

# 基于噪声标签重加权的车辆轨迹异常检测方法

苏越阳<sup>1,2</sup>, 姚 迪<sup>1,2</sup>, 毕经平<sup>1,2\*</sup>

(1. 中国科学院大学, 北京 100049; 2. 中国科学院计算技术研究所, 北京 100190)

**摘要:** 车辆轨迹异常检测为各种位置信息服务提供了重要的安全保障, 基于机器学习的方法作为主流检测方法已经被广泛地应用于交通、军事等各个领域。然而受限于噪声标签问题, 现有的异常检测方法在实际应用中性能不佳。为了解决这个问题, 本文提出了一种基于噪声标签重加权的车辆轨迹异常检测方法(noise label ReWeighting-based vehicle Trajectory Anomaly Detection, RW-TAD)。该方法采用自监督的方式构建样本权重估计模块, 通过计算轨迹的生成概率评估给定标签的可信度。然后使用基于加权损失的检测模型判定异常轨迹。在训练过程中, RW-TAD模型使用基于双层损失的协同优化机制联合学习样本权重估计模块和异常检测模块。实验结果表明该方法可以有效缓解噪声标签样本对模型训练的干扰, 取得了较好的性能。相比于已有的方法, RW-TAD在检测准确率和性能稳定性上都有很大的提升。

**关键词:** 异常检测; 轨迹数据; 噪声标签学习; 路网数据; 重加权

**基金项目:** 国家自然科学基金(No.62002343)

**中图分类号:** TP391

**文献标识码:** A

**文章编号:** 0372-2112(2025)01-0182-11

**电子学报 URL:** <http://www.ejournal.org.cn>

**DOI:** 10.12263/DZXB.20230568

## A Vehicle Trajectory Anomaly Detection Method Based on Noise Label Re-Weighting

SU YUE-yang<sup>1,2</sup>, YAO Di<sup>1,2</sup>, BI Jing-ping<sup>1,2\*</sup>

(1. University of Chinese Academy of Sciences, Beijing 100049, China;

2. Institute of Computing Technology, Chinese Academy of Sciences, Beijing 100190, China)

**Abstract:** Vehicle trajectory anomaly detection provides important security support for various location-based services. Machine learning-based methods, as the mainstream detection methods, have been widely applied in various fields such as transportation and military. However, due to the problem of noise labels, existing anomaly detection methods have poor performance in practical applications. To solve this problem, this paper proposes a vehicle trajectory anomaly detection method based on noise label re-weighting (RW-TAD). This method uses a self-supervised approach to construct a sample weight estimator, which evaluates the credibility of given labels by calculating the probability of trajectory generation. Then, a detector based on weighted loss is used to detect anomalous trajectories. During the training process, the RW-TAD model uses a collaborative optimization strategy based on a dual-layer loss to jointly learn the sample weight estimator and the detector. Experimental results show that this method can effectively alleviate the interference of noisy samples on model training and achieve good performance. Compared with existing methods, it has greatly improved in detection accuracy and performance stability.

**Key words:** anomaly detection; trajectory; noise label learning; road network; re-weighting

**Foundation Item(s):** National Natural Science Foundation of China (No.62002343)

## 1 引言

随着全球定位系统和低延时无线网络技术的快速发展, 各种位置信息服务层出不穷, 每天都会产生大量

的车辆轨迹数据<sup>[1]</sup>。发现和分析这些轨迹中存在的异常对于保障服务安全具有重要的意义。例如, 一些出租车司机会通过恶意绕路行为欺诈乘客, 获得不法收益。

通过分析随车传感器记录的轨迹数据,可以发现和遏制这种行为,从而有效地保护乘客的利益,维护出租车市场的稳定性。

目前,已经有许多学术界和工业界的研究人员开始关注车辆轨迹异常检测领域。现有的检测方法可以分为2类<sup>[2]</sup>:基于度量的方法和基于学习的方法。基于度量的方法使用手工特征描述轨迹的正常模式,认为不符合正常特征模式的轨迹即为异常。但是手工特征的选取过分依赖专家的领域知识,可扩展性不强;而且无法描述轨迹数据中复杂的时空特征以及深层关联关系,性能不佳。相比之下,基于学习的方法采用神经网络等可以有效描述时空特征之间复杂非线性关系的组件,能够挖掘轨迹数据复杂的深层特征,适用于异常特征复杂且类型多样的检测任务,已经成为了目前主流的异常检测方法。该类方法可以进一步分为基于有监督学习的方法和基于无监督学习的方法。得益于有效的监督信息,基于有监督学习的方法一般具有更好的性能。

然而,基于有监督学习的异常检测方法通常依赖大量准确标注的数据进行模型训练<sup>[3]</sup>。但是,在实际应用中,数据标注存在很多不确定性因素,广泛地存在噪声标签。具体体现在2个方面:一方面,异常轨迹通常由人工筛选异常置信度高的轨迹得到。由于异常轨迹的类型多样以及标记人员缺乏足够的背景知识,难免存在没有识别出的异常轨迹;另一方面,由于轨迹数据的时空相关性,其特征分布情况往往会随时间推移发生变化,即出现“数据漂移”。在这种情况下,历史异常轨迹所提供的监督信息,在当前时间下会变得无效或不够有效。

噪声标签严重影响模型在现实应用中的性能,对噪声标签数据的拟合会干扰和限制模型对有效特征的学习<sup>[4]</sup>。因此,如何在有噪声标签的情况下提高模型的检测性能是重要问题。传统的基于图像数据的噪声标签学习方法,主要包括基于数据清洗的方法,基于模型设计的方法和基于目标优化的方法。其中,前2种方法均无法直接应用于轨迹异常检测领域(具体分析见2.2节),而基于目标优化的方法通常需要1个准确标记且覆盖所有异常类型的高质量“验证集”训练噪声标签评估网络,这在实际应用中是无法满足的。综上,车辆轨迹异常检测中的噪声标签学习主要面临如下挑战。

(1)数据特征复杂:车辆轨迹数据通常包含大量的个体和多样的行为模式。由于个体之间和行为模式之间存在差异,异常样本可能呈现出与正常样本相似的浅层特征(速度、方向角等)。因此,分析和判定错误标注的样本需要挖掘轨迹数据深层特征模式,这显著增加了识别噪声样本的难度。

(2)噪声评估困难:鉴于车辆轨迹数据复杂的时空

特征,异常类型多样;而且随着时空状态的变化,不断有新的异常类型出现。所以,时刻维护干净且高质量的标记数据集是不现实的。因此,如何在没有“验证集”的情况下,识别错误标注的样本是非常困难的。

(3)在线检测:在实际应用中,为了适应在线检测场景,需要进行端到端的模型训练,即实现对噪声样本识别模块和异常检测模块的联合学习。设计合理的优化策略是非常必要且具有挑战性的问题。

为了解决上述挑战,本文提出了基于噪声标签重加权的车辆轨迹异常检测方法。针对数据特征的复杂性问题,引入了路网数据进行信息增强。同时为了建模多种特征模式、提高特征空间的表达能力,本文采用高斯混合函数建模特征隐空间。为了在没有“验证集”的情况下评估噪声标签,本文采用自监督的方式,学习轨迹数据中的时空转移模式,然后利用转移概率实现对噪声标签样本的评估。该方法有效地避免了对异常样本的分析以及对“验证集”的依赖。为了实现在线检测,本文提出了一种基于双层损失的协同优化机制,使用内外层循环分别优化权重估计模块和轨迹异常检测模块,实现了模型端到端的训练。总的来说,本文的主要贡献如下:

