

Sistema de Lixeiras Inteligentes com Reconhecimento em Tempo Real de Resíduos Sólidos

Sérgio Ademir Rocha do Carmo¹, Felipe Barbosa de Lima¹, Edson de Araújo Silva¹

¹Instituto de Ciências Exatas e Tecnologia – Universidade Federal do Amazonas (UFAM)
Itacoatiara – AM – Brasil

sergio.carmo@ufam.edu.br, felipefebl@gmail.com, edsonaraudo@super.ufam.edu.br

Resumo. O gerenciamento de resíduos sólidos representa um dilema para a sociedade, principalmente em regiões com infraestrutura limitada. A falta de equipamentos adequados e a desinformação da população sobre a separação correta dos resíduos agravam esse problema. Nesse sentido, tecnologias como sistemas embarcados autônomos e redes neurais convolucionais surgem como alternativas promissoras para otimizar esse processo, permitindo a automação da identificação e descarte adequado dos materiais descartados. O projeto desenvolveu lixeiras inteligentes equipadas com sensores e redes neurais convolucionais para classificar resíduos em tempo real, otimizando a separação e a coleta seletiva. O sistema utiliza uma câmera integrada a um Raspberry Pi 4 que captura e processa imagens dos materiais descartados, identifica sua categoria e aciona a abertura da lixeira. O modelo atingiu uma precisão de 92,75%, embora ainda enfrente desafios relacionados à variabilidade dos resíduos sólidos e à necessidade de aprimoramento do protótipo.

Palavras-chave: Lixeiras Inteligentes, Sistemas Embarcados, Classificação de Resíduos, Redes Neurais Convolucionais, Gestão de Resíduos Sólidos.

1. Introdução

O gerenciamento inadequado dos resíduos sólidos urbanos representa um dilema significativo para muitas cidades, principalmente no estado do Amazonas onde a dispersão geográfica e a infraestrutura limitada dificultam a coleta e o tratamento adequado do lixo. Nesse sentido, a ausência de equipamentos de coleta em locais estratégicos como parques, praça, shopping centers, centros de eventos e áreas de lazer, agrava a situação levando ao descarte irregular e causando impactos ambientais negativos.

A falta de informação da população sobre a separação correta dos resíduos também contribui para esse problema. Segundo Batista e Martins (2020), a disposição inadequada de resíduos compromete a qualidade de vida da população, além de poluir o solo, a água e o ar, favorecendo a proliferação de doenças. A Lei nº 12.305/2010 que institui a Política Nacional de Resíduos Sólidos, estabelece princípios e diretrizes para a gestão e gerenciamento adequado dos resíduos reforçando a responsabilidade compartilhada entre geradores e o poder público.

Cembranel et al. (2021) destacam que o descarte inadequado dos resíduos sólidos urbanos representa enormes desafios aos municípios brasileiros. A coleta seletiva é um importante instrumento no gerenciamento desses resíduos, porém a falta de adesão, estruturas inadequadas e a desinformação da população contribuem para a destinação de resíduos impróprios a reciclagem, sobrecarregando os processos de triagem com rejeitos.

Neste contexto, a tecnologia surge como uma ferramenta essencial para melhorar a eficiência do gerenciamento de resíduos. Segundo Almeida, Silva e El-Deir (2022), soluções como lixeiras inteligentes, equipadas com sensores capazes de identificar e classificar automaticamente os resíduos descartados podem otimizar o processo de coleta e promover a educação ambiental. O uso dessas soluções tecnológicas permite não apenas um controle mais eficaz sobre a geração e destinação dos resíduos mas também a redução de custos operacionais e a minimização dos impactos ambientais.

