

**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIAS E TECNOLOGIA DE SÃO
PAULO, CÂMPUS BRAGANÇA PAULISTA**
CURSO TÉCNICO EM ELETROELETRÔNICA INTEGRADO AO ENSINO MÉDIO

RICKELMY MARTINS ALVES
VINÍCIUS CYPRIANO DE SOUZA CAVALLARO

**LIXEIRA INTELIGENTE PARA SEPARAÇÃO AUTOMÁTICA DE RESÍDUOS
RECICLÁVEIS ATRAVÉS DE IA**

Bragança Paulista, SP

2025

RICKELMY MARTINS ALVES
VINÍCIUS CYPRIANO DE SOUZA CAVALLARO

**LIXEIRA INTELIGENTE PARA SEPARAÇÃO AUTOMÁTICA DE RESÍDUOS
RECICLÁVEIS ATRAVÉS DE IA**

Relatório para participação na 15º
BRAGANTEC - Feira de Ciência e
Tecnologia.

Orientador: Prof. Vitor Garcia

Bragança Paulista, SP

2025

AGRADECIMENTOS

Ao nosso professor orientador Vitor Garcia, pelo seu apoio e orientação durante realização do projeto. Sua participação na equipe de desenvolvimento foi fundamental para que ele existisse.

Ao professor Saimon Vendrame, pelo seu apoio e orientação durante a realização do projeto, principalmente na elaboração da peça de articulação.

Ao professor Alexandre Tomazati Oliveira, pelo seu apoio e orientação durante a realização do projeto, principalmente com relação à inteligência artificial.

À irmã e ao cunhado de um dos membros da equipe, Vanessa Cypriano de Souza Cavallaro e Marcelo Augusto Bellopedo de Aquino, pelas orientações no desenvolvimento deste relatório.

SUMÁRIO

1	RESUMO	05
2	INTRODUÇÃO	06
3	OBJETIVOS	08
3.1	Objetivo Geral	08
3.2	Objetivos Específicos	08
4	JUSTIFICATIVA	09
5	FUNDAMENTAÇÃO TEÓRICA	11
5.1	Conceitos Iniciais	11
5.2	Gestão dos Resíduos Sólidos no Brasil	12
5.3	Resíduos Sólidos em Ambiente Escolar	12
5.4	Separação Manual e Suas Limitações	13
5.5	Impactos Econômicos e Sociais da Reciclagem Eficiente	14
5.6	Tecnologia e Inteligência Artificial Aplicada à Separação de Resíduos	15
6	DESENVOLVIMENTO	19
6.1	Materiais e Métodos	19
6.2	Levantamento e Seleção de Componentes	19
6.3	Coleta e Preparação de Dados Para Treinamento da IA	20
6.4	Desenvolvimento e Treinamento do Modelo de IA	21
6.5	Desenvolvimento do Mecanismo de Separação	22
6.6	Projeto e Construção da Estrutura Física da Lixeira	23
7	RESULTADOS	24
7.1	Primeiro Modelo	24
7.2	Segundo Modelo	26
7.3	Terceiro Modelo	28
7.4	Quarto Modelo	30
7.5	Quinto Modelo	31
7.6	Sexto Modelo	33
8	CONCLUSÕES	36
	REFERÊNCIAS BIBLIOGRÁFICAS	37

1 RESUMO

A produção de resíduos urbanos é um problema global em expansão: estima-se que anualmente sejam geradas cerca de 2,01 bilhões de toneladas de lixo doméstico no mundo (WATER, c2022), esse volume massivo de lixo, associado a uma falha separação manual e constante contaminação de recicláveis, dificulta a reciclagem, agravando o descarte incorreto do lixo e efeitos negativos no ambiente e na saúde pública. No Brasil, a gestão de resíduos sólidos ainda enfrenta grandes desafios, especialmente no ambiente escolar, onde há alta produção de lixo e frequentes erros na separação manual que levam à contaminação dos recicláveis. Além disso, pesquisas mostram que o público de 15 a 29 anos é o menos engajado na coleta seletiva, o que agrava o problema (LLOYD’S REGISTER FOUNDATION; UNEP; ENGINEERING X, 2024). Esse trabalho se baseou nesses problemas para desenvolver uma lixeira inteligente voltada às instituições de ensino, equipada com sensores e inteligência artificial para classificar automaticamente os resíduos e direcioná-los ao compartimento adequado. Diferente de iniciativas internacionais como o TrashBot ou a Smart Bin Tech, que se concentram em países desenvolvidos e em ambientes de grande fluxo, este projeto foca no contexto escolar brasileiro, marcado por alta produção de lixo, baixa infraestrutura de reciclagem e pouco engajamento juvenil. O desenvolvimento do projeto segue o Método da Engenharia, com etapas que incluem o levantamento e seleção de componentes eletrônicos, destacando-se o microcontrolador ESP32-CAM, responsável pela captura e processamento inicial das imagens, e os servomotores MG996R e MG995, que atuarão nos mecanismos de direcionamento dos resíduos. Para a etapa de inteligência artificial, foi utilizada a plataforma Edge Impulse, voltada ao treinamento de um modelo baseado em Redes Neurais Convolucionais (CNN), capaz de identificar materiais como plástico, papel e metal a partir de imagens coletadas. Paralelamente, está sendo desenvolvido o protótipo físico da lixeira, projetado para integrar os sistemas de visão computacional, movimentação mecânica e armazenamento dos resíduos em compartimentos distintos. A avaliação do protótipo será feita por meio de testes sistemáticos de desempenho e de interação com usuários no Instituto Federal de Educação, Ciências e Tecnologia de São Paulo – campus Bragança Paulista, de modo a validar não apenas a precisão da separação, mas também a usabilidade e aceitação da solução.

2 INTRODUÇÃO

A gestão inadequada dos resíduos sólidos urbanos, comumente conhecidos como “lixo”, constitui um dos maiores desafios ambientais do Brasil. O crescimento populacional, aliado ao consumo em larga escala e à lógica de produção acelerada, intensifica a geração de resíduos em níveis que superam a capacidade de manejo dos sistemas tradicionais de coleta e tratamento. Essas dificuldades acarretam uma grande quantidade de lixo, cerca de 41% dos resíduos coletados, ou 28,7 milhões de toneladas, tendo destinação inadequada: em lixões, aterros irregulares, valas, terrenos baldios e córregos urbanos (ABREMA, 2024, apud O GLOBO, 2024). Essa destinação incorreta provoca malefícios ao meio ambiente e a saúde pública (ABREMA, 2024, apud O GLOBO, 2024).

Nesse contexto, a reciclagem surge como prática indispensável para a redução dos impactos ambientais, pois contribui para o prolongamento do ciclo de vida dos materiais, a diminuição da exploração de recursos naturais e a mitigação dos problemas associados ao descarte incorreto, sendo inclusive colocada como uma das primeiras na ordem de prioridades de práticas de gestão e gerenciamento do lixo da Política Nacional de Resíduos Sólidos, ficando apenas atrás da não geração, redução e reutilização (BRASIL, 2010).

