

武汉大学学报(信息科学版)

Geomatics and Information Science of Wuhan University

ISSN 1671-8860, CN 42-1676/TN

《武汉大学学报(信息科学版)》网络首发论文

题目: 融合区域空间相似性特征与事件时空特征的犯罪预测模型
作者: 林逸航, 郑坤, 夏书豪, 齐力, 戴杰, 蔡焯, 朱清刚
DOI: 10.13203/j.whugis20230395
收稿日期: 2024-05-30
网络首发日期: 2024-06-21
引用格式: 林逸航, 郑坤, 夏书豪, 齐力, 戴杰, 蔡焯, 朱清刚. 融合区域空间相似性特征与事件时空特征的犯罪预测模型[J/OL]. 武汉大学学报(信息科学版). <https://doi.org/10.13203/j.whugis20230395>



网络首发: 在编辑部工作流程中, 稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定, 且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式(包括网络呈现版式)排版后的稿件, 可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定; 学术研究成果具有创新性、科学性和先进性, 符合编辑部对刊文的录用要求, 不存在学术不端行为及其他侵权行为; 稿件内容应基本符合国家有关书刊编辑、出版的技术标准, 正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性, 录用定稿一经发布, 不得修改论文题目、作者、机构名称和学术内容, 只可基于编辑规范进行少量文字的修改。

出版确认: 纸质期刊编辑部通过与《中国学术期刊(光盘版)》电子杂志社有限公司签约, 在《中国学术期刊(网络版)》出版传播平台上创办与纸质期刊内容一致的网络版, 以单篇或整期出版形式, 在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊(网络版)》是国家新闻出版广电总局批准的网络连续型出版物(ISSN 2096-4188, CN 11-6037/Z), 所以签约期刊的网络版上网络首发论文视为正式出版。

Doi: 10.13203/j.whugis20230395

引用格式：

林逸航, 郑坤, 夏书豪, 等. 融合区域空间相似性特征与事件时空特征的犯罪预测模型[J]. 武汉大学学报(信息科学版), 2024, Doi:10.13203/j.whugis20230395. (LIN Yihang, ZHENG Kun, XIA Shuhao, et al. A Crime Prediction Model Incorporating Regional Spatial Similarity Characteristics and Spatio Temporal Characteristics of Events[J] *Geomatics and Information Science of Wuhan University*, 2024, Doi:10.13203/j.whugis20230395.)

融合区域空间相似性特征与事件时空特征的犯罪预测模型

林逸航¹, 郑坤¹, 夏书豪¹, 齐力², 戴杰², 蔡煊², 朱清刚³

1 中国地质大学(武汉)地理与信息工程学院, 湖北 武汉, 430074

2 公安部第三研究所, 上海, 200031

3 新疆生产建设兵团第十四师昆玉市公安局, 新疆 昆玉, 848116

摘要：犯罪预测可预测区域内犯罪活动概率和趋势, 优化执法资源分配、降低犯罪率并提高社会安全。由于犯罪事件存在空间相似性、周期性、空间异质性等变化规律, 现有的犯罪预测方法较少考虑犯罪区域空间相似性特征, 并在面对时空数据的长时空依赖问题上具有较强的局限性, 导致预测效果有限。针对此问题, 论文设计了一种融合区域空间相似性特征与事件时空特征的犯罪事件时空分布预测模型。该模型分为空间相似性特征捕捉和预测两部分, 分别由区域空间相似性特征捕捉网络与基于特征融合编码的犯罪预测网络组成。模型利用空间通道注意力机制, 以多图卷积网络为基础, 设计了一个空间通道注意力多图卷积网络, 实现空间相似性特征的捕捉。在此基础上, 通过可嵌入线性序列表示犯罪事件信息, 再融合捕捉到的犯罪区域空间相似性特征, 建立了具有时空犯罪特征表示编码; 为增强预测模型的长时空依赖性, 设计了一种基于多头时空注意力机制的 Transformer 预测网络。为验证提出模型的有效性, 论文通过芝加哥及洛杉矶地区不同时期的犯罪事件数据进行了实验, 并与 STGCN、ST-ResNet 和 ConvLSTM 方法进行了对比。实验结果表明, 在不同区域, 所提出的模型不仅在大尺度上的表现优于其他模型并且在小尺度上表现出更强的准确性和稳定性。

关键词：犯罪预测; 相关性特征; Transformer; 注意力机制

A Crime Prediction Model Incorporating Regional Spatial Similarity Characteristics and Spatio Temporal Characteristics of Events

LIN Yihang¹, ZHENG Kun¹, XIA Shuhao¹, QI Li², DAI Jie², CAI Xuan², ZHU Qinggang³

1 School of Geography and Information Engineering, China University of Geosciences, Wuhan 430074, China.

2 The Third Research Institute of the Ministry of Public Security, Shanghai 200031, China

3 Kunyu City Public Security Bureau, 14th Division, Xinjiang Production and Construction Corps, Kunyu 848116, China.

Abstract: Objective: Crime forecasting can predict the probability and trend of criminal activities in a region, optimize the allocation of law enforcement resources, reduce crime rates and improve social security. Because of the changing laws of spatial similarity, periodicity and spatial heterogeneity of crime events, existing crime prediction methods give less consideration to the characteristics of spatial similarity in crime regions and have strong limitations in facing the problem of long-term spatial and temporal dependence on spatial and

收稿日期: 2024-05-30

基金项目: 国家重点研发计划(2018YFB1004600); 国家自然科学基金(U1911205)。

第一作者: 林逸航, 硕士生, 主要从事犯罪预测研究工作。353819445@cug.edu.cn

通讯作者: 郑坤, 博士, 副教授。ZhengK@cug.edu.cn

temporal data, resulting in limited prediction effects. **Methods:** The model is divided into two parts: spatial similarity feature capture and prediction, which are composed of a regional spatial similarity feature capture network and a feature fusion coding-based crime prediction network, respectively. The model utilizes the spatial channel attention mechanism and designs a spatial channel attention multi-graph convolutional network based on a multi-graph convolutional network to achieve spatial similarity feature capture. On this basis, the crime event information is represented by embeddable linear sequences, and then the captured spatial similarity features of the crime region are fused to establish a spatio-temporal crime feature representation coding; in order to enhance the long spatio-temporal dependence of the prediction model, a Transformer prediction network based on the multi-head spatio-temporal attention mechanism is designed. To validate the effectiveness of the proposed model, the paper conducts experiments with crime event data from different periods in Chicago and Los Angeles areas and compares it with STGCN, ST-ResNet and ConvLSTM methods. **Results:** The experimental results show that the proposed model not only outperforms other models on large scales but also exhibits stronger accuracy and stability on small scales in different regions. **Conclusions:** The methodology improves the accuracy of crime prediction.

Key Words: Crime prediction; Correlation characteristics; Transformer; Attention mechanism

犯罪对社会稳定、经济发展和公众安全构成了巨大威胁^[1-2]。而犯罪预测能对未来犯罪的发生概率和可能的犯罪区域进行预测, 以提供警务人员更为准确和有效的犯罪预防和打击策略^[3-4]。因此, 提高犯罪预测准确度是至关重要的^[5]。

由于不同时间、空间以及犯罪模式复杂多变, 实现高准确度的犯罪预测具有极大挑战性^[5]。传统犯罪预测方法包括回归分析法^[6-9]、时间序列方法^[10-14]等, 其通过对犯罪相关的因素进行分析, 构建回归方程或时间序列模型预测未来犯罪的可能性^[15]。该方法在微观尺度下效果较差, 往往只能提供较为模糊的信息和较大范围的预测结果。近年, 深度学习逐渐成为犯罪预测的重要方向, 其可以自动从犯罪数据中学习到时空特征和犯罪模式等^[16]。长短期记忆网络 (Long Short-Term Memory, LSTM) 和循环神经网络 (Recurrent Neural Network, RNN)^[17-19]通过对犯罪时间序列存储长期信息构建预测模型。而后, 出现基于 RNN、LSTM 融合时空信息、外部因素的犯罪预测模型^[20-22]。卷积长短期记忆神经网络 (Convolutional Long Short-Term Memory, ConvLSTM)^[23]通过捕捉时空序列中时间维度上各节点的相互依赖以及空间维度上的局部关联性, 预测犯罪的时空分布情况。时空残差网络 (Spatio-Temporal Residual Networks, ST-ResNet)^[24-25]在时间和空间维度上分别应用 ResNet 和 CNN, 捕捉犯罪时空数据的非线性关系。时空元路径引导的可解释性犯罪预测框架^[26]通过将区域与其相关因素结合构建每时间段的异构图, 再利用 LSTM 模型捕获时空依赖性及与外部因素的相关性。LSTM 与时空图卷积网络 (Spatio-Temporal Graph Convolutional Network, STGCN) 融合的预测模型^[27], 捕获时序变化特征和拓扑时空特征, 预测每日社区级别的盗窃案件。深度时态多图卷积网络^[28]引入丰富外部因素以捕获时空关系提高预测精度。基于 GRU (Gated Recurrent Unit) 的短序列预测模型^[29]利用视频捕获人流量时间序列数据, 并结合犯罪数据对城市短期犯罪进行预测。

在犯罪预测中, 考虑犯罪区域空间相似性是有效的^[30-31]。而捕捉犯罪数据的区域空间相似性特征是较为复杂的^[24], 但是传统深度学习方法大多忽视了犯罪拓扑数据的空间相关性或较难准确捕捉犯罪区域空间相似性, 且在面对犯罪时空序列中的长时空依赖问题上具有较大局限性, 导致犯罪预测效果有限。当前研究表明, 多图卷积网络 (Multi Graph Convolutional Network, MGCN) 在针对节点间的多维度问题上具有明显优势^[32], 能够有效处理犯罪中复杂空间相似性的多维度问题。Transformer 机制^[33]在捕获时空长距离依赖性有着明显优势^[34]。VIT-Transformer^[35]将图像组织成序列, 并且引入位置信息编码, 提高了图像分类精度。Timesformer^[36]将视频视作 X 帧图像的集合, 并结合 Transformer, 有效地处理了视频中的时间和空间信息。因此使用基于 Transformer 的方法学习时空序列在整个时空维度上的依赖性具有很强的可行性。

