

I-037 APLICAÇÃO DO MÉTODO SVM PARA AVALIAÇÃO DE RECLAMAÇÕES DE FALTA D'ÁGUA A PARTIR DE VARIÁVEIS OPERACIONAIS DE UM SISTEMA DE ABASTECIMENTO DE ÁGUA)

Renato Von Randow Junior ⁽¹⁾

Bacharel em Engenharia Civil pela Universidade Federal do Espírito Santo - UFES (2007), Mestre em Tecnologias Sustentáveis pelo Instituto Federal do Espírito Santo (IFES – 2022). Engenheiro Civil na CESAN (Companhia Espírito Santense de Saneamento).

Reginaldo Barbosa Nunes ⁽²⁾

Bacharel em Engenharia Elétrica pela Universidade Federal do Espírito Santo - UFES (1988), Mestre em Informática (UFES - 2003) e Doutor em Engenharia Elétrica (UFES - 2016). Professor do Instituto Federal do Espírito Santo (IFES).

Endereço⁽¹⁾: Rua Fortaleza, 1500, Ap 101, Itapoã, Vila Velha ES – CEP 29-101575 - Brasil - Tel: +55 (27) 999312189 - e-mail: renatpra@gmail.com.

RESUMO

Os sistemas de abastecimento de água potável são muito complexos e com características diferentes. Entender o comportamento operacional é importante para soluções mais seguras e econômicas na gestão da operação, manutenção, expansão e projetos de sistemas de abastecimento. Melhorar a eficiência operacional para garantir o abastecimento e reduzir as perdas de água são uma questão de sustentabilidade empresarial. O estudo de variáveis como pressões, vazões, dentre outras, estão diretamente relacionados à demanda que, por sua vez, varia consoante mudanças e ou falhas que podem influenciar diretamente na distribuição e causar desabastecimento.

Neste artigo foram aplicados modelos computacionais de aprendizado de máquina com o classificador SVM (do inglês *Support Vector Machine* – Vetor Suporte de Máquina) para análise de previsões de dias com número elevado de reclamações de falta d'água em um setor de abastecimento de água do município de Viana-ES operados pela Companhia Espírito Santense de Saneamento (CESAN). O banco de dados com histórico de três anos das variáveis de pressão, vazão e nível de reservatório, associou ocorrências diárias de falta d'água à média, desvio padrão e intervalo interquartil das variáveis. Com esse trabalho foi possível classificar por meio da análise de matriz confusão e curva ROC, com precisão de até 80,0%, perfis operacionais correspondentes a dias com número elevado de reclamações de desabastecimento. Desta forma, as variáveis operacionais, quando calibradas adequadamente, podem auxiliar o planejamento e o controle operacional, permitindo assim, melhor gestão da distribuição pela automatização do sistema com desenvolvimento de padrões e alertas para os operadores.

PALAVRAS-CHAVE: Abastecimento de água, Variáveis operacionais; Reclamações de abastecimento; SVM, aprendizado de máquina.

INTRODUÇÃO

O tratamento e distribuição de água potável para a população em geral têm sido aprimorados pela necessidade de preservação da água, um recurso natural limitado. A sua utilização descontrolada pode levar à exaustão dos mananciais e assim ocorrer consequências de ordem ambiental e social por conta do desabastecimento. A identificação de falhas operacionais na distribuição de água emergiu como um componente imprescindível de gerenciamento de recursos hídricos com metodologias inteligentes. Tais abordagens fizeram com que as empresas prestadoras de serviços de saneamento buscassem novas abordagens de previsão mais especializadas que levem em conta os fatores especiais da demanda de água em cada região. Técnicas avançadas têm a capacidade de superar os problemas de não linearidade comumente encontrados ao investigar a complexa relação entre demanda de água, clima, variáveis socioeconômicas dentre outras. Relacionar as variáveis operacionais dos sistemas de abastecimento de água (SAA), a fim de manter um equilíbrio entre oferta e

demanda por meio de ações preventivas e corretivas, exige aplicação de ferramentas de previsão (GROPPO; COSTA; LIBÂNIO, 2019). Várias são as vantagens da obtenção de um modelo, entre as quais podem ser citadas: identificação imediata de perda física no sistema, identificação de anormalidades que possam representar perdas e ou desabastecimentos, ganho da qualidade da água através de estoques adequados, melhor planejamento da operação, maior eficiência das estações elevatórias da água bruta e tratada e da estação de tratamento, dentre outras. A detecção precoce de falhas é fundamental para manter a segurança operacional industrial. A detecção e o diagnóstico de falhas podem ser divididos em quatro tipos: Detecção de falha, detecção de comportamento anormal do processo, diagnóstico de falhas e identificação de variáveis relevantes para a ocorrência de falhas. (MAHADEVAN; SHAH, 2009).

