ESTIMATIVA DA COMPOSIÇÃO GRAVIMÉTRICA DE RESÍDUOS SÓLIDOS URBANOS EM MUNICÍPIOS BRASILEIROS POR MEIO DE REDES NEURAIS ARTIFICIAIS

Daniel Epifânio Bezerra[(1)]
Doutorando em Engenharia Civil e Ambiental, Mestre engenharia Civil e Ambiental, graduado em Engenharia Sanitária e Ambiental
Renan Camilo de Lima Paulo [(2)]
Especialista em , graduado em Engenharia Civil
Victor Emmanuel Avelino Gomes Bahia[(3)]
Doutorando em Engenharia Civil e Ambiental, Mestre engenharia Civil e Ambiental, graduado em Engenharia Civil
Cláudio Luis de Araújo Neto[(4)]
Doutor em Engenharia Civil e Ambiental, mestre em Engenharia Civil, graduado em Engenharia Sanitária e Ambiental e licenciado em Ciências Agrárias. Professor do Curso de Engenharia Ambiental e Sanitária e do Programa de Pós-Graduação em Ciência e Tecnologia Ambiental da Universidade Federal do Maranhão (UFMA)
Márcio Camargo de Melo[(5)]
Doutor em Ciências e Engenharia de Materiais, mestre em Engenharia Civil e Ambiental, licenciado em Ciências Biológicas e em Matemática. Professor do Curso de Engenharia Civil e do Programa de Pós-Graduação em Engenharia Civil e Ambiental (UFCG).

RESUMO

A gestão de Resíduos Sólidos Urbanos (RSU) representa um desafio crescente para municípios em decorrência do aumento populacional, expansão urbana e intensificação dos padrões de consumo. Nesse contexto, a composição gravimétrica dos resíduos constitui importante ferramenta de planejamento, embora sua determinação por métodos convencionais envolva elevados custos e limitações operacionais. Assim, este estudo avaliou o potencial de aplicação de Redes Neurais Artificiais (RNA) na estimativa da composição gravimétrica de RSU em municípios brasileiros a partir do Índice de Desenvolvimento Humano Municipal (IDHm). Para isso, foi estruturado um banco de dados com informações de 213 municípios brasileiros, reduzido para 146 após tratamento estatístico e utilizado no treinamento e avaliação de diferentes arquiteturas de RNA. A arquitetura n6_1000 (LOGSIN) apresentou o melhor desempenho, com gradiente de 0,044 e tempo de processamento de 57 s. A validação com dados de Campina Grande (PB), São Carlos (SP) e Curitiba (PR) demonstrou boa concordância entre valores observados e estimados e as projeções para 2030 indicaram redução da fração orgânica e aumento da categoria “outros”, associadas a mudanças no perfil socioeconômico. Os resultados evidenciam o potencial de capacidade preditiva e de generalização da RNA como ferramenta de apoio ao planejamento e gestão de RSU.

PALAVRAS-CHAVE: resíduos sólidos urbanos, redes neurais artificiais, composição gravimétrica.

INTRODUÇÃO

O Brasil é um país de dimensões territoriais continentais, com população estimada em 213.421.037 habitantes em 2025 (IBGE, 2025). Em escala global, o processo de urbanização também continua avançando de forma significativa, sendo estimado que cerca de 68% da população mundial resida em áreas urbanas até 2050 (UN-HABITAT, 2022). Esse crescimento populacional, associado à expansão urbana e à intensificação dos padrões de consumo, contribui diretamente para o aumento da geração de resíduos sólidos urbanos (RSU), ampliando a demanda por sistemas eficientes de manejo, tratamento e disposição final.

No Brasil, apesar dos avanços observados na implementação de políticas públicas e na consolidação do marco regulatório do saneamento básico, ainda persistem desigualdades significativas na infraestrutura e na qualidade dos serviços prestados. Dados divulgados no Panorama dos Resíduos Sólidos no Brasil 2025, publicado pela Associação Brasileira de Resíduos e Meio Ambiente (ABREMA), indicam que a geração de RSU no país supera 81 milhões de toneladas anuais, das quais aproximadamente 34% ainda tiveram como destinação final lixões ou aterros controlados em 2024 (ABREMA, 2025).

Nesse contexto, a composição gravimétrica dos resíduos sólidos urbanos constitui uma ferramenta fundamental para o planejamento e a gestão integrada dos resíduos, permitindo identificar a proporção dos diferentes constituintes presentes na massa descartada e subsidiando estratégias de coleta seletiva, reciclagem, tratamento e disposição final ambientalmente adequada (BOSCOV, 2008). Entretanto, sua determinação experimental apresenta limitações operacionais importantes, pois exige procedimentos de amostragem, segregação e pesagem que demandam infraestrutura adequada, mão de obra especializada e custos elevados, além de expor os profissionais a condições insalubres e a riscos de contaminação. Soma-se a isso a elevada heterogeneidade dos RSU, cuja composição varia em função de aspectos socioeconômicos, culturais, climáticos e regionais, dificultando a obtenção de amostras representativas (MATTEI; ESCOSTEGUY, 2007).

Diversos estudos na área de saneamento básico demonstram que indicadores socioeconômicos, como renda, Produto Interno Bruto (PIB) e Índice de Desenvolvimento Humano (IDH), estão relacionados à geração e à composição dos resíduos sólidos urbanos, contribuindo para variações significativas na composição gravimétrica observada em diferentes municípios e países (SÃO MATEUS *et al*., 2019). Nesse cenário, técnicas de inteligência artificial, especialmente as Redes Neurais Artificiais (RNA), destacam-se pela capacidade de modelar relações complexas e não lineares entre variáveis, permitindo a identificação de padrões e a realização de previsões a partir de bancos de dados estruturados (HAYKIN, 2001).
Assim, o presente estudo tem como objetivo utilizar Redes Neurais Artificiais para modelar e estimar a composição gravimétrica de resíduos sólidos urbanos em municípios brasileiros a partir do Índice de Desenvolvimento Humano Municipal (IDHm), buscando avaliar o potencial dessa abordagem como ferramenta preditiva de apoio à gestão de resíduos sólidos urbanos por meio da comparação com dados coletados nos municípios de Campina Grande (PB), São Carlos (SP) e Curitiba (PR).

