



Classificação Automatizada de Resíduos Sólidos Urbanos por Aprendizado Profundo

Richard Lima Ribeiro

Universidade do Vale do São Francisco (richard.lima@discente.edu.br)

Thiago Magalhães Amaral

Universidade do Vale do São Francisco (thiago.magalhaes@univasf.edu.br)

CONTEXTUALIZAÇÃO: A crescente geração de resíduos sólidos urbanos representa um dos grandes desafios socioambientais do século XXI. Segundo o Global Waste Management Outlook de 2024 do Programa das Nações Unidas para o Meio Ambiente (UNEP, 2024), estima-se que a produção global de resíduos municipais aumente de cerca de 2,1 bilhões de toneladas em 2023 para 3,8 bilhões até 2050. Esse crescimento impõe consequências diretas à saúde pública, à gestão urbana e ao meio ambiente, especialmente em países em desenvolvimento, onde persistem desigualdades na coleta seletiva e carência de políticas de manejo sustentável com inclusão social (Gouveia, 2012). Nesse contexto, uma classificação precisa de materiais recicláveis é crucial para agilizar a triagem, reduzir custos e mitigar impactos ambientais. O avanço das técnicas de aprendizado profundo (*deep learning*) aplicadas à visão computacional oferece oportunidades inéditas para automatizar esse processo, proporcionando maior precisão e velocidade em comparação com métodos tradicionais de triagem manual (Bezerra, 2016; Santos et al., 2022). As Redes Neurais Convolucionais (*Convolutional Neural Network* ou CNNs) destacam-se por sua elevada capacidade de generalização na identificação de padrões visuais complexos (Vargas; Paes; Vasconcelos, 2016). Além disso, pesquisas recentes têm demonstrado o potencial dessas redes em aplicações ambientais voltadas à

gestão de resíduos como em Abdu; Noor (2022) e em Zhang *et al.*, (2021). A utilização de arquiteturas modernas e leves, como a MobileNetV2, potencializa a aplicação prática dessas técnicas em cenários com restrição de recursos computacionais, como dispositivos móveis e sistemas embarcados, mantendo elevada acurácia e eficiência (Sandler *et al.*, 2018). A adoção de transfer learning, que reutiliza pesos pré-treinados em grandes bases de imagens como o ImageNet, permite acelerar o treinamento e melhorar o desempenho em domínios específicos, mesmo com conjuntos de dados reduzidos (Bezerra, 2016; Yosinski *et al.*, 2014; Claro *et al.*, 2020). As técnicas de *data augmentation* também desempenham papel essencial ao ampliar artificialmente o número de exemplos, equilibrando classes e reduzindo riscos de *overfitting*, o que garante maior capacidade de generalização dos modelos (Bezerra, 2016; Claro *et al.*, 2020). Pesquisas recentes reforçam o papel dessas abordagens no fortalecimento da sustentabilidade e na otimização da gestão ambiental. Diniz (2023) desenvolveu um modelo baseado em redes neurais convolucionais para o monitoramento de aterros sanitários, utilizando imagens aéreas e segmentação semântica para identificar áreas de resíduo exposto, contribuindo para o controle operacional e a sustentabilidade ambiental. Em escala global, estudos também apontam que técnicas de *deep learning*, especialmente as CNNs, têm se mostrado eficazes na detecção e classificação automática de resíduos, consolidando-se como ferramentas para triagem e gestão inteligente (Abdu; Noor, 2022; Zhang *et al.*, 2021).

OBJETIVO: Este trabalho tem como objetivo aplicar uma arquitetura baseada na MobileNetV2 transferida de pesos do ImageNet, com camadas adicionais de regularização e *fully connected*, para a classificação de seis classes de resíduos: papelão, vidro, metal, papel, plástico e lixo geral. O estudo busca avaliar a viabilidade técnica, a precisão alcançada e as contribuições potenciais para sistemas de gestão de resíduos urbanos inteligentes.

