



UNIVERSIDADE FEDERAL DA PARAÍBA
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA CIVIL E AMBIENTAL

LUCAS GERALDO FERREIRA DINIZ

**Aplicação de algoritmo de aprendizado de máquina para a melhoria
de processos em aterros sanitários**

JOÃO PESSOA
2023

Lucas Geraldo Ferreira Diniz

**Aplicação de algoritmos de aprendizado de máquina para a
melhoria de processos em aterros sanitários**

Trabalho apresentado a Universidade Federal da
Paraíba – UFPB, Campus João Pessoa, como re-
quisito para obtenção do título de Bacharel.

Orientador: Prof. Dr. Celso Augusto Guimarães
Santos

João Pessoa
2023

Diniz, Lucas

Aplicação de algoritmos de aprendizado de máquina para a melhoria de processos em aterros sanitários / Lucas Geraldo Ferreira Diniz. – João Pessoa, 2023.

XI 50 f. 39. ; 23.

Trabalho de Conclusão de Curso (Graduação em Engenharia Civil) - Universidade Federal da Paraíba, Campus João Pessoa, Paraíba, 2023

Orientador (a): Prof. Dr. Celso Augusto Guimarães Santos


1. Aterros Sanitários. 2. Inteligência Artificial. 3. Gestão de Resíduos. I. Aplicação de Inteligência Artificial para Aterros Sanitários. II. Santos, Celso. III. Universidade Federal da Paraíba.

FOLHA DE APROVAÇÃO

LUCAS GERALDO FERREIRA DINIZ


Aplicação de algoritmo de aprendizado de máquina para melhoria de processos em aterros sanitários

Trabalho de Conclusão de Curso em 10/11/2023 perante a seguinte Comissão Julgadora:




Celso Augusto Guimarães Santos
Departamento de Engenharia Civil e Ambiental do CT/UFPB

Aprovado



Leonardo Vidal Batista
Departamento de Sistemas de Computação do CI/UFPB

APROVADO



Richarde Marques da Silva
Departamento de Geociências do CCEN/UFPB

APROVADO

AGRADECIMENTOS

Agradeço a todos que, direta ou indiretamente, contribuíram com este trabalho, em especial:

Danilo G. Correia

Rogério C. Cabral

Rafael I. Cavalcante

Mariana M. Prado

Leonardo V. Batista

Celso A.G. Santos

"The main thing is be a man". – An UFC fighter

RESUMO

O manejo de resíduos sólidos no Brasil enfrenta desafios significativos, que requerem inovações tecnológicas para otimização e sustentabilidade. A inteligência artificial surge como um vetor de transformação, com capacidade para aprimorar a eficácia dos processos envolvidos. Este estudo visa desenvolver uma aplicação de inteligência artificial direcionada à gestão de aterros sanitários. A pesquisa foca na criação de um modelo computacional capaz de estimar a progressão da frente de trabalho utilizando redes neurais convolucionais, uma modalidade de deep learning especializada em tarefas de visão computacional. Imagens aéreas coletadas por Veículos Aéreos Não Tripulados (VANT) constituem a base de dados para treinamento do modelo proposto. Os resultados demonstram a capacidade da rede neural de identificar resíduos à superfície por meio de segmentação semântica, utilizando máscaras de classificação. A mensuração da expansão operacional é realizada pelo emprego do operador lógico XOR. A solução desenvolvida promete contribuir para o aprimoramento do controle operacional de aterros sanitários, impactando positivamente a gestão ambiental de resíduos sólidos.

Palavras-chave: Aterro Sanitário. Gestão de Resíduos Sólidos. Inteligência Artificial. Redes Neurais Convolucionais. Visão Computacional. Sustentabilidade Ambiental.

ABSTRACT

Solid waste management in Brazil faces significant challenges that demand technological innovations for optimization and sustainability. Artificial intelligence emerges as a transformative vector, with the capacity to enhance the efficiency of involved processes. This study aims to develop an artificial intelligence application targeted at the management of sanitary landfills. The research focuses on creating a computational model capable of estimating the progression of the working front using convolutional neural networks, a deep learning modality specialized in computer vision tasks. Aerial imagery collected by Unmanned Aerial Vehicles (UAVs) constitutes the database for training the proposed model. The results demonstrate the neural network's ability to identify surface waste through semantic segmentation, employing classification masks. The measurement of operational expansion is carried out using the XOR logical operator. The developed solution promises to contribute to the enhancement of operational control of sanitary landfills, positively impacting the environmental management of solid waste.

Keywords: Sanitary Landfill. Solid Waste Management. Artificial Intelligence. Convolutional Neural Networks. Computer Vision. Environmental Sustainability.

LISTAS DE FIGURAS

Figura 1 -	Avanço Operacional	10
Figura 2 -	Células de Aterro sanitários	11
Figura 3 -	Procedimentos operacionais	11
Figura 4 -	Custo ambiental de aterros sanitários	13
Figura 5 -	Linha do Tempo, revoluções digitais	15
Figura 6 -	Adoção de IA por setor	16
Figura 7 -	Adoção de IA por setor e força de trabalho	17
Figura 8 -	Número de recursos de IA que organizações incorporaram em pelo menos uma função ou unidade de negócio.	17
Figura 9 -	Processo de desenvolvimento de IA	18
Figura10 -	Aplicações de IA em diversos segmentos	19
Figura 11-	Entrada e saída do perceptron	22
Figura 12-	Organização da rede neural	22
Figura 13-	Camadas da CNN	23
Figura 14-	Banco de dados de imagens	24
Figura 15-	VANT utilizado	25
Figura 16-	Resultados da Aplicação da CNN	26
Figura 18-	Erros de identificação	28
Figura 19-	Procedimento de monitoramento	29
Figura 20-	Operador lógico	29
Figura 21-	Frente de operação, dia 1	30
Figura 22-	Frente de operação, dia 2	30
Figura 23-	Avanço operacional	31

