

doi: 10.11835/j.issn.1000-582X.2022.205

微观轨迹信息驱动的 Bi-LSTM 合流区车速预测

秦雅琴, 夏玉兰, 钱正富, 谢济铭

(昆明理工大学 交通工程学院, 昆明 650224)

摘要:为明确城市快速路合流区的微观速度特性,确保车辆在衔接段运行速度协调可控,使车辆安全运行。首先,基于无人机高空视频,从广域视角提取了典型多车道交织区全样本高精度车辆轨迹数据,分析车速的累积频率、分布趋势、特征百分位值等运行特性。然后,基于可有效捕捉前向历史速度数据的变化特征的 LSTM 模型,构建 Bi-LSTM 车速预测模型;考虑到人工设置训练参数对模型预测性能的影响较大、时间较长,提出基于遗传算法优化的 Bi-LSTM 速度预测模型(GA-Bi-LSTM)。最后,以 R^2 、Error Mean、Error StD、MSE、RMSE、NRMSE、秩相关 r_s 这 7 类评价指标,建立多指标融合的评价方案。结果表明:GA-Bi-LSTM 速度预测模型表现较优,拟合指标 R^2 、秩相关 r_s 分别为 0.904 6、0.949 5,误差指标 Error Mean、Error StD、MSE、RMSE、NRMSE 分别为 0.004 1、0.447 0、0.199 7、0.446 9、0.076 5。研究成果可为城市快速路的合流区车速调控提供理论依据。

关键词:交通工程;速度预测;GA-Bi-LSTM;多车道交织区;微观轨迹数据;遗传算法

中图分类号:U491.2

文献标志码:A

文章编号:1000-582X(2023)04-120-09

Bi-LSTM merging area speed prediction driven by microscopic trajectory information

QIN Yaqin, XIA Yulan, QIAN Zhengfu, XIE Jiming

(School of Transportation Engineering, Kunming University of Science and Technology,
Kunming 650504, P. R. China)

Abstract: In order to guarantee the vehicle safety, it is necessary to clarify the microscopic speed characteristics of the urban expressway merging area and to ensure the coordination and control of the vehicle speed in the area. First, after the full-sample high-precision vehicle trajectory data of typical multi-lane interweaving area were extracted from a wide-area view based on the UAV overhead video, the operational characteristics of vehicle speed, such as cumulative frequency, distribution trend, and characteristic percentile value, were analyzed. Then, the Bi-LSTM vehicle speed prediction model was constructed based on the LSTM model that could effectively capture the change characteristics of forward historical speed data. Considering the significant effect of manual setting of training parameters on the model prediction performance and the long time they take, the Bi-LSTM speed prediction model based on genetic algorithm optimization (GA-Bi-LSTM) was proposed. Finally, a multi-

收稿日期:2022-02-28 网络出版日期:2022-07-14

基金项目:国家自然科学基金资助项目(71861016);国家重点研发计划资助项目(2018YFB1600500)。

Supported by National Natural Science Foundation of China(71861016), and National Key Research and Development Program of China(2018YFB1600500).

作者简介:秦雅琴(1972—),女,博士,教授,主要从事驾驶人因安全、车路协同、系统仿真建模研究,(E-mail)qinyaqin@kust.edu.cn。

通信作者:谢济铭,男,博士,(E-mail)xiejiming@kust.edu.cn。

metric fusion evaluation scheme was established with seven types of evaluation metrics, namely, R^2 , Error Mean, Error StD, MSE, RMSE, NRMSE, and Rank Correlation. The results show that the GA-Bi-LSTM speed prediction model performs better, with the fitting indicators R^2 and Rank Correlation r_s of 0.904 6 and 0.949 5, respectively, and the error indicators Error Mean, Error StD, MSE, RMSE, and NRMSE of 0.004 1, 0.447 0, 0.199 7, 0.446 9 and 0.076 5, respectively. The findings can provide a theoretical basis for speed regulation in merging zones of urban expressways.

