



Universidade Católica Dom Bosco

Curso de Bacharelado em Engenharia de Computação

Medição Automática do Efeito de Herbivoria em Folhas  
de Soja Utilizando Técnicas de Segmentação e  
Aprendizagem Supervisionada

Diogo Sant'Ana Sarath

Prof. Dr. Hemerson Pistori

Trabalho de Conclusão de Curso apresentado à Coordenação do Curso de Bacharelado em Engenharia de Computação da Universidade Católica Dom Bosco como parte dos requisitos para a obtenção do título de Bacharelado em Engenharia de Computação.

UCDB - Campo Grande / MS - 11/2014

*Ao meu filho Douglas, que me motiva a nunca desistir*

# Agradecimentos

Primeiramente gostaria de agradecer a Deus por todas as oportunidades concedidas até hoje e pelas que ainda virão. Também agradeço a minha família, especialmente meus pais, Elcio Lopes Sarath e Geiza dos Remédios Pinto Sant'Ana Sarath e a minha irmã Lelia Maria Sant'Ana Amorim por estarem sempre ao meu lado me apoiando e proporcionando a ótima educação que tive e as oportunidades de estudo. Agradeço também a minha namorada Mayara da Costa Lopes por sua paciência e apoio durante essa caminhada cheia de obstáculos e por sua ajuda, estando sempre ao meu lado. Ao orientador Professor Dr. Hemerson Pistori pela paciência, dedicação e apoio durante todo o decorrer desse ano, proporcionando um grande aprendizado não somente em relação a esse projeto mas também na mudança da forma de pensar, ele está sempre moldando os seus orientandos para que se tornem verdadeiros pesquisadores. A todos os professores que passaram seu conhecimento durante as aulas ajudando diretamente na formação profissional e moral da turma. Aos companheiros do grupo INOVISÃO que sempre estiveram dispostos a auxiliar, sempre buscando a melhoria do grupo como um todo, também aos meus colegas de turma, os poucos "sobreviventes" que restaram e dividiram comigo essa importante etapa da vida, muitos se tornaram verdadeiros amigos, em especial ao Victor Borges Jussiani que trabalhou diretamente comigo no projeto, na implementação dos métodos e no decorrer de seu projeto de graduação. A meu chefe e supervisor de estágio na maior parte do ano Me. Thalles Torchi que sempre foi compreensivo com minhas responsabilidades relativas a faculdade e sempre apoiou o desenvolvimento profissional e intelectual. Por fim um agradecimento aos meus empregadores atuais da Compnet por me proporcionar uma flexibilidade de horário para que consiga assistir as aulas que ainda restam.

# Resumo

Este trabalho visa a implementação de uma ferramenta para medição automática dos danos causados pela herbivoria nas folhas de soja. As plantas, em geral, ao sofrerem predação por alguma doença ou praga, estimulam a produção de compostos químicos de defesa que as deixam mais resistente à ataques futuros [2]. Para os experimentos foram utilizadas lagartas *Spodoptera frugiperda* [4]. Conhecer essa resposta ao ataque é importante no desenvolvimento de estratégias de resistência de plantas e controle de insetos e pragas. Inicialmente foram realizados experimentos para a captura das imagens referentes às folhas de soja e elas foram processadas utilizando segmentação por limiarização [31], [23] com base no histograma HSB que obteve medições com correlação muito forte em relação às medições manuais de referência e, segundo o teste T de *Student*, não houve diferença significativa entre as medições usando um nível de confiança de 95% e 0,05% de significância. Posteriormente foi construída uma aplicação para processamento em superpixel's [1], [34] para medição de área foliar com possibilidade de medição de outras regiões de interesse simultaneamente. Os resultados foram comparados com as medições de referência através da análise de variância ANOVA onde foi verificado que não existem evidências estatísticas de que as médias dos diferentes métodos sejam diferentes. Por fim, foram realizados testes de correlação para verificar qual modelo foi mais preciso em relação a medição de área comparando com a referência e o método baseado em Limiarização foi o que apresentou a correlação mais forte com as medições de referência.

# Sumário

1. Introdução .....	11
2. Trabalhos correlatos.....	14
2.1 Medição computacional de área foliar.....	14
2.1.1 Direta .....	16
2.1.2 Indireta.....	17
3. Fundamentação teórica.....	19
3.1 Aspectos Biológicos .....	20
3.2 Visão Computacional .....	22
3.3 Segmentação de Imagens .....	23
3.3.1 Segmentação por Limiarização.....	24
3.3.2 Segmentação em Superpixels .....	26
3.4.1 SLIC.....	28
3.4 Extração de atributos .....	31
3.4.1 Cor .....	31
3.5 Aprendizagem Automática .....	33
3.5.1 Adaboost.....	34
3.5.1 Random Tree .....	36
3.5.1 SVM – Máquinas de Vetores de Suporte.....	37
3.6 Suavização da imagem.....	38
3.6.1 Filtro da Mediana .....	38
4. Metodologia.....	39
4.1 Captura de imagens e montagem do banco .....	39

4.2 Modelo Proposto Baseado em Limiarização .....	43
4.3 Modelo Proposto Baseado em Superpixel .....	44
4.3.1 Aprendizagem.....	45
4.3.2 Segmentação.....	49
4.3.3 Cálculo de área foliar .....	51
5. Resultados, análise e discussão .....	53
5.1 Resultados da Limiarização .....	54
5.2 Análise da Taxa de Acerto dos Classificadores .....	56
5.3 Resultados da Segmentação por Superpixel .....	57
5.3.1 Adaboost.....	57
5.3.2 Random Tree.....	60
5.3.3 SVM.....	62
5.4 Comparação e Avaliação .....	66
5.4.1 ANOVA .....	66
5.4.2 Teste de Correlação .....	67
6. Conclusões e trabalhos futuros .....	73
Referências .....	74

# Lista de Figuras

Figura 1: Cálculo de área utilizando método dos quadrados.....	15
Figura 2: Exemplo de medição para método de dimensões foliares. ....	19
Figura 3: Spodoptera frugiperda em folha de soja. ....	21
Figura 4: Histograma HSB com as faixas de mínimo e máximo selecionadas.....	25
Figura 5: Exemplo de imagem segmentada em superpixel.....	26
Figura 6: Exemplo de imagem segmentada em superpixel SLIC.....	28
Figura 7: Espaço de cor CIELAB.....	29
Figura 8: Imagem segmentada em superpixels SLIC.....	31
Figura 9: Representações do modelo de cores RGB. ....	32
Figura 10: Representação do modelo de cores HSB. ....	33
Figura 11: Combinação de Classificadores feita pelo Adaboost. ....	34
Figura 12: Modelo de funcionamento das Maquinas de Vetores de Suporte. ....	37
Figura 13: Exemplos da imagem depois de ser filtrada utilizando a mediana. ....	39
Figura 14: Exemplos de imagens da mesma folha pós herbivoria (a) e como era inicialmente (b). ....	41
Figura 15: Câmera em posição para coleta de imagens. ....	42
Figura 16: Moldura de fundo para posicionamento da folha de soja. ....	43
Figura 17: Exemplo de imagem processada pela limiarização.....	44
Figura 18: Modelo Proposto Baseado em Superpixel. ....	45
Figura 19: Aprendizagem – Ferramenta de aprendizagem implementada.....	46
Figura 20: Aprendizagem - Extração de superpixels.....	47

Figura 21: Aprendizagem – Selecionado com a cor verde os superpixels da classe folha e com marrom da classe não folha.....	48
Figura 22: Modelo executado pela Aprendizagem. ....	49
Figura 23: Segmentação – Ferramenta de segmentação implementada. ....	49
Figura 24: Modelo Executado pela Segmentação.....	51
Figura 25: Segmentação – Imagens segmentadas pelos classificadores. ....	51
Figura 26: Modelo executado pelo Cálculo de área Foliar. ....	52
Figura 27: Cálculo de área foliar – Imagens após a aplicação do filtro de mediana. ....	53
Figura 28: Folhas segmentadas pelo método Adaboost. ....	59
Figura 29: Imagens segmentadas pelo método Random Tree.....	62
Figura 30: Imagens segmentadas pelo método SVM.....	65
Figura 31: Correlação da área foliar obtida pela Limiarização com a obtida através de contagem manual. ....	68
Figura 32: Gráfico relativo a correlação da área foliar obtida pela Limiarização com a obtida através de contagem manual.....	68
Figura 33: Correlação da área foliar obtida pelo método Adaboost com a obtida através de contagem manual. ....	69
Figura 34: Correlação da área foliar obtida pelo método Adaboost com a obtida através de contagem manual. ....	69
Figura 35: Correlação da área foliar obtida pelo método Random Tree com a obtida através de contagem manual. ....	70
Figura 36: Correlação da área foliar obtida pelo método Random Tree com a obtida através de contagem manual. ....	70
Figura 37: Correlação da área foliar obtida pelo método SVM com a obtida através de contagem manual. ....	71

Figura 38: Correlação da área foliar obtida pelo método SVM com a obtida através de contagem manual. .... 71

# Lista de Tabelas

Tabela 1: Área foliar antes da herbivoria Limiarização.....	54
Tabela 2: Área foliar depois da herbivoria Limiarização .....	55
Tabela 3: Área foliar antes da herbivoria Adaboost.....	57
Tabela 4: Área foliar depois da herbivoria Adaboost.....	58
Tabela 5: Área foliar antes da herbivoria Random Tree .....	60
Tabela 6: Área foliar depois da herbivoria Random Tree .....	61
Tabela 7: Área foliar antes da herbivoria SVM.....	62
Tabela 8: Área foliar depois da herbivoria SVM .....	63
Tabela 9: Análise estatística sobre os métodos .....	66
Tabela 10: ANOVA – Single Factor.....	67
Tabela 11: Valores obtidos no teste de Correlação.....	72

# 1. Introdução

O Brasil, no período recente, tem apresentado um quadro de grande crescimento no agronegócio, destacando-se a produção brasileira da soja, do complexo sucroalcooleiro e do café [15]. Embora tenham ocorridos avanços nas técnicas de cultivo, essas produções tem enfrentado problemas em relação a como lidar com as doenças e pragas que atacam as lavouras [19].

Considerando-se que a soja [*Glycine max (L.) Merrill*] teve colheita de seis milhões de toneladas em 2012/2013, a quinta maior produção nacional [15], pode-se verificar que ela é um dos principais produtos agrícolas do MS. A mesma possui sua produtividade ameaçada pela lagarta *Spodoptera frugiperda* [4] e a compreensão do mecanismo de defesa da soja é de grande importância para a busca de alternativas menos agressivas de controle desta praga e/ou para o desenvolvimento biotecnológico de plantas mais resistentes. Dessa forma, medir a área foliar de soja automaticamente para um conjunto de imagens se torna extremamente relevante, pois pela variação de área consumida é possível inferir qual tratamento está ajudando a diminuir a predação [3].

O objetivo do projeto foi criar uma alternativa para o usuário que não tenha custo como nos integradores de área foliar, os quais serão detalhados nos trabalhos correlatos, e que possibilite ao usuário aprimorar sua medição utilizando atributos além da cor, como textura e forma, aplicando em quantas imagens desejar utilizando um dos classificadores gerados. Podendo assim não só mensurar o tamanho de uma folha em relação ao que é “não folha” na imagem, mas também adicionar e identificar outras classes como uma área danificada por um tipo de doença na folha e escolher qual dos classificadores oferece um melhor resultado para o problema.

Inicialmente foi criado um banco de imagens de folhas de soja, que será descrito na seção de Metodologia. O banco de imagens foi processado primeiramente utilizando a segmentação por limiarização de imagens coloridas

por ser uma técnica que a ferramenta utilizada (ImageJ<sup>1</sup> em Java) já possuía e havia sido utilizada previamente pelo grupo INOVISÃO (Grupo de Pesquisa, Desenvolvimento e Inovação em Visão Computacional), nesse caso foi preciso achar o limiar padrão das imagens para fazer a medição.

No módulo final o processamento é feito utilizando segmentação por Superpixel's [1],[34], por ser uma técnica recente que ajuda a processar mais rapidamente as imagens agrupando os pixels. Também identifica melhor formatos irregulares na imagem do que os métodos que utilizam aproximações quadradas, como o método dos quadrados que será explicado em Trabalhos Correlatos, pois seu formato se adapta de acordo com a segmentação.

Para validar os resultados foram realizadas medições de referência utilizando o método dos quadrados (apresentado na seção 2.1) em algumas amostras de cada subgrupo do banco de imagens (explicado na seção 4.1). Essas medições foram comparadas com os resultados dos métodos propostos utilizando testes de Correlação, T *Student* (para limiarização somente) e análise de variância ANOVA.

O modelo baseado em limiarização foi analisado de maneira isolada primeiramente pois foi implementado na primeira parte do projeto, mas depois foi comparado com modelo baseado em superpixels. Segundo o teste T de Student não houve diferença significativa entre as medições da limiarização e referência usando um nível de confiança de 95% e 0,05% de significância.

A análise do modelo baseado em superpixels foi realizada separando os resultados de seus algoritmos de aprendizagem automática. Eles foram comparados utilizando a análise de variância junto com as respostas da limiarização e a referência, onde foi verificado que também não há diferença significativa entre os resultados utilizando a mesma significância do teste T.

De acordo com os resultados as medições são pertinentes considerando o parâmetro de medição de área. Por fim foi analisada a correlação de cada modelo (e no caso do superpixel de cada algoritmo de aprendizagem automática) com a

---

<sup>1</sup> <http://imagej.nih.gov/ij/> - Image Processing and Analysis in Java

referência, onde pode-se observar que as medições que obtiveram as respostas mais correlacionadas foram as da limiarização.

Como propostas futuras podem ser feitos ajustes nos parâmetros dos algoritmos de aprendizagem automática utilizando para isso outras métricas além da precisão de resposta na quantidade de área foliar. Como o software foi construído com objetivo também de ser adaptável para cada problema através da configuração das classes, atributos e classificadores que deseja utilizar, também poderá ser aproveitado em outros projetos do grupo INOVISÃO, por exemplo na identificação e classificação de estrias na pele humana.

## 2. Trabalhos correlatos

Este capítulo descreve trabalhos correlatos obtidos na literatura a respeito da medição computacional de área foliar separados em dois subitens. O primeiro é referente a aplicação de técnicas para a medição direta da área, que utilizam medidas diretamente nas folhas. O segundo diz respeito aos métodos de medição indireta, que são baseados na correlação conhecida entre a variável medida e a área foliar.

### 2.1 Medição computacional de área foliar

Os métodos destrutivos são aqueles que necessitam a retirada da folha e outras estruturas e que muitas vezes não são possíveis devido a limitação do número de plantas na parcela experimental. Já os não destrutivos evitam a retirada das folhas, preservando as plantas.

Até a década de 2000 a medição da área de folhas através de imagens era realizada de forma complexa comparado aos métodos atuais em relação ao tempo para execução e demanda de serviço. O contorno da folha da planta era esboçado manualmente em um papel milimetrado com algum marcador ou impresso como feito na Figura 1.

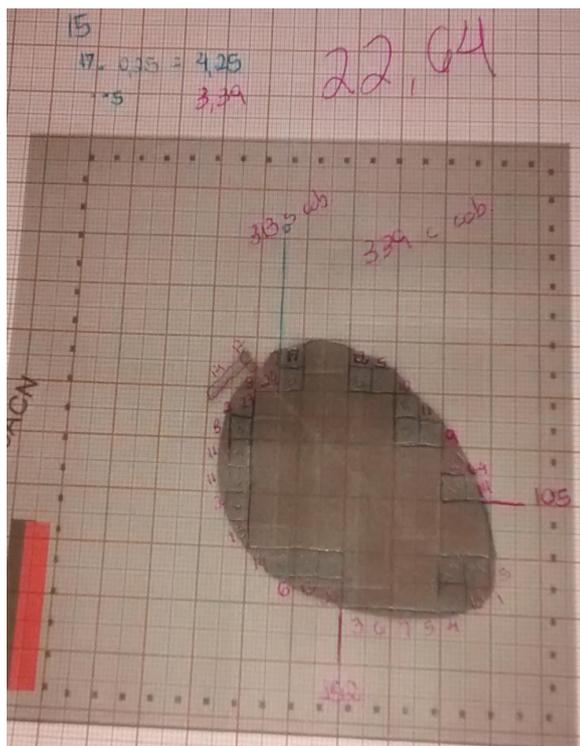


Figura 1: Cálculo de área utilizando método dos quadrados.

Em seguida, era realizada a contagem de cada um dos quadrados para obter o tamanho aproximado da área da folha (tal metodologia é conhecida como método dos quadrados [5]). Essa metodologia é precursora de grande parte dos métodos auxiliares atuais e ainda possui aplicações em determinados casos, como os que precisam medir folhas com falhas no seu interior.

Existem poucos trabalhos que revelam a eficiência do método dos quadrados, em virtude da grande quantidade de tempo gasto com a utilização do mesmo, além do maior número de pessoas envolvidas no processo, principalmente quando se trata de avaliações em um grande volume de material [5],[26]. No entanto, é um método muito eficaz em casos que, assim como este atacado neste trabalho, possui amostras em que as folhas estarão com alguns 'buracos' referentes aos ataques [2],[5].

Com o advento da computação foi possível que pessoas com conhecimento em desenho técnico estimassem o tamanho de cada folha escaneando a mesma e analisando as imagens em softwares de desenho, como,

por exemplo, o Autocad<sup>2</sup>. Entretanto exige-se que o profissional faça isso para cada imagem do conjunto, fazendo com que esse processo manual possa causar fadiga. Mas os métodos computacionais também possibilitaram o cálculo da área foliar utilizando medidas de variáveis correlacionadas, podendo assim calcular de forma direta ou indireta, e podendo ser destrutivos ou não.

### 2.1.1 Direta

Os métodos diretos utilizam medidas diretamente nas folhas para calcular a área foliar, como os integradores de área e o método dos quadrados. Foram criadas algumas soluções capazes de tal atividade, porém com o custo elevado. O aparelho *LI-COR*<sup>3</sup>, normalmente utilizado como referência, realiza cálculos para integrar a área da figura de acordo com sua leitura feita no seu scanner [2]. São aparelhos precisos, não fabricados no Brasil e por isso, são caros e de difícil manutenção. Além disso, alguns equipamentos têm dimensões que limitam a leitura em folhas grandes [18].

Segundo [18], a necessidade de um programa computacional (software) capaz de processar a imagem e calcular o resultado é uma das dificuldades da análise de área de uma figura, uma vez que os softwares que vêm embutidos no hardware de captura de imagem geralmente são de custo elevado (como os integradores) e que apesar de existir algumas versões de programas gratuitos, esses não possibilitam a criação de um classificador que utilize vários tipos de atributos e não dão suporte a execução de um classificador para um conjunto com várias imagens.

Alguns softwares já estão disponíveis para cálculo de área de foliar de forma direta, como o *SIARCS*<sup>4</sup>. Porém, eles, geralmente, não permitem processamento em lote de imagens e requer do usuário a escolha das cores que

---

<sup>2</sup> <http://www.autodesk.com.br/products/autocad/overview> AutoCAD®

<sup>3</sup> <http://www.licor.com/> - LI-COR Biosciences: leader in the design and manufacture of instrument systems for environmental and biotechnology research.

<sup>4</sup> <http://www.cnpdia.embrapa.br/produtos/siarcs.html> - Sistema Integrado para Análise de Raízes e Cobertura do Solo

serão consideradas no processo de segmentação, ou seja, utiliza somente o atributo de cor para essa medição.

