

DOI: 10.47094/COBRAMSEG2024/110

# O papel da Inteligência Artificial no preenchimento de lacunas deixadas pela pandemia COVID-19 no monitoramento dos Resíduos Sólidos Urbanos

Igor Pinhal Luqueci Thomaz

Pesquisador, COPPE/UFRJ, Rio de Janeiro, Brasil, pinhal@coc.ufrj.br

Claudio Fernando Mahler

Professor, COPPE/UFRJ, Rio de Janeiro, Brasil, mahler@coc.ufrj.br

**RESUMO:** O dimensionamento e estimativa da vida útil dos aterros sanitários municipais depende de um monitoramento contínuo dos Resíduos Sólidos Urbanos (RSU) produzidos pela população. A amostragem dos RSU é tradicionalmente realizada in loco, por profissionais especializados, que ficam expostos a riscos físicos e químicos. Contudo, uma das medidas governamentais adotadas para lidar com a pandemia COVID-19 foi a determinação de quarentenas obrigatórias. Tais quarentenas, executadas no intuito de reduzir expressivo número de infecções e óbitos, deixaram lacunas de informações no monitoramento dos RSU gerados em uma importante capital do Brasil. Dentro de tal contexto, este trabalho propõe o uso da Inteligência Artificial (IA) para preencher as lacunas de informações deixadas durante o período de quarentena obrigatória, visto que não é possível realizar amostragens físicas retroativamente. Os modelos de IA foram alimentados por conjuntos de dados socioeconômicos e revelaram previsibilidade das propriedades físicas dos RSU produzidos na cidade.

**PALAVRAS-CHAVE:** Resíduos Sólidos Urbanos; Inteligência Artificial; dados socioeconômicos; propriedades físicas; aterros sanitários; pandemia.

**ABSTRACT:** The sizing and estimation of the useful life of municipal landfills depends on continuous monitoring of Urban Solid Waste (MSW) produced by the population. MSW sampling is traditionally carried out on site, by specialized professionals, who are exposed to physical and chemical risks. However, one of the government measures adopted to deal with the COVID-19 pandemic was the determination of mandatory quarantines. Such quarantines, carried out with the aim of reducing a significant number of infections and deaths, left information gaps in the monitoring of MSW generated in an important capital of Brazil. Within this context, this work proposes the use of Artificial Intelligence (AI) to fill the information gaps left during the mandatory quarantine period, as it is not possible to carry out physical sampling retroactively. The AI models were fed by socioeconomic datasets and revealed predictability of the physical properties of MSW produced in the city.

**KEYWORDS:** Urban solid waste; Artificial intelligence; socioeconomic data; physical properties; landfills; pandemic.

## 1 INTRODUÇÃO

A problemática dos resíduos é tão antiga quanto a própria humanidade. Desde que a espécie humana, originalmente caçadora-coletora, começou a formar os primeiros aglomerados urbanos e, posteriormente, as primeiras cidades, o lixo produzido tornou-se uma preocupação, em virtude dos problemas relacionados à saúde pública e ao meio ambiente (Mahler et al., 2020).

A caracterização contínua dos Resíduos Sólidos Urbanos (RSU), promovida pela administração pública, permite o melhor conhecimento dos resíduos produzidos, possibilitando que sua destinação respeite parâmetros técnicos, econômicos e ambientais. A amostragem dos RSU é tradicionalmente realizada in loco, demanda emprego de pessoal especializado, consome quantidade significativa de tempo e recursos financeiros, e requer atenção constante na gestão dos riscos ocupacionais (Thomaz et al., 2023). Mas a pandemia da COVID-19 mudou o mundo, provocando transformações na economia, no emprego e na vida cotidiana (Ikiz et al., 2021). As preocupações com os riscos de contaminação de resíduos sólidos aumentaram, principalmente quanto aos resíduos infectados com agentes virulentos (Penteado e Castro, 2021).

Na prática, as medidas restritivas, como quarentenas, tão valiosas para proteger a sociedade, resultaram em detrimento ao monitoramento contínuo dos resíduos sólidos de alguns municípios, causando lacunas nos bancos de informações sobre os RSU coletados, conforme pode ser exemplificado pelo trecho de um documento oficial do Município do Rio de Janeiro (IPP, 2023a): “(...) *Devido a pandemia, a caracterização completa dos resíduos não foi realizada para o ano de 2020, portanto as informações não foram discriminadas por Área de Planejamento (...)*”.

Naquela conjuntura, em que as limitações impostas pela pandemia de COVID-19 tiveram de ser respeitadas, e era simultaneamente obrigatório manter um nível mínimo de qualidade na gestão de resíduos, houve um maior incentivo para adotar métodos alternativos e seguros para monitorar os resíduos produzidos, de tal modo que modelos preditivos utilizando Inteligência Artificial, como Redes Neurais Artificiais (RNA), ganharam visibilidade e importância (Adeleke et al., 2021; Andeobu et al., 2022).

