
Atributos de Ponto de Interesse e
Casamento de Modelos para Contagem
de Insetos-Praga em Cultura de Soja

Diogo Soares da Silva

Pós -GRADUAÇÃO DA UNIVERSIDADE FEDERAL
DE MATO GROSSO DO SUL DA FACULDADE DE
CIÊNCIAS DA COMPUTAÇÃO - FACOM

Data de Depósito:

Assinatura:_____

Atributos de Ponto de Interesse e Casamento de Modelos para Contagem de Insetos-Praga em Cultura de Soja

Diogo Soares da Silva

Orientador: *Prof. Dr. Hemerson Pistori*

Dissertação apresentada ao curso de Pós Graduação em Ciências da Computação, da Universidade Federal de Mato Grosso do Sul, como requisito parcial à obtenção do título de Mestre em Ciências da Computação.

UFMS - Campo Grande
março/2016

Agradecimentos

*A Hemerson Pistori que me orientou e proporcionou chegar ao fim desta etapa,
Ao Prof. Denilson Guilherme que nos ajudou e sofreu conosco durante todo o projeto,
A Gercina, Ariadne e Alessandro que foram meus amigos de campo, que além de contribuir com o projeto, deixavam os dias arduos mais alegres,
A Fundação MS e Fernando por contribuir com o planejamento e montagem de nosso experimento,
Aos membros da banca, Edson Takashi e Lucas Castro Torres,
A Maria Úrsula e toda sua família, por momentos de carinho e paciência,
A CAPES e FUNDECT pela ajuda financeira,
Aos meus pais Pedro Soares e Otilia Gasparini, que estiveram comigo em cada passo,
A meu irmão Adriano Soares, que sempre me incentivou e apoiou em cada decisão...
Aos meus amigos e todos que contribuíram direta e indiretamente a este trabalho.*

Abstract

This work presents an application to count insects in soybean fields. The purpose of this application is to help agronomists and agricultural technicians in the inspection of soybean crops. The application uses aerial images, captured by unmanned aerial vehicles, to count the insect. With this information specialists can determine whether there is an insect infestation in the crop field or not, deciding whether the use of insecticides is required. For identifying and counting of insects, computer vision techniques based on Points of Interest were used, where *Speeded Up Robust Feature* (SURF) was the technique used for the detection and description of the Points of Interest of the analyzed images. For classifying the insects, techniques based on template matching, in specific techniques that use the points of interest to set the matching between images, were used to define the similarity between the test image and the analyzed classes. With this information, three metrics were used to define the insect class, them being, the point with minimum distance, the average minimum distance and the number of matches. In the experiments the detector parameters and descriptor points of interest were changed until the best results for classification were found. The proposed method was compared to three classifiers based on Support Vector Machine, K nearest neighbor and decision trees. The proposed method achieved an F-measure of 0,899 being statistically better than the classifier based on decision trees and similar to those based on Support Vector Machine and K nearest neighbors. The counter module was compared to the count of an expert who classified all test images. Through ANOVA hypothesis testing (analysis of variance) it was proven that the count of the proposed method and the expert's are not divergent, with a significance level of 5%, evidentiating the proposal's potential in automating assessments of pests in crop fields.

Keywords: Points of Interest, Computer Vision, Soybean, Pests, Template Match

Resumo

Neste trabalho é apresentado uma aplicação para a contagem de insetos em plantações de soja, o objetivo desta aplicação é ser uma ferramenta para o auxílio de agrônomos e técnicos agrícolas na inspeção de cultivos de soja. A aplicação utiliza imagens aéreas, capturadas por Veículos Aéreos não Tripulados, para a contagem dos insetos, e com esta informação o especialista pode definir se existe infestação de insetos na plantação ou não, decidindo se é necessária a aplicação de inseticidas. Para a identificação e contagem dos insetos, técnicas de visão computacional baseadas em Pontos de Interesse foram utilizadas, sendo o *Speeded Up Robust Feature* (SURF) a técnica utilizada para a detecção e descrição dos Pontos de Interesse das imagens analisadas. Para a classificação dos insetos, técnicas baseadas em casamento de modelos, em específico técnicas que utilizam os pontos de interesse para definir o casamento entre as imagens, foram utilizadas para definir a semelhança entre a imagem teste com as classes analisadas. Com essa informação três métricas foram utilizadas para definir a classe do inseto, a do ponto com distância mínima, a distância média mínima e o número de casamentos. Nos experimentos realizados foram variados os parâmetros do detector e descritor de pontos de interesse a fim de encontrar os melhores resultados para a classificação. O método proposto foi comparado com três classificadores baseados em Máquina de Vetores de Suporte, K vizinhos mais próximos e árvores de decisão. O método proposto obteve uma medida-F de 0.899 sendo estatisticamente melhor do que o classificador baseado em árvores de decisão e semelhante aos baseados em Máquina de Vetores de Suporte e K vizinhos mais próximos. O módulo de contagem foi comparado com a contagem de um especialista que marcou todas as imagens de teste. Através do teste de hipóteses ANOVA (Análise de variância) foi comprovado que a contagem do método proposto e do especialista não são divergentes, com um nível de significância de 5%, evidenciando o potencial da proposta na automação de avaliações de pragas em campo.

Palavras Chave: Pontos de Interesse, Visão Computacional, Soja, Pragas, Casamento de Modelos

Sumário

Sumário	v
Lista de Figuras	ix
Lista de Tabelas	x
1 Introdução	1
1.1 Considerações Iniciais	1
1.2 Estrutura do Trabalho	4
2 Fundamentação Teórica	5
2.1 Detecção e Descrição de Pontos de Interesse	5
2.1.1 <i>Scale Invariant Feature Transformation (SIFT)</i>	5
2.1.2 <i>Speeded Up Robust Feature (SURF)</i>	9
2.2 Casamento de Pontos de Interesse	17
2.2.1 Algoritmos de Busca Pelos Vizinhos mais Próximos	17
2.2.2 Métricas para o Reconhecimento de Objetos	18
2.3 Cultura da Soja	20
2.3.1 Anatomia da Planta	20
2.3.2 Ciclo Fenológicos	24
2.3.3 Agricultura de Precisão	26
2.3.4 Morfologia Externa dos Insetos	27
2.3.5 Manejo Integrado de Pragas	28
2.3.6 Insetos Prejudiciais à Soja	29
2.3.7 Amostragem de Pragas da Soja	38
2.4 Utilização de Imagens na Agricultura de Precisão	41
2.4.1 VANT	42
3 Trabalhos Correlatos	44
4 Metodologia	48
4.1 Cultivo de Lavoura de Soja Experimental	48
4.1.1 Delineamento Safra 2014/2015	49
4.1.2 Delineamento Safra 2015/2016	50
4.2 Construção de um banco de imagens de Soja	52
4.2.1 Coleta dos Insetos Pontuais	52
4.2.2 Coleta dos Insetos no Pano-de-batida	53
4.3 Módulos de Classificação e Contagem de Insetos	53
4.3.1 Módulo de Classificação de Insetos	54
4.3.2 Módulo de Contagem de Insetos	56
4.4 Experimentos para Avaliação dos Módulos Propostos	58

4.4.1	Classificação de Insetos	60
4.4.2	Contagem de Insetos	60
4.5	Validação do Módulo de Classificação e Contagem de Insetos . . .	62
5	Resultados e Discussão	63
5.1	Classificação de Insetos	63
5.2	Contagem de Insetos	66
6	Considerações Finais	74
	Referências	82

Lista de Figuras

2.1	Ilustração das imagens com desfoque Gaussiano em diferentes escalas, e imagens com a diferença Gaussiana.	7
2.2	Detecção local extrema, o pixel preto é comparado com 26 vizinhos, sendo a comparação feita em três dimensões $3 \times 3 \times 3$, que se expandem pelas imagens da diferença Gaussiana de escalas adjacentes.	8
2.3	Descritor de características do SIFT.	9
2.4	Representação da imagem integral, com exemplo de soma dos pixels dentro dos retângulos. A somatória dos pixels na área verde da imagem é obtida no ponto 1 marcado na imagem, já a soma dos pixels da área roxa da imagem pode ser obtido pela subtração do ponto 2 pelo ponto 1, a soma da área em laranja é alcançada pela subtração do ponto 3 com o 1, por fim, para obter o valor da soma dos pixels da área em azul, basta subtrair o ponto 3 e 2 do ponto 4 e somar o 1.	11
2.5	Matriz Hessiana na direção y e xy e aproximação com filtros de caixa.	12
2.6	Representação dos tamanhos dos filtros de caixa segundo a escala. Oitavas variando exponencialmente em relação ao eixo y e aritmeticamente no eixo x (6 em 6, 12 em 12, 24 em 24).	13
2.7	Filtros das wavelets de Haar para encontrar a resposta nas direções x e y	14
2.8	Demonstração do espaço criado pelas respostas da região do ponto de interesse ao filtro das wavelets de Haar e atribuição da orientação.	14
2.9	Quadro orientado de 4×4 sub-regiões em torno do ponto de interesse (esquerda) e soma das resposta das wavelets de Haar. . . .	15
2.10	As entradas do descritor de cada sub-região representam a natureza do padrão de intensidade da imagem. Esquerda: Quando existe uma região homogênea, todos os valores são baixos. Centro: com frequências na direção x , o valor de $\sum d_x $ é alto, porém todo os outros valores são baixos. Quando a intensidade é gradualmente aumentada na direção x , os dois valores de $\sum d_x$, e $\sum d_x $ são altos.	16

2.11	Representação gráfica dos pontos de interesse. Sendo que cada ponto marcado representa a localização do pontos de interesse com sua orientação (orientação da linha amarela) e sua intensidade (comprimento da linha). Os pontos em vermelho representam pontos de interesse que são escuros e estão em fundos claros e os azuis são pontos de interesse claros em fundos escuros.	16
2.12	Exemplo de casamento de pontos de interesse, onde um polígono é utilizado para ilustrar o casamento de pontos de interesse de objetos diferentes.	19
2.13	Nódulos radiculares em planta de soja.	21
2.14	Planta de soja com as partes do caule marcados.	21
2.15	Folha de soja com a bainha, pecíolo e limbo marcados.	22
2.16	Folhas unifolioladas (folha simples) da soja e trifoliolada (folha composta).	22
2.17	Estrutura das flores [91].	23
2.18	Esquema morfológico de um inseto. Fonte: Garbaletto e Campos [35]	27
2.19	Níveis de ação das principais pragas da soja. Fonte: Embrapa Soja [23]	29
2.20	Possíveis ataques de pragas em cada ciclo vegetativo da soja. Fonte: Embrapa Soja [46]	30
2.21	Tamanduá-da-soja.	31
2.22	Broca-das-axilas.	32
2.23	Broca-do-colo.	33
2.24	Lagarta-da-soja.	33
2.25	Lagarta-falsa-medideira.	34
2.26	Lagarta-do-linho.	35
2.27	Percevejo marrom.	36
2.28	Percevejo verde pequeno.	37
2.29	Percevejo verde.	38
2.30	Ficha (frente) utilizada no monitoramento dos principais insetos-praga amostrados em soja, para programas de manejo integrado de pragas.	39
2.31	Metodologias para a amostragem em plantações de soja com o pano-de-batida.	40
2.32	Metodologias para a amostragem em plantações de soja com a rede-de-varredura.	41
2.33	Drone DJI Phantom 3 Professional, que foi utilizado durante a dissertação.	43
4.1	Demarcação da área do experimento.	49
4.2	Configuração final do cultivo de soja na safra 2014/2015.	50
4.3	Configuração final do cultivo de soja na safra 2015/2016.	50
4.4	Banco de imagens de insetos.	52
4.5	Exemplo do banco de imagens de múltiplos insetos.	53

4.6	Casamento entre a imagem teste (esquerda) e conjunto de treinamento (direita). Cada casamento possui um valor que descreve a distância Euclidiana entre os descritores do ponto de interesse, quanto menor esse valor mais parecidos são os pontos. Com isso as métricas utilizadas podem utilizar tanto o valor da distância entre os pontos de interesse quanto a quantidade de pontos casados para definir a qual classe a imagem pertence.	56
4.7	Pode-se ver, da esquerda para a direita, primeiro o exemplo anotado, posteriormente a imagem de entrada e por fim a representação do espaço de votos. Para cada exemplo o casamento de pontos de interesse é feito, após isso o centro do objeto é estimado segundo a orientação do ponto de interesse. Após esta estimativa, é feito o voto no possível centro do objeto em um espaço de votos. Após a comparação com todo o conjunto de treinamento, os espaços de votos são avaliados e pontos máximo encontrados.	57
4.8	Imagem anotada da classe percevejo marrom adulto, com os pontos delimitando a área do objeto de interesse. O valor de cada ponto representa o número do objeto que está sendo marcado, sendo assim, mais de um objeto pode ser marcado em uma única imagem.	57
4.9	Resultado da imagem anotada pelo especialista. Os pontos coloridos representam as classes (ponto verde representa percevejo verde pequeno adulto, ponto roxo representa percevejo verde pequeno ninfa e ponto laranja representa percevejo marrom ninfa) e na tela da direita pode-se ver a contagem de cada classe (1 para percevejo verde adulto, 1 para percevejo marrom adulto e 1 para percevejo verde pequeno ninfa).	61
5.1	Matriz de confusão do resultado obtido pelo classificador SVM. .	64
5.2	Matriz de confusão do resultado obtido pelo método proposto. . .	64
5.3	Ilustração de partes do inseto que são bem características da espécie. Marcação em azul ilustra marca branca nas costas do inseto, e marcação em cinza ilustra o prolongamento do pronoto.	65
5.4	Ilustração das variações dos valores de tons de cinza na classe percevejo marrom. Da esquerda para direita temos: imagem original, visão superior do gráfico onde os pontos mais claros correspondem a vales e por fim visão lateral do gráfico.	66
5.5	Diferenças entre os percevejos dependendo do estágio ninfal. . . .	67
5.6	Ilustração gráfica das variações de tons de cinza em cada classe.	68
5.7	Diagrama de caixas dos classificadores avaliados utilizando Medida-F.	69
5.8	Diagrama das caixas do teste <i>post hoc</i> usando Medida-F. Segundo o gráfico, existe diferença estatística entre o módulo proposto e o classificador baseado em árvore de decisão.	69
5.9	Gráfico dos valores obtidos na contagem dos insetos da classe percevejo marrom adulto no conjunto de imagem. Linha em azul representa a contagem do especialista, em vermelho, o resultado obtido pelo módulo proposto.	70

5.10	Gráfico dos valores obtidos na contagem dos insetos da classe percevejo marrom ninfa no conjunto de imagem. Linha em azul representa a contagem do especialista, em vermelho, o resultado obtido pelo módulo proposto.	70
5.11	Gráfico dos valores obtidos na contagem dos insetos da classe percevejo pequeno adulto no conjunto de imagem. Linha em azul representa a contagem do especialista, em vermelho, o resultado obtido pelo módulo proposto.	71
5.12	Gráfico dos valores obtidos na contagem dos insetos da classe percevejo pequeno ninfa no conjunto de imagem. Linha em azul representa a contagem do especialista, em vermelho, o resultado obtido pelo módulo proposto.	71
5.13	Exemplo de erro causado por muitos ruídos na imagem. Na primeira imagem podemos notar a contagem de um percevejo pequeno adulto (ponto verde) e dois percevejos marrons adultos (ponto laranja).	72
5.14	Exemplo de erro causado pela sombra do percevejo. Na primeira imagem podemos notar a contagem de três percevejos pequenos adultos (ponto verde), um percevejo pequeno ninfa (ponto roxo) e um percevejo marrom adulto (ponto laranja).	73
5.15	Ilustração do gráfico da variação dos tons de cinza do exemplo com sombra.	73

Lista de Tabelas

2.1	Comparação genérica entre as três técnicas de aquisição de imagens aéreas. Fonte: Silva Neto (2013)	42
4.1	Manejo de Lagartas.	51
4.2	Manejo de Percevejos.	51
4.3	Dose das aplicações.	51
5.1	Resultados obtidos pelos classificadores que foram comparados com o módulo proposto. Entre parênteses desvio padrão de cada resultado obtido.	63
5.2	Resultado da aplicação do teste de Friedman para o conjunto de resultados dos classificadores.	65
5.3	Quantidade de insetos por classe. Sendo PMA a classe percevejo marrom adulto, PMN percevejo marrom ninfa, PPA percevejo pequeno adulto e PPN percevejo pequeno ninfa. Podemos notar que dado o nível de significância de 5% a contagem entre o método proposto não difere da contagem do especialista em nenhuma das classes.	67

Introdução

1.1 Considerações Iniciais

Segundo a Secretaria de Políticas Agrícolas do Brasil, estudos da Organização para a Cooperação e o Desenvolvimento Econômico (OCDE) e da Agência das Nações Unidas para Agricultura e Alimentação (FAO) apontam crescimento, entre 15% e 40%, na demanda mundial por diversos tipos de alimentos no período entre 2009 e 2019. Segundo esses estudos, a maior parte desse incremento de consumo ocorrerá nos países em desenvolvimento, onde um dos principais países a expandir sua produção e exportação é o Brasil, de modo a atender a maior parte desse aumento [66].

Embora atualmente a soja (*Glycine max*, L. Merr) seja a principal cultura de grãos brasileiros, antes da década de 70, a soja possuía uma importância secundária, entrando como uma opção de verão em sucessão à cultura de trigo que ocorria no inverno. Em 1970 houve uma explosão do preço da soja no mercado mundial e a partir daí a cultura de soja ganhou destaque e incentivo governamental, se tornando a principal cultura nacional [64].

No cenário nacional, de acordo com Companhia Nacional de Abastecimento (CONAB) [63], o Centro-Oeste Brasileiro é o principal produtor da cultura, sendo que a previsão de área semeada para a safra de 2015/2016 é de 23,27 milhões de hectares, com uma produtividade média de 3,841 kg por hectare, totalizando 89,37 milhões de kg que devem ser colhidas. A segunda grande região produtora de soja no Brasil é a região sul, que possui a previsão de cultivo de 19,6 milhões de hectares, e deve ter uma produtividade de 3,872 kg por hectare, totalizando um montante de 75,92 milhões de kg. Os três maiores produtores de soja no Brasil são os Estados do Mato Grosso, Paraná e Rio Grande do Sul que possuem a previsão de colheita de 50,6 milhões de kg, 38,5 milhões de kg e 31 milhões de kg, respectivamente, nesta safra de 2015/2016.

Entre os principais fatores que limitam o rendimento das práticas de agricultura estão as pragas, seres nocivos aos vegetais, que incluem agentes que causam doenças nas plantas (fungos, bactérias, vírus e nematóides), insetos, ácaros e plantas daninhas. A FAO considera que as pragas são responsáveis,

em média, por cerca de 42,1% das perdas na produção [54].

É possível aumentar em até 42,1% a produção, somente eliminando os efeitos prejudiciais das pragas agrícolas, o que mostra a necessidade urgente do manejo destas pragas. Estima-se que 15,6% dos danos das plantações são causados por insetos e ácaros, os fitopatógenos (agentes causadores de doenças) são responsáveis por 13,3% e os 13,2% restante são causados por plantas daninhas [54].

Segundo Namias et. al. [76] a agricultura tem se tornado uma indústria onde cada vez mais se faz importante o conhecimento em resposta a questões ambientais e econômicas. Como é um importante setor brasileiro recebe diversos incentivos, que alavancam abordagens agrícolas baseadas no conhecimento, voltados a aumentar a eficiência da agricultura, melhorar a rentabilidade, reduzir impactos ambientais e devem impulsionar ainda mais a inovação tecnológica. Assim, o segmento do agronegócio é uma área com grande potencial de incentivo a inovações tecnológicas.

Para Theis [106] os investimentos em tecnologia são os principais motores do crescimento econômico global a longo prazo. Segundo Herwitz et. al. [44], a agricultura tem se tornado uma indústria onde cada vez mais se faz importante o investimento em conhecimento para se obter respostas a questões ambientais e econômicas. Abordagens agrícolas baseadas em tecnologia são destinadas a aumentar a produção da agricultura e a reduzir os impactos ambientais e devem impulsionar ainda mais a chegada de novas tecnologias ao campo. Logo, o segmento do agronegócio é uma área com grande potencial para essas inovações, como o sensoriamento remoto e a utilização de Veículos Aéreos Não Tripulados (VANTs).

Os VANTs que foram inicialmente projetados para fins militares, têm sido utilizados para diversos outros fins, como auxílio em vigilância, na cartografia, no controle de tráfego urbano, missões de busca e resgate, acesso a regiões críticas, bem como na agricultura - em especial, na agricultura de precisão [58]. A agricultura cada vez mais necessita de alguma implementação tecnológica que a beneficia em algum estágio produtivo ou em todos. A utilização de VANTs para a coleta de imagens nas quais, posteriormente, serão utilizadas técnicas de visão computacional para atingir objetivos diversos, como detecção de possíveis focos de doenças ou pragas, são nesse contexto, bons exemplos.

O monitoramento de safras a partir de imagens obtidas por VANTs possibilita a aquisição de dados, como imagens georreferenciadas da área das lavouras, desde a fase do plantio até a fase da colheita. Tais informações são úteis para o manejo e monitoramento de safras, bem como na gestão e logística da produção, entre outros. Segundo Silva [97] as imagens obtidas a partir do VANT aliadas a uma boa técnica de geoprocessamento, traz resultados satisfatórios acarretando uma melhor ocupação e tratamento do solo, plantio e colheita especializadas além da redução do custo de todo o processo. A agricultura, que é a base da economia brasileira, tende a ser mais tecnológica. Hoje existem diversas pesquisas e projetos voltados para esta área, o que antes era feito com imagens de satélite hoje ganhou um forte aliado, os VANTs.

Embora muitos tipos de imagens de satélite estejam disponíveis de graça, em baixa resolução (Landsat, MODIS) e com custo em alta resolução (WorldView, Quickbird), às vezes essas imagens não possuem resolução alta o suficiente, ou cobrem somente uma área limitada, ou capturam imagens em

somente alguns momentos do dia, situações essas que limitam sua utilização para diversas atividades. Se a resolução da imagem não é alta o suficiente para ver os detalhes de uma determinada área, ou esta área não pode ser completamente coberta pelas imagens, uma análise desta área de interesse será difícil de ser concluída. A capacidade de obter imagens de alta resolução com baixo custo proporciona aos VANTs um grande potencial para o preenchimento da lacuna de utilização deixado pelos satélites [42].

Devido ao tamanho dos VANTs e sua aerodinâmica, os VANTs são capazes de voar em altitudes baixas, coletando informações mais precisas do que os satélites. Este fator também significa que eles podem voar abaixo das nuvens, tornando-os mais vantajosos em áreas tropicais, onde as nuvens podem impedir a coleta de imagens por satélites. Os VANTs típicos podem capturar imagens com cerca de 6 cm de resolução espacial quando voando em uma altitude um pouco mais alta que 200 metros [87]. Com o dinamismo presente na agricultura de precisão, onde os ciclos de cultivo estão cada vez mais curtos, a coleta de dados por demanda para o monitoramento aéreo do cultivo em tempo real vai se tornando cada vez mais importante, o que torna o VANT ainda mais vantajoso.

Diversos grupos de pesquisa dentro e fora do estado de Mato Grosso do Sul têm desenvolvido trabalhos em computação que se relacionam com a produção de soja. Mura et. al. [75] dedicam seu trabalho para quantificar a área danificada por lagartas em folhas de soja contidas em imagens digitais. A equipe utilizou um scanner para a obtenção da imagem, onde a folha da soja era colocada sobre papel branco e digitalizada, após a coleta, a imagem era transformada em tons de cinza e então pré-processada para a amenização dos ruídos e segmentada para eliminação de informações irrelevantes. Após o pré-processamento, as bordas da imagem foram fechadas e por fim, foram avaliadas as regiões danificadas da folha para a estimativa da área afetada. O desempenho do sistema proposto obteve menor erro percentual médio que um especialista humano.

