

# Aprendizagem Semi-Supervisionada Aplicada em Problemas de Classificação em Imagens de Cultura de Soja

Gabriel Kirsten Menezes RGA: 201735063

Junho 2017

*A cultura da soja apresentou um elevado crescimento nas últimas duas décadas e constitui uma importante matéria prima para diversos produtos alimentícios ao redor do mundo. O objetivo deste trabalho é utilizar Aprendizagem de Máquina Semi-Supervisionada aplicada em técnicas de Aprendizagem Profunda (Deep Learning) para realizar a identificação de problemas relacionados a culturas de soja, utilizando para isso, imagens coletadas a partir de RPAs (Sistemas de Aeronaves Remotamente Pilotadas). As técnicas de aprendizagem profundo aliadas a técnicas de Aprendizagem Semi-Supervisionada, irão auxiliar na automatização da extração de atributos para classificação de imagens, utilizando um conjunto de imagens rotuladas juntamente com imagens sem rótulo, o que aumenta o conjunto de treinamento, aumentando também, teoricamente, a eficiência do treinamento, além de reduzir o esforço na atividade manual de rotulamento das imagens.*

## 1 Antecedentes e Justificativas

A soja representa a principal *commodity* da agricultura brasileira, sendo a cultura que mais cresceu nas últimas três décadas, cultivada especialmente nas regiões Centro Oeste e Sul do Brasil (COLUSSI et al., 2016). A soja se firmou como um dos produtos mais destacados da agricultura nacional e na balança comercial sendo que na safra de 2014/2015, o Brasil colheu 96,2 milhões de toneladas. (CONAB, 2010) O relatório apresentado pela *Food and Agriculture Organization of the United States*, sobre as perspectivas da agricultura do Brasil de 2015 a 2024, afirma que o crescimento agrícola tem sido impulsionado pelo rápido aumento da eficiência na utilização dos fatores de produção. Somado a isso, a partir da política de modernização agrícola brasileira, foram substituídas as máquinas obsoletas entre meados de 1970 a 1990, tornando-se assim, o Brasil, um dos países com melhores desempenhos de produtividade (FAO, 2014). A rentabilidade no cultivo de soja é cada vez mais relacionada à ganhos de produtividade nas lavouras, ao ampliar a produtividade a cada ano, com uso de novas tecnologias, os produtores rurais conseguem fazer frente ao aumento de custos de produção, e assim, continuar alcançando a lucratividade na cultura (COLUSSI et al., 2016).

De acordo com Neumaier et al. (2000), para combater os problemas da soja, como nos ambientes de lavouras não existem condições ótimas, o produtor deve estar atento para que os problemas sejam detectados o mais rápido possível, detendo o conhecimento de como a lavoura cresce e se desenvolve, para que os problemas sejam solucionados a tempo. De acordo com o Informe Técnico da Aprosoja, Nº 111/2016<sup>1</sup>, em casos em que a carga de soja contém sementes de plantas daninhas que podem ser tóxicas, como é o caso de sementes Fedegoso (*Senna occidentalis*), há relatos de que empresas se recusando a receber cargas de soja, e perante isso a instituição orienta aos produtores o cuidado na colheita, manejo e condução da lavoura, sendo possível elimina-lo no ciclo da cultura agrícola, mostrando a importância no controle e manejo de plantas invasoras.

A Agricultura de Precisão está normalmente associada à utilização de equipamento de alta tecnologia empregado na avaliação ou monitoramento das condições numa determinada parcela de terreno, aplicando depois os diversos factores de produção em conformidade a situação apresentada,

---

<sup>1</sup>Disponível em: <http://www.aprosoja.com.br/download/informe-tecnico/2016-03-04-10-06-11informe-tecnico-111-presenca-da-plant-daninha-fedegoso-em-cargas-de-soja.pdf>

aumentando a produtividade e sua adoção só fará sentido se os benefícios econômicos daí decorrentes, forem superiores ao investimento necessário à sua adoção. Muitas vezes, os sistemas de monitoramento da produtividade possibilitam, por si só, a identificação destas limitações, permitindo corrigir os problemas e aumentar as produções no ano seguinte. (COELHO et al., 2004).

