

基于时空注意力机制的低假阳性异常轨迹检测

牟丽蓉¹ 夏大文^{1*} 刘 龙¹
MOU Lirong XIA Dawen LIU Long

摘 要

移动轨迹大数据已成为异常轨迹检测、交通流量预测等智能交通分析的重要数据源。现有异常轨迹检测方法通常将明显偏离正常路线的轨迹判定为异常，但由于未充分考虑设备采样异常、极端天气或高峰期正常变道等情况，从而导致假阳性率较高。为此，文章提出了一种基于时空注意力机制的低假阳性异常轨迹检测模型（STAM-LFP），融合多尺度时间与空间依赖。首先，设计时空特征提取模块，以捕捉轨迹的长序列和周期性时间特征；其次，基于空间特征提取模块，建立图注意力网络（GAT），以自适应建模轨迹点间的空间关系；最后，构建高斯混合模型（GMM）建模轨迹的潜在空间分布，以识别轨迹异常。基于两个真实数据集的实验结果表明，STAM-LFP 模型在异常轨迹检测的准确性和鲁棒性方面表现良好。

关键词

异常轨迹检测；移动轨迹大数据；时空注意力机制；图注意力网络；高斯混合模型

doi: 10.3969/j.issn.1672-9528.2025.12.036

0 引言

随着移动计算的广泛应用，海量移动轨迹数据呈指数级增长，为深入理解和分析交通行为模式提供丰富的数据源。移动轨迹数据时空挖掘作为新兴研究方向，涵盖地图匹配^[1]、路径预测、时空特征提取、交通流量预测^[2]和异常轨迹检测^[3]等关键任务。其中，异常轨迹检测在构建智慧交通系统、保障公共安全和优化城市治理中发挥着不可替代作用。在数据驱动的智能交通系统中，出租车、网约车等公共交通出行方式具有覆盖范围广和出行便捷等优势，可以大幅提升公众的出行效率与通行便利。然而，部分驾驶员为了追求非法收益，有时存在故意绕路和延长行程等行为，不仅影响交通秩序，而且侵害乘客合法权益。异常轨迹检测能够实现恶意违规行为的精准识别，可以辅助预测潜在的交通风险（如交通拥堵、交通事故），有助于保障城市交通的高效、稳定和有序运行。

现有方法通常将异常轨迹定义为偏离常规行车路线的轨迹。如图 1 所示，在初始点 O 到目的地 D 的多条路线中，轨迹 T_1 、 T_2 是大多数驾驶员普遍选择的路线。相比之下，轨迹 T_3 由于明显偏离常规路线，被视为异常轨迹。但是，大部分现有方法并未考虑采样设备收集轨迹数据异常和高峰期正常变道等情况。在实际交通场景中，车辆途经轨道或遇到极端天气时，经常导致同样路径产生的轨迹数据不同。例如，

轨迹 T 运行的轨迹是 $\langle e_1, e_2, e_3, e_4, e_5, e_6 \rangle$ ，其中 $\langle e_3, e_4 \rangle$ 为隧道。因隧道内 GPS 信号弱，可能导致所收集的轨迹数据为 $\langle e_1, e_2, e_5, e_6 \rangle$ ，大多数现有方法通常将上述“非异常”轨迹判定为异常，从而导致检测结果出现假阳性过高问题。

为解决上述问题，本文提出一种基于时空注意力机制的低假阳性异常轨迹检测模型（spatiotemporal attention mechanisms for low false positive anomalous trajectory detection, STAM-LFP）。该模型整合多尺度的时间与空间依赖性，以增强异常模式识别。时间特征提取模块可以捕捉轨迹时间的长序列依赖性，提取轨迹时间特征的周期性，以提高异常轨迹检测模型的鲁棒性。空间特征提取模块引入图注意力网络（GAT），自适应建模轨迹点之间的空间关联关系，增强模型对空间结构的感知能力，以提取更为精确的空间特征表示^[4]。异常判定模块基于高斯混合模型（GMM）对轨迹的潜在空间分布进行建模^[5]，评估轨迹在混合分量中的生成概率，从而识别异常轨迹。在两个真实数据集上的实验评估表明，STAM-LFP 模型在检测准确性和鲁棒性方面表现良好。




图 1 异常轨迹定义

1. 贵州民族大学 贵州贵阳 550025

[基金项目] 高维数据统计分析与智能计算重点实验室项目 (GZMUSYS [2021] 04)

1 模型描述

1.1 轨迹处理

轨迹由一系列按照时间顺序所记录的轨迹点而构成，每个轨迹点包含经纬度坐标 (x, y) 与时间戳 t ，表示为 $p_i = (x_i, y_i, t_i)$ ，其中 $i \in 1, 2, \dots, n$ ， n 为轨迹点总数。

