

---

Atributos de Pontos de Interesse e  
Casamento de Modelos para Inspeção  
de Folhas de Soja em Imagens Coloridas

*Diogo Soares da Silva*

---



# Sumário

---

---

Sumário . . . . .	iii
<b>1 Antecedentes e Justificativa</b>	<b>1</b>
<b>2 Objetivos</b>	<b>5</b>
2.1 Geral . . . . .	5
2.2 Específicos . . . . .	5
<b>3 Revisão de Literatura</b>	<b>7</b>
3.1 Descrição de Características . . . . .	7
3.1.1 Scale Invariant Feature Transformation (SIFT) . . . . .	8
3.1.2 Speeded Up Robust Feature (SURF) . . . . .	11
3.1.3 Casamento de modelos . . . . .	14
3.1.4 Casamento de Pontos de Interesse . . . . .	17
<b>4 Metodologia</b>	<b>21</b>
4.1 Aprofundamento e atualização da revisão de literatura . . . . .	21
4.2 Construção de um banco de imagens de Soja . . . . .	21
4.3 Desenvolvimento do módulo de Classificação de Soja . . . . .	22
4.4 Validação do módulo de Classificação de Soja . . . . .	23
4.5 Registro e divulgação de resultados . . . . .	23
<b>5 Cronograma</b>	<b>25</b>
<b>Referências</b>	<b>29</b>



---

# Antecedentes e Justificativa

---

Segundo a Secretaria de Políticas Agrícola [2013] 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 exportações é o Brasil, de modo a atender a maior parte desse aumento.

Embora hoje a soja (*Glycine max*) 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 (Embrapa Soja [2014]).

No cenário nacional, de acordo com CONAB (2013), o Centro-Oeste Brasileiro é o principal produtor da cultura, sendo que na safra 2012/2013 a área semeada foi de 20,6 milhões de hectares, com uma produtividade média de 3,760 kg por hectare, totalizando 77,6 milhões de kg colhidas. A segunda grande região produtora de soja no Brasil é a região sul, que cultiva anualmente 18,5 milhões de hectares, e tem uma produtividade de 3,856 kg por hectare, totalizando um montante de 71,4 milhões de kg colhidos. Os três maiores produtores de soja no Brasil são os Estados do Mato Grosso (45,9,7 milhões de kg), Paraná (36,9 milhões de kg) e Rio Grande do Sul (28,2 milhões de kg).

Entre os principais fatores que limitam o rendimento das práticas de agri-

cultura estão as pragas, seres nocivos aos vegetais, que incluem agentes que causam doença na planta (fungos, bactérias, vírus e nematoides), insetos, ácaros e plantas daninhas. A Organização Mundial para Alimentação e Agricultura (FAO) considera que as pragas são responsáveis, em média, por cerca de 42,1% das perdas na produção (Kreyci and Menten [2013]).

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 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 insetos e ácaros (Kreyci and Menten [2013]).

Segundo Namias et al. [2012] 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 voltadas 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 and Tomkin [2012] os investimentos em tecnologia são o principal motor do crescimento econômico global a longo prazo. Segundo Herwitz et al. [2004], a agricultura tem se tornado uma indústria onde cada vez mais se faz importante o investimento ao conhecimento para se obter respostas a questões ambientais e econômicas. Abordagens agrícolas baseadas em tecnologia são destinadas a aumentar a produção agrícola e a reduzir os impactos ambientais e devem impulsionar ainda mais a inovação tecnológica no campo. Logo, o segmento do agronegócio é uma área com grande potencial para inovações tecnológicas, como o sensoriamento remoto e a utilização de Veículos Aéreos Não Tripulados (VANTs).

Os VANTs que foram inicialmente projetado 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 (Longhitabi [2010]). A agricultura cada vez mais necessitam 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 produtividade, possíveis focos de doenças ou pragas, são, nesse contexto, bons exemplos.

O monitoramento de safras a partir de imagens obtidas por VANTs possibi-

lita a aquisição de dados 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 [2013] 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 especializados 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.

Diversos grupos de pesquisa dentro e fora do Estado têm desenvolvidos trabalhos em computação que se relacionam com a produção de soja. Mura et al. [2007] dedicou 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 avaliados as regiões danificadas da folha para a estimativa da área afetada. O desempenho do sistema proposto obteve melhor erro percentual médio que um especialista humano.

Seguindo a metodologia de Mura, é proposto por Nazaré-Jr et al. [2010] 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 recuradas 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 melhor 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 por meio de geração de novas tecnologias, este trabalho tem como objetivo analisar a aplicação do Extração de Pontos de Interesse e Casamento de modelo para a identificação de anomalias 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, será utilizada o algoritmo SURF (Speeded Up Robust Feature) que re-

aliza a análise em imagens em tons de cinza, sendo uma nova contribuição do trabalho a adição de atributos de cor na descrição dos pontos de interesse encontrados pelo método utilizado.

