

文章编号: 1005-0523(2023)06-0062-07



基于组合预测模型的高铁预售期购票量预测研究

徐玉萍, 吴志刚, 王宗宇

(华东交通大学交通运输工程学院, 江西 南昌 330013)

摘要: 随着中国交通强国战略的部署, 高速铁路网络正持续扩展, 铁路旅客出行的需求量稳步提升。面对庞大的高铁客运市场, 如何运用智能高效的深度学习组合预测模型, 融合多种购票影响特征因素, 实时掌握预售期每天旅客购票需求的变化情况, 从而为铁路部门提供高效可靠的旅客车票预售期购票量预测模型成为亟需解决的问题。以沪昆高铁线路上 OD (origin-destination) 间高铁旅客历史购票数据为实例, 考虑历史连续发车日期预售期每天购票量、发车日期的日期、节假日和季节特征属性, 构建了基于深度学习 CNN-LSTM 的高铁预售期购票量组合预测模型。研究表明, 基于深度学习 CNN-LSTM 的组合预测模型相较于参数模型和机器学习模型预测性能更佳, 为铁路客运市场动态调整票额提供了相关理论参考。

关键词: 高速铁路; 车票预售期; 深度学习; 多特征融合; 组合预测模型

中图分类号: U293.1+3

文献标志码: A

本文引用格式: 徐玉萍, 吴志刚, 王宗宇. 基于组合预测模型的高铁预售期购票量预测研究[J]. 华东交通大学学报, 2023, 40(6): 62-68.

DOI: 10.16749/j.cnki.jecjtu.2023.06.005

Prediction of Ticket Purchase Volume in Pre-Sale Period of High-Speed Railway Based on Combined Prediction Model

Xu Yuping, Wu Zhigang, Wang Zongyu

(School of Transportation Engineering, East China Jiaotong University, Nanchang 330013, China)

Abstract: With the deployment of China's transportation power strategy, the high-speed railway network is continuing to expand. The demand for railway passenger travel is steadily increasing. Facing the huge high-speed railway passenger transport market, how to use intelligent and efficient deep learning technology to build a combined prediction model is a challenge. This paper integrates a variety of factors affecting ticket purchases and is committed to explore the changes in passenger ticket purchase demand on each day of the pre-sale period in real time. This shows that it's becoming an urgent problem to provide an efficient and reliable prediction model for passenger ticket pre-sale period for the railway department. This paper takes the historical ticket purchase data of high-speed railway passengers between OD (origin-destination) on the Shanghai-Kunming high-speed railway line as an example. The combined prediction model considers the number of tickets purchased on each day of the pre-sale period of the historical continuous departure date, the date of the departure date, statutory holiday, and seasonal characteristics. The research shows that the combined prediction model based on deep learning CNN-LSTM has better predictive power than the parameter model and machine learning model, which provides a

收稿日期: 2023-05-06

基金项目: 国家自然科学基金委员会青年科学基金项目(52002127); 江西省社科基金规划项目(22YJ17); 江西省研究生创新专项资金项目(YC2021-S421)

theoretical reference for the dynamic adjustment of fares in the railway passenger transport market.

Key words: high-speed railway; ticket pre-sale period; deep learning; multi-feature fusion; combined prediction model

Citation format: XU Y P, WU Z G, WANG Z Y. Prediction of ticket purchase volume in pre-sale period of high-speed railway based on combined prediction model [J]. Journal of East China Jiaotong University, 2023, 40 (6): 62-68.

中国现已建成投入运营具有世界先进水平的“四纵四横”高速铁路网络,基本覆盖大中城市及省会城市,正迈向“八纵八横”的高速铁路网。高铁旅客车票预售期是指铁路部门作为承运人提前发售旅客车票的天数^[1]。如何精准预测高铁车票预售期内各天旅客购票量的变化规律,是铁路部门提升运营生产效能的关键所在。

