

基于时序优化长短期记忆网络的采空区 环境多参数预测

张鹏宇¹, 马 砾¹, 石新慧², 王少荣², 李 昭²

(1. 西安科技大学 安全科学与工程学院, 陕西 西安 710054; 2. 鄂尔多斯市转龙湾煤炭有限公司,
内蒙古 鄂尔多斯 017205)

摘要: 采空区煤自燃和有害气体涌出会影响矿井安全生产, 采空区环境预测对隐患识别有重要意义. 本文通过对采空区环境特征数据采集分析, 确定了采空区绝对压力、环境温度、O₂ 浓度和 CO 浓度等环境参数的变化规律, 利用皮尔逊相关系数计算环境特征参数的相关性. 采用经验模态分解法(EMD)对环境特征序列进行自适应时频分解, 利用核主成分分析法(KPCA)将分解后的数据映射到高维特征空间, 建立了基于时序优化的长短期记忆神经网络(LSTM)采空区环境多参数预测模型, 并对某煤矿五采区采空区环境参数进行预测. 结果表明: 采空区环境参数演化具有多尺度、非平稳的时序特性, EMD 分解揭示了参数序列在不同时间尺度上的本征特征; O₂ 浓度波动与绝对压力变化表现出明显的相关性, CO 浓度和温度序列则呈现出较强的非线性和突变特征; 基于 KPCA 的降维处理保留了 98.12% 的数据信息量, 显著降低了特征冗余. 时序优化后的 LSTM 模型在预测性能上取得显著提升, 相比优化前的模型, 优化后模型的预测精度大幅提高, 具有较高的泛化能力和鲁棒性, 挖掘关联环境参数序列间的耦合关系, 提高了采空区环境参数预测的精度.

关键词: 煤自燃; 大面积采空区; 时间序列; 特征提取; 深度学习

中图分类号: TD 752 **文献标志码:** A **文章编号:** 1000-1964(2025)03-0653-14

Multi-parameter prediction of goaf environment based on time-series optimized long short-term memory network

ZHANG Pengyu¹, MA Li¹, SHI Xinhui², WANG Shaorong², LI Zhao²

(1. School of Safety Science and Engineering, Xi'an University of Science and Technology, Xi'an, Shaanxi 710054, China;
2. Ordos Zhuanlongwan Coal Co., Ltd., Erdos, Inner Mongolia 017205, China)

Abstract: Spontaneous combustion of coal and harmful gas emissions in goaf areas affect mine safety production, making environmental prediction in these areas crucial for hazard identification. Environmental characteristic data from goaf areas were collected and analyzed to determine the variation patterns of absolute pressure, temperature, O₂ concentration, and CO concentration, with correlations between parameters calculated using Pearson correlation coefficients. Empirical Mode Decomposition (EMD) was applied for adaptive time-frequency decom-

收稿日期: 2024-12-11 修回日期: 2025-03-11 DOI: 10.13247/j.cnki.jcmt.20240579

基金项目: 国家自然科学基金面上项目(52174206)

通信作者: 马 砾(1978—), 男, 四川省隆昌市人, 教授, 博士生导师, 工学博士, 从事灾害应急防控方面的研究.

E-mail: mal@xust.edu.cn Tel: 13759928279

引用格式: 张鹏宇, 马 砾, 石新慧, 等. 基于时序优化长短期记忆网络的采空区环境多参数预测[J]. 中国矿业大学学报, 2025, 54(3): 653-666.

ZHANG Pengyu, MA Li, SHI Xinhui, et al. Multi-parameter prediction of goaf environment based on time-series optimized long short-term memory network[J]. Journal of China University of Mining & Technology, 2025, 54(3): 653-666.

position of environmental characteristic sequences, while Kernel Principal Component Analysis (KPCA) was used to map the decomposed data into high-dimensional feature space. A Long Short-Term Memory (LSTM) neural network model with time-series optimization was developed to predict multiple environmental parameters in the No. 5 mining district goaf of a coal mine. The results show that environmental parameters in goaf exhibit multi-scale and non-stationary temporal characteristics, with EMD decomposition revealing intrinsic features of parameter sequences at different time scales. O_2 concentration fluctuations show significant correlation with absolute pressure changes, while CO concentration and temperature sequences demonstrate strong nonlinearity and abrupt features. The dimensionality reduction through KPCA preserves 98.12% of the data information content while significantly reducing feature redundancy. The LSTM model after time series optimization has achieved significant improvement in prediction performance. Compared with the non-optimized models, the prediction accuracy of the optimized model has been greatly improved, and it has high generalization ability and robustness. This approach effectively mines coupling relationships between environmental parameters, thereby improving the accuracy of goaf environmental parameter prediction.

Key words: coal spontaneous combustion; large-area goaf; time series; feature extraction; deep learning

随着矿井开采范围的增加,相邻多个工作面生产结束封闭后,形成大面积采空区^[1-2]。采空区环境复杂,具有气体成分多样、空间分布不均和时序动态波动等特点,其演化过程受采掘活动、通风系统、地质条件以及大气压力等多种因素影响,呈现出显著的非线性和非平稳特性。采空区气体受内部和外部环境条件变化的影响出现异常涌出现象,威胁矿井安全生产^[3]。因此,采空区环境参数的准确预测对隐患风险识别和灾害超前防控具有重要意义^[4-5]。

采空区环境参数主要包括温度、压力和气体浓度,学者们针对环境参数预测做了大量研究^[6-7]。文献[8]分析大气压力波动对采空区瓦斯涌出的影响,采用粒子群优化算法建立瓦斯参数的反演预测模型。文献[9]提出了基于相空间重构理论和自适应混沌粒子群优化支持向量机的瓦斯浓度预测模型。文献[10]采用程序升温试验指标气体数据作为输入,建立改进灰狼算法优化支持向量回归模型,预测采空区煤自燃温度。文献[11]基于低温氧化试验数据建立遗传算法优化支持向量回归模型,预测采空区 CO 浓度。文献[12-13]通过采集采空区现场气体数据,建立了参数优化的 PSO-RF 和 PSO-SVM 采空区温度预测模型。上述采空区环境参数预测模型能够挖掘参数内部变化机制并做出预测,随着矿井智能化发展,井下监测数据量快速增长,需要对多元环境序列信息有效利用^[14-15]。采空区环境参数序列信息之间变化

关系复杂,模型输入变量增多导致收敛计算速度减慢,并出现过拟合问题,限制了预测模型精度^[16-18]。长短期记忆网络(LSTM)对于复杂多维时间序列具有较高的预测精度,已广泛应用于能源预测领域^[19-21]。

针对采空区环境参数序列的非平稳性强、参数间非线性关系复杂等特点,本文提出了一种基于时序优化的 LSTM 采空区环境多参数预测方法。采用经验模态分解法(EMD)对环境数据中不同尺度的波动和趋势进行自适应时频分解,揭示数据的多尺度特征;利用核主成分分析法(KPCA)将分解后数据映射到高维特征空间,筛选出影响采空区环境参数的关键因子,消除环境序列的冗余性和相关性;最后,将降维后的数据作为 LSTM 模型输入变量,建立采空区环境多参数预测模型,实现对环境参数的高精度预测。该方法有效解决了传统预测模型面临的技术难题,提高了预测的准确性和稳定性。

1 采空区环境参数采集

1.1 工程概况

某矿五采区位于井田的北翼,采区南北走向长约 2.89 km,东西倾斜长约 2.35 km,面积为 6.78 km²。五采区除 5316 综放面外,其余工作面均已停采,形成大面积采空区。采区内均为 3 号可采煤层,Ⅱ类自燃煤层,最短自然发火期为 32 d。矿井采用立井开拓方式,两翼对角式通风,通风方

法为抽出式。矿井瓦斯相对涌出量为 $0.35 \text{ m}^3/\text{t}$ ，矿井瓦斯绝对涌出量为 $4.30 \text{ m}^3/\text{min}$ ，矿井二氧化碳相对涌出量为 $1.47 \text{ m}^3/\text{t}$ ，矿井二氧化碳绝对涌出量为 $17.92 \text{ m}^3/\text{min}$ ，矿井瓦斯等级为低瓦斯矿井。五采区通风系统如图 1 所示。

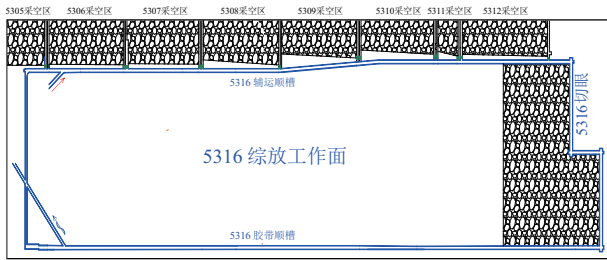


图 1 五采区通风系统示意

Fig. 1 Schematic diagram of ventilation system in the fifth mining area

利用采空区环境多参数无线监测系统对采空区密闭内外的环境参数进行采集，采样间隔为 1 min ，该系统由多参数合一无线监测传感器装置（包括 CO 、 O_2 、 CO_2 、 N_2 、 CH_4 、 C_2H_2 、 C_2H_4 气体浓度（体积分数 φ ）及温度、环境湿度、绝对压力等多元信息参数）、无线监测主机分站、地面信息传输软件系统 3 部分组成。监测系统构架如图 2 所示。

