

USO DE INTELIGÊNCIA ARTIFICIAL PARA PREVER O CONSUMO DE ÁGUA À CURTO PRAZO DE UMA REGIÃO RESIDENCIAL DA CIDADE DE PATO BRANCO-PR

Viviane Cristhyne Bini Conte

Professora da Universidade Tecnológica Federal do Paraná – Câmpus Apucarana.
vivianeconte@utfpr.edu.br

Paula Fernanda Vieira Gomes

Doutoranda do Programa de Pós Graduação em Métodos Numéricos em Engenharia na Universidade
Federal do Paraná.
paulafernandagv@gmail.com

Andrea Sartori Jabur

Professora da Universidade Tecnológica Federal do Paraná – Câmpus Apucarana.
jabur@utfpr.edu.br

Luciana de Souza Moraes.

Professora da Universidade Tecnológica Federal do Paraná – Câmpus Apucarana
lucianamoraes@utfpr.edu.br

Diony José Almeida

Professor do Instituto Federal do Paraná – Câmpus Telemaco Borba.
diony.a@gmail.com

RESUMO: Um dos fatores mais críticos na operação do sistema de abastecimento de água é manter um suprimento de água maior ou igual ao consumo da população. A água deve ser fornecida constantemente à população servida pelo sistema de abastecimento de água. Ao considerar que este consumo é variável ao longo do dia que todo sistema de abastecimento de água está sujeito a problemas operacionais que podem afetar diretamente a oferta, a previsão de consumo de água pode ajudar a melhorar a operação do sistema de abastecimento. Este trabalho tem como objetivo utilizar redes neurais artificiais (RNA), em especial a rede de função radial de base radial (RBF) para prever o consumo de água a curto prazo baseada em dados históricos de consumo de uma área de

uma cidade no interior do Paraná, especificamente, Pato Branco. A área é predominantemente residencial com consumo considerado médio. Os resultados obtidos foram satisfatórios e eficientes para descrever o modelo de previsão de consumo.

Palavras-chave: Previsão, Consumo de água, Redes Neurais Artificiais, Função de Base Radial.

USING ARTIFICIAL INTELLIGENCE BY FORECASTING SHORT-TERM CONSUMPTION IN A RESIDENTIAL NEIGHBORHOOD IN THE CITY OF PATO BRANCO - PR

ABSTRACT: One of the most critical factors in the operation of the water supply system is to maintain a supply of water equal to or larger than the population's consumption. The water must be supplied constantly to the population being served by the water supply system. By considering that this consumption is variable throughout the day and that every water supply system is subject to operational problems that can directly impact supply, forecasting water consumption can help to improve the operation of the supply system. This work aims to use artificial neural networks (ANN), in particular, the Radial Basis Function (RBF) network to predict short-term water consumption. The forecasting of the consumption was made based on historical consumption data of an area of a city of the Parana state, Pato Branco. The area was predominantly residential with medium consumption. The results of this study were satisfactory and efficient to describe the consumption forecast model.

Keywords: Forecasting, Water Supply System, Artificial Neural Networks, Radial Basis Function.

INTRODUÇÃO

A água é essencial para a sobrevivência e o bem-estar humano, para o desenvolvimento socioeconômico e para a manutenção de ecossistemas saudáveis (WANG, 2013). Considerada como um fator limitante para o desenvolvimento de uma região, a água tem se tornado como um dos principais recursos do planeta (LUZ et. al., 2019)

O abastecimento de água e o sistema operacional de distribuição são os principais componentes do consumo de água. Um modelo confiável de previsão de consumo permite um melhor planejamento das operações ao longo do dia. Tal modelo de previsão pode apoiar o sistema de abastecimento de água para fornecer água em quantidade e qualidade adequadas à população (TSUTIYA, 2006). Segundo o Programa de Pesquisas em Saneamento Básico – PROSAB (2009):

Os esforços para conservar água e energia podem ser vistos como complementares e sinérgicos, especialmente quando se analisam os sistemas públicos de abastecimento de água. Cerca de 3% do consumo nacional de eletricidade é destinado ao setor de abastecimento de água e tratamento de esgotos e, desse total, mais de 90% da energia destina-se ao uso de motores e bombas. Esses equipamentos, muitas vezes sobredimensionados e obsoletos, operam frequentemente durante os horários de pico. Isso, aliado também às altas perdas de água verificadas em quase a totalidade das companhias de abastecimento, contribui para onerar as tarifas de água e energia elétrica.

A água deve ser pensada como recurso econômico, bem ambiental e social e ser assunto de importância para toda a sociedade, assim como sua gestão deve ser entendida como assunto técnico e político, já que as soluções sobre como deve ser seu uso envolve tomar decisões sobre prioridades, nas quais alguns grupos e interesses podem ganhar ou perder. (ABERS, 2010).