OBJETIVOS

Objetivo Geral

Avaliar o potencial de Redes Neurais Artificiais (RNA) na estimativa da composição gravimétrica de resíduos sólidos urbanos em municípios brasileiros a partir do Índice de Desenvolvimento Humano Municipal (IDHm), como ferramenta preditiva de apoio à gestão de resíduos sólidos.

Objetivos Específicos

- Construir e organizar um banco de dados contendo informações sobre a composição gravimétrica de resíduos sólidos urbanos e indicadores de desenvolvimento humano de municípios brasileiros;
- Desenvolver e ajustar modelos de Redes Neurais Artificiais para estimar a composição gravimétrica dos resíduos sólidos urbanos;
- Avaliar o desempenho preditivo das arquiteturas de RNA a partir da comparação entre valores estimados e dados observados, tomando como base os municípios de Campina Grande (PB), São Carlos (SP) e Curitiba (PR) para validação da estimativa;
- Analisar o potencial de aplicação da modelagem baseada em RNA como ferramenta de apoio ao planejamento e à gestão municipal de resíduos sólidos urbanos.

METODOLOGIA UTILIZADA

A metodologia foi estruturada em 4 (quatro) etapas para melhor apresentação.

Construção do banco de dados

Inicialmente, foi realizado um levantamento bibliográfico com o objetivo de reunir e tabular dados sobre a composição gravimétrica de resíduos sólidos urbanos (RSU) em 213 municípios brasileiros, considerando seis categorias de resíduos: papel/papelão, plástico, metal, vidro, matéria orgânica e outros. As principais fontes de dados utilizadas foram planos estaduais de resíduos sólidos e estudos científicos disponíveis na literatura. Para cada município, também foram coletados, nos bancos de dados fornecidos pelo IBGE, valores referentes ao Índice de Desenvolvimento Humano Municipal (IDHm), referentes aos anos de 1991, 2000 e 2010, utilizados como variável de entrada na modelagem.

As informações obtidas foram organizadas em planilhas eletrônicas, e após a exclusão de dados inconsistentes, foi formado um banco de dados estruturado para posterior tratamento estatístico e treinamento das Redes Neurais Artificiais.

Tratamento estatístico dos dados

Os dados passaram por uma etapa de pré-processamento estatístico com o objetivo de identificar inconsistências, avaliar a distribuição das variáveis e remover valores discrepantes (outliers). Para isso, foram realizadas análises descritivas para cada conjunto de dados de composição de RSU e de IDHm, cujos principais parâmetros encontram-se compilados na Tabela 1. Essa etapa permitiu uma caracterização preliminar do banco de dados, possibilitando avaliar a dispersão das variáveis e identificar possíveis distorções que poderiam comprometer o treinamento da Rede Neural Artificial.

A utilização de municípios distribuídos pelas cinco regiões brasileiras buscou ampliar a representatividade do banco de dados, contemplando diferentes realidades socioeconômicas, climáticas e culturais que influenciam a geração de resíduos. Dessa forma, procurou-se incorporar ao conjunto de treinamento diferentes padrões de composição gravimétrica observados no território nacional, contribuindo para aumentar a capacidade de generalização da RNA e sua aplicação em contextos municipais distintos.

Tabela 1 - Análises descritivas realizadas

Conjunto de dados	Análises realizadas
Papel Plástico Metal Vidro Matéria Orgânica	Amplitude, valor mínimo, valor máximo, média, moda, mediana, verificação de 1º e 3º quartis, variância, desvio padrão e coeficiente de variação.

Fonte: Autor (2026).

Em função da limitação temporal dos dados disponíveis de IDHm, foi realizada uma modelagem estatística com o uso de regressão logarítmica para estimativa de valores em anos não contemplados diretamente pelos censos, permitindo estimar valores de IDHm nesses anos e inserir no banco de dados para viabilizar sua utilização na modelagem

Modelagem com Redes Neurais Artificiais

A modelagem preditiva foi desenvolvida por meio de Redes Neurais Artificiais (RNA) do tipo feedforward, implementada por meio do software MATLAB® versão R2018a, utilizando como variáveis de entrada (input) os valores de IDHm e como variáveis de saída (target) os percentuais de composição gravimétrica dos resíduos sólidos urbanos.

Foram realizados diferentes treinamentos variando parâmetros estruturais da RNA, incluindo o número de neurônios na camada oculta (3, 4, 10, 20, 30, 50 e 100), o número de iterações (50, 500 e 1000) e o tipo de função de ativação (logística e tangente hiperbólica), totalizando 21 configurações-base e 42 treinamentos ao considerar ambas as funções de ativação. A avaliação de diferentes arquiteturas teve como objetivo identificar a configuração mais adequada para representar a relação não linear entre o IDHm e a composição gravimétrica dos resíduos sólidos urbanos, bem como analisar a influência desses parâmetros sobre o desempenho preditivo da rede.

Manteve-se fixo o algoritmo de treinamento *Bayesian Regularization*, técnica que incorpora regularização ao ajuste dos pesos da rede, reduzindo o sobreajuste (*overfitting*) e melhorando sua capacidade de generalização. Para isso, a função de performance é modificada pela adição de um termo associado aos pesos e desvios da rede, permitindo o ajuste automático dos parâmetros de regularização e contribuindo para o aprimoramento das estimativas produzidas pelo modelo (NEGOITA *et al*., 2018).

O desempenho das arquiteturas foi avaliado por meio da ferramenta nntool, interface do software MATLAB® destinada ao treinamento de redes neurais, considerando critérios como performance, gradiente, tempo de processamento e capacidade de generalização dos dados, os quais permitiram avaliar a qualidade do treinamento e a capacidade preditiva de cada configuração, a fim de determinar a arquitetura com melhor adaptação ao conjunto analisado.

Validação do modelo

Após o treinamento e seleção da arquitetura de Rede Neural Artificial com melhor desempenho, procedeu-se à validação do modelo por meio da comparação entre os valores estimados pela RNA e dados reais de composição gravimétrica disponíveis na literatura para municípios brasileiros selecionados. Para essa etapa, foram utilizados os municípios de Campina Grande (PB), São Carlos (SP) e Curitiba (PR), escolhidos em função da disponibilidade de dados experimentais e de suas diferenças em relação às características socioeconômicas e regionais. A comparação entre os valores observados e estimados permitiu avaliar a capacidade preditiva e o potencial de generalização da rede neural, verificando sua aplicabilidade como ferramenta de apoio à gestão de resíduos sólidos urbanos.

