



CLASSIFICAÇÃO DE RESÍDUOS SÓLIDOS VIA REDE NEURAL E APRENDIZADO DE MÁQUINA COM PLATAFORMA EDGE IMPULSE

Guilherme de Almeida Rey Dominguez, Giovanni Gonçalves Bovolato, Dr. Walter Augusto Varella, Dr. Arnaldo de Carvalho Junior.

IFSP – g.rey@aluno.ifsp.edu.br, IFSP – giovanni.bovolato@aluno.ifsp.edu.br, IFSP – varella@ifsp.edu.br, IFSP – adecarvalhojr@ifsp.edu.br.

Resumo – O presente trabalho traz o desenvolvimento de um classificador de resíduos sólidos baseado em redes neurais artificiais, que pode ser embarcado tanto em microcontroladores, quanto em *smartphones* – que é o caso em que foi implementado pelos autores neste projeto. Todo o estudo foi realizado utilizando a plataforma gratuita Edge Impulse®.

Palavras-chave: Resíduos sólidos; Edge Impulse; Redes Neurais Artificiais.

INTRODUÇÃO

O aumento no consumo de bens e produtos é algo que ocorre em todo o mundo. Derivado desse fato está a contínua ampliação da quantidade de resíduos sólidos gerados, trazendo diversos problemas à sociedade [1].

Poucas cidades no mundo todo possuem um fluxo de coleta, separação e destinação correta de todo o lixo gerado, gerando além das poluições citadas, problemas com a proliferação de animais que vivem nesses cenários [1].

A reciclagem tem seu conceito definido de diversas formas diferentes [2]. De maneira geral, reciclagem é o reaproveitamento de objetos usados, fazendo com que novos produtos sejam feitos a partir deles, descartando a necessidade de se extrair mais recursos naturais para uma nova geração de produção. Esse conceito se diferencia da reutilização pelo fato de a reutilização transformar um material utilizado em outro, e não em um novo material igual [2].

O processo de reciclagem começa já dentro das casas de quem gera os resíduos. A separação desses materiais deve ser feita pelo próprio consumidor que utilizou o material e, após isso, encaminhá-lo para a coleta seletiva, para que o material possa seguir o fluxo correto e ser reaproveitado de alguma forma através do processo de reciclagem [2].

Os resíduos sólidos produzidos não são sempre passíveis de reciclagem. Define-se, de forma geral, os tipos de lixo como orgânico, reciclável ou rejeito. Dentro dos materiais recicláveis, há categorias de separação, sendo elas papel, plástico, vidro e metal [2].

A inteligência artificial (IA) pode ajudar na questão dos resíduos sólidos e a sua destinação. A IA tem sido bastante pesquisada nas décadas recentes [3],[4]. Desde o suporte a usuários até automatização de residências, essa tecnologia tem se mostrado importante e eficiente no cotidiano das pessoas. Um dos usos da IA que tem auxiliado diversas áreas é a classificação de imagens através de padrões [3].

As redes neurais artificiais (RNAs) têm como referência a estrutura de um cérebro biológico [3]. Dessa forma, elas consistem em uma conexão entre diversas células que representam, nesse sistema, os neurônios. Esse sistema funciona através de diversas ligações que simbolizam entradas e saídas, ou seja, uma célula recebe informação da saída de outra célula, e assim as informações vão sendo processadas ao longo de todas as camadas [3]. Assim, é possível dizer que as RNAs são um sistema de processamento de

dados, que é feito pelas células, chamadas de neurônios artificiais, conectados entre si, tendo forte relação com o funcionamento do cérebro [3].

As RNAs possuem características que tem atraído a atenção dos pesquisadores, como a capacidade de mapear padrões de entrada para associá-los aos de saída [4]. Além disso, as redes são sistemas robustos e resistentes a falhas, podendo completar ou consertar padrões incompletos ou com falhas [4]. Por fim, essas redes podem agrupar dados em grupos naturais através da similaridade, de acordo com os dados de treinamento recebido [3],[4].

