

# PLANODETRABALHO

**Título do Projeto:** Visão computacional aplicada na avaliação automática do efeito da desfolha na cultura da soja

**Título do Plano de trabalho:** Segmentação por Aprendizagem Supervisionada para Inspeção de Folhas de Soja em Imagens de Veículos Aéreos Não Tripulados

**Orientador:** Hemerson Pistori ([pistori@ucdb.br](mailto:pistori@ucdb.br))

**Orientanda:** Gercina Gonçalves da Silva. **RA:** 811141

**Curso:** Doutorado no Programa de Pós-graduação Stricto Sensu em Ciências Ambientais e Sustentabilidade Agropecuária **Semestre:** IIIº Semestre.

## **Resumo**

*Dada a importância da soja para o estado de Mato Grosso do Sul e sua relevância na pauta exportadora, este trabalho tem como objetivo a validação de um programa de computador, capaz de identificar danos na plantação de soja, através de um sistema de Visão computacional, utilizando-se de imagens capturadas por VANTs. O intuito é a redução de perdas de investimentos na lavoura causadas por doenças ou pragas.*

## **1. Antecedentes e Justificativa**

De acordo com o MINISTÉRIO DA AGRICULTURA, PECUÁRIA E ABASTECIMENTO- MAPA (2012), o Brasil, no período recente, tem apresentado um quadro de crescimento econômico e social marcado pela distribuição de renda e inclusão social, tendo o agronegócio como um dos pilares desse crescimento, destacando-se a produção brasileira do complexo soja, complexo sucroalcooleiro, carnes e café.

Entre as safras de 2005/2006 e 2010/2011, a produção brasileira de grãos aumentou 33%, e os quatro principais setores exportadores, complexo soja, complexo sucroalcooleiro, carnes e café, que participavam com 78,7% das exportações totais de 2006, ampliaram essa concentração para 79,4% em 2011 (MAPA, 2012).

De acordo com o MAPA (2013) a expectativa para o fechamento do ano de 2013 é de uma safra recorde em grãos, estimada entre 184 e 186 milhões

de toneladas. Em 2013, no Brasil, a área cultivada foi estimada em 52,99 milhões de hectares e desse total, a cultura da soja ocupa 52,2% (27,65 milhões de hectares), seguida do milho com 29,1% (15,41 milhões de hectares) – CONAB (2013).

A região Centro-Oeste do Brasil é responsável por 46,6% da produção nacional de soja (MAPA 2013). A expectativa da COMPANHIA NACIONAL DE ABASTECIMENTO – CONAB (2013) para essa região, na temporada 2012/2013, é que a mesma cultive 12,778 milhões de hectares de soja, superando os 11,495 milhões de hectares cultivados na safra anterior.

A soja é uma planta herbácea, incluída na classe Dicotyledoneae, ordem Rosales, família Leguminosae, subfamília das Papilionoideae, gênero *Glycine* L.. Durante todo o ciclo da planta são distinguidos quatro tipos de folha: cotiledonares, folhas primárias ou simples, folhas trifolioladas ou compostas e prófilos simples. Sua cor, na maioria dos cultivares, é verde pálida e, em outras, verde escura (CISOJA, 2013).

Para Yorinori (1993) a soja é uma das plantas mais fáceis de serem cultivadas, porém, a exploração econômica do seu potencial de rendimento (superior a 4.000 kg/ha) dificilmente é alcançada por falta de manejo adequado. Entre os principais fatores limitantes do rendimento estão as doenças que, em geral, são de difícil controle. Para o autor, o número de doenças causadas por bactérias, fungos, nematóides e vírus, continua aumentando a cada safra com a expansão da cultura para novos ambientes. A importância de cada doença varia de ano para ano e de região para região, dependendo das variedades predominantes e da condição climática de cada safra.

Inicialmente a soja se expandiu no Brasil com sanidade, todavia, após alguns anos de cultivo comercial surgiram doenças que passaram então, a serem fatores limitantes ao aumento e estabilidade do rendimento (YORINORI, 2000).

No Brasil as primeiras e mais comuns doenças da soja foram o míldio, a mancha púrpura e crestamento foliar de *Cercospora*, a mancha parda e a antracnose. Essas, provavelmente, vieram nas sementes introduzidas pelos imigrantes japoneses, que cultivaram a soja para consumo caseiro. Atualmente, as principais doenças da cultura da soja são: necrose da haste da soja,

mancha olho-de-rã, oídio, ferrugem asiática da soja, cancro-da-haste, antracnose, nanismo amarelo da soja entre outras (EMBRAPA, 2011).

O processo de modernização na agricultura brasileira se iniciou a partir de meados da década de 1960, com a Revolução Verde. Atualmente a agricultura passa por uma reformulação, onde os procedimentos repensados focam o controle de pragas e doenças agrícolas (ZARBIN, 2009). De acordo com o autor, em países desenvolvidos as perdas anuais na produção devido ao ataque de insetos são de 14% e de 38% nos países em desenvolvimento.

Para Herwitz et. al. (2004) a agricultura tem se tornado uma indústria onde cada vez mais se faz importante o conhecimento em resposta a questões ambientais e econômicas. Abordagens agrícolas baseadas no conhecimento são destinadas a aumentar a eficiência da agricultura, melhorar a rentabilidade, reduzir os impactos ambientais, e devem impulsionar ainda mais a inovação tecnológica. Logo, o segmento do agronegócio é um beneficiário potencial de inovações tecnológicas, como o sensoriamento remoto e a utilização de Veículos Aéreos Não Tripulados – VANTs.

Dado esse direcionamento, essa pesquisa faz parte dos projetos do INOVISÃO, 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 INOVISÃO 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.

## **2. Objetivos**

### **2.1 Geral**

Validar um programa de computador, capaz de identificar danos na plantação de soja, através de um sistema de Visão computacional utilizando

imagens capturadas por VANTs com o intuito de reduzir as perdas de investimentos na lavoura causadas por doenças ou pragas.

