



UEPB

**UNIVERSIDADE ESTADUAL DA PARAÍBA
CAMPUS I**

**CENTRO DE CIÊNCIAS E TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA SANITÁRIA E AMBIENTAL
CURSO DE GRADUAÇÃO EM ENGENHARIA SANITÁRIA E AMBIENTAL**

EMANUELA FIGUEIREDO ALVES

**DETERMINAÇÃO DA COMPOSIÇÃO FÍSICA DE RESÍDUOS SÓLIDOS
MUNICIPAIS NO BRASIL POR APLICAÇÃO DE MODELAGEM DE REDES
NEURAIS ARTIFICIAIS**

**CAMPINA GRANDE
2022**

EMANUELA FIGUEIREDO ALVES

**DETERMINAÇÃO DA COMPOSIÇÃO FÍSICA DE RESÍDUOS SÓLIDOS
MUNICIPAIS NO BRASIL POR APLICAÇÃO DE MODELAGEM DE REDES
NEURAS ARTIFICIAIS**

Trabalho de Conclusão de Curso (Monografia) apresentado a/ao Coordenação /Departamento do Curso Engenharia Sanitária e Ambiental da Universidade Estadual da Paraíba, como requisito parcial à obtenção do título de graduado em Engenharia Sanitária e Ambiental.

Orientador: Prof. Dr. William de Paiva

Coorientador: Me. Jessica Araújo Martildes Florêncio

**CAMPINA GRANDE
2022**

É expressamente proibido a comercialização deste documento, tanto na forma impressa como eletrônica. Sua reprodução total ou parcial é permitida exclusivamente para fins acadêmicos e científicos, desde que na reprodução figure a identificação do autor, título, instituição e ano do trabalho.

A474d Alves, Emanuela Figueiredo.

Determinação da composição física de resíduos sólidos municipais no Brasil por aplicação de modelagem de redes neurais artificiais [manuscrito] / Emanuela Figueiredo Alves. - 2022.

38 p. : il. colorido.

Digitado.

Trabalho de Conclusão de Curso (Graduação em Engenharia Sanitária e Ambiental) - Universidade Estadual da Paraíba, Centro de Ciências e Tecnologia , 2022.

"Orientação : Prof. Dr. William de Paiva , Coordenação do Curso de Engenharia Sanitária e Ambiental - CCT."

1. Resíduos sólidos urbanos. 2. Composição gravimétrica.
3. RNA. 4. Gestão de resíduos. I. Título

21. ed. CDD 363.728

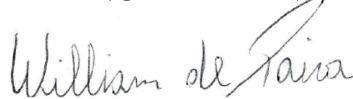
EMANUELA FIGUEIREDO ALVES

DETERMINAÇÃO DA COMPOSIÇÃO FÍSICA DE RESÍDUOS SÓLIDOS MUNICIPAIS
NO BRASIL POR APLICAÇÃO DE MODELAGEM DE REDES NEURAIAS ARTIFICIAIS

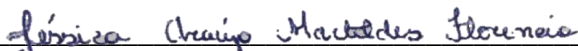
Trabalho de Conclusão de Curso (Artigo)
apresentado a/ao Coordenação /Departamento
do Curso Engenharia Sanitária e Ambiental da
Universidade Estadual da Paraíba, como
requisito parcial à obtenção do título de
graduação em Engenharia Sanitária e
Ambiental.

Aprovada em: 19/07/2022

BANCA EXAMINADORA



Prof. Dr. William de Paiva (Orientador)
Universidade Estadual da Paraíba (UEPB)



Me. Jessica Araújo Martildes Florencio (Coorientador)
Universidade Estadual da Paraíba (UEPB)



Prof. Dr. Whelton Brito dos Santos
Universidade Estadual da Paraíba (UEPB)



Eng. Sanitarista e Ambiental Daniel Epifânio Bezerra
Universidade Federal de Campina Grande (UFCG)

Ao meu grande sonho, em ver meu pai sendo um agricultor, e minha mãe que foi professora de escola rural, ter uma filha formada em Engenharia, DEDICO.

AGRADECIMENTOS

À Deus, por ser sempre meu guia espiritual e fiel companheiro diante todos os momentos da minha vida.

Aos meus pais, Jacinto e Aldemiza, por serem minha base e fortaleza, dedicando todo amor, apoio e incentivo em todos os meus passos. Ao meu irmão, que mesmo distante, mas é a minha extensão além dos meus pais.

Aos meus familiares, em especial aos meus padrinhos Pedro, Graça e Híria, por tanta dedicação com a minha educação.

Aos meus avós paternos, José e Mocinha e tia Lúcia, que me criaram na sua casa como filha sob todos os cuidados e zelo. Assim, como aos meus avós maternos, Rubéns (*in memória*) e Maria, que sempre me acolheram com muito carinho.

Aos meus primos que foram como irmãos e companheiros durante a minha ausência familiar.

Ao meu namorado, Tales, por ser meu aconchego e companhia, fazendo dos meus dias mais leves e divertidos. Assim, como à sua família, que me acolheu com muito respeito e carinho.

Aos meus amigos, Thaís (“do colégio para a vida”), meus “lixinhos” (Taty, Bethy e João), aos que a UEPB me agraciou nesses últimos 4 anos (Milena, Jesielly, Andréia, Luana, Edlayne, João, Júlia, Dany, Carol, Ronny, Jéssica, Wellem, Bruna, Walesca) e a família “Germano” (Rafinha, Kelma, Thalysson, Thiago), entre tantos outros que a vida me contemplou e fizeram dos meus dias mais felizes.

Ao meu orientador Prof. Dr.: Willian de Paiva, pela confiança e apoio no crescimento acadêmico.

À Coordenação do Curso, em especial, aos professores, por todo conhecimento repassado nesse período de aprendizado.

Ao Grupo de Pesquisa em Tecnologia Ambiental – GPTecA, por fornecer apoio em minhas pesquisas e estar presente na construção deste trabalho, assim como ao Grupo de Geotecnia Ambiental - GGA, no nome da Prof. Dra.: Weruschka Escarião, pela oportunidade de amadurecimento acadêmico.

Ao CNPq, pelo apoio financeiro.

À todos, muito obrigado.

LISTA DE FIGURAS

Figura 3 – Esquema de Unidade Processadora de McCulloch e Pitts	16
Figura 4 – Rede Feedforward	17
Figura 5 – Ilustração do algoritmo <i>Backpropagation</i>	18
Figura 6 – Configurações no Matlab	20
Figura 7 – Distribuição regional dos municípios catalogados	22
Figura 8 – Representatividade regional do banco de dados após tratamento.....	25
Figura 9 – Relação dos dados tratados x dados referentes à população	25
Figura 10 – Interface do treinamento da rede selecionada.....	28
Figura 11 – Gráficos da performance na RNA (A) e das regressões na RNA (B) escolhida ..	29

LISTA DE TABELAS

Tabela 1 – Recorte do banco de dados- Camadas de saída (target).....	23
Tabela 2 – Recorte do banco de dados- Camadas de entrada (input).....	23
Tabela 3 – Quantidade de outliers presentes no banco de dados.....	24
Tabela 4 – Resumo do percentual de perda de dados total e em cada região ao fim do tratamento	25
Tabela 5 – Resultados dos treinamentos realizados na RNA escolhida	27
Tabela 6 – Comparativo das Composições gravimétricas geradas para o município de Barra dos Coqueiros (SE) através da RNA escolhida	30

RESUMO

A análise gravimétrica de Resíduos Sólidos Urbanos é uma ferramenta de gestão, que possibilita classificar e distribuir em classificar os percentuais em massa dos constituintes de determinado volume de resíduos distribuídos, porém a composição é uma técnica minuciosa que exige altos custos, sejam de operação e mão de obra, além de uso de EPI's e que se qualifica como insalubre devido os riscos de contaminação da equipe operadora no processo de triagem. Por isso, necessita-se desenvolver tecnologias que visem facilitar o processo da gravimetria, uma das alternativas é a utilização de Redes Neurais Artificiais, que possibilitam simular problemáticas do dia a dia como modelo computacional e que resultam respostas semelhantes aos ensaios físicos feitos em larga escala. Portanto, este trabalho objetiva utilizar dos mecanismos das RNA como ferramenta de gestão para os RSU, simulando dados de composição gravimétrica de municípios fornecendo embasamento para previsão de composição dos RSU. No desenvolvimento deste trabalho, foram aplicados uma metodologia que utiliza como ferramenta base, a modelagem computacional, conhecida como Rede Neural Artificial aplicada por meio do *Software Matlab 2015a*, onde foram importados dados fornecidos por instituições públicas tais como suas respectivas composições gravimétricas de 678 municípios brasileiros, correlacionando seus índices socioeconômicos (PIB, população, taxa de escolaridade, taxa de empregabilidade) e climáticos (temperatura média, pluviosidade, altitude), onde foram tratados e construído um banco de dados para a realização do treinamento das redes neurais estudadas. Com o auxílio do tipo de rede (*Bayesian Regularization*), foram feitas alterações da quantidade de neurônios na camada oculta e o tipo de função de ativação, podendo assim determinar qual rede se adaptava melhor aos dados estudados. Após os treinamentos foi possível identificar a melhor rede segundo análises estatísticas, e fazer comparações com os resultados obtidos pela rede gerada e os demais dados inseridos no banco de dados inicial. E por isso, conclui-se que ao analisar os resultados gerados pelas diversas redes, pode-se inferir que estes não conseguiram ter grande precisão na predição dos dados de saída.