RESULTADOS E DISCUSSÕES

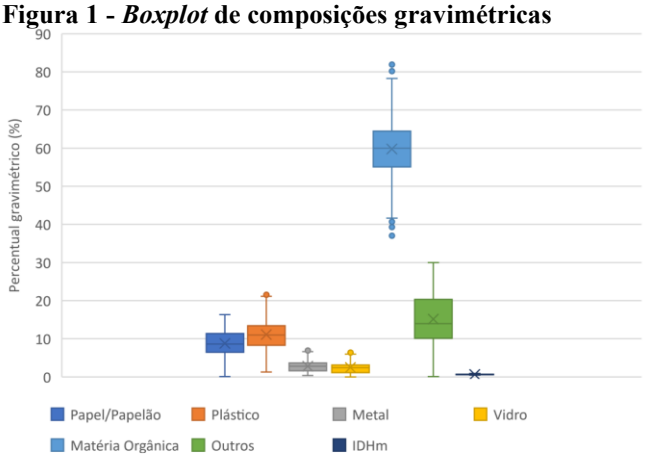
Nesta seção, são apresentados e discutidos os resultados obtidos nas etapas de tratamento de dados, treinamento das Redes Neurais Artificiais e validação do modelo.

Coleta e tratamento de dados

Por meio de uma ampla revisão de literatura foi possível tabular os dados de composição gravimétrica de Resíduos Sólidos Urbanos de 213 municípios brasileiros, contemplou municípios distribuídos entre as cinco regiões do Brasil, buscando representar diferentes realidades socioeconômicas e padrões de geração de resíduos e compondo o banco de dados inicial da pesquisa.

Os dados supracitados passaram por pré-tratamento estatístico, utilizando um gráfico do tipo *boxplot*, representado na Figura 1, com composições gravimétricas, a fim de identificar e remover dados individuais atípicos ou extremos, os quais podem ser causados por erros de coleta de dados, incluindo erros de introdução de dados, apresentados como *outliers*.

Figura 1 - *Boxplot* de composições gravimétricas



Fonte: Autor (2026).

Com base no gráfico, observou-se maior dispersão na fração de matéria orgânica, que apresentou os maiores percentuais gravimétricos entre as categorias analisadas, evidenciando a heterogeneidade dos resíduos gerados nos diferentes municípios. A categoria “outros” também apresentou elevada variabilidade, enquanto metal e vidro apresentaram menor dispersão e percentuais reduzidos. Após essa etapa, o banco de dados foi reduzido de 213 para 146 municípios, sendo utilizado nas fases de treinamento e validação do modelo.

Complementarmente, foi realizada uma análise quantitativa dos dados por região geográfica no Brasil, apresentada na Tabela 2.

Tabela 2 – Classificação dos dados por região

Região	Quantidade de municípios (Dados brutos)	Quantidade de municípios (Após remoção de *outliers*)
Norte	6	6
Nordeste	156	98
Centro-Oeste	26	18
Sudeste	11	10
Sul	14	14
Total	213	146

Fonte: Autor (2026).

A análise evidenciou uma concentração de dados oficiais e estudos sobre gestão, controle e caracterização de RSU na região Nordeste, que apresentou aproximadamente 83% mais registros que a região Centro-Oeste, segunda colocada em disponibilidade de dados. Em contrapartida, a região Norte apresentou o menor acervo bibliográfico, refletindo uma lacuna de informações que pode estar associada às dificuldades históricas enfrentadas pelo setor de gerenciamento de resíduos sólidos na região. Oliveira e Medeiros (2019) destacam que, embora a instituição da Política Nacional de Resíduos Sólidos (Lei nº 12.305/2010) tenha promovido avanços importantes no planejamento e na gestão dos resíduos na região Norte, a maior em extensão no país, sua implementação ainda limitações

estruturais e operacionais significativas, chamando atenção para o estado ainda emergencial do setor de gerenciamento regional. Após o pré-tratamento e a formação do banco de dados foi realizada a estatística descritiva para cada grupo de amostra, cujos resultados principais estão expressos na Tabela 3.

Tabela 3 - Análises descritivas da pesquisa

Variável	Média	Desvio padrão	Coeficiente de variação (%)
Papel	8,73	3,46	39,57
Plástico	11,13	3,96	35,54
Metal	2,70	1,43	53,18
Vidro	2,44	1,56	63,78
Matéria orgânica	60,22	8,78	14,59
Outros	14,78	7,33	49,55
IDHm	0,64	0,10	14,97

Fonte: Autor (2026).

A variabilidade dos dados foi avaliada por meio do coeficiente de variação (CV), considerando-se que valores inferiores a 15% indicam baixa dispersão, entre 15% e 30% indicam dispersão moderada e superiores a 30% caracterizam elevada dispersão (PAIVA, 2009). À vista disso, conforme apresentado na Tabela 1, apenas as variáveis matéria orgânica (14,59%) e IDHm (14,97%) apresentaram baixa variabilidade e maior estabilidade no conjunto amostral, enquanto as demais categorias apresentaram elevada dispersão, evidenciando a heterogeneidade da composição gravimétrica entre os municípios analisados.

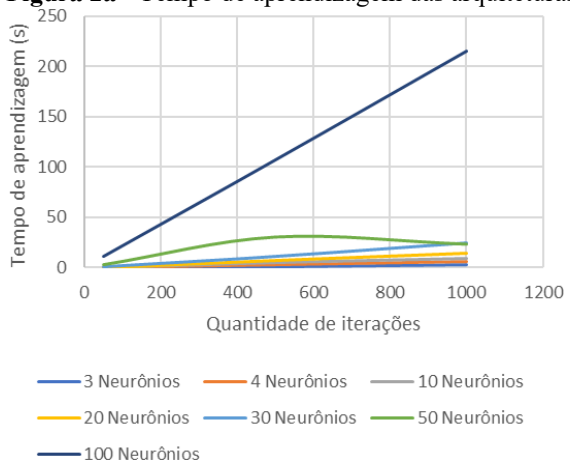
Avaliação do desempenho das RNA

Com a definição do banco de dados, foi realizado o treinamento das redes neurais com o uso do algoritmo *bayesian regularization*, considerando critérios de performance, gradiente e o parâmetro de ajuste de *Levenberg-Marquardt* (μ). Ulteriormente, procedeu-se à análise comparativa do desempenho das Redes Neurais Artificiais testadas, a fim de identificar a configuração mais adequada para a estimativa da composição gravimétrica dos resíduos sólidos urbanos. Os resultados expressos para cada rede estão expressos nos tópicos a seguir.

