OTIMIZAÇÃO TOPOLÓGICA DE REDES DE ESGOTO E MINIMIZAÇÃO DE CAPEX COM USO DE MACHINE LEARNING E SIG

Eduardo Magalhães Vieira
Engenheiro civil formado pela Universidade Federal de Sergipe (UFS). Atua como desenhista pleno e desenvolvedor BIM, com experiência IA e machine learning na E-Agua.

Endereço: Rua Sebastião de Moraes, 634 – Parque Santa Felícia – São Carlos – São Paulo - CEP: 13562-425 - Brasil - Tel: +55 (16) 3374-7025 - e-mail: eduardo.magalhaes@e-agua.com.

RESUMO

Este trabalho apresenta o desenvolvimento de uma ferramenta geoespacial integrada a um Sistema de Informação Geográfica (SIG) livre para a otimização do traçado de redes coletoras de esgoto, desenvolvida em Python com a biblioteca NetworkX. A proposta automatiza a definição do traçado de menor custo de implantação a partir da orçamentação determinística baseada nas composições do SINAPI e do algoritmo de busca heurística A*, exigindo do projetista apenas a indicação topográfica dos poços iniciais e do ponto de exutório. A ferramenta incorpora um modelo preditivo de aprendizado de máquina (XGBoost) treinado com 1.213 trechos provenientes de traçados reais, que reproduziu o orçamento de referência com coeficiente de determinação (R^2) de 0,9931 e erro médio absoluto (MAE) de R$ 4,97/m, equivalente a 1,76% do custo médio. O sistema realiza, de forma automática, a classificação do método construtivo de cada trecho entre Vala a Céu Aberto (VCA) e Método Não Destrutivo (MND), bem como a previsão da necessidade de estações elevatórias conforme as restrições locais, priorizando o escoamento por gravidade e a redução dos volumes de escavação. Dessa forma, a ferramenta automatiza etapas repetitivas do processo de projeto e amplia a aplicação de técnicas de inteligência artificial (IA) no setor de saneamento.

PALAVRAS-CHAVE: Redes coletoras de esgoto; Inteligência artificial; Geoprocessamento.

INTRODUÇÃO

A etapa de planejamento de sistemas de esgotamento sanitário constitui um pilar essencial para o desenvolvimento ordenado das cidades, especialmente em cenários que demandam rápida expansão urbana. Como preconizado por Tsutiya e Alem Sobrinho (1999), a concepção dessas redes exige um rigor técnico que contemple não apenas a eficiência hidráulica, mas também a viabilidade operacional e a longevidade das estruturas. No modelo convencional, a definição do traçado das tubulações costuma depender de processos manuais e da necessidade de estudar várias alternativas de rotas durante o processo, o que impõe ao engenheiro uma carga significativa de revisões e dificulta a busca por uma otimização econômica do empreendimento. Tais barreiras podem resultar em projetos menos eficientes e com custos de execução elevados devido à impossibilidade de analisar todas as alternativas em tempo hábil.

Com a digitalização da construção civil e a difusão de metodologias baseadas em dados, surge a oportunidade de aplicar algoritmos avançados para elevar a produtividade e a precisão no saneamento. Nessa perspectiva, este trabalho apresenta uma solução geoespacial desenvolvida em Python e integrada a um ambiente Sistemas de Informação Geográfica (SIG) livre. A ferramenta utiliza o algoritmo de busca heurística A* e a biblioteca NetworkX para automatizar a identificação do traçado de menor custo de implantação (CAPEX), adotando como referência os parâmetros orçamentários do SINAPI. O objetivo é converter a etapa de traçado, frequentemente repetitiva e lenta, em uma decisão estratégica que alia agilidade técnica e economia de recursos.

A integração entre a programação e a engenharia sanitária tem se consolidado como um caminho promissor para mitigar falhas, reduzir os custos de infraestrutura e otimizar tarefas. O desenvolvimento da ferramenta proposta fundamenta-se em duas sólidas vertentes de pesquisa nacional. Na área de otimização topológica, dialoga com os estudos de Farias (2026) sobre o uso da teoria dos grafos e caminhos mínimos, e com os avanços alcançados na Universidade de São Paulo (USP) por Ito (2023), focados na definição integrada de topologia e de menor custo de implementação. Simultaneamente, no campo da IA, a ferramenta alinha-se às pesquisas de Medina (2017), também da USP, que evidenciaram o alto potencial do aprendizado de máquina no reconhecimento de padrões em sistemas de saneamento. A aplicação da programação à engenharia permite que o projetista direcione

sua expertise para a análise crítica do projeto, enquanto o sistema computacional processa volumes massivos de dados topográficos e de restrições normativas para sugerir a rota ideal de forma automatizada.

A ferramenta proposta diferencia-se por adotar uma abordagem híbrida que combina o processamento de grafos para o roteamento com a IA para a análise de sensibilidade financeira do traçado. Modelos de aprendizado de máquina, treinados com dados de traçados reais e validados por parâmetros estatísticos, como o R^2 e o Erro Médio Absoluto (MAE), confirmaram que o custo de uma rede é majoritariamente determinado pela componente geométrica (extensão e profundidade), que, juntas, representam cerca de 88% do impacto orçamentário. A partir dessa inteligência e de parâmetros de entrada, como a profundidade máxima permitida, a ferramenta realiza autonomamente a estimativa do diâmetro da tubulação e a classificação do método construtivo entre Vala a Céu Aberto (VCA) e Método Não Destrutivo (MND). Simultaneamente, o algoritmo sinaliza a necessidade de estações elevatórias ao atingir os limites das concessionárias e prioriza rotas que exijam o menor volume de material até o exutório definido. Por ser um ambiente dinâmico, permite que o projetista faça ajustes manuais no traçado, reprocessando as alterações instantaneamente para gerar um memorial técnico completo, estruturado e pronto para importação em programas de dimensionamento.

