

# Recognition of Soybean Insect Pests using SURF and Template Matching

Diogo Soares da Silva,  
Universidade Federal de Mato Grosso do Sul - UFMS  
Cidade Universitária. Campo Grande - MS  
E-mail: diogo.ec.2013@gmail.com

Gercina Gonçalves da Silva, Ariadne Barbosa  
Gonçalves, Lucas Castro Torres, Hemerson Pistori  
Universidade Católica Dom Bosco – UCDB  
Avenida Tamandaré, 6000. Jardim Seminário.  
Campo Grande -MS  
E-mail: [gercina.goncalves@gmail.com](mailto:gercina.goncalves@gmail.com), [ariadne.gon@gmail.com](mailto:ariadne.gon@gmail.com),  
[rf4094@ucdb.br](mailto:rf4094@ucdb.br), [pistori@ucdb.br](mailto:pistori@ucdb.br)

**Abstract**— This paper presents some experimental results regarding the use of SURF and template matching for insects identification in soybean crops. Three different matching strategies have been proposed and tested using the F-Score and the AUC metric. A maximum F-Score of 85% has been achieved using the strategy of assigning the test images to the class containing the training image with the strongest keypoint match.

**Keywords**—computer vision, *Glycine max*, pests recognition; template match

## I. INTRODUÇÃO

A soja (*Glycine max*) é a principal cultura de grãos Brasileiros, no entanto antes da década de 70 ela 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 de então a cultura de soja ganhou destaque e incentivo governamental, se tornando a principal cultura nacional [1].

De acordo com Companhia Nacional de Abastecimento (CONAB) [2], o Centro-Oeste brasileiro é o principal produtor de soja, sendo que a previsão para a safra 2014/2015 é de 95 milhões de toneladas. O estado de Mato Grosso do Sul produziu nesse ciclo 6,89 milhões de toneladas.

No entanto, a produtividade de soja tem limitações devido a ocorrências nocivas aos vegetais e comprometem a sanidade da cultura. Fungos, bactérias, vírus e nematóides são organismos nocivos que desencadeiam doenças nas plantas. Além desses, pragas como, por exemplo, os insetos, os ácaros e as plantas daninhas comprometem o desenvolvimento da cultura. A FAO considera que as pragas são responsáveis, em média, por cerca 42,1% das perdas na produção [3].

Com a eliminação dos efeitos prejudiciais causados por pragas agrícolas, pode-se reduzir as perdas na produção, o que indica a necessidade do manejo destas. Estima-se que 13,3% dos danos das plantações são causados por fitopatógenos (agentes causadores de doenças), as plantas daninhas são responsáveis por 13,2% e os 15,6% do dano restante são causados por pragas como insetos e ácaros [3].

Nos últimos anos tem aumentado as tecnologias destinadas a aumentar a produção na agricultura e a reduzir os impactos ambientais e devem ocorrer mais inovações tecnológica no campo [4]. Assim, a cultura de soja possui grande potencial para a implementação de inovações tecnológicas. 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.

Com o intuito de colaborar com o setor agropecuário do Estado do Mato Grosso do Sul por meio de geração e implementação de novas tecnologias, este trabalho tem como objetivo desenvolver um programa de computador para a classificação de insetos que causam danos na plantação de soja, utilizando técnicas baseadas em Visão computacional. Para isso, serão utilizados atributos como descritores de pontos de interesse e algoritmos de casamento de modelos em imagens de lavouras de soja.

O trabalho está organizado em seis seções. Na Seção II a motivação do trabalho é apresentada. Na Seção III é apresentado a base teórica referente aos trabalhos relacionados utilizando técnicas de classificação de insetos. Na Seção IV é descrita a técnica e as utilidades dos detectores de pontos de interesse e casamento de modelos. A Seção V apresenta a metodologia utilizada para o experimento. A Seção VI apresenta os resultados e discussões sobre os experimentos e as conclusões em conjunto com propostas para trabalhos futuros estão expostos na Seção VII.

