



UNIVERSIDADE FEDERAL DE CAMPINA GRANDE – UFCG
CENTRO DE TECNOLOGIA E RECURSOS NATURAIS - CTRN
PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL E AMBIENTAL - PPGECA

MODELAGEM NEURAL DINÂMICA DAS CARACTERÍSTICAS
FÍSICO-QUÍMICAS DO LIXIVIADO DE ATERRO SANITÁRIO

AMANDA PAIVA FARIAS

Campina Grande – PB

Setembro de 2023

AMANDA PAIVA FARIAS

MODELAGEM NEURAL DINÂMICA DAS CARACTERÍSTICAS
FÍSICO-QUÍMICAS DO LIXIVIADO DE ATERRO SANITÁRIO

Tese apresentada ao Programa de Pós-Graduação em Engenharia Civil e Ambiental da Universidade Federal de Campina Grande - UFCG, como exigência a obtenção do título de doutora em Engenharia Civil e Ambiental.

Área de Concentração: Recursos Hídricos e Saneamento Ambiental

Orientador: Prof. Dr. Márcio Camargo de Melo

Coorientador: Prof. Dr. William de Paiva

Campina Grande – PB

Setembro de 2023

F224m

Farias, Amanda Paiva.

Modelagem neural dinâmica das características físico-químicas do lixiviado de aterro sanitário / Amanda Paiva Farias. – Campina Grande, 2023.

198 f. : il. color.

Tese (Doutorado em Engenharia Civil e Ambiental) – Universidade Federal de Campina Grande, Centro de Tecnologia e Recursos Naturais, 2023.

"Orientação: Prof. Dr. Márcio Camargo de Melo, Prof. Dr. William de Paiva".

Referências.

1. Aterro Sanitário. 2. Recursos Hídricos. 3. Saneamento Ambiental. 4. Chorume. 5. Resíduos Sólidos Urbanos. 6. Redes Neurais Artificiais – Dados Sintéticos – Lixiviado. I. Melo, Márcio Camargo de. II. Paiva, William de. III. Título.

CDU 628.472.3(043)

MODELAGEM NEURAL DINÂMICA DAS CARACTERÍSTICAS FÍSICO-QUÍMICAS DO LIXIVIADO DE ATERRO SANITÁRIO

AMADA PAIVA FARIAS

TESE APRESENTADA AO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL E AMBIENTAL DA UNIVERSIDADE FEDERAL DE CAMPINA GRANDE, COMO EXIGÊNCIA A OBTENÇÃO DO TÍTULO DE DOUTORA EM ENGENHARIA CIVIL E AMBIENTAL.

Aprovada em 22/09/2023

Examinada por:

Prof. Dr. Márcio Camargo de Melo
(Orientador – UFCG)

Prof. Dr. William de Paiva
(Coorientador – UEPB)

Prof. Dr. Camilo Allyson Simões de Farias
(Examinadora Interna – UFCG)

Prof^a. Dr^a. Vera Lucia Antunes de Lima
(Examinadora Externa – UFCG)

Prof. Dr. Valmir Cristiano Marques de Arruda
(Examinador Externo – UFRPE)

Prof. Dr. Juscelino Alves Henriques
(Examinador Externo – IFPE)

Campina Grande – PB

Setembro de 2023



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
POS-GRADUACAO ENGENHARIA CIVIL AMBIENTAL
Rua Aprigio Veloso, 882, - Bairro Universitario, Campina Grande/PB, CEP 58429-900

REGISTRO DE PRESENÇA E ASSINATURAS

1. **ATA DA DEFESA PARA CONCESSÃO DO GRAU DE DOUTOR EM ENGENHARIA CIVIL E AMBIENTAL**

2. **ALUNO(A): AMANDA PAIVA FARIAS / COMISSÃO EXAMINADORA: DR. MÁRCIO CAMARGO DE MELO - PPGECA/UFCG (PRESIDENTE) - ORIENTADOR, DR. WILLIAM DE PAIVA - PPGECA/UFCG - COORIENTADOR, DR. CAMILO ALLYSON SIMÕES DE FARIAS – UACTA/CCTA– EXAMINADOR INTERNO, DR. JUSCELINO ALVES HENRIQUES – IFPE – EXAMINADOR EXTERNO, DR.ª VERA LÚCIA ANTUNES DE LIMA – UAEA/UFCG – EXAMINADORA EXTERNA, DR. VALMIR CRISTIANO MARQUES DE ARRUDA - UFRPE - EXAMINADOR EXTERNO (PORTARIA 35/2023). / TÍTULO DA TESE: “MODELAGEM NEURAL DINÂMICA DAS CARACTERÍSTICAS FÍSICO-QUÍMICAS DO LIXIVIADO DE ATERRO SANITÁRIO” / ÁREA DE CONCENTRAÇÃO: RECURSOS HÍDRICOS E SANEAMENTO AMBIENTAL / HORA DE INÍCIO: 15:00 HORAS / FORMA DA SESSÃO: POR VIDEOCONFERÊNCIA.**

3. **EM SESSÃO REALIZADA POR VIDEOCONFERÊNCIA, APÓS EXPOSIÇÃO DE CERCA DE 40 MINUTOS, O(A) ALUNO(A) FOI ARGUIDO(A) ORALMENTE PELOS MEMBROS DA COMISSÃO EXAMINADORA, TENDO DEMONSTRADO SUFICIÊNCIA DE CONHECIMENTO E CAPACIDADE DE SISTEMATIZAÇÃO NO TEMA DE SUA TESE, SENDO-LHE ATRIBUÍDO O CONCEITO “EM EXIGÊNCIA”, SENDO QUE A POSSIBILIDADE DE APROVAÇÃO ESTÁ CONDICIONADA À AVALIAÇÃO DA NOVA VERSÃO DO TRABALHO FINAL, SEGUINDO PROCEDIMENTOS PREVISTOS NA RESOLUÇÃO DO PROGRAMA. O PRESIDENTE DA COMISSÃO EXAMINADORA, OUVIDOS OS DEMAIS MEMBROS, DEVERÁ FICAR RESPONSÁVEL POR ATESTAR QUE AS CORREÇÕES SOLICITADAS NA LISTA DE EXIGÊNCIAS FORAM ATENDIDAS NA VERSÃO FINAL DO TRABALHO. A COMISSÃO EXAMINADORA, CUMPRINDO OS PRAZOS REGIMENTAIS, ESTABELECE UM PRAZO MÁXIMO DE 30 DIAS PARA QUE SEJAM FEITAS AS ALTERAÇÕES EXIGIDAS. APÓS O DEPÓSITO FINAL DO DOCUMENTO DE TESE, DEVIDAMENTE REVISADO E MEDIANTE ATESTADO DO ORIENTADOR, O CONCEITO "EM EXIGÊNCIA" PASSARÁ IMEDIATAMENTE PARA O DE “APROVADO”. NA FORMA REGULAMENTAR, FOI LAVRADA A PRESENTE ATA, QUE É ASSINADA POR MIM, FLÁVIO PEREIRA DA CUNHA, SECRETÁRIO, ALUNO E OS MEMBROS DA COMISSÃO EXAMINADORA PRESENTES.**

4. **CAMPINA GRANDE, 22 DE SETEMBRO DE 2023**

5.

6.

7.

8.

9. **VALMIR CRISTIANO MARQUES DE ARRUDA - UFRPE - EXAMINADOR EXTERNO**



Documento assinado eletronicamente por **Juscelino Alves Henriques, Usuário Externo**, em 25/09/2023, às 16:03, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **Amanda Paiva Farias, Usuário Externo**, em 25/09/2023, às 17:15, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **William de Paiva, Usuário Externo**, em 25/09/2023, às 17:39, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **CAMILO ALLYSON SIMOES DE FARIAS, PROFESSOR(A) DO MAGISTERIO SUPERIOR**, em 26/09/2023, às 07:21, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **FLAVIO PEREIRA DA CUNHA, SECRETÁRIO (A)**, em 26/09/2023, às 11:11, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **MARCIO CAMARGO DE MELO, PROFESSOR(A) DO MAGISTERIO SUPERIOR**, em 28/09/2023, às 15:41, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **Valmir Cristiano Marques de Arruda, Usuário Externo**, em 29/09/2023, às 09:52, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **VERA LUCIA ANTUNES DE LIMA, PROFESSOR(A) DO MAGISTERIO SUPERIOR**, em 05/10/2023, às 14:40, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



A autenticidade deste documento pode ser conferida no site <https://sei.ufcg.edu.br/autenticidade>, informando o código verificador **3767649** e o código CRC **F5906AB6**.

Dedico a Deus por tantas graças concedidas, ao meu esposo Cláudio, aos meus pais Jordânia e Geraldo e minhas irmãs Ana Carolina e Beatriz pelo apoio e estímulos diários para a concretização de mais uma etapa acadêmica, e por permanecerem ao meu lado, além da paciência nos dias mais difíceis e presença sempre constante e fundamental de vocês em minha vida. Dedico a vocês por todo amor que nos envolve e nos mantém unidos de alguma forma, sem vocês não teria chegado até aqui.

AGRADECIMENTOS

A Deus pelo dom da vida, e por ter me proporcionado esta oportunidade ímpar de crescimento, profissional e pessoal. Por cada anoitecer e amanhecer, por não me abandonar e me reerguer diariamente, apesar das diversas dificuldades enfrentadas, me permitindo a conclusão desta etapa. Por todos os momentos vividos dou graças a Ele.

Ao meu amado esposo, Cláudio, por caminhar comigo lado a lado, me incentivando e apoiando desde a graduação, sem medir esforços pela busca constante do nosso crescimento e futuro, mesmo tendo que adiar alguns dos nossos projetos de vida. Por acreditar que eu seria capaz de chegar aonde cheguei, mesmo quando por vezes a minha vontade era desistir. Pela confiança depositada a cada dia, pela paciência, compreensão, carinho e amor, permitindo que o passar dos dias fossem mais leves.

Aos meus amados pais Jordânia e Geraldo, e as minhas amadas irmãs, Ana Carolina e Beatriz, pela formação do meu caráter, educação e por sempre serem suporte e incentivo para que eu persista na concretização dos meus sonhos, confiando na minha capacidade de alcançar mais esta conquista na minha vida. Foram pacientes, e descontraídos quando necessário, contribuindo como podiam em cada etapa vivida ao longo dessa caminhada nada fácil. Obrigada por serem meu porto seguro, e apesar de tudo, serem exemplos de amor, perseverança e união. Hoje, sou o que sou graças à abençoada presença de cada um de vocês em minha vida.

Agradeço a toda minha família. Representados aqui, em nome de tia Corrinha e tio Valdo que além de incentivadores, acompanharam de perto e torceram a cada dia pelo êxito deste trabalho. Cada mensagem, abraços e beijos recebidos serviram de estímulo, sempre reafirmando que eu não estava sozinha e que sou capaz. Vocês foram essenciais.

Aos meus pequenos Bernardo (afilhado), Maria Clara, Davi, Luísa, José e Cecília, por serem alegria, amor e pureza, e por renovarem minhas energias a cada abraço, brincadeira e descoberta da vida.

Aos meus queridos cunhados Breno e Kadu, por todos os momentos de descontração, confraternização e alegrias vivenciado, que deixaram a caminhada mais leve, vocês são especiais.

A Rayanne que constantemente precisou me fazer refletir e até reencontrar o sentido de concluir este trabalho. E acompanhou de perto minhas maiores angústias, dores, incertezas e medos. Obrigada por tudo.

Aos meus amigos e colegas, companheiros de disciplinas, de idas ao aterro sanitário, de laboratório e de programação, por toda ajuda e por dividirem comigo esta etapa tão importante de minha vida. Foram momentos que jamais esquecerei.

Ao GGA, por ter me permitido conhecer pessoas de diversas áreas de atuação e assim ampliar conhecimentos ao longo deste doutorado. Especialmente por proporcionar um campo de trabalho vasto e valioso. Pela oportunidade de liderar o subgrupo de Microbiologia, experiência nada fácil, de muita responsabilidade, que me fez crescer e adquirir muito conhecimento.

Ao meu orientador, Prof. Dr. Márcio Camargo de Melo, pela confiança depositada para a realização desta pesquisa.

Ao meu coorientador Prof. Dr. William de Paiva pelas valiosas contribuições com esta pesquisa, pelos ensinamentos, disponibilidade, paciência e solicitude.

Aos professores Camilo Allyson Simões de Farias, Vera Lucia Antunes de Lima, Valmir Cristiano Marques de Arruda e Juscelino Alves Henriques por aceitarem o convite para participar da comissão examinadora deste trabalho, pela atenção, sugestões e críticas propostas com o intuito de aprimorar a pesquisa desenvolvida.

A professora Veruschka Escarião Dessoles Monteiro, pela oportunidade, confiança e apoio ao longo desses anos de GGA.

A professora Mônica de Amorim Coura, por ter aceitado me orientar no estágio docência. Essa experiência levarei por toda a vida, especialmente por toda competência, organização, zelo e empatia em que foi conduzido esta etapa. Minha gratidão pelas orientações e escutas sobre conteúdo das aulas e até mesmo sobre a vida.

Aos funcionários e professores do Programa de Pós-Graduação em Engenharia Civil e Ambiental – PPGECA, da UFCG, por todas as orientações, apoio, paciência e conhecimento compartilhados. Mesmo vivendo momentos tão difíceis, como o enfrentamento a Pandemia de COVID – 19.

A UFMA que além de ser meu ambiente de trabalho nos últimos meses da pesquisa, também me proporcionou um espaço para o desenvolvimento computacional da pesquisa.

A ECOSOLO Campina Grande-PB, e aos seus funcionários, pelo fornecimento de informações do aterro sanitário e pela disponibilidade e colaboração na realização de atividade e coletas de dados em campo.

A CAPES pela bolsa concedida, que contribuiu para minha manutenção, permanência e finalização desta pesquisa.

Por fim, a todos que participaram de alguma forma e contribuíram direta ou indiretamente para a finalização deste trabalho!

RESUMO

Em virtude dos processos físicos, químicos e biológicos que os Resíduos Sólidos Urbanos (RSU) são submetidos durante a sua degradação em aterros sanitários, o lixiviado é um subproduto considerado extremamente complexo, devido a sua composição tóxica e variabilidade ao longo dos anos. Contudo, faz-se necessário conhecê-lo e monitorá-lo pois, todas as informações acerca do lixiviado são valiosas, e contribuem para o desenvolvimento de técnicas e aplicação de tecnologias adaptadas para o tratamento deste efluente. Diante da problemática que envolve a exposição de quem manuseia, os custos associados ao monitoramento, e visando a possibilidade em reduzir a frequência das coletas do lixiviado, além do auxílio à celeridade das respostas aos ensaios que podem demorar dias, as Redes Neurais Artificiais (RNA) podem ser uma alternativa na obtenção das características do lixiviado. Por isso, esse trabalho tem como objetivo desenvolver modelos neurais que representem as características quantitativas do lixiviado gerado em aterro sanitário localizado em região semiárida do Brasil. No qual realizaram-se as coletas e caracterização dos RSU com diferentes idades de aterramento e o monitoramento dos resíduos e lixiviado. Foram analisadas também as condições meteorológicas nas proximidades do Aterro Sanitário. Através dos dados de monitoramento do lixiviado, foi possível construir os bancos de dados experimentais, em busca de melhores desempenhos para as RNA foram gerados sinteticamente bancos com 125 e 1000 dados apresentando a mesma tendência do conjunto de dados original. Como preparação dos dados para a geração das RNA foram colocados em uma escala comum, através da padronização e normalização, cada conjunto de dados de saída que corresponde à Demanda Bioquímica de Oxigênio (DBO), Demanda Química de Oxigênio (DQO), Nitrogênio Amoniacal Total (NAT) e vazão. Nesta pesquisa foram testados variações dos números de neurônios na camada oculta (1 a 20), dos algoritmos utilizados no treinamento das RNA (*trainlm*, *trainbr*, *traingd* e *trainoss*), e das funções de ativação da camada oculta e de saída (*purelin*, *logsig*, *tansig* e *elliotsig*). E como medida de performance, foram avaliados, seguindo esta ordem de prioridades: o coeficiente de determinação (R^2), erro absoluto médio (MAE), erro da raiz quadrática média (RMSE) e a raiz quadrada do erro médio normalizado (NRMSE). Os resultados da caracterização gravimétrica indicaram uma forte relação entre a fração do componente “outros” que representaram a maior porcentagem em toda as idades de aterramento, com exceção para o resíduo fresco, enquanto a matéria orgânica levou destaque para o resíduo fresco, sendo reduzido ao longo dos anos de aterramento. Quanto ao lixiviado, o Aterro Sanitário em estudo apresenta condições e características exclusivas que variam com os tipos de resíduos depositados, e em função das condições climáticas da região semiárida, possuindo um acelerado processo biodegradativo, baixas taxas de geração de lixiviado e um elevado potencial poluidor. Através da verificação das métricas de desempenho, foram selecionadas as melhores RNA para a predição de cada variável desejada. As RNA selecionadas para predição da DBO, DQO e NAT possuíram bons desempenho e podem ser utilizadas para análise das características do lixiviado, já para a predição da vazão, recomenda-se a inserção de mais variáveis que possam aperfeiçoar o coeficiente de determinação (R^2), entre os dados observados e preditos.

Palavras chaves: Chorume; Dados sintéticos; Redes Neurais Artificiais; Semiárido

ABSTRACT

Due to the physical, chemical and biological processes that Municipal Solid Waste (MSW) are subjected to during their degradation in landfills, leachate is a byproduct considered extremely complex, due to its toxic composition and variability over the years. However, it is necessary to know and monitor it because all information about the leachate is valuable and contributes to the development of techniques and application of technologies adapted for the treatment of this effluent. Faced with the problem that involves the exposure of those who handle it, the costs associated with monitoring, and aiming at the possibility of reducing the frequency of leachate collections, in addition to helping to speed up responses to tests that can take days, Artificial Neural Networks (ANN) can be an alternative in obtaining the characteristics of the leachate. Therefore, this work aims to develop neural models that represent the quantitative characteristics of leachate generated in a landfill located in a semi-arid region of Brazil. In which the collection and characterization of MSW with different landfilling ages and monitoring of waste and leachate were carried out. The meteorological conditions near the landfill were also analyzed. Through leachate monitoring data, it was possible to build experimental databases. In search of better performance for ANN, banks with 125 and 1000 data were synthetically generated, showing the same trend as the original data set. To prepare the data for the generation of ANN, each set of output data corresponding to Biochemical Oxygen Demand (BOD), Chemical Oxygen Demand (COD), Total Ammonia Nitrogen was placed on a common scale, through standardization and normalization. (NAT) and throughput. In this research, variations in the number of neurons in the hidden layer (1 to 20), the algorithms used in training the ANN (trainlm, trainbr, trainingd and trainoss), and the hidden layer activation and output functions (purelin, logsig) were tested. , tansig and ellipsig). And as a performance measure, the following were evaluated, following this order of priorities: the coefficient of determination (R^2), mean absolute error (MAE), root mean square error (RMSE) and the square root of the normalized mean error (NRMSE). The results of the gravimetric characterization indicated a strong relationship between the fraction of the "other" component, which represented the highest percentage at all ages of landfilling, with the exception of fresh residue, while organic matter was highlighted in the fresh residue, being reduced to over the years of grounding. As for leachate, the Landfill under study presents exclusive conditions and characteristics that vary with the types of waste deposited, and depending on the climatic conditions of the semi-arid region, having an accelerated biodegradation process, low leachate generation rates and a high polluting potential. . By checking the performance metrics, the best ANN were selected for predicting each desired variable. The ANN selected for predicting BOD, COD and NAT had good performance and can be used to analyze the characteristics of the leachate, while for flow prediction, it is recommended to insert more variables that can improve the coefficient of determination (R^2), between the observed and predicted data.

Keywords: Manure; Synthetic data; Artificial Neural Networks; Semiarid

LISTA DE FIGURAS

Figura 1 – Fases da biodegradação dos RSU de aterro e a formação de biogás e lixiviado	26
Figura 2 – Neurônio artificial	40
Figura 3 - Representação da função linear	41
Figura 4 - Representação da função sigmoide.....	42
Figura 5 – Representação da função tangente hiperbólica	43
Figura 6 - Representação da função simétrica de Elliot	44
Figura 7 - <i>Feedforward</i> de camada simples	46
Figura 8 - <i>Feedforward</i> de camadas múltiplas	46
Figura 9 - Rede recorrente ou realimentada	47
Figura 10 - Rede reticulada	47
Figura 11 – Etapas da pesquisa.....	51
Figura 12 – Localização do Aterro Sanitário em região semiárida e dos municípios que depositaram RSU no empreendimento entre 2015 e 2022	53
Figura 13 – Vista superior do Aterro Sanitário em estudo	54
Figura 14 – Aterro Sanitário: (a) Sistema de drenagem de lixiviado; (b) Impermeabilização da camada de base com manta geossintética e solo compactado	55
Figura 15 - (a) coleta; (b) resíduos acondicionados no caminhão caçamba; (c) pesagem dos resíduos; (d) disposição dos resíduos no galpão.....	57
Figura 16 – Preparação de amostra: (a) picotagem; (b) extrato	59
Figura 17 – Lagoa de Tratamento de Lixiviado do Aterro Sanitário: (a) Tub LTL; (b) teste de vazão e coleta de lixiviado <i>in natura</i>	59
Figura 18 – Fluxograma do processo de criação do banco de dados	61
Figura 19 – Arquitetura da rede neural utilizada para predição: (a) DBO; (b) DQO; (c) NAT; (d) Vazão	62
Figura 20 -Precipitação e evaporação no município ao qual o Aterro Sanitário está inserido.	64
Figura 21 – (a) recirculação de lixiviado: carro pipa; (b) lixiviado empoçado na camada de cobertura.....	65
Figura 22 – Variação da temperatura ambiente no município ao qual o Aterro Sanitário está inserido	66
Figura 23 - Composição gravimétrica dos resíduos frescos, recém aterrados e com 1 e 2 anos aterrados.....	67
Figura 24 - Fração da composição gravimétrica dos resíduos frescos, recém aterrados e com 1 e 2 anos aterrados	68
Figura 25 – Temperatura do lixiviado	72
Figura 26 – Vazão do lixiviado e a precipitação acumulada.....	73
Figura 27 – Sólidos Totais e Sólidos Voláteis no lixiviado	74
Figura 28 - Turbidez no lixiviado.....	76
Figura 29 – Comportamento do pH.....	77
Figura 30 – Variação da Alcalinidade total	78
Figura 31 – Comportamento da DQO	79
Figura 32 – Boxplot concentrações anuais da DQO.....	80
Figura 33 – Comportamento da DBO ₅	81
Figura 34 – Comportamento do Nitrogênio Amoniacal Total	82
Figura 35 – Concentrações de metais	83
Figura 36 – Correlogramas dos dados de entrada e saída: experimentais (a), 125 sintéticos (b) e 1000 sintéticos (c).....	86

Figura 37 - Correlogramas dos dados de entrada e saída para a predição da vazão: experimentais (a), 125 sintéticos (b) e 1000 sintéticos (c)	88
Figura 38 - Correlogramas dos dados de entrada e saída para a predição DQO: experimentais (a), 125 sintéticos (b) e 1000 sintéticos (c).....	90
Figura 39 - Correlogramas dos dados de entrada e saída para a predição DBO: experimentais (a), 125 sintéticos (b) e 1000 sintéticos (c).....	91
Figura 40 - Correlogramas dos dados de entrada e saída para a predição NAT: experimentais (a), 125 sintéticos (b) e 1000 sintéticos (c).....	92
Figura 41 – Performance da RNA com o melhor desempenho para a predição da DBO	96
Figura 42 – Valores observados e preditos da DBO	97
Figura 43 - Performance da RNA com o melhor desempenho para a predição da DQO.....	99
Figura 44 - Valores observados e preditos da DQO.....	100
Figura 45 - Performance da RNA com o melhor desempenho para a predição do NAT	102
Figura 46 - Valores observados e preditos do NAT	103
Figura 47 - Performance da RNA com o melhor desempenho para a predição da vazão	105
Figura 48 - Valores observados e preditos da vazão	106

LISTA DE TABELAS

Tabela 1 – Variação da composição do lixiviados para diferentes idades de aterros.....	29
Tabela 2 – Variação da composição do lixiviado gerado em aterros brasileiros	30
Tabela 3 – Coeficiente de correlação estatística, ou coeficiente de correção de Pearson	34
Tabela 4 – Características físico-químicas dos resíduos sólidos urbanos	69
Tabela 5 - Análise descritiva dos dados	84
Tabela 6 – Correlação de Pearson entre o banco de dados experimentais e os sintéticos.....	89
Tabela 7 – Performance das RNA para a predição da DBO	94
Tabela 8 - Performance das RNA para a predição da DQO.....	97
Tabela 9 – Performance das RNA para a predição do NAT	100
Tabela 10 - Performance das RNA para a predição da vazão	103
Tabela 11 - Performances das melhores RNA para predição da DBO, DQO, NAT e vazão.	107
Tabela 12 - Performance do algoritmo <i>trainlm</i> para predição da DBO com banco de dados experimentais padronizados	135
Tabela 13 - Performance do algoritmo <i>trainlm</i> para predição da DBO com banco de 125 dados sintéticos padronizados	136
Tabela 14 - Performance do algoritmo <i>trainlm</i> para predição da DBO com banco de 1000 dados sintéticos padronizados	136
Tabela 15 – Performance do algoritmo <i>trainlm</i> para a predição da DBO com banco de dados experimentais normalizados	137
Tabela 16 - Performance do algoritmo <i>trainlm</i> para a predição da DBO com banco de 125 dados sintéticos normalizados	137
Tabela 17 - Performance do algoritmo <i>trainlm</i> para a predição da DBO com banco de 1000 dados sintéticos normalizados	138
Tabela 18 - Performance do algoritmo <i>trainbr</i> para predição da DBO com banco de dados experimentais padronizados	139
Tabela 19 - Performance do algoritmo <i>trainbr</i> para a predição da DBO com banco de 125 dados sintéticos padronizados	139
Tabela 20 - Performance do algoritmo <i>trainbr</i> para a predição da DBO com banco de 1000 dados sintéticos padronizados	140
Tabela 21 - Performance do algoritmo <i>trainbr</i> para predição da DBO com banco de dados experimentais normalizados	141
Tabela 22 – Performance do algoritmo <i>trainbr</i> para a predição da DBO com banco de 125 dados sintéticos normalizados	141
Tabela 23 - Performance do algoritmo <i>trainbr</i> para a predição da DBO com banco de 1000 dados sintéticos normalizados	142
Tabela 24 - Performance do algoritmo <i>traingd</i> para predição da DBO com banco de dados experimentais padronizados	143
Tabela 25 - Performance do algoritmo <i>traingd</i> para predição da DBO com banco de 125 dados sintéticos padronizados	143
Tabela 26 - Performance do algoritmo <i>traingd</i> para predição da DBO com banco de 1000 dados sintéticos padronizados	144
Tabela 27 - Performance do algoritmo <i>traingd</i> para predição da DBO com banco de dados experimentais normalizados	145
Tabela 28 - Performance do algoritmo <i>traingd</i> para predição da DBO com banco de 125 dados sintéticos normalizados	145
Tabela 29 - Performance do algoritmo <i>traingd</i> para predição da DBO com banco de 1000 dados sintéticos normalizados	146

Tabela 30 - Performance do algoritmo <i>trainoss</i> para predição da DBO com banco de dados experimentais padronizados	147
Tabela 31 - Performance do algoritmo <i>trainoss</i> para predição da DBO com banco de 125 dados sintéticos padronizados	147
Tabela 32 - Performance do algoritmo <i>trainoss</i> para predição da DBO com banco de 1000 dados sintéticos padronizados	148
Tabela 33 - Performance do algoritmo <i>trainoss</i> para predição da DBO com banco de dados experimentais normalizados	149
Tabela 34 - Performance do algoritmo <i>trainoss</i> para predição da DBO com banco de 125 dados sintéticos normalizados	149
Tabela 35 - Performance do algoritmo <i>trainoss</i> para predição da DBO com banco de 1000 dados sintéticos normalizados	150
Tabela 36 - Performance do algoritmo <i>trainlm</i> para predição da DQO com banco de dados experimentais padronizados	151
Tabela 37 - Performance do algoritmo <i>trainlm</i> para predição da DQO com banco de 125 dados sintéticos padronizados	151
Tabela 38 - Performance do algoritmo <i>trainlm</i> para predição da DQO com banco de 1000 dados sintéticos padronizados	152
Tabela 39 - Performance do algoritmo <i>trainlm</i> para predição da DQO com banco de dados experimentais normalizados	153
Tabela 40 - Performance do algoritmo <i>trainlm</i> para predição da DQO com banco de 125 dados sintéticos normalizados	153
Tabela 41 - Performance do algoritmo <i>trainlm</i> para predição da DQO com banco de 1000 dados sintéticos normalizados	154
Tabela 42 - Performance do algoritmo <i>trainbr</i> para predição da DQO com banco de dados experimentais padronizados	155
Tabela 43 - Performance do algoritmo <i>trainbr</i> para predição da DQO com banco de 125 dados sintéticos padronizados	155
Tabela 44 - Performance do algoritmo <i>trainbr</i> para predição da DQO com banco de 1000 dados sintéticos padronizados	156
Tabela 45 - Performance do algoritmo <i>trainbr</i> para predição da DQO com banco de dados experimentais normalizados	157
Tabela 46 - Performance do algoritmo <i>trainbr</i> para predição da DQO com banco de 125 dados sintéticos normalizados	157
Tabela 47 - Performance do algoritmo <i>trainbr</i> para predição da DQO com banco de 1000 dados sintéticos normalizados	158
Tabela 48 - Performance do algoritmo <i>traingd</i> para predição da DQO com banco de dados experimentais padronizados	159
Tabela 49 - Performance do algoritmo <i>traingd</i> para predição da DQO com banco de 125 dados sintéticos padronizados	159
Tabela 50 - Performance do algoritmo <i>traingd</i> para predição da DQO com banco de 1000 dados sintéticos padronizados	160
Tabela 51 - Performance do algoritmo <i>traingd</i> para predição da DQO com banco de dados experimentais normalizados	161
Tabela 52 - Performance do algoritmo <i>traingd</i> para predição da DQO com banco de 125 dados sintéticos normalizados	161
Tabela 53 - Performance do algoritmo <i>traingd</i> para predição da DQO com banco de 1000 dados sintéticos normalizados	162
Tabela 54 - Performance do algoritmo <i>trainoss</i> para predição da DQO com banco de dados experimentais padronizados	163

Tabela 55 - Performance do algoritmo <i>trainoss</i> para predição da DQO com banco de 125 dados sintéticos padronizados	163
Tabela 56 - Performance do algoritmo <i>trainoss</i> para predição da DQO com banco de 1000 dados sintéticos padronizados	164
Tabela 57 - Performance do algoritmo <i>trainoss</i> para predição da DQO com banco de dados experimentais normalizados	165
Tabela 58 – Performance do algoritmo <i>trainoss</i> para predição da DQO com banco de 125 dados sintéticos normalizados	165
Tabela 59 - Performance do algoritmo <i>trainoss</i> para predição da DQO com banco de 1000 dados sintéticos normalizados	166
Tabela 60 - Performance do algoritmo <i>trainlm</i> para predição de NAT com banco de dados experimentais padronizados	167
Tabela 61 - Performance do algoritmo <i>trainlm</i> para predição de NAT com banco de 125 dados sintéticos padronizados.....	167
Tabela 62 – Performance do algoritmo <i>trainlm</i> para predição de NAT com banco de 1000 dados sintéticos padronizados	168
Tabela 63 – Performance do algoritmo <i>trainlm</i> para predição de NAT com banco de dados experimentais normalizados	169
Tabela 64 - Performance do algoritmo <i>trainlm</i> para predição de NAT com banco de 125 dados sintéticos normalizados	169
Tabela 65 – Performance do algoritmo <i>trainlm</i> para predição de NAT com banco de 1000 dados sintéticos normalizados	170
Tabela 66 - Performance do algoritmo <i>trainbr</i> para predição de NAT com banco de dados experimentais padronizados	171
Tabela 67 - Performance do algoritmo <i>trainbr</i> para predição de NAT com banco de 125 dados sintéticos padronizados.....	171
Tabela 68 - Performance do algoritmo <i>trainbr</i> para predição de NAT com banco de 1000 dados sintéticos padronizados	172
Tabela 69 - Performance do algoritmo <i>trainbr</i> para predição de NAT com banco de dados experimentais normalizados	173
Tabela 70 - Performance do algoritmo <i>trainbr</i> para predição de NAT com banco de 125 dados sintéticos normalizados	173
Tabela 71 - Performance do algoritmo <i>trainbr</i> para predição de NAT com banco de 1000 dados sintéticos normalizados	174
Tabela 72 - Performance do algoritmo <i>traingd</i> para predição de NAT com banco de dados experimentais padronizados	175
Tabela 73 - Performance do algoritmo <i>traingd</i> para predição de NAT com banco de 125 dados sintéticos padronizados.....	175
Tabela 74 - Performance do algoritmo <i>traingd</i> para predição de NAT com banco de 1000 dados sintéticos padronizados	176
Tabela 75 - Performance do algoritmo <i>traingd</i> para predição de NAT com banco de dados experimentais normalizados	177
Tabela 76 - Performance do algoritmo <i>traingd</i> para predição de NAT com banco de 125 dados sintéticos normalizados	177
Tabela 77 - Performance do algoritmo <i>traingd</i> para predição de NAT com banco de 1000 dados sintéticos normalizados	178
Tabela 78 - Performance do algoritmo <i>trainoss</i> para predição de NAT com banco de dados experimentais padronizados	179
Tabela 79 - Performance do algoritmo <i>trainoss</i> para predição de NAT com banco de 125 dados sintéticos padronizados	179

Tabela 80 - Performance do algoritmo <i>trainoss</i> para predição de NAT com banco de 1000 dados sintéticos padronizados	180
Tabela 81 - Performance do algoritmo <i>trainoss</i> para predição de NAT com banco de dados experimentais normalizados	181
Tabela 82 - Performance do algoritmo <i>trainoss</i> para predição de NAT com banco de 125 dados sintéticos normalizados	181
Tabela 83 - Performance do algoritmo <i>trainoss</i> para predição de NAT com banco de 1000 dados sintéticos normalizados	182
Tabela 84 - Performance do algoritmo <i>trainlm</i> para predição de Vazão com banco de dados experimentais padronizados	183
Tabela 85 - Performance do algoritmo <i>trainlm</i> para predição de Vazão com banco de 125 dados sintéticos padronizados	183
Tabela 86 - Performance do algoritmo <i>trainlm</i> para predição de Vazão com banco de 1000 dados sintéticos padronizados	184
Tabela 87 - Performance do algoritmo <i>trainlm</i> para predição de Vazão com banco de dados experimentais normalizados	185
Tabela 88 - Performance do algoritmo <i>trainlm</i> para predição de Vazão com banco de 125 dados sintéticos normalizados	185
Tabela 89 - Performance do algoritmo <i>trainlm</i> para predição de Vazão com banco de 1000 dados sintéticos normalizados	186
Tabela 90 - Performance do algoritmo <i>trainbr</i> para predição de Vazão com banco de dados experimentais padronizados	187
Tabela 91 - Performance do algoritmo <i>trainbr</i> para predição de Vazão com banco de 125 dados sintéticos padronizados	187
Tabela 92 - Performance do algoritmo <i>trainbr</i> para predição de Vazão com banco de 1000 dados sintéticos padronizados	188
Tabela 93 - Performance do algoritmo <i>trainbr</i> para predição de Vazão com banco de dados experimentais normalizados	189
Tabela 94 - Performance do algoritmo <i>trainbr</i> para predição de Vazão com banco de 125 dados sintéticos normalizados	189
Tabela 95 - Performance do algoritmo <i>trainbr</i> para predição de Vazão com banco de 1000 dados sintéticos normalizados	190
Tabela 96 - Performance do algoritmo <i>traingd</i> para predição de Vazão com banco de dados experimentais padronizados	191
Tabela 97 - Performance do algoritmo <i>traingd</i> para predição de Vazão com banco de 125 dados sintéticos padronizados	191
Tabela 98 - Performance do algoritmo <i>traingd</i> para predição de Vazão com banco de 1000 dados sintéticos padronizados	192
Tabela 99 - Performance do algoritmo <i>traingd</i> para predição de Vazão com banco de dados experimentais normalizados	193
Tabela 100 - Performance do algoritmo <i>traingd</i> para predição de Vazão com banco de 125 dados sintéticos normalizados	193
Tabela 101 - Performance do algoritmo <i>traingd</i> para predição de Vazão com banco de 1000 dados sintéticos normalizados	194
Tabela 102 - Performance do algoritmo <i>trainoss</i> para predição de Vazão com banco de dados experimentais padronizados	195
Tabela 103 - Performance do algoritmo <i>trainoss</i> para predição de Vazão com banco de 125 dados sintéticos padronizados	195
Tabela 104 - Performance do algoritmo <i>trainoss</i> para predição de Vazão com banco de 1000 dados sintéticos padronizados	196

Tabela 105 - Performance do algoritmo <i>trainoss</i> para predição de Vazão com banco de dados experimentais normalizados	197
Tabela 106 - Performance do algoritmo <i>trainoss</i> para predição de Vazão com banco de 125 dados sintéticos normalizados	197
Tabela 107 - Performance do algoritmo <i>trainoss</i> para predição de Vazão com banco de 1000 dados sintéticos normalizados	198

LISTA DE QUADROS

Quadro 1 - Principais algoritmos de retropropagação e suas respectivas funções no <i>MatLab</i>	44
Quadro 2 - Análises físico-químicas e seus respectivos procedimentos metodológicos para o extrato dos resíduos sólidos	58
Quadro 3 - Análises físico-químicas e seus respectivos procedimentos metodológicos para o lixiviado	60

SUMÁRIO

1. INTRODUÇÃO.....	22
1.2 Objetivos.....	24
1.2.1 Objetivo Geral.....	24
1.2.2 Objetivos específicos	24
2. REVISÃO BIBLIOGRÁFICA	25
2.1 Degradação dos resíduos sólidos urbanos e geração de lixiviado	25
2.2 Características do lixiviado de aterros sanitários	28
2.3 Lixiviado em regiões semiáridas	32
2.4 Análise estatística	33
2.5 Banco de dados	34
2.6 Modelagem para predição do lixiviado	37
2.6.1 Redes Neurais Artificiais.....	39
2.6.1.1 Função de ativação	40
2.6.1.2 Algoritmos de treinamento	44
2.6.1.3 Arquiteturas	45
2.6.1.4 Aprendizado	48
2.6.1.5 Avaliação do desempenho de redes neurais artificiais	48
3. METODOLOGIA.....	51
3.1 Caracterização da área de estudo.....	52
3.2 Análise das condições meteorológicas	55
3.3 Caracterização dos resíduos sólidos urbanos	56
3.4 Caracterização e monitoramento do lixiviado	59
3.5 Banco de dados sintéticos.....	60
3.6 Modelagem para determinação das características do lixiviado	61
4. RESULTADOS E DISCUSSÕES.....	63
4.1 Análise das condições meteorológicas	63

4.2 Caracterização dos resíduos sólidos urbanos	66
4.2.1 Composição Gravimétrica	67
4.2.2 Caracterização físico-química	69
4.3 Caracterização e monitoramento do lixiviado do Aterro Sanitário	71
4.4 Banco de dados	84
4.5 Redes Neurais Artificiais.....	93
4.5.1 DBO.....	94
4.5.2 DQO	97
4.5.3 NAT	100
4.5.4 Vazão	103
4.5.4 Melhores RNA para predição da DBO, DQO, NAT e vazão.....	106
5. CONCLUSÕES	109
REFERÊNCIAS	111
APÊNDICE A	127
APÊNDICE B.....	130
APÊNDICE C.....	135

1. INTRODUÇÃO

O lixiviado de aterros sanitários é um subproduto líquido originado da biodegradação da matéria orgânica, da umidade presente nos próprios resíduos e da infiltração de águas pluviais na camada de cobertura dos aterros. A composição deste efluente, dá-se em função do tipo de resíduos, fases da biodegradação, tempo de deposição dos resíduos, condições meteorológicas locais e até mesmo o tipo de operação e execução deste empreendimento. Resultando em um líquido com altas concentrações de substâncias tóxicas e perigosas, como metais pesados (Xie *et al.*, 2009; São Mateus *et al.*, 2012; Zamri *et al.*, 2017; Vithanage *et al.*, 2017; Baderna *et al.*, 2019; Michalska *et al.*, 2020).

A caracterização de lixiviado de aterros sanitários é considerada por Feng *et al.* (2020) como um processo complexo. Porém, é necessário conhecer, caracterizar e monitorar este subproduto para tratá-lo de forma adequada, e auxiliar a operação e projetos de ampliação desses empreendimentos (Kortegast *et al.*, 2007; Zaman, 2010; Sivakumar, 2013). Ishii *et al.* (2022) consideram o tratamento do lixiviado como um processo crítico, devido a variabilidade das suas características, não existindo, conforme Costa *et al.* (2019), um tratamento universal ou solução padrão.

A dificuldade em lidar com o lixiviado tem origem desde a sua caracterização, em consequência das diversas influências e variações sofridas ao longo do tempo. Essas transformações tornam a avaliação desse efluente mais complexa e impossibilita a generalização da sua composição, prejudicando inclusive na escolha do tratamento do lixiviado a ser implantado no empreendimento (Grugnaletti *et al.*, 2016; Venkatesh Reddy *et al.*, 2020).

A variabilidade das características físico-químicas do lixiviado pode ser descrita por meio da aplicação de técnicas de modelagem. Essa ferramenta facilita a solução desses problemas e auxilia as tomadas de decisões, considerando a complexidade e as variações de indicadores e parâmetros na previsão e precisão de resultados para analisar esse efluente (Ishii *et al.*, 2022). O uso de Redes Neurais Artificiais (RNA) para modelar as características do lixiviado, favorece a reduzir a exposição e os riscos de quem manuseia este fluido, além dos custos associados ao monitoramento e da possibilidade de reduzir a frequência de coletas desse subproduto em aterros.

Com a perspectiva de facilitar a compreensão e predição, foram desenvolvidas e aplicadas técnicas de Inteligência Artificial (IA), que utilizam do aprendizado, percepção, compreensão, raciocínio e consciência do ambiente, simulando características humanas (Abdallah *et al.*, 2020). Entre as técnicas de IA, as RNA têm sido as mais atrativas por sua

capacidade de lidar com *big data*, mapear as relações não lineares e fornecer previsão de resultados (Wang *et al.*, 2018). Assim, a área da implantação de RNA se destaca devido a capacidade de autoaprendizagem e precisão à modelagem, conseguindo estabelecer uma relação complexa entre dados de entrada e saída, não havendo a necessidade de fórmulas matemáticas explícitas (Kalogirou, 2003).

Na área dos RSU, incluindo seus subprodutos, a RNA tem sido utilizada para estimativa de geração e transporte de gás de aterro (Li *et al.*, 2011), otimização de parâmetros no tratamento de lixiviado de aterro (Sabour e Amiri, 2017; Biglarijoo *et al.*, 2017), e previsão da geração de RSU (Ali e Ahmad, 2019).

Diferentes trabalhos foram desenvolvidos para investigar e prever a geração e a qualidade do lixiviado, em escalas de laboratório e de campo. Dentre esses estudos, Karaca e Özkaya (2006) usaram pela primeira vez uma RNA com algoritmo de retropropagação para prever a taxa de fluxo de lixiviado em um aterro sanitário. Azadi *et al.* (2016) aplicaram RNA para prever a demanda química de oxigênio em lixiviados com base em dados da estação seca, para lixiviados gerados em lisímetro em escala de laboratório. Abunama *et al.* (2018), Abunama *et al.* (2019) determinaram os principais elementos que contribuem para a geração de lixiviado usando algoritmo de IA. Esses estudos mostraram que a RNA pode alcançar bons resultados na modelagem da eficiência de geração de lixiviado.

Conforme demonstrado nos estudos mencionados anteriormente, os modelos de inteligência artificial são técnicas bem conhecidas e profundas na modelagem e previsão de dados. No entanto, conforme Abunama *et al.* (2019) não há estudos suficientes sobre a predição de lixiviados, sendo necessário mais estudos para determinar o desempenho de modelos baseados em IA na modelagem das características qualitativas e quantitativas de lixiviados de aterros sanitários. Quando se trata de aterros sanitários em regiões semiáridas, esses estudos são mais escassos, por isso a necessidade de desenvolver modelos específicos para essas condições.

Esse trabalho tem como contribuição científica o desenvolvimento de RNA, para predição da quantidade e qualidade do lixiviado proveniente de aterro sanitário localizado em região semiárida. Com a utilização de dados meteorológicos e parâmetros do monitoramento do aterro sanitário em escala real. Além do uso dos dados experimentais, utilizou-se da técnica da síntese de dados, com o intuito de tornar o banco de dados mais robusto na tentativa de melhorar o desempenho das RNA. Essas RNA poderão predizer as características do lixiviado de uma região semiárida brasileira que auxiliará, a operação e monitoramento de aterros sanitários, assim como os métodos de tratamento desse subproduto.

1.2 Objetivos

1.2.1 Objetivo Geral

Desenvolver modelos neurais que representem as características quantitativas do lixiviado gerado em um aterro sanitário localizado em região semiárida.

1.2.2 Objetivos específicos

- Determinar a composição gravimétrica e características físico-químicas dos resíduos em aterro sanitário localizado em região semiárida;
- Verificar as condições meteorológicas e suas influências no lixiviado gerado no aterro sanitário do semiárido;
- Caracterizar quantitativamente o lixiviado quanto aos parâmetros físico-químicos;
- Desenvolver modelos de predição em redes neurais artificiais para determinar a demanda bioquímica de oxigênio (DBO), demanda química de oxigênio (DQO) e nitrogênio amoniacal total (NAT) e a vazão no lixiviado;
- Avaliar o desempenho das redes neurais artificiais desenvolvidas para determinação da DBO, DQO, NAT e vazão do lixiviado de aterros sanitário em região semiárida.

2. REVISÃO BIBLIOGRÁFICA

Neste capítulo são abordados aspectos relacionados a degradação dos resíduos sólidos urbanos e os fatores que podem influenciar a quantidade e qualidade do lixiviado gerado. Desta maneira, serão apresentados os conceitos, propriedades, modelos, métodos e estudos relacionados ao RSU e ao lixiviado gerado em aterro sanitário localizado no semiárido. A revisão bibliográfica está dividida em cinco seções: i) degradação dos resíduos sólidos urbanos e geração de lixiviado; ii) características do lixiviado; iii) lixiviado de regiões semiáridas; iv) análise estatística dos dados; v) banco de dados; vi) modelagem para predição do lixiviado.

2.1 Degradação dos resíduos sólidos urbanos e geração de lixiviado

O aterro sanitário é o método mais utilizado em todo o mundo para a disposição de resíduos sólidos urbanos (RSU) (Brás *et al.*, 2017), devido à sua viabilidade técnica, facilidade e baixo custo destinado à operação, de forma a diminuir os danos ou riscos à saúde pública e a segurança, minimizando os impactos ambientais adversos segundo Kamaruddin *et al.* (2015), Follmann *et al.* (2017) e Destro (2020).

Os aterros sanitários podem ser analisados como verdadeiros reatores biológicos heterogêneos, e são considerados um dos mais dinâmicos ecossistemas terrestres que abrigam uma população altamente diversificada de microrganismos com capacidade de conviver e metabolizar substratos complexos, originando o biogás e o lixiviado como subprodutos da degradação dos RSU (Xu *et al.*, 2017; Wang *et al.*, 2017; Follmann *et al.*, 2017; Zainun e Simarani, 2018; Sekhohola-Dlamini e Tekere, 2020).

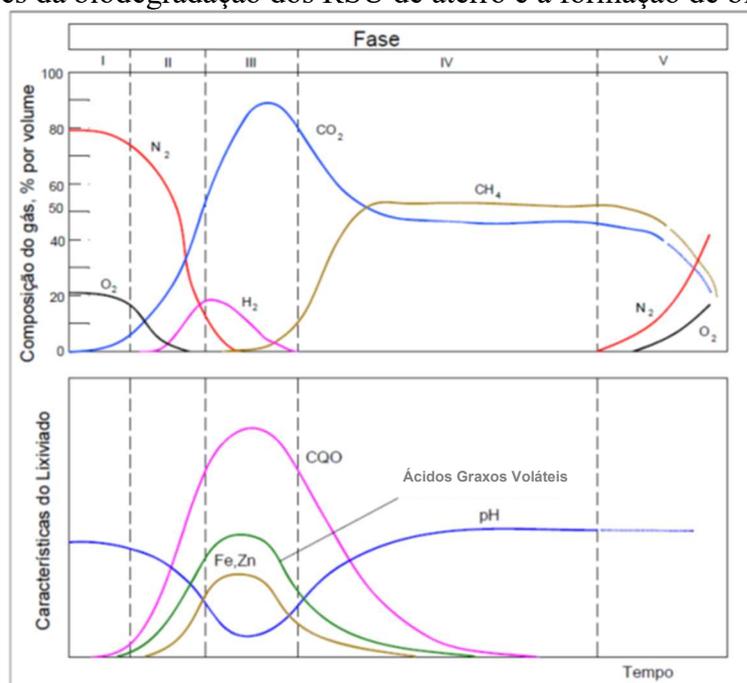
Kjeldsen *et al.* (2002) e Ziyang *et al.* (2009) afirmam que dentre os subprodutos gerados pela degradação dos RSU em aterros sanitários, o de maior impacto negativo é a produção de lixiviado, devido a elevada complexidade desse líquido, que gera dificuldades no desenvolvimento e aplicação de tecnologias simples e de baixo custo operacional para o tratamento desse efluente.

O lixiviado de aterros sanitários é um efluente líquido aquoso de extrema complexidade, possui coloração escura, com odor desagradável e é gerado por meio de processos físicos, químicos e biológicos da degradação dos resíduos. A formação desse líquido é potencializada por meio da umidade contida nos próprios resíduos, acrescida pela infiltração da água de chuvas, que percolam nos resíduos sólidos aterrados, sendo os principais responsáveis pela geração deste líquido altamente poluidor. Destaca-se que, na caracterização do lixiviado, em função da composição dos resíduos aterrados, apresenta grande quantidade de nitrogênio,

especialmente na forma de amônia, compostos orgânicos, inorgânicos, naturais e sintéticos, metais tóxicos e pesados (Castilhos Jr. *et al.*, 2003; Rani, 2020). No entanto, faz-se necessário conhecer a biodegradabilidade dos RSU para avaliar o funcionamento do aterro sanitário e propor técnicas eficientes para o tratamento desse subproduto.

Conforme Tchobanoglous *et al.* (1993), Pazoki e Ghasemzadeh (2020), a biodegradação dos resíduos sólidos acontece em cinco fases (Figura 1), que influenciam na produção do lixiviado, sobretudo em sua composição, por meio dos processos bioquímicos aeróbicos e anaeróbicos. As cinco fases são compostas por: fase de decomposição aeróbia, fase de transição (facultativa), e três fases anaeróbicas (ácida, metanogênica e maturação).

Figura 1 – Fases da biodegradação dos RSU de aterro e a formação de biogás e lixiviado



Fonte: Tchobanoglous *et al.* (1993).

Fase I – Fase aeróbia: Nas camadas superiores do aterro sanitário ocorrem a primeira fase do processo de degradação de compostos orgânicos, onde as bactérias aeróbicas consomem o oxigênio, enquanto metabolizam as cadeias de carboidratos complexos, proteínas e lipídios contidos nos resíduos compactados e recém aterrados, podendo esse processo ser potencializado com a infiltração de água proveniente das chuvas ou, em alguns casos, por meio da recirculação do lixiviado (Canziani e Cossu, 2012; Moratelli, 2013; Pazoki e Ghasemzadeh, 2020).

Normalmente, a fase aeróbia é limitada em duração, com poucos dias, devido à redução progressiva de oxigênio no meio, além disso verifica-se a redução de gás nitrogênio e sulfeto

de hidrogênio. Nesta fase cerca de 5 a 10% de degradação da matéria sólida passível de transformação em gases é observada, sendo raro o aparecimento de lixiviado proveniente exclusivamente nesta fase, pois, segundo Souto (2009), o resíduo ainda não atingiu a capacidade de campo, ou seja, o maciço ainda retém o líquido, não sendo possível o escoamento de lixiviado. No entanto, quando há o surgimento de lixiviado, sais e pequenas quantidades de material orgânico solúveis são caracterizados com material particulado devido ao arraste pelo escoamento dos líquidos (McBean, Rovers e Farquhar, 1995; Christensen *et al.*, 2005; Canziani e Cossu 2012).

Fase II – Fase de transição: quando o oxigênio se encontra em baixos níveis, favorecendo o desenvolvimento das condições anaeróbias. Nesta fase, apesar de ter curta duração, ocorre grande liberação de calor, e o lixiviado gerado apresenta elevadas concentrações de sais de alta solubilidade dissolvidos no líquido resultante. O nitrato e o sulfato, podem servir como receptores de elétrons em reações de conversão biológica e são reduzidos a gás nitrogênio, bem como sulfeto de hidrogênio. O material orgânico complexo é decomposto e transformado em ácidos orgânicos, dando-se início a próxima fase. Nota-se aumento na produção de CO₂.

Fase III – Fase Ácida ou Anaeróbia Ácida: continua com a formação de ácidos orgânicos que é iniciada na fase anterior. Há formação de ácidos, como o acético, fúlvico, entre outros. Os microrganismos são chamados de acidogênicos, onde cerca de 15 a 20% da matéria sólida com potencial de conversão em gás está sendo decomposta e os líquidos percolados nesta fase apresentam pH abaixo de 5, que pode contribuir na solubilização de materiais inorgânicos, podendo apresentar altas concentrações de ferro (Fe), manganês (Mn), zinco (Zn), cálcio (Ca) e magnésio (Mg), e a DBO₅ e DQO apresentam valores elevados devido a dissolução dos ácidos orgânicos produzidos. Nesta fase é notório o aumento considerável de CO₂ e pequena quantidade de H₂.

Fase IV – Fase Metanogênica: há conversão de ácido acético e gás hidrogênio em metano (CH₄) e dióxido de carbono (CO₂), reduzindo a produção de ácidos. Estes processos irão promover o aumento do pH atingindo uma faixa entre 6,5 e 7,5, enquanto as concentrações de DBO₅ e DQO sofrerão reduções significativas. Nessas condições (valores neutros de pH) observar-se, ainda, a redução da solubilidade de compostos inorgânicos, implicando uma menor quantidade de metais pesados contidos nos líquidos percolados.

Fase V - Fase de Maturação: Esta fase ocorrerá depois que toda a matéria orgânica disponível for convertida em CH₄ e CO₂ e pequenas quantidades de N₂ e O₂. A taxa de produção de gases diminui substancialmente, visto que a maioria dos nutrientes já foi removida pelos

líquidos percolados nas fases anteriores e os remanescentes apresentam lento processo de biodegradação. A decomposição da matéria sólida atinge valores entre 50 e 70%, dependendo da produção de metano e das práticas operacionais empregadas.

Por mais que estas etapas da biodegradação estejam interligadas de modo que favoreçam o processo de formação do substrato de cada fase, a duração dessas fases irá depender das características dos resíduos como: a distribuição de compostos orgânicos; a disposição contínua de resíduos novos, que causam a diferença de idade e interferem nas condições físico-químicas e biológicas dos resíduos; sistema de operação do aterro sanitário, como a compactação aplicada no solo da camada de cobertura bem como nas camadas intermediárias do empreendimento. Dessa forma, algumas fases podem ocorrer de forma simultaneamente (Vavlin *et al.*, 2003; Castilhos Jr. *et al.*, 2003).

No entanto, em regiões áridas e semiáridas os aterros sanitários, podem apresentar fases da biodegradação diferenciadas, que influenciam na formação e nas características dos lixiviados. Segundo Vahabian *et al.* (2019) é difícil descrever as reações químicas em aterros sanitários em regiões áridas e semiáridas devido ao déficit hídrico, que podem proporcionar diferentes estágios de decomposição dos RSU. Assim, a idade do aterro sanitário pode não ser obtida exclusivamente pelas características dos lixiviados.

Por isso, a necessidade de realizar ensaios de caracterização dos resíduos aterrados para que se possa definir quão avançado está o processo de degradação desses resíduos. Desse modo, a composição gravimétrica e as características físico-químicas e biológicas estão intimamente relacionadas no maciço, e são determinantes para a evolução da biodegradação dos RSU ao longo do tempo.

2.2 Características do lixiviado de aterros sanitários

Os resíduos sólidos urbanos depositados em aterros sanitários possuem um perfil bastante heterogêneo. As características dos RSU, quanto a composição, granulometria, a variação de umidade e idade influenciam diretamente na composição do lixiviado. No entanto, fatores voltados às condições climáticas, como precipitação, evaporação, insolação e temperatura; além dos aspectos operacionais e estruturais do aterro sanitário, como o balanço hídrico, a compactação dos resíduos, idade do aterro e altura do talude também influenciam nas características do lixiviado (Christensen *et al.*, 2001; Cintra *et al.*, 2002; El Fadel *et al.*, 2002; Kjeldsen *et al.*, 2002; Kurniawan *et al.*, 2006; Renou *et al.*, 2008, Žaltauskaitė e Vaitonyte, 2017; Naveen *et al.*, 2017; Bhatt *et al.*, 2017).

O lixiviado gerado em aterros sanitários possuem grande fator de risco para o meio ambiente e para a população, por apresentar uma espécie de matriz complexa de vários produtos químicos, como matéria orgânica, sais inorgânicos e metais pesados. As concentrações variam através dos processos físicos, como o intemperismo, processos químicos, como a dessorção, e microbiológicos, como a biodegradação dos resíduos orgânicos, processos esses, que ocorrem no maciço sanitário (Moody e Townsend, 2017).

As características do lixiviado são geralmente apresentadas através de análises físico-químicas e microbiológicas: pH, Demanda Química de Oxigênio (DQO), Demanda Bioquímica de Oxigênio (DBO₅) Carbono Orgânico Total (COT), Nitrogênio total Kjeldhal (NKT), nitrogênio amoniacal (N-NH₃), alcalinidade, sólidos em suspensão e toxicidade. É possível no lixiviado identificar por categoria, quatro poluentes: matéria orgânica dissolvida (ácidos graxos voláteis e compostos orgânicos mais refratários – ácidos húmicos e fúlvicos), macrocomponentes inorgânicos (Ca²⁺, Mg²⁺, Na⁺, K⁺, NH₄⁺, Fe²⁺, Mn²⁺, Cl⁻, SO₄²⁻, HCO₃³⁻) e compostos encontrados em menor concentração ou traços inorgânicos (Clement *et al.*, 1996; Sisino *et al.*, 2000; Cintra *et al.*, 2002; Kjeldsen *et al.*, 2002; Baun *et al.*, 2003; Karadag *et al.*, 2008; Renou *et al.*, 2008; Bayram, 2012; Qasim e Chiang, 2017).

A composição química do lixiviado varia muito com a idade do aterramento e com a fase de estabilização dos RSU. El-Fadel *et al.* (2002) mesmo afirmando que é limitada a generalização da composição do lixiviado quanto à concentração em um momento específico, descreveram na Tabela 1, a variação da qualidade dos lixiviado com a idade do aterro.

Tabela 1 – Variação da composição do lixiviados para diferentes idades de aterros

INDICADORES (mg.L ⁻¹)	IDADE DO LIXIVIADO (ANOS)			
	0-5	5-10	10-20	>20
pH*	3-6	6-7	7-7,5	7,5
DBO	10000-25000	1000-4000	50-1000	<50
DQO	15000-40000	10000-20000	1000-5000	<1000
TKN	1000-3000	400-600	75-300	<50
NH ₃ ⁺ -N	500-1500	300-500	50-200	<30
SDT	10000-25000	5-10000	2000-5000	<1000
Cálcio	2000-4000	500-2000	300-500	<300
Sódio e potássio	2000-4000	500-1500	100-500	<100
Ferro e magnésio	500-1500	500-1000	100-500	<100
Zinco	100-200	50-100	10-50	<10
Cloreto	1000-3000	500-2000	100-500	<100
Sulfato	500-2000	200-1000	50-200	<50
Fósforo	100-300	10-100	-	<10

*A unidade mg.L⁻¹ não é aplicável no pH.

Fonte: El-Fadel *et al.* (2002).

A Tabela 2, apresentada por Souto e Povinelli (2007) e discutida no Programa de Pesquisa em Saneamento Básico 5 (PROSAB, 2009), traz a composição média do lixiviado para aterros brasileiros, restringindo algumas características em relação as condições climáticas e socioeconômicas. Essas variações encontradas no lixiviado para aterros no Brasil, são indicativos das possíveis variações encontradas nos efluentes gerados nesses empreendimentos.

Tabela 2 – Variação da composição do lixiviado gerado em aterros brasileiros

INDICADORES	FAIXA MÁXIMA	FAIXA MAIS PROVÁVEL	FVMP (%)
pH	5,7 – 8,6	7,2 – 8,6	78
Alcalinidade total (mg.L ⁻¹ de CaCO ₃)	750 - 11400	750 - 7100	69
Dureza (mg.L ⁻¹ de CaCO ₃)	95 - 3100	95 - 2100	81
Condutividade (µS.cm ⁻¹)	2950 - 2500	2950 - 1766	77
DBO (mg.L ⁻¹ de O ₂)	< 20 - 30000	< 20 – 8600	75
DQO (mg.L ⁻¹ de O ₂)	190 - 80000	190 – 22300	83
Óleos e graxas (mg.L ⁻¹)	10 - 480	10 - 170	63
Fenóis (mg.L ⁻¹ de C ₆ H ₅ OH)	0,9 – 9,9	0,9 – 4,0	58
NTK (mg.L ⁻¹ de N)	80 - 3100	Não há	-
N-amoniacal (mg.L ⁻¹ de N)	0,4 – 3000	0,4 - 1800	72
N-orgânico (mg.L ⁻¹ de N)	5 – 1200	400 - 1200	80
N-nitrito (mg.L ⁻¹ de N)	0 - 50	0 - 15	69
N-nitrato (mg.L ⁻¹ de N)	0 - 11	0 – 3,5	69
P-total (mg.L ⁻¹)	0,1 - 40	0,1 - 15	63
Sulfeto (mg.L ⁻¹)	0 - 35	0 - 10	78
Sulfato (mg.L ⁻¹)	0 - 5400	0 - 1800	77
Cloreto (mg.L ⁻¹)	500 - 5200	500 - 3000	72
Sólidos totais (mg.L ⁻¹)	3200 - 21900	3200 - 14400	79
Sólidos totais fixos (mg.L ⁻¹)	630 -20000	630 - 5000	60
Sólidos totais voláteis (mg.L ⁻¹)	2100 - 14500	2100 - 8300	74
Sólidos suspensos totais (mg.L ⁻¹)	5 - 2800	5 - 700	68
Sólidos suspensos voláteis (mg.L ⁻¹)	5 - 530	5 - 200	62
Ferro (mg.L ⁻¹)	0,01 - 260	0,01 - 65	67
Manganês (mg.L ⁻¹)	0,04 - 2,6	0,04 - 2,0	79
Cobre (mg.L ⁻¹)	0,005 - 0,6	0,05 - 0,15	61
Níquel (mg.L ⁻¹)	0,03 - 1,1	0,03 - 0,5	71
Cromo (mg.L ⁻¹)	0,003 - 0,8	0,003 - 0,5	89
Cádmio (mg.L ⁻¹)	0 - 0,26	0 - 0,065	67
Chumbo (mg.L ⁻¹)	0,01 - 2,8	0,01 - 0,5	64
Zinco (mg.L ⁻¹)	0,01 - 8,0	0,001 - 1,5	70

FVMP: frequência de ocorrência dos valores mais prováveis.

Fonte: Souto e Povinelli (2007).

O lixiviado, na fase ácida, apresenta elevados nutrientes, metais pesados, DQO e DBO₅, uma vez que há predominância de compostos orgânicos simples e de alta solubilidade, principalmente ácidos graxos voláteis, que favorecem a solubilização de materiais inorgânicos.

Enquanto na fase metanogênica o pH varia entre 6,5 e 7,5, contendo valores consideráveis de nutrientes, metais pesados, DQO e DBO₅, no entanto, apresentam resultados inferiores ao da fase anterior. A DQO é comumente analisada para medir indiretamente o potencial poluidor dos efluentes e a DBO₅ representa uma medida indireta da quantidade de matéria orgânica biodegradável existente na amostra (Segato e Silva, 2000; Bayram, 2012; Da Silva e Mota, 2019).

A biodegradabilidade do lixiviado pode ser determinada pela variação da relação DBO₅/DQO. Quanto maior a razão entre DBO₅ e DQO, mais facilmente o lixiviado será tratado biologicamente, e quanto menor essa razão a indicação é de uma grande presença de material orgânico de difícil degradação (Hamada, 1997). Segundo Akerman (2005) o nitrogênio presente no lixiviado não depende exclusivamente da fase de degradação em que o RSU está inserido, nas fases ácida e metanogênica, sendo característico elevada concentração de nitrogênio, na forma de íon amônio.

A maior concentração de nitrogênio presente na composição do lixiviado está na forma amoniacal. O nitrogênio amoniacal total é um contaminante importante presente no lixiviado de aterros sanitários, e exige atenção, quanto aos seus altos níveis de amônia, por resultar grave poluição (Miao *et al.*, 2019). O nitrogênio amoniacal total é o parâmetro dentre os demais que dificulta o tratamento do lixiviado por um único método, tendo em vista que o tratamento físico-químico pode remover boa parte dos contaminantes, mas, o tratamento biológico é mais indicado para a remoção do nitrogênio no lixiviado. Diante disso, os lixiviados devem ser tratados por meio de processos que unam esses dois métodos (Di Iaconi *et al.*, 2006; Jokela *et al.*, 2002; Wiszniowski *et al.*, 2006).

O teor de sólidos voláteis determina indiretamente a quantidade de material passível de ser degradado nos resíduos. O lixiviado na fase inicial de decomposição apresenta elevado teor de sólidos voláteis, apontando para grande quantidade de matéria orgânica, e os baixos valores indicam que já passou por um acentuado processo de degradação (Da Silva e Mota, 2019). A análise da relação de sólidos voláteis totais e sólidos fixos totais é enfatizado por Venkataramani *et al.* (1984) como determinante na tratabilidade biológica do lixiviado e quanto maior a relação, maior a probabilidade de um bom tratamento biológico.

Alguns metais pesados típicos do lixiviado são Zn, Ni, Pb, Cu, Cr e Cd e metaloides como As, Se, Hg e Co. A natureza não biodegradável e solúvel dos metais pesados faz com que eles persistam no lixiviado por muito tempo (Ishak *et al.*, 2016). Os metais pesados podem ser principalmente liberados no lixiviado por baterias, peças automotivas, fiação elétrica, ligas, tintas, filamentos de lâmpadas e cerâmica (Trabelsi *et al.*, 2009). Mitrano *et al.* (2017)

encontraram partículas contendo Zn, Ag e Cu no lixiviado de resíduos de incineração, na Suíça. Para Mueller e Nowack (2008) essas concentrações de metais representam uma ameaça significativa ao meio ambiente, mesmo após incineração.

O lixiviado quando não é acondicionado corretamente ou tratado de forma adequada, pode contaminar o solo, lençol freático e águas superficiais. Esta contaminação pode ser causada também por falhas de impermeabilização da camada de base da célula do aterro sanitário (Da Silva e Mota, 2019).

Alguns aterros sanitários utilizam da técnica de recirculação do lixiviado no maciço sanitário, que embora não elimina a necessidade de tratamento do lixiviado, contribui para acelerar o processo de estabilização de materiais orgânicos presentes nos resíduos aterrados (Silva, 2023; Ferreira *et al.*, 2001; McBean, Rovers, Farquhar, 1995; Tchobanoglous, Theisen, Vigil, 1993)

Reinhart, Al-Yousif, (1996) determinaram que os efeitos principais positivos da recirculação são: a redução do volume de lixiviado (por evaporação), controle do volume de lixiviado em períodos de pico (precipitação), contribuição para o equilíbrio da variação da concentração química e biológica do lixiviado, aumento da taxa de recalque do aterro, ampliando o volume disponível para aterramento de resíduos. E o principal aspecto negativo relacionado a recirculação, quando usado em excesso, pode provocar instabilidades no maciço, através de problemas de estabilidade de taludes.

