

结合反事实与不确定性的交通流量异常检测方法

荣悦,周强,顾晶晶

(南京航空航天大学 计算机科学与技术学院,南京 211106)

E-mail:rongyue@nuaa.edu.cn

摘要: 现有的交通流量预测模型通常仅关注在容忍异常数据的基础上提升预测精度,忽略了异常数据的检测与归因对优化智慧交通系统的重要性. 针对该问题,提出了一种基于反事实生成与不确定性度量的交通流量异常检测方法 CUG-U. 具体来说,构建了一个反事实流量生成模块,该模块通过自监督训练将交通流量数据映射到高维特征空间进行扰动后,再映射回原始数据空间,确保反事实交通流量数据的真实性. 此外,提出了一个不确定性度量模块,从时间和空间角度对输入数据的不确定性进行评估量化. 最后,结合生成的反事实数据与不确定性量化结果,利用多次采样策略优化反事实流量数据的选取,进而实现精准的异常检测. 实验结果表明,与基线模型相比,CUG-U 在交通流量数据异常检测中表现出显著的性能优势.

关键词: 反事实生成;不确定性度量;异常检测;时空数据挖掘;贝叶斯神经网络

中图分类号: TP183

文献标识码: A

文章编号: 1000-1220(2026)04-0810-09

Traffic Flow Anomaly Detection Method via Counterfactual Generation and Uncertainty Quantification

RONG Yue, ZHOU Qiang, GU Jingjing

(Department of Computer Science and Technology, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China)

Abstract: Existing traffic flow prediction models typically focus solely on improving prediction accuracy while tolerating anomalous data, neglecting the importance of anomaly detection and attribution in optimizing intelligent transportation systems. To address this issue, this paper proposes a traffic flow anomaly detection method, CUG-U, based on counterfactual generation and uncertainty measurement. Specifically, a counterfactual traffic generation module is constructed, which maps traffic flow data to a high-dimensional feature space through self-supervised training, perturbs the data, and then maps it back to the original data space, ensuring the authenticity of the counterfactual traffic flow data. Additionally, an uncertainty measurement module is proposed to evaluate and quantify the uncertainty of input data from both temporal and spatial perspectives. Finally, by combining the generated counterfactual data with uncertainty quantification results, a multiple sampling strategy is employed to optimize the selection of counterfactual traffic flow data, thereby achieving precise anomaly detection. Experimental results demonstrate that, compared to baseline models, CUG-U exhibits significant performance advantages in traffic flow anomaly detection.

Keywords: counterfactual generation; uncertainty measurement; anomaly detection; spatial-temporal data mining; Bayesian neural networks

0 引言

随着智慧城市概念的深入推进,城市交通流量数据挖掘在城市规划、交通管理及居民生活质量提升中发挥着越来越重要的作用. 交通流量数据不仅反映了城市运行的动态特征,也是制定科学政策、优化资源配置的重要依据. 现有研究主要集中在交通流量的预测,尤其是短期流量的快速响应与长期趋势的精准把握. 然而,相较于流量预测,交通流量的异常检测研究较为有限. 异常检测作为智能交通管理系统的关键组成部分,能够有效检测与引导交通事故、缓解交通拥堵、提升道路通行能力.

尽管部分学者已经意识到异常交通数据对智能交通管理

系统的影响,但现有方法大多只能在容忍异常数据基础上提升流量预测性能,难以量化交通数据的不确定性,也不能提供直观的异常流量指示. 如图 1 所示,准确的流量预测能够提供流量变化的趋势,但无法缓解交通拥堵. 通过对异常交通流量区域进行归因与处理,能够显著提升交通运输能力.

因此,直接的异常交通事故检测对提升交通预测效率、优化交通事故处理与推进智慧城市建设具有重要意义. 但是,实现该任务具有以下 3 点挑战:

1) 城市道路网络的复杂性、交通事故的传播效应及处理滞后性,使得交通流量呈现出显著的时间和空间相关性. 例如,某一区域的交通异常会在后续时间段对邻近区域产生连锁反应,引发更大范围的交通影响. 这种复杂的时空相关性导

致传统方法难以有效捕捉异常模式,显著增加了异常检测的难度。

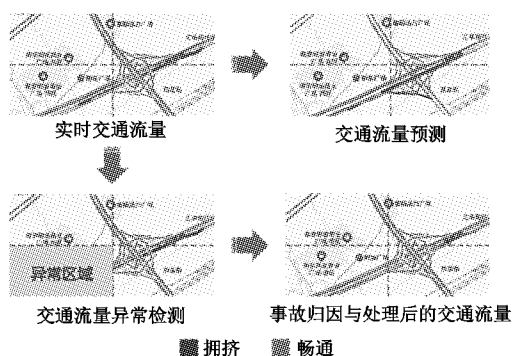


图1 交通流量预测与交通流量异常检测的对比
Fig. 1 Comparison between traffic flow prediction and traffic flow anomaly detection

2) 虽然基于贝叶斯神经网络等方法的不确定性度量能够提供输出结果的置信度,并以此反推特征级的数据异常^[1],但是交通流量数据同时受到时间和空间双重因素的耦合影响。因此,亟需一种能够分别建模时间与空间因素的不确定性模型,以全面评估交通流量数据的不确定性,实现异常交通流量数据检测。

3) 随着城市发展及传感器数量的增加,交通流量数据的规模持续扩大,但异常数据的获取仍然有限。现有公开数据集缺乏针对异常流量数据的标注,导致无法进行有监督训练,从而限制了模型的学习能力与性能提升。

针对上述挑战,本文结合反事实生成技术与不确定性度量技术,通过自监督学习全面捕捉交通流量的时空特征,为实现高效异常检测提供了新的思路。本文的主要贡献如下:

1) 设计了一种基于类变分自编码器结构的反事实流量数据生成模块。该模块通过对流量数据的高维表征进行扰动,生成符合真实分布的反事实流量。

2) 提出了一个从时间和空间角度评估流量数据不确定性的度量模块,解耦时空因素的影响,并引入多次扰动机制,以选取更符合实际情况的反事实流量数据,显著提升了异常检测的可靠性。

3) 在3种规模的公开数据集上进行实验,构造了两种不同的异常检测目标,与多个基线模型进行对比,结果表明,CUG-U在交通流量异常检测方面达到了最优性能。

1 相关工作

1.1 交通流量数据预测

交通流量预测是基于历史数据对未来交通流量进行预测的任务。早期方法主要包括基于统计的方法和传统机器学习方法。基于统计的方法包括自回归滑动平均模型 (ARMA)^[2]和指数平滑^[3],这些方法难以处理高维复杂数据。传统机器学习方法包括支持向量回归 (SVR)、k 近邻算法 (KNN) 及其变体^[4-6],但在处理大规模时空交通数据时性能受限。随着交通传感器和智能交通系统的快速发展,传统方法在挖掘深层时空关联方面面临更大挑战,深度学习方法逐渐成为交通流