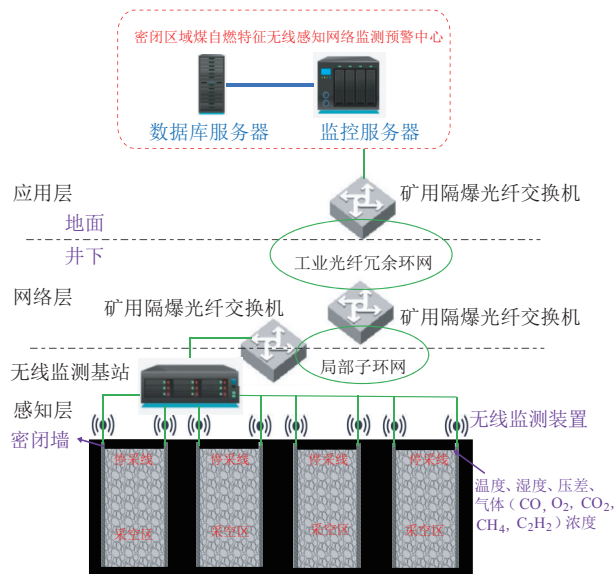


图 2 采空区环境多参数无线监测系统

Fig. 2 Multi parameter wireless monitoring system of goaf

多参数无线监测传感器通过模块化集成设计实现环境多参数同步监测，将不同检测原理的传感器集成于同一装置内，通过中央处理单元实现统一数据采集与处理。其中， CO 和 O_2 采用电化学传感器，通过转换电路将检测信号输入处理器； CH_4 采用近红外光谱原理传感器，具有温度补偿功能；温湿度采用数字式 SHT11 传感器，通过 I2C

总线传输数据；绝对压力采用 MPXV7007 压阻式传感器测量。各传感器输出信号经过信号调理电路，由 STM32F103 微处理器统一采集处理，经 LoRa 无线模块发送至主机分站。装置采用低功耗设计，具备主动泵吸功能，可根据需要选择采样间隔切换工作模式。为监测采空区内部气体运移情况，在 5306 采空区施工监测钻孔，高度为 1.5 m ，深度为 6 m ，接入多参数无线监测传感器。多参数无线监测传感器置于钻孔端部，钻孔口作密封处理，隔绝外界环境影响。无线监测主机固定于距离密闭墙 1.5 m 处的巷道帮部，高度为 1.2 m ，便于人员观测。

1.2 数据集的组成

数据采集时间为 2022 年 7 月 8 日至 7 月 12 日，采样地点在 5306 辅运顺槽密闭空间。在该时间段无线监测系统运行情况良好，数据在短时间内变化趋势稳定，数据来源可靠。该矿为低瓦斯矿井，监测地点 CH_4 浓度较低，且监测期间未发生煤自燃，没有生成 C_2H_2 、 C_2H_4 和 C_2H_6 气体。如果将这些特征引入模型会增加计算复杂度，降低模型对主要特征参数变化的敏感性，对采空区环境变化特征表征贡献有限。因此，不考虑将 CH_4 、 C_2H_2 、 C_2H_4 、 C_2H_6 气体特征作为模型的训练数据。选取 O_2 浓度、 N_2 浓度、 CO_2 浓度、 CO 浓度、温度 (T)、环境湿度 (φ)、环境压力 (P_0)、绝对压力 (ΔP) 特征进行研究，计算环境特征间相关系数，利用皮尔逊相关系数分析各环境因素特征之间的相关程度，见式(1)。

$$r_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}}, \quad (1)$$

式中： r_{xy} 为各影响因素之间的相关系数； n 为样本总数； x_i 和 y_i 分别为第 i 个数据点的不同因素的值； \bar{x} 和 \bar{y} 分别为不同因素的平均值。

采空区密闭空间内外绝对压力是判断采空区气体运移方向和运移强度的重要参数。如图 3 所示，图中圆圈的大小表示相关性的绝对值大小，即相关性强度，圆圈越大表示相关性越强；圆圈的颜色表示相关性的方向和强度，蓝色表示正相关，红色表示负相关，颜色越深表示相关性越强；右侧色条显示了皮尔逊相关系数的量化范围为 $-1 \sim 1$ 。从图 3 中可以观察到， O_2 与 CO_2 呈显著负相关，相关系数为 -0.93 ，反映了采空区内煤炭氧化过程中 O_2 消耗与 CO_2 生成的化学计量关系。 CO 与

其他参数的相关性普遍较弱,这是由于在采空区正常状态下,CO 浓度通常接近于 0,仅在煤自燃发生时才会显著升高,因此其相关性难以通过常态数据得到充分体现.绝对压力与 O_2 浓度呈正相关,相关系数为 0.60,表明压差变化会直接影响采空区气体运移情况;与温度的相关性较弱,相关系数仅为 0.11,这是由于采空区温度变化主要受煤体氧化放热过程控制.

考虑到温度和 CO 浓度是研判采空区煤自燃发展阶段最敏感的特征参数,虽然 CO 在常态监测数据中表现出较弱的相关性,在图 3 中表现为较小的圆圈,但其突变性增长对预警具有重要意义;同时 O_2 浓度作为支持煤自燃持续发展的必要条件,与绝对压力共同影响着采空区的漏风和气体运移规律.因此,选择温度、CO 浓度、 O_2 浓度和绝对压力作为模型的关键特征参数,可以全面反映采空区的安全状态,为预测模型提供有效的输入变量.

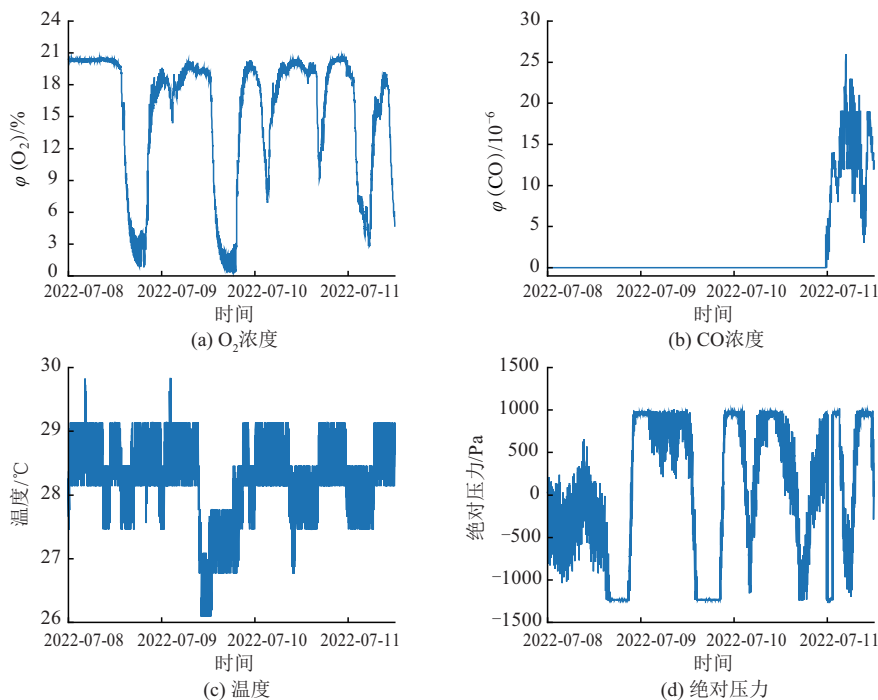


图 4 不同环境参数随时间的变化特征

Fig. 4 Temporal variation characteristics of different environmental parameters

从时序曲线特征可以看出,4 个环境参数均呈现显著的非线性和非平稳特征.其中, O_2 浓度、绝对压力和温度均表现出明显的准周期性波动,反映了采空区环境参数的动态变化规律. O_2 浓度和绝对压力的周期性波动呈现一定的相位关系,波动幅值和周期间隔存在差异,体现了采空区气体运移的动态特性;温度曲线同样展现出显著的周期性起伏,主要受矿井昼夜温差变化和通风系统运行周期的影响,但同时也包含不规则的随机扰

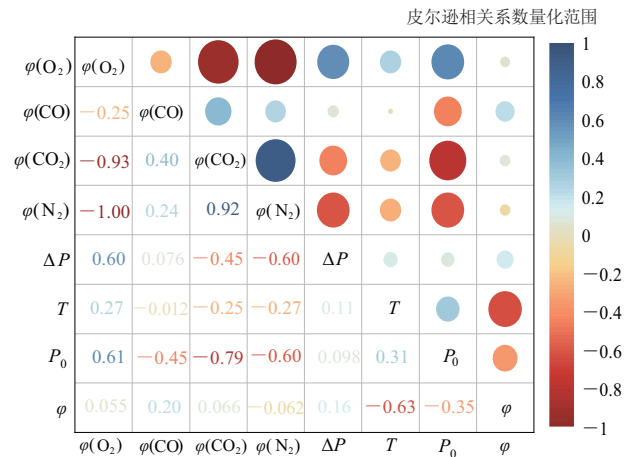


图 3 采空区环境参数之间的相关性分析矩阵

Fig. 3 Correlation analysis matrix of environmental parameters in the goaf area

选取 2022 年 7 月 8 日 0 时至 2022 年 7 月 11 日 12 时的采空区环境参数监测数据进行分析,如图 4 所示.

