

中文引用格式:秦跃平,唐飞,王海蓉,等. 基于 KOA-BiLSTM 的矿井淋水井筒风温预测模型及可解释性分析[J]. 中国安全科学学报, 2025, 35(7): 40-47.

英文引用格式:QIN Yueping, TANG Fei, WANG Hairong, et al. Prediction model and interpretability analysis of wind temperature in mine water-drenched shaft based on KOA-BiLSTM[J]. China Safety Science Journal, 2025, 35(7): 40-47.

基于 KOA-BiLSTM 的矿井淋水井筒风温预测模型 及可解释性分析*

秦跃平 教授, 唐飞**, 王海蓉, 王鹏, 郭铭彦, 王世斌

(中国矿业大学(北京) 应急管理与安全工程学院, 北京 100083)

中图分类号: X936

文献标志码: A

DOI: 10.16265/j.cnki.issn1003-3033.2025.07.1486

资助项目: 国家重点研发计划项目(2022YFC2904100)。

【摘要】 为提高矿井淋水井筒风温预测的准确性、稳定性及模型的可解释性, 首先, 通过皮尔逊相关性系数分析特征变量; 其次, 采用开普勒优化算法(KOA)优化双向长短期记忆网络(BiLSTM)模型, 建立基于 KOA-BiLSTM 的矿井淋水井筒风温预测模型; 然后, 在相同样本条件下, 与反向传播(BP)、随机森林(RF)、最小二乘增强(LSBoost)和支持向量机(SVM)算法进行综合对比; 最后, 利用沙普利可加性特征解释算法(SHAP)进行可解释性分析及实例验证。研究结果表明: KOA-BiLSTM 模型的绝对误差范围为 $-1.24 \sim 0.5$ °C, 比优化前模型的预测精度提高 3.98%; 与另外 4 个模型相比, 该模型的平均绝对误差(MAE)、平均绝对百分比误差(MAPE)和均方误差(MSE)等均为最佳, 表明该模型具有最优的预测效果和泛化能力; SHAP 分析表明: 井口风流温度对预测结果影响最大, 而地面压力影响最小; KOA-BiLSTM 模型实例验证的绝对误差范围为 $-0.49 \sim 0.38$ °C, 预测精度可满足实际工作需要。

【关键词】 开普勒优化算法(KOA)-双向长短期记忆网络(BiLSTM)模型; 淋水井筒; 风温预测模型; 可解释性分析; 皮尔逊相关性

Prediction model and interpretability analysis of wind temperature in mine water-drenched shaft based on KOA-BiLSTM

QIN Yueping, TANG Fei, WANG Hairong, WANG Peng, GUO Mingyan, WANG Shibin

(School of Emergency Management and Safety Engineering, China University of
Mining and Technology-Beijing, Beijing 100083)

Abstract: This study aims to improve the accuracy, stability and interpretability of the model for the prediction of the air temperature in the mine water-drenched shaft. Firstly, characteristic variables were analyzed by Pearson correlation coefficient. Secondly, BiLSTM model was optimized by KOA, and the prediction model of mine shaft air temperature based on KOA-BiLSTM was established. Then, under the same sample conditions, the algorithm was compared with back propagation (BP), random forest (RF), least squares boosting (LSBoost) and support vector machine (SVM). Finally, interpretability analysis was conducted using the shapley additive explanations (SHAP) algorithm, which was verified by an

* 文章编号: 1003-3033(2025)07-0040-08; 收稿日期: 2025-03-10; 修稿日期: 2025-05-16

** 通信作者: 唐飞(1997—), 男, 安徽阜南人, 博士研究生, 主要研究方向为矿井热害防治。E-mail: 2769133677@qq.com。

example. The results show that the absolute error range of KOA-BiLSTM model is $-1.24\sim-0.5\text{ }^{\circ}\text{C}$, which is 3.98% higher than the prediction accuracy of the unoptimized model. Compared with the other four models, the average absolute error (MAE), average absolute percentage error (MAPE) and mean square error (MSE) of the proposed model are the smallest, indicating that the model has the best prediction effect and generalization ability. The SHAP analysis shows that the wellhead air flow temperature has the greatest impact on the prediction results, while the surface pressure has the least impact. The absolute error range of KOA-BiLSTM model example verification is $-0.49\sim0.38\text{ }^{\circ}\text{C}$, and the prediction accuracy can meet the work needs.

