

# Plano de Trabalho: Sexagem automática de pupas de *Spodoptera frugiperda* por meio da rede neural Faster R-CNN

João Vitor de Andrade Porto<sup>a,b</sup>, Hemerson Pistori (Orientador)<sup>b,c</sup>, Gilberto Astolfi (Coorientador)<sup>b,a</sup>

<sup>a</sup>RA: 170291, Curso: Engenharia de Computação, Semestre: Sétimo

<sup>b</sup>Universidade Católica Dom Bosco, Campo Grande, MS, Brazil

<sup>c</sup>Federal University of Mato Grosso do Sul, Campo Grande, MS, Brazil

---

## Abstract

A lagarta *Spodoptera frugiperda* (J. E. Smith, 1797) (Noctuidae) é um objeto de estudo de grande importância para a economia nacional pois além de atacar o plantio do milho, sendo a maior praga desta cultura, também inflige diversas outras plantas cultivadas no território nacional, atacando tanto gramíneas como milheto, trigo e arroz, como também os cultivos de soja, tomate e algodão. Visto que a sexagem do inseto é um processo árduo e cansativo sendo feito de maneira manual, este trabalho propõe uma abordagem automática utilizando técnicas de visão computacional aliadas a redes neurais para o desenvolvimento de um protótipo de software que tem por objetivo auxiliar nos processos laboratoriais envolvendo indivíduos da espécie.

**Keywords:** Visão Computacional, *Spodoptera frugiperda*, Faster R-CNN

---

## 1. Introdução

Popularmente conhecida como a lagarta-do-cartucho, inicialmente por ter sido observada como praga na cultura do milho, a *Spodoptera frugiperda* (J. E. Smith, 1797) (Noctuidae) também ataca várias outras plantas da família das gramíneas como milheto, trigo, arroz [10] [8] [32]. No estado do Mato Grosso do Sul há relatos de ataque nas culturas de soja, tomate e algodão [25].

Os registros de Cruz [6], referência do estudo da praga no território nacional, informa que foi identificada pela primeira vez como a praga do milho em 1797, na Geórgia, Estados Unidos, originalmente descrita como *Phaenajaena frugiperda*. Hoje reconhecida por *S. frugiperda* como um inseto de metamorfose completa, sendo que seus ovos são colocados em massa nas folhas da planta. As larvas nascem em apenas dois dias, se a temperatura média for de 26,7°C. A duração do ciclo de vida pode variar conforme a temperatura ambiente, podendo variar entre 30 a 50 dias. Devido as condições climáticas favoráveis, no Brasil é possível encontrar a ocorrência do inseto durante todo o ano, e em diferentes regiões do país.

O controle químico através do uso de inseticidas sintéticos é a forma ampla aplicada em todo território nacional, contudo as aplicações de inseticidas realizadas de forma tardia e frequentemente acima do nível de controle definido em 20% no período vegetativo e 10% no período reprodutivo, e não atendendo as normativas de uso

tem desencadeado o surgimento de populações de insetos praga resistentes. Associado com ao uso incorreto, existe também a ação sobre os demais insetos, contaminação ambiental, contaminação dos alimentos produzidos, risco de intoxicação dos agricultores, entre outros [17] [33].

Uma opção promissora está no uso de plantas com potencial inseticida para o controle da lagarta. Os inseticidas botânicos foram muito populares e importantes entre as décadas de 30 e 40 no Brasil, o qual foi grande produtor e exportador destes produtos [1]. Por este motivo houve grande incentivo para os pesquisadores desenvolverem estudos com novas táticas de controle alternativo de pragas, como o uso de inseticidas de origem vegetal os quais podem causar diversos efeitos sobre os insetos-alvo como repelência, inibição de oviposição e da alimentação, alterações no sistema hormonal, causando distúrbios no desenvolvimento, deformações, infertilidade e mortalidade nas diversas fases [23] [7] [36].

