

RESSALVA

Atendendo a solicitação do autor, Weliton do Carmo Rodrigues, o texto completo deste documento será disponibilizado somente a partir de 08/08/2026.



UNIVERSIDADE ESTADUAL PAULISTA

“JÚLIO DE MESQUITA FILHO”

Faculdade de Engenharia de Bauru

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

WELITON DO CARMO RODRIGUES

**Localização de Vazamentos em Redes de Distribuição de Água
baseada em Amostragem e Agregação de Grafos (GraphSAGE)**

Bauru

2025

WELITON DO CARMO RODRIGUES

**Localização de Vazamentos em Redes de Distribuição de Água
baseada em Amostragem e Agregação de Grafos (GraphSAGE)**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Estadual Paulista “Júlio de Mesquita Filho” para a Defesa de Mestrado em Engenharia Elétrica.

Área de concentração: Automação
Linha de pesquisa: Mecatrônica

Orientador (a): Prof. Dr. Eduardo Paciência Godoy
Coorientador (a): Prof. Dr. Rodrigo Pita Rolle

Bauru
2025

R696l	Rodrigues, Weliton do Carmo Localização de Vazamentos em Redes de Distribuição de Água baseada em Amostragem e Agregação de Grafos (GraphSAGE) / Weliton do Carmo Rodrigues. -- Bauru, 2025 63 p. Dissertação (mestrado) - Universidade Estadual Paulista (UNESP), Faculdade de Engenharia, Bauru Orientador: Eduardo Paciência Godoy Coorientador: Rodrigo Pita Rolle 1. Localização de Vazamentos. 2. Redes de Distribuição de Água. 3. Redes Neurais de Grafos. 4. Inteligência Artificial. I. Título.
-------	--

ATA DA DEFESA PÚBLICA DA DISSERTAÇÃO DE MESTRADO DE WELITON DO CARMO RODRIGUES, DISCENTE DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA, DA FACULDADE DE ENGENHARIA - CÂMPUS DE BAURU.

Aos 07 dias do mês de agosto do ano de 2025, às 14h, por meio de Videoconferência, realizou-se a defesa de DISSERTAÇÃO DE MESTRADO de WELITON DO CARMO RODRIGUES, intitulada **LOCALIZAÇÃO DE VAZAMENTOS EM REDES DE DISTRIBUIÇÃO DE ÁGUA BASEADA EM AMOSTRAGEM E AGREGAÇÃO DE GRAFOS (GRAPHSAGE)**. A Comissão Examinadora foi constituída pelos seguintes membros: Prof. Dr. EDUARDO PACIÊNCIA GODOY (Orientador(a) - Participação Virtual) do(a) Departamento de Engenharia de Controle e Automação / Instituto de Ciência e Tecnologia UNESP Câmpus de Sorocaba, Prof. Dr. IVANOVITCH MEDEIROS DANTAS DA SILVA (Participação Virtual) do(a) Departamento de Engenharia de Computação e Automação / Universidade Federal do Rio Grande do Norte, Prof. Dr. LEOPOLDO ANDRÉ DUTRA LUSQUINO FILHO (Participação Virtual) do(a) Engenharia de Controle e Automação / ICTS - Instituto de Ciência e Tecnologia de Sorocaba - UNESP. Após a exposição pelo mestrando e arguição pelos membros da Comissão Examinadora que participaram do ato, de forma presencial e/ou virtual, o discente recebeu o conceito final: *Aprovado*. Nada mais havendo, foi lavrada a presente ata, que após lida e aprovada, foi assinada pelo(a) Presidente(a) da Comissão Examinadora.

Prof. Dr. EDUARDO PACIÊNCIA GODOY



UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"
ICPEdu - Certificado Pessoal
<https://pessoal.icpedu.rnp.br/public/verificar-assinatura>

Assinado de forma
digital por Eduardo
Paciencia
Godoy:29137583808
Dados: 2025.08.07
16:37:30 -03'00'

IMPACTO POTENCIAL DESSA PESQUISA

A presente pesquisa representa um avanço significativo no campo da gestão de redes de distribuição de água ao propor e validar uma abordagem inovadora baseada em redes neurais de grafos (GraphSAGE) para a detecção e localização de vazamentos. A metodologia se destaca por incorporar uma matriz de ponderação baseada na distância física entre os nós da rede, o que permite uma representação mais realista das características hidráulicas do sistema, contribuindo para o aumento da acurácia do modelo. Esta inovação tecnológica possui um alto potencial de impacto social, econômico e ambiental, visto que vazamentos em Redes de Distribuição de Água (RDAs) representam uma das principais causas de perdas no abastecimento urbano, comprometendo a eficiência operacional e gerando impactos financeiros e ambientais significativos. Com aplicações práticas viáveis, inclusive em cenários com recursos limitados, esta solução pode auxiliar companhias de saneamento a tomarem decisões mais precisas e eficientes. Os resultados empíricos da pesquisa demonstram que o uso do algoritmo GraphSAGE, especialmente com o agregador LSTM e a matriz ponderada por distâncias, apresenta melhorias significativas na acurácia da detecção e localização de vazamentos, superando o algoritmo GGNN utilizado como referência. A contribuição desta pesquisa para a redução do desperdício de água alinha-se diretamente com o Objetivo de Desenvolvimento Sustentável (ODS) 6 das Nações Unidas, que visa assegurar a disponibilidade e a gestão sustentável da água e saneamento para todos. Ao otimizar a identificação de perdas, o trabalho fortalece a resiliência e a sustentabilidade de sistemas urbanos, promovendo uma gestão hídrica mais eficiente e inteligente.

