

李亚香,王元庆.基于 PSO-LSSVM 算法的城市轨道交通断面客流量预测[J].长安大学学报(自然科学版),2021,41(6):91-102.

LI Ya-xiang, WANG Yuan-qing. Cross-section passenger flow forecasting of urban rail transit based on PSO-LSSVM algorithm[J]. Journal of Chang'an University(Natural Science Edition), 2021, 41(6): 91-102.

DOI:10.19721/j.cnki.1671-8879.2021.06.010

基于 PSO-LSSVM 算法的城市轨道交通断面客流量预测

李亚香,王元庆

(长安大学 运输工程学院,陕西 西安 710064)

摘要:为提高城市轨道交通服务水平和利用效率,针对非高峰期乘客等候时间过长、高峰期车厢满载率过高、列车运能浪费等现象,急需对具有非线性和随机波动特征的轨道交通最大断面客流实时准确预测,从而动态调整列车行车计划。首先,采集 2017 年 4~6 月份西安市轨道交通 2 号线全日分时段断面客流量为数据基础,将断面客流量划分为工作日、周末以及节假日的上行断面客流量和下行断面客流量。其次,利用前 3 d 各时段最大断面客流量以及前 1 d 各时段断面客流量作为模型输入变量,当天最大断面客流量作为模型输出变量,构建最小二乘支持向量机(LSSVM)核参数最优模型。然后,将 RBF 核、POLY 核和 Sigmoid 核组合出多种备选核函数,以正则化参数、宽度参数、阶数参数和偏置参数为对象,利用粒子群算法(PSO)来优化备选函数和关键参数。最后,对不同模型中粒子群算法优化前后预测效果的回归评价指标和工作日、周末和节假日各时段回归误差进行比较分析。研究结果表明:粒子群算法寻优工作日 LSSVM 备选函数和关键参数后平均绝对百分比误差在 5.0% 以内,预测精度均有所改善;工作日上行的 RBF 与 Sigmoid 混合核,以及下行的 RBF 核能够在运行速度更快且精度更高条件下对断面客流量预测效果最优;PSO-LSSVM 模型对工作日高峰期的断面客流量预测效果最优;相比 PSO-LSSVM 模型工作日较优的预测效果,其对周末和节假日上行的断面客流量具有一般预测效果。PSO 寻优 LSSVM 核函数模型能更好解释工作日断面客流量的复杂变化,在小样本下达到较为理想的回归精度,具有良好的实用价值。

关键词:交通工程;城市轨道交通;断面客流量预测;粒子群算法;LSSVM 算法;混合核函数

中图分类号:U491.14

文献标志码:A

文章编号:1671-8879(2021)06-0091-12

Cross-section passenger flow forecasting of urban rail transit based on PSO-LSSVM algorithm

LI Ya-xiang, WANG Yuan-qing

(College of Transportation Engineering, Chang'an University, Xi'an 710064, Shaanxi, China)

Abstract: In order to improve the level of service and the utilization efficiency of urban rail transit, in view of the problems such as long waiting time for passengers during the off-peak

收稿日期:2021-07-18

基金项目:国家自然科学基金项目(51878062, 51908462)

作者简介:李亚香(1987-),女,天津蓟州人,工学博士研究生,E-mail:gracelee@chd.edu.cn.

作者简介:王元庆(1968-),男,陕西吴起人,教授,博士研究生导师,E-mail:wyqing@chd.edu.cn.

period, high train loading rate during the peak period, and wasted train capacity etc., the maximum cross-section passenger flow of urban rail transit with the feature of nonlinear and random fluctuation was urgent to forecast accurately and rapidly, which could be applied to adjust the train operation plan in time. Firstly, the full-day and time-sharing cross-section passenger flow of Xi'an Urban Rail Transit Line 2 from April to June in 2017 were collected as the data basis, which were divided into the upward passenger flow and the downward passenger flow on weekdays, weekends and holidays. Secondly, the maximum cross-section passenger flow of each phase in the first three days and the cross-section passenger flow of each phase in the day before were adopted as the input variables of the model, and the intraday maximum cross-section passenger flow were adopted as the output variables of the model. Optimal parameters of kernel functions in least squares support vector machines (LSSVM) model were constructed. Thirdly, the RBF kernel, POLY kernel and Sigmoid kernel were combined into a variety of alternative kernel functions. Taking regularization parameter, width parameter, order parameter and offset parameter as the objects, particle swarm optimization (PSO) was chosen to optimize these alternative functions and key parameters. Finally, the regression evaluation indexes of the prediction effects before and after PSO optimization and regression errors in each phase on weekdays, weekends and holidays were compared in different models. The results show that the values of mean absolute percentage error are lower than 5.0% after that the alternative functions and key parameters in LSSVM are optimized by PSO on weekdays, and the accuracy of passenger flow prediction is improved. Under the condition of faster running speed and higher accuracy, the RBF and Sigmoid mixed kernel has the best fitting effect on the upward cross-section passenger flow on weekdays, and the RBF kernel function has the best fitting effect on the downward cross-section passenger flow on weekdays. PSO-LSSVM model has the optimal prediction effect on cross-section passenger flow during the peak hours on weekdays. Compared with the better prediction effect of PSO-LSSVM model on weekdays, it has a relatively poor prediction effect on cross-section passenger flow on weekends and upward cross-section passenger flow on holidays. The improved kernel function LSSVM model with PSO can better explain the complex fluctuations of cross-section passenger flow on weekdays, achieve ideal regression accuracy under the small sample, and has the real practical value. 1 tab, 12 figs, 25 refs.

