

UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM
MEIO AMBIENTE E RECURSOS HÍDRICOS

**Aplicação de Redes Neurais Multicamadas Associadas a Algoritmos Genéticos
Aplicadas a Operação de Redes de Distribuição de Água com Vistas a Eficiência
Hidroenergética em Cidades Inteligentes.**

Alex Takeo Yasumura Lima Silva

Itajubá (MG)

2023

**UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM
MEIO AMBIENTE E RECURSOS HÍDRICOS**

Alex Takeo Yasumura Lima Silva

**Aplicação de Redes Neurais Multicamadas Associadas a Algoritmos Genéticos
Aplicadas a Operação de Redes de Distribuição de Água com Vistas a Eficiência
Hidroenergética em Cidades Inteligentes**

Tese submetida ao Programa de Pós-Graduação em Meio Ambiente e Recursos Hídricos como parte dos requisitos para obtenção do título de doutor.

Área de Concentração: Meio Ambiente e Recursos Hídricos

Orientador: Prof. Dr. Fernando das Graças Braga da Silva

Itajubá (MG)

2023

*Dedico meu doutorado aos meus tios:
Joaquim Tavares de Lima (In memoriam)
Sergio Yoshiaki Yasumura (In memoriam)
Dalva Lima Silva (In memoriam).*

AGRADECIMENTOS

A minha mãe Edna Shizue, e a minha avó Cida pela garra e coragem para enfrentar as dificuldades da vida sempre com otimismo e bom humor, sendo um exemplo e incentivo para superar os desafios da vida e a meu pai Danilo (*in memoriam*) por ter sempre me incentivado aos estudos e a pesquisa científica, através de sua inteligência, bom humor e desejo de aprender.

A toda minha família pelo apoio e incentivo, em especial aos meus primos William, Aline, Talyta, Paula, Sávio e Maria Rita, bem como às minhas tias Aurora, Tiemi, Rita e meu tio Sérgio (*in memoriam*) pela força nas horas difíceis.

A minha tia, Dalva Lima Silva (*in memoriam*), pelo seu apoio em momentos cruciais da minha vida, em especial durante minha graduação e mestrado, os quais sem sua generosa ajuda não teriam se concretizado. E no doutorado, pelas inúmeras lições de vida que me deu com a sua costureira firmeza, mas sempre com bom humor.

Agradeço a República Vó Gina, minha segunda família que muito me ajudou nessa caminhada, em especial ao Pedro Vieira Bertoni (*Hagrid*) e ao Anderson Rodrigo de Queiroz pelas inestimáveis ajudas com a parte computacional do trabalho, fora a amizade e respeito construídos ao longo do tempo.

Ao meu orientador, Prof. Dr. Fernando das Graças Braga da Silva, pela amizade, compreensão, apoio técnico e acima de tudo, humano em momentos difíceis pelos quais passei neste doutorado. Muito obrigado!

Aos amigos que fiz na UNIFEI, dentre eles: Paula Oda, minha “irmã acadêmica” a qual devo a enorme ajuda acadêmica e pela amizade forte que construímos; Gabriela Vasconcellos, pela lealdade e amizade; à Sara Marques, pela amizade e pela competência que muito me auxiliou nos trabalhos e nos algoritmos; Matheus Barbedo e Mateus Cortez, pelo respeito e apoio; ao Alexandre Marciano “Xandinho” pelo apoio e amizade construídos nesse período.

Agradeço ao Projeto Redecope Finep – MCT (Ref. 0983/10) - Ministério da Ciência e Tecnologia, intitulado “Desenvolvimento de tecnologias eficientes para a gestão hidroenergética em sistemas de abastecimento de água” e Programa Pesquisador Mineiro da Fapemig pelo PPM - 00755-16 além de ser grato ao NUMMARH- Núcleo de Modelagem em Simulação em Meio Ambiente e Recursos e Sistemas Hidricos da UNIFEI.

Agradeço a Universidade Federal de Itajubá pela Bolsa Institucional de nº 23088.037588/2021-72.

“Lei zero: Um robô não pode causar mal à humanidade ou, por omissão, permitir que a humanidade sofra algum mal”.

Isaac Asimov.

RESUMO

A escassez de recursos naturais, especialmente água e energia, colocam em risco o abastecimento de água para a população. Portanto, tornam-se necessários procedimentos para garantir a operação ótima de uma rede de distribuição de água. O uso de técnicas de otimização como os algoritmos genéticos garante a operação ótima da rede, contudo, apenas encontrar os pontos ótimos não bastam, uma vez que as oscilações da demanda produzem flutuações nas pressões, exigindo também uma capacidade de aprendizado que garanta a adaptabilidade da distribuição de água conforme as demandas, indo de encontro com o conceito de cidades inteligentes. Assim, para dar a rede de distribuição de água essa capacidade de aprendizado, foram empregadas Redes Neurais Artificiais (RNA) do tipo “*perceptron*” de uma camada oculta, sendo uma delas simples para atuar apenas em um ponto de demanda prevendo os valores dos parâmetros operacionais (RNF, válvulas e bombas), como prova de conceito e então foi elaborada uma RNA mais avançada, com sete camadas ocultas, de modo a prever os parâmetros operacionais para as últimas 72 horas. As Redes de Distribuição de Água utilizadas foram duas redes teóricas com 13 nós, 2 Reservatórios de Nível Fixo (RNF), 2 bombas e 3 válvulas, variando apenas a posição da malha. Para ambas as redes de distribuição, as previsões chegaram a um bom resultado na maioria dos pontos baseado na Norma NBR 12218/2017. Como conclusão, as Redes Neurais Artificiais demonstraram boa capacidade de previsão de operação quando aplicados a redes de distribuição de água devido a sua complexidade inerente, possuindo potencial para melhores resultados.

Palavras-chave: Algoritmos genéticos, Cidades inteligentes, Distribuição de água, Eficiência hidroenergética, Redes Neurais Artificiais.

ABSTRACT

The scarcity of natural resources, especially water and energy, put the population at risk of water supply. Therefore, they become necessary procedures to guarantee the optimal operation of a water distribution network. The use of optimization techniques such as genetic algorithms guarantees the optimal operation of the network, however, just finding the optimal points is not enough, since demand oscillations affect fluctuations in those presented, also presenting a learning capacity that guarantees the adaptability of the network. distribution of water according to demand, meeting the concept of smart cities. Thus, to give the water distribution network this learning capability, Artificial Neural Networks (ANN) of the “perceptron” type of a hidden layer were used, one of which is simple to act only at a demand point, predicting the values of the operational parameters (RNF, valves and pumps), as a proof of concept and then a more advanced ANN was developed, with seven hidden classes, in order to predict the operational specifications for the last 72 hours. The Water Distribution Networks used were two theoretical networks with 13 nodes, 2 Fixed Level Reservoirs (RNF), 2 pumps and 3 valves, varying only the mesh position. For both distribution networks, the predictions reached a good result in most points based on Norma NBR 12218/2017. As a conclusion, Artificial Neural Networks are proven to have a good capacity to predict operation when applied to water distribution networks due to their inherent complexity, having the potential for better results with future adjustments.

Keywords: Efficient Operation, Smart Cities, Neural Networks, Water Distribution.

LISTA DE ILUSTRAÇÕES

Figura 1 – Rede de distribuição de água	16
Figura 2 – Índice de perdas na distribuição (%).	18
Figura 3 – Fluxograma de um algoritmo genético	22
Figura 4 – Comparação dos Resultados.	23
Figura 5 – Rede Hanoi.....	24
Figura 6 – Circuito hidráulico esquemático de Bagmalek.	26
Figura 7 – Pressões na rede da cidade de Rasht.	27
Figura 8 – Rede hidráulica da cidade de Nagpur, Índia.	28
Figura 9 – Fluxograma simplificado do modelo.	29
Figura 10 – Rede BWFL adaptada.	30
Figura 11 – Neurônio biológico.	31
Figura 12 – Estrutura de um neurônio artificial.	31
Figura 13 – Funções de ativação mais usadas.	32
Figura 14 – Associação de neurônios no cérebro.	33
Figura 15 – Estrutura de uma rede perceptron multicamada.	33
Figura 16 – Metodologia Hold-Out	35
Figura 17 – K-Fold.	36
Figura 18 – Rede Neural Artificial utilizada no trabalho.	37
Figura 19 – Rede teórica para os testes.	39
Figura 20 – Acurácia dos modelos	41
Figura 21 – Fluxograma das etapas de trabalho	43
Figura 22 - Interface gráfica de entrada de dados.	44
Figura 23 - Fluxograma da rotina de cálculo hidráulico	45
Figura 24 - Rede T1 com os identificadores dos nós.	46
Figura 25 - Arranjo da rede T2.....	48
Figura 26 - Fluxograma do Algoritmo Genético.....	51
Figura 27 - Redes Neurais de Operação	55
Figura 28 – Arquitetura das Redes Neurais de Operação.....	56
Figura 29 - RNA de previsão.....	59
Figura 30 - Diagrama de blocos da RNA de Previsão.....	60
Figura 30 - Algoritmo da RNA de Operação.	64
Figura 31 - Comparação dos resultados.	68

Figura 33 - Fluxograma do Algoritmo de RNA de Previsão.....	69
Figura 33 - Demanda dos nós 3 a 8.	70
Figura 34 - Demandas dos nós 9 a 14.....	71
Figura 35 - Demanda do nó 15.	71
Figura 37 - Parâmetros de RNF 1 para a T1.....	72
Figura 38 - Parâmetros de RNF 2 para T1.....	73
Figura 39 - Parâmetros de bomba 1 para a rede T1.....	73
Figura 40 - Parâmetros da Bomba 2 para a rede T1.	74
Figura 41 - Parâmetros da Válvula 1 para a rede T1.....	74
Figura 42 - Parâmetros da Válvula 2 para a rede T1.....	75
Figura 43 - Parâmetros da Válvula 3 para a rede T1.....	75
Figura 44 – Parâmetros previstos de RNF 1 para a T1.....	76
Figura 45 – Parâmetros previstos de RNF 2 para T1.	77
Figura 46 - Parâmetros previstos de bomba 1 para a rede T1.	77
Figura 47 – Parâmetros previstos da Bomba 2 para a rede T1.....	78
Figura 48 - Parâmetros previstos da Válvula 1 para a rede T1.....	78
Figura 49 - Parâmetros da Válvula 2 para a rede T1.....	79
Figura 50 - Parâmetros da Válvula 3 para a rede T1.....	79
Figura 51 - Perdas e pressão média da rede T1.	82
Figura 52 - Dados da RNF 1 para a rede T2.....	83
Figura 53 – Dados da RNF 2 para a rede T2.....	84
Figura 54 – Dados da bomba 1 para a rede T2.....	84
Figura 55 – Dados da bomba 2 para a rede T2.....	85
Figura 56 – Dados da válvula 1 para a rede T2.....	85
Figura 57 – Dados da Válvula 2 para a rede T2.....	86
Figura 58 - Dados da Válvula 3 para a rede T2.....	86
Figura 59 – Dados previstos da RNF 1 para a rede T2.....	87
Figura 60 - Dados previstos da RNF 2 para a rede T2.	88
Figura 61 - Dados da bomba 1 para a rede T2.....	88
Figura 62 - Dados da bomba 2 para a rede T2.....	89
Figura 63 - Dados da valvula 1 para a rede T2.....	89
Figura 64 - Dados da valvula 2 para a rede T2.....	90
Figura 65 - Dados da válvula 3 para a rede T2.....	90
Figura 66 - Perdas e pressões médias para a rede T2.....	92

LISTA DE TABELAS

Tabela 1 - Dados de cotas e demandas da rede T1.....	46
Tabela 2 - Dados das tubulações e válvulas da rede.....	47
Tabela 3 - Dados de cotas e demandas da rede T2.....	48
Tabela 4 - Dados das tubulações e válvulas da rede T2.....	49
Tabela 5 – Cenário-base para a rede T1.....	62
Tabela 6 – Cenário-base para a rede T2.....	63
Tabela 7 - Resultados para a rede T1.....	65
Tabela 8 - Resultados para a rede T2.....	66
Tabela 9 - Resultados de pressões para a rede T1.....	80
Tabela 10 – Pressões calculadas com os parâmetros previstos para a rede T2.....	91

LISTA DE SIGLAS

AG – Algoritmo Genético

KNN – *K-Nearest Neighbor* (K-vizinho mais próximo)

LSTM – *Long Short Term Memory* (Memória de longo e curto prazo)

ML – *Machine Learning* (Aprendizado de máquina)

NBC – *Naive Bayesian Classification* (Classificação *naive* Bayesiana)

PRV – *Pressure Reduction Valve* (Válvula redutora de pressão)

ReLU – *Rectified Linear Unit* (Unidade linear retificada)

RF – *Random Forest* (Floresta Aleatória)

RNA – Redes Neurais Artificiais

SOM – *Self-Organizing Maps* (Mapas auto-organizáveis)

SVM – *Support Vector Machine* (Vetor de suporte de máquina)

VRP – Válvula Redutora de Pressão

SUMÁRIO

1.	INTRODUÇÃO.....	13
2.	OBJETIVOS	15
2.1	Objetivo geral.....	15
2.2	Objetivos específicos	15
3.	FUNDAMENTAÇÃO TEÓRICA	16
3.1	Redes de distribuição de água e perdas na distribuição	16
3.2	Eficiência hidroenergética nas redes de distribuição de água	18
3.3	Aplicações atuais de algoritmos genéticos em redes de distribuição de água	20
3.4	Operação em redes de distribuição de água: trabalhos recentes relacionados a temática em estudo	25
3.5	Redes Neurais Artificiais.....	30
3.6	Redes Neurais Artificiais e seu uso em redes de distribuição de água.....	37
4.	METODOLOGIA.....	43
4.1	Etapa 1 – Elaboração da rotina de cálculo hidráulico	43
4.2	Etapa 2 – Elaboração das Redes de Distribuição de Água teóricas para o estudo	45
4.3	Etapa 3 – Escolha de fatores de otimização e Algoritmos Genéticos	50
4.4	Etapa 4 – Elaboração das Redes Neurais Artificiais	53
4.5	Cálculo das perdas nas redes de distribuição de água	60
5.	RESULTADOS E DISCUSSÃO.....	62
5.1	Resultados dos cenários-base.....	62
5.2	Resultados para a Rede Neural de Operação.....	63
5.3	Resultados para a Rede Neural de Previsão.....	69
6.	CONCLUSÕES.....	94
7.	RECOMENDAÇÕES PARA TRABALHOS FUTUROS	96
	REFERÊNCIAS	98
	Anexo I.....	102
	Anexo II	104
	Anexo III.....	106
	Anexo IV	107
	Anexo V	109

1. INTRODUÇÃO

A água é de suma importância para a humanidade, uma vez que dela literalmente depende a sobrevivência do ser humano. Sua disponibilidade, em quantidade e qualidade, pode definir as condições de desenvolvimento, saúde e até mesmo a habitabilidade de uma determinada região. Assim, seu fornecimento de forma segura e confiável são indispensáveis para o progresso da sociedade como um todo.

Contudo, não basta apenas ter o acesso a água. É preciso submetê-la ao tratamento para que se enquadre nos padrões de potabilidade necessários para garantir a saúde humana e dispor de infraestrutura para fazer sua distribuição. É nesse ponto que começam os problemas, uma vez que as perdas se concentram nesta etapa, uma vez que podem ser tanto perdas comerciais referentes a erros de medição e ligações clandestinas como podem ser perdas reais, geradas por vazamentos resultantes de falhas nas tubulações, em grande parte resultante do excesso de pressões.

O controle das perdas reais passa pelo controle das pressões na distribuição, que envolve o ajuste de estratégias operacionais através de parâmetros como o bombeamento e o controle de válvulas de redução de pressão. Contudo, são necessárias simulações computacionais para se estudar as consequências das alterações dos parâmetros e o emprego de técnicas de otimização que permitam obter os valores para os parâmetros que cheguem a uma estratégia operacional mais próxima possível da ótima.

No entanto, há de se lembrar que as demandas (variável importante que influi nas pressões da rede), oscilam durante o dia devido aos hábitos dos consumidores. Assim, é fundamental que a rede de distribuição de água seja capaz também de ajustar seus parâmetros conforme as demandas, impedindo que em momentos de menor consumo as pressões excedam a Norma NBR 12218/17 ou a falta de abastecimento em períodos de maior consumo.

Assim, o uso de técnicas de aprendizado de máquina como as Redes Neurais Artificiais tornam-se fundamentais para garantir que a rede de distribuição de água seja capaz de aprender a operar ao longo de um dia através das flutuações de demanda, indo de encontro com o conceito de cidades inteligentes, aplicado para redes de distribuição de energia elétrica, trânsito, comunicações, dentre outros serviços essenciais ao cidadão e cuja integração e racionalização tornam-se cada vez mais necessários devido a escassez de recursos naturais, espaço e energia disponíveis nos centros urbanos.

Portanto, este trabalho busca associar a otimização da rede utilizando algoritmos genéticos com a sua operação inteligente utilizando redes neurais artificiais de modo que a rede sempre opere em condições ótimas e seja capaz de se adaptar a variações na demanda, indo de encontro com a necessidade das cidades inteligentes do futuro em que recursos como água e energia precisarão de gestão eficaz para garantir o suprimento a população.

2. OBJETIVOS

2.1 Objetivo geral

O presente trabalho propõe dois algoritmos para controle ótimo de redes de distribuição de água utilizando Redes Neurais Artificiais supervisionado por Algoritmos Genéticos para a previsão de seus parâmetros de operação através de suas demandas, sendo um apenas para um horário específico e outro, capaz de realizar a previsão de 24 horas de parâmetros de uma rede.

2.2 Objetivos específicos

Os objetivos específicos desta tese são:

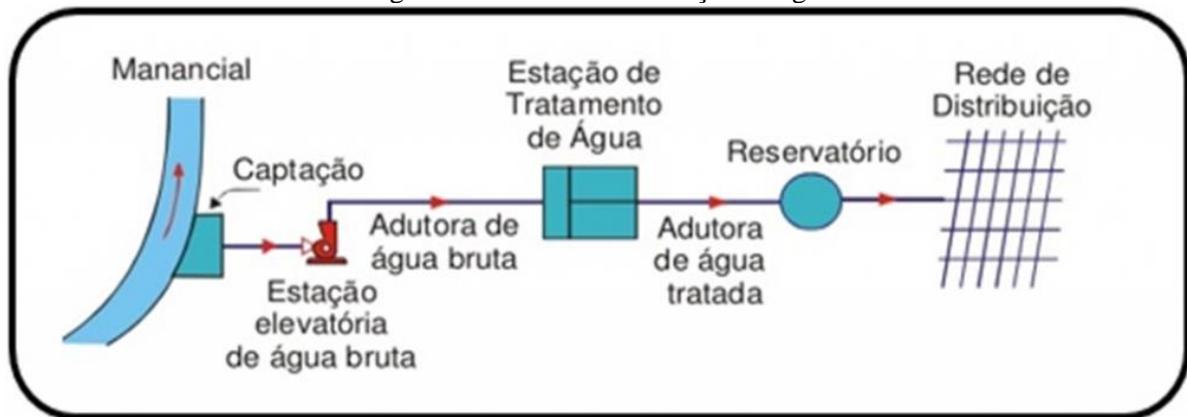
- a) Desenvolver um algoritmo de cálculo hidráulico em Python3, utilizando o pacote em R `epanet2toolkit`, para ler e simular arquivos `.inp` gerados pelo software EPANET;
- b) Propor um algoritmo genético capaz de otimizar uma rede de distribuição de água de modo a minimizar as perdas através da redução das pressões e atender aos requisitos de pressão mínimas e máximas;
- c) Elaborar uma Rede Neural Artificial do tipo *perceptron* capaz de realizar a operação da rede de distribuição de água para um determinado ponto de consumo, e assim, validar o conceito;
- d) Criar uma Rede Neural Artificial de aprendizagem profunda do tipo *perceptron* multicamada, utilizando as bibliotecas *tensorflow* e *keras*, capaz de aprender os parâmetros de operação da rede e se ajustar ao longo do tempo as variações de demanda;

3. FUNDAMENTAÇÃO TEÓRICA

3.1 Redes de distribuição de água e perdas na distribuição

Uma rede de distribuição de água é composta por tubulações, bombas, acessórios, reservatórios e demais equipamentos que lhe permitam atender, dentro de condições sanitárias e de vazão e pressão, aos pontos de consumo de uma cidade (PORTO, 2006). A Figura 1 apresenta um exemplo de arranjo de rede de distribuição de água.

Figura 1 – Rede de distribuição de água



Fonte: EOS Organização e Sistemas¹

Para que a rede de distribuição de água possa cumprir satisfatoriamente seu objetivo, é necessário um correto dimensionamento, que deve levar em conta fatores como a topografia, tipo de manancial disponível no local, população a ser atendida e a sua estimativa de crescimento, de modo que o sistema seja capaz de atender adequadamente a população durante muitos anos conforme (Tsutiya, 2006), sendo que os mananciais para abastecimento podem ser poços profundos e/ou rasos, lagos, rios e reservatórios formados por barragens.

Existem perdas em redes de distribuição de água, que podem ser segundo Kanakoudis e Muhammetoglu (2014) que podem ser aparentes ou comerciais, isto é, a água não faturada devido a ligações clandestinas, falhas em hidrômetros, contabilizações erradas do consumo de água e demais usos não autorizados de água e reais, ou seja, aquelas geradas por vazamentos oriundos de excessos de pressão, trincas nas tubulações, vazamentos, dentre outras causas.

Eletricidade e água são recursos essenciais para o desenvolvimento econômico e social. A demanda mundial por água vem crescendo continuamente ao longo dos anos,

¹ Disponível em: <https://www.eosconsultores.com.br/sistema-de-distribuicao-de-agua/>. Acesso em: 22 jan 2023.

aproximadamente 1% ao ano, enquanto o consumo de energia está previsto para crescer 28% até 2040, sendo que para se evitar a exploração de novas fontes, busque-se a redução das perdas para assegurar o atendimento (BAGRIYANIK; SONMEZ; BAGRIYANIK, 2023; CHINI; STILLWELL, 2018; PUGLIESE; GIUGNI, 2022).

Kanakoudis e Muhammetoglu (2014) mencionam perdas na ordem de 45 bilhões de m³ em todo o mundo, sendo que a redução pela metade dessas perdas seria capaz de abastecer cerca de 200 milhões de pessoas – quase o total da população brasileira - sem a necessidade de exploração de novos mananciais.

Já Fontana, Giugni e Portolano (2012) mencionam perdas na casa de 30 a 40% nas redes, na maioria das vezes devido a deterioração de seus componentes ao longo do tempo (tubulações, conexões, etc...) devido à falta de manutenção. Mutikanga, Sharma e Vairavamoorthy (2013), enfatizam que o fato de as tubulações estarem enterradas leva a negligência na manutenção até que apresentem vazamentos ou falhas, uma vez que usualmente se priorizam obras com maior impacto visual perante a população.

As perdas representam significativo prejuízo financeiro as companhias, na ordem de US\$ 14 bilhões de dólares ao ano em todo o mundo sendo particularmente mais crítico em países em desenvolvimento, pois tolhem a capacidade das companhias de investir em melhorias e expansão do sistema (MUTIKANGA; SHARMA; VAIRAVAMOORTHY, 2013).

Pinnto et al. (2016) mencionam que um projeto de rede de distribuição de água deveria balancear o custo de implantação, geralmente baixo, se comparado com o custo de manutenção que acaba por ser elevado devido à alta frequência de intervenções.

As perdas reais afetam diversos aspectos da operação das redes de distribuição de água, como a qualidade do serviço, piora no consumo energético e de insumos para tratamento, perdas econômicas e até mesmo riscos sanitários, sendo diretamente relacionadas ao envelhecimento das tubulações e ao excesso de pressão na rede, que causam rupturas. Assim, dada a importância do problema, as companhias de saneamento envidam esforços para reduzir suas perdas reais através do controle de pressões (GIUSTOLISI et al., 2023; SIMONE et al., 2018).

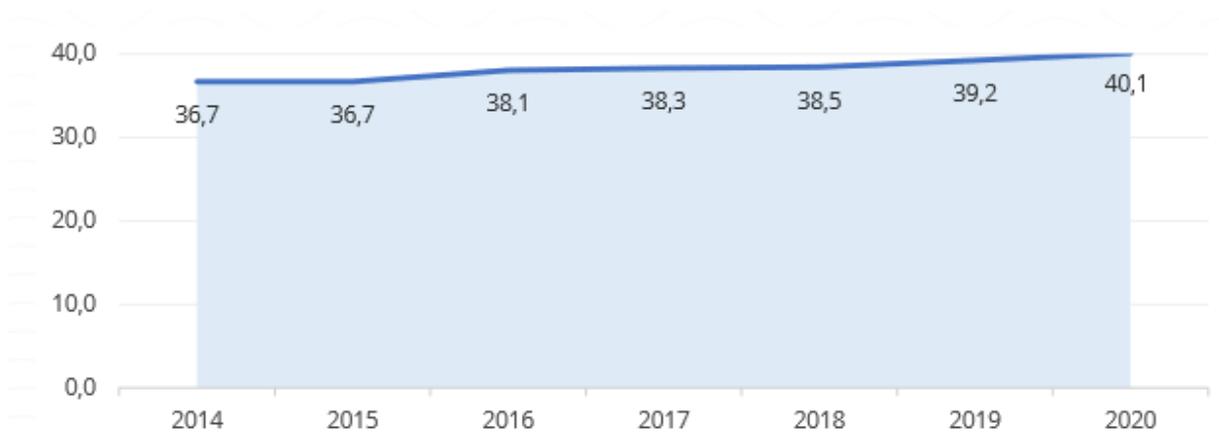
3.2 Eficiência hidroenergética nas redes de distribuição de água

A distribuição e o tratamento da água respondem por cerca de 7% do consumo mundial de energia, com previsão de aumento nos próximos anos segundo Coelho e Andrade-Campos (2014).

Portanto a melhoria da eficiência na operação de uma rede de distribuição de água é imperativa, uma vez que os consumos energético e de água vem crescendo constantemente ano após ano, possuindo significativo impacto econômico e ambiental (BAGRIYANIK; SONMEZ; BAGRIYANIK, 2023; PUGLIESE; GIUGNI, 2022).

O cenário brasileiro aponta perdas crescentes ao longo do tempo. O relatório do Serviço Nacional de Informações sobre Saneamento (BRASIL, 2021) vem apontando através do indicador IN049 – Índice de perdas na distribuição (perdas reais), um constante crescimento das perdas de água na distribuição desde 2015, como pode ser observado no gráfico da Figura 2.

Figura 2 – Índice de perdas na distribuição (%).



Fonte: Brasil (2021).

Assim, considerando todos os impactos que uma operação ineficiente associada as perdas crescentes possuem na economia, saúde e meio ambiente, torna-se necessário implementar medidas que aprimorem a eficiência das redes de distribuição de água, reduzindo perdas e naturalmente, reduzindo o consumo energético associado a água, utilizando, dentre outras possibilidades, o controle das pressões nas redes.

A norma técnica ABNT NBR nº 12.218/2017 (ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS, 2017), preconiza como limites de pressão nas redes de distribuição de

água os valores de 100 kPa (10 m.c.a.) para a pressão dinâmica mínima e 400 kPa (40 m.c.a.) de pressão estática máxima, sendo que pode ser admitido até 500 kPa (50 m.c.a.) em circunstâncias excepcionais, desde que justificadas.

Tsutiya (2006a) alerta para o pensamento equivocado de que pressões elevadas nas redes são sinônimo de um bom padrão de abastecimento de água.

Tal situação resulta, na realidade, em maior consumo energético devido ao bombeamento desnecessário, resultando em desperdício de energia, além do aumento do índice de perdas na distribuição, falhas nas tubulações e interrupções de serviço (TSUTIYA, 2006^a).

Como uma das medidas de melhoria de eficiência, Tsutiya (2006b) mostra a necessidade da adequação do projeto de bombeamento no que diz respeito ao dimensionamento dos motores, devendo ser feito de modo a evitar um baixo fator de carga.

Já Makisha e Kazimirova (2018) apontam um conjunto de medidas, que compreendem desde medidas de baixo custo até intervenções mais dispendiosas na rede. As medidas de baixo custo compreendem a operação adequada da rede de distribuição de água e seus equipamentos uma vez que muitas vezes carecem de instruções e/ou treinamentos adequados, e a correta manutenção dos equipamentos.

Dentre as medidas de baixo custo, Makisha e Kazimirova (2018) ressaltam a necessidade da operação adequada da rede de distribuição de água, uma vez que dentro da realidade brasileira, muitas vezes observa-se um grande desconhecimento das condições da rede.

Em alguns casos, chega-se ao ponto de faltarem informações básicas sobre as tubulações, como seu material e tempo de vida, prejudicando as ações de manutenção preventiva como recondiçionamentos e substituições, que poderiam incrementar a eficiência com maior rapidez e menor custo.

As medidas de custo médio, segundo Makisha e Kazimirova (2018) compreendem melhorias na rede de distribuição de água como readequação do projeto dos condutos em termos de diâmetro, cujo aumento em até 50% pode ser capaz de reduzir 75% das perdas de carga bem como a adoção de condutos com revestimentos menos rugosos, controle do consumo de água e prevenção de vazamentos, campanhas de uso consciente com a população, análise do consumo de água e operação econômica das bombas.

Assim, tais medidas certamente contribuem para a melhoria da eficiência hidroenergética da distribuição de água. Contudo, o foco deste trabalho é a melhoria obtida

através de otimizações na sua operação, incluindo a operação de bombas e válvulas, cujos pormenores serão abordados na seção 3.3 e 3.4.

3.3 Aplicações atuais de algoritmos genéticos em redes de distribuição de água

A técnica de otimização aqui descrita foi desenvolvida por John Holland em 1975, sendo baseada no princípio do naturalista inglês Charles Darwin, que é o da seleção natural e da sobrevivência dos mais aptos, onde afirma que o indivíduo mais bem adaptado ao seu ambiente terá maior chance de sobreviver e gerar descendentes (LACERDA; CARVALHO, 1999).

Durante a reprodução, fenômenos como a mutação – onde partes do material genético armazenado nos cromossomos sofrem alterações aleatórias – podem ocorrer, bem como o cruzamento, isto é, a mistura do material genético dos pais, que resulta em uma nova combinação nos filhos, que herdam suas características, fazendo assim com que haja a variabilidade nas espécies, essencial para a sua sobrevivência (LACERDA; CARVALHO, 1999).

Os Algoritmos Genéticos (AG) são empregados em diversas áreas do conhecimento humano onde há a necessidade de otimização de variáveis. Contudo, sua terminologia é fortemente baseada nos conceitos biológicos, como Lacerda e Carvalho (1999) descrevem como sendo como uma metáfora da seleção natural, listando então os termos mais utilizados:

- a) Cromossomo ou genoma: Genoma é o conjunto completo de genes de um organismo, podendo possuir vários cromossomos. Nos AGs, representam a estrutura de dados que codifica uma solução para um problema, logo, um cromossomo ou genoma representa um simples ponto no espaço de busca;
- b) Gene: A unidade de hereditariedade transmitida pelo cromossomo, nos AGs é um parâmetro codificado no cromossomo;
- c) Indivíduo: Um membro da população, nos AGs é formado pelo cromossomo e sua aptidão;
- d) Genótipo: A composição genética contida no Genoma, nos AGs é a informação contida no cromossomo;
- e) Fenótipo: Nos AGs, representa o objeto constituído pelas informações do genótipo;
- f) Alelo: Uma das formas alternativas de um gene, sendo que nos AGs representa os valores que o gene pode assumir;

- g) Epistasia: Interação entre os genes do cromossomo, ou seja, quando um valor de gene influencia o valor de outro gene. Problemas com altas epistasias são difíceis de serem resolvidos por AGs.

Assim, Lacerda e Carvalho (1999) também elencam uma série de vantagens dos Ags, sendo que algumas delas tornam-se particularmente interessantes para utilização em recursos hídricos, como:

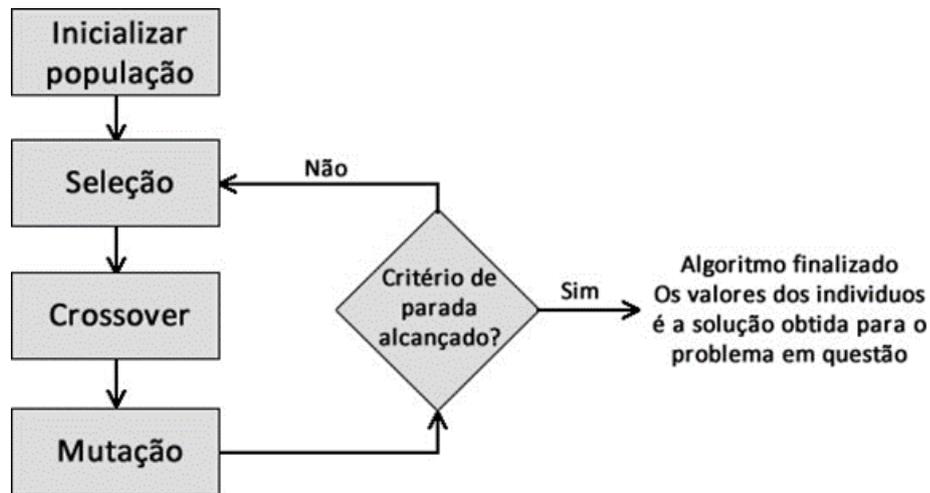
- a) Capacidade de funcionar com parâmetros contínuos, discretos, ou uma combinação de ambos;
- b) Realização de buscas simultâneas em várias regiões pois trabalham com uma população e não um ponto;
- c) Capacidade de otimizar grande número de variáveis;
- d) Fácil implementação em computadores;
- e) Modularidade e portabilidade: O mecanismo de evolução é separado do problema, podendo ser transferido e adaptado de um problema para outro;
- f) Flexibilidade com restrições arbitrárias e capacidade de otimizar múltiplas funções com objetivos conflitantes;
- g) Podem ser hibridizados com outras técnicas e heurísticas.

De todas essas vantagens, destacam-se para este trabalho a capacidade de otimização de grande número de variáveis, a facilidade de implementação computacional, sua modularidade e principalmente a capacidade de ser hibridizada com outras técnicas, uma vez que se prevê um uso conjunto com Redes Neurais Artificiais.

Uma grande questão no algoritmo genético é o critério de parada. Conforme Lacerda e Carvalho (1999), podem ser utilizados um número determinado de iterações (chamadas gerações), uma quantidade de soluções obtidas ou a obtenção de uma solução apenas que atenda aos requisitos.

A Figura 3 ilustra de modo bastante simples, mas didático, o funcionamento de um algoritmo genético:

Figura 3 – Fluxograma de um algoritmo genético



Fonte: Computa o Inteligente – O algoritmo gen tico²

Os Algoritmos Gen ticos s o uma t cnica que pode ser considerada cl ssica na solu o de diversos problemas de otimiza o em redes de distribu o de  gua. Nesse sentido, Savic e Walters (1997) os utilizam com a finalidade de se obter o menor custo para o projeto de uma rede de distribu o de  gua atrav s do desenvolvimento de um modelo computacional chamado GANET.

Savic e Walters (1997) n o mencionam maiores detalhes acerca da linguagem de programa o utilizada, mas afirmam que o uso de algoritmo gen tico se mostra vantajoso pois   capaz de solucionar problemas como o de minimiza o de custos sem necessidade de lineariza es, com a vantagem de ser capaz de atuar com valores discretos – no caso, os di metros das tubula es.

Na mesma linha de se obter o menor custo poss vel no projeto e expans o de redes de distribu o, Gupta, Gupta e Khanna (1999), onde os autores desenvolveram o algoritmo gen tico em linguagem FORTRAN e o comparam com t cnicas de programa o n o-linear.

Gupta, Gupta e Khanna (1999) ressaltando a superioridade do algoritmo gen tico, enfatizaram que por ser capaz de obter v rios picos de solu o durante a busca, reduzindo o risco de ficarem presos a um ponto de m nimo local, ainda que os resultados convirjam mais lentamente.