A partir de técnicas baseadas em modelos é possível inferir a causa raiz e identificar com grande probabilidade a causa real para a ocorrência da falha, por exemplo, uma rede obstruída, um vazamento significativo, uma mudança repentina na distribuição causada por manobras ou desligamento de elevatórias, ou outras condições do processo. Isto pode ser realizado com base em uma medida de confiança predefinida para identificação de forma rápida dos desvios e retificação das falhas para que o processo volte ao regime adequado de operação. Quando conhecidas as condições para o abastecimento adequado, pode-se planejar o tratamento e reserva de água para os períodos e automatizar a operação dos equipamentos de controle de vazões e pressões no sistema (FALKENBERG; DYMINSKI; RIBEIRO, 2003).

A aplicação de novas tecnologias, principalmente as que envolvem automação, ciência de dados e inteligência artificial, é de grande importância no setor do Saneamento no Brasil, como em outros lugares do planeta, que ainda não são digitais. Muitos destes, pouco a pouco, começam a trilhar seus caminhos em um mundo cada vez mais tecnológico, o que deve garantir celeridade e qualidade aos processos do cotidiano das empresas prestadoras de serviços (MANZI, 2020). Métodos de inteligência artificial fornecem ferramentas adicionais para tentar resolver problemas complexos do mundo real. Pesquisas em todo o mundo têm sido realizadas na área de distribuição de água para detecção vazamentos (KANG et al., 2018; LIU et al., 2019; MANZI, 2017) e também para previsões de demanda de abastecimento (GROPPO; COSTA; LIBÂNIO, 2019). Neste contexto, este trabalho tem por objetivo apresentar uma alternativa de avaliação como ferramenta para rápida e prática identificação de desvios operacionais na distribuição de água, com variáveis operacionais de pressão, vazão e níveis de reservatórios como atributos para avaliação de número elevado de reclamações de falta d'água em um setor distribuição de água. O cenário experimental estudado foi o sistema de abastecimento de água de Viana Sede no estado do Espírito Santo, operado pela Companhia Espírito Santense de Saneamento - CESAN. O trabalho aplica a ferramenta SVM para inferir condições críticas de abastecimento a partir de variáveis monitoradas em praticamente todas as estações de tratamento de água, que são: Vazão de distribuição, Nível de Reservatório e Pressão em um ponto de referência.

Diante de tantas abordagens sobre eficiência, as empresas de saneamento, a partir da capacitação dos funcionários e definições corretas dos parâmetros de controle operacional, podem caminhar para redução das perdas na distribuição com o controle de pressões e vazões e identificar falhas de forma mais rápida. O crescimento dos dados disponíveis pela implementação de tecnologias responsáveis pela aquisição e armazenamento de informações deu um impulso significativo ao desenvolvimento de algoritmos computacionais. Vários métodos orientados por dados, que visam identificar anomalias na distribuição de água, têm sido propostos com base nas taxas de vazão de entrada no setor e medidas de pressão. A demanda de água segue um padrão típico em um cenário ideal e eventos repentinos como, por exemplo, tomadas d'água em hidrantes, podem gerar mudanças bruscas de cenários típicos. Portanto, comportamentos incomuns, identificados como outliers na série de tempo de consumo de água, podem ser classificados através de uma detecção de anomalia por aproximação (MENAPACE et al., 2020).

MATERIAIS E MÉTODOS

PRIMEIRA ETAPA: DEFINIÇÃO DO SISTEMA E VARIÁVEIS

Foi escolhido o setor denominado Viana Sede como estudo de caso deste trabalho. É um setor pertencente ao município de Viana - ES, operado pela Companhia Espírito Santense de Saneamento - CESAN, com ocupação predominantemente residencial. A Figura 2 ilustra a área do setor no momento em que foi desenvolvido o estudo. A área tracejada em vermelho delimita a posição das ligações, concentradas no Centro da cidade, no Bairro Bom Pastor e no Bairro Ribeira. Ao final do ano de 2021 havia 1940 ligações ativas (referência Dezembro 2021).