POTENTIAL IMPACT OF THIS RESEARCH

This research represents a significant advancement in the field of water distribution network management by proposing and validating an innovative approach based on graph neural networks (GraphSAGE) for leak detection and localization. The methodology stands out by incorporating a weighting matrix based on the physical distance between network nodes, which allows for a more realistic representation of the system's hydraulic characteristics, contributing to increased model accuracy. This technological innovation has high potential for social, economic, and environmental impact, as leaks in Water Distribution Networks (WDNs) represent one of the main causes of losses in urban supply, compromising operational efficiency and generating significant financial and environmental impacts. With viable practical applications, even in resource-limited scenarios, this solution can assist water utilities in making more precise and efficient decisions. The empirical results of the research demonstrate that the use of the GraphSAGE algorithm, especially with the LSTM aggregator and the distance-weighted matrix, shows significant improvements in the accuracy of leak detection and localization, surpassing the GGNN algorithm used as a benchmark. This research's contribution to reducing water waste directly aligns with the United Nations' Sustainable Development Goal (SDG) 6, which aims to ensure the availability and sustainable management of water and sanitation for all. By optimizing leak identification, the work strengthens the resilience and sustainability of urban systems, promoting more efficient and intelligent water management.

AGRADECIMENTOS

Agradeço primeiramente a Deus, por me sustentar em cada etapa desta jornada, iluminando meus caminhos com sabedoria, força e perseverança. À minha esposa, **Ariadne Rodrigues**, pelo amor, companheirismo e incentivo incondicional. Sua paciência, apoio constante e compreensão foram fundamentais para que eu pudesse me dedicar plenamente a esta etapa da minha vida acadêmica. Ao meu orientador, **Prof. Dr. Eduardo Paciência Godoy**, por sua orientação competente, pela confiança no meu trabalho e pelo comprometimento com a minha formação. Sua dedicação e visão crítica foram essenciais para o desenvolvimento desta pesquisa. Ao meu coorientador, **Prof. Dr. Rodrigo Pita Rolle**, pela valiosa colaboração, pelas contribuições técnicas e pela disponibilidade ao longo de todo o projeto. Seu apoio e conhecimento ampliaram significativamente a qualidade deste trabalho. Aos **professores membros da banca examinadora**, pelos comentários, sugestões e contribuições que enriqueceram este trabalho e contribuíram para o meu crescimento acadêmico e pessoal. Agradeço pela atenção e generosidade em dedicar seu tempo à avaliação desta pesquisa. Agradeço à **CAPES**, pelo apoio financeiro concedido por meio da bolsa de estudos, que viabilizou a realização desta pesquisa. Este projeto foi financiado, em parte, pelo **Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq)**, sob os contratos **142383/2019-8** e **303967/2021-8**, aos quais também expresso meus sinceros agradecimentos. A todos que, de alguma forma, contribuíram para esta conquista, deixo aqui o meu muito obrigado.

CERTIFICADO DE APROVAÇÃO

Título da Dissertação de Mestrado: LOCALIZAÇÃO DE VAZAMENTOS EM REDES DE DISTRIBUIÇÃO DE ÁGUA BASEADA EM AMOSTRAGEM E AGREGAÇÃO DE GRAFOS (GRAPHSAGE)

Aluno: Weliton do Carmo Rodrigues

Orientador: Eduardo Paciencia Godoy

Coorientador: Rodrigo Pita Rolle

Aprovado como parte das exigências para obtenção do Título de Mestre em Engenharia Elétrica, Programa De Pós-Graduação em Engenharia Elétrica da Faculdade de Engenharia - Câmpus De Bauru, pela Comissão Examinadora:

Prof. Dr. EDUARDO PACIÊNCIA GODOY (Orientador)
Departamento de Engenharia de Controle e
Automação / Universidade Estadual Paulista
Câmpus de Sorocaba

 Assinado de forma digital por Eduardo Paciencia Godoy:29137583808
Dados: 2025.08.07 14:32:38 -03'00'

UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"
ICPEdu - Certificado Pessoal
<https://pessoal.icpedu.rnp.br/public/verificar-assinatura>

Prof. Dr. IVANOVITCH MEDEIROS DANTAS DA SILVA
Departamento de Engenharia de Computação e
Automação / Universidade Federal do Rio Grande do Norte

Documento assinado digitalmente
 IVANOVITCH MEDEIROS DANTAS DA SILVA
Data: 07/08/2025 17:21:23-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. LEOPOLDO ANDRÉ DUTRA LUSQUINO FILHO
Departamento de Engenharia de Controle e Automação
/ Universidade Estadual Paulista Câmpus de Sorocaba

Documento assinado digitalmente
 LEOPOLDO ANDRÉ DUTRA LUSQUINO FILHO
Data: 08/08/2025 11:05:15-0300
Verifique em <https://validar.iti.gov.br>

Bauru, 07 de agosto de 2025.

RESUMO

A rede de distribuição de água (RDA) desempenha um papel essencial na garantia do acesso confiável à água potável em comunidades urbanas e rurais. Contudo, o desperdício de água resultante de vazamentos na infraestrutura representa um desafio significativo, comprometendo a eficiência operacional e gerando impactos ambientais e financeiros. A detecção eficaz de vazamentos é uma tarefa complexa que demanda uma análise adequada dos dados, especialmente considerando as correlações existentes entre eles. Nesse contexto, a modelagem baseada em grafos proporciona uma representação robusta da estrutura das RDAs, enquanto as redes neurais de grafos (*Graph Neural Networks* – GNNs) apresentam o potencial de melhorar a precisão na detecção e localização de vazamentos. Este trabalho busca dar continuidade aos estudos sobre a aplicação de GNNs na localização de vazamentos em RDAs, propondo a utilização do algoritmo de Amostragem e Agregação de Grafos (*Graph Sample and Aggregation* – GraphSAGE) para essa tarefa. Além disso, investiga-se o uso de uma matriz de ponderação baseada nas distâncias físicas entre os nós da rede, em substituição à tradicional matriz de adjacência binária, com o objetivo de representar de forma mais realista as relações estruturais da RDA e aprimorar o aprendizado do modelo. Para a avaliação da proposta, foi utilizado como referência um estudo anterior que demonstrou a viabilidade da modelagem em grafos para essa finalidade, servindo como base comparativa para os resultados obtidos com o GraphSAGE.