Keywords: traffic engineering; speed prediction; GA-Bi-LSTM; multi lane weaving area; micro trajectory data; genetic algorithm

城市快速路合流区因主线与匝道车流的交汇,易产生交通瓶颈,降低通行效率,影响行车安全^[1]。车速作为衡量交通状态的一个重要指标,逐渐成为当前交通预测的重点研究对象之一。由于车速存在随机性、非线性、时空相关性等问题,如何准确地挖掘其在时间和空间上的特点,成为车速预测的关键。

国内外研究人员在数据驱动的交通预测方面开展了有益探索,主要围绕参数模型和深度学习展开^[2]。参数模型预测方法主要有多元线性回归^[3]、自回归移动平均^[4](integrated moving average, ARIMA)、卡尔曼滤波^[5](kalman filter, KF)等。由于交通参数特征具有数据规模大、维度复杂并且提取难度高的特点,参数模型稳定性较弱,难以反映其非线性变化特征。随着计算机处理能力的提升,深度学习因其深层次的数据表达能力成为交通预测的重要手段,得出了较多具有参考价值的研究成果^[6-7]。由于单一模型都有自身特点和应用局限性,反映数据信息也存在一定的差异,因此使用单一模型进行预测难免导致数据信息丢失。基于此,将不同模型通过适当方式进行有机融合,形成组合预测方法,提升预测准确性和稳定性,逐渐成为研究发展的需要^[8-10]。

然而集成模型通常需要大量的参数调节实验来提升模型的结构性能^[11],当面对已知样本和计算单元受到限制的情况下,其对复杂问题的泛化能力及计算能力同样难以满足要求,无法学习更有用的特征。此外,车路协同条件下高精度、高频率的交通信息采集要求,对交通参数的有效预测造成了一定限制。

针对以上问题,为进一步提高速度预测的准确性,笔者构建一种基于遗传算法(genetic algorithm, GA)优化的双向长短期记忆(bi-long short term memory, Bi-LSTM)网络合流区车速预测集成模型(GA-Bi-LSTM)。基于无人机视频提取技术及核相关滤波(kernel correlation filter, KCF)算法获取合流区高精度车辆轨迹数据,利用Bi-LSTM提取合流区车辆速度的非线性、不稳定性时空变化特征,构建Bi-LSTM车速预测模型,考虑到Bi-LSTM的训练时间较长,人工设置训练参数对预测性能的影响,为达到全局最优,采用遗传算法对Bi-LSTM模型进行超参数寻优,实验结果表明,笔者提出的GA-Bi-LSTM车速预测集成模型优于基准Bi-LSTM模型,并具有较好的稳定性和鲁棒性。

1 车速预测模型的构建

1.1 Bi-LSTM车速预测模型

长短期记忆网络(long short term memory, LSTM)作为循环神经网络(recurrent neural net, RNN)网络的改进^[12],由遗忘门 f_t 、输入门 i_t 、输出门 o_t 组成。Bi-LSTM模型是在LSTM的基础上,将单向的LSTM层变为双向的Backward层和Forward层,既继承了LSTM能够避免梯度消失及梯度爆炸的优势,又解决了LSTM在信息处理上只按照单向先后顺序的问题,能够实现对数据特征和规律更加全面的分析,其算法框架如图1所示。

Bi-LSTM在 t 时刻输出前向和后向的组合速度特征可表示为

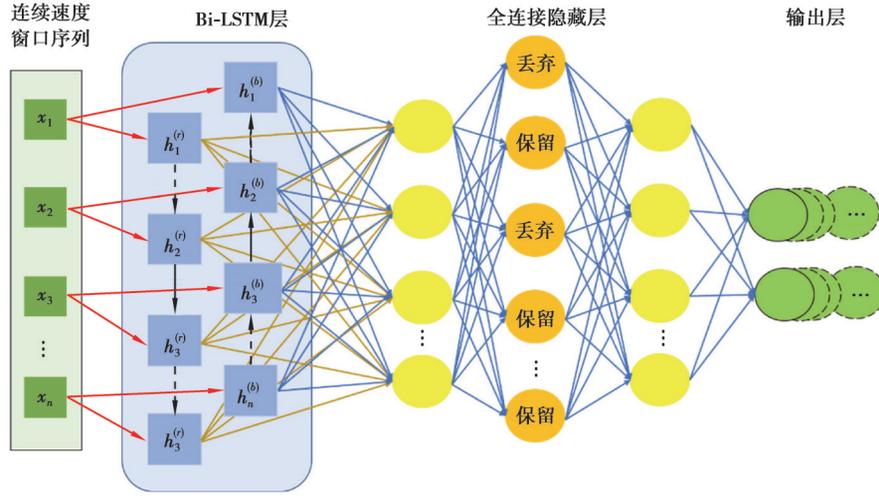


图1 Bi-LSTM框架

Fig. 1 The framework of the Bi-LSTM model

$$y_t = \omega_y \cdot [h_t^{(r)}, h_t^{(b)}] + b_y, \quad (1)$$

式中： $h_t^{(r)}$ 和 $h_t^{(b)}$ 分别为 t 时刻Backward层和Forward层中隐藏层的输出； ω_y 和 b_y 分别为权重和偏置。

