# INFERÊNCIA VIRTUAL DE PRESSÃO EM PONTO CRÍTICO UTILIZANDO TURBINA REDUTORA DE PRESSÃO E APRENDIZADO DE MÁQUINA PARA GARANTIA DO ABASTECIMENTO E APOIO À REDUÇÃO DE PERDAS

**Rafael Amorim Faleiros**[(1)]
Graduando em Engenharia Elétrica (UNIFRAN), Engenharia de Computação (UNIVESP) e pesquisador em Iniciação Científica. Atua como desenvolvedor no setor industrial, com experiência em automação, sistemas embarcados, arquiteturas IoT, banco de dados e desenvolvimento de sistemas SCADA.

**Endereço**[(1)]**:** Av. Dr. Armando de Sáles Oliveira, 201 - Parque Universitário - Franca - SP - CEP: 14404-600 - Brasil - Tel: +55 (16) 3711-8888 - e-mail: r.amorim@cs.unifran.edu.br .

## RESUMO

O monitoramento da pressão em pontos críticos é essencial para a universalização do abastecimento. Integrado ao controle ativo, permite operar com menores pressões excedentes e reduzir perdas reais. Contudo, essa operação esbarra em obstáculos tecnológicos: a dificuldade de acesso à rede elétrica e a dependência de *dataloggers* a bateria, que exigem grandes intervalos de transmissão. Este trabalho apresenta e valida uma solução inovadora: a combinação de uma turbina redutora de pressão (TRP) com um modelo de aprendizado de máquina para inferência virtual da pressão no ponto crítico. A TRP, instalada estrategicamente, mede variáveis hidráulicas continuamente, enquanto um *datalogger* monitora o ponto crítico. A campanha de 13/05/2026 a 05/06/2026 gerou 2.856 leituras pareadas. O modelo de regressão, treinado e operado em aprendizado contínuo, passou a estimar a pressão instantânea no ponto crítico apenas com dados da TRP, restringindo o *datalogger* a validações pontuais. A validação confirmou alta precisão: erro médio absoluto de 0,162 mca, raiz do erro quadrático médio de 0,252 mca e $R^2$ de 0,9942. Os resultados comprovam que a solução garante o abastecimento nos trechos vulneráveis e apoia a redução de perdas ao viabilizar operações com menores pressões excedentes.

**PALAVRAS-CHAVE:** Ponto crítico, Controle de perdas, TRP

## INTRODUÇÃO

A escassez hídrica e os impactos severos das mudanças climáticas elevaram a gestão de perdas nos sistemas de abastecimento de água ao patamar de urgência humanitária e regulatória. Em âmbito global, o controle eficiente dos recursos hídricos é diretriz fundamental do Objetivo de Desenvolvimento Sustentável 6 (ODS 6) da Organização das Nações Unidas (ONU), que preconiza garantir a disponibilidade e gestão sustentável de água potável e saneamento para todos. No cenário brasileiro, a ineficiência operacional deixou de ser uma mera variável econômica para se tornar uma grave restrição legal. Com a promulgação do Novo Marco Legal do Saneamento Básico (Lei nº 14.026/2020), estabeleceram-se metas rigorosas de universalização — que exigem o atendimento de 99% da população com água potável até 2033 —, além de diretrizes que obrigam as concessionárias a reduzirem drasticamente seus índices de perdas na distribuição, sob o risco de sanções e caducidade de contratos (TRATA BRASIL; GO ASSOCIADOS, 2023).

Para o cumprimento dessas exigências, o controle e a gestão de pressões despontam como a estratégia técnica mais eficaz (ABES, 2015). Pressões demasiadamente elevadas na rede de distribuição aceleram a fadiga da infraestrutura, multiplicando a frequência de rompimentos e o volume de vazamentos ocultos. Por outro lado, o subdimensionamento dessas pressões afeta diretamente a população, gerando intermitência e episódios de desabastecimento, especialmente nos setores topograficamente mais elevados ou periféricos. O impacto dessas inadequações operacionais é severo e atinge múltiplas frentes. No âmbito social, certas localidades enfrentam intervalos de abastecimento precário, uma situação que costuma ser regularizada de forma puramente reativa, somente após a notificação de queixas por parte dos consumidores. Simultaneamente, no âmbito ambiental e econômico, o desperdício de recursos hídricos onera pesadamente as companhias de saneamento. Além da perda de um volume de água tratada que poderia ser redirecionado para o abastecimento de outras regiões, somam-se os altos custos operacionais decorrentes da perda de faturamento e do deslocamento constante de equipes para manutenções e reparos emergenciais na rede.

Para equilibrar a integridade da rede com a garantia do nível de serviço, a operação orientada pelo "ponto crítico" — o nó hidraulicamente mais desfavorecido de um setor — assume papel central (AWWA, 2016; BEZERRA; CHEUNG, 2013). Operar a rede com base no ponto crítico permite ajustar a pressão do sistema ao menor patamar operacional compatível com a garantia do abastecimento nos pontos hidraulicamente mais desfavorecidos. Essa estratégia não elimina os vazamentos existentes, mas contribui para reduzir pressões excedentes, diminuindo a vazão dos vazamentos, a frequência de rompimentos e os esforços hidráulicos sobre a infraestrutura (CARDOSO et al., 2013). Quando associada ao controle ativo de pressão e ao monitoramento contínuo da rede, essa abordagem também pode favorecer a redução do consumo energético em sistemas dependentes de bombeamento.