Seguindo a metodologia de Mura, é proposto por Nazaré et. al. [77] o desenvolvimento de um sistema para quantificar a área foliar danificada em folhas de soja contidas em imagens digitais. Para encontrar a área de cada dano, primeiro foram quantificados os danos internos da folha, aqueles que não alcançam a borda. Em seguida, diferentemente do que foi feito por Mura, as bordas são recuperadas automaticamente, por fim, finaliza-se a quantificação da área afetada por meio da subtração de imagens. Para experimentar a abordagem proposta, foram utilizadas 185 amostras de folhas de soja com danos causados por agentes da natureza (como lagartas) colhidas aleatoriamente. O erro absoluto médio obtido foi sete vezes menor quando comparado com os erros obtidos no trabalho de Mura e na classificação humana.

Com o intuito de colaborar com o setor agropecuário do estado do Mato Grosso do Sul e de todo país por meio de geração de novas tecnologias, este trabalho tem como objetivo analisar a aplicação da Extração de Pontos de Interesse e Casamento de modelos para a identificação de pragas em plantações de soja por meio de padrões visuais presentes em imagens digitais aéreas previamente processadas por algoritmos de Visão Computacional e áreas afins, propondo uma nova estratégia para tal identificação. Para a extração de pontos de interesse, serão utilizados os algoritmos SURF (*Speeded Up Robust Feature*) e SIFT (*Scale Invariant Feature Transformation*) que realizam a análise

em imagens em tons de cinza.

Dentre os problemas encontrados o que foi considerado na presente proposta foi a infestação de insetos na cultura da soja. Para a identificação destes insetos, dois bancos de imagens dedicados ao problema foram feitos, sendo o primeiro com exemplos pontuais dos insetos, e o segundo com fotos de grupos de insetos em pano-de-batida (pano branco utilizado na amostragem de insetos em campo), sendo estas fotos obtidas por VANTs. Com as imagens pontuais dos insetos, um módulo de classificação utilizando casamento de modelos e extração de pontos de interesse foi desenvolvido e com isso o módulo de contagem de insetos pode ser desenvolvido e avaliado.

Para a criação do primeiro banco de imagens, os insetos eram coletados em campo experimental desenvolvido pelo projeto e levados ao laboratório, para que fossem classificados por um especialista e então fotografados, este banco de imagens contou com 3 espécies de insetos, sendo estas as que tiveram predominância no campo experimental. Cada espécie foi representada por 60 imagens, o que totalizou um número de 180 imagens. Já o segundo banco de imagens foi feito a campo, enquanto a amostragem de insetos, pelo método de pano-de-batida, era efetuada o VANT Phantom 3 sobrevoava o pano e fazia as fotos, este banco de imagens contou com um conjunto de 60 imagens.

Para a avaliação do módulo de classificação, classificadores baseados em árvore de decisão, Máquina de Vetor de Suporte (Support Vector Machine ou SVM) e os K vizinhos mais próximos (KNN) foram utilizados para comparação, sendo a Medida-F (F-Score) a métrica utilizada para medir o desempenho de cada classificador, junto com a matriz de confusão. Já para a avaliação do módulo de contagem de insetos, a contagem feita pelo módulo foi comparada com a contagem de um especialista, para verificar se as contagens eram estatisticamente iguais, foi feita a análise de variância com nível de significância de 5%.

Em resumo este trabalho contribuiu para a criação de diversos bancos de imagens relacionados a soja, em especial um banco de imagens pontuais de insetos que são prejudiciais a soja, e um banco de imagens de grupos de insetos sobre o pano-de-batida. Outra contribuição do trabalho, foi o desenvolvimento de um módulo de classificação e de contagem de insetos baseado em extração de pontos de interesse e casamento de modelos. Além, da apresentação de um estudo comparativo entre o módulo proposto e classificadores comumente utilizados. Vale a pena ressaltar que todo o material produzido por este trabalho está disponível ao público.

1.2 Estrutura do Trabalho

O próximo capítulo faz a abordagem teórica dos conceitos que são explorados neste trabalho, como visão computacional, VANTs e cultura da soja. O terceiro capítulo traz alguns trabalhos correlatos ao tema. Já o quarto capítulo apresenta os detalhes do desenvolvimento da aplicação, junto com o delineamento experimental, ficando o quinto capítulo com a apresentação dos resultados obtidos e discussão dos mesmos e por fim, o sexto capítulo mostra as considerações finais.

Fundamentação Teórica

2.1 *Detecção e Descrição de Pontos de Interesse*

Detecção de pontos de interesse é a identificação de determinados atributos em uma imagem (por exemplo, contornos, bordas, etc). A principal propriedade de algoritmos de detecção de pontos de interesse é a repetibilidade, isto é, dadas duas imagens distintas do mesmo objeto ou cena, obtidas sob diferentes condições de visualização, uma elevada porcentagem de pontos de interesse da cena devem ser encontradas em ambas as imagens [111]. Além da propriedade de repetibilidade, bons detectores de pontos de interesse devem possuir distintividade, localidade, quantidade, precisão e eficiência. A importância de cada uma destas características vai depender da aplicação desejada.

Uma vez que um conjunto de pontos de interesse foram detectados a partir de uma imagem, algumas medições são feitas a partir da região destes pontos e transformadas em descritores locais, ou descritores de pontos de interesse. Pesquisadores têm desenvolvido uma variedade de descritores de pontos de interesse para descrever o conteúdo de uma imagem, tais como SIFT [60], SURF [4], HOG [21], GLOH [69] e DAISY [109]. A seguir, serão resumidos os descritores SIFT e SURF, que são as técnicas mais utilizadas para tarefas de reconhecimento visual.

2.1.1 *Scale Invariant Feature Transformation (SIFT)*

SIFT [59] [60] foi originalmente proposto para a detecção e descrição de pontos de interesse. O descritor SIFT descreve cada ponto de interesse com um vetor de característica com 128 dimensões. Sua detecção é invariante à escala, rotações, transformações e parcialmente invariante a mudanças de iluminação o que o torna robusto para diversas aplicações. O SIFT possui quatro estágios para a localização e descrição dos pontos de interesse, que são descritos a seguir:

- **Detecção Extrema em Espaço de Escala** - O primeiro estágio da busca é sobre todas as escalas da imagem. Ele é realizado eficientemente pela

média da função da diferença Gaussiana para identificar potenciais pontos de interesse que são invariantes em orientação e escala.

- **Localização dos pontos de interesse** - Para cada ponto candidato a ponto de interesse, um modelo detalhado é ajustado para determinar a escala e a localização deste ponto. Os pontos que são eleitos como ponto de interesse são selecionados com base em suas médias de estabilidade, esta seleção será melhor descrita posteriormente.
- **Atribuição de orientação** - Uma ou mais orientações são atribuídas ao ponto de interesse, essas orientações são baseadas nas direções dos gradientes locais da imagem. A partir deste ponto todas as operações serão executadas na imagem transformada em relação à sua orientação, escala e localização, garantindo a invariância a esses tipo de transformação.
- **Construção dos descritores de pontos de interesse** - Os gradientes locais da imagem são medidos em uma escala selecionada na região em torno de cada ponto de interesse. Estes gradientes são transformados em uma representação que admite grandes distorções nos níveis de mudança de iluminação e distorção de forma locais.

Detecção Extrema em Espaço de Escala

Para o SIFT, pontos de interesse correspondem a locais extremos no espaço de escalas. Porém o núcleo para a construção do espaço de escalas é a função Gaussiana, visto que o espaço de escalas de uma imagem é definido pela função $L(x, y, \sigma)$ que é obtida pela convolução da Gaussiana $G(x, y, \sigma)$ com uma imagem de entrada $I(x, y)$:

$$L(x, y, \sigma) = G(x, y, \sigma) * I(x, y) \quad (2.1)$$

Onde, $*$ é a operação de convolução no ponto de coordenada x e y , e

$$G(x, y, \sigma) = \frac{1}{2\pi\sigma^2} e^{-\frac{(x^2+y^2)}{2\sigma^2}} \quad (2.2)$$

É a Gaussiana com escala variada, sendo σ o desvio padrão da distribuição Gaussiana.

Para detectar eficientemente pontos de interesse estáveis no espaço de escalas, Lowe [59] propõe a utilização de um espaço de escala obtido através da função da diferença Gaussiana convolucionada com a imagem $D(x, y, \sigma)$, que pode ser calculado a partir da diferença de duas escalas próximas, que são separadas por um fator de multiplicação constante k .

$$D(x, y, \sigma) = L(x, y, k\sigma) - L(x, y, \sigma) \quad (2.3)$$

Segundo Lowe [59] esta função é eficiente, visto que L deve ser calculada de qualquer maneira e D pode ser obtido por uma simples subtração de imagens.

Assumindo que o espaço de escalas é uma família de imagens referentes a um conjunto discreto de níveis de suavização e diferentes taxas de amostragem, todas elas derivadas de uma imagem de entrada inicial com um dado nível de suavização inicial. Esta família de imagens é dividida em subfamílias que compartilham uma taxa de amostragem comum. Visto que no algoritmo

original do SIFT, a taxa de amostragem é iterativamente diminuída por um fator de 2, essas subfamílias podem ser chamadas de oitavas.

O primeiro passo para a detecção dos pontos de interesse da imagem, é a convolução da imagem com a função Gaussiana para a produção de um espaço de escalas. As imagens convolucionadas são agrupadas por oitavas, cada oitava do espaço de escalas é dividido por um número, s , de intervalos. Para que a detecção extrema cubra todas as oitavas, deve-se produzir $s + 3$ imagens para cada oitava. As imagens de escalas adjacentes mostradas na coluna da esquerda na Figura 2.1 são subtraídas para produzir as imagens da diferença Gaussiana, ilustradas na coluna da direita.




Figura 2.1: Ilustração das imagens com desfoque Gaussiano em diferentes escalas, e imagens com a diferença Gaussiana.

Os pontos de interesse são identificados pelos locais de máxima e mínima das imagens da diferença Gaussiana através das escalas. Cada pixel das imagens da diferença Gaussiana são comparados com seus 8 vizinhos que possuem a mesma escala e com 9 vizinhos correspondentes de cada escalas adjacente, posterior e inferior. Se o pixel é o local máximo ou mínimo, ele é selecionado como candidato à ponto de interesse. A Figura 2.2 ilustra esse processo.

Com os candidatos a pontos de interesse encontrados pela comparação com seus vizinhos, o próximo passo é detalhar as informações referentes à localização, escala e proporções das principais curvaturas. Estas informações permitem que os pontos que possuem baixo contraste (o que os torna sensível ao ruído) ou que são mal localizados pelas bordas possam ser rejeitados.

Segundo Lowe [59] a função com valor extremo $D(\hat{X})$ é útil para rejeitar os pontos de interesse instáveis com baixo contraste. Esta função é descrita pela Equação 2.4.

$$D(\hat{X}) = D + \frac{1}{2} \frac{\partial D^T}{\partial X} \hat{X} \quad (2.4)$$




Figura 2.2: Detecção local extrema, o pixel preto é comparado com 26 vizinhos, sendo a comparação feita em três dimensões $3 \times 3 \times 3$, que se expandem pelas imagens da diferença Gaussiana de escalas adjacentes.

Onde, $\hat{X}$ é calculado ajustando a derivada de $D(x, y, \sigma)$ para zero.

Para a estabilidade dos pontos de interesse encontrados, rejeitar somente os com baixo contraste ainda não é suficiente. A diferença Gaussiana possui uma forte resposta nas bordas, que pode gerar ruídos na seleção de pontos de interesse. Assim, para filtrar os pontos de interesse com as respostas da diferença Gaussiana nas bordas, Lowe[59] utiliza a Equação 2.5.

$$\frac{Tr(H)^2}{Det(H)} < \frac{(r + 1^2)}{r} \quad (2.5)$$

Onde, H é uma matriz Hessiana de 2×2 que descreve a curvatura principal feita pela diferença Gaussiana descrita por Lowe [59], e r é a razão entre a maior e menor magnitude da curvatura.

Após o filtro dos pontos de interesse, cada ponto de interesse deve receber uma orientação baseada nas propriedades locais da imagem. O descritor do ponto de interesse pode ser representado segundo à sua orientação o que lhe dá invariância à rotação da imagem. A escala do ponto de interesse é utilizada para selecionar a imagem suavizada, L , com escala mais próxima. Então para cada ponto $L(x, y)$ da imagem selecionada, a magnitude $m(x, y)$ e a orientação $\theta(x, y)$ do gradiente são calculados usando as diferenças de pixels:

$$m(x, y) = \sqrt{(L(x + 1, y) - L(x - 1, y))^2 + (L(x, y + 1) - L(x, y - 1))^2} \quad (2.6)$$

$$\theta(x, y) = \tan^{-1}\left(\frac{L(x, y + 1) - L(x, y - 1)}{L(x + 1, y) - L(x - 1, y)}\right) \quad (2.7)$$

Um histograma de orientação é construído pelos gradientes de orientação dos pontos amostrados, $L(x, y)$, da região em volta do ponto de interesse. Este histograma de orientação possui 36 bins cobrindo uma faixa de 360° . Cada amostra adicionada ao histograma é ponderada pela sua magnitude. Os picos do histograma de orientação correspondem às direções dominantes dos gradientes locais. O SIFT encontra o maior pico dentro do histograma, caso

exista algum outro pico com magnitude semelhante (acima de 80%) ao pico encontrado, dois pontos de interesse serão criados, com a mesma localização e escala, porém com orientações diferentes. Caso não exista nenhum outro pico semelhante a orientação do maior pico é atribuída ao ponto de interesse.

Representação de Características do SIFT

Com a orientação do ponto de interesse definida, o descritor de características do ponto de interesse pode ser calculado, primeiro a magnitude do gradiente e a orientação são amostrados em torno da localização do ponto de interesse. Para manter a invariância à rotação, as coordenadas do descritor e a orientação do gradiente são rotacionados segundo a orientação do ponto de interesse.

Uma função Gaussiana é utilizada para dar peso à magnitude do gradiente em cada ponto na vizinhança do ponto-chave, com uma janela de suavização Gaussiana de escala σ igual à metade da largura da janela do descritor. Isto é feito para evitar mudanças súbitas do descritor a pequenas mudanças na posição da janela, e também serve para reduzir a ênfase nos gradientes que estão longe do centro do descritor, que são mais afetados por erros. Esse processo está ilustrado com o círculo no lado esquerdo da Figura 2.3. O descritor do ponto de interesse é ilustrado no lado direito da Figura 2.3, a figura mostra oito direções para cada histograma de orientação, sendo que o tamanho de cada flecha representa a magnitude do histograma.




Figura 2.3: Descritor de características do SIFT.

Cada histograma possui 8 bins, e cada descritor contém um conjunto de 4 histogramas ao redor do ponto de interesse. Isto proporciona um vetor de $4 \times 4 \times 8 = 128$ elementos que descrevem as características obtidas pelo SIFT. Este vetor é normalizado para proporcionar invariância às mudanças na iluminação. Já os parâmetros de direção para os pontos de interesse são determinados pela normalização do ângulo no espaço Euclidiano.

2.1.2 Speeded Up Robust Feature (SURF)

O SURF [4] é um algoritmo utilizado para a detecção de pontos de interesse e construção de descritores destes pontos de interesse em imagens, conhe-

cido por ser robusto, pode ser utilizado em tarefas baseadas em visão computacional, como reconhecimento de objetos e reconstrução 3D. Os pontos de interesse calculados com o SURF são invariantes à escala e rotação. Como detector, o SURF localiza os pontos de interesse que possuem a maior variação em uma imagem em tons de cinza, enquanto o descritor calcula vetores de características em volta de cada um destes pontos de interesse. Nas próximas seções será descrito como o SURF é utilizado para fins de reconhecimento de padrões em uma imagem.

Deteção de Pontos de Interesse

Para a deteção de pontos de interesse, o SURF utiliza o determinante de uma aproximação da matriz Hessiana. Na aproximação da matriz Hessiana, é utilizada a imagem integral ao invés da original para a redução do tempo de processamento. A matriz Hessiana $H(x, \sigma)$ para um dado ponto $p = (x, y)$ da imagem I com escala σ é dada por:

$$H(p, \sigma) = \begin{vmatrix} L_{xx}(p, \sigma) & L_{xy}(p, \sigma) \\ L_{xy}(p, \sigma) & L_{yy}(p, \sigma) \end{vmatrix} \quad (2.8)$$

Onde $L_{xx}(p, \sigma)$ é a convolução da derivada parcial de segunda ordem da Gaussiana $\frac{\partial^2}{\partial x^2} g(\sigma)$ com a imagem I no ponto p na direção horizontal, o mesmo ocorre com $L_{x,y}(p, \sigma)$ e $L_{y,x}(p, \sigma)$ na direção diagonal e $L_{yy}(p, \sigma)$ na direção vertical.

Imagem integral é um método de representação de uma imagem, esta representação pode ser feita somando todos os valores dos pixels (podendo ser somente um valor, no caso de representação de tons de cinza, ou três valores, na representação de cores) e formando uma matriz, onde cada posição da matriz possui a soma de todos os valores das posições anteriores, ou seja, dada uma matriz II , a posição $II_{2,2}$ terá a soma dos valores das posições: $I_{1,1}, I_{1,2}, I_{2,1}$ e $I_{2,2}$ da imagem I . Logo, para construir a imagem integral basta utilizar a Equação 2.9

$$II(x, y) = \sum_{x' < x, y' < y} I(x', y') \quad (2.9)$$

Onde, II é a representação da imagem integral e I é a matriz que representa a imagem. A Figura 2.4 ilustra um exemplo de imagem integral, onde deseje-se somar os valores dos pixels que estão dentro dos retângulos A, B, C e D. A soma dos pixels dentro do retângulo A é o valor da imagem integral no ponto 1, já a soma dos pixels do retângulo B é obtido pela subtração do valor do ponto 2 pelo 1, a soma dos pixels em C tem o valor da subtração do valor do ponto 3 com o 1, e por fim para obter a soma dos pixels em D basta subtrair o valor do ponto 4 pelo ponto 3 e 2 e somar o 1, visto que a área de A é descontada nas duas subtrações anteriores.




Figura 2.4: Representação da imagem integral, com exemplo de soma dos pixels dentro dos retângulos. A somatória dos pixels na área verde da imagem é obtida no ponto 1 marcado na imagem, já a soma dos pixels da área roxa da imagem pode ser obtido pela subtração do ponto 2 pelo ponto 1, a soma da área em laranja é alcançada pela subtração do ponto 3 com o 1, por fim, para obter o valor da soma dos pixels da área em azul, basta subtrair o ponto 3 e 2 do ponto 4 e somar o 1.

No SURF as derivadas parciais de segunda ordem da Gaussiana são aproximadas, essa aproximação é chamada de filtro de caixa, que podem ser avaliados com grande rapidez por imagens integrais. O filtro de caixa 9×9 ilustrado na Figura 2.5 é a aproximação da derivada parcial de segunda ordem da Gaussiana com $\sigma = 1.2$, este filtro de caixa é o utilizado na menor escala. As aproximações das derivadas parciais de segunda ordem da Gaussiana são denotadas por Bay [4] como D_{xx} para $L_{xx}(p, \sigma)$, D_{yy} para $L_{yy}(p, \sigma)$ e finalmente D_{xy} para $L_{xy}(p, \sigma)$. Na Figura 2.5, da esquerda para a direita, pode-se notar a derivada parcial de segunda ordem discreta da Gaussiana nas direções vertical e diagonal, respectivamente. As duas imagens da direita são as aproximações feitas pelo SURF nas direções vertical e na direção diagonal. As regiões cinzas são iguais a zero.




Figura 2.5: Matriz Hessiana na direção y e xy e aproximação com filtros de caixa.

Assim pode-se calcular o determinante:

$$\det(H_{approx}) = D_{xx}D_{yy} - (\omega D_{xy})^2 \quad (2.10)$$

Onde ω é a medida para a conservação de energia entre os núcleos Gaussianos e a aproximação dos núcleos Gaussianos e $\det(H_{approx})$ é a matriz Hessiana aproximada utilizada pelo SURF.

Espaço de Escalas e Oitavas

Normalmente a invariância à escala pode ser feita com a utilização de uma pirâmide de imagens. Em um cenário geral, a imagem original é suavizada pela Gaussiana e uma amostra desta imagem é feita com uma escala maior, com ela o processo se repete, novamente será suavizada pela Gaussiana e uma nova amostra será feita em uma escala maior, e assim a pirâmide é montada. Porém o SURF faz uma contribuição nesta área, o SURF implementa a invariância à escala com os filtros de caixa.

Ao invés de gerar imagens em diferentes escalas e posteriormente buscar os pontos de interesses nesse conjunto de imagens, o SURF aumenta o tamanho do filtro que será convolucionado com a imagem. Os tamanhos deste filtro variam de acordo com o conceito de oitavas. Como o valor das oitavas variam exponencialmente, podendo haver perda de informação entre as diferentes oitavas, o conceito de camadas é utilizado, onde as oitavas são divididas em camadas, que representam o tamanho do filtro que será aplicado na imagem. Essas camadas aumentam seu tamanho seguindo uma progressão aritmética,

sendo variações suaves que visam preservar as informações entre diferentes oitavas.

Na primeira oitava os filtros possuem os tamanhos de 9×9 , seguidos de 15×15 , 21×21 e 27×27 . Para maiores escalas a diferença entre as camadas da oitava deve dobrar conforme a escala, sendo assim para cada nova oitava, o incremento entre as camadas deve ser dobrado, sendo 6 para a primeira oitava 12 para a segunda, 24 para a terceira, e assim, sucessivamente para cada nova oitava adicionada. A Figura 2.6 ilustra os tamanhos do filtro para as diferentes oitavas.




Figura 2.6: Representação dos tamanhos dos filtros de caixa segundo a escala. Oitavas variando exponencialmente em relação ao eixo y e aritmeticamente no eixo x(6 em 6, 12 em 12, 24 em 24).

Então, para encontrar os pontos de interesse em diferentes escalas em uma imagem, é preciso aplicar uma supressão de não máximos em 3 dimensões. Esta última etapa é fundamental, visto que cada vez que é aplicada a convolução do filtro de caixa na imagem, uma matriz de resposta é obtida, e para encontrar os pontos de interesse é necessário encontrar os valores mais altos dentro destas matrizes. Porém as matrizes de escalas vizinhas não podem ser desconsideradas, quando um ponto máximo é encontrado, todos os outros valores são suprimidos. Assim, é feita a localização dos pontos máximos de variação da imagem no espaço de escala e no espaço da imagem onde são obtidas a localização dos pontos de interesse e a escala que este foi obtido.

Descrição dos Pontos de Interesse

Para a descrição do ponto de interesse o SURF realiza dois passos, o primeiro passo consiste em atribuir uma orientação à área do ponto de interesse, essa orientação é atribuída com o intuito de tornar o descritor resistente a variações de rotação. Então após definir uma orientação ao ponto de interesse, uma região quadrada em volta do ponto de interesse é construída e o SURF extrai as informações desta região. Este processo será melhor descrito nas seções seguintes.

Atribuição de Orientação Para atribuir uma direção ao ponto de interesse, dadas as coordenadas do ponto de interesse na imagem, uma área ao redor desta coordenada é utilizada para calcular as respostas dos filtros das wavelets de Haar nas direções x e y , essas respostas representam a variação dos

valores nos eixos x e y . A Figura 2.7 ilustra os filtros utilizados. A área utilizada para definir a orientação do ponto de interesse é circular e possui um raio de $6s$, onde s é a escala em que o ponto de interesse foi detectado.




Figura 2.7: Filtros das wavelets de Haar para encontrar a resposta nas direções x e y .