随着信息化时代的到来,近年来大数据技术中机器学习和深度学习神经网络因其自适应性、非线性、任意函数性和映射能力等特点,大量应用于交通运输领域的时间序列数据预测。徐玉萍等^[2]运用乘积季节模型引入注意力机制 LSTM 组合模型预测了铁路货运量。魏建堂等^[3]基于 DLP-WNN 神经网络构建了高铁日客流量中期预测模型。徐光明等^[4]基于考虑多输出间关联性的最小二乘支持向量回归-卷积长短期记忆网络模型预测了高铁预售期旅客购票量分布。史峰等^[5]运用 VMD-GA-BP 神经网络模型预测了高铁 OD 间日客流量。黄海超等^[6]运用 VMD-LSTM 神经网络模型预测了轨道交通小时客流量。滕靖等^[7]运用 PSO-LSTM 组合预测模型对高铁 OD 间短期客流进行了预测。WEN 等^[8]基于分解技术的迁移学习预测了沪昆高铁车站的节假日短期进出站客流量。在参数模型方面。姚加林等^[9]基于 ARIMA 模型预测了高铁 OD 间的日客流量。XIAO 等^[10]基于矩阵最小二乘法获取交通流特征信息,用灰色预测模型预测道路交通流量。帅斌等^[11]采用灰色预测模型预测了市郊铁路 OD 间日客流量。

针对高铁起止点 (origin-destination, OD) 预售期内各天购票量进行分析,结合多种数据特征,构建深度学习 CNN-LSTM 组合预测模型,把握预售期各天旅客购票需求变化情况,从而为铁路部门灵活调整票额划分和运输组织计划提供一定的依据。

1 高铁预售期购票量组合预测模型

1.1 CNN 卷积神经网络

设高铁 OD 间旅客车票预售期的总天数为 m , 发车日期的总天数为 n ; 旅客在预售期的第 s 天购买的第 d 天发车的购票量表示为 x_d^s (s 为预售期各天序号, $s=1, 2, \dots, m$; d 为发车日期序号, $d=1, 2, \dots, n$); X_d 表示在第 d 天发车,位于预售期第 1 天至第 m 天的购票量, $X_d=(x_d^1, x_d^2, \dots, x_d^m)$ 。针对各天发车的车票预售期内旅客购票量,采用一维卷积神经网络进行运算,分为卷积层和池化层两类操作。其中卷积层运算如下

$$C_{l_c}^{j_c} = f_c(\text{ConvD}(\sum(C_{l_{\text{input}}}^{i_c} * cw_{l_c}^{i_c j_c} + cb_{l_c}^{i_c}))) \quad (1)$$

式中: ConvD 为 1 维卷积操作^[12]; f_c 为卷积过程中的激活操作,在此参考已有文献,在卷积过程中均采用线性层 (linear layer), 未设激活函数^[13]; $C_{l_{\text{input}}}^{i_c}$ 为输入的数据矩阵; $C_{l_c}^{j_c}$ 为卷积后输出的数据矩阵; l_{input} 为输入数据矩阵的时间序列长度; l_c 为卷积后数据矩阵的时间序列长度; i_c 为卷积前数据矩阵的列数; j_c 为卷积后数据矩阵的列数; $cw_{l_c}^{i_c j_c}$ 为预测模型卷积核中的权重值; $cb_{l_c}^{i_c}$ 为卷积层的偏置值。

在一维卷积的池化层中用卷积后输出得到的数据 $C_{l_c}^{j_c}$ 进行二次采样。在此选择最大池化操作,池化的操作如式 2 所示,其中 $C_{l_{\text{cp}}}^{j_{\text{cp}}}$ 为二次采样池化后的输出数据值^[14]。