Tempo de aprendizagem

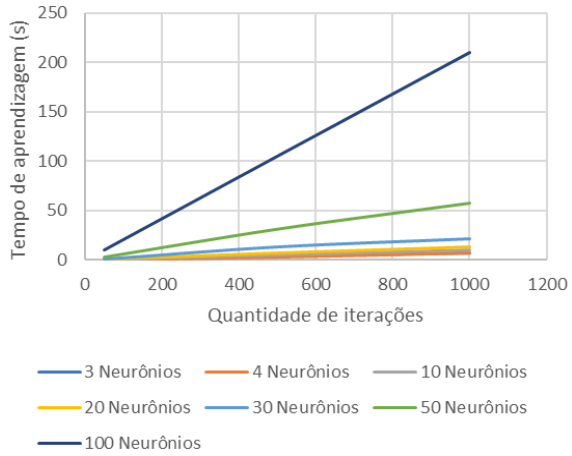
Embora o tempo de processamento não tenha sido um critério determinante para a seleção da melhor rede neural, sua análise permitiu avaliar a viabilidade computacional das arquiteturas testadas. Os gráficos das Figuras 2a e 2b retratam o comportamento do tempo de das diferentes configurações de RNA em função do número de neurônios na camada oculta e do número de iterações, considerando as funções de ativação tangente hiperbólica (Figura 2a) e logística (Figura 2b).

Figura 2a - Tempo de aprendizagem das arquiteturas de RNA com função de ativação tangente hiperbólica



Fonte: Autor (2026).

Figura 2b - Tempo de aprendizagem das arquiteturas de RNA com função de ativação logística



Fonte: Autor (2026).

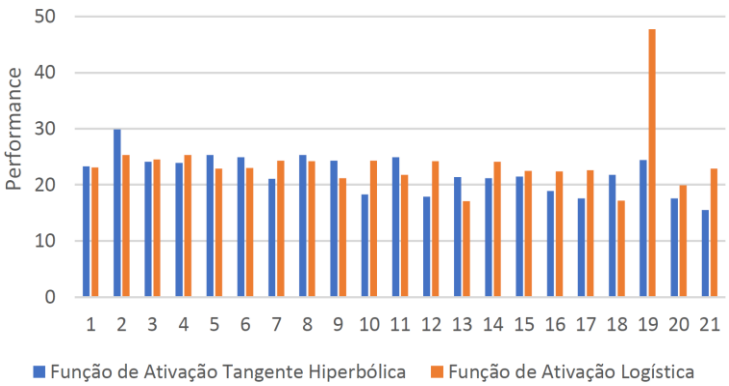
Observou-se que a função de ativação tangente hiperbólica apresentou, em média, menor tempo de processamento. O maior tempo registrado foi de 215 s para a arquitetura n7_1000 (TANSIN), composta por 100 neurônios na camada oculta e 1000 iterações de treinamento. A arquitetura n7_1000 (LOGSIN), com configuração equivalente e função de ativação logística, apresentou desempenho semelhante, com tempo de processamento de 210 s. Esses resultados indicam que, mesmo para as arquiteturas mais complexas avaliadas, os tempos de treinamento permaneceram inferiores a quatro minutos, evidenciando a viabilidade computacional da metodologia e sua aplicação em futuras atualizações do banco de dados.

De modo geral, verificou-se aumento progressivo do tempo de aprendizagem com o incremento do número de neurônios na camada oculta e do número de iterações, resultado compatível com o observado por Martins *et al*. (2007), que associam esse comportamento ao maior número de atualizações sinápticas durante o treinamento.

Performance e gradiente

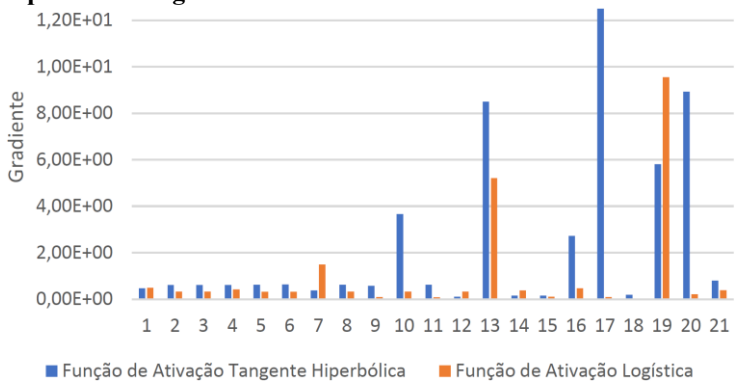
Além do tempo de processamento, a seleção da arquitetura mais adequada também considerou os parâmetros de performance e gradiente, utilizados na avaliação do treinamento da rede. No algoritmo *Bayesian Regularization*, a regularização modifica a função de performance ao adicionar um termo relacionado aos pesos e desvios da rede, permitindo o ajuste automático dos parâmetros de regularização e contribuindo para o aprimoramento do modelo (NEGOITA *et al*., 2018). A Figura 3a apresenta o comportamento da performance das arquiteturas treinadas em função do número de iterações e da quantidade de neurônios na camada oculta. De forma complementar, a Figura 3b ilustra o gradiente de treinamento para cada rede avaliada, parâmetro utilizado como critério de parada no processo de aprendizagem da RNA.

Figura 3a - Performance de treinamento das arquiteturas de RNA para as funções de ativação: tangente hiperbólica e logística



Fonte: Autor (2026).

Figura 3b - Gradiente de treinamento das arquiteturas de RNA para as funções de ativação: tangente hiperbólica e logística



Fonte: Autor (2026).