LISTA DE ABREVIATURAS E SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
RSU	Resíduos Sólidos Urbanos
ABRELPE	Associação de empresas de limpeza pública e resíduos especiais
PNRS	Plano nacional de resíduos sólidos
CESTESB	Companhia ambiental do estado de São Paulo
IA	Inteligência Artificial
CNN	Convolutional neural network
VANT	Veículo aéreo não tripulado

SUMÁRIO

1 INTRODUÇÃO	7
2 Objetivos	9
3.1 Aterro Sanitário	9
3.1.1 Frente de Operação	10
3.1.2 Compactação	12
3.1.3 Cobertura	13
3.1.5 Custo Ambiental	13
3.1.6 <i>Business Intelligence</i>	15
3.2 Inteligência Artificial	16
3.2.1 Inteligência Artificial na Gestão de Resíduos	19
3.3 Visão Computacional	21
3.3.1 <i>Deep Learning</i>	22
3.3.2 Redes Neurais Convolucionais (CNNs)	22
3.3.3 Mask R-CNN	26
4. Metodologia	27
5. Resultados	28
6. Método para estimar o avanço operacional	31
7. Viabilidade do Método	34
8. Considerações finais	35
REFERÊNCIAS	36

1 INTRODUÇÃO

A geração e gestão de resíduos sólidos urbanos (RSU) é um dos assuntos prioritários na pauta sobre sustentabilidade, estando relacionado a questões ambientais que afetam a fauna, a flora e a qualidade de vida humana. Com o crescente desenvolvimento econômico e movimento de pessoas para áreas urbanas, o mundo está em uma trajetória em que a geração de resíduos deverá ser mais que o dobro do crescimento populacional até 2050 (Vasquez, 2018).

Segundo o relatório do Banco Mundial, globalmente são gerados 2,01 bilhões de toneladas de resíduos por ano, espera-se que esse número aumente para 2,59 bilhões até 2030 e supere 3,4 bilhões até 2050. No Brasil, em 2010, a geração de RSU era de 66,7 milhões de toneladas no ano, passou para 79,1 milhões em 2019, e alcançou um total de aproximadamente 81,8 milhões em 2022, 224 mil toneladas diárias (ABRELPE, 2022), sendo 49,7% do total correspondente ao Sudeste e 24,7% ao Nordeste.

Devido ao crescente aumento da geração de RSU, em 2010 foi criado o Plano Nacional de Resíduos Sólidos, que estabeleceu diretrizes, responsabilidades, princípios e objetivos para nortear os diferentes participantes na implementação da gestão de resíduos sólidos no país (PNRS, 2022), todavia, embora o PNRS tenha instituído o fim dos lixões até 2014, segundo o último relatório da associação de empresas de limpeza pública e resíduos especiais, de 2022, lixões e aterros controlados ainda seguem operando em todas as regiões do país, recebendo 39% do total de resíduos coletados no Brasil (ABRELPE, 2022);

O novo marco do saneamento ajustou o prazo de extinção de lixões para até 2024 (LEI nº 14026/2020), para municípios que já haviam elaborado um plano intermunicipal de resíduos sólidos ou plano municipal de gestão integrada de resíduos sólidos, e que possuam menos de 50 mil habitantes, sendo necessária a implantação de aterros sanitários nos locais em que existem lixões ou aterros controlados.

O PNRS define o aterro sanitário, como a forma de disposição final ambientalmente adequada, para rejeitos sem possibilidade de tratamento ou valorização. O aterro sanitário consiste em uma técnica de disposição final de resíduos urbanos no solo, sem causar danos à saúde pública e minimizando impactos ambientais (Brasil 2006, NBR-8419), seguindo critérios de engenharia.

Apesar dos impactos ambientais provocados pela operação de aterros sanitários serem pequenos, comparado as atividades de lixões e aterros controlados, tais impactos existem, seja decorrente do desmatamento de grandes áreas para sua implantação, seja pela contaminação do solo. Atualmente, 61% do RSU gerado no Brasil é destinado para aterros sanitários (ABRELPE, 2022), devendo este número aumentar nos próximos anos, com a adequação das cidades às diretrizes ambientais; porém, quanto maior o volume de RSU destinado aos aterros sanitários, maior será o espaço ocupado pelo resíduo, maior será a área desmatada para implantação de novas células, maior o risco de contaminação do solo e lençol freático, maior a necessidade de controle operacional a fim de garantir eficiência e otimização de espaço.

Em meio a uma grande variedade de dificuldades envolvendo a geração e gestão de resíduos sólidos urbanos, a tecnologia e inovação surgem como uma questão fundamental para o desenvolvimento sustentável, empresas e governos. A tecnologia muda a forma como as pessoas vivem, se comunicam, e também afeta a forma como o lixo é gerido (World Bank, 2018). No cenário tecnológico atual, a inteligência artificial destaca-se como uma tecnologia emergente com grande potencial. O surgimento da IA está moldando uma gama cada vez maior de setores da sociedade e terá impacto sob todos os aspectos do desenvolvimento sustentável (Vinuesa et al, 2021).

A visão computacional é a área ligada à inteligência artificial, dedicada a extração de informações a partir de imagens digitais (Santos et al, 2020), às informações extraídas de imagens permitem reconhecer, manipular e pensar sobre os objetos que as compõem (Milano, 2010). Dentro da visão computacional, a rede neural convolucional está entre as técnicas mais modernas e eficientes de processamento de imagens, cujo potencial pode ser aplicado para o monitoramento e gestão de resíduos sólidos urbanos.

Este trabalho propõe uma aplicação de inteligência artificial para monitorar o avanço operacional de aterros sanitários, aplicando técnica de segmentação de imagens, usando redes neurais convolucionais. Tais resultados poderiam contribuir para a gestão da qualidade da operação de aterros sanitários, monitorando a eficiência de compactação do resíduo exposto, documentando o avanço operacional, e otimizando a vida útil do empreendimento.

2 Objetivos

Desenvolver uma aplicação de inteligência artificial utilizando técnicas de aprendizagem profunda (*Deep Learning*) com o intuito de otimizar a gestão e o monitoramento de aterros sanitários, por meio de segmentação de imagens e identificação de resíduos exposto.