Segundo Hussein e Ibrahim (2023), que realizaram um estudo de revisão sobre o impacto da recirculação de lixiviados em aterros sanitário, constataram que essa ação promove o aumento de contato entre bactérias metanogênicas e matéria orgânica dissolvida e ajuda a tamponar o pH durante o processo de hidrólise. E concluíram que essa técnica, melhora a decomposição dos resíduos através da permeação na massa de RSU, através da biodegradação acelerada.

2.3 Lixiviado em regiões semiáridas

Em regiões de clima quente e úmido o processo de decomposição é acelerado, podendo alcançar a fase metanogênica mais rapidamente e conforme Lo (1996), dentro do primeiro ano de funcionamento do aterro. Entretanto, regiões áridas e semiáridas, os aterros sanitários e o lixiviado gerado apresentam fases de degradação e características diferenciadas devido aos fatores climáticos presentes no local onde está inserido o empreendimento, à baixa taxa de precipitação e alto índice de insolação.

Em um aterro sanitário localizado no Irã, região de clima semiárido, Vahabian *et al.* (2019) estudaram resíduos sólidos de uma célula encerrada (2000 a 2007) e uma outra em plena atividade (início em 2007). Foi verificado uma maior concentração de poluentes na célula mais antiga, e provavelmente essa característica se deve às condições climáticas (baixa precipitação anual e seca extrema), que resulta em uma lenta decomposição dos resíduos, influenciando nas características e volume dos lixiviados com diferentes estágios de estabilização.

Outro estudo realizado em uma região semiárida, aterro sanitário na Palestina, Abunama *et al.* (2021) concluíram que este aterro apresentou as menores taxas de geração de lixiviado e maior potencial de poluição do que este efluente em regiões úmidas, revelando o efeito da diluição dos altos níveis de chuvas em climas úmidos.

Ghiasinejad *et al.* (2021) aplicaram um modelo de balanço hídrico desenvolvido para estimar a quantidade de lixiviado em regiões áridas e semiáridas. Foram implementados para caracterizar as propriedades hidrológicas básicas dos RSU e o efeito das condições climáticas na produção de lixiviado, testes de capacidade de campo, condutividade de água saturada e evaporação direta de resíduos. Foi constatado que a evaporação tem um papel crucial na redução da quantidade de lixiviado primário, e quase 30% da precipitação foi perdida como evaporação, resultando em uma maior carga poluidora ao ambiente devido às grandes concentrações de contaminantes.

Portanto, o lixiviado de regiões semiáridas apresentam condições e características particulares, em função das condições climáticas. Assim, deve-se conhecer os resíduos aterrados bem como o efluente gerado, pois suas características influenciam diretamente no tratamento a ser adotado a esse efluente.

2.4 Análise estatística

A estatística possui diversas facetas que, dentre elas, podem dispor de planejar experimentos, interpretar os dados obtidos através de pesquisas de campo e apresentar resultados de maneira a facilitar não só a compreensão, mas auxiliar nas tomadas de decisões. Busca-se também através da estatística modelar aleatoriedades e incertezas, possibilitando assim previsões ou até mesmo realizando estimativas conforme o objetivo (Guedes, 2020).

É subdividida em três áreas distintas: descritiva (descreve os dados de forma organizada, mostrando o comportamento de forma global), probabilística (ajusta os valores experimentais a modelos probabilísticos conhecidos) e inferencial (analisa os dados e busca por um nível de confiança para a veracidade do comportamento).

Assim, a estatística é uma importante ferramenta que irá auxiliar na análise dos dados coletados no sistema integrado de tratamento de lixiviado, sobretudo na compreensão do funcionamento quanto a eficiência do tratamento.

Os objetivos da estatística descritiva incluem o planejamento, coleta de dados, classificação, apuração e a exposição dos dados através de tabelas e gráficos. Etapas essas, que auxiliam na análise, interpretação e conclusão (Borges, 2003). Na estatística descritiva os elementos mais utilizados são as medidas de localização (média, mediana e moda) e de dispersão ou variabilidade (amplitude, variância, desvio padrão e coeficiente de variação) (Araujo Neto, 2021).

Para verificar a significância do estudo aplica-se um teste de hipótese, o método da análise de variância (ANOVA) agrupa em uma tabela e determina dentre outras informações a soma dos quadrados dos resíduos (SQR), que quanto menor o valor encontrado entre os modelos, pode inferir que é o melhor desses modelos que se ajustam ao banco de dados utilizados (Silva, 2006).

O coeficiente de correlação entre duas variáveis, seja variável independente e dependente ou entre a variável observada e prevista, pode ter vários graus, dependendo da maior ou menor dependência entre elas. Se as variáveis forem totalmente dependentes entre elas e não houver nenhum outro fator que interfira entre elas, têm-se uma correlação perfeita. Em casos com interferência de outras variáveis na relação das viáveis, a correlação diminuirá, podendo até deixar de existir. Devore (2018) definiu a intensidade que representa cada faixa de coeficiente de correlação, conforme a Tabela 3.

Tabela 3 – Coeficiente de correlação estatística, ou coeficiente de correção de Pearson

Coeficiente de correlação	Definição
0 a 0,19	Correlação bem fraca
0,2 a 0,39	Correlação fraca
0,4 a 0,69	Correlação moderada
0,7 a 0,89	Correlação forte
0,9 a 1	Correlação muito forte

Fonte: Devore (2018).

2.5 Banco de dados

A disponibilidade de bancos de dados, fornecem a base para os modelos de aprendizagem de máquina executarem diversas tarefas. Em algumas ocasiões, a quantidade de

informação disponível é limitada, havendo a necessidade da utilização de técnicas para obtenção de um banco de dados robusto e que represente o estudo (Almeida *et al.*, 2022).

Segundo Schons (2018), quando há limitação de informações para os modelos de aprendizagem profunda (*Deep Learning*), frequentemente se deparam com os desafios do *overfitting* que é quando o modelo pode apresentar um desempenho preciso nos dados de treinamento, mas não consegue generalizar ou extrapolar os dados durante o teste, ou do *underfitting* que é um cenário onde o desempenho do modelo já é ruim no próprio treinamento, ou seja, o modelo não consegue encontrar relações entre as variáveis, já se mostrando inviável.

Para sanar essas dificuldades e obter êxito nas análises, uma estratégia promissora envolve a adoção da técnica de aumento de dados (*Data Augmentation*). Este método é altamente eficaz em mitigar essas questões, além de ser indicado para aprimorar o desempenho do modelo. Esta técnica consiste em aumentar artificialmente o tamanho do conjunto de treinamento (banco de dados de entrada), gerando dados sintéticos a partir das informações originais (Castro, 2020).

Outra vantagem na utilização de dados sintéticos é a possibilidade de uso para complementar, aumentar ou até mesmo substituir dados reais ao treinar modelos de aprendizagem de máquina, sem o risco de exposição que acompanha a divulgação de dados (SDV, 2023). Vários geradores de dados sintéticos foram desenvolvidos na última década, impulsionados pelos avanços na aprendizagem automática e pela crescente procura de partilha de dados rápida e inclusiva (Dankar *et al.*, 2022).

Por meio de um Ambiente de Desenvolvimento Integrado (*Integrated Development Environment – IDE*), que é um programa dedicado ao desenvolvimento de software, onde integram diversas ferramentas, sendo que a maioria dos IDE oferecem suporte a muitas linguagens de programação diferentes, contendo muito mais recursos. Dentre editores e IDE específicos do *Python*, têm-se: *PyCharm*, *Spyder* e *Thonny*. O *Spyder* é um IDE Python de código aberto otimizado fluxos de trabalho de ciência de dados, e vem incluído na distribuição do gerenciador de pacotes *Anaconda Navigator* (Fincher, 2023).

Entre as ferramentas para a obtenção de dados sintéticos têm-se o Google *Colaboratory*®, mais conhecido como Google Colab. Essa plataforma é um serviço de nuvem gratuito, hospedado pela própria Google, com o intuito incentivar a pesquisa de aprendizagem de máquina (*Machine Learning*) e Inteligência Artificial. Outra ferramenta bastante utilizada na área da programação é o *Jupyter lab*, através da plataforma *Anaconda Navigator*. Que assim como o google Colab permite o desenvolvimento de códigos em Python no próprio navegador, facilitando a configuração e o compartilhamento de códigos.

A obtenção dos dados sintéticos é possível através da biblioteca *Synthetic Data Vault* (SDV) que consiste na geração de dados com base no conjunto de dados fornecidos apresentando as mesmas propriedades e estatísticas do conjunto de dados original. Por meio do SDV é possível gerar dados sintéticos usando aprendizado de máquina (*deep learning model*), através de diversos modelos, dentre eles o modelo *Gaussian Copula*, que vão desde métodos estatísticos clássicos até métodos de aprendizado profundo. Esses dados gerados podem ser uma única tabela, várias tabelas ou séries temporais, dependendo da necessidade (SDV, 2023).

O SDV, foi desenvolvido em 2016 por Patki *et al.* (2016). Esta biblioteca estima a distribuição conjunta de dados usando uma cópula gaussiana latente (Trivedi e David, 2007). Dado o conjunto de dados privado D extraído da população P , o SDV modela a função de distribuição cumulativa da população F da amostra, especificando separadamente as distribuições marginais dos diferentes atributos, F_1, \dots, F_d , bem como a estrutura de dependência entre esses atributos através da *Gaussian Copula*. As distribuições marginais são inferidas da amostra D , e a *Gaussian Copula* é expressa em função da matriz de covariância.

O SDV é implementado em Python e assume que todos os atributos são numéricos. Quando a suposição não se aplica, o SDV aplica o pré-processamento básico no conjunto de dados para transformar todos os atributos categóricos em valores numéricos entre $[0,1]$ (o valor reflete sua frequência no conjunto de dados). Os valores de data e hora são transformados em valores numéricos contando o número de segundos de um determinado carimbo de data/hora. Valores ausentes são considerados informações importantes e são modelados como valores nulos (Dankar *et al.*, 2021).

Segundo Medium (2021) quando discutido sobre a importância da padronização e normalização dos dados em *Machine Learning* é ressaltado que nem todos os modelos de aprendizado de máquinas precisam de dados em uma escala comum. Porém, uma vez que os valores dos pesos dos modelos estejam em escalas diferentes, o modelo “aprenderá” que determinados dados terão maior relevância para a previsão do que outros dados, e o resultado do modelo dará pela influência de alguns dados e não pela importância entre as variáveis. Logo, diante da discrepância dos valores das variáveis dentro dos bancos de dados, seja experimental ou sintético, é aconselhável testar as mais de uma forma para avaliar qual tem o melhor desempenho e acurácia para o ajuste dos dados.

A Padronização dos dados os coloca em uma mesma escala, com a média em 0 e o desvio padrão em 1. Esse algoritmo é melhor utilizado quando a distribuição é Gaussiana.

A fórmula z-score é uma das mais comuns utilizada na padronização de dados, e está determinada através da Equação 1

$$Z = \frac{(x - \mu)}{\sigma} \quad \text{Equação 1}$$

Sendo: x = o valor da variável

μ =o valor da média

σ = o valor do desvio padrão

Z = valor padronizado

A normalização consiste em colocar os dados em intervalo entre 0 e 1 ou -1 e 1, caso haja valores negativos, sem distorcer as diferenças nas faixas de valores. A Equação 2 determina a normalização dos dados.

$$Z = \frac{(X - X_{\min})}{(X_{\max} - X_{\min})} \quad \text{Equação 2}$$

Sendo: X = o valor da variável

X_{\min} =o menor valor da variável

X_{\max} = o maior valor da variável

Z = valor normalizado

2.6 Modelagem para predição do lixiviado

A modelagem matemática, conforme Bassanezi (2006), consiste em modelar circunstâncias reais, podendo imitar e as vezes prever situações, através da sua conversão em problemas matemáticos, sendo a interpretação das soluções na linguagem do mundo real. Essa metodologia, que consiste em modelar informações, tem se mostrado eficaz e inúmeros modelos matemáticos foram desenvolvidos e aplicados a diversas áreas do conhecimento.

Alguns modelos matemáticos foram desenvolvidos para simular quantidade e qualidade de lixiviado de aterros sanitários, a fim de controlar os impactos ambientais, como a poluição de águas subterrâneas, superficiais, auxiliar nas tomadas de decisões contribuindo na orientação dos projetos de controle, recirculação e coleta de lixiviado. Esses modelos têm-se mostrado mais eficiente na estimativa da quantidade do que na qualidade de lixiviado, devido às incertezas à estimativa de parâmetros utilizados no modelo que nem sempre descrevem adequadamente os complexos processos físicos, químicos e biológicos dos RSU do aterro

sanitário. Esses modelos tornam-se cada vez mais úteis à medida que mais dados de campo são obtidos e usados para fins de calibração e validação (El-Fadel *et al.*, 1997).

Assim, a modelagem matemática com parâmetros de lixiviados ainda não é amplamente utilizada, havendo muito a ser estudado e descoberto. Os primeiros modelos matemáticos, abordando o lixiviado, foram desenvolvidos para a geração e transporte de solutos contaminantes através de um aterro sanitário (Demetracopoulos *et al.*, 1986). Gau e Chow, (1998), aplicaram a modelagem para simular a qualidade do lixiviado em aterros anaeróbios e semiaeróbios, com combinações de resíduos incinerados.

Gönüllü (1994) desenvolveu um modelo para estimar a concentração de orgânicos, medida como DQO, em lixiviados de áreas de disposição de resíduos sólidos, sendo comparado com os dados experimentais de duas plantas em escala laboratorial. Kouzeli-Katsiri *et al.* (1999), desenvolveram um modelo matemático simples, com duas equações usando cinética de primeira ordem para descrever os processos, simulando a decomposição de resíduos sólidos em aterros sanitários, levando em consideração a troca da matéria orgânica entre as fases sólidas e líquida, e o esgotamento da matéria orgânica dissolvida devido à decomposição biológica, o campo de estudo foram lisímetros piloto em escala laboratorial.

Ozkaya *et al.* (2006) realizaram o monitoramento por 920 dias dos parâmetros de sulfato, cloreto, DQO e DBO em lixiviados produzidos em duas células de teste em grande escala no Aterro Sanitário de Odayeri, em Istambul, na Turquia. E apresentaram um modelo matemático dessas concentrações para duas células teste, uma de controle e outra com recirculação do lixiviado, comparando a eficiência do efeito da recirculação.

Devido ao avanço tecnológico, os modelos matemáticos estão se inclinando para abordagens de modelagens com o uso de inteligência artificial (IA), dentre elas, as redes neurais artificiais. IA são métodos projetados computacionalmente para reproduzir o pensamento humano ou habilidades cognitivas na solução de problemas. Esta técnica é uma abordagem adequada para resolver problemas de engenharia onde existem muitas entradas ou variáveis aleatórias nas quais a correlação entre entrada e saída é desconhecida (Alidoust *et al.*, 2021). Nesse sentido, as redes neurais artificiais, como um ramo da IA, são usadas para criar modelos, principalmente com base em dados experimentais, para fazer previsões sem ser explicitamente programado para isso (Kandiri *et al.*, 2020).

Karaca e Özkaya (2006) propuseram um modelo de lixiviado baseado em rede neural para prever a taxa de fluxo de lixiviado no aterro de Istambul. A RNA selecionada no estudo possui uma arquitetura com três camadas (entrada, oculta e saída) e uma função de transferência *tan-sigmoid* na camada oculta, bem como uma função de transferência linear na camada de

saída. Um algoritmo de *Levenberg-Marquardt* foi o que apresentou melhor desempenho com o $R^2 = 0,84$.

Cavalcanti *et al.* (2015) desenvolveram, com o auxílio do toolbox NNtool do software MatLab, uma rede neural *feedforward backpropagation* com 3 camadas (entrada, oculta e saída) para predizer o grau de degradação de lixiviado *in natura* utilizando processo foto-fenton solar. A configuração do modelo neural que proporcionou o melhor desempenho possuía uma função de transferência logaritmo sigmoidal (*logsig*) na camada oculta com 9 neurônios e função de transferência linear (*purelin*) na camada de saída. O algoritmo de treinamento utilizado foi *Levenberg-Marquardt backpropagation*.

Conforme demonstrado nos estudos mencionados anteriormente, os modelos de inteligência artificial são técnicas bem conhecidas e profundas na modelagem e previsão de dados. No entanto, a maioria desses estudos foi feita na modelagem da taxa de geração de gases de aterro, mas não há estudos suficientes sobre a previsão de lixiviados (Abunama *et al.*, 2019). Apesar que, o gerenciamento de lixiviados está entre os principais elementos a serem considerados nas atividades de projeto e operação de aterros sanitários devido aos seus vários conteúdos inorgânicos e orgânicos, bem como metais pesados (Vithanage *et al.*, 2017). O desenvolvimento de RNA para modelar o comportamento do lixiviado atenderá essa demanda tão necessária para o gerenciamento de aterros sanitários, principalmente de regiões semiáridas.

2.6.1 Redes Neurais Artificiais

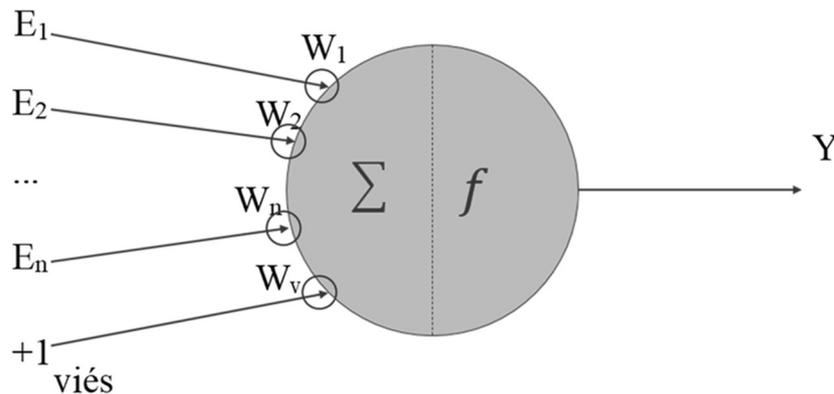
As Redes Neurais Artificiais (RNA) são sistemas computacionais adaptativos inspirados nas características de processamento de informação encontradas nos neurônios reais e nas características de suas interconexões, incluindo a capacidade de aquisição e manutenção do conhecimento adquirido (Haykin, 1999; Silva *et al.* 2010).

A rede neural é dada por um conjunto de neurônios (elementos processadores) que são interligados por um número grande de conexões capazes de aprender (ajuste de pesos), armazenar conhecimentos e adaptar a novas situações. O principal diferencial das redes neurais artificiais é a capacidade de aprender por meio de exemplos (padrões), e de generalizar (fornecer respostas adequadas para dados que não estão no conjunto de exemplos). Uma rede neural possibilita solucionar problemas complexos sem a necessidade de definições explícitas entre dados de entrada e saídas (Braga, 2014).

O primeiro modelo matemático para uma rede neural foi proposto por McCulloch e Pitts (1943). Assim como o neurônio biológico o neurônio artificial possui sinais de entrada (Ei) e

saída (Y). O corpo do neurônio é dividido em duas partes, sendo a primeira responsável por somar (Σ) o produto das entradas E_i pelos seus respectivos pesos w_i . Na segunda parte têm-se a função de ativação ou transferência f , que irá controlar o valor a ser enviado pela saída Y. Além das entradas E_i , também se prevê uma entrada extra, chamada entrada de viés (bias), que sempre tem como entrada o valor unitário, conforme ilustrada na Figura 2.

Figura 2 – Neurônio artificial



Fonte: Acervo da pesquisa (2021).

2.6.1.1 Função de ativação

A função de ativação, também denominada de função de transferência, corresponde a transformação não-linear dos dados de entrada, tornando-o capaz de aprender e executar tarefas mais complexas. A função de ativação é usada para aumentar a capacidade de expressão do modelo de rede neural, promovendo o significado de inteligência artificial (Wang *et al.*, 2020). Segundo Haykin (2001), Dubey, Singh e Chaudhuri, 2022, existem diversos tipos de funções de ativação, dentre elas:

- Função de linear (*purelin*) é considerada uma função de ativação simples (Equação 3), que produz kx para a entrada x com k como constante (Figura 3).

$$\text{função linear } (x) = kx$$

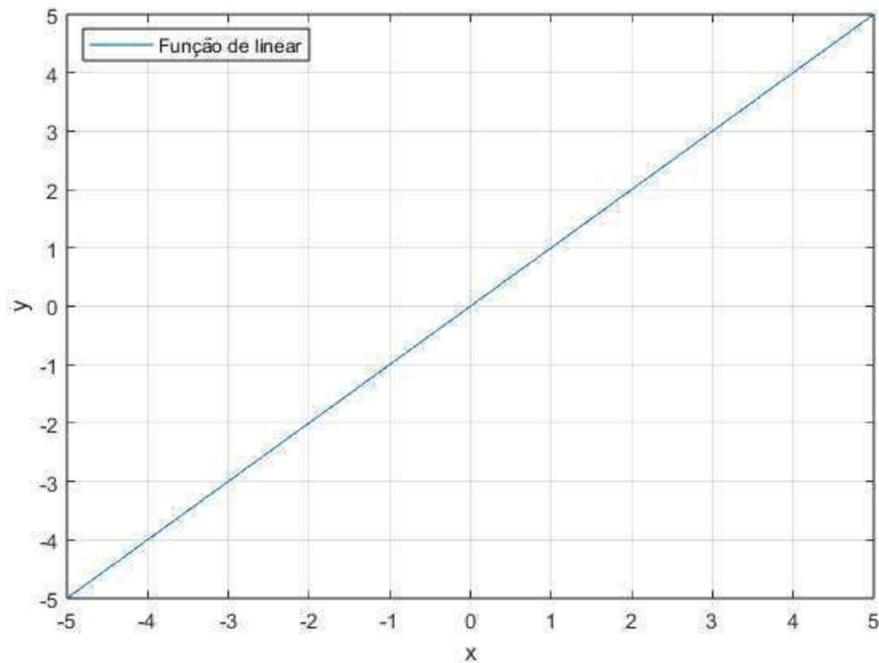
Equação 3

Sendo: *função linear* (x) = variável dependente;

k = o constante;

x = variável independente

Figura 3 - Representação da função linear



Fonte: Bezerra (2023).

- Função sigmoidal (*logsig*): apresenta um gráfico no formato de S, é a forma mais comum de função de ativação, e é definida como uma função crescente com balanceamento adequado entre o comportamento linear e não linear e assume um intervalo de variação entre 0 e 1 (Fleck *et al.*, 2016). Um exemplo de função sigmóide é a função logística, definida pela Equação 4 e representada na Figura 4.

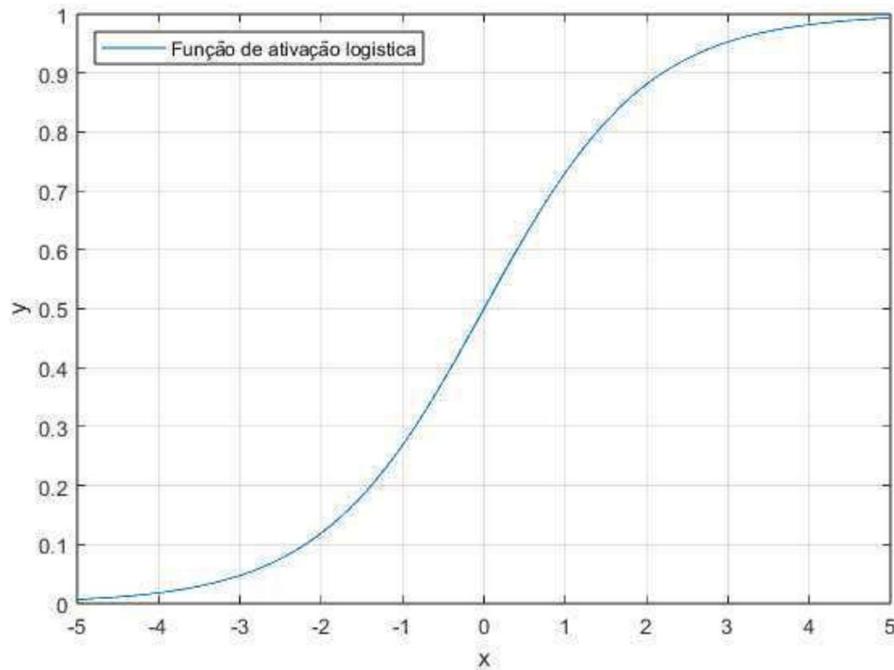
$$\text{função logística } (x) = \frac{1}{1 + e^{(x)}}$$

Equação 4

Sendo: *função logística* (x)= variável dependente;

x = variável independente

Figura 4 - Representação da função sigmoide



Fonte: Bezerra (2023).

- Função tangente hiperbólica (*tansig*): é semelhante a função Logistic Sigmoid enquanto exibe a propriedade centrada em zero. É uma função não linear, o resultado de saída sempre assumirá valores reais entre -1 e 1, representada pela Equação 5 e Figura 5.

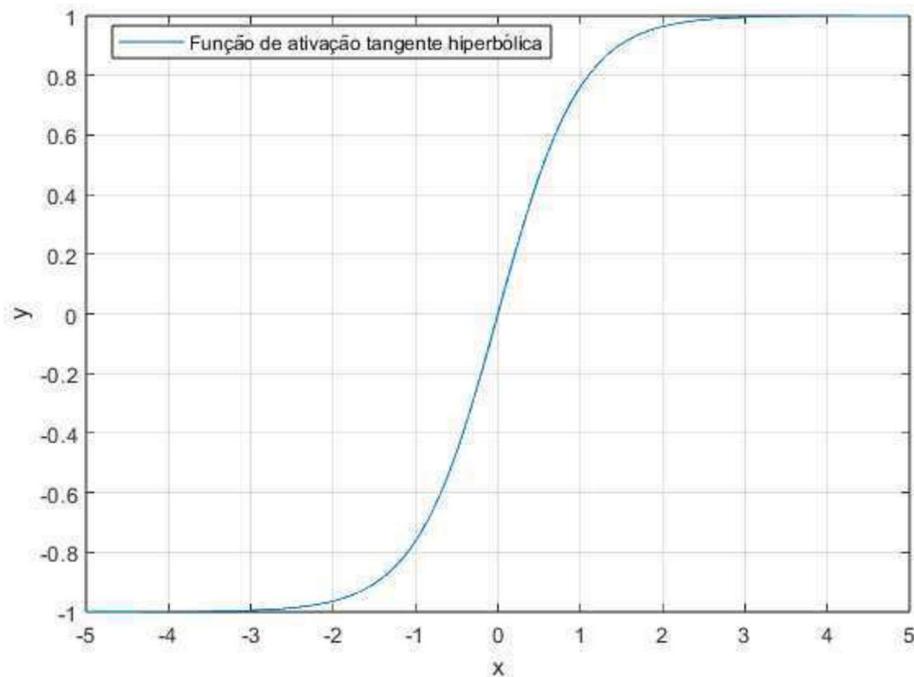
$$\text{função } (x) = \frac{1 - e^{(-2x)}}{1 + e^{(-2x)}}$$

Equação 5

Sendo: *função* (x) = variável dependente;

x = variável independente

Figura 5 – Representação da função tangente hiperbólica



Fonte: Bezerra (2023).

- Função sigmoide simétrica (*elliotsig*): a vantagem dessa função de transferência sobre os outros sigmoides é que ela é rápida para calcular em *hardware* de computação simples, pois não requer nenhuma função exponencial ou trigonométrica (Nguyen, Fernandes e Teixeira, 2022). Representada na Equação 6 e Figura 6.

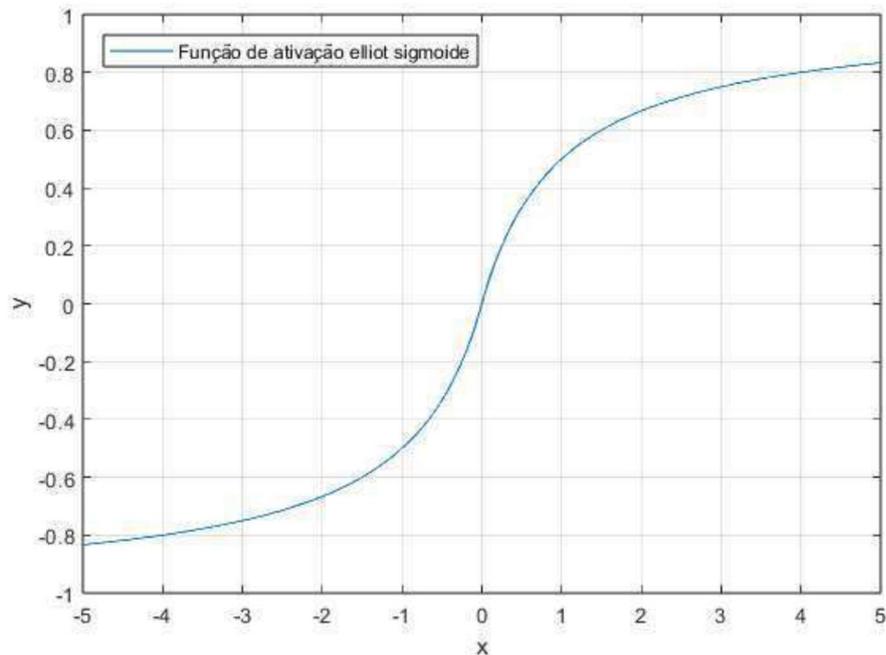
$$\text{função}(x) = \frac{x}{\sqrt{1+x^2}} + 0,5$$

Equação 6

Sendo: *função logística* (x)= variável dependente;

x = variável independente

Figura 6 - Representação da função simétrica de Elliot



Fonte: Bezerra (2023).

2.6.1.2 Algoritmos de treinamento

Os principais algoritmos de retropropagação que podem ser usados durante a etapa de treinamento de RNA e suas respectivas funções no *MatLab*, estão descritos na Quadro 1.

Quadro 1 - Principais algoritmos de retropropagação e suas respectivas funções no *MatLab*

Algoritmo	Função
Levenberg-Marquardt	<i>trainlm</i>
Bayesian Regularization	<i>trainbr</i>
BFGS quase-Newton	<i>trainbfg</i>
Conjugate gradiente with Powell-Beale restarts	<i>traincgb</i>
Conjugate gradiente with Fletcher-Reeves updates	<i>traincgf</i>
Conjugate gradiente with Polak-Ribière updates	<i>traincgp</i>
Gradiente descent	<i>traingd</i>
Gradient descente with adaptive learning rate	<i>traingda</i>
Gradient descente with momentum	<i>traingdm</i>
Gradient descente with momentum and adaptive learning rate	<i>traingdx</i>
Scaled conjugate gradiente	<i>trainscg</i>
One-step secant	<i>trainoss</i>
Resilient backpropagation	<i>trainrp</i>

Fonte: Pauletto, (2022).

O processo de treinamento das RNA é interrompido automaticamente quando todos os erros estão dentro da tolerância requerida ou quando o número de interações é atingido (Asl *et al.*, 2013; Ghaedi e Vafaei, 2017; Pauletto, 2022).

2.6.1.3 Arquiteturas

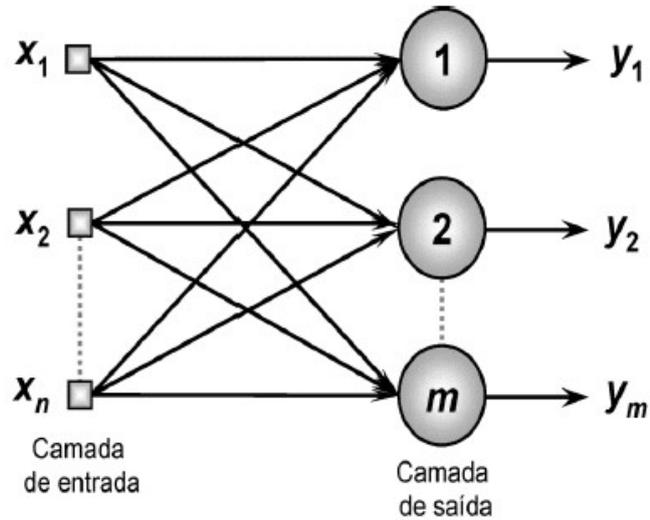
A arquitetura de uma rede neural artificial define a forma como os seus diversos neurônios estão arranados, ou dispostos, uns em relação aos outros. Sendo esses arranjos estruturados através do direcionamento das conexões sinápticas dos neurônios (Silva *et al.*, 2010).

Uma das maiores dificuldades encontradas no uso das redes neurais é a escolha da melhor arquitetura, uma vez que esse processo é experimental e demanda um grande tempo de execução (Albuquerque, 2019). Miranda *et al.* (2009) afirmam que na prática deve-se realizar testes com vários métodos de aprendizados e diferentes configurações, para chegar a melhor aplicação da rede.

De acordo com Silva *et al.* (2010) a rede neural artificial pode ser dividida em três partes, conhecidas por camadas. Sendo elas: camadas de entrada (responsável pelo recebimento de informações), camadas escondidas, intermediárias, ocultas ou invisíveis (compostas por neurônios responsáveis por extrair as características associadas) e camadas de saída (contendo neurônios responsáveis pela produção e apresentação dos resultados da rede). E as principais arquiteturas podem ser divididas em:

- *Feedforward* de camada simples: consta com apenas uma camada de entrada e uma única camada de neurônios, que é a própria camada de saída (Figura 7). O fluxo de dados segue sempre em uma única direção e a quantidade de saídas sempre coincidirá com o número de neurônios. São tipicamente empregadas em problemas que envolvam classificação de padrões e filtragem linear.

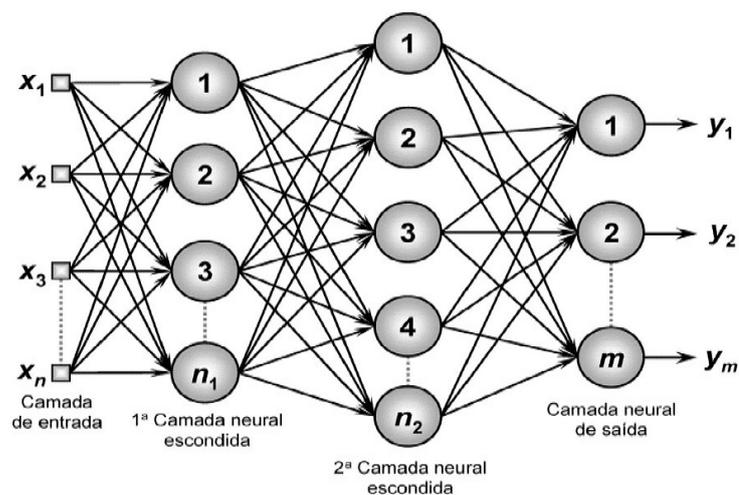
Figura 7 - *Feedforward* de camada simples



Fonte: Silva *et al.* (2010).

- *Feedforward* de camadas múltiplas: são constituídas pela presença de uma ou mais camadas ocultas de neurônios (Figura 8). Geralmente, um sinal é recebido pela camada de entrada. Passando, em seguida, por uma camada oculta onde o sinal é multiplicado por um peso e após a soma ponderada dos sinais tratados nesta camada, o sistema produz uma saída, baseada da extrapolação de um limite (Haykin, 2001). São aplicadas para aproximação de funções, classificação de padrões, identificações de sistemas, otimização, robótica e controle de processos.

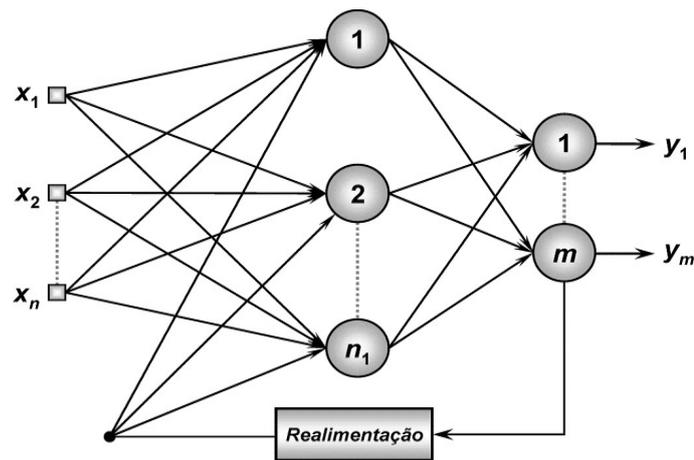
Figura 8 - *Feedforward* de camadas múltiplas



Fonte: Silva *et al.* (2010).

- Recorrente ou realimentada: quando as saídas dos neurônios são alimentadas como sinais de entrada para outros neurônios (Figura 9). Funcionam muito bem para processamento dinâmico de informações, envolvendo variantes em relação ao tempo, como previsão de séries temporais, otimização e identificação de sistemas, e controle de processos.

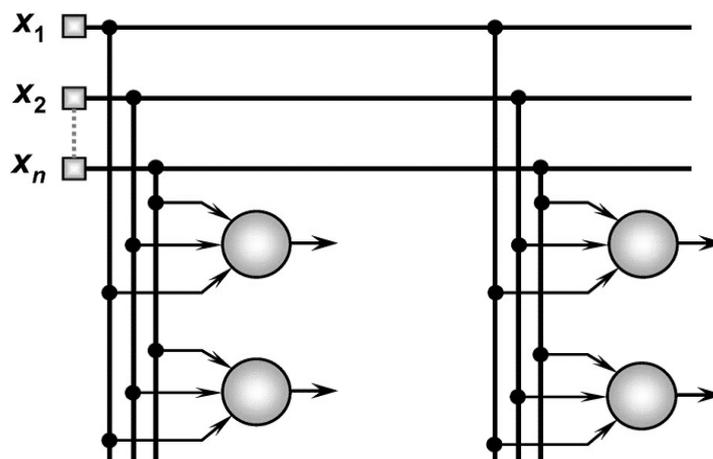
Figura 9 - Rede recorrente ou realimentada



Fonte: Silva *et al.* (2010).

- Rede reticulada: suas principais características são as disposições espaciais dos neurônios visando propósitos de extração de características. Assim, a localização espacial dos neurônios está diretamente relacionada com o processo de ajuste dos seus pesos e limiares (Figura 10).

Figura 10 - Rede reticulada



Fonte: Silva *et al.* (2010).

Considerando uma determinada arquitetura, a topologia pode ser definida como sendo as diferentes configurações que a rede neural pode assumir. Assim, a arquitetura pode contar com as topologias variando em: a) número de nós na camada de entrada (tal variável corresponde ao número de variáveis que serão usadas para alimentar a rede neural, sendo normalmente as variáveis de maior importância para o problema em estudo); b) número de camadas escondidas e número de neurônios a serem colocados nessas camadas e; c) número de neurônios na camada de saída (Santos *et al.*, 2005).

Henriques (2019), destaca algumas arquiteturas definidas para a modelagem de uma RNA: Adaline, Redes Neurais Convolucionais, Perceptron camada múltipla, Camada recorrente, Estrutura reticulada, Long, Short-Term Memory (LSTM), Redes de Hopfield, entre tantas outras arquiteturas que existem e outras que ainda se encontram em fase de desenvolvimento.

2.6.1.4 Aprendizado

O treinamento de uma arquitetura específica consiste na aplicação de um conjunto de passos ordenados, denominado de algoritmo de aprendizagem, que possuem o intuito de ajustar os pesos e os limiares de seus neurônios. Logo, o processo de aprendizagem de uma rede neural é fundamentado em aprender de acordo com um ambiente e assim melhorar seu desempenho (Haykin, 2001).

Existem duas formas básicas de aprendizado de redes neurais: aprendizado supervisionado e aprendizado não supervisionado (Haykin, 2001):

- **Aprendizado supervisionado:** um agente externo apresenta à rede neural alguns conjuntos de padrões de entrada e seus correspondentes padrões de saída. A resposta fornecida pela rede neural é comparada à resposta esperada. O erro verificado é informado à rede para que sejam feitos ajustes a fim de melhorar suas futuras respostas (Haykin, 2001; Silva *et al.*, 2010);
- **Aprendizado não supervisionado:** são inseridos apenas os conjuntos de padrões de entrada (atributos de entrada), sendo a saída definida pela própria rede (Artero, 2009).

2.6.1.5 Avaliação do desempenho de redes neurais artificiais

A avaliação de desempenho de redes neurais artificiais auxilia na identificação dos melhores modelos, que representem e interpretem com precisão o comportamento do lixiviado

de aterros sanitários. Conforme Shcherbakov *et al.*, (2013), uma das questões mais difíceis para avaliar o desempenho das RNA é a escolha das métricas mais adequadas, porém é imprescindível a escolha de mais de uma métrica na realização dessa avaliação.

Vários estudos desenvolvidos para resolução de problemas relacionados aos resíduos sólidos e seus subprodutos, dentre eles, o lixiviado, aplicaram mais de um índice para avaliação de desempenho de RNA. Por exemplo, Cavalcanti *et al.* (2015) utilizaram o erro quadrático médio (MSE) e o coeficiente de correlação (R) para selecionar a melhor RNA para a predição do grau de degradação de lixiviado *in natura*. Abunama *et al.* (2019) utilizaram RMSE, MAE e R para selecionar as melhores RNA de predição das taxas de geração de lixiviado.

Xu *et al.* (2021) analisaram 177 artigos relacionados a RNA e RSU publicados entre 2000 e 2010. Os autores descobriram que 32 índices de avaliação diferentes estavam envolvidos para avaliar o desempenho da modelagem de RNA. Dentre todos os índices de avaliação, o R^2 foi aplicado em mais de 90% dos estudos. RMSE, MSE, MAE e MAPE foram aplicados em 20% a 40% dos estudos, e os outros índices, como o coeficiente de eficiência (E) e o índice de concordância de Willmott (d), foram relatados em menos de 10% dos estudos revisados.

O desempenho das RNA pode ser avaliado com base em diversos critérios estatísticos que possuem diferentes aplicabilidades e limitações. O coeficiente de determinação (R^2) é uma medida estatística usada para indicar a força de uma relação linear entre dois grupos de dados (duas variáveis ou dados observados e previstos) (Perugu *et al.*, 2013). Seu valor varia entre 0 e 1 (0 a 100%), e quanto maior o valor, melhor a concordância entre modelo e observação. O (MAPE) é uma medida de erro percentual e não é adequado para dados contendo valores zero (Xu *et al.*, 2021).

As medidas de erro absoluto, como RMSE, MSE e MAE, representam o desvio médio entre o valor observado e predito. O MSE dá um peso maior para desvios grandes (pois os resíduos são elevados ao quadrado), enquanto o erro absoluto médio (MAE) é usado para avaliar o resíduo ou as diferenças entre os dois grupos de dados ou duas variáveis. Teoricamente, o valor mínimo do MAE é zero, significando que o modelo representa um ajuste perfeito, algo que não é fácil de alcançar (Abunama *et al.*, 2019).

O erro quadrático médio (RMSE) é amplamente aplicado em previsões numéricas, correspondendo a raiz quadrada da média do quadrado de todo erro. Na ocorrência de outlier no conjunto de dados, o peso será maior para o cálculo do RMSE e, por conseguinte, prejudicará sua métrica deixando-a maior. Se o RMSE ficar muito maior que o MAE, provavelmente, há presença de outliers (Araújo Neto, 2021). O erro quadrático médio normalizado (NRME) é uma extensão do RMSE e conforme Shcherbakov *et al.* (2013) sua utilização evita a

dependência de escala e reduz o impacto de outliers. Isso permite comparar a precisão de diferentes modelos ou técnicas em conjunto de dados. Valores menores de NRMSE indicam um melhor desempenho do modelo, pois isso significa que as previsões do modelo estão mais próximas dos valores reais.

Outras medidas estatísticas podem ser utilizadas para fornecer resultados de avaliação mais detalhados ao examinar a precisão das RNA, como o coeficiente de eficiência (também chamado de coeficiente de Nash-Sutcliffe), ou E, desenvolvido por Nash e Sutcliffe (1970), é utilizado com muita frequência na avaliação de modelos. Seu valor fica entre $-\infty$ e 1, e quanto maior o valor, melhor a concordância entre modelo e observação.

3. METODOLOGIA

Neste capítulo é realizada uma breve descrição do campo experimental, o Aterro Sanitário no qual está inserido em uma região semiárida. É apresentado também os procedimentos metodológicos, dentre eles: i) coletas de dados para as análises das condições meteorológicas; ii) caracterização dos resíduos sólidos urbanos; iii) caracterização e monitoramento do lixiviado; iv) banco de dados experimentais e sintéticos e; v) modelagem para determinação das características do lixiviado. Os itens i, ii e iii correspondem as coletas de dados e análises realizadas em campo e laboratório e os itens iv e v as análises numéricas realizadas nos softwares Microsoft Excel®, *Jupyter lab*® e *MATLAB*®.

As etapas desta pesquisa são ilustradas na Figura 11.

Figura 11 – Etapas da pesquisa



Fonte: Autoria própria (2023).

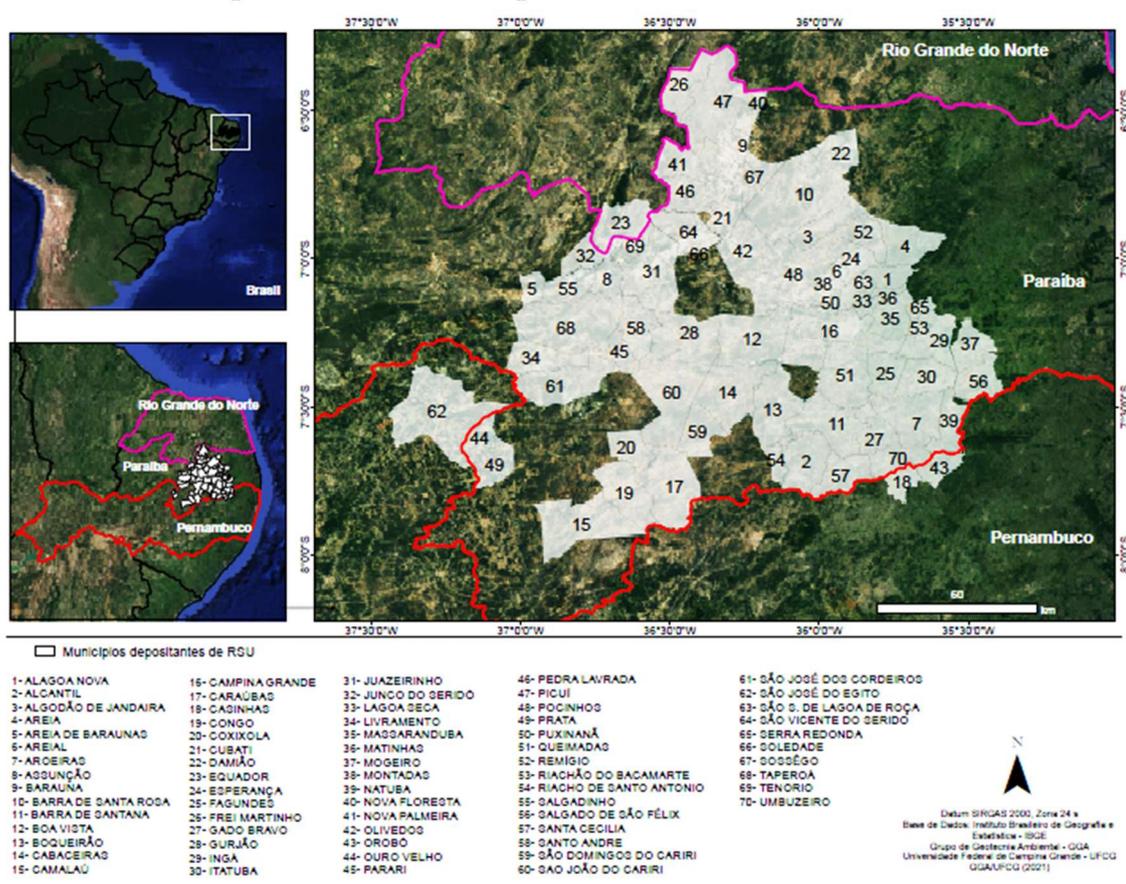
3.1 Caracterização da área de estudo

A área de estudo é o Aterro Sanitário localizado em região semiárida do Brasil. O município ao qual está situado, possui área territorial de 591,658 Km², com população estimada em 413.830 habitantes (IBGE, 2021), situa-se a 551 m de altitude. Segundo dados fornecidos pela AESA (2022) o clima da região é semiárido com temperatura do ar máxima anual média de 28,6 °C, mínima média de 19,5 °C e média de 22,7°C, evaporação anual de 1417,4 mm e pluviosidade média anual de 802,7 mm.ano⁻¹, e conforme a classificação climática proposta por Köppen e Geiger (1928), o município no qual o Aterro Sanitário está inserido tem o tipo de clima Bsh, ou seja, semiárido quente e seco.

A Superintendência do Desenvolvimento do Nordeste (SUDENE) também classifica Campina Grande como uma região semiárida e possui em sua Portaria nº 80 (SUDENE, 2021), responsável pela revisão da delimitação do Semiárido brasileiro, a caracterização do semiárido através das chuvas irregulares, precipitação pluviométrica média anual igual ou inferior a 800 mm, índice de aridez de Thornthwaite igual ou inferior a 0,5 e percentual diário de déficit hídrico igual ou superior a 60%.

O Aterro Sanitário em estudo possui uma área total de 64 ha, onde 40 ha são destinados à disposição de RSU, foi projetado para uma vida útil de 25 anos e está em operação desde julho de 2015. No ano de 2022, recebeu resíduos de 70 municípios, sendo 66 pertencem ao Estado da Paraíba, 3 ao Estado de Pernambuco e 1 ao Estado do Rio Grande do Norte. Equivalendo a uma média de 600 tRSU.dia⁻¹. Na Figura 12 é possível identificar os municípios que depositam RSU no empreendimento.

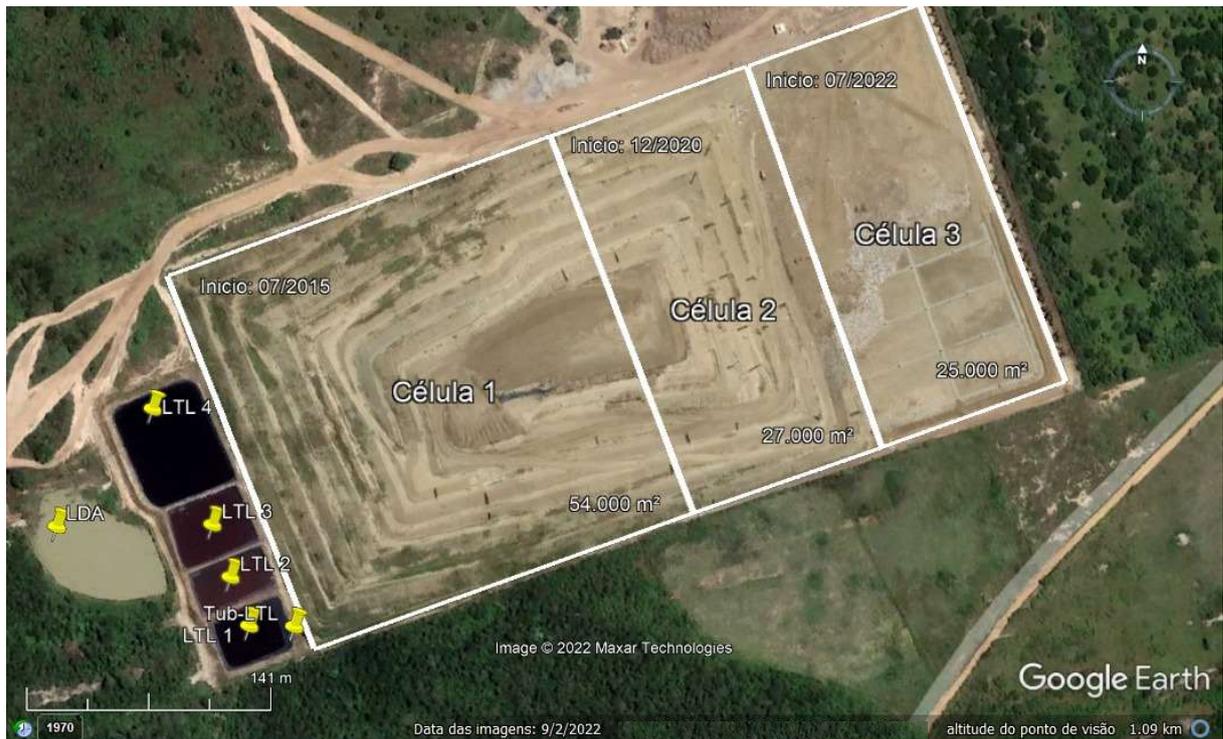
Figura 12 – Localização do Aterro Sanitário em região semiárida e dos municípios que depositaram RSU no empreendimento entre 2015 e 2022



Fonte: GGA (2022).

Desde o início da operação, em julho de 2015 até julho de 2022, o Aterro Sanitário em estudo passou por modificações, a fim de ampliar a capacidade de disposição de RSU. Desta forma, para esse novo cenário, o Aterro Sanitário em questão opera com três Células de RSU, denominadas de Célula 1, Célula 2 e Célula 3 (Figura 13). Os RSU foram depositados exclusivamente na Célula 1 até o mês de dezembro de 2020, passando, a partir dessa data, a serem depositados na Célula 2, que foi construída agregada à Célula 1. Em julho de 2022, finalizou-se o depósito de resíduos nas Células 1 e 2, e se iniciou o depósito de resíduos na Célula 3, que está sendo executada unida à Célula 2.

Figura 13 – Vista superior do Aterro Sanitário em estudo



Fonte: GGA (2022).

O Aterro Sanitário em estudo possui a camada de base de solo compactada, piezômetros do tipo Casagrande, camada de cobertura intermediária, marcos topográficos para medição de deslocamentos horizontais, placas de recalque superficiais, sistema de drenagem de biogás (com e sem queimadores do tipo *flares*), sistema de drenagem de lixiviado (do tipo espinha de peixe) (Figura 14a), a tubulação que leva o lixiviado canalizado até a lagoa de tratamento de lixiviado (tub. LTL – Figura 13) quatro Lagoas de Tratamento de Lixiviado (LTL 1, LTL 2, LTL 3 e LTL 4 – Figura 13), sistema de drenagem de águas pluviais e Lagoa de Drenagem de Águas (LDA – Figura 13). Na camada de base da Célula 3 foi acrescida uma manta geossintética PEAD de 1,5 mm, texturizada apenas em uma face e uma camada de solo para proteção mecânica (Figura 14b).

É importante ressaltar que, todo lixiviado drenado nas Células são conduzidos para a LTL 1 por meio de uma tubulação (Tub LTL). As LTL funcionam como lagoas de acumulação e evaporação de lixiviado, auxiliando no monitoramento de controle da vazão, onde parte desse lixiviado estocado é recirculado para as Células.

Figura 14 – Aterro Sanitário: (a) Sistema de drenagem de lixiviado; (b) Impermeabilização da camada de base com manta geossintética e solo compactado



Fonte: GGA (2022).

3.2 Análise das condições meteorológicas

Para verificar a influência das condições meteorológicas no funcionamento do aterro sanitário, e conseqüentemente aos subprodutos gerados, em especial na quantidade e qualidade do lixiviado produzido, foram analisados dados de precipitação acumulada, evaporação total e temperaturas, a fim de verificar suas influências no Aterro Sanitário em estudo.

O Aterro Sanitário em estudo possui uma estação meteorológica automatizada, porém, a coleta de dados com este equipamento iniciou em abril de 2022. Por esse motivo, os dados meteorológicos utilizados nesta pesquisa serão coletados a partir de uma estação convencional mais próxima ao empreendimento e que tem as informações meteorológicas correspondente ao período de estudo, localizada na Empresa Brasileira de Pesquisa Agropecuária/Algodão (Embrapa Algodão), sendo os dados disponibilizados pelo Instituto Nacional de Meteorologia (INMET).

Apesar, desse estudo, investigar os dados de lixiviado do Aterro Sanitário em região semiárida, a partir de julho de 2017 até julho de 2022, serão consideradas, as condições meteorológicas a partir de janeiro de 2017 até julho de 2022. Deve-se destacar que a composição e volume de lixiviado pode ser influenciada por eventos meteorológicos ocorridos anteriormente a data de início de monitoramento desse lixiviado.

Foram incluídos a essas condições meteorológicas do período equivalente a esta pesquisa, os dados de precipitação e evaporação da série histórica (1981 a 2010) registrados pela mesma estação meteorológica, da Embrapa Algodão, e que estão disponibilizados nas normas climatológicas do Brasil (INMET, 2022).

3.3 Caracterização dos resíduos sólidos urbanos

Realizou-se a coleta para a composição gravimétrica e caracterização físico-química dos RSU que chegam ao Aterro Sanitário em estudo e com três idades de aterramento. As coletas dos RSU seguiram a NBR 10007 (ABNT, 2004) e um planejamento estatístico, com nível de significância de 10%, para a obtenção de amostras representativas às características fidedignas dos resíduos que chegam ao aterro, assim como os processos de transformação ocorridos neles durante e após a disposição.

A massa de resíduos obtida para cada período de análise foi determinada por meio da equação do tamanho da amostra para populações finitas (Equação 7). Dessa forma, foi possível garantir, com nível de confiança de 90%, a representatividade dos resíduos.

$$n = \frac{Z^2 * \sigma^2 * N}{d^2 * (N - 1) + Z^2 * \sigma^2} \quad \text{Equação 7}$$

Sendo:

n = tamanho da amostra;

Z = valor crítico que corresponde ao grau de confiança desejado;

σ^2 = desvio padrão populacional da variável estudada;

N = tamanho da população;

d = erro amostral.

Para caracterizar os resíduos que chegam no Aterro Sanitário em estudo realizou-se a coleta com a participação de 17 municípios, correspondente ao dia que mais recebeu resíduos de diferentes municípios. Os resíduos foram pesados e dispostos em uma área previamente estabelecida, com a identificação de cada município de origem. Selecionou-se de forma proporcional e estratificada uma amostra de 10 t de resíduos, sendo 5,6 t de resíduos provenientes do município de Campina Grande, que é o maior contribuinte e 4,4 t de resíduos dos demais municípios depositantes.

As coletas dos RSU aterrados foram realizadas através de uma retroescavadeira Caterpillar, em regiões pré-estabelecidas, sendo desprezada a camada de cobertura, e os resíduos escavados (Figura 15a) foram dispostos em um caminhão caçamba (Figura 15b),

pesado (aproximadamente 6 t para os resíduos recém aterrados e 1 t para os resíduos com 1 e 2 anos de aterramento - Figura 15c). Após coleta no Aterro Sanitário em estudo, os resíduos foram encaminhados até um galpão para acondicionamento e realização das etapas posteriores (Figura 15d).

Figura 15 - (a) coleta; (b) resíduos acondicionados no caminhão caçamba; (c) pesagem dos resíduos; (d) disposição dos resíduos no galpão



Fonte: Adaptação Araújo Neto (2021) e GGA (2022).

Para a realização da composição gravimétrica, todos os resíduos, independente do tempo de aterramento, foram homogeneizados após aberturas dos sacos, quarteados até obtenção da amostra previamente definida, e segregados manualmente de acordo com a classificação adaptada da norma alemã GDA Empfehlungen E1-7 (DGGT, 1994). Após segregação, os materiais foram pesados, para calcular o percentual de cada componente dos RSU por meio da determinação da massa destes em relação à massa total.

A composição gravimétrica dos RSU é um importante método analítico quantitativo clássico, que tem como objetivo separar e pesar um determinado elemento ou composto definido em sua forma mais pura que foi separado de uma quantidade ou amostra previamente

conhecida. Esses dados permitem conhecer melhor as características dos resíduos, auxiliando nas tomadas de decisões da gestão integrada de resíduos sólidos (INEA, 2021).

Os resíduos foram classificados nos seguintes grupos: plástico, matéria orgânica, vidro, metal, papel, papelão, têxteis sanitários, têxteis e couro, madeira, compósito (materiais constituídos pela junção de mais um tipo de material) e outros. Foram classificados como outros os resíduos de difícil identificação e que não se enquadravam em nenhuma categoria.

Após a composição gravimétrica, determinou-se as características físico-químicas dos resíduos. Para aos ensaios físico-químicos foi necessário a obtenção de um extrato solubilizado e/ou lixiviado obtido a partir da amostra bruta do resíduo, por meio de testes de lixiviação realizados de acordo com a NBR 10.005 de 2004 e de solubilização NBR 10.006 de 2004. Os resíduos foram picotados (Figura 16a), mantendo uma dimensão aproximada de 1x3 cm, em seguida foram diluídos em uma proporção de 0,5 Kg de resíduos para 1 L de água destilada e após imersão por 30 min a amostra foi coada com malha de aproximadamente 1,2 mm, obtendo um extrato (Figura 16b) para realização dos ensaios seguindo os métodos descrito no Quadro 2.

Quadro 2 - Análises físico-químicas e seus respectivos procedimentos metodológicos para o extrato dos resíduos sólidos

Indicadores	Unidade	Método empregado	Metodologia
Teor de umidade	%	Secagem a 103-105 °C	Manassero <i>et al.</i> (1996), Monteiro (2003) e Silva (2012)
Teor de sólidos voláteis	%	Mufla 500 °C	WHO (1979); APHA, AWWA e WEF (2017)
pH	Adimensional	Eletrométrico	
Demanda Bioquímica de Oxigênio (DBO ₅)	mg.L ⁻¹	Diluição em frascos padrões com medidas de oxigênio dissolvido pelo método de Winkler	
Demanda Química de Oxigênio (DQO)	mg.L ⁻¹	Refluxação fechada do dicromato de potássio	

Fonte: Autoria própria (2023).

Figura 16 – Preparação de amostra: (a) picotagem; (b) extrato



Fonte: Adaptação Araújo Neto (2021).

3.4 Caracterização e monitoramento do lixiviado

As coletas de lixiviado *in natura* foram realizadas na tubulação (Tub LTL) que drena todo o lixiviado gerado no Aterro Sanitário em estudo para a primeira lagoa de tratamento de lixiviado (acumulação) (Figura 17a). Para a determinação de vazão de lixiviado a metodologia adotada foi por meio do tempo necessário para o enchimento de um recipiente de volume conhecido posicionado abaixo da Tub LTL (Figura 17b), equivalente a uma proveta graduada de 1000 ml. Esse ensaio foi realizado semanalmente, em triplicata, o tempo de enchimento foi cronometrado simultaneamente, anotado e em seguida feito uma média aritmética.

Figura 17 – Lagoa de Tratamento de Lixiviado do Aterro Sanitário: (a) Tub LTL; (b) teste de vazão e coleta de lixiviado *in natura*



Fonte: GGA (2020).

A coleta do lixiviado foi mensal, iniciou-se em julho de 2017 e seguiu até julho 2022. O lixiviado coletado foi acondicionado em frasco de polipropileno devidamente higienizado e estéril, sendo mantido em caixa térmica durante todo o trajeto até os laboratórios, onde foram realizados os ensaios e análises descritas no Quadro 3.

Quadro 3 - Análises físico-químicas e seus respectivos procedimentos metodológicos para o lixiviado

Ensaio	Unidade	Método empregado	Metodologia
Temperatura	°C	Termômetro digital	APHA, AWWA e WEF (2017)
Sólidos Totais (ST)	mg.L ⁻¹	Secagem a 103-105 °C	
Sólidos Voláteis (SV)	mg.L ⁻¹	Mufla 500 °C	
Turbidez	NTU	Nefelométrico	
pH	adimensional	Eletrométrico	
Alcalinidade total	mgCaCO ₃ .L ⁻¹	Titulação potenciométrica	
DBO ₅	mg.L ⁻¹	Diluição em frascos padrões com medidas de oxigênio dissolvido pelo método de Winkler	
DQO	mg.L ⁻¹	Refluxação fechada do dicromato de potássio	
NAT	mgN.L ⁻¹	Destilação e titulação	
Metais*	mg.L ⁻¹	Espectrometria de absorção atômica com chama	

*Ferro, Alumínio, Níquel, Manganês, Zinco, Cobre, Chumbo e Cromo.

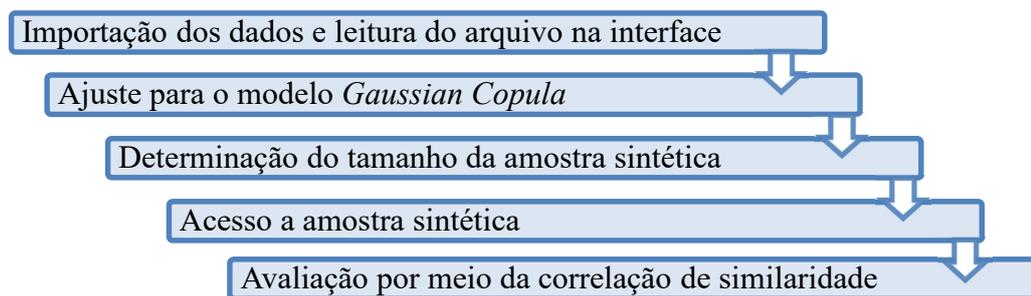
Fonte: Autoria própria (2023).

3.5 Banco de dados sintéticos

Para a formação de dados sintéticos, como plataforma de desenvolvimento foi utilizado o *Jupyter lab* com as versões do *Python 3.8* e a biblioteca *Synthetic Data Vault (SDV)* na versão *SDV 0.17.2*. Por meio dessas configurações foi possível criar bancos de dados sintéticos usando aprendizado de máquina, através do modelo de *Gaussian Copula*, que é capaz de aprender um conjunto de dados, para em seguida gerar dados sintéticos com o mesmo formato e propriedades estatísticas. Os códigos utilizados estão disponíveis no Apêndice A

O processo de criação dos dados sintéticos para 125 e 1000 dados para cada variável analisada seguiu o fluxograma ilustrado na Figura 18:

Figura 18 – Fluxograma do processo de criação do banco de dados



Fonte: Autoria própria (2023).

Após a geração dos bancos de dados sintéticos foram aplicadas técnicas comumente utilizadas em etapas de preparação de dados, a padronização e normalização. Devido a necessidade em ajustar os bancos de dados com intuito de transformar todas as variáveis para a mesma ordem de grandeza, visando analisar o poder dessas práticas na acurácia do modelo das RNA.

3.6 Modelagem para determinação das características do lixiviado

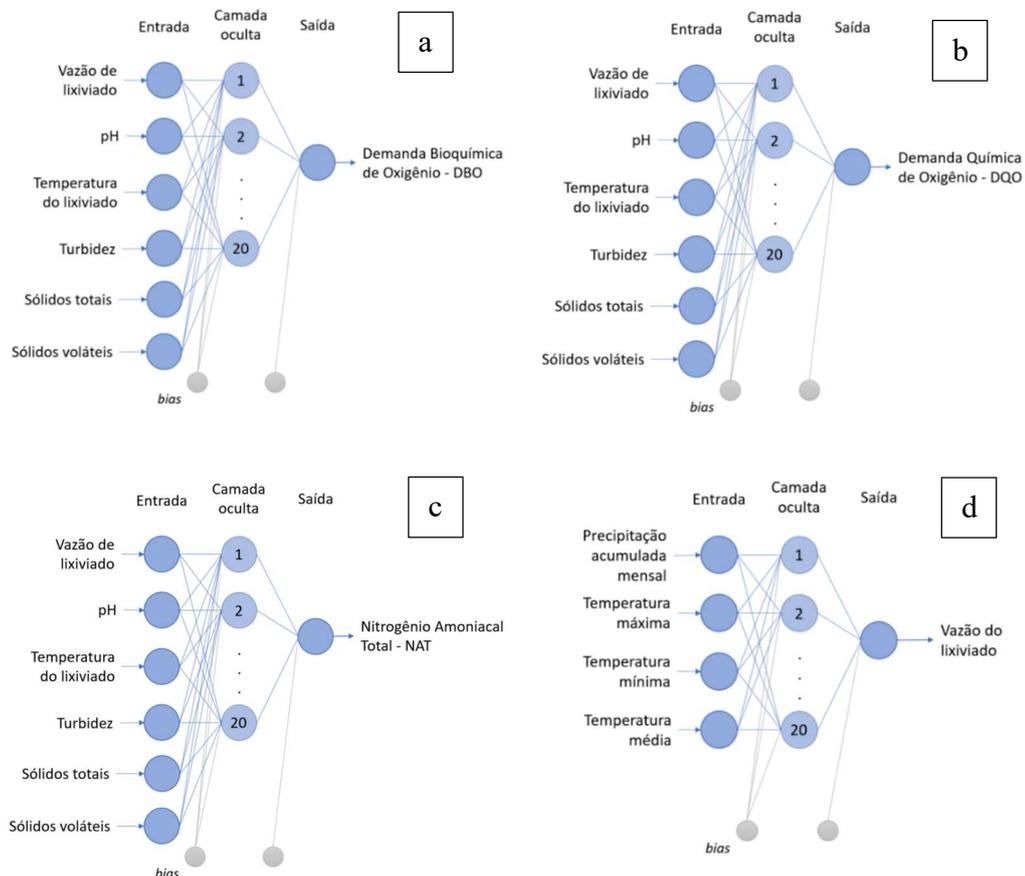
A modelagem para determinação das características do lixiviado foi desenvolvida por meio de RNA utilizando a biblioteca *Neural Network* no *software Matlab R2020a*. Conforme MathWorks (2020), com *MATLAB®* é possível combinar um ambiente ajustado para análise mútua e processos de design com uma linguagem de programação que expressa diretamente a matriz. MathWorks (2020) descreve que esse programa inclui um editor de scripts que combinam código, saída e texto formatado em um bloco de anotações executável.