Palavras-chave: Resíduos Sólidos Urbanos; Composição Gravimétrica; Função de ativação.

ABSTRACT

The gravimetric analysis of Municipal Solid Waste is a management tool, which allows classifying and distributing in classifying the mass percentages of the constituents of a given volume of distributed waste, but the composition is a thorough technique that requires high costs, whether of operation and labor, in addition to the use of PPE and that qualifies as unhealthy due to the risks of contamination of the operating team in the screening process. Therefore, it is necessary to develop technologies that aim to facilitate the process of gravimetry, one of the alternatives is the use of Artificial Neural Networks, which make it possible to simulate day-to-day problems as a computational model and result in responses similar to physical tests performed on a large scale. Therefore, this work aims to use the mechanisms of RNA as a management tool for the US, simulating gravimetric composition data of municipalities providing a basis for predicting the composition of the USWs. In the development of this work, a methodology that uses as a basic tool, computational modeling, known as artificial neural network applied through the Matlab 2015a Software, where data provided by public institutions such as their respective gravimetric compositions of 678 Brazilian municipalities were imported, correlating their socioeconomic (GDP, population, schooling rate, employability rate) and climatic (average temperature) and climatic indices (average temperature, rainfall, altitude), where a database was treated and constructed to perform the training of the neural networks studied. With the aid of the network type (Bayesian Regularization), alternation of the amount of neurons in the hidden layer and the type of activation function were made, thus being able to determine which network best adapted to the data studied. After the training, it was possible to identify the best network according to statistical analyses, and make comparisons with the results obtained by the generated network and the other data inserted in the initial database. Therefore, it is concluded that when analyzing the results generated by the various networks, it can be inferred that these could not have great accuracy in the prediction of the output data.

Keywords: Urban Solid Waste; Gravimetric Composition; Activation function.

SUMÁRIO

1	INTRODUÇÃO	10
2	OBJETIVOS	12
2.1	Objetivo geral	12
2.2	Objetivos específicos	12
3	FUNDAMENTAÇÃO TEÓRICA.....	13
3.1	Política Nacional dos Resíduos Sólidos - PNRS	13
3.2	Novo marco legal do saneamento básico	14
3.3	Composição gravimétrica.....	15
3.4	Redes Neurais Artificiais (RNA).....	15
4	METODOLOGIA.....	19
4.1	Construção do banco de dados	19
4.2	Tratamento estatístico dos dados	19
4.3	Construção da rede neural artificial	19
5	RESULTADOS E DISCUSSÕES.....	22
5.1	Criação do banco de dados.....	22
5.2	Tratamento do banco de dados	24
5.3	Testes da RNA.....	26
6	CONSIDERAÇÕES FINAIS	31
7	REFERÊNCIAS	32
8	APÊNDICE A-Análise estatística individual dos dados de entrada e saída	35

1 INTRODUÇÃO

À medida que a humanidade se desenvolvia, grandes mudanças no modo de viver das pessoas começaram a surgir, dentre elas podemos destacar a urbanização, caracterizada pelo êxodo rural e conseqüentemente pelos aglomerados urbanos e o surgimento de processos industriais que desencadeou o consumo desenfreado. Tais mudanças acarretaram um significativo aumento na geração de Resíduos Sólidos Urbanos, ocasionando um grave problema socioambiental, pois há uma incontrolável busca por produção e consumo, e que conseqüentemente geram problemas de saúde pública e impactos ambientais (JACOBI; BESSEN, 2006).

Com isso, surgiram diversas discussões sobre a temática em questão, é notório a mobilização que atrai à atenção dos gestores, sejam eles de órgãos públicos e privados, centros universitários e da sociedade, em busca de meios econômicos, sociais e ambientais que possibilitem manter os atuais padrões de produção e consumo, porém que provoquem uma menor degradação do meio, visto que os dejetos gerados são uma grande preocupação para todos (PEREIRA et al., 2017).

Surgem assim, projetos que idealizam as cidades sustentáveis, possibilitando um crescimento mais equilibrado e justo, garantindo desta forma o futuro das próximas gerações ao disseminar os princípios da sustentabilidade e como estes podem contribuir de forma positiva para tal desenvolvimento (SAETA, 2012).

Das estratégias para o desenvolvimento sustentável tem-se a gestão de resíduos sólidos urbanos devendo ter como base, o uso racional dos recursos naturais além de visar a redução dos resíduos gerados e minimizar os riscos associados ao seu processo de tratamento e que juntos formam a Política Nacional dos Resíduos Sólidos (BRASIL, 2010).

A atual legislação brasileira regulamentada pela Lei Federal nº.12.305/2010 (Política Nacional dos Resíduos Sólidos - PNRS) alterando a lei nº.9.605/1998 e o Decreto Federal nº.7.404/2010, dispõe “não geração, redução, reutilização, reciclagem e tratamento dos resíduos sólidos, bem como disposição final ambientalmente adequada dos rejeitos”, dentre outros objetivos (BRASIL, 2010).

A gestão de Resíduos Sólidos Urbanos (RSU) é um processo dissociado, onde a economia, fatores sociais e climáticos influenciam diretamente da produção dos resíduos em questão, determinando desta forma que o monitoramento seja uma ferramenta fundamental para qualquer estratégia aplicada. Também está associada à uma cadeia de atividades

interrelacionadas, desde a geração do resíduo, passando pela coleta, transferência, processamento e o seu destino final de forma correta (DAS et al., 2019).

Concomitantemente, a análise gravimétrica de RSU é uma ferramenta de gestão, em que possibilita uma “classificação individual e na determinação dos percentuais em massa dos constituintes de determinado volume de resíduos, distribuindo em classes bem definidas como, por exemplo, matéria orgânica, recicláveis e rejeitos”. A partir daí, têm-se uma estimativa e um direcionamento para os seus respectivos tratamentos e destinações para com os resíduos que foram gerados (BOSCOV, 2008 apud BEZERRA, 2020).

No entanto, a composição é uma técnica minuciosa que exige altos custos, sejam de operação e mão de obra, além de uso de EPI's e que se qualifica como insalubre devido os riscos de contaminação da equipe operadora no processo de triagem (BEZERRA, 2020). A heterogeneidade dos materiais analisados também dificulta a execução do ensaio, visto que a origem destes ocorrem em função de diversos aspectos sociais e físicos que impossibilitam de certa forma, na definição de uma amostra representativa (MATTEI; ESCOSTEGUY, 2007).

Por isso, uma alternativa viável é a utilização de modelagem com Redes Neurais Artificiais (RNA), que possibilitam simular problemáticas do dia a dia como modelo computacional e que resultam respostas semelhantes aos ensaios físicos feitos em larga escala. Tal mecanismo consiste em “uma estrutura conexionista, na qual o processamento é distribuído por um grande número de pequenas unidades densamente interligadas, possibilitando entender e emular as propriedades decorrentes do alto grau de paralelismo e conectividade dos sistemas biológicos” (FURTADO, 2019).

Portanto, este trabalho objetiva utilizar RNA como ferramenta de gestão para os RSU, simulando dados de composição gravimétrica de municípios que até então não tiveram seus estudos atualizados para um melhor desenvolvimento sustentável. Além que a aplicação de mecanismos tecnológicos, tais como as redes neurais, são úteis na praticidade de obtenção dos resultados desejados, economizando tempo e investimentos financeiros, contribuindo na gestão operacional dos riscos e dos resíduos em questão.

2 OBJETIVOS

2.1 Objetivo geral

Aplicação de Redes Neurais Artificiais para simular quantitativamente a composição gravimétrica de acordo com as características socioeconômicas e climáticas dos municípios brasileiros.