2.1 Objetivos específicos

- Elaborar uma rede neural convolucional apta a identificar resíduos expostos em imagens.
- Desenvolver um método para estimativa precisa do avanço operacional em aterros sanitários.
- Analisar a viabilidade técnica e operacional do método proposto.

3 Fundamentação Teórica

Este capítulo discorre sobre os conceitos imprescindíveis para a compreensão da solução proposta neste trabalho.

3.1 Aterro Sanitário

O aterro sanitário é uma estrutura de engenharia projetada para a disposição final de resíduos sólidos urbanos no solo, ocupando a menor área possível e mitigando impactos ambientais adversos (CETESB, 1997). A operacionalização de um aterro sanitário envolve o recebimento dos resíduos, que são direcionados à frente de operação onde são descarregados. Segue-se a distribuição e a compactação do ma-

terial por maquinário pesado, como tratores de esteiras e rolos compactadores, culminando na cobertura do resíduo com material inerte, geralmente argila. Este processo de compactação é crucial não apenas para a otimização do espaço, mas também para a minimização da percolação de águas pluviais e a consequente produção de lixiviado. Além disso, a compactação eficiente contribui para a elevada retenção de gases, como metano e dióxido de carbono, na camada de cobertura, prevenindo a sua emissão para a atmosfera.

3.1.1 Frente de Operação

A frente de operação refere-se ao setor do aterro sanitário destinado à disposição final do RSU (Resíduos Sólidos Urbanos). Este local é o epicentro das atividades da equipe de operação, que executa as tarefas de acordo com os critérios de engenharia e as melhores práticas operacionais. Na frente de operação, os resíduos são descarregados, distribuídos, compactados e posteriormente recobertos por uma camada de solo ou material inerte. Caracteriza-se pela sua dinâmica, alterando-se progressivamente em resposta ao contínuo ingresso de RSU. O avanço operacional, que é a expansão gradual desta frente de trabalho, ocorre dentro de uma área delimitada e licenciada, conhecida como célula. A figura subsequente ilustra a progressão da frente de operação de um aterro sanitário, comparando duas instâncias temporais com um intervalo de um mês.

Figura 1 – Avanço operacional



Fonte: Elaborado pelo autor, 2023


Para otimizar o uso do espaço em aterros sanitários, prevê-se não apenas a ocupação horizontal da célula, mas também seu desenvolvimento vertical, estratificado por camadas, que formam taludes. A figura subsequente apresenta, à esquerda, o projeto de células sanitárias e, à direita, sua execução com a formação de taludes.

Figura 2 – Células de aterro sanitário



Fonte: Elaborado pelo Autor, 2023.

Os resíduos devem ser descarregados em pilhas próximas às cristas dos taludes, na frente de operação. A partir daí, seguem-se os processos de distribuição, compactação e cobertura, com o auxílio de equipamentos apropriados, tipicamente tratores de esteiras e rolos compactadores, dedicados exclusivamente a essas funções (Lanza et al., 2006). A operação é realizada em declive, formando camadas de aproximadamente 0,6 m, com tratores percorrendo o material de 3 a 5 vezes para garantir a compactação adequada (Monteiro, 2001). O procedimento é exemplificado na figura seguinte, que ilustra o recebimento do resíduo, bem como as atividades de espalhamento e compactação.

Figura 3 – Procedimentos Operacionais

Fonte: Elaborado pelo autor, 2023.

A aplicação de uma camada de cobertura sobre os resíduos compactados é uma medida essencial, que cumpre múltiplas funções ambientais e sanitárias. Ela impede a infiltração de águas pluviais, que poderiam levar à formação de lixiviado, restringe a proliferação de vetores de doenças e aves, e atenua a emissão de odores. Conforme diretrizes técnicas, a camada de cobertura deve possuir uma espessura mínima de 20 cm e ser aplicada diariamente para assegurar sua eficácia (Monteiro, 2001).

3.1.2 Compactação

A compactação é um processo crucial na operação de aterros sanitários, pois promove a densificação dos resíduos. Uma maior densidade dos resíduos resulta na otimização do uso do espaço e na extensão da vida útil do aterro. Além disso, a compactação contribui para a estabilidade estrutural do maciço de resíduos, aumentando a segurança contra deslizamentos e permitindo a operação do aterro em alturas elevadas (Jeneivan et al., 1996). Esse processo também é eficaz em restringir a dispersão de resíduos pelo vento, limitar a migração de lixiviado e gases, e reduzir a espessura da camada de cobertura necessária (Nahas et al., 1996).

Vários fatores influenciam a eficiência da compactação, entre os quais a composição gravimétrica dos resíduos é particularmente notável (Marques, 2001). A presença de altas quantidades de materiais plásticos nos RSU, por exemplo, pode resultar em um índice de compactação reduzido (Carvalho, 1999). Outras variáveis relevantes incluem a espessura da camada de resíduos, a inclinação da superfície de operação, a umidade do resíduo, o peso e a eficiência dos equipamentos de compactação, a possibilidade de defeitos mecânicos que podem incapacitar temporariamente os equipamentos e a qualificação dos operadores.

3.1.3 Cobertura

A camada de cobertura em aterros sanitários constitui um sistema essencial cujo propósito primordial é prevenir a infiltração de líquidos no núcleo do aterro, bem como restringir a emissão de gases para a atmosfera, promovendo uma eficiente drenagem desses gases e reduzindo a formação e os custos associados ao tratamento de lixiviado (Costa, 2018). Essa camada é um elemento crucial para a operacionalidade do aterro, mitigando potenciais impactos ambientais adversos, assegurando a estabilidade do maciço de resíduos e contribuindo para a otimização do uso do espaço.

