

DOI:10.16356/j.1005-2615.2023.06.010

基于 VMD-LSSVM 的扇区流量短期预测

王 飞¹, 孙鹏飞²

(1. 中国民航大学空中交通管理学院, 天津 300300; 2. 北京蓝天航空科技股份有限公司, 北京 100085)

摘要: 对扇区流量进行短期预测, 是精准实施扇区流量优化和管理措施的前提。基于分解集成预测方法论, 建立了变分模态分解-最小二乘支持向量机 (Vibrational mode decomposition-least square support vector machines, VMD-LSSVM) 预测模型。首先, 应用变分模态分解 (Vibrational mode decomposition, VMD) 方法将扇区流量时序数据分解为若干个模态; 然后, 使用最小二乘支持向量机 (Least square support vector machines, LSSVM) 模型分别对模态进行预测; 接着, 对模态的预测结果进行加和集成, 得到了最终的预测值。算例计算结果显示, 针对 60 min 统计尺度流量时间序列, VMD-LSSVM 模型在 1~6 h 的均等系数 (Equal coefficient, EC) 值为 0.97, 在 7~12 h 的 EC 值为 0.94; 与差分自回归滑动平均模型 (Autoregressive integrated moving average model, ARIMA), 反向传播 (Back propagation, BP) 神经网络和 LSSVM 单一模型相比, VMD-LSSVM 模型 1~6 h 的 EC 值分别提升了 11.5%、7.8%、4.3%; 与完整聚合经验模态分解 (Compete ensemble empirical mode decomposition with adaptive noise, CEEMDAN)-LSSVM、CEEMDAN-BP 和 VMD-BP 相比, 提升了 2.1%、6.6%、5.4%; 与 30 min 和 15 min 统计尺度相比, 的 EC 值分别提升了 6.6% 和 19.8%; 针对时间普适性的 8 次实验, EC 值均在 0.94 以上, 针对 27 个扇区普适性的实验, 有 24 个扇区的 EC 值在 0.9 以上。算例结果表明, VMD-LSSVM 模型具备良好的预测性能和较好的普适性, 用于扇区流量短期预测是可行的和有效的。

关键词: 航空运输; 空中交通流量管理; 流量短期预测; 变分模态分解; 最小二乘支持向量机

中图分类号: U8 **文献标志码:** A **文章编号:** 1005-2615(2023)06-1033-11

Short Term Prediction of Sector Traffic Based on VMD-LSSVM

WANG Fei¹, SUN Pengfei²

(1. College of Air Traffic Management, Civil Aviation University of China, Tianjin 300300, China; 2. Bluesky Aviation Technology Co. Ltd., Beijing 100085, China)

Abstract: Short term prediction of sector traffic is the premise of accurately implementing sector traffic optimization and management measures. Based on the decomposition integration prediction methodology, a vibrational mode decomposition least square support vector machine (VMD-LSSVM) prediction model is established. Firstly, the VMD method is applied to decompose the traffic into several sectors. Then, the LSSVM model is used to predict the modes. The modal prediction results are added and integrated to obtain the final prediction value. The calculation results show that the prediction accuracy of the VMD-LSSVM model is 0.97 in 1—6 h and 0.94 in 7—12 h. Compared with the first mock exam model of autoregressive integrated moving average model (ARIMA), back propagation (BP) and LSSVM, the prediction accuracy of the VMD-LSSVM model 1—6 h increased by 11.5%, 7.8%, 4.3%, respectively, and 2.1%, 6.6%, 5.4% compared with compete ensemble empirical mode decomposition with adaptive noise (CEEMDAN)-LSSVM, CEEMDAN-BP and VMD-BP, respectively. Compared with 30 min and 15 min statistical scales, the prediction accuracy is improved by 6.6% and 19.8%, respectively. For the eight experiments of time

基金项目: 天津市应用基础多元投入基金重点项目 (21JCZDJC00840); 中央高校基本科研业务费专项资金项目 (3122019129)。

收稿日期: 2022-09-04; **修订日期:** 2023-09-27

通信作者: 王飞, 男, 副教授, E-mail: feiwang@cauc.edu.cn。

引用格式: 王飞, 孙鹏飞. 基于 VMD-LSSVM 的扇区流量短期预测 [J]. 南京航空航天大学学报, 2023, 55(6): 1033-1043. WANG Fei, SUN Pengfei. Short term prediction of sector traffic based on VMD-LSSVM [J]. Journal of Nanjing University of Aeronautics & Astronautics, 2023, 55(6): 1033-1043.

universality, the prediction accuracy is more than 0.94. For the experiments of 27 sectors, the prediction accuracy of 24 sectors is more than 0.9. The example results show that the VMD-LSSVM model has good prediction performance and good universality, and it is feasible and effective for short-term prediction of sector traffic.

Key words: transport aviation; air traffic flow management; short term flow forecast; variational modal decomposition; least square support vector machine

空中交通流量管理是空中交通管理的3大组成部分之一。流量预测是空中交通流量管理的重要内容,一般分为中长期预测与短期预测。流量中长期预测服务于流量管理的战略阶段,一般以年、月、日为单位进行预测,可以为机场布局、空域划设、航线网络规划等提供依据。流量短期预测主要用于流量管理的战术阶段,一般以小时和分钟为单位,对优化交通流和减少延误更具现实意义。

目前,国内外学者对空中交通流量短期预测的方法主要分为4类。第1类是基于航迹的流量预测方法^[1-6]。现阶段,基于航迹的运行(Trajectory based operation, TBO)技术尚未成熟应用,实际运行航迹受不确定因素影响,与计划航迹差异较大,导致预测准确度不高。第2类是基于数理统计的预测方法^[7-9]。该方法主要考虑空中交通流的线性特征,鉴于空中交通系统已被证实具有复杂的非线性特征^[10-12],因此具有局限性。第3类是基于非线性理论的预测方法^[13-14]。非线性模型中许多关键参数由经验确定,实际应用仍面临诸多难点。第4类是智能预测方法^[15-17]。该方法具有较强的自学习能力、适应性和鲁棒性,但存在着容易陷入局部最小、大规模数据训练时间较长的问题。

