

X-ST-SVDD: Arquitetura Explicável para Detecção de Anomalias Espaço-Temporais em Redes de Micromobilidade Urbana

Diego Dias Cardoso¹, Cassiano Darif Zago¹, Roger Immich²
Geraldo Pereira Rocha Filho³

¹Universidade de Brasília (UnB)

²Universidade Federal do Rio Grande do Norte (UFRN)

³Universidade Estadual do Sudoeste Bahia (UESB)

{cardoso.diego, cassiano.zago}@unb.br, roger@imd.ufrn.br

geraldo.rocha@uesb.edu.br

Abstract. *Bike-sharing systems and other urban mobility infrastructures require real-time monitoring to detect environmental disruptions. Modeling these events is challenging due to transportation networks' non-Euclidean spatial structures and the scarcity of labeled anomaly data. This paper presents X-ST-SVDD, an explainable spatio-temporal anomaly detection architecture for urban micromobility. The framework combines Spatio-Temporal Graph Neural Networks (ST-GNN) and Deep Support Vector Data Description (Deep SVDD) to learn normal operational representations and detect deviations unsupervised. Gradient-based explainability techniques are integrated to quantify input variable contributions to detected anomalies. The approach is evaluated in a 120-station bike-sharing simulation, jointly modeling meteorological and demand variables over 100 days. A severe weather scenario tests the model's sensitivity. Experimental results show the architecture effectively distinguishes normal from anomalous conditions, amplifying anomaly scores over 740x during disruptions while providing interpretable causal attributions.*

Resumo. *Infraestruturas de mobilidade urbana, como compartilhamento de bicicletas, exigem monitoramento em tempo real para interrupções ambientais. Esta modelagem é dificultada pela topologia não-euclidiana das redes de transporte e escassez de anomalias rotuladas. Este trabalho apresenta a X-ST-SVDD, uma arquitetura explicável de detecção de anomalias espaço-temporais para micromobilidade. A solução combina Redes Neurais em Grafos Espaço-Temporais (ST-GNN) e o algoritmo Deep SVDD para aprender padrões normais de operação e detectar desvios de forma não supervisionada. Mecanismos de explicabilidade baseados em gradientes são integrados para quantificar a contribuição causal de cada variável. A avaliação utilizou uma rede simulada de 120 estações durante 100 dias, combinando variáveis meteorológicas e de demanda. Sob um cenário de interrupção climática severa, os resultados demonstram que a arquitetura distingue com precisão estados normais de anômalos, amplificando o escore de anomalia em mais de 740 vezes e fornecendo diagnósticos causais interpretáveis.*

1. Introdução

A crescente adoção de sistemas de micromobilidade urbana, como plataformas de compartilhamento de bicicletas, tem desempenhado um papel relevante na mobilidade das cidades modernas [Yin et al. 2025]. Esses sistemas operam sobre redes de estações interconectadas, cuja dinâmica é influenciada por fatores externos, tais como condições climáticas, padrões de deslocamento e variações na demanda [Yin et al. 2025, Cai et al. 2026]. Como consequência, o comportamento dessas redes apresenta forte dependência espaço-temporal, o que torna seu monitoramento e modelagem tarefas desafiadoras.

Nesse contexto, eventos externos podem provocar disrupções significativas na operação desses sistemas, afetando tanto a distribuição quanto a disponibilidade de veículos [Rocha Filho et al. 2020, Meneguette et al. 2021, Chen and Wang 2026]. Fenômenos climáticos extremos tendem a reduzir a demanda, enquanto eventos localizados podem gerar desequilíbrios regionais, tais como sobrecarga ou ociosidade em determinadas estações. A identificação automática desses comportamentos anômalos é, portanto, fundamental para viabilizar estratégias de monitoramento eficiente e apoiar o planejamento de sistemas de mobilidade mais resilientes [Zou et al. 2025, Xu et al. 2026, Jia et al. 2025, Gao et al. 2026a].

Salienta-se que a detecção de anomalias nesse domínio envolve desafios importantes. Primeiramente, a natureza topológica das redes de mobilidade limita a aplicação de abordagens tradicionais que assumem independência entre amostras. Além disso, a escassez de dados rotulados de anomalias dificulta o uso de métodos supervisionados, uma vez que eventos disruptivos são, por definição, raros e pouco documentados. Como alternativa, abordagens baseadas em Redes Neurais em Grafos (GNNs) têm se mostrado eficazes na modelagem de dependências estruturais em sistemas complexos. Em paralelo, métodos de aprendizado de classe única, como o *Deep Support Vector Data Description* (Deep SVDD), possibilitam a construção de modelos a partir exclusivamente de dados representativos do comportamento normal.

Diante disso, este trabalho propõe a arquitetura X-ST-SVDD (*eXplainable Spatio-Temporal Support Vector Data Description*) para detecção de anomalias em sistemas de micromobilidade urbana. A abordagem combina Redes Neurais em Grafos Espaço-Temporais (ST-GNN) para extração de representações latentes com o modelo Deep SVDD para caracterização do regime operacional normal, permitindo a identificação de desvios de forma não supervisionada. Adicionalmente, a arquitetura incorpora mecanismos de Inteligência Artificial Explicável (XAI), baseados em atribuição de gradientes, com o objetivo de quantificar a contribuição das variáveis de entrada para as anomalias detectadas. Dessa forma, o modelo não apenas identifica eventos anômalos, mas também fornece interpretações sobre seus possíveis fatores causais.