3.1.5 Custo Ambiental

A despeito de aterros sanitários serem reconhecidos como a opção mais favorável do ponto de vista ambiental para a disposição final de resíduos sólidos urbanos, sua implementação e funcionamento acarretam impactos ambientais e riscos de danos ecológicos significativos. Tais impactos incluem a supressão da cobertura vegetal e o deslocamento de espécies de fauna e flora durante a fase de implantação, a contaminação do solo resultante da deposição de resíduos, a poluição atmosférica devida

à emissão de gases de efeito estufa, e a potencial contaminação do lençol freático pelo lixiviado. Esses elementos constituem o custo ambiental associado à instalação e operação de aterros sanitários.

Figura 4 – Custo Ambiental de aterros sanitários



Fonte: Elaborado pelo autor, 2023.

Dada a magnitude desse custo ambiental, é imprescindível que a gestão de aterros sanitários adote práticas operacionais exemplares, respeitando criteriosamente os parâmetros de engenharia e conformidade ambiental, com o objetivo de maximizar a vida útil das instalações e minimizar prejuízos ecológicos. A mitigação dos impactos ambientais decorrentes da implementação e operação de aterros sanitários pode ser efetivada por meio da seleção criteriosa do local de implantação, do desenvolvimento de um projeto abrangente, da adoção de práticas operacionais de alta qualidade, da escolha de insumos apropriados, e de um monitoramento e planejamento contínuos (Boscov, 2000).

3.1.6 *Business Intelligence*

A operação de aterros sanitários engloba uma variedade de processos e atividades que produzem um volume substancial de dados. A coleta, armazenamento e processamento adequados desses dados permitem extrair informações cruciais que podem ser empregadas para otimizar a eficiência dos processos e atividades mencionados, fornecer evidências para situações específicas, prever problemas e desenvolver inovações, aprimorando, conseqüentemente, a gestão global dos resíduos sólidos urbanos. Exemplos de indicadores monitoráveis em aterros sanitários incluem:

- Volume de lixiviado gerado;
- Produção de biogás;
- Dados pluviométricos;
- Consumo de materiais;
- Eficiência operacional;
- Quantidade de resíduos recebidos;
- Progresso dos sistemas de drenagem;
- Grau de assentamento dos resíduos.


Esses indicadores de desempenho são elementos fundamentais da gestão estratégica organizacional, pois possibilitam o monitoramento contínuo e embasam o processo decisório (Silva et al., 2015). A capacidade de transformar dados em informações decisivas no contexto empresarial é conhecida como business intelligence (Noronha, 1997). Historically, business intelligence predominantly focused on historical data. However, this paradigm shifted with the advent of technologies capable of capturing, storing, and utilizing data in real time (Watson, 2009).

3.2 Inteligência Artificial

Dentro do campo acadêmico, a inteligência artificial (IA) é um conceito com múltiplas definições. Em 1987, Roger C. Schank discutiu a natureza da IA em seu artigo "*What is AI, anyway?*", explorando as diversas facetas desta tecnologia. A IA poderia ser interpretada como uma disciplina matemática, pois envolve a busca por formalismos adequados para representar conhecimento, ou como engenharia de software, na medida em que o conhecimento embutido em um programa confere-lhe um caráter de "inteligência". Alternativamente, pode ser considerada sob a óptica da linguística, dado que a programação se realiza por meio de linguagens, ou mesmo da psicologia, pois a IA busca emular os processos cognitivos humanos. Schank argumenta que a definição de IA é contextual, dependendo dos objetivos e métodos aplicados em sua construção.

IA é, portanto, a habilidade de máquinas em simular aspectos do aprendizado humano, realizando tarefas cognitivas que são tipicamente associadas à função cerebral, tais como a compreensão da linguagem, o desenvolvimento de raciocínio lógico e a interação com o mundo físico. A relevância da IA tem se ampliado consideravelmente, com o surgimento de uma vasta gama de aplicações e muitos especialistas reconhecendo esta tendência como o prelúdio de uma nova era de disrupção digital. O progresso científico e tecnológico é intrinsecamente evolutivo, utilizando as ferramentas geradas por gerações anteriores para forjar as inovações subsequentes (Ziviani, 2017). Os avanços na IA podem ser vistos como um marco significativo nessa trajetória evolutiva.


Figura 5 – Linha do Tempo, revoluções digitais



Fonte: Adaptado, Ziviane 2017.

Segundo um estudo divulgado pela Bain & Company em 2023, relativo à adoção da inteligência artificial (IA), a implementação dessa tecnologia figura como uma prioridade para 85% das 600 corporações que participaram da pesquisa. A adoção da IA nessas entidades é projetada para proporcionar um incremento de produtividade na ordem de 50%. Jeff Spiegel, diretor da BlackRock, uma gestora de ativos, estima que o mercado atual de IA está avaliado em aproximadamente 40 bilhões de dólares e poderá atingir 1,3 trilhões de dólares em uma década. A IA está se configurando como uma força disruptiva em diversos setores econômicos, como manufatura, saúde e educação, devido à sua capacidade de predição de resultados, automação de tarefas, otimização de processos e melhoria da experiência do usuário. O gráfico subsequente, extraído do relatório da McKinsey & Company de 2018, ilustra os setores que estão à frente na adoção da IA.


Figura 6 – Adoção de IA por setor



Fonte: McKinsey&Company, 2018.

Em 2019, a Comissão Europeia divulgou um relatório sobre o impacto potencial da inteligência artificial (IA) no futuro do trabalho, tanto na União Europeia quanto nos Estados Unidos. O documento incluiu uma análise da adoção da IA em diversos setores empresariais, conforme ilustrado na Figura 7.


Figura 7 – Adoção de IA por setor e força de trabalho.



Fonte: Anual business survey, 2019.

Os dados revelaram uma significativa integração de IA em setores como tecnologia, serviços financeiros e utilidades públicas. Em contraste, setores como construção civil, agricultura e gestão de resíduos demonstraram índices mais baixos de adoção tecnológica. Entretanto, o relatório de 2022 da McKinsey & Company sobre o progresso da IA destacou um aumento na adoção de ferramentas de IA pelas organizações ao longo dos últimos cinco anos.

Figura 8 – Número de recursos de IA incorporaram pelas que organizações em pelo menos uma função ou unidade de negócio.