Apesar de sua importância, a prática da reciclagem ainda enfrenta limitações significativas no Brasil. Segundo o Panorama dos Resíduos Sólidos no Brasil 2024, elaborado pela Associação Brasileira de Resíduos e Meio Ambiente (ABREMA), em 2023 foram produzidas cerca de 80,96 milhões de toneladas de resíduos sólidos urbanos no país. Deste total, somente 8% foi destinado efetivamente à reciclagem, considerando tanto a coleta seletiva municipal quanto o trabalho dos catadores informais (ABREMA, 2024, apud O GLOBO, 2024), um aumento considerável em relação aos 3,5% do ano anterior, mas ainda assim muito abaixo da estatística alcançada por outros países. Esses dados são reflexo não apenas da limitação da infraestrutura de coleta seletiva, mas também da dependência de processos manuais sujeitos a falhas. A separação incorreta de materiais, muitas vezes causada por falta de informação ou descuido no descarte, compromete a qualidade do resíduo reciclável e dificulta seu reaproveitamento.

Este estudo propõe uma forma de aumentar a eficiência da reciclagem de maneira localizada, focada inicialmente nos resíduos produzidos dentro de uma instituição de ensino médio

e superior em Bragança Paulista, o Instituto Federal de Educação, Ciências e Tecnologia de São Paulo, campus Bragança Paulista (IFSP – BRA). Para tanto, visa o desenvolvimento de uma lixeira inteligente que incorporará um microcontrolador com uma inteligência artificial baseada em rede neural convolucional (CNN) embarcada. Esse sistema será capaz de identificar automaticamente o material do resíduo descartado e direcioná-lo para seu compartimento correspondente dentre as possibilidades (plástico, papel e metal) por meio da ativação de um mecanismo autônomo de separação.

Esta abordagem tecnológica visa eliminar erros humanos, aumentar a taxa de reaproveitamento de materiais e reduzir a contaminação entre recicláveis. Além do impacto ambiental positivo, o uso de lixeiras inteligentes em escolas tem também um papel educativo, incentivando práticas sustentáveis e aproximando os estudantes de soluções tecnológicas aplicadas ao cotidiano.

3 OBJETIVOS

3.1 Objetivo Geral

Desenvolver e prototipar uma lixeira inteligente, com estrutura própria, capaz de, utilizando Inteligência Artificial, identificar, classificar e separar automaticamente resíduos recicláveis comuns, como plástico, papel e metal, no momento do descarte, a fim de aumentar a eficiência da reciclagem no ambiente institucional, inicialmente do Instituto Federal de Educação, Ciências e Tecnologia de São Paulo – campus Bragança Paulista.

3.2 Objetivos Específicos

1. Pesquisar e selecionar os componentes eletrônicos que serão utilizados (microcontrolador, sistema de visão para o microcontrolador, motores etc.).
2. Coletar e organizar um conjunto de imagens de diferentes tipos de resíduos recicláveis encontrados comumente nas lixeiras presentes na instituição para treinamento da inteligência artificial.
3. Projetar e implementar um modelo de inteligência artificial (rede neural convolucional) capaz de classificar os resíduos com base nas imagens capturadas.
4. Desenvolver os mecanismos, principalmente utilizando motores, para direcionar o resíduo para o compartimento correto da lixeira após a classificação.
5. Projetar e construir a estrutura física da lixeira, considerando os requisitos de espaço para os componentes eletrônicos, mecanismos de separação e compartimentos de destino para os resíduos.
6. Integrar o sistema de visão, o modelo de IA e os mecanismos de separação em um protótipo funcional da lixeira inteligente.
7. Realizar testes de validação do protótipo para avaliar a precisão da classificação e a eficiência do mecanismo de separação

4 JUSTIFICATIVA

Embora já existam projetos bastante semelhantes ao que visamos desenvolver, como o TrashBot da CleanRobotics ou o Smart Bin Tech da UTS em parceria com a CSIRO, eles são comumente atraídos em áreas de grande fluxo populacional e predominantemente residentes em países desenvolvidos que já possuem alta preocupação com a reciclagem e gestão do lixo. Assim, este projeto busca viabilizar a aplicação dessas tecnologias em contextos e locais onde elas atualmente não são extremamente acessíveis.

Pensando no cenário brasileiro, a implementação de soluções tecnológicas na gestão de resíduos está diretamente ligada ao cumprimento de vários Objetivos de Desenvolvimento Sustentável (ODS) da ONU, como o ODS 9 (Indústria, Inovação e Infraestrutura), ODS 11 (Cidades e Comunidades Sustentáveis) e ODS 12 (Consumo e Produção Responsáveis).

O recorte específico no ambiente escolar brasileiro representa um diferencial fundamental. As instituições de ensino, como demonstram estudos de caracterização de resíduos, podem produzir mais de 10 toneladas de lixo por ano (SOUZA et al., 2020), sendo compostas majoritariamente por papéis, embalagens plásticas e restos de alimentos. Apesar desse volume expressivo, a separação ainda é ineficiente, marcada por falhas humanas, contaminação dos recicláveis e ausência de políticas internas estruturadas. Além disso, estudos apontam que a parcela mais jovem da população, de 15 a 29 anos, ainda possuem pouca conscientização sobre essa prática, com apenas 41% deles realizando a coleta. (LLOYD'S REGISTER FOUNDATION; UNEP; ENGINEERING X, 2024). Inserir a tecnologia de separação inteligente diretamente nesse contexto significa atuar em um espaço estratégico: um local que não gera apenas grande quantidade de resíduos, mas também concentra estudantes no processo de formação, ampliando o alcance educativo da proposta.

Outro aspecto inovador é o foco em eliminar erros recorrentes na separação manual, que, como mostram dados recentes, comprometem significativamente a eficácia da reciclagem. Pesquisas indicam que cerca de 41% da população brasileira descarta resíduos de forma incorreta (LLOYD'S REGISTER FOUNDATION; UNEP; ENGINEERING X, 2024), e que 50% não faz separação entre resíduos orgânicos e recicláveis, contribuindo para a contaminação dos materiais que poderiam ser reciclados (MINDMINERS, s.d.). Ao substituir a dependência exclusiva do

comportamento humano pela classificação inteligente por meio de sensores e inteligência artificial, o projeto potencializa o reaproveitamento de materiais e reduz os índices de contaminação.

Portanto, ao contrário de soluções já existentes no mercado internacional, este projeto propõe uma aplicação adaptada ao contexto brasileiro, de baixo custo e com impacto direto em uma realidade que carece de inovação tecnológica.

5 FUNDAMENTAÇÃO TEÓRICA

5.1 Conceitos Iniciais

Os resíduos sólidos são definidos pela Política Nacional de Resíduos Sólidos (Lei nº 12.305/2010) como "todo material, substância, objeto ou bem descartado resultante de atividades humanas em sociedade, cuja destinação final se procede, se propõe proceder ou está obrigado a proceder, nos estados sólido ou semissólido" (BRASIL, 2010).

Dentro desse universo, distinguem-se duas categorias principais:

Resíduos recicláveis secos, que podem ser reaproveitados em processos produtivos, como papel, papelão, vidro, tetrapak, plásticos e metais (BRASIL, s.d.).

Rejeitos, definidos pela mesma lei como "resíduos sólidos que, depois de esgotadas todas as possibilidades de tratamento e recuperação por processos tecnológicos disponíveis e economicamente viáveis, não apresentem outra possibilidade que não a disposição final ambientalmente adequada" (BRASIL, 2010).

