



**UNIVERSIDADE FEDERAL DE MATO GROSSO
CÂMPUS UNIVERSITÁRIO DE RONDONÓPOLIS
INSTITUTO DE CIÊNCIAS AGRÁRIAS E TECNOLÓGICAS
PROGRAMA DE PÓS GRADUAÇÃO EM ENGENHARIA AGRÍCOLA**

HEDERSON DE SOUZA SABÓIA

**APRENDIZADO PROFUNDO APLICADO NA PULVERIZAÇÃO
SELETIVA EM TEMPO REAL PARA CONTROLE DE *Ipomoea spp.***

RONDONÓPOLIS - MT

2020



**UNIVERSIDADE FEDERAL DE MATO GROSSO
CÂMPUS UNIVERSITÁRIO DE RONDONÓPOLIS
INSTITUTO DE CIÊNCIAS AGRÁRIAS E TECNOLÓGICAS
PROGRAMA DE PÓS GRADUAÇÃO EM ENGENHARIA AGRÍCOLA**

HEDERSON DE SOUZA SABÓIA

**APRENDIZADO PROFUNDO APLICADO NA PULVERIZAÇÃO
SELETIVA EM TEMPO REAL PARA CONTROLE DE *Ipomoea spp.***

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Agrícola da Universidade Federal de Mato Grosso campûs Rondonópolis, como requisito para a obtenção do título de Mestre em Engenharia Agrícola.

Orientador: Prof. Dr. Renildo Luiz Mion

RONDONÓPOLIS - MT

2020



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DE MATO GROSSO
PRÓ-REITORIA DE ENSINO DE PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA

FOLHA DE APROVAÇÃO

TÍTULO: "APRENDIZADO PROFUNDO APLICADO NA PULVERIZAÇÃO SELETIVA EM TEMPO REAL PARA CONTROLE DE *Ipomoea spp.*"

AUTOR: MESTRANDO HEDERSON DE SOUZA SABÓIA

Dissertação defendida e aprovada em 21 de julho de 2020.

COMPOSIÇÃO DA BANCA EXAMINADORA

1. Doutor Renildo Luiz Mion (Presidente Banca / Orientador)
2. Doutor João Paulo Arantes Rodrigues da Cunha (Examinador Externo)
3. Doutor Roger Resmini (Examinador Externo)
4. Doutor Arthur Akira Mamiya (Examinador Externo)
5. Doutor Marcio Koetz (Examinador Suplente)

Rondonópolis, 21/07/2020.



Documento assinado eletronicamente por **ARTHUR AKIRA MAMIYA, Docente da Universidade Federal de Mato Grosso**, em 22/07/2020, às 11:29, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **RENILDO LUIZ MION, Docente da Universidade Federal de Mato Grosso**, em 22/07/2020, às 11:34, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **João Paulo Arantes Rodrigues da Cunha, Usuário Externo**, em 22/07/2020, às 12:34, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).

Documento assinado eletronicamente por **ROGER RESMINI, Docente da Universidade Federal de Mato Grosso**, em 23/07/2020, às 11:24, conforme horário oficial de Brasília, com fundamento no art.



6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site http://sei.ufmt.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **2664385** e o código CRC **F7F1829B**.

Referência: Processo nº 23108.047794/2020-24

SEI nº 2664385

Dados Internacionais de Catalogação na Fonte.

S117a Sabóia, Hederson de Souza.

APRENDIZADO PROFUNDO APLICADO NA PULVERIZAÇÃO
SELETIVA EM TEMPO REAL PARA CONTROLE DE Ipomoea spp. /
Hederson de Souza Sabóia. -- 2020

65 f. ; 30 cm.

Orientador: Renildo Luiz Mion.

Dissertação (mestrado) - Universidade Federal de Mato Grosso, Instituto
de Ciências Agrárias e Tecnológicas, Programa de Pós-Graduação em
Engenharia Agrícola, Rondonópolis, 2020.

Inclui bibliografia.

1. Redes Neurais Convolucionais. 2. Agricultura de Precisão. 3. Plantas
Daninhas. I. Título.

Ficha catalográfica elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).

Permitida a reprodução parcial ou total, desde que citada a fonte.

A minha família, pelo apoio,
incentivo e motivação.

Dedico

AGRADECIMENTOS

A Deus, pela sabedoria, força, saúde e paciência concedidos para a conquista dos meus objetivos.

A todos os meus familiares pelo apoio e toda força para conclusão desta etapa em minha vida, em especial meus pais e irmãos.

Ao meu orientador Prof^o. Dr. Renildo Luiz Mion pelas pela paciência, confiança, orientação, apoio e conselhos que contribuíram para minha formação profissional e pessoal ao longo desta jornada.

Ao prof. Dr. Arthur Akira Mamyia pela “co-orientação” neste estudo e auxílio no desenvolvimento dele.

A todo grupo de pesquisa Smart Agriculture pela ajuda, colaboração e todo apoio no desenvolvimento deste projeto.

A todos meus amigos que sempre me apoiaram e contribuíram diretamente no direcionamento da minha trajetória profissional, em especial à Melkezedeqe Alves Lira, Bency G. Simeon, Cristhian Matheus Alves Reis.

A todos os colegas de pós-graduação pelos momentos de descontração, conselhos e auxílio ao longo do curso.

A todos que contribuíram direta ou indiretamente no desenvolvimento, execução de conclusão deste projeto e desta etapa da minha vida, meu muito obrigado!

RESUMO

A cultura da soja e algodão tem grande importância no cenário econômico brasileiro, ambas são commodities que movimentam bilhões de reais por ano em exportação. Essa importância, pode ser observada no aumento na produção e em áreas plantadas ano após ano, mantendo o país entre os maiores produtores do mundo de ambas culturas. O manejo de plantas daninhas é uma das operações importantes para se obter ótimas produtividades. Entretanto, devido o uso incorreto de métodos de controle, principalmente de herbicidas, tem provocado resistências de alguns biotipos aos princípios ativos mais comercializados popularmente. Entre as plantas que vêm obtendo resistência/tolerância, estão as do gênero *Ipomoea spp.* Mais popularmente conhecida como corda-de-viola. Estas plantas afetam as culturas de soja e algodão em todo seu ciclo, afetando sua produtividade. Neste contexto, o objetivo deste trabalho foi avaliar a implementação de dois algoritmos de detecção de objetos em tempo real (Faster R-CNN e YOLOv3), e desenvolver um sistema embarcado para pulverização seletiva de herbicidas em plantas de corda-de-viola nas culturas de soja e algodão, no Cerrado Mato-Grossense. O projeto foi desenvolvido no laboratório de Máquinas Agrícolas da Universidade Federal de Rondonópolis. Os algoritmos foram treinados para detecção de três classes (Soja, corda-de-viola e algodão) e avaliados em termos de precisão e sensibilidade em laboratório e em campo. Nos resultados de laboratório a precisão média do Faster R-CNN foi de 87,20% e sensibilidade 77,20 %, já o YOLOv3 tiny teve 81,16% de precisão média e 68,00% de sensibilidade. Já nos testes de campo o Faster R-CNN resultados superiores em comparação ao YOLOv3 tiny em ambos os módulos analisados, com média de controle de plantas daninhas de 81,70% na cultura do algodão e 77,00% na cultura da soja. O YOLOv3 tiny obteve resultados satisfatórios em campo, com resultados inferiores a 21,00% no controle de corda-de-viola, presente nos módulos. Os resultados no controle através das pulverizações do Faster R-CNN, demonstraram que algoritmos de detecção de objetos em tempo real para o controle seletivo de plantas daninhas de corda-de-viola em aplicação de herbicidas pós-ermegentes podem ser utilizados nas culturas de soja e algodão.

Palavras-chaves: Redes Neurais Convolucionais, Agricultura de Precisão, Plantas Daninhas.

ABSTRACT

The culture of soybean and cotton have great importance in the Brazilian economic scenario, both are commodities that move billions of reais per year in exports. The importance is demonstrated in the increased in planted areas and production year after year, keeping the country between the world's largest producers of crops. The weed management are of paramount importance, to achieve greater productivity year after year. However, due to the incorrect use of controls, mainly of herbicides, it has been causing resistance of some biotypes to the most popular active ingredients. Among the plants that have been representing resistance/tolerance are those of the genus *Ipomoea spp.*, most popularly known as Morning Glory. These plants affect soybean and cotton crops throughout their cycle, affecting their productivity. In this context, the object of this work was to evaluate the implementation of two object detection algorithms in real time (Faster R-CNN and YOLOv3), and to develop an embedded system for selective spraying of herbicides. Morning Glory plants in crops soybean and cotton, in the Cerrado Matogrossense. The project was developed at the Agricultural machinery laboratory of the Federal University of Mato Grosso, campus of Rondonopolis. The algorithms were trained to detect three classes (Soybean, Morning Glory and cotton) and evaluated in terms of precision and recall in the laboratory and field. The laboratory results of the Faster R-CNN algorithm showed results with an average accuracy of 87.20% and recall 77.20%, while the YOLOv3 tiny showed 81.16% accuracy and recall 68.00%. In the field tests, Faster R-CNN showed better results in comparison to YOLOv3 tiny in both modules analyzed, showing weed control average of 81.70% in cotton and 77.00% in soybean. The YOLOv3 tiny did not present satisfactory results in the field, presenting results less than 21.00% in the control of Morning Glory, present in the modules. The spray precision results of the Faster R-CNN demonstrate that object detection algorithms in real time for the selective control of post-emergent Morning Glory weeds in soybean and cotton crops.

Keywords: Convolutional Neural Networks, Precision Agriculture, Weeds.

LISTA DE TABELAS

Tabela 1- Pontos de melhores precisão média durante o treinamento de ambos os algoritmos e seus respectivos valores de Sensibilidade.	46
Tabela 2- Condições climáticas nos dias de realização das avaliações. Fonte: INMET Adaptado (2020).	47
Tabela 3 - Precisão dos algoritmos YOLOv3 tiny na detecção das classes de corda-de-viola, soja e algodão para ambos os módulos avaliados.....	49
Tabela 4- Sensibilidade do algoritmo YOLOv3 tiny em tempo real para as três classes avaliadas no estudo.....	49
Tabela 5- Médias dos resultados de precisão na detecção das 3 classes em ambos os módulos, em 10 repetições para o Faster R-CNN.	50
Tabela 6- Sensibilidade médio do algoritmo Faster R-CNN das 10 repetições nos módulos de avaliação, para as três diferentes classes.	52
Tabela 7 - Médias de Precisão e Sensibilidade das 10 repetições das avaliações dos algoritmos em campo, para cada classe a ser detectada.	52
Tabela 8- Precisão no controle de corda-de-violas nas culturas de soja e algodão em ambos os algoritmos avaliados no projeto.....	53
Tabela 9- Controle de corda-de-viola realizada pelo algoritmo YOLOv3 tiny, nos módulos de soja e algodão.	54
Tabela 10- Média de controle de corda-de-viola de ambos os algoritmos e módulos.	54

LISTA DE FIGURAS

Figura 1. Representação neurônio Matemático Simplificado.	22
Figura 2. Inteligência artificial e evolução dos seus campos.	23
Figura 3. Modelo da estrutura do Faster R-CNN. Fonte (Li et al., 2019).	28
Figura 4. Fotos de folhas de corda-de-viola (1a, 1b, 1c), algodão (2a, 2b, 2c) e soja (3a, 3b, 3c), em diversos ângulos, ambientes e condições climáticas utilizadas para formar o conjunto de dados de treinamento e testes da rede. Fonte: o autor.	29
Figura 5. Interface Labelimg, no momento da realização da rotulagem e marcação da localização da folha de corda-de-viola na imagem. Fonte: o autor.	30
Figura 6. A) visão frontal, B) visão traseira, C) visão lateral direita, D) visão lateral esquerda do protótipo de pulverizador seletivo desenvolvido em conjunto com o grupo Smart Agriculture.	35
Figura 7. Sistema de pulverização seletiva construído no protótipo de pulverizador seletivo.	36
Figura 8. Diagrama do sistema embarcado, mostrando a sequência das informações a serem transmitidas até a abertura da válvula solenoide.	37
Figura 9. Sistema embarcado protótipo de pulverização seletiva para controle de corda-de-viola.	37
Figura 10. Plantas de algodão semeadas em vasos para realização das avaliações em campo.	40
Figura 11. Croqui da área de avaliação dos algoritmos em campo.	40
Figura 12. Imagens dos módulos para avaliação dos algoritmos em campo.	41
Figura 13. Gráfico de perdas durante o treinamento da arquitetura do YOLOv3 após 3.100 iterações.	42
Figura 14. Gráfico de perdas durante o treinamento do incepton_v2 extrator de recursos utilizado no Faster R-CNN.	43
Figura 15. Gráfico de Precisão Média obtida no treinamento da rede do YOLOv3 tiny durante a etapa de treinamento, avaliado no conjunto de dados de teste.	44
Figura 16. Gráfico de Precisão média da rede incepton_v2 utilizada como extrator de recursos do algoritmo FASTER R-CNN durante a etapa de treinamento, avaliação no conjunto de dados testes.	45

Figura 17. Gráfico de sensibilidade para a rede inception_v2, utilizada como extrator de recursos do algoritmo Faster R-CNN durante a etapa de treinamento, obtida no conjunto de dados de testes.	45
Figura 18. Gráfico de sensibilidade média algoritmo YOLOv3 tiny durante o treinamento, obtidos no conjunto de imagens de teste.	46
FIGURA 19. Na imagem (a) a única folha de algodão detectado, (b) folhas não detectadas e (c) folha detectada incorretamente pelo YOLOv3 tiny no momento das avaliações.	48
Figura 20. Imagens das câmeras durante repetições em campo (a) detecção de folha de soja de maneira incorreta e correta, (b) e (c) folhas de soja detectadas e não detectadas pelo algoritmo YOLOv3 tiny.	49
Figura 21- (a) e (b) incidência de alta luminosidade nas plantas de algodão no momento das avaliações, provocando a não detecção e detecção incorreta das folhas pelos algoritmos, e (c) embaçamento da imagem no momento de ajuste focal da câmera.	50
Figura 22. (a), (b) e (c) Detecções de folhas de algodão; (d), (e) e (f) folhas de corda-de-viola; e (g), (h) e (i) folíolos de soja realizados pelo algoritmo Faster R-CNN.	51

SUMÁRIO

1.	INTRODUÇÃO	13
2.	REVISÃO DE LITERATURA	15
2.1.	Plantas daninhas	15
2.2.	Corda-de-viola (<i>Ipomoea spp.</i>)	17
2.3.	Controle de plantas daninhas	18
2.4.	Tecnologias de aplicação em taxas variáveis	20
2.5.	Redes neurais artificiais	21
2.6.	Aprendizado Profundo	23
2.7.	Redes Neurais Convolucionais	24
2.8.	Transferência de aprendizagem	25
3.	MATERIAIS E MÉTODOS	27
3.1.	Algoritmo Faster R-CNN	27
3.2.	Algoritmo YOLOv3	28
3.3.	Aquisição de imagens	29
3.4.	Treinamento das redes	31
3.4.1.	Treinamento YOLOv3	31
3.4.2.	Treinamento Faster R-CNN	32
3.5.	Avaliação das redes no treinamento	32
3.6.	Avaliações em campo	34
3.7.	Protótipo de pulverizador	34
3.7.1.	Estrutura	34
3.7.2.	Sistema de Pulverização	35
3.8.	Sistema embarcado	36
3.8.1.	Descrição dos componentes utilizados no sistema embarcado:	38
3.8.2.	Funcionamento do sistema	38
3.9.	Vazão do sistema de pulverização	39
3.10.	Metodologia para avaliação em campo	39
4.	RESULTADOS E DISCUSSÃO	42
4.1.	Resultados de Treinamento	42
4.2.	Avaliações em Campo	47
4.3.	Resultados de pulverização	53
5.	CONCLUSÃO	55

6.	REFERÊNCIAS BIBLIOGRÁFICAS	56
-----------	---	-----------

1. INTRODUÇÃO

A soja e o algodão se destacam no cenário mundial como duas das principais culturas de interesse econômico. De acordo com dados do Departamento de Agricultura dos Estados Unidos (USDA) a produção mundial de soja na safra 2018/2019 foi de 362,075 milhões de toneladas, e do algodão de aproximadamente 26,15 milhões de toneladas (CONAB, 2019).