Keywords: Kepler optimization algorithm (KOA)-bidirectional long short-term memory (BiLSTM) model; water-drenched shaft; wind temperature prediction model; interpretability analysis; Pearson correlation

0 引言

随着矿井开采深度的延伸和开采强度的提高,矿井高温热害问题日益严重^[1]。高温高湿的井下环境会导致矿工劳动效率降低、安全生产事故率上升和机械设备故障率增加等问题^[2-3]。由于矿井风流换热过程极其复杂,这使得风温预测难度加大。因此,探究矿井风温的变化特征,构建可靠的风温预测模型,持续提高风温预测的准确率。这对于科学评估矿井热害风险等级、优化矿井高温环境以及制定有效的热害预防和治理方案等具有重要的意义。

矿井淋水井筒风温预测是全矿井风温预测过程中最重要、最复杂的一环。其热交换过程涉及热湿传递,受到地表风温、风速、淋水吸热、井筒深度和岩石热物理性质等多因素的影响,导致淋水井筒风温预测极其困难^[4]。国内外学者围绕矿井风温预测开展了大量的研究。BASCOMPTA 等^[5]根据矿井通风线路中的温度、风量和通风距离等实测数据,建立了矿井通风线路中的温度预测模型。ZHOU Gang 等^[6]提出一种基于风流焓值方程的全矿井通风管网空气温度预测模型,并开发了风温预测软件。孔松等^[7]建立井筒风流热湿交换能量控制方程,通过有限差分的方法解算了风温迭代计算数学模型;何启林等^[8]通过回归分析的方式预测井筒风温。尽管上述研究推动了矿井风温预测的发展,但在预测精度、实时性、适应性以及操作程度复杂程度等方面仍存在一定局限性。

随着机器学习的发展,风温预测的精度和效率显著提升,特别是在应对复杂矿井环境的多变因素方面表现出更大的优势。近年来,诸多学者利用深度学习和神经网络等智能算法进行矿井风温预测研究^[9-10]。吕品等^[11]运用反向传播(Back Propagation, BP)神经网络预测淋水井筒风温;纪俊

红等^[12]提出基于 K 折网格搜索交叉验证法-极端梯度提升(Grid Search and K-Cross validation-eXtreme Gradient Boosting, GSK-XGBoost)的井底风温预测模型,以解决矿井井底风温预测过程中的精度不足的问题。高佳南等^[13]建立了遗传算法(Genetic Algorithm, GA)-BP 神经网络井筒风温预测模型,提高 BP 模型的预测精度。程磊等^[14]运用粒子群优化(Particle Swarm Optimization, PSO)-埃尔曼(Elman)神经网络建立了井底风温预测模型,改善神经网络收敛性差的特点。尽管这些研究取得一定进展,但上述模型在实际应用中容易陷入局部最优解问题,进而影响风温预测的稳定性和精确性。此外,这些模型缺乏对预测结果的可解释性分析,限制了其在工程中的推广和应用。

鉴于此,文中拟构建开普勒优化算法(Kepler Optimization Algorithm, KOA)-双向长短时记忆网络(Bidirectional Long Short-Term Memory, BiLSTM)淋水井筒风温预测模型。首先,以 20 个矿井的 60 组实测数据为样本,利用 BiLSTM 模型捕捉深层特征,并结合 KOA 算法避免模型陷入局部最优,进而提高风温预测的精度;然后,引入沙普利可加性特征解释算法(SHapley Additive exPlanation, SHAP)算法开展模型可解释性分析,明确不同特征变量对预测结果的影响;最后,以实例验证该模型的普适性。以期为井下通风系统调控与热害预警提供精准决策支持。

1 矿井淋水井筒风温预测模型构建

1.1 风温预测模型相关方法介绍

1) 皮尔逊相关系数。开展特征变量相关性检验,通过相关性分析选择特征变量,并选用皮尔逊(Pearson)相关系数法开展特征变量分析^[15]。

皮尔逊相关性系数取值范围为 $[0, 1]$,其值越大,特征变量相关性越强。当其值小于 0.5 时,则说

明 2 特征变量之间低度相关。

2) KOA 算法。ABDEL-BASSET 等^[16]在 2023 年提出基于物理学的元启发式算法——KOA。该算法基于开普勒行星运动定律,可预测行星在任何给定时间的位置和速度。

