

DOI:10.3969/j.issn.1003-5060.2025.12.014

基于时空预测基础模型的高校学生日常行为预测研究

于长伟¹, 周立², 闫艾婧³

(1. 合肥工业大学 党政办公室, 安徽 合肥 230009; 2. 合肥工业大学 党委保卫部, 安徽 合肥 230009; 3. 杭州爱靠粒机器人有限公司, 浙江 杭州 311200)

摘要:分析大学生在校行为模式与活动规律是提升高校精细化管理、保障校园安全、促进学生心理健康的重要基础。随着以视频监控为核心的综合安防系统在高校的广泛部署,海量带有时空标记的学生轨迹数据为行为建模提供了新机遇。然而,如何从非结构化的视频流中提取高质量轨迹,并实现跨场景、长周期的行为预测与异常感知,仍是亟待解决的问题。针对该问题,文章提出一种面向校园场景的学生日常行为预测框架(campus behavior prediction framework, CBPF),该框架由结构化轨迹生成、时空语义嵌入、时空预测基础模型(spatio-temporal prediction foundation model, STPFM)和预测-异常联合优化 4 个模块组成,其核心 STPFM 基于时空注意力机制(spatio-temporal attention, STA),能够自适应建模学生在多区域间的迁移规律与时间周期性。以某高校 681 名学生在 30 d 内的 79 843 条轨迹为例,对比分析不同模型在行为趋势预测和异常感知的评价指标,结果表明,在同一框架下 STPFM 在行为趋势预测任务中的平均绝对误差(mean absolute error, MAE)比长短期记忆网络(long short-term memory, LSTM)等基线模型降低了 14.2%,异常检测的 F_1 值提升了 10.3%。研究结果验证了所提模型在捕捉长期行为规律与识别潜在风险方面的有效性。

关键词:学生行为分析;时空预测基础模型(STPFM);计算机视觉;异常检测

中图分类号:TP399

文献标志码:A

文章编号:1003-5060(2025)12-1671-07

Research on predicting university students' daily behaviors based on a spatio-temporal prediction foundation model

YU Changwei¹, ZHOU Li², YAN Aijing³

(1. Party and Administration Office, Hefei University of Technology, Hefei 230009, China; 2. Party Committee Security Department, Hefei University of Technology, Hefei 230009, China; 3. Hangzhou Aiforia Robot Co., Ltd., Hangzhou 311200, China)

Abstract: Analyzing on-campus behavioral patterns and activity routines of university students is essential for enhancing meticulous management in universities, ensuring campus security, and promoting student psychological well-being. The widespread deployment of integrated security systems based on video surveillance in universities has generated large-scale student trajectory data with spatio-temporal tags, offering new opportunities for behavioral modeling. However, extracting high-quality trajectories from unstructured video streams and achieving cross-scene, long-term behavior prediction and anomaly perception remain challenging. To address these issues, this paper proposes a campus behavior prediction framework (CBPF), which comprises four modules: structured trajectory generation, spatio-temporal semantic embedding, spatio-temporal prediction foundation model (STPFM), and joint prediction-anomaly optimization. The STPFM leverages a spatio-temporal attention (STA) mechanism to adaptively model students' transition patterns across multiple regions and their temporal periodicities. Experiments were conducted on a dataset of over 79 843 trajectories from 681 students at a

收稿日期:2025-07-18;修回日期:2025-11-28

基金项目:国家自然科学基金资助项目(62476077)

作者简介:于长伟(1979—),男,山东威海人,合肥工业大学讲师;

周立(1979—),男,江西南昌人,合肥工业大学工程师,通信作者,E-mail:zhouli@hfut.edu.cn.

university over 30 days to comparatively analyze the evaluation metrics of different models in behavioral trend prediction and anomaly perception. Results demonstrate that within the unified framework, STPFM reduces mean absolute error(MAE) by 14.2% in behavioral trend prediction compared to baseline models such as long short-term memory(LSTM), and improves the anomaly detection F_1 -score by 10.3%. These findings validate the effectiveness of the proposed model in capturing long-term behavioral regularities and identifying potential risks.

