

DOI: 10.12066/j.issn.1007-2861.2409

• 考古与文化遗产保护 •

## 基于 EMD-LSTM 人工神经网络的 云冈石窟环境参数预测

卢宝明, 徐金明

(上海大学 力学与工程科学学院, 上海 200444)

**摘要:** 环境参数会直接影响石窟的风化过程, 因此, 预测环境参数是进行云冈石窟有效保护的重要内容. 以云冈石窟第十窟为例, 将壁温、环境湿度、环境温度的实测时序数据作为环境参数, 使用经验模态分解 (empirical model decomposition, EMD) 对实测时序数据进行分解, 研究了固有模态函数 (intrinsic mode function, IMF) 分量与实测时序数据的相关性, 建立了基于 EMD-长短期记忆 (long short-term memory, LSTM) 的人工神经网络 (artificial neural network, ANN) 组合模型. 使用平均绝对误差 (mean absolute error, MAE)、均方根误差 (root mean square error, RMSE)、平均绝对百分比误差 (mean absolute percentage error, MAPE)、决定系数 ( $R^2$ ) 作为评价指标, 对比分析了使用组合模型与使用单一 LSTM 的 ANN 模型进行环境参数预测的效果. 结果表明: IMF 分量的变化速率越大, 与实测时序数据的相关性就越强; 对于组合模型中的 LSTM 网络模型, 当隐藏层层数和初始学习率分别取 2 和 0.001 时, 组合模型预测效果最优; 与单一 LSTM 的 ANN 模型相比, 使用基于 EMD-LSTM 的 ANN 组合模型, 环境参数的 MAE、RMSE、MAPE 值减小、 $R^2$  值增大, 模型预测精度提高; 环境参数预测效果主要受环境参数变化幅度的影响, 变化幅度越小, 组合模型预测效果越好. 研究成果对于石窟文物保护具有一定的参考价值.

**关键词:** 壁温; 环境湿度; 环境温度; 经验模态分解; 长短期记忆; 人工神经网络

**中图分类号:** P 642.5 **文献标志码:** A **文章编号:** 1007-2861(2024)01-0001-16

## Estimation of environmental parameters of Yungang Grottoes based on empirical mode decomposition and long short-term memory artificial neural network

LU Baoming, XU Jinming

(School of Mechanics and Engineering Science, Shanghai University, Shanghai 200444, China)

**Abstract:** The weathering process of grottoes is directly influenced by environmental parameters. Consequently, estimating these parameters is important for the effective preservation of Yungang Grottoes. This research utilized measured time-series data of wall temperature, environmental humidity, and temperature from the 10th grotto of Yungang Grottoes. These data were decomposed into various components using empirical model

收稿日期: 2022-03-08

基金项目: 国家重点研发计划资助项目 (2019YFC1520500); 山西省重点研发计划资助项目 (201803D31080)

通信作者: 徐金明 (1963—), 男, 教授, 博士生导师, 博士, 研究方向为工程地质与岩土工程.

E-mail: xjming@163.com

decomposition (EMD). Correlations between the measured time-series data and intrinsic mode function (IMF) components were also investigated. A combined model, based on the EMD-long short-term memory (LSTM) artificial neural network (ANN), was then developed. Using mean absolute error (MAE), root mean square error (RMSE), mean absolute percentage error (MAPE), and  $R^2$  as the evaluation indices, comparisons were made between the recorded environmental parameters and those estimated by the combined model and standalone LSTM-based ANN. The findings suggested that as the rate of change in the IMF components increased, the correlation between the IMF components and measured time-series increased. When only employing the LSTM-based ANN, optimal results were obtained with 2 hidden layers and an initial learning rate of 0.001. Conversely, when using the combined model, MAE, RMSE, and MAPE values decreased, while  $R^2$  values increased, indicating the improved estimation efficiency. The accuracy of the environmental parameter estimations largely depended on the extent of parameter changes, with smaller changes leading to better model efficiency. The insights gained from this research can be useful for the preservation of cultural relics of grottoes.