量预测的主流。卷积神经网络 (CNN)、图卷积网络 (GCN) 和递归神经网络 (RNN) 被广泛应用。Wu 等人^[7]提出了一种结合 CNN 与 RNN 的模型,并引入注意力机制以捕捉关键时空特征,显著提升了预测精度。

尽管现有研究在预测精度上取得了显著进展,但模型的鲁棒性仍需进一步探讨。部分研究关注模型在分布外数据 (Out-of-Distribution, OOD) 上的泛化能力。例如,STONE 模型^[8]通过在图结构上施加扰动,提高了模型对异常数据的适应性,并构建 OOD 训练集以增强泛化能力。CauSTG^[9]则通过分层提取数据中的不变特征,提升了模型对 OOD 数据的鲁棒性。此外,一些研究尝试进行交通流量的异常检测。例如,STGAN^[10]使用时空图生成对抗网络,但在 NYC 数据集中仅设置了 20 个异常事故检测任务。MTGAE^[11]通过自定义异常注入方式构造数据集,并利用镜像图自编码器进行检测。然而,这些方法严重依赖于图结构,且一些数据集构造过于简单。

尽管现有模型在交通流量预测方面取得了显著进展,并在一定程度上提升了模型对异常数据的适应性,但这些方法主要关注预测精度的提升,而非异常检测与归因。现有研究往往依赖于异常数据的先验知识或简单的异常注入策略,缺乏对异常数据的系统性检测与深入分析。

1.2 反事实生成

近年来,反事实生成技术在多个领域中受到广泛关注,尤其在增强模型可解释性以及执行异常检测等任务中展现出显著潜力。该技术源于因果推理理论,其核心思想是在保持样本语义一致性的前提下,生成与真实样本在部分特征上存在差异的伪造样本,以揭示模型对关键特征的响应机制和泛化能力。

在技术实现层面,反事实生成模型因其良好的可解释性而获得广泛应用。其中,DiCE 方法^[12]面向可微分模型设计,特别适合处理连续特征的应用场景;基于贝叶斯优化的反事实解释方法^[13]则借助概率建模机制,能够有效生成满足先验约束的反事实样本。最新提出的多目标反事实 (MOC) 方法^[14]将反事实搜索建模为一个多目标优化问题,可以同时考虑多种目标之间的权衡,从而显著提升反事实样本的多样性和可操作性。

在应用领域方面,反事实生成技术最初主要应用于图像分类任务。研究者通常采用生成模型 (如生成对抗网络 GAN^[15]和变分自编码器 VAE^[16]) 对输入特征进行有针对性的干预,以生成逼真且具有语义一致性的反事实样本。在交通异常检测领域,基于 GAN 的架构已得到广泛应用,例如 STGAN^[10]使用时空图生成对抗网络,MTGAE-gan^[11]则利用 GAN 替换镜像编码器架构来实现反事实样本的构造。相比之下,在交通异常检测方面采用 VAE 结构的模型相对较少,但在时空数据分析领域中,STDTB-AD^[17]模型基于 VAE 结构实现的反事实生成在驾驶轨迹异常检测中取得了良好效果。

反事实生成技术在交通领域及其他时空数据分析任务中具有突出的实用价值。特别是在交通流量异常检测任务中,该技术不仅能有效识别异常数据,还能为流量预测模型提供更高的可解释性和鲁棒性。通过生成具有代表性的反事实样本,研究人员可以更深入地理解模型决策过程,从而优化模型性

能,提升其在实际应用中的表现.这些优势使得反事实生成技术成为智能交通系统研究和应用中不可或缺的重要工具^[18].

1.3 不确定性量化

现有的不确定性量化方法主要分为两类:基于非贝叶斯的方法和基于贝叶斯的方法^[19].非贝叶斯方法包括平均间隔分数(Mean Interval Score, MIS)回归^[20]和分位数回归^[21],这两种方法通过在损失函数中引入不确定性度量实现量化.此外,样条分位数(Spline Quantile, SQ)回归^[22]利用分位数函数量化不确定性,而 DeepAR 模型^[23]则通过估计时间序列的概率分布来量化不确定性,但未考虑空间因素的影响.

基于贝叶斯的方法中,贝叶斯神经网络通过概率分布表征神经网络参数^[24],使得参数不再是确定值,而是以概率分布形式存在,通常采用变分推理^[25]、重参数化技巧完成模型训练.这种建模方式引入了参数不确定性,使模型在相同输入下产生具有分布特征的输出,反映其内在的不确定性.

尽管现有研究在图数据建模和时序数据建模任务中开发了多种不确定性感知预测模型,但对时空数据的研究仍相对较少.尤其是在时空交通数据中,时空相关性使得不确定性度量更加复杂,这已成为一个有待解决的挑战.

2 相关概念和问题定义

2.1 基本定义

表1给出了文中使用到的符号定义,其中部分符号的详细解释如下.

流量时间信息:考虑到交通流量具有明显的日周期性(24小时),引入时间信息矩阵 X_{tod} 来表示一天中的时间信息,其形式为: $X_{tod} \in \mathbf{R}^{N \times T \times 1}$.

流量日期信息:由于交通流量同样存在周周期性(7天),进一步引入日期信息矩阵 X_{dow} 来表示一天在一周中的位置,即: $X_{dow} \in \mathbf{R}^{N \times T \times 1}$.

表1 符号定义表

Table 1 Symbol definition table

符号	定义
T	时间段长度
N	区域数量
X_{flow}	真实交通流量
\tilde{X}_{flow}	反事实流量
\hat{X}_{flow}	最优反事实流量
z	扰动后的交通流量数据高维特征
X_{tod}	时间信息
X_{dow}	日期信息
X	$X = X_{flow} \oplus X_{tod} \oplus X_{dow} \in \mathbf{R}^{N \times T \times 3}$
B_{st}	时空解耦的交通流量潜在空间表征
Y_{flow}	真实的下一时刻交通流量
\hat{Y}_{flow}	模型输出的下一时刻交通流量
U	交通流量的不确定性
A	异常流量指示矩阵
\hat{A}	模型输出的异常流量指示矩阵

异常流量指示矩阵:定义 $A \in \mathbf{R}^{N \times T}$ 为异常流量指示矩阵,其中 $A_{i,t} = 1$ 表示在区域 i 的时间段 t 的交通流量为异常值,否则 $A_{i,t} = 0$.

2.2 问题定义

交通流量异常检测:给定若干时间段长度为 T 的输入数据 X ,模型的目标是检测所有时间段内各区域流量是否为异常值,即学习一个映射函数 f 使得: $\hat{A} = f(X) \in \mathbf{R}^{N \times T}$,其中, \hat{A} 为模型输出的异常流量指示矩阵,其元素 $\hat{A}_{i,t}$ 表示模型对区域 i 在历史时间 t 是否为异常流量值的检测结果.