Portanto, esse projeto tem como objetivo geral desenvolver um protótipo de lixeiras inteligente que emprega rede neurais convolucionais (CNN) para reconhecimento de imagens e classificação automática de resíduos em tempo real. Dessa forma para alcançar esse objetivo se propõe as seguintes etapas:

- Desenvolver um modelo capaz de identificar e classificar diferentes tipos de resíduos sólidos;
- Integrar os sensores e atuadores em um sistema embarcado autônomo;
- Sensibilizar e educar a comunidade sobre a importância do descarte correto dos resíduos sólidos.

A adoção do protótipo visa mostrar uma solução tecnológica para gestão de resíduos se alinhando às diretrizes de políticas ambientais vigentes e promovendo um desenvolvimento urbano mais sustentável.

2. Fundamentação Teórica

A crescente necessidade de soluções tecnológicas para o gerenciamento de resíduos sólidos tem impulsionado pesquisas voltadas para a automação do processo de separação e reciclagem. Alguns estudos demonstram a viabilidade da aplicação de tecnologias como sistemas embarcados, aprendizado de máquina e visão computacional para a identificação e classificação automática de resíduos.

Dentre as pesquisas recentes o trabalho de Vukicevic et al. (2025) propõem um sistema baseado na arquitetura Segment Anything Model (SAM) para extração de objetos de resíduos em imagens, seguido pela classificação utilizando redes como MobileNetV2, VGG19, DenseNet, SqueezeNet, ResNet e Inception-v3. O estudo destaca que a integração do SAM com o MobileNetV2 alcançou uma acurácia de até 97% em diferentes cenários, demonstrando a robustez do modelo para aplicações industriais. Além disso, o artigo enfatiza a necessidade de flexibilidade na adaptação dos sistemas de classificação para diferentes tipos de resíduos e ambientes operacionais.

No mesmo sentido, Arishi (2025) propõe um sistema de detecção e classificação de resíduos domésticos em tempo real utilizando o modelo YOLOv8. O sistema foi treinado com um conjunto de dados personalizado contendo 3775 imagens de 17 tipos diferentes de resíduos domésticos. O estudo apresenta melhorias na precisão da classificação ao incorporar técnicas de aumento de dados e mecanismos de atenção, atingindo uma precisão de 89,5%. O autor enfatiza a importância de sistemas automatizados para melhorar a eficiência do processo de reciclagem e reduzir a contaminação de materiais recicláveis.

Complementando essas abordagens, Vo et al. (2024) propõem um sistema baseado em dispositivos AIoT para classificação de resíduos utilizando o modelo BEGNet que emprega RegNetY120 como backbone e inclui camadas adicionais e uma função de ativação

revisada. O estudo demonstrou que o modelo alcançou alta eficiência, atingindo 95,45% de precisão no conjunto de dados Trashnet e 98,09% no conjunto de dados BKTrashImage. Além disso, o artigo destaca a importância de soluções integradas para aumentar a conscientização dos usuários sobre a separação correta dos resíduos e otimizar o processo de reciclagem. A Tabela 1, apresenta uma comparação entre os três estudos mencionados, considerando as principais características de cada abordagem incluindo tecnologia principal, hardware utilizado, algoritmos empregados, dataset, precisão máxima, aplicação e principais dificuldades.

Table 1. Comparação entre estudos

Característica	Tecnologia Principal	Hardware Utilizado	Algoritmos	Dataset	Precisão Máxima	Aplicação	Principais Dificuldades
Classificação com Deep Learning (Vukicevic et al., 2025)	SAM + CNNs diversas	Computação de alto desempenho (GPUs)	MobileNetV2, VGG19, DenseNet, ResNet, Inception-v3	Diversos datasets públicos e privados	97%	Indústria de manufatura flexível	Necessidade de alto poder computacional; ajustes no modelo para diferentes indústrias
Detecção e Classificação em Tempo Real (Arishi, 2025)	YOLOv8	Computação otimizada para tempo real	YOLOv8	3775 imagens (17 classes de resíduos domésticos)	89,5%	Coleta seletiva doméstica e urbana	Desafios com iluminação e variação de resíduos
Classificação com Deep Learning (Vo et al., 2024)	RegNetY120 + CNNs	Raspberry Pi 4 + TensorFlow Lite	BEGNet	Trashnet e BKTrashImage	98,09%	Indústria e educação ambiental	Ajustes no modelo para diferentes aplicações