O SIARCS (sistema integrado para análise de Raízes e cobertura do solo) foi desenvolvido pelo CNPDIA – Embrapa e possibilita além da análise de raízes, permite também o cálculo de área em folhas afetadas por doenças e pragas, bem como a distribuição de gotas em áreas irrigadas. O sistema trabalha com uma lógica supervisionada onde o usuário precisa indicar qual cor da imagem ele gostaria de dimensionar e isso causa certa lentidão no processamento de várias imagens.

Em [29] foi proposto um método de detecção de área foliar danificada tratando de aspectos como redução de ruído e contorno das folhas. Para a reconstrução das bordas foram utilizados segmentos de retas e com isso através da folha danificada é possível estimar o possível tamanho dela quando sadia, utilizando limiarização pelo método de Otsu [20],[23].

## 2.1.2 Indireta

Os métodos indiretos são baseados na correlação conhecida entre a variável medida e a área foliar. Por exemplo, [14] estudaram e indicaram a viabilidade de utilização do diâmetro do caule e ramos da lima ácida “tahiti” para estimativa da área foliar de forma mais rápida, simples e não destrutiva. Em [6] são utilizados o comprimento da nervura principal e a largura foliar para calcular a área da folha da erva-do-touro (*Tridax procumbens*) usando uma equação de regressão.

Lucena et al. [26] propuseram a medição da área foliar da aceroleira medindo através de vários métodos e comparando os resultados para a verificação de qual é o mais eficaz e menos agressivo ao meio ambiente. No estudo foram coletadas 60 folhas aleatoriamente, sendo 30 novas e 30 velhas de uma aceroleira oriunda de um pomar comercial. Depois de coletadas foram enviadas ao laboratório da UFERSA (Universidade Federal Rural do Semi-Árido). A análise foi feita através do método dos quadrados, dimensões lineares, integrador de área foliar AM 300, discos foliares e análise de imagem digital (capturadas por um scanner). Os dados obtidos foram submetidos a análise de

regressão, os métodos foram comparados com o método de referência (scanner), com base no critério de coeficiente de determinação ( $R^2$ ).

Por fim o método do integrador portátil AM 300 foi o que estimou a área foliar da aceroleira mais aproximada do padrão referencial de precisão, com maior coeficiente de determinação. Todos os métodos utilizados para estimar a área foliar se mostraram satisfatórios, ficando a critério do pesquisador sua utilização conforme o nível de precisão exigida.

Membros do IAPAR (Instituto Agronômico do Paraná) e INPE (Instituto Nacional de Pesquisas Espaciais) realizaram um estudo estimativo de área da folha de soja utilizando imagens digitais e dimensões foliares [2]. No estudo publicado os mesmos verificam métodos diretos ou indiretos e destrutivos ou não destrutivos para a análise. Eles comparam os métodos de dimensões foliares (C x L) utilizando aparelho para medição [6],[17]. O primeiro método baseia-se na relação entre a área foliar real e parâmetros dimensionais (largura e comprimento máximos), sendo muito utilizado devido a sua fácil execução e possibilidade de aplicação não destrutiva.

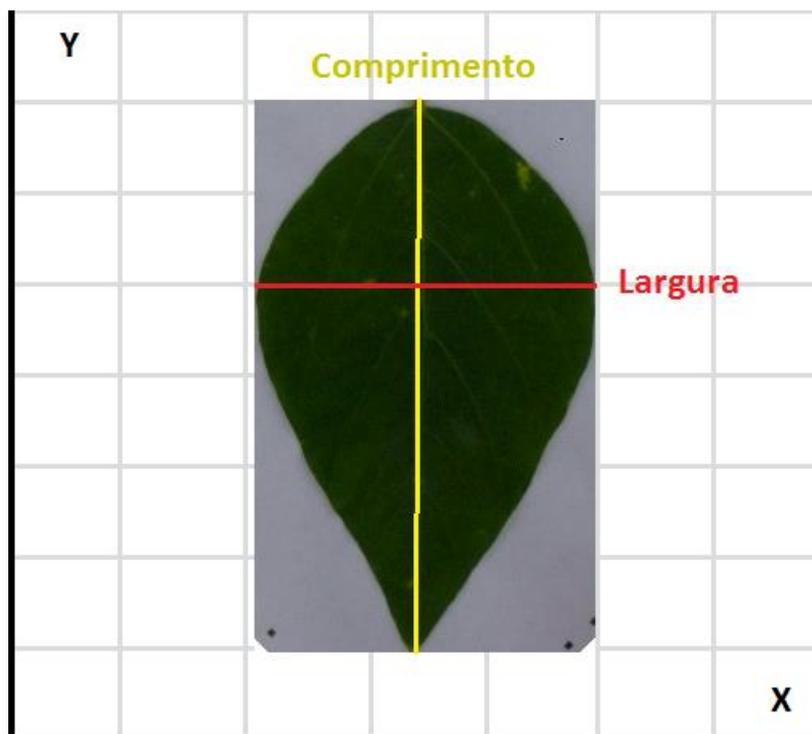


Figura 2: Exemplo de medição para método de dimensões foliares.

O método de dimensões foliares é menos preciso na estimativa de área foliar para folhas danificadas, já os métodos de imagem digital apresentam boas estimativas de área foliar, tanto para folhas normais quanto para danificadas, apresentando precisão similar ao aparelho integrador de área foliar LI-COR, mas sendo vantajoso devido à seu menor custo e sua portabilidade. Apesar do processamento ser realizado com imagens digitais, o projeto não contou com um software específico para essa análise e geração de relatórios.

### 3. Fundamentação teórica

Este capítulo descreve os aspectos biológicos e computacionais para o modelo proposto, que envolve a segmentação de imagens, extração de atributos, aprendizagem automática e suavização da imagem. Nos aspectos biológicos serão apresentados os parâmetros para os experimentos de coleta de imagens e explicação do processo nas plantas que justifica a análise de área foliar.

Posteriormente serão abordados assuntos relativos a visão computacional, segmentação de imagens, extração de atributos, aprendizagem automática.

### 3.1 Aspectos Biológicos

A análise de área foliar pode ser utilizada para, além de outros objetivos como indicativo de produtividade [16],[17], quantificar os danos causados por doenças e pragas. Saber com precisão a área foliar danificada é de grande importância para a determinação de ações de controle como aplicação de defensivos [29].

A soja possui sua produtividade, como visto anteriormente, ameaçada pela lagarta *Spodoptera frugiperda* [4]. Essa é uma praga que tem causado perdas significativas em várias culturas, como as de milho e soja [4],[9]. O nome dado para essa relação de predação de organismos vivos sobre plantas é herbivoria [9],[10]. Essa relação ecológica tem como consequência certas respostas desenvolvidas pelas plantas, geralmente que compensam os efeitos da relação ou criam resistência ao ataque [10].



Figura 3: *Spodoptera frugiperda* em folha de soja.

O ataque de herbívoros às plantas desencadeia a produção de compostos químicos como mecanismo de defesa. Esses compostos são denominados fitoalexinas [3],[12], que são produtos naturais ausentes na planta sadia, acumulados no local ou nos arredores da infecção. Essas substâncias apresentam atividades biológicas contra uma diversidade de agentes patogênicos [3]. Acredita-se que a maioria das plantas seja capaz de produzir fitoalexinas, mais algumas fazem de maneira muito lenta, permitindo que infestações completem o ataque antes que haja acúmulo dessas substâncias em quantidades suficiente para inibi-lo [10].

As plantas podem alterar seu metabolismo com a produção de substâncias no sentido de desenvolver mecanismo de proteção (resistência induzida) contra o próprio herbívoro [9]. De acordo com [7],[25], resistência induzida é o aumento quantitativo ou qualitativo dos mecanismos de defesa, em resposta a estímulos intrínsecos e/ ou extrínsecos como aqueles provocados por herbivoria, patógenos

e injúrias mecânicas (recortes de partes de folhas utilizando uma tesoura ou estilete), por exemplo.

O controle em lavouras é feito, geralmente, por meio de inseticidas sintéticos, que nem sempre são eficientes, pois tendem a encarecer os custos de produção e ainda podem deixar resíduos no ambiente e nos alimentos. Dentre outros métodos de controle, a utilização de plantas com atividade inseticida pode ser uma alternativa viável [19].

## 3.2 Visão Computacional

A visão computacional, ou visão de máquina, é uma área de conhecimento que procura desenvolver técnicas e métodos para à extração e interpretação de informações úteis contidas em imagens [23],[43]. Em geral, busca igualar a visão e a capacidade de interpretação humana a partir de dispositivos de captura de imagens [35].

Embora a interpretação de imagens seja trivial a muitos seres humanos, algumas tarefas relativamente simples, como identificar e analisar folhas em imagens, apresentam-se como grandes desafios para sistemas automáticos de visão computacional. Para que os sistemas de visão computacional consigam realizar essas tarefas os mesmos precisam passar por várias etapas [36], que se organizam de maneira independente, ou seja, em alguns casos as tarefas podem ser resolvidas sem a utilização de todas elas.

Geralmente é feito um pré-processamento para redução de ruídos (regiões que contém informações que não são relevantes para determinada análise) e com isso aumentar a qualidade das imagens [36]. Posteriormente uma segmentação (que visa separar informações ou separar pontos de interesse na imagem [43] e será explicada na próxima seção) que pode também utilizar extração de características e por fim o reconhecimento de padrões. No reconhecimento de padrões são utilizados algoritmos (geralmente de aprendizagem supervisionada, explicado na seção de aprendizagem automática) para identificar os objetos de interesse da imagem através das suas características. Os objetos que forem de

um mesmo tipo são agrupados em classes, sabendo quais classes compõem a tarefa é possível que o sistema identifique de qual classe o objeto pertence podendo assim ser feita a classificação da imagem de acordo com a tarefa [36].

### 3.3 Segmentação de Imagens

O processo de segmentação consiste em subdividir uma imagem em duas ou mais regiões homogêneas, considerando algumas de suas características intrínsecas, como, por exemplo, a cor ou a proximidade dos pixels [20].

As técnicas de segmentação são baseadas geralmente na definição geral que apresenta quatro condições para um processamento correto: todos os pixels da imagem devem pertencer a uma região; as regiões devem ser conectadas; todos os pixels de uma dada região devem ser considerados similares e por fim o resultado final deve satisfazer todas as três condições anteriores. A escolha do método de segmentação é uma tarefa importante na obtenção de um algoritmo apropriado para a resolução do problema, pois define até qual nível a subdivisão em regiões deve ser realizada [27],[42].

A segmentação é um processo natural e comum para o ser humano, porém complexo para um computador, pois nossos sistemas biológicos reconhecem e interpretam os objetos assim que os veem a partir de um conjunto de informações que são combinadas e processadas em paralelo no cérebro. Para o ser humano ver, ele precisa interpretar o significado das variações de intensidade de luz e cor que chegam aos olhos. Computacionalmente é complexo conseguir reproduzir com exatidão esse reconhecimento e interpretação, por outro lado em alguns casos a visão computacional pode compensar as deficiências da visão humana para identificar algumas frequências mais altas ou mais baixas de imagens que os limites suportados pela visão humana [21],[23].

### 3.3.1 Segmentação por Limiarização

O princípio da limiarização consiste em separar as regiões de uma imagem em duas ou mais classes, e definir qual é a classe ou grupo delas que é interessante para a resolução do problema [21]. O limiar (valor limite, pode ser o valor máximo ou mínimo) tem como base as características derivadas dos componentes perante um modelo de espaço de cores escolhido no caso de imagens coloridas ou no caso de imagens em tons de cinza corresponde a intensidade do tom de cinza [31]. Por exemplo, em imagens em tons de cinza, podemos definir, de acordo com algum critério pertinente à aplicação, que os pixels com valores abaixo de 100 (limiar) serão considerados como parte do objeto, enquanto os outros serão considerados como irrelevantes.

A limiarização envolve a utilização de histogramas para estabelecer o critério de uniformidade e, no caso de imagens coloridas, são utilizados os histogramas conforme o espaço de cores escolhidos. Nesses casos, em que lidamos com mais informações por pixel que nas imagens em tons de cinza, deve-se escolher qual sistema de cores (ou combinação de sistema de cores) será utilizado. Além disso, a definição de limiar pode ser mais complexa, dado que, na maioria dos casos, o espaço de representação de cores utilizado é tridimensional, o que implica na definição de 3 limiares [31].

O processamento pode ser comprometido dependendo da quantidade de cores que será utilizada para representar o objeto ou região. Logo, a escolha correta do sistema e a simplificação da imagem colorida possibilitam uma melhor identificação e análise de objetos [23].

Os espaços de cores mais comuns são o RGB (*red, green e blue*), que representam as cores através da mistura em várias possibilidades de intensidade dessas três cores primárias; e o HSB (também chamado de HSV), composto pela matiz (do inglês *hue*), a saturação (do inglês *saturation*) e o brilho (do inglês *brightness*), em que as cores são representadas basicamente pela tonalidade (matiz), pureza da cor e brilho [31].

Logo, para uma limiarização, caso o espaço de cor escolhido seja o HSB, haverá 3 pares de limiares, um para cada componente, possibilitando a filtragem

de pixels que estejam dentro das faixas de limiares estabelecidos. Na Figura 4 temos um histograma HSB que mostra a seleção dos limiares para os três componentes: matiz, saturação e brilho.

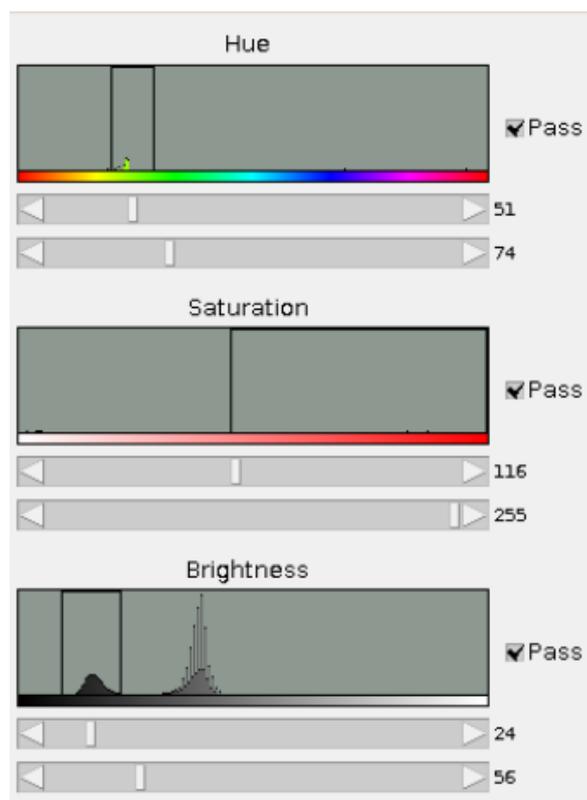


Figura 4: Histograma HSB com as faixas de mínimo e máximo selecionadas.

Um histograma é um gráfico que representa a variação sobre uma faixa específica de dados [21]. Na Figura 4 temos um histograma HSB aonde estão selecionados os limiares para a matiz, saturação e brilho. Pode ser observado que para a matiz estão selecionados os limiares 51 e 74 e na *checkbox* está marcado *pass* para selecionar os dados que estiverem entre esses valores, que pela imagem também podemos ver que representam o mínimo e máximo para representar a cor verde.

### 3.3.2 Segmentação em Superpixels

Malik et al [42] propuseram uma solução em agrupamento de pixels em regiões coerentes, com características comuns de cor, textura e brilho dentro da região. Eles desenvolveram um classificador para combinar características como contorno, textura, brilho e continuidade agrupando-as. Essas regiões com características similares são denominadas superpixels [1],[27].

Desta maneira os superpixels devem formar um bom agrupamento de pixels resultando em uma boa segmentação da imagem em regiões, de modo que seja possível identificar uma mesma região em partes diferentes da imagem. Superpixels podem causar um aumento substancial em relação a velocidade de processamento da imagem desde que o número de superpixels não seja muito grande, de 25 a 2500 em média [34].

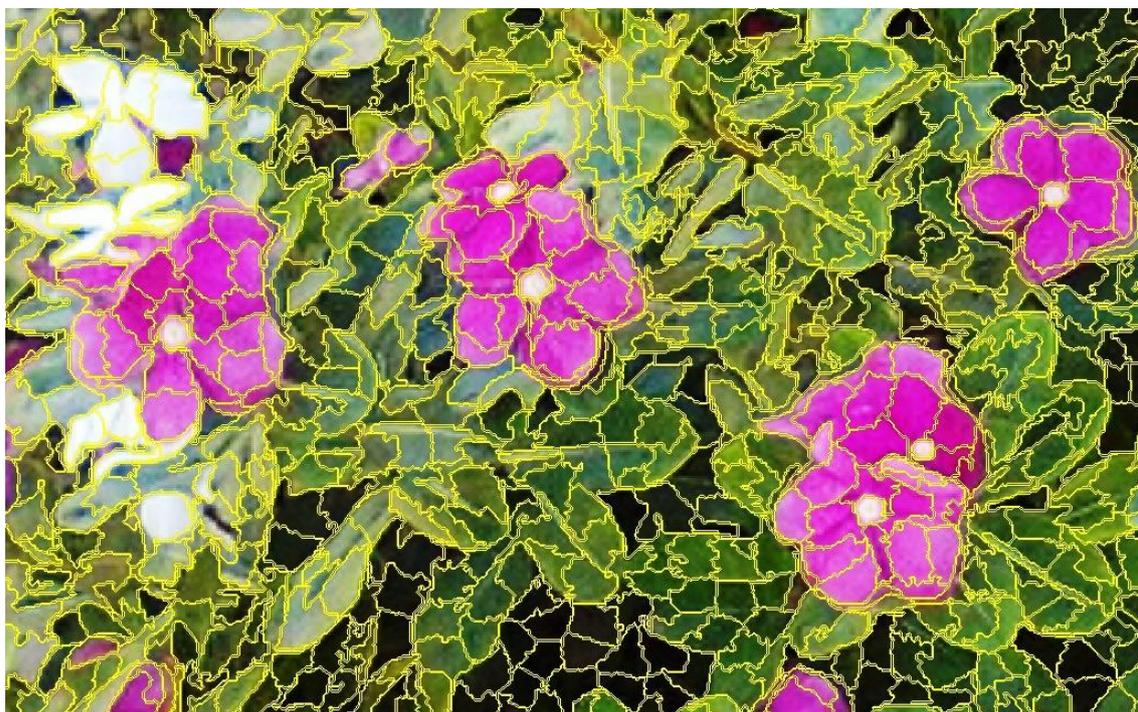


Figura 5: Exemplo de imagem segmentada em superpixel.

A desvantagem do uso dos superpixels se dá pela etapa de pré-processamento que exige um maior esforço computacional para construção das unidades pelo risco de perder dados relativos a bordas da imagem colocando-as

dentro de um superpixel. Por isso é importante escolher corretamente qual algoritmo será utilizado e seus parâmetros[1],[34].

Existem várias formas de agrupar regiões similares em superpixels, a mais comum foi a introduzida por Malik [41], onde é realizado o algoritmo *Normalized Cut*. Esse algoritmo é aplicado a imagem para obter o mapa dos superpixels. Para isso, o *Normalized Cut* particiona a imagem em regiões disjuntas com coerência dos atributos contorno e textura.

Este algoritmo utiliza as características da imagem de forma interligada obtendo um grafo ponderado, onde os pixels são os nós e o peso das arestas ligando os nós é definido por uma função de similaridade entre pixels, considerando características como contorno e textura. A segmentação é processada como um particionamento de grafos, no qual é calculada a discrepância entre os diferentes grupos e a semelhança entre os elementos do mesmo grupo. A aplicação mais popular para esse algoritmo é a adaptação denominada *N-Cuts* proposto por Shi [41],[42].

