

基于 AGRU-Trans 融合模型的特长海底隧道交通量预测

黄欣¹, 谢文红², 陈耀鹏¹, 李翔³, 张素磊^{1,4,*}

(1. 青岛理工大学 土木工程学院, 青岛 266525; 2. 台州市杭绍台高速公路有限公司, 台州 318000;

3. 青岛国信建设投资有限公司, 青岛 266000; 4. 青建集团股份有限公司, 青岛 266071)

摘要: 为了使海底隧道交通管控部门更好地掌握准确的交通数据, 给出行者提供更好的交通引导, 通过对循环神经网络和 Transformer 算法的研究, 结合 GRU 与 Transformer 模型算法优点并加入自注意力机制, 提出一种基于 AGRU-Trans 融合模型的海底隧道交通量预测模型。选取胶州湾海底隧道市南—黄岛交通运行数据, 通过 AGRU-Trans 融合模型与 3 种基准模型对比发现, LSTM, Transformer, GRU 模型的平均绝对误差 (MAE) 相比 AGRU-Trans 分别大了 31.48%, 67.54%, 20.57%; 均方根误差 (RMSE) 分别增长了 35.63%, 38.45%, 32.02%。结果表明: AGRU-Trans 融合模型的预测结果与真实数据贴合性最好, 预测精度均高于基准模型, 因此, 基于此方法可为胶州湾海底隧道管理部门对车辆进行精细化诱导及管控提供理论参考。

关键词: 海底隧道; 交通量预测; AGRU-Trans 融合模型; 循环神经网络; Transformer 模型

中图分类号: U491 **文献标志码:** A **文章编号:** 1673-4602(2024)01-0118-08

Traffic volume prediction of extra-long subsea tunnel based on AGRU-Trans fusion model

HUANG Xin¹, XIE Wenhong², CHEN Yaopeng¹, LI Xiang³, ZHANG Sulei^{1,4,*}

(1. School of Civil Engineering, Qingdao University of Technology, Qingdao 266525, China;

2. Taizhou-Hangzhou-Shaotai Expressway Co. Ltd., Taizhou 318000, China;

3. Qingdao Conson Construction & Investment Co. Ltd., Qingdao 266000, China;

4. Qingjian Group Co. Ltd., Qingdao 266071, China)

Abstract: In order to help the subsea tunned traffic control department of master accurate traffic data and provide better traffic guidance to travelers, this paper studies recurrent neural network (RNN) and Transformer algorithm, combines the advantages of GRU and Transformer model algorithm and adds self-attention mechanism. It finally proposes a traffic volume prediction model of subsea tunnel based on AGRU-Trans fusion model. It then selects the Shinan-Huangdao traffic operation data of Jiaozhou Bay subsea tunnel and compares the AGRU-Trans fusion model with three benchmark models. It is found that the mean absolute error (MAE) values of LSTM, Transformer and GRU models are respectively 31.48%, 67.54% and 20.57% larger than that of AGRU-Trans. Root mean square error (RMSE) increased by 35.63%, 38.45% and 32.02% respectively. The results show that

收稿日期: 2022-07-12

基金项目: 浙江省交通运输厅科技计划项目 (2021068)

作者简介: 黄欣 (1998-), 女, 黑龙江齐齐哈尔人。硕士, 研究方向为隧道及地下工程。E-mail: 1105738373@qq.com。

* 通信作者: 张素磊 (1983-), 男, 山东临朐人。博士 (后), 副教授, 主要从事地下结构健康诊断、地下工程施工及地下工程运营管理等方面的研究。E-mail: zhangsulei@qut.edu.cn。

the prediction results of AGRU-Trans fusion model fit the real data best, and the prediction accuracy is higher than that of the benchmark models. Therefore, it can be concluded that this model can provide theoretical reference for the management department of Jiaozhou Bay subsea tunnel to conduct refined vehicle guidance and control.