在 KOA 算法中,每颗行星的位置都是 1 个候选解,在优化过程中,候选解会与迄今为止的最佳解(太阳)进行对比更新。通过使候选解(行星)在不同时间与最佳解(太阳)呈现不同的情况,KOA 算法可以更有效地探索和利用搜索空间,并在搜索过程中不断调整和优化其搜索策略,以提高搜索效率和解的质量。同时,该算法能够有效克服 P-元进化算法在连续优化问题中遇到的容易陷入局部最优、收敛速度慢和种群多样性不足等优化问题。KOA 作为一种全局优化算法,包括探索和利用阶段,其算法流程如图 1 所示。




图 1 KOA 算法流程
Fig. 1 KOA algorithm process

3) BiLSTM 模型。长短期记忆网络 (Long Short-Term Memory, LSTM) 是循环神经网络 (Recurrent Neural Network, RNN) 经过改进之后的算法,有着长期记忆和有效利用历史信息的优点^[17]。该模型可以有效地解决 RNN 算法结构中存在的梯度消失问题,每个 LSTM 单元都由遗忘门、输入门和输出门组成,使得 LSTM 算法能记忆长期的信息^[18]。

BiLSTM 模型是在 LSTM 模型的基础上进行改




图 2 BiLSTM 模型结构
Fig. 2 BiLSTM model structure

进,利用正序训练和逆序训练来捕获过去和未来的信息。BiLSTM 的结构模型由 2 个独立的 LSTM 组成,分别对应前向 LSTM 层和后向 LSTM 层^[18]。BiLSTM 的模型结构如图 2 所示。

1.2 构建 KOA-BiLSTM 预测模型

利用 KOA 算法优化 BiLSTM 模型,建立矿井淋水井筒风温的 KOA-BiLSTM 预测模型,如图 3 所示,该模型预测流程如下:




图 3 KOA-BiLSTM 预测模型
Fig. 3 KOA-BiLSTM prediction model

1) 运用皮尔逊相关性算法探究特征变量之间的关联性,进而确定预测模型的特征变量。

2) 筛选和处理样本,导入风温预测的实测数据样本;将风温数据样本划分为训练集和测试集,训练集和测试集的占比分别为 80% 和 20%。

3) 建立风温预测模型,设置 BiLSTM 神经元个数等参数。通过 KOA 算法搜索相关参数,优化网络模型的超参数,并获得最优网络超参数,防止模型陷入局部最优解问题。

4) 导入风温数据训练集,运用 BiLSTM 模型提

取参数特征,建立 KOA-BiLSTM 预测模型。检测是否达到设定误差 0.001,如果达到,则继续下一步;否则重新训练训练集,直到达到标准。

5) 导入风温数据测试集,输出井筒风温的预测结果;与实测风温对比计算绝对误差、相对误差等参数,评估预测模型精度。

6) 实例运用,输入实测风温等相关数据,利用训练好的风温预测模型,对其它矿井淋水井筒井底风温进行预测。

1.3 预测结果评价

为评估对不同预测模型的预测性能和效果,选用均方误差 (Mean Squared Error, MSE)、平均绝对百分比误差 (Mean Absolute Percentage Error, MAPE)、均方根误差 (Root Mean Squared Error, RMSE)、平均绝对误差 (Mean Absolute Error, MAE) 和决定系数 (R^2) 作为预测模型的评价指标。其中, MSE、MAPE、RMSE 和 MAE 均为衡量实际值与预测值之间的偏差情况,值越大,表明预测模型越不准确。 R^2 反映实测值和预测的分布趋势,用来评估预测模型的拟合(预测)效果, R^2 值越接近 1,说明该模型的预测效果越好、拟合精度越高。计算公式如下:

$$MAE = \frac{1}{n} \sum_{j=1}^n |P_j - Q_j| \tag{1}$$

$$MAPE = \frac{1}{n} \sum_{j=1}^n \left| \frac{P_j - Q_j}{Q_j} \right| \times 100\% \tag{2}$$

$$MSE = \frac{1}{n} \sum_{j=1}^n (P_j - Q_j)^2 \tag{3}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{j=1}^n (P_j - Q_j)^2} \tag{4}$$

$$R^2 = 1 - \frac{\sum_{j=1}^n (Q_j - P_j)^2}{\sum_{j=1}^n (Q_j - \bar{Q})^2} \tag{5}$$

