

XI-1377 – APLICAÇÃO DE *SOFT SENSORS* PARA MACROMEDIÇÃO: UM ESTUDO DE CASO REAL

Gabryel Martins Raposo de Alencar⁽¹⁾

Graduando em Engenharia Elétrica pela Universidade Federal da Paraíba (UFPB). Aluno-pesquisador do Laboratório de Eficiência Energética e Hidráulica em Saneamento (LENHS/UFPB).

Júlio Martins da Silva Neto⁽²⁾

Graduando em Engenharia Elétrica pela Universidade Federal da Paraíba (UFPB). Aluno-pesquisador do Laboratório de Eficiência Energética e Hidráulica em Saneamento (LENHS/UFPB). Estagiário de Engenharia Elétrica na Gerência de Controle Operacional e Automação da CAGEPA-PB.

Altamar Alencar Cardoso⁽³⁾

Economista pela Universidade Federal da Campina Grande (UFCG). Especialista em Automação Industrial pela Faculdade SENAI. Gerente de Novos Negócios e Inovação na CAGEPA-PB. Doutorando em Administração pela Universidade Federal da Paraíba.

Petronio Ferreira de Melo⁽⁴⁾

Graduado em Ciências da Natureza pela Universidade Federal da Paraíba (UFPB). Especialista em Automação Industrial pela Faculdade SENAI. Técnico em Eletrotécnica pela ETEPB/IFPB. Subgerente de Automação na CAGEPA-PB.

Juan Moises Mauricio Villanueva⁽⁵⁾

Graduado em Engenharia Eletrônica pela Universidad Nacional de Ingeniería (Lima/Peru). Mestrado em Engenharia de Eletricidade pela Universidade Federal do Maranhão (UFMA). Doutorado pela Pontifícia Universidade Católica do Rio de Janeiro (PUC-RJ). Pós-Doutorado pela Universidade Federal de Campina Grande (UFCG). Professor associado do Departamento de Engenharia Elétrica da UFPB. Integrante da coordenação do Laboratório de Eficiência Energética e Hidráulica em Saneamento (LENHS/UFPB).

Endereço⁽¹⁾: Cidade Universitária - João Pessoa - PB - Brasil - CEP: 58051-970 - Tel: (83) 99683-4981 - e-mail: gabryel.alencar@cear.ufpb.br

RESUMO

O alto índice de perdas de água entre sua captação e distribuição à população é um fator de grande relevância e preocupação das concessionárias de água. A redução dessas perdas é objeto prioritário no planejamento das concessionárias, pois além de desperdício de um bem essencial à vida, envolve uma série de custos que poderiam ser evitados ou compensados caso não houvesse esse desperdício. Para combater as perdas, é necessário que se saiba o quanto e onde essas perdas acontecem, e para esse efeito, a mensuração da vazão entre a captação e a distribuição faz-se imprescindível, de forma que, com ela, pode-se tomar decisões mais acertadas e soluções mais estratégicas conforme a análise dos dados mensurados. Essa mensuração, quando realizada utilizando sensores *hardwired*, apresentam custos elevados de aquisição, manutenção e demandam esforço de instalação. Entretanto, com o desenvolvimento da Indústria 4.0, surgiram técnicas de estimação e predição de grandezas físicas baseadas em *softwares*, sendo chamados de *Soft Sensors*, sendo alternativas tecnológicas na mensuração, obtendo os dados indiretamente.

Com isso, o objetivo deste trabalho baseia-se na experimentação da eficácia da mensuração de dados de vazão através do uso de *Soft Sensor* em um sistema de abastecimento real, através de Redes Neurais Artificiais, baseado em aprendizado de máquina.

O modelo de *Soft Sensor* construído apresentou média de distribuição de erro próxima a 2%, conseguindo prever a vazão de distribuição com até 1 hora de antecedência, sendo um modelo aderente ao real e utilizável de acordo com a análise dos gestores da concessionária.

PALAVRAS-CHAVE: *Soft Sensor*, Medição Indireta, Macromedição, Redução de Perdas.