## **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
- Construção de um banco de imagens de lavoura de soja a partir de Veículos Aéreos Não Tripulados
- Implementação do módulo para segmentação por aprendizagem supervisionada para inspeção de folhas de soja em imagens multi-espectrais
- Validação do módulo
- Registro e divulgação de resultados

## **3 Revisão da Literatura**

Afim de atingir os objetivos supra propostos, esse trabalho se aprofunda na revisão de literatura iniciado com estudo acerca da Visão Computacional abordando a segmentação de imagens coloridas e a aprendizagem automática. Posteriormente a revisão define VANTs, discorrendo sobre sua utilização na agricultura; e conclui com as pragas da soja.

### **3.1 Visão Computacional**

De acordo com Milano e Honorato (2010) a visão computacional é uma ciência recente. Ela é responsável pela visão de uma máquina, pela forma como um computador enxerga o meio à sua volta, extraindo informações significativas a partir de imagens capturadas por câmeras de vídeo, sensores, scanners, entre outros dispositivos. De acordo com os autores estas

informações permitem reconhecer, manipular e pensar sobre os objetos que compõem uma imagem.

Para Molz (2001) desde o início da computação, a visão tem sido objeto de pesquisa por se tratar de um dos mais notáveis sistemas de percepção do ser humano. Assim, de acordo com o autor, o desenvolvimento de técnicas de dispositivos que possam estender essa sua capacidade e sensibilidade ainda mais, é motivado pela capacidade humana de processar e interpretar grandes quantidades de dados de natureza visual.

Para Szeliski (2010) a distinção da visão de computador a partir do campo já existente de processamento digital de imagens era um desejo de recuperar a estrutura tridimensional do mundo a partir de imagens e usar isto como um trampolim no que diz respeito ao entendimento dos cenários.

A visão computacional busca emular a visão humana, e tem como entrada uma imagem, e como saída, uma interpretação parcial ou total da imagem como um todo (MARENGONI e STRINGHINI, 2009). Dessa forma, o problema que norteia a visão computacional (ou visão de computador) é a extração de um conjunto de informações, modelos ou equações matemáticas, a partir de imagens. Essas informações, modelos ou equações matemáticas serão utilizadas para a tomada de decisão.

A forma como o ser humano identifica uma cena e como uma imagem digital é interpretada diferem-se entre si, pois o primeiro é capaz de perceber a estrutura tridimensional do mundo que o rodeia com aparente facilidade (SZELISKI, 2010) enquanto que o segundo identifica uma imagem a partir de atributos que devem ser extraídos da imagem, e que estão relacionados entre si (RUDEK et al., 2008).

A visão computacional tem a pretensão de reproduzir a capacidade de reconhecimento de imagens a partir de diversas técnicas computacionais, partindo de imagens e chegando a modelos matemáticos. Para tanto, pesquisadores nessa área desenvolveram técnicas matemáticas objetivando a recuperação da forma tridimensional, bem como da aparência de objetos em imagens (SZELISKI, 2010).

Com isso, utilizando-se de milhares de fotografias que se sobrepõem parcialmente, é possível calcular com precisão um modelo 3D parcial de um ambiente, a partir da utilização dessas técnicas. Todavia, para Szeliski (2010)

apesar de todo avanço na área de visão computacional, a visão é algo complexo, sendo caracterizado como um problema inverso. De acordo com o autor, a visão computacional busca descrever o mundo que vemos em uma ou mais imagens e reconstruir suas propriedades.

Na visão computacional, as soluções e pesquisas desenvolvidas para aplicações específicas foram obtidas por métodos de tentativas e erros, o que faz da mesma uma ciência experimental (MOLZ, 2001).

De acordo com Szeliski (2010), no início da década de 1970, a visão de computador era tida como um componente de percepção visual, participando de uma agenda ambiciosa que tinha por objetivo imitar a inteligência humana, dotando robôs de comportamentos inteligentes. Já na década de 1980, o foco e atenção centravam-se em técnicas matemáticas mais sofisticadas para a análise quantidade de imagens e cenários.

Na década de 1990, diversos dos tópicos de pesquisas da década anterior continuaram a ser explorados, e alguns deles tornaram-se significativamente mais ativo. Um dos trabalhos iniciados na década de 1980 que tratava do uso de medições detalhadas de cor e intensidade, combinados com modelos físicos precisos de cenários e formação de imagens coloridas veio a instituir seu próprio subcampo conhecido como visão com base na física (SZELISKI, 2010). Ainda nessa década, desenvolveu-se o notável estudo no campo da visão de computador: o aumento da interação com computação gráfica especialmente na área interdisciplinar de modelagem e renderização baseada em imagem.

A década dos anos 2000 continuou com um aprofundamento da interação entre os campos de visão e gráficos (SZELISKI, 2010). Para o autor, a tendência final é a aplicação de técnicas de aprendizado de máquina sofisticadas para problemas de visão de computador.

Atualmente o uso da visão computacional se dá em diversas áreas, como por exemplo: reconhecimento óptico de caracteres, fotogrametria, imagens médicas, segurança automotiva, jogo de vídeo e estabilização, captura de movimento, vigilância, reconhecimento de impressão digital e biometria, detecção de face, autenticação visual entre outros (SZELISKI, 2010).

Para Milano e Honorato (2010) a visão computacional, de forma geral, resolve problemas demandados por outras áreas de pesquisa. De acordo com

os autores, os sistemas de visão computacional basicamente envolvem reconhecimento de objetos em imagens e transformações dos objetos em informações que são processadas e posteriormente utilizadas em algum sistema.

Logo, a visão computacional propicia ao computador informações precisas extraídas de imagens e vídeos, levando o computador a executar tarefas inteligentes, imitando e até mesmo aproximando-se da inteligência humana. As principais etapas de um sistema de visão computacional são: aquisição de imagens, pré-processamento, extração de atributos ou características, Detecção e segmentação, Processamento de alto nível (MILANO e HONORATO, 2010).

Aquisição de Imagem é de acordo com Milano e Honorato (2010) o primeiro passo no sistema de visão computacional, dando-se a partir de sensores de câmeras, onde os pixels de cada imagem obtida indicam coordenadas de luz e propriedades físicas. Para os autores, a imagem pode ser bidimensional, tridimensional ou uma seqüência de imagens.

