SISTEMA DE APOIO À DECISÃO BASEADO EM COMBINAÇÃO DE PREVISÕES PARA OPERAÇÃO OTIMIZADA DE RESERVATÓRIOS EM SISTEMAS URBANOS DE ABASTECIMENTO DE ÁGUA

Fabrizio Silva Campos[(1)]
Engenheiro Ambiental e Sanitarista (UNIVALI), Mestre em Engenharia Hidráulica e Saneamento (EESC/USP), atualmente está como Analista de Engenharia Sanitária na Gerência de Água da Companhia Águas de Joinville, Santa Catarina. Atua nas áreas de ciências de dados e pesquisa operacional, com foco em desenvolvimento de ferramentas de suporte à decisão para sistemas urbanos de abastecimento de água.
Lucas Emanuel Martins[(2)]
Engenheiro Ambiental e Sanitarista (UFSC), Especialista em Transientes Hidráulicos (UPV), atualmente está como Gerente de Água na Companhia Águas de Joinville, Santa Catarina. Responsável pela gestão da equipe e operação do Sistema de Abastecimento de Água de Joinville, envolvendo toda a cadeia de produção e logística até o consumidor final (captação, tratamento, adução e distribuição de água).

Endereço[(1)]**:** R. XV de Novembro, 3950 - Glória, Joinville - SC, 89216-202 - Brasil - Tel: +55 (47) 3509-1613 - e-mail: fabrizio.campos@aguasdejoinville.com.br

RESUMO

A operação de reservatórios em sistemas de abastecimento de água (SAA) é tradicionalmente reativa, baseada na experiência de operadores e na análise visual de painéis SCADA, o que dificulta o planejamento, a segurança e o rastreio das decisões. Este trabalho apresenta um Sistema de Apoio à Decisão (SAD) que integra previsão horária de demanda, obtida por combinação de quatro algoritmos de aprendizado de máquina e variáveis climáticas, a um módulo de otimização que determina as vazões de entrada, garantindo a operação cíclica do reservatório, preservando seu efeito-pulmão e minimizando o número de manobras. A ferramenta foi avaliada por simulação contrafactual sobre cerca de dois meses de operação real de um reservatório urbano, indicando redução de aproximadamente 41% no número de manobras nas válvulas de entrada e aumento de 23% na amplitude diária de uso do reservatório, mantendo o nível em intervalo de segurança equivalente ao da operação real. Demonstra-se que a previsão de demanda acurada é fator crítico na operação de reservatórios e que SAD baseados em dados contribuem para a previsibilidade do planejamento, a padronização dos processos e a democratização da informação.

PALAVRAS-CHAVE: Abastecimento de água; Previsão de demanda; Otimização operacional.

1. INTRODUÇÃO

A segurança hídrica em centros urbanos depende, em larga medida, da operação eficiente da infraestrutura de distribuição de água tratada. Os reservatórios de distribuição cumprem papel duplo nessa infraestrutura: atendem à variabilidade horária do consumo e servem como reserva contra eventos não previstos, garantindo continuidade do abastecimento (TSUTIYA, 2006). A operação adequada desses reservatórios exige conciliar três objetivos frequentemente conflitantes: manter o nível dentro de um intervalo de segurança, atender à demanda variável dos setores abastecidos e preservar a estabilidade hidráulica da rede de distribuição.

Apesar dos avanços da literatura em otimização operacional de redes de abastecimento (MAYS, 2010; ORMSBEE; LANSEY, 1994), observa-se um descompasso persistente entre a maturidade técnico-científica das metodologias propostas e a prática operacional adotada pela maioria das companhias de saneamento no Brasil. A literatura documenta que a transposição de Sistemas de Apoio à Decisão (SAD) do estágio acadêmico para o ambiente operacional encontra barreiras relevantes, incluindo a complexidade dos modelos, a falta de interfaces apropriadas ao decisor humano e a dificuldade de integração com os sistemas SCADA existentes (SAVIC; BICIK; MORLEY, 2011; KAPELAN; SAVIC; WALTERS, 2005).

Na prática corrente, é comum que a operação dos reservatórios em centros de controle operacional (CCO) seja conduzida de forma reativa, com decisões fundamentadas na experiência dos operadores e na interpretação visual de painéis SCADA. Embora funcione na prática, esse modelo produz soluções não ótimas e com baixo

nível de critério técnico, dificulta a padronização das decisões entre turnos e equipes, reduz a auditabilidade das ações e introduz dependência crítica de profissionais experientes.

A migração de uma cultura operacional reativa para uma cultura baseada em dados requer dois elementos articulados. O primeiro é a capacidade de antecipar o comportamento da demanda em horizontes operacionalmente úteis (24 a 48 horas, por exemplo), com erro suficientemente baixo para sustentar decisões. A literatura indica que abordagens de aprendizado de máquina superam métodos univariados clássicos quando há regressores climáticos e de calendário disponíveis (DONKOR et al., 2014; HERRERA et al., 2010), e que métodos de combinação de previsões são particularmente robustos por mitigarem vieses individuais (BATES; GRANGER, 1969; PETROPOULOS et al., 2022). O segundo é a tradução dessa previsão em uma indicação operacional clara, as vazões de entrada, que respeite as restrições físicas do reservatório e seja interpretável pelo operador.

A integração desses dois componentes em um SAD funcional, com interface adequada ao CCO, é uma necessidade prática raramente atendida no cenário nacional. O presente trabalho desenvolve essa integração e apresenta os resultados de sua implementação em um reservatório real de SAA urbano. A contribuição é tripla: metodologicamente, propõe-se um fluxo de previsão combinada específico para o regime horário de reservatórios urbanos; do ponto de vista de engenharia de sistemas, apresenta-se a arquitetura de uma ferramenta interativa de apoio à decisão integrada às camadas preditiva e de otimização; e, operacionalmente, demonstra-se por simulação contrafactual que a adoção da ferramenta reduz substancialmente o número de manobras manuais sobre as válvulas de entrada, mantendo o nível dentro dos limites operacionais seguros.

Este artigo está organizado da seguinte forma. A seção 2 apresenta os objetivos. A seção 3 descreve a metodologia: área de estudo, dados, modelagem preditiva, formulação da otimização e arquitetura do sistema. A seção 4 reúne os resultados e a respectiva discussão. A seção 5 traz as conclusões e recomendações.

2. OBJETIVOS

2.1 OBJETIVO GERAL

Desenvolver e avaliar uma ferramenta interativa de apoio à decisão para o planejamento operacional de curto prazo de reservatórios em sistemas de abastecimento de água, integrando previsão de demanda baseada em combinação de modelos de aprendizado de máquina à otimização não-linear da vazão de entrada, com vistas a transitar de uma operação reativa baseada na experiência dos operadores para uma operação antecipatória baseada em dados.

2.2 OBJETIVOS ESPECÍFICOS

a) Desenvolver um modelo combinado para previsão horária da vazão de saída de reservatórios urbanos;

b) Formular matematicamente o problema de otimização da vazão de entrada de reservatórios com função objetivo alinhada à prática operacional de constância da alimentação;

c) Implementar uma ferramenta interativa, baseada em ambiente *Shiny*, que integre os componentes preditivo e de otimização e produza recomendações operacionais;

d) Avaliar a viabilidade operacional da ferramenta por meio de simulação contrafactual sobre operação real de reservatório de SAA urbano, comparando indicadores sob o regime convencional e sob o regime guiado pela ferramenta de suporte à decisão.

