

文章编号: 1671-251X(2024)02-0090-08

DOI: 10.13272/j.issn.1671-251x.2023090067

基于 SSA-LSTM 的瓦斯浓度预测模型

兰永青¹, 乔元栋², 程虹铭¹, 雷利兴¹, 罗化峰¹

(1. 山西大同大学 煤炭工程学院, 山西 大同 037003;

2. 山西大同大学 建筑与测绘工程学院, 山西 大同 037003)

摘要: 为了更好地捕捉瓦斯浓度的时变规律及有效信息, 实现对采煤工作面瓦斯浓度的精准预测, 采用麻雀搜索算法(SSA)优化长短期记忆(LSTM)网络, 提出了一种基于 SSA-LSTM 的瓦斯浓度预测模型。采用均值替换法对原始瓦斯浓度时序数据中的缺失数据及异常数据进行处理, 再进行归一化和小波阈值降噪; 对比测试了 SSA 与灰狼优化(GWO)算法、粒子群优化(PSO)算法的性能差异, 验证了 SSA 在寻优精度、收敛速度和适应能力等方面的优势; 利用 SSA 的自适应性依次对 LSTM 的学习率、隐藏层节点个数、正则化参数等超参数进行寻优, 以此来提高全局寻优能力, 避免预测模型陷入局部最优; 将得到的最佳超参数组合代入 LSTM 网络模型中, 输出预测结果。将 SSA-LSTM 与 LSTM、GWO-LSTM、PSO-LSTM 瓦斯浓度预测模型进行比较, 实验结果表明: 基于 SSA-LSTM 的瓦斯浓度预测模型的均方根误差(RMSE)较 LSTM, PSO-LSTM, GWO-LSTM 分别减少了 77.8%, 58.9%, 69.7%; 平均绝对误差(MAE)分别减少了 83.9%, 37.8%, 70%, 采用 SSA 优化的 LSTM 预测模型相较于传统 LSTM 模型具有更高的预测精度和鲁棒性。

关键词: 瓦斯浓度预测; 时序预测; 深度学习; 长短期记忆网络; 麻雀搜索算法; 超参数寻优
中图分类号: TD712 文献标志码: A

Gas concentration prediction model based on SSA-LSTM

LAN Yongqing¹, QIAO Yuandong², CHENG Hongming¹, LEI Lixing¹, LUO Huafeng¹

(1. School of Coal Engineering, Shanxi Datong University, Datong 037003, China;

2. School of Architecture and Geomatics Engineering, Shanxi Datong University, Datong 037003, China)

Abstract: In order to better capture the time-varying patterns and effective information of gas concentration, and achieve precise prediction of gas concentration in coal working faces, a gas concentration prediction model based on SSA-LSTM is proposed by optimizing the long short term memory (LSTM) network using sparrow search algorithm (SSA). The model uses the mean replacement method to process missing and abnormal data in the original gas concentration time series data, followed by normalization and wavelet threshold denoising. The performance differences between SSA and grey wolf optimization (GWO) and particle swarm optimization (PSO) algorithms are compared and tested. The result verifies the advantages of SSA in terms of optimization precision, convergence speed, and adaptability. By utilizing the adaptability of SSA, the hyperparameters of LSTM, such as learning rate, number of hidden layer nodes, and regularization parameters, are sequentially optimized to improve the global optimization capability and avoid the prediction model falling into local optimum. The obtained optimal hyperparameter combination is substituted into the LSTM network model and the prediction results are output. Comparing SSA-LSTM with LSTM, GWO-LSTM, and PSO-LSTM gas concentration prediction models, the experimental results show that the root mean square error (RMSE) of the gas concentration prediction model

收稿日期: 2023-09-20; 修回日期: 2024-02-20; 责任编辑: 胡娴。

基金项目: 山西省回国留学人员科研资助项目(2022174); 山西省高校科技创新项目(2021L397)。

作者简介: 兰永青(1997—), 男, 山西吕梁人, 硕士研究生, 研究方向为矿山灾害防治及智能监测预警技术, E-mail: 1934719607@qq.com。通信作者: 乔元栋(1978—), 男, 山西大同人, 教授, 主要从事矿山动力灾害防治方面的研究工作, E-mail: dtdxqyd@126.com。

引用格式: 兰永青, 乔元栋, 程虹铭, 等. 基于 SSA-LSTM 的瓦斯浓度预测模型[J]. 工矿自动化, 2024, 50(2): 90-97.

LAN Yongqing, QIAO Yuandong, CHENG Hongming, et al. Gas concentration prediction model based on SSA-LSTM[J]. Journal of Mine Automation, 2024, 50(2): 90-97.



扫码移动阅读

based on SSA-LSTM is reduced by 77.8%, 58.9%, and 69.7% compared to LSTM, PSO-LSTM, and GWO-LSTM, respectively. The mean absolute error (MAE) decreases by 83.9%, 37.8%, and 70%, respectively. The LSTM prediction model optimized by SSA has higher prediction precision and robustness compared to traditional LSTM models.