Fonte: Mickinsey&Company, 2022.

A IA abrange um leque extenso de aplicações, incluindo processamento de linguagem natural, visão computacional, robótica e aprendizado de máquina. Essas tecnologias estão encontrando aplicabilidade em uma gama diversificada de campos e indústrias.

3.2.1 Inteligência Artificial na Gestão de Resíduos


A gestão contemporânea de resíduos enfrenta desafios que demandam novas abordagens e inovações para aprimorar sua eficiência e acelerar a transição de uma economia linear para uma economia circular. A inteligência artificial (IA) emerge como uma ferramenta promissora, com potencial para complementar e expandir as capacidades humanas. Ela facilita o aprendizado por meio de retroalimentações aceleradas, manejo eficiente de situações complexas e a extrapolação de insights a partir de vastos volumes de dados e contextos dinâmicos (Mercathur, 2019).

Algoritmos de IA interpretam o mundo por intermédio de dados. Para o processamento eficaz, esses dados devem ser coletados e formatados adequadamente, analisados e empregados no desenvolvimento e refinamento dos algoritmos fundamentais da IA, conforme ilustra a Figura 9. A geração substancial de dados em aterros sanitários representa um terreno propício para a implementação de variadas soluções tecnológicas oferecidas pela IA.

Figura 9 – Processo de algoritmos de IA.

Fonte: Ellen Marcathur Foundation, 2019.

O interesse pela adoção de IA tem se intensificado em múltiplos domínios, incluindo a gestão de resíduos sólidos urbanos. Vários setores já demonstram casos exitosos de aplicação de IA. Exemplificativamente, o setor de gestão pública em algumas regiões do Brasil tem implementado IA para a detecção de fraudes fiscais, projeção de demanda por serviços públicos e acompanhamento de indicadores socioeconômicos (Zancan et al., 2023). Outras aplicações notáveis incluem o uso de veículos aéreos não tripulados autônomos, empregando técnicas de aprendizado profundo para entregas, e o ajuste automatizado em usinas eólicas via aprendizado de máquina para otimização da geração de energia em resposta às flutuações eólicas.

Figura 10 – Espectro de aplicações de IA em diferentes setores.

Fonte: Mickinsey&Company, 2017.

No contexto específico da gestão de resíduos sólidos urbanos, a IA tem o potencial de amplificar a eficiência e a logística na coleta de resíduos, identificar e

mitigar o descarte ilegal de resíduos, otimizar a conversão de resíduos em energia via biogás, desenvolver modelos preditivos para a geração de resíduos, aprimorar processos de triagem e reciclagem, e automatizar tarefas, incrementando a eficiência operacional (Fang et al., 2023).

Adicionalmente, a IA oferece ferramentas para engajar a sociedade e promover a educação sobre economia circular e responsabilidade ambiental. Exemplos incluem o uso de chatbots e assistentes virtuais equipados com IA para disseminar conhecimento e conscientização.

3.3 Visão Computacional

Visão computacional constitui um subsetor da inteligência artificial que se ocupa da interpretação e manipulação de informações provenientes de imagens digitais adquiridas por dispositivos como câmeras, scanners e sensores diversos. Esta disciplina capacita sistemas computacionais a emular funcionalidades análogas à visão biológica humana, executando tarefas complexas que requerem percepção visual inteligente (Milano, 2014).

O aprendizado de máquina (*machine learning*) desempenha um papel fundamental na implementação da visão computacional. Esta vertente de IA emprega modelos algorítmicos que, após o treinamento com conjuntos de dados robustos, adquirem a capacidade de identificar padrões, realizar inferências preditivas, formular recomendações e ajustar-se incrementalmente a partir de novas informações e interações (McKinsey & Company, 2023).

3.3.1 Deep Learning

Deep learning, uma subcategoria do *machine learning*, permite o processamento autônomo de vastas quantidades de dados com mínima intervenção humana, destacando-se por sua capacidade de gerar resultados de alta precisão. Esta metodologia avançada é caracterizada por uma arquitetura de múltiplas camadas que facilita o aprendizado hierárquico de representações de dados, sendo aplicada com êxito em diversos ramos da inteligência artificial, como processamento de linguagem natural, análise semântica e visão computacional (Guo, 2016).

Na visão computacional, especificamente, *deep learning* é utilizado para tarefas como classificação de imagens, detecção de objetos e segmentação semântica. A abordagem emprega redes neurais artificiais, que visam emular o processo de interação neuronal no cérebro humano, processando dados através de uma série de camadas intermediárias. Essa técnica permite que modelos computacionais construam conceitos complexos a partir de elementos mais simples, formando representações abstratas a partir de características primitivas como bordas e contornos (Bengio et al., 2015).

Os algoritmos de *deep learning* são particularmente úteis em contextos de alta complexidade e volumosos conjuntos de dados, simulando a configuração e funcionamento de uma rede neural biológica para descobrir padrões em distribuições complexas de dados (Gu et al., 2018). Em termos computacionais, redes neurais são modelos matemáticos compostos por múltiplas camadas de unidades de processamento, onde os dados, ao transitarem por estas unidades, são transformados por pesos sinápticos e vieses ajustáveis.

3.3.2 Redes Neurais Convolucionais (CNNs)


Redes neurais convolucionais são uma aplicação de deep learning, dentro da visão computacional, para execução de tarefas perceptivas, como identificação de objetos em imagens, CNNs são capazes de aplicar filtros em dados visuais, mantendo uma relação de vizinhança entre pixels ao longo do processamento da rede (Vargas

et al, 2020), a rede neural utiliza múltiplas camadas de processamento para estabelecer padrões e estruturar um conjunto de dados, onde cada camada aprende um conceito das camadas subsequentes, quanto maior o nível, mais abstratos serão os conceitos aprendidos.