近年来,“分解集成”预测模型成为当前时间序列预测领域的一种前沿技术,先将原始时序分解为不同频率的分量,再对分量进行分析和预测,最后集成分量预测结果形成整体预测结果。2012年, Liu等^[18]基于经验模态分解(Empirical mode decomposition, EMD)和人工神经网络(Artificial neural network, ANN),提出了一种用于风速预测的混合模型 EMD-ANN,预测效果较好。2016年, Wang等^[19]结合 EMD和差分自回归移动平均模型(Autoregressive integrated moving average, ARIMA),对5~20 min内的高速公路车辆速度进行了预测。2018年, Majumder等^[20]提出了一种基于变分模态分解(Vibrational 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。2018年, Li等^[21]提出了一种集合经验模态分解(Ensemble empirical mode decomposition, EEMD)与随机森林(Random forest,

RF)算法结合的 EEMD-RF模型,用于预测日常用电量。2019年,贺毅岳等^[22]结合了 VMD分解方法和支持向量回归(Support vector regression, SVR)预测方法,实现了对非平稳、非线性股票价格时间序列的高精度预测。分解集成预测方法在空中交通领域的应用刚刚起步,研究成果还不丰富。2021年,王飞等^[23]建立完整聚合经验模态分解(Compete ensemble empirical mode decomposition with adaptive noise, CEEMDAN)-反向传播(Back propagation, BP)神经网络模型,实现区域扇区流量短期预测,与30 min和15 min统计尺度预测结果相比,60 min尺度均衡系数最高,为92.4%,依然有很大提升空间。EMD及其演化形成的 EEMD和 CEEMD是瞬频分析方法,不依赖于先验基函数,采用的 Hilbert谱的分辨率远高于小波谱,准确性高,但易产生模态混叠。VMD是 Zosso等^[24]提出的一种自适应、完全非递归的数据分解方法,是典型的时频分析方法,能够自适应的匹配各模态的最佳中心频率和有限带宽,实现模态的有效分离,较好解决了模态混叠问题。

流量时间序列是研究空中交通流的一种有效手段,扇区是管制指挥的最基本单元。本文以扇区为研究对象,基于实测数据构建扇区流量时间序列,根据“分解集成”方法论,按照“时序分解-分量预测-集成预测”的步骤开展流量短期预测,为精准实施流量优化和管理措施提供依据。

1 分解与预测方法

1.1 变分模态分解

VMD可以降低复杂度高和非线性强的时间序列非平稳性,分解获得包含多个不同频率尺度且相对平稳的子序列,适用于非平稳性的序列。此外,采用了维纳滤波进行去噪,具有良好的去噪效果。VMD克服了EMD的端点效应和模态混叠问题,具有更为坚实的数学理论基础和更强的鲁棒性。VMD分解的原理包含构造变分问题和求解变分问题两个部分。

(1) 构造变分问题

① 利用希尔伯特变换求解 $u_k(t)$ 的边际谱,得到单侧频谱为

$$\left[\delta(t) + \frac{j}{\pi t} \right] u_k(t) \quad (1)$$

式中: $u_k(t)$ 为分解得到的 k 个模态函数分量, $\delta(t)$ 为单位脉冲函数, t 为采样时刻, j 为虚数单位。

② 按照式(2)将 $u_k(t)$ 的频谱调制到基频带

$$\left\{ \left[\delta(t) + \frac{j}{\pi t} \right] u_k(t) \right\} e^{-j\omega_k t} \quad (2)$$

式中 ω_k 为各模态函数的中心频率。

③ 使用高斯平滑法估计已解调信号的带宽, 将问题转化为求解带约束的变分问题, 如式(3)所示。

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s.t. } \sum_k u_k(t) = f(t) \end{cases} \quad (3)$$

式中: ∂_t 为对 t 求偏导, $\|\cdot\|_2$ 为求解二范数, $f(t)$ 为原始时序数据。

(2) 求解变分问题

① 将式(3)转换为增广拉格朗日无约束问题为

$$L = \alpha \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_k u_k(t) \right\rangle \quad (4)$$

式中: α 为二次惩罚因子, $\langle \cdot \rangle$ 为求数学期望, $\lambda(t)$ 为格朗日乘法算子。

② 将式(3)的最小化问题作为增广拉格朗日表达式的解, 采用交替方向乘子法不断更新 u_k^{N+1} , ω_k^{N+1} 和 λ^{N+1} , 模态 u_k 的更新迭代等价于最小化问题。

$$\hat{u}_k^{N+1} = \arg \min_{\hat{u}_k, u_k \in X} \left\{ \alpha \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_i u_i(t) + \frac{\lambda(t)}{2} \right\|_2^2 \right\} \quad (5)$$

式中: $\hat{\cdot}$ 为变量的估计量, $\arg \min$ 就是使式子达到最小值时的变量的取值。

③ 将 ω 用 $\omega - \omega_k$ 代替, 按照式(6)更新 \hat{u}_k^{N+1} 。

$$\hat{u}_k^{N+1} = \arg \min_{\hat{u}_k, u_k \in X} \left\{ \int_0^\infty 4\alpha (\omega - \omega_k)^2 |\hat{u}_k(\omega)|^2 d\omega + 2 \left| \hat{f}(\omega) - \sum_i \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2} \right|^2 d\omega \right\} \quad (6)$$

求二次规划问题的解为

$$\hat{u}_k^{N+1}(\omega) = \frac{\hat{f}(\omega) - \sum_i \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (7)$$

$$\omega_k^{N+1} = \frac{\int_0^\infty \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k(\omega)|^2 d\omega} \quad (8)$$

综合上述原理, VMD 分解的步骤为:

(1) 首先, 初始化 $\{\hat{u}_k^1\}, \{\omega_k^1\}, \{\hat{\lambda}^1\}$ 和 N 。

(2) 根据式(7,8)更新 $\hat{u}_k^{N+1}(\omega)$ 和 ω_k^{N+1} 。

(3) 根据式(9)更新 $\hat{\lambda}$ 。

$$\hat{\lambda}^{N+1}(\omega) = \hat{\lambda}^N(\omega) + \tau \left(\hat{f}(\omega) - \sum_k \hat{u}_k^{N+1}(\omega) \right) \quad (9)$$

式中 τ 为更新参数。

(4) 判断是否满足式(10)收敛条件, ϵ 为判别精度。若满足, 停止迭代, 输出模态子序列。若不满足, 返回步骤 2, 直至满足收敛条件。

$$\sum_k \|\hat{u}_k^{N+1}\|_2^2 / \|u_k^N\|_2^2 < \epsilon \quad (10)$$

1.2 最小二乘支持向量机

最小二乘支持向量机 (Least square support vector machine, LSSVM) 通过将支持向量机的非等式约束替换为等式约束, 将二次规划问题转变为求解线性方程组, 提高了运算速度, 降低了运算复杂度。LSSVM 模型的具体原理如下

