2021 年 第 21 卷 第 35 期
2021, 21(35): 15270-07

科 学 技 术 与 工 程
Science Technology and Engineering

ISSN 1671—1815
CN 11—4688/T

引用格式:王 飞, 孙鹏飞. 基于分解集成方法的空中交通流量短期预测[J]. 科学技术与工程, 2021, 21(35): 15270-15276.
Wang Fei, Sun Pengfei. Short term forecasting of air traffic flow based on decomposition and integration method[J]. Science Technology and Engineering, 2021, 21(35): 15270-15276.

基于分解集成方法的空中交通流量短期预测

王 飞, 孙鹏飞
(中国民航大学空中交通管理学院, 天津 300300)

摘 要 为对空中交通流量进行短期预测,提出了基于分解集成方法的组合预测模型。首先,应用集合经验模态分解(ensemble empirical mode decomposition,EEMD)方法将流量时序数据分解为若干个分量;其次,应用排列熵计算各分量的复杂度,复杂度高于0.5的归为高频分量,其余归为低频分量;然后,高频分量采用BP(back propagation)神经网络算法进行预测,低频分量采用最小二乘法进行预测;接着,对分量的预测结果进行加和集成,得到了最终的预测值。最后,采集实际运行数据进行算例分析。通过比较1~6 h和7~12 h的预测结果,本文模型在1~6 h的均等系数(equal coefficient,EC)值为0.905,准确度更高。与EMD-BP-OLS模型、BP模型进行比较,本文模型的评价指标均优于其他模型。通过比较60、30、15 min时间尺度数据的预测结果,60 min时间尺度的EC值为0.924,准确度最高。结果表明,提出的模型是可行的和有效的,更适用于短期流量预测。

关键词 航空运输; 流量短期预测; 分解集成方法; 集合经验模态分解; BP神经网络
中图法分类号 V355; **文献标志码** A

Short Term Forecasting of Air Traffic Flow Based on Decomposition and Integration Method

WANG Fei, SUN Peng-fei
(College of Air Traffic Management, Civil Aviation University of China, Tianjin 300300, China)

[**Abstract**] In order to forecast air traffic flow in short term, a combined forecasting model based on decomposition and integration method was proposed. Firstly, the ensemble empirical mode decomposition (EEMD) method was used to decompose the traffic time series data into several components. Secondly, the permutation entropy was used to calculate the complexity of each component. The high-frequency component was classified as high-frequency component and the rest was classified as low-frequency component. Then, BP(back propagation) neural network algorithm was used to predict the high-frequency component, and the least square method was used to predict the low-frequency component, and the prediction results of the components were added. Finally, the final prediction value was obtained, and the actual operation data were collected for example analysis. By comparing the prediction results of 0~6 h and 6~12 h, the equal coefficient (EC) value of the model in 0~6 h is 0.905, and the accuracy is higher. Compared with EMD-BP-OLS model and BP model, the evaluation index of this model is better than other models. By comparing the prediction results of 60 min, 30 min and 15 min time scale data, the EC value of 60 min time scale is 0.924, with the highest accuracy. The results show that the proposed model is feasible and effective, and more suitable for short-term flow forecasting.

[**Keywords**] air transport; short term traffic forecast; decomposition integration method; ensemble empirical mode decomposition; BP neural network

随着中国社会的进步与民航事业的发展,航班量持续增加,空域资源日益紧张,空管的协调压力持续增大,为了缓解空域拥挤和降低管制员的负荷,需要对空中交通流进行优化和管理。流量预测是空中交通管理的重要内容,流量预测一般分为中长期预测与短期预测,中长期预测可以为航空公司运营调整、机场建设和改造提供参考,流量短期预测可以为管制员提供辅助决策信息,对优化交通流和减少延误更具现实意义。因此,对空中交通流量进行短期预测是很有必要的。

目前中外学者对空中交通流量短期预测的主要研究方法有:①基于飞行计划的预测方法,该方法简单易行,但在航路飞行时,不确定因素较多,预测精度较差,并且航班量巨大时,运算较为复杂,速度较慢;②基于数理统计的预测方法,主要考虑了空中交通流的线性特征,操作较为简便,但对非线