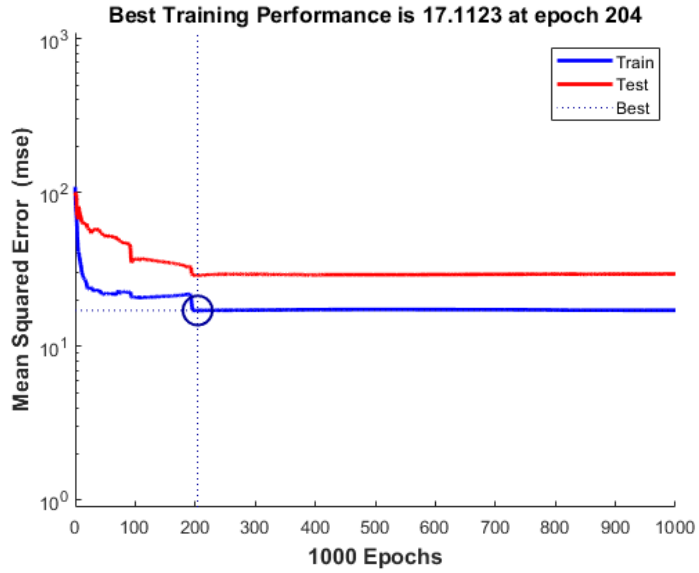
A análise conjunta dos parâmetros de performance e gradiente permitiu avaliar o comportamento das arquiteturas durante o treinamento, identificando aquelas com maior capacidade de convergência e melhor adaptação ao conjunto de dados. Entre as configurações testadas, destacaram-se as redes identificadas por n7_1000 (TANSIN) e n6_1000 (LOGSIN), que apresentaram os resultados mais satisfatórios dentre as arquiteturas avaliadas.

Considerando-se os resultados obtidos, observou-se tendência de melhoria da performance com o aumento do número de iterações, indicando maior refinamento do processo de treinamento. Tal comportamento está de acordo com o descrito por Negoita *et al*. (2018), segundo os quais o processo de treinamento tende a convergir para soluções mais adequadas à medida que são minimizados os erros associados à função de performance.

Seleção do modelo final

A partir da análise dos parâmetros de desempenho, a arquitetura n6_1000 (LOGSIN) foi selecionada como modelo final por apresentar os resultados mais satisfatórios entre as configurações avaliadas. Essa rede foi composta por 50 neurônios na camada oculta, função de ativação logística e 1000 iterações de treinamento, apresentando gradiente de 0,044 e tempo de processamento de 57 s. Após a definição da arquitetura, foram analisados os gráficos gerados por meio da ferramenta *nntool*, visando avaliar o comportamento do treinamento e a qualidade do ajuste obtido. A Figura 4 apresenta a evolução da performance da rede selecionada ao longo do processo de treinamento e a convergência do treinamento até o ponto de menor erro.

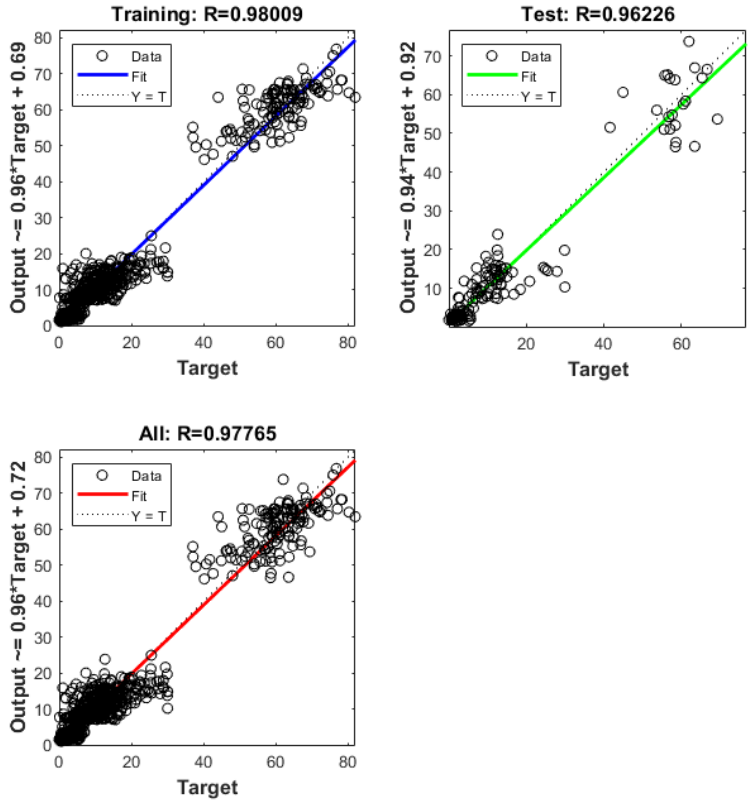
Figura 4 - Gráfico de comportamento da performance na RNA escolhida.



Fonte: Autor (2026).

Observa-se, na Figura 4, a convergência do treinamento para valores reduzidos da função de performance, indicando adequada adaptação da rede aos padrões presentes no conjunto de dados. Complementarmente, a Figura 5 apresenta a análise de regressão entre os valores observados e estimados pela RNA. Essa ferramenta permite avaliar a aderência do modelo aos dados utilizados e verificar a capacidade da rede em reproduzir os padrões presentes no conjunto analisado.

Figura 5 - Gráficos das regressões na RNA escolhida



Fonte: Autor (2026).

Validação do modelo e previsão de dados

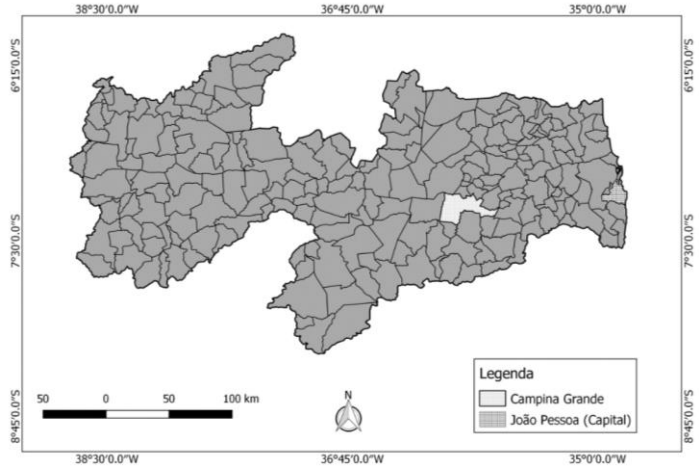
A validação da RNA foi realizada com base em dados reais de composição gravimétrica dos municípios de Campina Grande (PB), São Carlos (SP) e Curitiba (PR), sendo posteriormente aplicada na projeção de cenários para a composição dos resíduos sólidos urbanos no ano de 2030.