O pré-processamento ocorre antes da obtenção das informações de uma imagem, aplicando então, métodos que facilitam a identificação de um objeto. O próximo passo no sistema de visão computacional é a extração de características, onde verifica-se as características matemáticas que compõem uma imagem (MILANO e HONORATO, 2010).

A detecção e segmentação é o processo que é realizado com o objetivo de destacar regiões relevantes da imagem, segmentado-as para um processamento posterior. Na etapa de segmentação, busca-se um particionamento da imagem em regiões de forma a separar elementos de interesse, para o problema a ser resolvido, de elementos que são irrelevantes para o problema. Em alguns casos, em problemas que envolvem contagem ou reconhecimento de múltiplos objetos, a segmentação, além de separar os elementos irrelevantes, separa os objetos de interesse em regiões distintas.

O último passo refere-se ao processamento de alto nível que é um processo que inclui validação dos dados obtidos, estimativa de parâmetros sobre a imagem e classificação dos objetos obtidos em diferentes categorias (MILANO e HONORATO, 2010).

### **3.1.1 Segmentação de imagens coloridas**

O primeiro passo na análise de imagem é, geralmente, a segmentação. Segmentar, em processamento digital de imagem, significa subdividir uma imagem em suas partes ou objetos constituintes (NEVES e PELAES, 2001). Entre os grupos importantes de técnicas que podem ser aplicadas para segmentar imagens destacam-se a segmentação por limiarização, segmentação por agrupamento e segmentação por ajuste de modelos.

Marengoni e Stringhini (2009) afirmam que a segmentação dá-se através da partição de uma imagem em regiões ou objetos distintos. Esse processo é geralmente guiado por características do objeto ou região como a cor ou a proximidade. De acordo com os autores, na segmentação de imagens com distâncias diferentes, se a resolução das imagens for diferente, o tratamento utilizado no processo de segmentação pode ser diferente também.

A segmentação é baseada em duas características dos tons de cinza de uma imagem: a descontinuidade e a similaridade. O método da descontinuidade baseia-se na mudança abrupta dos valores de cinza e o método da similaridade fundamenta-se pela agregação de pixels em função da sua semelhança com os pixels vizinhos (NASCIMENTO e ALMEIDA FILHO, 1996; SILVA, 2009).

Aboud Neta et al (2009) afirmam que em imagens multiespectrais, o processo de segmentação pode utilizar a análise dos valores digitais dos pixels nas diversas bandas disponíveis.

Padilha (2005) afirma que a segmentação pode ser considerada como um processo de classificação de pixels. Se as classes e as suas probabilidades, bem como as propriedades (p.ex., brilho) e as suas probabilidades por classes, forem conhecidas a priori, a segmentação reduz-se a um problema clássico de decisão estatística. Quando as classes não são conhecidas pode recorrer-se a técnicas de agrupamento (clustering).

Para Nascimento e Almeida Filho (1996) a técnica de segmentação baseada no método de crescimento de regiões é uma das mais utilizadas, pois permite extrair um conjunto mais rico de atributos e de selecionar amostras mais representativas de cada classe.



A segmentação de imagens tem basicamente dois objetivos: (1º) decompor a imagem em partes para posterior análise; (2º) realizar uma mudança de representação. O resultado final esperado de um processo de segmentação é um número finito de regiões homogêneas, que individualizam as diferentes regiões contidas numa imagem. Dessa forma, a imagem seria formada por um conjunto de regiões, conectadas pelas suas bordas e que não se sobrepõe, de tal forma que cada pixel da imagem pertence unicamente a uma determinada região (SALDANHA e FREITAS, 2008).

Para Souza e Guimarães (2012) a utilização das cores reais das imagens, colabora no sentido de que seja possível expressar melhor a descrição e identificação dos objetos contidos em uma imagem, com base em sua característica de cor. Todavia as imagens coloridas podem possuir milhares de cores diferentes. Assim, a análise e identificação dos objetos que ela contém podem ficar prejudicada.

Ruiz et al (2007) afirmam que trabalhar com imagens coloridas, implica em escolher o sistema de cores mais adequado ou uma combinação dos mesmos. Para os autores o uso de diversos modelos de cores é uma tarefa complexa para os algoritmos de visão computacional, pois o espaço de cor pode ser interpretado e modelado de diferentes formas. As imagens em cores requerem um processamento mais intenso, devido ao espaço de representação utilizado ser, na maioria das vezes, tridimensional (BONVENTI JUNIOR, 2008).

De acordo com Bonventi Junior (2008) as cores de objetos observados em cenas naturais são representadas em espaços como RGB, HSI, YUV e formam grupos de “nuvens” de diversas configurações, algumas esparsas e outras mais densas, com variação na cor percebida e densidade.

A quantidade de cores utilizada para representar um mesmo objeto, ou região, pode dificultar ou, até mesmo, inviabilizar o processamento e a análise da imagem. Assim a simplificação de imagem colorida auxilia as técnicas de processamento digital de imagens, como a segmentação, ao diminuir o número de cores presentes em uma imagem, possibilitando uma melhor identificação e análise de seus objetos (SOUZA E GUIMARÃES, 2012).

De acordo com Cechinel (2000) a segmentação de imagens coloridas é um processo pelo qual se extraem, do domínio da imagem, uma ou mais regiões conectadas que satisfaçam o critério de uniformidade. Esse critério tem

sua base em características derivadas de componentes do espectro. Esses componentes são definidos em um modelo de espaço de cores escolhido.

Cavani et al (2006) afirmam que é importante escolher um algoritmo de segmentação que seja adequado para imagens de cenas naturais em cores e com texturas. De acordo com os autores, esse algoritmo não deve exigir ajustes dos parâmetros para cada imagem, para que não seja necessária a interferência do usuário. Outro aspecto ressaltado é que o algoritmo deve considerar as texturas de forma simples.