收稿日期: 2021-04-10; **修订日期**: 2021-08-31
基金项目: 国家自然科学基金青年科学基金(71801215);中央高校基本科研业务费专项(3122019129)
第一作者: 王 飞(1982—),男,汉族,安徽凤阳人,博士,副研究员。研究方向:交通运输规划与管理。E-mail:feiwang@cauc.edu.cn。

性因素考虑不足,具有局限性;③智能预测方法,具有较强的自学习能力、适应性和鲁棒性,可以在大量的数据中挖掘出复杂的数据关系,但数据较少时无法准确地获取数据的特征,预测效果较差;④基于非线性混沌理论的预测方法,该方法要求非常恰当的重构系统相空间,但相空间重构参数难以准确确定,主观性较强。

空中交通流已被证实具有复杂的非线性特征,杨阳[1]对空域扇区流量时间序列具备混沌特性进行了验证,王飞[2]对短期空中交通流的时间序列进行了非线性检验,验证了 5 min 时间尺度的空中交通流时间序列是非线性的。

针对空中交通非线性系统,传统方法在刻画内部结构、揭示演化机理、预测发展趋势等方面存在结构性瓶颈;由于空中交通流容易受到天气和人为等因素的影响,具有较强的非线性,利用单一方法直接进行预测时,难以取得较好的预测效果。分解集成方法自提出以来,在复杂非线性系统应用方面显示出良好的应用前景。分解集成方法在空中交通流预测领域的研究处于起步阶段,但该方法在股票、油价、电力预测等领域均有应用,尤其是地面交通领域的研究成果可为空中交通流量短期预测提供借鉴。贺毅岳等[3]提出了经验模态分解下基于支持向量回归的股票价格集成预测方法(empirical mode decomposition and SVR based stock price integrated forecasting,EMD-SVRF),实现了对非平稳、非线性股票价格时间序列的高精度预测。汪子述[4]构建了基于数据特征驱动重构的分解集成模型,并通过对原油价格进行预测,证明了该模型具有更高的预测准确度和更少的预测时间。周程等[5]提出了一种基于趋势分解和小波变换的多重"分解-集成"预测方法,利用趋势分解将货运量分解为趋势项和非趋势项,通过小波分解将非趋势项进一步分解成低频项和高频项,分别建立预测模型,选用相加集成得到货运量预测值,降低了问题复杂度,有效提高了预测性能。Wang 等[6]提出了一种 EMD-ARIMA(empirical mode decomposition and autoregressive integrated moving average)组合模型,对 5 ~ 20 min 内的高速公路车辆速度进行了预测,并将 EMD-ARIMA 组合模型与差分自回归移动平均模型(autoregressive integrated moving average, ARIMA),人工神经网络(artificial neural network, ANN)等传统预测方法进行比较,发现提出的组合预测模型结果更好。Majumder 等[7]提出了一种基于变分模态分解(variational mode decomposition, VMD)和新内核极限学习机的组合预测模型,用于太阳能辐射的预测,与其他模型作比较,有更高的预测精度。

为了对空中交通流量进行短期预测,现提出基于分解集成方法的组合预测模型。首先,对流量时序数据进行集合经验模态分解,得到若干分量,通过复杂度检验将这些分量分为高频和低频,高频的分量采用 BP(back propagation)神经网络进行预测,低频的分量使用最小二乘法进行预测。最后对各分量预测的结果采用线性加和进行集成预测,得到最终的预测结果。

1　分解与预测方法

1.1　集合经验模态分解

经典模态分解(empirical mode decomposition, EMD)是一种自适应信号时频处理方法,此方法可以根据数据的时间尺度特征进行分解,非常适用于非线性数据的处理[8]。但 EMD 分解存在着模态混叠问题,集合经验模态分解(ensemble empirical mode decomposition, EEMD)可有效克服这个问题[9]。