3 反事实生成与不确定性度量指导的交通数据异常检测模型

3.1 模型整体结构

CUG-U 的模型结构如图2所示.总体来说,模型分别训练反事实生成模块和不确定性度量模块,再通过多次扰动与




图2 CUG-U 框架图

Fig.2 CUG-U framework diagram

调用的方式完成最优反事实流量数据的选取,从而实现交通流量数据的异常检测.

3.2 反事实生成模块

针对交通流量数据蕴含的复杂时空特性,若直接在原始数据空间施加扰动,生成的反事实样本易偏离真实数据分布.

为避免上述问题,本文提出反事实生成模块.该模块通过自监督训练将交通流量数据映射到高维特征空间进行扰动后,再映射回原始数据空间,确保反事实交通流量数据的真实性.该模块的算法步骤如下:

首先,将输入的交通流量数据 X_{flow} 通过编码器提取高维

特征,得到隐层表示:

$$\mathbf{h}_{AE} = f_{enc}(\mathbf{X}_{flow}) \in \mathbf{R}^{N \times T \times d} \quad (1)$$

其中, f_{enc} 表示编码层, d 为高维特征的维度.

接着,通过两个线性层得到高维潜在空间特征的均值 $\boldsymbol{\mu}$ 和方差 $\boldsymbol{\sigma}$:

$$\boldsymbol{\mu} = \text{Linear}_1(\mathbf{h}_{AE}) \quad (2)$$

$$\boldsymbol{\sigma} = \text{Linear}_2(\mathbf{h}_{AE}) \quad (3)$$

为了避免直接采样操作导致损失函数不可导,扰动过程采用变分自编码器中的重参数化技巧来进行高斯扰动. 具体而言,通过以下公式进行潜在空间采样:

$$\mathbf{z} = \boldsymbol{\mu} + \boldsymbol{\sigma} \cdot \boldsymbol{\epsilon}, \boldsymbol{\epsilon} \sim \mathcal{N}(0, \mathbf{I}) \quad (4)$$

其中, $\boldsymbol{\epsilon}$ 是标准正态分布的噪声, \mathbf{z} 是扰动后的潜在空间特征.

接着,将扰动后的潜在空间特征输入到解码器中,得到扰动后的反事实流量 $\tilde{\mathbf{X}}_{flow}$:

$$\tilde{\mathbf{X}}_{flow} = f_{dec}(\mathbf{z}) \quad (5)$$

其中, f_{dec} 表示解码器.

该自编码器的设计类似于变分自编码器,可以完成简单的异常检测任务. 理论上,反事实流量数据 $\tilde{\mathbf{X}}_{flow}$ 与原始输入数据 \mathbf{X}_{flow} 之间的差异可以用于衡量数据的偏离程度. 基于此,计算输入与反事实流量之间的误差 $\Delta \mathbf{X}$:

$$\Delta \mathbf{X} = |(\tilde{\mathbf{X}}_{flow} - \mathbf{X}_{flow})| \quad (6)$$

当 $\Delta \mathbf{X}$ 超过设定的阈值时,则该数据点可被判定异常数据.

但是,通过反事实生成模块得到的异常检测结果仅仅是对于模型精度误差的衡量,无法评判模型对于结果的置信度.

3.3 不确定性度量模块

为了解决反事实生成模块中得到的反事实流量无法评判模型对结果的置信度的问题,本文提出了不确定性度量模块,对生成的反事实流量各节点间的不确定性进行度量. 该模块的核心思想是,通过自注意力机制提取时空特征,使用贝叶斯神经网络提供具有不确定性度量的结果. 模型结构如图 3 所示.

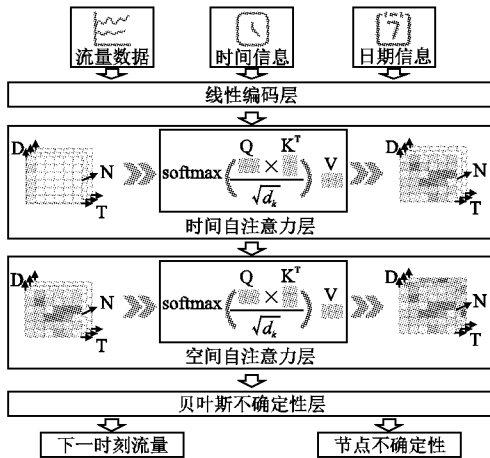


图3 不确定性度量模块结构图

Fig. 3 Uncertainty measurement module structure diagram

如果在不确定性度量模块继续使用输入作为标签的方式,会导致学习到的不确定性仍然只能表征模型的精度损失.

于是,在不确定性度量模块的训练中,本文选择时间段长度为的真实流量数据作为输入,以保证输入格式与反事实流量的格式相同;在训练过程中,将下一个时间段第 1 个时刻的流量数据,即 $t = T + 1$ 时刻的真实流量数据作为标签. 这样虽然损失了部分的训练样本,但能够保证不确定性估计与真实分布对齐.

3.3.1 时空表示学习

首先,模型以流量数据、时间信息和日期信息作为输入,并通过线性编码层将其映射至隐层空间,在隐层空间中,数据进一步连接,形成联合表示向量: $\mathbf{H} \in \mathbf{R}^{N \times T \times D}$, 其中 $D = d_{flow} + d_{tod} + d_{dow}$. d_{flow} , d_{tod} , d_{dow} 分别表示流量信息、时间信息、日期信息的维度.

接着,为了捕获数据在时间维度上的依赖关系,本文采用自注意力机制计算时间注意力分数:

$$\text{Attn}_t(\mathbf{Q}_t, \mathbf{K}_t, \mathbf{V}_t) = \text{softmax}\left(\frac{\mathbf{Q}_t \mathbf{K}_t^T}{\sqrt{d_k}}\right) \mathbf{V}_t \quad (7)$$

其中,查询矩阵 $\mathbf{Q}_t = \mathbf{W}_q^t \mathbf{H}$, 键矩阵 $\mathbf{K}_t = \mathbf{W}_k^t \mathbf{H}$, 值矩阵 $\mathbf{V}_t = \mathbf{W}_v^t \mathbf{H}$, \mathbf{W}_q^t , \mathbf{W}_k^t , \mathbf{W}_v^t 为可学习参数, d_k 是注意力头的维度.