Na camada de entrada (*input*) da RNA foram utilizados os dados de monitoramento meteorológico e das características do lixiviado, para dados experimentais e para dados sintéticos. As RNA foram treinadas, testadas e dependendo do tipo de algoritmo de otimização, validadas. Em seguida, verificou-se qual delas apresentou o melhor desempenho para determinação da DBO, DQO, NAT e vazão, do lixiviado do Aterro Sanitário em região semiárida em estudo.

Apesar da modelagem por redes neurais permitir obter mais de uma variável dependente na camada de saída, foram analisadas RNA com as seguintes camadas de saída: 1) uma variável resposta para a demanda bioquímica de oxigênio (DBO); 2) uma variável resposta para a demanda química de oxigênio (DQO); 3) uma variável resposta para nitrogênio amoniacal total (NAT) e; 4) uma variável resposta vazão.

A arquitetura da rede neural utilizada neste trabalho foi composta por uma camada de entrada, uma camada oculta e uma camada de saída. Para uma mesma arquitetura foram utilizadas diferentes topologias, isto é, variações no número de neurônios da camada oculta (1 a 20 neurônios), no tipo de saída (variável dependente), na função de ativação da camada oculta (tangente hiperbólica - *tansig*, logística sigmoidal - *logsig*, linear - *purelin* e sigmoide simétrica de Elliot - *elliotsig*), na função de ativação da camada de saída (tangente hiperbólica - *tansig*, logística sigmoidal - *logsig*, linear - *purelin* e sigmoide simétrica de Elliot - *elliotsig*), no tipo de algoritmo de otimização (*Bayesian regularization - trainbr*, *Levenberg-Marquadt - trainlm*, *Gradient descente - traingd* e *One-step secant - trainoss*) e como algoritmo de treinamento supervisionado foi utilizado o *back-propagation*. Essas variações são realizadas para diminuir o erro residual e, conseqüentemente, obter a RNA que possui um melhor desempenho. A Figura 19 ilustra as arquiteturas das RNA utilizadas neste trabalho, e no Apêndice B está disponível a programação utilizada para processamento e análise de RNA.

Figura 19 – Arquitetura da rede neural utilizada para predição: (a) DBO; (b) DQO; (c) NAT; (d) Vazão



Fonte: Autoria própria (2023).

As variáveis de entrada foram escolhidas por serem de fácil obtenção. Algumas dessas variáveis de entrada, também foram utilizadas nas RNA desenvolvidas por Bhatt *et al.* (2016), para a determinação da DBO₅ e DQO, por Ishii *et al.* (2022) para determinação da vazão, DBO₅, DQO e NAT e por Abunama *et al.* (2019) para análise da taxa de geração de lixiviado.

Para o desenvolvimento das RNA com a utilização do algoritmo *Bayesian regularization (trainbr)*, 70% do conjunto total do banco de dados foi selecionado, de modo aleatório, para treinamento e desenvolvimento das redes neurais. Os demais 30% do banco de dados, que não foram objetos de seleção aleatória para a etapa de treinamento, foram utilizados na etapa de teste. Quando os algoritmos *Levenberg-Marquadt (trainlm)*, *One-step secant (trainoss)* e *Gradient descente (traingd)* são utilizados no treinamento das RNA, 70% dos dados são selecionados, de forma aleatória, para treinamento, 15% para teste e 15% para validação. Esta otimização matemática, que compreende na divisão dos dados em conjunto de teste, validação e treinamento seguiu as recomendações descritas por Tatibana e Kaetsu (2020) e Xu *et al.* (2021).

As redes neurais envolvem um processo de tentativas. Por isso, apesar de definida inicialmente a arquitetura e topologia das RNA, se ela não apresentar um bom desempenho far-se-á necessidade de analisar outras topologias, e se necessário alterar a arquitetura. Artero (2009), recomenda alterar o número de neurônios, taxa de aprendizado, funções de ativação e adição ou remoção de parâmetros. Por isso, foram testadas para cada saída de RNA, 3 diferentes quantidades de banco de dados (experimentais e sintéticos com 125 e 1000 dados) e dois tipos de tratamentos de dados (padronização e normalização), sendo desenvolvidas 7680 redes para cada saída de RNA (DBO, DQO, NAT e vazão), totalizando 30720 RNA.

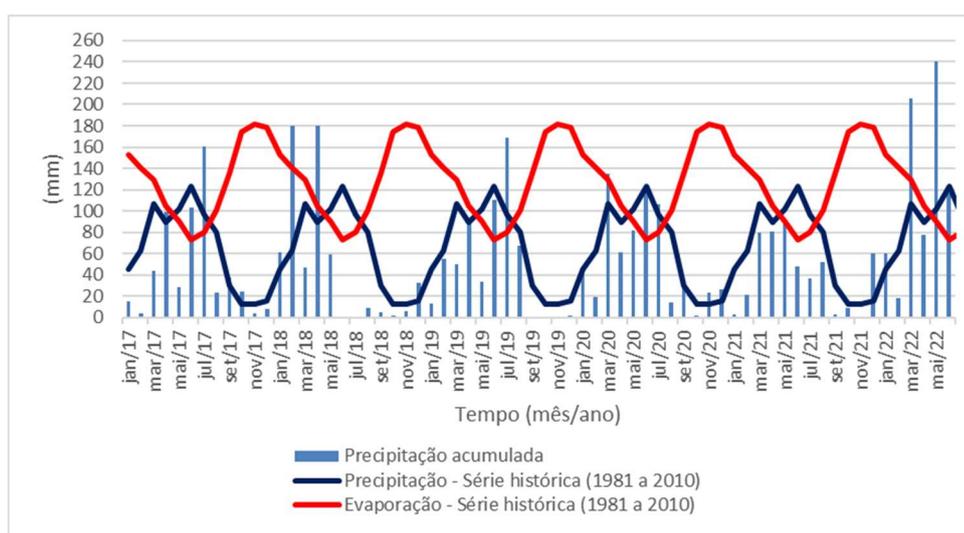
O desempenho das RNA desenvolvidas foi avaliado utilizando quatro índices estatísticos (métricas de desempenho): coeficiente de determinação (R^2); erro médio absoluto (MAE); raiz do erro quadrático médio (RMSE); e; raiz do erro quadrático médio normalizado (NRMSE). A escolha e a ordem desses indicadores foram determinadas conforme estudos realizados por Shcherbakov *et al.* (2013), Xu *et al.* (2021), Araújo Neto (2022) e Bezerra (2023).

4. RESULTADOS E DISCUSSÕES

4.1 Análise das condições meteorológicas

Em função das particularidades de condições e características da região semiárida ao qual o Aterro Sanitário está inserido, serão levadas em consideração as condições meteorológicas do município em que está situado. Na Figura 20 são apresentados dados de precipitação acumulada mensal registrados na Estação Meteorológica da Embrapa Algodão entre 2017 e 2022. Esse período corresponde ao intervalo do banco de dados utilizados neste estudo, referente ao monitoramento desse empreendimento, incluindo período das coletas de resíduos e lixiviados para análises laboratoriais e computacional. Adicionalmente, serão retratados em paralelo aos dados já citados, os dados históricos de precipitação e evaporação registrados pela Estação Meteorológica da Embrapa Algodão entre os anos de 1981 e 2010.

Figura 20 -Precipitação e evaporação no município ao qual o Aterro Sanitário está inserido



Observação: Dados históricos de evaporação obtidos por meio do evaporímetro de Piché
Fonte: Dados do INMET (2022).

Durante o período abordado neste estudo, referente ao aterro em questão, verifica-se, na Figura 20, que as precipitações mensais foram predominantemente inferiores as médias mensais históricas. Ao longo dos seis anos de monitoramento a precipitação acumulada foi de 550,6 mm em 2017, 581,6 mm em 2018, 589,2 mm em 2019, 664,4 mm em 2020, 483,6 mm em 2021 e 719,8 mm para 2022, e chegam a corresponder a 29%, 25%, 24%, 14%, 38% e 7%, respectivamente, quando comparados com a precipitação anual histórica, que é de 777 mm, mostrando-se inferior. Entretanto, no último ano (2022) foi contabilizado apenas os primeiros seis meses, correspondendo ao final da coleta de dados.

Ao observar ainda a Figura 20, verifica-se que historicamente a evaporação é maior que a precipitação em praticamente todos os meses do ano, caracterizando um déficit hídrico forte

na região onde está localizado o empreendimento, exceto nos meses chuvosos. Segundo Cunha *et al.* (2009), o período chuvoso se inicia em entre março e abril e finaliza entre julho e agosto. Assim, é possível avaliar a influência das condições meteorológicas do período chuvoso e seco no aterro sanitário em estudo. A média pluviométrica para cada ano correspondeu ao esperado, encontrando-se dentro da média pluviométrica histórica, sendo que nenhuma medida de precipitação analisada ultrapassou os 777 mm.

A média histórica mensal da evaporação é de 128,45 mm e da precipitação é de 64,75 mm, indicando que praticamente evapora o dobro do que precipita na região semiárida em que está localizado este aterro sanitário. Em estudo envolvendo balanço hídrico em uma região semiárida, Ghiasinejad *et al.* (2021) constataram que quase 30% da precipitação foi perdida como evaporação, o que pode se mostrar crucial na redução da quantidade de lixiviado. E essas condições podem contribuir para um aumento na carga poluidora ao ambiente devido às grandes concentrações de contaminantes nestes efluentes.

O déficit hídrico, favorece a implantação do processo de recirculação de lixiviado. Conforme Araújo Neto *et al.* (2021) essa prática irá auxiliar a aceleração dos processos biodegradativos no interior da Célula, entretanto, para uma maior eficiência da técnica de recirculação de lixiviado, orienta-se realizar um controle da vazão de recirculação para subsidiar o balanço hídrico no interior da Célula. No aterro sanitário em questão, a recirculação é uma prática recorrente desde junho de 2018, e que funciona basicamente como uma alternativa ao tratamento do lixiviado (Figura 21 a e b), porém, não há esse controle sugerido, sendo essa atividade suspensa em períodos de chuvas.

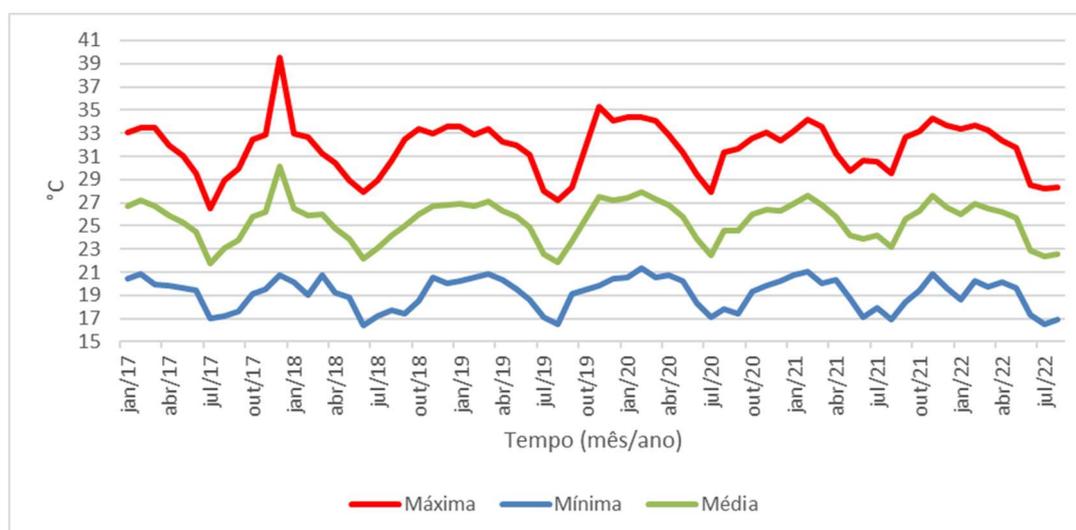
Figura 21 – (a) recirculação de lixiviado: carro pipa; (b) lixiviado empoçado na camada de cobertura



Fonte: Acervo de pesquisa (2019).

Inclui-se à precipitação e à evaporação, como influências aos processos biodegradativos, a temperatura ambiente, visto que são capazes de acelerar ou retardar as fases da degradação dos RSU, interferindo diretamente na geração do lixiviado. Na Figura 22 é apresentada a variação da temperatura ambiente do município, registrada na Estação Meteorológica da Embrapa Algodão, entre 2017 e 2022.

Figura 22 – Variação da temperatura ambiente no município ao qual o Aterro Sanitário está inserido



Fonte: Dados do INMET (2022).

Verifica-se na Figura 22 que a temperatura ambiente máxima registrada durante todo o período de monitoramento foi de 39,5 °C, no mês de dezembro de 2017, a mínima de 16,4 °C, no mês de junho de 2018, e a média oscilou entre 30 °C e 21,7 °C. Quanto a amplitude térmica, constatou-se que a maior variação de temperatura foi de 18,7 °C, em dezembro de 2017.

4.2 Caracterização dos resíduos sólidos urbanos

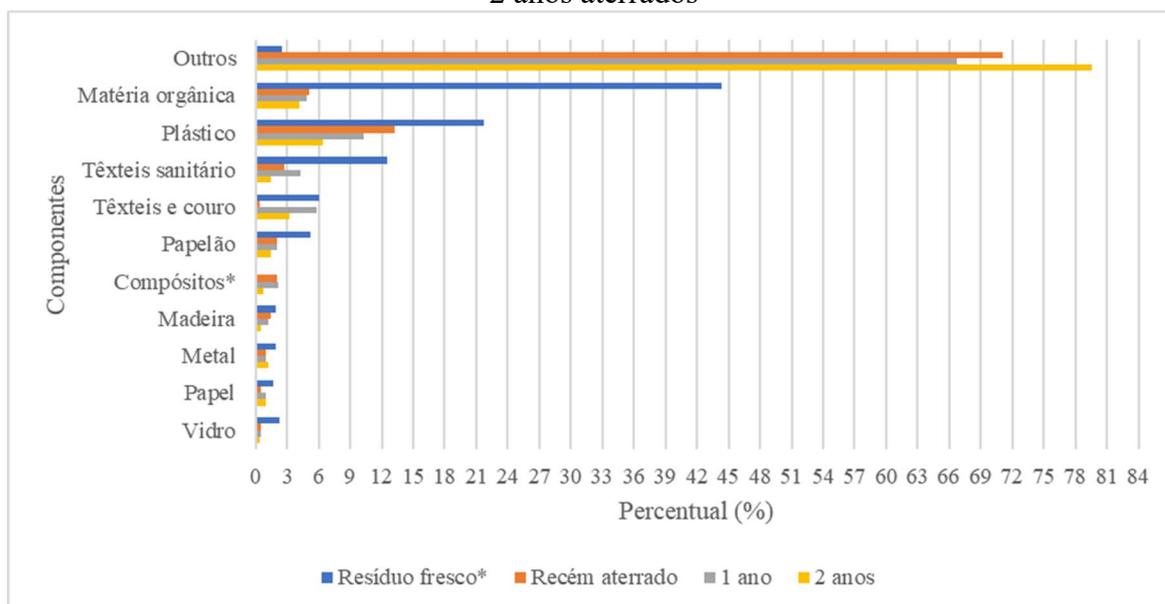
A composição dos RSU varia muito em se tratando de tipos de materiais que o compõe, e de região para região, pois mudam em função do porte do município, as principais atividades produtivas, hábitos da população, clima, nível educacional, e da presença de programas de reciclagem e compostagem. Assim, as características dos RSU, vão sofrendo alterações com o decorrer dos anos, sendo indicado a realização de caracterizações periódicas para servir de atualizações dos dados e adaptações ao sistema de gerenciamento dos resíduos (Song *et al.* 2013; Zhang *et al.* 2010; INEA, 2021).

Além da importância descrita sobre a necessidade da caracterização dos RSU, o Aterro Sanitário em estudo recebe resíduos de diversas cidades, e que ao longo dos anos houve mudanças nessas cidades depositantes. Por esses municípios apresentarem perfis diferentes entre si, faz-se necessária a caracterização dos resíduos do Aterro Sanitário ao longo do tempo de operação, e de monitoramento. Assim, foram caracterizados neste trabalho, os resíduos frescos (os que chegam ao aterro, antes mesmo do aterramento), os resíduos recém aterrados e após 1 e 2 anos de aterramento.

4.2.1 Composição Gravimétrica

A composição gravimétrica dos RSU que chegam ao Aterro Sanitário em estudo, dos recém aterrados e com idade de aterramento de 1 e 2 anos, estão apresentados na Figura 23. Alguns desses componentes estão evidenciados na Figura 24 para obtenção de uma melhor análise dessas frações.

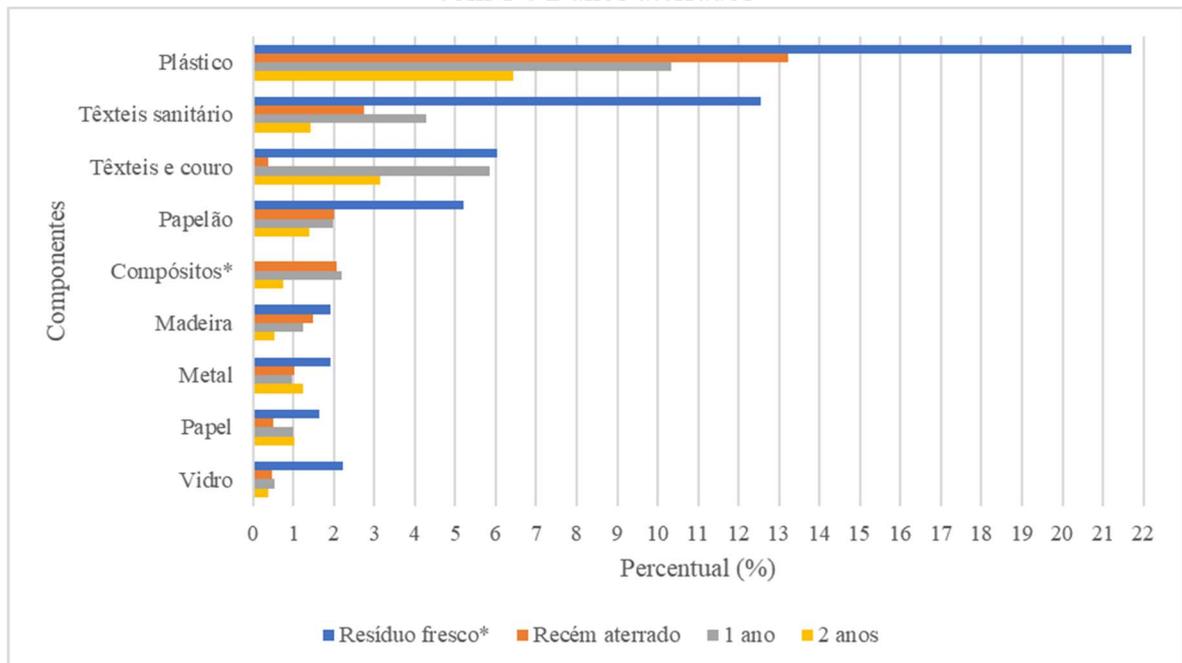
Figura 23 - Composição gravimétrica dos resíduos frescos, recém aterrados e com 1 e 2 anos aterrados



*A fração de compósitos na composição de resíduos frescos foi contabilizada como componente outros, devido à baixa quantidade desse material encontrada nos resíduos frescos.

Fonte: Adaptado de Araújo Neto (2022) e Bezerra (2023).

Figura 24 - Fração da composição gravimétrica dos resíduos frescos, recém aterrados e com 1 e 2 anos aterrados



*A fração de compósitos na composição de resíduos frescos foi contabilizada como componente outros, devido à baixa quantidade desse material encontrada nos resíduos frescos.

Fonte: Adaptado de Araújo Neto (2022) e Bezerra (2023).

Pode-se observar, na Figura 23, que o componente outros apresentou valores elevados acima de 66% para as três idades de resíduos aterrados e abaixo de 3% para o resíduo fresco. Dessa forma, o percentual do componente outros variou 77% quando comparada com as composições dos resíduos frescos e com 2 anos de aterramento.

Esse expressivo percentual do componente outros, nos resíduos aterrados, possivelmente tem contribuição da presença de matéria orgânica de difícil identificação, além da influência da compactação e do próprio aterramento que acabou incorporando o resíduo orgânico a outros materiais e do solo, que é utilizado na camada de cobertura. Este comportamento justifica a baixa concentração de matéria orgânica identificável (Thakur, Gupta e Ganguly, 2019; Araújo Neto *et al.* 2021).

O componente matéria orgânica, obteve o valor para o resíduo fresco, de aproximadamente 44%, valor próximo ao encontrado por Araújo Neto (2016), que foi de 46,9% para os resíduos depositados em um biorreator simulando as condições de um Aterro Sanitário em Campina Grande, e da média nacional que é de 45,3% conforme Abrelpe, (2020). Nos resíduos aterrados, o percentual de matéria orgânica reduziu para, aproximadamente 5% devido, provavelmente, a incorporação desse material em outras frações.

A configuração apresentada da matéria orgânica, com elevado percentual referente aos resíduos que chegam ao empreendimento em estudo, mostra-se com um indicativo favorável à geração de lixiviado. Visto que o componente matéria orgânica dos RSU é um dos fatores que influenciam a geração de lixiviado. (Thanh; Matsui; Fujiwara, 2010; Barr *et al.*, 2013; Guedes *et al.*, 2022).

O plástico, o papelão e a madeira apresentaram comportamento semelhante entre o resíduo fresco, recém aterrado e com 1 e 2 anos de aterramento. Esses componentes, sofreram reduções gradativas ao longo do período analisado (Figura 24) devido, provavelmente, ao processo de decomposição. Analisando as categorias de RSU nota-se ainda, a presença de resíduos recicláveis secos como plásticos, papel e papelão, vidros, metais e compósitos que poderiam ter sido recicláveis, principalmente quando analisado os resíduos frescos.

Os resíduos recicláveis secos somam 32,66% para a composição gravimétrica aplicada aos resíduos frescos que chegam ao Aterro Sanitário em estudo, valor próximo ao verificado no panorama dos resíduos sólidos no Brasil da Abrelpe (2020), que foi de 35%. Enquanto, para os resíduos aterrados obteve-se 19,3%, 17% e 11,2%, respectivamente, a idade crescente de aterramento em análise.

4.2.2 Caracterização físico-química

As características físico-químicas para os extratos dos RSU frescos, recém aterrados, com 1 ano e 2 anos de aterramento, estão apresentados na Tabela 4.

Tabela 4 – Características físico-químicas dos resíduos sólidos urbanos

Indicadores	Resíduos Frescos	Recém aterrado	1 ano de aterramento	2 anos de aterramento
Teor de umidade (%)	53,2	41	34,4	27,4
Teor de Sólidos Voláteis (%)	70	67	7,4	5,8
pH	5,6	5,0	6,1	6,7
DBO ₅ (mgO ₂ /L)	4500	-	2176	2175
DQO (mgO ₂ /L)	18000	-	16400	16207

Fonte: Autoria própria (2023).

O teor de umidade para resíduos frescos e recém aterrados se apresentaram superiores a 40% (Tabela 4), pertencendo a faixa ótima de 40% a 60% de umidade dos resíduos, defendida por Bidone e Povinelli (1999), para aterros sanitários brasileiros. Tchobanoglous, Theisen e Vigil (1993) e Palmisano e Barlaz (1996) indicam 40% como umidade máxima ótima para

resíduos recém aterrados. Warith e Sharma (1998) em seus estudos afirmam que o teor de umidade para os RSU recém aterrados apresenta uma condição favorável para atividades metabólicas na decomposição de matéria orgânica no início do aterramento, enquanto baixos níveis de umidade, podem causar diminuição das reações bioquímicas, pois não há fluxo adequado de enzimas no ambiente, não havendo também a diluição de materiais tóxicos, corroborando com os estudos realizados por Araújo Neto *et al.*, (2021) que obteve o teor de umidade de 41% para os RSU recém aterrados.

Reddy *et al.* (2015) descreve uma tendência crescente do teor de umidade e do tempo de aterramento. Entretanto, para este aterro sanitário em estudo esse comportamento foi decrescente (Tabela 4), e esse reflexo pode estar relacionado ao percentual de matéria orgânica que conforme observado na Figura 23, decresce ao longo do período de aterramento. Outros fatores que podem contribuir com essa tendência, é a baixa precipitação e alta evaporação por estar inserido em uma região semiárida, e fatores operacionais relacionados a compactação e espessura da camada de cobertura final que pode dificultar a infiltração da água superficial e do lixiviado recirculado (Figura 21 b).

Os valores encontrados para sólidos voláteis nas amostras de resíduos do empreendimento em estudo mostraram-se com valores elevados entre os resíduos frescos e recém aterrados, sendo reduzidos para os resíduos com 1 e 2 anos de aterramento. Conforme Nascimento *et al.* (2022), os sólidos voláteis indicam de forma indireta a quantidade de matéria orgânica a ser degradada nos resíduos, o que justifica os valores elevados dos teores de sólidos voláteis nos resíduos fresco e recém aterrados. Decottignies *et al.* (2005), afirmam que valores de sólidos voláteis inferiores a 10% correspondem a um material já bioestabilizado, corroborando com os valores encontrados para os resíduos com 1 e 2 anos de aterramento do aterro sanitário em estudo (Tabela 4). Logo, essa diferença discrepante dos sólidos voláteis entre os resíduos analisados em função do tempo de aterramento indica uma elevada atividade biológica durante esses períodos.

O pH do extrato das amostras de RSU em diferentes condições de aterramento (Tabela 4), indicou uma evolução que corresponde a um sistema típico de digestão anaeróbia em aterros, segundo Bezerra (2022). No início do aterramento, os resíduos sofrem uma redução do pH, pela ação das bactérias acidogênicas, que segundo Kjeldsen *et al.*, (2002), Renou *et al.*, (2008) e Nascimento *et al.* (2022) nessa etapa, há liberação de ácido lático, amônia e ácidos graxos voláteis, conferindo esse valor abaixo da neutralidade. A elevação do pH no 2 ano de aterramento indica conforme Teng *et al.* (2021), que a biodegradação dos resíduos equivale a um aterro de idade entre 5 e 10 anos para um pH entre 6,5 e 7,5, indicando que o Aterro Sanitário

em estudo possui um processo biodegradativo acelerado, favorecido pelas condições operacionais e climáticas da região.

Observa-se na Tabela 4 que os valores encontrados para a DBO₅ no extrato dos RSU em diferentes condições de aterramento sofreram variações superiores as da DQO. Não foi possível determinar a DBO e DQO dos resíduos recém aterrados devido a problemas operacionais e ajustes de metodologias ocorridos durante a fase de caracterização dos resíduos. A DBO₅ inicialmente apresentou 4500 mgO₂/L sendo reduzida a 2175 mgO₂/L, enquanto a DQO iniciou com 18000 mgO₂/L, chegando a 16207 mgO₂/L. Os de DQO maiores que os valores de DBO₅, indica a presença de matéria orgânica resistente a degradação biológica.

Para deduzir qual o estágio de degradação em que se encontram os resíduos, Tchobanoglous, Theisen e Vigil (1993) e Hamada (1997), recomendam a relação DBO₅/DQO. As relações encontradas para os resíduos estudados no Aterro Sanitário em estudo corresponderam a 0,25, 0,13 e 0,13, e conforme faixas determinadas por Teng *et al.* (2021) e El-Fadel *et al.* (2002), os valores determinados nessa relação equivalem a aterros com idade entre 5 e 10 anos. Esses resultados, indicam rápida estabilização dos RSU depositados no empreendimento em estudo.

4.3 Caracterização e monitoramento do lixiviado do Aterro Sanitário

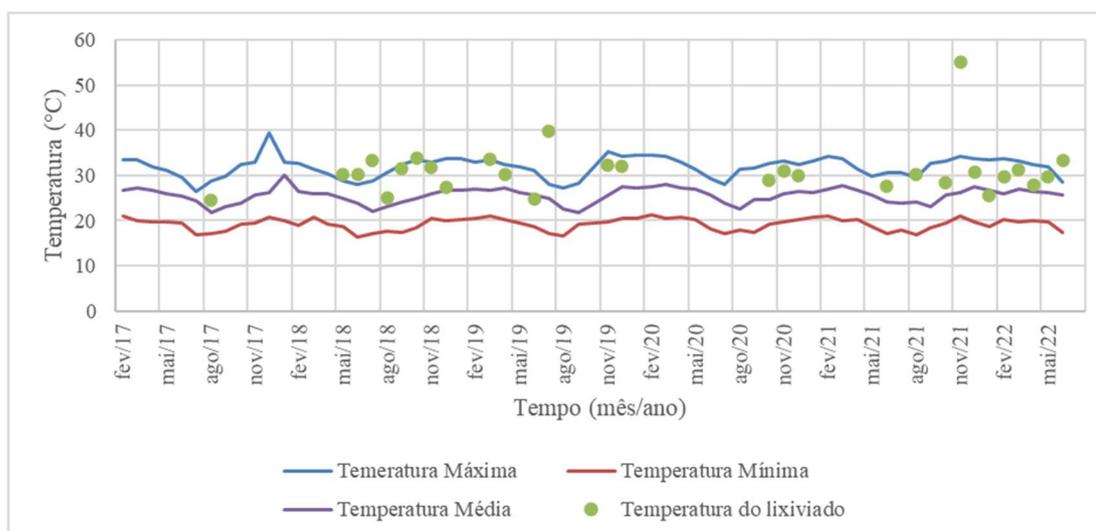
Apesar do Aterro Sanitário em estudo seguir em operação desde o ano de 2015, possuindo 7 anos de idade, neste trabalho serão contemplados dados a partir do ano de 2017 até 2022. Para a caracterização do lixiviado do Aterro Sanitário foram analisados os parâmetros citados no Quadro 3. Importante ressaltar que, o efluente coletado é da tubulação de entrada para a lagoa de acumulação desse líquido no Aterro Sanitário, portanto é um lixiviado *in natura*.

Durante o período de janeiro de 2020 a setembro do mesmo ano o monitoramento do Aterro Sanitário em estudo foi suspenso, em virtude da pandemia ocasionada pelo vírus SARS-CoV-2 (Covid- 19).

- **Temperatura**

Na Figura 25 são explanados os dados referentes a temperatura do lixiviado na tubulação que chega na lagoa de acumulação e as temperaturas máxima, mínima e média ambiente, fornecida pelo INMET para a cidade de Campina Grande - PB. Nota-se que a temperatura do lixiviado mantém uma tendência variando entre a temperatura máxima e a média ambiente.

Figura 25 – Temperatura do lixiviado



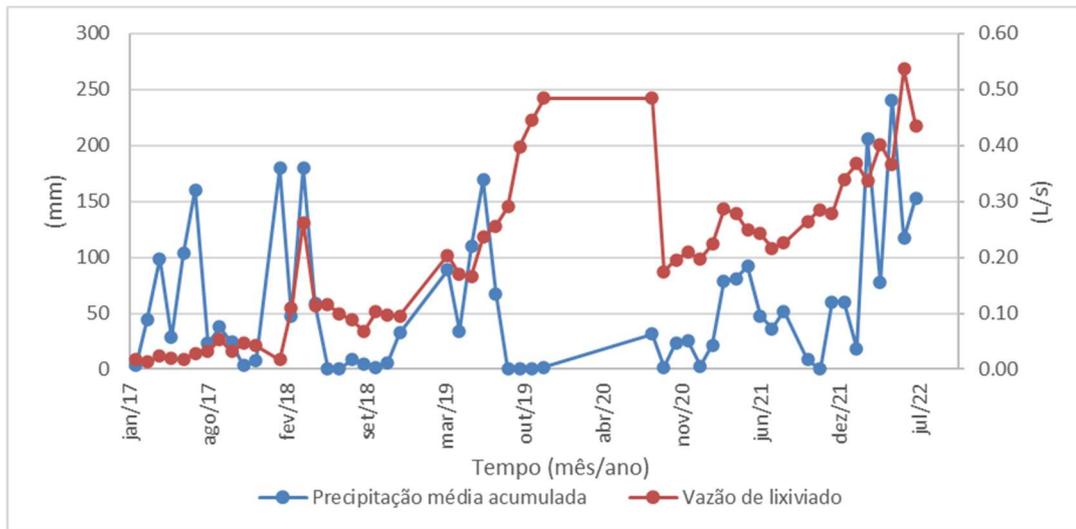
Fonte: Autoria própria (2023).

A temperatura mínima registrada durante o período de coletas de dados no aterro sanitário em estudo foi de 24,5 °C em agosto de 2017, enquanto a máxima foi de 55,1 °C em novembro de 2021. A média da temperatura ao longo dos anos de monitoramento corresponde a 31 °C. Nota-se na Figura 25 que a temperatura do lixiviado que chega a LTL mantêm-se sempre muito próximo a temperatura máxima registrada para a cidade de Campina Grande - PB, cerca de 62% dos dados se concentram entre a máxima e a média.

- **Vazão**

Verifica-se na Figura 26, que durante o período monitorado, o Aterro Sanitário em estudo atingiu uma vazão média de lixiviado de 0,20 L.s⁻¹, máxima de 0,54 L.s⁻¹ e mínima de 0,01 L.s⁻¹. Os valores do lixiviado deste empreendimento estão abaixo do gerado no aterro sanitário de São Gonçalo, Belford Roxo e Duque de Caxias, que é de 2,71 L.s⁻¹ e do gerado nos aterros sanitários de Nova Iguaçu e Santa Rosa que chegam a superar os 8 L.s⁻¹, segundo (D'Oliveira, 2020; Elk, 2022). Essa diferença pode estar relacionada ao tipo e quantidade de resíduos depositados e operação do aterro, assim como, as condições meteorológicas, visto que, a região do empreendimento está localizada em uma região de clima semiárido, caracterizado por evaporações superiores às precipitações, promovendo a redução da umidade dos resíduos, diferentemente dos outros aterros citados, que estão na região sudeste do Brasil.

Figura 26 – Vazão do lixiviado e a precipitação acumulada



Fonte: Autoria própria (2023).

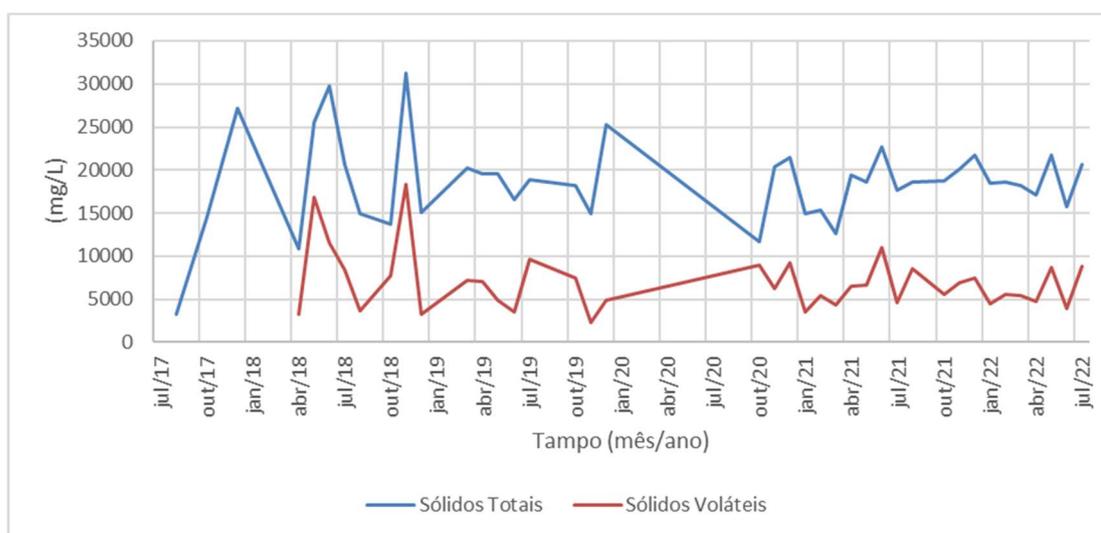
Abunama *et al.*, (2017) traz informações sobre a vazão e precipitação em estudo realizado em aterro sanitário localizado na Palestina, com clima semiárido. A precipitação média anual da região é de 342 mm, inferior à média da região do empreendimento em estudo (Figura 20), possui uma geração de lixiviado de 8.087 m³/ano (0,25L/s⁻¹), sendo um valor próximo a média anual referente ao período analisado neste trabalho (Figura 26). Há informações que neste aterro na Palestina a média de recebimento de RSU é de 100.000 ton/ano, com a contribuição de 13 municípios e vilas da região e a composição dos resíduos depositados correspondem a 52% de matéria orgânica, 11% de papel, 3% de metais e 18% de resíduos diversos, e 40% do lixiviado gerado é recirculado. Quanto a este presente estudo, há um recebimento maior de RSU e as frações apresentam valores inferiores aos percentuais das frações mencionadas.

Bastiani (2012) fez uma avaliação da influência da precipitação pluviométrica com a vazão do lixiviado, em um aterro sanitário de Lajeado/RS, e observou que é perceptível a correlação entre essas variáveis, porém nem todos os períodos de precipitação foram acompanhados por aumento da vazão de lixiviado, pois não foi atingida a capacidade de campo desses resíduos. Entretanto, verificou oscilações na vazão de lixiviado, em intervalos horários, mesmo sem ocorrência de precipitação pluviométrica, identificando uma possível influência inversamente proporcional com a temperatura. No entanto, esse comportamento não está evidenciado no aterro sanitário ao qual é objeto de estudo deste trabalho, talvez por não ter esses dados de vazão e temperatura ambiente em intervalos horários.

- **Sólidos totais e sólidos voláteis**

Os Sólidos Totais (ST) e Sólidos Voláteis (SV), no lixiviado do Aterro Sanitário em estudo, apresentaram conforme Figura 27, mudanças expressivas ao longo do monitoramento. Porém, percebe-se que nos últimos dois anos, aparentemente essas variações foram reduzindo. Os ST durante os anos de 2017 a 2022 variaram de 3194 a 31200 mg.L⁻¹, com média de 18609 mg.L⁻¹, e os SV de 2300 a 18400 mg.L⁻¹, com média de 6945 mg.L⁻¹.

Figura 27 – Sólidos Totais e Sólidos Voláteis no lixiviado



Fonte: Autoria própria (2023).

Tchobanoglous *et al.*, (1993) encontraram em aterros novos (menos de 2 anos) a faixa de variação de ST entre 200 e 2000 mg.L⁻¹ e para aterros antigos (mais de 10 anos) de 100 a 400 mg.L⁻¹. Já Souto e Povinelli, (2007) determinaram que a faixa máxima de concentração de ST para aterros de RSU no Brasil está entre 3200 e 21900 mg.L⁻¹, e para SV, uma faixa de 2100 e 14500 mg.L⁻¹, para ambos parâmetros a média da concentração do Aterro Sanitário em estudo está dentro da faixa estimada, embora possua valores acima dessa faixa ao longo do monitoramento.

Quando comparado com estudo realizado por Kashitarash *et al.* (2012) em um aterro inserido em uma região fria e semiárida, no oeste do Irã, o Aterro Sanitário em estudo apresentou concentração média de sólidos totais inferiores ao do Aterro de Hamadan, em que as propriedades do lixiviado *in natura* para a concentração de sólidos totais foi de 200000 mg.L⁻¹. Essa diferença impactante nos valores, pode estar associada a elevada fração de matéria orgânica em decomposição, associada a operação do empreendimento, que em virtude do grau de compactação das camadas intermediárias e de cobertura dos resíduos, acaba favorecendo a

infiltração maior de águas pluviais em períodos chuvosos, gerando o arraste de mais partículas para o lixiviado.

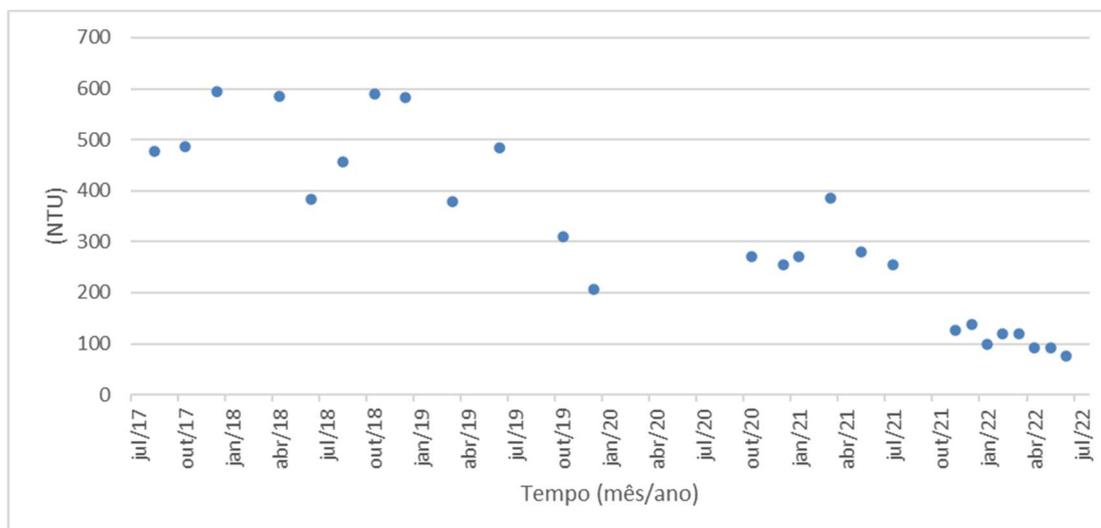
Morais *et al.* (2019) ao caracterizarem os lixiviados de aterros das cidades do estado de Pernambuco - Brasil, encontraram concentrações de sólidos totais que se apresentaram além das variações, e com comportamentos diferentes entre os dois anos de análises. Dentre essas cidades, algumas pertencem a região semiárida brasileira, a exemplo de Garanhuns, que houve um decréscimo acentuado nos ST, de 97520 para 16556 mg.L⁻¹, Lajedo que aumentou discretamente os ST de 12680 para 13163 mg.L⁻¹, Caruaru que apresentou um decréscimo significativo de 26760 para 15171 mg.L⁻¹ e Gravatá um acréscimo expressivo de 8620 para 14720 mg.L⁻¹. Os demais aterros apresentaram comportamentos semelhantes de variação, com decréscimo e acréscimo, entretanto, destaca-se o Aterro de Muribeca, já encerrado, que possui a concentração de ST variando de 5000 para 3284 mg.L⁻¹.

Essas investigações corroboram com a informação de Tchobanoglous *et al.* (1993) de que os aterros maduros podem ter valores mais baixos de ST, podendo indicar através do SV uma influência da presença da fração orgânica, na medida que esses valores são elevados (Moravia, 2007).

- **Turbidez**

A turbidez no lixiviado do aterro sanitário em estudo, conforme Figura 28, variou entre 75 NTU e 595 NTU para o período monitorado, alcançando uma média de 312 NTU. Os elevados teores de turbidez verificados no início do monitoramento estão associados a presença de materiais suspensos (Tomazoni *et al.* 2005).

Figura 28 - Turbidez no lixiviado



Fonte: Autoria própria (2023).

Conforme verificado em estudos por Cunha (2021), que verificou o valor da turbidez para lixiviado *in natura* de 218 NTU, para um aterro sanitário jovem e Domingos (2022), que para o lixiviado *in natura* de um aterro encerrado constatou valores variando entre 2,33 NTU e 21,9 NTU. No decorrer do tempo, esses valores tendem a reduzir, sendo valores baixos característico de aterros velhos, com operações encerradas ou de resíduos que passaram por intensos processos biodegradativos. Para este aterro sanitário em estudo, localizado no semiárido, é perceptível a redução da turbidez no lixiviado *in natura* ao longo do monitoramento, indicando um acelerado processo biodegradativo, que pode ter influência da recirculação do lixiviado nas células deste empreendimento.

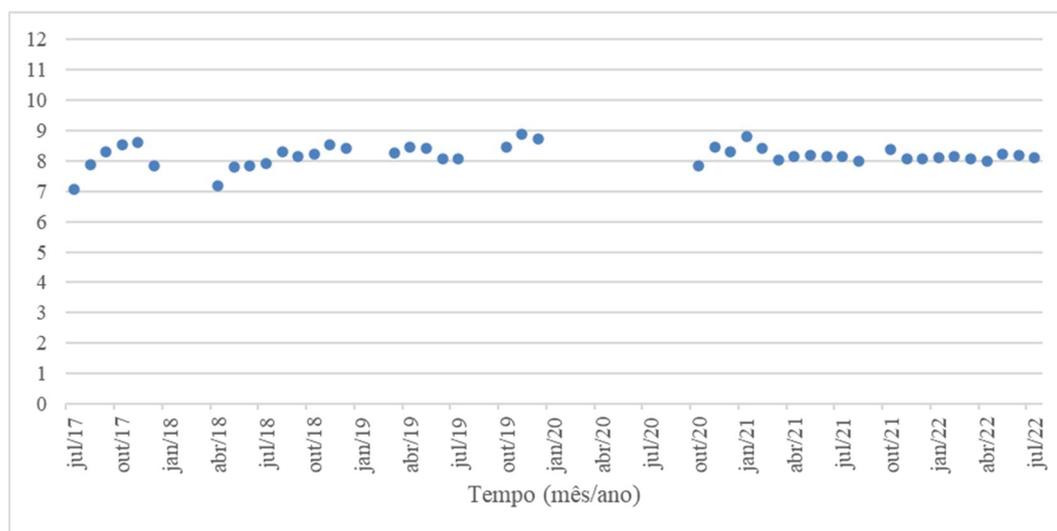
- **pH**

Tchobanoglous *et al.*, (1993), Pazoki e Ghasemzadeh (2020), descrevem as cinco fases da biodegradação dos resíduos sólidos, onde cada fase influencia a produção e composição do lixiviado. Ribeiro (2012) aponta o pH, alcalinidade e ácidos graxos voláteis como os parâmetros que descrevem o sistema ácido/básico nas fases que envolvem os processos anaeróbios, mostrando uma interligação entre si.

Na Figura 29 é explanada o comportamento do pH ao longo do monitoramento. Com valor mínimo de 7,06 em julho de 2017, no terceiro ano desde o início da operação do aterro sanitário. E o valor máximo de 8,86 em novembro de 2019, referente ao quinto ano do início do aterramento dos RSU no aterro sanitário em estudo. Destaca-se uma média de pH de 8,18

ao longo dos seis anos de monitoramento, com a faixa de pH compreendendo de 7 a 9, porém, a partir agosto de 2018 até julho de 2022 essa alternância ficou mais restrita, variando entre 8 e 9.

Figura 29 – Comportamento do pH



Fonte: Aatoria própria (2023).

Oliveira *et al.* (2016) afirmam que a precipitação acumulada interfere no valor do pH, ocorrendo uma leve redução desse parâmetro, proveniente da dissolução de CO₂ e O₂ que leva a diminuição do pH. O comportamento do efluente deste empreendimento estudado, indicando redução do pH (Figura 29), é sutilmente perceptível apenas nos primeiros dois anos de monitoramento entre os meses chuvosos (Figura 20).

Segundo um levantamento bibliográfico realizado por Show *et al.* (2019), Christensen *et al.* (2001) encontraram o pH variando entre 7,5 e 9 para lixiviado intermediário, enquadrando em um estágio metanogênico, correspondendo a idade de aterramento entre 10 e 20 anos. Entretanto, Umar *et al.* (2010), Abbas *et al.* (2009), Kulikowska e Klimiuk (2008), Tatsi e Zouboulis (2002), definiram pH entre 7,5 e 9 para aterros com idade acima de 20 anos, assim como Nazrieza *et al.* (2015), Tränkler *et al.* (2005) que estimaram valores superiores a 7,5 para o pH e consideraram o lixiviado em período de maturação final e em estágio de estabilização. Contudo, cerca de 95,5% dos dados de pH do lixiviado advindo do aterro sanitário em estudo, encontram-se dentro da faixa considerada para aterros moderadamente estáveis ou até mesmo estáveis, mesmo possuindo uma idade inferior ao que correspondente o pH descrito por diversos estudos.

faixa, variando entre 125 e 20200 mgCaCO₃.L⁻¹ para aterros sanitários na fase metanogênica de degradação.

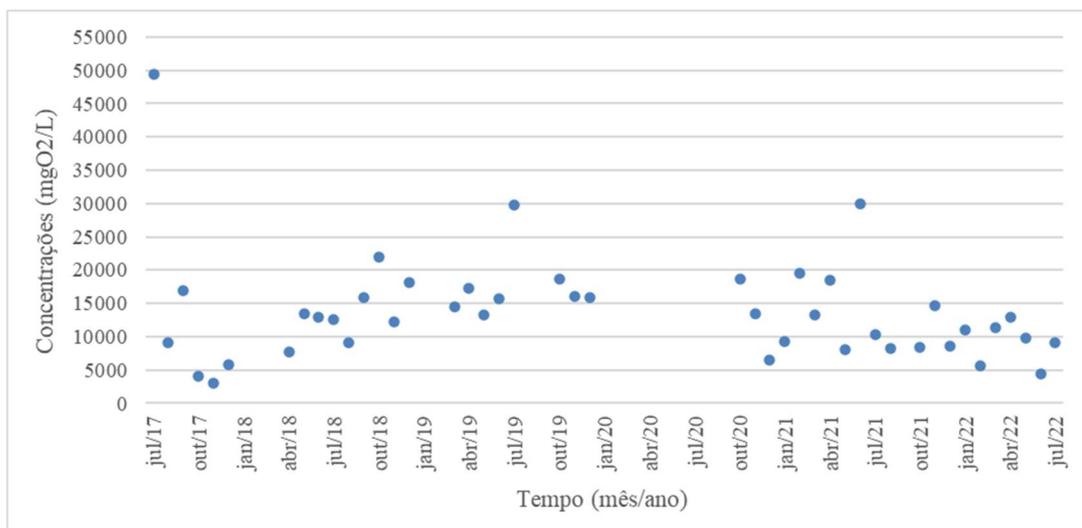
Os elevados valores nas concentrações da alcalinidade no lixiviado do aterro sanitário em estudo, favorecem a neutralidade do meio e conseqüentemente, o desenvolvimento das bactérias arqueas metanogênicas, devido a capacidade dos íons presentes no meio em neutralizar os ácidos, agindo como um efeito tampão natural (Ribeiro *et al.* 2021).

- **DQO e DBO₅**

As Figura 31 e Figura 33 apresentam a evolução da DQO e DBO₅ do lixiviado *in natura* do Aterro Sanitário em estudo desde o ano de 2017 até 2022. Segundo Renou *et al.* (2008), Abbas *et al.* (2009), Ziyang *et al.* (2009), Zhao *et al.* (2019), Show *et al.* (2019) e Nath & Debnath (2022) as concentrações da DQO e DBO₅ tendem a sofrer reduções ao longo do tempo devido às fases que antecedem a estabilização da matéria orgânica presente nos resíduos sólidos.

Sobretudo, Ribeiro (2012) afirma que a DQO decresce mais lentamente em relação à DBO₅, uma vez que, a DQO é um parâmetro que pode ser relacionado com os mais diversos tipos de matéria orgânica, de fácil e de difícil degradação. Entretanto, é importante ressaltar que, mesmo após 7 anos do início da operação do aterro sanitário em estudo, as Células ainda continuam recebendo resíduos, o que torna difícil uma clara identificação de tendência de redução na variabilidade da DQO e DBO₅.

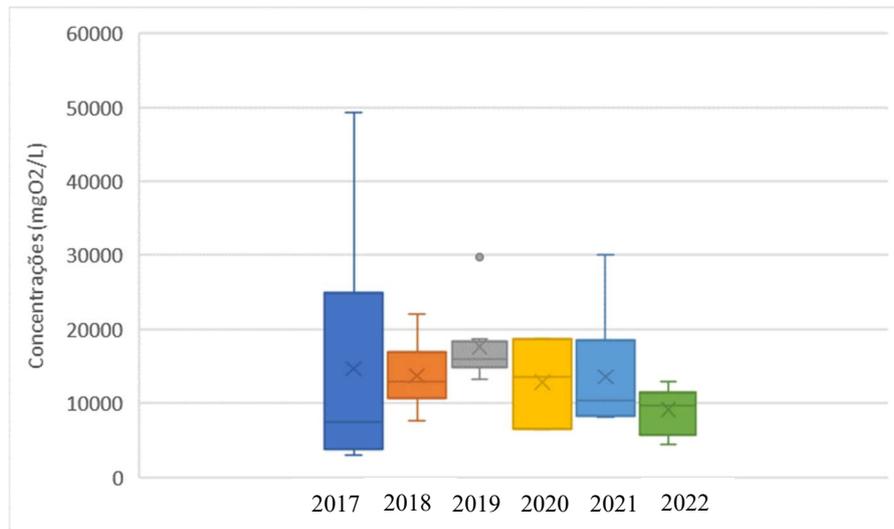
Figura 31 – Comportamento da DQO



Fonte: Autoria própria (2023).

A concentração da DQO no lixiviado *in natura*, conforme apresentado na Figura 31, possuiu um valor médio de 13747,58 mgO₂.L⁻¹, mínimo de 2973,98 mgO₂.L⁻¹ e máximo de 49390,24 mgO₂.L⁻¹, indicando que ao longo dos seis anos de monitoramento, houve uma variabilidade de 58,58%, mostrando uma forte dispersão dos dados. Esses valores obtidos são característicos da DQO do lixiviado de aterros que possuem entre 5 e 10 anos de idade, conforme estabelecido por Aziz *et al.* (2010), Umar *et al.* (2010), Christensen *et al.* (2001) e Costa *et al.* (2019).

Figura 32 – Boxplot concentrações anuais da DQO



Fonte: Autoria própria (2023).

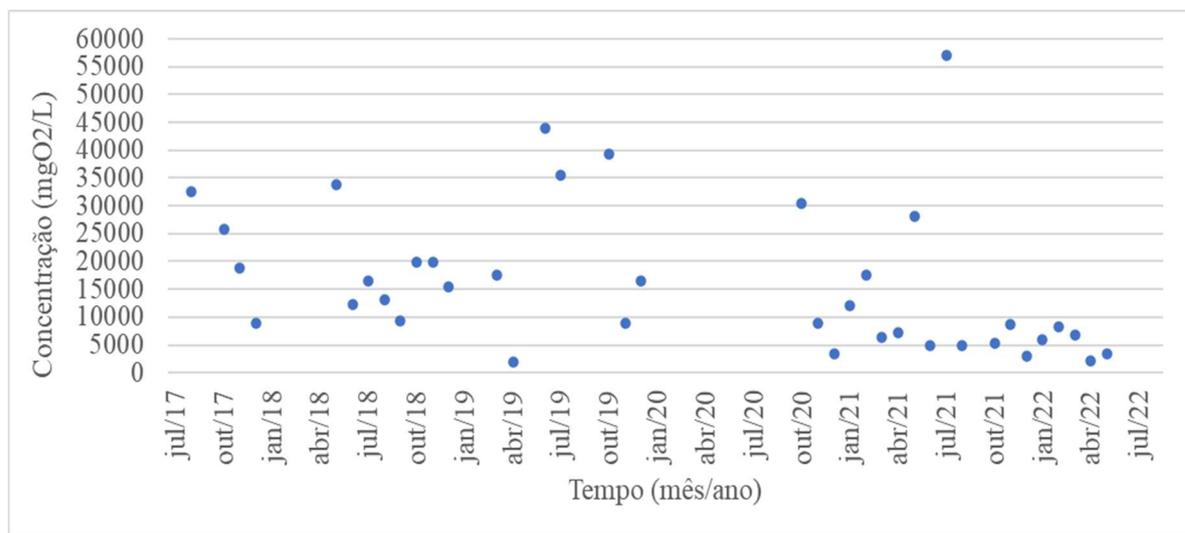
Ao analisar o Boxplot na Figura 32, observa-se que no ano de 2017, a DQO do lixiviado apresentou a maior variabilidade, indicando uma intensa influência na biodegradação da matéria orgânica, visto que nos anos iniciais da produção de lixiviado segue uma forte influência das bactérias aeróbias e facultativas, em que o valor médio foi de 14698,47 mgO₂.L⁻¹ e uma variabilidade de 120,53%. No ano de 2022 do monitoramento, a DQO do lixiviado apresentou um valor médio de 9188,23 mgO₂.L⁻¹ e uma variabilidade de 33,55%. Esses valores médios, indicam uma tendência a redução discreta nessas concentrações de DQO.

Porém, foram observados picos nos valores máximos para a DQO entre os meses de junho e julho dos anos de 2017, 2019 e 2021, períodos de maiores taxas de evaporação, indicando que este parâmetro é influenciado por outras variáveis e condições. Dentre algumas condições, destacam-se os processos de recirculação de lixiviado às Células, condições

meteorológicas, composição dos resíduos e a operação do aterro sanitário podem influenciar nas concentrações da DQO (Show *et al.*, 2019).

A concentração da DBO₅ no lixiviado *in natura*, conforme apresentado na Figura 33, possuiu um valor médio de 16174,34 mgO₂.L⁻¹, mínimo de 1875 mgO₂.L⁻¹ e máximo de 57000 mgO₂.L⁻¹, indicando que ao longo dos seis anos de monitoramento, de 2017 a 2022, houve uma variabilidade de 81,40%, indicando uma forte dispersão dos dados. Esses valores encontram-se dentro do determinado por Aziz *et al.* (2010) que é de 1000 a 57000 mgO₂.L⁻¹.

Figura 33 – Comportamento da DBO₅



Fonte: Autoria própria (2023).

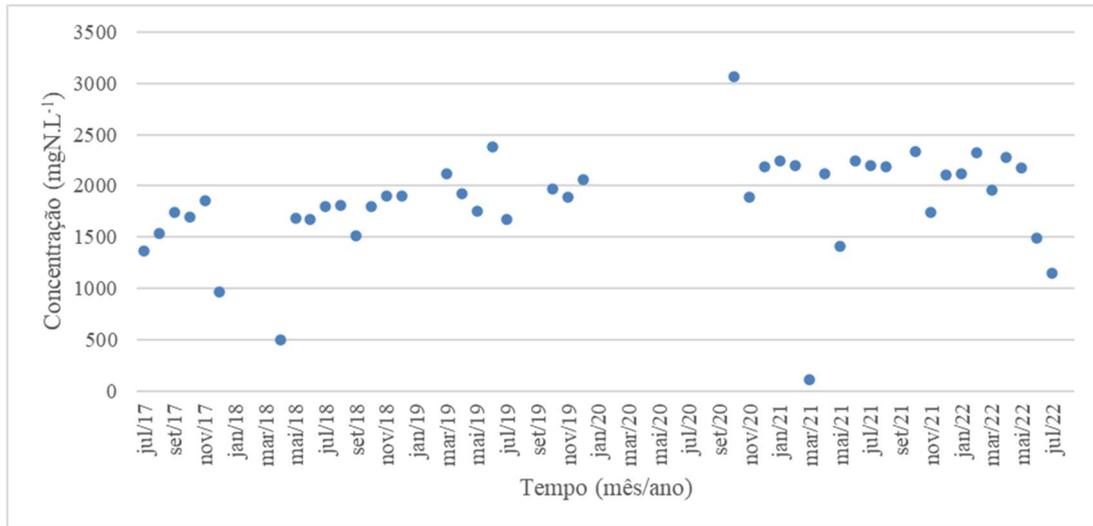
Nos estágios iniciais da biodegradação acidogênica, o lixiviado é caracterizado por elevada DBO₅ segundo Umar *et al.* (2010). Show *et al.* (2019) considera ainda que, ao longo dos primeiros 10 anos da geração de lixiviado, este efluente é considerado jovem e passa pela fase acidogênica com alto teor de carbono orgânico, justificando os valores elevados de DBO₅ e DQO.

- **Nitrogênio amoniacal total (NAT)**

O comportamento de NAT no lixiviado, observado na Figura 34, indica que as concentrações tendem a aumentar ao longo do monitoramento. Obteve-se concentração mínima

de 112 mgN.L⁻¹, máxima de 3066 mgN.L⁻¹ e uma média de 1841,6 mgN.L⁻¹ ao longo desse período monitorado, esse parâmetro manteve-se praticamente entre 1500 e 2500 mgN.L⁻¹.

Figura 34 – Comportamento do Nitrogênio Amoniacal Total



Fonte: Autorial própria (2023).

A concentração de amônia em lixiviados de diferentes aterros pode variar em dezenas ou centenas de mg.L⁻¹ (Martinen *et al.* 2003; Statom *et al.* 2004). Segundo Surmacz-Górska *et al.*, (2000), Kaczorek e Ledakowicz, (2002) a amônia em lixiviado pode variar entre 2000 e 3000 mgN.L⁻¹ ou conforme Tatsi e Zouboulis, (2002) pode alcançar concentrações superiores 10000 mgN.L⁻¹.

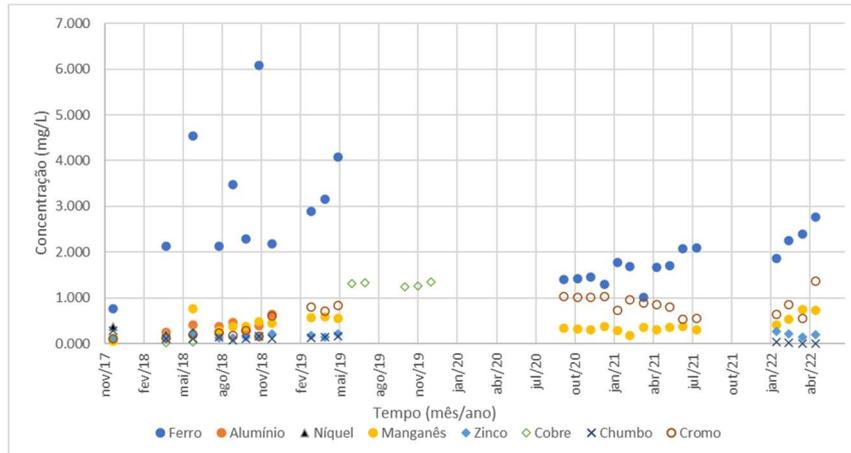
O nitrogênio amoniacal está presente em lixiviados de aterros jovens devido a desaminação de aminoácidos durante a reação envolvendo os compostos orgânicos (Tatsi e Zouboulis, 2002). E nos aterros mais antigos é rico em NAT devido a hidrólise e fermentação das frações nitrogenadas de substratos biodegradáveis (Carley e Mavinic, 1991).

- **Metais**

Os metais pesados são considerados substâncias perigosas em lixiviados de aterros sanitários. Na Figura 35, verifica-se o comportamento do cromo no lixiviado do aterro sanitário em estudo, em que as concentrações variaram entre 0,1 e 1,37 mg.L⁻¹ e a média de 0,65 mg.L⁻¹; o níquel com variação de 0,21 e 0,37 mg.L⁻¹ e a média de 0,67 mg.L⁻¹; o zinco variando de 0,1 a 0,26 mg.L⁻¹ e média de 0,17 mg.L⁻¹; e o chumbo variando de 0,003 a 0,29 mg.L⁻¹, com

média de $0,105 \text{ mg.L}^{-1}$. Estudos realizados por Xie *et al.*, (2015); Elbana *et al.*, (2018) indicam a influência do pH a mobilidade e a disponibilidade de metais pesados no meio.

Figura 35 – Concentrações de metais



Fonte: Autoria própria (2023).

Para alguns desses metais descritos na Figura 35, Christensen *et al.*, (2001), Kjeldsen e Christophersen, (2001), consideraram concentrações para o cromo entre $0,02$ e $1,5$ $0,08 \text{ mg.L}^{-1}$, para o níquel entre $0,015$ e 13 mg.L^{-1} , para o zinco entre $0,03$ e 1000 mg.L^{-1} , para o cobre entre $0,005$ e 10 mg.L^{-1} e para o Cromo entre $0,02$ e $1,5 \text{ mg.L}^{-1}$, sendo as concentrações do lixiviado do Aterro Sanitário em estudo dentro das faixas descritas por estes autores. Entretanto, o cromo encontrado no empreendimento em questão neste estudo apresentou um valor máximo muito próximo ao limite da faixa determinada.

Para alguns desses metais descritos, Mesquita *et al.*, (2021), consideraram para um lixiviado de aterro com mais de 10 anos de operação, e localizado na região semiárida brasileira, concentrações de $1,15 \text{ mg.L}^{-1}$ para o manganês, $0,063 \text{ mg.L}^{-1}$ para o zinco, $0,017 \text{ mg.L}^{-1}$ para o cobre, $0,65 \text{ mg.L}^{-1}$ para o níquel e $0,50 \text{ mg.L}^{-1}$ para o chumbo. Sendo valores de manganês, níquel e chumbo superiores, e zinco e cobre inferiores aos valores de concentrações encontrados no lixiviado do Aterro Sanitário em estudo. Essas diferenças podem estar relacionadas aos tipos de resíduos depositados nos aterros.

O ferro apresentou uma concentração máxima, de 6 mg.L^{-1} , mínima de $0,77 \text{ mg.L}^{-1}$ e média de $2,33 \text{ mg.L}^{-1}$ (Figura 35). A média foi próxima ao valor considerado para um aterro jovem, de $2,7 \text{ mg.L}^{-1}$, segundo Lopez *et al.* (2004). Enquanto para aterros de idade intermediária o resultado mostrou-se semelhante ao de Kennedy e Lentz (2000), que variou entre $1,28$ e $4,90 \text{ mg.L}^{-1}$. Porém, Im *et al.* (2001) determinou a concentração de 76 mg.L^{-1} para o ferro em um

aterro intermediário, valor bem acima do analisado nesse monitoramento. Silva *et al.* (2004) encontrou concentrações de 5,5 e 8,0 mg.L⁻¹ em um antigo aterro sanitário no Rio de Janeiro. O alumínio apresentou uma concentração máxima, mínima e média de 0,64, 0,1 e 0,36 mg.L⁻¹ (Figura 35) esses valores estão de acordo com as concentrações descritas por Kennedy e Lentz (2000), e Silva *et al.* (2004), menor que 0,02 a 0,92 mg.L⁻¹ e menor que 1 mg.L⁻¹, respectivamente.

As concentrações do cobre no lixiviado do aterro sanitário em estudo apresentaram valor máximo de 1,35 mg.L⁻¹, mínimo de 0,01 mg.L⁻¹ e média de 0,83 mg.L⁻¹ e as concentrações para o manganês apresentaram concentrações máxima de 3,37 mg.L⁻¹, mínima de 0,05 mg.L⁻¹ e média de 0,53 mg.L⁻¹ (Figura 35). Lopez *et al.* (2004), Kennedy e Lentz, (2000), Li e Zhao (2001), Rivas *et al.* (2003), Cho *et al.* (2002) e Silva *et al.* (2004) obtiveram em suas pesquisas valores de concentrações que compreendem os do Aterro Sanitário em estudo.