(1) 设样本 $D = \{(x_i, y_i) | i = 1, 2, \dots, n\}$, 其中 x_i 为 n 维输入数据集, y_i 为一维输出数据集, 通过非线性映射 $\varphi(\cdot)$ 将样本映射到高维的特征空间, 得到回归函数如下

$$f(x) = \omega^T \varphi(x) + b \quad (11)$$

式中: ω 为权值向量, b 为偏差量。

(2) 利用结构风险最小化原则, 建立 LSSVM 的回归方程

$$\begin{cases} \min J(\omega, e) = \frac{1}{2} \|\omega\|^2 + \frac{1}{2} \gamma \sum_{i=1}^n e_i^2 \\ \text{s.t.}: y_i = \omega^T \varphi(x_i) + b + e_i \quad i = 1, 2, \dots, n \end{cases} \quad (12)$$

式中: $\|\cdot\|$ 为求解二范数, J 为损失函数, e_i 为松弛因子, γ 为惩罚系数。

(3) 通过引入拉格朗日乘子 α_i , 建立拉格朗日方程 L

$$L(\omega, b, e, \alpha) = J(\omega, e) - \sum_{i=1}^n \alpha_i [\omega^T \varphi(x_i) + b + e_i - y_i] \quad (13)$$

对式(13)的 ω, b, e, α 分别求偏导, 并令偏导数为 0, 如式(14)所示。

$$\begin{cases} \frac{\partial L}{\partial \boldsymbol{\omega}} = 0 \rightarrow \boldsymbol{\omega} = \sum_{i=1}^l \alpha_i \varphi(x_i) \\ \frac{\partial L}{\partial \boldsymbol{b}} = 0 \rightarrow \sum_{i=1}^l \alpha_i = 0 \\ \frac{\partial L}{\partial e_i} = 0 \rightarrow \alpha_i = C e_i \quad i=1, 2, \dots, l \\ \frac{\partial L}{\partial \alpha_i} = 0 \rightarrow \boldsymbol{\omega}^T \varphi(x_i) + \boldsymbol{b} + e_i - y_i = 0 \quad i=1, 2, \dots, l \end{cases} \quad (14)$$

消去 $\boldsymbol{\omega}$ 和 e_i , 变换为矩阵

$$\begin{bmatrix} 0 \\ \boldsymbol{y} \end{bmatrix} = \begin{bmatrix} 0 & \boldsymbol{l}^T \\ \boldsymbol{l} & \boldsymbol{\Omega} + \frac{1}{\gamma} \boldsymbol{I} \end{bmatrix} \begin{bmatrix} \boldsymbol{b} \\ \boldsymbol{\alpha} \end{bmatrix} \quad (15)$$

式中: $\boldsymbol{l} = [1, 1, \dots, 1]^T$, $\boldsymbol{\alpha} = (\alpha_1, \alpha_2, \dots, \alpha_n)^T$, $\boldsymbol{\Omega}$ 为模型的核矩阵, 进一步得到

$$f(\boldsymbol{x}) = \sum_{i=1}^n \alpha_i k(x_i, x_j) + \boldsymbol{b} \quad (16)$$

式中 $k(x_i, x_j)$ 为模型训练过程中的核函数。

2 算例分析

采集三亚1号扇区2017年9月2日到2017年9月30日共计28天的数据,按照60 min(例如8:00~

9:00)统计尺度,统计经过该扇区的所有飞机架次数量,每天有24个流量值,28天共672个流量值,进而构造扇区流量时间序列。在研究时间段内,扇区结构不变,没有出现明显的强干扰事件,可以认为本文使用的数据为常态下的运行数据。

2.1 时序分解

在VMD分解过程中,模态数量 K 和惩罚因子 α 对分解结果影响较大。

2.1.1 模态数量 K

如果 K 过小,易造成欠分解,丢失原始序列中部分重要数据;如果 K 过大,易造成过分解,出现模态混叠现象。本部分采用文献[25]中方法,逐步增加 K 值,根据式(17)求相邻模态的 Pearson 相关系数,分析相邻模态的相关性来确定 K 值,具体结果如表1所示。其中, $C_{n,m}$ 表示第 n 个模态与第 m 个模态的 Pearson 相关系数。

$$r = \frac{N \sum x_i y_i - \sum x_i \sum y_i}{\sqrt{N \sum x_i^2 - (\sum x_i)^2} \sqrt{N \sum y_i^2 - (\sum y_i)^2}} \quad (17)$$

式中: r 为 Pearson 相关系数, N 为样本数目, x_i 与 y_i 表示两个模态。

表1 相邻模态相关系数

Table 1 Correlation coefficients of adjacent modes

模态数量	$C_{1,2}$	$C_{2,3}$	$C_{3,4}$	$C_{4,5}$	$C_{5,6}$	$C_{6,7}$	$C_{7,8}$	$C_{8,9}$	$C_{9,10}$	$C_{10,11}$
2	0.12	—	—	—	—	—	—	—	—	—
3	0.12	0.01	—	—	—	—	—	—	—	—
4	0.12	0.01	0.07	—	—	—	—	—	—	—
5	0.12	0.04	0.04	0.01	—	—	—	—	—	—
6	0.11	0.09	0.04	0.04	0.01	—	—	—	—	—
7	0.11	0.09	0.04	0.03	0.06	0.03	—	—	—	—
8	0.04	0.01	0.03	0.03	0.03	0.03	0.09	—	—	—
9	0.04	0.01	0.03	0.03	0.03	0.06	0.06	0.09	—	—
10	0.04	0.01	0.03	0.03	0.09	0.06	0.05	0.06	0.09	—
11	0.04	0.01	0.03	0.03	0.09	0.06	0.05	0.06	0.10	0.14

从表1可以看出, K 小于7时, $C_{1,2}$ 一直大于0.1; K 为8时, $C_{1,2}$ 下降至0.04。说明模态数量 K 小于7时,数据没有分解完全。 K 增加至11时, $C_{9,10}$ 为0.10, $C_{10,11}$ 为0.14, 相关系数增加明显,说明发生了模态混叠,应该停止分解。所以,就本算例而言, $K=10$ 较恰当。