Key words: student behavior analysis; spatio-temporal prediction foundation model(STPFM); computer vision; anomaly detection

大学生校园行为分析,特别是校园数据的时空建模与行为规律挖掘,是当前计算机科学、行为心理学、教育学等交叉学科的研究热点。随着高校管理向“数据驱动”转型,学生行为的识别与预测逐步成为校园精细化管理的关键方向。大学生的校园日常行为数据具有高度的非线性和相关性,提取其活动特征、关联分析并挖掘其活动习惯的时空过程,能够实现行为的预测和对校园异常行为的推理,为判断学生的行为变化奠定基础^[1]。

在高校“平安校园”建设持续深化的背景下,以视频监控系统为核心的综合安防系统得到了广泛的应用,这促使高校积累了海量的轨迹数据。此类数据为学生行为分析提供了丰富的时空数据源,将这类带有鲜明时空印记的视频轨迹数据应用于学生行为研究,虽然突破了传统结构化数据的局限(如缺乏动态轨迹),但也面临“非结构化视频转结构化数据”“长时行为建模”等挑战性问题,因此具有一定的研究创新性与应用价值。近年来,相关研究主要从以下 2 个方面展开。

1) 聚焦教育数据挖掘,从学业成绩、课程考勤或传感器记录等结构化数据中提取时空特征,用于预测学业表现或出勤趋势。此类工作虽拓宽了时空特征的应用边界,且验证了其在行为关联分析中的潜力,但所用数据缺乏真实空间轨迹,难以反映学生在校园多场景中的动态行为模式;同时,在轨迹建模的完整性与长期依赖关系预测方面存在短板,无法支撑长时段行为规律挖掘^[2]。

2) 侧重视觉识别,通过时空卷积、注意力机制等技术提取学生短期行为特征,虽在动作识别精度上取得突破,但多局限于片段化分析(如单场景短时动作),难以刻画长时段行为的演化逻辑;尽管部分研究尝试结合视频序列与深度时空网络模拟学生活动^[3],初步证实了轨迹数据的预测价值,但仍未突破“单场景、短时程”的限制,缺乏对跨区域、跨时段行为的系统性建模能力。此外,少数融合多模态特征(学业+位置+时间)的研究^[4]

实现了行为与学业表现的关联分析,却未能解决视频级轨迹的自动提取与长时趋势推断问题。部分研究利用轨迹嵌入进行校园异常检测^[5],但仍未解决跨场景建模与长期预测的协同优化问题。

现有研究在视频轨迹数据驱动的学生日常行为分析中,存在以下 3 个方面的不足。

1) 长期规律捕捉不足。多数模型过度依赖短时间片段的图像识别结果,未充分考虑行为的时间连续性与周期性(如工作日、周末行为差异),导致难以有效挖掘学生长期行为模式。

2) 跨场景建模缺失。研究多局限于单区域(如教学楼、宿舍)场景,缺乏对跨区域(如宿舍—食堂—图书馆)、跨时段(如白天—夜间)行为的时空关联建模,无法反映学生在校园多场景中的行为逻辑。

3) 模型鲁棒性差。传统机器学习方法或浅层神经网络处理高维时空轨迹数据时,易受环境噪声(如光照变化)、场景动态变化(如人流高峰)干扰,模型的稳定性与泛化能力难以满足校园复杂场景的需求。

针对上述不足,本文提出一种基于时空预测大模型的高校学生日常行为预测框架(campus behavior prediction framework, CBPF)。本框架首先通过结构化轨迹生成模块,将原始视频流转化为高质量、可计算的时空轨迹序列,解决数据源头问题;其次,通过时空语义嵌入模块,将离散的位置与时间信息映射为富含语义的特征向量,解决行为特征表达问题;最后,通过 STPFM 及其预测-异常联合优化机制同步实现行为趋势预测与异常风险感知,解决核心建模与优化问题。该设计使模型能够从海量轨迹数据中学习学生行为的通用规律,具备强大的泛化能力,契合面向校园微场景构建专用化预测大模型的技术路径。

CBPF 框架的核心时空预测基础模型(spatio-temporal prediction foundation model, STPFM)具备复杂的深层架构和强大的通用表示能力,该模型

采纳了构建现代基础模型 (foundation model) 的先进范式,是基于多层 Transformer 架构构建的编码器-解码器模型,通过空间与时间双维度的多头注意力机制,实现对校园跨区域、长时序行为依赖关系的全局建模。

1 高校学生日常行为预测框架

为系统解决校园视频轨迹数据驱动的行为预测问题,本文提出一个端到端的高校学生日常行为预测框架 CBPF。该框架由结构化轨迹生成、时空特征嵌入、STPFM 和预测-异常联合优化机制 4 个模块组成。CBPF 的整体框架如图 1 所示。