$$C_{l_{\text{cp}}}^{j_{\text{cp}}} = P_{\text{max}}(C_{l_c}^{j_c}) \quad (2)$$

式中: P_{max} 为预测模型中最大池化操作; l_{cp} 为池化后矩阵的时间序列长度; j_{cp} 为池化后数据矩阵的列数。

1.2 LSTM 长短期记忆神经网络

长短期记忆神经网络 (LSTM) 能够通过门结构

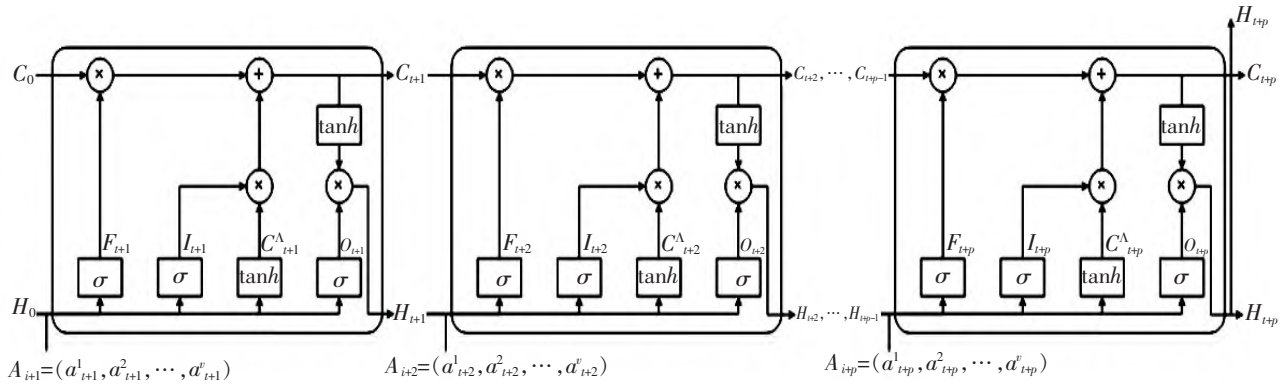


图 1 长短期记忆神经网络 LSTM 结构示意图

Fig.1 Schematic diagram of the structure of the long and short term memory neural network

对细胞状态进行运算,如图 1 所示。

在 LSTM 网络中输入 $\{A_{t+1}, A_{t+1}, \dots, A_{t+p}\}$, 即前 p 天(第 $t+1$ 天至第 $t+p$ 天)发车的各发车日共计 v 种数据特征,其中 $t(0 \leq t \leq n-p-1)$ 为高铁旅客车票发车日期对应的时间戳。 $A_{t+1} = (a_{t+1}^1, a_{t+1}^2, \dots, a_{t+1}^v)$ 含有在第 $t+1$ 天发车对应发车日期的日期、节假日和季节属性共计 v 种特征,在对样本进行模型训练和预测的过程中,作为组合模型输入结构的第二部分。 σ 和 \tanh 激活函数的计算如下

$$\sigma(\gamma) = \frac{1}{1+e^{-\gamma}} \quad (3)$$

$$\tanh(\gamma) = \frac{e^{-\gamma} - e^{\gamma}}{e^{\gamma} + e^{-\gamma}} \quad (4)$$

以发车日期位于样本的第 d 天作为时间序列的划分标准。在 LSTM 网络中有 3 类门,遗忘门 F_d , 输入门 I_d 和输出门 O_d ; H_{d-1} 为上一时间序列的隐藏状态,隐藏状态在初始时即 H_0 中的各元素为 0; C_{d-1} 为上一时序的记忆细胞状态,细胞状态在初始状态时即 C_0 中的各元素为 0; C_d 为当前时间序列的记忆细胞状态, \hat{C}_d 为候选细胞; H_{t+p} 为最终输出,其值蕴含了预测的第 $t+p+1$ 天预售期内各天购票量的信息。LSTM 网络在训练网络、输出预测值的计算过程如下

$$F_d = \sigma(W_f A_d + U_f A_{d-1} + b_f) \quad (5)$$

$$I_d = \sigma(W_i A_d + U_i A_{d-1} + b_i) \quad (6)$$

$$\hat{C}_d = \tanh(W_c A_d + U_c H_{d-1} + b_c) \quad (7)$$

$$C_d = F_d \odot C_{d-1} + I_d \odot \hat{C}_d \quad (8)$$

$$O_d = \sigma(W_o A_d + U_o H_{d-1} + b_o) \quad (9)$$

$$H_d = O_d \odot \tanh(C_d) \quad (10)$$

式中: \odot 为 Hadamard 乘积; $W_f, W_i, W_c, W_o, U_f, U_i, U_c, U_o$ 分别为遗忘门 F_d ; 输入门 I_d , 候选细胞 \hat{C}_d , 输出门 O_d 的权重矩阵; b_f, b_i, b_c, b_o 为偏置向量参数^[15]。

1.3 融合车票发车日期特征的高铁预售期组合预测模型

在此以高铁 OD 间发车日期为时间衡量标准,参考现有预测模型相关文献,选取旅客车票发车日的日期、节假日和季节属性作为组合预测模型中的特征标签^[16]。各特征标签如表 1 所示。