EEMD 分解的具体步骤如下。

Step 1　将白噪声 $\omega(t)$ 加入到原信号 $X(t)$ 里得到信号 $Y(t)$,表示为

$$Y(t) = X(t) + \omega(t) \tag{1}$$

Step 2　对信号 $Y(t)$ 进行 EMD 分解,得到 n 个模态分量 $c_i(t)$ 和一个残差 $r(t)$,表示为

$$Y(t) = \sum_{i=1}^{n} c_i(t) + r(t) \tag{2}$$

Step 3　重复 Step 1、Step 2 m 次,对信号 $Y(t)$ 加入不同的白噪声,得到 m 组模态分量和 m 个残差。根据文献[8],所添加的白噪声应符合关系式

$$\lambda = \frac{\varepsilon}{\sqrt{m}} \tag{3}$$

式(3)中:λ 为输入信号与经过 EEMD 分解后分量加和的误差;ε 为所加白噪声的幅值系数;m 为添加白噪声的次数。

Step 4　对得到的数据求均值,得到最终的 n 个模态分量 $\mathrm{imf}_i(t)$ 和一个残差 $\mathrm{res}(t)$,即

$$\mathrm{imf}_i(t) = \frac{1}{m}\sum_{j=1}^{m} c_{ij}(t), \quad i = 1,2,\cdots,n \tag{4}$$

$$\mathrm{res}(t) = \frac{1}{m}\sum_{j=1}^{m} r_j(t) \tag{5}$$

1.2　BP 神经网络

BP 神经网络是一种采用误差反向传播算法的神经网络,它在结构上分为输入层、隐含层和输出层,如图 1 所示。

BP 神经网络进行训练时,具体步骤如下。

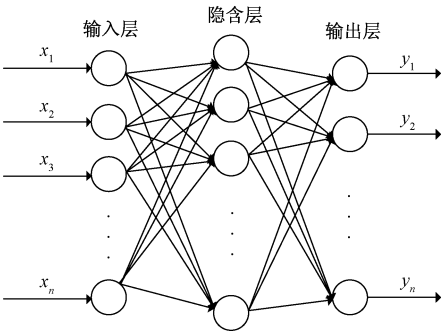

图 1 BP 神经网络的结构

Fig. 1 The structure of BP neural network

Stpe 1 信息正向传播。信息从输入层传递到隐含层,再传递到输出层,隐含层神经元的输入 u_i 为

$$u_i = \sum_{j=1}^{n} w_{ij}x_j + a_{1i} \tag{6}$$

式(6)中:n 为输入层节点数; w_{ij} 为输入层节点 j 与隐含层节点 i 之间的权重; x_j 为输入层节点; a_{1i} 为隐含层节点 i 的阈值。

隐含层神经元的输出 p_i 为

$$p_i = f(u_i) = f\left(\sum_{j=1}^{n} w_{ij}x_j + a_{1i}\right) \tag{7}$$

式(7)中:f 为隐含层的传递函数。

输出层神经元的输入 q_k 为

$$q_k = \sum_{i=1}^{r} w_{ki}p_i + a_{2k} = \sum_{i=1}^{r} w_{ki}f\left(\sum_{j=1}^{n} w_{ij}x_j + a_{1i}\right) + a_{2k} \tag{8}$$

式(8)中:r 为隐含层的节点数; w_{ki} 为隐藏层节点 i 与输出层节点 k 之间的权重; a_{2k} 为输出层节点 k 的阈值。

输出层神经元的输出 y_k 为

$$y_k = \varphi(q_k) = \varphi\left[\sum_{i=1}^{r} w_{ki}f\left(\sum_{j=1}^{n} w_{ij}x_j + a_{1i}\right) + a_{2k}\right] \tag{9}$$

式(9)中:φ 为输出层的传递函数。

Step 2 误差反向传播。得到训练的结果后与实际的数据进行比对,计算得到训练数据与实际数据的误差 E 为

$$E = \frac{1}{m}\sum_{k=1}^{m} (T_k - y_k)^2 \tag{10}$$

式(10)中:m 为输出层节点的数量; T_k 为输出层节点 k 的期望输出值。

利用误差去调整权值和阈值,使误差沿梯度方向下降,经过多次迭代后,得到误差最小的权值和阈值,停止训练。

1.3 最小二乘法

最小二乘法(ordinary least squares, OLS)是一种拟合算法,它通过寻找最小化误差的平方和拟合曲线,是一种简便的线性拟合方法。以直线拟合的例子讲解最小二乘法的原理。最小二乘法拟合的原理如下。