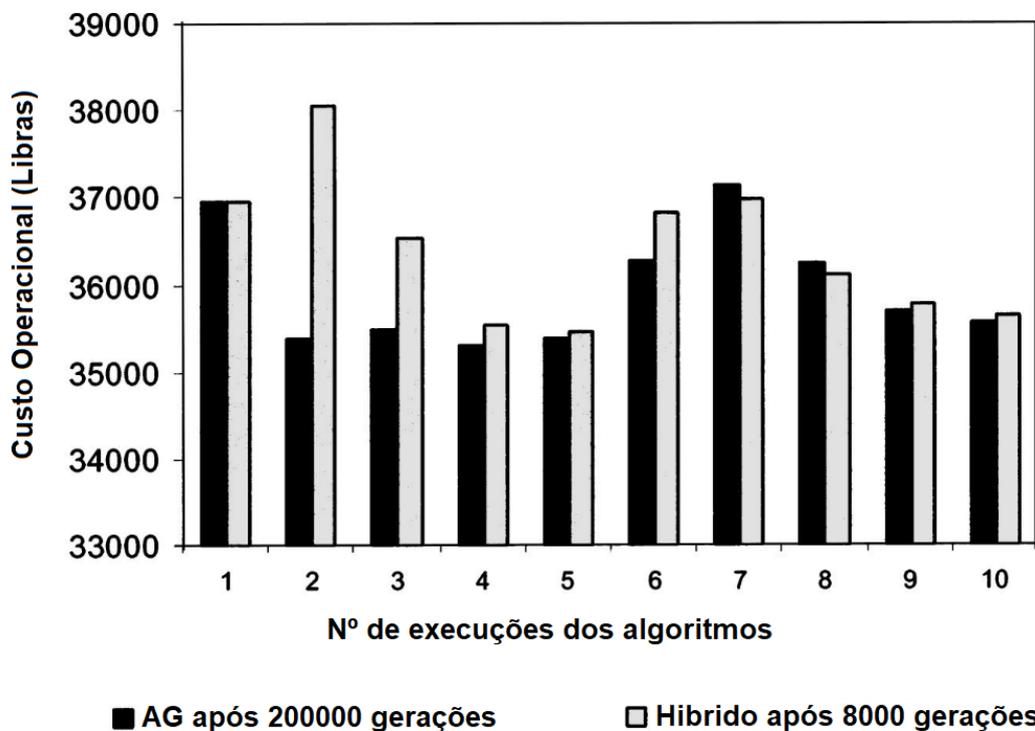
J  visando a opera o  tima, Van Zyl, Savic e Walters (2004) empregaram algoritmos gen ticos h bridos e puros para a otimiza o da opera o de uma rede de distribu o de  gua

² Dispon vel em: <http://computacaointeligente.com.br/algoritmos/o-algoritmo-genetico/>. Acesso em: 23 nov. 2017.

em Richmond, Reino Unido. Segundo os autores, a hibridização tornou-se necessária pois os algoritmos genéticos possuem uma boa convergência inicial, contudo, tornam-se menos eficientes ao longo das gerações para obter soluções quase ótimas.

Van Zyl, Savic e Walters (2004) utilizaram o método de busca de subida de montanha (*Hillclimb Method*) incorporado ao algoritmo genético, obtendo em 8000 gerações resultados próximos aos obtidos em 200000 gerações do algoritmo genético puro, como pode ser visto na Figura 4.

Figura 4 – Comparação dos Resultados.



Fonte: Van Zyl, Savic e Walters (2004) (Adaptado).

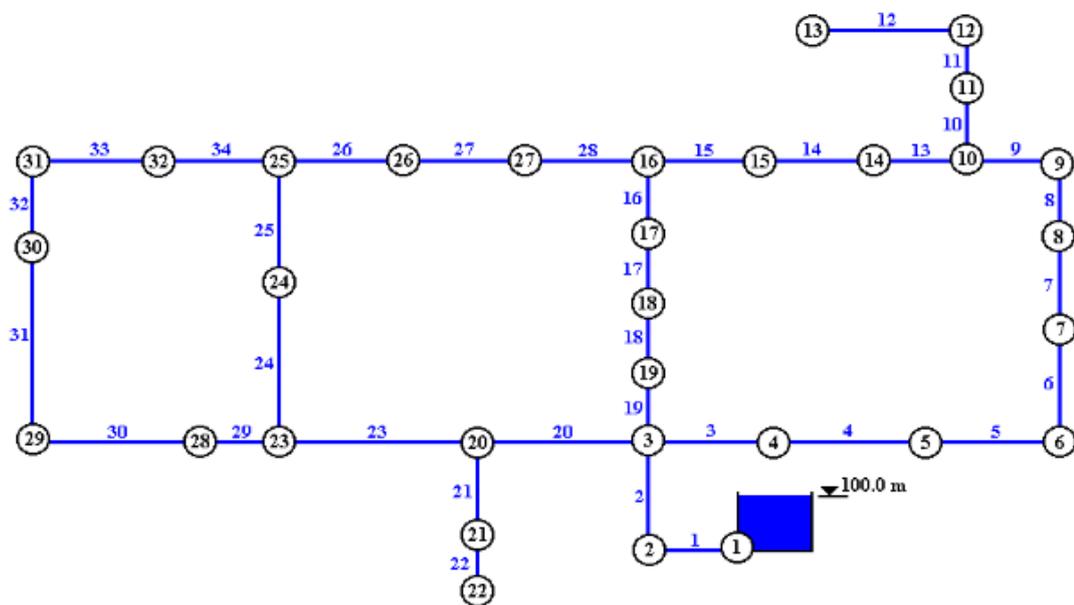
Na mesma linha dos algoritmos genéticos hibridizados, Costa, Ramos e De Castro (2010) compararam um algoritmo genético simples e um algoritmo genético hibridizado para reduzir custos de operação para a rede de distribuição da cidade de Ourém, Portugal. No caso, a hibridização consiste em adicionar penalidades as soluções não aptas, de modo a torná-las inviáveis.

Os algoritmos foram desenvolvidos utilizando a toolkit EPANET, sem que os autores fornecessem maiores dados acerca da linguagem de programação utilizada. Assim, Costa, Ramos e De Castro (2010) obtiveram com o algoritmo genético hibridizado resultados em 4 minutos, resultado superior ao algoritmo simples que levou 22 minutos para tal, fato que os

autores ressaltam como vantagem para fornecer aos gestores da rede estratégias operacionais em menor tempo, assegurando a operação ótima e econômica da rede.

Em uma abordagem mais recente, Van Dijk, Van Vuuren e Van Zyl (2018) empregaram algoritmos genéticos para desenvolver um software, em conjunto com o simulador EPANET de otimização de redes de distribuição de água, utilizando penalidades ponderadas, denominado GANEO, o qual foi testado em alguns *benchmarks* do EPANET como a rede Hanoi, vista na Figura 5, obtendo resultados em 2,7 minutos, quando comparados a outros algoritmos genéticos.

Figura 5 – Rede Hanoi.



Fonte: Van Dijk, Van Vuuren e Van Zyl (2018) (Adaptado)

Embora tenham se tornado populares para se obter soluções ótimas ou quase-ótimas em otimizações em redes de distribuição de água, possuem também o inconveniente de consumir grande tempo computacional em determinados casos, chegando a ponto de consumir dias de processamento ou exigir computadores muito poderosos em simulações de redes reais (TANYIMBOH; SEYOUM, 2017).

Assim, Tanyimboh e Seyoum (2017), apontam como solução o uso de computação paralela, ou seja, a utilização em paralelo de dois processadores sendo um responsável pela geração da população inicial e outro responsável pela seleção, cruzamento e mutação da população. Assim, consegue-se uma redução de tempo computacional para apenas 6,7% do

tempo de um algoritmo em série, uma vantagem que não se pode desprezar em situações de otimização de muitos parâmetros ou a necessidade de utilização do algoritmo repetidas vezes.

Para analisar as incertezas decorrentes da operação de redes de distribuição malhadas, como demandas, rugosidades, diâmetros, níveis de reservatório, dentre outras, Sivakumar, Prasad e Chandramouli (2016) utilizaram algoritmos genéticos incorporados ao EPANET, programados em MATLAB.

Sivakumar, Prasad e Chandramouli (2016) mostraram como vantagem que o método é capaz de solucionar as questões das incertezas de operação da rede independente de seu tamanho, ainda que ao custo de um maior tempo computacional e das análises separadas de pressões e vazões da rede.

3.4 Operação em redes de distribuição de água: trabalhos recentes relacionados a temática em estudo

Operar uma rede de distribuição de água envolve uma série de fatores, entre eles o custo relativo ao funcionamento de bombas, cujo objetivo é suprir as demandas, que por sua vez são revestidas de incerteza, conforme Ougui (2003).

Ougui (2003) ressalta a importância do dimensionamento e operação das bombas, que precisam ser adequadas para evitar desperdícios de energia elétrica. Além do bombeamento, Van Dijk, Van Vuuren e Van Zyl (2018) mencionam também como parâmetros operacionais os níveis de reservatório e controle de válvulas, que foram empregados nesta tese.

Este trabalho não tem a pretensão de esgotar a literatura sobre o assunto, mas sim apontar exemplos recentes que se enquadrem no escopo deste trabalho. Assim, a revisão sistemática da literatura realizada por Santos (2021), voltada a aplicação de métodos de otimização em redes de distribuição de água será a base desta seção.

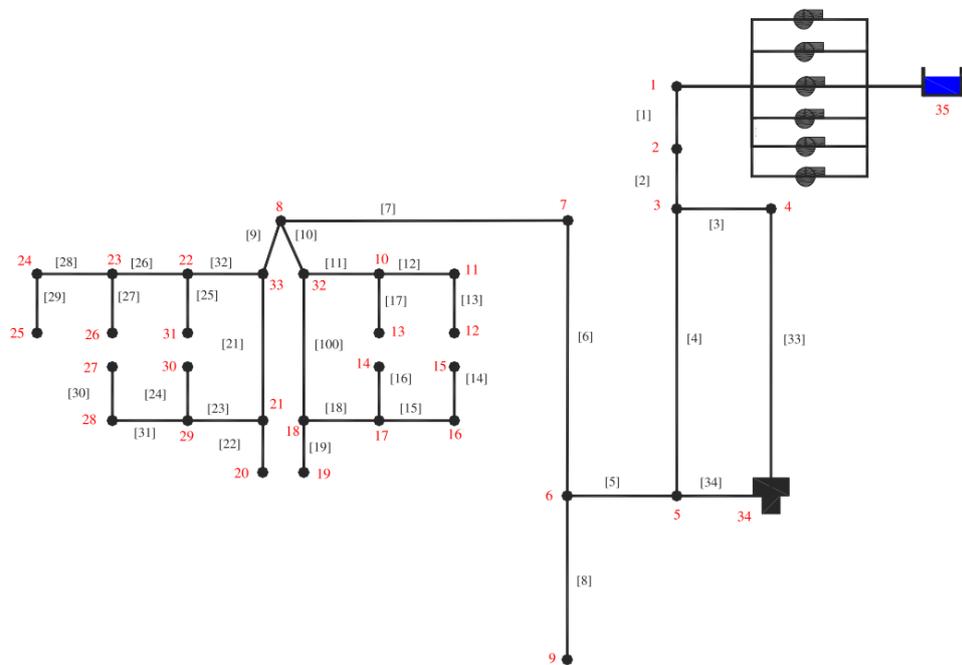
Portanto, do trabalho de Santos (2021) foram selecionados alguns trabalhos os quais, pelas suas abordagens, irão embasar a parte de operação desta tese, buscando uma aderência com os temas observados e a proposta do trabalho.

Assim, Marchi, Simpson e Lambert (2016) realizaram uma modificação na *toolkit* EPANET2 com o emprego de algoritmos genéticos para a otimização das operações de bombeamento, de modo a se resolver os problemas associados ao computo da energia gasta no bombeamento e seus custos.

Marchi, Simpson e Lambert (2016) afirmam que a nova *toolkit*, denominada ETTAR-EPANET2, passou a obter soluções melhores em custo-benefício, ainda que as custas de maior tempo computacional, uma vez que o algoritmo genético acaba criando um conjunto de regras operacionais ótimos para as bombas, conseqüentemente demandando mais tempo para tal.

Já Makaremi, Haghighi e Ghafouri (2017) também utilizaram algoritmos genéticos e o simulador EPANET para otimizar a operação de bombas em uma rede real na cidade de Baghmalek, Irã, cujo esquemático pode ser visto na Figura 6.

Figura 6 – Circuito hidráulico esquemático de Baghmalek.



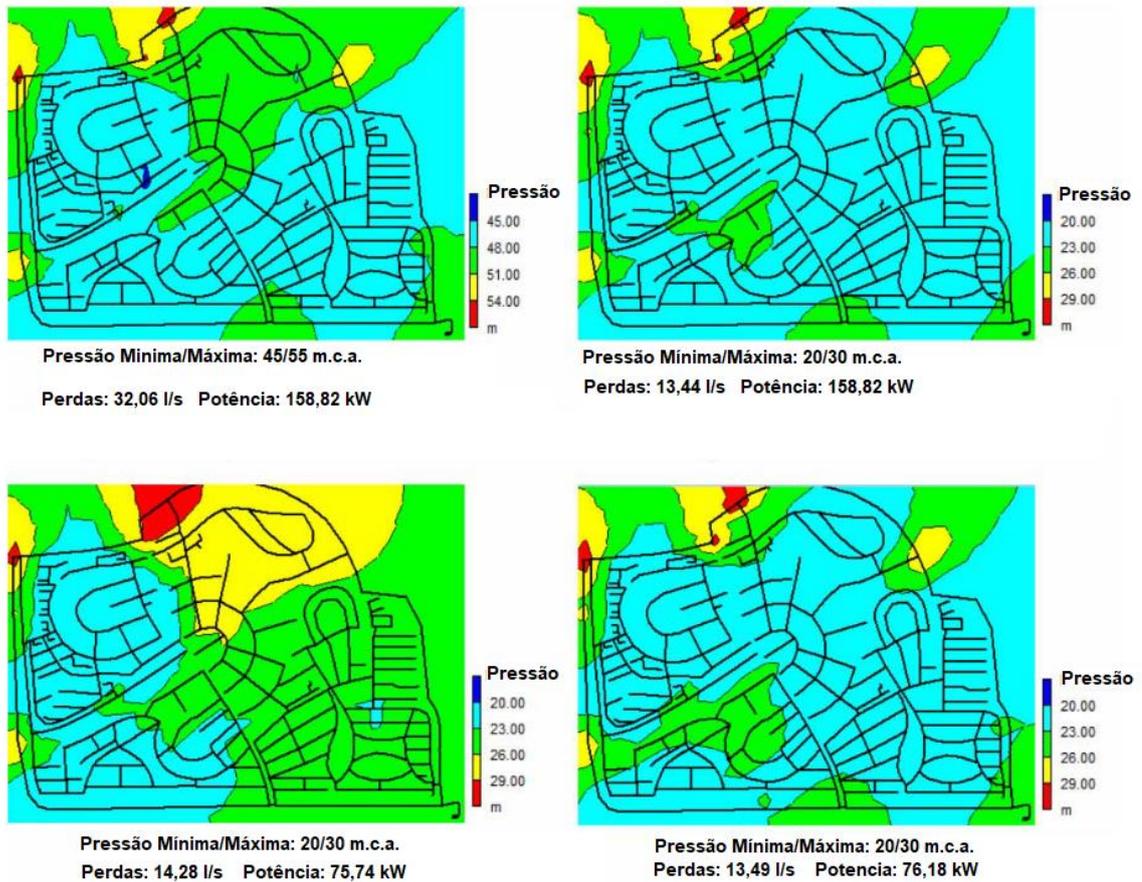
Fonte: Makaremi, Haghighi e Ghafouri (2017) (adaptado).

Aqui, Makaremi, Haghighi e Ghafouri (2017) ressaltam que um bom software de operação de bombas pode trazer ganhos significativos apenas na operação, ressaltando que houve uma redução no custo energético de 10%, além de melhorias na confiabilidade da operação.

A gestão das pressões em uma rede é tratada por Monsef et al. (2018), onde foram empregados algoritmos de evolução diferencial na linguagem MATLAB, juntamente ao simulador hidráulico EPANET para a otimização de parâmetros de bombas e válvulas em uma rede real na cidade de Rasht, Irã.

As perdas, inicialmente de 32,06 L/s passaram para 13,49 L/s e a potência consumida pelas bombas caiu de 158,82 kW para 76,18 kW. A Figura 7 mostra o mapa de pressões na rede ao longo das otimizações.

Figura 7 – Pressões na rede da cidade de Rasht.

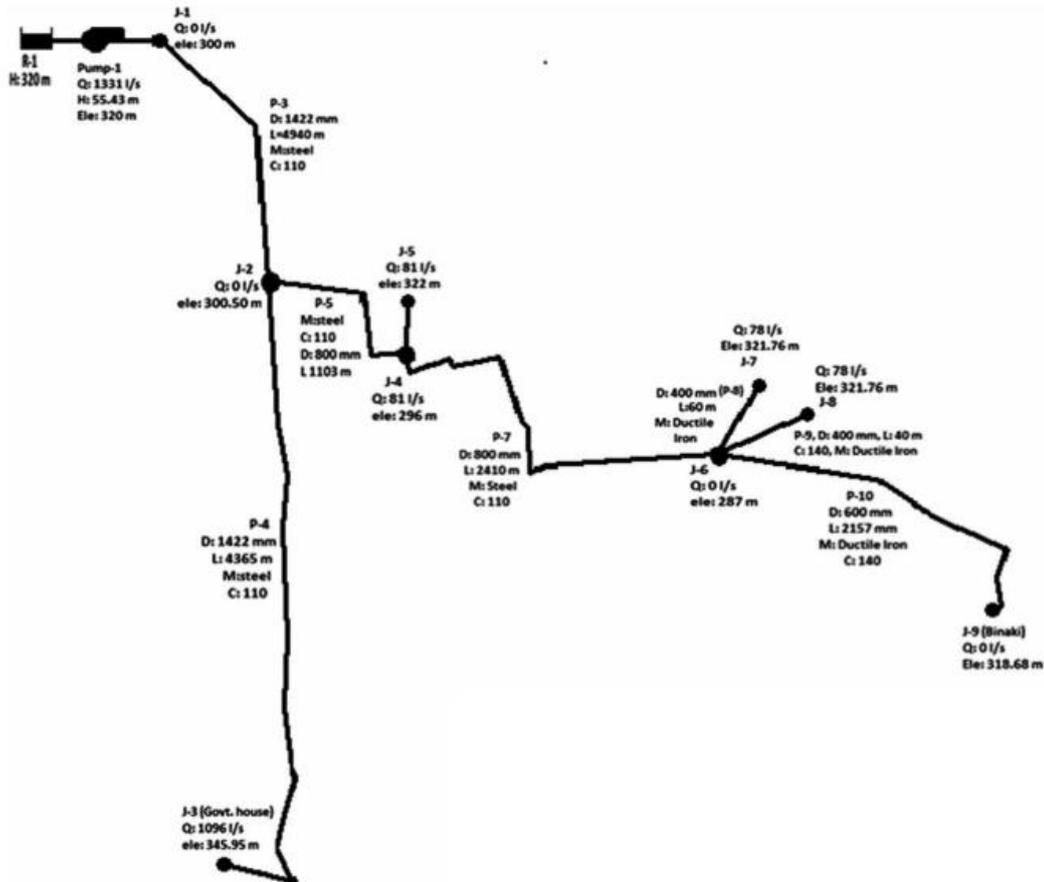


Fonte: Monsef et al. (2018) (adaptado).

O trabalho de Gupta, Dinesh e Kulat (2018) também segue a linha da busca pela redução de perdas por vazamentos através da gestão de pressões usando bombas de rotação variável e válvulas de redução de pressão, para a rede da zona central da cidade de Nagpur, Índia.

Foram utilizados o simulador hidráulico EPANET e um algoritmo genético implementado em MATLAB. O esquema hidráulico da rede pode ser observado na Figura 8.

Figura 8 – Rede hidráulica da cidade de Nagpur, Índia.



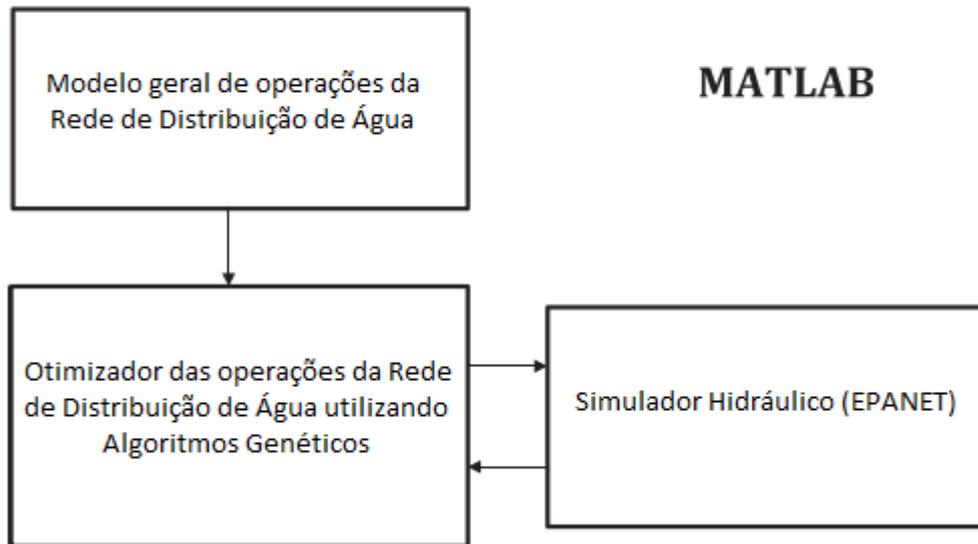
Fonte: Adaptado de Gupta, Dinesh e Kulat (2018).

Os autores apresentam resultados bastante expressivos com a melhor gestão da rede, com reduções de perdas de 16,57% até 26,30% conforme as mudanças nos padrões de demanda, gerando uma economia média diária de 5,066 MI de água, e mantendo as pressões dentro dos limites mínimos requeridos, sem que haja deficiências na rede.

Na mesma linha de operação, porém agora em condições críticas, Khatavkar e Mays (2019) propuseram um modelo de otimização e simulação em tempo real para operação de bombas e válvulas em redes de distribuição de água operando em condições críticas como disponibilidade limitada de energia e água em emergências como secas, falhas na rede elétrica, desastres naturais e promovidos por ação humana, entre outras contingências.

O modelo foi desenvolvido por Khatavkar e Mays (2019) em MATLAB, também empregando o simulador EPANET e algoritmos genéticos para a sua otimização, como pode ser visto no fluxograma simplificado da Figura 9.

Figura 9 – Fluxograma simplificado do modelo.



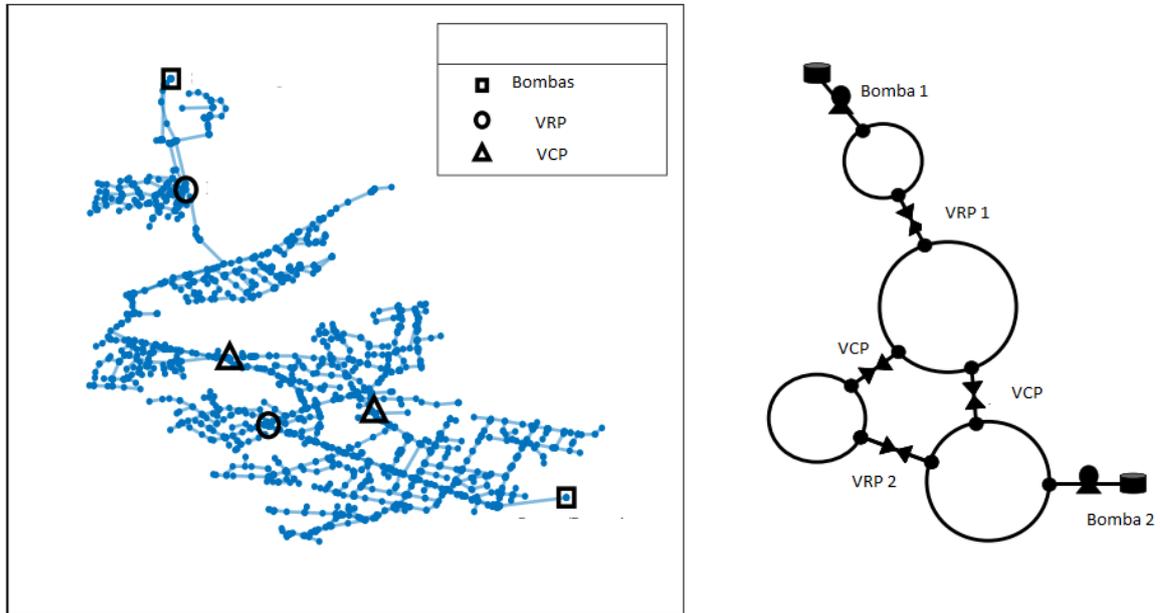
Fonte: Adaptado de Khatavkar e Mays (2019).

Khatavkar e Mays (2019) ressaltam em seu trabalho a nova metodologia, enfatizando que a mesma pode ser aplicada em redes reais minimizando a diferença entre as demandas solicitadas e atendidas na rede, podendo ser associadas a modelos de otimização e simulação convencionais como uma solução mais robusta em situações de falhas sequenciais ocasionadas por contingências diversas.

O trabalho de Nerantzis, Pecci e Stoianov (2020) também segue a linha de operação ótima, mas desta vez para redes sem reservatórios, formulando e resolvendo a operação da rede matematicamente, sem uso de simuladores como o EPANET, através do uso de programação não-linear não-convexa para se obter curvas ótimas para as bombas de velocidade variável e válvulas de redução de pressão.

O estudo foi feito utilizando a “*Bristol Water Field Lab*” (BWFL) modificada para o propósito, como pode ser visto na Figura 10.

Figura 10 – Rede BWFL adaptada.



Fonte: Adaptado de Nerantzis, Pecci e Stoianov (2020).

Uma vez que não utiliza simuladores hidráulicos e nem algoritmos genéticos, os autores enfatizam a velocidade de solução da otimização, que segundo eles, pode chegar a segundos com computadores convencionais, algo que é desejável para operações em tempo real de grandes redes.

3.5 Redes Neurais Artificiais

O conceito de Redes Neurais Artificiais não é exatamente novo, iniciando-se em 1943 com McCulloch, o qual realizou a modelagem matemática de um neurônio, sendo esse neurônio artificial essencialmente uma soma ponderada das entradas utilizadas em uma função de ativação para calcular uma saída, conforme Silva, Alves e Savio (2022).

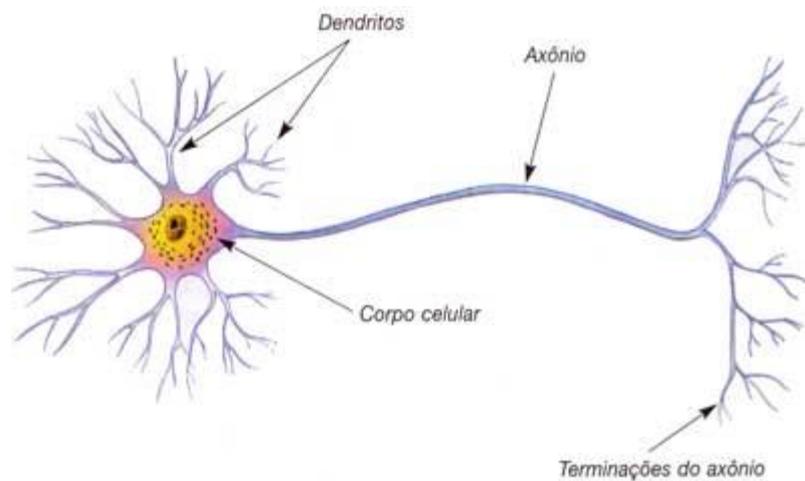
Assim, uma boa definição para as Redes Neurais Artificiais (RNA) pode ser encontrada em Amaral (2020) que as define como modelos matemáticos que buscam simular o comportamento do cérebro, sendo capazes de adquirir, manter e generalizar conhecimentos, possuindo como estrutura básica o neurônio artificial.

Fazendo uma analogia com o neurônio real, que pode ser visto na Figura 10, possui n entradas para os estímulos externos, ou seja, a camada de entrada do neurônio artificial pode ser comparada aos dendritos, sendo que esses estímulos (sinais) são ponderados através de

pesos para então serem linearmente combinados e então estão sujeitos a ação de uma função de ativação, que atua de forma análoga ao corpo celular, cuja característica principal é ser uma função diferenciável (AMARAL, 2020).

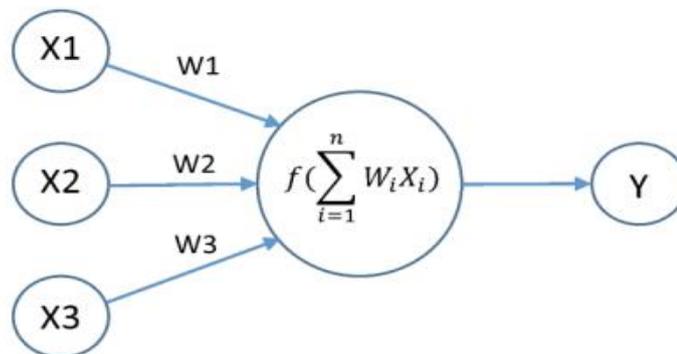
Assim, o sinal produzido irá para a camada de saída, que faz as vezes do axônio e suas terminações. A Figura 11 mostra um neurônio biológico enquanto a Figura 12 exemplifica a estrutura de um neurônio artificial, ficando bastante nítida a semelhança do conceito computacional com o neurônio biológico (AMARAL, 2020).

Figura 11 – Neurônio biológico.



Fonte: <https://metodosupera.com.br/neuronios-glossario-do-cerebro/>. Acesso em 29 jan. 2023.

Figura 12 – Estrutura de um neurônio artificial.



Fonte: Amaral (2020).

A função de ativação controla o nível de ativação do neurônio, gerando a resposta (saída) do mesmo, sendo então utilizadas funções de ativação não-lineares que possuem capacidade para aproximar funções. Dentre as funções de ativação mais comuns, destacam-se

a sigmoideal, tangente hiperbólica e a unidade linear retificada (ReLU), conforme equações 1, 2 e 3, respectivamente.

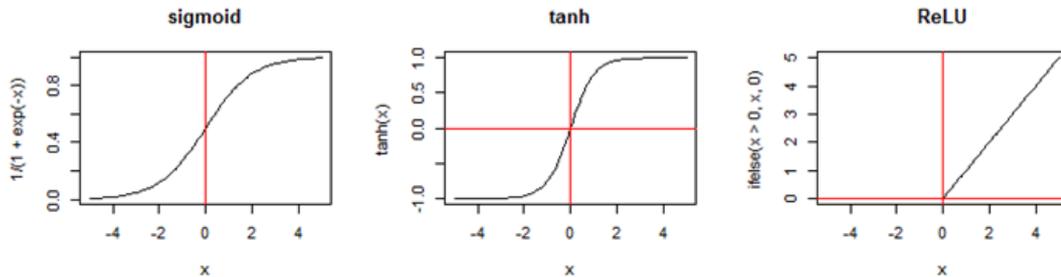
$$g(z) = \tanh(z) = \frac{(e^z - e^{-z})}{(e^z + e^{-z})} \quad (1)$$

$$g(z) = \sigma(z) = \frac{(1)}{(1 + e^{-z})} \quad (2)$$

$$g(z) = z, \text{ se } z \geq 0. \quad g(z) = 0, \text{ se } z < 0 \quad (3)$$

A Figura 13 mostra o comportamento das funções anteriormente elencadas.

Figura 13 – Funções de ativação mais usadas.



Fonte: <https://www.mql5.com/pt/articles/3473> Acesso em 10 fev. 2023

As redes neurais tipo *perceptron* de camada simples tem como limitação a sua capacidade de aprendizado, uma vez que consegue apenas lidar com um hiperplano. Da mesma maneira que em um ser humano não existe apenas um neurônio, sendo na realidade o cérebro uma associação destes em várias camadas, como pode ser observado na Figura 14.

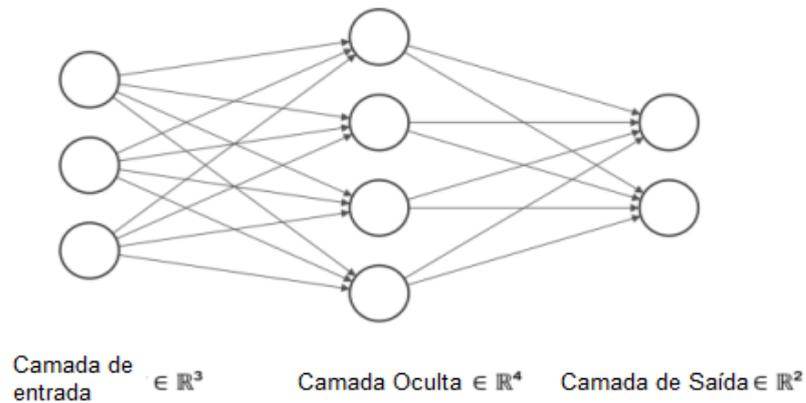
Logo, interconectam-se neurônios para formar as redes multicamadas, organizadas em camadas que são a de entrada (*input layer*), que transmite o dado externo para os elementos da próxima camada, as camadas ocultas (*hidden layer*), e a camada de saída (*output layer*) que externaliza o resultado processado pela rede, como pode ser visto na Figura 15 (AMARAL, 2020).

Figura 14 – Associação de neurônios no cérebro.



Fonte: <https://www.infoescola.com/neurologia/neuroanatomia/>. Acesso em 29 jan. 2023.

Figura 15 – Estrutura de uma rede *perceptron* multicamada.



Fonte: Amaral (2020) (Adaptado).

A quantidade de neurônios, camadas e a função de ativação dependem do problema a ser solucionado, no entanto usualmente são obtidas através de testes empíricos embora a literatura apresente métodos para se obter a melhor configuração da rede (AMARAL, 2020).

Contudo, tais métodos apresentam limitações e a rede neural também precisa aprender o comportamento da função, passando por um processo de treinamento antes da sua efetiva operação (AMARAL, 2020).

Cabe lembrar que nem sempre uma rede neural mais complexa implicará em melhor desempenho, uma vez que sua complexidade pode exceder a necessidade do projeto, além de acarretar um custo computacional desnecessário, implicando em maior tempo de execução.

Pode-se também desenvolver um algoritmo que permita o teste de diferentes configurações para a rede neural, permitindo testar e comparar os resultados utilizando diferentes funções de ativação, quantidade de camadas ocultas e a quantidade de neurônios nas camadas (GOOGLE, 2023).

Tais algoritmos, embora levem considerável tempo para serem executados, permitem a seleção de parâmetros para a rede neural de forma mais racional e menos demorada que testes do tipo “tentativa-e-erro” feitos de forma manual. Bibliotecas como o *keras* dispõem de algoritmos internos que permitem testar diferentes funções de ativação, taxas de aprendizagem, erro, dentre outros (GOOGLE, 2023).

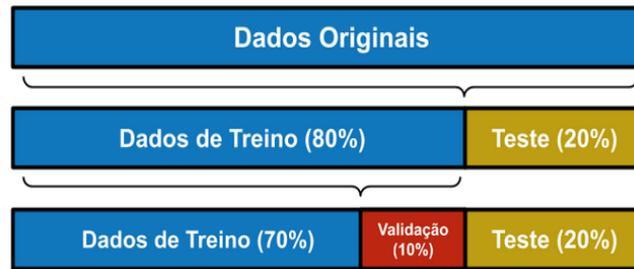
Para redes neurais multicamada há o método do gradiente descendente, que é utilizado para controlar a velocidade e a direção do aprendizado da rede. Nela, os dados de entrada e saída são apresentados a rede neural, sendo que a saída da rede é comparada ao valor real e se gera um erro, que é propagado da saída para a entrada, camada por camada (AMARAL, 2020).

