

Classificação do estado do olho através de imagens por redes neurais artificiais nas plataformas Edge Impulse e Roboflow

Giovanni Gonçalves Bovolato

Instituto Federal de Educação, Ciência e Tecnologia de São Paulo (IFSP) – Campus Cubatão, SP, Brasil.

Guilherme de Almeida Rey Dominguez

Instituto Federal de Educação, Ciência e Tecnologia de São Paulo (IFSP) – Campus Cubatão, SP, Brasil.

Dr. Arnaldo de Carvalho Junior

Laboratório Maxwell de Micro-ondas e Eletromagnetismo Aplicado (LABMAX)
Instituto Federal de Educação, Ciência e Tecnologia de São Paulo (IFSP) – Campus Cubatão, SP, Brasil.

Resumo: O reconhecimento de imagens através de redes neurais artificiais tem se mostrado bastante eficaz, principalmente através do uso de redes neurais convolucionais. Esse projeto busca fazer a correta classificação do estado do olho por imagens através de redes neurais artificiais. Para isso, buscou-se uma base de dados que contemplaria o treinamento das redes de forma satisfatória, além de uma precisa categorização em cada imagem analisada. A fim de se atingir esses objetivos, foram selecionadas bases de dados para o treinamento das redes, que foram feitas nas plataformas Edge Impulse® e Roboflow®. Através do *dataset* escolhido e do treinamento das redes em cada uma das plataformas, foram feitos testes de validação, tanto em imagens pré-selecionadas quanto classificações em tempo real, através de imagens obtidas pela câmera de um *smartphone*. Dessa forma foi possível validar a classificação do estado do olho, tanto em imagens estáticas quanto em tempo real.

Palavras-chave: Redes Neurais Artificiais. Inteligência Artificial. Reconhecimento de Imagem.

Abstract: The images recognition through artificial neural networks has proven to be quite effective, particularly with the use of convolutional neural networks. This project aims to correctly classify the eye's condition through images using artificial neural networks. To achieve this, a database was sought that would adequately cover the

training of the networks, ensuring precise categorization in each analyzed image. In order to fulfill these objectives, databases were selected for network training, conducted on the Edge Impulse™ and Roboflow™ platforms. Through the chosen dataset and network training on each platform, validation tests were performed on both pre-selected images and real-time classifications using images captured by a smartphone camera. This allowed for the validation of eye condition classification in both static images and real-time scenarios.

Keywords: *Artificial Neural Networks. Artificial Intelligence. Image Recognition.*

INTRODUÇÃO

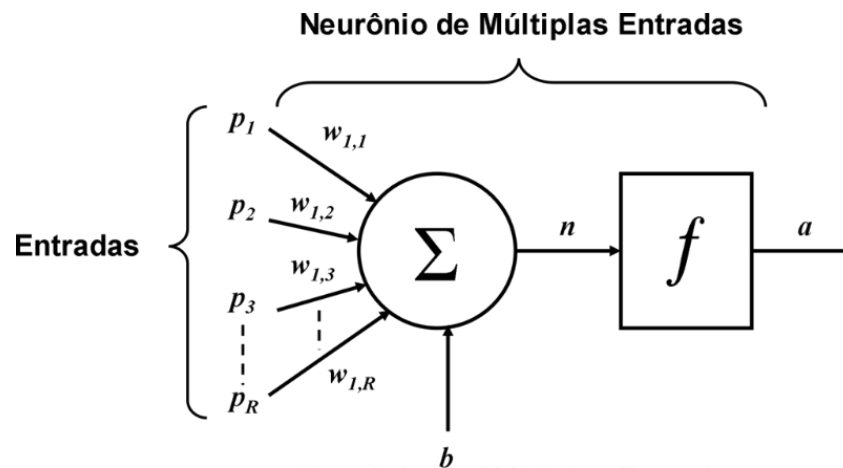
A classificação de imagens através de Redes Neurais Artificiais (RNA) tem tido seu uso aumentado, abrangendo cada vez mais utilizações e dando mais versatilidade às suas aplicações.

As RNA representam uma metodologia científica que utiliza técnicas computacionais para imitar o processo de funcionamento dos neurônios. Seu desenvolvimento tem como fundamento a estrutura do cérebro biológico (Instituto, 2023) baseando-se em uma conexão entre diversas células que representam os neurônios em um sistema (Bovolato, Dominguez, 2022). O sistema opera de maneira abrangente por meio de várias conexões que simbolizam as entradas e saídas, estabelecendo vínculos entre a saída de uma célula e a entrada de outra. Esse arranjo permite o processamento das informações por todas as camadas do sistema. As RNA, portanto, constituem um método de processamento de dados realizado por células denominadas neurônios artificiais, que, ao se conectarem entre si, processam as informações de maneira análoga ao funcionamento do cérebro (Bovolato, Dominguez, 2022).

As Redes Neurais Artificiais demonstram habilidades de mapeamento, possibilitando a associação de padrões de entrada aos padrões de saída desejados. Além disso, devido à sua capacidade de aprendizado, essas redes podem ser treinadas para adquirir o comportamento desejado. Em termos gerais, trata-se de um sistema altamente robusto, capaz de resistir a falhas, preenchendo padrões incompletos ou ajustando-se a padrões que tenham sido afetados por quebras ou ruídos, por exemplo (Sharma, Chopra, Akshit, 2013).

Na figura 1 é representado o diagrama esquemático do modelo matemático do neurônio de uma RNA.

Figura 1 - Diagrama esquemático do modelo matemático do neurônio de uma RNA.



Fonte: Adaptado de (Hagan *et al.*, 2014).

O valor de ajuste, ou *bias*, é representado por b e é somado a multiplicação da representação da força das sinapses, os pesos, que são identificados por w . A saída α é resultado da aplicação de uma função de ativação (f) ao resultado da soma (n) (De Carvalho Junior, 2021).

O *perceptron* é um algoritmo básico projetado para realizar a classificação em duas categorias distintas. Posto isso, a RNA que é composta por mais de um *perceptron* denomina-se *multilayer perceptron* (MLP). A sua composição é baseada em uma camada de entrada, responsável por receber o sinal, uma camada de saída, que é capaz de tomar uma decisão acerca da entrada e, entre essas, certa quantidade de camadas ocultas que auxiliam na aproximação de funções contínuas (Academy, 2022). A partir do *perceptron*, diversos neurônios artificiais foram desenvolvidos, com a aplicação de diferentes equações matemáticas, ou funções de ativação (f), apresentadas na Figura 1 (De Carvalho Junior, 2021, Carvalho et al, 2022).

As RNA possuem vantagens cruciais quando se trata de classificação de imagens, como baixa porcentagem de erro e alta velocidade de resposta, além de haver a possibilidade de um aprimoramento ainda maior nesse tempo, podendo diminuir algo que é 1/40 de um segundo (0,025s) para 0,008s (Wang, Chen, 2022).