Na busca de medidas alternativas que gerem menor impacto residual e diminuam os problemas associados, o grupo de Bioprospecção da UCDB instituído desde 2005 com a criação da Rede Pantaneira de Bioprospecção, do Centro de Pesquisas do Pantanal, CPP e posteriormente, pelo Instituto Nacional de Áreas úmidas, INAU, vem desenvolvendo estudos no intuito de contribuir efetivamente para mitigar esse problema através do desenvolvimento de inseticidas botânicos. E para tal desenvolve a criação de insetos em laboratório, para realização de testes de controle biológico e estudo das interferências de extratos de plantas e moléculas sobre o ciclo de vida do inseto.

Porém existem algumas variáveis morfológicas que precisam ser realizadas e comparadas com precisão, o que é

---

Email addresses: [jvporto@gmail.com](mailto:jvporto@gmail.com) (João Vitor de Andrade Porto), [pistori@ucdb.br](mailto:pistori@ucdb.br) (Hemerson Pistori (Orientador)), [gilberto.astolfi@ifms.edu.br](mailto:gilberto.astolfi@ifms.edu.br) (Gilberto Astolfi (Coorientador))

difícil e demorado de ser realizado manualmente, necessitando de ferramentas e equipamento que viabilizem com precisão e acuidade. Nesse caso nota-se a possibilidade do desenvolvimento de um software baseado em visão computacional para auxiliar os experimentos biológicos, que vão desde o acompanhamento do desenvolvimento do ciclo de vida até a identificação de características específicas ou coletas de dados. Especificamente na criação massal da *S. frugiperda* as imagens obtidas na fase de pupa servirão para realizar a classificação automática de machos e fêmeas, etapa crucial para a montagem das gaiolas de acasalamento e geração de população, que no momento atual é realizado manualmente e requer uma grande demanda de tempo. Dessa maneira foi levantada a hipótese do uso da *Faster R-CNN* (rede neural convolucional mais rápida focada em proposta de região) para reduzir a influência humana e promover aumento na velocidade e precisão neste processo que já se provou capaz de detectar e classificar múltiplos objetos dentro de uma mesma imagem através de diversas camadas de processamento em paralelo, que oferecem componentes de modelagem com informações geométricas essenciais [5] [34] [12].

## 2. Objetivos

### 2.1. Geral

O objetivo deste trabalho é desenvolver um protótipo de software com base na rede neural *Faster R-CNN* para realizar a sexagem automática de pupas por meio de imagens capturadas por estereomicroscópio.

### 2.2. Específicos

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

- Construir um banco de imagens contendo pupas de *Spodoptera frugiperda*.
- Propor um métodos de treinamento para a rede neural *Faster R-CNN*
- Analisar estatisticamente o desempenho dos métodos propostos.
- Desenvolver o protótipo do software de sexagem automática.

## 3. Revisão de literatura

### 3.1. *Spodoptera frugiperda*

A *Spodoptera frugiperda* (J. E. Smith, 1979) (Lepidoptera: Noctuidae) é um inseto praga de grande distribuição nas Américas, no Brasil é conhecida por lagarta-do-cartucho, embora também receba as designações de lagarta-dos-milharais ou lagarta-militar. O milho é a principal cultura alvo do seu ataque, porém nos últimos anos o ataque tem se intensificado em parte pela eliminação

tanto dos inimigos naturais como também pelo uso indiscriminado e recorrente de agrotóxicos, além do aumento do número de safras no mesmo ano que induz ao aumento na aplicação num período de tempo menor que o necessário para a acumulação dos produtos químicos. Embora a cultura do milho (*Zea mays* L.) seja a preferência para infestação pela *S. frugiperda*, o fato de ser uma espécie polífaga, é comum observar a infestação nas culturas de soja (*Glycine max* (L.) Merr.), tomate (*Solanum lycopersicum* L.) e algodão (*Gossypium hirsutum* L.) [25].