Integrada a um ambiente SIG livre, a ferramenta foi concebida para uso por concessionárias, escritórios de projeto e órgãos gestores, apoiando a transição do traçado empírico para um processo sistematizado e orientado pela otimização de custos.

OBJETIVO(S)

O objetivo principal deste trabalho é apresentar uma ferramenta geoespacial de apoio ao traçado de redes coletoras de esgoto, focada na minimização do CAPEX por meio da integração entre SIG, IA e orçamentação determinística.
A proposta contempla as seguintes metas específicas:

- Automatizar a definição do traçado no ambiente QGIS utilizando o algoritmo de busca heurística A* para identificar a rota financeiramente mais viável entre os poços de visita, tubos de ligação e o exutório;
- Empregar modelos de aprendizado de máquina, validados por análises de explicabilidade SHapley Additive exPlanations (SHAP), para direcionar o roteamento mitigando os altos custos atrelados à geometria da escavação (profundidade e extensão);
- Classificar automaticamente o método construtivo de cada trecho da rede entre VCA e MND, embasado nos parâmetros normativos e restrições de concessionárias locais;
- Prever a necessidade de implantação de estações elevatórias de forma autônoma durante o processo de roteamento topológico, priorizando rotas que favoreçam o escoamento por gravidade e o menor custo para execução;
- Permitir a edição interativa do projeto, reprocessando, em tempo real, os ajustes manuais do projetista para gerar memoriais técnicos detalhados, estruturados e prontos para a importação em softwares dedicados ao dimensionamento hidráulico.

METODOLOGIA

O desenvolvimento da ferramenta partiu da premissa de tratar a definição do traçado da rede coletora como um problema de otimização de custos tanto no projeto, quanto na execução, e não apenas como uma decisão geométrica ou hidráulica tomada de forma isolada. Para isso, a metodologia foi estruturada em torno de uma arquitetura híbrida que combina o processamento de grafos, responsável pelo roteamento físico da rede, a modelos de aprendizado de máquina, encarregados de traduzir as características de cada trecho em uma estimativa de custo de implantação e um pré-dimensionamento das dimensões dos tubos usando o método de cálculo usado por Mendonça (2017). Todo o fluxo foi concebido para operar de forma integrada ao ambiente QGIS, permitindo que o projetista atue diretamente sobre a base georreferenciada do projeto, e facilitado por ser um software livre.

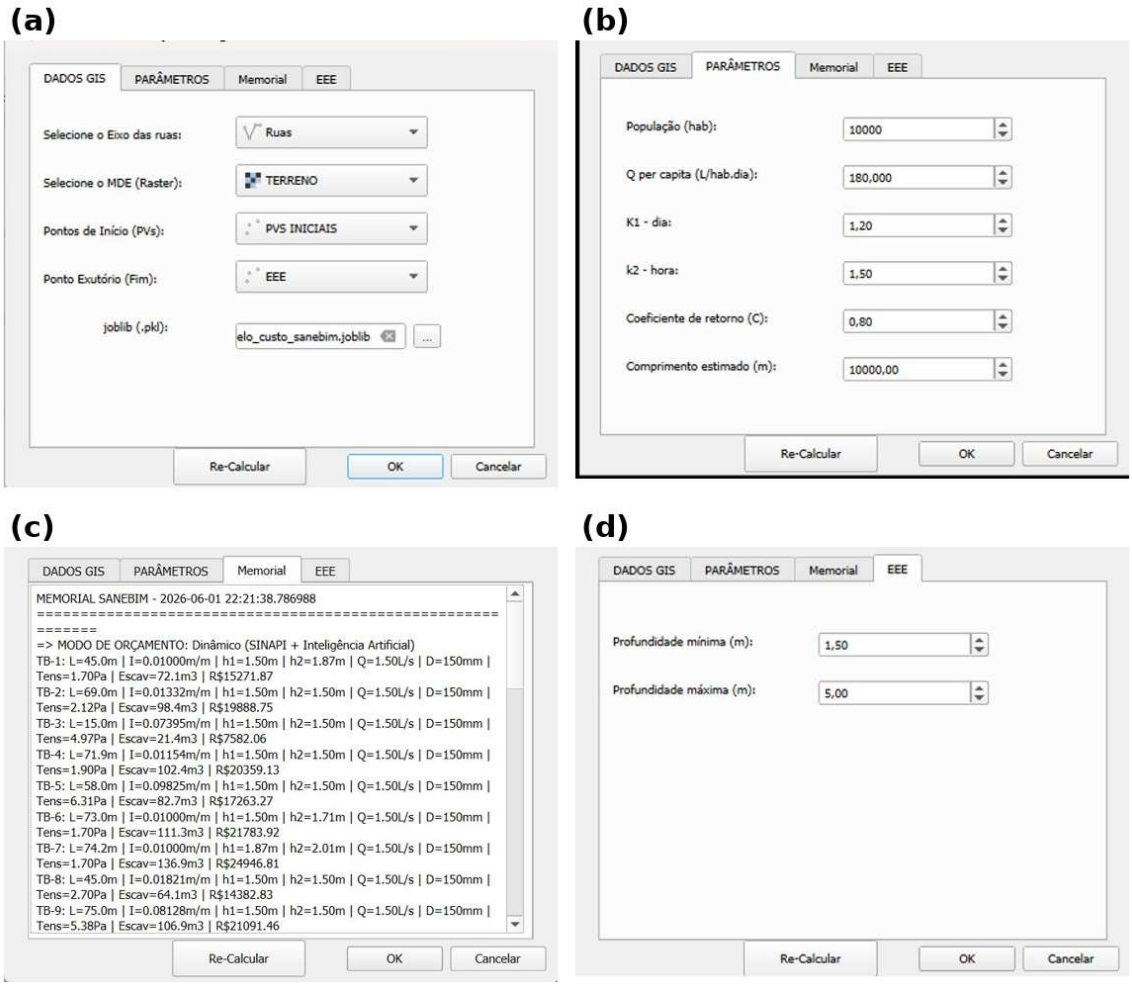
De maneira geral, o processo percorre quatro etapas encadeadas: a importação e a estruturação dos dados georreferenciados; a modelagem da rede como um grafo direcionado e a busca da rota de menor custo por meio do algoritmo de busca heurística A* (HART; NILSSON; RAPHAEL, 1968); a predição do custo de cada trecho por aprendizado de máquina, analisando cada caminho possível, sendo acompanhada da interpretação dos resultados; e, por fim, a classificação construtiva, a sinalização de estações elevatórias e a geração dos traçados. As subseções a seguir detalham cada uma dessas etapas.