Key words: gas concentration prediction; time series prediction; deep learning; long short-term memory network; sparrow search algorithm; hyperparameter optimization

0 引言

瓦斯是煤矿生产的关键致灾因素之一,与瓦斯窒息、瓦斯燃烧、瓦斯爆炸、煤与瓦斯突出等事故息息相关。瓦斯浓度是一种随时间变化的高动态、非线性时间序列数据,并受煤层赋存、采煤工艺、抽采工艺、风流等多种因素影响^[1],充分挖掘瓦斯浓度的时序性规律,实现瓦斯浓度精确、高效预测,对于预防瓦斯事故、保障煤矿安全生产具有重要意义。国内外学者最先采用统计学方法开展瓦斯浓度预测,如支持向量机^[2-5]、自回归积分滑动平均模型^[6-7]等,这类预测模型结构较简单,难以挖掘具有高度非线性的瓦斯浓度时序数据中隐含的相关特性。随着人工智能技术的不断发展,国内外学者将适用于大数据分析的深度学习方法应用到瓦斯浓度预测中,如循环神经网络(Recurrent Neural Network, RNN)模型^[8]、基于长短期记忆(Long Short-Term Memory, LSTM)网络的预测模型^[9-12]、基于门控循环单元(Gated Recurrent Unit, GRU)的预测模型^[13-14]等。这些研究方法极大地提高了瓦斯浓度预测精度,但尚未取得令人满意的结果,原因在于部分模型易发生过拟合现象,预测精度和效率受限。针对该问题,学者们采用蝗虫算法^[15]、遗传算法^[16]、鲸鱼算法^[17]等优化深度学习模型对瓦斯浓度预测模型进行改进,在一定程度上改善了预测效果。

麻雀搜索算法(Sparrow Search Algorithm, SSA)是根据麻雀觅食并躲避捕食者的行为而提出的群智能优化算法,由于添加了侦察预警行为,其收敛速度很快。SSA在温度预测、IGBT时间序列预测等方面的应用取得了良好的预测效果^[18-20]。基于此,本文首先对比测试了SSA与灰狼优化(Grey Wolf Optimization, GWO)算法、粒子群优化(Particle Swarm Optimization, PSO)算法的性能差异,然后利用SSA优化LSTM网络,提出一种基于SSA-LSTM的瓦斯浓度预测模型,采用实测数据进行了预测验证。

1 基于 SSA-LSTM 的瓦斯浓度预测模型

1.1 LSTM 网络模型

LSTM网络是RNN的一种特殊实现,其主要改

进了RNN中的隐藏层,在隐藏层中增加了3个门控制单元控制自循环,解决了RNN不能捕获长期依赖关系的问题。LSTM网络结构如图1所示。




图1 LSTM网络结构

Fig. 1 Structure of long short-term memory LSTM network

1) 遗忘门使用 Sigmoid 激活函数将上一时刻的记忆细胞与当前 t 时刻的输入转化为 $0 \sim 1$ 的数值, 0 表示丢弃所有信息, 1 表示保留所有信息。该数值决定多少信息被保留。遗忘门 f_t 计算公式为

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (1)$$

式中: σ 为 Sigmoid 函数; W_f 为遗忘门的权重矩阵; h_{t-1} 为输出神经元; x_t 为当前时刻的输入神经元; b_f 为遗忘门偏置项。

2) 输入门有 2 个部分: 第 1 部分是 Sigmoid 层, 决定了更新记忆细胞的状态; 第 2 部分是 tanh 层, 创建 1 个新的候选记忆细胞状态。输入门 I_t 计算公式为

$$I_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (3)$$

$$C_t = f_t C_{t-1} + I_t \tilde{C}_t \quad (4)$$

式中: W_i 为输入门权重矩阵; b_i , b_c 分别为输入门与细胞状态的偏置项; \tilde{C}_t 为备选更新信息; \tanh 为激活函数; W_c 为记忆细胞权重矩阵; C_t 为记忆细胞状态。

3) 输出门决定单元状态输出值。先利用 Sigmoid 层确定哪部分被输出, 再通过 tanh 处理并将其与 Sigmoid 函数的输出相乘。输出门 O_t 计算公式为

$$O_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = O_t \tanh C_t \quad (6)$$

式中: \mathbf{W}_0 为输出门权重矩阵; \mathbf{b}_0 为输出门偏置项。

1.2 SSA 及性能测试

SSA 是一种模拟自然界麻雀群体觅食和寻找最佳栖息地的群智能优化算法, 麻雀作为算法的主角, 其只有 1 项属性: 位置, 即表示其所寻觅食物的所在方位。对于每个麻雀个体, 其可能存在以下 3 种状态: ① 充当发现者, 带领种群寻觅食物。② 作为追随者, 追随发现者觅食。③ 作为警戒者, 具备警戒机制, 发现危险, 放弃觅食。

发现者位置计算公式为

$$X_{j+1}^{id} = \begin{cases} X_j^{id} \exp\left(\frac{-i}{\alpha T}\right) & R_2 < S \\ X_j^{id} + \Gamma L & R_2 \geq S \end{cases} \quad (7)$$