INTRODUÇÃO

De acordo com dados mais recentes do Sistema Nacional de Informações do Saneamento (SNIS), o índice nacional de perda na distribuição de água de 2021, foi de 40,25%. Ainda no ano de 2021, a Agência Nacional

de Água, responsável por determinar as normas de referência para regulação do setor de saneamento no Brasil, definiu, através da Portaria 490/2021, que as concessionárias de abastecimento de água devem reduzir as perdas na distribuição ano a ano, até o patamar de no máximo 25% de perdas da distribuição em 2034. De acordo com a ABES (2015), esse problema de perdas atinge não só o Brasil, e sua consequência é a baixa performance das concessionárias em cumprir sua missão de abastecer adequadamente e de forma universal nas áreas onde atuam.

Para Bezerra e Cheung (2013), a setorização permite o acompanhamento mais preciso da ação de redução de perdas, através da realização do balanço hídrico antes e depois das intervenções. O balanço hídrico (ABES, 2015) é feito utilizando os dados da quantidade de água que entra no setor em comparação com o efetivamente consumido e/ou faturado pelas economias. A confiabilidade do balanço hídrico é função do percentual de medição dos volumes de entrada da distribuição (volumes macromedidos) e os volumes efetivamente consumidos e/ou faturados (volumes micromedidos).

Em 2021, apenas cerca de 70% de toda água produzida foi macromedida (IN011 do SNIS), enquanto que o índice de micromedição (IN009 do SNIS) é maior que 90%. Portanto, ainda existe uma carência de acompanhamento mais preciso dos volumes de água que entram nos sistemas de abastecimento, para melhor gerir as perdas desses sistemas, além, é claro, da necessidade de monitorar também as entradas dos setores de distribuição.

Uma tendência tecnológica que pode contribuir para o avanço do monitoramento das vazões nos sistemas de distribuição de água e de seus setores, é a adoção de *Soft Sensors*, que, segundo Kadlec *et al.* (2009), consiste em *softwares* que utilizam uma base de dados para construir um modelo preditivo de grandezas de interesse. Segundo Lima (2022), os *Soft Sensors* são técnicas computacionais capazes de realizar processamento e análise do histórico de determinados dados de entradas correlacionados com a variável desejada, e através destes, prever com precisão esta última (Lima, 2022).

OBJETIVOS

O objetivo geral deste trabalho é avaliar a viabilidade técnica de utilizar um *Soft Sensor* para macromedição de forma indireta, mostrando em um ambiente real a eficácia de um *Soft Sensor* na medição de vazão de um Distrito de Macromedição e Controle (DMC).

Como objetivos específicos, avalia-se a capacidade de informações de outros instrumentos do sistema, como nível e pressão, serem preditores da vazão de distribuição, de modo a avaliar se o erro de medição entre o macromedidor real e o proposto *Soft Sensor* pode ser aceitável. As vantagens dessa abordagem são de que, além da evidente possibilidade de utilizar *Soft Sensors* para monitoramento de setores, o *Soft Sensor* também pode ser utilizado para prevenir e indicar possíveis falhas dos macromedidores reais, a necessidade de calibração destes e de serem capazes de substituí-los quando estes são inviáveis devido a restrições de instalação ou a seu elevado custo de aquisição (Liu *et al.*, 2020). Este último configura um aspecto muito importante, uma vez que macromedidores reais estão sujeitos a furtos, principalmente em unidades operacionais situadas em locais ermos.

O monitoramento regular das vazões de entrada permite acompanhar o Fator de Pesquisa, obtido através da relação entre a vazão mínima noturna e a vazão média diária. Quando essa relação é superior a 0,3 existem vazamentos economicamente evitáveis (ABES, 2013). O trabalho de Sjöbom *et al.* (2015) apresentou resultados reais expressivos na gestão de perdas com a introdução de inovações tecnológicas para reduzir os custos da automação de sistemas de monitoramento do abastecimento. Outra proposta de redução de custos de implantação de automação, como estratégia para viabilizar a sua aplicação em pequenos sistemas de abastecimento, é o trabalho de Cardoso *et al.* (2021).