3. METODOLOGIA

3.1 ÁREA DE ESTUDO E CARACTERIZAÇÃO DO RESERVATÓRIO

O estudo foi conduzido em um sistema de abastecimento de água (SAA) urbano brasileiro, considerando um reservatório de distribuição de geometria cilíndrica responsável pelo atendimento de um setor da rede. As principais características físicas são apresentadas na Tabela 1. O nível mínimo operacional refere-se à altura abaixo da qual o sistema entra em condição de risco, considerando a manutenção da pressão mínima de atendimento e o resguardo de reserva técnica.

Tabela 1 - Características físicas do reservatório de estudo

Parâmetro	Valor	Unidade
Altura máxima (cota de extravasamento)	4,58	m
Nível mínimo operacional	0,88	m
Faixa operacional (altura útil)	3,70	m
Raio equivalente	18,80	m
Área de seção horizontal	1.110,4	m²
Volume total	5.085,6	m³
Volume útil	4.108,5	m³
Volume mínimo operacional	977,2	m³

Fonte: elaboração própria a partir de dados do cadastro técnico da companhia (2026).

O reservatório é alimentado por adução proveniente de unidade de tratamento, sendo a vazão de entrada controlada por válvula motorizada, cuja abertura é ajustada manualmente pela equipe do CCO conforme leitura visual do nível e da vazão de saída em painel SCADA. A vazão de saída é determinada exclusivamente pela demanda do setor abastecido e não é controlável pelo operador.

3.2 DADOS E PRÉ-PROCESSAMENTO

Foram utilizados dados de nível e vazão coletados pelo SCADA da companhia a partir do sistema de telemetria, com granularidade horária, abrangendo período suficiente para a calibração da modelagem e a posterior aplicação. As variáveis foram: nível do reservatório (m), vazão de entrada (L/s) e vazão de saída para o setor abastecido (L/s). Compôs-se ainda um conjunto de variáveis exógenas: (i) regressores de calendário (hora do dia, dia da semana, mês, indicadores de fim de semana e de feriado); (ii) regressores climáticos de fonte meteorológica georreferenciada de domínio público (temperatura, umidade relativa, radiação solar, indicador de dia chuvoso, velocidade do vento e temperatura aparente); e (iii) regressores de Fourier para a sazonalidade complexa diária (24 h, $K_1 = 12$) e semanal (168 h, $K_2 = 21$).

O pré-processamento removeu observações inválidas (valores negativos e nulos por falha de aquisição) e, em seguida, identificou e descartou do conjunto de treinamento os *outliers* de demanda — valores acima de $Q_3 + 1{,}5 \cdot AIQ$ (amplitude de intervalo interquartil) por par "dia da semana × hora do dia" (CHATFIELD, 2004), por serem majoritariamente decorrentes de interferências operacionais. Por fim, observou-se um descompasso sistemático entre o balanço esperado (entrada medida menos saída medida) e a variação do volume armazenado, atribuível a perdas físicas, imprecisão de instrumentos ou inserções/extrações não monitoradas; aplicou-se uma correção de reconciliação para fechar o balanço de massa.

3.3 MODELAGEM PREDITIVA DA DEMANDA

A previsão da vazão horária de saída foi modelada por combinação de previsões (ensemble), agregando quatro algoritmos de naturezas distintas. A opção pela combinação, e a própria seleção das famílias de modelos, apoia-se nos resultados consolidados na competição *Battle of Water Demand Forecasting* (Batalha da Previsão de Demanda de Água)(ALVISI et al., 2025), competição internacional que comparou 31 métodos de previsão de demanda horária sobre setores reais de uma rede de distribuição e concluiu que abordagens que combinam modelos de naturezas diferentes superam consistentemente os modelos isolados, e que a inclusão de um componente de séries temporais aumenta a robustez da previsão. Esse resultado é coerente com a teoria clássica de combinação de previsões, segundo a qual agregar modelos de vieses distintos reduz a variância da estimativa e melhora a generalização (BATES; GRANGER, 1969; PETROPOULOS et al., 2022).

Os quatro modelos são: rede neural autorregressiva (NNETAR), com p = 24 defasagens (HYNDMAN; ATHANASOPOULOS, 2021); floresta aleatória (*Random Forest*) com 100 árvores e pesos temporais crescentes (BREIMAN, 2001); modelo linear generalizado Gamma com ligação logarítmica, apropriado a variáveis estritamente positivas como vazões; e *gradient boosting* (XGBoost) (CHEN; GUESTRIN, 2016). A seleção das variáveis exógenas em cada janela foi conduzida pelo operador LASSO (TIBSHIRANI, 1996), com escolha automática do parâmetro de penalização por validação cruzada, aplicando-se os regressores selecionados consistentemente aos quatro modelos. A previsão combinada foi obtida por média simples, conforme a equação (1):

$$\hat{Q}_s^{ens}(t) = (1/4) \cdot \Sigma\, \hat{Q}_s^{(m)}(t), \quad m = 1 \ldots 4 \qquad \text{equação (1)}$$

Onde, $\hat{Q}_s^{ens}(t)$ representa a vazão de saída prevista pela combinação de previsões no tempo (t), e m de 1 a 4 representa cada um dos modelos individuais. A média simples foi preferida a combinações ponderadas por mostrar-se igualmente competitiva e mais robusta fora da amostra (PETROPOULOS et al., 2022). A avaliação preditiva foi conduzida por validação em janela móvel (*rolling window*) com treino fixo de 1.344 horas (8 semanas), horizonte de 48 horas e passo de uma hora, reportando-se erro absoluto médio (MAE), raiz do erro quadrático médio (RMSE) e erro percentual absoluto médio (MAPE) ao longo de todas as janelas.

3.4 FORMULAÇÃO DO PROBLEMA DE OTIMIZAÇÃO

O balanço de massa do reservatório, em forma diferencial, é dado pela equação (2):

$$dV(t)/dt = Q_e(t) - Q_s(t) \qquad \text{equação (2)}$$

onde V(t) é o volume armazenado (m³), $Q_e(t)$ a vazão de entrada e $Q_s(t)$ a vazão de saída. A vazão de saída corresponde à demanda do setor abastecido: é uma variável exógena, não controlada pelo operador, que entra no problema como o termo de consumo do balanço. Para seção horizontal constante de área A, tem-se V(t) = A · h(t), com h(t) o nível (m). Integrando no intervalo [0, T], obtém-se a equação (3):

$$h(T) - h(0) = (1/A) \cdot \int_0^T [Q_e(t) - Q_s(t)]\, dt \qquad \text{equação (3)}$$

onde h(0) e h(T) são os níveis nos instantes inicial e final do horizonte, A é a área da seção horizontal do reservatório (m²) e T a duração do horizonte de planejamento (h).