利用Bi-LSTM模型进行速度预测的具体步骤为：

1)输入速度序列 $\mathbf{X}=[x_1, x_2, x_3, \dots, x_n]$ ，划分出80%的训练集与20%的测试集，由于文中的数据基本服从正态分布，且存在异常值，为保证预测结果的准确性，考虑先对数据进行min-max标准化处理，为

$$x'_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}}, \quad (2)$$

式中： x_i 为第 i 个原始数据； x'_i 为标准化处理后的新数据。

2)初始化隐藏层状态 h_0 、神经元的细胞状态 c_0 、最大训练次数等超参数。将经过步骤1)处理后的数据输入第一层Bi-LSTM神经元。

3)对当前时刻遗忘门向量 f_t 、输入门向量 x_t 、记忆细胞向量 c_t 、输出门向量 O_t 、隐藏状态 h_t 分别进行计算，保留 c_t 和 h_t 并将其传输到下一时刻的Bi-LSTM神经元。

4)判断Backward层和Forward层的LSTM神经元是否学习结束，若没有结束，则继续步骤3)。

5)重复以上步骤计算下一层的Bi-LSTM神经元，随后采用Dropout函数随机丢失一部分特征，以防止出现过拟合现象，最后，通过全连接层进行加权整合输出如式(1)，获得合流区车速预测值。

1.2 遗传算法优化的Bi-LSTM速度预测模型

执行车速预测任务时，需确定Bi-LSTM的超参数以保证算法获得最优性能^[12]，影响模型性能主要参数为：隐藏层单元数(hidden layer units, H_u)、学习率(learning rate, L_r)、隐藏层数(hidden layers, H_l)、L2正则化因子(L2 regularization, L_2)、Bi-LSTM层数(Bi-LSTM layers, L_s)。

考虑到Bi-LSTM模型的训练时间较长，人工设置上述参数对预测性能的影响较大，为保证模型预测性能，文中构建优化算法对参数进行自动寻优。遗传算法(GA)是模拟生物进化进行个体选择、交叉和变异的一种算法^[13]，其核心为参数编码、初始群的设定和适应函数的确定，具有可拓展性强、易于其他算法进行结合使用的优点。因此，文中将遗传算法与双向长短期记忆网络相结合，构建遗传算法优化的Bi-LSTM速度预测模型(GA-Bi-LSTM)。通过对LSTM模型参数动态调优，获取搜索空间内的最优解，具体步骤为：

1)参数设定。将超参数 $[H_u, L_r, H_l, L_2, L_s]$ 调节过程转换为染色体基因表达问题，选取预测结果的均方误差(MSE)作为适应度函数 F ，用以反映Bi-LSTM的模型优劣， F 的计算公式为

$$F = \frac{1}{N} \sum_{i=1}^N |x_{i-\text{act}} - x_{i-\text{out}}|, \quad (3)$$

式中： N 为样本数量； $x_{i-\text{act}}$ 为期望输出； $x_{i-\text{out}}$ 为实际输出。

2)编码解码。根据 Bi-LSTM 涉及的超参数特点,采用实数编码方式,提高编码方式与求解问题形式之间匹配度以及算法的局部搜索能力。

3)初始种群。根据 Bi-LSTM 模型结构特性,选择轮盘赌策略进行染色体优选,即模型超参数 $[H_u, L_r, H_1, L_2, L_s]$ 优选,设群体大小为 n ,个体 i 的适应度为 F_i ,则个体 i 被选中遗传到下一代群体的概率为

$$P_i = \frac{1}{F_i} / \sum_{i=1}^n \frac{1}{F_i}, \quad (4)$$

4)交叉变异。基于序值和拥挤距离选择序值小、拥挤距离大的个体,接着对交配池中个体进行交叉与变异操作。

5)结果判断。若满足种群迭代次数条件,则停止计算,输出最优参数组合 $[\bar{H}_u, \bar{L}_r, \bar{H}_1, \bar{L}_2, \bar{L}_s]$, 否则,继续交叉变异,直至找到 Bi-LSTM 最佳参数组合结果。

