



Fundação de Apoio ao Desenvolvimento do Ensino,
Ciência e Tecnologia do Estado de Mato Grosso do Sul

**Utilização de Aprendizado Profundo na Detecção de Plantas
Daninhas na Lavoura de Soja através de Imagens de Veículos
Aéreos Não Tripulados**

**Chamada FUNDECT/CAPES n° 01/2015 - Mestrado em Mato Grosso do
Sul**

Mestrado em Ciência da Computação

Universidade Federal de Mato Grosso do Sul

INOVISAO - UCDB

22/06/2015

Campo Grande – MS

1. ANTECEDENTES E JUSTIFICATIVA DO PROBLEMA A SER ABORDADO

De acordo com os dados da Confederação Nacional de Agricultura (CNA) de 2008 o agronegócio brasileiro é responsável por 24% do Produto Interno Bruto (PIB), deixando clara a importância do setor para a economia brasileira (Silva et al., 2011). Neste contexto a soja é a cultura agrícola que mais cresceu nas últimas três décadas. De acordo com o portal do Ministério da Agricultura a soja corresponde a 49% da área plantada em grãos no país (Ministério da Agricultura, 2015).

Cultivada principalmente nas regiões Centro-Oeste e Sul do país, a soja é um dos produtos mais destacados da agricultura nacional e na balança comercial. Na safra de 2013 os estados maiores produtores de soja no Brasil foram, respectivamente, Mato Grosso, Paraná, Rio Grande do Sul, Goiás e Mato Grosso do Sul, sendo o estado de Mato Grosso do Sul responsável por 7,07% da produção, demonstrando a importância do estado para a produção nacional de soja (SIDRA, 2015). A nível mundial, segundo dados de 2013, o Brasil se encontra na segunda posição, atrás apenas dos Estados Unidos, sendo responsável por aproximadamente 31% da produção mundial, o que correspondeu a 82 milhões de toneladas (SoyStats, 2015).

A nível mundial a soja representa o papel de principal oleaginosa consumida, tanto para o consumo animal através do farelo de soja quanto para consumo humano através do óleo. No Brasil a sua relevância para o agronegócio começou a partir dos anos 70 através do aumento da área cultivada e principalmente pelo aumento da produtividade obtido através do uso de novas tecnologias. A partir dos anos 90, a agricultura brasileira passou por um processo de modernização fazendo com que o setor de soja alcançasse maior crescimento e dinamismo. A importância do complexo de soja para o Brasil pode ser observada tanto pelo grande crescimento de produção quanto pela arrecadação com a sua exportação e de seus derivados como óleo e farelo de soja (Silva et al., 2011).

Dada a importância da soja no contexto econômico é imprescindível o uso de técnicas visando maximizar a produtividade e qualidade do produto. Neste

cenário se faz importante a agricultura de precisão que é definida por Pierce e Nowak (1999) como sendo “a aplicação de princípios e tecnologias para manejar a variabilidade espacial e temporal, associada com todos os aspectos da produção agrícola, com o objetivo de aumentar a produtividade na agricultura e a qualidade ambiental”.

Além da utilização de sistemas de posicionamento global, sensoriamento remoto e informação geográfica (Coelho, 2005), uma das bases da agricultura de precisão é a utilização de imagens capturadas por satélites para identificar variações da cultura e do solo. Entretanto devido a difícil disponibilidade e altos custos de imagens obtidas por satélites, uma alternativa mais econômica se faz necessária. Com os avanços tecnológicos nas últimas décadas, a utilização de VANTs têm se mostrado uma alternativa bastante atraente não apenas economicamente mas também superando outras limitações comuns das imagens obtidas por satélites e aeronaves (Peña-Barragán et al., 2012).

Essa pesquisa visa utilizar técnicas de Visão Computacional, mais especificamente o uso de Aprendizado Profundo, no auxílio da automatização da extração informação relevante das imagens de plantações de soja obtida pelos VANTs em fazendas no estado do Mato Grosso do Sul. O Aprendizado Profundo (Deep Learning) vem alcançando um desempenho notável nos últimos anos na área de Visão Computacional em especial no reconhecimento de objetos. Seu desempenho em *benchmarks* conhecidos como MNIST, conjunto de dados de dígitos manuscritos, e em competições como o ImageNet LSVRC tem atraído intenso estudo e mostrado quão promissor é o uso de Aprendizado Profundo no campo de reconhecimento de imagens (Deng, Yu, 2013).