De acordo com UNEP et al. (2024), é cada vez mais expressivo o uso da Inteligência Artificial para prever a composição gravimétrica dos resíduos (Thomaz et al., 2023), identificar e classificar os resíduos (Moore, 2023), reduzir o desperdício e a perda de alimentos (Onyeaka et al., 2023; Said et al., 2023) e prever focos de poluição por resíduos em ambientes marinhos (Fazri et al., 2023; Seyyedi et al., 2023).

Diante do exposto, o trabalho proposto engloba uma conjuntura em que a Inteligência Artificial pode ser valiosa à gestão de Resíduos Sólidos, tanto em cenários pandêmicos, nos quais é imperioso evitar o manuseio dos resíduos, quanto na realidade pós-pandemia, quando se faz necessário o preenchimento das lacunas de informação provocadas pela aplicação de medidas restritivas, como quarentenas, que afetaram a normalidade da gestão.

## 2 METODOLOGIA

Para selecionar modelos e conjuntos de dados apropriados, foi realizada uma revisão da literatura, a partir da qual se concluiu que as propriedades dos RSU são influenciadas por indicadores como: renda; PIB; nível educacional; tamanho das famílias; faixa etária familiar; acesso a assistência médica; acesso a eletricidade, abastecimento de água potável e sistema de saneamento; e quantitativo populacional (Vazquez et al., 2020; Ghanbari et al., 2021; Noman et al., 2023; Thomaz et al., 2023).

Portanto, a adoção de Inteligência Artificial para a previsão da composição gravimétrica dos RSU, pode se valer do fato de haver uma íntima associação entre propriedades dos RSU e fatores socioeconômicos da região paradigma. Dentre as soluções disponíveis, as RNA apresentam uma opção viável. No campo da gestão de resíduos, modelos RNA foram desenvolvidos para monitorar a geração e características dos resíduos, como composição gravimétrica, poder calorífico, resistência ao cisalhamento, peso específico, teor de umidade e potencial de geração de gás (Donevska, 2020; Adeleke et al., 2021; Bai et al., 2022; Thomaz et al., 2023).

As RNA adotadas neste estudo são modelos computacionais capazes de simular o comportamento do cérebro animal, que é um órgão apto a aprender sem conhecer o algoritmo que produz o problema, capaz de generalizar e robusto. O uso de RNA permite a compreensão de fenômenos complexos, bem como possibilita a estimativa de variáveis dependentes fazendo uso de outras mais acessíveis (Thomaz et al., 2023), devido à sua grande capacidade de autoaprendizagem e excelente precisão na resolução de interações não lineares complexas sem regras matemáticas complicadas (Shekoohiyan et al., 2023).

### 2.1 Área de Estudo

A área de estudo escolhida para validar o modelo foi o Município do Rio de Janeiro, capital do Estado de mesmo nome, localizado na região Sudeste do Brasil. Além de ser um dos principais centros econômicos e financeiros do país, o Rio de Janeiro é conhecido internacionalmente por seus atrativos culturais e paisagísticos.

Nas últimas cinco décadas, a população do Município do Rio de Janeiro cresceu de aproximadamente 4 milhões para pouco mais de 6 milhões, representando um aumento de mais de 40%. Porém, o crescimento percentual entre 2000 e 2022 foi de apenas 6%, marcado por períodos de declínio populacional entre os anos de 2006 e 2007, e entre os anos de 2021 e 2022. (IBGE, 2023c).

A coleta de RSU no Município do Rio de Janeiro é realizada pela Companhia Municipal de Limpeza Urbana (COMLURB), que disponibiliza os dados referentes à coleta e destinação dos RSU. Apesar dos dados sobre resíduos sólidos partirem, em sua maioria, de uma mesma fonte, foi necessário estabelecer um tratamento para que ficassem homogêneos dentro dos mesmos parâmetros. A partir do ano 2003 a fração “rejeitos” ficou mais detalhada, com a inclusão das subfrações de “Coco”, “Vela/parafina” e “Eletro/Eletrônico”. Porém,

optou-se por trabalhar a parcela rejeitos sob uma forma condensada, diferentemente do que foi feito com a parcela recicláveis, que foi detalhada por suas subfrações: Papel/Papelão, Plástico, Vidro e Metal. (IPP, 2023a).

Em termos econômicos, o PIB da cidade do Rio de Janeiro apresentou tendência de crescimento na maior parte dos anos no período entre 2004 e 2020, com notável aumento durante os anos de 2010 a 2013 em que o crescimento mínimo anual ultrapassou os 10%. Porém, a partir de 2018, quando o PIB atingiu seu ápice, iniciou-se um declínio com queda de 2,33% registrada entre os anos de 2018 e 2019, e queda ainda maior de 6,66% registrada entre os anos de 2019 e 2020 (IBGE, 2023a, 2023b).

