

DOI: 10.13382/j.jemi.B2205590

基于奇异谱分析的长时交通流混合预测模型*

王逸文 王维莉 陈怡霏 毛蔚敏 刘贤超

(上海海事大学物流研究中心 上海 201306)

摘要:长时交通流预测是综合交通运输系统规划的重要组成部分,也是宏观交通流管理政策制定的重要依据。针对时序预测中存在较多噪声及单一模型预测效果不稳定等问题,提出了一种基于奇异谱分析(SSA)的混合预测模型,以提高实际应用中交通流序列预测的精度与效率。首先将原始数据经过奇异谱分析后重构为趋势项、周期项和残差项,其中趋势项运用支持向量回归(SVR)进行预测,并引入灰狼优化(GWO)算法对模型参数进行优化,周期项利用带遗忘机制的在线序列极限学习机(FOS-ELM)预测,最后叠加两部分得到预测结果。以真实交通流数据开展实验,本文所提出的混合预测模型的平均绝对误差为215.15,均方根误差为278.51。整体结果表明,该模型能够解决单一模型预测结果误差波动大、预测效果不稳定等问题;相比经验模态分解(EMD)以及未经处理的时间序列,各模型对经过奇异谱分析的时间序列的预测误差均有所减小,进一步证实了奇异谱分析在时间序列分解中的有效性。

关键词:奇异谱分析;支持向量回归;极限学习机;交通流预测

中图分类号: U491.14 **文献标识码:** A **国家标准学科分类代码:** 580.20

Hybrid prediction model of long-time traffic flow based on singular spectrum analysis

Wang Yiwen Wang Weili Chen Yifei Mao Weimin Liu Xianchao

(Logistics Research Center, Shanghai Maritime University, Shanghai 201306, China)

Abstract: Long-term traffic flow prediction is a vital part of comprehensive transportation system planning, it is also an important basis for formulating macro traffic flow management policy. In order to improve the accuracy and efficiency of traffic sequence prediction, a hybrid prediction model based on singular spectrum analysis (SSA) is proposed, in which the problems of noise and unstable prediction of a single model in time series prediction are well solved. Firstly, raw data are reconstructed into tendency term, periodic term and residual term using SSA. Specifically, trend term is predicted using support vector regression (SVR), and grey wolf optimization (GWO) algorithm is introduced to optimize parameters of the regression model. Moreover, periodic term is predicted using forgetting online sequential-extreme learning machine (FOS-ELM). Finally, the predicted results are obtained by superimposing the above mentioned two parts. The experiment is carried out with real traffic flow data, and the mean absolute error (MAE) and root mean square error (RMSE) of the proposed hybrid prediction model are 215.15 and 278.51, respectively. The overall results show that the proposed model can solve the problems of large error fluctuation and unstable prediction of the single model. Furthermore, compared with empirical mode decomposition (EMD) and unprocessed time series, the prediction error of each model to the time series after singular spectrum analysis is reduced, which further illustrates the effectiveness of SSA in time series decomposition.

Keywords: singular spectrum analysis; support vector regression; extreme learning machine; traffic flow forecasting

0 引言

近年来,随着经济社会的快速发展和人民收入水平的大幅提高,机动车保有量不断上升,交通拥堵、机动车尾气污染等问题凸显。准确预测交通流是城市交通控制的基础,也是综合交通运输系统规划与管理的重要参考。

交通流预测可以从微观层面和宏观层面展开,微观层面即利用智能交通系统(intelligent transport system, ITS)获取实时交通数据信息,并基于此滚动预测未来几分钟或几十分钟的交通状况,有助于出行者合理规划出行路线,多为短时或短期预测。而宏观层面则是以天、月、季度,甚至以年为预测时间单位,以实现科学合理的交通运输系统规划与管理,通常也被称为长时交通流预测或战略预测。以往研究多集中于短时交通流预测^[1-3],相关研究可分为两类:一类是基于传统的统计模型,如差分整合移动平均自回归模型(autoregressive integrated moving average model, ARIMA)、指数平滑法、霍尔特-温特分解(Holt-Winters)、卡尔曼滤波等模型,但由于交通流具有非线性、社会性、高耦合、时空依赖性等特点^[4],该类传统模型逐渐不能满足日益精确的预测要求。因此,另一类非线性模型,如长短期记忆神经网络(long short-term memory, LSTM)、反向传播(back propagation, BP)神经网络、支持向量机(support vector machine, SVM)、自适应增强提升(adaboost)算法等人工智能模型越来越受到研究者的关注,这些模型能够处理高维数据,同时对非线性数据有较好的学习能力。然而,由于交通流的空间不均匀性和时变特性,上述单个模型多适用于特定的交通状况^[5]。

为进一步提高交通流预测的精度和适用性,混合模型和图卷积神经网络逐渐引起了研究者们的关注。前者主要针对模型层面,通过不同模型的预测产生具有无偏性的结果,可减少由参数或模型错误识别带来的预测误差^[6],其效果往往比单一模型要好,其效果往往比单一模型要好^[7-8];而后者则主要考虑交通流预测中的空间特征,即在待预测点的时间信息基础上,综合考虑其在路网中的空间信息进行预测^[9]。众多学者也针对时空图卷积神经网络做了改进,如刘赏等^[10]提出双分支时空图卷积神经网络,贺文武等^[11]提出轻量时空图卷积模型,倪庆剑等^[12]提出信息增强传输的时空图神经网络等。总体上看,当前研究多集中于短时交通流预测方法的改进与扩展,对长时交通流的科学预测仍显不足。

在长时交通流预测中,有两个问题值得关注。一是由于交通管制、节假日等特殊事件的干扰,长时交通流数据中不可避免地会产生噪声,利用附带噪声的数据去预测未来数据易导致误差增大,从而影响预测精度。二是

单项模型可能仅仅只包含数据的部分信息,无法全面获取预测数据所包含的内容,尤其是时间序列分析中真实数据生成过程通常具有区制转换等特性^[13],导致单一模型预测易产生预测效果不稳定等情况。