Para a operação horária, a equação (3) é discretizada na forma recursiva da equação (4):

$$h_{j+1} = h_j + (Q_e - \hat{Q}_{s,j}^{ens}) \cdot \Delta t / A \qquad \text{equação (4)}$$

onde j é o índice horário, h_j e h_{j+1} os níveis no início e no fim da hora j, Q_e a vazão de entrada constante no período, $\hat{Q}_{s,j}^{ens}$ a previsão combinada de demanda para a hora j (equação 1), Δt = 3600 s o passo de discretização e A a área da seção horizontal.

A variável de decisão é o vetor de vazões de entrada Q_e. O reservatório de estudo, subdimensionado para a demanda atual, raramente admite uma única vazão constante dentro dos limites. Assim, adota-se um pequeno número N de vazões constantes por dia (por exemplo, uma noturna e uma diurna), com transição programada. O planejamento é resolvido em horizonte de longo prazo: otimiza-se o horizonte completo, mas aplica-se apenas o primeiro dia, recalculando-se a cada novo dia. O número N de vazões por dia parte de 1 e só é incrementado quando traz melhora relativa da função objetivo.

O problema está sujeito à restrição operacional da equação (5), que limita a vazão aos valores fisicamente admissíveis ($0 \le Q_e \le Q_e^{max}$) e mantém o nível dentro da banda operacional, definida por margens de segurança em relação ao piso e ao topo da faixa física, [h_{min} + m_inf, h_{max} − m_sup], imposta por penalização quadrática:

$$0 \le Q_e \le Q_e^{max} \; ; \quad h_{min} \le h_j \le h_{max} \qquad \text{equação (5)}$$

onde Q_e^{max} é a vazão máxima admissível pela capacidade hidráulica do sistema; h_{min} e h_{max} são os limites inferior e superior da banda operacional, dados pelo nível mínimo operacional e pela altura máxima acrescidos das margens de segurança m_inf e m_sup; e h_j é o nível na hora j.

Da equação (3) decorre uma propriedade analítica útil, onde para uma única vazão constante operando em regime cíclico (subidas e descidas diárias), a vazão que promove o ciclo é igual à média da demanda no período, conforme a equação (6). Embora simples, o resultado é operacionalmente não-trivial, uma vez que a média da demanda futura não é observável no momento da decisão e depende essencialmente da previsão, sem ela, o operador é forçado à decisão reativa, e a qualidade da operação fica limitada.

$$\mathbf{Q_e^* = (1/T) \cdot \int_0^T Q_s(t)\, dt = \bar{Q}_s} \qquad \text{equação (6)}$$

onde Q_e^* é a vazão de entrada constante ótima, $\bar{Q}_s$ a média da demanda no horizonte, $Q_s(t)$ a demanda instantânea e T a duração do horizonte de planejamento.

A ferramenta dispõe de duas funções objetivo, ambas sujeitas às restrições da equação (5). A primeira, de operação equilibrada, adotada neste trabalho, minimiza a variância da vazão de entrada, conforme a equação (7). O objetivo dela é reduzir a variabilidade de Q_e, fazendo com que a alimentação se aproxime da vazão constante igual à média da demanda, estabilizando o regime de entrada e minimizando o número de manobras.

$$\mathbf{\min Var(Q_e)} \qquad \text{equação (7)}$$

onde $Var(Q_e)$ é a variância das vazões de entrada ao longo do horizonte de planejamento.

A segunda, de corte de pico, conduz o nível a um alvo elevado h_alvo = 0,80 · h_{max} (3,66 m) na hora t* imediatamente anterior ao início da subida diária do consumo, de modo a encher o reservatório antes do horário de maior demanda, conforme a equação (8):

$$\mathbf{\min \Sigma\, (h(t^*) - h_alvo)^2, \quad h_alvo = 0{,}80 \cdot h_{max}} \qquad \text{equação (8)}$$

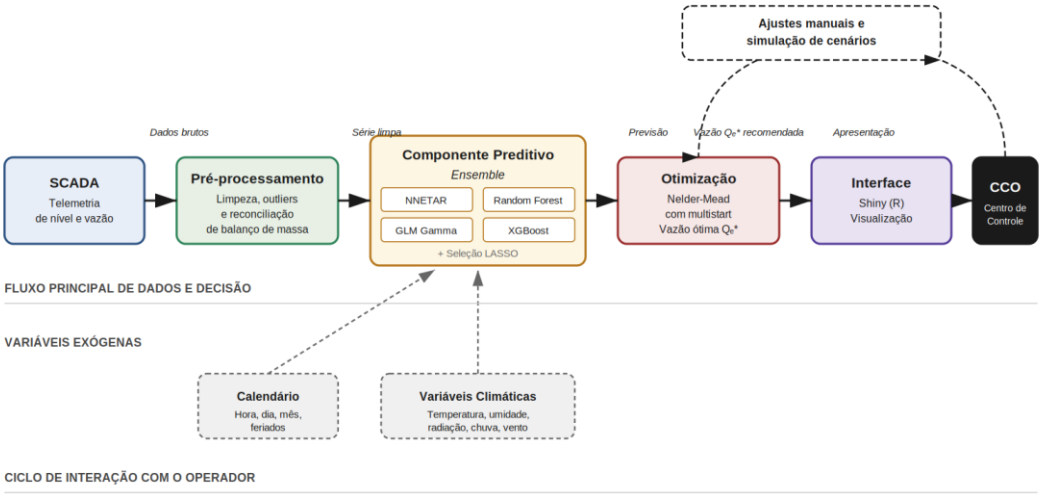
onde h(t*) é o nível na hora t* imediatamente anterior ao início da subida diária do consumo, h_alvo o nível-alvo elevado (0,80 · h_{max}) e h_{max} a altura máxima do reservatório.

Ambas as funções objetivo são resolvidas pelo método de Nelder-Mead (NELDER; MEAD, 1965) com estratégia de *multistart*, método de busca direta adequado à não-suavidade introduzida pelas penalizações e a problemas de dimensão reduzida. A comparação operacional entre as duas funções objetivo, que fundamenta a escolha da operação equilibrada, é apresentada na seção 4.4.

3.5 ARQUITETURA INTEGRADA E IMPLEMENTAÇÃO

A arquitetura foi concebida em camadas (Figura 1): aquisição das séries de nível e vazão do SCADA; pré-processamento (remoção de inválidos, tratamento de *outliers* e reconciliação de balanço); camada preditiva (combinação de previsões); camada de otimização (vazão de entrada recomendada e trajetória de nível esperada); e camada de interface, que apresenta os resultados ao operador e permite simulação de cenários e ajustes manuais.