Dentre os problemas encontrados que serão considerados na presente proposta, estão as infestações de plantas daninhas e as deficiências nutricionais das plantas de soja. Para a identificação das deficiências nutricionais, serão consideradas as alterações de cores características de cada nutriente e, para a identificação das plantas daninhas, serão consideradas as concentrações de vegetais nas regiões. As imagens a serem utilizadas na identificação de anomalias serão obtidas por meio de VANTs. Com tal identificação automatizada, espera-se aumentar a precisão das análises de plantações com custo e tempo comparativamente menores que o aumento dos números de amostras utilizados habitualmente nas produções de soja.

No município de Ponta Porã, no MS, a Rede AGROBIOCOMP: Computação Aplicada à Sustentabilidade, com colaboração do Grupo de Pesquisa em Engenharia e Computação (GPEC/UCDB), propõe a avaliação do efeito da luminosidade e do estresse hídrico (conjunto de reações causadas em plantas por falta de água) em folhas de soja e milho por meio da análise da textura das folhas dessas plantas. As imagens digitais serão obtidas por meio de VANTs que contarão com dispositivos para captura de imagens. Com colaboração do projeto proposto pela Rede AGROBIOCOMP, pretende-se neste trabalho aplicar a extração de atributos de pontos de interesse e casamento de modelos na classificação de agentes danificadores de folhas de soja em imagens coloridas na região de Mato Grosso do Sul. Para isso, serão obtidas imagens em campo de folhas de soja por meio de VANTs. Essas imagens serão processadas e submetidas e classificadas pela abordagem proposta.

Essa pesquisa faz parte dos projetos do INOVISAO, que é um Grupo de Pesquisa de Desenvolvimento e Inovação em Visão Computacional. O INOVISAO tem como principal objetivo a integração entre pesquisa, desenvolvimento e inovação para contribuir com o desenvolvimento do estado do Mato Grosso do Sul. O INOVISAO possui diversos projetos de visão computacional voltados para aplicações no agronegócio e outras áreas relevantes para a região e conta com parcerias com indústrias, outras instituições de pesquisa e agências de fomento, e tem tido sucesso na obtenção de investimentos para a pesquisa no estado, que já resultaram em diversas publicações e no registro de dois softwares, além da criação de uma empresa de base tecnológica que iniciou a inserção dos produtos gerados no mercado nacional e internacional.



---

# Objetivos

---

## 2.1 Geral

Desenvolver um programa de computador para a identificação de possíveis danos na plantação de soja utilizando técnicas baseadas em Visão computacional. Para isso serão utilizados atributos como descritores de pontos de interesse e cores e algoritmos de casamento de modelos em imagens de lavouras de soja capturadas por VANTs .

## 2.2 Específicos

Para atingir o objetivo geral definido na seção 2.1, foram estabelecidos os seguintes objetivos específicos:

- Aprofundamento e atualização da revisão de literatura em técnicas de Visão computacional, voltadas para descrição de pontos de interesse, extração de atributos de cores e casamento de modelos.
- Construção de um banco de imagens de lavouras de soja.
- Implementação do módulo de detecção de possíveis áreas danificadas em imagens aéreas de lavouras de soja.
- Validação do módulo de implementado.
- Registro e divulgação de resultados



---

## Revisão de Literatura

---

### 3.1 *Descrição de Características*

Detecção de características locais é a identificação de determinados atributos em uma imagem (por exemplo, contornos, pontos de interesse, bordas, etc). 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 (Tuytelaars and Mikolajczyk [2008]). 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.

Uma vez que um conjunto de características locais foram detectadas a partir de uma imagem, algumas medições são feitas a partir da região destas características 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 (Lowe [2004]), SURF (Bay et al. [2008]), HOG (Dalal and Triggs [2005]), GLOH (Mikolajczyk and Schmid [2005a]) e DAISY (Tola et al. [2010]). A seguir, serão resumidos os descritores SIFT e SURF, que são as técnicas mais utilizadas para tarefas de reconhecimento visual.

### 3.1.1 Scale Invariant Feature Transformation (SIFT)

SIFT (Lowe [2004] Lowe [1999]) foi originalmente proposto para a detecção e descrição de pontos de interesse. O descritor SIFT descreve cada ponto de interesse com um vetores 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 estágio 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 eleitas como ponto de interesse são selecionadas com base em suas médias das estabilidade, que será melhor descrito 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 filtro da diferença Gaussiana em diferentes escalas. Assim, para detectar eficientemente pontos de interesse estáveis no espaço de escalas, Lowe [1999] propõe a utilização de um espaço de escala extremo 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  $k$ . Representando a equação do filtro Gaussiano descrito na seguinte equação.

$$L(x,y,\sigma) = G(x,y,\sigma) \cdot I(x,y) \quad (3.1)$$

Onde,

$$G(x, y, \sigma) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{\sigma^2}} \quad (3.2)$$

É a Gaussiana com escala variada. cujo resultado da convolução da imagem pela diferença do filtro Gaussiano é dado por

$$D(x, y, \sigma) = L(x, y, k\sigma) - L(x, y, \sigma) \quad (3.3)$$

A função utilizada na verdade é apenas a diferença das imagens com desfoque Gaussiano nas escalas  $\sigma$  e  $k\sigma$ .