因此,本文提出一种基于奇异谱分析的混合模型对长时交通流问题进行预测。在降噪处理方面,以往的研究多数采用变分模态分解(variational mode decomposition, VMD)、经验模态分解(empirical mode decomposition, EMD)等数据清洗的方法^[14-15],但此类方法有较强的局限性,而奇异谱分析(singular spectral analysis, SSA)模型能够滤去序列中的高频噪声和非周期性的异常现象,对于长观测序列有良好的效果^[16]。本文基于奇异谱分析方法,将时间序列分解为趋势项、周期项和残余项。对于趋势项,采用支持向量回归(support vector regression, SVR)方法进行预测,并利用灰狼优化(grey wolf optimizer, GWO)算法进行参数寻优;对于周期项,采用带遗忘机制的在线序列极限学习机(forgetting online sequential-extreme learning machine, FOS-ELM)进行预测;最后叠加两部分预测结果,充分利用不同模型的优点,深层次挖掘交通流数据的特征,提高预测精度。

1 模型框架与方法

1.1 模型框架

针对长时交通流时间序列噪声大、不稳定等情况,本文提出了一种基于奇异谱分析的模型框架用于长时交通流预测,从而深度挖掘交通流特征,模型的框架图如图 1 所示,具体步骤如下:

步骤 1) 针对原始交通流时间序列的噪声,采用奇异谱分析进行分解重构,得到若干个序列分量。

步骤 2) 根据奇异值分解得到的特征值,确定出原始时间序列的趋势项、周期项、残余项,其中趋势项和周期项包含了原始时间序列的主要信息,残余项视为噪声。

步骤 3) 对趋势项和周期项时间序列进行预测,其中趋势项利用基于灰狼优化算法的支持向量回归进行预测,周期项利用带遗忘机制的在线序列极限学习机进行预测。

步骤 4) 叠加两部分结果,得到最终预测结果。

1.2 奇异谱分析

奇异谱分析是一种处理非线性时间序列数据的方法,它既不需要假设参数模型,也不需要假设平稳性条件,因而具有非常广泛的适用性。它基于构造在时间序列上的特定矩阵的奇异值分解(singular value decomposition, SVD),从而提取出时序数据中的不同成分序列,如趋势、周期、噪声等等,主要包括嵌入、分解、分

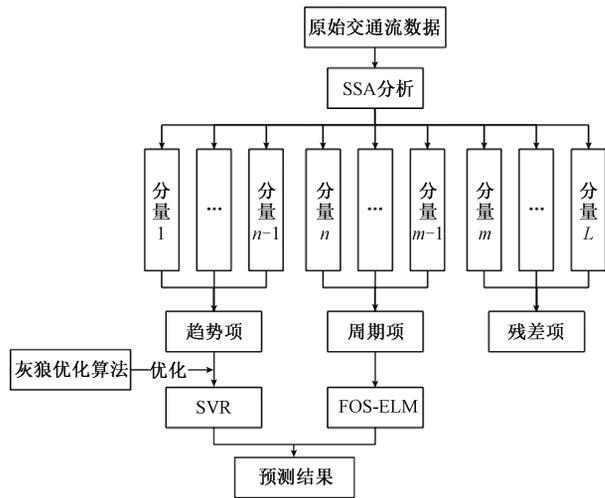


图 1 模型框架

Fig. 1 Model framework

组、重构 4 个步骤。

首先考虑一个有限长的一维时间序列 $[x_1, x_2, \dots, x_N]$, N 为序列长度。

1) 嵌入

选择合适的窗口长度 L (一般取 $L < N/2$, 可根据经验确定) 将原始时间序列进行滞后排列得到轨迹矩阵, 并令 $K = N - L + 1$, 构造出 $L \times K$ 阶的轨迹矩阵, 如式 (1) 所示:

$$X = \begin{bmatrix} x_1 & x_2 & \dots & x_K \\ x_2 & x_3 & \dots & x_{K+1} \\ \vdots & \vdots & \ddots & \vdots \\ x_L & x_{L+1} & \dots & x_N \end{bmatrix} \quad (1)$$

2) 分解

对轨迹矩阵进行奇异值分解 (SVD) 处理, 由于直接对轨迹矩阵分解比较困难, 因此首先按照式 (2) 计算轨迹矩阵的协方差矩阵:

$$S = XX^T \quad (2)$$

接着对 S 进行特征值分解得到特征值 $\lambda_1 > \lambda_2 > \dots > \lambda_L \geq 0$ 和对应的特征向量 $U = [U_1, U_2, \dots, U_L]$, $\lambda_1 > \lambda_2 > \dots > \lambda_L \geq 0$ 为原序列的奇异谱, 并且有:

$$X = \sum_{m=1}^L \sqrt{\lambda_m} U_m V_m^T, V_m = \frac{X^T U_m}{\sqrt{\lambda_m}}, m = 1, 2, \dots, L \quad (3)$$

其中, λ_i 对应的特征向量 U_i 反映了时间序列的演变型, 称为时间经验正交函数 (T-EOF)。

3) 分组

将下标集合 $\{1, 2, \dots, m\}$ 划分成 M 个互不相交的子集 I_1, I_2, \dots, I_M , 令 $I = \{i_1, i_2, \dots, i_p\}$, 则对应于 I 的合成矩阵有 $X_I = X_{i_1} + X_{i_2} + \dots + X_{i_p}$, 同时有:

$$X = X_{I_1} + X_{I_2} + \dots + X_{I_M} \quad (4)$$

4) 重构

将分组矩阵 $X_I = (y_{ij})_{L \times K}$ 用对角平均法转换为所对应的长度为 T 的序列 $RC_{I_i} = (rc_1, rc_2, \dots, rc_T)$, RC_{I_i} 中第 k 个元素为矩阵 X_I 中满足 $i + j = k + 1$ 的所有元素的均值。具体操作如式 (5) 所示:

$$X_I = \begin{cases} \frac{1}{k} \sum_{m=1}^k y_{m, k-m+1}, & 1 \leq k < L \\ \frac{1}{L} \sum_{m=1}^L y_{m, k-m+1}, & L \leq k < K \\ \frac{1}{T-k+1} \sum_{m=k-K+1}^{T-k+1} y_{m, k-m+1}, & K \leq k \leq T \end{cases} \quad (5)$$