Para solução do problema, o Grupo de Pesquisa de Desenvolvimento e Inovação em Visão Computacional (INOVISAO)<sup>2</sup>, da Universidade Católica Dom Bosco (UCDB), tem buscado integrar a pesquisa, o desenvolvimento e a inovação para contribuir com o desenvolvimento do estado do Mato Grosso do Sul, através de projetos que utilizam Visão Computacional para aplicações no agronegócio e outras áreas relevantes, contando com parcerias entre instituições de pesquisa, agências de fomento e empresas do agronegócio.

Essa trabalho visa estudar e utilizar técnicas de Visão Computacional, mais especificamente o uso de Aprendizado Semi-supervisionado, no auxílio da automatização da extração informações relevantes das imagens de plantações de soja obtida pelos RPAs. Um gargalo em algoritmos baseados em algoritmos de CNN (Redes Neurais Convolucionais) é a atividade de rotular um conjunto de imagens a ser utilizado no treinamento, a aquisição e a rotulação de tais dados é um esforço caro e demorado. A aprendizagem Semi-supervisionada vem para tratar o problema de quando temos um largo conjunto de dados porém poucos exemplos rotulados (PAPANDREOU et al., 2015).

## 2 Objetivos

### 2.1 Geral

Utilizar técnicas de aprendizagem semi-supervisionada em problemas de classificação de imagens obtidas a partir de RPAs em culturas de soja.

### 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 Aprendizagem de Máquina, Visão Computacional e Agricultura de Precisão.
- Construção de um banco de imagens de lavouras de soja.
- Implementação do módulo de Aprendizagem Semi-Supervisionada.
- Validação do módulo implementado.
- Registro e divulgação dos resultados.

## 3 Revisão da literatura

### 3.1 Problemas relacionados a Soja

Fleck e Gilberto (2004) trazem como possíveis problemas que ocorrem em culturas de soja são pragas, doenças e impurezas decorrentes da colheita, o que pode acarretar em prejuízos para a lavoura à perda de qualidade, o que implica em aumento de custo de produção e diminuição do valor da lavoura, em decorrência da competitividade das plantas por luz, água, nutrientes e espaço.

---

<sup>2</sup>Link para o INOVISAO: [www.gpec.ucdb.br/inovisao](http://www.gpec.ucdb.br/inovisao)

### 3.1.1 Doenças da Soja

Segundo (HENNING et al., 2014) que apresenta o manual de identificação de identificação de doenças da soja, as principais doenças da cultura da soja, que já foram constatadas no Brasil, são causadas por bactérias, fungos, nematoides e vírus. Cada doença tem suas particularidades relacionadas a sintomas, condições de desenvolvimento e possuem um tratamento específico, as doenças também ocorrem por condições ambientais específicas, portanto podem variar de localidade e particularidades da safra atual.

As principais doenças que ocorrem no Brasil são as seguintes (HENNING et al., 2014):