MÉTODO: A pesquisa foi conduzida a partir do conjunto de dados público Garbage Dataset Classification, contendo milhares de imagens rotuladas em seis categorias distintas, todas padronizadas para resolução de 256×256 pixels, de modo a



Anais do Simpósio Acadêmico de Engenharia de Produção (SAEPRO) da EEL-USP

IX SAEPRO – 25 e 26 de novembro de 2025

compatibilizar com os requisitos da MobileNetV2. Para o pré-processamento, utilizou-se a biblioteca ImageDataGenerator, aplicando técnicas de data augmentation como rotação de até 20°, variação de brilho (0.8 a 1.2), zoom, cisalhamento, inversão horizontal e deslocamentos de largura, com o objetivo de reduzir overfitting e aumentar a robustez do modelo. Os dados foram divididos em treinamento (70%), validação (15%) e teste (15%), garantindo balanceamento estratificado entre as classes. O modelo foi construído em TensorFlow/Keras, a partir da MobileNetV2 sem a camada top e com pesos pré-treinados no ImageNet, sendo acrescido de camadas adicionais como Global Average Pooling, duas densas com 128 neurônios e ativação ReLU, além de dropout de 30% e regularização L2 (0.001), finalizando com seis neurônios de saída e ativação softmax. A função de perda utilizada foi a categorical cross-entropy, com o otimizador Adam configurado para taxa de aprendizado inicial de $1e^{-4}$, e métricas de avaliação baseadas em acurácia. O treinamento foi conduzido por até 50 épocas, contando com *callbacks* de parada antecipada (*EarlyStopping*), ajuste dinâmico da taxa de aprendizado (*ReduceLROnPlateau*) e salvamento do melhor modelo (*ModelCheckpoint*). Para a análise dos resultados, foram utilizadas matriz de confusão, relatórios de classificação (*precision*, *recall*, *F1-score*), curvas ROC por classe e métricas agregadas (macro/micro *averages*).

RESULTADOS E DISCUSSÕES: O modelo obteve desempenho consistente ao longo do processo de treinamento, alcançando acurácia de validação superior a 92% já nas primeiras dez épocas e estabilizando em torno de 96% a partir da vigésima. A matriz de confusão final evidenciou excelente capacidade de generalização, com baixas taxas de erro em classes visualmente semelhantes, como plástico e vidro, e papel e papelão. Os resultados consolidados indicaram acurácia global de 96%, precisão de 96,25%, revocação de 96,36% e F1-score de 96,28%, confirmando a robustez do modelo. O relatório de classificação mostrou desempenho elevado em todas as categorias, destacando-se papelão (F1=0,98) e papel (F1=0,97) como as classes mais bem identificadas, enquanto a categoria lixo geral apresentou redução moderada no recall



Anais do Simpósio Acadêmico de Engenharia de Produção (SAEPRO) da EEL-USP

IX SAEPRO – 25 e 26 de novembro de 2025

(0,93), atribuída à heterogeneidade de elementos nela contidos. As curvas ROC apresentaram AUCs superiores a 0,99 em todas as classes, com valores máximos de 0,9993 para papelão e 0,9992 para papel, evidenciando a confiabilidade da rede para aplicações práticas. Além disso, o uso de técnicas de data *augmentation* e regularização foi essencial para mitigar o sobreajuste, garantindo estabilidade nas curvas de perda e acurácia, enquanto o ajuste dinâmico da taxa de aprendizado contribuiu para a convergência gradual do treinamento.

CONSIDERAÇÕES FINAIS: O estudo demonstrou que a aplicação da arquitetura MobileNetV2 com fine-tuning é altamente eficaz para a classificação automática de resíduos sólidos urbanos, alcançando 96% de acurácia global e evidenciando seu potencial de aplicação em sistemas automatizados de triagem em esteiras industriais, coletores inteligentes de lixo e iniciativas de educação ambiental. Do ponto de vista científico, a pesquisa reforça a importância do uso de redes convolucionais leves e otimizadas, como a MobileNetV2, para problemas reais de classificação de imagens, especialmente em cenários com restrição computacional. Como perspectivas futuras, destaca-se a necessidade de ampliar o conjunto de dados com imagens obtidas em condições reais de iluminação e ambientes urbanos, além da possibilidade de fazer uso de integração do modelo a dispositivos embarcados de baixo custo, de modo a aproximar a tecnologia de aplicações práticas em políticas públicas e estratégias de economia circular. O estudo é inovador e importante para a área de engenharia e gestão ambiental e sustentabilidade e pesquisa operacional da engenharia de produção.