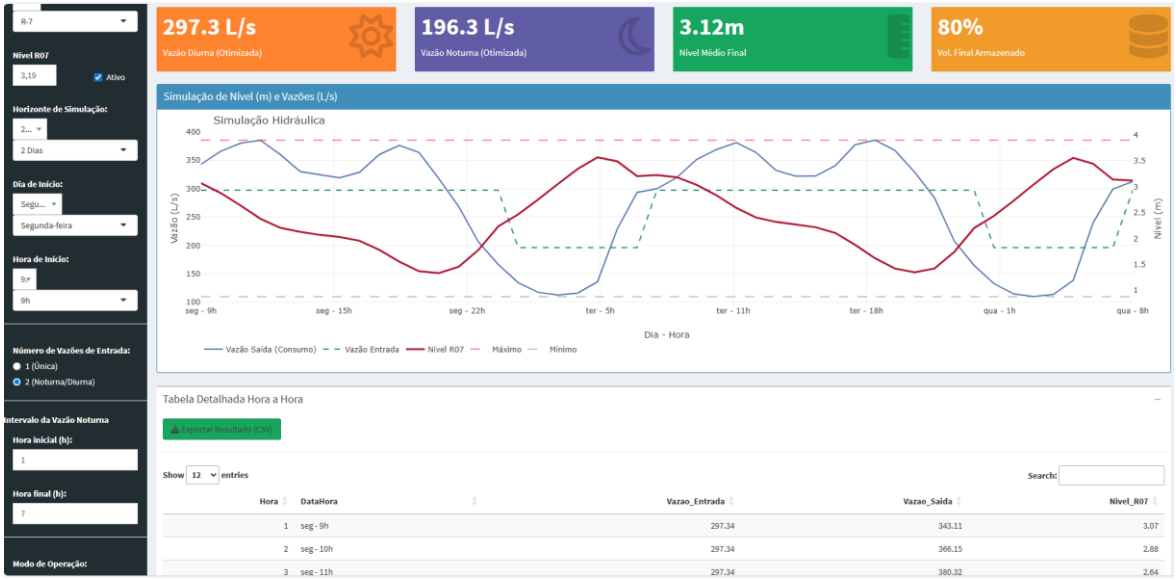
Figura 1 - Arquitetura em camadas do Sistema de Apoio à Decisão



Fonte: elaboração própria (2026).

Os modelos utilizaram os pacotes *forecast* (HYNDMAN; KHANDAKAR, 2008), *randomForest* (LIAW; WIENER, 2002), *glmnet* (FRIEDMAN; HASTIE; TIBSHIRANI, 2010) e *xgboost* (CHEN; GUESTRIN, 2016); a otimização empregou a função optim em método Nelder-Mead. A implementação foi realizada em linguagem R (R CORE TEAM, 2024), com interface no *framework Shiny* (CHANG et al., 2024), organizada em três áreas (Figura 2). À esquerda, um painel de controle reúne os parâmetros da decisão: seleção do reservatório; nível inicial de cada célula, com opção de ativar ou desativar células individuais, horizonte de simulação (1, 2 ou 7 dias), dia e hora de início do planejamento, número de vazões de entrada (única ou noturna/diurna), modo de operação (otimizar a vazão ou simular uma vazão manual), e o objetivo da otimização. No topo, um painel de indicadores sintetiza o resultado em cartões. Ao centro, um gráfico interativo sobrepõe, ao longo do horizonte, a vazão de saída (demanda), a vazão de entrada otimizada, a trajetória de nível de cada célula e as linhas de nível máximo e mínimo, permitindo inspeção visual direta do efeito-pulmão e do respeito à faixa de operação. Abaixo, uma tabela detalhada hora a hora apresenta vazões e volumes de entrada e saída, por célula, e o nível resultante, com exportação para CSV. A ferramenta mantém-se no papel de apoio à decisão: o operador pode alternar entre otimização e simulação manual e ajustar parâmetros, exercendo julgamento próprio sobre a recomendação.

Figura 2 - Tela da ferramenta interativa de apoio à decisão (painel de controle, indicadores, gráfico de simulação e tabela detalhada).



Fonte: elaboração própria (2026).

3.6 PROTOCOLO DE AVALIAÇÃO CONTRAFACTUAL

A avaliação operacional foi conduzida por simulação contrafactual sobre uma janela contínua de operação real, abrangendo de 01 de janeiro a 30 de abril de 2026. A abordagem contrafactual permite avaliar o sistema sobre janela mais longa do que pilotos curtos, além disso é fisicamente válida porque a vazão de saída é determinada pela demanda do setor, não pela estratégia de controle da entrada. Comparam-se dois cenários reconstruídos sobre o mesmo período. No Cenário Real (factual), a operação efetivamente realizada pelo CCO, com vazão de entrada e nível extraídos do log do SCADA e o número de manobras estimado a partir das variações nos comandos da válvula. No Cenário Simulado (contrafactual), para cada dia supõe-se que o operador consulta o sistema à 0h, a combinação de previsões é executada com treino apenas em dados anteriores, o otimizador prescreve a vazão de entrada e a trajetória de nível é reconstruída pela equação (3) usando como demanda exatamente a observada no SCADA, com espaço de busca de 1 a 6.

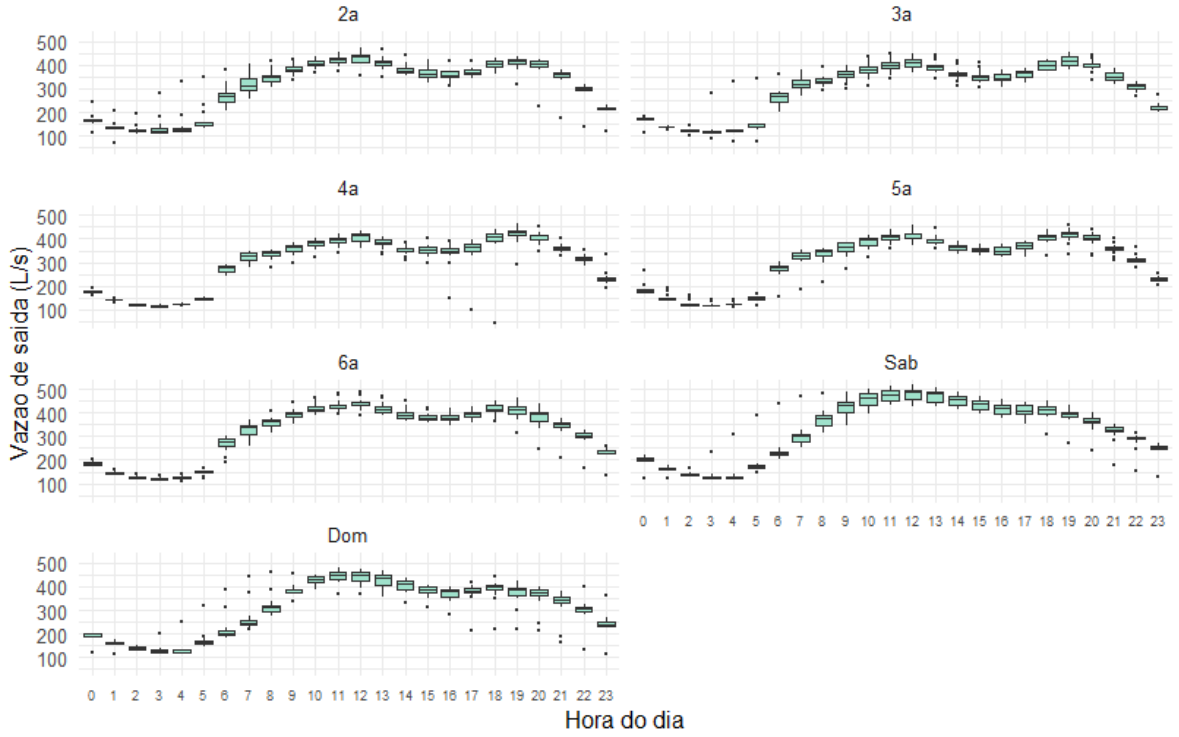
A janela efetiva de avaliação compreende 03 de março a 30 de abril de 2026 (1.382 horas, ≈ 58 dias), reservadas as 1.344 horas iniciais ao primeiro treino. Os indicadores comparados são: número médio diário de manobras (primário), desvio-padrão horário da vazão de entrada (estabilidade da alimentação), percentual de horas com nível dentro da banda segura [h_{min}, h_{max}], amplitude diária do nível (uso do efeito) e horas com violação das restrições. Para isolar o desempenho da política operacional de dias atípicos, reporta-se também o conjunto sem dias anômalos, dias com demanda extrema (≥ 2 horas-outlier) ou com nível inicial real já fora da banda.