O primeiro passo para a detecção dos pontos de interesse da imagens, é a convolução da imagem com a função Gaussiana para a produção de imagens separadas por um fator  $k$  no espaço de escalas, mostrados na coluna da esquerda na Figura 3.1. As imagens convolucionadas são agrupadas por oitavas (uma oitava corresponde ao dobro do valor de  $\sigma$ ). Cada oitava do espaço de escalas é dividido por um número,  $s$ , de intervalos, logo  $k = 2^{1/s}$ . Para que a detecção extrema cubra todas as oitavas, deve-se produzir  $s + 3$  imagens para cada oitava. As imagens de escalas adjacentes são subtraídas para produzir as imagens da diferença Gaussiana, ilustradas na coluna na direita.

Figura 3.1: 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, 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 3.2.

Figura 3.2: Detecção local extrema, o pixel marcado  $X$  é comparado com 26 vizinhos com uma vizinhança de  $3 \times 3 \times 3$  que se expandem pelas imagens da diferença Gaussiana adjacentes.

Com os cadidatos a pontos de interesse encontrados pela comparação com seus vizinhos, 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 [1999] 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 3.4.

$$D(\hat{X}) = D + \frac{1}{2} \frac{\partial D^T}{\partial X} \hat{X} \quad (3.4)$$

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 destas respostas da diferença Gaussiana nas boras, Lowe [1999] utiliza a Equação 3.5.

$$\frac{Tr(H)^2}{Det(H)} < \frac{(r+1)^2}{r} \quad (3.5)$$

Onde,  $H$  é uma matriz Hessiana de  $2 \times 2$  que descreve a curvatura principal feita pela diferença Gaussian, descrita por Lowe [1999], 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 relativo à sua orientação o que lhe dá invariância à rotação da imagem. A escala do ponto de interesse é utilizado para selecionar a imagem com convolução Gaussiana,  $L$ , com escala mais próxima. Então para a imagem selecionada, o gradiente de magnitude  $m(x, y)$  e orientação  $\theta(x, y)$  são calculados com as seguintes equações:

$$m(x, y) = \sqrt{(L(x+1, y) - L(x-1, y))^2 + (L(x, y+1) - L(x, y-1))^2} \quad (3.6)$$

$$\theta(x, y) = \tan^{-1} \left( \frac{L(x, y+1) - L(x, y-1)}{L(x+1, y) - L(x-1, y)} \right) \quad (3.7)$$

As operações descritas anteriormente, atribuíram localização, escala e orientação a cada ponto de interesse.

### *Representação de Características do SIFT*

Com a orientação do ponto de interesse definido, o descritor de características do ponto de interesse pode ser calculado, primeiro o gradiente de magnitude e orientação são amostrados em torno da localização ponto de interesse, utilizando a escala do ponto de interesse para selecionar o nível do filtro Gaussiano da imagem. Para manter a invariância a rotação, as coordenadas do descrito e o gradiente de orientação são rotacionados segundo a orientação do ponto de interesse. Essa descrição pode ser visto no lado esquerdo da Figura 3.3.

Uma função Gaussiana de peso  $\sigma$  igual à metade do tamanho da janela do

descritor é utilizada para atribuir o peso a magnetude de cada ponto. Esse processo esta ilustrado com o circulo no lado esquerdo da Figura 3.3. O descrito do ponto de interesse é ilustrado no lado direito da Figura 3.3, a figura mastra oito direções para cada histogram de orientações, sendo que o tamanho de cada flexa representa a magnetude do histogram.

Figura 3.3: Descritor de características do SIFT.

Cada histograma possui 8 bins, e cada descritor contem um conjunto de 4 histogramas ao redor do ponto de interesse. Isto proporciona ao vetor de características do SIFT com  $4 \times 4 \times 8 = 128$  elementos. 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 angulo no espaço Euclidiano.

### 3.1.2 *Speeded Up Robust Feaure (SURF)*

O SURF (Bay et al. [2008]) 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. Os pontos de interesse calculados com o SURF, são invariantes à escala e rotação. Como detector, o SURF localiza os pontos de interesse na imagem 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 sessões será descrito como o SURF é utilizado para fins de reconhecimento de padrões em uma imagem.

