

# Uma Análise da Rede Convolutacional YOLO v8 na Detecção de Passageiros que Embarcam nos Terminais de Ferryboat

Roberto P. C. Reis<sup>2</sup>, Francisco C. S. Pimentel<sup>2</sup>, Omar A. Carmona Cortes<sup>1,2</sup>  
Daniel Lima Gomes Jr<sup>1</sup>

<sup>1</sup>Departamento de Computação (DComp) – Instituto Federal do Maranhão (IFMA)  
Av. Getulio Vargas, 04 – 65.030-005 – São Luís, MA – Brasil

<sup>2</sup>Universidade Estadual do Maranhão (UEMA)  
Programa de Pós-Graduação em Engenharia da Computação e Sistemas (PECS)  
65.055-310 – São Luís – MA – Brasil

adm.robertoreis@hotmail.com, fcalpimentel@hotmail.com

{omar, daniellima}@ifma.edu.br

**Resumo.** *Este artigo tem como objetivo realizar uma análise de uma rede neural convolutacional chamada YOLO v8 na detecção de passageiros que embarcam e desembarcam nos terminais de ferry boat. A análise visa verificar a viabilidade da utilização da rede em tempo-real em substituição a contagem que atualmente é feita de forma manual e completamente dependente da perícia humana. Resultados indicam que a rede boas classificações a medida que a confiança aumenta. Adicionalmente, a rede apresenta um desempenho de menos de um segundo para detecção de uma pessoa sendo adequada para uso em tempo real.*

## 1. Introdução

O *ferryboat* é uma embarcação projetada especificamente para transportar passageiros, veículos e carga através de corpos d'água, como rios, lagos ou mares, realizando trajetos regulares entre pontos de embarque e desembarque pré-determinados. Segundo Souza [8], estruturalmente é uma embarcação de fundo chato que permite o transporte de até 1,2 mil toneladas, abrigando até 800 pessoas. Vem sendo uma alternativa para a navegação hidroviária. No estado do Maranhão as operações utilizando *ferryboats*, embarcações mais modernas e espaçosas, tiveram início em 1988 e, em 2018, comemoraram 30 anos de serviço, transportando passageiros, veículos leves, ônibus, caminhões e cargas entre as duas localidades. Essa travessia é reconhecida como a rota mais direta para o transporte de mercadorias para a baixada maranhense, além de desempenhar um papel importante como uma alternativa crucial na conexão entre MA e PA [5].

No caso de transporte, é importante observar a **percebibilidade do serviço**, ou seja, durante datas comemorativas e horários de pico, a demanda por travessias de ferryboat tende a aumentar significativamente. Nesses momentos, a **contagem manual de passageiros** pode se tornar desafiadora devido à alta quantidade de pessoas utilizando o serviço simultaneamente, sendo propensa a erros. Desse modo, a lentidão no processo de embarque e desembarque nesses períodos pode gerar insatisfação entre os passageiros. Nesse contexto, este trabalho investiga a utilização de uma rede neural convolutacional chamada YOLO para realizar a contagem automática.

## 2. Trabalhos relacionados

A base do controle logístico que lida com passageiros devem prover informações úteis a tomada de decisão gerencial, provendo melhores índices e segurança através do controle de embarque. Assim, Velastin et al. [9] afirma que uma das principais causas de atrasos em sistemas de transportes ocorrem nas estações de embarque. Outro estudo relevante nesta temática e com aderência a esta pesquisa foi proposto por Collini et al. [1] que abordou a gestão do turismo no contexto urbano de cidades italianas como Florença, Veneza, Roma, Milão. Também é válido mencionar o estudo desenvolvido por Erlina & Fikri [4] que foi aplicado a lojas de varejo na Indonésia, motivado pela necessidade de oferecer segurança adequada.

Desta forma, neste estudo pretende-se responder a seguinte questão de pesquisa: como realizar a contagem automática da quantidade de passageiros que embarcam e desembarcam nos ferrieboats. Assim, a ideia é usar uma rede neural convolucional chamada YOLO em sua versão 8 em detecção de diversos tipos de objetos, em especial, de pessoas para realizar a contagem.