Um dos maiores desafios do setor é a contaminação dos resíduos recicláveis. Isso ocorre quando materiais potencialmente recicláveis entram em contato com orgânicos ou rejeitos, inviabilizando sua triagem e reaproveitamento. Segundo a Associação Brasileira de Resíduos e Meio Ambiente (ABREMA), esse é um dos fatores que reduz a taxa de reciclagem no país para apenas 8% do total coletado (ABREMA, 2024).

A coleta seletiva é entendida como o processo de recolhimento diferenciado dos resíduos previamente separados segundo sua constituição ou composição (BRASIL, 2010). No Brasil, o Conselho Nacional do Meio Ambiente (CONAMA) estabeleceu a padronização das cores para identificação dos diferentes tipos de resíduos: azul (papel e papelão), vermelho (plástico), verde (vidro), amarelo (metal), marrom (orgânicos), preto (madeira), laranja (resíduos perigosos), branco (hospitalares), roxo (radioativos) e cinza (rejeitos) (BRASIL, 2001).

5.2 Gestão dos Resíduos Sólidos no Brasil

Segundo o Panorama dos Resíduos Sólidos no Brasil 2024, elaborado pela Associação Brasileira de Resíduos e Meio Ambiente (Abrema), em 2023 foram produzidas cerca de 80,96 milhões de toneladas de resíduos sólidos urbanos no país. Deste total, somente 8% foi destinado efetivamente à reciclagem, considerando tanto a coleta seletiva municipal quanto o trabalho dos catadores informais (ABREMA, 2024, apud O GLOBO, 2024), um aumento considerável em relação aos 3,5% do ano anterior, mas ainda assim muito abaixo da estatística alcançada por outros países. Ainda de acordo com o IBGE, apenas 60,5% dos municípios brasileiros declararam possuir algum tipo de coleta seletiva, revelando a dificuldade de se implantar práticas de reciclagem em escala nacional (CAMPOS, 2024).

Em relação a coleta seletiva, 59% das residências separam os materiais antes de descartá-los, superando a média mundial, segundo a pesquisa “*A World of Waste: Risks and opportunities in household waste management*” realizada pela Lloyd’s Register Foundation, em colaboração com o Programa das Nações Unidas para o Meio Ambiente (UNEP) e a empresa Engineering X (2024). No entanto, este estudo também apontou uma diferença geracional: 75% das pessoas acima de 65 anos realizam a coleta, enquanto apenas 41% dos jovens entre 15 e 29 anos adotam essa prática, demonstrando que a parcela mais jovem da população ainda possui pouca conscientização.

Mesmo com um bom engajamento na separação nas residências brasileiras, cerca de 41% dos resíduos coletados, ou 28,7 milhões de toneladas, tiveram destinação inadequada: em lixões, aterros irregulares, valas, terrenos baldios e córregos urbanos (ABREMA, 2024, apud O GLOBO, 2024). Essa destinação incorreta provoca malefícios ao meio ambiente e a saúde pública (ABREMA, 2024, apud O GLOBO, 2024).

5.3 Resíduos Sólidos em Ambiente Escolar

No ambiente escolar esse problema também é evidente, ainda que existam menos estatísticas nacionais específicas publicadas. Um estudo de caso sobre a caracterização de resíduos sólidos em uma escola pública estadual em Barreiras (BA) evidenciou que a instituição gera em

média 53,05 kg de resíduos por dia (SOUZA et al., 2020). Considerando 200 dias letivos por ano, essa escola produz aproximadamente 10.610 kg de lixo anuais, ou seja, mais de 10 toneladas de resíduos a cada ano.

Muitas vezes, as instituições de ensino não contam com infraestrutura adequada para separação ou, quando contam com infraestrutura, sofrem com conscientização insuficiente para que alunos e funcionários façam o descarte correto. Pesquisas no Nordeste apontam que, mesmo em escolas onde existe coleta seletiva, os estudantes e funcionários frequentemente demonstram insegurança sobre em qual lixeira descartar determinados resíduos, o que leva a erros constantes e à mistura de materiais recicláveis e orgânicos (PEREIRA, 2025).

O descarte incorreto resulta em outro desafio recorrente, a contaminação dos resíduos recicláveis. Restos de alimentos descartados junto a papéis, plásticos ou embalagens inviabilizam o reaproveitamento de grande parte dos materiais, que acabam sendo direcionados como rejeitos. Estudos realizados em escolas do Norte do Brasil mostram que essa prática é comum, reduzindo a eficiência da coleta seletiva e aumentando os custos de destinação final (BANDEIRA et al., 2025).

Em resumo, dentro das escolas o problema da gestão de resíduos sólidos envolve muitas vezes a falta de estrutura e, sobretudo, a baixa efetividade da conscientização da comunidade escolar. Esse conjunto de fatores gera altos volumes de resíduos descartados de forma incorreta, inviabilizando a reciclagem e aumentando tanto os impactos ambientais quanto os custos associados à destinação final.

5.4 Separação Manual e Suas Limitações

Mesmo quando há lixeiras de coleta seletiva, é comum ocorrer a contaminação dos recicláveis pelo descarte incorreto, o que reduz muito a eficácia da reciclagem. De fato, pesquisas mostram que cerca de 41% das pessoas no Brasil descartam resíduos inadequadamente, misturando recicláveis com lixo comum ou errando no tipo de lixeira (LLOYD'S REGISTER FOUNDATION; UNEP; ENGINEERING X, 2024). Outro estudo, “O alimento que jogamos fora”, utilizando uma análise comportamental, indica que 50% da população não faz qualquer separação entre resíduos orgânicos e recicláveis, descartando tudo no lixo comum (MINDMINERS, [s.d.]).

A principal limitação da separação manual é a dependência direta da conscientização e do conhecimento individual. Muitas pessoas não sabem identificar corretamente o tipo de material a ser descartado, especialmente quando se trata de embalagens compostas (como caixas de longa vida ou plásticos mistos). Isso gera confusão no momento do descarte e aumenta a contaminação dos resíduos, o que, em muitos casos, inviabiliza o reaproveitamento.

Além disso, o processo de separação manual implica custos adicionais para os sistemas de limpeza urbana e para os catadores. Os resíduos mal descartados precisam ser reclassificados manualmente em centrais de triagem, o que exige mais tempo, mão de obra e recursos. Em Curitiba, por exemplo, estima-se que 30% do material coletado seja perdido devido à contaminação ou erros de separação, representando desperdício econômico e ambiental (PREFEITURA, 2013).

Essa situação demonstra que dependemos demais do acerto manual do usuário, o que é vulnerável a confusões por falta de informação, sinais pouco claros nas lixeiras ou ausência de conscientização.

5.5 Impactos Econômicos e Sociais da Reciclagem Eficiente

De acordo com a ABRELPE, o Brasil perde anualmente cerca de R\$14 bilhões por não aproveitar corretamente materiais recicláveis descartados como rejeitados (MAURICIO; FOSTERS, 2020). Esse valor corresponde ao potencial econômico que poderia ser gerado pela comercialização de materiais como papel, plástico, vidro e metais, caso fossem devidamente separados e reinseridos nas cadeias produtivas.