Contudo, a implantação plena dessa premissa esbarra em um obstáculo tecnológico: o monitoramento remoto intermitente. Tradicionalmente, a medição no ponto crítico é realizada por *dataloggers* — dispositivos eletrônicos autônomos projetados para monitorar, medir, registrar e transmitir dados automaticamente ao longo do tempo. Esses equipamentos são dotados de transdutores de pressão e dependem exclusivamente de baterias para o seu funcionamento. O uso de alimentação autônoma é essencial para viabilizar a instalação nos pontos requisitados, visto que a conexão à rede elétrica convencional nesses locais mostra-se, na grande maioria das vezes, logisticamente complexa e inviável. O revés dessa arquitetura é a limitação energética: para garantir que a vida útil das baterias se estenda por anos, as companhias de saneamento são forçadas a configurar grandes intervalos de medição e de transmissão de dados, operando na escala de horas.

Essa baixa densidade de dados cria uma verdadeira "cegueira operacional". Omitindo fenômenos transitórios, picos de demanda, manobras operacionais, eventos de vazamento e outras anomalias de rede, o monitoramento espaçado impede o uso do ponto crítico como variável de controle em tempo real, restringindo seu uso apenas para análise histórica limitada. Consequentemente, para evitar o risco de desabastecimento, as operadoras injetam pressões com margens de segurança, alimentando o ciclo de perdas reais e desperdício energético.

Como resposta a essas limitações estruturais, soluções tecnológicas alinhadas ao conceito de Cidades Inteligentes (*Smart Cities*) vêm sendo integradas aos distritos de medição e controle para reduzir perdas reais. Destaca-se o emprego de Turbinas Redutoras de Pressão (TRP) que, ao aproveitarem o próprio potencial hidráulico para a geração de energia, tornam-se nós autossustentáveis. Estudos de caso recentes demonstram que a substituição de válvulas redutoras de pressão mecânicas por TRPs resulta em reduções expressivas das perdas hídricas, oferecendo uma infraestrutura robusta para controle de pressão, macromedição e telemetria ininterrupta (BETTARELLO; PIRES, 2024).

Embora a TRP atue diretamente na regulação a jusante do setor, o presente artigo explora o uso contínuo de seus dados operacionais para superar o gargalo da latência no ponto crítico. A proposta central deste estudo é o desenvolvimento de um "sensor virtual" por meio de aprendizado de máquina (*Machine Learning*).

A hipótese científica central deste estudo postula que o conjunto de variáveis hidráulicas coletadas ininterruptamente por uma Turbina Redutora de Pressão em um nó estratégico de controle contém informação latente e correlação sistêmica suficientes para inferir, por meio de modelos não lineares, a pressão instantânea em um ponto crítico hidraulicamente acoplado. Valida-se, assim, a substituição da necessidade de aferição remota constante por um “sensor virtual” impulsionado por aprendizado de máquina.

Adotando as diretrizes metodológicas de um estudo de caso prático (YIN, 2015), foi conduzida uma campanha de coleta em campo (maio a junho de 2026), baseando a inferência em um algoritmo de aprendizado de máquina. Este trabalho apresenta a arquitetura da solução, os tratamentos da base de dados e a validação do modelo, discutindo como a inferência virtual possibilita um controle dinâmico e preventivo. Ao reduzir a dependência de transmissões frequentes de dispositivos alimentados por bateria, a solução amplia a visibilidade operacional sobre o ponto crítico e fortalece a gestão do abastecimento nos trechos mais vulneráveis da rede. Com isso, torna-se possível preservar as condições mínimas de atendimento e, ao mesmo tempo, apoiar estratégias de redução de perdas reais, uma vez que a operação passa a dispor de informações mais precisas para reduzir pressões excedentes sem aumentar o risco de desabastecimento.

## OBJETIVOS

O objetivo geral deste estudo é desenvolver e avaliar uma solução de monitoramento virtual de pressão em ponto crítico, baseada na integração entre turbina redutora de pressão, *datalogger* e modelo de aprendizado de

máquina, visando aprimorar a gestão operacional do abastecimento em pontos hidraulicamente desfavorecidos e apoiar estratégias de redução de perdas reais por meio de um controle mais seguro das pressões excedentes na rede. Para o alcance dessa meta, delinearam-se os seguintes objetivos específicos:

- Caracterizar as limitações do monitoramento tradicional de ponto crítico realizado exclusivamente com *dataloggers* alimentados por bateria, em termos de frequência de medição, densidade de dados e aplicabilidade ao controle em tempo real.
- Descrever a arquitetura proposta, que integra turbina redutora de pressão, *datalogger* em ponto crítico e modelo de regressão baseado em aprendizado de máquina, contextualizando-a no escopo de tecnologias para redução de perdas já avaliadas em estudos anteriores com TRP.
- Coletar e tratar uma base de dados pareada entre variáveis medidas na TRP e pressão real no ponto crítico, ao longo do período de 13/05/2026 a 05/06/2026, garantindo qualidade e representatividade das amostras.
- Treinar, validar e aplicar em regime de aprendizado contínuo um modelo de inferência virtual de pressão, quantificando sua acurácia por meio de métricas estatísticas como erro médio absoluto, raiz do erro quadrático médio e coeficiente de determinação.
- Discutir a aplicação prática da solução no contexto da gestão do abastecimento e do controle operacional de pressão por ponto crítico, destacando sua contribuição para preservar pressões mínimas nos pontos mais vulneráveis da rede, apoiar a redução de perdas reais por meio da diminuição de pressões excedentes, bem como suas limitações, necessidade de recalibração e perspectivas de evolução para diagnósticos mais completos dos sistemas de distribuição de água.