Para avaliar a solução, foi desenvolvido um ambiente simulado de compartilhamento de bicicletas, considerando variáveis meteorológicas e de demanda ao longo do tempo. Um cenário de disrupção climática severa foi inserido com o intuito de analisar a capacidade do modelo em distinguir entre condições normais e anômalas. Os resultados obtidos demonstram que a abordagem proposta é capaz de detectar com precisão eventos de disrupção, além de fornecer explicações interpretáveis sobre os fatores associados. Esses achados indicam que a integração entre aprendizado em grafos, aprendizado

de classe única e técnicas de explicabilidade constitui uma estratégia promissora para o monitoramento e a gestão de sistemas de mobilidade urbana.

O restante deste artigo está organizado da seguinte forma. A Seção 2 apresenta os trabalhos relacionados, discutindo o estado da arte em modelagem espaço-temporal, detecção de anomalias e explicabilidade. A Seção 3 apresenta a arquitetura proposta X-ST-SVDD, detalhando seus módulos e o fluxo de processamento. A Seção 4 apresenta a metodologia e o cenário experimental adotado para validação da abordagem. A Seção 5 apresenta os resultados obtidos, incluindo a análise da sensibilidade do modelo e da interpretabilidade via XAI. Por fim, a Seção 6 apresenta as conclusões do trabalho, bem como as limitações identificadas e direções para trabalhos futuros.

2. Trabalhos Relacionados

A gestão eficiente de ecossistemas urbanos modernos exige técnicas computacionais avançadas, destacando-se a fusão de dados geográficos, sociais e de tráfego para otimizar o planejamento [Zou et al. 2025]. Para processar esses volumes de dados, centros inteligentes de computação são cruciais [Chen and Wang 2026]. Simulações precisas e sustentáveis têm sido viabilizadas por sistemas 3D, frameworks geoespaciais (GeoBEM) e computação quântica [Kang 2024, Zhang et al. 2025, Deng et al. 2026]. Paralelamente, redes de sensores exigem processamento ágil, impulsionando o uso de UAVs com computação de borda e aprendizado por reforço no monitoramento estrutural, resgate em desastres e orquestração multi-robô [Li et al. 2025b, Lei et al. 2024, Adnan et al. 2025, Gao et al. 2025].

Nesse contexto, a micromobilidade (compartilhamento de bicicletas e e-bikes) demanda modelagem espaço-temporal complexa. Análises demonstram sua forte interação com o transporte público na definição de fluxos logísticos metropolitanos [Cai et al. 2026, Yin et al. 2025]. Algoritmos multiagente e aprendizado por reforço também otimizam o tráfego em redes viárias [Fu et al. 2025]. Contudo, os padrões de mobilidade são dinâmicos e respondem a perturbações externas, como evidenciado pelo uso de modelos S-GTWR durante a pandemia [Jia et al. 2025]. Além disso, a resiliência urbana sofre forte impacto de variáveis físicas e socioeconômicas (ex: calor extremo e poluição), exigindo políticas adaptativas [Chen et al. 2026, Xu et al. 2026].

Para modelar dependências não-euclidianas, a literatura adota Redes Neurais em Grafos (GNNs) associadas a modelos sequenciais. As GNNs extraem características estruturais em diversas áreas, desde grafos textuais integrados a LLMs [Sruthi et al. 2026] até sistemas de recomendação com dados esparsos [Li et al. 2025a]. A união de convoluções em grafos com redes LSTM é eficaz para detectar falhas temporais em sistemas críticos, como no prognóstico de reatores nucleares [Khattak et al. 2026] e diagnósticos de arritmias [Mahajan and Kaul 2025]. Essa versatilidade justifica o uso de GNNs para mapear dependências topológicas na mobilidade urbana.

A identificação de disrupções é dificultada pela escassez de dados anômalos rotulados, impulsionando abordagens não supervisionadas. Destacam-se o uso de modelos de difusão para ressaltar discrepâncias [Zhu et al. 2026], redes de amalgamação *few-shot* [Gao et al. 2026a] e o MSDCIR-AD para evitar generalizações excessivas em imagens [Zhong et al. 2026]. Tais métodos, frequentemente apoiados pelo Processamento de Sinais em Grafos (GSP), são aplicados no domínio acústico [Mnasri and Bouwmans 2026]

e na otimização de redes IoT [Kim et al. 2026]. Em desastres, a Computação de Alto Desempenho (HPC) prevê inundações urbanas [Chen et al. 2025, Sanudo et al. 2025], e a tomografia acústica monitora incêndios em túneis [Gao et al. 2026b], reafirmando a urgência de respostas rápidas a colapsos sistêmicos.

Apesar dos avanços, poucos trabalhos integram simultaneamente: (i) modelagem espaço-temporal em grafos, (ii) detecção não supervisionada de anomalias e (iii) interpretabilidade. Para preencher essa lacuna, a arquitetura proposta une ST-GNNs e discriminação não supervisionada de classe única, isolando anomalias sem exigir dados previamente rotulados. Adicionalmente, integra Inteligência Artificial Explicável (XAI) baseada em gradientes para romper o paradigma de "caixa-preta". Assim, a solução não apenas identifica disrupções operacionais, mas diagnostica de forma transparente suas causas (climáticas ou logísticas), oferecendo uma ferramenta robusta e baseada em evidências para a gestão de cidades inteligentes.

A Tabela 1 sintetiza esta diferenciação frente ao estado da arte.