O abastecimento de água potável na cidade do Rio de Janeiro é caracterizado por alta cobertura e taxa de atendimento da população que ultrapassa os 90% desde 2004. A rede de abastecimento cresceu aproximadamente 16% no período entre 2000 e 2021, atingindo 10.874 km de extensão (SNIS, 2023a).

Ao mesmo tempo, o volume total consumido de água tratada variou entre 405 e 777 milhões de m<sup>3</sup>, registrado nos anos de 2020 e 2018, respectivamente (SNIS, 2023b).

Em relação aos dados coletados sobre o sistema de saneamento para o período de 2000 a 2021, houve um declínio perceptível no atendimento à população, entre 2000 a 2009. Este período foi caracterizado por uma diminuição de 91,2% no ano de 2000 para 68,7% no ano 2009, seguida de uma melhoria que elevou a taxa de atendimento para 80,9% em 2013 e voltou ao patamar de 90% em 2021 (SNIS, 2023c).

## 2.2 Ferramenta Computacional

Os dados sobre a população estudada e RSU produzidos foram agrupados em planilhas, que foram cruzadas, tratadas, processadas e transformadas em um banco de informações detalhadas, utilizadas para montar conjuntos “entradas – alvos” compatíveis com os softwares utilizados ao longo da pesquisa.

O *software* MATLAB foi selecionado para programar as RNA, por ter apresentado a melhor performance dentre outros programas testados. Uma das vantagens dos MATLAB é a Toolbox incorporada ao ambiente de trabalho, que permite o monitoramento em tempo real do aprendizado da rede (figura 1), possibilitando cancelar, reconfigurar, alterar os hiperparâmetros e reiniciar o processo a qualquer momento. A avaliação preliminar do desempenho do treinamento da RNA também pode ser realizada através de um gráfico dos valores do erro quadrático médio (MSE) em relação ao número de épocas de treinamento. A métrica MSE enfatiza erros maiores, elevando ao quadrado cada erro individual antes de calcular a média desses erros quadrados.

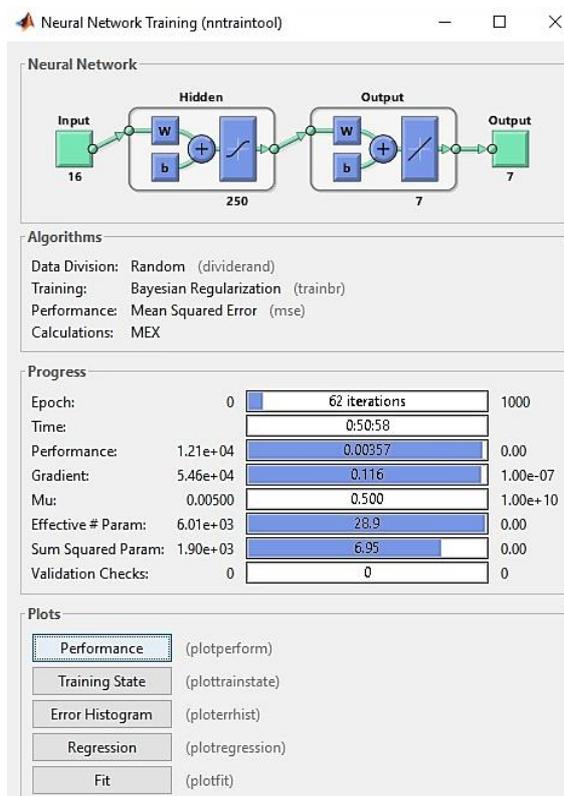


Figura 1. Monitoramento em tempo real do aprendizado em rede. Fonte: Autor.

O número de camadas ocultas do script foi escolhido de acordo com método empírico proposto por Beale et al. (2022), adequando-se o número de camadas ocultas ao passo em que os resultados se tornaram apropriados, evitando-se excessivas camadas, que poderiam provocar problema de sobreajuste (overfitting), prejudicando o processo de generalização.

Foram iniciados testes com 10 camadas ocultas, tendo o número de camadas sido aumentado até o patamar das 1000 camadas. As simulações realizadas com mais de 500 camadas exigiram um esforço computacional bastante grande, mas o desempenho dos resultados não acompanhou o acréscimo de camadas. As representações gráficas regression (Figura 2) e performance (Figura 3) podem ser visualizadas a seguir.

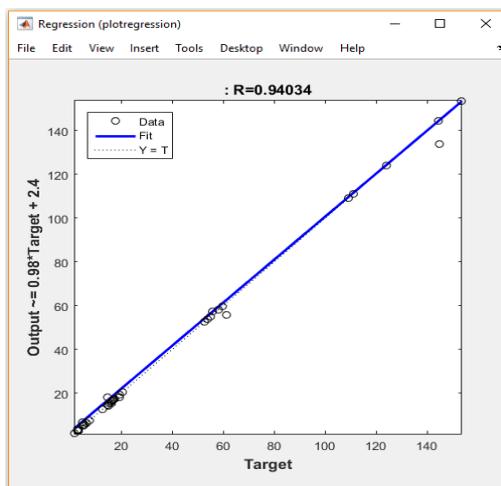


Figura 2. Representação gráfica regression. Fonte: Autor.