Key words: subsea tunnel; traffic volume prediction; AGRU-Trans fusion model; recurrent neural network(RNN); Transformer model

随着社会经济水平的发展与城市规模的扩大,我国城市机动化水平日益提高,海底隧道里程也在不断增加,交通拥堵问题愈发严重,交通事故频发,因此迫切需要有效的交通控制和诱导策略。构建智慧交通系统(ITS)能够更好地改善交通拥堵,缩短出行时间,提高通行安全性。交通量预测通过实时交通数据的信息滚动来预测未来的交通状况,是对车辆进行精细化诱导及管控的重要依据。

目前,国内外针对交通量预测的相关研究提出了大量预测方法。WILLIAMS 等^[1]提出了季节性 ARIMA 模型并结合交通量周期性的特征,来提高交通量预测的精度;李文勇等^[2]对 ARIMA 模型交通流预测方法进行改进,构建实际交通流量数据均值和方差之间的函数关系,并因此推导出交通量时间序列的方差齐次转换函数。但由于传统交通量预测模型为浅层结构,无法对特定函数族进行有效的表征从而获取数据集的本质特征^[3],且对于高维度数据集运用传统预测方法会造成维度灾难问题^[4]。

随着计算机技术的发展,研究人员提出了大量智能预测方法。罗向龙等^[5]对交通流进行特征分析,在网络顶层连接支持向量回归模型进行交通量预测,相比于传统交通量预测模型具有更高的预测精度;WANG 等^[6]结合实验客运量数据,通过与基准预测模型进行对比,验证了 LSTM 网络能够取得较好的预测性能,同时分析了各种参数设置对 LSTM 预测性能的影响;沈庙生等^[7]通过对实测交通流量数据进行实验,得到了考虑缺失值修复的 Dropout-LSTM 的高速公路流量预测模型相较于长期记忆模型预测精度更高的结论;温惠英等^[8]提出基于 Bi-LSTM 的方法,研究表明,该模型在非线性交通流数据中具有更好的预测性和广泛性;SUN 等^[9]针对道路网络交通流,提出了一种新的基于最大似然的选择性堆叠门控循环单元模型(SSGRU),得出应用于所有道路场景的多道路输入基础设施时,该模型比其他模型具有更高的准确性的结论。殷礼胜等^[10]基于考虑短时交通流量时间序列的复杂非平稳性、空间相关性和时间依赖性特性,提出改进的 VMD-GAT-GRU 交通量融合预测模型,相较于基准模型,其预测精度及收敛速度均有所提升。汪鸣等^[11]结合 Transformer 算法提出多时间尺度时空图网络模型,并通过消融实验证明了该模型提升预测性能的有效性。

上述研究提出的模型仅关注高速公路短期交通量预测,训练所用数据量较少,忽略了具有城市道路功能的海底隧道中短期交通量在时间跨度内的变化规律,且用于交通量预测算法更多集中于 LSTM 及其融合模型,针对新提出的 GRU 模型及 Transformer 模型研究较少。本文提出基于 AGRU-Trans 融合模型的海底隧道交通量预测模型,以小时为跨度、近一年交通数据量为训练,对海底隧道交通量进行预测,通过结果分析,验证了该模型相比其他基准预测模型具有更高的预测精度,为胶州湾海底隧道管理部门对车辆进行精细化诱导及管控提供了理论参考。

1 交通量预测模型

交通量预测模型的不断优化进一步推动了交通流预测技术的发展,大量学者从多元时间序列联合预测^[12]、量化时间序列噪声的随机性^[13]、分析不同观测时间尺度的时间序列构成^[14]等多个角度提出研究方法。单一模型预测无法很好地满足预测的需要,为了提高预测精度,组合模型、切换模型、模型优化等方法被广泛使用^[15]。

1.1 LSTM 模型

长短期记忆(LSTM)模型^[16]是循环神经网络(RNN)的改进变体。相比于普通的 RNN,LSTM 能够在更长的时间序列中有更好的表现。该模型通过增加遗忘门、输入门和输出门等门控单元来克服传统的循环神经网络模型梯度消失或梯度爆炸的问题^[17]。其中遗忘门利用激活函数 sigmoid 对上一时刻的记

忆状态进行选择性地遗忘或者保留,输入门利用 tanh 函数生成该时刻记忆状态的候选值,然后再通过与该时刻输入门输出值进行元素对位相乘,以控制该时刻的记忆状态是否发生更新,而输出门为控制记忆状态输出到 LSTM 的当前输出值。LSTM 的神经网络结构如图 1 所示,其计算公式如式(1)一式(6)所示。