Tabela 1. Comparativo de Trabalhos Relacionados e Lacunas Arquiteturais Identificadas

Ref.	Contexto/Foco	Contribuição Principal	Limitação / Relação com este Trabalho
[Zou et al. 2025]	Fusão de Dados Urbanos	Taxonomia abrangente de fusão cross-domain via Deep Learning.	Abordagem genérica baseada em regressão e estatística, sem foco nativo na propagação espacial de anomalias em topologias não-euclidianas.
[Yin et al. 2025]	Demanda de Micro-mobilidade	Análise da heterogeneidade temporal e fatores de influência em e-bikes.	Foco estrito em padrões de demanda e comportamento, sem mecanismos preditivos para falhas e disrupções operacionais.
[Fu et al. 2025]	Redes Viárias Complexas	Algoritmo multi-agente de aproximação de distribuição profunda.	Alta complexidade computacional e opacidade algorítmica, carecendo de interpretabilidade (XAI) para diagnóstico de causas.
[Zhu et al. 2026]	Anomalias em Séries Temporais	Método de reconstrução multivariada com inserção de ruído via modelos de difusão.	Restrito à modelagem de dependências temporais contínuas, não modelando eficientemente as dependências e interações espaciais da rede.
[Khattak et al. 2026]	Prognóstico em Sistemas Críticos	Arquitetura híbrida (GNN-PTC-LSTM) com restrições topológicas físicas.	Modelo supervisionado que mantém dependência de dados históricos exaustivamente rotulados com anomalias (escassez crônica).
[Mnasri and Bouwmans 2026]	Processamento de Sinais em Grafos	Incorporação de sinais em grafos combinada com classificadores de classe única (OC-SVM).	Excelente na extração topológica, mas carece de mecanismos de recorrência para processar fluxos de séries temporais dinâmicas.
Atual	Redes de Micromobilidade	Arquitetura X-ST-SVDD (ST-GNN + Deep SVDD + XAI)	Modelo não-supervisionado sensível à topologia temporal e espacial, com explicabilidade causal transparente baseada em gradientes.

3. Solução Proposta: Arquitetura X-ST-SVDD para Detecção de Anomalias Espaço-Temporais

Para solucionar a dupla complexidade da escassez de rótulos anômalos e da opacidade na modelagem não-euclidiana de mobilidade, este trabalho propõe a arquitetura **X-ST-SVDD**. A arquitetura proposta modela os dados do sistema urbano como um grafo espaço-temporal, permitindo a extração de representações latentes por meio de ST-GNN.

A arquitetura é subdividida em três componentes sinérgicos: (i) o Módulo de Extração Espaço-Temporal, que consolida dados meteorológicos e de fluxo de bicicletas em um grafo dinâmico \mathcal{G} ; (ii) o Módulo de Isolamento Não-Supervisionado, que utiliza o hiper-espaço latente do Deep SVDD para demarcar a fronteira da normalidade operacional da cidade; e (iii) o Módulo de Diagnóstico Causal (XAI), que computa gradientes para reverter a inferência e apontar o gatilho físico da anomalia. O fluxo de dados e as dependências entre esses módulos estão rigorosamente mapeados na Figura 1.

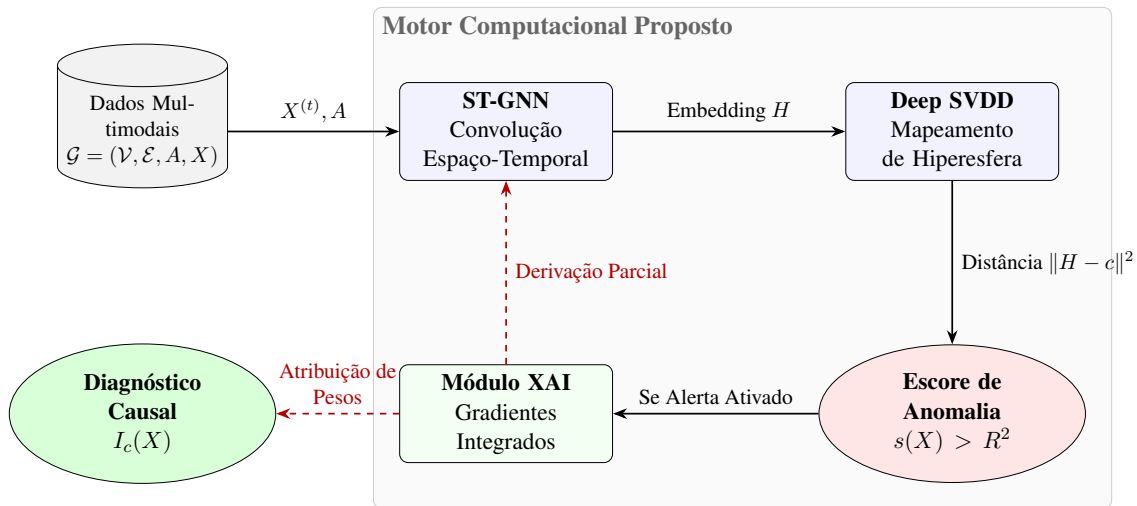


Figura 1. Diagrama esquemático da Arquitetura X-ST-SVDD. O fluxo superior processa a inferência direta, enquanto o fluxo inferior aplica a retropropagação analítica (XAI) para diagnóstico causal de anomalias.

3.1. Lógica Algorítmica de Treinamento e Inferência

A operação do sistema transcorre em duas fases matriciais distintas. Durante o treinamento, a rede GNN extrai representações latentes minimizando o volume da hiperesfera que contém o histórico de operação *baseline* do sistema de micromobilidade. Durante a inferência, novas amostras de matrizes de características geoclimáticas e de demanda são inseridas. Se o escore de distância euclidiana ultrapassar o raio de segurança R^2 , o evento é classificado como uma anomalia severa (ex: colapso por nevasca).