## II. INSETOS NA SOJA

O monitoramento 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 pode evitar que o produtor tenha possíveis perdas de produtividade por demora em sua tomada de decisão [7].

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. 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 [7]. A cultura da soja está sujeita ao ataque de insetos em todo o seu ciclo vegetativo, conforme Figura 1.

Inseto	Parte da planta atacada	Importância
<i>Anticarsia gemmatilis</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 sp.</i>	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 sp.</i>	Fo	Secundária
<i>Chalcodermus sp.</i>	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 sp.</i>	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 testualis</i>	Va	Esporádica
<i>Sternuchus 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 sp.</i>	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 spp. (Corós)</i>	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 1: Possíveis ataques de pragas em cada ciclo vegetativo da soja.  
Fonte: Embrapa Soja [8]

Logo após a germinação, a partir do início do estágio vegetativo, vários insetos como o bicudo-da-soja, a lagarta elasmó, os corós e os percevejos-castanholas-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. 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 atacam 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 [8].

### III. TRABALHOS RELACIONADOS

Mura et. al. [9] 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 [10] 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.

No trabalho [11] os autores construíram um algoritmo baseado nas técnicas k-média e filtro de correspondência para detecção e reconhecimento de pragas em mais de 10 tipos de culturas distintas. O algoritmo empregado foi capaz de detectar e reconhecer as pragas presentes nas plantas, com suas mais variadas formas, tamanhos, orientações e posições.

### IV. ALGORITMOS BASE

Detecção de características locais é a identificação de determinados atributos em uma imagem, por exemplo, contornos, pontos de interesse, bordas, e outros. A principal propriedade de algoritmos de detecção de características é a repetibilidade, isto é, dadas duas imagens distintas do mesmo

objeto ou cena, tiradas sob diferentes condições de visualização, uma elevada porcentagem de características de pontos de interesse da cena devem ser encontradas em ambas as imagens [12]. Além da propriedade de repetibilidade, bons detectores de características devem possuir distintividade, localidade, quantidade, precisão e eficiência. A importância de cada uma destas características vai depender da aplicação desejada.

- Detecção de Pontos de Interesse

O algoritmo SIFT [13] [14] 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. Para o SIFT, pontos de interesse correspondem a locais extremos no filtro da diferença Gaussiana (DOG) em diferentes escalas. Assim, para detectar eficientemente pontos de interesse estáveis no espaço de escalas, Lowe [14] propõe a utilização de um espaço de escala extremo da função da diferença Gaussiana convoluída 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  $k$ .

Com os pontos de interesse localizados nos locais extremos da DOG, uma região em torno do ponto de interesse é selecionada e a partir desta área 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 transformações. Com os gradientes locais da imagem em uma determinada escala, esses gradientes são transformados em atributos que descrevem o ponto de interesse e que admitem grandes distorções nos níveis de mudanças de iluminação e rotação.

O algoritmo SURF [15] é um algoritmo utilizado para a detecção de pontos de interesse e construção de descritores destes pontos de interesse em imagens, conhecido por ser robusto, pode ser utilizado em tarefas baseadas em visão computacional, como reconhecimento de objetos e reconstrução 3D. Para a detecção de pontos de interesse, o SURF utiliza o determinante da aproximação da matriz Hessiana. Na aproximação da matriz Hessiana, é utilizada a integral das imagens ao invés da original para a redução do tempo de processamento.

E assim como o SIFT, o SURF seleciona uma região em torno do ponto de interesse para a atribuição de uma orientação ao ponto de interesse. Essa orientação é definida pelo cálculo da resposta da região do ponto de interesse ao filtro das *Haar wavelets* nas direções horizontal e vertical. Após definir a orientação dominante do ponto de interesse, novamente uma resposta ao filtro das *Haar wavelets* é calculada na região do ponto de interesse, porém a resposta do filtro é feito em relação à orientação dominante do pontos de interesse. As respostas do filtro das *Haar wavelets* são utilizadas para descrever o ponto de interesse, tendo também invariância à rotação e iluminação.