- Doenças causadas por fungos: Antracnose (*Colletotrichum truncatum*); Cancro da haste (*Diaporthe aspalathi* e *Diaporthe caulivora*); Crestamento foliar de *Cercospora* e mancha púrpura (*Cercospora kikuchii*); Ferrugem (*Phakopsora pachyrhizi* e *P. meibomiae*); Mancha alvo e podridão radicular de *Corynespora* (*Corynespora cassiicola*); Mancha foliar de *Ascochyta* (*Ascochyta sojae*); Mancha foliar de *Myrothecium* (*Myrothecium roridum*); Mancha olho-de-rã (*Cercospora sojina*); Mancha parda (*Septoria glycines*); Mela ou requeima (*Rhizoctonia solani* AG1); Míldio (*Peronospora manshurica*); Tombamento e morte em reboleira de *Rhizoctonia* (*Rhizoctonia solani*); Tombamento e murcha de *Sclerotium* (*Sclerotium rolfsii*); Oídio (*Microspheera diffusa*); Mofo branco (*Sclerotinia sclerotiorum*); Podridão de carvão da raiz (*Macrophomina phaseolina*); Podridão parda da haste (*Cadophora gregata*); Podridão radicular de *Rosellinia* (*Rosellinia necatrix*); Seca da haste e da vagem (*Phomopsis* spp.); Podridão radicular de *Phytophthora* (*Phytophthora sojae*); Podridão vermelha da raiz (*Fusarium brasiliense*, *F. tucumanaiae*, *F. crassistipitatum*).
- Doenças causadas por bactérias: Crestamento bacteriano (*Pseudomonas savastanoi* pv. *glycinea*); Fogo selvagem (*Pseudomonas syringae* pv. *tabaci*); Pústula bacteriana (*Xanthomonas axonopodis* pv. *glycines*); Mancha bacteriana marrom (*Curtobacterium flaccumfaciens* pv. *flaccumfaciens*).
- Doenças causadas por vírus: Mosaico cálico (Alfalfa Mosaic Virus - AMV); Mosqueado do feijão (Bean Pod Mottle Virus - BPMV); Mosaico comum da soja (Soybean Mosaic Virus - SMV); Necrose da haste (Cowpea Mild Mottle Virus - CPMMV); Queima do broto (Tobacco Streak Virus - TSV);
- Doenças causadas por nematoides: Nematóide de cisto (*Heterodera glycines*); Nematóides de galhas (*Meloidogyne incognita* e *M. javanica*); Nematóide das lesões (*Pratylenchus brachyurus*); Nematóide reniforme (*Rotylenchulus reniformis*);

### 3.1.2 Plantas Invasoras na Soja

Segundo Gazziero et al. (2006), dentre os problemas da soja, as plantas daninha (ou invasoras) podem ser responsáveis por queda na produtividade, desde que a soja foi introduzida comercialmente no Brasil, o controle de plantas daninhas é uma das operações mais complexas e caras do sistema de produção, para o controle de cada espécie é necessário ser realizada a identificação da espécie, para que assim sejam tomadas medidas específicas, tarefa importante tanto para soja convencional quanto para soja geneticamente modificada. A diversidade de plantas daninhas em países tropicais como o Brasil é muito grande, porém algumas espécies se destacam nas lavouras.

As plantas daninhas mais facilmente encontradas nas lavouras brasileiras são (GAZZIERO et al., 2006):

- Família *Amaranthaceae* *Altemanthera tenella*; *Amaranthus deflexus*; *Amaranthus hybridus*; *Amaranthus spinosus*; *Amaranthus viridis*;
- Família *Asteraceae* (*Compositae*); *Acanthospermum hispidum*; *Acanthospermum australe*; *Ageratum conyzoides*; *Bidens* spp.; *Conyza* spp.; *Emilia sonchifolia*; *Galinsoga parviflora*; *Melampodium perfoliatum*; *Parthenium hysterophorus*; *Porophyllum ruderale*; *Senecio brasiliensis*; *Siegesbeckia orientalis*; *Sonchus oleraceus*; *Tridax procumbens*;

- Família Brassicaceae; Coronopus didymus; Raphanus raphanistrum;
- Família Commelinaceae; Commelina benghalensis;
- Família Convolvulaceae; Ipomoea grandifolia; Ipomoea nil; Ipomoea purpúrea;
- Família Euphorbiaceae; Chamaesyce hirta; Chamaesyce hyssopifolia; Croton glandulosus; Euphorbia heterophylla; Phyllanthus tenellus;
- Família Fabaceae; Desmodium tortuosum; Senna obtusifolia;
- Família Lamiaceae; Hyptys suaveolens; Leonotis nepetifolia; Leonurus sibiricus;
- Família Malvaceae; Sida rhombifolia;
- Família Poaceae; Brachiaria brizantha; Brachiaria decumbens; Brachiaria plantaginea; Cenchrus echinatus; Chloris spp.; Digitaria spp.; Digitaria insularis; Echinochloa colonum; Eleusine indica; Panicum maximum; Pennisetum setosum; Rhynchelytrum repens; Setaria geniculata; Sorghum halepense;
- Família Portulacaceae; Portulaca oleracea; Talinum paniculatum;
- Família Rubiaceae; Richardia brasiliensis; Spermacoce latifólia;
- Família Sapindaceae; Cardiospermum halicacabum;
- Família Solanaceae; Nicandra physaloides; Solanum americanum;