一般来说, 在进行奇异值分解后, 为了确定噪声分量的位置, 往往会根据奇异值分解计算出的特征值重组为趋势项、周期项、残差项 3 个部分, 其中残差项即为噪声部分, 其余两部分包含了原时间序列的主要信息, 将重构为新的时间序列, 作为预测模型的输入。

1.3 趋势项预测模型

1) 支持向量回归 SVR

在趋势项预测模型选择上, 支持向量机能够适应小样本数据, 具有泛化能力强、训练时间短等优点, 因而本文选用该模型对趋势项进行预测。支持向量机应用到非线性回归估计和曲线拟合中, 被称为支持向量回归。

对于样本 $\{(x_i, y_i), i = 1, 2, \dots, l\}$, 其中 $x_i \in R^n$ 为样本输入, $y_i \in R$ 为样本输出。首先利用非线性映射 $\varphi(x)$ 将样本映射到一个高维特征空间, 建立线性模型 $y = f(x) = \omega^T \varphi(x) + b$, 并使其估计真实风险最小, 需要极小化结构风险函数, 该函数回归问题等价于:

$$\min \frac{1}{2} \omega^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) \quad (6)$$

$$\text{s. t. } \begin{cases} f(x_i) - y_i \leq \varepsilon + \xi_i \\ y_i - f(x_i) \leq \varepsilon + \xi_i^* \\ \xi_i \geq 0, \xi_i^* \geq 0, i = 1, 2, \dots, l \end{cases}$$

式中: $\|\omega^2\|$ 为与模型复杂度相关的因素, C 为惩罚系数, ξ_i, ξ_i^* 为松弛变量, 表示样本偏离 ε 不敏感区域的程度。对于式 (7), 求解模型的拉格朗日对偶问题获得原问题的最优解:

$$f(x) = \sum_{i=1}^l (\alpha_i^* - \alpha_i) K(x_i, x) + b \quad (7)$$

其中, α_i, α_i^* 为拉格朗日乘子, $K(x_i, x) = \varphi(x_i) \varphi(x)$ 为一个满足 Mercer 条件的核函数。在本研究中, 采用最常用与性能较好的径向基核函数作为支持向量回归的核函数。

2) GWO-SVR

SVR 模型中, 惩罚系数 C 、径向基核函数的参数 γ 和不敏感损失函数 ε 是需要标定的关键参数。以往研究中, 这类参数通常依据工程经验来确定, 且人工难以寻找

最优参数组合。本文将灰狼优化算法与支持向量回归算法融合,利用灰狼优化算法结构简单、收敛速度快、能够在平衡局部寻优与全局搜索之间实现平衡的优点,对支持向量回归的参数进行寻优。

灰狼优化算法由澳大利亚学者 Mirjalili 等^[17]受自然界中灰狼捕猎行为启发于 2014 年提出。假设灰狼群分为 4 个等级并从小到大呈现出金字塔结构,处于金字塔顶端至低端的灰狼分别用 α 、 β 、 δ 、 ω 表示,且上一层级的灰狼对下面层级的灰狼拥有绝对的支配权。

假设有 1 只灰狼 α 、1 只灰狼 β 和 1 只灰狼 δ ,同时假设在 d 维空间中,灰狼 α 、 β 、 δ 的位置分别为 $X_\alpha(X_{\alpha,1}, X_{\alpha,2}, \dots, X_{\alpha,d})$, $X_\beta(X_{\beta,1}, X_{\beta,2}, \dots, X_{\beta,d})$ 和 $X_\delta(X_{\delta,1}, X_{\delta,2}, \dots, X_{\delta,d})$,灰狼 i (任一层级的灰狼均有可能) 的当前位置为 $X_i(X_{i,1}, X_{i,2}, \dots, X_{i,d})$,则灰狼 i 在灰狼 α 的引导下的下一个位置 $X_{\alpha i}(X_{\alpha i,1}, X_{\alpha i,2}, \dots, X_{\alpha i,d})$ 的计算公式如下:

$$X_{\alpha i,k} = X_{\alpha,k} - A_1 D_{\alpha,k} \quad (8)$$

$$D_{\alpha,k} = |C_1 X_{\alpha,k} - X_{i,k}| \quad (9)$$

$$C_1 = 2r_2 \quad (10)$$

$$A_1 = 2ar_1 - a \quad (11)$$

式中: $X_{\alpha i,k}$ 为空间坐标 $X_{\alpha i}$ 的第 k 个分量; $D_{\alpha,k}$ 为狼群与猎物之间的距离, C_1 为系数向量,控制狼群行动; A_1 为收敛向量,控制狼群行动, a 随着迭代次数的增加,在 0~2 范围内递减; r_1 和 r_2 为 $[0, 1]$ 的随机数。

同理,灰狼 i 在灰狼 β 、灰狼 δ 的引导下的下一个位置 $X_{\beta i,k}$ 、 $X_{\delta i,k}$ 的计算可依此类推。

综上所述,灰狼 i 在灰狼 α 、 β 、 δ 的同时引导下的下一个位置 X_i 的第 k 个分量计算公式如下:

$$X_{i,k} = \frac{X_{\alpha i,k} + X_{\beta i,k} + X_{\delta i,k}}{3} \quad (12)$$