2.1.2 惩罚因子 α

α 取值越大,模态的带宽越窄; α 取值越小,模态的带宽越宽^[26-27]。为了合理确定 α , 本文定义了模态重构误差 IE, 如式(18)所示。不同 α 对应的 IE 和分解时间如表2所示。

$$IE = \frac{\sum_{n=1}^h |s(n) - t(n)|}{h} \quad (18)$$

表2 VMD分解时间与重构误差

Table 2 VMD decomposition time and reconstruction error

α	VMD分解时间/s	模态重构误差/架次
100	2.88	0.10
200	2.12	0.17
400	0.77	0.30
800	0.65	0.48
1 600	0.59	0.81
3 200	0.48	1.26
6 400	0.93	1.78
12 800	0.47	2.32

式中: $s(n)$ 为原始数据; $t(n)$ 为模态集成数据, 即各模态的线性加和; h 为样本个数。

从表 2 可以看出,随着 α 的增加, VMD 分解时间整体上呈减少的趋势,且分解时间都不大。随着 α 的增加,模态重构误差逐渐增大,即 VMD 分解对于原始数据的还原程度与 α 成反比。结合本文算例,经多次计算验证,设置 $\alpha=400$ 。

综合以上分析,设置 $K=10, \alpha=400$,原始时序数据分解结果如图 1 所示。

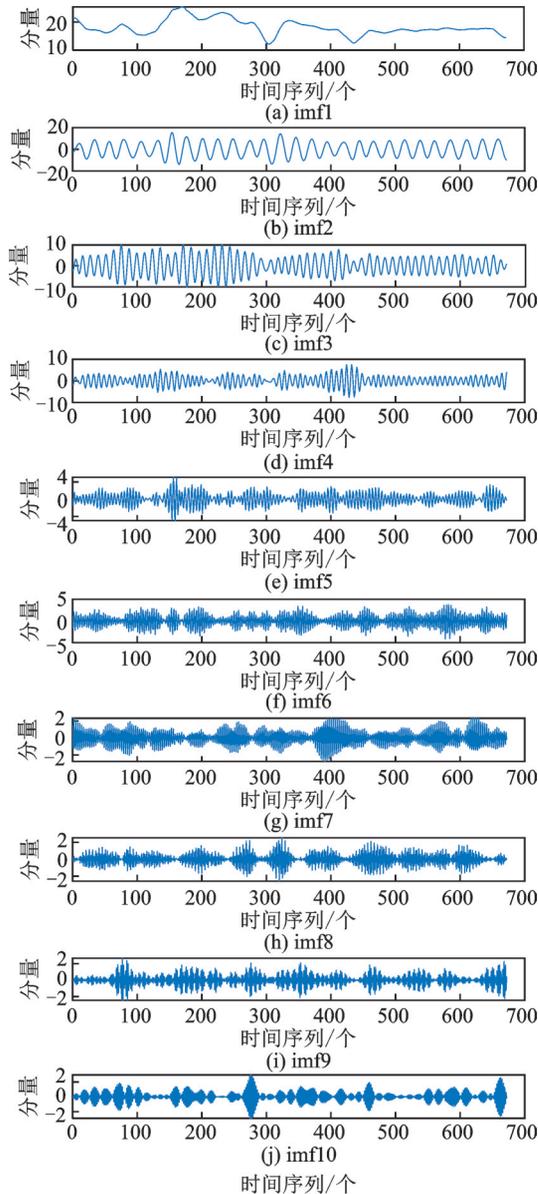


图 1 VMD 分解后的分量

Fig.1 Components based on VMD

计算了各模态分量的样本熵^[28]、Pearson 相关系数和方差贡献率^[29],如表 3 所示。

原始时序数据的样本熵为 1.57,相较而言,各模态的样本熵都有显著的降低,说明 VMD 分解可以有效降低数据的复杂度。imf2 和 imf3 的 Pearson 相关系数和方差贡献率均明显高于其他模态,说明这两个分量的预测准确性将对最终结果起决定性作用。

表 3 VMD 分解后各模态的相关指标

Table 3 Relevant indexes of each mode decomposed by VMD

模态	样本熵	Pearson 相关系数	方差贡献率/%
imf1	0.12	0.33	7.18
imf2	0.42	0.70	43.48
imf3	0.46	0.53	24.73
imf4	0.52	0.28	5.19
imf5	0.66	0.20	1.99
imf6	0.53	0.20	2.48
imf7	0.53	0.14	1.00
imf8	0.63	0.12	0.66
imf9	0.62	0.12	0.69
imf10	0.55	0.11	0.72

2.2 模态预测

LSSVM 使用目前应用最广泛的径向基核函数(Radial basis function, RBF),由于具有强大的非线性处理能力,需要设置的参数为核函数带宽 σ 和惩罚系数 γ 。为了合理设置参数,提高预测的准确度,本文采用 10 折交叉验证法对模型参数进行优化。首先将训练集分为 10 个互不相交的集合,通过给定 σ 和 γ ,对其中 9 个集合进行训练,利用其中 1 个集合进行验证,计算其均方误差。重复以上步骤 10 次,选择均方误差最小的参数组合作为模型参数。利用前 27 天的数据作为训练集,第 28 天 1~6 h 的数据作为验证集,通过 10 折交叉验证法确定 VMD 分解的各分量预测模型的参数,如表 4 所示,得到各模态预测结果如图 2 所示。

表 4 VMD-LSSVM 模型参数

Table 4 VMD-LSSVM model parameters

模态	核函数带宽 σ	惩罚系数 γ
imf1	253	1.08×10^5
imf2	36	2.79×10^6
imf3	6.61×10^3	3.64×10^7
imf4	3.10×10^3	1.34×10^6
imf5	4.16×10^4	3.52×10^6
imf6	2.11×10^4	5.77×10^6
imf7	2.18×10^4	4.52×10^5
imf8	6.32×10^3	9.10×10^6
imf9	3.56×10^4	2.97×10^6
imf10	1.61×10^3	6.03×10^5

为了对预测准确度进行量化评价,选择了常用的均方根误差(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。