Prever o consumo de água nos sistemas de abastecimento é imperativo em muitos processos dentro de uma empresa de saneamento. Alguns desses processos podem estar relacionados a projetos de novos sistemas de suprimento ou ampliação de sistemas existentes, produção de água que atuem na captação e tratamento de água doce, distribuição de água e armazenamento de água para os usuários finais. O grande cientista social Walter Benjamin (1985) escreveu: “Os homens de uma sociedade não apenas vivem o seu presente, mas também sonham com a época seguinte”.

Para projetos de novos sistemas de abastecimento de água, a previsão de consumo é feita com base no número de conexões de água previstas e dados de crescimento demográfico disponíveis através de metodologias de cálculo. Esta metodologia de cálculo é apresentada em (WASLKI et. al., 2013). Nos projetos de expansão ou melhoria de sistemas, além dos dados utilizados em projetos de novos sistemas de suprimento, também são utilizados dados históricos de consumo. Nos processos de produção e distribuição, a previsão de consumo é realizada com base em dados históricos do consumo de cada componente do sistema de abastecimento de água em estudo e da experiência prática dos técnicos envolvidos na operação do sistema.

A implementação prática dos modelos de Redes Neurais Artificiais (ANN) tem se mostrado aplicáveis para diversos problemas, esse fato se dá devido a sua abordagem matemática flexível e adaptativa. Na literatura, encontramos exemplos de sua aplicação para encontrar soluções aceitáveis para diversos modelos clássicos de programação linear. As RNA

têm se mostrado aplicáveis para prever consumo a curto prazo para a cidade de Curitiba-PR (TRAUTWEIN JR, 2004). SANTOS (2011) apresenta a previsão de demanda de água em sistemas urbanos de abastecimento na região metropolitana de São Paulo - SP através de Rede Neural Artificial (RNA) utilizando dados de consumo de água e variáveis meteorológicas e socioambientais. As ANN, como exemplo atual, aplicada como ferramenta capaz de prever como as mudanças no nível de bloqueio (ir e vir) afetaram a qualidade do ar, uma vez que o nível de bloqueio pode estar diretamente relacionado com o número casos de COVID-19, oriundos na pandemia (TADANO Y. S; et.al, 2021).

Uma vez que o uso de RNA se mostra tão promissor, usar-se-á como ferramenta para uma previsão para o consumo de água no curto prazo para dados obtidos de um bairro residencial da cidade de Pato Branco-PR.

Para a previsão de consumo a curto prazo em Curitiba-PR, Trautwein Jr (2004) apresenta duas abordagens de RNA usando Perceptron Multicamadas (MLP) e Função de Base Radial (RBF). Neste trabalho utilizar-se-á o mesmo design de rede.

As RNA RBF são ferramentas altamente flexíveis em um ambiente dinâmico. Elas têm a capacidade de aprender padrões complexos rapidamente e se adaptar às mudanças, tais características se tornam adequadas para previsão de séries temporais, especialmente àquelas regidas por processos não lineares e/ou não estacionários. As redes neurais artificiais do tipo RBF compõe uma classe de redes neurais particularmente adequadas para o ajuste de curva, isto é, para a aproximação de funções. As RBFs são capazes de modelar relações não lineares nos dados, o que é importante para prever padrões complexos de consumo de água, que muitas vezes são influenciados por fatores sazonais, meteorológicos e comportamentais.

A principal motivação para o uso da Rede Neural da Função de Base Radial (RNA RBF) é a necessidade de desenvolver modelos para previsão da demanda de água para sistemas urbanos de abastecimento de água com metodologias específicas para previsão de problemas deste tipo no Brasil, especialmente para a área de Pato Branco - Paraná.

1. AJUSTE DE CURVAS PARA PREVISÃO DE CONSUMO PARA A CIDADE DE PATO BRANCO (PR)

Nesta seção serão descritas informações sobre a cidade de Pato Branco no sudoeste do Paraná e a técnica utilizada para a previsão do consumo via ajuste de curvas.

1. 1 O MUNICÍPIO DE PATO BRANCO NO PARANÁ

O município de Pato Branco está localizado ao sudoeste do estado do Paraná, na microrregião de Pato Branco, como se observa na Figura 1. Segundo o Instituto Brasileiro de Geografia e Estatística, sua área total é de 539,087 km² (IBGE/2021), com densidade demográfica de 134,25 habitantes por km² (IBGE/2010). De acordo com os dados estimados do IBGE para o ano de 2021, a cidade possui 84.779 habitantes.