Key words: traffic engineering; urban rail transit; cross-section passenger flow forecasting; particle swarm optimization; least squares support vector machines; mixed kernel function

0 引言

基于轨道交通客流量预测对列车行车计划和调度策略进行调整,使得轨道交通运能与客流需求相匹配,从而有效提高列车运载效率、减少运能损失、降低运行成本。截至 2020 年底,中国(不含港澳台)已有 44 个城市开通运营了 233 条轨道交通线路,总长度为 7 545.5 km^[1]。其中,北京、上海、广州、深圳、西安等城市的轨道交通车站广泛采用自动检票系统(automated fare collection, AFC),该智能联网收费系统的应用为城市轨道交通客流量预测提供了数据支持^[2-3]。与此同时,数学理论与数理统计的传

统优化方法在轨道交通客流量受众多因素影响的非线性问题预测局限性日益凸出,先进技术如计算机技术、大数据技术、自动化技术等广泛应用,已成为轨道交通智能化系统发展的新趋势^[4]。回顾过去十多年研究成果,客流量预测优化问题普遍采用参数模型与非参数模型。参数预测模型包括多元线性回归^[5]、移动平均回归模型(ARIMA)^[4,6]、灰色模型(GM)^[7]等。非参数预测模型则是对目标函数形式不做过多假设,利用历史数据和现实数据拟合出大量的不同函数,此模型涉及支持向量机(SVM)^[8-10]、BP 神经网络^[11]、小波分析^[12-13]、K 近邻方法^[14-15]、长短期记忆递归神经网络(LSTM)^[16-17]等方法。

目前,研究轨道交通客流量预测的文献多采用小样本情况下仍具有较好预测效果的支持向量机模型,此模型基于严格的数学理论保证结构风险最小化,在求解非线性、有限样本等优化问题的实际应用中具有优越的性能^[2-4,8-12,18-23]。周家中等分别采用了最小二乘支持向量机(LSSVM)、四阶段模型、多元回归模型来预测轨道交通车站客流量,发现基于空间加权的最小二乘支持向量机的预测效果要显著优于其他模型^[18]。Tang 等提出了基于模糊信息粒化和混沌粒子群算法(CPSO)优化最小二乘支持向量机核函数参数的轨道交通客流量波动范围组合预测模型,并证明该模型的预测效果优于最小二乘支持向量机模型、BP 神经网络^[21]。张和杰等构建了 SVM 轨道交通客流量回归预测模型,并与 ARIMA、BP 神经网络等方法的预测结果进行对比分析,结果表明 SVM 将平均绝对百分比误差值降低了 8.0%^[8]。Li 等采用季节性移动平均回归模型(SARIMA)和支持向量机预测线性组合来拟合轨道交通车站进站客流量,结果表明 SARIMA-SVM 组合模型优于 SVM 的预测效果^[4]。上述研究多侧重于支持向量机组合模型的构建、模型预测精度的改善、客流量波动范围的确定,但未全面考虑支持向量机的不同核函数类型对轨道交通客流量预测结果的影响。

不同核函数类型的选用是直接影响支持向量机预测模型精度的关键因素^[21]。轨道交通客流量预测模型通常采用泛化能力强的 RBF 核函数^[12,19,21,23],以及 RBF 与 POLY 混合核函数^[10,20,22]。Sun 等采用小波技术将轨道交通客流量数据分解成高频量与低频量,随后利用 LSSVM 的 RBF 核函数参数调优来预测客流量,研究表明小波支持向量机模型的预测性能与原始时间序列、残差时间序列基本一致^[12]。Liu 等针对节假日轨道交通客流量预测,提出利用改进的粒子群算法(IPSO)对最小二乘支持向量机 RBF 核函数参数寻优,采用 k-重(k-Fold)交叉验证方法来检验预测精度,研究证明 IPSO-LSSVM 方法的预测精度高于 ARIMA、BP 神经网络等方法^[19]。郭文等以苏州轨道交通数据为例,构建 SVM 的 RBF 核函数轨道交通进站客流量预测模型,并与遗传算法改进支持向量机模型(GA-SVM)结果进行对比分析,指出所提出 PSO-SVM 模型将平均相对误差值降低了 2.0%^[23]。赵丽琴提出无限叠迭黄金分割(GCPSO)算法和 SVM 的 RBF 与 POLY 混合核相结合的轨道交通进站客

流量预测模型,并与单核 SVM 的预测结果进行比较,验证所提出方法的预测精度更高^[10]。耿立艳等构建了基于果蝇算法(FOA)优化 LSSVM 的 RBF 与 POLY 混合核的铁路货运量预测方法,研究表明混合核 LSSVM 比单核 LSSVM 能更好地揭示铁路货运量的复杂变化^[20]。Zhu 等针对轨道交通客流量预测,利用深度信念网络模型提炼客流变动特征,并用遗传算法优化 SVM 的 RBF 和 POLY 核函数参数,结果发现,时间粒度越大则模型预测精度就越高^[22]。因此,本文调用多种核函数、单核函数或混合核函数来比选不同模型预测效果,为轨道交通客流量预测研究提供借鉴。

LSSVM 参数优化问题没有确定或通用的共识方法。由于智能算法在轨道交通客流量预测模型参数的选取确定方面具有稳健性和通用性,客流量预测模型参数最优化过程中主要采用了遗传算法^[9,22]、果蝇优化算法^[20]、萤火虫算法^[8]、粒子群算法(PSO)^[9-10,18-23]、网格搜索算法^[9]、神经网络^[24]等智能算法。粒子群算法不断调整自身和种群最优位置关系,具有更强寻优能力。因此,为进一步得到可靠的模型参数,可沿用粒子群算法进行尝试验证。

基于支持向量机模型研究的对象和数据大多为轨道交通车站的刷卡交易数据^[3]、工作日和节假日的进出站客流量^[2]、工作日进站客流量^[4,8-10,22-23]、非工作日进站客流量^[4,8-9,22]、进站和换乘客流量^[12]、年平均工作日客流量^[18]、节假日进站客流量^[19]、工作日早高峰客流量^[21]。但是,针对 LSSVM 的不同核函数,其参数的选择和优化在轨道交通断面客流量预测研究鲜有涉及。

本文提出了一种改进的 PSO-LSSVM 算法流程,以西安市轨道交通数据为例,对不同核函数模式进行测试,将轨道交通断面客流量划分为工作日、周末以及节假日的上行断面客流量和下行断面客流量进行预测,并对回归评价指标结果比较分析,归纳总结了可借鉴算法成果。

1 LSSVM 算法模型

1.1 LSSVM 原理

最小二乘支持向量机,是由 Suykens 等提出,结合最小二乘估计将 SVM 问题转化为求解线性方程^[25]。目前 LS-SVMlab 工具箱包含 MATLAB/C,实现了许多 LSSVM 算法。