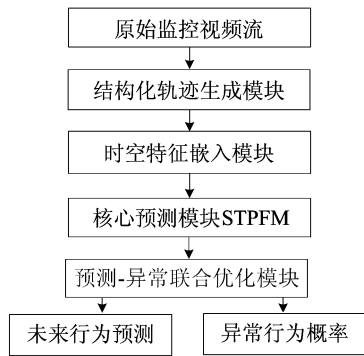


图 1 CBPF 框架

鉴于 STPFM 在交通、气象等领域的成功应用^[6],本文将其引入校园行为建模场景。STPFM 作为框架的核心模块,负责捕捉跨区域、跨时段的行为依赖关系,并支持预测与异常检测的联合推理。

1.1 结构化轨迹生成模块

利用结构化轨迹生成模块突破非结构化视频数据的使用瓶颈,为长时序建模提供可靠的数据基础。首先将视频数据通过预处理来解决噪声、畸变等问题;然后通过人脸、人体检测与身份识别算法从视频中提取行人的时空轨迹;最后基于跨摄像头轨迹聚类形成结构化的轨迹档案。

研究表明,充分利用时序上下文信息的视频识别方法,相较于依赖单张图片的方法,身份比对的准确率可获得大幅提升。为确保获取高质量的轨迹数据,该模块采用基于视频人体识别的时序信息整合多帧特征,构建人体动态索引,维持身份连续性。其基本原理为利用视频序列中连续的多帧信息,构建一个在时间维度上动态演进的、更丰富可靠的人体特征表示。

从原始监控视频出发,通过多摄像头融合与轨迹聚类生成结构化语义轨迹。监控视频经人体检测抓拍与身份匹配后,得到“身份标识-地点-时间”的原始轨迹数据。对于第 i 个学生,每个轨迹点在时间 t 的位置可表示为:

$$\mathbf{x}_i(t) = (l_i(t), p_i(t)) \quad (1)$$

其中: $l_i(t)$ 为地理位置; $p_i(t)$ 为时间戳,表示该次抓拍发生的精确时刻。

轨迹序列 $X_i = \{\mathbf{x}_i(1), \dots, \mathbf{x}_i(T)\}$ 经过卡尔曼滤波去噪和平滑以修正遮挡误差,再通过区域映射规则函数 $f_r(\cdot)$ 将位置映射到语义区域标签(如宿舍、食堂、教学楼等功能区),得到语义化轨迹序列 $s_i(t) = f_r(\mathbf{x}_i(t))$,最终输出由离散区域标签组成的时序数组。

1.2 时空特征嵌入模块

为捕捉学生行为的空间依赖与时间周期特征,引入双层嵌入表示。时空特征嵌入模块将区域标签和时间周期编码用统一向量表示。将校园场景的“时间周期节律”与“空间语义属性”转化为维度一致、语义可协同的向量表示,使“时空耦合的行为事件”能在同一数学空间内建模、计算与关联,为后续跨场景行为分析提供高质量特征基础。

学生行为的时间特征具有多尺度周期性,且不同周期承载不同语义。时间维度采用周期编码,周期编码的本质是将校园时间从“数字”转化为“语义”,通过数学公式将“8点”“12点”“周一”“周末”等时间概念转化为模型可理解的向量特征。针对每个核心周期,先计算时间在周期内的“相对位置”,再通过正弦、余弦函数编码为向量,保留周期内的语义差异(如早8点/午12点)。

$$\mathbf{t}(t) = (\sin(2\pi t/P), \cos(2\pi t/P)) \quad (2)$$

其中: t 为当前时刻的数值表示(如小时或总小时数); P 为时间周期(如 $P=24$ 表示一天, $P=168$ 表示一周);输出 $\mathbf{t}(t)$ 为二维时间编码向量,几何意义为单位圆上的角度位置,能自然表达周期性。