Figura 2 - Imagem da localização das ligações no setor Viana Sede. Os pontos representam as ligações e a área tracejada o DMC - Distrito de Medição e Controle (Fonte: CESAN).

Preliminarmente às simulações, foram adquiridos os dados operacionais do sistema e os dados de reclamações de falta d'água (itens de atendimento pelos canais da companhia). Foram distribuídos em uma matriz e ordenados com o resumo diário das informações para treinamento e testes relativos aos anos 2019, 2020 e 2021. Nesta etapa, foram avaliadas as medições disponíveis no banco de dados da companhia relativas aos seguintes dados operacionais: vazão em litros por segundo (L.s-1), Níveis dos reservatórios em porcentagem, (%), vazão de distribuição em litros por segundo (L.s-1) e Pressão de sucção em uma elevatória da distribuição de água tratada em metros de coluna d'água (mca).

Com a finalidade de avaliar a influência das variáveis nas reclamações de falta d'água, o primeiro passo foi a aquisição e tratamento dos sinais relativos aos dados operacionais fornecidos pela Companhia sendo, duas fontes de Captação de água bruta, uma ETA (Estação de Tratamento de Água), dois reservatórios de água tratada (RAT), e duas redes de saída para distribuição, sendo uma destas exclusiva para o Presídio de Viana e outra para a Cidade, objeto do estudo. No setor Centro, os sinais de pressão na sucção de da Elevatória (EEAT) Bom Pastor foram aplicados para avaliar desabastecimentos, já que, quando há queda de pressão, sugere-se interrupção provocada por vazamentos, reduções ou paralisações na distribuição.

Os dados operacionais foram extraídos do portal do Centro de Controle Operacional (CCO) da Companhia e exportados para planilha Excel. Em seguida foram realizados ajustes como substituição de vírgulas por ponto, redução de casas decimais, configuração do vetor dia e hora para futura integração com o software MATLAB. Durante o processo de aquisição de dados houve necessidade de identificar e tratar dados corrompidos após identificação de condições aleatórias e atípicas para formar o conjunto de atributos de treinamento e validação

do modelo. Foi definida para correção dos dados faltantes a ferramenta PCA Missing Data do MATLAB ®. Os dias que não tiveram medição de nenhum dado não foram considerados nos treinamentos e testes.

Foi utilizada a análise de componentes principais (PCA), uma técnica aplicada para reduzir a dimensionalidade de conjuntos de dados aumentando a interpretabilidade e reduzindo perda de informações para preservar o máximo de variabilidade possível ao encontrar novas variáveis que são funções lineares daquelas do conjunto de dados original e maximizam sucessivamente a variância (JOLLIFE; CADIMA, 2016). O trabalho buscou analisar a interação de certas variáveis para compreender e classificar processos dinâmicos.

SEGUNDA ETAPA: DADOS PARA SIMULAÇÕES

as possíveis falhas foram consideradas para validar os novos dados de treinamento aplicados no dia de sua ocorrência e classificados no período. Os dados foram dispostos em vetores com média, desvio padrão e intervalo interquartil diários compilados conforme Tabela 1.

Tabela 1- Atributos utilizados para classificação dos dias com elevado número de reclamações

Dados Extraídos do portal CCO		
Média diária dos valores corrigidos	Desvio Padrão diário dos valores corrigidos	Intervalo Interquartil diário dos valores corrigidos

Além da média e desvio padrão, o intervalo interquartil foi um vetor utilizado como preditor. Este intervalo é aplicado para construção do diagrama de caixas (boxplots). Ele mostra um resumo compacto das características da distribuição de valores permitindo avaliar a dispersão e assimetria de um conjunto de dados. Esta avaliação pode ser um grande auxílio para os operadores de sistemas de saneamento que, em geral, avaliam relatórios diários para identificação de desvios operacionais e tomada de decisão para identificar pontos de melhoria e ajustar os seus sistemas.

O SVM - Máquina de Vetor Suporte (Support Vector Machine) é um classificador que tem origem na aplicação de conceitos da teoria de aprendizado estatístico sendo um reconhecedor de padrões, uma vez que opera transformações não lineares de forma a separar os hiperplanos de solução no espaço (MANZI, 2017).