Palavras-chave: Detecção de Vazamentos, Modelagem Baseada em Grafos, Redes Neurais de Grafo (GNN), Simulação de Redes de Distribuição de Água.

ABSTRACT

The water distribution network (WDN) plays an essential role in ensuring reliable access to potable water in both urban and rural communities. However, water loss caused by infrastructure leaks poses a significant challenge, compromising operational efficiency and generating environmental and financial impacts. Effective leak detection is a complex task that requires proper data analysis, especially considering the correlations among data points. In this context, graph-based modeling offers a robust representation of the structure of WDNs, while Graph Neural Networks (GNNs) have the potential to improve the accuracy of leak detection and localization. This work aims to advance studies on the application of GNNs for leak localization in WDNs by proposing the use of the Graph Sample and Aggregation (GraphSAGE) algorithm for this task. In addition, it investigates the use of a weighting matrix based on the physical distances between network nodes, as an alternative to the traditional binary adjacency matrix, with the goal of more realistically representing the structural relationships within the WDN and enhancing the model's learning process. To evaluate the proposed approach, a previous study that demonstrated the feasibility of graph-based modeling for this purpose was used as a reference, serving as a benchmark for the results obtained with GraphSAGE.

Keywords: Leakage Detection, Graph-Based Modeling, Graph Neural Networks (GNN), Water Distribution Network Simulation.

LISTA DE ABREVIATURAS E SIGLAS

AE	<i>Autoencoders</i>
ANN	<i>Artificial Neural Network</i>
CFVT	Circuito Fechado de Televisão
CNN	<i>Convolutional Neural Network</i>
EPA	<i>United States Environmental Protection Agency</i>
GAT	<i>Graph Attention Network</i>
GCN	<i>Graph Convolutional Network</i>
GraphSAGE	<i>Graph Sample and Aggregation</i>
GNN	<i>Graph Neural Network</i>
GGNN	<i>Gated Graph Neural Network</i>
GRNN	<i>Graph Recurrent Neural Network</i>
IoT	<i>Internet of Things</i>
LDA	<i>Linear Discriminant Analise</i>
LPM	Litros por Minuto
LSTM	<i>Long Short-Term Memory</i>
mca	Metros de coluna de água
ML	<i>Machine Learning</i>
ODS 6	Objetivo de Desenvolvimento Sustentável 6
ONU	Organização das Nações Unidas
RDA	Rede de Distribuição de Água
ReLU	<i>Rectified Linear Unit</i>
RNA	Redes Neurais Artificiais
RNF	Reservatório de Nível Fixo
RNV	Reservatório de Nível Variável
VS Code	<i>Visual Studio Code</i>
WL	Weisfeiler-Lehman

LISTA DE FIGURAS

Figura 1 - Panorama das técnicas empregadas na detecção de vazamentos em RDAs.....	5
Figura 2 – Exemplo de redes de distribuição	14
Figura 3 – Padrão de consumo em uma RDA para o intervalo 24 horas	17
Figura 4 - Ilustração visual da abordagem de amostragem e agregação do GraphSAGE	21
Figura 5 - Ilustração de uma RDA hipotética representando um condomínio fictício com quatro casas.....	31
Figura 6 - Fluxograma da rotina de simulação implementada utilizando o EPANET-MATLAB <i>toolkit</i>	32
Figura 7 - Conversão da estrutura da RDA em grafo	34
Figura 8 - Exemplo de grafo com suas matrizes de adjacência e distâncias	35
Figura 9 - Fluxograma de aplicação do modelo de GNN aplicado para detecção e localização de vazamentos.....	35
Figura 10 - Fluxograma final da aplicação do modelo de GNN aplicado para detecção e localização de vazamentos.....	39
Figura 11 - RDA do primeiro cenário.	42
Figura 12 – Grafo equivalente à RDA do primeiro cenário.	43
Figura 13 - Distribuição da acurácia de validação dos modelos GGNN e GraphSAGE (Mean, Pooling e LSTM) com matriz de adjacência binária e matriz ponderada por distâncias, para o Cenário 1.....	46
Figura 14 - RDA do segundo cenário.....	47
Figura 15 - Grafo equivalente à RDA do segundo cenário.	48
Figura 16 - Distribuição da acurácia de validação dos modelos GGNN e GraphSAGE (<i>Mean</i> , <i>Pooling</i> e LSTM) com matriz de adjacência binária e matriz ponderada por distâncias, para o Cenário 2.....	50

LISTA DE TABELAS

Tabela 1 – Parâmetro comuns dos modelos de RDAs gerados	32
Tabela 2 – Atribuições de rótulos para as classes de vazamentos do cenário 1.....	44
Tabela 3 – Matriz de adjacência binária do Cenário 1.	44
Tabela 4 – Matriz de distâncias do Cenário 1.	45
Tabela 5 - Atribuições de rótulos para as classes de vazamentos do cenário 2.....	49
Tabela 6 – Apresentação das métricas de avaliação dos modelos de GNNs aplicados na tarefa para o Cenário 1.....	51
Tabela 7 - Apresentação das métricas de avaliação dos modelos de GNNs aplicados na tarefa para o Cenário 2.....	52
Tabela 8 - Matriz de adjacência binária do Cenário 2.....	62
Tabela 9 - Matriz de ponderação baseada nas distâncias do Cenário 2.....	63

