

基于误差补偿的多模态协同交通流预测模型

吴宇轩, 虞慧群*, 范贵生

(华东理工大学计算机科学与工程系, 上海 200237)

摘要: 交通流量因受周期性特征、突发状况等多重因素影响, 现有模型的预测精度无法满足实际需求。对此, 本文提出了基于误差补偿的多模态协同交通流预测模型(Multimodal Collaborative traffic flow prediction model based on Error Compensation, MCEC)。针对传统预测模型不能兼顾时间序列和协变量的问题, 提出基于小波分析的特征拓展方法, 该方法引入聚类算法得到节假日标签特征, 将拥堵指数、交通事故图、天气信息作为拓展特征, 对特征进行多尺度分解。在训练阶段, 为达到充分学习各部分数据、最优匹配模型的效果, 采用差分整合移动平均自回归模型(Autoregressive Integrated Moving Average Model, ARIMA)、长短期记忆神经网络(Long Short-Term Memory network, LSTM)、限制动态时间规整技术(Dynamic Time Warping, DTW)以及自注意力机制(Self-Attention), 设计了多模态协同模型训练。在误差补偿阶段, 将得到的相应过程值输入基于支持向量机回归(Support Vector Regression, SVR)的误差补偿模块, 对各分量的误差进行学习、补偿, 并重构得到预测结果。使用公开的高速公路数据集对 MCEC 进行验证, 在多个时间间隔下对比实验结果表明, MCEC 在交通流量预测中的平均绝对百分比误差(Mean Absolute Percentage Error, MAPE)达到 17.02%, 比 LSTM-SVR、ConvLSTM (Convolutional Long Short-Term Memory network)、ST-GCN (Spatial Temporal Graph Convolutional Networks)、MFFB (Multi-stream Feature Fusion Block)、Transformer 等预测模型具有更高的预测精度, MCEC 模型具有较好的有效性与合理性。

关键词: 交通流预测; 误差补偿; 多模态协同; 长短期记忆神经网络; 差分整合移动平均自回归模型

基金项目: 国家自然科学基金(No.62276097)

中图分类号: TP183; TP181

文献标识码: A

文章编号: 0372-2112(2024)08-2878-13

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

DOI: 10.12263/DZXB.20230523

Multimodal Cooperative Traffic Flow Prediction Model Based on Error Compensation

WU Yu-xuan, YU Hui-qun*, FAN Gui-sheng

(School of Computer Science and Engineering, East China University of Science and Technology, Shanghai 200237, China)

Abstract: Since the traffic flow is affected by multiple factors such as periodic characteristics and unexpected conditions, the prediction accuracy of existing models cannot satisfy the practical requirements. Under this background, this paper proposes a multimodal collaborative traffic flow prediction model based on error compensation (MCEC). To address the problem that traditional prediction models cannot take account of time series and covariates, this paper proposes a feature expansion method based on wavelet analysis, which introduces a clustering algorithm to obtain holiday labeling features, and uses congestion index, traffic accident map, and weather information as expanded features, and decomposes them on multiple scales. In the training phase, a multimodal collaborative model training was designed by adopting ARIMA (Autoregressive Integrated Moving Average) model, LSTM (Long-Short-Term Memory network), a restricted dynamic time regularization technique, and a self-attentive mechanism to achieve the effect of fully learning each part of the data and optimally matching the model. In the error compensation stage, the obtained corresponding process values are input into the error compensation module based on SVR (Support Vector Regression) to learn and compensate the errors of each component, and reconstruct the prediction results. The MCEC is validated using a publicly available real highway data set. The results of a large number of comparison experiments at multiple time intervals show that the MAPE (Mean Absolute Percentage Error) of MCEC in traffic flow prediction reaches 17.02%, which has a higher prediction accuracy than other prediction mod-

els such as LSTM-SVR, ConvLSTM (Convolutional Long Short-Term Memory network), ST-GCN (Spatial Temporal Graph Convolutional Networks), MFFB (Multi-stream Feature Fusion Block), Transformer, indicating the validity and reasonableness of the MCEC model.

Key words: traffic flow prediction; error compensation; multimodal cooperation; long-short-term memory neural networks; differential integrated moving average autoregressive models

Foundation Item(s): National Natural Science Foundation of China (No.62276097)

1 引言

随着国家经济的高速发展,机动车拥有量快速增长,致使城市交通压力激增,围绕车辆运行出现了一系列交通综合问题,例如道路拥堵严重、交通事故频发、城市交通低效以及能源浪费。国家近年来的交通事故

统计结果显示,每年发生的机动车辆交通事件总数超过 20×10^4 件,导致超过 10×10^9 元的直接财产损失,且有逐年升高趋向。如图 1 所示,其中,图 1(a) 反映了从 2013—2022 年私人汽车拥有量的变化;图 1(b)~(d) 分别展示了从 2013—2021 年逐年的交通事故数、损失金额以及死亡人数的情况。

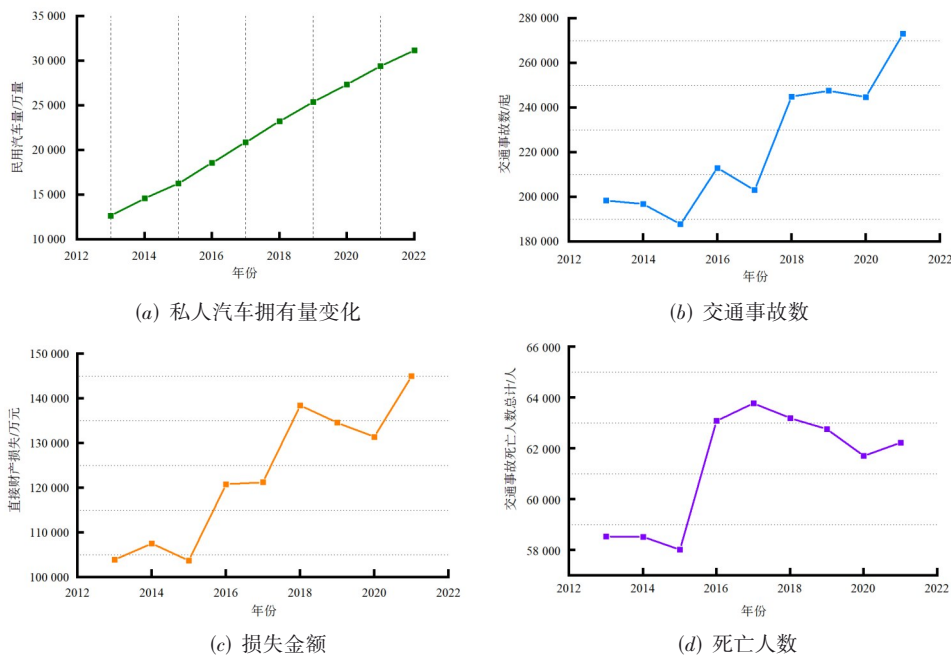


图 1 年度交通信息统计图

在有限的城市交通路网内,单方面的基础道路建设难以有效解决道路交通拥堵、交通安全等问题。将车辆移动、道路通行密切结合,实现高效、安全、便利的出行,有效解决频发的交通问题成为迫切发展的目标。经过多年探索与发展,人们设计并研究了智能交通系统(Intelligent Traffic System, ITS),且取得了重要成果^[1-3]。

智能交通系统 ITS 是基于大数据技术的智能管理系统^[4,5],采用多种先进技术,融合地理信息、天气信息、人口信息、交通设施数据、实时交通数据和综合态势,进行数据综合分析预测,为用户提供优选的行车路线和出行建议,有效减少交通拥堵,舒缓道路交通压力,提高通行效率。