动分量;CO 浓度则呈现典型的突变性和随机性特征,反映了采空区局部环境的瞬态变化规律.这些曲线特征揭示了采空区环境演化的本质,既存在着由通风系统、环境温差等因素主导的确定性周期变化,又受到煤体氧化、漏风扰动等不确定因素的随机影响.这种多尺度、非平稳的时序特性使得环境参数变化呈现出复杂的非线性特征.从监测数据中可以发现, O_2 浓度的波动与绝对压力的变化具有一定的相位关系,表明气体运移受压力场

主导；温度序列中的高频波动与 CO 浓度的突变性增长在时间上存在对应关系，反映了采空区热量积累与煤体氧化过程的内在联系。这种参数间的耦合变化规律和多重动态特征，对预测模型提出了较高要求，需要模型同时具备捕捉多尺度时序特征、处理非线性关系以及适应参数突变的能力。环境参数序列表现出的周期性与随机性耦合特征，揭示了采用传统线性预测方法难以实现预期效果，需要引入能够处理确定性分量和随机性分量的预测算法。

2 预测模型构建

2.1 模型原理

2.1.1 经验模态分解法(EMD)

EMD 是一种复杂信号的处理方法，具有自适应性强、多尺度分解和无损分解等特点。其核心是根据信号的局部特征自适应地找到本征模态函数(IMF)，因此适用于分析非线性、非平稳的时间序列信号。由于采空区 4 种环境参数存在随机性和波动性特征，通过 EMD 将环境序列信号在不同时间尺度上的信息分离出来，分解为不同数量的本征模态函数和一个剩余分量，揭示信号在不同时间尺度上的特征，从而为后续的信号分析、特征提取和趋势分析提供基础。其具体分解过程^[22]如下：

1) 极值点识别：对给定的原始信号 $x(t)$ ，找到其所有极大值和极小值点。根据极大值点和极小值点分别构建上包络线和下包络线。

2) 计算包络线均值：上包络线和下包络线之间的局部平均值记为 $m(t)$ ，随后将其从原始信号中扣除，得到第一个本征模态函数的候选分量 $h_1(t)$ 。

$$h_1(t) = x(t) - m(t). \quad (2)$$

3) 反复筛选：将 $h_1(t)$ 视为新的数据，重复上述过程，直到 $h_1(t)$ 满足 IMF 的 2 个特性，即极值点和过零点数量相差不超过 1，且局部均值为 0。形成的 $h_1(t)$ 即为第一个 IMF 分量。

4) 剩余信号处理：从原始信号中扣除第一个 IMF 分量，得到一个新的剩余信号。将剩余信号 $r_1(t)$ 作为新的输入，重复上述过程，直至剩余信号变为单调函数或没有本征模态可提取。

$$r_1(t) = x(t) - h_1(t). \quad (3)$$

5) 最终原始信号 $x(t)$ 被分解为若干个 IMF 分量 $q_i(t)$ 和一个剩余分量 $r_n(t)$ ：

$$x(t) = \sum_{i=1}^n q_i(t) + r_n(t). \quad (4)$$

2.1.2 核主成分分析法(KPCA)

原始数据在经过 EMD 分解后，数据特征的扩导致模型输入维度增加。为保证后续 LSTM 模型的预测精度，防止模型过拟合，引入 KPCA 方法对高维数据特征降维处理，降低模型计算复杂度，保证环境数据的有效性和代表性^[23-24]。

KPCA 是主成分分析法(PCA)的一种非线性扩展方法。与传统 PCA 只能捕捉数据的线性特征不同，KPCA 通过引入“核技巧”，将数据映射到高维特征空间，在高维空间中进行 PCA 运算，从而能够提取数据的非线性特征。算法步骤如下：

1) 假设原始数据集为 $X = \{x_1, x_2, \dots, x_n\}$ ，通过一个非线性映射函数 Φ ，将数据从低维空间映射到高维特征空间，使数据在高维空间中更容易被线性分离：

$$x_i \rightarrow \Phi(x_i). \quad (5)$$

2) 通过核函数 $k(x_i, x_j) = [\Phi(x_i), \Phi(x_j)]$ 实现隐式计算高维特征空间中的内积，避免了直接计算映射函数 $\Phi(x)$ ，本研究采用高斯核函数实现这一过程：

$$k(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right), \quad (6)$$

式中 σ 为高斯核函数的带宽参数，控制函数的平滑程度。

3) 通过核函数，构造核矩阵 \mathbf{K} ，其中 $\mathbf{K}_{ij} = k(x_i, x_j)$ 。为了确保数据在高维空间中是中心化的(即均值为 0)，需要对核矩阵 \mathbf{K} 进行中心化。中心化核矩阵 \mathbf{K}' 的计算公式为

$$\mathbf{K}' = \mathbf{K} - \mathbf{I}_n \mathbf{K} - \mathbf{K} \mathbf{I}_n + \mathbf{I}_n \mathbf{K} \mathbf{I}_n, \quad (7)$$

式中 \mathbf{I}_n 为 $n \times n$ 维的矩阵。

4) 在中心化后的核矩阵 \mathbf{K}' 上进行特征值分解，求解 \mathbf{K}' 的特征值和特征向量：

$$\mathbf{K}' \mathbf{v}_i = \lambda \mathbf{v}_i, \quad (8)$$

式中： λ 为特征值； \mathbf{v}_i 为对应的特征向量。

5) 得到特征值和特征向量后，可以选择前 k 个最大特征值对应的特征向量排列成矩阵，作为降维后数据的主要成分。

2.1.3 长短期记忆神经网络(LSTM)

LSTM 模型是一种特殊的递归神经网络(RNN)，专门用于解决标准 RNN 难以捕捉长期依赖关系的问题^[25]。LSTM 的核心是引入了“记忆单元”和“门”控机制。分别为遗忘门、输入门和输出门，用于选择性地添加或移除信息，从而控制数据的流动，使得其能高效处理非平稳、长时间依赖的序列数据^[26]。

对于序列 $x = (x_1, x_2, \dots, x_a)$, 当前 t 时刻的隐藏状态向量 h_t 和当前节点状态下的输出向量 y_t 计算如下。

$$h_t = f_a(W_{xh}x_t + W_{hh}h_{t-1} + b_h), \quad (9)$$

$$y_t = W_{xy}h_t + b_y, \quad (10)$$

式中: W_{xh} 为输入到隐藏状态的权重矩阵, 连接输入层和隐藏层; W_{hh} 为隐藏状态转移权重矩阵, 连接前一时刻和当前时刻的隐藏状态; W_{xy} 为隐藏状态到输出的权重矩阵, 连接隐藏层和输出层; x_t 为 t 时刻的输入向量; h_{t-1} 为 $t-1$ 时刻的隐藏状态向量, 作为记忆信息传递给当前时刻; b_h 为隐藏层的偏置向量; b_y 为输出层的偏置向量; f_a 为激活函数。

LSTM 模型的网络结构如图 5 所示, 遗忘门用于决定记忆单元的遗忘部分, 遗忘门的输出是一个介于 0 和 1 之间的值, 表示需要遗忘的比例。输入门控制新信息的流入, 决定信息的更新和记忆内容。输出门控制当前时刻的隐藏状态输出, 图中的“+”符号表示元素级加法运算, 用于将不同信息流进行融合, “×”符号表示元素级乘法运算, 是实现门控机制的核心操作, 通过乘法控制信息通过的比例, 其前向计算过程如下:

$$i_t = S(W_{xi}x_t + W_{hi}h_{t-1} + W_{ci}c_{t-1} + b_i), \quad (11)$$

$$f_t = S(W_{xf}x_t + W_{hf}h_{t-1} + W_{cf}c_{t-1} + b_f), \quad (12)$$

$$c_t = f_t c_{t-1} + i_t \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c), \quad (13)$$

$$o_t = S(W_{xo}x_t + W_{ho}h_{t-1} + W_{co}c_{t-1} + b_o), \quad (14)$$

$$h_t = o_t \tanh(c_t), \quad (15)$$

式中: i_t 为输入门向量, 控制当前输入信息流入记忆单元的比例; f_t 为遗忘门向量, 控制上一时刻记忆单元信息保留的比例; c_t 为记忆单元向量, 存储长期依赖信息; c_{t-1} 为前一时刻的记忆单元向量; o_t 为输出门向量, 控制记忆单元信息流向隐藏状态的比例; W_{xi} 为输入向量到输入门的权重矩阵; W_{hi} 为前一隐藏状态到输入门的权重矩阵; W_{ci} 为前一记忆单元到输入门的权重矩阵; W_{xf} 为输入向量到遗忘门的权重矩阵; W_{hf} 为前一隐藏状态到遗忘门的权重矩阵; W_{cf} 为前一记忆单元到遗忘门的权重矩阵; W_{xc} 为输入向量到候选记忆单元的权重矩阵; W_{hc} 为前一隐藏状态到候选记忆单元的权重矩阵; W_{xo} 为输入向量到输出门的权重矩阵; W_{ho} 为前一隐藏状态到输出门的权重矩阵; W_{co} 为当前记忆单元到输出门的权重矩阵; b_i 为输入门的偏置向量; b_f 为遗忘门的偏置向量; b_c 为候选记忆单元的偏置向量; b_o 为输出门的偏置向量; \tanh 为双曲正切激活函数; S 为 sigmoid 激活函数。