6)基于上述优化步骤,完成 GA-Bi-LSTM 速度预测模型的构建。

2 数据获取与分析

2.1 高空视频采集

文中选取某多车道交织区为研究对象,该交织区承担东-西流向主要过境流量,具有速度离散、行为随机、冲突集聚等独特的交通特性,导致车速变化规律难以准确掌握。在天气良好的工作日,利用无人机悬停于交织区上方 120 m 采集车辆运行高清视频,如图 2 所示。在实验过程中,为避免数据采集影响交通运行,要求实验人员在人行道或周边高地,使用无人机装置录制工作日高、平峰高清视频数据。

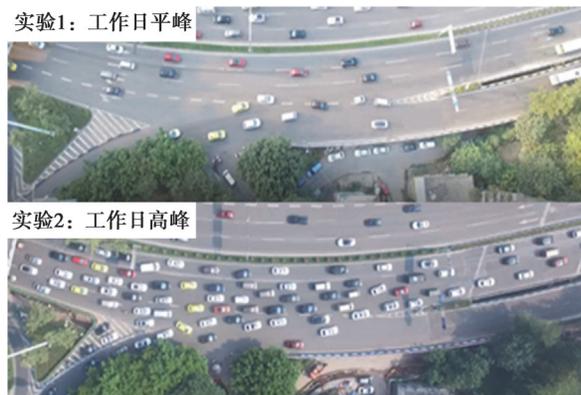


图 2 高空视频拍摄场景

Fig. 2 High-altitude video shooting scene

2.2 交通信息提取

为从航拍视角获取有效的车辆运行宏微观信息,采用多尺度 KCF 车辆跟踪优化算法对视频中的运动车辆进行识别和跟踪,并对数据进行了坐标变换、数据验证和误差消除等处理分析,提取流程如图 3 所示,得到帧 ID、时间 ID、车辆 ID、车辆质心坐标等车辆动态属性。基于此,构建交通流信息与车辆行为信息基础数据库,包括车速、加速度、速度角度等。

通过车辆自动跟踪及人工标定,获取行经交织区的 1 000 辆车的完整轨迹,得到共计 30 余万条微观轨迹数据,轨迹信息时间精度 0.1 s、空间精度 0.1 m/px,数据颗粒度小,检测结果精度较高。

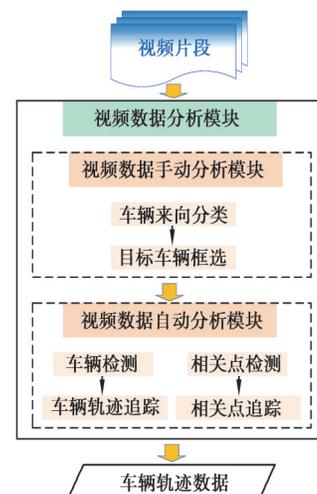


图 3 数据提取过程^[14]

Fig. 3 Data extraction process

2.3 合流区速度分析

2.3.1 合流区车速分布

高峰与平峰时段的合流区车速频率分布及数据拟合如图4所示,可以看出:

1)高峰时段速度总体处于 $[0,20]$ km/h杂乱波动,主要集中于 6 ± 3 km/h区间,平均速度约5.86 km/h。其中,85%车速小于10.0 km/h,速度累积频率曲线的斜率突变点出现在90%分位左右。这是因为在高峰状态下,合流区车辆数量较多且前后跟驰密集,来自主线与匝道的车辆在保证安全的情况下在此进行汇合,车辆低速缓慢行驶,导致通过合流区的车速上下波动。

2)平峰时段车速分布略显扁平,有序分布于 $[7.5,45]$ km/h内,主要集中于 20 ± 10 km/h,平均速度约23.3 km/h,85%车速小于32.4 km/h,速度累积频率曲线平稳上升,斜率突变点出现在85%分位左右,说明平峰时段车辆从匝道和主线驶入合流区时,基本不受路径选择、平纵线型、交织构型等外在因素影响,行车间距与视距充足,车辆之间产生的影响较小,车辆选择近似匀加速行驶。