Logo, são realizadas as atualizações dos pesos de acordo com sua contribuição com o erro na saída, sendo chamado de *backpropagation* ou retropropagação, sendo nestes casos considerados algoritmos de aprendizagem supervisionada, conforme Amaral (2020).

Outro ponto que deve ser levado em consideração em Redes Neurais é a necessidade de avaliar a qualidade de seus resultados, isto é, sua capacidade de generalização, uma vez que modelos superadequados (*overfitting*) para uma condição podem ser incapazes de produzir bons resultados em outras redes. Assim, para avaliar sua capacidade de generalização utilizam-se técnicas de validação (SCACCIA, 2020).

A Divisão Treino e Teste simples (*Hold-out*) consiste em dividir o conjunto original de dados em um conjunto de treino e outro de teste. Assim, ajusta-se o modelo ao conjunto de treino e usando o conjunto de teste verifica-se o desempenho do modelo em dados nunca vistos, sendo que usualmente se divide os dados em 80% para treino e 20% para teste (SCACCIA, 2020).

Quando é necessário comparar modelos diferentes, separa-se uma parte dos dados para calcular seus erros e assim modificar seus parâmetros de forma a reduzi-los, como visto na Figura 16 (SCACCIA, 2020).

Figura 16 – Metodologia *Hold-Out*

Fonte: Scaccia (2020) (Adaptado).

Há também a Validação Cruzada (*K-fold*), bastante utilizada para selecionar os melhores modelos em um conjunto de modelos ou ajustar os hiperparâmetros de um modelo já escolhido, uma vez que resolve o problema da variância do conjunto de validação e produz uma avaliação mais robusta do modelo (SCACCIA, 2020).

Durante a sua execução, é produzido um conjunto de medidas de performance que podem ser resumidas em uma só, sendo esse valor final uma medida mais robusta que apenas avaliar o modelo uma vez, resultando na diminuição do viés que pode haver em um conjunto de validação, resultando em um modelo mais capaz de generalizar para dados nunca vistos (SCACCIA, 2020).

Uma das abordagens mais populares é o *K-Fold* para realizar a validação das redes neurais, sendo que a sua implementação em Python costuma ser feita através de bibliotecas como a *sklearn* e a *Tensorflow*, tendo também a possibilidade de utilização dos núcleos das placas de vídeo através das bibliotecas CUDA e CUDNN (GOOGLE, 2023b).

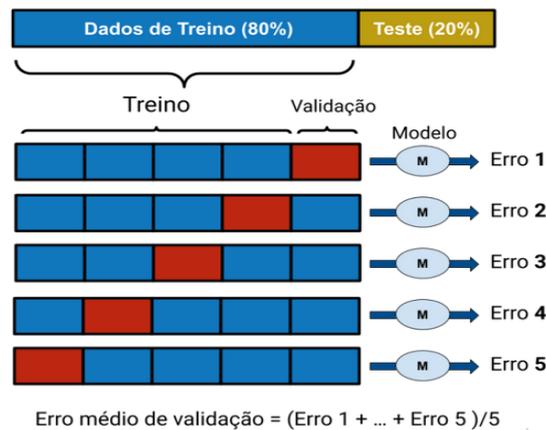
O algoritmo do *K-fold* é o seguinte, conforme Scaccia (2020):

- Dividir os dados em dois subconjuntos, um para treino e validação, outro para teste;
- Dividir o conjunto de treino e validação em k grupos de tamanhos iguais (k *folds*);
- Para cada grupo, repetir k vezes:
 - Escolher um dos k grupos para ser o conjunto de validação (Hold-out);
 - Usar os $k-1$ grupos restantes para treinar o modelo;

- Após o treino, avaliar o modelo no conjunto de validação e armazenar o desempenho obtido.
- Sumarizar o desempenho do modelo, tendo assim o erro médio ou o desvio padrão dos erros calculados;
- Se preciso, ajustar os hiperparâmetros e repetir os passos de 1 a 4 até obter um desempenho satisfatório;
- Avaliar o desempenho do modelo no conjunto de teste, sendo essa a medida real da capacidade de generalização do modelo.

A Figura 17 esquematiza a validação cruzada com $k = 5$.

Figura 17 – *K-Fold*.



Fonte: Scaccia (2020) (Adaptado).

O uso da capacidade das placas de vídeo acelera o treinamento quando utilizados em computadores domésticos, uma vez que as placas de vídeo chegam a ter centenas de núcleos de processamento atuando em paralelo, se comparados aos processadores.

Portanto, as redes neurais, dada a sua elevada capacidade de generalização e adaptação, encontram usos na classificação de padrões, *clustering*, aproximação de funções de otimização e previsão ou estimação de valores (AMARAL, 2020).

Assim, dadas tais qualidades, há o potencial de seu emprego em redes de distribuição de água, como pode ser observado nos trabalhos do tópico seguinte.

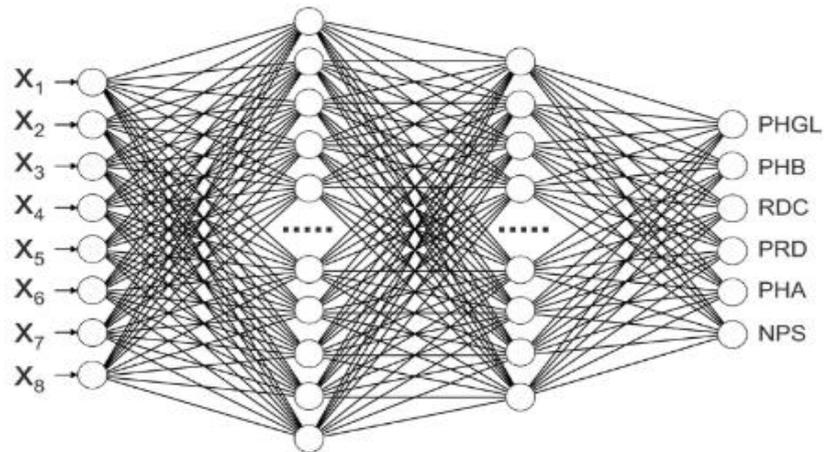
3.6 Redes Neurais Artificiais e seu uso em redes de distribuição de água

Um dos usos de Redes Neurais em distribuição de água é detalhado por Dawidowicz (2018) onde as RNA foram empregadas para avaliar pressões e zonas de pressões em redes de distribuição de água.

O tipo de rede usada foi a *Perceptron* multicamada, onde a camada de entrada consiste em 8 neurônios correspondentes ao vetor de entrada X , a primeira camada oculta consiste em 85 neurônios usando a função logística como função de ativação, a segunda camada oculta com 68 neurônios também com a função logística e a camada de saída com 6 neurônios com a função de ativação *Softmax*.

O esquema da rede neural utilizada pode ser visto na Figura 18.

Figura 18 – Rede Neural Artificial utilizada no trabalho.



Fonte: Dawidowicz (2018).

O vetor de entrada X consiste das seguintes variáveis

- X_1 : pressão nos nós da rede;
- X_2 : comprimento da menor distância entre o reservatório e o nó;
- X_3 : diferença de cota entre o reservatório e o nó;
- X_4 : maior diferença de cota entre a menor distância entre o reservatório e o nó;
- X_5 : soma das perdas de pressão entre a menor distância entre o reservatório e o nó;
- X_6 : maior pressão entre a menor distância entre o reservatório e o nó;

- X_7 : média ponderada da rugosidade absoluta k das tubulações entre o reservatório e o nó;
- X_8 : pressão nos nós.

Segundo Dawidowicz (2018), redes de água frequentemente são avaliadas computacionalmente muitas vezes apenas para cada variável, assim, não obtendo resultados na primeira tentativa. Contudo, dada a sua característica, as redes neurais aprimoram seu funcionamento ao longo do tempo, logo, o autor concluiu que o algoritmo se mostrou uma técnica complementar aos métodos tradicionais de cálculo.

Dawidowicz (2018) também apontou que as técnicas de modelagem neural combinadas com elementos de diagnósticos de processos na rede devem aprimorar o funcionamento de uma rede de distribuição de água, tanto nos custos operacionais como na melhoria das condições operacionais de serviço.

O trabalho de Carvalho, Filho e Porto (2021) traz uma constatação sobre o uso de técnicas de ML no Brasil: As mesmas vem recebendo atenção cada vez maior a medida que pesquisadores começam a compreender que tais algoritmos podem aprender sobre dados de demanda de água e capturar relações não lineares entre demanda e outras variáveis relevantes.

Assim, em seu trabalho, utilizaram as técnicas de Mapas Auto-organizáveis (SOM), Floresta Aleatória (RF) e Redes Neurais Artificiais para avaliar padrões de demanda e desenvolver um modelo de previsão para a cidade de Fortaleza. Foram então utilizadas informações em escala fina (CT – malhas censitárias) e grosseira (CB – blocos censitários).

As redes neurais utilizadas foram do tipo *perceptron* multicamada e ressalta-se aqui uma observação feita por Carvalho, Filho e Porto (2021) que tem relevância para esta tese: apontam que redes multicamadas *perceptron* com uma ou duas camadas ocultas são suficientes para solucionar qualquer problema não-linear.

Carvalho, Filho e Porto (2021) afirmam que mais camadas podem acarretar em maior tempo computacional e um set de dados maior para treinamento. Assim, utilizaram uma rede com apenas uma camada oculta. As redes neurais tiveram um desempenho ligeiramente melhor na escala fina, e no geral, as técnicas de ML empregadas conseguiram uma boa capacidade de explicação da demanda de água em Fortaleza.

O uso de Redes Neurais Artificiais como meio de detecção e gestão de perdas em redes de distribuição de água é reportado por Hu *et al.* (2021), no qual foram utilizadas as técnicas de

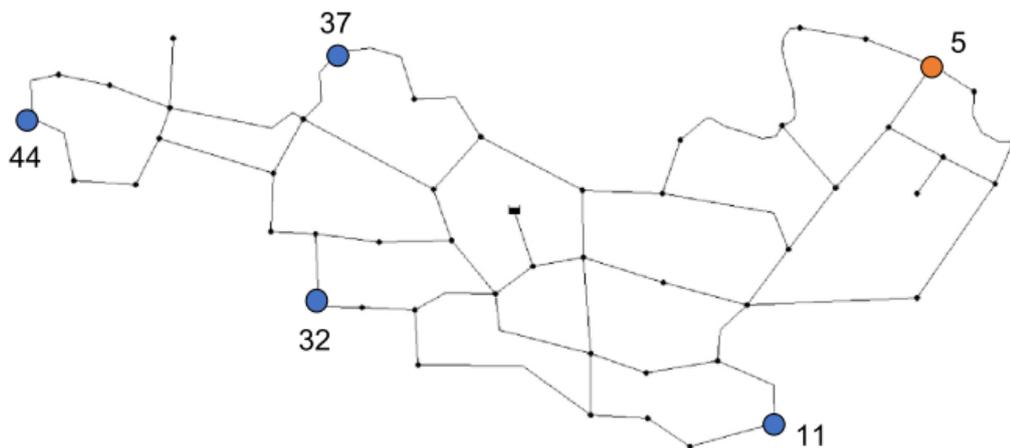
clustering baseados em densidade espacial associadas a Redes Neurais Convolucionais Multiescala para a detecção e controle de perdas.

Os resultados, se comparados a técnicas de vetor de suporte de máquina (SVM), classificador Bayes (NBC) e k-próximo vizinho (KNN) foram 78%, 72% e 28% superiores. Contudo, o artigo chama a atenção pela sua conclusão, onde os autores pretendem em estudos futuros adicionar algoritmos de otimização.

Hu *et al.* (2021) mencionam dentre eles os algoritmos genéticos, para otimizar as estruturas das redes neurais e assim comparar os resultados com os obtidos pelo trabalho, demonstrando a possibilidade de associação de algoritmos genéticos com redes neurais para obtenção de melhores resultados.

Outra abordagem com uso das redes neurais é a de Xing e Sela (2022), os quais utilizaram Redes Neurais para Grafos para estimar vazões e pressões em regiões não monitoradas de uma rede, utilizando a linguagem Python e o simulador hidráulico EPANET. Os testes foram realizados em uma rede teórica de 51 nós, 65 tubulações e um reservatório de nível fixo, onde pode-se observar na Figura 19 os pontos de monitoramento.

Figura 19 – Rede teórica para os testes.



Fonte: Adaptado de Xing e Sela (2022).

Os autores ressaltam a robustez das Redes Neurais para Grafos, enfatizando que em trabalhos futuros deve-se checar a escalabilidade do modelo, que trará vantagens por permitir um monitoramento mais econômico da rede, com menos pontos de monitoramento ou mesmo uma redundância, em caso de falhas.

O conceito de cidades inteligentes é caracterizado pela interação entre três componentes: tecnologia, pessoas e instituições, que são avaliadas e desenvolvidas por seis características distintas: economia, população, governança, mobilidade, meio-ambiente e qualidade de vida (CORAGGIO; HAN; TRYFONAS, 2023).

Assim, segundo os autores, ainda que a água seja uma parte essencial da infraestrutura urbana, muitas vezes é sonogada pois muitos projetos de cidades inteligentes não incluem a gestão inteligente da água, um erro gravíssimo, uma vez que a medida que as ações antrópicas progridem e a população cresce e ocorre a melhoria de qualidade de vida, a água torna-se um recurso cada vez mais escasso.

Portanto, nesse sentido, surge a hidroinformática, que é o elemento de ligação entre as cidades inteligentes e a gestão inteligente da água, se aproveitando da cada vez mais difundida Internet das Coisas, que permite que sensores possam enviar dados em tempo real para que os mesmos possam ser processados (CORAGGIO; HAN; TRYFONAS, 2023).

A hidroinformática vem cada vez mais se difundindo nos últimos anos e espera-se que com as novas tecnologias, venha a permitir uma gestão inteligente dos recursos hídricos sem esquecer das preocupações ambientais e sociais que o uso da água naturalmente possui (CORAGGIO; HAN; TRYFONAS, 2023).

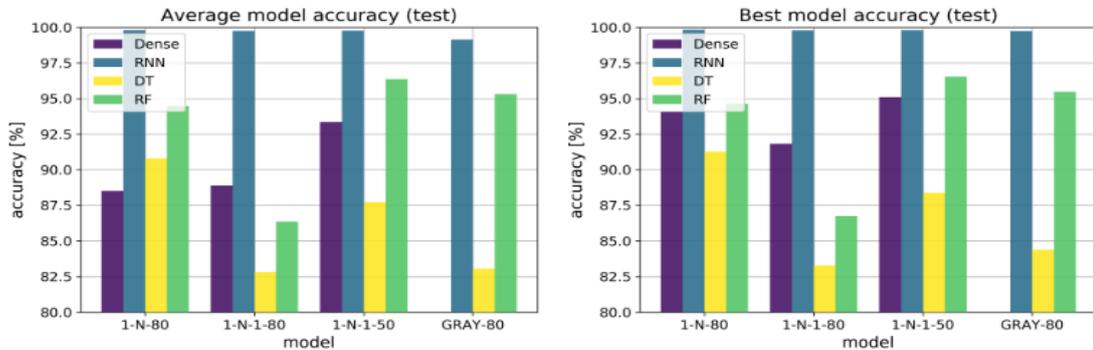
Assim, Predescu *et al.* (2020) utilizaram algoritmos de ML tradicionais e Redes Neurais para criar um sistema supervisorio para estações de bombeamento em uma rede de distribuição inteligente. Aqui, além de técnicas tradicionais de ML como árvores de decisão e floresta aleatória foram usados o modelo denso, de redes neurais artificiais com múltiplas camadas ocultas e as redes neurais recorrentes.

As redes neurais recorrentes são na realidade redes neurais artificiais organizadas em células que incorporam o conceito de memória para processar sequencias ou entradas de dados, se destacando as LSTM (*Long Short Term-Memory* – Memória de curto e longo prazo).

As LSTM utilizam componentes de dois estados para aprender o vetor de entrada de dados: um de curto prazo, representada pelas células ocultas e as de longo prazo, representadas pelo estado interno das células. A rede neural utilizada foi uma Rede Neural Recorrente com três camadas LSTM ocultas e a camada de saída. Os autores chegaram a desenvolver um modelo experimental físico para testar o conceito.

As Redes Neurais Recorrentes superaram os modelos Denso, Floresta Aleatória (RF) e Árvores de Decisão (DT), conforme Figura 20.

Figura 20 – Acurácia dos modelos



Fonte: Predescu et al. (2020).

Predescu *et al.* (2020) então constataram a superioridade das redes neurais recorrentes, reforçando que técnicas de aprendizado reforçado como as Redes Neurais, em especial as recorrentes, possuem resultados promissores para estruturas de controle altamente adaptáveis, essenciais em futuras cidades inteligentes, onde cada vez mais se faz necessário um controle cada vez mais preciso da distribuição de recursos como água e energia para satisfazer as necessidades populacionais.

Até então, foram encontradas apenas abordagens de operação utilizando sistemas supervisórios como Filho *et al.* (2018) ou plataformas de Internet das Coisas (IoT) como em Predescu *et al.* (2020), sendo que nesses casos não se considerou a possibilidade de otimização utilizando algoritmos genéticos ou qualquer outra técnica existente para tal.

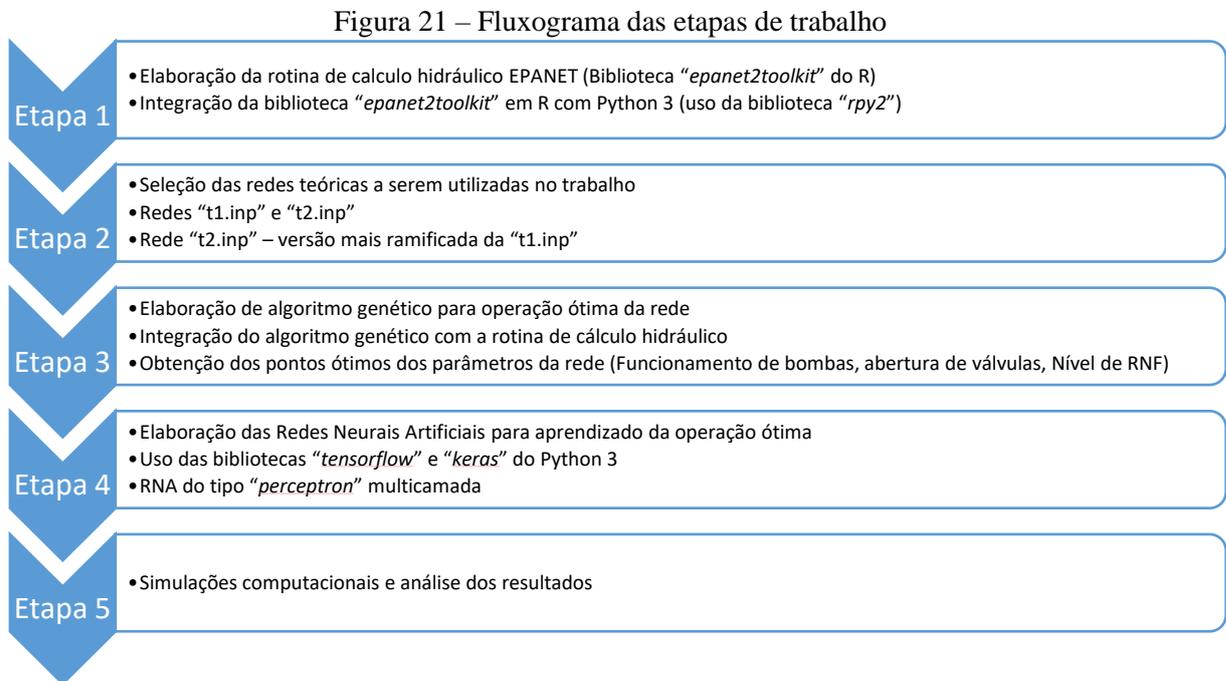
Em relação as redes neurais, muitos artigos trazem abordagens relativas a modelagens e previsão de demanda, como pode ser visto em Carvalho, Filho e Porto (2021) ou até mesmo a previsão de falhas, como em Snider e Mcbean (2020), contudo, não se encontrou na literatura trabalhos que associassem o cálculo hidráulico do EPANET, a otimização dos algoritmos genéticos e o aprendizado das redes neurais.

O diferencial da tese a ser elaborada pelo discente consiste no fato que até o presente momento não foram observados trabalhos acadêmicos que buscassem desenvolver um algoritmo de otimização utilizando algoritmos genéticos e operação de rede utilizando Redes Neurais Artificiais multicamada e a bibliotecas como a *EPANET2TOOLKIT* em linguagem R,

empregada em Python através da biblioteca *rpy2*, com vistas a operação ótima da rede de distribuição de água e realizar o aprendizado conforme a oscilação das demandas.

4. METODOLOGIA

O trabalho é dividido em etapas, conforme o fluxograma ilustrado na Figura 21.



Fonte: O autor (2022).

4.1 Etapa 1 – Elaboração da rotina de cálculo hidráulico

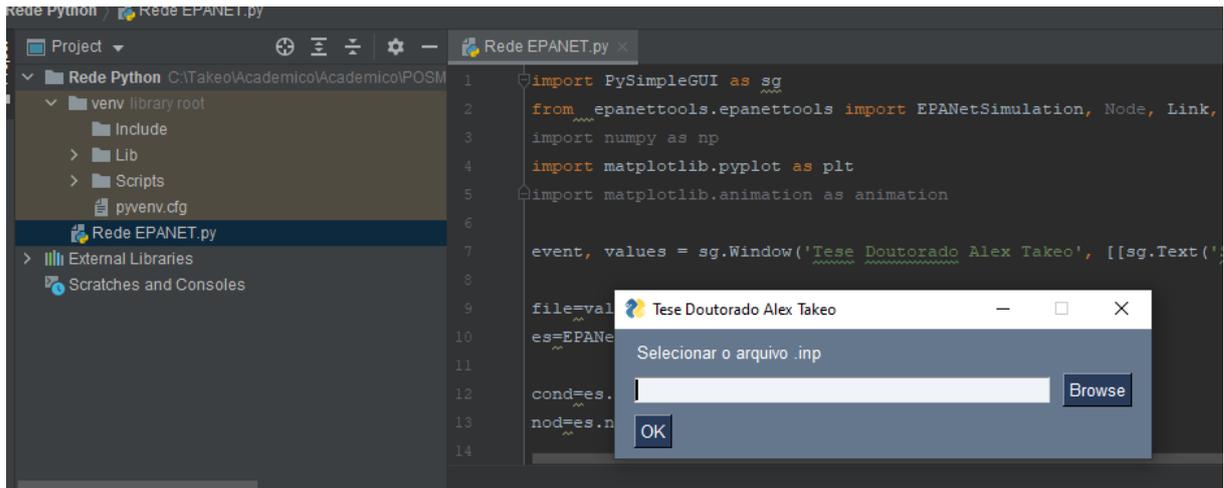
A etapa 1 consistiu na elaboração de uma rotina de cálculo hidráulico utilizando o pacote “*epanet2toolkit*” na linguagem R, uma vez que se trata do uso do EPANET via toolkit, uma ferramenta de cálculos para redes hidráulicas conhecida por sua confiabilidade nos resultados. Contudo, para permitir seu uso em linguagem Python, fez-se necessário o uso da biblioteca “*rpy2*”, que permite utilizar pacotes e comandos da linguagem R no Python.

Tal opção foi adotada pois o grupo de pesquisa no qual esta tese está inserida faz uso da linguagem R, além de as bibliotecas disponíveis para uso do EPANET em Python não terem se mostrado confiáveis em iterações, apresentando uma falha onde a cada 167 iterações o programa de cálculo hidráulico interrompia seu funcionamento, inviabilizando seu uso nas etapas 2 e 3, que exigiram, ao todo, 50000 iterações.

Contudo, o formato das saídas do pacote R serem em “*arrays*” individuais para cada valor de pressão, demanda, e outros parâmetros da rede consultados pelo algoritmo exigiu que

fossem realizadas conversões através da biblioteca “*numpy*”, com o comando “*np.asarray*”, convertendo, então, os “*arrays*” individuais em um “*array*” simples. Assim, há a entrada dos dados da rede a ser simulada em formato *.inp* através de interface de janelas via biblioteca “*PySimpleGUI*”, como pode ser observado na Figura 22.

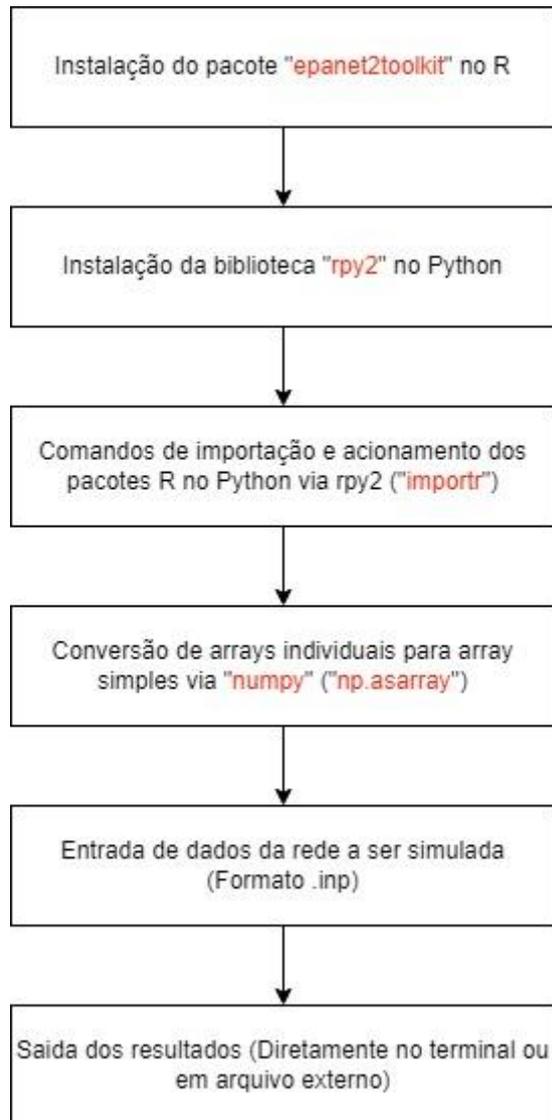
Figura 22 - Interface gráfica de entrada de dados.



Fonte: O autor.

O fluxograma da Figura 23 mostra o funcionamento da rotina de cálculo hidráulico através dos acionamentos dos pacotes e bibliotecas necessários ao seu funcionamento. A rotina de cálculo, então, será utilizada nas fases posteriores desta tese, podendo gerar resultados diretamente no terminal ou em arquivos externos em formato *.txt* ou *.xls*, conforme necessário.

Figura 23 - Fluxograma da rotina de cálculo hidráulico



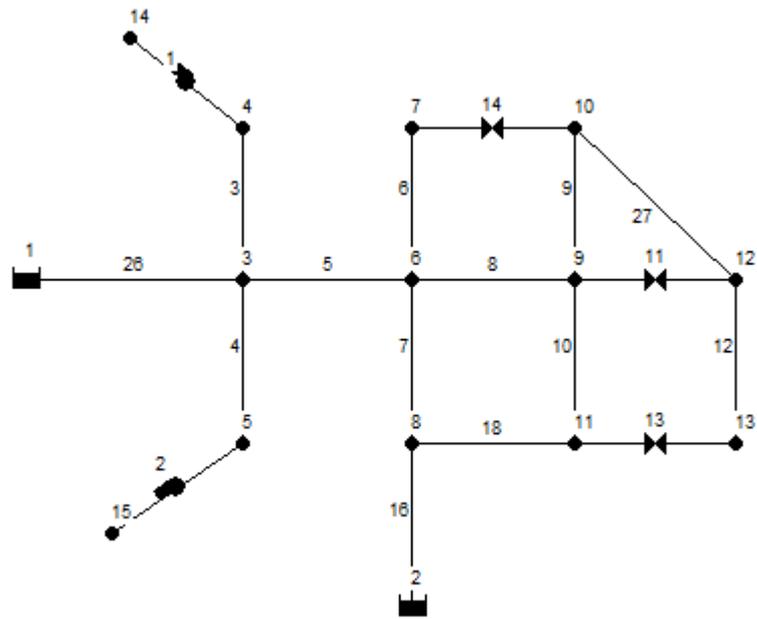
Fonte: O autor.

4.2 Etapa 2 – Elaboração das Redes de Distribuição de Água teóricas para o estudo

As redes de distribuição de água utilizadas neste trabalho foram elaboradas possuindo 13 nós, 2 RNFs, 2 bombas e 3 válvulas, de modo que as cotas dos nós e dos reservatórios representassem uma região de topografia irregular, condição desfavorável para sua operação. Foram então criadas duas redes, T1 e T2, descritas a seguir.

A rede T1 possui o seguinte arranjo como pode se observar na Figura 24.

Figura 24 - Rede T1 com os identificadores dos nós.



Fonte: O autor.

A Tabela 1 mostra os valores de cota dos nós e dos RNF.

Tabela 1 - Dados de cotas e demandas da rede T1.

ID do nó	Cota (m)	Demanda (l/s)
3	845	1
4	840	1
5	835	2
6	830	1
7	825	2
8	830	3
9	810	2
10	805	1
11	815	1
12	800	1
13	805	1
14	915	2

15	920	3
RNF 1	890	N/A
RNF 2	890	N/A

Fonte: O autor.

Na Tabela 2 encontram-se os valores referentes as tubulações da rede.

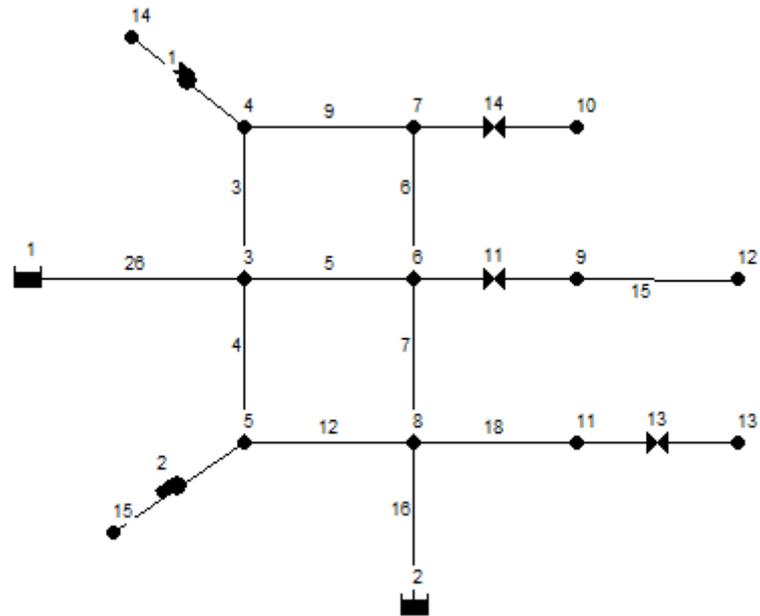
Tabela 2 - Dados das tubulações e válvulas da rede.

ID do link	Comprimento (m)	Diâmetro (mm)	Rugosidade (mm)
3	100	100	0,06
4	100	100	0,06
5	150	100	0,06
6	100	100	0,06
7	100	100	0,06
8	100	75	0,06
9	100	75	0,06
10	100	75	0,06
12	150	50	0,06
26	500	200	0,06
27	100	50	0,06
16	300	200	0,06
18	100	100	0,06
Bomba 1	N/A	N/A	N/A
Bomba 2	N/A	N/A	N/A
Válvula 1 (11)	N/A	50	N/A
Válvula 2 (13)	N/A	50	N/A
Válvula 3 (14)	N/A	75	N/A

Fonte: O autor.

A rede T2 trata-se de um novo arranjo das tubulações da rede T1, fazendo com que se tornasse mais ramificada ao deslocar a malha dos nós 9, 10, 11, 12 e 13 para os nós 3, 4, 5, 6, 7 e 8, além do reposicionamento da válvula 1 (11 no desenho da rede), que, como pode ser observado na Figura 25.

Figura 25 - Arranjo da rede T2.



Fonte: O autor.

Os valores dos nós estão apresentados na Tabela 3.

Tabela 3 - Dados de cotas e demandas da rede T2.

ID do nó	Cota (m)	Demanda (l/s)
3	845	1
4	840	1
5	835	2
6	830	1
7	825	2
8	830	3
9	810	2
10	805	1
11	815	1
12	800	1
13	805	1
14	915	2
15	920	3

RNF 1	890	N/A
RNF 2	890	N/A

Fonte: O autor.

De forma análoga, os valores das tubulações relativos ao comprimento, diâmetro e rugosidade estão contidos na Tabela 4.

Tabela 4 - Dados das tubulações e válvulas da rede T2.

ID do link	Comprimento (m)	Diâmetro (mm)	Rugosidade (mm)
3	100	100	0,06
4	100	100	0,06
5	150	100	0,06
6	100	100	0,06
7	100	100	0,06
26	500	200	0,06
16	300	200	0,06
18	100	100	0,06
9	150	75	0,06
12	150	75	0,06
15	100	75	0,06
Bomba 1	N/A	N/A	N/A
Bomba 2	N/A	N/A	N/A
Válvula 1 (11)	N/A	50	N/A
Válvula 2 (13)	N/A	75	N/A
Válvula 3 (14)	N/A	75	N/A

Fonte: O autor.

Para ambas as redes, utilizaram-se as mesmas configurações de bomba, inclusive sua curva característica, dada pela equação 4.

$$P = 41,00 - 0,004017 \times Q^{2,19} \quad (4)$$

A operação das bombas pelos algoritmos a seguir visa apenas controlar a sua rotação, e não seu ponto de maior eficiência, simulando bombas de rotação variável alterando sua rotação conforme a necessidade da rede, não havendo a preocupação de se alterar curvas ou potencia do motor.

4.3 Etapa 3 – Escolha de fatores de otimização e Algoritmos Genéticos

Para a operação ótima das redes de distribuição de água a serem tratadas nesta tese, foram então elencados os seguintes parâmetros: Reservatório de Nível Fixo (RNF), pressão de saída nas Válvulas de Redução de Pressão (VRP) e porcentagem de rotação das bombas.

A variação de RNF, no caso, deve ser entendida como se fosse uma variação provocada pelo bombeamento na saída dos reservatórios, sendo feita em metros de coluna d'água (m.c.a.).

Quanto as VRP, considera-se a variação da pressão a sua jusante causada pela sua abertura ou fechamento, também em metros de coluna d'água (m.c.a.). Para as bombas, considera-se o proporcional de sua rotação, sendo o valor 0 para a bomba parada e 1 para 100% da sua rotação nominal.