2. OBJETIVOS

2.1. Objetivo Geral

O objetivo do trabalho é implementar um programa que através de técnicas de Visão Computacional, utilize imagens de lavouras de soja registradas por VANTs para entregar ao usuário final a ocorrência de ervas daninhas nesta plantação. O intuito desta abordagem é reduzir as perdas geradas por estas infestações.

2.2. Objetivos Específicos

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

1. Aprofundamento e atualização da revisão de literatura em técnicas de Visão Computacional e VANTs na agricultura e Aprendizado Profundo.
2. Construção de um banco de imagens de soja.
3. Implementação do módulo de detecção de ervas daninhas em lavouras de soja.
4. Validação do módulo implementado.
5. Registro e divulgação de resultados.

3. REVISÃO DE LITERATURA

3.1 Visão Computacional na Agricultura

Prince (2012) define que o objetivo da Visão Computacional é extrair informação útil das imagens. Esta tarefa tem se demonstrado surpreendentemente desafiante, tendo ocupado centenas de mentes criativas nas últimas quatro décadas. Apesar disso ainda estamos longe de construir uma “máquina que enxega” para propósito geral. De acordo com Shapiro e Stockman (2000), o seu objetivo é tomar decisões úteis sobre objetos físicos e cenas através de imagens. Para tomar decisões sobre objetos reais é quase sempre necessário construir alguma descrição ou modelo deles a partir das imagens. Devido a esse fato, muitos estudiosos dirão que o objetivo da Visão Computacional é a construção da descrição de cenas obtidas das imagens.

Na Visão Computacional tenta-se descrever o mundo que vemos em uma ou mais imagens e reconstruir suas propriedades como forma, iluminação e distribuição de cor. Como humanos e animais tendem a realizar essa tarefa com facilidade as pessoas que não trabalham na área costumam subestimar a dificuldade do problema (Szeliski, 2010). De qualquer forma, tem sido alcançado um notável progresso recente em nosso entendimento da Visão Computacional e na última década se viu uma grande escala de desenvolvimento de tecnologias relacionadas à área para o consumidor. Um exemplo é que atualmente a maioria

das câmeras digitais possuem algoritmos embutidos para reconhecimento de face (Prince, 2012).

A Visão de Máquina ou Visão Computacional é relacionada a inúmeras outras áreas. Muitas técnicas desenvolvidas em outras áreas podem ser utilizadas para recuperar informações das imagens. Jain, Kasturi e Schuck (1995) citam Processamento de Imagens, Computação Gráfica, Reconhecimento de Padrões e Inteligência Artificial como áreas que contribuem com técnicas úteis à Visão Computacional.

Por ser uma técnica de inspeção rápida, econômica e consistente, a Visão Computacional vem se expandindo para as mais diversas indústrias. Sua velocidade e precisão satisfazem os pré-requisitos de produção e qualidade, ajudando no desenvolvimento de um processo completamente automatizado. Este método de inspeção tem encontrado várias aplicações na agricultura e indústria de alimentos (Brosnan, Sun, 2002).

Um importante problema que vem surgindo na agricultura está relacionado à automatização de tarefas, onde sensores óticos realizam um papel importante. Eles fornecem imagens que devem ser convenientemente processadas. O principal problema relacionado com a aplicação de métodos de Visão de Máquina é a segmentação de imagens. Uma eficiente e automática segmentação da vegetação nas imagens da cultura é um importante passo para muitas aplicações como detecção de pragas (Guijarro et al., 2010).

Vários projetos que utilizam técnicas de Visão Computacional direcionados à agricultura vem sendo implementados. Pesquisas tem destacado as possibilidade da utilização de sistemas de visão em várias áreas da agricultura como análise do comportamento animal, aplicação na implementação de agricultura de precisão e orientação das máquinas, silvicultura e análise de medida e crescimento das plantações (Brosnan, Sun, 2002).

3.2 VANTs na Agricultura

Os VANTs (Veículos Aéreos Não Tripulados), mais conhecidos como drones, são aeronaves capazes de serem operadas por controle remoto ou autonomamente. Também são conhecidos como *Unmanned Aerial Vehicles* (UAVs), *Uninhabited Aerial Vehicles* e *Unnamed Aircraft Systems* (UASs). O

conceito de construir aeronaves não tripuladas para aplicações diversas surgiu, inicialmente, em virtude de necessidades militares. Os primeiros testes sem tripulação datam de 1916, mas somente em 1917, durante a Primeira Guerra Mundial, o primeiro VANT foi desenvolvido. Na década de 1970 tem início a era moderna dos VANTS. De qualquer forma, pode-se dizer que foram após as operações de 1991, com o VANT Pioneer sendo utilizado em mais de 300 missões durante a operação *Tempestade no Deserto*, que a utilização de VANTS deslanchou (Chaves et al., 2012).