式中: X_j^{id} 为种群中第 j 代第 i 只麻雀在第 d 维的位置; α 为 $(0,1]$ 的随机数; T 为最大迭代次数; R_2, S 分别为预警值和安全阈值, $R_2 \in [0,1]$, $S \in [0.5,1]$; Γ 为服从标准正态分布的随机数; L 为 $1 \times d$ 的矩阵, 矩阵内元素均为 1。

当 $R_2 \geq S$ 时, 部分麻雀发现捕食者, 并向其他麻雀发出警告; 当 $R_2 < S$ 时, 表示当前环境周围没有捕食者, 可继续扩大搜索范围。

追随者位置计算公式为

$$X_{j+1}^{id} = \begin{cases} \Gamma \exp\left(\frac{X_{w_j}^d - X_j^{id}}{i^2}\right) & i > \frac{n}{2} \\ X_{p(j+1)}^d + |X_{j+1}^d - X_{p(j+1)}^d| \mathbf{A}^+ \mathbf{L} & \text{其他} \end{cases} \quad (8)$$

式中: $X_{w_j}^d$ 为第 j 次迭代时麻雀在第 d 维的最劣位置;

n 为种群大小; $X_{p(j+1)}^d$ 为第 $j+1$ 次迭代时麻雀在第 d 维的最优位置; \mathbf{A}^+ 为 $1 \times d$ 的矩阵, 矩阵内元素随机赋值为 1 或 -1。

当 $i > n/2$ 时, 表明该追求者没有获得食物, 存活率较低, 需飞往其他区域觅食来获取足够能量。

警戒者位置计算公式为

$$X_{j+1}^{id} = \begin{cases} X_{b_j}^d + \beta(X_j^{id} - X_{b_j}^d) & F_i \neq F_g \\ X_j^{id} + \mathbf{K} \left(\frac{X_j^{id} - X_{b_j}^d}{|F_i - F_w| + \delta} \right) & F_i = F_g \end{cases} \quad (9)$$

式中: $X_{b_j}^d$ 为当前全局最优位置; β 为步长控制参数; F_i 为第 i 只麻雀的适应度; F_g 和 F_w 分别为麻雀种群当前最优和最差适应度; \mathbf{K} 为麻雀移动方向, 其值为 $[-1,1]$ 的随机数; δ 为接近 0 的常数。

当 $F_i > F_g$ 时, 表示麻雀处于群体活动的边缘地带, 易受到袭击; 当 $F_i = F_g$ 时, 表示麻雀已经感知到危险, 需尽快向其他麻雀靠拢, 以减少被捕食的风险。

采用 CEC2005 函数集中的 Quartic, Generalized, Kowalik's 函数对 SSA 进行性能测试, 种群规模为 30, 最大迭代次数为 500。采用 GWO, PSO 算法对比验证 SSA 在收敛速度、搜索精度及适应能力等方面的优势。适应度曲线对比如图 2 所示。可看出, 在测试函数 Quartic、Kowalik's 中, 3 种优化算法最终都能够收敛, 其中 SSA 的收敛速度最快, GWO 次之, PSO 最慢; 在 Generalized 函数中, 仍是 SSA 的收敛速度最快, 可看到 SSA 在寻优精度和收敛速度方面均优于 GWO 和 PSO, 证明了 SSA 的高效性、稳定性。




图 2 适应度曲线对比

Fig. 2 Comparison of fitness curves

1.3 SSA-LSTM 瓦斯浓度预测模型

采用 SSA 算法改进 LSTM 网络模型, 构建瓦斯浓度预测模型, 其流程如图 3 所示。

1) 在数据预处理中, 为解决由传感器造成的数据缺失、异常波动等情况, 先采用均值法对缺失数据进行插值, 再采用小波变换对异常波动数据进行降噪处理, 最后对得到的数据集进行归一化处理。归一化公式为

$$Y'_t = \frac{Y_t - \min Y}{\max Y - \min Y} \quad (10)$$

式中: Y'_t 为归一化后瓦斯浓度数据; Y_t 为归一化前瓦斯浓度数据; Y 为单个瓦斯浓度数据; $\min Y, \max Y$ 分别为样本数据中的最小值、最大值。

2) 构建基于 LSTM 网络模型的基础框架, 采用均方误差 (Mean Squared Error, MSE) 作为模型预测评价指标, MSE 越小, 模型预测的准确度越高。