2.2 Objetivos específicos

- Estudar o comportamento da rede através da modificação de sua arquitetura e do banco de dados utilizado;
- Analisar as métricas de desempenho da RNA, de acordo com os dados reais;
- Realizar previsões de Composições Gravimétricas de RSU em municípios brasileiros.

3 FUNDAMENTAÇÃO TEÓRICA

3.1 Política Nacional dos Resíduos Sólidos - PNRS

A Lei nº 12.305 de 02 de agosto de 2010 em que institui a PNRS, regulamenta de forma estratégica um modelo de gestão integrado, onde hierarquias de prioridades e gerenciamentos dos resíduos sólidos precisam ser atendidos. São instituídos conceitos relacionados ao RSU, desde a não geração, implantação de uma conscientização pela redução, e se assim houver, que possa acontecer a reciclagem, e nos demais, que tenham um tratamento e disposição final de forma ambientalmente adequada, minimizando ao máximo os danos ao meio e que se possa aproveitar ao máximo do poder funcional da matéria até que seja descartada (CEZÁRIO, 2022).

A PNRS define resíduos sólidos em seu art. 3º, inciso XVI, como:

resíduos sólidos: material, substância, objeto ou bem descartado resultante de atividades humanas em sociedade, a cuja destinação final se procede, se propõe proceder ou se está obrigado a proceder, nos estados sólido ou semissólido, bem como gases contidos em recipientes e líquidos cujas particularidades tornem inviável o seu lançamento na rede pública de esgotos ou em corpos d'água, ou exijam para isso soluções técnica ou economicamente inviáveis em face da melhor tecnologia disponível (BRASIL, 2010).

É definido também no art. 3º, inciso X que:

O gerenciamento de resíduos sólidos: conjunto de ações exercidas, direta ou indiretamente, nas etapas de coleta, transporte, transbordo, tratamento e destinação final ambientalmente adequada dos resíduos sólidos e disposição final ambientalmente adequada dos rejeitos, de acordo com plano municipal de gestão integrada de resíduos sólidos ou com plano de gerenciamento de resíduos sólidos, exigidos na forma desta Lei (BRASIL, 2010).

As destinações finais dos resíduos no país variam entre lixões, aterros controlados e aterros sanitários, onde as 2 (duas) primeiras opções são tecnicamente inviáveis ao meio ambiente, causando insegurança na integridade do meio exposto e à população local. Segundo estudos realizados pela Associação Brasileira de Empresas de Limpeza Pública e Resíduos Especiais (Abrelpe), existem grandes problemáticas associadas em todo o gerenciamento em questão, desde o grande contingente de pessoas não atendidas aos serviços relacionados como as formas de disposição destes (ABRELPE, 2019).

Assim, os aterros sanitários são constituídos como a melhor forma ambientalmente adequada para a disposição final, em que são definidos como técnicas de engenharia que possibilitam o acondicionamento dos resíduos em uma menor área possível e que possam ser reduzidos ao menor volume permissível. É necessário que sua implantação ocorra de forma

segura, estejam dispostos e tratados sob áreas licenciadas por órgãos ambientais e que não causem danos à saúde pública e segurança dos demais (ABNT, 1992).

A PNRS institui que aconteça uma melhor integração com as demais legislações em vigor, à exemplo tem-se a Política Nacional do Meio Ambiente que se articula com a Política Nacional de Educação Ambiental (Lei nº 9.795, de 27 de abril de 1999), além da Política Federal de Saneamento Básico (Lei nº 11.445, de 2007) e com a Lei nº 11.107, de 6 de abril de 2005, segundo o art. 5º (BRASIL, 2010).

3.2 Novo marco legal do saneamento básico

A Lei nº 14.026, de 15 de julho de 2020 há uma designação que saneamento básico consiste em um conjunto de serviços públicos, sejam eles infraestruturas e de instalações operacionais que englobam abastecimento de água potável, esgotamento sanitário, limpeza urbana e o manejo adequado dos resíduos sólidos e da drenagem e manejo das águas pluviais urbanas (OAB, 2020).

Tal lei visa atualizar o marco legal do saneamento básico brasileiro, instituindo diversas mudanças no gerenciamento de determinados recursos naturais destinados ao bem-estar da população. Dentre essas mudanças pode-se citar a atribuição de competências para a ANA, vedar a administração de determinados contratos, além de aprimorar como deverão acontecer as condições estruturais do saneamento básico nacional, concernindo assim, os prazos referentes às disposições finais de rejeitos, o que causa mudanças na PNRS, e por fim, a autorização de financiamentos de serviços técnicos especializados (BRASIL, 2020).

No art. 54º, também detalha-se os prazos que deverão ser obedecidos quanto ao fechamentos de lixões no país segundo o novo marco do saneamento legal, no qual foi embasado nas determinações feitas anteriormente pela PNRS, que havia firmado o prazo para capitais até 2018 e para os demais municípios menores essa data estava para 2021, no entanto, com a aprovação da atual lei, foram redefinidos novos prazos, para as capitais o prazo estendeu-se até 2021 e 2024 para os municípios com até 50 mil habitantes (BRASIL, 2020).

Assim, a nova legislação promete possibilitar o direito universal a todos os cidadãos aos serviços de saneamento básico, principalmente as comunidades de baixa renda de núcleos urbanos informais consolidados ou não e que não se encontrem em situações de risco (OAB, 2020).

3.3 Composição gravimétrica

A composição gravimétrica compreende a caracterização dos resíduos sólidos, expressando o percentual de cada um dos componentes presentes no resíduo em relação ao peso total da amostra em análise. Com isso, pode-se afirmar que é uma técnica em que se estima o percentual dos componentes gerados de um determinado local (MOURA et al., 2012).

Através desta avaliação é possível pontuar certas problemáticas ambientais que são indispensáveis ao processo de gerenciamento dos RSU. Pode-se afirmar que a gravimetria expõe um retrato real da situação em questão, permitindo que pontos de solução sejam discutidos para um melhor manejo sustentável (OLIVEIRA et al., 2021). A sua variabilidade ocorre em função de fatores socioeconômicos e ambientais.

Com isso a composição tem a amostragem como um dos passos para a sua realização e que consiste na coleta de uma quantidade representativa do resíduo podendo assim determinar as características materiais e seus respectivos tratamentos. A Norma NBR 10007: “Amostragem de resíduos sólidos” define quarteamento como:

Processo de divisão em quatro partes iguais de uma amostra pré-homogeneizada, sendo tomadas duas partes opostas entre si para constituir uma nova amostra e descartadas as partes restantes. As partes não descartadas são misturadas totalmente e o processo de quarteamento é repetido até que se obtenha o volume desejado.

Ao estudar a disposição dos RSU, quantificando-os, é possível analisar o crescimento ou diminuição da geração dos mesmos, possibilitando ter um indicador causal e possíveis projeções ao longo dos anos, auxiliando assim, no processo de gerenciamento que inclui desde a coleta seletiva ao dimensionamento da vida útil do aterro (CEZARIO, 2022).

Porém a composição apresenta alguns percalços no decorrer da sua realização, dentre eles pode-se citar os altos custos com mão de obra operária, maquinários e equipamentos que auxiliam na realização da atividade. Devido a heterogeneidade dos materiais há uma certa dificuldade na execução além de se enquadrar como um ambiente insalubre, colocando em riscos os trabalhadores atuantes na área.

3.4 Redes Neurais Artificiais (RNA)

As redes neurais artificiais compõem uma das vertentes pertencentes à simulação cognitiva, técnica esta, que possibilita a imitação de certas estruturas e dos seus mecanismos de


raciocínio pelos operadores no cumprimento de suas atividades baseados nos conceitos desenvolvidos na modelagem cognitiva. Assim, ela possui uma estrutura conexionista, operando sob um processamento compartilhado por diversas unidades de pequeno porte, mas que estão densamente interligadas (FURTADO, 2019).

RNA é definida como uma técnica computacional que apresenta um modelo inspirado nas estruturas neurais biológicas dos seres inteligentes e que estes adquirem conhecimento através das experiências, através dos algoritmos de aprendizagem (SANTOS, 2015). A aprendizagem é baseada em experimentos nos quais as RNA coletam, utilizam e armazenam informações e que este processo é realizado através de algoritmos de aprendizagem, determinando que os pesos sinápticos da rede são modificados de uma forma ordenada para alcançar o resultado desejado (MATSUNAGA, 2012).