As respostas dos filtros das wavelets de Haar para cada pixel são representadas em um espaço, onde a resposta do filtro na horizontal (x) é representada ao longo da abcissa e a resposta na vertical (y) é representada na ordinária. Para definir a orientação dominante do ponto de interesse o espaço que representa as respostas ao filtro é dividido em janelas que cobrem um ângulo de $\frac{\pi}{3}$, então para cada janela as respostas da vertical e horizontal são somadas, gerando um vetor para cada janela, o maior vetor define a orientação do ponto de interesse. A Figura 2.8 ilustra o espaço criado pelas respostas ao filtro das wavelets de Haar, onde o espaço foi dividido em janelas que cobrem o ângulo de $\frac{\pi}{3}$ e a flecha vermelha ilustra a orientação atribuída ao ponto de interesse.




Figura 2.8: Demonstração do espaço criado pelas respostas da região do ponto de interesse ao filtro das wavelets de Haar e atribuição da orientação.

Componentes do Descritor Para a extração do descritor do ponto de interesse, o primeiro passo é a definição de uma área quadrada em torno do ponto de interesse orientada na direção escolhida no passo anterior. O tamanho desta área é $20s$, onde s é a escala em que o ponto de interesse foi detectado.

Após a definição da área do quadrado, é realizada uma divisão desta área que resulta em sub-áreas de 4×4 . Para cada sub-área, são calculadas as respostas do filtro das wavelets de Haar novamente, mas diferente da etapa anterior, a horizontal é definida em relação à orientação atribuída ao ponto de interesse, assim como a vertical é em relação a orientação do ponto de interesse. Cada resposta obtida pelo filtro das wavelets de Haar na horizontal é chamado de d_x e as respostas obtidas na vertical de d_y . A Figura 2.9 ilustra o cálculo da resposta ao filtro das wavelets de Haar.




Figura 2.9: Quadro orientado de 4×4 sub-regiões em torno do ponto de interesse (esquerda) e soma das resposta das wavelets de Haar.

Com as respostas das wavelets de Haar os atributos de cada sub-área podem ser extraídos. Para cada sub-área um vetor de descrição v com quatro dimensões é extraído, onde:

$$v = (\sum d_x, \sum d_y, \sum |d_x|, \sum |d_y|) \quad (2.11)$$

Assim para cada sub-área (4×4) do ponto de interesse quatro atributos são extraídos, resultando em um vetor de características de 64 posições. A resposta das wavelets de Haar é invariante a influência de iluminação. A invariância ao contraste (um fator de escala) pode ser obtida transformando o descritor em um vetor unitário.

A Figura 2.10 ilustra as propriedades do descritor em três imagens de fundo de um inseto, com diferentes padrões de intensidade nas sub-regiões. Onde na imagem da esquerda, existe uma região homogênea, todos os valores são relativamente baixos. Na imagem do meio, com frequências na direção x , o valor de $\sum |d_x|$ é alto, porém todos os outros permanecem baixos. Na direita, se a intensidade é aumentada gradativamente na direção x , ambos os valores de $\sum d_x$ e $\sum |d_x|$ são altos.

A Figura 2.11 ilustra o detector de pontos de interesse em um inseto que ataca a soja, onde é representada a natureza das características dos detectores baseados na matriz Hessiana. Nela podemos ver a localização dos pontos




Figura 2.10: As entradas do descritor de cada sub-região representam a natureza do padrão de intensidade da imagem. Esquerda: Quando existe uma região homogênea, todos os valores são baixos. Centro: com frequências na direção x , o valor de $\sum |d_x|$ é alto, porém todos os outros valores são baixos. Quando a intensidade é gradualmente aumentada na direção x , os dois valores de $\sum d_x$, e $\sum |d_x|$ são altos.

de interesse, sua orientação (orientação da linha) e sua intensidade (comprimento da linha). Pontos em azul são pontos de interesse claros em fundos escuros e os em vermelho pontos de interesse escuros em fundos claros, essa informação é relevante no estágio de casamento entre os pontos, visto que somente pontos com mesmo contraste serão comparados.




Figura 2.11: Representação gráfica dos pontos de interesse. Sendo que cada ponto marcado representa a localização do pontos de interesse com sua orientação (orientação da linha amarela) e sua intensidade (comprimento da linha). Os pontos em vermelho representam pontos de interesse que são escuros e estão em fundos claros e os azuis são pontos de interesse claros em fundos escuros.

2.2 Casamento de Pontos de Interesse

Neste trabalho o casamento de modelos será aplicado no resultado obtido pela aplicação do algoritmo de extração de pontos de interesse. Este casamento deverá relacionar os pontos de interesse entre o modelo a ser buscado e a imagem de entrada. Esta abordagem pode ser chamada de *Casamento de Pontos de Interesse*. Quando Bay et. al. [4] apresentaram o SURF, os mesmos utilizaram dois modelos de casamento de pontos de interesse, um baseado em um limiar de similaridade, e outro baseado na quantidade de vizinhos mais próximos.

Já o casamento de modelos dos pontos de interesse obtidos pelo SIFT é comumente obtido pelo cálculo da distância Euclidiana dos descritores de cada ponto de interesse. Este algoritmo utiliza a taxa da distância dos vizinhos mais próximos, onde o ponto é definido como casamento se a distância entre o ponto de interesse for menor do que 60% da distância a seu vizinho mais próximo, esta metodologia minimiza o número de falsos positivos [70].

Para encontrar um casamento de um único ponto de interesse, este algoritmo deve efetuar uma quantidade imensa de cálculos. Supondo que o tamanho do descritor de um ponto de interesse seja n , para encontrar um casamento deste ponto de interesse, o algoritmo deve fazer n multiplicações, adições e subtrações para cada ponto de interesse que existir na base de dados. Como uma imagem pode ter diversos pontos de interesses, isso se torna um bloqueante para repositórios com grande quantidade de pontos de interesse. Para resolver esse problema, foram propostos alguns algoritmos que utilizam a aproximação do vizinho mais próximo, como o *Best-bin First* proposto por Lowe [60], que acelera significativamente o tempo do algoritmo. Esses algoritmos serão discutidos na próxima seção.

2.2.1 Algoritmos de Busca Pelos Vizinhos mais Próximos

Muitas aplicações que utilizam pontos de interesse para a localização de objetos de interesse ou rastreamento, necessitam encontrar casamentos / correspondências de imagens com um grande repositório. Nesses tipos de casos, o tempo necessário para encontrar as correspondências entre a imagem e o repositório acaba sendo muito grande. Para estes tipos de aplicações, vários métodos baseados em árvore para a busca dos vizinhos mais próximos foram propostos.

Dos métodos propostos, o mais utilizado foi proposto por Friedman et. al. [30], este método envolve a construção de uma *kd-tree*. A *kd-tree* possui o esquema de uma árvore binária, onde cada nó é um ponto do espaço, e cada nó não folha divide o subespaço em dois com um hiperplano em um eixo, a sub-árvore esquerda do nó não folha representa os pontos que estão à esquerda do hiperplano, esta ramificação ocorre a cada nova inserção de nó. Segundo a literatura, os métodos que utilizam *kd-tree* trabalham bem com busca de vizinho mais próximo com dados de baixa dimensão, mas rapidamente se tornam menos efetivos quando o número de dimensões é grande [110]. Para os descritores de ponto de interesse, que normalmente são maiores que 10, utilizar busca de vizinhos mais próximos com *kd-tree* não é recomendável.

Para um grande número de aplicações, talvez não seja necessário saber a correspondência exata dos vizinhos mais próximos, uma correspondência

aproximada já é o suficiente. Para este fim, Beis e Lowe [5] utilizam uma fila de prioridades para acelerar a busca na *kd-tree* visitando os nós na ordem da distância do ponto em questão. Esse algoritmo *Best-Bin First* (BBF), controla o grau de aproximação com um limite no número de nós que serão consultados após encontrar a melhor correspondência o que reduz o tempo de busca na árvore.

Muja et. al. [74] desenvolveram uma variação do *k-means tree* análoga à aproximação do BBF para a *kd-tree*. A *k-means tree* proposta por Fukunaga e Narendra [32] é construída através da combinação de pontos de dados com o algoritmo *k-means* em grupos distintos de k , em seguida, de forma recursiva é feito um novo agrupamento em cada grupo de k . A recursão é parada quando o número de pontos no grupo é menor que k . Já Muja e Lowe [74] propõe executar primeiramente uma única travessia na árvore que atualiza um fila de prioridades de todos os ramos inexplorados em cada nó durante a travessia. Em seguida o algoritmo seleciona da fila o ramo que tem o centro mais próximo ao ponto de consulta e ele reinicia o percurso da árvore daquele ramo. Em cada travessia do algoritmo continua a adicionar à fila de prioridade os ramos inexplorados ao longo do caminho, este algoritmo interrompe a busca quando uma quantidade de nós folhas específica foram examinados.

A *Fast Library for Approximate Nearest-Neighbours* (FLANN) [74], é uma biblioteca de algoritmos de buscas aproximadas baseados no vizinhos mais próximos, é um software de disponibilidade pública que irá escolher o melhor algoritmo a ser utilizado dado um conjunto de dados e a precisão desejada. Esta biblioteca foi utilizada no desenvolvimento da proposta deste trabalho.

2.2.2 Métricas para o Reconhecimento de Objetos

Como já descrito a idéia do casamento de pontos de interesse, é extrair pontos de interesse entre duas imagens e procurar por suas correspondências, essa idéia pode ser aplicada para a busca de objetos em uma imagem. Porém, a simples existência de alguma correspondência não é suficiente para determinar se um objeto existe ou não em uma imagem, visto que o ponto de interesse possui informações locais de um objeto, não sendo capaz de descrever totalmente o objeto. Como na Figura 2.12, onde em ambas as imagens ocorrem o casamento de pontos de interesse, porém não necessariamente o objeto buscado existe na imagem.

Sendo assim, após a aplicação do casamento de pontos de interesse uma avaliação do resultado deve ser feita e uma decisão tomada, essa decisão consiste em afirmar se existe ou não o objeto. Neste trabalho o objeto buscado (inseto) possui uma classe (determinada por sua espécie), e para avaliar se um determinado objeto de determinada classe existe em uma imagem, a imagem é comparada com um conjunto de exemplos, que já estão rotulados. Esta comparação é feita através do casamento de modelos. Com os resultados dos casamentos da imagem avaliada com cada exemplo anotado a decisão de quais objetos existem na imagem pode ser tomada.

Esta decisão pode ser baseada em algumas informações que são obtidas pelo casamento de pontos de interesse, essas informações são: a quantidade de pontos casados (contando a quantidade de correspondências entre a imagem avaliada e os exemplos de cada classe) e a distância entre cada correspondência. A seguir são apresentadas as métricas utilizadas para definir se




Figura 2.12: Exemplo de casamento de pontos de interesse, onde um polígono é utilizado para ilustrar o casamento de pontos de interesse de objetos diferentes.

um objeto de determinada classe está na imagem avaliada ou não.

Distância Mínima Nesta métrica para determinar se um objeto de determinada classe existe na imagem, primeiro é encontrado o ponto de interesse com menor distância entre a imagem de entrada e o conjunto de exemplos de cada classe. Após a busca do ponto mais próximo, a classe recebe como distância da imagem de entrada a distância do ponto mínimo encontrado. Após a atribuição das distâncias às classes, é assumido que a imagem possui um objeto da classe com a menor distância.

Média das Distâncias Na segunda métrica, para determinar a presença de um objeto de determinada classe na imagem, a média das distâncias dos pontos casados entre a imagem de entrada e o conjunto de exemplos de cada classe é calculada. Com a média da distância, cada classe recebe como distância da imagem de entrada a média das distâncias dos pontos de interesse, e é assumido que a imagem possui um objeto da classe com a menor distância encontrada. A diferença entre esta metodologia e a anterior, é que a de distância mínima avalia somente um ponto por classe, independente da quantidade de exemplos (o que obteve casamento com a menor distância em todo o conjunto), já a de média, avalia a distância da classe em relação à imagem de entrada.

Número de Pontos Casados Está métrica é a mesma utilizada por Bay et. al. [4] quando o SURF foi apresentado. Nela, para cada classe é realizado uma somatória da quantidade de pontos de interesse casados de cada imagem do conjunto de exemplos com a imagem de entrada. É assumido que a imagem possui o objeto da classe que obteve a maior quantidade de pontos de interesse casados com a imagem de entrada.

2.3 Cultura da Soja

2.3.1 Anatomia da Planta

Nesta seção informações básicas sobre a anatomia da planta serão esplanadas, não é a intensão deste trabalho se aprofundar na botânica, mas é necessário que alguns termos que serão utilizados durante o texto sejam explicados. As plantas são seres vivos, e como os outros seres vivos, sua unidade básica é a célula. As células vegetais ficam agrupadas e interligadas por canais que transportam alimento e água. Esses agrupamentos de células são chamadas de tecidos, e os tecidos formam os órgãos da planta, que juntos realizam diferentes funções fundamentais para a sobrevivência das plantas [88].

Raiz

Em geral as raízes se diferem do caule da planta pela ausência das folhas. Possui duas funções principais, servir como meio de fixação e a absorção de água, compostos nitrogenados e outras substâncias do solo. Na extremidade da raiz, pode-se observar as seguintes partes: coifa, zona lisa, zona pilífera e zona de ramificação que serão melhores descritas a seguir [68].

- Coifa: É uma espécie de parede que protege a ponta da raiz. Nesta região existem as células responsáveis pelo crescimento da planta. Essas células se multiplicam intensamente e são extremamente sensíveis. A coifa envolve e protege essa região do atrito com o solo e contra o ataque de microorganismos.
- Zona lisa (ou de crescimento): É a área onde ocorre o alongamento das células produzidas na ponta da raiz (protegida pela coifa). É nesta região que as células produzidas se alongam e fazem com que a raiz cresça.
- Zona pilífera: Nesta região existem extensões (pelos radiculares) que retiram do solo água e sais minerais, e que irão formar a seiva bruta. É também chamada zona de absorção.
- Zona de ramificação: Região na qual a raiz se ramifica, originando as raízes secundárias, que auxiliam a fixação da planta no solo e aumentam a superfície da absorção.

Plantas da família *Fabaceae*, caso da soja, possuem em suas raízes nódulos radiculares, esses nódulos são responsáveis pelo processo de fixação do nitrogênio, isto é, transformam o N_2 (gás) disponível no solo para NH_{4+} (nitrato), que é a forma em que o nitrogênio é utilizável pelas plantas. Estes nódulos são gerados pela infestação de bactérias que penetram na raiz da planta pelos pêlos radiculares. Esta associação entre a planta e a bactéria tem grande importância para a adaptabilidade da planta em solos pobres de nitrato [68]. A Figura 2.13 ilustra a raiz da soja.

Caule

O caule é a extensão da raiz e normalmente fica sobre o solo. Tem a função de conduzir a seiva da raiz para a parte aérea da plantas, além de ser



Figura 2.13: Nódulos radiculares em planta de soja.

responsável pela sustentação da planta. O caule se divide em gema terminal (no ápice, é responsável pelo crescimento do vegetal), nó (de onde saem as folhas, ou flores, ou uma ramificação do caule), entrenó (região que fica entre dois nós) e gema axilar (produz folhas ou ramo folioso e geralmente não se desenvolve como a gema terminal) [68]. A estrutura do caule é ilustrada na Figura 2.14.




Figura 2.14: Planta de soja com as partes do caule marcados.

Folha

As folhas são órgãos das plantas especializados na captura de luz e responsável por fazer a troca gasosa com a atmosfera para realizar a fotossíntese, transpiração e respiração. São, na maioria das espécies, mais estruturados para realizar a fotossíntese. As folhas se dividem em bainha (estrutura que liga a folha ao caule), pecíolo (alongamento da bainha até o limbo) e limbo (parte laminar mais evidenciada da folha). A Figura 2.15 ilustra como é a estrutura de uma folha de soja [88].




Figura 2.15: Folha de soja com a bainha, pecíolo e limbo marcados.

As folhas podem ser caracterizadas segundo a estrutura de seu limbo, esta classificação é dada como folha simples, quando o limbo é inteiro (não existe subdivisões), e folha composta, quando o limbo é formado por várias outras unidades, que são chamadas de folíolos. A Figura 2.16 ilustra as folhas simples da soja e as compostas (trifoliolada) [68].




Figura 2.16: Folhas unifolioladas (folha simples) da soja e trifoliolada (folha composta).

Flor

A flor é a estrutura reprodutora característica das plantas Angiospérmicas. Tem a função de produzir sementes através da reprodução sexuada. Para as plantas, as sementes são como um embrião, que irá germinar e gerar uma nova planta. As sementes são o principal meio através do qual as espécies de espermatófitas (angiospermas e gimnospermas) se perpetuam e se propagam. As flores se originam de gemas localizadas em posições diversas [26].

A flor é formada pelo pedúnculo, que é ramo de caule em cuja extremidade a flor se forma, receptáculo que é a extremidade do pedúnculo onde as peças

da flor se fixam, sépalas que são folhas modificadas, geralmente verdes, cuja função é de proteção, pétalas que também são folhas modificadas, geralmente coloridas, cuja função é proteger os órgãos reprodutores e atrair pássaros ou insetos, que irão transportar os grãos de pólen de uma flor a outra, estames outras folhas modificadas que são os órgãos reprodutores masculinos do vegetal e cuja função é produzir os grãos de pólen e finalmente carpelos que são os órgãos reprodutores femininos que formam um ovário onde serão produzidos os óvulos [26]. A Figura 2.17 ilustra a posição e forma de cada parte da flor.




Figura 2.17: Estrutura das flores [91].

Sementes

A semente é o ovulo maduro já fecundado das plantas Angiospérmicas, tem a função de gerar uma nova planta. As principais partes da semente são:

- Tegumento: um envoltório protetor da semente. Geralmente é um material bem resistente. Em algumas sementes, o tegumento é constituído por duas partes: a testa, que é externa e espessa, e o tegmen, que é a parte interna.
- Amêndoa: parte principal da semente. É protegida pelo tegumento e consta, em geral, de duas partes: embrião e albúmen.
- Embrião: responsável pela origem da nova planta, quando há germinação da semente. O embrião é um verdadeiro vegetal em estado potencial, com seus órgãos rudimentares, representados pela radícula, caulículo e gêmula.
- Albúmen: reserva alimentar acumulada na semente.

No embrião, a radícula dá origem a raiz, enquanto que, o caulículo origina o colo ou nó vital (região de transição entre a raiz e o caule) e a gêmula se responsabiliza pelo desenvolvimento do caule e das folhas. Além do albúmen a semente possui os cotilédones que são folhas modificadas que se traduzem em reservatórios de alimentos, utilizados pelo vegetal nos primórdios do seu desenvolvimento [26].

2.3.2 Ciclo Fenológicos

O conhecimento do ciclo fenológico de uma cultura é fundamental para determinar as características morfológicas do cultivo, seu momento fisiológico, associados a necessidades do vegetal, que uma vez atendidas possibilitam a boa produtividade do cultivo. Em nível técnico, o conhecimento da fenologia da cultura da soja é fundamental, uma vez que os envolvidos na produção da cultura devem estar familiarizados com os diferentes estádios de desenvolvimento da cultura, a fim de identificar o melhor manejo, adotando medidas no momento em que há maior possibilidade da planta responder favoravelmente [20].

A descrição do ciclo fenológico da soja feita por Fehr e Caviness [27] é o mais utilizado no mundo, visto que apresenta uma terminologia única, e divide o desenvolvimento da soja em estádios vegetativos e estádios reprodutivos. Os estádios, em ordem cronológica são descritos a seguir.

Fase Vegetativa

Estádio VE (Emergência) Os cotilédones apresentam-se acima do solo, ocorrendo desdobramento e expansão das folhas primárias; a coloração do hipocótilo é verde, branca ou verde arroxeadado dependendo do cultivar. Possui duração de 3 a 7 dias.

Estádio VC (Cotilédones desenvolvidos) Os cotilédones apresentam-se bem desenvolvidos, espessos e com coloração verde escura, com desdobramento e expansão das folhas primárias. A plântula¹ ainda dependente dos cotilédones para sobrevivência. Possui duração de 3 a 10 dias.

Estádio V1 (Primeiro nó) As folhas unifolioladas estão estendidas e a primeira trifoliolada está suficientemente aberta, de tal modo que os unifólios não estão se tocando. Possui duração de 3 a 10 dias.

Estádio V2 (Segundo nó) A primeira trifoliolada está estendida, isto é, com os três folíolos expandidos e a segunda folha trifoliolada está suficientemente aberta, de tal modo que cada unifólio não estão se tocando. A planta passa a depender da fotossíntese das folhas já estabelecidas e em desenvolvimento. Ocorre o início da formação dos nódulos radiculares. Possui duração de 3 a 8 dias.

Estádio V3 (Terceiro nó) A segunda trifoliolada está estendida, isto é, com os três folíolos expandidos e a terceira folha trifoliolada está suficientemente aberta, de tal modo que cada unifólio não estão se tocando. Ocorre o amarelecimento e abscisão (queda) dos cotilédones, início da fixação de nitrogênio. Possui duração de 3 a 8 dias.

Estádio Vn (Enésimo nó) A enésima folha trifoliolada está estendida, isto é, com os três folíolos expandidos e a folha trifoliolada $n+1$ está suficientemente

¹ Embrião em seu início de desenvolvimento.

aberta, de tal modo que cada unifólio não estão se tocando. Finaliza o estágio vegetativo quando ocorre o aparecimento de flores, iniciando o estágio reprodutivo.

Fase Reprodutiva

Estádio R1 (Início do florescimento) Ocorre uma flor aberta em qualquer nó da haste principal. É caracterizada como o início do período reprodutivo, ou seja, aparecimento dos primeiros botões florais.

Estádio R2 (Florescimento pleno) As flores apresentam-se abertas em um dos dois nós superiores da haste principal. A planta atinge em torno de 90% de sua altura final (hábito de crescimento determinado), e a taxa de fixação de nitrogênio pelos nódulos radiculares aumenta sensivelmente. Temperaturas inferiores a 15°C podem afetar o processo de fecundação das flores e temperaturas superiores a 30°C podem provocar o abortamento de flores. Possui duração de 5 a 15 dias.

Estádio R3 (Início da frutificação) Ocorre a presença de vagens com 0,5 cm de tamanho em um dos quatro nós superiores da haste principal. Alta taxa de fixação de nitrogênio pelos nódulos radiculares (plena atividade). Temperaturas superiores a 30°C podem provocar abortamento. Possui duração de 5 a 15 dias.

Estádio R4 (Vagem formada) Ocorre a presença de vagens com 2 cm de comprimento em um dos quatro nós superiores da haste principal. Crescimento da vagem e início do desenvolvimento de grãos. Vagens atingem tamanho máximo (comprimento e largura) antes dos grãos começarem o enchimento. Temperaturas superiores a 30°C podem provocar abortamento de vagens. Possui duração de 4 a 26 dias.

Estádio R5 (Início da formação dos grãos) Ocorre o início da formação dos grãos que apresentam 0,3 cm de tamanho em um dos quatro nós superiores. A planta atinge máxima altura, máximo número de nós e máxima área foliar. Alta taxa de fixação de nitrogênio pelos nódulos radiculares. Fase crítica com relação à falta de água. Possui duração de 11 a 20 dias,

Estádio R6 (Grãos formados) Ocorre o enchimento completo de grãos. Vagem contendo grãos verdes que preenchem totalmente a cavidade da mesma. O peso das vagens é máximo. Fase crítica com relação ao estresse hídrico. Possui duração de 9 a 30 dias.

Estádio R7 (Início de maturidade fisiológica) Ocorre a maturidade fisiológica, ponto em que os grãos se desligam da planta mãe, a planta cessa a translocação de fotoassimilados para estes, e tem início o processo de perda de água. Os grãos de soja encontram-se com teores de umidade entre 45 a 60%, com alteração na coloração e no tamanho.