针对当前犯罪预测方法中, 存在较难准确捕捉犯罪区域空间相似性特征, 以及在面对长时空依赖上具有较大局限性的问题, 论文提出一种融合犯罪区域空间相似性特征与犯罪事件

时空特征的犯罪事件时空分布预测模型 (Spatio temporal crime prediction model, STCPM)。该模型首先基于 GCN 构建空间通道注意力多图卷积网络 (Spatial Channel Attention Multi Graph Convolutional Network, SCA-MGCN) 以融合不同犯罪区域空间相似性数据, 提供丰富的空间相似性特征。在此基础上, 对犯罪时空数据进行嵌入以获取犯罪事件时空特征, 并将犯罪区域空间相似性特征与犯罪事件时空特征进行融合, 通过基于 Transformer 设计的 STC-Transformer (Spatio temporal Crime Transformer) 网络, 预测犯罪事件在不同时空尺度下的分布。

1 犯罪事件时空分布预测模型

基于 MGCN 在节点间多维度问题上的优势^[37]及 Transformer 在捕获时空长距离依赖性上的明显优势^[34], 研究设计了犯罪事件时空分布预测模型, 模型的整体结构如图 1 所示。该模型整体包含一个学习犯罪区域空间相似性特征的网络、一个学习犯罪事件时空特征的生成器网络以及一个预测分布特征的解码器网络。步骤为: (1) 将区域 POI 相似图、区域犯罪相似图、区域距离图输入至 SCA-MGCN 网络中, 以获取重要犯罪区域空间相似性特征; (2) 将犯罪区域空间相似性特征与犯罪事件时空特征融合, 并使用 STC-Transformer 的多层编码器 (Encoder) 编码记忆信息, 得到更高维度的时空记忆信息; (3) 记忆信息输入到解码器 (Decoder) 中结合前置犯罪时空序列输出未来犯罪时空序列。

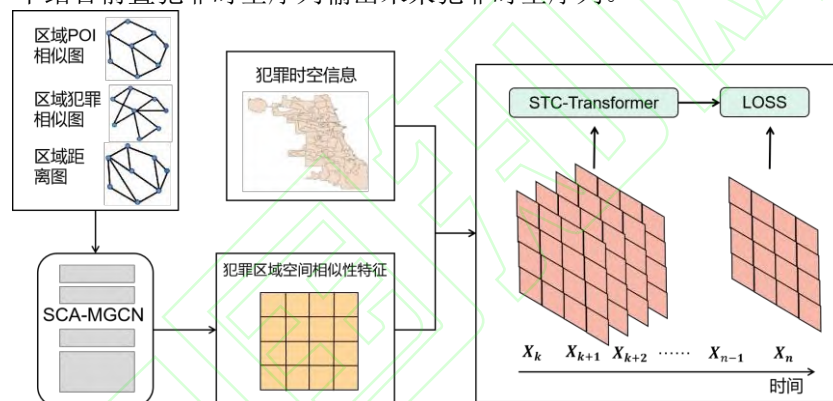


图 1 STCPM 模型
Fig. 1 STCPM Model

1.1 SCA-MGCN 网络

犯罪事件具有复杂的空间相似性特征^[24], 而这些特征存在复杂的相互作用关系。因此, 研究将多种犯罪区域空间相似性因素进行融合以使模型更加准确地预测犯罪事件。面对复杂多样的空间相似性信息, 论文基于 MGCN 提出了 SCA-MGCN 网络, 整体结构如图 2。网络整体分为三个模块: (1) 针对区域 POI 功能相似性、区域犯罪相似性、区域间距离设计独立的卷积网络, 分别捕捉犯罪区域空间相似性特征; (2) 设计了共同卷积层对空间相似性特征进行融合表达; (3) 构造空间通道注意力网络以自适应学习嵌入的重要性权重, 更好地捕捉不同特征之间的关系, 使得空间相似性特征和类别充分融合表达, 最后输出重要犯罪区域空间相似性特征。

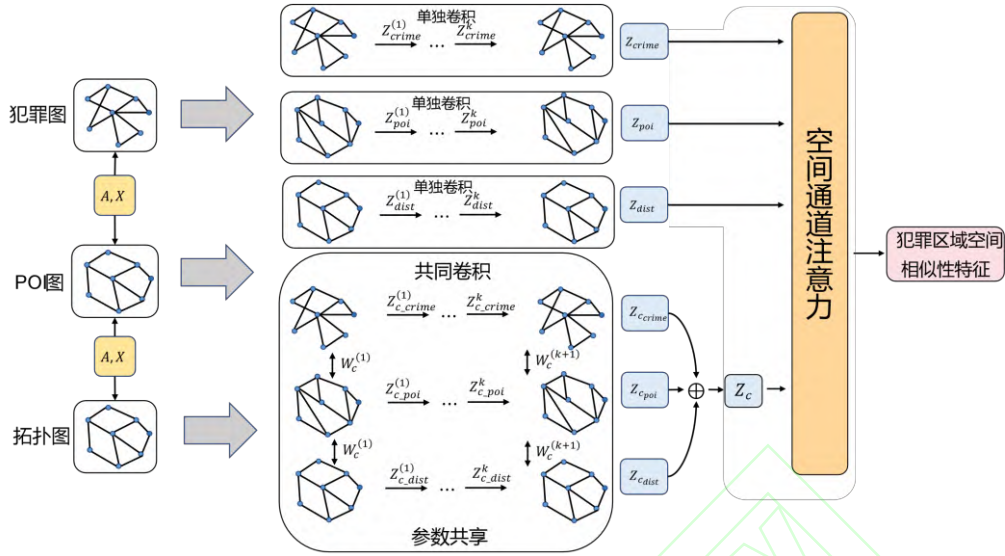


图 2 SCA-MGCN 网络

Fig. 2 SCA-MGCN Network

1.1.1 空间相似性特征构建模块

根据地理学第一定律^[38]可知，各现象之间存在关联，而邻近地区之间的关联通常更为显著。在犯罪领域，即一个地区的犯罪事件往往与其附近地区的事件存在关联，距离相近的区域通常具有相似的犯罪事件数量^[39]，为了描述这种关联，模型引入区域距离信息。考虑到具有相似特征的地区通常具有相似的犯罪模式^[40]，模型引入区域功能相似信息。另外，前置时间中犯罪特点相似的区域在后续时间中犯罪仍具有相似性，因此结合区域犯罪相似信息构建了犯罪区域空间相似性特征。

1.1.2 空间卷积模块

空间卷积模块通过对图分别进行单独卷积和共同卷积，以更好地捕捉犯罪区域空间相似性特征。

(1) 单独卷积

为捕捉区域 POI 功能结构特征空间中的信息，基于节点特征矩阵 X_{poi} 构建图 $Graph_{poi} = (A_{poi}, X_{poi})$ ，其中 A_{poi} 是 POI 图的邻接矩阵。使用 $Graph_{poi}$ 进行多层 GCN 运算后输出表示为 Z_{poi} ，表示为 POI 特征空间中捕获特定信息 Z_{poi} 的节点嵌入。公式如下^[41]：

$$Z_{poi}^{(k)} = \text{ReLU} \left(\tilde{D}_{poi}^{-\frac{1}{2}} \tilde{A}_{poi} \tilde{D}_{poi}^{-\frac{1}{2}} Z_{poi}^{(k-1)} W_{poi}^{(k)} \right) \quad (1)$$

其中 $W_{poi}^{(k)}$ 是 GCN 中第 k 层的权重矩阵，ReLU是激活函数，初始 $Z_{poi}^{(0)} = X_{poi}$ 。 \tilde{A}_{poi} 是图的邻接， \tilde{D}_{poi} 是 \tilde{A}_{poi} 的度矩阵。对于特征空间犯罪模式和拓扑空间距离，同样上述计算方式计算得到区域犯罪相似输出 Z_{crime} 和区域距离输出 Z_{dist} 。

(2) 共同卷积

由于犯罪事件的特征与拓扑空间具有一定关系，研究通过提取三个空间共享的公共信息以帮助预测模型确定哪部分信息最相关。研究设计了一个具有参数共享策略的公共卷积，从三个空间中过滤出共享特征。根据不同的输入图，我们可以得到三个输出嵌入 $Z_{c_{dist}}$ 、 $Z_{c_{crime}}$ 和 $Z_{c_{poi}}$ 。公式如下^[41]：

$$Z_{c_{\alpha}}^{(k)} = \text{ReLU} \left(\tilde{D}_{\alpha}^{-\frac{1}{2}} \tilde{A}_{\alpha} \tilde{D}_{\alpha}^{-\frac{1}{2}} Z_{\alpha}^{(k-1)} W_c^{(k)} \right)$$

(2)

