

Dispositivo de Detecção Inteligente de incêndio

Lucas Silva, Myrna Cunha e João Dias

Resumo—Este trabalho é parte do projeto Dispositivos de Prevenção e Combate a Incêndio (DPCI) desenvolvido por estudantes extensionistas do ensino médio-técnico. Este projeto tem como finalidade desenvolver dispositivos inteligentes de prevenção e combate a incêndio. Neste dispositivo em particular, foi desenvolvido um sistema inteligente para reconhecimento de fogo. No desenvolvimento foi utilizado uma placa *RaspBerry PI 4* que, devido ao pequeno tamanho, pode ser instalado em lugares de difícil acesso, uma microcâmera e uma rede neural com 3 camadas. Os resultados obtidos foram promissores, apresentando uma acurácia de 98% no treinamento e 80% na fase de teste.

Palavras-Chave—Rede Neural, Combate a incêndio, Inteligência Artificial.

Abstract—This work is part of the Prevention and Firefighting Devices (DPCI) project developed by extension students in high school. This project aims to develop smart prevention and firefighting devices. In this particular device, an intelligent fire recognition system was developed. The development used a *RaspBerry PI 4* plate which, due to its small size, can be installed in difficult to reach places, a micro camera and a 3-layer neural network. The results obtained were promising, presenting an accuracy of 98% in the training and 80% in the test phase.

Keywords—Neural network, Firefight, Artificial intelligence.

I. INTRODUÇÃO

Com a evolução tecnológica, novas abordagens tem sido desenvolvidas com o intuito de aperfeiçoar as técnicas de detecção e prevenção de incêndio. Recentemente, tem-se observado o uso de soluções baseadas em Inteligência Artificial (IA) para a classificação de imagens [1] e, algumas dessas, aplicadas ao reconhecimento de incêndios [2]. Contudo, a maioria dos trabalhos utiliza sensores como principal forma de identificar incêndios [3]. Este estudo busca avaliar o desempenho de uma IA de visão computacional na detecção de incêndio. Para isso, foi implementada e treinada uma Rede Neural Convolucional (CNN) de arquitetura *Xception* e embarcada em um *hardware RaspBerry PI* com uma microcâmera.

Este trabalho está organizado da seguinte maneira: o desenvolvimento da IA é apresentado na Seção 2; os resultados dos treinamentos são mostrados na Seção 3; e as conclusões são feitas na Seção 4.

II. INTELIGÊNCIA ARTIFICIAL

Nesta Seção será descrito o processo de construção da IA e os processos de treinamento e teste da CNN. A arquitetura escolhida foi a *Xception* [4] e o pré-processamento de dados foi realizado com OpenCV [5]. Para o treinamento, foi usado o

Lucas T. Silva, curso técnico de Informática, Cefet/RJ, Rio de Janeiro, e-mail: lucasbabur@gmail.com; Myrna Cunha, curso técnico de Segurança do Trabalho, Cefet/RJ, Rio de Janeiro, e-mail: myrna.cunha@cefet-rj.br; João Dias, Departamento de engenharia de Telecomunicações, Cefet/RJ, Rio de Janeiro, e-mail: joao.dias@cefet-rj.br.

banco de dados *Fire Dataset* [6]. Para a construção do código foi utilizada uma Interface de Programação de Aplicação (API) denominada *Tensorflow* em conjunto com a biblioteca de redes neurais *Keras* [7]. Para realização dos testes, a CNN foi embarcada em um computador *raspberry PI 4* modelo B com uma microcâmera de 720p.

A. Processamento de dados

Devido ao pequeno tamanho do banco de dados, 999 imagens, fez-se necessário a ampliação do mesmo por meio de técnicas de *Data augmentation* [8]. Com isso, foi realizada rotação das imagens em 90 graus, alteração da luminância e rotação em 180 graus, conseguindo triplicar o tamanho do banco de dados. Após essa fase, foram aplicadas técnicas com objetivo de destacar informações na imagem, facilitando o treinamento da CNN. Dentre as técnicas aplicadas, destacamos: o efeito Gaussiano, máscaras para a cor vermelha e a padronização das imagens. Desta forma, transformamos todas as imagens em uma resolução padrão de 200x200 pixels e realçamos suas características detectáveis. Um exemplo do processamento realizado pode ser observado na Figura 1.




Fig. 1. Demonstração do processamento de imagem

B. Arquitetura

A arquitetura *Xception* é composta da estrutura mostrada na Figura 2. Ela foi ligeiramente alterada para aceitar imagens de 200x200 pixels.