Estádio R8 (Maturação em campo) Ocorre o início do desfolhamento das plantas de soja, decréscimo do teor de umidade dos grãos, alteração na coloração e tamanho destes. Possui duração de 5 a 7 dias.

Estádio R9 (Ponto de colheita) As plantas apresentam-se com 95% das vagens maduras, decréscimo máximo do teor de umidade dos grãos. Alteração na coloração e tamanho de vagens e planta. São necessários 5 a 10 dias de tempo seco, após o R8, para que os grãos da soja apresentem menos de 15% de umidade, ponto ideal para colheita mecanizada.

2.3.3 Agricultura de Precisão

Agricultura de precisão pode ser definida como gestão de informações de cunho espacial e temporal a nível de campo, para melhorar a viabilidade econômica e reduzir os impactos ambientais [8]. A agricultura de precisão foi um termo utilizado para definir o sistema que pode proporcionar o conhecimento de cada metro quadrado da lavoura, um conhecimento que acabou se perdendo conforme as pequenas propriedades começaram a desaparecer e os grandes latifúndios foram aumentando cada vez mais as áreas de cultivo [65]. A dificuldade em fazer tratamentos específicos em cada região da lavoura, nestas grandes áreas de cultivos, fez com que a agricultura se tornasse uma atividade baseada em probabilidades, ou seja, a partir de uma amostra pouco representativa da área as decisões são feitas e as recomendações de intervenção são realizadas na área toda, com base em valores médios, como se esta área fosse homogênea.

Como se pode imaginar, isso resulta em um grande desperdício de insumos. Os recentes avanços tecnológicos na área de informação e telecomunicações tem ajudado os agricultores a reduzir sua incerteza na tomada de decisão, utilizando as ferramentas da Agricultura de Precisão com a possibilidade de aquisição de grandes quantidades de dados, é possível coletar um maior número de informações por unidade de área gerenciando-as para identificar e tratar a variabilidade da área em questão contribuindo no processo de tomada de decisão e intervenção [7][71]. McBratney et al. descreve que a Agricultura de Precisão não pode se restringir apenas a espacialização da informação, mas que precisa de elementos de tempo, espaço e lucratividade em sua implementação, tais como melhorias nas operações de manejo de solo e das culturas, na qualidade do produto, na conservação do meio ambiente e no rendimento por área [67].

Segundo Adrian et al. a adoção da Agricultura de Precisão não depende somente de razões econômicas, mas também da percepção das características tecnológicas [1]. Difundir a Agricultura de Precisão para além dos entusiastas requer uma melhor formação das pessoas que trabalham em campo e utilizam a ferramenta, o que pode ser alcançado com treinamentos e cursos de gestão. Mas somente isso não é o suficiente, também precisam ser feitas melhorias tecnológicas, tornando as ferramentas menos complexas e mais eficientes, para que o tempo de aprendizagem não seja outro desperdício [62]. Outro desafio, que provavelmente é o principal, é reduzir os custos de aquisição de máquinas e equipamentos para a viabilização e rentabilidade da adoção da Agricultura de precisão [90].

2.3.4 Morfologia Externa dos Insetos




Figura 2.18: Esquema morfológico de um inseto. Fonte: Garbaletto e Campos [35]

O termo inseto, de uma maneira ampla, faz referência a todos os animais com três tagmas (grupo de segmentos especializados de artrópodes), e que possuem três pares de pernas apenas no tagma torácico. Os insetos atuais são geralmente pequenos e têm o corpo anatômico segmentado, protegido por um exoesqueleto rígido de um material conhecido como quitina. Podem ser caracterizados como animais de simetria bilateral [36]. Na cabeça do inseto estão centrados os órgãos relacionados aos sentidos e as estruturas de captura e primeiro tratamento do alimento. No tórax estão presentes, principalmente, as estruturas de locomoção. No abdômen estão presentes os órgãos dos sistemas digestivo, excretor e reprodutor.

Na parte cefálica estão presentes sete membros, que são: um par de antenas, um par de mandíbulas, um par de maxilas, e um lábio. Na cabeça estão presentes um par de olhos compostos, usados para a visão, e ao menos três olhos simples ou ocelos, que são estruturas fotoreceptoras [36].

O tórax consta de três segmentos (Protórax, mesotórax e metatórax), cada um com um par de pernas. A grande maioria de insetos possuem asas, um par no segundo segmento do tórax, no mesotórax, e um par no terceiro segmento, no metatórax. O protórax é o segmento mais anterior do tórax dos insetos, tendo nele inserido o primeiro par de pernas. Possui três escleritos² principais, que são o pronoto (dorsal), o proesterno (ventral) e o propleuro (lateral) em ambos os lados [36].

O abdômen possui onze segmentos. Os primeiros insetos, provavelmente,

²Escleritos são placas de quitina que fazem parte do revestimento do inseto, unidas por suturas ou sulcos.

possuíam apêndices³ reduzidos em cada um dos segmentos do abdômen, porém foram perdidos ao longo da evolução [61]. O abdômen também contém a maior parte do aparelho digestivo, respiratório, excretor e estruturas internas reprodutivas. Nos machos o segmento genital é o nono, onde há a abertura genital. As fêmeas de muitos insetos possuem ovipositores, que são extensões dos segmentos genitais adaptados à postura de ovos [36].

2.3.5 *Manejo Integrado de Pragas*

Um dos resultados da adoção da agricultura de precisão foi a adoção do Manejo Integrado de Pragas (MIP) que visa à integração de várias táticas de manejo ao invés de se basear no controle por uso exclusivo e excessivo de inseticidas [53]. Segundo os preceitos da agricultura de precisão, o MIP consiste num processo de tomada de decisão envolvendo o uso coordenado de múltiplas táticas para otimizar o controle de todas as classes de pragas de uma maneira sustentável [86].

O MIP-Soja visa manter o agroecossistema da soja o mais próximo possível do equilíbrio ecológico, para isso utilizam a tecnologia aliada com as informações coletadas na lavoura para a correta tomada de decisão no manejo das pragas. O MIP-Soja tem em sua base o reconhecimento das pragas e seus inimigos naturais, o monitoramentos desses insetos e os níveis de ação, informações que são fundamentais para o manejo da lavoura, dando ao produtor respaldo para que ele possa fazer a correção em sua plantação e histórico para que ele invista em uma planta com maior resistência [46].

Monitoramento de Pragas O monitoramento de pragas é fundamental para a obtenção de conhecimento das principais pragas e dos insetos benéficos presentes no ecossistema da soja, bem como da sua biologia e principais hábitos comportamentais, além do monitoramento das pragas e de seus inimigos naturais através de métodos de amostragem o que garante que o produtor evite possíveis perdas de produtividade por demora em sua tomada de decisão [23].

As vistorias da lavoura devem ser periódicas, e na soja o método mais utilizado para o monitoramento dos principais insetos da parte aérea é o pano-de-batida que será explanado nesta seção. Dependendo do hábito da praga que existe na cultura, outros métodos de amostragem podem ser utilizados, como amostragem de solo para monitoramento de pragas que vivem no solo e danificam as raízes das plantas ou exame visual das plantas, principalmente para brocas e insetos galhadores [23].

Nível de Ação e Nível de Dano Econômico Segundo Stern et al. [102] o nível de dano econômico é a menor população de pragas que pode causar dano econômico significativo na soja. Porém, para culturas que precisam de grande produção, é importante considerar a tolerância que a planta possui a um determinado nível populacional da praga e o seu consequente dano que podemos chamar de nível de ação, que precede o nível de dano econômico. Logo, o nível de ação seria o momento ideal para que uma medida de controle seja iniciada, evitando assim que o dano de uma população de insetos prejudique a produtividade da planta [83].

³Apêndice é qualquer estrutura que se projeta para fora do corpo de um animal ou de um dos seus órgãos.

Para as principais pragas que atacam a cultura da soja o nível de ação é bem determinado e pode ser visto na Figura 2.19. Várias outras pragas já tiveram seus níveis de ação determinados porém a validade desses níveis é questionável, visto que o hábito de crescimento dos cultivares, ciclo e época de semeadura da soja foram alterados. Hoje a grande maioria da soja cultivada tem hábito de crescimento indeterminado, tinham ciclo mais longo e eram semeadas mais tarde.

					
Emergência		Período vegetativo		Floração	
Formação de vagens		Enchimento de vagens		Maturação	
30% de desfolha ou 20 lagartas/m*			15% de desfolha ou 20 lagartas/m*		
Lavoura para consumo			2 percevejos/m**		
Lavoura para semente			1 percevejo/m**		
Broca-das-axilas: a partir de 25% - 30% de plantas com ponteiros atacados					
Tamanduá-da-soja: até V3: 1 adulto/m linear de V4 a V6: 2 adultos/m linear					
Lagarta-das-vagens: a partir de 10% de vagens atacadas					

* Maiores de 1,5cm e considerando a batida de apenas uma fileira de soja sobre o pano.
** Maiores de 0,5cm e considerando a batida de apenas uma fileira de soja sobre o pano.

* Maiores de 1,5cm e considerando a batida de apenas uma fileira de soja sobre o pano.
 ** Maiores de 0,5cm e considerando a batida de apenas uma fileira de soja sobre o pano.

Figura 2.19: Níveis de ação das principais pragas da soja. Fonte: Embrapa Soja [23]

2.3.6 Insetos Prejudiciais à Soja

Como pode ser visto na Figura 2.20, a cultura da soja está sujeita ao ataque de insetos em todo o seu ciclo vegetativo. Logo após a germinação, a partir do início do estágio vegetativo, vários insetos como o bicudo-da-soja, a lagarta elasmô, os corós e o percevejo-castanho-da-raiz atacam as raízes das plantas danificando a cultura. Mais adiante, a lagarta-da-soja, a lagarta falsa-medideira e vários outros desfolhadores atacam as plantas prejudicando a fotossíntese e assim a produção da planta, ocorrendo em maior número durante as fases vegetativas e de floração.

Com o início da fase reprodutiva, surgem os percevejos sugadores de vagens e sementes, dentre outras espécies, que causam danos desde a formação das vagens até o final do enchimento dos grãos. Além das pragas principais, a soja pode ser atacada por outras espécies de insetos, consideradas pragas esporádicas, cujos aumentos populacionais são determinados por alterações climáticas, ou outros fatores, como, por exemplo, os sistemas de produção específicos de cada região. Nesta seção serão apresentados as principais espécies causadoras de danos às plantações de soja.

Em geral existem 5 classes de insetos prejudiciais a diferentes etapas da soja, são elas: insetos que atacam raízes e nódulos da soja, pragas que ata-

Inseto	Parte da planta atacada	Importância
<i>Anticarsia gemmatalis</i>	Fo'	Praga principal
<i>Epinotia aporema</i>	Fo, Br, Va	Secundária, com alguma importância em áreas restritas
<i>Omiodes indicatus</i>	Fo	Secundária, geralmente ocorrendo no final do ciclo da cultura, quando a desfolha não é importante
<i>Pseudoplusia includens</i>	Fo	Secundária
<i>Rachiplusia nu</i>	Fo	Secundária
<i>Cerotoma</i> sp.	Fo(A), No(L)	Secundária, em áreas de soja precedida por feijão
<i>Diabrotica speciosa</i>	Fo(A), Ra(L)	Secundária, em áreas de soja precedida por milho "safrinha"
<i>Aracanthus mourei</i>	Fo, Pe	Secundária, ocorrência no início do crescimento da soja
<i>Maecolaspis calcarifera</i>	Fo	Secundária
<i>Megascelis</i> sp.	Fo	Secundária
<i>Chalcodermus</i> sp.	Fo	Secundária, praga regionalmente importante
<i>Bemisia argentifolii</i>	Fo	Secundária, com potencial alto de dano
Gafanhotos	Fo	Esporádica
Ácaros	Fo	Esporádica
Tripes	Fj	Secundária, importante em áreas muito restritas, vetores de vírus da "queima do broto"
<i>Nezara viridula</i>	Va, Se	Praga principal
<i>Piezodorus guildinii</i>	Va, Se	Praga principal
<i>Euschistus heros</i>	Va, Se	Praga principal
<i>Dichelops furcatus</i>	Va	Secundária
<i>Edessa mediatubunda</i>	Va	Secundária
<i>Thyanta perditor</i>	Va	Secundária
<i>Acrosternum</i> sp.	Va	Secundária
<i>Ethiella zinckenella</i>	Va	Secundária, com alguma importância em áreas restritas
<i>Spodoptera latifascia</i>	Va	Esporádica
<i>Spodoptera eridania</i>	Va	Esporádica
<i>Maruca testulalis</i>	Va	Esporádica
<i>Sternechus subsignatus</i>	Ha	Praga regionalmente importante
<i>Elasmopalpus lignosellus</i>	Ha	Esporádica, usualmente importantes em anos com prolongado período seco, na fase inicial da cultura
<i>Myochrous armatus</i>	Ha	Esporádica
<i>Blapstinus</i> sp.	Pl, Ha	Esporádica
Piolhos-de-cobra	Pl, Pp	Secundária, importante em áreas de semeadura direta
Caracóis e lesmas	Pl, Co, Fj	Secundária, importantes em áreas de semeadura direta
<i>Phyllophaga</i> spp. (Corós)	Ra	Praga regionalmente importante
<i>Scaptocoris castanea</i>	Ra	Praga regionalmente importante
Cochonilhas-da-raiz	Ra	Secundária, importantes em áreas de semeadura direta

Br = brotos; Co = cotilédones; Fj = folhas jovens; Fo = folhas; Ha = hastes; No = nódulos; Pe = pecíolos; Pl = plântulas; Pp = plantas pequenas; Ra = raízes; Se = sementes; Va = vagens.
(A) = adulto, (L) = larva.

Figura 2.20: Possíveis ataques de pragas em cada ciclo vegetativo da soja.
Fonte: Embrapa Soja [46]

cam plântulas, hastes e pecíolos da soja, artrópodes que atacam as folhas da soja, insetos que atacam vagens e grãos e insetos que atacam grãos de soja armazenados. Os insetos que atacam raízes e nódulos da soja sobrevivem em habitat subterrâneo, assim não é possível a captura de imagens destas espécies por imagens aéreas, já os insetos que atacam grão de soja armazenados também estão em ambientes que não é possível a captura de imagens aéreas, sendo assim, iremos ilustrar somente as pragas que podem ser identificadas

pela metodologia descrita neste trabalho, sendo elas chamadas de pragas da parte aérea. Todas as descrições apresentadas nesta seção foram obtidas pela Embrapa [46].

Pragas que Atacam Plântulas, Hastes e Pecíolos da Soja



Figura 2.21: Tamanduá-da-soja.

Sternechus subsignatus (Boheman, 1836) (Coleoptera: Curculionidae) Bicudo-da-soja, cascudo-da-soja ou tamanduá-da-soja são os nomes populares de *S. subsignatus*. O adulto, principalmente o macho, raspa o caule e desfia os tecidos no local do ataque. Quando a população é alta e ocorre na fase inicial da cultura, ocorre ruptura do caule na região do ataque, interrompendo a circulação de seiva, ocasionando morte das plantas e podendo redundar em perda total de partes da lavoura [96]. Quando o ataque acontece mais tarde, com o caule mais resistente, este inseto deposita ovos dentro do caule e com o desenvolvimento das larvas na haste principal, forma-se uma galha (crescimentos atípicos das plantas que provém abrigo, alimento e proteção para os indutores e sua progênie [95]) de tecido modificado e muito frágil, podendo o caule quebrar pela ação do vento e das chuvas, causando desde o acamamento até a morte das plantas e, consequentemente, diminuindo a população de plantas da cultura.

Os adultos são gorgulhos de, aproximadamente, 8 mm de comprimento, de coloração preta, com faixas amarelas na parte dorsal do tórax próximo à cabeça (pronoto) e nos élitros⁴ (asas duras), formadas por pequenas escamas. Em situações de excesso de umidade, essas listras podem assumir a coloração creme. Habitualmente, durante o dia, os adultos são encontrados sob a folhagem da soja, nas partes baixas da planta ou sob restos da cultura anterior, movimentando-se para as partes mais altas das plantas durante a noite, para o acasalamento [96]. Entretanto, Guedes et al. [40] observaram, na região de Pinhal Grande-RS, que a movimentação de adultos para a parte superior da planta se inicia às 15 h, com pico entre 20 e 22 h.

⁴Élitros são o primeiro par de asas, de certas ordens de insetos (Coleoptera)



Figura 2.22: Broca-das-axilas.

Crociosema (Epinotia) aporema (Walsingham, 1914) (Lepidoptera: Tortricidae) *Crociosema aporema*, até 1994, citada na literatura como *Epinotia aporema* [85], é uma praga popularmente chamada de broca-das-axilas. Devido aos seus hábitos alimentares em plantas de soja, o inseto pode causar danos econômicos consideráveis à cultura, quando ocorre em plantas com 25 a 30% de ponteiros atacados [23]. Nos estágios iniciais, a larva ataca os brotos foliares. À medida que as larvas se desenvolvem, os folíolos apicais atacados permanecem ligados entre si por fios de seda, formando uma espécie de cartucho que caracteriza o ataque do inseto [19]. As larvas, então, se locomovem dos tecidos em decomposição para as axilas das folhas, onde penetram nos pecíolos e haste, obstruindo o fluxo de seiva da planta.

Os adultos ovipositam nos folíolos tenros dos brotos terminais da soja. Os ovos são muito pequenos, medindo, aproximadamente, 0,47 x 0,31 mm; têm formato oval e cor amarelo-clara. As larvas recém-eclodidas apresentam coloração amarelo-esverdeada, com cabeça e carapaça protorácica de cor preta brilhante, e, segundo Liljestrom et al. [57], pode ocorrer mais de uma por broto. À medida que se desenvolve, a larva se torna de coloração bege ou amarelada, mas quando totalmente desenvolvida (cerca de 1,10 cm), próxima à transformação em pupa, muda sua cor para avermelhada. A fase de pupa ocorre no solo entre 1 a 2 cm de profundidade, próximo ao colo da planta.

Os adultos são mariposas pequenas que medem, aproximadamente, 14 mm de envergadura. Quando em repouso, as asas permanecem paralelas ao corpo, sendo as anteriores de coloração cinza a marrom-escuro, com manchas prateadas [100]. Os machos são escuros nas laterais das asas e de cor clara no dorso, ocorrendo o oposto nas fêmeas [19].

Elasmopalpus lignosellus (Zeller, 1848) (Lepidoptera: Pyralidae) Essa espécie é popularmente chamada broca-do-colo ou lagarta elasm e pode causar danos consideráveis no primeiro ano de cultivo em áreas recém-abertas, nos cerrados do Brasil Central [80]. Sua incidência é geralmente cíclica, principalmente, em anos com estiagem prolongada em áreas com solo arenoso, na fase inicial das lavouras.

O adulto é uma mariposa pequena com 15 a 25 mm de envergadura, geralmente mais ativo à noite. Os machos, normalmente menores que as fêmeas,



Figura 2.23: Broca-do-colo.

apresentam coloração marrom com manchas escuras nas asas anteriores, enquanto as fêmeas são de coloração cinza. Os ovos, inicialmente branco-amarelados e posteriormente avermelhados ou róseo escuros, são colocados no solo, próximos à planta. A eclosão das lagartas ocorre em 2 ou 3 dias, enquanto a fase larval dura de 8 a 42 dias, dependendo da temperatura [33].

Artrópodes que atacam as folhas da soja




Figura 2.24: Lagarta-da-soja.

Anticarsia gemmatilis (Hübner, 1818) (Lepidoptera: Noctuidae) Cada lagarta de *A. gemmatilis*, mais conhecida como lagarta-da-soja pode consumir de 85 cm² a 150 cm² de área foliar de soja até completar a fase larval [10]. Nos primeiros três instares, o consumo é muito baixo, e as lagartas, ainda muito pequenas, não conseguem sequer perfurar as folhas, alimentando-se apenas dos tecidos mais tenros. No terceiro ínstar, as lagartas já provocam pequenas perfurações, mas ainda deixam as nervuras centrais e laterais intactas. A maior capacidade de desfolha ocorre do quarto ao sexto ínstar, quando as lagartas atingem grande potencial de injúria na soja [12]. Quando não manejadas corretamente, essas lagartas podem provocar até 100% de desfolha,

que, dependendo do estágio de desenvolvimento da planta, ocasionam reduções significativas na produtividade da lavoura que podem chegar à perda total da lavoura.

A *A. gemmatalis* quando pequena (até 1 cm) geralmente apresenta cor verde e possui quatro pares de pernas abdominais, sendo dois deles vestigiais e mais um par anal. Nessa fase, ela se locomove medindo palmos e, assim, muitas vezes, é confundida com lagartas-falsas-medideiras (*Plusiinae* como a *C. includens*). As lagartas maiores do que 1,5 cm podem ser encontradas tanto nas formas verdes como escuras e apresentam três linhas longitudinais brancas no dorso. Após seis instares larvais, essas lagartas transformam-se em pupas, que apresentam coloração marrom, usualmente localizadas no solo. Dessas pupas emergem as mariposas, que apresentam envergadura de asas de 30 a 38 mm e coloração bastante variável na parte dorsal (de cinza claro ao marrom-escuro). Contudo, elas têm sempre presente uma linha diagonal de cor marrom canela unindo as pontas do primeiro par de asas, o que auxilia em seu reconhecimento [100]. Durante o dia, essas mariposas são frequentemente encontradas sob a vegetação natural ao redor de áreas de soja e também protegidas nas partes baixas e sombreadas das plantas, mas deixam esses abrigos assim que perturbadas. Logo após o pôr do sol, elas iniciam voos curtos e orientados, localizando parceiros para o acasalamento ou plantas para a oviposição.



Figura 2.25: Lagarta-falsa-medideira.

Chrysodeixis (= *Pseudoplusia*) *includens* (Walker, 1858) (Lepidoptera: Noctuidae) A lagarta-falsa-medideira no primeiro e segundo instar, apenas raspam as folhas, enquanto, a partir do terceiro instar, conseguem perfurá-las, deixando, entretanto, as nervuras centrais e laterais intactas, proporcionando aspecto característico de folhas rendilhadas, diferente do dano causado por outros desfolhadores [13]. O consumo total médio de folhas de soja por lagartas de *C. includens* relatado na literatura é bastante variável, sendo encontrados valores de 64 cm² a 200 cm² [12]. Essa variação, conforme também observada para outros lepidópteros, ocorre certamente devido às diferenças nos tipos de folhas utilizadas nos estudos (folhas de casa de vegetação, do campo, de diferentes estágios fenológicos da planta, entre outras).

Os ovos da *C. includens* são globulares, medem cerca de 0,5 mm de diâmetro e apresentam coloração creme-clara logo após a oviposição e marrom-clara próximo à eclosão. O desenvolvimento embrionário se completa em torno de 2,5 dias [84]. As lagartas que eclodem são de coloração verde-clara, com listras longitudinais brancas e pontuações pretas, atingindo de 40 a 45 mm de comprimento em seu último estágio larval [100]. Dentro de cada ínstar, a lagarta sofre uma perceptível mudança na coloração, de verde amarronzado claro enquanto se alimenta, para verde-limão translúcida. Os adultos são mariposas com 35 mm de envergadura de asas, dispostas em forma inclinada. As asas anteriores são de coloração escura, com duas manchas prateadas brilhantes na parte central do primeiro par de asas, e as asas posteriores são de coloração marrom [100].



Figura 2.26: Lagarta-do-linho.

Rachiplusia nu (Guenée, 1852) (Lepidoptera: Noctuidae) Os danos causados por *R. nu*, mais conhecida como lagarta-do-linho, são semelhantes aos de *C. includens*, ocasionando o aspecto rendilhado dos folíolos da soja, devido à alimentação das lagartas, que preferencialmente atacam o parênquima foliar, deixando as nervuras intactas [100]. Assim como a maioria dos artrópodes desfolhadores da soja, *R. nu* também causa maior dano nos últimos instares do desenvolvimento. Uma lagarta de quinto ínstar dura em média 3,3 dias e tem um consumo de 325,4 mg de folha, enquanto que uma lagarta de sexto ínstar tem duração de 5,2 dias e tem um consumo médio de 876 mg [34]. Em média, cada lagarta de *R. nu* consome um total de 1074 mg de folha durante o seu desenvolvimento larval.