该层可以有效捕获流量数据的时间依赖关系,生成时间维度上的特征表示:

$$\mathbf{H}_t = \text{Attn}_t(\mathbf{Q}_t, \mathbf{K}_t, \mathbf{V}_t) \in \mathbf{R}^{N \times T \times D} \quad (8)$$

然后,为了进一步建模区域之间的空间关联,本文引入空间自注意力机制:

$$\text{Attn}_s(\mathbf{Q}_s, \mathbf{K}_s, \mathbf{V}_s) = \text{softmax}\left(\frac{\mathbf{Q}_s \mathbf{K}_s^T}{\sqrt{d_k}}\right) \mathbf{V}_s \quad (9)$$

其中,查询矩阵 $\mathbf{Q}_s = \mathbf{W}_q^s \mathbf{H}_t$, 键矩阵 $\mathbf{K}_s = \mathbf{W}_k^s \mathbf{H}_t$, 值矩阵 $\mathbf{V}_s = \mathbf{W}_v^s \mathbf{H}_t$, \mathbf{W}_q^s , \mathbf{W}_k^s , \mathbf{W}_v^s 为可学习参数.

经过该层后,得到融合时空信息的最终隐层表示:

$$\mathbf{H}_{st} = \text{Attn}_s(\mathbf{Q}_s, \mathbf{K}_s, \mathbf{V}_s) \in \mathbf{R}^{N \times T \times D} \quad (10)$$

分别学习时间和空间维度的依赖关系的方式可以单独分析时间和空间的影响. 在此基础上,使用贝叶斯神经网络实现时空解耦的不确定性估计.

3.3.2 贝叶斯不确定性层

贝叶斯不确定性层采用贝叶斯神经网络 (Bayesian Neural Networks, BNN) 实现, BNN 的核心思想是通过神经网络进行概率建模,从而量化不确定性. 在传统的神经网络中,权重是固定的,而在贝叶斯神经网络中,权重被视为随机变量,其分布通常假设为高斯分布,即:

$$\mathbf{w} \sim \mathcal{N}(\boldsymbol{\mu}_w, \boldsymbol{\sigma}_w^2) \quad (11)$$

$$\mathbf{b} \sim \mathcal{N}(\boldsymbol{\mu}_b, \boldsymbol{\sigma}_b^2) \quad (12)$$

其中, $\boldsymbol{\mu}_w$, $\boldsymbol{\sigma}_w$, $\boldsymbol{\mu}_b$, $\boldsymbol{\sigma}_b$ 分别是权重的均值和方差、偏置的均值和方差.

在给定输入 x 和目标输出 y 的前提下, BNN 的目标是学习模型参数 $\theta = \{w, b\}$ 的后验分布 $p(\theta | \mathcal{D})$, $\mathcal{D} = \{x_i, y_i\}_{i=1}^N$ 为训练数据集.

根据贝叶斯公式:

$$p(\theta | \mathcal{D}) = \frac{p(\mathcal{D} | \theta) p(\theta)}{p(\mathcal{D})} \quad (13)$$

由于边际似然 $p(\mathcal{D}) = \int p(\mathcal{D} | \theta) p(\theta) d\theta$ 难以计算, BNN 通常通过近似方法进行训练.

变分推理通过引入一个可学习的变分分布 $q(\theta)$ 来逼近后验分布 $p(\theta|\mathcal{D})$. KL 散度衡量两个分布之间的差异, KL 越小, 说明变分分布越接近真实后验, 所以通过最小化变分分布与真实后验分布之间的 KL 散度实现近似:

$$\text{KL}(q(\theta) \parallel p(\theta|\mathcal{D})) = q(\theta) \log \int \frac{q(\theta)}{p(\theta|\mathcal{D})} d\theta \quad (14)$$

该目标等价于最大化变分下界 (ELBO):

$$\mathcal{L}_{\text{ELBO}} = \mathbf{E}_{q(\theta)} [\log p(\mathcal{D} | \theta)] - \text{KL}(q(\theta) \parallel p(\theta)) \quad (15)$$

其中, 第1项为似然项, 对应于数据拟合; 第2项为正则化项, 控制参数分布的复杂度.

为了使训练可以通过梯度下降优化, 引入重参数化技巧通过将随机变量表示为可导的确定性函数与随机噪声的组合, 使得梯度可以反向传播, 过程与公式(4)类似.

在 BNN 中, 每次前向传播都会从参数分布中采样一组权重, 因此预测结果是一个概率分布而非单一值. 这种机制允许模型在每次预测时输出一个均值 + 方差的结果, 反映其对预测结果的自信程度. 举例来说, 当模型面对熟悉的输入数据时, 输出方差较小, 表示预测稳定; 而在异常或罕见输入下, 模型输出方差较大, 意味着其对预测存在较高的不确定性.

通过变分推理和重参数化技巧, 贝叶斯神经网络能够高效地计算梯度并优化参数分布, 从而实现对模型不确定性的量化. 相比传统神经网络仅给出点预测, BNN 能够输出包含置信度的信息, 使得模型在面对输入时不仅能给出预测结果, 还能评估其可靠性.

3.3.3 不确定性量化

隐层表示通过贝叶斯不确定性层, 可以表示为:

$$\mathbf{B}_{st} = \mathbf{w}^T \mathbf{H}_{st} + \mathbf{b} \quad (16)$$

由于权重和偏置是从高斯分布中采样得到, 贝叶斯网络得到的 \mathbf{B}_{st} 也符合高斯分布:

$$\mathbf{B}_{st} \sim \mathcal{N}(\boldsymbol{\mu}_{st}, \boldsymbol{\sigma}_{st}) \quad (17)$$

其中, $\boldsymbol{\mu}_{st} = \boldsymbol{\mu}_w^T \mathbf{H}_{st} + \boldsymbol{\mu}_b$, $\boldsymbol{\sigma}_{st} = \boldsymbol{\sigma}_w^2 \|\mathbf{H}_{st}\|^2 + \boldsymbol{\sigma}_b^2$.

通过 K_1 次采样, 得到多个 $\mathbf{B}_{st}^i (i=1, 2, \dots, K_1)$, 再通过线性层得到多个输出 $\hat{\mathbf{Y}}_{flow}^i$, 其方差可以反映输出的不确定性:

$$\mathbf{U} = \text{Var}(\hat{\mathbf{Y}}_{flow}) = \frac{1}{N} \sum_{i=1}^N (\hat{\mathbf{Y}}_{flow}^i - \mathbf{E}[\hat{\mathbf{Y}}_{flow}])^2 \quad (18)$$

其中, $\hat{\mathbf{Y}}_{flow}^i$ 是第 i 次采样的输出, $\mathbf{E}[\hat{\mathbf{Y}}_{flow}^i]$ 是多次采样的均值, 通过线性层即模型输出的 $t = T + 1$ 时刻的交通流量, 表示为:

$$\hat{\mathbf{Y}}_{flow} = \mathbf{E}[\hat{\mathbf{Y}}_{flow}^i] \quad (19)$$

3.4 异常检测模块

在上述两个模块单独训练后, 为了进行异常流量数据的检测, 本文在训练好的反事实生成模块上进行多次扰动, 获取不同的反事实流量. 再将反事实流量输入到训练好的不确定性度量模块中, 选择不确定性最小的反事实流量作为最优反事实流量, 最后通过差值完成异常检测. 具体步骤如下.