式中: n 为数据个数; P_j 为预测值; Q_j 为实测值; $\bar{Q}$ 为实测值的平均值。

2 风温预测模型算例及结果分析

2.1 风温影响因素及样本数据

淋水井筒换热过程复杂,风流受到空气自压缩、围岩加热、风速、风温和岩体热物理性质等因素影响。该过程中存在着传热、传湿和传质,导致目前矿井淋水井筒风温从理论上预测十分困难。

不同矿井的岩石热物理性质总体差异不大,各矿井井筒风速均十分接近煤矿最大安全标准 (15 m/s)。结合有关矿井淋水井筒风温预测相关文献和现场实际测试数据,选取井口风温、井口风流相对湿度、地面大气压力和井筒深度作为预测模型的特征变量进行预测实际风温。选用文献[7-15]中的 60 组现场实测风温、风流湿度等参数作为样本数据,其中,前 48 组为训练集,后 12 组为测试集。部分现场数据见表 1。

表 1 样本数据
Table 1 Sample data

序号	井口风温/℃	井口风流相对湿度/%	地面大气压力/Pa	井筒深度/m	井底风温/℃
1	26	91	100 380	476.35	25.6
2	26.6	81.7	100 240	476.35	25.8
3	26.4	85.4	100 339	476.35	25.5
4	29.8	63	100 520	518.78	28.6
5	28.8	62.6	100 880	518.78	27.6
⋮	⋮	⋮	⋮	⋮	⋮
58	26.8	79	99 965	673.20	26.8
59	28.1	80	99 868	673.20	27.9
60	15.7	67.3	100 350	482.02	16.6

2.2 皮尔逊相关性检验

首先计算表 1 中各个特征变量的皮尔逊相关性系数,并绘制特征变量相关性系数热力图,如图 4 所示。由图 4 可知:4 个特征变量的皮尔逊相关性系数值均小于 0.5。其中,井口风流温度和井口相对湿度的皮尔逊相关性系数最大,其值为 0.35;地面大气压和井筒深度皮尔逊相关性系数最小,其值为 0.046。4 个特征变量的相关性比较弱,满足同时作为井筒风温预测变量之间的相关性要求。因此,将取井口风温、井筒深度等 4 个变量作为预测模型的输入值。




图 4 特征变量相关性系数

Fig. 4 Correlation coefficients of characteristic variables

2.3 优化效果检验

为验证 KOA 算法对 BiLSTM 预测模型的优化效果,分别计算 BiLSTM 和 KOA-BiLSTM 模型的 MAE、MAPE、MSE、RMSE 和 R^2 值。BiLSTM 模型评价指标分别为 1.03℃、5.59%、1.5、1.2 和 0.892 3,而 KOA-BiLSTM 模型评价指标分别为 0.38℃、1.61%、0.26、0.51 和 0.985 7。通过对比,KOA-BiLSTM 模型的平均相对预测精度提高 3.98%。可见,KOA 算法能够显著提高 BiLSTM 模型的预测精度和泛化能力。

2.4 风温预测模型对比及分析

在相同的样本集条件下,对比 KOA-BiLSTM 模型与 BP、随机森林(Random Forest, RF)、最小二乘增强(Least Squares Boosting, LSBoost)和支持向量机(Support Vector Machine, SVM)这 4 种预测模型的预测结果。上述模型均采用最常见的参数设置,例

如;BP 模型使用典型的 3 层网络结构,SVM 模型则采用径向基核函数等。5 种模型的预测值和实际值对比结果见表 2,由表 2 可知;BP、RF、LSBoost、SVM 和 KOA-BiLSTM 模型的相对误差范围分别为 10.5%~5.3%、-7.6%~3.9%、-6.3%~3.4%、6.8%~1.1%、-2.6%~3.0%,KOA-BiLSTM 模型的相对误差范围最小,预测效果最好。