表 1 高铁发车日期属性特征表
Tab.1 High-speed railway departure date attribute

Serial number	Departure date attributes tag names	Tag value range
1	Month	1, 2, ..., 12
2	Day of the month	1, 2, ..., 31
3	Week of the year	0, 1, ..., 52
4	Day of the week	1, 2, ..., 7
5	Weekend	0, 1
6	Holiday	0, 1
7	Working day	0, 1
8	Season	1, 2, 3, 4

基于深度学习 CNN-LSTM 的高铁旅客车票预售期购票量组合预测模型运算过程共分为 7 步。

1) 高铁 OD 间预售期购票量数据采集。经过数据预处理获取高铁 OD 间历史预售期购票量总样本 P_{All} 如式 11 所示。

$$P_{All} = \begin{bmatrix} 1 & 2 & \cdots & m \\ x_1 & x_1 & \cdots & x_1 \\ 1 & 2 & \cdots & m \\ x_2 & x_2 & \cdots & x_2 \\ \vdots & \vdots & \ddots & \vdots \\ 1 & 2 & \cdots & m \\ x_n & x_n & \cdots & x_n \end{bmatrix} \quad (11)$$

P_{All} 的每一行 $X_d=(x_d^1, x_d^2, \dots, x_d^m)$ 代表在同一发车日期的预售期各天的购票量 x_d^m 的信息,将其作为模型输入结构的第一部分。

2) 车票发车日期的日期属性特征采集。采集高铁 OD 间车票发车日期的日期、节假日和季节特征总样本 Q_{All} 如下

$$Q_{All} = \begin{bmatrix} 1 & 2 & \cdots & v \\ a_1 & a_1 & \cdots & a_1 \\ 1 & 2 & \cdots & v \\ a_2 & a_2 & \cdots & a_2 \\ \vdots & \vdots & \ddots & \vdots \\ 1 & 2 & \cdots & v \\ a_n & a_n & \cdots & a_n \end{bmatrix} \quad (12)$$

上式中 v 为车票发车日期的日期、节假日和季节特征属性总特征数(选取“月份”、“每月第几天”、“季节”等共计 8 种特征,在此 v 取值为 8)。 Q_{All} 中每一行 $A_d = (a_d^1, a_d^2, \dots, a_d^v)$ 含有在第 d 天发车对应发车日期的日期、节假日和季节属性,将其作为模型输入结构的第二部分。

3) 数据标准化处理。采用离差标准化方法(min-max 标准化方法)对高铁车票预售期旅客购票量和特征信息数据进行标准化处理。

4) 训练集和测试集的划分。将共计 364 d 发车的预售期购票量和车票特征信息数据的总样本 P_{Train} 和 Q_{Train} ,采用 8:2 的比例求余数取整后划分训练集和测试集。将车票发车日期为样本第 1 天至第 288 天的预售期各天购票量和车票发车日期的多特征属性数据共计 288 行数据作为训练集 P_{Train}, Q_{Train} ,如下

$$P_{Train} = \begin{bmatrix} 1 & 2 & \cdots & m \\ x_1 & x_1 & \cdots & x_1 \\ 1 & 2 & \cdots & m \\ x_2 & x_2 & \cdots & x_2 \\ \vdots & \vdots & \ddots & \vdots \\ 1 & 2 & \cdots & m \\ x_{n,Train} & x_{n,Train} & \cdots & x_{n,Train} \end{bmatrix} \quad (13)$$

$$Q_{Train} = \begin{bmatrix} 1 & 2 & \cdots & v \\ a_1 & a_1 & \cdots & a_1 \\ 1 & 2 & \cdots & v \\ a_2 & a_2 & \cdots & a_2 \\ \vdots & \vdots & \ddots & \vdots \\ 1 & 2 & \cdots & v \\ a_{n,Train} & a_{n,Train} & \cdots & a_{n,Train} \end{bmatrix} \quad (14)$$