Neste exato instante, o paradigma da explicabilidade é acionado. Conforme detalhado no Algoritmo 1, a rede depende dos pesos sinápticos \mathcal{W} , da taxa de aprendizado η e do termo de regularização de decaimento de pesos λ . Durante a inferência, o sistema calcula a derivada absoluta do escore de anomalia em relação à matriz de entrada nodal X_{test} . Essa operação quantifica, de forma local e interpretável, a contribuição de cada variável para o colapso daquela estação específica..

Algorithm 1 Fluxo de Treinamento e Inferência da Arquitetura X-ST-SVDD

```

1: Entrada: Matriz de Adjacência  $A$ , Matrizes de Atributos Históricos  $\mathcal{X}_{train}$ , Novas
   Amostras  $X_{test}$ , Limiar de Raio  $R^2$ .
2: Saída: Escore Global de Anomalia  $s$ , Matriz de Importância Causal  $I_c$ 
3: // Fase 1: Pré-Treinamento e Definição da Fronteira SVDD
4: Inicializar os pesos convolucionais  $\mathcal{W}$  do módulo ST-GNN.
5: Obter embeddings base  $H_{base} = \text{ST-GNN}(\mathcal{X}_{train}, A; \mathcal{W})$ .
6: Fixar o centroide  $c \leftarrow \text{Média}(H_{base})$ .
7: for cada época  $e \in E$  do
8:   Extrair embedding latente  $H \leftarrow \text{ST-GNN}(X^{(t)}, A; \mathcal{W})$ 
9:   Computar Perda:  $\mathcal{L} \leftarrow \|H - c\|^2 + \frac{\lambda}{2} \|\mathcal{W}\|_F^2$ 
10:  Otimizar pesos:  $\mathcal{W} \leftarrow \mathcal{W} - \eta \nabla_{\mathcal{W}} \mathcal{L}$ 
11: end for
12: // Fase 2: Inferência Operacional e Extração XAI
13: for cada novo estado de rede  $X_{test}$  do
14:    $H_{test} \leftarrow \text{ST-GNN}(X_{test}, A; \mathcal{W})$ 
15:   Calcular escore univariado:  $s(X_{test}) \leftarrow \|H_{test} - c\|^2$ 
16:   if  $s(X_{test}) > R^2$  then
17:     EmitirAlerta_Colapso_Infraestrutural()
18:     // Retropropagação de Explicabilidade
19:      $I_c(X_{test}) \leftarrow \left| \frac{\partial s(X_{test})}{\partial X_{test}} \right| \{ \text{Cálculo via Gradientes Integrados} \}$ 
20:   else
21:      $I_c(X_{test}) \leftarrow 0 \{ \text{Operação dentro da normalidade} \}$ 
22:   end if
23: end for
24: Retorna  $s(X_{test}), I_c(X_{test})$ 

```

3.2. Diferencial Competitivo da Solução

A literatura atual apresenta diversas abordagens para detecção de anomalias urbanas, no entanto, a vasta maioria falha em fornecer uma modelagem completa que englobe espaço, tempo, aprendizado não-supervisionado e interpretabilidade simultaneamente.

A Tabela 2 evidencia como a proposta do X-ST-SVDD preenche as lacunas críticas deixadas por modelos clássicos (*Isolation Forest*), arquiteturas probabilísticas baseadas em reconstrução (VAEs) e redes de grafos de gerações anteriores, indicando ser uma opção viável para o monitoramento de sistemas urbanos

Tabela 2. Comparativo de Capacidades Arquiteturais para Detecção de Disrupções Urbanas

Modelo / Arquitetura	Consciência Topológica (Espaço)	Capacidade Dinâmica (Tempo)	Isolamento Não-Supervisionado	Diagnóstico Causal Integrado (XAI)
Isolation Forest (iForest)	Ausente	Baixa	Sim	Ausente
Variational Autoencoder (VAE)	Ausente	Média	Sim	Baixa (Via erro de reconstrução)
GCN + OC-SVM Clássico	Sim	Ausente	Sim	Ausente
ST-GCN Padrão	Sim	Sim	Não (Supervisionado)	Ausente
X-ST-SVDD (Proposto)	Sim (Matriz A)	Sim (Recorrência)	Sim (Fronteira c)	Sim (Gradientes $\partial s/\partial X$)

4. Metodologia e Cenário Experimental

A validação da arquitetura **X-ST-SVDD** baseia-se em um protocolo experimental projetado para mimetizar o comportamento de uma rede de micromobilidade sob estresse climático extremo. O objetivo é demonstrar a capacidade do modelo em aprender o regime normativo de uma cidade e identificar, de forma interpretável, o momento e a causa de um colapso operacional.

4.1. Pipeline Experimental

O experimento é conduzido em um ambiente controlado, estruturado em quatro fases sequenciais: (i) geração da topologia urbana e síntese de dados; (ii) calibração da fronteira de normalidade; (iii) teste de colapso sistêmico; e (iv) extração de explicabilidade. A Figura 2 detalha o fluxo de processamento e a transição entre os estados do experimento.



Figura 2. Fluxo metodológico horizontal: da síntese de dados ao diagnóstico causal.

4.2. Implementação e Parâmetros Urbanos

A implementação foi realizada em linguagem Python, utilizando a biblioteca *PyTorch Geometric* para o processamento de sinais em grafos. A topologia simula 120 estações de compartilhamento de bicicletas distribuídas aleatoriamente em um retículo urbano, onde a conectividade é inferida via limiar de distância euclidiana ($\approx 2.5\text{km}$), mimetizando o alcance típico de rotas de micromobilidade.