如图 2 所示，原始轨迹 $\langle p_1, p_2, \dots, p_n \rangle$ 表示车辆在时间维度上的完整行驶过程。为结合地理空间信息，路网被建模为有向图 $G(V, E)$ ，其中节点 V 表示道路交叉口初始轨迹经过地图匹配映射到路网之后而得到的地图匹配轨迹 $T = \langle e_1, e_2, \dots, e_n \rangle$ ；边 E 表示连接节点的道路段。其中， $e_i \in E$ 为道路段。




图 2 地图匹配轨迹

1.2 时间特征提取

如图 3 所示，为增强模型在长程时间维度上的建模能力，提高异常轨迹检测的鲁棒性，本文在时间特征提取模块引入时序卷积网络（TCN）。该网络可以捕捉轨迹时序的长程序列依赖性，以提取轨迹时间特征的周期性。




图 3 STAM-LFP 模型

时间向量通过一维扩张卷积实现长时间依赖捕捉，多个一维空洞卷积层 z_t 堆叠与残差 X_t 进行连接，以构建轨迹的时间特征 y_t ：

$$y = \text{Activation}(\text{BN}(z_t)) + X_t \quad (1)$$

式中：BN 为批归一化（Batch Normalization），一维空洞卷积层 z_t 为：

$$z_t = \sum_{k=0}^{K-1} W_k \cdot x_{t-d \cdot k} + b \quad (2)$$

式中： K 为卷积核大小； d 为扩张率； W_k 为卷积核的第 k 个权重参数； $x_{t-d \cdot k}$ 为当前时间点 t 向前 $d \cdot k$ 个时间步的输入特征； b 为可学习参数。

经 B 层残差块后，输出即时间嵌入 $E^{(t)}$ ：

$$E^{(t)} = [y_1^{(B)}, y_2^{(B)}, \dots, y_n^{(B)}]^T \in \mathbb{R}^{n \times d_t} \quad (3)$$

式中： $y_i^{(B)}$ 为第 B 个残差块在时刻 i 的 d_t 维特征向量。

1.3 空间特征提取

如图 3 所示，在空间特征提取网络中引入 GAT，对于轨迹点 V_i 的初始特征向量 h_i ，自适应地建模轨迹点之间的空间关系。基于图注意力机制，每个节点的更新表示为：

$$h_i^{(l+1)} = \sigma \left(\sum_{j \in N(i)} \alpha_{ij}^{(l)} W^{(l)} h_j^{(l)} \right) \quad (4)$$

式中： $\alpha_{ij}^{(l)}$ 为注意力权重，以衡量邻居节点 j 对节点 i 的影响，GAT 可以通过学习注意力机制自适应分配轨迹点的权重； $W^{(l)}$ 为第 l 层可学习的线性变换矩阵； $N(i)$ 为节点 i 的邻接节点集合； σ 为 ReLU 非线性激活函数。

空间嵌入序列 $E^{(s)}$ 是和 L 层传播后，按照轨迹点排列将最后一层的输出作为各轨迹点的表征。

$$E^{(s)} = [h_1^{(L)}, h_2^{(L)}, \dots, h_n^{(L)}]^T \in \mathbb{R}^{n \times d_s} \quad (5)$$

式中： $h_i^{(L)}$ 为节点 i 在第 L 层的表征； d_s 为特征维度。

1.4 多尺度时空融合

多尺度时空融合模块实现轨迹长周期的时空特征多尺度融合，提取的时间特征 $E^{(t)}$ 和空间特征 $E^{(s)}$ 通过双向交叉注意力在时间和空间维度融合轨迹的时空表达，以拼接生成时空特征 $\tilde{E}$ 。

$\tilde{E}$ 基于 3 种不同尺度上的特征嵌入序列进行表达，分别提取轨迹点、轨迹段和整条轨迹的特征联系。对于正常轨迹，可以提取多尺度特征，以更好实现路线构建。对于异常轨迹，可以分析轨迹突变点的异常连贯性与整体的合理性，以更好地实现异常判断。