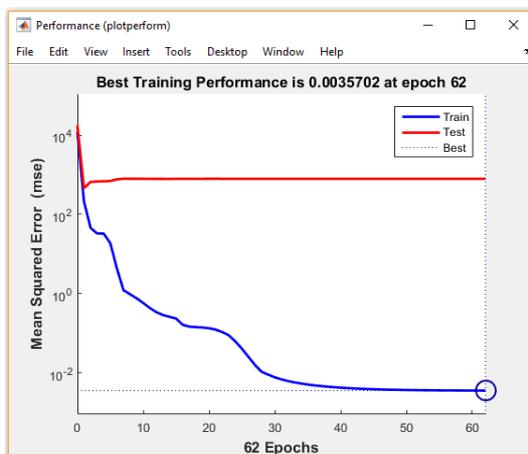


Figura 3. Representação gráfica performance. Fonte: Autor.

### 3 RESULTADOS E DISCUSSÃO

#### 3.1 Previsão de Composição Gravimétrica

Para atingir o objetivo proposto, o modelo computacional foi alimentado por conjuntos de dados representativos do Município do Rio de Janeiro, considerando a íntima associação entre propriedades dos RSU e fatores socioeconômicos da região paradigma (Vazquez et al., 2020; Ghanbari et al., 2021; Noman et al., 2023; Thomaz et al., 2023).

O conjunto de entradas consiste na combinação de dados quantitativos da população, Produto Interno Bruto (PIB), abastecimento de água potável e dados do sistema de saneamento, consolidados a partir de IBGE (2023a, 2023b e 2023c), IPP (2023a e 2023b) e SNIS (2023a, 2023b e 2023c), conforme tabela 1.

Tabela 1 - Informações de entrada relacionadas ao algoritmo desenvolvido em MATLAB para previsão de Composição Gravimétrica do Município do Rio de Janeiro. Fonte: Consolidado pelo autor a partir de IBGE (2023a, 2023b e 2023c) e SNIS (2023a, 2023b e 2023c).

Ano		2015	2016	2017	2018	2019	2020	
Entradas	PIB preço corrente (em milhões R\$)	320187	328440	337675	363403	354933	331280	
	População (habitantes)	6476631	6498837	6520266	6688927	6718903	6747815	
	Abastecimento de Água Potável	Quantidade de ligações ativas de água	1067360	1073813	1077384	1086868	1357211	1407758
		Quantidade de economias ativas	2396224	2423676	2433242	2450920	2613356	2715431
		Extensão da rede (km)	10353	10891	10710	10737	10839	10851
		Produção em ETA e/ou Importada (m³)	1087094	1087546	1086049	1102521	1111972	1106319
		Medição por hidrômetros (m³)	425276	429917	431846	434983	358579	260388
		Consumo efetivo (m³)	760232	768528	771976	777585	527345	405461
	Sistema de esgotamento	Percentual de população atendida (%)	83,08	85,16	85,98	85,10	86,27	87,95
		Quantidade de ligações ativas	796590	819368	832277	847533	965444	879016
		Quantidade de economias ativas	1781002	1817185	1839249	1869049	2124514	2177739
		Volume coletado (1.000 m3/ano)	455815	449064	449781	455923	427368	393234
		Volume tratado (1.000 m3/ano)	338009	342100	355103	333335	346019	341557
		Extensão da Rede de Esgoto (Km)	6254	6665	6428	6556	6766	6926

### 3.1.1. Procedimento de validação utilizando valores de referência do ano 2015

A fim de verificar a validade do modelo proposto para as previsões de composição gravimétrica de RSU, foram feitas simulações utilizando alvos conhecidos para o cenário do Município do Rio de Janeiro. A primeira validação ocorreu para alvos do ano 2015, conforme evidenciado na tabela 2.

Tabela 2 - Informações de alvos relacionados ao algoritmo desenvolvido em MATLAB para previsão de Composição Gravimétrica do Município do Rio de Janeiro. Fonte: Consolidado pelo autor, com referências de IPP (2023a e 2023b).

Ano		2015	2016	2017	2018	2019	2020
Composição gravimétrica RSU domiciliar	Papel - Papelão (%)	Alvo $\neq$	14,82	14,70	14,31	14,63	11,17
	Plástico (%)	Alvo $\neq$	20,24	24,66	15,33	15,72	15,69
	Vidro (%)	Alvo $\neq$	3,55	3,46	3,48	3,58	4,37
	Metal (%)	Alvo $\neq$	1,65	1,51	1,81	1,75	1,51
	Outros (%)	Alvo $\neq$	6,51	6,46	14,56	16,99	20,48
	Matéria Orgânica (%)	Alvo $\neq$	53,23	49,21	50,51	47,33	46,78

Os resultados das previsões para o ano 2015 podem ser observados na tabela 3, a seguir, que evidencia as diferenças entre os valores de referência e os valores estimados pelo modelo.