Sumário

1. INTRODUÇÃO	1
1.1. Apresentação do tema da pesquisa	1
1.2. Objetivo da pesquisa	2
1.3. Estrutura e conteúdo abordado	3
2. REVISÃO BIBLIOGRÁFICA	5
2.1. Detecção e localização de vazamentos	5
2.1.1. Métodos de detecção passiva	5
2.1.2. Métodos de detecção ativa	7
2.1.3. Aprendizado de máquina para detecção de vazamentos	8
2.1.4. Aplicação baseada em grafos	10
2.1.5. Uso do GraphSAGE para Detecção de Anomalias	11
3. FUNDAMENTAÇÃO TEÓRICA	13
3.1. Modelagem de redes de distribuição de água	13
3.1.1. Componentes de um modelo	15
3.1.2. Lei da conservação de massa	15
3.1.3. Lei da conservação de energia	16
3.1.4. Consumo de água	16
3.1.5. Perdas de carga	17
3.1.6. Controles	18
3.1.7. Modelagem de vazamentos	18
3.2. Redes neurais de grafo	19
3.2.1. Arquitetura e funcionamento do GraphSAGE	20
3.2.1.1. Algoritmos de geração de <i>embeddings</i>	21
3.2.1.2. Aprendizado dos parâmetros do GraphSAGE	25
3.2.1.3. Arquitetura de agregadores	25
3.3. Representação de grafos: matrizes de adjacência e matrizes ponderadas	27
3.3.1. Matriz de adjacência (binária)	27
3.3.2. Matrizes ponderadas	28
4. MATERIAIS E MÉTODOS	29
4.1. Simulação de cenários via EPANET	29
4.1.1. Configuração da rede de distribuição de água	29
4.1.2. Aquisição dos dados	31
4.1.3. Geração dos cenários	32
4.1.4. Conversão da estrutura da RDA em grafo	33

4.1.5.	Fluxograma da aplicação do modelo de GNN	35
4.1.6.	Processamento de dados.....	37
4.1.7.	Parâmetros utilizados para os algoritmos	38
4.2.	Métodos de avaliação da performance do modelo	38
5.	RESULTADOS E DISCUSSÃO	41
5.1.	Descrição dos experimentos	41
5.2.	Cenário 1	41
5.2.1.	Performance dos modelos para o Cenário 1	45
5.3.	Cenário 2	47
5.3.1.	Performance dos modelos para o Cenário 2	50
5.4.	Considerações sobre os resultados	51
6.	CONCLUSÃO.....	55
	REFERÊNCIAS.....	57
	APÊNDICES.....	62

1. INTRODUÇÃO

1.1. Apresentação do tema da pesquisa

A rede de distribuição de água (RDA) é essencial para a sustentabilidade de comunidades urbanas e rurais, fornecendo acesso seguro e confiável à água potável. A gestão sustentável dessas redes deve priorizar a acessibilidade, a qualidade, a quantidade e a confiabilidade da água (Velayudhan et al., 2022). No entanto, o desperdício causado por vazamentos na infraestrutura representa um desafio significativo, comprometendo a eficiência operacional e gerando impactos ambientais e financeiros consideráveis.

Alinhado ao Objetivo de Desenvolvimento Sustentável 6 (ODS 6) das Nações Unidas, que visa assegurar a disponibilidade e a gestão sustentável da água e do saneamento para todos, o enfrentamento das perdas em redes de distribuição tornou-se uma prioridade global. A ONU destaca que a adoção de tecnologias para detecção de vazamentos é essencial para aumentar a eficiência no uso da água, promover a sustentabilidade dos sistemas de abastecimento e fortalecer a governança dos recursos hídricos (UN-Water, 2024). Tais medidas contribuem diretamente para reduzir desperdícios, ampliar o acesso à água potável e apoiar a resiliência das infraestruturas hidráulicas, especialmente em áreas urbanas em expansão.

Entretanto, o desenvolvimento de sistemas eficazes para a detecção e localização de vazamentos em RDAs é uma tarefa desafiadora. A análise adequada dos dados provenientes de experimentos físicos ou simulações é fundamental, pois desconsiderar as correlações entre os dados pode comprometer a confiabilidade dos sistemas de detecção e afetar negativamente a precisão na localização dos vazamentos. Nesse contexto, a modelagem baseada em grafos oferece uma forma robusta de representar a estrutura e a dinâmica das RDAs, contribuindo para aumentar a eficiência na detecção de vazamentos (Mpiana et al., 2017). Mapear as interconexões entre componentes do sistema, como tubulações, válvulas e pontos de monitoramento, permite uma compreensão mais detalhada e precisa da dinâmica do sistema, facilitando uma representação visual e estrutural de redes complexas que preserva suas características e relações.

A aplicação de técnicas de aprendizado de máquina para a detecção de vazamentos em RDAs tem o potencial de melhorar a precisão e a eficiência dos sistemas já existentes (Kang et al., 2018). Integrar a capacidade de aprendizado das redes neurais à estrutura visual e relacional dos grafos utilizados na modelagem das RDAs potencializa a identificação precisa de vazamentos.

As redes neurais de grafos (*Graph Neural Networks* – GNNs) (Scarselli et al., 2009) são modelos de aprendizado de máquina que utilizam estruturas de grafos para representar e processar informações (Li et al., 2023). Compostas por nós que representam entidades ou conceitos e por arestas que indicam as relações entre esses elementos, as GNNs oferecem uma representação rica em dados interconectados, sendo particularmente adequadas para lidar com dados não euclidianos, como os presentes nas RDAs.

A representação em grafo das RDAs permite uma compreensão detalhada das interconexões entre os componentes do sistema, enquanto as GNNs possibilitam a análise e o aprendizado de padrões complexos de dados correlacionados, como variações de pressão, fluxo e vazão. A combinação dessas abordagens proporciona uma estrutura robusta para identificar e localizar vazamentos, promovendo maior precisão e eficiência, ao capitalizar as vantagens tanto dos grafos na modelagem estrutural quanto das redes neurais na interpretação e análise de dados complexos de forma mais simplificada.

1.2. Objetivo da pesquisa

Este trabalho tem como objetivo avançar na investigação sobre a viabilidade do uso de GNNs para a detecção e localização de vazamentos em RDAs. Para isso, propõe-se a utilização do algoritmo de GNN conhecido como Amostragem e Agregação de Grafos (*Graph Sample and Aggregation* - GraphSAGE) (Hamilton et al., 2017), consolidado na literatura, para realizar essa tarefa, aplicando três diferentes tipos de agregadores.