De acordo com Bezerra e Cheung (2013), o controle de pressão na rede é uma das principais ações para redução das perdas. A setorização na distribuição de água, uma subdivisão da rede de distribuição, é uma estratégia que permite um controle de pressão mais eficaz. A NBR 12218, que trata dos projetos de redes de distribuição de água, define que os setores de manobras devem conter no máximo 3 mil economias, e a pressão deve variar entre 100 kPa e 500 kPa.

METODOLOGIA UTILIZADA

Para o desenvolvimento do *Soft Sensor*, Kadlec *et al.* (2009) modelaram um processo para a construção deste, que pode ser adaptado em 4 etapas:

- Seleção do histórico de dados – Identificação e seleção dos dados correlacionados a serem usados como entrada no *Soft Sensor*;
- Pré-processamento dos dados – Tratamento de dados ausentes, remoção de *outliers*, que consistem em valores drasticamente anormais do padrão dos dados de entrada, *etc*;
- Seleção do modelo, treinamento e validação da metodologia usada para o *Soft Sensor*;
- Validação dos dados de saída e manutenção do *Soft Sensor*.



Figura 1: Metodologia de construção do *Soft Sensor* – Kadlec *et al.*, 2009 (adaptado).

Para a seleção de histórico de dados, foram utilizados dados reais captados e enviados ao sistema supervisorio utilizado pela concessionária. A entrada do setor é um reservatório elevado (REL) de distribuição; uma rede de distribuição que abastece cerca de 1,4 mil ligações com monitoramento de pressão. O Arranjo analisado está descrito na Figura 2:




Figura 2: SAA Salgado de São Félix – Autoria própria.

Os dados de nível, pressão e vazão são enviados ao SCADA-LTS, ficando armazenados no banco de dados da companhia. O SCADA-LTS constitui uma plataforma categorizada como *Supervisory Control And Data Acquisition* (SCADA) sob uso da concessionária em questão, que registra os dados em uma frequência de 6 minutos. Entretanto, a varredura da leitura dos equipamentos ocorre em uma frequência de 30 segundos. Desta forma, é importante relatar que o registro a cada 6 minutos é referente à média das leituras realizadas neste período. A amostra de dados totaliza 9040 registros de cada variável:

- LIT-REL-01 – nível do reservatório de distribuição (m);
- PIT-DMC-01 – pressão da rede de distribuição (mca);
- FIT-DMC-01 – vazão de saída do reservatório de distribuição (l/s).




Figura 3: Séries de nível, pressão e vazão separadas em treino, validação e teste – Autoria própria.

Com isso, o modelo de predição do *Soft Sensor* escolhido foi um algoritmo computacional baseado em *machine learning* conhecido como Rede Neural Artificial (RNA). A RNA utiliza o cérebro humano como modelo estrutural para subsidiar seu aprendizado, consistindo em um conjunto de nós interconectados chamados de “neurônios artificiais”. Estes neurônios são organizados em uma rede variada dividida em camadas e interligados entre si por entradas e saídas, as quais podem possuir pesos atribuídos, até atingir determinada(s) saída(s) (Lima, 2022).

RESULTADOS OBTIDOS OU ESPERADOS

Foi utilizada a técnica de aprendizado supervisionado, desta forma, parte dos dados foram utilizados para treinar (cor azul na Figura 3) o algoritmo de RNA. Os dados de validação (cor vermelha) são utilizados para comparação de modelos com hiperparâmetros diferentes. Por fim, os dados de teste (cor verde) são utilizados para mensurar os indicadores de ajuste do modelo. O objetivo de testar o modelo com dados não utilizados no treinamento se dá pelo interesse na generalização do modelo para novos cenários.