Ambiente de pré-traçado e dados de entrada

A ferramenta foi desenvolvida em Python e integrada ao QGIS, valendo-se da biblioteca NetworkX para a construção e a análise dos grafos da rede e das bibliotecas scikit-learn e xgboost para o treinamento e a aplicação dos modelos preditivos, com otimização de hiperparâmetros por busca em grade (GridSearchCV), além de pacotes voltados à manipulação de dados e ao geoprocessamento, como pandas e geopandas. Essa combinação permite organizar, de forma automatizada e acessível, as rotinas de leitura, roteamento, predição de custos e exportação dos resultados.

Os dados de entrada são compostos pela camada topográfica da área de projeto, a linha que representa as ruas que é onde o traçado pode passar, pela posição dos poços de visita iniciais e do ponto de lançamento, que delimitam, respectivamente, os pontos de partida e o destino do escoamento e a inserção do arquivo .joblib para utilizar dos dados do modelo preditivo, caso não seja inserido vai seguir um modelo determinístico. A partir dessas informações, o projetista define os parâmetros de projeto, que limitam a análise do traçado a certos possíveis caminhos, sendo eles: a profundidade máxima admissível, o comprimento máximo por trecho e as demais restrições impostas pela concessionária local (Figura 1).

Figura 1 – Interface da ferramenta desenvolvida: (a) aba DADOS GIS; (b) aba PARÂMETROS; (c) aba Memorial; (d) aba EEE.



Fonte: Autor, 2026.

Na Figura 1, são apresentas as quatro abas da interface. Na aba DADOS GIS (a), o projetista carrega as camadas georreferenciadas do projeto, o eixo das ruas, o modelo digital de elevação (MDE), os poços de visita iniciais e o ponto de exutório, além do arquivo do modelo preditivo de custo (.joblib). A aba PARÂMETROS (b) reúne as variáveis de cálculo da vazão sanitária, como a população, o consumo per capita, os coeficientes K1, K2 e de retorno, e o comprimento estimado da rede. A aba Memorial (c) consolida o memorial técnico por trecho e seus parâmetros: comprimento, profundidades, declividade, diâmetro, vazão, velocidade, tensão trativa e custo — pronto para exportação. Por fim, a aba EEE (d) define as profundidades mínima e máxima admissíveis, que

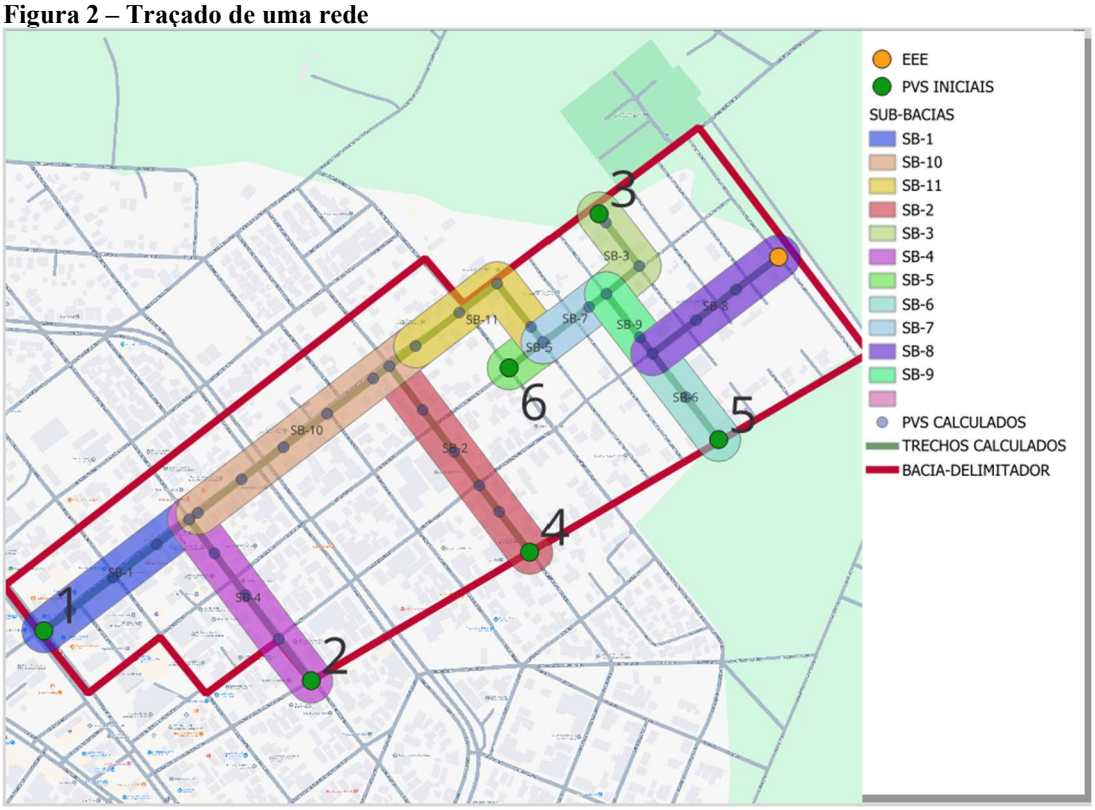
restringem o traçado e determinam a indicação automática de estações elevatórias.