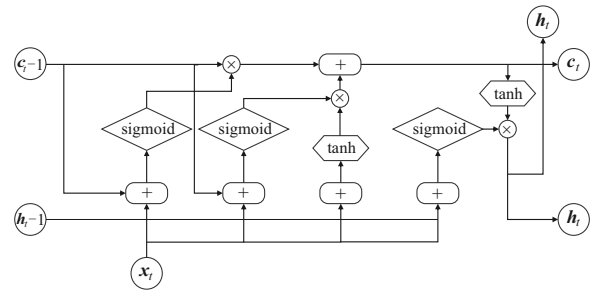


图 5 LSTM 隐含层细胞结构

Fig. 5 LSTM hidden layer cell structure

2.2 模型构建过程

基于上述理论基础, 本文针对采空区环境参数序列非平稳性、多尺度特征和参数间耦合关系复杂等特点, 设计了时序优化 LSTM 预测模型. 将 EMD 多尺度分解与 KPCA 非线性降维相结合, 实现对 LSTM 输入数据的时序特征优化, 有效解决了传统预测模型在处理采空区复杂环境参数时面临的技术难题。

时序优化的优势具体体现在以下 3 个方面: 首先, EMD 分解能够自适应地将环境参数序列分解为不同频率尺度的本征模态函数, 捕捉参数在多个时间尺度上的变化特征, 有效处理数据的非平稳性; 其次, KPCA 通过核函数将数据映射到高维特征空间, 提取非线性主成分, 在保留关键信息的同时大幅降低特征维度, 减少计算复杂度; 最后, 优化后的特征输入 LSTM 网络, 充分利用其对长时序依赖关系的建模能力, 实现多参数的高精度预测. 这种时序优化策略显著提高了模型对采空区环境参数突变特性和复杂关联性的识别能力. 与传统方法相比, 时序优化策略解决了原始数据非平稳性导致的预测误差累积问题, 并能同时捕捉多个环境参数之间的动态耦合关系, 有效避免了输入维度增加导致的过拟合问题, 增强了模型的泛化能力和鲁棒性. 图 6 为时序优化 LSTM 方法的设计流程, 主要步骤如下:

1) 数据预处理: 对采集到的环境特征序列数据进行系统化预处理, 包括缺失值处理、异常值识别和数据归一化. 预处理确保数据在统一尺度上, 避免训练过程中出现数值不稳定的情况, 提高模型的收敛速度和预测精度。

2) 经验模态分解: 对预处理后的环境时间序列数据进行 EMD 分解, 将非线性非平稳的原始信号分解为多个 IMF 和一个残余项. 每个 IMF 代表不同时间尺度下的波动成分, 共同构成原始信号的完整表达, 特别适合处理采空区环境参数序列所表现出的非平稳多尺度特性. EMD 分解使得模

型能够分别捕捉数据在不同频率上的变化规律,将原始环境信号中的周期性波动、随机扰动和长期趋势进行了有效分离。

3)核主成分分析:对每个 IMF 分量进行 KP-CA 分析,提取其中的主要非线性特征,减少数据维度.选择径向基函数作为核函数,通过构造核矩阵并解析其特征值问题,选取主要特征分量.通过 KPCA 处理,有效提取了 IMF 中的非线性特征结构,克服了传统 PCA 只能提取线性关系的局限性,为后续 LSTM 建模提供了更具代表性的特征

输入。

4)LSTM 模型构建:将经 EMD-KPCA 处理后的特征序列重构为输入和目标样本集合,并分为训练集和测试集. LSTM 网络结构包括多层 LSTM 层、Dropout 层和全连接输出层.模型训练采用 Adam 优化器,并使用早停策略防止过拟合。

5)模型性能评价:采用误差评价指标对模型性能进行评估,分析模型在不同环境条件下的预测稳定性。

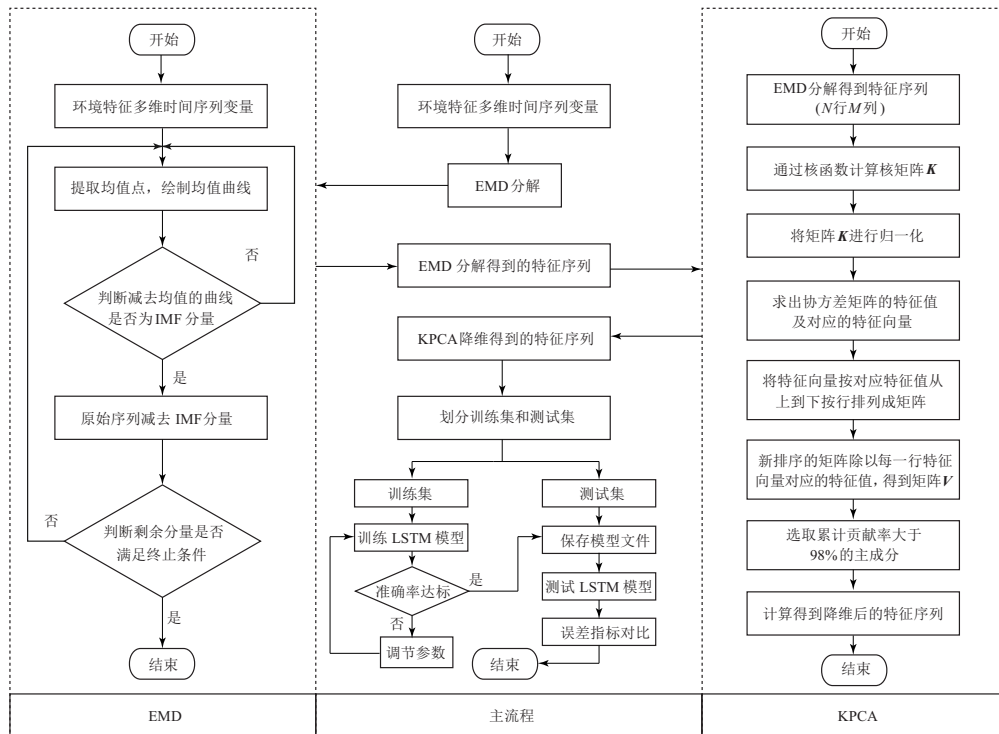


图 6 基于时序优化 LSTM 的预测流程

Fig. 6 Prediction process based on time-series optimized LSTM

2.3 模型性能评价

为全面评估预测模型的性能,本研究选用了 3 种互补的误差分析指标.平均绝对误差 (E_{MAE}) 量化预测值与实际值的平均偏差,直观反映预测精度;均方根误差 (E_{RMSE}) 通过平方项放大较大误差,更敏感地反映异常预测情况;确定系数 (R^2) 则衡量模型对数据变异性的解释能力,值越接近 1 表示模型拟合效果越好.这 3 种指标从不同角度综合评价模型性能, E_{MAE} 和 E_{RMSE} 值越小、 R^2 值越大,表明模型预测精度越高,见式(16)~式(18)。

$$E_{MAE} = \frac{1}{m} \sum_{i=1}^n |f_i - y_i|, \quad (16)$$

$$E_{RMSE} = \sqrt{\frac{1}{m} \sum_{i=1}^n (f_i - y_i)^2}, \quad (17)$$

$$R^2 = 1 - \frac{\sum_{i=1}^m (f_i - y_i)^2}{\sum_{i=1}^m (\bar{y} - y_i)^2}, \quad (18)$$

式中: y_i 为实际值; f_i 为预测值; \bar{y} 为实际值的平均值; m 为预测值的个数。

3 实例分析

3.1 模型设置与参数选择

本研究采用 2022 年 7 月 8 日 0 时至 7 月 11 日 12 时的监测数据构建 LSTM 网络模型,数据采集频率为 1 次/min.共获取 5 040 组训练样本 (1440 组/d×3.5 d),测试数据选取 7 月 11 日 12 时至 7 月 12 日 0 时的 720 组样本.输入数据为经 KPCA 降维后得到 10 个主成分特征. LSTM 模型结构如下:输入层序列长度为 1,特征维度为 10;单个隐藏层包含 100 个神经元;输出层维度为 1,用

于预测未来时刻的环境参数. 训练过程采用 Mini-batch 方式, 批次大小为 10, 迭代 500 轮, 使用 Adam 优化器进行参数更新. 这种网络配置充分考虑了采空区环境参数的时序特性和非线性关系, 既保证了模型的学习能力, 又避免了结构过于复杂导致的过拟合问题.