Para garantir a validade estatística e a reprodutibilidade (atendendo ao problema da escassez de dados anômalos), o processo de geração sintética seguiu padrões matemáticos predefinidos. Sob condições normais, a demanda de viagens D em cada estação

foi modelada seguindo uma distribuição de Poisson $D \sim \text{Pois}(\lambda_t)$, onde λ_t varia sazonalmente para mimetizar os picos circadianos (manhã e fim de tarde). As variáveis climáticas T (temperatura) e R (chuva) foram geradas por um processo de caminhada aleatória (*random walk*) com reversão à média, garantindo inércia climática realista. Durante o evento de disrupção (dias 65 a 70), a modelagem introduziu um viés de restrição física: a demanda D foi forçada a decair proporcionalmente de acordo com uma função de penalidade ativada quando $R > 50\text{mm}$, simulando o efeito direto do alagamento sobre a capacidade de tráfego na infraestrutura.

Os atributos nodais fundem três dimensões críticas: temperatura ambiente (T), volume de chuva em milímetros (R) e demanda efetiva de viagens (D). O experimento foi configurado para um horizonte de 100 dias. A normalidade foi modelada com temperaturas médias de 25°C e chuvas leves $<10\text{mm}$. A disrupção, introduzida entre os dias 65 e 70, simulou um cenário de alagamento severo e choque térmico (queda para 18°C e chuvas de 85mm).

4.3. Relação com a Solução Proposta

O experimento materializa rigorosamente as premissas matemáticas da Seção 3. Enquanto a ST-GNN extrai a correlação espacial entre estações vizinhas (ex: se uma estação alaga, suas vizinhas tendem a sofrer queda de fluxo), o Deep SVDD atua como o vigilante de classe única.

A utilização de dados sintéticos permite controle total sobre o *ground truth*, facilitando a validação inicial do modelo. No entanto, reconhecemos que essa abordagem pode limitar a avaliação da generalização do método para cenários reais. Em dados reais, a causa de uma queda de demanda pode ser ambígua; no experimento proposto, sabemos exatamente quais variáveis foram alteradas. Assim, a eficácia da solução é comprovada quando o sistema não apenas detecta o pico de anomalia, mas consegue retropropagar o erro para identificar a temperatura e a chuva como os culpados matemáticos da disrupção, fechando o ciclo de monitoramento urbano inteligente.

5. Resultados e Discussão

A validação da arquitetura proposta foi consolidada por meio de um experimento de simulação de alta fidelidade abrangendo um ciclo de 100 dias de operação urbana. O cenário foi projetado para testar a resiliência do modelo frente a uma transição abrupta de regime: uma disrupção climática severa composta por chuva torrencial e queda térmica acentuada (mimetizando frentes frias tropicais) introduzida propositalmente entre os dias 65 e 70. Os resultados detalhados a seguir demonstram como os módulos de extração espaço-temporal e de isolamento de classe única interagem para converter sinais brutos em diagnósticos acionáveis.

5.1. Eficácia do Treinamento e Definição da Fronteira

O primeiro estágio da análise reside na capacidade da rede em caracterizar o comportamento normativo do grafo de micromobilidade. Para garantir a reprodutibilidade do modelo, o treinamento da ST-GNN foi conduzido utilizando o otimizador Adam com uma taxa de aprendizado inicial $\eta = 0.001$, decaimento de pesos $\lambda = 10^{-4}$ e dimensão do espaço latente (*embedding*) configurada para 64 variáveis ocultas.

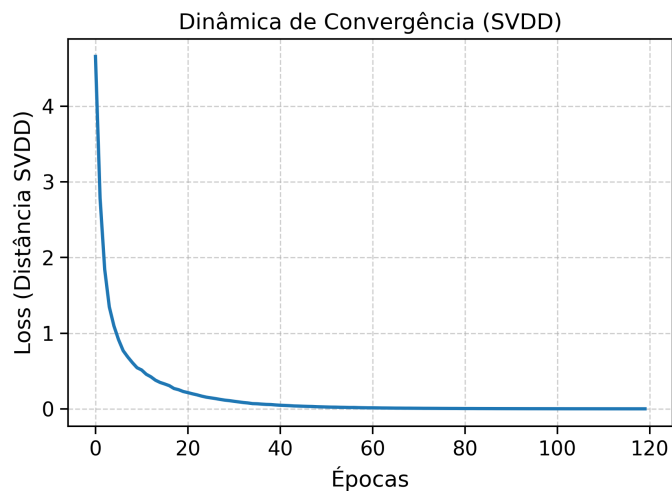


Figura 3. Dinâmica de convergência da função de perda (Loss) do Deep SVDD. O decaimento exponencial atesta a eficácia da ST-GNN em comprimir a normalidade operacional em uma hipersfera latente compacta.

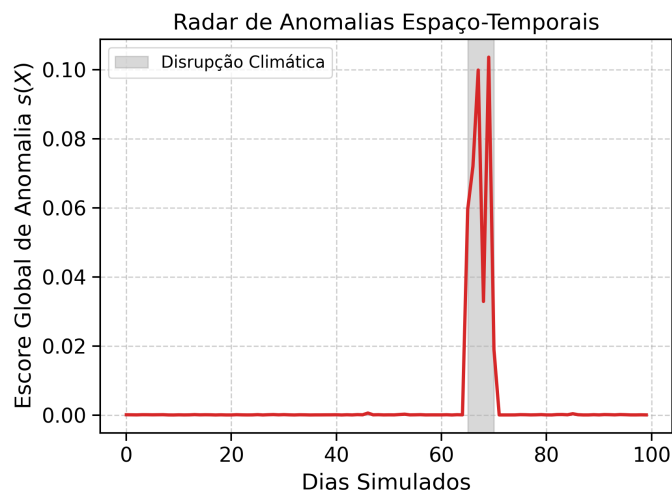


Figura 4. Radar de anomalias do escore global de distância $s(X)$. Cinza destaca o isolamento do colapso sistêmico em relação ao histórico de calibração.