O reconhecimento de imagens conta com adversidades particulares, como deformação, oclusão, desordem de fundo, condições de iluminação, além das variações de ponto de vista, escala e intraclasse (CS231N, 2023). Levar em conta esses desafios é de suma importância para que o algoritmo obtenha sucesso classificando a imagem na categoria correta.

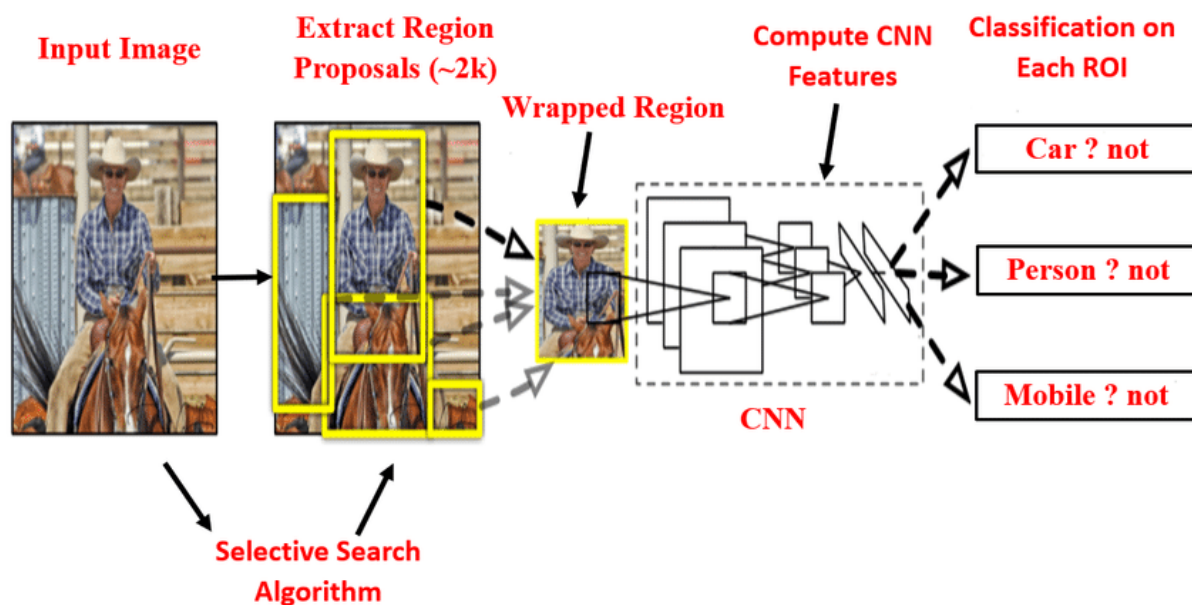
As Redes Neurais Convolucionais (RNC) demonstram a habilidade de compreender a complexidade de uma imagem, utilizando pesos e filtros para identificar as relações temporais e espaciais presentes nela (Saha, 2018). Identificação de expressões faciais, indivíduos, rostos, sinais de rua, legumes, verduras, animais e diversos outros aspectos de dados visuais que tem a identificação possibilitada por algoritmos, que conseguem reconhecer objetos e realizar a classificação de imagens, são denominadas Redes Neurais Convolucionais (Academy, 2022).

O arranjo dos neurônios em três dimensões, altura, largura e profundidade, permite que as RNC tenham uma grande vantagem no reconhecimento de imagens quando comparadas a redes neurais regulares, restringindo a arquitetura de uma forma mais sensível por conta de as entradas serem imagens (CS231N, 2023).

A identificação e classificação de imagens através de diferentes métodos vem sendo extremamente utilizada em áreas distintas, sempre com o objetivo de tratar com mais precisão a informação obtida através da imagem. Em um estudo para caracterizar a ocupação desordenada do solo sobre um recorte do Parque Nacional da Tijuca, no Rio de Janeiro, foram utilizadas redes neurais convolucionais para a classificação das imagens obtidas (Vale, 2022). No trabalho citado, foram coletadas algumas imagens que passaram por um tratamento e normalização. Após isso, a Rede Neural Convolucional utilizada foi implementada, para as etapas de treinamento e validação, e posteriormente testadas. Por fim, os resultados foram avaliados através de gráficos de treinamento e mapas de classificação. Após as etapas e validações feitas, com aumento de dados utilizado para o aperfeiçoamento do algoritmo, a Rede Neural Convolucional obteve uma acurácia geral de aproximadamente 92%, validando o emprego desse tipo de redes para classificação de imagens após treinamento com grande volume de dados (Vale, 2022).

A imagem da Figura 2 a seguir demonstra, de maneira lúdica, o funcionamento de uma RNC, desde a entrada da imagem, a extração de propostas de região, a região envolvida e a área de atuação da RNC, para que então se obtenha a classificação para a imagem proposta.

Figura 2 - Arquitetura de uma RNC.



Fonte: Adaptado de (Murthy, 2020).

Objetivos

Esse trabalho tem como objetivo principal a correta classificação do estado do olho através do reconhecimento de imagens feito por redes neurais artificiais.

Como objetivos específicos desse trabalho, estão:

- a) Identificar e selecionar a base de dados a ser utilizada para o treinamento da rede neural;
- b) Desenvolver o algoritmo de RNA e verificar a capacidade de classificação do sistema junto à base de dados utilizada;
- c) Classificar corretamente cada imagem detectada, a fim de validar a proposta do trabalho.

METODOLOGIA

Neste capítulo serão apresentados a metodologia e as plataformas utilizadas para a realização deste trabalho.

Apresentação das plataformas Edge Impulse® e Roboflow®

Para desenvolver o projeto de reconhecimento de estado do olho através de imagens, inicialmente foram escolhidas ferramentas que permitissem realizar o treinamento de redes neurais através de modelos computacionais.

A linguagem de programação Python oferece diversas bibliotecas que facilitam e auxiliam a criação, desenvolvimento e treinamento de redes, mas alguns ambientes contemplam, de forma unificada, todas essas bibliotecas. Esse é o caso dos ambientes do Edge Impulse® e Roboflow®.

O Edge Impulse® agrupa um conjunto de ferramentas que possibilita a construção, treinamento e implantação de modelos de aprendizado de máquina (Edge Impulse, 2023). De maneira geral, o ambiente permite a viabilização de projetos de reconhecimento de sons, identificação de objetos ou de movimentos. Tem como principal atrativo a otimização para dispositivos de uso final, como microcontroladores ou smartphones.

Esse ambiente permite a importação de dados em diversos formatos diferentes e, com isso, treinar modelos para o fim desejado. Através de blocos de aprendizagem existentes na plataforma, o usuário consegue personalizar o treinamento escolhendo diferentes redes, quantidade de neurônios, épocas de treinamentos e outras variáveis que influenciam no resultado.

Por fim, o Edge Impulse® tem grande integração com dispositivos, desde microcontroladores e placas de vídeo, até a câmera de um smartphone. Dessa maneira, torna-se atrativo por tornar fácil a embarcação de modelos treinados em outros dispositivos, viabilizando a construção de projetos.