本研究中所用的 BP 神经网络模型采用 3 层结构, 包含输入层、隐含层和输出层. 其中输入层节点数与输入特征维度相同, 隐含层节点数为 15, 输出层节点数为 1. 隐含层采用双曲正切 S 型传递函数 Tansig, 输出层采用线性传递函数 Purelin. 训练采用 Levenberg-Marquardt 算法 Trainlm, 最大训练次数设置为 1 000, 学习率为 0.01, 训练目标最小误差设为 0.000 01. 其他模型都是基于 LSTM 模型构建, 为保证结果的可比性, 参数设置保持一致. LSTM 网络模型参数是基于深度学习最佳实践和采空区环境数据特性确定的. 设置初始学习率为 0.01, 可以在训练初期提供适当的参数更新力度, 避免训练过程中的不稳定性. 为优化训练后期的收敛质量, 引入了 0.2 的学习率调整因子, 使模型在接近最优解时能进行更加精细的参数调整. 隐藏层包含 100 个神经元, 这一规模考虑了输入特征维度与数据复杂性的平衡, 足以捕捉环境参数中的复杂非线性时序关系. 批处理大小

选择 25 个样本, 既保证了计算效率, 又维持了梯度计算的准确性. 模型训练的最大迭代次数设为 1 000, 并结合早停机制, 在验证集性能不再提升时及时终止训练, 有效防止过拟合现象. 采用 L2 正则化策略来控制模型复杂度, 抑制权重参数过大, 提高模型在不同环境条件下的泛化能力. 优化算法选用 Adam, 其自适应调整特性能够有效处理非平稳时间序列数据. 设置梯度阈值为 1, 保证训练过程的数值稳定性. 试验环境采用处理器 AMD R7-4800H, CPU 频率 2.9 GHz, 内存 16 GB, 操作系统 Windows 10(64 位), 程序设计语言为 Matlab-R2020b.

3.2 结果与分析

3.2.1 EMD 分解结果

采空区环境参数的时间序列呈现出非平稳特性, 且由于地下环境的复杂性, 这些序列往往具有随机性和突变性. 为揭示数据的多尺度结构和内在模式, 利用 EMD 对原始环境数据进行处理. 图 7 展示了 EMD 分解结果, 清晰地呈现了原始环境序列的局部特征和振荡模式. 表 1 展示了各环境参数 EMD 分解后得到的 IMF 数量及残余项. 分析表明, 全部环境参数共产生 42 个 IMF 分量和 4 个残余项, 总计 46 维特征序列作为新的特征序列集合.

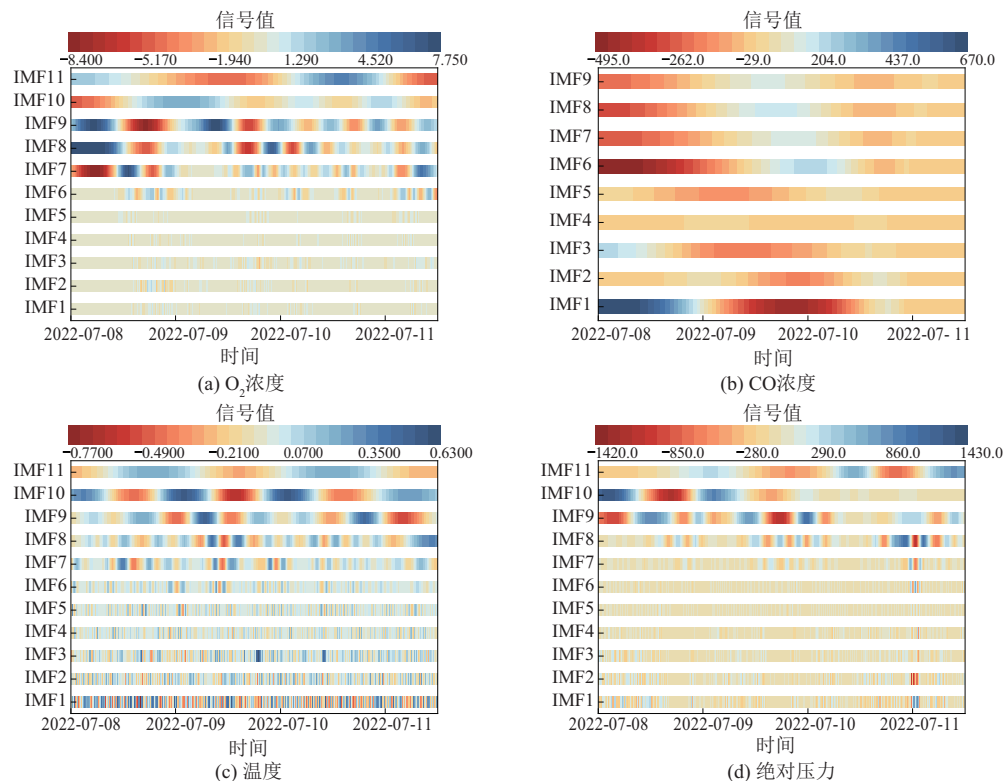


图 7 EMD 分解后的环境特征

Fig. 7 Environmental characteristics after EMD decomposition

O₂ 浓度序列分解得到 11 个 IMF 分量,其中高阶 IMF 分量(IMF7~IMF11)呈现出明显的低频特征,对应着 O₂ 浓度的主要周期性变化;CO 浓度序列得到 9 个 IMF 分量,其中 IMF1 和 IMF2 包含了高频突变信息,反映了 CO 浓度的瞬态波动特征. 温度序列分解为 11 个 IMF 分量,信号能量主要集中在 IMF8~IMF11,表明温度变化以低频周期波动为主;绝对压力序列获得 11 个 IMF 分量,其中 IMF9~IMF11 的振幅较大,体现了压力场的主导周期特征,而低阶 IMF 分量则反映了短期扰动信息. 通过 EMD 分解,环境参数序列被自适应地分解为不同频率尺度的固有模态函数,为后续提取关键特征、消除随机噪声提供了基础.

表 1 环境数据的分解结果

环境特征数据	IMF 分量数量	剩余分量数量
O ₂ 浓度	11	1
CO 浓度	9	1
温度	11	1
绝对压力	11	1

3.2.2 KPCA 降维结果

为消除 EMD 分解引入的数据冗余,采用 KPCA 法对特征序列进行非线性降维处理. 对 4 个环境参数的 46 维特征进行 KPCA 分析,其中包含 42 个 IMF 分量和 4 个残余项,结果如表 2 所示. 前 10 个主成分的特征值分布在 9.53×10^{-4} 至 2.53×10^{-5} 之间,累计方差贡献率达到 98.12%. 选择 98% 作为累积贡献率阈值是基于信息保留与

表 2 核主成分分析方差贡献率

Table 2 Variance contribution rate of kernel principal component analysis

成分	特征值	方差贡献率/%	累计贡献率/%	成分	特征值	方差贡献率/%	累计贡献率/%
1	9.53×10^{-4}	32.01	32.01	10	2.53×10^{-5}	0.85	98.12
2	6.97×10^{-4}	23.42	55.43	11	1.51×10^{-5}	0.51	98.66
3	4.27×10^{-4}	14.35	69.78	12	1.23×10^{-5}	0.41	99.07
4	3.79×10^{-4}	12.73	82.51	13	1.17×10^{-5}	0.39	99.46
5	2.23×10^{-4}	7.48	89.99	⋮	⋮	⋮	⋮
6	9.97×10^{-5}	3.35	93.34	43	1.14×10^{-8}	0.00	100.00
7	5.64×10^{-5}	1.90	95.24	44	1.01×10^{-8}	0.00	100.00
8	3.08×10^{-5}	1.04	96.28	45	9.76×10^{-9}	0.00	100.00
9	2.95×10^{-5}	0.99	97.27	46	9.22×10^{-9}	0.00	100.00

3.2.3 LSTM 模型预测结果

为验证时序优化 LSTM 模型的预测性能,本研究将其与 BP 神经网络、标准 LSTM 模型和

维度降低的平衡考量,该阈值能在保留数据主要变化特征的同时有效降低特征维度. 第一主成分和第二主成分的方差贡献率分别为 32.01% 和 23.42%,共计解释了 55.43% 的数据变异. 第三、四主成分的贡献率分别为 14.35% 和 12.73%,反映了重要的非线性特征信息. 第五至第十主成分单个贡献率相对较小,从 7.48% 递减至 0.85%,但对捕捉数据的局部特征具有重要作用. 第十主成分之后的成分贡献率均小于 0.5%,主要反映了数据中的随机波动和测量噪声,将其纳入模型不仅无法提供有效信息,反而会增加计算复杂度. 表 3 给出了前 10 个主成分对应的特征向量,第一主成分在各 IMF 分量上的权重为 $-3.66 \times 10^{-2} \sim -3.71 \times 10^{-2}$,体现了对原始特征的稳定表达能力;后续主成分的特征向量呈现出数量级递减的特点,反映了不同尺度特征的重要性差异. 通过此方法获得的 10 个主成分既保留了原始 46 维数据中的关键信息,又显著降低了特征维度,为后续 LSTM 模型提供了高质量的输入特征.