Modelagem da rede e traçado via grafos

Com os dados carregados, o sistema representa a área de projeto como um grafo direcionado, no qual os nós correspondem aos poços de visita e as arestas representam os trechos candidatos a receber a tubulação. Sobre essa estrutura, aplica-se o algoritmo de busca heurística A*, cuja finalidade é localizar, entre todas as rotas possíveis até o ponto final, aquela que apresenta o menor custo total de implantação (CAPEX), o que resulta em uma otimização do traçado.

Diferentemente de uma busca orientada apenas pela menor distância horizontal, a função de custo adotada incorpora as composições de preços do SINAPI, de modo que cada aresta é ponderada não pela extensão, mas pelo custo estimado de execução do trecho correspondente. Com isso, o algoritmo privilegia o escoamento por gravidade e penaliza trajetos que, embora possam ser mais curtos, exigiriam para sua execução escavações profundas ou maiores volumes de material tornando assim inviável, e assim o software conduz a rede ao traçado economicamente mais vantajoso (Figura 2).

Figura 2 – Traçado de uma rede



Fonte: Autor, 2026.

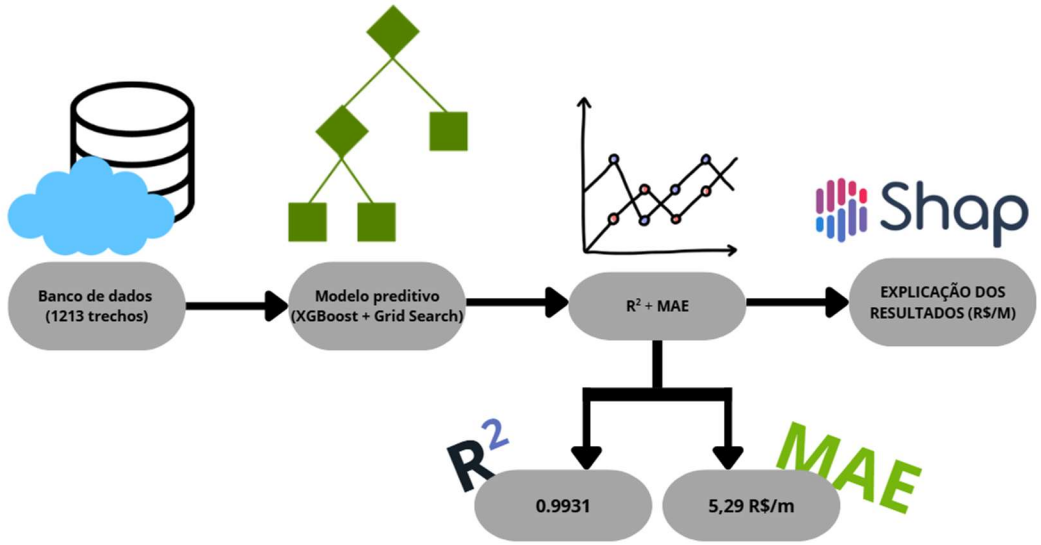
Predição de custos e explicabilidade via aprendizado de máquina

O custo que pondera cada aresta no roteamento é obtido por um modelo determinístico fundamentado nas composições de preços do SINAPI, que contabiliza escavação, assentamento, reaterro, escoramento e poços de visita. Em paralelo, um modelo de aprendizado de máquina supervisionado, treinado a partir de uma base de traçados reais processada em lote, atua como emulador desse orçamento e como camada de explicabilidade, viabilizando a análise dos fatores que governam o custo de implantação. Essa base reúne atualmente 1.213 trechos de tubulação com diferentes parâmetros, como comprimentos, diferenças de cota, declividade e vazões, o que confere ao modelo representatividade frente à diversidade de situações encontradas em campo.

