



DOI:10.12404/j.issn.1671-1815.2403792

引用格式:牛兆吉,李德仓,胥如迅,等.基于 SABO-LSTM 的高铁沿线短期风速预测方法[J].科学技术与工程,2025,25(9):3880-3887.

Niu Zhaoji, Li Decang, Xu Ruxun, et al. Short-term wind speed prediction method along high-speed railway based on SABO-LSTM[J]. Science Technology and Engineering, 2025, 25(9): 3880-3887.

交通运输

基于 SABO-LSTM 的高铁沿线短期风速预测方法

牛兆吉¹, 李德仓^{1,2,3*}, 胥如迅^{1,2,3}, 陈晓强^{1,2,3}

(1. 兰州交通大学机电技术研究所, 兰州 730070; 2 甘肃省物流及运输装备信息化工程技术研究中心, 兰州 730070;

3. 甘肃省物流与运输装备行业技术中心, 兰州 730070)

摘要 准确的高铁沿线风速预测是铁路灾害预警系统的基础需求,为了提升应对和处理强风灾害致突发事件的能力,提出一种基于减法平均优化(subtraction average based optimizer, SABO)算法优化长短时记忆(long short-term memory, LSTM)神经网络的高铁沿线短期风速预测方法。首先,针对风速非线性和非平稳特性,采用极小化极大(min-max, MM)方法对风速数据进行归一化处理;其次,采用 SABO 算法中的“-v”方法对 LSTM 模型的关键参数搜索寻优,并构建风速预测模型;最后,以中国宝兰高铁沿线风速采集点采集的实测风速数据为例,对模型进行有效性检验。实验结果表明:SABO 算法的寻优效果更加良好,预测精度更高,所建模型的平均绝对误差(mean absolute error, MAE)、平均绝对百分比误差(mean absolute percentage error, MAPE)和均方根误差(route mean square error, RMSE)分别仅为 11.96%、1.23% 和 16.47%,决定系数(r -square, R^2)为 0.995。与其他模型相比,通过 SABO 算法优化后的 LSTM 神经网络在短期风速预测上具有较好的拟合效果和更高的预测精度,可为高铁沿线大风预测预警提供一种新的方法和思路。

关键词 高铁; 风速预测; 减法平均优化算法; 长短时记忆神经网络

中图分类号 U298.12 TP301.6; **文献标志码** A

Short-term Wind Speed Prediction Method along High-speed Railway Based on SABO-LSTM

NIU Zhao-ji¹, LI De-cang^{1,2,3*}, XU Ru-xun^{1,2,3}, CHEN Xiao-qiang^{1,2,3}

(1. Mechatronics T & R Institute, Lanzhou Jiaotong University, Lanzhou 730070, China;

2. Gansu Provincial Engineering Technology Center for Information of Logistics & Transport Equipment, Lanzhou 730070, China;

3. Gansu Provincial Industry Technology Center of Logistics & Transport Equipment, Lanzhou 730070, China)

[Abstract] Accurate prediction of wind speed along high-speed rail lines is a fundamental requirement for railway disaster warning systems. To enhance the capability to respond to and handle sudden events caused by strong winds, a short-term wind speed prediction method based on the subtraction average based optimizer (SABO) algorithm optimized long short-term memory (LSTM) neural network was proposed. Firstly, considering the nonlinearity and non-stationarity of wind speed, the min-max (MM) method was used to normalize the wind speed data. Secondly, the “-v” method in the SABO algorithm was employed to search and optimize the key parameters of the LSTM model, constructing a wind speed prediction model. Finally, the effectiveness of the model was tested using measured wind speed data collected from wind speed collection points along the Baoji-Lanzhou high-speed railway in China. Experimental results show that the SABO algorithm's optimization effect is better, and the prediction accuracy is higher. The average absolute error (MAE), mean absolute percentage error (MAPE), and root mean square error (RMSE) of the constructed model are 11.96%, 1.23%, and 16.47%, respectively, with a coefficient of determination (R^2) of 0.995. Compared to other models, the LSTM neural network optimized by the SABO algorithm exhibits better fitting performance and higher prediction accuracy in short-term wind speed prediction, providing a new method and approach for wind prediction and warning along high-speed railway.