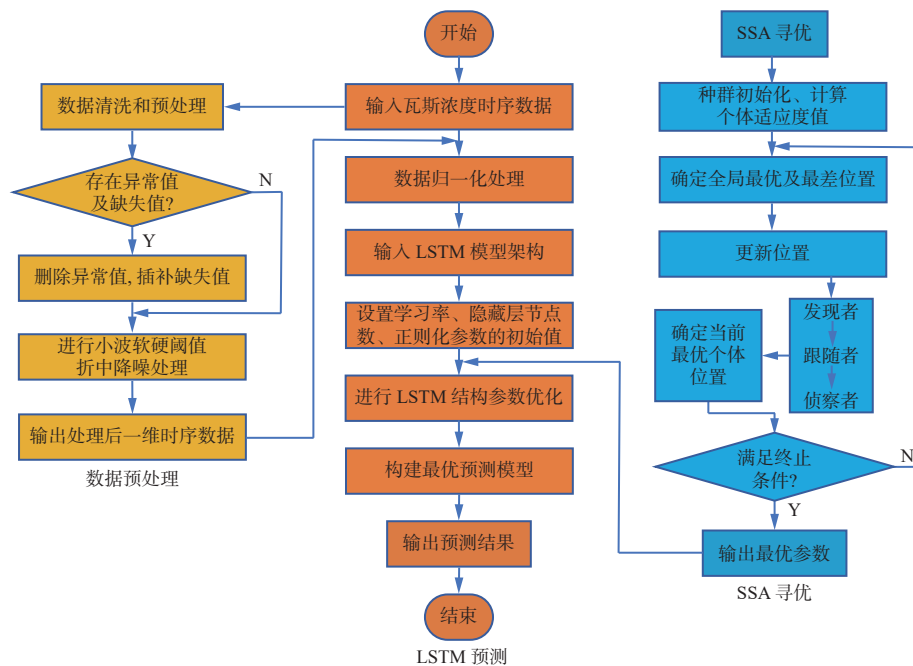


图3 基于 SSA-LSTM 的瓦斯浓度预测模型

Fig. 3 Gas concentration prediction model based on sparrow search algorithm(SSA)-LSTM

MSE 计算公式为

$$MSE = \frac{1}{N} \sum_{m=1}^N (Z(m) - \hat{Z}(m))^2 \quad (11)$$

式中: N 为测试集中的样本个数; $Z(m)$ 为测试集的真实值; $\hat{Z}(m)$ 为预测值。

3) 初始化 SSA 中的种群数量、最大迭代次数等相关参数, 然后利用 SSA 的自适应性依次对 LSTM 网络超参数进行寻优, 直到满足条件, 输出最佳超参数组合。

4) 将得到的最佳超参数组合代入 LSTM 网络模型中, 完成最终预测并输出预测结果。

2 模型参数寻优

2.1 实测数据及处理

实测数据来自同煤大唐塔山煤矿综放工作面瓦斯日常监测数据, 该矿主采石炭系 3—5 号煤层, 平均煤厚为 15.8 m, 平均倾角为 5° 左右, 煤层瓦斯含量为 $1.6 \sim 1.97 \text{ m}^3/\text{t}$, 设计生产能力为 15 Mt/a, 采用一井一面生产方式。工作面走向长度为 2 500 m 左右, 倾斜长度为 240 m 左右, 采用 U 型通风, 最大通风量为 $3\,500 \text{ m}^3/\text{min}$, 平均瓦斯涌出量为 $36.75 \text{ m}^3/\text{min}$, 呈典型的“低赋存, 高涌出”的状况。该工作面瓦斯涌出主要以采空区为主, 占总涌出量的 82% 左右, 采用顶板专用巷治理邻近层和采空区瓦斯, 回风巷瓦斯体积分数可控制在 0.4% 以下。瓦斯浓度数据每分钟采集记录 1 次, 共获取 12 000 条数据。为提高预测

精度, 对原始数据集进行预处理。

由于实测数据容易受到复杂的井下环境影响, 数据集存在异常及缺失现象, 并包含一定噪声, 所以需要数据集进行预处理。由于瓦斯浓度作为时序数据在时间上有天然连续性, 且一般情况下数据较平稳, 故采集的瓦斯浓度时序数集中缺失和异常数据较少, 于是利用缺失数据与异常数据前后间隔 30 min 数据的平均值进行替换。

原始数据集中的噪声会降低预测的准确性, 为保证数据的平滑性, 采用小波阈值进行降噪处理, 主要步骤如下。

1) 选取 sym8 小波基、5 层分解层对瓦斯浓度数据进行分解^[21-23], 对含噪信号进行相应层分解, 然后对瓦斯浓度数据进行小波变换, 将原始数据集转换为小波域, 利用分解信号将其分解为不同频率的子信号。

2) 选取合适阈值, 保留信号的信息并去除噪声。阈值的选取对降噪质量有很大影响, 若阈值过小, 则去噪效果不理想; 若阈值过大, 容易导致信号失真。目前使用最多的是固定阈值:

$$\lambda = s \sqrt{2 \ln a} \quad (12)$$

$$s = \frac{\text{median}(|B_{J,k}|)}{0.6745} \quad (13)$$

式中: s 为含噪信号中噪声的方差; a 为信号的采样长度; $\text{median}(\cdot)$ 为中值函数; $B_{J,k}$ 为小波系数, J, k 为分解层数。