Dadas as definições iniciais, foi necessária a criação de conceitos para definir a similaridade. A similaridade pode ser intra-região, na qual os elementos internos de um superpixel são definidos como similares de acordo com critérios como brilho, textura e fracos contornos no interior dessa região. Entre diferentes regiões deve haver uma dissimilaridade, na qual esses critérios são diferentes entre as regiões [40].

Os métodos baseados em grafos são indicados para casos onde a precisão em relação a borda das formas na figura são de grande importância [1], mas o *Normalized Cut* não possui eficiência tão boa em relação a precisão nas bordas e atualmente é um dos métodos mais lentos, principalmente para imagens grandes. Para o processamento nesse trabalho foi utilizado o método SLIC que é um método mais rápido e eficiente em relação ao uso de memória [1].



Figura 6: Exemplo de imagem segmentada em superpixel SLIC.

### 3.3.3 SLIC

O SLIC (*Simple Linear Iterative Clustering*) é uma adaptação do algoritmo *K-means* para a geração de superpixel [1]. O número de cálculos de distância é reduzido pois o espaço é limitado proporcionalmente ao tamanho de um superpixel, reduzindo assim a complexidade para ser proporcional ao número de pixels e independente do número de superpixels.

Para a geração dos superpixels o algoritmo combina cor e proximidade espacial (otimizando a detecção das bordas) enquanto controla o tamanho e a quantidade de unidades [1]. O algoritmo é simples, por padrão o único parâmetro é  $k$ , que corresponde ao número de superpixels ajustados na imagem.

A aplicação forma agrupamentos locais de pixels no espaço 5-D definido por  $L$ ,  $a$ ,  $b$  (valores da escala CIELAB de cor) e as coordenadas  $x$  e  $y$  dos pixels. Por isso tem uma medição de distância diferente que permite a regularidade nas formas dos superpixels e possibilita a utilização em imagens em tons de cinza também [22].

O espaço de cor CIELAB é uma aproximação de escala uniforme de cor, onde as diferenças no espaço correspondem a diferenças visuais. O mesmo é organizado de forma que  $L^*$  é um eixo vertical que no valor máximo (100) representa o branco e o mínimo (0) representa o preto, e existem os eixos  $a^*$  e  $b^*$  horizontais que não tem valores máximos numéricos mas como referência tem o valor de 60 unidades de cor. O valor de  $a^*$  positivo traz uma tendência para o vermelho e negativo para o verde, já o valor de  $b^*$  positivo corresponde ao amarelo e negativo ao azul.

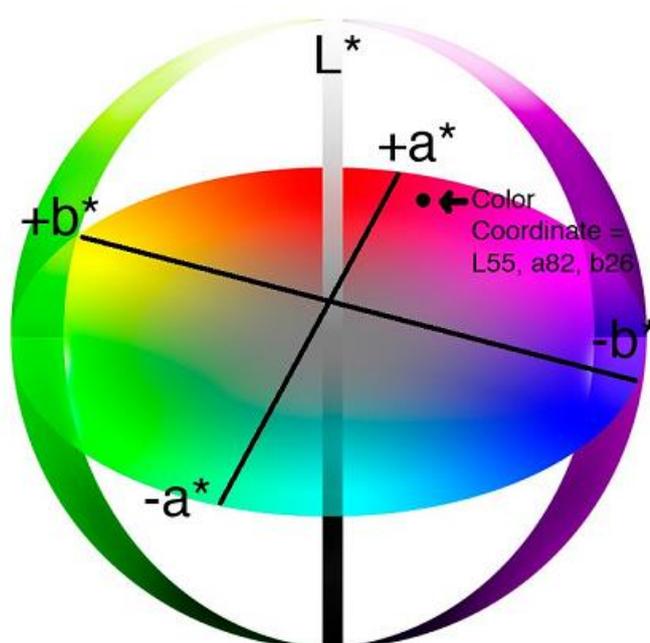


Figura 7: Espaço de cor CIELAB.

O método gera as unidades agrupando os pixels com base na sua semelhança e proximidade de cor no plano da imagem, o CIELAB é considerado um espaço de cor uniforme para pequenas variações de cor. Não é aconselhável utilizar simplesmente distância euclidiana no espaço 5D pois a mesma excede o limite percentual de distância em cor e com isso perde-se a precisão, portanto foi introduzida uma nova medida de distância que considera o tamanho do superpixel [1].

Como entrada temos o número  $k$  que corresponde à quantidade de unidades equalizadas (com a mesma densidade de pixels), logo cada superpixel

terá aproximadamente  $\frac{N}{k}$  pixels. Assim para unidades de tamanho igual haveria um centro em cada intervalo da grade  $S = \sqrt{N/K}$ . Os centros dos agrupamentos de superpixel  $C_k = [l_k, a_k, b_k, x_k, y_k]$  com  $k = [1, K]$  são escolhidos, espaçados em um grid regular para formar os agrupamentos de tamanho aproximado  $S^2$ , podendo ser definido como a área de  $2S \times 2S$  em torno do centro do superpixel no plano xy [1],[34]. Os centros são movidos para o valor de menor gradiente sobre uma vizinhança de  $3 \times 3$  pixels, evitando a alocação do centróide em regiões de bordas ou que tenham pixels ruidosos.

A distância final pode ser entendida como:

1.  $d_{Lab} = \sqrt{(l_k - l_i)^2 + (a_k - a_i)^2 + (b_k - b_i)^2}$
2.  $d_{xy} = \sqrt{(x_k - x_i)^2 + (y_k - y_i)^2}$
3.  $D_s = d_{lab} + \left(\frac{m}{S}\right) * d_{xy}$

Onde  $D_s$  é a soma da distância  $d_{Lab}$  (1) e a distancia  $d_{xy}$  (2) normalizada pelo intervalo  $S$ . A variável  $m$  corresponde ao controle de compactação do superpixel, quanto maior o seu valor mais a proximidade espacial é enfatizada e mais compactado é o agrupamento [34].

Cada pixel da imagem é associada a um centro mais próximo de um grupo cuja área de busca sobrepõe este pixel, depois de todos os pixels estarem associados a um centro, um novo centro é calculado com o vetor  $Lab_{xy}$  de todos os superpixels que pertencem ao grupo. No final do processo alguns pixels podem ficar conectados a um grupo incorretamente, e por isso o algoritmo reforça a conectividade na última etapa atribuindo os pixels sozinhos aos maiores grupos vizinhos [34].

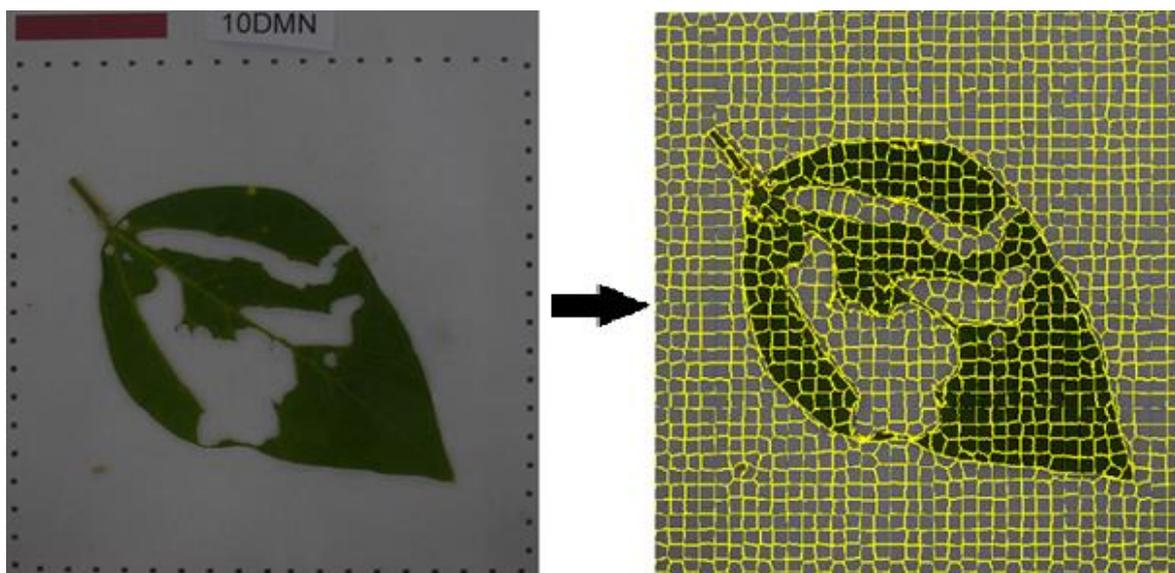


Figura 8: Imagem segmentada em superpixels SLIC.

### 3.4 Extração de atributos

A extração de atributos procura identificar informações relativas a características de modo que através desses dados possam ser identificados objetos semelhantes por valores semelhantes e diferenciar se os valores forem distintos [30],[39]. As informações que melhor representem o objeto ou o dado são coletadas para posterior classificação dos mesmos em relação as classes do experimento.

O tipo de atributo que deve ser coletado está relacionado ao problema em questão, pois através dessas informações será preciso discriminar todas as classes possíveis [36]. Nesse projeto foram utilizados os atributos de cor, mas também podem ser utilizados alguns atributos de textura e forma implementados na biblioteca que contém os extratores utilizados pelo grupo INOVISÃO.

#### 3.4.1 Cor

Como visto anteriormente podemos representar cores através de vários espaços, como o CIELAB que foi explicado e é utilizado para a segmentação em superpixels, e também o RGB e o HSB citados anteriormente, que foram os

utilizados na extração de atributos. Também podem ser analisadas imagens em tons de cinza, onde são possíveis geralmente 256 tonalidades pois possuem 8 bits para guardar essa informação [36].

O modelo RGB é baseado na variação e combinação de cores primárias (vermelho, verde e azul). Cada cor é representada também por 8 bits, ou seja, pode ter 256 variações de tom e ao combinar as variações podemos ter mais de 16 milhões de cores diferentes [36]. O modelo pode ser representado em um sistema de coordenadas cartesianas XYZ onde o eixo x corresponde a cor verde, o eixo z a cor vermelha e o y a cor azul, nesse caso o ponto  $P1(0,0,0)$  corresponde a cor preta e o branco ficaria no ponto  $P2(1,1,1)$ . Também pode ser representado por uma seção plana, onde as cores representadas por círculos combinadas formam outras cores [39].

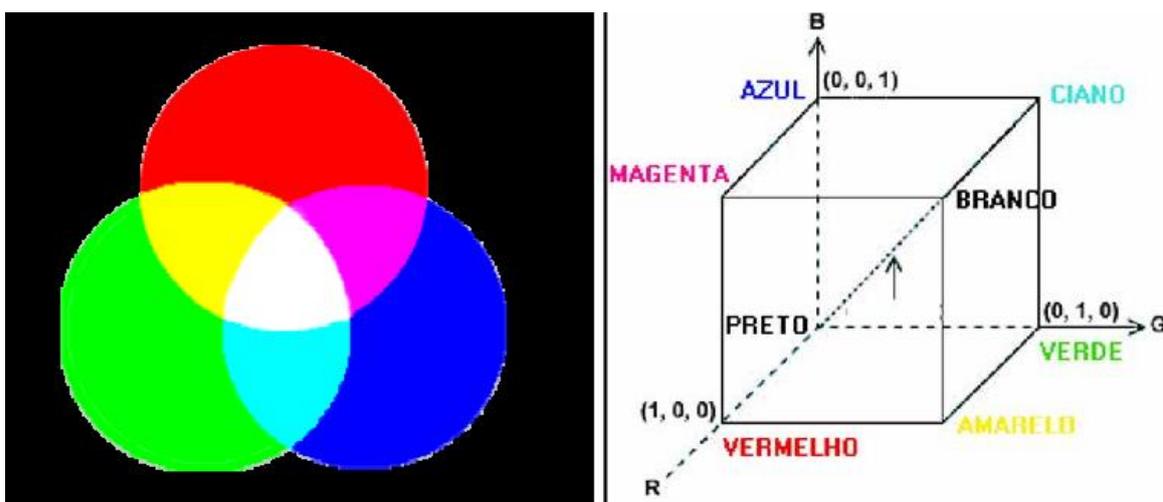


Figura 9: Representações do modelo de cores RGB.

O modelo de cores HSB (também chamado de HSV) é bastante utilizado na manipulação e processamento de cores em imagens. O modelo foi baseado na visão humana e é composto pela matiz (hue) que é o atributo relacionado ao comprimento de onda dominante. A matiz é responsável pela cor dominante percebida por um observador. Também composto pela saturação, que representa a pureza da imagem. Ou seja, a saturação representa o quanto a cor(matiz) foi

amenizada pela luz branca [21]. E, por fim, o brilho que corresponde a intensidade de luz separando assim as cores mais claras das mais escuras [36].

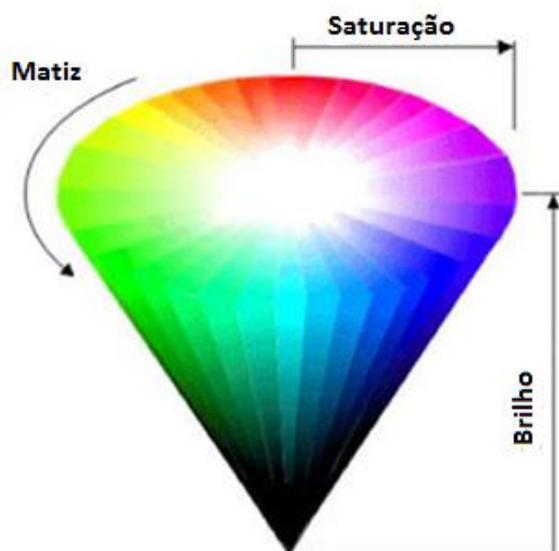


Figura 10: Representação do modelo de cores HSB.

### 3.5 Aprendizagem Automática

O processo de aprendizagem automática está ligado a etapa de reconhecimento de padrões, que seria identificar uma categoria de padrões com base em informações relativas para que pudesse ser feita a distinção [37]. Os algoritmos que realizam esse reconhecimento também são chamados de classificadores, a aprendizagem automática é um dos métodos que vem sendo mais utilizado atualmente, consiste na utilização de instâncias (amostras) para treinar a identificação das classes [37].

A aprendizagem pode ser feita de maneira supervisionada ou não. A forma supervisionada consiste em montar o conjunto de treinamento com amostras já classificadas previamente (baseia-se em experiências acumuladas contidas no treinamento) e a não supervisionada utiliza conjuntos de instâncias gerados a partir dos padrões de entrada. Neste trabalho foi utilizada a aprendizagem supervisionada de maneira automática como foi explicado na seção específica, os

métodos utilizados foram escolhidos na biblioteca de classificadores do WEKA<sup>5</sup> e serão descritos a seguir.

### 3.5.1 Adaboost

O Adaboost é um algoritmo que é utilizado para melhorar a performance de outro algoritmo de aprendizagem. A ideia geral é que combinando vários classificadores mais simples é possível gerar um classificador mais preciso [37],[28], como mostrado na Figura 11. Dessa forma, a cada passo que o Adaboost é executado o mesmo faz chamadas a um algoritmo de classificação e por isso o peso dos exemplos (amostras) deixando assim a aplicação focada em exemplos mais difíceis.

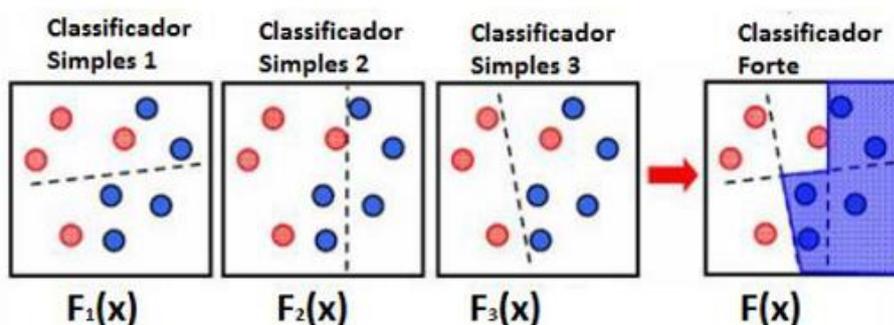


Figura 11: Combinação de Classificadores feita pelo Adaboost.

Inicialmente o algoritmo foi construído para encontrar um classificador binário que diferenciava entre exemplos verdadeiros e falsos. A entrada para a etapa de aprendizagem é um conjunto de exemplos de treinamento na forma  $(x_n; y_n)$ ;  $n = 1, \dots, N$ , onde cada  $x_n$  é um exemplo e  $y_n$  é um valor booleano (verdadeiro ou falso) correspondente a classe do  $x_n$ . Para que os classificadores simples sejam aprimorados, eles são aplicados para resolver uma sequência de problemas de aprendizagem, depois de cada rodada dessa etapa os exemplos são redistribuídos e o peso dos classificados incorretamente é aumentado a fim

<sup>5</sup> <http://www.cs.waikato.ac.nz/ml/weka/> Data Mining Software in Java

de induzir o algoritmo a focar-se nos exemplos mais complexos [37],[28]. O classificador aprimorado adquire a forma de uma rede *perceptron*: uma combinação ponderada de métodos simples seguidos de uma limiarização. Grandes pesos são atribuídos a funções com boa classificação enquanto as menos precisas tem pesos menores na rede.

O método Adaboost foi projetado para atender problemas de classificação binária como visto anteriormente, mas para processar imagens de meio ambiente é preciso lidar com múltiplas classes. Para esses casos foram criadas abordagens como uma sequência otimizada de classificadores binários como proposto por [28] ou mudanças no algoritmo como o Adaboost M2 idealizado por Freund e Shapire em 2001.

Mozos et al [28] implementaram a variação Adaboost M2 que é capaz de lidar com múltiplas classes. Neste modelo os classificadores simples possuem um argumento adicional que representa a classe do exemplo do treinamento. A ideia principal é reduzir a hipótese multiclasse em hipóteses binárias, para isso cada método simples é decomposto em  $K$  classificadores, sendo  $K$  o número de classes total, e com isso processa-los separadamente tratando como uma classificação binária.

Outra alternativa foi proposta em [28] onde alguns classificadores binários foram organizados na forma de uma lista de decisão. A cada passo da lista um método simples verifica se o exemplo pertence a uma classe específica, se a resposta é positiva o exemplo é assumido como classificado corretamente e se passar por toda a lista não sendo considerado como pertencente de nenhuma classe. Nesse caso é considerado como um erro na classificação e para tratar os erros é realizado um aumento nos pesos desse exemplo a fim de que a lista se foque mais nesse exemplo no próximo treinamento. A ordem dos métodos influencia diretamente no desempenho do processo, por isso em geral são ordenados de acordo com sua taxa de erro estimada pois os primeiros acabam processando mais exemplos.

Para o processamento nesse projeto foi utilizada a implementação do Adaboost presente na biblioteca do WEKA que é o Adaboost M1 [28]. Ele é um

classificador binário que para esse problema foi construído utilizando a ideia proposta para poder processar problemas multiclasse.

A abordagem M1 serviu de base para construção do M2 e possui a mesma lógica de processamento. Sua desvantagem em relação ao M2 é o baixo desempenho quando as hipóteses propostas pelos classificadores simples possuem um erro médio que não é muito baixo, e em alguns problemas esses exemplos de bom desempenho de treinamento podem não ser encontrados com facilidade. No geral o Adaboost M2 permite que os classificadores gerem hipóteses mais expressivas, melhorando o desempenho da aprendizagem.