4. RESULTADOS E DISCUSSÕES

4.1 CARACTERIZAÇÃO DO CONSUMO DO SETOR ABASTECIDO

O consumo do setor segue o padrão típico de áreas predominantemente residenciais, conforme os diagramas de caixa por dia da semana e hora do dia da Figura 3: vazão baixa na madrugada (0h–5h), forte elevação no período da manhã (6h–9h), patamar elevado ao longo do dia e novo pico no início da noite (18h–21h); aos sábados e domingos os picos deslocam-se para horários mais tardios. Destaca-se que a variabilidade residual em torno de cada par "dia × hora", visível na amplitude interquartil, é relevante, o que justifica o uso de previsão condicional (clima, calendário e história recente) em vez de uma curva média fixa como base da operação.

Figura 3 - Vazão de saída por dia da semana e hora do dia (diagramas de caixa)



Fonte: elaboração própria a partir dos dados SCADA do operador (2026).

4.2 DESEMPENHO PREDITIVO DA COMBINAÇÃO DE PREVISÕES

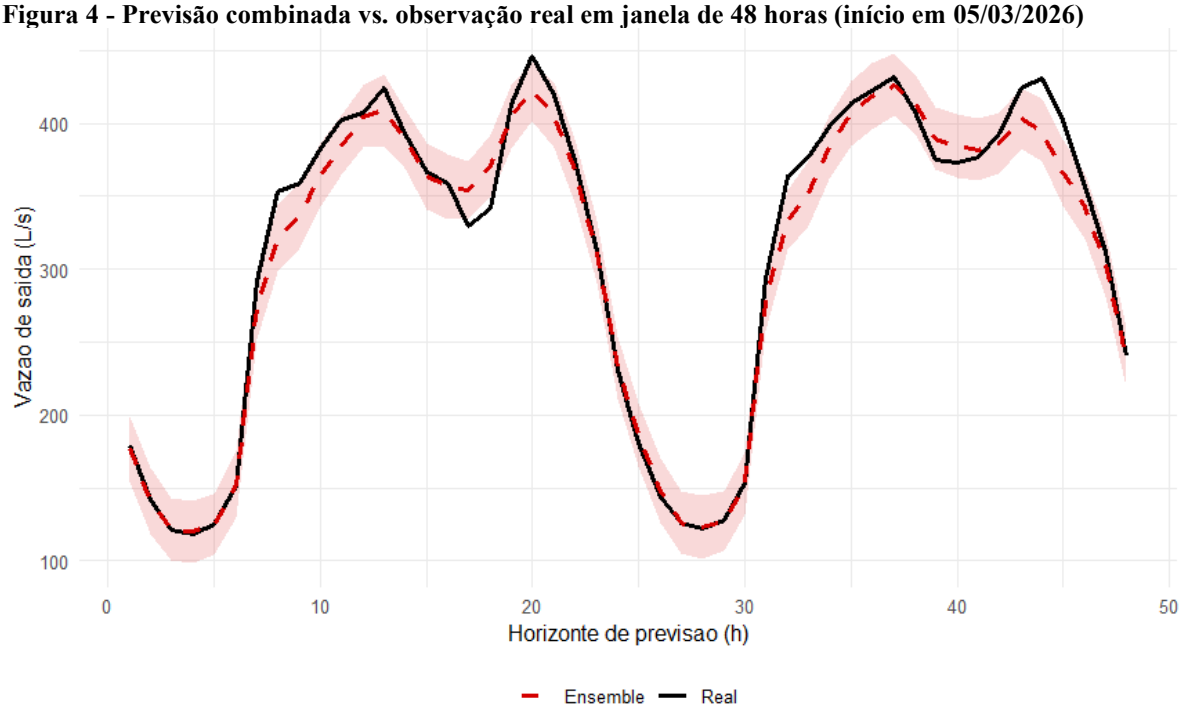
A Tabela 2 compara o erro médio dos quatro modelos e da combinação de previsões, ao longo de todas as janelas de validação. A combinação por média simples obteve o menor erro entre todas as abordagens (MAE 14,18 L/s; MAPE 4,47%), superando o melhor modelo individual, demonstrando a sinergia da combinação e o potencial de melhores resultados. Excluídos os 12 dias atípicos, o MAPE da combinação cai para 3,12%, mantendo a ordenação. Dados os bons resultados de previsão, considera-se que o desempenho é adequado para sustentar a decisão operacional da ferramenta de otimização. A Figura 4 ilustra uma janela de 48 horas de previsão sobreposta à observação real, com o respectivo intervalo de confiança.

Tabela 2 - Métricas médias de erro preditivo (todos os dias)

Modelo	MAE (L/s)	RMSE (L/s)	MAPE (%)
NNETAR	14,59	24,94	4,64
Random Forest	15,30	26,56	4,81
GLM Gamma	15,28	24,38	5,06
XGBoost	16,96	31,45	5,23
Combinação (média simples)	14,18	24,30	4,47

Fonte: elaboração própria (2026). MAE: erro absoluto médio; RMSE: raiz do erro quadrático médio; MAPE: erro percentual absoluto médio.

Figura 4 - Previsão combinada vs. observação real em janela de 48 horas (início em 05/03/2026)



Fonte: elaboração própria (2026).

4.3 AVALIAÇÃO OPERACIONAL POR SIMULAÇÃO CONTRAFACTUAL

A avaliação compreendeu de 03 de março a 30 de abril de 2026 (≈ 58 dias, dos quais 12 anômalos). Entre as funções objetivo disponíveis, adotou-se a de operação equilibrada, que minimiza a variação da vazão de entrada (alimentação estável). A alternativa de "corte de pico", que busca encher o reservatório antes dos horários de maior consumo, foi descartada por elevar substancialmente o desvio-padrão da vazão de entrada (de 48,9 para 67,8 L/s, ou seja, +39% sobre o real), contrariando o objetivo de estabilizar a alimentação e reduzir manobras.