[Keywords] high-speed railway; wind speed prediction; subtraction average based optimizer (SABO); long short-term memory (LSTM) neural networks

收稿日期: 2024-05-22 修订日期: 2024-12-29

基金项目: 国家自然科学基金(72061021, 62063013); 甘肃省科技计划(21JR7RA284)

第一作者: 牛兆吉(2000—), 男, 汉族, 甘肃会宁人, 硕士研究生。研究方向: 铁路沿线风速监测与预测。E-mail: 1113948246@qq.com。

* 通信作者: 李德仓(1976—), 男, 汉族, 甘肃白银人, 博士, 副教授。研究方向: 机电装备与测控技术。E-mail: lidecang1978@163.com。

截至 2023 年底,“八纵八横”高铁网主通道已建成 3.61 万 km,到 2030 年基本形成覆盖广泛、安全高效的“八纵八横”铁路网络。随着高铁网规模不断扩大和列车运行环境逐渐复杂发展趋势,强风、地震和泥石流等自然灾害对列车运行造成严重威胁。中国地域广阔,地质情况复杂,气候多变,是全球自然灾害最为严重的国家之一。其中,强风是影响铁路运输安全性和稳定性的主要自然灾害之一,强风灾害占全国铁路灾害的 13.35%^[1-2],轻则造成列车晚点、乘客滞留;重则造成铁路交通安全事故,带来巨大的经济损失、人身伤亡。为了确保强风环境下能够高效、安全地完成运输生产任务,国内外许多机构和学者研发高铁强风智能预警系统。而准确的风速预测是预警系统的基础和核心,因此,开展风速预测方法的研究对于列车智能驾驶和智能调度决策在未来实际应用方面具有积极的理论意义和重要的实践意义。

近年来,风速预测研究受到国内外相关专家及学者的日益重视。传统基于统计学的风速预测方法主要包括自回归模型和时间序列法等。其中,Wang 等^[3]根据历史风电数据建立自回归滑动平均(auto regressive moving average, ARMA)模型,基于聚类理论对风速预测开展研究,虽然该方法简单,且实时性较好,但可能会导致过度拟合;Kumar 等^[4]采用时间序列法研究了风速的短期预测,取得了较好的预测结果,但是没有综合考虑风速非线性趋势特征及模型参数对预测精度的影响。随着人工智能技术的飞速发展,机器学习和深度学习在处理非线性和非平稳数据方面具有良好的预测精度,例如,反向传播神经网络(back propagation neural networks, BPNN)、循环神经网络(recurrent neural networks, RNN)、长短时记忆(long short-term memory, LSTM)等^[5-7]。因此,人工智能算法在铁路风速预测领域得到了青睐,Wang 等^[8]利用 LSTM 检测风速的长期和短期记忆特征,对每个特征子信号建立合适的预测模型,并通过对 3 个区域风速数据的模拟,验证了 LSTM 在捕捉风速波动的长期和短期记忆特征方面具有良好的性能;李冰等^[9]提出了一种基于 LSTM 神经网络的短期风速预测方法,以历史数据作为输入,建立短期风速预测模型并进行训练,实现提前一步短期风速预测。虽然 LSTM 具有良好的预测性能,但是其仍然存在参数设置难确定、模型训练时间长等缺陷。在模型参数设置中,隐含层数和隐含层神经元数直接决定模型的拟合能力,学习率和迭代次数影响模型的训练过程和效果^[10],在实际应用过程中,这些参数都是靠人为经验设置,具有

较大的不确定性,且预测精度较一般。现通过采用各种优化算法优化 LSTM 的各项超参数来提高模型的整体性能,提升预测的准确性。

许多学者提出使用智能算法充当优化器优化 LSTM 的输入参数,受小生境技术的启发,有学者提出了多群体策略,以保持种群的多样性,这对于寻优效果至关重要^[11]。乔建刚等^[12]采用动态调整惯性权重和学习权重对不同类型的粒子进行更新,提高种群多样性,增强了粒子的寻优效果,从而优化了 LSTM 的输入参数,有效预测了高速公路交通流量,表明对智能优化算法种群多样性的增强会有效提高算法性能,但该算法未考虑到算法陷入局部最优问题;凌晓等^[13]采用 Logistics 混沌映射提升萤火虫算法(firefly algorithm, FA)初始种群的多样性,并加入线性递减惯性权重帮助算法跳出局部最优,取得了较好预测效果。Houran 等^[14]采用长鼻浣熊优化算法(coati optimization algorithm, COA)优化 LSTM 中的超参数,显著提升了模型在电力预测中的性能。上述研究均采用智能优化算法来提升种群多样性以提高预测精度。

综上所述,虽然 LSTM 在处理非线性、非平稳性信号方面具有显著优势,但是, LSTM 的参数设置需要人为靠经验来确定,预测精度较差。传统的群智能优化算法仍存在问题,如初始参数设置较多,容易陷入局部最优解。基于此,现提出一种基于 SABO-LSTM 的高铁沿线短期风速预测方法。采用 Min-max 方法对风速数据进行归一化处理,并创新性地将减法平均优化(subtraction average based optimizer, SABO)算法^[15]应用于优化 LSTM 参数设置,避免因人为设定参数而引发过拟合问题;通过使用减法平均值来更新种群位置,增强算法的全局探索能力,减少对特定种群成员的依赖,提升模型收敛速度和避免局部最优,从而实现高铁沿线更精确的风速预测结果。