## METODOLOGIA UTILIZADA

O estudo foi conduzido em um setor de abastecimento de água dotado de uma turbina redutora de pressão (TRP) instalada em um ponto estratégico da rede, a montante da área de consumo atendida. A TRP atua simultaneamente como elemento de controle de pressão e como plataforma de medição e telemetria. Devido à sua capacidade de gerar a própria energia por meio da quebra de pressão, o equipamento dispõe de energia ilimitada para a coleta contínua de dados, funcionalidade essencial para a viabilização deste estudo. A Tabela 1 detalha as variáveis hidráulicas monitoradas com alta granularidade.

**Tabela 1 - Variáveis Monitoradas pela TRP**

| Variável | Unidade | Descrição |
|---|---|---|
| Pressão Montante | MCA | Pressão na entrada da TRP |
| Pressão Jusante | MCA | Pressão na saída da TRP (pressão fornecida para rede) |
| Vazão Instantânea | L/s | Vazão de água instantânea passando pela TRP para abastecimento da rede |
| Abertura da Turbina | Graus (°) | Posição específica do perfil da turbina para suprir o atendimento necessário em condições pontuais de consumo |
| Velocidade do Fluxo de Água | m/s | Velocidade do fluxo de água que passa pela turbina para abastecimento da rede. |

Fonte: Elaborado pelo Autor.

Graças a essa autossuficiência energética, os sensores operam de forma ininterrupta, transmitindo dados para um servidor sem a necessidade de baterias de longa duração. O ponto crítico do setor, definido por critérios de cota altimétrica e distância hidráulica, recebeu um *datalogger* tradicional (alimentado por baterias) para registrar a pressão real no local, servindo como base de aprendizado.

Para fundamentar a modelagem, uma campanha de coleta de dados foi realizada entre 13/05/2026 e 05/06/2026. Nesse período, a TRP registrou as variáveis em intervalos de poucos segundos, enquanto o *datalogger* operou em intervalos de dezenas de minutos para garantir boa resolução na fase inicial de treinamento. A primeira semana gerou a base estática de treinamento (mais de 1.000 amostras), seguida por uma segunda fase de

operação contínua onde o algoritmo recebeu novas leituras para validação e retroalimentação, consolidando um banco de dados com 2.856 amostras.

O tráfego e sincronismo dos dados foram orquestrados por um *middleware* de integração desenvolvido especificamente para este fim. Essa Interface de Programação de Aplicações (API) operou de forma assíncrona: a cada pacote de dados emitido pelo *datalogger*, a API interceptava a requisição e comandava uma varredura instantânea nos registradores da TRP, garantindo o alinhamento temporal exato. O processamento subsequente envolveu rotinas de higienização para a exclusão de *outliers* decorrentes de latência, formatando os vetores de entrada (*features*) a partir da TRP e a variável de saída (*target*) a partir do *datalogger*.

Para a etapa de inferência preditiva, foi desenvolvido um modelo supervisionado de regressão, destinado a estimar a pressão no ponto crítico a partir das variáveis hidráulicas monitoradas continuamente pela Turbina Redutora de Pressão. A escolha da abordagem considerou a necessidade de representar relações não lineares entre vazão, pressões, condição operacional da turbina e resposta hidráulica da rede, bem como a robustez frente a ruídos e pequenas inconsistências típicas de medições em campo.

O modelo foi estruturado a partir de uma base pareada de dados, composta por leituras da TRP e medições reais obtidas no ponto crítico. As amostras foram tratadas, sincronizadas e particionadas para treinamento e validação, permitindo avaliar a capacidade do modelo de generalizar o comportamento hidráulico do setor analisado. A calibração foi conduzida de forma iterativa, buscando equilíbrio entre precisão preditiva, estabilidade operacional e viabilidade de aplicação em ambiente de monitoramento contínuo.

Por se tratar de uma solução tecnológica aplicada e com potencial de uso operacional, os detalhes específicos da arquitetura computacional, dos parâmetros internos de modelagem e das rotinas proprietárias de atualização do modelo não são apresentados neste trabalho. A validação da solução é demonstrada por meio das métricas estatísticas de desempenho, incluindo erro médio absoluto, raiz do erro quadrático médio e coeficiente de determinação, bem como pela comparação entre pressões medidas e pressões estimadas no ponto crítico.

Por fim, a avaliação do desempenho do modelo foi ancorada em três métricas principais: Erro Médio Absoluto (MAE), Raiz do Erro Quadrático Médio (RMSE) e Coeficiente de Determinação ($R^2$). Tais métricas forneceram o suporte matemático e estatístico necessário para a validação de modelos aplicados à engenharia e análise de dados complexos (MONTGOMERY; RUNGER, 2012). Complementarmente, a avaliação qualitativa empregou análises de dispersão e o contraste temporal de transientes, simulando o cenário onde o *datalogger* físico passa a atuar apenas com transmissões reduzidas para eventual recalibração.