交通流量预测是智能交通系统 ITS 的核心支撑模块。交通流量具有不平稳性、随机性、周期性、动态相关

性和时效性等特征,表现出无规律的波动,为精确预测带来困难,因此,流量预测成为智能交通领域的研究热点^[6,7]。本文利用特定模型学习获得的实时车流量数据规律,预测未来时刻路段的交通流量。随着数据采集技术与智慧城市的内涵发展,交通流量预测进入大数据与多模态数据相结合阶段^[8]。合理引入多模态数据能帮助模型更好地学习交通流量的潜在规律,提高预测精确度。准确的交通流量预测,可预估交通拥堵态势,实现交通智能调度,方便人们出行活动,促进城市有效运行。

为此,提出基于误差补偿的多模态协同交通流量预测模型。通过特征拓展模块实现多模态数据拓展,根据小波理论提出多模态协同训练模块,用误差补偿模块辅助修正预测结果,实现全面且准确的交通流量预测。

2 相关工作

智能交通与社会经济发展的联系愈加紧密,智能交通系统的研究成为当今热点研究课题^[9]. 交通流预测是 ITS 的基础信息支撑,也是实现智能交通调度的关键^[10,11],因此,专业人员一直致力于研究高精度的交通流量预测模型,并将其应用于 ITS.

2.1 机器学习

传统交通流量预测模型多数是机器学习中的线性模型,例如差分自回归滑动平均(Autoregressive Integrated Moving Average, ARIMA)模型^[12],季节自回归求和移动平均(Seasonal Autoregressive Integrated Moving Average, SARIMA)模型^[13],基于一维管道流动动量方程的预测模型^[14]以及卡尔曼滤波(Kalman Filtering, KF)模型^[15]等. 但线性模型不适合处理具有随机、不确定、周期性及非线性等特点的交通流量数据,因此, Pamul 等人^[16]提出基于神经网络的交通流量预测方法,并应用于 ITS,提升预测精度,突破线性模型的瓶颈,证明了神经网络能够在信息源不完整、不准确等复杂数据环境下,通过自身结构调整,提取数据特性,对未来做出有效预测,验证了其在预测领域的合理性和可行性.

2.2 深度学习

为进一步解决预测过程中的非线性问题,引入深度学习. 乔松林等人^[17]构建 LSTM-SVR (Long Short-Term Memory network-Support Vector Regression)模型,将神经网络与回归模型结合,提升预测模型准确率,证明在复杂的实际交通流中,基于单一神经网络的预测具有片面性,应针对实际状况,选择合适的模型进行组合与重构,汲取各模型的优点,获得更精准预测结果. 王金峰在文献^[18]中提出结合误差修正模型(Error Correction Model, ECM)和 LSTM (Long Short-Term Memory network)的模型,解决预测过程中误差逐渐偏移问题,证明误差补偿模块的有效性. Zhang 等人^[19]提出基于遗传算法(Genetic Algorithm, GA)、随机森林(Random Forest, RF)和 SVR 的组合方法进行短期交通流量预测. 王圆等人^[13]运用 SARIMA 预测,采用 LSTM 模型对残差进行预测,将结果作为 BP (Back Propagation)网络的输入,结果表明多模型预测能有效发挥模型优点,提高预测精度. 周兰庭等人^[20]为克服混凝土状态预测过程中周期性问题的,提出基于小波分析(Wavelet Analysis, WA)^[21,22]、LSTM 和 ARIMA 的 WA-LSTM-ARIMA 多模型融合预测模型,通过小波分析对原始监测序列进行多尺度分解,提出分别对高频特征与低频特征进行不同预测处理. 陈娇娜等人^[23]为预测高速公路交通事件持续时间,将多阶段自然语言描述的交通事件文本信息与预测

模型相结合,提出基于深度学习的多模态数据持续时间预测架构,这标志着预测技术由单模态进入到多模态、跨模态和跨学科的 AI 阶段^[24-26]. 以上研究对预测各有特点和突破,但均未能有效满足实际应用需要. 鉴于此,本文提出具有更高预测精度,基于误差补偿的多模态协同交通流预测模型,着力解决传统预测模型不能兼顾时间序列和协变量问题,强化了模型针对周期性序列和随机性特征的学习判别能力. 本文从模块开始介绍该模型的设计实现,展示其在公开数据集的对比实验结果,验证模型有效性、合理性.

3 基于误差补偿的多模态协同预测模型

在本节中,主要从3个模块切入介绍基于误差补偿的多模态协同预测模型. 模型分3部分,特征拓展模块实现多模态输入拓展,将特征细分为高频、低频特征. 多模态协同训练模块将高频特征输入改进 LSTM 学习,低频特征则由 ARIMA 模型学习. 误差补偿模块接收预测过程值,学习误差并进行补偿,重构得到预测结果. 预测模型框架如图2所示.

3.1 特征拓展模块

鲁棒性表示算法模型对异常数据的抗干扰能力,而泛化能力则指已训练的模型网络在未见过的、与训练集不同的数据上能否给出合适输出的能力. 为提高交通流量预测模型的泛化性和鲁棒性,设置了特征拓展模块.

3.1.1 多模态拓展

交通流的实际情况基本取决于人的社会行为,综合探究可能影响的因素,因此,引入天气特征、交通指数(Traffic Performance Index, TPI)以及交通事故图来提高预测准确性.

考虑到工作日、休息日和节假日对人们出行意愿和需求的影响,采取对历史交通流量按日求和,使用聚类算法将数据集分为3类,并为每个类别添加标签作为新特征加入输入矩阵的思路,实现节假日标签特征的拓展.

此外,为了更好地考虑突发情况的影响,引入交通事故图来实现图像的多模态拓展. 首先,通过使用残差网络(Residual Network, ResNet),从输入的交通事故图像中提取特征. ResNet 是一种深度卷积神经网络,通过跳跃连接(Skip Connection)和残差单元(Residual Unit)有效解决了深层网络训练中的梯度消失问题. 通过 ResNet 获得高质量且具有较好表达能力的交通事故图像特征.