将车票发车日期为样本第 289 天至第 360 天的预售期各天购票量和车票发车日期的多特征属性数据共计 72 行数据作为测试集 P_{Test}, Q_{Test} ,如下

$$P_{Test} = \begin{bmatrix} 1 & 2 & \cdots & m \\ x_1 & x_1 & \cdots & x_1 \\ 1 & 2 & \cdots & m \\ x_2 & x_2 & \cdots & x_2 \\ \vdots & \vdots & \ddots & \vdots \\ 1 & 2 & \cdots & m \\ x_{n,Test} & x_{n,Test} & \cdots & x_{n,Test} \end{bmatrix} \quad (15)$$

$$Q_{Test} = \begin{bmatrix} 1 & 2 & \cdots & v \\ x_1 & x_1 & \cdots & x_1 \\ 1 & 2 & \cdots & v \\ x_2 & x_2 & \cdots & x_2 \\ \vdots & \vdots & \ddots & \vdots \\ 1 & 2 & \cdots & v \\ x_{n,Test} & x_{n,Test} & \cdots & x_{n,Test} \end{bmatrix} \quad (16)$$

5) 构建基于深度学习 CNN-LSTM 的高铁旅客车票预售期购票量组合预测模型。运用深度学习中的卷积神经网络 CNN、长短期记忆神经网络 LSTM、Dropout 约束层、Flatten 展平层和全连接 Dense 层,构建组合预测模型^[7]。在此以输入前 p 天(即第 $t+1$ 天至第 $t+p$ 天)发车的预售期购票量数据 $\{X_{t+1}, X_{t+2}, \dots, X_{t+p}\}$ 和发车日期蕴含的多特征数据 $\{A_{t+1}, A_{t+2}, \dots, A_{t+p}\}$,预测输出第 $t+p+1$ 天发车的预售期购票量数据 \hat{X}_{t+p+1} 为例进行说明。

模型运用 Keras 框架中的 Keras.layers.add 方法进行特征加权融合。待模型训练后,将测试集中的数据输入训练后的模型,得到模型的预测数据 $\hat{X}_{t+p+1}=(\hat{X}_{t+p+1}^1, \hat{X}_{t+p+1}^2, \dots, \hat{X}_{t+p+1}^m)$ 。

6) 预测数据反归一化处理。将预测模型测试集中模型预测的数据,进行反归一化处理,便于后续和模型预测数据对应的样本真实值进行比较,从而衡量模型的预测精度。

7) 预测模型精度的测定。将反归一化后的数据和真实的旅客购票量数据进行比较运算,进行预测模型精度的测定。

2 预测结果分析

2.1 实验数据

使用铁路部门提供的沪昆高铁 OD 间车票预售期内各天旅客购票量为例,进行数据分析预测。运用 Python 中 Matplotlib 库绘制的算例 1、算例 2 的预售期内的购票量情况如图 2、图 3 所示。图中 X 轴表示高铁车票样本发车日期序号中的第 d 天, Y 轴表示位于共计 m d(此时 m 取值为 60 d)车票预售期的第 s 天, Z 轴表示高铁旅客在预售期的第 s 天购买在样本中第 d 天发车的旅客购票数量 x_d^s 。

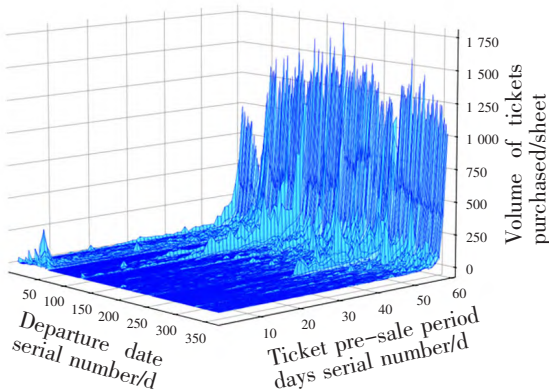


图 2 算例 1 总样本的高铁车票预售期购票量
Fig.2 Total sample of high-speed railway tickets purchased during the pre-sale period of example 1

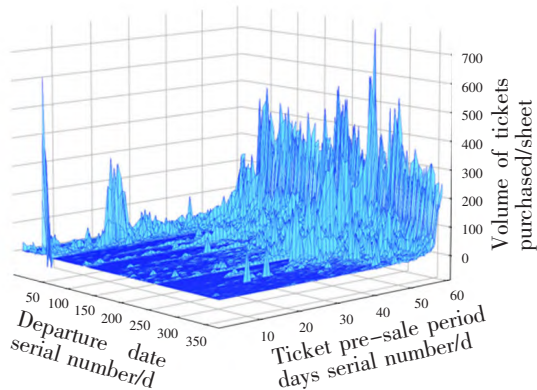


图 3 算例 2 总样本的高铁车票预售期购票量
Fig.3 Total sample of high-speed railway tickets purchased during the pre-sale period of example 2