O ambiente do Roboflow®, assim com o do Edge Impulse®, permite a criação de modelos computacionais através de um compilado de diversas bibliotecas (Roboflow, 2023). Ao seguir alguns passos pré-definidos dentro do ambiente é possível construir aplicativos de visão computacional, sempre suportado pela plataforma, que oferece diversos exemplos e modelos prontos para que o usuário possa se basear.

De maneira geral, para gerar um modelo computacional, são adicionadas imagens do próprio usuário para que, nelas, seja feita uma classificação. O ambiente permite realizar o pré-processamento de imagens, com funções como auto orientação e redimensionamento, o que evita erros de processamento ao ter imagens com diferentes resoluções. Além disso, existem ferramentas de aumento de dados, chamados de *augmentation*, que permitem aumentar a quantidade de imagens para o treinamento de modelos a partir de variações em uma mesma imagem, como a rotação, o cisalhamento e o aumento de brilho.

Por fim, os modelos são treinados dentro do próprio ambiente, porém com um tempo elevado para ser concluído. O ambiente permite uma integração com linguagens externas, como a embarcação através de linguagens como o Python, todavia com etapas que não são simples, situação contrária à integração possibilitada pelo Edge Impulse®.

Base de dados

O caminho escolhido pelos autores para o treinamento da rede foi o de utilizar *datasets* prontos e específicos sobre o estado dos olhos, assim evitando lidar com a privacidade de diversas pessoas, a Lei Geral de Proteção de Dados Pessoais (LGPD) e devido a maior facilidade de manipulação dos dados.

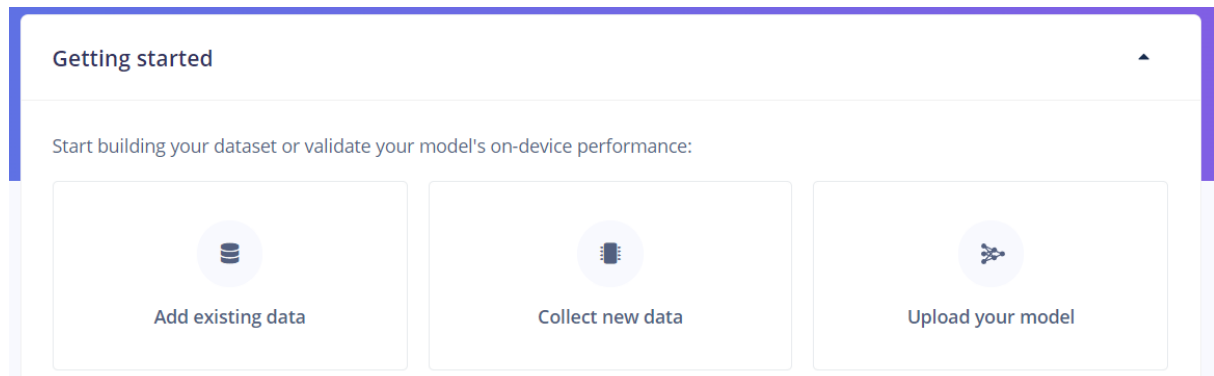
Dois *datasets* do site Kaggle foram selecionados, um monocromático em tons de cinza e o outro em cores, sendo um do usuário Dheeraj Perumandla (Kaggle, 2023) e o outro de Prasad V Patil (Kaggle, 2023).

Utilização da plataforma Edge Impulse®

A primeira validação de metodologia foi realizada na plataforma Edge Impulse®, sendo ela iniciada através da realização do treinamento da rede.

A Figura 3 apresenta a tela inicial do banco de imagens. Assim que o projeto é criado, é necessário construir um banco de imagens para a plataforma, tanto por meio de imagens já existentes, ou então criando novas.

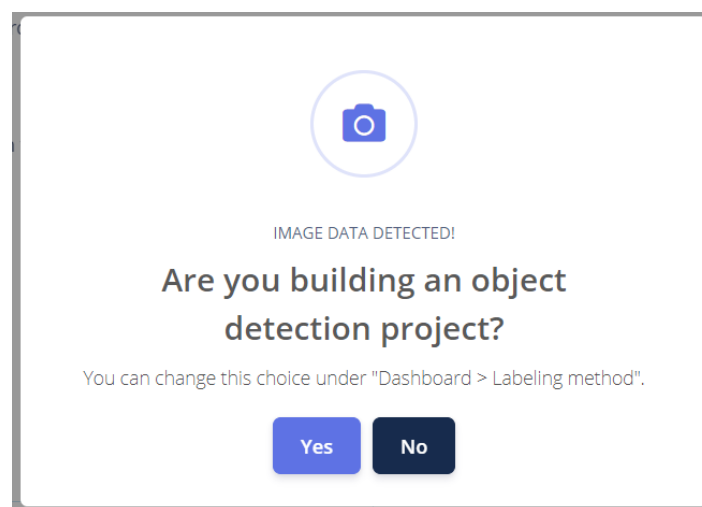
Figura 3 - Tela inicial do banco de imagens.



Fonte: Dos Autores (2023).

Logo após o *upload* das primeiras imagens ser realizado, a plataforma rapidamente já reconhece o tipo de detecção que será realizado e confirma em uma janela de *pop-up*, conforme Figura 4.

Figura 4 - *Pop-up* de identificação do tipo de projeto.



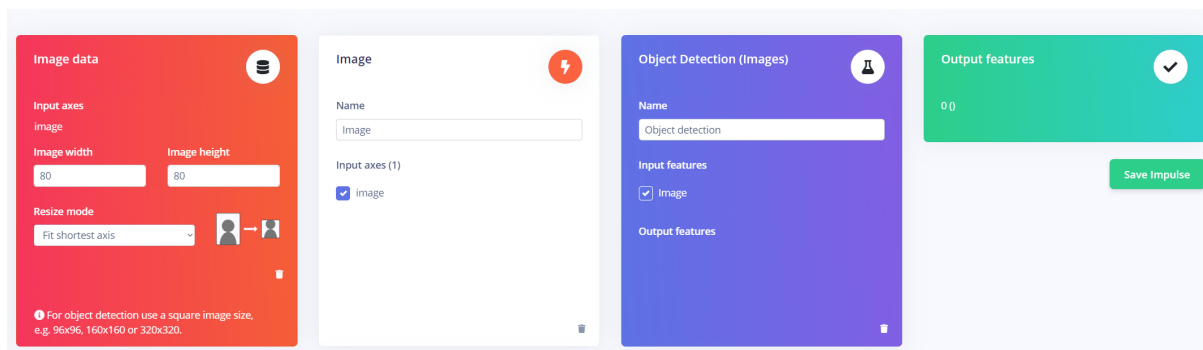
Fonte: Dos Autores (2023).

Com o tipo de detecção escolhido, o *dataset* é criado e realizada a divisão entre imagens de treino e de teste, sendo utilizada a proporção 80/20, mas que pode ser manualmente alterada para quais valores sejam de preferência do usuário.