Além disso, será investigada a aplicação de uma matriz de ponderação baseada nas distâncias físicas entre os nós da rede, em substituição à tradicional matriz de adjacência binária, como forma de representar com maior fidelidade as relações estruturais da RDA e aprimorar a expressividade dos modelos GNN.

Para atingir o objetivo proposto, este estudo fundamenta-se na mesma estrutura de RDAs, bem como na metodologia de aplicação de GNNs utilizadas por Rolle (2024). Assim, este trabalho pode ser considerado uma continuação da pesquisa anterior, que também servirá como referência e *benchmark* para a avaliação dos resultados aqui obtidos.

A partir desse escopo, formulam-se as seguintes perguntas de pesquisa:

P1: A aplicação do algoritmo GraphSAGE melhora o desempenho da detecção e localização de vazamentos em RDAs modeladas como grafos, em comparação com algoritmos de GNNs utilizados anteriormente?

P2: O uso de uma matriz de ponderação baseada nas distâncias físicas entre os nós da rede, em vez da matriz de adjacência binária, melhora o desempenho do modelo GNN na tarefa de detecção e localização de vazamentos?

Para responder a essas questões, são formuladas as seguintes hipóteses:

- **H_{01} (hipótese nula da **P1**):** O uso do algoritmo GraphSAGE, com diferentes agregadores, não apresenta melhora o desempenho de detecção e localização de vazamentos em RDAs, quando comparado aos algoritmos de GNNs utilizados anteriormente.
- **H_{11} (hipótese alternativa da **P1**):** O uso do algoritmo GraphSAGE, com diferentes agregadores, apresenta melhora o desempenho de detecção e localização de vazamentos em RDAs, superando os algoritmos previamente utilizados como *benchmark*.
- **H_{02} (hipótese nula da **P2**):** O uso de uma matriz de ponderação baseada nas distâncias físicas entre os nós da rede não melhora o desempenho do modelo GNN em comparação com a matriz de adjacência binária.
- **H_{12} (hipótese alternativa da **P2**):** O uso de uma matriz de ponderação baseada nas distâncias físicas entre os nós da rede melhora o desempenho do modelo GNN em relação à matriz de adjacência binária.

Essas hipóteses serão avaliadas com base nas métricas de desempenho obtidas em diferentes cenários simulados. A análise dos resultados permitirá verificar não apenas se o GraphSAGE com diferentes agregadores apresenta superioridade em relação a outros algoritmos GNN, mas também se a substituição da matriz binária por uma matriz ponderada contribui de forma significativa para aprimorar a detecção e localização de vazamentos em RDAs.

1.3. Estrutura e conteúdo abordado

O presente trabalho é estruturado em 6 Capítulos, incluindo esta introdução e desconsiderando as referências bibliográficas.

No Capítulo 2, é realizada uma revisão bibliográfica, abordando a detecção e localização de vazamentos em RDAs, descrevendo os métodos tradicionais e a aplicação de aprendizado de máquina para essa tarefa, destacando também a utilização de GNNs neste contexto.

No Capítulo 3, é apresentada a fundamentação teórica, na qual se discute a modelagem de RDAs por meio do *software* EPANET, além de se abordar os fundamentos das GNNs, com ênfase na arquitetura do GraphSAGE e na introdução dos conceitos de matrizes de adjacência e de distâncias.

O Capítulo 4 descreve os materiais e métodos da pesquisa, detalhando o modelamento das RDAs no *software* EPANET, bem como a aquisição dos seus dados, através de simulações utilizando o EPANET-Matlab *Toolkit* (version 2.2). Nele também é apresentado o fluxograma da aplicação do algoritmo de GNN utilizado, descrevendo os hiperparâmetros adotados. Além disso, são apresentadas as métricas de avaliação empregadas para mensurar a performance do algoritmo.

No Capítulo 5, são expostos os resultados obtidos após o treinamento e validação do algoritmo nas RDAs hipotéticas utilizadas, que servem como base para discutir o potencial e as limitações das técnicas aqui implementadas.

Por fim, no Capítulo 6, são fornecidas as conclusões da pesquisa.

6. CONCLUSÃO

Esta pesquisa teve como objetivo principal investigar a aplicação do algoritmo GraphSAGE na tarefa de detecção e localização de vazamentos em RDAs, analisando seu desempenho em comparação com abordagens baseadas em GNNs previamente utilizadas, como a GGNN. Adicionalmente, buscou-se avaliar o impacto da substituição da matriz de adjacência binária por uma matriz de ponderação baseada nas distâncias físicas entre os nós da rede. As investigações foram conduzidas por meio da formulação de duas perguntas de pesquisa: (P1) se a aplicação do GraphSAGE melhora a acurácia na detecção e localização de vazamentos; e (P2) se a utilização de uma matriz de ponderação baseada em distâncias físicas melhora o desempenho do modelo GNN em comparação com a matriz binária.

Em relação à primeira pergunta de pesquisa (P1), os resultados obtidos nos cenários simulados indicaram que o algoritmo GraphSAGE, quando comparado à GGNN, apresentou melhorias nas métricas de desempenho, especialmente em termos de acurácia e F1-score. Esses ganhos foram observados com maior consistência quando utilizado o agregador LSTM. Diante disso, conclui-se que a hipótese nula H_{01} foi rejeitada e a hipótese alternativa H_{11} foi confirmada, ou seja, o uso do GraphSAGE melhora a acurácia da detecção e localização de vazamentos em RDAs, superando o algoritmo utilizado como referência.

Quanto à segunda pergunta de pesquisa (P2), verificou-se que a utilização da matriz de ponderação baseada nas distâncias físicas entre os nós também levou a melhorias no desempenho dos modelos em comparação à matriz de adjacência binária. Em ambos os cenários, a introdução dessa matriz resultou em ganhos em acurácia e estabilidade do modelo, com destaque para o Cenário 2, onde verificou-se maior sensibilidade dos modelos quanto à qualidade da representação estrutural da rede. Dessa forma, a hipótese nula H_{02} foi rejeitada e a hipótese alternativa H_{12} foi confirmada, evidenciando que a matriz baseada em distâncias contribui para o aprendizado do modelo e para a representação mais fiel das propriedades físicas da rede.