3) 对小波系数进行阈值处理, 根据选取的阈值类型和大小, 将小于阈值的系数置零。

4) 通过逆小波变换将处理过的小波系数转换回时域, 得到最终降噪后的瓦斯浓度时间序列数据。预处理前后的数据对比如图 4 所示。

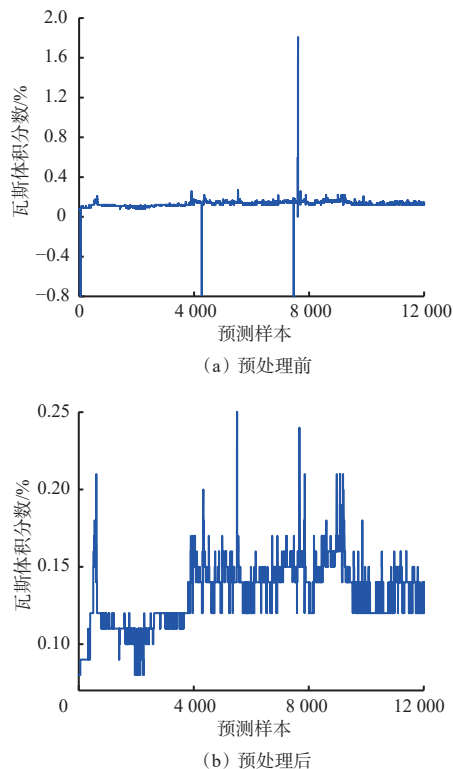


图 4 数据预处理前后对比

Fig. 4 Comparison before and after data preprocessing

2.2 SSA 参数确定

将构建好的 LSTM 网络基本框架输入到 SSA 中, SSA 最小搜索维度为 5, 最大搜索维度为 8; 麻雀种群数量为 6, 最大迭代次数为 8, 优化参数个数为 3; 将 MSE 作为适应度函数 F 的值。寻优结果 SSA 搜索维度为 6; 麻雀种群数量为 5, 最大迭代次数为 3; 利用 SSA 自适应性觅食行为找到的最优位置为 $[0.008\ 9, 27, 0.047\ 9]$ 。

2.3 LSTM 网络模型超参数寻优

根据经验值确定初始超参数, 选取 MSE 作为损失函数评价值, 利用 Matlab 软件得到不同算法优化后 LSTM 网络模型的训练损失曲线, 如图 5 所示。可看出在迭代 100 次时所有曲线都已接近平稳, 所以接下来调整超参数时将模型训练的迭代次数设置为 100。

选取模型的均方根误差 (Root Mean Squared Error, RMSE)、平均绝对误差 (Mean Absolute Error, MAE) 作为评价指标, 分析不同学习率、隐藏层节点个数、正则化参数对模型预测效果的影响。

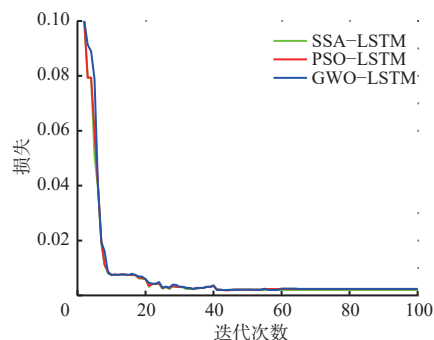


图 5 不同模型训练损失曲线

Fig. 5 Training loss curves of different models

$$\text{MAE} = \frac{1}{N} \sum_{m=1}^N |\hat{Z}(m) - Z(m)| \quad (14)$$

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{m=1}^N (Z(m) - \hat{Z}(m))^2} \quad (15)$$

1) 学习率控制了权重更新的步长, 学习率的取值一般控制在 $0.001 \sim 0.1$ 。学习率取值过小, 会导致模型过拟合; 学习率取值过大, 会使损失函数震荡不收敛。学习率对模型预测效果的影响如图 6 所示。

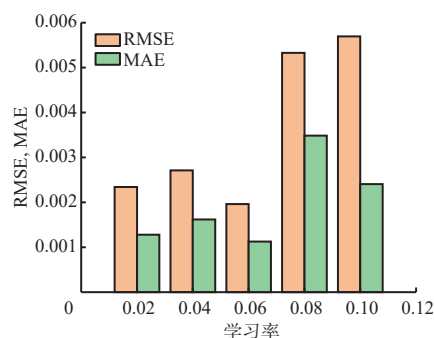


图 6 学习率对模型预测效果的影响

Fig. 6 The influence of learning rate on model prediction performance

2) 隐藏层节点个数决定了 LSTM 网络模型的复杂度和表达能力。节点数过少, 会导致无法满足训练要求; 节点数过多, 会使得模型结构过于复杂, 导致训练时间过长。通过 SSA 搜索最佳的隐藏层节点个数, 来提高模型的预测准确性。隐藏层节点个数对模型预测效果的影响如图 7 所示。

3) 正则化参数可降低 LSTM 网络模型的复杂度, 提高模型的泛化能力, 防止出现过拟合现象。正则化参数对模型预测效果的影响如图 8 所示。

最终确定 LSTM 网络模型的超参数组合见表 1。

3 预测结果分析

3.1 SSA-LSTM 模型预测结果

将预处理后的瓦斯浓度数据集根据常用的划分原则, 按 8:2 的比例划分为训练集和测试集。同时,




图7 隐藏层节点个数对模型预测效果的影响

Fig. 7 The influence of the number of hidden layer nodes on model prediction performance

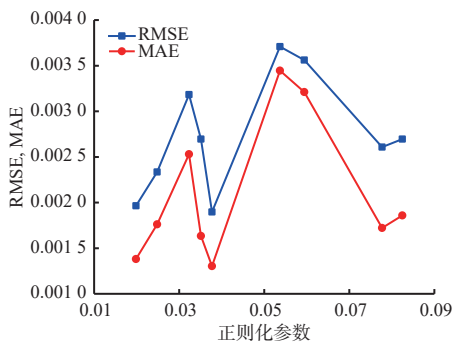


图8 正则化参数对模型预测效果的影响

Fig. 8 The influence of regularization parameters on model prediction performance

