

## DETECÇÃO E RASTREAMENTO DE PEIXES UTILIZANDO REDE NEURAL CONVOLUCIONAL E FILTROS CORRELACIONAIS

MARCELO THEIS GERALDI<sup>1</sup>, MARIA BERNADETE DE MORAIS FRANÇA<sup>2</sup>,  
PAULO CESAR MELETTI<sup>3</sup>

<sup>1</sup> Mestrando em Engenharia Elétrica, UEL, Londrina – PR, mtg1603@gmail.com

<sup>2</sup> Prof. Doutora, Departamento de Engenharia Elétrica, UEL, Londrina – PR, mbmorais@uel.br

<sup>3</sup> Prof. Doutor, Departamento de Ciências Fisiológicas, UEL, Londrina – PR, pcmeletti@gmail.com

Apresentado no  
XLIX Congresso Brasileiro de Engenharia Agrícola - CONBEA 2020  
23 a 25 de novembro de 2020 - Congresso On-line

**RESUMO:** Os corpos d'água impactados por efluentes urbanos, industriais ou agrícolas contêm resíduos químicos que implicam na qualidade da água e que são prejudiciais à saúde humana e ao ambiente aquático. O comportamento dos peixes pode ser afetado por vários desses resíduos, sendo que o peixe atua como um indicador da presença ou do efeito de xenobióticos na água. Identificação e monitoramento são dificuldades relacionadas à detecção de substâncias químicas na água. Técnicas aplicadas para monitorar o comportamento dos peixes podem ser um meio para auxiliar no gerenciamento desta problemática. Este trabalho tem como objetivo o desenvolvimento de um sistema de detecção e rastreamento de peixes voltado a dispositivos embarcados, buscando auxiliar pesquisadores em análises comportamentais de peixes. Para o desenvolvimento deste trabalho utilizou-se a classe peixe presente no *dataset* Open Images Dataset V4. O dispositivo embarcado NVIDIA Jetson Nano foi utilizado para a implantação do sistema. Para a detecção foi utilizada a rede neural convolucional MobileNetV2 e para o rastreamento o algoritmo presente na biblioteca dlib baseada em filtros correlacionais. A rede treinada apresentou uma *average precision* de 73,32% no processo de detecção com indícios de um desempenho inicial positivo para o processo de rastreamento. Com base nos resultados obtidos o sistema projetado efetuou a detecção e o rastreamento dos peixes.

**PALAVRAS-CHAVE:** Detecção e Rastreamento de Peixes; Aprendizagem de Máquina; Visão Computacional.

## FISH DETECTION AND TRACKING USING CONVOLUTIONAL NEURAL NETWORK AND CORRELATIONAL FILTERS

**ABSTRACT:** Water bodies impacted by urban, industrial and agricultural effluents contain chemical residues that are harmful to human health and aquatic environment. Fish behavior can be affected by several substances and it can be used as an indicator of the presence or effect of xenobiotics in water. Identification and monitoring are difficulties linked to detection of chemical substances in water. Techniques to monitor the fish behavior can be a way to assist the management of this problem. This work aims to design a fish detection and tracking system using embedded devices to assist researchers in fish behavioral analysis. For the development process the fish class in dataset Open Images Dataset V4 is used. NVIDIA Jetson Nano was chosen for the system deployment. Convolutional neural network MobileNetV2 was used for detection and for tracking the algorithm present in the dlib library

based on correlational filters. The trained network presented an average precision of 73.32% in the detection process and a positive initial performance for the tracking process. Based on the results obtained, the projected system performed the fish detection and tracking.