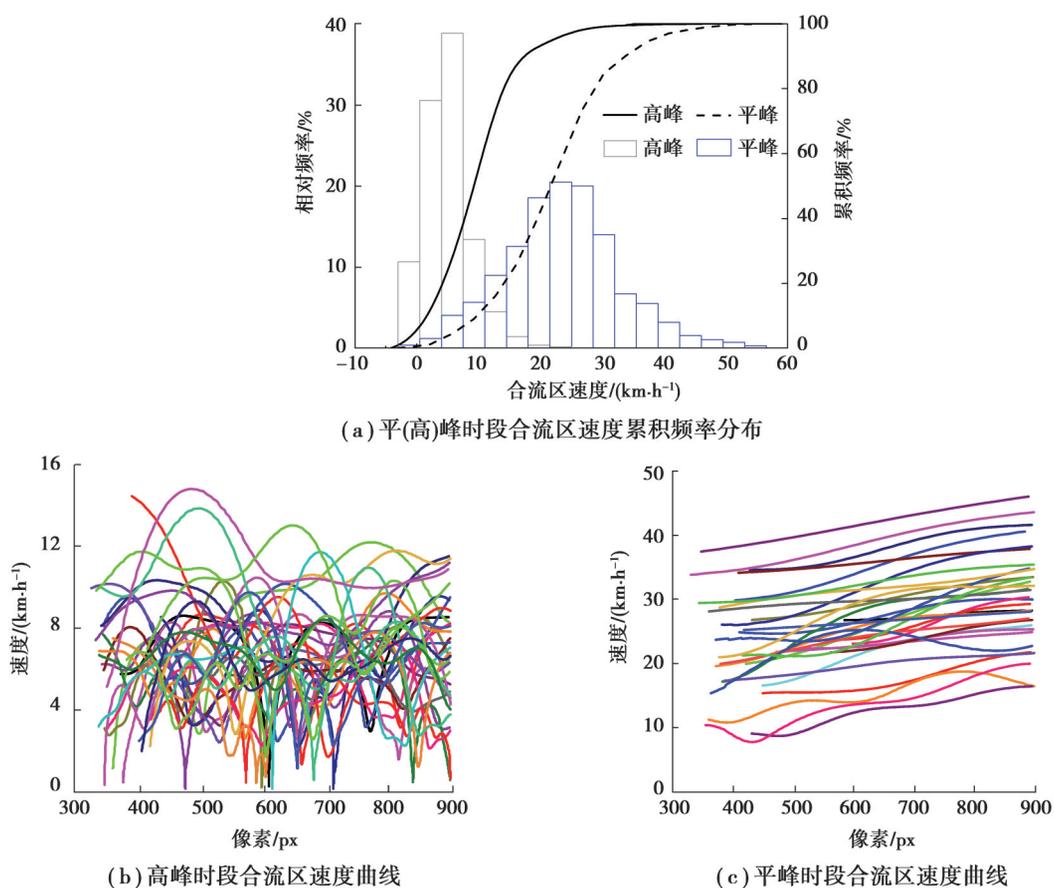


图4 平(高)峰状态下的合流区速度分布

Fig. 4 Speed distribution in the merging zone under normal (rush hours) state

2.3.2 合流区车速描述统计

为进一步验证合流区车速描述统计规律,如表1所示。假设检验方面,Kline等^[15]提出,当样本数据偏度的绝对值小于3,峰度的绝对值小于10时,可认为观测变量基本服从Gaussian分布。因此,可认为合流区车速运行数据符合Gaussian分布;车速统计方面,高峰时段合流区速度的均值、标准差、50分位值、85分位值均小于平峰状态,车速大幅衰减,均达50%以上。

表 1 合流区速度描述统计
Table 1 Speed descriptive statistics in the merging area

合流区速度统计	观测数	均值	标准差	50分位 值	85分位 值	偏度(<3)	峰度(<10)
平峰时段/(km·h ⁻¹)	20 445	23.298	9.381	22.235	32.394	0.342(Y)	0.128(Y)
高峰时段/(km·h ⁻¹)	150 860	5.863	3.790	6.612	9.918	0.944(Y)	2.535(Y)
$((V_m^{平峰} - V_m^{高峰})/V_m^{平峰})/\%$	—	74.83	59.6	70.26	69.38	—	—

由前述分析可知,实例合流区高峰时段具有车速离散、分布紊乱、瓶颈现象等独特的特性,车速变化规律难以准确把握。面向车路协同系统的速度控制调节,须保证此类非典型场景复杂车速运行精准预测。

3 模型验证

3.1 模型训练

为体现 Bi-LSTM 模型的性能优势,人工设置 Bi-LSTM 模型结构性能使其达到最优。按隐层数量×遍历轮数×批大小的形式,设计了表 2 所示的 24 组交叉实验进行测试^[14]。模型包含 4 类隐藏层结构,第 1 类只有 1 个隐藏层,隐藏层单元数为 100,表示为 h_{100} ;第 2 类有 2 个隐藏层,神经元数量均为 100,表示为 $h_{100} \times h_{100}$,以此类推其余两类分别为 $h_{100} \times h_{100} \times h_{75}$ 和 $h_{100} \times h_{100} \times h_{75} \times h_{75}$ 。