O processo de segmentação pode ser melhorado através de alguns conhecimentos adicionais sobre os objetos em cena tais como as suas propriedades ópticas e geométricas (CECHINEL, 2000).

### **3.1.2 Aprendizagem automática**

Os métodos de Aprendizagem Automática (Machine Learning) desempenham um papel muito importante na área da Inteligência Artificial, nos dias de hoje, Resolução de Problemas, Prova de Teoremas, Processamento da Linguagem Natural, Robótica e Sistemas Especialistas são sub áreas que utilizam tais métodos .

A Aprendizagem Automática (MachineLearning) é uma das áreas da Inteligência Artificial cujo objetivo é o desenvolvimento de técnicas que permita aos computadores aprender com a experiência, ou seja, criar programas capazes de induzir conhecimentos a partir de informação não estruturada em forma de exemplos. A Aprendizagem Automática trabalha muito com os métodos computacionais que torna possível que computadores não somente aprendam, mas que também melhorem o seu desempenho com a experiência (CAPELA e GEORGIEVA, 2012).

Capela e Georgieva (2012) destaca algumas das cinco principais técnicas de Aprendizagem Automática:

- K-NearestNeighbor (k-NN) – O K-NN é um método de classificação de objetos, que tem por base K exemplos de treino mais próximos do objeto a classificar. Neste algoritmo um objeto é classificado por uma maioria de votos dos seus vizinhos, com o objeto a ser atribuído à classe mais comum entre os seus K vizinhos mais próximos. K é, por norma, um

número inteiro positivo ímpar, de forma a evitar empates e, por conseguinte, indefinições na classificação do objeto. Para as situações em que  $K=1$ , o objeto a classificar é simplesmente atribuído à classe do seu vizinho mais próximo.

- NaiveBayes - O classificador NaiveBayes é uma técnica probabilística baseada no teorema de Bayes.
- Support Vector Machine (SVM) - (SVM) é uma técnica de classificação que tem como objetivo definir um hiperplano que permita separar os dados de forma a identificar as classes . Tendo então um conjunto de dados, tal como representado pela Figura 2, esta técnica tenta determinar o plano que permite maximizar a margem entre as classes existentes, para que de seguida possa classificar novos objetos com uma maior precisão.
- Redes Neurais Artificiais (ANN) - A Rede Neuronal Artificial (Artificial Neural Network- ANN) é um modelo matemático inspirado da estrutura e as funcionalidades das Redes Neurais Biológicas (RNB). As Redes Neuronal Artificiais (RNA) são constituídas por camadas de funções matemáticas, chamadas neurônios artificiais, que se aproximam em termos de função aos neurônios biológicos.
- Árvores de decisão (AD) - Arvore de Decisão (DecisionTree) é técnica de classificação baseada na divisão de um problema complexo em vários subproblemas, repetindo este processo de forma recursiva através da geração de uma árvore.

### **3.2 Veículos Aéreos Não Tripulados - VANTS**

Estudos relacionados aos Veículos Aéreos Não Tripulados (VANT) têm apresentado crescimento ao redor do mundo proporcionando com isso novos avanços na tecnologia computacional, desenvolvimento de software, materiais mais leves, sistemas globais de navegação, avançados links de dados, sofisticados sensores e a miniaturização (JORGE *et. al.*, 2011).

Para Medeiros (2007) os VANTs são pequenas aeronaves que sem qualquer contato físico direto, possuem a capacidade de executar tarefas como monitorar, mapear, entre outras. Logo são aeronaves que se caracterizam por

dois aspectos básicos: não possuem piloto a bordo e carregam equipamentos – normalmente sensores que lhes permitem cumprir missões determinadas. Esses VANTs são pilotados ou controlados a distância através de meios eletrônicos e computacionais, supervisionados pelo homem ou via Controladores Lógicos Programáveis.

Inicialmente, foram idealizados para fins militares. No Brasil, o primeiro VANT de que se tem registro refere-se ao BQM1BR, fabricado pela extinta CBT (Companhia Brasileira de Tratores), de propulsão a jato. Esse protótipo serviria como alvo aéreo e realizou um voo em 1983.

A partir do ano 2000, os VANTs para uso civil começaram a ganhar força no mercado. Nessa década, surgiu o Projeto Arara (Aeronave de Reconhecimento Autônoma e Remotamente Assistida), desenvolvido numa parceria do Instituto de Ciências Matemáticas e Computação da Universidade de São Paulo (ICMC-USP) e a Empresa Brasileira de Pesquisa Agropecuária (Embrapa), especialmente para utilização em agricultura de precisão. O projeto deu origem, em abril de 2005, ao primeiro VANT de asa fixa desenvolvido com tecnologia 100% brasileira, cujo desenho industrial foi patenteado pela EMBRAPA.

Medeiros (2007) afirma que na agricultura de precisão, as imagens obtidas são utilizadas principalmente para monitoramento de lavouras, estimativas de volume de produção e índice de doenças e pragas. As fotografias aéreas obtidas a partir do VANT auxiliam no mapeamento das culturas, na avaliação de áreas cultivadas, na detecção de áreas afetadas, em cadastros rurais e no mapeamento do solo.

Herwitz et al (2004) afirma que a agricultura está se tornando uma indústria cada vez mais baseada no conhecimento em resposta a considerações econômicas e ambientais. Os autores realizam um estudo junto a Kauai Coffee Company no Hawaí, utilizando VANT para a coleta de imagens objetivando vigilância e apoio às decisões na plantação de café. Para os autores, existem vários aspectos de manejo da cultura que podem se beneficiar de observação aérea. O estudo demonstrou a capacidade de um VANT de sobrevoar a plantação, equipado com sistemas de imagem para monitorar uma região agrícola por um período de tempo prolongado, estando os VANTS a

oferecer uma valiosa contribuição para futuro monitoramento de recursos agrícola.

O estudo se mostrou importante demonstrando que a alta resolução de imagens foi imediatamente útil para mapear os focos de capim-colônia, bem como para mostrar diferenças na cobertura total do solo dentro de campos. Assim, para os autores, os VANTs são chamadas a desempenhar um papel mais amplo, complementar ao de satélites e aviões convencionalmente testados em apoio à agricultura (HERWITZ et al, 2004).