首先, 在反事实生成模块的编码器后进行 K_2 次高斯噪声扰动:

$$\mathbf{z}^i = \boldsymbol{\mu} + \boldsymbol{\sigma} \cdot \boldsymbol{\epsilon}^i, \boldsymbol{\epsilon}^i \sim \mathcal{N}(0, \mathbf{I}), i=1, 2, \dots, K_2 \quad (20)$$

其中, K_2 为扰动次数, $\boldsymbol{\epsilon}^i$ 服从正态分布, 确保每次扰动具有随机性.

在反事实生成模块, 最终得到多个反事实交通流量 $\hat{\mathbf{X}}_{flow}^i$,

$i=1, 2, \dots, K_2$.

对于每个扰动样本 $\hat{\mathbf{X}}_{flow}^i$, 经过反事实模块, 本文可以得到其在每个区域上的不确定性 U_n^i .

然后, 对于每个区域 n , 选择使得 U_n^i 最小的扰动样本 $\hat{\mathbf{X}}_n^i$:

$$\hat{\mathbf{X}}_n = \hat{\mathbf{X}}_n^i \text{ where } i = \arg \min U_n^i \quad (21)$$

其中, $\hat{\mathbf{X}}_n^i$ 是 $\hat{\mathbf{X}}_{flow}^i$ 在维度 N 上的切片, $\hat{\mathbf{X}}_n$ 是在区域 n 上的最优反事实流量. 合并所有区域的最优反事实流量, 表示为 $\hat{\mathbf{X}}_{flow}$.

最后, 根据 $\hat{\mathbf{X}}_{flow}$ 与 \mathbf{X}_{flow} 的差值, 选择合适的阈值 τ , 得到异常流量指示矩阵:

$$\hat{\mathbf{A}} = |\hat{\mathbf{X}}_{flow} - \mathbf{X}_{flow}| > \tau \quad (22)$$

3.5 损失函数与异常检测过程

反事实生成模块的损失函数包含两个部分, 反事实流量与真实流量之间的精度损失和高维空间先验分布的 KL 散度损失, 具体表达式如下:

$$\mathcal{L}_{AE} = \mathbf{E}_{q(\mathbf{z}|\mathbf{X}_{flow})} [\|\hat{\mathbf{X}}_{flow} - \mathbf{X}_{flow}\|^2] + \alpha \cdot D_{KL}(q(\mathbf{z}|\mathbf{X}_{flow}) \parallel p(\mathbf{z})) \quad (23)$$

其中, 第1项是均方误差损失, 用于衡量反事实流量与原始流量之间的差异; 第2项是 KL 散度损失, 用于衡量高维潜在空间分布与先验分布之间的差异, 这里, $q(\mathbf{z}|\mathbf{X}_{flow})$ 表示从编码器输出的潜在空间分布, 而 $p(\mathbf{z})$ 是预定义的先验分布, 为标准正态分布; α 是控制两类损失的超参数.

不确定性度量模块的损失函数包含两个部分: 1) 输出的下一时刻流量值与真实流量值之间的误差; 2) 贝叶斯网络的权重和偏置分布与先验分布之间的 KL 散度损失. 具体的损失函数表达式为:

$$\mathcal{L}_{UT} = \mathbf{E} [\|\hat{\mathbf{Y}}_{flow} - \mathbf{Y}_{flow}\|^2] + \beta \cdot D_{KL}(p(\mathbf{w}, \mathbf{b}) \parallel q(\mathbf{w}, \mathbf{b})) \quad (24)$$

其中, $\mathbf{E} [\|\hat{\mathbf{Y}}_{flow} - \mathbf{Y}_{flow}\|^2]$ 表示模型输出值与真实值之间的均方误差损失, $D_{KL}(p(\mathbf{w}, \mathbf{b}) \parallel q(\mathbf{w}, \mathbf{b}))$ 表示贝叶斯网络中权重和偏置的后验分布 $q(\mathbf{w}, \mathbf{b})$ 与先验分布 $p(\mathbf{w}, \mathbf{b})$ 之间的 KL 散度, 用于约束模型的复杂度和推断的不确定性. β 是一个超参数, 用于控制两个损失函数的比例.

使用以上损失函数单独训练反事实生成模块和不确定性度量模块. 此后的异常检测主要包括 4 个阶段: 反事实流量生成、不确定性度量、最优反事实流量选取和异常检测判别. 具体流程如下:

1) 反事实流量生成: 首先, 将原始流量数据 \mathbf{X}_{flow} 输入至反事实生成模块, 并进行 K_2 次扰动, 以生成 K_2 组反事实流量 $\hat{\mathbf{X}}_{flow}$. 这些反事实流量用于模拟可能的正常流量模式, 为后续异常检测提供对比基准.

2) 不确定性度量: 接着, 将这 K_2 组反事实流量输入至不确定性度量模块, 计算每个反事实流量的节点级不确定性, 即通过贝叶斯神经网络估计输入流量的不确定性, 以衡量各个反事实流量的可信程度.

3) 最优反事实流量选取: 对于每个节点, 选择不确定性最小的反事实流量, 作为最优反事实流量 $\hat{\mathbf{X}}_{flow}$. 由于不确定性较低的流量更接近真实流量模式, 因此该流量可用于判定异常程度.

4)异常检测判别:根据优化后的反事实流量 \hat{X}_{flow} 计算异常检测指标,并利用公式(22)判别异常流量数据点,实现对异常流量的精准检测。

4 实验

4.1 数据集

本文使用的交通流量数据集为 NYC-Taxi 数据集,该数据集包含自 2009 年以来在纽约市收集的不同类型出租车的 GPS 轨迹信息。本文中数据按照每 30 分钟一个时间片进行聚合,涵盖了 3 种规模的时间段,具体为:2023 年 1 月~2023 年 3 月、2023 年 1 月~2023 年 6 月以及 2023 年 1 月~2023 年 12 月,分别记为 NYC3、NYC6、NYC12。

在异常检测任务中,数据分布差异的存在对于模型构建和检测效果具有重要影响。不同时间段或区域的交通流量在均值和方差上可能存在显著差异,如果不加以处理,模型可能会将某些自然波动误判为异常。

为了缓解这一问题,在数据预处理阶段引入标准化操作显得尤为关键。标准化能够将不同来源或分布的数据映射到统一的数值范围(通常为均值为 0,方差为 1 的标准正态分布),从而有效消除由分布尺度差异引起的建模干扰。这样,模型可以更加专注于学习数据的相对变化趋势,而非被不同区域或时间段的绝对流量数值所干扰。这种统一的表示方式有助于增强模型对于潜在异常模式的敏感性,提高检测的鲁棒性与泛化能力。