3. Metodologia

O projeto seguiu uma abordagem experimental, quantitativa e qualitativa para o desenvolvimento de um sistema embarcado autônomo de classificação automatizada de resíduos sólidos. Inicialmente, foi realizada uma revisão da literatura para compreender as soluções existentes com relação ao tema. Em seguida, foi desenvolvida a arquitetura do sistema e a elaboração do modelo.

A integração do hardware foi realizada conectando os componentes a um Raspberry Pi 4, permitindo a ativação automática dos motores de passo responsáveis pela abertura das lixeiras conforme a classificação do resíduo. A Figura 1 ilustra o diagrama do sistema proposto.

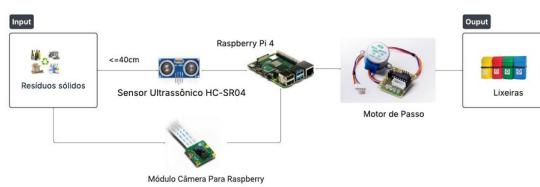


Figure 1. Esquema do sistema inteligente proposto

No sistema proposto, um módulo de câmera acoplado ao Raspberry Pi 4 é responsável pela captura de imagens de resíduos sólidos depositados em uma determinada

área. Nesse sentido para que ocorram os demais processos, o resíduo deve estar a uma distância máxima de 40 cm do sensor ultrassônico, pois o sensor é acionado conforme os parâmetros definidos no código desenvolvido na Raspberry Pi 4. O sensor detecta a presença do objeto e envia um sinal para iniciar o processo de captura e análise da imagem. Após a captura, ocorre um pré-processamento em tempo real para preparar a imagem para análise pelo modelo de classificação.

Em seguida, a imagem pré-processada é enviada ao microprocessador que executa um modelo de classificação baseado em visão computacional. O sistema analisa as características do resíduo e determina sua categoria (plástico, papel, metal ou vidro). Após a classificação, o Raspberry Pi 4 gera um comando para o motor de passo que controla o mecanismo responsável pelo direcionamento e descarte do resíduo na lixeira correspondente. Vale ressaltar que todo o processamento é realizado localmente no dispositivo, sem integração com rede externa, caracterizando o sistema como um protótipo embarcado autônomo.

3.1. Modelo de Detecção de Objetos

Na classificação dos resíduos foi desenvolvido um modelo de aprendizado de máquina baseado em redes neurais convolucionais (CNN). O treinamento do modelo utilizou um conjunto de dados composto por 8.000 imagens de resíduos categorizados em quatro classes: vidro, metal, papel e plástico.

A distribuição das imagens no conjunto de dados é uniforme, contendo 2.000 imagens para cada categoria. A distribuição das classes pode ser visualizada na Figura 2. O conjunto de dados consiste em 2000 imagens de papel, 2000 imagens de metais, 2000 imagens de plástico e 2000 imagens de vidro.