As margens de segurança de nível do reservatório definem o intervalo efetivo de operação, o afastamento em relação ao topo e a base da faixa física. A Tabela 3 resume o efeito de três combinações de pares de margem de segurança, sobre os indicadores (dias normais). A margem de topo de 0,2 m (cenário 0,2/0,4) produz a melhor suavização, menor desvio-padrão (33,0 L/s) e menos manobras (3,3/dia), no entanto gera 9 horas de transbordo, violando o limite superior, dado que esse comportamento não é aceitável, para garantir eficiência operacional, foi adotado margem superior de pelo menos 0,4 m. Com topo de 0,4 m, o cenário 0,4/0,4 é a alternativa ótima em suavização (3,4 manobras/dia, desvio-padrão 40,0 L/s, sem transbordo, faixa de operação equivalente à real). Adotou-se, contudo, como padrão o cenário 0,4/0,6, mais conservador: por priorizar maior tempo no intervalo de operação, atributo crítico em abastecimento de água, ele entrega a maior conformidade de nível (97,3% das horas dentro da faixa), zero transbordo e a menor ocorrência de esvaziamento (29 h contra 48 h da operação real), ao custo de aproximadamente uma manobra a mais por dia frente ao 0,4/0,4.

Tabela 3 - Sensibilidade às margens de segurança (objetivo equilibrado; dias normais)

Cenário (topo/piso)	Manobras/dia	DP de Q_e (L/s)	Perc. Faixa (%)	Amplitude (m)	Transbordo (h)
Real (operação)	7,31	48,85	95,56	2,36	0
0,2/0,4	3,29	33,00	94,91	3,31	9
0,4/0,4	3,44	40,04	95,74	3,08	0
0,4/0,6 (adotado)	4,16	45,89	97,31	2,90	0

Fonte: elaboração própria (2026). DP = desvio-padrão. Perc. Faixa = percentual de horas com o nível dentro de [h_{min}, h_{max}].

A Tabela 4 compara os dois cenários no objetivo equilibrado com a margem adotada (0,4/0,6 m), apresentando o conjunto completo e o conjunto sem os 12 dias atípicos. O indicador primário, manobras por dia, caiu de 7,05 para 4,16 considerando todos os dias (redução de 41%, indo de 402 para 237 manobras no período) e de 7,31 para 4,16 excluídos os dias atípicos (redução de 43%, de 329 para 187). Em termos absolutos, ao longo de cerca de dois meses a ferramenta exigiria da ordem de 190 a 240 ajustes de válvula, contra mais de 400 efetivamente realizados.

Tabela 4 - Indicadores operacionais: Cenário Real vs. Simulado (objetivo equilibrado, margem 0,4/0,6 m)

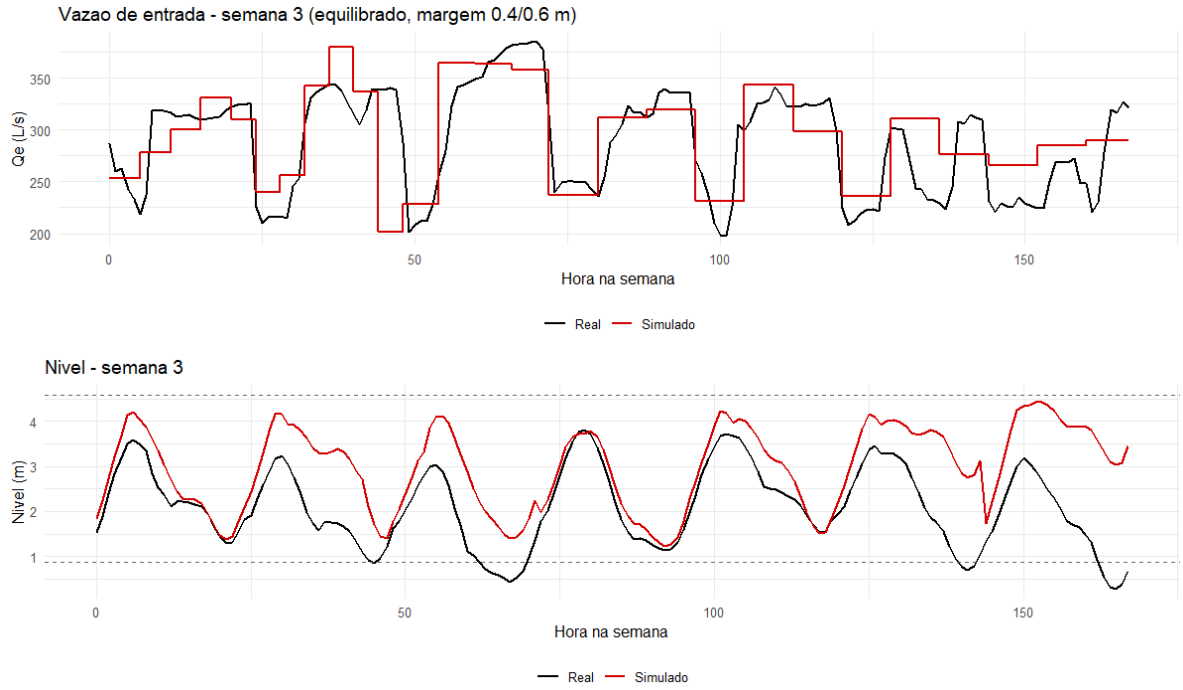
Indicador	Real (todos)	Sim. (todos)	Real (s/ atíp.)	Sim. (s/ atíp.)
Manobras médias/dia	7,05	4,16	7,31	4,16
Total de manobras no período	402	237	329	187
Desvio-padrão de Q_e (L/s)	48,46	48,49	48,85	45,89
Horas na banda (%)	94,88	95,47	95,56	97,31
Amplitude diária média (m)	2,42	2,97	2,36	2,90
Horas com violação	70	62	48	29

Fonte: elaboração própria (2026). a partir dos dados SCADA do operador e da simulação contrafactual. “s/ atíp.” = sem os 12 dias atípicos.

A amplitude diária média do nível aumentou de 2,42 para 2,97 m (+23%), refletindo o aproveitamento mais pleno do efeito-pulmão. O percentual de horas com o nível dentro da banda manteve-se equivalente ao da operação real (95,5% contra 94,9% no conjunto completo e 97,3% contra 95,6% excluídos os dias atípicos), confirmando que a redução de manobras não se deu às custas da segurança. O desvio-padrão da vazão de entrada ficou equivalente ao real considerando todos os dias (48,5 L/s em ambos) e reduziu-se cerca de 6% (45,9 contra 48,9 L/s) nos dias normais, nos 12 dias atípicos, de demanda extrema ou nível inicial já fora da banda, o otimizador precisa impor degraus de vazão mais amplos para recolocar o reservatório na faixa segura, o que eleva a dispersão.