O conjunto de dados foi particionado em subconjuntos de treinamento e de teste, seguindo as melhores práticas de validação estatística e aprendizado supervisionado para assegurar uma avaliação fidedigna da capacidade preditiva do modelo (HASTIE; TIBSHIRANI; FRIEDMAN, 2009). O modelo foi treinado sobre o conjunto de treinamento e, em seguida, a capacidade de generalização foi avaliada no conjunto de teste utilizando métricas específicas de regressão.

Na etapa de inferência virtual, o modelo foi alimentado exclusivamente com dados provenientes da TRP, gerando estimativas contínuas de pressão no ponto crítico. Em momentos pontuais, essas estimativas foram comparadas com novas leituras obtidas pelo *datalogger* operando com frequência de transmissão reduzida, simulando o cenário real em que o *datalogger* passa a ser usado apenas para validação e recalibração.

## RESULTADOS OBTIDOS

Entre 13/05/2026 e 05/06/2026, foram obtidas 2.856 amostras pareadas, combinando variáveis medidas na TRP e a pressão real no ponto crítico. Essa amostragem contemplou a diversidade operacional do setor, capturando oscilações de demanda em diferentes dias e horários, o que proporcionou uma base de treinamento robusta e fiel ao cotidiano da rede.

As variações de pressão observadas no ponto crítico são reflexos da estratégia de controle do setor, que utiliza a Turbina Redutora de Pressão para operar com *setpoints* variáveis. Esses valores são ajustados conforme cronogramas de consumo previstos para cada dia da semana, gerando diferentes patamares de pressão no ponto

monitorado. Tal heterogeneidade de cenários é fundamental para que o modelo de aprendizado de máquina compreenda a dinâmica sistêmica e seus impactos nas perdas reais.

A validação do modelo indicou um desempenho altamente satisfatório para o ambiente operacional. As principais métricas apuradas sobre as amostras coletadas (conjunto de testes e operação em tempo real) foram:

- Erro médio absoluto (MAE): 0,162 mca.

O MAE de 0,162 mca significa que, em média, o módulo da diferença entre a pressão prevista e a pressão real no ponto crítico foi inferior a 17 centímetros de coluna d'água, levando em consideração a pressão média observada nesse período isso corresponde a um erro médio de 1,47%. Considerando a escala de variação típica de pressões em sistemas de distribuição, esse nível de erro é marginal, sendo em muitos casos inferior à própria incerteza intrínseca dos transdutores de pressão de campo.

- Raiz do erro quadrático médio (RMSE): 0,252 mca.

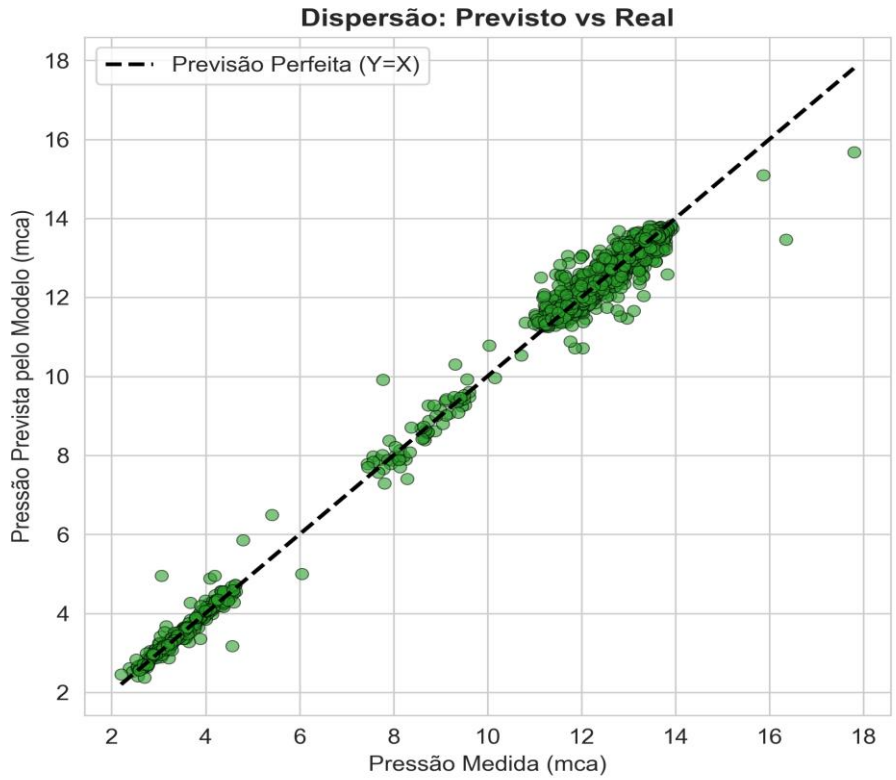
O RMSE de 0,252 mca reforça essa percepção, indicando que erros maiores também são relativamente raros e mantêm magnitude compatível com aplicações operacionais críticas.

- Coeficiente de determinação ($R^2$): 0,9942.

O coeficiente ($R^2$) de 0,9942 evidencia que mais de 99,4% da variância observada no ponto crítico é perfeitamente explicada pelo modelo, confirmando a forte correlação entre as medições da TRP e o comportamento da extremidade da rede.

A qualidade das estimativas geradas pode ser visualmente atestada na Figura 1, que apresenta o diagrama de dispersão dos valores previstos versus os valores reais medidos em campo. Observa-se um conjunto de pontos fortemente concentrados e alinhados sobre a reta de referência ideal (Y=X). Essa aderência visual confirma a elevada capacidade de generalização do algoritmo para diferentes regimes de pressão.