通过多头设计思路^[27,28],分别设置卷积核大小为 3×3、5×5 和 7×7 的 3 个卷积模块,这些不同尺寸的卷积

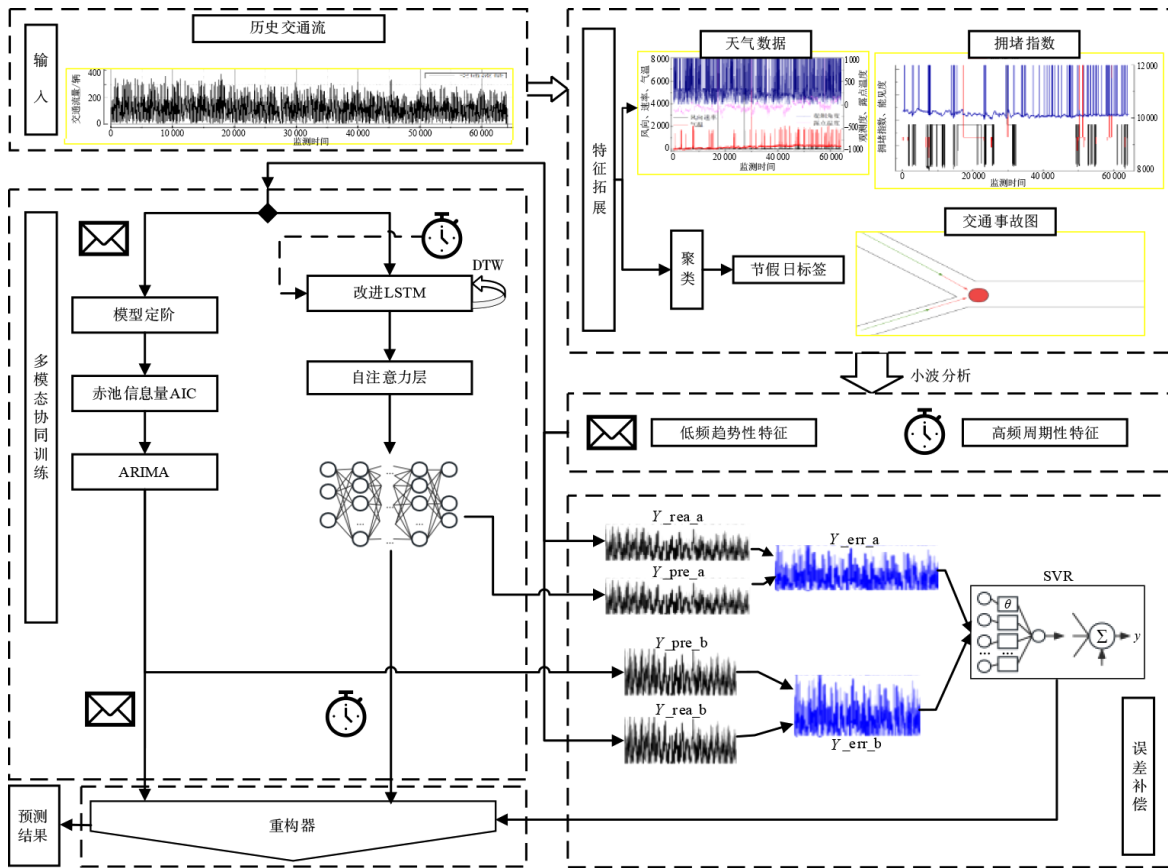


图2 基于误差补偿的多模态协同预测模型示意图

模块旨在增强不同尺度范围内特征捕获的敏感性,提取到包括局部细节和全局上下文等不同范围大小的特征信息,全面分析挖掘交通事故图像的特征信息.最后,分别接入平均池化层与线性层,获取与时间序列相同维度的交通事故图特征向量.平均池化操作能将特征图的空间维度降低,保留重要特征信息,简化后续模型的处理与操作.通过充分利用ResNet提取的交通事故图像特征,有效实现模型特征的多模态表达,更好地理解和学习实时交通流量,如图3所示.

3.1.2 离散小波变换

特征拓展后的数据序列中蕴含了交通流量、天气、温度、交通指数、节假日标签以及事故噪声信息.其中,交通流量、节假日标签、温度对交通流量的影响体现出高频率、周期性特点,其余则体现出较明显的低频率、趋势性特点.对旨在学习周期性的深度学习预测模型而言,低频率、趋势性信息属于模型噪声,为强化模型对周期性特征的学习能力,合理引入低频率、趋势性特征,本文采用离散小波变换进行数据频率分析,并设置协同训练模块.

离散小波变换是基于分解的小波分析方法,能够将序列信号在时间和频率上进行分解与表示.相比传统傅里叶变换或连续小波变换,离散小波变换具有更

好的时频局部性,提供对信号的多尺度分析.离散小波变换结构如图4所示,图中 f_0 为真实序列, f_1, f_2, \dots, f_N 为低频分量, d_1, d_2, \dots, d_N 为高频分量.

在每层中,对低频分量进行分解,保留高频分量部分,直至分解后的子序列无明显周期性变化.通过叠加分解完成的子序列,得到特征拆分后的低频趋势性分量和高频周期性分量.低频趋势性分量是变化频率较低且变化较为随机部分,而高频周期性分量是具有变化频率较高且带有周期性的部分.

3.2 多模态协同训练模块

MCEC多模态协同训练模块分为2个子模块,分别为低频趋势分量训练子模块与高频周期分量训练子模块.模块接收融合了图、数据的多模态拓展信息后,根据信息特征分别调用不同子模块进行学习及预测.

3.2.1 离散小波变换

低频趋势分量训练子模块基于ARIMA模型进行设计.ARIMA模型是线性模型,用于时间序列的分析和预测.该模型由Box和Jenkins提出,结合自回归模型(AR)、移动平均模型(MA)和差分法.AR模型基于过去的观测值预测未来的观测值,MA模型基于过去的误差预测未来的观测值,而差分法则用于平稳化非平稳时间序列.ARIMA模型是对时间序列进行建模和预测的

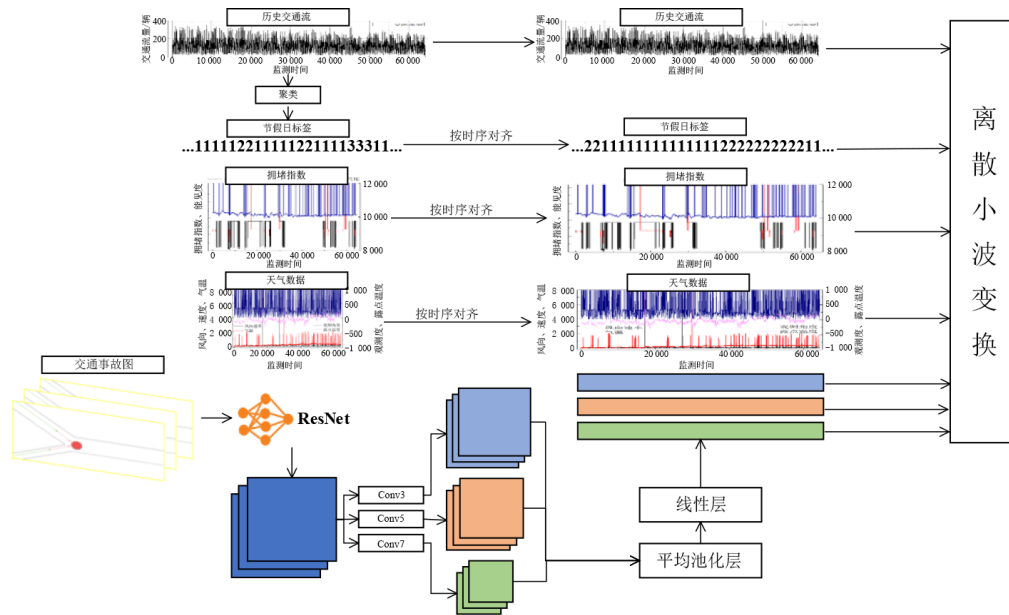


图3 多模态拓展示意图




图4 小波变换分解示意图

重要工具,其公式具体如式(1):

$$y_t = \mu + \sum_{i=1}^p \gamma_i y_{t-i} + \varepsilon_t + \sum_{i=1}^q \theta_i \varepsilon_{t-i} \quad (1)$$

该公式的核心为3个参数,分别为AR模型的 p 阶数、MA模型的 q 阶数以及差分法的 d 阶数,ARIMA模型的建立是围绕着确定3个参数展开的,包含模型识别及定阶、参数估计2个阶段。

模型识别及定阶问题主要是确定差分阶数 d ,一般经过数据可视化,通过观察图确定,通常为1阶或2阶。

参数估计阶段负责确定 p 和 q 的阶数。该阶段中,预测误差用平方误差表示,在误差相同情况下,根据奥卡姆剃刀准则(Occam's Razor),尽可能选用简单模型。因此,在确定模型阶数时,通常采用信息准则函数法,本文采用赤池信息量准则(Akaike Information Criterion, AIC)确定模型阶数。

赤池信息量准则是最小化信息量准则,建立在熵

的概念基础上,AIC如式(2)所示:

$$AIC = -2\ln(L) + 2k \quad (2)$$

其中, L 是该模型下的最大似然, k 是模型变量个数。AIC越小,则代表模型越好。在ARIMA模型参数估计过程中,可以通过最小化AIC的值来确定最优的 p 、 d 、 q 参数阶数。这种方法能避免过度拟合的问题,得到更加准确的预测结果。