表 2 NYC Taxi 数据分布表

Table 2 NYC Taxi data distribution table

数据类型	NYC3	NYC6	NYC12
均值	15.8319	16.3577	16.4624
方差	44.7283	45.8090	45.8843

尽管本文使用的 3 个数据集均来源于同一交通数据源,但它们在数据规模与采样范围上的不同,导致了各自数据分布特征存在明显差异。如表 2 所示,随着数据规模的扩大,流量值的变化范围和分布形态也趋于复杂,均值与方差的偏移更为显著。数据分布的这种动态变化直接影响模型对异常行为的判定标准,进而可能引发误判或漏判。




图 4 流量与事故关系图

Fig. 4 Traffic and accident relationship diagram

为应对这一挑战,本文在模型训练前对不同规模的数据子集分别进行了标准化处理,确保每个子集都在其自身的分布条件下实现均值为 0、方差为 1 的局部统一表示。这种局部标准化策略不仅保留了各子集内数据的相对结构特征,还有效缓解了因全局尺度不一致带来的建模偏差。通过这种方式,

模型能够在各自独立的尺度体系下,更加精准地识别局部异常行为,提升整体检测的灵敏度与准确性,尤其是在多尺度、多样性数据场景下展现出更强的适应能力与稳定性。

为了构建异常流量指示矩阵,本文利用了公开的 NYC 城市交通事故数据集。在这 3 种规模的数据集中,交通事故占比分别为 1.78%、1.86% 和 1.88%。由于交通事故仅占据部分异常流量数据,且占比较小。因此在公开交通事故矩阵的基础上,本文进一步选择了每个节点流量数据最多的 10% 作为异常交通流量。如图 4 所示,交通事故的发生通常伴随着一段时间内交通流量的增加。此外,交通异常检测的最终目的是缓解交通拥堵问题。在没有任何异常流量数据标签的情况下,模型应当对高流量值输出较高的不确定性,以反映流量异常的潜在风险。

4.2 评价指标

在本文中,使用了命中数、准确率、召回率和 F1 分数来评估交通流量异常检测的效果。具体而言,命中数表示输出的异常流量指示矩阵与标签中相匹配的个数。准确率(Precision)、召回率(Recall)和 F1 分数(F1 Score, F1)则是基于返回的异常指示矩阵与标签矩阵来计算的,具体公式如下:

$$Precision = \frac{TP}{TP + FP} \quad (25)$$

$$Recall = \frac{TP}{TP + FN} \quad (26)$$

$$F1 = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} \quad (27)$$

其中,TP 表示正确识别为异常的个数,FP 表示误识别为异常的个数,FN 表示漏检的异常个数。F1 分数是准确率和召回率的调和平均值,兼顾了二者的权衡。

通过这些指标,能够全面评估异常检测模型的表现,确保不仅能够正确识别异常流量,还能减少误报和漏报的发生。

4.3 基准模型

目前,交通流量异常检测的研究相对较少,然而,变分自编码器(VAE)架构在图像领域中已被广泛应用于异常检测,并且其设计思想可以较容易地迁移到交通流量数据的异常检测任务中。以下是本研究中采用的基准模型:

1) VAE^[26]:VAE 通过学习数据的潜在空间表示,能够有效地识别输入数据的异常情况。在交通流量异常检测中,VAE 通过生成模型重建流量数据,重建误差较大的数据点通常被视为异常。

2) LSTM^[27]:LSTM 作为一种典型的时序数据处理模型,能够捕捉交通流量数据中的时序模式。在本研究中,通过对 LSTM 进行改造,使其能够在捕捉流量变化趋势的同时,识别出与正常模式偏离较大的异常流量点。

3) Transformer^[28]:Transformer 模型在处理长时序依赖关系上具有独特优势,其自注意力机制可以有效地关注交通流量数据中的重要时刻。本研究基于 Transformer 模型的结构,引入异常检测机制,通过检测流量序列中的异常波动,来提高模型对异常情况的识别能力。

4) STAEformer^[29]:STAEformer 通过结合时空特征的编码与解码过程,能够更好地捕捉交通流量数据的空间与时间关联。基于 STAEformer 的框架,本文对其进行了扩展,增加

了异常检测模块,以便在处理复杂的交通流量数据时,能够准确识别出异常的时空模式.

5) MTGAE^[11]: MTGAE 是交通异常检测模型,结合图自编码器与镜像时间卷积网络,旨在解决动态交通网络中节点间时空关联复杂、高周期性数据下异常检测困难的问题. 模型核心包含两个模块:镜像时间卷积模块和图卷积门控循环单元,用于识别节点间复杂依赖中的潜在异常.

通过对这些基准模型的改动和优化,增强了模型在交通流量数据中的异常检测能力,为异常检测在交通领域的应用提供了新的思路和方法.

4.4 参数设置

本文使用的实验环境主要是在 Linux 系统下环境进行搭建,本次模型的构建以及训练均在系统提供的终端内完成,使用基于 Pytorch 的机器学习框架,学习率为 0.001,批量大小为 32,通过 Z-score 标准化将数据映射到 [-1,1] 中. 具体的参数设置为 $d = 64, d_{flow} = 64, d_{tod} = 24, d_{dow} = 24, K_1 = 5, K_2 = 20, \alpha = 0.1, \beta = 0.1$.

4.5 交通事故异常检测结果对比

表 3 是不同模型在召回不同比例的目标后,命中的交通

表 3 不同召回率下交通事故检测命中结果
Table 3 Traffic accident detection hit results under different recall rates

Table with 6 columns: 数据集, 模型, 2%, 4%, 6%, 8%, 10%. Rows include NYC3, NYC6, NYC12 datasets with models VAE, LSTM, Transformer, STAEformer, MTGAE, and CUG-U.

事故的数量. 在交通事故检测的结果中, CUG-U 模型能够在相同召回率下命中更多目标,表明该模型能够更有效地识别并区分数据中的异常情况. LSTM 和 Transformer 模型的表现较为优异,这一结果可能与交通事故的时间依赖性有关,而 LSTM 的递归结构更适合捕捉此类时序特性. 相比之下, Transformer 模型能够更好地拟合数据,但易发生过拟合. VAE 在召回率较低时表现较差,但随着召回率的提升,其表现逐渐改善. 尽管 VAE 缺乏显式建模时间层面的能力,但其具有一定的空间建模能力,能够捕捉到交通流量中某些空间相关性的异常模式,因此在处理空间信息时表现出一定优势. STAEformer 模型的检测效果相对较差,可能是由于其强大的时空建模能力在面对交通事故的高维扰动时,会严重破坏数据的原始结构,导致模型无法有效地识别交通事故异常. MTGAE 在数据集规模较小时效果较好,但随着数据集的增加模型效果逐渐下降. 这可能是因为 MTGAE 依赖于节点间的邻接矩阵,本文中采用的邻接矩阵使用的是各区域质心间距离的倒数,不能完全反映准确的邻接关系,反而可能引入额外噪声. 随着数据集规模的增加,模型中噪声影响越显著. 相比之下, CUG-U 模型在无需邻接矩阵等辅助信息的前提下,就能达到最优检测效果.