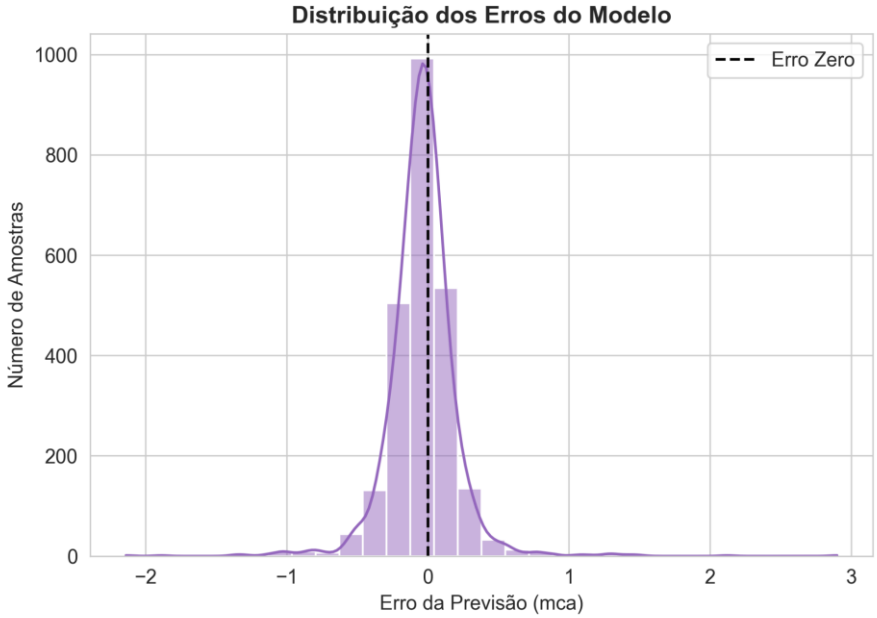
**Figura 1 - Dispersão dos valores de pressão previstos versus valores reais medidos em campo.**




Fonte: Elaborado pelo autor.

Complementarmente, a Figura 2 ilustra o histograma da distribuição dos erros (resíduos) do modelo. A distribuição apresenta-se predominantemente simétrica e centrada em zero, sem evidências de viés sistemático (subestimação ou superestimação crônica) ao longo da faixa de operação. As caudas rapidamente decrescentes confirmam que discrepâncias maiores são eventos raros, não comprometendo o uso do modelo para o controle operacional diário.

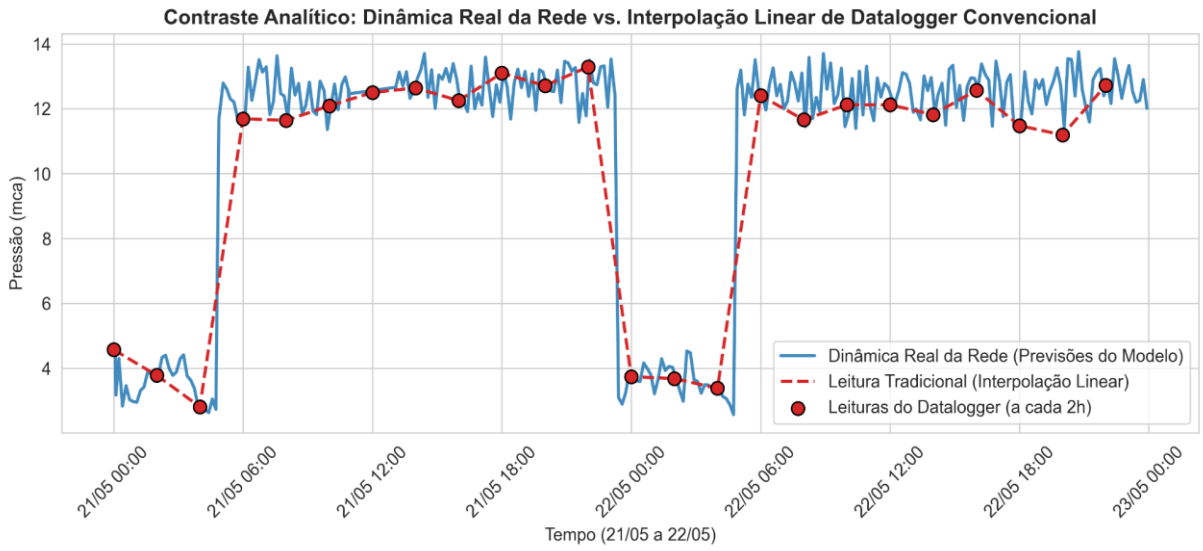
**Figura 2 - Histograma da distribuição dos erros (resíduos) do modelo.**




Fonte: Elaborado pelo autor.

Na etapa de inferência virtual, o modelo operou alimentado exclusivamente com dados da TRP. Para demonstrar o impacto prático dessa solução, a Figura 3 simula o contraste entre a visão contínua gerada pelo sensor virtual (modelo de IA) e a visão tradicional de um *datalogger* físico configurado para transmitir dados a cada 2 horas (frequência típica para longa duração de bateria).

**Figura 3 - Contraste entre a pressão estimada pelo sensor virtual e a monitorada fisicamente pelo datalogger.**




Fonte: Elaborado pelo autor.