No Brasil, um dos maiores produtores das duas commodities, tem se observado uma intensificação no sistema produtivo buscando-se melhores rendimentos e lucratividade, (CONAB, 2019). Para se alcançar melhores produtividades e rendimentos, além de condições climáticas favoráveis, é necessário realizar de forma correta o manejo cultural. Dentre as operações, o manejo de plantas daninhas representa um dos mais importantes a serem realizados, tendo em vista os impactos negativos que elas ocasionam seja na produtividade de ambas as culturas, e/ou na qualidade da fibra de algodão, além de influenciar nos custos de produção.

Atualmente ha uma predominância no uso de herbicidas como ferramenta no controle de plantas daninhas devido a ser menos eficiente, oneroso e seletivo a algumas culturas quando comparado a outros métodos, na realização do controle pré e pós-emergente de plantas daninhas em grandes áreas.

Porém, o uso inadequado de herbicidas traz consigo implicações em maior consumo de agrotóxico, maiores gastos com insumos e podem resultar na maior contaminação do solo e recursos hídricos por produtos químicos. Além de propiciarem a seleção de biótipos de plantas daninhas resistentes e/ou tolerantes ao mesmo, quando utilizado somente um princípio ativo durante várias safras consecutivas.

Entre as plantas daninhas com maior ocorrência e que tem apresentado resistência ao controle químico em algumas lavouras de Mato Grosso, destaca-se a corda-de-viola (*Ipomoea spp.*) (PICINNI, 2018). Estas plantas são trepadeiras, e afetam diversas culturas, diminuindo a produtividade e qualidade final do produto colhido. A resistência dessas plantas daninhas a algum princípio ativo de herbicida demanda alteração nos métodos de controle, elevando os custos da operação.

No entanto, o emprego de tecnologias de agricultura de precisão como o sensoriamento remoto em tempo real, possibilita o aumento da eficiência, evitam os desperdícios de insumo e

consequentemente auxiliam na redução dos custos operacionais e impactos ambientais. Dentre os sensores mais utilizados para detecção em veículos terrestres, se encontram os espectrométricos, optoeletrônicos e os de imagens. Embora muito utilizados em pesquisas anteriores e até comercializados mundialmente como os sensores WeedSeeker®, GreenSeeker® (Trimble Agriculture, Sunnyvale, CA, EUA), os sensores espectrométricos e optoeletrônicos possuem desvantagem com relação aos de imagens, uma vez que possuem maior dificuldade em diferenciar às espécies de plantas daninhas e cultura.

A utilização de visão de máquina aliada a técnicas de inteligência artificial (IA) na detecção e classificação de plantas tem apresentado resultados satisfatórios. Seja no emprego de aprendizado de máquina e extratores de recursos mais simples (Pulido-Rojas *et al.*, 2016; Pulido *et al.*, 2017), a algoritmos de aprendizagem profunda como PARTEL *et al.*, (2019), que utilizaram YOLOv3 na detecção de plantas daninhas para pulverização seletiva, encontrando precisão geral acima de 70% em ambos os cenários avaliados, e Quan *et al.*, (2019) que utilizaram um modelo de algoritmo Faster R-CNN, na detecção de milho em vários estagios de desenvolvimento, alcançando 97,71%. Já TANG *et al.* (2017) utilizaram como técnicas de agrupamento k-means e redes neurais convolucionais na identificação de plantas daninhas obtendo precisão superior a 90%.

A tecnologia recente e suas aplicações como uma ferramenta de agricultura de precisão para detecção de plantas daninhas carece de novos estudos, a fim de verificar sua aplicabilidade e sua melhor forma de implementação. Diante do exposto, objetivou-se avaliar a aplicação de dois algoritmos de detecção de objetos (FASTER R-CNN e YOLOv3) em termos de precisão e sensibilidade em conjunto de imagens e em tempo real, e desenvolver um sistema embarcado de pulverização seletiva para o controle de *Ipomoea spp.* nas culturas de soja e algodão.

2. REVISÃO DE LITERATURA

2.1. Plantas daninhas

As plantas daninhas são categorizadas como plantas que se desenvolvem em local inadequado aos objetivos dos homens, interferindo de forma negativa nas culturas econômicas, tanto na produtividade, quanto na qualidade final dos produtos colhidos (VASCONCELOS *et al.*, 2012). Essas plantas não se diferem aparentemente de uma espécie cultivada em termos de ciclo fisiológico. Porém, apresentam características que dificultam seu controle dentre: capacidade de germinação em ambientes desfavoráveis, mudança de fase vegetativa para reprodutiva em curto espaço de tempo, grande produção e dispersão de propágulos, com alta viabilidade e longevidade (FONTES *et al.*, 2003). Segundo Beltrão (2000) as espécies que possuem este tipo de características são consideradas plantas daninhas nocivas. Já plantas que não apresentam essa rusticidade, principalmente em termos de crescimento e desenvolvimento em condições adversas, no caso, plantas domesticadas, que se tornam nefastas em algumas ocasiões, são consideradas plantas daninhas “comum”.

A importância dessas plantas na produção agrícola refere-se aos seus efeitos diretos na cultura, como o alto grau de interferência (ação da competição e alelopatia) e os efeitos indiretos como o aumento do custo de produção, dificuldade de colheita, depreciação da qualidade do produto além de hospedar pragas e doenças (KARAM, 2008). O termo interferência refere-se ao conjunto de efeitos sofridos por uma determinada cultura em decorrência da presença de plantas daninhas no ambiente comum (MEIRELLES *et al.*, 2016).

Todo ser vivo necessita de condições adequadas para expressar o seu máximo potencial, assim, a disponibilidade de recursos em quantidade suficiente é um fator primordial para o desenvolvimento e convivência harmônica entre os indivíduos em uma comunidade. Em um agroecossistema onde os recursos (água, oxigênio, gás carbônico, nutrientes, minerais, espaço físicos e radiação solar) disponíveis são limitados, e podem se tornar insuficientes para necessidades da planta à medida em que se desenvolve, quadro que pode ser agravado com presença de outras plantas no mesmo local, que necessitam dos mesmos fatores, gerando competição intra e interespecíficas (VASCONCELOS *et al.*, 2012).

As competições sejam intra ou interespecíficas, afetam o desenvolvimento de ambos os indivíduos. Porém, as plantas daninhas são menos afetadas devido às suas características que

lhes proporcionam uma melhor habilidade de competição. A habilidade de competitividade de uma espécie está relacionada à utilização eficiente dos recursos do meio no qual essa planta se encontra (RIZZARDI *et al.*, 2001). Espécies não domesticadas e nocivas tendem a extrair e acumular maior quantidade de nutrientes mesmo em condições adversas. Em condições de escassez de nutrientes e elevada saturação de alumínio, *Bidens pilosa* (picão-preto) e *Urochloa brizantha* (braquiarião) conseguiram extrair 274,32 e 204,75 mg de N por planta, superiores a cultura do milho na mesma condição com valores de 113,88 mg por planta, demonstrando a alta flexibilidade adaptativa e grande capacidade de extração de nutrientes em condições desfavoráveis (MELO *et al.*, 2015). Quanto mais semelhanças morfológicas e fisiológicas entre as espécies, mais intensa a disputa (SILVA & DURIGAN 2006).

Além da competição natural, determinadas espécies de plantas daninhas expelem compostos químicos no ambiente que podem influenciar no desenvolvimento da vegetação adjacente sendo este fenômeno de interferência denominado alelopatia. A liberação destes compostos denominados aleloquímicos pode ocorrer de várias maneiras (MARASCHIN-SILVA; AQUILA, 2006) seja por lixiviação, volatilização, exudação das raízes e decomposição de resíduos de algum tipo de vegetal que são capazes de interferir na germinação e no desenvolvimento inicial de certas espécies de plantas (VASCONCELOS, 2012).

A disponibilidade de dados com relação ao efeito quantitativo de plantas daninhas na produção é bastante limitada, uma vez que experimentos deste tipo são muito árduos e demorados, levando em considerações que as perdas variam a cada estação de crescimento devido a variação de ocorrência e severidade das pragas, onde apresentam diversos problemas em estimativas de dados de diversas culturas (OERKE,2006).

No entanto, é amplamente sabido que as perdas causadas por plantas daninhas excederam as perdas de qualquer categoria de pragas agrícolas, como insetos, nematóides, doenças, roedores etc. (ABOUZIENA, 2016). Em culturas graneleiras como feijão a diminuição no rendimento chega a 71 % (KOZLOWSKI *et al.*, 2002), na soja as perdas médias variam, de 37% (FLECK & CANDEMIL 1995), 58% (RIZZARDI *et al.*, 2003), e em alguns casos a perda total da lavoura. Essas perdas levam em consideração o conjunto de espécies, a densidade de plantas infestantes e ao período de convivência.

O conjunto de plantas e a predominância de espécies indesejadas varia de região para região em decorrência de diversos fatores, dentre eles clima, banco de sementes presentes no solo, além da variedade de biomas existentes.

2.2. Corda-de-viola (*Ipomoea spp.*)

As espécies de corda-de-viola pertencem à família da Convolvulaceae, composta por 55 gêneros e 650 espécies, sendo que destes somente seis gêneros são considerados infestantes: *Convolvulus*, *Dichondra*, *Evolvulus*, *Jacquemontia*, *Merremia* e a *Ipomoea*. (AZANIA *et al.*, 2011).

A *Ipomoea spp.* apresenta mais de 140 espécies distribuídas por todo país, sendo algumas espécies mais encontradas em regiões específicas e sendo raras em outras como *Ipomoea asarifolia*, que quase não são encontradas na região sul do Brasil. Elas são popularmente conhecidas como “campainha” dentre outros nomes regionais, mas principalmente por “corda-de-viola” (CONSTANTIN *et al.*, 2011), e possuem ciclo anual, ou seja, seu desenvolvimento e produção de sementes ocorrem dentro de um ano (AZANIA *et al.*, 2011).

As plantas de corda-de-viola são herbáceas e cerca de 74% apresentam caule trepador volúvel (sobem por enrolamento em outras plantas ou obstáculos), muito ramificado, crescendo apoiada ao solo. Já outras apresentam caule ereto e retilíneo, pouco ramificado, porém todos são cilíndricos, apresentando coloração verde podendo apresentar pigmentações ou colorações amareladas ou avermelhadas dependendo da espécie. Suas folhas possuem grande variabilidade no formato, na maioria são cordiformes (formato de coração), podendo ser alongadas ou como ponta de lança e no caso distinto da *Ipomoea quamoclit* apresentam forma de pena, lobadas e afilados. Já as flores são geralmente muito vistosas e intensamente coloridas, devido a isto grande parte das espécies são utilizadas como plantas ornamentais (CORREIA e KRONKA, 2010; GAZZIERO *et al.*, 2015; AZANIA *et al.*, 2011). As sementes viáveis mostram alta longevidade no solo podendo formar bancos permanentes de sementes.

Outras espécies, no entanto, podem ser consideradas infestantes em diversas culturas econômicas, devido à alta longevidade das sementes no solo, formando banco de sementes expressivos em alguns locais, sendo elas: *Ipomoea alba* L., *Ipomoea aristolochiifolia* G. Don, *Ipomoea asarifolia* (Desr.) Roem. e Schult., *Ipomoea cairica* (L.) Sweet, *Ipomoea carnea* Jacq., *Ipomoea fimbriosepala* Choisy, *Ipomoea hederifolia* L., *Ipomoea indivisa* (Vell.) Hallier f., *Ipomoea nil*(L.) Roth, *Ipomoea pes-caprae* (L.) R. Br., *Ipomoea purpurea* (L.) Roth, *Ipomoea quamoclit* L., *Ipomoea ramosissima* (Poir.) Choisy, *Ipomoea triloba* L. e *Ipomoea wrightii* A. Gray, *Ipomoea grandifolia* (MOREIRA e BRAGANÇA, 2011; BRIGHENTI, 2010;

OLIVEIRA JR. *et al.*, 2011; CORREIA e KRONKA JR., 2010). Estas plantas são de comum ocorrência em culturas anuais de verão (HENRIQUES *et al.*, 2015).

Devido as suas características de crescimento rápido e a capacidade de habitar em vários ambientes (FERREIRA & MIOTTO, 2009), estas culturas são encontradas em lavouras de hortifruti (MOREIRA e BRAGANÇA, 2011), cana-de-açúcar (CORREIA e KRONKA JR., 2010; AZANIA *et al.*, 2011), soja, algodão (CONSTANTIN, 2011) e cereais. As áreas que essas espécies predominam têm sua produtividade reduzida a cultura da cana-de-açúcar por exemplo, em competição com *Ipomoea hederifolia* obteve 34% de redução do número de final de colmos e 46% na produtividade (SILVA *et al.*, 2009), na cultura da soja a redução varia de 15,53%, chegando a 80% conforme a densidade de corda-de-viola (PICCININI *et al.*, 2018; PAGNONCELLI *et al.*, 2017). RIZZARDI *et al.* (2004) ressalta que a incidência e densidade de corda-de-viola têm aumentado substancialmente nos últimos anos afetando diretamente a cultura da soja.

De acordo com Correia & Kronka (2010), além dos prejuízos decorrentes da competição natural por água, luz, nutrientes e espaço, essas espécies provocam danos sérios no momento da colheita mecanizada dificultando o corte mecanizado, comprometendo o rendimento das colhedoras e a qualidade final do produto colhido. Além de servirem de hospedeiros alternativos para a mosca-branca, devendo ser monitoradas na cultura do algodão, a fim de não comprometer a qualidade da fibra (RODRIGUES & SILVA, 2018).

Outro fator importante é o processo evolutivo que essas espécies tiveram em algumas áreas, adquirindo mecanismos de competitividade e sobrevivência, a condições extremamente adversas. Em culturas de Soja transgênicas RR®, devido a utilização intensificada de glifosato, sem adoção de outros mecanismos de ação e o uso indevido da tecnologia Roundup Ready (RR®), levaram ao surgimento de biótipos resistentes ou tolerantes, sendo as plantas da família *Convolvulaceae*, especificamente o gênero *Ipomoea spp.*, pertencente a esse grupo de plantas resistentes (PICCININI *et al.*, 2018).

2.3. Controle de plantas daninhas

No controle de plantas daninhas diversos métodos entre preventivos culturais, físicos, químicos ou biológicos, podem ser empregados juntos ou separados. O emprego dos diferentes

métodos disponíveis de forma integrada, racional e preservando o meio ambiente é definido como manejo integrado de plantas daninhas (VICTORIA FILHO E CHIRSTOFFOLI, 2001; DA SILVA *et al.*, 2018). Porém, na agricultura moderna existe uma predominância na utilização do método químico, sendo o herbicida dominante no controle de plantas daninhas (CASTRO *et al.* 2011; HARKER & O'DONOVAM, 2013).

Este método geralmente é menos oneroso e mais eficaz para grandes áreas, se comparados a outros métodos, como de controle mecânico e manual que são pouco eficazes e de baixo rendimento (DE OLIVEIRA & BRIGHENTI, 2018). Outro fator relevante para o domínio do uso de herbicidas está relacionado ao fato de que os mesmos em alguns casos são seletivos a cultura. O desenvolvimento de cultivares de soja transgênicas resistentes ou tolerantes ao glifosato resultou em modificação na forma de realização dos manejos químicos, sendo as cultivares com a tecnologia Roundup Ready desenvolvida pela Monsanto, as mais plantadas e comercializadas (SCHIOSCHET & DE PAULA, 2008).

De acordo com Sarker *et al.* (2019) os herbicidas vêm de fato sendo empregado de forma excessiva e regularmente nos campos de maneira convencional há vários anos. Sendo responsável pelos maiores custos da produção agrícola devido a recomendações e utilização de doses superiores à necessárias no controle de pragas, doenças e plantas daninhas, elevando os custos de produção e podendo causar sérios danos ao meio ambiente (DAINESE *et al.*, 2004). Além disto Agostinetto *et al.* (2015) ressalta que a utilização de um único método continuamente pode reduzir sua eficiência, além de favorecer a seleção de populações resistentes e/ou tolerantes a ele constituindo em um sério problema. De acordo com Christoffoleti & López-Ovejero (2003), há relatos de seleção de populações resistentes aos mais diversos tipos de classes químicas e mecanismos de ação, principalmente do grupo químico das triazinas, dos inibidores de acetolactato sintase (ALS) e da acetil coenzima A carboxilase, além dos princípios ativos do glifosato.

Para reduzir tais problemas, a utilização de tecnologias de agricultura de precisão (AP) permite a aplicação de herbicidas conforme as necessidades específicas, e em taxa variáveis, evitando excessos e reduzindo os impactos ambientais, assim aumentando a lucratividade da produção (DE MORAES *et al.*, 2008).