No ano de 2008, Apan et al (2010) realizaram um estudo que investigou o uso de um veículo aéreo não tripulado (VANT) para uso em aplicações agrícolas. A área de estudo foi localizada em Watts Bridge Memorial Airfield no sudeste de Queensland, Austrália. Para os autores, o uso de VANTs como ferramentas de sensoriamento remoto não é novo pois já foram utilizados para fotografar pastagens, para busca e salvamento em deserto, para o monitoramento da maturação do café e em outras coisas, para monitorar trigo.

O objetivo do estudo de Apan et al (2010) foi avaliar um sistema totalmente autônomo de aquisição de imagem. Para tanto, testou-se a capacidade do piloto automático para desencadear um sistema de câmara de detecção remota, bem como avaliou-se a precisão tridimensional do piloto automático (  $x$  ,  $y$  ,  $z$  ). A capacidade de adquirir imagens com precisão sobre pontos pré-determinados foi essencial para garantir a cobertura e agilizar o mosaico das imagens (APAN et al, 2010).

A conclusão do estudo de Apan et al, 2010 fez referência a necessidade de mais desenvolvimento para superar os problemas de precisão. Todavia, de acordo com os autores, a capacidade de realizar registro automático e mosaico das imagens adquiridas, e filtros passa baixa a partir de imagens aéreas convencionais, e considerando o baixo custo desse sistema de sensoriamento remoto, há projeção de um grande potencial para ser utilizado em aplicações agrícolas mais amplas.

Em 2011, Primicerio et al. (2012) utilizaram um VANT para realização de uma pesquisa baseada em Índice de Vegetação por Diferença Normalizada (NDVI), mapeando vinhedos na Itália, justificando que os mapas podem ser um

instrumento adequado para intra-bloco de gestão da vinha e precisão na viticultura, com a possibilidade de fornecimento de informações úteis aos viticultores para aumentar o potencial enológico da vinha. De acordo com os autores o fato do VANT pesar menos de 7 kg faz com que esse seja submetido a limitações mínimas do espaço aéreo, ficando livre das restrições de planos de vôo programados, tornando-se um sistema de sensoriamento remoto muito flexível quando se trata de pequenas culturas. Todavia, de acordo com os autores, mesmo com resultados preliminares animadores, uma maior miniaturização de sensores e detectores poderia aumentar consideravelmente o potencial desta plataforma.

Durante o ano de 2012, os autores Honkavaara et al (2013) realizaram um estudo no MTT Agroalimentar Research Finlândia, que teve por objetivo investigar uma metodologia de processamento completo para a imagem espectral FPI, obtidas a partir de um VANT ou especificamente, o bloco de imagem foi recolhida com a câmara espectral FPI usando um helicóptero VANT, onde pretendeu-se demonstrar o potencial em um processo de estimativa de biomassa para a agricultura de precisão. A área consistiu em parcelas de ensaio que continham tanto trigo e cevada. Os resultados levaram os autores a concluir que a nova tecnologia FPI tem um grande potencial na agricultura de precisão.

Gómez-Candon et al (2014) realizaram um estudo em dois campos de trigo na província de Sevilha, na Andaluzia ao sul da Espanha. Os campos estavam naturalmente infestados por plantas daninhas de folhas largas e gramíneas. O estudo de precisão geométrica das orto-imagens foram obtidas a partir de múltiplas imagens sobrepostas tiradas em lavouras de trigo naturalmente infestados por plantas daninhas nos primeiros estágios usando imagens de VANTs. Os autores concluíram que um VANT voando a uma distância de 30 a 100 m de altitude e com um número moderado de pontos de controle é capaz de gerar alta resolução espacial nas orto-imagens com a precisão de georeferenciamento necessária para mapear joios ainda pequenos do trigo em um estágio fenológico inicial.

Atualmente no Brasil já se pode falar no uso de VANTs gerando imagens importantes para a agricultura de precisão. O monitoramento de safras a partir

de imagens possibilita 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 (SILVA NETO, 2013).

Para Silva Neto (2013) as imagens tomadas por VANT aliadas a uma boa técnica de geoprocessamento trás resultados satisfatórios acarretando a uma melhor ocupação e tratamento do solo, plantio e colheita especializados. 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.

Honkavaara et al (2013) afirmam que os métodos que se utilizam de VANTS possibilitam a coleta de dados eficiente, em termos de custo, com o espaço desejado e resoluções temporais. Para os autores, uma importante vantagem dessa tecnologia se refere ao fato que os dados de sensoriamento remoto podem ser obtidos ainda que sob condições de imagem pobres, ou seja, sob a cobertura de nuvens, fato que torna o método operacional em uma ampla gama de aplicações de medição ambiental.

Os VANTS na agricultura são utilizados em situações diversas como, por exemplo, para detecção e controle de invasores na plantação de milho. Uma grande vantagem desse tipo de uso, é que os VANTS podem operar a altitudes mais baixas e, portanto, a captura de imagens com uma resolução espacial muito elevada (de alguns centímetros ou milímetros), o que não seria viável a partir de vôos convencionais ou satélites. Isso é fundamental para discriminar entre as pequenas mudas de plantas daninhas e de culturas em estágios iniciais, na maioria dos campos (PEÑA-BARRAGÁN et. al., 2012).

A expectativa é que os VANTS possam fornecer ferramentas de sensoriamento remoto que sejam eficientes para a agricultura de precisão, atuando nos objetivos de permitir o uso eficiente de recursos, proteger o ambiente e fornecer informações relacionadas a tratamentos de gestão (utilização de máquinas para aplicações orientadas, semeadura, fertilização e proteção fitossanitária) (HONKAVAARA et al, 2013).

### 3.3 Pragas da Soja

Relevante para a economia brasileira, a soja (*Glycine max*) é uma das plantas mais fáceis de serem cultivadas, porém, a exploração econômica do seu potencial de rendimento (mais de 4.000 kg/ha) dificilmente é alcançada (YORINORI, 1997). As doenças da soja encontram-se inseridas entre os principais fatores limitantes do rendimento, e em geral são de difícil controle.