Tabela 3 - Informações de referências e saídas relacionadas ao algoritmo desenvolvido em MATLAB para previsão de Composição Gravimétrica do Município do Rio de Janeiro. Fonte: Consolidado pelo autor, com referências de IPP (2023a e 2023b).

ID: #2015	Composição gravimétrica	Valores de Referência	Valores Estimados	Erros	
				Absoluto	Relativo
	Papel - Papelão	15,14%	15,88%	-0,7370	-4,87%
	Plástico	17,84%	18,94%	-1,1027	-6,18%
	Vidro	3,69%	3,54%	0,1528	4,14%
	Metal	1,68%	1,77%	-0,0897	-5,34%
	Outros	8,05%	8,27%	-0,2179	-2,71%
	Matéria Orgânica	53,60%	51,61%	1,9945	3,72%

Os resultados da previsão para o ano 2015, apresentados na tabela 3, foram bem-sucedidos. Em nenhum dos casos, os erros relativos foram superiores a 10%, conforme exibido a seguir:

- Matéria Orgânica → Subestimado (Erro Rel. 3,72%);
- Papel/Papelão → Superestimado (Erro Rel. -4,87%);
- Plástico → Superestimado (Erro Rel. -6,18%);
- Vidro → Subestimado (Erro Rel. 4,14%);
- Metal → Superestimado (Erro Rel. -5,34%);
- Outros Rejeitos → Superestimado (Erro Rel. -2,71%).

Os resultados das previsões para o ano 2015 podem ser observados nos gráficos a seguir (figura 4).

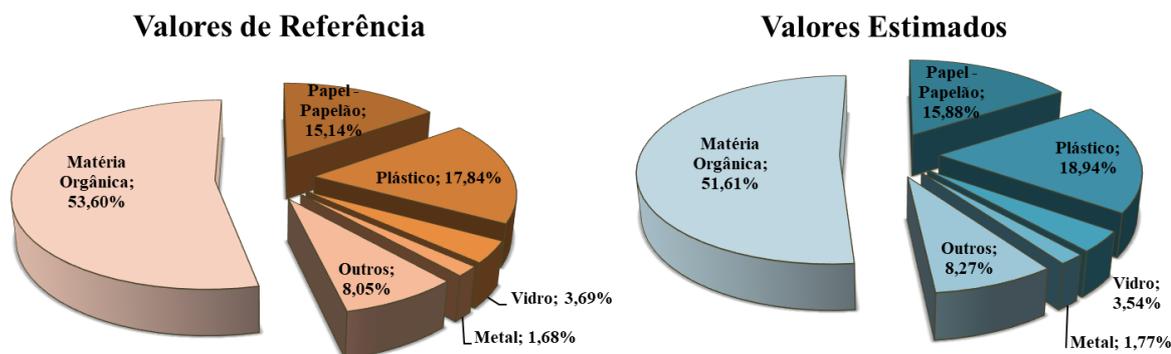


Figura 4. Representações gráficas das frações de referência e estimadas de Composição Gravimétrica do ano 2015 no Município do Rio de Janeiro. Fonte: Autor. Fonte: Elaborados pelo autor, com referências de IPP (2023a e 2023b).

### 3.1.2. Procedimento de validação utilizando valores de referência do ano 2020

A fim de verificar a validade do modelo proposto para as previsões de composição gravimétrica de RSU, foram feitas simulações utilizando alvos conhecidos para o cenário do Município do Rio de Janeiro. A primeira validação ocorreu para alvos do ano 2020, conforme evidenciado na tabela 4.

Tabela 4 - Informações de alvos relacionados ao algoritmo desenvolvido em MATLAB para previsão de Composição Gravimétrica do Município do Rio de Janeiro. Fonte: Consolidado pelo autor, com referências de IPP (2023a e 2023b).

Ano		2015	2016	2017	2018	2019	2020
Composição gravimétrica RSU domiciliar	Papel - Papelão (%)	15,14	14,82	14,70	14,31	14,63	Alvo $\mu$
	Plástico (%)	17,84	20,24	24,66	15,33	15,72	Alvo $\mu$
	Vidro (%)	3,69	3,55	3,46	3,48	3,58	Alvo $\mu$
	Metal (%)	1,68	1,65	1,51	1,81	1,75	Alvo $\mu$
	Outros (%)	8,05	6,51	6,46	14,56	16,99	Alvo $\mu$
	Matéria Orgânica (%)	53,60	53,23	49,21	50,51	47,33	Alvo $\mu$

Os resultados das previsões para o ano 2020 podem ser observados na tabela 5, a seguir, que evidencia as diferenças entre os valores de referência e os valores estimados pelo modelo.

Tabela 5 - Informações de referências e saídas relacionadas ao algoritmo desenvolvido em MATLAB para previsão de Composição Gravimétrica do Município do Rio de Janeiro. Fonte: Consolidado pelo autor, com referências de IPP (2023a e 2023b).