O aprendizado das redes neurais pode ser classificado em supervisionada ou não supervisionada. Quando for aplicado o aprendizado supervisionado, confere-se o quanto a rede está próxima de uma solução aceitável, ajustando os pesos entre os neurônios no treinamento para que se tenha uma menor diferença entre as saídas desejadas. (MATSUNAGA, 2012). Enquanto que no não supervisionado, inicialmente, as saídas da rede são desconhecidas, é necessário que ocorra uma adaptação dos sinais, processando as entradas, detecte-se regularidades e posteriormente com o auxílio de algoritmos de aprendizado (baseados geralmente em conceitos de vizinhança e agrupamento), aconteça o ajuste da rede baseada em regularidades estatísticas dos dados de entrada, criando categorias, que otimizam em relação aos parâmetros livres da rede uma medida da quantidade que é independente da tarefa a ser executada (HAYKIN, 2008).

A estrutura lógico-matemática semelhante ao neurônio biológico composta por estruturas como o axônio e soma, onde ocorrem sinapses entre os axônios e o corpo celular de um outro neurônio qualquer possibilitando que caso esse impulso alcance um certo nível de excitação, ocorre a transmissão de informação (MCCULLOCH; PITTS, 1943)

Figura 1 – Esquema de Unidade Processadora de McCulloch e Pitts




Fonte: Rosa (2012).

A Figura 3 representa o neurônio de *McCullock e Pitts*, em que estão expostos a entrada x_j interligados ao sinal da entrada apresentado à sinapse j , que conecta ao neurônio k , multiplicado por um peso sináptico w_{kj} . A partir daí, no neurônio k , ocorre a soma ponderada dos sinais recebidos e produz um determinado nível de atividade a ser analisada. Se caso o nível de atividade exceder um certo limite, a unidade processadora produzirá uma determinada resposta como saída (FURTADO, 2019).

As redes *feedforward* (Figura 4) configuradas de forma unidirecionais (o sentido dos dados é sempre das unidades entrada para as unidades de saída), variando em camadas simples ou com multicamadas e nelas não existem laços de realimentação (ROCHA, 2019).

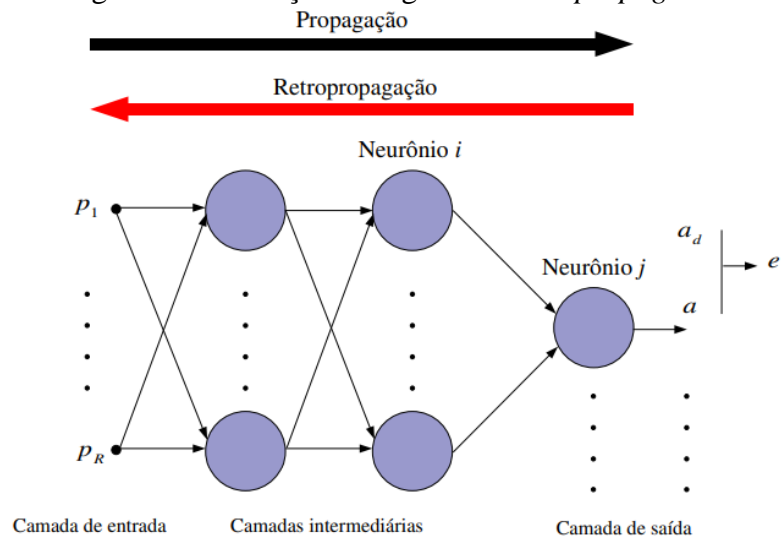
Figura 2 – Rede Feedforward



Fonte: Rocha (2019).

O algoritmo *backpropagation* (Figura 5) acontece em 2 (dois) passos, sendo o primeiro em que visa achar de forma iterativa a mínima diferença entre as saídas desejadas e as saídas obtidas pela rede neural, e estas com o mínimo de erro e , posteriormente, é ajustado os pesos das conexões sinápticas entre as camadas através da retropropagação do erro encontrado em cada iteração (MATSUNAGA, 2012).

Figura 3 – Ilustração do algoritmo *Backpropagation*



Fonte: Matsunaga (2012).

A aplicação da função de ativação visa limitar a saída do neurônio e introduzir a não-linearidade ao modelo. Assim como descritos nos neurônios biológicos que disparam quando as somas dos impulsos recebidos ultrapassam o limiar de excitação, o neurônio artificial é emulado por mecanismos simples que fazem a soma de tais valores recebidos (soma ponderada) e a partir daí, o neurônio decide se dispara ou não, onde suas saídas podem ser iguais à 0 ou 1. Dentre as funções de ativação, pode-se citar *sigmoidal* (logsig), tangente hiperbólica (tansig), linear (purelin).

4 METODOLOGIA

4.1 Construção do banco de dados

À princípio foi realizado uma catalogação bibliográfica sobre 668 municípios brasileiros que possuíam os registros dos seus Planos de Gerenciamento de Resíduos Sólidos Urbanos (PGRSU), para assim poder extrair os dados das suas respectivas composições gravimétricas, nas quais foram subdivididas em 6 (seis) categorias de classificação de resíduos (Papel, Plástico, Metal, Vidro, Matéria Orgânica e Outros). Vale salientar que boa parte das contribuições destes dados foram obtidos dos Planos Estaduais de Resíduos Sólidos (PERS), assim como de publicações científicas relacionadas à composição dos resíduos de determinados municípios. Também foram pesquisados dados socioeconômicos (PIB, População, Taxa de Emprego e Escolaridade) e climáticos (Temperatura, Pluviosidade e Altitude), obtidos através de bases como o IBGE e CLIMATE-DATE.ORG, em que foram aplicados como dados de entrada para a modelagem da RNA.

Após a coleta, os registros foram tabulados no software Microsoft *Excel 365* e normalizados, permitindo assim a eliminação de dados inconsistentes.

4.2 Tratamento estatístico dos dados

Para realização dessa etapa foram utilizados os softwares de fácil acesso *Microsoft Excel 365* e *Past*. O primeiro se trata de um editor de planilhas de ampla utilização e o segundo de um software de estatística com código livre.

Com o auxílio dos softwares mencionados foram realizadas análises descritivas dos dados com plotagem de gráficos auxiliares (*bloxpot*, dispersão, histograma, linhas) para inferir o comportamento dos dados e realizar a identificação de *outliers* para posterior remoção e redução das inconsistências.

4.3 Construção da rede neural artificial

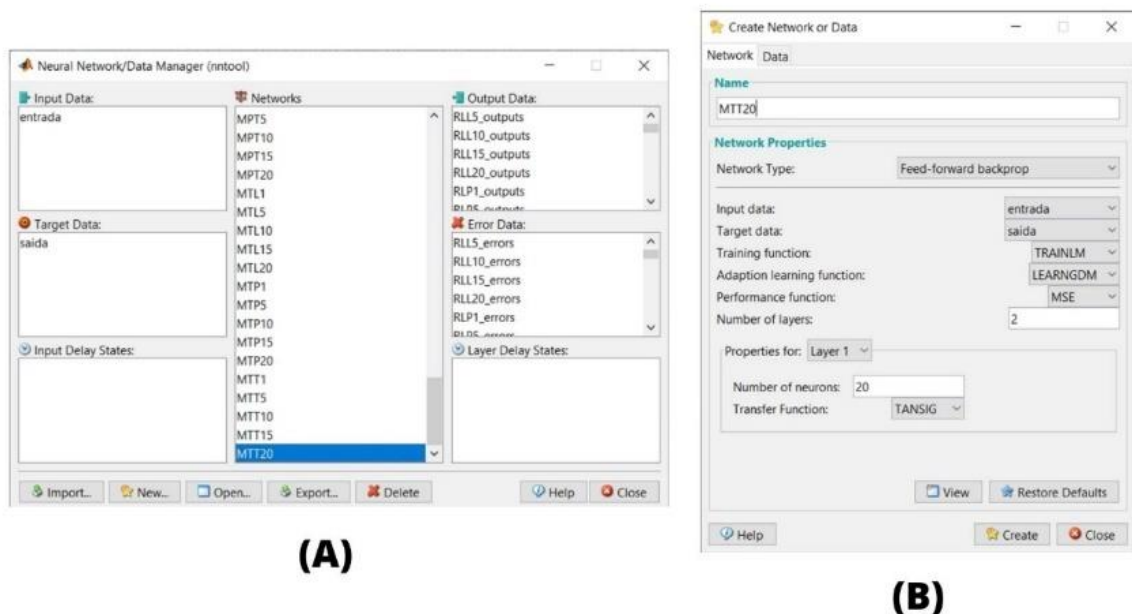
Para o desenvolvimento da rede neural foi utilizado o software *Matlab R2018a*, software desenvolvido pela *The MathWorks, Inc*, consiste em um sistema interativo com uma linguagem de programação baseados numa matriz, em que as soluções e problemas são expressos em

linguagem matemática. Com o auxílio desta ferramenta é possível realizar análise numérica, operações com matrizes, construção de gráficos e criação de interfaces com o usuário. Também são disponibilizadas diversas bibliotecas ou ferramentas (*toolboxes*) para aplicações específicas, à exemplo, as Redes Neurais, que pode ser através da interface gráfica *NNTool* (*Neural Network Toolbox*) permitindo importar, criar, utilizar e exportar dados de redes neurais e o seu acesso é realizado digitando *nntool* na janela de comandos do *MATLAB*.