### 3.5.2 Random Tree

A Random Tree é um modelo de árvore que considera  $n$  atributos escolhidos aleatoriamente em cada nó da árvore. É um conceito de árvore de regressão induzido por amostras bootstrap (reamostragem) e é geralmente utilizado como base de outros métodos como Random Forests. Para cada nó de sua árvore são escolhidos aleatoriamente  $n$  atributos que irão direcionar o nó, com base na melhor discriminação de classes do conjunto de treinamento em relação a alguma métrica. No projeto foi utilizado o modelo de Random Tree disponível na biblioteca do WEKA para a montagem do classificador.

As Random Forests [47] classificam uma instância utilizando um conjunto de Random Trees, o método combina o resultado de cada árvore por um mecanismo de eleição. Cada árvore dá uma classificação e por fim a classe que recebeu mais votos em toda floresta é dada como a classe correta para aquela instância. Para cada árvore gerada é utilizado um conjunto de treinamento diferente formado por instâncias escolhidas aleatoriamente, geralmente a quantidade de atributos para cada árvore deve ser bem menor que o total de atributos para que possam ser geradas árvores diferentes, as quais serão combinadas para classificar uma determinada instância.

### 3.5.3 SVM – Máquinas de Vetores de Suporte

As máquinas de vetores de suporte (*Support Vector Machine – SVM*) são utilizadas para treinamento de classificadores e tem como uma de suas vantagens o alto poder de generalização, pois suas hipóteses não se baseiam no número de atributos e sim no grau de separação dos dados [37]. Por esse motivo sua utilização em classificação de dados em imagens é interessante, já que geralmente o tamanho dos vetores de atributos é grande.

O funcionamento da SVM se dá pela separação dos dados em duas classes através da construção de um hiperplano para separação das mesmas, de forma que os dados pertencentes a um dos lados assumem o valor de 1 e do outro lado é atribuído o valor -1. Um hiperplano ótimo realiza a separação dos dados com a maior margem possível, para a determinação da margem é feita a soma das distancias entre os pontos positivos e negativos próximos ao plano, os quais são denominados de vetores de suporte [37],[11], como exemplificado na Figura 12. O conjunto de treinamento realiza a coleta de amostras e posteriormente é determinado a qual grupo as amostras pertencem com base no hiperplano e em casos onde os dados não são separáveis linearmente o hiperplano é criado baseando-se na transformação dos dados iniciais por algoritmos de separabilidade de padrões como funções de núcleos, função polinomial, entre outras [11],[33].

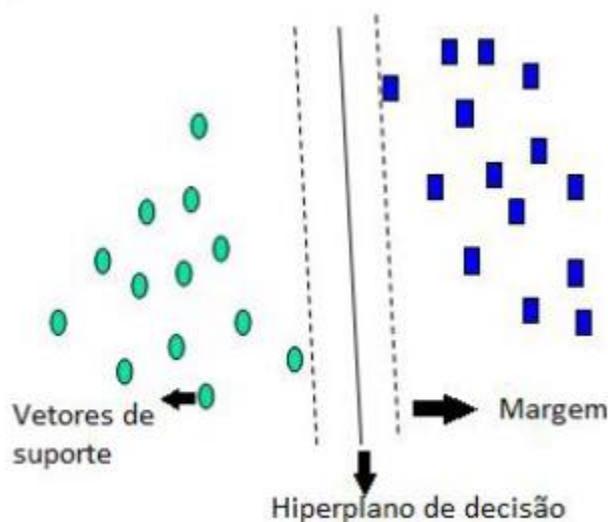


Figura 12: Modelo de funcionamento das Maquinas de Vetores de Suporte.

Para a aplicação foi utilizado o método SMO (mínima sequência de Otimização) que está disponível na biblioteca do WEKA. É um algoritmo que visa uma rápida solução para o problema quadrático da SVM, dividindo-o em vários subproblemas mais simples que podem ser resolvidos minimizando o uso de memória ao não armazenar dados [37]. Sua maior vantagem inclusive é selecionar sempre o menor problema para otimizar a cada interação, otimizando e ajustando a SVM. Apesar de ser mais simples o método aumenta o número de interações para ser executado. É uma abordagem de classificação binária mas pode ser realizada de maneira a separar as classes e executar as comparações na forma de lista de decisão assim como foi realizado no Adaboost.

## 3.6 Suavização da imagem

Após a segmentação a imagem é binarizada de acordo com suas classes mas a borda que divide os limites dos superpixels ainda existe na imagem, podendo interferir na contagem de área posterior. Os filtros de média, mediana e moda produzem o efeito de suavização na imagem, reduzindo variações de níveis de cinza entre pixels adjacentes e podem ser utilizados para diminuição de ruído e interferências [44], assim como pode ser utilizado para conexão de pequenas descontinuidades em linhas e curvas [22].

Por outro lado, as técnicas de suavização se utilizadas sem ajuste correto de parâmetros podem gerar borramento, com isso perdendo detalhes como linhas finas e curvas agudas [38]. Na aplicação desenvolvida foi utilizado um filtro de mediana para eliminar os ruídos causados pelas divisões em superpixel's.

### 3.6.1 Filtro da Mediana

A filtragem por mediana consiste na análise de cada pixel, sendo o seu nível de cinza substituído pela mediana dos níveis dos pixels adjacentes [44]. A mediana de um conjunto de pixel's pode ser entendida como o valor do pixel da

posição central se o número de pixels for ímpar e pode ser também a média entre dois pixels nas posições centrais se a quantidade for par.

Com a implementação dessa técnica é obtida uma redução do ruído e diminui-se o borramento que pode ter sido causado por outros filtros de suavização como o filtro de média. Um dos problemas da sua utilização é o seu custo computacional, pois precisa ordenar os valores da vizinhança, o que pode deixar o processamento lento [23],[38].

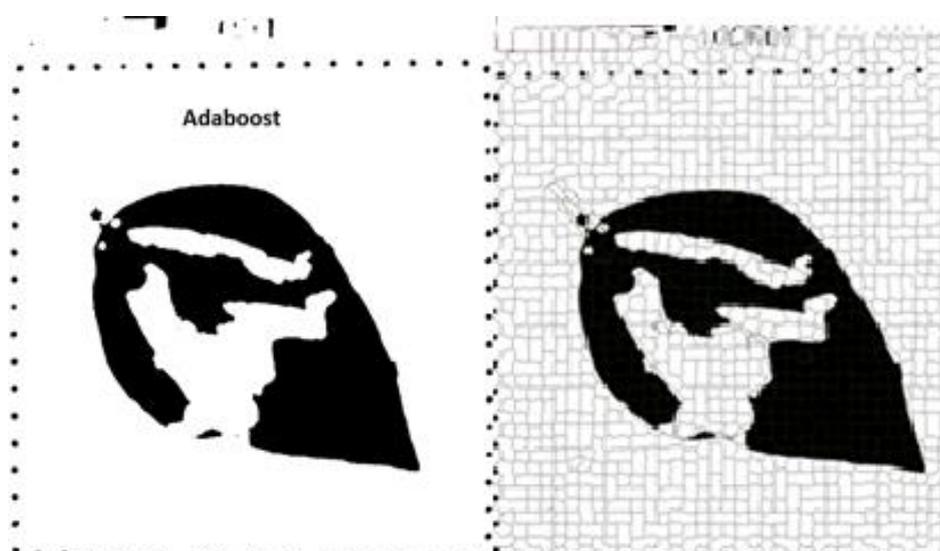


Figura 13: Exemplos da imagem depois de ser filtrada utilizando a mediana.

## 4. Metodologia

### 4.1 Captura de imagens e montagem do banco

Para a coleta de imagens das folhas de soja foram utilizadas folhas de plantas (soja) transgênica e comum. Antes da coleta, as plantas que ofereceram as folhas para o experimento passaram por três diferentes tratamentos. Um grupo

de plantas sofreu o ataque das lagartas em algumas de suas folhas (Esse grupo foi denominado Spodoptera); outro grupo sofreu danos mecânicos manuais em algumas de suas folhas (denominado Mecânico); e, no último grupo, não houve dano nas folhas (denominado Controle). Em cada um dos grupos, foram separadas as amostras de soja comum das amostras de soja transgênica, produzindo assim 6 subgrupos diferentes de plantas que ofereceram folhas sadias para o experimento (as folhas que foram danificadas no processo de tratamento das plantas não foram utilizadas).

A coleta de lagartas para a criação estoque foi feita em lavouras de milho ou soja no início das safras agrícolas e, posteriormente, foram levadas ao laboratório para criação em estoque. Elas foram alimentadas com folhas de soja até a idade de 10 dias e ficaram em jejum por 24 horas antes da infestação, em que foi utilizada uma lagarta por folha, mantidas em gaiolas de voal individuais, por 24 horas.

De cada um dos subgrupos, foram digitalizadas 25 folhas livres de ataques ou danos. Posteriormente, essas folhas foram separadas individualmente num recipiente próprio, onde foi introduzida uma lagarta para realizar a predação, a fim de comparar por fim se os tratamentos feitos na planta antes da coleta das folhas utilizadas no experimento causa alguma mudança na quantidade consumida de folha, sendo isso medido pela comparação da área antes e depois. Após 24 horas de herbivoria, foram realizadas novas coletas de imagens das folhas, pós ataque, e, por fim, foi construído o banco de imagens para processamento pelos métodos implementados.

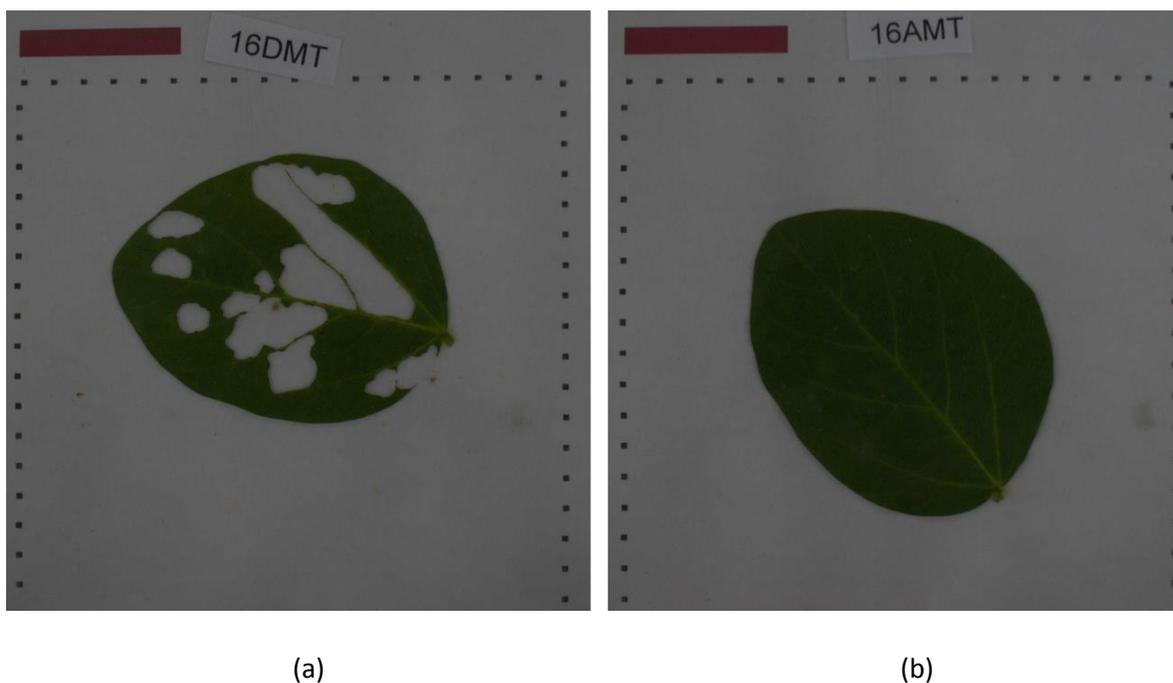


Figura 14: Exemplos de imagens da mesma folha pós herbivoria (a) e como era inicialmente (b).

Para a captura das imagens foi utilizada a câmera Sony Alpha DSLR-A350, utilizando a resolução máxima, de 14.2 MP, sem flash, que estava apoiada com um tripé comum e posicionado o obturador para baixo de forma que o campo de visão fique em 90° para baixo a uma distância média de 30 centímetros da mesa.



Figura 15: Câmera em posição para coleta de imagens.

Na mesa, foi fixada uma folha de papel A4 branco que continha uma moldura impressa pontilhada para onde o foco da câmera estava ajustado, onde as folhas de soja eram posicionadas. Acima da moldura, foi impresso um retângulo com 3 centímetros de largura e 0,5 centímetro de altura, que foi utilizado no processamento para estabelecer uma escala de conversão entre pixel e centímetros nas medições que foram realizadas pelos softwares.



Figura 16: Moldura de fundo para posicionamento da folha de soja.

## 4.2 Modelo Proposto Baseado em Limiarização

Para o processamento inicial de imagens foi utilizada a linguagem de programação Java, com auxílio da biblioteca de processamento e análise de imagens ImageJ.

Com base nas variações de colorações das folhas das amostras, foi definido um limiar selecionando pequenas áreas de várias folhas e verificando quais eram os valores mínimos e máximos para as componentes do modelo HSB (matiz = 51 a 74; saturação = 116 a 255 e brilho = 24 a 56). Com isso foi possível o processamento de todas as imagens e, adicionalmente, foi ajustada a escala de conversão média entre pixels e centímetros com base nos retângulos de

calibração de algumas amostras, alcançando a conversão de 216,9 pixels para um centímetro.

O sistema inicialmente duplica cada imagem contida na pasta indicada pelo usuário. Na cópia da imagem, foi feito um redimensionamento (diminuindo o tamanho da imagem) para eliminar os ruídos, retirando a moldura e o retângulo de calibração, restando somente a folha no centro da imagem. Posteriormente, o sistema realizou a segmentação baseada no limiar estabelecido do padrão HSB, destacando assim os pixels desejados da imagem. Por fim realizou-se a contagem desses pixels através da escala que foi estabelecida inicialmente para a obtenção da área.

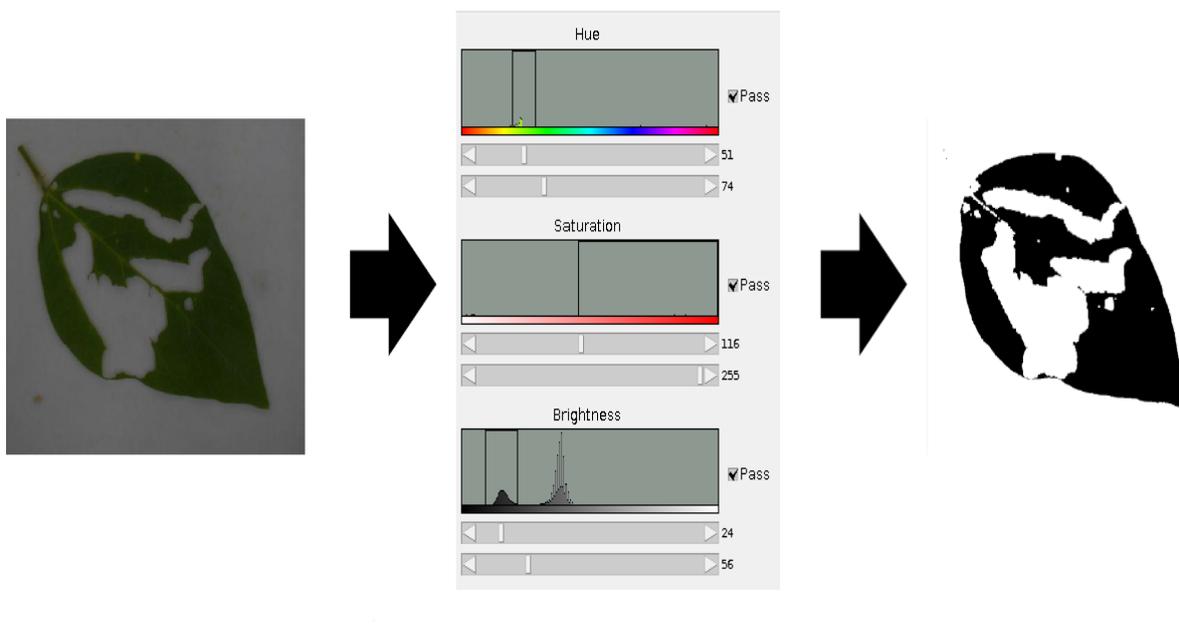


Figura 17: Exemplo de imagem processada pela limiarização.

### 4.3 Modelo Proposto Baseado em Superpixel

O modelo baseado em Superpixel foi dividido em três partes, na primeira foi feita a aprendizagem por parte da aplicação, é onde o usuário treina o classificador fornecendo a ele exemplos de instâncias e suas respectivas classes. Isso é feito pela identificação dos superpixels e marcação por parte do usuário de

qual superpixel representa determinada classe, conforme será explicado na seção 4.3.1.

A segunda etapa realiza a segmentação através dos classificadores. O usuário seleciona uma ou mais imagens e depois as classifica com algum dos classificadores gerados na primeira parte, como será exemplificado na seção 4.3.2. A resposta da segunda etapa é uma imagem segmentada para cada classe, de onde é possível mensurar o tamanho que cada classe ocupa em relação a alguma referência ou a imagem inteira como será explicado na seção 4.3.3.

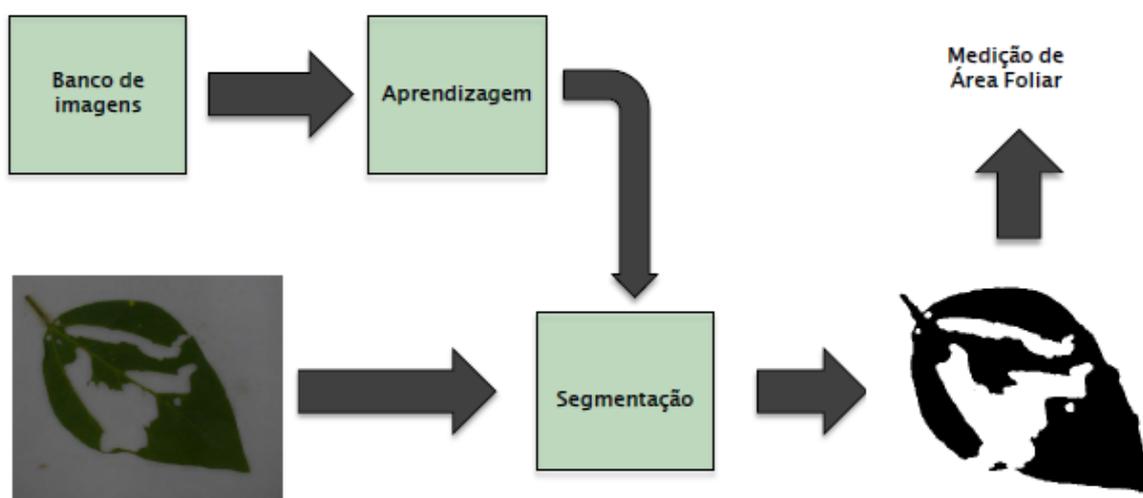


Figura 18: Modelo Proposto Baseado em Superpixel.

### 4.3.1 Aprendizagem

A aprendizagem pode ser realizada utilizando a ferramenta desenvolvida, na qual é possível cadastrar as classes que serão utilizadas no problema (através do arquivo de configuração em XML). A aplicação também suporta a utilização de varias imagens para gerar o arquivo .arff que contém as informações relativas aos superpixels. O ARFF é um arquivo no formato padrão do WEKA onde são descritos todos os atributos e todas as classes, por fim são colocados os valores correspondentes a cada atributo para um determinado dado e sua classe

correspondente. Com o .arff é gerado os model's que são os classificadores que deverão ser utilizados na Segmentação.