Outro dado que reforça essa dimensão econômica é que apenas 4% dos resíduos sólidos urbanos no Brasil passam por reciclagem efetiva, enquanto países de mesma faixa de renda e grau de desenvolvimento econômico chegam a 16% de reaproveitamento, em relação aos países desenvolvidos a discrepância aumenta ainda mais, pois alcançam 67% de reciclagem efetiva (GANDRA, 2022), demonstrando não apenas o déficit ambiental, mas também o desperdício de recursos que poderia movimentar a economia circular, reduzindo a retenção de materiais primários e gerando novos mercados.

Do ponto de vista social, a reciclagem eficiente contribui diretamente para a geração de empregos e renda. Segundo o Movimento Nacional dos Catadores de Materiais Recicláveis (MNCR) estima-se que mais de 800 mil pessoas no Brasil atuem como catadores de materiais recicláveis, muitos em situação de vulnerabilidade social (BRITO; GERAQUE; RAJÃO, 2024). A ampliação da eficiência da coleta seletiva e a redução da contaminação dos materiais poderiam garantir melhores condições de trabalho, maior valorização dos resíduos e, consequentemente, rendimento mais estável para essa população.

Além disso, a reciclagem eficiente também gera benefícios indiretos, como a redução dos gastos públicos com a destinação final de resíduos em aterros sanitários. Em 2020, os custos com transporte e destinação de lixo consumiram R\$30,5 bilhões, majoritariamente recursos públicos municipais (ABREMA, 2024). Quanto maior for o índice de reciclagem, menores serão esses custos, permitindo que os recursos públicos sejam realocados para outras áreas prioritárias, como saúde e educação.

No âmbito da saúde pública, a correta gestão e reaproveitamento dos resíduos diminui a rotina de vetores de doenças, como moscas e roedores, associados ao descarte inadequado. Isso se traduz em menos impactos sociais negativos e menor pressão sobre os sistemas de saúde, reforçando a importância de investir em processos de separação mais eficientes.

Portanto, uma reciclagem eficiente deve ser vista não apenas como uma prática ambientalmente responsável, mas como uma estratégia capaz de contribuir para a economia circular, gerar empregos e renda, reduzir custos públicos e promover qualidade de vida. Nesse contexto, tecnologias inovadoras que minimizam erros no descarte e maximizam o reaproveitamento dos resíduos tornam-se essenciais para potencializar esses benefícios.

5.6 Tecnologia e Inteligência Artificial Aplicada à Separação de Resíduos

A baixa eficiência dos processos de triagem, majoritariamente manuais, e a falta de uma cultura de descarte adequado são barreiras significativas para a reciclagem. Neste contexto, a

tecnologia surge como a principal ferramenta para uma mudança de paradigma, e a Inteligência Artificial (IA), em especial a visão computacional, oferece soluções inovadoras para automatizar a separação de materiais, aumentando a eficiência e promovendo a economia circular.

A inteligência artificial é um campo da ciência da computação que visa o desenvolvimento de sistemas que simulam processos cognitivos humanos, como reconhecimento de padrões, tomada de decisão e aprendizado a partir de experiências. Dentro da IA, uma das abordagens mais utilizadas é o Aprendizado de Máquina (Machine Learning – ML), que consiste em treinar algoritmos para que possam melhorar seu desempenho em uma tarefa à medida que são expostos a novos dados.

Entre os diversos modelos de ML, destacam-se as Redes Neurais Convolucionais (CNNs – Convolutional Neural Networks), amplamente aplicadas em tarefas de visão computacional, como a identificação de imagens. No contexto deste projeto, a CNN é responsável por classificar os resíduos (plástico, papel e metal) com base em características visuais extraídas das imagens capturadas pela câmera do microcontrolador utilizado, um ESP32-CAM.

Uma CNN se inspira no funcionamento do córtex visual humano, e é organizada em várias camadas compostas por neurônios artificiais. Cada neurônio recebe entradas de neurônios das camadas anteriores, que carregam características extraídas da imagem, como bordas, texturas ou padrões de cor. Essas entradas são ponderadas por pesos, valores numéricos que determinam o grau de importância de cada característica para a tarefa de classificação. O neurônio então processa essa combinação, a opera matematicamente e transmite o resultado para a próxima camada. Ao longo das camadas, essas transformações sucessivas permitem que a rede combine informações simples das camadas iniciais em padrões mais complexos das camadas profundas, até que os sinais convergem para uma das saídas possíveis, representando a classe final atribuída ao resíduo. A precisão desse processo depende diretamente da qualidade do treinamento, que ajusta os pesos para que a rede aprenda a distinguir corretamente cada categoria.

O processo de treinamento do modelo da CNN para reconhecimento de imagens envolve diversas etapas. Inicialmente, é necessário a coleta de diversas imagens, que irão compor o conjunto de dados, ou *dataset*, utilizados pelo programa para ele ser capaz de reconhecer padrões a partir do *data labeling*, que é o processo de rotulagem, onde se identifica a posição na imagem e

classificação dos objetos relevantes da imagem. Após o labeling, antes do início do treinamento, define-se o *train-validation-test set split*, ou seja, a separação do conjunto total de imagens em três categorias. O *train set* é utilizado para treinar a IA, permitindo que ela aprenda padrões a partir dos dados. O *validation set* é apresentado durante o treinamento para avaliar o desempenho intermediário e auxiliar no ajuste de parâmetros. Por fim, o *test set* é usado após o treinamento para avaliar os resultados finais e fornecer uma estimativa de como o modelo se comportará em um contexto real.

Em seguida, a IA é exposta a uma série de múltiplas *epochs*, também conhecidas como *training cycles*, que são a passagem completa por todo o conjunto de dados. Dentro das *epochs*, a cada uma certa quantidade de imagens analisadas, o programa realiza alterações no comportamento dos pesos, explorando inicialmente valores aleatórios, mas que vão sendo ajustados de acordo com os erros e acertos provenientes de cada mudança, o que molda lentamente o comportamento do modelo para uma classificação mais precisa. A quantidade de imagens que será analisada até haver alteração dos pesos é chamada de *batch size*, e o grau dessa alteração é definido pelo *learning rate*, com valores mais altos significando mudanças mais bruscas.

Os valores de *epochs*, *batch size*, e *learning rate*, tal qual a quantidade de imagens que compõem o conjunto de dados final, o individual de cada classe e as porcentagem de distribuição do *train-validation-test set split*, são parâmetros que devem ser definidos para o treinamento visando um melhor aproveitamento e resultado, considerando por exemplo características de hardware e software utilizados, mas também evitando valores extremos, tanto para mais quanto para menos, pois podem causar resultados ruins, ocorrência de vieses de classificação, falta de capacidade de generalização, entre outros fatores.

Após o treinamento, o modelo de IA é embarcado em algum dispositivo ou componente com capacidade de processamento, como um microcontrolador, que é acoplado a uma câmera para ser capaz de realizar os processos de captura de imagens. O que o programa faz nessa etapa é simplesmente aplicar os valores dos pesos identificados durante o treinamento como mais adequados para a classificação utilizando as imagens capturadas pela câmera, realizando o processamento internamente pelo microcontrolador. O resultado gerado a partir desse processamento é utilizado, de acordo com a aplicação pensada, para acionar atuadores responsáveis

pela segregação do lixo, como servomotores para fazer o direcionamento do resíduo para um compartimento correto.