图1 LSTM 的神经网络结构

$$f_t = \sigma(\mathbf{W}_f \cdot [\mathbf{h}_{t-1}, \mathbf{x}_t] + b_f) \tag{1}$$

$$i_t = \sigma(\mathbf{W}_i \cdot [\mathbf{h}_{t-1}, \mathbf{x}_t] + b_i) \tag{2}$$

$$\tilde{\mathbf{C}}_t = \tanh(\mathbf{W}_C \cdot [\mathbf{h}_{t-1}, \mathbf{x}_t] + b_C) \tag{3}$$

$$\mathbf{C}_t = f_t * \mathbf{C}_{t-1} + i_t * \tilde{\mathbf{C}}_t \tag{4}$$

$$o_t = \sigma(\mathbf{W}_o \cdot [\mathbf{h}_{t-1}, \mathbf{x}_t] + b_o) \tag{5}$$

$$\mathbf{h}_t = o_t * \tanh(\mathbf{C}_t) \tag{6}$$

式中: f_t 为遗忘门; σ 为 sigmoid 函数; \mathbf{W} 为权重矩阵; b 为增量; i_t 为输入门; \mathbf{C}_t 为记忆向量; $\tilde{\mathbf{C}}_t$ 为临时记忆向量; \mathbf{x}_t 为时间步 t 的输入向量; o_t 为输出门; \mathbf{h}_t 为时间步 t 隐藏层的输出向量; $*$ 为 Hadamard 乘法。

1.2 GRU 模型

门控循环单元神经网络(GRU)是由 K. CHO 等在 2014 年提出的,它同 LSTM 一样也是传统 RNN 的变体,能够有效捕捉长序列之间间隔较大的依赖关系。GRU 是对 LSTM 复杂模型结构的精简改进,在获取将来时段信息数据过程中,保证信息数据准确率的同时速度也得到提升。它的核心结构分为更新门及重置门两个部分^[18],GRU 单元结构如图 2 所示。其计算公式如式(7)一式(10)所示。

$$z_t = \sigma(\mathbf{W}_z \cdot [\mathbf{h}_{t-1}, \mathbf{x}_t]) \tag{7}$$

$$r_t = \sigma(\mathbf{W}_r \cdot [\mathbf{h}_{t-1}, \mathbf{x}_t]) \tag{8}$$

$$\tilde{\mathbf{h}}_t = \tanh(\mathbf{W} \cdot [r_t * \mathbf{h}_{t-1}, \mathbf{x}_t]) \tag{9}$$

$$\mathbf{h}_t = (1 - z_t) * \mathbf{h}_{t-1} + z_t * \tilde{\mathbf{h}}_t \tag{10}$$

式中: z_t 为更新门; r_t 为重置门; $\tilde{\mathbf{h}}_t$ 为候选隐藏状态。

LSTM 和 GRU 都通过门控机制保留了前一序列的有用信息,克服在长期传播过程中丢失的问题。但由于 GRU 参数个数较少,所以 GRU 整体运行速度相比 LSTM 更快。然而 GRU 有着神经网络结构本身不可并行计算的弊端,在未来数据量和模型体量持续增大的趋势下,仍需进一步优化。

1.3 Attention based GRU(AGRU)模型

通过来自注意力机制的嵌入信息修改 GRU 架构后,AGRU 可以有效地提取复杂查询中的关键信息。AGRU 使用权重来代替 GRU 的更新门,权重越大,当前时刻隐藏状态更新的信息就越多,之前的信息遗




图2 GRU 单元结构

忘的也就越多,该方式需要修改 GRU 单元内部的计算公式,计算见式(11)。

$$\mathbf{h}'_t = (1 - a_t) * \mathbf{h}'_{t-1} + a_t * \tilde{\mathbf{h}}_t \tag{11}$$