Conforme evidenciado no gráfico da Figura 3, o método de monitoramento convencional — representado pela linha tracejada vermelha, que interpola linearmente as leituras transmitidas a cada duas horas — cria uma representação artificialmente suavizada do sistema. Essa abordagem ancorada na economia de bateria baseia-se na premissa de que a rede de distribuição transita de forma constante e linear entre dois estados estáticos. Na realidade operacional, contudo, a infraestrutura sofre transientes hidráulicos e flutuações de demanda que ocorrem integralmente dentro desse "ponto cego" temporal de horas.

Sob a ótica do modelo tradicional, a visão do centro de controle é severamente restrita e defasada. Uma leitura isolada de 6 mca sucedendo um registro de 4 mca, por exemplo, pode induzir a operação a enxergar uma tendência gradual de elevação, quando, na verdade, trata-se da captura de um pico momentâneo de pressurização que pode se reverter subitamente sem que a telemetria detecte. Em contrapartida, o sensor virtual (representado pela linha azul contínua) demonstrou a capacidade de reconstituir a dinâmica hidráulica real em alta resolução.

Ao preencher os vazios temporais do *datalogger* físico, as predições do algoritmo revelam as oscilações, quedas e picos de pressão que permaneciam completamente invisíveis à operação convencional. O fornecimento de visibilidade operacional em tempo real confere às companhias de saneamento maior segurança operacional para aproximar a pressão alvo da rede aos limites mínimos exigidos por norma, mitigando as perdas reais por sobre pressão, reduzindo o risco de subpressão ou desabastecimento.

As comparações indicaram boa concordância entre as estimativas geradas pelo modelo e as medições reais obtidas em campo, mantendo-se dentro das margens de erro observadas na fase de validação. No gráfico, a curva de pressão estimada ao longo do tempo apresenta aderência satisfatória aos pontos de pressão medida, evidenciando a capacidade do modelo de representar o comportamento hidráulico do ponto crítico em condições operacionais semelhantes às utilizadas no treinamento. Essa consistência reforça a viabilidade do uso da TRP como fonte contínua e operacionalmente estável de dados para a inferência virtual da pressão no ponto crítico.

Do ponto de vista da gestão do abastecimento e do controle de perdas, a possibilidade de estimar a pressão no ponto crítico com erro médio absoluto de 0,162 mca amplia a segurança operacional para ajustar a pressão alvo da rede, preservando as condições mínimas de atendimento nos pontos hidraulicamente mais desfavorecidos. Com maior visibilidade sobre esse ponto de referência, torna-se possível reduzir pressões excedentes que, em muitos setores, são mantidas como margem de segurança diante da ausência de informação em tempo real. Essa condição é particularmente relevante em redes nas quais a operação tende a adotar folgas elevadas de pressão, o que pode contribuir para o aumento da vazão de vazamentos, da frequência de rupturas e, em sistemas dependentes de bombeamento, do consumo energético.

## ANÁLISE E DISCUSSÃO DOS RESULTADOS

Os resultados obtidos demonstram que a combinação entre turbina redutora de pressão e modelo de aprendizado de máquina é capaz de reproduzir com alta fidelidade o comportamento da pressão em ponto crítico, a partir de um conjunto limitado, porém bem estruturado, de dados de treinamento. A forte correlação observada entre as variáveis medidas na TRP e a pressão no ponto crítico confirma a hipótese de que a TRP pode ser utilizada como ponto de observação privilegiado da rede, fornecendo informações suficientes para inferir a condição do ponto mais sensível.

Do ponto de vista da acurácia, os valores de MAE e RMSE obtidos são significativamente inferiores às variações típicas de pressão que motivam ações operacionais na rede. Em muitos casos, diferenças de alguns metros de coluna d'água já são suficientes para caracterizar condições de sobrepressão ou subpressão que exigem intervenção. Um erro médio da ordem de décimos de metro, portanto, mostra-se reduzido frente às variações de pressão normalmente relevantes para a tomada de decisão operacional. Dessa forma, a estimativa virtual do ponto crítico apresenta precisão compatível com seu uso como referência de apoio ao controle de pressão, desde que mantidos procedimentos periódicos de validação e recalibração do modelo.

Em termos de robustez, o elevado valor de ($R^2$) e a ausência de padrões de viés nos gráficos de resíduos sugerem que o modelo aprendeu relações estruturais reais entre as variáveis medidas na TRP e a pressão no ponto crítico. Diferentemente de um modelo puramente teórico, baseado apenas em equações hidráulicas ideais, o aprendizado de máquina captura de forma implícita efeitos combinados de rugosidade, conexões, perdas localizadas, variações de consumo e outras características específicas da rede analisada. Essa capacidade de incorporar

peculiaridades locais é particularmente importante para companhias de saneamento, que frequentemente operam redes heterogêneas, antigas e com histórico complexo de intervenções.

Sob a perspectiva do controle de perdas, e universalização do abastecimento, a solução proposta contribui diretamente para viabilizar o controle de pressão a partir da condição do ponto crítico, sem a necessidade de manter um sensor permanentemente instalado e energizado nesse ponto. Estudos anteriores com TRP já demonstraram reduções expressivas no índice de perdas por ligação após a implantação da turbina e de outras tecnologias complementares (BETTARELLO; PIRES, 2024). Os resultados aqui apresentados sugerem que há potencial adicional de redução, ao permitir um controle ainda mais refinado da pressão com base na condição do ponto crítico, mesmo quando não há medição contínua diretamente nesse local.