待拟合的 b 组数据为 (x_i, y_i) $(i = 1,2,\cdots,b)$,设拟合的直线为 $\hat{y}$, 表示为

$$\hat{y} = a_0 + a_1 x, \quad a_0, a_1 \in \mathbf{R} \tag{11}$$

$x = x_i$ 时,需要使 y_i 与 $\hat{y}_i$ 之间的差值最小,对于所有数据来说,需要使所有差值的平方和 Q 最小,表达式为

$$\sum_{i=1}^{b} [y_i - (a_0 + a_1 x_i)]^2 = Q(a_0, a_1) \tag{12}$$

为了求得 Q 的最小值,将 Q 对 a_0 和 a_1 分别求偏导,即

$$\frac{\partial Q}{\partial a_0} = -2\sum_{i=1}^{b} (y_i - a_0 - a_1 x_i) = 0 \tag{13}$$

$$\frac{\partial Q}{\partial a_1} = -2\sum_{i=1}^{b} (y_i - a_0 - a_1 x_i)x_1 = 0 \tag{14}$$

进而可计算得到 a_0、a_1, 即

$$a_0 = \frac{(\sum_{i=1}^{b} x_i^2)(\sum_{i=1}^{b} y_i) - (\sum_{i=1}^{b} x_i)(\sum_{i=1}^{b} x_i y_i)}{b(\sum_{i=1}^{b} x_i^2) - (\sum_{i=1}^{b} x_i)^2} \tag{15}$$

$$a_1 = \frac{b(\sum_{i=1}^{b} x_i y_i) - (\sum_{i=1}^{b} x_i)(\sum_{i=1}^{b} y_i)}{b(\sum_{i=1}^{b} x_i^2) - (\sum_{i=1}^{b} x_i)^2} \tag{16}$$

2 算例仿真

2.1 数据来源

数据来源于三亚 4 号扇区 2017 年 9 月 2—19 日共计 18 d 时间尺度为 30 min 的流量数据,如图 2 所示,将前 17 d 的数据作为训练数据,第 18 天前 12 h 的数据对预测模型的预测效果进行验证。

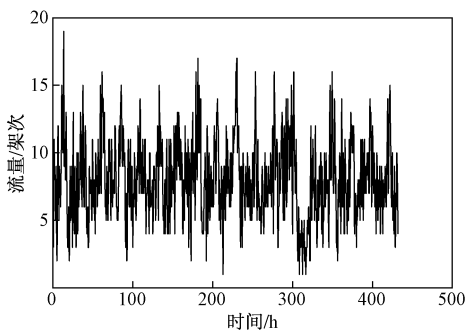

图 2 原始交通流时间序列

Fig. 2 Original traffic flow time series

2.2　评价指标

为了评估预测模型性能,选择了均方根误差(root mean squared error, RMSE);平均绝对误差(mean absolute error, MAE);均等系数(equal coefficient, EC)作为评价指标,计算公式为

$$\mathrm{RMSE} = \sqrt{\frac{1}{N}\sum_{t=1}^{N}(y_t - \hat{y}_t)^2} \tag{17}$$

$$\mathrm{MAE} = \frac{1}{N}\sum_{t=1}^{N}|y_t - \hat{y}_t| \tag{18}$$

$$\mathrm{EC} = 1 - \frac{\sqrt{\sum_{t=1}^{N}(\hat{y}_t - y_t)^2}}{\sqrt{\sum_{t=1}^{N}\hat{y}_t^{\,2}} + \sqrt{\sum_{t=1}^{N}y_t^{\,2}}} \tag{19}$$

式中:y_t 为真实值;$\hat{y}_t$ 为预测值;N 为样本的个数。RMSE、MAE 的值越小,EC 的值越大,模型的预测效果越好。

2.3　数据预测

首先对 18 d 共计 432 h 的流量数据进行 EEMD 分解,根据文献[9]的研究,添加白噪声的次数为 100 时,白噪声的幅值系数取 0.01 ~ 0.5 较为适宜。经过尝试比较后,设置添加白噪声的次数为 100,白噪声的幅值系数为 0.1,经过分解后得到模态分量 $\mathrm{imf}_i(t)(i = 1,2,\cdots,8)$ 与残差 $\mathrm{res}(t)$,如图 3 所示。