**KEYWORDS:** Fish Detection and Tracking; Machine Learning; Computer Vision.

**INTRODUÇÃO:** Atividades industriais e agrícolas são algumas das fontes agravantes para a degradação da água. Substâncias como metais, agrotóxicos e efluentes urbanos, provocam modificações das propriedades biológicas da água, implicando na redução de sua qualidade e tornando-a imprópria para o consumo, além de se tornar uma grande ameaça para os seres aquáticos e a saúde humana. A diminuição ou aumento da população de peixes e algas, assim como a ocorrência de alterações comportamentais e biológicas de seres aquáticos são algumas das consequências da poluição no ambiente aquático (ALVES *et al.*, 2014). Em um peixe, por exemplo, é possível observar a presença das substâncias químicas na água por meio de análises comportamentais. Por meio destas análises é possível observar comportamentos de esquiva, agonísticos, de ansiedade, de interação social, aprendizado e memória. Para observar estes comportamentos, repertórios de testes são criados, simulando condições e situações no ambiente do animal. Logo, a realização de experimentos com peixes, que é considerado um biomarcador e um biosensor, torna-se uma ferramenta viável e altamente complexa para a avaliação de substâncias presentes na água (SIEBEL; BONAN, 2015). A utilização de recursos tecnológicos como controles automatizados de temperatura, alimentação e circulação de água, captura de imagens e vídeos, obtenção e processamento de dados, se combinados, tornam-se uma poderosa ferramenta para o estudo comportamental e biológico dos peixes. *Softwares* como o SACAM e EthoVision XT são ferramentas desenvolvidas com a finalidade de facilitar o monitoramento e rastreamento dos peixes por pesquisadores, realizando pesquisas referentes à sobre a atuação de certas substâncias sobre o peixe e até mesmo da qualidade da água. A partir de uma câmera conectada a um computador, estes *softwares* conseguem identificar os peixes no ambiente aquático, gravar imagens e vídeos, extrair dados, fazer análises, gerar gráficos, dentre outras funções. Com o advento da inteligência artificial, mais precisamente as redes neurais (sistemas computacionais inspirados no funcionamento dos neurônios do cérebro dos animais), e da visão computacional, técnicas alternativas estão sendo aplicadas para a automatização da análise comportamental. Redes neurais convolucionais são aplicadas em tarefas de visão computacional como reconhecimento de objetos e classificação de imagens, devido ao seu alto e consistente desempenho. O objetivo deste trabalho é desenvolver um sistema voltado a dispositivos embarcados utilizando uma rede neural convolucional e um algoritmo de rastreamento para realizar a detecção e rastreamento de peixes, visando auxiliar pesquisadores na tarefa de análises comportamentais.

**MATERIAL E MÉTODOS:** Este trabalho foi desenvolvido baseado no fluxo de trabalho de aprendizagem de máquina proposto por Amershi *et al.* (2019) e na técnica de rastreamento por detecção. O desenvolvimento e testes de execução do sistema de detecção e rastreamento de peixes foram realizados em um *notebook*. O sistema foi implantado e executado na placa de desenvolvimento NVIDIA Jetson Nano, devido ao seu poder de processamento, capacidade de memória RAM (*Random Access Memory*) e custo. Para a captura das imagens uma câmera CSI (*Camera Serial Interface*) foi acoplada à placa NVIDIA Jetson Nano e uma *webcam* USB (*Universal Serial Bus*) ao *notebook*. Peixes robóticos foram inseridos em um pequeno aquário para simular um teste natatório. O *dataset* utilizado para o desenvolvimento deste trabalho foi o Open Images Dataset V4 (OIDv4), no qual está presente a classe “peixe (*fish*)” contendo 5.434 imagens de treinamento, 340 de validação e 914 de teste. Após a coleta dos dados do *dataset*, uma limpeza fez-se necessária devido à presença de algumas imagens

inconsistentes e ruidosas. Após a limpeza houve uma redução do *dataset* para 4.558 imagens de treinamento, 219 de validação e 539 de teste. A rede neural convolucional MobileNetV2 foi adotada para o processo de detecção, sendo treinada por meio do *framework* TensorFlow em conjunto da Object Detection API (*Application Programming Interface*), utilizando a plataforma em nuvem Google Colab. O processo de treinamento da rede necessitou de 4 horas para ser concluído para 10.000 iterações (épocas) e aplicando a técnica de *fine-tuning*. Para o processo de rastreamento a biblioteca dlib foi utilizada. Para avaliar os processos de detecção e rastreamento, métricas e inspeção visual foram aplicadas. Em relação ao desenvolvimento do sistema de detecção e rastreamento de peixes, foram implementadas algumas funcionalidades que visam o auxílio ao pesquisador (usuário do sistema): detecção e rastreamento de múltiplos peixes; escolha de processamento via GPU (*Graphics Processing Unit*) ou CPU (*Central Process Unit*); suporte a diversos modelos de câmeras; suporte à captura em tempo real com armazenamento do vídeo com e sem informações de detecção e rastreamento; suporte a vídeos de experimentos gravados previamente com geração do vídeo de informações de detecção e rastreamento; escolha da resolução e *codec* para o armazenamento do vídeo; e geração de um arquivo CSV (*Comma-Separated Values*) contendo os pontos e peixes detectados e rastreados.

**RESULTADOS E DISCUSSÃO:** O treinamento da rede MobileNetV2 gerou o arquivo de pesos que, utilizando a ferramenta TensorBoard do *framework* TensorFlow, é possível obter os resultados das métricas PASCAL VOC: IoU (*Intersect Over Union*), *Precision*, *Recall* e AP (*Average Precision*). A Tabela 1 apresenta os resultados do treinamento.