Sua identificação é relativamente difícil, porque as lagartas e as mariposas desta espécie são muito semelhantes às de *C. includens* [100]. A diferenciação entre as lagartas dessas espécies, feita usualmente em campo, com base na coloração das pernas torácicas, não é confiável. A principal diferença entre lagartas de *R. nu* e *C. includens* é observada na região interna da mandíbula: *C. includens* apresenta dois dentes internos e carenas que não convergem até a margem distal da mandíbula, enquanto *R. nu* possui carenas que atingem a margem da mandíbula, sem a presença de dentes.

Insetos que atacam vagens e grãos De modo geral, ao atingir as sementes, os insetos danificam diretamente os tecidos da semente, tornando-as chochas e enrugadas, afetando consequentemente a produção e a qualidade dos grãos. Os *pentatomídeos fitófagos*, ao se alimentarem das sementes, injetam saliva contendo enzimas digestivas e sugam o conteúdo liquefeito [108]. Essas enzimas alteram a fisiologia e a bioquímica dos tecidos próximos à punção feita pelo inseto. A difusão da saliva pode causar morte celular dos tecidos vegetais sem envolvimento de danos mecânicos causados pelos estiletes [78].

O excesso de saliva ao redor do estilete solidifica-se, formando uma bainha na superfície da vagem. Essas bainhas têm sido utilizadas como indicadores da atividade alimentar de percevejos pentatomídeos. A punctura também facilita a contaminação dos grãos por patógenos como o fungo *Nematospora coryli* Peglion, causador da mancha de levedura. Pode, ainda, haver aborto de grãos e vagens, redução da germinação, do vigor das sementes, do teor de óleo dos grãos, bem como causar distúrbios fisiológicos, como o retardamento da maturação. Dos percevejos que atacam a soja, as espécies *Euschistus heros*, *Piezodorus guildinii* e *Nezara viridula* se destacam pelos danos que podem causar [100].



Figura 2.27: Percevejo marrom.

Euschistus heros (Fabricius, 1798) (Hemiptera: Pentatomidae) O adulto de *E. heros* apresenta coloração marrom escura, com dois prolongamentos laterais do pronoto, em forma de espinhos. No verão, geralmente, os insetos apresentam espinhos mais longos e mais escuros, comparados com os adultos coletados no inverno, que são de cor marrom-avermelhada e com espinhos pronotais arredondados [82].

Os ovos são depositados em pequenas massas de cor amarela, normalmente com 5-8 ovos por massa, apresentando mancha rósea, próximo à eclosão das ninfas (forma imatura pela qual passam alguns insetos que sofrem metamorfose incompleta). Os ovos são colocados, principalmente, nas folhas ou nas vagens de soja. As ninfas recém-eclodidas medem cerca de 1,3 mm e têm o corpo alaranjado e a cabeça preta. Apresentam hábito gregário e permanecem sobre os ovos até que atinjam o segundo ínstar. As ninfas maiores (terceiro ao quinto ínstar) apresentam coloração que pode variar de cinza a marrom. Apesar de iniciarem a alimentação no segundo ínstar, as ninfas

do percevejo-marrom causam danos às sementes apenas a partir do terceiro ínstar, quando atingem tamanho médio de 3,63 mm [39].



Figura 2.28: Percevejo verde pequeno.

Piezodorus guildinii (Westwood, 1837) (Hemiptera: Pentatomidae) Os adultos de *P. guildinii* medem aproximadamente 9 mm de comprimento e são de coloração verde claro, podendo tornar-se amarelada no final da vida do inseto. Apresenta uma lista transversal marrom-avermelhada na parte dorsal do tórax, próxima à cabeça (pronoto). Os ovos são pretos, em formato de barril e colocados em fileiras duplas, tendo, em média, de 11 a 15 ovos por postura. Preferencialmente, os ovos são depositados nas vagens, mas podem ser encontrados na face ventral ou dorsal das folhas, no caule e nos ramos. As ninfas recém-eclodidas medem apenas 1 mm, possuem comportamento gregário, permanecendo próximas à postura. Inicialmente, apresentam coloração preta e avermelhada, adquirindo coloração esverdeada à medida que avançam no ciclo [29]. Segundo Cividanes [18] esses percevejos completam o desenvolvimento de ovo a adulto em torno de 24,4 dias, com as durações das fases ninfais variando de 3 (primeiro ínstar) a 6 dias (quinto ínstar). Ninfas de segundo até quinto ínstar medem, respectivamente, 2,3, 2,6, 4,6 e 7,8 mm de comprimento [39].

Nezara viridula (Linnaeus, 1758) (Hemiptera: Pentatomidae) Os adultos de *N. viridula* medem cerca de 10-17 mm e possuem coloração verde, podendo variar a tonalidade para verde-escuro. A face ventral é verde-clara, e as antenas são avermelhadas. As fêmeas fazem posturas agrupadas de até 200 ovos em placas hexagonais, na parte inferior das folhas ou nas partes mais abrigadas das plantas, de coloração inicialmente amarelada, passando a uma cor rosada próximo à eclosão. Durante a oviposição, as fêmeas apresentam comportamento interessante de agrupar os ovos na postura com o auxílio dos tarsômeros do último par de pernas [79]. A longevidade do inseto é de aproximadamente 117 dias, tanto para machos quanto para fêmeas.

As formas jovens passam por cinco estádios ninfais; as recém eclodidas apresentam coloração alaranjada. No primeiro e segundo ínstares, medem de 1,3 mm a 3,1 mm, com coloração preta e manchas brancas no dorso [107].



Figura 2.29: Percevejo verde.

Nessa fase, praticamente não causam danos à cultura, permanecendo agrupadas até o terceiro estágio, quando iniciam os danos às plantas. A partir do terceiro ínstar, passam a alimentar-se dos grãos de soja, com intensidade crescente, até o último ínstar. Neste, as ninfas adquirem coloração verde com manchas brancas, amarelas e vermelhas na parte dorsal do abdômen e podem atingir cerca de 9 mm. O período ninfal pode durar entre 20 e 31 dias [108].

2.3.7 Amostragem de Pragas da Soja

Como já explanado nas seções anteriores, os programas de manejo integrado de pragas da soja requerem determinações precisas e rápidas dos níveis populacionais de praga presentes nas lavouras sendo de fundamental importância o acompanhamento da população das pragas, através das amostragens realizadas [51]. Se não efetuado corretamente e dentro da frequência pré-definida, haverá sempre o risco de serem tomadas decisões equivocadas quanto ao uso de agrotóxicos, antecipando-se aplicações dispensáveis ou dispensando-se aplicações necessárias.

Vários são os métodos que podem ser empregados nas amostragens das diferentes espécies de insetos, sendo a escolha do método um resultado da análise de vários fatores, entre os quais a espécie a ser amostrada, características da cultura no momento do monitoramento, precisão desejada na estimativa populacional, além dos custos operacionais e dificuldades de realização. Quando uma situação precisa ser diagnosticada rapidamente, como usualmente ocorre em condições de campo na tomada de decisão, para a maioria dos insetos da parte aérea da soja, dois métodos têm sido mais empregados, o pano-de-batida e a rede-de-varredura [52].

A EMBRAPA disponibiliza uma ficha de monitoramento para facilitar o controle de pragas pelo método MIP. Com esta ficha o proprietário ou técnico agrícola pode fazer a amostragem em uma determinada região e preencher a quantidade de pragas encontradas na propriedade, a quantidade de pragas que apresentam sintomas de doenças (que fazem o controle biológico da praga) e dos predadores naturais das pragas dando um panorama de como está a infestação na cultura da soja. A Figura 2.30 ilustra a ficha de monitoramento

MONITORAMENTO DE PRAGAS NA CULTURA DA SOJA																
MIP SOJA 																
Data: _____ Monitor: _____ Propriedade/Município: _____ Cultivar: _____ Data da Semeadura: _____ Lote/Talhão: _____												☐ Vegetativo ☐ Floração ☐ Desenvolvimento de vagens ☐ Enchimento de grãos ☐ Maturação				
PRAGAS			PONTOS DE AMOSTRAGEM										Nível de controle			
Lagartas: Pequenas = menores do que 1,5 cm Grandes = maiores do que 1,5 cm			1	2	3	4	5	6	7	8	9	10	Total	Média		
	Lagarta da Soja (<i>Anticarsia</i>)	Pequena													20 lagartas > 1,5 cm/m	
		Grande														
	Lagarta Falsa Medideira (<i>Pseudoplusia</i>)	Pequena													30 % até o florescim. ou 15 % após	
		Grande														
Desfolhamento																
	Percevejo Verde (<i>Nezara</i>)	Ninfa (3ª ao 5º instar)													Levou-se Orão: 2 perc. /m	
		Adulto														
	Percevejo Pequeno (<i>Piezodorus</i>)	Ninfa (3ª ao 5º instar)													Levou-se Semente: 1 perc. /m	
		Adulto														
	Percevejo Marrom (<i>Euschistus</i>)	Ninfa (3ª ao 5º instar)														
		Adulto														
	Percevejo Barriga verde (<i>Dichelops</i>)	Ninfa (3ª ao 5º instar)														
		Adulto														
Outros Percevejos																
	Broca dos Ponteiros (<i>Crociosema</i>)	Ponteiros Atacados Nº de Plantas													25 a 30% das plantas c/ ponteiros atacados	
	Tamanduá da Soja (<i>Sternechus</i>)	Adulto													até V3 1 adulto/m V4-V8 2 adultos/m	
	Vaquinhas (<i>Diabrotica</i>) (<i>Ceratomyza</i>) (<i>Colaspis</i>)	Adulto													Desfolha: 30% até o florescim. ou 15% após	
	Torrãozinho (<i>Araecanthus</i>)	Adulto														
Outros Insetos																
Outros Insetos																

Adaptado de: CORRÊA-FERREIRA, B.S. Monitoramento de pragas na cultura da soja. Londrina: Embrapa Soja, s.d. 1 folder.

Figura 2.30: Ficha (frente) utilizada no monitoramento dos principais insetos-praga amostrados em soja, para programas de manejo integrado de pragas.

Pano-de-batida Segundo Kogan e Pitre [52] o pano-de-batida é um excelente método para a captura e avaliação de lagartas, besouros desfolhadores, percevejos (particularmente as ninfas), além dos insetos predadores que vivem na soja. Este método consta de um pano ou plástico branco de 1 m de comprimento por 1 m de largura, tendo nas laterais uma bainha onde são inseridos dois cabos de madeira. Este pano, deve ser devidamente enrolado (para que não perturbe as folhas) e introduzido entre duas fileiras adjacentes de soja e então estendido sobre o solo. Rapidamente após estender o pano, as plantas das duas fileiras de soja são inclinadas sobre o pano e batidas vigorosamente, com o objetivo de derrubar os insetos das plantas no pano. Na sequência,

as plantas voltam à posição original, e os insetos sobre o pano são contados e registrados em fichas de monitoramento. Motsinger et al [73] foi quem introduziu este método na amostragem para a determinação dos níveis de infestação dos insetos em soja e, posteriormente, sugerido em programas de manejo integrado de pragas da soja como o método mais eficiente para uso nesta cultura.



Figura 2.31: Metodologias para a amostragem em plantações de soja com o pano-de-batida.

Para a determinação do número de batidas nas plantas de soja necessárias para a maior eficiência do método, Carvalho et al. [16] determinaram que, para percevejos, a extração é melhor quando feita com três a cinco batidas, visto que segundo os autores quando maior a quantidade de batidas maior o tempo para que os percevejos escapem da batida. Já para lagartas, verificaram que a extração de lagarta é mais eficiente com o maior número de batidas nas plantas (de três a seis batidas). Visto que, usualmente os produtores irão amostrar ambas as pragas no mesmo momento, o número de batidas em cada ponto de amostra indicado deverá ser o que busque a melhor extração de insetos.

No método do pano-de-batidas, o horário da aplicação do método pode interferir nos resultados do monitoramento, dependendo da espécie amostrada e do estado fenológico da planta. Segundo Ribeiro et. al. [89] para os percevejos da soja, não houve diferença na eficiência na extração em amostragens realizadas no período das 7 horas às 18 horas. Já Kuss et al. [55] recomenda que as coletas sejam realizadas nas horas mais frias do dia, visto que os percevejos, para alçar voo, precisam elevar a sua temperatura corpórea, assim nos horários mais frescos precisam de mais tempo para voar, facilitando a contagem destes insetos.

Rede-de-varredura A rede-de-varredura, comumente utilizada nos estudos com insetos da soja, tem 38 cm de diâmetro, pode ser utilizada de diferentes formas na coleta das amostras. Na cultura da soja, três métodos de amostragem são comumente utilizados. A Figura 2.32 demonstra as três metodologias que podem ser aplicadas, onde em *A* a rede é passada através de uma fileira de soja formando um desenho em oito aberto, já em *B* a rede é passada em uma fileira em oito fechado, já em *C*, através de duas fileiras em oito aberto [81].




Figura 2.32: Metodologias para a amostragem em plantações de soja com a rede-de-varredura.

Embora a rede-de-varredura seja um método mais rápido, comparado ao método do pano-de-batida, sua precisão na estimativa é mais baixa, além da interpretação dos resultados ser mais difícil. Segundo os estudos realizados por De Long [22], vários fatores ambientais como temperatura, umidade, velocidade do vento, posição do sol, entre outros e características da planta como tamanho e densidade são responsáveis pela viabilidade dos resultados obtidos por essa metodologia. Entretanto, este é o método de maior capacidade de captura de insetos da vegetação/hora-homem, o equipamento é barato e não causa maior dano à cultura, sendo normalmente recomendado para a amostragem de insetos pequenos e de maior mobilidade [81] [80].

2.4 Utilização de Imagens na Agricultura de Precisão

Como já descrito a utilização de informações na agricultura de precisão é essencial para a tomada de decisão dos agricultores que a utilizam, com isso a utilização de imagens na agricultura tem ganhado destaque por permitir o monitoramento da produção através da aquisição de dados, permitindo ao produtor uma série de informações acerca da lavoura do plantio até a colheita [98].

Os dados aéreos podem ser utilizados para agilizar e maximizar a produção agrícola, podendo ser utilizados na previsão da produção agrícola, detecção de pestes, de falta de nutrientes na planta, previsão de condições ambientais, avaliar as condições do campo, entre outros [6]. Segundo Silva Neto [98] essas imagens podem ser resultantes de diferentes modalidades de coletas, incluindo a coleta via satélites, veículo aéreo tripulado e veículo aéreo não tripulado (VANT).

Na aquisição de imagens o preço das imagens de satélites, à programar, com alta resolução, podem variar entre R\$ 80,00 até R\$ 150,00 por km², sendo necessário comprar área mínima de 100 km² (10.000 ha). Sobre a comparação das modalidades de captura supra citadas, Silva Neto [98] propôs uma comparação conforme Tabela 2.1.

		Satélite	Fotogrametria Tradicional	VANT
Condições	Sobrevoar áreas urbanas	Possível	Possível	Não possível
	Sobrevoar abaixo das nuvens	Não é possível	Não é possível	Possível
Tempo	Período de Revisita	Semanas	Alguns dias	Diário
	Obtenção de dados brutos	Rápido	Médio	Rápido
	Aquisição da ortofoto	Rápido	Médio	Rápido
Qualidade	Resolução espacial (GSD)	Ruim	Ótima	Ótima
	Acurácia planimétrica ⁵	Ruim	Ótima	Boa
	Acurácia altimétrica ⁶	Ruim (SRTM ⁷)	Ótima	Boa
Custos	Preço aquisição do sistema	Não se aplica	R\$ 2 (milhões)	R\$ 130 a 200 (mil)

Tabela 2.1: Comparação genérica entre as três técnicas de aquisição de imagens aéreas. Fonte: Silva Neto (2013)

Vale ressaltar que as imagens de satélite podem ser obtidas sem custo, porém, não tem agilidade na obtenção bem como falta de resolução. Para obtenção envolvendo custos, as imagens de satélites precisam ser programadas, entrar na fila de demandas das operadoras, e o cliente deve aguardar um prazo de 30 dias, em média. Para grandes áreas, maiores que 10.000 ha, as imagens de satélites são viáveis, desde que o cliente não tenha urgência.

2.4.1 VANT

Pela definição do Departamento de Defesa Norte-Americano [38], *Unmanned Aircraft* (Veículos Aéreos Não Tripulados - VANTs) são balões ou veículos aéreos que não precisam de operador humano e são capazes de voar pelo controle remoto ou por programação autônoma. Os VANTs tem sido utilizados principalmente na área militar, esta utilização foi a que contribuiu com os maiores ganhos em tecnologia. Segundo Dempsey [24] a utilização extensiva dos VANTs pelo Exército Norte-Americano, mostrou que os VANTs são capazes de reduzir os riscos de seus soldados, visto que com sua tecnologia os VANTs podem obter informações dos inimigos, e até mesmo, mirar e destruir alvos.

Os VANTs começaram a ser utilizados em aplicações agrícolas em 2002, quando a NASA utilizou seus fundos para construir o VANT Pathfinder-Plus, que é alimentado por energia solar, utilizava câmeras de alta resolução e multi-espectrais e conseguia enviar as fotos tiradas para uma central de controle por meio de um dispositivo de rádio. Este VANT foi utilizado para mapear 1500 hectares de terra no Hawaii [43].

⁵Acurácia das coordenadas geográficas de um ponto.

⁶Acurácia da altitude de um ponto.

⁷A Missão Topográfica Radar Shuttle (SRTM) é uma missão espacial para obter um modelo digital do terreno da zona da Terra, as informações obtidas são disponibilizadas gratuitamente pelo governo norte-americano

Com a criação de novos modelos de VANTs, ocasionados pelo barateamento e miniaturização de componentes utilizados por esses VANTs como sensores, dispositivos GPS e sistemas embarcados, os VANTs começaram a ser comercializados com mais facilidade o que impulsionou seu uso em aplicações civis [6]. Um exemplo deste novos modelos são os do tipo helicóptero, com várias hélices, que embora possuam um sistema de controle de voo complexo e baixo tempo de voo, começaram a ser comercializados a baixo custo [6]. A Figura 2.33, ilustra o drone utilizado nesta dissertação.



Figura 2.33: Drone DJI Phantom 3 Professional, que foi utilizado durante a dissertação.

Trabalhos Correlatos

Várias aplicações utilizando casamento de pontos de interesse podem ser encontradas, Megha Sahu e Neeraj Shukla [93] utilizaram um classificador baseado no SURF para medir qual o desempenho da técnica na classificação de impressão digital. Eles utilizaram esta técnica pois ela é invariante à rotação e como representa a imagem utilizando as características locais, obtém um bom resultado mesmo com presença de oclusão (imagem de impressão digital parcial). O método desenvolvido pelos autores se resume na aquisição da imagem, pré-processamento, onde é aplicado um filtro gaussiano para remoção dos ruídos da imagem, extração de pontos de interesse da imagem (realizado pelo SURF), e finalmente um casamento entre as imagens é feito e a comparação entre os pontos de interesse é utilizado para dizer se a imagem é da mesma impressão ou não. Os autores utilizaram um conjunto com 150 imagens, onde para cada impressão digital, três amostras foram coletadas. Deste conjunto de dados, 90 imagens foram registradas para a comparação e 60 foram utilizadas para o teste. Os pesquisadores concluíram que o SURF é superior ao SIFT em relação ao tempo de resposta e precisão, porém não suporta imagens coloridas.

Já Seok-Wun Ha e Yong-Ho Moon [94] utilizaram um extrator de pontos de interesse SIFT para localizar e rastrear múltiplos objetos em uma imagem. Eles utilizaram o SIFT por ser um robusto extrator de pontos de interesse com invariância a mudanças de escala, iluminação e distorções geométricas. Segundo os autores o problema de rastrear objetos em um vídeo com o SIFT, é a inclusão dos pontos de interesse que são encontrados no próximo quadro, mas que porém, estão com uma posição diferente em relação à referência original, o que causa instabilidade ao rastreamento de objetos em um vídeo, principalmente com objetos pequenos. A solução proposta pelos autores é encontrar quais os pontos de interesse do quadro analisado são encontrados no quadro de referência, e somente contabilizar aqueles que possuem uma distância da posição original até um valor limiar definido pela pesquisa. Os autores fizeram dois experimentos, um utilizando a extração dos pontos de interesse padrão do SIFT sem levar em consideração a localização de cada ponto e outro com a extração dos pontos de interesse do SIFT levando em conta a

localização de cada ponto. No primeiro experimento o objeto que estava sendo rastreado teve uma distância média da região encontrada de 41 pixels, já no método proposto essa distância média foi de 5 pixels. Os autores concluíram, com os resultados obtidos, que o método proposto é mais estável e robusto que o rastreamento padrão com o SIFT, visto que a distância entre a janela e o objeto de interesse foi bem menor, e por ser uma prática simples, calcular a distância de um ponto ao outro, pode ser facilmente aplicado ao rastreamento.

Badrinath et. al. [2] desenvolveram um sistema para o reconhecimento das juntas dos dedos, o grupo propôs a combinação do casamento de pontos de interesse do SURF e do SIFT para esta tarefa. O sistema consistia em quatro etapas, onde na primeira imagem a ser reconhecida passa por um processo de pré-processamento, onde as bordas da imagem tinham o contraste de sua textura realçados. Após o pré-processamento, o sistema extrai as características da imagem, que no sistema proposto seria a extração de ponto de interesse pelo SURF e pelo SIFT e finalmente na última etapa a fusão entre estes pontos de interesse é feita. Esta fusão consiste em fazer a correspondência entre os pontos de interesse extraídos pelo SIFT e pelo SURF e calcular a pontuação obtida por cada um pelo método de vizinhos mais próximos. Finalmente com a pontuação de cada método um cálculo de correspondência é feito, onde a pontuação de cada técnica é multiplicada por um peso e então dado um limiar de comparação a imagem pode ser reconhecida ou não. O sistema proposto foi avaliado com um dataset de 7920 imagens de juntas dos dedos e obteve uma taxa de verdadeiros positivos de 100% e uma taxa verdadeiros negativos de 0.215% e se mostrou muito robusto a mudança de escala e à rotação.

Na Agricultura Gomes et. al. [37] afirmam que na última década a evolução de equipamentos de sensoriamento para captura de informações vem permitindo um avanço na criação de novas técnicas para a implementação de sistemas de inspeção visual para o monitoramento de processos agrícolas. Ainda segundo Gomes et. al [37], a agricultura possui cada vez mais demanda e por possuir uma variedade incrível de tamanhos, cores e formatos, somados com o crescente investimento na agricultura de precisão e por possuir diversos ramos de atuação (controle de pragas, doenças, garantia de qualidade, etc) esta área se torna um grande potencial para o desenvolvimento de sistemas baseados em visão computacional.

Dentro da agricultura de precisão um dos objetivos é minimizar a quantidade de pesticidas utilizados em sistemas de controle de pragas, e para este fim, segundo Alberto Tellaeché [104] dois fatores principais devem ser considerados: a similaridade em termos de forma e textura entre pragas e vegetação e da irregularidade na distribuição de pragas na vegetação. Com esta definição em vista, muitas pesquisas foram realizadas utilizando visão computacional para resolver este problema [37]. Na plantação, um dos indicadores que guiam o veículo robô através das linhas de cultivo é o contraste entre o verde das plantas e a cor do solo. Olsen [99] utilizou um indicador de intensidade dentro do sistema de cor RGB, para conseguir identificar as plantas dentro das linhas de cultivo. Com o mesmo objetivo de guiar o veículo nas linhas de cultivos, Tijmen Bakker et. al. [3] utilizaram uma versão normalizada deste indicador, concluindo que é melhor utilizar esta versão quando existe alterações na iluminação.