O conjunto de 1.213 trechos foi particionado em 80% para treino e 20% para teste. Os hiperparâmetros do modelo XGBoost foram otimizados por busca em grade (GridSearch) com validação cruzada de 5 folds sobre os dados de treino, resultando na configuração final (n_estimators = 1200, learning_rate = 0,1, max_depth = 3). Avaliado no conjunto de teste, isto é, em trechos não vistos durante o treinamento, o modelo atingiu $R^2 = 0,9931$ e MAE = R$ 4,97/m. A estabilidade foi confirmada por validação cruzada de 5 folds, com MAE médio de R$ 5,29/m e desvio padrão de apenas R$ 0,88/m, indicando desempenho consistente entre as partições.

Considerando o custo médio de referência de R$ 301,22/m da base, esse erro corresponde a apenas 1,76%, evidenciando que o modelo reproduz com elevada fidelidade o orçamento determinístico calculado a partir das composições do SINAPI. Cabe ressaltar que tal aderência reflete a capacidade do modelo de emular o orçamento de referência, do qual deriva a variável-alvo, e não uma estimativa dos custos efetivamente executados em obra (Figura 3).

Figura 3 – Fluxograma da arquitetura de treinamento e validação do modelo preditivo.



Fonte: Autor, 2026.

Classificação construtiva e previsão de estações elevatórias

A partir do perfil de rebaixo obtido ao longo do traçado, o sistema classifica automaticamente cada trecho quanto ao método construtivo mais adequado, distinguindo entre VCA e MND, de acordo com a profundidade, a extensão máxima de cada trecho e a viabilidade econômica de cada situação (Figura 4). Essa classificação dispensa a análise manual trecho a trecho. Além disso, mantém a coerência entre a solução construtiva e as condições topográficas locais.

Quando a topografia inviabiliza a manutenção da profundidade máxima estabelecida pela concessionária, o algoritmo sinaliza a necessidade de implantação de uma Estação Elevatória de Esgoto (EEE) e reinicia o cálculo da cota de fundo a partir desse ponto, de modo a preservar o escoamento otimizado no restante da rede.

Figura 4 – Tabela com informações de cada trecho no QGIS

ID_TUBO	TB-1
DECLIV	0,01
DIAMETRO	150
MATERIAL	PVC
Q_FINAL	1,500
D_TEORICO	57,49
VELOC	0,66
LAMINA	0,19
COMPRIM	45,00
TENS_TRAT	1,70
H_MONT	1,50
H_JUS	1,87
VOL_ESCAV	72,12
VOL_REAT	82,02
TUBO_QUEDA	Nao
SUB_BACIA	SB-1
METODO	MND
CUSTO_M	339,37
CUSTO_TOT	15271,87

Fonte: Autor, 2026.

Notas: COMPRIM = comprimento do trecho (m); PROF = profundidade (m); DECLIV = declividade do tubo (m/m); DN = diâmetro nominal (mm); Q = vazão (L/s); V = velocidade (m/s); CUSTO_TOT = custo total do trecho (R$).

Edição interativa e dinâmica, validação e saídas

Por se tratar de um ambiente dinâmico, a ferramenta permite que o projetista realize ajustes manuais no traçado sugerido, reprocessando instantaneamente as alterações e recalculando custos e classificações sem a necessidade de reiniciar todo o procedimento. Essa interatividade preserva o controle técnico do engenheiro sobre o projeto e, ao mesmo tempo, mantém os ganhos de produtividade proporcionados pela otimização.

Ao término do processo, o sistema consolida um memorial técnico resumido (Figura 5), contendo cada trecho criado e otimizado e seus respectivos atributos, pronto para ser importado em softwares dedicados ao dimensionamento do modelo hidráulico.

Figura 5 – Memorial contendo a descrição por trecho

```
=> MODO DE ORÇAMENTO: Dinâmico (SINAPI + Inteligência Artificial)
TB-1: L=45.0m | I=0.01000m/m | h1=1.50m | h2=1.87m | Q=1.50L/s | D=150mm |
Tens=1.70Pa | Escav=72.1m3 | R$15271.87
TB-2: L=69.0m | I=0.01332m/m | h1=1.50m | h2=1.50m | Q=1.50L/s | D=150mm |
Tens=2.12Pa | Escav=98.4m3 | R$19888.75
TB-3: L=15.0m | I=0.07395m/m | h1=1.50m | h2=1.50m | Q=1.50L/s | D=150mm |
Tens=4.97Pa | Escav=21.4m3 | R$7582.06
TB-4: L=71.9m | I=0.01154m/m | h1=1.50m | h2=1.50m | Q=1.50L/s | D=150mm |
Tens=1.90Pa | Escav=102.4m3 | R$20359.13
TB-5: L=58.0m | I=0.09825m/m | h1=1.50m | h2=1.50m | Q=1.50L/s | D=150mm |
Tens=6.31Pa | Escav=82.7m3 | R$17263.27
TB-6: L=73.0m | I=0.01000m/m | h1=1.50m | h2=1.71m | Q=1.50L/s | D=150mm |
Tens=1.70Pa | Escav=111.3m3 | R$21783.92
TB-7: L=74.2m | I=0.01000m/m | h1=1.87m | h2=2.01m | Q=1.50L/s | D=150mm |
Tens=1.70Pa | Escav=136.9m3 | R$24946.81
TB-8: L=45.0m | I=0.01821m/m | h1=1.50m | h2=1.50m | Q=1.50L/s | D=150mm |
Tens=2.70Pa | Escav=64.1m3 | R$14382.83
TB-9: L=75.0m | I=0.08128m/m | h1=1.50m | h2=1.50m | Q=1.50L/s | D=150mm |
Tens=5.38Pa | Escav=106.9m3 | R$21091.46
```