5 种预测模型在测试集上的预测值和误差如图 5、图 6 所示。由图 5 可知;相比于其他 4 个模型,KOA-BiLSTM 模型的预测值和实际值曲线更为贴近,说明该模型预测可靠性最高。由图 6 可知;BP 模型、RF 模型、LSBoost 模型、SVM 模型和 KOA-BiLSTM 模型的绝对误差范围分别为-2.31~1.55℃、-2.1~0.62℃、-2.65~0.95℃、-1.5~0.25℃和-1.24~0.5℃,KOA-BiLSTM 模型的绝对误差的绝对值最小,最大值仅为 1.24℃,远低于其他预测模型,说明该预测模型预测准确性最高。

表 2 5 种模型预测结果及误差

Table 2 5 Model prediction results and errors

序号	实际风温/ ℃	BP 模型			RF 模型			LSBoost 模型			SVM 模型			KOA-BiLSTM 模型		
		预测值/ ℃	绝对误差/ ℃	相对误差/ %	预测值/ ℃	绝对误差/ ℃	相对误差/ %	预测值/ ℃	绝对误差/ ℃	相对误差/ %	预测值/ ℃	绝对误差/ ℃	相对误差/ %	预测值/ ℃	绝对误差/ ℃	相对误差/ %
1	16.0	16.57	0.57	3.54	16.62	0.62	3.90	14.99	-1.01	-6.33	15.35	-0.65	-4.06	15.76	-0.24	-1.50
2	26.9	26.60	-0.30	-1.12	25.58	-1.32	-4.93	25.76	-1.14	-4.25	26.63	-0.27	-0.99	26.67	-0.23	-0.87
3	23.2	23.21	0.01	0.05	23.55	0.35	1.52	22.67	-0.53	-2.29	23.45	0.25	1.07	23.19	-0.01	-0.03
4	29.1	30.65	1.55	5.32	27.03	-2.07	-7.11	27.27	-1.83	-6.29	28.44	-0.66	-2.28	28.67	-0.43	-1.46
5	27.4	27.52	0.12	0.42	25.30	-2.10	-7.67	26.20	-1.20	-4.37	26.74	-0.66	-2.41	26.79	-0.61	-2.23
6	26.5	26.42	-0.08	-0.31	26.35	-0.15	-0.57	26.77	0.27	1.00	26.16	-0.34	-1.30	26.43	-0.07	-0.26
7	27.8	27.27	-0.53	-1.90	26.75	-1.05	-3.79	26.49	-1.31	-4.70	26.85	-0.95	-3.42	27.05	-0.75	-2.69
8	21.9	19.59	-2.31	-10.54	20.18	-1.72	-7.85	19.25	-2.65	-12.08	20.40	-1.50	-6.84	20.66	-1.24	-5.66
9	27.0	26.85	-0.15	-0.56	25.92	-1.08	-4.00	26.10	-0.90	-3.34	26.72	-0.28	-1.03	26.87	-0.13	-0.50
10	26.8	25.70	-1.10	-4.11	26.51	-0.29	-1.09	27.45	0.65	2.42	26.51	-0.29	-1.09	26.68	-0.12	-0.43
11	27.9	27.82	-0.08	-0.30	27.78	-0.12	-0.42	28.85	0.95	3.42	27.56	-0.34	-1.24	27.69	-0.21	-0.75
12	16.6	16.61	0.01	0.08	16.97	0.37	2.24	16.28	-0.32	-1.93	16.94	0.34	2.08	17.10	0.50	3.00

为更科学地评估该模型的预测效果,采用 MAE、MAPE、MSE、RMSE 和 R^2 分别评价 5 种模型的预测结果,5 种模型的预测值评估结果对比如图 7 所示。

由图 7 可知;与 BP 模型、RF 模型、LSBoost 模型和 SVM 模型相比,KOA-BiLSTM 模型的 MAE、MAPE、MSE 和 RMSE 值最低,分别为 0.38℃、1.6%、0.26 和 0.51。BP 模型、RF 模型、LSBoost 模型、SVM 模型和 KOA-BiLSTM 模型的 R^2 值分别为 0.955 1、0.923 7、0.914 6、0.976 3 和 0.985 7。5 种

模型的 R^2 均接近 1,但 KOA-BiLSTM 模型的 R^2 值最大,表明该模型预测效果最好。预测结果表明;KOA-BiLSTM 模型具有较高的准确性和稳定性,可以提高淋水井筒风温预测精度。