ID: #2020		Valores de Referência	Valores Estimados	Erros	
				Absoluto	Relativo
Composição gravimétrica	Papel - Papelão	11,17%	10,53%	0,6378	5,71%
	Plástico	15,69%	16,39%	-0,6911	-4,40%
	Vidro	4,37%	4,03%	0,3385	7,74%
	Metal	1,51%	1,59%	-0,0839	-5,57%
	Outros	20,48%	19,65%	0,8320	4,06%
	Matéria Orgânica	46,78%	47,82%	-1,0352	-2,21%

Os resultados da previsão para o ano 2020, apresentados na tabela 5, foram bem-sucedidos. Em nenhum dos casos, os erros relativos foram superiores a 10%, conforme exibido a seguir:

- Matéria Orgânica → Superestimado (Erro Rel. -2,21%);
- Papel/Papelão → Subestimado (Erro Rel. 5,71%);
- Plástico → Superestimado (Erro Rel. -4,4%);
- Vidro → Subestimado (Erro Rel. 7,74%);
- Metal → Superestimado (Erro Rel. -5,57%);
- Outros Rejeitos → Subestimado (Erro Rel. 4,06%).

Os resultados das previsões para o ano 2020 podem ser observados nos gráficos a seguir (figura 5).

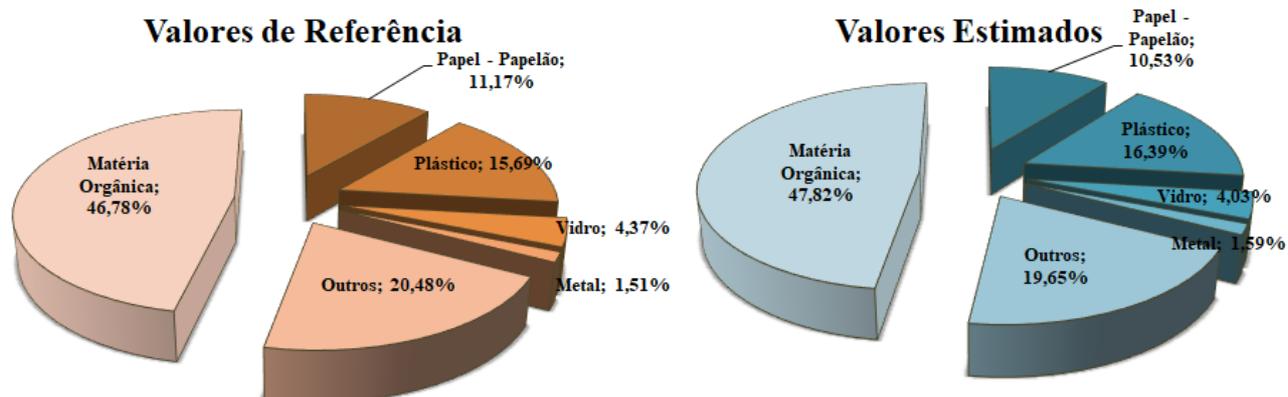


Figura 5. Representações gráficas das frações de referência e estimadas de Composição Gravimétrica do ano 2020 no Município do Rio de Janeiro. Fonte: Autor. Fonte: Elaborados pelo autor, com referências de IPP (2023a e 2023b).

#### 4 CONCLUSÕES

A compreensão do fenômeno socioeconômico que governa a produção de resíduos permite concluir que não há uma relação linear entre as características dos RSU e os fatores socioeconômicos da população que o produziu, todavia, isso não se tornou um problema para o uso de RNA, pois este método computacional é versátil e adequado a situações não lineares e de complexidades singulares, sendo capaz de extrapolar dados com base nas taxas de variação dos fatores socioeconômicos utilizados.

Tendo em vista que as previsões obtidas por meio das RNA estão lastreadas em dados de terceiros, os resultados obtidos através delas serão tão confiáveis quanto às previsões das instituições que servem de alimentadores de dados. O uso de dados não confiáveis torna o processo de previsão meramente matemático, não tendo, portanto, utilidade prática. Portanto, recomenda-se que especial atenção seja dada a parte da coleta de dados e validação das fontes.

Diferentes indicadores socioeconômicos podem ser utilizados nas previsões, devendo ser feita uma seleção de fatores abrangente o suficiente para extrair informações e gerar previsões. A seleção de fatores

consagrados pode ser realizada por revisão bibliográfica, ou a proposição de novos fatores pode ser feita por extrapolação, seguida de verificação estatística. Neste estudo, destacaram-se os dados de quantitativo populacional e PIB, pois além de serem frequentemente mencionados na literatura sobre o tema, são variáveis que, de modo geral, são amplamente divulgadas pelo poder público.