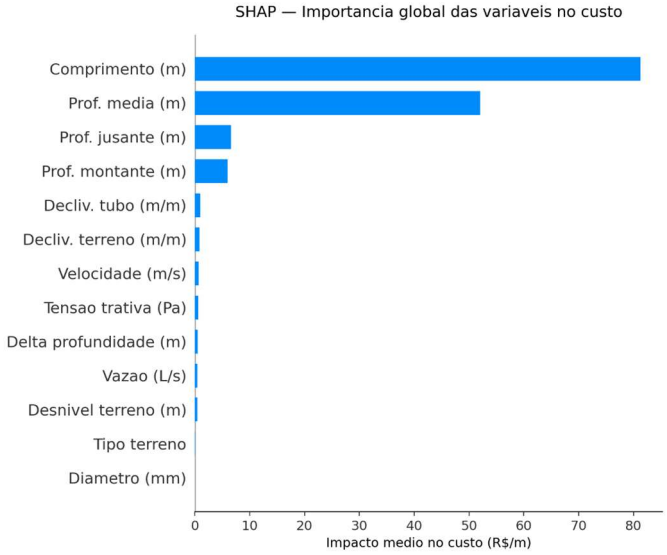
Fonte: Autor, 2026.

RESULTADOS OBTIDOS

A aplicação da abordagem híbrida proposta apresentou resultados consistentes, tanto na predição de custos quanto na otimização topológica em ambiente SIG. A validação do modelo preditivo foi realizada utilizando uma base atualmente composta por 1.213 trechos de tubulação, com comprimentos e diferenças de cota variados. Por meio da análise de explicabilidade baseada nos valores SHAP, foi possível mensurar matematicamente o impacto de cada variável no custo final de implantação, medido em reais por metro (R$/m).

A análise evidenciou que o custo unitário de uma rede coletora é predominantemente determinado por fatores geométricos. O comprimento do trecho apresentou o maior grau de importância, correspondendo a 54,0% do impacto no custo unitário, seguido pela profundidade média da vala, com 34,6% (Figura 6). Cabe destacar, contudo, que a influência do comprimento se manifesta de forma inversa: como os custos fixos por trecho, sobretudo os poços de visita, responsáveis por cerca de 38% do custo total, são diluídos ao longo da extensão, os trechos mais curtos apresentam maior custo por metro, ao passo que a profundidade atua de maneira direta, por meio do incremento do volume de escavação.

Figura 6 – Importância dos parâmetros no traçado da rede por IA.



Fonte: Autor, 2026.

Notas: SHAP (SHapley Additive exPlanations), técnica de explicabilidade que quantifica a contribuição de cada variável para a predição do modelo. MAE (erro médio absoluto), erro médio das estimativas frente ao orçamento de referência, em R$/m. Variáveis: comprimento do trecho (m); profundidade média, a montante e a jusante (m); declividade do tubo (m/m); diâmetro nominal (mm); vazão (L/s); velocidade (m/s); tensão trativa (Pa).

Juntas, essas duas variáveis geométricas explicam cerca de 88,6% da variação financeira do projeto. Em contrapartida, as variáveis estritamente hidráulicas, como vazão, velocidade e tensão trativa contribuíram, de forma combinada, com apenas 1,1% do custo total. Essa constatação validou a estratégia do software de concentrar os esforços de roteamento na minimização dos rebaixos topográficos e das escavações. Sob essa ótica, a análise SHAP forneceu uma diretriz objetiva de projeto: a redução do número de poços de visita e a consequente diminuição da fragmentação da rede em trechos curtos, somadas ao controle das escavações, que constituem os principais vetores de redução do custo por metro.

Durante as simulações práticas no QGIS, a biblioteca de busca A* utilizou essas premissas para traçar rotas otimizadas a partir dos poços de visita iniciais até o exutório. O sistema evitou caminhos que, embora fossem mais curtos em distância horizontal, exigiriam escavações profundas e dispendiosas, priorizando sempre o escoamento por gravidade acoplado ao menor CAPEX, calculado com base nas composições do SINAPI.

Além da precisão do traçado, a ferramenta também obteve sucesso na classificação autônoma dos métodos construtivos. Ao analisar o rebaixo ao longo do perfil do terreno, a ferramenta categorizou corretamente os trechos aplicáveis à VCA e identificou as seções em que a profundidade, o comprimento, a declividade e a viabilidade econômica exigiam a transição para o MND (Figura 7).

Figura 7 – Classificação do trecho baseada em comprimento e declividade.

COMPRIM	45,00
TENS_TRAT	1,70
H_MONT	1,50
H_JUS	1,87
VOL_ESCAV	72,12
VOL_REAT	82,02
TUBO_QUEDA	Nao
SUB_BACIA	SB-1
METODO	MND
CUSTO_M	339,37
CUSTO_TOT	15271,87

Fonte: Autor, 2026.

O sistema também demonstrou eficácia ao respeitar as restrições normativas parametrizadas pelo usuário. Nos cenários em que a topografia impossibilitava a manutenção da profundidade máxima estabelecida pela concessionária local, o algoritmo sinalizou automaticamente a necessidade de implantação de EEE e reiniciou o cálculo da cota de fundo para garantir o escoamento otimizado.