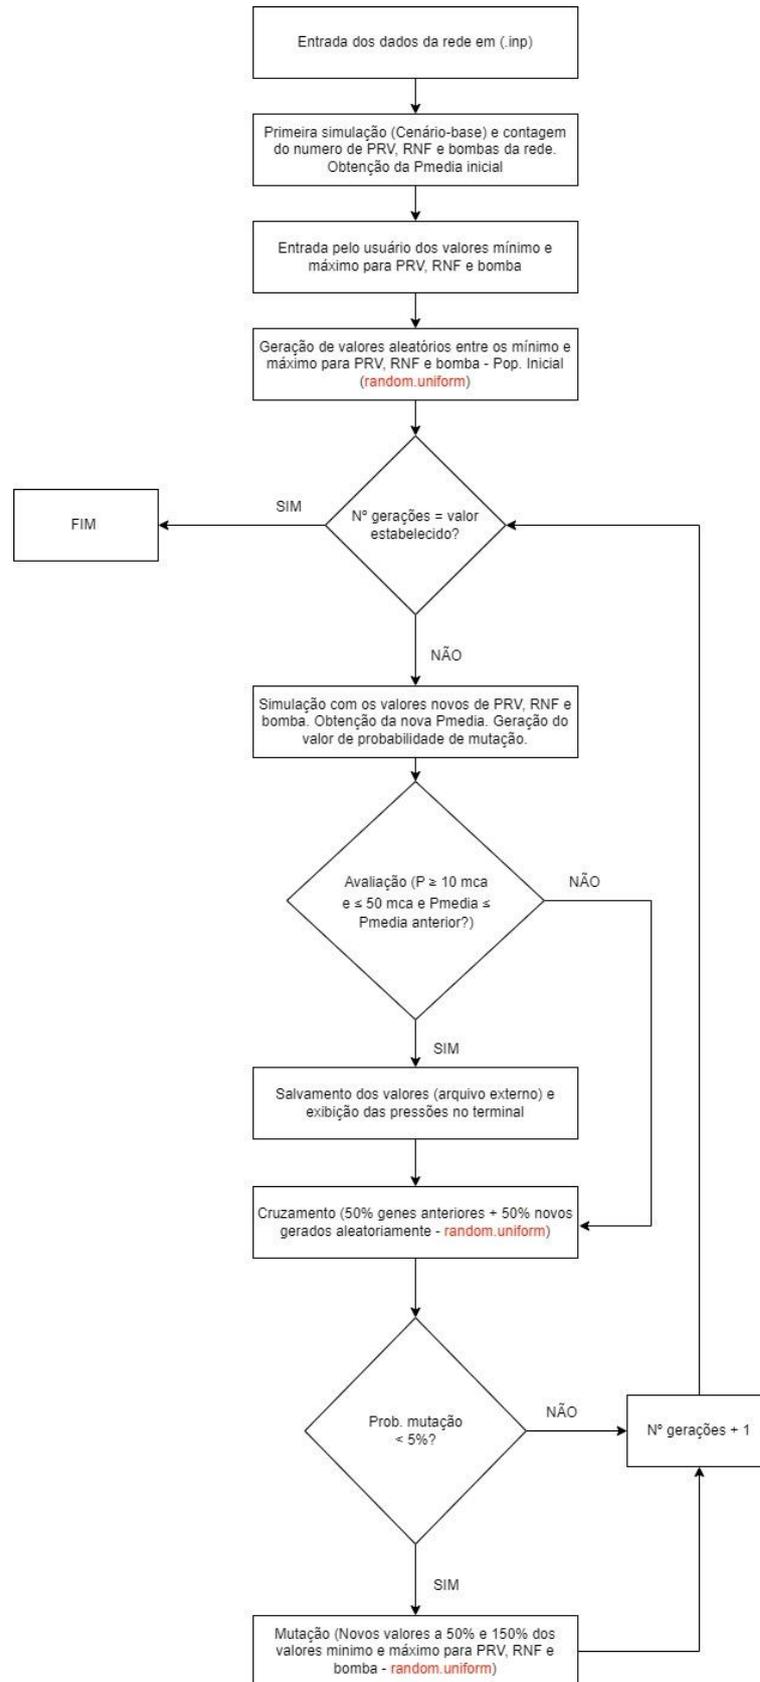
Assim, para se obter os pontos ótimos dos parâmetros anteriormente mencionados, desenvolveu-se uma rotina computacional de otimização utilizando algoritmos genéticos. O algoritmo genético foi desenvolvido objetivando atingir pontos ótimos dos parâmetros, mantendo as pressões entre 10 e 50 m.c.a. e buscando minimizar a pressão média da rede, quando possível.

Sua função objetivo consiste em minimizar a pressão média da rede, estando sujeita aos limites impostos pela norma NBR 12218, sendo que para esta tese foi considerado o limite superior de 50 m.c.a. A equação 5 mostra a função objetivo, junto de suas restrições, sendo P_i a pressão em cada nó e n o número de nós da rede.

$$\text{Min. F. O.} = \frac{\sum_{i=0}^n P_i}{n}, \text{ sujeito a } P_i \geq 10 \text{ m.c.a. e } P_i \leq 50 \text{ m.c.a.} \quad (5)$$

O algoritmo genético é descrito pelo fluxograma da Figura 26. As simulações são feitas pela rotina de cálculo hidráulico descrita na Figura 22 e a quantidade de gerações pode ser ajustada conforme a necessidade.

Figura 26 - Fluxograma do Algoritmo Genético



Fonte: O autor.

De modo a se evitar uma maior complexidade na rotina computacional que pudesse impactar na sua velocidade de execução, optou-se por um algoritmo genético de simples objetivo no qual as condições de contorno referente as pressões mínima e máxima da rede, bem como a redução da pressão média estão contidas nas restrições de sua função objetivo.

Este não seria um problema para a Rede Neural de operação, uma vez que ela obtém resultado apenas para um horário, contudo, seria uma grave questão quando utilizado para a geração dos parâmetros da Rede Neural de Previsão, uma vez que precisaria fazê-lo 72 vezes (uma por hora), sendo que para cada hora o computador utilizado levava cerca de 15 minutos para obter os resultados, totalizando aproximadamente 18 horas para gerar um conjunto de dados completo.

Uma peculiaridade na execução deste Algoritmo Genético de Otimização é que para a Rede Neural de Previsão, foi utilizada o conceito de semente aleatória. Foram empregados quatro computadores, de mesmo modelo, marca e configurações, do Laboratório de Hidráulica Computacional da UNIFEI para executarem, simultaneamente, o algoritmo.

Como para gerar os valores aleatórios se utilizou o comando *random.uniform* da biblioteca *random* do Python, em cada computador será então iniciado um valor diferente para cada execução do algoritmo, possibilitando que cada máquina encontrasse respostas diferentes, o que permitiu um ganho de tempo, pois em apenas 18 horas de funcionamento foram obtidos 4 conjuntos de dados e assim, a seleção dos melhores parâmetros.

Para comparação, se fosse executado 4 vezes seguidas, um computador apenas levaria cerca de 72 horas (3 dias), algo impraticável não apenas pela demora na obtenção dos resultados, mas também pelos transtornos que potencialmente seriam gerados uma vez que o laboratório é utilizado para aulas e demais pesquisas, bem como os riscos inerentes a um longo período de funcionamento do computador, como interrupções de energia, travamentos, aquecimento, dentre outros que poderiam comprometer a obtenção dos resultados.

4.4 Etapa 4 – Elaboração das Redes Neurais Artificiais

Para este trabalho foram desenvolvidas duas redes neurais, descritas a seguir:

a) Redes Neurais Artificiais de Operação:

Esta rede neural tem por característica principal trabalhar com as demandas de apenas um horário específico, ou seja, ela não visa receber um conjunto de dados como é usual, mas sim aprender a operar apenas em um ponto específico.

Optou-se por tal abordagem devido a sua implementação mais simples e mais rápida obtenção de resultados, tanto pelo Algoritmo Genético de Otimização (AGO) que precisa produzir resultados para apenas um horário, como também por não utilizar bibliotecas específicas, além de permitir ajustes mais facilmente, permitindo, portanto, que se validasse a possibilidade de uso das redes neurais como elemento de controle em redes de distribuição de água.

Ela recebe diretamente os parâmetros ótimos de operação obtidos no algoritmo genético, que é incorporado a este algoritmo e recebe em sua camada de entrada as demandas, produzindo em sua saída os parâmetros de RNF, VRP e bomba na camada de saída. É do tipo *perceptron* multicamada, com uma camada oculta, sendo a função de ativação em todos os neurônios a função linear.

Para se evitar discrepâncias geradas pelas ordens de grandeza diferentes entre as variáveis, realizou-se a normalização das variáveis através da equação 6, através da técnica MinMax, na qual a normalização se baseia na amplitude dos valores.

$$Valor\ Normalizado = \frac{Valor - Valor_{minimo}}{Valor_{maximo} - Valor_{minimo}} \quad (6)$$

A quantidade de neurônios na camada de entrada é igual a de nós, uma vez que é a quantidade de demandas a serem processadas, enquanto a camada de saída é igual a soma das RNFs, VRPs e bombas disponíveis na rede de distribuição, sendo que a camada oculta possui a mesma quantidade de neurônios da camada de entrada.

Caso a rede não possua VRPs ou bombas, não há problema em seu funcionamento, uma vez que o algoritmo dispõe de mecanismos para verificar suas existências ou não, bem como as quantidades, além de identificar também a quantidade de nós, sendo requisito fundamental para

o funcionamento a existência de pelo menos um RNF, um nó e uma tubulação que faça sua ligação.

Por utilizar a função linear como função de ativação, não é possível utilizar o gradiente de descida, razão pela qual adotou-se a diferença entre os parâmetros ótimos e os calculados pela rede neural, para realizar o cálculo dos pesos novos na camada de saída, conforme equação 7.

$$\text{Pesos novos Camada de Saída} = \text{Parâmetro ótimo} - \text{Parâmetro obtido pela RNAOp} \quad (7)$$

O cálculo dos pesos novos da camada oculta é feito com a diferença entre as pressões ótimas e as pressões calculadas pela rotina de cálculos hidráulicos incorporada a mesma como o erro, como pode ser visto na equação 8.

$$\text{Pesos novos Camada Oculta} = \text{Pressões ótimas} - \text{Pressões obtidas pela RNAOp} \quad (8)$$

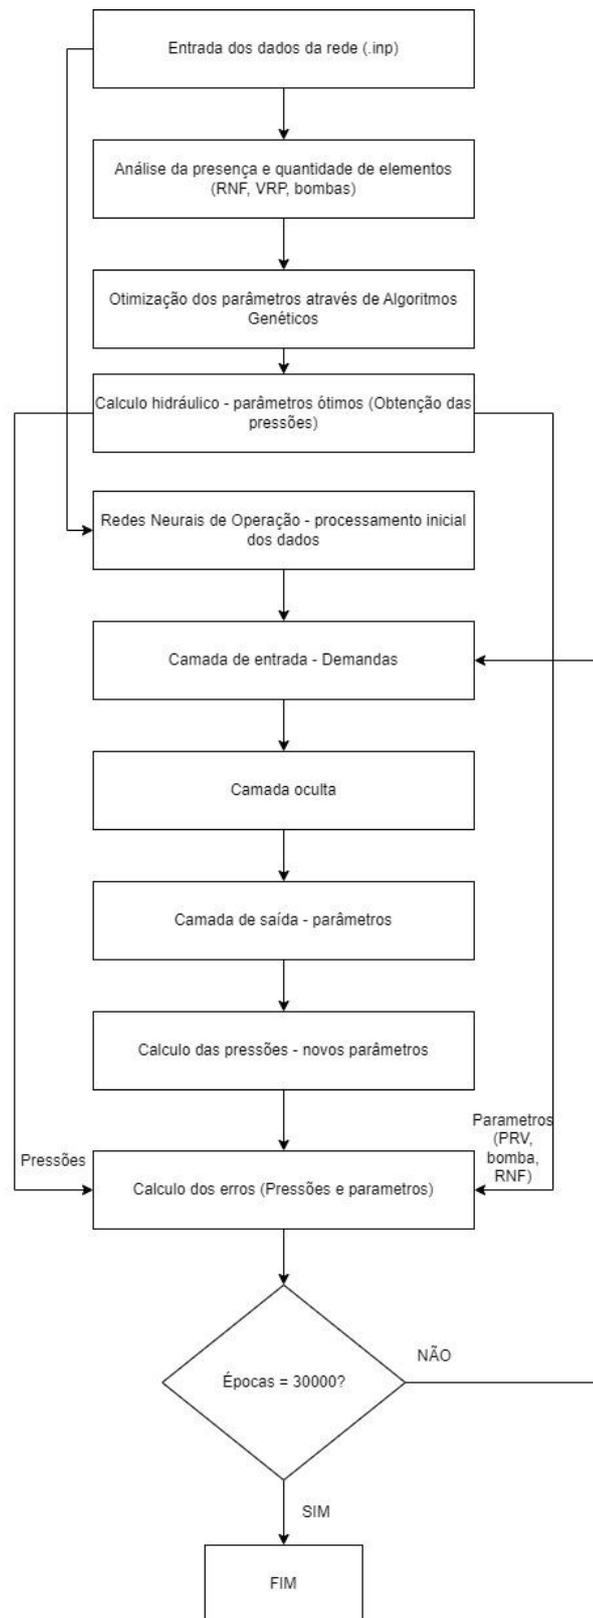
Logo, quanto maior o erro, maior será o ajuste feito pela rede neural e vice-versa. Para evitar um efeito análogo ao da explosão de gradiente, isto é, quando os ajustes da rede neural passam a ser descontroladamente altos a ponto de inviabilizar os resultados, adotou-se uma taxa de aprendizagem de 0,001 (0,1%), sendo fixada a quantidade de épocas em 30000.

Aqui, cabe lembrar: as épocas em uma rede neural são análogas as gerações em um algoritmo genético, ou seja, suas iterações. A equação 9 descreve o funcionamento das Redes Neurais de Operação, mais precisamente a obtenção dos valores de saída dos parâmetros.

$$\text{Parâmetro}_j = \sum_1^{j=\text{elementos de saída}} (\sum_1^{i=\text{nós}} \text{demanda}_i \times \text{peso novo Camada Oculta}_{i \times j}) \times \text{peso novo Camada de Saída}_{i \times j} \quad (9)$$

O fluxograma da Figura 27 mostra a sequência de seu funcionamento.

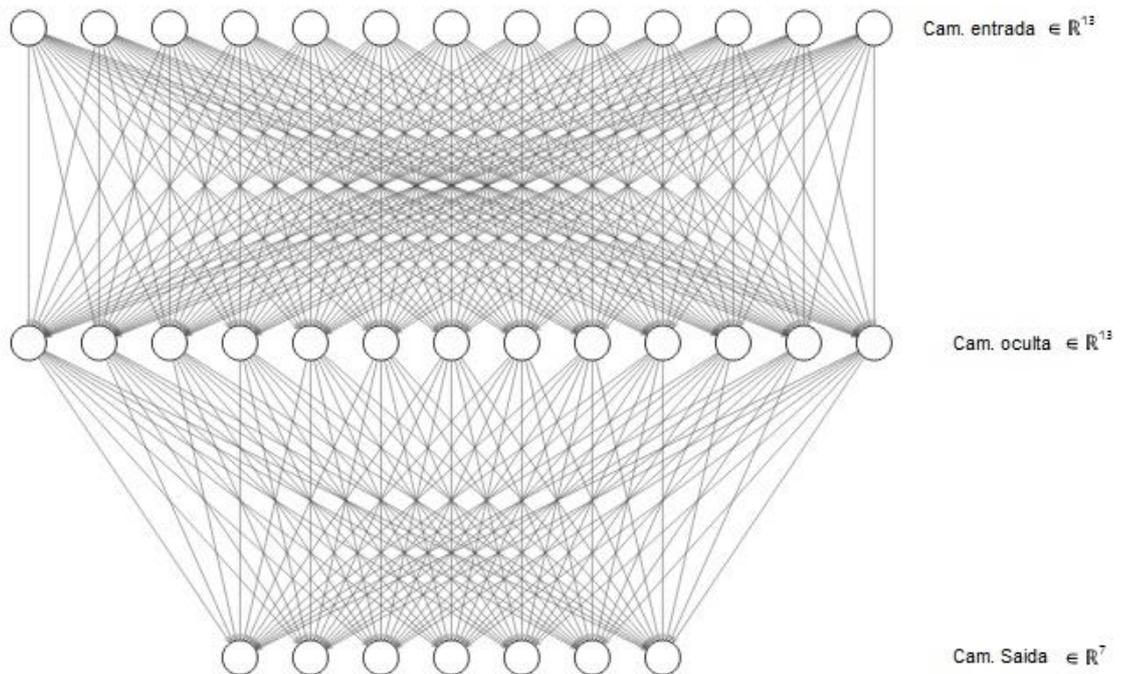
Figura 27 - Redes Neurais de Operação



Fonte: O autor.

A Figura 28 mostra um diagrama de neurônios das Redes Neurais de operação para uma rede com 13 nós, 2 RNFs, 2 bombas e 3 VRPs, no caso tanto para a rede de distribuição teórica T1 como para a T2, ambas com 13 nós, 2 bombas, 2 RNFs e 3 VRPs, totalizando 13 neurônios na camada de entrada, 13 na camada oculta e 7 na camada de saída.

Figura 28 – Arquitetura das Redes Neurais de Operação.



Fonte: O autor.

Uma das grandes vantagens deste algoritmo de Redes Neurais é que o mesmo é praticamente capaz de rodar quaisquer rede em formato *.inp* do EPANET, desde que possua no mínimo um RNF, uma tubulação e um nó, uma vez que possui mecanismos para a identificação dos seus elementos, bem como suas quantidades nas redes, tornando o algoritmo versátil para estudos em redes de diferentes configurações.

Uma eventual modificação seria simples e rápida para otimizar e operar outros parâmetros como Reservatórios de Nível Variável, Válvulas de Pressão Contínua, dentre outros, sendo até mesmo capaz de operar parâmetros não relacionados diretamente a operação como rugosidade, diâmetro e demandas.

Tais modificações, a despeito de não serem diretamente relacionadas a esta tese, podem permitir estudos posteriores incluindo outros parâmetros, calibrações ou sobre configurações ótimas para a criação ou expansão de redes de distribuição de água, possuindo um potencial

para compor, por si só, um futuro algoritmo de otimização de redes, sem a assistência dos Algoritmos Genéticos.

b) Redes Neurais Artificiais de Previsão de parâmetros operacionais:

Esta rede neural tem como característica a capacidade de receber um conjunto de dados (“*dataframe*”) com no mínimo 72 horas de dados de demandas da rede e dados de parâmetros operacionais (RNF, VRP e bombas) e com isso fazer previsão para as próximas 24 horas baseado nos dados das últimas 24 horas de demanda.

Os parâmetros ótimos são gerados pelo algoritmo genético de otimização, este com 50000 gerações, que produz um *dataframe* com as demandas utilizadas e os parâmetros obtidos em formato *.xls*. Após, a rotina de redes neurais é executada, que foi elaborada utilizando as bibliotecas “*tensorflow*” e “*keras*”.

A grande vantagem de tais bibliotecas reside no fato que, para além de sua otimização em termos de desempenho e a possibilidade de inúmeros arranjos com funções de ativação, camadas ocultas, dentre outras, a possibilidade de utilizar a aceleração de placa gráfica, quando disponível no computador, permitindo uma maior velocidade de execução, em especial quando do uso de conjunto de dados extensos.

De forma similar a Rede Neural de Previsão, foi necessária a normalização das variáveis. Contudo, aqui foi empregada a técnica de normalização via média e desvio-padrão, como pode ser visto na equação 10.

$$X_{normalizado} = \frac{X - \bar{X}}{\sigma_X} \quad (10)$$

Para esta rede neural, foi estabelecido 30000 épocas e utilizado o *dataframe* gerado anteriormente com 72 horas de demandas para uma rede de 13 nós, 2 RNFs, 2 bombas e 3 VRPs.

A rede neural foi treinada de hora em hora (*batch* = 1), sendo estabelecidas 24 horas (1 dia) para treinamento, 24 horas para teste e 24 horas para validação cruzada dos resultados (*k-fold*) com $k = 3$, portanto sendo 1/3 para cada etapa. Trata-se de um arranjo pouco usual, uma vez que segundo Scaccia (2020), costuma-se usar 80% e 20% para teste.

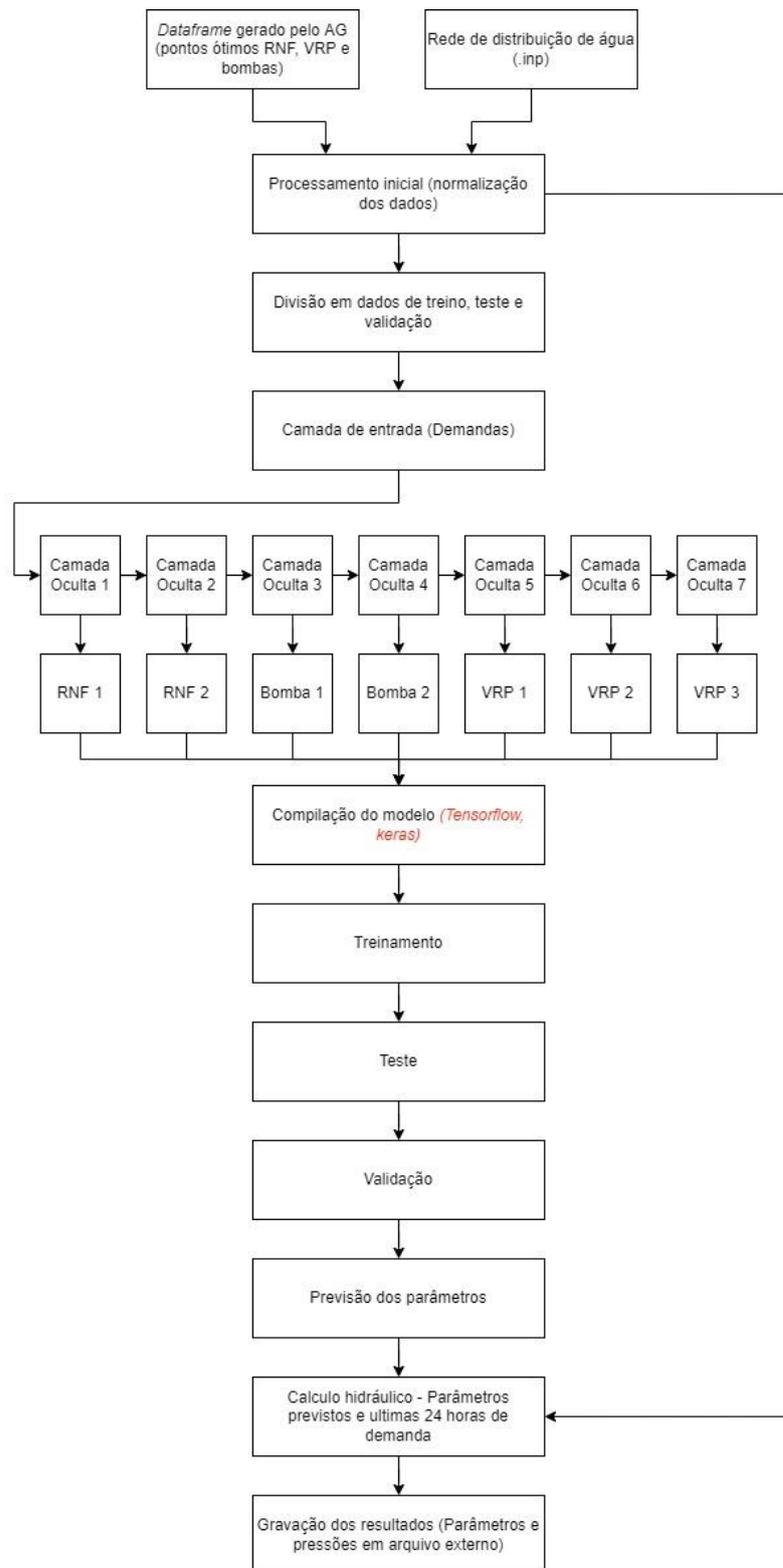
Não existem recomendações explícitas na literatura acerca das porcentagens a serem utilizadas, uma vez que costumam ser decididas empiricamente, contudo, a divisão de 1/3 dos dados para cada etapa foi a que se mostrou com melhor desempenho nos testes realizados.

Adicionalmente, tal arranjo faz sentido nas condições impostas pelo trabalho, uma vez que a rede aprenderia em um dia, validaria seus dados no dia seguinte e realizaria o teste no dia final, uma vez que devido a variação de consumo durante o dia, treinar a rede com apenas algumas horas de um dia completo poderia produzir distorções graves na sua operação.

A taxa de aprendizagem estabelecida foi de 0,01 (1%) e a RNA possui 7 camadas ocultas interligadas entre si (função “*dense*” do “*keras*”), sendo que cada camada oculta possui 128 nós e, sequencialmente, cada camada oculta possui como camada de saída um parâmetro.

A função de ativação utilizada é a unidade linear retificada (*ReLU*) e ao fim da execução da rede neural, a rotina de cálculo hidráulico é acionada para utilizar os parâmetros previstos com as demandas das últimas 24 horas e os resultados são salvos em arquivo externo. O fluxograma da Figura 29 explica o funcionamento do algoritmo.

Figura 29 - RNA de previsão.

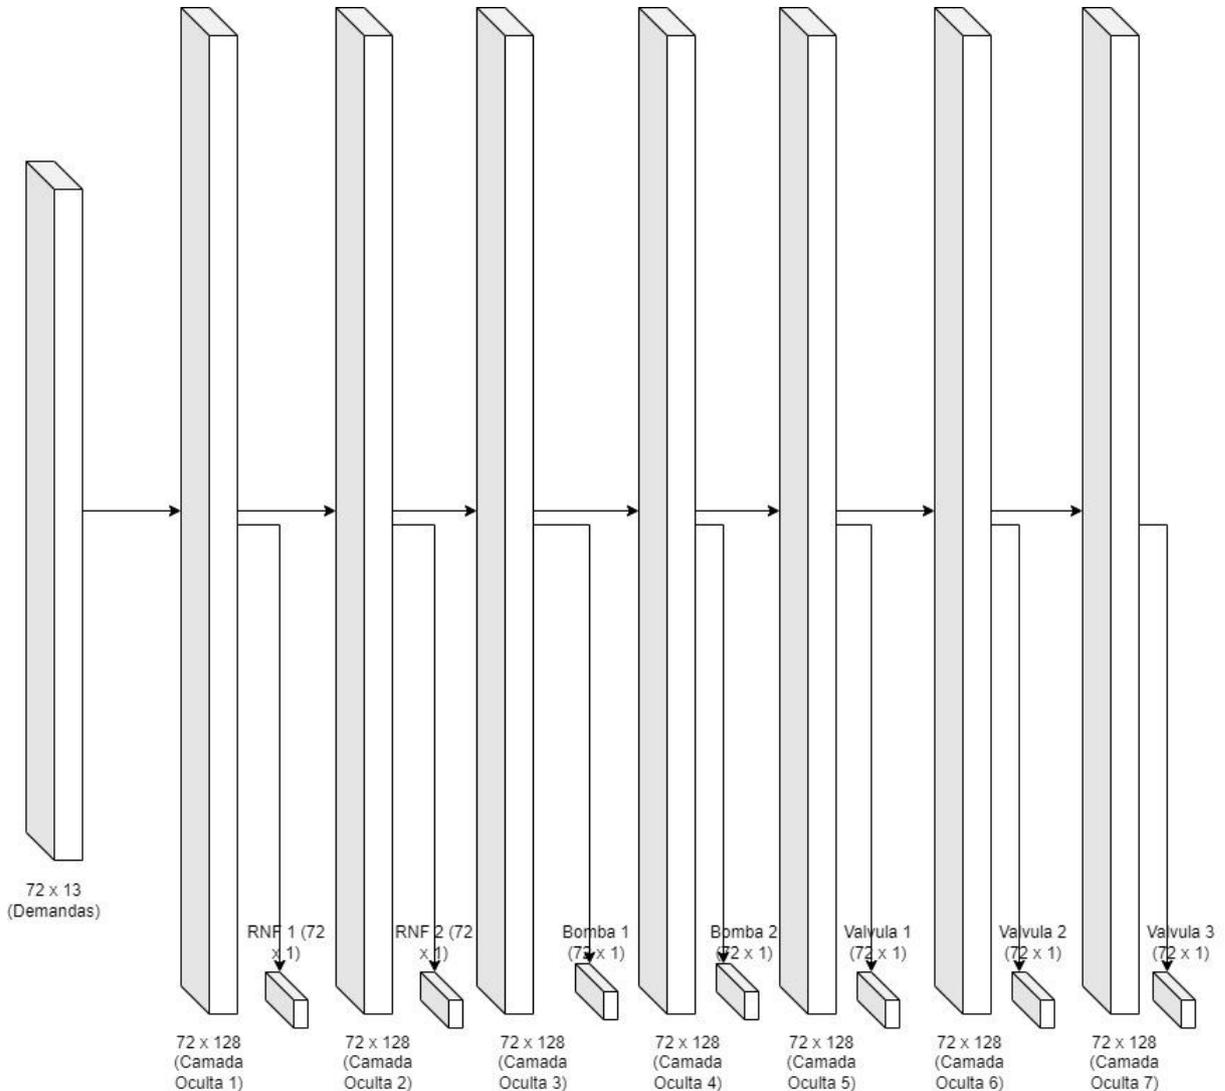


Fonte: O autor.

Pela grande quantidade de nós nas camadas ocultas, que tornaria impraticável a sua exibição através de diagrama de neurônios como no caso das Redes Neurais de Operação, o

diagrama referente as Redes Neurais de Previsão é mostrado em diagrama de blocos, conforme a Figura 30.

Figura 30 - Diagrama de blocos da RNA de Previsão.



Fonte: O autor.

4.5 Cálculo das perdas nas redes de distribuição de água

O cálculo das perdas realizado nesta tese é baseado em Tucciarelli, Criminisi e Termini (1999), que consideram que as perdas em uma rede de distribuição de água são proporcionais aos pequenos vazamentos ao redor de cada nó, elevados a uma potência a da pressão no referido nó.

O expoente a possui um valor mínimo de 0,5, correspondendo ao valor constante da área dos pequenos vazamentos ao redor dos nós, sendo que os valores podem ser ajustados para se adequar as características das redes.

Para esta tese, foi adotada uma abordagem similar a de Silva et al. (2020), onde se utiliza o mesmo conceito de Tucciarelli, Criminisi e Termini (1999) aplicado a pressão média da rede, resultando na equação 11.

$$\sum_{i=1}^{nós} Perdas = P_{media}^{0,5} \times 7,27 \quad (11)$$

Diferente de Silva et al. (2020), o cálculo das perdas não é feito direto no algoritmo, mas sim no *dataset* gerado em planilha *excel*. Tal solução foi adotada para se evitar custo computacional na geração dos *datasets* nos algoritmos genéticos e nas redes neurais utilizadas no trabalho.

5. RESULTADOS E DISCUSSÃO

5.1 Resultados dos cenários-base

O cenário-base para a T1 em relação as pressões, está apresentado na Tabela 5.

Tabela 5 – Cenário-base para a rede T1.

ID do nó	Pressão (m.c.a.)
3	44,69
4	49,51
5	54,23
6	59,58
7	64,49
8	59,83
9	79,06
10	83,32
11	74,59
12	85,70
13	79,61
14	15,49
15	28,22

Fonte: O autor.

Já o cenário-base para a T2 em relação as pressões, está apresentado na Tabela 6.

Tabela 6 – Cenário-base para a rede T2.

ID do nó	Pressão (m.c.a.)
3	44,71
4	49,46
5	54,48
6	59,52
7	64,40
8	59,82
9	50,00
10	20,00
11	74,73
12	59,90
13	20,00
14	15,44
15	28,47

Fonte: O autor.

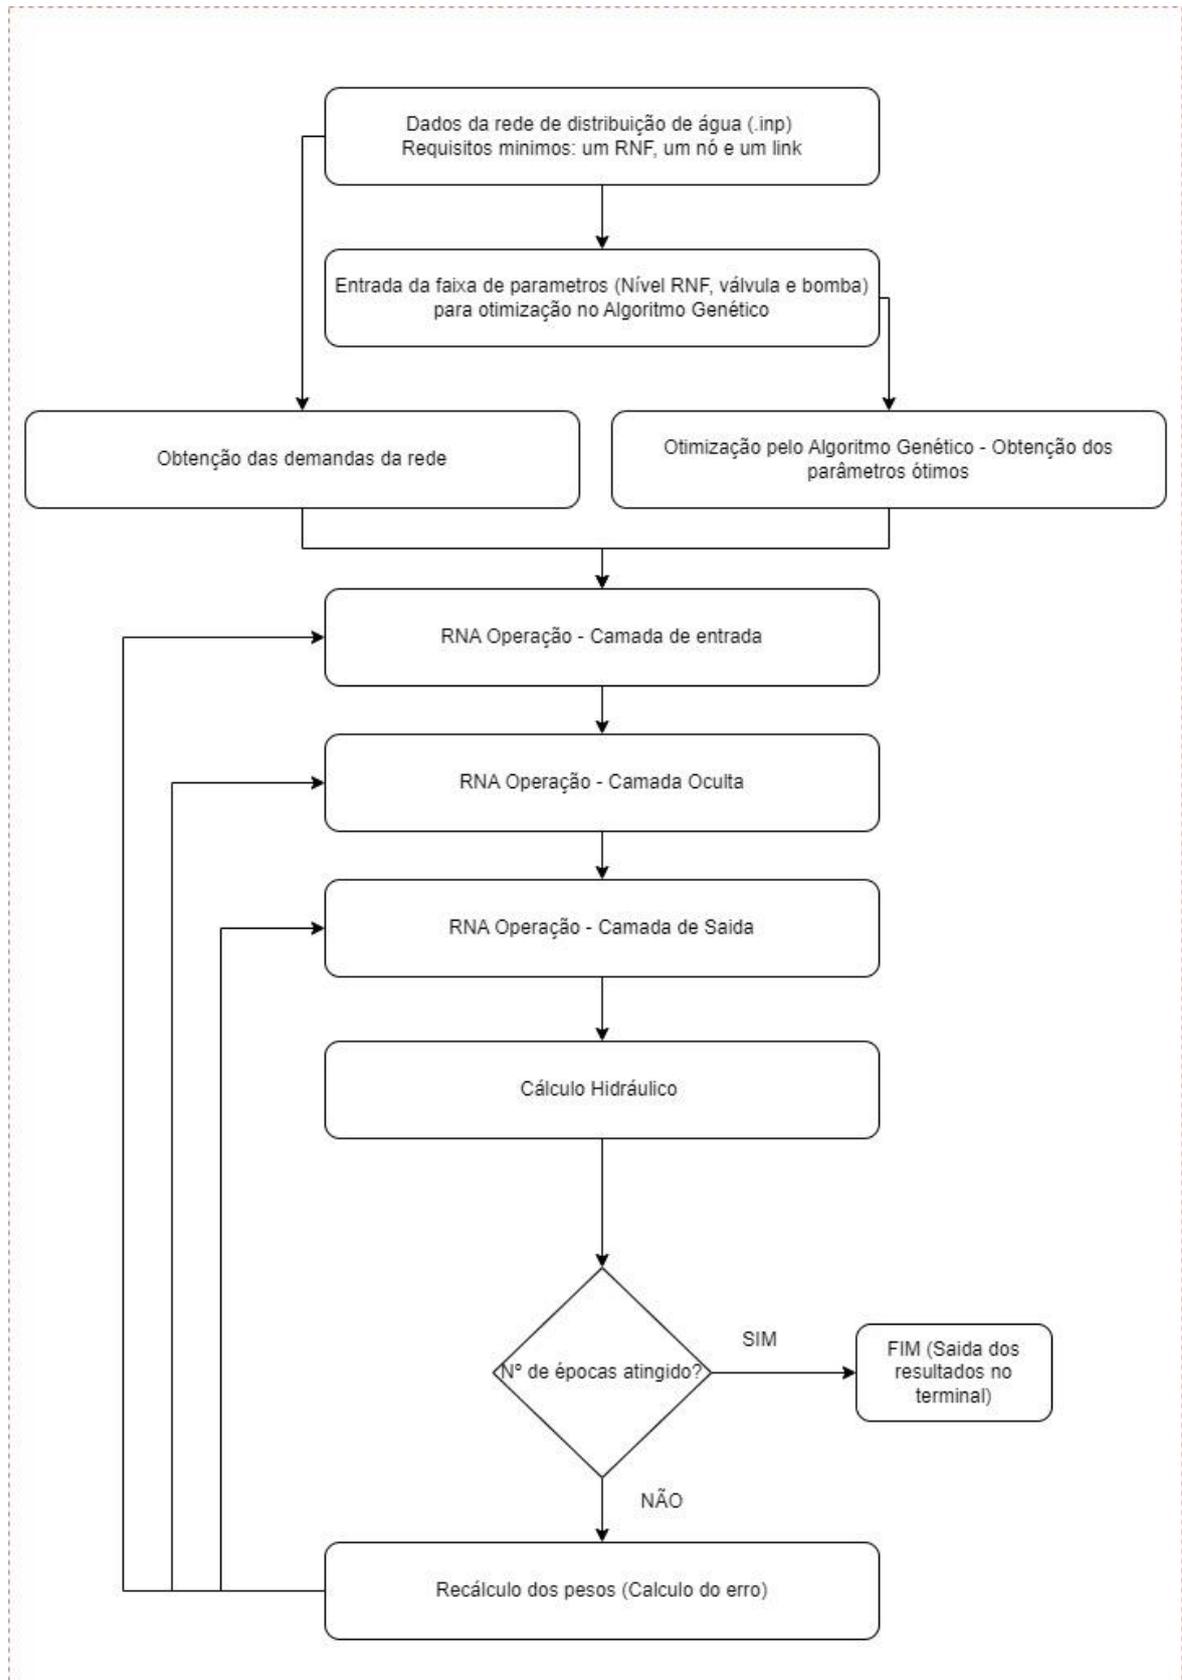
Pode-se observar um problema em comum aos cenários-base, que é a existência de pontos acima da pressão máxima estabelecida pela norma, estabelecida em 50 m.c.a.