Ainda na agricultura de precisão Alberto Tellaeché e sua equipe [104] [105] apresentaram um método para a detecção de plantas daninhas automática-

mente em plantações de cevada. O método proposto determina a quantidade, a distribuição e o método de aplicação de pesticida utilizando segmentação e fazendo decisões pela lógica fuzzy. O grupo sugeriu que trabalhos mais aprofundados deveriam ser feitos devido a significativa variação da luz durante a aquisição da imagem.

Burgos-Artizzu et. al. [15] [14] apresentaram diversas metodologias baseadas em visão computacional para estimar a porcentagem de cultura de plantas daninhas ou sujeiras presentes em imagens do campo. Os problemas identificados foram a falta de controle sobre o nível de iluminação e as diferentes fases de crescimento das plantas. Neste caminho, o processamento da imagem foi feito em três estágios onde diferentes elementos foram extraídos. Primeiro, a segmentação foi feita pela separação das plantas e não plantas, em seguida é feita a extração das plantas daninhas. Em cada estágio diferentes metodologias foram testadas, de modo a melhorar a velocidade e a acurácia do sistema. Os resultados obtidos pelo grupo foram de 95% de acurácia na classificação de pestes e 80% para vegetação dentro de diferentes níveis de iluminação, umidade e estágios da planta.

No controle de insetos Paul Boissard et. al. [9] propõem um método para a detecção de bioagressores em plantações, o sistema separa as imagens em regiões de interesse e posteriormente classifica essas regiões com aprendizagem de máquina. O papel do sistema é o reconhecimento, classificação e contagem de moscas-brancas (*Bemisia argentifolii*) na imagem. O grupo utilizou 180 imagens como base teste, onde em cada imagem existiam de 0 a 5 moscas-brancas. Na coleta de imagens, o grupo utilizou folhas de rosas para a amostragem das imagens. O sistema só classifica e encontra as moscas em estágio maduro, os autores pretendem encontrar moscas-brancas em outros estágios de desenvolvimento.

Já Huddar et al. [49] propuseram um sistema para detecção de pestes em plantas que inclui quatro etapas, conversão de cor, segmentação, redução de ruídos e contagem das moscas-brancas. O grupo propôs um algoritmo, nomeado Diferença Relativa na Intensidade dos Pixels (RDI), para a detecção de moscas-brancas que afetam várias folhas. O algoritmo foi proposto para ser utilizado em estufas, mas segundo os autores, ele pode ser estendido para plantações. O algoritmo foi testado com mais de 100 imagens de moscas-brancas e obteve acurácia de 96%.

Souza e sua equipe [101] dedicaram seu trabalho para classificar qual inseto está danificando folhas de soja, para isso o grupo propôs um método de classificação automática de agentes causadores de danos às folhas de soja. O método se baseia na aquisição da imagem, e após o pré-processamento, as informações sobre o contorno dos danos são obtidos. Cada contorno é modelado como redes complexas que são utilizadas para treinar um algoritmo de Máquina de Vetor de Suporte. Nos experimentos realizados o grupo conseguiu uma acurácia maior que 90% no método proposto.

Como pode ser visto existem diversas aplicações que podem ser atacadas utilizando visão computacional dentro da agricultura, uma nova área de atuação que vem ganhando espaço é a utilização de VANTs dentro da agricultura, com essa nova ferramenta, a quantidade de aplicações que surgem e podem ser exploradas aumentam. Este trabalho usa desta tecnologia para propor a automatização da avaliação e monitoramento de pragas em cultivos de soja, fazendo a contagem automática de insetos, de fotos provenientes de VANT,

sendo este trabalho pioneiro neste tipo de aplicação.

Metodologia

Dois experimentos foram realizados neste trabalho, sendo o primeiro feito para a classificação de cada inseto e o segundo para a contagem dos insetos em pano-de-batida. Nestes experimentos foram utilizados dois bancos de imagens, um com exemplos pontuais dos insetos e o segundo com imagens de grupos de insetos sobre o pano-de-batida, estes bancos de imagens serão descritos na Seção 4.2. Para a construção dos bancos de imagens, o projeto cultivou uma lavoura de soja experimental durante a safra de 2014/2015 e 2015/2016, a metodologia de cultivo será melhor detalhada na Seção 4.1. Todas as imagens utilizadas neste trabalho foram obtidas nesta lavoura.

Como já mencionado, este trabalho classifica e conta insetos em imagens, para isso dois módulos baseados em casamento de modelos e pontos de interesse foram criados, eles serão descritos nas Seções 4.3.1 e 4.3.2. Para avaliar o desempenho do módulo de classificação, foi proposto a comparação do módulo desenvolvido com outros classificadores comumente utilizados, já o módulo de contagem foi comparado com a contagem de um especialista através da análise de variância com um nível de significância de 5%. Esta avaliação será melhor explanada na Seção 4.5.

4.1 Cultivo de Lavoura de Soja Experimental

Como este trabalho pertence a um projeto que visa a solução de diversos problemas que ocorrem na soja, para obter as imagens necessárias para o desenvolvimento e posterior teste dos módulos que o projeto propõe, durante as safras de 2014/2015 e 2015/2016 uma lavoura experimental foi cultivada para a simulação de todos os ambientes que os módulos pretendem enfrentar. Os ambientes que as lavouras desenvolvidas visaram simular foram os de ataque de doenças, infestação de insetos e infestação de plantas daninhas. Vale a pena ressaltar, que somente a área dedicada a este trabalho (infestação de insetos) será comentada.

Ambas as safras foram conduzidas na fazenda São José localizada sob as coordenadas geográficas Latitude 20°24'9.88"S, Longitude 54°36'31.49"O ilustrado na Figura 4.1. O campo experimental foi instalado em uma área de 0.5

(meio hectare) com a soja da variedade BMX Potência RR. Esta é uma das cultivares mais plantadas no Brasil, possui ciclo precoce, apresenta elevado potencial produtivo, resistência ao acamamento, grande quantidade de vagens com três grãos, boa opção para semeadura com antecedência, porte alto, boa rusticidade e ampla adaptação a vários ambientes, apresentando ótima sanidade, principalmente na maturação; ótima opção para rotação com cana-de-açúcar, principalmente em plantio direto na palha [11].



Figura 4.1: Demarcação da área do experimento.

No plantio, foram utilizadas 16 sementes por metro linear. Como recomendado pela análise do solo, na adubação foi utilizado o adubo N-P-K na formulação 02-23-23 e aplicado 320 kg ha⁻¹. O tratamento das sementes foi feito com os produtos Standak Top (Fipronil 25%), Comofix (Co 1% e Mo 10%) na concentração de 2 mL por kg de semente. O inoculante utilizado foi o Masterfix L (inoculante líquido para soja) na concentração de 1,5 mL por kg de semente. O que foi alterado entre as duas safras foi o delineamento seguido durante a condução do cultivo, cada delineamento será melhor explicado nas seções a seguir.

4.1.1 Delineamento Safra 2014/2015

A plantação foi feita com quatro quadrantes distintos de 25 por 50 metros de área. No primeiro quadrante o cultivo da soja foi classificado como *normal*, feito com todos os controles necessários (aplicação de herbicida, fungicidas e inseticidas), no segundo não houve controle de plantas daninhas no cultivo (aplicação de fungicidas e inseticidas) e foi classificado como *Daninhas*, no terceiro não houve controle de doenças no cultivo (aplicação de herbicida e inseticidas) e foi chamado de *Doenças* e finalmente no quarto não houve controle de insetos no cultivo (aplicação de herbicida e fungicidas) e foi chamado de *Pragas*. A Figura 4.2 ilustra como a plantação ficou configurada. Vale salientar que o foco deste trabalho é o quadrante intitulado como "Pragas", pois é propício ao aumento da população de insetos.

Cada quadrante foi separado por um cultivo de milho, que foi plantado entre os quadrantes e em volta de todo o cultivo de soja. O milho foi plantado nesta lavoura como deriva para que nenhuma das aplicações do experimento se espalhassem pela áreas de controle próximas, visto que outros experimento são realizados nesta área.




Figura 4.2: Configuração final do cultivo de soja na safra 2014/2015.

O controle de plantas daninhas foi feito com o Glifosato e Verdict, onde foram utilizados $1,5 \text{ L/ha}^{-1}$ de Glifosato e $0,5 \text{ L/ha}^{-1}$ de Verdict, já o controle de insetos foi feito com o Methomex e Assist com uma concentração de $0,3 \text{ L/ha}^{-1}$ e $0,6 \text{ L/ha}^{-1}$ respectivamente. Vale ressaltar que todas as aplicações foram feitas conforme recomendação agrônômica, sendo levado em consideração as necessidades do projeto. O controle foi feito somente no dia 17/12/2014, onde foi aplicado o controle correspondente em cada quadrante. Em todo o ciclo da soja uma equipe ficou responsável por fazer o acompanhamento semanal do cultivo, sendo esse acompanhamento em campo duas vezes por semana.

4.1.2 Delineamento Safra 2015/2016

No segundo ano de cultivo a plantação foi feita com quatro quadrantes distintos sendo realizado em blocos com 4 tratamentos e 5 repetições (parcelas de 6 por 10 metros). O formato pode ser visualizado na Figura 4.3.

	R1	R2	R3	R4	R5		R1	R2	R3	R4	R5
0%	L11	L12	L13	L14	L15	C	E11	E12	E13	E14	E15
30%	L21	L22	L23	L24	L25	C	E21	E22	E23	E24	E25
60%	L31	L32	L33	L34	L35	C	E31	E32	E33	E34	E35
100%	L41	L42	L43	L44	L45	C	E41	E42	E43	E44	E45
0%	P11	P12	P13	P14	P15	C	D11	D12	D13	D14	D15
30%	P21	P22	P23	P24	P25	C	D21	D22	D23	D24	D25
60%	P31	P32	P33	P34	P35	C	D31	D32	D33	D34	D35
100%	P41	P42	P43	P44	P45	C	D41	D42	D43	D44	D45

Figura 4.3: Configuração final do cultivo de soja na safra 2015/2016.

Onde, as letras referem-se aos problemas trabalhados (L=lagartas, P=percevejos, E=ervas daninhas, D=doenças, e C=corredor), o primeiro número refere-se ao tratamento, sendo que: 4= Controle (tratos culturais conforme a cultura necessita); 3= 60% da dose recomendada; 2= 30% da dose recomendada e 1=

0% (Sem controle), o segundo e último número refere-se a repetição dos tratamentos. Como cada problema deve ser isolado em cada tratamento, o controle dos outros problemas deve ser total. Na área que as lagartas estavam sendo avaliadas, por exemplo, o controle contra doenças, plantas daninhas e percevejos sempre é de 100% (tratamento sugerido para a eliminação completa destes agentes). As aplicações referentes às áreas de controle de lagartas e percevejos foram realizadas conforme as Tabelas 4.1, 4.2 sendo que o 'X' indica quando foram realizadas e o produto que foi utilizado. Já a Tabela 4.3 contém as quantidades necessárias para a condução das aplicações:

Tratamento / Época de Aplicação	V2/V4	V6/V8	R1/R2	R3	R5.2	R5.5
100%	X	X	X	X	X	X
60%	X		X	X		
30%		X		X		
0%						

Tabela 4.1: Estádios fenológicos em que devem ser realizadas as aplicações para o manejo de lagartas. Usar sempre Avatar 400 mL/ha^{-1} + Nimbus 600 mL/ha^{-1} .

Tratamento / Época de Aplicação	V7	R2	R4	R5.2
100%	X	X	X	X
60%		X		X
30%			X	
0%				

Tabela 4.2: Estádios fenológicos em que devem ser realizadas as aplicações para o manejo de percevejos. Usar sempre Galil 400 mL/ha^{-1} + Nimbus 600 mL/ha^{-1} .

Item	Dose (mL/ha^{-1})	Tamanho Parcela (m^2)	Volume por Parcela (mL)	Repetições	Aplicações	Volume Total (mL)
Avatar	400	100	4	5	11	220
Galil	400	100	4	5	7	140
Nimbus	600	100	6	5	27	810

Tabela 4.3: Dose de cada item a ser aplicado na plantação.

Novamente, uma equipe ficou responsável pelo acompanhamento semanal do cultivo, sendo esse acompanhamento em campo duas vezes por semana.

4.2 Construção de um banco de imagens de Soja


Nesta dissertação dois bancos de imagens foram construídos, o primeiro e o segundo foram construídos com a coleta semanal de fotos da lavoura experimental que o projeto desenvolveu, sendo o primeiro, feito durante a safra de 2014/2015 e o segundo durante a safra 2015/2016. O primeiro foi obtido através da coleta de imagens pontuais dos insetos que atacam a cultura da soja e finalmente o segundo foi obtido através da captura de imagens pelo VANT do pano-de-batida, sendo este banco simulado devido a problemas técnicos. As metodologias de coletas de imagens que foram utilizadas para construção dos bancos de imagens utilizados neste trabalho, serão melhores descritas a seguir.

4.2.1 Coleta dos Insetos Pontuais

Este banco de imagens foi construído com as imagens pontuais de cada espécie de inseto que foi avaliado neste trabalho. Para a construção deste banco de imagens, foi necessária a captura dos insetos na plantação experimental. A captura dos insetos foi feita pela técnica do pano-de-batida. Os insetos capturados foram levados para um laboratório para que um especialista identificasse e classificasse cada inseto obtido. Para cada inseto classificado uma foto do mesmo foi obtida, esta foto foi feita colocando-se o inseto em cima de uma folha branca, e com uma câmera Sony α 350 de 14.2 megapixels e lente de 0,38 milímetros a imagem foi capturada. O processo de captura dos insetos e exemplos do banco de imagem podem ser vistos na Figura 4.4.



(a) Captura dos insetos pelo pano-de-batida.



(b) Exemplos do banco de imagens

Figura 4.4: Banco de imagens de insetos.

Neste banco de imagens foram obtidas três classes, sendo elas: Percevejo verde pequeno, Percevejo marrom e Vaquinha. Cada classe ficou com uma quantidade de exemplos igual a 60, o que totalizou 180 imagens. Outras fotos foram obtidas, porém para que o banco de imagens ficasse com exemplos balanceados (cada classe com a mesma quantidade de imagens), diversas imagens foram removidas do banco de imagens.

4.2.2 Coleta dos Insetos no Pano-de-batida

Este banco de imagens foi construído com as imagens obtidas pelo VANT Phantom 3 Professional. A intenção inicial era a captura de imagens do pano-de-batida enquanto o drone sobrevoava a área em uma altura de 3 metros, porém isso não foi possível, visto que a resolução da imagem não foi suficiente para a captura de detalhes dos insetos, detalhes estes, fundamentais para a identificação. Para obter imagens com a resolução adequada, o VANT deveria voar mais próximo do pano-de-batida, porém desta maneira dois problemas ocorriam, sendo o primeiro a perigosidade, visto que o equipamento ficava muito próximo do indivíduo que segurava o pano-de-batida, o que poderia ocasionar algum acidente, e o segundo estava na coleta da imagem, quando o VANT se aproximava do pano-de-batida, o vento produzido pelas hélices do equipamento acabava jogando os insetos para fora do pano, prejudicando a coleta da imagem.

Sendo assim, para a construção deste banco de imagens, o voo do VANT foi simulado. Para a coleta da imagem, o VANT era desligado e segurado em uma altura de 0,50 metro de distância do pano-de-batida e nesta altura as imagens eram feitas. A câmera utilizada para a captura das imagens foi uma Sony EXMOR 1/2.3", 12.4 megapixels (total de pixels: 12.76 M), lente FOV 94° 20 mm. Um exemplo do banco de imagens pode ser visto na Figura 4.5.



Figura 4.5: Exemplo do banco de imagens de múltiplos insetos.

Neste banco de imagens foram obtidas quatro classes, sendo elas: Percevejo verde pequeno ninfa (de terceiro a quinto instar) e adulto, Percevejo marrom (de terceiro a quinto instar) e adulto. A quantidade total de imagens no banco de dados foi de 60 imagens.

4.3 Módulos de Classificação e Contagem de Insetos

Como já foi dito, neste trabalho foram desenvolvidos dois módulos, um para a classificação dos insetos que atacam a cultura da soja, e um segundo

módulo para a contagem de insetos em imagens de pano-de-batida. O segundo módulo foi construído a partir do primeiro, logo o princípio de ambos os módulos é o mesmo, diferenciando somente a localização e classificação de múltiplos objetos de interesses. A seguir é descrito como cada módulo foi desenvolvido.

4.3.1 Módulo de Classificação de Insetos

O objetivo deste módulo é a identificação e classificação dos insetos maleficos à cultura da soja. Para isso foi desenvolvido um sistema baseado em visão computacional que classifica um exemplo de inseto através de técnicas de extração de pontos de interesse e casamento de modelos. O módulo desenvolvido possui três etapas principais, onde na primeira os pontos de interesse da imagem a ser classificada e das imagens de treinamento são extraídos, já na segunda os pontos de interesse da imagem a ser classificada são casados com os pontos de interesse das imagens de treinamento, a técnica utilizada para efetuar esse casamento foi a FLANN e, finalmente, na terceira etapa, um módulo de classificação utiliza os dados gerados para atribuir uma classe à imagem. Vale ressaltar, que este módulo de classificação utiliza as técnicas de reconhecimento de objetos, apresentadas na seção 2.2.2.

Para que as diferentes métricas possam ser testadas em conjunto, foi atribuído ao classificador, um peso para cada métrica, onde é atribuído um valor numérico que indica qual a importância que a métrica possui na decisão do classificador. Assim, quando ocorre a classificação de uma imagem, cada métrica atribui uma pontuação a cada classe, essa pontuação é definida pelo peso atribuído a essa métrica e a pontuação alcançada pela classe. Assim, a classe que possuir a maior pontuação será escolhida como classe da imagem. O Algoritmo 1 apresenta como foi feita a classificação.

A Figura 4.6 ilustra o casamento entre uma imagem teste e os exemplos das classes, onde os valores que estão nas linhas representam as distâncias entre os pontos de interesse. Com os dados obtidos pelos casamentos de pontos de interesse entre a imagem teste e o conjunto de treinamento, segundo a métrica de *Distância Mínima*, a classe escolhida para a imagem de teste seria a *Classe 3*, visto que de todos os pontos de interesse encontrados no conjunto de treinamento a correspondência com distância mínima foi a correspondência 0.1214. Segundo a métrica da *Média das Distâncias*, a classe escolhida para a imagem teste seria a *Classe 2*, visto que a média das distâncias (0.28095) foi a mais baixa entre as classes. Por fim, caso a métrica do *Número de Pontos Casados* fosse determinar a classe da imagem teste, a classe selecionada seria a *Classe 1* que possui a maior quantidade de pontos casados, que é 4.

Caso mais de uma métrica seja utilizada os resultados devem ser normalizados, e com base nessa normalização a métrica faz a pontuação da classe. O método de normalização utilizado é a Combinação Linear [103]. Sendo assim, a pontuação de cada classe vai seguir a seguinte fórmula:

$$nScore_c = \frac{score_c * p_c}{P} \quad (4.1)$$

Onde, $nScore_c$ seria a pontuação normalizada da classe c , $score_c$ a pontuação da classe segundo a métrica, p_c o peso atribuído à métrica e P o valor da somatória dos pesos das métricas.

Algoritmo 1: Algoritmo de classificação de insetos baseado em casamento de modelos com inserção de pesos nas métricas.

Data: I : Imagem de entrada, T : conjunto de treinamento e C : classes avaliadas.

Result: *selected*: classe mais semelhante à imagem.

begin

```
/* Detecta os pontos de interesse */
 $p^I \leftarrow SURF(I)$ 
for  $t \in T$  do
    /* Detecta os pontos de interesse do treinamento */
     $p^t \leftarrow SURF(t)$ 
    /* Faz o casamento de pontos de interesse, retornando
       os n pontos casados */
     $d^{p^I p^t} \leftarrow matchPoints(p^I, p^t)$ 
    /* Guarda a quantidade de pontos casados para a classe
       da imagem de treinamento */
     $qtdIP[classe(t)] \leftarrow qtdIP[classe(t)] + size(d^{p^I p^t})$ 
    /* Guarda a soma das distância dos pontos casados para
       a classe da imagem de treinamento */
     $sumIP[classe(t)] \leftarrow sumIP[classe(t)] + sum(d^{p^I p^t})$ 
    /* Guarda o ponto com menor distância entre a imagem
       de entrada e classe da imagem de treinamento */
    if  $minIP[classe(t)] > min(d^{p^I p^t})$  then
         $minIP[classe(t)] \leftarrow min(d^{p^I p^t})$ 
    end
end
for  $c \in C$  do
    /* Calcula a média das distâncias dos pontos casados
       para cada classe */
     $mcIP[c] \leftarrow \frac{sumIP[classe(t)]}{qtdIP[classe(t)]}$ 
    /* Calcula a pontuação da classe segundo as métricas e
       seus pesos */
     $score[c] \leftarrow score[c] + normalizationMinDistance(minIP[classe(t)])$ 
     $score[c] \leftarrow score[c] + normalizationMeanDistance(mcIP[classe(t)])$ 
     $score[c] \leftarrow score[c] + normalizationQuantityPoints(qtdIP[classe(t)])$ 
end
/* seleciona a classe com a maior pontuação */
selected  $\leftarrow max(score)$ 
end
```




Figura 4.6: Casamento entre a imagem teste (esquerda) e conjunto de treinamento (direita). Cada casamento possui um valor que descreve a distância Euclidiana entre os descritores do ponto de interesse, quanto menor esse valor mais parecidos são os pontos. Com isso as métricas utilizadas podem utilizar tanto o valor da distância entre os pontos de interesse quanto a quantidade de pontos casados para definir a qual classe a imagem pertence.

4.3.2 Módulo de Contagem de Insetos

Para que a contagem dos insetos em uma imagem fosse feita, a localização de múltiplos objetos pelo casamento de modelos deve ser possível. Para isso, a proposta adotada foi baseada nos trabalhos de Zickler e Veloso [112] e de Higa et. al [45], onde os objetos podem ser encontrados e identificados utilizando um espaço de votos do centro do objeto, estes votos são obtidos através dos descritores de pontos de interesse que tiveram correspondência, ou seja, a quantidade de casamentos em uma determinada região da imagem.

A estrutura geral pode ser vista na Figura 4.7, onde a imagem da esquerda é uma imagem anotada que possui alguns pontos de interesse que tiveram correspondências com a imagem teste. Para cada correspondência encontrada, o centro do objeto é estimado, e a posição deste centro recebe um voto em um espaço de votos, este espaço é semelhante ao espaço de Hough [25]. Após a avaliação de todas as correspondências, cada classe possuirá um espaço com seus respectivos votos, a partir daí, basta buscar os pontos máximos em cada espaço. Vale lembrar que um mesmo objeto pode ter pontos máximos em diferentes classes, neste caso ocorre a supressão de não máximos entre os espaços de cada classes. Todo o processo será melhor detalhado nas próximas seções.

Marcação do Banco de imagens Para a localização dos insetos e classificação dos mesmos, as imagens de teste devem ser casadas com imagens de exemplos anotadas. Essa anotação consiste em determinar as bordas do ob-




Figura 4.7: Pode-se ver, da esquerda para a direita, primeiro o exemplo anotado, posteriormente a imagem de entrada e por fim a representação do espaço de votos. Para cada exemplo o casamento de pontos de interesse é feito, após isso o centro do objeto é estimado segundo a orientação do ponto de interesse. Após esta estimativa, é feito o voto no possível centro do objeto em um espaço de votos. Após a comparação com todo o conjunto de treinamento, os espaços de votos são avaliados e pontos máximo encontrados.

jeto de interesse, para que tudo que não esteja dentro desta marcação seja descartado. O centro do objeto é encontrado pelo cálculo do centro de massa da marcação, vale ressaltar que a classe do objeto também é anotada. Este centro de massa é utilizado para a estimativa do centro do objeto buscado, isto será melhor explanado adiante. A Figura 4.8 ilustra como a imagem é anotada, sendo os pontos verdes os delimitadores do objeto buscado.