### 3.2 Redes Neurais Convolucionais (CNN)

O estudo da Neurociência Computacional, é o estudo do funcionamento das redes neurais. As redes neurais consistem na construção de modelos matemáticos que reproduzam atividades cerebrais, e de forma inversa, pensar como o funcionamento do cérebro pode ajudar a estender o âmbito das ideias técnicas. Desde 1943 têm sido desenvolvido modelos muitos mais detalhados e realistas, as redes neurais permanecem uma das formas mais populares e eficazes de aprendizagem do sistema e são dignas de estudo (RUSSELL; NORVIG, 2009). O neurônio artificial foi concebido matematicamente utilizando hipóteses adotadas pela neurofisiologia teórica, é composto por partes como o Soma e Axônios, sua adjunções são chamadas de Sinapses e ligam a Soma de um nerônio com a Soma de outro, possibilitando assim estabelecer-se uma rede. Os neurônios possuem também limiares, onde o estímulo aplicado, deve excede-lo para que o neurônio inicie o impulso. Ao entender o funcionamento destas células cerebrais básicas foi possível criar um modelo altamente simplificado de um neurônio (MCCULLOCH; PITTS, 1943). Este neurônio será chamado neste trabalho de neurônio MCP. O modelo matemático proposto pelo neurônio MCP tem a saída descrita pela seguinte equação (RUSSELL; NORVIG, 2009):

$$in_j = \sum_n^{i=0} w_i, a_i \quad (1)$$

Aplicando a função de ativação  $g$  na saída:

$$a_j = g(in_j) = g \sum_n^{i=0} w_i, a_i \quad (2)$$

Dado as limitações dos neurônios MCP, foi concebido um modelo chamado de *perceptron* em 1957 no *Cornell Aeronautical Laboratory*, que consiste em uma rede neural *feedforward* (com alimentação para frente), um classificador linear que possa resolver problemas linearmente separáveis, o modelo consiste em um neurônio MCP possui entradas que passam primeiramente através de alguns pré-processadores, que são chamados de unidades de associação. Estas unidades de associação detectam a presença de determinadas características específicas nas entradas. Como o nome sugere,

um *perceptron* foi concebido para ser um dispositivo de reconhecimento de padrões, e as unidades de associação correspondem a detectores de características ou padrões (ROSENBLATT, 1958). Porém, muitos problemas são não-lineares, necessitando de uma rede com mais de uma camada de neurônios em alimentação direta, que são chamadas de *perceptron* multicamadas (RUSSELL; NORVIG, 2009).

Um estudo realizado entre os anos de 1950 e 1960 mostrou que o cortex visual de gatos e macacos possui neurônios que respondem individualmente a pequenas regiões do campo visual. O estudo identificou dois tipos de células visuais no cérebro, as simples, cuja saída é maximizada por bordas retas tendo orientações particulares dentro de seu campo receptivo e as complexas, que contém campos receptivos maiores, cuja saída é insensível à posição exata dos bordos no campo. (HUBEL; WIESEL, 1968). As CNN, modelam a percepção visual de um animal e pode ser aplicada a tarefas de reconhecimento de imagens.

O funcionamento das CNNs, que foram propostas por LeCun et al. (1990), são composta de uma entrada com uma imagem bidimensional de tamanho fixo, e uma saída composta por  $n$  números de saída, para  $n$  classes, no caso do problema abordado por LeCun, classificação de dígitos escritos a mão, eram 10 classes, implicando em 10 saídas. As camadas intermediárias da rede eram compostas por camadas de convolução e camadas de *subsampling*.

A convolução é uma operação matemática entre duas funções  $f$  e  $g$ , que produz uma terceira função, que pode ser interpretada como uma função modificada de  $f$ . No processamento de imagens, onde a imagem é definida como uma função bidimensional, a convolução é útil para muitas tarefas como: detecção de bordas, suavização de imagem, extração de atributos, entre outras aplicações. O funcionamento da convolução é realizado aplicando um núcleo (*kernel* ou no contexto de CNNs chamada por LeCun et al. (1990) de *weight vector*) que multiplica cada pixel da imagem (PARKER, 2011). Aplicando uma matriz de convolução (*kernel*) que pode ser vista na Imagem 1 pode-se chegar na Imagem 2.