A aplicação localizada de herbicidas pode ser realizada de duas formas distintas. Na primeira um sistema embarcado para detecção em tempo real é montado em um veículo e o

mesmo controla a pulverização. Na segunda, utiliza-se mapas de variabilidade gerados através dados de sensores no campo (STAFFORD e MILLER, 1996).

2.4. Tecnologias de aplicação em taxas variáveis

Na área de tecnologias de pulverização seletivas encontra-se um grande número de trabalhos e utilizando sensores óptico eletrônicos que medem intensidades de reflexão de bandas espectrais geralmente a refletância do espectro vermelho na faixa visível e do infravermelho próximo (NIR) na invisível, como no trabalho de Viliotti (2002) em que resistores dependentes de Luz (LDR) foram utilizados para detectar a presença de plantas daninhas ou somente o solo exposto, com resultado de 100% de acerto.

Esses tipos de sensores também são empregados em controladores de bicos disponíveis no mercado como WeedSeeker[®] (Trimble Navigation Limited[®]) que permite a pulverização de forma seletiva pela variação da refletância do infravermelho próximo das plantas e solos. Na sua segunda geração WeedSeeker2[®] lançada em 2020, conta dois sensores ópticos equipados com leitores de NDVI (Normalized Difference Vegetation Index) que de acordo com a Trimble[®] (2020) aumenta a eficiência na detecção e conseguindo não só diferenciar do solo como na geração anterior mais também de outra vegetação já implantada.

Outro sensor existente no mercado é o WEED-IT[®], com características diferente dos sensores anteriores que trabalham com a refletância da planta, este sensor trabalha com a fluorescência da clorofila em resposta a uma luz infravermelho próximo emitida de alta intensidade, diminuindo a interferência da refletância da área e melhorando a eficiência da operação (VISSER, R. & TIMMERMANS, 1996).

Atualmente controladores utilizando sensores de imagem e inteligência artificial vêm sendo desenvolvidos e comercializados como See & Spray[®] (Blue River technology) que através de seus programas de inteligência artificial realizam o processamento de imagens obtidas por câmeras utilizadas como sensor, detectam a presença de ervas daninhas em áreas de plantação de algodão e soja, permitindo uma pulverização mais seletiva (Blue River technology, 2020).

O emprego da visão de máquinas com aprendizado profundo é crescente nas pesquisas recentes para desenvolvimento de tecnologias de aplicação seletiva, trabalho como de Ferreira et al. (2017) que desenvolveram um software para detecção de plantas daninhas em culturas da

soja utilizando de redes convolucionais profundas e obteve precisão acima de 99% em seu estudo.

2.5. Redes neurais artificiais

As redes neurais artificiais (RNAs) são um conjunto de técnicas não paramétricas, que modelam a forma de processar as informações do cérebro humano (FERNEDA, 2006), sendo capazes de generalizar o conhecimento obtido para um conjunto de dados novos, além de extrair características não explícitas do conjunto de informações que são fornecidas como exemplo (GORGENS *et al.*, 2009).

Em um conceito mais abrangente, as RNAs são uma tecnologia de inteligência artificial com capacidade de incorporar métodos, de solucionar problemas, através de padrões pré-estabelecidos ou por análise de resultados, graças à habilidade do sistema de aprender (FREITAS *et al.*, 2011).

As RNAs surgiram através do modelo matemático de neurônio biológico de McCulloch e Walter Pitts em 1943, que provaram, que estas unidades de processamento binária são capazes de executar várias operações lógicas (MCCULLOCH & PITTS, 1943), baseado no funcionamento de aprendizagem do cérebro humano, que é composto por bilhões de neurônios. Estes neurônios são células formadas por três partes com funções específicas e complementares: corpo, dendritos e axônio (FERNEDA, 2006). Os neurônios estão conectados entre eles através de sinapses, formando uma grande rede, denominada rede neural.

As sinapses são conexões responsáveis por transmitir estímulos a outros neurônios podendo excitá-los ou inibi-los, mandando ou não comandos a células específicas em todo corpo humano (OLIVEIRA, 2005).

Um modelo de neurônio matemático pode ser visto na Figura 1. Neste modelo, os impulsos provenientes de outros neurônios são representados pelos sinais de entrada (x_m) que são excitados ou não pelos pesos sinápticos (w_{km}), onde k é o índice do neurônio em questão, e m se refere a sinapse no qual o peso sináptico se refere. Os pesos podem assumir valor negativo ou positivo, caso o mesmo seja inibitório ou excitatório, respectivamente (OLIVEIRA, 2005). Os valores referentes às entradas multiplicadas por seus respectivos pesos, são somados de forma ponderada pelo somador, posteriormente uma função de ativação define qual será a saída (y_k) do neurônio. Já o viés (bias) tem a capacidade de aumentar ou diminuir a entrada na função de ativação.

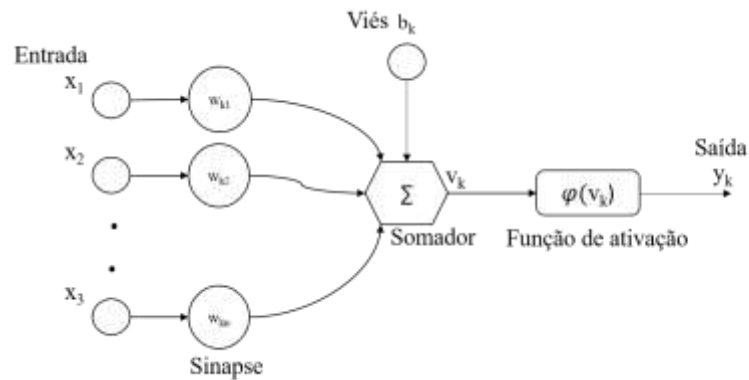


Figura 1. Representação neurônio Matemático Simplificado.

A representação matemática de um neurônio, pode ser expressa por uma função, como descrito na Equação 1:

Equação 1. Representação matemática de um neurônio artificial.

$$y_k = \varphi\left(\sum_{i=1}^m x_i w_{ki} + b_k\right) \quad (1)$$

De maneira mais simples, o neurônio matemático de uma rede neural artificial realiza a soma ponderada de várias entradas, aplica uma função para controlar a amplitude dos dados e passa o resultado adiante (FERNEDA, 2006).

Uma RNA é composta por vários neurônios distribuídos em camadas. Basicamente a primeira camada tem por função armazenar os dados de entrada. As camadas intermediárias ou “ocultas” como são popularmente denominadas, são as que realizam o processamento dos dados e a última camada recebe então os valores de saída da rede (SCHOENINGER *et al.*, 2009). O número de camadas, de neurônios em cada camada e a forma que são ajustados os pesos após o aprendizado varia de acordo com a arquitetura da rede neural.

Desde a concepção do neurônio biológico, diversas arquiteturas e modelos surgiram aplicando diferentes combinações entre os neurônios e técnicas matemáticas e estatísticas, o que proporcionou arquiteturas complexas de Deep Learning (Aprendizado Profundo), como Redes Convolucionais, Redes recorrentes, Auto Encoders, dentre outras existentes.

2.6. Aprendizado Profundo

Nas arquiteturas de aprendizado de máquinas padrão às quais redes neurais comuns se enquadram, os recursos devem ser extraídos e predefinidos manualmente. Somente após esta etapa os dados são fornecidos para a aprendizagem e classificação da rede, o que é relativamente demorado, afetando a precisão da previsão e torna o modelo menos flexível a alterações ou atualizações (AMIDI *et al.*, 2018). A superação dessas desvantagens ocorre por meio de técnicas de aprendizado profundo, que extraem recursos de forma contínua dos dados fornecidos como entrada, a extração através de métodos convencionais baseados em gradiente ou propagação de diferenças de ativação se faz se a interpretabilidade dos recursos for essencial (Shrikumar, Greenside & Kundaje, 2017) .

O Aprendizado profundo é um subconjunto do Aprendizado de máquina (do inglês “*Machine Learning*”), que é um subconjunto da Inteligência Artificial (IA), Figura 2. Portanto, aprendizado profundo é um dos campos de IA, e refere-se a RNA com mais de uma camada oculta, ou seja, multicamadas complexas (ABIODUN *et al.*, 2018).




Figura 2. Inteligência artificial e evolução dos seus campos.

O aprendizado profundo se diferencia pelas suas formas complexas em que as camadas se conectam, contendo um maior número de neurônios que as redes comuns conseguindo expressar modelos mais complexos, extraindo recursos de forma automática que exige um alto poder computacional para treinamento (ABIODUN *et al.*, 2018). O alto custo computacional

necessário é devido a grande quantidade de dados utilizados para treinamento e várias camadas ocultas em seu modelo para extrair as características mais efetivas, aumentando sua precisão (CHEN *et al.*, 2018).

As abordagens recentes usando, aprendizado profundo tem apresentado resultados satisfatórios em tarefas de classificação, segmentação, detecção de objetos e rastreamento de imagens (ZHOU *et al.*, 2019).

Dentre o grupo de algoritmos de aprendizagem profunda se encontram os auto-condensers, Deep Boltzmann machine (SALAKHUTDINOV & HILTON, 2009), redes neurais recorrentes, redes de memória longo prazo (do inglês Long Short-Term Memory Networks – LSTMs), redes de crenças profundas e redes neurais convolucionais. Estes visam o processamento de dados analógicos rotulados, como imagem, texto, áudio e vídeo. Sendo as redes neurais convolucionais as mais utilizadas atualmente em termos de processamento de imagem e vídeo, para classificação e detecção de objetos.

2.7. Redes Neurais Convolucionais

As redes convolucionais (do inglês “*Convolutional Neural Network*”, CNN) são os mais notáveis subtipo de arquitetura de aprendizagem profunda discriminativa, sendo poderosas para treinamento em dados multidimensionais com topologia tipo grade como imagens e vídeos, uma vez que foram projetadas para lidar com informações espaciais 2D (GUO *et al.*, 2016). Sua arquitetura é inspirada na organização do córtex visual (LIU, 2017) e diferentemente das RNAs comum, elas utilizam camadas conectadas localmente e não vetores para suas camadas ocultas, assim múltiplas camadas são treinadas de forma robusta. Se comparadas com as RNA padrão, as CNNs reduzem o número de pesos, através do compartilhamento de pesos em cada local da imagem (LITJENS *et al.*, 2019).

O principal intuito de uma CNN é criar uma hierarquia de recursos auto-aprendidos, que se baseiam em características menos abstratas das camadas anteriores (DYRMANN *et al.*, 2016). Em que várias convoluções se realizam em algumas camadas da rede, gerando representações gerais do conjunto de dados de treinamento nas camadas iniciais e à medida que as camadas se aprofundam, tornam as representações mais específicas. As convoluções então geram como saídas um mapa de recursos. Estes mapas podem se diferenciar dependendo do filtro aplicado e são posteriormente reduzidos pelas camadas de agrupamento.

As camadas convolucionais transformam então recursos de níveis inferiores, em mais discriminativos, ou seja, o recurso se torna mais complexo à medida que se aprofunda nas camadas, dentro do contexto classificação (KAMILARIS & PRENAFETA-BOLDÚ, 2018). De acordo com Reyes *et al.* (2015) podem ser entendidas como um conjunto de filtros que transformam a imagem de entrada em outra imagem, evidenciando padrões específicos.

Já as camadas de agrupamento (do inglês “*pool*”) realizam uma operação de redução espacial no mapa de recursos, originados nas camadas de convolução, através de uma amostragem máxima ou média da vizinhança, fornecendo uma forma de invariância de conversão (LONG *et al.*, 2017).

Uma rede CNN pode ser considerada um tipo de rede *feedforward*, tendo na sua arquitetura, várias camadas convolucionais intercaladas com camadas de agrupamento, de ativação e no final as camadas totalmente conectadas (ZHOU *et al.*, 2019). As camadas totalmente conectadas são as mesmas das RNAS comuns e tem a função de reduzir as informações dos mapas de recursos em uma previsão única (LITJENS *et al.*, 2019).

As características auto-aprendidas tornam essas redes menos afetadas por variações naturais como mudanças na iluminação, sombras, folhas tortas e plantas ocluídas, se comparado com outros métodos de classificação (DYRMANN *et al.*, 2016). Sendo reconhecida como altamente eficaz e o tipo de aprendizagem mais adotada em diversas aplicações de visão computacional (GUO *et al.*, 2016).

No campo das imagens de sensoriamento remoto, muitas experiências de detecção de objetos usam apenas modelos CNN pré-treinados em grandes conjuntos de dados. Sendo adequadas para tarefas de reconhecimento de classificação de imagens de objetos, reconhecimento de classificação de imagens de objetos, reconhecimento de cenas, reconhecimento de cenas, reconhecimento de baixa granularidade, detecção de atributos e recuperação de imagens aplicadas a um conjunto diversificado de conjuntos de dados (SHARIF RAZAVIAN *et al.* 2014).

2.8. Transferência de aprendizagem

Para se criar uma rede convolucional robusta para classificação e/ou detecção de objetos do zero, necessita-se de grandes quantidades de dados, e conseqüentemente de um grande poder computacional. A exigência de grande conjunto de dados é necessária, para que a máquina consiga extrair as características e realizar a aprendizagem de forma correta e precisa, nesse sentido, a rede necessita de inúmeros exemplos para ser treinada. Logo, quanto maior a

quantidade de dados a serem fornecidos para a rede, maior serão os custos de recursos computacionais (em termos de processamento e armazenamento). Em alguns casos o número de amostras de dados tende a ser escasso e o custo de coleta de dados relativamente caro ou inviável. Sendo então, desejável a aplicação de transferência de aprendizagem nessas hipóteses (LI *et al.*, 2019).

Assim a transferência de aprendizagem é uma técnica que visa reduzir o tempo gasto durante a etapa de treinamento e ao mesmo tempo suprir a falta de um grande conjunto de dados para o treinamento, “adaptando” um modelo treinado em um grande conjunto de dados para uma determinada tarefa, para outra tarefa de desejo (MENEGOLA *et. al.*, 2017). Ou seja, transferência de aprendizado visa extrair o conhecimento de uma ou mais tarefas de origem e aplicar o conhecimento em outra tarefa de destino (PAN & YAN 2010).

3. MATERIAIS E MÉTODOS

O projeto foi desenvolvido no laboratório de Máquinas e Mecanização Agrícola da Universidade Federal de Rondonópolis - UFR.

3.1. Algoritmo Faster R-CNN

O Faster R-CNN (REN *et al.*, 2016) é uma evolução do FAST R-CNN (Girshick 2015), trazendo melhorias em desempenho computacional da rede em termos de tempo de processamento e detecção em algoritmos de busca seletiva.

Neste algoritmo várias imagens são fornecidas como entrada na rede totalmente convolucional pré-treinada em que são extraído o mapa de recursos convolucionais. Posteriormente uma pequena rede convolucional denominada rede de proposta de região (do inglês “Region Proposal Network”, RPN), que faz uma varredura em cada local no mapa de recursos através de janelas deslizantes. Assim, m caixas de ancoragens correspondentes a 3 escalas (128, 256 e 512) x 3 proporções (1:1, 1:2, 2:1) são responsáveis por gerar as propostas de regiões. Uma camada de classificação é responsável por gerar $2m$ de pontuações, ou seja, tem ou não objeto em m caixas de ancoragens. Outra camada gera as $4m$ coordenadas das caixas delimitadoras do objeto na imagem (x,y,w,h).

Em seguida essas propostas de objetos em diferentes escalas e proporções passam juntamente com o mapa de recursos extraídos pela primeira rede convolucional por uma camada de redução de região de interesse (*ROI pooling*) que tem a função de padronizar em um tamanho fixo. Os dados padronizados seguem para duas ramificações das camadas totalmente conectadas (TC): uma função de classificação softmax (1) utilizada para prever o objeto observado nos vetores fornecidos a ela e as localizações das caixas delimitadoras foram ajustadas com uma regressão linear (2) (Figura 3).

Como várias caixas de ancoragens foram geradas na rede de proposta de região é aplicada uma supressão não máxima para evitar sobreposições nas detecções. A supressão não máxima determina um limiar para a probabilidade da caixa delimitadora que pode ser considerada como a correta, ou seja, só é mantida a caixa delimitadora que tiver probabilidade maior ou igual ao limiar de conter o objeto, evitando assim a duplicação nas detecções.