Com o avanço tecnológico nos setores de processamento de dados e miniaturização de componentes eletrônicos ocorridos nas últimas duas décadas, diversas aplicações militares de VANTS foram desenvolvidas ao redor do mundo. Mais recentemente, usos científicos e civis têm sido desenvolvidos devido ao fato que esses veículos aéreos desprovidos de tripulação podem apresentar vantagens técnicas e econômicas nas mais diversas áreas. Entre as vantagens obtidas no sensoriamento remoto utilizando VANTS podemos citar redução dos custos para obtenção de imagens aéreas, maior flexibilidade para a aquisição de imagens em alta resolução, possibilidade de execução dos mais variados tipos de missão sem colocar em risco a vida do piloto ou operador de câmera, economia no gasto do treinamento de pilotos e maior facilidade e velocidade de incorporação de novas tecnologias (LONGHITANO, 2010).

Entre as atividades civis onde o uso de VANTS vem sendo cada vez mais utilizado nos últimos anos, podemos citar a agricultura. Devido às vantagens citadas anteriormente, a utilização de drones vem sendo aproveitada com os mais variados objetivos na agricultura tendo como foco reduzir os custos e aumentar a produtividade no campo. Entre os vários trabalhos que mostram o crescimento da utilização de drones na agricultura, temos o estudo recente de Primicerio et al. (2012) que utilizou um VANT modelo *VIPtero* no auxílio de uma aplicação direcionada a agricultura de precisão em um vinhedo na Itália Central. Como conclusão do seu trabalho, eles apontaram que a aplicação da tecnologia no setor da agricultura pode melhorar significativamente a eficiência, sustentabilidade ambiental e os lucros do agricultor. Também afirmam que embora melhorias sejam necessárias, os resultados preliminares foram animadores.

Peña-Barragán et al. (2012) utilizaram imagens da nova geração de VANTs para o controle de ervas daninhas em plantações de milho. Através de imagens da cultura obtidas a partir de drones, o objetivo era distinguir pequenas mudas dessas ervas para tratar com o herbicida específico. As limitações conhecidas em utilizar imagens remotas para esse fim foram superadas com a utilização dos VANTS, que têm como principal potencial a grande flexibilidade de acordo com o objetivo econômico, além de poderem operar em baixas altitudes capturando imagens em alta resolução que não podem ser obtidas por aviões convencionais ou satélites. Este aspecto é determinante para a diferenciação das plantas daninhas nos primeiros estágios das culturas.

Como outro estudo que demonstra a utilização de VANTs na agricultura podemos citar Swain et al. (2010) que utilizou um helicóptero não tripulado controlado por rádio com sensores remotos de baixa altitude para obter imagens de alta resolução com objetivo de estimar a área e biomassa total de plantações de arroz. O estudo concluiu que o uso de dessas plataformas poderiam substituir a obtenção de imagens via satélite ou por aeronaves na agricultura de precisão das lavouras de arroz. O uso de um VANT de baixo custo se mostrou adequado para a rápida aquisição de imagens e análise de dados visando a avaliação adequada do crescimento de uma plantação.

3.3 Agricultura de Precisão

A mais simples definição da agricultura de precisão pode ser descrita como “aplicar o tratamento correto no lugar certo na hora certa” (Gebbers, Adamchuk, 2010). De acordo Zhang e Kovacs (2012), a agricultura de precisão pode ser definida como a aplicação de técnicas e sensores geoespaciais como sistemas de informação geográfica ou GPS para identificar variações no campo e lidar com elas através de estratégias alternativas.

A utilização da agricultura de precisão tem claros benefícios para otimizar a eficiência da produção e aumentar a qualidade, além de minimizar os riscos e impactos ambientais. Dado a esses aspectos ela pode ser vista como uma solução que otimiza a qualidade e quantidade do produto ao mesmo tempo que minimiza os custos, a intervenção humana e as variações causadas pela imprevisibilidade da natureza (PRECISION AGRICULTURE, 2014). Os

benefícios da agricultura de precisão para o ambiente são obtidos através de alvos mais específicos, usos de insumos que reduzem as perdas e das reduções de perdas causadas por desequilíbrio de nutrientes, ataques de pragas e ervas daninhas (Bongiovanni, 2004). Existem também evidências de pesquisas que afirmam que a degradação ambiental é reduzida quando utilizadas técnicas de agricultura de precisão (PRECISION AGRICULTURE, 2014).