**Key words:** wall temperature; environmental humidity; environmental temperature; empirical mode decomposition (EMD); long short-term memory (LSTM); artificial neural network (ANN)

石窟文物是中华文明历史的见证, 而石窟文物风化防治是石窟文物保护的重要基础. 由于石窟风化过程直接受环境参数的影响, 准确估计石窟文物环境参数可以有效预判环境参数的变化趋势, 进而为合理选取石窟文物保护措施提供参考. 因此, 石窟文物环境参数的预测研究具有重要的实际意义.

目前, 石窟文物风化研究已经取得了丰富的研究成果. 黄继忠等<sup>[1]</sup>使用湿杯法对山西大同云冈石窟中的两类砂岩进行了水汽扩散试验, 研究了石窟文物水汽透过砂岩扩散速率与石窟风化程度、环境湿度的关系. 富中华等<sup>[2]</sup>采用现场调查和分析归纳方法探讨了山西大同雕落寺的风化病害特征, 提出了相应的保护措施. 任建光等<sup>[3]</sup>利用磁化率仪对云冈石窟风化程度进行了检测与分级, 实现了石窟风化程度的定量化描述. 张景科等<sup>[4]</sup>分析了甘肃庆阳北石窟寺砂岩文物风化特征的现场调查结果, 认为河湖边缘沉积环境是岩石文物风化的外部影响因素, 岩石性质是岩石风化的关键影响因素. 曹赤鹏等<sup>[5]</sup>将多光谱成像和随机森林算法相结合, 提出了石窟风化程度的一种评估方法. 任建光等<sup>[6]</sup>利用超声波技术对云冈石窟内部风化情况进行无损检测, 认为这一技术对分析石窟文物内部结构具有较好的适用性.

文物的环境参数直接影响文物的保存状态, 对文物环境参数的研究可以有效提高文物的保护质量. D'agostino 等<sup>[7]</sup>使用岩石类文物风化作用监测数据, 并结合三维仿真模型模拟结果, 认为环境温度和风速对岩石类文物风化作用的影响最大. Rijniers 等<sup>[8]</sup>使用试验分析方法, 研究了盐类类型对石窟文物风化作用的影响, 认为  $\text{Na}_2\text{SO}_4$  对石窟文物风化具有明显的加速作用. 王彦武等<sup>[9]</sup>研究了甘肃庆阳北石窟寺降雨量、周围泉水水位、泉水流量等环境因素的作用, 使用地下水水质检测报告分析了水环境对石窟文物风化的影响. 马江丽等<sup>[10]</sup>将 K 线理论引入馆藏文物环境温湿度评价体系, 建立了环境监测数据分析模型. 李娟等<sup>[11]</sup>通过文物区现场试验, 分析了文物区回风口不同高度处环境温度和相对湿度的空间分布特征. 金涛<sup>[12]</sup>分析了海水、海洋生物和底质等海洋环境对海洋水下文物病害的影响, 阐述了针对环境破坏的海洋文物保护措施. 周文静等<sup>[13]</sup>分析了污染气体、温度、水污染对石质文物病害的影响, 提出了对环境参数影响的保护措施. 徐方圆等<sup>[14]</sup>基于温湿度分布图构建了博物馆现场文物温湿度波

动指数评价指标.

基于经验模态分解 (empirical model decomposition, EMD) 的组合模型, 对时序数据预测具有较高的准确性, 已逐渐成为解决工程问题的研究方法. 宁武霆等<sup>[15]</sup>利用 EMD-小波 (wavelet) 组合模型, 对混凝土坝光纤测温结果进行了降噪处理与预测分析. 张晓晗等<sup>[16]</sup>利用 EMD-长短期记忆 (long short-term memory, LSTM) 方法来去除交通流量时序数据中的白噪声和长时依赖项, 较好解决了预测精度不足的问题. 朱玥等<sup>[17]</sup>利用 EMD-LSTM 模型预测了光伏发电功率, 分析了发电功率与气象条件的相关性. Napolitano 等<sup>[18]</sup>认为, EMD-人工神经网络 (artificial neural network, ANN) 组合模型可以较好地提高预测结果的准确性. Li 等<sup>[19]</sup>构建了 EMD-递归神经网络 (Elman)-LSTM 组合模型, 并将预测结果与单一模型进行比较, 认为该组合模型可以有效提高模型预测的精准度. 刘艳等<sup>[20]</sup>构建了玛纳斯河水流流量与流速的集合经验模态分解-差分整合移动平均自回归 (ensemble EMD-autoregressive integrated moving average, EEMD-ARIMA) 组合模型, 认为组合模型的预测结果优于传统的 ARIMA 模型.