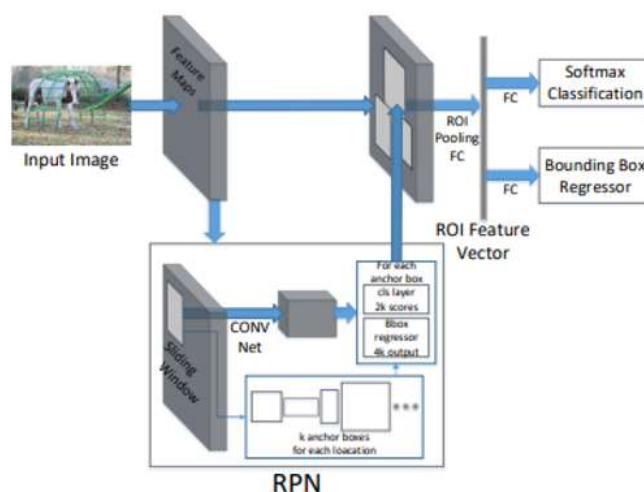


Figura 3. Modelo da estrutura do Faster R-CNN. Fonte (Li *et al.*, 2019).

3.2. Algoritmo YOLOv3

O YOLO (*You Only Look Once*) é um algoritmo de detecção de objetos em tempo real (REDMON & FARHADI, 2018), baseado em redes neurais convolucionais para detecção de vários objetos com boa capacidade de generalização e realizando previsões em vários locais na imagem simultaneamente, predizendo se o objeto pertence a uma classe ou não, de maneira otimizada que permite trabalhar em altas taxas de frames por segundo (FPS).

O algoritmo realiza a detecção de objetos dividindo as imagens fornecidas como entrada em grades $S \times S$. Se o centro do objeto cair no centro de uma célula de grade, esta célula é então responsável em prever a localização, uma pontuação de confiança e uma classe do objeto que a caixa delimitadora ou *bounding box* popularmente chamado pode conter usando a classificação dos rótulos treinados. Basicamente, cada célula de grade prevê 3 caixas delimitadoras que pode conter um objeto e em 3 escalas diferentes. Já para realizar a classificação dos rótulos, o YOLO não utiliza camadas totalmente conectadas (TC) e nem a função softmax comumente utilizadas por outras arquiteturas de redes e outros algoritmos de detecção de objetos como Faster R-CNN, mas utiliza regressão logística.

Além disto, na sua terceira versão o algoritmo não utiliza o erro quadrático médio no cálculo da perda de classificação, mas sim a perda de entropia cruzada binária para cada rótulo. A perda de entropia cruzada binária é uma perda de log utilizada para minimizar o erro de aprendizado durante o treinamento com ativação sigmoide para classificação de várias classes,

ao qual, para cada caixa âncora pode ter somente uma classe, porém cada objeto pode pertencer a mais de uma classe.

3.3. Aquisição de imagens

Foi criado um banco de imagens contendo folhas de soja, corda-de-viola e algodão, que são as classes com interesse em detectar. As imagens foram captadas com o auxílio de uma câmera semiprofissional Nikon P250 com resolução 4860x3672 pixels, em áreas da Universidade Federal de Rondonópolis e do Instituto Mato-grossense de Algodão (IMA) em Rondonópolis, com a cultura do algodão e soja plantados e com presença de corda-de-viola, em diversos horários do dia, com diferentes posições, a fim de representar as condições reais as quais os algoritmos foram expostos (Figura 4). A alta variabilidade e quantidade de imagens são fatores que auxiliam no processo de aprendizado de uma CNN, devendo corresponderem o mais próximo possível a sua aplicação real (OLSEN *et al.* 2019).




Figura 4. Fotos de folhas de corda-de-viola (1a, 1b, 1c), algodão (2a, 2b, 2c) e soja (3a, 3b, 3c), em diversos ângulos, ambientes e condições climáticas utilizadas para formar o conjunto de dados de treinamento e testes da rede. Fonte: o autor.

Foi realizado o pré-processamento das imagens redimensionando-as para 416 x 416 pixels, antes de realizar o treinamento das redes dos algoritmos. O banco de imagens criado continha 1.612 imagens de treinamento, destas 1.214 foram adquiridas em módulos das culturas plantados na UFR, e 398 foram obtidas no IMA. Deste total 708 imagens de folhas de corda-de-violão, 487 de algodão e 417 de soja, em que 10% das imagens foram escolhidas de forma aleatória para compor o conjunto de teste, com 162 imagens, dividido em 54 imagens de cada classe. As imagens variaram em relação ao número de folhas contidos em cada uma, com diferentes ângulos, formando um conjunto de dados com uma variabilidade representativa.

Após redimensionar o banco de imagens, foi realizado um processo de marcação e rotulagem de forma manual, com auxílio de um programa com interface gráfica conhecido como Labelimg disponível no repositório de Darrenl (2019)¹ (Figura 5).

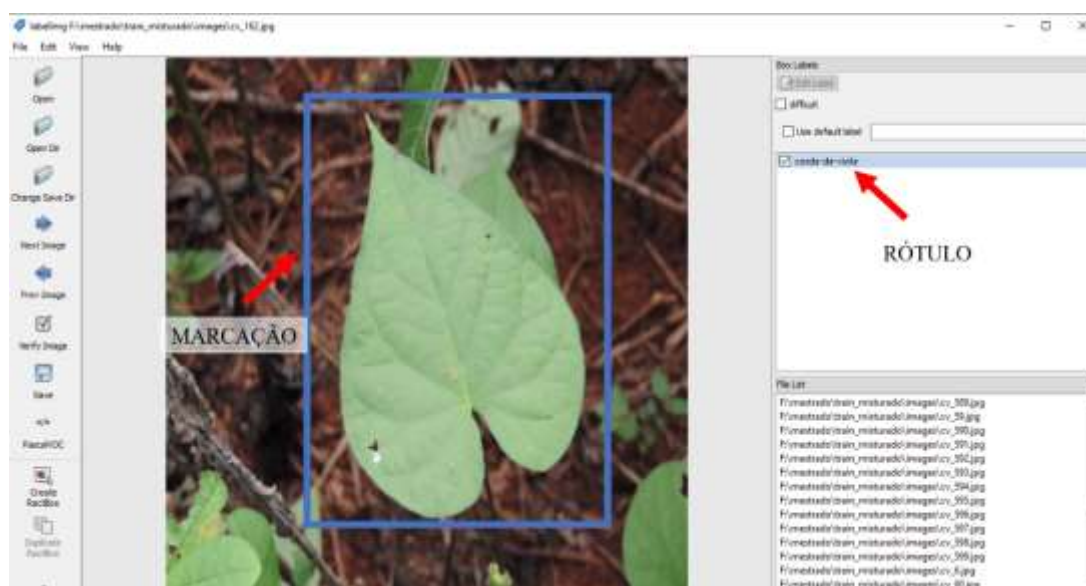


Figura 5. Interface Labelimg, no momento da realização da rotulagem e marcação da localização da folha de corda-de-violão na imagem. Fonte: o autor.

A marcação e rotulagem consistiu em demarcar a área em que cada uma das folhas se localiza na imagem e a qual classe ela pertencia através de um quadrado desenhado sobre ela, em que eram salvas em um arquivo xml com as coordenadas espaciais em pixel de cada vértice deste quadrado.

¹ DARREN, 2019. LabelImg, repositório Github, Disponível em < <https://github.com/tzutalin/labelImg>>. Acessado em: abril de 2019.

3.4. Treinamento das redes

O treinamento dos algoritmos foi realizado em um computador com as seguintes especificações: processador i7-8700 com 3.19 GHz, memória de 16 GB, placa de vídeo Geforce RTX 2070, com 8 GB de memória dedicada. As configurações do computador influenciam diretamente no tempo de treinamento, no tamanho da rede suportada e na velocidade de detecção em tempo real.

Neste estudo utilizou-se a versão com menor tamanho de arquitetura do YOLOV3, uma rede menor, mais rápida denominada YOLOv3 tiny, desenvolvida para hardwares com configurações médias, possibilitando atingir o objetivo com menor custo computacional, ao invés de utilizar o backbone YOLOV3, que possui maior número de camadas e parâmetros como arquitetura de rede. Devido a quantidade de memória disponível na GPU e a capacidade de processamento dos computadores utilizados no estudo optou-se pela versão YOLOv3 tiny.

3.4.1. Treinamento YOLOv3

As redes YOLO tiny possuem a vantagem de serem mais rápidas, embora percam em precisão em comparação com as redes YOLO (PARTEL *et al.*, 2019). A arquitetura YOLOV3 foi desenvolvido por Redmon & Farhadi (2018), e a implementação do programa utilizada neste estudo foi disponibilizada por Alexey (2019)² em um repositório online, utilizando pesos³ originais do YOLOV3 tiny.

Para a execução do treinamento, foi alterado o número de classes e lotes, filtros e os valores das caixas de ancoragem de acordo com o objetivo do nosso estudo. O número de classes de treinamento foi alterado para 3 e o número de lotes definidos foram de 64 divididos em 16 subdivisões com a taxa de aprendizado definida em 0,001. Já os filtros das camadas convolucionais foram alterados de acordo com a equação 2.

Equação 2- Cálculo da quantidade de filtros a serem aplicados sobre a imagem na rede do YOLOv3 tiny nas camadas de detecções.

$$\text{Filtros} = 3 \cdot (c + 5) \quad (2)$$

O c refere-se à quantidade de classes que será submetida a rede para ela aprender, neste estudo os filtros foram definidos em 24.

² ALEXEY, 2019. AlexeyAB: Darknet, repositório Github, Disponível em: < <https://github.com/AlexeyAB/darknet> > Acessado em: abril de 2019.

³ Disponível em: < <https://pjreddie.com/darknet/YOLO/> >, Acessado em: abril de 2019.

3.4.2. Treinamento Faster R-CNN

O Faster R-CNN (Ren et al., 2015), utilizado nesse estudo foi uma implementação disponibilizada por Evan (2019)⁴, e como sua rede utilizou-se a arquitetura de rede incepton_v2 pré-treinada disponibilizada Pkulzc (2019)⁵. Foram alteradas o número de classes a serem treinadas de acordo com YOLOV3 e a taxa de aprendizado foi de 0,0002. O modelo do Faster R-CNN deste projeto foi desenvolvido e executado na API object detection do tensorflow.

3.5. Avaliação das redes no treinamento

Para avaliações do treinamento e definição de qual o melhor ponto de verificação que seriam aplicados em campo, em ambos os algoritmos, aplicou-se as métricas precisão e sensibilidade de acordo com Fletcher & Suzanne (2005), Olson & Dursiun (2008), e a precisão média conforme o *benchmark* em detecção de objetos MS COCO (LIN *et al.* 2014) recomendadas para competições de detecções de objetos do COCO⁶. Assim as métricas IoU, precisão, sensibilidade e precisão média para ambos os casos foram aplicadas em conjunto sobre um banco de imagens testes para avaliação da rede durante o treinamento.

A validade da detecção de um objeto é calculada através da razão entre a interseção e a união das regiões delimitadas pelas caixas propostas (IoU):

Equação 3- Cálculo da Interseção da área, sobre a união das áreas de verdade do solo e geradas pelo algoritmo (REZATOFIGHI *et al.* 2019).

$$IoU(A, B) = \frac{|A \cap B|}{|A \cup B|} \text{ sendo } 0 \leq IoU(A, B) \leq 1 \quad (3)$$

O IoU demonstra a confiança das caixas delimitadoras previstas e os objetos são considerados corretos quando sua classe se coincidir com a classe esperada, e a sobreposição das caixas de delimitação forem maiores ou iguais a 50%, das caixas tidas como verdades (caixas demarcadas em imagens para teste). Está métrica não é avaliada diretamente, porém ela

⁴ EVAN, 2019. TensorFlow-Object-Detection-API-Tutorial-Train-Multiple-Objects-Windows-10. Repositório GitHub, Disponível em: <<https://github.com/EdjeElectronics/TensorFlow-Object-Detection-API-Tutorial-Train-Multiple-Objects-Windows-10>>. Acessado em: abril de 2019.

⁵ PKULZC, 2019. Tensorflow detection model zoo. repositório GitHub, Disponível em:<https://github.com/pkulzc/models/blob/master/research/object_detection/g3doc/detection_model_zoo.md>, Acessado em: abril de 2019.

⁶ Disponível em:< <https://cocodataset.org/#detection-eval>>, Acessado em: abril de 2019.

exerce um papel importante na determinação das outras métricas, devido ser a primeira realizada pelos algoritmos para definir se o objeto pode ser considerado válido na detecção.

Já a precisão representa a porcentagem de suas previsões estarem corretas, ou seja, a capacidade em classificar cada objeto pertencente a uma determinada classe de forma correta. Sendo o resultado da divisão dos objetivos detectados corretamente, pelo total dos objetos detectados para aquela classe.

Equação 4- Métrica precisão utilizada na avaliação dos algoritmos de detecção de objetos em tempo real (OLSON & DURSIUN, 2008, apud QUAN et al., 2019).

$$\text{Precisão} = \frac{VP}{VP + FP} \quad (4)$$

Em que:

VP (Verdadeiro positivo) é o número de objetos da classe previsto corretamente;

FP (Falso positivo) é o número de objetos que não pertenciam a classe e foram classificadas como a mesma;

A sensibilidade demonstra se a rede está conseguindo detectar todos os objetos da classe presente na imagem, quanto maior o resultado melhor.

Equação 5- Métrica sensibilidade utilizada para prever a quantidade de objetos por imagem detectados pelo algoritmo (OLSON & DURSIUN, 2008, apud QUAN et al., 2019).

$$\text{Sensibilidade} = \frac{VP}{VP + FN} \quad (5)$$

Em que:

FN (Falso Negativo) é o total de objetos que deveriam ser detectados e não foram.

Englobando as métricas anteriores, aplicou-se a precisão Média (MAP), que é calculada área de interpolação da curva gerada pela interação da precisão em 101 níveis de sensibilidade.

Equação 6 - Métrica de Precisão Média para avaliação dos algoritmos de acordo com MS COCO.

$$mAP = \frac{1}{101} \sum_{r \in (0, 0.01, n, 1)} \rho_{interp(r)} \quad (5)$$

Em que:

r- níveis de sensibilidade.

Outra métrica de avaliação analisada para acompanhamento da evolução do treinamento foi os gráficos de perda. A função de perda do algoritmo Faster R-CNN a entropia cruzada categórica, que é própria para determinar as perdas em classificação de várias classes, quando utiliza uma função softmax para classificação. Já a perda do YOLO tiny é a entropia cruzada binária como já mencionada anteriormente. Elas demonstram se as redes estão aprendendo de forma correta com os dados das três diferentes classes, iniciando com valores acima de 1 para todos os algoritmos e tende a zero à medida que a rede aprende ao longo das épocas de treinamento.

3.6. Avaliações em campo

As avaliações das redes em condições de campo foram aferidas através da sua precisão e sensibilidade para cada classe em cada algoritmo, analisando visualmente cada frame de vídeo de cada repetição e cada câmera gravadas no momento dos testes, realizando a contagem do número de folhas capturadas por cada câmera, de acordo com folhas detectadas corretamente (VP), as folhas não detectadas (FN) e as folhas detectas incorretamente (FP), procedendo aos cálculos conforme as equações (1) e (2), descritas no subtópico anterior.

3.7. Protótipo de pulverizador

3.7.1. Estrutura

O protótipo de pulverizador seletivo para avaliação em campo foi desenvolvido em conjunto com alunos de graduação do grupo de pesquisa Smart Agriculture. O chassi foi construído de ferro (chapa 16) tipo U, com 1,17 m de comprimento, 0,9 m de largura, altura de 0,57 m do solo e bitola de 0,65 m (Figura 6).

As bitolas com tamanhos fixos, assim como os garfos das rodas traseiras que não possuíam articulação, ou seja, não realizam nenhum movimento, sendo somente as rodas dianteiras articuladas. A articulação das rodas dianteiras era realizada por um mancal em cada garfo, que possibilitava o giro da roda em seu próprio eixo através do sistema de direção.

O sistema de direção constituído de um motor 12 volts de corrente contínua, acoplado em um eixo adaptado com dois pinhões, tracionando as coroas fixadas no garfo de cada pneu, realizando o movimento de rotação do protótipo.



Figura 6. A) visão frontal, B) visão traseira, C) visão lateral direita, D) visão lateral esquerda do protótipo de pulverizador seletivo desenvolvido em conjunto com o grupo Smart Agriculture.