Assim, serão apresentados os resultados obtidos pela Rede Neural de Operação, cujo objetivo foi o de aprender a operar na melhor condição possível obtida pelo Algoritmo Genético de otimização para um determinado horário e após, os resultados para a operação nas últimas 24 horas obtidas pela Rede Neural de Previsão.

5.2 Resultados para a Rede Neural de Operação.

A Rede Neural de Operação é um algoritmo produto deste trabalho, cujo funcionamento é descrito pelo fluxograma da Figura 30.

Figura 31 - Algoritmo da RNA de Operação.



Fonte: Autor (2023).

O algoritmo funciona da seguinte forma: Seleciona-se o arquivo *.inp* da rede a ser submetida a operação (no caso, as redes T1 e T2) e então se estabelece, através do terminal, a faixa mínima e máxima dos parâmetros a serem otimizados, sendo que caso a rede não disponha do referido parâmetro – por exemplo: uma rede sem bombas – o algoritmo irá ignorá-los.

Assim, após a otimização pelo algoritmo genético, os dados ótimos obtidos irão para a Rede Neural de Operação, a qual irá executar 30000 épocas para então obter os parâmetros previstos para as demandas do horário estabelecido, submetendo os parâmetros ao cálculo hidráulico e então realizando o cálculo do erro face ao resultado ótimo obtido pelo algoritmo genético.

Em seguida, conforme o erro, realiza-se o recálculo dos pesos e reinicia-se a operação na Rede Neural até que se atinjam todas as épocas. Para a rede T1, foram obtidos os seguintes resultados, incluindo o cálculo das perdas, como pode ser observado na Tabela 7, onde “AG” se refere aos resultados obtidos pelo algoritmo genético e “RNAOp” aos resultados obtidos pela Rede Neural Artificial de Operação.

Tabela 7 - Resultados para a rede T1.

Base T1		AG T1		RNAOpT1	
ID do nó	Pressão (m.c.a.)	ID do nó	Pressão (m.c.a.)	ID do nó	Pressão (m.c.a.)
3	44,69	3	10,79	3	10,80
4	49,51	4	15,61	4	15,62
5	54,23	5	20,33	5	20,35
6	59,58	6	15,12	6	15,13
7	64,49	7	20,04	7	20,04
8	59,83	8	12,55	8	12,56
9	79,06	9	32,61	9	32,62
10	83,32	10	36,87	10	36,88
11	74,59	11	27,55	11	27,55
12	85,70	12	39,26	12	39,26
13	79,61	13	33,17	13	33,17
14	15,49	14	38,18	14	38,19
15	28,22	15	42,50	15	32,89
média (m.c.a.)	59,87	média (m.c.a.)	26,51	média (m.c.a.)	25,77
perdas (%)	56,25%	perdas (%)	37,43%	perdas (%)	36,91%

Fonte: O autor.

Para o sistema de distribuição de água T1, destacam-se os resultados relativos as pressões obtidas pelo Algoritmo Genético, onde observa-se uma redução nas pressões da rede, que passaram a atender integralmente o disposto na norma NBR 12218 (ABNT, 2017).

Deve-se notar, porém, que o nó 15 apresentou um ligeiro aumento na sua pressão, no caso, um aumento de 14,28 m.c.a. em comparação ao cenário-base. Apesar desse aumento, a pressão média caiu 33,36 m.c.a., e as perdas sofreram uma redução de 18,82 pontos percentuais, apresentando uma redução de 33,46 % em relação ao cenário-base.

Os resultados obtidos pelas Redes Neurais Artificiais mostraram uma redução na pressão e nas perdas em comparação aos obtidos pelos Algoritmos Genéticos, inclusive com o nó 15 apresentando um aumento de 4,67 m.c.a. em relação ao cenário base.

Observando-se os valores de pressão média, nota-se uma redução de 0,73 m.c.a., resultando em uma perda 0,52% menor e uma redução de 0,93% em relação aos resultados obtidos pelos Algoritmos Genéticos.

Os resultados podem indicar um potencial das Redes Neurais de Operação para incorporar outros parâmetros de supervisão que permitam maior aderência dos demais nós aos valores de pressão da norma, além dos resultados dos Algoritmos Genéticos.

Agora, para o sistema de distribuição de água T2, os resultados estão na Tabela 8 juntamente com suas perdas.

Tabela 8 - Resultados para a rede T2

Base T2		AG T2		RNAOpt2	
ID do nó	Pressão (m.c.a.)	ID do nó	Pressão (m.c.a.)	ID do nó	Pressão (m.c.a.)
3	44,71	3	17,56	3	17,57
4	49,46	4	20,97	4	20,98
5	54,48	5	24,49	5	24,50
6	59,52	6	25,65	6	25,65
7	64,40	7	30,91	7	30,92
8	59,82	8	21,18	8	21,18
9	50,00	9	15,25	9	10,69
10	20,00	10	20,51	10	10,69
11	74,73	11	36,09	11	36,10
12	59,90	12	25,15	12	20,59
13	20,00	13	10,69	13	10,69
14	15,44	14	16,00	14	16,01
15	28,47	15	29,42	15	9,51
média (m.c.a.)	46,23	média (m.c.a.)	22,61	média (m.c.a.)	19,62
perdas (%)	49,43%	perdas (%)	34,57%	perdas (%)	32,20%

Fonte: O autor.

Assim como na rede T1, o Algoritmo Genético obteve uma redução da pressão média no sistema de distribuição de água, passando de 46,23 m.c.a. no cenário base para 22,61 m.c.a.,

resultando na redução das perdas de 49,43% para 34,57%, uma redução de 14,86 pontos percentuais e redução de 30,07% em relação ao cenário base.

As Redes Neurais obtiveram uma pressão média de 19,62 m.c.a. e 32,20% de perdas, sendo 2,36 pontos percentuais inferior aos algoritmos genéticos e representando numa melhoria de 34,85%.

Destacam-se os nós 9, 10 e 12, cujas pressões foram 4,56 m.c.a., 9,82 m.c.a. e 4,56 m.c.a. inferiores aos obtidos pelos Algoritmos Genéticos, respectivamente. No entanto, o nó 15 obteve uma pressão de 9,51 m.c.a., ligeiramente inferior aos 10 m.c.a. estabelecidos pela NBR 12218.

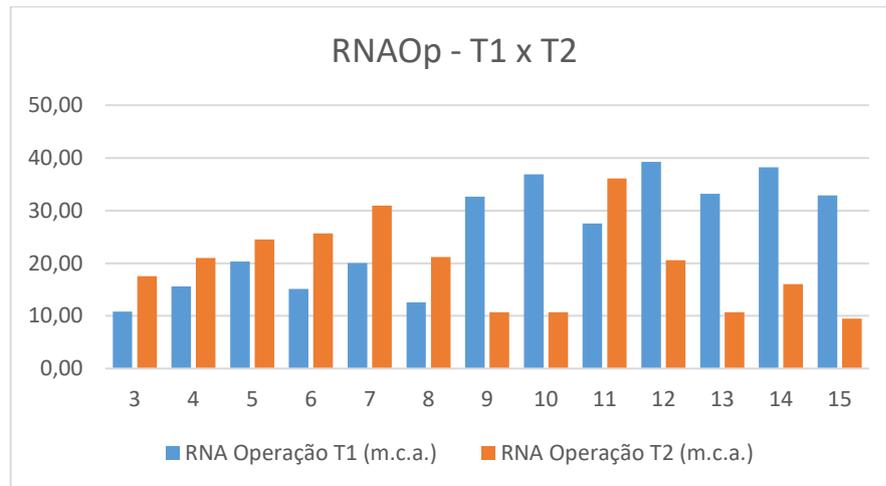
Como o nó 15 é suprido pela Bomba 2, é possível que algum fator não esteja permitindo um ajuste adequado da referida bomba pela Rede Neural de Operação, o que não ocorre na rede T1. Assim, há a possibilidade que a malha formada pelos nós 3, 4, 5, 6, 7 e 8 na rede T2 possa ter criado alguma condição que a Rede Neural de Operação não tenha conseguido contornar satisfatoriamente.

Assim, pode-se recomendar que o algoritmo incorpore futuramente algum dispositivo que permita pequenas correções nos parâmetros para tais situações, permitindo pequenos ajustes nos parâmetros de bomba para suprir pequenas deficiências, menores que 0,5 m.c.a.

Uma comparação entre os resultados obtidos da rede T1 com a rede T2 é pertinente, uma vez que trata-se de comparação entre redes cujas cotas e demandas são idênticas, variando apenas o arranjo de tubulações, sendo a T1 concentrando a malha mais na região baixa e a T2, na região alta.

Tal diferença influi no desempenho de válvulas, uma vez que na rede T1 as mesmas estão localizadas em região malhada, que tende a redistribuir a pressão da rede, enquanto na T2 as válvulas estão em região ramificada, que potencializa seu desempenho. Portanto, a diferença de pressões entre as redes pode ser observada no gráfico da Figura 30.

Figura 32 - Comparação dos resultados.



Fonte: O autor.

Observa-se que na rede T1, a presença da malha formada pelos nós de 7 a 15 acaba por redistribuir a pressão, fazendo com que as válvulas tenham menor eficácia se comparadas a rede T2, onde a configuração malhada dos nós anteriormente mencionados permite um controle das válvulas mais preciso.

Deve-se atentar também que na rede T1, as bombas, que suprem os nós 14 e 15 enviam mais pressão que seria necessário, indicando que poderiam funcionar com menos rotação para evitar sobrepessão nos referidos nós.

Assim, os resultados apontam que as redes neurais do tipo *perceptron*, ainda que com apenas uma camada oculta e utilizando uma função de ativação simples como a linear, podem ser utilizadas para controle de sistemas de distribuição de água.

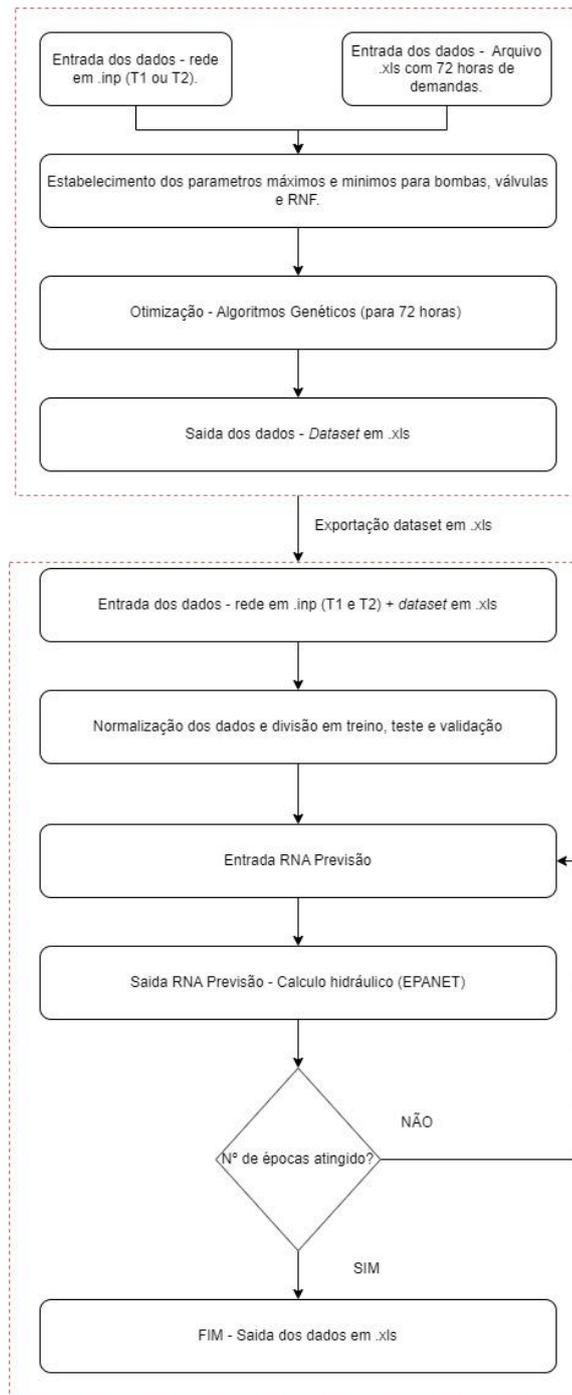
As Redes Neurais de Operação, tanto para a rede T1 como para a rede T2 se mostraram capazes de controlar os parâmetros de distribuição de água, ainda que o nó 15 da rede T2 tenha ficado ligeiramente abaixo de 10 m.c.a., sugerindo que as redes neurais recebam algum mecanismo que permita pequenas correções.

Portanto, o conceito de se utilizarem Redes Neurais para a obtenção de parâmetros de operação de sistemas de distribuição de água através de dados de demanda dos nós mostra-se válido, permitindo que o trabalho prosseguisse com um conceito mais complexo, de realizar a previsão dos parâmetros utilizando como dados de entrada as demandas nos nós de dias seguidos, fazendo com que a rede de distribuição de água passe a aprender a operar conforme as suas demandas.

5.3 Resultados para a Rede Neural de Previsão

O principal produto deste trabalho foi o algoritmo de Redes Neurais de Previsão, cujo funcionamento é explicado no fluxograma da Figura 33.

Figura 33 - Fluxograma do Algoritmo de RNA de Previsão.



Fonte: Autor (2023).

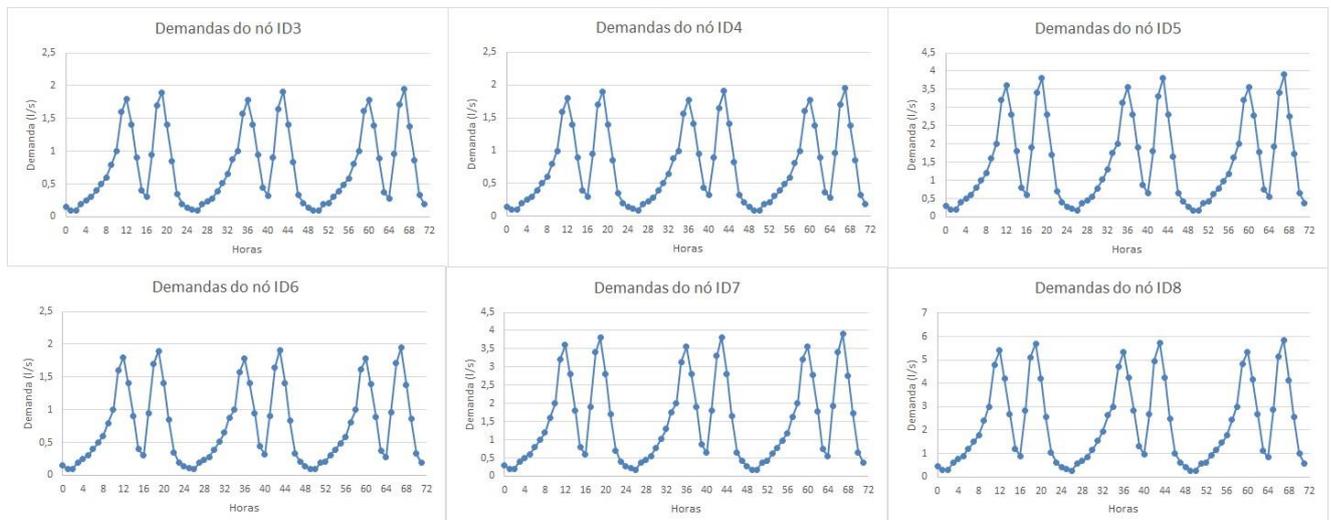
O Algoritmo da RNA de Previsão funciona da seguinte forma: Primeiro, entra-se com o arquivo *.inp* das redes T1 ou T2 e com a faixa dos parâmetros a serem otimizados, sendo eles bombas, RNF e válvulas, e também com o arquivo *.xls* contendo as 72 horas de demandas para os nós das redes.

Após, exporta-se o *dataset* em *.xls* com os pontos ótimos e então é feita a otimização para cada horário com os algoritmos genéticos, sendo esse o processo mais demorado de todos.

Assim, com os parâmetros ótimos obtidos e as demandas, alimenta-se as Redes Neurais de Previsão, que irão realizar, por 30000 épocas, as previsões para as últimas 24 horas do modelo, que irão para o módulo de cálculo hidráulico e assim, o arquivo *.xls* com as pressões calculadas será obtido.

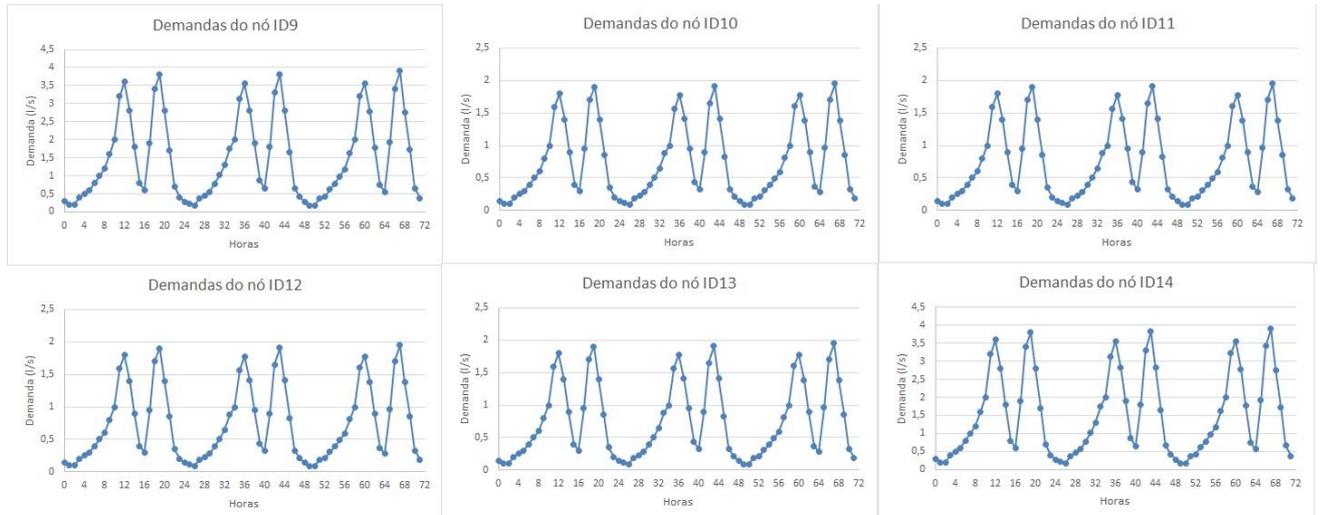
Assim, para T1 e T2, foram utilizadas as demandas como fatores preditores para 72 horas (3 dias) mostradas nas figuras 32, 33 e 34, respectivamente, podendo seus valores serem consultados no Anexo I.

Figura 34 - Demanda dos nós 3 a 8.



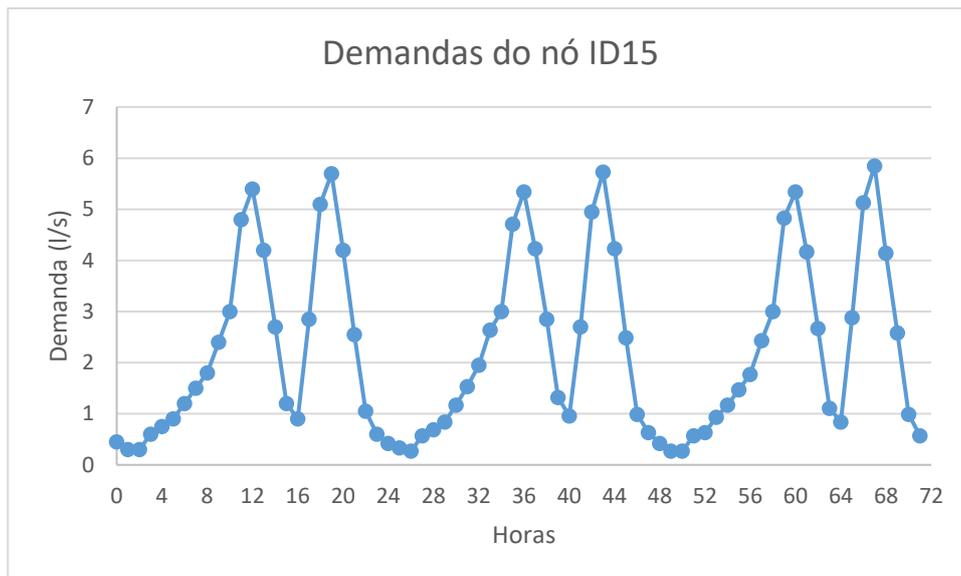
Fonte: O autor.

Figura 35 - Demandas dos nós 9 a 14.



Fonte: O autor.

Figura 36 - Demanda do nó 15.



Fonte: O autor.

Observa-se que as demandas seguem um padrão geral, variando apenas a faixa de consumo, com pontos apresentando demandas maiores como os nós 8 e 15, pontos de consumo intermediário como os nós 5, 7, 9 e 14, e pontos de baixo consumo como os demais nós.

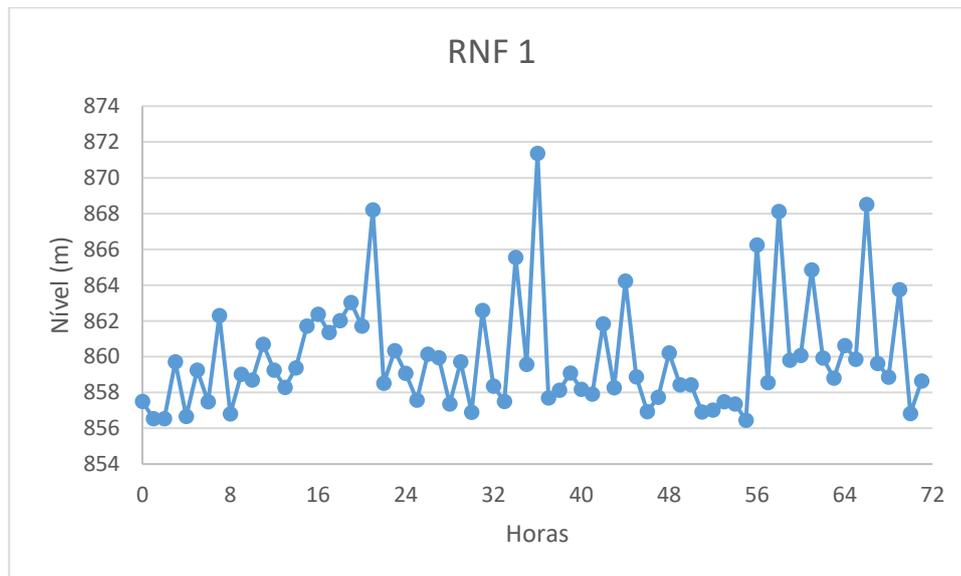
O Objetivo era de simular uma rede de distribuição de água com diferenças de consumo entre os pontos, sendo que se pode considerar que os pontos de consumo são residências, que os consumos caem nos períodos de noite e vão aumentando progressivamente durante o dia.

Apresenta-se um pico nos horários próximos ao almoço (entre 11 e 13 horas), caindo novamente até um ponto de vale nas 16 horas, e voltando a subir para um novo pico correspondente as 20 horas, caindo novamente e assim sucessivamente nos 2 dias seguintes.

Assim, pelo uso do Algoritmo Genético de Otimização, obtiveram-se os seguintes parâmetros de reservatório de nível fixo, bombas e válvulas para a rede T1, para serem utilizados pelas Redes Neurais de Previsão em conjunto com os fatores preditores, para seu aprendizado. Maiores detalhes acerca dos valores podem ser consultados na tabela do Anexo II.

Nota-se que conforme a Figura 37, para o RNF 1 o Algoritmo Genético obteve resultados com oscilações de no máximo 6 m.c.a., excetuando-se nos horários 21, 36, 56, 58 e 66, onde notam-se os picos. Não parece haver uma relação entre os picos apontados e o consumo no horário 21, contudo, nos demais horários mencionados aparentam existir uma relação entre os picos e o consumo nos horários.

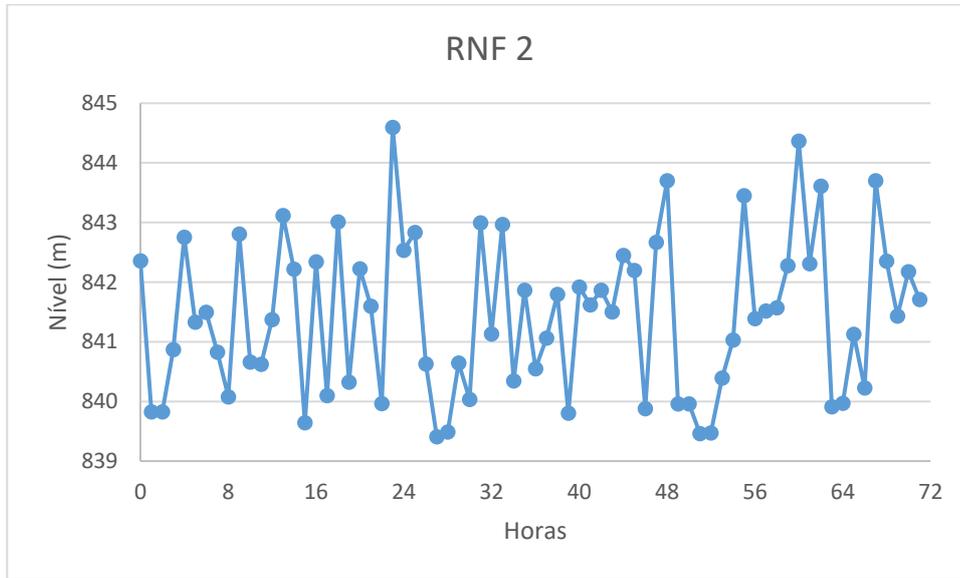
Figura 37 - Parâmetros de RNF 1 para a T1.



Fonte: O autor.

Já para o RNF 2, como se verifica na Figura 38, houve menos de 6 m.c.a. de amplitude entre o valor mínimo e máximo de funcionamento. Chama a atenção o salto dos horários 22 para 23, o de maior amplitude para este parâmetro

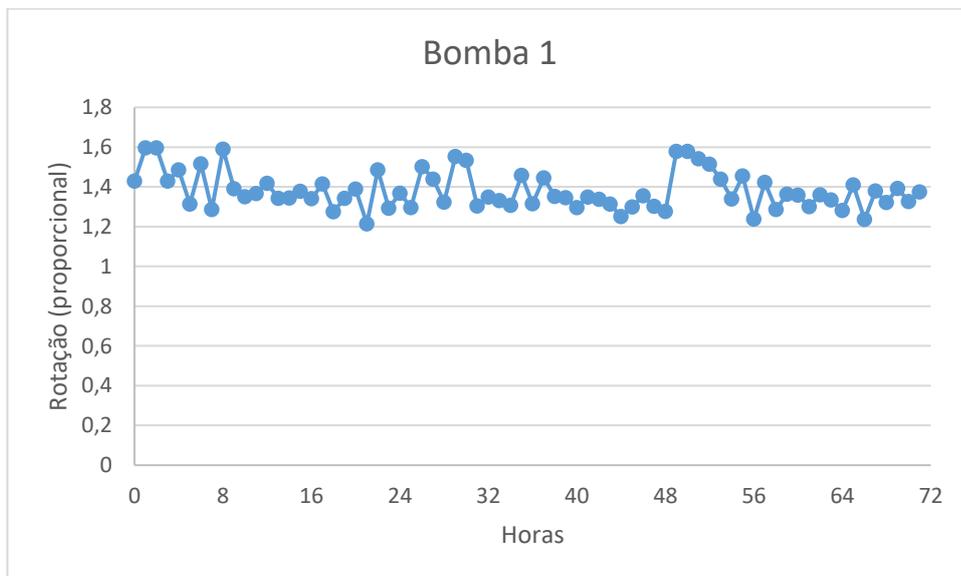
Figura 38 - Parâmetros de RNF 2 para T1.



Fonte: O autor.

A Figura 39 mostra que a bomba 1 esteve oscilando de 1,2 a 1,6. Chama a atenção o salto entre os horários 48 e 49, uma vez que é momento de menor consumo da rede, conforme as demandas.

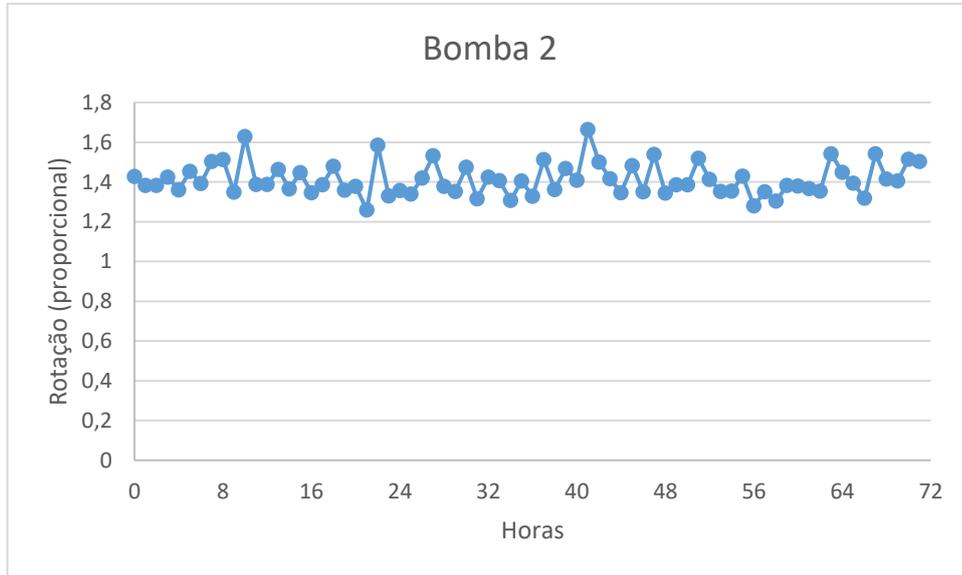
Figura 39 - Parâmetros de bomba 1 para a rede T1.



Fonte: O autor.

A bomba 2, como se vê na Figura 40, também não apresentou um salto como apresentado na bomba 1.

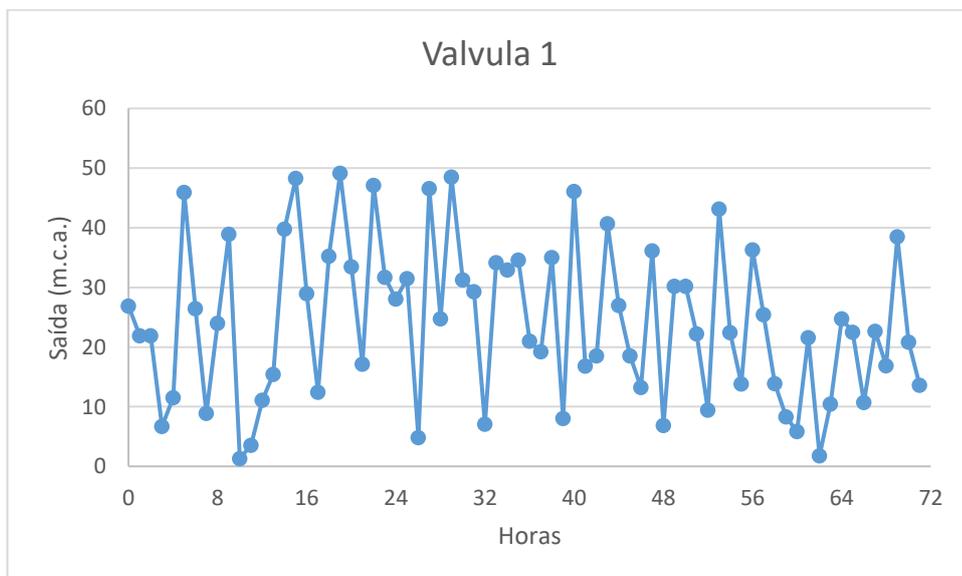
Figura 40 - Parâmetros da Bomba 2 para a rede T1.



Fonte: O autor.

A válvula 1, como na Figura 41 apresentou uma grande oscilação nos parâmetros, indo de 1,31 m.c.a. no horário 10 até 49,41 m.c.a. no horário 19. A grande amplitude dos parâmetros se repete em praticamente todos os horários.

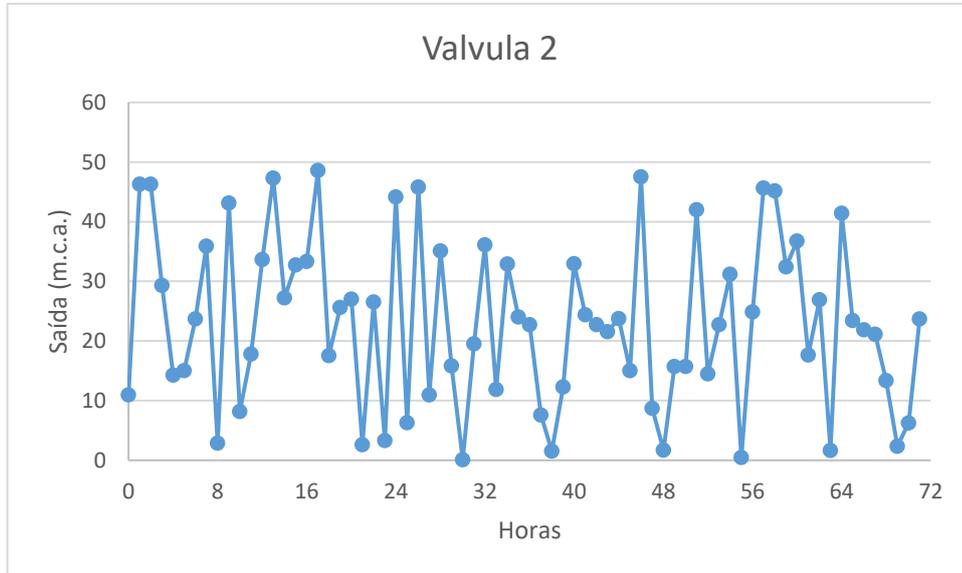
Figura 41 - Parâmetros da Válvula 1 para a rede T1.



Fonte: O autor.

De forma análoga a válvula 1, também se observa uma grande amplitude dos parâmetros obtidos para a válvula 2 como pode ser visto na Figura 42.