其中 $W_c^{(k)}$ 是公共 GCN 的第 k 层权重矩阵， α 表示三个空间其中之一。 $Z_{c_\alpha}^{(k-1)}$ 是嵌入在 α 空间中第 $(k-1)$ 层中的节点， $Z_{c_\alpha}^{(0)} = X_\alpha$ 。三个空间的公共嵌入 Z_C 为：

$$Z_C = (Z_{c_{poi}} + Z_{c_{dist}} + Z_{c_{crime}})/3 \quad (3)$$

共同卷积模块的输出 Z 为：

$$Z = [Z_{c_{dist}}, Z_{c_{crime}}, Z_{c_{poi}}, Z_C] \quad (4)$$

1.1.3 空间通道注意力模块

空间通道注意力机制使模型能够自适应地关注从空间卷积模块获取特征中的重要空间和通道，从而提高模型的性能，如图 3 所示。

通道注意力通过计算输入特征的全局平均池化和全局最大池化，将两者连接并通过全连接层计算权重。而后将这些权重应用于输入特征的通道维度。这种加权可以帮助模型在特定任务中关注更有意义的特征通道。公式如下^[42]：

$$M_c(F) = \sigma(\text{MLP}(\text{AvgPool}(F)) + \text{MLP}(\text{MaxPool}(F))) \quad (5)$$

其中， $M_c(F)$ 为通道注意力模块， σ 是sigmoid函数，MLP为多层感知器， $\text{AvgPool}(F)$ 和 $\text{MaxPool}(F)$ 分别表示平均池化和最大池化。

空间注意力通过计算输入特征沿通道维度的平均和最大值，将两者连接并通过卷积层计算权重。而后将这些权重应用于输入特征的空间维度。这种加权有助于模型在特定任务中关注更有意义的空间区域。公式如下^[42]：

$$M_s(F') = \sigma(f([\text{AvgPool}(F'), \text{MaxPool}(F')])) \quad (6)$$

其中， $M_s(F')$ 为空间注意力模块， σ 是sigmoid函数， f 为卷积运算， $\text{AvgPool}(F')$ 和 $\text{MaxPool}(F')$ 分别表示平均池化和最大池化。

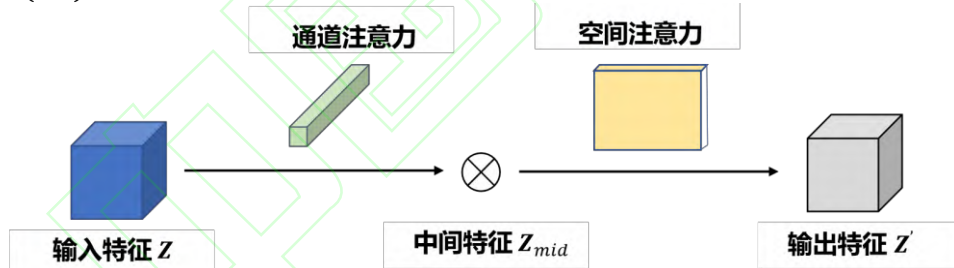


图 3 空间通道注意力结构示意图

Fig. 3 Schematic Diagram of the Attention Structure of the Space Channel

1.2 STC-Transformer 网络

基于 Transformer 的 Timesformer 模型不仅能有效处理时间和空间信息，且在时空长距离依赖捕获具有优势。研究基于 Timesformer，并融合 VIT-Transformer^[35]将图像分割成补丁序列并编码进位置信息的方法设计了 STC-Transformer 网络，实现在时空域上进行有效的图像序列预测，其结构如图 4 所示。STC-Transformer 网络总体分为三个模块：①对犯罪事件时空特征进行嵌入，再与犯罪区域空间相似性特征融合；②特征融合后引入时间位置编码；③输入至 Encoder-Decoder 部分，以学习犯罪事件的特征信息，并结合前置时空序列来生成输出序列。图 5 对 STC-Transformer 网络中的时空特征嵌入和多头时空注意力进行了详细描述。

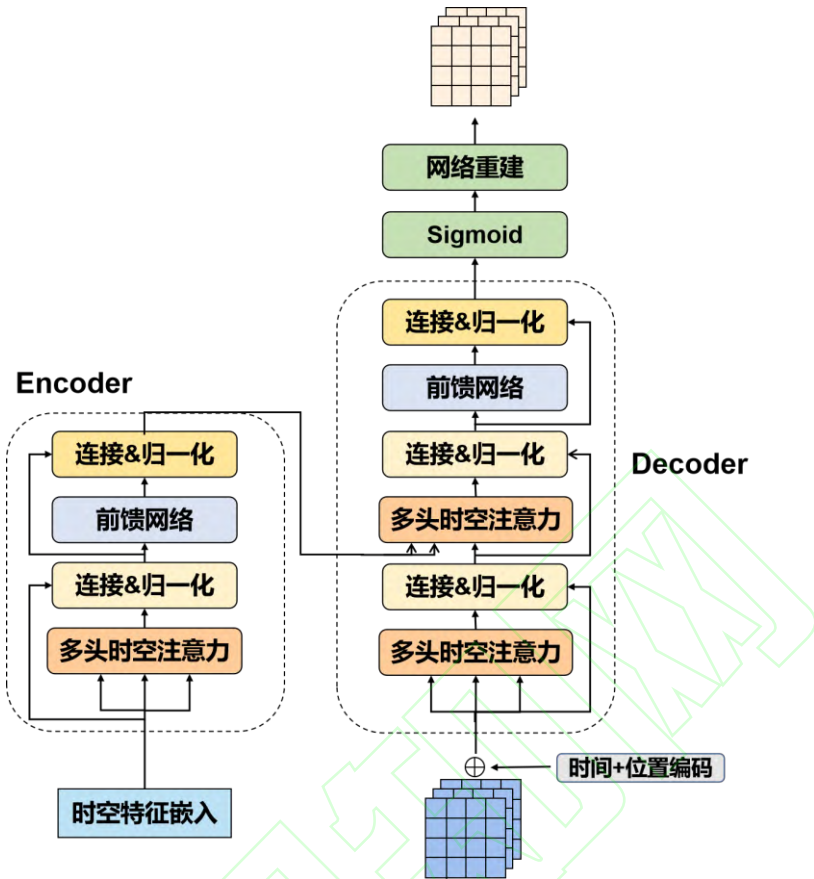


图 4 STC-Transformer 网络
Fig. 4 STC-Transformer Network

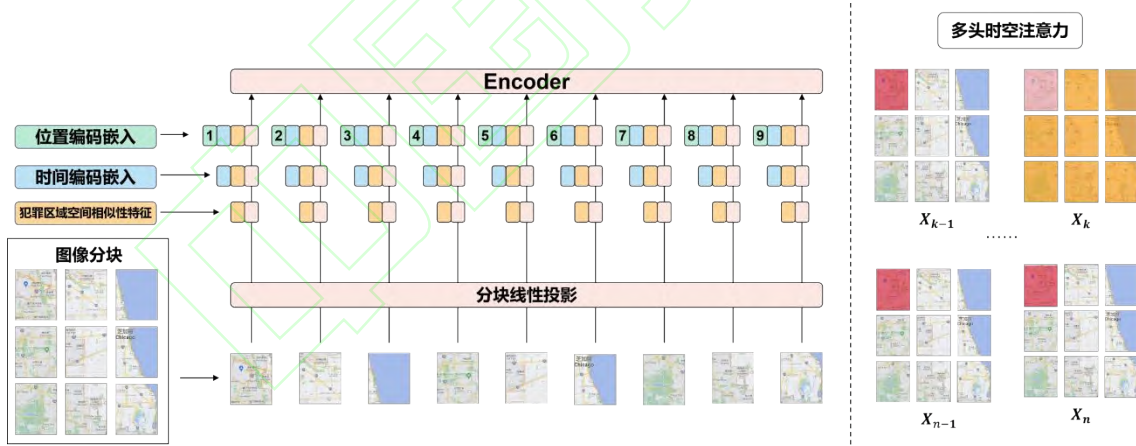


图 5 时空特征嵌入和多头时空注意力（多头时空注意力中，为了说明，用粉色表示查询块，橙色表示同一时间内在空间上与查询块计算注意力的小块，红色表示同一区域在不同时间上与查询块计算注意力的小块，无颜色代表不需与查询块计算）

Fig. 5 Spatio Temporal Feature Embedding and Multiple Spatio Temporal Attention (in Multiple Spatio Temporal Attention, for illustrative purposes, pink is used to denote query blocks, orange to denote chunks of the same space at the same time with which the query block computes its attention, red to denote chunks of the same space at a different time with which the query block computes its attention, and colorless to denote that it does not need to be computed with the query block)

1. 2. 1 犯罪事件时空特征嵌入

在时空犯罪预测问题中，每个时间点的犯罪事件时空序列可以视作一个张量 $X \in R^{C \times H \times W}$ ，预测的过程即根据前置的 N 个时间点的犯罪事件时空序列数据，预测未来 M 个时间点的犯罪

时间时空序列的变化情况。模型所需为从犯罪事件时空数据中抽取的历史序列，即可视为一个张量 $X^{B \times T \times C \times H \times W}$ ，其中 B 为 Batch size， T 为前置犯罪事件时间序列长度， C 为通道数即犯罪事件类别数， H 和 W 分别为网格的长和宽。

为将犯罪事件时空特征与犯罪区域空间相似性特征进行关联，研究针对犯罪事件时空数据，将其时间序列中的每个网格 $T_i^{(B \times T \times C \times H \times W)}$ 分解为 N 个不重叠的块，每个块的大小为 $P \times P$ ，即 $N = HW/P^2$ (如图 6 所示)，再将这些块展平为向量 $x_{(p,t)} \in R^{3P^2}$ ，其中 $p = 1, \dots, N$ 表示空间位置， $t = 1, \dots, F$ 表示网格切分后的索引。