Foram definidos os dados de entrada (*input*) da RNA correspondendo aos dados socioeconômicos (PIB, População, Taxa de Emprego e Escolaridade) e climáticos (Temperatura, Pluviosidade e Altitude) e os dados coletados da composição gravimétrica foram definidos como as camadas de saída (*target*), como demonstrado na Figura 6A.

Para a definição do modelo que apresentasse as melhores configurações de cada uma das redes no processamento, foram aplicados a variação intercalada dos algoritmos de treinamentos *Byesian Regularization* com as funções de ativação LOGSIG, PURELIN e TANSIG, além da quantidade de neurônios (1,7,14 e 20) da Camada Oculta, totalizando 36 configurações diferentes de redes neurais possíveis para análise (Figura 6B).

Figura 4 – Configurações no Matlab



Fonte: Autor (2022).

O processamento foi efetuado com o auxílio da ferramenta *nntool* dentro da interface do *software* que permite treinar as RNA modeladas. Após os testes, foi verificado qual configuração apresentou os melhores resultados estatísticos, e conseqüente seria definido a rede


destinada para a aplicação e confirmação da veracidade do sistema. Onde foram inseridos dados de entrada de um município que não estava contido no banco de dados inicial, possibilitando assim que a rede escolhida respondesse com a sua respectiva composição gravimétrica.

5 RESULTADOS E DISCUSSÕES

5.1 Criação do banco de dados

Ao todo foram catalogados 668 municípios brasileiros distribuídos nas 5 (cinco) regiões demográficas (Norte, Nordeste, Centro-Oeste, Sudeste e Sul), em que estão representados graficamente segundo a concentração em cada uma das regiões na Figura 7.

Figura 5 – Distribuição regional dos municípios catalogados



Fonte: Autor (2022).

Ao analisar a Figura 7 é possível perceber que a Região Nordeste concentra o maior registro de dados referentes à gestão, controle e análise de RSU no país. Nessa classificação seguem quase que uniformemente as regiões Sul, Sudeste e Centro-Oeste respectivamente, enquanto a região Norte, apresentou o menor índice de registros, visto que é uma região onde ocorre maior déficit na gestão de RSU. Entretanto, por mais que estes valores ainda estejam abaixo da média nacional, pode-se afirmar que houve avanços após a implantação da PNRS (OLIVEIRA; MEDEIROS, 2019).

Porém, cabe ressaltar que diante do cenário onde se busca a representatividade da amostra a níveis nacionais, a lacuna de dados entre as regiões se torna um importante ressalva a ser levada em consideração.

As tabelas a seguir apresentam um pequeno recorte do banco de dados utilizados para trabalho na RNA. Na Tabela 1 estão listados os dados referentes as composições gravimétricas dos municípios, as quais serão tratadas como as “camadas de saída” (*target*) na elaboração da rede neural. Já na Tabela 2 consta recorte dos dados de índices socioeconômicos e indicadores climáticos tratados como “camadas de entrada” (*input*).

Tabela 1 – Recorte do banco de dados- Camadas de saída (target)

Região	Município	Composição (%)					
		Papel/Papelão	Plástico	Vidro	Metal	Matéria Orgânica	Outros
SUDESTE	Belo Horizonte	9,5	10,9	2,9	2,3	61,6	7,5
	Campinas	16,2	16,3	1,2	1,3	47,2	17,8
	São Gonçalo	14,0	17,0	3,0	1,5	58,5	6,0
NORTE	Rio Branco	17,9	16,1	1,1	2,0	46,8	16,1
	Palmas	9,8	14,8	0,6	3,0	70,7	1,2
	Ji- Paraná	12,0	7,5	2,0	2,2	66,7	9,6
SUL	Santa Maria	13,1	13,5	2,4	2,9	51,6	16,5
	Florianópolis	33,0	15,0	13,0	12,0	19,0	8,0
	Maringá	11,7	16,7	5,0	4,4	40,1	22,1
GENTRO OESTE	Distrito Federal	7,5	16,7	1,9	3,6	54,0	16,3
	Paranaíba	9,2	16,9	2,2	1,7	60,2	9,8
	Barão de Melgaço	12,0	12,0	4,0	3,0	63,0	6,0
NORDESTE	Formosa	12,7	17,9	2,5	1,9	55,1	9,8
	Cururupu	11,7	15,0	3,4	2,0	36,7	31,3
	Parnaíba	7,0	17,0	1,0	2,0	57,0	16,0
	Pereiro	17,0	11,0	3,0	4,0	57,0	8,0
	Nísia Floresta	18,9	7,7	1,2	0,8	55,1	16,3
	Barra de São Miguel	10,1	21,8	2,8	3,7	26,8	34,9
	Lajedo	10,0	13,4	1,9	3,2	60,6	10,9
	Anadia	9,2	21,1	1,7	1,6	48,5	17,9
	Itapetinga	16,1	4,3	1,8	2,0	50,6	25,2
	Aracaju	4,6	9,4	0,7	0,7	59,2	25,4

Fonte: Autor (2022).

Tabela 2 – Recorte do banco de dados- Camadas de entrada (input)

Região	Município	Indicadores Socioeconômicos				Indicadores Climáticos		
		PIB (R\$)	Pop.	Tx. Emp.(%)	Esc. (%)	Prec. (mm)	T (°C)	Alt. (m)
SUDESTE	Belo Horizonte	36.759,66	2375151	58	98	1600	21,00	857
	Campinas	51.417,44	1080113	38,7	96	1462	21,30	685
	São Gonçalo	17.167,60	999728	11,3	96,7	1709	23,00	19
	Rio Branco	22.287,70	407319	25,7	95,1	1806	25,50	136
	Palmas	32.293,39	228332	48,3	98	1977	26,80	255
	Ji- Paraná	26.287,35	128969	25,3	96,6	1805	26,00	141
SUL	Santa Maria	27.785,51	282123	29	98,1	1838	19,00	153
	Florianópolis	42.719,16	500973	63,9	98,4	1506	20,80	17
	Maringá	48.187,98	81475	26,9	97,4	1768	21,10	5
GENTRO OESTE	Distrito Federal	23.740,39	40192	23,2	97,5	1455	23,00	474
	Paranaíba	34.043,66	46424	21,3	97	1536	23,00	362
	Barão de Melgaço	31.601,74	16219	9,3	94,3	1796	25,40	360
NORDESTE	Formosa	41.815,21	176424	25,5	97	1493	23,40	748
	Cururupu	24.333,00	41152	50,97	96,90	1587	28,38	87,95
	Parnaíba	13.772,41	4543	58,49	99,52	879	27,29	35,79
	Pereiro	12.371,15	197965	65,64	96,75	740	26,00	407,08
	Nísia Floresta	6.883,14	13949	44,64	94,99	358	25,58	8,05
	Barra de São Miguel	6.716,34	2590	46,99	98,45	785	27,33	456,66
	Lajedo	9.029,98	2088	68,37	97,97	494	26,33	245
	Anadia	17.034,15	3522	64,11	99,02	644	25,92	269,11
	Itapetinga	14.145,91	4556	49,31	95,50	1268	25,42	4,29
	Aracaju	13.524,00	6313	56,30	95,64	967	25,46	11,05

Fonte: Autor (2022).

5.2 Tratamento do banco de dados

Para cada conjunto de dados de entradas e saídas foi realizada análise individual do comportamento dos dados resultando no Apêndice A que seguem anexados ao fim deste trabalho. Ao verificar os dados de estatística descritiva foi possível averiguar a existência de grande variância em praticamente todas as séries. Além disso, os gráficos de *bloxpot* apresentaram quantidade significativa de *outliers*, os quais seguem resumidos na Tabela 3, onde ainda são apresentados representação percentual dos *outliers* para cada amostra.