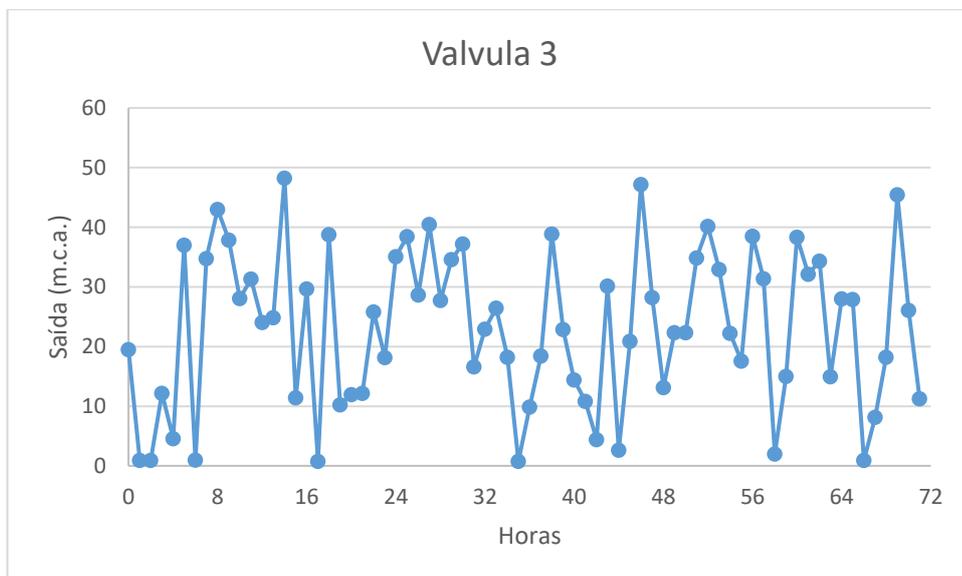
Figura 42 - Parâmetros da Válvula 2 para a rede T1.



Fonte: O autor.

A válvula 3, como se observa na Figura 43, também apresenta uma grande amplitude nos parâmetros. Assim, pode-se concluir que os parâmetros das válvulas apresentaram grande oscilação na sua obtenção por Algoritmos Genéticos.

Figura 43 - Parâmetros da Válvula 3 para a rede T1.

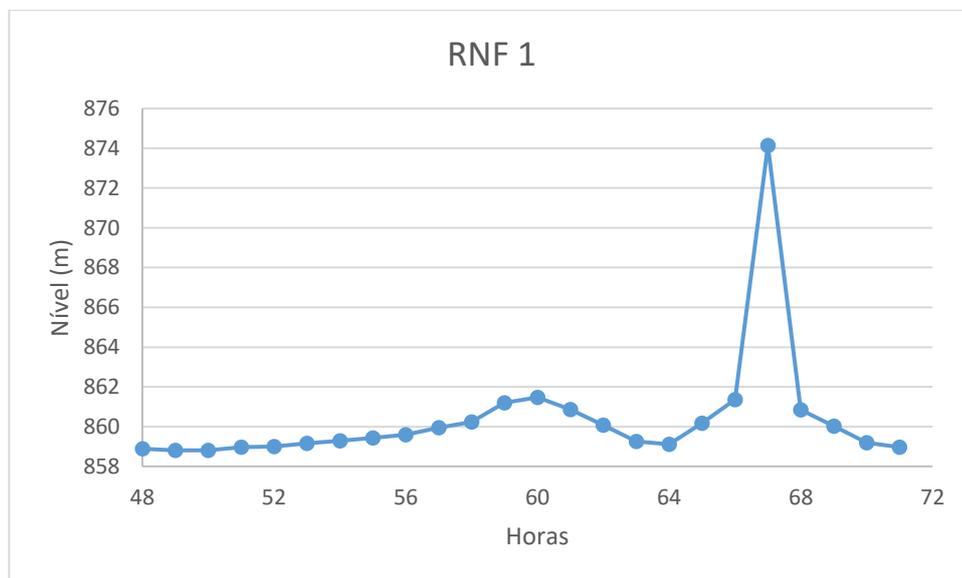


Fonte: O autor.

Os parâmetros previstos pela Rede Neural de Previsão para as próximas 24 horas (hora 48 a hora 71, correspondentes as últimas 24 horas de demandas da série mostrada) estão contidos nos gráficos das figuras 44 a 50, com seus valores numéricos podendo ser observados no Anexo III.

Aqui, a despeito da estabilidade geral, chama a atenção o comportamento anômalo no horário 67, sendo significativamente superior aos demais horários como é destacado na Figura 44.

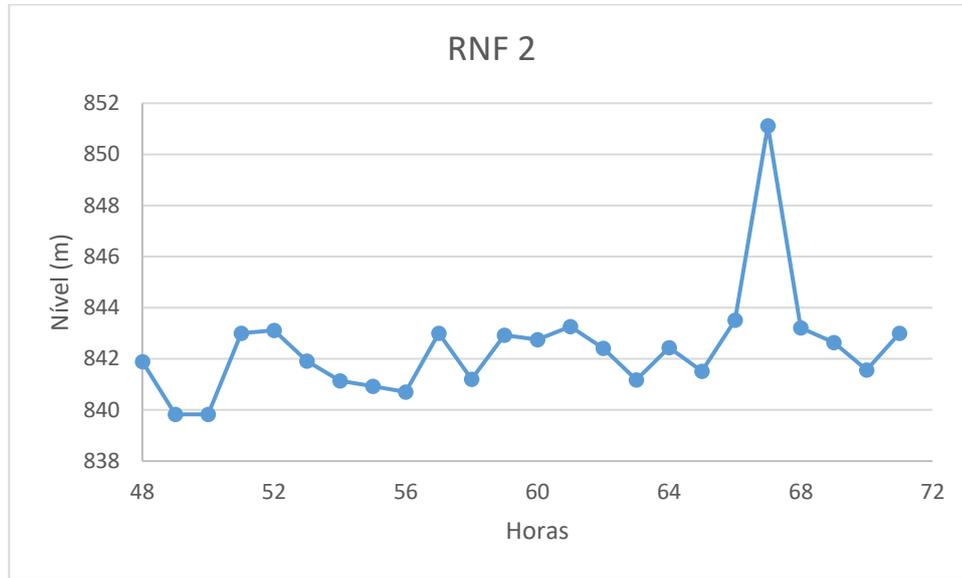
Figura 44 – Parâmetros previstos de RNF 1 para a T1.



Fonte: O autor.

Para o RNF 2, houve menos estabilidade que no RNF 1, e verificou-se o mesmo comportamento anômalo no horário 67, como é visível na Figura 45. Aventa-se como uma possível causa o fato de o horário 67 ser o de maior demanda em toda a série de dados utilizada.

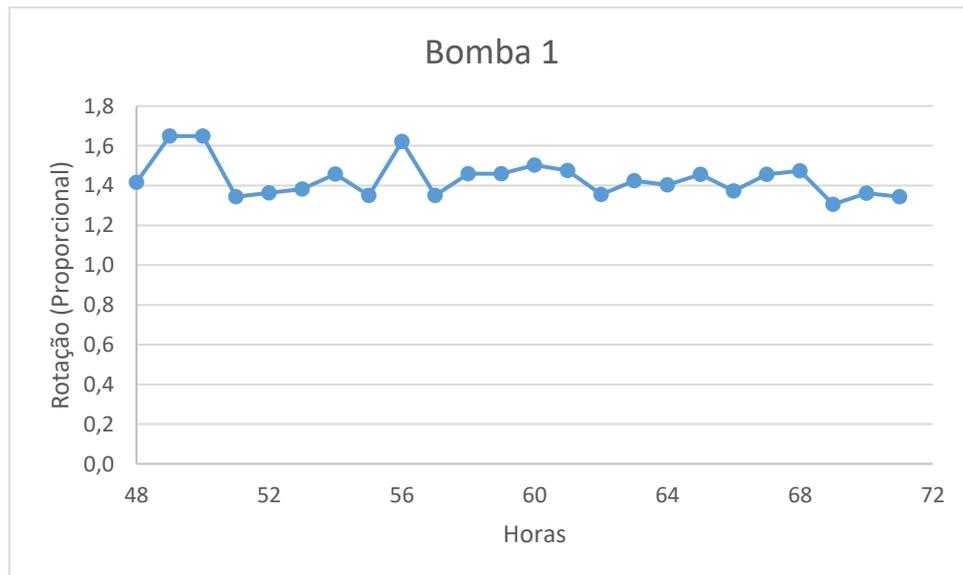
Figura 45 – Parâmetros previstos de RNF 2 para T1.



Fonte: O autor.

Observando os parâmetros da bomba 1 na Figura 46, chama a atenção a amplitude de oscilação de apenas 0,3, excetuando-se os horários 49, 50 e 56. Não se observa a anomalia do horário 67, presente nos RNF 1 e 2.

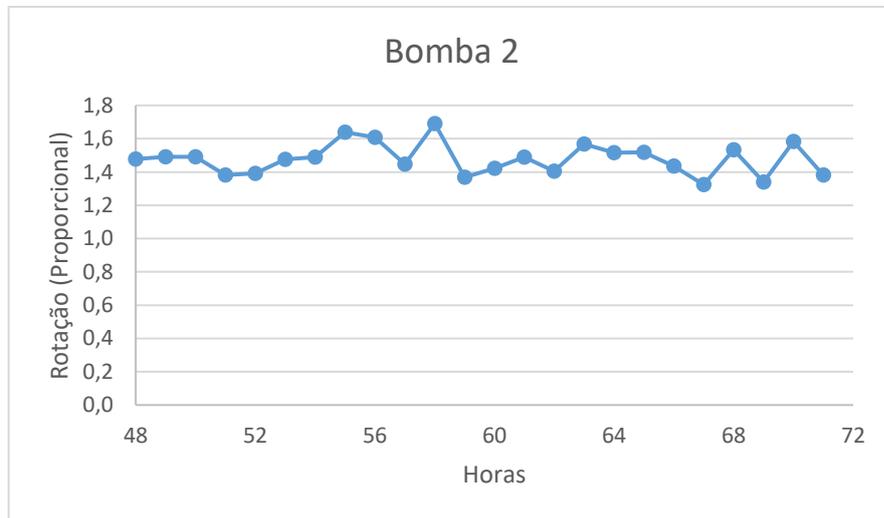
Figura 46 - Parâmetros previstos de bomba 1 para a rede T1.



Fonte: O autor.

Já a bomba 2 apresentou oscilações de cerca de 0,2, excetuando-se os horários 58, 68 e 70, também não sofrendo da anomalia do horário 67, como pode ser observado na Figura 47.

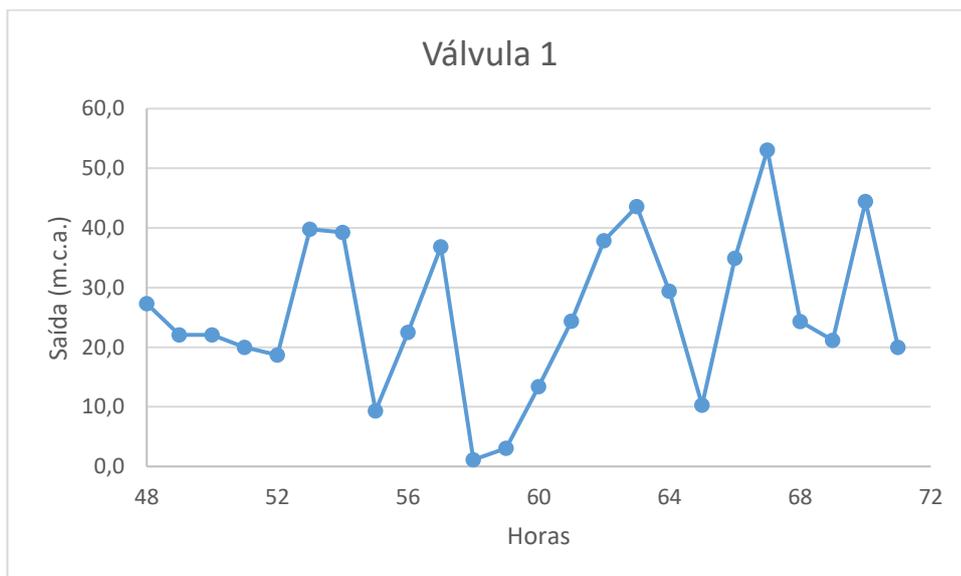
Figura 47 – Parâmetros previstos da Bomba 2 para a rede T1.



Fonte: O autor.

A válvula 1 apresentou oscilação de até 40 m.c.a. nos seus parâmetros. Destaca-se o ponto 67, onde também ocorreu a anomalia, tal como nos RNF 1 e 2, visível na Figura 48.

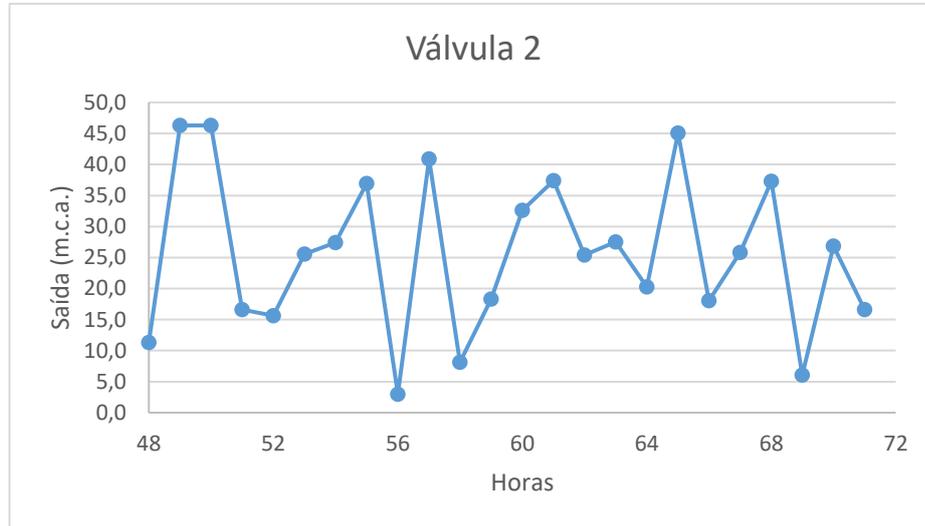
Figura 48 - Parâmetros previstos da Válvula 1 para a rede T1.



Fonte: O autor.

A válvula 2 também apresentou oscilação de aproximadamente 40 m.c.a. em seus parâmetros, porém sem apresentar a anomalia do horário 67, como foi registrado na Figura 49.

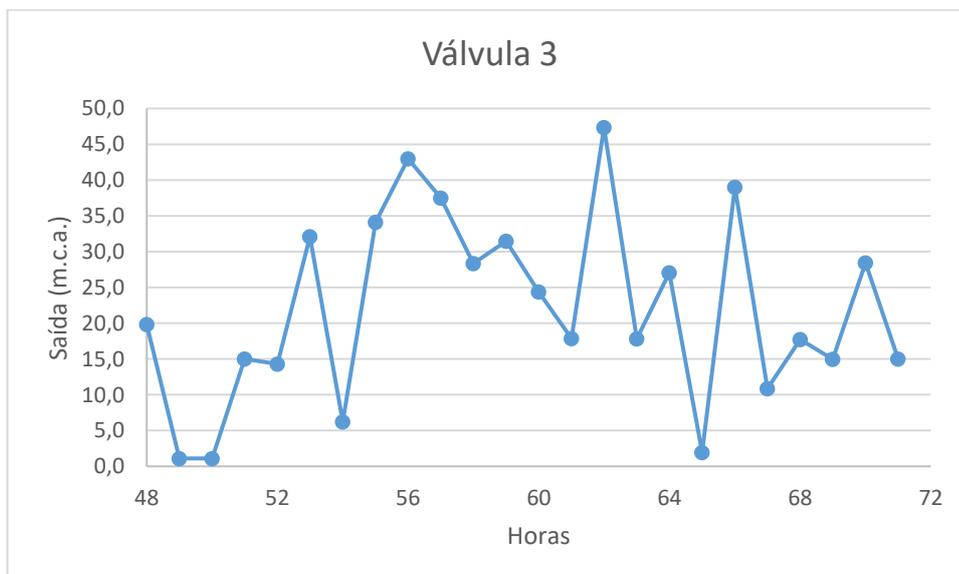
Figura 49 - Parâmetros da Válvula 2 para a rede T1.



Fonte: O autor.

Novamente, similarmente a válvula 2, há amplitude de até aproximadamente 50 m.c.a. nos parâmetros, porém, não há registro da anomalia do horário 67, como registrado na Figura 50.

Figura 50 - Parâmetros da Válvula 3 para a rede T1.



Fonte: O autor.

Assim, os resultados de pressão obtidos com os parâmetros previstos, para a rede T1, estão contidos na Tabela 9, onde se destacam em vermelho as pressões que excederam a norma em mais de 1 m.c.a., em azul as que o fizeram em menos de 1 m.c.a. e em amarelo a anomalia do horário 67.

Tabela 9 - Resultados de pressões para a rede T1

HORA S (DIA)	HORA S (PREVISÃO)	ID3	ID4	ID5	ID6	ID7	ID8	ID9	ID10	ID11	ID12	ID13	ID14	ID15
48	0	12,64	17,64	22,63	16,58	21,58	12,48	34,46	39,44	27,84	44,37	39,34	24,78	27,16
49	1	12,48	17,48	22,47	15,20	20,20	10,51	32,91	37,90	25,96	42,86	37,86	53,92	28,76
50	2	12,48	17,48	22,47	15,20	20,20	10,51	32,91	37,90	25,96	42,86	37,86	53,92	28,76
51	3	12,74	17,74	22,72	17,29	22,29	13,52	35,24	40,20	28,83	45,07	40,02	16,75	15,98
52	4	12,76	17,76	22,74	17,34	22,33	13,62	35,27	40,23	28,92	45,08	40,01	18,87	17,07
53	5	12,73	17,72	22,67	16,30	21,29	12,41	33,95	38,86	27,68	43,56	38,42	21,13	27,01
54	6	12,71	17,69	22,63	15,60	20,58	11,62	33,04	37,91	26,86	42,45	37,25	29,80	28,52
55	7	12,73	17,71	22,61	15,27	20,25	11,37	32,57	37,36	26,55	41,67	36,37	17,39	47,67
56	8	12,70	17,66	22,52	14,39	18,86	11,12	33,33	38,86	26,47	42,97	37,55	50,44	43,51
57	9	13,02	17,96	22,71	16,39	21,33	13,24	33,76	38,43	28,27	42,58	37,47	17,76	23,45
58	10	12,93	17,84	22,47	14,74	19,64	11,43	31,63	35,89	26,43	38,27	32,18	30,18	54,62
59	11	13,23	18,02	22,11	15,46	20,25	12,96	32,59	36,27	27,72	37,32	31,46	30,42	13,78
60	12	13,23	17,98	21,88	15,09	19,84	12,76	31,96	34,83	27,43	32,32	24,38	35,47	19,63
61	13	13,22	18,06	22,37	15,95	20,79	13,34	33,16	36,79	28,23	36,92	29,93	32,35	28,23
62	14	12,93	17,86	22,56	15,20	19,53	12,67	33,98	39,53	27,84	43,98	38,10	18,17	18,35
63	15	12,70	17,69	22,63	15,66	20,65	11,67	33,14	38,02	26,91	42,60	37,41	25,85	38,45
64	16	12,75	17,74	22,71	16,72	21,72	12,9	34,48	39,41	28,19	44,15	39,04	23,50	31,96
65	17	12,94	17,86	22,52	15,02	19,94	11,74	31,98	36,29	26,75	38,87	32,86	29,84	32,04
66	18	13,23	18,00	21,98	15,24	19,25	13,54	33,84	38,99	28,46	43,07	38,46	20,27	21,37
67	19	25,21	29,92	33,61	24,04	28,75	21,14	40,21	42,63	35,76	38,36	29,61	41,78	20,27
68	20	13,21	18,06	22,38	15,91	20,76	13,28	33,11	36,77	28,18	36,97	30,00	32,06	33,59
69	21	13,00	17,94	22,66	16,01	20,95	12,87	33,19	37,63	27,90	40,66	34,83	12,81	11,18
70	22	12,71	17,70	22,65	16,01	21,00	12,07	33,59	38,49	27,33	43,15	38,00	18,76	40,39
71	23	12,74	17,74	22,72	17,29	22,29	13,52	35,24	40,20	28,83	45,07	40,02	16,75	15,98

Fonte: O autor.

Observa-se que em linhas gerais, as Redes Neurais conseguiram realizar uma previsão dos parâmetros, produzindo resultados dentro do estabelecido da norma, excetuando-se os horários 49, 50 e 56 (Horas 01, 02 e 08 do dia) onde as pressões excederam o estabelecido pela NBR 121228, ficando em 53,92 m.c.a., 53,92 m.c.a. e 50,44 m.c.a., respectivamente.

Nota-se que os valores fora da faixa são relacionados a bomba 1 operando aproximadamente a 160% da sua rotação nominal, enquanto no nó 15, o horário 58 obteve uma pressão de 54,62 m.c.a., sendo este último um nó relacionado a bomba 2.

No entanto, um ajuste geral nos hiperparâmetros nas Redes Neurais de Previsão realizado de forma descoordenada poderia comprometer todo o seu funcionamento, podendo fazer com que os demais parâmetros previstos gerem resultados fora da faixa.

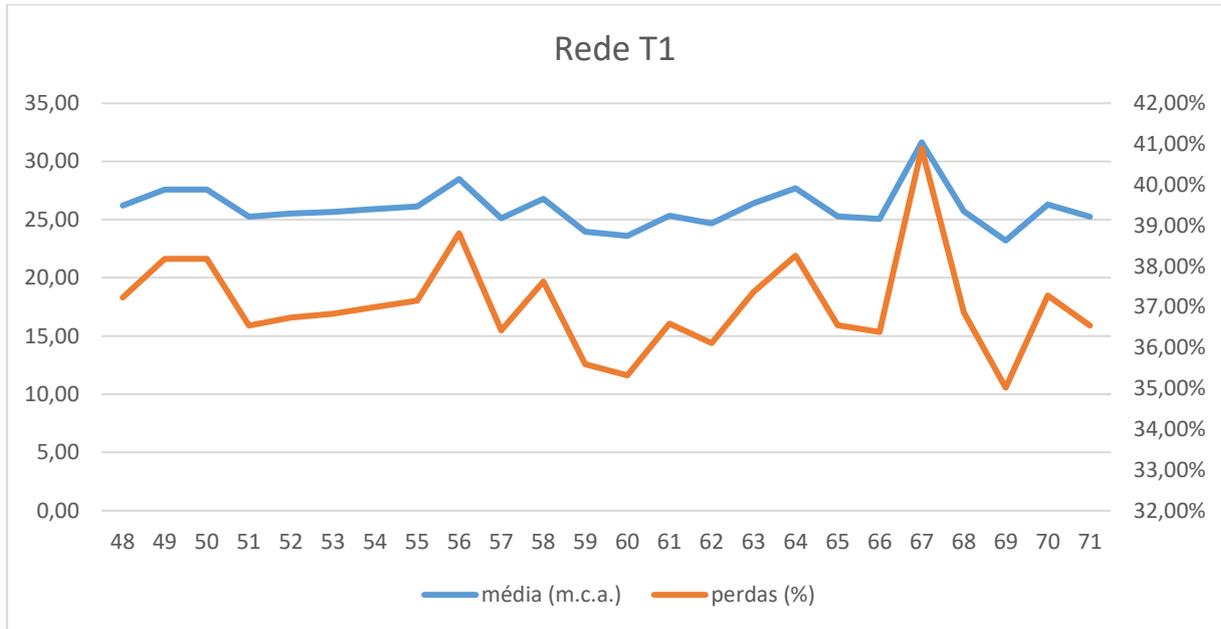
Assim, sugere-se que a implantação de um mecanismo que, após as previsões e os resultados obtidos, seja capaz de fazer ajustes finos na bomba 1 e 2 de modo a reduzir sua rotação para garantir que as pressões se enquadrem na norma e reenviar os resultados novos para as próximas épocas da rede neural, fazendo-a operar de forma ótima.

Pode-se notar no horário 67 um comportamento anômalo das pressões, sensivelmente mais altas que o restante dos horários, com exceção do nó 13. Uma possível causa deste comportamento seriam as demandas, consideradas de pico nos três dias de dados, levando a Rede Neural a produzir parâmetros que, em geral, produzem resultados acima da média como uma forma de compensação da maior demanda.

No entanto, tal situação pode sugerir também a necessidade de implantação de algum mecanismo que evite uma atuação tão agressiva, uma vez que as demandas nos horários 19, 43 e 67 acabaram por induzir as Redes Neurais a exacerbar o ajuste dos parâmetros.

Avaliando o desempenho das Redes Neurais sob o ponto de vista das perdas, observa-se uma redução em relação aos 56,25% em relação ao cenário-base, com valores que oscilam de 35,02% no horário 69 ao pior caso, 40,89%, no horário 67. Novamente, a anomalia do horário 67 se repete, com a rede apresentando maior pressão média e maiores perdas, como pode ser visto na Figura 51.

Figura 51 - Perdas e pressão média da rede T1.



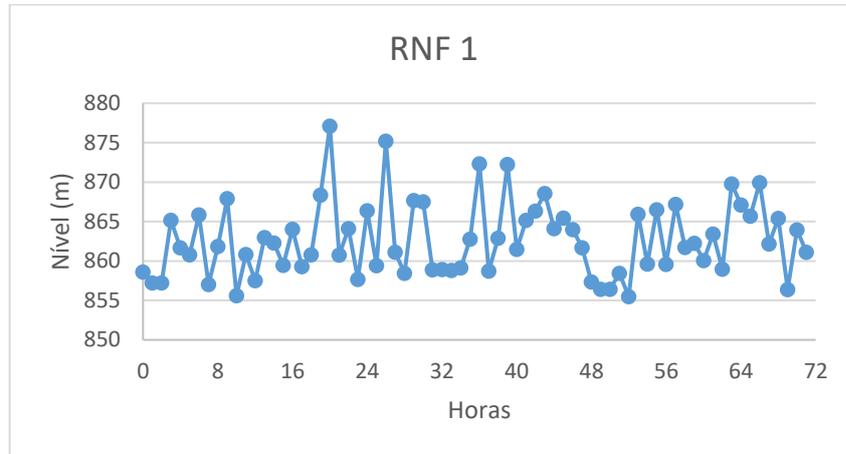
Fonte: O autor.

Portanto, feitas as ressalvas, as Redes Neurais de Previsão conseguiram prever, através das demandas, parâmetros de operação da rede e reduzir as perdas se comparados ao cenário-base, ainda que com as ressalvas da anomalia do horário 67 e dos pontos acima de 50 m.c.a., mostrando-se com potencial para obtenção de melhores resultados com futuros ajustes no algoritmo.

Para a rede T2, foram obtidos os seguintes parâmetros pelo AG de otimização como se vê nas Figuras 52 a 59. Maiores detalhes podem ser consultados no Anexo IV.

Para a rede T2, o Algoritmo Genético teve uma oscilação de aproximadamente 20 m.c.a., se comparada a T1, destacando-se o salto entre os horários 25 e 26, de aproximadamente 15 m.c.a como pode ser observado na Figura 52, indicando um ajuste maior por parte do algoritmo.

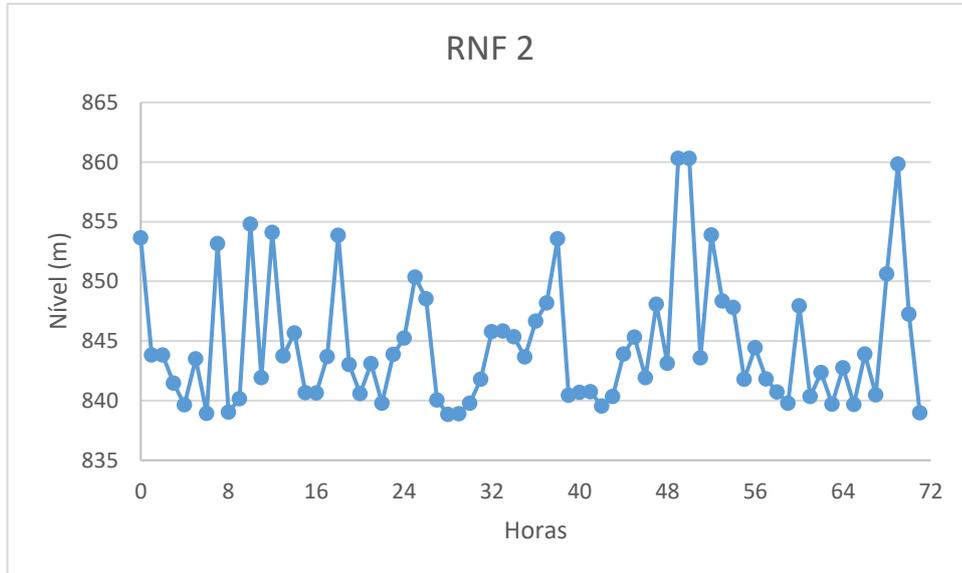
Figura 52 - Dados da RNF 1 para a rede T2.



Fonte: O autor.

O RNF 2, como visto na Figura 53, apresentou amplitudes de até 20 m.c.a., destacando-se um salto de aproximadamente 17 m.c.a. entre os horários 48 e 49.

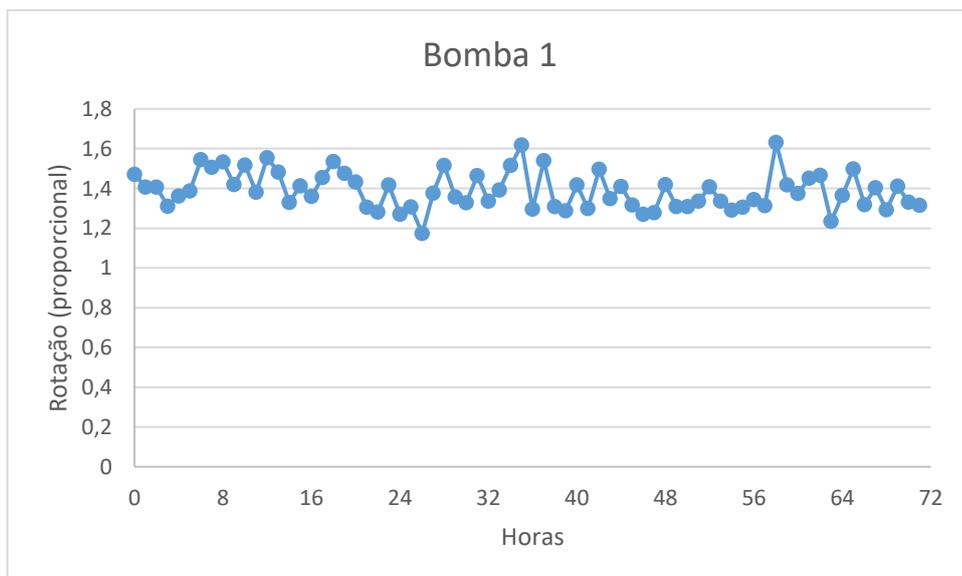
Figura 53 – Dados da RNF 2 para a rede T2.



Fonte: O autor.

Já a bomba 1, como registrado na Figura 54, comportou-se de forma análoga a rede T1, com oscilações de até 0,3, porém, não apresentando o salto dos horários 48 e 49.

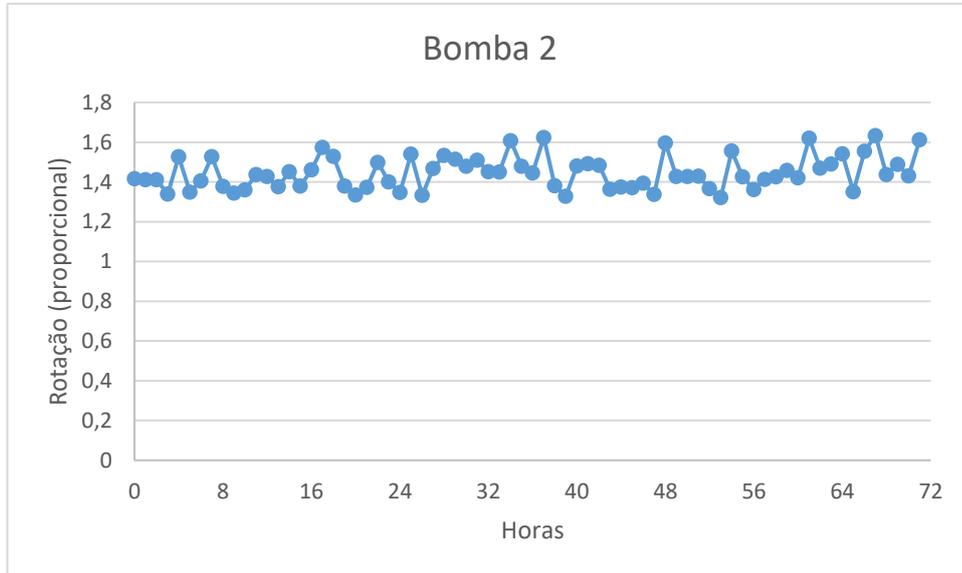
Figura 54 – Dados da bomba 1 para a rede T2.



Fonte: O autor.

A bomba 2 também apresentou oscilações de até 0,3, como pode ser observado na Figura 55.

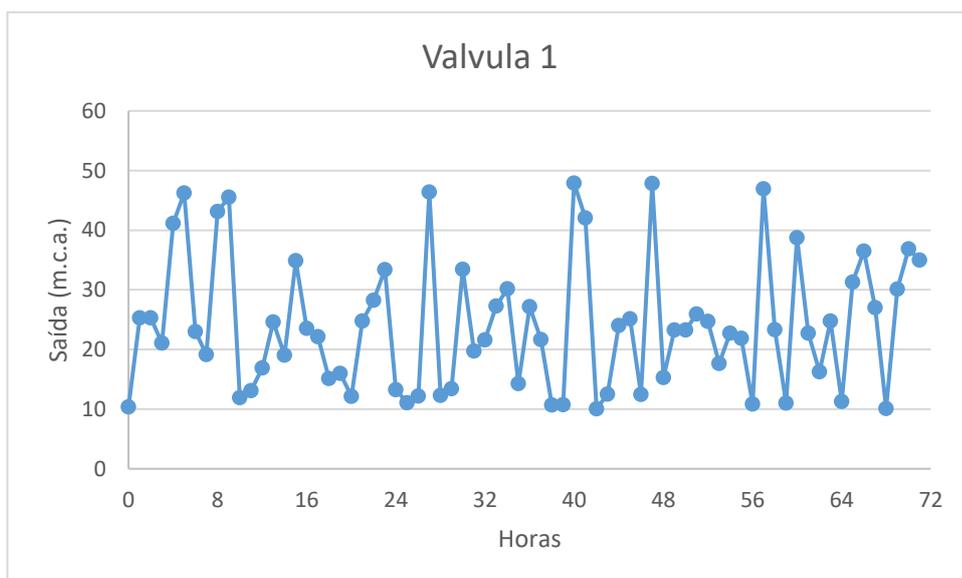
Figura 55 – Dados da bomba 2 para a rede T2.



Fonte: O autor.

A válvula 1 apresentou oscilações de até 40 m.c.a. , tal como na rede T1, destacando-se a diferença nos horários 39 e 40, como se observa na Figura 56.

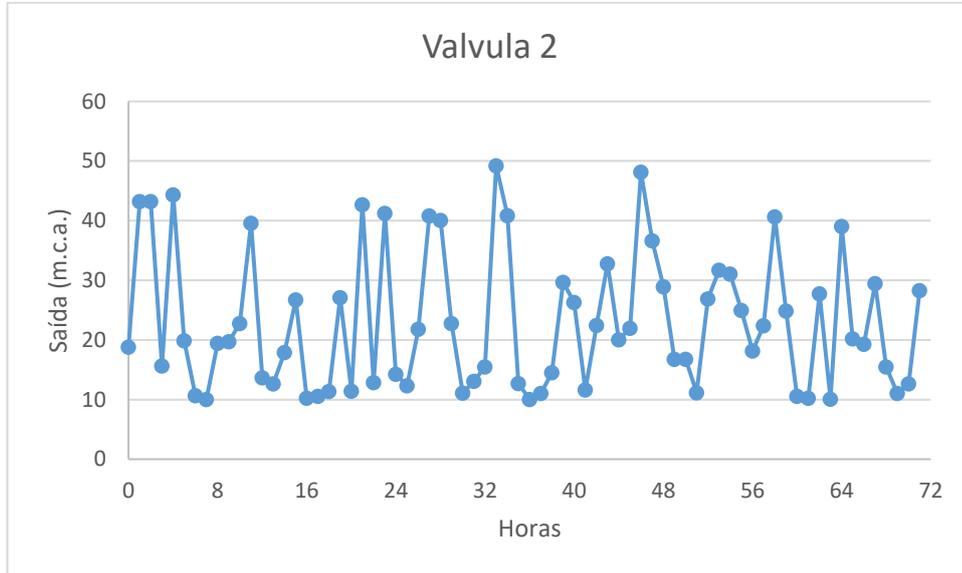
Figura 56 – Dados da válvula 1 para a rede T2.