Para a propulsão do mesmo, dois motores de 12 volts de corrente contínua foram utilizados, cada um com eixo soldado a uma catraca, realizando a tração dos pneus traseiros através de correntes, com velocidade constante de $0,5 \text{ m.s}^{-1}$.

3.7.2. Sistema de Pulverização

O sistema de pulverização desenvolvido foi composto por um reservatório com capacidade de 30 L, uma bomba de pressurização e quatro seções, conectadas por conexões

hidráulicas e mangueiras de alta pressão. Cada secção composta por uma válvula solenoide e uma ponta de pulverização.

A bomba e o reservatório ficaram posicionados na parte superior do chassi, afixados com parafusos em uma madeira de base, os bicos e válvulas de pulverização localizados na parte traseira do protótipo, fixados em uma chapa galvanizada, distanciada a 0,63 m do chassi por barras de metalon de 25 x 25 mm (Figura 7).

As válvulas solenoides foram colocadas entre as mangueiras e as pontas de cada secção, de forma que a calda percorria a mangueira. O espaçamento entre as câmeras e a barra de pulverização era de 0,10 m e o suporte para os sensores foram posicionados a 0,50 m do solo.




Figura 7. Sistema de pulverização seletiva construído no protótipo de pulverizador seletivo.

As pontas para aplicação do produto foram instaladas a uma altura de 0,50 m do solo, propiciando uma sobreposição de 22%, com faixa de pulverização de 0,70 m, os bicos da JACTO, cor amarela, modelo JSF, vazão de $0,76 \text{ L}\cdot\text{s}^{-1}$ com ângulo de aplicação de 110° a pressão de trabalho 310,26 kPa.

3.8. Sistema embarcado

O sistema embarcado para detecção e controle da pulverização seletiva foi composto de um computador, um microcontrolador, quatro webcams e um módulo relé de quatro canais (Figura 8 e 9).

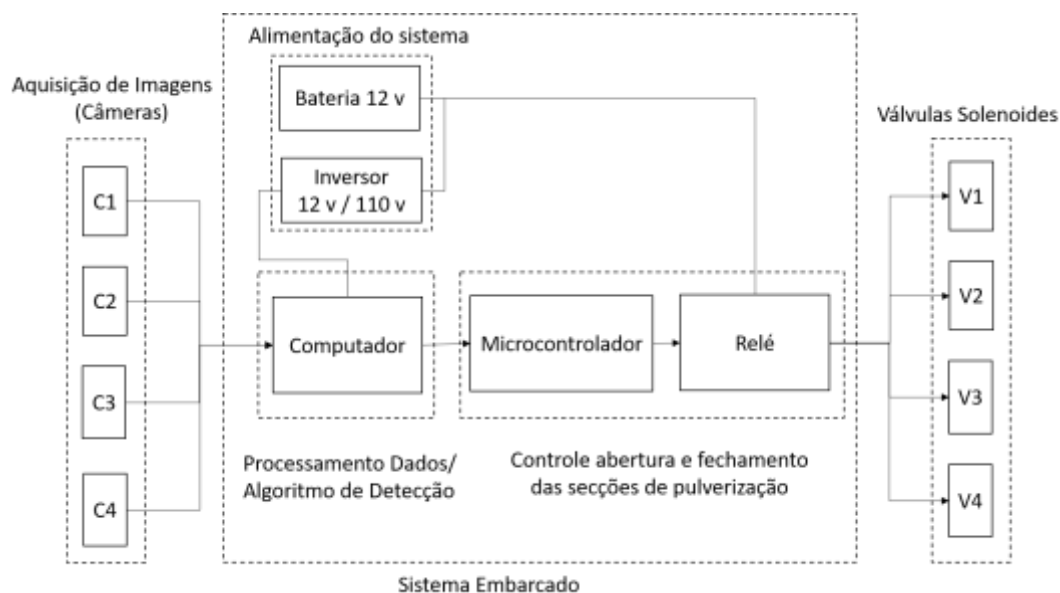


Figura 8. Diagrama do sistema embarcado, mostrando a sequência das informações a serem transmitidas até a abertura da válvula solenoide.




Figura 9. Sistema embarcado protótipo de pulverização seletiva para controle de corda-de-viola.

3.8.1. Descrição dos componentes utilizados no sistema embarcado:

- Webcam: Logitech C920 HD PRO, resolução máxima: 1080p/30qps - 720p/30qps, foco automático;
- Computador: Processador Pentium gold G5400 3,70 GHz, memória ram 8,00 GB, Placa de vídeo NVIDIA Geforce GTX 1050 (Memória 4GB GDDR5, sistema operacional Windows 10);
- Placa de Plototipagem: Arduino Nano com microcontrolador Atmega Atmel 328P;
- Válvulas: Marca DVR, pressão trabalho de até 1172,11 kPa, material :aço inoxidável, tensão 12 V;
- Bomba de pressão (Marca Seaflo), pressão de trabalho 420 kPa vazão de 4,92 L.m⁻¹;

3.8.2. Funcionamento do sistema

As webcams (Sensores) estão conectadas ao computador que realiza o processamento do algoritmo de detecção, e quando uma folha de corda-de-viola é detectada, ele envia um sinal ao microcontrolador Arduino. O sinal enviado indica qual sensor detectou a planta daninha, de forma com que o microcontrolador emita um sinal para cada canal do relé em que houve a detecção. O relé é uma chave eletromecânica, que ao receber um sinal elétrico, emite um novo sinal para o acionamento de outro componente.

Desta maneira, o acionamento das válvulas é feito de forma individual, uma vez que cada válvula solenoide é conectada a um canal do relé que por sua vez está ligado em quatro portas digitais diferentes no Arduino, realizando o acionamento somente quando a porta emitir sinal 5 V. Neste caso, quando a programação detectar a folha de corda-de-viola, o computador, enviará um comando para o microcontrolador, o mesmo enviará um sinal para o módulo relé, que acionará as válvulas solenoides, para realizar a pulverização.

O fornecimento de energia a todo sistema foi realizado por uma bateria de 12 V corrente contínua (CC) com fornecimento de 60 Ah. Já para energização do computador com fonte bivolt de corrente alternada, um inversor de tensão de 1000 W de potência foi utilizado, transformando tensão 12 V em corrente contínua (CC) da bateria, em 127 V em corrente alternada (CA).

3.9. Vazão do sistema de pulverização

A vazão média dos bicos no estudo a pressão de trabalho da bomba de 400 kPa de trabalho foi de 0,64 L min⁻¹ e foi obtida de acordo com metodologia da Chaim (2019), em que, o sistema ficou acionado durante 1 minuto, e coletado o volume pulverizado através de um copo volumétrico de 1 L, conforme equação (6).

$$q = \frac{V}{T_s} \quad (6)$$

Em que:

q = a vazão do sistema em L.min⁻¹;

V = volume obtido no copo graduado em litros, para o tempo de acionamento do sistema (Ts) em minutos.

3.10. Metodologia para avaliação em campo

Para avaliação da rede em campo, foi adotada a metodologia de PARTEL et. al. (2019) adaptada, em que foram montados dois módulos de ensaio, o primeiro contendo duas fileiras de 2 metros de comprimento cada, para a cultura da soja, com espaçamento entre plantas de 0,20 m e espaçamento entre fileiras de 0,90 m. O segundo continha duas fileiras de 4 metros de comprimento cada para cultura do algodão, espaçados de 0,15 m entre plantas e 0,90 m entre fileiras. Os espaçamentos adotados nesse trabalho não correspondem ao espaçamento adequado para a cultura da soja devido à bitola do protótipo, a fim de não haver esmagamento das linhas avaliadas da cultura no momento das avaliações.

As plantas foram semeadas inicialmente em vasos plásticos, mantidas em condições ambiente e posteriormente transplantadas no campo para realização das análises (Figura 10). Em conjunto às plantas de interesse econômico foram transplantadas plantas de corda-de-viola, aleatoriamente nas entrelinhas e linhas de cultura.



Figura 10. Plantas de algodão semeadas em vasos para realização das avaliações em campo.

Nas avaliações de campo o protótipo de pulverizador deslocou-se com velocidade máxima de $0,5 \text{ m.s}^{-1}$, com a bomba de pressurização a 400 kPa , sendo a vazão das pontas $0,64 \text{ L min}^{-1}$. Foram realizadas 10 repetições, em cada módulo de cada cultura. Um croqui da área experimental de avaliação pode ser visto na Figura 11, e uma imagem dos módulos instalados em campo se encontra na figura 12.




Figura 11. Croqui da área de avaliação dos algoritmos em campo.



Figura 12. Imagens dos módulos para avaliação dos algoritmos em campo.

No momento das avaliações, os vídeos em tempo real de cada câmera fornecidos as redes foram gravadas em cada repetição, sendo salvos e posteriormente convertidos em imagens e analisados frame a frame, um por um em laboratório, em que foram contadas as quantidades de folhas detectadas corretamente consideradas como VP, de folhas não detectadas consideradas como FN e a quantidade de folhas detectadas incorretamente sendo as FP. Realizou-se então a tabulação dos dados, e calculou-se para cada classe, câmera e repetição a precisão e sensibilidade conforme a equações (3) e (4) no item 3.5.

Realizou-se também a contagem da quantidade de plantas de corda-de-viola pulverizadas em cada repetição, algoritmo e módulo. Para se determinar o percentual de controle das plantas alvos na área, uma pessoa foi caminhando atrás do protótipo anotando toda vez que um bico de pulverização era acionado sobre o alvo desejado.

4. RESULTADOS E DISCUSSÃO

4.1. Resultados de Treinamento

Devido a diferença entre as arquiteturas das redes de extração de recursos utilizadas em cada algoritmo, o número de épocas de treinamento variou entre elas, uma vez que se buscava o ponto em que fornecesse o melhor resultado de precisão média (mAP) de detecção em ambos.

Os valores de perda demonstram o quão próximo as probabilidades das classes estimadas correspondem ao rótulo real do objeto a ser classificado (BINGUITCHAFARE & SHARMA, 2019), logo, se esses valores forem elevados pode se dizer que a rede é falha em termos de classificação. Na Figura 13 encontra-se o gráfico de perdas no treinamento da rede do YOLOv3 tiny.

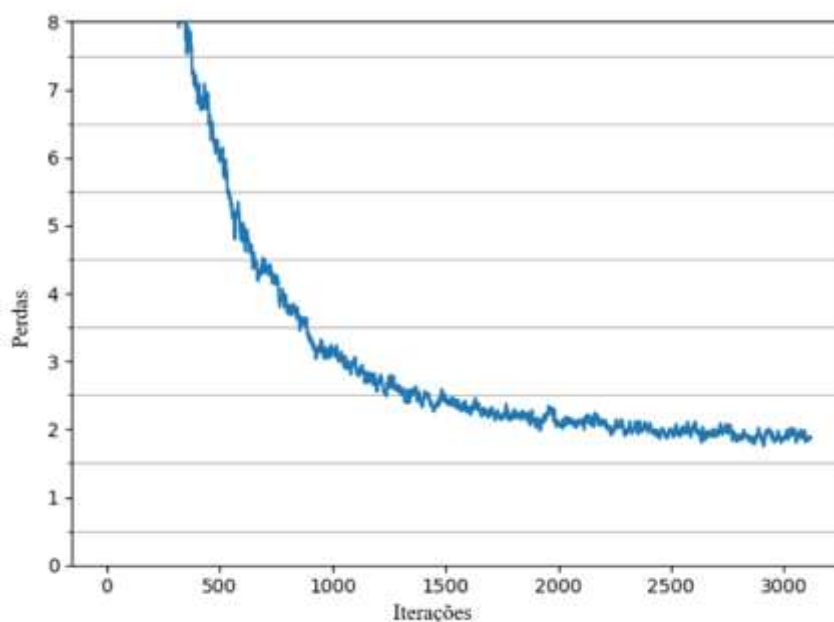


Figura 13. Gráfico de perdas durante o treinamento da arquitetura do YOLOv3 após 3.100 iterações.

O gráfico de perda durante o treinamento da rede YOLOv3 tiny demonstra um decaimento abrupto inicial até as primeiras 1000 iterações, e subsequentemente uma redução gradual das perdas, estabilizando-se e atingindo um valor mínimo de 1,88. De

acordo com Basheer & Hajmmer (2000) a queda abrupta do erro de treinamento inicial está relacionada ao aprendizado, porém quando a diminuição do erro se torna lenta pode ser atribuída ao número excessivo de ciclos de treinamento adotado provocando a memorização e/ou a adaptação excessiva dos dados ocasionado por um grande número de nós ocultos.

Já para a rede de extração de recursos incepton_v2 utilizada no Faster R-CNN as perdas de treinamento podem ser observadas no gráfico da Figura 14, em que há duas curvas diferentemente do gráfico do YOLOv3, tal fato é explicado devido ao treinamento ser realizado na API object detection do tensorflow e assim o gráfico é gerado no tensorboard, onde avalia-se simultaneamente a perda de treinamento com a perda dos dados de validação. A linha mais clara representa os valores com relação aos dados de testes, tidos como dados de validação, já a cor mais escura mostra as perdas no gráfico de treinamento. Ambas as curvas obtiveram valores de perdas abaixo de 1 após 2000 iterações de treinamento, atingindo valor de 0.2053 para os dados de teste e 0.1774 para os dados de treinamento após 23.000 iterações.

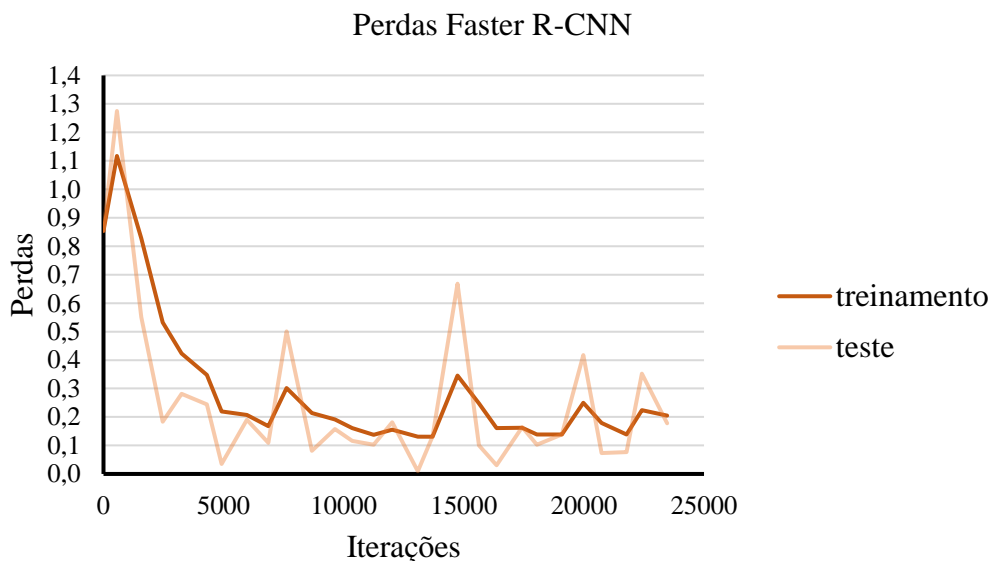


Figura 14. Gráfico de perdas durante o treinamento do incepton_v2 extrator de recursos utilizado no Faster R-CNN.

Os gráficos de perdas demonstram o andamento do treinamento em termos de aprendizado, e foi o fator utilizado para determinar o momento em que deve-se encerrar o treinamento, levando em consideração também as métricas, precisão, sensibilidade e precisão média conforme descrito no item 3.5, para evitar *underfitting* e *overfitting*.

O algoritmo YOLOv3 tiny apresentou precisão média para as três classes de 81,16 % em 2.500 iterações, conforme visualizado no gráfico da Figura 15, observando que ao inverso do gráfico de perdas, a precisão aumenta exponencialmente no início do treinamento, de forma a estabilizar de 2400 até 3100 iterações.