- 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. [15] 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 [16].

## V. MATERIAIS E MÉTODOS

- Banco de imagens

As imagens utilizadas neste trabalho foram obtidas junto a uma lavoura instalada em uma área de um hectare. A plantação foi separada em quatro quadrantes de 25 por 50 metros de área, onde em cada quadrante uma praga da soja foi simulada, conforme Figura 2. O primeiro quadrante foi chamado de cultura “normal” onde é realiza o manejo contra plantas daninhas, doenças e insetos. O segundo quadrante foi nomeado como “daninhas”, pois nele as plantas daninhas foram evidenciadas pela falta de controle desta praga. O terceiro quadrante foi nomeado como “doenças” visto que nesta área não houve controle contra doenças. O quarto quadrante foi nomeado como “pragas”, referindo-se aos insetos, já que o controle de insetos prejudiciais a soja não foram realizados nesse quadrante.

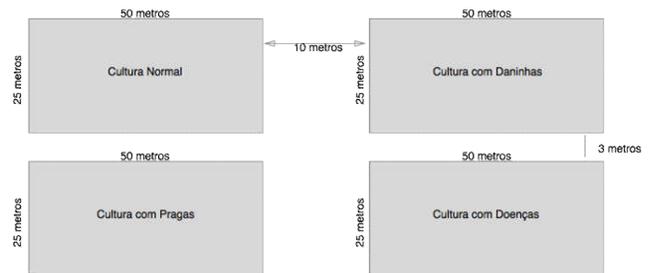


Figura 2: Configuração final do cultivo da soja

Vale ressaltar que somente o quadrante intitulado “pragas” foi avaliado neste trabalho. Com o cultivo de soja implantado, uma coleta de insetos pela metodologia do pano-de-batida [17] foi feita, conforme demonstrado na Figura 3. Com os insetos capturados, um entomologista ficou encarregado de classificar cada exemplar capturado e após a classificação foram capturadas imagens dos espécimes, o que originou o banco de imagens utilizado para o desenvolvimento e avaliação da aplicação aqui proposta.



Figura 3: Captura dos insetos com pano-de-batida.

Neste banco de imagens foram obtidas três classes, sendo elas: percevejo marrom (*Euschistus* sp.) que pode ser visto na Figura 4.A, percevejo verde pequeno (*Piezodorus* sp.) que está representado na Figura 4.B e finalmente vaquinha (*Diabrotica* sp.) que está representada na imagem 4.C. Como a quantidade de imagens obtida foi proporcional aos insetos capturados em campo, cada classe ficou com quantidades diferentes de imagens, visto que alguns insetos tiveram mais infestação que outros. A primeira classes com 25 exemplos, a segunda com 59 e a terceira com 21. A Figura 4 ilustra os exemplares do banco de imagem.

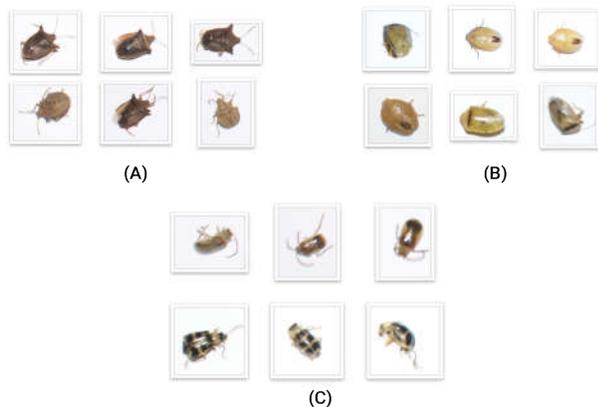


Figura 4: Banco de imagens dos insetos.