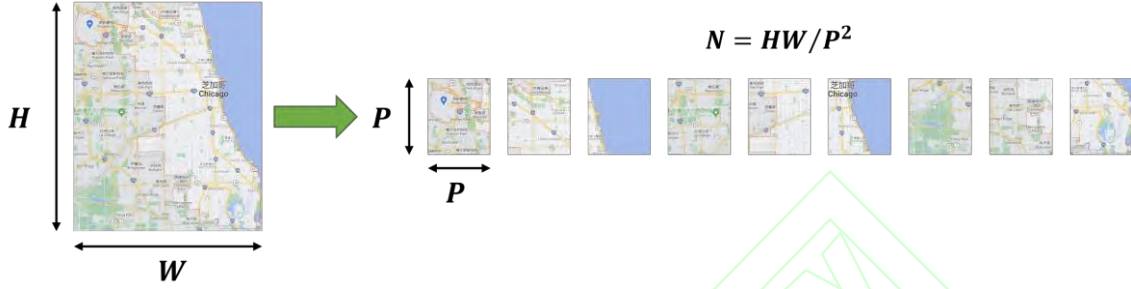


图 6 图像切块

Fig. 6 Image Chunking

线性映射每个 Patch 的向量 $x_{(p,t)}$ 通过可学习矩阵 $E \in R^{D \times 3P^2}$ 转为嵌入向量 $P_{(p,t)} \in R^D$ ，再将每个 Patch 嵌入向量与降维后的犯罪区域空间相似性特征 Z 融合，如公式 7 所示。

$$P_{(p,t)} = Ex_{(p,t)} + Z \quad (7)$$

1. 2. 2 时空编码

犯罪事件具有周期性且不同时间的犯罪事件表现较大差异。通过引入时间编码使得模型更好地捕捉犯罪时空数据的时间间隔和周期性信息，其编码方法为：

$$E_{t,2p} = \sin\left(\frac{t}{10000^{2p/d_e}}\right) \quad (8)$$

$$E_{t,2p+1} = \cos\left(\frac{t}{10000^{2p/d_e}}\right) \quad (9)$$

其中 d_e 和 t 分别表示嵌入维度和相对时间值。定义 $2p$ 和 $2p + 1$ 分别表示偶数和奇数位置的嵌入元素索引。

通常，Transformer 网络难以处理序列中每个元素的位置信息，需要结合位置编码来表达序列中元素的位置信息。位置编码可通过可学习的空间嵌入将位置编码 $D_{(p,t)}$ 映射至和时间编码一个维度。

时间编码、位置编码和 Patch 编码具有相同的维度，三者直接相加以得到最后的输入嵌入表达：

$$Z_{p,t}^i = P_{(p,t)} + E_{(p,t)} + D_{(p,t)} \quad (10)$$

1. 2. 3 Encoder-Decoder

STC-Transformer 中的 Encoder 和 Decoder 层，每层由 L 个编码块 (Block) 组成。

在每个块处，根据前一块编码的表示为 $z_{(p,t)}^{(l-1)}$ 每个块计算 Query, Key 和 Value^[33]：

$$q_{(p,t)}^{(l,a)} = W_Q^{(l,a)} \text{LN}\left(z_{(p,t)}^{(l-1)}\right) \quad (11)$$

$$k_{(p,t)}^{(l,a)} = W_K^{(l,a)} \text{LN}\left(z_{(p,t)}^{(l-1)}\right)$$

(12)

$$v_{(p,t)}^{(l,a)} = W_V^{(l,a)} \text{LN} \left(z_{(p,t)}^{(l-1)} \right)$$

(13)

其中，LN表示 Layer Normalization， $a = 1, \dots, A$ 表示 heads 的索引。每个注意力头部的潜在维度设置为 $D_h = D/A$ 。

为降低模型计算量同时保证捕获不同时间段之间的时空相关性，对于每个 Patch，通过将其与其他时间片段中相同空间位置的所有图像块进行比较以计算时间注意力，再将其与同一时间片段中其他图像块进行比较以计算空间注意力。公式如下^[36]：

$$\begin{cases} \alpha_{(\rho,t)}^{(\ell,\alpha)time} = SM \left(\frac{q_{(\rho,t)}^{(\ell,\alpha)T}}{\sqrt{D}} \right) \cdot \left[k_{(0,0)}^{(\ell,\alpha)} \left\{ k_{(p',t')}^{(\ell,\alpha)} \right\}_{t'=1,\dots,F} \right] \\ \alpha_{(\rho,t)}^{(\ell,\alpha)space} = SM \left(\frac{q_{(\rho,t)}^{(\ell,\alpha)T}}{\sqrt{D}} \right) \cdot \left[k_{(0,0)}^{(\ell,\alpha)} \left\{ k_{(p',t')}^{(\ell,\alpha)} \right\}_{p'=1,\dots,N} \right] \end{cases}$$

(14)

使用 Attention 值 α 和相应的 Value 加权求和，得到多头注意力中某一个头的更新值 S，再拼接多个头上的更新值。

$$S_{(p,t)}^{(l,a)} = \alpha_{(p,t)(0,0)}^{(\ell,\alpha)} V_{(0,0)}^{(\ell,\alpha)} + \sum_{p'=1}^N \sum_{t'=1}^F \alpha_{(p,t)(p',t')}^{(\ell,\alpha)} V_{(p',t')}^{(\ell,\alpha)} \quad (15)$$

来自所有头部的这些向量的拼接被投影并通过 MLP，在每次操作后使用剩余连接：

$$\begin{cases} z_{(p,t)}^{(l)} = W_O \left[S_{(p,t)}^{(l,1)}, \dots, S_{(p,t)}^{(l,A)} \right]^T + z_{(p,t)}^{(l-1)} \\ z_{(p,t)}^{(l)} = MLP \left(\text{LN} \left(z_{(p,t)}^{(l)} \right) \right) \end{cases}$$

(16)

1.3 损失函数

STCPM 模型将 BCE Loss 和 Dice Loss 结合作为损失函数，可以综合考虑模型对正负样本的预测准确性，提高模型的整体预测能力。定义损失函数如下^[43-44]：

$$\ell_{CE}(\theta) = -\sum_{\varepsilon}^{\beta} \left[X_{t+\varepsilon} \log(\hat{X}_{t+\varepsilon}) + (1 - X_{t+\varepsilon}) \left(1 - \log(\hat{X}_{t+\varepsilon}) \right) \right]$$

(17)

$$\ell_{DL}(\theta) = \sum_{\varepsilon}^{\beta} \left(1 - \frac{2 \sum X_{t+\varepsilon} \hat{X}_{t+\varepsilon}}{\sum X_{t+\varepsilon}} \right)$$

(18)

$$\ell(\theta) = \ell_{CE}(\theta) + \ell_{DL}(\theta)$$

(19)

其中， $y_{m,n}^{ct}$ 表示第 c 类时空事件发生在第 t 时隙中的区域 $r_{m,n}$ 的估计概率。

2 实验与分析

研究通过详细的实验分析 STCPM 模型的犯罪预测性能，下面详细描述实验设计和实验结果及分析。

2.1 实验设计

2.1.1 实验环境

实验采用的硬件环境为专用的深度学习平台，CPU 型号为 Intel I7-12700F，GPU 数量为 1 块，GPU 型号为 NVIDIA RTX 3080TI，运行内存为 12 GB。实验所采用的系统环境为 Windows11 使用的软件主要包括 Python 3.8，Pytorch-GPU 2.0。

2.1.2 数据情况

实验以美国芝加哥市和美国洛杉矶市为研究区域，研究数据为研究区域不同时期的犯罪事件数据及犯罪区域空间相似性数据两类，其中犯罪区域空间相似性数据包括区域兴趣点（POI）数据、区域犯罪事件数据以及区域距离数据。区域犯罪事件数据为对各区域各时间区间的各犯罪事件类型的数量进行统计后的数据。区域距离数据为区域间的曼哈顿距离。

①美国芝加哥市数据

芝加哥犯罪事件时空数据：其为美国芝加哥市的盗窃、殴打、袭击、刑事损害数据，采集自芝加哥开放数据门户（<https://data.cityofchicago.org/>）。为了开展充分的实验验证，训练集使用了 2016 年 1 月 1 日至 2017 年 9 月 30 日的数据，验证集选用 2017 年 10 月 1 日至 2017 年 12 月 31 日和 2022 年 1 月 1 日至 2022 年 12 月 31 日两个时期的数据集，犯罪事件数量如表 1 所示。

芝加哥区域 POI 数据：自 OpenStreetMap 网站（<https://www.openstreetmap.org/>）采集，共获取 9460 个 POI 点，并分为十三类：定居点、公共服务点、医疗点、教育点、旅游点、商店点、商业点、体育运动点、餐饮点、运输点、住宿点、宗教活动点、汽车服务点。

表 1 芝加哥犯罪事件数量表

Tab.1 Table of Number of Crime Incidents in Chicago

类别	殴打	袭击	刑事损害	盗窃
训练集（2016 年 1 月 1 日至 2017 年 9 月 30 日）	92485	26464	55460	108847
测试集 1（2017 年 10 月 1 日至 2017 年 12 月 31 日）	6904	11508	4426	16183
测试集 2（2022 年 1 月 1 日至 2022 年 12 月 31 日）	25719	39127	19865	50860

②美国洛杉矶市数据

洛杉矶犯罪事件时空数据：其为美国洛杉矶市的盗窃、殴打、袭击、刑事损害数据，采集自洛杉矶开放数据门户（<https://data.lacity.org/>）。训练集使用了 2022 年 1 月 1 日至 2023 年 10 月 25 日的数据，验证集选用 2023 年 10 月 26 日至 2023 年 12 月 31 日数据，犯罪事件数量如表 2 所示。

洛杉矶区域 POI 数据：共采集 10731 个 POI 点，其采集方式及分类方法与芝加哥区域 POI 数据相同。

表 2 洛杉矶犯罪事件数量表

Tab.2 Table of Number of Crime Incidents in Los Angeles

类别	殴打	袭击	刑事损害	盗窃
训练集（2023 年 1 月 1 日至 2023 年 10 月 25 日）	6443	25392	16594	54416

10月26日)				
测试集 (2023年				
10月26日至2023	997	4243	2519	6872
年12月31日)				