(1)提出了一种新的基于噪声标签重加权的车辆轨迹异常检测方法 RW-TAD(noise label ReWeighting-based vehicle Trajectory Anomaly Detection),包括基于 GCN(Graph Convolution Networks, GCN)的时空特征建模模块、基于生成概率的权重估计模块以及基于加权损失的轨迹异常检测模块。具体来说,首先利用基于 GCN 的时空特征建模模块建模时空环境特征,生成路段表征;然后,使用基于生成概率的权重估计模块,以自监督的方式,实现细粒度权重学习;最后,利用基于加权损失的轨迹异常检测模块,采用带权交叉熵损失函数训练检测模型,减少噪声样本对检测模型优化的影响。

(2)提出了一种基于双层损失的协同优化机制,通过权重估计模块和异常检测模块的迭代优化,进行端到端的模型训练,有效地提高了模型的应用价值。

(3)在真实轨迹数据集上进行了大量实验,实验结果表明:相较于现有方法,本文提出的 RW-TAD 方法能够有效缓解噪声标签数据对模型性能的影响,提升噪声标签场景下的轨迹异常检测准确率。

## 2 相关工作

本节分别介绍了当前车辆轨迹异常检测方法以及噪声标签学习方法的相关研究工作。

### 2.1 车辆轨迹异常检测方法

根据技术原理的不同,本文将现有的车辆轨迹异常检测方法分为基于度量的异常检测方法和基于学习

的异常检测方法。

基于度量的方法<sup>[2]</sup>采用手工特征描述正常轨迹的特征模式,然后通过基于密度或者距离的相似性度量,判定与正常轨迹差异较大的样本为异常轨迹。Zhang 等人<sup>[5]</sup>提出了基于孤立树的异常检测方法 IBAT(Isolation-Based Anomalous Trajectory),该方法将城市划分成均匀的网格单元,然后基于隔离异常轨迹的单元数通常小于隔离正常轨迹的单元数的假设检测异常。Liu 等人<sup>[6]</sup>提出了一种基于分割和识别的两阶段检测方法,采用基于距离和密度的混合方法度量轨迹段之间的相似性,将相似轨迹段数量小于既定阈值的子轨迹判定为异常。Zhu 等人<sup>[7]</sup>提出了一种基于主流路线的异常检测方法 TPRRO(Time-dependent Popular Routes based Real-time trajectory Outlier detection),该方法通过构建时间相关转移图,记录在某个时间内某条路径上的轨迹数量,认为在其旅行时间内与主流路线有很大差异的轨迹为异常。Lv 等人<sup>[8]</sup>提出了一种基于密度的检测算法,该方法首先通过聚类算法计算遵循相似路线的轨迹,然后根据轨迹距离聚类中心的距离识别异常轨迹。然而,由于手工特征(如速度频率分布以及密度阈值等)的时空相关性,不同时空状态下的轨迹通常表现出不同的统计特征,因此这种方法可扩展性差。另一方面,手工特征的表达能力有限,无法检测统计特征正常但是深层模式表现为异常的轨迹。

随着机器学习在图像<sup>[9,10]</sup>以及自然语言处理<sup>[11,12]</sup>等领域的成功应用,很多学者开始探索基于学习的异常检测方法。该类方法主要使用深度学习模型挖掘轨迹的深层特征,学习潜在行为模式。按照是否需要标签数据,可以进一步分为基于有监督学习的方法和基于无监督学习的方法。基于有监督学习的方法需要大量的标注数据进行模型训练。Song 等人<sup>[13]</sup>应用循环神经网络(Recurrent Neural Network, RNN)<sup>[14]</sup>建模轨迹数据的序列信息,捕捉相似轨迹中的内在特征。而基于无监督学习的方法通常通过构建序列重建等自监督学习任务,进行模型训练。Liu 等人<sup>[15]</sup>提出了一种基于高斯混合变分自编码器(Variational Auto-Encoder, VAE)的异常检测方法 GM-VSAE(Gaussian Mixture Variational Sequence Auto-Encoder)。该方法采用混合高斯分布建模轨迹潜在模式,认为正常轨迹由潜在模式生成的概率较大,而异常轨迹的生成概率较小。Han 等人<sup>[16]</sup>在高斯混合变分自编码器的基础上,使用卷积神经网络(Convolutional Neural Networks, CNN)<sup>[17]</sup>建模不同时间窗口内的交通模式,从而检测时间依赖型轨迹异常。Wu 等人<sup>[18]</sup>使用最大熵反强化学习模型建模历史轨迹中的驾驶偏好,进一步评估不同路段选择的潜在成本,认为综合成本高的轨迹为异常。总的来说,基于学习的异常检测方法具有更好的特

建模能力,适用于时空特征动态变化的检测场景。其中,基于无监督学习的方法虽然取得了一定的成果,但是由于缺少监督信息,模型无法挖掘正常样本和异常样本之间的区分性特征,检测能力有限。相比之下,基于有监督学习的方法具有更好的性能,但是由于依赖大量的历史标注数据,在标注信息不准确的情况下检测效果差。

## 2.2 噪声标签学习方法

传统的基于机器学习的方法通常假设标签信息是完全干净和完整的<sup>[3]</sup>。但是在实际应用中,数据标注的质量受限于标注人员的领域知识,广泛存在错标或者漏标的情况,即存在一定比例的噪声标签样本<sup>[19]</sup>。对这类样本的拟合会导致模型的负向调整,造成性能的急剧下降。现有的噪声标签场景下的学习方法<sup>[4,20]</sup>主要包括基于数据清洗的方法,基于模型设计的方法和基于目标优化的方法。

基于数据清洗的方法<sup>[21,22]</sup>通过清除噪声置信度较高的样本,获得较为干净的数据集,从而进行模型训练。Thongkam 等人<sup>[23]</sup>提出了基于支持向量机(Support Vector Machine, SVM)<sup>[24]</sup>的噪声样本识别方法,将乳腺癌标注样本中的离群样本视为噪声样本。Jiang 等人<sup>[25]</sup>使用预训练好的教师网络选择标签置信度高的样本,进行目标任务网络的训练。类似的, Yu 等人<sup>[26]</sup>采用多教师网络联合过滤的方式,每个教师网络选择一定数量的高置信度样本提供给任务网络进行训练。但是,基于数据清洗的方法对疑似噪声数据的置信度强,仅适用于数据集中含有许多与正确标注样本差别很大的疑似噪声数据的应用场景。然而,由于异常特征的复杂性,可能存在的漏标异常样本往往呈现出与正常样本相似的特征。因此,基于数据清洗的方法并不适用于轨迹异常检测任务。

基于模型设计的方法<sup>[27,28]</sup>旨在通过设计噪声自适应网络估计标签转移矩阵,从而利用真实标签和噪声标签之间的转换概率,进行损失函数修正。Xia 等人<sup>[28]</sup>通过选择每种类别最具代表性的样本作为锚点数据,然后计算锚点样本的噪声类后验,实现对标签转移矩阵的无偏估计。Han 等人<sup>[29]</sup>提出了一种基于人工辅助的标签转移矩阵估计方法,通过引入专家先验知识,解决由样本数量有限造成的模型学习不充分问题。Yao 等人<sup>[30]</sup>引入了质量变量表示噪声标签的可信度。他们首先将质量变量嵌入到不同的子空间,然后通过调整潜在标签和噪声标签之间的转移概率,降低噪声数据对模型训练的影响。受限于对标签转移矩阵的需求,这种方法只适用于所有异常类型均已知的情况。因此,无法适用于不断有新异常类型出现的现实场景。

基于目标优化的方法<sup>[31,32]</sup>旨在采用目标函数修正和样本重加权等方式减少噪声样本对模型优化的影响。

Shu 等人<sup>[33]</sup>提出了 Meta-Weight-Net 重加权框架,从数据中自适应地学习加权函数,从而减轻噪声标签数据对优化目标的贡献. Dehghani 等人<sup>[32]</sup>提出使用置信度网络评估样本质量,进一步指导目标网络的参数更新,从而避免由噪声样本产生的反向传播对模型训练的影响. 然而,基于目标优化的方法通常假设训练数据集中包含一部分标注准确且覆盖所有异常类型的“验证集”,这在轨迹异常检测中常常是无法满足的. 尤其是在时空状态以及异常概念不断变化的现实场景中,时刻维护一个干净的数据集是不现实的. 因此,现有的基于目标优化的方法不适用于车辆轨迹异常检测任务.