6 DESENVOLVIMENTO

6.1 Materiais e Métodos

A presente pesquisa se baseia no Método da Engenharia, que se concentra no projeto, desenvolvimento e avaliação de soluções tecnológicas para problemas práticos. É de natureza aplicada e experimental, visando à criação e teste de um protótipo funcional. Foi e será utilizada majoritariamente a análise quantitativa para trabalhar com os dados obtidos, como por exemplo as estatísticas de desempenho da IA.

Para o desenvolvimento deste projeto, foram empregados recursos humanos, físicos e financeiros. A equipe de desenvolvimento, formada por 2 estudantes e orientada por um professor, ambos do IFSP - BRA, é responsável pelo planejamento, execução das etapas de hardware e software, treinamento da IA e construção do protótipo. O protótipo está sendo desenvolvido e montado nas instalações da própria instituição e nas residências dos membros da equipe.

Financeiramente, o projeto está sendo executado com recursos próprios dos integrantes da equipe e o apoio do orientador, buscando a otimização de custos por meio da aquisição de materiais de preços mais acessíveis e, quando viável, o reaproveitamento de componentes.

Até o presente momento da escrita deste relatório, o foco do desenvolvimento foi em prototipar o modelo de inteligência artificial que será utilizado para realizar a classificação dos resíduos, deixando em segundo plano a criação da estrutura física da lixeira e construção do mecanismo de seleção, sendo feito somente a escolha dos materiais e componentes eletrônicos e primeiros testes de capacidade, etapas que serão melhor descritas abaixo.

6.2 Levantamento e Seleção de Componentes

Para criar a estrutura que idealizamos, identificamos que seria necessário a utilização de um microcontrolador para embarcar o modelo de inteligência artificial e controlar a separação

baseado na classificação do modelo, e um motor para poder realizar os movimentos do processo de separação.

A seleção dos modelos de cada componente foi criteriosamente avaliada pela sua capacidade de desempenho nas tarefas designadas. Para o microcontrolador, a análise considerou sua capacidade de processamento, a complexidade de programação e a compatibilidade com a integração de outras tecnologias, como o sistema de visão. Com base nesses critérios, o ESP32-CAM se mostrou a opção mais viável, devido à sua capacidade de processamento suficiente para a inteligência artificial embarcada, relativa simplicidade de operação e câmera integrada. Quanto aos motores, a seleção baseou-se na precisão necessária para a função de direcionamento dos resíduos no sistema da lixeira. Assim, a decisão foi pela utilização de servomotores. O modelo do servomotor utilizado foi pensado em relação a sua capacidade de suportar o peso que seria imposto sobre ele. Por esse motivo, optamos pela escolha do modelo MG996R e MG995, pela sua grande disponibilidade de torque e resistência de carga.

6.3 Coleta e Preparação de Dados Para Treinamento da IA

A construção do conjunto de dados iniciou-se com a reunião de um conjunto diversificado de imagens de resíduos recicláveis comuns, como embalagens alimentícias, papéis amassados e latas de alumínio, todos provenientes das lixeiras do campus do IFSP - BRA. Desde o início da coleta, o vidro foi descartado como possibilidade de classificação, visto que muito raramente havia ocorrência de elementos de vidro sendo descartados no campus, deixando então apenas papel, plástico e metal. Com o desenvolvimento do projeto, foi percebida uma necessidade de diminuir a diversidade existente no conjunto de cada tipo de resíduo, pois isso dificultava muito a classificação, sendo então elegidos representantes para cada classe: caixas de suco para papel, garrafas PET para plástico e latas de alumínio para metal. Mesmo com a diminuição do escopo dos elementos identificados, foram recolhidos diferentes tipos de cada um.

Como durante a classificação o microcontrolador estaria sempre na mesma posição, a coleta das imagens para os testes já realizados foi feita com a câmera apontando em um mesmo ângulo de aproximadamente 45° com a horizontal, escolha baseada em critérios de visibilidade das características visuais dos resíduos utilizados. No entanto, as imagens contemplam diferentes

variações de iluminação ambiente e ângulos de disposição do lixo, simulando as diferenças existentes em diversas situações de descarte. Foi utilizado também uma chapa de metal pintada de cinza abaixo dos resíduos em todas as imagens, pois será a base para a colocação do lixo no processo de classificação.

Para tirar as fotos que iriam compor o treinamento do modelo nos testes, usamos a câmera do celular de um dos membros da equipe. A resolução das imagens foi decidida em 240x240 pixels, por ser uma resolução suportada pelo ESP32-CAM, quadrada para facilitar no redimensionamento caso fosse necessário, e alta o suficiente para possibilitar a identificação do resíduo sem que pesasse muito no treinamento ou no processamento.

Para o preparo do conjunto de imagens, utilizamos o site Roboflow para realizar o *data augmentation*, processo de aumento da quantidade de imagens por mudanças em suas características. Os *augmentation steps* empregados foram: *shear* de 4 graus positivos ou negativos e na horizontal ou vertical, *brightness* entre 10 graus negativos e positivos, *exposure* entre 10 graus negativos e positivos e *blur* de até meio pixel. O *data labeling* foi feito manualmente em cada uma das imagens, garantindo a correta nomeação de cada tipo de lixo para o treinamento posterior.

6.4 Desenvolvimento e Treinamento do Modelo de IA

O modelo de Inteligência Artificial principal será uma Rede Neural Convolutacional (CNN), projetada e treinada utilizando a plataforma Edge Impulse. Essa plataforma foi selecionada por sua capacidade de otimização de modelos para dispositivos embarcados e pela facilidade que oferece para desenvolvê-los. A quantidade de saídas para o modelo são 3, no caso, os 3 tipos de resíduos identificados: papel, plástico e metal.

Para a criação da IA em testes preliminares, tendo em vista as limitações do ESP32-CAM e do plano do edge impulse que possuímos, foram utilizadas uma quantia similar de imagens em cada classe, para evitar a criação de viés, de aproximadamente 100, valor esse que se mostrou suficiente para adquirir resultados levemente satisfatórios, mas que será aumentado nas próximas versões. Além das imagens enviadas ao programa por nós, também utilizamos o sistema de *data augmentation* oferecido pelo Edge Impulse para aumentar ainda mais o conjunto de dados. O *train-*

validation-test set split utilizado durante os testes foi o padrão do edge impulse, de 20% reservados para o *test set*, e dos 80% restantes, 20% são destinados ao *validation set* e os demais ao *train set*. Esses valores se traduzem para um *split* de 64/16/20 entre *train*, *validation* e *test set*, respectivamente. Para o número de *epochs* no treinamento, foi identificada uma estagnação dos resultados após chegar aproximadamente em 100 *epochs*, então assumimos esse como o valor definitivo para os modelos. Em relação ao *batch size*, utilizamos o valor padrão do treinamento do Edge Impulse, que é 32. Com o *Learning rate*, tanto 0,01 quanto 0,001 apresentaram resultados satisfatórios, mas optamos especialmente por 0,001.