A evolução da tecnologia permitiu que sofisticadas ferramentas de computação, que outrora eram reservadas a poucos segmentos, sejam empregadas em larga escala para o benefício da sociedade. A escolha da técnica de RNA para previsão da composição gravimétrica dos RSU se mostra mais eficiente do que a amostragem in loco, pois esta última demanda emprego de pessoal especializado e consome significativa quantidade de tempo. Todavia, não é recomendável descartar completamente a realização amostragens in loco, visto que um método pode complementar e retroalimentar o outro.

Ademais, o modelo proposto é de imensa valia para o emprego em previsões de eventos que já ocorreram, como as lacunas deixadas em períodos de pandemia, visto que, nestes casos, as amostragens in loco são fisicamente impossíveis de serem realizadas, pois seria necessário desafiar o espaço-tempo.

Por fim, a aplicação simples e de baixo custo pode ser vantajosa para cidades com deficiências na caracterização gravimétrica de resíduos causadas por restrições de recursos técnicos e financeiros.

## REFERÊNCIAS BIBLIOGRÁFICAS

- Adeleke, O., Akinlabi, SA, Jen, T., Dunmade I. (2021) Application of artificial neural networks for predicting the physical composition of municipal solid waste: An assessment of the impact of seasonal variation. *Waste Management & Research: The Journal for a Sustainable Circular Economy*, vol. 39. <http://dx.doi.org/10.1177/0734242x21991642> .
- Andeobu, L., Wibowo, S., Grandhi, S. (2022) Artificial intelligence applications for sustainable solid waste management practices in Australia: A systematic review. *Science of The Total Environment*, vol. 834. <https://doi.org/10.1016/j.scitotenv.2022.155389>.
- Bai, B., Bai, Y., Wang, G., Bao, X., Wang, H. (2022) ANN/GA-ANN modeling study on operating parameter prediction for waste-to-energy plant. *Biomass Convers Biorefin.* doi:10.1007/s13399-022-03687-4. <http://dx.doi.org/10.1007/s13399-022-03687-4>.
- Beale, M.H., Hagan, M.T., Demuth, H.B. (2022) *Deep Learning Toolbox™ User's Guide*, 14th Ed, Massachusetts, MathWorks.
- Donevska K. (2020) Estimating municipal solid waste generation: From traditional methods to artificial neural networks. In: *Lecture Notes in Civil Engineering*. Cham: Springer International Publishing. p. 11–19. [http://dx.doi.org/10.1007/978-3-030-51350-4\\_2](http://dx.doi.org/10.1007/978-3-030-51350-4_2).
- Fazri, M.F., Kusuma, L.B., Rahmawan, R.B., Fauji, H.N., Camille, C. (2023) Implementing Artificial Intelligence to reduce marine ecosystem pollution. *itsdi.* 4(2):101–108. doi:10.34306/itsdi.v4i2.579. <http://dx.doi.org/10.34306/itsdi.v4i2.579>.
- Ghanbari, F., Kamalan, H., Sarraf, A. (2021) An evolutionary machine learning approach for municipal solid waste generation estimation utilizing socioeconomic components. *Arab J Geosci.* 14(2). <http://dx.doi.org/10.1007/s12517-020-06348-w>.
- IBGE. (2023a) Table 1517. Produto Interno Bruto (PIB) das capitais, segundo os setores econômicos - Brasil - 2002-2012 (in portuguese). [accessed 2023 Sep 31]. <https://www.arcgis.com/sharing/rest/content/items/0fee074296c9473aa9752813c453d1c3/data>.
- IBGE. (2023b) Table 3438. Produto Interno Bruto (PIB) a preço de mercado corrente, segundo as Grandes Regiões, Unidades da Federação do Sudeste do Brasil e suas capitais entre 2010-2020 (in portuguese). [accessed 2023 Jan 11]. <https://www.arcgis.com/sharing/rest/content/items/fc0d70cdca5a44f39387db73b1110455/data>.
- IBGE. (2023c) Table 3704. População residente estimada do Município do Rio de Janeiro - 1970 a 2022 (in portuguese). [accessed 2023 Jul 7]. <https://www.arcgis.com/sharing/rest/content/items/90106eb8874f4e8fbbc27678bbb1e772/data>.
- Ikiz, E., Maclaren, V.W., Alfred, E., Sivanesan, S. (2021) Impact of COVID-19 on household waste flows, diversion and reuse: The case of multi-residential buildings in Toronto, Canada. *Waste management*, vol 164. <https://doi.org/10.1016/j.resconrec.2020.105111>
- IPP. (2023a) Table 1494. Principais características do lixo domiciliar: composição gravimétrica percentual, peso específico e teor de umidade segundo as Áreas de Planejamento (AP) do Município do Rio de Janeiro entre 1995-2021 (in portuguese). [accessed 2023 Sep 11]. <https://www.arcgis.com/sharing/rest/content/items/ccdc3c0946ff430db6ef479befe8a5a5/data>.
- IPP. (2023b) Table 2661. Indicadores de Resíduos Sólidos Urbanos: coleta no Município do Rio de Janeiro entre 2002-2021. [accessed 2023 Jul 7]. <https://www.arcgis.com/sharing/rest/content/items/3123338773b243509b2c1a91a4257f08/data>.
- Mahler, C.F., Mendez, G.P., Taquette, S.R. (2020) Systematic review of qualitative studies in solid waste. In: *New Trends in Qualitative Research: Qualitative Research in Social Sciences: advances and challenges*, vol 4. <https://doi.org/10.36367/ntqr.4.2020.55-66>