Em seguida, a tela de “criação de impulso” (Figura 5) é aberta, onde é possível adicionar o impulso que irá varrer os dados fornecidos ao banco de imagens

e através deles realizar o treinamento da rede e a predição de classificação para novas imagens.

Figura 5 - Tela de criação de impulso.

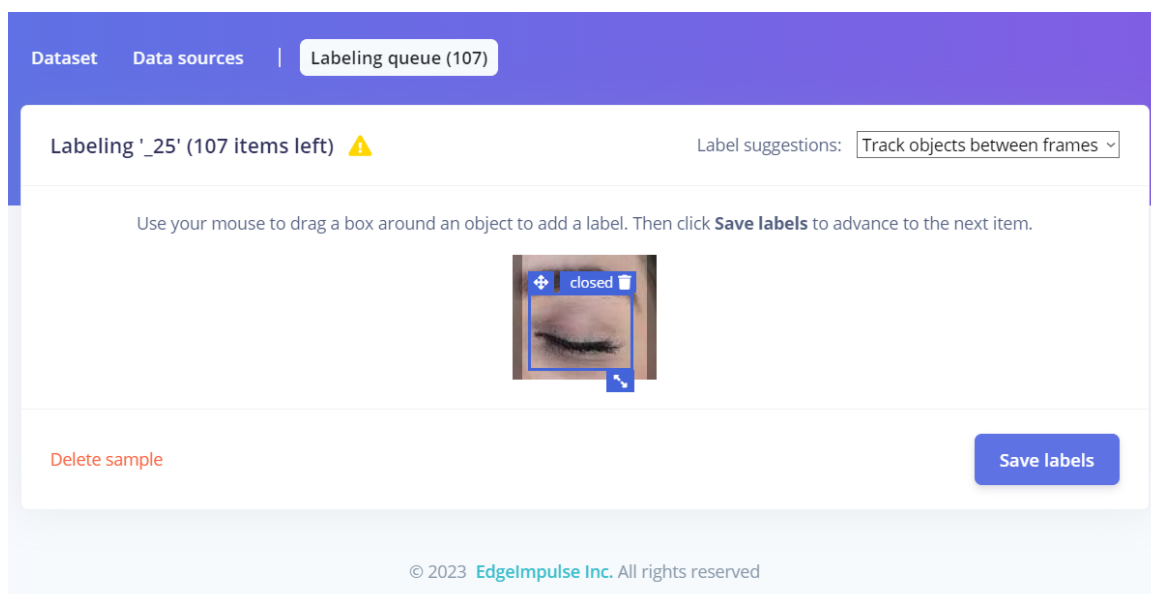


Fonte: Dos Autores (2023).

Em seguida, a tela de “criação de impulso” é aberta, onde é possível adicionar o impulso que irá varrer os dados fornecidos ao banco de imagens e através deles realizar o treinamento da rede e a predição de classificação para novas imagens.

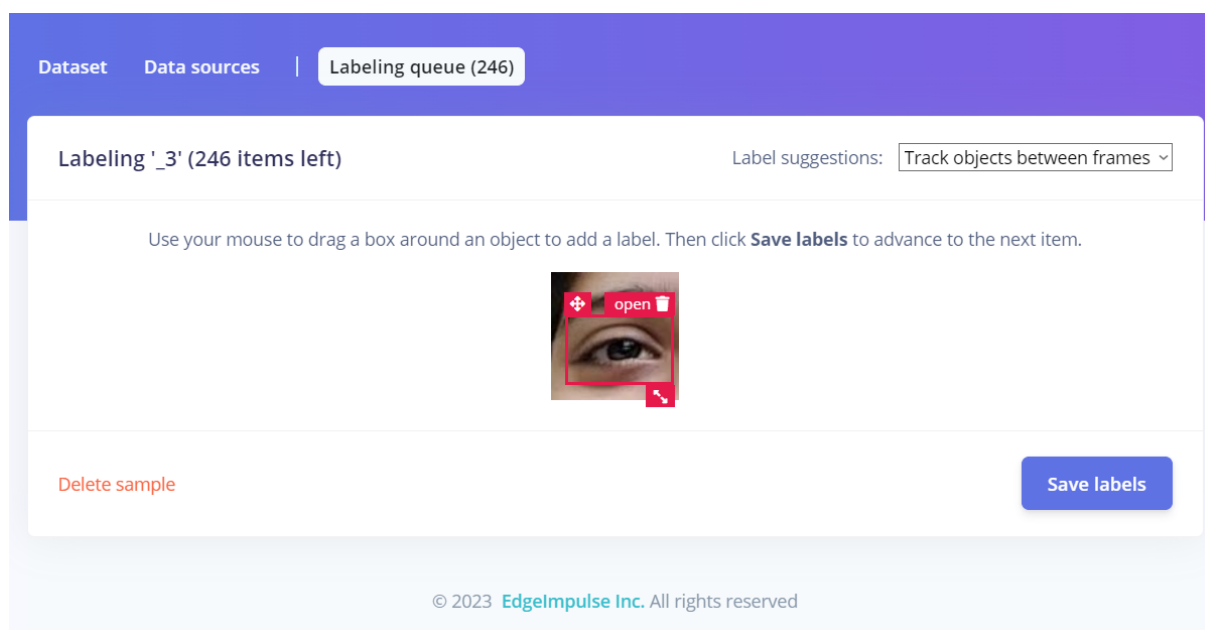
Antes da criação do impulso, é necessária a rotulação manual de todas as imagens do *dataset*, motivo pelo qual a quantidade de imagens foi reduzida, nas duas imagens abaixo é possível verificar a inserção de rótulos nas imagens, conforme Figura 6 e Figura 7.

Figura 6 - Rotulação de olhos fechados.



Fonte: Dos Autores (2023).

Figura 7 - Rotulação de olhos abertos.



Fonte: Dos Autores (2023).

Após ser consolidada, a rede pode ser utilizada, tanto em placas de desenvolvimento, quanto em *smartphones*.