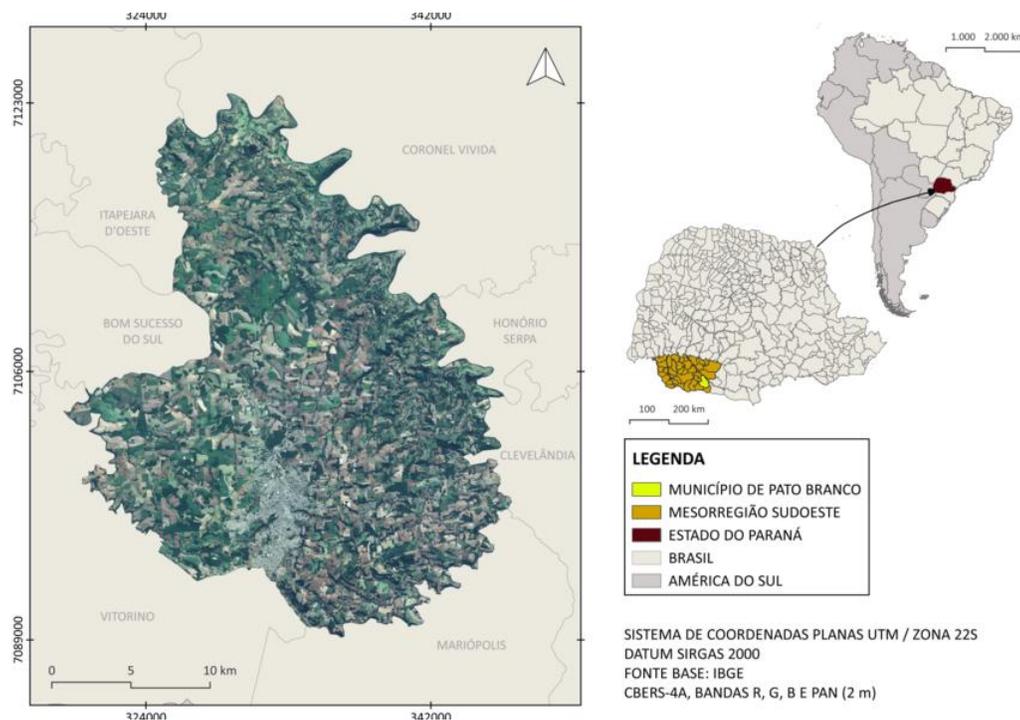


Figura 1: Município de Pato Branco - PR destacado no mapa do Paraná
Fonte: De Faveri Marquesine, Chamma, Batistella (2022)

A cidade se destaca regionalmente por ser um polo de educação, apresentando mais de 350 cursos presenciais e EAD. Além disso, sua economia voltada aos setores de informática e eletroeletrônicos a transformam num pequeno centro tecnológico industrial, onde estão presentes cerca de 100 indústrias de softwares de aparelhos e componentes eletrônicos, que somam-se às ações de universidades locais e da municipalidade, o que garante que a cidade

tenha um Parque Tecnológico instalado e reconhecido em nível nacional.

De acordo com os dados de 2016, Pato Branco é uma das cidades mais desenvolvidas do país, ela ocupa o 4º lugar do Paraná no Índice Firjan de Desenvolvimento Municipal (IFMD). Este índice faz o acompanhamento anual do desenvolvimento socioeconômico dos municípios brasileiros em três áreas de atuação: emprego/renda, educação e saúde. No ranking nacional, Pato Branco ocupa o 19º lugar, liderando na região sudeste do Paraná com a situação no nível do alto desenvolvimento nas três áreas.

No que diz respeito ao desenvolvimento humano, Pato Branco, possui o Índice de Desenvolvimento Humano Municipal - IDHM 0,782 (2010). A figura 2 mostra a evolução do IDHM do município de Pato Branco de 1991 a 2010.

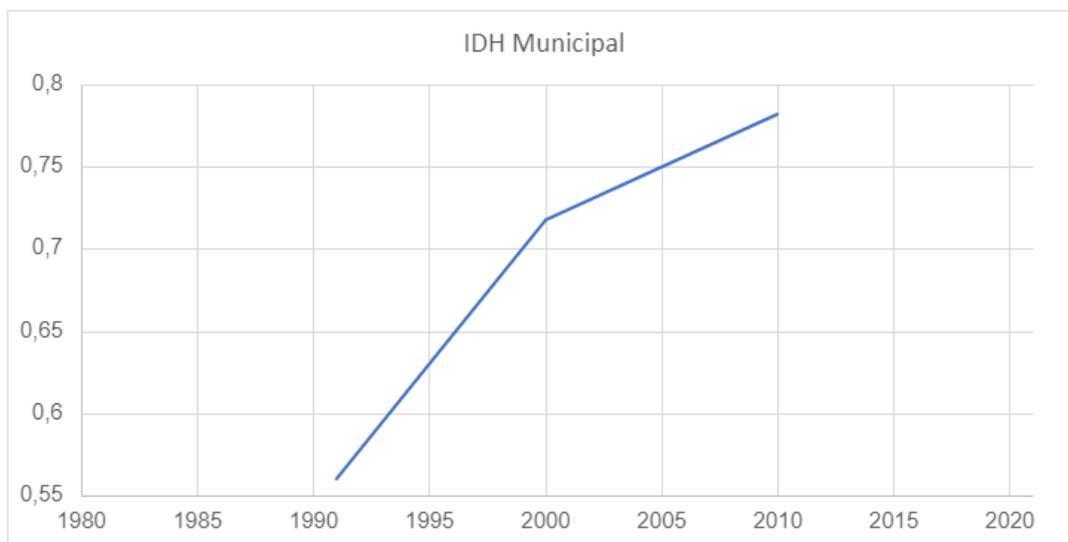


Figura 2: Índice de Desenvolvimento Humano Municipal de Pato Branco - PR

1. 1. 1 HIDROGRAFIA DE PATO BRANCO

O perímetro urbano situa-se ao longo da bacia do Rio Ligeiro, tendo as elevações tanto para Oeste, como para Leste, relativamente acentuadas. Os mananciais em razão da topografia específica do Paraná, também dirigem-se para oeste, pertencendo a bacia do Iguaçu e este a sub-bacia do Paraná.