1 基础理论

1.1 LSTM 模型

LSTM 网络是 RNN 的一种特殊类型,能够解决 RNN 梯度爆炸或梯度消失的问题,可学习长期依赖信息,非常适合对时间序列进行分类和预测^[16],其网络单元及扩展结构如图 1 所示。

相较传统 RNN 的循环连接结构,LSTM 引入记忆单元(memory cell, MC)结构用来记忆以往的信息,LSTM 网络的关键是单元状态 C_t ,可被看作是网络内部的信息传递管道,通过“门”结构可以添加或删除单元状态信息,而门结构具体包括输入门、遗忘门和输出门^[17]。




图1 LSTM 单元结构图和扩展图

Fig. 1 LSTM unit structure and expansion

(1) 输入门。输入门通过 sigmoid 函数层和 tanh 函数层的协同作用,确定新信息将被存储到单元状态中。其中, sigmoid 函数层负责确定新信息的选择度,而 tanh 函数层负责产生一个代表所学习到新信息的候选值 \tilde{C}_t [18]。输入风速数据 $x(n)_t$ 在输入门中的计算过程如式(1)~式(3)所示。

$$i_t = \sigma[W_i x(n)_t + W_i h_{t-1} + b_i] \quad (1)$$

$$\tilde{C}_t = \tanh[W_c x(n)_t + W_c h_{t-1} + b_c] \quad (2)$$

$$\tanh[x(n)_t] = [1 - e^{-x(n)_t}] / [1 + e^{-x(n)_t}] \quad (3)$$

式中: W_i 、 b_i 分别为输入门 sigmoid 函数层对应的权重矩阵与偏置项; W_c 、 b_c 分别为输入门 tanh 函数层对应的权重矩阵与偏置项。

(2) 遗忘门。遗忘门决定了需要从单元状态中丢弃的信息,其允许 LSTM 模型从先前的记忆中选择性地清除不必要的信息,以便让新的信息能够更好地影响模型的决策。遗忘门 f_t 和激活函数 σ 的计算如式(4)和式(5)所示。

$$f_t = \sigma[W_f x(n)_t + W_f h_{t-1} + b_f] \quad (4)$$

$$\sigma[x(n)_t] = 1 / [1 + e^{-x(n)_t}] \quad (5)$$

式中: W_f 、 b_f 分别为遗忘门的权重矩阵与偏置矩阵; σ 为 sigmoid 函数。

同时,利用遗忘门和输入门的输出、上一时刻的单元状态以及 tanh 函数层产生的候选值向量,可以更新单元状态。单元状态 C_t 更新公式如式(6)所示。

$$C_t = i_t \tilde{C}_t + f_t C_{t-1} \quad (6)$$

(3) 输出门。输出门通过 sigmoid 函数确定基于当前时间步的单元状态和输入而产生的输出,并且通过双曲正切函数 tanh 对该状态进行调整。输出门 o_t 和隐藏状态 h_t 的计算如式(7)和式(8)所示。

$$o_t = \sigma[W_o x(n)_t + W_o h_{t-1} + b_o] \quad (7)$$

$$h_t = o_t \tanh C_t \quad (8)$$

式中: W_o 、 b_o 分别为输出门的权重矩阵和偏置量。

1.2 SABO 算法

SABO 算法是一种基于数学的元启发式算法,其设计灵感来源于数学概念,如平均值、搜索代理

的位置差异、目标函数值的差异符号。

该算法通过使用个体的减法平均值来更新群体成员在搜索空间中的位置,具有寻优能力强,收敛速度快等特点。SABO 计算算数平均值的概念是完全独特的,因为它是基于一种特殊运算“ $-v$ ”,称为搜索代理 B 与搜索代理 A 的“ $-v$ ”,其计算公式如式(9)所示。

$$A -_v B = \text{sign}[F(A) - F(B)] (A - v * B) \quad (9)$$

式(9)中: v 为 m 维向量,其中的分量为集合 $\{1, 2\}$ 中生成的随机数; $*$ 表示两个向量的 Hadamard 乘积(即结果向量的所有分量都是由给定两个向量的相应分量相乘形成); $F(A)$ 、 $F(B)$ 分别为搜索代理 A 和搜索代理 B 对应的目标函数值; sign 表示 signum 的函数。

搜索代理 X_i 在搜索空间中的位移是由搜索代理 X_j 与 X_i 进行“ $-v$ ”运算后的算数平均值计算得到($i, j = 1, 2, \dots, N$),其计算公式如式(10)所示。

$$X_i^{\text{new}} = X_i + r_i * \frac{1}{N} \sum_{j=1}^N (X_i -_v X_j) \quad (10)$$