表 2 交叉实验结构
Table 2 The structure of the cross-experiment

隐藏层数	遍历轮数	批大小	模型组别
h_{100}			1~6
$h_{100} \times h_{100}$	100~200,步长为 100	32~128, 步长为 32	7~12
$h_{100} \times h_{100} \times h_{75}$			13~18
$h_{100} \times h_{100} \times h_{75} \times h_{75}$			19~24

完成 24 组训练测试后,根据模型的损失均值 $\bar{L}_{0.05}$ 和 RMSE 均值 M_{RMSE} 筛选出误差最小的结构参数组合,作为模型的最优结构参数。最终采用第 4 组(隐藏层为 h_{100} ,批大小为 32,遍历轮数为 200)作为 Bi-LSTM 模型的最优结构参数。为保证模型控制条件唯一,将 Bi-LSTM 车速预测模型的最优结构参数值代入 GA-Bi-LSTM 车速预测模型中,使两模型具有相同的初始结构参数,此时针对 GA-Bi-LSTM 车速预测模型进行自动调参,如表 3 所示,进行合流区高峰时段速度预测。

表 3 超参数设置范围
Table 3 Setting range for hyperparameters

优化指标	隐藏层数 H_1	隐藏层单元数 H_0	Bi-LSTM 层 L_s	基础学习率 L_r	L2 正则化因子 L_2
域空间	[1,4]	[50,200]	[1-2]	$[1 \times 10^{-3}, 1]$	$[1 \times 10^{-10}, 1 \times 10^{-2}]$
初始值	1	100	1	0.005 0	1×10^{-10}

3.2 预测效果评价

针对高峰时段合流区车速数据,考虑到 0.1 s 时间窗口预测尺度适用性相对不强^[4],文中将速度值按照从小到大排序构建历史时域数据集 x_i ,基于该结果采用滑动时窗的方法提取 1 s 的速度序列平均值,如图 5 所示。时间步长设置为 1 s,每次向前更新 10 个数据节点,新序列长度为 $n = x_i/10$,共计得到 1 507 组速度序列数据,对其标准化处理得到数据集 x'_i 即为车速预测模型实验数据,如图 6 所示。其中,横坐标为第 i 个数据点,纵坐标为标准化速度。

统计 2 个模型的预测车速数据,对比情况如表 4 所示,以 7 类评价指标为切入点,可以看出:相对于原始的 Bi-LSTM 深度学习模型,经遗传算法优化后的 GA-Bi-LSTM 模型结构在车速预测方面具有明显优势,表