表1 不同预测模型超参数选择

Table 1 Selection of hyperparameters for different prediction models


模型	学习率	隐藏层节点个数	正则化参数
SSA-LSTM	0.06	40	0.038 3
PSO-LSTM	0.03	60	0.051 2
GWO-LSTM	0.05	80	0.041 6

把利用 SSA 寻优得到的最佳超参数组合输入到 LSTM 网络预测模型中,对未来采煤工作面的瓦斯浓度进行预测。为了验证采用 SSA 对传统 LSTM 网络模型超参数优化后预测精确度的提升,将传统 LSTM 网络模型预测结果和 SSA-LSTM 模型预测结果进行对比分析,结果如图 9 所示。

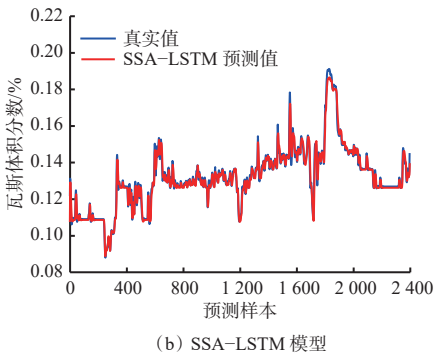
由图 9 可知,经 SSA 优化后的 LSTM 网络模型预测精度有很大提高,数据的拟合效果也较好,与传统的 LSTM 网络预测模型相比, RMSE 减小了 77.8%, MAE 减小了 83.9%,证明了基于 SSA-LSTM 的瓦斯浓度预测模型在提高预测精度方面的有效性。利用 SSA 算法对 LSTM 网络模型超参寻优避免了模型易陷入数据过拟合的弊端,提高了模型预测性能。

3.2 不同模型预测结果对比分析

为了验证本文所提瓦斯浓度预测模型的高效性,同时避免预测模型的单一性及片面性,采用



(a) LSTM 网络模型




(b) SSA-LSTM 模型

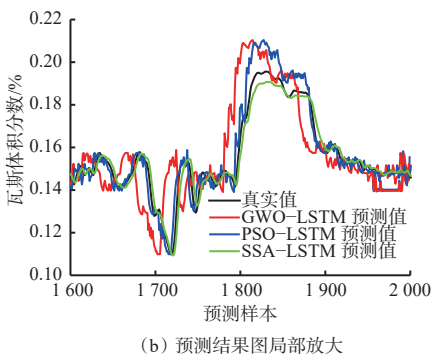
图9 LSTM 网络和 SSA-LSTM 预测结果对比

Fig. 9 Comparison of prediction results between LSTM network and SSA-LSTM

PSO-LSTM、GWO-LSTM 与 SSA-LSTM 模型的预测结果进行对比分析,各模型预测结果对比如图 10(a)所示。将测试集中波动较大的部分数据点(样本序号为 1 600—2 400)的预测结果局部放大,可更加清晰地展示各模型预测性能差异,如图 10(b)所示。



(a) 不同模型预测结果对比



(b) 预测结果图局部放大

图10 不同模型预测结果对比

Fig. 10 Comparison of prediction results of different models

从图 10 可以看出, SSA-LSTM 模型预测效果最佳, 预测值更加接近真实值。GWO-LSTM 模型次之, 接下来是 PSO-LSTM, 进一步验证了 SSA 优化 LSTM 网络的瓦斯浓度预测模型具有更高的预测准确性、稳定性。

采用 RMSE、MAE、运行时间、 R^2 对 PSO-LSTM、GWO-LSTM、SSA-LSTM 模型的预测性能进行对比, 结果见表 2。由表 2 可知, SSA-LSTM 模型的 RMSE 较 PSO-LSTM, GWO-LSTM 模型分别减少了 58.9%, 69.7%; SSA-LSTM 模型的 MAE 较 PSO-LSTM, GWO-LSTM 模型分别减少了 37.8%, 70%; 综合 R^2 、运行时间等评价指标来看, SSA-LSTM 模型的预测精度最高, 运行时间相对较短, 取得了良好的预测效果。

表 2 不同模型预测结果评价

Table 2 Evaluation of prediction results of different models

模型	MAE	RMSE	R^2	运行时间/s
LSTM	0.011 35	0.011 7	0.577 6	45
PSO-LSTM	0.002 93	0.004 8	0.908 9	50
SSA-LSTM	0.001 82	0.002 6	0.962 5	47
GWO-LSTM	0.006 15	0.008 6	0.780 3	49

4 结论

1) 采用 3 种不同的测试函数对 SSA 进行了性能测试, 同时与 PSO 算法和 GWO 算法进行了对比, 结果验证了 SSA 在寻优精度、收敛速度和适应能力等方面的优势。

2) 针对高度动态和非线性瓦斯浓度预测问题, 本文提出一种利用 SSA 对 LSTM 网络结构超参数进行优化的方法, 该方法避免了预测模型陷入局部最优情况。相较于传统 LSTM 网络模型, SSA-LSTM 模型预测精度更高, 预测效果更好。