给定数据集 $\{(x_1, y_1), (x_2, y_2), \dots, (x_i, y_i), \dots, (x_\eta, y_\eta) | i=1, 2, \dots, \eta, x_i \in \mathbf{R}^n, y_i \in \mathbf{R}\}$, 其中: η 为集

合样本总数; x_i 为 n 维空间的第 i 个输入变量; \mathbf{R}^n 为 n 维欧几里得空间; y_i 为与 x_i 相对应的输出变量; \mathbf{R} 为一维欧几里得空间。LSSVM 回归预测函数 $f(x)$ 为

$$f(x) = \mathbf{w}^T \varphi(x) + b \quad (1)$$

式中: $\varphi(x)$ 为输入数据集非线性变换函数; \mathbf{w}^T 为权重向量 \mathbf{w} 的转置; b 为偏置项。

LSSVM 的结构风险最小化优化形式如下

$$\min J(\mathbf{w}, e) = \frac{1}{2} \mathbf{w}^T \mathbf{w} + \frac{\gamma}{2} \sum_{i=1}^{\eta} e_i^2 \quad (2)$$

式中: $J(\cdot)$ 为风险目标函数; e 为误差; e_i 为第 i 个样本误差; γ 为惩罚参数(又称正则化参数)。

转换成等式约束条件为

$$y_i - \mathbf{w}^T \varphi(x_i) - b - e_i = 0 \quad (3)$$

构造 Lagrange 函数如下

$$\begin{cases} L(\mathbf{w}, b, e, \alpha) = J(\mathbf{w}, e) - \\ \sum_{i=1}^{\eta} \alpha_i \{ [\mathbf{w}^T \varphi(x_i) + b] + e_i - y_i \} = \\ \frac{1}{2} \mathbf{w}^T \mathbf{w} + \frac{\gamma}{2} \sum_{i=1}^{\eta} e_i^2 - \\ \sum_{i=1}^{\eta} \alpha_i \{ [\mathbf{w}^T \varphi(x_i) + b] + e_i - y_i \} \end{cases} \quad (4)$$

式中: $L(\mathbf{w}, b, e, \alpha)$ 为拉格朗日函数表达式; α 为拉格朗日乘子, $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_{\eta})^T$ 。

根据 Karush-Kuhn-Tucke(KKT) 优化条件, 满足如下约束

$$\begin{cases} \frac{\partial L}{\partial \mathbf{w}} = 0 \Rightarrow \mathbf{w} = \sum_{i=1}^{\eta} \alpha_i \varphi(x_i) \\ \frac{\partial L}{\partial b} = 0 \Rightarrow \sum_{i=1}^{\eta} \alpha_i = 0 \\ \frac{\partial L}{\partial e_i} = 0 \Rightarrow \alpha_i = \gamma e_i \\ \frac{\partial L}{\partial \alpha_i} = 0 \Rightarrow y_i = \mathbf{w}^T \varphi(x_i) + b + e_i \end{cases} \quad (5)$$

1.2 LSSVM 核函数类型

常用的核函数种类一般分为:

(1) 线性核函数 $K(x_i, x_j)$

$$K(x_i, x_j) = \gamma x_i x_j \quad (6)$$

(2) 多项式核函数 $K_P(x_i, x_j)$

$$K_P(x_i, x_j) = (1 + \gamma x_i x_j)^q \quad i, j \in \eta \quad (7)$$

式中: q 为 POLY 核函数的阶数参数。

(3) RBF 核函数(高斯核函数) $K_R(x_i, x_j)$

$$K_R(x_i, x_j) = e^{-\frac{\gamma \|x_i - x_j\|^2}{\sigma^2}} \quad (8)$$

式中: σ^2 为 RBF 核函数的核宽度参数。

(4) Sigmoid 核函数 $K_S(x_i, x_j)$

$$K_S(x_i, x_j) = \tanh(\gamma x_i x_j + c) \quad (9)$$

式中: c 为 Sigmoid 核函数的偏置参数。

由于 Mercer 核的非负线性组合仍是满足 Mercer 条件的核函数^[20]。因此, RBF 与 POLY 混合核函数 $K_{RP}(x_i, x_j)$ 可表示为

$$K_{RP}(x_i, x_j) = K_R(x_i, x_j) + K_P(x_i, x_j) \quad (10)$$

同理, RBF 与 Sigmoid 混合核函数 $K_{RS}(x_i, x_j)$ 可表示为

$$K_{RS}(x_i, x_j) = K_R(x_i, x_j) + K_S(x_i, x_j) \quad (11)$$

2 粒子群算法原理

粒子群算法随机生成 D 维搜索空间具有 m 个粒子的群落。粒子 μ 的位置表示为向量 $\mathbf{x}_{\mu} = (\chi_{\mu 1}, \chi_{\mu 2}, \dots, \chi_{\mu D})$, $\mu = 1, 2, \dots, m$ 。根据 \mathbf{x}_{μ} 可判断该位置是否合适, 也可使用 \mathbf{x}_{μ} 来计算适应度, 用函数 $\theta(\mathbf{x}_{\mu})$ 来表示。粒子以一定的速度 $\mathbf{v}_{\mu} = (v_{\mu 1}, v_{\mu 2}, \dots, v_{\mu D})$ 找到个体最优位置 $\mathbf{P}_{b_{\mu}} = (p_{\mu 1}, p_{\mu 2}, \dots, p_{\mu D})$ 和种群最优位置 $\mathbf{G}_b = (g_1, g_2, \dots, g_D)$ 。速度和位置更新如下

$$v_{\mu d}^{k+1} = \omega v_{\mu d}^k + c_1 r_1 (p_{\mu d}^k - \chi_{\mu d}^k) + c_2 r_2 (g_d^k - \chi_{\mu d}^k) \quad (12)$$

$$\chi_{\mu d}^{k+1} = \chi_{\mu d}^k + v_{\mu d}^k \quad (13)$$

式中: k 为迭代次数; d 为空间维度, $d = 1, 2, \dots, D$; $v_{\mu d}^{k+1}$ 、 $v_{\mu d}^k$ 分别为第 $k+1$ 次迭代、第 k 次迭代粒子 μ 的移动速度向量第 d 维分量; $\chi_{\mu d}^{k+1}$ 、 $\chi_{\mu d}^k$ 分别为第 $k+1$ 次迭代、第 k 次迭代粒子 μ 移动位置向量的第 d 维分量; $p_{\mu d}^k$ 为第 k 次迭代粒子 μ 经过最优位置的第 d 维分量; g_d^k 为第 k 次迭代种群最优位置的第 d 维分量; ω 为惯性权重; c_1 、 c_2 为学习因子; r_1 、 r_2 为 $(0, 1)$ 范围内的随机数。