石窟风化取决于多种环境因素, 现有的研究多集中在单一因素作用方面, 对多种因素综合作用下石窟风化研究的成果还不多. Zheng 等<sup>[21]</sup>使用灰色关联分析方法, 分析了河南洛阳龙门石窟不同环境因素 (壁温、环境温度、环境湿度) 间的相关性, 探究了影响风化裂缝病害的主要因素. Wang 等<sup>[22]</sup>采用现场调查的分析方法, 探究了云冈石窟盐类析出病害与环境温湿度变化的关系. ANN 组合模型考虑了多种因素的综合作用, 可用于石窟环境参数的预测. 本工作根据云冈石窟第十窟的实测数据, 将壁温、环境温度、环境湿度作为环境因素, 分析这些环境参数的主要特征, 构建基于 EMD-LSTM 的 ANN 组合模型, 对云冈石窟环境参数进行预测.

## 1 云冈石窟环境参数变化特征

本工作的研究对象是云冈石窟第十窟的壁温、环境湿度、环境温度的实测时序数据, 研究时间为 2018 年 8 月 24 日—2020 年 6 月 28 日 (共计 675 d). 壁温监测仪布置于西北侧, 紧贴石窟表面, 距地面 1.5 m; 湿度与温度监测仪布置于第十窟西北侧, 距石窟表面水平距离 1 m, 距地面 1.5 m. 为了避免游客对测试结果的影响, 选取每天 0 时的实测时序数据进行分析.

壁温极值点分布是分析云冈石窟壁温变化特征的基础. 壁温实测时序数据的局部极值点分布如图 1 所示, 其中横坐标表示距离监测开始日期 (2018 年 8 月 24 日) 的天数. 由图 1 可知: 壁温在 3 个夏季较高, 在中间 2 个冬季较低, 壁温变化的主要影响因素为季节因素; 在同一季节之中, 由于环境温度和湿度等因素的影响, 壁温存在不同程度的差异.




图 1 壁温实测时序数据的极值分布

Fig. 1 Distributions of extreme values in measured time-series data of wall temperature

本工作采用分段三次 Hermite 插值多项式, 得到壁温实测时序曲线的上下包络线. 这两条包络线对应数据的均值点如图 2 所示. 可以看出: 壁温实测时序数据上下包络线距离较近, 局部变化较小; 冬季和夏季上下包络线的距离大于春季和秋季, 主要原因是较大环境(大同市)下夏季和冬季的温度和湿度变化范围更大.

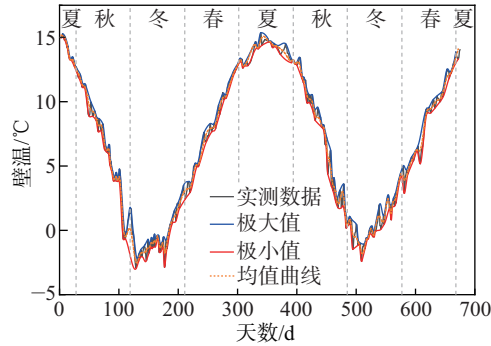


图 2 壁温实测时序数据

Fig. 2 Measured time-series data of wall temperature

## 2 环境参数的 EMD 计算

随时间变化的环境参数(壁温、环境湿度、环境温度)是一种非线性、非平稳信号. 对该类信号, EMD 是一种有效的分解方法, 可以根据环境参数信号的时间尺度特征将复杂信号分解为具有原信号局部特征的固有模态函数(intrinsic mode function, IMF)分量. 根据环境参数时序数据  $S(t)$ , 使用 EMD 获得 IMF 分量的步骤如下.

