

ANÁLISE DO DESEMPENHO DO MODELO YOLO-NAS NA DETECÇÃO DE MÁQUINAS AGRÍCOLAS AUTOPROPELIDAS

ANDRÉ SANDMANN¹, ALDINO NORMELIO BRUN POLO², MARIA LUIZA BARCO CATTO KOSSAR³, JOSÉ AIRTON AZEVEDO DOS SANTOS⁴, DEBORAH CATHARINE DE ASSIS LEITE⁵, VERA LUCIA ANTUNES LIMA⁶

¹ Licenciatura em Matemática, Prof. Doutor, PPGTCA/UTFPR, sandmann@utfpr.edu.br.

² Eng. Químico, Mestrando em Tecnologias Computacionais para o Agronegócio, PPGTCA/UTFPR

³ Eng. de Alimentos, Mestranda em Tecnologias Computacionais para o Agronegócio, PPGTCA/UTFPR

⁴ Eng. Elétrica, Prof. Doutor, PPGTCA/UTFPR, airton@utfpr.edu.br.

⁵ Bacharel em Ciências Biológicas, Prof. Doutora, PPGTCA/UTFPR

⁶ Eng. Agrícola, Prof. Doutora, PPGEA/UFCG

Apresentado no
LIII Congresso Brasileiro de Engenharia Agrícola - CONBEA 2024
6 a 8 de agosto de 2024 – Natal – RN, Brasil

RESUMO: Neste trabalho analisa-se o desempenho do modelo YOLO-NAS (*You Only Look Once - Neural Architecture Search*) na detecção, em imagens, de máquinas agrícolas autopropelidas. A detecção de objetos, importante campo de estudo de visão computacional, visa identificar e localizar objetos específicos em imagens. O YOLO é um algoritmo de redes neurais CNC (*Convolutional Neural Network*) que permite a detecção de objetos contidos em imagens. NAS é uma técnica, de Aprendizado de Máquina (*Machine Learning*), utilizada para automatizar projetos de redes neurais. Neste trabalho, para detectar máquinas agrícolas por meio de imagens, utiliza-se um conjunto de dados com 311 imagens. Os resultados obtidos, do modelo YOLO-NAS, foram analisados por meio da pontuação de confiança. Verificou-se, por meio de imagens de teste, que o modelo YOLO-NAS obteve um bom desempenho.

PALAVRAS-CHAVE: Detecção de objetos, Imagens, Aprendizado de máquina

PERFORMANCE ANALYSIS OF YOLO-NAS MODEL IN DETECTING SELF-PROPELLED AGRICULTURAL MACHINES

ABSTRACT: This work analyzes the performance of the YOLO-NAS (*You Only Look Once - Neural Architecture Search*) model in detecting self-propelled agricultural machines in images. Object detection, an important field of study in computer vision, aims to identify and localize specific objects in images. YOLO is a CNC (*Convolutional Neural Network*) neural network algorithm that allows the detection of objects contained in images. NAS is a Machine Learning technique used to automate neural network projects. In this work, to detect agricultural machines through images, a dataset with 311 images is used. The results obtained from the YOLO-NAS model were analyzed using the confidence score. It was verified, through test images, that the YOLO-NAS model performed well.

KEYWORDS: Object detection, Images, Machine learning

INTRODUÇÃO: Algoritmos de detecção de objetos, por meio de imagens, obtiveram um avanço significativo nos últimos anos. Recentemente, foram lançados novos modelos baseados

na arquitetura NAS. Entre esses modelos, de detecção de objetos por imagens, tem-se o YOLO-NAS (*You Only Look Once - Neural Architecture Search*). O YOLO-NAS é um modelo de detecção de objetos poderoso e versátil, capaz de atender a diversas aplicações. Este modelo permite, de maneira automática, a busca por uma arquitetura de rede mais adequada a detecção de objetos. Oferecendo vantagens de facilidade de uso, velocidade e precisão (KHVEDCHENYA; SAHOTA, 2023; OLIVEIRA, 2023; REDMON et al., 2016). O trânsito de máquinas agrícolas em rodovias pavimentadas, situação comum em cidades onde o agronegócio é a principal atividade econômica, podem causar acidentes, congestionamentos, entre outros problemas para a circulação de veículos e pessoas. Assim, modelos de detecção de imagens aéreas, de máquinas agrícolas autopropelidas, podem colaborar, com órgãos fiscalizadores, na identificação dessas máquinas nas estradas do país. Neste contexto, este trabalho tem como objetivo analisar o desempenho do modelo YOLO-NAS na detecção, em imagens, de máquinas agrícolas autopropelidas.

MATERIAL E MÉTODOS: Utilizou-se neste trabalho, para detecção de máquinas agrícolas autopropelidas, uma base de dados com trezentos e onze (311) imagens aéreas. O banco de imagens foi separado da seguinte forma: 70% das imagens utilizadas para treinamento, 20% das imagens para validação e 10% das imagens para teste do modelo. Na Figura 1 apresenta-se uma amostra da base de dados utilizada neste trabalho.