3 预测流程

将 LSSVM 参数寻优与预测融合到 PSO 算法内, 其流程见图 1, 具体步骤如下。

步骤 1, 数据预处理。将前 3 d 每日最大断面客流量, 以及前 1 d 全日各断面客流量作为输入变量, 当天最大断面客流量作为输出变量, 对数据样本标准化处理。随机选取训练样本集(80% 的断面客流数据)和测试样本集(剩余 20% 的断面客流数据)。

步骤 2, PSO 算法的初始化。设置粒子群规模 m 初始值, 粒子位置 \mathbf{x}_{μ} 初始值, 粒子速度 \mathbf{v}_{μ} 初始值, 最大迭代次数 k_{\max} 初始值, 惯性权重 ω 以及学习因子 c_1 和 c_2 等初始值。

步骤 3, PSO 算法求最优解。首先, 定义适应度函数 $\theta(\chi_{\mu})$ 。其次, 将计算出的适应度值与历史 $P_{b_{\mu}}$ 比较, 对其进行更新。对每个粒子的 $P_{b_{\mu}}$, 用它的最大值与种群历史最优位置 G_b 比较, 对其进行更新。

步骤 4, PSO 算法更新速度和位置的公式。

步骤 5, PSO 算法终止。达到设定迭代次数 k_{\max} , 满足约束条件则退出。否则, 转入步骤 3 和 4。

步骤 6, LSSVM 模型构建与预测。估计 RBF 核函数的正则化参数 γ 和核宽度参数 σ^2 , 多项式核函数的正则化参数 γ 和多项式阶数参数 q , Sigmoid 核函数的正则化参数 γ 和偏置参数 c , 对当天最大断面客流量进行预测。

步骤 7, 预测结果还原。反量纲一化, 将 LSSVM 模型的预测值转换为实际预测值, 并将最大断面客流量实际预测值与观测值进行比较。

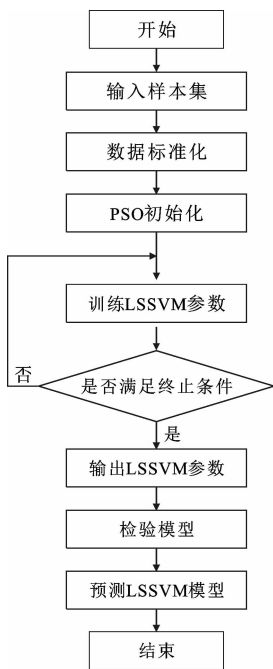


图 1 PSO-LSSVM 预测流程

Fig. 1 Prediction flow of PSO-LSSVM

4 试验仿真

4.1 数值算例及性能指标

4.1.1 数值算例

本文算例选取西安市轨道交通 2 号线, 轨道交通车站站间有 20 个断面, 其断面客流分为上行(北客站—韦曲南)和下行(韦曲南—北客站)2 个方向。观测到 2017 年 4~6 月份连续 3 个月 6:00~24:00 运营期内以 1 h 为单位 18 个时段的客流数据, 即每日有 720 个上行和下行观测值。所研究时段包含工

作日总计 61 d、周末总计 21 d 以及节假日总计 9 d。总样本量 65 520 个客流值, 包含工作日总计 43 920 个客流值、周末总计 15 120 个客流值以及节假日总计 6 480 个客流值。2017 年 4 月 18 日 8:00~9:00 的断面客流量数据如图 2 所示。对于非线性、周期性、随机波动性特征的断面客流数据, 可从历史观测到断面客流量数据推断出未来断面客流量。本研究采用将前 ρ 天内每日最大断面客流量, 以及前 1 d 全日各断面客流量作为输入变量, 而当天最大断面客流量作为输出变量。将全部数据样本量纲一化处理, 其抽象的数学表达式为

$$T = \begin{bmatrix} \kappa_{1,\beta+1}^{\max} & \kappa_{2,\beta+1}^{\max} & \cdots & \kappa_{\tau,\beta+1}^{\max} \\ \kappa_{1,\beta}^{\max} & \kappa_{2,\beta}^{\max} & \cdots & \kappa_{\tau,\beta}^{\max} \\ \kappa_{1,\beta-1}^{\max} & \kappa_{2,\beta-1}^{\max} & \cdots & \kappa_{\tau,\beta-1}^{\max} \\ \vdots & \vdots & \vdots & \vdots \\ \kappa_{1,\beta-S_c}^{\max} & \kappa_{2,\beta-S_c}^{\max} & \cdots & \kappa_{\tau,\beta-S_c}^{\max} \end{bmatrix} = \Psi(T) \quad (14)$$

式中: $\kappa_{1,\beta+1}^{\max}, \kappa_{2,\beta+1}^{\max}, \dots, \kappa_{\tau,\beta+1}^{\max}$ 分别为第 $\beta+1$ 天的 1, 2, \dots, τ 时段的最大断面客流时序数据; $\kappa_{1,\beta}^{\max}, \kappa_{2,\beta}^{\max}, \dots, \kappa_{\tau,\beta}^{\max}$ 分别为第 β 天的 1, 2, \dots, τ 时段的最大断面客流时序数据; $\kappa_{1,\beta-1}^{\max}, \kappa_{2,\beta-1}^{\max}, \dots, \kappa_{\tau,\beta-1}^{\max}$ 分别为第 $\beta-1$ 天的 1, 2, \dots, τ 时段的最大断面客流时序数据; $\kappa_{1,\beta-S_c}^{\max}, \kappa_{2,\beta-S_c}^{\max}, \dots, \kappa_{\tau,\beta-S_c}^{\max}$ 分别为第 $\beta-S_c$ 天的 1, 2, \dots, τ 时段的最大断面客流时序数据; S_c 为轨道交通 2 号线的断面编号, 取值 1, 2, $\dots, 20$; $\Psi(T)$ 为非线性函数。