确定了参数估计阶段的理论基础后,通过迭代不同的 p 、 q 组合,使用类似于网格搜索的方式进行最佳模型参数的确定,在这个过程中迭代不同的 p 、 q 值,使用预定误差度量评估每个组合的性能。最终,选择具有最小误差度量的 p 、 q 组合作为最佳模型参数。

通过对低频趋势性分量特征进行模型识别及定阶,得到ARIMA模型参数,并对低频趋势分量训练子模块进行学习与预测。

3.2.2 高频周期分量训练子模块

高频周期分量训练子模块基于改进LSTM模型进行设计。长短期记忆神经网络(LSTM)是为增强循环神经网络(Recurrent Neural Network, RNN)在长期工作状态下的记忆能力而提出的改良模型,在RNN基础上额外增加了1个单元状态 c 使每个神经元对来自上1个神经元的信息进行筛选、保留与忘记。其中, c 由遗忘门、输入门以及输出门决定,结构如图5所示。

LSTM能够在长时间序列的训练中,避免丢失过往特征且能防止梯度爆炸、梯度消失等问题的产生。为此,通过引入自注意力层至隐含层和输出层,进一步强化该优势。

自注意力机制是有效的神经网络机制,旨在让神

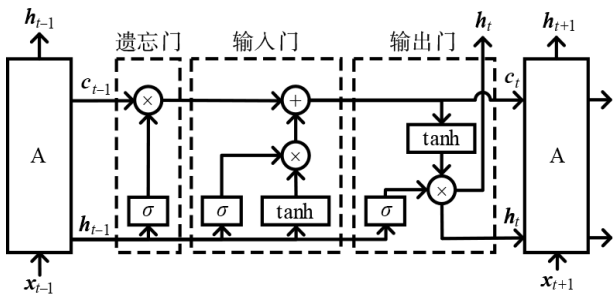


图5 LSTM网络结构示意图

神经网络更好地自我关注和选择,其主要目的是允许神经网络灵活地根据输入数据的特征自主性选择分配和处理信息.核心思想是通过学习数据内部之间的依赖关系来计算每个输入信息的重要度,并进行不同程度的强调.注意力机制如式(3)所示:

$$\begin{aligned}
 M &= \tanh(H) \\
 \alpha &= \text{soft max}(w^T M) \\
 Y &= H\alpha^T
 \end{aligned}
 \tag{3}$$

其中, H 是深度学习模型每个时间步输出构成的矩阵, w 是由学习得到的权重向量, α 是归一化得到的注意力权重.

此外,本文还考虑了损失函数的合理性.在交通流量时序预测领域中,传统 LSTM 模型使用欧氏距离作为损失函数,无法有效反映样本序列与预测序列之间差异.为解决此问题,采用动态时间规整(Dynamic Time Warping, DTW)方法^[29-31].

DTW 是一种计算时间序列间距离的方法,主要解决欧氏距离在评估时间序列相似性时的缺陷. DTW 与欧氏距离不同的是,它允许数据元素根据度量需要重复计算多次.欧氏距离在比较长度一致的序列时表现良好,而 DTW 则适用于比较任意长度的序列,可以在匹配过程中考虑局部范围内时间序列波形的压缩或拉伸变化.这种方法在评估相似性时更准确地反映出 2 个序列之间的距离,区别于欧氏距离,DTW 能够发现并考虑时间序列的局部特征,提高结果准确性和可靠性.

具体而言,该方法使用动态规划思想对序列进行 Time-Warping 处理,使 2 个序列中样点间不再保持一一对应,通过引入相对延展或收缩的偏移量进行匹配,即在局部范围内,压缩或拉伸时间序列的波形.通过这种方式,DTW 可以突破欧氏距离的长度限制和严格对齐假设,使相似但不完全匹配的时间序列也可以进行比较和处理,更贴近实际应用需求.

假设现有 2 个时间序列,分别为 $X = \{x_1, x_2, \dots, x_i, \dots, x_m\}$ 和 $Y = \{y_1, y_2, \dots, y_j, \dots, y_n\}$, 为匹配 X 与 Y 序列,建立 $m \times n$ 的矩阵,其中每个元素代表 2 点间的欧氏距离.规整路径 W 是连续的矩阵元素,代表 2 个序列间的映射,如式(4)所示:

$$W = \{w_1, w_2, \dots, w_i, \dots, w_k\}, k \in [\max(m, n), m+n-1] \tag{4}$$

在寻找最佳路径的过程中,还需要满足边界条件、连续性以及单调性(即路径只能向前不能向后匹配) 3 个原则,如图 6 所示.




图6 DTW最佳路径寻路示意图

在使序列达到最佳匹配后,计算其相似度,以该相似度为损失函数进行整体优化.因此,用 DTW 方法作为 LSTM 模型的损失函数,进一步提高性能和泛化能力.

由于 DTW 的计算基于动态规划思想,其复杂度随矩阵大小指数性增长,因此,需要进行限制.为了解决 DTW 复杂度过高问题,目前主要有 2 种思路:(1)通过设置约束条件限制寻找最佳路径的范围,如 Sakoe-Chiba 和 Itakura-Parallelogram 约束;(2)选取复杂度更低的距离度量方法替代 DTW 进行计算,过滤掉不满足相似性要求的序列,减少 DTW 算法的运算次数.本文采用 Sakio-Chiba 约束与 LB_Yi 下界函数相结合的方式降低模型复杂度.

Sakoe-Chiba 约束利用 2 条沿对角线方向直线构成的条形区域对弯曲路径进行约束,如图 7 所示.设置该约束需要设置弯曲窗口宽度 r ,根据 2 条时间序列的最




图7 Sakoe-Chiba约束示意图

大长度百分比来设置,如式(5)所示:

$$r = \lambda \times \max(m, n) \quad (5)$$

其中, λ 满足 $0 \leq \lambda \leq 1$, m, n 分别为 2 个序列的长度.

本文采用 LB_Yi 下界函数,其函数值小于 DTW 计算结果,在兼顾序列特征的同时保持较低复杂度. 在计算序列间 DTW 时,优先计算下界函数,若下界函数值大于误差阈值,则直接舍弃该对序列,节省计算时间.

LB_Yi 下界函数通过设置 2 条基准线,即其中 1 个时间序列中的最大和最小值,选取另 1 条序列中不在基准线包围区域内的序列点作为特征点. 通过计算这些特征点与对应点之间的距离求和得到下界距离. LB_Yi 函数如式(6)所示:

$$LB_Yi(Q, C) = \sum_{c_i > \max(Q)} d(c_i, \max(Q)) + \sum_{c_i < \min(Q)} d(c_i, \min(Q)) \quad (6)$$

对于高频周期性分量,设计了基于改进 LSTM 模型的高频周期性分量训练子模块,以学习其潜在规律,得到高频周期性特征的预测结果. 该模型可有效学习数据的时间序列特征,实现更准确预测. 相关原理如式(7):

$$\text{forget}_i = \sigma(W^f[h_{i-1}, x_i] + b^f) \quad (7)$$

式(7)中, σ 是 Sigmoid 函数,权重参数为 W^f ,偏置参数为 b^f .

$$\text{input}_i = \sigma(W^i[h_{i-1}, x_i] + b^i) \quad (8)$$

式(8)是输入门的逻辑公式,其中输入门的权重参数为 W^i ,偏置参数为 b^i .

$$\text{output}_i = \sigma(W^o[h_{i-1}, x_i] + b^o) \quad (9)$$

式(9)中,权重参数为 W^o ,偏置参数为 b^o .

$$c_i = c_{i-1} \cdot \text{forget}_i + \text{input}_i \cdot \tanh(W^c[h_{i-1}, x_i] + b^c) \quad (10)$$

式(10)是神经网络中神经元的单元状态方程, \tanh 函数是单元状态 c 的激活函数, W^c, b^c 分别为神经元状态 c 的权重参数与偏置参数. 隐藏状态 h_i 如式(11)所示:

$$h_i = \text{output}_i \cdot \tanh(c_i) \quad (11)$$

3.3 误差补偿模块

误差补偿模块的设计基于 SVR(Support Vector Regression)模型,分别对高频周期性特征和低频趋势性特征的误差进行学习. 通过对 2 组误差的学习,准确地对不同特征所带来的误差进行处理. 误差补偿相对准确地还原原始信号中的各分量,得到更精准的预测结果^[32-34].