空间语义嵌入是将校园空间从“物理坐标空间”映射到“语义向量空间”,同时保留空间拓扑关联(如教室离图书馆近,向量相似度高)。空间维度通过可学习嵌入矩阵 \mathbf{E}_s 表示语义区域特征。首先对校园空间进行语义分类,设核心语义区域集合为 $S = \{s_1, s_2, s_3, s_4, s_5, s_6\}$ ($s_1 \sim s_6$ 分别为教室、宿舍、食堂、图书馆、操场、实验室);然后对矩阵进行结构设计、进行时空融合,矩阵行维度为 N ,对应语义区域类别数,列维度与时间嵌入维度一致。最终输入向量为:

$$\mathbf{z}_i(t) = \mathbf{W}_1[\mathbf{E}_s(s_i(t)) \quad \mathbf{t}(t)]^T + \mathbf{b}_1 \quad (3)$$

其中: \mathbf{W}_1 为可学习权重矩阵,用于融合空间与时间信息; \mathbf{b}_1 为偏置项; $\mathbf{E}_s(s_i(t))$ 为区域 $s_i(t)$ 的语义嵌入向量; 输出 $\mathbf{z}_i(t)$ 为最终输入到 STPFM 模型的统一时空嵌入向量。该表示在保持空间语义一致性的同时,编码了行为的时间节奏。

1.3 时空预测核心模块

通过时空注意力 (spatio-temporal attention, STA) 模块赋予框架对校园多区域、多时段行为模式的动态感知与关联分析能力,实现对跨场景行为的系统性建模。

在 CBPF 框架中, STPFM 作为核心预测组件,旨在从结构化的行为轨迹中自适应地建立学生在空间迁移与时间演化 2 个维度上的复杂依赖关系。其设计目标是突破传统时序模型对局部模式或固定周期的依赖,实现对跨区域、长周期行为规律的动态捕捉。STPFM 基于注意力机制对历史行为序列进行动态建模,将原始的轨迹序列与多种时间上下文特征进行融合,这些特征包括位置以及关键的时间周期信息,如一天中的时刻、是否为工作日或周末等,可显式地提供模型学习行为周期规律必需的语义信息,使模型不仅能够关注相邻时间点的行为(保持连续性),还能直接捕捉长程的周期性模式。例如,模型可以据此发现“本周一上午 9 点”与“上周一上午 9 点”的关联,并区分“周六晚上”与“工作日晚上”的不同行为模式。

STPFM 采用 STA 机制,以滑动窗口内的历史嵌入序列 $\{\mathbf{z}_i(t-k+1), \dots, \mathbf{z}_i(t)\}$ 为输入,通过查询-键-值交互计算各时间步的重要性权重,即

$$\alpha_{t,j} = \frac{\exp\{[\mathbf{W}_Q \mathbf{z}_i(t)]^T [\mathbf{W}_K \mathbf{z}_i(j)] / \sqrt{d}\}}{\sum_{j'=1}^k \exp\{[\mathbf{W}_Q \mathbf{z}_i(t)]^T [\mathbf{W}_K \mathbf{z}_i(j')] / \sqrt{d}\}} \quad (4)$$

其中: $\mathbf{W}_Q, \mathbf{W}_K \in \mathbf{R}^{d \times d}$ 分别为查询和键矩阵; d 为嵌入维度; $\alpha_{t,j}$ 为时间步 j 对当前时刻 t 的贡献权重。基于上述权重,模型聚合上下文信息,生成当前状态的上下文表示为:

$$\mathbf{h}_i(t) = \sum_{j=1}^k \alpha_{t,j} (\mathbf{W}_V \mathbf{z}_i(j)) \quad (5)$$

其中, $\mathbf{W}_V \in \mathbf{R}^{d \times d}$ 为值矩阵,预测网络以 $\mathbf{h}_i(t)$ 为输入,输出下一时刻的行为状态 $\hat{\mathbf{z}}_i(t+1)$ 。

为分析上述时空建模能力, STPFM 采用堆叠式 Transformer 编码器架构,共包含 4 层时空注意力块 (spatio-temporal attention blocks)。每

层包含一个多头时空注意力子层(头数为 8)和一个前馈神经网络 (feedforward neural network, FFN), FFN 隐藏层维度为 512。模型输入嵌入维度 d 为 128,与空间嵌入矩阵 \mathbf{E}_s 及时间编码向量对齐。整个 STPFM 模块的可训练参数量约为 3.2×10^9 ,其中注意力机制相关参数占 68%,其余为 FFN 层和投影层参数。