3 可解释性分析

KOA-BiLSTM 模型本身属于“黑盒”模型,无从知道其训练与预测的具体过程。为更深入了解预测模型各个因素敏感性,利用 SHAP 算法对建立模型进行解释性分析。




图 5 5 种模型预测结果对比

Fig. 5 Comparison of prediction results of five models




图 6 5 种模型的绝对误差

Fig. 6 Absolute error of five models




图 7 5 种模型的评估结果对比

Fig. 7 Comparison of evaluation results of five models

SHAP 算法用于解释机器学习模型的预测,基于博弈论中的 SHAP 值。SHAP 值是一种公平分配

博弈的支付,用于确定每个特征对博弈总体结果的贡献,其计算原理如下^[19]:

$$\phi_i = \sum_{S \subseteq N \setminus \{i\}} \frac{|S|! (|N| - |S| - 1)!}{|N|!} (v(S \cup \{i\}) - v(S)) \quad (6)$$

式中: ϕ_i 为第 i 个特征的贡献值 (SHAP 值); N 为所有特征的集合; S 为不包含特征 i 的任何一个特征子集; $|S|$ 为集合 S 中的特征数; $v(S)$ 为特征集 S 对模型预测输出的贡献 (如模型的预测输出); $v(S \cup \{i\})$ 为包含特征 i 的特征集 $S \cup \{i\}$ 对模型预测输出的贡献。基于加性特征属性方法,定义线性函数 f , 即:

$$f(i) = \phi_0 + \sum_{i=1}^N \phi_i x_i \quad (7)$$

式中: $f(i)$ 为样本 i 的事后解释模型预测值 (重要性评分); ϕ_0 为模型预测值的平均值; x_i 为第 i 个特征样本。

由式 (6)、式 (7) 的计算结果,得到了特征变量的重要性排序,以及特征变量对模型预测的影响结果,如图 8、图 9 所示。由图 8 可知:模型特征变量的重要性从大到小排序分别为井口风流温度、井筒深度、井口相对湿度和地面大气压力。其中,井口风流温度对模型预测结果影响最大,是井筒井底风温预测过程中最重要的特征变量。




图 8 特征变量的重要性排序

Fig. 8 Importance ranking of characteristic variables

图 9 中,SHAP 值为正表明特征因素呈正相关,反之亦然。由图 9 可知:SHAP 值随着井口风流温度、井筒深度的增大而增大,即井口风温、井筒深度越大,则井筒底部风温越大。SHAP 值随着井口相对湿度、地面大气压力的增大而减小,即井口相对湿度、地面大气压力越大,则井筒底部风温越小。通过解释性分析知:抑制井底风温升高,最好的方法为控制井口风流温度;其次是减少井筒的深度。




图9 特征变量对模型预测的影响

Fig. 9 The impact of characteristic variables on model prediction




图10 实测值和预测值对比

Fig. 10 Comparison of measured and predicted values

4 风温预测模型实例验证

为验证 KOA-BiLSTM 淋水井筒风温预测模型的通用性和精确性。收集 2023 年 4 月内蒙古鄂尔多斯市某矿井的 5 组实测数据,利用训练好的 KOA-BiLSTM 模型进行验证。矿井的实测数据见表 3,模型预测结果见表 4,预测值和真实值对比如图 10 所示。

表 3 现场实测数据

Table 3 On-site measured data

序号	井口风温/℃	井口风流相对湿度/%	地面大气压力/Pa	井筒深度/m	井底风温/℃
1	12.6	56.9	93 102	420.3	14.2
2	15.5	51.2	93 012	420.3	16.6
3	16.4	53.5	93 162	420.3	17.1
4	14.7	59.4	92 790	420.3	15.9
5	14.3	65.6	92 380	420.3	15.2

表 4 风温预测结果

Table 4 Wind temperature prediction results

真实值/℃	预测值/℃	绝对误差/℃	相对误差/%	MSE
14.2	14.58	0.38	2.67	0.14
16.6	16.10	-0.49	-2.95	
17.1	16.66	-0.44	-2.57	
15.9	15.66	-0.24	-1.51	
15.2	15.43	0.23	1.51	