O SVM toma como entrada um conjunto de dados e prediz, para cada entrada dada, qual de duas possíveis classes a entrada faz parte, o que faz dele um classificador linear binário não probabilístico. Tem como objetivo encontrar uma função que produza saídas contínuas para os dados de treinamento que desviem ao máximo de um rótulo desejado. Essa função deve ser o mais uniforme e regular possível (FACELI, 2011).

Após preparados os atributos preditores, por meio do classificador SVM, as amostras com dados operacionais do mesmo dia das reclamações e também com dados do dia anterior às reclamações, foram aplicadas para avaliar a capacidade de previsão de reclamações no dia (D) e no dia anterior (D-1) a partir de diferentes simulações dos dados operacionais.

TERCEIRA ETAPA: AVALIAÇÃO DA ACURÁCIA DO CLASSIFICADOR

Algoritmos de aprendizado têm um viés para as classes com maior número de instâncias. Regras que predizem corretamente essas instâncias são ponderadas positivamente em favor da métrica de precisão enquanto regras específicas, que predizem exemplos da classe minoritária, são geralmente ignoradas, tratando-as como ruído (GALAR et al., 2011). Com tamanho de amostra pequeno, conjuntos de dados desequilibrados não têm exemplos suficientes de classes minoritárias. Logo, a taxa de erro causada pela distribuição de classe desbalanceada diminui quando o número de exemplos da classe minoritária é representativo. Desta forma, padrões que são definidos por instâncias positivas podem ser melhor aprendidos, apesar da distribuição

desigual de classes. No entanto, esse fato geralmente é inalcançável em problemas do mundo real (GALAR et al., 2011).

Portanto, o teste foi realizado de forma balanceada por meio de validação cruzada com 5 conjuntos, onde 4 serviram como treinamento e 1 como teste. A média dos 5 testes ofereceu a acurácia do classificador por meio da Curva Característica de Operação do Receptor ou, do inglês, *Receiver Operating Characteristic Curve* (ROC curve). A curva ROC é uma representação gráfica que ilustra o desempenho de um sistema classificador. Sua análise equivale à área abaixo da curva (AUC -*Area under the curve*). Ela varia de 0 a 1, sendo que 0,5 representa um modelo que seria completamente aleatório. Quanto mais próximo de 1, maior é a probabilidade de classificação correta. Este gráfico permite visualizar e comparar os benefícios (VP - Verdadeiros Positivos) e os custos (FP - Falsos Positivos). A AUC fornece uma única medida do desempenho de um classificador para avaliar qual modelo é melhor. A AUC é construída pelo espaço plotado em um gráfico bidimensional pelo VP (eixo Y) contra o FP (eixo X). Os pontos em (0, 0) e (1, 1) são classificadores triviais onde a classe prevista é sempre a negativa e a positiva, respectivamente. Pelo contrário, o ponto (0, 1) representa a classificação perfeita.

RESULTADOS

Após intenso trabalho de preparação dos dados, filtros e experimentos com diferentes atributos, foi elaborada a matriz atributos para classificação dos dias com elevado número de reclamações de falta d'água com os dados diários de 2019, 2020 e 2021 do setor Viana-Sede. Destaca-se que foi utilizada a data de registro da reclamação, mesmo que a variável pudesse apresentar desvios em dias sem reclamações.

1 - Os dados Brutos, 70937 linhas, foram tratados com o preenchimento dos dados faltantes (NaN) pela função *PCA Missing Data* (MATLAB) a partir dos vetores originais do portal CCO por hora do dia.

2 - Da Matriz principal, incluindo os dados corrigidos, foram extraídas a média, desvio padrão e Intervalo Interquartil diários, em um vetor com 21 colunas e 1096 Linhas relativas aos dias dos três anos estudados;

3 - A Matriz Atributos foi definida após filtro dos dados dos dias que tiveram medições confirmadas após avaliação do portal CCO. O vetor filtro foi aplicado e 955 dias foram validados para o estudo, sendo que os demais não tiveram medições pela telemetria.

Levando-se em conta as variáveis operacionais, separando dias com até nove reclamações e dias sem reclamações de falta d'água relatados pelos clientes, é apresentado na Tabela 2 o resumo dos resultados dos cenários com diferentes arquiteturas com o classificador SVM. Foi seguida a configuração padrão do aplicativo Classification Learner do MATLAB. Foram aplicados como atributos a média (M), desvio padrão (DP) e intervalo interquartil (IQR). Dados do Dia das reclamações (D) e Dia anterior às reclamações (D-1). Os resultados foram apresentados em Porcentagem de Acerto e AUC (área abaixo da curva ROC).