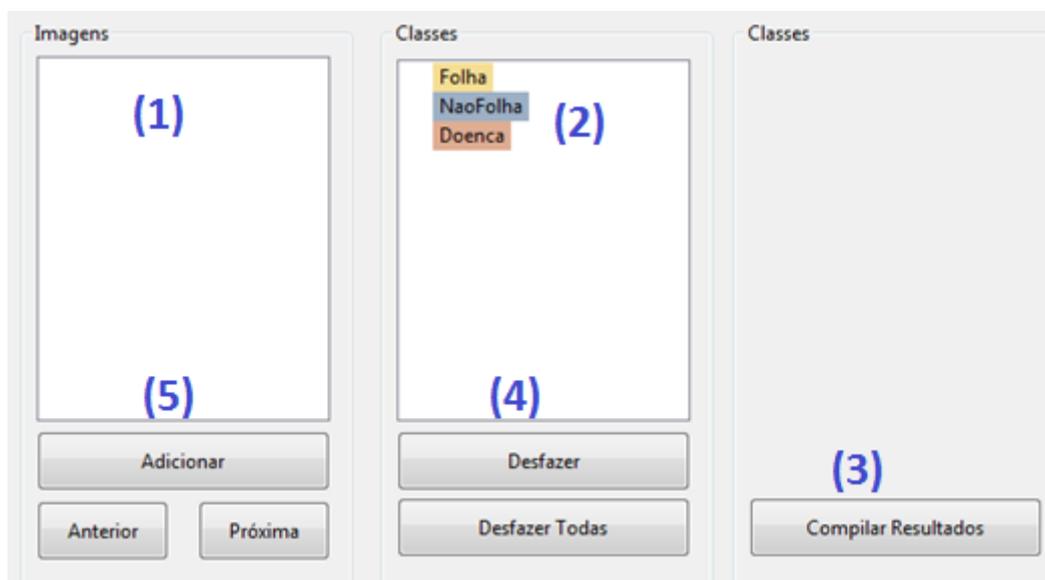


Figura 19: Aprendizagem – Ferramenta de aprendizagem implementada.

- (1) Espaço destinado a Lista de imagens;
- (2) Classes cadastradas no arquivo .XML;
- (3) Botão para processar as marcações realizadas e gerar o arquivo Arff e os classificadores;
- (4) Botões para desfazer a última ou todas as marcações na imagem;
- (5) Botões para adicionar uma imagem;

A aprendizagem se inicia com a segmentação da imagem em superpixels, para isso o usuário deve clicar em Adicionar (5) e escolher uma ou mais imagens que irá utilizar para fazer as marcações. A aplicação leva alguns segundos para segmentar as imagens em superpixels e depois que foram processadas são listadas no campo Imagens (1). O usuário ao clicar no título de alguma imagem da lista irá visualizar a imagem conforme a figura abaixo:

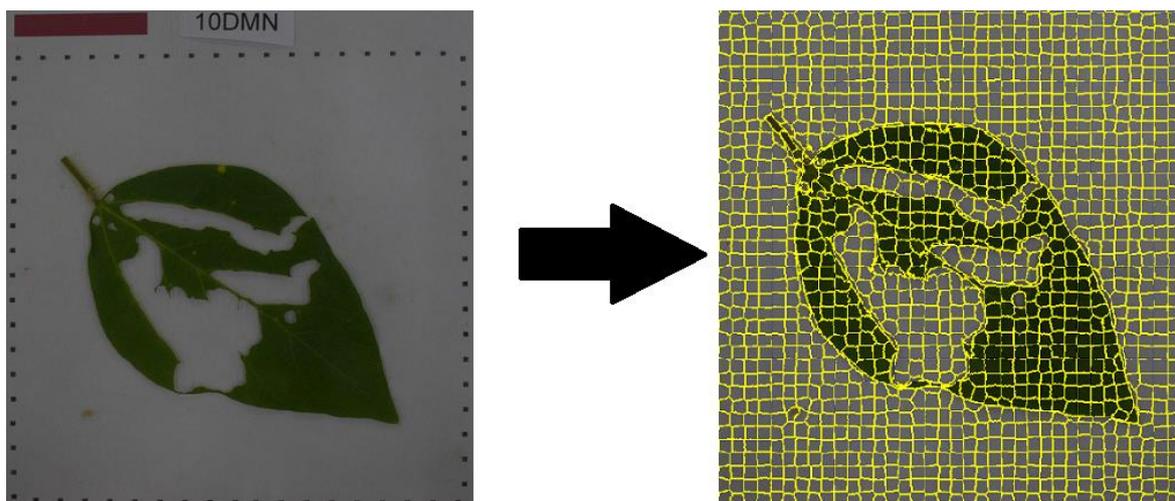


Figura 20: Aprendizagem - Extração de superpixels.

Posteriormente o usuário poderá fazer as marcações na imagem segmentada. É um processo que pode ser repetido em várias (sendo a quantidade definida pelo usuário) imagens para que o classificador seja construído com um conjunto de instâncias maior e treinado com um número maior de dados, possibilitando que ele consiga identificar com maior precisão os superpixels. Para realizar as marcações deve ser selecionada uma das classes do campo (2) e por fim clicar no superpixel que represente aquela classe e o mesmo será pintado com a cor que estiver colorido o título da classe no campo (2), esse processo pode ser feito para quantos superpixels o usuário desejar.

Depois de marcados os representantes de uma das classes, deve-se selecionar também os superpixels das outras classes, para isso basta clicar em outra das classes do campo (2) e repetir o processo de marcação. Como resultado a imagem ficará com pixels coloridos conforme a cor da classe na tela da aplicação.

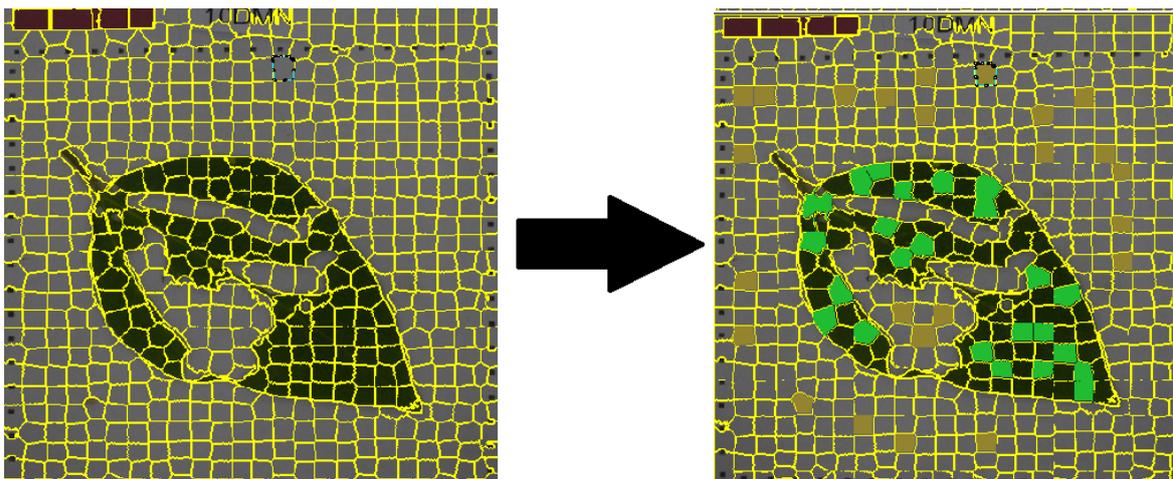


Figura 21: Aprendizagem – Selecionado com a cor verde os superpixels da classe folha e com marrom da classe não folha.

Após a seleção das unidades que representam cada classe (em quantas imagens o usuário desejar) pode ser realizado o processamento das marcações, através do botão Compilar Resultados (3). Ao clicar é realizada, primeiramente, a extração dos atributos dos superpixels escolhidos. Com essas informações é possível que os classificadores aprendam a diferenciar e identificar todas as classes. Foram utilizados atributos de cor RGB e HSB, como saída desse processo é criado um arquivo .arff.

Com o .arff é possível criar classificadores utilizando a biblioteca do weka, esses algoritmos de aprendizagem automática são salvos como modelos (.model). Eles são criados automaticamente pela aplicação e são treinados com os dados presentes no .arff que foi gerado, ficando prontos para ser utilizados na etapa de Segmentação. Ao final da etapa de Aprendizagem são gerados um arquivo compactado que contém os modelos de classificador, o arquivo ARFF e as imagens recortadas de cada superpixel selecionado.

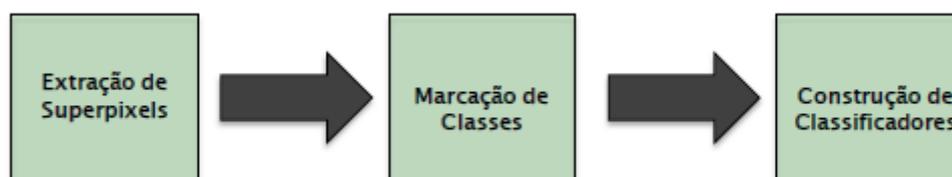


Figura 22: Modelo executado pela Aprendizagem.

### 4.3.2 Segmentação

A segmentação é a segunda parte do processo realizado pela ferramenta. Agora com os modelos treinados é possível classificar novas instâncias (superpixels de outras imagens que não foram utilizadas no treinamento) e com isso segmentar mais rapidamente em relação a identificação manual. Após a classificação a aplicação fornece a opção de mostrar a imagem segmentada ou salvar a imagem binarizando-a em relação as classes, por exemplo, é gerada uma imagem binarizada que diferencia se os superpixels são da classe folha.

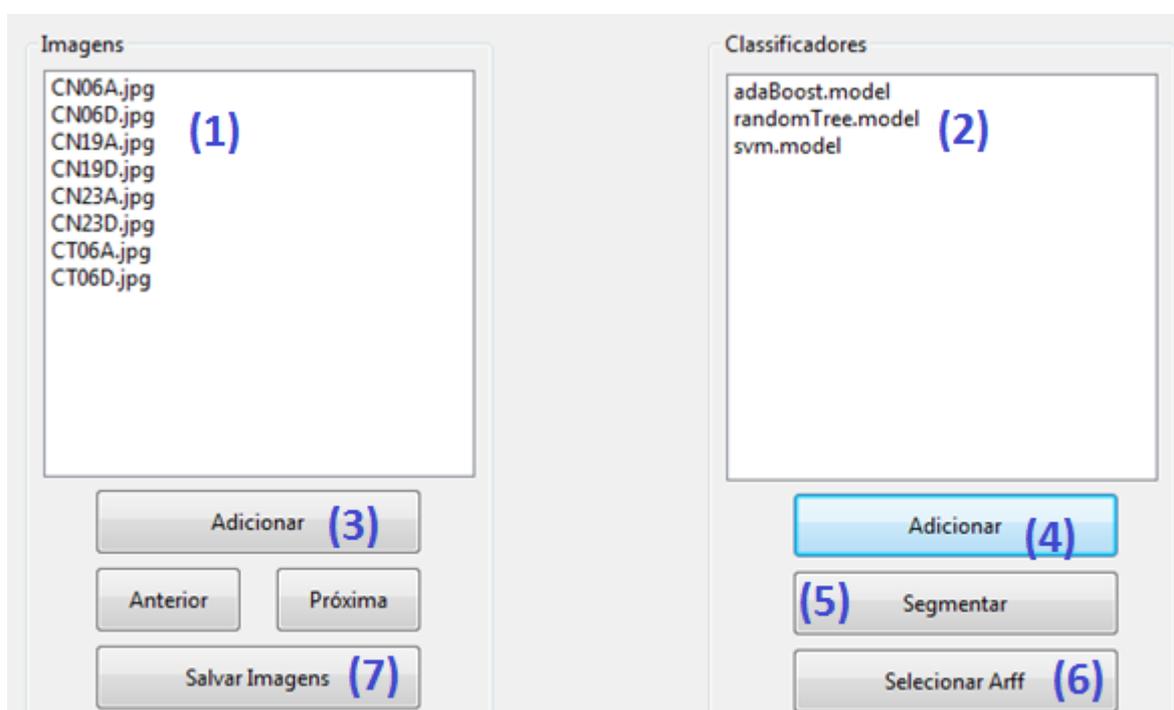


Figura 23: Segmentação – Ferramenta de segmentação implementada.

- (1) Espaço destinado a Lista de Imagens;
- (2) Espaço destinado a Lista de Classificadores
- (3) Botão para adicionar imagens;
- (4) Botão para adicionar classificadores;
- (5) Botão para para segmentar uma imagem selecionada na lista utilizando um classificador que esteja marcado;
- (6) Botão para seleção do ARFF;
- (7) Botão para segmentar todas as imagens da lista com base no classificador que esteja marcado;

Inicialmente na tela mostrada na figura 20 o usuário deve selecionar as imagens que deseja segmentar através do botão (3), em seguida selecionar os modelos de classificação pelo botão (4), por fim deve selecionar o ARFF que foi utilizado para criar os classificadores (6). O .arff ainda é necessário pois através dele a aplicação reconhece quais são os atributos que deve extrair das novas imagens e quais são as possíveis classes em que os superpixels serão classificados, com isso possibilita que mesmo que o usuário utilize outras classes e outros atributos na etapa de aprendizagem não atrapalhe o processo de segmentação.

O usuário tem a opção de segmentar somente uma imagem, ou todas da lista, para processar somente uma imagem deve selecionar uma da lista e depois selecionar um classificador, por fim clicar em Segmentar (5). O processamento é feito realizando a extração de superpixels da mesma forma que na aprendizagem. Cada superpixel da nova imagem será posteriormente analisado e identificado como membro de uma das classes pelos classificadores.

Para realizar a classificação, cada superpixel na nova imagem passa pela extração de atributos conforme foi especificado no ARFF que foi selecionado anteriormente. A classificação é feita pelos modelos de algoritmos gerados na etapa anterior, cada superpixel da imagem nova é uma instancia a ser

classificada, dessa forma através da análise dos atributos coletados é feita a identificação conforme as classes informadas. Por fim é exibida a imagem segmentada de acordo com suas classes.



Figura 24: Modelo Executado pela Segmentação.

O sistema também possibilita o processamento de todas as imagens da lista, cada imagem passa pelos mesmos procedimentos descritos anteriormente e o resultado é a binarização da imagem em relação a cada uma das classes, podendo, assim, o sistema medir quanto de área é ocupada por cada conjunto. O grupo de imagens processadas é salvo em um arquivo compactado no final do processo.

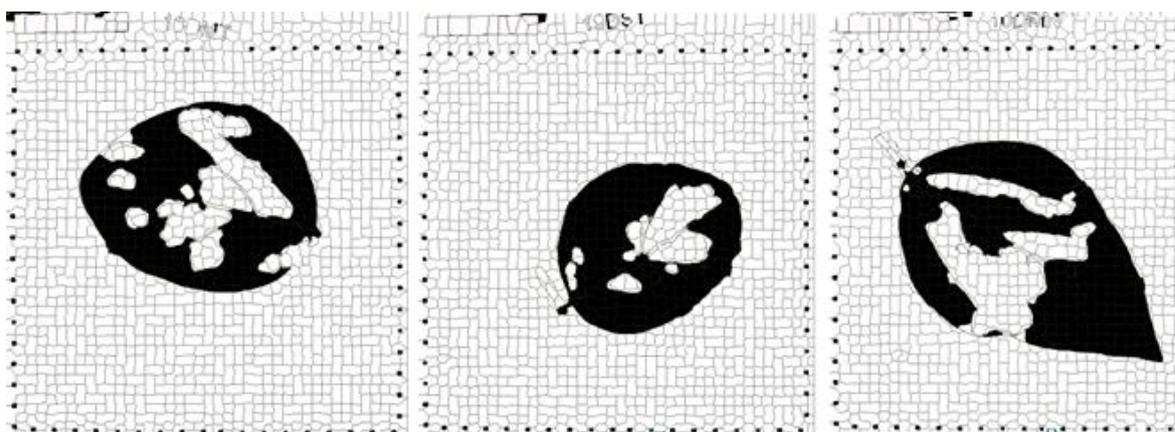


Figura 25: Segmentação – Imagens segmentadas pelos classificadores.

### 4.3.3 Cálculo de área foliar

Como a classificação realizada na etapa de Segmentação é feita processando todos os superpixels, ao identificar que um deles não pertence a uma determinada classe ele é apagado da imagem, mas o sistema mantém a referência de sua localização, esse fato ocasiona a presença das linhas de delimitação dos superpixels nas imagens binarizadas finais. Ainda não foi possível apagar os superpixels e suas referências de modo que não seja gerado nenhum erro no processamento pois os mesmos não são isolados, ao apagar um deles, outro iria perder sua referência de localização junto, impossibilitando-o depois de passar pela classificação.



Figura 26: Modelo executado pelo Cálculo de área Foliar.

Para que seja possível calcular a área da imagem de resultado da segmentação por superpixel é preciso que as linhas que delimitam essas regiões sejam removidas, e para isso foi utilizado um filtro de mediana, obtendo como resultado uma imagem onde é possível calcular diretamente a área ocupada pela classe, conhecendo a proporção de pixels para centímetros. A precisão na identificação dos superpixels e consequentemente na medição de área depende da precisão do algoritmo para realizar a classificação.

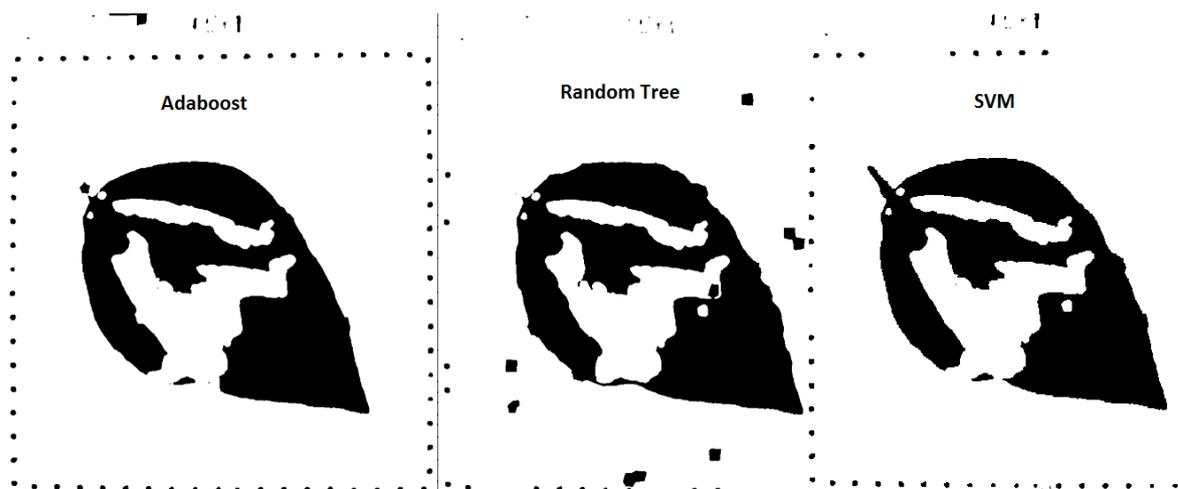


Figura 27: Cálculo de área foliar – Imagens após a aplicação do filtro de mediana.

## 5. Resultados, análise e discussão

Nesta seção serão apresentados os resultados da medição de área foliar das abordagens, e serão feitos testes estatísticos para verificar qual dos métodos teve um melhor desempenho no problema tratado.

As medições que foram utilizadas de referência para avaliação do desempenho da aplicação foram feitas utilizando o método dos quadrados [5], pois seu desempenho em casos em que as folhas estão com irregularidades mantém-se alto, ao contrário da maioria dos métodos, que, geralmente, são mais rápidos, pois utilizam medidas das folhas aplicadas em equações específicas para realizar a integração, mas acabam desconsiderando as irregularidades no interior das folhas. Para a medição foi feita a soma a cada milímetro quadrado na imagem e quadrados parcialmente preenchidos foram contados como totalmente preenchidos, fazendo assim uma aproximação nas bordas.