由表 4 和图 10 可知:文中建立的 KOA-BiLSTM 淋水井筒风温预测模型的相对误差范围为-2.95%~2.67%,绝对误差的绝对值均小于 0.5℃,MSE 值为 0.14。其整体预测精度可以满足矿井风温预测的实际需要,证明该预测模型具有较好的通用性。

5 结 论

1) 相较于优化前的 BiLSTM 模型, KOA-BiLSTM 模型的风温预测精度提高 3.98%。该模型可突破传统建模与单一算法的局限,通过 KOA 算法达成 BiLSTM 超参数自适应寻优,融合双向特征提取机制,有效增强动态热湿耦合环境下的预测鲁棒性。

2) 与 BP 模型、RF 模型、LSBoost 模型和 SVM 模型相比, KOA-BiLSTM 模型在 MAE、MAPE、MSE 和 RMSE 和 R^2 等 5 个指标均为最佳,该模型具有更强的泛化能力和更好的预测效果。

3) 经 SHAP 算法进行可解释性分析知:井口风流温度对模型的预测结果影响最大。这为矿井热害防治提供了关键策略方向,管理人员可聚焦此变量调控,提高井底风温管控效率。

4) 实例验证结果表明: KOA-BiLSTM 模型能满足矿井热害防治对风温预测的精度要求,具有较好的通用性。未来可进一步拓展模型的适应性,纳入更多风温预测相关因素,完善模型体系,为矿井热害防治提供更优方案。

参 考 文 献

[1] 何满潮,武毅艺,高玉兵,等. 深部采矿岩石力学进展[J]. 煤炭学报, 2024, 49(1): 75-99.
HE Manchao, WU Yiyi, GAO Yubing, et al. Research progress of rock mechanics in deep mining[J]. Journal of China Coal Society, 2024, 49(1): 75-99.