Foram testadas várias composições de RNAs do tipo LSTM (*Long Short-Term Memory*) e seus hiperparâmetros, o melhor ajuste encontrado foi para o modelo. A escolha de um modelo de LSTM se deu pelo fato da mesma considerarmos que o comportamento anterior da rede de distribuição, ou seja, o comportamento de consumo é uma informação relevante para determinação da vazão de distribuição atual.

Apenas a utilização das informações de nível e pressão como entrada do modelo não foi possível chegar a um modelo com ajuste adequado. Ao adicionar a informação de vazão (defasada no tempo) foi possível selecionar um modelo de LSTM com ajuste adequado. Foram analisadas as seguintes medidas de erro:

- Erro Absoluto Médio (*Mean Absolute Error* - MAE) que por utilizar o módulo para evitar os erros negativos, se torna menos sensível aos outliers:




Figura 4: Análise do Erro Absoluto Médio (MAE) – Autoria própria.

- Erro Quadrático Médio (*Mean Square Error* – MSE) fornece a média da diferença elevada à segunda potência, desta forma, penaliza mais os erros maiores.




Figura 5: Análise do Erro Quadrático Médio (MSE) – Autoria própria.

- Raiz do Erro Quadrático Médio (*Root Mean Square Error* – RMSE) mesma análise do MSE, entretanto, ao aplicar a raiz quadrada, apresenta resultados na mesma escala dos dados de entrada.




Figura 6: Análise da Raiz do Erro Quadrático Médio (RMSE) – Autoria própria.

Uma vez que os dados de entrada foram normalizados para valores entre 0 e 1, as saídas no MAE e RMSE, não são interpretados como erros em l/s, mas em termos de percentuais do máximo valor observado. Desta forma, os resultados apresentam que o erro médio para o modelo de validação não é muito diferente do modelo de treinamento, e são da magnitude de 8% para o MSE e 12% para o RMSE, essa diferença pode ser atribuída a maior penalidade dos erros calculados pelo método da RMSE.

ANÁLISE E DISCUSSÃO DOS RESULTADOS

O objetivo de construção do *Soft Sensor* é o de prever a variável FIT-DMC-01. O modelo conseguiu prever essa variável com uma hora de antecedência a partir dos dados de PIT-DMC-01, LIT-REL-01 e o próprio FIT-DMC-01 defasado (anteriores), com erro com variação média entre 8% e 12%.

Observa-se através das Figuras 7 e 8 que o ajuste do modelo é aderente ao real, e pode ser utilizado para identificar falhas no macromedidor e/ou vazamentos na rede de distribuição. Entretanto, não foi possível construir um instrumento capaz de prever a vazão a partir das variáveis de pressão e nível apenas.




Figura 7: Série do FIT-DMC-01 com ajuste do modelo de validação – Autoria própria.




Figura 8: Série real x previsto – Autoria própria.

Embora o erro médio seja elevado em comparação a outros instrumentos de medição, a depender do interesse do objetivo da medição, a média dos erros pode ser de maior interesse que o próprio erro médio. Ou seja, pode ser que mesmo que as previsões pontuais tenham variações altas em relação ao valor real, a média dessas leituras pode apresentar um valor nulo. Esse parece ser o caso das medições de DMC, pois o objetivo de maior relevância não consiste em identificar a pressão da vazão instantânea, mas a precisão dos balanços diários e mensais, para identificação de parâmetros de vazamentos, como o Fator de Pesquisa.

Desta forma, ao analisarmos o histograma da distribuição dos erros, observamos um comportamento aproximado a uma distribuição normal. Essa característica é interessante, por permitir supor que o volume acumulado durante o período, estimado pelo *Soft Sensor* será bem próximo ao volume acumulado pelo FIT-DMC-01, com erro próximo a 2% (média da distribuição de erro), sendo considerado o viés deste modelo baixo para as necessidades do negócio. Ao gestor cabe responder à pergunta, vale a pena investir um macromedidor real em relação ao *Soft Sensor*, para ter uma precisão do volume consumido de 2%?




Figura 9: Histograma de distribuição do erro – Autoria própria.