在单张 NVIDIA RTX 3090 GPU 上,使用批量大小 64 进行训练时,平均每轮 (epoch) 耗时约 8.7 min; 推理阶段处理一条长度为 24 的序列仅需约 4.2 ms。模型单次前向传播的计算复杂度约为 1.8 GFLOPS (Giga Floating-point Operations),显著低于同等性能的 ConvLSTM (约 3.5 GFLOPS) 和深层 Transformer-TS 变体 (>4.0 GFLOPS)。该设计在保证建模能力的同时,兼顾了校园行为序列长度(典型滑动窗口长度 k 为 24~48)下的计算效率。

相较于长短期记忆网络 (long short-term memory, LSTM)、门控循环单元 (gated recurrent unit, GRU) 或 ConvLSTM 等传统时序模型, STPFM 显式融合区域语义嵌入与周期性时间编码,保留行为的空间上下文与时间节奏;可通过全局注意力捕捉非局部时空依赖,而非仅依赖局部卷积或循环结构,为后续联合优化提供可微分的预测路径^[7]。

1.4 联合优化模块

为进一步提升模型对异常行为的敏感性,本文在预测任务的基础上引入异常检测分支,构建预测与异常识别的协同学习机制。该机制通过共享主干特征表示,使模型在拟合正常行为模式的同时,能够自动识别显著偏离该模式的潜在风险事件。

通过预测-异常联合优化模块将长时预测的稳定性与异常检测的灵敏性相结合,提升了模型在真实复杂场景下的综合性能与鲁棒性。通过联合损失函数同步优化预测精度和异常敏感性,实现对个体行为趋势的前瞻性推断。

为实现预测与异常检测的协同学习,构建联合损失函数:

$$L = \lambda_1 L_{\text{pred}} + \lambda_2 L_{\text{anom}} \quad (6)$$

其中: λ_1, λ_2 为权重系数,用于驱动模型学习主流行为规律; 预测损失 L_{pred} 采用平均绝对误差 (mean absolute error, MAE) 表征,用于最小化预测偏差; 异常检测损失 L_{anom} 基于重构误差(即预测残差),当预测残差超过预设阈值 δ 时,认为该

行为偏离正常模式,被判定为异常。

联合优化可在学习主流行为规律的同时增强模型的敏感性^[8],避免单一任务训练导致的过拟合或漏检问题。

2 实验与结果

本研究所有实验均在 NVIDIA A100 GPU 上完成,使用 PyTorch 2.3 实现。模型采用滑动窗口训练,优化器使用 Adam,学习率设为 10^{-4} 。训练集数量与验证集、测试集数量按 7:3 划分,通过早停机制防止过拟合。在推理阶段,模型输入学生最近的轨迹片段,输出未来多步的语义区域序列及其对应的异常概率,实现对个体与群体行为的实时预测。

2.1 数据集与实验设置

实验数据来源于某高校宿舍与教学区的 45 个监控节点,采集周期 30 d,涉及 681 名学生的 79 843 条轨迹,具体数据统计信息见表 1 所列。

表 1 681 名学生的数据统计

| 区域类型 | 摄像头数量 | 轨迹条数 | 平均时长/min | 占比/% |
|------|-------|--------|----------|-------|
| 宿舍区 | 18 | 32 486 | 45.3 | 40.6 |
| 教学楼 | 12 | 24 130 | 38.7 | 30.1 |
| 食堂 | 8 | 14 275 | 22.4 | 17.8 |
| 公共区域 | 7 | 8 952 | 27.9 | 11.5 |
| 总计 | 45 | 79 843 | | 100.0 |

轨迹经过身份关联、插值补全与匿名化处理后划分为训练集(70%)、验证集(15%)、测试集(15%)。

为全面评估框架性能,本文以 MAE、均方根误差(root mean square error, RMSE)和 Recall@5 为评价指标评估轨迹预测任务的性能。MAE 和 RMSE 衡量模型预测未来语义区域序列的绝对误差和总体偏差;Recall@5 则评估真实的下一个活动区域出现在模型预测的前 5 个最可能区域中的概率,从排序角度衡量预测准确性。以精确率(precision)、召回率(recall)和 F_1 值为评价指标,综合衡量模型识别行为异常模式的性能。

2.2 对比模型与参数

本文所提出的 STPFM 是 CBPF 框架的重要组成部分,为验证其在本框架下的有效性,选取了 4 类在时序预测领域具有代表性的基线模型进行对比。这些模型涵盖了从经典递归网络到现代注意力机制的不同技术路线,旨在从不同维度检验 STPFM 模型的性能优势。所选基线模型及其选