4.6 异常交通流量检测结果对比

异常交通流量的检测结果如表 4 所示. 在异常交通数据检测结果中, CUG-U 模型在 3 个数据集上的 F1 分数分别达到 0.7346、0.7185 和 0.7434,显著优于其他模型. 相比之下, VAE 的表现略逊于 LSTM 和 Transformer. 这主要是因为 VAE 更多关注交通流量的空间关系,忽略了时间建模,而全面的异常检测需要时间和空间两个维度的建模. Transformer 的检测效果优于 LSTM,原因在于 Transformer 通过自注意力机制能够捕捉时间序列中的长期依赖关系,从而在时间依赖性建模方面表现优异. 这些模型都仅对空间或时间进行建模,所以在面对不同的任务时表现出不同的结果,缺乏稳定性. STAEformer 模型虽然是专为流量预测设计的,但在异常检测任务中的表现却不如其他模型,这可能是由于 STAEformer 在处理高维特征时可能过度拟合训练数据的分布,导致在面对异常数据时泛化能力下降. MTGAE 因为邻接矩阵的噪声影响,随着数据集规模增加,效果逐渐下降. 相比之下, CUG-U 模型通过结合时间和空间维度的自注意力,能够同时捕捉交通流量数据中的空间相关性和时间依赖性,从而在异常检

表 4 相同召回率下异常交通流量检测结果

Table 4 Anomaly traffic flow detection results under the same recall rate

Table with 8 columns: 数据集, 评价指标, VAE, LSTM, Transformer, STAEformer, MTGAE, CUG-U. Rows show Precision, Recall, and F1 for NYC3, NYC6, and NYC12 datasets.

测方面展现出更强的能力. 在 3 种不同规模的数据集上,

CUG-U 模型都能取得相对较高的检测结果,这表明该模型具

有较强的异常检测能力,并且在不同规模的任务中展现出良好的稳定性.

4.7 参数分析

本节对实验中使用的4个关键参数进行分析,数据集为NYC数据集2023年1月~2023年3月期间的数据,采用异常检测任务中的F1分数作为性能评价指标.在对一个参数进行分析时,固定其他的参数不变.参数分析结果如图5所示.




图5 参数分析结果

Fig. 5 Parameter analysis results

首先,分析不确定性模块的参数 K_1 .随着不确定性采样次数的增加,模型的性能表现出先上升后下降的趋势.这是因为尽管增加采样次数可以增强模型对不确定性的感知,但在计算方差时,随机的采样也会引入更多的噪声,导致模型性能的下降.

接着,分析扰动次数 K_2 的影响.随着扰动次数的增加,模型的性能逐步提升.但是当 K_2 大于20时,提升趋于平缓,且会消耗更多资源.因为扰动次数增加可以得到更多反事实样本,当 $K_2=20$ 时,已经能够得到较好的反事实数据.

然后,分析模型隐层空间维度 d 的影响.当 $d=64$ 时,模型的性能表现最佳,说明这一维度能够有效捕捉数据中的关键特征.

最后,分析编码器和解码器的层数 L 的影响.结果表明,当 $L=4$ 时,模型的性能最为优秀,可能是因为在这个层数配置下,模型既能充分学习到时空特征,又不至于过度拟合.

4.8 消融实验

本节将证明CUG-U模型各组件的有效性,分别移除CUG-U重要的组件,并将结果与完整的CUG-U模型进行性能对比.CUG-U模型包含3个变种:

- 1) noUT. 移除不确定度量模块,仅使用反事实生成模块进行异常检测.
- 2) noNE. 移除反事实生成模块中的高斯扰动部分.
- 3) noHD. 移除反事实生成模块中的高维映射部分,在原始数据空间进行扰动.

数据集为NYC数据集2023年1月~2023年3月期间的数据,使用F1分数进行评估,变种模型的参数设置和CUG-U一致,实验结果如图6所示.

从图中可以看出,噪声扰动对模型的异常检测能力具有重要影响,去除噪声扰动模块后,模型的准确率、召回率和F1分别下降了38.25%、40.17%和39.19%.这一变化显示了噪声扰动模块对模型性能的显著贡献,增强了模型在高维表征中的稳健性,赋予了模型生成反事实的能力,进而提高了异常检测的准确性.具体来看,噪声扰动模块对F1分数的贡献最大,表明其在实际异常检测任务中的核心作用.




图6 消融实验结果图

Fig. 6 Ablation study results

此外,去除不确定性度量模块后的模型F1下降了19.30%,尽管自编码器模块本身具有一定的异常检测能力,但其生成的反事实流量仅是对模型精度误差的衡量.因此,不确定性度量模块在提高反事实生成的准确性方面起到了关键作用.

去除高维映射模块后,模型的F1下降了5.21%,这表明高维映射模块的作用相对较小.去除该模块后,模型在原始空间的扰动可能无法充分反映真实数据分布,从而影响了异常检测的性能.

综合来看,噪声扰动模块对模型的贡献最大,其次是不确定性度量模块,而高维映射模块对整体性能的影响最小.通过这些消融实验,能够清楚地量化不同模块对异常检测效果的相对重要性,进一步证明了提出模型在结合不确定性度量、噪声扰动和高维映射时的有效性,能够更好地捕捉交通流量数据中的时空特征并提升异常检测性能.

5 结束语

本文提出了一种结合反事实生成与不确定性度量的交通流量异常检测模型CUG-U,旨在检测城市交通流量数据中的异常值.CUG-U模型构建了一个反事实流量生成模块,使用自监督训练将交通流量数据映射到高维特征空间进行扰动,再映射回原始数据空间,生成具备真实性的反事实流量;再通过不确定性度量模块,从时间和空间角度对输入数据的不确定性进行评估量化;最后,采用多次采样策略优化异常流量数据的筛选,实现精准的异常检测.在多个规模的公开数据集上具有卓越的异常检测能力.

未来计划从以下两个方面展开进一步研究:首先,针对交通流量中的异常值,基于领域知识和数据分布特征,选择适合的模型和数据预处理方法,将交通事故、假期影响和特殊事件等因素纳入异常数据的标注范围,从而构建一个全面且有效的数据集.通过定义异常数据的阈值或规则,确保数据集的多样性和代表性,为模型训练提供高质量的数据支持.其次,考虑在检测到异常情况并处理后对后续交通流量预测的影响,设计一种基于多任务学习的框架,将异常检测与交通预测相结合,通过分析异常处理后的数据分布变化,优化交通流量预

测模型的输入特征,给出更合理的交通预测模型解决方案.