式中: \mathbf{h}'_t 为 AGRU 时间步为 t 时隐藏层的输出变量; a_t 为权重。

1.4 Transformer 模型

除上述算法可以处理时间序列数据以外,近几年由 Google 提出的 Transformer 算法同样可以解决梯度消失问题以处理时间序列数据,其中的注意力机制运行原理实现了并行计算,相比于只能串行计算的 RNN 极大地提升了运行速度。基于以上特性,Transformer 一经提出就引起了研究者的广泛关注,在机器翻译、阅读理解、文本摘要等多个领域展现出了优异的应用效果^[19]。本文将 Transformer 模型引入到交通量预测领域,为其增加了新的应用场景。该算法基于编码和解码构建,解码部分比编码部分多了一个交互层和一个被掩盖的多头注意力机制。由于编码部分和解码部分相差不大,为方便介绍,本文主要介绍 Transformer 算法的解码部分。Transformer 算法解码部分的结构如图 3 所示。

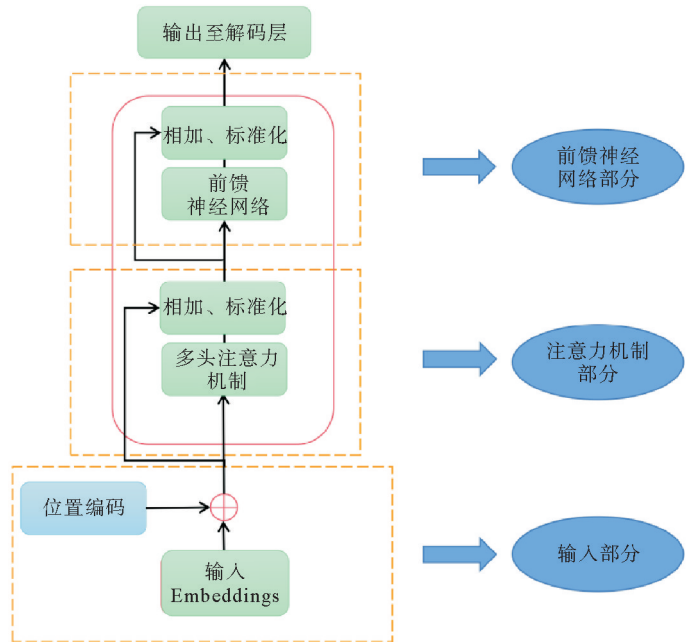


图 3 Transformer 算法解码部分结构

其中位置编码计算见式(12)—式(13)。

$$P(p, 2i) = \sin\left(\frac{p}{10000 \times 2i/d_{\text{model}}}\right) \tag{12}$$

$$P(p, 2i + 1) = \cos\left(\frac{p}{10000 \times 2i/d_{\text{model}}}\right) \tag{13}$$

式中: P 为位置编码; p 为时间序列的位置; d_{model} 表示模型的维度。

1.5 基准模型优劣比较

基于以上分析,对 LSTM,GRU,AGRU 及 Transformer 4 种交通量预测模型间优劣进行整体对比分析,见表 1。

表 1 基准模型优劣比较

模型	优势	劣势
LSTM	能够克服传统的循环神经网络模型梯度消失或梯度爆炸的问题	不可并行计算、训练速度慢
GRU	能够克服传统的循环神经网络模型梯度消失或梯度爆炸的问题,同时模型较 LSTM 简单,训练速度快	不可并行计算
AGRU	在 GRU 算法基础上能够有效地提取复杂查询中的关键信息	不可并行计算
Transformer	能够解决梯度消失问题,并可同时构建长短期依赖模型;能够并行运算,极大地提升了运行速度	计算空间复杂度大,需要处理序列的编码及解码

1.6 AGRU-Trans 融合预测模型

基于以上分析,本文提出了基于 AGRU-Trans 的融合预测模型,如图 4 所示,操作流程如下:

- 1) 对数据集进行划分,分为训练集和测试集;
- 2) 将数据集分别输入至 AGRU 模型和 Transformer 模型中进行训练;

- 3) 将 Transformer 模型输出值进行降维后与 AGRU 模型的输出值利用 concat 函数进行拼接;
- 4) 最后将拼接后的矩阵通过全连接层输出相应的预测值矩阵。