## 3. O dataset


Para compor o dataset nesta investigação, recorreu-se a busca por imagens reais nos repositórios de imagens na internet, sendo um desafio para a rede pois as imagens coletadas tinham diferentes tipos de tamanho, resolução e as vezes baixa qualidade.

Usando data augmentation, gerou-se um conjunto de dados de 185 (cento e oitenta e cinco) imagens. Esse procedimento consistiu no espelhamento horizontal e vertical; rotação de 90° no sentido horário e anti-horário; recorte de zoom máximo de 40%; rotação entre -45° e +45° e cisalhamento de  $\pm 10^\circ$  Horizontal e  $\pm 10^\circ$  Vertical. Também fez parte deste processo, alteração no matiz entre -15° e +15°; alteração na saturação entre -25% e +25%; desfoque de até 1.5px; e exposição da caixa delimitadora entre -10% e +10%.

## 4. Experimentos

O treinamento deste modelo consistiu-se em 200 de épocas. As imagens foram redimensionadas para 640x640 pixels, sendo que o modelo foi validado usando a curva de confiança baseado em precisão, recall. O conjunto de validação consistiu em 15 imagens, com um total de 230 instâncias de objetos. Também foi averiguada a velocidade de inferência do modelo, indicando o tempo médio necessário para realizar a detecção de objetos em uma imagem para sua aplicação em tempo real. Foi utilizada a parada prematura em 50 épocas sem evolução, com melhor resultado na época 47. O modelo treinado apresenta um total de 168 camadas e 11.128.293 parâmetros.

Para visualizar o desempenho do modelo utilizou-se a curva de confiança para as métricas de precisão e recall, que ilustra a relação entre a precisão, recall e a confiança do modelo para diferentes classes, sendo confiança a probabilidade atribuída pelo modelo de que um objeto detectado pertence a uma determinada classe. No caso da precisão a anotação “*all classes 1.00 at 0.836*” indica que todas as classes alcançam uma precisão máxima quando o limiar de confiança está definido para aproximadamente 0.836. No caso do recall a anotação “*all classes 0.86 at 0.000*” que todas as classes alcançam um recall de 0.86 quando o limiar de confiança está definido para zero



**Figure 1. Curva de precisão-confiança do modelo YOLOv8 para as cinco classes do conjunto de dados personalizado na precisão e no recall**

Nesse contexto, a partir da análise da Figura 1, pode-se considerar que: (i) a classe ônibus (linha azul) apresenta uma alta precisão em baixos níveis de confiança que diminui à medida que a confiança aumenta. Isso indica que o modelo tem dificuldade em distinguir ônibus de outros tipos de veículos, especialmente quando a confiança é alta; (ii) a classe carro (linha laranja) tem um comportamento semelhante ao da classe ônibus, mas com uma queda mais abrupta na precisão em torno da marca de 0.8 na confiança. Isso indica que o modelo também pode confundir carros com outros tipos de veículos, mas com uma maior sensibilidade ao limiar de confiança; (iii) a classe balsa (linha verde) mostra uma alta variação na precisão em todos os níveis de confiança. Isso indica que o modelo tem uma grande incerteza na detecção de balsas, podendo acertar ou errar independentemente da confiança atribuída; (iv) a classe pessoa (linha vermelha) tem um aumento constante na precisão à medida que a confiança aumenta até cerca de 0.6 onde se estabiliza. Isso indica que o modelo tem uma boa capacidade de reconhecer pessoas, mas com uma certa margem de erro em baixos níveis de confiança. Esta é a classe mais importante nesse estudo; finalmente, (v) a classe caminhão (linha lilás) mostra um aumento inicial rápido na precisão seguido por uma estabilização. Isso indica que o modelo tem uma excelente capacidade de reconhecer caminhões, sendo quase infalível em altos níveis de confiança. Não obstante, a velocidade de inferência foi registrada como 4.2 milissegundos para a inferência, sendo adequada para utilização em tempo-real.