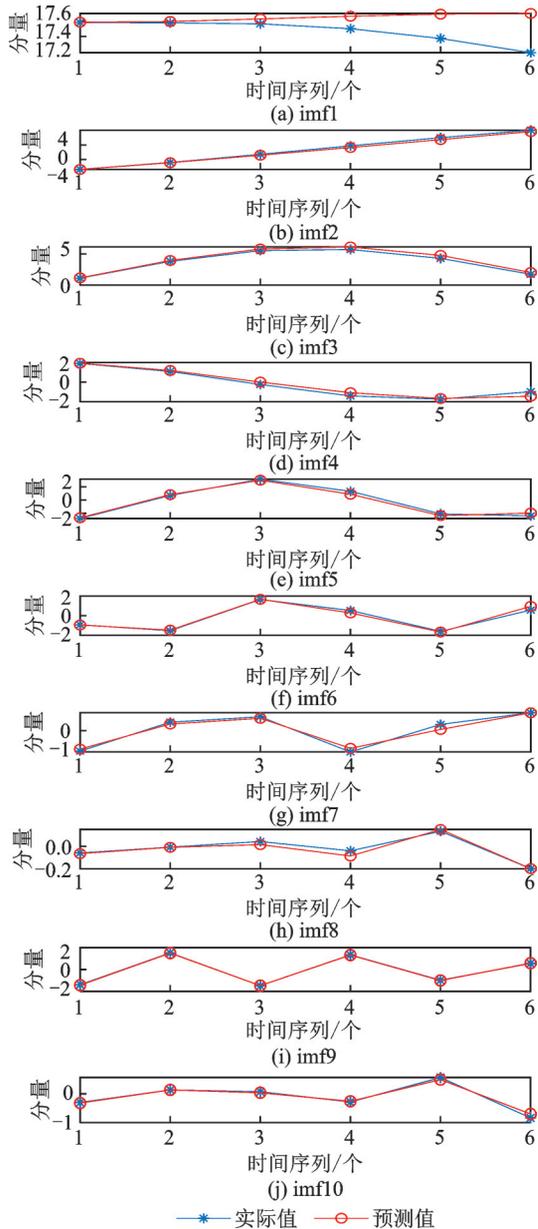


图2 基于LSSVM模型的模态预测

Fig.2 Modal prediction based on VMD-LSSVM model

RMSE、MAE的值越小,预测值与真实值的误差越小,模型的准确度越高。EC值的范围在0~1,EC值越接近1,准确度越高。

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (y_t - \hat{y}_t)^2} \quad (19)$$

$$MAE = \frac{1}{N} \sum_{t=1}^N |y_t - \hat{y}_t| \quad (20)$$

$$EC = 1 - \frac{\sqrt{\sum_{t=1}^N (\hat{y}_t - y_t)^2}}{\sqrt{\sum_{t=1}^N (\hat{y}_t)^2 + \sum_{t=1}^N (y_t)^2}} \quad (21)$$

式中: y_t 为真实值, \hat{y}_t 为预测值。

各模态分量预测结果评价指标值如表5所示。

从表5可以看出,仅有imf8和imf10预测的EC值低于0.9,其余都高于0.9,取得了较好的预测效

表5 基于LSSVM的模态预测评价指标值

Table 5 Evaluation index values of modal prediction based on LSSVM

模态	样本熵	方差贡献率/%	RMSE	MAE	EC
imf1	0.12	7.18	0.16	0.21	1.00
imf2	0.42	43.48	0.29	0.21	0.96
imf3	0.46	24.73	0.26	0.27	0.97
imf4	0.52	5.19	0.26	0.13	0.90
imf5	0.66	1.99	0.33	0.26	0.92
imf6	0.53	2.48	0.20	0.13	0.92
imf7	0.53	1.00	0.16	0.13	0.90
imf8	0.63	0.66	0.03	0.04	0.87
imf9	0.62	0.69	0.04	0.04	0.98
imf10	0.55	0.72	0.10	0.05	0.88

果。由于VMD较好提取了原始数据细节分量,各模态的复杂度普遍较低,预测难度得到有效降低。

2.3 集成预测

集成预测方法有线性集成方法和智能预测方法等。由于VMD分解得到一系列线性模态^[30],所以本文采用线性集成方法对各模态预测结果进行集成预测,如式(22)所示。

$$P = \sum_{i=1}^K P_i \quad (22)$$

式中: P 为最终预测结果, P_i 为模态预测结果, K 为模态的数量。

结合2.1和2.2小节内容,根据式(22)计算得到VMD-LSSVM最终预测结果如图3所示。RMSE为0.87,MAE为0.74,EC值为0.97,预测效果较好。结合表4可以看出,起决定性作用的imf2和imf3的预测准确度都较高,从而保障了最终集成预测准确度。

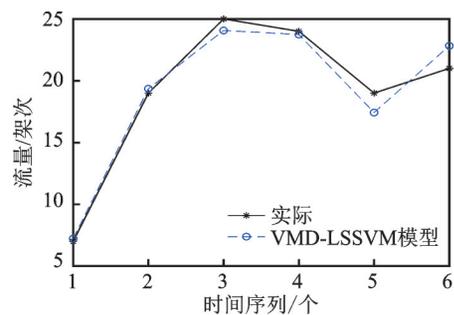


图3 VMD-LSSVM模型预测结果

Fig.3 Integrated prediction results of VMD-LSSVM model

3 综合分析

3.1 预测时长影响

流量短期预测的时间跨度通常是未来1~6h,

为了探究 VMD-LSSVM 模型对预测时长的敏感性,本小节针对 1~6 h、7~12 h、1~12 h 3 种时长进行预测,评价指标值如表 6 所示。

表 6 不同时长预测结果评价指标值

Table 6 Evaluation index values of prediction results of different time lengths

模型	预测时长/h	RMSE	MAE	EC
VMD-LSSVM	1~6	0.87	0.74	0.97
	7~12	2.38	1.85	0.94
	1~12	1.79	1.30	0.95

从表 6 可以看出,整体而言 VMD-LSSVM 模型在 3 个预测时长的预测效果都较好。具体而言,在 1~6 h 的预测准确度要比 7~12 h 的高,对于流量短期预测效果较好。后续所有分析均是指 1~6 h 的预测。

3.2 统计尺度分析

应用相同的数据,构造 30 min、15 min 统计尺度的流量时间序列,预测结果如图 4、5 所示,相关评价指标值如表 7 所示。

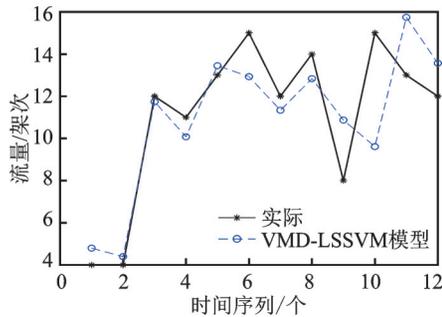


图 4 30 min 统计尺度预测结果

Fig.4 Prediction results of 30 min statistical scale

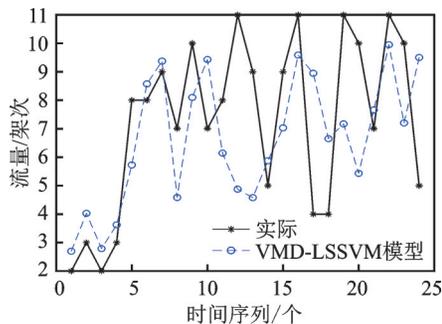


图 5 15 min 统计尺度预测结果

Fig.5 Prediction results of 15 min statistical scale

表 7 不同统计尺度预测结果评价指标值

Table 7 Evaluation index values of prediction results at different statistical scales