4.1.2 性能指标

本文选取 3 个指标来综合评价断面客流量预测效果

$$R_{MSE} = \sqrt{\frac{\sum_{t=1}^{\zeta} (P_t - \hat{P}_t)^2}{\zeta}} \quad (15)$$

$$M_{APE} = \frac{1}{\zeta} \sum_{t=1}^{\zeta} \frac{|P_t - \hat{P}_t|}{P_t} \quad (16)$$

$$R^2 = 1 - \frac{\sum_{t=1}^{\zeta} (P_t - \hat{P}_t)^2}{\sum_{t=1}^{\zeta} (P_t - \bar{P})^2} \quad (17)$$

式中: R_{MSE} 为均方根误差; M_{APE} 为平均绝对百分比误差; R^2 为判定系数; P_t 为断面客流量的第 t 时段观测值; \hat{P}_t 为断面客流量的第 t 时段预测值; $t=1, 2, \dots, \zeta$, ζ 为时段总数。

R_{MSE} 和 M_{APE} 的预测结果越小, R^2 越接近 1, 表明回归效果越好。

4.2 算例结果

4.2.1 RBF 核函数的 PSO-LSSVM 优化

以工作日断面客流量为例, 将 RBF 核函数宽度




图 2 断面客流量数据

Fig. 2 Cross-section passenger flow data

参数 σ^2 初始化为 100,并设置此参数下界为 0,上界为 200。RBF 核函数正则化参数 γ 初始化为 100,并设置此参数下界为 0,上界为 200,预测结果如图 3 所示。表 1 为工作日、周末和节假日回归评价指标。由表 1 可知:训练集的断面客流量 PSO 未优化时,上行的 RBF 核参数的回归评价指标 R^2 为 0.973, R_{MSE} 为 834.322, M_{APE} 为 6.385%;下行时的 R^2 为 0.958, R_{MSE} 为 1 004.134, M_{APE} 为 7.847%。可见,PSO 未优化训练集的 M_{APE} 均大于 5.0%。

粒子群算法 k_{max} 设置为 100,全局逼近 RBF 核函数宽度参数 σ^2 和正则化参数 γ ,参数收敛情况如图 4 所示。可见,测试集的 R_{MSE} 显著降低了,这表明了 PSO 对 RBF 核参数的寻优是非常有效的。上行优化的最优核函数参数为正则化参数 γ 为 148.512,宽度参数 σ^2 为 17;下行正则化参数 γ 为 119.685,宽度参数 σ^2 为 6。

由表 1 可知:测试集的断面客流量 PSO 优化后,上行的 RBF 核参数的回归评价指标 R^2 为 0.988, R_{MSE} 为 598.290, M_{APE} 为 4.365%;下行时 R^2 为 0.982, R_{MSE} 为 704.051, M_{APE} 为 4.083%。PSO 优化后测试集的 M_{APE} 均小于 5.0%。对比 PSO 优化前和优化后的训练集与测试集的各项指标可以发现,粒子群算法优化后的指标均有较大改善,预测结




图 3 RBF 核预测结果

Fig. 3 Prediction results of RBF kernel

果如图 5 所示。PSO 优化 RBF 核函数参数后的上

表 1 工作日、周末和节假日回归评价指标								
Tab. 1 Regression evaluation indexes on weekdays, weekends and holidays								
研究时段	模型状态	核函数类型	上行评价指标			下行评价指标		
			R^2	R_{MSE}	$M_{APE}/\%$	R^2	R_{MSE}	$M_{APE}/\%$
工作日 训练集	未优化	RBF	0.973	834.322	6.385	0.958	1 004.134	7.847
		RBF+POLY	0.990	515.290	4.229	0.982	647.146	5.274
		RBF+Sigmoid	0.242	4 420.878	132.939	0.901	1 534.016	112.663
	PSO 优化	RBF	0.992	456.485	3.641	0.995	351.898	2.887
		RBF+POLY	0.994	390.020	3.152	0.983	637.319	4.995
		RBF+Sigmoid	0.994	406.649	3.272	0.983	631.601	4.913
工作日 测试集	未优化	RBF	0.980	778.027	5.692	0.951	1 160.179	7.648
		RBF+POLY	0.978	805.160	5.531	0.963	1 018.431	6.698
		RBF+Sigmoid	0.258	4 718.543	29.715	0.885	1 782.085	14.588
	PSO 优化	RBF	0.988	598.290	4.365	0.982	704.051	4.083
		RBF+POLY	0.989	579.606	4.181	0.973	867.498	5.441
		RBF+Sigmoid	0.989	569.976	4.086	0.971	903.927	5.262
周末测试集	PSO 优化	RBF	0.888	885.521	7.898	0.897	849.176	6.663
		RBF+POLY	0.887	886.387	7.628	0.897	848.381	6.834
		RBF+Sigmoid	0.885	895.853	7.960	0.900	832.206	6.982
节假日 测试集	PSO 优化	RBF	0.899	1 411.039	10.171	0.942	901.184	5.844
		RBF+POLY	0.922	1 237.069	16.492	0.958	764.115	5.912
		RBF+Sigmoid	0.904	1 376.920	9.938	0.948	850.620	5.327




图 4 PSO 寻优 RBF 参数收敛

Fig. 4 Convergence of RBF parameters optimized by PSO




图 5 PSO 寻优 RBF 核预测结果

Fig. 5 Prediction results of RBF kernel optimized by PSO

行和下行的预测值与真实值间的差距非常小,表明了 PSO-LSSVM 模型能够有效预测工作日断面客

流量的非线性波动关系。




图 6 RBF 与 POLY 混合核预测结果

Fig. 6 Prediction results of RBF+POLY mixed kernel

4. 2. 2 RBF 与 POLY 混合核函数的 PSO-LSSVM 优化

以工作日断面客流量为例,将 RBF 核函数宽度参数 σ^2 初始化为 100,并设置此参数下界为 0,上界为 200。RBF 核函数正则化参数 γ 初始化为 100,并设置此参数下界为 0,上界为 200。POLY 核函数正则化参数 γ 初始化为 1,并设置此参数下界为 1,上界为 5。POLY 核函数阶数参数 q 初始化为 2,并设置此参数下界为 1,上界为 5。预测结果如图 6 所示。由表 1 可知,训练集的断面客流量 PSO 未优化时,上行的 RBF 与 POLY 混合核参数的回归评价指标 R^2 为 0.990, R_{MSE} 为 515.290, M_{APE} 为 4.229%;下行时的 R^2 为 0.982, R_{MSE} 为 647.146, M_{APE} 为 5.274%。