2.2 实验评价指标

在此运用上文构建的基于深度学习 CNN-LSTM 的高铁预售期购票量组合预测模型,经过训练集训练后在测试集上运算的预测值和真实值的预测精度指标采用均方根误差 (root mean square error, RMSE)、平均绝对误差 (mean absolute error,

MAE) 和平均绝对百分比误差 (mean absolute percentage error, MAPE) 三方面进行评价,分别如式 18 至 20 所示^[18]。

$$\text{RMSE} = \sqrt{\frac{1}{z} \sum_{j=1}^z (\hat{X}_{\text{Test},j} - X_{\text{Test},j})^2} \quad (17)$$

$$\text{MAE} = \frac{1}{z} \sum_{j=1}^z \left| \hat{X}_{\text{Test},j} - X_{\text{Test},j} \right| \quad (18)$$

$$\text{MAPE} = \frac{100\%}{z} \sum_{j=1}^z \left| \frac{\hat{X}_{\text{Test},j} - X_{\text{Test},j}}{X_{\text{Test},j}} \right| \quad (19)$$

式中: $\hat{X}_{\text{Test},j}$ 为测试集中模型输出的预测购票量矩阵; $X_{\text{Test},j}$ 为预测购票量矩阵在样本中同一日期的真实购票量矩阵; j 表示测试集中预测的各预售期购票量对应的发车日期序号; z 为测试集预测输出结果对应的发车日期总天数, $j=1, 2, \dots, z$ 。

2.3 实验结果分析

在实验中 CNN 网络的卷积核数分别设置为 32 和 64,采用同尺寸填充, LSTM 隐藏神经元数为 60, Dropout 参数为 0.2, 损失函数为 MSE, 优化器为 Adam, 学习率为 0.001, 迭代次数 epoch 为 100, batchsize 为 128, 模型预测输入数据中对应发车天数 p 为 7。将第 1 天至第 288 天发车的预售期各天购票量共计 288 行数据作为训练集, 将样本中第 289 天至第 360 天发车的预售期各天购票量共计 72 行数据作为测试集, 基于上文构建的组合预测模型的预测值和真实值的如图 4、图 5 所示。

将上文构建的基于深度学习 CNN-LSTM 的高铁预售期购票量组合预测模型与传统参数模型和

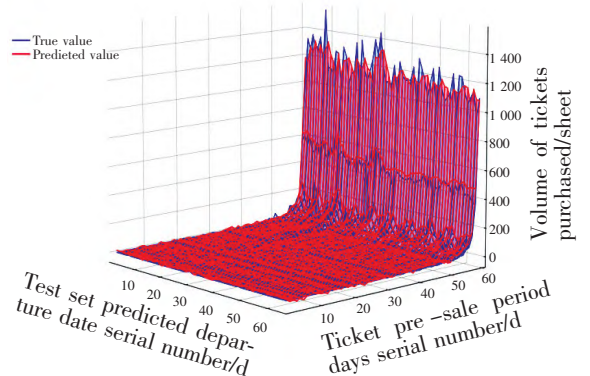


图 4 算例 1 基于深度学习 CNN-LSTM 的高铁预售期购票量组合预测模型预测值与真实值对比图

Fig.4 Comparison of predicted and real values of combined prediction model of high-speed railway pre-sale ticket quantity based on deep learning CNN-LSTM of example 1