O número de doenças causadas por bactérias, fungos, nematóides e vírus, continua aumentando a cada safra com a expansão da cultura para novos ambientes. No Brasil, já foram identificadas aproximadamente 40 doenças. A importância de cada doença varia de ano para ano e de região para região, dependendo das variedades predominantes e da condição climática de cada safra (EMBRAPA, 2011).

De acordo com a EMBRAPA (2011) entre as doenças causadas por nematóides destacam-se: nematóides de galhas, nematóide de galhas, nematóide de galhas, nematóide de cisto da soja, nematóide reniforme e nematóide das lesões radiculares. Destacam-se entre as doenças causadas por vírus: mosaico comum da soja, queima do broto, mosaico cálico e necrose da haste. Entre as doenças bacterianas destacam-se: crestamento bacteriano, pústula bacteriana, fogo selvagem. Entre as doenças da soja causadas por fungos, foram verificadas no Brasil:

- a. Doenças da parte aérea: crestamento foliar de cercóspora, ferrugem americana, ferrugem asiática, mancha foliar de alternária, mancha foliar de ascoquita, antracnose, cancro da haste, mancha púrpura da semente, seca da haste e da vagem, seca da vagem, mancha de levedura, mancha foliar de mirotécio, mancha parda, mancha “olho-de-rã”, míldio, mancha foliar de filosticta, mancha alvo, mela ou requeima da soja, podridão branca da haste ou mofo branco, oídio.
- b. Doenças radiculares: podridão de carvão, podridão parda da haste, podridão de fitóftora, podridão radicular de cilindrocládio, tombamento de escleródio, murcha de escleródio, tombamento de rizoctonia, morte em reboleira, podridão da raiz e da base da haste, podridão vermelha da



raiz (síndrome da morte súbita - PVR/SDS), podridão radicular de rosé-lí-  
nia, podridão radicular de corinéspora.

#### **4. METODOLOGIA**

Para cada um dos objetivos específicos listados na Seção 2.2, serão apresentados a seguir os aspectos metodológicos que nortearão a execução desta proposta.

##### **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 Visão Computacional, utilização de Veículos Aéreos Não Tripulados – 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 será desenvolvido pelo grupo INOVISÃO, projeto HERBIVIC, e também para testar seu desempenho, um banco de imagens será construído. O banco conterà cerca de 100 imagens para cada classe do problema. As classes, neste caso, correspondem aos problemas relacionadas a soja. As imagens serão capturadas a partir de um Veículo Aéreo Não Tripulado – VANTs, com quatro hélices com uma câmera GoPro acoplada, devendo cada captura de imagens ocorrer em mesmo horário conforme iluminação ideal. Exemplos de imagens similares às que serão utilizadas neste plano podem ser vistos na Figura 1.




Figura 1 – Imagens de Sojas com e sem danos.

#### 4.3. Implementação do módulo para Inspeção de Folhas de Soja

O módulo para Inspeção de Folhas de Soja em Imagens Multi-espectrais será desenvolvido em Linguagem C++ tendo como apoio o pacote para Visão Computacional OpenCV (BRADSKI, 2000) versão X.Y e o software Weka versão X.Y. Serão seguidas as regras definidas pelo grupo de pesquisa e desenvolvimento INOVISAO disponíveis no site do grupo<sup>1</sup>. A metodologia de desenvolvimento de software do INOVISAO tem como base o SCRUM (SIMS; JOHNSON, 2011) com todo o material produzido sob controle de versões utilizando a ferramenta SubVersion<sup>2</sup>. O padrão de documentação de código é baseado no JavaDoc (mesmo para programas em C e C++).

1 O site do INOVISAO está em [www.gpec.ucdb.br/inovisao](http://www.gpec.ucdb.br/inovisao) e as instruções para desenvolvedores pode ser acessada através do link “trac”, neste mesmo site, ou diretamente em [trac.gpec.ucdb.br](http://trac.gpec.ucdb.br).

2 O software de controle de versões subversion é apresentado em <http://subversion.apache.org/>.

#### 4.4. Validação do módulo

Os algoritmos escolhidos e implementados serão comparados entre si e também em relação ao desempenho humano 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<sup>3</sup> na versão X.Y (HALL et al., 2009). Para cada algoritmo testado, serão calculados os desempenhos médios referentes às métricas de precisão, abrangência, medida-F e taxa de acerto ajustadas para problemas com mais de duas classes quando necessário. Para identificar se os algoritmos testados diferem estatisticamente em relação ao desempenho, considerando-se cada uma das métricas, serão utilizados o teste não-paramétrico proposto por Friedman (1940) e análise de variância (ANOVA), ambos disponíveis no software estatístico R<sup>4</sup>, versão 2.14.1, com cada bloco correspondendo a uma das classes do problema. Serão reportados os valores-p encontrados para cada métrica e o nível de significância necessário para descartar a hipótese nula. Para todas as métricas será realizado um pós-teste e os diagramas de caixa e valores-p dois a dois resultantes serão analisados. O pós-teste, 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 que relacione agricultura e tecnologia. Será utilizada a ferramenta Latex<sup>5</sup> 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.