Portanto, com base nas evidências empíricas apresentadas, pode-se afirmar que ambas as contribuições propostas por esta dissertação, o uso do GraphSAGE com diferentes estratégias de agregação e a substituição da matriz binária por uma matriz ponderada por distâncias, resultaram em melhorias relevantes na tarefa de detecção e localização de vazamentos em RDAs. Os resultados obtidos reforçam o potencial da abordagem proposta para aplicações práticas no setor de saneamento, contribuindo para o desenvolvimento de sistemas inteligentes, eficientes e sustentáveis de monitoramento de perdas hídricas.

Como trabalhos futuros, sugerem-se investigações que ampliem a complexidade e o realismo dos cenários avaliados, contemplando: a incorporação da variável altura ao modelo hidráulico; a adição de ruídos aos sinais de pressão para simular leituras reais de sensores; estudos sobre a quantidade mínima e o posicionamento ótimo de sensores na rede; a aplicação do método em redes com topologia malhada ou mista; a exploração de diferentes formas de ponderação das relações entre os nós; e o uso de arquiteturas mais avançadas de GNN, especialmente aquelas baseadas em mecanismos de atenção, capazes de capturar padrões mais complexos e heterogêneos.

REFERÊNCIAS

- Abdulshaheed, A.; Mustapha, F.; Ghavamian, A. A pressure-based method for monitoring leaks in a pipe distribution system: A review. *Renewable and Sustainable Energy Reviews*, Elsevier, v. 69, p. 902–911, 2017.
- ABOU RIDA, A.; AMHAZ, R.; PARREND, P. Anomaly detection for cybersecurity using convolutional graph neural network compared to graph analysis and graph embedding. In: *International Conference on Computational Science and Computational Intelligence (CSCI)*, 2021. Proceedings [...]. Las Vegas: IEEE, 2021. p. 1234-1240.
- Adedeji, K. B.; Hamam, Y.; Abe, B. T.; Abu-Mahfouz, A. M. Towards achieving a reliable leakage detection and localization algorithm for application in water piping networks: An overview. *IEEE Access*, IEEE, v. 5, p. 20272–20285, 2017.
- Ayati, A. H.; Haghighi, A.; Lee, P. Statistical review of major standpoints in hydraulic transient-based leak detection. *Journal of Hydraulic Structures*, Shahid Chamran University of Ahvaz, v. 5, n. 1, p. 1–26, 2019.
- Battaglia, P.W., Hamrick, J.B., Bapst, V., Sanchez- Gonzalez, A., Zambaldi, V., Malinowski, M., Tacchetti, A., Raposo, D., Santoro, A., Faulkner, R., et al. (2018). Relational inductive biases, deep learning, and graph networks. arXiv preprint arXiv:1806.01261.
- Bermúdez, J.-R.; López-Estrada, F.-R.; Besançon, G.; Valencia-Palomo, G.; Torres, L.; Hernández, H.-R. Modeling and simulation of a hydraulic network for leak diagnosis. *Mathematical and computational applications*, Multidisciplinary Digital Publishing Institute, v. 23, n. 4, p. 70, 2018.
- Candelieri, A., Conti, D., and Archetti, F. (2014). A graph based analysis of leak localization in urban water networks. *Procedia Engineering*, 70, 228-237. doi:10.1016/j.proeng.2014.02.026. 12th International Conference on Computing and Control for theWater Industry, CCWI2013.
- Chan, T. K.; Chin, C. S.; Zhong, X. Review of current technologies and proposed intelligent methodologies for water distributed network leakage detection. *IEEE Access*, IEEE, v. 6, p. 78846–78867, 2018.
- Chen, C.; Li, Y.; Jiang, M. An improved GraphSAGE to detect power system anomaly based on time-neighbor feature. *Energy Reports*, v. 9, p. 930-937, 2023. DOI: <https://doi.org/10.1016/j.egyr.2022.12.055>.
- Colombo, A. F.; Lee, P.; Karney, B. W. A selective literature review of transient-based leak detection methods. *Journal of hydro-environment research*, Elsevier, v. 2, n. 4, p. 212–227, 2009.

Eliades, D. G.; Kyriakou, M.; Vrachimis, S.; Polycarpou, M. M. EPANET-MATLAB Toolkit: An open-source software for interfacing EPANET with MATLAB. In: *Proc. 14th International Conference on Computing and Control for the Water Industry (CCWI)*. The Netherlands: [s.n.], 2016. p. 8.

Fan, X., Zhang, X. & Yu, X.(B. Machine learning model and strategy for fast and accurate detection of leaks in water supply network. *J Infrastruct Preserv Resil* 2, 10 (2021). <https://doi.org/10.1186/s43065-021-00021-6>.

Gilmer, J., Schoenholz, S. S., Riley, P. F., Vinyals, O., & Dahl, G. E. (2017, July). Neural message passing for quantum chemistry. In *International conference on machine learning* (pp. 1263-1272). PMLR.

Hamilton, W.L., Ying, R., and Leskovec, J. (2017). Inductive representation learning on large graphs. In NIPS. doi:10.48550/arXiv:1706.02216[cs.SI].

Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780.

Javadiha, M.; Blesa, J.; Soldevila, A.; Puig, V. Leak localization in water distribution networks using deep learning. In: IEEE. *2019 6th International Conference on Control, Decision and Information Technologies (CoDIT)*. [S.l.], 2019. p. 1426–1431.

Kang, J., Park, Y.J., Lee, J., Wang, S.H., and Eom, D.S. (2018). Novel leakage detection by ensemble CNN-SVM and graph-based localization in water distribution systems. *IEEE Transactions on Industrial Electronics*, 65(5), 4279–4289. doi:10.1109/TIE.2017.2764861.

Kipf, T.N. and Welling, M. (2016). Semi-supervised classification with graph convolutional networks. arXiv preprint arXiv:1609.02907. doi:10.48550/arXiv.1609.02907.