A unidade básica de processamento da rede neural, o neurônio artificial, é chamado de perceptron, estão conectados por canais de comunicação associados a pesos, a característica de inteligência da rede neural é atribuída as interações dos perceptrons na rede. Segundo McCulloch e Pitts, a operação do perceptron ocorre em etapas, com o neurônio artificial possuindo função de decisão ($\phi(z)$), combinado aos sinais de entrada (x), e o vetor de pesos sinápticos correspondente w , sendo z a soma ponderada dos sinais que produz um nível de atividade.


$$z = w_1x_1 + w_2x_2 + \dots + w_n x_n$$

$$w = \begin{bmatrix} w_1 \\ \cdot \\ \cdot \\ \cdot \\ w_n \end{bmatrix} \quad x = \begin{bmatrix} x_1 \\ \cdot \\ \cdot \\ \cdot \\ x_n \end{bmatrix}$$

Figura 11 – Entrada e saída do perceptron

Fonte: GFT, Neurônios artificiais, 2022.

A arquitetura de uma CNN é hierarquicamente estruturada em múltiplas camadas que incluem uma camada de entrada, várias camadas intermediárias (também conhecidas como camadas ocultas), e uma camada de saída. A camada de entrada é responsável por receber os dados brutos, enquanto as camadas ocultas são compostas por uma série de camadas convolucionais, camadas de agrupamento (*pooling layers*), camadas de normalização e camadas totalmente conectadas (*fully connected layers*), que transformam os dados de entrada em representações mais abstratas e úteis. Finalmente, a camada de saída fornece a predição ou classificação final do modelo. A aprendizagem da rede é conduzida pela retro propagação (*backpropagation*), um algoritmo que ajusta os pesos sinápticos das conexões em resposta ao erro obtido na saída da rede, minimizando uma função de custo predeterminada ao longo de múltiplas iterações de treinamento.

Figura 12 – Organização da rede neural


Fonte: Gu, Deep Learning, 2018.

A convolução é uma operação matemática fundamental no contexto de redes neurais convolucionais, envolvendo duas funções, $f(x)$ e $g(x)$, que resulta em uma terceira função expressando a forma como uma é modificada pela outra. No domínio das CNNs, essa operação é utilizada para a extração de características essenciais das entradas, como bordas e texturas. A operação de convolução pode ser descrita pela seguinte equação integral para o caso contínuo:

$$f(x) * g(x) = \int_{-\infty}^{\infty} f(\tau) \cdot g(x - \tau) d\tau$$

onde f e g representam as funções a serem convoluídas e τ é a variável independente.

Além das camadas convolucionais, as redes neurais convolucionais incluem camadas de agrupamento, conhecidas como 'pooling layers', que têm o propósito de reduzir a dimensionalidade dos dados processados. Isso contribui para a redução da complexidade computacional e previne o sobreajuste, melhorando assim a eficiência e a generalização do modelo durante o treinamento.

Figura 13 – Camadas da CNN

Fonte: Vargas, 2020.

Ao processar uma imagem, por exemplo, de um caractere tipográfico como a letra 'A', a rede neural convolucional processa inicialmente a representação pixelizada da imagem. Nas camadas intermediárias, a rede identifica e aprende características discriminativas, como arestas e curvas, que são intrínsecas ao caractere. Com base nessas características aprendidas, a CNN é capaz de reconhecer a letra 'A' em diferentes contextos e variações. As redes neurais convolucionais, apesar de serem uma inovação comparativamente recente em aprendizado de máquina, têm estabelecido padrões de excelência em tarefas de visão computacional, atingindo, em determinadas aplicações, desempenhos que são considerados estado da arte.

3.3.3 Mask R-CNN

Mask R-CNN constitui uma arquitetura de rede neural convolucional, capaz de prever uma máscara de segmentação pixel a pixel, representando uma extensão intuitiva de Faster R-CNN. Mask R-CNN é uma rede neural convolucional, capaz de gerar resultados no estado da arte, em termos de segmentação. Essa variante de redes neurais profundas, detectam objetos em imagens e gera máscaras de segmentação de alta qualidade para cada instância (Odemakinde, 2022).

4. Metodologia

Para alcançar os objetivos propostos neste trabalho, que consiste no desenvolvimento de uma aplicação de Inteligência Artificial (IA) para a gestão e monitoramento de aterros sanitários, optou-se pelo uso de imagens oriundas de Veículo Aéreo Não Tripulado (VANT) pertencentes à empresa administradora do aterro sanitário. Selecionaram-se imagens capturadas especificamente da frente de operação do aterro sanitário, o foco deste estudo. Essas imagens foram empregadas na constituição do banco de dados necessário para o treinamento da rede neural. No total, 30 imagens foram utilizadas para o treinamento e a validação, com uma distribuição de 80% para o treinamento e 20% para a validação. A escolha de utilizar o mesmo conjunto de dados para treinamento e validação justifica-se pela limitação no volume de imagens disponíveis (Leite, 2020).

Figura 14 – Banco de dados de imagens

Nome	Tamanho	Comprimido	Tipo
..			Pasta de arquivos
DJI_0042.JPG	8.317.043	8.318.313	Arquivo JPG
DJI_0043.JPG	8.250.814	8.252.074	Arquivo JPG
DJI_0095.JPG	8.411.541	8.412.826	Arquivo JPG
DJI_0098.JPG	8.485.234	8.486.529	Arquivo JPG
DJI_0160.JPG	8.644.739	8.646.059	Arquivo JPG
DJI_0201.JPG	8.154.717	8.155.962	Arquivo JPG
DJI_0212.JPG	8.757.635	8.758.975	Arquivo JPG
DJI_0217.JPG	8.210.554	8.211.809	Arquivo JPG
DJI_0218.JPG	8.195.518	8.196.773	Arquivo JPG
DJI_0220.JPG	8.655.648	8.656.973	Arquivo JPG
DJI_0269.JPG	8.440.939	8.442.229	Arquivo JPG
DJI_0273.JPG	8.401.444	8.402.729	Arquivo JPG
DJI_0279.JPG	8.863.860	8.865.215	Arquivo JPG
DJI_0280.JPG	8.886.160	8.887.520	Arquivo JPG
DJI_0281.JPG	8.641.223	8.642.543	Arquivo JPG
DJI_0768.JPG	8.990.577	8.991.952	Arquivo JPG

Fonte: Elaborado pelo autor.