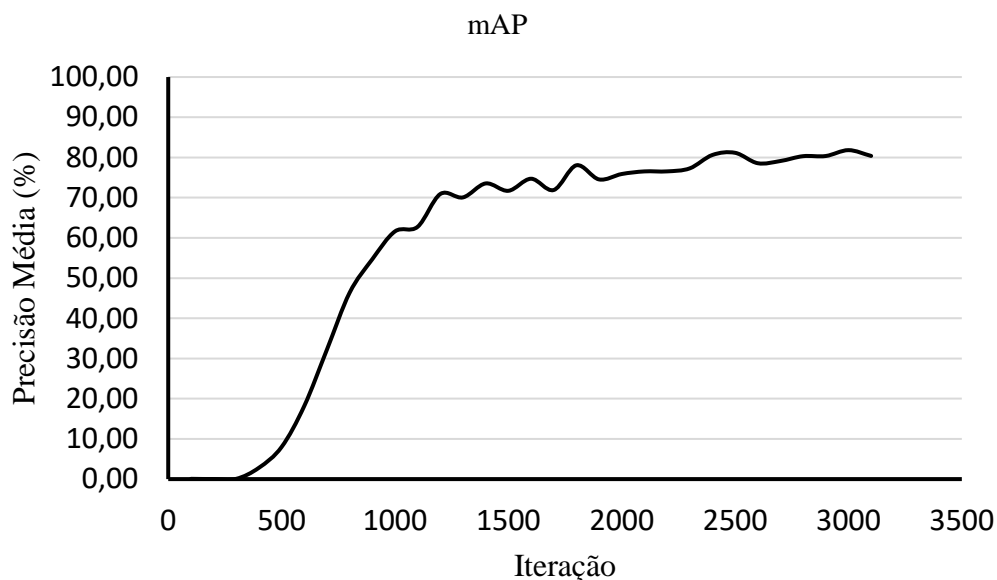


Figura 15. Gráfico de Precisão Média obtida no treinamento da rede do YOLOv3 tiny durante a etapa de treinamento, avaliado no conjunto de dados de teste.

Na Figura 16 encontra-se o gráfico de evolução da precisão média do Faster R-CNN ao longo da etapa de treinamento. Nota-se que a precisão média apresenta comportamento crescente ao longo do treinamento dos dados de testes, alcançando valor de 87,20% após 23.464 iterações. A fim de evitar o *overfitting* da rede, o treinamento foi interrompido após o gráfico não apresentar evolução em 3.100 iterações.

Em termos de sensibilidade do Faster R-CNN o valor máximo foi atingido em 21.780 iterações com pontuação de 78,10 %, porém o ponto de maior precisão média a precisão foi de 77,20% observado na Figura 17. Resultados superiores foram encontrados por Quan *et al.* (2019), treinando um algoritmo Faster R-CNN com backbone VGG19 para detecções da planta milho em diferentes condições, alcançando uma precisão de 97,71% e a sensibilidade do conjunto total de testes foi de 96,92%. Porém é importante ressaltar que as características das plantas de milhos são diferentes das culturas avaliadas neste estudo, assim como as condições em que se foram realizado as análises.




Figura 16. Gráfico de Precisão média da rede incepton_v2 utilizada como extrator de recursos do algoritmo FASTER R-CNN durante a etapa de treinamento, avaliação no conjunto de dados testes.

Os resultados inferiores deste trabalho podem estar relacionados ao menor número de imagens do conjunto de dados, pois os autores utilizaram 32.354 imagens rotuladas entre plantas daninhas e milho. Uma vez que quanto maior o conjunto de dados maior será a quantidade de exemplos fornecidos para auxiliar na aprendizagem da máquina.




Figura 17. Gráfico de sensibilidade para a rede incepton_v2, utilizada como extrator de recursos do algoritmo Faster R-CNN durante a etapa de treinamento, obtida no conjunto de dados de testes.

YOLOv3 tiny obteve valor máximo de sensibilidade na iteração de 2.800, com 72,00%, com precisão média nesta iteração de 80,32%, abaixo da precisão média obtida em 2.500 iterações, cuja sensibilidade foi de 68,00% (Figura 18).

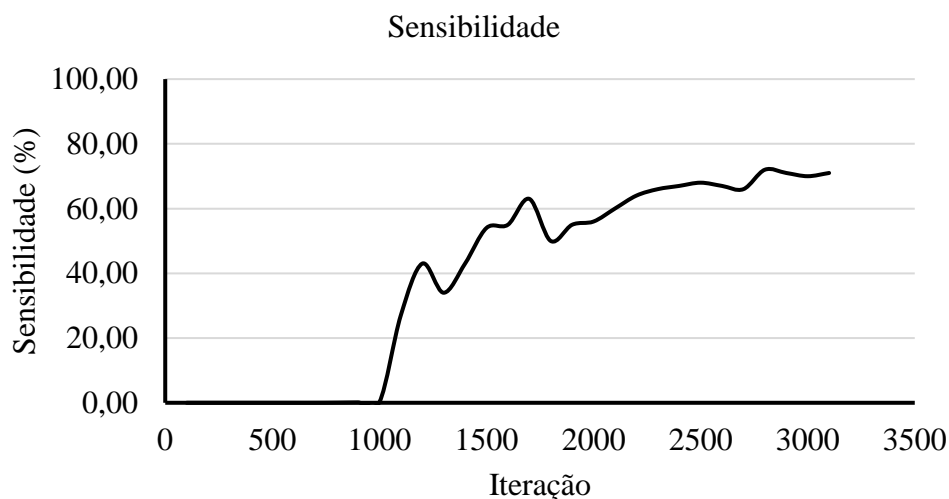


Figura 18. Gráfico de sensibilidade média algoritmo YOLOv3 tiny durante o treinamento, obtidos no conjunto de imagens de teste.

No entanto, na pulverização seletiva de plantas daninhas não é necessária a detecção de todas as folhas presentes na imagem, sendo mais importante uma precisão mais alta, mesmo com diminuição da sensibilidade. Uma vez que, segundo Yu *et al.* (2019), as folhas não detectadas possivelmente estejam na zona de aplicação dos bicos tipo leque ao quais uma ou mais folhas foram detectadas.

A Tabela 1 mostra os pontos de treinamentos dos algoritmos que apresentaram maiores mAP e que apresentam resultados promissores para serem aplicados em tempo real para aplicação de herbicidas de forma seletiva.

Tabela 1- Pontos de melhores precisão média durante o treinamento de ambos os algoritmos e seus respectivos valores de Sensibilidade.

Algoritmo	Iterações	Precisão (%)	Sensibilidade (%)
YOLOv3 tiny	2.500	81,16	68,00
Faster R-CNN	23.464	87,20	77,20

Os resultados de precisão para ambos os algoritmos embora estejam abaixo de 90,00%, apresentam resultados excelentes levando em consideração o número de imagens e as características muito semelhantes morfológicamente das folhas de algodão, *Ipomoea spp.*, e folíolos de soja, que dificultam a diferenciação entre as espécies, provocando detecções equivocadamente erradas, diminuindo a precisão do mesmo. Segundo Bakhshipour & Jafari (2017) as classificações com resultados inferiores observados nas suas avaliações podem ser referidas à semelhança de forma das plantas daninhas e da cultura de interesses, bem como, outras espécies de plantas daninhas.

4.2. Avaliações em Campo

As avaliações em campo nos módulos experimentais ocorreram nos dias 07 e 08 de janeiro de 2020 no horário das 8 h às 10 h da manhã. As condições meteorológicas para ambos os dias podem ser vistas na Tabela 2, abaixo:

Tabela 2- Condições climáticas nos dias de realização das avaliações. Fonte: INMET Adaptado (2020).

Data	Hora UTC	Temp. (°C)		Umidade (%)		Vento (m/s)			Chuva (mm)
		Máx.	Min.	Máx.	Min.	Vel.	Dir. (°)	Raj.	
07/01	12 h	26,4	25	85	85	0,1	360	2,2	0
08/01	13 h	26,1	24,4	87	84	0,4	56	2,6	0,2

Temperatura (Temp.) e Umidade relativa (U.).

O YOLOv3 tiny durante as avaliações realizadas em campo na cultura do algodão conseguiu detectar somente uma folha como correta da cultura, em somente uma repetição, das dez que foram realizadas. Sendo assim, a média de precisão obtida foi de 10% (Figura 19).

O erro de classificação das folhas de algodão pode estar relacionado ao formato das folhas e o ângulo em que as imagens são capturadas, já que as folhas de algodão também são cordiformes e conforme o estágio em que se encontra e o ângulo em relação a câmera apresentam formato semelhantes a de corda-de-viola.



FIGURA 19. Na imagem (a) a única folha de algodão detectado, (b) folhas não detectadas e (c) folha detectada incorretamente pelo YOLOv3 tiny no momento das avaliações.

O ângulo de captura também tem um efeito na precisão da detecção, conforme observado por Quan *et al.* (2019), em que os autores avaliaram diferentes algoritmos de detecções de objetos (YOLOV2, FASTER R-CNN e FASTER R-CNN com VGG19), na detecção de plantas de milho e plantas daninhas em estágios fenológicos diferentes de crescimento em função de três ângulos de posicionamento da câmera para captura das imagens (0° , 30° e 75°), observando melhores resultados para o ângulo de 75° para todos os algoritmos, e valores superiores para o FASTER R-CNN com VGG19, apresentando precisão de 98,20% e sensibilidade de 97,25%. Os autores atribuem essa diferença ao maior tamanho da imagem e a vista das plantas de milhos, que no ângulo de 30° e 75° apresentam vista frontal e superior, enquanto no ângulo de 0° somente superior, como utilizado neste estudo. Já para soja a precisão ficou em 98,00%, mostrando que o algoritmo em alguns momentos classificou erroneamente planta daninha como de cultura, neste caso.

Na detecção da corda-de-viola houve diferença entre os módulos, tendo maior precisão nas detecções nas plantas daninhas encontradas na cultura do algodão com 93,00%, e menor na cultura da soja com 76,00% (Tabela 3). Mostrando que embora o formato das folhas do algodão seja mais semelhante com as corda-de-viola, o algoritmo confundiu mais na detecção entre folíolos da soja como folhas da corda-de-viola, diminuindo assim a precisão na detecção da planta daninha (Figura 20).

Tal fato pode ser explicado talvez pelas características extraídas das imagens de ambas as plantas no momento de treinamento e aprendizado, podendo apresentar pontos mais similares para o algoritmo.



Figura 20. Imagens das câmeras durante repetições em campo (a) detecção de folha de soja de maneira incorreta e correta, (b) e (c) folhas de soja detectadas e não detectadas pelo algoritmo YOLOv3 tiny.

Os autores Kazmi *et al* (2015) extraíram 14 índices de vegetação de cardo rastejante e beterraba sacarina, para diferenciar as plantas e obtiveram precisão de 97,00%, entretanto as características extraídas durante o treinamento e aprendizado das CNNs nesse estudo são desconhecidos.

Tabela 3 - Precisão dos algoritmos YOLOv3 tiny na detecção das classes de corda-de-viola, soja e algodão para ambos os módulos avaliados.

Precisão YOLOv3 tiny			
Módulo Algodão		Módulo Soja	
Algodão	Corda-de-viola	Soja	Corda-de-viola
10,00%	93,00%	98,00%	76,00%

Com relação a sensibilidade, para corda-de-viola em ambos os módulos e classes, ficaram abaixo de 12,00%, como observado na Tabela 4. Tais resultados, ficaram abaixo do valor obtido nos conjuntos de imagens de testes em laboratório, demonstrando uma baixa capacidade do algoritmo YOLOv3 tiny em recuperar todos os objetos contidos na imagem em tempo real.

Tabela 4- Sensibilidade do algoritmo YOLOv3 tiny em tempo real para as três classes avaliadas no estudo.

Sensibilidade YOLOv3 tiny			
Módulo Algodão		Módulo Soja	
Algodão	Corda-de-viola	Soja	Corda-de-viola
1,00%	8,00%	10,00%	11,00%

Esses valores de sensibilidade podem ter sido influenciados pelas condições do ambiente no momento do teste e a câmera utilizada, que estava programada para uso com um zoom automático e não apresentava um foco adequado das imagens. A procura constate do ajuste focal em movimento, pode ter contribuído para a baixa detecção de todos os objetos na imagem e para classificação incorreta de algumas plantas (Figura 21). Segundo Zheng *et. al.* (2017) a detecção em imagens RGB naturais é bastante difícil devido ao fundo complexo, diferentes iluminações, clima, regiões de sombra e semelhanças de cores. De acordo Hong *et al.* (2012) as condições de iluminação são um dos desafios da visão de máquinas, uma vez que a refletância pode aumentar em dias de iluminação intensa, reduzindo a diferenciação de características e dificultando a detecção, isto porque o aumento de refletância distorce as cores da imagem.



Figura 21- (a) e (b) incidência de alta luminosidade nas plantas de algodão no momento das avaliações, provocando a não detecção e detecção incorreta das folhas pelos algoritmos, e (c) embaçamento da imagem no momento de ajuste focal da câmera.

O Faster R-CNN apresentou ótimos resultados de precisão tanto para cultura do algodão como para cultura da soja, para corda-de-viola houve uma variação de 4,00% entre as médias em ambos os módulos, como observado na Tabela 5.

Tabela 5- Médias dos resultados de precisão na detecção das 3 classes em ambos os módulos, em 10 repetições para o Faster R-CNN.

Precisão Faster R-CNN			
Módulo Algodão		Módulo Soja	
Algodão	Corda-de-viola	Soja	Corda-de-viola
100,00%	92,00%	96,00%	88,00%

As precisões para algodão e corda-de-viola no módulo de algodão ficaram acima de 90,00%, para a corda-de-viola no módulo de soja ficou abaixo de 88,00%. Resultados semelhantes foram encontrados por Olsen *et al.* (2019) avaliando o desempenho de duas arquiteturas de Redes Neurais Convolucionais, na classificação de 8 espécies de plantas daninhas, em que obtiveram precisão variando entre as espécies de plantas daninhas de 88,50% a 97,60% utilizando a arquitetura ResNet-50. Os autores acreditam que o desempenho mais baixo de precisão de algumas plantas daninhas deve-se ao fato delas terem características visíveis menos exclusivas para serem treinadas. Eles ainda ressaltam que número elevado de confusão na classificação entre as plantas daninhas está relacionada às características de imagem semelhantes.

Assim, conforme salientado anteriormente a posição em que se encontrava a folha ou folíolo no momento de captura da imagem pela câmera pode se apresentar semelhante a outras espécies a ser detectada levando a máquina a uma classificação equivocada.

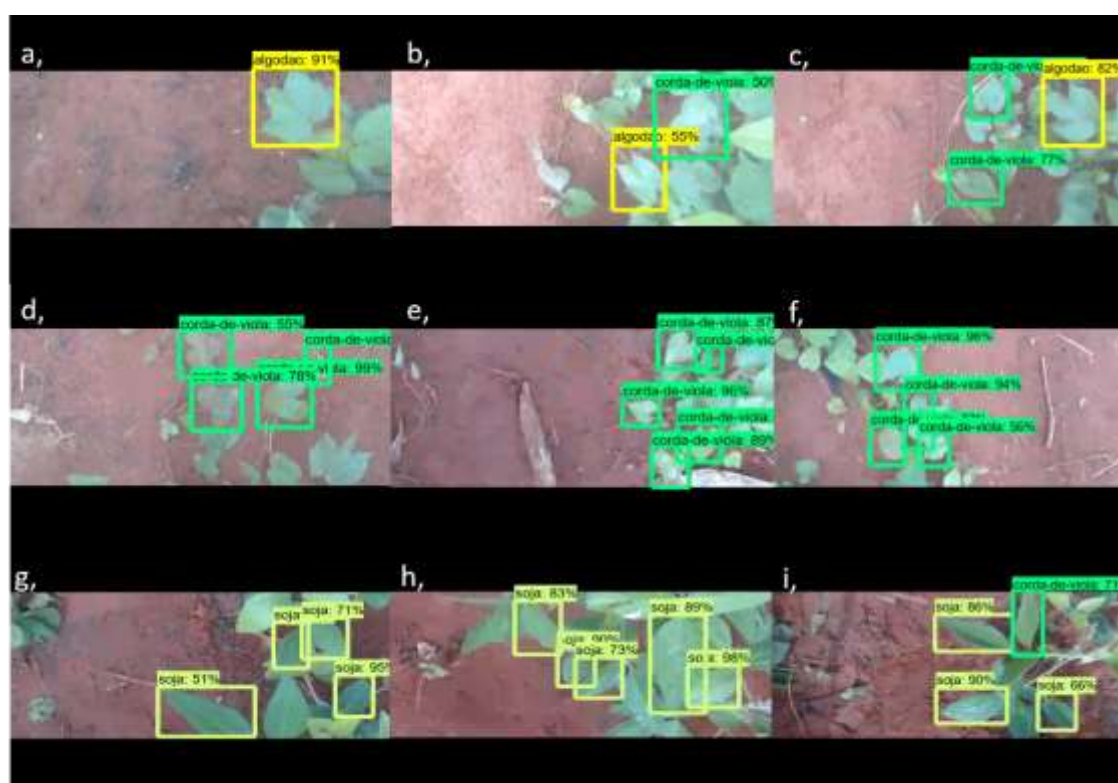


Figura 22. (a), (b) e (c) Detecções de folhas de algodão; (d), (e) e (f) folhas de corda-de-viola; e (g), (h) e (i) folíolos de soja realizados pelo algoritmo Faster R-CNN.