4.4 Banco de dados

Para o desenvolvimento das redes neurais artificiais realizou-se uma análise descritiva das variáveis de entrada e saída. Inicialmente foram analisadas a média, mediana, desvio padrão, coeficiente de variação e os valores máximos e mínimos de cada variável em estudo, conforme Tabela 5.

Tabela 5 - Análise descritiva dos dados

Variável	Desvio Padrão	Mínimo	Máximo	Média	Mediana	Coeficiente de variação (%)
DBO (mgO.L ⁻¹)	10744	2250	43875	11943	8250	90
DQO (mgO.L ⁻¹)	4398	5642	22000	12434	11439	35
NAT (mgN.L ⁻¹)	396	1148	3066	2006	2013	20
pH	0.20	7.83	8.71	8.17	8.13	2.40
Temperatura* (°C)	7	25	55	31	30	22
Sólidos Totais (mg.L ⁻¹)	4288	11700	29700	18871	18500	23
Sólidos Voláteis (mg.L ⁻¹)	2383	3300	11500	6409	5600	37
Turbidez (NTU)	177	75	590	246	139	72
Vazão (L/s)	0.13	0.03	0.54	0.22	0.22	58.50
Temperatura máxima (°C)	2	27	40	32	32	8
Temperatura mínima (°C)	1	16	21	19	19	7
Temperatura média (°C)	2	22	30	25	26	7
Precipitação acumulada mensal (mm/mês)	60	0	241	55	36	109

*Temperatura do lixiviado

Fonte: Autoria própria (2023).

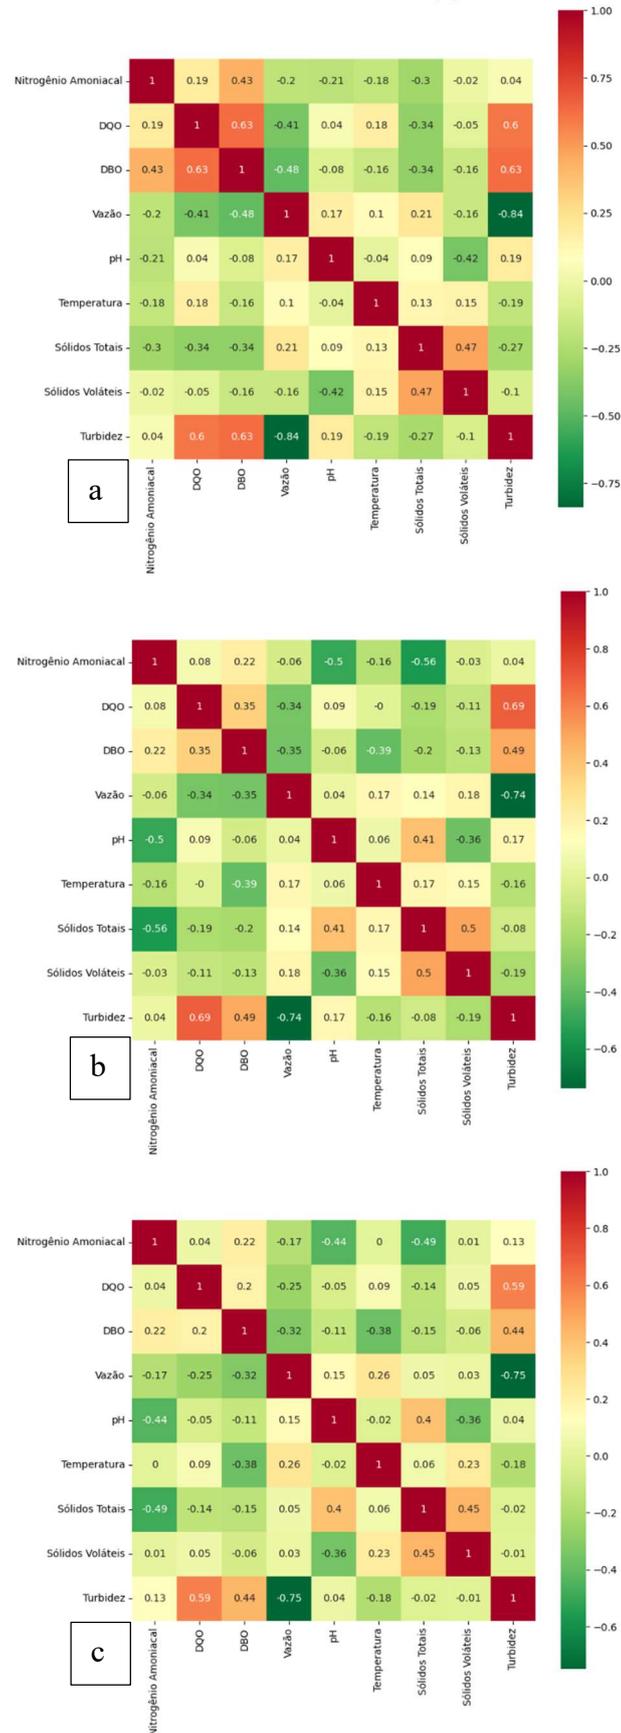
Ao analisar a média e mediana das variáveis estudadas (Tabela 5), verifica-se que NAT, pH, temperatura do lixiviado, sólidos totais, vazão, temperatura máxima, temperatura mínima e temperatura média possuem valores próximos entre si, indicando uma distribuição do tipo simétrica. Porém, a média e mediana para DBO, DQO, sólidos voláteis, turbidez e precipitação acumulada mensal, indica que dados não estão distribuídos uniformemente, seguindo uma distribuição assimétrica.

Conforme as medidas de dispersão (desvio padrão, coeficiente de variação, e valor máximo e mínimo), os dados possuem uma grande variabilidade e uma amplitude considerável, porém admissível, tendo em vista a dinâmica do Aterro Sanitário e das fases de biodegradação dos resíduos. A menor variabilidade é observada nas variáveis meteorológicas que possuem o coeficiente de variação inferior a 15%. Conforme Correa (2003) os valores experimentais possuem uma pequena variabilidade (dispersão) quando o coeficiente de variação é menor ou igual a 15%. Essa baixa variabilidade também é verificada para o pH.

As variáveis NAT, temperatura do lixiviado e sólidos totais possuem média dispersão pois possuem um coeficiente de variação entre 15% e 30%. Já as variáveis DBO, DQO, sólidos voláteis, turbidez, vazão e precipitação acumulada possuem grande dispersão, uma vez que apresentam um coeficiente de variação superior a 30%.

Como as variáveis estudadas possuem diferentes distribuições e unidades de medidas, conforme apresentado na Tabela 5, realizou-se a padronização e normalização dos dados para processamento das RNA. De acordo com Golub e Starovoitov (2021), os dados que possuem alta variabilidade, diferentes tipos de escalas e unidades de medida devem ser convertidos em uma única representação por normalização ou padronização. Além da padronização, Xu *et al.*, (2021), em uma vasta revisão da literatura, verificaram que a maioria dos estudos incluiu um tamanho de dados de 101 a 150, mas o tamanho pode ser menor na pesquisa baseada em experimentos e significativamente maior na pesquisa baseada em monitoramento ou estatística. Por isso, realizou-se também a sintetização dos dados obtidos experimentalmente para obtenção de um banco de dados sintéticos com 125 e 1000 dados para cada variável estudada. Na Figura 36 é possível analisar os correlogramas de desempenho do banco de dados experimentais e sintéticos.

Figura 36 – Correlogramas dos dados de entrada e saída: experimentais (a), 125 sintéticos (b) e 1000 sintéticos (c)



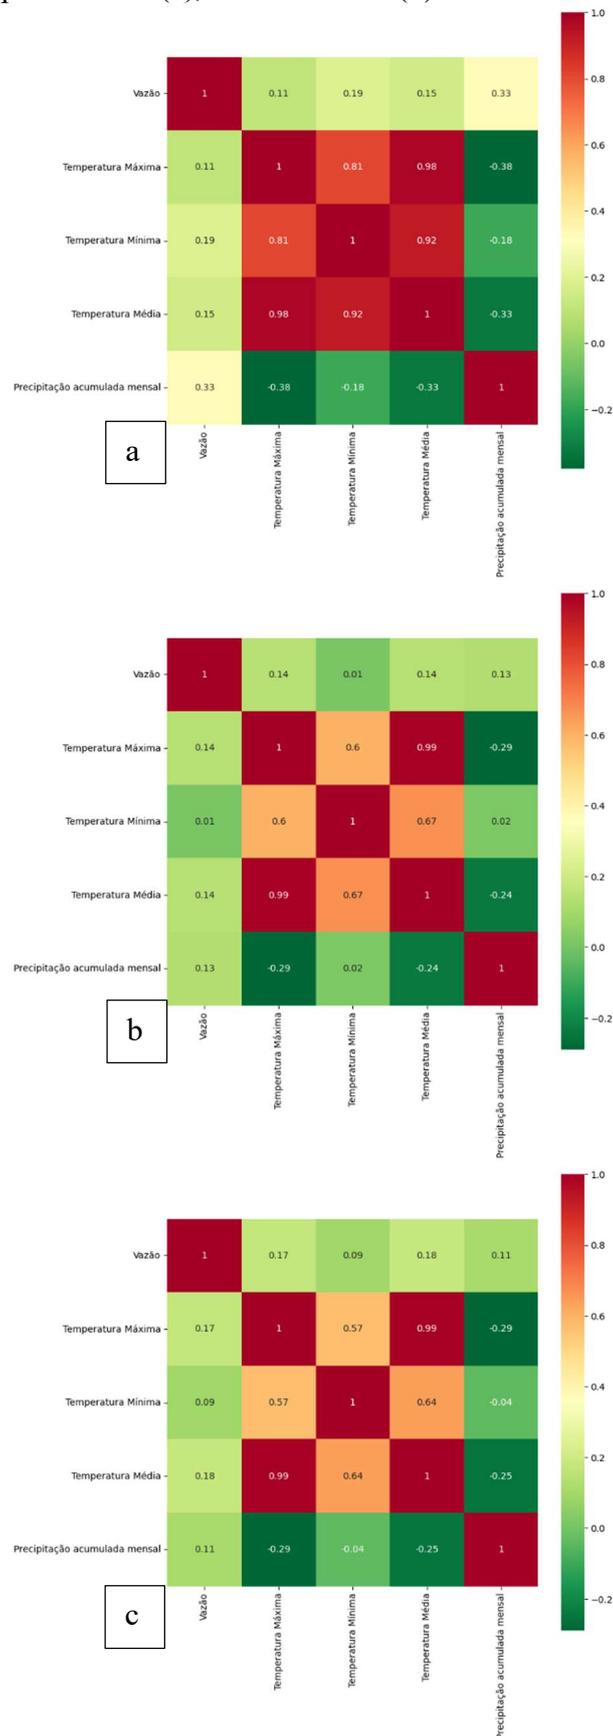
Fonte: Autoria própria (2023).

Após a realização das sínteses de dados, foram obtidas as correlações de Pearson para os dados experimentais e os 125 sintéticos de 0,95 e para os dados experimentais e os 1000 sintéticos de 0,93, indicando uma correlação muito forte entre os dados obtidos experimentalmente e os sintéticos. Na Figura 36, ao analisar as correlações das variáveis selecionadas para o desenvolvimento das redes neurais artificiais em conjunto, constatou-se que elas possuem correlações bem fracas, fracas, moderadas e forte quando analisadas de forma pontual e direta. Entretanto, há uma tendência de comportamento, as correlações positivas tendem a permanecerem positivas e as negativas tendem a permanecerem negativas.

Além do banco de dados sintéticos para processamento das RNA para predição da DBO, DQO e NAT, também foram construídos bancos de dados sintéticos para a vazão, visto que esta variável estava associada a fatores meteorológicos como temperatura máxima, mínima e média e precipitação acumulada mensal, além de possuir a quantidade de dados experimentais superiores a aqueles obtidos na Figura 36.

Após a realização das sínteses dos bancos de dados que representa a saída vazão, foram obtidas correlações de Pearson para os dados experimentais e os 125 sintéticos de 0,99 e para os dados experimentais e os 1000 sintéticos de 0,97, indicando uma correlação muito forte entre os dados obtidos experimentalmente e os sintéticos. Na Figura 37 estão ilustrados os correlogramas para o banco de dados experimentais e sintéticos que correspondem a saída vazão no desenvolvimento das RNA.

Figura 37 - Correlogramas dos dados de entrada e saída para a predição da vazão: experimentais (a), 125 sintéticos (b) e 1000 sintéticos (c)



Fonte: Autoria própria (2023).

Ao analisar as correlações das variáveis selecionadas para o desenvolvimento das redes neurais artificiais para a predição da vazão constatou-se na Figura 37, que as correlações se apresentaram bem fracas, fracas, moderadas, forte e muito forte quando analisadas de forma pontual e direta. E que as correlações da vazão com os demais parâmetros meteorológicos apresentaram uma mesma tendencia de comportamento. As correlações positivas tendem a permanecerem positivas, havendo apenas uma mudança de nível de correlação de fraco para bem fraco quando analisada a vazão com a precipitação acumulada mensal.

Na busca da otimização das métricas de desempenho foram construídos bancos de dados sintéticos para cada variável de saída das RNA. Na Tabela 6 é possível observar os coeficientes de correlação de Pearson dos dados obtidos experimentalmente com os dados sintéticos. Como o banco de dados para a predição da vazão já foi sintetizado separadamente, não houve a necessidade da sintetização de novos bancos de dados para esta variável de saída.

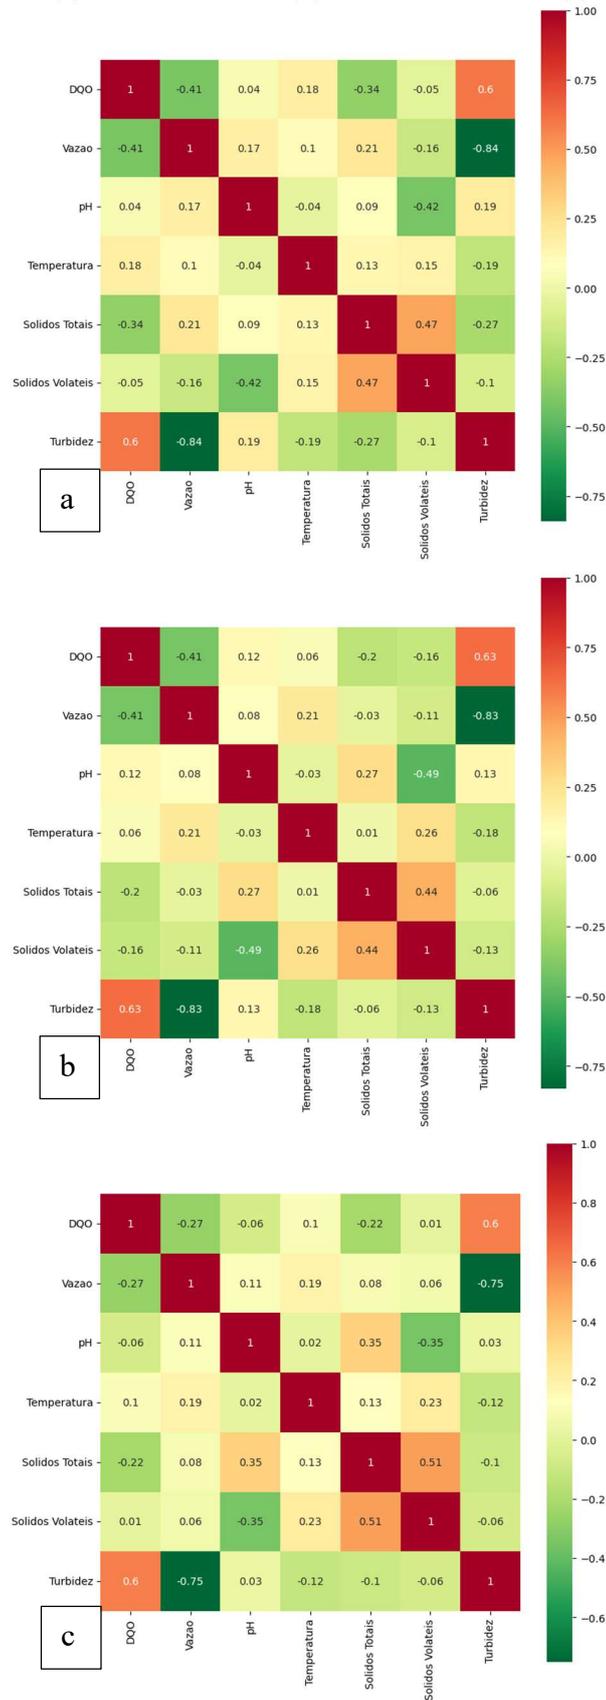
Tabela 6 – Correlação de Pearson entre o banco de dados experimentais e os sintéticos

Banco de dados	Coeficiente de correlação de Pearson	
	125 dados	1000 dados
DBO	0,98	0,94
DQO	1,0	0,93
NAT	0,99	0,97

Fonte: Autoria própria (2023).

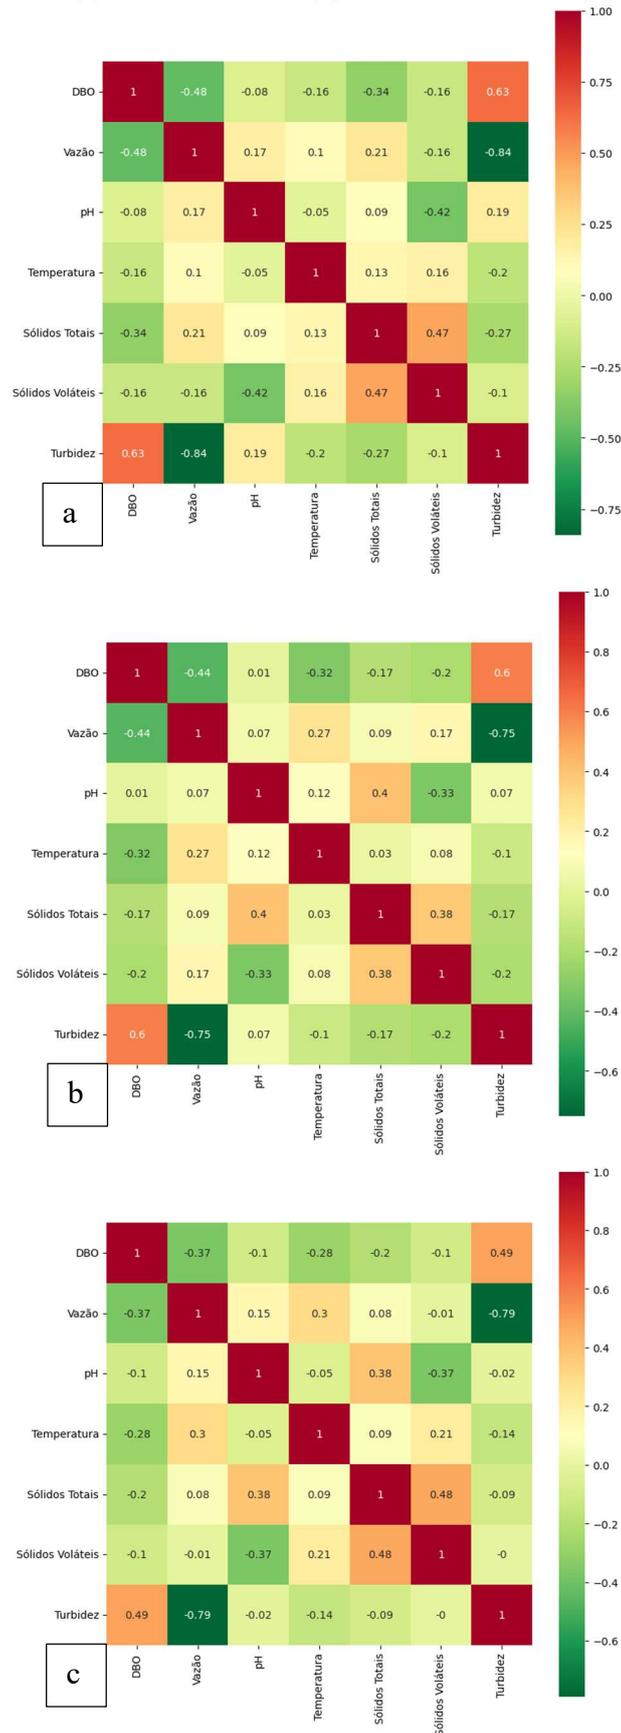
Os correlogramas estão ilustrados nas Figuras 38, 39 e 40 para DQO, DBO e NAT, respectivamente.

Figura 38 - Correlogramas dos dados de entrada e saída para a predição DQO: experimentais (a), 125 sintéticos (b) e 1000 sintéticos (c)



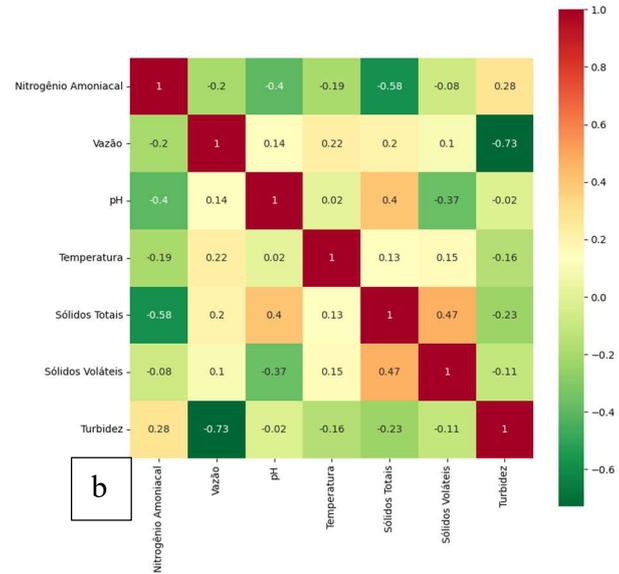
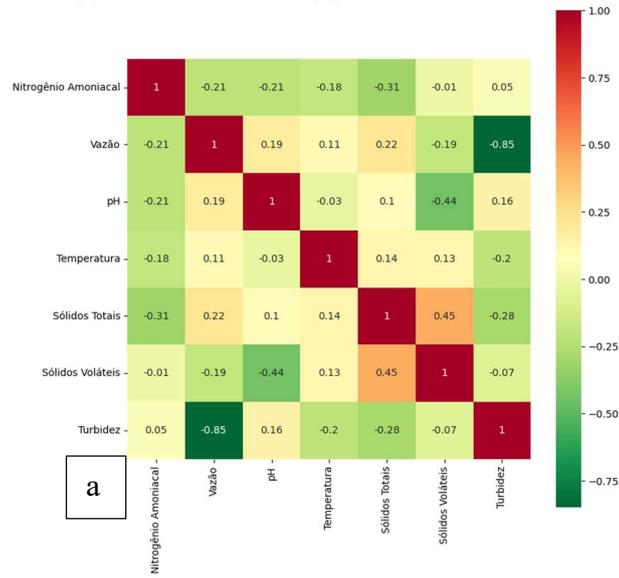
Fonte: Autoria própria (2023).

Figura 39 - Correlogramas dos dados de entrada e saída para a predição DBO: experimentais (a), 125 sintéticos (b) e 1000 sintéticos (c)



Fonte: Autoria própria (2023).

Figura 40 - Correlogramas dos dados de entrada e saída para a predição NAT: experimentais (a), 125 sintéticos (b) e 1000 sintéticos (c)



Fonte: Autoria própria (2023).

Constatou-se na Figura 38, que as correlações se apresentaram bem fracas, fracas, moderadas e fortes quando analisadas de forma pontual e direta. E que as correlações da DQO com os demais parâmetros que correspondem a esse mesmo banco de dados apresentam o mesmo comportamento, as correlações positivas e negativa permaneceram com as mesmas características, assim como, os níveis de correlação, quando comparados os bancos de dados experimentais e os de 125 dados sintéticos. O comportamento é semelhante entre os bancos de dados experimentais e os de 1000 dados sintéticos, entretanto, as correlações entre DQO e sólidos voláteis variaram entre negativa e positiva, porém percebe-se que os valores permaneceram próximos. Entre DQO e vazão manteve-se uma correlação inversamente proporcional.

Constatou-se na Figura 39, que as correlações se apresentaram bem fracas, fracas, moderadas e fortes quando analisadas de forma pontual e direta. E que as correlações da DBO com os demais parâmetros que correspondem a esse mesmo banco de dados apresentam comportamentos tendenciosos, as correlações positivas e negativa variaram entre algumas correlações, assim como, os níveis de correlação, quando comparados os bancos de dados experimentais e os de 125 dados sintéticos. As alterações de comportamentos são mais discretas entre os bancos de dados experimentais e os de 1000 dados sintéticos, havendo a permanência das correlações negativa e positivas, e os valores permaneceram próximos.

Constatou-se na Figura 40, que as correlações se apresentaram bem fracas, fracas, moderadas e fortes quando analisadas de forma pontual e direta. As correlações do NAT com os demais parâmetros que correspondem a esse mesmo banco de dados apresentam uma tendência de comportamento, as correlações positivas tenderam a permanecerem positivas e negativas tenderam a permanecerem negativas, os níveis de correlação mantiveram com valores aproximados, quando comparados os bancos de dados experimentais e os de 125 dados sintéticos. Quanto as alterações de comportamentos entre os bancos de dados experimentais e os de 1000 dados sintéticos, houve a permanência das correlações negativas e positivas, e os valores permaneceram próximos.

4.5 Redes Neurais Artificiais

Para obter a melhor estrutura de RNA para a predição da DBO, DQO, NAT e vazão, várias estruturas de *feedforward backpropagation* com três camadas e diferentes números de neurônios foram investigados. Os algoritmos *trainlm*, *trainbr*, *traingd* e *trainoss* foram usados como função de treinamento e os *tansig*, *logsig*, *purelin* e *elliotsig* como função de ativação.

Serão apresentadas as RNA com as melhores métricas de desempenho para cada banco de dados analisados. As características das RNA e as métricas analisadas para cada arquitetura da rede foram: tipo de banco de dados, neurônios na camada oculta (NCO), função de ativação na camada oculta (FACO), função de ativação na camada de saída (FACS), coeficiente de determinação (R^2), erro médio absoluto (MAE), erro médio quadrático da raiz (RMSE) e erro médio quadrático da raiz normalizado (NRMSE).

4.5.1 DBO

Na Tabela 7 são apresentadas as RNA para a predição de DBO que possuíram as melhores performances de desempenho para cada bancos de dados padronizados e normalizados obtidos experimentalmente e sinteticamente.

Tabela 7 – Performance das RNA para a predição da DBO

Banco de dados	Características da RNA				Medidas de performance				
		NCO	FACO	FACS	AT	MAE	RMSE	NRMSE	R^2
Dados exp.	Pad.	18	<i>tansig</i>	<i>elliotsig</i>	<i>trainlm</i>	0,22	0,27	0,20	0,68
	Nor.	12	<i>elliotsig</i>	<i>purelin</i>	<i>trainoss</i>	0,05	0,06	0,18	0,87
125 dados	Pad.	16	<i>logsig</i>	<i>purelin</i>	<i>trainoss</i>	0,52	0,71	0,19	0,53
	Nor.	12	<i>elliotsig</i>	<i>elliotsig</i>	<i>trainoss</i>	0,16	0,13	0,16	0,83
1000 dados	Pad.	1	<i>tansig</i>	<i>elliotsig</i>	<i>trainlm</i>	0,51	0,64	0,17	0,61
	Nor.	1	<i>logsig</i>	<i>elliotsig</i>	<i>trainlm</i>	0,10	0,13	0,17	0,61

Obs¹: NCO – neurônios na camada oculta; FACO – função de ativação na camada oculta; FACS – função de ativação na camada de saída; R^2 - coeficiente de determinação; MAE – erro médio absoluto; RMSE – erro médio quadrático da raiz; e NRMSE – erro médio quadrático da raiz normalizado

Obs²: A RNA selecionada para a predição da DBO está destacada em negrito.

Fonte: Autoria própria (2023).

Ao analisar as características das melhores RNA selecionadas para a predição da DBO (Tabela 7) verifica-se que, o número de neurônios na camada oculta variou de 1 a 18, sendo 12 o melhor número de neurônios na camada oculta para a predição da DBO. Diferentes números de neurônios na camada oculta são utilizados para análise de problemas ambientais, não havendo uma especificação do número ideal.

Xu *et al.*, (2021) revisou 177 estudos de RNA relacionadas a resíduos sólidos e seus subprodutos (biogás e lixiviado) e apenas 51% especificaram a atribuição de intervalo para otimizar o número de neurônios da camada oculta, indicando que a importância e a transparência dos neurônios da camada oculta devem receber mais atenção. Na maioria dos casos, os limites inferiores dos neurônios da camada oculta estavam entre 1 e 9, e os limites

superiores estavam na faixa de 10 a 29. A partir dos resultados, o número ideal de neurônios da camada oculta em 80% dos estudos ficou entre 4 e 20, corroborando com o número de neurônios ideal encontrado neste estudo. Apesar da otimização do número de neurônios na camada oculta ser uma etapa necessária no estabelecimento do modelo ideal de RNA, não é decisivo para a escolha da RNA.

Quanto ao algoritmo utilizado para a predição da DBO verifica-se na Tabela 7 que apenas os algoritmos *trainlm* e *trainoss* foram indicados dentre os melhores. *Levenberg-Marquardt* atualmente domina os algoritmos de treinamento provavelmente por causa de sua boa capacidade de resolução para problemas de ajuste (Kipli *et al.*, 2012) e suas propriedades de computação rápida e estável (Grosan e Abraham, 2011). Apesar de serem selecionadas, na Tabela 7, três redes neurais com o algoritmo de treinamento *trainlm*, a melhor RNA para a predição da DBO nesse estudo foi o algoritmo de treinamento *trainoss*.

Ao analisar as medidas de performance na Tabela 7 verifica-se que os coeficientes de determinação variaram entre 0,53 e 0,87, sendo as melhores correlações encontradas com os bancos de dados normalizados. Entretanto, ao comparar os bancos de dados, os que apresentaram melhor desempenho, foram os dados experimentais, indicando para esta medida de performance que a elevação do número de dados não representa necessariamente uma melhoria no desempenho da RNA.

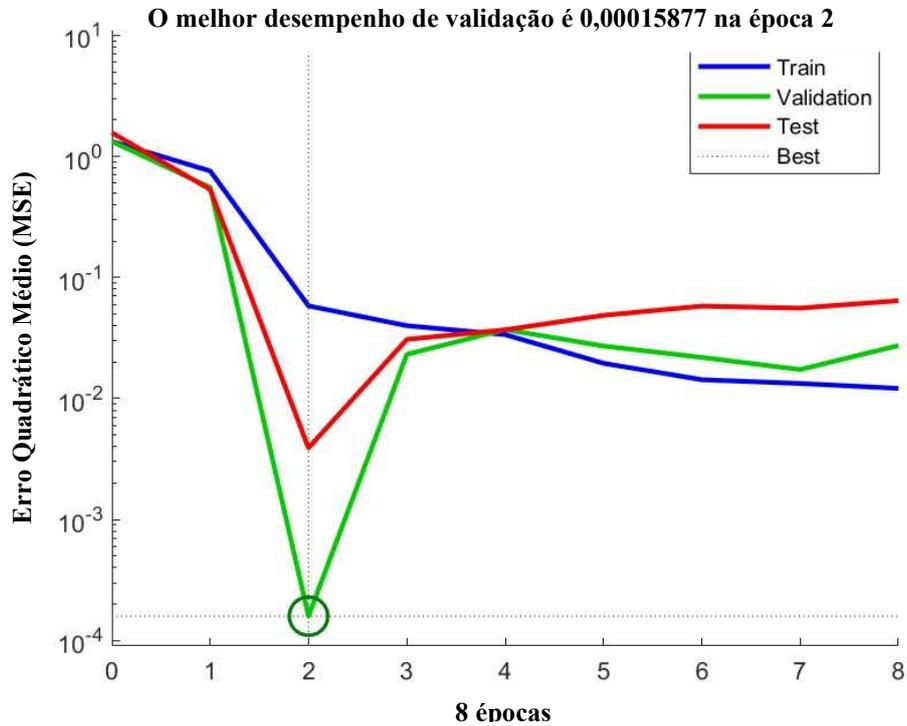
Apesar da obtenção de RNA com o coeficiente de determinação (R^2) indicando uma correlação forte ($0,70 < R^2 < 0,89$) para a predição da DBO, Legate e McCabe Júnior (1999) relatam que este índice é insensível a diferenças aditivas e proporcionais entre as simulações e observações do modelo. Porém, conforme Xu *et al.*, (2021) identificou que essa métrica foi aplicada em 90% dos 177 artigos que analisaram sobre RNA e RSU, publicados entre 2010 e 2020, indicando que este é o coeficiente mais utilizado nas análises de RNA. Entretanto, além da avaliação do coeficiente de determinação, faz-se necessário a análise de outras medidas de performance para confirmação do bom desempenho e escolha da melhor RNA.

De acordo com os resultados obtidos para as medidas de erro absoluto (MAE, RMSE) a melhor rede neural artificial possui MAE de 0,05 e RMSE 0,06, permanecendo a mesma rede que foi selecionada com o maior R^2 . O RMSE é mais sensível a variação de dados, quando comparado com o MAE, por isso o valor obtido para essa métrica foi ligeiramente maior. O NRMSE das RNA apresentadas na Tabela 7 apresentaram uma baixa variação, por isso não foi considerada para seleção da melhor rede neural artificial para a predição da DBO.

Observa-se na Figura 41 o treinamento, validação e teste da performance da RNA selecionada para a predição da DBO. O treinamento foi interrompido com 8 interações, sendo

a melhor performance identificada já na segunda interação, com um erro quadrático médio próximo de zero.

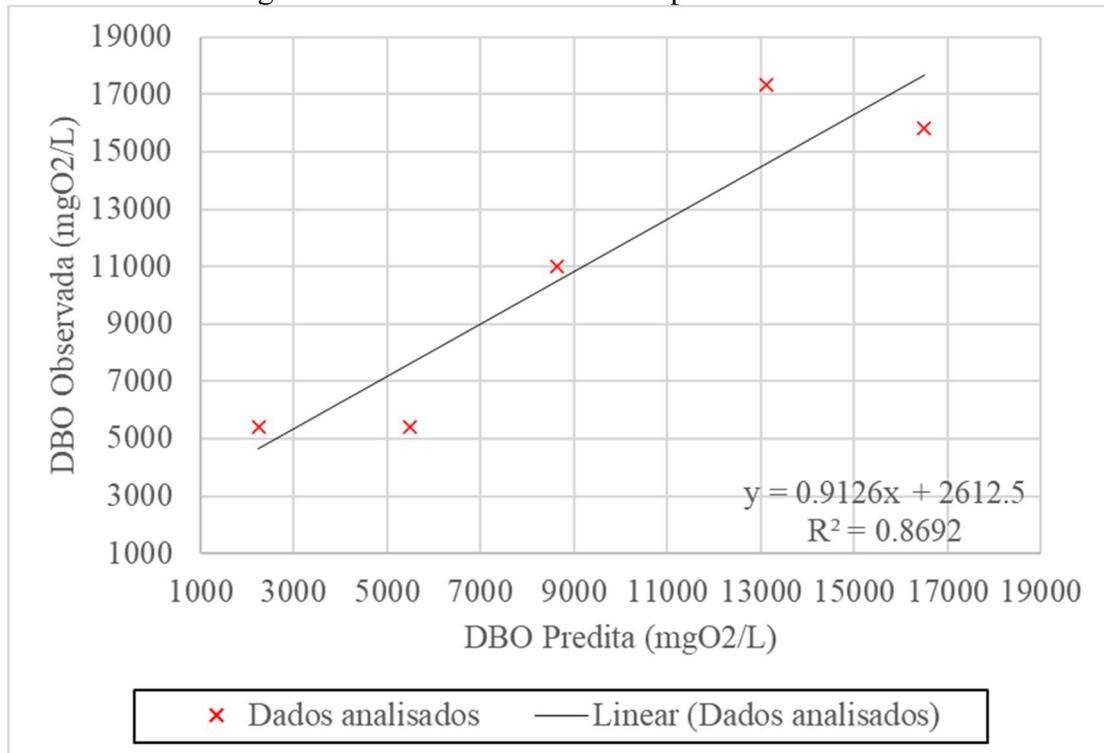
Figura 41 – Performance da RNA com o melhor desempenho para a predição da DBO



Fonte: Autoria própria (2023).

Para analisar o comportamento da RNA selecionada para a predição da DBO também foi plotado um gráfico (Figura 42) demonstrando o comportamento dos valores preditos e observados. Para uma melhor visualização da relação entre os valores preditos e observados, realizou-se uma regressão linear. Observa-se que os pontos se distribuem próximos a linha do ajuste do modelo, indicando proximidade entre as predições e os valores observados para a DBO. Esse padrão de distribuição é característico de um bom modelo preditivo.

Figura 42 – Valores observados e preditos da DBO



Fonte: Autoria própria (2023).

4.5.2 DQO

Na Tabela 8 são apresentadas as RNA para a predição da DQO que possuíram as melhores performances de desempenho para cada banco de dados padronizado e normalizados obtidos experimentalmente e sinteticamente.

Tabela 8 - Performance das RNA para a predição da DQO

Banco de dados	Características da RNA				Medidas de performance				
	NCO	FACO	FACS	AT	MAE	RMSE	NRMSE	R ²	
Dados exp.	Pad.	12	<i>logsig</i>	<i>logsig</i>	<i>trainoss</i>	0,60	0,78	0,51	0,88
	Nor.	12	<i>logsig</i>	<i>logsig</i>	<i>trainoss</i>	0,16	0,21	0,51	0,88
125 dados	Pad.	8	<i>elliotsig</i>	<i>purelin</i>	<i>trainoss</i>	0,50	0,64	0,19	0,59
	Nor.	4	<i>logsig</i>	<i>tansig</i>	<i>trainoss</i>	0,15	0,18	0,20	0,59
1000 dados	Pad.	19	<i>logsig</i>	<i>purelin</i>	<i>traingd</i>	0,59	0,74	0,20	0,39
	Nor.	19	<i>logsig</i>	<i>purelin</i>	<i>trainlm</i>	0,17	0,20	0,21	0,38

Obs¹: NCO – neurônios na camada oculta; FACO – função de ativação na camada oculta; FACS – função de ativação na camada de saída; R² - coeficiente de determinação; MAE – erro médio absoluto; RMSE – erro médio quadrático da raiz; e NRMSE – erro médio quadrático da raiz normalizado

Obs²: A RNA selecionada para a predição da DQO está destacada em negrito.

Fonte: Autoria própria (2023).

Ao analisar as características das melhores RNA selecionadas para a predição da DQO (Tabela 8) verifica-se que a melhor RNA dos bancos de dados experimentais padronizados e normalizados apresentaram as mesmas características quanto ao número de neurônios, função de ativação da camada oculta, função de ativação da camada de saída e algoritmo de treinamento. O mesmo foi verificado para o banco de 1000 dados sintéticos padronizado e normalizado. As métricas de performance NRMSE e R^2 (Tabela 8), apresentaram valores semelhantes quando comparado os dados padronizados e normalizados para cada banco de dados.

O número de neurônios na camada oculta variou de 4 a 19, sendo 12 o melhor número de neurônios na camada oculta para a predição da DQO. O número de neurônios da RNA considerada ideal para a predição da DQO foi igual ao verificado na Tabela 7 para a predição da DBO.

Dentre as melhores RNA para a predição da DQO o algoritmo que prevaleceu foi o *trainoss*, sendo o *trainbr* o único algoritmo que não esteve presente na Tabela 8. Arabameri *et al.* (2017) compararam 10 algoritmos de treinamento diferentes para prever a eficiência de remoção de DQO do lixiviado do aterro, e *trainlm* foi identificado como o melhor para o treinamento de RNA. O desempenho insatisfatório do algoritmo *trainbr* pode ser associado ao fato de que ele atualiza os valores de peso e viés de acordo com a otimização, processo chamado de regularização bayesiana, onde as paradas de validação são desativadas por padrão, para que o treinamento continue até que uma combinação ideal de erros e pesos seja encontrado (Liang *et al.*, 2018).

Ao analisar as medidas de performance na Tabela 8 verifica-se que os coeficientes de determinação variaram entre 0,38 e 0,88, apresentando correlações consideradas fracas a fortes, respectivamente. Ao comparar os bancos de dados, os que apresentaram melhor desempenho, foram os dados experimentais normalizados, indicando para esta medida de performance que a elevação do número de dados não representa necessariamente uma melhoria no desempenho da RNA. Comportamento análogo a DQO foi verificado na Tabela 7 para a predição da DBO.

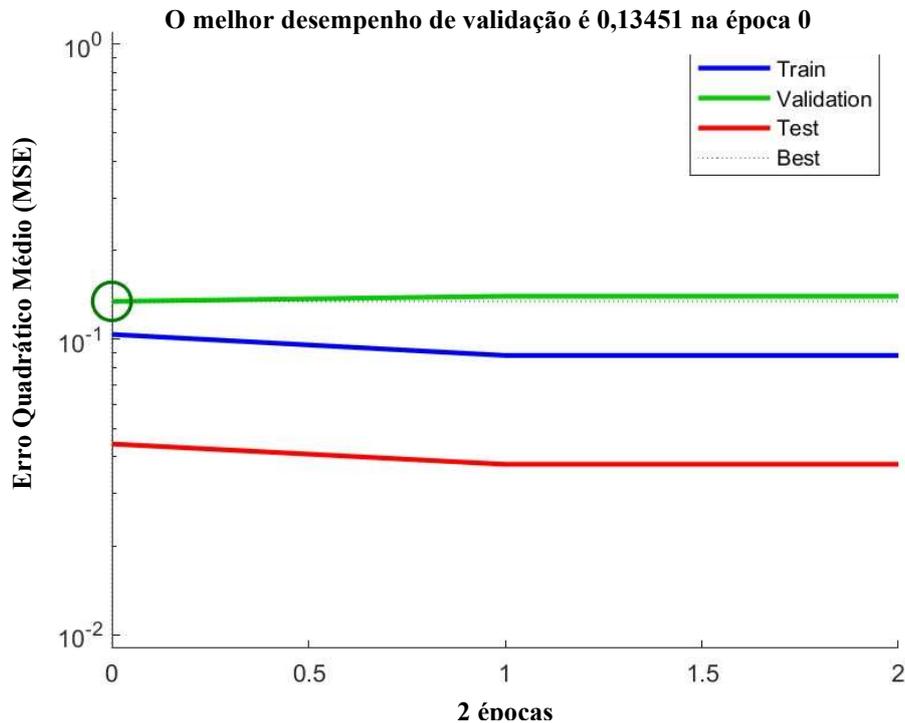
Apesar da obtenção de uma RNA com o coeficiente de determinação (R^2) indicando uma correlação forte ($0,70 < R^2 < 0,89$) para a predição da DQO, faz-se necessária a análise de outras métricas de desempenho, como o erro absoluto e normalizado.

Os bancos de dados sintéticos apresentaram os menores erros absolutos (MAE, RMSE), e estes apresentaram valores semelhantes e avaliando o NRMSE das RNA apresentadas na Tabela 8, verificou-se uma variação de 0,19 a 0,51. Através das análises do conjunto de medidas de performance, a rede neural artificial escolhida para a predição da DQO, apresentou o MAE

de 0,16 e RMSE de 0,21 e NRMSE de 0,51, e que mesmo não possuindo os menores erros, foi selecionada em virtude do R^2 ser o maior dentre as demais RNA.

Observa-se na Figura 43 o treinamento, validação e teste da performance da RNA selecionada para a predição da DQO. O treinamento foi interrompido com 2 interações, com um erro quadrático médio de 0,13.

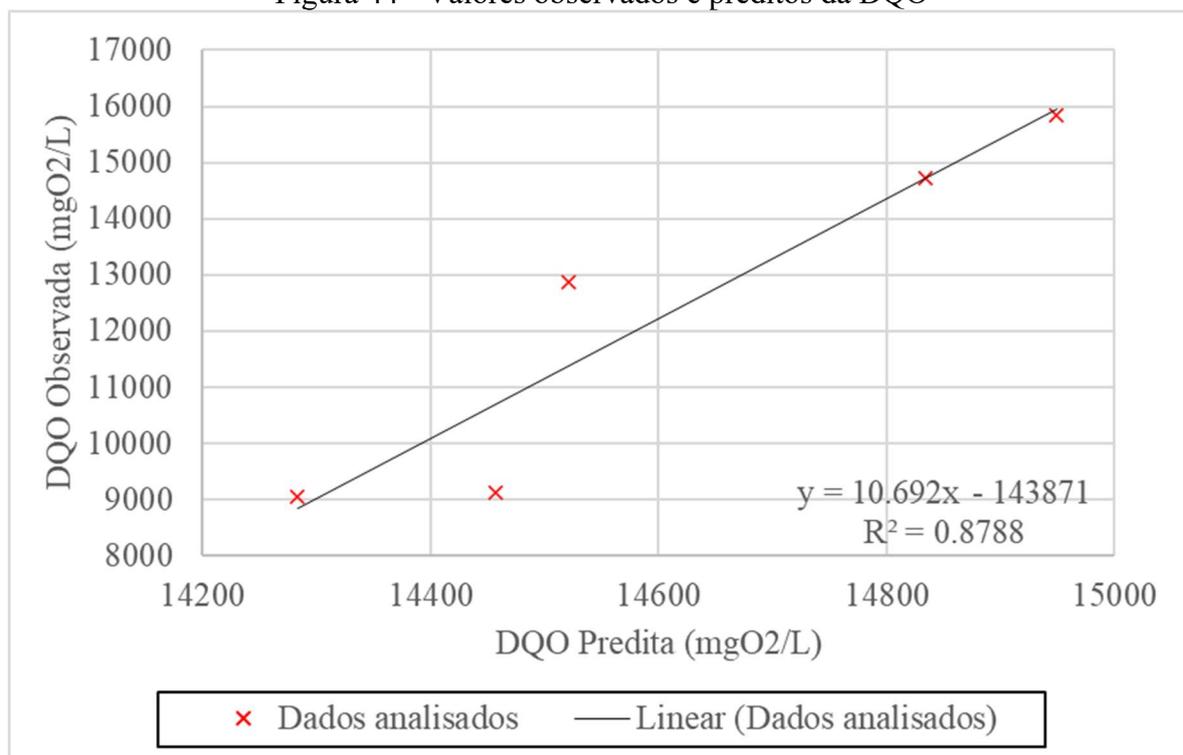
Figura 43 - Performance da RNA com o melhor desempenho para a predição da DQO
Erro Quadrático Médio (MSE)



Fonte: Autoria própria (2023).

Para analisar o comportamento da RNA selecionada para a predição da DQO também foi plotado um gráfico (Figura 44) demonstrando o comportamento dos valores preditos e observados. Para a melhor visualização dessa relação, realizou-se uma regressão linear. Observa-se que os pontos se distribuem próximos a linha do ajuste do modelo, indicando proximidade entre as predições e os valores observados para a DQO. Esse padrão de distribuição é característico de um bom modelo preditivo.

Figura 44 - Valores observados e preditos da DQO



Fonte: Autoria própria (2023).

4.5.3 NAT

Na Tabela 9 são apresentadas as RNA para a predição de NAT que possuíram as melhores performances de desempenho para cada bancos de dados padronizados e normalizados obtidos experimentalmente e sinteticamente.

Tabela 9 – Performance das RNA para a predição do NAT

Banco de dados	Características da RNA				Medidas de performance				
	Pad.	NCO	FACO	FACS	AT	MAE	RMSE	NRMSE	R ²
Dados exp.	Pad.	7	<i>purelin</i>	<i>elliotsig</i>	<i>traingd</i>	0,56	0,76	0,26	0,56
	Nor.	13	<i>elliotsig</i>	<i>tansig</i>	<i>trainoss</i>	0,06	0,06	0,12	0,94
125 dados	Pad.	4	<i>logsig</i>	<i>elliotsig</i>	<i>traingd</i>	0,64	0,79	0,20	0,24
	Nor.	13	<i>logsig</i>	<i>tansig</i>	<i>traingd</i>	0,09	0,12	0,14	0,66
1000 dados	Pad.	20	<i>tansig</i>	<i>tansig</i>	<i>trainoss</i>	0,65	0,82	0,19	0,39
	Nor.	10	<i>tansig</i>	<i>purelin</i>	<i>trainlm</i>	0,14	0,17	0,19	0,36

Obs¹: NCO – neurônios na camada oculta; FACO – função de ativação na camada oculta; FACS – função de ativação na camada de saída; R² - coeficiente de determinação; MAE – erro médio absoluto; RMSE – erro médio quadrático da raiz; e NRMSE – erro médio quadrático da raiz normalizado

Obs²: A RNA selecionada para a predição da NAT está destacada em negrito.

Fonte: Autoria própria (2023).

Ao analisar as características das melhores RNA selecionadas para a predição do NAT (Tabela 9) verifica-se que, dentre os bancos de dados analisados, elas não possuem um padrão de comportamento. O número de neurônios na camada oculta variou de 4 a 20, sendo 13 o melhor número de neurônios na camada oculta para a predição do NAT. Comportamento análogo foi verificado na Tabela 7 para a predição da DBO. O número de neurônios da RNA considerada ideal para a predição do NAT encontra-se dentro da faixa de investigação determinada por Xu *et al.*, (2022). Segundo Zonouz *et al.*, (2016) esse parâmetro geralmente é determinado por tentativa e erro, não havendo uma especificação para o número de neurônios na camada oculta, sua determinação só é possível após a realização de testes e análises das métricas de desempenho das RNA.

Com os bancos de dados para a predição do NAT, as melhores RNA selecionadas apresentaram pelo menos um dos algoritmos de treinamento dentre todos utilizados nos testes das RNA, exceto o *trainbr*. Comportamento análogo à performance Comportamento análogo foi verificado na Tabela 8 para a predição da DQO.

Apesar do algoritmo *traingd* não ter sido o algoritmo da RNA selecionada para a predição do NAT, ele se mostrou em três das seis RNA apresentadas na Tabela 9. O algoritmo *traingd* é uma função de treinamento de RNA que atualiza os valores de peso e bias de acordo com a descida do gradiente, e assim, requer pequenas taxas para um aprendizado estável (Bezerra, 2021). Alguns autores encontraram bons desempenhos em redes neurais utilizando o algoritmo *traingd*, como por exemplo, Pandey *et al.* (2012), que a utilizaram na previsão de temperatura interna em edifícios (MAE:0,67 e MSE: 0,75) e Pamungkas *et al.* (2020) para previsão de colheitas na Indonésia (MAE: 0,0366, RMSE: 0,1913 e MAPE: 29,89%), demonstrando diversas e efetivas aplicações para a função de treinamento.

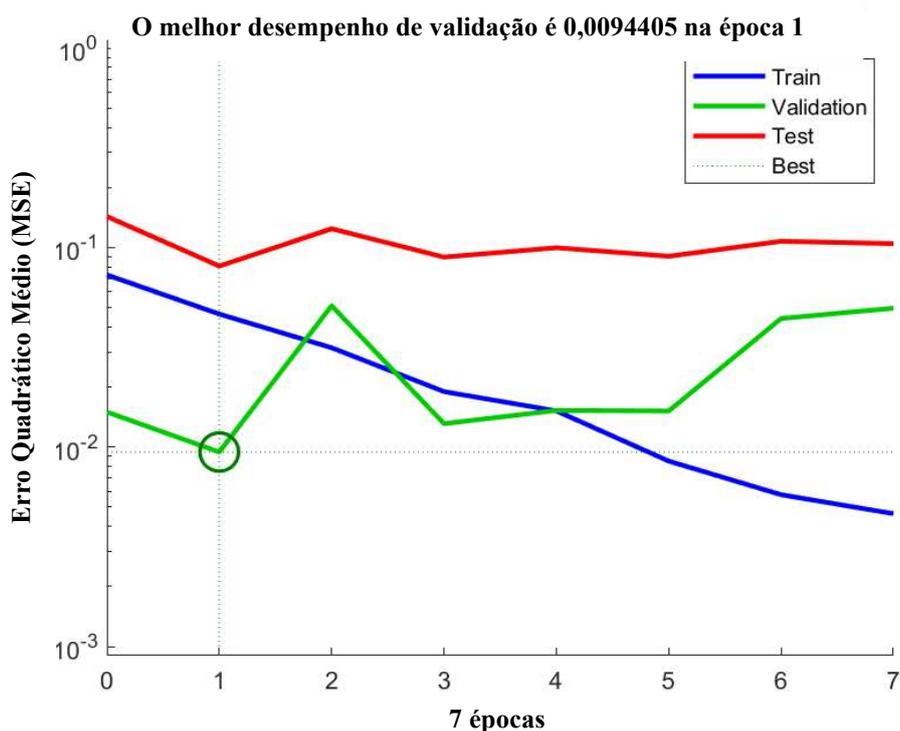
Ao analisar as medidas de performance na Tabela 9, verifica-se que os coeficientes de determinação variaram entre 0,24 e 0,94, apresentando correlações consideradas fracas a muito forte, respectivamente. Entretanto, ao comparar os bancos de dados, os que apresentaram melhor desempenho, foram os dados experimentais normalizados, indicando para esta medida de performance que a elevação do número de dados não representa necessariamente uma melhoria no desempenho da RNA. Comportamento análogo foi verificado nas Tabela 7 e Tabela 8 para a predição da DBO e da DQO, respectivamente.

Apesar da obtenção de uma RNA com o coeficiente de determinação (R^2) indicando uma correlação muito forte ($0,90 < R^2 < 1,00$) para a predição do NAT, faz-se necessária a análise de outras métricas de desempenho, como o erro absoluto e normalizado.

De acordo com os resultados obtidos para as medidas de erro absoluto (MAE, RMSE) a melhor rede neural artificial possui MAE de 0,06 e RMSE 0,06, permanecendo a mesma rede que foi selecionada com o maior R^2 . Mesmo o RMSE sendo mais sensível com a variação de dados quando comparada com o MAE, ambas métricas apresentaram numericamente, valores próximos, indicando que não houve variações significativas nos resíduos analisados. Avaliando o NRMSE das RNA apresentadas na Tabela 9 verificou-se uma variação de 0,12 a 0,26, sendo o menor valor encontrado para a RNA selecionada para a predição do NAT.

Observa-se na Figura 45 o treinamento, validação e teste da performance da RNA selecionada para a predição do NAT. O treinamento foi interrompido com 7 interações, sendo a melhor performance identificada já na primeira interação, com um erro quadrático médio próximo de zero.

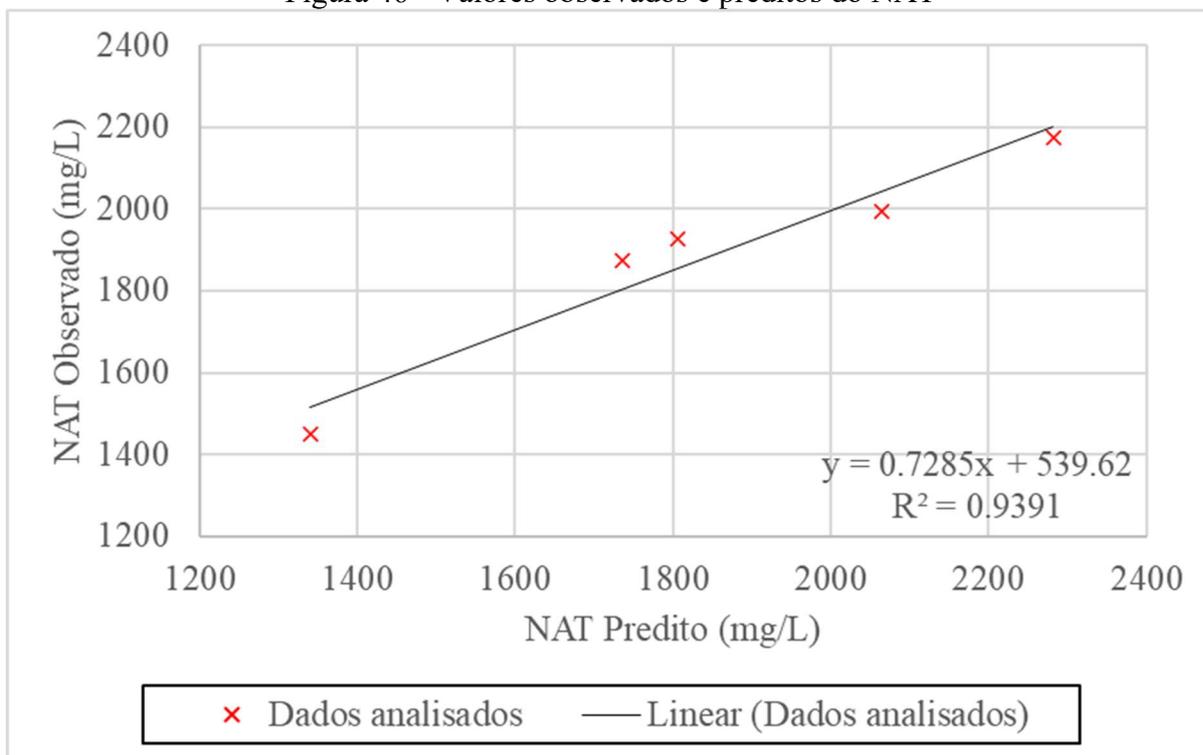
Figura 45 - Performance da RNA com o melhor desempenho para a predição do NAT



Fonte: Autoria própria (2023).

Para analisar o comportamento da RNA selecionada para a predição do NAT também foi plotado um gráfico (Figura 46) demonstrando o comportamento dos valores preditos e observados. Para a melhor visualização dessa relação, realizou-se uma regressão linear. Observa-se que os pontos se distribuem próximos a linha do ajuste do modelo, indicando proximidade entre as predições e os valores observados para a DBO. Esse padrão de distribuição é característico de um bom modelo preditivo.

Figura 46 - Valores observados e preditos do NAT



Fonte: Autoria própria (2023).

4.5.4 Vazão

Na Tabela 10 são apresentadas as RNA para a predição da vazão que possuíram as melhores performances de desempenho para cada bancos de dados padronizados e normalizados obtidos experimentalmente e sinteticamente.

Tabela 10 - Performance das RNA para a predição da vazão

Banco de dados	Características da RNA				Medidas de performance				
	NCO	FACO	FACS	AT	MAE	RMSE	NRMSE	R ²	
Dados exp.	Pad.	14	<i>tansig</i>	<i>purelin</i>	<i>trainoss</i>	0,58	0,80	0,23	0,46
	Nor.	15	<i>elliotsig</i>	<i>tansig</i>	<i>trainlm</i>	0,17	0,21	0,24	0,55
125 dados	Pad.	16	<i>elliotsig</i>	<i>tansig</i>	<i>traingd</i>	0,67	0,87	0,24	0,24
	Nor.	12	<i>elliotsig</i>	<i>purelin</i>	<i>trainoss</i>	0,21	0,25	0,25	0,26
1000 dados	Pad.	18	<i>tansig</i>	<i>elliotsig</i>	<i>traingd</i>	0,69	0,84	0,22	0,17
	Nor.	10	<i>elliotsig</i>	<i>tansig</i>	<i>traingd</i>	0,17	0,22	0,23	0,12

Obs¹: NCO – neurônios na camada oculta; FACO – função de ativação na camada oculta; FACS – função de ativação na camada de saída; R² - coeficiente de determinação; MAE – erro médio absoluto; RMSE – erro médio quadrático da raiz; e NRMSE – erro médio quadrático da raiz normalizado

Obs²: A RNA selecionada para a predição da vazão está destacada em negrito.

Fonte: Autoria própria (2023).

As melhores RNA selecionadas para a predição da vazão (Tabela 10) não possuem um padrão de comportamento. O número de neurônios na camada oculta variou de 10 a 18, sendo a RNA com 15 o melhor número de neurônios na camada oculta para a predição da vazão.

Conforme Gadekar *et al.*, (2019) a determinação do número de neurônios da camada oculta tem uma influência direta no desempenho da RNA. Na maioria dos estudos baseados em RNA, o número de neurônios da camada oculta variou entre 1 e 20, segundo Kıranşan *et al.*, (2015), Karri *et al.*, (2018). Embora um aumento no número de neurônios da camada oculta possa melhorar a eficiência do processo, simultaneamente, também pode exagerar a probabilidade de ajuste excessivo do modelo (Taghavifar *et al.*, 2014). Por outro lado, RNA com menor número de neurônios da camada oculta pode restringir a precisão e representação arbitrária aproximada devido à falta de graus de liberdade suficientes, a capacidade de aprendizagem é restrita junto com a precisão arbitrária aproximada (Angeline *et al.*, 2019; Dil *et al.*, 2016). Portanto, após o treinamento, com diferentes RNA faz-se necessária a análise de suas métricas de desempenho para seleção da melhor (Reza *et al.*, 2022).

Com os bancos de dados para a predição da vazão, as melhores RNA selecionadas apresentaram pelo menos um dos algoritmos de treinamento dentre todos utilizados nos testes das RNA, exceto o *trainbr*. Seguindo a mesma tendência das melhores RNA selecionadas para a predição do NAT (Tabela 9).

Ao analisar as medidas de performance na Tabela 10, verifica-se uma variação nos coeficientes de determinação entre 0,12 e 0,55, apresentando correlações consideradas bem fracas a moderada, respectivamente. Entretanto, ao comparar os bancos de dados, os que apresentaram um melhor desempenho, foram os dados experimentais, sobretudo o normalizado, indicando que a elevação do número de dados não representa necessariamente uma melhoria no desempenho da RNA, para esta medida de performance. Comportamento análogo foi verificado em todas as melhores RNA nas Tabela 7, Tabela 8 e Tabela 9 para a predição da DBO, DQO e NAT, respectivamente.

Apesar da obtenção de uma RNA com o coeficiente de determinação (R^2) indicando uma correlação moderada ($0,40 < R^2 < 0,69$) para a predição da vazão, faz-se necessária a análise de outras métricas de desempenho, como o erro absoluto e normalizado.

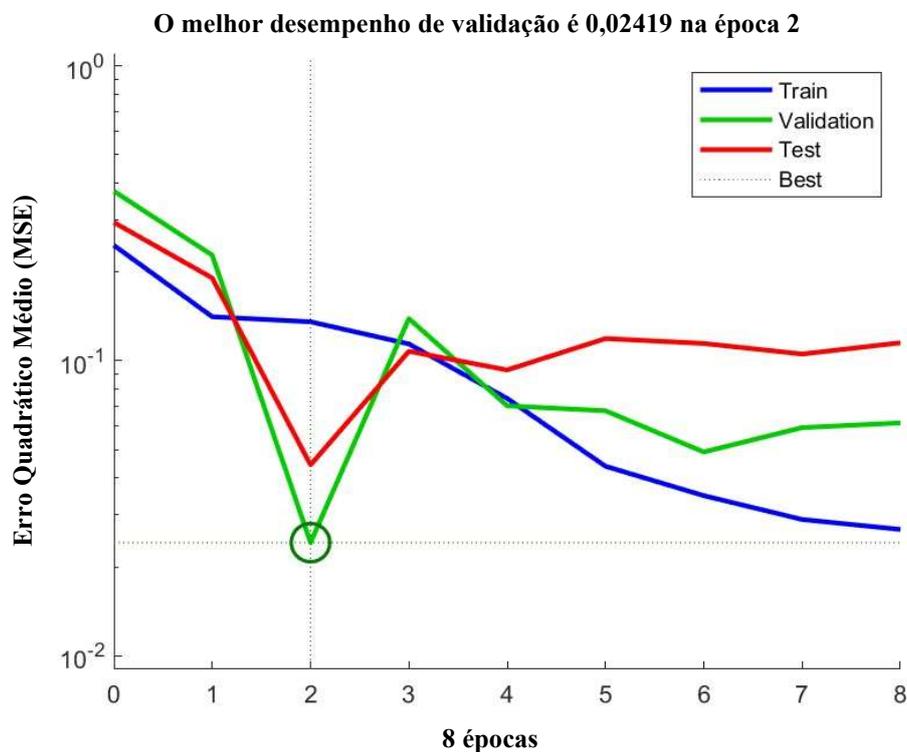
De acordo com os resultados obtidos para as medidas de erro absoluto (MAE, RMSE) a melhor rede neural artificial possui MAE de 0,17 e RMSE 0,21, coincidindo com a mesma rede que apresentou o maior R^2 . Verifica-se que o RMSE da RNA selecionada para a predição da vazão é maior que o MAE, indicando a possibilidade de uma maior dispersão dos resultados,

uma vez que, o RMSE é mais sensível a variação dos dados quando comparado ao MAE. Olatunji *et al.*, (2019) e Liu *et al.*, (2022) também encontraram valores de RMSE maiores que o MAE em seus estudos de RSU com utilização de RNA, sendo o MAE de 0,33 e 42,31, e RMSE de 3,095 e 63,32, respectivamente.

Avaliando o NRMSE das RNA apresentadas na Tabela 10 verificou-se uma variação de 0,22 a 0,25. Entretanto, o menor NRMSE para a predição de vazão não foi adotado como prioridade na escolha da melhor RNA, em virtude da priorização da escolha pelo maior R^2 , dos menores valores para o MAE e RMSE, além de que os próprios valores de NRMSE sofrerem poucas variações entre as RNA selecionadas na Tabela 10.

Observa-se na Figura 47 o treinamento, validação e teste da performance da RNA selecionada para a predição da vazão. O treinamento foi interrompido com 8 interações, sendo a melhor performance identificada na segunda interação, com um erro quadrático médio de 0,02.

Figura 47 - Performance da RNA com o melhor desempenho para a predição da vazão

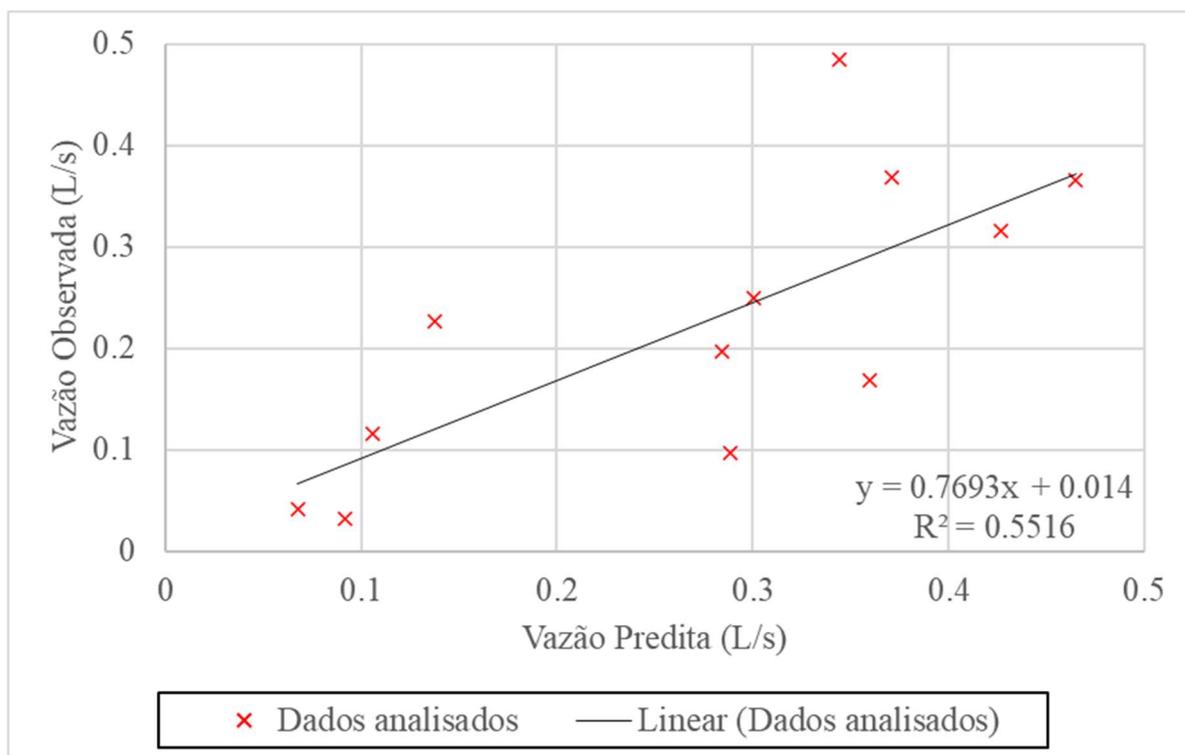


Fonte: Autoria própria (2023).