Ao disponibilizar uma estimativa em tempo quase real da pressão no ponto crítico, a inferência virtual possibilita:

- Reduzir com segurança os níveis médios de pressão na rede, em especial nos períodos de menor demanda, sem risco de comprometer o atendimento no ponto crítico
- Identificar rapidamente situações de sobrepressões decorrentes de manobras ou falhas operacionais, que poderiam aumentar o risco de rompimentos.
- Detectar prontamente episódios em que a pressão caia abaixo do limite regulamentar do setor, permitindo uma intervenção imediata para evitar que tais ocorrências evoluam para interrupções prolongadas no fornecimento de água.
- Correlacionar elevações atípicas de pressão e variações de vazão com possíveis eventos de vazamento ou fechamentos indevidos de registros, apoiando a gestão de perdas reais.
- Por meio da estimativa em tempo quase real da pressão no ponto crítico, a TRP pode apoiar o ajuste dinâmico da pressão de operação da rede, buscando preservar os níveis mínimos de atendimento nos pontos hidraulicamente mais desfavorecidos. Essa abordagem permite reduzir pressões excedentes com maior segurança operacional, contribuindo para a diminuição da vazão de vazamentos, da ocorrência de rupturas e, consequentemente, das perdas reais no sistema.

A presença da TRP como fonte de energia e de dados contínuos permite deslocar a função de monitoramento em alta frequência para um ponto da rede onde a autossuficiência energética é possível, preservando o *datalogger* do ponto crítico para funções de validação esporádica e manutenção do modelo. Dessa forma, torna-se possível configurar o *datalogger* com intervalos de transmissão significativamente mais longos, aumentando a vida útil da bateria sem abrir mão da visibilidade em tempo real da pressão no ponto crítico por meio da inferência virtual.

A abordagem, entretanto, possui algumas limitações. O modelo depende de um período inicial de treinamento com dados de boa qualidade, incluindo variação suficiente das condições operacionais para que se aprenda as relações relevantes. Se, após o treinamento, ocorrerem mudanças significativas na configuração hidráulica do setor, como abertura ou fechamento de válvulas, interligações, substituição de trechos de rede ou alterações expressivas na topologia, será necessário realizar nova campanha de coleta e recalibração do modelo, ou aguardar a atualização através do recurso de aprendizado contínuo.

A necessidade de um acompanhamento constante da precisão das estimativas é outro fator importante a ser considerado. Mesmo que o modelo exiba uma performance superior durante a validação, a dinâmica da rede pode ser influenciada ao longo do tempo por variáveis externas, tais como vazamentos de grande porte, incrustações, obstruções ou o desgaste natural dos sensores. Para mitigar esses efeitos, a metodologia prevê que os dados coletados pelo datalogger, ainda que em uma frequência reduzida, sejam integrados continuamente para refinar o treinamento e atualizar o modelo. Dessa forma, as medições pontuais realizadas pelo *datalogger* mantêm papel estratégico na validação das estimativas e no aprimoramento contínuo do modelo preditivo.

Somado a isso, visto que a tecnologia apresentada neste trabalho se baseia no armazenamento de históricos operacionais e na constante evolução sobre a dinâmica da rede, ela pode ser integrada a algoritmos auxiliares para atuar como uma estrutura de identificação de anomalias. Isso permite não apenas a inferência da pressão no ponto crítico, mas também a identificação de desvios no comportamento padrão da rede, possibilitando o diagnóstico precoce de irregularidades operacionais, como a ocorrência de novos vazamentos. Sob essa ótica, o modelo de aprendizado de máquina passa a atuar de forma análoga a um "Gêmeo Digital" (*Digital Twin*) da infraestrutura física. A utilização de Gêmeos Digitais baseados em Redes Neurais Artificiais e *machine learning* tem se mostrado uma ferramenta robusta para espelhar o comportamento de plantas hidráulicas em tempo real,

sendo extremamente valiosa para proteger a integridade do sistema físico, detectar anomalias e atuar como um supervisor autônomo (NASCIMENTO, 2022).

Em termos de escalabilidade, a solução apresenta vantagens importantes. Uma mesma arquitetura conceitual pode ser replicada em diversos setores de abastecimento, respeitando-se particularidades locais, com a TRP atuando como fonte de dados e regulador de pressão, e modelos específicos treinados para cada ponto crítico relevante. A incorporação de sistemas de automação e supervisão possibilitaria, futuramente, o estabelecimento de estratégias de controle automático fundamentadas na pressão virtual do ponto crítico. Nesse modelo, a Turbina Redutora de Pressão (TRP) passa a receber atualizações constantes da pressão prevista pelo algoritmo, executando o ajuste dinâmico no ponto estratégico de sua instalação para regular a pressão no ponto crítico. Tal evolução aproxima a gestão operacional das diretrizes de cidades inteligentes e sustentáveis, conforme explorado por (BETTARELLO; PIRES, 2024).

Assim, a inferência virtual de pressão em ponto crítico, apoiada pela TRP, não se restringe a um ganho pontual de precisão, mas representa um avanço na forma como a pressão é medida, interpretada e utilizada para reduzir perdas, otimizar energia e aumentar a resiliência das redes de distribuição.