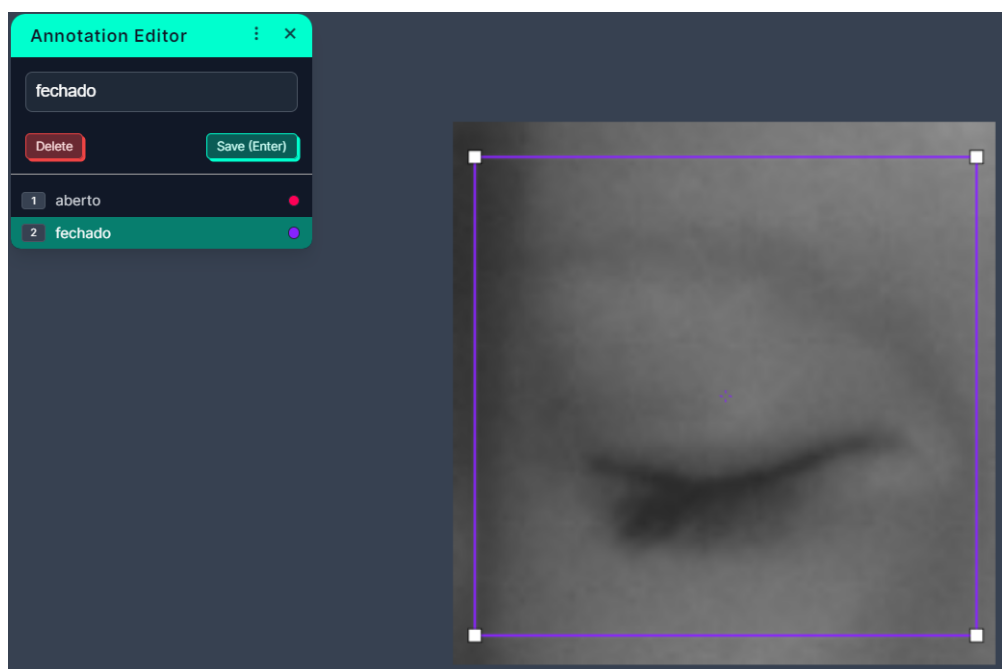
Utilização da plataforma Roboflow®

Como apresentado anteriormente, o Roboflow® é um ambiente que permite o desenvolvimento de modelos computacionais. Através dele foi possível desenvolver uma solução alternativa ao Edge Impulse®, inicialmente com o mesmo objetivo de fazer a classificação de um olho como aberto ou fechado (Roboflow, 2023).

Para realizar o treinamento da rede nesse ambiente, é necessário inicialmente colocar na plataforma as imagens que serão utilizadas para desenvolver o modelo computacional, nesse caso, o treinamento da rede.

Após as fotos já estarem no ambiente, é necessário definir a área de leitura a ser feita na imagem e então classificá-la. No caso trabalhado, as classificações utilizadas foram olho aberto e olho fechado, “aberto” e “fechado” respectivamente. A Figura 8 mostra uma imagem tendo sua área determinada e sua classificação definida.

Figura 8 - Determinação da área da foto e classificação.



Fonte: Dos Autores (2023).

Para o treinamento da rede nesse ambiente foram utilizadas 100 imagens. Nesse caso foi utilizado o sistema 70/20/10, ou seja, 70% das imagens foram utilizadas para o treinamento, 20% para a validação e outros 10% para os testes.

Visando obter um melhor resultado, foram utilizados alguns pré-processamentos nas imagens selecionadas, sendo eles a auto orientação da imagem e o redimensionamento de cada uma delas para 320x320 pixels, a fim de manter um padrão em todas as imagens.

Após o pré-processamento, foram utilizadas ferramentas de aumento de dados, chamadas nesse ambiente de *augmentation*. Essas ferramentas são utilizadas para, a partir de uma mesma imagem, gerar novos exemplos que contribuam no treinamento da rede. Para essa etapa foram utilizadas as ferramentas de rotação, recorte, cisalhamento e alterações no brilho.

Depois de todas as etapas, foi possível realizar o treinamento da rede com a opção máxima da versão oferecida pela plataforma, de 240 imagens – sendo 210 para treinamento (esse aumento devido às ferramentas de *augmentation*), 20 para validação e 10 para treinamento. Esse treinamento foi realizado por 300 épocas e teve

cerca de 3 horas de duração. Os resultados obtidos serão mostrados no próximo capítulo.

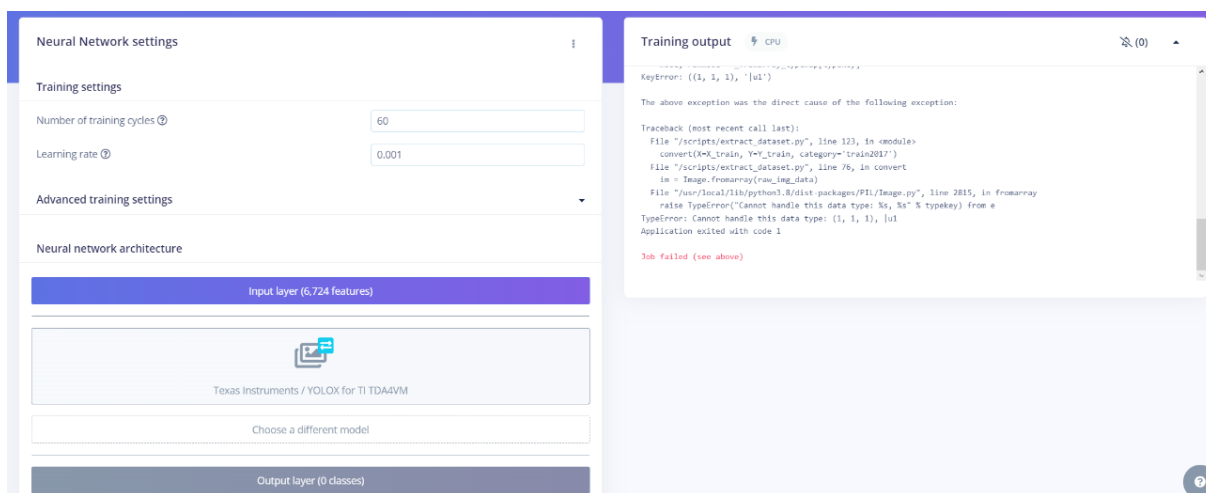
RESULTADOS

A seguir são apresentados os resultados obtidos com os respectivos comentários.

Classificação Através da Plataforma Edge Impulse®

A rede foi previamente treinada com cerca de quinhentas imagens de cada classe, sendo elas definidas como *closed*, para olhos fechados, e *open*, para olhos abertos. Ao tentar realizar esse primeiro treinamento, o tempo de processamento da versão de desenvolvedor da plataforma foi excedido, não completando o treino e disparando uma mensagem de erro. Diante desse impasse, foi optado pela redução do *dataset* para uma quantidade de cem imagens no total, ao dar início ao treinamento uma série de erros foi encontrada pelos autores, como é possível observar nas Figura 9, Figura 10 e Figura 11.