基于 KPCA 的降维结果,选取前 10 个主成分作为预测模型的输入特征,既保留了环境参数序列 98% 以上的信息量,又将特征维度从 46 维降至 10 维,显著降低了模型的计算复杂度. 这种非线性降维方法不仅提取了 EMD 分解得到的多尺度特征中的关键信息,而且有效解决了特征集中的信息冗余问题,为后续 LSTM 模型的训练提供了高质量的输入样本.

EMD 优化 LSTM 模型进行对比,结果如图 8 和表 4 所示.

表 3 核主成分分析特征向量
Table 3 Eigenvectors calculated by kernel principal component analysis

主成分	1	2	3	4	5	6	7	8	9	10
1	-3.66×10^{-2}	3.51×10^{-3}	1.16×10^{-3}	-9.54×10^{-3}	-3.00×10^{-3}	8.72×10^{-3}	4.65×10^{-3}	2.05×10^{-2}	2.40×10^{-3}	-1.55×10^{-3}
2	-3.67×10^{-2}	3.46×10^{-3}	1.17×10^{-3}	-9.55×10^{-3}	-2.87×10^{-3}	1.63×10^{-2}	4.56×10^{-3}	1.90×10^{-2}	1.67×10^{-3}	-1.83×10^{-3}
3	-3.68×10^{-2}	3.41×10^{-3}	1.16×10^{-3}	-9.55×10^{-3}	-2.82×10^{-3}	1.93×10^{-2}	4.50×10^{-3}	1.73×10^{-2}	8.12×10^{-4}	-2.03×10^{-3}
4	-3.68×10^{-2}	3.36×10^{-3}	1.14×10^{-3}	-9.53×10^{-3}	-2.89×10^{-3}	1.67×10^{-2}	4.47×10^{-3}	1.55×10^{-2}	-1.45×10^{-4}	-2.11×10^{-3}
5	-3.68×10^{-2}	3.32×10^{-3}	1.12×10^{-3}	-9.50×10^{-3}	-3.05×10^{-3}	9.62×10^{-3}	4.46×10^{-3}	1.28×10^{-2}	-1.57×10^{-3}	-2.17×10^{-3}
6	-3.69×10^{-2}	3.28×10^{-3}	1.09×10^{-3}	-9.46×10^{-3}	-3.22×10^{-3}	1.51×10^{-3}	4.47×10^{-3}	1.04×10^{-2}	-2.80×10^{-3}	-2.24×10^{-3}
7	-3.69×10^{-2}	3.23×10^{-3}	1.06×10^{-3}	-9.42×10^{-3}	-3.42×10^{-3}	-7.77×10^{-3}	4.45×10^{-3}	5.93×10^{-3}	-5.05×10^{-3}	-2.47×10^{-3}
8	-3.70×10^{-2}	3.19×10^{-3}	1.03×10^{-3}	-9.38×10^{-3}	-3.58×10^{-3}	-1.49×10^{-2}	4.42×10^{-3}	7.20×10^{-4}	-7.62×10^{-3}	-2.87×10^{-3}
9	-3.70×10^{-2}	3.14×10^{-3}	1.00×10^{-3}	-9.35×10^{-3}	-3.69×10^{-3}	-1.98×10^{-2}	4.32×10^{-3}	-7.46×10^{-3}	-1.16×10^{-2}	-3.59×10^{-3}
10	-3.71×10^{-2}	3.08×10^{-3}	1.04×10^{-3}	-9.42×10^{-3}	-3.32×10^{-3}	4.10×10^{-4}	4.69×10^{-3}	6.97×10^{-3}	-4.11×10^{-3}	-3.38×10^{-3}

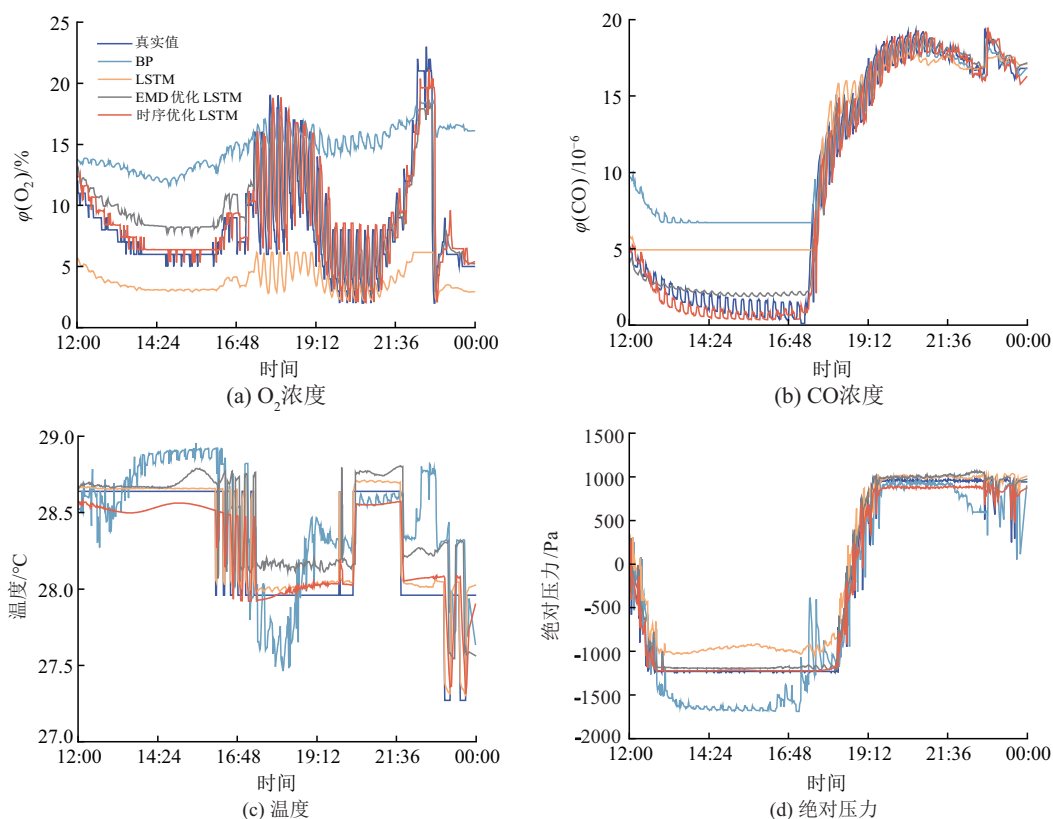


图 8 不同模型的预测结果对比

Fig. 8 Comparison of prediction results of different models

图 8a 为 O_2 浓度预测结果, 时序优化 LSTM 模型预测曲线与实际值重合度更高, 在 O_2 浓度快速变化阶段, 该模型表现出优异的动态跟踪能力, 准确捕捉了浓度的波动变化; 而 BP 神经网络和标准 LSTM 模型在此区间表现出明显的滞后性和过度平滑现象, EMD 优化 LSTM 模型虽有改善但仍存在波动偏差. 表 4 数据显示, 测试数据集上, 时序优化 LSTM 模型的 E_{MAE} 为 0.742 3%, E_{RMSE} 为 0.963 1, R^2 达到 0.992 9; 相比之下, BP 神经网络、标准

LSTM 模型和 EMD 优化 LSTM 模型的预测精度均较低. 图 8b 为 CO 浓度预测结果, BP 神经网络模型对于 CO 浓度预测误差显著, 从训练误差和测试误差的对比结果上出现了明显的过拟合现象. 时序优化 LSTM 模型能够精确跟踪 CO 浓度的高频波动和突变趋势, 在 CO 浓度急剧上升和下降阶段保持高精度拟合, 曲线平滑且贴合度高; 而其他模型在浓度突变处出现不同程度的预测偏差. 由表 4 可知, 测试数据集上, 时序优化 LSTM 模型的 E_{MAE} 为

2.0703×10^{-6} , E_{RMSE} 为 2.410 3, R^2 为 0.853 8; BP 神经网络表现最差 (E_{MAE} 为 6.6225×10^{-6} , E_{RMSE} 为 7.243 7, R^2 仅为 0.473 9); 标准 LSTM (E_{MAE} 为 4.6207×10^{-6} , E_{RMSE} 为 5.692 9, R^2 为 0.805 0) 和 EMD 优化 LSTM (E_{MAE} 为 2.3680×10^{-6} , E_{RMSE} 为 3.546 5, R^2 为 0.619 3) 虽有所改善但预测效果仍不及时序优化模型, 时序优化 LSTM 模型展现出更强的数据变异解释能力。

图 8c 为温度预测结果, 时序优化 LSTM 模型的预测曲线最接近实际值。在测试数据集上, BP 神经网络模型和标准 LSTM 模型预测结果不理想, 而 EMD 优化 LSTM 模型误差得到了较好的改善, E_{MAE} 为 0.120 5 °C, E_{RMSE} 为 0.167 2, R^2 为 0.903 6。时序优化 LSTM 模型误差指标 E_{MAE} 为 0.044 7 °C, E_{RMSE} 为 0.052 3, R^2 为 0.997 8, 相比 EMD 优化 LSTM 模型, E_{MAE} 降低了 62.9%, E_{RMSE}