Para realizar o *deployment* do modelo no microcontrolador, o Edge Impulse oferece uma opção de exportação do código para a Arduino IDE. Foi utilizado um modelo otimizado, quantizado em int8 por meio do EON Compiler. A escolha pelo modelo quantizado visa reduzir a latência durante a classificação e o consumo de RAM, considerando as limitações do hardware e a necessidade de latências moderadas.

6.5 Desenvolvimento do Mecanismo de Separação

O mecanismo de separação está sendo desenvolvido com foco em 3 partes essenciais: a plataforma basculante, a peça de articulação e o componente de movimentação.

A plataforma basculante será o apoio dos resíduos durante a fase de classificação pela IA, onde eles serão depositados acima dela para poderem ser vistos pela câmera do ESP32-CAM. Ela será composta de uma chapa única de metal, especificamente feita de zinco, com dimensões de proporção 1:1. Até o momento, as dimensões que estão sendo utilizadas são 32x32 cm. Além disso, utilizamos uma tinta em spray automotiva, na cor cinza, da marca Colorgin, para realizar a pintura da chapa de metal e garantir que ela fosse mais fosca, evitando o excesso de brilho advindo da chapa, anteriormente de cor metálica prateada.

A peça responsável por realizar a articulação do movimento será acoplada na face inferior da plataforma basculante e na parte superior da haste de madeira levantada perpendicularmente à base de madeira. Esta peça será impressa em 3d, e ainda está em etapa de projeto utilizando o programa Fusion 360, desenvolvido pela Autodesk. Ela compreenderá 2 partes principais para a

articulação, uma fixa na base e a outra conectada na primeira por um eixo. Cada uma irá acompanhar um dos servomotores, que possuem a função de realizar um movimento semicircular referente a basculação da plataforma basculante e outro para o alinhamento horizontal da plataforma em direção ao compartimento de armazenamento correspondente com a classificação realizada.

O componente de movimento refere-se aos servomotores MG996R e MG995, que serão fixados na peça de articulação para controlar a movimentação efetiva do mecanismo.

6.6 Projeto e Construção da Estrutura Física da Lixeira

Para a estrutura física da lixeira, foram selecionados materiais simples de construção, para que fossem de fácil obtenção, mas que seriam capazes de garantir estabilidade para o protótipo. O projeto da estrutura foi simplificado em relação ao que era inicialmente, e é composto por 4 partes: a base, a haste, os compartimentos de armazenamento dos resíduos e o suporte para o ESP32-CAM.

A base consiste em uma chapa de madeira de dimensões 51x61 cm e 2 cm de espessura. Ela ficará posicionada no chão e servirá de apoio para as lixeiras e a haste.

Para elevarmos a altura do mecanismo de seleção, fez-se necessária a utilização de uma haste de madeira, de dimensões 7,5x7,5x45 cm, considerando largura, profundidade e altura, respectivamente. Sua face inferior será fixada centralmente na base e sua face superior na peça de articulação, da qual serve de apoio.

Os compartimentos de armazenamento dos resíduos, originalmente pensados como algo que seria parte da construção interna da lixeira, foram substituídos por lixeiras menores, feitas de polipropileno, com capacidade de aproximadamente 15 litros, unidas sobre a base e em volta da haste e serão a destinação final do processo de segregação dos resíduos após a classificação.

Para sermos capazes de definir a altura do ESP32-CAM e seu ângulo de inclinação, utilizaremos um suporte, fixado na base, que compreenderá o microcontrolador. Seus materiais ainda não foram decididos propriamente.


7 RESULTADOS

Foram feitos testes para validação dos resultados da classificação dos modelos de IA em múltiplas etapas.

7.1 Primeiro Modelo

O primeiro modelo foi feito utilizando as imagens com diversidade estendida do início do projeto, que contemplava todos os resíduos produzidos dentro da instituição. A resolução das imagens era de 96x96 pixels, existiam 4 classes (lixo comum, metal, papel e plástico) e havia uma diferença de mais de 12 vezes entre a quantidade de imagens da classe com mais imagens (plástico, 255 imagens) para a classe com menos (metal, 19 imagens), conforme Imagem 1.

Imagem 1: Distribuição das imagens de treinamento do modelo 1.




fonte: Edge Impulse (2025)

Isso ocasionou um resultado insatisfatório na classificação pela criação de viés, com a IA reconhecendo uma boa estratégia de acerto como sendo a generalização de todo resíduo para plástico, o que ela mais conhecia devido a quantidade de imagens do treinamento. E, da mesma forma, não reconhecendo nenhum resíduo como metal pelo seu desconhecimento dele em razão da falta de dados. Essa conclusão foi possível em função de testes realizados utilizando *Live Classification*, uma ferramenta disponibilizada pelo Edge Impulse para classificação em tempo real sem necessitar da exportação do modelo para o microcontrolador. O *Live Classification* foi realizado utilizando uma webcam conectada a um computador, que processava o modelo.

Outra forma de perceber a ineficácia do modelo é analisando o *Feature Explorer*, que representa um “mapa” do *dataset*, mostrando se as classes podem ser bem identificadas baseadas nas características extraídas, processo esse que é feito anteriormente ao treinamento (Imagem 2).

Imagem 2: *Feature Explorer* do modelo 1.



fonte: Edge Impulse (2025)


A distribuição dos círculos de maneira tão agrupada, sem qualquer distinção clara entre as regiões de maior ocorrência das cores, representa uma dificuldade de diferenciar as características individuais de cada classe.

Para os próximos modelos, percebemos que teríamos que diminuir a diversidade de resíduos, que era o principal causador da maior quantidade de plásticos.

7.2 Segundo Modelo

A fim de alcançar melhores resultados, diminuimos a diversidade de resíduos, elegendo representantes para cada classe (garrafas PET para plástico, papéis amassados e caixas de suco para papel e latinhas de alumínio para metal) e retiramos a classe dos lixos comuns do treinamento. Também utilizamos o site Roboflow para realizar *data augmentation*. A partir dessas alterações, as diferenças na quantidade de imagens foi menos expressiva, sendo o máximo de apenas 5x entre a classe com maior quantidade de imagens (papel, 183) e a classe com menor quantidade de imagens (metal, 36) (Imagem 3).

Imagem 3: Distribuição das imagens de treinamento do modelo 2.




fonte: Edge Impulse (2025)

As mudanças realizadas tiveram como resultado uma melhora na classificação, identificada utilizando *Live Classification* nas mesmas condições anteriores. Ainda assim, a classificação permaneceu insatisfatória.

O *Feature Explorer* também apresentou melhorias, com uma clara diferença em relação ao primeiro modelo, agora apresentando uma separação mais clara entre as regiões de cada classe, com maior evidência entre papel e plástico (Imagem 4).

Imagem 4: *Feature Explorer* do modelo 2.



fonte: Edge Impulse (2025)

Posteriormente, foi identificado a partir de observação das imagens que o modelo usava para treinamento que 96x96 pixels era uma resolução insuficiente para o reconhecimento. Portanto, percebemos a necessidade de aumento dessa quantidade em modelos sucessores.

7.3 Terceiro Modelo

Para o terceiro modelo, diminuámos ainda mais a diversidade, restringindo os representantes de papel para apenas caixas de suco, e a diferença de quantidade de imagens entre classes, resultando em apenas 1,2 vezes mais imagens entre a classe com mais imagens (papel, 56) e com menos imagens (metal, 45) (Imagem 5).