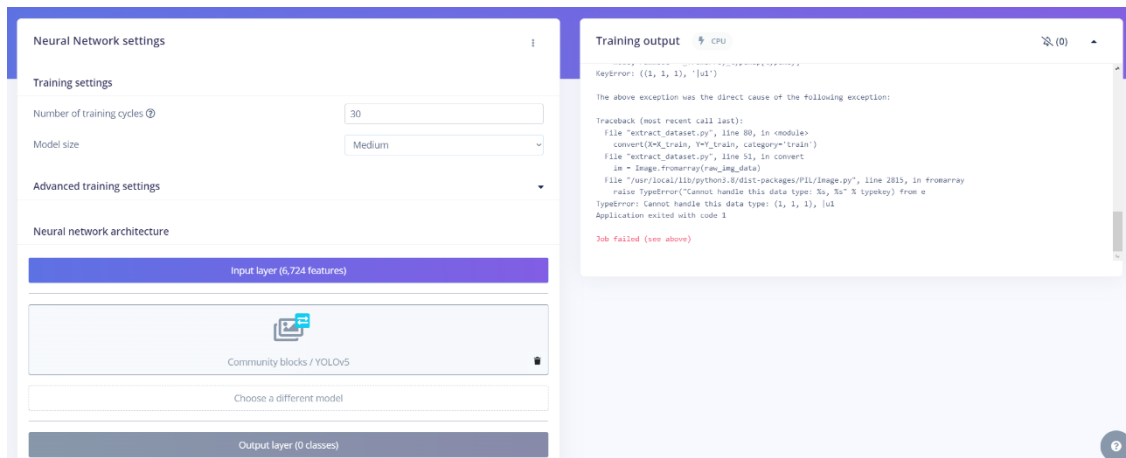
Figura 9 - Erro com a rede YOLOX.



Fonte: Dos Autores (2023).

Com a obtenção dessa primeira mensagem de erro, foi realizada a substituição da rede, da YOLOX para o modelo YOLOv5, porém o resultado obtido não foi satisfatório, visto que os erros seguiram.

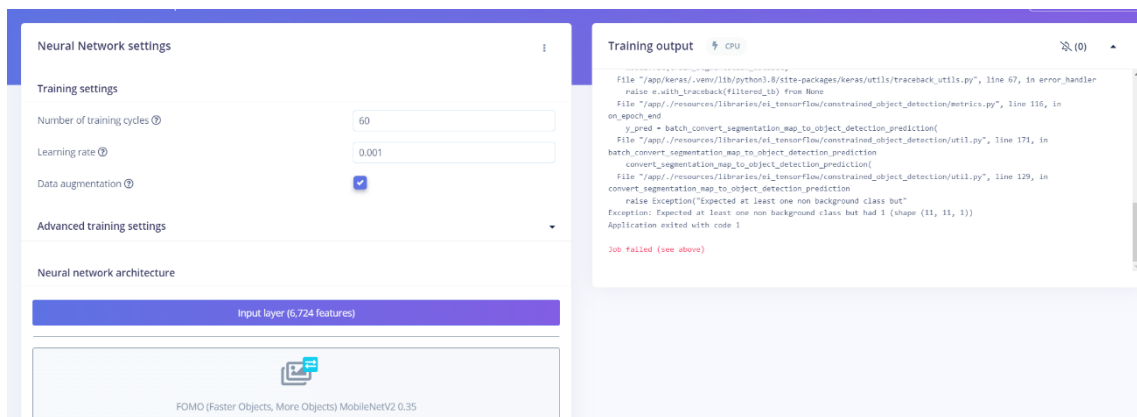
Figura 10 - Erro com a rede YOLOv5.



Fonte: Dos Autores (2023).

Ao receber outra mensagem de erro, o caminho escolhido foi alterar novamente a rede, alterando de YOLOv5 para FOMO, porém os erros continuaram a ser observados.

Figura 11 - Erro com a rede FOMO.

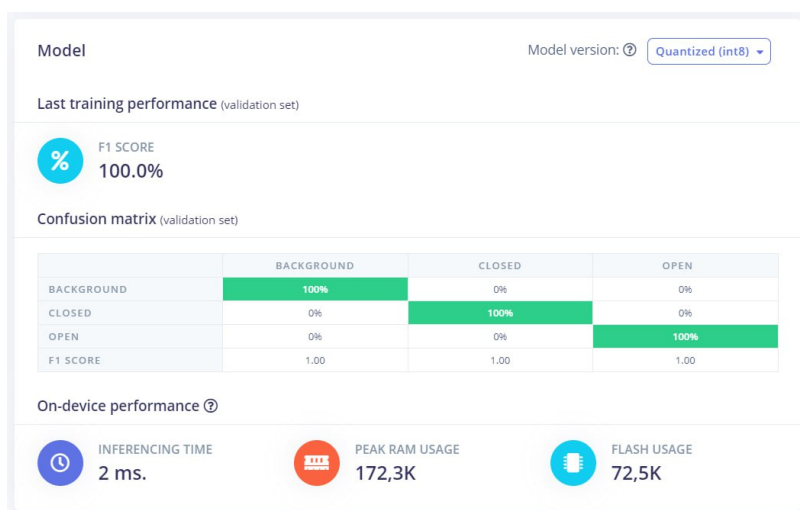


Fonte: Dos Autores (2023).

Depois de muito estudo e análise dos autores, foi constatado que seria necessária a padronização das dimensões das imagens no banco de imagens criado, visto que elas possuíam diferentes resoluções, além do processo de rotulação manual, explicada anteriormente.

Finalizado o treinamento com sucesso, os números obtidos foram extremamente satisfatórios. A rede obteve uma precisão de aproximadamente 100% ao classificar as imagens, como é possível observar na Figura 12 a seguir.

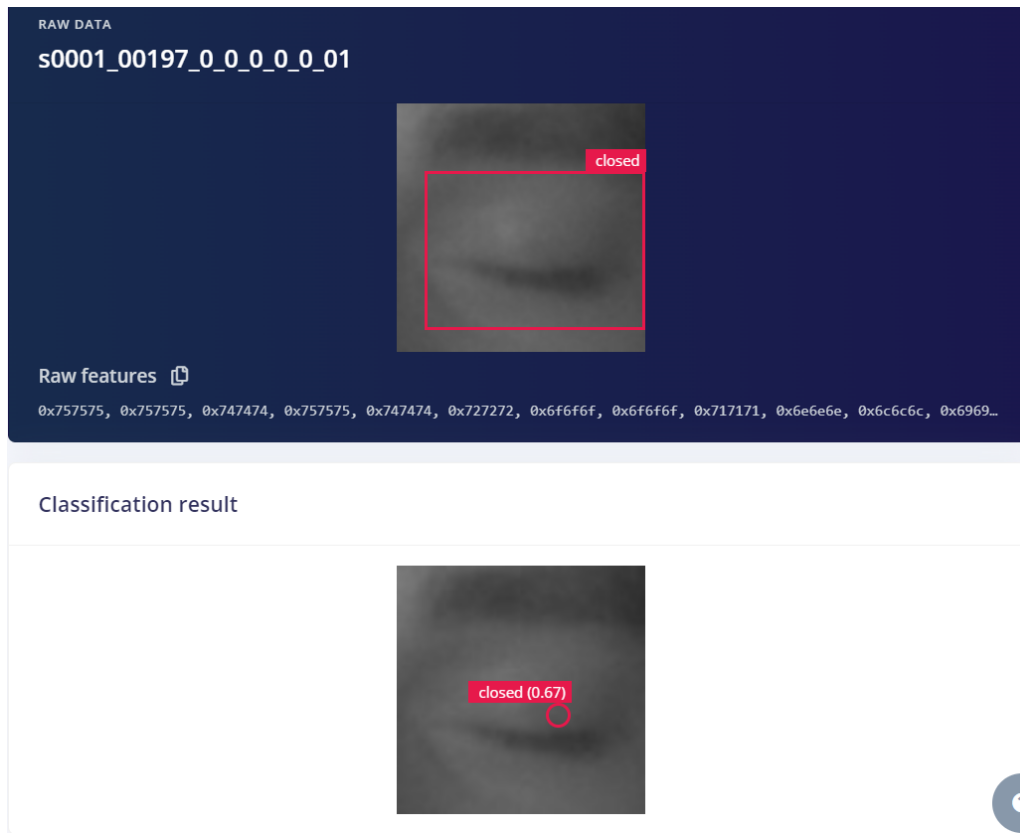
Figura 12 - Performance da Rede treinada.