1.5 路线推断

在获得多尺度的轨迹嵌入之后，将每个尺度的嵌入序列分别输入循环神经网络（RNN）编码器，以得到对应的隐藏表示 $h_k^{(s)}$ 、 $h_k^{(t)}$ 。在此，使用加权融合得到多尺度时间和空间特征的融合结果 $r^{(s)}$ 和 $r^{(t)}$ ：

$$r^{(s)} = \sum_k \lambda_k^{(s)} h_k^{(s)} \quad (6)$$

$$r^{(t)} = \sum_k \lambda_k^{(t)} h_k^{(t)} \quad (7)$$

式中：权重 λ_k 为可学习参数。

最后，利用 GMM 对不同路线进行建模，生成时空特征的均值与方差向量，以获得潜在路线分布。

1.6 轨迹生成

生成器网络 p_γ 在训练阶段通过对数似然下界或等价的重构正则化目标进行联合优化。轨迹 T 的时空维度分别由条件分布 $p_\gamma(\mathbf{E}^{(t)}|\mathbf{r}^{(t)})$ 与 $p_\gamma(\mathbf{E}^{(s)}|\mathbf{r}^{(s)})$ 进行表示，每个轨迹点的生成过程为：

$$e_i \sim p_\gamma(e_i|e_{<i}, r) = p_\gamma(e_i|m_{i-1}) \quad (8)$$

式中： $m=r$ 为初始的隐状态。模型在训练过程中与 ELBO (evidence lower bound) 目标共同优化，使得解码器对正常轨迹模式赋予更高的生成概率。

1.7 异常评分

轨迹的异常性由生成概率与潜在路线匹配程度而确定。对于给定轨迹 T ，计算最有可能的路线类别 c ，利用生成器计算轨迹在该路线下的重建概率 $P(T|c)$ 。异常评分 $\text{Score}(T)$ 定义为：

$$\text{Score}(T) = 1 - \exp\left(\frac{1}{n} \log P(T|c)\right) \quad (9)$$

$$c = \text{argmax}_c p(c|r(s), r(t)) \quad (10)$$

$$P(T|c) = p_\gamma(T^{(s)}|\mu_c^{(s)}) \cdot p_\gamma(T^{(t)}|\mu_c^{(t)}) \quad (11)$$

式中： n 为轨迹点数量。

分值越高表示轨迹越偏离最可能的正常模式。在检测场景中，可以在轨迹尚未结束时基于前 m 个点计算部分得分，以实现早期异常识别。该生成式评分机制能够同时捕捉空间偏移、时间异常和模式突变，以保持动态环境下检测的稳定性。

2 实验与结果分析

为评估 STAM-LFP 模型的检测性能，基于两个真实数据集的实验结果表明，STAM-LFP 模型在检测准确性和鲁棒性方面表现良好，可以有效解决因非正常因素所导致的异常检测假阳性问题。

2.1 数据集

基于 Porto 和成都两个真实的出租车轨迹数据集开展实验，Porto 数据集包含 442 辆出租车轨迹数据（每 15 s 采集一次位置信息），成都数据集包含约 1.4 万辆出租车的 14 亿个轨迹点。

参照现有研究，将地理空间划分成 100 m×100 m 大小相同的网格，并过滤得到 498 550 条 Porto 数据、576 350 条成都数据。

实验结果显示，STAM-LFP 模型在两个数据集上的 PR-AUC 值（精确度 - 召回率曲线下面积）分别为 0.794、0.911、0.977 和 0.875、0.931、0.981，异常检测的精确性表现良好。

2.2 基准模型

iBAT^[6]：该方法基于隔离的异常检测，通过分析目标轨

迹与参考轨迹之间的离散程度，实现异常轨迹的识别。

SAE^[7]：该方法基于 RNN 实现的序列到序列映射，通过重建误差最小化以量化轨迹异常得分。

VSAE^[8]：该方法是 GM-VSAE 潜路线分布服从高斯分布。

TPRRO^[9]：该方法通过计算时间特征的转移图区分异常值，基于时间序列的热门路线实现异常识别。

GM-VSAE^[10]：该方法基于循环神经网络模型，通过轨迹分布实现异常检测。

DeepTEA^[11]：该方法结合动态交通条件和轨迹模式进行异常轨迹检测。

2.3 实验设置

基于 PyTorch 2.0.1 框架实现 STAM-LFP 模型，并在 NVIDIA RIX 4090 GPU 和 128 GB 内存的高性能服务器上予以实现。

2.4 实验结果与分析

为了评估模型有效性，在相同数据集下开展 STAM-LFP 模型与基准模型的对比实验。

同时，实验采用 PR-AUC (Precision-Recall Area Under Curve) 作为评价指标，以评估模型在异常轨迹和正常轨迹样本数量不平衡情况下的异常检测能力，实验结果如表 1 和表 2 所示。

表 1 基于 Porto 数据集的性能比较

Method	Porto		
	$a=0.1; d=3$	$a=0.2; d=2$	$a=0.3; d=2$
iBAT	0.199	0.304	0.331
SAE	0.331	0.654	0.893
VSAE	0.306	0.649	0.871
TPRRO	0.292	0.303	0.322
GM-VSAE	0.374	0.722	0.91
DeepTEA	0.408	0.736	0.921
STAM-LFP	0.794	0.911	0.977