Convolution Matrix			
	1	2	3
1	0	1	0
2	1	-4	1
3	0	1	0

Figura 1: Matriz de Convolução (*kernel*).

O resultado da convolução, mostrado pela imagem a direita da Figura 2, no contexto das CNNs, passa por uma função de ativação, como por exemplo as funções de ReLU (*Rectified Linear Unit*), que são neurônios com função de ativação definida como a não-linearidade na forma apresentada na Equação 3, o valor resultante é chamado por LeCun, Bengio et al. (1995) de *feature map*, é responsável pela identificação de padrões da imagem.

$$f(x) = \max(0, x) \quad (3)$$

As camadas de *pooling* são uma forma de *down-sampling*. Após a camada convolucional detectar padrões da camada anterior, o papel das camadas de *pooling* é fundir padrões semanticamente semelhantes em um, criando uma invariância para pequenas mudanças e distorções. Uma típica camada de *pooling* computa o máximo local de uma determinada região do *feature map*, como pode ser visto na Figura 3. Ao reduzir a dimensão da matriz, reduz também a complexidade computacional. (LECUN; BENGIO; HINTON, 2015).

A arquitetura de uma CNN, como visto anteriormente, é composta de diversas camadas, os primeiros  $n$  estágios são compostos de camadas de convolução e *max pooling*, que resultam em *feature*

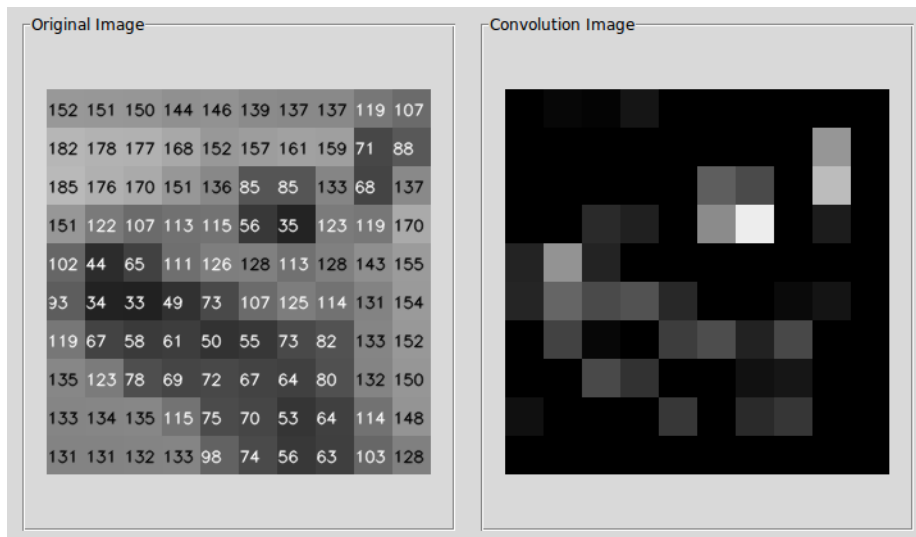


Figura 2: Imagem antes (esquerda) e após a convolução (direita).




Figura 3: Max pooling aplicado em uma imagem 4x4 utilizando um filtro 2x2. Além de reduzir o tamanho da imagem, consequentemente reduzindo o processamento para as próximas camadas, essa técnica também auxilia no tratamento de invariâncias locais.




Figura 4: Exemplo de aplicação de uma função de *down-sample* em uma imagem, uma das etapas de uma CNN, a esquerda temos a imagem em resolução original, a direita temos a imagem com a resolução reduzida.

*maps*, uma ilustração da arquitetura pode ser vista da Figura 5, (LECUN; BENGIO; HINTON, 2015).




Figura 5: Arquitetura tradicional das Redes Neurais Convolucionais. Os primeiros estágios são compostos de camadas de convolução e *pooling*. As últimas camadas são completamente conexas.