Figura 4.8: Imagem anotada da classe percevejo marrom adulto, com os pontos delimitando a área do objeto de interesse. O valor de cada ponto representa o número do objeto que está sendo marcado, sendo assim, mais de um objeto pode ser marcado em uma única imagem.

Com a imagem anotada, todos os pontos de interesse que estão fora da marcação (não pertencem ao objeto de interesse) são rejeitadas, os pontos de

interesse remanescentes tem a sua localização relativa calculada, conforme a Equação 4.2, e armazenada em um conjunto que vai representar a classe do objeto buscado.

$$locrel(k) = c_i - loc(k) \quad (4.2)$$

Onde c_i seria o centro de massa do objeto de interesse e k o ponto de interesse.

Reconhecimento Na etapa de reconhecimento para cada imagem de teste os pontos de interesse são encontrados, com isso o casamento de modelos é feito com o conjunto de treinamento. Para cada ponto de interesse (k_i) casado, é calculada a posição hipotética do centro do objeto ao qual o ponto de interesse pertence, essa posição é calculada escalando e rotacionando o ponto de interesse do conjunto de treinamento (t_l) para que ele fique igual ao ponto de interesse k_i . O cálculo do centro do objeto é obtido pela seguinte equação:

$$p_l = pos(t_l) + \left(\frac{scale(k_{ij})}{scale(t_l)} * \begin{bmatrix} \cos\beta & -\sin\beta \\ \sin\beta & \cos\beta \end{bmatrix} * locrel_l \right) \quad (4.3)$$

Onde $\beta = orientacao(k_i) - orientacao(t_l)$.

Logo, para cada casamento entre a imagem de entrada e o conjunto de treinamento o possível centro do objeto é calculado e sua coordenada recebe um voto no espaço de votos da classe que o exemplo representa. Como existem diferentes classes, diferentes espaços de votos são criados e, consequentemente, recebem votos. Após a execução de todos os votos, os picos destes espaços representam os centro dos objetos de cada classe. Para o agrupamento dos votos, o *MeanShift* foi utilizado. Após a finalização do agrupamento, a busca pelos pontos máximos em cada espaço pode ser feita e assim a contagem pode ser determinada. A síntese da contagem pode ser vista no Algoritmo 2 apresentado a seguir.

4.4 Experimentos para Avaliação dos Módulos Propostos

Na classificação de insetos, um banco com 3 classes foi utilizado, tendo cada classe 60 exemplos. Para a comparação do método proposto, classificadores baseados em árvore de decisão, SVM e KNN foram utilizados. Os parâmetros de todos esses classificadores foram variados para obter os melhores resultados na classificação, utilizando validação cruzada com 10 partições e repetições. Atributos de cor, forma e textura foram utilizados para a descrição da imagem, sendo possível a classificação dos insetos pela espécie. Vale a pena lembrar que o paradigma utilizado na classificação pelo método proposto e os classificadores comumente utilizados é diferente, o que dificulta a comparação entre estes classificadores.

Já na contagem de insetos, um conjunto de 60 imagens com 4 classes foi utilizado para a avaliação do método, sendo que todas as imagens foram avaliadas por um especialista, que marcou e contou cada inseto. A metodologia descrita na Seção 4.3.2 foi utilizada, e após a contagem do método proposto os resultados obtidos foram submetidos ao teste ANOVA com um nível de significância de 5%, para verificar se as contagens eram diferentes estatisticamente. As seções a seguir descrevem cada experimento com mais detalhes.

Algoritmo 2: Algoritmo de classificação e contagem de múltiplos insetos, baseado em casamento de modelos.

Data: I : Imagem de entrada, T : conjunto de treinamento anotado e C : classes avaliadas.

Result: J : Número de insetos por classe.

begin

 /* Detecta os pontos de interesse */

$p^I \leftarrow SURF(I)$

for $t \in T$ **do**

 /* Faz a leitura da marcação (com pontos de interesse, centro de massa e classe) */

$m^t \leftarrow readMarkers(t)$

 /* Faz o casamento de pontos de interesse, retornando os n pontos casados */

$d^{p^I m^t} \leftarrow matchPoints(p^I, m^t)$

for $k \in d^{p^I m^t}$ **do**

 /* Realiza o cálculo do possível centro do objeto */

$[x, y] \leftarrow calcHypotheticalCenter(k)$

 /* Realiza um voto no espaço de votos da classe do exemplo */

$voteSpace[class(t)][x][y] \leftarrow voteSpace[class(t)][x][y] + 1$

end

end

for $c \in C$ **do**

 /* Realiza o agrupamento no espaço de votos da classe */

$voteSpace[c] \leftarrow meanShift(voteSpace[c])$

end

 /* Realiza supressão nas diferentes classes */

$voteSpace \leftarrow nomMaxima(voteSpace)$

 /* Seleciona os pontos máximo no espaço de votos */

$J \leftarrow findMaxima(c)$

end

4.4.1 Classificação de Insetos

Para buscar os melhores parâmetros dos classificadores que foram utilizados para a comparação do módulo proposto, a ferramenta *Grid Search* do Sci-kit Learn [56] foi utilizada. Dados os parâmetros e as faixas de valores que estes parâmetros devem receber, esta ferramenta faz uma busca exaustiva pelo melhor conjunto de parâmetros dentro deste conjunto predeterminado. Assim, os parâmetros para cada classificador foram variados da seguinte forma:

- SVM: foram utilizados os núcleos linear e RBF. Os valores de C e γ foram variados exponencialmente correspondendo a faixa de valores: 2^{-5} a 2^{15} para C e 2^{-15} a 2^3 para γ , como é recomendado por Chih-wei [17].
- KNN: o valor de K foi variado de 1 à 300 incrementando em uma unidade. As métricas utilizadas para calcular a distância dos pontos também variaram. Foi utilizada a métrica uniforme, mantendo a distância dos pontos de forma uniforme, e o inverso da distância, isto é, pontos mais próximos tem maior peso na classificação.
- Árvore de decisão: como estratégia de divisão de cada nó da árvore, foi utilizada a melhor divisão ou uma aleatória. O critério de divisão também foi variado entre entropia e *gini* para impuridade de Gini.

Já os atributos utilizados para fazer a descrição da imagem e o treinamento dos classificadores foram:

- Cor: Valores dos espaço de cores RGB, HSV e Cielab, onde para cada um destes valores são extraídos o máximo, mínimo e desvio padrão.
- Forma: Sete momentos de Hu [48], que é um descritor de forma, invariante a escala, translação e rotação.
- Textura: Construção da Matriz de Coocorrência [92], sendo extraído contrastes, dissimilaridades, homogeneidades, asm, energias e correlações desta matriz. São utilizadas matrizes 4×4 nas distâncias 1 e 2 e com ângulos 0, 45 e 90 graus.

Já para a calibração do módulo proposto, como a classificação depende da quantidade de pontos de interesse encontrados, do casamento dos pontos de interesse e da métrica de decisão, na detecção de pontos de interesses, diferentes parâmetros foram avaliados. Sendo que o número de oitavas e camadas por oitavas assumiram os valores 4 e 3 e o limiar Hessiano foi alterado entre 0.0001 e 0.1 com um incremento de 0.0001. No casamento de modelos, para determinar a correspondência entre os pontos de interesse o FLANN foi utilizado em sua configuração padrão (não houve alteração), já a métrica de decisão teve seus pesos alterados, onde para cada uma das três métricas os pesos variaram de 0 ate 5 com incremento de uma unidade.

4.4.2 Contagem de Insetos

Assim como o módulo de classificação, a contagem depende da detecção de pontos de interesse e correspondência entre eles. Como as imagens utilizadas neste experimento são diferentes das usadas na classificação, com um

diferente nível de detalhamento, a necessidade da escolha de um novo limiar Hessiano surgiu. Para a escolha desse novo limiar, um conjunto de testes foi feito, sendo que o valor assumido pelo limiar Hessiano nos testes, variou de 0.1 até 15 com um incremento de 0.1.

Com o valor do limiar Hessiano decidido, o próximo passo para a configuração do módulo de contagem foi a escolha do limiar de pontos máximos no espaço de votos. Como já explanado na Seção 4.3.2, a imagem teste tem seus pontos de interesse casados com um conjunto de exemplos e para cada correspondência um voto é feito no espaço de votos. Após a conclusão destes votos, os pontos máximos devem ser definidos, e assim, todos os valores acima do limiar serão contados. Para a escolha deste limiar, um conjunto de teste foi feito, e o valor assumido pelo limiar variou de 1 até 20 com um incremento de 1.

Por fim, para que houvesse a comparação entre a contagem do método proposto e a contagem do especialista, todas as imagens utilizadas no experimento foram marcadas. Essa marcação foi feita via *software*, onde o especialista abria a imagem, selecionava uma classe e marcava todos os insetos que representavam aquela classe. Para cada inseto marcado, o contador da classe selecionada era incrementado. A Figura 4.9 ilustra como foi feita a marcação, onde os pontos coloridos com um número representam as classes (ponto verde representa percevejo verde pequeno adulto, ponto roxo representa percevejo verde pequeno ninfa e ponto laranja representa percevejo marrom ninfa), sendo na direita a contagem de cada classe (1 para percevejo verde pequeno adulto, 1 para percevejo marrom adulto e 1 para percevejo verde pequeno ninfa).




Figura 4.9: Resultado da imagem anotada pelo especialista. Os pontos coloridos representam as classes (ponto verde representa percevejo verde pequeno adulto, ponto roxo representa percevejo verde pequeno ninfa e ponto laranja representa percevejo marrom ninfa) e na tela da direita pode-se ver a contagem de cada classe (1 para percevejo verde pequeno adulto, 1 para percevejo marrom adulto e 1 para percevejo verde pequeno ninfa).

4.5 Validação do Módulo de Classificação e Contagem de Insetos

Na validação do método de classificação, o sistema produzido foi comparado com os algoritmos de classificação baseados em aprendizagem de máquina, utilizando o banco de imagens de insetos. Como técnica de amostragem, foi adotada a validação cruzada de 10 partições, com 10 repetições, essa implementação está disponível no software Weka na versão 3.6 [41] e para a classificação pelo sistema proposto, foi seguida a mesma estratégia. Para cada algoritmo testado, foram calculados os desempenhos médios referentes a métrica medida-F, também foram analisadas as matrizes de confusão dos métodos com melhores desempenhos. Para identificar se os algoritmos testados diferem estatisticamente em relação ao desempenho, foi utilizado o teste não-paramétrico proposto por Friedman [31] e disponível no software estatístico R, versão 3.1, com cada bloco correspondendo a uma das classes do problema. Como houve diferença estatística entre os classificadores, o teste post-hoc foi utilizado para a avaliação dos resultados. O teste post-hoc, também disponível no R, tem como base o teste de Wilcoxon com correção para FWER (Family-wise Error Rate) descrito por Hollander e Wolf [47].

Já na validação do método de contagem de insetos, cada imagem testada pelo sistema proposto foi marcada por um especialista, que anotava a quantidade de insetos de cada classe na imagem, então com o resultado da contagem pelo módulo e a marcação do especialista, a análise de variância foi realizada. O teste ANOVA [28] foi feito com análise de um único fator, a contagem, tendo esta contagem dois grupos, a contagem pelo especialista e a contagem pelo método proposto. Sendo assim, foi amostrado o resultado da contagem de cada uma das 60 imagens por ambos os métodos, sendo cada contagem uma repetição, com isso o teste foi feito e a hipótese nula avaliada. O nível de significância utilizado neste trabalho foi de 5%. Caso a hipótese nula fosse rejeitada, um pos-teste para a comparação entre os grupos seria feito, sendo este, o teste de Tukey [50], que compara os grupos par a par, avaliando a Diferença Mínima Significativa (DMS). Esta metodologia foi a mesma utilizada no trabalho de Mongelo et. al. [72].

Resultados e Discussão

Os resultados obtidos pelos experimentos descritos na Seção 4.4, são apresentados de forma que, na Seção 5.1 os resultados obtidos pelo módulo de classificação de insetos pontuais são mostrados e discutidos e na Seção 5.2 os resultados obtidos pela módulo de contagem de insetos são apresentados juntos com a discussão dos mesmos.

5.1 Classificação de Insetos

Os resultados obtidos no experimento para busca dos melhores conjuntos de parâmetros para os classificadores, que foram utilizados para a comparação do método proposto, podem ser observados na Tabela 5.1, onde o SVM obteve o melhor resultado. Os parâmetros que obtiveram este resultado foram: núcleo RBM, $C = 18042.84398160$ e $\gamma = 4.55110 * 10^{-5}$, a matriz de confusão do classificador SVM pode ser visto na Figura 5.1. Já o KNN obteve seu melhor resultado com o valor de $K = 7$ e tendo a menor distância como maior peso na classificação. Já a árvore de decisão, o classificador que obteve o pior resultado dentre os comparados, obteve seu resultado utilizando o critério de divisão *gini*.

Classificador	Medida-F
SVM	0.82 (0,029)
KNN	0.72 (0,044)
Árvore de decisão	0.66 (0,053)

Tabela 5.1: Resultados obtidos pelos classificadores que foram comparados com o módulo proposto. Entre parênteses desvio padrão de cada resultado obtido.

Já na calibração do método proposto, o melhor conjunto de parâmetros obtidos na classificação de insetos foi obtido com número de oitavas = 4, camadas por oitava = 4 e limiar Hessiano = 0.00005 para o detector de pontos de



a	b	c	
49	6	5	a - Perc. Marron
9	50	1	b - Perc. Verde Pequeno
8	3	49	c - Vaquinha

Figura 5.1: Matriz de confusão do resultado obtido pelo classificador SVM.

interesse e utilizando somente a quantidade de pontos de interesse como decisão. O resultado obtido pelo módulo segundo a medida-F foi de 0.89 (0,036) e a Figura 5.2 demonstra a matriz de confusão deste resultado.



a	b	c	
60	0	0	a - Perc. Marrom
6	54	0	b - Perc. Verde Pequeno
0	13	47	c - Vaquinha

Figura 5.2: Matriz de confusão do resultado obtido pelo método proposto.

Avaliando a matriz de confusão do módulo proposto, é possível notar que o classificador acertou todos os exemplos da classe percevejo marrom, isto é ocasionado pelas fortes características desta classe, onde na região das costas do inseto existe uma marca branca característica da espécie, além da região prolongada do pronoto (parte que parece com um chifre), ambas as regiões estão ilustradas na Figura 5.3.

Já a Figura 5.4, ilustra o gráfico das variações dos tons de cinza do percevejo, onde as regiões mais claras correspondem a vales no gráfico, e regiões escuras aos picos. Pode-se notar que nas costas do inseto diversos vales são formados, sendo o maior ocasionado pela marca branca, ilustrada na Figura 5.3. Os outros vales ocorrem, principalmente por causa da reflexão de luz na imagem. Vale a pena ressaltar que em todos os testes efetuados, a classe percevejo marrom sempre foi a que obteve o melhor desempenho.

Já para a classe do percevejo pequeno, o erro pode ter ocorrido pelo fato do conjunto de treinamento possuir exemplos de percevejos em fase adulta e ninfal, o que acaba gerando características divergentes na mesma classe. Na Figura 5.5 são mostrados os diferentes estágios de crescimento do percevejo pequeno, que existem no banco de imagens utilizado neste experimento.

Já a classe vaquinha, obteve o pior resultado em todos os testes realizados no módulo proposto, assim como nos classificadores utilizados na comparação com a técnica proposta. Como este inseto é menor que os demais, diversos de seus exemplos tiveram que ser ampliados, o que ocasionou uma perda de informação, esta pode ser a razão desta classe ter tido os piores resultados. A




Figura 5.3: Ilustração de partes do inseto que são bem características da espécie. Marcação em azul ilustra marca branca nas costas do inseto, e marcação em cinza ilustra o prolongamento do pronoto.

Figura 5.6 ilustra um exemplo de cada classe com seus respectivos gráficos, ilustrando as variações nos tons de cinza.

A Figura 5.7 ilustra o diagrama de caixas dos valores da medida-F obtidos por cada classificador. É possível verificar que a módulo proposto possui um desempenho maior do que os classificadores comumente utilizados. Para verificar se existe diferença estatística entre os desempenhos, o teste de hipótese de Friedman [31] foi aplicado.

Os resultados obtidos pela aplicação do teste de Friedman podem ser vistos na Tabela 5.2. Pode-se notar que não existe diferença estatística entre o módulo proposto e os classificadores baseados em SVM e KNN, mas que existe diferença entre o baseado em árvore de decisão e o módulo proposto (valor- $p < 0.05$).


Classificadores	valor-p
Proposta - KNN	0.06548219
SVM - KNN	0.51869127
Árv. decisão - KNN	0.94719004
SVM - Proposta	0.69233323
Árv. decisão - Proposta	0.01381762
Árv. decisão - SVM	0.22075286

Tabela 5.2: Resultado da aplicação do teste de Friedman para o conjunto de resultados dos classificadores.


Como existe diferença estatística entre o método proposto e o classificador baseado em árvores de decisão, o pós-teste foi feito, e o seu resultado pode ser visto na Figura 5.8. De acordo com o pós-teste, é possível observar os classificadores que se diferem (caixas verdes). Quanto maior a distância do eixo $y = 0$ maior é a diferença entre os classificadores. Vale a pena notar que



(a) Percevejo marrom adulto.



(b) Visão superior do gráfico



(c) Visão lateral do gráfico.

Figura 5.4: Ilustração das variações dos valores de tons de cinza na classe percevejo marrom. Da esquerda para direita temos: imagem original, visão superior do gráfico onde os pontos mais claros correspondem a vales e por fim visão lateral do gráfico.

segundo o pos-teste não existe diferença estatística entre os classificadores baseados em SVM, KNN e árvores de decisão.

5.2 Contagem de Insetos

Na calibração do módulo de contagem os valores encontrados para o limiar Hessiano e limiar de escolha de máximos foram de 12 e 7 respectivamente.




Figura 5.5: Diferenças entre os percevejos dependendo do estágio ninfal.

Os resultados obtidos por este conjunto de parâmetros podem ser vistos na Tabela 5.3, onde pode ser observada a contagem total de cada classe para as 60 imagens entre o especialista e módulo proposto. A Tabela 5.3 também apresenta os valores-p obtidos pela análise de variância e teste de Tukey de cada classe.

Classe	Especialista	Proposta	p-value
PMA	74	70	0.2322807
PMN	39	48	0.1871587
PPA	49	57	0.2332308
PPN	48	45	0.6646269


Tabela 5.3: Quantidade de insetos por classe. Sendo PMA a classe percevejo marrom adulto, PMN percevejo marrom ninfa, PPA percevejo pequeno adulto e PPN percevejo pequeno ninfa. Podemos notar que dado o nível de significância de 5% a contagem entre o método proposto não difere da contagem do especialista em nenhuma das classes.

Comparando os resultados obtidos pela avaliação da imagem de insetos em pano-de-batida pelo especialista e pelo módulo proposto, observa-se que a contagem por visão humana e computacional sobre as imagens não diferiram para as quatro classes avaliadas, evidenciando o potencial de utilização do módulo na avaliação de pragas da soja.

As Figuras 5.9, 5.10, 5.11 e 5.12 mostram os resultados das contagens das classes percevejo marrom adulta, percevejo marrom ninfa, percevejo pequeno adulto e percevejo pequeno ninfa do módulo em relação ao especialista, em todo o conjunto de imagens. No eixo y , a linha azul mostra a contagem realizada pelo especialista, já a linha vermelho mostra a contagem feita pelo módulo proposto, o eixo x corresponde à imagem que foi avaliada, sendo um total de 60 imagens.




(a) Exemplo da classe percevejo marrom.



(b) Gráfico das variações em tons de cinza do exemplo da classe percevejo marrom.




(c) Exemplo da classe percevejo pequeno.



(d) Gráfico das variações em tons de cinza do exemplo da classe percevejo pequeno.



(e) Exemplo da classe vaquinha.



(f) Gráfico das variações em tons de cinza do exemplo da classe vaquinha.

Figura 5.6: Ilustração gráfica das variações de tons de cinza em cada classe.




Figura 5.7: Diagrama de caixas dos classificadores avaliados utilizando Medida-F.




Figura 5.8: Diagrama das caixas do teste *post hoc* usando Medida-F. Segundo o gráfico, existe diferença estatística entre o módulo proposto e o classificador baseado em árvore de decisão.




Figura 5.9: Gráfico dos valores obtidos na contagem dos insetos da classe percevejo marrom adulto no conjunto de imagem. Linha em azul representa a contagem do especialista, em vermelho, o resultado obtido pelo módulo proposto.




Figura 5.10: Gráfico dos valores obtidos na contagem dos insetos da classe percevejo marrom ninfa no conjunto de imagem. Linha em azul representa a contagem do especialista, em vermelho, o resultado obtido pelo módulo proposto.




Figura 5.11: Gráfico dos valores obtidos na contagem dos insetos da classe percevejo pequeno adulto no conjunto de imagem. Linha em azul representa a contagem do especialista, em vermelho, o resultado obtido pelo módulo proposto.





Figura 5.12: Gráfico dos valores obtidos na contagem dos insetos da classe percevejo pequeno ninf no conjunto de imagem. Linha em azul representa a contagem do especialista, em vermelho, o resultado obtido pelo módulo proposto.

Avaliando as imagens que geraram os erros pode-se notar alguns casos interessantes. O primeiro caso que chama a atenção são os ruídos no pano-de-batida (sujeira, insetos não prejudiciais a soja, folhas, etc), dependendo do tamanho, diversos pontos de interesse acabam tendo correspondência e gerando uma contagem errada. A Figura 5.13 ilustra este problema, sendo a imagem da esquerda a original marcada pelo especialista e a da direita o espaço de votos.



(a) Imagem marcada pelo especialista.


(b) Imagem com o espaço de votos marcado.

Figura 5.13: Exemplo de erro causado por muitos ruídos na imagem. Na primeira imagem podemos notar a contagem de um percevejo pequeno adulto (ponto verde) e dois percevejos marrons adultos (ponto laranja).

Outro erro que acabou acontecendo foi a marcação da sombra do inseto. Como alguns insetos estavam em cima de outros, ajustes de parâmetros foram feitos para que esses insetos também fossem contados. Porém, em algumas imagens a sombra do inseto foi contada. A Figura 5.14 ilustra esse caso, onde a imagem da esquerda é a original com a marcação do especialista e a da direita o espaço de votos. Já a Figura 5.15 ilustra o gráfico da variação em tons de cinza da mesma imagem, onde pode-se observar os picos na região com sombra do percevejo marrom adulto.




(a) Imagem marcada pelo especialista.




(b) Imagem com o espaço de votos marcado.

Figura 5.14: Exemplo de erro causado pela sombra do percevejo. Na primeira imagem podemos notar a contagem de três percevejos pequenos adultos (ponto verde), um percevejo pequeno ninfa (ponto roxo) e um percevejo marrom adulto (ponto laranja).



(a) Imagem em tons de cinza.



(b) Gráfico da variação em tons de cinza.

Figura 5.15: Ilustração do gráfico da variação dos tons de cinza do exemplo com sombra.

Considerações Finais

Neste trabalho foi proposto a utilização de atributos de ponto de interesse para a classificação e contagem de insetos em plantações de soja. Para este fim, foi implementado um sistema capaz de classificar e contar insetos a partir dos seus pontos de interesse. Primeiramente um módulo de classificação foi implementado e posteriormente uma extensão dele foi desenvolvida.