Campina Grande (PB)

Campina Grande está localizada no interior da Paraíba e possui população estimada em 443.911 habitantes e área territorial de aproximadamente 592 km² (IBGE, 2025). O município destaca-se como um dos principais polos tecnológicos, educacionais e econômicos do interior do Nordeste, exercendo grande influência no desenvolvimento regional. Além disso, apresenta PIB per capita superior a R$ 28 mil, refletindo sua relevância econômica no contexto estadual e regional.

Tais características socioeconômicas, associadas à disponibilidade de dados de composição gravimétrica na literatura, justificam a seleção do município para a etapa de validação da RNA, uma vez que refletem fatores diretamente relacionados aos padrões de geração e composição dos resíduos sólidos urbanos. Sua localização no estado está ilustrada no mapa da Figura 6.

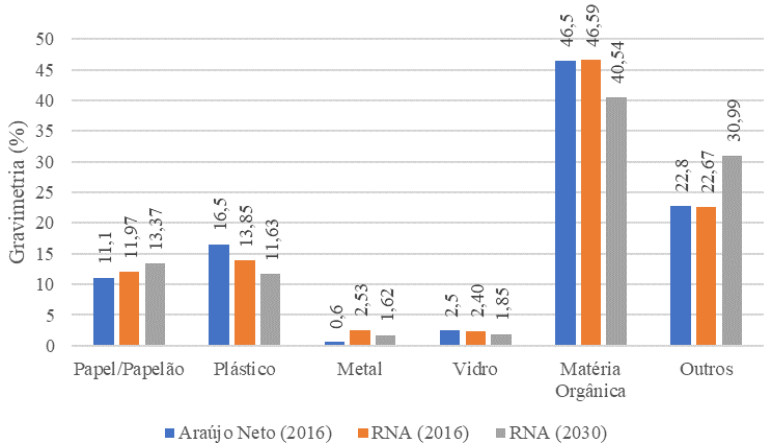
Figura 6 - Localização do município de Campina Grande (PB)



Fonte: Autor (2026).

Para a validação da RNA em Campina Grande (PB), foram utilizados dados de composição gravimétrica obtidos por Araújo Neto (2016), considerando IDHm de 0,7993 para 2016. O município, que apresenta PIB per capita de aproximadamente R$ 27 mil, constitui um importante centro econômico do interior nordestino. A partir desse cenário, foi realizada a projeção da composição gravimétrica para 2030, utilizando IDHm estimado de 0,8951. A comparação entre os valores observados, estimados e projetados está apresentada na Figura 7.

Figura 7 - Comparação entre valores observados e estimados de RSU em Campina Grande (PB)



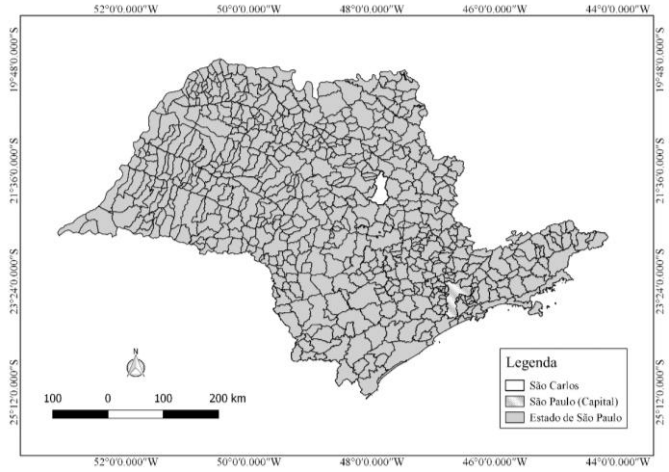
Fonte: Autor (2026).

A capacidade preditiva da RNA é ratificada pelos dados da Figura 7, dada a proximidade entre os valores modelados e os observados por Araújo Neto (2016). Para o ano de 2030, a estimativa apontou uma redução expressiva na geração de matéria orgânica, possivelmente atrelada à elevação prevista do IDHm. Tal comportamento corrobora o que foi indicado por Feil *et al.* (2015): que o desenvolvimento socioeconômico tende a mitigar a produção de resíduos orgânicos, podendo, por outro lado, incrementar a fração de papel e diminuir as de plástico e metal.

São Carlos (SP)

O município de São Carlos está localizado na região centro-leste do estado de São Paulo e possui área territorial de aproximadamente 1.137 km². Com população estimada em 266.427 habitantes, destaca-se como um importante polo tecnológico, industrial e universitário do interior paulista, apresentando elevado nível de desenvolvimento socioeconômico e PIB per capita de R$ 72.146,03 (IBGE, 2025). Essas características refletem padrões de consumo e geração de resíduos distintos daqueles observados em municípios de menor desenvolvimento econômico. Sua localização no estado está ilustrada no mapa da Figura 8.

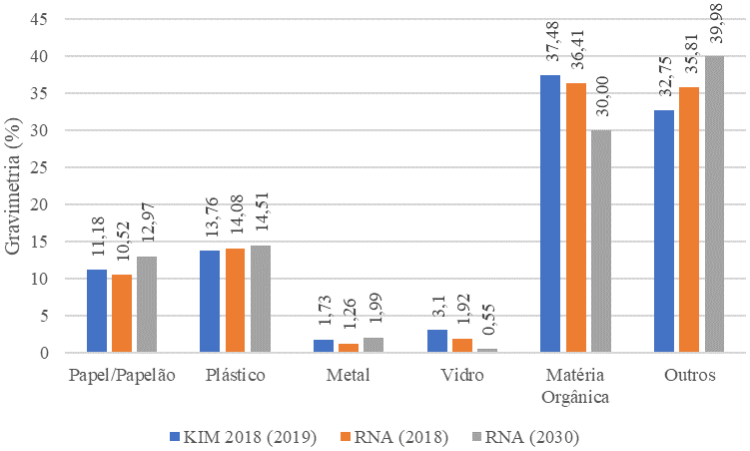
Figura 8 - Localização do município de São Carlos (SP)



Fonte: Autor (2026).