O VANT utilizado é do modelo DJI Phantom 3 Professional, realizando voos a uma altitude de 30 a 40 metros, e está equipado com uma câmera Sony Exmor de 1/2.3 polegadas.

Figura 15 – VANT utilizado.




Fonte: Angar, 2022.


O algoritmo de IA foi desenvolvido na plataforma Colab Notebook, um ambiente de programação fornecido pela Google, utilizando a linguagem de programação Python. A plataforma foi empregada tanto para a criação das regiões de interesse utilizadas nos treinamentos quanto para a construção da rede neural com o auxílio do TensorFlow. O processo de treinamento foi executado ao longo de 30 épocas.

5. Resultados

A rede neural desenvolvida visa identificar resíduo exposto na frente de operação de aterros sanitários, aplicando uma máscara colorida sobre o resíduo. As imagens subsequentes ilustram os resultados alcançados.

Figura 16 – Resultados da aplicação da rede neural






Fonte: Elaborado pelo autor.

Observou-se que a rede neural apresenta variações em seu desempenho conforme a qualidade da imagem, ângulo, luminosidade e características do resíduo exposto. As figuras subsequentes exibem exemplos de imprecisões: a rede neural não foi capaz de identificar a totalidade do resíduo exposto em algumas imagens e/ou reconheceu objetos diversos como resíduos. Estas imprecisões são atribuídas à limitada dimensão do banco de dados empregado. Ampliar a base de dados utilizada para treinamento tende a aumentar a capacidade de generalização da rede neural.

Figura 17 – Erros de identificação




Fonte: Elaborado pelo autor.

6. Método para estimar o avanço operacional

Para estimar o avanço operacional, é imprescindível estabelecer um período de monitoramento da frente de operação, com o Veículo Aéreo Não Tripulado (VANT) realizando registros fotográficos diários durante o período estipulado. É necessário criar um procedimento operacional padrão para garantir a eficácia do método. O registro fotográfico deve ser efetuado diariamente em um horário fixo, e é fundamental

que o ângulo da imagem, a altura do voo e a posição se mantenham inalterados, com o perímetro de monitoramento constante.


Figura 18 – Procedimento de monitoramento



Fonte: Elaborado pelo autor, 2023.

No que concerne à computação, para a estimativa do avanço operacional, será empregado o operador lógico XOR, que avalia duas condições mutuamente exclusivas e indica se uma delas é satisfeita.

Figura 19 – Operador lógico



Fonte: Elaborado pelo autor, 2023.

Considere as imagens subsequentes como registros fotográficos obtidos por VANT, com a segmentação de imagem realizada pela inteligência artificial, em dias consecutivos. A área destacada em amarelo corresponde ao resíduo exposto.

Figura 20 – Frente de Operação, dia 1



Fonte: Elaborado pelo autor, 2023.

Figura 21 – Frente de operação, dia 2



Fonte: Elaborado pelo autor, 2023.

Entre o dia 1 e o dia 2, observou-se um aumento na área de resíduo exposto, indicado pela coloração amarela, devido à disposição de novos resíduos. Para estimar o incremento, as imagens serão sobrepostas e a região comum será eliminada. Após esse processo, a área remanescente corresponderá ao avanço operacional entre os dois dias.

Figura 22 – Avanço operacional



Fonte: Elaborado pelo autor, 2023.

Entre o dia 1 e o dia 2, observou-se um aumento na área de resíduo exposto, indicado pela coloração amarela, devido à disposição de novos resíduos. Para estimar o incremento, as imagens serão sobrepostas e a região comum será eliminada. Após esse processo, a área remanescente corresponderá ao avanço operacional entre os dois dias.

7. Viabilidade do Método

Devido a questões de procedimento operacional da empresa administradora do aterro sanitário, não havia fotos de dias subsequentes, apenas imagens com intervalos de tempo mensais. Essa limitação inviabiliza a aplicação do método proposto, dada a frequência de cobertura dos resíduos. O método, se devidamente aplicado, oferece benefícios como maior controle da frente de operação, podendo servir como um indicador da qualidade da compactação. Por exemplo, um aumento na velocidade média de avanço operacional diário, sem alteração do volume de resíduos recebidos, pode sugerir, entre outros fatores, uma compactação ineficiente, indicando

que os resíduos estariam sendo apenas espalhados e cobertos. Um controle mais efetivo da frente de operação implica em melhor gerenciamento do espaço destinado à disposição de resíduos, garantindo a otimização operacional do aterro sanitário e evitando o desmatamento desnecessário de novas áreas florestais para a implantação de novos aterros.

A exposição de resíduos contribui para o aumento na geração de chorume, devido à ausência de cobertura, facilitando a infiltração de águas pluviais; reduz a eficiência da captação de biogás, com o incremento dos níveis de oxigênio no maciço; diminui a eficiência operacional, com o acúmulo de água e degradação dos resíduos, resultando em maior consumo de diesel pelos tratores e ineficácia na compactação; além de fomentar a proliferação de insetos e o contato de animais silvestres com o resíduo exposto. Portanto, a importância do controle e do monitoramento da frente de operação de aterros sanitários é evidente.

Adicionalmente, a ferramenta proposta oferece a vantagem da rapidez na obtenção de informações, uma vez que o processo é executado por IA, sem necessidade de intervenção humana; permite a identificação da área exposta e a documentação da evolução da frente de operação, contribuindo para uma compreensão aprimorada das operações do aterro sanitário e possibilitando a análise de situações passíveis de revisão em contextos futuros; e destaca-se pelo baixo custo, além da facilidade e praticidade de uso.

Contudo, o método, tal como apresentado neste estudo, enfrenta desafios significativos, tais como a necessidade de generalização da IA, que demanda um banco de dados mais abrangente e um número maior de ciclos de treinamento, a aplicação de técnicas para avaliar a qualidade da IA, o desenvolvimento e implementação de um procedimento operacional padrão, definição de um cronograma de monitoramento e treinamento para o operador do VANT.