A figura 3 apresenta as bacias hidrográficas do Paraná e é possível identificar que o

município pertence à bacia do Iguçu (em verde-lima no mapa abaixo das bacias de Piqueri e Paraná 3 e à direita de Jordão e Médio Iguçu).



Figura 3: Bacias Hidrográficas do Paraná

O município é banhado pela sub-bacia do Rio Pato Branco, que tem as nascentes no Gramado São Joaquim em Mariópolis, neste rio é feita a captação de água pela empresa de abastecimento do estado. Os principais rios são: Pato Branco, Ligeiro, Vitorino, todos afluentes do Rio Chopim.

1. 2 REDES NEURAIS ARTIFICIAIS DE FUNÇÃO DE BASE RADIAL

As Redes Neurais Artificiais (RNA) são técnicas computacionais que geram modelos inspirados na estrutura neural de organismos inteligentes e adquirem conhecimento através da

análise de experiências anteriores (SRIRAM, 1997). Neste trabalho utiliza-se a RNA com uso da Função de Base Radial (RBF) como função de ativação para prever o consumo de água no curto prazo.

A rede neural de Função de Base Radial, RBF tem esse nome devido ao uso de funções de base radial que são utilizadas nas camadas intermediárias na rede (FAUSETT, 1994). As funções radiais mais utilizadas são: Função gaussiana, Função multi-quadrática e Função *thin-plate-spline*, que tem suas formas analíticas apresentadas na Tabela 1, onde x é o vetor de entrada e μ o centro da função e σ a largura da função.

Tabela 1 – Funções de base radial

Função	Expressão
Gaussiana	$f(x) = \exp(- (x - \mu)^2 / 2\sigma^2), \sigma > 0$
Multi-quadrática	$f(x) = \sqrt{\quad}, \sigma > 0$
<i>Thin-plate-spline</i>	$f(x) = (x - \mu)^2 \ln(x - \mu)$

Fonte: Adaptado de Braga; Carvalho e Ludermir (2011)

A primeira camada de uma rede RBF tem o papel de agrupar os dados em grupos (ou clusters), cujos neurônios utilizam funções de base radial, esse agrupamento é realizado hiper-elipsóides no espaço de padrões de entrada, tornando um conjunto de padrões de entrada não-linearmente separáveis em um conjunto de saídas linearmente separáveis. A segunda camada é a camada de saída e por sua vez é a responsável por classificar os padrões recebidos da camada anterior.

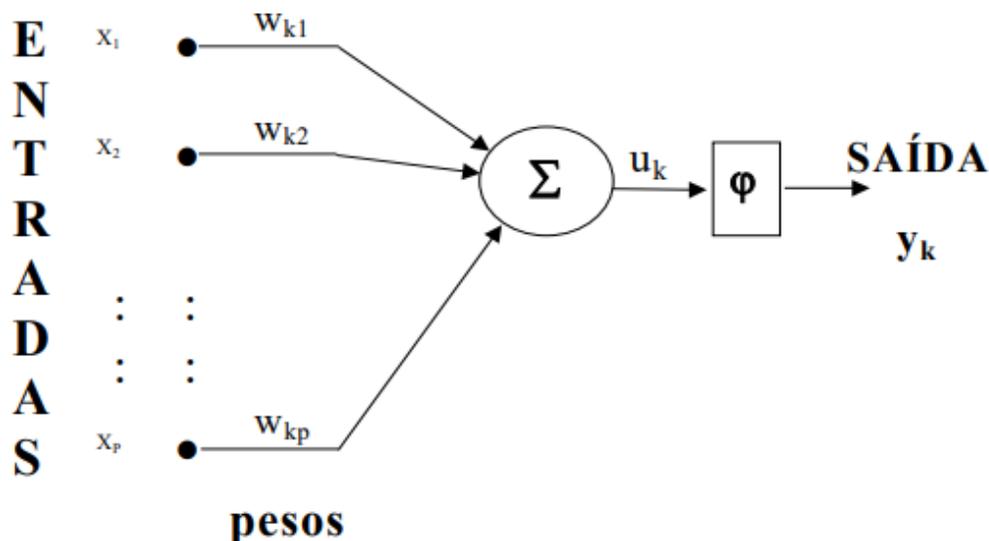


Figura 4: Modelo de Neurônio de Rede Neural Artificial

A figura 4 apresenta um modelo de neurônio de rede neural artificial (RNA) com p entradas de x , com pesos dados por w , uma função de combinação de pesos e entradas e uma função de ativação para a resposta y .