Para o município de São Carlos (SP), a validação da RNA foi realizada com base nos dados de composição gravimétrica apresentados por Kim (2019), considerando IDHm de 0,9011 para 2018. Também foi realizada a projeção da composição gravimétrica para 2030, com IDHm estimado de 0,9653. Os resultados dessa comparação estão apresentados na Figura 9.

Figura 9 - Comparação entre valores observados e estimados de RSU em São Carlos (SP)



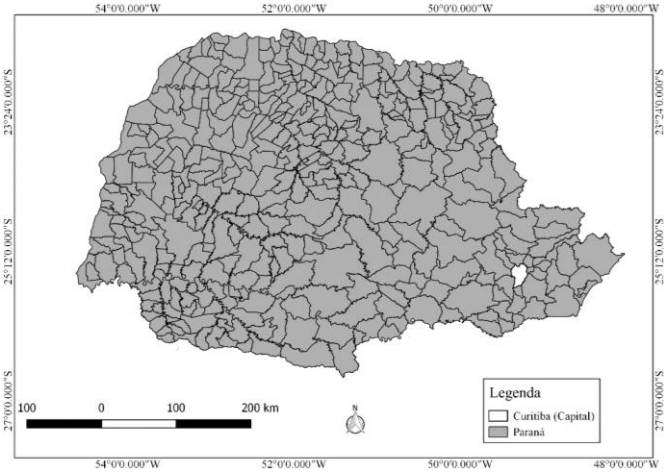
Fonte: Autor (2026).

Os resultados indicaram bom ajuste da RNA em relação aos dados observados, evidenciando a capacidade do modelo em representar a composição gravimétrica do município. Para o cenário projetado em 2030, verificou-se redução nas frações de matéria orgânica e vidro, além de aumento expressivo na categoria “outros”, possivelmente associado a alterações nos padrões de consumo e à maior diversificação dos resíduos gerados. Esses resultados reforçam a tendência observada nas demais estimativas, indicando influência do desenvolvimento socioeconômico sobre a composição gravimétrica dos RSU, conforme tendência discutida também por Kim (2019).

Curitiba (PR)

Com área territorial de aproximadamente 435 km² e PIB per capita superior a R$ 60 mil, a capital paranaense representa um cenário de elevado desenvolvimento socioeconômico, constituindo um contexto adequado para avaliar o comportamento da RNA em condições distintas das observadas nos demais municípios estudados. Além disso, por concentrar uma população superior a 1,8 milhão de habitantes, Curitiba apresenta dinâmica urbana complexa e elevada demanda por serviços de gestão de resíduos (IBGE, 2025). Sua localização no estado está ilustrada no mapa da Figura 10.

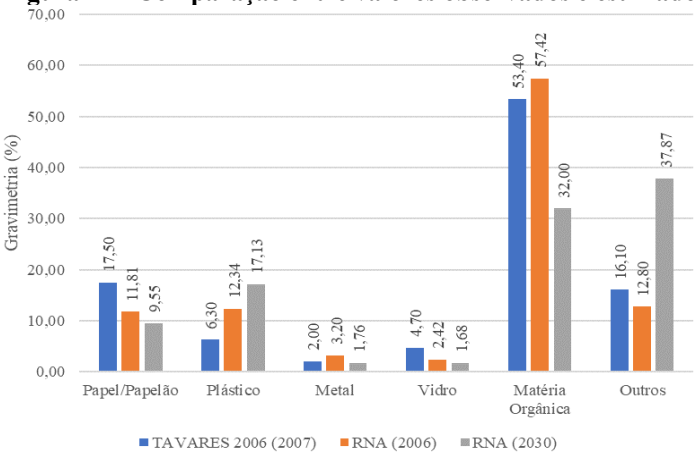
Figura 10 - Localização do município de Curitiba (PR)



Fonte: Autor (2026).

Por fim, para o município de Curitiba (PR), a validação da RNA foi realizada com base nos dados de composição gravimétrica apresentados por Tavares (2007), considerando IDHm de 0,7921 para 2006. Também foi realizada a projeção da composição gravimétrica para 2030, utilizando IDHm estimado de 0,9852, o maior entre os municípios analisados. Esse cenário possibilita avaliar a resposta da RNA em um contexto de elevado desenvolvimento humano. A comparação entre os dados da literatura, as estimativas geradas pela RNA e as projeções para 2030 é apresentada na Figura 11.

Figura 11 - Comparação entre valores observados e estimados de RSU em Curitiba (PR)



Fonte: Autor (2026).

Os resultados para Curitiba (PR) indicaram uma maior discrepância entre os valores observados na literatura e aqueles estimados pela RNA, possivelmente pelo fato da utilização de valores da composição gravimétrica com dados de 2006, gerando maior distorção entre o real e o estimado. Não obstante, ainda pode-se considerar satisfatória a precisão da RNA, ratificando o potencial do modelo para estimar a composição gravimétrica de RSU em diferentes municípios brasileiros. No cenário projetado para 2030, além da redução da fração de matéria orgânica, destacou-se o aumento considerável da categoria "outros", indicando maior participação de resíduos não enquadrados nas frações tradicionais, reflexo da diversificação dos padrões de consumo em municípios com maior nível de desenvolvimento. (FEIL *et al.*, 2015; KIM, 2019)

CONCLUSÃO

A gestão de resíduos sólidos urbanos no Brasil ainda enfrenta desafios relacionados à elevada geração de resíduos, à heterogeneidade de sua composição e às limitações operacionais e econômicas dos métodos tradicionais de caracterização gravimétrica. Nesse contexto, este estudo propôs o uso de Redes Neurais Artificiais como ferramenta preditiva para estimar essa composição a partir do Índice de Desenvolvimento

Humano Municipal (IDHm), buscando oferecer uma alternativa mais rápida, segura e economicamente viável para apoio à gestão.