3) 对比 LSTM, PSO-LSTM, GWO-LSTM 与 SSA-LSTM 模型的预测性能, 得出 SSA-LSTM 模型的预测效果最好, 与其他模型相比, RMSE 减少了 58.9%~77.8%, MAE 减少了 37.8~83.9%。SSA-LSTM 模型相较于其他预测模型拥有更高的预测精度, 可为煤矿瓦斯灾害防治提供有效决策支持。

参考文献(References):

[1] 王双明. 对我国煤炭主体能源地位与绿色开采的思考[J]. 中国煤炭, 2020, 46(2): 11-16.
WANG Shuangming. Thoughts about the main energy status of coal and green mining in China[J]. China Coal, 2020, 46(2): 11-16.

[2] 付华, 代巍. 基于 ACP SO 的 PSR-MK-LSSVM 瓦斯浓度动态预测方法[J]. 传感技术学报, 2016, 29(6): 903-908.
FU Hua, DAI Wei. Gas concentration dynamic prediction method of mixtures kernels LSSVM based on ACP SO and PSR[J]. Chinese Journal of Sensors and Actuators, 2016, 29(6): 903-908.

[3] 钱建生, 邱春荣, 李紫阳, 等. 深度学习耦合粒子群优化 SVM 的瓦斯浓度预测[J]. 煤矿安全, 2016, 47(11): 173-176.
QIAN Jiansheng, QIU Chunrong, LI Ziyang, et al. Gas emission quantity prediction based on particle swarm optimization of SVM and deep learning network[J]. Safety in Coal Mines, 2016, 47(11): 173-176.

[4] 吴海波, 施式亮, 念其锋. 基于 Isomap+SVR 的瓦斯浓度预测方法[J]. 矿业工程研究, 2019, 34(2): 51-54.
WU Haibo, SHI Shiliang, NIAN Qifeng. Prediction of gas concentration based on Isomap and SVR[J]. Mineral Engineering Research, 2019, 34(2): 51-54.

[5] 李欢, 贾佳, 杨秀宇, 等. 煤矿综采工作面瓦斯浓度预测模型[J]. 工矿自动化, 2018, 44(12): 48-53.
LI Huan, JIA Jia, YANG Xiuyu, et al. Gas concentration prediction model for fully mechanized coal mining face[J]. Industry and Mine Automation, 2018, 44(12): 48-53.

[6] 王鹏, 伍永平, 王桂林, 等. 矿井瓦斯浓度 Lagrange-ARIMA 实时预测模型研究[J]. 煤炭科学技术, 2019, 47(4): 141-146.
WANG Peng, WU Yongping, WANG Shuanlin, et al. Study on Lagrange-ARIMA real-time prediction model of mine gas concentration[J]. Coal Science and Technology, 2019, 47(4): 141-146.

[7] 张震, 朱权洁, 李青松, 等. 基于 Python 的瓦斯浓度 ARIMA 预测模型构建及其应用[J]. 华北科技学院学报, 2020, 17(2): 23-28, 49.
ZHANG Zhen, ZHU Quanjie, LI Qingsong, et al. Construction and application of ARIMA prediction model of gas concentration based on Python[J]. Journal of North China Institute of Science and Technology, 2020, 17(2): 23-28, 49.

[8] 王怀远, 张保会, 杨松浩, 等. 电力系统暂态稳定切机控制策略表的快速整定方法[J]. 电力系统自动化, 2016, 40(11): 68-72, 79.
WANG Huaiyuan, ZHANG Baohui, YANG Songhao, et al. Fast setting method of generator tripping strategy tables in transient stability control of power systems[J]. Automation of Electric Power Systems, 2016, 40(11): 68-72, 79.

[9] 郭星燃, 李娟莉, 苗栋, 等. 基于 LSTM-Adam 的矿井提升机故障预警模型[J]. 机电工程, 2024, 41(1): 175-182.
GUO Xingran, LI Juanli, MIAO Dong, et al. A fault