- **Módulo de Classificação**

O módulo de classificação de insetos possui três etapas principais, onde na primeira os pontos de interesse da imagem a ser classificada e das imagens do 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 e, finalmente, na terceira etapa, um módulo de classificação utiliza os dados gerados para atribuir uma classe à imagem teste.

Na primeira etapa a imagem teste e todas as imagens do conjunto de treinamento (exemplos dos modelos que devem

ser buscados) tem seus ponto de interesse extraídos pelo SURF como é mostrado na Figura 5.A. Já na segunda etapa, os pontos de interesse da imagem teste são casados com cada exemplo do banco de imagem (Figura 5.B), a técnica utilizada para efetuar esse casamento é a técnica utilizada por Bay et. al. [15]. Finalmente na terceira etapa, é atribuída uma classe à imagem teste segundo a metodologia de classificação que será apresentada a seguir.

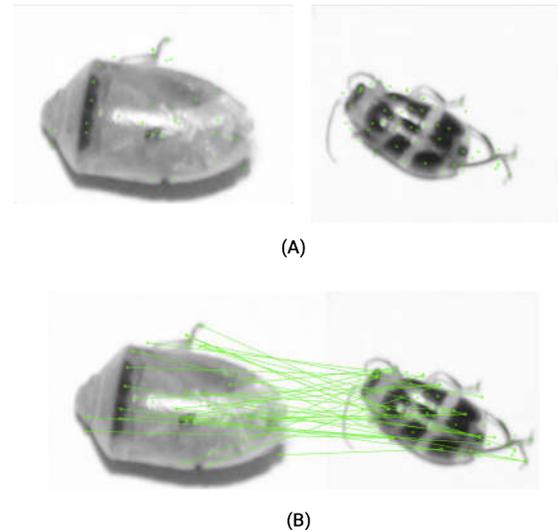


Figura 5: Exemplo dos pontos de interesses detectados e do casamento de pontos de interesse.

Visto que somente um ponto de interesse não possui informação suficiente para descrever um objeto, para a determinação da classe da imagem teste, uma métrica que utiliza das informações do casamento de modelo deve ser utilizada. Para determinar a classe que a imagem pertence, duas informações devem ser extraídas do resultado do casamento de modelos. Essas informações são: a quantidade de pontos casados e a distância entre cada correspondência. Para classificar a imagem, três abordagens são utilizadas, sendo elas:

**Distância Mínima:** Para determinar a classe que a imagem pertence, primeiro é encontrado o ponto de interesse com a menor distância entre a imagem de entrada e o conjunto de treinamento de cada classe. É assumida a classe que tiver o ponto com menos distância da imagem teste.

**Média das Distâncias:** Para determinar a classe que a imagem pertence, é encontrada a média das distâncias entre a imagem de entrada e o conjunto de treinamento de cada classe. É assumida a classe que tiver a menos distância da imagem teste.

**Números de Pontos Casados:** Nesta metodologia é assumido que a classe da imagem de entrada é igual a da classe que obteve a maior quantidade de pontos casados.

Vale a pena ressaltar que para que as diferentes métricas de classificação 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 à pontuação dada pela métrica à classe em questão. O classificador utiliza a soma dessa pontuação para definir qual a classe escolhida.

## VI. RESULTADOS E DISCUSSÃO

Buscando o melhor resultado de classificação utilizando as três classes do banco de imagens (percevejo verde pequeno, percevejo marrom e vaquinha) no sistema desenvolvido, foram realizados diferentes testes para encontrar o melhor conjunto de parâmetros para a classificação. Vale ressaltar que em todos os experimento a Medida-F foi utilizada como medida de desempenho. Na detecção e descrição de pontos de interesse, o único parâmetro alterado foi o limiar Hessiano que determina a sensibilidade do detector.