Para analisar o comportamento da RNA selecionada para a predição da vazão também foi plotado um gráfico (Figura 48) demonstrando o comportamento dos valores preditos e observados. Observa-se que, os valores se encontram dispersos e a regressão linear não possuiu

um bom ajuste aos dados. Provavelmente esse baixo poder preditivo da melhor RNA esteja associada as variáveis de entrada da rede.

Figura 48 - Valores observados e preditos da vazão



Fonte: Autoria própria (2023).

Mesmo escolhendo parâmetros comumente utilizados para a predição da vazão do lixiviado de aterros sanitários, como verificados nos estudos de Ishii *et al.* (2022), Karaca Özkaya *et al.* (2006) e Abunama *et al.*, (2019), não foi possível obter uma RNA com alta capacidade de predição. Outros fatores como eficiência do sistema de drenagem e as camadas de cobertura intermediária de solo das células do aterro sanitário, assim como, a recirculação de lixiviado podem ter influenciado na vazão mais do que os fatores meteorológicos. Porém, não foi possível incluir essas variáveis nesta pesquisa, devido a incerteza dos dados. Sendo necessário a realização de estudos específicos para a certificação da eficiência do sistema de drenagem e controle da vazão de lixiviado recirculado.

4.5.4 Melhores RNA para predição da DBO, DQO, NAT e vazão

Mesmo com a síntese de dados, para 125 e 1000 dados para cada banco de dados utilizados na predição da DBO, DQO, NAT e vazão de lixiviado de aterro sanitário no semiárido, para melhorar a robustez do banco de dados, as melhores RNA foram obtidas com o banco de dados experimentais normalizados. No Apêndice C é possível verificar o desempenho da melhor RNA para cada variação do número de neurônios da camada oculta, sendo analisados por banco de dados e algoritmo de treinamento.

Na Tabela 11 são apresentadas as performances de desempenho das melhores RNA para a predição da DBO, DQO, NAT e vazão de lixiviado de aterro sanitário no semiárido.

Tabela 11 - Performances das melhores RNA para predição da DBO, DQO, NAT e vazão

Predição da variável	Características da RNA				Medidas de performance			
	NCO	FACO	FACS	AT	MAE	RMSE	NRMSE	R ²
DBO	12	<i>elliotsig</i>	<i>purelin</i>	<i>trainoss</i>	0,05	0,06	0,18	0,87
DQO	12	<i>logsig</i>	<i>logsig</i>	<i>trainoss</i>	0,16	0,21	0,51	0,88
NAT	13	<i>elliotsig</i>	<i>tansig</i>	<i>trainoss</i>	0,06	0,06	0,12	0,94
Vazão	15	<i>elliotsig</i>	<i>tansig</i>	<i>trainlm</i>	0,17	0,21	0,24	0,55

Obs! : NCO – neurônios na camada oculta; FACO – função de ativação na camada oculta; FACS – função de ativação na camada de saída; R² - coeficiente de determinação; MAE – erro médio absoluto; RMSE – erro médio quadrático da raiz; e NRMSE – erro médio quadrático da raiz normalizado

Fonte: Autoria própria (2023).

Observa-se na Tabela 11, que o número de neurônios na camada oculta esteve entre 12 e 15. O algoritmo de treinamento, que prevaleceu entre as melhores RNA foi o *trainoss*, exceto para a vazão que foi o algoritmo *trainlm* que apresentou um melhor desempenho. Baptista *et al.*, (2013), realizou uma comparação de 21 algoritmos de treinamentos de RNA com diversos bancos de dados e constatou que, de uma maneira geral, o *trainoss* é o melhor algoritmo de treinamento e na segunda posição encontram-se *trainlm*. Em relação aos piores desempenhos, os autores, encontraram o algoritmo de *traingd* com uma classificação muito baixa quando comparado a outros algoritmos. Corroborando com os resultados encontrados nesta pesquisa.

As funções de ativação na camada oculta, também obtiveram um comportamento semelhante, a *elliotsig* esteve presente na DBO, NAT e vazão, e a *logsig* para a DQO. Quanto a camada de saída, houve uma variação do tipo de função de ativação selecionada para predição das variáveis, sendo a *purelin* para a DBO, *logsig* para DQO e *tansig* para NAT e vazão. Entretanto a função *elliotsig* não esteve presente na predição de nenhuma variável na camada de saída.

Diante das melhores RNA desenvolvidas e selecionadas, que foram apresentadas na Tabela 11, para a predição da DBO, DQO e NAT, pode-se afirmar que são boas preditoras em função das medidas de performance analisadas e podem ser utilizadas para análise do comportamento e característica do lixiviado gerado em aterro sanitário. Para a predição da vazão recomenda-se a inserção de mais variáveis que possam aumentar o coeficiente de determinação (R^2) uma vez que, para o estágio atual da investigação, esta RNA só consegue explicar 55% da variação da vazão.

5. CONCLUSÕES

- Neste trabalho foram desenvolvidos modelos neurais, testando diversas variações na arquitetura da RNA e banco de dados, buscando auxiliar na caracterização do lixiviado de aterro sanitário localizado em região semiárida brasileira, através da predição da DBO, DQO, NAT e vazão, obtendo bons resultados através das análises das métricas de desempenho;
- Os estudos envolvendo os resíduos mostraram-se importantes por permitir conhecer melhor a caracterização dos resíduos e seu comportamento em função da idade de aterramento, assim como as frações dos materiais com potencial de geração de lixiviado, que pode auxiliar nas tomadas de decisões da gestão integrada de resíduos sólidos;
- As características físico-químicas dos resíduos sólidos urbanos para este empreendimento localizado em região semiárida brasileira, para essas condições climáticas e de operação do aterro sanitário, como a compactação e o processo de recirculação de lixiviado que é realizado no maciço sanitário, além da composição dos RSU, indicaram que este aterro sanitário possui um processo biodegradativo acelerado, apontando rápida estabilização dos RSU depositados.
- Ao longo dos anos de aterramento, os resíduos apresentaram uma redução do teor de umidade, teor de sólidos voláteis, DBO₅ e DQO. Essa redução está diretamente relacionada com a matéria orgânica que inicialmente apresenta elevada atividade biológica;
- As características climáticas da região semiárida, confere ao lixiviado características exclusivas, quando comparados com aterros sanitários de outras localidades. O Aterro Sanitário em estudo apresentou baixas taxas de geração de lixiviado, e consequentemente, um elevado potencial poluidor, indicado o efeito da concentração dos parâmetros em virtude principalmente dos baixos índices pluviométricos e elevadas taxas de evaporação que caracterizam a localização deste empreendimento. Estes efeitos dificultam a aplicação de modelos já desenvolvidos para a predição das características quantitativas do lixiviado;
- Através do monitoramento para a caracterização do lixiviado verificou-se que o lixiviado do Aterro Sanitário em estudo apresenta valores de turbidez, pH, sólidos totais e voláteis, DQO, DBO₅, que correspondem a um acelerado processo biodegradativo, quando comparado a idade equivalente da disposição de RSU no Aterro Sanitário;

- Os bancos de dados sintéticos utilizados nesta pesquisa, apresentaram coeficientes de correlação de Pearson muito forte, entre o banco de dados experimental e os sintéticos de 125 e 1000 dados, indicando similaridades entre os bancos de dados. Comprovando que para cada banco de dados criado sinteticamente a partir de dados experimentais do monitoramento, há representatividade e semelhanças no comportamento, equivalente aos banco de dados original;
- Dentre os bancos de dados normalizados e padronizados, experimentais e sintéticos com 125 e 1000 dados, as melhores RNA desenvolvidas e selecionadas para a predição da DBO, DQO, NAT e vazão por possibilitarem os melhores desempenhos seguindo as análises das medidas de performance, foram para o banco de dados experimentais normalizados;
- Para a predição da DBO, DQO e NAT, as melhores RNA foram selecionadas seguindo algumas prioridades das medidas de performance, sendo respectivamente, os maiores coeficiente de determinação (R^2) de 0,87, 0,88, e 0,94; seguindo por menores erro médio absoluto (MAE) de 0,05, 0,16, 0,06; erro médio quadrático da raiz (RMSE) de 0,06, 0,21, 0,06; e erro médio quadrático da raiz normalizado (NRMSE) de 0,18, 0,51 e 0,12. Esses resultados indicam que as RNA desenvolvidas são boas preditoras da DBO, DQO e NAT, e podem ser utilizadas para análise do comportamento e característica do lixiviado gerado em aterro sanitário;
- Para a predição da vazão, as medidas de performance selecionadas foram respectivamente, R^2 de 0,55; MAE de 0,17; RMSE de 0,21; e NRMSE de 0,24. Para esta RNA da vazão, recomenda-se um ajuste no banco de dados, como a inserção de mais variáveis que possam aperfeiçoar o R^2 , entre os dados observados e preditos.

REFERÊNCIAS

- ABBAS, A. A., JINGSONG, G., PING, L. Z., YA, P. Y., & AL-REKABI, W. S. (2009). Review on landfill leachate treatments. **Journal of Applied Sciences Research**, 5, 534–545.
- ABDALLAH, M., TALIB, M. A., FEROZ, S., NASIR, Q., ABDALLA, H., & MAHFOOD, B. (2020). Artificial intelligence applications in solid waste management: A systematic research review. **Waste Management**, 109, 231-246.
- ABRELPE. **Associação Brasileira de Empresas de Limpeza Pública e Resíduos Especiais**. 2020.
- ABUNAMA, Taher et al. Quantifying the Generated and Percolated Leachate through a Landfill's Lining System in Gaza Strip, Palestine. **Polish Journal of Environmental Studies**, v. 26, n. 6, 2017.
- ABUNAMA, T., OTHMAN, F., & YOUNES, M. K. (2018). Predicting sanitary landfill leachate generation in humid regions using ANFIS modeling. **Environmental monitoring and assessment**, 190(10), 1-15.
- ABUNAMA, T., OTHMAN, F., ANSARI, M., & EL-SHAFIE, A. (2019). Leachate generation rate modeling using artificial intelligence algorithms aided by input optimization method for an MSW landfill. **Environmental Science and Pollution Research**, 26(4), 3368-3381.
- ABUNAMA, T; OTHMAN, F; NILAM, T. I. T. **Comparison of landfill leachate generation and pollution potentials in humid and semi-arid climates** . **Jornal Internacional de Meio Ambiente e Gerenciamento de Resíduos**, v. 27, n. 1, pág. 79-92, 2021.
- AGÊNCIA EXECUTIVA DE GESTÃO DAS ÁGUAS DO ESTADO DA PARAÍBA. AESA: **Meteorologia** – Chuvas. Campina Grande: AESA. Disponível em: <http://www.aesa.pb.gov.br/aesa-website/meteorologia-chuvas/?formdate=2019-08-30&produto=municipio&periodo=anual>. Acesso em: 1 ago. 2022.
- AKERMAN, A. **Feasibility of nitrate-shunt (nitritation) on landfill leachate**. MS Tesis. Lund University. Instituto de Tecnologia. Lund (Suécia), 2005.
- ALBUQUERQUE, J. C. (2019). Modelagem do processo de tratamento do lixiviado de um aterro sanitário usando processos oxidativos avançados, via redes neurais artificiais. Disponível em: <http://tede.bc.uepb.edu.br/jspui/handle/tede/3907>. Acesso em: 01 out. 2022.
- ALI, S. A., & AHMAD, A. (2019). Forecasting MSW generation using artificial neural network time series model: a study from metropolitan city. **SN Applied Sciences**, 1(11), 1-16.
- ALIDOUST, P., KERAMATI, M., HAMIDIAN, P., AMLASHI, A. T., GHAREHVERAN, M. M., & BEHNOOD, A. (2021). Prediction of the shear modulus of municipal solid waste (MSW): An application of machine learning techniques. **Journal of Cleaner Production**, 303, 127053.
- ALMEIDA, A. C. S., REZENDE, T. M., & ALMEIDA, S. G. M. (2022) **Ampliação da base MINDS-Libras: um estudo de aplicação de técnicas de aumento sintético de dados e da inclusão de novos conjuntos de vídeos disponíveis na literatura**. Disponível em:

https://www.researchgate.net/profile/Tamires-Rezende/publication/368894775_Ampliacao_da_base_MINDS-Libras_um_estudo_de_aplicacao_de_tecnicas_de_aumento_sintetico_dedados_e_da_inclusao_de_novos_conjuntos_de_videos_disponiveis_na_literatura/links/63ff95ef0cf1030a56611468/Ampliacao-da-base-MINDS-Libras-um-estudo-de-aplicacao-de-tecnicas-de-aumento-sintetico-dedados-e-da-inclusao-de-novos-conjuntos-de-videos-disponiveis-na-literatura.pdf. Acesso em: 24 de agosto de 2023.

AMERICAN PUBLIC HEALTH ASSOCIATION. APHA: **Standard Methods for Examination of Water and Wastewater**. 22 ed. APHA, AWWA and WEF. 2017.

ANGELINE, A.A.; ASIRVATHAM, L.G.; HEMANTH, D.J.; JAYAKUMAR, J.; WONGWISES, S. Performance prediction of hybrid thermoelectric generator with high accuracy using artificial neural networks Sustain. **Energy Technol. Assess.**, 33 (2019), pp. 53-60,

ARABAMERI, M.; JAVID, A.; ROUDBARI, A. Artificial neural network (ANN) modeling of cod reduction from landfill leachate by the ultrasonic process. **Environment Protection Engineering**, v. 43, n. 1, 2017.

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

ARAÚJO NETO, Cláudio Luis. **Modelagem da resistência ao cisalhamento de resíduos sólidos urbanos para análises da estabilidade de taludes de aterros sanitários**. 2021. 296 f. Tese (Doutorado em Engenharia Civil e Ambiental) – Universidade Federal de Campina Grande, Campina Grande, 2021.

ARAÚJO NETO, C. L., GURJÃO, R. Í. L., FARIAS, A. P., DE MELO, M. C., & MONTEIRO, V. E. D. (2021). Physical, chemical, and mechanical properties of landfilled waste from Campina Grande, Brazil. **Environmental Science and Pollution Research**, 1-11.

ARTERO, A.O. Inteligência Artificial Teórica e Prática. São Paulo: Livraria da Física, 2009.

ASL, SeyedMostafa Hosseini et al. Artificial neural network (ANN) approach for modeling of Cr (VI) adsorption from aqueous solution by zeolite prepared from raw fly ash (ZFA). **Journal of Industrial and Engineering Chemistry**, v. 19, n. 3, p. 1044-1055, 2013.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). **ABNT NBR 10005: Resíduos Sólidos – procedimento para obtenção de extrato de lixiviado de resíduos sólidos**, Rio de Janeiro, pp. 16, 2004.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). **ABNT NBR 10006: Resíduos Sólidos – procedimento para obtenção de extrato solubilizado de resíduos sólidos**, Rio de Janeiro, pp. 7, 2004.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). **ABNT NBR 10007: Amostragem de Resíduos**. Rio de Janeiro: ABNT, 2004.

- AZADI, S., AMIRI, H., & RAKHSHANDEHROO, G. R. (2016). Evaluating the ability of artificial neural network and PCA-M5P models in predicting leachate COD load in landfills. **Waste management**, 55, 220-230.
- AZIZ, S. Q., AZIZ, H. A., YUSOFF, M. S., BASHIR, M. J., & UMAR, M. (2010). Leachate characterization in semi-aerobic and anaerobic sanitary landfills: a comparative study. **Journal of Environmental Management**, 91, 2608–2614.
- BADERNA, D.; CALONI, F.; BENFENATI, E. Investigando a toxicidade do lixiviado de aterro sanitário in vitro: Uma revisão dos modelos de células e parâmetros finais. **Environment International**, v. 122, p. 21-30, 2019.
- BAPTISTA, F. D., RODRIGUES, S., & MORGADO-DIAS, F. (2013, setembro). Comparação de desempenho de algoritmos de treinamento de RNA para classificação. Em 2013 IEEE 8th **International Symposium on Intelligent Signal Processing** (pp. 115-120). IEEE.
- BARR, S.; GUILBERT, S.; METCALFE, A.; RILEY, M.; ROBINSON, G. M.; TUDOR, T. L. Beyond recycling: an integrated approach for understanding municipal waste management. **Applied Geography**, v. 39, p. 67-77, 2013.
- BAUN, A., REITZEL, LA, LEDIN, A., CHRISTENSEN, TH, & BJERG, PL. Atenuação natural de compostos orgânicos xenobióticos em uma pluma de lixiviado de aterro (Vejen, Dinamarca). **Journal of Contaminant Hydrology**, v. 65, n. 3-4, pág. 269-291, 2003.
- BAYRAM, S. C. Y. **Remoção de Matéria Orgânica e Nitrogênio de Lixiviados de aterro sanitário. Tratamento por Nitrificação/Desnitrificação biológica e processos físico-químicos**. Doutorado: Programa de Pós-Graduação em Engenharia Hidráulica e Sanitária. Universidade de São Paulo, São Paulo, 2012.
- BEZERRA, Daniel Epifânio. **Redes Neurais Artificiais para determinação da composição de resíduos sólidos urbanos**. 2020. 62f. Trabalho de Conclusão de Curso (Graduação em Engenharia Sanitária e Ambiental) - Universidade Estadual da Paraíba, Campina Grande, 2020.
- BHATT, A. H., KARANJEKAR, R. V., ALTOUQI, S., SATTLER, M. L., HOSSAIN, M. S., & CHEN, V. P. (2017). Estimating landfill leachate BOD and COD based on rainfall, ambient temperature, and waste composition: Exploration of a MARS statistical approach. **Environmental Technology & Innovation**, v. 8, p. 1-16, 2017.
- BIDONE, F. R. A.; POVINELLI, J. **Conceitos básicos de resíduos sólidos**. 1. ed. São Carlos: EESC/USP, 1999. 109p.
- BIGLARIJOO, N., MIRBAGHERI, S. A., BAGHERI, M., & EHTESHAMI, M. (2017). Assessment of effective parameters in landfill leachate treatment and optimization of the process using neural network, genetic algorithm and response surface methodology. **Process safety and environmental protection**, 106, 89-103.
- BORGES, B. L. M., **Simplificando a estatística: coletânea de textos e exercícios didáticos**. Campina Grande: EDUEP, 2003.
- BASSANEZI, R. C. **Ensino-aprendizagem com modelagem matemática: uma nova estratégia**. São Paulo: Contexto, 2006. 3.ed. 389 p.

BASTIANI, Fernanda. **Avaliação da influência de elementos meteorológicos na vazão do lixiviado gerado no aterro sanitário do município de Lajeado/RS**. 2012. Trabalho de Conclusão de Curso

BRAGA, Fabiano de Vargas Arigony. **Estimativa dos parâmetros da resistência do solo ao cisalhamento através de Pedotransferência**. 2014. Tese (Doutorado em Engenharia Agrícola) - Universidade Federal de Santa Maria. Santa Maria. 2014

BRÁS, I.; FERREIRA, B. S.; FERREIRA SILVA, M. E. Avaliação do efeito da recirculação de lixiviados num aterro sanitário. **Millenium**, n. Edição especial 2, p. 107-117, 2017.

CANZIANI R, COSSU R (2012) 4.1 Landfill hydrology and leachate production. In: Sanitary landfilling: process, technology and environmental impact, p 185

CARLEY, B. N.; MAVINIC, D. S. The effects of external carbon loading on nitrification and denitrification of a high-ammonia landfill leachate. **Research Journal of the Water Pollution Control Federation**, p. 51-59, 1991.

CASTILHOS JR, A. B., MEDEIROS, P. A., FIRTA, I. N., LUPATINI, G., & SILVA, J. D.. Principais processos de degradação de resíduos sólidos urbanos. **Alternativas de Disposição de Resíduos Sólidos Urbanos para Pequenas Comunidades**. Rio de Janeiro: ABES, Rima, p. 19-50, 2003.

CAVALCANTI, A. S., IZÁRIO FILHO, H. J., GUIMARÃES, O. L. C., & SIQUEIRA, A. F. (2015). Modelagem neural e análise estatística do processo de degradação de chorume por foto-Fenton solar. **Revista Ambiente & Água**, 10, 89-106.

CHRISTENSEN T. H., COSSU R, STEGMANN R (eds) (2005) Landfilling of waste: leachate. CRC Press

CHRISTENSEN, T. H., KJELDSSEN, P., BJERG, P. L., JENSEN, D. L., CHRISTENSEN, J. B., BAUN, A., ALBRECHTSEN, H. J., & HERON, G. (2001). Biogeochemistry of landfill leachate plumes. **Applied Geochemistry**, 16, 659–718..

CHO, S. P., HONG, S. C., & HONG, S. I. (2002). Photocatalytic degradation of the landfill leachate containing refractory matters and nitrogen compounds. **Applied Catalysis B: Environmental**, 39(2), 125-133.

CINTRA, F. H.; HAMADA, J.; CASTILHO FILHO, G. S. Fatores que afetam a qualidade do chorume gerado em aterro controlado de resíduos sólidos urbanos. **VI Simpósio Ítalo-Brasileiro de Engenharia Sanitária e Ambiental**, Vitória, 2002.

CLEMENT, B., PERSOONE, G., JANSSEN, C., & DÛ-DELEPIERRE, L. Estimation of the hazard of landfills through toxicity testing of leachates, 1: determination of leachate toxicity with a battery of acute tests. **Chemosphere**, v. 33, n. 11, p. 2303-2320, 1996.

CORREA, S. M. B. B. **Probabilidade e estatística**. 2. ed. Belo Horizonte: PUC-Minas Virtual, 2003.

COSTA, A. M.; ALFAIA, R. G. DE S. M.; CAMPOS, J. C. Landfill leachate treatment in Brazil – An overview, **Journal of Environmental Management**, v. 232, p. 110-116, 2019. Acesso em 07 Ago 2019.

CUNHA, J. E. B. L.; RUFINO, I. A. A.; IDEIÃO, S. M. A. Determinação da temperatura de superfície na cidade de Campina Grande-PB a partir de imagens do satélite Landsat 5-TM. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14., 2009, Natal. Anais [...]. Rio Grande do Norte: INPE,2009.

CUNHA, Joyce Adriane Ribeiro da. **Coagulação/floculação e adsorção de lixiviado de aterro sanitário na remoção de matéria orgânica e avaliação da toxicidade**. 2021. 41f. Trabalho de Conclusão de Curso (Graduação em Engenharia Agrícola e Ambiental) – Universidade Federal de Mato Grosso, Instituto de Ciências Agrárias e Ambientais, Sinop, 2021

DANKAR, F.K.; IBRAHIM, M. **Fake It Till You Make It: Guidelines for Effective Synthetic** Data Generation. Appl. Sci. 2021, 11, 2158. <https://doi.org/10.3390/app11052158>

DANKAR, Fida K.; IBRAHIM, Mahmoud K.; ISMAIL, Leila. s. IEEE Access, v. 10, p. 11147-11158, 2022.

DA SILVA, A. K. M.; MOTA, F. S. B. **Caracterização dos Resíduos Sólidos Urbanos: Aproveitamento do Biogás**. Editora Appris, 2019.

DECOTTIGNIES, V. et al. Comparison of analytical methods to determine the stability of municipal solid waste and related wastes. Memórias. Sardinia 2005. In: **INTERNATIONAL WASTE MANAGEMENT AND LANDFILL SYMPOSIUM**, 10, 2005. Cagliari. Anais. Cagliari, 3-7, 2005.

DEMETRACOPOULOS, A. C., SEHAYEK, L., & ERDOGAN, H. (1986). Modeling leachate production from municipal landfills. **Journal of Environmental Engineering**, 112(5), 849-866.

DESTRO, G. E. Caracterização e proposição de tratamento adequado a lixiviados produzidos em aterros sanitários de resíduos sólidos urbanos. 2020.

DEVORE, J. L. Probabilidade e estatística: para engenharia e ciências. 9. ed. São Paulo: **Cengage Learning**, 2018.

DI IACONI, C., RAMADORI, R., & LOPEZ, A. (2006). Combined biological and chemical degradation for treating a mature municipal landfill leachate. **Biochemical Engineering Journal**, 31(2), 118-124.

DIL, E. A.; GHAEDI, M.; ASFARAM, A.; MEHRABI, F.; BAZRAFSHAN, A.A.; GHAEDI, A.M. Trace determination of safranin O dye using ultrasound assisted dispersive solid-phase micro extraction: artificial neural network-genetic algorithm and response surface methodology Ultrason. **Sonochem.**, 33 (2016), pp. 129-140,

D'OLIVEIRA, P.M.S. **Potencial poluidor da disposição final de resíduos sólidos nas águas da Bacia Hidrográfica da Baía de Guanabara** 100 f. Dissertação (Mestrado em Engenharia Ambiental) – Departamento de Engenharia Sanitária e do Meio Ambiente, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2020.

DOMINGOS, Janaina de Melo Franco. **Tratamento de lixiviado de aterro sanitário utilizando coagulação/floculação, cavitação associada a ozonização e polimento com carvão ativado**. 2022.

DGGT, Deutsche Gesellschaft für Geotechnik. Geotechnik der Deponien und Altlasten. GDA-Empfehlungen, 3 Auflage, Ernst & Sohn, Berlin, 1994.

DUBEY, Shiv Ram; SINGH, Satish Kumar; CHAUDHURI, Bidyut Baran. Activation functions in deep learning: A comprehensive survey and benchmark. **Neurocomputing**, 2022.

ELBANA, T. A. et al. Freundlich sorption parameters for cadmium, copper, nickel, lead, and zinc for different soils: Influence of kinetics. *Geoderma*, v. 324, p. 80-88, 2018.

EL-FADEL, M., FINDIKAKIS, A. N., & LECKIE, J. O. (1997). Modeling leachate generation and transport in solid waste landfills. **Environmental technology**, 18(7), 669-686.

EL-FADEL, M., BOU-ZEID, E., CHAHINE, W., & ALAYLI, B. J. W. M. (2002). Temporal variation of leachate quality from pre-sorted and baled municipal solid waste with high organic and moisture content. **Waste management**, 22(3), 269-282.

ELK, A. G. H. P. V., D'OLIVEIRA, P. M. S., GIORDANO, G., & ANDRADE, R. C. D. (2022). Potencial poluidor da disposição final de resíduos sólidos nas águas da bacia hidrográfica da Baía de Guanabara–RJ. **Engenharia Sanitária e Ambiental**, 27, 195-203.

FARIAS, A. P., MALVEZZI, L. B., JUNIOR, F. A. F. M., DE SOUZA ABREU, J. L., & DA SILVA RIBEIRO, L. **Avaliação do pH, alcalinidade total e ácidos graxos voláteis no lixiviado bruto de um aterro sanitário localizado no semiárido brasileiro**. XIX Simpósio Luso-Brasileiro de Engenharia Sanitária e Ambiental – SILUBESA (2020)

FENG, S. J., BAI, Z. B., ZHENG, Q. T., LU, S. F., & ZHANG, X. L. (2020). A finite-volume numerical model for temporal and spatial variability of methane oxidation in landfill covers. **Computers and Geotechnics**, 122, 103510.

FERREIRA, J. A.; GIORDANO, G.; RITTER, E.; ROSSO, T. C. A.; CAMPOS, J. C.; LIMA, P. Z. M. **Uma revisão das técnicas de tratamento de chorume e a realidade do estado do Rio de Janeiro**. In: CONGRESSO BRASILEIRO DE ENGENHARIA SANITÁRIA E AMBIENTAL, 21., 2001, João Pessoa. Anais [...] Rio de Janeiro: ABES, 2001.

FINCHER, J. **"Python IDEs and Code Editors (Guide) Real Python**. [Online]. Disponível em: <https://realpython.com/python-ides-code-editors-guide/>. Acesso: 28-Aug-2023.

FOLLMANN, H. V. D. M., SCHIRMER, W. N., CABRAL, A. R., CROVADOR, M. I. C., DOURADO, D. C., & STROPARO, E. C. (2017). Avaliação de parâmetros físico-químicos na degradação de Resíduos Sólidos Urbanos (RSU) de diferentes idades e sua relação com a geração de biogás. **Espacios**, 38(39), 1-9.

GAU, S. H., & CHOW, J. D. (1998). Landfill leachate characteristics and modeling of municipal solid wastes combined with incinerated residuals. **Journal of hazardous materials**, 58(1-3), 249-259.

GADEKAR, M.R.; AHAMMED, M.M. Modelling dye removal by adsorption onto water treatment residuals using combined response surface methodology-artificial neural network approach J. **Environ. Manag.**, 231 (2019), pp. 241-248, 10.1016/j.jenvman.2018.10.017

GHAEDI, A. M.; VAFAEI, A. Applications of artificial neural networks for adsorption removal of dyes from aqueous solution: a review. **Advances in colloid and interface science**, v. 245, p. 20-39, 2017.

GHIASINEJAD, H.; GHASEMI, M.; SHARIATMADARI, N.; PAZOKI, M. **Prediction of landfill leachate quantity in arid and semiarid climate: a case study of Aradkouh, Tehran.** International Journal of Environmental Science and Technology, v. 18, n. 3, p. 589-600, 2021.

GÖNÜLLÜ, M. Talha. Analytical modelling of organic contaminants in leachate. **Waste management & research**, v. 12, n. 2, p. 141-150, 1994.

GROSAN, Crina; ABRAHAM, Ajith. Intelligent systems. Berlin: **Springer**, 2011

GRUGNALETTI, M., PANTINI, S., VERGINELLI, I., & LOMBARDI, F. (2016). An easy-to-use tool for the evaluation of leachate production at landfill sites. **Waste management**, 55, 204-219.

GUEDES, T. A.; ACORSI, C. R. L.; MARTINS, A. B. T.; JANEIRO, V. Estatística Descritiva. Disponível em: <www.des.uem.br>. Acesso em Novembro de 2020.

GUEDES, M. J. F., RIBERO, L. S., MOREIRA, F. G. S., GOMES, N. A., CARIBÉ, R. M., AIRES, K. D., MELO, M. C., MONTEIRO, V. E. D. (2022) Análise qualitativa do biogás e lixiviado em aterro sanitário brasileiro. **Revista DAE**, v. 70, n 235, 127-141.

HAYKIN, S., Neural Networks: a comprehensive foundation. New York: **MacMillan College Publishing Co.**, 1999.

HAYKIN, S. Redes Neurais: Princípios e prática. 2.ed. **Porto Alegre: Bookman**, 900p, 2001.

HAMADA, Jorge. Estimativas de geração e caracterização do chorume em aterros sanitários. In: **Anais do XIX Congresso Brasileiro de Engenharia Sanitária e Ambiental. Foz do Iguaçu.** 1997.

HENRIQUES, J. A. **Proposição de modelo de predição de desempenho de estações convencionais de tratamento de água utilizando redes neurais artificiais.** 2019. Tese (Doutorado em Saneamento, Meio Ambiente e Recursos Hídricos) – Universidade Federal de Minas Gerais, Belo Horizonte, 2019.

HUSSEIN, O. A.; IBRAHIM, J. A. Leachates Recirculation Impact on the Stabilization of the Solid Wastes-A Review. **Journal of Ecological Engineering**, v. 24, n. 4, 2023.

IM, J. H., WOO, H. J., CHOI, M. W., HAN, K. B., & KIM, C. W. (2001). Simultaneous organic and nitrogen removal from municipal landfill leachate using an anaerobic-aerobic system. **Water research**, 35(10), 2403-2410.

INSTITUTO ESTADUAL DO AMBIENTE (INEA). Estudo da Caracterização Gravimétrica de Resíduos Sólidos Urbanos: Conhecendo a composição dos resíduos para aplicação na gestão municipal. Disponível em: <http://www.inea.rj.gov.br/wp-content/uploads/2021/01/Cartilha-Estudo-da-Characteriza%C3%A7%C3%A3o-Gravim%C3%A9trica-de-Res%C3%ADduos-S%C3%B3lidos-Urbanos-2.pdf>. Acessado em: 30 de outubro de 2021.

INSTITUTO NACIONAL DE METEOROLOGIA. INMET: Meteorologia básica. Brasília, DF: INMET. Disponível em: http://www.inmet.gov.br/portal/index.php?r=home/page&page=meteorologia_basica. Acesso em: 12 ago. 2022.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. IBGE: Contagem populacional. Brasília, DF: IBGE. Disponível em: <https://cidades.ibge.gov.br/brasil/pb/campina-grande/panorama>. Acesso em: 1 ago. 2021.

ISHAK, Ahmad Razali *et al.* Leachate and surface water characterization and heavy metal health risk on cockles in Kuala Selangor. **Procedia-Social and Behavioral Sciences**, v. 222, p. 263-271, 2016.

ISHII, K., SATO, M., & OCHIAI, S. (2022). Prediction of leachate quantity and quality from a landfill site by the long short-term memory model. **Journal of Environmental Management**, 310, 114733.

JOKELA, J. P. Y., KETTUNEN, R. H., SORMUNEN, K. M., & RINTALA, J. A. (2002). Biological nitrogen removal from municipal landfill leachate: low-cost nitrification in biofilters and laboratory scale in-situ denitrification. **Water Research**, 36(16), 4079-4087.

KACZOREK, K.; LEDAKOWICZ, S. Deamonifikacja odcieków z wysypiska na złożu torfowym. **Inżynieria i aparatura chemiczna**, v. 3, p. 65-66, 2002.

KALOGIROU, S. A. (2003). Artificial intelligence for the modeling and control of combustion processes: a review. **Progress in energy and combustion science**, 29(6), 515-566.

KAMARUDDIN, MA, YUSOFF, MS, AZIZ, HA, & HUNG, YT Tratamento sustentável de lixiviado de aterro. **Applied Water Science**, v. 5, n. 2, pág. 113-126, 2015.

KANDIRI, A., GOLAFSHANI, E. M., & BEHNOOD, A. 2020. Estimation of the compressive strength of concretes containing ground granulated blast furnace slag using hybridized multiobjective ANN and salp swarm algorithm. **Construct. Build. Mater.** 248, 118676.

KARACA F, ÖZKAYA B (2006) NN-LEAP: a neural network-based model for controlling leachate flow-rate in a municipal solid waste landfill site. **Environ Model Softw** 21(8):1190–1197

KARADAG, D., TOK, S., AKGUL, E., TURAN, M., OZTURK, M., & DEMIR, A, DOGAN Ammonium removal from sanitary landfill leachate using natural Gördes clinoptilolite. **Journal of hazardous materials**, v. 153, n. 1-2, p. 60-66, 2008.

KARRI, R.R.; TANZIFI, M.; TAVAKKOLI YARAKI, M.; SAHU, J.N.; Optimization and modeling of methyl orange adsorption onto polyaniline nano-adsorbent through response surface methodology and differential evolution embedded neural network **J. Environ. Manag.**, 223 (2018), pp. 517-529,

KASHITARASH, Z. E., TAGHI, S. M., KAZEM, N., ABBASS, A., & ALIREZA, R. (2012). Application of iron nanoparticles in landfill leachate treatment-case study: Hamadan landfill leachate. **Iranian Journal of Environmental Health Science & Engineering**, 9(1), 1-5.

KENNEDY, K. J.; LENTZ, E. M. Treatment of landfill leachate using sequencing batch and continuous flow upflow anaerobic sludge blanket (UASB) reactors. **Water Research**, v. 34, n. 14, p. 3640-3656, 2000.

KIPLI, Kuryati et al. Performance of Levenberg-Marquardt backpropagation for full reference hybrid image quality metrics. In: **Proceedings of International Conference of MultiConference of Engineers and Computer Scientists (IMECS'12)**. 2012. p. 704-707.

KIRANŞAN, M.; KHATAEE, A.; KARACA, S.; SHEYDAEI, M. Artificial neural network modeling of photocatalytic removal of a disperse dye using synthesized ZnO nanoparticles on montmorillonite Spectroc. Acta Pt. A-Molec. **BioMolec. Spectr.**, 140 (2015), pp. 465-473, 10.1016/j.saa.2014.12.100

KJELDSEN, P., BARLAZ, M. A., ROOKER, A. P., BAUN, A., LEDIN, A., & CHRISTENSEN, T. H. Present and long-term composition of MSW landfill leachate: a review. **Critical reviews in environmental science and technology**, v. 32, n. 4, p. 297-336, 2002.

KJELDSEN, Peter; CHRISTOPHERSEN, Mette. Composition of leachate from old landfills in Denmark. **Waste Management & Research**, v. 19, n. 3, p. 249-256, 2001.

KÖPPEN, W.; GEIGER, R. *Klimate der Erde*. Gotha: Verlag Justus Perthes. 1928. Wallmap 150 cm x 200 cm.

KORTEGAST AP, ELEDRIDGE SF, RICHARDS BA, YONG S, CHOCK ET, BRYCE A, ROBINSON H, CARVILLE M (2007) Leachate generation and treatment at the Bukit Tagar Landfill, Malaysia. In: Presented at Sardinia 2007, **11th international waste management and landfill symposium, Sardinia, Italy**.

KOUZELI-KATSIRI, A.; BOSDOGIANNI, A.; CHRISTOULAS, D. Prediction of leachate quality from sanitary landfills. **Journal of environmental engineering**, v. 125, n. 10, p. 950-958, 1999.

KULIKOWSKA, D., & KLIMIUK, E. (2008). The effect of landfill age on municipal leachate composition. **Bioresource Technology**, 99, 5981–5985.

KURNIAWAN, T. A., CHAN, G. Y., LO, W. H., & BABEL, S. Physico-chemical treatment techniques for wastewater laden with heavy metals. **Chemical engineering journal**, v. 118, n. 1-2, p. 83-98, 2006.

LI, X. Z.; ZHAO, Q. L. Efficiency of biological treatment affected by high strength of ammonium-nitrogen in leachate and chemical precipitation of ammonium-nitrogen as pretreatment. **Chemosphere**, v. 44, n. 1, p. 37-43, 2001.

LIANG, Qingqing et al. Comparative study of probabilistic neural network and back propagation network for fault diagnosis of refrigeration systems. **Science and Technology for the Built Environment**, v. 24, n. 4, p. 448-457, 2018.

LIU B, ZHANG N, WANG L, ZHANG X. Electricity Generation Forecast of Shanghai Municipal Solid Waste Based on Bidirectional Long Short-Term Memory Model. **International Journal of Environmental Research and Public Health**. 2022; 19(11):6616. <https://doi.org/10.3390/ijerph19116616>

LO, I. M. Characteristics and Treatment of Leachates From Domestic Landfills. *Environment International*. v. 22 n. 4, p. 433 – 442, 1996.

LOPEZ, A., PAGANO, M., VOLPE, A., & DI PINTO, A. C. (2004). Fenton's pre-treatment of mature landfill leachate. *Chemosphere*, 54(7), 1005-1010.

MARTTINEN, Sanna K.; KETTUNEN, Riitta H.; RINTALA, Jukka A. Occurrence and removal of organic pollutants in sewages and landfill leachates. *Science of the total environment*, v. 301, n. 1-3, p. 1-12, 2003.

MATHWORKS. Matlab R2020a. Produtos. Disponível em: <https://www.mathworks.com/products/matlab.html>. Acessado em: 13/04/2023.

MCBEAN, E. A.; ROVERS, F. A., FARQUHAR, G. J. Solid Waste Landfill – Engineering and Design. Prentice Hall, Inc. p. 521, 1995

MEDIUM , 2021. Disponível em: A importância da normalização e padronização dos dados em Machine Learning | by IPNET Growth Partner | Parceiro de crescimento IPNET | Medium. Acessado em: 25 de junho de 2023

MESQUITA, F. O. et al. Translocation factor of heavy metals by elephant grass grown with varying concentrations of landfill leachate. *Environmental Science and Pollution Research*, v. 28, n. 32, p. 43831-43841, 2021..

MIAO, L., YANG, G., TAO, T., & PENG, Y. (2019). Recent advances in nitrogen removal from landfill leachate using biological treatments—A review. *Journal of environmental management*, 235, 178-185.

MICHALSKA, J., PIŃSKI, A., ŻUR, J., & MROZIK, A. (2020). Seleção de bactérias candidatas à bioaugmentação de lodo ativado para melhorar o tratamento aeróbio de lixiviado de aterro. *Água*, 12 (1), 140.

MIRANDA, F. A.; FREITAS, S. R. C.; FAGGION, P. L. Integração e interpolação de dados de anomalias ar livre utilizando-se a técnica de RNA e krigagem. *Boletim de Ciências Geodésicas*, v.15, n.3, p. 428-443. 2009.

MCCULLOCH, W.S.; PITTS, W.A. logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, v.5, p.115-133, 1943

MCBEAN, E. A.; ROVERS, F. A.; FARQUIHAR, G. J. Solid waste landfill engineering and design. Nova Jérsei (EUA): **Prentice Hall**, 1995.

MITRANO, Denise M. *et al.* Mobility of metallic (nano) particles in leachates from landfills containing waste incineration residues. *Environmental Science: Nano*, v. 4, n. 2, p. 480-492, 2017.

MOODY, C. M., TOWNSEND, T. G. A comparison of landfill leachates based on waste composition. *Waste Management*, v. 63, p-267-274, 2017.

MORATELLI, L. Estudo da evaporação como tecnologia aplicada ao pré-tratamento de lixiviados de aterros sanitários. 270 f. Dissertação (Mestrado em Engenharia Ambiental) – Universidade Federal de Santa Catarina, Florianópolis, 2013.

MUELLER, N. C.; NOWACK, B. Exposure modeling of engineered nanoparticles in the environment. **Environmental science & technology**, v. 42, n. 12, p. 4447-4453, 2008.

NASCIMENTO, S. C., DA SILVA, E. M., GOMES, N. A., RIBEIRO, L. D. S. D. S., MELO, M. C. D., & MONTEIRO, V. E. D. (2022). Variação sazonal de indicadores físico-químicos e fitotoxicológicos em lixiviado de aterro sanitário localizado no semiárido brasileiro. **Engenharia Sanitaria e Ambiental**, 27, 1097-1104.

NASH, J. E.; SUTCLIFFE, J. V. River flow forecasting through conceptual models, part I - A discussion of principles. **Journal of Hydrology**, [s. l.]. v. 10, n.3, p. 282-290, 1970.

NATH, A.; DEBNATH, A. A short review on landfill leachate treatment technologies. **Materials Today: Proceedings**, 2022.

NAVEEN, B.P.; MAHAPATRA, D. M.; SITHARAM, T.G.; SIVAPULLAIAH, P.V.; RAMACHANDRA, T.V. Physico-chemical and biological characterization of urban municipal landfill leachate. *Environmental Pollution*. v. 220, p. 1-12, 1 jan. 2017.

NAZRIEZA, N., SITI ROHANA, M. Y., SUBRAMANIAM, K., & HAZILIA, H. (2015). Characterization of leachate from panchang bedena landfill, Batang Padang Landfill and Matang Landfill: a comparative study. **Malaysian Journal of Science**, 34, 69–77.

OLATUNJI, O., AKINLABI, S., MADUSHELE, N., ADEDEJI, P.A., FELIX, I., 2019. Multilayer perceptron artificial neural network for the prediction of heating value of municipal solid waste. **AIMS Energy** 7, 944–956.

OZKAYA, B.; DEMIR, A.; BILGILI, M. S. Mathematical simulation and long-term monitoring of leachate components from two different landfill cells. **Journal of hazardous materials**, v. 135, n. 1-3, p. 32-39, 2006.

PAMUNGKAS, A. et al. Application of artificial neural networks to forecast *Litopenaeus vannamei* and *Penaeus monodon* harvests in Indramayu regency, Indonesia. In: **IOP Conference Series: Earth and Environmental Science**. IOP Publishing, 2020. p. 012018.

PATKI, N.; WEDGE, R.; VEERAMACHANENI, K. **The synthetic data vault**. In: **2016 IEEE International Conference on Data Science and Advanced Analytics (DSAA)**. IEEE, 2016. p. 399-410.

PAULETTO, Paola de Souza et al. Modelos computacionais avançados aplicados na adsorção multicomponente de fármacos. 2022. **Tese de Doutorado**. Universidade Federal de Santa Maria.

PAZOKI, Maryam; GHASEMZADEH, Reza. Leachate Quality. In: **Municipal Landfill Leachate Management**. Springer, Cham, 2020. p. 101-127.

QASIM, S. R.; CHIANG, W. **Sanitary landfill leachate: generation, control and treatment**. Routledge, 2017.

RANI, A.; NEGI, S.; HUSSAIN, A.; & KUMAR, S. (2020). Tratamento de lixiviado de aterro municipal urbano utilizando enzima de lixo. **Bioresource technology** , 297 , 122437.

REDDY, K. R.; HETTIARACHCHI, H.; GIRI, R. K.; GANGATHULASI, J. Effects of Degradation on Geotechnical Properties of Municipal Solid Waste from Orchard Hills Landfill, USA. **International Journal of Geosynthetics and Ground Engineering**, [s. l.], v. 1, n.3, p.1-14, 15 jul. 2015.

REINHART, D. R.; AL-YOUSFI, A. B. The impact of leachate recirculation on municipal solid waste landfill operating characteristics. **Waste Management and Research**, Thousand Oaks, Eua, v. 14, p. 337-346, 1996.

RENOU, S., GIVAUDAN, J. G., POULAIN, S., DIRASSOUYAN, F., & MOULIN, P. Landfill leachate treatment: Review and opportunity. **Journal of hazardous materials**, v. 150, n. 3, p. 468-493, 2008.

RENOU, S., POULAIN, S., GIVAUDAN, J. G., & MOULIN, P. Treatment process adapted to stabilized leachates: Lime precipitation–prefiltration–reverse osmosis. **Journal of Membrane Science**, v. 313, n. 1-2, p. 9-22, 2008.

REZA, A.; CHEN, L.; KRUGER, K. Microwave irradiated ammonia nitrogen removal from anaerobically digested liquid dairy manure: A response surface methodology and artificial neural network-based optimization and modeling. **Journal of Environmental Chemical Engineering**, v. 10, n. 5, p. 108279, 2022.

RIBEIRO, L. S. **Estudo da Degradação dos Resíduos Sólidos Urbanos através dos Parâmetros Físicos e Físico-Químicos em um Biorreator de Escala Experimental**. 2012. 136 f. Dissertação (Mestrado em Engenharia Civil e Ambiental) – Universidade Federal de Campina Grande, Campina Grande, 2012.

RIBEIRO, L. S. et al. Monitoramento físico-químico de um biorreator com resíduos sólidos urbanos em escala piloto na cidade de Campina Grande (PB). **Engenharia Sanitária e Ambiental (Online)**, v. 21, n. 1, p. 1-9, 2016.

RIBEIRO, L. S., GOMES, N. A., ALMEIDA, M. V. A., & DE PAIVA, W. (2021). Análise da relação de indicadores físico-químicos do lixiviado gerado em um aterro sanitário no Semiárido Brasileiro. **Agropecuária científica no semiárido**, 17(1), 36-42.

RIVAS, F. J., BELTRÁN, F., GIMENO, O., ACEDO, B., & CARVALHO, F. (2003). Stabilized leachates: ozone-activated carbon treatment and kinetics. **Water research**, 37(20), 4823-4834.

SABOUR, M. R., & AMIRI, A. (2017). Comparative study of ANN and RSM for simultaneous optimization of multiple targets in Fenton treatment of landfill leachate. **Waste management**, 65, 54-62.

SANTOS, A. M.; SEIXAS, J. M. D.; PEREIRA, B. D. B.; MEDRONHO, R. D. A. Usando Redes Neurais Artificiais e Regressão Logística na predição da Hepatite A. *Revista Brasileira de Epidemiologia*, v. 8, n. 2, 117-126, 2005.

SÃO MATEUS, M. D. S. C., MACHADO, S. L., & BARBOSA, M. C. (2012). An attempt to perform water balance in a Brazilian municipal solid waste landfill. **Waste Management**, 32(3), 471-481.

SEGATO, L. M.; SILVA, C. L. Caracterização do Lixiviado do Aterro Sanitário de Bauru. In: **Congresso Interamericano de Engenharia Sanitária e Ambiental**. 2000.

SEKHOHOLA-DLAMINI, L.; TEKERE, M. Microbiology of municipal solid waste landfills: A review of microbial dynamics and ecological influences in waste bioprocessing. **Biodegradation**, v. 31, n. 1, p. 1-21, 2020.

SDV, 2023. Disponível em: <https://sdv.dev/SDV/index.html>. Acessado em: 24 de junho de 2023

SHOW, P.L., PAL, P., LEONG, H.Y. et al. A review on the advanced leachate treatment technologies and their performance comparison: an opportunity to keep the environment safe. **Environ Monit Assess** 191, 227 (2019). <https://doi.org/10.1007/s10661-019-7380-9>

SHCHERBAKOV, M. V. *et al.* A survey of forecast error measures. **World applied sciences journal**, v. 24, n. 24, p. 171-176, 2013.

SILVA, AC; DEZOTTI, M.; SANT'ANNA JR, GL Tratamento e desintoxicação de um lixiviado de aterro sanitário. **Chemosphere** , v. 55, n. 2, pág. 207-214, 2004.

SILVA, VDF (2006). Volatilidade estatística determinística: uma avaliação para o retorno da ação" Vale do Rio Doce".

SILVA, I. N., SPATTI, D. H., & FLAUZINO, R. A. Redes neurais artificiais para engenharia e ciências aplicadas-curso prático. **São Paulo: Artliber**. (2010).

SILVA, A. S.; RIBEIRO, L. S.; PAIVA, W.; MELO, M. C.; MONTEIRO, V. E. D. Avaliação do potencial tóxico dos resíduos sólidos urbanos da cidade de Campina Grande-PB. **Revista Matéria**, Rio de Janeiro, v. 20, n. 4, 2015, p. 840-851.

SILVA, F. G. L. **Situação atual do tratamento de lixiviados de aterros sanitários do Estado do Rio de Janeiro com ênfase nos aterros de Seropédica e Sapucaia**. 2023. 95 f. Dissertação (Mestrado em Engenharia Ambiental) - Faculdade de Engenharia, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2023.

SIVAKUMAR D (2013) Experimental and analytical model studies on leachate volume computation from solid waste. **Int J Environ Sci Technol** 10(5):903–916.

SISINNO, C. L. S., OLIVEIRA-FILHO, E. C., DUFRAYER, M. C., MOREIRA, J. C., & PAUMGARTTEN, F. J. R. Toxicity evaluation of a municipal dump leachate using zebrafish acute tests. **Bulletin of Environmental Contamination and Toxicology**, v. 64, n. 1, p. 107-113, 2000.

SONG, Q.; WANG, Z.; LI, J. **Environmental performance of municipal solid waste strategies based on LCA method: a case study of Macau**. *Journal of Cleaner Production*. v. 57, n. 15, p. 92-100, 2013.

SOUTO, G. A. B. **Lixiviado de Aterros Sanitários Brasileiros – estudo de remoção do nitrogênio amoniacal por processo de arraste com ar (“stripping”)**. 371 p. – Tese (Doutorado) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2009.

SOUTO, G. D., & POVINELLI, J. (2007). Características do lixiviado de aterros sanitários no Brasil.

STAROVOITOV V.V., GOLUB YU.I. Data normalization in machine learning. *Informatics*. 2021;18(3):83-96. (In Russ.). Disponível em: <https://doi.org/10.37661/1816-0301-2021-18-3-83-96> . Acesso em: 13 de julho de 2023.

STATOM, R. A.; THYNE, G. D.; MCCRAY, J. E. Temporal changes in leachate chemistry of a municipal solid waste landfill cell in Florida, USA. **Environmental Geology**, v. 45, n. 7, p. 982-991, 2004.

SUDENE. Superintendência de Desenvolvimento do Nordeste. Abordagem Territorial. Disponível em: <http://antigo.sudene.gov.br/prdne/abordagemterritorial>. Acessado em junho de 2021.

SURMACZ-GÓRSKA, J.; MIKSCH, K.; KITA, T. Możliwości podczyszczania odcieków z wysypisk metodami biologicznymi. **Archiwum Ochrony Środowiska**, v. 26, n. 3, p. 43-54, 2000.

TAGHAVIFAR, H.; KHALILARYA, S.; JAFARMADAR, S. Diesel engine spray characteristics prediction with hybridized artificial neural network optimized by genetic algorithm **Energy**, 71 (2014), pp. 656-664,

TATIBANA, C. Y.; KAETSU, D. Y. Homepage de Redes Neurais. Disponível em: <http://www.din.uem.br/ia/neurais/>. Acesso em: 28 de abriu 2020. 72. 2020

TATSI, A. A., & ZOUBOULIS, A. I. (2002). A field investigation of the quantity and quality of leachate from a municipal solid waste landfill in a Mediterranean climate (Thessaloniki, Greece). **Advances in Environmental Research**, 6, 207–219.

TCHOBANOGLIOUS, G.; THEISEN, H.; VIGIL, S. Integrated solid waste management: engineering principle sand management issues. **McGraw-Hill Science/Engineering/Math**, 1993, 978 p.

TENG, C. et al. Characterization and treatment of landfill leachate: A review. **Water Research**, 2021. v. 203, n. July, p. 117525.

THAKUR, Disha; GUPTA, Ashok Kumar; GANGULY, Rajiv. Geotechnical properties of fresh and degraded MSW in the foothill of Shivalik range Una, Himachal Pradesh. **International Journal of Recent Technology and Engineering**, [s. l.], v. 8, n. 2, p. 363 374, 2019.

THANH, N. P.; MATSUI, Y.; FUJIWARA, T. Household solid waste generation and characteristic in a Mekong Delta city, Vietna. **Journal of Environmental Management**, v. 91, n. 11, p. 2307-2321, 2010.

TOMAZONI, J. C.; MANTOVANI, L. E.; BITTENCOURT, A. V. L.; ROSA FILHO, E. F. Utilização de medidas de turbidez na quantificação da movimentação de sólidos por veiculação hídrica nas bacias dos rios Anta Gorda, Brinco, Coxilha Rica e Jirau – sudoeste do estado do Paraná. **Boletim Paranaense de Geociências**, v.57, p. 49-56, 2005.

TRABELSI, Ismail *et al.* Coupling of anoxic and aerobic biological treatment of landfill leachate. **Desalination**, v. 246, n. 1-3, p. 506-513, 2009.

TRÄNKLER, J., VISVANATHAN, C., KURUPARAN, P. & TUBTIMTHAI, O. (2005). Influence of tropical seasonal variations on landfill leachate characteristics—Results from lysimeter studies. **Waste Management**, 25(10), 1013–1020.

TRIVEDI, P.K.; ZIMMER, D.M. **Copula Modeling: An Introduction for Practitioners; Now Publishers Inc.:** Hanover, MA, USA, 2007.

UMAR, M., AZIZ, H. A., & YUSOFF, M. S. (2010). Variability of parameters involved in leachate pollution index and determination of lpi from four landfills in Malaysia. **International Journal of Chemical Engineering**, 2010, 1–6.

VAHABIAN, Mehdi; HASSANZADEH, Yousef; MAROFI, Safar. Assessment of landfill leachate in semi-arid climate and its impact on the groundwater quality case study: Hamedan, Iran. **Environmental monitoring and assessment**, v. 191, n. 2, p. 109, 2019.

VAVLIN, V. A.; RYTOV, S.V.; JOKELA, J.; RINTALA, J. A distributed model of solid waste anaerobic digestion sensitivity analysis. *Wiley Periodicals*. v.38, n. 4, p. 147-154, 2003.

VENKATARAMANI, ES, AHLERT, RC, CORBO, P., & IRVINE, RL. Tratamento biológico de lixiviados de aterro. **Revisões críticas em controle ambiental** , v. 14, n. 4, pág. 333-376, 1984.

VENKATESH REDDY, C; SHEKHAR RAO, D.; KALAMDHAD, A. S. Statistical modelling and assessment of landfill leachate emission from fresh municipal solid waste: a laboratory-scale anaerobic landfill simulation reactor study. **Waste Management & Research**, v. 38, n. 10, p. 1161-1175, 2020.

VITHANAGE, M., WIJESEKARA, H., & MAYAKADUWA, S. S. (2017). Isolation, purification and analysis of dissolved organic carbon from Gohagoda uncontrolled open dumpsite leachate, Sri Lanka. **Environmental Technology**, 38(13-14), 1610-1618.

WANG X, CAO A, ZHAO G, ZHOU C, XU R (2017) Microbial community structure and diversity in a municipal solid waste landfill. **Waste Manag** 66:79–87

WANG, D., HE, H., & LIU, D. (2018). Intelligent optimal control with critic learning for a nonlinear overhead crane system. **IEEE Transactions on Industrial Informatics**, 14(7), 2932-2940.

WANG, Y. et al. **The influence of the activation function in a convolution neural network model of facial expression recognition**. *Applied Sciences*, v. 10, n. 5, p. 1897, 2020.

WARITH, MA; SHARMA, R. Revisão técnica de métodos para potencializar a degradação biológica em aterros sanitários. **Revista de Pesquisa em Qualidade da Água** , v. 3, pág. 417-438, 1998.

WHO. **International reference center for wastes disposal: Methods of analysis of sewage sludge solid waste and compost**. Switzerland, 1978. 49p.

WISZNIOWSKI, J., ROBERT, D., SURMACZ-GORSKA, J., MIKSCH, K., & WEBER, J. V. (2006). Landfill leachate treatment methods: A review. **Environmental chemistry letters**, 4(1), 51-61.

XIE H, CHEN Y, ZHAN L, CHEN R, TANG X, CHEN R, KE H (2009) Investigation of migration of pollutant at the base of Suzhou Qizishan landfill without a liner system. **J. Zhejiang Univ. Sci. A.**, 10(3), 439–449.

XIE, S. et al. Fluctuation of dissolved heavy metal concentrations in the leachate from anaerobic digestion of municipal solid waste in commercial scale landfill bioreactors: The effect of pH and associated mechanisms. **Journal of hazardous materials**, v. 299, p. 577-583, 2015.

XU S, LU W, LIU Y, MING Z, LIU Y, MENG R, WANG H (2017) Structure and diversity of bacterial communities in two large sanitary landfills in China as revealed by highthroughput sequencing (MiSeq). **Waste Manag** 63:41–48

XU, A., CHANG, H., XU, Y., LI, R., LI, X., & ZHAO, Y. (2021). Applying artificial neural networks (ANNs) to solve solid waste-related issues: A critical review. **Waste Management**, 124, 385-402.

XU, Ankun et al. Artificial neural network (ANN) modeling for the prediction of odor emission rates from landfill working surface. **Waste Management**, v. 138, p. 158-171, 2022.

ZAINUN MY, SIMARANI K (2018) Metagenomics profiling for assessing microbial diversity in both active and closed landfills. **Sci Total Environ** 616–617:269–278

ŽALTAUSKAITĖ, J.; VAITONYTE, I. Toxicological assessment of closed municipal solidwaste landfill impact to the environment. **Environmental Research, Engineering and Management**, v. 72, n. 4, 16 mar. 2017.

ZAMAN AU (2010) Comparative study of municipal solid waste treatment technologies using life cycle assessment method. **Int J Environ Sci Technol** 7(2):225–234

ZAMRI, M.F.M.A., KAMARUDDIN, M.A., YUSOFF, M.S., Aziz, H.A. and FOO, K.Y. (2017). Semi-aerobic stabilized landfill leachate treatment by ion exchange resin: isotherm and kinetic study. **Applied Water Science** 7(2), 581-590. DOI 10.1007/s13201-015-0266-2

ZHANG, D.; KEAT, T. S.; GERSBERG, R. M. A comparison of municipal solid waste management in Berlin and Singapore. **Waste Management**, v. 30, p. 921–933, 2010.

ZHAO, R., WANG, X., CHEN, X., LIU, Y., 2019. Impacts of different aged landfill leachate on PVC corrosion. **Environ. Sci. Pollut. Res.** 26, 18256–18266.

ZIYANG, L., YOUCAI, Z., TAO, Y., YU, S., HUILI, C., NANWEN, Z., & RENHUA, H.. Natural attenuation and characterization of contaminants composition in landfill leachate under different disposing ages. *Science of the Total Environment*, v. 407, n. 10, p. 3385-3391, 2009.

ZONOUZ, P.R.; NIAEI, A.; Tarjomannejad A. Modeling and optimization of toluene oxidation over perovskite-type nanocatalysts using a hybrid artificial neural network-genetic algorithm method *J. Taiwan Inst. Chem. Eng.*, 65 (2016), pp. 276-285

APÊNDICE A

O Apêndice A mostra de maneira resumida o código utilizado para a síntese de dados. O mesmo código foi usado para gerar os 125 e 1000 dados sintéticos, para cada banco de dados

```
# Importando a biblioteca pandas
```

```
import pandas as pd
```

```
# Realizando uma leitura de um arquivo csv
```

```
df = pd.read_csv('dbopPadronizado.csv', sep=";")
```

```
df
```

	DBO	Vazão	pH	Temperatura	Sólidos Totais	Sólidos Voláteis	Turbidez
0	12375	0.1156	7.86	30	29700	11500	384
1	13125	0.0877	8.30	25	14900	3600	456
2	19875	0.1028	8.23	34	13700	7800	590
...
16	5475	0.4360	8.12	25	20600	8800	91

```
from sdv.tabular import GaussianCopula
```

```
model = GaussianCopula()
```

```
model.fit(df)
```

```
sample = model.sample(125)
```

```
sample
```

	DBO	Vazão	pH	Temperatura	Sólidos Totais	Sólidos Voláteis	Turbidez
0	14137	0.3422	8.02	32	12564	3869	334
1	23698	0.1694	8.08	33	18299	4914	322
2	12576	0.3991	8.30	31	21948	6779	184
...
124	21159	0.3582	8.29	48	15397	4818	506

```
from sdv.evaluation import evaluate
evaluate(sample, df, metrics=['LogisticDetection'], aggregate=False)
```

metric	name	raw score	normalized score	min value	max value	goal	error
Logistic Detection	Logistic Regression Detection	0.948509	0.948509	0.0	1.0	MAXIMIZE	None

```
from sdmetrics.column_pairs import CorrelationSimilarity
```

```
CorrelationSimilarity.compute(
    real_data=df,
    synthetic_data=sample,
    coefficient='Pearson'
)
```

```
0.9807667016068169
```

```
sample.to_csv('dbopadronizado125.csv', index=False)
```

```
model.save('dbopadronizado125.pk')
```

FIM

```
sample = model.sample(1000)
sample
```

	DBO	Vazão	pH	Temperatura	Sólidos Totais	Sólidos Voláteis	Turbidez
0	4432	0.3196	8.34	26	17029	4467	134
1	11231	0.4371	8.53	29	24781	9789	192
2	7206	0.2263	8.31	45	22673	6187	427
...
999	4461	0.4244	7.95	41	19356	6916	103

```
from sdv.evaluation import evaluate
evaluate(sample, df, metrics=['LogisticDetection'], aggregate=False)
```

metric	name	raw score	normalized score	min value	max value	goal	error
--------	------	-----------	------------------	-----------	-----------	------	-------

Logistic Detection	Logistic Regression Detection	0.998332	0.998332	0.0	1.0	MAXIMIZE	None
-----------------------	-------------------------------------	----------	----------	-----	-----	----------	------

```
from sdmetrics.column_pairs import CorrelationSimilarity
```

```
CorrelationSimilarity.compute(  
    real_data=df,  
    synthetic_data=sample,  
    coefficient='Pearson'  
)
```

```
0.9422850870801152
```

```
sample.to_csv('dbopadronizado1000.csv', index=False)
```

```
model.save('dbopadronizado1000.pk')
```

```
FIM
```

APÊNDICE B

O Apêndice B mostra de maneira resumida o código utilizado para o treinamento com Redes Neurais Artificiais. O mesmo código foi utilizado para todas as saídas do treinamento proposto neste trabalho, salvo os ajustes de nomenclatura para a leitura de cada banco de dados.

```

%Adaptado de: Bezerra (2023)
%Última modificação: junho 2023
%Título: Previsão de DBO em lixiviado
%Banco de dados DBO Padronizado

%limpando prompt
clear
clc

variavelan = "DBO";
bancodedados = "DBOPadronizado.xls";

%definindo funções de ativação e treinamento
funcaoativacao = ["logsig" "tansig" "purelin" "elliotsig"];
funcaotreinamento = ["trainlm" "trainbr" "traingd" "trainoss"];

%Variáveis de controle
p = 1; %Navegador de funções de treinamento
i = 1; %Navegador de funções de ativação na camada oculta
j = 0; %Navegador de funções de ativação na camada de saída

%Primeira camada para escolha de cada função de ativação
while (p < 5)

    funtrain = funcaotreinamento{p}; %Função de treinamento na posição p
    exeline = 4; %Variável de controle para saída no excel
    neurons = 0; %Iniciar variável número de neurônios

    %Segunda camada para número de RNA treinadas n = 324
    while (exeline < 324)

        if (i == 1)%Função logsig na camada oculta

            while (exeline < 84)%Terceira camada para finalização do algoritmo logsig

                %Condições de contorno para o código
                if (exeline == 4)%Posição inicial para gravação dos dados .xlsx
                    neurons = 0;%Zerar o número de neurônios na camada oculta
                elseif (exeline == 24)%Posição para gravação dos dados .xlsx
                    neurons = 0;%Zerar o número de neurônios na camada oculta
            end
        end
    end
end

```

```

elseif (exeline == 44)%Posição para gravação dos dados .xlsx
    neurons = 0;%Zerar o número de neurônios na camada oculta
elseif (exeline == 64)%Posição para gravação dos dados .xlsx
    neurons = 0;%Zerar o número de neurônios na camada oculta
end

if (exeline < 24)%Limite da primeira série de treinamentos Logsig_Logsig
    j = 1;%Função logsig na camada de saída
elseif (exeline >= 24) && (exeline < 44)%Limite da primeira série de treinamentos
Logsig_Tansig
    j = 2;%Função tansig na camada de saída
elseif (exeline >= 44)&&(exeline < 64)%Limite da primeira série de treinamentos
Logsig_Purelin
    j = 3;%Função purelin na camada de saída
elseif (exeline >= 64)&&(exeline < 84)%Limite da primeira série de treinamentos
Logsig_Elliotsig
    j = 4;%Função ellioticsig na camada de saída
end

%Configurações dependentes para a RNA
atvfnco = funcaoativacao{i}; %Escolha da função de ativação na camada oculta
atvfncs = funcaoativacao{j}; %Escolha da função de ativação na camada de saída
neurons = neurons + 1; %Atualização do número de neurônios

%importacao do banco de dados
dadosgerais = xlsread(bancodedados, 1, "A2:G201");%Banco de dados original
novaentrada = dadosgerais;%Variável de controle para o BD
entrada = novaentrada (:, 2:end)';%Separação da entrada
saida = novaentrada (:, 1)';%Separação da saída

%iniciando a rede neural
net = feedforwardnet(neurons);%Cria RNA do tipo feedforward
net = configure(net, entrada, saida);%Configura a RNA com o banco de dados

%treinamento

net.trainFcn = funtrain; %definindo algoritmo de treinamento
net.divideFcn = 'divideint';%tipo de divisão do BD

%divisao do banco de dados
net.divideParam.trainRatio = 0.7;%Porcentagem de treinamento
% net.divideParam.valRatio = 0.15;%Porcentagem de
% validação
net.divideParam.testRatio = 0.3;%Porcentagem de teste

%parametros da rna
net.trainParam.epochs = 1000; %numero maximo de iteracoes
net.trainParam.lr = 0.01; %taxa de aprendizagem
net.trainParam.time = inf; %tempo máximo de iteracoes

```

```

net.layers{1}.transferFcn = atvfnco; %definicao da funcao de ativacao da camada
oculta
net.layers{2}.transferFcn = atvfncs; %definicao da funcao de ativacao da camada de
saida

%treinamento
[net,tr] = train(net, entrada, saida);%treinamento da RNA

novaentrada = entrada;
saidamodificada = zeros(5, size(saida,2)); %cria matriz zeradas do tamanho da
entrada de dados
novasaida = [saida(1, :); saidamodificada];%Junta as linhas zeradas aos dados de
entrada

%Separação das máscaras de treinamento e teste do banco de
%dados de entrada dependendo da distribuição do bd
treinoinput = gmultiply(novaentrada,tr.trainMask);%Máscara de treinamento
testeinput = gmultiply(novaentrada,tr.testMask);%Máscara de teste

treino1input = cell2mat(treinoinput);%Conversão da máscara entrada (Célula) para
formato de matriz
teste1input = cell2mat(testeinput);%Conversão da máscara saída (Célula) para
formato de matriz

treino1input = treino1input(:,all(~isnan(treino1input)));%Remove os valores NaN
teste1input = teste1input(:,all(~isnan(teste1input)));%Remove os valores NaN

%Separação das máscaras de treinamento e teste do banco de
%dados de saída dependendo da distribuição do bd
treinooutput = gmultiply(novasaida,tr.trainMask);%Máscara de treinamento
testeoutput = gmultiply(novasaida,tr.testMask);%Máscara de teste

treino1output = cell2mat(treinooutput);%Conversão da máscara entrada (Célula)
para formato de matriz
teste1output = cell2mat(testeoutput);%Conversão da máscara saída (Célula) para
formato de matriz

NaN
treino1output = treino1output(:,all(~isnan(treino1output)));%Remove os valores
teste1output = teste1output(:,all(~isnan(teste1output)));%Remove os valores NaN

%Remoção de linhas excedentes criadas para controle das
%máscaras
teste1output(6,:) = [];
teste1output(5,:) = [];
teste1output(4,:) = [];
teste1output(3,:) = [];
teste1output(2,:) = [];

%Validacao

```

```

resultado = net (teste1input); %Previsão dos dados de teste
resultado = resultado'; %Transpor matriz resultado
teste1output = teste1output'; %Transpor matriz de dados originais
tt = teste1output (:,1); %Variável de controle para gráficos
vetorindex = 1:length(tt);%Cria um vetor para posicionamento dos resultados em
gráficos
modelolinear = fitlm (((teste1output*11942.6)+10744.3),
((resultado*11942.6)+10744.3));

%Calcula o Erro Absoluto Médio (MAE)
MAE = (mae (teste1output, resultado));

%Calcula o RMSE, MSE e Mape
estatisticas = (CalcPerf (teste1output,resultado));

%Calcula o coeficiente de determinação R²
Rdois = modelolinear.Rsquared.Ordinary;

%Calcula o coeficiente de eficiência (E)
Eficiencia = modelolinear.Rsquared.Adjusted;

%Compilação e transcrição dos resultados
estfinal = [MAE estatisticas.RMSE estatisticas.Mape estatisticas.NRMSE Rdois
Eficiencia]; %Cria matriz de resultados
nomenclatura = [num2str(neurons) convertCharsToStrings(atvfnco)
convertCharsToStrings(atvfncs) convertCharsToStrings(funtrain)]; %Cria matriz com a
configuração da RNA

xlswrite ("Resultados.xlsx", nomenclatura, p, strcat ("A",
num2str(exeline),":", "D",num2str(exeline))); %Transcreve em xlsx a matriz de configurações
xlswrite ("Resultados.xlsx", estfinal, p, strcat ("E",
num2str(exeline),":", "J",num2str(exeline))); %Transcreve em xlsx a matriz de resultados

%Exporta o workspace da RNA
nomerede = strcat(funtrain, "_",atvfnco,"_",atvfncs,"_"); %Nomenclatura dos
arquivos
nomerede1 = strcat(atvfnco,"_",atvfncs); %Nomenclatura da legenda das imagens
save (strcat (nomerede, "_", num2str(neurons))); %Exporta o workspace

%Atualização da posição do arquivo xlsx
exeline = exeline + 1;

%Gráficos
figure(1)%observados vs preditos de acordo com a posição
plot (vetorindex,((teste1output*11942.6)+10744.3), "ko:", vetorindex,
((resultado*11942.6)+10744.3),"rx:"); %Plotagem do gráfico valores preditos e observados
grid on; %Ativar o grid
legend ("Observados", nomerede1+"."+neurons+"."+funtrain); %legenda
xlabel('POSICÃO'); % eixo x
ylabel('DBO (mgO2/L)') % eixo y

```

```

saveas(gcf, strcat(nomerede, "DBO", num2str(neurons)), "png");%Salvar o Gráfico
.png

figure (1)
plotperform(tr) %plotagem do gráfico de performance
saveas(gcf, strcat(nomerede, "perf_DBO_", num2str(neurons)), "png");%Salvar o
Gráfico .png

figure (3) %gráfico do R2, observados vs preditos
plot (modelolinear);
grid on; %Ativar o grid
legend ("Dados analisados", "Ajuste do modelo", "Limites do modelo")
xlabel('DBO (mgO2/L) - Observado'); % eixo x
ylabel('DBO (mgO2/L) - Preditos') % eixo y
saveas(gcf, strcat(nomerede, "OxP_DBO_", num2str(neurons)), "png");%Salvar o
Gráfico .png

%limpando o workspace
clear entrada saida perf vetorindex teste1output teste1input testeoutput testeinput
treino1input tr MAE treino1output treinooutput treinoinput validacaooutput validacao1output
validacaoinput validacao1input resultado perf mae estatisticas Rdois Eficiencia estfinal
clc

end

[+]elseif (i == 2)%Função tansig na camada oculta
[+]elseif (i == 3)%Função purelin na camada oculta
[+]elseif (i == 4)%Função elliot sig na camada oculta

else
    i = 0; %zera função de ativação
    j = 0; %zera função de ativação

end

end

i = i + 1; %controle da posição na função de ativação

end

p = p + 1; %Somatório para posição da função de treinamento

end

```

APÊNDICE C

O Apêndice C é composto por tabelas que indicam o desempenho da melhor RNA para cada variação do número de neurônios da camada oculta, sendo analisados por banco de dados e algoritmo de treinamento. As melhores RNA foram selecionadas levando em consideração o R^2 e as métricas de desempenho.