算法的具体流程如图 2 所示。

1.4 周期项预测模型

1) 极限学习机 ELM

在周期项预测方面,为了加快运行速度、减少参数设置,本文选择带遗忘机制的在线序列极限学习机模型。极限学习机(ELM)算法可解决传统神经网络中迭代时间长、学习速率慢、学习参数需要人为提前设置等问题。假设有一组训练样本 $(\mathbf{x}_i, \mathbf{y}_i)$, $\mathbf{x}_i = (x_{i1}, x_{i2}, \dots, x_{in})^T \in R^n$ 为网络的样本输入向量, $\mathbf{y}_i = (y_{i1}, y_{i2}, \dots, y_{im})^T \in R^m$ 为网络的输出向量,标准的带 L 个隐层神经元的 ELM 的一般形式如式(13)所示:

$$f_L(x) = \sum_{i=1}^L \beta_i G_i(x) = \sum_{i=1}^L \beta_i G_i(a_i, b_i, X) \quad (13)$$

式中: β_i 为输出权重, $G_i(a_i, b_i, X)$ 为激活函数, a_i 为网络的输入权重, b_i 为第 i 个隐层的单元阈值。

2) FOS-ELM

当有新的训练样本出现时,ELM 会对原有数据和新

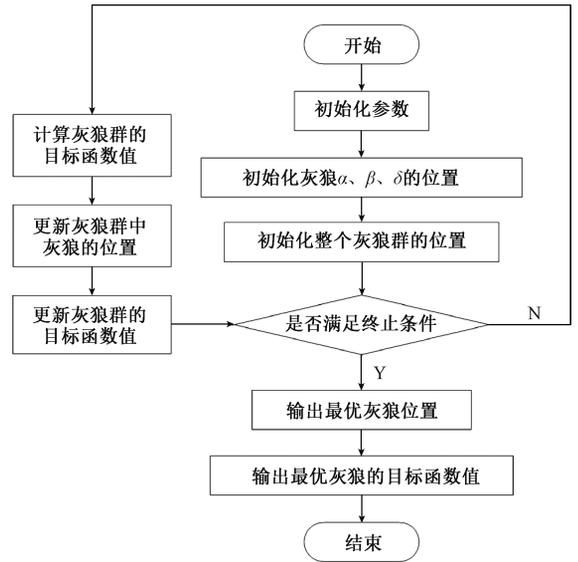


图 2 灰狼优化算法流程

Fig. 2 Flow chart of gray wolf optimization algorithm

数据重新进行训练,导致学习效率低下,因而 Liang 等^[18]提出了在线序列极限学习机(online sequential-extreme learning machine, OS-ELM),该算法与标准 ELM 的区别在于引入在线机制,即不需要重复训练旧的样本,主要涉及权重的更新,即当第 k 批样本到达时的 β 更新方式为:

$$\beta^k = \beta^{k-1} + P_k H_k^T (T_k - H_k \beta^{k-1}) \quad (14)$$

其中, H_k 为 $G_k(a_k, b_k, X)$; P_k 命名为工作矩阵,为 H_k 的转置与 H_k 乘积的逆,初始化时:

$$P_0 = (H_0^T H_0)^{-1} \quad (15)$$

其更新方式为:

$$P_k = P_{k-1} - P_{k-1} H_k^T (I + H_k H_k^T)^{-1} H_k P_{k-1} \quad (16)$$

式中: I 为单位矩阵。

在实际应用过程中,训练数据不但具有动态变化的特性,往往还具有时效性。因此,在增量学习过程中加入新样本的同时,也应该及时淘汰那些过于陈旧的样本^[19]。针对这一问题,Zhao 等^[20]将遗忘机制与 OS-ELM 结合,以消除过期数据对预测的影响。该机制通过设置滑动时间窗口来完成模型的在线更新,当超过该窗口时,学习机会启动遗忘机制,在学习过程中丢弃过时的数据,减少其对后续训练的不良影响。如果启动了遗忘机制,设待删除的样本为第 l 批,则对工作矩阵 P_k 有:

$$P_k = \left(\sum_{i=k-l+1}^k H_i^T H_i + H_k^T H_k \right)^{-1} = (P_{k-1}^{-1} + H_k^T H_k - H_{k-l}^T H_{k-l})^{-1} \quad (17)$$

那么 β 的更新方式为:

$$\beta^k = \beta^{k-1} + P_k \begin{bmatrix} -H_{k-l} \\ H_k \end{bmatrix}^T \left(\begin{bmatrix} T_{k-l} \\ T_k \end{bmatrix} - \begin{bmatrix} H_{k-l} \\ H_k \end{bmatrix} \beta^{k-1} \right) \quad (18)$$

2 实证分析

2.1 数据来源

本文采用深圳市宝安区某监测点位车流量日统计数据作为样本,时间跨度在 2017 年 3 月~2019 年 8 月,符

合长时交通流的特征。由图 3 可以看出,该时间序列没有明显的趋势,呈现不规则、波动较大等特征,且存在明显的噪声。为了验证模型的有效性,本文划分序列的前 90%数据为训练集,共 792 条;后 10%数据为测试集,共 88 条。

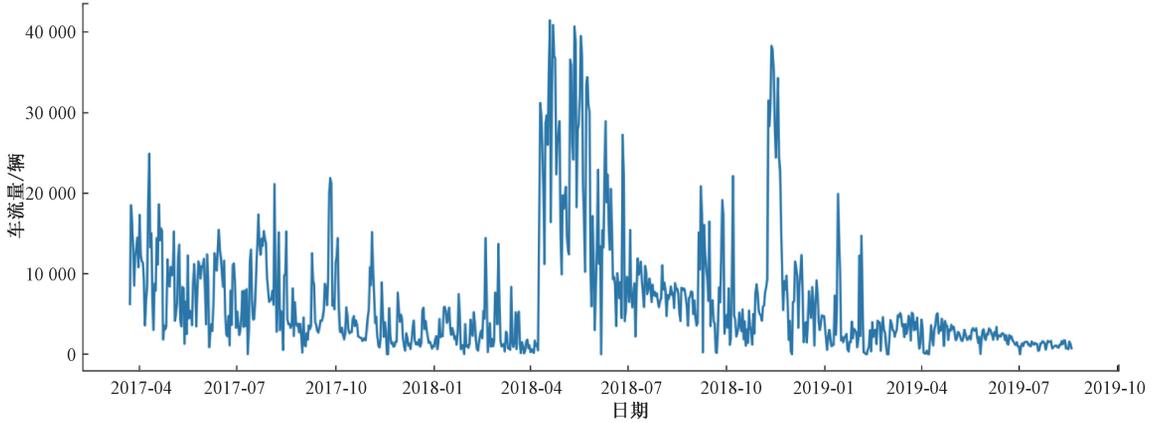


图 3 车流量日统计数据折线图

Fig. 3 Line chart of daily traffic flow data

2.2 数据分解与重构

本文首先对原始时间序列进行奇异谱分析,一般来说,过小的窗口长度无法提取主要信息,而过大的窗口长度又会增加模型的复杂度。在本研究中,所要预测的序列主要为趋势项和周期项,且原序列的主要成分通常在