式(10)中: X_i^{new} 为第 i 个搜索代理 X_i 更新后的位置($i = 1, 2, \dots, N$); N 为粒子的总数; r_i 为 m 维向量。

更新后的新位置 X_i^{new} 能够使目标函数的值得到提高,则可作为相应代理的新位置,粒子位置替换公式如式(11)所示。

$$X_i = \begin{cases} X_i^{\text{new}}, & F_i^{\text{new}} < F_i \\ X_i, & \text{其他} \end{cases} \quad (11)$$

式(11)中: F_i 、 X_i^{new} 分别为搜索代理 X_i 和 X_i^{new} 的目标函数值。

由式(10)可得, $X_i -_v X_j$ 表示为一个矢量 χ_{ij} , 可以看作是搜索代理 X_i 的运动方程,因此,原方程可改写为 $X_i^{\text{new}} = X_i + r_i * M_i$ 的形式。其中,平均向量 M_i 可由式(12)计算得到。

$$M_i = \frac{1}{N} \sum_{j=1}^N \chi_{ij} \quad (12)$$

基于“ $-v$ 运算”算数平均值的搜索机制,其本质属性是既实现了探索阶段,又实现了开发阶段,在搜索空间中对有希望的领域进行探索。探索阶段通过“ $-v$ 运算”(即矢量 χ_{ij})实现,如图 2(a) 所示;开发阶段通过“ $-v$ 运算”后取算数平均值(即矢量 M_i)实现,如图 2(b) 所示。

2 模型构建

2.1 SABO-LSTM 风速预测模型

基于所述基础理论和 MATLAB 仿真平台,结合 SABO 算法实现了一种改进的 SABO-LSTM 算法。考




图2 SABO的数学模型

Fig. 2 Mathematical model of SABO

考虑到 LSTM 神经网络的超参数对于预测结果具有显著影响,故采用减法平均优化算法对 LSTM 的隐藏层节点数、学习率、迭代次数等参数进行自动搜索寻优。结合文献[11]构建预测模型,流程如图3所示,具体步骤如下。

步骤1 确定 LSTM 网络结构,初始化网络参数。

步骤2 设定 SABO 算法寻优迭代次数 T 、种群个数 N ,优化 LSTM 网络中的超参数用于风速预测。

步骤3 采用适用度函数来确定种群中的全局最优粒子位置 G_{best} 和局部最优粒子位置 P_{best} ,选取最优个体。

步骤4 根据 SABO 算法的式(10)、式(11)对最优个体进行二次搜索。

步骤5 比较 $fit(nG_{best})$ 和 $fit(G_{best})$,若当前粒子的适应度值小于最佳适应度值,则选取全局最优解,否则返回上一步继续进行迭代。

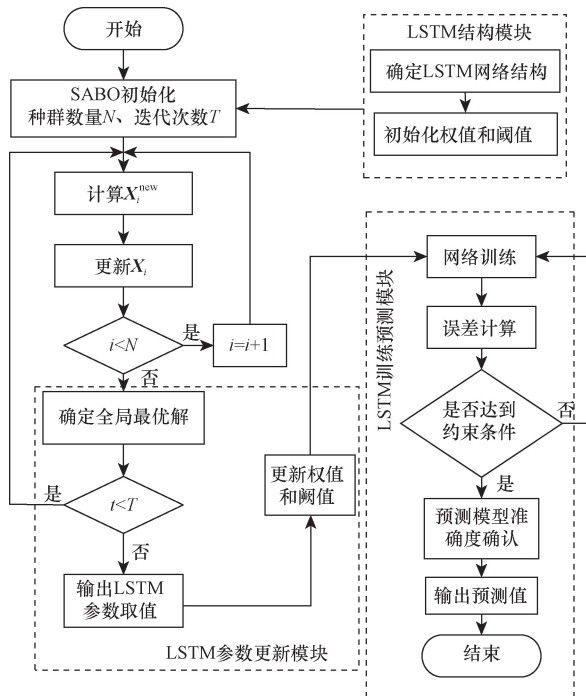


图3 SABO-LSTM 算法流程图

Fig. 3 Flowchart of the SABO-LSTM algorithm

步骤6 利用最优超参数构建 LSTM 模型,得到基于 SABO-LSTM 的风速预测模型,将历史风速数据输入该模型即可得到风速预测结果。

2.2 预测结果评价标准

将测试集预测结果进行量化评价,用平均绝对误差(mean absolute error, MAE)、平均绝对百分比误差(mean absolute percentage error, MAPE)和均方根误差(route mean square error, RMSE)作为精度的评估指标,拟合优度(r -square, R^2)作为拟合程度的评价指标^[19]。

$$MAE = \frac{1}{n} \sum_{i=1}^n |f(x_i) - y_i| \quad (13)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|f(x_i) - y_i|}{f(x_i)} \times 100\% \quad (14)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n [f(x_i) - y_i]^2}{n}} \quad (15)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n [f(x_i) - \bar{y}]^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (16)$$