Tabela 3 – Quantidade de outliers presentes no banco de dados

	Total da amostra	Nº de outliers	Percentual (%)
Papel	668	26	3,89
Plástico	668	44	6,59
Vidro	668	38	5,69
Metal	668	51	7,63
Mat. Org.	668	59	8,83
Outros	668	50	7,49
PIB (R\$)	668	51	7,63
Pop. Total	668	597	89,37
Tx. de emp. (%)	668	0	0,00
Escol. (%)	668	56	8,38
Precip. (mm)	668	16	2,40
Temp. (°C)	668	59	8,83
Altitude (m)	668	6	0,90


Fonte: Autor (2022).

Em análise aos dados foi ainda possível verificar que a série de dados “População” possui quantidade discrepante de *outliers*. Essa característica se dá pela heterogeneidade inerente à série, pois, temos dados de grandes centros urbanos e de municípios de pequeno porte. Nesse caso, em especial, foi necessária realizar uma redução na série de dados de forma a garantir uma menor amplitude. A redução foi realizada seguindo os parâmetros de retirada gradual dos 10 (dez) dados de valores máximo e mínimos com posterior análise da quantidade de *outliers* da amostra resultante. Realizando esse processo, a quantidade de *outliers* caiu exponencialmente de forma que ao remover 60 (sessenta) dados extremos (30 maiores e 30 menores), encontrou-se um número de 74 (setenta e quatro) *outliers* e qualquer redução acima dessa quantia não reduziria significativamente as discrepâncias.

O resultado após tratamento dos dados foi de um total de 381 amostras, nas quais foram realizados os demais passos para treinamento da rede neural. Nas Figuras 8 e 9, podem ser visualizadas a representatividade regional das amostras após tratamento dos dados e na Tabela 4, há um resumo com o percentual de perda de dados total e em cada região ao fim do

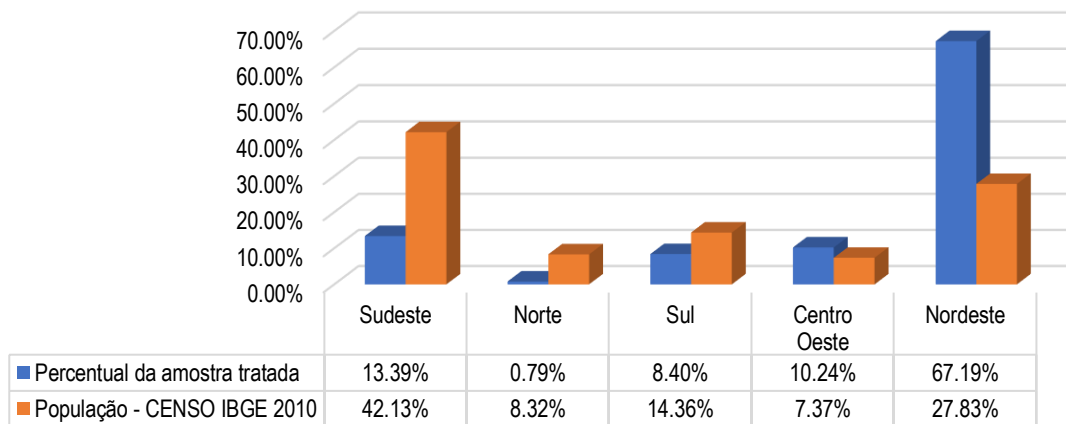
tratamento. Nota-se que ao todo há uma redução de 43% dos dados inicialmente catalogados ocorrendo ainda uma perda desproporcional de dados por região, como a Região Norte, onde houve uma redução de 87,50% dos dados catalogados.

Figura 6 – Representatividade regional do banco de dados após tratamento



Fonte: Autor (2022).

Figura 7 – Relação dos dados tratados x dados referentes à população



Fonte: Autor (2022).

Tabela 4 – Resumo do percentual de perda de dados total e em cada região ao fim do tratamento

Região	Nº de dados Iniciais	Nº de dados tratados	Percentual da amostra tratada	Percentual de redução de dados	População (IBGE, 2010)
Sudeste	92,00	51,00	13,39%	-44,57%	42,13%
Norte	24,00	3,00	0,79%	-87,50%	8,32%
Sul	104,00	32,00	8,40%	-69,23%	14,36%
Centro Oeste	71,00	39,00	10,24%	-45,07%	7,37%
Nordeste	377,00	256,00	67,19%	-32,10%	27,83%
Total	668,00	381,00		-43%	

Fonte: Autor (2022).

Cabe destacar ainda que todas as análises descritivas e gráficas foram refeitas com os dados tratados e testes de normalidade foram aplicados as séries, juntamente com a análise do histograma. Os testes de normalidade acusaram que os dados não se encaixam na distribuição normal, sendo necessária a normalização dos dados para prosseguimento das análises.

As amostras foram padronizadas de forma a haver ajustes entre escalas, fator fundamental para uso de dados em algoritmos de RNA. A normalização dos dados foi feita através do método “Min-Max”, $X_i' = (x_i - x_{\min}) / (x_{\max} - x_{\min})$, onde: x_i : o valor à ser configurado; x_{\min} e x_{\max} : é o menor e o maior valor da série selecionada, e estes valores devem ficar entre 0 e 1.

5.3 Testes da RNA

Os resultados obtidos através dos treinamentos da RNA estão expostos na Tabela 5, onde estão descritas as variações de funções de ativações, quantidade de neurônios das camadas ocultas e o algoritmo de treinamento compondo assim a configuração de uma das 36 (trinta e seis) redes operadas. Após os treinamentos foram obtidos o tempo de execução, a performance, o gradiente, R^2 para o algoritmo de treinamento *Byesian Regularization*.

Tabela 5 – Resultados dos treinamentos realizados na RNA escolhida

		Camadas Ocultas	Rede	Iterações	Segundos	Performance	Gradiente	μ	R(Training)	R(Test)	R(All)	
TRAIN BR	LOGSIG	logsig	1	RLL1	0	0	0,061	3,31E-09	0,005	-0,15554	-0,16456	-0,15682
			7	RLL7	383	1	0,0563	0,00254	5E+10	0,44559	0,52504	0,457
			14	RLL14	217	3	0,0586	0,0000802	5E+10	0,45635	0,43744	0,45331
			20	RLL20	2	0	0,0586	0,0000641	5E+10	0,44003	0,43657	0,43944
		purilin	1	RLP1	69	0	0,035	0,000293	5E+10	0,52181	0,51714	0,52048
			7	RLP7	1000	7	0,0369	0,000455	0,005	0,52022	0,57672	0,52818
			14	RLP14	278	4	0,0279	0,000273	5E+10	0,66617	0,45125	0,63415
			20	RLP20	905	19	0,0358	0,000438	5E+10	0,53338	0,49895	0,52815
		tansig	1	RLT1	143	0	0,0368	0,000293	5E+10	0,51772	0,53651	0,52049
			7	RLT7	249	1	0,033	0,000252	5E+10	0,5869	0,57906	0,58572
			14	RLT14	273	4	0,0274	0,00026	5E+10	0,67002	0,37955	0,62577
			20	RLT20	311	7	0,0269	0,000325	5E+10	0,67756	0,4908	0,64807
		Camadas Ocultas	Rede	Iterações	Segundos	Performance	Gradiente	μ	R(Training)	R(Test)	R(All)	
TRAIN BR	PURILIN	logsig	1	RPL1	161	0	0,0601	0,0000607	5E+10	0,44519	0,40771	0,43975
			7	RPL7	353	2	0,0585	0,000133	5E+10	0,4567	0,43605	0,45212
			14	RPL14	787	10	0,0576	0,000136	5E+10	0,46973	0,40118	0,45941
			20	RPL20	209	4	0,0587	0,000137	5E+10	0,46769	0,41709	0,46005
		purilin	1	RPP1	1000	3	0,035	0,000513	0,00005	0,5434	0,39537	0,52057
			7	RPP7	1000	7	0,0356	0,000856	0,00005	0,53386	0,4997	0,52856
			14	RPP14	1000	14	0,0365	0,00085	5E-06	0,53526	0,48943	0,52894
			20	RPP20	1000	20	0,0354	0,000828	5E-06	0,52857	0,53334	0,52922
		tansig	1	RPT1	1000	3	0,0364	0,000517	0,00005	0,5224	0,51712	0,52148
			7	RPT7	1000	7	0,0366	0,000856	0,00005	0,52816	0,53314	0,52886
			14	RPT14	1000	12	0,0362	0,00099	0,00005	0,52928	0,52122	0,52781
			20	RPT20	1000	19	0,0359	0,000854	1,00E-20	0,53504	0,4951	0,52909
		Camadas Ocultas	Rede	Iterações	Segundos	Performance	Gradiente	μ	R(Training)	R(Test)	R(All)	
TRAIN BR	TANSIG	logsig	1	RTL1	168	0	0,0584	0,0000384	5E+10	0,44589	0,46045	0,44577
			7	RTL7	402	2	0,0585	0,000175	5E+10	0,47604	0,47157	0,47503
			14	RTL14	860	10	0,0588	0,000204	5E+10	0,48436	0,39819	0,47245
			20	RTL20	311	6	0,0585	0,000196	5E+10	0,47323	0,47527	0,47346
		purilin	1	RTR1	127	0	0,0372	0,000531	5E+10	0,52111	0,52168	0,52103
			7	RTP7	210	1	0,0338	0,000614	5E+10	0,57928	0,54253	0,57383
			14	RTP14	29	2	0,0296	0,000643	5E+10	0,64598	0,45633	0,61723
			20	RTP20	18	18	0,0352	0,000715	0,5	0,55671	0,51534	0,55102
		tansig	1	RTT1	482	1	0,0371	0,000522	1E+10	0,51694	0,54175	0,5205
			7	RTT7	265	1	0,033	0,000611	5E+10	0,58707	0,44275	0,56588
			14	RTT14	436	5	0,0286	0,000552	5E+10	0,65357	0,49613	0,62871
			20	RTT20	674	15	0,026	0,000617	5E+10	0,69665	0,36044	0,64194

Fonte: Autor (2022).