前几个分量之中,因此嵌入窗口长度设置不宜过多。经过多次调试,将嵌入窗口长度设置为 10,得到 10 个序列分量,如图 4 所示。根据奇异值分解计算特征值与方差贡献率,如表 1 和图 5 所示。

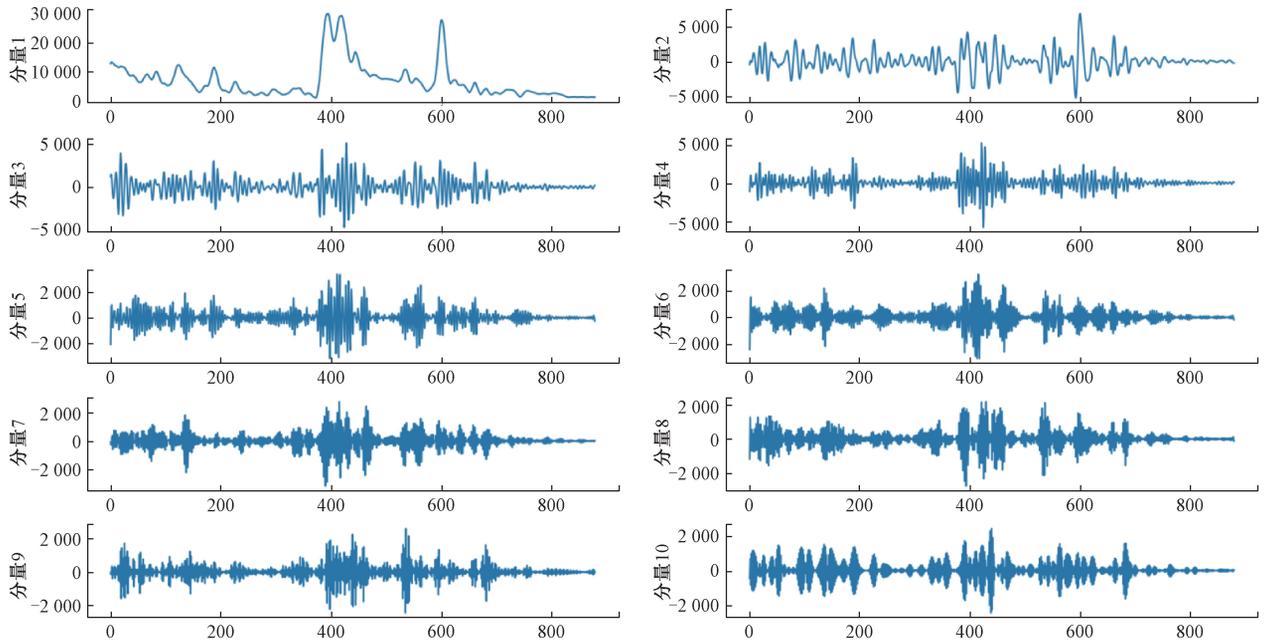


图 4 重构后的序列分量

Fig. 4 Reconstructed sequence components

表 1 SSA 重构分量对应的特征值及方差贡献率

Table 1 Eigenvalues and variance contribution rates corresponding to SSA reconstruction components

序号	特征值	特征值求和	方差贡献率/%	累计方差贡献率/%
1	863 738. 954	863 738. 954	44. 53	44. 53
2	217 605. 062 3	1 081 343. 95	11. 22	55. 75
3	160 702. 896 4	1 242 046. 85	8. 29	64. 04
4	143 344. 428 9	1 385 391. 28	7. 39	71. 43
5	119 695. 011 2	1 505 086. 29	6. 17	77. 60
6	102 588. 483 8	1 607 674. 77	5. 29	82. 89
7	95 326. 321 48	1 703 001. 1	4. 91	87. 80
8	86 428. 192 59	1 789 429. 29	4. 46	92. 26
9	78 857. 505 9	1 868 286. 79	4. 07	96. 32
10	71 342. 1614 3	1 939 628. 96	3. 68	100. 00

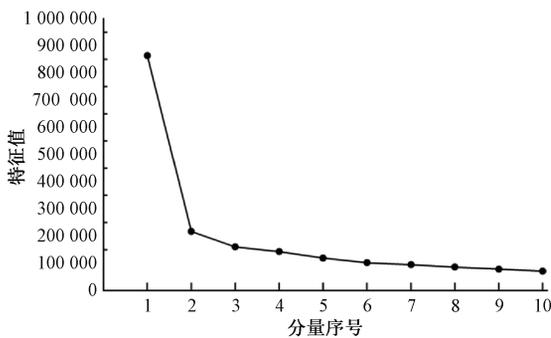


图 5 SSA 重构分量对应的特征值

Fig. 5 Eigenvalues of SSA reconstruction components

由图 5 可知,第 1~2 个序列分量大致反映了原序列的趋势,其余分量则展现了原序列的周期与噪声。为了进一步确定原序列的趋势与周期,由图 4 和 5 可知,第 2 个特征值开始呈现“断点”趋势,第 6~7 个序列分量特征值趋于平稳。因此,为了尽可能保留原序列的信息,本文选取前 7 个序列分量进行重构,其累计方差贡献率达到了 87.8%,基本能够反映原交通流的特征。经过多次测试结果对比,本文选取前 2 个分量为趋势项,第 3~7 个分量为周期项,第 8~10 个分量为噪声项。