式中: $f(x_i)$ 和 y_i 分别为第 i 个节点的风速预测值和实际值; \bar{y} 为风速实际值的平均值; n 为总的风速数据值。

3 实验及分析

3.1 SABO 性能测试

为验证 SABO 算法的性能,利用经典测试函数分析其迭代次数、平均值和标准差等,选取3个常用的经典测试函数如表1所示。单峰测试函数能够更容易地评估优化算法的性能、收敛速度和精度;多峰测试函数则可以更好地衡量算法的鲁棒性和泛化能力。

为证明所提算法的有效性,选取粒子群优化(particle swarm optimization, PSO)算法、灰狼优化

表1 测试函数

Table 1 Test function

函数公式	定义域	最优值
$F_1(x) = \sum_{i=1}^n x_i^2$	$[-100, 100]$	0
$F_2(x) = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i $	$[-10, 10]$	0
$F_3(x) = 20 \exp\left(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}\right) - \exp\left[\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i)\right] + 20 + e$	$[-32, 32]$	0

注: $F_1 \sim F_2$ 为单峰测试函数; F_3 为多峰测试函数^[20]。

(grey wolf optimization, GWO)算法、鲸鱼优化算法 (whale optimization algorithm, WOA) 等算法进行对比。每种算法的初始种群数量为 30, 最大迭代次数均为 500。采用平均值和标准差作为评估指标, 反映算法的收敛精度和稳定性。实验结果如表 2 所示。从表 2 可知, SABO 相较于其他 3 种对比算法在收敛精度和收敛速度方面有明显提升, 且平均值和标准差也相对较好, 表明在每一次运行中都能在迭代 500 次内取得最优结果, 算法具有更好的稳定性。各函数三维模型及算法收敛曲线如图 4 所示^[20]。


3.2 实验结果与分析

实验选取宝兰高铁沿线风速采集点采集的风速


表 2 测试函数验证结果

Table 2 Validate the results of the test function


函数	算法	平均值	标准差
F_1	PSO	299.10	201.71
	GWO	1.02×10^{-27}	1.67×10^{-27}
	WOA	1.15×10^{-74}	2.58×10^{-74}
	SABO	1.75×10^{-198}	0
F_2	PSO	20.35	5.22
	GWO	4.94×10^{-17}	3.02×10^{-17}
	WOA	8.77×10^{-51}	9.52×10^{-51}
	SABO	2.36×10^{-111}	1.29×10^{-111}
F_3	PSO	5.98	0.83
	GWO	1.12×10^{-13}	2.40×10^{-14}
	WOA	5.86×10^{-15}	1.95×10^{-15}
	SABO	4.44×10^{-15}	0



(a) 函数 F_1 三维模型及收敛曲线



(b) 函数 F_2 三维模型及收敛曲线



(c) 函数 F_3 三维模型及收敛曲线

图 4 各函数三维模型及收敛曲线

Fig. 4 Three-dimensional model of each function and convergence curve

数据共计 1 000 组,其中前 70% 作为训练数据,后 30% 作为测试数据。模型训练过程中,采用 Adam 优化器进行优化、迭代次数设置为 2 500,初始学习率设置为 0.02。在 350 轮训练后乘以下降因子 0.2 降低学习率,提高网络的训练速度和预测精度。为

了比较和验证所建立模型的预测精度,建立 4 种对比模型: SABO-LSTM、 PSO-LSTM、 GWO-LSTM、 WOA-LSTM,针对不同模型的预测值和实际值进行对比分析,并对不同算法的预测结果对比,结果如图 5、图 6 所示。