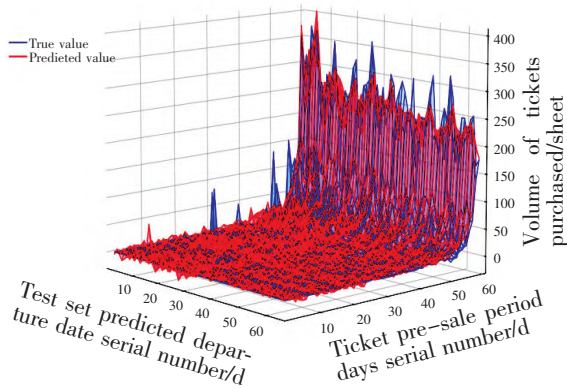


图 5 算例 2 基于深度学习 CNN-LSTM 的高铁预售期购票量组合预测模型预测值与真实值对比图

Fig.5 Comparison of predicted and real values of combined prediction model of high-speed railway pre-sale ticket quantity based on deep learning CNN-LSTM of example 2

机器模型进行预测误差精度的对比分析,算例 1、算例 2 的结果分别如表 2、表 3 所示。

由以上两表可知,上文构建的基于深度学习 CNN-LSTM 的高铁预售期购票量组合预测模型在算例 1 中 MAPE 误差精度较 ARIMA 模型提升

表 2 算例 1 高铁预售期购票量预测模型误差精度效果对比
Tab.2 Comparison of error accuracy effects of pre-sale ticket quantity prediction models for high-speed railway of example 1

Prediction model	RMSE/sheet	MAE/sheet	MAPE/%
ARIMA	37.9	11.8	8.7
BP	33.9	20.9	3.1
CNN	22.4	9.5	1.4
LSTM	28.3	12.6	7.0
CNN-LSTM combination	24.0	11.9	1.1

表 3 算例 2 高铁预售期购票量预测模型误差精度效果对比
Tab.3 Comparison of error accuracy effects of pre-sale ticket quantity prediction models for high-speed railway of example 2

Prediction model	RMSE/sheet	MAE/sheet	MAPE/%
ARIMA	48.5	13.0	19.2
BP	18.9	13.3	22.0
CNN	13.2	7.3	3.4
LSTM	14.3	7.1	2.3
CNN-LSTM combination	13.8	8.1	1.1

7.6%,较 BP 模型提升 2%,较 CNN 模型提升 0.3%,较 LSTM 模型提升 5.9%;算例 2 中 MAPE 误差精度较 ARIMA 模型提升 18.1%,较 BP 模型提升 20.9%,较 CNN 模型提升 2.3%,较 LSTM 模型提升 1.2%。

3 结论

1) 对比 ARIMA 模型、BP 神经网络、CNN 卷积神经网络、LSTM 长短期记忆神经网络、CNN-LSTM 组合模型,发现上文基于深度学习 CNN-LSTM 的高铁预售期购票量组合预测模型可在一定程度上提高预测精度,由此可见,所提出的高铁预售期购票量组合预测模型适用于高铁 OD 间的预售期购票需求预测。

2) 考虑历史连续发车预售期每天购票量、日期、节假日和季节特征属性的组合预测模型的平均绝对百分比误差 MAPE 精度较高,但从评价指标可知,与其他预测模型的效果差距不大。

参考文献

[1] 何南,贺全志,思东琴. 旅客列车车票预售期设置研究[J]. 铁道学报,2019,41(10):1-9.
HE N, HE Q Z, SI D Q. Planning of pre-sale period of passenger train tickets[J]. Journal of the China Railway Society, 2019, 41(10):1-9.

[2] 徐玉萍,邓俊翔,蒋泽华. 基于组合预测模型的铁路货运量预测研究[J]. 铁道科学与工程学报,2021,18(1):243-249.
XU Y P, DENG J X, JIANG Z H. Railway freight volume forecasting based on a combined model[J]. Journal of Railway Science and Engineering, 2021, 18(1):243-249.

[3] 魏堂建,杨星琪,徐光明,等. 基于 DLP-WNN 的高速铁路日客流量中期预测[J]. 中国铁道科学,2021,42(6):194-204.
WEI T J, YANG X Q, XU G M, et al. Medium-term forecast method for daily passenger flow of high-speed railway based on DLP-WNN[J]. China Railway Science, 2021, 42(6):194-204.