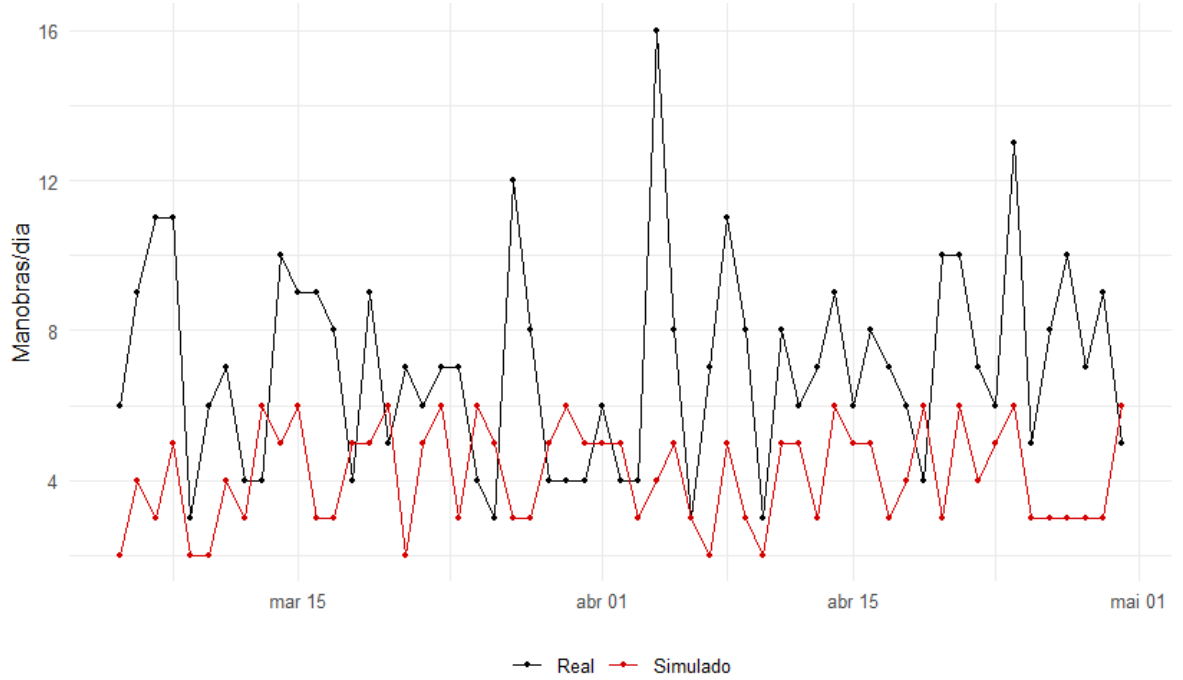
As Figuras 5 a 7 ilustram esses resultados. A Figura 5 sobrepõe, em uma semana representativa, a vazão de entrada e o nível dos dois cenários: a operação real corrige a vazão muitas vezes ao dia, enquanto a simulada opera em poucos patamares, com o nível percorrendo melhor a banda. A Figura 6 mostra as manobras diárias ao longo de todo o período, evidenciando o patamar consistentemente menor do cenário simulado. A Figura 7 sintetiza a variação percentual dos indicadores frente à operação real (dias normais): no objetivo equilibrado, todos os indicadores são favoráveis, manobras −43%, desvio-padrão −6%, horas na banda +2% e amplitude +23%.

Figura 5 - Vazão de entrada e nível nos cenários Real e Simulado em semana representativa (objetivo equilibrado, margem 0,4/0,6 m)



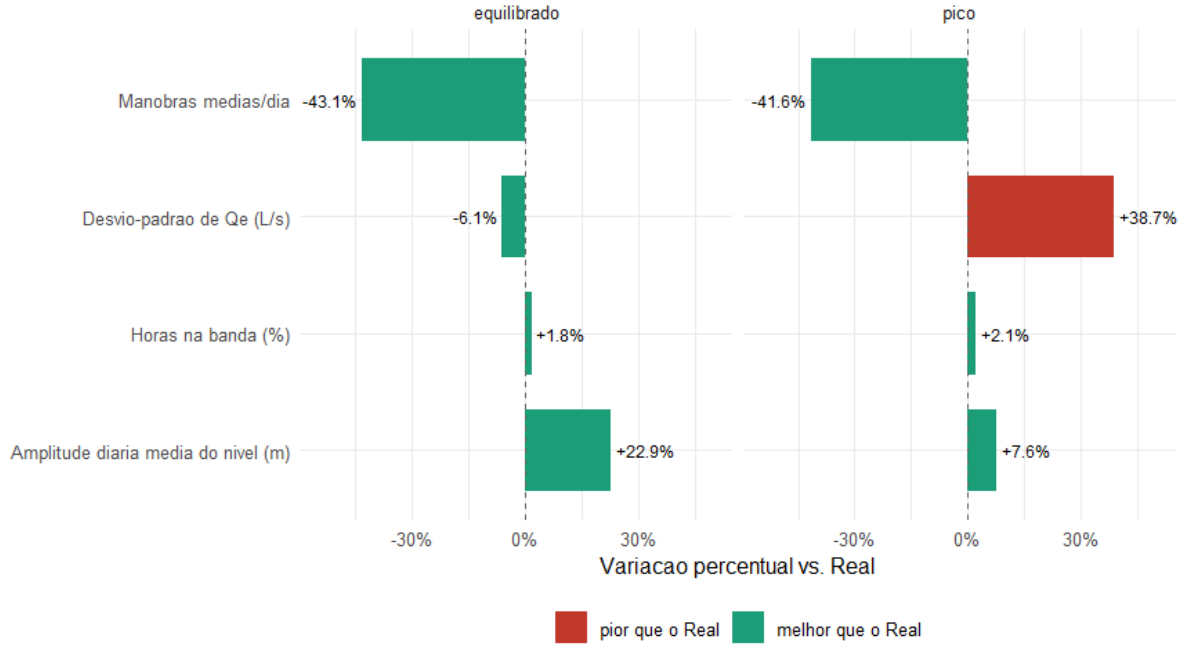
Fonte: elaboração própria (2026) a partir dos dados SCADA do operador e da simulação contrafactual.

Figura 6 - Manobras diárias nas válvulas de entrada ao longo do período: Real vs. Simulado



Fonte: elaboração própria (2026).

Figura 7 - Variação percentual dos indicadores operacionais frente à operação real (objetivos equilibrado e de pico em dias normais)



Fonte: elaboração própria (2026).

Em síntese, a ferramenta transforma a operação reativa em uma rotina antecipatória e auditável, reduzindo a dependência da experiência tácita do operador e padronizando a decisão. Construída integralmente sobre *software* livre (R e *Shin*), constitui um desenvolvimento tecnológico de baixo custo de adoção e diretamente transferível, atributo especialmente relevante para operadoras de pequeno e médio porte. Cabe ressaltar que os parâmetros aqui calibrados (geometria, banda e margens) são específicos do reservatório de estudo; a aplicação a outros reservatórios exige recalibração do componente preditivo e reavaliação das margens, e a validação prospectiva em campo permanece como passo recomendado.

5. CONCLUSÕES E RECOMENDAÇÕES

Este trabalho desenvolveu, implementou e avaliou um Sistema de Apoio à Decisão (SAD) para a operação de curto prazo de reservatórios de abastecimento de água. Mais do que um modelo isolado, o resultado é um desenvolvimento tecnológico concreto e aplicável: a integração, em uma única ferramenta operacional, de uma camada preditiva por combinação de quatro modelos de aprendizado de máquina, de um módulo de otimização não-linear da vazão de entrada e de uma interface interativa que entrega ao operador uma recomendação clara e auditável. Toda a solução foi construída sobre *software* livre (linguagem R e *framework Shiny*), sem dependência de licenciamento proprietário, o que a torna transferível e de baixo custo de adoção. É essa integração ponta a ponta, desde a telemetria à decisão operacional, que constitui o principal diferencial técnico do trabalho.