#### *Detecção de Pontos de Interesse*

Para a detecção de pontos de interesse, o SURF utilizada 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. A matriz Hessiana  $H(x, \sigma)$  para um dado ponto  $x = (x, y)$  de imagem com escala  $\sigma$  é dada por

$$H(x, \sigma) = \begin{vmatrix} L_{xx}(x, \sigma) & L_{xy}(x, \sigma) \\ L_{xy}(x, \sigma) & L_{yy}(x, \sigma) \end{vmatrix} \quad (3.8)$$

Onde  $L_{xx}(x, \sigma)$ ,  $L_{x,y}(x, \sigma)$  e  $L_{yy}(x, \sigma)$  são convoluções da derivada parcial Gaussianas de segunda ordem nas direções horizontal, vertical e diagonal da ima-

gem  $I$  no ponto  $x$  como pode ser visto na Equação 3.9.

$$\frac{\partial^2}{\partial x^2} g(\sigma) \quad (3.9)$$

Para otimaizar o custo computacional, o SURF utiliza um conjunto de filtros de caixa  $9 \times 9$  para a aproximação da derivada Gaussiana de segunda ordem com  $\sigma = 1.2$ , isto reduz o tempo de processamento e pode ser analisado com grande rapidez com a utilização de imagens integrais. Na Figura 3.4, da esquerda para a direita, pode-se notar a derivada parcial Gaussiana de segunda ordem discreta nas direções  $y - (L_{yy})$  e  $xy - L_{xy}$ , respectivamente. As duas imagens da direita são a aproximação da derivada parcial Gaussiana de segunda ordem em  $yD_{yy}$  e na direção  $xy D_{xy}$ . As regiões cinzas são iguais a zero.

Figura 3.4: Matiz Hessiana na direção  $y$  e  $xy$  e aproximação dos filtros de caixa.

Assim pode-se calcular o determinante:

$$\det(H_{approx}) = D_{xx}D_{yy} - (\omega D_{xy})^2 \quad (3.10)$$

Onde  $\omega$  é a medida para a conservação de energia entre os kernels Gaussianos e a aproximação dos kernels Gaussianos.

### *Espaço de Escalas e Oitavas*

Nomalmente a invariância a 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 proceso 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, como acontece na pirâmide de escalas, o SURF aumenta o tamanho do filtro que será convolucionado com a imagem. A mudança na escala é exponencial, assim para não perder informações intermediárias entre as escalas, o espaço de escalas é dividido em oitavas. Uma oitava representa uma série de mapas de resposta do filtro obtidos pela convolução de uma mesma imagem de entrada com um incremento do tamanho do filtro. Vale a pena lembrar que este processo de aumento do filtro, pode ocasionar um erro quando se trabalha com imagens muito pequenas, visto que o filtro se torna maior que a imagem e assim nenhuma convolução é



feita, não encontrando nenhum ponto de interesse. A construção do espaço de escalas começa com filtros de caixa de  $9 \times 9$ , seguido de  $15 \times 15$  e  $21 \times 21$ , como pode ser visto na Figura 3.5.

Figura 3.5: Representação dos tamanhos do filtro de caixa segundo a escala. Cada um é dividida em oitavas, estas oitavas são utilizadas para preservar as informações entre as escalas, visto que a escala cresce exponencialmente.

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 escala vizinha não podem ser desconsideradas, sendo necessário a dos vizinhos do ponto analisado, da primeira escala acima e da primeira escala abaixo, quando um ponto máximo é encontrado, todos os outros valores são suprimidos. Assim, é feita uma localização dos pontos máximos de variação da imagem no espaço de escala e no espaço da imagem onde são obtidos a localização dos pontos de interesse e a escala que este foi obtido.

#### *Descrição dos Pontos de Interesse*

O SURF utiliza a soma da resposta das *Haar wavelets* para descrever as características do ponto de interesse, onde é feita a invariância de rotação. Os filtros das *Haar wavelets* são utilizados para calcular as repostas nas direções  $x$  e  $y$ . Para extrair os descritores, primeiro é construída uma circunferência centralizada na região do ponto de interesse que é orientada ao longo da orientação selecionada pelo método especial de seleção que é descrito em Tuytelaars and Mikolajczyk [2008].

A primeira imagem da Figura 3.6 ilustra o detector de pontos de interesse em um campo de girassóis, onde é representada a natureza das características dos detectores baseados na matriz Hessiana. A imagem central, demonstra os filtros da *Haar wavelets* utilizadas pelo SURF, e finalmente a terceira imagem da Figura 3.6 mostra o tamanho da janela do descritor em diferentes escalas.

Figura 3.6: Matiz Hessiana na direção  $y$  e  $xy$  e aproximação dos filtros de caixa.

Com o quadro definido, é realizada uma divisão no quadro que resulta em um quadro de  $4 \times 4$  sub-regiões, que pode ser visto na Figura 3.7. Isto preserva as principais informações espaciais. Para cada sub-região, é calculada

as respostas da *Haar wavelet* com pontos de  $5 \times 5$  equivalentes ao espaço dos pontos analisados. É definido  $d_x$  como a resposta da *Haar wavelet* na direção horizontal e  $d_y$  é definido como a resposta da *Haar wavelet* na direção vertical. Para cada sub-região, o  $d_x$  e  $d_y$  são calculados e estes são medidos pela Gaussiana centralizada no ponto de interesse, o que aumenta a robustez contra deformações geométricas e erros de localização.