粒子群算法 k_{max} 设置为 100,全局逼近 RBF 核函数宽度参数 σ^2 、RBF 核函数正则化参数 γ 、POLY 核函数正则化参数 γ 、POLY 核函数阶数参数 q ,参数收敛情况如图 7 所示。可见,测试集的 R_{MSE} 显著降低了,这表明了 PSO 对 RBF 与 POLY




图 7 PSO 寻优 RBF 与 POLY 混合核参数收敛

Fig. 7 Convergence of RBF+POLY mixed kernel parameters optimized by PSO

混合核参数的寻优是非常有效的。上行优化出来的最优核函数参数 RBF 核函数正则化参数 γ 为 131.581,RBF 核函数宽度参数 σ^2 为 10,POLY 核函数正则化参数 γ 为 4.996,POLY 核函数阶数参数 q 为 1。下行时 RBF 核函数正则化参数 γ 为 109.781,RBF 核函数宽度参数 σ^2 为 32,POLY 核函数正则化参数 γ 为 4.028,POLY 核函数阶数参数 q 为 1。

由表 1 可知:测试集的断面客流量 PSO 优化后,上行的 RBF 与 POLY 混合核参数的回归评价指标为: R^2 为 0.989, R_{MSE} 为 579.606, M_{APE} 为 4.181%;下行 R^2 为 0.973, R_{MSE} 为 867.498, M_{APE} 为 5.441%。可见,PSO 优化后上行的测试集的 M_{APE} 小于 5.0%。对比 PSO 优化前和优化后的训练集与测试集的各项指标可以发现,粒子群算法优化后的指标均有微小改善。预测结果如图 8 所示。可见,PSO 优化 RBF 与 POLY 核函数参数后的上行和下行的预测值与真实值间的差距非常小,表明了 PSO-LSSVM 模型能够有效预测工作日断面客流量的非线性波动关系。




图 8 PSO 寻优 RBF 与 POLY 混合核预测结果
Fig.8 Prediction results of RBF+POLY mixed kernel optimized by PSO

4.2.3 RBF 与 Sigmoid 混合核函数的 PSO-LSSVM 优化

以工作日断面客流量为例,将 RBF 核函数宽度参数 σ^2 初始化为 100,并设置此参数下界为 0,上界为 200。RBF 核函数正则化参数 γ 初始化为 100,并设置此参数下界为 0,上界为 200。Sigmoid 核函数正则化参数 γ 为 0.05,并设置此参数下界为 0.001,上界为 2。Sigmoid 核函数偏置参数 c 为 3,并设置此参数下界为 0,上界为 5。预测结果如图 9 所示。由表 1 可知:训练集的断面客流量 PSO 未优化时,上行的 RBF 与 Sigmoid 混合核参数的回归评价指标 R^2 为 0.242, R_{MSE} 为 4 420.878, M_{APE} 为 132.939%;下行时 R^2 为 0.901, R_{MSE} 为 1 534.016, M_{APE} 为 112.663%。可见,PSO 未优化训练集的 M_{APE} 均大于 5.0%。

粒子群算法 k_{max} 设置为 100,全局逼近 RBF 核函数宽度参数 σ^2 、RBF 核函数正则化参数 γ 、Sigmoid 核函数正则化参数 γ 、Sigmoid 核函数偏置参数 c ,参数收敛情况如图 10 所示。可见,测试集的 R_{MSE} 显著降低了,这表明了 PSO 对 RBF 与 Sigmoid




图 9 RBF 与 Sigmoid 混合核预测结果
Fig.9 Prediction results of RBF+Sigmoid mixed kernel

混合核参数的寻优是非常有效的。上行优化的最优核函数参数 RBF 核函数正则化参数 γ 为 96.615, RBF 核函数宽度参数 σ^2 为 10, Sigmoid 核函数正则化参数 γ 为 0.001, Sigmoid 核函数偏置参数 c 为 3.182;下行时 RBF 核函数正则化参数 γ 为 104.483, RBF 核函数宽度参数 σ^2 为 30, Sigmoid 核函数正则化参数 γ 为 0.001, Sigmoid 核函数偏置参数 c 为 2.793。

由表 1 可知:测试集的断面客流量 PSO 优化后,上行的 RBF 与 Sigmoid 混合核参数的回归评价指标 R^2 为 0.989, R_{MSE} 为 569.976, M_{APE} 为 4.086%;下行时的 R^2 为 0.971, R_{MSE} 为 903.927, M_{APE} 为 5.262%。可见,PSO 优化后上行的测试集的 M_{APE} 小于 5.0%。对比 PSO 优化前和优化后的训练集与测试集的各项指标可以发现,粒子群算法优化后的指标均有较大改善。预测结果如图 11 所示,可见 PSO 优化 RBF 与 Sigmoid 核函数参数后的上行和下行的预测值与真实值间的差距非常小,表明了 PSO-LSSVM 模型能够有效预测工作日断面客流量的非线性波动关系。




图 10 PSO 寻优 RBF 与 Sigmoid 混合核参数收敛
Fig. 10 Convergence of RBF+Sigmoid mixed kernel parameters optimized by PSO

4.2.4 RBF、RBF-POLY、RBF-Sigmoid 核函数的对比分析

PSO 寻优能够明显改善各核函数对断面客流的预测效果。由表 1、图 5、图 11 可知,PSO 优化后,上行的 RBF 与 Sigmoid 混合核对测试集的回归最优,此时回归评价指标 R^2 为 0.989, R_{MSE} 为 569.976, M_{APE} 为 4.086%,均优于其他 5 个模型。下行 RBF 核对测试集的回归最优,此时回归评价指标 R^2 为 0.982, R_{MSE} 为 704.051, M_{APE} 为 4.083%,均优于其他 5 个模型。工作日、周末和节假日各时段回归误差如图 12 所示。可见,工作日上行 RBF 与 Sigmoid 混合核以及工作日下行 RBF 核在工作日的 7:00~9:00 时段、11:00~13:00 时段以及 16:00~19:00 时段的误差较小,在工作日的 6:00~7:00 时段、13:00~14:00 时段、15:00~16:00 时段以及 19:00~23:00 时段的误差较大。6:00~7:00 时段和 19:00~23:00 时段的误差明显高于高峰时段的误差,这与工作日平峰时段的断面客流量真实值远小于高峰时段的断面客流量真实值有关。PSO-LSSVM 模型对工作日高峰期的断面客流量具有最优预