2.3 参数设置与模型预测

实验在 Window 10 x64 操作系统下进行,CPU 为 Intel(R) Core(TM) i7-8700 @ 3.20 GHz,内存为 8 GB, GPU 为 NVIDIA GeForce GTX 1060 6 GB。训练之前,首先对样本数据进行归一化处理,如式(19)所示:

$$x' = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (19)$$

式中: x' 为归一化后的数据, x_i 为原始数据, x_{\max} 为原始数据最大值, x_{\min} 为原始数据最小值。

在预测过程中,设置时间步长为 6;灰狼优化算法参数根据人工经验确定;趋势项根据灰狼优化算法优化的参数,设置支持向量回归的惩罚系数 C 为 2.117,径向基

核函数的参数 γ 为 13.99,不敏感损失函数 ε 为 0.003 69,预测结果如图 6 所示。从图 6 中可以看出,经过灰狼优化算法优化后的 SVR 模型(GWO-SVR)基本贴合原始数据,展现了良好的预测效果;周期项模型 FOS-ELM 的隐层节点数根据调试和经验设置为 18,预测结果如图 7 所示。所有模型的参数设置如表 2 所示。在预测完成后,对预测结果反归一化,并将两部分预测结果叠加,预测结果如图 8 所示。

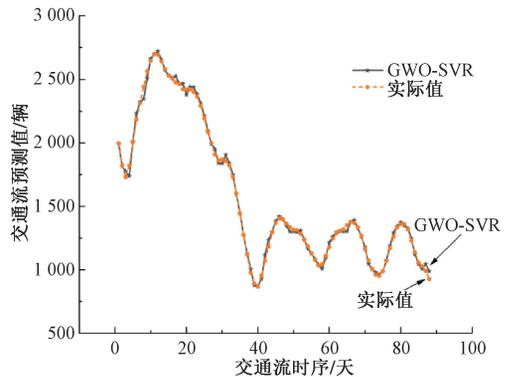


图 6 趋势项预测结果

Fig. 6 Prediction results of trend items

表 2 模型参数设置

Table 2 Comparison of optimization algorithms

模型	参数名	值
GWO	狼群数量	15
GWO	最大迭代次数	50
GWO	寻优参数 C 区间	[0,10]
GWO	寻优参数 ε 区间	[0,10]
GWO	寻优参数 γ 区间	[0,100]
SVR	C	2.117
SVR	ε	0.003 69
SVR	γ	13.99
FOS-ELM	隐层节点数	18

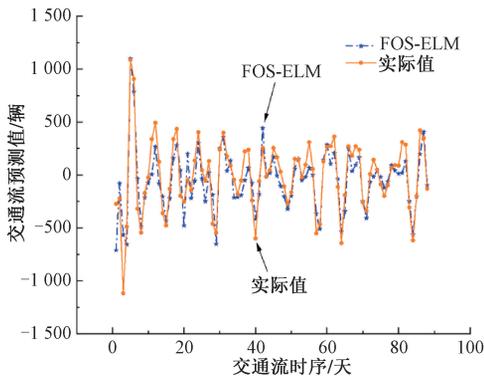


图 7 周期项预测结果

Fig. 7 Prediction results of period term

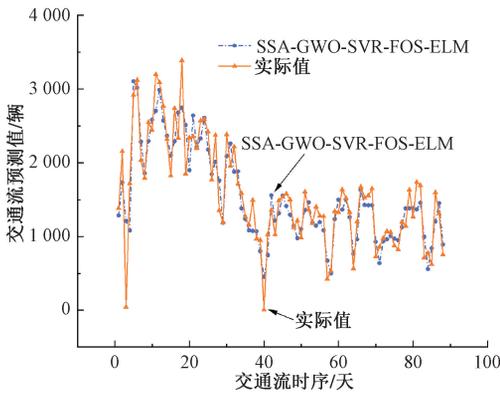


图 8 最终预测结果

Fig. 8 Final prediction results

2.4 结果分析

为了验证上述混合预测模型的预测效果,将本文提出的模型与其他代表性模型进行对比。在评价指标选取上,本文选取平均绝对误差(mean absolute error, MAE)、均方根误差(root mean square error, RMSE)作为模型误差分析的指标。MAE、RMSE 的公式分别为:

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (20)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (21)$$

式中: \hat{y}_i 为预测值, y_i 为实际值, n 为样本量。

首先,在趋势项模型预测中,优化算法的计算效率值得关注。为了进一步分析本文所选用的灰狼优化算法的效率,选取了遗传算法(genetic algorithm, GA)、粒子群算法(particle swarm optimization, PSO)进行比较。其中,遗传算法通过自然选择思想迭代生成最优解,应用较为广泛;粒子群算法通过模拟一组粒子在空间中飞行搜索产生最优解,能够平衡局部搜索和全部搜索能力。将两种算法优化后的参数输入到趋势项 SVR 模型之中,输出评

价指标与收敛速度,其中收敛速度如图 9 所示,与 GWO-SVR 和原始 SVR 模型的预测结果对比如表 3 所示。

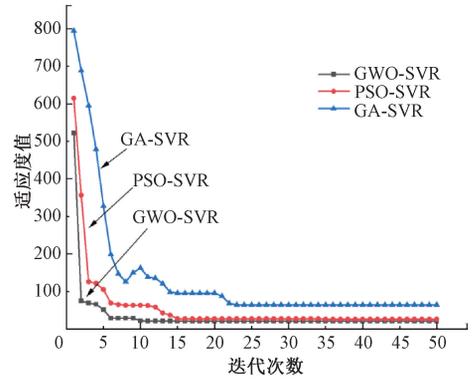


图 9 收敛速度对比

Fig. 9 Comparison of convergence speed

表 3 趋势项优化算法对比

Table 3 Comparison of optimization algorithms on tendency term

模型	MAE	RMSE
GWO-SVR	20.85	27.98
GA-SVR	64.45	78.01
PSO-SVR	26.04	32.70
SVR	238.55	283.55

由表 3 和图 9 可知,经过灰狼优化的支持向量回归算法 MAE 为 20.85, RMSE 为 27.98, 约 10 次时找到全局最优解,与其他 3 种模型相比误差更小、收敛速度更快。进一步看,3 种优化算法中遗传算法计算效率较差,容易陷入局部极值,可能是由于其控制参数较多、对初始种群优劣的依赖性较强等原因造成;粒子群算法计算效率较高,约 15 次左右完成收敛;而未经过优化的 SVR 模型误差较大。总体上看,灰狼优化算法在优化过程中具有较好的寻优能力与计算效率。