Fonte: Dos Autores (2023).

foi possível realizar a validação da rede de duas formas, tanto pelo próprio *browser*, inserindo novas imagens já prontas e realizando a classificação através da rede, como é possível visualizar na Figura 13.


Figura 13 - Resultado da classificação com imagem no navegador.



Fonte: Dos Autores (2023).

A outra maneira de realizar a validação da rede é através de um dispositivo, podendo ser uma placa de desenvolvimento, ou um smartphone, que foi a opção selecionada e que pode ser observada na Figura 14.

Figura 14 - Teste da rede através da câmera frontal de smartphone.




Fonte: Dos Autores (2023).

Classificação Através da Plataforma Roboflow®

O primeiro treinamento da rede no ambiente do Roboflow® levou cerca de 3 horas para ser concluído. O ambiente oferece alguns resumos de informações e gera gráficos para que seja possível analisar os resultados obtidos pela rede no treinamento.

De maneira geral, em números, o treinamento da rede foi extremamente satisfatório. A rede obteve uma precisão de aproximadamente 99,5% ao classificar as imagens, como é possível observar na Figura 15 a seguir.

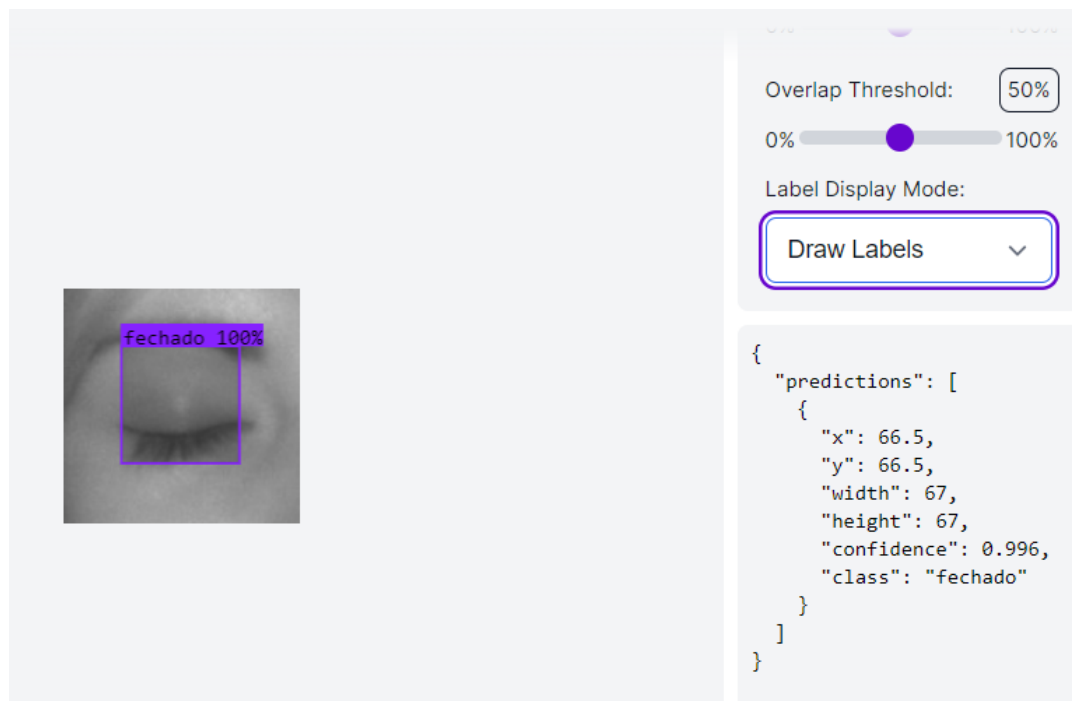
Figura 15 - Precisão obtida pelo treinamento da rede ao longo das épocas.



Fonte: Dos Autores (2023).

Além dos testes realizados pelo próprio ambiente no momento do treinamento, é possível testar a rede com imagens diferentes das pré-selecionadas. A Figura 16 apresenta um exemplo de validação.

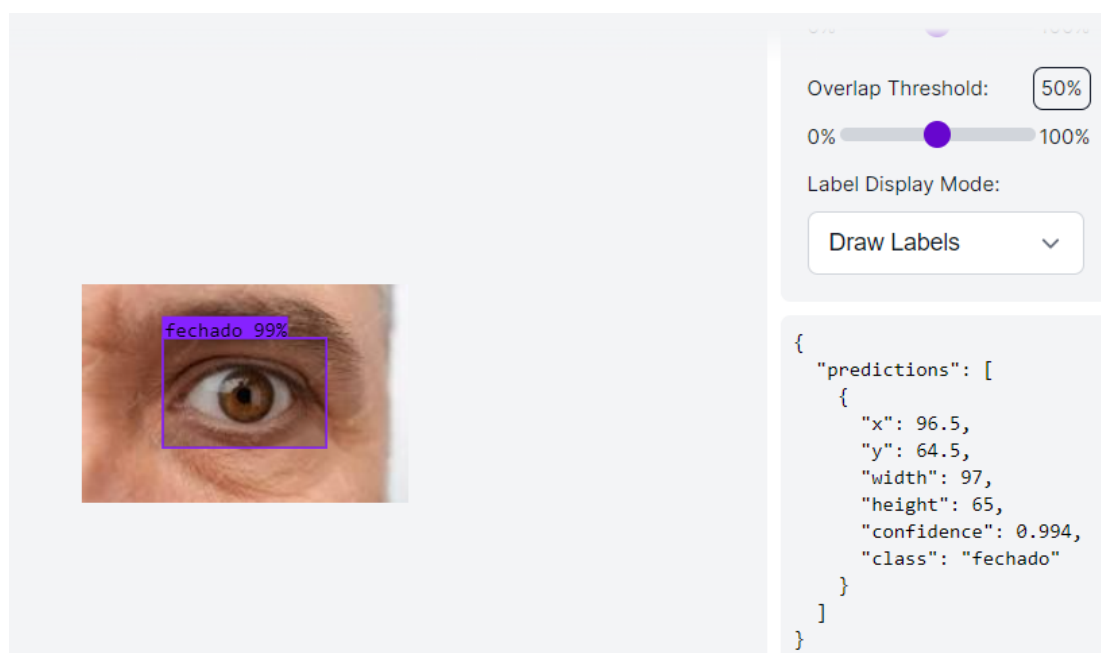
Figura 16 - Exemplo de teste de classificação.