- Algoritmo *trainlm* para a predição de DBO

Para o algoritmo de treinamento *trainlm* e banco de dados experimentais, 125 e 1000 dados sintéticos, estão representadas, respectivamente nas tabelas 12, 13 e 14 as melhores RNA para esses bancos de dados padronizados, e nas tabelas 15, 16 e 17 as melhores RNA para esses bancos de dados normalizados.

Tabela 12 - Performance do algoritmo *trainlm* para predição da DBO com banco de dados experimentais padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R^2
1	<i>purelin</i>	<i>logsig</i>	1,29	1,38	1,04	0,46
2	<i>tansig</i>	<i>elliotsig</i>	0,50	0,61	0,46	0,79
3	<i>logsig</i>	<i>logsig</i>	1,29	1,38	1,04	0,51
4	<i>purelin</i>	<i>logsig</i>	1,29	1,38	1,04	0,87
5	<i>tansig</i>	<i>tansig</i>	0,72	0,75	0,57	0,80
6	<i>logsig</i>	<i>tansig</i>	0,78	0,84	0,63	0,34
7	<i>purelin</i>	<i>logsig</i>	1,29	1,38	1,04	0,47
8	<i>logsig</i>	<i>tansig</i>	0,49	0,59	0,45	0,95
9	<i>logsig</i>	<i>tansig</i>	0,66	0,82	0,62	0,51
10	<i>tansig</i>	<i>elliotsig</i>	0,50	0,73	0,55	0,71
11	<i>tansig</i>	<i>purelin</i>	0,33	0,45	0,34	0,46
12	<i>tansig</i>	<i>purelin</i>	1,23	1,37	1,03	0,46
13	<i>tansig</i>	<i>logsig</i>	1,29	1,38	1,04	0,46
14	<i>purelin</i>	<i>tansig</i>	0,86	1,21	0,91	0,51
15	<i>tansig</i>	<i>logsig</i>	1,29	1,38	1,04	0,73
16	<i>elliotsig</i>	<i>logsig</i>	1,29	1,38	1,04	0,46
17	<i>elliotsig</i>	<i>logsig</i>	1,31	1,39	1,05	0,58
18	<i>tansig</i>	<i>elliotsig</i>	0,22	0,27	0,20	0,68
19	<i>tansig</i>	<i>purelin</i>	0,70	0,89	0,67	0,85
20	<i>purelin</i>	<i>logsig</i>	1,29	1,38	1,04	0,46

Fonte: Autoria própria (2023).

Tabela 13 - Performance do algoritmo *trainlm* para predição da DBO com banco de 125 dados sintéticos padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>elliotsig</i>	<i>purelin</i>	0,65	0,80	0,21	0,47
2	<i>logsig</i>	<i>tansig</i>	0,65	0,79	0,21	0,44
3	<i>tansig</i>	<i>purelin</i>	0,66	0,78	0,21	0,53
4	<i>elliotsig</i>	<i>elliotsig</i>	0,61	0,78	0,21	0,44
5	<i>logsig</i>	<i>tansig</i>	0,61	0,76	0,20	0,47
6	<i>purelin</i>	<i>purelin</i>	0,66	0,80	0,21	0,42
7	<i>logsig</i>	<i>purelin</i>	0,68	0,82	0,22	0,37
8	<i>logsig</i>	<i>purelin</i>	0,68	0,82	0,22	0,45
9	<i>elliotsig</i>	<i>tansig</i>	0,60	0,76	0,20	0,47
10	<i>purelin</i>	<i>purelin</i>	0,66	0,80	0,21	0,42
11	<i>tansig</i>	<i>elliotsig</i>	0,67	0,79	0,21	0,45
12	<i>elliotsig</i>	<i>tansig</i>	0,65	0,79	0,21	0,43
13	<i>purelin</i>	<i>purelin</i>	0,66	0,80	0,21	0,42
14	<i>purelin</i>	<i>purelin</i>	0,66	0,80	0,21	0,42
15	<i>elliotsig</i>	<i>elliotsig</i>	0,60	0,76	0,20	0,46
16	<i>purelin</i>	<i>purelin</i>	0,66	0,80	0,21	0,42
17	<i>purelin</i>	<i>tansig</i>	0,63	0,78	0,21	0,44
18	<i>elliotsig</i>	<i>tansig</i>	0,85	1,08	0,29	0,48
19	<i>purelin</i>	<i>purelin</i>	0,66	0,80	0,21	0,42
20	<i>purelin</i>	<i>purelin</i>	0,66	0,80	0,21	0,42

Fonte: Autoria própria (2023).

Tabela 14 - Performance do algoritmo *trainlm* para predição da DBO com banco de 1000 dados sintéticos padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>tansig</i>	<i>elliotsig</i>	0,51	0,64	0,17	0,61
2	<i>logsig</i>	<i>tansig</i>	0,52	0,64	0,17	0,59
3	<i>tansig</i>	<i>tansig</i>	0,52	0,64	0,17	0,59
4	<i>tansig</i>	<i>elliotsig</i>	0,56	0,70	0,18	0,51
5	<i>tansig</i>	<i>elliotsig</i>	0,55	0,66	0,17	0,54
6	<i>purelin</i>	<i>elliotsig</i>	0,57	0,69	0,18	0,55
7	<i>logsig</i>	<i>tansig</i>	0,58	0,72	0,19	0,55
8	<i>logsig</i>	<i>tansig</i>	0,55	0,68	0,18	0,57
9	<i>logsig</i>	<i>elliotsig</i>	0,51	0,66	0,17	0,55
10	<i>elliotsig</i>	<i>elliotsig</i>	0,61	0,76	0,20	0,53
11	<i>purelin</i>	<i>purelin</i>	0,56	0,69	0,18	0,52
12	<i>logsig</i>	<i>elliotsig</i>	0,59	0,73	0,19	0,56

13	<i>purelin</i>	<i>purelin</i>	0,56	0,69	0,18	0,52
14	<i>logsig</i>	<i>tansig</i>	0,51	0,65	0,17	0,56
15	<i>purelin</i>	<i>purelin</i>	0,56	0,69	0,18	0,52
16	<i>logsig</i>	<i>tansig</i>	0,56	0,70	0,18	0,56
17	<i>purelin</i>	<i>tansig</i>	0,54	0,69	0,18	0,53
18	<i>elliotsig</i>	<i>purelin</i>	0,52	0,65	0,17	0,54
19	<i>purelin</i>	<i>purelin</i>	0,56	0,69	0,18	0,52
20	<i>purelin</i>	<i>purelin</i>	0,56	0,69	0,18	0,52

Fonte: Autoria própria (2023).

Tabela 15 – Performance do algoritmo *trainlm* para a predição da DBO com banco de dados experimentais normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>purelin</i>	<i>logsig</i>	0,33	0,36	1,04	0,45
2	<i>logsig</i>	<i>tansig</i>	0,21	0,25	0,74	0,06
3	<i>tansig</i>	<i>elliotsig</i>	0,11	0,14	0,41	0,15
4	<i>purelin</i>	<i>logsig</i>	0,33	0,36	1,04	0,57
5	<i>purelin</i>	<i>tansig</i>	0,17	0,20	0,59	0,78
6	<i>purelin</i>	<i>tansig</i>	0,17	0,20	0,59	0,63
7	<i>elliotsig</i>	<i>logsig</i>	0,33	0,36	1,04	0,46
8	<i>logsig</i>	<i>tansig</i>	0,19	0,23	0,66	0,40
9	<i>elliotsig</i>	<i>logsig</i>	0,33	0,36	1,04	0,45
10	<i>tansig</i>	<i>tansig</i>	0,17	0,21	0,61	0,51
11	<i>tansig</i>	<i>logsig</i>	0,33	0,36	1,04	0,46
12	<i>tansig</i>	<i>purelin</i>	0,20	0,24	0,71	0,57
13	<i>purelin</i>	<i>logsig</i>	0,33	0,36	1,04	0,46
14	<i>purelin</i>	<i>tansig</i>	0,23	0,32	0,95	0,44
15	<i>tansig</i>	<i>tansig</i>	0,06	0,06	0,19	0,83
16	<i>elliotsig</i>	<i>logsig</i>	0,33	0,36	1,04	0,46
17	<i>logsig</i>	<i>logsig</i>	0,33	0,36	1,04	0,46
18	<i>tansig</i>	<i>elliotsig</i>	0,07	0,09	0,27	0,53
19	<i>tansig</i>	<i>purelin</i>	0,17	0,23	0,67	0,86
20	<i>purelin</i>	<i>logsig</i>	0,33	0,36	1,04	0,44

Fonte: Autoria própria (2023).

Tabela 16 - Performance do algoritmo *trainlm* para a predição da DBO com banco de 125 dados sintéticos normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>elliotsig</i>	<i>elliotsig</i>	0,16	0,19	0,22	0,43

2	<i>logsig</i>	<i>tansig</i>	0,15	0,18	0,21	0,44
3	<i>elliotsig</i>	<i>purelin</i>	0,16	0,20	0,22	0,46
4	<i>purelin</i>	<i>tansig</i>	0,15	0,18	0,21	0,44
5	<i>logsig</i>	<i>tansig</i>	0,15	0,19	0,21	0,47
6	<i>purelin</i>	<i>elliotsig</i>	0,15	0,18	0,20	0,49
7	<i>logsig</i>	<i>elliotsig</i>	0,14	0,19	0,21	0,46
8	<i>purelin</i>	<i>tansig</i>	0,14	0,18	0,20	0,50
9	<i>purelin</i>	<i>elliotsig</i>	0,16	0,20	0,23	0,47
10	<i>purelin</i>	<i>purelin</i>	0,16	0,19	0,21	0,42
11	<i>tansig</i>	<i>elliotsig</i>	0,15	0,18	0,21	0,45
12	<i>purelin</i>	<i>purelin</i>	0,16	0,19	0,21	0,42
13	<i>logsig</i>	<i>tansig</i>	0,16	0,19	0,21	0,50
14	<i>elliotsig</i>	<i>elliotsig</i>	0,15	0,19	0,21	0,43
15	<i>purelin</i>	<i>elliotsig</i>	0,13	0,17	0,19	0,52
16	<i>purelin</i>	<i>purelin</i>	0,16	0,19	0,21	0,42
17	<i>purelin</i>	<i>purelin</i>	0,15	0,19	0,21	0,43
18	<i>purelin</i>	<i>purelin</i>	0,16	0,19	0,21	0,42
19	<i>purelin</i>	<i>purelin</i>	0,16	0,19	0,21	0,42
20	<i>purelin</i>	<i>purelin</i>	0,16	0,19	0,21	0,42

Fonte: Autoria própria (2023).

Tabela 17 - Performance do algoritmo *trainlm* para a predição da DBO com banco de 1000 dados sintéticos normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>logsig</i>	<i>elliotsig</i>	0,10	0,13	0,17	0,61
2	<i>logsig</i>	<i>tansig</i>	0,11	0,14	0,18	0,57
3	<i>elliotsig</i>	<i>elliotsig</i>	0,10	0,13	0,17	0,59
4	<i>tansig</i>	<i>elliotsig</i>	0,15	0,18	0,23	0,56
5	<i>logsig</i>	<i>tansig</i>	0,11	0,13	0,17	0,56
6	<i>logsig</i>	<i>tansig</i>	0,11	0,13	0,17	0,56
7	<i>elliotsig</i>	<i>elliotsig</i>	0,10	0,13	0,17	0,60
8	<i>elliotsig</i>	<i>elliotsig</i>	0,10	0,13	0,17	0,55
9	<i>logsig</i>	<i>tansig</i>	0,10	0,13	0,17	0,53
10	<i>tansig</i>	<i>tansig</i>	0,10	0,13	0,17	0,56
11	<i>purelin</i>	<i>elliotsig</i>	0,11	0,13	0,17	0,58
12	<i>logsig</i>	<i>tansig</i>	0,13	0,16	0,20	0,57
13	<i>purelin</i>	<i>purelin</i>	0,11	0,14	0,18	0,52
14	<i>logsig</i>	<i>elliotsig</i>	0,11	0,14	0,19	0,53
15	<i>logsig</i>	<i>elliotsig</i>	0,11	0,13	0,17	0,60
16	<i>logsig</i>	<i>purelin</i>	0,11	0,13	0,17	0,53
17	<i>logsig</i>	<i>purelin</i>	0,11	0,14	0,18	0,53

18	<i>purelin</i>	<i>elliotsig</i>	0,11	0,14	0,18	0,57
19	<i>logsig</i>	<i>purelin</i>	0,11	0,14	0,18	0,53
20	<i>logsig</i>	<i>purelin</i>	0,11	0,14	0,18	0,52

Fonte: Autoria própria (2023).

- Algoritmo *trainbr* para a predição de DBO

Para o algoritmo de treinamento *trainbr* e banco de dados experimentais, 125 e 1000 dados sintéticos, estão representadas, respectivamente nas tabelas 18, 19 e 20 as melhores RNA para esses bancos de dados padronizados, e nas tabelas 21, 22 e 23 as melhores RNA para esses bancos de dados normalizados.

Tabela 18 - Performance do algoritmo *trainbr* para predição da DBO com banco de dados experimentais padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>purelin</i>	<i>purelin</i>	1,42	1,72	1,30	0,16
2	<i>elliotsig</i>	<i>purelin</i>	1,09	1,35	1,02	0,21
3	<i>elliotsig</i>	<i>purelin</i>	1,34	1,63	1,23	0,26
4	<i>logsig</i>	<i>purelin</i>	0,28	0,38	0,29	0,70
5	<i>tansig</i>	<i>purelin</i>	1,21	1,45	1,10	0,17
6	<i>tansig</i>	<i>purelin</i>	1,21	1,45	1,10	0,17
7	<i>tansig</i>	<i>purelin</i>	1,21	1,45	1,10	0,17
8	<i>logsig</i>	<i>logsig</i>	1,29	1,38	1,04	0,23
9	<i>tansig</i>	<i>purelin</i>	1,21	1,45	1,10	0,17
10	<i>tansig</i>	<i>purelin</i>	1,21	1,45	1,09	0,17
11	<i>logsig</i>	<i>logsig</i>	1,29	1,38	1,04	0,16
12	<i>purelin</i>	<i>logsig</i>	1,29	1,38	1,04	0,19
13	<i>logsig</i>	<i>logsig</i>	1,29	1,38	1,04	0,17
14	<i>logsig</i>	<i>elliotsig</i>	0,60	0,66	0,50	0,28
15	<i>logsig</i>	<i>elliotsig</i>	0,49	0,56	0,43	0,19
16	<i>logsig</i>	<i>logsig</i>	1,29	1,38	1,04	0,15
17	<i>purelin</i>	<i>purelin</i>	1,43	1,73	1,30	0,16
18	<i>logsig</i>	<i>logsig</i>	1,29	1,38	1,04	0,18
19	<i>logsig</i>	<i>logsig</i>	1,29	1,38	1,04	0,21
20	<i>tansig</i>	<i>purelin</i>	1,21	1,45	1,10	0,17

Fonte: Autoria própria (2023).

Tabela 19 - Performance do algoritmo *trainbr* para a predição da DBO com banco de 125 dados sintéticos padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²

1	<i>purelin</i>	<i>purelin</i>	0,64	0,78	0,21	0,45
2	<i>purelin</i>	<i>purelin</i>	0,64	0,78	0,21	0,45
3	<i>purelin</i>	<i>purelin</i>	0,64	0,78	0,21	0,45
4	<i>elliotsig</i>	<i>purelin</i>	0,60	0,75	0,20	0,49
5	<i>elliotsig</i>	<i>tansig</i>	0,61	0,77	0,20	0,47
6	<i>elliotsig</i>	<i>purelin</i>	0,60	0,75	0,20	0,49
7	<i>elliotsig</i>	<i>tansig</i>	0,59	0,74	0,20	0,50
8	<i>elliotsig</i>	<i>purelin</i>	0,61	0,77	0,20	0,46
9	<i>elliotsig</i>	<i>purelin</i>	0,60	0,75	0,20	0,48
10	<i>elliotsig</i>	<i>purelin</i>	0,61	0,77	0,20	0,46
11	<i>purelin</i>	<i>purelin</i>	0,64	0,78	0,21	0,45
12	<i>logsig</i>	<i>elliotsig</i>	0,93	1,03	0,27	0,48
13	<i>logsig</i>	<i>elliotsig</i>	0,93	1,03	0,27	0,47
14	<i>purelin</i>	<i>purelin</i>	0,64	0,78	0,21	0,45
15	<i>elliotsig</i>	<i>purelin</i>	0,60	0,76	0,20	0,48
16	<i>logsig</i>	<i>elliotsig</i>	0,93	1,03	0,27	0,47
17	<i>purelin</i>	<i>purelin</i>	0,64	0,78	0,21	0,45
18	<i>purelin</i>	<i>purelin</i>	0,64	0,78	0,21	0,45
19	<i>logsig</i>	<i>elliotsig</i>	0,94	1,03	0,27	0,48
20	<i>elliotsig</i>	<i>purelin</i>	0,60	0,76	0,20	0,48

Fonte: Autoria própria (2023).

Tabela 20 - Performance do algoritmo *trainbr* para a predição da DBO com banco de 1000 dados sintéticos padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>elliotsig</i>	<i>elliotsig</i>	0,55	0,68	0,18	0,59
2	<i>elliotsig</i>	<i>purelin</i>	0,54	0,68	0,18	0,54
3	<i>elliotsig</i>	<i>tansig</i>	0,54	0,68	0,18	0,54
4	<i>elliotsig</i>	<i>purelin</i>	0,54	0,68	0,18	0,54
5	<i>elliotsig</i>	<i>tansig</i>	0,55	0,69	0,18	0,54
6	<i>elliotsig</i>	<i>tansig</i>	0,54	0,68	0,18	0,54
7	<i>elliotsig</i>	<i>tansig</i>	0,54	0,68	0,18	0,54
8	<i>elliotsig</i>	<i>tansig</i>	0,54	0,68	0,18	0,54
9	<i>elliotsig</i>	<i>tansig</i>	0,54	0,68	0,18	0,54
10	<i>elliotsig</i>	<i>tansig</i>	0,54	0,68	0,18	0,54
11	<i>elliotsig</i>	<i>tansig</i>	0,54	0,68	0,18	0,54
12	<i>elliotsig</i>	<i>tansig</i>	0,54	0,68	0,18	0,54
13	<i>elliotsig</i>	<i>tansig</i>	0,54	0,68	0,18	0,53
14	<i>elliotsig</i>	<i>tansig</i>	0,54	0,68	0,18	0,54
15	<i>elliotsig</i>	<i>tansig</i>	0,54	0,68	0,18	0,53
16	<i>elliotsig</i>	<i>tansig</i>	0,55	0,68	0,18	0,53
17	<i>elliotsig</i>	<i>elliotsig</i>	0,55	0,69	0,18	0,53

18	<i>elliotsig</i>	<i>tansig</i>	0,54	0,68	0,18	0,53
19	<i>elliotsig</i>	<i>tansig</i>	0,55	0,68	0,18	0,53
20	<i>elliotsig</i>	<i>tansig</i>	0,55	0,68	0,18	0,53

Fonte: Autoria própria (2023).

Tabela 21 - Performance do algoritmo *trainbr* para predição da DBO com banco de dados experimentais normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>purelin</i>	<i>purelin</i>	0,37	0,44	1,30	0,16
2	<i>elliotsig</i>	<i>purelin</i>	0,28	0,35	1,02	0,21
3	<i>elliotsig</i>	<i>purelin</i>	0,35	0,43	1,24	0,26
4	<i>logsig</i>	<i>purelin</i>	0,07	0,10	0,29	0,70
5	<i>elliotsig</i>	<i>purelin</i>	0,38	0,45	1,32	0,21
6	<i>tansig</i>	<i>purelin</i>	0,31	0,37	1,09	0,17
7	<i>logsig</i>	<i>purelin</i>	0,17	0,19	0,55	0,64
8	<i>tansig</i>	<i>purelin</i>	0,31	0,37	1,10	0,17
9	<i>tansig</i>	<i>purelin</i>	0,31	0,37	1,10	0,17
10	<i>tansig</i>	<i>purelin</i>	0,31	0,38	1,10	0,17
11	<i>tansig</i>	<i>purelin</i>	0,31	0,37	1,10	0,17
12	<i>logsig</i>	<i>logsig</i>	0,33	0,36	1,04	0,17
13	<i>logsig</i>	<i>logsig</i>	0,33	0,36	1,04	0,27
14	<i>logsig</i>	<i>elliotsig</i>	0,16	0,17	0,50	0,28
15	<i>purelin</i>	<i>logsig</i>	0,33	0,36	1,04	0,20
16	<i>tansig</i>	<i>purelin</i>	0,24	0,29	0,86	0,12
17	<i>logsig</i>	<i>logsig</i>	0,33	0,36	1,04	0,18
18	<i>tansig</i>	<i>purelin</i>	0,36	0,43	1,27	0,16
19	<i>logsig</i>	<i>logsig</i>	0,33	0,36	1,04	0,19
20	<i>logsig</i>	<i>logsig</i>	0,33	0,36	1,04	0,18

Fonte: Autoria própria (2023).

Tabela 22 – Performance do algoritmo *trainbr* para a predição da DBO com banco de 125 dados sintéticos normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>purelin</i>	<i>purelin</i>	0,15	0,18	0,21	0,45
2	<i>purelin</i>	<i>purelin</i>	0,15	0,18	0,21	0,45
3	<i>purelin</i>	<i>purelin</i>	0,15	0,18	0,21	0,45
4	<i>elliotsig</i>	<i>purelin</i>	0,14	0,18	0,20	0,49
5	<i>elliotsig</i>	<i>tansig</i>	0,14	0,18	0,20	0,47
6	<i>elliotsig</i>	<i>purelin</i>	0,14	0,18	0,20	0,49

7	<i>elliotsig</i>	<i>tansig</i>	0,35	0,23	0,30	0,63
8	<i>elliotsig</i>	<i>purelin</i>	0,14	0,18	0,20	0,46
9	<i>elliotsig</i>	<i>purelin</i>	0,14	0,18	0,20	0,48
10	<i>elliotsig</i>	<i>purelin</i>	0,14	0,18	0,20	0,46
11	<i>purelin</i>	<i>purelin</i>	0,15	0,18	0,21	0,45
12	<i>logsig</i>	<i>elliotsig</i>	0,22	0,24	0,27	0,48
13	<i>logsig</i>	<i>elliotsig</i>	0,22	0,24	0,27	0,48
14	<i>logsig</i>	<i>tansig</i>	0,22	0,24	0,28	0,48
15	<i>logsig</i>	<i>elliotsig</i>	0,22	0,24	0,28	0,48
16	<i>elliotsig</i>	<i>purelin</i>	0,14	0,18	0,20	0,49
17	<i>logsig</i>	<i>elliotsig</i>	0,22	0,24	0,28	0,48
18	<i>logsig</i>	<i>tansig</i>	0,22	0,24	0,28	0,48
19	<i>elliotsig</i>	<i>tansig</i>	0,14	0,18	0,20	0,50
20	<i>logsig</i>	<i>tansig</i>	0,22	0,24	0,28	0,47

Fonte: Autoria própria (2023).

Tabela 23 - Performance do algoritmo *trainbr* para a predição da DBO com banco de 1000 dados sintéticos normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>elliotsig</i>	<i>elliotsig</i>	0,11	0,13	0,18	0,59
2	<i>elliotsig</i>	<i>purelin</i>	0,11	0,13	0,18	0,54
3	<i>elliotsig</i>	<i>tansig</i>	0,11	0,14	0,18	0,54
4	<i>elliotsig</i>	<i>purelin</i>	0,11	0,14	0,18	0,54
5	<i>elliotsig</i>	<i>tansig</i>	0,11	0,14	0,18	0,54
6	<i>elliotsig</i>	<i>tansig</i>	0,11	0,14	0,18	0,54
7	<i>elliotsig</i>	<i>tansig</i>	0,11	0,14	0,18	0,54
8	<i>elliotsig</i>	<i>tansig</i>	0,11	0,14	0,18	0,54
9	<i>elliotsig</i>	<i>tansig</i>	0,11	0,14	0,18	0,54
10	<i>elliotsig</i>	<i>tansig</i>	0,11	0,14	0,18	0,54
11	<i>elliotsig</i>	<i>tansig</i>	0,11	0,14	0,18	0,54
12	<i>elliotsig</i>	<i>tansig</i>	0,11	0,14	0,18	0,54
13	<i>elliotsig</i>	<i>tansig</i>	0,11	0,14	0,18	0,53
14	<i>elliotsig</i>	<i>tansig</i>	0,11	0,14	0,18	0,54
15	<i>elliotsig</i>	<i>tansig</i>	0,11	0,14	0,18	0,53
16	<i>elliotsig</i>	<i>tansig</i>	0,11	0,14	0,18	0,53
17	<i>elliotsig</i>	<i>elliotsig</i>	0,11	0,14	0,18	0,53
18	<i>elliotsig</i>	<i>tansig</i>	0,11	0,14	0,18	0,53
19	<i>elliotsig</i>	<i>tansig</i>	0,11	0,14	0,18	0,53
20	<i>elliotsig</i>	<i>elliotsig</i>	0,11	0,14	0,18	0,53

Fonte: Autoria própria (2023).

- Algoritmo *traingd* para a predição de DBO

Para o algoritmo de treinamento *traingd* e banco de dados experimentais, 125 e 1000 dados sintéticos, estão representadas, respectivamente nas tabelas 24, 25 e 26 as melhores RNA para esses bancos de dados padronizados, e nas tabelas 27, 28 e 29 as melhores RNA para esses bancos de dados normalizados

Tabela 24 - Performance do algoritmo *traingd* para predição da DBO com banco de dados experimentais padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>elliotsig</i>	<i>logsig</i>	1,35	1,42	1,07	0,54
2	<i>tansig</i>	<i>purelin</i>	0,39	0,48	0,36	0,70
3	<i>elliotsig</i>	<i>elliotsig</i>	0,49	0,57	0,43	0,67
4	<i>elliotsig</i>	<i>elliotsig</i>	0,47	0,58	0,44	0,88
5	<i>purelin</i>	<i>logsig</i>	1,30	1,38	1,04	0,61
6	<i>tansig</i>	<i>tansig</i>	0,96	1,12	0,84	0,73
7	<i>tansig</i>	<i>logsig</i>	1,40	1,45	1,09	0,84
8	<i>elliotsig</i>	<i>purelin</i>	0,34	0,46	0,35	0,72
9	<i>purelin</i>	<i>tansig</i>	0,50	0,62	0,47	0,93
10	<i>elliotsig</i>	<i>tansig</i>	0,81	0,96	0,72	0,78
11	<i>elliotsig</i>	<i>elliotsig</i>	0,65	0,67	0,51	0,89
12	<i>elliotsig</i>	<i>tansig</i>	0,98	1,22	0,92	0,58
13	<i>purelin</i>	<i>elliotsig</i>	0,59	0,81	0,61	0,53
14	<i>logsig</i>	<i>logsig</i>	1,31	1,39	1,05	0,23
15	<i>purelin</i>	<i>tansig</i>	0,46	0,69	0,52	0,86
16	<i>logsig</i>	<i>purelin</i>	0,67	0,75	0,57	0,74
17	<i>tansig</i>	<i>purelin</i>	1,84	2,00	1,51	0,83
18	<i>logsig</i>	<i>elliotsig</i>	0,36	0,42	0,32	0,88
19	<i>tansig</i>	<i>purelin</i>	1,23	1,55	1,17	0,91
20	<i>elliotsig</i>	<i>purelin</i>	1,39	1,77	1,33	0,52

Fonte: Autoria própria (2023).

Tabela 25 - Performance do algoritmo *traingd* para predição da DBO com banco de 125 dados sintéticos padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>purelin</i>	<i>tansig</i>	0,60	0,76	0,20	0,49
2	<i>purelin</i>	<i>purelin</i>	0,62	0,77	0,21	0,47
3	<i>tansig</i>	<i>purelin</i>	0,60	0,78	0,21	0,45
4	<i>tansig</i>	<i>purelin</i>	0,65	0,77	0,20	0,48

5	<i>logsig</i>	<i>tansig</i>	0,61	0,78	0,21	0,47
6	<i>purelin</i>	<i>purelin</i>	0,59	0,77	0,21	0,44
7	<i>logsig</i>	<i>elliotsig</i>	0,68	0,81	0,22	0,47
8	<i>logsig</i>	<i>purelin</i>	0,61	0,78	0,21	0,44
9	<i>elliotsig</i>	<i>elliotsig</i>	0,63	0,75	0,20	0,50
10	<i>logsig</i>	<i>purelin</i>	0,64	0,79	0,21	0,50
11	<i>tansig</i>	<i>elliotsig</i>	0,64	0,78	0,21	0,43
12	<i>logsig</i>	<i>tansig</i>	0,62	0,78	0,21	0,46
13	<i>logsig</i>	<i>purelin</i>	0,62	0,76	0,20	0,48
14	<i>logsig</i>	<i>purelin</i>	0,59	0,76	0,20	0,48
15	<i>purelin</i>	<i>purelin</i>	0,66	0,80	0,21	0,42
16	<i>purelin</i>	<i>purelin</i>	0,66	0,81	0,22	0,40
17	<i>logsig</i>	<i>tansig</i>	0,67	0,80	0,21	0,45
18	<i>purelin</i>	<i>tansig</i>	1,35	1,59	0,42	0,47
19	<i>logsig</i>	<i>elliotsig</i>	0,68	0,82	0,22	0,43
20	<i>elliotsig</i>	<i>elliotsig</i>	0,61	0,78	0,21	0,43

Fonte: Autoria própria (2023).

Tabela 26 - Performance do algoritmo *traingd* para predição da DBO com banco de 1000 dados sintéticos padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>elliotsig</i>	<i>elliotsig</i>	0,58	0,71	0,18	0,52
2	<i>purelin</i>	<i>purelin</i>	0,60	0,74	0,19	0,43
3	<i>purelin</i>	<i>elliotsig</i>	0,58	0,71	0,19	0,50
4	<i>tansig</i>	<i>purelin</i>	0,57	0,69	0,18	0,50
5	<i>logsig</i>	<i>tansig</i>	0,58	0,71	0,19	0,48
6	<i>purelin</i>	<i>purelin</i>	0,56	0,68	0,18	0,52
7	<i>purelin</i>	<i>tansig</i>	0,52	0,66	0,17	0,53
8	<i>elliotsig</i>	<i>tansig</i>	0,52	0,64	0,17	0,59
9	<i>logsig</i>	<i>tansig</i>	0,56	0,68	0,18	0,55
10	<i>tansig</i>	<i>purelin</i>	0,53	0,65	0,17	0,55
11	<i>purelin</i>	<i>purelin</i>	0,56	0,69	0,18	0,52
12	<i>purelin</i>	<i>purelin</i>	0,56	0,69	0,18	0,52
13	<i>purelin</i>	<i>purelin</i>	0,56	0,69	0,18	0,52
14	<i>logsig</i>	<i>purelin</i>	0,55	0,69	0,18	0,52
15	<i>elliotsig</i>	<i>elliotsig</i>	0,60	0,72	0,19	0,48
16	<i>logsig</i>	<i>elliotsig</i>	0,57	0,71	0,18	0,53
17	<i>tansig</i>	<i>tansig</i>	0,55	0,66	0,17	0,53
18	<i>logsig</i>	<i>tansig</i>	0,54	0,66	0,17	0,56
19	<i>elliotsig</i>	<i>tansig</i>	0,51	0,65	0,17	0,55
20	<i>logsig</i>	<i>elliotsig</i>	0,55	0,68	0,18	0,55

Fonte: Autoria própria (2023).

Tabela 27 - Performance do algoritmo *traingd* para predição da DBO com banco de dados experimentais normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>elliotsig</i>	<i>purelin</i>	0,21	0,23	0,67	0,48
2	<i>elliotsig</i>	<i>logsig</i>	0,40	0,42	1,22	0,73
3	<i>tansig</i>	<i>tansig</i>	0,15	0,17	0,48	0,72
4	<i>tansig</i>	<i>tansig</i>	0,25	0,28	0,82	0,63
5	<i>purelin</i>	<i>logsig</i>	0,34	0,36	1,05	0,66
6	<i>tansig</i>	<i>tansig</i>	0,25	0,29	0,84	0,73
7	<i>tansig</i>	<i>logsig</i>	0,40	0,41	1,19	0,74
8	<i>tansig</i>	<i>purelin</i>	0,28	0,36	1,05	0,75
9	<i>purelin</i>	<i>tansig</i>	0,12	0,15	0,42	0,92
10	<i>tansig</i>	<i>tansig</i>	0,32	0,41	1,18	0,88
11	<i>elliotsig</i>	<i>elliotsig</i>	0,18	0,19	0,56	0,88
12	<i>elliotsig</i>	<i>tansig</i>	0,25	0,31	0,92	0,57
13	<i>purelin</i>	<i>logsig</i>	0,83	0,84	2,45	0,59
14	<i>elliotsig</i>	<i>purelin</i>	0,13	0,17	0,49	0,62
15	<i>purelin</i>	<i>tansig</i>	0,50	0,57	1,68	0,77
16	<i>purelin</i>	<i>purelin</i>	0,23	0,29	0,83	0,99
17	<i>tansig</i>	<i>purelin</i>	0,48	0,51	1,50	0,84
18	<i>logsig</i>	<i>elliotsig</i>	0,09	0,11	0,31	0,92
19	<i>tansig</i>	<i>purelin</i>	0,32	0,39	1,15	0,91
20	<i>tansig</i>	<i>elliotsig</i>	0,08	0,10	0,29	0,77

Fonte: Autoria própria (2023).

Tabela 28 - Performance do algoritmo *traingd* para predição da DBO com banco de 125 dados sintéticos normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>tansig</i>	<i>purelin</i>	0,22	0,24	0,27	0,46
2	<i>logsig</i>	<i>tansig</i>	0,16	0,19	0,22	0,43
3	<i>purelin</i>	<i>purelin</i>	0,16	0,19	0,22	0,38
4	<i>logsig</i>	<i>purelin</i>	0,17	0,21	0,23	0,34
5	<i>elliotsig</i>	<i>elliotsig</i>	0,15	0,18	0,20	0,47
6	<i>purelin</i>	<i>purelin</i>	0,14	0,18	0,21	0,44
7	<i>purelin</i>	<i>tansig</i>	0,19	0,24	0,26	0,48
8	<i>elliotsig</i>	<i>tansig</i>	0,15	0,19	0,22	0,41
9	<i>tansig</i>	<i>tansig</i>	0,15	0,21	0,23	0,40

10	<i>purelin</i>	<i>purelin</i>	0,16	0,19	0,21	0,41
11	<i>logsig</i>	<i>tansig</i>	0,14	0,19	0,21	0,42
12	<i>purelin</i>	<i>purelin</i>	0,15	0,19	0,21	0,44
13	<i>purelin</i>	<i>purelin</i>	0,15	0,19	0,21	0,43
14	<i>purelin</i>	<i>tansig</i>	0,24	0,29	0,32	0,44
15	<i>purelin</i>	<i>elliotsig</i>	0,14	0,19	0,22	0,47
16	<i>purelin</i>	<i>purelin</i>	0,15	0,19	0,21	0,42
17	<i>purelin</i>	<i>purelin</i>	0,15	0,19	0,21	0,42
18	<i>purelin</i>	<i>tansig</i>	0,32	0,38	0,42	0,47
19	<i>purelin</i>	<i>purelin</i>	0,15	0,19	0,21	0,44
20	<i>tansig</i>	<i>tansig</i>	0,24	0,30	0,34	0,42

Fonte: Autoria própria (2023).

Tabela 29 - Performance do algoritmo *traingd* para predição da DBO com banco de 1000 dados sintéticos normalizados

NCO	Características da RNA		Medidas de performance			
	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>purelin</i>	<i>elliotsig</i>	0,12	0,15	0,20	0,39
2	<i>logsig</i>	<i>tansig</i>	0,14	0,16	0,21	0,39
3	<i>elliotsig</i>	<i>logsig</i>	0,21	0,25	0,33	0,37
4	<i>logsig</i>	<i>purelin</i>	0,14	0,17	0,22	0,35
5	<i>tansig</i>	<i>logsig</i>	0,21	0,26	0,34	0,34
6	<i>purelin</i>	<i>purelin</i>	0,10	0,13	0,17	0,56
7	<i>logsig</i>	<i>logsig</i>	0,19	0,23	0,30	0,31
8	<i>elliotsig</i>	<i>tansig</i>	0,11	0,14	0,19	0,47
9	<i>tansig</i>	<i>tansig</i>	0,14	0,17	0,22	0,48
10	<i>logsig</i>	<i>logsig</i>	0,20	0,24	0,32	0,45
11	<i>logsig</i>	<i>tansig</i>	0,12	0,15	0,20	0,39
12	<i>purelin</i>	<i>purelin</i>	0,13	0,15	0,20	0,34
13	<i>logsig</i>	<i>purelin</i>	0,13	0,16	0,20	0,34
14	<i>purelin</i>	<i>purelin</i>	0,12	0,15	0,20	0,34
15	<i>purelin</i>	<i>purelin</i>	0,11	0,14	0,18	0,54
16	<i>elliotsig</i>	<i>tansig</i>	0,15	0,18	0,23	0,29
17	<i>tansig</i>	<i>elliotsig</i>	0,13	0,16	0,21	0,39
18	<i>purelin</i>	<i>purelin</i>	0,11	0,13	0,18	0,53
19	<i>purelin</i>	<i>purelin</i>	0,11	0,14	0,18	0,55
20	<i>purelin</i>	<i>purelin</i>	0,12	0,14	0,19	0,43

Fonte: Autoria própria (2023).

- Algoritmo *trainoss* para a predição de DBO

Para o algoritmo de treinamento *trainoss* e banco de dados experimentais, 125 e 1000 dados sintéticos, estão representadas, respectivamente nas tabelas 30, 31 e 32 as melhores RNA para esses bancos de dados padronizados, e nas tabelas 33, 34 e 35 as melhores RNA para esses bancos de dados normalizados

Tabela 30 - Performance do algoritmo *trainoss* para predição da DBO com banco de dados experimentais padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>elliotsig</i>	<i>elliotsig</i>	0,34	0,40	0,30	0,42
2	<i>purelin</i>	<i>tansig</i>	0,39	0,42	0,32	0,35
3	<i>purelin</i>	<i>elliotsig</i>	0,48	0,57	0,43	0,89
4	<i>purelin</i>	<i>purelin</i>	0,66	0,72	0,54	0,27
5	<i>purelin</i>	<i>purelin</i>	0,71	0,92	0,70	0,59
6	<i>purelin</i>	<i>logsig</i>	1,29	1,38	1,04	0,51
7	<i>elliotsig</i>	<i>purelin</i>	0,58	0,61	0,46	0,93
8	<i>tansig</i>	<i>elliotsig</i>	0,29	0,39	0,29	0,71
9	<i>purelin</i>	<i>tansig</i>	1,58	2,01	1,51	0,63
10	<i>logsig</i>	<i>tansig</i>	0,66	0,71	0,53	0,77
11	<i>purelin</i>	<i>tansig</i>	0,65	0,80	0,61	0,62
12	<i>tansig</i>	<i>elliotsig</i>	0,57	0,70	0,53	0,66
13	<i>elliotsig</i>	<i>elliotsig</i>	0,36	0,42	0,32	0,33
14	<i>tansig</i>	<i>purelin</i>	1,05	1,33	1,00	0,33
15	<i>tansig</i>	<i>elliotsig</i>	0,55	0,68	0,51	0,81
16	<i>purelin</i>	<i>tansig</i>	1,20	1,86	1,40	0,45
17	<i>elliotsig</i>	<i>logsig</i>	1,29	1,38	1,04	0,66
18	<i>logsig</i>	<i>purelin</i>	0,96	1,06	0,80	0,47
19	<i>tansig</i>	<i>tansig</i>	0,62	0,81	0,61	0,69
20	<i>logsig</i>	<i>logsig</i>	1,29	1,38	1,04	0,73

Fonte: Autoria própria (2023).

Tabela 31 - Performance do algoritmo *trainoss* para predição da DBO com banco de 125 dados sintéticos padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>elliotsig</i>	<i>elliotsig</i>	0,58	0,75	0,20	0,52
2	<i>logsig</i>	<i>elliotsig</i>	0,60	0,76	0,20	0,47
3	<i>tansig</i>	<i>purelin</i>	0,62	0,77	0,21	0,48
4	<i>purelin</i>	<i>tansig</i>	0,63	0,80	0,21	0,46
5	<i>logsig</i>	<i>purelin</i>	0,63	0,78	0,21	0,44
6	<i>tansig</i>	<i>purelin</i>	0,62	0,79	0,21	0,46

7	<i>logsig</i>	<i>elliotsig</i>	0,61	0,77	0,21	0,49
8	<i>logsig</i>	<i>purelin</i>	0,56	0,73	0,19	0,52
9	<i>tansig</i>	<i>purelin</i>	0,53	0,74	0,20	0,49
10	<i>logsig</i>	<i>tansig</i>	0,64	0,79	0,21	0,42
11	<i>logsig</i>	<i>elliotsig</i>	0,56	0,73	0,19	0,50
12	<i>logsig</i>	<i>tansig</i>	0,64	0,78	0,21	0,46
13	<i>logsig</i>	<i>elliotsig</i>	0,59	0,76	0,20	0,49
14	<i>purelin</i>	<i>elliotsig</i>	0,67	0,90	0,24	0,50
15	<i>elliotsig</i>	<i>tansig</i>	0,58	0,74	0,20	0,49
16	<i>logsig</i>	<i>purelin</i>	0,52	0,71	0,19	0,53
17	<i>purelin</i>	<i>purelin</i>	0,58	0,77	0,21	0,44
18	<i>logsig</i>	<i>tansig</i>	0,58	0,76	0,20	0,46
19	<i>elliotsig</i>	<i>tansig</i>	0,62	0,76	0,20	0,47
20	<i>purelin</i>	<i>purelin</i>	0,61	0,76	0,20	0,47

Fonte: Autoria própria (2023).

Tabela 32 - Performance do algoritmo *trainoss* para predição da DBO com banco de 1000 dados sintéticos padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>elliotsig</i>	<i>elliotsig</i>	0,52	0,65	0,17	0,60
2	<i>logsig</i>	<i>purelin</i>	0,53	0,65	0,17	0,57
3	<i>elliotsig</i>	<i>elliotsig</i>	0,53	0,66	0,17	0,60
4	<i>logsig</i>	<i>elliotsig</i>	0,57	0,69	0,18	0,50
5	<i>logsig</i>	<i>tansig</i>	0,52	0,64	0,17	0,58
6	<i>tansig</i>	<i>tansig</i>	0,51	0,63	0,16	0,60
7	<i>purelin</i>	<i>tansig</i>	0,56	0,68	0,18	0,55
8	<i>logsig</i>	<i>tansig</i>	0,55	0,67	0,18	0,55
9	<i>elliotsig</i>	<i>elliotsig</i>	0,56	0,70	0,18	0,50
10	<i>logsig</i>	<i>tansig</i>	0,51	0,66	0,17	0,53
11	<i>logsig</i>	<i>tansig</i>	0,54	0,66	0,17	0,54
12	<i>logsig</i>	<i>tansig</i>	0,56	0,69	0,18	0,52
13	<i>logsig</i>	<i>tansig</i>	0,55	0,68	0,18	0,53
14	<i>elliotsig</i>	<i>elliotsig</i>	0,53	0,66	0,17	0,57
15	<i>elliotsig</i>	<i>elliotsig</i>	0,52	0,66	0,17	0,56
16	<i>elliotsig</i>	<i>purelin</i>	0,52	0,66	0,17	0,54
17	<i>logsig</i>	<i>purelin</i>	0,52	0,65	0,17	0,55
18	<i>tansig</i>	<i>elliotsig</i>	0,53	0,67	0,18	0,54
19	<i>logsig</i>	<i>tansig</i>	0,53	0,66	0,17	0,54
20	<i>elliotsig</i>	<i>elliotsig</i>	0,49	0,65	0,17	0,59

Fonte: Autoria própria (2023).

Tabela 33 - Performance do algoritmo *trainoss* para predição da DBO com banco de dados experimentais normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>elliotsig</i>	<i>elliotsig</i>	0,12	0,14	0,40	0,66
2	<i>purelin</i>	<i>tansig</i>	0,11	0,11	0,33	0,41
3	<i>tansig</i>	<i>elliotsig</i>	0,27	0,36	1,05	0,80
4	<i>purelin</i>	<i>purelin</i>	0,51	0,58	1,71	0,30
5	<i>purelin</i>	<i>purelin</i>	0,16	0,19	0,56	0,68
6	<i>tansig</i>	<i>logsig</i>	0,36	0,38	1,11	0,15
7	<i>elliotsig</i>	<i>purelin</i>	0,24	0,26	0,75	0,88
8	<i>tansig</i>	<i>elliotsig</i>	0,11	0,12	0,34	0,89
9	<i>purelin</i>	<i>tansig</i>	0,41	0,52	1,51	0,63
10	<i>tansig</i>	<i>tansig</i>	0,18	0,24	0,69	0,86
11	<i>purelin</i>	<i>purelin</i>	0,44	0,51	1,48	0,16
12	<i>elliotsig</i>	<i>purelin</i>	0,05	0,06	0,18	0,87
13	<i>logsig</i>	<i>elliotsig</i>	0,12	0,14	0,42	0,56
14	<i>elliotsig</i>	<i>elliotsig</i>	0,09	0,12	0,34	0,12
15	<i>tansig</i>	<i>elliotsig</i>	0,11	0,16	0,46	0,42
16	<i>purelin</i>	<i>tansig</i>	0,31	0,48	1,40	0,45
17	<i>purelin</i>	<i>purelin</i>	0,30	0,36	1,06	0,88
18	<i>tansig</i>	<i>logsig</i>	0,34	0,36	1,05	0,80
19	<i>elliotsig</i>	<i>elliotsig</i>	0,21	0,22	0,64	0,86
20	<i>tansig</i>	<i>tansig</i>	0,24	0,29	0,86	0,29

Fonte: Autoria própria (2023).

Tabela 34 – Performance do algoritmo *trainoss* para predição da DBO com banco de 125 dados sintéticos normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>tansig</i>	<i>purelin</i>	0,14	0,18	0,20	0,49
2	<i>logsig</i>	<i>purelin</i>	0,15	0,18	0,20	0,47
3	<i>purelin</i>	<i>elliotsig</i>	0,15	0,18	0,20	0,51
4	<i>elliotsig</i>	<i>elliotsig</i>	0,15	0,18	0,21	0,48
5	<i>purelin</i>	<i>tansig</i>	0,23	0,19	0,19	0,65
6	<i>tansig</i>	<i>purelin</i>	0,15	0,19	0,21	0,48
7	<i>logsig</i>	<i>elliotsig</i>	0,14	0,18	0,20	0,49
8	<i>elliotsig</i>	<i>purelin</i>	0,25	0,18	0,19	0,70
9	<i>elliotsig</i>	<i>tansig</i>	0,14	0,18	0,20	0,50
10	<i>logsig</i>	<i>tansig</i>	0,15	0,19	0,21	0,45
11	<i>logsig</i>	<i>elliotsig</i>	0,15	0,18	0,21	0,47

12	<i>elliotsig</i>	<i>elliotsig</i>	0,16	0,13	0,16	0,83
13	<i>logsig</i>	<i>purelin</i>	0,14	0,18	0,20	0,47
14	<i>tansig</i>	<i>purelin</i>	0,14	0,18	0,20	0,46
15	<i>elliotsig</i>	<i>purelin</i>	0,14	0,18	0,20	0,47
16	<i>logsig</i>	<i>purelin</i>	0,15	0,18	0,20	0,49
17	<i>elliotsig</i>	<i>elliotsig</i>	0,16	0,19	0,22	0,40
18	<i>logsig</i>	<i>tansig</i>	0,14	0,19	0,21	0,44
19	<i>logsig</i>	<i>elliotsig</i>	0,38	0,23	0,25	0,69
20	<i>purelin</i>	<i>purelin</i>	0,16	0,19	0,21	0,41

Fonte: Autoria própria (2023).

Tabela 35 - Performance do algoritmo *trainoss* para predição da DBO com banco de 1000 dados sintéticos normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>elliotsig</i>	<i>purelin</i>	0,11	0,13	0,17	0,57
2	<i>logsig</i>	<i>purelin</i>	0,11	0,14	0,19	0,50
3	<i>elliotsig</i>	<i>elliotsig</i>	0,11	0,13	0,17	0,59
4	<i>logsig</i>	<i>elliotsig</i>	0,12	0,14	0,18	0,51
5	<i>logsig</i>	<i>tansig</i>	0,11	0,14	0,19	0,58
6	<i>logsig</i>	<i>tansig</i>	0,11	0,13	0,17	0,54
7	<i>logsig</i>	<i>tansig</i>	0,11	0,13	0,17	0,57
8	<i>purelin</i>	<i>purelin</i>	0,11	0,14	0,18	0,51
9	<i>logsig</i>	<i>tansig</i>	0,11	0,13	0,18	0,55
10	<i>elliotsig</i>	<i>elliotsig</i>	0,10	0,13	0,17	0,55
11	<i>tansig</i>	<i>tansig</i>	0,10	0,13	0,18	0,56
12	<i>logsig</i>	<i>tansig</i>	0,11	0,14	0,18	0,51
13	<i>logsig</i>	<i>elliotsig</i>	0,11	0,14	0,18	0,52
14	<i>elliotsig</i>	<i>elliotsig</i>	0,10	0,13	0,17	0,57
15	<i>elliotsig</i>	<i>elliotsig</i>	0,11	0,13	0,18	0,54
16	<i>elliotsig</i>	<i>purelin</i>	0,11	0,13	0,18	0,54
17	<i>logsig</i>	<i>purelin</i>	0,11	0,13	0,18	0,52
18	<i>elliotsig</i>	<i>elliotsig</i>	0,11	0,13	0,17	0,53
19	<i>purelin</i>	<i>purelin</i>	0,11	0,13	0,18	0,55
20	<i>elliotsig</i>	<i>elliotsig</i>	0,10	0,14	0,18	0,57

Fonte: Autoria própria (2023).

- Algoritmo *trainlm* para a predição de DQO

Para o algoritmo de treinamento *trainlm* e banco de dados experimentais, 125 e 1000 dados sintéticos, estão representadas, respectivamente nas tabelas 36, 37 e 38 as melhores RNA

para esses bancos de dados padronizados, e nas tabelas 39, 40 e 41 as melhores RNA para esses bancos de dados normalizados

Tabela 36 - Performance do algoritmo *trainlm* para predição da DQO com banco de dados experimentais padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	logsig	logsig	0,61	0,72	0,47	0,46
2	<i>tansig</i>	<i>tansig</i>	1,31	1,61	1,04	0,38
3	<i>elliotsig</i>	<i>logsig</i>	0,67	0,82	0,53	0,34
4	<i>elliotsig</i>	<i>logsig</i>	0,61	0,73	0,47	0,34
5	<i>purelin</i>	<i>tansig</i>	1,28	1,46	0,95	0,73
6	<i>tansig</i>	<i>purelin</i>	1,23	1,41	0,91	0,80
7	<i>tansig</i>	<i>tansig</i>	0,99	1,37	0,89	0,38
8	<i>logsig</i>	<i>purelin</i>	1,37	1,73	1,12	0,62
9	<i>tansig</i>	<i>purelin</i>	1,63	2,06	1,33	0,42
10	<i>elliotsig</i>	<i>logsig</i>	0,67	0,83	0,54	0,34
11	<i>elliotsig</i>	<i>elliotsig</i>	1,39	1,57	1,02	0,94
12	<i>elliotsig</i>	<i>logsig</i>	0,80	1,07	0,69	0,34
13	<i>purelin</i>	<i>logsig</i>	0,62	0,74	0,48	0,34
14	<i>purelin</i>	<i>elliotsig</i>	1,60	1,72	1,11	0,66
15	<i>logsig</i>	<i>logsig</i>	0,70	0,87	0,57	0,34
16	<i>tansig</i>	<i>elliotsig</i>	1,25	1,34	0,87	0,43
17	<i>elliotsig</i>	<i>elliotsig</i>	1,33	1,47	0,95	0,51
18	<i>elliotsig</i>	<i>logsig</i>	0,80	1,06	0,68	0,34
19	<i>purelin</i>	<i>elliotsig</i>	1,96	2,04	1,32	0,80
20	<i>tansig</i>	<i>logsig</i>	0,98	1,42	0,92	0,34

Fonte: Autoria própria (2023).

Tabela 37 - Performance do algoritmo *trainlm* para predição da DQO com banco de 125 dados sintéticos padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>tansig</i>	<i>elliotsig</i>	0,60	0,71	0,21	0,50
2	<i>purelin</i>	<i>purelin</i>	0,54	0,68	0,19	0,52
3	<i>tansig</i>	<i>tansig</i>	0,54	0,66	0,19	0,58
4	<i>purelin</i>	<i>elliotsig</i>	0,58	0,70	0,20	0,53
5	<i>tansig</i>	<i>tansig</i>	0,60	0,73	0,21	0,52
6	<i>purelin</i>	<i>tansig</i>	0,55	0,65	0,19	0,56
7	<i>purelin</i>	<i>tansig</i>	0,57	0,71	0,20	0,49

8	<i>tansig</i>	<i>elliotsig</i>	0,55	0,67	0,19	0,59
9	<i>purelin</i>	<i>purelin</i>	0,55	0,68	0,20	0,51
10	<i>purelin</i>	<i>purelin</i>	0,57	0,71	0,20	0,48
11	<i>purelin</i>	<i>purelin</i>	0,57	0,71	0,20	0,48
12	<i>purelin</i>	<i>purelin</i>	0,57	0,71	0,20	0,48
13	<i>tansig</i>	<i>elliotsig</i>	0,56	0,71	0,20	0,49
14	<i>purelin</i>	<i>purelin</i>	0,57	0,71	0,20	0,48
15	<i>purelin</i>	<i>purelin</i>	0,57	0,71	0,20	0,48
16	<i>logsig</i>	<i>elliotsig</i>	0,55	0,66	0,19	0,57
17	<i>purelin</i>	<i>purelin</i>	0,57	0,71	0,20	0,49
18	<i>purelin</i>	<i>tansig</i>	0,54	0,68	0,20	0,53
19	<i>purelin</i>	<i>elliotsig</i>	0,60	0,72	0,21	0,49
20	<i>purelin</i>	<i>purelin</i>	0,57	0,71	0,20	0,48

Fonte: Autoria própria (2023).

Tabela 38 - Performance do algoritmo *trainlm* para predição da DQO com banco de 1000 dados sintéticos padronizados

NCO	Características da RNA		Medidas de performance			
	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>logsig</i>	<i>purelin</i>	0,64	0,78	0,21	0,34
2	<i>elliotsig</i>	<i>purelin</i>	0,61	0,77	0,21	0,36
3	<i>purelin</i>	<i>purelin</i>	0,64	0,78	0,21	0,35
4	<i>purelin</i>	<i>elliotsig</i>	0,66	0,79	0,21	0,32
5	<i>elliotsig</i>	<i>purelin</i>	0,60	0,75	0,20	0,38
6	<i>purelin</i>	<i>purelin</i>	0,64	0,78	0,21	0,35
7	<i>purelin</i>	<i>tansig</i>	0,65	0,77	0,21	0,34
8	<i>purelin</i>	<i>elliotsig</i>	0,67	0,79	0,21	0,33
9	<i>purelin</i>	<i>purelin</i>	0,64	0,78	0,21	0,35
10	<i>purelin</i>	<i>purelin</i>	0,64	0,78	0,21	0,35
11	<i>purelin</i>	<i>purelin</i>	0,64	0,78	0,21	0,34
12	<i>purelin</i>	<i>purelin</i>	0,64	0,78	0,21	0,35
13	<i>purelin</i>	<i>tansig</i>	0,65	0,77	0,21	0,36
14	<i>purelin</i>	<i>tansig</i>	0,66	0,78	0,21	0,33
15	<i>purelin</i>	<i>purelin</i>	0,64	0,78	0,21	0,35
16	<i>purelin</i>	<i>purelin</i>	0,64	0,78	0,21	0,35
17	<i>purelin</i>	<i>purelin</i>	0,64	0,78	0,21	0,35
18	<i>purelin</i>	<i>purelin</i>	0,64	0,78	0,21	0,35
19	<i>purelin</i>	<i>tansig</i>	0,65	0,77	0,21	0,35
20	<i>purelin</i>	<i>purelin</i>	0,64	0,78	0,21	0,35

Fonte: Autoria própria (2023).

Tabela 39 - Performance do algoritmo *trainlm* para predição da DQO com banco de dados experimentais normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>purelin</i>	<i>logsig</i>	0.18	0.21	0.51	0.34
2	<i>purelin</i>	<i>elliotsig</i>	0.30	0.34	0.82	0.53
3	<i>elliotsig</i>	<i>elliotsig</i>	0.31	0.35	0.85	0.46
4	<i>logsig</i>	<i>purelin</i>	0.33	0.42	1.02	0.48
5	<i>purelin</i>	<i>tansig</i>	0.34	0.39	0.93	0.79
6	<i>tansig</i>	<i>purelin</i>	0.27	0.32	0.77	0.72
7	<i>tansig</i>	<i>tansig</i>	0.32	0.38	0.91	0.52
8	<i>logsig</i>	<i>tansig</i>	0.31	0.38	0.92	0.75
9	<i>purelin</i>	<i>tansig</i>	0.36	0.42	1.01	0.55
10	<i>purelin</i>	<i>logsig</i>	0.16	0.19	0.47	0.42
11	<i>elliotsig</i>	<i>elliotsig</i>	0.38	0.42	1.00	0.93
12	<i>elliotsig</i>	<i>tansig</i>	0.35	0.40	0.97	0.69
13	<i>logsig</i>	<i>tansig</i>	0.28	0.34	0.82	0.49
14	<i>purelin</i>	<i>elliotsig</i>	0.31	0.36	0.87	0.63
15	<i>purelin</i>	<i>tansig</i>	0.39	0.47	1.14	0.55
16	<i>purelin</i>	<i>tansig</i>	0.38	0.42	1.01	0.71
17	<i>logsig</i>	<i>logsig</i>	0.20	0.25	0.61	0.34
18	<i>tansig</i>	<i>purelin</i>	0.45	0.66	1.60	0.34
19	<i>logsig</i>	<i>elliotsig</i>	0.30	0.32	0.78	0.85
20	<i>elliotsig</i>	<i>tansig</i>	0.52	0.56	1.34	0.68

Fonte: Autoria própria (2023).

Tabela 40 – Performance do algoritmo *trainlm* para predição da DQO com banco de 125 dados sintéticos normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>elliotsig</i>	<i>elliotsig</i>	0.16	0.19	0.20	0.53
2	<i>purelin</i>	<i>purelin</i>	0.15	0.18	0.19	0.52
3	<i>tansig</i>	<i>tansig</i>	0.15	0.18	0.20	0.55
4	<i>purelin</i>	<i>tansig</i>	0.15	0.18	0.19	0.55
5	<i>elliotsig</i>	<i>tansig</i>	0.15	0.18	0.20	0.54
6	<i>logsig</i>	<i>tansig</i>	0.15	0.18	0.19	0.55
7	<i>logsig</i>	<i>logsig</i>	0.19	0.24	0.26	0.44
8	<i>purelin</i>	<i>purelin</i>	0.15	0.18	0.20	0.53
9	<i>purelin</i>	<i>purelin</i>	0.15	0.18	0.20	0.51
10	<i>elliotsig</i>	<i>purelin</i>	0.16	0.19	0.20	0.56
11	<i>purelin</i>	<i>purelin</i>	0.15	0.19	0.20	0.49

12	<i>purelin</i>	<i>purelin</i>	0.15	0.19	0.20	0.48
13	<i>logsig</i>	<i>elliotsig</i>	0.16	0.18	0.20	0.51
14	<i>logsig</i>	<i>tansig</i>	0.16	0.22	0.23	0.52
15	<i>purelin</i>	<i>tansig</i>	0.15	0.18	0.20	0.56
16	<i>logsig</i>	<i>elliotsig</i>	0.14	0.17	0.19	0.58
17	<i>purelin</i>	<i>purelin</i>	0.15	0.19	0.20	0.49
18	<i>purelin</i>	<i>tansig</i>	0.15	0.18	0.19	0.55
19	<i>purelin</i>	<i>purelin</i>	0.15	0.19	0.20	0.48
20	<i>purelin</i>	<i>tansig</i>	0.15	0.18	0.19	0.55

Fonte: Autoria própria (2023).

Tabela 41 - Performance do algoritmo *trainlm* para predição da DQO com banco de 1000 dados sintéticos normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>logsig</i>	<i>tansig</i>	0.17	0.21	0.21	0.33
2	<i>purelin</i>	<i>purelin</i>	0.17	0.21	0.21	0.35
3	<i>purelin</i>	<i>purelin</i>	0.17	0.21	0.21	0.35
4	<i>purelin</i>	<i>tansig</i>	0.17	0.20	0.21	0.35
5	<i>purelin</i>	<i>purelin</i>	0.17	0.21	0.21	0.35
6	<i>purelin</i>	<i>purelin</i>	0.17	0.21	0.21	0.35
7	<i>purelin</i>	<i>purelin</i>	0.17	0.21	0.21	0.33
8	<i>tansig</i>	<i>tansig</i>	0.17	0.21	0.21	0.33
9	<i>purelin</i>	<i>purelin</i>	0.17	0.21	0.21	0.35
10	<i>purelin</i>	<i>purelin</i>	0.17	0.21	0.21	0.35
11	<i>purelin</i>	<i>purelin</i>	0.17	0.21	0.21	0.34
12	<i>purelin</i>	<i>purelin</i>	0.17	0.21	0.21	0.35
13	<i>logsig</i>	<i>purelin</i>	0.17	0.20	0.21	0.36
14	<i>purelin</i>	<i>tansig</i>	0.17	0.21	0.21	0.33
15	<i>purelin</i>	<i>purelin</i>	0.17	0.21	0.21	0.35
16	<i>purelin</i>	<i>purelin</i>	0.17	0.21	0.21	0.35
17	<i>purelin</i>	<i>purelin</i>	0.17	0.21	0.21	0.35
18	<i>purelin</i>	<i>purelin</i>	0.17	0.21	0.21	0.35
19	<i>logsig</i>	<i>purelin</i>	0.17	0.20	0.21	0.38
20	<i>purelin</i>	<i>purelin</i>	0.17	0.21	0.21	0.35

Fonte: Autoria própria (2023).