2.1.3 数据处理

(1) 犯罪事件时空数据

研究将所有犯罪事件时空数据引入对应区域地图中，如图7所示（以芝加哥市为例）。

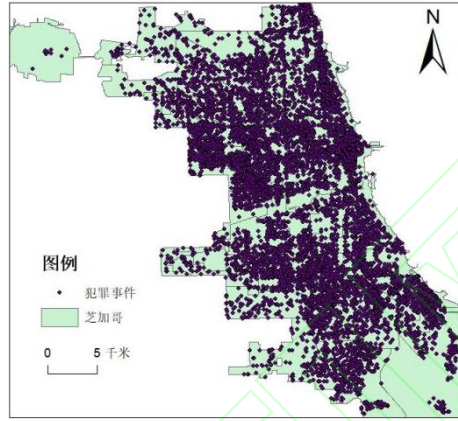


图7 犯罪事件时空数据处理

Fig.7 Processing of Spatio temporal Data on Crime Incidents

(2) 犯罪区域空间相似性数据

针对犯罪区域空间相似性数据，研究首先将区域分别按照 1km^2 、 2km^2 空间分辨率网格化为 16×16 、 24×24 的网格，如图8所示（以芝加哥市为例）。将一段时间划分成若干时间段，每个时间段代表一个时间区间。最终，将每个网格单元和每个时间段组合起来，形成三维时空网格。其中，每个网格单元记录了该网格单元在每个时间段内发生的犯罪类型及其数量。

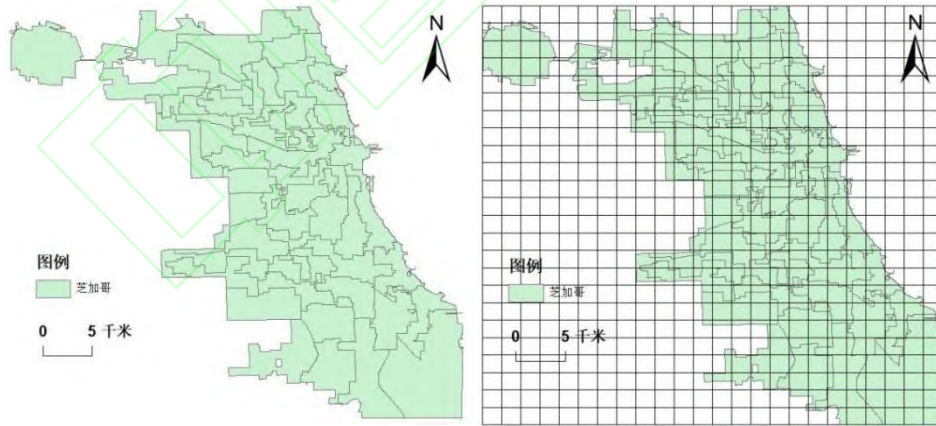


图8 犯罪区域空间相似性数据处理

Fig.8 Processing of Spatial Similarity Data in Crime Areas

①区域POI数据：建立区域POI相似图 $POI = (V, E_p, A_p)$ 用于编码区域之间的功能相似性，其维数等于POI类别的数量，每个条目表示区域 i 内特定类别的POI数量。定义如下：

$$A_p^{ij} = \exp\left(-\frac{[\cos_similar(POI_i, POI_j)]^2}{2\theta_p^2}\right) \quad (20)$$

POI_i 是区域 i 的POI向量， θ_p 是控制相似度矩阵的尺度的参数。

②区域犯罪事件数据：建立区域犯罪相似图 $Crime = (V, E_C, A_C)$ 对区域间的历史犯罪事件相似性进行编码，其维数等于犯罪时空数据中的时间间隙数量，每个条目对应于区域 i 内各时间间隙中发生的犯罪事件数。定义如下：

$$A_P^{ij} = \exp\left(-\frac{[\cos_similar(Crime_i, Crime_j)]^2}{2\theta_C^2}\right) \quad (21)$$

其中 $Crime_i$ 是区域 i 的犯罪事件向量， θ_C 是控制邻接矩阵规模的参数。

③区域距离数据：建立区域距离图 $Dist = (V, E_D, A_D)$ ，用于编码区域之间的空间相似性，应用高斯核加权函数来定义边缘的权重。定义如下：

$$A_D^{ij} = \exp\left(-\frac{[Dist(i, j)]^2}{2\theta_D^2}\right) \quad (22)$$

其中 $Dist(i, j)$ 是区域 i 和 j 之间的曼哈顿距离， θ_D 是控制邻接矩阵比例的参数。

2.1.4 评价指标

犯罪预测可视为分类问题，即是否犯罪以及发生哪一类事件。模型分类水平评估中常用的精确率（Precision, P）、召回率（Recall, R）和 F1 值，F1 值的取值范围是 0 到 1，其值越大表示分类模型的性能越好。公式如下^[45]：

$$R = \frac{TP}{TP+FN} \quad (23)$$

$$P = \frac{TP}{TP+FP} \quad (24)$$

$$F1 = \frac{2 \times P \times R}{P+R} \quad (25)$$

TP (True Positive)、FP (False Positive)、FN (False Negative) 分别表示真正例、假正例、假反例。

对于多类型犯罪事件时空预测，单一选择 F1 值无法较好评估模型性能，实验选择 Micro-F1 和 Macro-F1 以减少由于类别间数据量差异大而产生对指标的影响过大。公式如下^[45]：

$$Macro - F1 = \frac{\sum_i^N F1_i}{N} \quad (26)$$

$$P_{micro} = \frac{\sum_i^N TP_i}{\sum_i^N TP_i + \sum_i^N FP_i} \quad (27)$$

$$R_{micro} = \frac{\sum_i^N TP_i}{\sum_i^N TP_i + \sum_i^N FN_i} \quad (28)$$

$$Micro - F1 = \frac{2 \times P_{micro} \times R_{micro}}{P_{micro} + R_{micro}} \quad (29)$$

其中 i 表示犯罪事件的当前类别， N 表示犯罪事件类别数量。

2.2 实验结果与分析

实验以输入的 9 个时间点的犯罪时空序列推测未来 3 个时间点的方式，对芝加哥市及洛

杉矶市的四类犯罪类型：刑事损害、殴打、袭击、盗窃进行了预测。

2.2.1 实验结果

使用 STCPM 犯罪事件时空分布预测模型对四类犯罪事件的预测如图所示，分别预测 16*16 和 24*24 网格大小下的效果，并且使用 ConvLSTM、STGCN、ST-ResNet 同样进行预测，将预测结果与真实结果进行对比验证。

(1) 预测结果对比分析

图 9 为实验所使用方法预测的 16*16 网格下的七天实验结果样例，其中第一行至第五行分别为真实数据、STCPM 预测结果、STGCN 预测结果、ST-ResNet 预测结果、ConvLSTM 预测结果。整体来看，STGCN 相较于真实数据，存在较多漏预测情况，而 ConvLSTM 存在过多预测情况。通过横向对比，STGCN 模型预测的犯罪区域在该段时间中没有发生任何变化，ConvLSTM 模型基本没有变化，STCPM 和 ST-ResNet 模型会随着时间及时空特征的变化而变化。在图 9 中 A 处范围中，对比各预测结果中此处，仅有 STCPM 模型该范围进行了预测，并在图 9 中 B 处预测准确。由于 C 处发生犯罪，导致 STCPM 预测结果中的 D 处对其进行了预测，而在当天的真实数据中，并未发生，影响 STCPM 模型中的 E 处并未预测。

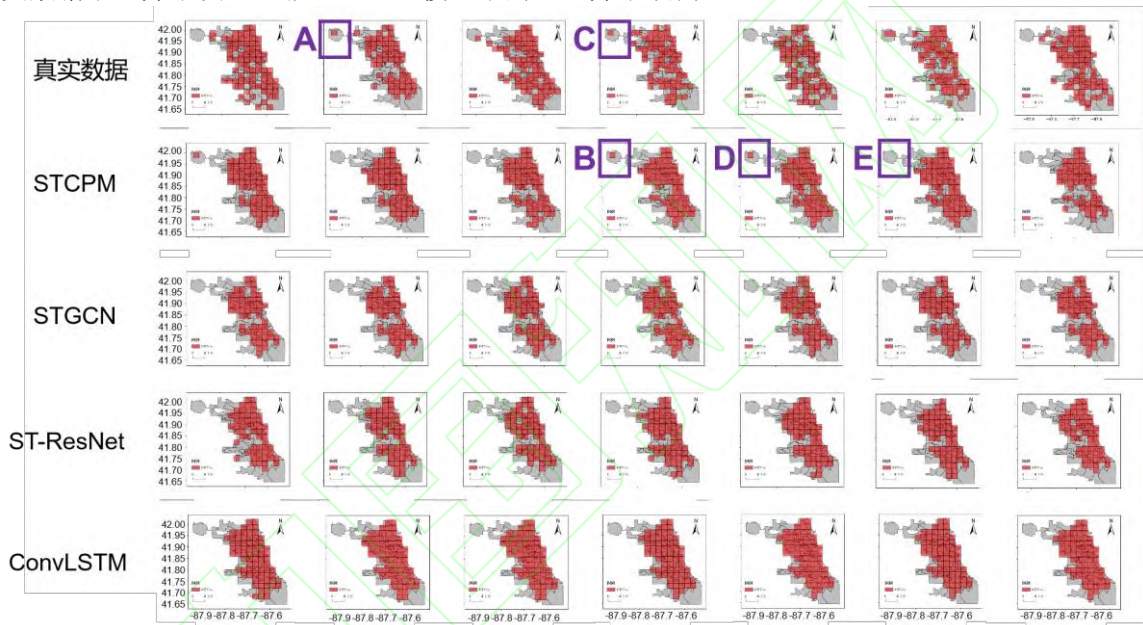


图 9 16*16 网格预测结果与实际数据对比图

Fig. 9 Comparison of 16*16 Grid Prediction Results with Actual Data

图 10 为本文方法预测的 24*24 网格下的七天实验结果样例。同样，整体来看，STGCN 相较于真实数据，存在较多漏预测情况，而 ConvLSTM 存在过多预测情况。例如在橙色框中，STGCN 预测过于稀疏，而 ConvLSTM 过于密集，且对于真实数据橙色框中的一个未发生犯罪事件的区域，STCPM 相较于 ST-ResNet 预测准确。通过横向对比，能看出 STGCN 预测结果在该段时间内没有发生任何变化，ConvLSTM 发生了小幅度变化，STCPM 和 ST-ResNet 随时间及时空特征发生变化，与 16*16 网格分析结果相符。