通过复杂度检验可以确定高复杂度与低复杂度分量,大于 0.5 的分量被认为具有高复杂度,小于 0.5 的具有低复杂度[4]。针对不同复杂度的分量采用不同的方法进行预测,可以降低运算时间,提高预测准确度。通过计算排列熵来确定分量的复杂度,使用平均互信息估计相空间重构的延迟时间,使用虚假最近邻点算法估计相空间重构的嵌入维数,并对排列熵归一化处理,得到最终的排列熵。设置阈值为 0.5,大于 0.5 的定义为高频分量,小于 0.5 的定义为低频分量,如表 1 所示。

为了更好地验证模型的预测效果,取各分量前

表 1　各分量的排列熵

Table 1　Permutation entropy of each component

分量	排列熵	分类
imf1	0.992 2	高频
imf2	0.990 4	高频
imf3	0.952 6	高频
imf4	0.833 8	高频
imf5	0.778 8	高频
imf6	0.699 3	高频
imf7	0.575 1	高频
imf8	0.484 9	低频
res	0.378 4	低频

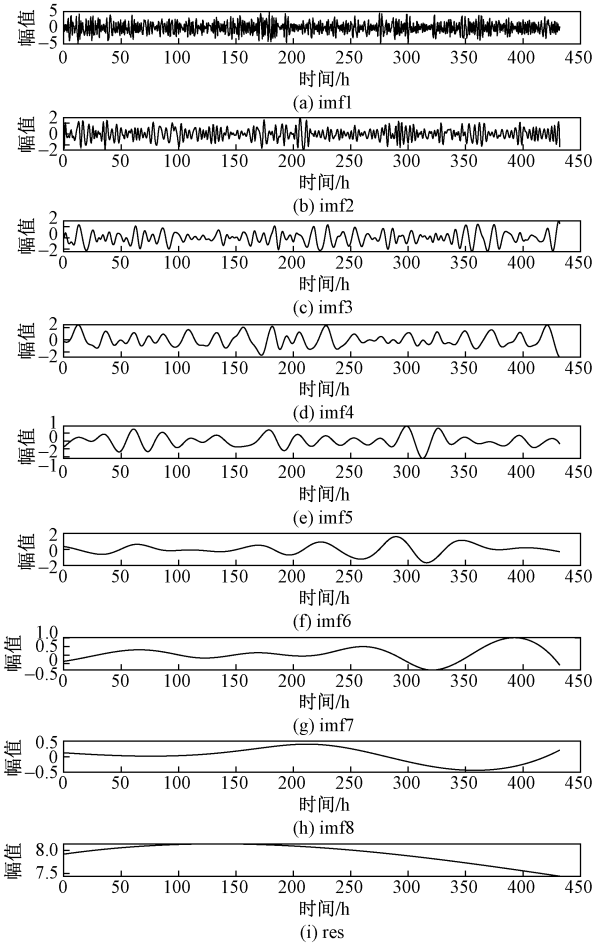

图 3　EEMD 分解后的分量

Fig. 3　The component value after EEMD decomposition

17 d 共计 408 h 的数据 a_i(其中 i 为天数,$i = 1,2,\cdots,17$)作为训练集。取第 18 天前 12 h 的数据 b_{18} 作为验证集。

BP 神经网络具有良好的非线性映射能力和自学习能力,由于高频分量的复杂度较高,预测难度较大,所以对于高频分量,采用 BP 神经网络进行预测。设置训练次数为 5 000 次,收敛误差为 10^{-7},权值的学习算法设置为 trainlm,选择 $a_i(i = 1,2,\cdots,16)$ 作为训练集上的输入,设置输入层节点数为 16,选择 a_{17} 作为训练集上的输出,设置输出层的节点数为 1。目前,隐含层节点数的设定还没有一套系统的方法,通常是通过一系列试算确定[10]。通过试算确定了 $\mathrm{imf}_i(t)(i = 1,2,\cdots,7)$ 的隐含层节点个数为 8、5、5、5、3、3、3。

最小二乘法是一种简便的线性拟合算法,具有计算快速的优点。由于低频分量的复杂度较低,采用最小二乘法进行拟合,可以降低计算成本,减少预测的时间。通过多次实验后确定 imf_8 和 res 拟合多项式的次数为 4 和 6。最后依次进行了预测,如图 4 所示。