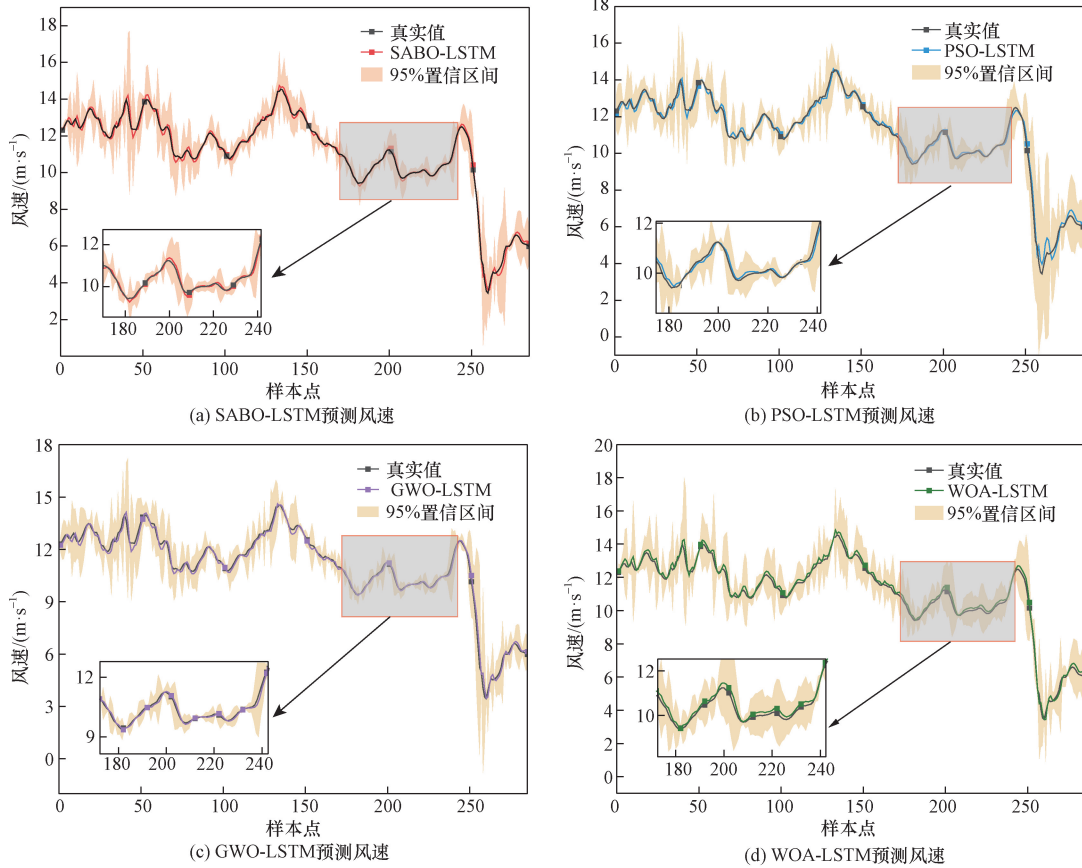


图 5 各模型预测曲线

Fig. 5 Comparison of prediction curves of each model

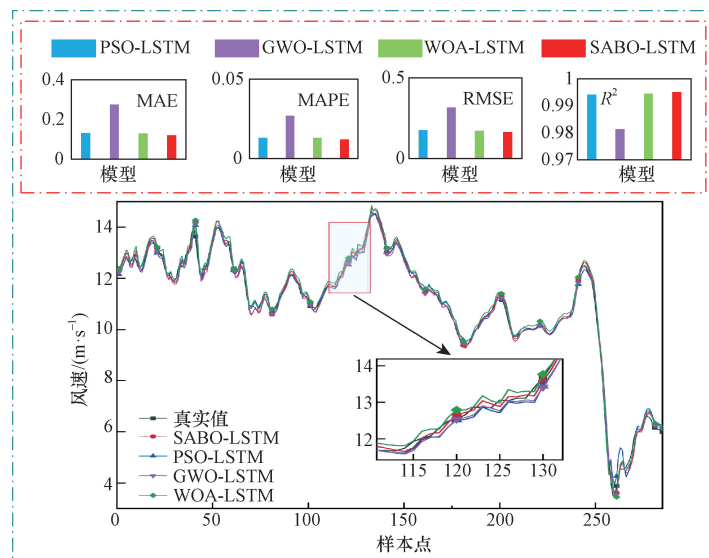


图 6 各模型预测结果对比

Fig. 6 Comparison of prediction results of each model

由图 5 和图 6 可得出,相较于其他 3 种模型,采用 SABO-LSTM 模型预测的结果曲线相对较平稳,所得的风速拟合效果明显优于其他算法预测结果。同时,为了凸显所提方法的优越性,将不同模型在测试集上的预测误差进行对比,具体结果如表 3 所示。

由表 3 可知,较 PSO-LSTM、GWO-LSTM、WOA-LSTM,所构建的 SABO-LSTM 预测模型的 MAE、RMSE、MAPE、 R^2 分别为:0.119 6 m/s、0.164 7 m/s、1.231 6%、0.995 0,具有较小的 MAE、RMSE、MAPE。MAE 从 0.132 3 减小到了 0.119 6;相对于其他 3 种模型,SABO-LSTM 模型在 MAPE 方面有了一定程度的降低; R^2 (决定系数)也有所提升,从 0.994 2 升到了 0.995 0 (更接近于 1)。这表明 SABO-LSTM 预测模型具有较高的稳定性、精度和较小的预测误差,且泛化性能较好。

