

# Data Augmentation e Transfer Learning Aplicados na Classificação de Imagens do Futebol de Robôs Utilizando a Plataforma Edge Impulse

Franklin A. Brito<sup>1</sup>, André L. C. Ottoni<sup>2</sup>

RAI/CETEC/UFRB, Cruz das Almas, BA

Marcos S. Oliveira<sup>3</sup>

DEMAT/UFSJ, São João del-Rei, MG

O desafio do futebol de robôs visa otimizar a eficiência, autonomia e cooperação entre um ou mais agentes robóticos. Para isso, é necessário que o agente possua a capacidade de navegar e interagir com o espaço em que se encontra. A visão computacional é uma ferramenta capaz de extrair informações de uma imagem, de forma que o agente robótico possa compreender o ambiente no qual está inserido e atuar de acordo com seu sistema de Inteligência Artificial [2].

*Transfer Learning* (TL) é uma técnica que visa transferir o aprendizado prévio de um agente para uma nova tarefa, a fim de acelerar o aprendizado e aperfeiçoar o desempenho do mesmo no novo problema. A literatura demonstra que a técnica possibilita a obtenção de resultados mais eficientes em problemas de aprendizado de máquina [3]. Por outro lado, a técnica *Data Augmentation* (DA) cria uma diversidade de amostras distintas com classes balanceadas para o treinamento da base de dados, de forma a fazer com que um modelo de aprendizado de máquina profundo obtenha uma melhor performance e acurácia [1]. Portanto, este trabalho tem o objetivo de analisar e comparar os efeitos do uso de DA e TL na classificação multiclases de imagens do futebol de robôs utilizando a plataforma *Edge Impulse*.

Primeiramente, foi necessário selecionar manualmente um conjunto de imagens do futebol de robôs para constituir a base de dados. A categoria de futebol de robôs escolhida foi a de robôs humanoides devido ao maior número de imagens disponíveis para construção de uma base de dados sólida, visando o não comprometimento do aprendizado da máquina nas etapas subsequentes. Em vista disto, foram então criadas 5 classes de 200 imagens cada (Bola, Bola na linha, Robô, Robô com Bola e Com gol na imagem).

A plataforma *Edge impulse* foi utilizada para realizar os experimentos de classificação das imagens, bem como o pré-processamento das mesmas e a aderência das técnicas de TL e DA. A arquitetura *default* utilizada, tanto apenas com o TL quanto com DA, foi a MobileNetV2 96x96 0.35.

Os experimentos de classificação foram divididos em 3 etapas: sem o uso de TL ou DA, apenas com o uso de TL e com o uso de ambas TL e DA, a fim de comparar e verificar a eficácia destas técnicas. Os experimentos binários realizados foram: (1) Bola e Robô; (2) Com e sem gol; (3) Robô com bola e Robô sem bola. Para a classe “Sem Gol”, foram utilizadas 50 imagens de cada uma das 4 demais classes que não possuem um Gol na imagem. Já o experimento com três classes realizado foi entre as classes: Robô com bola; Bola na linha; Bola. E por fim, foi realizado o experimento

---

<sup>1</sup>frank.engcet@gmail.com

<sup>2</sup>andre.ottoni@ufrb.edu.br

<sup>3</sup>mso@ufs.j.edu.br

com todas as 5 classes. A Tabela 1 apresenta os resultados de acurácia (ACC) do modelo em cada caso dos experimentos.

Tabela 1: Resultados dos experimentos.

Experimento	ACC (Sem técnicas)	ACC (TL)	ACC (TL e DA)
Bola e Robô	84,6%	100,0%	100,0%
Com gol e Sem gol na imagem	80,6%	100,0%	100,0%
Robô com bola e Robô sem bola	87,7%	90,8%	92,3%
Bola, Robô com bola, Bola na linha	89,7%	99,0%	100,0%
Todas as 5 classes	72,5%	96,9%	96,3%

Os resultados dos experimentos binários (1) e (2) apresentaram melhoras de 15,4% e 19,6%, respectivamente, na acurácia do modelo ao aplicar TL, e mantendo estes mesmos percentuais, visto que com e sem DA foi possível chegar aos 100% de acurácia. Já no experimento binário (3), a acurácia do modelo obteve uma melhora de 3,1% ao utilizar a técnica TL na classificação das imagens. E utilizando DA, obteve-se uma melhora de mais 1,5% na acurácia do modelo. O experimento com 3 classes também apresentou melhoras expressivas na acurácia do modelo aplicando TL, aumentando-a em 9,3%, e finalmente alcançando 100% de acurácia ao aplicar DA. Por fim, no experimento com as 5 classes, o modelo alcançou uma melhora de 24,4% em sua acurácia através do uso de TL e, diferente dos demais experimentos, uma perda de 0,6% na mesma ao adicionar a técnica DA.

Portanto, analisando os resultados obtidos no presente trabalho, nota-se uma melhora expressiva na eficácia do modelo de classificação de imagens do futebol de robôs quando são utilizadas as técnicas de TL e DA. Em um trabalho futuro, seria interessante analisar juntamente os efeitos do ajuste dos hiperparâmetros de aprendizado na classificação das imagens do futebol de robôs humanoid na plataforma Edge Impulse.

## Agradecimentos

Agradecemos ao CNPq (01/23 - Iniciação Científica), UFRB e UFSJ pelo fomento à pesquisa.

## Referências

- [1] K. Alomar, H. Aysel e X. Cai. “Data Augmentation in Classification and Segmentation: A Survey and New Strategies”. Em: **Journal of Imaging** 9 (2023), p. 46. DOI: 10.3390/jimaging9020046.
- [2] R. A. C. Bianchi e A. H. Reali-Costa. “O Sistema de Visão Computacional do time FUTEPOLI de Futebol de Robôs”. Em: **Congresso Brasileiro de Automática**. 2000, pp. 2156–2162.
- [3] G. K. B. Souza, S. O. S. Santos, A. L. C. Ottoni, M. S. Oliveira, D. C. R. Oliveira e E. G. Nepomuceno. “Transfer Reinforcement Learning for Combinatorial Optimization Problems”. Em: **Algorithms** 2 (2024), p. 87. DOI: 10.3390/a17020087.