A implementação da agricultura de precisão tem se tornado possível graças ao desenvolvimento de sensores combinados a técnicas de gerenciamento da cultura tais como cultivo, semeadura, fertilização, aplicação de herbicidas e colheita. No que se refere às tecnologias o progresso vem acontecendo devido ao rápido desenvolvimento, minituarização e melhoria na precisão do Sistema Global de Navegação por Satélite (*Global Navigation Satellite System – GNSS*) do qual o GPS é o mais utilizado atualmente. Esse sistema é altamente utilizado por inúmeras fazendas para atividades como geoposicionamento e produção de informação georeferencial (PRECISION AGRICULTURE, 2014).

Além disso imagens em alta resolução capturadas por satélite são comumente utilizadas para identificar variações da safra e do solo. Porém a disponibilidade e frequentes custos proibitivos dessas imagens vem exigindo uma alternativa para estas aplicações na agricultura de precisão. Como uma solução, o uso de VANTs, citados no tópico anterior, vem se mostrando como uma alternativa em potencial, dado o baixo custo operacional em monitoramento ambiental além da sua alta flexibilidade na aquisição de imagens (Zhang et al., 2012).

Peña-Barragán et al. (2012) descreveram em seu trabalho as vantagens de se utilizar VANTs em relação às tecnologias tradicionais, que tinha como limitações costumeiras resolução insuficiente para discriminar o solo de faixas de cultura e ervas daninhas, detectar as diferenças da plantação para ervas daninhas no início da plantação além da interferência da reflectância do solo na detecção. Essas limitações foram superadas através do uso de VANTs que podem capturar imagens com alta resolução a baixas altitudes, crucial para a discriminação entre a cultura e ervas daninhas nos primeiros estágios da cultura.

3.4 Ervas Daninhas na Soja

Ervas daninhas, também conhecidas como plantas daninhas, invasoras, inços e tingueras, são plantas que crescem espontaneamente em solos agrícolas onde não são desejadas. O crescimento dessas plantas competindo com culturas econômicas, como a soja, causa prejuízos dificultando a operação de máquinas colhedoras e aumentando a impureza e umidade dos grãos (EMBRAPA, 2005).

Através de observações e levantamentos nas regiões produtoras de soja no Brasil, podemos indicar como mais frequentes as seguintes invasoras (EMBRAPA, 2005):

- 1) gramíneas: capim-custódio (*Pennisetum setosum*), c-marmelada (*Brachiaria plantaginea*), braquiária (*B. decumbens*), c.-carrapicho (*Cenchrus echinatus*), c.-colchão (*Digitaria spp.*) e trapoeraba (*Commelina benghalensis*).
- 2) folhas largas: carrapicho-rasteiro (*Acanthospermum australe*), picão-preto (*Bidens pilosa*), corda-de-viola (*Ipomoea spp.*), amendoim-bravo (*Euphorbia heterophylla*), caruru (*Amaranthus spp.*), erva-quente (*Spermacoce latifolia*), joá (*Solanum spp.*), falsa-serralha (*Emilia sonchifolia*), guanxuma (*Sida rhombifolia*), poaia-branca (*Richardia brasilienses*), cheirosa (*Hyptis suaveolens*), mentrasto (*Agetarum conizoides*) e o desmodio (*Desmodium tortuosum*).

Os efeitos negativos das plantas daninhas nas lavouras incluem a competição de água, luz, nutrientes e espaço, aumento de custos de produção, dificuldade de colheita, depreciação da qualidade do produto, hospedagem de pragas e doenças e diminuição do valor comercial das áreas cultivadas (Rizzardi, Fleck, 2004). Para controlar a competição das ervas daninhas são utilizados quatro tipos de manejos: exclusão, prevenção, supressão e erradicação (EMBRAPA, 2005).