Fonte: O autor.

A válvula 2 também teve oscilações de até 40 m.c.a., como observa-se na Figura 57.

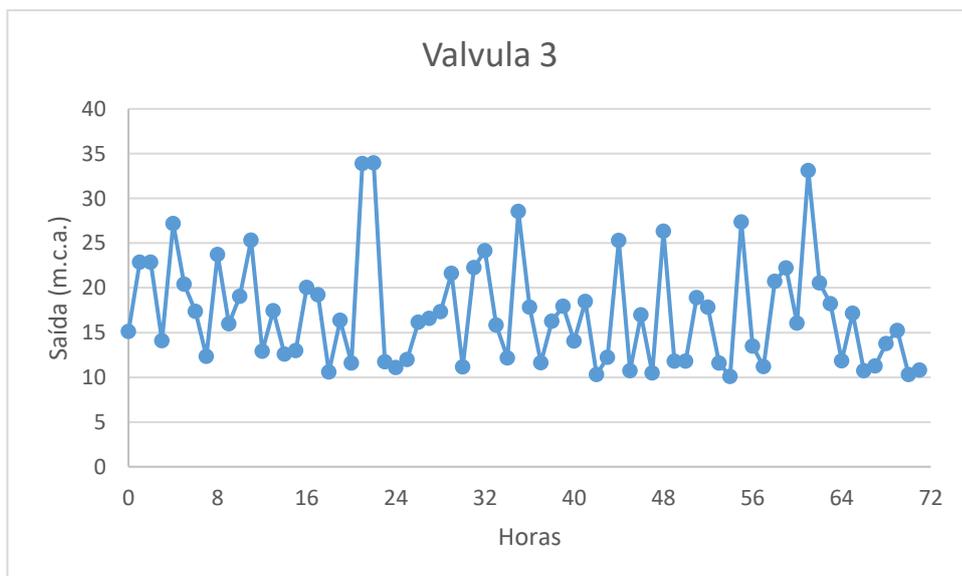
Figura 57 – Dados da Válvula 2 para a rede T2.



Fonte: O autor.

A válvula 3 também teve comportamento similar ao apresentado na rede T1, destacando-se os horários 21 e 22 com pressões praticamente idênticas, como visto na figura 58.

Figura 58 - Dados da Válvula 3 para a rede T2.

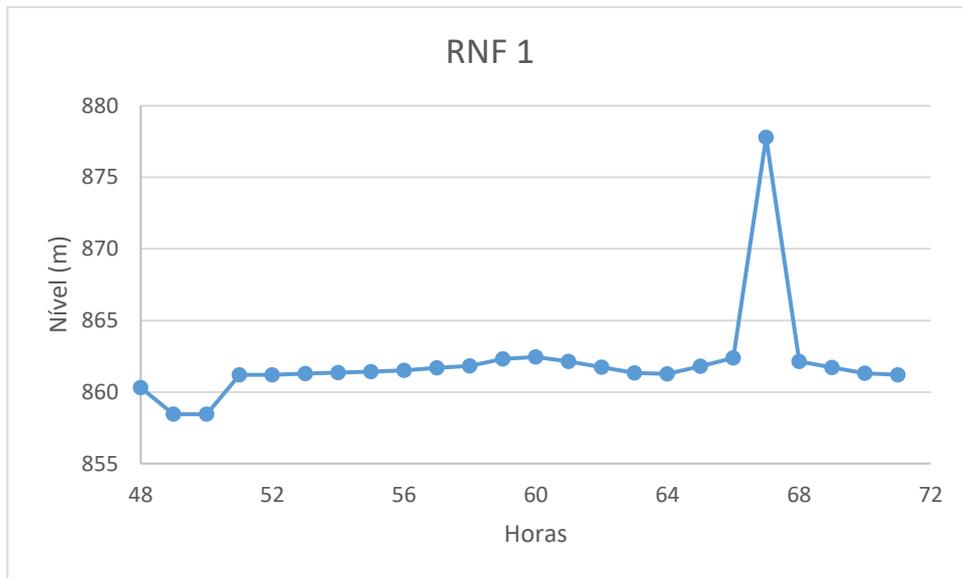


Fonte: O autor.

Para a previsão das próximas 24 horas, utilizando as últimas 24 horas da série de demandas apresentadas, os valores dos parâmetros previstos são mostrados nos gráficos das figuras 59 a 64. Mais dados estão disponíveis no Anexo V.

Para a previsão realizada pela rede neural para a RNF 1, destaca-se, além da anomalia do horário 67 que voltou a ocorrer, uma ligeira queda nos horários 49 e 50, como registrado na Figura 59.

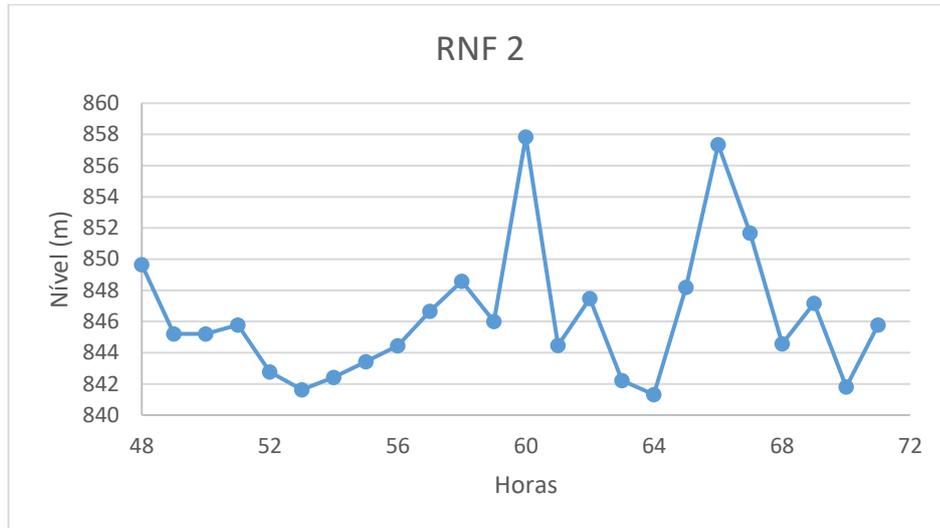
Figura 59 – Dados previstos da RNF 1 para a rede T2.



Fonte: O autor.

Já na RNF 2, ocorre também a anomalia do horário 67, porém, há outro pico, ligeiramente maior, no horário 60, como observado na Figura 60. Não parece estar relacionado a demanda e a nenhuma outra variável, não se sabendo a sua causa.

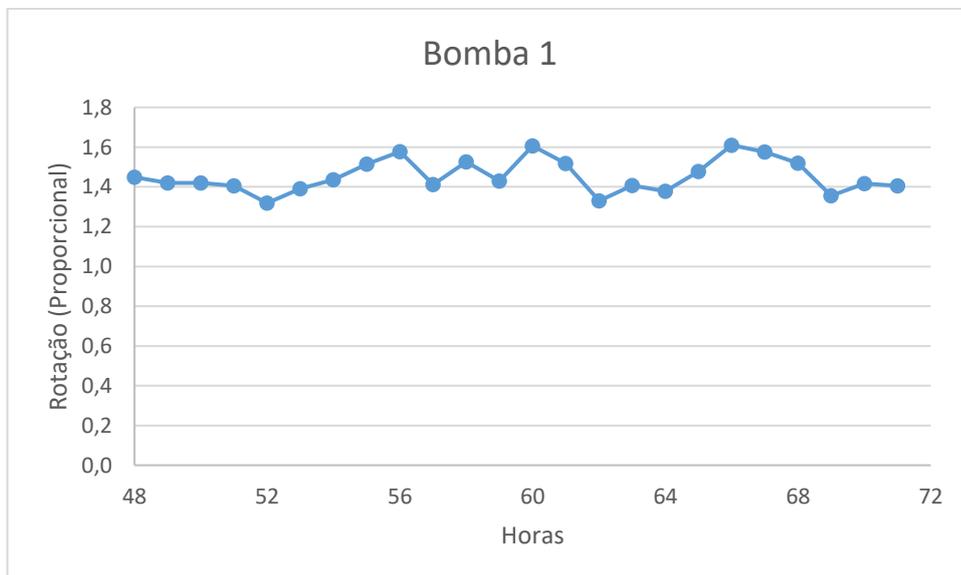
Figura 60 - Dados previstos da RNF 2 para a rede T2.



Fonte: O autor.

Já a bomba 1 não apresentou anomalias, com amplitudes de até 0,3, como na rede T1, conforme pode ser visto na Figura 61.

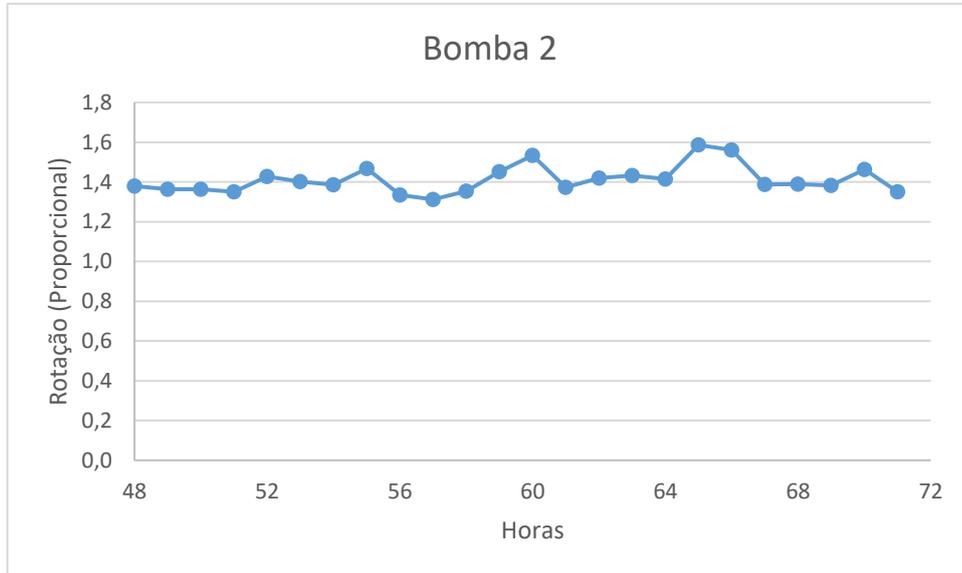
Figura 61 - Dados da bomba 1 para a rede T2.



Fonte: O autor.

A bomba 2 se comportou de forma similar a bomba 1, como pode ser observado na Figura 62.

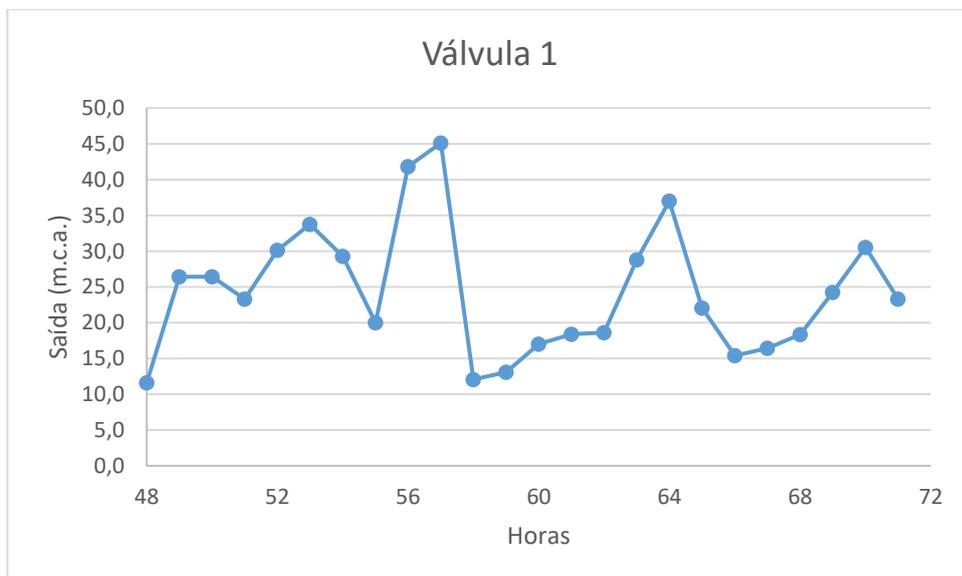
Figura 62 - Dados da bomba 2 para a rede T2.



Fonte: O autor.

Tal como na rede T1, a válvula 1 também se comportou com oscilações, sem, contudo, apresentar a anomalia do horário 67. Destaca-se a diferença de aproximadamente 33 m.c.a. entre os horários 57 e 58, que pode ser visto na Figura 63.

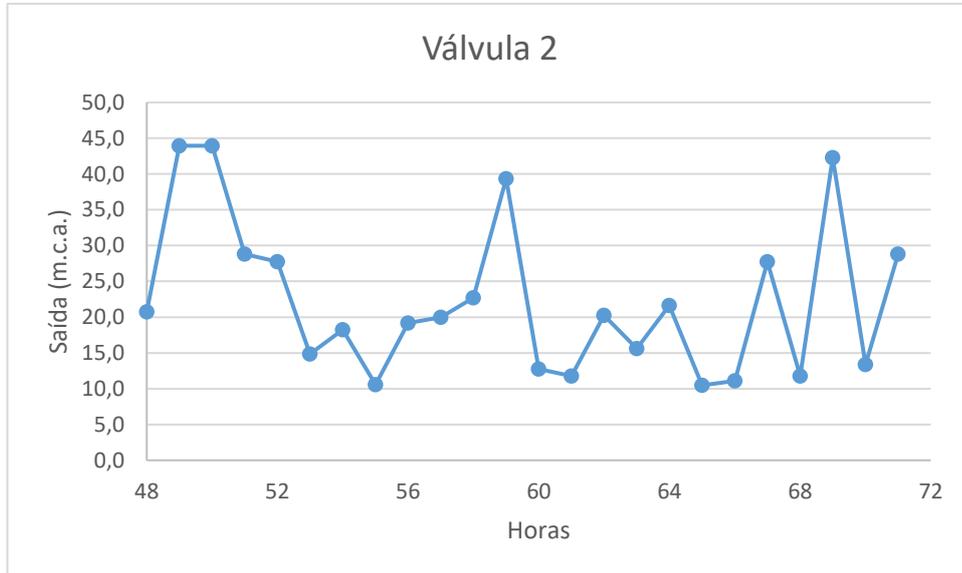
Figura 63 - Dados da válvula 1 para a rede T2.



Fonte: O autor.

A válvula 2 também apresentou oscilações, com destaque para os horários 68 e 69, com aproximadamente 31 m.c.a. de diferença, como visto na Figura 64.

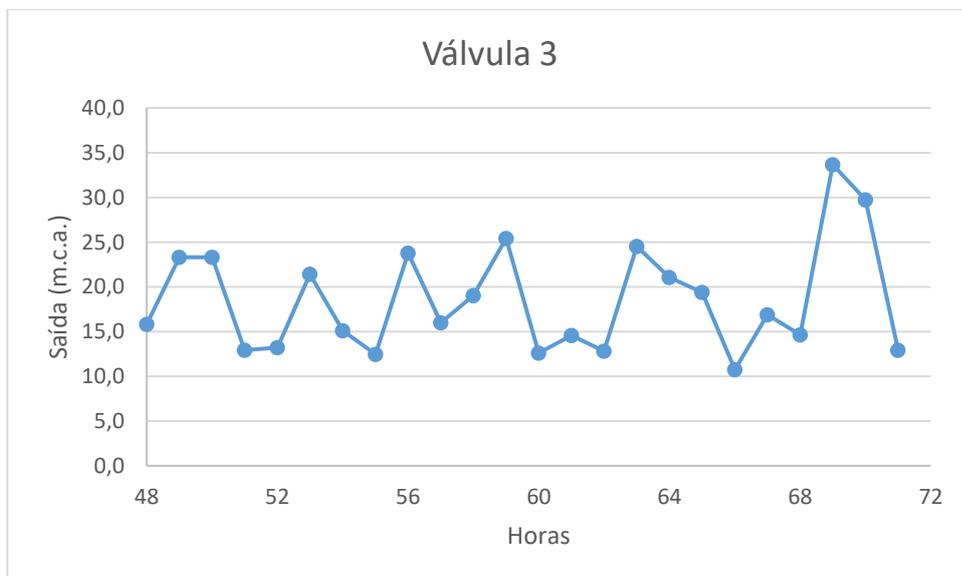
Figura 64 - Dados da válvula 2 para a rede T2.



Fonte: O autor.

Já a válvula 3 apresentou menor amplitude de oscilação que as válvulas 1 e 2, bem como as válvulas em geral na rede T1. Destacam-se os picos dos horários 69 e 70, como visto na Figura 65.

Figura 65 - Dados da válvula 3 para a rede T2.



Fonte: O autor.

Logo, com os parâmetros, foram realizados os cálculos das pressões, conforme Tabela 10, onde destacam-se as pressões que ficaram abaixo da norma em mais de 1 m.c.a. em vermelho e em amarelo, a anomalia do horário 67.

Tabela 10 – Pressões calculadas com os parâmetros previstos para a rede T2.

HORA S (DIA)	HORA S (PREVISÃO)	ID3	ID4	ID5	ID6	ID7	ID8	ID9	ID10	ID11	ID12	ID13	ID14	ID15
48	0	13,66	18,15	22,39	24,83	30,23	20,46	15,83	15,83	35,46	25,83	15,83	29,16	15,41
49	1	11,48	15,89	19,99	21,84	27,84	16,26	23,31	23,31	31,26	33,31	23,31	23,55	11,10
50	2	11,48	15,89	19,99	21,84	27,84	16,26	23,31	23,31	31,26	33,31	23,31	23,55	11,10
51	3	13,78	18,03	21,92	23,22	28,78	16,93	12,92	12,92	31,93	22,92	12,92	23,98	11,71
52	4	13,32	17,43	21,10	21,67	27,34	14,13	13,21	13,21	29,12	23,20	13,21	13,70	19,66
53	5	13,06	17,04	20,55	20,80	26,48	12,99	21,41	21,41	27,98	31,39	21,41	21,34	16,16
54	6	13,11	17,06	20,56	20,98	26,59	13,68	15,11	15,11	28,67	25,10	15,11	26,56	14,28
55	7	13,17	17,09	20,58	21,20	26,74	14,55	12,45	12,45	29,53	22,42	12,45	36,16	23,90
56	8	13,24	17,13	20,61	21,45	26,92	15,42	23,77	23,77	30,39	33,73	23,77	44,21	8,62
57	9	13,41	17,26	20,73	22,07	27,39	17,36	16,01	16,01	32,30	25,95	16,01	23,97	6,26
58	10	13,60	17,41	20,89	22,69	27,91	19,07	19,02	19,02	33,98	28,92	19,02	37,96	10,89
59	11	12,54	15,69	18,39	19,63	24,75	16,32	25,41	25,41	31,12	35,18	25,41	24,43	19,71
60	12	15,35	19,43	23,35	27,83	32,77	27,79	12,61	12,61	42,55	22,33	12,61	50,17	34,68
61	13	12,45	15,68	18,45	19,25	24,46	14,96	14,57	14,57	29,81	24,39	14,57	35,19	10,71
62	14	13,49	17,31	20,79	22,32	27,60	18,07	12,83	12,83	33,01	22,75	12,83	14,87	18,37
63	15	13,10	17,05	20,55	20,93	26,56	13,51	24,54	24,54	28,50	34,52	24,54	23,25	19,64
64	16	13,05	17,03	20,55	20,74	26,44	12,74	21,08	21,08	27,73	31,07	21,08	19,95	17,57
65	17	13,56	17,38	20,85	22,55	27,80	18,71	19,39	19,31	33,63	29,30	19,34	31,84	38,95
66	18	15,22	19,27	23,17	27,46	32,43	27,33	10,75	10,75	42,11	20,49	10,75	50,55	37,99
67	19	25,39	27,53	28,95	27,84	33,08	22,23	16,90	16,90	36,94	26,56	16,90	54,24	22,74
68	20	12,49	15,73	18,52	19,34	24,56	15,07	14,64	14,64	29,92	24,46	14,64	35,30	12,52
69	21	13,46	17,29	20,76	22,22	27,52	17,81	33,66	33,66	32,74	43,59	33,66	17,73	14,12
70	22	13,08	17,04	20,55	20,85	26,50	13,17	29,74	29,74	28,15	39,72	29,74	24,38	23,21
71	23	13,78	18,03	21,92	23,22	28,78	16,93	12,92	12,92	31,93	22,92	12,92	23,98	11,72

Fonte: O autor.

Observa-se que as condições se assemelham ao do cenário com a rede T1, destacando-se a anormalidade no horário 67. Contudo, para a rede T2 a ocorrência de pressões abaixo da norma ocorreu no nó 15 e nos horários 56 e 57, com pressões de 8,62 m.c.a. e 6,26 m.c.a., respectivamente.

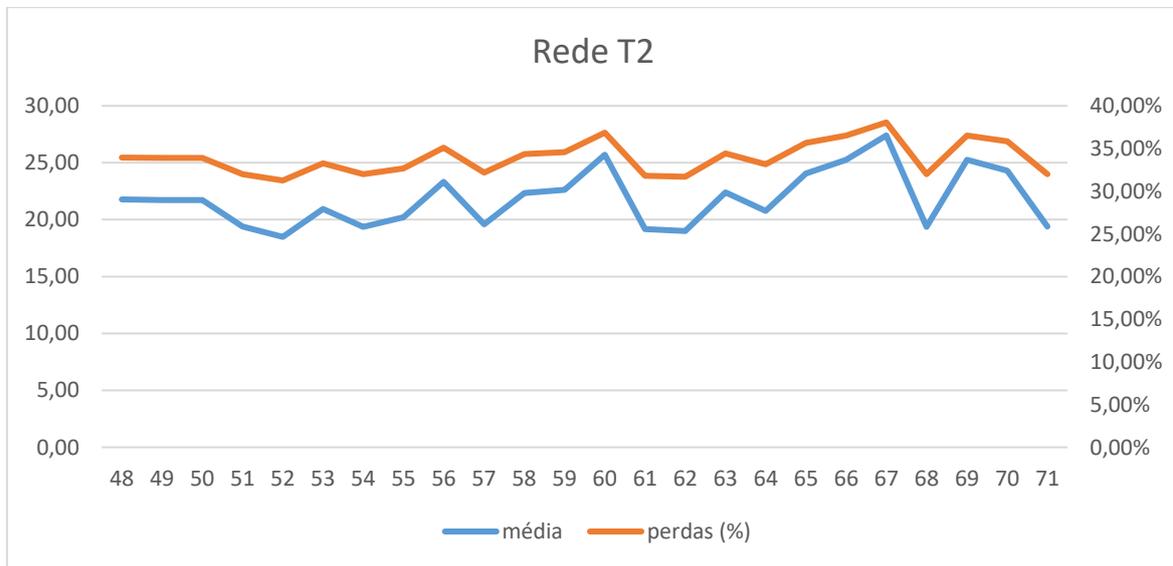
Já as pressões acima da norma foram no nó 14, nos horários 60 e 66, com 50,17 m.c.a. e 50,55 m.c.a., respectivamente.

Na rede T2, portanto, recomenda-se algo análogo ao que se recomenda na rede T1, isto é, a adição de algum mecanismo que permita a compensação das bombas 1 e 2, de modo a se permitir o atendimento adequado em situações excepcionais.

Recomenda-se também, analogamente a rede T1, algum mecanismo que coíba o ajuste demasiadamente agressivo no horário 67, de modo a evitar um aumento desnecessário da pressão média, uma vez que sendo as demandas comuns as duas redes (T1 e T2), a anomalia ocorre novamente.

O gráfico da Figura 66 mostra as perdas e as pressões médias para a rede T2.

Figura 66 - Perdas e pressões médias para a rede T2.



Fonte: O autor.

Novamente, observando pelo prisma das perdas, observa-se a sua redução em relação ao cenário base, cuja pressão média e perdas foram, respectivamente, de 46,23 m.c.a. e 49,43 %.

Tal como na rede T1, observa-se que o pior ponto foi o horário 67, devido a anomalia de previsão, e a Rede Neural de Previsão mostra-se, igualmente, com potencial para resultados ainda melhores, levando-se em consideração as ressalvas das subpressões no nó 15, relativas a bomba 2 e a anomalia do horário 67.

Observa-se também que a anomalia do horário 67 foi menos influente que na rede T1.

Assim, de um modo geral, as Redes Neurais de Previsão obtiveram previsões de parâmetros para as redes T1 e T2 que, a despeito de possuírem a mesma demanda, nós,

elementos e cotas, possuem arranjos diferentes de tubulações, sendo a T2 ligeiramente mais propensa a subpressões e a T1 mais propensa a excesso de pressão.

Na rede T1 e T2, ambas as bombas tiveram pontos fora da norma. Logo, o algoritmo deverá incorporar em aperfeiçoamentos futuros algum mecanismo que permita pequenas compensações dos parâmetros após a previsão, bem como a retroalimentação da Rede Neural com os novos parâmetros para bombas.

6. CONCLUSÕES

O objetivo deste trabalho foi a proposição de um algoritmo de otimização e operação de redes de distribuição de água utilizando algoritmos genéticos associados a redes neurais multicamadas do tipo *perceptron*, sendo uma rede voltada mais para a operação em um horário específico e outra mais voltada a previsão de parâmetros ao longo de uma série temporal.

Para tal, utilizaram-se ferramentas computacionais como o EPANET, bem como a sua *toolkit*, a linguagem de programação R e Python 3, as bibliotecas *rpy2*, *keras*, *tensorflow* (Python) e o pacote *epanet2toolkit* (R), sendo a sua aplicação em duas redes teóricas (T1 e T2) elaboradas de forma a atender os requisitos deste trabalho.

Assim, foram então criadas duas redes neurais: a Rede Neural de Operação, mais simples, que visava o controle das redes de distribuição de água recebendo apenas um horário de demandas, e a Rede Neural de Previsão, que recebia 72 horas de demandas e parâmetros ótimos para então realizar a previsão das próximas 24 horas da série de dados.

Os resultados para a Rede Neural de Operação atenderam a expectativa, pois mostrou-se capaz de aprender a operar, ainda que o nó 15 da rede T2 tenha ficado 0,5 m.c.a. abaixo do preconizado pela norma NBR 12218. Assim, este trabalho pôde então prosseguir com uma abordagem mais complexa de redes neurais, agora destinada a fazer a previsão para 24 horas a partir de um conjunto de dados de 72 horas de demandas e parâmetros.

Os resultados obtidos pela Rede Neural de Previsão atenderam o disposto na NBR 12218, ainda que na rede T1, o nó 14 tenha apresentado pressões acima da norma nos horários 49, 50 e 56, bem como no nó 15 houve pressão acima da norma no horário 58.

Já para a rede T2, foi registrada pressão acima da norma no nó 14 para o horário 60 e 66, bem como pressões abaixo da preconizada pela norma nos horários 56 e 57 no nó 15.

Observou-se também, tanto em T1 como em T2 uma anomalia no horário 67, com pressões substancialmente acima da média, sem, contudo, apresentar resultados fora do especificado pela norma.

Pode-se creditar tal fato a uma tentativa mais agressiva de ajuste das redes neurais, uma vez que os horários 19, 43 e 67 apresentavam as maiores demandas, levando a Rede Neural de Previsão a entender o horário de pico (19 horas dos dias 1, 2 e 3) como uma necessidade de maior pressurização da rede.

As pressões acima da média no horário 67 mostraram a necessidade de adotar um dispositivo no algoritmo que seja capaz de contornar os ajustes mais acentuados caso se mostrem desnecessários ou exagerados.

Portanto, as Redes Neurais de Previsão empregadas neste trabalho mostraram potencial para obter todos os resultados dentro da norma, e no caso das Redes Neurais de Operação, até mesmo um potencial futuro para elas próprias se tornarem otimizadoras de redes, com os devidos ajustes.

Logo, espera-se que em desenvolvimentos futuros as Redes Neurais de Previsão passem a ser integradas a Internet das Coisas, nas quais possuirão conexões sem fio com hidrômetros, manômetros e demais dispositivos que lhe alimentarão com dados em tempo real de demandas, vazões e pressões de redes de distribuição de água e, assim, passem, em um momento inicial, controlar pequenos distritos de medição e controle, melhorando assim sua eficiência e passando a aprender a operar conforme oscilações das demandas.

A capacidade de detecção de padrões pode auxiliar na manutenção preventiva da rede, apontando regiões suscetíveis a falha e até mesmo, se forem corretamente alimentadas com dados sobre os componentes da rede (material e data das tubulações por exemplo), prever futuras falhas permitindo o planejamento da substituição ou reparo de componentes de modo a minimizar-se os transtornos normalmente causados.

7. RECOMENDAÇÕES PARA TRABALHOS FUTUROS

Este trabalho deixa as seguintes recomendações para um aprimoramento das Redes Neurais de Operação:

- Realizar o cálculo do erro baseado somente nas pressões dos nós, e não na diferença dos parâmetros, de modo a se eliminar a necessidade dos resultados obtidos pelo Algoritmo Genético, tornando as Redes Neurais de Operação um dispositivo de otimização de operação por si só;
- Testes com outros parâmetros como Reservatórios de Nível Variável, outras válvulas, dentre outras configurações que permitam a Rede Neural de Operação atuar com outras redes de distribuição de água;
- Testes com parâmetros não envolvidos diretamente na operação, como comprimento, rugosidade e diâmetro de tubulações, com vistas a elaboração futura de uma Rede Neural de Projeto de redes hidráulicas ótimas;
- Elaborar uma futura configuração com as sugestões anteriormente mencionadas de forma a se obter uma futura Rede Neural de Obtenção de Estratégias Operacionais Ótimas baseada em demandas;
- Teste utilizando outros parâmetros como preditores ao invés das demandas.

Já para as Redes Neurais de Previsão, deixam-se as seguintes recomendações:

- Adição de um mecanismo de controle após a previsão dos parâmetros, de modo que se permitam pequenos ajustes para corrigir eventuais excessos ou faltas de pressão, permitindo também que os novos parâmetros passem a retroalimentar a Rede Neural de Previsão, para reforçar seu aprendizado;
- Testes com um conjunto de dados maiores, se possível com pelo menos uma semana (168 horas) de dados de demandas e parâmetros ótimos;
- Testes com novas configurações de disposições de neurônios nas camadas ocultas, bem como o uso de novas funções de ativação e mesmo o uso de diferentes funções de ativação por camada;

- Com um conjunto de dados maior, testar diferentes disposições dos conjuntos de treino, teste e validação, tomando por base o arranjo de 50% para treino, 20% para teste e 30% para validação;
- Testes utilizando outros preditores em conjunto com as demandas.

REFERÊNCIAS

AMARAL, Haroldo Luiz Moretti do. **Desenvolvimento de uma nova metodologia para previsão do consumo de energia elétrica de curto prazo utilizando redes neurais artificiais e decomposição de séries temporais**. 2020. 113 f. Universidade de São Paulo, 2020. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/3/3143/tde-07022020-113308/>>.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **ABNT NBR 12.218**: projeto de rede de distribuição de água para abastecimento público: procedimento. Rio de Janeiro: ABNT, 2017.

BAGRIYANIK, F.G.; SONMEZ, M.A.; BAGRIYANIK, M. The impact of mutual interaction between electric and water distribution systems via demand response. **Sustainable Energy, Grids and Networks**, v. 34, p. 101008, jun. 2023. Disponível em: <<https://doi.org/10.1016/j.segan.2023.101008>>.

BRASIL. **Panorama do Saneamento Básico do Brasil. SNIS**. [S.l.: s.n.], 2021. Disponível em: <<http://www.ufrgs.br/actavet/31-1/artigo552.pdf>>.

CARVALHO, Taís Maria Nunes; FILHO, Francisco de Assis de Souza; PORTO, Victor Costa. Urban Water Demand Modeling Using Machine Learning Techniques: Case Study of Fortaleza, Brazil. **Journal of Water Resources Planning and Management**, v. 147, n. 1, p. 05020026, jan. 2021. Disponível em: <<http://ascelibrary.org/doi/10.1061/%28ASCE%29WR.1943-5452.0001310>>.

CHINI, Christopher M.; STILLWELL, Ashlynn S. The State of U.S. Urban Water: Data and the Energy-Water Nexus. **Water Resources Research**, v. 54, n. 3, p. 1796–1811, 2018.

CORAGGIO, Elisa; HAN, Dawei; TRYFONAS, Theo. Chapter 22 - Smart cities and hydroinformatics. In: ESLAMIAN, Saeid; ESLAMIAN, Faezeh (Org.). **Handb. Hydroinformatics**. Elsevier, 2023. p. 341–355. Disponível em: <<https://www.sciencedirect.com/science/article/pii/B9780128219614000294>>.

COSTA, L. H.M.; RAMOS, H. M.; DE CASTRO, M. A.H. Hybrid genetic algorithm in the optimization of energy costs in water supply networks. **Water Science and Technology: Water Supply**, v. 10, n. 3, p. 315–326, 2010.

DAWIDOWICZ, Jacek. Evaluation of a pressure head and pressure zones in water distribution systems by artificial neural networks. **Neural Computing and Applications**, v. 30, n. 8, p. 2531–2538, 2018.

FILHO, Emânuel Guerra Barros et al. Intelligent system for control of water distribution networks. **Water Science and Technology: Water Supply**, v. 18, n. 4, p. 1270–1281, 2018.

FONTANA, Nicola; GIUGNI, Maurizio; PORTOLANO, Davide. Losses Reduction and Energy Production in Water-Distribution Networks. **Journal of Water Resources Planning and Management**, v. 138, n. 3, p. 237–244, 2012. Disponível em: <<http://ascelibrary.org/doi/10.1061/%28ASCE%29WR.1943-5452.0000179>>.

GIUSTOLISI, Orazio et al. Leakage Management Influence on Water Age of Water Distribution Networks. **Water Resources Research**, v. 59, n. 1, p. 1–18, 17 jan. 2023. Disponível em: <<https://onlinelibrary.wiley.com/doi/10.1029/2021WR031919>>.

GOOGLE. **Keras**. Disponível em: <<https://keras.io/>>. Acesso em: 30 jan. 2023.

GUPTA, Aditya Dinesh; KULAT, Kishore. Leakage reduction in water distribution system using efficient pressure management techniques. Case study: Nagpur, India. **Water Science and Technology: Water Supply**, v. 18, n. 6, p. 2015–2027, 2018.

GUPTA, Indrani; GUPTA, A; KHANNA, P. Genetic algorithm for optimization of water distribution systems. **Environmental Modelling & Software**, v. 14, n. 5, p. 437–446, mar. 1999. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S1364815298000899>>.

HU, Xuan et al. Novel leakage detection and water loss management of urban water supply network using multiscale neural networks. **Journal of Cleaner Production**, v. 278, p. 123611, 2021. Disponível em: <<https://doi.org/10.1016/j.jclepro.2020.123611>>.

KANAKOUDIS, Vasilis; MUHAMMETOGLU, Habib. Urban water pipe networks management towards non-revenue water reduction: Two case studies from Greece and Turkey. **Clean - Soil, Air, Water**, v. 42, n. 7, p. 880–892, 2014.

KHATAVKAR, Puneet; MAYS, Larry W. Optimization-simulation model for real-time pump and valve operation of water distribution systems under critical conditions. **Urban Water Journal**, v. 16, n. 1, p. 45–55, 2 jan. 2019. Disponível em: <<https://doi.org/10.1080/1573062X.2019.1634108>>.