Figura 3.7: Quadro orientado de  $4 \times 4$  sub-regiões em torno do ponto de interesse (esquerda) e soma das resposta da *Haar wavelets*.

As respostas da *Haar wavelet*  $d_x$  e  $d_y$  são somadas para cada sub-região e formam o primeiro conjunto de entradas no vetor de características. Para se obter informações referentes a polaridade da mudanças na intensidade, também é extraída a soma dos valores absolutos das respostas  $|d_x|$  e  $|d_y|$ .

Após esse processo, cada sub-região obtêm um vetor de descrição  $v$  com quatro dimensões que define sua estrutura de intensidade, onde:

$$v = (\sum d_x, \sum d_y, \sum |d_x|, \sum |d_y|) \quad (3.11)$$

Isto resulta em um vetor de descrição para todas as  $4 \times 4$  sub-regiões de tamanho 64. A resposta da *Haar wavelet* são invariantes a influência de iluminação. A invariância ao contraste (um fator de escala) pode ser obtida transformando o descritor em um vetor unitário.

A Figura 3.8 ilustra as propriedades do descritor em três imagens 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.

Figura 3.8: As entradas do descritor de cada sub-região representam a natureza do padrão de intensidade da imagem. Esquerda: Quando a 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.. Caso a intensidade é gradualmente aumentada na direção  $x$ , os dois valores de  $\sum d_x$ , e  $\sum |d_x|$  são altos.

### 3.1.3 Casamento de modelos

A idéia básica por trás do casamento de modelos é que existe um modelo (o 'template') da região de interesse buscada que possui alta similaridades com

outras imagens com estas características. Dois parâmetros desempenham papel importante dentro do casamento de modelos, sendo eles, o modelo ou um conjunto de modelos, e a medida de similaridade. Nas seções seguintes, diferentes definições de medidas de similaridade, diferentes representações da vista icônica e invariância em orientação e escala serão apresentados.

Tendo um modelo denotada por  $T$  e a intensidade de um determinado pixel deste modelo é denotado  $T(u, v)$ . Analogicamente,  $I$  denota a imagem a ser analisada e  $I(i, j)$  a intensidade do pixel na posição  $(i, j)$  da imagem. Além disso, tendo que  $S(i, j)$  é a similaridade entre o modelo  $T$  e o trecho da imagem  $I_T$  na posição  $(i, j)$  e existindo uma definição das medidas de similaridade do modelo na imagem buscada, é estimada a posição na matriz de similaridade onde o valor da medida representa o máximo na matriz. Esta posição é encontrada segundo a Equação 3.12.

$$(\hat{i}, \hat{j}) = \arg \max_{i, j} S(i, j) \quad (3.12)$$

### *Medida de Similaridade*

Nesta seção serão introduzidas três diferentes definições de medida de similaridade: (i) a correlação cruzada normalizada, (ii) correlação cruzada modificada, e (iii) o erro médio quadrático.

*Correlação Cruzada Normalizada* Correlação cruzada é uma medida de similaridade que já foi utilizada por Baron [1981] para o reconhecimento de faces. Para redimensionar a distribuição de energia do modelo e da imagem, com intuito de combinar às suas médias e variantes, uma versão normalizada foi proposta (Brunelli and Poggio [1993]). Esta correlação cruzada normalizada é definida por:

$$S(i, j) = \frac{\langle T x I_T \rangle - \langle T \rangle \langle I_T \rangle}{\sigma(T) \sigma(I_T)} \quad (3.13)$$

Onde,  $I_T$  é um trecho da imagem  $I$  na posição  $(i, j)$  que deve ser comparada com  $T$ ,  $\langle \rangle$  é o operador de média, assim

$$\langle T \rangle = \frac{1}{n} \sum_{u, v} T(u, v) \quad (3.14)$$

e  $\langle x \rangle$  representa o produto de pixel-a-pixel:

$$\langle T x I_T \rangle = \frac{1}{n} \sum_{u, v} T(u, v) I(i + u, j + v) \quad (3.15)$$

$\sigma$  é o desvio padrão sobre a área de correspondência:

$$\sigma^2(T) = \frac{1}{n-1} \left( \sum_{u,v} (T(u,v))^2 - \langle T \rangle^2 \right) \quad (3.16)$$

*Coeficiente de Correlação Cruzada Modificada* Para reduzir a influência de pequenas mudanças na forma da região de interesse, Brunelli and Poggio [1993] introduziram o coeficiente de correlação modificado:

$$S(i, j) = \sum_{u,v} (T(u,v)) I(i+u+\hat{k}, j+v+\hat{l}) \quad (3.17)$$

Ao invés de utilizar o produto de pixel-a-pixel do modelo e do trecho da imagem que possuem correspondência, o valor de intensidade do pixel do modelo é multiplicado pelo pixel com maior correspondência em torno de uma pequena janela de pixel de correspondência no trecho da imagem, por exemplo, o pixel com deslocamento  $(\hat{k}, \hat{l})$  que satisfaça a condição:

$$(\hat{k}, \hat{l}) = \operatorname{argmin}_{k,l} |I(i+u+k, j+v+l) - T(u,v)| \quad (3.18)$$

Este coeficiente permite pequenas deformações locais no cálculo da medida de similaridade. Esta é a forma normalizada do Equação 3.13.