综上所述,现有的噪声标签学习方法均无法适用于基于噪声标签数据的车辆轨迹异常检测任务. 因此,本文提出了一种新的检测方法,旨在在没有“验证集”的情况下训练噪声评估模型,进而采用样本重加权的方式,缓减噪声样本对模型优化的影响. 该方法有效避免了标签转移矩阵的引入以及数据清洗造成的样本信息丢失问题. 同时,提出的方法不需要“验证集”的辅助,可以适用于实际应用场景.

### 3 基于噪声标签重加权的车辆轨迹异常检测方法

#### 3.1 问题定义

原始车辆轨迹数据(Trajectory):给定车辆  $u$  的一段有时间顺序的位置序列  $T = \langle p_1, \dots, p_i, \dots, p_n \rangle$ . 其中,  $p_i = (x_i, y_i, t_i)$  是一个三元组,  $x_i$  和  $y_i$  分别是  $u$  在  $t_i$  时刻的经纬度信息,  $n$  是轨迹长度.

路网数据(Road Network, RN):路网数据可以建模为有向图  $G(V, E)$ ,其中,  $V$  是节点集(十字路口,道路交界处或道路终点),  $E$  是边集(路段).

路网匹配车辆轨迹(Mapped Trajectory, MT):路网匹配之后的车辆轨迹是一段有时间顺序的路段序列  $T = \langle e_1, \dots, e_i, \dots, e_m \rangle$ ,其中,  $e_i$  是路段编号,  $m$  是序列长度.

车辆轨迹异常检测(Trajectory Anomaly Detection, TAD):给定 1 组起点和终点对  $\langle S, D \rangle$ ,假设  $S$  和  $D$  之间存在一些大部分轨迹都经过的正常路线. 轨迹异常检测的目标是发现那些偏离正常路线的异常轨迹.

基于噪声标签数据的车辆轨迹异常检测(Trajectory Anomaly Detection with Noise Label, TADNL):给定含噪车辆轨迹数据集  $D_{\text{train}} = \{ (T_1, \tilde{y}_1), (T_2, \tilde{y}_2), \dots, (T_n, \tilde{y}_n) \}$ ,其中,  $T_i$  为轨迹样本,  $\tilde{y}_i \in \{0, 1\}$  为样本标注标签. 样本的真实标签为  $y_i$ ,则噪声标签样本定义为真实标签和标注标签不相同的样本,即  $\tilde{y}_i \neq y_i$ . 利用  $D_{\text{train}}$  中的噪声标签数据训练模型,识别测试数据集  $D_{\text{test}}$  中的异常轨迹.

#### 3.2 基于噪声标签重加权的车辆轨迹异常检测方法

基于噪声标签重加权的车辆轨迹异常检测方法主要包括 3 个部分,即基于 GCN 的时空特征建模模块、基于生成概率的权重估计模块以及基于加权损失的轨迹异常检测模块,整体框架如图 1 所示.

首先,通过引入路网数据以及历史轨迹数据的统计特征作为先验知识,使用基于 GCN 的时空特征建模模块学习路段表征. 然后,使用基于生成概率的权重估计模块,以自监督的方式计算样本标签的可信度,生成对应的样本权重. 最后,利用学习到的样本权重,使用加权损失函数训练模型,调整样本对异常检测模块参数优化的贡献. 为了实现模型端到端的训练,本文提出基于双层损失的协同优化机制.

基于 GCN 的时空特征建模模块(Spatio-Temporal

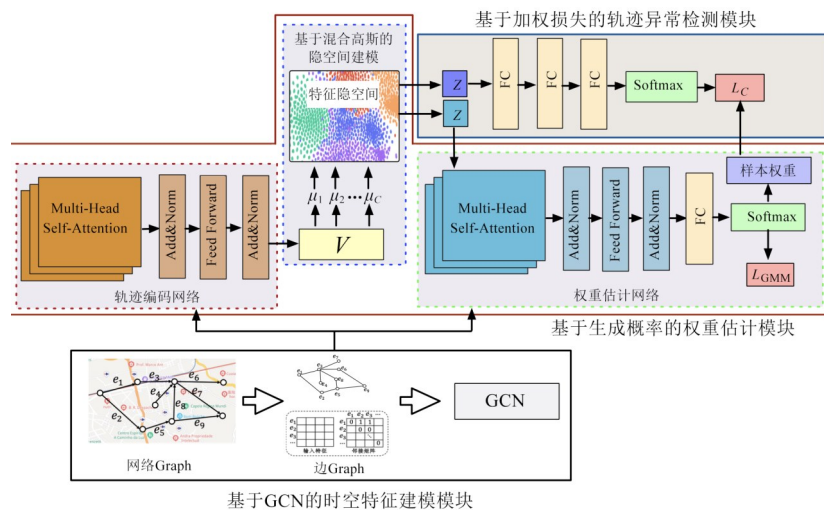


图 1 RW-TAD 方法框架

feature learner based on GCN, ST-learner): 由于车辆轨迹数据的时空特征复杂以及异常概念的定义和时空环境密切相关等特点, 轨迹异常检测需要综合考虑数据的序列特征以及时空环境因素. 因此, 本文引入了路网数据作为先验知识, 描述静态环境特征; 使用历史轨迹数据中的统计信息建模交通状态, 描述动态环境特征. 具体来说, 首先将路网有向图  $G(V, E)$  转换为以路段为节点的边图  $G'(V', E')$ , 其中,  $V' = \{e_1, \dots, e_i, \dots, e_N\}$ ,  $N$  是路段的数量,  $E'$  是边集. 然后, 通过路段之间的连接关系构建邻接矩阵  $A \in \mathbb{R}^{N \times N}$ . 进一步, 引入路段类型、路段限速以及路段历史平均速度等作为节点属性  $F^{N \times P}$  (路段类型、路段限速用来描述静态环境特征, 路段历史平均速度用来描述动态环境特征), 其中,  $P$  是选择的特征数量.