No estado do Mato Grosso do Sul, de acordo com dados do projeto SIGA MS (Famasul, 2014), as plantas daninhas de maior incidência na safra 2014/2015 foram a buva (*Conyza bonariensis*), capim amargoso (*Elionurus candidus*), carrapicho (*acanthospermum australe*) e picão preto (*Bidens pilosa*). Destas, a buva e o capim amargoso tiveram maior incidência nas lavouras da região. Na

figura abaixo temos um trecho de plantação de soja onde a ocorrência de plantas daninhas foi controlada quimicamente através de herbicidas e outro trecho onde nenhuma medida para evitar a competição foi tomada e as ervas daninhas se desenvolveram prejudicando a lavoura de soja.



Figura 3.1 – À esquerda trechos da plantação de soja com utilização de herbicida. À direita não foi utilizado nenhum manejo para evitar a competição, sendo visível a presença de c-marmelada (*Brachiaria plantaginea*).

3.5 Aprendizado Profundo

Aprendizado Profundo (*Deep Learning*) é uma nova área de pesquisa de Aprendizado de Máquina que foi apresentada com o objetivo de aproximá-lo de um dos seus objetivos originais: a Inteligência Artificial (Deep Learning Tutorial, 2015). Deng, Yu (2013), entre várias definições, definem Aprendizado Profundo como uma classe de técnicas de Aprendizado de Máquina que exploram muitas camadas de processamento de informação não linear para extração e

transformação supervisionada ou não-supervisionada e para análise de padrões e classificação.

Vários estudos vêm demonstrando a eficiência do Aprendizado Profundo em uma grande variedade de aplicações. Podemos citar o seu uso no reconhecimento de dígitos manuscritos da base de dados MNIST, aplicações de reconhecimento facial, reconhecimento e detecção de fala, reconhecimento de objetos em geral, processamento de linguagem e robótica. O interesse em Aprendizado Profundo não tem se limitado a pesquisa na área acadêmica, sendo recentemente objeto de interesse do DARPA (*Defense Advanced Research Projects Agency*) que anunciou um projeto de pesquisa focado exclusivamente na área (Arel et al. 2010).

A sua aplicação na área de Visão Computacional tem alcançado um notável progresso nos últimos anos, em especial no campo do reconhecimento de objetos. Pode ser considerada a segunda área onde a aplicação das técnicas de Aprendizado Profundo foram utilizadas com sucesso, seguindo o reconhecimento de fala. Durante muitos anos o reconhecimento de imagem em Visão Computacional ficou dependente de técnicas como SIFT (*Scale Invariant Feature Transform*) e HOG (*Histogram of Oriented Gradients*). Entretanto essas técnicas capturam apenas baixo nível de informação. O Aprendizado Profundo visa superar essas dificuldades através de aprendizado supervisionado e não-supervisionado dos dados da imagem (Deng, Yu 2013).

Vários trabalhos vêm sendo realizados e gradativamente provando a eficácia do uso de Aprendizado Profundo no reconhecimento de imagens. Ciresan et al. (2012) utilizando uma arquitetura de redes neurais artificiais profundas conseguiram bater a performance humana no reconhecimento de dígitos escritos a mão e sinais de trânsito nos conjuntos de dados MNIST, NORB, entre outros.

Para alcançar esse objetivo foram utilizadas Redes Neurais Convolucionais com camadas bidimensionais de neurônios conhecidos como o *vencedor leva tudo*. Somente neurônios vencedores foram treinados; os outros esquecem tudo o que aprenderam embora possam ser afetados por mudanças de peso em camadas mais periféricas. Inspiradas em micro-colunas de neurônios do cortex cerebral, foram combinadas várias colunas de Redes Neurais Convolucionais para formar uma multi coluna. Através da utilização de GPUs eles

otimizaram o tempo de treinamento dessas redes. Com a implementação de código cuidadosamente modelado para GPUs permitiram um ganho de velocidade de 50-100 vezes em relação a computadores tradicionais. Como resultado, esta implementação pela primeira vez conseguiu um resultado competitivo com o reconhecimento humano em um grande conjunto de dados. Em muitos conjuntos de imagens o algoritmo melhorou o estado da arte em 30-80% (Ciresan et al. 2012).

Outro avanço notável do uso de Aprendizado Profundo na área de reconhecimento de imagens foi obtido na competição ImageNet LSVRC de 2012. A competição consiste de um treinamento baseado em 1.2 milhão de imagens em alta resolução, para então classificar 1000 diferentes classes de imagens desconhecidas. Logo após a divulgação dos resultados obtidos nessa competição, houve intenso estudo dessas arquiteturas em Visão Computacional (Deng, Yu 2013).