A distância euclidiana $\|x - \mu\|$ do vetor de entrada x ao vetor centro μ serve de entrada para a função, que retorna o valor de ativação da unidade intermediária. A resposta y gerada em um neurônio k de saída será dada por:

$$y(x) = \sum_{i=1}^k w_{ji} \phi(\|x - \mu\|) + b \tag{1}$$

É necessário definir o número de neurônios da camada intermediária RBF. Uma alternativa para isso é definir o número de neurônios como igual ao número de padrões de entrada. Quando o número de funções radiais é igual ao número total de padrões de treinamento, cada centro pode ser situado sobre um vetor de entrada. Com isso, a rede mapeia com exatidão o vetor de entrada para a saída correta. Contudo, essa interpolação exata é indesejável, fazendo com que a rede decore os padrões apresentados.

As RBFs têm uma estrutura relativamente simples, tornando-as mais fáceis de

implementar e entender. A rede RBF utiliza um método de treinamento híbrido, uma vez que é dividido em duas etapas. Na primeira, o número de funções radiais e seus parâmetros são determinados por métodos não-supervisionados, já a segunda etapa de treinamento ajusta os pesos dos neurônios de saída. Como a saída dos neurônios da camada intermediária é um vetor linearmente separável, os pesos podem ser determinados por modelos lineares.

2. METODOLOGIA

Ao aplicar RNA – RBF, alimentada com uma base de dados, composta com os volumes de consumo de água, segmentada por dias da semana e horários, espera-se que a rede seja capaz de obter uma previsão obedecendo a mesma segmentação dos dados de entrada.

A base de dados utilizada no estudo possui 168 padrões. Para o treinamento da rede utilizou-se 139 padrões da base de dados e os demais 29 padrões foram empregados para o teste da rede.

As entradas de hora e dia da semana são originalmente dados contínuos. Para evitar qualquer viés nos resultados utilizou-se entradas binárias, portanto, sete entradas para os dias de semana e vinte e quatro entradas para a hora.

Para implementação da rede utilizou-se o software Matlab, que possui recursos pré-programados que facilitam a codificação. A função que cria este tipo de rede no Matlab é a função *newrb*, ela não permite a definição do número de neurônios na camada escondida, podendo somente ser estipulado o número máximo. Os parâmetros utilizados para criação da rede RBF através do comando *newrb* (P, T, *goal*, *spread*, MN) foram os seguintes:

- Matriz de vetores de entrada (P)
- Matriz de vetores de saída (T)
- Erro médio quadrático pretendido (*goal*)
- Raio da função de base radial (*spread*)
- Número máximo de neurônios na camada oculta (MN)

A Figura 5 mostra uma curva característica de consumo (série histórica) utilizada nesta pesquisa. Pode-se observar a variação do consumo de água durante um período de sete dias em um ciclo de 0h de um sábado e 0h de uma sexta-feira.

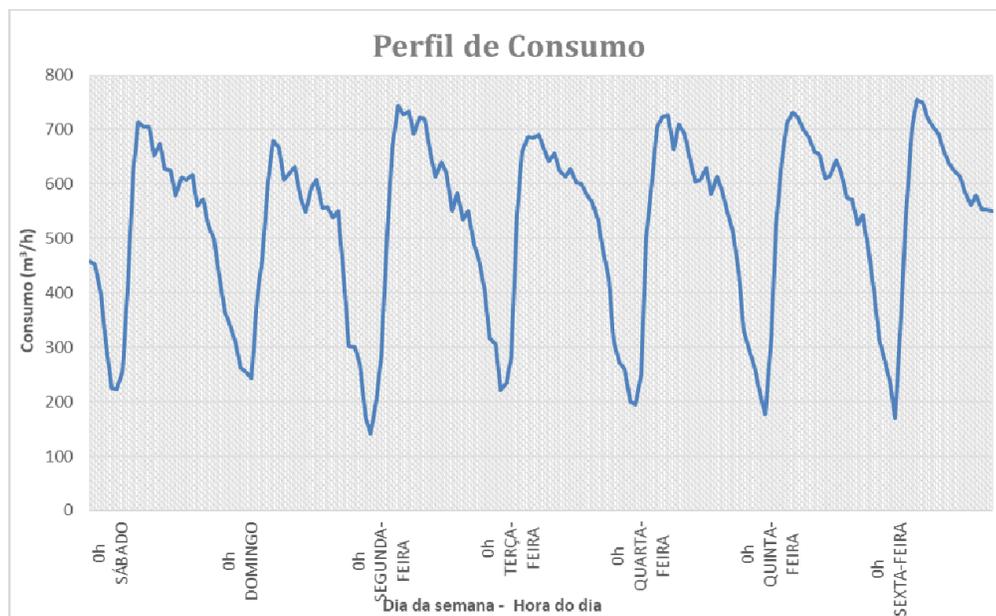


Figura 5: Comportamento de consumo

3. RESULTADOS

As configurações dos parâmetros de treinamento da rede adotadas neste estudo foram:

- Erro médio quadrático pretendido = 0.01;
- Raio da função de base radial = 1;
- Número máximo de neurônios na camada oculta = 100.