## CONCLUSÕES / RECOMENDAÇÕES

Este trabalho apresentou o desenvolvimento e a validação de uma solução de inferência virtual de pressão em ponto crítico, baseada na integração entre turbina redutora de pressão e modelo de aprendizado de máquina. A abordagem busca contornar limitações clássicas do monitoramento de pontos críticos com dataloggers a bateria, que impõem grandes intervalos de medição e comprometem tanto a densidade de dados quanto a possibilidade de uso dessas informações para controle em tempo real.

A campanha de coleta de dados realizada entre 13/05/2026 e 05/06/2026 resultou em 2.856 leituras pareadas de alta qualidade, nas quais a pressão real no ponto crítico foi associada a variáveis hidráulicas monitoradas pela TRP. A partir dessa base, foi treinado um modelo de regressão, capaz de estimar a pressão no ponto crítico apenas com base nas leituras da Turbina Redutora de Pressão.

Os resultados da validação indicaram erro médio absoluto de 0,162 mca, raiz do erro quadrático médio de 0,252 mca e coeficiente de determinação de 0,9942, demonstrando elevada acurácia e robustez. A análise gráfica de previsto versus real, dos resíduos e da distribuição de erros reforçou a conclusão de que o modelo pode ser adequado para uso operacional em controle de pressão e controle de perdas.

Sob a ótica das companhias de saneamento, a principal contribuição da solução proposta está na possibilidade de controlar a pressão da rede a partir da condição do ponto crítico, sem depender de um sensor permanentemente instalado e energizado nesse ponto. Isso poderá reduzir de forma sustentada os níveis médios de pressão nos setores, diminuir a ocorrência de vazamentos e rompimentos, alongar a vida útil de ativos e equipamentos e otimizar o uso de energia elétrica no bombeamento, podendo ter impacto direto na redução de perdas reais e nos custos operacionais.

A solução permite reduzir significativamente a frequência de transmissão do datalogger, que passa a ser utilizado principalmente para validação periódica e manutenção do modelo, enquanto a TRP, autossuficiente em energia, fornece o fluxo contínuo de dados necessário para a inferência virtual. Com isso, obtém-se visão em tempo real da pressão no ponto crítico, sem a necessidade de um sensor permanentemente ativo e com consumo intensivo de bateria nesse ponto.

Do ponto de vista da evolução tecnológica, a proposta dialoga diretamente com as diretrizes de cidades inteligentes e sustentáveis, ao integrar geração de energia, telemetria, análise de dados e aprendizado de máquina em prol da eficiência hídrica. Em complemento aos resultados já demonstrados em estudos de caso de redução de perdas com TRP e geofonia associada à inteligência artificial (BETTARELLO; PIRES, 2024) , a inferência virtual de pressão em ponto crítico aparece como um novo componente para compor planos propositivos de combate às perdas reais.

Diante da crescente pressão imposta pela escassez hídrica, metas regulatórias e pela necessidade de universalização do abastecimento, a adoção de tecnologias capazes de ampliar a eficiência operacional dos

sistemas de distribuição torna-se cada vez mais relevante. Nesse contexto, a inferência virtual de pressão em ponto crítico, suportada pela TRP, apresenta-se como uma ferramenta promissora para aprimorar a gestão do abastecimento e apoiar estratégias de redução de perdas reais. Ao ampliar a visibilidade operacional da rede e permitir ajustes mais seguros das pressões excedentes, a solução contribui para a mitigação do desperdício de água tratada, a redução de esforços hidráulicos sobre a infraestrutura, a diminuição de ocorrências operacionais e a melhoria da eficiência energética em sistemas dependentes de bombeamento. Dessa forma, a proposta se alinha às diretrizes de eficiência, sustentabilidade e cidades inteligentes aplicadas ao setor de saneamento.

## REFERÊNCIAS BIBLIOGRÁFICAS

1. ABES. Controle e redução de perdas nos sistemas públicos de abastecimento de água. Posicionamento e contribuições técnicas ABES. São Paulo, 2015.
2. AWWA. *M36 - Water Audits and Loss Control Programs*. 4. ed. Denver: American Water Works Association, 2016.
3. BETTARELLO, E. J.; PIRES, D. F. Cidades inteligentes e sustentáveis: tecnologias aplicadas para o combate às perdas de água reais no saneamento. In: Anais do 33º Congresso Brasileiro de Engenharia Sanitária e Ambiental / FITABES, 2024.
4. BEZERRA, S. D. T. M.; CHEUNG, P. B. Perdas de água: tecnologias de controle. João Pessoa: Editora da UFPB, 2013.
5. CARDOSO, A. P. P. M. et al. Redução de perdas reais em sistemas de abastecimento de água: otimização das pressões numa grande rede de distribuição de água. FEUP, Porto, 2013.
6. HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. 2. ed. New York: Springer, 2009.
7. MONTGOMERY, D. C.; RUNGER, G. C. Estatística aplicada e probabilidade para engenheiros. 5. ed. Rio de Janeiro: LTC, 2012.
8. NASCIMENTO, C. M. Gêmeo digital de um sistema de bombeamento de água. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal da Paraíba (UFPB), João Pessoa, 2022.
9. TRATA BRASIL; GO ASSOCIADOS. Perdas de água 2023 (SNIS 2021): desafio para a disponibilidade hídrica e avanço da eficiência do saneamento básico no Brasil. São Paulo, 2023.
10. YIN, R. K. Estudo de caso: planejamento e métodos. 5. ed. Porto Alegre: Bookman, 2015.