O feito em questão, alcançado por Krizhevsky et al. (2012), utilizou abordagens similares ao trabalho de Ciresan et al. descrito anteriormente, com o uso de Redes Neurais Convolucionais e GPUs para otimizar o tempo de treinamento dos conjuntos. Entretanto o reconhecimento em imagens realísticas, utilizadas nesse caso, exigem conjuntos de treinamento muito superiores que os dígitos escritos a mão ou sinais de trânsito. Os resultados alcançados mostraram que uma rede neural convolucional profunda é capaz de obter resultados fantásticos em conjuntos de dados utilizando puramente aprendizado supervisionado. Também foi observado que a retirada de uma única camada reduz a performance da rede, mostrando que a profundidade da rede é determinante para o alcance dos resultados. Avanços nos anos seguintes, utilizando melhorias em abordagem similares (Deng, Yu 2013) vêm comprovando quão promissor é a utilização de Aprendizado Profundo no reconhecimento de imagens.

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, VANTs, Agricultura de Precisão e Aprendizado Profundo. 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 e também para testar seu desempenho, conforme será descrito na seção 4.4., um banco de imagens será construído. Atualmente já há um banco de imagens construído a partir de fotografias em duas fazendas de Campo Grande, Bela Vista e São José, durante o período de Dezembro de 2014 a Março de 2015. As imagens foram capturadas a partir de um Veículo Aéreo Não Tripulado – VANT e fotografia manual, com as capturas realizadas com a frequência de 1 a 2 vezes por semana. Com apoio de especialistas, cada imagem será anotada, constituindo assim um conjunto de referência para análise de desempenho. O banco está disponibilizado através de link direto para uma conta Dropbox do grupo INOVISAO. Esse conjunto de imagens será dividido em classes de acordo com o objetivo deste trabalho. Atualmente as imagens estão separadas em 3 classes, solo, soja e capim marmelada, mas espera-se utilizar pelo menos mais uma classe para outro tipo de erva daninha. Exemplos de imagens similares às que serão utilizadas neste plano podem ser vistos na Figura 3.1.

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 e o software Weka versão 3.6. 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). O padrão de documentação de código é baseado no JavaDoc (mesmo para programas em C e C++). Vale-se ressaltar que para a utilização do Weka nos testes comparativos é necessário que esteja disponível a implementação de um algoritmo de Aprendizado Profundo para a ferramenta, implementação esta não disponível atualmente.

4.4. Validação do módulo

A implementação de Aprendizado Profundo utilizada neste trabalho será comparada com outros algoritmos conhecidos no estado da arte através do módulo *experimenter* do software Weka, 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 3.6 (HALL et al., 2009). Para cada algoritmo testado, serão calculados os desempenhos médios referentes às métricas de precisão, abrangência, medida-F, área sob a curva ROC e taxa de acerto ajustadas para problemas com mais de duas classes. 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, 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 da área de Visão Computacional. 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.

Em resumo, as seguintes atividades serão realizadas:

1. Aprofundamento e atualização da revisão de literatura
 1. Estudar artigos sobre Visão Computacional e sua aplicação na agricultura,
 2. Estudar artigos sobre VANTs e sua utilização na agricultura.
 3. Estudar artigos sobre agricultura de precisão.
 4. Estudar artigos sobre Aprendizado Profundo (Deep Learning).
2. Construção de um banco de imagens da lavoura de Soja
 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. Aprofundamento no aprendizado da área de pesquisa.
4. Implementação do algoritmo utilizando Aprendizado Profundo.
5. Validação do módulo.
6. Registro e divulgação de resultados.

5. ATIVIDADES E CRONOGRAMA DE EXECUÇÃO

Atividade	Trimestre de 2015				Trimestre de 2016			
	01	02	03	04	01	02	03	04
Atividade 1.1.:Estudar artigos sobre Visão Computacional e sua aplicação na agricultura,	X							
Atividade 1.2.: Estudar artigos sobre VANTs e sua utilização na agricultura	X							
Atividade 1.3.: Estudar artigos sobre agricultura de precisão	X							
Atividade 2.1.: Construção de um banco de imagens da lavoura de Soja	X	X						
Atividade 3: Aprofundamento no aprendizado da área de pesquisa		X	X					
Atividade 4: Implementação do algoritmo utilizando Aprendizado Profundo.			X	X				
Atividade 5: Validação do módulo.					X	X		
Atividade 6: Registro e divulgação de resultados.							X	X