Em resumo, as seguintes atividades serão realizadas:

- 
- 3 O Weka é um software livre e gratuito disponível em <http://www.cs.waikato.ac.nz/ml/weka/>.
  - 4 O software R está disponível em <http://www.r-project.org/>. Para o teste de Friedman com análise post-hoc é necessário instalar o
  - 5 O editor de textos Latex é livre e gratuito e pode ser obtido em <http://www.latex-project.org/>

1. Aprofundamento e atualização da revisão de literatura
  - 1.1. Estudar artigos sobre Visão Computacional,
  - 1.2. Estudar artigos sobre a segmentação de imagens coloridas.
  - 1.3. Estudar artigos sobre a aprendizagem automática.
  - 1.4. Estudar artigos sobre VANTs e sua utilização na agricultura a nível mundial e brasileiro.
  - 1.5. Estudar as principais doenças e pragas da soja.
2. Construção de um banco de imagens da lavoura de Soja
  - 2.1. Utilizar um VANT com câmera Go-pro acoplada para obtenção de imagens. Realizar acompanhamento da lavoura obtendo imagens do início, meio e final do ciclo produtivo. As imagens deverão ser obtidas em horário definido como mais oportuno para a qualidade das imagens
3. Implementação do módulo para Segmentação por Aprendizagem Supervisionada para Inspeção de Folhas de Soja em Imagens Multi-espectrais.
4. Validação do módulo
5. Registro e divulgação de resultados

## 5. Cronograma

|  | 2014-2016 (Trimestral) |    |    |    |    |    |    |    |    |    |    |    |
|--|------------------------|----|----|----|----|----|----|----|----|----|----|----|
|  | 01                     | 02 | 03 | 04 | 05 | 06 | 07 | 08 | 09 | 10 | 11 | 12 |
| 1.1. Estudar artigos sobre Visão Computacional   | X                      | X  |    |    |    |    |    |    |    |    |    |    |
| 1.2 Estudar artigos sobre a segmentação de imagens coloridas.  | X                      | X  |    |    |    |    |    |    |    |    |    |    |
| 1.3 Estudar artigos sobre a aprendizagem automática.   |                        | X  | X  |    |    |    |    |    |    |    |    |    |
| 1.4 Estudar artigos sobre VANTs e sua utilização na agricultura a nível mundial e brasileiro.  | X                      | X  |    |    |    |    |    |    |    |    |    |    |
| 1.5 Estudar as principais doenças e pragas da soja.  | X                      | X  |    |    |    |    |    |    |    |    |    |    |
| 2.1 Construção de um banco de imagens da lavoura de Soja (Plantio)   |                        |    |    | X  |    |    |    |    |    |    |    |    |
| 2.2 Construção de um banco de imagens da lavoura de Soja (Colheita)  |                        |    |    |    | X  |    |    |    |    |    |    |    |
| 2. 3 Implementação do módulo para Segmentação por Aprendizagem Supervisionada para Inspeção de Folhas de Soja em Imagens Multi-espectrais. |                        |    |    |    | X  | X  | X  |    |    |    |    |    |
| 3. 4 Validação do módulo   |                        |    |    |    |    |    | X  | X  | X  |    |    |    |
| 5 Registro e divulgação de resultados  |                        |    |    |    |    |    | X  | X  | X  | X  | X  | X  |

## 6. Referências Bibliográficas

ABOUD NETA, S. R.; DUTRA, L. V.; PRADO, B. R.. **Segmentação de imagens multiespectrais utilizando-se o atributo matiz**. In: XIV Simpósio Brasileiro de Sensoriamento Remoto, 2009, Natal. XIV Simpósio Brasileiro de Sensoriamento Remoto, 2009.

APAN, A.; TROY, J.; LES, C. Z.. **The use of an unmanned aerial vehicle as a remote sensing platform in agriculture**. Australian. Journal of Multi-disciplinary Engineering. Nov. 2010.

BONVENTI JR., W. . **Agrupamentos Nebulosos em Segmentação de Imagens Coloridas: Quantificação Histológica**. In: IV Workshop de Visão Computacional - WVC 2008, 2008, Bauru. Anais do IV Workshop de Visão Computacional. Bauru: Canal 6 Projetos Editoriais, 2008.

BRADSKI, G. The OpenCV Library. **Dr. Dobb's Journal of Software Tools**, 2000.

BRASIL. MINISTÉRIO DA AGRICULTURA, PECUÁRIA E ABASTECIMENTO - MAPA. **Comércio Exterior da Agropecuária Brasileira - Principais Produtos e Mercados**. Edição 2012. Secretaria de Relações Internacionais do Agronegócio. – Brasília: MAPA/ACS, 2012.

BRASIL. MINISTÉRIO DA AGRICULTURA, PECUÁRIA E ABASTECIMENTO - MAPA. **Projeções do Agronegócio: Brasil 2012/2013 a 2022/2023**. Assessoria de Gestão Estratégica. – Brasília : Mapa/ACS, 2013.

CAVANI, F. A.; SOUSA, R. V.; PORTO, A. J. V.; TRONCO, M. L.. **Segmentação e classificação de imagens de laranjeiras utilizando JSEG e perceptron multicamadas**. **Revista Minerva**, v. 3, p. 189-197, 2006.

CECHINEL, C.. **Técnicas de Segmentação de Imagens a Cores**. Seminário Visão Computacional - CPGCC/UFSC – 2000. Disponível em <<http://www.inf.ufsc.br/~visao/2000/Cores/>>. Acesso em janeiro/2014.

COMPANHIA NACIONAL DE ABASTECIMENTO - CONAB. **Acompanhamento de safra brasileira: grãos**. Sexto levantamento, março 2013 / Brasília : Conab, 2013.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA - EMBRAPA SOJA. **Tecnologias de produção de soja – região central do Brasil 2012 e 2013**. - Londrina: Embrapa Soja, 2011.

FRIEDMAN, M. A comparison of alternative tests of significance for the problem of m rankings. **The Annals of Mathematical Statistics**, v. 11, n. 1, p. 86–92, 1940.

HALL, M.; FRANK, E.; HOLMES, G.; PFAHRINGER, B.; REUTEMANN, P.; WITTEN, I. H. The WEKA Data Mining Software: An Update. **SIGKDD Explorations**, v. 11, n. 1., 2009.

HERWITZ ,[S.R.](#); et al. **Imaging from an unmanned aerial vehicle: agricultural surveillance and decision support**. [Computers and Electronics in Agriculture](#). [Volume 44, Issue 1](#), July 2004, Pages 49–61.



HOLLANDER, M.; WOLF, D. A. **Nonparametric Statistical Methods**. 2nd Edition. New York: John Wiley & Sons, 1999.