Considerada como uma das espécies mais nocivas nas regiões tropicais das Américas, por sua ampla distribuição geográfica e incidência nas diferentes estações do ano, apresenta elevado potencial biótico quando em condições climáticas favoráveis. Sua polifagia permite ainda que essa praga tenha fontes variadas de alimentação, favorecendo ao ataque de diferentes cultivos, além da infestação em duas e até mesmo três safras consecutivas na mesma área, garantindo a manutenção de gerações durante todo o ano [27] [3] [25].

Em sua metamorfose, os adultos de *S. frugiperda* são mariposas com 35 mm de envergadura, asas anteriores pardo-escuras e as posteriores branco-acinzentadas, a sua postura varia de 1500 a 2000 ovos. Passados cerca de três dias os ovos eclodem e dão origem as lagartas de primeiro instar que se alimentam das folhas das plantas e conforme vão se desenvolvendo conseguem fazer furos e até destruir completamente o vegetal. É interessante inferir que, mesmo apresentando hábito de herbivoria, quando existem uma concentração de indivíduos em determinado ambiente ou em local restrito de oferta alimentar é comum observar o canibalismo nesta espécie. A próxima fase é a larval que dura de 12 a 30 dias, em seguida penetram no solo onde se transformam em pupas, permanecendo por 8 dias no verão e até 25 dias no inverno, fato este que interfere diretamente nos períodos entre gerações [2].

Predominantemente o controle das pragas mais eficientes são de origem sintética, tanto pela praticidade como pela rápida resposta, contudo, são tóxicos em sua maioria para animais, e ainda afetam espécies não-alvo e contaminam o meio ambiente. Outra forma de controle é o uso de espécies vegetais transgênicas, as quais contem genes exógenos, no geral vindos do *Bacillus thuringiensis* (Bt), que são inofensivas ao homem e meio ambiente. Entretanto, os cultivares Bt disponíveis no mercado brasileiro já há indícios de evolução de resistência de *S. frugiperda*, o que promove a pressão de seleção e alta infestação [35].

As perdas decorrentes das infestações pela lagarta-do-cartucho alcançam de 17% a 38,7% na produção de milho e de sorgo, com ocorrência também registrada de declínio em lavouras de algodão, soja, pastagens dentre outras. A presença da resistência de plantas impulsiona ao desenvolvimento de outras estratégias de controle de pragas, a exemplo do MIP (manejo integrado de pragas). Entre os termos para definir resistência de plantas estão a tolerância e a suscetibilidade, condicionada ao efeito adverso sobre a população de uma ou mais espécies de insetos-praga, rela-

cionada aos mecanismos como as alterações negativas no desenvolvimento do inseto, chamada antibiose, a não preferência ou antixenose ocorre quando a planta é menos utilizada ou preferida para alimentação, oviposição e a menor escolha como fonte alimentar, interferindo nas fases imaturas, redução de tamanho e peso das fases imaturas e adultas e redução da fecundidade e fertilidade nos adultos [24].

A voracidade do consumo alimentar pode comprometer todo o ciclo da cultura, com capacidade de completar mais de oito gerações por ano, em alguns sistemas de produção de cultivos do Brasil, razão pela qual há o uso recorrente de inseticidas químicos como piretroides, fosforados e espinosinas, propiciando a evolução da resistência a diferentes grupos químicos e a necessidade cada vez mais frequente de inseticidas, contribuindo para o aumento dos custos de produção e poluindo o meio ambiente. Motivo pelo qual tem sido realizado vários estudos de laboratório com intuito de obter fontes de resistência, conhecimentos dos aspectos biológicos e da fertilidade, visando gerar informações para a maximização das estratégias de manejo de supressão populacional da praga [9].