支持向量机回归的基本思想是在给定的精度和拟合函数复杂性之间达到平衡,以最小化正确分类为风险,构建能最大化边界内的数据点数量和距离的超平面达到最小化回归误差目的,其原理是在已知样本集构建 1 个回归模型: $f(x) = w^T x + b$, 使 $f(x)$ 与 y 尽可能接近,其中, w 是超平面的法向量, b 是位移项. 传统的回

归问题仅认为 $f(x) = y$ 时,模型损失才为 0,但 SVR 模型允许 $f(x)$ 与 y 存在一定误差 ε , 当且仅当 $|f(x) - y| > \varepsilon$ 时,才认为回归模型存在损失,相当于以 $f(x) + \varepsilon$ 和 $f(x) - \varepsilon$ 为上下界所围成的区域,如图 8 所示.




图 8 支持向量回归(SVR)示意图

通过引入核函数将数据映射到高维空间,从而将 SVR 应用于非线性回归问题;引入松弛因子,通过对偶原理和拉格朗日乘子法得到 SVR 模型的核心表达式,即

$$f(x) = \sum_{i=1}^m (\hat{a}_i - a_i) k(x_i, x) + b \quad (12)$$

对高频周期性特征和低频趋势性特征的误差进行学习. 首先,选取训练集前 65% 的数据训练 ARIMA 模型和改进 LSTM 模型,根据其余训练集数据分别得出高频特征与低频特征的预测结果. 然后将预测结果与实际测试集数据相减得到误差数据,并用其训练 SVR 误差补偿模型. 最后,应用机器学习方法和神经网络技术实现对高频预测特征、低频预测特征、高频误差补偿特征以及低频误差补偿特征的重构^[35]. 首先,设置 1 个投影头(Projection Head),它能够将输入数据投影到 1 个维度相异的表示空间. 通过对投影后的数据进行一系列非线性变换和降维操作,得到更有意义且具有更好区分性的特征表示^[36]. 接着,引入全连接层(Fully Connected Layer),它利用各个特征之间的复杂关系,加工和整合投影头输出的特征表示. 通过 Projection Head 与全连接层的组合变换,实现对高频预测特征、低频预测特征、高频误差补偿特征及低频误差补偿特征的有效重构,得到最终交通流量预测结果.

4 实验分析

为了验证本文提出预测模型的性能优势,选择 4 个指标进行评估,分别是:绝对值平均误差(Mean Absolute Percentage Error, MAPE)、相对均方根误差(relative Root Mean Square Error, rRMSE)、相对平均绝对误差(relative Mean Absolute Error, rMAE)以及均方根误差

(Root Mean Square Error, RMSE). 这 4 个指标能全面反映模型的预测性能, 检验其准确度. 通过对这些指标进行评估, 本文的预测模型将获得客观评价, 确保研究结论的可靠性和科学性. 各指标的计算公式如下:

$$\text{MAPE} = \frac{1}{m} \sum_{i=1}^m \left| \frac{f_i - \hat{f}_i}{f_i} \right| \quad (13)$$

$$\text{rRMSE} = \sqrt{\frac{\frac{1}{m} \sum_{i=1}^m (f_i - \hat{f}_i)^2}{\frac{1}{m} \sum_{i=1}^m f_i}} \times 100\% \quad (14)$$

$$\text{rMAE} = \frac{\sum_{i=1}^m |f_i - \hat{f}_i|}{\sum_{i=1}^m f_i} \times 100\% \quad (15)$$

$$\text{RMSE} = \sqrt{\frac{1}{m} \sum_{i=1}^m (f_i - \hat{f}_i)^2} \quad (16)$$

4.1 实验数据集

本实验以 2013 年 1 月 1 日—2013 年 8 月 31 日的编号 3100 道路的交通流量、气候观测点数据、交通拥堵指数 (Traffic Performance Index, TPI) 数据以及交通事故图提取信息为实验数据, 以 5、10、15 min 为时间间隔对相关特征进行统计, 得到大小为 $69\ 684 \times 33$ 的时序矩阵. 3100 号道路位于圣弗朗西斯科, 道路交通流量折线图如图 9 所示, 可以从图中观察到交通流量具有周期性性质.




图 9 3100 号道路交通流量折线图

4.2 数据预处理

原数据集包含不同时段、不同道路的交通流量, 以及天气特征、TPI 及交通事故图等信息, 因此, 需要对数据集进行预处理、拓展特征、基于小波分析的特征拆解.

(1) 考虑原数据集的复杂性, 首先提取图信息, 接着进行数据清洗以去除缺失值和异常值.

(2) 根据原数据集的分时交通流量, 计算日交通流

量, 通过聚类算法得到节假日标签.

(3) 根据原数据集采样间隔 5 min 的交通流量, 处理得到采样间隔分别为 10 min 和 15 min 的数据.

(4) 基于小波多频率分析对特征进行多频度拆解, 得到低频趋势分量与高频周期分量.

(5) 为降低训练规模, 对部分特征进行归一化处理.

(6) 划分前 80% 的数据集作为训练集, 后 20% 的数据集作为验证集.

低频趋势性分量子模块基于 ARIMA 模型, 以差分处理后的低频序列作为输入, 对低频序列的二阶差分序列见图 10. 可以观察到经过差分后的时序数据没有明显的趋势和季节性变化, 具有稳定性.

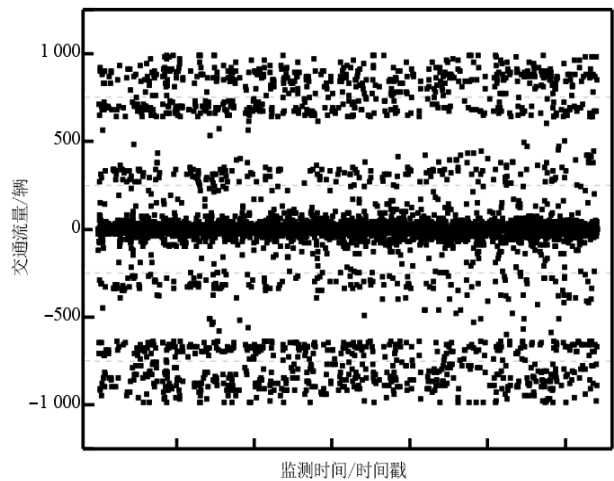


图 10 二阶差分低频序列

4.3 实验结果

本文使用 Pytorch 框架进行神经网络模型训练. 为进一步探究基于误差补偿的多模态协同预测模型处理时序序列的优越性, 将提出的方法与 LSTM 神经网络模型、LSTM-SVR 神经网络模型、RNN 神经网络模型、GRU (Gated Recurrent Unit) 神经网络模型、ConvLSTM 卷积长短期记忆神经网络^[37]、ST-GCN (Spatial Temporal Graph Convolution Networks) 时空图卷积网络^[38]、MFFB (Multi-stream Feature Fusion Block) 多流特征融合模型^[39]及 Transformer 模型^[40]进行对比, 分别采用 3 个分辨率 5 min、10 min、15 min 下的交通流量数据. 以采样间隔为 15 min 的数据集为例, 预测结果如图 11 所示.