Por meio de pesquisa bibliográfica, foi possível construir e realizar o tratamento estatístico de um banco de dados com informações gravimétricas e socioeconômicas de municípios brasileiros, permitindo o treinamento e a avaliação de diferentes arquiteturas de RNA. Entre as configurações avaliadas, foi selecionada a rede n6_1000 (LOGSIN), composta por 50 neurônios na camada oculta, função de ativação logística e 1000 iterações, com gradiente de 0,044 e tempo de processamento de 57 s, destacando-se pelo melhor desempenho preditivo e capacidade de generalização. A validação realizada com dados dos municípios de Campina Grande (PB), São Carlos (SP) e Curitiba (PR) demonstrou boa aproximação entre valores observados e estimados. Em termos de precisão, a fração de matéria orgânica apresentou erros percentuais reduzidos, da ordem de 0,19%, 2,85% e 7,53%, respectivamente, evidenciando a capacidade da RNA em representar adequadamente os padrões presentes nos dados. Em contrapartida, algumas discrepâncias foram observadas em frações específicas, como na categoria metais para Campina Grande, indicando limitações inerentes à modelagem empírica adotada.

As projeções para 2030 indicaram tendência de redução da fração de matéria orgânica, com quedas de aproximadamente 6,0 pontos percentuais em Campina Grande, 7,4 em São Carlos e 32,0 em Curitiba. Em contrapartida, na categoria “outros” observou-se aumento expressivo, da ordem de 1,8, 3,1 e 21,8 pontos percentuais, respectivamente, reforçando a influência do desenvolvimento socioeconômico na composição dos resíduos. Também foram observados aumentos mais discretos nas frações de papel, papelão e plástico, associados à diversificação dos padrões de consumo, ao desenvolvimento industrial e ao maior uso de embalagens. Tais tendências mostram-se compatíveis com transformações observadas em localidades com maiores níveis de desenvolvimento humano e econômico.

Dessa forma, os objetivos propostos foram alcançados e o método mostrou potencial como ferramenta de apoio ao planejamento da gestão integrada dos RSU, podendo subsidiar estimativas preliminares em municípios sem dados gravimétricos disponíveis, auxiliar no dimensionamento de sistemas de coleta, tratamento e disposição final, além de contribuir para projeções futuras e para a tomada de decisão no planejamento municipal. Embora não substitua integralmente a caracterização in loco, a metodologia apresenta potencial para complementar estudos gravimétricos convencionais, especialmente em contextos de restrição técnica e financeira. Ressalta-se, entretanto, que a precisão das estimativas permanece condicionada à qualidade e representatividade do banco de dados utilizado, de modo que sua ampliação e a atualização futura dos indicadores socioeconômicos poderão contribuir para o aprimoramento das previsões e para a consolidação da aplicação de RNAs na gestão de resíduos sólidos urbanos.

REFERÊNCIAS BIBLIOGRÁFICAS

1. ARAÚJO NETO, Cláudio Luís. Análise do comportamento dos resíduos sólidos urbanos e desenvolvimento de modelos estatísticos para previsão das deformações de aterros sanitários. Dissertação (Mestrado em Engenharia Civil e Ambiental), Universidade Federal de Campina Grande - UFCG, Campina Grande - PB, 2016.

2. ASSOCIAÇÃO BRASILEIRA DE RESÍDUOS E MEIO AMBIENTE (ABREMA). Panorama dos resíduos sólidos no Brasil 2025. São Paulo: ABREMA, 2025.

3. BOSCOV, M. E. G. Geotecnia ambiental. Oficina de Textos, 2008.

4. FEIL, A.; SPILKI, F. R.; SCHREIBER, D. Análise global das características de frações de resíduos urbanos residenciais. Revista Brasileira de Ciências Ambientais (Online), n. 38, p. 63-77, 2015.

5. HAYKIN, S. Redes Neurais: Princípios e prática. Porto Alegre (RS): Editora Brookman, 2001. 900p.

6. INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). Cidades e Estados do Brasil. Rio de Janeiro: IBGE, 2025. Disponível em: https://cidades.ibge.gov.br/. Acesso em: 12 jun. 2026.

7. KIM, Viviane Jin Hee. Análise da composição gravimétrica dos resíduos domiciliares de São Carlos (SP). Tese de Doutorado (Escola de Engenharia de São Carlos). Universidade de São Paulo - USP. 2019.

8. MARTINS, A. C. G.; SIMÕES, A. S.; PRADO, G. I. Classificação de texturas usando redes neurais artificiais e o modelo de Spot Noise. Anais do VI Encontro Nacional de Inteligência Artificial, 2007.

9. MATTEI, G.; ESCOSTEGUY, P. A. V. Composição gravimétrica de resíduos sólidos aterrados. Engenharia Sanitária e Ambiental, v. 12, n. 3, p. 247-251, 2007.

10. NEGOITA, G. A. *et al*. *Deep Learning: a Tool for Computational Nuclear Physics*. *arXiv preprint arXiv*:1803.03215, 2018.

11. OLIVEIRA, B. O. S.; MEDEIROS, G. A. Evolução e desafios no gerenciamento dos resíduos sólidos urbanos nos estados da região Norte, Brasil. Revista Valore, v. 4, n. 1, p. 749–761, 2019. DOI: 10.22408/reva412019211749-761.

12. PAIVA, William de. Aplicação da estatística para descrever o comportamento de um solo expansivo. 2009. 217 f. Tese (Doutorado) - Pós-Graduação em Engenharia Civil, Departamento de Engenharia Civil, Universidade Federal de Pernambuco, Recife, 2009.

13. SÃO MATEUS, Maria do Socorro Costa *et al*. Características dos resíduos sólidos urbanos (RSU) do estado da Bahia e sua correlação com o índice de desenvolvimento humano. In: CONGRESSO BRASILEIRO DE ENGENHARIA SANITÁRIA E AMBIENTAL, 30., 2019, Natal, RN. Anais eletrônicos [...]. Rio de Janeiro: ABES, 2019.

14. TAVARES, Romero Coelho. Composição gravimétrica: uma ferramenta de planejamento e gerenciamento do resíduo urbano de Curitiba e região metropolitana. Dissertação (Programa Profissionalizante em Desenvolvimento de Tecnologia - PRODETEC). Instituto de Tecnologia para o Desenvolvimento (LACTEC) e do Instituto de Engenharia do Paraná (IEP). 2007.

15. *UNITED NATIONS HUMAN SETTLEMENTS PROGRAMME (UN-HABITAT). World Cities Report* 2022: *envisioning the future of cities*. Nairobi: UN-Habitat, 2022.