### 3.2. Visão Computacional

A visão computacional pode ser definida como a geração de novas representações ou decisões utilizando ferramentas computacionais a partir de uma imagem estática ou em movimento que, por meio de valores extraídos de seus pixels, infere o conteúdo da imagem e cria identidade para certos grupos de pixels, podendo assim automatizar tal processo [37], [19].

Esta área da computação busca desenvolver teorias e métodos voltados à extração de informações significativas de uma imagem ou do ambiente ao redor, possibilitando reconhecer, manipular e analisar os objetos que compõem esse meio. Ela tem a capacidade de extrair informações relevantes a partir de imagens capturadas por câmeras fotográficas, vídeos, sensores, entre outros dispositivos, para automatizar a tomada de decisão. E em particular, ao ser aplicada ao sistema agrícola, é definida como agricultura de precisão, fazendo uso das técnicas de tecnologia da informação, com o auxílio de técnicas de visão computacional, aprendizado de máquina através de redes neurais e reconhecimento de padrões desenvolvemos um algoritmo capaz de identificar plantas que contenham as doenças ou ameaças. A partir deste diagnóstico fornecido pelo algoritmo, o agricultor terá condições de tomar as medidas necessárias para tratamento de sua plantação evitando prejuízos futuros [11].

A resolução dos problemas de produtividade é uma nova maneira de gerenciar a produção com o auxílio de tecnologias e procedimentos que visam otimizar a lavoura. Neste contexto a utilização de um VANT (Veículo Aéreo Não Tripulado) serve para mensurar a produtividade através da visão computacional e aprendizagem de máquina, aplicando a tecnologia no campo, a fim de obter maior exatidão na mensuração da produtividade das culturas agrícolas [26].

As tecnologias de inteligência artificial (ia) estão permitindo identificar com mais precisão doenças em folhas de plantas por meio da análise de imagens, com efeitos benéficos sobre a agricultura (custo, eficiência, qualidade), e através das características visuais está sendo possível o reconhecimento das doenças em cada tecnologia/plataforma analisada, e assim agir diretamente no problema localizado [21].

Outra aplicação da VC (Visão Computacional) é para dimensionar os campos para iniciar tratamentos com inseticidas, utilizando a capturar imagens de uma lavoura de milho, com o objetivo de estimar o índice de área foliar (IAF) de um talhão infestado por *S. frugiperda*. Durante o ciclo da cultura do milho foram realizadas várias avaliações: determinação do índice de área foliar (IAF), severidade do ataque da praga. Os resultados obtidos demonstraram eficiência e maior precisão na estimativa do IAF para o modelo radiométrico e minimização para aplicação dos produtos químicos [31].

### 3.3. Redes Neurais Convolucionais

A junção da visão computacional com o reconhecimento de padrões é comumente usada nas redes neurais, definidas como unidades computacionais paralelas com interconexão parcial ou total através de unidades funcionais nomeadas de “neurônios artificiais”, que realizam operações determinadas e transmitem seus resultados entre si pelo processo de *feed forward*. Por meio de um treinamento, a rede consegue reconhecer e identificar padrões em várias imagens [29].

Antes da criação das redes neurais convolucionais (*CNN*), um dos métodos clássicos para se classificar imagens de qualquer tipo se dava pela extração de características visuais da imagem, geração de um pacote de palavras representando tais características e classificação das mesma através do uso de uma Máquina de Vetores de Suporte (*Support Vector Machine*) associada ao pacote previamente gerado. Com a criação das *CNNs*, os três processos foram unificados gerando alta capacidade de treinamento. Geralmente, estas redes têm sido usadas para a compreensão de imagens, que podem ser integradas e convertidas em algoritmos capazes de gerar informações para uma identificação seletiva [22], [20].