从图 11 及放大图块可以观察到, 在该数据集上, MCEC 模型的预测结果比 LSTM-SVR、ConvLSTM、ST-GCN、MFFB、Transformer 等模型的预测结果更精准. 表 1 给出不同模型在 3 种不同数据分辨率 5 min、10 min、15 min 下预测结果的误差指标, 可以看出基于误差补偿的多模态协同预测 (Multimodal Collaborative

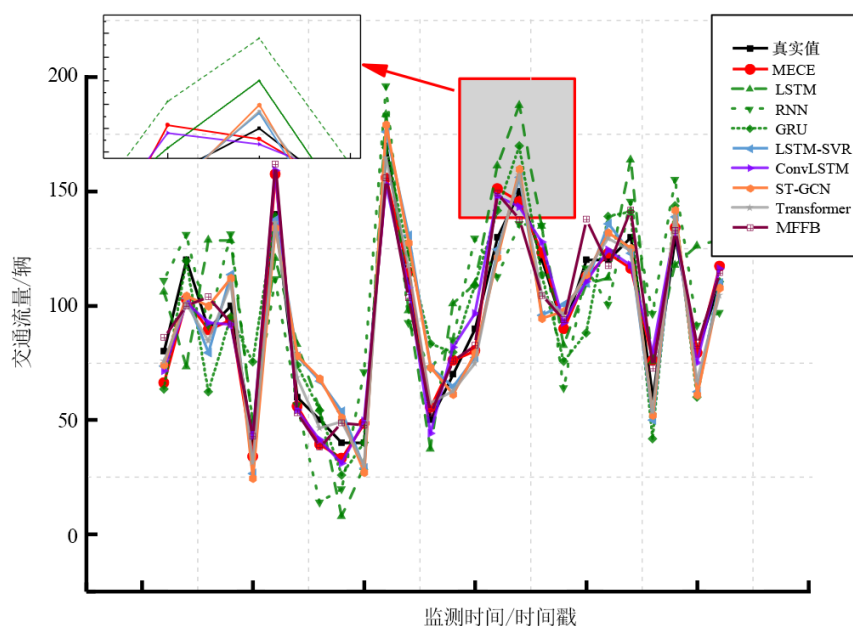


图 11 模型交通流量预测结果图

traffic flow prediction model based on Error Compensation, MCEC)模型预测的结果最优.

如表 1 所示,使用了 RNN、GRU、LSTM、LSTM-SVR、

ST-GCN、MFFB、ConvLSTM、Transformer 和 MCEC 这 9 种模型来预测不同采样间隔的交通流量,并展示其在评价指标方面的表现,直观对比如图 12 所示.

表 1 模型交通流量预测结果评价指标表

模型	MAPE/%			rRMSE/%			rMAE/%			RMSE		
	5 min	10 min	15 min	5 min	10 min	15 min	5 min	10 min	15 min	5 min	10 min	15 min
RNN	19.11	19.07	19.23	10.79	10.68	11.03	9.32	9.31	9.46	1.049	1.041	1.093
GRU	18.89	18.75	19.01	10.63	10.62	10.92	9.19	9.07	9.41	1.034	1.029	1.071
LSTM	18.78	18.76	18.96	10.61	10.59	10.78	9.18	9.11	9.37	1.032	1.028	1.057
LSTM-SVR ^[17]	18.07	17.79	18.31	10.21	10.07	10.46	8.83	8.81	9.04	0.995	0.993	1.021
ST-GCN ^[38]	18.13	17.78	18.26	10.26	9.97	10.43	8.87	8.74	8.97	1.003	0.988	1.019
MFFB ^[39]	17.07	17.03	17.16	9.67	9.59	9.91	8.29	8.26	8.74	0.929	0.915	1.012
ConvLSTM ^[37]	17.17	17.11	17.27	9.71	9.62	10.08	8.35	8.27	8.81	0.934	0.919	1.015
Transformer ^[40]	17.98	17.54	18.05	9.84	9.78	10.29	8.74	8.59	8.92	0.967	0.936	1.018
MCEC	17.02	16.96	17.24	9.56	9.54	9.92	8.28	8.23	8.73	0.929	0.913	1.014

图 12 (a) 是 MAPE 的指数柱状图, 图 12 (b) 是 RMSE 指数折线图. 其中, RMSE 是用来衡量预测值和实际值之间的偏差, 其值越小说明预测误差越小. 通过对比 5 个模型的 RMSE 值, 可以发现基于误差补偿的多模态协同预测模型的表现更好, 其预测结果的评价指标值小于其他经典模型, 这表明该模型对道路交通流量预测具有更好的准确性和有效性.

为进一步验证模型的有效性, 分别对特征拓展模块(模块 A)、多模态协同训练模块(模块 B)以及误差补

偿模块(模块 C)进行消融实验. 设置 ARIMA-LSTM 模型为基准模型, 依次添加上述模块, 在数据采样间隔为 5 min 的数据集上进行消融实验, 结果如表 2 所示.

通过柱状可视化方法, 分析消融实验中各模块对预测结果的影响, 如图 13 所示. 特征拓展模块、多模态协同训练模块以及误差补偿模块均对基准模型有所提升, 且模块与模块结合能进一步提升道路交通流量预测模型的准确性. 综上, 本文方法的有效性得到证明.

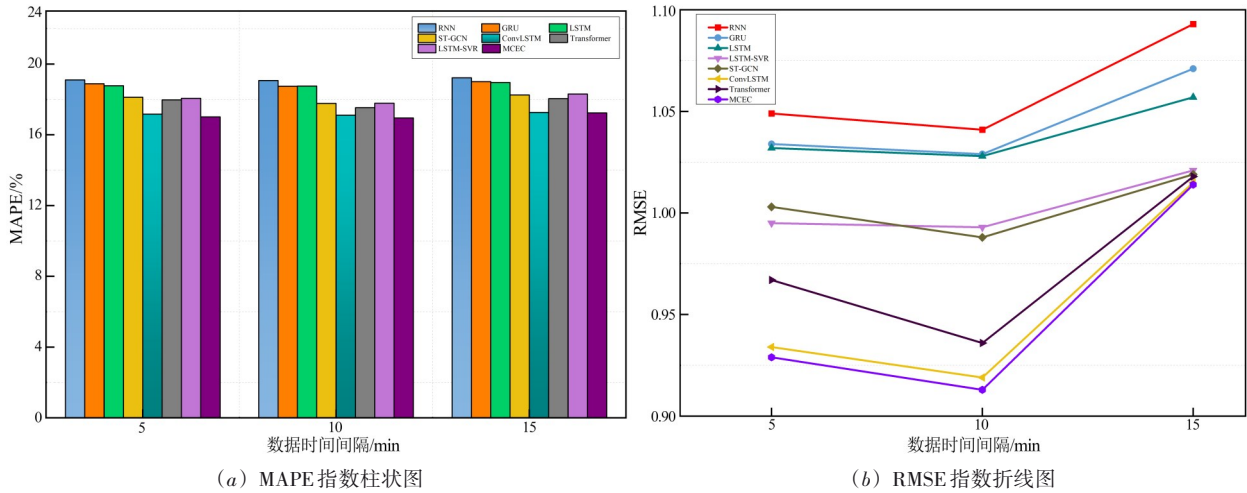


图 12 模型指数对比示意图

表 2 模块消融实验评价指标表

模型	MAPE/%	rRMSE/%	rMAE/%	RMSE
ARIMA-LSTM	18.48	10.57	9.07	1.014
ARIMA-LSTM-A	18.42	10.52	8.97	9.89
ARIMA-LSTM-B	18.46	10.55	9.01	1.006
ARIMA-LSTM-C	18.39	10.47	8.84	9.85
ARIMA-LSTM-AB	17.89	10.13	8.67	0.961
ARIMA-LSTM-AC	17.34	9.72	8.34	0.937
ARIMA-LSTM-BC	17.67	9.84	8.41	0.953
MCEC	17.02	9.56	8.28	0.929




