

CLASSIFICAÇÃO DE INSETOS COM O USO DE REDES NEURAIS CONVOLUCIONAIS

Bruno Cabrera Garcia¹, Danilo Hernani Perico²

¹Engenharia de Robôs

²Ciência da Computação

brunocgarcia10@gmail.com e dperico@fei.edu.br

Resumo: O inseto *Euschistus heros*, também conhecido como percevejo-marrom, é uma praga e seu principal hospedeiro é a soja. Sua alimentação é feita através da sucção de seiva dos ramos, hastes e vagens, o que resulta em grande prejuízo econômico e reduz a produção da soja juntamente da redução da qualidade das sementes. Assim, utilizando visão computacional, serão classificados os percevejos-marrom entre fêmeas e machos também entre os estágios de vida do inseto-praga instar ou adultos, para trabalhar estes dados utilizou-se de *Convolutional Neural Network* (CNN), ou redes neurais convolucionais.

1. Introdução

O uso de agrotóxicos se torna cada vez mais presente nas lavouras com a intenção de maximizar a produção. O uso desses produtos químicos de fato acelera o crescimento da planta, protegendo-a contra pragas que tentam atacá-la. No entanto, o consumo destes agrotóxicos pode causar problemas graves como intoxicação e doenças agudas e crônicas nos seres humanos.

O percevejo marrom, *Euschistus*, é uma das grandes pragas da soja no Brasil. A reprodução desse percevejo é diretamente influenciada pela microvespa *podisibug*, que busca pelos ovos do percevejo no campo e, neles, deposita os seus próprios ovos, interrompendo o desenvolvimento do percevejo logo no início de seu ciclo (KOPPERT, 2021).

A empresa Koppert do Brasil oferece uma solução alternativa para controle de pragas e, assim, maior produção no cultivo da soja. A técnica, conhecida como Manejo Integrado de Pragas (MIP) (KOGAN, 1998) consiste na utilização de agentes biológicos para reduzir e eliminar pragas. A ideia no caso da soja é reproduzir os ovos de percevejos já com os ovos de *podisibug* em seu interior e liberar esses ovos na plantação.

Esse processo é muito benéfico, pois apresenta um combate contra defensivos químicos, caminhando, assim, para uma agricultura sustentável e não prejudicial ao meio ambiente.

O Centro Universitário FEI em parceria com a empresa Koppert do Brasil está desenvolvendo um projeto que tem como objetivo geral a automação da criação dos percevejos marrons e da extração de seus ovos. A automação da criação do percevejo marrom é bastante complexa e várias pesquisas podem ser realizadas com partes do problema completo.

Nesse projeto de pesquisa o foco é dado à classificação dos percevejos por meio do uso de Visão Computacional. A motivação dessa pesquisa vem do

fato de ser um problema a dificuldade encontrada por seres humanos para classificar corretamente se um inseto é macho ou fêmea. Outra classificação complexa é a distinção exata entre ninfas, que é a fase inicial da vida do inseto, e adultos.

2. Conceitos Fundamentais

Uma rede neural convolucional é uma rede neural feita em camadas onde dentro de cada camada há neurônios interconectados onde cada um possui peso e tendência de aprendizado. Para a rede neural convolucional, há camadas gerais chamadas por camada convolucional, camada de pooling e camada totalmente conectada, ou “Fully Connected (FC)”. A camada convolucional junta conjuntos de informações, a camada de pooling reduz a dimensão da camada e associa a saída dos neurônios a uma única camada. Por fim, a camada totalmente conectada associa todos os neurônios de uma camada a todos os outros de outra camada.

3. Metodologia

Criação de um banco de dados para as imagens do percevejo-marrom com suas classificações em instares e diferenciação de sexos. Inicialmente com uma rede neural para os instares do percevejo-marrom e outra para o sexo quando adulto. Os estágios escolhidos foram os 5 instares do ciclo de vida mais a fase adulta como uma única classificação, enquanto para a segunda rede será feito a diferenciação dos machos e fêmeas na fase adulta. Construção de uma rede neural convolucional, CNN, que tem inicialmente um processo de convolução, Conv2D, com 32 filtros de imagem, seguido pelo mesmo processo, porém com 64 e logo após 128 filtros de imagens. Após estes filtros de imagem, ocorre a unificação de todos estes valores em um único array pelo Flatten()(x). Após a unificação em um array, iniciou o dropout, para evitar overfitting e underfitting. Por fim, há a criação das camadas densas convolucionais pelo Dense(), que são camadas que estão profundamente conectadas com as camadas anteriores da rede neural. Após toda a construção da rede neural, há o treinamento e por fim há a criação de gráficos para ser possível verificar os erros de predição gerados.

4. Experimentos e Resultados Parciais

Após a construção da rede, houve diversos treinamentos em poucas repetições para ajustar erros que ocorrem apenas no início do treinamento ou erros

de código e de aprimoramento como salvar os gráficos de precisão e perdas. Houve alguns em grande quantidade de episódios, onde houve 5000 episódios, onde foi possível observar a ocorrência de overfitting e underfitting, como foi possível observar na Figura 2 estagnou o desenvolvimento após a grande quantidade de episódios.