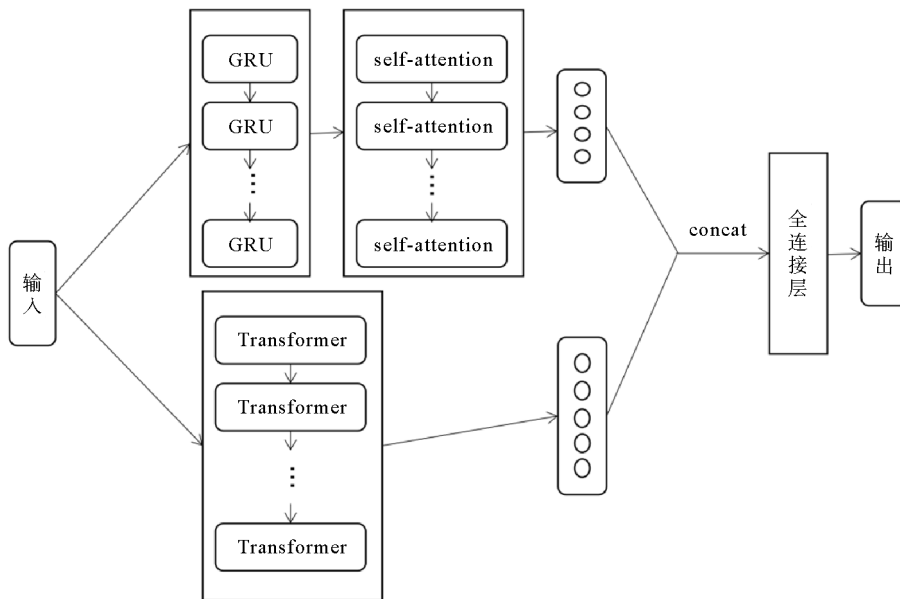


图4 AGRU-Trans 融合模型结构

2 胶州湾海底隧道交通信息数据特征分析

本文所依托的隧道工程为青岛胶州湾隧道,该隧道是连接青岛市市南区与黄岛区的双向六车道海底公路隧道,全长 7.8 km,隧道纵断面最大坡度为 3.9%,内净空高 10.391 m,宽 14.426 m。该隧道的建成,不仅有效缩短了两岸间的通行距离,而且极大缓解了交通运营压力,缩短了人们的出行时间。

对具有城市道路功能的海底隧道中短期交通量在时间跨度内的变化规律进行研究。由于该隧道 2021 年 6 月底进行大区间增设可变道路段,为提高训练精度,因此选取胶州湾海底隧道 2021 年 7 月 1 日到 2022 年 5 月 18 日时间跨度为 1 h 的交通量数据信息,经处理后的数据共有 7464 条,对处理后的交通量数据按照时间进行可视化操作,如图 5 所示。交通量的数值虽然在 0~4200 veh/h,但是主要的交通量数值还是集中在 0~2500 veh/h。

为近一步了解目前胶州湾隧道内交通量的特性,且避免初始或结尾数据以及数据的偶然性对交通参数规律性造成影响,本文选取中间时间段 2021 年 8 月 30 日到 2021 年 9 月 20 日 3 周内的交通信息数据进行细化处理,并针对 1 周内的交通数据规律性进行分析。图 6 为各交通量 1 周内的可视化数据。




图5 胶州湾隧道交通量分布示意




图6 胶州湾隧道单周交通量分布示意

— 第1周; — 第2周; — 第3周

从图 6 中可以看出,交通量变化规律呈现出周期性和时间相关性,并非杂乱无章。1 周内工作日通过海底隧道的交通量相较于休息日更多,休息日高峰期呈现滞后性,这突出反映了交通参数和人们的出行习惯具有很强的相关性。

3 实验基础

3.1 评估指标

本文采用平均绝对误差 (Mean Absolute Error, MAE)、均方根误差 (Root Mean Square Error, RMSE) 和拟合优度可决系数 R^2 作为模型预测精度的评价指标。MAE 表示的是真实值和预测值之间的绝对误差的平均值;RMSE 可以测量误差的平均大小,是真实值与预测值偏差的平方与实测次数 n 比值的平方根; R^2 可以衡量预测曲线对于真实数据拟合效果的好坏, R^2 越大说明拟合效果越好, R^2 的最优值为 1^[20]。

$$h = \sum_{i=1}^n \frac{|Y_i - Y_i^*|}{n} \quad (14)$$

$$u = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - Y_i^*)^2} \quad (15)$$

$$R^2 = \frac{\sum_{i=1}^n (Y_i^* - \bar{Y}_i)^2}{\sum_{i=1}^n (Y_i - \bar{Y}_i)^2} \quad (16)$$