Para verificar se os resultados da rede testada foram satisfatórios, comparou-se com a técnica até então utilizada, que consiste no ajuste dos dados a um polinômio de grau 6, para cada dia da semana. Para cada dia da semana mede-se o R-quadrado da regressão, que mede a proporção da variabilidade em Y que é explicada por X , o quanto o modelo explicou os dados, se R-quadrado for igual a 1, o modelo explicou 100% dos dados.

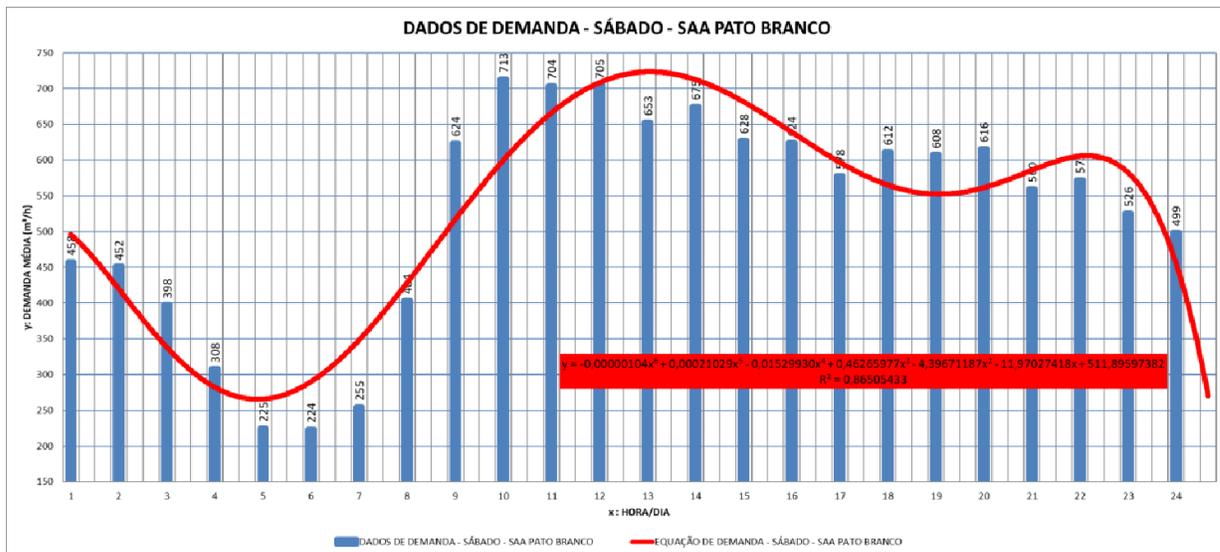


Figura 6: Dados de demanda de um sábado com ajuste de curva polinomial

A figura 6 mostra o perfil de demanda de um sábado na cidade de Pato Branco. Foi adicionado neste gráfico uma curva em vermelho dado pelo ajuste polinomial usado atualmente pela empresa de abastecimento. Já a figura 7 mostra um ajuste utilizando série temporal, a média móvel. Neste última caso, o ajuste é mais acurado.