现出更好的预测精度。

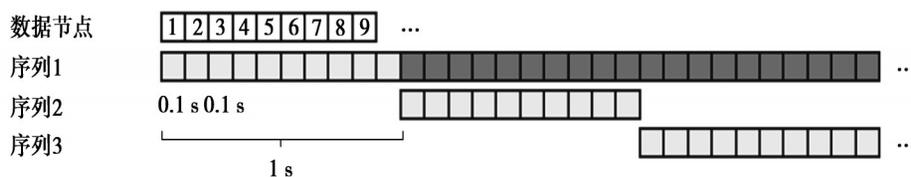


图5 滑动窗口采样示意图

Fig. 5 Schematic diagram of sliding window sampling

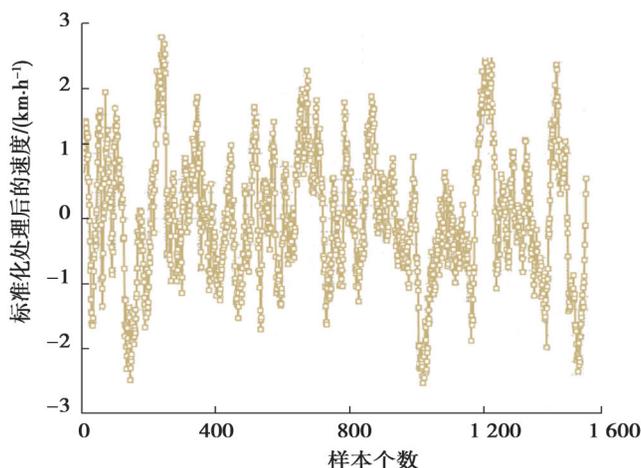


图6 实验数据现状

Fig. 6 Status of experimental data

表4 模型总体评价指标对比

Table 4 Comparison of overall model evaluation indicators

指标	Bi-LSTM ^[14]	GA-Bi-LSTM	提升或下降比例
R^2	0.888 2	0.904 6	+0.016 4(↑ 1.64%)
Error Mean	-0.005 3	0.004 1	+0.009 4(↓ 177.36%)
Error StD	0.471 1	0.447 0	-0.024 1(↑ 5.12%)
MSE	0.221 8	0.199 7	-0.022 1(↑ 9.96%)
RMSE	0.470 9	0.446 9	-0.024 0(↑ 5.10%)
NRMSE	0.080 6	0.076 5	-0.004 1(↑ 5.09%)
r'_s	0.945 3	0.949 5	+0.004 2(↑ 0.42%)

注:黑体加粗表示最优指标

1)拟合优度 R^2 。Bi-LSTM、GA-Bi-LSTM 的 R^2 分别为 0.888 2 和 0.904 6, 即 GA-Bi-LSTM 较 Bi-LSTM 整体提升了 1.64%。显然, GA-Bi-LSTM 速度预测模型的预测值拟合优度更高, 预测值与原始值的相关性更高, 即速度预测值更加接近实际值。

2)总体误差 Error Mean、Error StD。Bi-LSTM、GA-Bi-LSTM 的 Error Mean 分别为 -0.005 3 和 0.004 1, 两者差异明显, 这是由于 Error Mean 计算过程中正负误差值相互抵消所致。Error StD 分别为 0.471 1 和 0.447 0, GA-Bi-LSTM 较 Bi-LSTM 在 Error StD 层面提升了 5.12%, 表明 GA-Bi-LSTM 预测误差分布更为集中。

3)逐样本误差 MSE、RMSE、NRMSE。Bi-LSTM 的 MSE、RMSE、NRMSE 依次为 0.221 8、0.470 9、0.080 6;

GA-Bi-LSTM 分别为 0.199 7、0.446 9、0.076 5, GA-Bi-LSTM 较 Bi-LSTM 的 MSE、RMSE、NRMSE 分别提升 9.96%、5.10%、5.09%,说明 GA-Bi-LSTM 性能更为稳定,表现出更好的鲁棒性。

4)秩相关性 r_s 。Bi-LSTM、GA-Bi-LSTM 的秩相关结果分别为 0.945 3、0.949 5, GA-Bi-LSTM 相关性稍高,较 Bi-LSTM 提升了 0.42%。

3.3 优化效果评价

最后,进行遗传算法优化效果评价,迭代次数设置为 100 次,优化过程如图 7 所示。遗传算法优化器分别迭代至第 2、4、5 次时,预测误差骤减;迭代至第 6 次时,模型开始收敛,迭代至 99 次时,模型持续收敛,得到最小误差、最佳超参数点。说明遗传算法的目标函数在评估成本高的任务时,可以较快速度收敛,能够应用于高峰时段合流区车速预测,表现出更好的泛化性与可靠性。

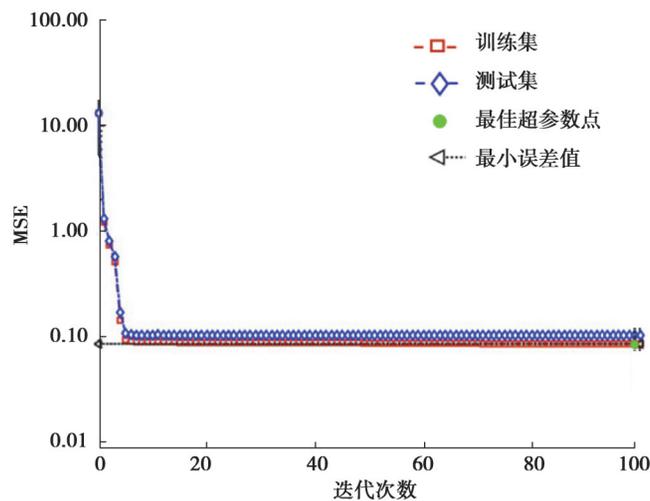


图7 超参数优化过程

Fig. 7 Hyperparameter optimization process

4 结束语

文中采用遗传算法对 Bi-LSTM 神经网络结构中的隐藏层单元数、学习率、隐藏层、L2 正则化因子进行超参数优化,构建 GA-Bi-LSTM 速度预测模型。基于 R^2 、Error Mean、Error StD、MSE 等评价指标,与 Bi-LSTM 速度预测模型相比,GA-Bi-LSTM 速度预测模型的预测精度更高,说明基于遗传算法优化的速度预测集成模型可有效适应与预测合流区高峰期复杂的速度特征,表现出更好的鲁棒性与泛化性。