择依据如下:

1) LSTM 作为处理序列数据的经典模型,能够捕捉时间维度的长期依赖关系。将其作为基线模型,可以验证更复杂的时空模型相对于基本时间序列模型的性能提升程度。

2) GRU-Attn 模型在 GRU 的基础上引入了时间注意力机制(temporal attention)。选择此模型旨在验证,与仅使用时间注意力相比,本文提出的时空双维度注意力机制是否具有优势。

3) ConvLSTM 将卷积操作融入 LSTM 内部,能够显式地同时捕捉时空特征。将其作为对比,可以评估 STPFM 所采用的基于注意力的时空建模方式与基于卷积的时空建模方式在校园行为预测任务上的性能差异。

4) Transformer-TS 模型是 Transformer 架构在时间序列预测领域的典型应用^[7],其核心的自注意力机制擅长捕捉序列内部的全局依赖关系。选择此基线模型是为了检验 STPFM 在应对长序列依赖和复杂模式识别方面,是否比标准的 Transformer 架构更具竞争力。

本文提出的 STPFM 与上述基线模型的关键区别在于,STPFM 系统地引入了区域语义嵌入模块与预测-异常联合优化模块,旨在更精细地建模校园场景的时空语义并提升模型的泛化能力。

为保证对比的公平性,所有模型均采用 2.1 节相同的轨迹序列作为输入,并使用相同的输入、输出格式。输入历史行为序列的窗口长度 $k=24$ (以小时为单位,对应一天的行为模式),预测未来时间步长 $L=6$ h 内的语义区域序列。模型优化器均采用 Adam,学习率设置为 10^{-4} ,批量大小(Batch Size)为 64。

2.3 预测性能对比

不同模型的预测结果见表 2 所列。

表 2 不同模型的预测性能比较

| 模型 | MAE | RMSE | Recall@5 |
|----------------|-------|-------|----------|
| LSTM | 0.247 | 0.314 | 0.781 |
| GRU-Attn | 0.231 | 0.297 | 0.802 |
| ConvLSTM | 0.219 | 0.281 | 0.824 |
| Transformer-TS | 0.218 | 0.275 | 0.838 |
| STPFM | 0.212 | 0.263 | 0.861 |

从表 2 可以看出,STPFM 在 MAE 和 RMSE 上均优于其他模型,其 MAE 比 LSTM 降低了 14.2%,说明引入时空注意力和语义嵌入能有效

提升趋势拟合能力。

STPFM 模型预测的行为分布与真实行为分布如图 2 所示。从图 2 可以看出,STPFM 能较准确地捕捉早晚高峰(7:00—9:00 与 18:00—21:00)的周期性变化,说明本文模型在时间依赖建模方面表现稳定。




图 2 STPFM 的预测结果与真实行为分布对比

2.4 异常检测与性能分析

为进一步验证模型在真实场景下的异常检测能力,本文绘制了基于主成分分析(principal components analysis, PCA)的时空轨迹点云分布图,如图 3 所示。




图 3 时空轨迹数据分布点云图

图 3 中:灰色点为正常轨迹样本;红色标记点为 STPFM 识别出的异常样本,包括夜间异常出入、非规律聚集等典型违规行为;蓝色椭圆区域为正常行为的 95% 置信区间,绝大多数常规活动集中于该区域内。异常检测性能对比见表 3 所列。

从图 3 可以看出,STPFM 成功捕获了多个远离主簇的异常点,且与人工标注高度一致,相比 ConvLSTM 等基线模型,STPFM 显示出更强的

边界敏感性和更低的误报率,这也解释了其在 F_1 值和召回率上的显著优势(表 3)。此外,本文模型不仅能够识别当前异常,还可通过时间序列预测潜在风险路径,从而实现从“事后识别”向“事前预警”的演进,展现出良好的实用价值。

表 3 异常检测性能比较

| 模型 | 精确率 | 召回率 | F_1 值 |
|----------------|-------|-------|---------|
| LSTM | 0.781 | 0.726 | 0.752 |
| GRU-Attn | 0.802 | 0.743 | 0.771 |
| ConvLSTM | 0.824 | 0.768 | 0.795 |
| Transformer-TS | 0.839 | 0.802 | 0.821 |
| STPFM | 0.853 | 0.848 | 0.850 |