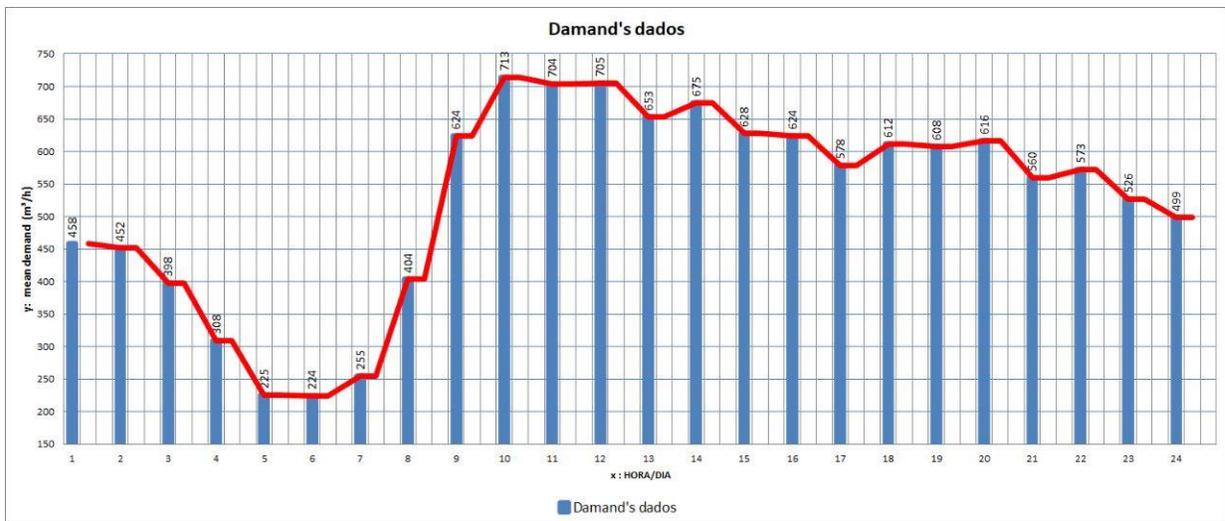


Figura 7: Dados de demanda de um sábado com ajuste usando média móvel

Após o treinamento da rede, empregou-se os 29 dados separados para o teste para estimar o consumo.

Tabela 2 – Comparação R-quadrado

	RNA-RBF	Ajuste Polinomial
Domingo	0,9993	0,9227
Segunda	0,9994	0,9301
Terça	0,9932	0,8891
Quarta	0,9968	0,9333
Quinta	0,9960	0,9160
Sexta	0,9994	0,8930
Sábado	0,9964	0,8651

Fonte: Autor (2021)

O modelo de RNA-RBF apresentou resultados aceitáveis e satisfatórios. Ao analisar a tabela 2, percebe-se que os valores de R-quadrado para as estimativas da rede são melhores quando comparados ao modelo polinomial atual utilizado pela empresa.

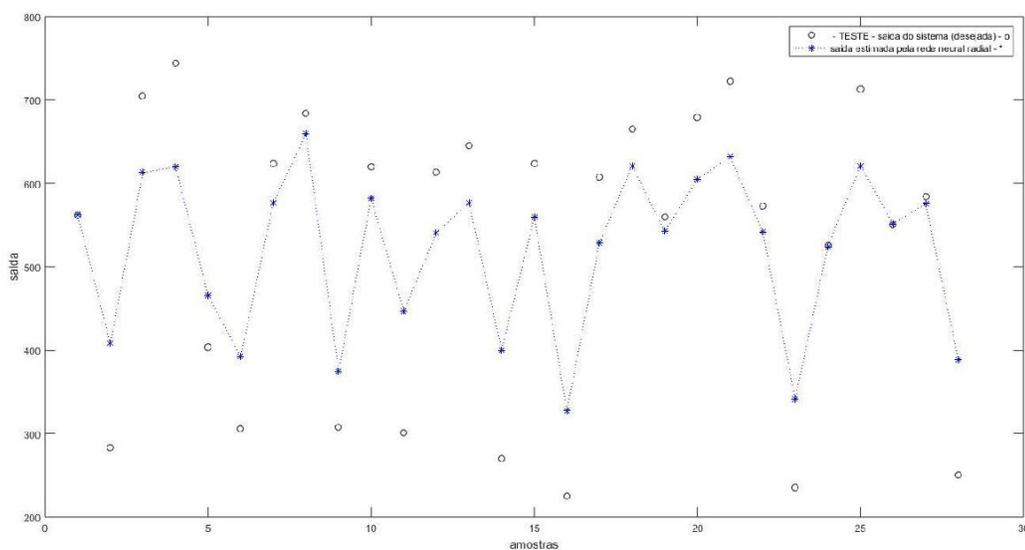


Figura 7: Previsão de consumo via RNA-RBF para dados de teste

Pode-se perceber analisando a figura 7 que a rede foi capaz de generalizar e estender as estimativas. A raiz quadrada do erro médio quadrático para os dados de treinamento foi 81,08.

CONSIDERAÇÕES FINAIS

A previsão de consumo a curto prazo permite uma tomada de decisão mais ágil e eficiente na operação de cada unidade de fornecimento em termos de distribuição e cada estação de tratamento na produção de água. O crescimento está extrapolando previsões e a capacidade de oferta de água justifica-se o desenvolvimento e a aplicação de modelagens matemáticas para a obtenção de políticas de planejamento otimizadas para uma gestão adequada deste recurso. Tal tomada de decisão incluiria, por exemplo, melhorias nas instalações de saneamento, reduzindo os custos de energia.

Uma Rede Neural de Função de Base Radial (RBFNN) pode ser uma escolha promissora para prever o consumo de água devido às suas vantagens de modelagem de relações não lineares, boa generalização e eficiência computacional. No entanto, é importante abordar cuidadosamente a seleção e das variáveis de entrada que melhor descrevem o consumo de água, o tamanho e a qualidade do conjunto de dados, bem como a determinação dos parâmetros da rede para obter os melhores resultados.

Um modelo baseado em RBFNN para prever o consumo de água a curto prazo usando os dados históricos de consumo da cidade de Pato Branco (PR) no Brasil foi proposto neste trabalho. O RBFNN apresenta uma estrutura adequada para a construção do mapeamento local dos dados de entrada e saída. Este tipo de rede é caracterizado pelo rápido aprendizado e eficiência no mapeamento de séries temporais. Para cada dia da semana mediu-se o R-quadrado da regressão obtida via RBFNN e esta ficou em torno de 0,99, isto quer dizer que 99% dos dados foram explicados pelo modelo ajustado, superando o ajuste polinomial realizado por técnicas usuais.