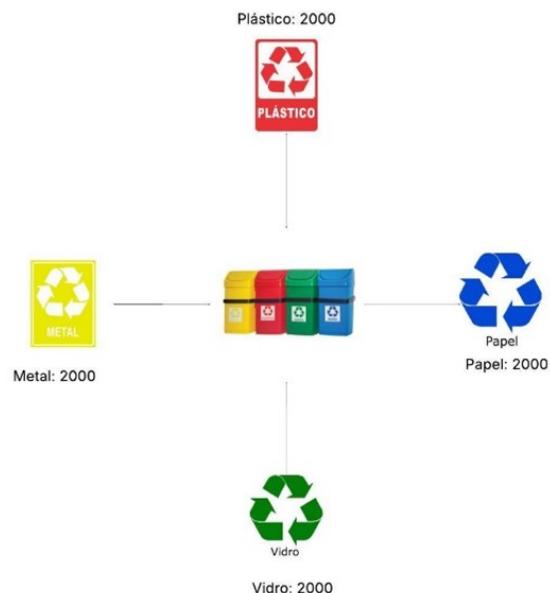


Figure 2. Conjunto de dados de cada classe

Durante o treinamento dos dados, foram utilizadas técnicas de data augmentation como rotação e reflexão. Além disso, 5120 das imagens foram usadas para treinamento, 1600 imagens para teste e 1280 imagens para validação.

4. Resultados e Discussão

4.1. Visão Geral do Projeto do Sistema desenvolvido ou Protótipo de lixeira inteligente

O sistema desenvolvido consiste em quatro lixeiras cada uma identificada com uma figura representando o tipo de material descartado: plástico, papel, metal e vidro. Nesse sentido, essas lixeiras utilizam um sensor ultrassônico para detectar a presença de resíduos e um motor de passo para controlar a abertura da tampa correspondente. A figura 3, ilustra o protótipo do projeto.



Figure 3. Modelo do Protótipo de lixeira Inteligente

Os resíduos descartados são inicialmente depositados em uma área temporária onde permanecem até serem identificados. A figura 4 mostra a área onde ocorre a classificação do resíduo sólido.



Figure 4. Modelo do Protótipo de lixeira Inteligente

O módulo de câmera do Raspberry Pi 4 Model B presente na figura 5, captura imagens do material descartado e utilizando um modelo treinado de rede neural convolucional (CNN) realiza a classificação do resíduo em tempo real. A Figura 5, ilustra o sistema em operação onde um objeto é identificado como plástico por meio de um modelo de predição baseado em aprendizado de máquina.

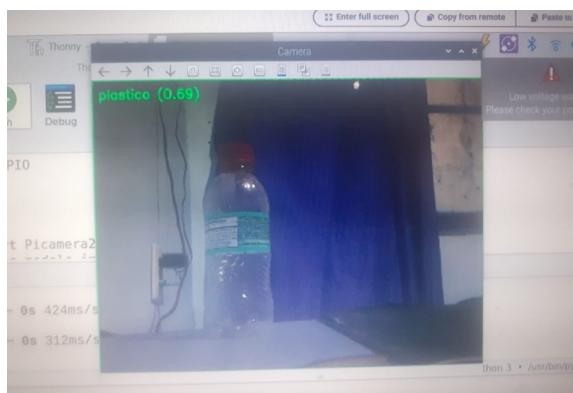


Figure 5. Modelo do Protótipo de lixeira Inteligente

Além disso, o controle de abertura e fechamento das lixeiras é realizado pelo Raspberry Pi 4 Model B que recebe a classificação do material e aciona o mecanismo correspondente por meio de um motor de passo. Nesse sentido, esse sistema automatizado melhora a eficiência do descarte seletivo, garantindo a destinação correta dos resíduos. A Figura 6 ilustra o funcionamento do controle de abertura e fechamento das lixeiras.



Figure 6. Modelo do Protótipo de lixeira Inteligente

Outro ponto importante são os materiais utilizados durante a realização do projeto. A tabela 2 apresenta a função geral dos componentes eletrônicos utilizados no desenvolvimento do sistema:

Table 2. Função geral dos componentes eletrônicos”

Componentes	Função
Raspberry Pi 4 Model B	Processamento de imagens e execução do modelo CNN
Módulo de Câmera	Captura de imagens para classificação dos resíduos
Motor de Passo	Acionamento automatizado da tampa das lixeiras
Sensor Ultrassônico	Detecta a proximidade do resíduo até 40 cm acionando o processo de classificação.
Protoboard	Facilita a conexão e organização dos componentes eletrônicos.
Jumpers	Conexão dos componentes
Notebook	Utilizado para a criação, treinamento e ajuste do modelo de classificação de resíduos.