- Algoritmo *trainbr* para a predição de DQO

Para o algoritmo de treinamento *trainbr* e banco de dados experimentais, 125 e 1000 dados sintéticos, estão representadas, respectivamente nas tabelas 42, 43 e 44 as melhores RNA

para esses bancos de dados padronizados, e nas tabelas 45, 46 e 47 as melhores RNA para esses bancos de dados normalizados

Tabela 42 – Performance do algoritmo *trainbr* para predição da DQO com banco de dados experimentais padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>logsig</i>	<i>logsig</i>	0,74	0,96	0,62	0,32
2	<i>logsig</i>	<i>logsig</i>	0,74	0,94	0,61	0,34
3	<i>logsig</i>	<i>logsig</i>	0,74	0,96	0,62	0,32
4	<i>logsig</i>	<i>logsig</i>	0,75	0,97	0,63	0,33
5	<i>logsig</i>	<i>logsig</i>	0,74	0,97	0,63	0,32
6	<i>logsig</i>	<i>logsig</i>	0,73	0,95	0,61	0,32
7	<i>logsig</i>	<i>logsig</i>	0,73	0,94	0,61	0,32
8	<i>logsig</i>	<i>logsig</i>	0,73	0,94	0,61	0,32
9	<i>logsig</i>	<i>logsig</i>	0,73	0,95	0,61	0,32
10	<i>logsig</i>	<i>logsig</i>	0,75	0,98	0,63	0,33
11	<i>logsig</i>	<i>tansig</i>	0,60	0,64	0,42	0,68
12	<i>logsig</i>	<i>logsig</i>	0,75	0,98	0,64	0,33
13	<i>logsig</i>	<i>logsig</i>	0,75	0,98	0,64	0,33
14	<i>elliotsig</i>	<i>logsig</i>	0,74	0,97	0,63	0,30
15	<i>purelin</i>	<i>purelin</i>	1,18	1,46	0,95	0,28
16	<i>elliotsig</i>	<i>logsig</i>	0,72	0,94	0,61	0,29
17	<i>logsig</i>	<i>logsig</i>	0,76	0,98	0,64	0,33
18	<i>tansig</i>	<i>elliotsig</i>	0,97	1,20	0,78	0,84
19	<i>logsig</i>	<i>purelin</i>	1,19	1,47	0,95	0,29
20	<i>logsig</i>	<i>tansig</i>	0,70	0,76	0,49	0,30

Fonte: Autoria própria (2023).

Tabela 43 – Performance do algoritmo *trainbr* para predição da DQO com banco de 125 dados sintéticos padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>logsig</i>	<i>purelin</i>	0,54	0,66	0,19	0,56
2	<i>purelin</i>	<i>purelin</i>	0,54	0,67	0,19	0,56
3	<i>purelin</i>	<i>purelin</i>	0,54	0,67	0,19	0,56
4	<i>purelin</i>	<i>purelin</i>	0,54	0,67	0,19	0,56
5	<i>logsig</i>	<i>purelin</i>	0,79	0,97	0,28	0,57
6	<i>purelin</i>	<i>purelin</i>	0,54	0,67	0,19	0,56
7	<i>purelin</i>	<i>purelin</i>	0,54	0,67	0,19	0,56
8	<i>purelin</i>	<i>purelin</i>	0,54	0,67	0,19	0,56
9	<i>purelin</i>	<i>purelin</i>	0,54	0,67	0,19	0,56

10	<i>logsig</i>	<i>purelin</i>	0,79	0,97	0,28	0,57
11	<i>logsig</i>	<i>tansig</i>	0,79	0,97	0,28	0,57
12	<i>logsig</i>	<i>elliotsig</i>	0,79	0,98	0,28	0,57
13	<i>logsig</i>	<i>elliotsig</i>	0,79	0,98	0,28	0,57
14	<i>logsig</i>	<i>elliotsig</i>	0,79	0,98	0,28	0,57
15	<i>logsig</i>	<i>elliotsig</i>	0,79	0,98	0,28	0,57
16	<i>logsig</i>	<i>elliotsig</i>	0,79	0,98	0,28	0,57
17	<i>logsig</i>	<i>elliotsig</i>	0,79	0,98	0,28	0,58
18	<i>logsig</i>	<i>elliotsig</i>	0,79	0,98	0,28	0,57
19	<i>logsig</i>	<i>elliotsig</i>	0,79	0,98	0,28	0,57
20	<i>logsig</i>	<i>elliotsig</i>	0,79	0,98	0,28	0,58

Fonte: Autoria própria (2023).

Tabela 44 – Performance do algoritmo *trainbr* para predição da DQO com banco de 1000 dados sintéticos padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>purelin</i>	<i>purelin</i>	0,65	0,78	0,21	0,34
2	<i>purelin</i>	<i>purelin</i>	0,65	0,78	0,21	0,34
3	<i>purelin</i>	<i>purelin</i>	0,65	0,78	0,21	0,34
4	<i>elliotsig</i>	<i>purelin</i>	0,64	0,78	0,21	0,34
5	<i>elliotsig</i>	<i>tansig</i>	0,62	0,77	0,21	0,35
6	<i>elliotsig</i>	<i>purelin</i>	0,64	0,78	0,21	0,34
7	<i>elliotsig</i>	<i>purelin</i>	0,64	0,78	0,21	0,34
8	<i>elliotsig</i>	<i>purelin</i>	0,64	0,78	0,21	0,34
9	<i>elliotsig</i>	<i>purelin</i>	0,64	0,78	0,21	0,34
10	<i>elliotsig</i>	<i>purelin</i>	0,64	0,78	0,21	0,34
11	<i>elliotsig</i>	<i>purelin</i>	0,64	0,78	0,21	0,34
12	<i>elliotsig</i>	<i>purelin</i>	0,62	0,77	0,21	0,34
13	<i>elliotsig</i>	<i>purelin</i>	0,64	0,78	0,21	0,34
14	<i>elliotsig</i>	<i>purelin</i>	0,62	0,77	0,21	0,34
15	<i>elliotsig</i>	<i>purelin</i>	0,64	0,78	0,21	0,34
16	<i>elliotsig</i>	<i>purelin</i>	0,64	0,78	0,21	0,34
17	<i>elliotsig</i>	<i>purelin</i>	0,64	0,78	0,21	0,34
18	<i>elliotsig</i>	<i>purelin</i>	0,64	0,78	0,21	0,34
19	<i>elliotsig</i>	<i>purelin</i>	0,64	0,78	0,21	0,34
20	<i>elliotsig</i>	<i>purelin</i>	0,64	0,78	0,21	0,34

Fonte: Autoria própria (2023).

Tabela 45 – Performance do algoritmo *trainbr* para predição da DQO com banco de dados experimentais normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	tansig	logsig	0.22	0.30	0.72	0.33
2	elliotsig	purelin	0.23	0.26	0.62	0.82
3	logsig	elliotsig	0.16	0.18	0.44	0.90
4	elliotsig	purelin	0.16	0.18	0.44	0.35
5	elliotsig	purelin	0.36	0.42	1.01	0.74
6	purelin	tansig	0.39	0.43	1.04	0.34
7	logsig	logsig	0.20	0.25	0.61	0.32
8	logsig	logsig	0.20	0.26	0.61	0.32
9	logsig	logsig	0.20	0.26	0.62	0.32
10	logsig	logsig	0.20	0.26	0.62	0.33
11	logsig	logsig	0.20	0.26	0.63	0.33
12	logsig	logsig	0.20	0.26	0.63	0.33
13	logsig	logsig	0.20	0.26	0.64	0.33
14	elliotsig	logsig	0.21	0.28	0.68	0.34
15	logsig	logsig	0.20	0.26	0.64	0.33
16	logsig	elliotsig	0.15	0.17	0.42	0.52
17	tansig	elliotsig	0.13	0.17	0.41	0.57
18	tansig	elliotsig	0.26	0.32	0.78	0.84
19	purelin	purelin	0.17	0.19	0.47	0.28
20	purelin	purelin	0.18	0.20	0.48	0.28

Fonte: Autoria própria (2023).

Tabela 46 – Performance do algoritmo *trainbr* para predição da DQO com banco de 125 dados sintéticos normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	tansig	purelin	0,14	0,17	0,18	0,59
2	purelin	purelin	0,15	0,18	0,19	0,56
3	purelin	purelin	0,15	0,18	0,19	0,56
4	purelin	purelin	0,15	0,18	0,19	0,56
5	logsig	purelin	0,21	0,26	0,28	0,57
6	purelin	purelin	0,15	0,18	0,19	0,56
7	purelin	purelin	0,15	0,18	0,19	0,56
8	purelin	purelin	0,15	0,18	0,19	0,56
9	purelin	purelin	0,15	0,18	0,19	0,56
10	logsig	purelin	0,21	0,26	0,28	0,57

11	<i>logsig</i>	<i>tansig</i>	0,21	0,26	0,28	0,57
12	<i>elliotsig</i>	<i>tansig</i>	0,21	0,26	0,28	0,58
13	<i>tansig</i>	<i>elliotsig</i>	0,21	0,26	0,28	0,57
14	<i>elliotsig</i>	<i>elliotsig</i>	0,21	0,26	0,28	0,59
15	<i>tansig</i>	<i>purelin</i>	0,21	0,26	0,28	0,59
16	<i>logsig</i>	<i>tansig</i>	0,21	0,26	0,28	0,57
17	<i>logsig</i>	<i>tansig</i>	0,21	0,26	0,28	0,57
18	<i>logsig</i>	<i>elliotsig</i>	0,21	0,26	0,28	0,58
19	<i>logsig</i>	<i>elliotsig</i>	0,21	0,26	0,28	0,58
20	<i>logsig</i>	<i>elliotsig</i>	0,21	0,26	0,28	0,58

Fonte: Autoria própria (2023).

Tabela 47 - Performance do algoritmo *trainbr* para predição da DQO com banco de 1000 dados sintéticos normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>purelin</i>	<i>purelin</i>	0.17	0.21	0.21	0.34
2	<i>purelin</i>	<i>purelin</i>	0.17	0.21	0.21	0.34
3	<i>purelin</i>	<i>purelin</i>	0.17	0.21	0.21	0.34
4	<i>elliotsig</i>	<i>purelin</i>	0.17	0.21	0.21	0.34
5	<i>elliotsig</i>	<i>tansig</i>	0.16	0.20	0.21	0.35
6	<i>elliotsig</i>	<i>purelin</i>	0.17	0.21	0.21	0.34
7	<i>elliotsig</i>	<i>purelin</i>	0.17	0.21	0.21	0.34
8	<i>elliotsig</i>	<i>purelin</i>	0.17	0.21	0.21	0.34
9	<i>elliotsig</i>	<i>purelin</i>	0.17	0.21	0.21	0.34
10	<i>elliotsig</i>	<i>purelin</i>	0.17	0.21	0.21	0.34
11	<i>elliotsig</i>	<i>purelin</i>	0.17	0.21	0.21	0.34
12	<i>elliotsig</i>	<i>purelin</i>	0.16	0.20	0.21	0.34
13	<i>elliotsig</i>	<i>purelin</i>	0.17	0.21	0.21	0.34
14	<i>elliotsig</i>	<i>purelin</i>	0.16	0.20	0.21	0.34
15	<i>elliotsig</i>	<i>purelin</i>	0.17	0.21	0.21	0.34
16	<i>elliotsig</i>	<i>purelin</i>	0.17	0.21	0.21	0.34
17	<i>elliotsig</i>	<i>purelin</i>	0.17	0.21	0.21	0.34
18	<i>elliotsig</i>	<i>purelin</i>	0.17	0.21	0.21	0.34
19	<i>elliotsig</i>	<i>purelin</i>	0.17	0.21	0.21	0.34
20	<i>elliotsig</i>	<i>purelin</i>	0.17	0.21	0.21	0.34

Fonte: Autoria própria (2023).

- Algoritmo *traingd* para a predição de DQO

Para o algoritmo de treinamento *traingd* e banco de dados experimentais, 125 e 1000 dados sintéticos, estão representadas, respectivamente nas tabelas 48, 49 e 50 as melhores RNA para esses bancos de dados padronizados, e nas tabelas 51, 52 e 53 as melhores RNA para esses bancos de dados normalizados

Tabela 48 - Performance do algoritmo *traingd* para predição da DQO com banco de dados experimentais padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>logsig</i>	<i>elliotsig</i>	0,63	0,79	0,51	0,91
2	<i>purelin</i>	<i>elliotsig</i>	0,98	1,15	0,75	0,56
3	<i>elliotsig</i>	<i>purelin</i>	1,23	1,41	0,91	0,58
4	<i>logsig</i>	<i>elliotsig</i>	1,08	1,25	0,81	0,43
5	<i>purelin</i>	<i>purelin</i>	1,60	2,00	1,30	0,77
6	<i>purelin</i>	<i>elliotsig</i>	1,48	1,56	1,01	0,89
7	<i>elliotsig</i>	<i>purelin</i>	1,53	1,79	1,16	0,71
8	<i>elliotsig</i>	<i>elliotsig</i>	1,15	1,24	0,80	0,49
9	<i>tansig</i>	<i>elliotsig</i>	1,26	1,40	0,91	0,70
10	<i>logsig</i>	<i>tansig</i>	1,19	1,40	0,91	0,57
11	<i>tansig</i>	<i>tansig</i>	1,41	1,53	0,99	0,83
12	<i>elliotsig</i>	<i>purelin</i>	1,41	1,66	1,08	0,67
13	<i>elliotsig</i>	<i>purelin</i>	1,62	2,18	1,41	0,63
14	<i>tansig</i>	<i>purelin</i>	0,24	0,36	0,24	0,85
15	<i>purelin</i>	<i>purelin</i>	1,26	1,59	1,03	0,60
16	<i>elliotsig</i>	<i>elliotsig</i>	0,47	0,57	0,37	0,69
17	<i>logsig</i>	<i>elliotsig</i>	1,17	1,27	0,83	0,79
18	<i>logsig</i>	<i>tansig</i>	1,21	1,40	0,91	0,65
19	<i>tansig</i>	<i>elliotsig</i>	0,75	0,77	0,50	0,91
20	<i>purelin</i>	<i>elliotsig</i>	1,25	1,37	0,89	0,93

Fonte: Autoria própria (2023).

Tabela 49 - Performance do algoritmo *traingd* para predição da DQO com banco de 125 dados sintéticos padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>tansig</i>	<i>tansig</i>	0,54	0,67	0,19	0,61
2	<i>purelin</i>	<i>purelin</i>	0,55	0,66	0,19	0,64
3	<i>purelin</i>	<i>tansig</i>	0,56	0,70	0,20	0,51
4	<i>logsig</i>	<i>tansig</i>	0,59	0,71	0,21	0,53
5	<i>logsig</i>	<i>tansig</i>	0,53	0,69	0,20	0,59

6	<i>purelin</i>	<i>elliotsig</i>	0,54	0,68	0,20	0,54
7	<i>logsig</i>	<i>tansig</i>	0,60	0,72	0,21	0,57
8	<i>elliotsig</i>	<i>tansig</i>	0,53	0,67	0,19	0,55
9	<i>logsig</i>	<i>purelin</i>	0,56	0,70	0,20	0,52
10	<i>purelin</i>	<i>purelin</i>	0,57	0,70	0,20	0,49
11	<i>logsig</i>	<i>purelin</i>	0,57	0,70	0,20	0,57
12	<i>purelin</i>	<i>logsig</i>	0,73	0,91	0,26	0,55
13	<i>logsig</i>	<i>elliotsig</i>	0,52	0,63	0,18	0,65
14	<i>logsig</i>	<i>elliotsig</i>	0,57	0,70	0,20	0,61
15	<i>purelin</i>	<i>elliotsig</i>	0,54	0,66	0,19	0,58
16	<i>logsig</i>	<i>tansig</i>	0,55	0,69	0,20	0,56
17	<i>logsig</i>	<i>logsig</i>	0,79	0,97	0,28	0,60
18	<i>purelin</i>	<i>tansig</i>	1,04	1,21	0,35	0,49
19	<i>logsig</i>	<i>elliotsig</i>	0,60	0,74	0,21	0,48
20	<i>logsig</i>	<i>tansig</i>	0,53	0,66	0,19	0,60

Fonte: Autoria própria (2023).

Tabela 50 - Performance do algoritmo *traingd* para predição da DQO com banco de 1000 dados sintéticos padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>purelin</i>	<i>tansig</i>	0,67	0,80	0,22	0,29
2	<i>purelin</i>	<i>tansig</i>	0,65	0,77	0,21	0,35
3	<i>purelin</i>	<i>tansig</i>	0,66	0,78	0,21	0,33
4	<i>purelin</i>	<i>purelin</i>	0,65	0,78	0,21	0,35
5	<i>purelin</i>	<i>logsig</i>	0,74	0,93	0,25	0,27
6	<i>purelin</i>	<i>tansig</i>	0,66	0,78	0,21	0,33
7	<i>logsig</i>	<i>purelin</i>	0,68	0,80	0,22	0,29
8	<i>tansig</i>	<i>purelin</i>	0,63	0,76	0,20	0,37
9	<i>purelin</i>	<i>purelin</i>	0,63	0,78	0,21	0,34
10	<i>tansig</i>	<i>tansig</i>	0,63	0,76	0,21	0,37
11	<i>elliotsig</i>	<i>purelin</i>	0,65	0,78	0,21	0,34
12	<i>logsig</i>	<i>purelin</i>	0,64	0,78	0,21	0,34
13	<i>purelin</i>	<i>elliotsig</i>	0,66	0,79	0,21	0,32
14	<i>elliotsig</i>	<i>purelin</i>	0,62	0,74	0,20	0,40
15	<i>logsig</i>	<i>purelin</i>	0,64	0,77	0,21	0,36
16	<i>purelin</i>	<i>tansig</i>	0,66	0,78	0,21	0,34
17	<i>tansig</i>	<i>purelin</i>	0,62	0,77	0,21	0,37
18	<i>tansig</i>	<i>tansig</i>	0,66	0,80	0,22	0,32
19	<i>logsig</i>	<i>purelin</i>	0,59	0,74	0,20	0,39
20	<i>logsig</i>	<i>purelin</i>	0,64	0,76	0,21	0,36

Fonte: Autoria própria (2023).

Tabela 51 - Performance do algoritmo *traingd* para predição da DQO com banco de dados experimentais normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>logsig</i>	<i>elliotsig</i>	0,17	0,21	0,51	0,91
2	<i>tansig</i>	<i>tansig</i>	0,13	0,14	0,35	0,68
3	<i>tansig</i>	<i>tansig</i>	0,30	0,33	0,80	0,48
4	<i>tansig</i>	<i>tansig</i>	0,26	0,28	0,68	0,62
5	<i>purelin</i>	<i>purelin</i>	0,43	0,52	1,25	0,83
6	<i>purelin</i>	<i>elliotsig</i>	0,40	0,42	1,01	0,89
7	<i>elliotsig</i>	<i>purelin</i>	0,39	0,46	1,10	0,60
8	<i>elliotsig</i>	<i>elliotsig</i>	0,31	0,33	0,80	0,49
9	<i>purelin</i>	<i>purelin</i>	0,55	0,71	1,72	0,67
10	<i>tansig</i>	<i>elliotsig</i>	0,28	0,31	0,74	0,54
11	<i>tansig</i>	<i>tansig</i>	0,38	0,41	0,99	0,83
12	<i>logsig</i>	<i>tansig</i>	0,19	0,20	0,49	0,87
13	<i>logsig</i>	<i>purelin</i>	0,27	0,33	0,79	0,67
14	<i>tansig</i>	<i>purelin</i>	0,06	0,10	0,24	0,85
15	<i>purelin</i>	<i>logsig</i>	0,18	0,21	0,50	0,39
16	<i>logsig</i>	<i>elliotsig</i>	0,18	0,19	0,47	0,95
17	<i>tansig</i>	<i>logsig</i>	0,16	0,20	0,48	0,90
18	<i>logsig</i>	<i>tansig</i>	0,33	0,37	0,89	0,81
19	<i>tansig</i>	<i>elliotsig</i>	0,17	0,18	0,44	0,91
20	<i>logsig</i>	<i>logsig</i>	0,17	0,20	0,49	0,58

Fonte: Autoria própria (2023).

Tabela 52 - Performance do algoritmo *traingd* para predição da DQO com banco de 125 dados sintéticos normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>tansig</i>	<i>tansig</i>	0.17	0.2	0.21	0.54
2	<i>logsig</i>	<i>tansig</i>	0.17	0.2	0.22	0.52
3	<i>purelin</i>	<i>tansig</i>	0.16	0.2	0.22	0.54
4	<i>elliotsig</i>	<i>purelin</i>	0.18	0.21	0.23	0.53
5	<i>elliotsig</i>	<i>elliotsig</i>	0.14	0.19	0.2	0.51
6	<i>tansig</i>	<i>logsig</i>	0.24	0.29	0.31	0.52
7	<i>purelin</i>	<i>tansig</i>	0.19	0.24	0.26	0.52
8	<i>elliotsig</i>	<i>tansig</i>	0.14	0.18	0.19	0.55
9	<i>purelin</i>	<i>tansig</i>	0.16	0.2	0.22	0.44
10	<i>tansig</i>	<i>logsig</i>	0.26	0.29	0.32	0.5
11	<i>logsig</i>	<i>tansig</i>	0.14	0.18	0.19	0.56

12	<i>purelin</i>	<i>purelin</i>	0.14	0.18	0.19	0.61
13	<i>logsig</i>	<i>elliotsig</i>	0.11	0.15	0.16	0.69
14	<i>purelin</i>	<i>purelin</i>	0.15	0.18	0.2	0.55
15	<i>purelin</i>	<i>elliotsig</i>	0.15	0.18	0.19	0.58
16	<i>purelin</i>	<i>purelin</i>	0.16	0.2	0.22	0.46
17	<i>purelin</i>	<i>purelin</i>	0.15	0.18	0.2	0.57
18	<i>purelin</i>	<i>tansig</i>	0.28	0.32	0.35	0.49
19	<i>purelin</i>	<i>purelin</i>	0.15	0.19	0.2	0.5
20	<i>tansig</i>	<i>tansig</i>	0.13	0.17	0.18	0.73

Fonte: Autoria própria (2023).

Tabela 53 – Performance do algoritmo *traingd* para predição da DQO com banco de 1000 dados sintéticos normalizados

NCO	Características da RNA		Medidas de performance			
	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>tansig</i>	<i>tansig</i>	0,19	0,23	0,23	0,19
2	<i>elliotsig</i>	<i>purelin</i>	0,23	0,29	0,29	0,22
3	<i>purelin</i>	<i>purelin</i>	0,19	0,22	0,22	0,25
4	<i>purelin</i>	<i>purelin</i>	0,19	0,22	0,22	0,26
5	<i>elliotsig</i>	<i>elliotsig</i>	0,19	0,23	0,24	0,19
6	<i>purelin</i>	<i>purelin</i>	0,17	0,21	0,21	0,31
7	<i>tansig</i>	<i>purelin</i>	0,19	0,23	0,23	0,22
8	<i>purelin</i>	<i>purelin</i>	0,17	0,21	0,21	0,32
9	<i>purelin</i>	<i>purelin</i>	0,17	0,21	0,21	0,34
10	<i>tansig</i>	<i>tansig</i>	0,16	0,22	0,22	0,34
11	<i>purelin</i>	<i>purelin</i>	0,17	0,21	0,21	0,32
12	<i>elliotsig</i>	<i>logsig</i>	0,24	0,30	0,30	0,29
13	<i>purelin</i>	<i>purelin</i>	0,17	0,21	0,21	0,34
14	<i>purelin</i>	<i>purelin</i>	0,18	0,21	0,22	0,30
15	<i>purelin</i>	<i>purelin</i>	0,17	0,21	0,21	0,32
16	<i>purelin</i>	<i>purelin</i>	0,17	0,21	0,21	0,34
17	<i>logsig</i>	<i>logsig</i>	0,21	0,27	0,27	0,35
18	<i>purelin</i>	<i>purelin</i>	0,17	0,21	0,21	0,34
19	<i>logsig</i>	<i>purelin</i>	0,17	0,21	0,21	0,31
20	<i>purelin</i>	<i>purelin</i>	0,17	0,21	0,21	0,35

Fonte: Autoria própria (2023).

- Algoritmo *trainoss* para a predição de DQO

Para o algoritmo de treinamento *trainoss* e banco de dados experimentais, 125 e 1000 dados sintéticos, estão representadas, respectivamente nas tabelas 54, 55 e 56 as melhores RNA

para esses bancos de dados padronizados, e nas tabelas 57, 58 e 59 as melhores RNA para esses bancos de dados normalizados

Tabela 54 - Performance do algoritmo *trainoss* para predição da DQO com banco de dados experimentais padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>tansig</i>	<i>purelin</i>	1,66	1,95	1,26	0,43
2	<i>purelin</i>	<i>purelin</i>	2,04	2,40	1,55	0,64
3	<i>tansig</i>	<i>purelin</i>	1,40	1,58	1,03	0,81
4	<i>logsig</i>	<i>logsig</i>	0,61	0,73	0,47	0,46
5	<i>logsig</i>	<i>purelin</i>	1,33	1,57	1,02	0,65
6	<i>purelin</i>	<i>purelin</i>	2,08	2,66	1,73	0,70
7	<i>logsig</i>	<i>logsig</i>	1,15	1,35	0,87	0,97
8	<i>purelin</i>	<i>elliotsig</i>	1,39	1,57	1,02	0,84
9	<i>elliotsig</i>	<i>elliotsig</i>	1,22	1,41	0,92	0,42
10	<i>logsig</i>	<i>tansig</i>	1,08	1,34	0,87	0,43
11	<i>purelin</i>	<i>logsig</i>	0,95	1,04	0,67	0,59
12	<i>logsig</i>	<i>logsig</i>	0,60	0,78	0,51	0,88
13	<i>elliotsig</i>	<i>purelin</i>	1,74	2,03	1,32	0,67
14	<i>logsig</i>	<i>logsig</i>	0,78	1,02	0,66	0,82
15	<i>logsig</i>	<i>purelin</i>	1,49	1,79	1,16	0,64
16	<i>purelin</i>	<i>purelin</i>	1,97	2,39	1,55	0,72
17	<i>purelin</i>	<i>purelin</i>	1,28	1,75	1,13	0,64
18	<i>logsig</i>	<i>purelin</i>	1,60	1,84	1,20	0,77
19	<i>logsig</i>	<i>purelin</i>	1,36	1,63	1,06	0,77
20	<i>purelin</i>	<i>purelin</i>	3,04	3,77	2,44	0,65

Fonte: Autoria própria (2023).

Tabela 55 - Performance do algoritmo *trainoss* para predição da DQO com banco de 125 dados sintéticos padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>purelin</i>	<i>purelin</i>	0,70	0,82	0,24	0,60
2	<i>tansig</i>	<i>purelin</i>	0,52	0,66	0,19	0,62
3	<i>elliotsig</i>	<i>purelin</i>	0,58	0,70	0,20	0,59
4	<i>logsig</i>	<i>purelin</i>	0,53	0,67	0,19	0,58
5	<i>purelin</i>	<i>purelin</i>	0,54	0,64	0,18	0,61
6	<i>purelin</i>	<i>elliotsig</i>	0,57	0,69	0,20	0,60
7	<i>elliotsig</i>	<i>purelin</i>	0,53	0,64	0,19	0,62

8	<i>elliotsig</i>	<i>purelin</i>	0,50	0,64	0,19	0,59
9	<i>logsig</i>	<i>purelin</i>	0,54	0,63	0,18	0,61
10	<i>purelin</i>	<i>purelin</i>	0,53	0,64	0,18	0,57
11	<i>logsig</i>	<i>elliotsig</i>	0,55	0,65	0,19	0,59
12	<i>purelin</i>	<i>tansig</i>	0,66	0,82	0,24	0,57
13	<i>logsig</i>	<i>elliotsig</i>	0,59	0,70	0,20	0,52
14	<i>tansig</i>	<i>elliotsig</i>	0,54	0,65	0,19	0,57
15	<i>tansig</i>	<i>purelin</i>	0,62	0,75	0,22	0,51
16	<i>logsig</i>	<i>tansig</i>	0,56	0,70	0,20	0,55
17	<i>purelin</i>	<i>elliotsig</i>	0,59	0,72	0,21	0,58
18	<i>logsig</i>	<i>tansig</i>	0,58	0,72	0,21	0,59
19	<i>purelin</i>	<i>elliotsig</i>	0,58	0,69	0,20	0,56
20	<i>elliotsig</i>	<i>tansig</i>	0,57	0,68	0,19	0,54

Fonte: Autoria própria (2023).

Tabela 56 - Performance do algoritmo *trainoss* para predição da DQO com banco de 1000 dados sintéticos padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>purelin</i>	<i>tansig</i>	0,67	0,80	0,22	0,29
2	<i>tansig</i>	<i>tansig</i>	0,67	0,81	0,22	0,30
3	<i>purelin</i>	<i>purelin</i>	0,67	0,79	0,21	0,32
4	<i>purelin</i>	<i>purelin</i>	0,64	0,77	0,21	0,35
5	<i>purelin</i>	<i>tansig</i>	0,66	0,81	0,22	0,35
6	<i>purelin</i>	<i>tansig</i>	0,65	0,78	0,21	0,33
7	<i>logsig</i>	<i>purelin</i>	0,64	0,78	0,21	0,34
8	<i>purelin</i>	<i>purelin</i>	0,66	0,78	0,21	0,33
9	<i>logsig</i>	<i>purelin</i>	0,65	0,78	0,21	0,34
10	<i>purelin</i>	<i>purelin</i>	0,63	0,78	0,21	0,36
11	<i>purelin</i>	<i>purelin</i>	0,65	0,80	0,22	0,33
12	<i>purelin</i>	<i>tansig</i>	0,65	0,78	0,21	0,33
13	<i>logsig</i>	<i>elliotsig</i>	0,66	0,79	0,21	0,31
14	<i>elliotsig</i>	<i>purelin</i>	0,64	0,79	0,21	0,32
15	<i>purelin</i>	<i>purelin</i>	0,64	0,78	0,21	0,35
16	<i>purelin</i>	<i>purelin</i>	0,64	0,77	0,21	0,35
17	<i>purelin</i>	<i>purelin</i>	0,64	0,77	0,21	0,35
18	<i>purelin</i>	<i>purelin</i>	0,66	0,78	0,21	0,32
19	<i>purelin</i>	<i>purelin</i>	0,66	0,78	0,21	0,33
20	<i>elliotsig</i>	<i>purelin</i>	0,67	0,83	0,22	0,32

Fonte: Autoria própria (2023).

Tabela 57 - Performance do algoritmo *trainoss* para predição da DQO com banco de dados experimentais normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>tansig</i>	<i>elliotsig</i>	0,34	0,38	0,93	0,36
2	<i>purelin</i>	<i>purelin</i>	0,39	0,47	1,13	0,53
3	<i>tansig</i>	<i>purelin</i>	0,38	0,43	1,03	0,81
4	<i>logsig</i>	<i>logsig</i>	0,16	0,20	0,47	0,46
5	<i>logsig</i>	<i>logsig</i>	0,26	0,32	0,77	0,49
6	<i>elliotsig</i>	<i>logsig</i>	0,39	0,41	0,98	0,42
7	<i>logsig</i>	<i>logsig</i>	0,31	0,36	0,87	0,97
8	<i>tansig</i>	<i>purelin</i>	0,39	0,50	1,20	0,62
9	<i>tansig</i>	<i>tansig</i>	0,31	0,36	0,86	0,64
10	<i>tansig</i>	<i>purelin</i>	0,67	0,89	2,16	0,64
11	<i>purelin</i>	<i>purelin</i>	0,37	0,44	1,05	0,82
12	<i>logsig</i>	<i>logsig</i>	0,16	0,21	0,51	0,88
13	<i>logsig</i>	<i>purelin</i>	0,36	0,42	1,01	0,69
14	<i>tansig</i>	<i>tansig</i>	0,40	0,45	1,07	0,94
15	<i>logsig</i>	<i>purelin</i>	0,45	0,55	1,32	0,76
16	<i>tansig</i>	<i>purelin</i>	0,24	0,33	0,79	0,51
17	<i>elliotsig</i>	<i>purelin</i>	0,36	0,40	0,98	0,60
18	<i>purelin</i>	<i>elliotsig</i>	0,40	0,41	1,00	0,86
19	<i>logsig</i>	<i>purelin</i>	0,38	0,43	1,04	0,91
20	<i>purelin</i>	<i>purelin</i>	0,56	0,71	1,71	0,57

Fonte: Autoria própria (2023).

Tabela 58 – Performance do algoritmo *trainoss* para predição da DQO com banco de 125 dados sintéticos normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>purelin</i>	<i>tansig</i>	0.16	0.19	0.21	0.61
2	<i>logsig</i>	<i>elliotsig</i>	0.14	0.17	0.19	0.62
3	<i>elliotsig</i>	<i>purelin</i>	0.15	0.17	0.19	0.6
4	<i>logsig</i>	<i>tansig</i>	0.09	0.13	0.14	0.75
5	<i>tansig</i>	<i>purelin</i>	0.15	0.17	0.18	0.63
6	<i>purelin</i>	<i>purelin</i>	0.14	0.18	0.19	0.60
7	<i>logsig</i>	<i>tansig</i>	0.14	0.17	0.19	0.61
8	<i>logsig</i>	<i>purelin</i>	0.15	0.19	0.2	0.55
9	<i>logsig</i>	<i>purelin</i>	0.14	0.17	0.18	0.60
10	<i>logsig</i>	<i>elliotsig</i>	0.15	0.19	0.20	0.57
11	<i>logsig</i>	<i>elliotsig</i>	0.14	0.17	0.18	0.61

12	<i>purelin</i>	<i>elliotsig</i>	0.16	0.20	0.21	0.58
13	<i>logsig</i>	<i>elliotsig</i>	0.15	0.19	0.20	0.57
14	<i>logsig</i>	<i>elliotsig</i>	0.15	0.18	0.20	0.57
15	<i>purelin</i>	<i>tansig</i>	0.14	0.18	0.20	0.53
16	<i>elliotsig</i>	<i>tansig</i>	0.17	0.20	0.22	0.53
17	<i>purelin</i>	<i>purelin</i>	0.15	0.18	0.20	0.53
18	<i>logsig</i>	<i>purelin</i>	0.15	0.18	0.20	0.61
19	<i>logsig</i>	<i>purelin</i>	0.16	0.18	0.2	0.52
20	<i>logsig</i>	<i>tansig</i>	0.16	0.19	0.20	0.58

Fonte: Autoria própria (2023).

Tabela 59 - Performance do algoritmo *trainoss* para predição da DQO com banco de 1000 dados sintéticos normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>purelin</i>	<i>purelin</i>	0,17	0,21	0,21	0,33
2	<i>elliotsig</i>	<i>tansig</i>	0,17	0,21	0,21	0,33
3	<i>purelin</i>	<i>purelin</i>	0,18	0,21	0,21	0,32
4	<i>purelin</i>	<i>purelin</i>	0,17	0,21	0,21	0,34
5	<i>purelin</i>	<i>tansig</i>	0,17	0,21	0,21	0,34
6	<i>purelin</i>	<i>purelin</i>	0,18	0,21	0,22	0,29
7	<i>purelin</i>	<i>purelin</i>	0,17	0,20	0,21	0,36
8	<i>purelin</i>	<i>purelin</i>	0,18	0,21	0,21	0,32
9	<i>logsig</i>	<i>purelin</i>	0,17	0,21	0,22	0,33
10	<i>elliotsig</i>	<i>purelin</i>	0,17	0,21	0,21	0,35
11	<i>purelin</i>	<i>purelin</i>	0,17	0,21	0,21	0,34
12	<i>purelin</i>	<i>tansig</i>	0,17	0,21	0,21	0,33
13	<i>logsig</i>	<i>elliotsig</i>	0,18	0,21	0,22	0,31
14	<i>logsig</i>	<i>purelin</i>	0,17	0,21	0,22	0,29
15	<i>purelin</i>	<i>purelin</i>	0,17	0,21	0,21	0,35
16	<i>purelin</i>	<i>purelin</i>	0,17	0,21	0,21	0,33
17	<i>logsig</i>	<i>purelin</i>	0,18	0,21	0,21	0,32
18	<i>logsig</i>	<i>tansig</i>	0,17	0,21	0,21	0,33
19	<i>purelin</i>	<i>purelin</i>	0,17	0,21	0,21	0,32
20	<i>purelin</i>	<i>purelin</i>	0,17	0,21	0,21	0,35

Fonte: Autoria própria (2023).

- Algoritmo *trainlm* para a predição do NAT

Para o algoritmo de treinamento *trainlm* e banco de dados experimentais, 125 e 1000 dados sintéticos, estão representadas, respectivamente nas tabelas 60, 61 e 62 as melhores RNA

para esses bancos de dados padronizados, e nas tabelas 63, 64 e 65 as melhores RNA para esses bancos de dados normalizados

Tabela 60 - Performance do algoritmo *trainlm* para predição de NAT com banco de dados experimentais padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>purelin</i>	<i>elliotsig</i>	1,00	1,22	0,43	0,26
2	<i>tansig</i>	<i>logsig</i>	1,20	1,60	0,56	0,66
3	<i>tansig</i>	<i>logsig</i>	1,35	2,10	0,73	0,74
4	<i>elliotsig</i>	<i>purelin</i>	0,75	1,07	0,37	0,56
5	<i>tansig</i>	<i>logsig</i>	0,99	1,32	0,46	0,76
6	<i>tansig</i>	<i>tansig</i>	0,80	1,20	0,42	0,37
7	<i>elliotsig</i>	<i>logsig</i>	1,20	1,68	0,59	0,79
8	<i>tansig</i>	<i>logsig</i>	0,94	1,23	0,43	0,72
9	<i>tansig</i>	<i>logsig</i>	0,97	1,31	0,46	0,50
10	<i>tansig</i>	<i>logsig</i>	1,15	1,67	0,58	0,74
11	<i>elliotsig</i>	<i>logsig</i>	1,07	1,54	0,54	0,64
12	<i>logsig</i>	<i>logsig</i>	1,33	2,06	0,72	0,74
13	<i>purelin</i>	<i>logsig</i>	0,93	1,23	0,43	0,39
14	<i>tansig</i>	<i>logsig</i>	1,03	1,39	0,48	0,74
15	<i>elliotsig</i>	<i>elliotsig</i>	0,69	0,86	0,30	0,56
16	<i>purelin</i>	<i>tansig</i>	1,85	2,08	0,73	0,78
17	<i>elliotsig</i>	<i>elliotsig</i>	1,01	1,26	0,44	0,52
18	<i>logsig</i>	<i>logsig</i>	0,97	1,29	0,45	0,66
19	<i>purelin</i>	<i>logsig</i>	0,93	1,23	0,43	0,74
20	<i>elliotsig</i>	<i>logsig</i>	1,14	1,65	0,58	0,71

Fonte: Autoria própria (2023).

Tabela 61 - Performance do algoritmo *trainlm* para predição de NAT com banco de 125 dados sintéticos padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>elliotsig</i>	<i>tansig</i>	0,64	0,80	0,21	0,19
2	<i>tansig</i>	<i>elliotsig</i>	0,63	0,80	0,21	0,23
3	<i>purelin</i>	<i>elliotsig</i>	0,60	0,80	0,21	0,21
4	<i>logsig</i>	<i>logsig</i>	0,71	0,86	0,22	0,21
5	<i>logsig</i>	<i>purelin</i>	0,68	0,85	0,22	0,18
6	<i>tansig</i>	<i>purelin</i>	0,62	0,81	0,21	0,17
7	<i>logsig</i>	<i>logsig</i>	0,69	0,83	0,22	0,25

8	<i>tansig</i>	<i>logsig</i>	0,66	0,82	0,21	0,22
9	<i>tansig</i>	<i>logsig</i>	0,68	0,88	0,23	0,22
10	<i>elliotsig</i>	<i>logsig</i>	0,68	0,83	0,22	0,18
11	<i>elliotsig</i>	<i>tansig</i>	0,67	0,80	0,21	0,24
12	<i>elliotsig</i>	<i>elliotsig</i>	0,76	0,91	0,24	0,18
13	<i>purelin</i>	<i>purelin</i>	0,70	0,85	0,22	0,18
14	<i>elliotsig</i>	<i>logsig</i>	0,68	0,84	0,22	0,24
15	<i>purelin</i>	<i>purelin</i>	0,70	0,85	0,22	0,18
16	<i>tansig</i>	<i>tansig</i>	0,75	0,92	0,24	0,19
17	<i>purelin</i>	<i>purelin</i>	0,70	0,85	0,22	0,18
18	<i>tansig</i>	<i>purelin</i>	0,96	1,17	0,30	0,21
19	<i>logsig</i>	<i>logsig</i>	0,74	0,89	0,23	0,21
20	<i>tansig</i>	<i>purelin</i>	0,82	0,94	0,24	0,18

Fonte: Autoria própria (2023).

Tabela 62 – Performance do algoritmo *trainlm* para predição de NAT com banco de 1000 dados sintéticos padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>elliotsig</i>	<i>tansig</i>	0,71	0,86	0,20	0,35
2	<i>tansig</i>	<i>tansig</i>	0,69	0,84	0,20	0,36
3	<i>tansig</i>	<i>purelin</i>	0,70	0,84	0,20	0,38
4	<i>purelin</i>	<i>elliotsig</i>	0,75	0,90	0,21	0,36
5	<i>tansig</i>	<i>tansig</i>	0,71	0,85	0,20	0,35
6	<i>purelin</i>	<i>tansig</i>	0,70	0,86	0,20	0,34
7	<i>tansig</i>	<i>elliotsig</i>	0,68	0,85	0,20	0,35
8	<i>tansig</i>	<i>tansig</i>	0,67	0,82	0,19	0,38
9	<i>tansig</i>	<i>elliotsig</i>	0,66	0,83	0,19	0,36
10	<i>purelin</i>	<i>tansig</i>	0,70	0,86	0,20	0,34
11	<i>elliotsig</i>	<i>elliotsig</i>	0,68	0,84	0,20	0,34
12	<i>purelin</i>	<i>elliotsig</i>	0,67	0,85	0,20	0,35
13	<i>elliotsig</i>	<i>elliotsig</i>	0,67	0,84	0,20	0,35
14	<i>purelin</i>	<i>tansig</i>	0,70	0,87	0,20	0,33
15	<i>purelin</i>	<i>purelin</i>	0,71	0,86	0,20	0,33
16	<i>purelin</i>	<i>tansig</i>	0,71	0,86	0,20	0,34
17	<i>purelin</i>	<i>purelin</i>	0,71	0,86	0,20	0,33
18	<i>purelin</i>	<i>tansig</i>	0,70	0,86	0,20	0,34
19	<i>purelin</i>	<i>tansig</i>	0,70	0,86	0,20	0,34
20	<i>purelin</i>	<i>elliotsig</i>	0,69	0,85	0,20	0,34

Fonte: Autoria própria (2023).

Tabela 63 – Performance do algoritmo *trainlm* para predição de NAT com banco de dados experimentais normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>elliotsig</i>	<i>logsig</i>	0,25	0,38	0,64	0,74
2	<i>tansig</i>	<i>purelin</i>	0,18	0,19	0,32	0,40
3	<i>tansig</i>	<i>logsig</i>	0,22	0,33	0,55	0,50
4	<i>elliotsig</i>	<i>tansig</i>	0,18	0,23	0,38	0,46
5	<i>elliotsig</i>	<i>tansig</i>	0,34	0,40	0,68	0,37
6	<i>tansig</i>	<i>tansig</i>	0,34	0,38	0,65	0,36
7	<i>tansig</i>	<i>purelin</i>	0,18	0,24	0,40	0,61
8	<i>tansig</i>	<i>logsig</i>	0,19	0,26	0,44	0,75
9	<i>tansig</i>	<i>logsig</i>	0,21	0,28	0,47	0,84
10	<i>tansig</i>	<i>logsig</i>	0,22	0,30	0,51	0,73
11	<i>tansig</i>	<i>logsig</i>	0,24	0,36	0,61	0,60
12	<i>tansig</i>	<i>logsig</i>	0,20	0,27	0,45	0,74
13	<i>logsig</i>	<i>logsig</i>	0,21	0,28	0,47	0,74
14	<i>tansig</i>	<i>logsig</i>	0,20	0,26	0,45	0,73
15	<i>elliotsig</i>	<i>elliotsig</i>	0,14	0,18	0,30	0,56
16	<i>logsig</i>	<i>logsig</i>	0,26	0,40	0,67	0,72
17	<i>tansig</i>	<i>logsig</i>	0,19	0,25	0,43	0,74
18	<i>logsig</i>	<i>logsig</i>	0,21	0,30	0,50	0,75
19	<i>tansig</i>	<i>logsig</i>	0,21	0,28	0,48	0,79
20	<i>tansig</i>	<i>logsig</i>	0,22	0,32	0,54	0,74

Fonte: Autoria própria (2023).

Tabela 64 - Performance do algoritmo *trainlm* para predição de NAT com banco de 125 dados sintéticos normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>elliotsig</i>	<i>logsig</i>	0,15	0,19	0,22	0,18
2	<i>elliotsig</i>	<i>purelin</i>	0,15	0,19	0,22	0,19
3	<i>elliotsig</i>	<i>elliotsig</i>	0,15	0,19	0,22	0,24
4	<i>logsig</i>	<i>logsig</i>	0,15	0,19	0,22	0,22
5	<i>purelin</i>	<i>elliotsig</i>	0,18	0,21	0,25	0,21
6	<i>tansig</i>	<i>logsig</i>	0,17	0,21	0,24	0,18
7	<i>purelin</i>	<i>purelin</i>	0,15	0,19	0,22	0,18
8	<i>logsig</i>	<i>logsig</i>	0,17	0,21	0,24	0,19
9	<i>logsig</i>	<i>purelin</i>	0,18	0,20	0,24	0,19
10	<i>elliotsig</i>	<i>elliotsig</i>	0,11	0,15	0,17	0,49
11	<i>purelin</i>	<i>purelin</i>	0,15	0,19	0,22	0,18

12	<i>logsig</i>	<i>tansig</i>	0,16	0,19	0,23	0,21
13	<i>purelin</i>	<i>purelin</i>	0,19	0,22	0,26	0,17
14	<i>elliotsig</i>	<i>tansig</i>	0,17	0,20	0,24	0,26
15	<i>logsig</i>	<i>purelin</i>	0,14	0,17	0,20	0,23
16	<i>elliotsig</i>	<i>purelin</i>	0,19	0,21	0,25	0,18
17	<i>logsig</i>	<i>purelin</i>	0,16	0,18	0,22	0,19
18	<i>tansig</i>	<i>tansig</i>	0,16	0,21	0,25	0,19
19	<i>purelin</i>	<i>purelin</i>	0,15	0,19	0,22	0,18
20	<i>tansig</i>	<i>purelin</i>	0,14	0,17	0,20	0,30

Fonte: Autoria própria (2023).

Tabela 65 – Performance do algoritmo *trainlm* para predição de NAT com banco de 1000 dados sintéticos normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>purelin</i>	<i>elliotsig</i>	0,14	0,17	0,20	0,35
2	<i>logsig</i>	<i>purelin</i>	0,14	0,17	0,20	0,34
3	<i>logsig</i>	<i>purelin</i>	0,14	0,17	0,20	0,35
4	<i>logsig</i>	<i>tansig</i>	0,14	0,17	0,20	0,34
5	<i>tansig</i>	<i>elliotsig</i>	0,16	0,19	0,21	0,35
6	<i>tansig</i>	<i>elliotsig</i>	0,15	0,18	0,20	0,35
7	<i>purelin</i>	<i>tansig</i>	0,14	0,17	0,20	0,34
8	<i>purelin</i>	<i>tansig</i>	0,14	0,17	0,20	0,34
9	<i>elliotsig</i>	<i>elliotsig</i>	0,14	0,17	0,20	0,35
10	<i>tansig</i>	<i>purelin</i>	0,14	0,17	0,19	0,36
11	<i>purelin</i>	<i>tansig</i>	0,14	0,17	0,20	0,34
12	<i>purelin</i>	<i>purelin</i>	0,15	0,18	0,20	0,33
13	<i>purelin</i>	<i>purelin</i>	0,15	0,18	0,20	0,33
14	<i>purelin</i>	<i>tansig</i>	0,14	0,17	0,20	0,34
15	<i>tansig</i>	<i>tansig</i>	0,14	0,18	0,20	0,34
16	<i>elliotsig</i>	<i>purelin</i>	0,15	0,17	0,20	0,38
17	<i>purelin</i>	<i>elliotsig</i>	0,14	0,17	0,20	0,36
18	<i>purelin</i>	<i>purelin</i>	0,15	0,18	0,20	0,33
19	<i>logsig</i>	<i>elliotsig</i>	0,15	0,18	0,20	0,38
20	<i>elliotsig</i>	<i>elliotsig</i>	0,14	0,17	0,20	0,36

Fonte: Autoria própria (2023).

- Algoritmo *trainbr* para a predição do NAT

Para o algoritmo de treinamento *trainbr* e banco de dados experimentais, 125 e 1000 dados sintéticos, estão representadas, respectivamente nas tabelas 66, 67 e 68 as melhores RNA

para esses bancos de dados padronizados, e nas tabelas 69, 70 e 71 as melhores RNA para esses bancos de dados normalizados

Tabela 66 - Performance do algoritmo *trainbr* para predição de NAT com banco de dados experimentais padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>logsig</i>	<i>logsig</i>	0,98	1,30	0,46	0,36
2	<i>logsig</i>	<i>logsig</i>	0,97	1,30	0,46	0,34
3	<i>logsig</i>	<i>logsig</i>	0,97	1,30	0,45	0,28
4	<i>purelin</i>	<i>logsig</i>	0,99	1,32	0,46	0,25
5	<i>purelin</i>	<i>logsig</i>	0,99	1,32	0,46	0,27
6	<i>purelin</i>	<i>logsig</i>	0,99	1,32	0,46	0,24
7	<i>tansig</i>	<i>logsig</i>	0,98	1,31	0,46	0,25
8	<i>purelin</i>	<i>logsig</i>	0,99	1,32	0,46	0,26
9	<i>purelin</i>	<i>logsig</i>	0,99	1,32	0,46	0,26
10	<i>tansig</i>	<i>logsig</i>	0,98	1,31	0,46	0,26
11	<i>elliotsig</i>	<i>purelin</i>	0,93	1,20	0,42	0,28
12	<i>tansig</i>	<i>logsig</i>	0,99	1,32	0,46	0,27
13	<i>tansig</i>	<i>logsig</i>	0,99	1,32	0,46	0,27
14	<i>purelin</i>	<i>logsig</i>	0,99	1,32	0,46	0,26
15	<i>purelin</i>	<i>logsig</i>	0,98	1,32	0,46	0,25
16	<i>tansig</i>	<i>logsig</i>	0,99	1,32	0,46	0,26
17	<i>purelin</i>	<i>tansig</i>	0,91	1,22	0,42	0,29
18	<i>tansig</i>	<i>purelin</i>	0,91	1,20	0,42	0,64
19	<i>tansig</i>	<i>purelin</i>	0,87	1,32	0,46	0,27
20	<i>purelin</i>	<i>logsig</i>	0,99	1,32	0,46	0,27

Fonte: Autoria própria (2023).

Tabela 67 - Performance do algoritmo *trainbr* para predição de NAT com banco de 125 dados sintéticos padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>logsig</i>	<i>elliotsig</i>	0,69	0,91	0,24	0,21
2	<i>purelin</i>	<i>purelin</i>	0,70	0,85	0,22	0,17
3	<i>elliotsig</i>	<i>purelin</i>	0,71	0,85	0,22	0,17
4	<i>purelin</i>	<i>purelin</i>	0,70	0,85	0,22	0,17
5	<i>elliotsig</i>	<i>purelin</i>	0,71	0,85	0,22	0,17
6	<i>purelin</i>	<i>purelin</i>	0,70	0,84	0,22	0,17
7	<i>purelin</i>	<i>purelin</i>	0,70	0,85	0,22	0,17

8	<i>purelin</i>	<i>purelin</i>	0,70	0,85	0,22	0,17
9	<i>purelin</i>	<i>purelin</i>	0,70	0,85	0,22	0,17
10	<i>logsig</i>	<i>purelin</i>	0,69	0,91	0,24	0,21
11	<i>logsig</i>	<i>purelin</i>	0,69	0,91	0,24	0,21
12	<i>logsig</i>	<i>elliotsig</i>	0,69	0,91	0,24	0,21
13	<i>logsig</i>	<i>elliotsig</i>	0,68	0,90	0,23	0,21
14	<i>purelin</i>	<i>purelin</i>	0,70	0,85	0,22	0,17
15	<i>logsig</i>	<i>elliotsig</i>	0,69	0,91	0,24	0,21
16	<i>logsig</i>	<i>elliotsig</i>	0,68	0,91	0,24	0,21
17	<i>logsig</i>	<i>elliotsig</i>	0,69	0,91	0,24	0,21
18	<i>purelin</i>	<i>purelin</i>	0,70	0,85	0,22	0,17
19	<i>logsig</i>	<i>elliotsig</i>	0,68	0,90	0,23	0,21
20	<i>purelin</i>	<i>purelin</i>	0,70	0,85	0,22	0,17

Fonte: Autoria própria (2023).

Tabela 68 - Performance do algoritmo *trainbr* para predição de NAT com banco de 1000 dados sintéticos padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>purelin</i>	<i>elliotsig</i>	0,71	0,86	0,20	0,33
2	<i>elliotsig</i>	<i>elliotsig</i>	0,68	0,84	0,20	0,36
3	<i>elliotsig</i>	<i>elliotsig</i>	0,69	0,85	0,20	0,36
4	<i>elliotsig</i>	<i>elliotsig</i>	0,69	0,85	0,20	0,36
5	<i>elliotsig</i>	<i>elliotsig</i>	0,69	0,85	0,20	0,36
6	<i>elliotsig</i>	<i>tansig</i>	0,71	0,86	0,20	0,33
7	<i>elliotsig</i>	<i>elliotsig</i>	0,69	0,85	0,20	0,36
8	<i>elliotsig</i>	<i>elliotsig</i>	0,69	0,85	0,20	0,36
9	<i>elliotsig</i>	<i>elliotsig</i>	0,69	0,85	0,20	0,36
10	<i>elliotsig</i>	<i>elliotsig</i>	0,69	0,85	0,20	0,36
11	<i>elliotsig</i>	<i>elliotsig</i>	0,69	0,85	0,20	0,36
12	<i>tansig</i>	<i>elliotsig</i>	0,71	0,86	0,20	0,33
13	<i>tansig</i>	<i>elliotsig</i>	0,71	0,86	0,20	0,33
14	<i>tansig</i>	<i>elliotsig</i>	0,71	0,86	0,20	0,33
15	<i>tansig</i>	<i>elliotsig</i>	0,71	0,86	0,20	0,33
16	<i>tansig</i>	<i>elliotsig</i>	0,71	0,86	0,20	0,33
17	<i>tansig</i>	<i>elliotsig</i>	0,71	0,86	0,20	0,33
18	<i>tansig</i>	<i>elliotsig</i>	0,71	0,86	0,20	0,33
19	<i>tansig</i>	<i>elliotsig</i>	0,71	0,86	0,20	0,33
20	<i>tansig</i>	<i>elliotsig</i>	0,71	0,86	0,20	0,33

Fonte: Autoria própria (2023).

Tabela 69 - Performance do algoritmo *trainbr* para predição de NAT com banco de dados experimentais normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>logsig</i>	<i>logsig</i>	0,20	0,27	0,46	0,36
2	<i>tansig</i>	<i>tansig</i>	0,18	0,25	0,42	0,44
3	<i>logsig</i>	<i>logsig</i>	0,20	0,27	0,45	0,29
4	<i>purelin</i>	<i>logsig</i>	0,20	0,27	0,46	0,26
5	<i>tansig</i>	<i>logsig</i>	0,20	0,27	0,46	0,25
6	<i>tansig</i>	<i>logsig</i>	0,20	0,27	0,46	0,25
7	<i>purelin</i>	<i>logsig</i>	0,20	0,27	0,46	0,23
8	<i>tansig</i>	<i>logsig</i>	0,20	0,27	0,46	0,24
9	<i>elliotsig</i>	<i>elliotsig</i>	0,19	0,25	0,42	0,52
10	<i>elliotsig</i>	<i>logsig</i>	0,20	0,27	0,45	0,27
11	<i>tansig</i>	<i>logsig</i>	0,20	0,27	0,46	0,24
12	<i>purelin</i>	<i>logsig</i>	0,20	0,27	0,46	0,26
13	<i>tansig</i>	<i>logsig</i>	0,20	0,27	0,46	0,27
14	<i>purelin</i>	<i>logsig</i>	0,20	0,27	0,46	0,24
15	<i>purelin</i>	<i>logsig</i>	0,20	0,27	0,46	0,22
16	<i>purelin</i>	<i>logsig</i>	0,20	0,27	0,46	0,24
17	<i>purelin</i>	<i>logsig</i>	0,20	0,27	0,46	0,25
18	<i>tansig</i>	<i>purelin</i>	0,19	0,25	0,42	0,32
19	<i>purelin</i>	<i>logsig</i>	0,20	0,27	0,46	0,23
20	<i>tansig</i>	<i>logsig</i>	0,20	0,27	0,46	0,25

Fonte: Autoria própria (2023).

Tabela 70 - Performance do algoritmo *trainbr* para predição de NAT com banco de 125 dados sintéticos normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>purelin</i>	<i>purelin</i>	0,15	0,19	0,22	0,17
2	<i>purelin</i>	<i>tansig</i>	0,15	0,20	0,24	0,22
3	<i>elliotsig</i>	<i>purelin</i>	0,16	0,19	0,22	0,17
4	<i>purelin</i>	<i>purelin</i>	0,15	0,19	0,22	0,17
5	<i>purelin</i>	<i>purelin</i>	0,15	0,19	0,22	0,17
6	<i>purelin</i>	<i>purelin</i>	0,15	0,19	0,22	0,17
7	<i>purelin</i>	<i>purelin</i>	0,15	0,19	0,22	0,17
8	<i>purelin</i>	<i>purelin</i>	0,15	0,19	0,22	0,17
9	<i>purelin</i>	<i>elliotsig</i>	0,15	0,20	0,23	0,17
10	<i>purelin</i>	<i>purelin</i>	0,15	0,19	0,22	0,17
11	<i>logsig</i>	<i>tansig</i>	0,15	0,20	0,24	0,21

12	<i>logsig</i>	<i>purelin</i>	0,15	0,20	0,24	0,21
13	<i>logsig</i>	<i>purelin</i>	0,15	0,20	0,24	0,21
14	<i>logsig</i>	<i>purelin</i>	0,15	0,20	0,24	0,21
15	<i>logsig</i>	<i>tansig</i>	0,15	0,20	0,24	0,21
16	<i>logsig</i>	<i>purelin</i>	0,15	0,20	0,24	0,21
17	<i>logsig</i>	<i>purelin</i>	0,15	0,20	0,24	0,21
18	<i>logsig</i>	<i>tansig</i>	0,15	0,20	0,24	0,21
19	<i>logsig</i>	<i>purelin</i>	0,15	0,20	0,24	0,21
20	<i>logsig</i>	<i>tansig</i>	0,15	0,20	0,24	0,21

Fonte: Autoria própria (2023).

Tabela 71 - Performance do algoritmo *trainbr* para predição de NAT com banco de 1000 dados sintéticos normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>purelin</i>	<i>elliotsig</i>	0,14	0,18	0,20	0,33
2	<i>elliotsig</i>	<i>elliotsig</i>	0,14	0,17	0,20	0,36
3	<i>elliotsig</i>	<i>elliotsig</i>	0,14	0,17	0,20	0,36
4	<i>elliotsig</i>	<i>elliotsig</i>	0,14	0,17	0,20	0,36
5	<i>elliotsig</i>	<i>elliotsig</i>	0,14	0,17	0,20	0,36
6	<i>elliotsig</i>	<i>tansig</i>	0,14	0,18	0,20	0,33
7	<i>elliotsig</i>	<i>elliotsig</i>	0,14	0,17	0,20	0,36
8	<i>elliotsig</i>	<i>elliotsig</i>	0,14	0,17	0,20	0,36
9	<i>elliotsig</i>	<i>elliotsig</i>	0,14	0,17	0,20	0,36
10	<i>elliotsig</i>	<i>elliotsig</i>	0,14	0,17	0,20	0,36
11	<i>elliotsig</i>	<i>elliotsig</i>	0,14	0,17	0,20	0,36
12	<i>tansig</i>	<i>elliotsig</i>	0,14	0,17	0,20	0,33
13	<i>tansig</i>	<i>elliotsig</i>	0,14	0,17	0,20	0,33
14	<i>tansig</i>	<i>elliotsig</i>	0,14	0,17	0,20	0,33
15	<i>tansig</i>	<i>elliotsig</i>	0,14	0,17	0,20	0,33
16	<i>tansig</i>	<i>elliotsig</i>	0,14	0,17	0,20	0,33
17	<i>tansig</i>	<i>elliotsig</i>	0,14	0,17	0,20	0,33
18	<i>tansig</i>	<i>elliotsig</i>	0,14	0,17	0,20	0,33
19	<i>tansig</i>	<i>elliotsig</i>	0,14	0,17	0,20	0,33
20	<i>tansig</i>	<i>elliotsig</i>	0,14	0,17	0,20	0,33

Fonte: Autoria própria (2023).

- Algoritmo *traingd* para a predição do NAT

Para o algoritmo de treinamento *traingd* e banco de dados experimentais, 125 e 1000 dados sintéticos, estão representadas, respectivamente nas tabelas 72, 73 e 74 as melhores RNA

para esses bancos de dados padronizados, e nas tabelas 75, 76 e 77 as melhores RNA para esses bancos de dados normalizados

Tabela 72 - Performance do algoritmo *traingd* para predição de NAT com banco de dados experimentais padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>purelin</i>	<i>tansig</i>	0,95	1,11	0,39	0,38
2	<i>tansig</i>	<i>purelin</i>	1,43	1,62	0,57	0,43
3	<i>tansig</i>	<i>logsig</i>	1,02	1,32	0,46	0,19
4	<i>purelin</i>	<i>elliotsig</i>	1,22	1,59	0,55	0,88
5	<i>elliotsig</i>	<i>tansig</i>	1,15	1,65	0,57	0,12
6	<i>elliotsig</i>	<i>logsig</i>	1,10	1,44	0,50	0,73
7	<i>purelin</i>	<i>elliotsig</i>	0,56	0,76	0,26	0,56
8	<i>purelin</i>	<i>elliotsig</i>	1,54	1,72	0,60	0,63
9	<i>purelin</i>	<i>tansig</i>	1,92	2,36	0,82	0,22
10	<i>purelin</i>	<i>tansig</i>	2,07	2,14	0,75	0,68
11	<i>elliotsig</i>	<i>elliotsig</i>	1,99	2,25	0,79	0,34
12	<i>logsig</i>	<i>tansig</i>	0,87	1,06	0,37	0,14
13	<i>purelin</i>	<i>tansig</i>	2,38	2,79	0,97	0,32
14	<i>purelin</i>	<i>logsig</i>	1,01	1,34	0,47	0,62
15	<i>purelin</i>	<i>elliotsig</i>	1,30	1,46	0,51	0,71
16	<i>tansig</i>	<i>tansig</i>	2,35	2,53	0,88	0,31
17	<i>tansig</i>	<i>logsig</i>	0,96	1,24	0,43	0,20
18	<i>logsig</i>	<i>logsig</i>	0,96	1,26	0,44	0,65
19	<i>logsig</i>	<i>tansig</i>	1,53	1,73	0,60	0,98
20	<i>logsig</i>	<i>purelin</i>	1,03	1,60	0,56	0,48

Fonte: Autoria própria (2023).

Tabela 73 - Performance do algoritmo *traingd* para predição de NAT com banco de 125 dados sintéticos padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>elliotsig</i>	<i>purelin</i>	0,70	0,83	0,22	0,18
2	<i>logsig</i>	<i>tansig</i>	0,65	0,83	0,21	0,15
3	<i>logsig</i>	<i>elliotsig</i>	0,66	0,80	0,21	0,22
4	<i>logsig</i>	<i>elliotsig</i>	0,64	0,79	0,20	0,24
5	<i>tansig</i>	<i>purelin</i>	0,69	0,83	0,21	0,18
6	<i>logsig</i>	<i>purelin</i>	0,64	0,78	0,20	0,26

7	<i>purelin</i>	<i>purelin</i>	0,69	0,83	0,21	0,19
8	<i>purelin</i>	<i>tansig</i>	0,65	0,80	0,21	0,23
9	<i>elliotsig</i>	<i>purelin</i>	0,72	0,83	0,22	0,20
10	<i>logsig</i>	<i>tansig</i>	0,65	0,81	0,21	0,24
11	<i>purelin</i>	<i>logsig</i>	0,78	1,00	0,26	0,21
12	<i>logsig</i>	<i>tansig</i>	0,69	0,83	0,22	0,20
13	<i>tansig</i>	<i>elliotsig</i>	0,75	0,87	0,23	0,18
14	<i>purelin</i>	<i>elliotsig</i>	0,84	0,98	0,26	0,20
15	<i>purelin</i>	<i>purelin</i>	0,70	0,85	0,22	0,18
16	<i>logsig</i>	<i>logsig</i>	0,70	0,89	0,23	0,28
17	<i>purelin</i>	<i>tansig</i>	0,79	0,92	0,24	0,17
18	<i>elliotsig</i>	<i>elliotsig</i>	0,75	0,88	0,23	0,20
19	<i>purelin</i>	<i>tansig</i>	1,53	1,74	0,45	0,27
20	<i>elliotsig</i>	<i>tansig</i>	0,74	0,89	0,23	0,15

Fonte: Autoria própria (2023).

Tabela 74 - Performance do algoritmo *traingd* para predição de NAT com banco de 1000 dados sintéticos padronizados

NCO	Características da RNA		Medidas de performance			
	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>purelin</i>	<i>tansig</i>	0,74	0,91	0,21	0,29
2	<i>purelin</i>	<i>purelin</i>	0,73	0,88	0,21	0,29
3	<i>logsig</i>	<i>purelin</i>	0,73	0,88	0,21	0,35
4	<i>tansig</i>	<i>purelin</i>	0,69	0,84	0,20	0,34
5	<i>purelin</i>	<i>purelin</i>	0,72	0,86	0,20	0,34
6	<i>tansig</i>	<i>elliotsig</i>	0,71	0,86	0,20	0,34
7	<i>tansig</i>	<i>elliotsig</i>	0,66	0,84	0,20	0,35
8	<i>elliotsig</i>	<i>elliotsig</i>	0,73	0,87	0,20	0,33
9	<i>purelin</i>	<i>tansig</i>	0,69	0,87	0,20	0,33
10	<i>logsig</i>	<i>purelin</i>	0,73	0,87	0,20	0,33
11	<i>purelin</i>	<i>tansig</i>	0,70	0,86	0,20	0,34
12	<i>logsig</i>	<i>tansig</i>	0,70	0,84	0,20	0,38
13	<i>purelin</i>	<i>tansig</i>	0,70	0,88	0,21	0,34
14	<i>logsig</i>	<i>elliotsig</i>	0,76	0,90	0,21	0,33
15	<i>purelin</i>	<i>elliotsig</i>	0,69	0,85	0,20	0,33
16	<i>purelin</i>	<i>purelin</i>	0,72	0,87	0,20	0,33
17	<i>purelin</i>	<i>tansig</i>	0,69	0,86	0,20	0,35
18	<i>logsig</i>	<i>elliotsig</i>	0,74	0,89	0,21	0,33
19	<i>elliotsig</i>	<i>purelin</i>	0,72	0,87	0,20	0,34
20	<i>purelin</i>	<i>elliotsig</i>	0,67	0,85	0,20	0,33

Fonte: Autoria própria (2023).