### 3.3 Aprendizagem de Máquina

Um sistema aprende quando melhora seu desempenho após realizar algum tipo de observação, e após essa observação, melhorar o seu desempenho. Existem 3 tipos de *feedback* para análise do desempenho no aprendizado, a aprendizagem não supervisionada, onde a tarefa mais comum é o agrupamento, aprendizagem por reforço, onde é realizado o treinamento com recompensas ou punições, e a aprendizagem supervisionada, onde é observada pares de entradas e saídas correspondentes (RUSSELL; NORVIG, 2009).

#### 3.3.1 Aprendizagem Semi-Supervisionada

Um aspecto insatisfatório na aprendizagem automática é que os dados não rotulados não tem valia para algoritmos de aprendizagem (CHAPELLE; SCHOLKOPF; ZIEN, 2006).

A Aprendizagem Semi-Supervisionada consiste em uma metodologia de aprendizado no meio do caminho entre a da aprendizagem supervisionada e a não supervisionada. O conjunto de treinamento pode conter exemplos de treinamento rotulados, porém não todo o conjunto necessita de um rótulo (BLUM; MITCHELL, 1998). O objetivo dessa aprendizagem, é dado um conjunto de dados não rotulados  $U$ , e um conjunto de dados rotulados  $L$  são obtidas as regras de predição com maior taxa de acerto do que somente com os dados de  $L$ . A ideia geral subjacente à aprendizagem semi-supervisionada é que os dados não rotulados, embora faltem os rótulos, contudo, muitas vezes contêm informações úteis (CHAPELLE; SCHOLKOPF; ZIEN, 2009).

Segundo Chapelle, Scholkopf e Zien (2009), existem 3 suposições para a aplicação da Aprendizagem Semi-Supervisionada, os algoritmos utilizam pelo menos uma destas estruturas para a distribuição subjacente dos dados:

- **Suposição da suavidade**

Pontos que estão próximos uns dos outros são mais propensos a compartilhar um rótulo.

- **Suposição do conjunto**

Os dados tendem a formar clusters discretos, e pontos no mesmo cluster são mais propensos a compartilhar um rótulo

- **Suposição da Variação**

Os dados (de alta dimensão) são (aproximadamente) em um variação de baixa dimensão.

A aprendizagem semi-supervisionada pode-se utilizar de diversos métodos, listadas por Chappelle, Scholkopf e Zien (2009) incluindo, mas não se limitando a:

- **Modelos generativos**

A inferência usando um modelo generativo envolve a estimativa da densidade condicional  $p(x|y)$ . Embora nem todos os métodos sejam probabilísticos, é mais fácil procurar métodos que representam hipóteses por  $p(y|x)$  e os dados não rotulados por  $p(x)$ , onde a probabilidade de um dado não rotulado  $x$  tem de pertencer a um conjunto de rotulo  $y$ . A aprendizagem semi-supervisionada com modelos generativos pode ser vista como uma extensão da aprendizagem supervisionada (classificação de  $p(x)$ ) ou como uma extensão da aprendizagem não supervisionada (agrupamento de mais alguns rótulos).

- **Métodos com base em grafos**

Os métodos semi-supervisionados podem ser baseados em grafos, onde é definido um grafo em que os nós são rotulados e exemplos não rotulados no conjunto de dados, as arestas, que podem ter pesos representando o grau de semelhança do exemplo. Esses métodos geralmente assumem a suavidade do rótulo sobre o grafo. Os métodos de grafo são não paramétricos, discriminatórios e de natureza transdutiva.

## 4 Metodologia

Para cada um dos objetivos específicos listados na Seção 3, serão apresentados a seguir os aspectos metodológicos que nortearão a execução desta proposta.

### 4.1 Aprofundamento e atualização da revisão de literatura em técnicas de Aprendizagem de Máquina, Visão Computacional e Agricultura de Precisão

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 técnicas de aprendizagem de máquina, visão computacional e agricultura de precisão. Estes artigos serão revisados para complementar o texto apresentado neste plano de trabalho.