4.2. Classificação e categorização de resíduos baseada no Modelo CNN

A classificação e categorização dos resíduos sólidos foram realizadas utilizando um modelo baseado na arquitetura MobileNetV2 treinado na plataforma Google Colab. Nesse sentido, o treinamento do modelo foi realizado utilizando um dataset composto por 8000 imagens de resíduos sólidos, distribuídos igualmente entre quatro categorias: vidro, metal, papel e plástico. Além disso, para melhorar o modelo foram aplicadas técnicas de data augmentation, como rotação e reflexão.

O treinamento ocorreu com 50 épocas utilizando uma GPU Nvidia Tesla T4 disponível no Google Colab. O modelo obteve uma acurácia final de 92,75% na avaliação do conjunto de testes, demonstrando um bom desempenho na classificação dos resíduos. Desse modo, o resultado indica que o modelo é capaz de identificar corretamente os diferentes tipos de resíduos. A figura 7, mostra a evolução do treinamento.

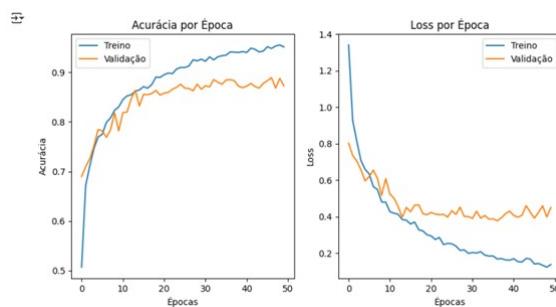


Figure 7. Modelo do Protótipo de lixeira Inteligente

Os gráficos mostram como o modelo aprende ao longo do tempo. No primeiro gráfico, a acurácia melhora conforme ele treina. No entanto, o desempenho dos dados

de teste fica um pouco abaixo do treino, o que pode indicar que o modelo pode estar aprendendo mais os padrões do treino do que os dos dados novos.

No segundo gráfico, a perda diminui no treino, mas nos dados de teste ela para de melhorar e começa a oscilar no gráfico. Dessa forma, isso sugere que o modelo pode estar treinando demais e ficando muito ajustado aos dados do treino, o que pode prejudicar seu desempenho em novos dados.

Os resultados de algumas visualizações mostram que o modelo identifica corretamente a maioria dos resíduos sólidos como vidro, metal, papel e plástico. Na figura 8, as classificações corretas são destacadas em verde, enquanto os erros aparecem em vermelho. Essa representação facilita a análise do desempenho do modelo e ajuda a identificar os tipos de resíduos que ainda apresentam dificuldades na categorização.

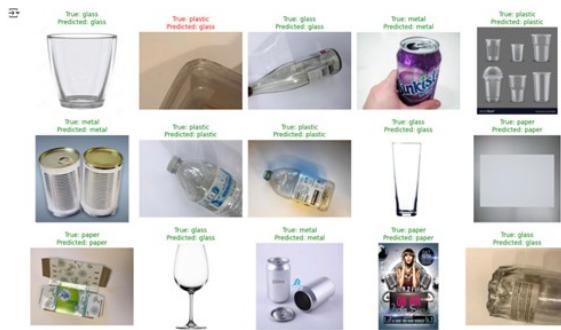


Figure 8. Resultado de algumas visualizações do modelo

Logo entre os acertos existem copos de vidro, latas metálicas, garrafas plásticas e papéis corretamente classificados. No entanto, existem imagens que apresentam erros de predição como um objeto de plástico sendo identificado como metal, recipiente de plástico sendo confundido com vidro, entre outros. Nessa perspectiva esses erros podem estar relacionados a características visuais semelhantes entre certos materiais como brilho, textura ou transparência.