CONCLUSÕES/RECOMENDAÇÕES

O *Soft Sensor* é uma alternativa tecnológica que tem potencial para otimizar sistemas de abastecimento de água, seja na economia de implantação de novos macromedidores (CAPEX), seja na definição de alertas de calibração (OPEX). Entretanto, o diferencial para exploração do seu potencial é a integração e disponibilidade de dados operacionais dos sistemas SCADA. Com a existência de mais informações, os modelos podem ser cada vez mais robustos, adaptativos e precisos, seguindo uma dinâmica de comportamento mais próxima do real.

O modelo de melhor ajuste permite uma previsão de até uma hora de antecedência da vazão de distribuição. Esse modelo já poderia ser utilizado para identificar vazamentos e/ou necessidade de calibração do macromedidor da entrada do DMC. Entretanto, ainda não foi possível dispensar a existência do macromedidor, pois a informação de vazão passada é um preditor do modelo de melhor ajuste.

Esse trabalho é o primeiro relato de um projeto de pesquisa de um ICT com uma concessionária de abastecimento, financiado parcialmente pela Fundação de Apoio à Pesquisa (FAP) do estado em que o estudo está sendo realizado. Espera-se que novas informações e melhor modelagem, possam viabilizar a construção de um *Soft Sensor* para monitoramento de vazão de DMCs aplicáveis em todo o território nacional. Para tanto, os próximos modelos deverão considerar a variação do nível do reservatório, hora e dia da semana, vazão de entrada do reservatório e/ou status de funcionamento dos motores como fonte adicional de informação. Essas novas informações serão analisadas sob a óptica do custo benefício em termos de ganho de precisão e aumentos da complexidade e exigência de infraestrutura de instrumentação.

REFERÊNCIAS BIBLIOGRÁFICAS

1. <https://www.in.gov.br/en/web/dou/-/portaria-n-490-de-22-de-marco-de-2021-309988760>
2. <https://www.gov.br/mdr/pt-br/assuntos/saneamento/snis/painel>
3. BEZERRA, S. T. M. CHEUNG P. B. (2013). *Perdas de água: tecnologias de controle*. João Pessoa: Editora UFPB.
4. Associação Brasileira de Engenharia Sanitária e Ambiental [ABES] (2015). *CONTROLE E REDUÇÃO DE PERDAS NOS SISTEMAS PÚBLICOS DE ABASTECIMENTO DE ÁGUA: POSICIONAMENTO E CONTRIBUIÇÕES TÉCNICAS DA ABES*.
5. Lima, Robson Pacífico Guimarães. (2022) *Desenvolvimento de um soft sensor para estimação da vazão em sistemas de abastecimento de água utilizando redes neurais artificiais*. [Tese de Doutorado, Universidade Federal da Paraíba]. <https://repositorio.ufpb.br/jspui/handle/123456789/24485>
6. CARDOSO, A. A. C., MELO P. F., CAMBOIN, T. C. M. & DIAS, L. A. (2021). Arquitetura de automação de baixo custo para sistemas de abastecimento de água: um experimento em uma empresa de saneamento. In *Congresso Brasileiro de Engenharia Sanitária e Ambiental (31: 2020: Curitiba)*. *Anais eletrônicos*. Rio de Janeiro: Abes, 2021.
7. SJÖBOM JR. A. A. SOUZA, A. G. SANTOS, I. RODRIGUES, R. F. MEDEIROS JR, J. W. (2015). Inovação e Automação em Saneamento. In *Congresso Brasileiro de Engenharia Sanitária e Ambiental (28: 2015: Rio de Janeiro)*. *Anais eletrônicos*. Rio de Janeiro: Abes, 2015.
8. Liu, Y., & Xie, M. (2020). *Rebooting data-driven soft-sensors in process industries: A review of kernel methods*. *Journal of Process Control*, 89, 58-73.
9. Kadlec, P., Gabrys, B., & Strandt, S. (2009). Data-driven Soft Sensors in the process industry. *Comp. Chem. Eng.*, 33, 795,814.