Devido a dificuldade e demanda maior de tempo para realização do método dos quadrados foram feitas 36 medições, sendo 18 de imagens antes da herbivoria e 18 para pós herbivoria. Foram selecionadas aleatoriamente 3 imagens de cada um dos subgrupos do banco de imagens.

## 5.1 Resultados da Limiarização

Os resultados obtidos com o modelo de limiarização e com a medição de referência estão apresentados nas Tabelas 1 e 2, correspondendo a análise entre as medidas de área antes e pós herbivoria, respectivamente. Os nomes das amostras seguem o padrão de identificação das folhas: a primeira letra representa o tipo de tratamento (S – plantas que tinham sofrido herbivoria com a *Spodoptera frugiperda*, M – plantas que sofreram danos mecânicos e C – plantas sadias de controle); a segunda letra indica se a amostra é comum (N) ou transgênica (T); seguidas pelo número da amostra no experimento. Por fim é apresentada a média ( $\bar{X}$ ) e o desvio padrão das medições ( $\sigma$ ).

Tabela 1: Área foliar antes da herbivoria usando a abordagem por Limiarização.

Amostra	Área foliar (cm <sup>2</sup> )	
	Calculada pelo aplicativo (cm <sup>2</sup> )	Obtida através de contagem manual (cm <sup>2</sup> )
ST01	18,394	18,1
ST15	24,864	24,83
ST19	18,113	17,75
SN18	21,972	21,9
SN03	26,736	26,51
SN22	23,333	22,96
MT16	24,465	25,16
MT07	26,267	26,55
MT06	28,708	28,51
MN20	47,264	47,58
MN15	31,781	32,45
MN10	30,138	29,45
CT18	21,169	21,57
CT15	34,668	33,94
CT06	31,985	31,95
CN06	27,365	26,45
CN19	22,735	22,64
CN23	30,117	29,97

<b>Área foliar (cm<sup>2</sup>)</b>		
$\bar{X} \pm \sigma$	27,226 ± 6,836	27,126 ± 6,891

Pela Tabela 1, pode-se verificar que os valores médios obtidos pela Limiarização e pela contagem manual das folhas antes da herbivoria são próximos, com as amostras geralmente variando em no máximo 1 cm<sup>2</sup> para mais ou para menos.

Tabela 2: Área foliar depois da herbivoria usando a abordagem por Limiarização.

Amostra	<b>Área foliar (cm<sup>2</sup>)</b>	
	<b>Calculada pelo aplicativo (cm<sup>2</sup>)</b>	<b>Obtida através de contagem manual (cm<sup>2</sup>)</b>
ST01	17,095	17,26
ST15	21,443	21,54
ST19	15,280	14,89
SN18	16,190	16,23
SN03	25,374	25,80
SN22	22,377	22,54
MT16	17,288	17,38
MT07	25,060	25,83
MT06	26,664	27,06
MN20	42,569	43,24
MN15	26,500	25,71
MN10	21,415	21,03
CT18	14,587	13,59
CT15	32,019	31,45
CT06	29,482	30,20
CN06	19,543	18,93
CN19	21,767	20,85
CN23	22,541	22,83
$\bar{X} \pm \sigma$	23,177 ± 6,879	23,131 ± 7,131

Pela Tabela 2 também pode-se verificar a pouca variação entre as médias do aplicativo e as manuais no pós herbivoria, apenas com uma diferença maior do desvio padrão. Os resultados da Limiarização foram comparados com os valores

de referência utilizando também o Teste T de Student pois até então era o único método implementado, trabalhando com nível de confiança de 95% (0,05% de significância).

Para o teste T de Student, antes de realizados os cálculos foram estabelecidas duas hipóteses:

$H_0$ : as médias são iguais;

$H_1$ : as médias são diferentes.

Foi considerado nível de confiança de 95% (0,05% de significância), visto que, se o resultado for menor que o nível de significância, aceita-se  $H_1$ , mas se for maior aceita-se  $H_0$ .

Os resultados foram de 0,3561 e 0,5633 para as amostras de antes e pós herbivoria respectivamente. Ou seja, não há diferença significativa entre os cálculos manuais e da Limiarização.

## 5.2 Análise da Taxa de Acerto dos Classificadores

Os algoritmos de aprendizagem supervisionada foram construídos utilizando instâncias geradas a partir dos superpixels que foram marcados na imagem como foi descrito anteriormente. Cada um deles foi treinado com 237 instâncias provenientes de 10 imagens auxiliares que não foram utilizadas nos experimentos de medição de área baseado em limiarização e superpixel, evitando assim que os métodos pudessem “decorar” as respostas de classificação quando fossem utilizados nesses experimentos.

O número de instâncias para o treinamento foi determinado pela análise da taxa de acerto na classificação posterior. Para o teste foram fornecido o mesmo número de instâncias, sem repetição e validação cruzada, e com elas os

métodos conseguiram uma porcentagem de acerto de mais de 95%. O SVM obteve a maior taxa com 99.8326% de acerto seguido pelo Random Tree com 99.7908% e por fim o Adaboost com 99.7211%, com esses resultados foram iniciados os experimentos de análise de área foliar baseado em superpixel.

### 5.3 Resultados da Segmentação por Superpixel

Os resultados do modelo baseado em Superpixel dependem diretamente do algoritmo de aprendizagem supervisionada utilizado pois eles são os responsáveis pela identificação e classificação dos superpixels. Por isso os resultados serão apresentados divididos em duas tabelas para cada método, correspondendo a análise entre as medidas de área antes e pós herbivoria, respectivamente, cada uma contendo os valores das amostras, a média ( $\bar{X}$ ) e o desvio padrão das medições ( $\sigma$ ).

#### 5.3.1 Adaboost

Tabela 3: Área foliar antes da herbivoria Adaboost.

Amostra	Área foliar (cm <sup>2</sup> )	
	<i>Calculada pelo método Adaboost (cm<sup>2</sup>)</i>	<i>Obtida através de contagem manual (cm<sup>2</sup>)</i>
ST01	17,69	18,1
ST15	24,68	24,83
ST19	17,71	17,75
SN18	21,06	21,9
SN03	25,57	26,51
SN22	23,10	22,96
MT16	24,33	25,16
MT07	25,89	26,55
MT06	27,87	28,51
MN20	46,28	47,58
MN15	31,00	32,45
MN10	29,33	29,45
CT18	20,37	21,57

<b>Área foliar (cm<sup>2</sup>)</b>		
CT15	33,80	33,94
CT06	31,69	31,95
CN06	25,52	26,45
CN19	19,91	22,64
CN23	29,84	29,97
$\bar{X} \pm \sigma$	26,429 $\pm$ 6,860	27,126 $\pm$ 6,891

Pela Tabela 3, pode-se verificar que os valores obtidos utilizando o Adaboost em relação a contagem manual das folhas antes da herbivoria são próximos, mas variam mais a média e o desvio padrão do que os valores da limiarização em relação a referência. Os nomes das amostras seguem o padrão de identificação das folhas descrito na limiarização.

Tabela 4: Área foliar depois da herbivoria Adaboost.

Amostra	<b>Área foliar (cm<sup>2</sup>)</b>	
	<b><i>Calculada pelo método Adaboost (cm<sup>2</sup>)</i></b>	<b><i>Obtida através de contagem manual (cm<sup>2</sup>)</i></b>
ST01	15,20	17,26
ST15	20,44	21,54
ST19	13,51	14,89
SN18	14,37	16,23
SN03	24,99	25,80
SN22	22,44	22,54
MT16	16,00	17,38
MT07	24,13	25,83
MT06	25,72	27,06
MN20	41,43	43,24
MN15	26,26	25,71
MN10	19,91	21,03
CT18	10,81	13,59
CT15	31,90	31,45
CT06	29,28	30,20
CN06	19,13	18,93
CN19	20,42	20,85
CN23	21,68	22,83

Área foliar (cm <sup>2</sup> )		
$\bar{X} \pm \sigma$	22,098 ± 7,394	23,131 ± 7,131

Pela Tabela 4 também pode-se verificar a pouca variação entre as medidas utilizando o Adaboost em relação a contagem manual no pós herbivoria. Abaixo podem ser verificados exemplos da classificação.

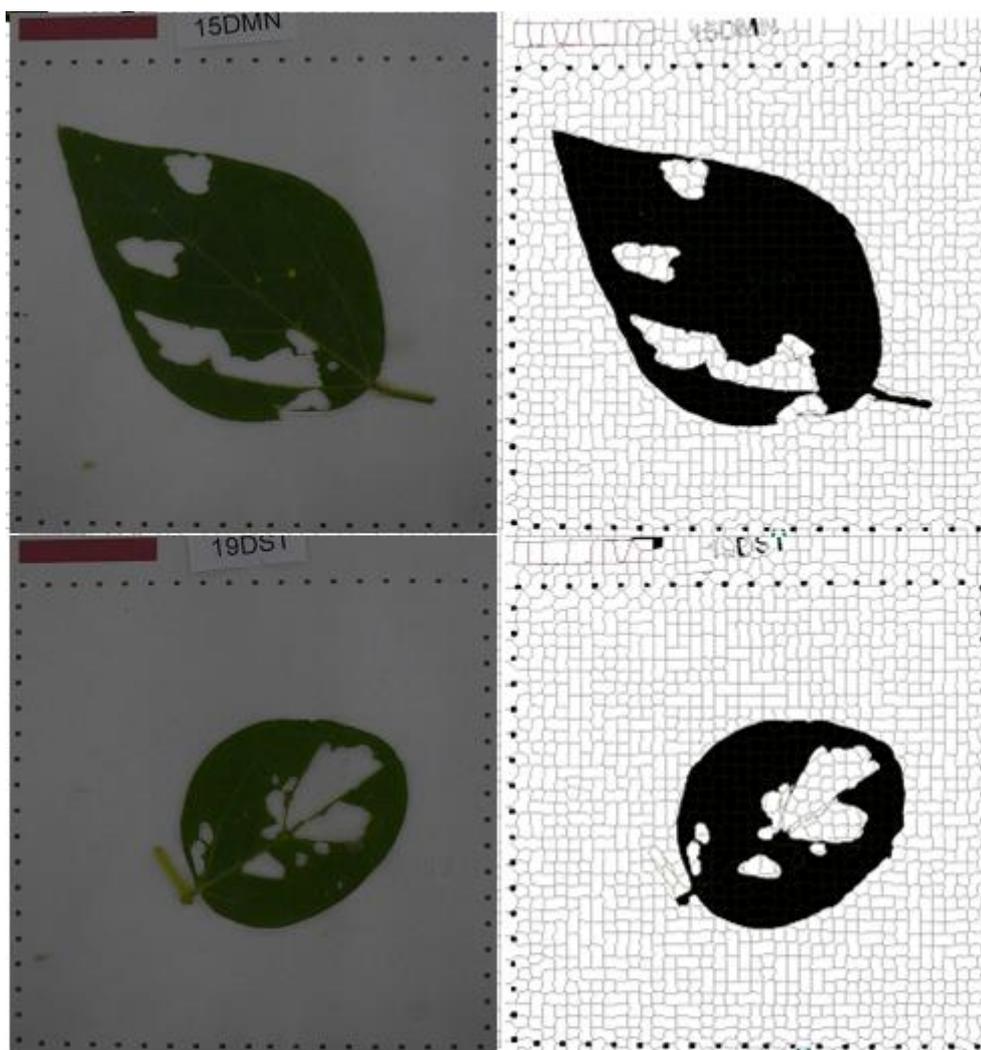


Figura 28: Folhas segmentadas pelo método Adaboost.

### 5.3.2 Random Tree

Tabela 5: Área foliar antes da herbivoria Random Tree.

Amostra	Área foliar (cm <sup>2</sup> )	
	<i>Calculada pelo método Random Tree (cm<sup>2</sup>)</i>	<i>Obtida através de contagem manual (cm<sup>2</sup>)</i>
ST01	17,81	18,1
ST15	25,04	24,83
ST19	17,76	17,75
SN18	21,31	21,9
SN03	25,89	26,51
SN22	22,54	22,96
MT16	24,47	25,16
MT07	26,11	26,55
MT06	28,59	28,51
MN20	46,94	47,58
MN15	31,36	32,45
MN10	29,82	29,45
CT18	20,96	21,57
CT15	34,33	33,94
CT06	31,85	31,95
CN06	25,60	26,45
CN19	20,20	22,64
CN23	30,01	29,97
$\bar{X} \pm \sigma$	26,709 ± 6,991	27,126 ± 6,891

Pela Tabela 5, pode-se verificar que os valores obtidos utilizando o Random Tree em relação a contagem manual das folhas antes da herbivoria são próximos, e variam menos do que os valores do Adaboost em relação a referência em algumas amostras. Os nomes das amostras seguem o padrão de identificação das folhas descrito na limiarização.

Tabela 6: Área foliar depois da herbivoria Random Tree.

Amostra	Área foliar (cm <sup>2</sup> )	
	<i>Calculada pelo método Random Tree (cm<sup>2</sup>)</i>	<i>Obtida através de contagem manual (cm<sup>2</sup>)</i>
ST01	15,57	17,26
ST15	20,85	21,54
ST19	13,69	14,89
SN18	14,87	16,23
SN03	25,71	25,80
SN22	22,70	22,54
MT16	16,39	17,38
MT07	24,51	25,83
MT06	26,35	27,06
MN20	42,47	43,24
MN15	26,60	25,71
MN10	20,83	21,03
CT18	11,10	13,59
CT15	32,61	31,45
CT06	30,40	30,20
CN06	19,96	18,93
CN19	20,51	20,85
CN23	22,10	22,83
$\bar{X} \pm \sigma$	22,626 $\pm$ 7,578	23,131 $\pm$ 7,131

Pela Tabela 6 também pode-se verificar a pouca variação entre as medidas utilizando o Random Tree em relação a contagem manual no pós herbivoria. Em alguns casos a variação entre as medidas é maior, provavelmente pelo erro na classificação do superpixel, que pode ser observada na imagem a seguir, que mostra alguns casos de falsos positivos na imagem.

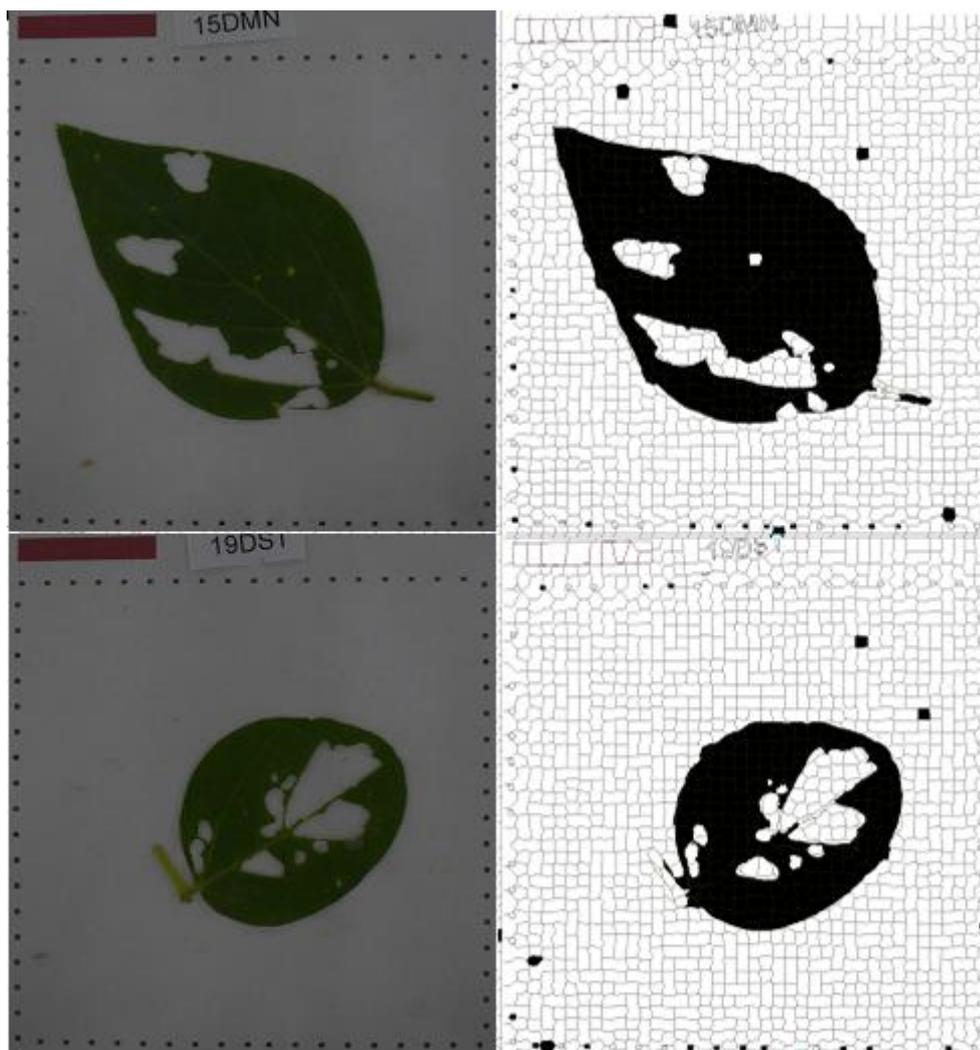


Figura 29: Imagens segmentadas pelo método Random Tree.

### 5.3.3 SVM

Tabela 7: Área foliar antes da herbivoria SVM.

Amostra	Área foliar (cm <sup>2</sup> )	
	<i>Calculada pelo método SVM (cm<sup>2</sup>)</i>	<i>Obtida através de contagem manual (cm<sup>2</sup>)</i>
ST01	18,12	18,1
ST15	25,01	24,83

<b>Área foliar (cm<sup>2</sup>)</b>		
ST19	17,99	17,75
SN18	21,49	21,9
SN03	25,84	26,51
SN22	22,67	22,96
MT16	24,26	25,16
MT07	25,93	26,55
MT06	28,14	28,51
MN20	46,56	47,58
MN15	31,32	32,45
MN10	29,62	29,45
CT18	20,82	21,57
CT15	34,14	33,94
CT06	31,90	31,95
CN06	25,89	26,45
CN19	20,16	22,64
CN23	30,11	29,97
$\bar{X} \pm \sigma$	26,667 $\pm$ 6,867	27,126 $\pm$ 6,891

Pela Tabela 7, pode-se verificar que os valores obtidos utilizando o SVM em relação a contagem manual das folhas antes da herbivoria são próximos, e em alguns casos variam menos que os valores do Random Tree tanto que o desvio padrão é mais próximo do desvio da referência. Os nomes das amostras seguem o padrão de identificação das folhas descrito na limiarização.

Tabela 8: Área foliar depois da herbivoria SVM.

<b>Área foliar (cm<sup>2</sup>)</b>		
<b>Amostra</b>	<b>Calculada pelo método SVM (cm<sup>2</sup>)</b>	<b>Obtida através de contagem manual (cm<sup>2</sup>)</b>
ST01	15,38	17,26
ST15	20,70	21,54
ST19	13,77	14,89
SN18	14,85	16,23
SN03	25,27	25,80

<b>Área foliar (cm<sup>2</sup>)</b>		
SN22	22,65	22,54
MT16	16,10	17,38
MT07	24,18	25,83
MT06	25,85	27,06
MN20	42,02	43,24
MN15	26,32	25,71
MN10	20,18	21,03
CT18	10,94	13,59
CT15	31,92	31,45
CT06	30,01	30,20
CN06	19,08	18,93
CN19	20,77	20,85
CN23	21,99	22,83
$\bar{X} \pm \sigma$	$22,339 \pm 7,457$	$23,131 \pm 7,131$

Pela Tabela 8 também pode-se verificar a pouca variação entre as medidas utilizando o SVM em relação a contagem manual no pós herbivoria. Em alguns casos a variação entre as medidas é maior, provavelmente pelo erro na classificação do superpixel, como pode ser observado na imagem abaixo. Comparando as imagens de exemplos dos 2 métodos pode-se observar algumas variações na classificação que dependem da característica de cada algoritmo.