*Erro Médio Quadrático* Já é conhecido que a correlação cruzada possui alto custo computacionalmente. Uma alternativa para a medida de similaridade com baixa carga computacional é o erro médio quadrático definido por:

$$S(i, j) = \frac{1}{n} \sum_{u,v} (T(u,v) - I(i+u, j+v))^2 \quad (3.19)$$

Nota-se que se for aplicada a Equação 3.12 esta medida de similaridade deve ser negativa.

### *Normalização de Intensidade*

Todas as medidas de similaridades apresentadas são sensíveis a mudança de iluminação. Brunelli and Poggio [1993] sugeriram diferentes caminhos para o pré-processamento das imagens para se livrar deste efeito que pode causar confusão. Em seus experimentos eles compararam quatro diferentes normalizações de intensidade: (i) sem pré-processamento, por exemplo, as intensidades simples de  $I$ , (ii) normalização utilizando razão do valor local sobre a média do brilho, por exemplo,  $I_T^N = T_t / \langle I_T \rangle$  (da mesma forma para a imagem do modelo), (iii) intensidade do gradiente da imagem  $I_T^N = D(I_T) = |\delta_x I_T| + |\delta_y I_T|$ , e (iv) a Laplaciana da intensidade  $I_T^N = DD(I_T) = (\delta_{xx} I_T + \delta_{yy} I_T)$ . Eles informaram

que a normalização baseada no gradiente proporcione o melhor desempenho no reconhecimento.

### *Invariância de Rotação e Escala*

Claramente, todas as medidas de similaridade discutidas sofrem com a diferença entre tamanho e orientação entre o modelo e a região de interesse da imagem a original. Para superar estas desvantagens, o modelo pode ser modificado a fim de melhorar a correspondência com a região de interesse da imagem original, por exemplo:

$$T^m = RST \quad (3.20)$$

Onde  $R$  e  $S$  representam a matriz de rotação e escala, respectivamente. Agora, para encontrar a posição da região de interesse na imagem, onde deve-se encontrar a similaridade máxima  $S(i, j)$  sobre todas as possíveis rotações e escalas.

#### *3.1.4 Casamento de Pontos de Interesse*

Como o casamento de modelos será aplicado no resultado obtido pela aplicação do algoritmo de extração de pontos de interesse. O casamento de modelos 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. [2008] apresentou o SURF, o mesmo utiliza dois modelos de casamento de pontos de interesse, um baseado em um limiar de similaridade, e outra baseado na quantidade de vizinhos mais próximos.

Já o casamento de modelos dos pontos de interesse obtidos pelo SIFT, são comumente obtidos pelo cálculo da distância Euclidiana dos descritores de cada ponto de interesse. Este algoritmo utiliza a taxa da distancia do vizinhos mais próximos, onde o ponto é definido como casamento se a distância entre o ponto de interesse for menor do que 0.6 a distância a seu vizinho mais próximo, esta metodologia minimiza o número de falsos positivos Mikolajczyk and Schmid [2005b].

Para encontrar um casamento de um único ponto de interesse, este algoritmo deve calcular  $n$ , sendo  $n$  o tamanho do descritor do ponto de interesse, multiplicações, adições e subtrações de cada ponto de interesse em potencial da base de dados. Isso se tornar um bloqueante para repositórios muito grande. Para resolver isso, foram propostos alguns com a aproximação da metodologia do vizinho mais próximo, porém mais rápidos, como o *Best-bin First* proposto por Lowe [2004], que acelera significativamente o tempo de casamento.

Esses algoritmos serão discutidos na próxima seção.

### *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.

Deste métodos, o mais utilizado foi proposto por J.H. Friedman and Finkel. [1977], este método envolve a construção de uma *kd-tree*. Esta *kd-tree* (para uma árvore de *k-dimensões*) é um esquema binário de um espaço particionado que separa os dados, onde ao longo da primeira dimensão é mostrado a maior variância, então, recursivamente, ao longo da dimensão com a segunda maior variância, e assim por diante até os dados forem divididos ao longo de cada eixo. Caso mais ramificações sejam necessárias, a divisão é iniciada novamente ao longo do eixo com maior variância. 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 maior que 10. Para os descritores de ponto e 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 do vizinhos mais próximo, uma correspondência aproximada já é o suficiente. Para este fim, Beis and Lowe. [1997] utilizam uma fila de prioridades para acelerar a busca na *kd-tree* visitando os nós na ordem da distância dos pontos em questão. Esse algoritmo *Best-BinFirst* (BBF), controla o grau de aproximação um limite no número de nós que serão consultados após encontrar a melhor correspondência o que reduz o tempo de busca na árvore.