式中: h 为平均绝对误差; u 为均方根误差; R^2 为拟合优度可决系数; Y_i 为交通量真实值; Y_i^* 为交通量预测值; \bar{Y}_i 为交通量平均值; n 为预测序列长度。

3.2 超参数设置

设置超参数回溯时间窗为 24,即每次输入一个交通信息数据,模型都需要考虑前 24 h 数据的值;设置分批大小为 32,即模型一次训练所选取的交通信息数据数,可以减少模型训练的时间,从而能及时反馈预测的值;学习率为 5×10^{-4} ,用以反向传播更新梯度参数和权重系数;隐藏层单元数设置为 100 个;层数设置为 4 层;最后设置迭代次数为 100 次。

3.3 对比模型选取

为检测模型精度,将所选模型和其余基准模型进行对比,基准模型包括:长短期记忆模型 (LSTM)、门控循环模型 (GRU)、Transformer 模型。

4 实证研究

4.1 数据来源

本实验采用青岛胶州湾海底隧道交通量数据,以青岛市市南区—黄岛区作为研究对象。将 2021 年 7 月 1 日—2022 年 5 月 18 日按时间跨度为 1 h 交通量数据信息进行划分,将前面 80% 的数据作为训练集,最后 20% 的数据作为测试集用以判断训练后模型的性能状况。

4.2 结果对比

分别通过 4 种模型对海底隧道交通量数据进行训练和预测,如表 2 所示,在 4 种模型中,AGRU-Trans 融合模型的 MAE 值和 RMSE 值相比基准模型最小,其 R^2 也最接近于 1,具有良好的预测性能与精度。

通过表 2 可以看出 4 种模型的 R^2 均大于 80%,可以认为 4 种模型在交通量预测上均有较好的预测性,而 Transformer 模型预测误差相对更大,究其原因因为 Transformer 模型算法

表 2 各模型预测效果比较

模型	MAE	RMSE	$R^2/\%$
LSTM	180.79	290.63	89.86
Transformer	230.38	296.68	89.40
GRU	165.79	282.90	90.70
AGRU-Trans	137.50	214.27	94.41

完全基于 self-attention,对于位置之间的信息有一定的丢失。GRU 模型的拟合程度略高于 LSTM 模型,这与时空序列预测的结论一致^[21]。LSTM, Transformer, GRU 模型的 MAE 值相比 AGRU-Trans 分别大了 31.48%, 67.55%, 20.57%; RMSE 值分别增长了 35.64%, 38.46%, 32.03%。

由于交通量数据多、重复率高且交通量变化规律呈现出周期性和时间相关性,为更清晰展示模型预测结果,本文选取基准模型中预测性能最好的 GRU 模型与本文所提出的 AGRU-Trans 融合模型为研究对象,对某包含早晚高峰时刻的 120 个预测数据和真实数据进行对比。从图 7 中可以直观看出,AGRU-Trans 融合模型的预测结果与真实数据贴合性最好,预测精度高于基准模型,在交通量波动大的时段预测结果更接近真实值。




图7 预测结果对比

—■— 实际值; - -●- GRU; —◆— AGRU-Trans

从图 7 中可以直观看出,AGRU-Trans 融合模型的预测结果与真实数据贴合性最好,预测精度高于基准模型,在交通量波动大的时段预测结果更接近真实值。

5 结论

1) 通过对循环神经网络和 Transformer 算法的研究,结合 GRU 与 Transformer 模型算法优点并加入自注意力机制,提出一种基于 AGRU-Trans 融合模型的海底隧道交通量预测模型用以对青岛胶州湾海底隧道交通信息数据进行预测,该模型预测结果与真实数据贴合性好,具有良好的预测性能和精度。

2) 选取胶州湾海底隧道市南区—黄岛区交通数据,通过 AGRU-Trans 融合模型与 3 种基准模型对比发现,LSTM, Transformer, GRU 模型的 MAE 值相比 AGRU-Trans 分别大了 31.48%, 67.55%, 20.57%; RMSE 值分别增长了 35.64%, 38.46%, 32.03%。表明:AGRU-Trans 融合模型的预测结果与真实数据贴合性最好,预测精度均高于基准模型。