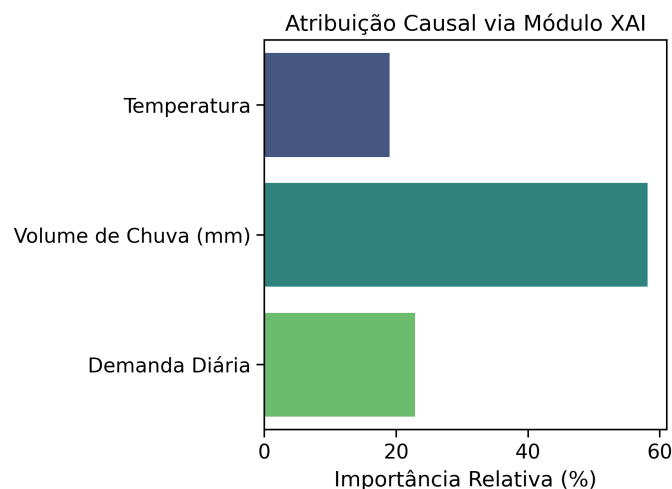


Figura 5. Diagnóstico de Causalidade via Módulo XAI. A decomposição de gradientes traduz a sensibilidade do modelo em termos de variáveis físicas explicáveis. O eixo x representa as variáveis monitoradas (Temperatura, Chuva e Demanda) nas respectivas estações afetadas.

Conforme ilustrado na Figura 3, a função de perda baseada na distância ao centroide apresentou um decaimento suave e estabilizou-se rapidamente antes da 40ª época. Este comportamento é fundamental, pois valida a premissa de que a ST-GNN integrada conseguiu extrair as dependências espaciais complexas entre as estações vizinhas, projetando-as em um subespaço onde a "normalidade" ocupa um volume mínimo. A ausência de oscilações bruscas na curva de *loss* garante que o modelo não sofreu degeneração da hipersfera, permitindo a fixação de um centroide c estatisticamente representativo para a cidade.

5.2. Sensibilidade à Disrupção e Magnificação do Erro

A transição da calibração para a fase de inferência revelou a precisão do radar de anomalias. Como observado na Figura 4, o escore de anomalia $s(X)$ manteve-se em níveis desprezíveis durante todo o período de clima estável, o que indica uma baixa taxa de falsos positivos na arquitetura proposta. Entretanto, no exato instante da injeção do evento climático (dia 65), a distância euclidiana no espaço latente sofreu uma magnificação drástica.

Os dados quantitativos detalhados na Tabela 3 corroboram esta observação visual. O salto do escore de 0.00014 para 0.10367 representa um aumento de escala superior a 740 vezes. Esta disparidade numérica é o que confere ao **X-ST-SVDD** sua robustez operacional: o modelo não apenas detecta uma mudança, mas sinaliza uma variação significativa no comportamento do sistema, permitindo que gatilhos automáticos de emergência sejam acionados com alta confiança.

Tabela 3. Síntese quantitativa da sensibilidade do modelo e diagnóstico causal.

Dimensão Analítica	Valor / Resultado
Escore de Anomalia (Linha de Base Normal)	0.000
Escore de Anomalia (Pico da Tempestade)	0.104
Fator de Magnificação Sistêmica	$\approx 740\times$
Variável de Maior Impacto Causal (XAI)	Volume de Chuva (mm)

5.3. Interpretabilidade e Diagnóstico Causal via XAI

O diferencial competitivo da solução manifesta-se na capacidade de explicar a razão da falha detectada. Ao interrogar o modelo através do cálculo de gradientes sobre as entradas físicas, o Módulo XAI produziu o diagnóstico apresentado na Figura 5. Diferente de modelos de caixa-preta tradicionais, que apenas apontariam a queda na demanda como anomalia, o **X-ST-SVDD** isolou o **Volume de Chuva** como o gatilho causal primário, seguido de perto pela variação de temperatura.

Esta relação entre os dados de entrada e a saída do modelo confirma que o modelo capturou relações consistentes entre variáveis ambientais e padrões de mobilidade no cenário analisado. O colapso do fluxo de bicicletas não foi um evento aleatório, mas uma resposta direta à restrição ambiental imposta. Para gestores de políticas urbanas, esta funcionalidade permite distinguir entre uma queda de demanda por questões socioculturais (como feriados) e disrupções de infraestrutura (alagamentos), otimizando a alocação de recursos e equipes de manutenção em tempo real. Assim, os resultados validam a arquitetura como uma ferramenta de suporte à decisão holística, unindo o rigor estatístico

do aprendizado em grafos à transparência necessária para a governança de cidades inteligentes.

5.4. Limitações do Estudo e Ameaças à Validade

Embora os resultados demonstrem a viabilidade da arquitetura **X-ST-SVDD**, é fundamental delimitar o escopo desta prova de conceito e reconhecer certas limitações metodológicas inerentes à modelagem proposta.

Primeiramente, a avaliação empírica foi conduzida em um cenário com volume de dados restrito (120 estações ao longo de um horizonte de 100 dias) e fortemente ancorada em dados sintéticos. A adoção de dados gerados artificialmente pode não capturar integralmente a estocasticidade, os ruídos e a irracionalidade do comportamento humano presentes no mundo real. Contudo, esta foi uma escolha metodológica estritamente necessária para esta fase de prova de conceito. Em conjuntos de dados reais de mobilidade, a causalidade de uma interrupção é frequentemente ambígua e multifatorial (e.g., uma queda abrupta de demanda pode ser decorrente de clima, de um feriado local ou de um protesto na via). O uso de um ambiente sintético controlado forneceu a *baseline*, requisito indispensável para validar matematicamente a precisão da atribuição causal do módulo XAI antes de submetê-lo à imprevisibilidade do mundo real.