Firat et al. (2009) ao avaliarem diversas técnicas de RNA, inclusive RBFNN para previsão de consumo de água mensal e utilizando fatores socioeconômicos e climáticos que afetam o uso da água, concluíram que as redes neurais de Regressão Generalizada (GRNN) superaram todos os demais métodos na modelagem do consumo mensal da água. Dessa forma, pretende-se testar a GRNN para fazer futuras previsões em dados históricos de consumo de longo prazo para a cidade de Pato Branco.

REFERÊNCIAS

- ABERS, R. N. (org).** *Água e política: atores, instituições e poder nos Organismos Colegiados de Bacia Hidrográfica no Brasil*. São Paulo: Annablume, 2010.
- BENJAMIN, W.** Paris. *Capital do século XIX*. In: **COHN, G.** (org.) Walter Benjamin: *Coleção Grandes Cientistas Sociais*. São Paulo: E. Ática, 1985.
- BRAGA, A. P.; CARVALHO, A. C. P. L. F.; LUDERMIR, T. B.** *Redes Neurais Artificiais: Teoria e Aplicações*. 2. ed. Rio de Janeiro: LTC, 2011.
- DE FAVERI MARQUESINE, M. I.; CHAMMA, W.; BATISTELLA, D.** *Estudo de localização para instalação de usina à base de energia solar concentrada*. Revista Brasileira de Energia, 2022.
- FAUSETT, L.** *Fundamentals of Neural Networks: Architectures, Algorithms, and Applications*. Prentice-Hall, Inc., Upper Saddle River, NJ, USA, 1994.
- FIRAT, Firat, M., YURDUSEV, M. A.,TURAN, M. E.** *Evaluation of Artificial Neural Network Techniques for Municipal Water Consumption Modeling*. Water Resources Management. v. 23. p. 617-639, 2009.
- ÍNDICE FIRJAN DE DESENVOLVIMENTO MUNICIPAL (IFDM).** *Consulta ao índice*. Disponível em: <<https://firjan.com.br/ifdm/consulta-ao-indice/ifdm-indice-firjan-de-desenvolvimento-municipal-resultado.htm?UF=PR&IdCidade=411850&Indicador=1&Ano=2016>> Acesso em: 20 mar. 2023.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE).** *Resultados do Censo de 2021*. Disponível em: <<https://ibge.gov.br/cidades-e-estados/pr/pato-branco.html>>. Acesso em: 20 mar. 2023.
- LUZ, E. de; TOMAZONI, J. C.; POKRYWIECK, T. S.** Monitoramento da Qualidade da Água e Avaliação da Capacidade de Autodepuração do Rio Ligeiro no Município de Pato Branco – PR. São Paulo, UNESP, Revista Geociências, v. 38, n. 3, p. 755 - 768, 2019
- PROJETO PROSAB.** *Conservação de água e energia em sistemas prediais e públicos de abastecimento de água*. Ricardo Franci Gonçalves (coordenador). Rio de Janeiro: ABES, 2009.
- SANTOS, C. C. S.** *Previsão de demanda de água em sistemas urbanos de abastecimento na região metropolitana de São Paulo com de Rede Neural Artificial (RNA) utilizando dados de consumo de água e condições meteorológicas e socioambientais*. Tese(doutorado). Escola Politécnica da Universidade de São Paulo, 2011.
- SRIRAM, R. D.** *Intelligent Systems for Engineering – A Knowledge-based Approach*. Londres, Springer-Verlag, 1997.
- TADANO Y. S., VERMAAK S., KACHBA Y. R., CHIROLI D. M.G., SILVA L. C., SANTOS J.C., MOREIRA C. A.B., MACHADO V., ALVES T. A., SIQUEIRA H., GODOI R. H.M.** *Dynamic model to predict the association between air quality, COVID-19 cases, and level of lockdown*, Environmental Pollution, Volume 268, Part B, 2021.
- TRAUTWEIN JR., B.** *Avaliação de métodos para previsão de consumo de água para curtíssimo prazo: um estudo de caso em uma empresa de saneamento*. Dissertação de Mestrado.

Pontifícia Universidade Católica do Paraná, 2004.

TSUTIYA, M. T. *Abastecimento de água*. Escola Politécnica de São Paulo, São Paulo, 2006.

WALSKI, T.; CHASE, D.V.; SAVIC, D. *Water distribution modeling*. Waterbury, CT, USA: Haestad Press, 2013.

WANG, X. *A novel T-FGM(1,1) forecasting model based on RBF neural network for water demand forecasting*. Bio Technology: An Indian Journal, v. 8, 551-554, 2013.

Enviado em 25/07/2023

Aprovado em 03/06/2024