对于 2 个邻接路段, 由于空间邻近以及相互连通的特点, 它们的时空环境相互影响且非常相似. 基于这一观察, 本文引入图卷积神经网络 GCN, 使用自监督的方式学习路段表征. 具体来说, 借鉴 Dong 等人<sup>[34]</sup>的思路, 通过增强相邻路段表征之间的互信息进行模型训练. 这种方法一方面可以有效建模路段之间时空环境的关联关系; 另一方面, 可以通过相邻节点间的信息传递, 解决由于部分路段历史轨迹稀疏造成的模型无法有效建模动态环境特征的问题. 记 GCN 学习到的路段表征矩阵为  $E \in \mathbb{R}^{d_{emb} \times N}$ , 其公式化表述如下:

$$E = \text{GCN}(G', F, A) \quad (1)$$

综上, 给定 1 条路网匹配车辆轨迹  $T = \langle e_1, \dots, e_i, \dots, e_m \rangle$ , 根据 GCN 学习到的路段表征矩阵  $E$ , 可以得到每个路段的表征向量  $em_i = \text{Embedding}(e_i, E)$ , 则处理之后的车辆轨迹序列可以表示为  $T_r = \langle em_1, \dots, em_i, \dots, em_m \rangle$ .

基于生成概率的权重估计模块 (Estimator): 为了在没有“验证集”存在的情况下, 评估噪声标签数据集中样本标签的可信度, 本文提出了基于生成概率的权重估计模块, 主要包括轨迹编码网络 (Encoder Network, EN)、基于混合高斯分布的隐空间建模 (GMM Module, GM) 和权重估计网络 (Weight Network, WN) 3 个部分.

轨迹编码网络: 采用基于 Transformer<sup>[35]</sup>的编码器进行序列建模, 学习轨迹数据的隐表征. 具体的, 将 ST-learner 处理之后的轨迹序列  $T_r$  作为编码器的输入, 其输出即为轨迹序列的隐表征向量  $V_{d_c} \in \mathbb{R}^{d_c}$ , 公式化定义为

$$V_{d_c} = \text{Encoder}(T_r, \varphi) \quad (2)$$

其中,  $d_c$  为轨迹隐表征向量的维度,  $\varphi$  为编码器的参数集合. 进一步, 使用高斯分布建模轨迹的潜在特征模式, 其后验概率分布为  $q_\phi(z|T)$ :

$$z_T \sim q_\phi(z|T) = N(\mu_T, \sigma_T^2 I) \quad (3)$$

$$\mu_T = g_1(V_{d_c}, \phi_\mu) \quad (4)$$

$$\sigma_T = g_2(V_{d_c}, \phi_\sigma) \quad (5)$$

其中,  $\mu_T$  和  $\sigma_T$  是对应高斯分布的均值和方差,  $g_1(\cdot)$  和  $g_2(\cdot)$  均为全连接网络,  $I$  为单位矩阵.

基于混合高斯分布的隐空间建模: 对于 1 对给定的起止点, 它们之间的路线可能包含多组路线模式. 然而, 使用单高斯分布无法建模可能存在的多样化的潜在路线特征模式, 隐空间表达能力有限. 为了解决这个问题, 本文引入了混合高斯分布作为潜在路线特征模式的先验概率分布, 建模轨迹数据的特征隐空间. 具体的, 使用每个高斯分布描述 1 种路线特征模式, 然后使用多项式分布描述轨迹属于每种模式的概率. 假设有  $C$  种路线特征模式, 则隐空间可以建模为

$$p_\psi(z) = p_\psi(z|c) p_\psi(c) \quad (6)$$

$$p_\psi(c) = \text{Cat}(\pi) \quad (7)$$

$$p_\psi(z|c) = N(\mu_c, \sigma_c^2 I) \quad (8)$$

其中,  $p_\psi(c)$  为多项式分布,  $\pi \in \mathbb{R}^C$ ,  $\sum_{i=1}^C \pi_i = 1$ ,  $p_\psi(z|c)$  为模式  $c$  对应的高斯分布.

这里认为潜在路线特征模式与  $\mu_c$  相似的轨迹  $T$  属于模式  $c$ , 形式化定义为

$$\begin{aligned} q_\phi(c|T) &:= p_\psi(c|z_T) = \frac{p_\psi(z_T|c) p_\psi(c)}{\sum_{i=1}^C p_\psi(z_T|c_i) p_\psi(c_i)} \\ &= \text{softmax} \left( \frac{z_T - \mu_c}{\sum_{i=1}^C (z_T - \mu_i)} \right) \end{aligned} \quad (9)$$

进一步, 轨迹  $T$  的潜在路线特征模式的后验概率分布可以改写为

$$z_T \sim q_\phi(z, c|T) = q_\phi(z|T) q_\phi(c|T) \quad (10)$$

权重估计网络: 通过上述处理, 可以得到轨迹  $T_r$  的潜在路线特征模式向量  $z_T$ . 进一步, 使用基于 Transformer 的解码器计算轨迹由学习到的路线特征模式生成的概率. 具体来说, 使用向量  $z_T$  和当前位置之前的路段序列表征信息作为输入, 生成当前路段编号, 形式化定义如下:

$$g_i = \text{Decoder}(z_T, g_{i-1}, \theta_d) \quad (11)$$

$$e'_i \sim p_\theta(e|e_{<i}, z) = \text{softmax}(g_3(g_i, \theta_g)) \quad (12)$$

其中,  $e'_i$  为生成的路段编号,  $g_3(\cdot)$  是用于生成路段的全连接层. 通过  $g_3(\cdot)$  的映射, 可以将  $g_i$  转换到路段编号对应空间.

综上, 对于给定轨迹  $T_r$ , 其由学习到的路线特征模

式生成的概率可以计算如下:

$$P(\mathbf{T}_{\leq i}) = \operatorname{argmax}_{c \in C} \exp \left[ \frac{\log p_{\theta}(\mathbf{T}_{\leq i-1} | \boldsymbol{\mu}_c) \log p_{\theta}(\mathbf{T}_{\leq i} | \mathbf{T}_{\leq i-1}, \boldsymbol{\mu}_c)}{i} \right] \quad (13)$$

通过上述方法,可以学习到给定数据的潜在路线特征模式,以及能够计算由学习到的模式生成指定序列的概率. 接下来,需要讨论如何利用上述结构评估标签可信度. 一般来说,1条轨迹由正常路线特征模式生成的概率越低,轨迹是异常的概率则越大,其作为正常标签数据的可信度越小,样本在目标优化过程中的权重应该越小. 反之,则权重越大. 因此,如何保证 Estimator 学习到正常轨迹的路线特征模式是重要问题,本文通过基于无标签数据集的预训练和基于噪声标签数据的联合优化,拟合可以刻画正常路线特征模式的混合高斯分布,具体优化过程见 3.3 节. 最后,样本权重可以计算如下:

$$w_k = \begin{cases} \lambda_1 P_k, \tilde{y}_k = 0 \\ \lambda_2 (1 - P_k), \tilde{y}_k = 1 \end{cases} \quad (14)$$

其中,  $P_k$  为第  $k$  个样本的由匹配到的正常路线特征模式生成的概率,  $\tilde{y}_k$  为第  $k$  个样本的标注标签,  $\lambda_1$  和  $\lambda_2$  为超参数.