统计尺度/min	RMSE	MAE	EC
60	0.87	0.74	0.97
30	2.05	1.17	0.91
15	2.77	2.24	0.81

从表 7 可以看出,VMD-LSSVM 模型对于 15 min 统计尺度的流量数据预测效果较差,对 60 min 统计尺度的数据预测效果最佳,说明随着统计尺度减小,预测难度增加,预测准确度下降。后续分析均是以 60 min 统计尺度为例。

3.3 模型性能分析

本小节从 2 个方面来分析模型性能。

(1) 与单一模型对比

ARIMA、BP 和 LSSVM 都是时间序列预测领域中常用的方法,无需分解原始时序,可直接用于原始时序预测。这 3 种方法的预测结果如图 6 所示,具体评价指标值如表 7 所示。

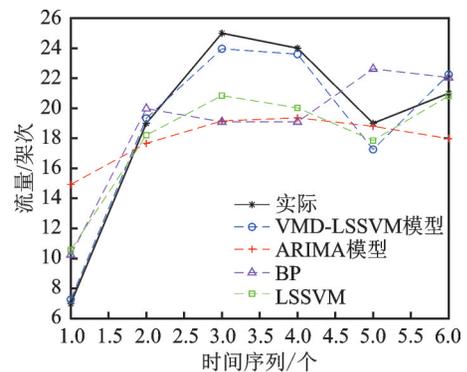


图 6 单一模型预测结果对比

Fig.6 Comparison with single model prediction results

(2) 不同分解集成方法对比

在分解集成预测框架下,与 CEEMDAN-LSSVM 模型、CEEMDAN-BP 模型和 VMD-BP 模型的预测结果进行对比,如图 7 所示,具体评价指标值如表 8 所示。

从表 8 可以看出,ARIMA 模型对于非线性较强、复杂度较高的短期流量预测效果欠佳。LSSVM 模型预测效果较好,对流量短期预测表现出较好的适应性。4 种分解集成预测模型的预测结果 EC 值均高于 0.9,整体表现较好。其中,VMD-LSSVM 模型

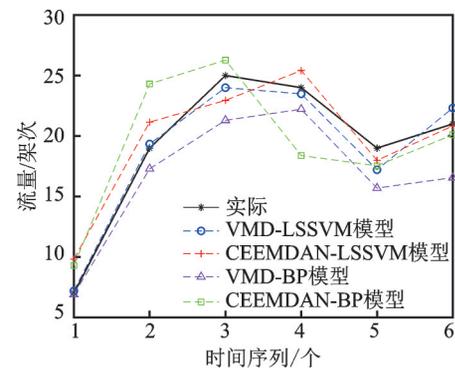


图 7 不同分解集成模型预测结果对比

Fig.7 Comparison of prediction results of different decomposition integration models

表8 不同模型预测结果评价指标值

Table 8 Evaluation index values of prediction results of different models

模型类型	模型	RMSE	MAE	EC
单一模型	ARIMA	4.64	3.82	0.87
	BP	3.80	3.15	0.90
	LSSVM	2.80	2.34	0.93
分解集成预测模型	VMD-LSSVM	0.87	0.74	0.97
	CEEMDAN-LSSVM	1.65	1.35	0.95
	VMD-BP	2.89	2.50	0.92
	CEEMDAN-BP	3.40	2.80	0.91

的各项评价指标均体现出较大的优势。CEEMDAN-LSSVM模型和VMD-LSSVM模型的RMSE值、MAE值和EC值明显好于单一模型,但CEEMDAN-BP模型和VMD-BP模型的预测效果均不如LSSVM模型。此外,EEMD-LSSVM、EMD-LSSVM的EC值分别为0.95和0.93,预测效果较好,但稍逊于VMD-LSSVM模型。说明只有选择合适的分解方法和预测方法才能有效的提高预测性能。

3.4 数据长度影响分析

为了分析训练集数据长度,即数据量对模型预测性能的影响,将训练数量由预测日前2天逐步增长至27天,预测第28天1~6h的数据,来观察EC值的变化,如图8所示。

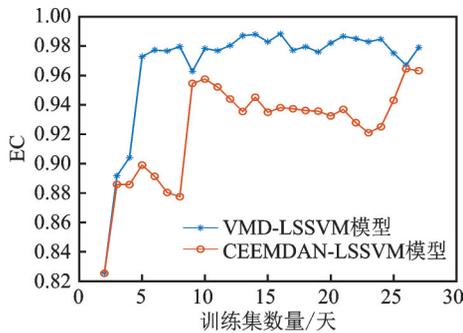


图8 EC随时序数据长度的变化

Fig.8 Change of EC with the length of time series data

从图8可以看出,对于VMD-LSSVM模型,训练集数据在5天以下时,因为训练样本有限,模型没有得到充分的训练,EC值较低,随着训练样本的增加,EC值逐渐增大,训练集数量在5~12天时,EC值有所震荡,在训练集数量增长至12天以上时,EC值在高位上趋于稳定。对于CEEMDAN-LSSVM模型,在12天以内,EC值波动较大,在15~20天之间,EC值相对稳定,但在20天之后又有剧烈变动。说明,CEEMDAN-LSSVM模型对数据长度更为敏感。

3.5 模型普适性分析

为了验证分解集成方法的普适性,对时间普适性和扇区普适性进行了研究。

3.5.1 时间普适性

选择原始数据中前20日的数据作为训练集,第21日前6h的数据作为验证集,通过每次向后递推1日的方法,保持20天的训练数据,滚动预测第21天至第28天的数据,得到了8组数据,如图9所示。计算了相关评价指标,如表9所示。从表9可以看出,在8次实验中,EC值都在0.94以上,预测效果较好,VMD-LSSVM模型表现出了良好的时间普适性。