本文提出的基于 AGRU-Trans 融合模型的海底隧道交通量预测模型对交通规划及交通控制有积极意义,基于此方法可为胶州湾海底隧道管理部门对车辆的诱导及管控提供理论参考。

参考文献(References):

- [1] WILLIAMS B M, HOEL L A. Modeling and forecasting vehicular traffic flow as a seasonal ARIMA process: Theoretical basis and empirical results[J]. *Journal of Transportation Engineering*, 2003, 129(6): 664-672.
- [2] 李文勇, 李俊卓, 王涛. 基于 Box-Cox 指数变换改进的 ARIMA 模型交通流预测方法[J]. *武汉理工大学学报(交通科学与工程版)*, 2020, 44(6): 974-977.
LI Wenyong, LI Junzhuo, WANG Tao. Improved ARIMA model traffic flow prediction method based on Box-Cox exponential transformation[J]. *Journal of Wuhan University of Technology (Transportation Science and Engineering)*, 2020, 44(6): 974-977.
- [3] BENGIO Y, LECUN Y. Scaling learning algorithms towards AI[J]. *Large-Scale Kernel Machines*, 2007, 34(5): 1-41.
- [4] ERFANI S M, RAJASEGARAR S, KARUNASEKERA S, et al. High-dimensional and large-scale anomaly detection using a linear one-class SVM with deep learning[J]. *Pattern Recognition*, 2016, 58(C): 121-134.
- [5] 罗向龙, 焦琴琴, 牛力瑶, 等. 基于深度学习的短时交通流预测[J]. *计算机应用研究*, 2017, 34(1): 91-93.
LUO Xianglong, JIAO Qinqin, NIU Liyao, et al. Short-term traffic flow prediction based on deep learning[J]. *Application Research of Computers*, 2017, 34(1): 91-93.
- [6] WANG Xu, YANG Linjian, AN Yisheng, et al. Passenger traffic volume prediction with LSTM neural network[J]. *Frontiers in Artificial Intelligence and Applications*, 2019, 314: 107-116.
- [7] 沈庙生, 高更君. 基于 LSTM 的短时高速公路交通量预测[J]. *控制工程*, 2023, 30(11): 2011-2018.
SHEN Miaosheng, GAO Gengjun. Short-term forecasting of highway traffic volume based on LSTM[J]. *Control Engineering of China*, 2023, 30(11): 2011-2018.
- [8] 温惠英, 张东冉. 基于 Bi-LSTM 模型的高速公路交通量预测[J]. *公路工程*, 2019, 44(6): 51-56.
WEN Huiying, ZHANG Dongran. Highway traffic volume prediction based on Bi-LSTM model[J]. *Highway Engineering*, 2019,