A avaliação do módulo de classificação foi feita pela comparação com três classificadores comumente utilizados, sendo baseados em Máquina de Vetores de Suporte, K vizinhos mais próximos e árvores de decisão. Pode-se notar nos resultados obtidos que o classificador proposto obteve uma medida-F maior que os classificadores testados, porém com a avaliação do teste de Friedman, foi comprovado que o classificador proposto se diferencia estatisticamente somente do classificador baseado em árvores de decisão, sendo seu resultado superior.

Já o módulo de contagem de insetos foi comparado com a contagem de um especialista, que marcou as imagens previamente. Com os resultados obtidos pela contagem do módulo, foi comprovado através da análise de variância com significância de 5%, que o método proposto não difere estatisticamente da contagem do especialista, evidenciando o potencial de utilização do módulo na automação da avaliação de pragas da soja.

Este trabalho visa contribuir na automação de atividades cansativas do homem do campo, que deve fazer a avaliação de tempos em tempos através do pano-de-batida. Embora a avaliação pelo VANT não tenha sido feita na íntegra (a coleta de imagens teve que ser simulada, devido a má qualidade das imagens), este trabalho tem a intenção de ser utilizado quando houver tecnologia para que as imagens possam ser coletadas em campo, visto que a contagem do módulo proposto não difere estatisticamente da contagem do especialista.

Referências Bibliográficas

- [1] A. M. Adrian, S. H. Norwood, and P. L. Masko. Producers' perceptions and attitudes toward precision agriculture technologies. *Computer and Electronics in Agriculture*, 48:256 – 271, 2005.
- [2] G. S. Badrinath, A. Nigam, and P. Gupta. An efficient finger-knuckle-print based recognition system fusing sift and surf matching scores. In *Proceedings of the 13th International Conference on Information and Communications Security, ICICS'11*, pages 374–387. Springer-Verlag, 2011.
- [3] T. Bakker, H. Wouters, A. Kees van, J. Bontsema, L. Tang, J. Müller, and G. Van Straten. A vision based row detection system for sugar beet. *Computers and Electronics in Agriculture*, 60(1):87 – 95, 2008.
- [4] H. Bay, A. Ess, T. Tuytelaars, and L. Van Gool. Speeded-up robust features (surf). *Computer Vision and Image Understanding (CVIU)*, 110(3):346–359, 2008.
- [5] J. Beis and D. G. . Lowe. Shape indexing using approximate nearest-neighbour search in high-dimensional spaces. In *Conference on Computer Vision and Pattern Recognition.*, pages 1000–1006, 1997.
- [6] J. Berni, P. Zarco-Tejada, L. Suárez, and E. Fereres. Thermal and narrowband multispectral remote sensing for vegetation monitoring from an unmanned aerial vehicle. *Geoscience and Remote Sensing*, 47:722 – 738, 2009.
- [7] S. Blackmore. Developing the principles of precision farming. In *ICETS*, pages 11 – 13, 2000.
- [8] S. Blackmore, R. Godwin, and S. Fountas. The analysis of spatial and temporal trends in yield map data over six years. *Biosystems Engineering*, 84(4):455 – 466, 2003.
- [9] P. Boissard, V. Martin, and S. Moisan. A cognitive vision approach to early pest detection in greenhouse crops. *Computers and Electronics in Agriculture*, 62(2):81 – 93, 2008.
- [10] P. E. Boldt, K. D. Biever, and C. M. Ignoffo. Lepidopteran pests of soybean: consumption of soybean foliage and pods and development time. *Journal of Economic Entomology*, 1975.
- [11] Brejeiro. Bmx potência rr, 2015. Acesso em 27/12/2014.

- [12] A. F. Bueno, B. S. Corrêa-Ferreira, and R. C. O. F. Bueno. Controle de pragas apenas com o mip. *A Granja*, 2010b.
- [13] R. C. O. F. Bueno, J. R. P. Parra, A. F. Bueno, F. Moscardi, J. R. G. Oliveira, and M. F. Camillo. Sem barreira. *Revista Cultivar*, 2007.
- [14] X. P. Burgos-Artizzu, A. Ribeiro, M. Guijarro, and G. Pajares. Real-time image processing for crop/weed discrimination in maize fields. *Computers and Electronics in Agriculture*, 75(2):337 – 346, 2011.
- [15] X. P. Burgos-Artizzu, A. Ribeiro, A. Tellaeché, G. Pajares, and C. Fernández-Quintanilla. Analysis of natural images processing for the extraction of agricultural elements. *Image and Vision Computing*, 28(1):138 – 149, 2010.
- [16] L. F. Carvalho, J. M. Caruso, C. Czepak, N. M. M. Ribeiro, G. P. Silveira, and E. N. Camargo. Determinação do número necessário de batidas nas plantas de soja para a obtenção do maior número possível de insetos. *CONGRESSO BRASILEIRO DE ENTOMOLOGIA*, 2006.
- [17] H. Chih-wei, C. Chih-chung, and L. Chih-jen. A practical guide to support vector classification, 2010.
- [18] F. J. Cividanes. Determinação das exigências térmicas de nezara viridula (l., 1758), piezodorus guildinii (west., 1837) e euschistus heros (fabr., 1798) (heteroptera: Pentatomidae) visando ao seu zoneamento ecológico. Master's thesis, Escola Superior de Agricultura Luiz de Queiroz - USP, Piracicaba, 1992.
- [19] B. Corrêa-Ferreira. Sampling epinotia aporema on soybean. *Sampling methods in soybean entomology*, 1980.
- [20] G. M. S. Câmara. *Fenologia da soja*. Informações Agronômicas, 1998.
- [21] N. Dalal and B. Triggs. Histograms of oriented gradients for human detection. In *Computer Vision and Pattern Recognition (CVPR)*, pages 886–893, 2005.
- [22] D. De Long. Some problems encountered in the estimation of insect populations by the sweeping method. *Annals Entomological Society of America*, 1932.
- [23] E. S. S. de Produção. Tecnologias de produção de soja - da região central do brasil 2012 e 2013. Technical report, Londrina: Embrapa Soja: Embrapa Cerrados; Embrapa Agropecuária Oeste, 2011.
- [24] M. Dempsey. Us army unmanned aircraft systems roadmap. *Federation Of American Scientists*, page 2010 à 2035, 2010.
- [25] R. O. Duda and P. E. Hart. Use of the hough transformation to detect lines and curves in pictures. *Graphics and Image Processing*, 1972.
- [26] A. J. Eames. *Morphology of the Angiosperms*. McGraw-Hill Book Co., 1961.

- [27] W. R. Fehr and C. E. Caviness. Stage of soybean development. Technical report, "Iowa State University. Special report 80", 1977.
- [28] R. A. Fisher. Studies in crop variation. i. an examination of the yield of dressed grain from broadbalk. *The Journal of Agricultural Science*, 11, 1921.
- [29] C. P. Fraga and L. H. Ochoa. Aspectos morfológicos y biológicos de *piezodorus guildinii* (west.). (*Hemiptera: Pent.*). *IDIA- Supl*, 1972.
- [30] J. H. Friedman, J. L. Bentley, and R. A. Finkel. An algorithm for finding best matches in logarithmic expected time. *ACM Trans. Math. Softw.*, 3:209–226, 1977.
- [31] M. Friedman. A comparison of alternative tests of significance for the problem of m rankings. *Ann. Math. Statist.*, 1940.
- [32] K. Fukunaga and P. M. Narendra. A branch and bound algorithm for computing k-nearest neighbours. *IEEE Trans. Comput.*, pages 750–753, 1975.
- [33] D. Gallo, O. Nakano, S. Siveira Neto, R. P. L. Carvalho, G. C. Baptista, E. Berti-filho, J. R. P. Parra, R. A. Zucchi, and S. B. Alves. *Manual de entomologia agrícola*. São Paulo: Ceres, 1978.
- [34] J. C. Gamundi and M. E. Buchman. Algunos aspectos biológicos y consumo filiar en soja de la oruga medidora *rachiplusia* nu (guenée) en condiciones de laboratorio. In *JORNADAS FITOSANITARIAS ARGENTINAS*, 1983.
- [35] T. A. Garbaletto and L. A. Campos. *Pentatominae do Sul de Santa Catarina*. Curitiba: Sociedade Brasileira de Zoologia, 2014.
- [36] C. Gillott. *Entomology*. Ed. New York, Plenum Press, 1995.
- [37] J. F. S. Gomes, R. R. Vieira, and F. R. Leta. Applications of computer vision techniques in the agriculture and food industry: a review. *European Food Research & Technology (Print)*, 235, 2012.
- [38] W. E. Gortney. Remote-sensing technology for vegetation monitoring using an unmanned helicopter. *Federation Of American Scientists*, 2010.
- [39] J. Grazia, M. Del Vecchio, F. M. P. Balestieri, and Z. A. Ramiro. Estudo das ninfas de pentatomídeos (heteroptera) que vivem sobre soja (*glycine max* (l.) merrill): *I euschistus heros* (fabricius, 1798) e *piezodorus guildinii* (westwood, 1837). *Anais da Sociedade Entomológica do Brasil*, 1980.
- [40] J. V. C. Guedes, F. F. Silva, R. F. Giordani, E. C. Costa, J. A. S. França, and S. H. B. Dornelles. Comportamento de adultos do tamanduá-da-soja *sternechus subsignatus* (col.: Curculionidae) na cultura da soja. *REUNIÃO SUL BRASILEIRA DE PRAGAS DE SOLO*, 1999.
- [41] M. Hall, E. Frank, G. Holmes, B. Pfahringer, P. Reutemann, and I. H. Witten. The weka data mining software: An update. *SIGKDD Explor. Newsl.*, 2009.

- [42] L. Harriman and J. Muhlhausen. A new eye in the sky: Eco-drones., 2013. Acesso em 10/05/2015.
- [43] S. Herwitz, J. Leung, R. Higgins, and S. Dunagan. Remote command-and-control of imaging payloads using commercial off-the-shelf technology. *Geoscience and Remote Sensing*, pages 2726 – 2728, 2002.
- [44] S. R. Herwitz, L. F. Johnson, S. E. Dunagan, R. G. Higgins, D. V. Sullivan, J. Zheng, B. M. Lobitz, J. G. Leung, B. A. Gallmeyer, and M. Aoyagi. Imaging from an unmanned aerial vehicle: agricultural surveillance and decision support. *Computers and Electronics in Agriculture*, 44:49–61, 2004.
- [45] K. Higa, K. Iwamoto, and T. Nomura. Multiple object identification using grid voting of object center estimated from keypoint matches. *20th IEEE International Conference on Image Processing (ICIP)*, 2013.
- [46] C. B. Hoffmann-Campo, B. S. Corrêa-Ferreira, and F. Moscardi. *Soja - Manejo Integrado de Insetos e outros Artrópodes-Praga*. Livraria Embrapa, 2012.
- [47] M. Hollander and D. A. Wolfe. Nonparametric statistical methods. *Wiley, Universidade de Michigan*, 1973.
- [48] M.-K. Hu. Visual pattern recognition by moment invariants. *Information Theory, IRE Transactions on*, 8(2):179–187, February 1962.
- [49] S. R. Huddar, S. Gowri, K. Keerthana, S. Vasanthi, and S. R. Rupana-gudi. Novel algorithm for segmentation and automatic identification of pests on plants using image processing. *Computing Communication & Networking Technologies (ICCCNT)*, pages 1 – 5, 2012.
- [50] W. T. John. Comparing individual means in the analysis of variance. *Biometrics*, 5, 1949.
- [51] M. Kogan and D. C. Herzog. *Sampling methods in soybean entomology*. New York: Springer-Verlag, 1980.
- [52] M. Kogan and H. PITRE Jr. General sampling methods for above-ground populations of soybean arthropods. *Sampling methods in soybean entomology*, 1980.
- [53] M. Kogan, S. G. Turnipseed, M. Shepard, and A. Oliveira, E.B.; Borgo. Pilot insect pest management program for soybean in southern brazil. *Journal of Economic Entomology*, 1977.
- [54] P. F. Kreyci and J. O. M. Menten. Limitadoras de produtividade. Technical Report 167, Esalq/USP, 2013.
- [55] R. C. R. Kuss, J. V. C. Guedes, G. Z. Moser, A. Guareschi, J. A. Ar-nemann, and C. d. S. Stecca. Amostragem de percevejos-da-soja com diferentes métodos e horários de coleta. *REUNIÃO DE PESQUISA DE SOJA DA REGIÃO SUL*, 2007.

- [56] B. Lars, L. Gilles, B. Mathieu, P. Fabian, M. Andreas, G. Olivier, N. Vlad, P. Peter, G. Alexandre, G. Jaques, L. Robert, V. Jake, J. Arnaud, H. Brian, and V. Gaël. API design for machine learning software: experiences from the scikit-learn project. In *ECML PKDD Workshop: Languages for Data Mining and Machine Learning*, pages 108–122, 2013.
- [57] G. G. Liljesthom, G. C. Rojas, and P. C. Pereyra. Utilización de recursos y supervivencia larval del barrenador del brote, *crocidosema aporema* (lepidoptera: Tortricidae), en soja (*glycine max*). *Ecología Austral*, 2001.
- [58] G. A. Longhitabi. Vants para sensoriamento remoto: aplicabilidade na avaliação e monitoramento de impactos ambientais causados por acidentes com cargas perigosas. Master’s thesis, Escola Politecnica da Universidade de São Paulo. Departamento de Engenharia de Transportes, São Paulo, 2010.
- [59] D. Lowe. Object recognition from local scale-invariant features. In *International Conference on Computer Vision (ICCV)*, pages 1150–1157, 1999.
- [60] D. Lowe. Distinctive image features from scale-invariant keypoints. *International Journal of Computer Vision (IJCV)*, 60:91–110, 2004.
- [61] R. Matsuda. Morphology and evolution of the insect abdomen. *Pergamon Press, Oxford*, 1976.
- [62] M. J. Mattoso and J. C. Garcia. Análise econômica da agricultura de precisão. *Congresso Brasileiro de Agricultura de Precisão*, 2, 2006.
- [63] CONAB - Companhia Nacional de Abastecimento. Acompanhamento da safra brasileira: Grãos safra 2012/2013. Technical report, Companhia Nacional de Abastecimento (Conab), 2013.
- [64] Embrapa Soja. Consórcio antiferrugem - parceria público-privado o combate à ferrugem asiática de soja. Technical report, Embrapa, 2014.
- [65] Molin, J. P. Agricultura de precisão o gerenciamento da variabilidade. Technical report, Piracicaba, 2001.
- [66] Secretaria de Políticas Agrícolas. Plano agrícola e pecuário 2013/2014. Technical report, Ministério da Agricultura, Pecuária e Abastecimento, 2013.
- [67] A. McBratney, B. Whelan, and T. Ancev. Future directions of precision agriculture. *Precision agriculture*, 6, 2005.
- [68] N. L. Menezes, J. R. Pirani, A. M. Giulietti, W. R. Monteiro, M. Venturelli, M. E. Estelita, J. E. Kraus, V. Angyalossy, M. Arduin, G. C. T. Ceccantini, and G. F. Melo-De-Pinna. *Anatomia e Morfologia de Plantas Vasculares*. Apostila do Departamento de Botânica, Universidade de São Paulo, 2006.
- [69] K. Mikolajczyk and C. Schmid. A performance evaluation of local descriptors. *IEEE Transactions on Pattern Analysis and Machine Intelligence (PAMI)*, 27(10):1615–1630, 2005.

- [70] K. Mikolajczyk and C. Schmid. A performance evaluation of local descriptors. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 27(10):1615–1630, 2005.
- [71] J. P. Molin. Tendências da agricultura de precisão no brasil. *Congresso Brasileiro de Agricultura de Precisão*, pages 1 – 10, 2004.
- [72] A. I. Mongelo, D. S. Silva, L. N. B. Quinta, H. Pistori, and M. P. Cereda. Validação de método baseado em visão computacional para automação de contagem de viabilidade de leveduras em indústrias alcooleiras. *VIII Congresso Brasileiro de Agroinformática SBIAGRO*, 2011.
- [73] R. E. Motsinger, J. L. Bagent, S. D. Hensley, N. Horn, and L. D. Newsum. Soybean diseases and insects of louisiana. *Louisiana Cooperative Extension Service*, 1967.
- [74] M. Muja and D. Lowe. Fast approximate nearest neighbors with automatic algorithm configuration. *International Conference on Computer Vision Theory and Applications (VISAPP'09)*, 2009.
- [75] W. D. Mura, A. L. Oliveira, E. M. Sgarbi, and L. G. Sachs. Detecção automática da área foliar da soja danificada pela lagarta (anticarsia gemmatalis) utilizando processamento digital de imagens. *WORKSHOP OF UNDERGRADUATE WORKS / BRAZILIAN SYMPOSIUM ON COMPUTER GRAPHICS AND IMAGE PROCESSING (WUW-SIBGRAP)*, pages 01–04, 2007.
- [76] R. Namías, C. Gallo, R. M. Craviotto, M. R. Arango, and P. M. Granitto. Automatic grading of green intensity in soybean seeds. In *ASAI 2012, 13th Argentine symposium on artificial intelligence*, pages 96–104, 2012.
- [77] A. C. Nazaré-Jr, D. Menotti, J. M. R. Neves, and T. Sediyaama. Quantificando automaticamente a Área foliar danificada da soja por meio de imagens digitais. *REVISTA ELETRÔNICA DE INICIAÇÃO CIENTÍFICA*, 10:01–18, 2010.
- [78] P. Nuorteva and L. Reinius. Incorporation and spread of c14-labeled oral secretions of wheat bugs in wheat kernels. *Annales Entomologici Fennici*, 1953.
- [79] A. R. Panizzi. Possible egg positioning and gluing behavior by ovipositing southern green stink bug, nezara viridula (l.) (heteroptera: Pentatomidae). *Neotropical Entomology*, 2006.
- [80] A. R. Panizzi, B. S. Corrêa, D. Gazzoni, E. B. d. Oliveira, G. G. Newman, and S. G. Turnipseed. Insetos da soja no brasil. Technical report, "Londrina: EMBRAPA-CNPSO", 1977.
- [81] A. R. Panizzi, B. S. Corrêa-Ferreira, N. Neumaier, and E. F. d. Queiroz. Efeitos da época de semeadura e do espaçamento entre fileiras na população de artrópodos associados à soja. *SEMINÁRIO NACIONAL DE PESQUISA DE SOJA*, 1979.
- [82] A. R. Panizzi and C. C. Niva. Overwintering strategy of the brown stink bug in northern paraná. *Pesquisa Agropecuária Brasileira*, 1994.

- [83] L. P. Pedigo, S. H. Hutchins, and L. G. Higley. Economic injury levels in theory and practice. *Annual Review of Entomology*, 1986.
- [84] A. Peterson. Egg types among moths of the noctuidae. *Florida Entomologist*, 1964.
- [85] J. A. Powell, J. Razowski, and R. L. Brown. Tortricidae: Olethreutinae. *Atlas of Neotropical Lepidoptera, Checklist Part II: Hyblacoidea, Pyraloidea e Tortricoidea*. Gainesville: Association for Tropical Lepidoptera: Scientific Publishers, 1995.
- [86] R. J. Prokopy and M. Kogan. *Integrated pest management*. Encyclopedia of Insects. New York, Academic Press, 2003.
- [87] A. Rango and A. Laliberte. Impact of flight regulations on effective use of unmanned aircraft systems for natural resources applications. *Journal of Applied Remote Sensing*, 2010.
- [88] P. H. Raven, R. F. Evert, and S. E. Eichorn. *Biologia Vegetal*. 7^a edição. Editora Guanabara Koogan, 2007.
- [89] N. M. M. Riveiro, A. C. Camargo, E. A. Fernandes, M. d. O. Santos, V. N. H., J. M. Caruso, and C. Czepak. Determinação do melhor método de amostragem de insetos-praga na cultura da soja. *CONGRESSO BRASILEIRO DE ENTOMOLOGIA*, 2006.
- [90] E. M. Rogers. *Diffusion of innovations*. Free Press, 2003.
- [91] M. Ruiz. Mature flower diagram, 2015. Acesso em 11/02/2015.
- [92] Y. Ryuzo and M. H. Robert. Texture synthesis using a growth model. *Computer Graphics and Image Processing*, 8, 1978.
- [93] M. Sahu and N. Shukla. Rotation invariant approach of surf for unimodal biometric system. *International Journal of Emerging Technology and Advanced Engineering (IJETA)*, 3, 2013.
- [94] H. Seok-Wun and M. Yong-Ho. Multiple object tracking using sift features and location matching. *International Journal of Smart Home*, 5(4), 2011.
- [95] J. Shorthouse, D. Wool, and A. Raman. Gall-inducing insects ? nature's most sophisticated herbivores. *Basic and Applied Ecology*, 2005.
- [96] M. T. B. d. Silva, N. Neto, and C. B. Hoffmann-Campo. Distribution of eggs, larvae and adults of *sternechus subsignatus bohe*man on soybean plants under a no-till system. *Anais da Sociedade Entomológica do Brasil*, 1998.
- [97] N. M. Silva. Como utilizar imagens aéreas na agricultura de precisão?, 2013. Acesso em 19/05/2014.
- [98] M. Silva Neto. Como utilizar imagens aéreas na agricultura de precisão?, 2013. Acesso em 24/12/2014.

- [99] H. T. Sogaard and H. J. Olsen. Determination of crop rows by image analysis without segmentation. *Computers and Electronics in Agriculture*, 38(2):141 – 158, 2003.
- [100] D. R. Sosa-Gómez, B. S. Corrêa-Ferreira, C. B. Hoffmann-Campo, I. C. Corso, L. J. Oliveira, and F. Moscardi. Manual de identificação de insetos e outros invertebrados na cultura da soja. Technical report, Londrina: Embrapa Soja, 2010.
- [101] T. L. G. Souza, E. S. Mapa, K. dos Santos, and D. Menotti. Application of complex networks for automatic classification of damaging agents in soybean leaflets. *Image Processing (ICIP)*, pages 1065 – 1068, 2011.
- [102] V. M. Stern, R. F. Smith, R. Van Den Bosch, and R. S. Hagen. The integrated control concept. *Hilgardia*, 1959.
- [103] P. Tan, M. Steinbach, and V. Kumar. *Introduction to Data Mining*. Addison Wesley., 2005.
- [104] A. Tellaeche, X. P. BurgosArtizzu, G. Pajares, A. Ribeiro, and C. Fernández-Quintanilla. A new vision-based approach to differential spraying in precision agriculture. *Computers and Electronics in Agriculture*, 60(2):144 – 155, 2008.
- [105] A. Tellaeche, G. Pajares, X. P. Burgos-Artizzu, and A. Ribeiro. A computer vision approach for weeds identification through support vector machines. *Appl. Soft Comput.*, 11(1):908–915, 2011.
- [106] T. Theis and J. Tomkin. Sustainability: A comprehensive foundation, 2012. Acesso em 21/05/2014.
- [107] J. W. Todd. Ecology and behavior of nezara viridula. *Annual Review of Entomology*, 1989.
- [108] J. W. Todd and D. C. Herzog. Sampling phytophagous pentatomidae on soybean. *Sampling methods in soybean entomology*, 1980.
- [109] E. Tola, V. Lepetit, and P. Fua. Daisy: An efficient dense descriptor applied to wide base- line stereo. *IEEE Transactions on Pattern Analysis and Machine Intelligence (PAMI)*, 32(5):815–830, 2010.
- [110] C. Toth, J. O'Rourke, and J. Goodman. *Handbook of Discrete and Computational Geometry, Second Edition*. Discrete and Combinatorial Mathematics Series. Taylor & Francis, 2004.
- [111] T. Tuytelaars and K. Mikolajczyk. Local invariant feature detectors: A survey. *Foundations and Trends in Computer Graphics and Vision*, 3:177–280, 2008.
- [112] S. Zickler and M. Veloso. Detection and localization of multiple objects. In *Humanoid Robots, 2006 6th IEEE-RAS International Conference on*, pages 20–25, 2006.