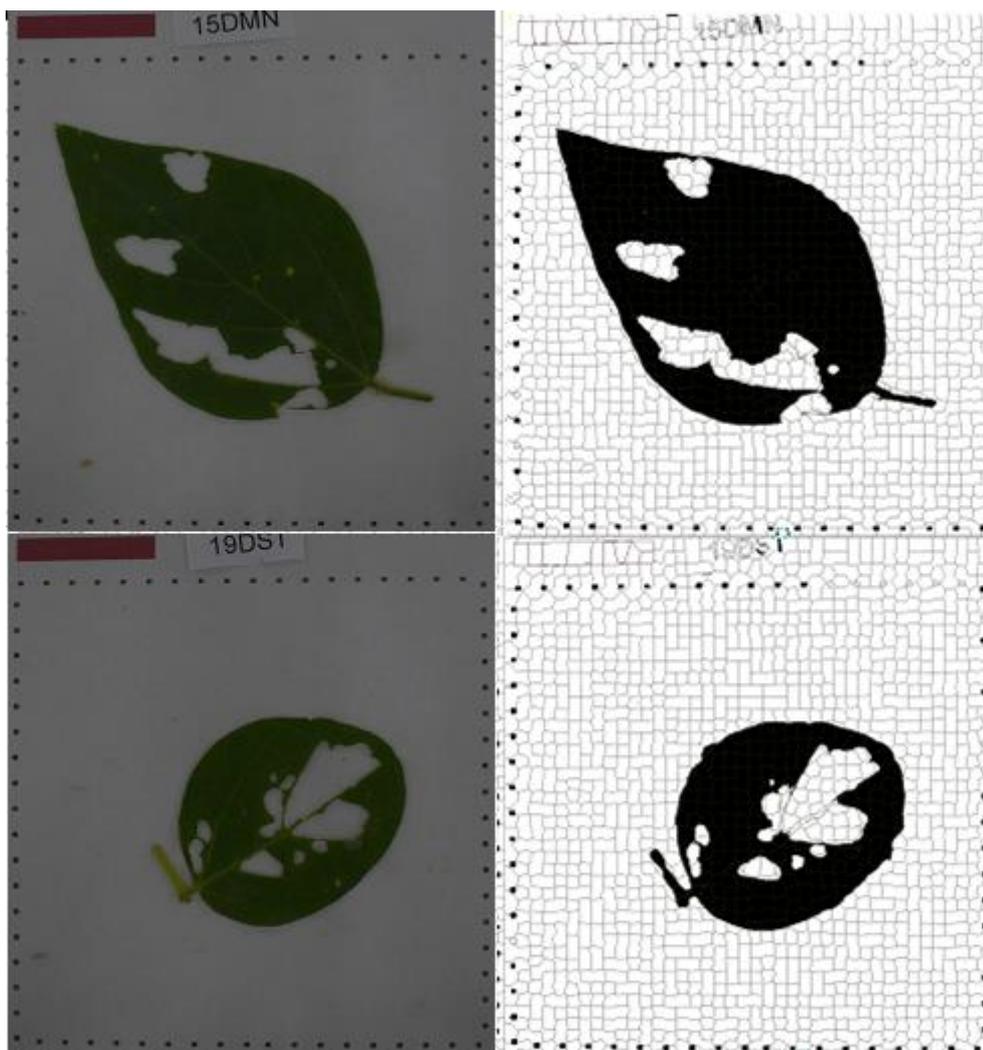


Figura 30: Imagens segmentadas pelo método SVM.

## 5.4 Comparação e Avaliação

### 5.4.1 ANOVA

A análise de variância visa comparar mais de 2 conjuntos e determinar se a diferença observada é causada apenas por variações aleatórias de uma amostra a outra ou se os dados vêm de populações onde as médias são de fato diferentes. A avaliação é feita verificando o quão diferentes são as médias e quanto as observações estão dispersas ao redor das respectivas médias. A ANOVA compara a variação resultante de fontes específicas com a variação entre indivíduos que deveriam ser semelhantes

Antes de realizados os cálculos foram estabelecidas duas hipóteses:

$H_0$ : as médias são iguais, não existem evidências estatísticas de que as médias sejam diferentes;

$H_1$ : as médias são diferentes.

Foi considerado também nível de confiança de 95% e 0,05% de significância, visto que, se o resultado for menor que o nível de significância, aceita-se  $H_1$ , mas se for maior aceita-se  $H_0$ .

Tabela 9: Análise estatística sobre os métodos.

<i>Grupos</i>	<i>Quantidade</i>	<i>Soma</i>	<i>Média</i>	<i>Variância</i>
manual – Referência	36	904,63	25,12861111	51,86266944
Adaboost	36	873,237	24,25658333	54,24509819
RandomTree	36	887,758	24,65994444	55,90428263
SVM	36	881,932	24,49811111	54,74093747
Limiarização	36	907,2683	25,20189722	49,89918075

Pela tabela pode ser observado que as médias são bem próximas e a variância tem valores próximos para os métodos. Com esses dados pode ser feita a análise de variância ANOVA:

Tabela 10: ANOVA – Single Factor.

<i>Source of Variation</i>	<i>SS</i>	<i>df</i>	<i>MS</i>	<i>F</i>	<i>P-value</i>	<i>F crit</i>
Between Groups	23,85254827	4	5,963137069	0,111814899	0,978251	2,423286
Within Groups	9332,825897	175	53,3304337			
Total	9356,678445	179				

O valor F, que é calculado pela divisão da variância entre grupos pela variância dentro dos grupos, demonstra que quanto maior o seu valor, mais diferença há entre os métodos, para o teste realizado o valor F foi de 0,111814899.

Os resultado do valor P foi de 0,9782 comparando todas as amostras de todos os métodos com as medições de referência. Ou seja, não existem evidências estatísticas de que as médias sejam diferentes.

#### 5.4.2 Teste de Correlação

Visto que segundo a análise de Variância ANOVA feito com todos os métodos e teste T para a Limiarização os valores medidos não tem diferenças significativas entre si e, conseqüentemente, em relação às medidas de referência, será utilizado também o teste de correlação para verificar quão correlacionadas estão as medidas de cada método com as de referência. Foram gerados os gráficos de dispersão a seguir :

Limiarização:

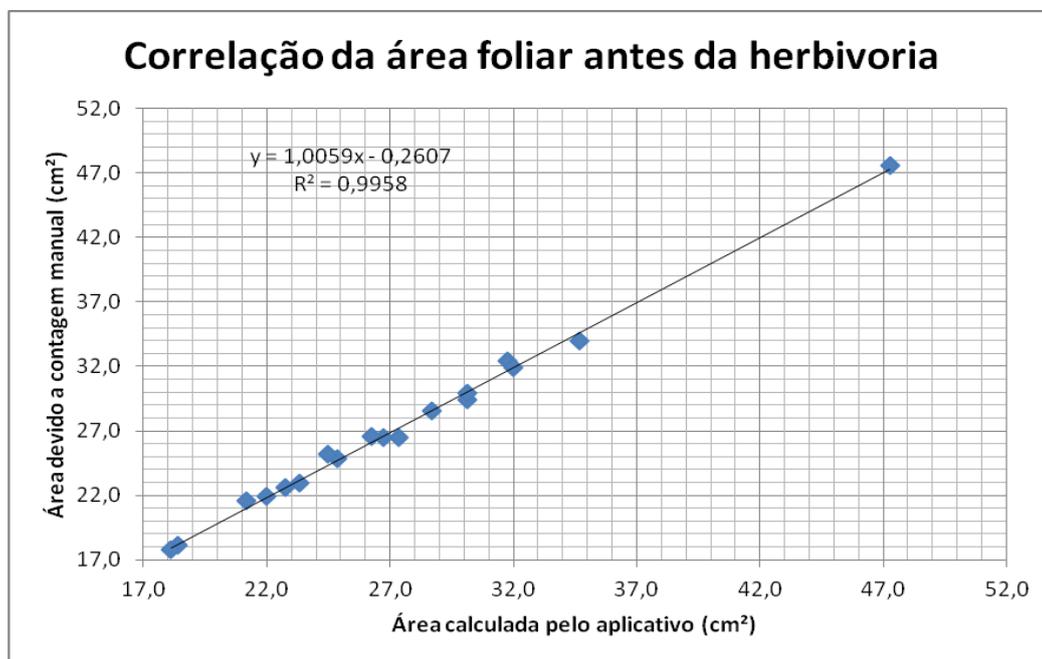


Figura 31: Correlação da área foliar obtida pela Limiarização com a obtida através de contagem manual.

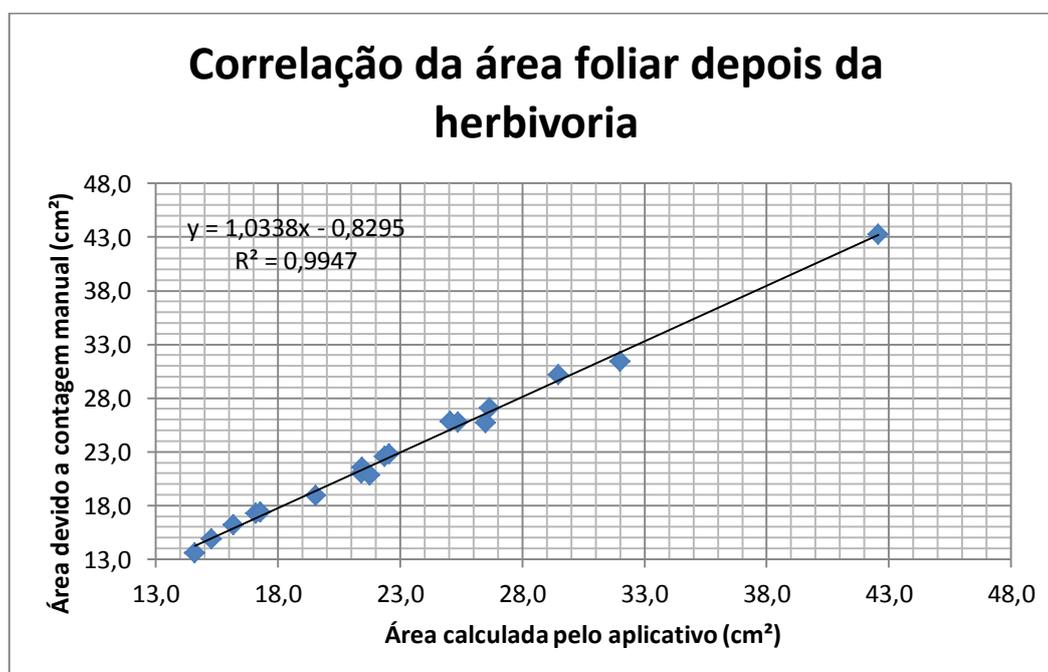


Figura 32: Gráfico relativo a correlação da área foliar obtida pela Limiarização com a obtida através de contagem manual.

Adaboost:

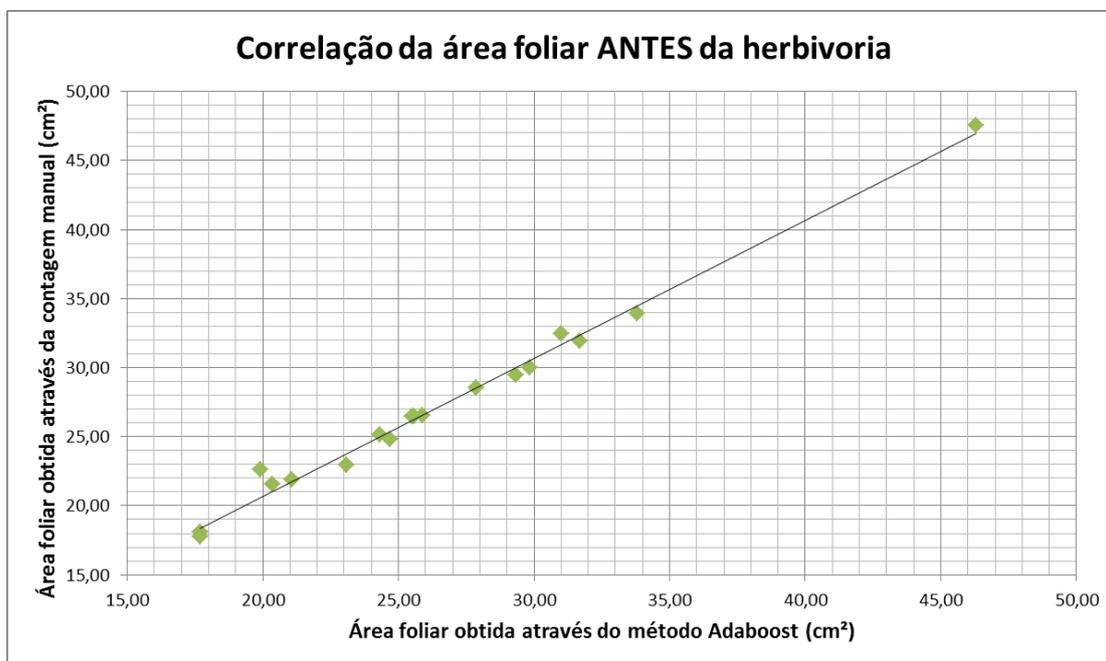


Figura 33: Correlação da área foliar obtida pelo método Adaboost com a obtida através de contagem manual.

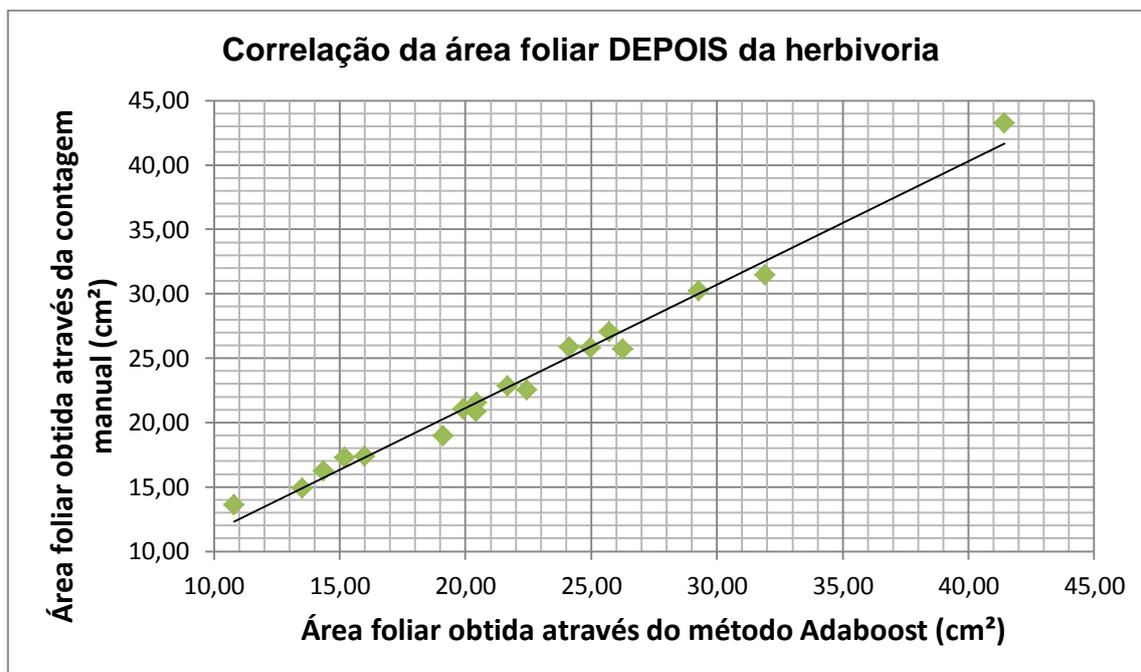


Figura 34: Correlação da área foliar obtida pelo método Adaboost com a obtida através de contagem manual.

Random Tree:

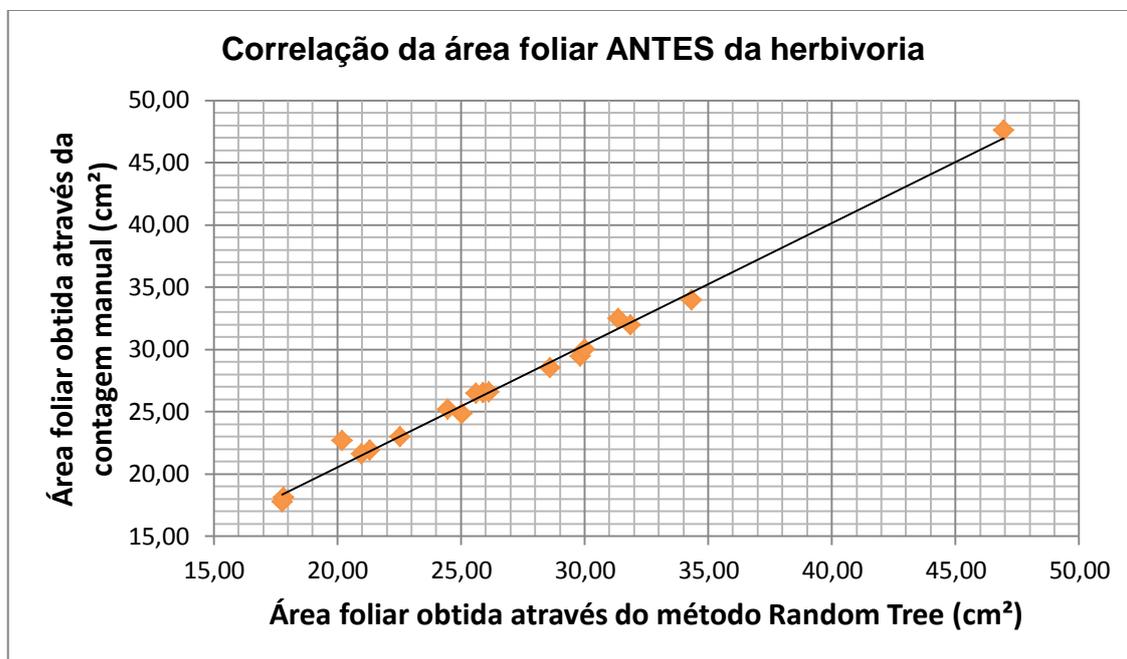


Figura 35: Correlação da área foliar obtida pelo método *Random Tree* com a obtida através de contagem manual.