Imagem 5: Distribuição das imagens de treinamento do modelo 3.




fonte: Edge Impulse (2025)

Além disso, também aumentamos a resolução da imagem para o triplo de suas dimensões, assumindo 288x288 pixels, o que significa um aumento de 9 vezes mais pixels por imagem, facilitando o reconhecimento. Essas alterações levaram a resultados mais satisfatórios pelo *Live Classification*, mas que ainda possui algumas inconsistências.

O aumento na resolução não causou melhoras significativas na visualização do *Feature Explorer* (Imagem 6).

Imagem 6: *Feature Explorer* do modelo 3.



fonte: Edge Impulse (2025)

Esse teste nos mostrou que o aumento na resolução foi positivo, mas ainda era necessária uma maior quantidade de imagens para que o modelo alcançasse um melhor resultado.

7.4 Quarto Modelo

Aumentamos a quantidade de imagens por classe, mas mantendo-as com quantidades próximas, com apenas 1,1 vezes mais imagens da classe com mais imagens (plástico, 85) em relação a com menos imagens (metal, 77) (Imagem 7). Adicionamos também imagens com a plataforma basculante vazia e os resíduos dispostos ao fundo da imagem, a fim de treinar a IA para reconhecer apenas objetos acima da plataforma.

Imagem 7: Distribuição das imagens de treinamento do modelo 4.




fonte: Edge Impulse (2025)

O resultado se manteve positivo nos testes com *Live Classification* para a classificação, mas ela permaneceu reconhecendo resíduos fora da plataforma, o que muito provavelmente indica que as imagens vazias foram ou ignoradas ou causadoras de possíveis pioras nos resultados.

Essas mudanças realizadas para este modelo não ocasionaram grandes mudanças na visualização do *Feature Explorer*, mas que permanece com um resultado decente (Imagem 8).

Imagem 8: *Feature Explorer* do modelo 4.



fonte: Edge Impulse (2025)

Portanto, como não foi perceptível mudanças positivas no modelo com a utilização de imagens vazias, abandonamos seu uso para evitar falhas.

7.5 Quinto Modelo

Com esse modelo, não utilizamos mais as imagens vazias, e alteramos levemente a quantidade de itens na classe dos metais, resultando em 1,06 vezes mais imagens entre as classes com mais (plástico, 85) e menos (metal, 80) (Imagem 9).

Imagem 9: Distribuição das imagens de treinamento do modelo 5.




fonte: Edge Impulse (2025)

O resultado observado na utilização do *Live Classification* se manteve similar aos modelos anteriores, com a classificação satisfatória mas apresentando inconsistências de vez em quando.

A mudança no *Feature Explorer* ocorreu de maneira não expressiva, apresentando apenas uma leve melhora em relação ao modelo anterior (Imagem 10).

Imagem 10: *Feature Explorer* do modelo 5.



fonte: Edge Impulse (2025)

Com este modelo alcançando um resultado suficiente, realizamos também a exportação dele para o microcontrolador para verificar sua qualidade embarcado. Com esse teste, percebemos que a resolução de 288x288 pixels não era suportada pelo ESP32-CAM, o que impedia o funcionamento do código. Portanto, conferimos a necessidade de adaptar para uma resolução aceita nos próximos modelos.

7.6 Sexto Modelo

Para este modelo, a única mudança foi a mudança da resolução para 240x240 pixels, que é aceita pelo ESP32-CAM. A quantidade de imagens permanece a mesma do modelo passado, com a diferença de 1,06 vezes mais entre a classe com mais (plástico, 85) e a com menos (metal, 80) (Imagem 11).

Imagem 11: Distribuição das imagens de treinamento do modelo 6.




fonte: Edge Impulse

A mudança na resolução não causou mudanças significativas na classificação, que continuou trazendo resultados positivos no *Live Classification*, apesar das incongruências.

Na análise do *Feature Explorer*, é possível perceber bastante semelhança com o último modelo, preservando a boa separação entre as classes, com uma menor visualização disso no exemplo do metal (Imagem 12).

Imagem 12: *Feature Explorer* do modelo 6.



fonte: Edge Impulse (2025)

Ao exportar o modelo para o ESP32-CAM para testá-lo embarcado, percebeu-se uma dificuldade muito grande de fazer a classificação dos resíduos, com a maioria do tempo nada sendo identificado, mesmo com os objetos na visão da câmera. Ao visualizar a imagem que a câmera captava, notamos a nítida diferença entre a qualidade da câmera do ESP32-CAM e de um celular, que havia sido usado para tirar as fotos para o treinamento. Constatamos então que essa dificuldade era advinda dessa diferença, e que para os modelos futuros seria melhor a utilização de imagens tiradas da própria câmera do ESP32-CAM.

8 CONCLUSÕES

A presente pesquisa se baseou no método da engenharia para enfrentar o problema da ineficiência da reciclagem no campus do IFSP - BRA, causada pela falta de precisão da segregação manual. A solução escolhida, utilizando inteligência artificial baseada em CNN, mostrou-se viável, de acordo com o levantamento de outros projetos internacionais.

Foram realizados testes com seis modelos da inteligência artificial, que apresentaram melhora progressiva na capacidade de reconhecer os resíduos recicláveis conforme ajustes no treinamento, como aumento da resolução das imagens, equilíbrio da quantidade de imagens entre classes e expansão do conjunto de imagens de cada categoria. Embora a classificação ao vivo tenha apresentado resultados satisfatórios, a execução no ESP32-CAM mostrou dificuldades, possivelmente devido à diferença na qualidade das imagens de treinamento e da câmera do microcontrolador.