测效果。




图 11 PSO 寻优 RBF 与 Sigmoid 混合核预测结果
Fig. 11 Prediction results of RBF+Sigmoid mixed kernel optimized by PSO




图 12 工作日、周末和节假日各时段回归误差
Fig. 12 Regression errors in each phase on weekdays, weekends and holidays

4.2.5 周末和节假日的 PSO-LSSVM 优化

以周末断面客流量为例,由表 1 可知:测试集的断面客流量 PSO 优化后,上行的 RBF 与 POLY 混合核的回归评价指标 R^2 为 0.887, R_{MSE} 为 886.387, M_{APE} 为 7.628%。下行 RBF 核的评价指标 R^2 为 0.897, R_{MSE} 为 849.176, M_{APE} 为 6.663%。相比于表 1 中工作日断面客流量的 PSO 优化结果,PSO-LSSVM 模型对波动范围较大的周末断面客流量具有较一般预测效果。如图 12 所示,周末上行 RBF 与

POLY 混合核以及周末下行 RBF 核对断面客流量预测效果弱于工作日的预测效果。在周末的 9:00~19:00 时段的误差较小,在周末的 6:00~9:00 时段和 19:00~23:00 时段的误差较大,这表明了 PSO-LSSVM 模型对周末日间的断面客流量具有最优预测效果,对列车始发后 3 h 和收车前 4 h 的波动范围较大的断面客流量具有较一般的预测效果。

以节假日断面客流量为例,由于采集到节假日样本数据较少,如表 1 所示,测试集的断面客流量 PSO 优化后,上行的 RBF 与 Sigmoid 混合核的回归评价指标 R^2 为 0.904, R_{MSE} 为 1 376.920, M_{APE} 为 9.938%;下行时 R^2 为 0.948, R_{MSE} 为 850.620, M_{APE} 为 5.327%。相比于表 1 中工作日断面客流量的 PSO 优化结果,PSO-LSSVM 模型对波动范围较大的节假日断面客流量具有较一般的预测效果。节假日上行的 RBF 核、RBF 与 POLY 混合核以及 RBF 与 Sigmoid 混合核 M_{APE} 值大于节假日下行时,这表明了节假日期间上行和下行 2 个方向的最大断面客流量不均系数高。图 12 为工作日、周末和节假日各时段回归误差。可见,节假日上行 RBF 与 Sigmoid 混合核对断面客流量预测效果弱于工作日时,但节假日下行 RBF 与 Sigmoid 混合核对断面客流量预测效果在部分时段优于工作日时。在节假日的 9:00~17:00 时段的误差相对较小,在节假日上行的 6:00~9:00 时段和 17:00~23:00 时段的误差相对较大,这表明了 PSO-LSSVM 模型对节假日日间的断面客流量具有最优预测效果,对列车始发后 3 h 和收车前 6 h 的波动范围较大的断面客流量具有一般的预测效果。

5 结 语

(1)本文以西安市轨道交通客流为例,选取具有非线性、周期性、随机波动性特征的断面客流数据,划分研究时段为工作日、周末和节假日,构建 LSSVM 最优核函数参数模型。利用粒子群算法寻找不同核函数的最优参数值,并将不同模型的预测效果回归评价指标对比分析。

(2)以工作日断面客流量为例,粒子群算法寻优后各参数的客流量预测效果均有所改善。PSO 优化后,上行的 RBF 与 Sigmoid 混合核对断面客流量具有最优预测效果;下行的 RBF 核对断面客流量具有最优预测效果。以周末断面客流量为例,上行的 RBF 与 POLY 混合核对断面客流量具有较好预测效果;下行 RBF 核对断面客流量具有较好预测效果。以节假日断面客流量为例,上行的 RBF 与 Sig-

moid 混合核对断面客流量具有较好预测效果;下行的 RBF 与 Sigmoid 混合核对断面客流量具有较好预测效果。

(3)土地利用、社会经济、天气、特殊事件等因素对轨道交通客流的复杂变化具有重要影响。后续,需要收集更多数据改进模型,从而提高对环境 and 异常事件变化迅速响应能力。针对断面客流波动范围较大的周末和节假日的预测误差较大问题,以及工作日个别时段的预测误差较大问题,未来需提出其他方法优化 PSO-LSSVM 模型,从而准确预测短期客流变化趋势。此外,深度学习、小波理论、模糊信息粒化等模型在轨道交通断面客流量预测的应用有待进一步验证。

参考文献:

References:

- [1] 中华人民共和国交通运输部. 2020 年城市轨道交通运营数据发布[EB/OL]. (2021-01-06)[2021-06-10]. https://www.mot.gov.cn/jiaotongyaowen/202101/t20210106_3512388.html
Ministry of Transport of the People's Republic of China. Release of urban rail transit operation data in 2020[EB/OL]. (2021-01-06)[2021-06-10]. https://www.mot.gov.cn/jiaotongyaowen/202101/t20210106_3512388.html
- [2] GUO J Y, XIE Z, QIN Y, et al. Short-term abnormal passenger flow prediction based on the fusion of SVR and LSTM[J]. IEEE Access, 2019, 7: 42946-42955.
- [3] TANG L Y, ZHAO Y, CABRERA J, et al. Forecasting short-term passenger flow: An empirical study on Shenzhen metro[J]. IEEE Transactions on Intelligent Transportation Systems, 2019, 20(10): 3613-3622.
- [4] LI W, SUIL Y, ZHOU M, et al. Short-term passenger flow forecast for urban rail transit based on multi-source data[J]. EURASIP Journal on Wireless Communications and Networking, 2021(1): 1-13.
- [5] 张 佳. 城市轨道交通初期客流时空演变及影响因素研究:以西安市为例[D]. 西安:长安大学, 2017.
ZHANG Jia. Study of the initial passenger flow evolution and its influential factors in urban rail transit — Take Xi'an as an example[D]. Xi'an: Chang'an University, 2017.
- [6] LI L C, WANG Y G, ZHONG G, et al. Short-to-medium term passenger flow forecasting for metro stations using a hybrid model[J]. KSCE Journal of Civil Engineering, 2018, 22(5): 1937-1945.
- [7] 潘 杰, 马超群. 基于改进灰色马尔科夫模型的地铁客流预测[J]. 交通科技与经济, 2018, 20(6): 52-56, 69.