- Noman, A.A., Rafizul, I.M., Moniruzzaman, S.M., Kraft, E., Berner, S. (2023) Assessment of municipal solid waste from households in Khulna city of Bangladesh. *Heliyon*. <http://dx.doi.org/10.1016/j.heliyon.2023.e22446>.
- Onyeaka, H., Tamasiga, P., Nwauzoma, U.M., Miri, T., Juliet, U.C., Nwaiwu, O., Akinsemolu, A.A. (2023) Using artificial intelligence to tackle food waste and enhance the circular economy: Maximising resource efficiency and minimising environmental impact: A review. *Sustainability*. 15(13):10482. doi:10.3390/su151310482. <http://dx.doi.org/10.3390/su151310482>.
- Penteado, C.S.G.; Castro, M.A.S. (2021) Covid-19 effects on municipal solid waste management: What can effectively be done in the Brazilian scenario? *Waste management*, vol 164. <https://doi.org/10.1016/j.resconrec.2020.105152>
- Said, Z., Sharma, P., Thi Bich Nhung, Q., Bora, B.J., Lichtfouse, E., Khalid, H.M., Luque, R., Nguyen, X.P., Hoang, A.T. (2023) Intelligent approaches for sustainable management and valorisation of food waste. *Bioresour Technol*. 377(128952):128952. doi:10.1016/j.biortech.2023.128952. <http://dx.doi.org/10.1016/j.biortech.2023.128952>.
- Seyyedi, S.R., Kowsari, E., Ramakrishna, S., Gheibi, M., Chinnappan, A. (2023) Marine plastics, circular economy, and artificial intelligence: A comprehensive review of challenges, solutions, and policies. *J Environ Manage*. 345(118591):118591. doi:10.1016/j.jenvman.2023.118591. <http://dx.doi.org/10.1016/j.jenvman.2023.118591>.
- Shekoohiyani, S., Hadadian, M., Heidari, M., Hosseinzadeh-Bandbafha, H. (2023) Life cycle assessment of Tehran Municipal solid waste during the COVID-19 pandemic and environmental impacts prediction using machine learning. *Case Studies in Chemical and Environmental Engineering*. 7(100331):100331. doi:10.1016/j.cscee.2023.100331. <http://dx.doi.org/10.1016/j.cscee.2023.100331>
- SNIS. (2023a) Table 1477. População total, população atendida, quantidade de ligações, quantidade de economias e extensão de rede de abastecimento de água no Município do Rio de Janeiro entre 1996-2021 (in portuguese). [accessed 2023 Jul 7]. <https://www.arcgis.com/sharing/rest/content/items/0e0c2674837242b18d78f9a66f638433/data>.
- SNIS. (2023b) Table 1479. Volumes de produção e distribuição pela rede de abastecimento de água no Município do Rio de Janeiro entre 1996-2021 (in portuguese). [accessed 2023 Jul 7]. <https://www.arcgis.com/sharing/rest/content/items/17823cc5cc994c9588cd38ba890fb1cd/data>.
- SNIS. (2023c) Table 1485. População atendida, quantidade de ligações, quantidade de economias ativas, volumes e extensão da rede do sistema de esgotamento sanitário no Município do Rio de Janeiro entre 1996-2021 (in portuguese). [accessed 2023 Jul 10]. <https://www.arcgis.com/sharing/rest/content/items/ad48cb6eea134cecb5586a7f3efead14/data>.
- Thomaz, I.P.L. (2016) Utilização de Redes Neurais Artificiais (RNA) para previsão da composição gravimétrica e peso específico de Resíduos Sólidos Urbanos (RSU), dissertação de mestrado, COPPE/UFRJ, Rio de Janeiro.
- Thomaz, I.P.L., Mahler, C.F., Calôba, L.P. (2023) Artificial Intelligence (AI) applied to waste management: A contingency measure to fill out the lack of information resulting from restrictions on field sampling. *Waste Management Bulletin*. <https://doi.org/10.1016/j.wmb.2023.06.002>
- UNEP - United Nations Environment Programme, International Solid Waste Association. (2024) *Global Waste Management Outlook 2024 - Beyond an age of waste: Turning rubbish into a resource*. <http://dx.doi.org/10.59117/20.500.11822/44939>.
- Vazquez, Y.V., Barragán, F., Castillo, L.A., Barbosa, S.E. (2020) Analysis of the relationship between the amount and type of MSW and population socioeconomic level: Bahía Blanca case study, Argentina. *Heliyon*. <http://dx.doi.org/10.1016/j.heliyon.2020.e04343>