损失函数:与传统的基于 VAE 的生成模型一样,本文使用变分下界 (Evidence Lower Bound, ELBO) 定义损失函数,包括轨迹路段的重构损失和 KL 损失 2 个部分. 记  $\phi = \{\phi, \phi_{\mu}, \phi_{\sigma}\}$ ,  $\psi = \{\boldsymbol{\pi}, \boldsymbol{\mu}_c, \boldsymbol{\sigma}_c\}$ ,  $\theta = \{\theta_d, \theta_g\}$ , 公式化描述如下:

$$L_{\text{GMM}}(\phi, \theta, \psi; \mathbf{T}) = \mathbb{E}_{q_{\phi}(z|\mathbf{T})} [\log p_{\theta}(\mathbf{T}|z)] - \mathbb{E}_{q_{\phi}(z|\mathbf{T})} [D_{\text{KL}}(q_{\phi}(c|\mathbf{T}) \| p_{\psi}(c))] - \mathbb{E}_{q_{\phi}(z|\mathbf{T})} [D_{\text{KL}}(q_{\phi}(z|\mathbf{T}) \| p_{\psi}(z|c))] \quad (15)$$

其中,  $D_{\text{KL}}(\cdot \| \cdot)$  为 KL 散度.  $\mathbb{E}_{q_{\phi}(z|\mathbf{T})} [\log p_{\theta}(\mathbf{T}|z)]$  为轨迹序列的重构损失,公式化描述为

$$\mathbb{E}_{q_{\phi}(z|\mathbf{T})} [\log p_{\theta}(\mathbf{T}|z)] = \sum_{i=1}^m f_{\text{CE}}(e_i, e'_i) \quad (16)$$

其中,  $f_{\text{CE}}(\cdot)$  为交叉熵函数,  $e_i$  为路段编号,  $e'_i$  为生成的路段编号.

基于加权损失的轨迹异常检测模块 (Detector): 对于给定样本  $\mathbf{T}_i$ , 利用 ST-learner 以及 Estimator 可以计算其对应的样本权重, 记为

$$w_{\mathbf{T}_i} = \text{Est}(\mathbf{T}_i) \quad (17)$$

其中,  $\text{Est}(\cdot)$  表示 Estimator 的操作算子. 得到的样本权重  $w_{\mathbf{T}_i}$  会进一步作为 Detector 的输入, 缓减模型对噪声样本的拟合. 具体来说, 首先使用权重估计模块的 Encoder Network 和 GMM Module 获得轨迹的隐表征向量

$\mathbf{z}_{\mathbf{T}_i}$ . 鉴于轨迹异常的时空相关性, 本文同时结合了起止点信息以及当前轨迹的起始时间信息作为 Detector 的输入, 公式化描述如下:

$$\mathbf{h}_{\text{od}} = \text{concat}(\mathbf{e}_{\text{orig}}, \mathbf{e}_{\text{dest}}) \quad (18)$$

$$\mathbf{h}_{\mathbf{T}_i} = \text{concat}(\mathbf{t}_1; \mathbf{z}_{\mathbf{T}_i}; \mathbf{h}_{\text{od}}) \quad (19)$$

其中,  $\mathbf{e}_{\text{orig}}$  和  $\mathbf{e}_{\text{dest}}$  分别为起止点的路段表征向量,  $\mathbf{t}_1$  为轨迹的起始时间向量. 聚合之后的向量  $\mathbf{h}_{\mathbf{T}_i}$  会被送入以全连接层为基础结构的检测网络, 形式化定义为

$$\mathbf{o}_{\mathbf{T}_i} = \text{softmax}(\text{FC}(\mathbf{h}_{\mathbf{T}_i}, \gamma)) \quad (20)$$

其中,  $\mathbf{o}_{\mathbf{T}_i}$  为第  $i$  个样本属于异常的概率,  $\gamma$  为检测网络的参数,  $\text{FC}(\cdot)$  为全连接层. 进一步, 采用加权损失作为目标函数, 调整不同标签可信度的样本对优化目标的贡献. 记  $Y = \{\gamma\}$ , 则损失函数为

$$L_c(Y) = \sum_{i=1}^{\text{BN}} w_{\mathbf{T}_i} f_{\text{CE}}(\mathbf{o}_{\mathbf{T}_i}, l_i) \quad (21)$$

其中,  $w_{\mathbf{T}_i}$  为样本权重,  $l_i$  为样本标签,  $f_{\text{CE}}(\cdot)$  为交叉熵损失函数, BN 为当前 batch 中样本的数量.

### 3.3 基于双层损失的协同优化机制

为了适应在线检测场景, 实现端到端的训练, 本文提出了基于双层损失的协同优化机制, 使用内外层循环分别优化 Estimator 和 Detector.

Estimator 优化: 在迭代优化过程中, 保持 Detector 的参数不变. 该阶段的目标是使用高置信度正常样本指导模型更好地学习正常路线的潜在特征模式, 从而提高样本权重估计的准确性. 具体来说, 首先从训练集中采样训练样本, 经过 Detector 的处理之后, 得到样本被识别为异常的概率  $\mathbf{o}_{\mathbf{T}}$ . 然后, 选取  $\mathbf{o}_{\mathbf{T}} < \rho$  的  $m$  个正常标签样本作为当前 batch, 优化模型参数, 记  $\Theta = \{\phi, \psi, \theta\}$ , 则形式化描述如下:

$$\Theta^{t+1} = \Theta^t - \beta \frac{1}{m} L_{\text{GMM}}(\Theta^t) \quad (22)$$

另外, 在协同优化之前, 为了提高模型收敛速度, 首先使用无标签数据集对权重估计模块进行预训练, 促进模型对有效特征的学习. 预训练过程同样采用重建序列数据作为预训练任务, 并用式 (16) 进行模型优化. 由于无标签数据中异常轨迹占比很少, 所以当数据量足够大的时候, 模型可以有效挖掘正常样本的潜在路线特征模式. 采用这种方式, 可以得到较好的模型初始化参数  $\Theta$ , 提高 Encoder Network 提取特征的有效性以及 Weight Network 的权重估计效果.

Detector 优化: 在迭代优化过程中, 保持 Estimator 参数不变. 首先, 使用 Estimator 获取当前 batch 中样本的权重, 然后使用加权损失更新 Detector 的参数  $Y$ , 形式化描述如下:

$$\begin{aligned}
Y^{t+1} &= Y^t - \alpha \frac{1}{n} L_C(Y^t) \\
&= Y^t - \alpha \frac{1}{n} \sum_{i=1}^{\text{BN}} \text{Est}(T_i) f_{\text{CE}}(\mathbf{o}_{T_i}, l_i)
\end{aligned} \quad (23)$$

其中, BN 为 batch 中样本数量.

本文从概率的角度出发, 利用轨迹序列中位置点之间的顺序依赖性, 设计了一种面向轨迹数据的标签权重评估方法, 即基于生成概率的权重估计模块. 相较于传统方法的研究思路(即利用高质量的干净标签数据集, 学习样本数据和标签可信度之间的映射关系), 这种方法从轨迹数据的固有属性出发, 从移动目标转移概率的角度出发建模轨迹生成过程, 利用生成轨迹点的合理性评估标签权重, 具有更好的可靠性和可解释性. 另一方面, 通过无标签数据集上的预训练和在噪声标签数据集上的联合优化, 该方法有效避免了传统方法存在的对“验证集”的依赖问题, 可以适应时空环境动态变化以及不断有新异常类型产生的实际应用场景.

在轨迹特征模式建模方面, 引入了混合高斯分布拟合特征空间. 这种方法可以有效提高特征空间的表达能力, 保证学习到覆盖大部分正常轨迹特征模式的特征空间. 此外, 提出的基于双层损失的协同优化机制, 可以实现基于生成概率的权重估计模块和基于加权损失的轨迹异常检测模块的联合优化. 使得模型可以在无需人工干预的情况下, 进行端到端的模型训练.

## 4 实验评估与结果分析

本文通过广泛的实验, 验证了 RW-TAD 方法的有效性. 本节首先介绍了实验所使用的数据集、参数设置和评价指标. 然后介绍了实验所采用的对比方法, 并对实验结果进行了分析. 最后, 通过消融实验验证了模型各个组件的有效性.