## 5. Conclusão

Este trabalho analisou o uso da YOLO v8 para detecção de passageiros. Foram coletadas 77 imagens da internet e esse conjunto de dados foi aumentado para 185 usando data augmentation. Adicionalmente, verificou-se através das curvas de confiança e da avaliação de desempenho que a rede é adequada para a detecção de passageiros e realizar a efetiva contagem, especialmente em tempo-real. No entanto, para melhorar os resultados aumentar a quantidade do dataset de imagens está sendo significativamente incrementado com imagens reais do Porto do Itaquí.

## Agradecimentos

Gostaríamos de agradecer o apoio financeiro ao Ministério de Ciência, Tecnologia e Inovação (MCTI) através dos recursos da Lei No. 8.248 de 23 de outubro de

1991, no escopo do PPI-Softex, coordenado pela Associação pela Promoção na Excelência de Software Brasileiro (Softex) e publicado como Residência TIC 09 (processo 01245.005714/2022-18), executado pelo Instituto Federal do Maranhão, e também a FAPEMA.

## References

- [1] COLLINI, Enrico; PALESI, Luciano; IPSARO, Alessandro; NESI, Paolo; PANTALEO, Gianni; ZHAO, William. Flexible thermal camera solution for Smart city people detection and counting, *Multimed Tools Appl* 83, 20457–20485 (2024), <https://doi.org/10.1007/s11042-023-16374-x>.
- [2] DIAS, Rafaella. FIGUEIREDO, Felipe Augusto Pereira de. Comparação de Modelos YOLOv5 e YOLOv8 para Detecção de Imagens de Áreas Rurais. 2023. DOI: 10.13140/RG.2.2.30587.90400.
- [3] ERAZO, Jhon Jamilton Majin. Desenvolvimento de um Sistema de contagem e classificação de veículos utilizando Redes Neurais Convolucionais. Dissertação (Mestrado em Engenharia de Automação e Sistemas) Universidade Federal de Santa Catarina. Florianópolis, 2021.
- [4] ERLINA, Tati; FIKRI, Muhammad. Yolo Algorithm-Based Visitor Detection System For Small Retail Stores Using Single Board Computer, *Journal of Applied Engineering and Technological Science* 4(2), 2023, pp. 908–920
- [5] FERRY Boat em São Luís. Encontra São Luís. 05 dez. 2022. Disponível em: <https://www.encontrasaoluisma.com.br/sobre/ferry-boat-sao-luis/> Acesso em 10 dez. de 2023 às 10:39
- [6] FILHO, Juraci. EMAP faz investimentos em ferry boat ampliando serviços a população maranhense. Blog Juraci Filho. 11 jan. 2024. Disponível em: <https://blogdojuracifilho.com.br/2024/01/11/emap-faz-investimentos-em-ferry-boat-ampliando-servicos-a-populacao-maranhense/> Acesso em 12 jan. 2024 às 11:18
- [7] Nilesh Parmanand Motwani, Soumya S. Human Activities Detection using Deep Learning Technique- YOLOv8. School of Robotics, Defence Institute of Advanced Technology (DU). ITM Web of Conferences 56, 03003 (2023). <https://doi.org/10.1051/itmconf/20235603003>
- [8] SOUZA, Daiane. Conheça o Ferryboat, alternativa para a navegação hidroviária, transporte de cargas e de passageiros pouco explorado no Brasil e com grande potencial em nosso sistema intermodal. Naval Porto Estaleiro, Indústria Naval. 29 nov. 2022. Disponível em: <https://navalportoestaleiro.com/conheca-o-ferryboat-alternativa-para-a-navegacao-hidroviaria-transporte-de-cargas-e-de-passageiros-pouco-explorado-no-brasil-e-com-grande-potencial-em-nosso-sistema-intermodal/> Acesso em 08 dez. 2023
- [9] VELASTIN, Sergio A.; FERNÁNDEZ, Rodrigo; ESPINOSA, Jorge E., BAY, Alessandro. Detecting, Tracking and Counting People Getting On/Off a Metropolitan Train Using a Standard Video Camera. *Sensors* 2020, 20, 6251; doi:10.3390/s20216251.