表 3 不同模型预测误差

预测模型	MAE/ ($\text{m}\cdot\text{s}^{-1}$)	RMSE/ ($\text{m}\cdot\text{s}^{-1}$)	MAPE/%	R^2
PSO-LSTM	0.132 3	0.176 5	1.345 9	0.994 2
GWO-LSTM	0.275 8	0.317 9	2.707 1	0.981 4
WOA-LSTM	0.129 7	0.172 3	1.346 5	0.994 5
SABO-LSTM	0.119 6	0.164 7	1.231 6	0.995 0

4 结论

针对高铁沿线短期风速预测问题,提出一种基于 SABO-LSTM 的风速预测方法,经实验验证,得到以下结论。

(1) 考虑到风速数据之间的时间关联性,采用 LSTM 网络作为预测模型基础,以数学概念、SABO 和 LSTM 算法理论为依据,提出基于 SABO-LSTM 的预测模型开展风速预测实验。预测结果与实际风速数据对比分析得出,SABO-LSTM 模型的预测结果与实际风速数据之间具有良好的一致性。

(2) 考虑 LSTM 在预测中受超参数的影响,采用具有较强收敛性能与全局搜索性能的 SABO 算法对 LSTM 的超参数进行优化,采用“-v 运算”的算数平均值来更新每个粒子的位置,使粒子能够更有效地在搜索空间中移动,减少了传统优化算法中的早熟收敛问题,增强了粒子的寻优效果,进而提升对 LSTM 超参数的优化能力,避免了人为经验设置的不确定性。

(3) 与 PSO-LSTM、GWO-LSTM、WOA-LSTM 预测模型进行对比分析,SABO-LSTM 通过减法平均值在开发和探索之间实现良好的平衡并根据当前迭

代次数计算适应度值,自适应调整粒子位置和更新策略,从而增加算法的鲁棒性和稳定性。所提出的 SABO-LSTM 模型各项评价指标均优于其他 3 种模型,具有更高的预测精度且预测值和实际值的拟合效果更好,验证了所提方法的可行性。

所提 SABO-LSTM 风速预测方法可提升短期风速预测精度,对高铁列车的安全运行具有一定实用价值。目前,国内外在高铁沿线风速预测方面的研究和应用都取得了显著进展。国外,特别是在日本和欧洲,已建立了成熟的高精度风速监测系统,并应用了多种先进的气象预测模型,以确保高铁运行的安全性。国内,高铁沿线风速预测技术也在不断发展,依托于大数据分析和人工智能技术,部分地区已初步实现了实时监测与预警。然而,现有的风速预测方法仍面临诸多挑战,如数据精度和覆盖范围不足、预测模型的鲁棒性和自适应性有待提高、多因素协同预测能力不足等。未来,高效的数据融合和智能优化预测模型的开发应成为高速铁路沿线风速预测算法研究的重点。通过整合多源数据,如地面气象站、卫星遥感和气象雷达,确保数据的全面性和高精度,并结合深度学习和机器学习技术,开发自适应和智能化的预测模型,实现对风速变化的高精度预测,从而提高列车运行的安全性和稳定性。

参 考 文 献

- [1] 韩鹏,郭桂祯,孙宁,等. 广东省台风灾害时空格局及影响因素研究[J]. 灾害学, 2022, 37(3): 112-117.
Han Peng, Guo Guizhen, Sun Ning, et al. Spatiotemporal patterns and influencing factors of typhoon disasters in Guangdong Province, China [J]. Journal of Catastrophology, 2022, 37(3): 112-117.
- [2] Zhao J, Liu K, Wang M. Exposure analysis of Chinese railways to multihazards based on datasets from 2000 to 2016[J]. Geomatics, Natural Hazards and Risk, 2020, 11(1): 272-287.
- [3] Wang Y R, Wang D C, Tang Y. Clustered hybrid wind power prediction model based on ARMA, PSO-SVM, and clustering methods [J]. IEEE Access, 2020, 8: 17071-17079.
- [4] Kumar R, Prakash M, Shakila B, et al. A comparative analysis of time series and machine learning models for wind speed prediction [C]//2023 IEEE 3rd Mysore Sub Section International Conference (MysuruCon). HASSAN: IEEE, 2023: 1-6.
- [5] 梁亚峰,马立红,邱剑洪,等. 基于 CEEMD-LSTM 光伏短期功率预测[J]. 科学技术与工程, 2024, 24(13): 5396-5405.
Liang Yafeng, Ma Lihong, Qiu Jianhong, et al. Short-term photovoltaic power forecasting based on CEEMD-LSTM [J]. Science Technology and Engineering, 2024, 24(13): 5396-5405.
- [6] Cheoneum P, Changki L, Lynn H, et al. S2-Net: machine reading comprehension with SRU-based self-matching networks [J]. ETRI Journal, 2019, 41(3): 371-382.
- [7] Tang G, Wu Y F, Li C S, et al. A novel wind speed interval pre-