6. RESULTADOS ESPERADOS, PRODUTOS E AVANÇOS

Espera-se com este trabalho ajudar a evolução da agricultura de precisão no Brasil, mais especificamente no estado do Mato Grosso do Sul, aumentando a produtividade e reduzindo as perdas causadas pelas ervas daninhas na cultura de soja, um dos produtos mais importantes para o agronegócio brasileiro. Rizzardi e Fleck (2004) citam que o conhecimento da infestação é um procedimento fundamental para a utilização de medidas preventivas no controle das ervas daninhas e foca na importância de dispôr-se de métodos que realizem a quantificação e análise da distribuição da infestação de ervas daninhas de forma rápida e econômica, evidenciando a necessidade de um método mais prático que a realização de observações sistemáticas das lavouras. As novas tecnologias abordadas neste trabalho representam uma alternativa que visa a diminuição de custos com monitoramento humano frequente para detectar a infestação de ervas daninhas, além de maior precisão e alcance de monitoramento obtida através do uso de VANTs.

O Aprendizado Profundo proposto neste trabalho é uma técnica que vem se mostrando muito promissora nos mais diversos campos e com grande

potencial na área de Visão Computacional. Esta técnica vem obtendo êxito em resolver problemas que vinham resistindo às melhores soluções utilizando Inteligência Artificial por muitos anos. Entretanto, embora seja uma área muito promissora é também uma área muito recente cujo o verdadeiro potencial ainda não está completamente exposto. É esperado que o Aprendizado Profundo terá muito mais sucesso num futuro próximo devido ao fato de necessitar de pouca engenharia manual, podendo se beneficiar do aumento de capacidade de computação e dados (LeCun et al., 2015). Esse trabalho tenta pôr a prova a eficácia dessa técnica na detecção de imagens capturadas por VANTs e expandir os horizontes do desenvolvimento dessa área na pesquisa brasileira.

7. IMPACTOS E BENEFÍCIOS ESPERADOS PARA MATO GROSSO DO SUL

Esse trabalho propõe uma parceria entre a área Acadêmica e o setor privado do desenvolvimento de soja de Mato Grosso do Sul. Dada a importância do produto para a economia brasileira e sul-matogrossense, as perdas causadas pelo ataque de ervas daninhas na lavoura de soja representam um problema crítico a ser combatido. De acordo com dados do projeto SIGA MS (Famasul, 2014), na safra 2014/2015, houve infestação de plantas daninhas em todas as regiões de plantio do estado do Mato Grosso do Sul. Em algumas regiões a incidência de buva e capim amargoso alcançaram mais de 20% da área cultivada, na região central do estado chegando aos 30% de incidência de buva. O êxito na conclusão dessa pesquisa, que visa o auxílio ao combate às ervas daninhas, significa um avanço na agricultura de precisão no estado, conseqüentemente aumentando a produtividade e os ganhos dessa cultura.

Atualmente o grupo INOVISÃO, um grupo de pesquisadores e estudantes do Mato Grosso do Sul a qual essa pesquisa está vinculada, já possui vários de projetos como VANTAGRO e FISHCV, onde utiliza a Visão Computacional em aplicações de agronegócio e outras áreas relevantes para a região, visando a pesquisa e inovação em prol do desenvolvimento do estado. O sucesso econômico desse projeto também pode levar a uma maior aproximação entre o meio acadêmico e as empresas privadas, aumentando os investimentos do setor privado em pesquisa e inovação. Esta parceria ainda é relativamente baixa no Brasil mas apresenta um grande potencial a ser explorado.

8. REFERÊNCIAS BIBLIOGRÁFICAS

SILVA, A.C.; LIMA, E.P.C; BATISTA, H.R. **A Importância da Soja para o Agronegócio Brasileiro: uma Análise sob o Enfoque da Produção, Emprego e Exportação.** 2011.

Ministério da Agricultura. Disponível em <<http://www.agricultura.gov.br/vegetal/culturas/soja>>. Acesso em 03/04/2015.

Sistema IBGE de Recuperação Automática - SIDRA, <<http://www.sidra.ibge.gov.br/bda/tabela/listabl1.asp?c=1612>>. Acesso em 03/04/2015.

SoyStats - World Soybean Production 2013. Disponível em <<http://soystats.com/international-world-soybean-production/>>. Acesso em 04/04/2015.

PIERCE, F. J.; NOWAK, P. **Aspects of precision agriculture.** Advances in Agronomy, San Diego, v. 67, p. 1-85, 1999.