- [2] 郭平业,卜墨华,张鹏,等. 高地温隧道灾变机制与灾害防控研究进展[J]. 岩石力学与工程学报, 2023, 42(7): 1 561-1 581.
GUO Pingye, BU Mohua, ZHANG Peng, et al. Review on catastrophe mechanism and disaster countermeasure of high geotemperature tunnels [J]. Chinese Journal of Rock Mechanics and Engineering, 2023, 42(7): 1 561-1 581.
- [3] 郭平业,卜墨华,张鹏,等. 矿山地热防控与利用研究进展[J]. 工程科学学报, 2022, 44(10): 1 632-1 651.
GUO Pingye, BU Mohua, ZHANG Peng, et al. Research progress on the prevention and utilization of mine geothermal energy[J]. Chinese Journal of Engineering, 2022, 44(10): 1 632-1 651.
- [4] 马恒,尹彬,刘剑. 矿井风流温度预测分析研究[J]. 中国安全科学学报, 2010, 20(11): 91-95.
MA Heng, YIN Bin, LIU Jian. Analytical study on the prediction of mine airflow temperature[J]. China Journal of Safety Science, 2010, 20(11): 91-95.
- [5] BASCOMPTA M, ROSSELL J M, SANMIQUEL L, et al. Temperature prediction model in the main ventilation system of an underground mine[J]. Applied Sciences 2020, 20(10): DOI:0. 3390/app10207238.
- [6] ZHOU Gang, CHENG Weimin, NIE Wen, et al. Prediction and study of air thermal parameters in unexploited mine regions based on temperature prediction model in whole ventilation network[J]. Procedia Engineering. 2011, 26: 751-758.
- [7] 孔松,吴建松,孙广京,等. 高温矿井进风井筒及巷道风温预测[J]. 煤矿安全, 2015, 46(10): 199-202.
KONG Song, WU Jiansong, SUN Guangjing, et al. Prediction of wind temperature in intake shafts and roadways of high temperature mines[J]. Coal Mine Safety, 2015, 46(10): 199-202.
- [8] 何启林,任克斌. 深井建井期入风井筒风温的预测[J]. 煤炭工程, 2002, (8): 47-48.
HE Qilin, REN Kebin. Prediction of wind temperature in the shaft during the construction period of deep wells[J]. Coal Engineering, 2002, (8): 47-48.
- [9] 张翔,王伯顺,徐硕,等. 基于 PSO-BP 的矿井淋水井筒风温预测[J]. 煤矿安全, 2012, 43(11): 178-181.
ZHANG Xiang, WANG Baishun, XU Shuo, et al. Prediction of wind temperature in mine drench shaft based on PSO-BP[J]. Coal Mine Safety, 2012, 43(11): 178-181.
- [10] 马恒,刘亮亮. 基于 T-S 模糊神经网络的淋水井筒温度预测分析[J]. 世界科技研究与发展, 2015, 37(3): 226-229.
MA Heng, LIU Liangliang. Temperature prediction analysis of drenching wellbore based on T-S fuzzy neural network[J]. World Science and Technology Research and Development, 2015, 37(3): 226-229.
- [11] 吕品,左金宝,倪小军. 基于 BP 神经网络的矿井淋水井筒风温预测[J]. 煤矿安全, 2008, 39(12): 11-13.
LYU Pin, ZUO Jinbao, NI Xiaojun. Prediction of air temperature in mine drenching shaft based on BP neural network [J]. Coal Mine Safety, 2008, 39(12): 11-13.
- [12] 纪俊红,马铭阳,崔铁军,等. GSK-XGBoost 模型在井底风温预测中的应用[J]. 中国安全生产科学技术, 2022, 18(3): 131-136.
JI Junhong, MA Mingyang, CUI Tiejun, et al. Application of GSK-XGBoost model in prediction of wind temperature at well bottom[J]. Journal of Safety Science and Technology, 2022, 18(3): 131-136.
- [13] 高佳南,马乐天,白金阳,等. 基于 GA-BP 神经网络的淋水井筒风温预测模型[J]. 中国矿业, 2023, 32(11): 96-101.
GAO Jia'nan, MA Letian, BAI Jinyang, et al. Prediction model of airflow temperature of shaft with water dropping based on GA-BP Neural Network[J]. China Mining Magazine, 2023, 32(11): 96-101.
- [14] 程磊,李正健,史浩铭,等. 基于 PSO-Elman 神经网络的井底风温预测模型[J]. 工矿自动化, 2024, 50(1): 131-137.
CHENG Lei, LI Zhengjian, SHI Haorong, et al. A bottom air temperature prediction model based on PSO-Elman neural network[J]. Journal of Mine Automation, 2024, 50(1): 131-137.
- [15] ZHANG Maoqing, LI Wuzhao, ZHANG Liang, et al. A Pearson correlation-based adaptive variable grouping method for large-scale multi-objective optimization[J]. Information Sciences, 2023, 639: DOI: 10. 1016/j. ins. 2023. 02. 055.
- [16] ABDEL-BASSET M, MOHAMED R, AZEEM S A A, et al. Kepler optimization algorithm: a new metaheuristic algorithm inspired by Kepler's laws of planetary motion[J]. Knowledge-Based Systems, 2023, 268: DOI: 10. 1016/j. knosys. 2023. 110454.
- [17] 王兴隆,许晏丰. 基于 AM-LSTM 的飞行区航空器滑行轨迹预测与冲突识别[J]. 中国安全科学学报, 2024, 34(1): 116-124.
WANG Xinglong, XU Yanfeng. Aircraft taxiing trajectory prediction and conflict risk identification in airfield area based on AM-LSTM[J]. China Safety Science Journal, 2024, 34(1): 116-124.
- [18] 林海香,卢冉,陆人杰,等. 融合 BiLSTM-CBA 组合模型的高铁车载设备故障诊断[J]. 中国安全科学学报, 2022, 32(6): 79-86.
LIN Haixiang, LU Ran, LU Renjie, et al. Fault diagnosis of high-speed railway on-board equipment based on BiLSTM-CBA hybrid model[J]. China Safety Science Journal, 2022, 32(6): 79-86.
- [19] LI Ziqi. Extracting spatial effects from machine learning model using local interpretation method: an example of SHAP and XGBoost [J]. Computers, Environment and Urban Systems, 2022, 96: DOI: 10. 1016/j. compenvurbysys. 2022. 101845.



作者简介: 秦跃平 (1964—),男,山西夏县人,博士,教授,主要从事矿井火灾及瓦斯灾害防治、矿井热害防治以及数值模拟方法等方面的研究。E-mail: qyp@cumb.edu.cn。