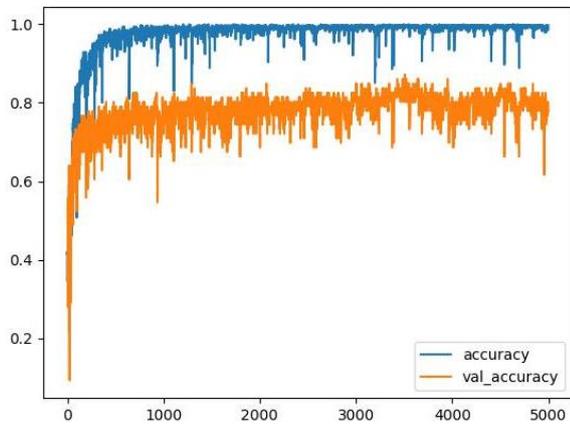


Figura 1 – Gráfico do desenvolvimento da accuracy e val_accuracy, pela quantidade de episódios.

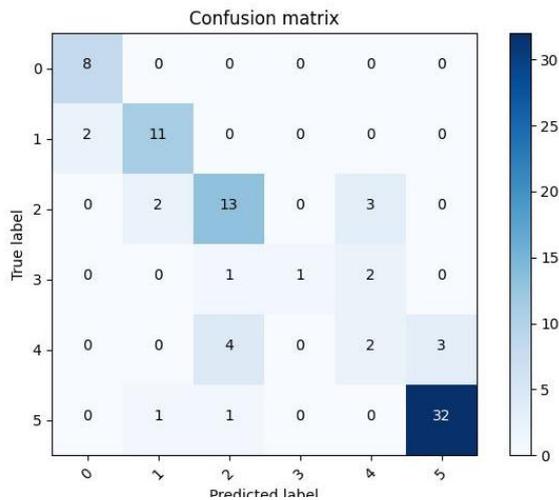


Figura 2 – Confusion Matrix.

Classification Report				
	precision	recall	f1-score	support
0	0.80	1.00	0.89	8
1	0.79	0.85	0.81	13
2	0.68	0.72	0.70	18
3	1.00	0.25	0.40	4
4	0.29	0.22	0.25	9
5	0.91	0.94	0.93	34
accuracy			0.78	86
macro avg	0.74	0.66	0.66	86
weighted avg	0.77	0.78	0.76	86

Figura 3 – Classification Report.

5. Conclusões

Para prosseguir com esta iniciação científica será necessário a mudança do modelo da rede neural convolucional, para buscar resultados melhores devido a estagnar o aprendizado após mil episódios e uma acurácia de 78%. Logo, será construída uma rede neural maior e em um modelo mais otimizado para buscar um melhor resultado.

Referências

- [1] SILVA, E. H. Avaliação do dano causado pelo percevejo marrom *Euschistus heros* (Heteroptera: Pentatomidae) em soja. Londrina: Embrapa Soja, 2012.
- [2] S. Albawi, T. A. Mohammed and S. Al-AZawi, "Understanding of a convolutional neural network," 2017 International Conference on Engineering and Technology (ICET), 2017, pp. 1-6, doi: 10.1109/ICEngTechnol.2017.8308186.
- [3] KOPPERT BIOLOGICAL SYSTEMS. Podisibug. 2021. Disponível em: <https://www.koppert.com.br/podisibug/>. Acesso em: 27 jul. 2021.
- [4] BRANDÃO, M. P.; MENDES, V. S. RECONHECIMENTO DE ASSINATURAS FALSAS COM O USO DE REDES NEURAIAS PROFUNDAS. São Bernardo do Campo, 2021
- [5] HOWARD, A. G. Some Improvements on Deep Convolutional Neural Network Based Image Classification. Ventura, Canada, 2013.
- [6] T. Guo, J. Dong, H. Li and Y. Gao, "Simple convolutional neural network on image classification," 2017 IEEE 2nd International Conference on Big Data Analysis (ICBDA), 2017, pp. 721-724, doi: 10.1109/ICBDA.2017.8078730.
- [7] Xia D, Chen P, Wang B, Zhang J, Xie C. Insect Detection and Classification Based on an Improved Convolutional Neural Network. Sensors (Basel, Suíça). Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6308804/>. Acesso em: 10 abril. 2022
- [8] Ung, Hieu & Ung, Huy & Nguyen, Binh. (2021). An Efficient Insect Pest Classification Using Multiple Convolutional Neural Network Based Models. Disponível em: https://www.researchgate.net/publication/353478930_An_Efficient_Insect_Pest_Classification_Using_Multiple_Convolutional_Neural_Network_Based_Models. Acesso em: 10/4/2022
- [9] Loris Nanni, Gianluca Maguolo, Fabio Pancino, Insect pest image detection and recognition based on bio-inspired methods, Ecological Informatics, Volume 57, 2020, 101089, ISSN 1574-9541, <https://doi.org/10.1016/j.ecoinf.2020.101089>. (<https://www.sciencedirect.com/science/article/pii/S157495412030039X>).