- 44(6):51-56.
- [9] SUN Peng,BOUKERCHE Azzedine,TAO Yanjie. SSGRU: A novel hybrid stacked GRU-based traffic volume prediction approach in a road network[J]. *Computer Communications*,2020,160:502-511.
- [10] 殷礼胜,吴洋洋. 基于改进 VMD-GAT-GRU 的交通流量组合预测模型[J]. *电子测量与仪器学报*,2022,36(7):62-72.
YIN Lisheng,WU Yangyang. Traffic flow combination prediction model based on improved VMD-GAT-GRU[J]. *Journal of Electronic Measurement and Instrumentation*,2022,36(7):62-72.
- [11] 汪鸣,彭舰,黄飞虎. 基于多时间尺度时空图网络的交通流量预测模型[J]. *计算机科学*,2022,49(8):40-48.
WANG Ming,PENG Jian,HUANG Feihu. Multi-time scale spatial-temporal graph neural network for traffic flow prediction[J]. *Computer Science*,2022,49(8):40-48.
- [12] YIN Yi,SHANG Pengjian. Forecasting traffic time series with multivariate predicting method[J]. *Applied Mathematics and Computation*,2016,291:266-278.
- [13] YANG Zhengling,LIU Yadi,ZHU Xinshan,et al. Removing forecasting errors with white Gaussian noise after square root transformation[J]. *Journal of Forecasting*,2016,35(8):741-750.
- [14] YUAN Pengcheng,LIN Xuxun. How long will the traffic flow time series keep efficacious to forecast the future? [J]. *Physica A: Statistical Mechanics and its Applications*,2017,467:419-431.
- [15] 葛志鹏,李锐,张健,等. 基于时间序列与 GSVMR 模型的短时交通量组合预测[J]. *长安大学学报(自然科学版)*,2015,35(S1):222-225.
GE Zhipeng,LI Rui,ZHANG Jian,et al. Short-term traffic volume combinational forecasting based on time series and GSVMR model[J]. *Journal of Chang'an University (Natural Science Edition)*,2015,35(S1):222-225.
- [16] HOCHREITER S,SCHMIDHUBER J. Long short-term memory[J]. *Neural Computation*,1997,9(8):1735-1780.
- [17] ALEX Graves. Supervised sequence labelling with recurrent neural networks[M]. Berlin:Springer,2012.
- [18] ZHANG Guowei,LIU Da. Causal convolutional gated recurrent unit network with multiple decomposition methods for short-term wind speed forecasting[J]. *Energy Conversion and Management*,2020,226:113500.
- [19] 周哲韬,刘路,宋晓,等. 基于 Transformer 模型的滚动轴承剩余使用寿命预测方法[J]. *北京航空航天大学学报*,2023,49(2):430-443.
ZHOU Zhetao,LIU Lu,SONG Xiao,et al. Remaining useful life prediction method of rolling bearings based on transformer model[J]. *Journal of Beijing University of Aeronautics and Astronautics*,2023,49(2):430-443.
- [20] 田考聪. 曲线拟合优度的一种检验方法[J]. *重庆医科大学学报*,1994(3):204-206.
TIAN Kaocong. A test method for goodness of curve fitting[J]. *Journal of Chongqing Medical University*,1994(3):204-206.
- [21] FU R,ZHANG Z,LI L. Using LSTM and GRU neural network methods for traffic flow prediction[C]// Youth Academic Annual Conference of Chinese Association of Automation. Wuhan,2017:324-328.

(责任编辑 赵金环;英文校审 程文华)

(上接第 117 页)

- [16] National Research Council. Transportation research board highway capacity manual 2010[M]. Washington DC:Transportation Research Board,2010.
- [17] 邵海鹏,王宇轩,陈兴影,等. 信号交叉口进口道掉头设置条件研究[J]. *系统仿真学报*,2018,30(11):4429-4436.
SHAO Haipeng,WANG Yuxuan,CHEN Xingying,et al. Setting conditions of u-turns at entrances of signalized intersections[J]. *Journal of System Simulation*,2018,30(11):4429-4436.
- [18] DEB K,AGRAWAL S,PRATAP A,et al. A fast and elitist multiobjective genetic algorithm: NSGA- II. [J]. *IEEE Transaction on Evolutionary Computation*,2002,6(2):182-197.
- [19] KRISHNAMOORTHY M S. Nature-inspired optimization algorithms[J]. *Computing reviews*. 2015, 56(4):224-225.
- [20] 王丽萍,任宇,邱启仓,等. 多目标进化算法性能评价指标研究综述[J]. *计算机学报*,2021,44(8):1590-1619.
WANG Liping,REN Yu,QIU Qicang,et al. Survey on performance indicators for multi-objective evolutionary algorithms[J]. *Chinese Journal of Computers*,2021,44(8):1590-1619.
- [21] 卢守峰,刘喜敏. 微观交通仿真[M]. 长沙:中南大学出版社,2016.
LU Shoufeng,LIU Ximin. Microscopic traffic simulation[M]. Changsha:Zhongnan University Press,2016.
- [22] 许伦辉,高雅隼. VISSIM 下环交的信号控制仿真和配时优化设计[J]. *广西师范大学学报(自然科学版)*,2014,32(1):1-6.
XU Lunhui,GAO Yajun. Signal control simulation and timing optimization design of roundabout based on VISSIM[J]. *Journal of Guangxi Normal University(Natural Science Edition)*,2014,32(1):1-6.

(责任编辑 张晓靖;英文校审 程文华)