LACERDA, Estefâne George Macedo; CARVALHO, André Carlos Ponce de Leon Ferreira. **Introdução aos Algoritmos Genéticos - Sistemas Inteligentes - Aplicações a Recursos Hídricos e Ciências Ambientais**. 1. ed. Porto Alegre: Editora da Universidade Federal do Rio Grande do Sul, 1999.

MAKAREMI, Yasaman; HAGHIGHI, Ali; GHAFOURI, Hamid Reza. Optimization of Pump Scheduling Program in Water Supply Systems Using a Self-Adaptive NSGA-II; a Review of Theory to Real Application. **Water Resources Management**, v. 31, n. 4, p. 1283–1304, 2017.

MAKISHA, Nikolay; KAZIMIROVA, Tatiana. Principles of energy saving in water supply and sewage systems. v. 04013, p. 1–6, 2018.

MARCHI, Angela; SIMPSON, Angus R.; LAMBERT, Martin F. Optimization of Pump Operation Using Rule-Based Controls in EPANET2: New ETTAR Toolkit and Correction of Energy Computation. **Journal of Water Resources Planning and Management**, v. 142, n. 7, p. 1–11, jul. 2016. Disponível em: <<https://ascelibrary.org/doi/10.1061/%28ASCE%29WR.1943-5452.0000637>>.

MONSEF, H. et al. Pressure management in water distribution systems in order to reduce energy consumption and background leakage. **Journal of Water Supply: Research and Technology - Aqua**, v. 67, n. 4, p. 397–403, jun. 2018. Disponível em: <<https://iwaponline.com/aqua/article/67/4/397-403/38998>>.

MUTIKANGA, HE; SHARMA, Saroj K.; VAIRAVAMOORTHY, Kalanithy. Methods and tools for managing losses in water distribution systems. **Journal of Water Resources Planning and management**, v. 139, n. April, p. 166–174, 2013. Disponível em: <[http://ascelibrary.org/doi/abs/10.1061/\(ASCE\)WR.1943-5452.0000245](http://ascelibrary.org/doi/abs/10.1061/(ASCE)WR.1943-5452.0000245)>.

NERANTZIS, Dimitrios; PECCI, Filippo; STOIANOV, Ivan. Optimal control of water distribution networks without storage. **European Journal of Operational Research**, v. 284, n. 1, p. 345–354, 2020. Disponível em: <<https://doi.org/10.1016/j.ejor.2019.12.011>>.

OUGUI, Jorge Yutaka. **Estudo da operação otimizada de sistema de bombeamento de água**. 2003. 145 f. Universidade de São Paulo, 2003.

PINNTO, Marcos Rodrigues et al. Dimensionamento econômico otimizado de redes de distribuição de água considerando custos de manutenção. **Engenharia Sanitaria e Ambiental**, v. 22, n. 1, p. 145–153, 2016. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1413-41522017000100145&lng=pt&tlng=pt>.

PORTO, Rodrigo de Melo. **Hidráulica Básica**. 4. ed. São Carlos: EESC/USP, 2006.

PREDESCU, Alexandru et al. An Advanced Learning-Based Multiple Model Control Supervisor for Pumping Stations in a Smart Water Distribution System. **Mathematics**, v. 8, n. 6, p. 887, 1 jun. 2020. Disponível em: <<https://www.mdpi.com/2227-7390/8/6/887>>.

PUGLIESE, Francesco; GIUGNI, Maurizio. An Operative Framework for the Optimal Selection of Centrifugal Pumps As Turbines (PATs) in Water Distribution Networks (WDNs). **Water (Switzerland)**, v. 14, n. 11, 2022.

SANTOS, Haline Costa dos. **APLICAÇÃO DE MÉTODOS DE OTIMIZAÇÃO PARA OPERAÇÃO DE REDES DE DISTRIBUIÇÃO DE ÁGUA: Uma Revisão Sistemática da Literatura**. 2021. 80 f. Universidade Federal de Itajubá, 2021.

SAVIC, Dragan A.; WALTERS, Godfrey A. Genetic Algorithms for Least-Cost Design of Water. **Journal of Water Resources Planning and Management**, v. 123, n. 2, p. 67–77, 1997.

SCACCIA, Kevin. **Validação Cruzada Aninhada com Scikit-learn**. Disponível em: <<https://dataml.com.br/validacao-cruzada-aninhada-com-scikit-learn/>>.

SILVA, Alex Takeo Yasumura Lima et al. Proposal of optimal operation strategy applied to water distribution network with statistical approach. **Revista Ambiente e Agua**, v. 15, n. 2, p. 10, 2020.

SILVA, Daniel Henrique Cordeiro; ALVES, Vladmir Kronemberger; SAVIO, Ernandes. Redes neurais artificiais aplicadas à moagem de minério de ferro combinadas a modelos empíricos. **Research, Society and Development**, v. 11, n. 13, p. e84111332329, 2 out. 2022. Disponível em: <<https://rsdjournal.org/index.php/rsd/article/view/32329>>.

SIMONE, Antonietta et al. Centrality metrics for Water Distribution Networks. n. July, p. 1–8, 2018.

SIVAKUMAR, P.; PRASAD, R. K.; CHANDRAMOULI, S. Uncertainty Analysis of Looped Water Distribution Networks Using Linked EPANET-GA Method. **Water Resources Management**, v. 30, n. 1, p. 331–358, 2016. Disponível em: <<http://dx.doi.org/10.1007/s11269-015-1165-x>>.

SNIDER, Brett; MCBEAN, Edward A. Improving Urban Water Security through Pipe-Break Prediction Models: Machine Learning or Survival Analysis. **Journal of Environmental Engineering**, v. 146, n. 3, p. 04019129, mar. 2020. Disponível em: <<http://ascelibrary.org/doi/10.1061/%28ASCE%29EE.1943-7870.0001657>>.

T. TUCCIARELLI; A. CRIMINISI; TERMINI, D. Leak Analysis in Pipeline Systems by Means of Optimal Valve Regulation. n. March, p. 277–285, 1999.

TANYIMBOH, T T; SEYOUM, A G. Efficient parallel evolutionary optimization algorithm applied to a water distribution system. n. c, p. 375–381, 2017.

TSUTIYA, Milton Tomoyuki. **Abastecimento de Água**. 3. ed. São Paulo: Departamento de Engenharia Hidráulica e Sanitária da Escola Politécnica da Universidade de São Paulo - USP, 2006a.

TSUTIYA, Milton Tomoyuki. **Redução do Custo de Energia Elétrica em Sistemas de Abastecimento de Água**. 1. ed. São Paulo: Associação Brasileira de Engenharia Sanitária e Ambiental - ABES, 2006b.

VAN DIJK, M; . Optimising water distribution systems using a weighted penalty in a genetic algorithm. **Water SA**, v. 34, n. 5, p. 537, 7 dez. 2018. Disponível em: <<https://www.ajol.info/index.php/wsa/article/view/180651>>.

VAN ZYL, Jakobus E.; SAVIC, Dragan A.; WALTERS, Godfrey A. Operational Optimization of Water Distribution Systems Using a Hybrid Genetic Algorithm. **Journal of Water Resources Planning and Management**, v. 130, n. 2, p. 160–170, 2004.

XING, Lu; SELA, Lina. Graph Neural Networks for State Estimation in Water Distribution Systems: Application of Supervised and Semisupervised Learning. **Journal of Water Resources Planning and Management**, v. 148, n. 5, p. 1–14, maio 2022. Disponível em: <<https://ascelibrary.org/doi/10.1061/%28ASCE%29WR.1943-5452.0001550>>.

ANEXO I

Tabela 1 – Demandas utilizadas na RNA de previsão.

HORAS	ID3	ID4	ID5	ID6	ID7	ID8	ID9	ID10	ID11	ID12	ID13	ID14	ID15
0	0,15	0,15	0,3	0,15	0,3	0,45	0,3	0,15	0,15	0,15	0,15	0,3	0,45
1	0,1	0,1	0,2	0,1	0,2	0,3	0,2	0,1	0,1	0,1	0,1	0,2	0,3
2	0,1	0,1	0,2	0,1	0,2	0,3	0,2	0,1	0,1	0,1	0,1	0,2	0,3
3	0,2	0,2	0,4	0,2	0,4	0,6	0,4	0,2	0,2	0,2	0,2	0,4	0,6
4	0,25	0,25	0,5	0,25	0,5	0,75	0,5	0,25	0,25	0,25	0,25	0,5	0,75
5	0,3	0,3	0,6	0,3	0,6	0,9	0,6	0,3	0,3	0,3	0,3	0,6	0,9
6	0,4	0,4	0,8	0,4	0,8	1,2	0,8	0,4	0,4	0,4	0,4	0,8	1,2
7	0,5	0,5	1	0,5	1	1,5	1	0,5	0,5	0,5	0,5	1	1,5
8	0,6	0,6	1,2	0,6	1,2	1,8	1,2	0,6	0,6	0,6	0,6	1,2	1,8
9	0,8	0,8	1,6	0,8	1,6	2,4	1,6	0,8	0,8	0,8	0,8	1,6	2,4
10	1	1	2	1	2	3	2	1	1	1	1	2	3
11	1,6	1,6	3,2	1,6	3,2	4,8	3,2	1,6	1,6	1,6	1,6	3,2	4,8
12	1,8	1,8	3,6	1,8	3,6	5,4	3,6	1,8	1,8	1,8	1,8	3,6	5,4
13	1,4	1,4	2,8	1,4	2,8	4,2	2,8	1,4	1,4	1,4	1,4	2,8	4,2
14	0,9	0,9	1,8	0,9	1,8	2,7	1,8	0,9	0,9	0,9	0,9	1,8	2,7
15	0,4	0,4	0,8	0,4	0,8	1,2	0,8	0,4	0,4	0,4	0,4	0,8	1,2
16	0,3	0,3	0,6	0,3	0,6	0,9	0,6	0,3	0,3	0,3	0,3	0,6	0,9
17	0,95	0,95	1,9	0,95	1,9	2,85	1,9	0,95	0,95	0,95	0,95	1,9	2,85
18	1,7	1,7	3,4	1,7	3,4	5,1	3,4	1,7	1,7	1,7	1,7	3,4	5,1
19	1,9	1,9	3,8	1,9	3,8	5,7	3,8	1,9	1,9	1,9	1,9	3,8	5,7
20	1,4	1,4	2,8	1,4	2,8	4,2	2,8	1,4	1,4	1,4	1,4	2,8	4,2
21	0,85	0,85	1,7	0,85	1,7	2,55	1,7	0,85	0,85	0,85	0,85	1,7	2,55
22	0,35	0,35	0,7	0,35	0,7	1,05	0,7	0,35	0,35	0,35	0,35	0,7	1,05
23	0,2	0,2	0,4	0,2	0,4	0,6	0,4	0,2	0,2	0,2	0,2	0,4	0,6
24	0,14	0,14	0,28	0,14	0,28	0,42	0,28	0,14	0,14	0,14	0,14	0,28	0,42
25	0,11	0,11	0,22	0,11	0,22	0,33	0,22	0,11	0,11	0,11	0,11	0,22	0,33
26	0,09	0,09	0,18	0,09	0,18	0,27	0,18	0,09	0,09	0,09	0,09	0,18	0,27
27	0,19	0,19	0,38	0,19	0,38	0,57	0,38	0,19	0,19	0,19	0,19	0,38	0,57
28	0,23	0,23	0,46	0,23	0,46	0,69	0,46	0,23	0,23	0,23	0,23	0,46	0,69
29	0,28	0,28	0,56	0,28	0,56	0,84	0,56	0,28	0,28	0,28	0,28	0,56	0,84
30	0,39	0,39	0,78	0,39	0,78	1,17	0,78	0,39	0,39	0,39	0,39	0,78	1,17
31	0,51	0,51	1,02	0,51	1,02	1,53	1,02	0,51	0,51	0,51	0,51	1,02	1,53
32	0,65	0,65	1,3	0,65	1,3	1,95	1,3	0,65	0,65	0,65	0,65	1,3	1,95
33	0,88	0,88	1,76	0,88	1,76	2,64	1,76	0,88	0,88	0,88	0,88	1,76	2,64
34	1	1	2	1	2	3	2	1	1	1	1	2	3
35	1,57	1,57	3,14	1,57	3,14	4,71	3,14	1,57	1,57	1,57	1,57	3,14	4,71
36	1,78	1,78	3,56	1,78	3,56	5,34	3,56	1,78	1,78	1,78	1,78	3,56	5,34
37	1,41	1,41	2,82	1,41	2,82	4,23	2,82	1,41	1,41	1,41	1,41	2,82	4,23
38	0,95	0,95	1,9	0,95	1,9	2,85	1,9	0,95	0,95	0,95	0,95	1,9	2,85
39	0,44	0,44	0,88	0,44	0,88	1,32	0,88	0,44	0,44	0,44	0,44	0,88	1,32
40	0,32	0,32	0,64	0,32	0,64	0,96	0,64	0,32	0,32	0,32	0,32	0,64	0,96

41	0,9	0,9	1,8	0,9	1,8	2,7	1,8	0,9	0,9	0,9	0,9	1,8	2,7
42	1,65	1,65	3,3	1,65	3,3	4,95	3,3	1,65	1,65	1,65	1,65	3,3	4,95
43	1,91	1,91	3,82	1,91	3,82	5,73	3,82	1,91	1,91	1,91	1,91	3,82	5,73
44	1,41	1,41	2,82	1,41	2,82	4,23	2,82	1,41	1,41	1,41	1,41	2,82	4,23
45	0,83	0,83	1,66	0,83	1,66	2,49	1,66	0,83	0,83	0,83	0,83	1,66	2,49
46	0,33	0,33	0,66	0,33	0,66	0,99	0,66	0,33	0,33	0,33	0,33	0,66	0,99
47	0,21	0,21	0,42	0,21	0,42	0,63	0,42	0,21	0,21	0,21	0,21	0,42	0,63
48	0,14	0,14	0,28	0,14	0,28	0,42	0,28	0,14	0,14	0,14	0,14	0,28	0,42
49	0,09	0,09	0,18	0,09	0,18	0,27	0,18	0,09	0,09	0,09	0,09	0,18	0,27
50	0,09	0,09	0,18	0,09	0,18	0,27	0,18	0,09	0,09	0,09	0,09	0,18	0,27
51	0,19	0,19	0,38	0,19	0,38	0,57	0,38	0,19	0,19	0,19	0,19	0,38	0,57
52	0,21	0,21	0,42	0,21	0,42	0,63	0,42	0,21	0,21	0,21	0,21	0,42	0,63
53	0,31	0,31	0,62	0,31	0,62	0,93	0,62	0,31	0,31	0,31	0,31	0,62	0,93
54	0,39	0,39	0,78	0,39	0,78	1,17	0,78	0,39	0,39	0,39	0,39	0,78	1,17
55	0,49	0,49	0,98	0,49	0,98	1,47	0,98	0,49	0,49	0,49	0,49	0,98	1,47
56	0,59	0,59	1,18	0,59	1,18	1,77	1,18	0,59	0,59	0,59	0,59	1,18	1,77
57	0,81	0,81	1,62	0,81	1,62	2,43	1,62	0,81	0,81	0,81	0,81	1,62	2,43
58	1	1	2	1	2	3	2	1	1	1	1	2	3
59	1,61	1,61	3,22	1,61	3,22	4,83	3,22	1,61	1,61	1,61	1,61	3,22	4,83
60	1,78	1,78	3,56	1,78	3,56	5,34	3,56	1,78	1,78	1,78	1,78	3,56	5,34
61	1,39	1,39	2,78	1,39	2,78	4,17	2,78	1,39	1,39	1,39	1,39	2,78	4,17
62	0,89	0,89	1,78	0,89	1,78	2,67	1,78	0,89	0,89	0,89	0,89	1,78	2,67
63	0,37	0,37	0,74	0,37	0,74	1,11	0,74	0,37	0,37	0,37	0,37	0,74	1,11
64	0,28	0,28	0,56	0,28	0,56	0,84	0,56	0,28	0,28	0,28	0,28	0,56	0,84
65	0,96	0,96	1,92	0,96	1,92	2,88	1,92	0,96	0,96	0,96	0,96	1,92	2,88
66	1,71	1,71	3,42	1,71	3,42	5,13	3,42	1,71	1,71	1,71	1,71	3,42	5,13
67	1,95	1,95	3,9	1,95	3,9	5,85	3,9	1,95	1,95	1,95	1,95	3,9	5,85
68	1,38	1,38	2,76	1,38	2,76	4,14	2,76	1,38	1,38	1,38	1,38	2,76	4,14
69	0,86	0,86	1,72	0,86	1,72	2,58	1,72	0,86	0,86	0,86	0,86	1,72	2,58
70	0,33	0,33	0,66	0,33	0,66	0,99	0,66	0,33	0,33	0,33	0,33	0,66	0,99
71	0,19	0,19	0,38	0,19	0,38	0,57	0,38	0,19	0,19	0,19	0,19	0,38	0,57

Fonte: O autor.

ANEXO II

Tabela 2 - Parâmetros da rede T1.

HORAS	RNF1	RNF2	BOMBA1	BOMBA2	VALVULA1	VALVULA2	VALVULA3
0	857,5069	842,3598	1,429777	1,427071	26,89599	10,97097	19,52648
1	856,5327	839,826	1,596495	1,382626	21,9065	46,28178	0,921687
2	856,5327	839,826	1,596495	1,382626	21,9065	46,28178	0,921687
3	859,7089	840,8732	1,428483	1,424214	6,726048	29,32947	12,14273
4	856,6666	842,7546	1,485498	1,359915	11,53783	14,26492	4,559414
5	859,2581	841,3315	1,314141	1,453412	45,93937	15,06098	37,01432
6	857,4918	841,4963	1,515846	1,392398	26,47708	23,69064	0,972973
7	862,2952	840,8261	1,287008	1,503765	8,900359	35,92584	34,75858
8	856,8103	840,0765	1,589517	1,513267	23,98691	2,890986	42,99701
9	859,0227	842,8109	1,390041	1,349522	38,90409	43,13035	37,83644
10	858,6891	840,6631	1,350533	1,627547	1,307958	8,207648	28,06672
11	860,7018	840,6261	1,36587	1,386819	3,520147	17,84276	31,31626
12	859,2477	841,3761	1,418284	1,387947	11,0677	33,65472	24,04414
13	858,2898	843,1196	1,342022	1,463613	15,42329	47,32617	24,84759
14	859,3793	842,217	1,344514	1,364139	39,79272	27,25368	48,23718
15	861,7075	839,643	1,37795	1,447345	48,29379	32,75499	11,40562
16	862,3678	842,3405	1,340578	1,345297	28,99044	33,3304	29,67589
17	861,3623	840,0995	1,414798	1,385045	12,428	48,59427	0,767874
18	862,014	843,0114	1,275146	1,478913	35,25146	17,57515	38,77996
19	863,0357	840,3231	1,342897	1,357771	49,13802	25,62229	10,24223
20	861,7069	842,2242	1,389119	1,378485	33,44537	27,04876	11,95668
21	868,2145	841,6003	1,214815	1,258788	17,15685	2,642793	12,16711
22	858,5172	839,9654	1,485009	1,584965	47,13524	26,55525	25,79834
23	860,346	844,5974	1,292938	1,330019	31,69326	3,30643	18,17198
24	859,0642	842,5363	1,368455	1,356629	28,0587	44,1797	35,07081
25	857,5777	842,8376	1,295218	1,339155	31,49374	6,297521	38,45669
26	860,1493	840,6273	1,500869	1,41995	4,819573	45,79752	28,64804
27	859,9443	839,4105	1,439047	1,531841	46,55973	10,98468	40,46862
28	857,3628	839,4904	1,323009	1,377215	24,74623	35,10154	27,72004
29	859,719	840,6444	1,552169	1,351474	48,52212	15,85715	34,59476
30	856,8888	840,0349	1,533286	1,473295	31,26175	0,104761	37,21569
31	862,5801	842,9936	1,304762	1,315714	29,29256	19,51407	16,59851
32	858,3538	841,1315	1,349328	1,424954	7,078754	36,11706	22,95433
33	857,5078	842,9708	1,332038	1,405944	34,16444	11,85448	26,45586
34	865,5459	840,3436	1,307455	1,307551	32,92941	32,89955	18,21489
35	859,569	841,8648	1,458688	1,404875	34,57118	24,02223	0,762496
36	871,374	840,5475	1,315315	1,327758	21,00278	22,75298	9,865769
37	857,7016	841,0613	1,445115	1,511823	19,24358	7,611877	18,45311
38	858,1321	841,7941	1,352836	1,362448	35,04562	1,549309	38,85541
39	859,0974	839,8043	1,345863	1,468067	8,049374	12,31479	22,87663

40	858,1873	841,9173	1,296515	1,408899	46,12384	32,95421	14,42607
41	857,9145	841,6222	1,349646	1,664287	16,80646	24,39923	10,83776
42	861,8423	841,8643	1,337288	1,499704	18,51122	22,75358	4,427255
43	858,2614	841,4998	1,314072	1,415843	40,68787	21,58485	30,16651
44	864,2283	842,4518	1,251799	1,34503	26,98467	23,77592	2,665711
45	858,869	842,2008	1,299929	1,481866	18,54078	15,05971	20,90597
46	856,925	839,8792	1,355203	1,350321	13,25848	47,53133	47,15316
47	857,7265	842,6691	1,302834	1,537911	36,13148	8,715081	28,21961
48	860,2087	843,7035	1,276256	1,344007	6,885387	1,703331	13,12663
49	858,4232	839,9597	1,578238	1,386127	30,20922	15,75082	22,34043
50	858,4232	839,9597	1,578238	1,386127	30,20922	15,75082	22,34043
51	856,9102	839,4652	1,541766	1,518874	22,21115	41,99264	34,84961
52	857,0212	839,4758	1,514917	1,412789	9,415432	14,51967	40,1382
53	857,4897	840,3946	1,439117	1,352433	43,13739	22,75044	32,93641
54	857,3506	841,0293	1,340095	1,354129	22,44001	31,18837	22,23756
55	856,4552	843,4496	1,454478	1,429746	13,82168	0,49234	17,5568
56	866,2455	841,3886	1,238336	1,279737	36,30468	24,87254	38,52159
57	858,5584	841,5184	1,422491	1,351165	25,41451	45,68139	31,40642
58	868,111	841,5724	1,285961	1,304565	13,86939	45,15661	1,994145
59	859,8072	842,2806	1,364069	1,382627	8,320663	32,45108	15,02751
60	860,0662	844,3684	1,358048	1,378543	5,829592	36,74632	38,32674
61	864,8487	842,308	1,300093	1,365785	21,59728	17,64444	32,1084
62	859,9284	843,6099	1,360993	1,354018	1,777476	26,89896	34,35058
63	858,8084	839,9136	1,335257	1,541375	10,47019	1,644437	14,92757
64	860,6237	839,9707	1,281136	1,448484	24,74155	41,41578	28,01352
65	859,8519	841,1269	1,409816	1,393569	22,50002	23,42788	27,89908
66	868,5047	840,2279	1,237168	1,318122	10,72614	21,87859	0,92984
67	859,6278	843,7023	1,378893	1,541733	22,6777	21,13116	8,131329
68	858,8644	842,3523	1,322119	1,414576	16,87915	13,40461	18,23744
69	863,7416	841,4302	1,392451	1,404382	38,50258	2,373857	45,4598
70	856,8205	842,1762	1,326358	1,514759	20,82803	6,234916	26,10304
71	858,6471	841,7085	1,374357	1,502472	13,62878	23,72923	11,25685

Fonte: O autor.

ANEXO III

Tabela 11 - Resultados dos parâmetros previstos para a segunda rodada da rede T1.

HORAS (DIA)	HORAS (PREVISÃO)	RNF1	RNF2	BOMBA1	BOMBA2	VALVULA1	VALVULA2	VALVULA3
48	0	858,8865000	841,8921500	1,4153875	1,4777513	27,3034780	11,3150660	19,8436450
49	1	858,8078000	839,8274000	1,6486486	1,4921395	22,0859490	46,2883800	1,1058234
50	2	858,8078000	839,8274000	1,6486486	1,4921395	22,0859490	46,2883800	1,1058234
51	3	858,9652000	843,0036000	1,3435350	1,3815546	20,0018120	16,6024740	14,9864290
52	4	858,9966400	843,1161000	1,3624542	1,3910683	18,6846160	15,6053980	14,2954560
53	5	859,1540500	841,9153000	1,3829690	1,4761776	39,7904360	25,5851060	32,0900500
54	6	859,2800000	841,1401000	1,4575840	1,4890023	39,2376630	27,4165250	6,2140346
55	7	859,4372600	840,9280000	1,3496639	1,6384801	9,3191820	36,9381980	34,1117500
56	8	859,5947000	840,6980600	1,6213511	1,6079004	22,4745770	2,9784410	42,9721200
57	9	859,9409000	842,9964600	1,3507248	1,4463209	36,8513400	40,9109080	37,4694750
58	10	860,2400500	841,2074000	1,4595991	1,6906993	1,1198809	8,0986080	28,3570120
59	11	861,2001300	842,9249000	1,4601308	1,3685147	3,0464547	18,3096310	31,4580060
60	12	861,4676500	842,7515000	1,5020629	1,4219395	13,3928550	32,6142850	24,3771690
61	13	860,8538000	843,2701000	1,4758197	1,4893011	24,3621200	37,3783800	17,8747770
62	14	860,0668300	842,4206000	1,3553177	1,4040174	37,8359300	25,3952520	47,3435480
63	15	859,2485400	841,1780400	1,4242436	1,5682140	43,5608520	27,5208680	17,8342200
64	16	859,1068000	842,4344000	1,4035121	1,5162600	29,3720700	20,2690810	27,0573560
65	17	860,1770000	841,5127600	1,4565936	1,5186820	10,2670765	45,0545960	1,9483739
66	18	861,3574000	843,5191700	1,3729116	1,4358116	34,9113900	18,0633430	38,9946700
67	19	874,1356000	851,1210300	1,4556466	1,3237818	53,0840570	25,8298130	10,8809100
68	20	860,8381300	843,2110600	1,4734622	1,5325328	24,2904530	37,3143920	17,7130340
69	21	860,0196500	842,6365000	1,3054725	1,3393744	21,1663130	6,0830936	14,9592330
70	22	859,1855500	841,5690000	1,3620754	1,5829757	44,4208300	26,8592760	28,4131240
71	23	858,9652000	843,0036000	1,3435350	1,3815546	20,0018120	16,6024740	14,9864290

Fonte: O autor.

ANEXO IV

Tabela 4 - Parâmetros da rede T2 obtidos pelo AG.

HORAS	RNF1	RNF2	BOMBA1	BOMBA2	VALVULA1	VALVULA2	VALVULA3
0	858,6126	853,6415	1,470896	1,416139	10,36166	18,81698	15,11636
1	857,2327	843,8277	1,406985	1,411186	25,30607	43,24067	22,88102
2	857,2327	843,8277	1,406985	1,411186	25,30607	43,24067	22,88102
3	865,1686	841,4658	1,3107	1,338368	21,09516	15,63209	14,0817
4	861,6925	839,6488	1,361492	1,527769	41,1549	44,36418	27,20062
5	860,7969	843,5135	1,387564	1,348187	46,22151	19,87153	20,38952
6	865,846	838,9283	1,544789	1,405319	23,00035	10,66892	17,38577
7	857,0442	853,1672	1,506829	1,526509	19,12958	10,05302	12,33887
8	861,8726	839,0378	1,533175	1,377664	43,11053	19,4461	23,7246
9	867,9428	840,1576	1,418844	1,344031	45,52225	19,69844	15,97306
10	855,6203	854,8097	1,518027	1,359314	11,9327	22,7976	19,04925
11	860,8547	841,9269	1,38118	1,436991	13,11844	39,60632	25,31343
12	857,5415	854,119	1,55404	1,426874	16,913	13,66758	12,90008
13	862,9899	843,7365	1,482347	1,376115	24,59655	12,6467	17,44167
14	862,2856	845,674	1,330125	1,451329	19,03593	17,89383	12,58705
15	859,4585	840,6598	1,412964	1,379622	34,91055	26,72825	12,98529
16	864,0269	840,6358	1,36056	1,460875	23,53546	10,24461	20,06665
17	859,3046	843,6978	1,455095	1,574246	22,16194	10,56506	19,24371
18	860,7894	853,8558	1,53454	1,529017	15,12064	11,36006	10,58254
19	868,3572	843,0164	1,475316	1,379265	16,00514	27,12863	16,36361
20	877,1255	840,5913	1,432608	1,334594	12,12798	11,4068	11,60321
21	860,7466	843,1158	1,30531	1,372567	24,79671	42,67499	33,90851
22	864,0997	839,787	1,282015	1,49823	28,2554	12,85658	33,95373
23	857,6797	843,8844	1,417171	1,399773	33,41813	41,24332	11,74089
24	866,3985	845,2398	1,27034	1,346735	13,28865	14,25903	11,08727
25	859,4266	850,3648	1,30645	1,539579	11,07729	12,33821	11,97509
26	875,2082	848,5396	1,173283	1,332294	12,1826	21,78776	16,16389
27	861,1076	840,0453	1,376326	1,468278	46,4046	40,78867	16,59518
28	858,4564	838,8451	1,51609	1,534158	12,32684	40,08329	17,32394
29	867,6765	838,9059	1,356628	1,514923	13,43	22,76359	21,63688
30	867,53	839,7924	1,327455	1,47864	33,43332	11,09067	11,14704
31	858,8965	841,803	1,463872	1,510111	19,76939	13,0653	22,24917
32	858,9499	845,7842	1,335706	1,451214	21,59531	15,51721	24,14322
33	858,8145	845,8267	1,392223	1,449895	27,27213	49,19332	15,83684
34	859,1611	845,3507	1,516309	1,607942	30,18627	40,88493	12,1753
35	862,7866	843,6691	1,617836	1,478209	14,25731	12,72691	28,5416
36	872,3289	846,6776	1,295707	1,444827	27,20266	10,00778	17,85395
37	858,7441	848,1905	1,54003	1,623001	21,65253	11,02651	11,63033
38	862,9115	853,5843	1,309003	1,381538	10,70148	14,5423	16,26355
39	872,2542	840,4637	1,286894	1,327165	10,76151	29,69463	17,94326

40	861,4755	840,7043	1,41713	1,480308	47,90529	26,28393	14,06137
41	865,1519	840,7516	1,298606	1,492413	42,08484	11,6372	18,473
42	866,3477	839,5385	1,496849	1,483234	10,04198	22,42885	10,32414
43	868,5818	840,3534	1,348275	1,362548	12,51828	32,7693	12,24347
44	864,129	843,915	1,410273	1,375219	24,04266	20,05183	25,28333
45	865,4673	845,3266	1,316826	1,371799	25,14537	21,96244	10,74832
46	864,0049	841,9281	1,27025	1,393357	12,48434	48,13875	16,97811
47	861,6926	848,0808	1,278454	1,337083	47,85884	36,63333	10,48914
48	857,3652	843,1352	1,41921	1,59683	15,27786	28,94086	26,34765
49	856,4195	860,3239	1,308139	1,426893	23,25879	16,76017	11,8197
50	856,4195	860,3239	1,308139	1,426893	23,25879	16,76017	11,8197
51	858,4728	843,5992	1,336072	1,429179	25,9419	11,14746	18,89575
52	855,4827	853,8981	1,408575	1,366824	24,72154	26,8769	17,83868
53	865,952	848,3428	1,336315	1,321231	17,66395	31,70636	11,59628
54	859,6381	847,8064	1,2906	1,55615	22,72989	31,06921	10,10225
55	866,5185	841,7984	1,304958	1,425458	21,87862	24,94767	27,37424
56	859,5793	844,4489	1,344522	1,362077	10,86148	18,18796	13,48023
57	867,1792	841,8332	1,313877	1,412507	46,93699	22,42292	11,21142
58	861,7366	840,7167	1,630987	1,425555	23,30915	40,6677	20,71415
59	862,249	839,7843	1,417275	1,45734	11,01579	24,88282	22,21229
60	860,0527	847,9534	1,374117	1,420769	38,73654	10,54699	16,05709
61	863,4455	840,3451	1,451816	1,61945	22,73725	10,26199	33,10603
62	858,978	842,3516	1,465855	1,468818	16,26636	27,75117	20,53821
63	869,7693	839,7038	1,235341	1,489595	24,79799	10,08299	18,2448
64	867,1119	842,7659	1,365369	1,54217	11,26588	39,07071	11,8284
65	865,7104	839,6946	1,498202	1,350074	31,288	20,22641	17,15641
66	869,933	843,9106	1,318867	1,554281	36,48075	19,27167	10,73654
67	862,1772	840,4796	1,402788	1,633441	27,00875	29,46472	11,28374
68	865,4158	850,6343	1,292277	1,437243	10,12211	15,49769	13,76603
69	856,3943	859,8472	1,410503	1,48836	30,1416	11,04931	15,22671
70	863,9722	847,2463	1,330693	1,430718	36,89245	12,67781	10,32264
71	861,1299	838,987	1,315323	1,611572	34,98305	28,27127	10,7951

Fonte: O autor.

ANEXO V

Tabela 5 - Parâmetros previstos para as últimas 24 horas da rede T2.

HORAS (DIA)	HORAS (PREVISÃO)	RNF1	RNF2	BOMBA1	BOMBA2	VALVULA1	VALVULA2	VALVULA3
48	0	860,3159000	849,6526000	1,4484069	1,3795185	11,6288150	20,7532020	15,8320010
49	1	858,4449000	845,2157000	1,4199507	1,3624790	26,4192800	43,9470100	23,3085960
50	2	858,4449000	845,2157000	1,4199507	1,3624790	26,4192800	43,9470100	23,3085960
51	3	861,1918300	845,7859500	1,4051445	1,3506962	23,3054600	28,7923150	12,9200960
52	4	861,2076000	842,7606000	1,3185050	1,4276250	30,1111180	27,7273300	13,2094170
53	5	861,2864000	841,6160000	1,3907807	1,4021864	33,7329980	14,8411100	21,4067210
54	6	861,3493700	842,4248000	1,4356377	1,3857363	29,2959520	18,2288820	15,1161230
55	7	861,4281600	843,4358500	1,5147562	1,4677639	19,9938010	10,5725565	12,4484020
56	8	861,5070000	844,4468400	1,5778892	1,3345678	41,8260000	19,1790450	23,7706010
57	9	861,6803000	846,6711400	1,4117174	1,3118562	45,1138080	19,9595490	16,0135630
58	10	861,8299600	848,5921600	1,5265999	1,3528842	12,0805040	22,7083300	19,0182250
59	11	862,3106700	846,0091600	1,4292513	1,4519386	13,1047680	39,3243370	25,4126430
60	12	862,4446000	857,8460700	1,6059995	1,5339749	17,0121860	12,7604810	12,6141310
61	13	862,1372000	844,4728000	1,5182820	1,3734791	18,3867660	11,7680890	14,5747790
62	14	861,7433000	847,4798600	1,3303032	1,4194862	18,6131630	20,2526320	12,8272380
63	15	861,3337000	842,2226600	1,4072387	1,4320836	28,7820050	15,5933220	24,5390320
64	16	861,2628000	841,3126000	1,3785789	1,4144626	36,9958100	21,6367170	21,0790330
65	17	861,7984600	848,1875600	1,4772612	1,5860353	22,0696350	10,4718480	19,3914000
66	18	862,3894000	857,3592500	1,6101110	1,5614337	15,4148770	11,1039220	10,7539200
67	19	877,7953000	851,6704000	1,5752159	1,3878129	16,4345130	27,7554320	16,8994030
68	20	862,1293300	844,5796500	1,5188267	1,3888258	18,3328840	11,7702700	14,6394430
69	21	861,7196700	847,1767000	1,3564308	1,3826878	24,2158580	42,2807120	33,6645930
70	22	861,3021000	841,8182400	1,4171374	1,4622408	30,5192950	13,3732510	29,7373750
71	23	861,1918300	845,7859500	1,4051445	1,3506962	23,3054600	28,7923150	12,9200960

Fonte: O autor.