TABELA 1. Métricas e seus valores resultantes do processo de treinamento.

IoU	<i>Precision</i>	<i>Recall</i>	AP
62,28%	0,95	0,65	73,32%

Os arquivos de peso treinado e configuração da rede são utilizados no algoritmo do sistema desenvolvido para testar a eficácia da rede treinada. As detecções são realizadas a cada 50 *frames* e, nos demais, o rastreador atua seguindo o peixe. Esta metodologia foi adotada visando o melhor desempenho do sistema, pois, o processo de detecção é uma tarefa mais complexa e exige um maior poder de processamento se comparado ao rastreador. Na Figura 1 é possível ver uma amostra do teste de execução do sistema.




FIGURA 1. Resultado de teste do sistema, demonstrando em sequência de quadros (*frames*) a detecção e o rastreamento dos peixes.

A fim de testar o desempenho de todo o sistema projetado e a capacidade de processamento da placa NVIDIA Jetson Nano e do *notebook* quatro vídeos de 30 segundos com diferentes resoluções foram capturados e aplicados. O desempenho da execução do sistema foi medido em *frames* por segundo (FPS), no qual é realizada uma média entre todos os *frames* processados de cada um dos vídeos aplicados. Além disso, foi monitorado o consumo de memória pelo sistema e, para a rede treinada, observou que em torno de 1,77 GB é necessário

para seu carregamento e execução. A Tabela 2 apresenta o desempenho do sistema no *notebook* e na NVIDIA Jetson Nano, medidos em FPS.

TABELA 2. Desempenho do sistema.

Dispositivo	Resolução (comprimento x altura, em <i>pixels</i> )	FPS
NVIDIA Jetson Nano (GPU)	640x480	12,21
	800x600	10,75
	1280x720	8,14
<i>Notebook</i> (CPU)	640x480	18,33
	800x600	17,16
	1280x720	15,62

Analisando os resultados das Tabelas apresentadas anteriormente, é possível observar que o desempenho do sistema é satisfatório. Contudo, falhas foram identificadas durante o processo de detecção e rastreamento. Para a detecção, em alguns momentos, os peixes não foram detectados ou detectados incorretamente. No caso do rastreamento, foram observados alguns momentos de perda da trajetória do peixe e oclusão (troca do número de identificação e a caixa delimitadora com outro peixe). Referente ao desempenho de execução do sistema nota-se que o *notebook* (CPU) apresentou um desempenho superior à placa, contudo, pequenos travamentos foram percebidos no momento da detecção, algo não observado ao utilizar a placa (GPU). O processo de rastreamento foi realizado com maior rapidez e estabilidade no *notebook* em comparação a placa. Percebe-se que níveis superiores de FPS do *notebook* são advindos do processo de rastreamento, devido a sua predominância de execução.

**CONCLUSÕES:** O sistema conseguiu rastrear e detectar os peixes, podendo ser aplicado como ferramenta para pesquisadores de estudos comportamentais. Apesar das falhas que poderiam ser ocasionadas devido à ausência ou equívocos durante os processos de detecção e rastreamento, este sistema apresentou um desempenho favorável nos dispositivos utilizados. Tal sistema será avaliado por meio da condução de novos experimentos, a fim de aperfeiçoá-lo em relação à detecção e rastreamento. Como trabalhos futuros, o treinamento e a aplicação de outros rastreadores e redes neurais convolucionais pode auxiliar o sistema na resolução dos problemas na etapa de detecção e rastreamento. O algoritmo do sistema desenvolvido está disponibilizado na página do GitHub: <https://github.com/mtg1603/Fish-CNN-Tracking>.

**AGRADECIMENTOS:** Este trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) - Código de Financiamento 001.

#### REFERÊNCIAS:

AMERSHI, S.; BEGEL, A.; BIRD, C.; DELINE, R.; GALL, H.; KAMAR, E.; NAGAPPAN, N.; NUSHI, B.; ZIMMERMANN, T. **Software engineering for machine learning: A case study**. In: Proceedings of the 41st International Conference on Software Engineering: Software Engineering in Practice. IEEE Press, 2019. (ICSE-SEIP), p. 291–300.

SIEBEL, A.; BONAN, C. **Zebrafish como Modelo para Estudos Comportamentais**. 2015.

ALVES, M. T. R.; TERESA, F. B.; NABOUT, J. C. **A global scientific literature of research on water quality indices: trends, biases and future directions**. Acta Limnologica Brasiliensia, SciELO, v. 26, p. 245–253, 2014.