Li, C.T., Tsai, Y.C., and Liao, J.C. (2023). Graph neural networks for tabular data learning. In 2023 IEEE 39th International Conference on Data Engineering (ICDE), 3589–3592. doi:10.1109/ICDE55515.2023.00275.

Liang, B.; Verma, S.; Xu, J.; Liang, S.; Li, Z.; Wang, Y.; Chen, F. A data driven approach for leak detection with smart sensors. In: IEEE. *2020 16th International Conference on Control, Automation, Robotics and Vision (ICARCV)*. [S.l.], 2020. p. 1311–1316.

Loureiro, D.; Amado, C.; Martins, A.; Vitorino, D.; Mamade, A.; Coelho, S. T. Water distribution systems flow monitoring and anomalous event detection: A practical approach. *Urban Water Journal*, Taylor & Francis, v. 13, n. 3, p. 242–252, 2016.

Lučin, I.; Lučin, B.; Čarija, Z.; Sikirica, A. Data-Driven Leak Localization in Urban Water Distribution Networks Using Big Data for Random Forest Classifier. *Mathematics* 2021, 9, 672.

Marfo, W.; Lazarova-Molnar, S.; Al-Shemmery, H. Enhancing network anomaly detection using graph neural networks. In: *Mediterranean Communication and Computer Networking Conference (MedComNet)*, 22., 2024, Roma. Proceedings [...]. Roma: IEEE, 2024. p. 1-7.

Medina, M. M. G. *Detecção de vazamentos e alterações em redes de distribuição de água para abastecimento, durante a operação, usando sinais de pressão*. Tese (Doutorado) — Universidade de São Paulo, 2017.

Mpiana, L.A., Hamam, Y., and Abu-Mahfouz, A.M. (2017). Graph based hydraulic modelling of pressure in water distribution networks. In 2017 IEEE AFRICON, 1558-1563. doi:10.1109/AFRICON.2017.8095714.

Nkemeni, V.; Mieyeville, F.; Tsafack, P. A distributed computing solution based on distributed kalman filter for leak detection in WSN-based water pipeline monitoring. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 20, n. 18, p. 5204, 2020.

Oliveira, E.; Fonseca, M.; Kappes, D.; Medeiros, A.; Stefanini, I. Leak detection system using machine learning techniques. In: *6th International Congress on Automation in Mining, At Santiago, Chile*. [S.l.: s.n.], 2018.

Pérez-Pérez, E.; López-Estrada, F. R.; Valencia-Palomo, O, G.; Torres,L.; PUIG, V.; Mina-Antonio, J. Leak diagnosis in pipelines using a combined artificial neural network approach. *Control Engineering Practice*, Elsevier, v. 107, p. 104677, 2021.

Perez, R.; Sanz, G.; Puig, V.; Quevedo, J.; Escofet, M. A. C.; Nejari, F.; Meseguer, J.; Cembrano, G.; Tur, J. M. M.; Sarrate, R.; Leak localization in water networks: A model-based methodology using pressure sensors applied to a real network in barcelona [applications of control]. *IEEE control systems magazine*, IEEE, v. 34, n. 4, p. 24–36, 2014.

Rojek, I.; Studzinski, J., Detection and localization of water leaks in water nets supported by an ICT system with artificial intelligence methods as a way forward for smart cities. *Sustainability*, Multidisciplinary Digital Publishing Institute, v. 11, n. 2, p. 518, 2019.

Rolle R.P., *Detecção e Localização de Vazamentos utilizando Internet das Coisas e Aprendizado de Máquina*. Tese (Doutorado) – Universidade Estadual Paulista “Julio de Mesquita Filho”, 2024.

Rolle R.P., Monteiro, L. N., Tomazini, L. R., Monteiro, L. N. and Godoy, E. P., “Detecção de vazamentos em redes hidráulicas utilizando Redes Neurais de Grafos”, (2022). Congresso Brasileiro de Automática - CBA. 3. 10.20906/CBA2022/3688.

Rolle, R. P., Rodrigues, W. C., Tomazini, L. R., Monteiro, L. N. and Godoy, E. P., "Leveraging graph-based leak localization in water distribution networks," 2024 IEEE International Workshop on Metrology for Industry 4.0 & IoT (MetroInd4.0 & IoT), Firenze, Italy, 2024, pp. 192-197, doi: 10.1109/MetroInd4.0IoT61288.2024.10584129.

- Romano, M.; Kapelan, Z.; SAVIĆ, D. A. Automated detection of pipe bursts and other events in water distribution systems. *Journal of Water Resources Planning and Management*, American Society of Civil Engineers, v. 140, n. 4, p. 457–467, 2014.
- Rossman, L. A.; Woo, H.; TrybyRYBY, M.; Shang, F.; Janke, R.; Haxston, T. EPANET users manual. EPA-Environmental Protection Agency, 1994.
- Scarselli, F., Gori, M., Tsoi, A.C., Hagenbuchner, M., and Monfardini, G. (2009). The graph neural network model. *IEEE Transactions on Neural Networks*, 20(1), 61-80. doi:10.1109/TNN.2008.2005605.
- Scott, S. L.; Barrufet, M. A., *Worldwide assessment of industry leak detection capabilities for single & multiphase pipelines*. [S.l.]: Offshore Technology Research Center College Station, 2003.
- SILVA, C. O. d. *Modelagem de rede de distribuição de água com ênfase no controle de perdas*. Dissertação (Mestrado) — Universidade Federal da Paraíba, 2014.
- Sun, C.; Parellada, B.; Puig, V.; Cembrano, G. Leak localization in water distribution networks using pressure and data-driven classifier approach. *Water*, Multidisciplinary Digital Publishing Institute, v. 12, n. 1, p. 54, 2020.
- Tejaswini, M.; Silo, G.; Ashwini, B. Design of water supply distribution network using EPANET software: a case study of Kuvempu Nagar, Mandya. *International Research Journal of Engineering and Technology*, v. 7, p. 1582, 2020.
- Tomazini, L.R., Rodrigues, W.C., Rolle, R.P., Simões, A.S., Colombini, E.L., and Godoy, E.P. (2024). Graphleak: A realistic dataset to detect and locate leaks in water distribution networks. URL <https://github.com/gasiepgodoy/WDN-Models-and-Data-Sets>.
- Torres, L.; Jiménez-Cabas, J.; González, O.; Molina, L.; López-Estrada, F.-R. Kalman filters for leak diagnosis in pipelines: Brief history and future research. *Journal of Marine Science and Engineering*, Multidisciplinary Digital Publishing Institute, v. 8, n. 3, p. 173, 2020.
- UN-Water. *UN World Water Development Report 2024: Water for Prosperity and Peace*. Paris: UNESCO/UN-Water, 19 mar. 2024.
- Velayudhan, N.K., Pradeep, P., Rao, S.N., Devidas, A.R., and Ramesh, M.V. (2022). Iot-enabled water distribution systems - a comparative technological review. *IEEE Access*, 10, 101042-101070. doi:10.1109/ACCESS.2022.3208142.
- Veličković, P., Cucurull, G., Casanova, A., Romero, A., Lio, P., & Bengio, Y. (2017). Graph attention networks. arXiv preprint arXiv:1710.10903.
- Walski, T. M.; Chase, D. V.; Savic D. A.; Grayman, W.; Beckwith, S.; Koelle E. Advanced water distribution modeling and management. Haestad press, 2003.