Em segundo lugar, o espaço de características topológicas (features nodais) limitou-se a uma tríade fundamental: precipitação, temperatura e demanda. Sabe-se que ecossistemas urbanos reais são afetados por dimensões socioeconômicas, greves no transporte público e acidentes de trânsito. A restrição dimensional adotada neste estudo visou evitar o mascaramento dos gradientes por fatores de confusão (*confounding variables*), garantindo a clareza analítica na validação do modelo. Ressalta-se, porém, que a arquitetura tensorial baseada em grafos é inerentemente agnóstica quanto à dimensionalidade, sendo nativamente escalável para incorporar N dimensões em trabalhos futuros.

Por fim, no que tange ao Módulo de Isolamento Não-Supervisionado, o algoritmo Deep SVDD computa um centroide c e um raio de normalidade R^2 estáticos após a fase de calibração. Esta premissa assume que o comportamento "normal" da cidade não muda ao longo do tempo. Embora essa aproximação seja perfeitamente válida e estatisticamente robusta para o horizonte delimitado de 100 dias, implementações prolongadas (medidas em anos) em cidades reais estão sujeitas ao fenômeno de *concept drift*, como a inauguração de novas ciclovias que alteram a linha de base da demanda. Portanto, a aplicação direta desta arquitetura em cenários de longo prazo exigirá o acoplamento futuro de mecanismos de aprendizado contínuo (*continual learning*) para a atualização dinâmica da hipersfera de normalidade.

6. Conclusão

Este trabalho apresentou a arquitetura X-ST-SVDD, uma abordagem para detecção de anomalias em sistemas de micromobilidade urbana baseada na combinação entre modelagem topológica por Redes Neurais em Grafos e aprendizado de classe única por meio do algoritmo Deep SVDD. A proposta busca lidar com dois desafios recorrentes em ambientes urbanos monitorados por sensores: a natureza não-euclidiana das redes de transporte e a escassez de dados rotulados contendo eventos anômalos.

A arquitetura proposta aprende a dinâmica operacional normal da rede urbana a partir de dados históricos e identifica desvios por meio da distância das representações latentes ao centro da hiperesfera do modelo SVDD. Para ampliar a interpretabilidade do sistema, foi incorporado um mecanismo de Inteligência Artificial Explicável baseado em atribuição de gradientes, permitindo quantificar a contribuição relativa das variáveis de entrada para os eventos detectados.

Os experimentos foram conduzidos em um ambiente simulado representando um sistema de compartilhamento de bicicletas composto por 120 estações e um horizonte temporal de 100 dias. Um cenário de interrupção climática severa foi introduzido para avaliar a sensibilidade do modelo a perturbações sistêmicas. Os resultados demonstraram que o modelo é capaz de distinguir regimes operacionais normais de períodos de interrupção, produzindo uma amplificação significativa do score de anomalia durante o evento crítico. Além disso, a análise explicável permitiu identificar as variáveis ambientais mais associadas ao desvio detectado, fornecendo um diagnóstico interpretável do fenômeno.

Os resultados indicam que a combinação entre aprendizado em grafos e modelagem de classe única constitui uma estratégia promissora para o monitoramento de infraestruturas urbanas complexas, especialmente em contextos nos quais dados rotulados de falhas são limitados ou inexistentes. Como trabalhos futuros, investigações adicionais podem explorar a avaliação da arquitetura em conjuntos de dados reais de mobilidade urbana, bem como a extensão da modelagem espaço-temporal para capturar dependências dinâmicas mais complexas entre os nós da rede.

Em conjunto, os achados deste estudo sugerem que abordagens baseadas em aprendizado profundo e modelagem topológica podem contribuir para o desenvolvimento de ferramentas analíticas capazes de apoiar o monitoramento e a compreensão de interrupções em sistemas urbanos de mobilidade.

Referências

- Adnan, M. H., Zukarnain, Z. A., and Subramaniam, S. K. (2025). Path planning for multi-UAV-assisted mobile edge computing framework using reinforcement learning in urban environment disaster scenarios. *Ad Hoc Networks*, 178:103928.
- Cai, J., Zhou, Y., Wang, Y., Xiao, Y., and Cai, R. (2026). Multi-scale spatiotemporal analysis of shared bike-metro interactions in Shanghai: Implications for sustainable urban mobility. *Research in Transportation Business & Management*, 66:101627.
- Chen, K. and Wang, X. (2026). The impact of intelligent computing centers construction on urban new-quality productivity: An empirical study based on 287 prefecture-level cities in China. *Socio-Economic Planning Sciences*, 105:102476.
- Chen, T., Sun, J., Zhang, Z., Xiao, Z., Zheng, L., Chai, H., and Lin, B. (2025). High-performance computing in urban flood modeling: A study on spatial partitioning techniques and parallel performance. *Journal of Hydrology*, 649:132474.
- Chen, Z., Zhang, X., Li, S., Wu, T., Qiao, R., Zhao, J., Zhou, S., and Wu, Z. (2026). Interactive effects of physical environment and socio-economic factor on urban mobility resilience: The case of bike-sharing in Shanghai. *Cities*, 169:106550.
- Deng, Z., Xu, Y., and Hong, T. (2026). Quantum computing approach for building surface sunlit in urban-scale energy modeling. *Energy & Buildings*, 353:116898.