8. Considerações finais

Neste trabalho, apresentou-se uma solução de aplicação de IA para aterros sanitários, visando monitorar o avanço operacional e contribuir para aumentar a eficiência na gestão resíduos sólidos urbanos. Para tanto, foram utilizadas técnicas de

deep learning e redes neurais convolucionais para identificar objetos em imagens e propor um método para a estimativa do avanço da frente de operação.

Os desafios citados na seção anterior podem ser explorados em trabalhos futuros. É possível enriquecer o banco de dados com a aquisição de novas imagens e pela aplicação de técnicas de aumento de dados (*data augmentation*). A quantidade de épocas de treinamento pode ser incrementada com o acesso a recursos computacionais mais avançados, como o *Colab Pro* e unidades de processamento de alto desempenho. O método utilizado para estimar o avanço operacional pode ser aperfeiçoado com a adoção de técnicas mais sofisticadas e adequadas ao propósito.

A área de visão computacional é um campo vasto, que abrange uma variedade de possibilidades de aplicações dentro da gestão de resíduos, não se limitando apenas às redes neurais convolucionais. A integração da IA com outras tecnologias, como a Internet das Coisas (IoT), também representa um caminho promissor. Ademais, outras vertentes da IA podem ser exploradas no desenvolvimento de soluções pertinentes para a área de gestão de resíduos sólidos urbanos.

REFERÊNCIAS

MICKINSEY&COMPANY. **Artificial intelligence: Construction technology's next frontier**. 2018.

ABRELPE. Associação de empresas de limpeza pública e resíduos especiais **Panorama dos resíduos sólidos no Brasil**. 2022.

MINISTERIO DO MEIO AMBIENTE, Secretaria de qualidade ambiental. **Plano nacional de resíduos sólidos**. 2022.

VASQUES, E.I. **What a waste 2.0, a global snapshot of solid waste management to 2050**. 2018, p.11.

WORLD BANK GROUP. **What a waste 2.0, a global snapshot of solid waste management to 2050**. 2018.

ABAR. Associação Brasileira de agências reguladoras. **O papel das agências reguladoras na implementação do novo marco legal de saneamento básico em relação aos serviços de limpeza urbana e manejo de resíduos sólidos**. 2021.

ABNT – ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. NBR 8419. **Apresentação de projetos de aterros sanitários de resíduos sólidos urbanos**. 1992.

NASCIMENTO, V.F; SOBRAL, A.C; ANDRADE, P.R; OMETTO, J.P.H.B. **Evolução e desafios no gerenciamento de resíduos sólidos urbanos no Brasil**. 2015

GRISA, DANIELA CRISTINA. **Resíduos Sólidos urbanos, visão 2035: Agendas setoriais para o desenvolvimento**. 2022.

MORAIS, G.L. **Estudo das restrições à implantação de aterros sanitários no cone leste paulista: Uma análise das áreas de recarga de aquíferos**. 2018.

OBLADEN, N.L; OBLADEN, N.T.R; BARROS, K.R. **Guia para elaboração de projetos de aterros sanitários para resíduos sólidos urbanos**. 2022.

GUDJÃO, R.I.L; NETO, C.L.A; PAIVA, W. Avaliação do tempo de vida útil do aterro sanitário de Campina Grande - PB. **Congresso Nacional de Pesquisa e Ensino em Ciências**. 2017.

VARVEKOVÁ, M.D. **Landfill impacts on the environment – Review**. 2019.

CONDE, T.T; STACHIW, R. FERREIRA, E. Aterro sanitário como alternativa para preservação ambiental. **Revista Brasileira de ciências da Amazônia**. V.3, n.1, p.69-80. 2014.

SILVA, W.O.B. **Aterros Sanitários e os resíduos sólidos**.2020.

LANZA, V.C.V; CARVALHO, A.L. **Orientações básicas para operação de aterros sanitários**. Belo Horizonte, 2006.

UNESCO. Artificial Intelligence for sustainable development. **Mobile learning week 2019**. 2019.

VINUESSA, R; AZIZPOUR, H; LEITE, I; BALAAM, M; DIGNUM, V. DOMISCH, S; FELLANDER, A; LANGHANS, S; TEGMARK, M; NERINI, F.F. **The role of artificial intelligence in achieving the sustainable development goals**. 2020.

SANTOS, T.T; BARBETO, J.G.A; TERNES, S; NETO, J.C; KOENIGKAN, L.V; SOUZA, K.X.S. **Visão computacional aplicada na agricultura**. 2020.

VARGAS, A.C.G; PAES, A; VASCONCELOS, C.N. **Estudo sobre redes neurais convolucionais e sua aplicação em detecção de pedestres**. 2017.

MICKINSEY&COMPANY. **The state of IA in 2023. Generative IA's breakout year**. 2023.

MICKINSEY&COMPANY. **The state of IA in 2022 and a half decade in review**. 2022.

MICKINSEY&COMPANY. **Artificial intelligence the next digital frontier**. 2017.

SCHANK, R.C. **What is AI, anyway?**. AI magazine, v.8, n.4. 1987.

MICKINSEY&COMPANY. **What is AI?**. 2023.

ZAVIANI, N. Dialogo. **Revista Fonte, tecnologia e inovação na gestão pública**. São Paulo, v.14, n.17, p.6, jul. 2017.

ELLEN MACARTHUR FOUNDATION. **Artificial intelligence and the circular economy - AI as a tool to accelerate the transition**. 2019.

FANG, B; YU, J; CHEN, Z; OSMAN, A; FARGHALI, M; IHARA, I; HAMZA, E; ROONEY, D.W; YAP, P.S. **Artificial intelligence for waste management in smart cities: a review**. 2023.

MILANO, D; HONORATO, L.B. Visão Computacional. São Paulo. 2010.

BENGIO, Y. GOODFELLOW, I; COURVILLE, A. **Deep Learning**. 2015.

GU, D, SHEN, J; WANG, X. **Deep learning, Project report**. 2018.