表 2 基于 Chengdu 数据集的性能比较

Method	Chengdu		
	$a=0.1; d=3$	$a=0.2; d=2$	$a=0.3; d=2$
iBAT	0.409	0.504	0.585
SAE	0.836	0.913	0.918
VSAE	0.831	0.907	0.924
TPRRO	0.553	0.551	0.543
GM-VSAE	0.858	0.919	0.947
DeepTEA	0.875	0.931	0.935
STAM-LFP	0.942	0.965	0.981

参数 a 、 d 用于生成模拟异常轨迹。参数 a 为异常点连续占比以控制异常轨迹段长度；参数 d 为基于网格平移量设定空间偏移程度。

由表 1~2 可知，与 6 种基准模型相比，STAM-LFP 模型的 PR-AUC 分数均有所提高。STAM-LFP 模型在各参数下均表现良好，特别是在参数 a 较大的情况下，STAM-LFP 模型获得更高分数，表明模型检测准确性和鲁棒性均表现良好。

3 总结

为了解决现有异常轨迹检测方法未充分考虑设备采样异常、极端天气或高峰期正常变道等情形而导致假阳性率较高问题，本文提出一种基于时空注意力机制的低假阳性异常轨迹检测模型（STAM-LFP）。该模型通过捕捉轨迹的长序列依赖和周期性时间特征，自适应建模轨迹点之间的空间关系，提取轨迹的时空特征表达。同时，采用交叉注意力和多尺度融合时空特征。STAM-LFP 模型融合多尺度时间与空间依赖，大多数非正常情况下的轨迹异常判定不再仅依靠单一突发点的生成，而是分析轨迹突变点的异常连贯性与整体的合理性。两个真实数据集上的实验结果表明，STAM-LFP 模型在检测准确性和鲁棒性方面均表现良好，可以有效降低非正常因素而引起的异常检测假阳性问题。

参考文献：

- [1]MILLARD-BALL A, HAMPSHIRE R C, WEINBERGER R R. Map-matching poor-quality GPS data in urban environments: the pgMapMatch package[J]. Transportation planning and technology, 2019, 42(6): 539-553.
- [2]XIA D W, YANG N, JIANG S Y, et al. A parallel NAW-DBLSTM algorithm on spark for traffic flow forecasting[J]. Neural computing and applications, 2022, 34(2): 1557-1575.
- [3]XIA D W, JIANG S Y, LI Y S, et al. An ASM-CF model for anomalous trajectory detection with mobile trajectory big data[J].Physica A: statistical mechanics and its applications, 2023, 621: 128770.
- [4]NIKNAM G, MOLAEI S, ZARE H, et al. DyVGRNN: Dynamic mixture variational graph recurrent neural networks[J]. Neural networks, 2023, 165: 596-610.
- [5]FARNIA F, WANG W, DAS S, et al. GAT-GMM: generative adversarial training for gaussian mixture models[J].SIAM journal on mathematics of data science, 2023, 5(1): 122-146.
- [6]ZHANG D Q, LI N, ZHOU Z H, et al. iBAT: detecting anomalous taxi trajectories from GPS traces[C]// Proceedings of the 13th International Conference on Ubiquitous Computing. NewYork:ACM,2011: 99-108.
- [7]MALHOTRA P, RAMAKRISHNAN A, ANAND G, et al. LSTM-based encoder-decoder for multi-sensor anomaly detection[EB/OL].(2016-07-11)[2025-11-22].https://doi.org/10.48550/arXiv.1607.00148.
- [8]KINGMA D P, WELLING M. Auto-encoding variational bayes[EB/OL].(2022-12-10)[2025-11-22].https://doi.org/10.48550/arXiv.1312.6114.
- [9]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.
- [10]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.
- [11]HAN X L, CHENG R, MA C H, et al. DeepTEA: effective and efficient online time-dependent trajectory outlier detection[J]. Proceedings of the VLDB endowment, 2022, 15(7): 1493-1505.

【作者简介】

牟丽蓉（1999—），女，贵州安顺人，硕士研究生，研究方向：大数据分析、人工智能和深度学习。

夏大文（1982—），通信作者（email:dwxia@gzmu.edu.cn），男，湖南永州人，博士，博士研究生、硕士研究生导师，研究方向：大数据、人工智能、机器学习、数据挖掘。

刘龙（2001—），男，江苏徐州人，硕士研究生，研究方向：大数据分析、人工智能和深度学习。

（收稿日期：2025-10-21 修回日期：2025-12-10）