其次,将混合模型与经过奇异谱分析的单一模型进行了对比,分别为 SSA-LSTM^[21]、SSA-SVR、SSA-FOS-ELM,数据处理的方法均与上文相同,预测结果如表 4 所示。

表 4 本文提出模型与 SSA 处理后的单一模型对比

Table 4 Comparison of the presented model with single models after SSA treatment

模型	MAE	RMSE
本文模型	215.15	278.51
SSA-LSTM	254.87	336.63
SSA-SVR	215.15	283.84
SSA-FOS-ELM	229.95	301.97

由表 4 可知,本文所提出的混合模型在与经过 SSA

处理后的单一模型对比中,2 项误差指标均优于 SSA-LSTM、SSA-FOS-ELM 模型,且能够较大程度的降低误差;在与 SSA-SVR 模型的对比中,SVR 模型也经过了灰狼算法优化,虽然 MAE 指标与其无明显差距,但 RMSE 指标均优于 SSA-SVR 模型,说明了本文所提出的混合模型稳定性较强,能够充分挖掘不同模型的优势。

同时,本文也给出了未经过奇异谱分析的模型对比和经过经验模态分解后的模型对比,预测结果如表 5 所示。

表 5 本文提出模型其他模型对比

Table 5 Comparison of the presented model with other models

模型	MAE	RMSE
本文模型	215.15	278.51
LSTM	596.61	721.62
EMD-LSTM	744.69	832.92
SVR	390.05	520.21
随机森林	773.79	966.06

结合表 4 和 5 可知,1) 与未经 SSA 处理的单一模型相比,经过 SSA 处理后的模型具有更好的预测效果,主要原因在于奇异谱分析能够去除原时间序列中的高频噪声和异常现象,且分解效果比传统的经验模态分解效果更好。2) 经过 SSA 处理,混合模型的预测效果比单一模型的预测效果更好,主要原因在于混合模型能够减少由参数或模型识别错误带来的预测误差,发挥不同模型的优势,挖掘更全面的交通流时序信息,从而提高预测精度。

本文提出的模型可拓展至其他带有噪声的时间序列,即适用于波动不平滑、不规律、有其他特殊事件干扰的时间序列。相比于奇异谱分析与单一模型组合的模型,能够减少单一模型预测不稳定或模型识别错误带来的预测误差。在预测过程中,需关注奇异谱分析中特征值的变化趋势,合理选择趋势项、周期项与噪声项,在有效去噪的同时防止丢失过多原序列信息,从而达到良好的预测效果。

3 结论

针对长时交通流预测问题,本文提出了一种基于奇异谱分析的混合预测模型,首先将原始时间序列经过奇异谱分析后重构为趋势项、周期项和残余项,趋势项采用经过灰狼优化算法优化的支持向量回归进行预测,周期项采用带遗忘机制的在线序列极限学习机进行预测,最后叠加两部分预测结果。该混合模型克服了单一模型预测误差波动大、预测精度不稳定等问题,经过 SSA 处理后模型预测精度有较大提升。与当前代表性的其他长时段交通流预测模型相比,本文提出的模型有更好的预测表现。未来可进一步考虑影响交通流的外部影响因素,从

而修正预测结果,进一步提高预测精度。

参考文献

- [1] 陈喜群,曹震,沈楼涛,等.融合路段传输模型和深度学习的城市路网短时交通流状态预测[J].中国公路学报,2021,34(12):203-216.
CHEN X Q, CAO ZH, SHEN L T, et al. Prediction of short-term traffic flow in urban road network based on road segment transmission model and deep learning [J]. China Journal of Highway and Transportation, 2021, 34(12):203-216.
- [2] TSELENTIS D, VLAHOGIANNI E, KARLAFTIS M G. Improving short-term traffic forecasts: To combine models or not to combine? [J]. Intelligent Transport Systems IET, 2014, 9(2):193-201.
- [3] ZHANG S Q, LIN K P. Short-term traffic flow forecasting based on data-driven model [J]. Mathematics, 2020, 8(2):152.
- [4] 杨凤满.基于人工神经网络的交通流预测方法综述[J].公路交通科技,2020,37(S1):130-135.
YANG F M. Review of traffic flow prediction methods based on artificial neural networks [J]. Journal of Highway Transportation Science and Technology, 2020, 37(S1):130-135.
- [5] ZHOU T, HAN G, XU X, et al. A Learning-based multimodel integrated framework for dynamic traffic flow forecasting[J]. Neural Process Letters, 2019, 49(5):407-430.
- [6] 王逸文,王维莉.基于 LSTM-RELM 组合模型的电商 GMV 预测研究[J/OL].计算机工程与应用:1-9[2022-08-06]. <http://kns.cnki.net/kcms/detail/11.2127.TP.20220705.1856.016.html> WANG Y W, WANG W L. Research on GMV prediction of E-commerce based on LSTM-RELM combination model [J/OL]. Computer Engineering and Application: 1-9[2022-08-06]. <http://kns.cnki.net/kcms/detail/11.2127.TP.20220705.1856.016.html>.
- [7] 殷礼胜,孙双晨,魏帅康,等.基于自适应 VMD-Attention-BiLSTM 的交通流组合预测模型[J].电子测量与仪器学报,2021,35(7):130-139.
YIN L SH, SUN SH CH, WEI SH K, et al. Traffic flow combination prediction model based on adaptive VMD-attention-BiLSTM [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(7):130-139.
- [8] 奇兴族.基于 MI-CEEMDAN-ADABOOST 的快速路短时交通流预测[J].公路交通科技,2022,39(6):136-143.
QI X Z. Short-time traffic flow prediction based on MI-CEEMDAN-ADABOOST [J]. Science and Technology of Highway and Transportation, 2022, 39(6):136-143.
- [9] 关为生,肖建力.联合时空特征的交通流参数预测综