上述实验结果分析表明，STGCN 和 ConvLSTM 模型预测较为固化，对于变化的部分难以预测精准。再仔细对比图 9、图 10 中各网格，STCPM 模型相较于其他三个模型，与真实数据更为吻合。为更清晰对比模型预测结果并证明 STCPM 的科学性，将 STCPM 与其他模型进行评价指标对比。

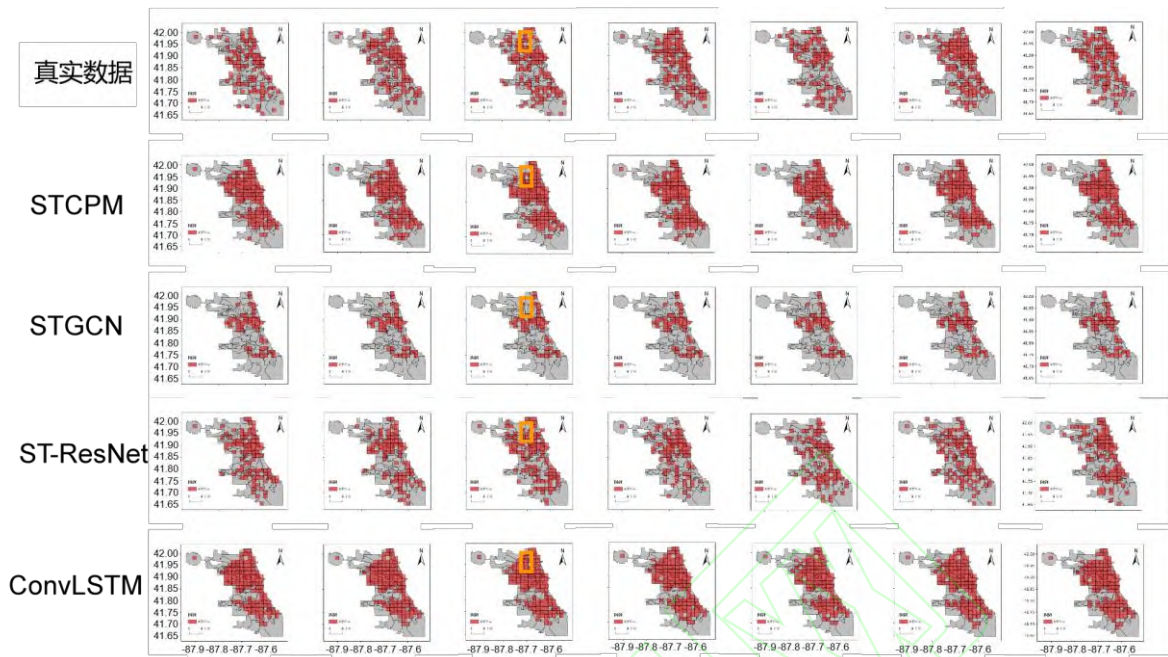


图 10 24*24 网格预测结果与实际数据对比图

Fig. 10 Comparison of 24*24 Grid Prediction Results with Actual Data

(2) 评价指标对比分析

为对比美国芝加哥市和美国洛杉矶市 16*16 和 24*24 网格大小下的模型预测情况，根据评价指标对四种类别犯罪事件的预测结果进行计算，以获取预测效果，表 3 显示了芝加哥和洛杉矶数据集在 16*16 网格下的犯罪预测准确性，表 4 显示了两个数据集在 24*24 网格下的犯罪预测准确性，准确度统计如图 11 所示。

图 11 分别对芝加哥市及洛杉矶市两种网格大小的预测结果准确度进行了更为直观的可视化处理，根据其可以直观地看出，无论是单个类型事件的 F1 值或是整体犯罪事件的 F1 值，STCPM 的犯罪事件时空预测模型均优于基于 STGCN、ST-ResNet 和 ConvLSTM 的预测模型。STCPM 不仅在大尺度上的表现优于其他模型并且在小尺度上表现出更强的准确性和稳定性。而 STGCN 模型在此呈现不稳定性，从表 3 和表 4 可以观察到，由于殴打、盗窃犯罪事件数据量较大，即变相反应发生区域相对较多，该两种犯罪事件随时间、时空特征变化相对于袭击、刑事损害较小，即导致 STGCN 对该两种犯罪事件预测效果较好，而刑事损害和袭击犯罪事件相对较差，且由于 STGCN 使用图结构数据将二维空间数据展平成一维数据，对空间聚集性的捕捉效果较差，导致准确性及稳定性不及 STCPM 模型。ConvLSTM 由于使用 CNN 具有局部局限性，预测结果固化，不同时间段的预测结果差异很小。ST-ResNet 没有很好地捕捉到犯罪事件的空间聚集性，预测结果较为分散。

在芝加哥数据集的大尺度情境下，STCPM 相较于其他模型中 Micro-F1 和 Macro-F1 的最高值提高了 7.7% 和 10.9%，小尺度下分别提高了 32.3% 和 38.1%，在洛杉矶数据集的大尺度情境下，STCPM 相较于其他模型中 Micro-F1 和 Macro-F1 的最高值提高了 2.3% 和 2.9%，小尺度下分别提高了 15.6% 和 16.9%。表明 STCPM 模型在犯罪预测上相比其他三种模型预测的结果更准确，更加符合实际真实情况。在小尺度下，STCPM 模型相较于其他模型预测提升效果明显，即使空间尺度缩小依然捕捉到时空规律，预测结果不断变化，符合犯罪事件的时间特征分布规律。

表 3 16*16 网格预测结果
Tab. 3 16*16 Grid Prediction Results

数据区域	模型名称	刑事损害	殴打	袭击	盗窃	Micro-F1	Macro-F1
芝加哥	STGCN	0.681	0.823	0.458	0.857	0.742	0.705
	ST-ResNet	0.611	0.788	0.525	0.774	0.690	0.675
	ConvLSTM	0.602	0.754	0.489	0.816	0.688	0.665
	STCPM	0.790	0.866	0.580	0.893	0.799	0.782
洛杉矶	STGCN	0.057	0.682	0.627	0.848	0.687	0.553
	ST-ResNet	0.028	0.409	0.344	0.579	0.451	0.362
	ConvLSTM	0.263	0.799	0.731	0.922	0.782	0.679
	STCPM	0.300	0.817	0.732	0.946	0.800	0.699

表 4 24*24 网格预测结果
Tab. 4 24*24 Grid Prediction Results

数据区域	模型名称	刑事损害	殴打	袭击	盗窃	Micro-F1	Macro-F1
芝加哥	STGCN	0.216	0.549	0.118	0.611	0.430	0.374
	ST-ResNet	0.335	0.454	0.323	0.527	0.432	0.410
	ConvLSTM	0.338	0.571	0.143	0.673	0.498	0.431
	STCPM	0.507	0.723	0.360	0.791	0.659	0.595
洛杉矶	STGCN	0.028	0.489	0.387	0.626	0.486	0.375
	ST-ResNet	0.035	0.245	0.222	0.492	0.354	0.248
	ConvLSTM	0.122	0.448	0.453	0.775	0.565	0.449
	STCPM	0.165	0.580	0.500	0.853	0.653	0.525