Tabela 2- Resultados Falta D'água comparando dias sem reclamações com dias com nove ou mais reclamações. Avaliação com diferentes atributos e Classificador SVM.

Atributo	SVM (dados do mesmo dia)		SVM (dados do dia anterior)	
	%	AUC	%	AUC
1 - Média	92,5	0,94	90,5	0,96
2 - DP	82,5	0,90	83,0	0,89
3 - IQR	88,5	0,95	87,5	0,94
4 - PCA 2	76,0	0,82	73,5	0,80
5 - PCA 3	77,0	0,83	71,5	0,78
6 - Atributos 1 ,2 e 3	94,0	0,99	92,0	0,97

Foi possível observar que a utilização dos atributos combinados, item 6 da Tabela 2, apresentou os melhores resultados. Logo, uma nova simulação foi executada aplicando-se os testes com a média, desvio padrão e intervalo interquartil combinados de todas as amostras. Duas classes foram atribuídas com diferentes limites de reclamações, sendo a primeira classe dias com menos de x reclamações e a segunda classe relativa aos dias com x ou mais reclamações. Os resultados são apresentados na Tabela 3.

Tabela 3- Resultados: Falta D'água comparando dias com duas classes e atributos combinados. Classificador SVM.

Número de reclamações (x) Duas Classes ($\geq x$ e $< x$)	SVM (dados do mesmo dia)		SVM (dados do dia anterior)	
	%	AUC	%	AUC
1	74,0	0,80	74,0	0,81
2	76,0	0,78	70,5	0,74
3	80,0	0,86	71,5	0,77
4	68,5	0,77	76,0	0,82
5	72,5	0,74	72,0	0,76
6	66,5	0,73	71,0	0,76
7	72,5	0,79	68,0	0,78
8	75,5	0,79	75,0	0,82
9	74,5	0,83	72,5	0,80
10	71,0	0,76	72,5	0,82

Observa-se no gráfico *scatter plot* na Figura 3 o melhor resultado da simulação com SVM no mesmo dia e com todos os atributos (média, desvio padrão e intervalo interquartil). Foram destacadas 200 amostras aleatórias, sendo 100 amostras de dias com menos de 3 reclamações e 100 amostras de dias com três reclamações ou mais. Para classificação, as amostras foram dispostas de forma randômica em uma matriz de classificação e realizada a validação cruzada com 5 grupos balanceados.




Figura 3 – Scatter Plot, classificador SVM com 200 amostras aleatórias de dias com três ou mais reclamações (vermelho) e dias com até duas reclamações de falta d’água (azul).

A matriz confusão e curva ROC geradas a partir do melhor classificador são apresentadas na Figura 4.




Figura 4 – Matriz Confusão e Curva ROC do Melhor Classificador SVM com os atributos (média, desvio padrão e intervalo interquartil - dados operacionais do mesmo dia das reclamações.

CONCLUSÕES

Com base no trabalho realizado, concluiu-se que:

Os resultados obtidos apresentaram melhor sensibilidade para identificação dos dias com maior número de reclamações com a utilização dos dados Vazão de captação, vazão de distribuição, nível de reservatório e pressão em um ponto no setor de distribuição aplicados de forma combinada;
Quando a simulação para classificação de dias sem reclamações em comparação com dias com mais de nove reclamações, a **média diária** dos dados operacionais foi o melhor atributo para classificação;

Apesar de pequena a diferença do modelo entre identificação das reclamações do dia e do dia anterior, é possível identificar falhas no abastecimento no dia anterior às reclamações, avaliando assim planos de emergência para evitar maiores consequências à população;

Nos testes com diferentes faixas de reclamação, a identificação dos dias com menos de 3 reclamações apresentaram melhores resultados de previsão com 80% de acerto e 0,86 de AUC.

Em todas as simulações, os resultados apresentam melhor avaliação da curva ROC quando os dados são balanceados, ou seja, o mesmo número de amostras em cada classe. Os dias adjacentes às reclamações, mesmo não tendo elevado número de reclamações, podem acusar desvio operacional. Desta forma, o relato de reclamação pode não acontecer no mesmo dia do desvio operacional bem como haver reclamação em dia com perfil operacional sem desvios.