O teste de classificação foi realizado utilizando diferentes faixas de parametrização para o limiar Hessiano, conforme Tabela 1, onde se verifica o pior e melhor resultado obtido por cada faixa do limiar Hessiano com a medida-F. Destaca-se que as três primeiras faixas foram utilizadas para a calibração dos parâmetros, visto que a variação do limiar Hessiano é grande. A partir da quarta faixa os resultados começaram a se estabilizar.

Tabela 1: Resultados obtidos no primeiro experimento usando a métrica medida-F.

Faixa do limiar Hessiano	Pior Resultado	Melhor Resultado
0,1 à 0,5	0.24242	0.24242
0,01 à 0,05	0.24242	0.50606
0,001 à 0,005	0.24848	0.76060
0,0001 à 0,0009	0.16666	0.82424
0,00001 à 0,00009	0.10303	0.83333
0,000001 à 0,000009	0.10606	0.85454

Conforme o limiar Hessiano é reduzido, a classificação melhora devido ao aumento de pontos de interesse encontrados nas imagens (quanto menor o limiar mais sensível a detecção). O problema da redução deste limiar é o custo computacional. A Figura 5 demonstra a matriz de confusão do melhor resultado da classificação correta dos insetos. Vale ressaltar que o valor amostrado em cada experimento é a Medida-F.

A	B	C		
				A
7	1	0		B
3	15	0		C
0	1	6		

A- *Euschistus* sp.; B- *Piezodorus* sp.; C) *Diabrotica* sp.  
Figura 5: Matriz de confusão da classificação dos insetos.

Conforme demonstrado pela matriz de confusão do melhor resultado, a maior faixa de erro ocorre entre a classe do percevejo marrom e percevejo verde pequeno. Os percevejos em geral possuem diversos estágios de crescimento, conforme Figuras 6 e 7, e nestes estágios os percevejos podem mudar sua forma e coloração, o que torna sua classificação ainda mais difícil visto que temos características divergentes na mesma classe, o que se intensifica com a baixa representatividade do banco de imagens.



Figura 6: Percevejo marrom (*Euschistus* sp.)



Figura 7: Percevejo verde pequeno (*Piezodorus* sp.)

## VII. CONCLUSÃO

Este trabalho foi desenvolvido com o intuito de automatizar a classificação de insetos em cultura de soja, sendo esta uma pesquisa pioneira na automatização da identificação de insetos em culturas de soja, pois não foi encontrada literatura com esta especificidade. Apesar do banco de imagem não ser representativo, visto que os insetos possuem vários estágios ninfaís, o resultado obtido neste experimento foi de 85% com a medida-F, sendo considerado aceitável para um trabalho pioneiro.

Para trabalhos futuros, espera-se que sejam utilizadas imagens capturadas por Veículos Aéreos Não Tripulados que é a nova tecnologia para avaliação de culturas. Além do mais,

implementar um algoritmo para segmentação dos insetos, para automatização de sua contagem no manejo de pragas de em cultura de soja.

Nos próximos trabalhos, a técnica de casamento de pontos de interesse como FLANN pode ser utilizada para melhorar o desempenho do sistema, reduzir o custo computacional e proporcionar assim, a redução do limiar Hessiano que aumenta a quantidade de pontos de interesse avaliados pelo classificador. Dado que os pontos de interesse utilizam imagens em tons de cinza, nenhuma característica relacionada a cor das classes foi avaliada, o que pode interferir na classificação, por isso sugere-se a utilização de atributos de cor nos descritores.

### VIII. AGRADECIMENTOS

Este trabalho recebeu apoio financeiro da Universidade Católica Dom Bosco - UCDB, da Fundação de Apoio ao Desenvolvimento do Ensino, Ciência e Tecnologia do Estado de Mato Grosso do Sul – FUNDECT, do Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPQ e da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - CAPES.