A classificação de imagens é feita através de RNAs que são treinadas para realizar essa separação de acordo com padrões, aos quais essas redes são treinadas para identificar. Para que esse treinamento das RNAs tenha o efeito desejado, é necessário extrair as características dos objetos que serão analisados, determinar dentre elas quais são as discriminatórias para que, então, seja realizada a classificação dessas características em padrões [5].

O sistema de reconhecimento de padrões, o qual a classificação de imagens é uma derivada, funciona através de, basicamente, dois passos. O primeiro passo é a coleta das informações, com o objetivo de selecionar pequenos padrões que vão representar os dados de entrada e, aplicando ao caso de classificação de imagens, é feito através de alguma técnica de processamento digital. O segundo passo é classificação desses padrões que foram identificados no primeiro passo, na qual as características serão atribuídas às classes estabelecidas. Essa análise e separação é feita através das RNAs que, de acordo com o treinamento aos quais foram submetidas, tomarão a decisão de alocar os objetos de acordo com as características coletadas [5].

O objetivo deste artigo é o desenvolvimento de um classificador de resíduos sólidos baseado em RNAs e aprendizado de máquinas, utilizando a plataforma Edge Impulse® [6], [7]. que pode ser embarcado tanto em microcontroladores, quanto em smartphones,

DESENVOLVIMENTO

Como citado na seção anterior, a plataforma que será utilizada para o desenvolvimento será a Edge Impulse®, que é uma plataforma gratuita para desenvolvedores de sistemas de aprendizado de máquina em dispositivos de borda [6],[7],[8]. O projeto seguiu as instruções do manual disponível na plataforma [9].



Após acessar o *site* da Edge Impulse® [6], foi criado o projeto em modo desenvolvedor – que possui algumas limitações de uso, como tempo de trabalho, tamanho de dados e limite de colaboradores.

Com o projeto criado são definidos quais serão os tipos de dados a serem trabalhados, podendo ser áudio, movimento, ou no caso deste trabalho, imagens. Depois de definido o ponto focal (*focal point*) do estudo é selecionado o que será classificado, imagens (um único objeto) ou então objetos (múltiplos objetos).

Após a definição da classificação como “imagens”, foi selecionada a base de dados (*dataset*) “Garbage Classification”, no *site* Kaggle [10], importada para a plataforma Edge Impulse® e definida como seria a categorização dos objetos, no caso: orgânico, metal, plástico, vidro e papel.

RESULTADOS E DISCUSSÕES

A construção da primeira versão do algoritmo foi realizada com 16 neurônios – que é a quantidade que a plataforma pré-estabelece como *default* da rede – além de 20 ciclos de treinamento – que também é *default*.

A precisão da rede padrão retornou uma baixa acurácia após seu treinamento, principalmente nas classes “metal” e “plástico”, o que motivou os autores a modificarem alguns parâmetros da rede a fim de torná-la mais precisa e com uma menor percentagem de classificações erradas.

A Figura 1 apresenta a distribuição da quantidade de amostras para cada categoria. A Figura 2 apresenta os resultados da RNA após o treinamento na configuração *default*.

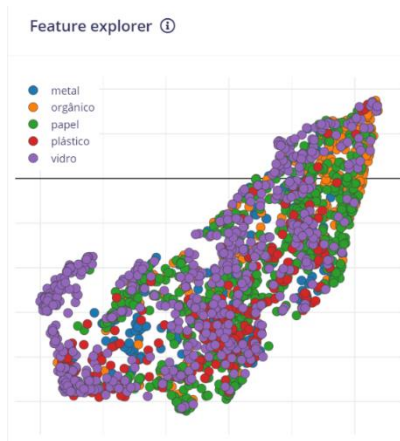


Figura 1 – Visualização gráfica da quantidade de dados inserida de cada categoria.




Figura 2 – Resultados após o treinamento da primeira rede nas configurações padrão.

Com intuito de aprimorar a precisão da RNA, o número de ciclos de treinamento foi elevado de 20 para 22, assim como o número de neurônios foi aumentado de 16 para 32. Foi alterado ainda o parâmetro de entrada de imagens, de tons de cinza para coloridas, o que acarretou no pior resultado de todos os testados, conforme apresentado nas Figuras 3 e 4.



Figura 3 – Resultados após o treinamento com as entradas coloridas.