HONKAVAARA, E.; SAARI, H.; KAIVOSOJA, J.; PÖLÖNEN, I.; HAKALA, T.; LITKEY, P.; MÄKYNEN, J.; PESONEN, L. **Processing and Assessment of Spectrometric, Stereoscopic Imagery Collected Using a Lightweight UAV Spectral Camera for Precision Agriculture**. *Remote Sens*. 2013, 5, 5006-5039.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA – IBGE. **Retratos do Brasil Rural: modernização da agropecuária contrasta com baixa escolaridade**. 2012. Disponível em <http://saladeimprensa.ibge.gov.br/noticias?view=noticia&id=1&busca=1&idnoticia=2242> Acesso em 21 de novembro de 2013.

JORGE, L. A. C.; INAMASU, R. Y. ; CARMO, R. B. . **Desenvolvimento de um VANT totalmente configurado para aplicações em agricultura de precisão no Brasil**. In: XV Simpósio Brasileiro de Sensoriamento Remoto-SBSR, 2011, Curitiba. Anais XV Simpósio Brasileiro de Sensoriamento Remoto-SBSR, 2011.

MARENGONI, M.; STRINGHINI D. **Introdução a visão computacional usando openCV**. RITA, v.XIII, n.1, 2009.

MEDEIROS, F.A. **Desenvolvimento de um veículo aéreo não tripulado para aplicação em agricultura de precisão**. 2007. 102f. Dissertação (Mestrado em Engenharia Agrícola)-Universidade Federal de Santa Maria, Santa Maria.

MILANO, D. D.; HONORATO, L. B. **Visão computacional**. – Universidade Estadual de Campinas– Faculdade de Tecnologia. 2010.

NASCIMENTO, P. S. R.; ALMEIDA FILHO, R. **Utilização da técnica de segmentação em imagens TM/Landsat visando otimizar a técnica de interpretação visual**. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 8., 1996, Salvador. Artigos... São José dos Campos: INPE/SELPER, 1996.

NEVES, S. C. M.; PELAES, E. G. **Estudo e implementação de técnicas de segmentação de imagens**. Revista Virtual de Iniciação Acadêmica da UFPA. Vol 1, No 2, Julho 2001.

PADILHA, A. J. M. N.. **Processamento e Análise de Imagem**. Ficheiro de aula – Capítulo 4. DEEC - Departamento de Engenharia Electrotécnica e de Computadores. Faculdade de Engenharia da Universidade do Porto. Porto – Portugal. 2005. Disponível em <http://paginas.fe.up.pt/~padilha/PAI/ficheiros/> Acesso em janeiro/2014.

PRIMICERIO, J., Di GENNARO, S. F., FIORILLO, E., GENESIO, L., LUGATO, E., MATESE, A. and VACCARI, F. P. 2012. **A flexible unmanned aerial vehicle for precision agriculture**. *Precision Agriculture* 13 517–523

RUDEK, M.; COELHO, L. dos S.; CANGIOLIERI, O.. **Visão Computacional Aplicada a Sistemas Produtivos: Fundamentos e Estudo de Caso**. Disponível em: <[http://www.abepro.org.br/biblioteca/ENEGEP2001\\_TR10\\_0917.pdf](http://www.abepro.org.br/biblioteca/ENEGEP2001_TR10_0917.pdf)>. Acesso em: 12 set. 2008.

RUIZ, Henrique de Souza, ET AL.. **Seleção Automática de Componentes de Cor para Segmentação de Imagens**. In: Workshop de Visão Computacional - WVC 2007, 2007, São José do Rio Preto. WVC 2007, 2007.

SALDANHA, M.; FREITAS, C.. **Segmentação de Imagens Digitais: Uma Revisão**. 2008. Disponível em: <<http://www.lac.inpe.br/cap/arquivos/pdf/P19.pdf>>. Acesso em janeiro de 2014.

SECRETARIA DE ESTADO DE AGRICULTURA, PECUÁRIA E ABASTECIMENTO - SEAB/MG. **Perfil do agronegócio brasileiro**. Novembro/2013. Disponível em [http://www.agricultura.mg.gov.br/images/files/perfil/perfil\\_brasil1.pdf](http://www.agricultura.mg.gov.br/images/files/perfil/perfil_brasil1.pdf). Acesso em 21 de novembro de 2013.

SILVA, Lincoln Faria da. **Distinção automática de texto impresso e manuscrito em uma imagem de documento**. Dissertação (Mestrado em Computação) - Universidade Federal Fluminense, Niterói, RJ. 2009.

SILVA NETO, M.. **Como utilizar imagens aéreas na agricultura de precisão?** 13 de Setembro de 2013. Disponível em <<http://www.agrimensordofuturo.com/post.cfm?post=COMO%20UTILIZAR%20IMAGENS%20A%C3%89REAS%20NA%20AGRICULTURA%20DE%20PRECIS%C3%83O%3F&id=42>> Acesso em 26/11/2013.

SIMS, C.; JOHNSON, H. L. **The Elements of Scrum**. Dymaxicon, 2011.

SOUZA, K. J. F.; GUIMARÃES, S. J. F. **Uma Abordagem de Simplificação de Imagem Colorida Baseada na Árvore Geradora Mínima**. Instituto de Ciências Exatas e Informática. PUC MG, Brasil. Disponível em <[www.decom.ufop.br/sibgrapi2012/eeproceedings/wtd/102539\\_2.pdf](http://www.decom.ufop.br/sibgrapi2012/eeproceedings/wtd/102539_2.pdf)> Acesso em janeiro/2014.

SZELISKI, R.. **Computer Vision: Algorithms and Applications**. Springer, 2010.

YORINORI, J.T. *et al.*. **Doenças da soja e seu controle**. In: ARANTES, N.E.; SOUZA, P.I. de M. de., ed. *Cultura de soja nos cerrados*. Piracicaba: POTAFOS, 1993.. p.333-397..

ZARBIN, P. H. G.; RODRIGUES, M. A. C. M.; LIMA, E. R.. **Feromônios de insetos: tecnologia e desafios para uma agricultura competitiva no Brasil**. *Quím. Nova* [online]. 2009, vol.32, n.3, pp. 722-731.