图 13 模块消融实验评价指标条形堆积图

5 结论

为有效解决交通流量预测模型受周期性特征、突发状况和时变特点等多重因素影响导致精度无法满足需求的问题,本文提出了基于误差补偿的多模态协同交通流量预测(MCEC)模型,实现了对道路交通流量的有效预测.通过加入特征拓展模块与误差补偿模块,解决了传统预测模型不能兼顾时间序列和协变量的问题,提高模型可靠性与准确性.通过设置多模态协同训练模块,达到充分学习历史数据及模型最优匹配效果,

进一步提高模型准确性、泛化性与鲁棒性.

交通流变化是1个复杂过程,通过单一交通参数来预测交通状态会因信息不全导致判断结果存在二义性.本文模型适用于有较为全面、完整数据且拓扑关联度相对较低的情景,暂时未能多方面引入路网拓扑、人口分布、车辆类别、城市布局等信息.此外,本文工作专注于提高混合预测模型对周期性和时变特点等因素的学习能力,依旧是从模型角度出发做出的理论改进,后续将进一步研究时空路网与多模态信息结合.

参考文献

- [1] 郭玉坤,李永政.国外公共交通导向型城市发展研究综述:基于建筑环境对公共交通客流量影响的视角[J].城市问题,2014(7):26-31.
GUO Y K, LI Y Z. Research review on foreign TOD urban development: Based on the perspective of influences on transit ridership by built environment[J]. Urban Problems, 2014(7): 26-31. (in Chinese)
- [2] MILLER I, CAMPBELL M. Sensitivity analysis of a tightly-coupled GPS/INS system for autonomous navigation[J]. IEEE Transactions on Aerospace and Electronic Systems, 2012, 48(2): 1115-1135.
- [3] 高海军,王健,陈龙,等.空中交通流量管理研究综述[J].控制工程,2003,10(6):484-487,517.
GAO H J, WANG J, CHEN L, et al. Review on the research of air traffic flow management[J]. Control Engineering of China, 2003, 10(6): 484-487, 517. (in Chinese)
- [4] 王晓宇,赵鹏,陈莹锋.新基建下的智能交通系统发展综述[J].上海公路,2022,2:91-95,167-168.
WANG X Y, ZHAO P, CHEN Y F. Development of ITS under new infrastructure[J]. Shanghai Highways, 2022, 2: 91-95, 167-168. (in Chinese)

- [5] 赵娜, 袁家斌, 徐晗. 智能交通系统综述[J]. 计算机科学, 2014, 41(11): 7-11, 45.
ZHAO N, YUAN J B, XU H. Survey on intelligent transportation system[J]. Computer Science, 2014, 41(11): 7-11, 45. (in Chinese)
- [6] 邵虎, 卓越, 刘鹏杰, 等. 城市交通流量估计的运筹学方法[J]. 运筹学学报, 2023, 27(2): 27-48.
SHAO H, ZHUO Y, LIU P J, et al. Operational research methods for urban traffic flow estimation[J]. Operations Research Transactions, 2023, 27(2): 27-48. (in Chinese)
- [7] 胡冰华. 基于时空数据的交通流量预测神经网络算法研究综述[J]. 计算机产品与流通, 2023(3): 95-97.
HU B H. A review of neural network algorithms for traffic flow prediction based on spatio-temporal data[J]. Computer Products and Circulation, 2023(3): 95-97. (in Chinese)
- [8] 陆化普, 孙智源, 屈闻聪. 大数据及其在城市智能交通系统中的应用综述[J]. 交通运输系统工程与信息, 2015, 15(5): 45-52.
LU H P, SUN Z Y, QU W C. Big data and its applications in urban intelligent transportation system[J]. Journal of Transportation Systems Engineering and Information Technology, 2015, 15(5): 45-52. (in Chinese)
- [9] DAI G W, MA C X, XU X C. Short-term traffic flow prediction method for urban road sections based on space-time analysis and GRU[J]. IEEE Access, 2019, 7: 143025-143035.
- [10] MACKENZIE J, RODDICK J F, ZITO R. An evaluation of HTM and LSTM for short-term arterial traffic flow prediction[J]. IEEE Transactions on Intelligent Transportation Systems, 2019, 20(5): 1847-1857.
- [11] WAGNER-MUNS I M, GUARDIOLA I G, SAMARANAYKE V A, et al. A functional data analysis approach to traffic volume forecasting[J]. IEEE Transactions on Intelligent Transportation Systems, 2018, 19(3): 878-888.
- [12] 殷礼胜, 唐圣期, 李胜, 等. 基于整合移动平均自回归和遗传粒子群优化小波神经网络组合模型的交通流预测[J]. 电子与信息学报, 2019, 41(9): 2273-2279.
YIN L S, TANG S Q, LI S, et al. Traffic flow prediction based on hybrid model of auto-regressive integrated moving average and genetic particle swarm optimization wavelet neural network[J]. Journal of Electronics & Information Technology, 2019, 41(9): 2273-2279. (in Chinese)
- [13] 王圆. 基于 SARIMA 和 LSTM 模型的城市车流量预测[D]. 湘潭: 湘潭大学, 2020.
WANG Y. Based on SARIMA and LSTM Model Smart City Traffic Forecast[D]. Xiangtan: Xiangtan University, 2020. (in Chinese)
- [14] 吴正. 交通流的动力学模拟与测量方法[J]. 复旦学报(自然科学版), 1991, 30(1): 111-117.
WU Z. Traffic flow dynamic modeling[J]. Journal of Fudan University, 1991, 30(1): 111-117. (in Chinese)
- [15] 刘美琪, 焦朋朋, 孙拓. 城市轨道交通进站客流量短时预测模型研究[J]. 城市轨道交通研究, 2015, 18(11): 13-17, 29.
LIU M Q, JIAO P P, SUN T. On short-term forecasting model of passenger flow in urban rail transit[J]. Urban Mass Transit, 2015, 18(11): 13-17, 29. (in Chinese)
- [16] TERESA PAMUŁ A. Road traffic parameters prediction in urban traffic management systems using neural networks[J]. Transport Problems, 2011, 6(3): 123-128.
- [17] 乔松林, 孙仁诚, 刘吉. 基于深度学习的短时交通流量预测[J]. 青岛大学学报(自然科学版), 2017, 30(4): 65-69.
QIAO S L, SUN R C, LIU J. Short-term traffic flow forecast based on deep learning[J]. Journal of Qingdao University (Natural Science Edition), 2017, 30(4): 65-69. (in Chinese)
- [18] 王金锋, 孙连英, 张天, 等. 基于 K-LSTM-ecm 模型的城市轨道交通短时客流预测[J]. 制造业自动化, 2022, 44(5): 103-107, 133.
WANG J F, SUN L Y, ZHANG T, et al. Short-term passenger flow prediction of urban rail transit based on K-LSTM-ecm model[J]. Manufacturing Automation, 2022, 44(5): 103-107, 133. (in Chinese)
- [19] ZHANG L Z, ALHARBE N R, LUO G C, et al. A hybrid forecasting framework based on support vector regression with a modified genetic algorithm and a random forest for traffic flow prediction[J]. Tsinghua Science and Technology, 2018, 23(4): 479-492.
- [20] 周兰庭, 柳志坤, 徐长华. 基于 WA-LSTM-ARIMA 的混凝土坝变形组合预测模型[J]. 人民黄河, 2022, 44(1): 124-128.
ZHOU L T, LIU Z K, XU C H. Concrete dam deformation combination prediction based on WA-LSTM-ARIMA[J]. Yellow River, 2022, 44(1): 124-128. (in Chinese)
- [21] 杨丽. 小波理论在大坝变形监测数据分析中的应用研究[D]. 西安: 西安理工大学, 2010.
YANG L. Applied Research of Wavelet Theory in Dam Deformation Monitoring Data Analysis[D]. Xi'an: Xi'an University of Technology, 2010. (in Chinese)
- [22] 王新洲, 范千, 许承权, 等. 基于小波变换和支持向量机