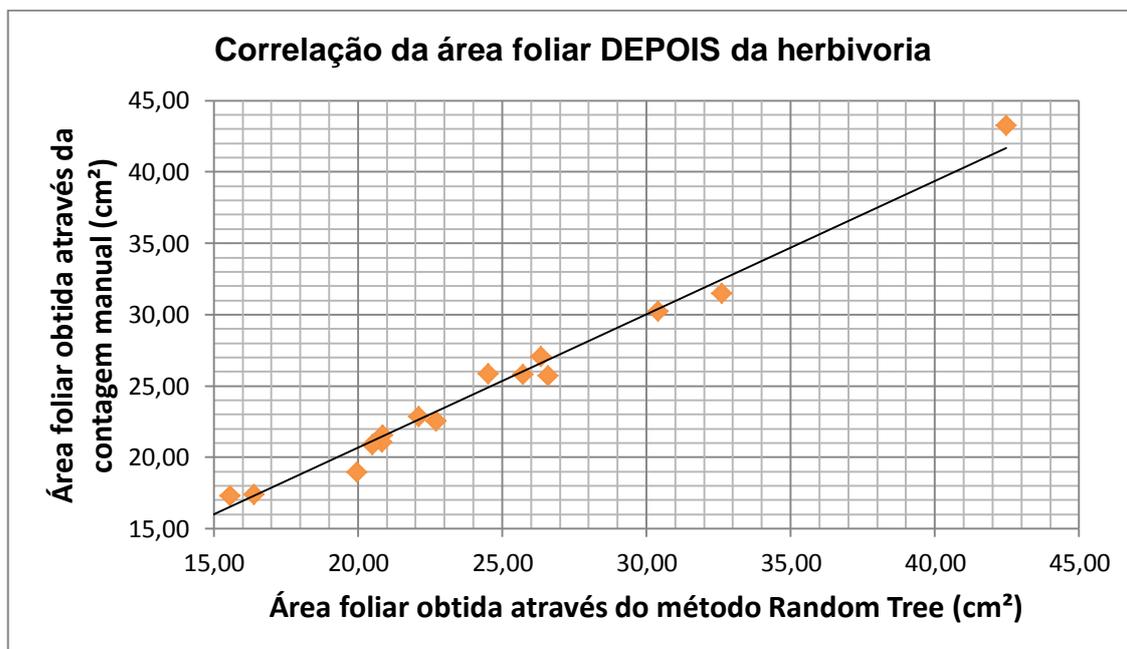


Figura 36: Correlação da área foliar obtida pelo método *Random Tree* com a obtida através de contagem manual.

SVM:

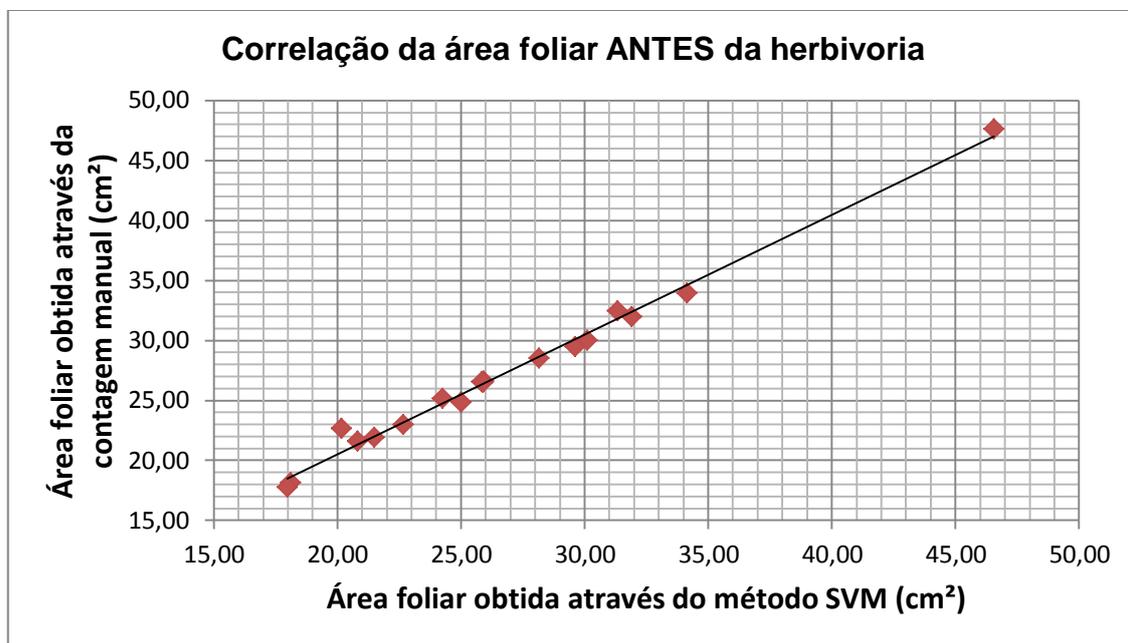


Figura 37: Correlação da área foliar obtida pelo método SVM com a obtida através de contagem manual.

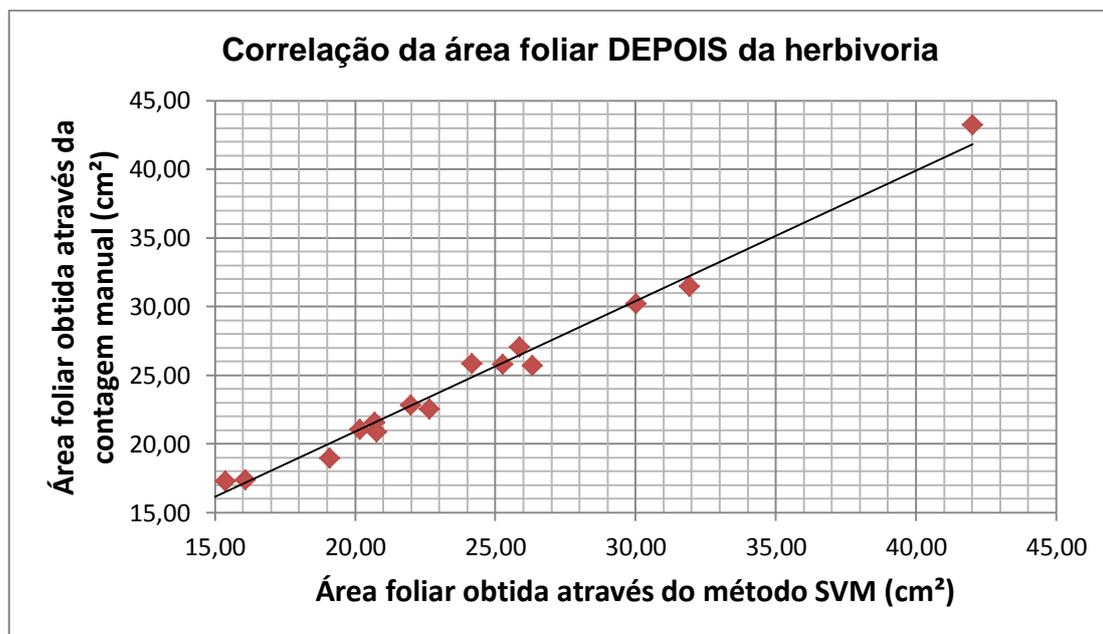


Figura 38: Correlação da área foliar obtida pelo método SVM com a obtida através de contagem manual.

Os valores de correlação medidos para cada método podem ser observados na tabela a seguir:

Tabela 11: Valores obtidos no teste de Correlação.

Método	Correlação	
	<i>Amostras Pré - Herbivoria</i>	<i>Amostras Pós - Herbivoria</i>
Limiarização	0,9958	0,9947
Adaboost	0,9950	0,9930
Random Tree	0,9956	0,9932
SVM	0,9952	0,9940

Pode-se verificar que tanto para imagens pré Herbivoria quanto para pós Herbivoria o valor de correlação da Limiarização é que fica mais perto de 1 (valor máximo para esse teste), ou seja, que possui a correlação mais forte. Porém, para realizar esse método o usuário tem que conhecer os limiares de cor e ajustá-los para que consiga um bom desempenho na medição de área.

Para os métodos baseados em superpixel, as medidas de correlação ainda são fortes porém um pouco menos que as da Limiarização. Esses métodos tem por facilidade o processamento e classificação automática e com isso um procedimento mais simples para o usuário final.

A métrica que foi analisada foi a resposta na medição de área, portanto não podemos afirmar com certeza qual dos métodos é melhor, na medição de imagens antes o Random Tree teve valores mais próximos e nas imagens depois o SVM teve medições mais próximas da referência. Mas ao observar a imagem 24 com alguns exemplos da resposta do Random Tree pode ser observado que o mesmo comete alguns erros encontrando falsos positivos.

Para uma análise futura mais detalhada poderiam ser utilizadas outras métricas para avaliar os classificadores e seus parâmetros. Pois mesmo com suas taxas de acerto altas pode ter ocorrido erro ao recortar os superpixel's para que eles fossem classificados, atrapalhando assim a resposta dos algoritmos e consequentemente na medição final de área.

## 6. Conclusões e trabalhos futuros

Neste projeto foram implementados métodos diretos para cálculo de área foliar computacionalmente, e ambos modelos propostos e executados obtiveram um resultado preciso em relação as medidas de área comparando com as medidas de referência. Para essa análise foi criado um banco de imagens que ainda poderá ser utilizado em outros projetos correlatos aos parâmetros de folhas, em geral, ou especificamente, da soja.

Os relatórios gerados na implementação do primeiro modelo (Limiarização) que foram posteriormente confirmados pelo segundo deram base para os biólogos participantes do grupo Soja (inicialmente chamado de Herbivic), continuarem suas pesquisas à respeito das consequências da herbivoria nas plantas, e no possível aproveitamento desses efeitos. Com o modelo baseado em superpixel será mais simples para que os próprios usuários analisem suas amostras e identifiquem outras classes conforme a necessidade. A abordagem que obteve os melhores resultados foi a baseada na Limiarização, mas os outros métodos conseguiram resultados proximos para o mesmo experimento.

Como melhorias futuras podem ser feitos ajustes nos algoritmos de aprendizagem supervisionada para obter maior precisão na medição e para avaliá-los utilizando também outras métricas. Devem ser feitos estudos à respeito dos atributos mais significativos para o problema além de melhorias no layout para facilitar a usabilidade com o usuário final.

As aplicações implementadas serão utilizadas também em outros projetos do grupo INOVISÃO a fim de facilitar a identificação e classificação em outros problemas, para isso pode ser ajustados os atributos e classes conforme a aplicação estudada. Também será utilizado possivelmente na análise de imagens de plantações que serão coletadas pelos colegas do grupo Soja e seus resultados serão comparados com as respostas dos métodos que ainda serão implementados para essa análise específica.

# Referências

- [1] ACHANTA, R et al SLIC superpixels compared to state-of-the-art superpixel methods. Pattern Analysis and Machine Intelligence, IEEE Transactions on (Volume:34 , Issue: 11 ), 2012.
- [2] ADAMI, M. et al Estimativa de área foliar de soja usando imagens digitais e dimensões foliares. Anais XIII Simpósio Brasileiro de Sensoriamento Remoto, Florianópolis: INPE, 2007. p 9-14.
- [3] AHUJA, L. et al. *Phytoalexins in defense against pathogens. Trends in Plant Science*, 2012. 17(2): 73-90.
- [4] ALI, A et al. *Distribution of fall armyworm (Lepidoptera: Noctuidae) egg masses on cotton. Environmental Entomology*, College Park, 1989. v. 18, n.5, p. 881-885.
- [5] BENINCASA, M.. Análise de crescimento de plantas, noções básicas. 2. ed. Jaboticabal: UNESP, 2003. 41 p.
- [6] BIANCO S. et al, Estimativa da área foliar de *tridax procumbens* usando dimensões lineares do limbo foliar, Planta Daninha, vol. 22, no. 2, pp. 247–250, abril/junho 2004.
- [7] BOREGAS, K. et al. Adaptação de *Spodoptera frugiperda* (J. E. Smith) (*Lepidoptera: Noctuidae*) em diferentes hospedeiros no campo. In: CONGRESSO DE ECOLOGIA DO BRASIL, 9., 2009, São Lourenço. Anais... São Lourenço, 2009. p.1-3.
- [8] BOROVEC, J., & Kybic, J. (2014). jSLIC : superpixels in ImageJ. Computer Vision Winter Workshop. Praha.
- [9] BORTOLI, S. et al Herbivoria em Soja: Efeito na Composicao Quimica das Folhas e na Biologia da Lagarta da Soja e do Percevejo Verde Pequeno. *Comunicata Scientiae*, 2012. v.3,n.3.

- [10] BRAGA, M. Fitoalexinas. In: PASCHOLATI, S.F.; LEITE, B.; STANGARLIN, J.R.; CIA, P. (Ed.). *Interação Planta Patógeno – Fisiologia, bioquímica e biologia molecular*. Piracicaba: FEALQ, 2008. p.305-346.
- [11] BRANDOLI, B.M. Inferência Gramatical Aplicada ao Reconhecimento de Comportamentos em Animais, Relatório final apresentado à Coordenação do Curso como parte dos requisitos para a obtenção do título de Bacharel em Engenharia de Computação, Novembro 2007.
- [12] BURDEN, R et al. *Structure of the phytoalexin from soybean. Phytochemistry*, 1975. v.14, p.1389- 1390.
- [13] CASANOVA, D. Identificação de espécies vegetais por meio da análise de textura foliar. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/55/55134/tde-04032009-101456/pt-br.php>> Acesso em: 06 fev. 2014.
- [14] COELHO FILHO, M. A et al Avaliação de métodos diretos e indiretos na estimativa de área foliar em árvores de lima ácida 'tahiti', Rev. Bras. Frutic. vol.27 no.1 Jaboticabal Apr. 2005.
- [15] CONAB – Companhia Nacional de Abastecimento. Governo Federal. Brasil. Disponível em <http://www.conab.gov.br>, acessado em 22/abril/2014.
- [16] FAVARIN, J. L., et al. Equações para a estimativa do índice de área foliar do cafeeiro, Pesquisa Agropecuária Brasileira, vol. 37, no. 6, pp. 769–773, junho 2002.
- [17] FAVARIN J. L., et al. Análise comparativa de métodos de estimativa de área foliar em cafeeiro, Bragantia, vol. 61, no. 2, pp. 199–203, maio/agosto 2002.
- [18] GODOY, L. et al. Análise da imagem digital para estimativa da área foliar em plantas de laranja "Pêra". Revista Brasileira de Fruticultura, Jaboticabal, 2007. v. 29, n .3.
- [19] GOMEZ, S. É tempo de preocupação com as pragas da soja. [S.l.: s.n., 200].Disponívelem:<[http://www.agrolink.com.br/ferrugem/artigos\\_pg\\_detalhe\\_noticia.asp?cod=34947](http://www.agrolink.com.br/ferrugem/artigos_pg_detalhe_noticia.asp?cod=34947)>. Acesso em: 25 jan. 2014.

- [20] GONZALEZ, R. C. & R. E. WOODS. *Digital image processing*. Addison-Wesley, 3rd Edition, 1992.
- [21] GONZALEZ, R. *Digital Image Processing (2nd Edition)* Prentice Hall, January, 2002.
- [22] GONZALEZ, et al. *Digital Image Processing using MATLAB*. 2006.
- [23] GONZALEZ, R. & WOODS, R.E. *Processamento Digital de Imagens*. 3.ed. São Paulo: Pearson Prentice Hall, 2009.
- [24] INTERNATIONAL GRAINS COUNCIL. Grain Market Report. IGC: GMR, n.442,3,2014.Disponível em:  
<http://www.igc.int/en/downloads/gmrsummary/gmrsumme.pdf>. Acesso em: 10/05/2014.
- [25] KOGAN, M. & Fischer, D.C. *Inducible defenses in soybean against herbivorous insect*. New York, USA, 1991. p. 347-380.
- [26] LUCENA, R. et al. Medição de área Foliar de aceroleira . *Revista Caatinga*, 2011. v.24, n.2.
- [27] MARTIN, D. *An empirical approach to grouping and segmentation*. PhD thesis, University of California, Berkeley, 2002.
- [28] MOZOS, O. M. Martinez *Supervised Learning of Places from Range Data using AdaBoost*, University of Freiburg, Department of Computer Science, D-79110 Freiburg, Germany.
- [29] NAZARÉ-JR, A. C., et al Detecção da área foliar danificada de soja, in 7o Congresso Brasileiro de Agroinformática - SBIAgro, 2009, aceito para publicação.
- [30] PASQUALI, A. L. Extração de Características Utilizando Filtro de Gabor Aplicado à Identificação de Defeitos no Couro Bovino, Relatório Final submetido como um dos requisitos para a obtenção do título de Bacharel em Engenharia de Computação, Novembro 2007.
- [31] PEDRINI H. & W. R. SCHWARTZ, *Análise de Imagens Digitais*, 1st ed. São Paulo: Thomson, 2008.

- [32] PEREIRA, A. et al. Evapotranspiração. Piracicaba: FEALQ/ ESALQ/USP, 1997. 70 p
- [33] PISTORI H. et al Técnicas de Segmentação Baseadas em Subtração de Fundo e Modelos de Cores: Um Estudo Comparativo, CMNE/CILAMCE, Porto, 13 a 15 de Junho, 2007.
- [34] PROTZEL, P. et al, Superpixel Benchmark and Comparison Chemnitz University of Technology, Department of Electrical Engineering and Information Technology.
- [35] QUEIROZ, J. H. F. S. Desenvolvimento de um Sistema de Visão Computacional para o Monitoramento e Controle de Experimentos Laboratoriais Realizados com Larvas do *Aedes aegypti* L., Relatório Final submetido como um dos requisitos para a obtenção do título de Bacharel em Engenharia de Computação., Novembro 2010.
- [36] QUINTA, Lia N. B. Utilização de Florestas de Caminhos Ótimos para Identificação de Grãos de Pólen, Dissertação apresentada como parte das exigências para obtenção do título de mestre em Biotecnologia, no Programa de PósGraduação em Biotecnologia da Universidade Católica Dom Bosco - Área de concentração: Biotecnologia Aplicada à Agropecuária, Novembro 2011.
- [37] RODRIGUES, Ricardo C. B. & VIANA, R. H. R. Máquinas de Vetores de Suporte Aplicadas à Classificação de Defeitos em Couro Bovino, Relatório Final submetido como um dos requisitos para a obtenção do título de Bacharel em Engenharia de Computação, Novembro 2007.
- [38] SAITO, P. et al Uso da Computação Paralela Distribuída para Melhoria no Tempo de Processamento de Imagens Médicas, Univem – Centro Universitário Eurípides de Marília, XIV ERI-PR 2007
- [39] SANTOS, J. C. Extração de atributos de forma e seleção de atributos usando algoritmos genéticos para classificação de regiões. Instituto Nacional de Pesquisas Espaciais (INPE), 2007.
- [40] SILVA, N. Identificação de trajetórias espaço-temporais de movimentos em vídeo. Dissertação de mestrado Universidade Federal de Uberlândia. 2010.

- [41] SHI, J. & MALIK, J. *Normalized Cuts and Image Segmentation*. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 22, 2000. 888–905.
- [42] SHI, J. & MALIK, J. *Contour and texture analysis for image segmentation*. *International Journal of Computer Vision*, 2001. 43, 7-27.
- [43] SOUZA, K. P. Aplicação de Modelos de Markov Ocultos na Obtenção de Taxas de Mortalidade das Larvas do Mosquito da Dengue, Dissertação de Mestrado apresentada à Faculdade de Computação do Centro de Ciências Exatas e Tecnologia da Universidade Federal de Mato Grosso do Sul, Fevereiro 2010.
- [44] SOUZA TACIANA. Estudo de técnicas de realce de imagens digitais e suas aplicações, II Congresso de Pesquisa e Inovação da Rede Norte Nordeste de Educação Tecnológica, João Pessoa - PB - 2007
- [45] TORRES, A. Segmentação de imagens médicas visando a construção de modelos médicos. Relatório final do trabalho de projeto de mestrado no instituto politécnico de Bragança. 2012
- [46] ZUNIGA, A. G. Sistema de visão artificial para identificação do estado nutricional de plantas. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/55/55134/tde-20062012-101012/pt-br.php>> Acesso em: 06 fev. 2014
- [47] BREIMAN, Leo. "Random Forests". *Machine Learning* 45 (2001): 5–32