Fonte: Dos Autores (2023).

Porém, foi verificado que ao realizar os testes com imagens coloridas ao invés de monocromáticas, a rede não apresentava resultados consistentes, como ilustra a Figura 17.

Figura 17 - Exemplo de classificação errada feita pela rede.



Fonte: Dos Autores (2023).


Dessa forma, foi verificado que, por mais que os números obtidos com o treinamento tenham sido satisfatórios, a rede, por vezes, classificava os objetos de forma errada, principalmente quando as imagens não eram monocromáticas.

Por conta disso, foi buscada uma rede já treinada no próprio ambiente do Roboflow®. Nele foi encontrada uma rede que, como essa, buscava detectar e classificar o olho como aberto ou fechado para então resultar em uma classificação de fadiga.

A rede encontrada, chamada de “*Drowsiness Detection*”, feita pelo usuário Phoenix, apresentou resultados consistentes em números, com 99,4% de precisão, feita sob um treinamento com 769 imagens (Phoenix, 2023).

Para testá-la da mesma forma que com a rede original, desenvolvida pelos autores, foram feitos testes manuais, como ilustram as Figura 18 e Figura 19 a seguir.

Figura 18 - Teste realizado com modelo computacional de outro usuário.



Fonte: Dos Autores (2023).

Figura 19 - Segundo teste realizado com rede de outro usuário.



Fonte: Dos Autores (2023).

Com esses testes foi verificado que essa rede obteve maior quantidade de acertos durante todas as verificações feitas.

CONCLUSÃO

Este artigo abordou a classificação do estado do olho por imagens através de redes neurais artificiais utilizando as plataformas Edge Impulse® e Roboflow®. A utilização das plataformas foi de grande valia e se mostraram práticas e funcionais para projetos relacionados a inteligência artificial e aprendizado de máquina.

Através dos resultados obtidos foi possível validar o conceito de detecção de imagem por Redes Neurais Artificiais, visto que as RNA treinadas nas plataformas obtiveram acurácia de quase 100%. O treinamento de cada uma das redes foi concluído com êxito e, durante as validações, foi possível visualizar uma correta classificação de cada estado do olho captado.

Dessa forma, entende-se que os objetivos propostos foram atingidos, visto que foram treinadas redes para classificação do estado do olho através de imagens. Além disso, a classificação feita pelas redes em cada uma das plataformas foi feita corretamente, validando a proposta do trabalho.

Como sugestão de projeto futuro fica a utilização destas redes para utilização em projetos nos quais seja relevante o monitoramento do estado dos olhos, como

testes de atenção ou detecção de fadiga em motoristas. A plataforma Edge Impulse® se mostra mais pronta para ser utilizada em dispositivos de borda, por conta da sua facilidade de integração de dispositivos, como o smartphone mostrado nesse trabalho.

REFERÊNCIAS

ACADEMY, D.S. Deep Learning Book. **Data Science Academy**, 2022. Disponível em: <https://www.deeplearningbook.com.br/>. Acesso em: 25 Mai. 2023.

BOVOLATO, Giovanni; DOMINGUEZ, Guilherme de Almeida. Classificação de Resíduos Sólidos Por Redes Neurais Artificiais Utilizando Edge Impulse. **IFSP**. Cubatão-SP. 2022.

CARVALHO, A., JUSTO, J.F., ANGELICO, B.A. *et al.* Model reference control by recurrent neural network built with paraconsistent neurons for trajectory tracking of a rotary inverted pendulum, **Applied Soft Computing**, 2022, 109927, ISSN 1568-4946. DOI: 10.1016/j.asoc.2022.109927

CS231N. Convolutional Neural Networks. **CS231N - Git Hub**. Disponível em: <https://cs231n.github.io/convolutional-networks/>. Acesso em: 15 jun. 2023.

CS231N. Image Classification. **CS231n: Deep Learning for Computer Vision**, Stanford – Spring, 2023. Disponível em: <https://cs231n.github.io/classification/>. Acesso em: 5 abr. 2023.

DE CARVALHO JUNIOR, A. Identificação e Controle de Sistemas Dinâmicos com Rede Neural Paraconsistente. 2021. 196 p. Tese (Doutorado) – Programa de Engenharia Elétrica, **Escola Politécnica, Universidade de São Paulo**, São Paulo, 2021. DOI: 10.11606/T.3.2021.tde-08102021-100149.

EDGE IMPULSE. For beginners, **Edge Impulse**, 2023. Disponível em: <https://docs.edgeimpulse.com/docs/readme/for-beginners>. Acesso em 09 jun. 2023.

INSTITUTO, Ciências Matemáticas. Redes Neurais Artificiais. **USP - Instituto De Ciências Matemáticas E De Computação**. Disponível em: <https://sites.icmc.usp.br/andre/research/neural/>. Acesso em: 10 abr. 2023.

KAGGLE. Drowsiness dataset. **Kaggle**, 2023. Disponível em: <https://www.kaggle.com/datasets/dheerajperumandla/drowsiness-dataset> Acesso em 25 ago. 2023.

KAGGLE. Drowsiness Detection Dataset. **Kaggle**, 2023. Disponível em: <https://www.kaggle.com/datasets/prasadvpatil/mri-dataset> Acesso em 27 ago. 2023.

MURTHY, Chinthakindi Balaram et al. Investigations of object detection in images/videos using various deep learning techniques and embedded platforms—A comprehensive review. **Applied sciences**, v. 10, n. 9, p. 3280, 2020.

PHOENIX. Drowsiness detection data-set. Open source dataset, **Roboflow**, 2023. Disponível em: <<https://universe.roboflow.com/phoenix-bpovw/drowsiness-detection-n9uj5>>. Acesso em 31 de ago. de 2023.

ROBOFLOW. Introduction, **Roboflow**, 2023. Disponível em: <https://docs.roboflow.com/>. Acesso em 25 ago. 2023.

SAHA, Sumit. A Comprehensive Guide to Convolutional Neural Networks — the ELI5 way. **Towards Data Science**, 2018. Disponível em: <<https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>>. Acesso em: 5 de abr. de 2023.

SHARMA, Ayushi; CHOPRA, AKSHIT. Artificial neural networks: Applications in management. **Journal of Business and Management**, v. 12, n. 5, p. 32-40, 2013.

VALE, Italo Guimarães do, et al. Classificação de Imagens hiperespectrais utilizando redes neurais convolucionais para caracterização da ocupação desordenada do solo sobre um recorte do Parque Nacional da Tijuca, RJ. **Revista Brasileira de Geografia Física**, v.15, n.01, 561-571, 2022.

WANG, Peng; CHEN, Meng-ya. Fast recognition of cat and dog images based on network compression. In: **Second International Symposium on Computer Technology and Information Science (ISCTIS 2022)**. SPIE. p. 694-699, 2022.