Figura 4 – Quantidade de erros após o treinamento com as entradas coloridas.

O alto número de erros culminou na volta das imagens em escala de cinza e na alteração dos parâmetros para 64 neurônios e um ciclo de treino de 20 épocas. Os resultados são apresentados na Figura 5.



Figura 5 – Resultados após o treinamento com os novos parâmetros.

Embora os resultados gerais tenham apresentado uma melhora significativa em relação a primeira versão, que possuía 78,9% de precisão, os valores nas categorias “metal” e “plástico” ainda foram



considerados baixos. Assim, após uma investigação, foi realizada uma nova versão, com 50 neurônios, 22 épocas de treinamento e uma taxa de aprendizado da RNA (*learning rate*) de 0,0002, conforme Figuras 6 e 7. Essas configurações foram as que apresentaram um melhor resultado e, assim, decidiu-se a utilização desses parâmetros como a solução ótima para o trabalho. As Figuras 8 e 9 apresentam os resultados desta configuração final.

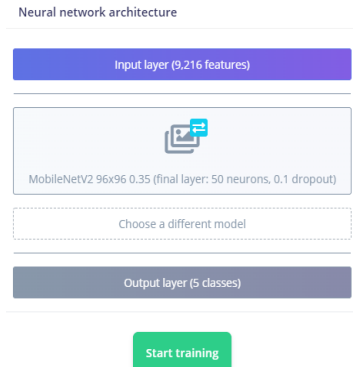


Figura 6 – Arquitetura e parâmetros da rede.

	METAL	ORGÂNICO	PAPEL	PLÁSTICO	VIDRO
METAL	59.6%	4.4%	8.8%	9.6%	17.5%
ORGÂNICO	1.1%	93.9%	1.7%	2.3%	1.1%
PAPEL	2.3%	0.7%	89.4%	3.3%	4.3%
PLÁSTICO	5.2%	1.5%	4.5%	69.4%	19.4%
VIDRO	2.8%	2.5%	3.1%	5.7%	85.8%
F1 SCORE	0.66	0.92	0.90	0.69	0.84

Figura 8 – Resultados da rede utilizada.

A fim de realizar uma análise comparativa de todas as versões das redes treinadas, foram planilhados os dados com as percentagens de acerto de cada classificação, além da geral, apresentados na Tabela 1.

Com a rede funcionando de acordo com o esperado, foi gerado um código de resposta rápida (*Quick Response - QR Code*) para que o algoritmo pudesse ser executado por um *smartphone* e, assim, os usuários pudessem realizar testes com objetos reais. A fim de comprovar a funcionalidade desta, os autores promoveram testes com alguns objetos do cotidiano, conforme Figura 10.

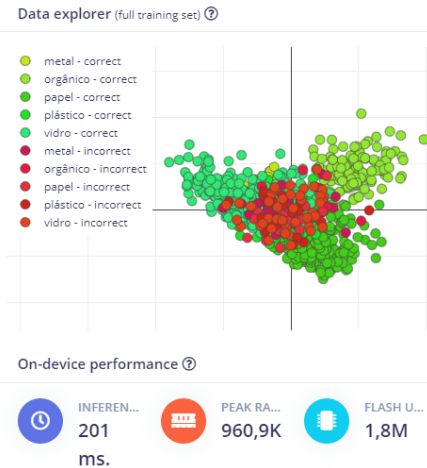
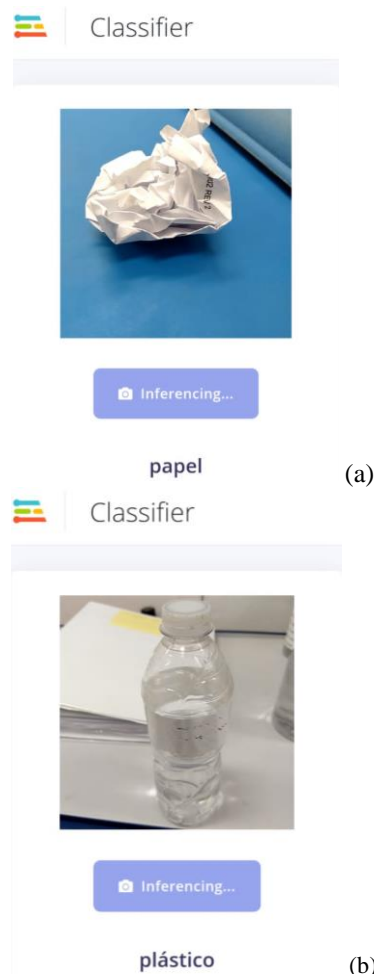


Figura 9 – Quantidade dos acertos da rede utilizada.