- early warning model of mine hoist based on LSTM-Adam[J]. *Journal of Mechanical & Electrical Engineering*, 2024, 41(1): 175-182.
- [10] 周浩杰, 杨建卫, 王尊, 等. 基于 LSTM 光伏发电功率超短期预测模型研究[J]. *电源技术*, 2023, 47(6): 785-789.
ZHOU Haojie, YANG Jianwei, WANG Zun, et al. Research on ultra-short term prediction model of photovoltaic power generation based on LSTM[J]. *Chinese Journal of Power Sources*, 2023, 47(6): 785-789.
- [11] 余琼芳, 王联港, 杨艺. 基于 LSTM-TCN 的综采工作面顶板压力预测[J]. *煤炭技术*, 2023, 42(6): 5-9.
YU Qiongfang, WANG Liangang, YANG Yi. Pressure prediction of top plate of comprehensive mining working face based on LSTM-TCN[J]. *Coal Technology*, 2023, 42(6): 5-9.
- [12] 谭美芳, 匡锐, 张清勇, 等. 基于改进灰狼算法优化 LSTM 的断面交通流预测[J]. *武汉理工大学学报*, 2023, 45(5): 132-139.
TAN Meifang, KUANG Rui, ZHANG Qingyong, et al. LSTM for cross-sectional traffic flow prediction based on improved grey wolf optimizer algorithm[J]. *Journal of Wuhan University of Technology*, 2023, 45(5): 132-139.
- [13] 吴家葆, 曾国辉, 张振华, 等. 基于 K-means 分层聚类的 TCN-GRU 和 LSTM 动态组合光伏短期功率预测[J]. *可再生能源*, 2023, 41(8): 1015-1022.
WU Jiabao, ZENG Guohui, ZHANG Zhenhua, et al. Dynamic combination of TCN-GRU and LSTM photovoltaic short-term power prediction based on K-means hierarchical clustering[J]. *Renewable Energy Resources*, 2023, 41(8): 1015-1022.
- [14] 杨雨佳, 肖庆来, 陈健, 等. 融合空间和统计特征的 CNN-GRU 臭氧浓度预测模型研究[J]. *南京大学学报(自然科学)*, 2023, 59(2): 322-332.
YANG Yujia, XIAO Qinglai, CHEN Jian, et al. Research on CNN-GRU ozone prediction considering spatial features and statistical features[J]. *Journal of Nanjing University(Natural Science)*, 2023, 59(2): 322-332.
- [15] 王雨虹, 王淑月, 王志中, 等. 基于改进蝗虫算法优化长短期记忆神经网络的多参数瓦斯浓度预测模型研究[J]. *传感技术学报*, 2021, 34(9): 1196-1203.
WANG Yuhong, WANG Shuyue, WANG Zhizhong, et al. Multi-parameter gas concentration prediction model based on improved locust algorithm to optimize long and short time memory neural network[J]. *Chinese Journal of Sensors and Actuators*, 2021, 34(9): 1196-1203.
- [16] 王德忠, 朱国宏, 王禹, 等. 基于 GA-LSTM 的综采面瓦斯浓度预测模型[J]. *煤炭技术*, 2023, 42(1): 219-221.
WANG Dezhong, ZHU Guohong, WANG Yu, et al. Prediction model of gas concentration in fully mechanized mining face based on GA-LSTM[J]. *Coal Technology*, 2023, 42(1): 219-221.
- [17] 郝可青, 吕志刚, 邸若海, 等. 基于鲸鱼算法优化长短期记忆神经网络的锂电池剩余寿命预测[J]. *科学技术与工程*, 2022, 22(29): 12900-12908.
HAO Keqing, LYU Zhigang, DI Ruohai, et al. Remaining useful life prediction of lithium battery based on long short-term memory optimized by whale optimization algorithm[J]. *Science Technology and Engineering*, 2022, 22(29): 12900-12908.
- [18] 王冰, 尚亚强, 严一蹕, 等. 基于麻雀搜索算法的橡胶复合挤出机温度压力解耦控制[J]. *大众科技*, 2022, 24(7): 9-13.
WANG Bing, SHANG Yaqiang, YAN Yichuo, et al. Temperature and pressure decoupling control of rubber composite extruder based on sparrow search algorithm[J]. *Popular Science & Technology*, 2022, 24(7): 9-13.
- [19] 祖林禄, 柳平增, 赵妍平, 等. 基于 SSA-LSTM 的日光温室环境预测模型研究[J]. *农业机械学报*, 2023, 54(2): 351-358.
ZU Linlu, LIU Pingzeng, ZHAO Yanping, et al. Solar greenhouse environment prediction model based on SSA-LSTM[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2023, 54(2): 351-358.
- [20] 冷丽英, 付建哲, 宁波. 基于 SSA-LSTM 模型的 IGBT 时间序列预测研究[J]. *半导体技术*, 2023, 48(1): 66-72.
LENG Liying, FU Jianzhe, NING Bo. Research on IGBT sequentially prediction based on SSA-LSTM model[J]. *Semiconductor Technology*, 2023, 48(1): 66-72.
- [21] 刘栋, 梅雪松, 冯斌, 等. 基于 Symlets 小波滤波的滚珠丝杠伺服进给系统频响特性辨识[J]. *机械工程学报*, 2011, 47(13): 153-159.
LIU Dong, MEI Xuesong, FENG Bin, et al. Frequency response identification for ballscrew servo driven system based on Symlets wavelet[J]. *Journal of Mechanical Engineering*, 2011, 47(13): 153-159.
- [22] 张会峰, 张德正, 程卫健, 等. 基于小波滤波和 SVPWM 的矿用 APF 研究[J]. *煤矿机械*, 2023, 44(9): 198-200.
ZHANG Huifeng, ZHANG Dezheng, CHENG Weijian, et al. Research on mining APF based on wavelet filtering and SVPWM[J]. *Coal Mine Machinery*, 2023, 44(9): 198-200.
- [23] 陈俊, 余雷. 基于小波分解切换规则的交互系统切换滤波方法[J]. *电工技术*, 2022(13): 31-34, 97.
CHEN Jun, YU Lei. A switching filtering method for interactive systems based on wavelet decomposition switching rules[J]. *Electric Engineering*, 2022(13): 31-34, 97.