为了进一步对模型预测效果进行分析,计算了各分量预测模型的评价指标,如表 2 所示。

因为经过 EEMD 分解后得到了一系列线性分量,所以各分量的和等于原始数据 $X(t)$,即 $X(t)=\sum_{i=1}^{8}\mathrm{imf}_i(t)+\mathrm{res}(t)$,所以将各分量的预测数据进行线性加和处理,得到了本文模型总的预测数据 $C(t)$ 为

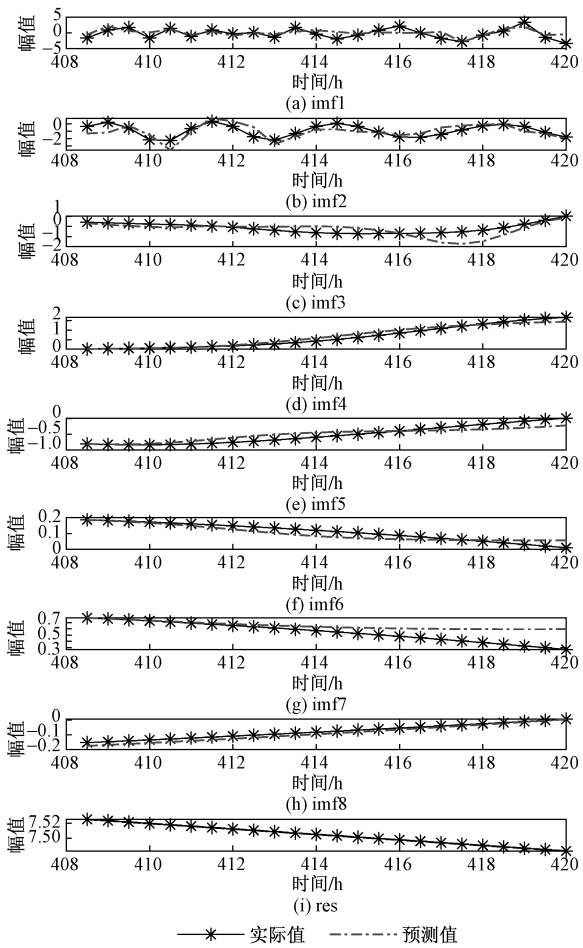

图 4 各分量实际值与预测值的对比

Fig. 4 Comparison of actual and predicted values of each component

表 2 各分量的评价指标值

Table 2 Evaluation index value of each component

分量	RMSE	MAE	EC
imf1	1.260 4	1.008 9	0.540 7
imf2	0.694 5	0.577 6	0.680 7
imf3	0.519 8	0.402 4	0.586 0
imf4	0.236 6	0.185 0	0.586 4
imf5	0.133 6	0.112 5	0.902 5
imf6	0.024 3	0.020 3	0.740 6
imf7	0.144 5	0.103 6	0.916 6
imf8	0.014 6	0.013 1	0.867 8
res	$7.054\ 2\times10^{-5}$	6.705×10^{-5}	1

$$C(t)=\sum_{i=1}^{9}c_{18i} \tag{20}$$

计算本文模型预测数据的评价指标,如表 3 所示。

表 3 EEMD-BP-OLS 的评价指标值

Table 3 Evaluation index value of EEMD-BP-OLS

评价指标	1~6 h	7~12 h	平均值
RMSE	1.220 7	1.544 2	1.391 9
MAE	0.958 3	1.203 5	1.080 9
EC	0.905 0	0.840 8	0.864 7

经过分析发现,本文中预测模型在 1~6 h 的 RMSE 值和 MAE 值均比 7~12 h 的值小,在 1~6 h 的 EC 值为 0.905 0,大于 7~12 h 的 0.840 8,说明本模型在 1~6 h 的预测精度要比 7~12 h 的高。