Com relação à identificação de falhas operacionais, como as cidades apresentam comportamento dinâmico ao longo dos anos, o modelo deverá ser treinado periodicamente para adaptar-se às mudanças do meio buscando melhoria contínua, afim de controlar a distribuição com o mínimo de reclamações.

Qualquer modelo inteligente serve para auxiliar a decisão dos operadores que têm função insubstituível na operação e controle dos sistemas de distribuição de água. Por meio de um modelo calibrado do sistema é possível testar configurações para a melhor saída. Uma das formas de avaliar é testar a menor vazão possível que atenda a distribuição sem provocar desabastecimento. A redução de vazão implica em redução de consumo de energia, insumos, mão de obra e perdas contribuindo para o desenvolvimento sustentável das empresas prestadoras de serviços de saneamento.

REFERÊNCIAS BIBLIOGRÁFICAS

1. BRENTAN, B. et al. Hybrid SOM+k-Means clustering to improve planning, operation and management in water distribution systems. *Environmental Modelling and Software*, [s. l.], v. 106, p. 77–88, 2018. Disponível em: <https://doi.org/10.1016/j.envsoft.2018.02.013>. Acesso em: 21 maio 2022.
2. FACELI, K. et al. *Inteligência artificial: uma abordagem de aprendizado de máquina*. 1. ed. Rio de Janeiro: LTC, 2011
3. FALKENBERG, A. V.; DYMINSKI, A. S.; RIBEIRO, E. P. Redes neurais artificiais aplicadas à previsão de consumo de água. In: CONGRESSO BRASILEIRO DE REDES NEURAI, 6., 2003, São Paulo. Anais [...]. São Paulo: Centro Universitário da FEI, 2003. p. 319-324.
4. GALAR, M. et al. Hybrid-based approaches. *IEEE Transactions On Systems, Man, And Cybernetics—Part C: Applications And Reviews*, [s. l.], v. 12, p. 1–22, 2011
5. GROppo, G. de S.; COSTA, M. A.; LIBÂNIO, M. Predicting water demand: a review of the methods employed and future possibilities. *Water Supply*, [s. l.], v. 19, n. 8, p. 2179–2198, 2019
6. JOLLIFE, I. T.; CADIMA, J. Principal component analysis: a review and recent developments. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, [s. l.], v. 374, n. 2065, 2016. DOI: 10.1098/rsta.2015.0202
7. KANG, J. et al. Novel leakage detection by ensemble. *IEEE Transactions on Industrial Electronics*, [s. l.], v. 65, n. 5, p. 4279-4289, 2018.
8. KAUFFMAN, S. et al. Palisade: a framework for anomaly detection in embedded systems. *Journal of Systems Architecture*, [s. l.], v. 113, fev. 2021. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S1383762120301545>. Acesso em: 28 maio 2022
9. LIU, Y. et al. Water pipeline leakage detection based on machine learning and wireless sensor networks. *Sensors, Switzerland*, v. 19, n. 23, p. 1–21, 2019.
10. MAHADEVAN, S.; SHAH, S. L. Fault detection and diagnosis in process data using one-class support vector machines. *Journal of Process Control*, [s. l.], v. 19, n. 10, p. 1627–1639, 2009. Disponível em: <http://dx.doi.org/10.1016/j.jprocont.2009.07.011>. Acesso em: 20 maio 2022.
11. MANZI, D. Detecção e localização de rompimentos em redes de distribuição de água a partir de análise dos sinais de pressão em regime transitório. 2017. 242 f. Tese (Doutorado em Engenharia Civil na área de Recursos Hídricos, Energéticos e Ambientais) – Universidade de São Paulo, Campinas, 2017.
12. MANZI, D. (2020). *A hidráulica de todo dia no saneamento (1a)*. Appris.



13. MENAPACE, A., ZANFEI, A., FELICETTI, M., AVESANI D., RIGHETTI, M., & GARGANO, R. Burst Detection in Water Distribution Systems: The Issue of Dataset Collection. *Applied Sciences*, 2020, 10, 8219. <https://doi.org/10.3390/app10228219>
14. RAMOS, H. M.; CARRAVETTA, A.; MCNABOLA, A. New challenges in water systems. *Water*, [s. l.], v. 12, n. 2340, 2020. DOI: 10.3390/w12092340. Disponível em: www.mdpi.com/journal/water. Acesso em: 23 set. 2022.