2.5 结果讨论

本文研究结果表明,STPFM 在学生行为趋势预测和异常检测 2 项任务中均表现出优越的综合性能。其优势主要体现在以下 3 个方面:

1) 结构化轨迹生成模块有效整合了多摄像头视频流,消除了原始数据的噪声干扰,为模型提供了高质量、连续性的输入特征。

2) 时空注意力机制能够捕捉学生跨区域、跨时间的行为依赖关系,显著提升了对周期性活动和空间迁移模式的建模能力。

3) 联合优化策略在预测精度与异常检测灵敏度之间实现了平衡,使模型在保持整体稳定性的同时,具备了识别突发或异常行为的能力。

从应用层面来看,模型输出的预测结果和异常分布具有直接的管理价值。例如,通过对行为热度的短期预测,可辅助校园在高峰时段进行人流疏导与场地调度;夜间异常检测结果可用于宿舍安全监控与访问控制优化;而长期趋势分析则能为能耗分配与空间资源管理提供决策支持。总体而言,STPFM 不仅在算法层面上突破了现有时空序列建模的局限,更在实践中展现出面向智慧校园建设的可扩展潜力与前瞻性。

3 结 论

本文围绕高校学生日常行为分析中的关键问题,提出了一种面向校园场景的学生日常行为预测框架 CBPF。该框架通过结构化轨迹生成、时空语义嵌入、时空预测基础模型 STPFM 及预测-异常联合优化四大模块,系统性地实现了从原始视频数据到行为规律挖掘的全流程建模。

本文基于某高校 30 d 实际数据开展研究,结果表明,在同一框架下,模型在行为趋势预测与异

常感知 2 个方面均优于传统模型。其中,基于时空注意力机制的 STPFM 能够有效建模学生的跨区域迁移与时间周期性,在预测任务中能显著降低平均绝对误差,并在异常检测中提升 F_1 值,验证了其在捕捉长期行为规律与识别潜在风险方面的综合能力。

本研究为基于视频轨迹的学生行为分析提供了一套完整、可行的技术路径。未来的研究将进一步优化模型的泛化能力与实时性,探索与多模态感知数据(如 WiFi 信号、门禁记录、校园卡消费系统、教务学业数据等)的联合建模,以构建更完整、更完善的学生行为预测系统。

[参 考 文 献]

- [1] 喻宏伟,周东波,徐雯慧,等. 基于多片段语义时空图卷积网络的大学校园日常行为预测[J]. 清华大学学报(自然科学版),2022,62(1):105-115.
- [2] LAI G, CHANG W C, YANG Y, et al. Modeling long-and short-term temporal patterns with deep neural networks [C]//The 41st International ACM SIGIR Conference on Research and Development in Information Retrieval. Ann Arbor, MI: ACM, 2018: 95-104.
- [3] 江怡. 基于卷积神经网络的视频监控个体异常行为检测方法研究[D]. 西安:西安石油大学,2025.
- [4] 申民哲. 基于数据挖掘的学生画像与学业预警方法研究[D]. 郑州:郑州轻工业大学,2022.
- [5] 张晓东. 基于时空轨迹的学生异常情绪预警系统的设计与实现[D]. 西安:西安电子科技大学,2024.
- [6] 徐邦琪,臧钰歆,朱志伟,等. 时空投影模型(STPM)的次季节至季节(S2S)预测应用进展[J]. 大气科学学报,2020,43(1):212-224.
- [7] 姚杰,操星,平红,等. STMS:一种基于时空注意力机制的行人轨迹预测模型[J/OL]. 云南民族大学学报(自然科学版),2024;1-11[2024-07-10]. <https://link.cnki.net/urlid/53.1192.N.20240708.1101.002>.
- [8] 杨锐. 基于未来帧预测的视频异常检测方法研究[D]. 南京:南京邮电大学,2023.
- [9] PALMISANO N J, ROSARIO N, WYSOCKI M, et al. The recycling endosome protein RAB-10 promotes autophagic flux and localization of the transmembrane protein ATG-9 [J]. *Autophagy*, 2017, 13(10):1742-1753.
- [10] CHANG J T, KUMSTA C, HELLMAN A B, et al. Spatio-temporal regulation of autophagy during *Caenorhabditis elegans* aging[J]. *eLife*, 2017, 6: e18459.
- [11] BUTLER V J, GAO F, CORRALES C, et al. Age-and stress-associated *C. elegans* granulins impair lysosomal function and induce a compensatory HLH-30/TFEB transcriptional response[J]. *PLoS Genet*, 2019, 15(8): e1008295.
- [12] XU M, LIU Y, ZHAO L, et al. The lysosomal cathepsin protease CPL-1 plays a leading role in phagosomal degradation of apoptotic cells in *Caenorhabditis elegans* [J]. *Mol Biol Cell*, 2014, 25(13):2071-2083.
- [13] FUNKELSTEIN L, BEINFELD M, MNOKADEHL A, et al. Unique biological function of cathepsin L in secretory vesicles for biosynthesis of neuropeptides[J]. *Neuropeptides*, 2010, 44(6):457-466.
- [14] YANG M, ZHANG Y, PAN J, et al. Cathepsin L activity controls adipogenesis and glucose tolerance[J]. *Nat Cell Biol*, 2007, 9(8):970-977.
- [15] LIN Y, BAO B, YIN H, et al. Peripheral cathepsin L inhibition induces fat loss in *C. elegans* and mice through promoting central serotonin synthesis[J]. *BMC Biol*, 2019, 17(1):93.
- [16] 陆芮,刘健,林燕. 溶酶体活性影响秀丽隐杆线虫脂肪沉积的作用[J]. 合肥工业大学学报(自然科学版), 2023, 46(4):541-546.
- [17] BRITTON C, MURRAY L. Cathepsin L protease (CPL-1) is essential for yolk processing during embryogenesis in *Caenorhabditis elegans* [J]. *J Cell Sci*, 2004, 117(Pt 21): 5133-5143.
- [18] 聂先奇,鲍斌. 构建 *eat-2/cpl-1&Plgg-1gfp::lgg-1* 双突变体线虫[J]. 合肥工业大学学报(自然科学版), 2019, 42(12):1699-1703.