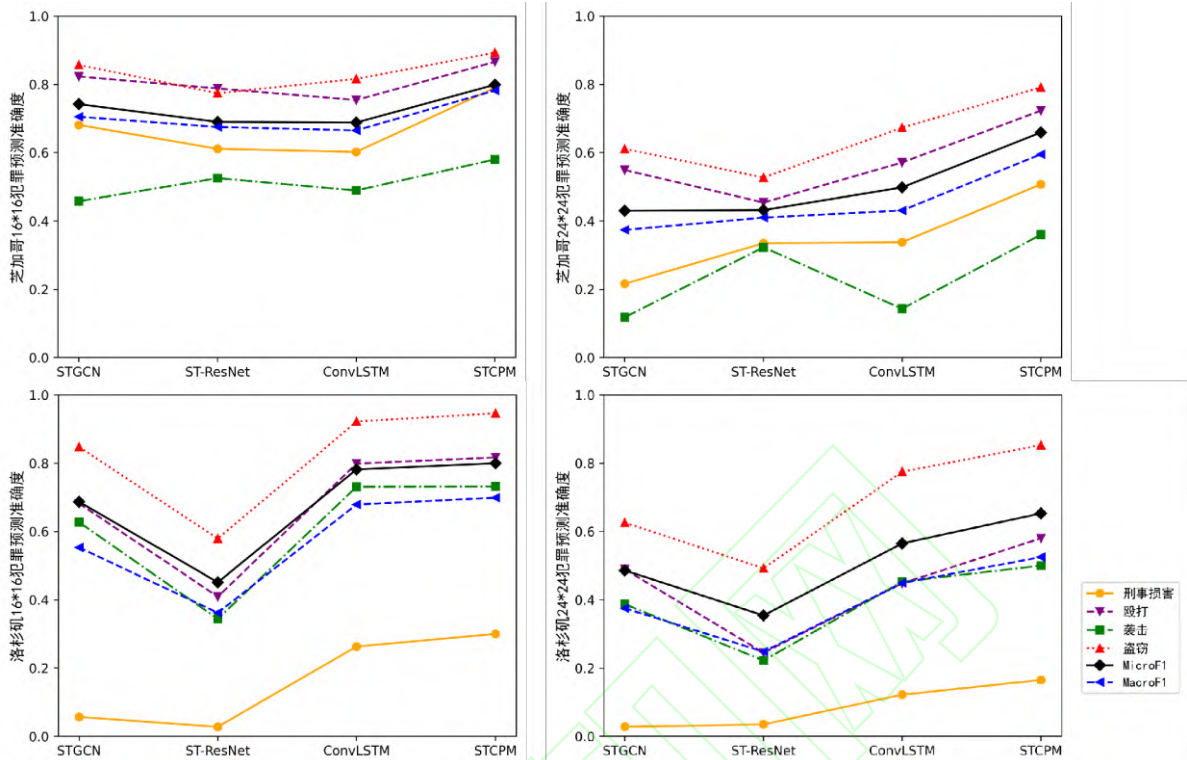


图 11 犯罪预测准确度统计

Fig. 11 Crime Prediction Accuracy Statistics

(3) 模型复杂度对比分析

论文通过 FLOPs、Params、模型平均运行时间及 GPU 内存峰值四个指标对比模型之间复杂度。其中 FLOPs 表示模型计算复杂度，Params 表示模型参数数量，模型平均运行时间表示模型时间复杂度，GPU 内存峰值表示模型空间复杂度。实验对各模型各指标进行定量对比评价，如表 5 所示。其中，所有模型均以 24*24 网格数据运行，GPU 内存峰值是在的单个 NVIDIA RTX 3080TI GPU 上以 8 个批量大小测量，FLOPs 单位 G 代表 billion，Params 单位 M 代表 Million，平均运行时间单位 s 代表 seconds，GPU 内存峰值 MB 代表 Megabytes。为提高犯罪预测准确度，STCPM 引入犯罪区域空间相似性特征作为输入，而相应增加了 FLOPs 及 Params，进而导致对平均运行时间及 GPU 内存峰值的增加，从表 5 可知，STCPM 的平均运行时间相较 STGCN、ST-ResNet 偏高，相较 ConvLSTM 偏低，GPU 内存峰值相较其他模型均偏高，但其 FLOPs、Params、平均运行时间、GPU 内存峰值的增加均属于正常增幅，且各项数值均在常规范围之内。

表 5 各模型计算量及参数量定量评价

Tab. 5 Quantitative Evaluation of the Computational and Parametric Quantities of Each Model

模型	输入	FLOPs (G)	Params (M)	平均运行时间 (s)	GPU 内存峰值 (MB)
STGCN		0.3533	0.0901	3.761	219.685
ST-ResNet	犯罪事件时空数据: 24×24	5.0961	0.7364	5.992	104.242
ConvLSTM	犯罪事件时空数据: 24×24	10.0340	0.0976	22.148	253.160
STCPM	区域 POI 功能相似图: 576×576	22.0490	1.8963	13.715	455.998

区域犯罪相似图: 576×576

区域距离相似图: 576×576

2.2.2 消融实验

为验证 SCA-MGCN 对空间相似性特征的融合作用以及犯罪事件时空特征在犯罪预测模型中的作用, 设计了消融实验: ①ST-TransA: 仅输入犯罪事件时空信息至 STC-Transformer; ②ST-TransB: 直接融合犯罪事件时空信息和犯罪区域空间相似性特征并输入至 STC-Transformer, 而不使用 SCA-MGCN, 对比 STCPM 进行了测试, 预测结果如表 6 所示, 图 12 左图、右图分别表示芝加哥、洛杉矶消融实验犯罪预测准确度统计。

从预测结果可以看出, 空间相似性特征的加入提升了预测精度, SCA-MGCN 有效提升了捕捉空间相似性特征的能力, 两者的结合使 STCPM 基本上处于最佳效果, 呈现更好的综合效果。在芝加哥数据集中 STCPM 相较于 ST-TransA, Micro-F1 和 Macro-F1 分别提高了 17.5%和 20.9%, 相较于 ST-TransB, Micro-F1 和 Macro-F1 分别提高了 21.6%和 24.5%。在洛杉矶数据集中, STCPM 相较于 ST-TransA, Micro-F1 和 Macro-F1 分别提高了 9.0%和 11.0%, 相较于 ST-TransB, Micro-F1 和 Macro-F1 分别提高了 12.4%和 15.6%。

表 6 消融实验结果

Tab.6 Results of ablation experiments

数据区域	模型名称	刑事损害	殴打	袭击	盗窃	Micro-F1	Macro-F1
芝加哥	ST-TransA	0.389	0.640	0.222	0.715	0.561	0.492
	ST-TransB	0.371	0.631	0.207	0.704	0.542	0.478
	STCPM	0.507	0.723	0.360	0.791	0.659	0.595
洛杉矶	ST-TransA	0.135	0.496	0.467	0.793	0.599	0.473
	ST-TransB	0.113	0.484	0.438	0.781	0.581	0.454
	STCPM	0.165	0.580	0.500	0.853	0.653	0.525




图 12 消融实验犯罪预测准确度统计

Fig.12 Ablation experiment crime prediction accuracy statistics

3 总结和展望

研究提出了一种新的犯罪预测模型, 提高了犯罪预测的准确性。研究主要创新点如下:

(1) 提出了一种多元犯罪区域空间相似性特征捕捉的思路, 以获取与犯罪相关的多种因素重要特征, 以更好对犯罪进行预测。(2) 设计了一种融合犯罪区域空间相似性与犯罪事件时空特征的犯罪预测模型。该模型基于 GCN 设计空间通道注意力多图卷积网络, 可以较好捕捉犯罪区域空间相似性特征, 并且 STC-Transformer 网络, 捕捉长距离时空依赖, 使模型预测准确度提升。模型不仅在大尺度上的表现优于其他模型并且在小尺度上表现出了更强的准

确性和稳定性。(3)研究工作给后续犯罪预测研究带来了新思路,即通过更准确捕捉多元犯罪区域空间相似性特征并更有效结合犯罪事件时空特征以提高犯罪预测准确度,为后续学者进行犯罪预测研究提供了参考。

未来工作主要包含如下两个方面:(1)融合其他多模态相关性要素。犯罪事件是复杂的,其可能与区域经济、环境、人口等要素都息息相关,需要考虑融合哪些更重要要素、如何更好融合要素,表达相关性特征,以提高犯罪预测准确性。(2)微观尺度下稀疏性分析。由于犯罪事件的发生通常是随机和不规则的,因此在某些地点和时间,可能很少或几乎没有犯罪事件发生,导致数据的稀疏性。这种稀疏性问题可能会影响预测模型的准确性和可靠性。

参考文献

- [1] LIANG W, WANG Y, TAO H, et al. Towards hour-level crime prediction: A neural attentive framework with spatial-temporal-categorical fusion [J]. *Neurocomputing*, 2022, 486: 286-97.
- [2] RAYHAN Y, HASHEM T. Aist: An interpretable attention-based deep learning model for crime prediction [J]. *arXiv preprint arXiv:201208713*, 2020.
- [3] HOU M, HU X, CAI J, et al. An integrated graph model for spatial-temporal urban crime prediction based on attention mechanism [J]. *ISPRS International Journal of Geo-Information*, 2022, 11(5): 294.
- [4] LI Weihong, WEN Lei, CHEN Yebin. Property Crime Forecast Based on Improved GA-BP Neural Network Model [J]. *Geomatics and Information Science of Wuhan University*, 2017, 42(8): 1110-1116, 1171. (李卫红, 闻磊, 陈业滨. 改进的GA-BP神经网络模型在财产犯罪预测中的应用 [J]. *武汉大学学报(信息科学版)*, 2017, 42(8): 1110-1116, 1171.)
- [5] LI Z, HUANG C, XIA L, et al. Spatial-temporal hypergraph self-supervised learning for crime prediction; proceedings of the 2022 IEEE 38th International Conference on Data Engineering (ICDE), F, 2022 [C]. IEEE.
- [6] CATLETT C, CESARIO E, TALIA D, et al. Spatio-temporal crime predictions in smart cities: A data-driven approach and experiments [J]. *Pervasive and Mobile Computing*, 2019, 53: 62-74.
- [7] OSGOOD D W. Poisson-Based Regression Analysis of Aggregate Crime Rates [J]. *Journal of Quantitative Criminology*, 2000, 16(1): 21-43.
- [8] VULTUREANU-ALBIȘI A, BĂDICĂ C. Optimizing Regularized Multiple Linear Regression Using Hyperparameter Tuning for Crime Rate Performance Prediction; proceedings of the World Conference on Information Systems and Technologies, F, 2021 [C]. Springer.
- [9] RAZA D M, VICTOR D B. Data mining and Region Prediction Based on Crime Using Random Forest; proceedings of the 2021 International Conference on Artificial Intelligence and Smart Systems (ICAIS), F, 2021 [C].
- [10] BUTT U M, LETCHMUNAN S, HASSAN F H, et al. Spatio-temporal crime predictions by leveraging artificial intelligence for citizens security in smart cities [J]. *IEEE Access*, 2021, 9: 47516-29.
- [11] SIRISHA U M, BELAVAGI M C, ATTIGERI G. Profit Prediction Using ARIMA, SARIMA and LSTM Models in Time Series Forecasting: A Comparison [J]. *IEEE Access*, 2022, 10: 124715-27.
- [12] SAUNDERS J, HUNT P, HOLLYWOOD J S. Predictions put into practice: a quasi-experimental evaluation of Chicago's predictive policing pilot [J]. *Journal of experimental criminology*, 2016, 12: 347-71.
- [13] CHANDRA B, GUPTA M, GUPTA M. A multivariate time series clustering approach for crime trends prediction; proceedings of the 2008 IEEE International Conference on Systems, Man and Cybernetics, F, 2008 [C]. IEEE.
- [14] YADAV R, SHEORAN S K. Modified ARIMA model for improving certainty in spatio-temporal crime event prediction; proceedings of the 2018 3rd International Conference and Workshops on Recent Advances and Innovations in Engineering (ICRAIE), F, 2018 [C]. IEEE.
- [15] BROWN D E, OXFORD R B. Data mining time series with applications to crime analysis; proceedings of the 2001 IEEE International Conference on Systems, Man and Cybernetics e-Systems and e-Man for Cybernetics in Cyberspace (Cat No 01CH37236), F, 2001 [C]. IEEE.
- [16] MATEREKE T, NYIRENDA C N, GHAZIASGAR M. A Comparative Evaluation of Spatio Temporal Deep Learning Techniques for Crime Prediction; proceedings of the AFRICON, F, 2021 [C].
- [17] CORTEZ B, CARRERA B, KIM Y J, et al. An architecture for emergency event prediction using LSTM recurrent neural networks [J]. *Expert Systems with Applications*, 2018, 97: 315-24.