Wu, Z., Pan, S., Chen, F., Long, G., Zhang, C. and Philip. S. Y., "A Comprehensive Survey on Graph Neural Networks," in *IEEE Transactions on Neural Networks and Learning Systems*, vol. 32, no. 1, pp. 4-24, Jan. 2021, doi: 10.1109/TNNLS.2020.2978386.

Zanfei, A., Menapace, A., Brentan, B.M., Righetti, M., and Herrera, M. (2022). Novel approach for burst detection in water distribution systems based on graph neural networks. *Sustainable Cities and Society*, 86, 104090. doi:<https://doi.org/10.1016/j.scs.2022.104090>.

Zhou, B.; Lau, V.; Wang, X. Machine-learning-based leakage-event identification for smart water supply systems. *IEEE Internet of Things Journal*, IEEE, v. 7, n. 3, p. 2277–2292, 2019.

Zhou, J., Cui, G., Hu, S., Zhang, Z., Yang, C., Liu, Z., Wang, L., Li, C., Sun, M.; Graph neural networks: A review of methods and applications, *AI Open*, Volume 1, 2020, Pages 57-81, ISSN 2666-6510, doi.org/10.1016/j.aiopen.2021.01.001.

Zhou, X.; Tang, Z.; Xu, W.; Meng, F.; Chu, X.; Xin, K.; Fu, G. Deep learning identifies accurate burst locations in water distribution networks. *Water research*, Elsevier, v. 166, p. 115058, 2019.

APÊNDICES

Apêndice A – Matriz de adjacência binária e matriz de distâncias do Cenário 2.

Tabela 8 - Matriz de adjacência binária do Cenário 2.

	M	J1	J2	J3	J4	J5	J6	J7	UC1	UC2	UC3	UC4	UC5	UC6	UC7	UC8	UC9	UC10	UC11
M	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
J1	1	0	1	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0
J2	0	1	0	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0
J3	0	0	1	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0	0
J4	0	0	1	0	0	0	0	0	0	0	1	1	1	0	0	0	0	0	0
J5	0	1	0	0	0	0	1	0	0	0	0	0	0	1	1	0	0	0	0
J6	0	0	0	0	0	1	0	1	0	0	0	0	0	0	0	0	0	1	1
J7	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	1	1	0	0
UC1	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
UC2	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
UC3	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0
UC4	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0
UC5	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0
UC6	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0
UC7	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0
UC8	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0
UC9	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0
UC10	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0
UC11	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0

Fonte: Autoria própria.

Tabela 9 - Matriz de ponderação baseada nas distâncias do Cenário 2.

	M	J1	J2	J3	J4	J5	J6	J7	UC1	UC2	UC3	UC4	UC5	UC6	UC7	UC8	UC9	UC10	UC11
M	0	100	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
J1	100	0	180	0	0	131	0	0	0	0	0	0	0	0	0	0	0	0	0
J2	0	180	0	102	86	0	0	0	0	0	0	0	0	0	0	0	0	0	0
J3	0	0	102	0	0	0	0	0	150	130	0	0	0	0	0	0	0	0	0
J4	0	0	86	0	0	0	0	0	0	0	106	130	94	0	0	0	0	0	0
J5	0	131	0	0	0	0	120	0	0	0	0	0	0	98	120	0	0	0	0
J6	0	0	0	0	0	120	0	165	0	0	0	0	0	0	0	0	0	158	100
J7	0	0	0	0	0	0	165	0	0	0	0	0	0	0	0	74	150	0	0
UC1	0	0	0	150	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
UC2	0	0	0	130	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
UC3	0	0	0	0	106	0	0	0	0	0	0	0	0	0	0	0	0	0	0
UC4	0	0	0	0	130	0	0	0	0	0	0	0	0	0	0	0	0	0	0
UC5	0	0	0	0	94	0	0	0	0	0	0	0	0	0	0	0	0	0	0
UC6	0	0	0	0	0	98	0	0	0	0	0	0	0	0	0	0	0	0	0
UC7	0	0	0	0	0	120	0	0	0	0	0	0	0	0	0	0	0	0	0
UC8	0	0	0	0	0	0	0	74	0	0	0	0	0	0	0	0	0	0	0
UC9	0	0	0	0	0	0	0	150	0	0	0	0	0	0	0	0	0	0	0
UC10	0	0	0	0	0	0	158	0	0	0	0	0	0	0	0	0	0	0	0
UC11	0	0	0	0	0	0	100	0	0	0	0	0	0	0	0	0	0	0	0

Fonte: Autoria própria.