M. Muja [2009] desenvolveram uma variação do *k-meanstree* análoga à aproximação do BBF para a *kd-tree*. A *k-meanstree* clássica Fukunaga and Narendra. [1975] 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 o mesmo em cada grupo de *k*. A recursão é parada quando o número de ponto no grupo é menor que *k*. Já M. Muja [2009] propõe executar primeiramente um única travessia na árvore enquanto se atualiza a fila de prioridades de todos os ramos não explorados em nó ao longo da travessia. Então o algoritmo percorre os ramos não explorados conforme a

ordem de prioridades segundo a distância do ponto corrente (essa distância é a média dos valores do conjuntos de dados de cada ramo). O limite de busca é definido antes dos ramos serem percorridos, e caso esse limite seja ultrapassado, a melhor correspondência será eleita.

A *FastLibraryforApproximateNearest – Neighbours* (FLANN) M. Muja [2009], é uma biblioteca de algoritmos de busca aproximadas baseados no vizinhos mais próximos, é um software de disponibilidade pública que irá escolher melhor algoritmo a ser utilizado dado um conjunto de dados e precisão desejada. Esta biblioteca será utilizado no desenvolvimento da proposta deste trabalho.





---

# Metodologia

---

A seguir, será apresentada a metodologia proposta para a realização de cada um dos objetivos deste plano.

## *4.1 Aprofundamento e atualização da revisão de literatura*

Através de consultas aos principais portais de periódicos mundiais, como IEEE Xplore, ACM DL, Science Direct e Scopus, serão identificados artigos com trabalhos correlatos nas áreas de Extração de Atributos de Pontos de Interesse, Casamento de Modelos, utilização de VANTs na Agricultura, e Pragas da Soja. Estes artigos serão revisados para complementar o texto apresentado neste plano de trabalho.

## *4.2 Construção de um banco de imagens de Soja*

Para ajustar os parâmetros do módulo que serão desenvolvido e também para testar seu desempenho, conforme serão descrito na seção 4.4., um banco de imagens será construído. O banco conterá cerca de 100 imagens para cada classe do problema. As classes, neste caso, correspondem às doenças relacionadas com a soja. As imagens serão capturadas nas plantações de soja utilizando um VANT, com quatro hélices com uma câmera GoPro acoplada, devendo cada captura de imagens ocorrer em mesmo horário conforme a iluminação ideal. Com apoio de especialistas, cada imagem será anotada, constituindo assim um conjunto de referência para análise de desempenho. O

banco também será disponibilizado através do website do projeto HERBIVIC. Exemplos de imagens similares as que serão utilizadas neste plano podem ser vistos na Figura 4.1.



Figura 4.1: Conjunto de imagens das classes

### 4.3 *Desenvolvimento do módulo de Classificação de Soja*

O módulo será desenvolvido em Linguagem C++ tendo como apoio o pacote para Visão Computacional OpenCV (BRADSKI, 2000) versão 2.4. Serão seguidas as regras definidas pelo grupo de pesquisa e desenvolvimento INOVISAO

disponíveis no site do grupo . A metodologia de desenvolvimento de software do INOVISAO tem como base o SCRUM (SIMS; JOHNSON, 2011) com todo o material produzido sob controle de versão utilizando a ferramenta SubVersion . O padrão de documentação de código é baseado no JavaDoc (mesmo para programas em C e C++).

#### *4.4 Validação do módulo de Classificação de Soja*

O algoritmo baseado em extratores de pontos de interesse e casamento de modelos será comparado com os algoritmos de classificação baseados em aprendizagem de máquina utilizando o banco de imagens descrito na seção 4.2. Como técnica de amostragem será adotada a validação cruzada de 10 dobras com 10 repetições disponível no software Weka na versão X.Y (HALL et al., 2009). Para cada algoritmo testado, serão calculados os desempenhos médios referentes às métricas recall, precision, f-score e percent correct. Para identificar se os algoritmos testados diferem estatisticamente em relação ao desempenho, considerando-se cada uma das métricas, será utilizado o teste não-paramétrico proposto por Friedman (1940) e disponível no software estatístico R , versão 3.1, com cada bloco correspondendo a uma das classes do problema. Caso, utilizando-se um nível de significância de 95% ( $p\text{-value} < 0.05$ ), seja constatada diferença, um teste post-hoc será realizado e os box-plots resultantes analisados. 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 (1999).

#### *4.5 Registro e divulgação de resultados*

Serão produzidos um resumo, um relatório final e no mínimo um artigo científico com resultados finais deste plano. O artigo será submetido para um evento ou revista da área de Visão Computacional e Biotecnologia. Será utilizada a ferramenta Latex para produção dos textos visando facilitar a adaptação dos mesmos para as regras utilizadas em periódicos e eventos da área da computação e que geralmente disponibilizam modelos em Latex.