2.4 不同方法预测结果对比

为了更好地验证本文组合模型的性能,选取了 EMD-BP-OLS 模型,BP 神经网络模型进行预测,如图 5 所示(30 min 尺度)。

为了进一步比较不同模型的预测性能,计算了各模型的评价指标,如表 4 所示。

分析发现,本文中 EEMD-BP-OLS 模型相对于 EMD-BP-OLS 模型和 BP 模型,RMSE 值和 MAE 值更小,EC 值为 0.853 2,大于其他两个模型。而 EMD-BP-OLS 模型相对于 BP 模型,RMSE 值,MAE 值相差不大,EC 值为 0.807 6,要小于 BP 模型的 EC 值,说明选择合适的分解方法直接影响预测效果。

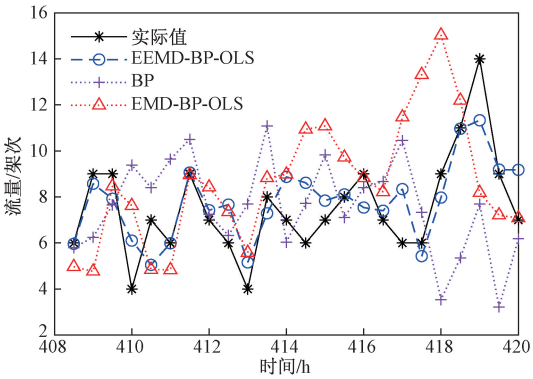

图 5 各模型的预测值

Fig. 5 Predicted values of each model

表 4 各模型的评价指标值

Table 4 Evaluation index values of each model

模型	RMSE	MAE	EC
BP	3.243 2	2.587 3	0.853 2
EEMD-BP-OLS	1.391 9	1.080 9	0.864 7
EMD-BP-OLS	3.247 9	2.491 3	0.807 3

2.5　不同时间尺度预测结果对比

为了更好地研究不同时间尺度对本文预测模型的影响,选取了 15 min 和 60 min 时间尺度的数据进行预测,如图 6 所示。

为了更好地分析时间尺度对预测精度的影响,计算了不同尺度下的评价指标,如表 5 所示。

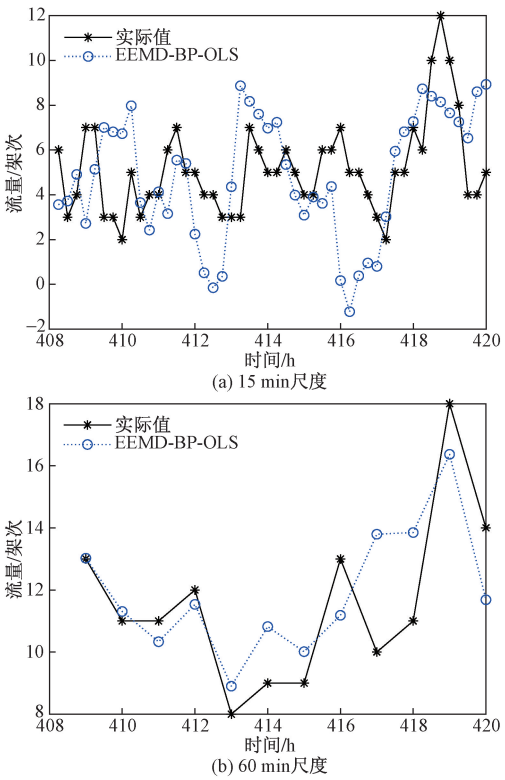

图 6　不同时间尺度预测结果对比

Fig. 6　Predicted values comparison of different time scale

表 5　各尺度的评价指标值

Table 5　Evaluation index value of each scale

时间尺度	RMSE	MAE	EC
15 min	2.915 0	2.417 4	0.737 6
30 min	1.391 9	1.080 9	0.864 7
60 min	1.820 0	1.466 9	0.924 0

经过分析发现,15 min 时间尺度的预测准确度较低,甚至出现了负值,EC 值最小,为 0.737 6,60 min 时间尺度的 EC 值最大,为 0.924 0。由于空中交通易受天气、人为干扰等随机因素影响,在 15 min 统计尺度的流量数据上体现更为明显,波动性较大,因此难以准确预测。统计尺度越大,部分的随机因素影响会被抵消,更有利于预测。