[4] 徐光明,林珊珊,米希伟,等. 高速铁路预售期旅客购票量分布预测[J/OL]. 铁道科学与工程学报:1-12[2023-06-20].
<https://doi.org/10.19713/j.cnki.43-1423/u.T20230293>.
XU G M, LIN S S, MI X W, et al. Prediction of passenger booking volume distribution during pre-sale period for high-speed railways[J/OL]. Journal of Railway Science and

- Engineering; 1–12[2023–06–20]. <https://doi.org/10.19713/j.cnki.43-1423/u.T20230293>.
- [5] 史峰, 杨星琪, 胡心磊, 等. 基于数据替补修正的高速铁路日常客流量 VMD-GA-BP 预测方法[J]. 中国铁道科学, 2019, 40(3): 129–136.
SHI F, YANG X Q, HU X L, et al. A VMA-GA-BP method for predicting non-holiday passenger flow of high speed railway based on data replacement correction[J]. China Railway Science, 2019, 40(3): 129–136.
- [6] 黄海超, 陈景雅, 孙睿. 基于 VMD-LSTM 轨道交通客流预测模型[J]. 华东交通大学学报, 2021, 38(1): 95–99.
HUANG H C, CHEN J Y, SUN R. Rail transit passenger flow prediction model based on VMD-LSTM[J]. Journal of East China Jiaotong University, 2021, 38(1): 95–99.
- [7] 滕靖, 李金洋. 考虑日期属性和天气因素的铁路城际短期客流预测方法[J]. 中国铁道科学, 2020, 41(5): 136–144.
TENG J, LI J Y. Short-term forecast method for intercity railway passenger flow considering date attributes and weather factors[J]. China Railway Science, 2020, 41(5): 136–144.
- [8] WEN K, ZHAO G, HE B, et al. A decomposition-based forecasting method with transfer learning for railway short-term passenger flow in holidays[J]. Expert Systems with Applications, 2022, 189: 116102.
- [9] 姚加林, 皮珊. 基于 ARIMA 模型的高铁浮动票价与票额分配优化方法[J]. 铁道科学与工程学报, 2020, 17(7): 1655–1661.
YAO J L, PI S. The Optimization method of floating ticket price and ticket allocation of high-speed railway based on ARIMA model[J]. Journal of Railway Science and Engineering, 2020, 17(7): 1655–1661.
- [10] XIAO X, DUAN H. A new grey model for traffic flow mechanics[J]. Engineering Applications of Artificial Intelligence, 2020, 88: 103350.
- [11] 帅斌, 张玥, 张永超. 我国市郊铁路客流特征分析及需求预测[J]. 铁道工程学报, 2014(1): 20–23.
SHUAI B, ZHANG Y, ZHANG Y C. Analysis of suburban railway passenger flow characteristics and demand forecast in China[J]. Journal of Railway Engineering Society, 2014(1): 20–23.
- [12] ALJUAYDI F, WIWATANAPATAPHEE B, WU Y H. Multivariate machine learning-based prediction models of freeway traffic flow under non-recurrent events[J]. Alexandria Engineering Journal, 2023, 65: 151–162.
- [13] ZHANG J, CHE H, CHEN F, et al. Short-term origin-destination demand prediction in urban rail transit systems: A channel-wise attentive split-convolutional neural network method[J]. Transportation Research Part C: Emerging Technologies, 2021, 124: 102928.
- [14] REMPE F, FRANECK P, BOGENBERGER K. On the estimation of traffic speeds with deep convolutional neural networks given probe data[J]. Transportation Research Part C: Emerging Technologies, 2022, 134: 103448.
- [15] GUAN L, SHI J, WANG D, et al. A trajectory prediction method based on bayonet importance encoding and bidirectional LSTM[J]. Expert Systems with Applications, 2023, 223: 119888.
- [16] TSAI T H, LEE C K, WEI C H. Neural network based temporal feature models for short-term railway passenger demand forecasting[J]. Expert Systems with Applications, 2009, 36(2): 3728–3736.
- [17] MAO J, HUANG H, LU W, et al. Multi-precision traffic speed predictions via modified sequence to sequence model and spatial dependency evaluation method[J]. Applied Soft Computing, 2022, 130: 109700.
- [18] ISRABEL D P, SILAS S, RAJSINGH E B. Long-term traffic flow prediction using multivariate SSA forecasting in SDN based networks[J]. Pervasive and Mobile Computing, 2022, 83: 101590.



通信作者: 徐玉萍(1973—), 女, 教授, 硕士生导师, 研究方向为交通运输规划与管理。E-mail: 1423907384@qq.com。

(责任编辑: 姜红贵)