### REFERÊNCIAS

- [1] Embrapa Soja, “Consórcio antiferrugem - parceria público-privado o combate à ferrugem asiática de soja,” Embrapa, Tech. Rep., 2014. [Online]. Available: <http://www.consorcioantiferrugem.net/portal/>.
- [2] CONAB - Companhia Nacional de Abastecimento, “Acompanhamento da safra brasileira: Grãos safra 2012/2013,” Companhia Nacional de Abastecimento (Conab), Tech. Rep., 2013. [Online]. Available: [http://www.conab.gov.br/OlalaCMS/uploads/arquivos/13\\_08\\_09\\_10\\_43\\_44\\_boletim\\_portuges\\_agosto\\_2013\\_port.pdf](http://www.conab.gov.br/OlalaCMS/uploads/arquivos/13_08_09_10_43_44_boletim_portuges_agosto_2013_port.pdf).
- [3] P. F. Kreyci and J. O. M. Menten, “Limitadoras de produtividade,” *Esalq/USP*, Tech. Rep. 167, 2013.
- [4] 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*, vol. 44, pp. 49–61, 2004.
- [5] C. Gillott, *Entomology*. Ed. New York, Plenum Press, 1995.
- [6] R. Matsuda, “Morphology and evolution of the insect abdomen.” Pergamon Press, Oxford, 1976.
- [7] E. S. S. de Produção, “Tecnologias de produção de soja - da região central do Brasil 2012 e 2013,” Londrina: Embrapa Soja: Embrapa Cerrados; Embrapa Agropecuária Oeste, Tech. Rep., 2011.
- [8] C. Hoffmann-Campo, B. Corrêa-Ferreira, and F. Moscardi, *Soja - Manejo Integrado de Insetos e outros Artrópodes-Praga*. Livraria Embrapa, 2012.
- [9] W. D. Mura, A. L. Oliveira, E. M. Sgarbi, and L. G. Sachs, “Detecção automática da área foliar da soja danificada pela lagarta (*antarsia gemmatalis*) utilizando processamento digital de imagens.” *Workshop of Undergraduate Works / Brazilian Symposium on Computer Graphics and Image Processing (Wuw-Sibgrapi)*, pp. 01–04, 2007.
- [10] A. C. Nazaré-Jr, D. Menotti, J. M. R. Neves, and T. Sedyama, “Quantificando automaticamente a Área foliar danificada da soja por meio de imagens digitais,” *REVISTA ELETRÔNICA DE INICIAÇÃO CIENTÍFICA*, vol. 10, pp. 01–18, 2010.
- [11] F. Fina, P. Birch, R. Young, J. Obu, B. Faithpraise, C. Chatwin. Automatic Plant Pest Detection and Recognition Using K-Means Clustering Algorithm and Correspondence Filters. *International Journal of Advanced Biotechnology and Research*, v.4, p. 189-199, 2013.
- [12] T. Tuytelaars and K. Mikolajczyk, “Local invariant feature detectors: A survey,” *Foundations and Trends in Computer Graphics and Vision*, vol. 3, pp. 177–280, 2008.
- [13] D. Lowe, “Distinctive image features from scale-invariant keypoints,” *International Journal of Computer Vision (IJCV)*, vol. 60, pp. 91–110, 2004.
- [14] D. Lowe, “Object recognition from local scale-invariant features,” In *International Conference on Computer Vision (ICCV)*, pp. 1150–1157, 1999.
- [15] H. Bay, A. Ess, T. Tuytelaars, and L. Van Gool, “Speeded-up robust features (surf),” *Computer Vision and Image Understanding (CVIU)*, vol. 110(3), pp. 346–359, 2008.
- [16] K. Mikolajczyk and C. Schmid, “A performance evaluation of local descriptors,” *IEEE Transactions on Pattern Analysis & Machine Intelligence*, vol. 27, no. 10, pp. 1615–1630, 2005. [Online]. Available: <http://lear.inrialpes.fr/pubs/2005/MS05>
- [17] R. Motsinger, J. Bagent, S. Hensley, H. Horn and L. Newson, “Soybean diseases and insects of Louisiana” Louisiana Cooperative Extension Service, 1967.