- diction based on error prediction method[J]. IEEE Transactions on Transportation Electrification, 2020, 16(11): 6806-6815.
- [8] Wang J, Li X. Multi-step ahead wind speed prediction based on optimal feature extraction, long short-term memory neural network and error correction strategy[J]. Apply Energy, 2018, 230: 429-431.
- [9] 李冰, 张妍, 刘石. 基于 LSTM 的短期风速预测研究[J]. 计算机仿真, 2018, 35(11): 456-461.
Li Bing, Zhang Yan, Liu Shi. Wind speed short term prediction study based on LSTM[J]. Computer Simulation, 2018, 35(11): 456-461.
- [10] 李万, 冯芬玲, 蒋琦玮. 改进粒子群算法优化 LSTM 神经网络的铁路客运量预测[J]. 铁道科学与工程学报, 2018, 15(12): 3274-3280.
Li Wan, Fen Fenling, Jiang Qiwei. Prediction for railway passenger volume based on modified PSO optimized LSTM neural network[J]. Journal of Railway Science and Engineering, 2018, 15(12): 3274-3280.
- [11] 张忠林, 张艳. 改进 FA 优化 LSTM 的时序预测模型[J]. 计算机工程与应用, 2022, 58(11): 125-132.
Zhang Zhonglin, Zhang Yan. Improved FA optimizing LSTM time series prediction model[J]. Computer Engineering and Applications, 2022, 58(11): 125-132.
- [12] 乔建刚, 李硕, 刘怡美, 等. 改进 PSO-LSTM 算法预测高速公路交通量[J]. 科学技术与工程, 2024, 24(15): 6466-6472.
Qiao Jiangan, Li Shuo, Liu Yimei, et al. Improved PSO-LSTM algorithm for forecasting expressway traffic volume[J]. Science Technology and Engineering, 2024, 24(15): 6466-6472.
- [13] 凌晓, 徐鲁帅, 高甲程, 等. 基于 IFA-BPNN 的长输管道外腐蚀速率预测[J]. 表面技术, 2021, 50(4): 285-293.
Ling Xiao, Xu Lushuai, Gao Jiacheng, et al. Prediction of external corrosion rate of long-distance pipeline based on IFA-BPNN[J]. Surface Technology, 2021, 50(4): 285-293.
- [14] Houran M A, Bukhari S M S, Zafar M H, et al. COA-CNN-LSTM: coati optimization algorithm-based hybrid deep learning model for PV/wind power forecasting in smart grid applications[J]. Applied Energy, 2023, 349: 121638.
- [15] Pavel T, Mohamad D. Subtraction-average-based optimizer: a new swarm-inspired metaheuristic algorithm for solving optimization problems[J]. Biomimetics, 2023, 8(2): 4-9.
- [16] 赵星宇, 吴泉军, 朱威, 等. 基于 CEEMDAN 和 TCN-LSTM 模型的短期电力负荷预测[J]. 科学技术与工程, 2023, 23(4): 1557-1564.
Zhao Xingyu, Wu Quanjun, Zhu Wei. Short-term power load forecasting based on CEEMDAN and TCN-LSTM model[J]. Science Technology and Engineering, 2023, 23(4): 1557-1564.
- [17] 王俊, 李霞, 周昔东, 等. 基于 VMD 和 LSTM 的超短期风速预测[J]. 电力系统保护与控制, 2020, 48(11): 45-52.
Wang Jun, Li Xia, Zhou Xidong, et al. Ultra-short-term wind speed prediction based on VMD-LSTM[J]. Power System Protection and Control, 2020, 48(11): 45-52.
- [18] 张学清, 李芳, 张绚, 等. 基于 CNN-LSTM 模型的中国碳排放量实时预测研究[J]. 中阿科技论坛, 2022(10): 71-75.
Zhang Xueqing, Li Fang, Zhang Xuan, et al. Research on real-time prediction of carbon emissions in China based on CNN-LSTM model[J]. China-Arab States Science and Technology Forum, 2022(10): 71-75.
- [19] 李蓉蓉, 戴永. 基于 LSTM 和时间序列分析法的短期风速预测[J]. 计算机仿真, 2020, 37(3): 393-398.
Li Rongrong, Dai Yong. Short-term wind speed prediction based on short and long time memory network and time series analysis method[J]. Computer Simulation, 2020, 37(3): 393-398.
- [20] 陈建东, 聂斌, 雷银香. 一种改进灰狼优化算法[J]. 现代信息技术, 2023, 7(19): 94-98.
Cheng Jiandong, Nie Bin, Lei Yinxiang. An improved gray wolf optimization[J]. Modern Information Technology, 2023, 7(19): 94-98.