步骤 1 获取环境参数时序数据  $S(t)$  的极大值点、极小值点.

步骤 2 绘制  $S(t)$  的包络线及均值线  $h_1(t)$ , 计算  $S(t)$  与  $h_1(t)$  的差值  $m_1(t)$ .

步骤 3 判定时间序列  $m_1(t)$  是否满足极值点个数与零点个数相等或差值为 1, 以及上下包络线关于时间轴对称的条件; 若满足, 则  $m_1(t)$  为  $S(t)$  的第一个 IMF 分量; 否则, 令  $S(t) = m_1(t)$ , 重复前述步骤直至满足这一条件, 得到  $S(t)$  的第一个 IMF 分量.

步骤 4 令  $r_1(t) = h_1(t)$ , 将步骤 1~步骤 3 中环境参数时序数据  $S(t)$  替换为  $r_1(t)$ , 重复步骤 1~步骤 3.

步骤 5 当  $r_n(t)$  为单调序列或常值序列时, 结束计算过程, 得到多个 IMF 分量及残差  $r_n(t)$ .

壁温实测时序数据的 IMF 分量和残差如图 3 所示, 其中红色曲线为壁温实测时序数据, 蓝色曲线为壁温 IMF 分量, 橙色曲线为残差. 可以看出, 壁温的 IMF2~IMF6 分量随时间变化具有相同的趋势. 利用周期表征这一变化趋势, 采用最小二乘原理拟合每个壁温 IMF 分量为标准周期的正弦函数, 进而计算出每个壁温 IMF 分量的周期.

由于在监测时间内不同 IMF 分量的变化速率不同, 设环境参数 IMF 分量周期为  $T$ , 则由大到小将 IMF 分量变化速率划分为 3 个等级, 分别为  $T < 30$  d、 $T \in [30, 365)$  d、 $T \geq 365$  d. 不同壁温实测时序数据 IMF 分量周期的计算结果如表 1 所示. 可以看出: IMF1、IMF2、IMF3 分量的  $T < 30$  d; IMF4 分量的  $T \in [30, 365)$  d; IMF5、IMF6 分量的  $T \geq 365$  d.

表 2 为不同壁温 IMF 分量和残差的均值、方差、标准差、相关系数的计算结果. 可以看出: IMF5、IMF6 分量的相关系数分别为 0.62、0.76, 均大于 0.5, 与实测时序数据的相关性最




图 3 壁温实测时序数据及其 EMD 分解结果

Fig. 3 Measured time-series data and corresponding EMD component results of wall temperature

表 1 壁温 IMF 分量的周期

Table 1 Periods of IMF components of wall temperature d

IMF 分量	周期	IMF 分量	周期
IMF1	5.38	IMF4	40.91
IMF2	10.89	IMF5	450
IMF3	24.11	IMF6	675

表 2 壁温 IMF 分量的统计结果

Table 2 Statistical results of IMF components of wall temperature

IMF 分量	标准差	均值	方差	相关系数
IMF1	0.28	-0.01	0.08	0.05
IMF2	0.31	0.004	0.10	0.14
IMF3	0.25	-0.01	0.06	0.16
IMF4	0.34	0.11	0.11	0.36
IMF5	5.37	-0.18	28.83	0.62
IMF6	0.39	-0.02	0.16	0.76
残差	0.92	6.89	0.84	0.52

好; IMF4 分量的相关系数为 0.36, 与实测时序数据的相关性较差; IMF1、IMF2、IMF3 分量的相关系数分别为 0.05、0.14、0.16, 均小于 0.2, 与实测时序数据的相关性最差. 由此可知, 壁



温 IMF 分量与实测时序数据相关性由高到低的顺序为  $T \geq 365$  d、 $T \in [30, 365)$  d、 $T < 30$  d, 其中  $T \geq 365$  d 的分量可以较好地反映壁温实测时序数据的变化情况.

标准差贡献率可以反映每个 IMF 分量对壁温实测时序数据整体变化的影响, 即 IMF 分量标准差贡献率越大, 对壁温实测时序数据整体变化的影响就越大. 本工作中的标准差贡献率计算公式为

$$P = \sigma_i / \sum_{i=1}^n \sigma_i, \quad (1)$$

式中:  $P$  为 IMF 分量的标准差贡献率;  $\sigma$  为 IMF 分量的标准差.