### 4.1 数据集

本实验在 2 个公开的车辆轨迹数据集上验证了 RW-TAD 的性能, 分别是成都和西安的出租车轨迹数据集. 为了实验结果的有效性, 删除了路网匹配之后长度小于 10 以及行程持续时间大于 2 h 的轨迹. 由于数据集中没有异常标签样本, 所以手工构造了一部分异常轨迹进行分析, 具体构造方法如下:

异常轨迹构造方法: 首先, 选定一组起止点对, 并确定其在路网上的正常路径. 然后, 从路网中随机删除路径上的一个或者多个路段, 构造新的拓扑结构. 最后, 使用 Dijkstra<sup>[36]</sup> 算法在新的路网结构上生成选定起止点之间的异常轨迹.

噪声标签注入: 随机选取  $m$  个样本进行标签翻转,

实现噪声标签注入. 噪声率  $\rho$  定义为数据集中噪声标签样本的占比, 形式化描述为

$$\rho = \frac{m}{N}, \rho \in [0, 1] \quad (24)$$

其中,  $N$  为数据集中的样本总数.

通过上述处理之后, 进一步将数据集划分为 3 个子集, 即训练集、测试集和验证集(这里的验证集是用于调整超参数的数据集, 不同于基于目标优化的噪声标签学习方法中的“验证集”). 最后得到的数据集统计情况如表 1 所示.

表 1 数据集详情

数据集	训练集		测试集		验证集	
	正常	异常	正常	异常	正常	异常
成都	8 000	800	3 000	1 000	3 000	300
西安	7 000	700	3 000	1 000	2 000	200

### 4.2 模型及参数设置

本实验采用 2 层的 Transformer 作为 Encoder Network 和 Weight Network 的基础结构, 混合高斯分布组件的数量设置为 6. 使用 2 层的 GCN 学习路段表征, 3 层的全连接层构建检测模块. 训练阶段的 Batch Size 设置为 64, 测试阶段设置为 128. Estimator 和 Detector 的学习率分别设置为 0.001、0.01. 超参数  $\lambda_1$  设置为 0.9,  $\lambda_2$  为 0.4. 若无特殊说明,  $\rho$  设置为 0.2. 无论是 Estimator 的预训练还是 Estimator 和 Detector 的联合优化, 本实验均采用表 1 中的训练集进行训练, 不同的是预训练阶段忽略了标签信息. 预训练和联合优化均训练了 100 个 Epoch, 然后选取收敛之后的最优模型参数作为最终结果. 实验选取的 5 种基于学习的轨迹异常检测方法按照原论文中的超参数设定进行实验. 选取的 2 种噪声标签学习方法, 即 CC 和 MentorNet 的学习率均设置为 0.01, 训练阶段的 Batch Size 设置为 64, 测试阶段设置为 128.

### 4.3 对比方法

由于目前没有关于基于噪声标签数据的车辆轨迹异常检测方法的研究, 本实验选取了 5 种基于学习的轨迹异常检测方法以及 2 种噪声标签学习方法进行对比, 这些方法包括:

ATD-RNN<sup>[13]</sup> (Anomalous Trajectory Detection method based on Recurrent Neural Network): 一种基于循环神经网络 RNN 的轨迹异常检测方法. 该方法利用 RNN 建模轨迹序列特征, 然后使用分类器识别异常轨迹.

EncDecAD<sup>[37]</sup> (long short term memory networks based Encoder-Decoder scheme for Anomaly Detection): 一种基于双向长短时记忆网络的生成式轨迹异常检测方法. 该方法通过重建误差进行异常分类, 认为正常样

本的重建效果优于异常样本。

Traj2Vec<sup>[38]</sup> (Trajectory to Vector): 一种半监督的轨迹表示学习方法。该方法使用滑动窗口提取轨迹的统计特征, 然后使用 seq2seq 模型学习轨迹表征。本实验通过附加的分类器进行异常检测。

GM-VSAE<sup>[15]</sup>: 一种基于混合高斯变分自编码器的异常检测方法。该方法使用混合高斯描述轨迹潜在的路线模式, 根据轨迹由正常模式的生成概率识别异常。

DeepTEA<sup>[16]</sup> (Deep-probabilistic-based Time-dEpendent anomaly detection algorithm): 一种基于变分自编码器的轨迹异常检测方法, 旨在检测时间依赖型轨迹异常。该方法在使用 CNN 建模道路交通特征的同时, 使用混合高斯 VAE 建模轨迹潜在路线的模式特征。最后, 根据生成概率识别异常。

Cluster-based Correction (CC)<sup>[39]</sup> (Correction Method based on Cluster): 一种基于聚类的噪声标签学习方法, 该方法通过 KMeans 聚类算法去除训练样本中的离群点, 达到去噪的效果。本实验使用与 4.5.2 节中 RW-TADg 相同的网络结构构建异常检测模型, 然后在去噪之后的数据集上进行训练, 从而检测异常轨迹。

MentorNet<sup>[25]</sup> (Method to Learn the Curriculum from Data by a Network): 一种基于浅层神经网络的噪声标签学习方法, 该方法通过构建 Mentor 网络评估样本权重, 达到去噪的效果。本实验使用 2 层 LSTM 构建 Mentor 网络, 同样使用与 4.5.2 节中 RW-TADg 相同的网络结构构建检测模型, 从而实现异常判定。

#### 4.4 评价指标

本文实验采用 Precision、Recall 和  $F_1$ -score 作为评价指标, 评估 RW-TAD 模型的性能。

### 4.5 实验结果与分析

#### 4.5.1 整体性能评估实验

在整体性能评估的实验中, 为了保证结果的稳定性, 取 10 次重复实验的平均值进行分析, 实验结果如表 2 所示。

从表 2 可以看出, 本文的方法在 3 个指标上均取得了最好的结果。以成都数据集为例, 与轨迹异常检测对比方法中性能最好的 DeepTEA 相比, 本文的方法在  $F_1$ -score 和 Precision 指标上分别提高了 11.6%、11.1%。这说明提出的方法不仅能够建模轨迹潜在特征模式, 还能提高模型对噪声样本的鲁棒性, 可以有效应用于噪声标签场景下的车辆轨迹异常检测任务。与噪声样本学习的对比方法相比,  $F_1$ -score 和 Precision 分别提高了 7.4%、6.3%。由于采用的检测模型结构完全相同, 所以检测性能的显著提高验证了 Estimator 对标签可信度评

估的准确性以及基于生成概率的评估方法对车辆轨迹数据的有效性。

在轨迹异常检测的对比方法中, DeepTEA 的性能最好, 该方法在建模轨迹特征模式多样性的同时, 考虑了交通模式的变化, 具有较强的轨迹建模能力。然而, 这种方法依赖于模型对正常特征模式的学习效果, 在噪声标签数据集上的性能较差, 与本文提出的方法具有显著差距。在噪声标签学习的对比方法中, MentorNet 的性能最优, 这是因为 CC 在去除噪声样本的同时, 过滤了大量的干净样本, 会造成训练样本的显著减少, 最终导致模型的性能不佳。而 MentorNet 采用样本加权的方式, 在有效控制噪声样本对模型优化影响的同时, 保证了训练样本的规模以及多样性。因此, 取得了较好的性能。

#### 4.5.2 消融实验

为了验证基于生成概率的样本权重估计模块的有效性, 提出了 2 个 RW-TAD 的变体 RW-TADg 和 RW-TADm, 详细信息如下:

RW-TADg (Noise label Reweighting-based Vehicle Trajectory Anomaly Detection Method with Gaussian): 使用与 RW-TAD 完全相同的 Encoder Network + GMM Module + Detector 进行异常检测。在优化过程中, 认为所有样本的标签都是准确的(为了测试的公平性, 采用相同的方式对 Encoder Network + GMM Module 进行预训练)。

RW-TADm (Noise label Reweighting-based Vehicle Trajectory Anomaly Detection Method with MentorNet): 使用 2 层 Transformer 网络替换 Estimator。通过神经网络直接生成样本权重, 而不是使用生成概率预测的方式。其他各部分均与 RW-TAD 相同。在 2 个数据集上的实验结果如表 3 所示。

从表 3 可以看出, 相较于 RW-TAD, RW-TADg 方法的  $F_1$ -score 在成都数据集和西安数据集上分别降低了 11.2% 和 9.1%。性能的显著下降证明了 Estimator 对于模型在噪声标签场景下的检测效果具有重要的作用。RW-TADm 方法的  $F_1$ -score 在 2 个数据集上分别降低了 9% 和 6.3%, 这说明基于生成概率进行样本权重评估对于车辆轨迹数据具有较好的效果。同时, 对轨迹生成过程的建模很好地刻画了轨迹生成的合理性, 为权重估计提供了重要的信息。

为了进一步分析权重估计效果, 本实验从成都数据集中采样了 1 000 条正常样本和 1 000 条异常样本进行实验。从中随机选取了 50% 的样本进行标签翻转, 然后利用权重估计模块计算样本对应的权重。图 2 为样本权重分布情况的可视化分析图, 横坐标轴表示权重

区间,纵坐标轴表示落在各权重区间中的样本数量.从图中可以看出,干净标签样本大多数都落在了权重较大的区间,而噪声标签样本的权重大部分都小于0.4.这表明 Estimator 可以准确评估样本的噪声程度,对于检测效果的提升有重要的意义.




图2 样本权重分布图

### 4.5.3 噪声率敏感性分析

为了测试模型在不同噪声率情况下的检测性能,选取了3种典型的对比方法,在 $\rho \in [0, 0.2, 0.4, 0.6, 0.8, 1]$ 的数据集上进行了分析.具体方法包括 EncDecAD、DeepTEA 和 MentorNet.在成都出租车轨迹数据集上的实验结果如图3所示.

图3清晰明了地展示了不同模型的检测性能随数据集噪声率的变化情况,其中横坐标轴为数据集的噪

声率,纵坐标轴为模型在数据集上的  $F_1$ -score,不同颜色代表不同的检测方法.显而易见,随着噪声率的增加,RW-TAD表现出相对稳定的性能,而且可以更好地适应于极端场景. EncDecAD 和 DeepTEA 的性能随着噪声率的上升,表现出明显的下降趋势.当 $\rho=0.4$ 时,性能呈现断崖式下降;当 $\rho=0.6$ 时,  $F_1$ -score 均低于50%,几乎失去了检测能力. MentorNet 方法在 $\rho \leq 0.4$ 时,性能相对平稳,但仍然比 RW-TAD 的检测效果差.当 $\rho=0.6$ 时,  $F_1$ -score 呈现断崖式下降,这是由于 Mentor 网络的训练对数据集的质量有较高的要求,因此无法适用于极端噪声率场景下的轨迹异常检测任务.综上所述, RW-TAD 可以有效应用于噪声标签场景下的车辆轨迹异常检测任务,对于不同程度的噪声场景具有良好的适应性.




图3 噪声敏感性分析图

表2 轨迹异常检测方法性能对比结果表

评估指标	方法							
	ATD-RNN	EncDecAD	Traj2Vec	GM-VSAE	DeepTEA	CC	MentorNet	RW-TAD
评估指标	成都数据集( $\rho=0.2$ )							
Recall	0.568	0.613	0.651	0.690	0.705	0.765	0.742	<b>0.825</b>
Precision	0.653	0.677	0.716	0.763	0.748	0.749	0.796	<b>0.859</b>
$F_1$ -score	0.608	0.643	0.682	0.724	0.726	0.757	0.768	<b>0.842</b>
评估指标	西安数据集( $\rho=0.2$ )							
Recall	0.572	0.603	0.633	0.682	0.691	0.733	0.752	<b>0.817</b>
Precision	0.603	0.657	0.696	0.729	0.739	0.762	0.772	<b>0.805</b>
$F_1$ -score	0.587	0.629	0.663	0.705	0.714	0.747	0.761	<b>0.811</b>

注:加粗数据表示最优结果.

表3 消融实验结果表( $\rho=0.2$ )

评估指标	RW-TADg		RW-TADm		RW-TAD	
	成都数据集	西安数据集	成都数据集	西安数据集	成都数据集	西安数据集
Recall	0.721	0.704	0.726	0.732	<b>0.825</b>	<b>0.817</b>
Precision	0.737	0.736	0.779	0.765	<b>0.859</b>	<b>0.805</b>
$F_1$ -score	0.730	0.720	0.752	0.748	<b>0.842</b>	<b>0.811</b>

注:加粗数据表示最优结果.

## 5 总结

本文分析了在噪声标签数据集上进行车辆轨迹异常检测存在的问题,并提出了一种基于噪声标签重加权的车辆轨迹异常检测方法 RW-TAD. 该方法引入了路网数据以及历史轨迹数据的统计信息进行信息增强,采用高斯混合分布建模轨迹特征隐空间. 然后通过一种基于生成概率的权重估计模块评估样本可信度,采用加权损失减少噪声样本在模型优化过程中的贡献,进而提高模型对噪声数据的鲁棒性. 同时,提出了一种基于双层损失的协同优化机制,进行端到端的模型优化. 最后,从定量分析的角度,在成都和西安的出租车轨迹数据集上进行了广泛的实验. 结果证明了,相较于现有的检测方法, RW-TAD 在有噪声标签数据集上的准确率和稳定性均获得了较大的提升.