TABELA 1 – Acertos máximos (verde) e mínimos (vermelho) de cada versão da rede, por categoria.

Versão da Rede	1	2	3	4	5
Metal	52.6%	68.4%	57.9%	65.8%	59.6%
Orgânico	90.9%	96.0%	94.9%	91.5%	93.8%
Papel	93.4%	93.7%	85.1%	94.1%	89.4%
Plástico	53.7%	56.0%	21.6%	57.5%	69.4%
Vidro	78.3%	79.2%	75.5%	78.0%	85.8%
Geral	78.9%	82.1%	72.7%	81.0%	83.3%






Figura 10 — Aplicativo no *smartphone* identificando papel (a), plástico (b), metal (c), vidro (d) e resíduo orgânico (e).

CONCLUSÃO

O impacto da destinação errada de resíduos sólidos é extremamente negativo na sociedade. A classificação desses resíduos é de extrema importância para se dar o destino correto a cada tipo de material.

O uso da IA na classificação dos resíduos busca facilitar e reduzir erros nesse processo. Uma seleção feita através de imagens traz grande eficiência nas técnicas de reciclagem, tornando o processo cada vez mais assertivo. A classificação de resíduos sólidos por RNAs é de grande valia para essa área. De maneira mais específica, o uso desse método através do software Edge Impulse® demonstrou o quão efetivo pode se tornar a classificação desses materiais por imagens.

Todos os resultados foram imensamente satisfatórios, visto que foram atingidos índices de acerto próximos ao máximo, garantindo uma seleção efetiva e, portanto, uma possível aplicação dessa metodologia em sistemas reais.

REFERÊNCIAS

- [1] BATISTA, M. A. F. O Impacto do Lixo Doméstico No Meio Ambiente. **Revista SL Educacional**, v. 5, n. 5, p. 493, 2019.
- [2] KRAUCZUK, H. M. R. Reciclagem. **FESPPR Publica**, v. 3, n. 1, p. 18, 2019.
- [3] ABIODUN, O. I., *et al.* State-of-the-art in artificial neural network applications: A survey, **Heliyon**, vol. 4, no. 11, Nov. 2018.
- [4] CARVALHO, A.; *et al.* "Rotary Inverted Pendulum Identification for Control by Paraconsistent Neural Network," in **IEEE Access**, vol. 9, pp. 74155-74167, 2021, doi: 10.1109/ACCESS.2021.3080176.
- [5] KRUG, Á. B.; *et al.* Análise e reconhecimento de padrões usando processamento de imagens e inteligência artificial. **Revista de Iniciação Científica da ULBRA**, v. 7, n. 7, 2008.
- [6] **Edge impulse**. Disponível em: <<https://edgeimpulse.com/>>. Acesso em: 27 de junho de 2022.
- [7] HONG, S. H. Edge Impulse Machine Learning for Embedded System Design. **Journal of Korea Society of Digital Industry and Information Management**, v. 17, n. 3, p. 9-15, 2021.
- [8] DIAB, M. S.; Rodriguez-Villegas, E. Performance Evaluation of Embedded Image Classification Models Using Edge Impulse for Application on Medical Images, **44th Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)**, 2022, pp. 2639-2642, doi: 10.1109/EMBC48229.2022.9871108.
- [9] Edge Impulse Guide. Bring Your Own Model **Edge Impulse**. Disponível em: <<https://docs.edgeimpulse.com/docs/edge-impulse-studio/learning-blocks/adding-custom-learning-blocks>>. Acessado em: 07 de outubro de 2022
- [10] **Kaggle**. Disponível em: <<https://www.kaggle.com/>>. Acesso em: 27 de junho de 2022.