Por fim, observou-se uma drástica redução no tempo despendido na geração de alternativas de traçado. A capacidade da ferramenta de processar novas rotas instantaneamente, em resposta às edições manuais do projetista, entrega à etapa de dimensionamento um traçado já estruturado, consolidando ganhos de produtividade e de segurança orçamentária.

A validação descrita refere-se ao modelo de custo. A otimização do traçado, por sua vez, é assegurada pela propriedade de admissibilidade do algoritmo A*, que garante a obtenção da rota de menor custo segundo a função de custo adotada. Complementarmente, realizou-se uma verificação empírica em uma sub-bacia real de pequeno porte, comparando o traçado convencional, elaborado manualmente pelo projetista, com o traçado otimizado gerado pela ferramenta, mantendo-se o mesmo exutório, os mesmos parâmetros de vazão e as mesmas restrições de profundidade, de modo a isolar o efeito do traçado sobre os quantitativos (Quadro 1).

Quadro 1 – Comparativo entre o traçado convencional e o traçado otimizado.

Critério	Traçado convencional	Traçado otimizado	Variação
Extensão total da rede (m)	795,31	765,49	-3,7%
Número de trechos	24	23	-4,2%
Número de órgãos acessórios	25	24	-4,0%
Volume total escavado (m³)	1.133,3	1.090,8	-3,7%
CAPEX estimado – SINAPI (R$)	305.801,54	294.072,52	-3,8%

Fonte: Autor, 2026.

Nota: extensões de trechos, números de trechos e de órgãos acessórios medidos sobre os dois traçados. Volume escavado e CAPEX estimados, para ambos os cenários, partindo de premissas padronizadas idênticas: profundidade média de 1,5 m, vala de 0,95 m (DN 150 mm em PVC) e as mesmas composições SINAPI adotadas pela ferramenta (escavação, assentamento, reaterro, escoramento e poços de visita), de modo que as diferenças decorrem exclusivamente da extensão da rede e do número de órgãos acessórios.

A partir dos resultados indicados no Quadro 1, verificou-se que o traçado otimizado reproduziu com fidelidade a solução de projeto, reduzindo a extensão total da rede em 3,7% e propondo um trecho e um órgão acessório a menos do que a alternativa convencional. Considerando que os custos fixos por trecho, sobretudo os órgãos acessórios (poços de visita e terminais de limpeza), respondem por parcela relevante do custo total, conforme evidenciado pela análise SHAP, essas reduções se traduzem, na estimativa padronizada do Quadro 1, em uma economia de aproximadamente R$ 11,7 mil (3,8% do CAPEX) na implantação da sub-bacia analisada, podendo se amplificar quando extrapoladas a programas de expansão com dezenas de sub-bacias. Como limitação observada, o algoritmo tende a propor travessias na busca por caminhos mais curtos, o que pode elevar o custo executivo em interferências específicas; a análise explícita do custo dessas travessias na função objetivo é um aprimoramento previsto para versões futuras da ferramenta.

ANÁLISE E DISCUSSÃO DOS RESULTADOS

A aplicação conjunta do roteamento geoespacial e da predição de custos busca otimizar a execução de projetos de infraestrutura, além de oferecer maior segurança orçamentária e técnica, tanto para engenheiros projetistas quanto para gestores públicos na tomada de decisão.

A aplicação da ferramenta evidenciou que a integração entre algoritmos de roteamento geoespacial e IA qualifica a tomada de decisão na concepção de redes coletoras de esgoto. Em vez de se limitar à verificação das condições hidráulicas após o traçado estar desenhado, a ferramenta antecipa o problema, considerando o custo de implantação (CAPEX) como o critério primário para a definição das rotas.

Um dos diferenciais mais relevantes do estudo foi o uso dos valores SHAP para interpretar o modelo preditivo. A explicabilidade do modelo traduziu a complexidade matemática em um direcionamento prático para a engenharia: a geometria da vala determina o custo da obra. A constatação de que a extensão e a profundidade respondem por quase 90% do impacto financeiro permitiu que o algoritmo tomasse decisões mais precisas no QGIS, justificando tecnicamente cada desvio de rota adotado.

Durante as simulações, o algoritmo A* comprovou sua eficácia ao rejeitar traçados retilíneos que demandariam escavações profundas, preferindo contornos topográficos que mantivessem o escoamento por gravidade com rebaixos mínimos. Essa análise topográfica garantiu ao sistema a capacidade de classificar os trechos com maior precisão, embasando a escolha do melhor caminho de forma prática e lógica. Dessa forma, o software assegurou sempre a adoção da alternativa mais econômica e tecnicamente viável.

Além da assertividade nas rotas, observou-se um ganho drástico de produtividade. A avaliação de múltiplas alternativas de traçado e orçamentação, que, manualmente, consumiria horas ou dias de trabalho, foi reduzida a instantes com o uso de plataformas CAD. O atendimento às diretrizes operacionais também foi validado, visto que o software atua estritamente delimitado aos parâmetros iniciais estipulados pelo usuário, como as profundidades mínima e máxima da rede e o comprimento máximo por trecho. Com isso, o sistema sinaliza a necessidade de EEE sempre que o limite estabelecido pelas concessionárias locais é atingido, reiniciando a cota de fundo de maneira automatizada.