- PAN Jie, MA Chao-qun. Passenger flow forecast based on improved grey Markov model[J]. Technology & Economy in Areas of Communications, 2018, 20(6): 52-56, 69.
- [8] 张和杰, 马维华. 基于时空特征的地铁客流预测[J]. 计算机科学, 2019, 46(7): 292-299.
- ZHANG He-jie, MA Wei-hua. Subway passenger flow forecasting model based on temporal and spatial characteristics[J]. Computer Science, 2019, 46(7): 292-299.
- [9] 李捷. 基于深度学习的地铁短时客流量预测研究[D]. 成都: 西南交通大学, 2018.
- LI Jie. Study on metro short-term passenger flow forecasting based on deep learning [D]. Chengdu: Southwest Jiaotong University, 2018.
- [10] 赵丽琴. 混合核支持向量机在地铁客流预测中的应用研究[D]. 兰州: 兰州交通大学, 2015.
- ZHAO Li-qin. Application and research on prediction of subway passenger flow using mixed kernel support vector machine [D]. Lanzhou: Lanzhou Jiaotong University, 2015.
- [11] 武创. 基于 BP 神经网络的重庆市轨道交通客流预测分析: 以三号线观音桥站为例[D]. 成都: 西南交通大学, 2018.
- WU Chuang. Forecast and analysis of Chongqing rail transit passenger flow based on BP neural network—Taking Guanyinqiao Station on Line Three as an example [D]. Chengdu: Southwest Jiaotong University, 2018.
- [12] SUN Y X, LENG B, GUAN W. A novel wavelet-SVM short-time passenger flow prediction in Beijing subway system[J]. Neurocomputing, 2015, 166: 109-121.
- [13] LI D W, ZHANG C, CAO J M. Short-term passenger flow prediction of a passageway in a subway station using time space correlations between multi sites[J]. IEEE Access, 2020, 8: 72471-72484.
- [14] 周思源. 城市轨道交通基于时空相关性分析的短时客流预测及行车组织研究[D]. 西安: 长安大学, 2018.
- ZHOU Si-yuan. Short time prediction and traffic organization research of urban rail transit based on spatio-temporal correlation analysis [D]. Xi'an: Chang'an University, 2018.
- [15] 卢天伟, 姚恩建, 刘莎莎, 等. 城轨新线客流成长期进出站量短时预测研究[J]. 铁道学报, 2020, 42(5): 19-28.
- LU Tian-wei, YAO En-jian, LIU Sha-sha, et al. Short-time forecast of entrance and exit passenger flow for new line of urban rail transit during growth period [J]. Journal of the China Railway Society, 2020, 42(5): 19-28.
- [16] LIU Y, LIU Z Y, JIA R. Deep PF: A deep learning based architecture for metro passenger flow prediction [J]. Transportation Research Part C, 2019, 101: 18-34.
- [17] 赵阳阳, 夏亮, 江欣国. 基于经验模态分解与长短期记忆神经网络的短时地铁客流预测模型[J]. 交通运输工程学报, 2020, 20(4): 194-204.
- ZHAO Yang-yang, XIA Liang, JIANG Xin-guo. Short-term metro passenger flow prediction based on EMD-LSTM[J]. Journal of Traffic and Transportation Engineering, 2020, 20(4): 194-204.
- [18] 周家中, 张殿业. 基于空间加权的 LS-SVM 城市轨道交通车站客流量预测[J]. 铁道学报, 2014, 36(1): 1-7.
- ZHOU Jia-zhong, ZHANG Dian-ye. Direct ridership forecast model of urban rail transit stations based on spatial weighted LS-SVM [J]. Journal of the China Railway Society, 2014, 36(1): 1-7.
- [19] LIU S S, YAO E J. Holiday passenger flow forecasting based on the modified least-square support vector machine for the metro system [J]. Journal of Transportation Engineering, 2017, 143(2): 04016005.
- [20] 耿立艳, 陈丽华. 基于 FOA 优化混合核 LSSVM 的铁路货运量预测[J]. 计算机应用研究, 2017, 34(2): 409-412.
- GENG Li-yan, CHEN Li-hua. Forecast on railway traffic volume using mixed-kernel LSSVM optimized by FOA [J]. Application Research of Computers, 2017, 34(2): 409-412.
- [21] TANG M A, ZHANG K, LIU X. Combination forecast for urban rail transit passenger flow based on fuzzy information granulation and CPSO-LSSVM [J]. Journal of Measurement Science and Instrumentation, 2018, 9(1): 32-41.
- [22] ZHU K E, XUN P, LI W, et al. Prediction of passenger flow in urban rail transit based on big data analysis and deep learning [J]. IEEE Access, 2019, 7: 142272-142279.
- [23] 郭文, 肖为周, 秦菲菲. 基于支持向量机模型的地铁进站客流量预测[J]. 河北工业科技, 2019, 36(1): 31-35.
- GUO Wen, XIAO Wei-zhou, QIN Fei-fei. Prediction of subway entry flow based on support vector machine model [J]. Hebei Journal of Industrial Science and Technology, 2019, 36(1): 31-35.
- [24] 胡小敏, 贺园园. 基于组合模型的铁路客运量预测[J]. 微型电脑应用, 2017, 33(12): 67-70.
- HU Xiao-min, HE Yuan-yuan. Railway passenger volume prediction based on hybrid model [J]. Microcomputer Applications, 2017, 33(12): 67-70.
- [25] SUYKENS J A K, VAN DE WALLE J. Least squares support vector machine classifiers [J]. Neural Processing Letters, 1999, 9(3): 293-300.