- 的大坝变形预测[J]. 武汉大学学报(信息科学版), 2008, 33(5): 469-471, 507.
- WANG X Z, FAN Q, XU C Q, et al. Dam deformation prediction based on wavelet transform and support vector machine[J]. Geomatics and Information Science of Wuhan University, 2008, 33(5): 469-471, 507. (in Chinese)
- [23] 陈娇娜, 陶伟俊, 靳引利, 等. 多模态文本信息的高速公路交通事故持续时间预测[J]. 中国安全生产科学技术, 2023, 19(6): 180-186.
- CHEN J N, TAO W J, JIN Y L, et al. Prediction of traffic incident duration on expressway based on multimodal text information[J]. Journal of Safety Science and Technology, 2023, 19(6): 180-186. (in Chinese)
- [24] 张轶, 翟盛华, 陶海红. 雨衰时间序列的混沌识别与预测[J]. 电子学报, 2023, 51(2): 365-371.
- ZHANG Y, ZHAI S H, TAO H H. Chaos identification and prediction for rain attenuation time series[J]. Acta Electronica Sinica, 2023, 51(2): 365-371. (in Chinese)
- [25] 张聿远, 闫文君, 张立民. 基于多模态特征融合网络的空时分组码识别算法[J]. 电子学报, 2023, 51(2): 489-498.
- ZHANG Y Y, YAN W J, ZHANG L M. Space-time block code recognition algorithm based on multi-modality features fusion network[J]. Acta Electronica Sinica, 2023, 51(2): 489-498. (in Chinese)
- [26] 张若楠, 安高云. 基于多模态特征转换嵌入的场景图生成[J]. 信号处理, 2023, 39(1): 51-60.
- ZHANG R N, AN G Y. Multimodal feature translating embedding based scene graph generation[J]. Journal of Signal Processing, 2023, 39(1): 51-60. (in Chinese)
- [27] 杨真真, 孙雪, 邵静, 等. 基于多尺度偶数卷积注意力 U-Net 的医学图像分割[J]. 信号处理, 2022, 38(9): 1912-1921.
- YANG Z Z, SUN X, SHAO J, et al. Medical image segmentation based on multiscale even convolution attention U-Net[J]. Journal of Signal Processing, 2022, 38(9): 1912-1921. (in Chinese)
- [28] 周隽杰, 付东翔. 基于 Attention-LSTM-Kalman 建模的风洞动态流量软测量[J]. 数据采集与处理, 2022, 37(2): 463-470.
- ZHOU J J, FU D X. Soft measurement of wind tunnel dynamic flow based on Attention-LSTM-Kalman modeling[J]. Journal of Data Acquisition and Processing, 2022, 37(2): 463-470. (in Chinese)
- [29] 刘宜成, 李志鹏, 吕淳朴, 等. 基于动态时间调整的时空图卷积路网交通流量预测[J]. 交通运输系统工程与信息, 2022, 22(3): 147-157, 178.
- LIU Y C, LI Z P, LV C P, et al. Network-wide traffic flow prediction research based on DTW algorithm spatial-temporal graph convolution[J]. Journal of Transportation Systems Engineering and Information Technology, 2022, 22(3): 147-157, 178. (in Chinese)
- [30] LU H P, YANG F. A network traffic prediction model based on wavelet transformation and LSTM network[C]//2018 IEEE 9th International Conference on Software Engineering and Service Science (ICSESS). Piscataway: IEEE, 2018: 1-4.
- [31] TIAN Y X, PAN L. Predicting short-term traffic flow by long short-term memory recurrent neural network [C]//2015 IEEE International Conference on Smart City/SocialCom/SustainCom (SmartCity). Piscataway: IEEE, 2015: 153-158.
- [32] 张峻屹, 李双金, 马爽. 基于市民生活行为学的交通行为研究综述[J]. 交通运输系统工程与信息, 2022, 22(2): 1-16, 63.
- ZHANG J Y, LI S J, MA S. Overview of life-oriented travel behavior research[J]. Journal of Transportation Systems Engineering and Information Technology, 2022, 22(2): 1-16, 63. (in Chinese)
- [33] LI T, ZHANG J B, BAO K N, et al. AutoST: Efficient neural architecture search for spatio-temporal prediction [C]//Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York: ACM, 2020: 794-802.
- [34] 李文静, 王潇潇. 基于简化型 LSTM 神经网络的时间序列预测方法[J]. 北京工业大学学报, 2021, 47(5): 480-488.
- LI W J, WANG X X. Time series prediction method based on simplified LSTM neural network[J]. Journal of Beijing University of Technology, 2021, 47(5): 480-488. (in Chinese)
- [35] 王英伟, 马树才. 基于 ARIMA 和 LSTM 混合模型的时间序列预测[J]. 计算机应用与软件, 2021, 38(2): 291-298.
- WANG Y W, MA S C. Time series forecasting based on ARIMA_DLSTM hybrid model[J]. Computer Applications and Software, 2021, 38(2): 291-298. (in Chinese)
- [36] SONG X, LI W J, MA D F, et al. A match-then-predict method for daily traffic flow forecasting based on group method of data handling[J]. Computer-Aided Civil and Infrastructure Engineering, 2018, 33(11): 982-998.
- [37] SHI X J, CHEN Z R, WANG H, et al. Convolutional

LSTM network: A machine learning approach for precipitation nowcasting[C]//Proceedings of the 28th International Conference on Neural Information Processing Systems. New York: ACM, 2015: 802-810.

- [38] BING Y, YIN H T, ZHU Z X. Spatio-temporal graph convolutional networks: A deep learning framework for traffic forecasting[EB/OL]. (2017-09-14) [2024-01-03]. <http://arxiv.org/abs/1709.04875>.
- [39] LI Z S, XIONG G, TIAN Y L, et al. A multi-stream feature fusion approach for traffic prediction[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(2): 1456-1466.
- [40] LI G Y, ZHONG S H, DENG X D, et al. A lightweight and accurate spatial-temporal transformer for traffic forecasting[J]. IEEE Transactions on Knowledge and Data Engineering, 2023, 35(11): 10967-10980.

作者简介



吴宇轩 男, 1999 年 8 月出生, 湖北武汉人. 华东理工大学计算机科学与工程系博士生. 主要研究方向为时序预测与多模态技术.
E-mail: wyuxuan@mail.ecust.edu.cn



虞慧群 男, 1967 年 2 月出生, 华东理工大学信息学院教授、博士生导师、CCF 高级会员. 主要研究方向为软件工程、可信计算、云计算、形式化方法.
E-mail: yhq@ecust.edu.cn



范贵生 男, 1980 年 7 月出生, 华东理工大学信息学院副教授、博士生导师、CCF 专业会员. 主要研究方向为复杂软件系统的形式化方法、服务计算、软件架构分析技术.
E-mail: gsfan@ecust.edu.cn