Para uma classificação de imagens mais precisa, foi utilizada uma rede neural densa com 256 neurônios na primeira camada, 64 na segunda, e um na última. Sendo esta última camada responsável pela classificação final, ou seja, se há ou não fogo nas imagens recebidas.

C. Treinamento

O treinamento foi realizado por meio de um desktop com sistema operacional Windows 10, processador intel core i5 e placa de vídeo GeForce GTX 1050Ti. O treinamento foi dividido em 100 épocas com 3147 imagens. Sendo 999 imagens obtidas a partir do banco de dados *Fire Dataset*, 50 imagens obtidas a partir da microcâmera instalada no *hardware raspberry PI*, e cada imagem gerando 3 novas imagens no algoritmo de *Data augmentation*. O banco de




Fig. 2. Arquitetura Base [1]

dados foi dividido em 100 partes iguais e aplicada a técnica *leaving out* no processo de treinamento e validação dos dados. Houve também, aplicação de embaralhamento em cada época e correção com camadas de *dropout* e residuais presentes na estrutura *Xception*.

D. Implementação

Depois de treinada a rede, foi utilizada a ferramenta *Pickle* para transferir os parâmetros já estabelecidos para o computador *Raspberry Pi 4*. A instalação da rede ocorreu no sistema operacional *Raspberry Pi OS*. A Figura 3 mostra o *hardware* utilizado para embarcar e testar a rede, ou seja, a microcâmera e o *Raspberry*.



Fig. 3. Computador *Raspberry Pi 4* modelo B com a microcâmera fixa ao cabo flex.

III. RESULTADOS

Com uma acurácia de 98% no treinamento e validação dos dados, a rede se mostrou eficiente para classificação de

incêndios. No entanto, imagens ensolaradas são frequentemente classificadas de forma errônea. Quando levadas em consideração, reduzem a precisão para 72%, mostrando que existe margem para melhoria da rede. O desempenho da IA durante o treinamento estão demonstrados na figura 4 e tabela I.




Fig. 4. Gráfico do Treinamento

TABELA I

MATRIZ DE CONFUSÃO DURANTE A VALIDAÇÃO COM IMAGENS COM INCIDÊNCIA SOLAR

| | Positivo | Negativo |
|------------|----------|----------|
| Verdadeiro | 131 | 15 |
| Falso | 4 | 52 |

IV. CONCLUSÕES

O desempenho da IA na detecção de incêndio mostra o grande potencial da utilização das redes neurais nesta área. Os testes, mesmo sendo realizado em um computador de baixa capacidade, alcançou uma precisão de 80%. Utilizando-se um banco de dados maior e computadores com maior capacidade, é possível vislumbrar resultados ainda melhores. Neste trabalho, também foi possível testar a utilização do *Raspberry Pi 4* para aplicações em inteligência artificial.

AGRADECIMENTOS

Agradecemos ao Cefet/RJ e ao CNPq pelo financiamento parcial do projeto que deu origem a esse trabalho.

REFERÊNCIAS

- [1] KIM, W.T.; KIM, HYUN, SPARK, J.H.; LEE, S. *Dependable Fire Detection System with Multifunctional Artificial Intelligence Framework.*, sensors, 2019
- [2] Z. Emilia; K. Wolk; C. Wojciech; *Deep Learning in State-of-the-Art Image Classification Exceeding 99% Accuracy*, World Conference on Information Systems and Technologies, 2019
- [3] Suresh B. A.; Satya J. B.; Gokul R. P.A *Novel Forest Fire Detection System Using Fuzzy Entropy Optimized Thresholding and STN-based CNN* International Conference on COMMunication Systems & NETWORKS (COMSNETS), 2020
- [4] F. Chollet, *Xception: Deep Learning with Depthwise Separable Convolutions*. ed. Google, ano 2017.
- [5] J. Cicolani, *Beggining Robotics With Raspberry Pi and Arduino*. 2. ed., editora: Apress, ano 2021.
- [6] A. Saied, *Firedataset*. 2. ed., ano 2020.
- [7] Tensorflow, <https://www.tensorflow.org/?hl=es-419>, acessado em 30/12/2020
- [8] L. Taylor; G. Nitschke. *Improving Deep Learning with Generic Data Augmentation.*. IEEE Symposium Series on Computational Intelligence (SSCI), 2018.