As *CNNs* são focadas na classificação das imagens como um todo, ignorando os possíveis objetos contidos nela. Através deste conceito foi desenvolvida uma rede neural convolucional focada em regiões, a *R-CNN*, que trabalha com regiões dentro da imagem classificando seus objetos separadamente. Apesar da melhora na classificação de objetos a *R-CNN* ainda apresenta complexidade notável devido às várias localizações que podem ter um objeto, localizações estas chamadas de propostas presentes durante toda a execução do método, gerando a necessidade de um maior processamento para remover regiões desnecessárias, sacrificando a velocidade ou acurácia. Por esta razão foi desenvolvida a *Fast R-CNN* que busca melhorar o algoritmo de aprendizagem de região já presente na *R-CNN* a

fim de simplificar e agilizar o treinamento e classificação [15], [14].

Mantendo a sequência de melhorias já feitas na *Fast R-CNN*, o método das redes neurais convolucionais mais rápidas baseadas em propostas de região (*Faster R-CNN*) usam duas redes neurais convolucionais multicamadas executadas em paralelo. A primeira sendo essencialmente uma *Fast R-CNN*, responsável pela extração de características das regiões anotadas pela segunda rede, sendo esta a Rede Neural para Proposta de Região (*RPN*) que é baseada na *Fast R-CNN* porém apresenta camadas adicionais para auxiliar na proposição de regiões retangulares com pontuações associadas na imagem, onde cada uma destas determina a probabilidade que a região apresenta de conter um dado objeto [14], [18], [30].

## 4. Materiais e Métodos

### 4.1. Banco de imagens

A metodologia para criação em ambiente de laboratório será adaptada de Giolo et al. (2002) [13] e de Busato et al. (2005) [4], através do cultivo controlado de lagartas de *S. frugiperda* provenientes da cultura de milho no campus da Fazenda Escola Lagoa da Cruz, da Universidade Católica Dom Bosco (UCDB) (latitude 20°23'15.82"S e longitude 54°36'40.22") durante o período de seca.

Os indivíduos selecionados da coleta na fase de lagarta serão separados e criados separadamente seguindo a metodologia previamente citada e serão alimentados com uma dieta artificial de acordo com Greene et al. (1976) [16], modificada por Parra (2001) [28]. A criação será feita por meio de tubos de vidro de fundo chato (2,5 cm de diâmetro x 8,5 cm de altura) contendo os indivíduos e seus alimentos, estes tubos serão organizados em uma estante de MDF, para estabelecimento da criação massal, no laboratório de Entomologia da UCDB (B09). O cultivo em tubos de dieta artificial se manterá até que os indivíduos alcancem a fase de pupa, onde ocorrerá o processo de captura de imagens e formulação do banco.

O processo de captura será feito através do estereomicroscópio Leica MC170 HD, onde cada imagem conterá um indivíduo e será nomeada de acordo com o gênero da pupa, essa classificação de gênero será feita pelo aluno de mestrado responsável pela criação massal. Com o banco formado e por meio da ferramenta de anotação *LabelImg*<sup>1</sup> serão gerados arquivos *.XML* para cada imagem do banco contendo dados de localidade das regiões de interesse que representam as características do gênero de cada pupa, estas regiões serão classificadas de acordo com o nome da imagem à qual pertencem.

### 4.2. Estudo dos parâmetros

Serão feitas pesquisas sobre outros trabalhos relacionados usando redes neurais convolucionais para solução de

problemas parecidos, destes trabalhos serão coletados os parâmetros iniciais para o estudo. Com os parâmetros iniciais definidos serão feitas rodadas de treinamento e teste usando a implementação da *Faster R-CNN*<sup>2</sup> e através dos gráficos provenientes destas rodadas de treino e teste os parâmetros finais serão definidos.

### 4.3. Método de amostragem

Com os parâmetros finais definidos, as imagens serão separadas em 10 grupos de mesmo tamanho para a execução da validação cruzada de 10 dobras. Em cada dobra um grupo será selecionado para o teste e os demais servirão para treinamento e validação seguindo a distribuição interna da *Faster R-CNN*, cada grupo somente participará do processo uma vez como teste. Esta validação cruzada será executada quatro vezes variando os hiperparâmetros de aumento de dados (com e sem aumento) e rede base (vgg16 ou resnet50), para cada uma destas execuções serão salvos dados de precisão, acurácia e medida F para uma análise posterior.