### 4.2 Construção de um banco de imagens de lavouras de soja

Para ajustar os parâmetros do módulo que será desenvolvido e também para testar seu desempenho, 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 Dezembro de 2016, as imagens foram capturadas a partir de um RPA. 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. Os atuais bancos de imagens contém imagens de cultivos de soja controlados, será interessante obter em novos bancos imagens a partir de culturas comerciais de soja. O novo banco de imagens será capturado a partir de um RPA de asa fixa, o eBee RTK<sup>3</sup>, equipado com uma câmera multiespectral Parrot SEQUOIA<sup>4</sup>, uma câmera voltada para captura de imagens agrícolas a partir de RPAs.

---

<sup>3</sup><https://www.sensefly.com/drones/ebee-rtk.html>

<sup>4</sup><https://www.parrot.com/us/Business-solutions/parrot-sequoia#parrot-sequoia->



### 4.3 Implementação do módulo de aprendizagem semi-supervisionada

O módulo desenvolvido será implementado utilizando Python e auxiliará no treinamento de redes neurais convolucionais, possivelmente será realizada a integração com um software PYNOVISAO já desenvolvido pelo grupo de pesquisa INOVISÃO, utilizando um *framework* para o auxílio na construção de uma rede neural convolucional e técnicas de aprendizagem semi-supervisionada.

### 4.4 Validação do Módulo

A implementação de Aprendizado Semi-supervisionada neste trabalho será comparada com outros algoritmos conhecidos no estado da arte, será realizada análises estatísticas para constatação da precisão do algoritmo. Como técnica de amostragem será adota a validação cruzada de 10 dobras com 10 repetições disponível no software Weka<sup>5</sup> na sua versão mais atual (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>6</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 Wolfe (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.
  - (a) Estudar artigos sobre Aprendizagem de Máquina.
  - (b) Estudar artigos sobre Visão Computacional e sua aplicação na agricultura.
  - (c) Estudar artigos sobre Agricultura de Precisão.
2. Construção de um banco de imagens da lavoura de Soja.
  - (a) 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 algoritmo utilizando Aprendizado Semi-Supervisionado.
4. Validação do Módulo.
5. Registro e divulgação dos resultados.

## 5 Cronograma

---

<sup>5</sup>O Weka é um software livre e gratuito disponível em <http://www.cs.waikato.ac.nz/ml/weka/>

<sup>6</sup>O software R está disponível em <http://www.r-project.org/>. Para o teste de Friedman com análise *post-hoc* é necessário instalar o software Gnu-R.

Atividade	Trimestre 2017				Trimestre 2018			
Atividade 1.a. Estudar artigos sobre Aprendizagem de Máquina.	X	X						
Atividade 1.b. Estudar artigos sobre Visão Computacional e sua aplicação na agricultura.	X	X						
Atividade 1.c. Estudar artigos sobre Agricultura de precisão	X	X						
Atividade 2.a. Construção de um banco de imagens da lavoura de Soja.			X	X				
Atividade 3. Implementação do algoritmo utilizando Aprendizagem Semi-Supervisionado				X	X	X	X	
Atividade 4. Validação do Módulo.							X	
Atividade 5. Registro e divulgação dos resultados.				X				X

## Referências

BLUM, A.; MITCHELL, T. Combining labeled and unlabeled data with co-training. In: **ACM. Proceedings of the eleventh annual conference on Computational learning theory**. [S.l.], 1998. p. 92–100. Citado na página 7.

CHAPELLE, O.; SCHOLKOPF, B.; ZIEN, A. Semi-supervised learning (chappelle, o. et al., eds.; 2006)[book reviews]. **IEEE Transactions on Neural Networks**, IEEE, v. 20, n. 3, p. 542–542, 2009. Citado 2 vezes nas páginas 7 e 8.

COELHO, J. C. et al. Agricultura de precisão. **Prefácio, Lisboa**, 2004. Citado na página 2.

COLUSSI, J. et al. O agronegócio da soja: Uma análise da rentabilidade do cultivo da soja no brasil. **Revista ESPACIOS| Vol. 37 (Nº 16) Año 2016**, 2016. Citado na página 1.

CONAB, C. N. D. A. Custos de produção agrícola: A metodologia da conab. p. 90, 2010. Citado na página 1.

FAO, F. A. O. **OECD-FAO Agricultural Outlook, 2015-2024**. [S.l.]: OECD, 2014. Citado na página 1.