参考文献

- [1] 张鑫,张卫华.快速路合流区主线不同交通状态下的安全性分析[J].吉林大学学报(工学版),2022,52(6):1308-1314.
Zhang X, Zhang W H. Safety analysis of main line under different traffic conditions in expressway confluence area[J].Journal of Jilin University(Engineering and Technology Edition), 2022,52(6):1308-1314.(in Chinese)
- [2] 帅斌,米荣伟,张锐,等.考虑驾驶行为异质性的城市快速路合流区仿真模型[J].交通运输系统工程与信息,2022,22(3):267-275,302.
Shuai B, Mi R W, Zhang R, et al. Urban expressway merging area simulation model based on heterogeneity of driving behavior [J]. Journal of Transportation Systems Engineering and Information Technology, 2022, 22(3): 267-275, 302. (in Chinese)
- [3] 贺正冰,徐瑞康,谢东繁,等.数据驱动跟驰模型综述[J].交通运输系统工程与信息,2021,21(5):102-113.
He Z B, Xu R K, Xie D F, et al. A review of data-driven car-following models [J]. Journal of Transportation Systems Engineering and Information Technology, 2021, 21(5): 102-113.(in Chinese)

- [4] 徐进,曾粤. 高速条件下隧道出入口行驶速度特性[J]. 交通运输工程学报, 2021, 21(4): 197-209.
Xu J, Zeng Y. Characteristics of driving speed at tunnel entrance and exit at high speed [J]. Journal of Traffic and Transportation Engineering, 2021, 21(4): 197-209.(in Chinese)
- [5] 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.
- [6] Mir Z H, Filali F. An adaptive Kalman filter based traffic prediction algorithm for urban road network [C]//2016 12th International Conference on Innovations in Information Technology (IIT). November 28-30, 2016, Al Ain, United Arab Emirates. IEEE, 2016: 1-6.
- [7] Yao B Z, Chen C, Cao Q D, et al. Short-term traffic speed prediction for an urban corridor[J]. Computer-Aided Civil and Infrastructure Engineering, 2017, 32(2): 154-169.
- [8] Zhao Z, Chen W H, Wu X M, et al. LSTM network: a deep learning approach for short-term traffic forecast [J]. IET Intelligent Transport Systems, 2017, 11(2): 68-75.
- [9] Xu Y Y, Kong Q J, Klette R, et al. Accurate and interpretable Bayesian MARS for traffic flow prediction [J]. IEEE Transactions on Intelligent Transportation Systems, 2014, 15(6): 2457-2469.
- [10] Zheng L J, Yang J, Chen L, et al. Dynamic spatial-temporal feature optimization with ERI big data for Short-term traffic flow prediction [J]. Neurocomputing, 2020, 412: 339-350.
- [11] Peng Y N, Xiang W L. Short-term traffic volume prediction using GA-BP based on wavelet denoising and phase space reconstruction[J]. Physica A: Statistical Mechanics and Its Applications, 2020, 549: 123913.
- [12] Ma X L, Tao Z M, Wang Y H, et al. Long short-term memory neural network for traffic speed prediction using remote microwave sensor data[J]. Transportation Research Part C: Emerging Technologies, 2015, 54: 187-197.
- [13] Kim C, Batra R, Chen L H, et al. Polymer design using genetic algorithm and machine learning[J]. Computational Materials Science, 2021, 186: 110067.
- [14] 谢济铭,夏玉兰,秦雅琴,等. 基于双向长短期记忆网络的城市快速路合流区车速预测[J/OL]. 西南交通大学学报:1-9 [2022-07-10].<http://kns.cnki.net/kcms/detail/51.1277.U.20220705.2038.020.html>.
Xie J M, Xia Y L, Qin Y Q, et al. Traffic speed prediction in merging zone of urban expressway based on bidirectional long short-term memory network [J/OL]. Journal of Southwest Jiao tong University: 1-9 [2022-07-10].<http://kns.cnki.net/kcms/detail/51.1277.U.20220705.2038.020.html>.(in Chinese)
- [15] Kline R B, Little T D. Principles and practice of structural equation modeling[M]. New York: Guilford Press, 2011.

(编辑 詹燕平)