Outro fato importante de se salientar é com relação a precisão das culturas de interesse, tendo em vista, que houve pouco erro em classificar plantas daninhas como

sendo plantas de cultura. Esse resultado é ótimo, uma vez que busca-se controlar as plantas daninhas e caso a mesma seja detectada e classificada erroneamente, ela não será pulverizada. Porém, a detecção de plantas de cultura de interesse econômico como plantas daninhas, leva ao desperdício de herbicidas e conseqüentemente maior quantidade dos produtos presentes no meio ambiente.

Em termos de sensibilidade o Faster R-CNN obteve resultados também inferiores a 30,00% quando realizada a detecção em tempo real para ambos os módulos (Tabela 6). A baixa capacidade em detectar todos os objetos na imagem é insignificante para as culturas de interesse econômico, tendo em vista que o objetivo é pulverizar somente as plantas daninhas, já para as plantas daninhas não é necessária a detecção de todas as folhas entretanto é necessária a detecção de pelo menos uma folha de cada planta, a fim de acionar os bicos e realizar a pulverização do herbicida.

Tabela 6- Sensibilidade médio do algoritmo Faster R-CNN das 10 repetições nos módulos de avaliação, para as três diferentes classes.

Sensibilidade Faster R-CNN			
Módulo Algodão		Módulo Soja	
Algodão	Corda-de-viola	Soja	Corda-de-viola
18,00%	25,00%	24,00%	26,00%

Na comparação entre os algoritmos o Faster R-CNN apresentou melhores resultados em termos de sensibilidade para ambos os módulos e ambas as classes, entretanto a precisão ficou próxima do YOLOv3, sendo superior para a corda-de-viola no módulo de soja, ou seja, detectando um menor número de fólhos de soja como sendo planta daninha (Tabela 7).

Tabela 7 - Médias de Precisão e Sensibilidade das 10 repetições das avaliações dos algoritmos em campo, para cada classe a ser detectada.

Resultados Algoritmos								
Algoritmo	Módulo Algodão				Módulo Soja			
	Algodão		Corda-de-viola		Soja		Corda-de-viola	
	Precisão	Sbl.	Precisão	Sbl.	Precisão	Sbl.	Precisão	Sbl.
Faster R-CNN	100,00%	18,00%	92,00%	25,00%	96,00%	24,00%	88,00%	26,00%
YOLOv3 Tiny	10,00%	1,00%	93,00%	8,00%	98,00%	10,00%	76,00%	11,00%

Sensibilidade (Sbl.)

Resultados obtidos por Quan *et al.* (2019) comparando o FASTER-CNN clássico, Faster R-CNN com arquitetura VGG19 e a versão YOLOv2, mostraram que o FASTER R-CNN foi superior ao YOLOv2 em termos de precisão de 10,31% nas detecções de mudas de milho entre 6-7 folhas. Embora seja uma versão anterior do YOLO demonstra que o Faster R-CNN possui resultados de precisão superior, porém o processamento mais lento.

4.3. Resultados de pulverização

O controle através da pulverização está diretamente relacionado a precisão e a sensibilidade de detecções. Neste contexto, o Faster R-CNN apresentou variações de controle durante as repetições em cada módulo. No módulo do algodão podem-se observar porcentagens maiores, variando de 67,00 a 87,00% entre as repetições. Já para o módulo da soja a menor porcentagem ocorreu na repetição 9, isto talvez devido a várias passadas do protótipo na área onde algumas folhas de corda-de-viola foram esmagadas, dificultando sua detecção e conseqüentemente seu controle. No entanto as demais repetições apresentaram porcentagens superiores ou iguais a 67,00% no controle das plantas daninhas (Tabela 8 e 9).

Tabela 8- Precisão no controle de corda-de-violas nas culturas de soja e algodão em ambos os algoritmos avaliados no projeto.

Controle de corda-de-viola na Cultura							
Algoritmo	Rep.	Algodão			Soja		
		Pulverizada	Total	Controladas	Pulverizada	Total	Controladas
Faster R-CNN	1	11	15	73,00%	6	9	7,00%
	2	12	15	80,00%	7	9	78,00%
	3	13	15	87,00%	9	9	100,00%
	4	10	15	67,00%	9	9	100,00%
	5	13	15	87,00%	7	9	78,00%
	6	13	15	87,00%	8	9	89,00%
	7	12	15	80,00%	6	9	67,00%
	8	12	15	80,00%	6	9	67,00%
	9	13	15	87,00%	5	9	56,00%
	10	13	15	87,00%	7	9	78,00%

Já para o algoritmo YOLOv3 tiny conforme a Tabela 8 o controle de corda-de-viola ficou abaixo de 40% em ambos os módulos. Este valor é refletido pelo baixo número de sensibilidade apresentado pelo algoritmo de detecção, embora tenha boa porcentagem de precisão na detecção (Tabela 9).

A média de plantas daninhas pulverizadas no módulo de algodão ficou em 3 (três) plantas de 15, representando média de 19,00% no controle. Já para o módulo de soja a o controle ficou em 20,00% com média de 2 (duas) plantas pulverizadas de 9 presentes no módulo, em 10 repetições.

Tabela 9- Controle de corda-de-viola realizada pelo algoritmo YOLOv3 tiny, nos módulos de soja e algodão.

Controle de corda-de-viola na Cultura							
Algoritmo	Rep.	Algodão			Soja		
		Pulverizada	Total	Controladas	Pulverizada	Total	Controladas
YOLOv3 Tiny	1	1	15	7,00%	3	9	33,00%
	2	6	15	40,00%	4	9	44,00%
	3	3	15	20,00%	2	9	22,00%
	4	2	15	13,00%	0	9	0,00%
	5	2	15	13,00%	1	9	11,00%
	6	3	15	20,00%	2	9	22,00%
	7	1	15	7,00%	2	9	22,00%
	8	4	15	27,00%	1	9	11,00%
	9	4	15	27,00%	0	9	0,00%
	10	3	15	20,00%	3	9	33,00%

Para o algoritmo Faster R-CNN a melhor média de controle de plantas de corda-de-viola foi obtida em ambos os módulos, conseguindo controlar em média 12 plantas de 15 presentes no módulo de algodão e 7 plantas pulverizadas de 9 plantas presentes no módulo da soja. A média de controle foi de 81% para o módulo de algodão e 78% para a soja (Tabela 10).

Tabela 10- Média de controle de corda-de-viola de ambos os algoritmos e módulos.

Média de Controle (%)		
Algoritmo	Módulo	
Faster R-CNN	Algodão	Soja
	81,00%	78,00%
YOLOv3 tiny	Algodão	Soja
	19,00%	20,00%

5. CONCLUSÃO

Nas avaliações dos algoritmos em termos de precisão e sensibilidade no conjunto de imagens durante a etapa de treinamento, ambos os algoritmos apresentaram ótimo desempenho na detecção e classificação das folhas de algodão, soja e corda-de-viola.

Nos testes em campo realizado no protótipo de pulverizador seletivo, o Faster R-CNN apresentou resultados melhores no controle das corda-de-viola presentes tanto no módulo com implementação de algodão, quanto no módulo de soja mesmo com baixos valores de sensibilidade.

A baixa capacidade na detecção das folhas de *Ipomoea spp.* não afetou o desempenho já que ao menos uma folha de cada planta foi detectada.

O YOLOv3 tiny controlou uma baixa porcentagem de corda-de-viola em ambas as culturas de avaliação devido aos baixos valores de sensibilidade obtidos nos módulos, não sendo uma ferramenta eficiente nas condições deste estudo.

O sistema embarcado desenvolvido para o protótipo de pulverização, foi eficiente no acionamento individual de cada bico, realizando a aplicação de forma seletiva de acordo com o alvo detectado.

O uso da implementação do algoritmo FASTER R-CNN demonstrou aplicabilidade como uma ferramenta de detecção de plantas de *Ipomoea spp.* para pulverização a taxa variável de herbicidas.

6. REFERÊNCIAS BIBLIOGRÁFICAS

ABIODUN, O. I.; JANTAN, A.; OMALARA, A. E.; DADA, K. V. & MOHAMED, N. A.; ARSHAD, H. State-of-the-art in artificial neural network applications: A survey. *Helyon*, ed. 11, v. 4, 2018. DOI: <https://doi.org/10.1016/j.heliyon.2018.e00938>

ABOUZIENA, H.F.; HAGGAG, W.M.; Weed control in clean agriculture: a review. **Planta Daninha**, Viçosa-MG, v. 34, n. 2, p. 377-392, 2016.

ABRAPA (ASSOCIAÇÃO BRASILEIRA DE PRODUTORES DE ALGODÃO). Disponível em: <https://www.abrapa.com.br/Paginas/dados/comercializacao-brasil.aspx>. Acesso em: setembro 2019.

AMIDI, A.; AMIDI, S.; VLACHAKIS, D.; MEGALOOIKONOMOU, V.; PARAGIOS, N. & ZACHARAKI, E. I. EnzyNet: enzyme classification using 3D convolutional neural networks on spatial representation. **PeerJ** 6:e4750, 2018; DOI: 10.7717/peerj.4750

AZANIA, C. A. M.; HIRATA, A. C. S.; AZANIA, A. A. P. M. Biologia e manejo químico de corda-de-viola em cana-de-açúcar. **Boletim Técnico IAC**, Campinas, n. 209, 2011.

BASHEER, I. A. & HAJMEER, M. Artificial neural networks: fundamentals, computing, design, and application. **Journal of microbiological methods**. v. 43, n.1, p. 3-31. 2000.
BELTRÃO, N. E. M. Herbicidas, Competição e Combate as Plantas Daninhas na Cultura do Algodão. Circular Técnica-37, ed. 1ª, Embrapa – Algodão, Campina Grande-PB, 2000.

BINGUITCHA-FARE, A. & SHARMA, P. Crops and weeds classification using Convolutional Neural Networks via optimization of transfer learning parameters. *International Journal of Engineering and Advanced Technology (IJEAT)*, v.8, 2019. Disponível em: <https://www.ijeat.org/wp-content/uploads/papers/v8i5/E7727068519.pdf>, Acesso em: novembro 2019.

BRIGHENTI, A. M. Manual de Identificação e Manejo de Plantas Daninhas em Cultivos de Cana-de-açúcar. 1ª ed. Embrapa Gado de Leite, Juiz de Fora -MG, 2010.

CASTRO, G.S.A., CRUSCIOL, C.A.C., NEGRISOLI, E.; PERIM, L. Sistemas de produção de grãos e incidência de plantas daninhas. **Planta Daninha**, Viçosa-MG, v. 29, p. 1001-1010, 2011.

CHAIM, A. Boas práticas agrícolas: Aplicação de Agrotóxicos e Meio Ambiente. Embrapa - Meio Ambiente, 2019. Disponível em: <https://www.embrapa.br/documents/10180/13599347/ID19.pdf>. Acessado em: setembro 2019.

CHEN, J., ZHOU, H., HU, H., SONG, Y., GIFU, D., LI, Y., E HUANG, Y. (2018). Pesquisa em sistema de monitoramento agrícola baseado em rede neural convolucional. *Future Generation Computer Systems*, 88, 271-278. doi: 10.1016 / j.future.2018.05.045

CHRISTOFFOLETI, P.J. & LÓPEZ-OVEJERO, R. Principais aspectos da resistência de plantas daninhas ao herbicida glyphosate. **Planta Daninha**, v.21, n.3, p.507-515, 2003.

CONAB (COMPANHIA NACIONAL DE ABASTECIMENTO). Acompanhamento de safra brasileiro – grãos: Décimo primeiro levantamento, agosto 2019 – safra 2018/2019.: Brasília: Companhia Nacional de Abastecimento. 2019. Disponível em: <https://www.conab.gov.br/info-agro/safra/safra-graos/boletim-da-safra-de-graos>. Acesso em: 01 set 2019.

CONSTANTIN, J.; OLIVEIRA JR. R. S.; GHENO, E. A.; *et al.* Controle de corda-de-violão com as opções de tratamentos herbicidas disponíveis para a cultura do algodão. 8º Congresso brasileiro de algodão, COTTON EXPO, 1, São Paulo. Evolução da cadeia para construção de um setor forte: Anais. p. 797, 2011.

CORREIA, N.M. & KRONKA JR., B. CONTROLE QUÍMICO DE PLANTAS DOS GÊNEROS *Ipomoea* E *Merremia* EM CANA-SOCA. **Planta Daninha**, Viçosa-MG, v. 28, p. 1143-1152, 2010.

DAINESE, R.C. *et al.* Avaliação da incidência de plantas invasoras por meio de segmentação de imagens e redes neurais. In: CONGRESSO BRASILEIRO DE AP, 2004, Piracicaba. Resumos... Piracicaba/SP: ESALQ/USP, 2004, p. 14.

DE MORAES, P. V. D.; AGOSTINETTO, D.; GALON, L.; PIESANTI, R. Agricultura de precisão no controle de plantas daninhas. **Revista da FZVA**. Uruguaiana, v.15, n.1, p. 01-14. 2008.

DE OLIVEIRA, M. F. & BRIGHENTI, A. M. CONTROLE DE PLANTAS DANINHAS: Métodos físico, mecânico, cultural, biológico e alelopatia. EMBRAPA – Milho e Sorgo. Brasília, DF, 2018.

DYRMANN, M.; KARSTOF, H.; MIDTIBY, H. S. Plant species classification using deep convolutional neural network. **Biosystems Engineering**, v. 151, p. 72-80, 2016. DOI: 10.1016/j.biosystemseng.2016.08.024.

FARIA, E. L. Redes neurais convolucionais e máquinas de aprendizado extremo aplicadas ao mercado financeiro brasileiro. Tese (Doutorado em Engenharia Civil), Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2018

FERNEDA, E. Redes neurais e sua aplicação em sistemas de recuperação de informação. **Ciência da Informação**., Brasília - DF, v. 35, n. 1, p. 25-30, 2006. Doi: <http://dx.doi.org/10.1590/S0100-19652006000100003>.

FERREIRA, P. P. A. & MIOTTO, S. T. S. Flora Ilustrada do Rio Grande do Sul: Sinopse das espécies de *Ipomoea* L. (Convolvulaceae) ocorrentes no Rio Grande do Sul, Brasil. **Revista Brasileira Biociências**, Porto Alegre, v. 7, n. 4, p. 440-453, 2009.

FLECK, N. G. & CANDEMIL, C. R. G. Interferência de plantas daninhas na cultura da soja (*GLYCINE MAX (L.) MERRILL*). **Ciência Rural**, Santa Maria, v. 25, n. 1, p. 27-32, 1995.

FLETCHER, R. H.; Suzanne W. Clinical epidemiology: the Essentials, ed. 4ª. Baltimore, Md.: Lippincott Williams & Wilkins. p. 45, 2005. ISBN 0-7817-5215-9

FONTES, J. R. A.; SHIRATSUCHI, L. S.; NEVES, J. L.; DE JÚLIO, L.; SODRÉ FILHO, J. Manejo Integrado de Plantas Daninhas. **Embrapa Cerrados**, v. 1, n. 1517–5111, p. 24–25, 2003.

FREITAS, C. S.; MARCELINO JR.; D. L.; TANAKA, L. C.; PIRES, D. F. Aplicação de redes neurais artificiais em sistemas de apoio para tomada de decisões. *Revista eletrônica de sistema de informação e gestão tecnológica*, v. 1, n. 1, 2011.

GAZZIEIRO, D. L. P.; LOLLATO, R. P.; BRIGHETTI, A. M. PITELLI, R. A.; VOLL, E. Manual de identificação de plantas daninhas da cultura da soja. 2ª edição. EMBRAPA-SOJA, Londrina -PR, 2015.

GIRSHICK, ROSS. FAST R-CNN. The IEEE International Conference on Computer Vision (ICCV), 2015. Disponível em: <https://arxiv.org/abs/1504.08083>. Acesso em: agosto 2019.