References:

- [1] Ding N, Gao H, Bu H, et al. RADM: real-time anomaly detection in multivariate time series based on Bayesian network [C]//Proceedings of the IEEE International Conference on Smart Internet of Things (SmartIoT), 2018: 129-34.
- [2] Said S E, Dickey D A. Testing for unit roots in autoregressive-moving average models of unknown order [J]. *Biometrika*, 1984, 71 (3): 599-607.
- [3] Li Z, Cao J, Shi X, et al. QPSO-AHES-RC: a hybrid learning model for short-term traffic flow prediction [J]. *Soft Computing*, 2023, 27 (14): 9347-9366.
- [4] Lippi M, Bertini M, Frasconi P. Short-term traffic flow forecasting: an experimental comparison of time-series analysis and supervised learning [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2013, 14(2): 871-882.
- [5] Zhu Z, Peng B, Xiong C, et al. Short-term traffic flow prediction with linear conditional Gaussian Bayesian network [J]. *Journal of Advanced Transportation*, 2016, 50(6): 1111-1123.
- [6] Liu Z, Li H, Zeng J, et al. Influence of Fe/HZSM-5 catalyst on elemental distribution and product properties during hydrothermal liquefaction of *Nannochloropsis sp* [J]. *Algal Research*, 2018, 35: 1-9, doi: 10.1016/j.algal.2018.08.011.
- [7] Wu Y, Tan H, Qin L, et al. A hybrid deep learning based traffic flow prediction method and its understanding [J]. *Transportation Research Part C: Emerging Technologies*, 2018, 90: 166-180, doi: 10.1016/j.trc.2018.03.001.
- [8] Wang B, Ma J, Wang P, et al. Stone: a spatio-temporal ood learning framework kills both spatial and temporal shifts [C]//Proceedings of the Proceedings of the 30th ACM SIGKDD Conference on Knowledge Discovery and Data Mining, 2024: 2948-2959.
- [9] Zhou Z, Huang Q, Yang K, et al. Maintaining the status quo: capturing invariant relations for ood spatiotemporal learning [C]//Proceedings of the Proceedings of the 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining, 2023: 3603-3614.
- [10] Deng L, Lian D, Huang Z, et al. Graph convolutional adversarial networks for spatiotemporal anomaly detection [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2022, 33(6): 2416-2428.
- [11] Ren Z, Li X, Peng J, et al. Graph autoencoder with mirror temporal convolutional networks for traffic anomaly detection [J]. *Scientific Reports*, 2024, 14(1): 1247, doi: 10.1038/s41598-024-51374-3.
- [12] Mothilal R K, Sharma A, Tan C. Explaining machine learning classifiers through diverse counterfactual explanations [C]//Proceedings of the Proceedings of the Conference on Fairness, Accountability, and Transparency, 2020: 607-617.
- [13] Verama S, Boonsanong V, Hoang M, et al. Counterfactual explanations and algorithmic recourses for machine learning: areview [J]. *ACM Computing Surveys*, 2024, 56(12): 1-42.
- [14] Dandl S, Molnar C, Binder M, et al. Multi-objective counterfactual explanations [C]//Proceedings of the International Conference on Parallel Problem Solving from Nature, 2020: 448-469.
- [15] Goodfellow I J, Pouget Abadie J, Mirza M, et al. Generative adversarial nets [J]. *Advances in Neural Information Processing Systems*, 2014, 27, doi: 10.3156/JSOFT.29.5_177_2.
- [16] Kingma D P, Welling M. Auto-encoding variational bayes [Z]. Banff, Canada, 2013.
- [17] Yu W, Huang Q. A deep encoder-decoder network for anomaly detection in driving trajectory behavior under spatio-temporal context [J]. *International Journal of Applied Earth Observation and Geoinformation*, 2022, 115: 103115, doi: 10.1016/j.jag.2022.103115.
- [18] Wang R, Xin Y, Zhang Y, et al. Counterfactual explanations for deep learning-based traffic forecasting [J]. *Communications in Transportation Research*, 2025, 5: 100176, doi: 10.1016/j.comtr.2025.100176.
- [19] LIU L, GUO S N, JIN X Y, et al. Spatial-temporal traffic data imputation method with uncertainty modeling [J]. *Journal of Computer Research and Development*, 2024, 61: 1-18, doi: 10.7544/issn1000-1239.202330455.
- [20] Wu D, Gao L, Chinazzi M, et al. Quantifying uncertainty in deep spatiotemporal forecasting [C]//Proceedings of the Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining, 2021: 1841-1851.
- [21] Koenker R, Hallock K F. Quantile regression [J]. *Journal of Economic Perspectives*, 2001, 15(4): 143-156.
- [22] Gasthaus J, Benidis K, Wang Y, et al. Probabilistic forecasting with spline quantile function RNNs [C]//Proceedings of the the 22nd International Conference on Artificial Intelligence and Statistics, 2019: 1901-1910.
- [23] Salinas D, Flunkert V, Gasthaus J, et al. DeepAR: probabilistic forecasting with autoregressive recurrent networks [J]. *International Journal of Forecasting*, 2020, 36(3): 1181-1191.
- [24] Jospin L V, Laga H, Boussaid F, et al. Hands-on Bayesian neural networks—a tutorial for deep learning users [J]. *IEEE Computational Intelligence Magazine*, 2022, 17(2): 29-48.
- [25] Maronas J, Paredes R, Ramos D. Calibration of deep probabilistic models with decoupled bayesian neural networks [J]. *Neurocomputing*, 2020, 407: 194-205, doi: 10.1016/j.neucom.2020.04.103.
- [26] Xu H, Chen W, Zhao N, et al. Unsupervised anomaly detection via variational auto-encoder for seasonal kpis in web applications [C]//Proceedings of the Proceedings of the World Wide Web Conference, 2018: 187-196.
- [27] Maleki S, Maleki S, Jennings N R. Unsupervised anomaly detection with LSTM autoencoders using statistical data-filtering [J]. *Applied Soft Computing*, 2021, 108: 107443, doi: 10.1016/j.asoc.2021.107443.
- [28] Lim B, Ark S Ö, Loeff N, et al. Temporal fusion transformers for interpretable multi-horizon time series forecasting [J]. *International Journal of Forecasting*, 2021, 37(4): 1748-1764.
- [29] Liu H, Dong Z, Jiang R, et al. Spatio-temporal adaptive embedding makes vanilla transformer sota for traffic forecasting [C]//Proceedings of the Proceedings of the 32nd ACM International Conference on Information and Knowledge Management, 2023: 4125-4129.

附中文参考文献:

- [19] 刘乐, 郭晟楠, 靳希源, 等. 融合不确定性建模的时空交通数据插补方法 [J]. *计算机研究与发展*, 2024, 61: 1-18, doi: 10.7544/issn1000-1239.202330455.