FIGURA 1. Amostra da base de dados (Máquinas Agrícolas). Fonte: Zeppelin (2021).

Observa-se que a estratégia, de treinamento do modelo YOLO-NAS, consistiu da utilização de pesos pré-treinados no COCO. COCO é uma base de dados muito utilizada para treinar modelos *deep learning* para detecção de objetos (HUANG et al., 2017). Na sequência, a partir das configurações obtidas inicialmente, obteve-se a atualização dos pesos durante o treinamento. Para melhorar a generalização do modelo, durante a etapa de treinamento, foi aplicada a técnica de *data augmentation* (*DetectionRandomAffine*). Esta técnica, através da criação de novas amostras, a partir de modificações das existentes, aumenta quantidade de dados de treinamento (DISTRITO, 2023). As modificações nas imagens existentes são realizadas através de rotações, espelhamentos, mudanças de brilho, saturação, etc.

RESULTADOS E DISCUSSÃO: A pontuação de confiança indica a probabilidade de uma previsão estar correta. A pontuação é dada pela seguinte equação (GUILLEMELLE, 2023):

$$C = Pr(class) * IoU \quad (1)$$

Onde: $Pr(class)$ é a probabilidade de um objeto pertencer a esta classe e IoU é a pontuação de interseção na união entre a caixa prevista e a caixa de detecção verdadeira. Nas Figuras 2 e 3 apresentam-se, como exemplo, a identificação, em imagens, de máquinas agrícolas autopropelidas. Observam-se, nestas figuras, pontuações de confiança de 0.78 e 0.64, indicando que a probabilidade da previsão, nas duas imagens, estarem corretas são de 78% e 64%.




FIGURA 2. Detecção de máquina agrícola ($C=0.78$). Fonte: Siebert (2020).



FIGURA 3. Detecção de máquina agrícola (C=0.64). Fonte: PWC (2018).

Observa-se que as pontuações de confiança podem ser úteis para entender o nível de certeza do algoritmo, mas não devem ser interpretadas como prova definitiva da precisão de uma previsão.

CONCLUSÕES: Este estudo analisou o desempenho do modelo YOLO-NAS na detecção, em imagens, de máquinas agrícolas autopropelidas. Utilizou-se, no desenvolvimento do modelo, 311 imagens, para treinamento, validação e teste. Inicialmente, realizaram-se as etapas de treinamento e validação. O modelo YOLO-NAS passou pela etapa de treinamento e validação utilizando um conjunto de dados com 401 imagens, 311 para treinamento e 90 para validação. Na sequência, observou-se, por meio de imagens do conjunto de teste (42), a boa capacidade do modelo YOLO-NAS na detecção, em imagens, de máquinas agrícolas autopropelidas.

REFERÊNCIAS:

DISTRITO. **Data augmentation: o que é e como usar essa técnica?** Disponível em: <<https://distrito.me/blog/data-augmentation-o-que-e-e-como-usar-essa-tecnica/>>. Acesso em: 5 abr. 2024.

GUILLEMELLE, Q. **Détection automatique de l'environnement d'un véhicule autonome à l'aide de l'intelligence artificielle.** Dissertação (Mestrado)—Quebec: École de Technologie Supérieure - Université du Québec, 2023.

HUANG, J. et al. **Speed/accuracy trade-offs for modern convolutional object detectors.** arXiv, 24 abr. 2017. Disponível em: <<http://arxiv.org/abs/1611.10012>>. Acesso em: 14 mar. 2024

KHVEDCHENYA, E.; SAHOTA, H. YOLO-NAS by Deci achieves SOTA performance on object detection using neural architecture search. **Computer Vision and Pattern Recognition Conference (CVPR)**, 2023.

OLIVEIRA, R. C. D. **Avaliação de modelos YOLO para detectar percevejos em plantações de soja.** Trabalho de Conclusão de Curso (Graduação)—Brasília: Universidade de Brasília, 2023.

PWC. **Building block(chain)s for a better planet.** Set. 2018. Disponível em: <<https://www.pwc.com/gx/en/sustainability/assets/blockchain-for-a-better-planet.pdf>>. Acesso em: 5 abr. 2024

REDMON, J. et al. **You Only Look Once: Unified, Real-Time Object Detection.** arXiv, 9 maio 2016. Disponível em: <<http://arxiv.org/abs/1506.02640>>. Acesso em: 11 jan. 2024

SIEBERT, T. **Máquina Agrícola.** Disponível em: <<https://unsplash.com/pt-br/fotografias/brinquedo-lego-azul-e-prata-LkqmBbrvPZI>>. Acesso em: 2 mar. 2024.

ZEPPELIN, R. **Máquinas Agrícolas.** Disponível em: <<https://unsplash.com>>. Acesso em: 2 mar. 2024.