表 3 为不同壁温 IMF 分量对壁温实测时序数据的标准差贡献率. 可以看出: 不同 IMF 分量和残差的标准差贡献率呈现先增大后减小的变化趋势; IMF1、IMF2、IMF3 分量的标准差贡献率分别为 0.04、0.04、0.03; IMF4 分量的标准差贡献率为 0.04; IMF5、IMF6 分量的标准差贡献率分别为 0.68、0.05; 残差的标准差贡献率为 0.12. 由此可知,  $T < 30$  d 的分量对壁温实测时序数据变化趋势的影响最小,  $T \in [30, 365)$  d 的分量影响次之,  $T \geq 365$  d 的分量影响最大.

表 3 壁温 IMF 分量的标准差贡献率

Table 3 Contribution rates of standard deviation of IMF components of wall temperature

IMF 分量	标准差贡献率	IMF 分量	标准差贡献率
IMF1	0.04	IMF5	0.68
IMF2	0.04	IMF6	0.05
IMF3	0.03	残差	0.12
IMF4	0.04		

将  $T \geq 365$  d 的分量进行叠加可得到  $T \geq 365$  d 的分量的集成时序数据, 其与壁温实测时序数据如图 4 所示. 可以看出:  $T \geq 365$  d 的分量的集成时序数据与壁温实测时序数据变化趋势相同, 主要是由于  $T \geq 365$  d 的分量对壁温标准差贡献率最大, 对壁温变化趋势的影响最大; 两曲线间的差值为  $T < 30$  d 的分量、 $T \in [30, 365)$  d 的分量以及残差分量的集成时序数据之和, 其中  $T < 30$  d 的分量和  $T \in [30, 365)$  d 的分量的周期、标准差贡献率及数据值均较小, 主要影响两曲线差值的局部变化, 而两曲线差值大小主要受残差的影响.

环境湿度实测时序数据的 IMF 分量和残差如图 5 所示. 可以看出: 环境湿度实测时序数据的变化幅度大于壁温; IMF 分量数量多于壁温;  $T < 30$  d 的分量数量也多于壁温.

表 4 为不同环境湿度 IMF 分量的周期. 可以看出: IMF1、IMF2、IMF3 分量的  $T < 30$  d; IMF4、IMF5、IMF6 分量的  $T \in [30, 365)$  d; IMF7、IMF8、IMF9 分量的  $T \geq 365$  d.

表 5 为不同环境湿度 IMF 分量和残差的均值、方差、标准差、相关系数的计算结果. 可以看出, 环境湿度 IMF 分量与实测时序数据相关性由高到低的顺序为  $T \geq 365$  d、 $T \in [30, 365)$  d、 $T < 30$  d, 其中  $T \geq 365$  d 的分量相关性最高, 可以较好地反映环境湿度实测时序数据的变化情况.

表 6 为不同环境湿度 IMF 分量对环境湿度实测时序数据的标准差贡献率. 可以看出:  $T \geq 365$  d 的分量对环境湿度变化趋势的影响最大,  $T \in [30, 365)$  d 的分量影响次之,  $T < 30$  d 的分量影响最小.




图 4  $T \geq 365$  d 的壁温 IMF 分量的集成时序数据与实测时序数据

Fig. 4 Integrated and measured time-series data of  $T \geq 365$  d IMF components of wall temperature