### 参考文献

- [1] WANG S, BAO Z F, CULPEPPER J S, et al. A survey on trajectory data management, analytics, and learning[J]. *ACM Computing Surveys*, 2021, 54(2): 1-36.
- [2] BELHADI A, DJENOURI Y, LIN J C, et al. Trajectory outlier detection[J]. *ACM Transactions on Management Information Systems*, 2020, 11(3): 1-29.
- [3] SUKHBAATA S, FERGUS R. Learning from noisy labels with deep neural networks[EB/OL]. (2015-04-10)[2023-06-01]. <https://arxiv.org/abs/1406.2080v4>.
- [4] CORDEIRO F R, CARNEIRO G. A survey on deep learning with noisy labels: How to train your model when you cannot trust on the annotations? [C]//2020 33rd SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI). Piscataway: IEEE, 2020: 9-16.
- [5] ZHANG D Q, LI N, ZHOU Z H, et al. iBAT: Detecting anomalous taxi trajectories from GPS traces[C]//UbiComp'11: Proceedings of the 2011 ACM Conference on Ubiquitous Computing. New York: ACM, 2011: 99-108.
- [6] LIU W, ZHENG Y, CHAWLA S, et al. Discovering spatio-temporal causal interactions in traffic data streams[C]//Proceedings of the 17th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2011: 1010-1018.
- [7] ZHU J, JIANG W, LIU A, et al. Effective and efficient trajectory outlier detection based on time-dependent popular route[J]. *World Wide Web*, 2017, 20(1): 111-134.
- [8] LV Z J, XU J J, ZHAO P P, et al. Outlier Trajectory Detection: A Trajectory Analytics Based Approach[M]//Database Systems for Advanced Applications. Cham: Springer International Publishing, 2017: 231-246.
- [9] TSIRIKOGLU A, EILERTSEN G, UNGER J. A survey of image synthesis methods for visual machine learning[J]. *Computer Graphics Forum*, 2020, 39(6): 426-451.
- [10] NICHOLS J A, HERBERT CHAN H W, BAKER M A B. Machine learning: Applications of artificial intelligence to imaging and diagnosis[J]. *Biophysical Reviews*, 2019, 11(1): 111-118.
- [11] OTTER D W, MEDINA J R, KALITA J K. A survey of the usages of deep learning for natural language processing[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, 32(2): 604-624.
- [12] TORFI A, SHIRVANI R A, KENESHLOO Y, et al. Natural language processing advancements by deep learning: A survey[EB/OL]. (2021-02-27)[2023-06-01]. <http://arxiv.org/abs/2003.01200v4>.
- [13] SONG L, WANG R J, XIAO D, et al. Anomalous trajectory detection using recurrent neural network[M]//Advanced Data Mining and Applications. Cham: Springer International Publishing, 2018: 263-277.
- [14] FANG W, CHEN Y P, XUE Q Y. Survey on research of RNN-based spatio-temporal sequence prediction algorithms[J]. *Journal on Big Data*, 2021, 3(3): 97-110.
- [15] LIU Y D, ZHAO K Q, CONG G, et al. Online anomalous trajectory detection with deep generative sequence modeling[C]//2020 IEEE 36th International Conference on Data Engineering (ICDE). Piscataway: IEEE, 2020: 949-960.
- [16] HAN X L, CHENG R, MA C H, et al. DeepTEA[J]. *Proceedings of the VLDB Endowment*, 2022, 15(7): 1493-1505.
- [17] SAHU M, DASH R. A survey on deep learning: Convolution neural network (CNN)[C]//Intelligent and Cloud Computing. Singapore: Springer, 2021: 317-325.
- [18] WU H, SUN W W, ZHENG B H, et al. A fast trajectory outlier detection approach via driving behavior modeling[C]//Proceedings of the 2017 ACM Conference on Information and Knowledge Management. New York: ACM, 2017: 837-846.
- [19] HAN B, YAO Q M, LIU T L, et al. A survey of label-noise representation learning: Past, present and future[EB/OL]. (2021-02-20)[2023-06-01]. <http://arxiv.org/abs/2011.04406v2>.
- [20] SONG H, KIM M, PARK D, et al. Learning from noisy labels with deep neural networks: A survey[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2023, 34(11): 8135-8153.
- [21] DELANY S J, SEGATA N, MAC NAMEE B. Profiling instances in noise reduction[J]. *Knowledge-Based Systems*, 2012, 31: 28-40.
- [22] GAMBERGER D, LAVRAC N, DZEROSKI S. Noise detection and elimination in data preprocessing: Experiments in medical domains[J]. *Applied Artificial Intelligence*, 2000,

- 14(2): 205-223.
- [23] THONGKAM J, XU G D, ZHANG Y C, et al. Support vector machine for outlier detection in breast cancer survivability prediction[M]//Advanced Web and Network Technologies, and Applications. Berlin: Springer, 2008: 99-109.
- [24] CERVANTES J, GARCIA-LAMONT F, RODRÍGUEZ-MAZAHUA L, et al. A comprehensive survey on support vector machine classification: Applications, challenges and trends[J]. Neurocomputing, 2020, 408: 189-215.
- [25] JIANG L, ZHOU Z Y, LEUNG T, et al. MentorNet: Learning data-driven curriculum for very deep neural networks on corrupted labels[EB/OL]. (2018-08-13) [2023-06-01]. <http://arxiv.org/abs/1712.05055v2>.
- [26] YU X R, HAN B, YAO J C, et al. How does disagreement help generalization against label corruption?[EB/OL]. (2019-05-12)[2023-06-01]. <http://arxiv.org/abs/1901.04215v3>.
- [27] CHENG L L, ZHOU X Z, ZHAO L M, et al. Weakly supervised learning with side information for noisy labeled images[M]//Computer Vision - ECCV 2020. Cham: Springer International Publishing, 2020: 306-321.
- [28] XIA X B, HAN B, WANG N N, et al. Extended \$T\$-\$T\$: Learning with mixed closed-set and open-set noisy labels[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(3): 3047-3058.
- [29] HAN B, YAO J C, NIU G, et al. Masking: A new perspective of noisy supervision[EB/OL]. (2018-11-31)[2023-06-01]. <http://arxiv.org/abs/1805.08193v2>.
- [30] YAO J C, WANG J J, TSANG I W, et al. Deep learning from noisy image labels with quality embedding[J]. IEEE Transactions on Image Processing, 2019, 28(4): 1909-1922.
- [31] ZHENG G Q, AWADALLAH A H, DUMAIS S. Meta label correction for noisy label learning[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2021, 35(12): 11053-11061.
- [32] DEGHANI M, SEVERYN A, ROTHE S, et al. Learning to learn from weak supervision by full supervision[EB/OL]. (2017-11-30)[2023-06-01]. <http://arxiv.org/abs/1711.11383>.
- [33] SHU J, XIE Q, YI L X, et al. Meta-weight-net: Learning an explicit mapping for sample weighting[EB/OL]. (2019-09-27)[2023-06-01]. <http://arxiv.org/abs/1902.07379v6>.
- [34] DONG W, YAN D W, WANG P. Self-supervised node representation learning via node-to-neighbourhood alignment[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2024, 46(6):4218-4233.
- [35] VASWANI A, SHAZEER N M, PARMAR N, et al. Attention is all you need[EB/OL]. (2017-06-12) [2023-06-01]. <http://arxiv.org/abs/1706.03762>.
- [36] MEDAK J, GOGOI P P. Review and analysis of single-source shortest path problem using fijkstra's algorithm[J]. IOSR Journal of Computer Engineering (IOSR-JCE), 2018, 20(2): 10-15.
- [37] MALHOTRA P, RAMAKRISHNAN A, ANAND G, et al. LSTM-based encoder-decoder for multi-sensor anomaly detection[EB/OL]. (2016-07-11)[2023-06-01]. <http://arxiv.org/abs/1607.00148v2>.
- [38] YAO D, ZHANG C, ZHU Z H, et al. Trajectory clustering via deep representation learning[C]//2017 International Joint Conference on Neural Networks (IJCNN). Piscataway: IEEE, 2017: 3880-3887.
- [39] NICHOLSON B, ZHANG J, SHENG V S, et al. Label noise correction methods[C]//2015 IEEE International Conference on Data Science and Advanced Analytics (DSAA). Piscataway: IEEE, 2015: 1-9.

### 作者简介



**苏越阳** 男,1992年12月出生,内蒙古包头人.中国科学院计算技术研究所助理研究员.主要研究方向为时序数据挖掘、异常检测以及RAG系统分析.

E-mail: [suyueyang@ict.ac.cn](mailto:suyueyang@ict.ac.cn)



**姚迪** 男,1990年8月出生,河南省许昌人.中国科学院计算技术研究所副研究员.主要研究方向为时空数据挖掘和深度学习.

E-mail: [yaodi@ict.ac.cn](mailto:yaodi@ict.ac.cn)



**毕经平** 女,1974年7月出生,山东省泰安人.中国科学院计算技术研究所研究员.主要研究方向为网络测量、路由、虚拟化、SDN和大数据分析.

E-mail: [bjp@ict.ac.cn](mailto:bjp@ict.ac.cn)