FLECK, M. A. R.; GILBERTO, N. Métodos de quantificação da cobertura foliar da infestação de plantas daninhas e da cultura da soja1. **Ciência Rural**, SciELO Brasil, v. 34, n. 1, 2004. Citado na página 2.

FRIEDMAN, M. A comparison of alternative tests of significance for the problem of m rankings. **The Annals of Mathematical Statistics**, JSTOR, v. 11, n. 1, p. 86–92, 1940. Citado na página 9.

GAZZIERO, D. L. P. et al. **Manual de identificação de plantas daninhas da cultura da soja**. [S.l.]: Embrapa soja., 2006. Citado na página 3.

HALL, M. et al. The weka data mining software: an update. **ACM SIGKDD explorations newsletter**, ACM, v. 11, n. 1, p. 10–18, 2009. Citado na página 9.

HENNING, A. A. et al. **Manual de identificação de doenças de soja**. [S.l.]: Embrapa Soja, 2014. Citado na página 3.

HOLLANDER, M.; WOLFE, D. A. Nonparametric statistical methods. Wiley-Interscience, 1999. Citado na página 9.

HUBEL, D. H.; WIESEL, T. N. Receptive fields and functional architecture of monkey striate cortex. **The Journal of physiology**, v. 195, n. 1, p. 215–43, 1968. ISSN 0022-3751. Disponível em: <<http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=1557912&tool=pmcentrez&rendertype=ab>>. Citado na página 5.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, v. 521, n. 7553, p. 436–444, may 2015. ISSN 0028-0836. Disponível em: <<http://pages.cs.wisc.edu/~dyer/cs540/handouts/deep-learning-nature2015.pdf>><http://www.nature.com/doi/10.1038/nature145>>. Citado 2 vezes nas páginas 5 e 7.

LECUN, Y.; BENGIO, Y. et al. Convolutional networks for images, speech, and time series. **The handbook of brain theory and neural networks**, v. 3361, n. 10, p. 1995, 1995. Citado na página 5.

LECUN, Y. et al. Handwritten digit recognition with a back-propagation network. In: TOUTRETZKY, D. (Ed.). **Advances in Neural Information Processing Systems (NIPS 1989)**. Denver, CO: Morgan Kaufman, 1990. v. 2. Citado na página 5.

MCCULLOCH, W. S.; PITTS, W. A Logical Calculus of the Idea Immanent in Nervous Activity. **Bulletin of Mathematical Biophysics**, Springer, v. 5, n. 4, p. 115–133, 1943. ISSN 0007-4985. Disponível em: <<http://www.cse.chalmers.se/~coquand/AUTOMATA/mcp.p>>. Citado na página 4.

NEUMAIER, N. et al. Estádios de desenvolvimento da cultura de soja. **Estresses em soja. Passo Fundo: Embrapa Trigo**, p. 19–44, 2000. Citado na página 1.

PAPANDREOU, G. et al. Weakly-and semi-supervised learning of a deep convolutional network for semantic image segmentation. In: **Proceedings of the IEEE International Conference on Computer Vision**. [S.l.: s.n.], 2015. p. 1742–1750. Citado na página 2.

PARKER, J. R. Algorithms for Image Processing and Computer Vision. **Vasa**, p. 504, 2011. ISSN 14337851. Disponível em: <[www.wiley.com/go/jrparker](http://www.wiley.com/go/jrparker)>. Citado na página 5.

ROSENBLATT, F. The perceptron: A probabilistic model for information storage and organization in .... **Psychological Review**, v. 65, n. 6, p. 386–408, 1958. ISSN 1939-1471(Electronic);0033-295X(Print). Disponível em: <<http://psycnet.apa.org/journals/rev/65/6/386.pdf>><http://c53d1644-cd41-40df-912d-ee195b4a4c2b/Paper/p15420>>. Citado na página 5.

RUSSELL, S.; NORVIG, P. **Artificial Intelligence: A Modern Approach (3rd Edition)**. [S.l.: s.n.], 2009. ISBN 9780136042594. Citado 3 vezes nas páginas 4, 5 e 7.