(责任编辑 闫杏丽)

(上接第 1656 页)

- [9] PALMISANO N J, ROSARIO N, WYSOCKI M, et al. The recycling endosome protein RAB-10 promotes autophagic flux and localization of the transmembrane protein ATG-9 [J]. *Autophagy*, 2017, 13(10):1742-1753.
- [10] CHANG J T, KUMSTA C, HELLMAN A B, et al. Spatio-temporal regulation of autophagy during *Caenorhabditis elegans* aging[J]. *eLife*, 2017, 6: e18459.
- [11] BUTLER V J, GAO F, CORRALES C, et al. Age-and stress-associated *C. elegans* granulins impair lysosomal function and induce a compensatory HLH-30/TFEB transcriptional response[J]. *PLoS Genet*, 2019, 15(8): e1008295.
- [12] XU M, LIU Y, ZHAO L, et al. The lysosomal cathepsin protease CPL-1 plays a leading role in phagosomal degradation of apoptotic cells in *Caenorhabditis elegans* [J]. *Mol Biol Cell*, 2014, 25(13):2071-2083.
- [13] FUNKELSTEIN L, BEINFELD M, MNOKADEHL A, et al. Unique biological function of cathepsin L in secretory vesicles for biosynthesis of neuropeptides[J]. *Neuropeptides*, 2010, 44(6):457-466.
- [14] YANG M, ZHANG Y, PAN J, et al. Cathepsin L activity controls adipogenesis and glucose tolerance[J]. *Nat Cell Biol*, 2007, 9(8):970-977.
- [15] LIN Y, BAO B, YIN H, et al. Peripheral cathepsin L inhibition induces fat loss in *C. elegans* and mice through promoting central serotonin synthesis[J]. *BMC Biol*, 2019, 17(1):93.
- [16] 陆芮,刘健,林燕. 溶酶体活性影响秀丽隐杆线虫脂肪沉积的作用[J]. 合肥工业大学学报(自然科学版), 2023, 46(4):541-546.
- [17] BRITTON C, MURRAY L. Cathepsin L protease (CPL-1) is essential for yolk processing during embryogenesis in *Caenorhabditis elegans* [J]. *J Cell Sci*, 2004, 117(Pt 21): 5133-5143.
- [18] 聂先奇,鲍斌. 构建 *eat-2/cpl-1&Plgg-1gfp::lgg-1* 双突变体线虫[J]. 合肥工业大学学报(自然科学版), 2019, 42(12):1699-1703.

(责任编辑 闫杏丽)