### 4.4. Análise de desempenho

Através dos dados da subseção 4.3 as execuções serão comparadas estatisticamente entre si utilizando o *software* estatístico R, versão 4.0.0, por meio da análise de variância (ANOVA) com pós-teste de Tukey ao nível de significância de 5%. Para esta análise também serão utilizadas ferramentas de estatística robusta, como diagramas de caixa-e-bigode (*boxplots*).

## 5. Cronograma

Em resumo, as seguintes atividades serão realizadas:

1. Estudar artigos sobre classificação e sexagem de insetos usando redes neurais
2. Capturar e anotar imagens de *Spodoptera frugiperda*
3. Estudar os parâmetros da *Faster R-CNN* e realizar rodadas de teste para definir a melhor combinação para o problema
4. Escrever o relatório parcial do PIBIC
5. Realizar testes usando o método de treinamento proposto juntamente com a técnica de amostragem previamente definida.
6. Comparar estatisticamente os resultados obtidos
7. Escrever o artigo final do PIBIC

A tabela 1 apresenta o cronograma bimestral para as atividades propostas.

<sup>2</sup>GitHub da implementação: <http://git.inovisao.ucdb.br/inovisao/frcnn>

<sup>1</sup>GitHub da ferramenta: <https://github.com/tzutalin/labelImg>

Table 1: Cronograma Bimestral de Execução das Atividades Propostas

Ativ.	B1	B2	B3	B4	B5	B6
1	X	X				
2	X	X				
3			X	X		
4			X			
5			X	X	X	
6					X	
7					X	X

## References

- [1] Aguiar-Menezes, E., 2005. Inseticidas botânicos: seus princípios ativos, modo de ação e uso agrícola. documentos, 205. Seropédica: Embrapa Agrobiologia, 58p.
- [2] BALESTRIN, A. L., BORDIN, S., 2016. Uso de trichogramma pretiosum no controle de spodoptera frugiperda em lavoura de milho. Revista Eletrônica Científica da Uergs 2 (3), 259–266.
- [3] Boregas, K. G. B., Mendes, S. M., Waquil, J. M., Fernandes, G. W., 2013. Estádio de adaptação de spodoptera frugiperda (je smith)(lepidoptera: Noctuidae) em hospedeiros alternativos. Embrapa Milho e Sorgo-Artigo em periódico indexado (ALICE).
- [4] Busato, G. R., Grützmacher, A. D., Garcia, M. S., Giolo, F. P., Zotti, M. J., Stefanello Júnior, G. J., 2005. Biologia comparada de populações de spodoptera frugiperda (je smith)(lepidoptera: Noctuidae) em folhas de milho e arroz. Neotropical Entomology 34 (5), 743–750.
- [5] Cheng, B., Wei, Y., Shi, H., Feris, R., Xiong, J., Huang, T., 2018. Revisiting rcnn: On awakening the classification power of faster rcnn. In: Proceedings of the European Conference on Computer Vision (ECCV). pp. 453–468.
- [6] Cruz, I., 1995. A lagarta-do-cartucho na cultura do milho. Embrapa Milho e Sorgo-Circular Técnica (INFOTECA-E).
- [7] de Almeida, S. A., Almeida, F., Santos, N., Araujo, M., Rodrigues, J., 2004. Atividade inseticida de extratos vegetais sobre callosobruchus maculatus (fabr., 1775)(coleoptera: Bruchidae). Current Agricultural Science and Technology 10 (1).
- [8] Dequech, S. T. B., Camera, C., Sturza, V. S., Ribeiro, L. d. P., Querino, R. B., Poncio, S., 2013. Population fluctuation of spodoptera frugiperda eggs and natural parasitism by trichogramma in maize. Acta Scientiarum. Agronomy 35 (3), 295–300.