4.3. Limitações

O desenvolvimento do protótipo demonstrou certos dilemas que precisam ser analisados para melhorar a precisão e a eficiência do protótipo da lixeira inteligente. Nesse sentido, o projeto enfrentou diversas restrições tanto técnicas quanto operacionais que surgiram ao longo da implementação. Entre as principais dificuldades técnicas é possível destacar a pouca experiência da equipe, o que dificultou a integração eficiente dos componentes, conflitos de ideias, entre outros.

Outro ponto a ser destacado foi a limitação do hardware como a câmera utilizada no protótipo que apresenta limitações que afetam a qualidade da classificação. Além disso, o modelo de aprendizado de máquina também apresentou algumas limitações com relação à classificação dos resíduos sólidos. Durante o treinamento, a equipe utilizou um conjunto fixo de imagens contendo quatro categorias principais: vidro, metal, papel e plástico. Porém no ambiente real existem diferentes variações desses materiais podem surgir como vidros foscos ou espelhados, metais enferrujados, papéis plastificados e plásticos transparentes. Algumas dessas variações causaram erros na classificação, o que

indica a necessidade de ampliar o banco de dados de treinamento e continuar aprimorando o modelo ao longo do tempo. Dessa forma, apesar das limitações do projeto é importante buscar soluções para o descarte seletivo de resíduos

5. Conclusão

Portanto, o desenvolvimento do protótipo de lixeiras inteligentes com reconhecimento em tempo real de resíduos sólidos demonstrou desafios desde a construção do modelo de classificação até a integração dos componentes. Apesar das dificuldades, a utilização de redes neurais convolucionais (CNN) aliada a um sistema embarcado autônomo permitiu a identificação e categorização dos resíduos de forma eficiente e sem necessidade de conexão em rede.

Os resultados obtidos mostram que o modelo implementado apresenta um desempenho satisfatório, alcançando uma acurácia de 92,75% na classificação dos resíduos. Entretanto, o trabalho evidencia a necessidade de aprimoramentos, como o refinamento do treinamento do modelo e a adaptação para diferentes variações de materiais.

Dessa forma, o estudo reforça a importância do uso de sistemas embarcados inteligentes no gerenciamento de resíduos sólidos. A adoção de soluções como esta pode contribuir para a redução do impacto ambiental, a eficiência na coleta seletiva e o incentivo a práticas sustentáveis. Como trabalhos futuros, sugere-se a expansão do protótipo para novas categorias de resíduos, bem como o desenvolvimento de versões que incorporem conectividade para monitoramento remoto, caso se torne viável.

Referências

- Almeida, I. M. S. d., Silva, K. A. d., and El-Deir, S. G. (2022). *Resíduos sólidos: gestão e gerenciamento*. EDUFRPE, Recife, 1 edition. Obra disponível em versão eletrônica.
- Arishi, A. (2025). Real-time household waste detection and classification for sustainable recycling: A deep learning approach. *Sustainability*, 17(5).
- Batista, M. H. and Martins, F. C. (2019). Informação e conhecimento social das cidades no gerenciamento de resíduos sólidos. *Gestão de Resíduos Sólidos Volume*, page 7.
- Brasil (2010). Lei nº 12.305, de 2 de agosto de 2010. institui a política nacional de resíduos sólidos. Diário Oficial da União, Brasília, DF, 3 ago. 2010.
- Cembranel, A. S., Balbinotti, E. C., Bravo, C. E. C., Tonial, I. B., and Pinto, E. P. (2021). Composição gravimétrica e as causas da geração de rejeitos na triagem dos resíduos recicláveis municipal. *Brazilian Journal of Development*, 7(4):36217–36239.
- Vo, N. S., Nguyen, N. T. X., and et al., G. P. L. (2024). An efficient model on aiot devices for trash classification applications. *SN Computer Science*, 5.
- Vukicevic, A. M., Petrovic, M., and et al., N. J. (2025). Versatile waste sorting in small batch and flexible manufacturing industries using deep learning techniques. *Scientific Reports*, 15.