降低了 68.7%, R^2 提高了 10.4%, 体现出良好的泛化能力和预测优势。图 8d 为绝对压力预测结果, 时序优化 LSTM 模型对压力变化的跟踪最为精准, 其他模型在压力波动处均表现出不同程度的误差。表 4 分析显示, 时序优化 LSTM 模型在训练和测试数据集上取得了最优效果, E_{MAE} 为 55.802 0 Pa, E_{RMSE} 为 66.957 3, R^2 为 0.999 3。

综合 4 种环境参数的预测结果分析, 时序优化 LSTM 模型在所有评价指标上均优于其他对比模型。在 R^2 指标方面, 4 项环境参数的 R^2 值均超过 0.85 以上, 表明模型具有极强的解释能力和预测精度。该模型通过 EMD 分解捕捉多尺度特征和 KPCA 提取非线性特征的双重优化, 有效解决了采空区环境参数预测中的非线性、非平稳性问题, 在保留关键时序特征的同时降低了数据噪声干扰, 显著提高了环境参数预测的准确性和稳定性。

表 4 模型预测误差对比
Table 4 Comparison of model prediction errors

对比模型	训练数据			测试数据			
	E_{MAE}	E_{RMSE}	R^2	E_{MAE}	E_{RMSE}	R^2	
O ₂ 浓度	BP	2.153 2%	2.658 5	0.972 6	3.052 8%	3.811 5	0.980 8
	LSTM	1.520 3%	1.992 1	0.969 0	2.145 0%	2.599 1	0.983 0
	EMD 优化 LSTM	0.584 3%	0.847 1	0.990 8	0.920 1%	1.241 3	0.988 0
	时序优化 LSTM	0.419 8%	0.572 7	0.996 0	0.742 3%	0.963 1	0.992 9
CO 浓度	BP	0.8922×10^{-6}	1.488 3	0.959 9	6.6225×10^{-6}	7.243 7	0.473 9
	LSTM	2.3583×10^{-6}	3.657 9	0.965 2	4.6207×10^{-6}	5.692 9	0.805 0
	EMD 优化 LSTM	0.4277×10^{-6}	1.455 0	0.958 2	2.3680×10^{-6}	3.546 5	0.619 3
	时序优化 LSTM	0.2441×10^{-6}	0.846 8	0.986 2	2.0703×10^{-6}	2.410 3	0.853 8
温度	BP	0.335 1 °C	0.414 8	0.752 1	0.282 5 °C	0.360 1	0.596 8
	LSTM	0.373 4 °C	0.461 4	0.712 9	0.186 7 °C	0.265 7	0.790 0
	EMD 优化 LSTM	0.297 8 °C	0.010 5	0.823 6	0.120 5 °C	0.167 2	0.903 6
	时序优化 LSTM	0.068 8 °C	0.083 7	0.995 8	0.044 5 °C	0.052 3	0.997 8
绝对压力	BP	147.175 7 Pa	241.333 6	0.954 9	132.814 8 Pa	226.952 5	0.960 6
	LSTM	261.953 3 Pa	317.887 2	0.970 7	197.179 5 Pa	244.843 5	0.991 9
	EMD 优化 LSTM	60.321 7 Pa	86.152 4	0.994 7	48.937 0 Pa	67.406 6	0.998 9
	时序优化 LSTM	52.508 9 Pa	72.546 8	0.997 7	55.802 0 Pa	66.957 3	0.999 3

图 9 的误差箱线图进一步揭示了模型预测的稳定性特征。时序优化 LSTM 模型在 4 个参数预测中均表现出最小的误差离散度: O₂ 浓度预测误差主要集中在 $\pm 1\%$ 范围内, CO 浓度误差控制在 $\pm 5 \times 10^{-6}$ 以内, 温度预测误差的四分位距最小且极少出现异常值, 绝对压力预测的误差分布最为紧凑。相比之

下, BP 神经网络和标准 LSTM 模型的误差箱体普遍较大, 异常值较多, EMD 优化 LSTM 模型虽有改善但仍不及时序优化模型的稳定性。表明该模型具有较强的预测精度和鲁棒性, 能够更好地揭示采空区环境特征之间的非线性关系, 准确预测采空区未来态势, 是一种简单可靠的预测方法。

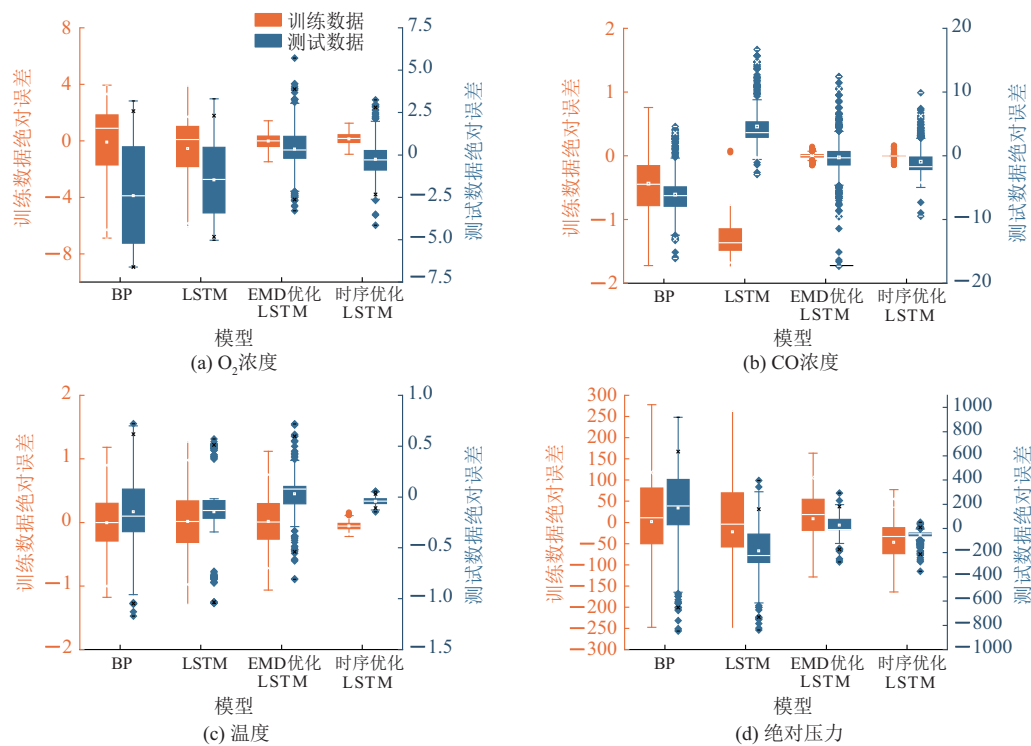


图 9 不同预测模型的误差箱线图

Fig. 9 Box plot of prediction errors for different models

4 结 论

1) 研究揭示了采空区环境参数的变化规律及相互关系. 采空区密闭内外绝对压力受煤柱及遗煤的破碎程度、地面大气压变化、井巷道特征、周边采掘活动以及通风系统参数等因素影响, 呈现出显著的周期性变化特征. 监测数据分析表明, 绝对压力与 O_2 浓度、CO 浓度、温度等环境参数具有较强的相关性.

2) 应用 EMD 自适应时频分解技术, 实现了采空区环境参数非平稳性的自适应分解. EMD 对环境特征序列进行多尺度分解, 有效捕捉了数据信号在不同时间尺度上的演变特征. 针对 4 个环境参数, EMD 分解共得到 42 个固有模态分量和 4 个残余项, 实现了采空区环境特征序列中不同时间尺度波动和趋势的精确表征, 为建模提供了高质量的特征序列.

3) 提出了 KPCA 非线性特征降维策略, 消除了 EMD 分解后高维特征的冗余问题. KPCA 将 EMD 分解后数据映射到高维特征空间, 筛选出影响采空区环境特征的关键因子, 将模型输入维度从 46 维降低到 10 维, 累积方差贡献率达到 98.12%. 不仅消除了不同时间序列的冗余特征和无关变量, 还显著提高了计算效率, 降低了模型复杂度, 增强了模型的泛化能力和实时性.

4) 构建的时序优化 LSTM 预测模型, 实现了采空区环境参数的高精度预测. 该模型对多变量时间序列与采空区环境特征序列之间的非线性关系进行动态时间建模. 测试结果表明, 相比 BP 神经网络、LSTM 和 EMD 优化 LSTM 模型, 时序优化 LSTM 模型在 O_2 浓度、CO 浓度、温度和绝对压力预测中误差指标达到了最优. 时序优化 LSTM 模型的高精度预测能力为采空区环境风险早期识别、动态监控和主动防控提供了有力支撑, 对提高矿井安全生产水平具有重要实践意义.