- [9] Fernandes, F. O., Abreu, J. Á., Christi, L., Rodrigues Filho, J. A., Martins, A., da Rosa, A. P. S. A., 2017. Boletim de pesquisa e desenvolvimento 264.
- [10] Figueiredo, M. d. L. C., Martins-Dias, A. M. P., Cruz, I., 2006. Relação entre a lagarta-do-cartucho e seus agentes de controle biológico natural na produção de milho. Pesquisa Agropecuária Brasileira 41 (12), 1693–1698.
- [11] GALVÃO, G. F. P., Carvalho, W., Rocha, W., da Silva Costa, J. C., 2018. Visão computacional para detecção de doenças fúngicas na agricultura. ÚNICA Cadernos Acadêmicos 2 (1).
- [12] Galvez, R. L., Bandala, A. A., Dadios, E. P., Vicerra, R. R. P., Maningo, J. M. Z., 2018. Object detection using convolutional neural networks. In: TENCON 2018-2018 IEEE Region 10 Conference. IEEE, pp. 2023–2027.
- [13] GIOLO, F., Grützmacher, A., Garcia, M., Busato, G., 2002. Parâmetros biológicos de spodoptera frugiperda (je smith, 1797)(lep.: Noctuidae) oriundas de diferentes localidades e hospedeiros. Current Agricultural Science and Technology 8 (3).
- [14] Girshick, R., 2015. Fast r-cnn. In: Proceedings of the IEEE international conference on computer vision. pp. 1440–1448.
- [15] Girshick, R., Donahue, J., Darrell, T., Malik, J., 2014. Rich feature hierarchies for accurate object detection and semantic segmentation. In: Proceedings of the IEEE conference on computer vision and pattern recognition. pp. 580–587.
- [16] Greene, G., Leppla, N., Dickerson, W., 1976. Velvetbean caterpillar: a rearing procedure and artificial medium. Journal of Economic Entomology 69 (4), 487–488.
- [17] Grützmacher, A., Martins, J. d. S., Cunha, U. d., Parfitt, J., 2000. Insetos-pragas das culturas do milho e sorgo no agroecossistema de várzea. PARFITT, JMB Produção de milho e sorgo em várzea. Pelotas: Embrapa Clima Temperado, 87–102.
- [18] He, K., Gkioxari, G., Dollár, P., Girshick, R., 2017. Mask rcnn. In: Proceedings of the IEEE international conference on computer vision. pp. 2961–2969.
- [19] Kaehler, A., Bradski, G., 2016. Learning OpenCV 3: computer vision in C++ with the OpenCV library. ” O’Reilly Media, Inc.”.
- [20] Karpathy, A., Toderici, G., Shetty, S., Leung, T., Sukthankar, R., Fei-Fei, L., 2014. Large-scale video classification with convolutional neural networks. In: Proceedings of the IEEE conference on Computer Vision and Pattern Recognition. pp. 1725–1732.
- [21] Kaufman, D., Boas, L. L. V., 2019. Visão computacional na agricultura: Apis de detecção e reconhecimento de doenças das plantas. TECCOGS: Revista Digital de Tecnologias Cognitivas (20).
- [22] Lenc, K., Vedaldi, A., 2015. R-cnn minus r. arXiv preprint arXiv:1506.06981.
- [23] Martinez, S., Van Emden, H., 1999. Sublethal concentrations of azadirachtin affect food intake, conversion efficiency and feeding behaviour of spodoptera littoralis (lepidoptera: Noctuidae). Bulletin of Entomological Research 89 (1), 65–71.