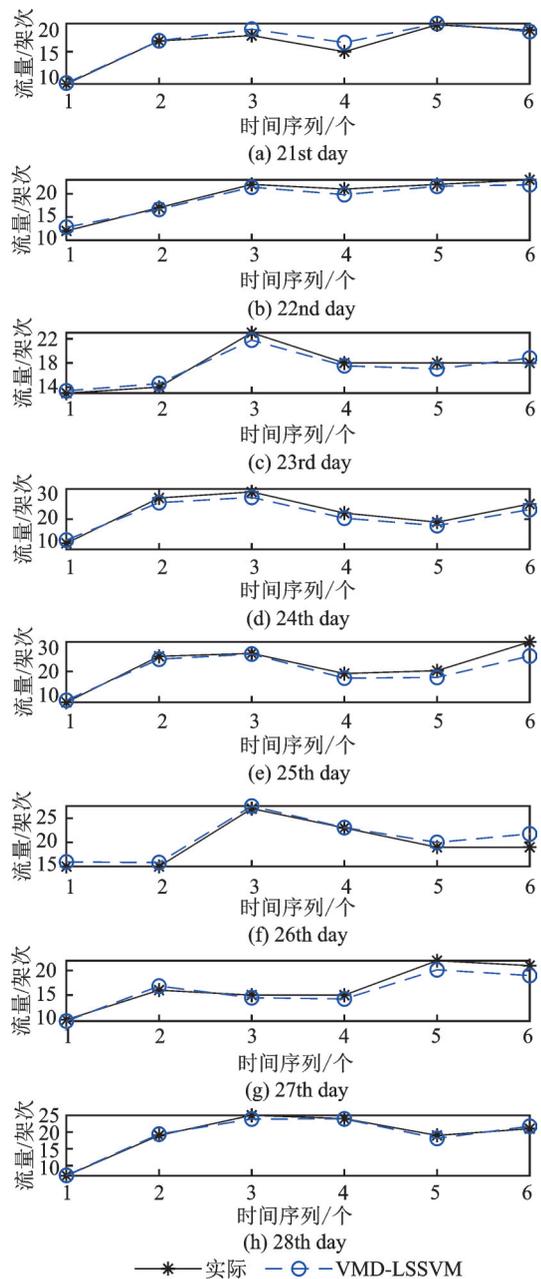


图9 第21~28天预测结果

Fig.9 Prediction results from the 21st to 28th day

表 9 不同时间的预测评价指标值

Table 9 Prediction evaluation index values at different time

天数	RMSE	MAE	EC
21	1.15	0.81	0.96
22	1.14	1.04	0.97
23	1.04	0.84	0.97
24	1.71	1.56	0.96
25	2.49	1.93	0.94
26	1.85	1.44	0.95
27	0.92	0.70	0.97
28	1.07	0.71	0.97

3.5.2 扇区普适性

采集数据时,三亚区域有 1 号、2 号、3 号和 4 号扇区。由于三亚 3 号扇区为洋区扇区,流量较少,不作为本文研究对象。对三亚区域 1、2、4 号扇区统计尺度为 60 min 的流量进行了预测,如表 10 所示。

表 10 三亚区域各扇区预测评价指标值

Table 10 Prediction evaluation index values of each sector in Sanya control area

扇区	RMSE	MAE	EC
1	0.87	0.74	0.97
2	0.84	0.70	0.98
4	0.55	0.47	0.97

从表 10 可以看出,本文提出的预测模型对三亚 1、2、4 号扇区均表现出了良好的普适性,EC 值均在 0.97 以上。

为了进一步验证本文模型的扇区普适性,应用北京区域 2018 年 12 月共 31 天的 60 min 尺度的流量数据,设定前 30 天的数据作为训练集,第 31 天前 6 h 的数据作为验证集。因为当时北京区域尚未进行空域调整,因此共有 27 个扇区。选用 VMD-LSSVM 模型进行预测,并计算了相关评价指标值,如图 10 所示。

从图 10 可以看出,在 27 个扇区中,EC 值在 0.8

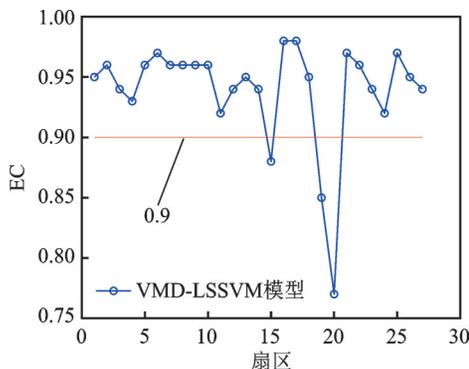


图 10 北京区域 27 个扇区流量预测的 EC

Fig.10 EC of 27 sectors in Beijing control area

以下的有 1 个扇区,占总扇区数的 3.70%,EC 值在 0.8~0.9 之间的扇区有 2 个,占总扇区数的 7.40%,EC 值在 0.9 以上的扇区有 24 个,占总扇区数的 88.88%,说明 VMD-LSSVM 模型具有较好的扇区普适性。需要说明的是,对不同扇区针对性优化模型参数,可进一步提升预测效果。

4 结 论

(1)分解集成预测模型应用于扇区流量短期预测是可行的。针对不同研究对象,需要选择合适的分解方法和预测方法才能有效地提高预测性能。就本文算例而言,VMD-LSSVM 模型的预测效果较好。

(2)VMD-LSSVM 模型在 1~6 h 的 EC 值高于 7~12 h,短期流量预测效果较好。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理论保障的。

(3)60 min 统计尺度预测效果高于 30 min 和 15 min,统计尺度越小,预测难度越大。

(4)VMD-LSSVM 模型对不同时间和不同扇区具有较好的普适性。

参考文献:

[1] 殷允楠. 空中交通流量统计预测技术研究[D]. 南京: 南京航空航天大学, 2010.
YIN Yunnan. Research on air traffic flow statistical prediction technology[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2010.

[2] 邢健. 基于高精度 4D 航迹预测的空中交通诱导技术研究[D]. 南京: 南京航空航天大学, 2015.
XING Jian. Research on air traffic guidance technology based on high-precision 4D track prediction[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2015.

[3] 马勇. 基于数据挖掘的四维航迹精密预测方法研究[D]. 南京: 南京航空航天大学, 2016.
MA Yong. Research on four-dimensional track precision prediction method based on data mining[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2016.

[4] 田文, 胡明华. 空域扇区概率交通需求预测模型[J]. 西南交通大学学报, 2011, 46(2): 340-346.
TIAN Wen, HU Minghua. Spatial sector probabilistic traffic demand forecasting model[J]. Journal of Southwest Jiaotong University, 2011, 46(2): 340-346.