PALAVRAS-CHAVE: Classificação de resíduos. Deep learning. MobileNetV2. Visão computacional. Gestão Ambiental.



Anais do Simpósio Acadêmico de Engenharia de Produção (SAEPRO) da EEL-USP

IX SAEPRO – 25 e 26 de novembro de 2025

REFERÊNCIAS

ABDU, Haruna; NOOR, Mohd Halim Mohd. A Survey on Waste Detection and Classification Using Deep Learning. IEEE Access, v. 10, p. 128151–128170, 2022. DOI: 10.1109/ACCESS.2022.3226682.

BEZERRA, Eduardo. Introdução à aprendizagem profunda. In: XXVII Simpósio Brasileiro de Banco de Dados – Minicursos. Porto Alegre: SBC, 2016. p. 75-108.

CLARO, Maíla et al. Utilização de técnicas de Data Augmentation em imagens: teoria e prática. In: SIMPÓSIO BRASILEIRO DE BANCO DE DADOS, 35., 2020, Fortaleza. Minicursos. Porto Alegre: SBC, 2020. p. 109-145.

DINIZ, Lucas Geraldo Ferreira. Aplicação de algoritmos de aprendizado de máquina para a melhoria de processos em aterros sanitários. João Pessoa: Universidade Federal da Paraíba, 2023.

GOUVEIA, Nelson. Resíduos sólidos urbanos: impactos socioambientais e perspectiva de manejo sustentável com inclusão social. Ciência & Saúde Coletiva, v. 17, n. 6, p. 1503-1510, 2012.

KAGGLE. Garbage Classification Dataset. Disponível em: <https://www.kaggle.com/code/limarich/notebooka0cded4d9b>. Acesso em: 25 set. 2025.

KAGGLE. Garbage Images Dataset (2000/class). Disponível em: <https://www.kaggle.com/datasets/zlatan599/garbage-dataset-classification>. Acesso em: 25 set. 2025.

SANDLER, M.; HOWARD, A.; ZHU, M.; ZHMOGINOV, A.; CHEN, L. C. MobileNetV2: Inverted Residuals and Linear Bottlenecks. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Salt Lake City, 2018. p. 4510–4520. DOI: 10.1109/CVPR.2018.00474.

SANTOS, R. et al. Aplicação de redes neurais convolucionais na classificação de resíduos sólidos urbanos. Revista Engenharia Sanitária e Ambiental, v. 27, n. 3, p. 497–506, 2022.



Anais do Simpósio Acadêmico de Engenharia de Produção (SAEPRO) da EEL-USP

IX SAEPRO – 25 e 26 de novembro de 2025

UNITED NATIONS ENVIRONMENT PROGRAMME (UNEP). Global Waste Management Outlook 2024. Nairobi: UNEP, 2024. Disponível em: <https://www.unep.org/resources/global-waste-management-outlook-2024>. Acesso em: 28 set. 2025.

VARGAS, Ana Caroline Gomes; PAES, Aline; VASCONCELOS, Cristina Nader. Um estudo sobre redes neurais convolucionais e sua aplicação em detecção de pedestres. In: SIMPÓSIO BRASILEIRO DE BANCO DE DADOS, 31., 2016, Salvador. Anais [...]. Porto Alegre: SBC, 2016. p. 377-382.

YOSINSKI, J.; CLUNE, J.; BENGIO, Y.; LIPSON, H. How transferable are features in deep neural networks? In: Advances in Neural Information Processing Systems (NeurIPS), 2014. p. 3320–3328.

ZHANG, Z. et al. Deep learning-based waste classification: A comprehensive survey. Waste Management, v. 126, p. 119–132, 2021.