3　结论

利用基于分解集成方法的组合预测模型对空中交通流量进行短期预测,结果显示:本文模型在 1 ~ 6 h 的 RMSE 值和 MAE 值均小于其在 7 ~ 12 h 上的,且 1 ~ 6 h 的 EC 值更大,达到了 0.905 0,说明本文模型在 1 ~ 6 h 预测的精度更高,更适应于短期流量的预测。这一结果也符合空中交通流具有混沌、分形特征,短期预测的准确性是能够得到保障的;通过比较不同的预测模型,本文提出的预测模型精度更高,误差更小,EC 值为 0.864 7,说明本文的分解集成方法可以充分提取数据的特征信息,降低了数据的复杂度。针对不同特征的分量采用不同的算法进行预测,充分体现了“分而治之”的思想,提高了预测的精度。而 EMD-BP-OLS 模型相对于 BP 模型 RMSE 值和 MAE 值相差不大,且 EC 值更小,说明需要根据实际情况合理选择分解方法;通过比较不同时间尺度的预测结果,发现 60 min 时间尺度的 EC 值最高,达到 0.924 0,准确度较高,其次是 30 min 时间尺度,为 0.864 7,15 min 时间尺度最低,只有 0.737 6,误差较大,说明本文的预测模型更适合用于 30 min 和 60 min 时间尺度的流量短期预测。

参　考　文　献

[1] 杨　阳. 空中交通流量短期预测方法研究[D]. 天津: 中国民航大学, 2017.
Yang Yang. Research on short-term air traffic flow prediction method[D]. Tianjin: Civil Aviation University of China, 2017.

[2] 王　飞. 空中交通流非线性分形特征[J]. 西南交通大学学报, 2019, 54(6): 1147-1154.
Wang Fei. Nonlinear fractal characteristics of air traffic flow[J]. Journal of Southwest Jiaotong University, 2019, 54 (6): 1147-1154.

[3] 贺毅岳, 高　妮, 王峰虎, 等. EMD 分解下基于 SVR 的股票价格集成预测[J]. 西北大学学报(自然科学版), 2019, 49(3): 329-336.
He Yiyue, Gao Ni, Wang Fenghu, et al. Integrated prediction of stock price based on SVR under EMD decomposition[J]. Journal of Northwest University (Natural Science Edition), 2019, 49(3): 329-336.

[4] 汪子述. 分解集成框架下的石油价格预测: 模态重构与分量预测技术研究[D]. 北京: 北京化工大学, 2016.
Wang Zishu. Oil price prediction under the framework of decomposition integration: research on modal reconstruction and component prediction technology[D]. Beijing: Beijing University of Chemical Technology, 2016.

[5] 周　程, 李　松. 基于多重“分解—集成”策略的物流货运量预测[J]. 交通运输系统工程与信息, 2015, 15(1): 150-158.
Zhou Cheng, Li Song. Logisticsfreight volume forecasting based on multiple decomposition and integration strategies[J]. Transportation Systems Engineering and Information Technology, 2015, 15(1): 150-158.

[6] Wang H, Liu L, Dong S, et al. A novel work zone short-term vehicle-type specific traffic speed prediction model through the hybrid EMD-ARIMA framework[J]. Transportmetrica B: Transport Dy-

namics, 2016, 4(3): 159-186.

[7] Majumder I, Dash P K, Bisoi R. Variational mode decomposition based low rank robust kernel extreme learning machine for solar irradiation forecasting[J]. Energy Conversion and Management, 2018, 171: 787-806.

[8] 朱宁辉, 白晓民, 董伟杰. 基于EEMD的谐波检测方法[J]. 中国电机工程学报, 2013, 33(7): 92-98, 14.
Zhu Ninghui, Bai Xiaomin, Dong Weijie. Harmonicdetection method based on EEMD[J]. Chinese Journal of Electrical Engineering, 2013, 33(7): 92-98, 14.

[9] 侯明明. 油中微量水分的近红外光谱测定方法研究[D]. 重庆: 重庆工商大学, 2012.
Hou Mingming. Determination of trace moisture in oil by near infrared spectroscopy[D]. Chongqing: Chongqing Technology and Business University, 2012.

[10] 谢 浩. 基于BP神经网络及其优化算法的汽车车速预测[D]. 重庆: 重庆大学, 2014.
Xie Hao. Vehiclespeed prediction based on BP neural network and its optimization algorithm[D]. Chongqing: Chongqing University, 2014.