O projeto cumpriu as etapas iniciais do método da engenharia, identificando o problema, realizando a pesquisa e explorando o desenvolvimento da solução. Os próximos passos incluem o treinamento do modelo final, incorporando as alterações positivas identificadas nos testes anteriores, a finalização da peça de articulação e o acoplamento do mecanismo de separação, a montagem da estrutura física integrando o microcontrolador e o mecanismo, e, finalmente, a validação do protótipo, testando sua eficácia tanto na classificação quanto na segregação correta dos resíduos.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABREMA - ASSOCIAÇÃO BRASILEIRA DE RESÍDUOS E MEIO AMBIENTE. **Reciclagem de resíduos chega a 8% no país com trabalho informal, aponta estudo**. 12 dez. 2024. Disponível em: <https://www.abrema.org.br/2024/12/12/reciclagem-de-residuos-chega-a-8-no-pais-com-trabalho-informal-aponta-estudo>. Acesso em: 24 set. 2025.
- ABREMA - ASSOCIAÇÃO BRASILEIRA DE RESÍDUOS E MEIO AMBIENTE. **Crise do lixo custa R\$ 97 bilhões por ano ao Brasil, aponta estudo**. 5 jun. 2024. Disponível em: <https://www.abrema.org.br/2024/06/05/crise-do-lixo-custa-r-97-bilhoes-por-ano-ao-brasil-aponta-estudo/>. Acesso em: 24 set. 2025.
- BANDEIRA, Jean Braga et al. **Gestão de resíduos sólidos em escola pública do Brasil: uma revisão integrativa**. Revista Brasileira de Gestão Ambiental e Sustentabilidade, [S.l.], v. 12, n. 30, p. 225-245, 2025. DOI: 10.21438/rbgas(2025)123022. Disponível em: <https://revista.ecogestaobrasil.net/v12n30/v12n30a22a.html>. Acesso em: 24 set. 2025.
- BRASIL. Conselho Nacional do Meio Ambiente – CONAMA. **Resolução CONAMA nº 275, de 25 de abril 2001**. Estabelece o código de cores para os diferentes tipos de resíduos, a ser adotado na identificação de coletores e transportadores, bem como nas campanhas informativas para a coleta seletiva. Diário Oficial da União: Brasília, DF, 2001. Disponível em: <https://www.siam.mg.gov.br/sla/download.pdf?idNorma=291>. Acesso em: 24 set. 2025.
- BRASIL. **Lei Nº 12.305, de 2 de agosto de 2010**. Institui a Política Nacional de Resíduos Sólidos; altera a Lei no 9.605, de 12 de fevereiro de 1998; e dá outras providências. Brasília, DF: Diário Oficial da União, 2010. Acesso em: 24 set. 2025.
- BRASIL. Ministério do Meio Ambiente. **Reciclagem e reaproveitamento**. Brasília: MMA, [s.d.]. Disponível em: <https://antigo.mma.gov.br/cidades-sustentaveis/residuos-solidos/catadores-de-materiais-reciclaveis/reciclagem-e-reaproveitamento.html>. Acesso em: 27 set. 2025.
- BRITO, Letícia; GERAQUE, Eduardo; RAJÃO, Guilherme. **Catadores são parte fundamental para a reciclagem, dizem especialistas**. CNN Brasil, São Paulo, 06 set. 2024. Disponível em: <https://www.cnnbrasil.com.br/nacional/catadores-sao-parte-fundamental-para-a-reciclagem-dizem-especialistas/>. Acesso em: 23 set. 2025.
- CAMPOS, Ana Cristina. **IBGE: 60,5% dos municípios têm coleta seletiva**. Agência Brasil [online], Rio de Janeiro, 28 nov. 2024. Disponível em: <https://agenciabrasil.ebc.com.br/geral/noticia/2024-11/ibge-605-dos-municipios-tem-coleta-seletiva>. Acesso em: 24 set. 2025.
- EDGE IMPULSE. **Edge Impulse - The Leading Edge AI Platform**. [S.l.: s.n], [s.d.]. Disponível em: <https://edgeimpulse.com>. Acesso em: 17 abr. 2025.
- ÉPOCA NEGÓCIOS. **Startup cria lixeira-robô que separa material reciclável**. [S.l.], 17 fev. 2020. Disponível em: <https://epocanegocios.globo.com/Tecnologia/noticia/2020/02/startup-cria-lixeira-robo-que-separa-material-reciclavel.html>. Acesso em: 23 mar. 2025.
- GANDRA, Alana. **Índice de reciclagem no Brasil é de apenas 4%, diz Abrelpe**. Agência Brasil, Rio de Janeiro, 5 jun. 2022. Disponível em:

<https://agenciabrasil.ebc.com.br/geral/noticia/2022-06/indice-de-reciclagem-no-brasil-e-de-4-diz-abrelpe>. Acesso em: 24 set. 2025.

KIKKEN, Natalie. **Smart Bin Technology sorts recyclable bottles automatically**. CSIRO. [S.l.], 16 ago. 2022. Disponível em: <https://www.csiro.au/en/news/All/Articles/2022/August/smart-bin-technology>. Acesso em: 23 mar. 2025.

KRISNA, Rithik. **Object Detection using ESP32-CAM and Edge Impulse**. Circuit Digest. [S.l.], 9 jul. 2024. Disponível em: <https://circuitdigest.com/microcontroller-projects/object-recognition-using-esp32-cam-and-edge-impulse>. Acesso em: 2 abr. 2025.

LLOYD'S REGISTER FOUNDATION; UNITED NATIONS ENVIRONMENT PROGRAMME (UNEP); ENGINEERING X. **A World of Waste: Risks and opportunities in household waste management**. 2024. Disponível em: <https://www.lrfoundation.org.uk/publications/a-world-of-waste-risks-and-opportunities-in-household-waste-management>. Acesso em: 24 set. 2025.

MAURÍCIO, Talis; FORSTER, Paula. **Brasil deixa de ganhar R\$ 14 bilhões com reciclagem de lixo**. CNN Brasil, 04 ago. 2020. Disponível em: <https://www.cnnbrasil.com.br/nacional/brasil-deixa-de-ganhar-r-14-bilhoes-com-reciclagem-de-lixo/>. Acesso em: 24 set. 2025.

MINDMINERS. **O alimento que jogamos fora**. [s.d.]. Disponível em: <https://mindminers.com/blog/o-alimento-que-jogamos-fora/>. Acesso em: 28 set. 2025.

O GLOBO. **Relatório aponta crescimento da reciclagem de resíduos no Brasil, mas persistência de lixões preocupa**. O Globo. [S.l.], 10 dez. 2024. Disponível em: <https://www.abrema.org.br/2024/12/10/relatorio-aponta-crescimento-da-reciclagem-de-residuos-no-brasil-mas-persistencia-de-lixoes-preocupa/>. Acesso em: 15 jun. 2025.

PEREIRA, E. de A. A.; SOARES, J. K. N. C.; PEREIRA, E. V.; GUEDES, C. dos S.; CANDEIA, A. L.; SILVA, J. M. D. da; COSTA, J. G. N. da; FERREIRA, E. S. de A. Caracterização de resíduos sólidos em escola pública de Patos, PB. **Caderno Pedagógico**, [S. l.], v. 22, n. 9, p. e18448, 2025. DOI: 10.54033/cadpedv22n9-347. Disponível em: <https://ojs.studiespublicacoes.com.br/ojs/index.php/cadped/article/view/18448>. Acesso em: 24 set. 2025.

PREFEITURA MUNICIPAL DE CURITIBA. **30% do material enviado para a coleta seletiva é rejeitado**. Curitiba, PR, 28 out. 2013. Disponível em: <https://www.curitiba.pr.gov.br/noticias/30-do-material-enviado-para-a-coleta-seletiva-e-rejeitado/31104>. Acesso em: 24 set. 2025.

SOUZA, Raniello Barreiras Barbosa; SILVA FILHO, Antonio José da; SOUZA, Raniele Barbosa. Caracterização de resíduos sólidos em uma escola pública estadual no município de Barreiras/Bahia. **Nature and Conservation**, [S. l.], v. 13, n. 1, p. 43–49, 2020. DOI: 10.6008/CBPC2318-2881.2020.001.0006. Disponível em: <https://sustenere.inf.br/index.php/nature/article/view/CBPC2318-2881.2020.001.0006>. Acesso em: 23 set. 2025.

UTS; CSIRO. **AI powered Smart Bin Technologies**. [S.l.: s.n.], 2022. Disponível em: <https://smartbin.tech>. Acesso em: 23 mar. 2025.

WATER & WASTE MANAGEMENT. **Solid Waste**. Water & Waste Management, [s.l.], c2022. Disponível em: <https://waterandwastemanagement.org/solid-waste.html>. Acesso em: 24 set. 2025.