GORGENS, E.; GARCIA LEITE, H.; SANTOS, H. N.; GLERIANI, J. M. Estimação do volume de árvores utilizando redes neurais artificiais. **Revista Árvore**, v. 33, n. 6, p. 1141-1147, 2009. Disponível em: <http://www.redalyc.org/articulo.oa?id=48815855016>.

GUO, Y.; LIU, Y.; OERLEMANS, A.; LAO, S.; WU, C.; LEW, M. S. Deep Learning for Visual Understanding: A Review. **Neurocomputing**. v. 187, p. 27-48, 2016. <https://doi.org/10.1016/j.neucom.2015.09.116>

HARKER, K. N. & O'DONOVAN, J. T. Recent Weed Control, Weed Management, and Integrated Weed Management. **Weed Technology**, v. 27, n. 1, p. 1-11, 2013. DOI: <https://doi.org/10.1614/WT-D-12-00109.1>

HENRIQUES, M. J.; GUERRA, N.; OLIVEIRA NETO, A. M.; PIAZETTA, H. V. L.; BOTTEGA, E. L. Controle de corda-de-violão e picão-preto com aplicação de [clorimuron-etílico+glifosato] em pós-emergência da soja. In: V CONCCEPAR – CONGRESSO CIENTÍFICO DA REGIÃO CENTRO-OCIDENTAL DO PARANÁ. 2013.

HONG, S.; MINZAN, L. & ZHANG, Q. Detection system of smart sprayer: Status, challenges, and perspectives. **Int. J. Agri. Biol. Eng.**, v. 5, n. 3, p. 10-23, 2012.

KAMILARIS, A.; PRENAFETA-BOLDÚ, F. X. Deep learning in agriculture: A survey. **Computers and Electronics in Agriculture**, v. 147, p. 70-90, 2018. <https://doi.org/10.1016/j.compag.2018.02.016>

KOZLOWSKI, L.A., RONZELLI JÚNIOR, P., PURISSIMO, C., DAROS, E.; KOEHLER, H.S. Período crítico de interferência das plantas daninhas na cultura do

feijoeiro-comum em sistema de semeadura direta. **Planta Daninha**, Viçosa-MG, v.20, n.2, p.213-220, 2002.

LI J, WU W, XUE D, GAO P. Multi-Source Deep Transfer Neural Network Algorithm. **Sensors**, Basel- Switzerland, v. 19,18 3992, 2019, doi:10.3390/s19183992.

LIN, T.-Y.; MAIRE, M.; BELONGIE, S.; HAYS, J.; PERONA, P.; RAMANAN, D.; DOLLAR, P. & ZITNICK, C. L. Microsoft coco: Common objects in context. European conference on computer vision, Springer, p. 740–755, 2014.

LITJENS, G. CIOMPI, F.; WOLTERNINK, J. M.; DE VOS, B. D.; LEINER, T.; TEUWEN, J.; ISGUM, I. STATE-OF-THE-ART REVIEW: State-of-the-Art Deep Learning in Cardiovascular Image Analysis, *J A C C: C A R D I O V A S C U L A R I M A G I N G*, v. 12, n. 8, p. 1 5 4 9 – 6 5, 2 0 1 9.

LIU, W.; WANG, Z.; LIU, X.; ZENG, N.; LIU, Y.; ALSSADI, F. E. A survey of deep neural network architectures and their applications. **Neurocomputing**, v. 234, p. 11-26, 2017.

MAPA (Ministério da agricultura, pecuária e abastecimento). AGROSTAT - Estatísticas de Comércio Exterior do Agronegócio Brasileiro. Disponível em: <http://indicadores.agricultura.gov.br/index.htm>. Acesso: setembro 2019.

MARASCHIN-SILVA, F.; AQUILA, M. E. A. Potencial alelopático de espécies nativas na germinação e crescimento inicial de *Lactuca sativa* L. (Asteraceae). **Acta Botanica Brasilica**, vol. 20, n. 1, p. 61-69. 2006.

MCCULLOCH, W S; PITTS, W. A logical calculus of the ideas immanent in nervous activity: The bulletin of mathematical biophysics. **Bulletin of Mathematical Biophysics**, v. 5, n. 4, p. 115–133, 1943.

MEIRELLES, G.L.S., ALVES, P.L.C.A. e NEPOMUCENO, M.P. Determinação dos períodos de convivência da cana-soca com plantas daninhas. **Planta Daninha**, Viçosa-MG, v. 27, n. 1, p. 67-73, 2009.

MELO, C. A. D.; GUIMARÃES, F. A. R.; GONÇALVES, V. A.; BENEVENUTE, S. S.; FERREIRA, G. L.; FERREIRA, L. R.; FERREIRA, F. A. Acúmulo de macronutrientes por plantas daninhas e de milho cultivadas em convivência em solo com diferentes manejos de fertilidade. **Semina: Ciências Agrárias**, Londrina, v. 36, n. 2, p. 669-682, mar./abr. 2015. DOI: 10.5433/1679-0359.2015v36n2p669.

MENEGOLA, A.; FORNACIALI, M.; PIRES, R.; BITTENCOURT, F. V.; AVILA, S.; VALLE, E. Knowledge transfer for melanoma screening with deep learning. arXiv preprint arXiv:1703.07479, 2017.

MONACO, T. J.; WELLER, S. C.; A., Floyd M. A. **WEED SCIENCE Principles and Practices**. 4ª ed., JOHNWHILE e SONS, 2002.

MOREIRA, H. J. C. & BRAGANÇA, H. B. N. Manual de identificação de plantas infestantes: Hortifrútil. São Paulo: FMC Agricultural Products, 2011.

OERKE, E. C. Crop losses to pests. **Journal of Agricultural Science**, v. 144, n. 1, p. 31–43, 2006.

OLIVEIRA, Ângelo Rocha de. Redes Neurais Artificiais Aplicadas Na Detecção, Classificação E Localização De Defeitos Em Linhas De Transmissão. 132 f., Dissertação (Mestrado em Engenharia Elétrica), Universidade Federal de Juiz de Fora, Juiz de Fora, 2005.

OLSEN, A.; KONOVALOV, D. A.; PHILIPPA, B.; RIDD, P.; WOOD, J. C.; JHONS, J. *et al.* Deepweeds: a multiclass weed species image dataset for deep learning. **Sci Rep**, v. 9, 2058, 2019. doi: 10.1038 / s41598-018-38343-3

Olson, D. L., & Dursun, D. *Advanced Data Mining Techniques*, Ed. 1ª, Springer, p. 138, ISBN 3-540- 76916-1

PAGNONCELLI, F. B.; TREZZIL, M M.; VIDAL, R. A.; PORTES, A. F.; SCALCON, E. L.; MACHADO, A. Morning glory species interference on the development and yield of soybeans. **Bragantia**, Campinas, v. 76, n. 4, p.470-479, 2017.

PAN S.J. & QIANG Y. A Survey on Transfer Learning. *IEEE Trans. Knowl. Data Eng.* V. 22, n. 10, p. 1345–1359, 2010. doi: 10.1109/TKDE.2009.191

PARTEL, V.; KAKARLA, S. C.; AMPATZIDIS, Y. Development and evaluation of a low-cost and smart technology for precision weed management utilizing artificial intelligence. **Computers and Electronics in Agriculture**, v. 157, p. 339-350, 2019.

PICCININI, F.; MACHADO, S. L. O.; MARTIN, T. N.; KRUSE, N. D.; BALBINOT, A.; GUARESCHI, A. Interference of morning glory in soybean yield. **Planta Daninha**, v. 36, 2018. DOI: 10.1590 / s0100-83582018360100063.

PULIDO, C.; SOLAQUE, L.; VELASCO, N. Weed recognition by SVM texture feature classification in outdoor vegetable crop images. **Ingeniería e Investigación**, v. 37, n. 1, p. 68 – 74, 2017.

PULIDO-ROJAS, C. A.; MOLINA-VILLA, M. A.; SOLAQUE-GUZMÁN, L. E. Machine vision system for weed detection using image filtering in vegetables crops. **Revista Facultad de Ingeniería Universidad de Antioquia**, n.80, Medellín, 2016.

QUAN, L.; FENG, H.; LY, Y.; WANG, O.; ZHANG, C.; LIU, J. e YUAN, Z. Maize seedling detection under different growth stages and complex field environments based on an improved Faster R-CNN. **Biosystems engineering**, v. 184, p. 1- 23, 2019.

REDMON, J. & FARHADI, A. YOLOv3: An Incremental Improvement. *Computer Science*, arXiv pré impressão arXiv: 1804.02767. 2018. Disponível em: <http://arxiv.org/abs/1804.02767>. Acesso em: novembro 2018.

REN, S.; HE, K.; GIRSHICK, R.; SUN, J. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. 2016. Disponível em: <https://arxiv.org/abs/1506.01497v3>. Acesso em: novembro 2018.

REYES, A.K., CAICEDO, J.C., CAMARGO, J.E.: Fine-tuning deep convolutional networks for plant recognition. In: Working Notes of Conference and Labs of the Evaluation forum (CLEF) (2015).

REZATOFIGHI, H.; TSOI, N.; GWAK, J.; SADEGHIAN, A.; REID, I; & SAVARESE, S. "Generalized Intersection Over Union: A Metric and a Loss for Bounding Box Regression ", Conferência IEEE / CVF sobre visão computacional e Reconhecimento de padrões (CVPR) , Long Beach, CA, EUA, 2019, p. 658-666, doi: 10.1109 / CVPR.2019.00075.

RIZZARDI, M. A.; FLECK, N. G.; MUNDSTOCK, C. M.; BIANCHI, M. A. perdas de rendimento de grãos de soja causadas por interferência de picão-preto e guanxuma. **Ciência Rural**, Santa Maria, v. 33, n. 4, p. 621-627, 2003.

RIZZARDI, M. A.; FLECK, N. G.; VIDAL, R. A.; MEROTTO JR., A.; AGOSTINETTO, D. Competição por recursos do solo entre plantas daninhas e culturas. **Ciência Rural**, v. 31, n. 4, 2001.

RIZZARDI, M. A.; ROMAN, E. S.; BOROWSKI, D. Z.; MARCON, R. Interferência de populações de *Euphorbia heterophylla* e *Ipomoea ramosissima* isoladas ou em misturas sobre a cultura de soja. **Planta Daninha**, Viçosa-MG, v. 22, n.1, p. 29-34, 2004.

RODRIGUES, S. & SILVA, A. F. Weeds associated with cotton crop and hosting whitefly. Arquivos do Instituto Biológico. v.85, 1-5, e0242017, 2018. DOI: 10.1590/1808-1657000242017.

SALAKHUTDINOV, R. & HINTON, G. **Deep Boltzmann machines**. Artificial intelligence and statistics, p. 448-455. 2009.

SARKER, M. I. & KIM, H. Farm land weed detection with region-based deep convolutional neural networks. arXiv preprint arXiv:1906.01885, 2019 - arxiv.org. Disponível em:< <https://arxiv.org/abs/1906.01885>>, Acessado em: agosto 2019.

SCHIOSCHET, T. & DE PAULA, N. Soja transgênica no Brasil: os limites do processo de difusão tecnológica. **Estudos sociedade e agricultura**, v. 16, n. 1, p. 27-53, 2008.

SCHOENINGER, E. R.; KOEHLER, H. S. ; WATZLAWICK, L. F. & DE OLIVEIRA FILHO, P. C.. Uso de redes neurais artificiais como uma alternativa para mapeamento de biomassa e carbono orgânico no componente arbóreo de florestas naturais. **Ambiência**, v. 4, n. 3, p. 529–549, 2009.

SHARIF RAZAVIAN, A., AZIZPOUR, H., SULLIVAN, J., & CARLSSON, S. (2014). CNN features off-the-shelf: An astounding baseline for recognition. In Paper presented at the proceedings of the IEEE conference on computer vision and pattern recognition workshops.

SHRIKUMAR A, GREENSIDE P, KUNDAJE A. Learning important features through propagating activation differences. CoRR. 2017. Available at <http://arxiv.org/abs/1704.02685>.

SILVA, I.A.B.; KUVA, M.A.; ALVES, P.L.C.A.; SALGADO, T.P. Interferência de uma comunidade de plantas daninhas com predominância de *Ipomoea hederifolia* na cana-soca. **Planta Daninha**, Viçosa-MG, v. 27, nº 2, p. 265-272, 2009. Doi: <http://dx.doi.org/10.1590/S0100-83582009000200008>

SILVA, M.R.M. & DURIGAN, J.C. Períodos de interferência das plantas daninhas na cultura do arroz de terras altas. I - Cultivar IAC 2021. **Planta Daninha**, Viçosa-MG, v. 24, n. 4, p. 685-694, 2006.

STAFFORD, J. V. e MILLER, P. C. H. Spatially variable treatment of weed patches. In: Proceedings of the 3rd International Conference on Precision Agriculture, edited by P. C. Roberts, R. H. Rust and W. E. Larsen (American Society of Agronomy, Madison, USA), p. 465–474, 1996.

TAGHADOMI-SABERI, S. e HEMMALT, A. Improving field management by Machine vision - A review. **CIGR Journal**, v. 17, p. 92-111, 2015. Disponível em: https://www.researchgate.net/publication/282641179_Improving_field_management_by_Machine_vision_-_A_review. Acesso em: junho 2019

TANG, J.; WANG, D.; ZHANG, Z.; HE, L.; XIN, J. e XU, Y. Weed identification based on K-means feature learning combined with convolutional neural network. **Computers and Electronics in Agriculture**, v. 135, p. 63–70, 2017. <http://dx.doi.org/10.1016/j.compag.2017.01.001>

VASCONCELOS, M. C. C.; DA SILVA, A. F. A.; LIMA, R. S. Interferência de Plantas Daninhas sobre Plantas Cultivadas. **Agropecuária científica no semiárido**, v. 8, n. 1, p. 1–6, 2012. Disponível em: <<http://www.cstr.ufcg.edu.br/acsa/%5CnRevista>>.

VICTORIA FILHO, R. e CHRISTOFFOLETI, P. J. Manejo de plantas daninhas e produtividade da cana. **Visão agrícola**, n. 1, 2004. Disponível em: <https://www.esalq.usp.br/visaoagricola/sites/default/files/cana-producao-vegetal03.pdf>. Acesso em: janeiro 2019.

VILIOTTI, C. A. Desenvolvimento de um sistema eletrônico para detecção da presença de plantas daninhas e controle da aplicação de herbicidas. Tese – (Doutor em Engenharia Agrícola), Universidade Federal de Viçosa, Viçosa -MG, 2002.

VISSER, R. & TIMMERMANS, A. J. M. O.. Weed-It: a new selective weed control system. Proc. SPIE 2907 Optics in Agriculture, Forestry, and Biological Processing II. 1996. Doi: 10.1117/12.262852.

WANG, A.; ZHANG, W.; WEI, X. A review on weed detection using ground-based machine vision and image processing techniques. **Computers and Electronics in Agriculture**. v. 15; n. 8, p. 226-240, 2019.

Y. Long, Y. Gong, Z. Xiao and Q. Liu, "Accurate Object Localization in Remote Sensing Images Based on Convolutional Neural Networks," in *IEEE Transactions on Geoscience*

and Remote Sensing, vol. 55, no. 5, pp. 2486-2498, May 2017.
doi: 10.1109/TGRS.2016.2645610

YU, J., SCHUMANN, A. W., CAO, Z., SHARPE, S. M., & BOYD, N. S. (2019). Weed Detection in Perennial Ryegrass With Deep Learning Convolutional Neural Network. **Frontiers in plant science**, 10, 1422. <https://doi.org/10.3389/fpls.2019.01422>

ZHENG, Y., ZHU, Q., HUANG, M., GUI, Y., QIN, J. Maize and weed classification using color indices with support vector data description in outdoor fields. **Computers and Electronics in Agriculture**, v. 141, p. 215–222, 2017.
doi:10.1016/j.compag.2017.07.028

ZHOU, T.; RUAN, S.; CANU, S. A review: Deep learning for medical image segmentation using multi-modality fusion. **ARRAY**, 2019, doi: <https://doi.org/10.1016/j.array.2019.100004>.

ZIMDAHIL, R. L. *Fundamentals of Weed Science*. 3^a ed., Elsevier, 2007.

MENEZES, R. S. T.; MAGALHÃES, R. M. & MAIA, H. Object Recognition Using Convolutional Neural Networks [Online First], **IntechOpen**, 2019. DOI: 10.5772/intechopen.89726. Disponível em: <<https://www.intechopen.com/online-first/object-recognition-using-convolutional-neural-networks>>. Acessado em: novembro 2019.