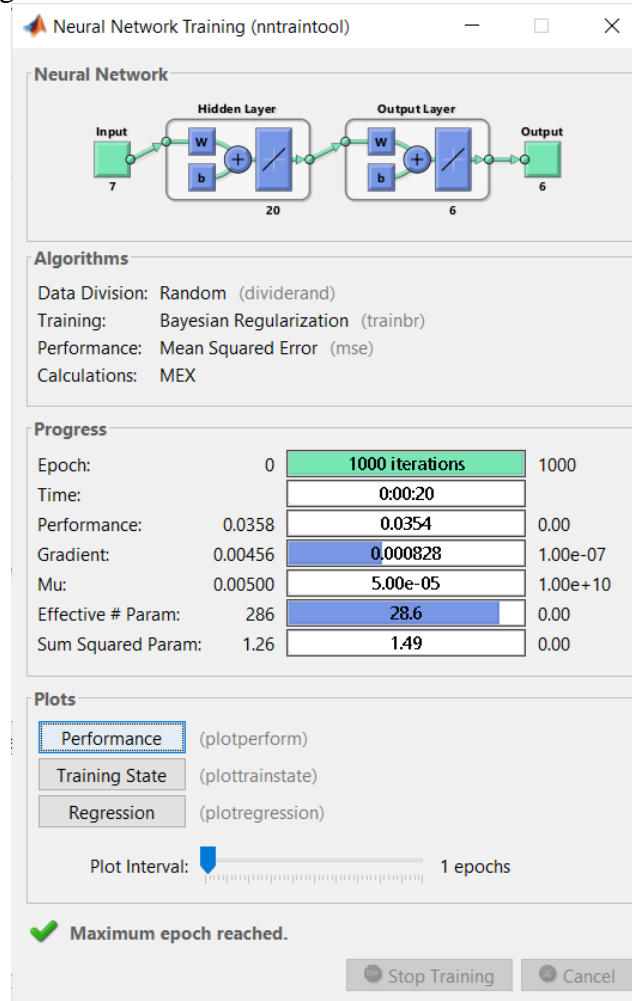
Os treinamentos que obtiveram os melhores desempenhos estavam definidos pela RNA denominada RPP20, configurada com 2 (duas) funções de ativação, sendo elas *Purelin* e *Purelin*, contendo 20 (vinte) neurônios na camada oculta e que resultaram em um $R^2 = 0,5292$ (52,92%). Este coeficiente definido como “coeficiente de determinação no qual implica na “medida estatística de quão próximos os dados estão da linha de regressão ajustada”, isto

configura a porcentagem da variação da variável resposta que é explicada por um modelo linear. Além que quanto maior o valor desse coeficiente, melhor o modelo se ajusta aos dados (MINITAB, 2022). Pode-se observar que dentre os R^2 obtidos tem-se valores maiores ao escolhido para teste, porém ao comparar aos R^2 de Treinamento e Teste têm uma variação que implica na funcionalidade da rede.

Também foi analisado quanto a performance, e foi estabelecido que o mais próximo ao menor valor encontrado para a performance, seria definido como o parâmetro para escolha da rede de melhor desempenho associado à análise do R^2 . O treinamento realizado por meio do algoritmo *Backpropagation* têm-se que o ajuste dos pesos é realizado pelo método do gradiente descendente, o que configura a rede em questão.

A interface do treinamento da rede gerada na plataforma detalhando os resultados obtidos está exposto na Figura 10.

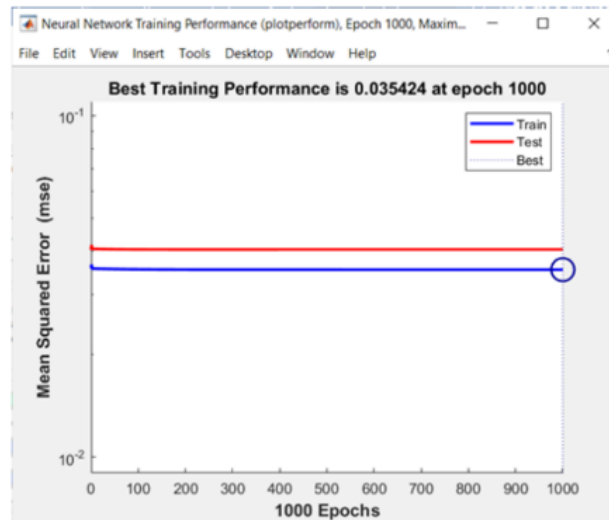
Figura 8 – Interface do treinamento da rede selecionada



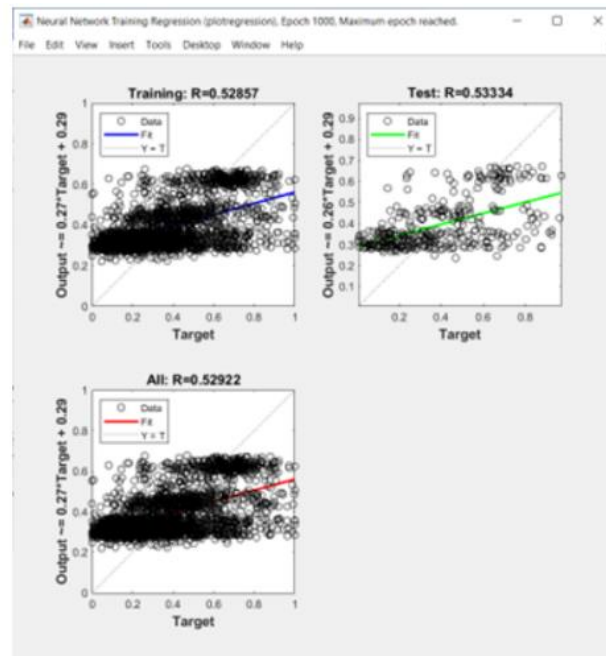
Fonte: Autor (2022).

Também foram gerados gráficos através da ferramenta *ntool* em que detalha a performance da RNA (Figura 11A) e os seus respectivos gráficos das regressões (Figura 11B).

Figura 9 – Gráficos da performance na RNA (A) e das regressões na RNA (B) escolhida



A



B

Fonte: Autor (2022).

Para a verificação do desempenho da rede em questão, foram atribuídos os valores referentes aos indicadores socioeconômicos e climáticos de um determinado município escolhido aleatoriamente que estava contido no banco de dados inicial, mas que não foi incluído no banco de testes, o que possibilitou que a rede neural gerasse a composição gravimétrica como camada de saída.

Após o treinamento foi constatado que os valores obtidos apresentavam uma certa concordância quando comparado à realidade, visto que foi possível compará-los à composição gravimétrica inicial e apresentava características socioeconômicas e físicas semelhantes ao município de teste. A Tabela 6 expõe os dados obtidos no treinamento realizado através do *software Matlab*.

Tabela 6 – Comparativo das Composições gravimétricas geradas para o município de Barra dos Coqueiros (SE) através da RNA escolhida

	Papel/Papelão	Plástico	Vidro	Metal	Matéria Orgânica	Outros
Composição inicial	10,10	11,50	2,15	2,35	39,09	34,81
Composição gerada normalizada	0,32	0,43	0,29	0,31	0,63	0,33
Composição gerada final	7,25	11,84	1,75	1,87	60,42	13,50

Fonte: Autor (2022).