---

# Cronograma

---

---

Tabela 5.1: Cronograma

Atividade	Trimestre de 2014				Trimestre de 2015			
	01	02	03	04	01	02	03	04
Atividade 1.1: Identificação de trabalhos correlatos	X	X	X					
Atividade 1.2: Revisão dos trabalhos correlatos	X	X	X					
Atividade 2.1: Busca de imagens exemplo para montagem de banco exemplo	X	X	X					
Atividade 2.2: Preparação do equipamento de coleta		X	X	X	X			
Atividade 2.3: Coleta das imagens no campo			X	X	X			
Atividade 2.4: Catalogamento e armazenamento das imagens coletadas			X	X	X			
Atividade 3.1: Desenvolvimento de algoritmo para extração dos atributos e classificação das imagens		X	X	X	X			
Atividade 3.2: Realização dos experimentos			X	X	X	X		
Atividade 4.1: Validação dos experimentos realizados				X	X	X		
Atividade 4.2: Correções e ajustes encontrado					X	X	X	
Atividade 5.1: Preparação do relatório final e resumo	X	X	X	X	X	X	X	
Atividade 5.2: Desenvolvimento do artigo e divulgação dos resultados						X	X	X

# Referências Bibliográficas

---

- R. Baron. Mechanisms of human facial recognition. *International Journal of Man-Machine Studies*, 15:137–178, 1981. Citado na página 15.
- 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. Citado nas páginas 7, 11, e 17.
- 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. Citado na página 18.
- R. Brunelli and T. Poggio. Face recognition: Features versus templates. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 15:1042 – 1052, 1993. Citado nas páginas 15 e 16.
- N. Dalal and B. Triggs. Histograms of oriented gradients for human detection. *In Computer Vision and Pattern Recognition (CVPR)*, pages 886–893, 2005. Citado na página 7.
- K. Fukunaga and P.M. Narendra. A branch and bound algorithm for computing k-nearest neighbours. *IEEE Trans. Comput.*, pages 750–753, 1975. Citado na página 18.
- 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. Citado na página 2.
- J.L. Bentley J.H. Friedman and R.A Finkel. An algorithm for finding best matches in logarithmic expected time. *ACM Trans. Math. Softw.*, 3:209–226, 1977. Citado na página 18.

- Patricia Fabretti Kreycki and José Otávio M. Menten. Limitadoras de produtividade. Technical Report 167, Esalq/USP, 2013. Citado na página 2.
- 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. Citado na página 2.
- D. Lowe. Object recognition from local scale-invariant features. *In International Conference on Computer Vision (ICCV)*, pages 1150–1157, 1999. Citado nas páginas 8, 9, e 10.
- D. Lowe. Distinctive image features from scale-invariant keypoints. *International Journal of Computer Vision (IJCV)*, 60:91–110, 2004. Citado nas páginas 7, 8, e 17.
- D. Lowe. M. Muja. Fast approximate nearest neighbors with automatic algorithm configuration. *International Conference on Computer Vision Theory and Applications (VISAPP'09)*, 2009. Citado nas páginas 18 e 19.
- Embrapa Soja. Consórcio antiferrugem - parceria público-privado o combate à ferrugem asiática de soja. Technical report, Embrapa, 2014. URL <http://www.consorcioantiferrugem.net/portal/>. Citado na página 1.
- Secretaria de Políticas Agrícola. Plano agrícola e pecuário 2013/2014. Technical report, Ministério da Agricultura, Pecuária e Abastecimento, 2013. Citado na página 1.
- K. Mikolajczyk and C. Schmid. A performance evaluation of local descriptors. *IEEE Transactions on Pattern Analysis and Machine Intelligence (PAMI)*, 27(10):1615–1630, 2005a. Citado na página 7.
- Krystian Mikolajczyk and Cordelia Schmid. A performance evaluation of local descriptors. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 27(10):1615–1630, 2005b. URL <http://lear.inrialpes.fr/pubs/2005/MS05>. Citado na página 17.
- 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. Citado na página 3.



- 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. Citado na página 2.
- 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*, 10:01–18, 2010. Citado na página 3.
- N. M. Silva. Como utilizar imagens aéreas na agricultura de precisão?, 2013. URL [Disponível em http://www.agrimensordofuturo.com/post.cfm?id=42](http://www.agrimensordofuturo.com/post.cfm?id=42). Acesso em 19/05/2014. Citado na página 3.
- T. Theis and J. Tomkin. Sustainability: A comprehensive foundation, 2012. URL [Disponível em http://cnx.org/content/col11325/latest/](http://cnx.org/content/col11325/latest/). Acesso em 21/05/2014. Citado na página 2.
- 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. Citado na página 7.
- T. Tuytelaars and K. Mikolajczyk. Local invariant feature detectors: A survey. *Foundations and Trends in Computer Graphics and Vision*, 3:177–280, 2008. Citado nas páginas 7 e 13.