Embora a IA já tenha apresentado alta assertividade no reconhecimento de padrões de custo, o modelo atual foi treinado com uma base de 1.213 trechos. A expansão desse banco de dados para contemplar diversos tipos de topografia, comprimentos de tubo, variações de diâmetro, declividade, interferências urbanas e atualizações de tabelas como o SINAPI será o próximo avanço natural, valendo-se da metodologia de aprendizado offline em lotes. Acredita-se que, com a contínua alimentação do modelo preditivo, a ferramenta proposta poderá consolidar-se não apenas como um roteador de traçados, mas também como um instrumento de apoio ao equilíbrio orçamentário e à viabilidade executiva em projetos de saneamento.

CONSIDERAÇÕES FINAIS E RECOMENDAÇÕES

O desenvolvimento da ferramenta representa um avanço na transição da engenharia sanitária convencional para uma abordagem orientada à inteligência de custos e à otimização. A ferramenta rompe com o paradigma do traçado puramente empírico ou fundamentado apenas na hidráulica, ao aliar algoritmos de busca heurística (A*) e de aprendizado de máquina à orçamentação determinística do SINAPI. Essa integração contribui para ganhos de agilidade no projeto, segurança orçamentária e eficiência executiva.

A estrutura atual do sistema mostrou-se adequada à aplicação em cenários complexos. Ao unificar o ambiente de Sistemas de Informação Geográfica (QGIS) ao processamento em Python e à explicabilidade dos dados via parâmetros SHAP, a ferramenta fornece um roteamento otimizado que vai além do desenho geométrico. O software atende restrições normativas, define automaticamente os métodos construtivos mais viáveis (VCA e MND) e prevê a necessidade de EEE de forma autônoma, atendendo diretamente à demanda do setor por ferramentas de mitigação de CAPEX.

Para trabalhos futuros e aprimoramento contínuo da ferramenta, recomenda-se a expansão da base de dados utilizada no treinamento do modelo preditivo, atualmente restrita a trechos de diâmetro nominal de 150 mm em PVC, de modo a contemplar diâmetros superiores e materiais distintos, como o concreto. A incorporação de novas variáveis topológicas e de diferentes perfis topográficos, mediante a metodologia de aprendizado offline em lotes, permitirá o refinamento da inteligência artificial. Recomenda-se, ainda, como evolução de maior impacto, a calibração do modelo a partir de custos efetivamente executados em obra, o que permitiria capturar os desvios entre o orçamento teórico de referência e os valores praticados, consolidando a sensibilidade financeira do algoritmo e tornando suas predições ainda mais assertivas e universais.

Por fim, a adoção desta abordagem por concessionárias de saneamento, escritórios de engenharia e órgãos de gestão pública pode contribuir para reduzir o desperdício de recursos nas obras de infraestrutura. Com a maturação de suas funcionalidades e a validação contínua, a ferramenta apresenta potencial de contribuir para o planejamento estratégico, técnico e econômico de sistemas de esgotamento sanitário, em conjunto com programas de dimensionamento de redes.

REFERÊNCIAS BIBLIOGRÁFICAS

1. ABNT – ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. NBR 9649:1996 – Projeto de Redes Coletoras de Esgoto Sanitário. Rio de Janeiro: ABNT, 1996.

2. ABNT – ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. NBR 14486:2000 – Sistemas Enterrados para Condução de Esgoto Sanitário – Projeto de Redes Coletoras com Tubos de PVC. Rio de Janeiro: ABNT, 2000.

3. CAIXA ECONÔMICA FEDERAL. SINAPI - Sistema Nacional de Pesquisa de Custos e Índices da Construção Civil. Brasília: Caixa Econômica Federal, 2026.

4. FARIAS, G. M. Otimização do traçado de redes coletoras de esgoto utilizando estratégias de caminhos mínimos em árvores de busca em largura. 2026. Tese (Doutorado em Engenharia Civil - Recursos Hídricos) - Centro de Tecnologia, Universidade Federal do Ceará, Fortaleza, 2026.

5. HAGBERG, A.; SCHULT, D.; SWART, P. *Exploring network structure, dynamics, and function using NetworkX. Proceedings of the 7th Python in Science Conference* (SciPy2008), Pasadena, CA USA, p. 11-15, 2008.

6. HART, P. E.; NILSSON, N. J.; RAPHAEL, B. *A Formal Basis for the Heuristic Determination of Minimum Cost Paths. IEEE Transactions on Systems Science and Cybernetics*, v. 4, n. 2, p. 100-107, 1968.

7. ITO, A. H. Otimização no traçado e dimensionamento de redes coletoras de esgoto sanitário. 2023. Tese (Doutorado em Engenharia Hidráulica e Ambiental) - Escola Politécnica, Universidade de São Paulo, São Paulo, 2023.

8. LUNDBERG, S. M.; LEE, S. I. *A unified approach to interpreting model predictions. Advances in Neural Information Processing Systems*, v. 30, p. 4765-4774, 2017.

9. MEDINA, M. M. G. Detecção de vazamentos e alterações em redes de distribuição de água para abastecimento, durante a operação: uma abordagem de aprendizado de máquina. 2017. Tese (Doutorado em Engenharia Hidráulica e Saneamento) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2017.

10. MENDONÇA, S. R.; MENDONÇA, L. C. Sistemas sustentáveis de esgotos – orientações técnicas para projeto e dimensionamento de redes coletoras, emissários, canais, estações elevatórias, tratamento e reúso na agricultura. 2. ed. São Paulo: Blucher, 2017.

11. TSUTIYA, M. T.; ALEM SOBRINHO, P. Coleta e Transporte de Esgoto Sanitário. São Paulo: CETESB, 1999.