Tabela 75 - Performance do algoritmo *traingd* para predição de NAT com banco de dados experimentais normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>purelin</i>	<i>tansig</i>	0,20	0,23	0,39	0,37
2	<i>purelin</i>	<i>elliotsig</i>	0,22	0,28	0,47	0,33
3	<i>purelin</i>	<i>purelin</i>	0,27	0,34	0,57	0,12
4	<i>purelin</i>	<i>elliotsig</i>	0,25	0,33	0,55	0,88
5	<i>purelin</i>	<i>elliotsig</i>	0,39	0,43	0,73	0,17
6	<i>tansig</i>	<i>purelin</i>	0,41	0,52	0,89	0,58
7	<i>purelin</i>	<i>elliotsig</i>	0,11	0,15	0,25	0,60
8	<i>purelin</i>	<i>elliotsig</i>	0,30	0,35	0,71	0,51
9	<i>purelin</i>	<i>tansig</i>	0,38	0,48	0,81	0,22
10	<i>purelin</i>	<i>tansig</i>	0,43	0,44	0,75	0,68
11	<i>elliotsig</i>	<i>elliotsig</i>	0,41	0,46	0,79	0,34
12	<i>elliotsig</i>	<i>logsig</i>	0,28	0,36	0,61	0,14
13	<i>purelin</i>	<i>tansig</i>	0,48	0,57	0,96	0,33
14	<i>purelin</i>	<i>logsig</i>	0,21	0,28	0,47	0,63
15	<i>purelin</i>	<i>elliotsig</i>	0,27	0,30	0,51	0,71
16	<i>tansig</i>	<i>tansig</i>	0,48	0,52	0,88	0,31
17	<i>tansig</i>	<i>logsig</i>	0,12	0,15	0,30	0,68
18	<i>logsig</i>	<i>logsig</i>	0,22	0,28	0,48	0,52
19	<i>logsig</i>	<i>tansig</i>	0,31	0,36	0,60	0,98
20	<i>logsig</i>	<i>logsig</i>	0,21	0,27	0,45	0,49

Fonte: Autoria própria (2023).

Tabela 76 - Performance do algoritmo *traingd* para predição de NAT com banco de 125 dados sintéticos normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>tansig</i>	<i>purelin</i>	0,14	0,18	0,21	0,19
2	<i>purelin</i>	<i>purelin</i>	0,14	0,18	0,21	0,19
3	<i>elliotsig</i>	<i>logsig</i>	0,24	0,27	0,32	0,21
4	<i>elliotsig</i>	<i>purelin</i>	0,13	0,18	0,21	0,19
5	<i>purelin</i>	<i>logsig</i>	0,18	0,23	0,28	0,28
6	<i>logsig</i>	<i>logsig</i>	0,23	0,26	0,31	0,18
7	<i>logsig</i>	<i>tansig</i>	0,26	0,32	0,38	0,23
8	<i>elliotsig</i>	<i>logsig</i>	0,18	0,23	0,27	0,28
9	<i>tansig</i>	<i>elliotsig</i>	0,15	0,18	0,21	0,25

10	<i>elliotsig</i>	<i>tansig</i>	0,15	0,20	0,23	0,21
11	<i>elliotsig</i>	<i>tansig</i>	0,14	0,18	0,22	0,23
12	<i>elliotsig</i>	<i>purelin</i>	0,16	0,19	0,22	0,21
13	<i>logsig</i>	<i>tansig</i>	0,09	0,12	0,14	0,66
14	<i>logsig</i>	<i>purelin</i>	0,12	0,17	0,20	0,27
15	<i>elliotsig</i>	<i>logsig</i>	0,26	0,30	0,35	0,30
16	<i>tansig</i>	<i>purelin</i>	0,15	0,19	0,22	0,26
17	<i>elliotsig</i>	<i>tansig</i>	0,15	0,19	0,23	0,23
18	<i>purelin</i>	<i>elliotsig</i>	0,19	0,22	0,26	0,18
19	<i>purelin</i>	<i>purelin</i>	0,15	0,19	0,22	0,18
20	<i>purelin</i>	<i>purelin</i>	0,15	0,19	0,22	0,18

Fonte: Autoria própria (2023).

Tabela 77 - Performance do algoritmo *traingd* para predição de NAT com banco de 1000 dados sintéticos normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>elliotsig</i>	<i>purelin</i>	0,21	0,24	0,27	0,16
2	<i>purelin</i>	<i>purelin</i>	0,15	0,18	0,21	0,27
3	<i>purelin</i>	<i>logsig</i>	0,19	0,23	0,27	0,24
4	<i>purelin</i>	<i>tansig</i>	0,14	0,18	0,21	0,26
5	<i>purelin</i>	<i>purelin</i>	0,15	0,18	0,21	0,26
6	<i>purelin</i>	<i>tansig</i>	0,38	0,43	0,49	0,24
7	<i>purelin</i>	<i>purelin</i>	0,15	0,18	0,21	0,25
8	<i>elliotsig</i>	<i>tansig</i>	0,17	0,20	0,23	0,16
9	<i>purelin</i>	<i>purelin</i>	0,16	0,19	0,22	0,17
10	<i>purelin</i>	<i>purelin</i>	0,14	0,18	0,20	0,32
11	<i>purelin</i>	<i>tansig</i>	0,14	0,18	0,21	0,34
12	<i>purelin</i>	<i>purelin</i>	0,14	0,18	0,20	0,31
13	<i>purelin</i>	<i>purelin</i>	0,14	0,18	0,20	0,32
14	<i>purelin</i>	<i>purelin</i>	0,14	0,17	0,20	0,34
15	<i>purelin</i>	<i>elliotsig</i>	0,14	0,18	0,21	0,34
16	<i>purelin</i>	<i>purelin</i>	0,14	0,17	0,20	0,35
17	<i>purelin</i>	<i>purelin</i>	0,14	0,17	0,20	0,34
18	<i>tansig</i>	<i>purelin</i>	0,17	0,21	0,24	0,27
19	<i>purelin</i>	<i>purelin</i>	0,15	0,18	0,20	0,32
20	<i>purelin</i>	<i>elliotsig</i>	0,17	0,22	0,25	0,32

Fonte: Autoria própria (2023).

- Algoritmo *trainoss* para a predição do NAT

Para o algoritmo de treinamento *trainoss* e banco de dados experimentais, 125 e 1000 dados sintéticos, estão representadas, respectivamente nas tabelas 78, 79 e 80 as melhores RNA para esses bancos de dados padronizados, e nas tabelas 81, 82 e 83 as melhores RNA para esses bancos de dados normalizados

Tabela 78 - Performance do algoritmo *trainoss* para predição de NAT com banco de dados experimentais padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>elliotsig</i>	<i>purelin</i>	0,89	1,17	0,41	0,12
2	<i>tansig</i>	<i>elliotsig</i>	0,86	1,13	0,40	0,52
3	<i>purelin</i>	<i>logsig</i>	1,90	2,67	0,93	0,61
4	<i>elliotsig</i>	<i>purelin</i>	1,22	1,53	0,54	0,62
5	<i>logsig</i>	<i>elliotsig</i>	1,07	1,28	0,45	0,31
6	<i>tansig</i>	<i>logsig</i>	0,94	1,24	0,43	0,57
7	<i>logsig</i>	<i>logsig</i>	0,93	1,23	0,43	0,00
8	<i>tansig</i>	<i>elliotsig</i>	1,03	1,49	0,52	0,27
9	<i>elliotsig</i>	<i>logsig</i>	0,95	1,25	0,44	0,39
10	<i>tansig</i>	<i>tansig</i>	1,62	1,88	0,66	0,39
11	<i>elliotsig</i>	<i>purelin</i>	1,56	1,86	0,65	0,26
12	<i>logsig</i>	<i>logsig</i>	0,93	1,23	0,43	0,68
13	<i>tansig</i>	<i>purelin</i>	1,71	2,12	0,74	0,16
14	<i>elliotsig</i>	<i>elliotsig</i>	0,63	0,76	0,27	0,50
15	<i>purelin</i>	<i>logsig</i>	0,94	1,23	0,43	0,77
16	<i>logsig</i>	<i>elliotsig</i>	1,37	1,83	0,64	0,12
17	<i>tansig</i>	<i>tansig</i>	1,79	2,00	0,70	0,29
18	<i>logsig</i>	<i>elliotsig</i>	1,42	1,70	0,59	0,50
19	<i>elliotsig</i>	<i>tansig</i>	1,71	2,13	0,74	0,34
20	<i>elliotsig</i>	<i>purelin</i>	0,86	1,05	0,37	0,43

Fonte: Autoria própria (2023).

Tabela 79 - Performance do algoritmo *trainoss* para predição de NAT com banco de 125 dados sintéticos padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>purelin</i>	<i>purelin</i>	0,70	0,85	0,22	0,18
2	<i>elliotsig</i>	<i>purelin</i>	0,70	0,84	0,22	0,19
3	<i>tansig</i>	<i>purelin</i>	0,70	0,83	0,22	0,18
4	<i>logsig</i>	<i>purelin</i>	0,64	0,82	0,21	0,22

5	<i>purelin</i>	<i>logsig</i>	0,69	0,89	0,23	0,19
6	<i>logsig</i>	<i>tansig</i>	0,69	0,85	0,22	0,19
7	<i>logsig</i>	<i>logsig</i>	0,70	0,89	0,23	0,23
8	<i>tansig</i>	<i>purelin</i>	0,73	0,88	0,23	0,19
9	<i>purelin</i>	<i>purelin</i>	0,70	0,85	0,22	0,18
10	<i>tansig</i>	<i>purelin</i>	0,68	0,83	0,22	0,20
11	<i>purelin</i>	<i>tansig</i>	2,18	2,45	0,64	0,21
12	<i>logsig</i>	<i>purelin</i>	0,67	0,81	0,21	0,20
13	<i>purelin</i>	<i>purelin</i>	0,69	0,84	0,22	0,19
14	<i>logsig</i>	<i>purelin</i>	0,69	0,83	0,22	0,20
15	<i>logsig</i>	<i>purelin</i>	0,68	0,82	0,21	0,23
16	<i>logsig</i>	<i>purelin</i>	0,72	0,84	0,22	0,18
17	<i>purelin</i>	<i>purelin</i>	0,69	0,83	0,22	0,21
18	<i>purelin</i>	<i>purelin</i>	0,70	0,86	0,22	0,17
19	<i>purelin</i>	<i>elliotsig</i>	1,54	1,70	0,44	0,27
20	<i>tansig</i>	<i>tansig</i>	0,71	0,89	0,23	0,18

Fonte: Autoria própria (2023).

Tabela 80 - Performance do algoritmo *trainoss* para predição de NAT com banco de 1000 dados sintéticos padronizados

NCO	Características da RNA		Medidas de performance			
	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>logsig</i>	<i>purelin</i>	0,70	0,88	0,20	0,29
2	<i>purelin</i>	<i>elliotsig</i>	0,69	0,85	0,20	0,33
3	<i>logsig</i>	<i>elliotsig</i>	0,70	0,86	0,20	0,32
4	<i>elliotsig</i>	<i>elliotsig</i>	0,75	0,89	0,21	0,37
5	<i>logsig</i>	<i>purelin</i>	0,71	0,86	0,20	0,35
6	<i>purelin</i>	<i>elliotsig</i>	0,69	0,85	0,20	0,33
7	<i>purelin</i>	<i>elliotsig</i>	0,69	0,85	0,20	0,33
8	<i>elliotsig</i>	<i>elliotsig</i>	0,67	0,84	0,20	0,35
9	<i>purelin</i>	<i>elliotsig</i>	0,69	0,85	0,20	0,33
10	<i>elliotsig</i>	<i>tansig</i>	0,71	0,85	0,20	0,33
11	<i>tansig</i>	<i>purelin</i>	0,71	0,87	0,20	0,35
12	<i>elliotsig</i>	<i>purelin</i>	0,70	0,86	0,20	0,32
13	<i>purelin</i>	<i>elliotsig</i>	0,69	0,85	0,20	0,33
14	<i>tansig</i>	<i>tansig</i>	0,68	0,85	0,20	0,33
15	<i>elliotsig</i>	<i>purelin</i>	0,70	0,86	0,20	0,32
16	<i>purelin</i>	<i>elliotsig</i>	0,69	0,84	0,20	0,35
17	<i>purelin</i>	<i>elliotsig</i>	0,68	0,83	0,20	0,36
18	<i>purelin</i>	<i>elliotsig</i>	0,69	0,85	0,20	0,33
19	<i>purelin</i>	<i>purelin</i>	0,72	0,87	0,20	0,34
20	<i>tansig</i>	<i>tansig</i>	0,65	0,82	0,19	0,39

Fonte: Autoria própria (2023).

Tabela 81 - Performance do algoritmo *trainoss* para predição de NAT com banco de dados experimentais normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>elliotsig</i>	<i>purelin</i>	0,19	0,24	0,41	0,25
2	<i>tansig</i>	<i>elliotsig</i>	0,19	0,25	0,42	0,40
3	<i>tansig</i>	<i>elliotsig</i>	0,11	0,18	0,30	0,55
4	<i>tansig</i>	<i>tansig</i>	0,20	0,31	0,52	0,34
5	<i>elliotsig</i>	<i>elliotsig</i>	0,21	0,23	0,39	0,40
6	<i>elliotsig</i>	<i>purelin</i>	0,25	0,30	0,51	0,39
7	<i>purelin</i>	<i>tansig</i>	0,21	0,25	0,43	0,32
8	<i>tansig</i>	<i>elliotsig</i>	0,18	0,30	0,52	0,34
9	<i>elliotsig</i>	<i>logsig</i>	0,20	0,26	0,44	0,39
10	<i>tansig</i>	<i>logsig</i>	0,20	0,26	0,44	0,67
11	<i>elliotsig</i>	<i>purelin</i>	0,32	0,38	0,65	0,26
12	<i>elliotsig</i>	<i>purelin</i>	0,21	0,26	0,45	0,37
13	<i>elliotsig</i>	<i>tansig</i>	0,06	0,06	0,12	0,94
14	<i>elliotsig</i>	<i>elliotsig</i>	0,13	0,16	0,27	0,50
15	<i>purelin</i>	<i>logsig</i>	0,24	0,35	0,59	0,76
16	<i>logsig</i>	<i>elliotsig</i>	0,26	0,32	0,54	0,30
17	<i>purelin</i>	<i>elliotsig</i>	0,38	0,45	0,76	0,20
18	<i>tansig</i>	<i>elliotsig</i>	0,23	0,32	0,55	0,43
19	<i>elliotsig</i>	<i>tansig</i>	0,34	0,43	0,73	0,24
20	<i>logsig</i>	<i>purelin</i>	0,15	0,17	0,28	0,51

Fonte: Autoria própria (2023).

Tabela 82 - Performance do algoritmo *trainoss* para predição de NAT com banco de 125 dados sintéticos normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>logsig</i>	<i>purelin</i>	0,14	0,18	0,21	0,19
2	<i>purelin</i>	<i>elliotsig</i>	0,14	0,17	0,20	0,23
3	<i>logsig</i>	<i>purelin</i>	0,16	0,18	0,22	0,16
4	<i>purelin</i>	<i>tansig</i>	0,16	0,19	0,22	0,20
5	<i>purelin</i>	<i>purelin</i>	0,15	0,18	0,22	0,18
6	<i>logsig</i>	<i>purelin</i>	0,15	0,19	0,22	0,18
7	<i>purelin</i>	<i>tansig</i>	0,17	0,20	0,24	0,22
8	<i>purelin</i>	<i>tansig</i>	0,16	0,19	0,22	0,18
9	<i>purelin</i>	<i>purelin</i>	0,15	0,18	0,22	0,19

10	<i>purelin</i>	<i>purelin</i>	0,15	0,18	0,22	0,19
11	<i>tansig</i>	<i>tansig</i>	0,16	0,19	0,22	0,22
12	<i>purelin</i>	<i>purelin</i>	0,15	0,19	0,22	0,18
13	<i>logsig</i>	<i>tansig</i>	0,18	0,20	0,24	0,20
14	<i>tansig</i>	<i>tansig</i>	0,41	0,44	0,52	0,17
15	<i>elliotsig</i>	<i>tansig</i>	0,17	0,20	0,24	0,19
16	<i>tansig</i>	<i>purelin</i>	0,14	0,18	0,21	0,21
17	<i>elliotsig</i>	<i>tansig</i>	0,15	0,18	0,21	0,23
18	<i>logsig</i>	<i>purelin</i>	0,17	0,19	0,23	0,20
19	<i>purelin</i>	<i>purelin</i>	0,16	0,19	0,22	0,20
20	<i>purelin</i>	<i>purelin</i>	0,15	0,19	0,22	0,18

Fonte: Autoria própria (2023).

Tabela 83 - Performance do algoritmo *trainoss* para predição de NAT com banco de 1000 dados sintéticos normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>purelin</i>	<i>purelin</i>	0,15	0,18	0,21	0,28
2	<i>purelin</i>	<i>purelin</i>	0,15	0,18	0,21	0,28
3	<i>elliotsig</i>	<i>purelin</i>	0,14	0,17	0,20	0,32
4	<i>tansig</i>	<i>tansig</i>	0,14	0,17	0,20	0,33
5	<i>purelin</i>	<i>elliotsig</i>	0,13	0,17	0,20	0,33
6	<i>purelin</i>	<i>elliotsig</i>	0,14	0,17	0,20	0,33
7	<i>logsig</i>	<i>elliotsig</i>	0,15	0,18	0,21	0,31
8	<i>logsig</i>	<i>purelin</i>	0,15	0,18	0,20	0,31
9	<i>purelin</i>	<i>tansig</i>	0,14	0,17	0,20	0,34
10	<i>logsig</i>	<i>elliotsig</i>	0,14	0,18	0,21	0,29
11	<i>tansig</i>	<i>purelin</i>	0,14	0,17	0,20	0,35
12	<i>purelin</i>	<i>tansig</i>	0,14	0,17	0,19	0,36
13	<i>purelin</i>	<i>purelin</i>	0,14	0,17	0,20	0,35
14	<i>purelin</i>	<i>tansig</i>	0,14	0,17	0,20	0,34
15	<i>purelin</i>	<i>elliotsig</i>	0,14	0,18	0,20	0,31
16	<i>purelin</i>	<i>elliotsig</i>	0,14	0,17	0,20	0,33
17	<i>purelin</i>	<i>tansig</i>	0,14	0,17	0,20	0,35
18	<i>purelin</i>	<i>purelin</i>	0,15	0,18	0,20	0,33
19	<i>purelin</i>	<i>purelin</i>	0,14	0,17	0,20	0,35
20	<i>tansig</i>	<i>tansig</i>	0,13	0,17	0,19	0,36

Fonte: Autoria própria (2023).

- Algoritmo *trainlm* para a predição da vazão

Para o algoritmo de treinamento *trainlm* e banco de dados experimentais, 125 e 1000 dados sintéticos, estão representadas, respectivamente nas tabelas 84, 85 e 86 as melhores RNA para esses bancos de dados padronizados, e nas tabelas 87, 88 e 89 as melhores RNA para esses bancos de dados normalizados

Tabela 84 - Performance do algoritmo *trainlm* para predição de Vazão com banco de dados experimentais padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>purelin</i>	<i>logsig</i>	1,15	1,49	0,43	0,16
2	<i>logsig</i>	<i>elliotsig</i>	0,59	0,80	0,23	0,57
3	<i>elliotsig</i>	<i>purelin</i>	0,72	0,95	0,27	0,18
4	<i>purelin</i>	<i>logsig</i>	1,15	1,49	0,43	0,16
5	<i>logsig</i>	<i>elliotsig</i>	0,59	0,76	0,22	0,58
6	<i>logsig</i>	<i>tansig</i>	1,11	1,43	0,41	0,19
7	<i>tansig</i>	<i>elliotsig</i>	0,82	1,04	0,30	0,34
8	<i>purelin</i>	<i>logsig</i>	1,15	1,49	0,43	0,16
9	<i>elliotsig</i>	<i>purelin</i>	0,67	0,89	0,26	0,32
10	<i>tansig</i>	<i>tansig</i>	1,12	1,48	0,42	0,16
11	<i>tansig</i>	<i>elliotsig</i>	0,86	1,06	0,31	0,32
12	<i>tansig</i>	<i>tansig</i>	0,57	0,77	0,22	0,47
13	<i>elliotsig</i>	<i>logsig</i>	0,96	1,13	0,32	0,10
14	<i>tansig</i>	<i>purelin</i>	0,71	0,84	0,24	0,35
15	<i>elliotsig</i>	<i>purelin</i>	1,41	1,94	0,56	0,23
16	<i>elliotsig</i>	<i>logsig</i>	1,15	1,49	0,43	0,15
17	<i>purelin</i>	<i>logsig</i>	1,15	1,49	0,43	0,16
18	<i>tansig</i>	<i>logsig</i>	1,15	1,49	0,43	0,16
19	<i>tansig</i>	<i>tansig</i>	0,81	0,92	0,26	0,33
20	<i>purelin</i>	<i>logsig</i>	1,15	1,49	0,43	0,16

Fonte: Autoria própria (2023).

Tabela 85 - Performance do algoritmo *trainlm* para predição de Vazão com banco de 125 dados sintéticos padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>elliotsig</i>	<i>tansig</i>	0,78	0,94	0,26	0,15
2	<i>purelin</i>	<i>purelin</i>	0,71	0,95	0,26	0,15
3	<i>tansig</i>	<i>tansig</i>	0,80	0,95	0,26	0,14
4	<i>purelin</i>	<i>elliotsig</i>	0,78	0,94	0,26	0,13
5	<i>purelin</i>	<i>tansig</i>	0,79	0,95	0,26	0,11
6	<i>tansig</i>	<i>tansig</i>	0,85	0,98	0,27	0,14

7	<i>elliotsig</i>	<i>purelin</i>	0,78	0,94	0,26	0,14
8	<i>logsig</i>	<i>tansig</i>	0,80	0,93	0,26	0,18
9	<i>logsig</i>	<i>elliotsig</i>	0,78	0,94	0,26	0,14
10	<i>logsig</i>	<i>elliotsig</i>	0,81	0,95	0,26	0,11
11	<i>purelin</i>	<i>tansig</i>	0,79	0,95	0,26	0,11
12	<i>purelin</i>	<i>tansig</i>	0,80	0,95	0,26	0,11
13	<i>tansig</i>	<i>tansig</i>	0,70	0,95	0,26	0,15
14	<i>logsig</i>	<i>elliotsig</i>	0,91	1,11	0,31	0,16
15	<i>logsig</i>	<i>tansig</i>	0,89	1,00	0,28	0,14
16	<i>purelin</i>	<i>elliotsig</i>	0,79	0,95	0,26	0,12
17	<i>tansig</i>	<i>elliotsig</i>	0,79	0,98	0,27	0,12
18	<i>logsig</i>	<i>purelin</i>	0,80	0,94	0,26	0,15
19	<i>purelin</i>	<i>tansig</i>	0,79	0,95	0,26	0,11
20	<i>purelin</i>	<i>tansig</i>	0,80	0,95	0,26	0,12

Fonte: Autoria própria (2023).

Tabela 86 - Performance do algoritmo *trainlm* para predição de Vazão com banco de 1000 dados sintéticos padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>logsig</i>	<i>tansig</i>	0,73	0,88	0,23	0,10
2	<i>purelin</i>	<i>tansig</i>	0,72	0,88	0,23	0,09
3	<i>tansig</i>	<i>tansig</i>	0,73	0,88	0,23	0,09
4	<i>elliotsig</i>	<i>tansig</i>	0,75	0,90	0,24	0,11
5	<i>purelin</i>	<i>elliotsig</i>	0,74	0,89	0,24	0,08
6	<i>logsig</i>	<i>elliotsig</i>	0,74	0,91	0,24	0,07
7	<i>logsig</i>	<i>elliotsig</i>	0,73	0,89	0,24	0,07
8	<i>purelin</i>	<i>tansig</i>	0,72	0,88	0,23	0,07
9	<i>purelin</i>	<i>purelin</i>	0,73	0,89	0,24	0,06
10	<i>purelin</i>	<i>purelin</i>	0,73	0,89	0,24	0,06
11	<i>purelin</i>	<i>purelin</i>	0,73	0,89	0,24	0,06
12	<i>logsig</i>	<i>tansig</i>	0,72	0,87	0,23	0,09
13	<i>tansig</i>	<i>purelin</i>	0,88	1,09	0,29	0,08
14	<i>purelin</i>	<i>purelin</i>	0,73	0,89	0,24	0,06
15	<i>purelin</i>	<i>purelin</i>	0,73	0,89	0,24	0,06
16	<i>purelin</i>	<i>elliotsig</i>	0,73	0,88	0,24	0,07
17	<i>purelin</i>	<i>tansig</i>	0,73	0,88	0,23	0,07
18	<i>purelin</i>	<i>tansig</i>	0,72	0,88	0,23	0,08
19	<i>purelin</i>	<i>purelin</i>	0,73	0,89	0,24	0,06
20	<i>purelin</i>	<i>purelin</i>	0,73	0,89	0,24	0,06

Fonte: Autoria própria (2023).

Tabela 87 - Performance do algoritmo *trainlm* para predição de Vazão com banco de dados experimentais normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>purelin</i>	<i>elliotsig</i>	0,19	0,24	0,27	0,18
2	<i>tansig</i>	<i>tansig</i>	0,19	0,25	0,28	0,18
3	<i>elliotsig</i>	<i>purelin</i>	0,20	0,25	0,28	0,20
4	<i>elliotsig</i>	<i>tansig</i>	0,19	0,26	0,30	0,10
5	<i>purelin</i>	<i>logsig</i>	0,29	0,38	0,43	0,16
6	<i>logsig</i>	<i>purelin</i>	0,17	0,21	0,23	0,42
7	<i>tansig</i>	<i>logsig</i>	0,26	0,32	0,36	0,13
8	<i>purelin</i>	<i>logsig</i>	0,29	0,38	0,43	0,16
9	<i>logsig</i>	<i>tansig</i>	0,19	0,26	0,29	0,22
10	<i>purelin</i>	<i>elliotsig</i>	0,18	0,24	0,27	0,17
11	<i>logsig</i>	<i>logsig</i>	0,29	0,38	0,43	0,16
12	<i>tansig</i>	<i>logsig</i>	0,29	0,38	0,43	0,16
13	<i>purelin</i>	<i>logsig</i>	0,29	0,38	0,43	0,16
14	<i>tansig</i>	<i>purelin</i>	0,18	0,22	0,24	0,36
16	<i>tansig</i>	<i>tansig</i>	0,25	0,32	0,35	0,17
17	<i>logsig</i>	<i>logsig</i>	0,29	0,38	0,43	0,16
18	<i>tansig</i>	<i>logsig</i>	0,29	0,38	0,43	0,16
19	<i>elliotsig</i>	<i>purelin</i>	0,21	0,27	0,31	0,17
20	<i>elliotsig</i>	<i>logsig</i>	0,29	0,38	0,43	0,16
15	<i>elliotsig</i>	<i>tansig</i>	0,17	0,21	0,24	0,55

Fonte: Autoria própria (2023).

Tabela 88 - Performance do algoritmo *trainlm* para predição de Vazão com banco de 125 dados sintéticos normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>purelin</i>	<i>purelin</i>	0,22	0,26	0,26	0,16
2	<i>purelin</i>	<i>purelin</i>	0,22	0,26	0,26	0,15
3	<i>purelin</i>	<i>elliotsig</i>	0,22	0,26	0,26	0,13
4	<i>elliotsig</i>	<i>tansig</i>	0,21	0,26	0,26	0,17
5	<i>purelin</i>	<i>elliotsig</i>	0,22	0,26	0,26	0,11
6	<i>logsig</i>	<i>tansig</i>	0,21	0,26	0,26	0,14
7	<i>elliotsig</i>	<i>purelin</i>	0,21	0,26	0,26	0,15
8	<i>logsig</i>	<i>tansig</i>	0,22	0,26	0,26	0,18
9	<i>logsig</i>	<i>tansig</i>	0,22	0,26	0,26	0,14
10	<i>purelin</i>	<i>tansig</i>	0,22	0,26	0,26	0,11
11	<i>logsig</i>	<i>elliotsig</i>	0,22	0,26	0,26	0,12

12	<i>tansig</i>	<i>tansig</i>	0,23	0,26	0,26	0,15
13	<i>tansig</i>	<i>elliotsig</i>	0,23	0,27	0,27	0,15
14	<i>purelin</i>	<i>logsig</i>	0,28	0,31	0,31	0,12
15	<i>tansig</i>	<i>tansig</i>	0,26	0,32	0,32	0,15
16	<i>purelin</i>	<i>elliotsig</i>	0,22	0,26	0,26	0,11
17	<i>purelin</i>	<i>tansig</i>	0,22	0,26	0,26	0,11
18	<i>logsig</i>	<i>purelin</i>	0,22	0,26	0,26	0,16
19	<i>purelin</i>	<i>purelin</i>	0,22	0,26	0,26	0,10
20	<i>logsig</i>	<i>tansig</i>	0,23	0,27	0,27	0,13

Fonte: Autoria própria (2023).

Tabela 89 - Performance do algoritmo *trainlm* para predição de Vazão com banco de 1000 dados sintéticos normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>elliotsig</i>	<i>tansig</i>	0,18	0,22	0,23	0,10
2	<i>elliotsig</i>	<i>logsig</i>	0,22	0,26	0,27	0,18
3	<i>purelin</i>	<i>purelin</i>	0,18	0,23	0,24	0,10
4	<i>purelin</i>	<i>elliotsig</i>	0,18	0,22	0,23	0,09
5	<i>elliotsig</i>	<i>elliotsig</i>	0,18	0,22	0,23	0,08
6	<i>logsig</i>	<i>elliotsig</i>	0,18	0,22	0,23	0,08
7	<i>purelin</i>	<i>purelin</i>	0,18	0,22	0,23	0,08
8	<i>purelin</i>	<i>tansig</i>	0,18	0,22	0,23	0,08
9	<i>logsig</i>	<i>tansig</i>	0,19	0,23	0,24	0,09
10	<i>purelin</i>	<i>purelin</i>	0,18	0,22	0,24	0,06
11	<i>purelin</i>	<i>purelin</i>	0,18	0,22	0,24	0,06
12	<i>elliotsig</i>	<i>tansig</i>	0,19	0,23	0,24	0,07
13	<i>purelin</i>	<i>purelin</i>	0,18	0,22	0,23	0,07
14	<i>logsig</i>	<i>elliotsig</i>	0,18	0,22	0,23	0,08
15	<i>purelin</i>	<i>purelin</i>	0,18	0,22	0,24	0,06
16	<i>purelin</i>	<i>purelin</i>	0,18	0,22	0,24	0,06
17	<i>purelin</i>	<i>purelin</i>	0,18	0,22	0,24	0,06
18	<i>purelin</i>	<i>tansig</i>	0,18	0,22	0,23	0,07
19	<i>purelin</i>	<i>purelin</i>	0,18	0,22	0,24	0,06
20	<i>purelin</i>	<i>tansig</i>	0,18	0,22	0,24	0,07

Fonte: Autoria própria (2023).

- Algoritmo *trainbr* para a predição da vazão

Para o algoritmo de treinamento *trainbr* e banco de dados experimentais, 125 e 1000 dados sintéticos, estão representadas, respectivamente nas tabelas 90, 91 e 92 as melhores RNA

para esses bancos de dados padronizados, e nas tabelas 93, 94 e 95 as melhores RNA para esses bancos de dados normalizados

Tabela 90 – Performance do algoritmo *trainbr* para predição de Vazão com banco de dados experimentais padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>logsig</i>	<i>tansig</i>	0,88	1,04	0,30	0,15
2	<i>logsig</i>	<i>purelin</i>	0,87	1,04	0,30	0,15
3	<i>logsig</i>	<i>elliotsig</i>	0,87	1,04	0,30	0,15
4	<i>logsig</i>	<i>purelin</i>	0,87	1,04	0,30	0,15
5	<i>tansig</i>	<i>purelin</i>	0,87	1,04	0,30	0,15
6	<i>logsig</i>	<i>purelin</i>	0,87	1,04	0,30	0,16
7	<i>logsig</i>	<i>purelin</i>	0,87	1,04	0,30	0,16
8	<i>logsig</i>	<i>elliotsig</i>	0,87	1,04	0,30	0,15
9	<i>logsig</i>	<i>purelin</i>	0,87	1,04	0,30	0,15
10	<i>logsig</i>	<i>purelin</i>	0,86	1,03	0,30	0,16
11	<i>logsig</i>	<i>elliotsig</i>	0,87	1,04	0,30	0,16
12	<i>logsig</i>	<i>purelin</i>	0,87	1,04	0,30	0,16
13	<i>logsig</i>	<i>purelin</i>	0,87	1,04	0,30	0,15
14	<i>logsig</i>	<i>purelin</i>	0,87	1,04	0,30	0,16
15	<i>logsig</i>	<i>tansig</i>	0,87	1,04	0,30	0,16
16	<i>logsig</i>	<i>purelin</i>	0,86	1,03	0,30	0,16
17	<i>logsig</i>	<i>purelin</i>	0,87	1,04	0,30	0,15
18	<i>logsig</i>	<i>purelin</i>	0,87	1,04	0,30	0,16
19	<i>logsig</i>	<i>purelin</i>	0,86	1,03	0,30	0,16
20	<i>logsig</i>	<i>purelin</i>	1,03	1,23	0,35	0,16

Fonte: Autoria própria (2023).

Tabela 91 - Performance do algoritmo *trainbr* para predição de Vazão com banco de 125 dados sintéticos padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>purelin</i>	<i>tansig</i>	0,82	0,96	0,27	0,13
2	<i>tansig</i>	<i>purelin</i>	0,82	0,97	0,27	0,13
3	<i>purelin</i>	<i>purelin</i>	0,82	0,96	0,27	0,14
4	<i>tansig</i>	<i>elliotsig</i>	0,87	0,99	0,27	0,10
5	<i>purelin</i>	<i>purelin</i>	0,85	0,98	0,27	0,10
6	<i>logsig</i>	<i>purelin</i>	0,87	1,00	0,28	0,10
7	<i>elliotsig</i>	<i>tansig</i>	0,85	0,97	0,27	0,15

8	<i>elliotsig</i>	<i>tansig</i>	0,86	0,98	0,27	0,12
9	<i>purelin</i>	<i>logsig</i>	1,00	1,12	0,31	0,09
10	<i>tansig</i>	<i>purelin</i>	0,87	0,99	0,27	0,13
11	<i>tansig</i>	<i>elliotsig</i>	0,88	0,99	0,27	0,12
12	<i>purelin</i>	<i>logsig</i>	1,00	1,12	0,31	0,09
13	<i>purelin</i>	<i>logsig</i>	1,00	1,12	0,31	0,09
14	<i>purelin</i>	<i>logsig</i>	1,00	1,12	0,31	0,09
15	<i>purelin</i>	<i>logsig</i>	1,00	1,12	0,31	0,09
16	<i>tansig</i>	<i>purelin</i>	0,87	0,99	0,27	0,10
17	<i>purelin</i>	<i>logsig</i>	1,00	1,12	0,31	0,10
18	<i>purelin</i>	<i>logsig</i>	1,00	1,12	0,31	0,09
19	<i>purelin</i>	<i>logsig</i>	1,00	1,12	0,31	0,10
20	<i>purelin</i>	<i>logsig</i>	1,00	1,12	0,31	0,09

Fonte: Autoria própria (2023).

Tabela 92 - Performance do algoritmo *trainbr* para predição de Vazão com banco de 1000 dados sintéticos padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>logsig</i>	<i>purelin</i>	0,76	0,90	0,24	0,10
2	<i>purelin</i>	<i>purelin</i>	0,76	0,91	0,24	0,07
3	<i>elliotsig</i>	<i>tansig</i>	0,74	0,89	0,24	0,09
4	<i>purelin</i>	<i>purelin</i>	0,75	0,89	0,24	0,07
5	<i>tansig</i>	<i>purelin</i>	0,76	0,90	0,24	0,10
6	<i>tansig</i>	<i>purelin</i>	0,75	0,89	0,24	0,09
7	<i>purelin</i>	<i>purelin</i>	0,75	0,89	0,24	0,08
8	<i>tansig</i>	<i>tansig</i>	0,75	0,89	0,24	0,08
9	<i>logsig</i>	<i>purelin</i>	0,77	0,91	0,24	0,09
10	<i>tansig</i>	<i>purelin</i>	0,76	0,91	0,24	0,10
11	<i>tansig</i>	<i>logsig</i>	0,86	1,02	0,27	0,11
12	<i>logsig</i>	<i>purelin</i>	0,77	0,91	0,24	0,08
13	<i>tansig</i>	<i>elliotsig</i>	0,76	0,91	0,24	0,07
14	<i>logsig</i>	<i>tansig</i>	0,73	0,88	0,23	0,09
15	<i>purelin</i>	<i>elliotsig</i>	0,77	0,91	0,24	0,07
16	<i>tansig</i>	<i>purelin</i>	0,74	0,89	0,24	0,09
17	<i>logsig</i>	<i>tansig</i>	0,76	0,90	0,24	0,09
18	<i>elliotsig</i>	<i>tansig</i>	0,76	0,90	0,24	0,08
19	<i>purelin</i>	<i>elliotsig</i>	0,77	0,91	0,24	0,07
20	<i>logsig</i>	<i>purelin</i>	0,77	0,91	0,24	0,10

Fonte: Autoria própria (2023).

Tabela 93 – Performance do algoritmo *trainbr* para predição de Vazão com banco de dados experimentais normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>logsig</i>	<i>tansig</i>	0,22	0,27	0,30	0,18
2	<i>logsig</i>	<i>tansig</i>	0,22	0,27	0,30	0,17
3	<i>elliotsig</i>	<i>tansig</i>	0,22	0,27	0,30	0,15
4	<i>logsig</i>	<i>purelin</i>	0,22	0,27	0,30	0,15
5	<i>tansig</i>	<i>elliotsig</i>	0,22	0,27	0,30	0,16
6	<i>purelin</i>	<i>elliotsig</i>	0,22	0,27	0,30	0,20
7	<i>logsig</i>	<i>tansig</i>	0,22	0,27	0,30	0,16
8	<i>logsig</i>	<i>tansig</i>	0,22	0,27	0,30	0,15
9	<i>logsig</i>	<i>tansig</i>	0,22	0,27	0,30	0,16
10	<i>logsig</i>	<i>purelin</i>	0,22	0,27	0,30	0,15
11	<i>logsig</i>	<i>elliotsig</i>	0,22	0,27	0,30	0,21
12	<i>tansig</i>	<i>tansig</i>	0,22	0,27	0,30	0,15
13	<i>logsig</i>	<i>elliotsig</i>	0,22	0,27	0,30	0,17
14	<i>logsig</i>	<i>purelin</i>	0,22	0,27	0,30	0,15
15	<i>logsig</i>	<i>tansig</i>	0,22	0,27	0,30	0,15
16	<i>tansig</i>	<i>tansig</i>	0,22	0,27	0,30	0,15
17	<i>purelin</i>	<i>tansig</i>	0,22	0,27	0,30	0,15
18	<i>logsig</i>	<i>elliotsig</i>	0,22	0,27	0,30	0,15
19	<i>purelin</i>	<i>elliotsig</i>	0,22	0,27	0,30	0,15
20	<i>logsig</i>	<i>purelin</i>	0,26	0,31	0,35	0,16

Fonte: Autoria própria (2023).

Tabela 94 - Performance do algoritmo *trainbr* para predição de Vazão com banco de 125 dados sintéticos normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>purelin</i>	<i>tansig</i>	0,23	0,27	0,27	0,13
2	<i>tansig</i>	<i>purelin</i>	0,23	0,27	0,27	0,13
3	<i>purelin</i>	<i>purelin</i>	0,23	0,27	0,27	0,14
4	<i>tansig</i>	<i>elliotsig</i>	0,24	0,27	0,27	0,10
5	<i>purelin</i>	<i>purelin</i>	0,24	0,27	0,27	0,10
6	<i>logsig</i>	<i>purelin</i>	0,24	0,28	0,28	0,10
7	<i>elliotsig</i>	<i>tansig</i>	0,23	0,27	0,27	0,15
8	<i>elliotsig</i>	<i>tansig</i>	0,24	0,27	0,27	0,12
9	<i>purelin</i>	<i>logsig</i>	0,28	0,31	0,31	0,09
10	<i>tansig</i>	<i>purelin</i>	0,24	0,27	0,27	0,13
11	<i>tansig</i>	<i>elliotsig</i>	0,24	0,27	0,27	0,12

12	<i>purelin</i>	<i>logsig</i>	0,28	0,31	0,31	0,10
13	<i>purelin</i>	<i>logsig</i>	0,28	0,31	0,31	0,09
14	<i>purelin</i>	<i>logsig</i>	0,28	0,31	0,31	0,09
15	<i>purelin</i>	<i>logsig</i>	0,28	0,31	0,31	0,10
16	<i>tansig</i>	<i>purelin</i>	0,23	0,27	0,27	0,11
17	<i>tansig</i>	<i>purelin</i>	0,23	0,27	0,27	0,12
18	<i>purelin</i>	<i>logsig</i>	0,28	0,31	0,31	0,09
19	<i>tansig</i>	<i>purelin</i>	0,24	0,27	0,27	0,11
20	<i>purelin</i>	<i>logsig</i>	0,28	0,31	0,31	0,09

Fonte: Autoria própria (2023).

Tabela 95 - Performance do algoritmo *trainbr* para predição de Vazão com banco de 1000 dados sintéticos normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>logsig</i>	<i>purelin</i>	0,19	0,23	0,24	0,10
2	<i>purelin</i>	<i>purelin</i>	0,19	0,23	0,24	0,07
3	<i>elliotsig</i>	<i>tansig</i>	0,19	0,22	0,24	0,09
4	<i>tansig</i>	<i>logsig</i>	0,22	0,26	0,27	0,12
5	<i>tansig</i>	<i>purelin</i>	0,19	0,23	0,24	0,10
6	<i>tansig</i>	<i>purelin</i>	0,19	0,22	0,24	0,09
7	<i>tansig</i>	<i>logsig</i>	0,22	0,26	0,27	0,08
8	<i>tansig</i>	<i>tansig</i>	0,19	0,23	0,24	0,08
9	<i>logsig</i>	<i>purelin</i>	0,19	0,23	0,24	0,09
10	<i>tansig</i>	<i>purelin</i>	0,19	0,23	0,24	0,10
11	<i>tansig</i>	<i>purelin</i>	0,19	0,23	0,24	0,09
12	<i>logsig</i>	<i>purelin</i>	0,19	0,23	0,24	0,08
13	<i>tansig</i>	<i>elliotsig</i>	0,19	0,23	0,24	0,07
14	<i>logsig</i>	<i>tansig</i>	0,18	0,22	0,23	0,09
15	<i>purelin</i>	<i>elliotsig</i>	0,19	0,23	0,24	0,07
16	<i>tansig</i>	<i>purelin</i>	0,19	0,22	0,24	0,09
17	<i>logsig</i>	<i>tansig</i>	0,19	0,23	0,24	0,09
18	<i>elliotsig</i>	<i>tansig</i>	0,19	0,23	0,24	0,08
19	<i>logsig</i>	<i>logsig</i>	0,22	0,26	0,27	0,09
20	<i>logsig</i>	<i>purelin</i>	0,19	0,23	0,24	0,10

Fonte: Autoria própria (2023).

- Algoritmo *traingd* para a predição da vazão

Para o algoritmo de treinamento *traingd* e banco de dados experimentais, 125 e 1000 dados sintéticos, estão representadas, respectivamente nas tabelas 96, 97 e 98 as melhores RNA

para esses bancos de dados padronizados, e nas tabelas 99, 100 e 101 as melhores RNA para esses bancos de dados normalizados

Tabela 96 - Performance do algoritmo *traingd* para predição de Vazão com banco de dados experimentais padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>purelin</i>	<i>elliotsig</i>	0,77	0,95	0,27	0,21
2	<i>purelin</i>	<i>purelin</i>	0,73	0,94	0,27	0,20
3	<i>logsig</i>	<i>purelin</i>	0,78	0,94	0,27	0,22
4	<i>logsig</i>	<i>logsig</i>	1,01	1,17	0,33	0,30
5	<i>logsig</i>	<i>tansig</i>	0,80	0,95	0,27	0,19
6	<i>tansig</i>	<i>tansig</i>	0,71	0,88	0,25	0,33
7	<i>elliotsig</i>	<i>purelin</i>	0,76	0,91	0,26	0,26
8	<i>logsig</i>	<i>tansig</i>	0,69	0,91	0,26	0,25
9	<i>logsig</i>	<i>elliotsig</i>	0,79	0,95	0,27	0,23
10	<i>purelin</i>	<i>logsig</i>	0,99	1,14	0,33	0,11
11	<i>purelin</i>	<i>logsig</i>	0,99	1,14	0,33	0,25
12	<i>tansig</i>	<i>purelin</i>	0,65	0,82	0,23	0,41
13	<i>tansig</i>	<i>purelin</i>	0,93	1,06	0,30	0,14
14	<i>tansig</i>	<i>purelin</i>	0,70	0,84	0,24	0,36
15	<i>tansig</i>	<i>tansig</i>	0,86	1,07	0,31	0,17
16	<i>elliotsig</i>	<i>tansig</i>	0,65	0,80	0,23	0,43
17	<i>elliotsig</i>	<i>elliotsig</i>	0,78	0,93	0,27	0,24
18	<i>elliotsig</i>	<i>purelin</i>	0,81	0,95	0,27	0,24
19	<i>elliotsig</i>	<i>tansig</i>	0,88	1,17	0,33	0,19
20	<i>elliotsig</i>	<i>purelin</i>	1,46	1,66	0,48	0,18

Fonte: Autoria própria (2023).

Tabela 97 - Performance do algoritmo *traingd* para predição de Vazão com banco de 125 dados sintéticos padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>purelin</i>	<i>purelin</i>	0,76	0,94	0,26	0,14
2	<i>purelin</i>	<i>purelin</i>	0,78	0,94	0,26	0,16
3	<i>tansig</i>	<i>purelin</i>	0,74	0,91	0,25	0,18
4	<i>elliotsig</i>	<i>tansig</i>	0,78	0,92	0,25	0,19
5	<i>purelin</i>	<i>purelin</i>	0,76	0,93	0,26	0,16
6	<i>purelin</i>	<i>elliotsig</i>	0,77	0,93	0,26	0,16
7	<i>elliotsig</i>	<i>purelin</i>	0,77	0,93	0,26	0,18

8	<i>logsig</i>	<i>elliotsig</i>	0,83	0,97	0,27	0,17
9	<i>logsig</i>	<i>tansig</i>	0,76	0,92	0,25	0,19
10	<i>purelin</i>	<i>logsig</i>	1,01	1,12	0,31	0,16
11	<i>elliotsig</i>	<i>purelin</i>	0,78	0,93	0,26	0,16
12	<i>purelin</i>	<i>elliotsig</i>	0,77	0,94	0,26	0,15
13	<i>purelin</i>	<i>elliotsig</i>	0,77	0,93	0,26	0,16
14	<i>tansig</i>	<i>purelin</i>	0,75	0,90	0,25	0,20
15	<i>logsig</i>	<i>purelin</i>	0,78	0,94	0,26	0,14
16	<i>elliotsig</i>	<i>tansig</i>	0,67	0,87	0,24	0,24
17	<i>logsig</i>	<i>tansig</i>	0,80	0,95	0,26	0,12
18	<i>tansig</i>	<i>elliotsig</i>	0,72	0,92	0,25	0,17
19	<i>elliotsig</i>	<i>tansig</i>	0,79	0,98	0,27	0,12
20	<i>logsig</i>	<i>purelin</i>	1,62	1,91	0,53	0,17

Fonte: Autoria própria (2023).

Tabela 98 - Performance do algoritmo *traingd* para predição de Vazão com banco de 1000 dados sintéticos padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>logsig</i>	<i>logsig</i>	0,89	1,04	0,28	0,09
2	<i>purelin</i>	<i>elliotsig</i>	0,74	0,89	0,24	0,09
3	<i>elliotsig</i>	<i>tansig</i>	0,74	0,89	0,24	0,09
4	<i>purelin</i>	<i>purelin</i>	0,72	0,88	0,23	0,09
5	<i>purelin</i>	<i>purelin</i>	0,72	0,88	0,23	0,09
6	<i>elliotsig</i>	<i>purelin</i>	0,72	0,88	0,23	0,10
7	<i>logsig</i>	<i>logsig</i>	0,88	1,03	0,27	0,10
8	<i>tansig</i>	<i>purelin</i>	0,73	0,87	0,23	0,09
9	<i>purelin</i>	<i>purelin</i>	0,72	0,88	0,23	0,09
10	<i>elliotsig</i>	<i>tansig</i>	0,67	0,87	0,23	0,12
11	<i>purelin</i>	<i>elliotsig</i>	0,73	0,88	0,23	0,08
12	<i>purelin</i>	<i>tansig</i>	0,72	0,88	0,23	0,08
13	<i>purelin</i>	<i>purelin</i>	0,72	0,88	0,23	0,09
14	<i>logsig</i>	<i>elliotsig</i>	0,73	0,88	0,23	0,08
15	<i>tansig</i>	<i>tansig</i>	0,78	0,93	0,25	0,11
16	<i>elliotsig</i>	<i>elliotsig</i>	0,73	0,89	0,24	0,06
17	<i>elliotsig</i>	<i>purelin</i>	0,72	0,90	0,24	0,06
18	<i>tansig</i>	<i>elliotsig</i>	0,69	0,84	0,22	0,17
19	<i>purelin</i>	<i>purelin</i>	10,13	11,99	3,19	0,04
20	<i>elliotsig</i>	<i>tansig</i>	0,72	0,89	0,24	0,07

Fonte: Autoria própria (2023).

Tabela 99 - Performance do algoritmo *traingd* para predição de Vazão com banco de dados experimentais normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>purelin</i>	<i>elliotsig</i>	0,24	0,28	0,32	0,25
2	<i>logsig</i>	<i>tansig</i>	0,23	0,27	0,30	0,18
3	<i>logsig</i>	<i>purelin</i>	0,20	0,24	0,27	0,23
4	<i>tansig</i>	<i>tansig</i>	0,20	0,25	0,28	0,20
5	<i>logsig</i>	<i>tansig</i>	0,25	0,30	0,34	0,24
6	<i>tansig</i>	<i>tansig</i>	0,18	0,23	0,26	0,32
7	<i>elliotsig</i>	<i>purelin</i>	0,19	0,23	0,26	0,26
8	<i>purelin</i>	<i>purelin</i>	0,22	0,24	0,27	0,25
9	<i>elliotsig</i>	<i>purelin</i>	0,20	0,24	0,27	0,21
10	<i>purelin</i>	<i>purelin</i>	0,18	0,24	0,27	0,18
11	<i>elliotsig</i>	<i>logsig</i>	0,30	0,35	0,40	0,19
12	<i>tansig</i>	<i>purelin</i>	0,18	0,23	0,26	0,27
13	<i>logsig</i>	<i>purelin</i>	0,27	0,32	0,35	0,36
14	<i>tansig</i>	<i>purelin</i>	0,18	0,22	0,24	0,36
15	<i>elliotsig</i>	<i>purelin</i>	0,20	0,24	0,27	0,22
16	<i>elliotsig</i>	<i>tansig</i>	0,16	0,20	0,23	0,43
17	<i>purelin</i>	<i>purelin</i>	0,21	0,25	0,28	0,20
18	<i>elliotsig</i>	<i>purelin</i>	0,21	0,24	0,27	0,23
19	<i>elliotsig</i>	<i>elliotsig</i>	0,19	0,23	0,26	0,29
20	<i>logsig</i>	<i>elliotsig</i>	0,21	0,24	0,27	0,27

Fonte: Autoria própria (2023).

Tabela 100 - Performance do algoritmo *traingd* para predição de Vazão com banco de 125 dados sintéticos normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>purelin</i>	<i>purelin</i>	0,21	0,26	0,26	0,14
2	<i>purelin</i>	<i>purelin</i>	0,21	0,26	0,26	0,13
3	<i>tansig</i>	<i>purelin</i>	0,20	0,25	0,25	0,18
4	<i>purelin</i>	<i>purelin</i>	0,20	0,25	0,26	0,17
5	<i>purelin</i>	<i>purelin</i>	0,20	0,26	0,26	0,16
6	<i>tansig</i>	<i>logsig</i>	0,33	0,38	0,38	0,17
7	<i>purelin</i>	<i>purelin</i>	0,21	0,25	0,25	0,17
8	<i>tansig</i>	<i>logsig</i>	0,29	0,33	0,33	0,14
9	<i>elliotsig</i>	<i>purelin</i>	0,21	0,25	0,25	0,16
10	<i>tansig</i>	<i>purelin</i>	0,24	0,30	0,30	0,15

11	<i>purelin</i>	<i>purelin</i>	0,57	0,67	0,67	0,16
12	<i>purelin</i>	<i>purelin</i>	0,21	0,26	0,26	0,16
13	<i>elliotsig</i>	<i>purelin</i>	0,19	0,26	0,26	0,20
14	<i>tansig</i>	<i>purelin</i>	0,22	0,27	0,27	0,17
15	<i>purelin</i>	<i>elliotsig</i>	0,21	0,31	0,31	0,11
16	<i>elliotsig</i>	<i>tansig</i>	0,19	0,25	0,25	0,22
17	<i>tansig</i>	<i>logsig</i>	0,30	0,33	0,33	0,15
18	<i>elliotsig</i>	<i>elliotsig</i>	0,21	0,27	0,27	0,16
19	<i>elliotsig</i>	<i>elliotsig</i>	0,23	0,27	0,27	0,10
20	<i>logsig</i>	<i>purelin</i>	0,45	0,53	0,53	0,17

Fonte: Autoria própria (2023).

Tabela 101 - Performance do algoritmo *traingd* para predição de Vazão com banco de 1000 dados sintéticos normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>logsig</i>	<i>logsig</i>	0,28	0,33	0,34	0,10
2	<i>purelin</i>	<i>elliotsig</i>	0,27	0,32	0,33	0,09
3	<i>tansig</i>	<i>purelin</i>	0,18	0,22	0,23	0,12
4	<i>purelin</i>	<i>purelin</i>	0,19	0,23	0,24	0,08
5	<i>tansig</i>	<i>elliotsig</i>	0,18	0,23	0,24	0,09
6	<i>tansig</i>	<i>elliotsig</i>	0,26	0,31	0,33	0,07
7	<i>logsig</i>	<i>logsig</i>	0,27	0,32	0,34	0,09
8	<i>tansig</i>	<i>purelin</i>	0,19	0,22	0,23	0,10
9	<i>purelin</i>	<i>logsig</i>	0,22	0,26	0,27	0,06
10	<i>elliotsig</i>	<i>tansig</i>	0,17	0,22	0,23	0,12
11	<i>purelin</i>	<i>elliotsig</i>	0,18	0,22	0,23	0,09
12	<i>purelin</i>	<i>tansig</i>	0,18	0,22	0,23	0,08
13	<i>purelin</i>	<i>purelin</i>	0,18	0,22	0,23	0,09
14	<i>elliotsig</i>	<i>elliotsig</i>	0,26	0,32	0,34	0,11
15	<i>tansig</i>	<i>tansig</i>	0,20	0,26	0,27	0,08
16	<i>tansig</i>	<i>purelin</i>	0,19	0,24	0,25	0,06
17	<i>elliotsig</i>	<i>logsig</i>	0,24	0,29	0,30	0,08
18	<i>tansig</i>	<i>logsig</i>	0,23	0,27	0,29	0,08
19	<i>tansig</i>	<i>logsig</i>	0,23	0,27	0,29	0,06
20	<i>elliotsig</i>	<i>tansig</i>	0,22	0,26	0,27	0,07

Fonte: Autoria própria (2023).

- Algoritmo *trainoss* para a predição da vazão

Para o algoritmo de treinamento *trainoss* e banco de dados experimentais, 125 e 1000 dados sintéticos, estão representadas, respectivamente nas tabelas 102, 103 e 104 as melhores RNA para esses bancos de dados padronizados, e nas tabelas 105, 106 e 107 as melhores RNA para esses bancos de dados normalizados

Tabela 102 - Performance do algoritmo *trainoss* para predição de Vazão com banco de dados experimentais padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>tansig</i>	<i>tansig</i>	0,75	0,95	0,27	0,20
2	<i>logsig</i>	<i>purelin</i>	0,70	0,96	0,28	0,16
3	<i>purelin</i>	<i>purelin</i>	0,74	0,92	0,26	0,24
4	<i>purelin</i>	<i>elliotsig</i>	0,75	0,96	0,27	0,18
5	<i>tansig</i>	<i>elliotsig</i>	0,69	0,96	0,28	0,21
6	<i>purelin</i>	<i>tansig</i>	0,84	1,01	0,29	0,18
7	<i>tansig</i>	<i>purelin</i>	0,67	0,90	0,26	0,34
8	<i>elliotsig</i>	<i>tansig</i>	0,71	0,94	0,27	0,22
9	<i>purelin</i>	<i>purelin</i>	0,80	0,95	0,27	0,21
10	<i>purelin</i>	<i>purelin</i>	0,76	0,96	0,27	0,19
11	<i>logsig</i>	<i>purelin</i>	0,72	0,90	0,26	0,29
12	<i>elliotsig</i>	<i>purelin</i>	0,74	0,94	0,27	0,28
13	<i>logsig</i>	<i>purelin</i>	0,70	0,88	0,25	0,29
14	<i>tansig</i>	<i>purelin</i>	0,58	0,80	0,23	0,46
15	<i>elliotsig</i>	<i>logsig</i>	1,15	1,49	0,43	0,16
16	<i>elliotsig</i>	<i>tansig</i>	0,74	0,86	0,25	0,32
17	<i>logsig</i>	<i>purelin</i>	1,03	1,26	0,36	0,24
18	<i>elliotsig</i>	<i>purelin</i>	0,69	0,81	0,23	0,41
19	<i>tansig</i>	<i>logsig</i>	0,99	1,15	0,33	0,16
20	<i>tansig</i>	<i>tansig</i>	1,09	1,26	0,36	0,10

Fonte: Autoria própria (2023).

Tabela 103 - Performance do algoritmo *trainoss* para predição de Vazão com banco de 125 dados sintéticos padronizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>tansig</i>	<i>purelin</i>	0,79	0,94	0,26	0,15
2	<i>purelin</i>	<i>purelin</i>	0,79	0,94	0,26	0,16
3	<i>purelin</i>	<i>purelin</i>	0,78	0,93	0,26	0,17
4	<i>purelin</i>	<i>elliotsig</i>	0,80	0,94	0,26	0,15

5	<i>purelin</i>	<i>purelin</i>	0,78	0,94	0,26	0,16
6	<i>elliotsig</i>	<i>purelin</i>	0,71	0,91	0,25	0,18
7	<i>purelin</i>	<i>purelin</i>	0,74	0,92	0,25	0,16
8	<i>tansig</i>	<i>purelin</i>	0,78	0,93	0,26	0,16
9	<i>tansig</i>	<i>elliotsig</i>	0,74	0,94	0,26	0,14
10	<i>logsig</i>	<i>purelin</i>	0,77	0,93	0,26	0,16
11	<i>logsig</i>	<i>purelin</i>	0,73	0,91	0,25	0,19
12	<i>purelin</i>	<i>elliotsig</i>	0,75	0,93	0,26	0,14
13	<i>purelin</i>	<i>purelin</i>	0,76	0,93	0,26	0,17
14	<i>purelin</i>	<i>tansig</i>	0,79	0,95	0,26	0,13
15	<i>logsig</i>	<i>purelin</i>	0,75	0,92	0,25	0,17
16	<i>purelin</i>	<i>purelin</i>	0,78	0,94	0,26	0,16
17	<i>elliotsig</i>	<i>purelin</i>	0,77	0,91	0,25	0,18
18	<i>purelin</i>	<i>purelin</i>	0,76	0,92	0,26	0,17
19	<i>logsig</i>	<i>tansig</i>	0,74	0,94	0,26	0,16
20	<i>logsig</i>	<i>elliotsig</i>	0,78	0,95	0,26	0,11

Fonte: Autoria própria (2023).

Tabela 104 - Performance do algoritmo *trainoss* para predição de Vazão com banco de 1000 dados sintéticos padronizados

NCO	Características da RNA		Medidas de performance			
	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>purelin</i>	<i>tansig</i>	0,74	0,88	0,23	0,08
2	<i>logsig</i>	<i>purelin</i>	0,73	0,88	0,23	0,10
3	<i>purelin</i>	<i>purelin</i>	0,76	0,90	0,24	0,10
4	<i>purelin</i>	<i>elliotsig</i>	0,74	0,88	0,24	0,09
5	<i>elliotsig</i>	<i>tansig</i>	0,73	0,88	0,23	0,10
6	<i>purelin</i>	<i>purelin</i>	0,73	0,88	0,23	0,09
7	<i>purelin</i>	<i>purelin</i>	0,72	0,87	0,23	0,10
8	<i>purelin</i>	<i>tansig</i>	0,73	0,89	0,24	0,07
9	<i>purelin</i>	<i>elliotsig</i>	0,74	0,88	0,23	0,08
10	<i>tansig</i>	<i>tansig</i>	0,74	0,88	0,24	0,08
11	<i>logsig</i>	<i>elliotsig</i>	0,74	0,88	0,23	0,11
12	<i>purelin</i>	<i>purelin</i>	0,73	0,88	0,23	0,10
13	<i>purelin</i>	<i>purelin</i>	0,72	0,87	0,23	0,10
14	<i>logsig</i>	<i>tansig</i>	0,73	0,88	0,23	0,10
15	<i>purelin</i>	<i>elliotsig</i>	0,74	0,89	0,24	0,08
16	<i>purelin</i>	<i>tansig</i>	1,49	1,75	0,46	0,09
17	<i>purelin</i>	<i>purelin</i>	0,73	0,88	0,23	0,08
18	<i>purelin</i>	<i>elliotsig</i>	0,73	0,89	0,24	0,08
19	<i>logsig</i>	<i>tansig</i>	0,74	0,89	0,24	0,05
20	<i>purelin</i>	<i>elliotsig</i>	0,74	0,88	0,23	0,09

Fonte: Autoria própria (2023).

Tabela 105 - Performance do algoritmo *trainoss* para predição de Vazão com banco de dados experimentais normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>elliotsig</i>	<i>tansig</i>	0,20	0,24	0,27	0,28
2	<i>tansig</i>	<i>purelin</i>	0,26	0,31	0,35	0,20
3	<i>tansig</i>	<i>tansig</i>	0,24	0,30	0,34	0,18
4	<i>logsig</i>	<i>tansig</i>	0,18	0,23	0,26	0,26
5	<i>elliotsig</i>	<i>elliotsig</i>	0,20	0,25	0,28	0,19
6	<i>logsig</i>	<i>elliotsig</i>	0,22	0,25	0,28	0,27
7	<i>tansig</i>	<i>purelin</i>	0,20	0,23	0,26	0,24
8	<i>purelin</i>	<i>purelin</i>	0,17	0,24	0,27	0,24
9	<i>tansig</i>	<i>elliotsig</i>	0,19	0,25	0,28	0,18
10	<i>purelin</i>	<i>purelin</i>	0,17	0,24	0,27	0,22
11	<i>logsig</i>	<i>purelin</i>	0,19	0,23	0,26	0,25
12	<i>elliotsig</i>	<i>purelin</i>	0,18	0,24	0,27	0,23
13	<i>logsig</i>	<i>purelin</i>	0,18	0,23	0,25	0,29
14	<i>tansig</i>	<i>purelin</i>	0,15	0,20	0,23	0,46
15	<i>elliotsig</i>	<i>purelin</i>	0,19	0,23	0,25	0,28
16	<i>elliotsig</i>	<i>tansig</i>	0,22	0,24	0,27	0,26
17	<i>tansig</i>	<i>purelin</i>	0,20	0,24	0,27	0,21
18	<i>elliotsig</i>	<i>purelin</i>	0,18	0,22	0,25	0,32
19	<i>purelin</i>	<i>purelin</i>	0,18	0,25	0,28	0,20
20	<i>tansig</i>	<i>tansig</i>	0,28	0,32	0,36	0,10

Fonte: Autoria própria (2023).

Tabela 106 - Performance do algoritmo *trainoss* para predição de Vazão com banco de 125 dados sintéticos normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>tansig</i>	<i>purelin</i>	0,21	0,26	0,26	0,13
2	<i>purelin</i>	<i>elliotsig</i>	0,23	0,27	0,27	0,05
3	<i>logsig</i>	<i>tansig</i>	0,22	0,26	0,26	0,11
4	<i>purelin</i>	<i>tansig</i>	0,22	0,26	0,26	0,17
5	<i>purelin</i>	<i>purelin</i>	0,20	0,25	0,25	0,16
6	<i>logsig</i>	<i>purelin</i>	0,20	0,25	0,25	0,18
7	<i>purelin</i>	<i>elliotsig</i>	0,22	0,26	0,26	0,16
8	<i>tansig</i>	<i>purelin</i>	0,21	0,25	0,25	0,17
9	<i>tansig</i>	<i>tansig</i>	0,21	0,25	0,25	0,18

10	<i>purelin</i>	<i>purelin</i>	0,21	0,26	0,26	0,17
11	<i>elliotsig</i>	<i>tansig</i>	0,21	0,26	0,26	0,15
12	<i>elliotsig</i>	<i>purelin</i>	0,21	0,25	0,25	0,26
13	<i>purelin</i>	<i>elliotsig</i>	0,22	0,26	0,26	0,16
14	<i>purelin</i>	<i>tansig</i>	0,22	0,26	0,26	0,13
15	<i>logsig</i>	<i>purelin</i>	0,21	0,25	0,25	0,17
16	<i>purelin</i>	<i>purelin</i>	0,22	0,26	0,26	0,17
17	<i>logsig</i>	<i>tansig</i>	0,21	0,26	0,26	0,14
18	<i>purelin</i>	<i>purelin</i>	0,21	0,26	0,26	0,16
19	<i>tansig</i>	<i>purelin</i>	0,23	0,28	0,28	0,09
20	<i>tansig</i>	<i>tansig</i>	0,24	0,31	0,31	0,08

Fonte: Autoria própria (2023).

Tabela 107 - Performance do algoritmo *trainoss* para predição de Vazão com banco de 1000 dados sintéticos normalizados

Características da RNA			Medidas de performance			
NCO	FACO	FACS	MAE	RMSE	NRMSE	R ²
1	<i>logsig</i>	<i>tansig</i>	0,19	0,23	0,24	0,09
2	<i>logsig</i>	<i>purelin</i>	0,18	0,22	0,23	0,10
3	<i>purelin</i>	<i>purelin</i>	0,19	0,23	0,24	0,11
4	<i>purelin</i>	<i>tansig</i>	0,19	0,22	0,24	0,10
5	<i>elliotsig</i>	<i>tansig</i>	0,19	0,22	0,23	0,10
6	<i>elliotsig</i>	<i>purelin</i>	0,18	0,22	0,23	0,09
7	<i>purelin</i>	<i>purelin</i>	0,18	0,22	0,23	0,10
8	<i>purelin</i>	<i>tansig</i>	0,18	0,22	0,24	0,07
9	<i>purelin</i>	<i>purelin</i>	0,18	0,22	0,23	0,07
10	<i>logsig</i>	<i>tansig</i>	0,18	0,22	0,23	0,08
11	<i>logsig</i>	<i>elliotsig</i>	0,19	0,22	0,23	0,11
12	<i>logsig</i>	<i>purelin</i>	0,18	0,22	0,23	0,09
13	<i>purelin</i>	<i>purelin</i>	0,18	0,22	0,23	0,09
14	<i>purelin</i>	<i>tansig</i>	0,19	0,22	0,23	0,09
15	<i>purelin</i>	<i>elliotsig</i>	0,19	0,22	0,24	0,09
16	<i>purelin</i>	<i>elliotsig</i>	0,19	0,22	0,23	0,09
17	<i>purelin</i>	<i>tansig</i>	0,18	0,22	0,23	0,10
18	<i>purelin</i>	<i>elliotsig</i>	0,19	0,22	0,24	0,10
19	<i>logsig</i>	<i>tansig</i>	0,19	0,22	0,24	0,05
20	<i>purelin</i>	<i>elliotsig</i>	0,19	0,23	0,24	0,05

Fonte: Autoria própria (2023).