- [18] JINGHUA Y, MIAOMIAO H. Predicting time series of theft crimes based on LSTM network [J]. *Data Analysis and Knowledge Discovery*, 2020, 4(11): 84-91.
- [19] MESKELA T E, AFEWORK Y K, AYELE N A, et al. Designing time series crime prediction model using long short-term memory recurrent neural network [J]. *International Journal of Recent Technology and Engineering (IJRTE)*, 2020, 9: 402-5.
- [20] WANG B, LUO X, ZHANG F, et al. Graph-based deep modeling and real time forecasting of sparse spatio-temporal data [J]. *arXiv preprint arXiv:180400684*, 2018.
- [21] HUANG C, ZHANG J, ZHENG Y, et al. DeepCrime: Attentive hierarchical recurrent networks for crime prediction; proceedings of the Proceedings of the 27th ACM international conference on information and knowledge management, F, 2018 [C].
- [22] ZHUANG Y, ALMEIDA M, MORABITO M, et al. Crime hot spot forecasting: A recurrent model with spatial and temporal information; proceedings of the 2017 IEEE International Conference on Big Knowledge (ICBK), F, 2017 [C]. IEEE.
- [23] Gao S. Predictive modeling of spatio-temporal distribution of burglary alarms based on ConvLSTM network, [D]. Nanjing Normal University. 2020. (郜世伟. 基于ConvLSTM网络的盗窃类警情时空分布预测模型研究 [D]; 南京师范大学, 2020.)
- [24] WANG B, ZHANG D, ZHANG D, et al. Deep learning for real time crime forecasting [J]. *arXiv preprint arXiv:170703340*, 2017.
- [25] ZHANG H, ZHANG J, WANG Z, et al. An Adaptive Spatial Resolution Method Based on the ST-ResNet Model for Hourly Property Crime Prediction [J]. *ISPRS International Journal of Geo-Information*, 2021, 10(5): 314.
- [26] SUN Y, CHEN T, YIN H. Spatial-temporal meta-path guided explainable crime prediction [J]. *World Wide Web*, 2023: 1-27.
- [27] HAN X, HU X, WU H, et al. Risk Prediction of Theft Crimes in Urban Communities: An Integrated Model of LSTM and ST-GCN [J]. *IEEE Access*, 2020, 8: 217222-30.
- [28] WANG Y, GE L, LI S, et al. Deep temporal multi-graph convolutional network for crime prediction; proceedings of the Conceptual Modeling: 39th International Conference, ER 2020, Vienna, Austria, November 3-6, 2020, Proceedings 39, F, 2020 [C]. Springer.
- [29] LI Z, ZHANG X, XU F, et al. A multi-scale video surveillance based information aggregation model for crime prediction [J]. *Alexandria Engineering Journal*, 2023, 73: 695-707.
- [30] QIAN Y, PAN L, WU P, et al. GeST: A grid embedding based spatio-temporal correlation model for crime prediction; proceedings of the 2020 IEEE Fifth International Conference on Data Science in Cyberspace (DSC), F, 2020 [C]. IEEE.
- [31] WANG Zengli, LIU Xuejun, LU Juan, WU Wei, ZHANG Hong. Construction and Spatial-Temporal Analysis of Crime Network: A Case Study on Burglary [J]. *Geomatics and Information Science of Wuhan University*, 2018, 43(5): 759-765. (王增利, 刘学军, 陆娟, et al. 犯罪网络构建及其时空分析——以入室盗窃为例 [J]. *武汉大学学报 (信息科学版)*, 2018, 43(5): 759-765.)
- [32] MA Y, WANG S, AGGARWAL C C, et al. Multi-dimensional graph convolutional networks; proceedings of the Proceedings of the 2019 SIAM international conference on data mining, F, 2019 [C]. SIAM.
- [33] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [J]. *Advances in neural information processing systems*, 2017, 30.
- [34] ZHOU T, MA Z, WEN Q, et al. Fedformer: Frequency enhanced decomposed transformer for long-term series forecasting; proceedings of the International Conference on Machine Learning, F, 2022 [C]. PMLR.
- [35] DOSOVITSKIY A, BEYER L, KOLESNIKOV A, et al. An image is worth 16x16 words: Transformers for image recognition at scale [J]. *arXiv preprint arXiv:201011929*, 2020.
- [36] BERTASIOUS G, WANG H, TORRESANI L. Is space-time attention all you need for video understanding?; proceedings of the ICML, F, 2021 [C].
- [37] MA Y, WANG S, AGGARWAL C, et al. Multi-dimensional Graph Convolutional Networks [J]. *SDM*, 2018, abs/1808.06099: undefined.
- [38] TOBLER W R. A computer movie simulating urban growth in the Detroit region [J]. *Economic geography*, 1970, 46(sup1): 234-40.
- [39] ZHAO X, TANG J. Modeling temporal-spatial correlations for crime prediction; proceedings of the Proceedings of the 2017 ACM on Conference on Information and Knowledge Management, F, 2017 [C].
- [40] YI F, YU Z, ZHUANG F, et al. An integrated model for crime prediction using temporal and

- spatial factors; proceedings of the 2018 IEEE International Conference on Data Mining (ICDM), F, 2018 [C]. IEEE.
- [41] KIPF T N, WELLING M. Semi-supervised classification with graph convolutional networks [J]. arXiv preprint arXiv:160902907, 2016.
- [42] WOO S, PARK J, LEE J-Y, et al. Cbam: Convolutional block attention module; proceedings of the Proceedings of the European conference on computer vision (ECCV), F, 2018 [C].
- [43] TU W-C, LIU M-Y, JAMPANI V, et al. Learning superpixels with segmentation-aware affinity loss; proceedings of the Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, F, 2018 [C].
- [44] ZHANG J, SHEN X, ZHUO T, et al. Brain tumor segmentation based on refined fully convolutional neural networks with a hierarchical dice loss [J]. arXiv preprint arXiv:171209093, 2017.
- [45] YANG Y, LIU X. A re-examination of text categorization methods; proceedings of the Proceedings of the 22nd annual international ACM SIGIR conference on Research and development in information retrieval, F, 1999 [C].

网络首发:

标题: 融合区域空间相似性特征与事件时空特征的犯罪预测模型

作者: 林逸航, 郑坤, 夏书豪, 齐力, 戴杰, 蔡焯, 朱清刚

Doi: 10.13203/j.whugis20230395

收稿日期: 2024-05-30

引用格式:

林逸航, 郑坤, 夏书豪, 等. 融合区域空间相似性特征与事件时空特征的犯罪预测模型[J]. 武汉大学学报(信息科学版), 2024, Doi:10.13203/j.whugis20230395. (LIN Yihang, ZHENG Kun, XIA Shuhao, et al. A Crime Prediction Model Incorporating Regional Spatial Similarity Characteristics and Spatio Temporal Characteristics of Events[J] *Geomatics and Information Science of Wuhan University*, 2024, Doi:10.13203/j.whugis20230395.)

网络首发文章内容和格式与正式出版会有细微差别, 请以正式出版文件为准!

您感兴趣的其他相关论文:

顾及路口转移偏好和当前移动模式的个体驾驶目的地预测方法

桂志鹏, 杨乐, 丁劲宸, 王锦添, 孙云增, 吴华意

武汉大学学报(信息科学版), 2024, 49(5): 819-830.

<http://ch.whu.edu.cn/cn/article/doi/10.13203/j.whugis20210555>

基于 QAR 飞行大数据的空中颠簸风险时空分布模式探索与分析

张林意, 孙华波, 王纯, 余长慧, 卢宾宾

武汉大学学报(信息科学版), 2024, 49(3): 482-490.

<http://ch.whu.edu.cn/cn/article/doi/10.13203/j.whugis20210616>

一种融合多维关系的地理环境时空主题发现方法

朱杰, 张宏军, 廖湘琳, 徐有为

武汉大学学报(信息科学版), 2024, 49(2): 291-302.

<http://ch.whu.edu.cn/cn/article/doi/10.13203/j.whugis20210326>