- [24] MARTINS, L. d. O., dos Santos, A. J. N., Rocha, M. S., Damasceno, N., Guimarães, A. F., Figueiredo, Y. G., RODRIGUES, J., MENDES, S., 2016. Antibiose de spodoptera frugiperda alimentada em cultivares de sorgo. In: Embrapa Milho e Sorgo-Artigo em anais de congresso (ALICE). In: SEMINÁRIO DE INICIAÇÃO CIENTÍFICA PIBIC/BIC JÚNIOR, 10., 2016.
- [25] MENDES, S., da SILVA, A., CARVALHO, S. d. S., SOUZA, C., 2016. A buva (conyza spp.) pode ser considerada planta hospedeira de spodoptera frugiperda e helicoverpa armigera? Embrapa Milho e Sorgo-Comunicado Técnico (INFOTECA-E).
- [26] Nunes, C. D., Lopes, L. F. B., 2016. Proposta metodológica para avaliação de produtividade de lavouras de soja baseada em visão computacional e aprendizagem de máquina. Revista de Pós-Graduação do Centro Universitário Cidade Verde 2 (2).
- [27] Panizzi, A. R., Bueno, A. d. F., Silva, F. d., 2012. Insetos que atacam vagens e grãos. Soja: manejo integrado de insetos e outros artrópodes-praga. Brasília: Embrapa, 335–420.
- [28] Parra, J. R. P., 2001. Técnicas de criação de insetos para programas de controle biológico.
- [29] Perelmutter, G., Carrera, E., Vellasco, M., Pacheco, A., 1995. Reconhecimento de imagens bidimensionais utilizando redes neurais artificiais. Anais do VIII Sibgrapi, 197–203.
- [30] Ren, S., He, K., Girshick, R., Sun, J., 2015. Faster r-cnn: Towards real-time object detection with region proposal networks. In: Advances in neural information processing systems. pp. 91–99.
- [31] Resende, D. B., de Abreu Júnior, C. A. M., Martins, G. D., José, O., Marques, L. C. M. X., 2020. Uso de imagens tomadas por aeronaves remotamente pilotadas para detecção da cultura do milho infestada por spodoptera frugiperda. Revista Brasileira de Geografia Física 13 (01), 156–166.
- [32] Ribeiro, L. P., Dequech, S. T., Camera, C., Sturza, V. S., Poncio, S., Vendramim, J. D., et al., 2014. Vertical and temporal distribution of spodoptera frugiperda (je smith)(lepidoptera: Noctuidae) egg masses, parasitized and non-parasitized, on maize plants. Maydica 59 (2014), 315–320.
- [33] Silva, C. F., Bernardes, J. T., Goulart, A. C., Goulart, S. M., 2018. Estudo da lixiviação do carbofurano em diferentes perfis de coluna de latossolo vermelho. Acta Brasiliensis 2 (3), 96–99.
- [34] Singh, B., Davis, L. S., 2018. An analysis of scale invariance in object detection snip. In: Proceedings of the IEEE conference

- on computer vision and pattern recognition. pp. 3578–3587.
- [35] Soares, M. M., Vasconcelos, E. D., Braz, L. C. C., Ramos, J. P., da Silva, C. R. C., Sofiatti, V., dos Santos, R. C., 2017. Estimativa de mortalidade de *spodoptera frugiperda* alimentadas com milho bt (2b655pw) em ambiente semiárido. In: Embrapa Algodão-Artigo em anais de congresso (ALICE). In: SIMPÓSIO DE ENGENHARIA DE BIOTECNOLOGIA E BIOPROCESSOS DO SEMIÁRIDO, 2017.
- [36] Tavares, M. A., Vendramim, J. D., 2005. Bioatividade da erva-de-santa-maria, *chenopodium ambrosioides* L., sobre *sitophilus zeamais* Mots.(coleoptera: Curculionidae). *Neotropical Entomology* 34 (2), 319–323.
- [37] Weinstein, B. G., 2018. A computer vision for animal ecology. *Journal of Animal Ecology* 87 (3), 533–545.