A análise da formulação demonstrou que, sob o critério de alimentação constante, a vazão de entrada que mantém o reservatório em ciclo é igual à média da demanda no horizonte, valor que não é observável no momento da decisão. Disso decorre uma conclusão central: a obtenção de uma previsão de demanda acurada é fator de decisão crítico na operação de reservatórios, pois a qualidade da prescrição operacional fica limitada, em primeira ordem, pela qualidade da previsão. A combinação de previsões adotada, ao agregar modelos de vieses distintos, mostrou-se a abordagem de menor erro e, portanto, a base mais confiável para a decisão.

A avaliação por simulação contrafactual sobre cerca de dois meses de operação real indicou redução de aproximadamente 41% no número diário de manobras nas válvulas de entrada (de 7,0 para 4,2 por dia; 43% excluídos os dias atípicos), aumento de 23% na amplitude diária do nível, sinal de melhor aproveitamento do efeito-pulmão, e manutenção do nível dentro da faixa de segurança em proporção equivalente à da operação

real. A escolha da margem de segurança 0,4/0,6 m, mais conservadora, privilegiou a conformidade de banda e a ausência de transbordo, prioridade no contexto do saneamento.

Para além dos ganhos quantitativos, os SAD baseados em dados contribuem, na prática, em múltiplas dimensões da gestão operacional. Primeiro, ampliam a previsibilidade do planejamento, ao antecipar o comportamento da demanda em horizonte útil e transformar a operação reativa em antecipatória. Segundo, sustentam a tomada de decisão baseada em dados, substituindo a leitura visual de painéis por uma recomendação quantitativa e rastreável. Terceiro, reduzem a complexidade da operação, condensando a decisão em poucas manobras programadas por dia, em vez de múltiplas correções contínuas. Quarto, favorecem a padronização dos processos, ao oferecer um critério único e auditável que independe do turno ou do operador de plantão, mitigando a dependência da experiência tácita individual. Por fim, promovem a democratização da informação, ao tornar explícitos e compartilháveis os fundamentos de cada decisão, atributo crescentemente exigido por marcos regulatórios e por planos de continuidade operacional.

Recomenda-se, como trabalhos futuros, a recalibração e a validação para reservatórios com características distintas (regimes de demanda industrial, turístico ou com perdas significativas), a validação prospectiva em ambiente operacional real, com adoção supervisionada no CCO, e a incorporação do custo energético tarifário e da coordenação multi-reservatório à função objetivo. Os resultados demonstram que a transição de uma cultura operacional reativa, dependente da experiência individual, para uma cultura antecipatória e baseada em dados é tecnicamente viável com ferramentas de domínio público, com ganhos operacionais mensuráveis em escala de poucas semanas.

REFERÊNCIAS BIBLIOGRÁFICAS

1. ALVISI, S. et al. Battle of Water Demand Forecasting. Journal of Water Resources Planning and Management, v. 151, n. 10, art. 04025049, 2025.
2. BATES, J. M.; GRANGER, C. W. J. The combination of forecasts. *Operational Research Quarterly*, v. 20, n. 4, p. 451-468, 1969.
3. BREIMAN, L. Random forests. *Machine Learning*, v. 45, n. 1, p. 5-32, 2001.
4. CHANG, W. et al. *shiny*: Web Application Framework for R. R package version 1.8.0. 2024. Disponível em: https://CRAN.R-project.org/package=shiny.
5. CHATFIELD, C. *The analysis of time series*: an introduction. 6th ed. Boca Raton: Chapman & Hall/CRC, 2004.
6. CHEN, T.; GUESTRIN, C. XGBoost: a scalable tree boosting system. In: ACM SIGKDD INTERNATIONAL CONFERENCE ON KNOWLEDGE DISCOVERY AND DATA MINING, 22., 2016, San Francisco. *Proceedings*... New York: ACM, 2016. p. 785-794.
7. DONKOR, E. A.; MAZZUCHI, T. A.; SOYER, R.; ROBERSON, J. A. Urban water demand forecasting: review of methods and models. *Journal of Water Resources Planning and Management*, v. 140, n. 2, p. 146-159, 2014.
8. FRIEDMAN, J.; HASTIE, T.; TIBSHIRANI, R. Regularization paths for generalized linear models via coordinate descent. *Journal of Statistical Software*, v. 33, n. 1, p. 1-22, 2010.
9. HERRERA, M.; TORGO, L.; IZQUIERDO, J.; PÉREZ-GARCÍA, R. Predictive models for forecasting hourly urban water demand. *Journal of Hydrology*, v. 387, n. 1-2, p. 141-150, 2010.
10. HYNDMAN, R. J.; ATHANASOPOULOS, G. *Forecasting*: principles and practice. 3rd ed. Melbourne: OTexts, 2021.
11. HYNDMAN, R. J.; KHANDAKAR, Y. Automatic time series forecasting: the forecast package for R. *Journal of Statistical Software*, v. 27, n. 3, p. 1-22, 2008.
12. KAPELAN, Z. S.; SAVIC, D. A.; WALTERS, G. A. Multiobjective design of water distribution systems under uncertainty. *Water Resources Research*, v. 41, n. 11, W11407, 2005.

13. LIAW, A.; WIENER, M. Classification and regression by randomForest. *R News*, v. 2, n. 3, p. 18-22, 2002.

14. MAYS, L. W. *Water resources engineering*. 2nd ed. Hoboken: John Wiley & Sons, 2010.

15. NELDER, J. A.; MEAD, R. A simplex method for function minimization. *The Computer Journal*, v. 7, n. 4, p. 308-313, 1965.

16. ORMSBEE, L. E.; LANSEY, K. E. Optimal control of water supply pumping systems. *Journal of Water Resources Planning and Management*, v. 120, n. 2, p. 237-252, 1994.

17. PETROPOULOS, F. et al. Forecasting: theory and practice. *International Journal of Forecasting*, v. 38, n. 3, p. 705-871, 2022.

18. R CORE TEAM. *R*: a language and environment for statistical computing. Vienna: R Foundation for Statistical Computing, 2024. Disponível em: https://www.R-project.org/.

19. SAVIC, D. A.; BICIK, J.; MORLEY, M. S. A DSS generator for multiobjective optimisation of spreadsheet-based models. *Environmental Modelling & Software*, v. 26, n. 5, p. 551-561, 2011.

20. TIBSHIRANI, R. Regression shrinkage and selection via the lasso. *Journal of the Royal Statistical Society: Series B (Methodological)*, v. 58, n. 1, p. 267-288, 1996.

21. TSUTIYA, M. T. *Abastecimento de água*. 3. ed. São Paulo: Departamento de Engenharia Hidráulica e Sanitária da Escola Politécnica da USP, 2006.