COELHO, A.M. **Agricultura de Precisão: manejo da variabilidade espacial e temporal dos solos e culturas.** Embrapa, Documentos 46, 2005.

PEÑA-BARRAGAN, J.M; KELLY, M; et al. **Object-base approach for crop row characterization in UAV images for site-specific weed management.** Proceedings of the 4th GEOBIA, p426, 2012.

DENG, L.; YU D. **Deep Learning Methods and Applications.** Foundations and Trends in Signal Processing, Vol. 7, 2013.

PRINCE, S. J. D. **Computer Vision: Models, Learning and Inference.** Cambridge University Press, 2012.

SHAPIRO, L; STOCKMAN, G. **Computer Vision.** Prentice Hall, 2000.

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

JAIN, R.; KASTURI, R.; SCHUNCK, B. **Machine Vision.** McGraw-Hill, 1995.

GUIJARRO, M.; PAJARES, G.; RIOMOROS, I; et al. **Automatic segmentation of relevant textures in agricultural images.** Computers and Electronics in Agriculture, p75-83, 2011.

BROSNAN, T; SUN, D. **Inspection and grading of agricultural and foodproducts by**

computervision systems – a review. Computers and Electronics in Agriculture, p193-213, 2002.

CHAVES, A.N.; CUGNASCA, P.S.; NETO, J.J. **Busca Adaptativa com Múltiplos Veículos Aéreos Não Tripulados.** Revista de Sistemas e Computação, Salvador, v2, n.1, p53-59, 2012.

LOGHITANO, G.A. **VANTs para sensoriamento remoto: aplicabilidade na aviação e monitoramento de impactos ambientais causados por acidentes com cargas perigosas.** Escola Politécnica da Universidade de São Paulo, 2010.

PRIMICERIO, J; GENNARO, S.F.; FIORILLO, E.; et al. **A flexible unmanned aerial vehicle for precision agriculture.** Springer, 2012.

SWAIN, K.C.; THOMSON, S.J; JAYASURIYA, H.P.W. **Adoption of an unmanned helicopter for low-altitude remote sensing to estimate yield and total biomass of a rice crop.** American Society of Agricultural and Biological Engineering, v53(1), p21-27, 2010.

GEBBERS, R. and ADAMCHUK, V.I. **Precision Agriculture and Food Security.** Science Vol. 327 , pp. 828-831, 2010.

ZHANG C.; KOVACS J. M. **The application of small unmanned aerial systems for precision agriculture: a review.** Precision Agriculture, v13, p693-712, 2012.

JOINT RESEARCH CENTRE; MONITORING AGRICULTURE RESOURCES. **Precision Agriculture: An Opportunity for EU Farmers.** 2014.

BONGIOVANNI R.; LOWENBERG-DEBOER J. **Precision Agriculture and Sustainability.** Precision Agriculture, v5, p359–387, 2004.

EMPRAPA SOJA. **Dinâmica das Plantas Daninhas e Práticas de Manejo.** Documentos 260, ISSN 1516-781X, 2005.

RIZZARDI, M.A.; FLECK, N.G. **Métodos de quantificação da cobertura foliar da infestação das plantas daninhas e da cultura de soja.** Ciência Rural, v. 34, n. 1, 2004.

Famasul. Disponível em <<http://famasul.com.br/public/area-produtor/5577-informativo-agricultura-dezembro-2014-edicao-n-2.pdf>>. Acesso em 24/06/2015.

Lisa LAB, **Deep Learning Tutorial.** University of Montreal, 2015.

AREL, I.; ROSE, D. C.; KARNOWSKI, T. P. **Deep Machine Learning – A New Frontier in Artificial Intelligence Research.** The University of Tennessee, IEEE Computational Intelligence Magazine, 2010.

CIRESAN, D.; MEIER, U.; SCHMIDHUBER, J. **Multi-column Deep Neural Networks for Image Classification**. 2012.

KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. **ImageNet Classification with Deep Convolutional Neural Networks**. Proceedings of Neural Information Processing Systems, 2012.

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

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

HALL, M.; FRANK, E.; HOLMES, G.; PFAHRINGER, et al. **The WEKA Data Mining Software: An Update**. SIGKDD Explorations, v. 11, n. 1, 2009.

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

LECUN, Y.; BENGIO, Y.; HINTON, G. **Deep Learning**. Nature, v. 521, p436-444 , 2015.