6 CONSIDERAÇÕES FINAIS

Ao analisar os resultados gerados pelas diversas redes, pode-se inferir que estes não conseguiram ter grande precisão na predição dos dados de saída. Algumas ressalvas acerca do banco de dados podem ter significativo papel no erro ocasionado. Pois, conforme análise inicial, há grande variância nos dados socioeconômicos, fruto da própria discrepância e desigualdade presente no país.

Nesse caso, uma forma de contornar a situação, seria a adoção de um índice representativo dos fatores socioeconômicos como o IDHm utilizado em trabalho realizado por Bezerra (2020), já que uma redução maior no banco de dados poderia levar a uma maior perda de representatividade das regiões do país.

Uma alternativa seria a redução das variáveis de saída através da categorização da composição dos resíduos em grupos de maior relevância sejam matéria orgânica, a qual tem grande influência na geração de metano e por consequência no potencial poluidor e aproveitamento energético dos resíduos; materiais recicláveis, dando uma ideia do potencial de redução da produção de resíduos e materiais não recicláveis, os quais necessitam de destinação final em aterros sanitários, devendo ser levado em conta para dimensionamento de equipamentos e infraestrutura do aterro.

Verifica-se ainda através das análises do tratamento de dados por região que a criação de modelos independentes para cada região pode ser uma boa alternativa, já que o país possui discrepâncias demográficas e socioeconômicas gritantes. Assim como em momentos de crise ou apogeu, a quantidade e caracterização dos resíduos gerados servem como um indicador destes eventos, ocorrem variações no consumo, sejam estes de bens duráveis ou não, na alimentação, e o que dificulta a homogeneização dos dados.

Por fim, embora tenha se realizados os testes e a rede neural tenha parte final do trabalho na qual se apresentam as conclusões ou considerações finais apoiadas no desenvolvimento do assunto. É a recapitulação sintética dos resultados obtidos. Pode apresentar recomendações e sugestões para pesquisas futuras.

7 REFERÊNCIAS

ABNT – ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. NBR 8419: Apresentação de projetos de aterros sanitários de resíduos sólidos urbanos. Rio de Janeiro, 1992.

ABNT – ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. NBR 10007: Amostragem de resíduos sólidos. Rio de Janeiro, 2004.

ABRELPE - Associação Brasileira de Empresas de Limpeza Pública e Resíduos Especiais. 2019. Disponível em: < <https://abrelpe.org.br/brasil-produz-mais-lixo-mas-nao-avanca-em-coleta-seletiva/>> Acesso: julho de 2022.

BEIGL, P.; LEBERSRGER, S.; SALHOFER, S. **Modelling municipal solid waste generation: review**. Vienna, Austria: Institute of Waste Management, Department of Water, Atmosphere and Environment, BOKU University of Natural Resources and Applied Life Sciences. 2008.

BEZERRA, Daniel Epifânio. Redes Neurais Artificiais para determinação da composição de resíduos sólidos urbanos. Trabalho de Conclusão de Curso (Graduação em Engenharia Sanitária e Ambiental) - Universidade Estadual da Paraíba, Centro de Ciências e Tecnologia , 2020.

BRASIL, Lei nº 12.305, de 2 de agosto de 2010a. Institui a Política Nacional de Resíduos Sólidos; altera a Lei no 9.605, de 12 de fevereiro de 1998; e dá outras 48 providências. **Diário Oficial da República Federativa do Brasil**, Brasília, 3 ago. 2010, Seção 1, p. 3.

BRASIL, Lei nº 14.026, de 15 de julho de 2020. Atualiza o marco legal do saneamento básico e altera a Lei nº 9.984. **Diário Oficial da República Federativa do Brasil**, Brasília, 16 jul. 2020, Seção: 1, p. 1

BOSCOV, M. E. G. Geotecnia ambiental. Oficina de Textos, 2008 apud BEZERRA, Daniel Epifânio. Redes Neurais Artificiais para determinação da composição de resíduos sólidos urbanos. Trabalho de Conclusão de Curso (Graduação em Engenharia Sanitária e Ambiental) - Universidade Estadual da Paraíba, Centro de Ciências e Tecnologia, 2020.

CEZÁRIO, Janaina Aparecida. **Previsão da geração de resíduos sólidos urbanos para o aterro sanitário no município de Campina Grande – PB**. Dissertação (Mestrado em Ciência e Tecnologia Ambiental) - Universidade Estadual da Paraíba, Centro de Ciências e Tecnologia, 2022.

CLIMATE-DATE.ORG. Disponível em: < <https://pt.climate-data.org/>>. Acesso: maio de 2021.

DAS, S. et al. **Solid waste management: Scope and the challenge of sustainability**. **Journal of cleaner production**, v. 228, p. 658-678, 2019.

FURTADO, Maria Inês Vasconcellos. **Redes neurais artificiais [recurso eletrônico]: uma abordagem para sala de aula** / Maria Inês Vasconcellos Furtado. – Ponta Grossa (PR): Atena Editora, 2019.

HAYKIN, Simon. **Neural Networks and Learning Machines**, 3ª edição. Prentice Hall, 2008

IBGE - Instituto Brasileiro de Geografia e Estatística. Cidades. 2021. Disponível em: <<https://cidades.ibge.gov.br/>>. Acesso: maio de 2021.

JACOBI, P. R.; BESEN, G.R. **Gestão de resíduos sólidos na região metropolitana de São Paulo: avanços e desafios**. São Paulo, 2006.

MINITAB. Disponível em: < <https://blog.minitab.com/pt/analise-de-regressao-como-interpretar-o-r-quadrado-e-avaliar-a-qualidade-de-ajuste>>. Acesso: junho de 2022.

OLIVEIRA, A. F.; LOPES, A. A. Composição gravimétrica como ferramenta para a gestão de resíduos sólidos. *Brazilian Journal of Development*, Curitiba, v.7, n.3, p. 27221-27226, mar 2021.

OLIVEIRA, B. O. S.; MEDEIROS, G. A.; **Evolução e desafios no gerenciamento dos resíduos sólidos urbanos nos estados da região norte, Brasil**. *Revista Valore*, Volta Redonda, 4 (1): p.749-761, Jan/Jun, 2019

PEREIRA, S. S.; CURI, R. C.; CURI, W. F. **Uso de indicadores na gestão dos resíduos sólidos urbanos: uma proposta metodológica de construção e análise para municípios e regiões**. *Eng Sanit Ambient*, v.23, n.3, p. 471-483, maio/jun 2018.

ROCHA, Karoline da. **Sistema de apoio à decisão na classificação de imagens histológicas em epitélio oral displásico ou não displásico**. 2019. 114 f. Dissertação (Mestrado). Universidade Federal de Santa Catarina - Centro Tecnológico. Florianópolis, 2019.

ROSA, G. M.; LUZ, J. A. M. **Simulação de moagem mista por rede neural artificial**. *REM: R. Esc. Minas*, Ouro Preto, 65(2), p. 247-255, abr/jun 2012.

SAETA, Fernanda. Pereira.; **SUSTENTABILIDADE URBANA: o desafio da construção de indicadores de sustentabilidade urbana**. Dissertação (Mestrado em Arquitetura e Urbanismo)-Universidade Presbiteriana Mackenzie, São Paulo, 2012.

MCCULLOCH, Warren S.; PITTS, Walter. "A logical calculus of the ideas immanent in nervous activity". *Bulletin of Mathematical Biophysics*, v.5, 1943.

MathWorks. Matlab R2020a. Produtos. Disponível em: <https://www.mathworks.com/products/matlab.html>. Acessado em: 11/06/2022.

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

MATSUNAGA, V. Y. **Curso de Redes Neurais utilizando o MATLAB**. Belém-(PA), Brasil, 2012.

MOURA, A. A.; LIMA, W. S.; ARCHANJO, C. R.; **Análise da composição gravimétrica de resíduos sólidos urbanos: estudo de caso - município de Itaúna- MG**. *SynThesis Revista Digital FAPAM*, Pará de Minas, n.3, 4 - 16, abr. 2012.

OAB. **O novo marco legal do saneamento básico: Lei nº 14.026/2020**. Brasil, 2020.

PAST 4.03 Disponível em: <<https://past.en.lo4d.com/windows>> Acessado em: 16/07/2022.

SANTOS, R. B.; Detecção e localização de vazamentos em tubulações de gás de baixa pressão por meio de sensores acústicos e processamento matemático de sinais. Tese (doutorado) - Universidade Estadual de Campinas, Faculdade de Engenharia Química (UNICAMP), Campinas, SP, 2015.

8 APÊNDICE A - Análise estatística individual dos dados de entrada e saída