[5] 王超, 杨乐. 空域扇区流量与拥塞预测的概率方法[J]. 西南交通大学学报, 2011, 46(1): 162-166.
WANG Chao, YANG Le. Probabilistic method for

- spatial sector traffic and congestion prediction[J]. Journal of Southwest Jiaotong University, 2011, 46(1): 162-166.
- [6] 别翌荟,张洪海,张哲铭.空中交通网络流量短期概率预测方法[J].航空计算技术,2013,43(2): 29-32.
BIE Yihui, ZHANG Honghai, ZHANG Zheming. Short term probability prediction method of air traffic network flow[J]. Aeronautical Computing Technology, 2013, 43(2): 29-32.
- [7] 王冉冉.空中交通流量统计预测技术研究[D].南京:南京航空航天大学,2010.
WANG Ranran. Research on air traffic flow statistical prediction technology[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2010.
- [8] 陈丹,胡明华,张洪海,等.基于贝叶斯估计的短时空域扇区交通流量预测[J].西南交通大学学报,2016, 51(4): 807-814.
CHEN Dan, HU Minghua, ZHANG Honghai, et al. Short term spatial sector traffic flow prediction based on Bayesian estimation[J]. Journal of Southwest Jiaotong University, 2016, 51(4): 807-814.
- [9] 赵元棣,陈俊夫,刘泽宇,等.基于K近邻模型的空中交通流量短期预测[J].中国民航大学学报,2017,35(5): 1-5, 11.
ZHAO Yuandi, CHEN Junfu, LIU Zeyu, et al. Short term prediction of air traffic flow based on K-nearest neighbor model[J]. Journal of Civil Aviation University of China, 2017, 35(5): 1-5, 11.
- [10] LI Shanmei, XU Xiaohao, MENG Linghang. Flight conflict forecasting based on chaotic time series[J]. Transactions of Nanjing University of Aeronautics and Astronautics, 2012, 29(4): 388-394.
- [11] 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 prediction method of air traffic flow[D]. Tianjin: Civil Aviation University of China, 2017.
- [12] 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.
- [13] 王超,朱明,赵元棣.基于改进加权一阶局域法的空中交通流量预测模型[J].西南交通大学学报,2018,53(1): 206-213.
WANG Chao, ZHU Ming, ZHAO Yuandi. Air traffic flow prediction model based on improved weighted first-order local area method[J]. Journal of Southwest Jiaotong University, 2018, 53(1): 206-213.
- [14] 王飞,韩翔宇.基于分形插值的空中交通流量短期预测[J].航空学报,2022,43(9): 513-520.
WANG Fei, HAN Xiangyu. The air traffic flow short-term forecasting based on fractal interpolation[J]. Acta Aeronautica et Astronautica Sinica, 2022, 43(9): 513-520.
- [15] 潘志毅.基于灰色神经网络的空中交通流量预测方法[J].微计算机信息,2011,27(9): 163-164.
PAN Zhiyi. Air traffic flow prediction method based on grey neural network[J]. Microcomputer Information, 2011, 27(9): 163-164.
- [16] LIN Yi, ZHANG Jianwen, LIU Hong. Deep learning based short-term air traffic flow prediction considering temporal-spatial correlation[J]. Aerospace Science and Technology, 2019, 93: 105-113.
- [17] YANG Zhao, WANG Yifan, LI Jie, et al. Airport arrival flow prediction considering meteorological factors based on deep-learning methods[J]. Complexity, 2020. DOI: 10.1155/2020/6309272.
- [18] LIU Hui, CHEN Chao, TIAN Hongqi, et al. A hybrid model for wind speed prediction using empirical mode decomposition and artificial neural networks[J]. Renewable Energy, 2012, 48: 545-556.
- [19] WANG Haizhong, LIU Lu, DONG Shanxia, et al. A novel work zone short-term vehicle-type specific traffic speed prediction model through the hybrid EMD-ARIMA framework[J]. Transport Metrics B Transport Dynamics, 2016, 4(3): 159-186.
- [20] 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.
- [21] LI Chuan, TAO Yin, AO Wengang, et al. Improving forecasting accuracy of daily enterprise electricity consumption using a random forest based on ensemble empirical mode decomposition[J]. Energy, 2018, 165: 1220-1227.
- [22] 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. Research on integrated forecasting of stock price based on EMD and support vector regression[J]. Journal of Northwest University (Natural Science Edition), 2019, 49(3): 329-336.
- [23] 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, 21(35): 15270-15276.
- [24] ZOSSO D, DRAGOMIRETSKIY K. Variational mode decomposition[J]. IEEE Transactions on Signal Processing: A publication of the IEEE Signal Processing Society, 2014, 62: 531-544.
- [25] 陶凯. 风电场发电功率的短期预测方法研究[D]. 无锡: 江南大学, 2021.
TAO Kai. Research on short-term forecasting method of wind farm power[D]. Wuxi: Jiangnan University, 2021.
- [26] 李佳鑫. 基于VMD和SVM的输电线路故障性质识别[D]. 西安: 西安科技大学, 2020.
LI Jiaxin. Transmission line fault identification based on VMD and SVM[D]. Xi'an: Xi'an University of Science and Technology, 2020.
- [27] 郑小霞, 周国旺, 任浩翰, 等. 基于变分模态分解和排列熵的滚动轴承故障诊断[J]. 振动与冲击, 2017, 36(22): 22-28.
ZHENG Xiaoxia, ZHOU Guowang, REN Haohan, et al. Rolling bearing fault diagnosis based on variational mode decomposition and permutation entropy[J]. Journal of Vibration and Shock, 2017, 36(22): 22-28.
- [28] 王飞. 基于样本熵的空中交通流复杂性分析[J]. 飞行力学, 2019, 37(3): 48-51.
WANG Fei. Complexity analysis of air traffic flow based on sample entropy[J]. Flight Mechanics, 2019, 37(3): 48-51.
- [29] 李政毓. 基于EEMD-ARIMA-LSTM组合模型对原油期货价格预测[D]. 济南: 山东大学, 2021.
LI Zhengyu. Crude oil futures price prediction based on EEMD-ARIMA-LSTM portfolio model[D]. Jinan: Shandong University, 2021.
- [30] 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 based on decomposition and integration framework: Research on modal reconstruction and component prediction[D]. Beijing: Beijing University of Chemical Technology, 2016.

(编辑: 张蓓)