参考文献:

- [1] 王德明, 邵振鲁, 朱云飞. 煤矿热动力重大灾害中的几个科学问题[J]. 煤炭学报, 2021, 46(1): 57-64.
WANG Deming, SHAO Zhenlu, ZHU Yunfei. Several scientific issues on major thermodynamic disasters in coal mines[J]. Journal of China Coal Society, 2021, 46(1): 57-64.
- [2] 林柏泉, 李庆钊, 周 延. 煤矿采空区瓦斯与煤自燃复合热动力灾害多场演化研究进展[J]. 煤炭学报, 2021, 46(6): 1715-1726.
LIN Baiquan, LI Qingzhao, ZHOU Yan. Research advances about multi-field evolution of coupled thermodynamic disasters in coal mine goaf[J]. Journal of China Coal Society, 2021, 46(6): 1715-1726.
- [3] 彭 斌, 聂百胜, 申杰升, 等. 低瓦斯矿井封闭采空区

- “呼吸”现象特征及防控技术[J]. 煤炭学报, 2019, 44(2): 490-501.
- PENG Bin, NIE Baisheng, SHEN Jiesheng, et al. Characteristics and control technology of breathing phenomenon of sealed goaf in low-gas mine[J]. Journal of China Coal Society, 2019, 44(2): 490-501.
- [4] 黄炳香, 韩晓克, 赵兴龙, 等. 采动岩层多相多场耦合运动数字孪生方法构想[J]. 中国矿业大学学报, 2024, 53(6): 1037-1052.
- HUANG Bingxiang, HAN Xiaoke, ZHAO Xinglong, et al. Research framework of digital twin construction method for mining induced strata movement under multiphase and multifield coupling[J]. Journal of China University of Mining & Technology, 2024, 53(6): 1037-1052.
- [5] 赵鹏翔, 裴文博, 李树刚, 等. 巨厚煤层下分层开采邻近采空区破碎岩体分形继发性演化机理[J]. 中国矿业大学学报, 2024, 53(4): 696-709.
- ZHAO Pengxiang, PEI Wenbo, LI Shugang, et al. Fractal secondary evolution mechanism of fractured rock mass in adjacent goaf areas under extremely thick coal seam lower slice mining[J]. Journal of China University of Mining & Technology, 2024, 53(4): 696-709.
- [6] 张学博, 王攀, 王豪. 小断层影响下的采空区瓦斯运移规律研究[J]. 煤炭科学技术, 2024, 52(4): 214-230.
- ZHANG Xuebo, WANG Pan, WANG Hao. Study on gas migration law in goaf under the influence of small faults[J]. Coal Science and Technology, 2024, 52(4): 214-230.
- [7] 罗振敏, 张利冬, 宋泽阳. 基于全连接的长短期记忆网络实现采空区CO多步预测[J]. 清华大学学报(自然科学版), 2024, 64(6): 940-952.
- LUO Zhenmin, ZHANG Lidong, SONG Zeyang. Multi-step prediction of CO in the extraction zone based on a fully connected long short-term memory network[J]. Journal of Tsinghua University (Science and Technology), 2024, 64(6): 940-952.
- [8] WU B, HE B, ZHAO C, et al. Research on multi-parameter inversion of the phenomenon of gob breathing induced by atmospheric pressure fluctuation[J]. Energy Exploration & Exploitation, 2022, 40(5): 1482-1493.
- [9] 付华, 代巍. 基于ACPSO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 ACPSO and PSR[J]. Chinese Journal of Sensors and Actuators, 2016, 29(6): 903-908.
- [10] LI S, XU K, XUE G, et al. Prediction of coal spontaneous combustion temperature based on improved grey wolf optimizer algorithm and support vector regression[J]. Fuel, 2022, 324: 124670.
- [11] GUO Q, REN W, LU W. A method for predicting coal temperature using CO with GA-SVR model for early warning of the spontaneous combustion of coal[J]. Combustion Science and Technology, 2022, 194(3): 523-538.
- [12] 邓军, 雷昌奎, 曹凯, 等. 采空区煤自燃预测的随机森林方法[J]. 煤炭学报, 2018, 43(10): 2800-2808.
- DENG Jun, LEI Changkui, CAO Kai, et al. Random forest method for predicting coal spontaneous combustion in gob[J]. Journal of China Coal Society, 2018, 43(10): 2800-2808.
- [13] LEI C, DENG J, CAO K, et al. A random forest approach for predicting coal spontaneous combustion[J]. Fuel, 2018, 223: 63-73.
- [14] 邓军, 李鑫, 王凯, 等. 矿井火灾智能监测预警技术近20年研究进展及展望[J]. 煤炭科学技术, 2024, 52(1): 154-177.
- DENG Jun, LI Xin, WANG Kai, et al. Research progress and prospect of mine fire intelligent monitoring and early warning technology in recent 20 years[J]. Coal Science and Technology, 2024, 52(1): 154-177.
- [15] 侯朋远, 徐帅, 梁瑞余, 等. 基于BP神经网络的采空区激光探测环境误差修正[J]. 中南大学学报(自然科学版), 2020, 51(3): 758-766.
- HOU Pengyuan, XU Shuai, LIANG Ruiyu, et al. Environmental error correction of 3D laser detection for goaf based on BP neural network[J]. Journal of Central South University (Science and Technology), 2020, 51(3): 758-766.
- [16] XIAO H, TIAN Y. Prediction of mine coal layer spontaneous combustion danger based on genetic algorithm and BP neural networks[J]. Procedia Engineering, 2011, 26: 139-146.
- [17] WANG L, REN T, NIE B, et al. Development of a spontaneous combustion TARPs system based on BP neural network[J]. International Journal of Mining Science and Technology, 2015, 25(5): 803-810.
- [18] LI S, XU K, XUE G, et al. Prediction of coal spontaneous combustion temperature based on improved grey wolf optimizer algorithm and support vector regression[J]. Fuel, 2022, 324: 124670.
- [19] 欧阳静, 杨吕, 尹康, 等. 基于ALIF-LSTM多任务学习的综合能源系统短期负荷预测[J]. 太阳能学报, 2022, 43(9): 499-507.
- OUYANG Jing, YANG Lü, YIN Kang, et al. Short-term load forecasting method for integrated energy sys-

- tem based on ALIF-LSTM and multi-task learning[J]. *Acta Energiæ Solaris Sinica*, 2022, 43(9): 499-507.
- [20] 冀荣华, 史珊弋, 赵迎迎, 等. 基于 LSTM-Seq2Seq 的兔舍环境多参数预测[J]. *农业机械学报*, 2021, 52(增 1): 396-401.
- JI Ronghua, SHI Shanyi, ZHAO Yingying, et al. Multi-variable environmental prediction model of rabbit house based on LSTM-Seq2Seg[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2021, 52(Sup 1): 396-401.
- [21] 刘 强, 李 娜, 张 森, 等. 基于 CNN-Bi-LSTM 模型的煤含水率预测研究[J]. *中国煤炭*, 2023, 49(12): 97-104.
- LIU Qiang, LI Na, ZHANG Miao, et al. Research on the prediction method of coal moisture content based on CNN-Bi-LSTM model[J]. *China Coal*, 2023, 49(12): 97-104.
- [22] 毛清华, 安炎基, 马宏伟, 等. 煤矿掘进装备光纤惯导多源异构噪声降噪方法研究[J]. *煤炭科学技术*, 2023, 51(2): 390-399.
- MAO Qinghua, AN Yanji, MA Hongwei, et al. Study on noise reduction method of multiple heterogeneous noise of optical fiber inertial navigation for coal mine excavation equipment[J]. *Coal Science and Technology*, 2023, 51(2): 390-399.
- [23] 尹 刚, 李伊惠, 何 飞, 等. 基于 KPCA 和 SVM 的铝电解槽漏槽事故预警方法[J]. *化工学报*, 2023, 74(8): 3419-3428.
- YIN Gang, LI Yinhui, HE Fei, et al. Early warning method of aluminum reduction cell leakage accident based on KPCA and SVM[J]. *CIESC Journal*, 2023, 74(8): 3419-3428.
- [24] 曹现刚, 叶 煜, 赵友军, 等. 基于 KPCA-LSTM 的旋转机械剩余使用寿命预测[J]. *振动与冲击*, 2023, 42(24): 81-91.
- CAO Xiangang, YE Yu, ZHAO Youjun, et al. Remaining useful life prediction of rotating machinery based on KPCA-LSTM[J]. *Journal of Vibration and Shock*, 2023, 42(24): 81-91.
- [25] 邓立军, 袁金波, 刘 剑, 等. 基于 SSA-LSTM 的风速异常波动检测方法[J]. *煤炭科学技术*, 2024, 52(3): 139-147.
- DENG Lijun, YUAN Jinbo, LIU Jian, et al. Detection method of wind speed anomaly fluctuation based on SSA-LSTM[J]. *Coal Science and Technology*, 2024, 52(3): 139-147.
- [26] 李 娜, 刘 强, 张 森, 等. 基于长短期记忆的煤炭含水率智能预测与实验研究[J]. *实验室研究与探索*, 2022, 41(4): 35-39.
- LI Na, LIU Qiang, ZHANG Miao, et al. Intelligent prediction and experimental research of coal moisture content based on LSTM[J]. *Research and Exploration in Laboratory*, 2022, 41(4): 35-39.

(责任编辑 宋 爽)