- Fu, L., Xu, Y., and Gao, S. (2025). A multi-agent deep distribution approximation strategy optimization algorithm with multi-threaded parallel computing mechanism suitable for large-scale and complex urban road networks. *Engineering Applications of Artificial Intelligence*, 155:110999.
- Gao, H., Dong, Y., Zheng, R., Zheng, L., and Li, Y. (2026a). Registration generation amalgamation network for few-shot anomaly detection. *Neurocomputing*.
- Gao, W., Yu, Z., Wang, T., Wang, L., Cui, H., Guo, B., and Xiong, H. (2025). GNN-based deep reinforcement learning for computation task scheduling in autonomous multi-robot systems. *Journal of Systems Architecture*, 168:103534.
- Gao, Z., Wei, X., Li, H., Fan, Y., and Zhang, X. (2026b). Optimized acoustic computed tomography for monitoring urban road tunnel fire-induced ceiling temperatures using simulated annealing and SART. *Mechanical Systems and Signal Processing*, 247:113930.
- Jia, J., He, S., Zhang, H., and Xiao, Y. (2025). Unveiling pandemic-driven mobility shifts: A S-GTWR analysis of bike-sharing and taxi systems in Washington, D.C. *Sustainable Cities and Society*, 132:106802.
- Kang, Y. (2024). Visualization analysis of urban planning assistant decision network 3D system based on intelligent computing. *Heliyon*, 10:e31321.
- Khattak, S. A., Liu, Y.-K., Liu, Y.-K., Gao, J.-R., Shi, Z.-X., and Liu, J. (2026). A deep learning-based prognostic approach for predicting PWR degradation and remaining useful life using GNN-PTC-LSTM. *Annals of Nuclear Energy*, 230:112172.
- Kim, J., Suh, B., Park, Y., Kim, K.-I., Ullah, S., and Bhargava, A. (2026). Recent trends in artificial intelligence for anomaly detection and their applications in low power wireless networks. *Pervasive and Mobile Computing*, 119:102214.
- Lei, B., Li, N., Guo, Y., Wang, Z., Wei, J., and Chen, R. (2024). Rapid data collection and processing in dense urban edge computing networks with drone assistance. *Physical Communication*, 66:102462.
- Li, W., Song, X., and Tu, Y. (2025a). GraphDRL: GNN-based deep reinforcement learning for interactive recommendation with sparse data. *Expert Systems With Applications*, 273:126832.
- Li, Y., Xiong, B., Wang, C., Sun, T., Xiong, Q., and Kong, Q. (2025b). Automatic, batching and remote detection of urban building inclination information with edge computing of LIDAR point clouds on a UAV. *Journal of Building Engineering*, 109:112981.
- Mahajan, P. and Kaul, A. (2025). Graph-enhanced deep learning for ECG arrhythmia detection: An integration of CNN-GNN-BILSTM approach. *Medical Engineering and Physics*, 145:104418.
- Meneguette, R., De Grande, R., Ueyama, J., Filho, G. P. R., and Madeira, E. (2021). Vehicular edge computing: Architecture, resource management, security, and challenges. *ACM Computing Surveys (CSUR)*, 55(1):1–46.

- Mnasri, Z. and Bouwmans, T. (2026). A novel method for anomaly detection using graph signal embedding: Application to anomalous sound detection. *Expert Systems with Applications*, page 132278.
- Rocha Filho, G. P., Meneguette, R. I., Neto, J. R. T., Valejo, A., Weigang, L., Ueyama, J., Pessin, G., and Villas, L. A. (2020). Enhancing intelligence in traffic management systems to aid in vehicle traffic congestion problems in smart cities. *Ad Hoc Networks*, 107:102265.
- Sanudo, E., García-Feal, O., Hagen, L., Cea, L., Puertas, J., Montalvo, C., Alvarado-Vicencio, R., and Hofmann, J. (2025). IberSWMM+: A high-performance computing solver for 2D-1D pluvial flood modelling in urban environments. *Journal of Hydrology*, 651:132603.
- Sruthi, K., Sreekumar, A., and Balakrishnan, K. (2026). Text meets topology: A dynamic graph learning method with Dy-GNNs and LLMs for tracking text attributed community evolution in complex networks. *Chaos, Solitons and Fractals*, 208:118121.
- Xu, X., Wang, J., Poslad, S., Rui, X., Zhang, G., and Fan, Y. (2026). Exploring urban human mobility patterns and the effects of air pollution and weather conditions from a dockless bike-sharing lens. *Journal of Cleaner Production*, 554:148155.
- Yin, A., Chen, X., He, H., Morris, A., Yuan, Q., Ma, X., and Yang, Z. (2025). Shared e-bikes demand in urban mobility: Temporal heterogeneity, driving factors, and strategic implications. *Travel Behaviour and Society*, 41:101075.
- Zhang, S., Chen, L., Xu, L., and Wang, Z. (2025). GeoBEM: A geospatial computing empowered framework for urban-scale building energy modeling. *Sustainable Cities and Society*, 121:106203.
- Zhong, Y., Guo, B., Sun, Z., Deng, L., Xu, X., and Dian, S. (2026). MSDCIR-AD: Unsupervised anomaly detection via multi-criteria semantic distances and constrained image reconstruction. *Computers in Industry*, 178:104467.
- Zhu, H., Liu, X., Zhang, Y., and Zhang, L. (2026). A new reconstruction-based method for multivariate time series anomaly detection with diffusion models. *Engineering Applications of Artificial Intelligence*, 175:114656.
- Zou, X., Yan, Y., Hao, X., Hu, Y., Wen, H., Liu, E., Zhang, J., Li, Y., Li, T., Zheng, Y., and Liang, Y. (2025). Deep learning for cross-domain data fusion in urban computing: Taxonomy, advances, and outlook. *Information Fusion*, 113:102606.