- 述[J]. 上海理工大学学报, 2022, 44(6): 592-602.
- GUAN W SH, XIAO J L. A Survey of traffic flow parameter prediction based on spatio-temporal characteristics [J]. Journal of Shanghai University of Science and Technology, 2022, 44(6): 592-602.
- [10] 刘赏, 陈浩, 陈小玉, 等. 面向交通流预测的双分支时空图卷积神经网络[J/OL]. 信息与控制; 1-14 [2022-06-01]. <http://kns.cnki.net/kcms/detail/21.1138.TP.20220519.1448.002.html>.
- LIU SH, CHEN H, CHEN X Y, et al. Facing the double branch of traffic flow predictive spatio-temporal figure convolutional neural networks [J/OL]. Information and Control; 1-14 [2022-06-01]. <http://kns.cnki.net/kcms/detail/21.1138.TP.20220519.1448.002.html>.
- [11] 贺文武, 裴博或, 毛国君, 等. 基于轻量时空图卷积模型的路网交通流预测[J]. 铁道科学与工程学报, 2022, 19(9): 2552-2562.
- HE W W, PEI B Y, MAO G J, et al. Road network traffic flow prediction based on lightweight spatio-temporal graph convolution model [J]. Journal of Railway Science and Engineering, 2022, 19(9): 2552-2562.
- [12] 倪庆剑, 彭文强, 张志政, 等. 基于信息增强传输的时空图神经网络交通流预测[J]. 计算机研究与发展, 2022, 59(2): 282-293.
- NI Q J, PENG W Q, ZHANG ZH ZH, et al. Traffic flow prediction based on spatiotemporal graph neural network with information enhanced transmission [J]. Computer Research and Development, 2022, 59(2): 282-293.
- [13] 凌立文, 张大斌. 组合预测模型构建方法及其应用研究综述[J]. 统计与决策, 2019, 35(1): 18-23.
- LING L W, ZHANG D B. A review of combinatorial forecasting model construction methods and their applications [J]. Statistics and Decision, 2019, 35(1): 18-23.
- [14] 殷礼胜, 唐圣期, 李胜, 等. 基于 EEMD-IPSO-LSSVM 的交通流组合预测模型[J]. 电子测量与仪器学报, 2019, 33(12): 126-133.
- YIN L SH, TANG SH Q, LI SH, et al. Traffic flow combination prediction model based on EEMD-IPSO-LSSVM [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(12): 126-133.
- [15] 李帅永, 夏传强, 程振华, 等. 基于 VMD 和互谱分析的供水管道泄漏定位方法[J]. 仪器仪表学报, 2019, 40(7): 195-205.
- LI SH Y, XIA CH Q, CH ZH H, et al. Leakage location method of water supply pipeline based on VMD and cross spectrum analysis [J]. Chinese Journal of Scientific Instrument, 2019, 40(7): 195-205.
- [16] 梁小珍, 乔晗, 汪寿阳, 等. 基于奇异谱分析的我国航空客流量集成预测模型[J]. 系统工程理论与实践, 2017, 37(6): 1479-1488.
- LIANG X ZH, QIAO H, WANG SH Y, et al. An integrated prediction model for China's air passenger traffic based on singular spectrum analysis [J]. Systems Engineering Theory & Practice, 2017, 37(6): 1479-1488.
- [17] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer[J]. Advances in Engineering Software, 2014, 69(3): 46-61.
- [18] LIANG N Y, HUANG G B, SARATCHANDRAN P. A fast and accurate online sequential learning algorithm for feed forward networks[J]. IEEE Transactions on Neural Networks, 2006, 17(6): 1411-1423.
- [19] 徐睿, 梁循, 齐金山, 等. 极限学习机前沿进展与趋势[J]. 计算机学报, 2019, 42(7): 1640-1670.
- XU R, LIANG X, QI J SH, et al. Advances and trends of extreme learning machine [J]. Journal of Computer Science, 2019, 42(7): 1640-1670.
- [20] ZHAO J, WANG Z, PARK D S. Online sequential extreme learning machine with forgetting mechanism[J]. Neurocomputing, 2012, 87: 79-89.
- [21] 任鹏达, 左忠义, 陈洪涛. 基于 SSA-LSTM 的城市轨道交通短时客流预测[J]. 武汉理工大学学报, 2022, 44(2): 44-52.
- REN P D, ZUO ZH Y, CHEN H T. Short-term passenger flow prediction of urban rail transit based on SSA-LSTM [J]. Journal of Wuhan University of Technology, 2022, 44(2): 44-52.

作者简介



王逸文, 2021 年于厦门大学嘉庚学院获得学士学位, 现为上海海事大学硕士研究生, 主要研究方向为物流系统优化。

E-mail: 929458033@qq.com

Wang Yiwen received his B. Sc. degree from Xiamen University TKK College in 2021.

Now He is a M. Sc. candidate at Shanghai Maritime University. His main research interest includes optimization of logistics system.



王维莉(通信作者), 2009 年于武汉大学获得学士学位, 2011 于武汉大学获得硕士学位, 2015 年于香港城市大学获得博士学位, 现为上海海事大学副教授, 主要研究方向为复杂交通系统建模与仿真。

E-mail: wlwang@shmtu.edu.cn

Wang Weili (Corresponding author) received her B. Sc. degree from Wuhan University in 2009, M. Sc. degree from Wuhan University in 2011, and Ph. D. degree from City University of Hong Kong in 2015, respectively. Now She is an associate professor in Shanghai Maritime University. Her main research interests include modeling and simulation of complex traffic system.