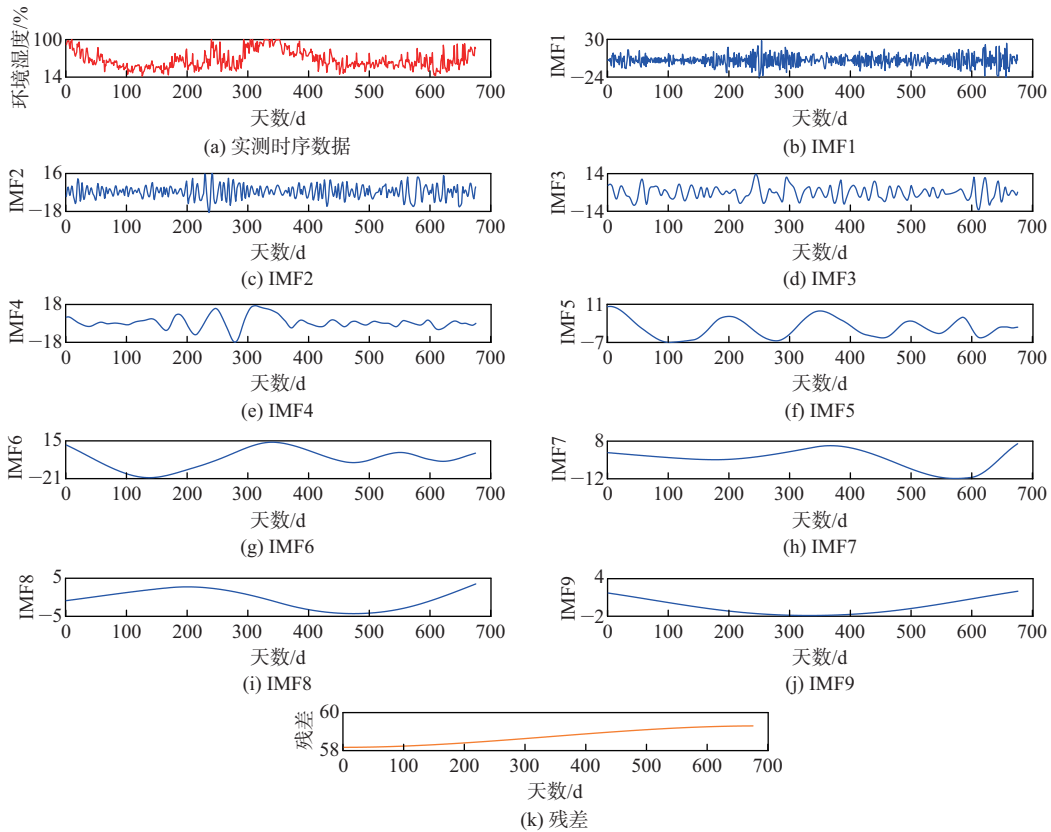


图 5 环境湿度实测时序数据的 IMF 分量和残差

Fig. 5 IMF components and residuals of measured time-series data of environmental humidity

环境温度实测时序数据的 IMF 分量和残差如图 6 所示. 可以看出: 环境温度的变化幅度介于壁温与环境湿度之间; IMF 分量、 $T < 30$  d 的分量、 $T \in [30, 365)$  d 的分量及  $T \geq 365$  d 的分量的数量与壁温相同.

表 4 环境湿度 IMF 分量的周期

Table 4 Periods of IMF components of environmental humidity d

IMF 分量	周期	IMF 分量	周期
IMF1	3.30	IMF6	259
IMF2	8.04	IMF7	519
IMF3	18.24	IMF8	602
IMF4	42.19	IMF9	964
IMF5	96.42		

表 5 环境湿度 IMF 分量的统计结果

Table 5 Statistical results of IMF components of environmental humidity

IMF 分量	标准差	均值	方差	相关系数
IMF1	2.05	-0.15	4.20	0.09
IMF2	2.15	-0.39	4.62	0.21
IMF3	3.45	-0.16	11.90	0.26
IMF4	2.80	1.01	7.84	0.35
IMF5	4.80	-0.11	23.04	0.42
IMF6	12.10	-2.15	146.41	0.52
IMF7	9.75	-1.40	95.06	0.66
IMF8	10.20	-0.41	104.04	0.72
IMF9	23.40	-0.46	547.56	0.79
残差	6.75	58.74	45.56	0.64

表 6 环境湿度 IMF 分量的标准差贡献率

Table 6 Contribution rates of standard deviations of IMF components of environmental humidity

IMF 分量	标准差贡献率	IMF 分量	标准差贡献率
IMF1	0.03	IMF6	0.16
IMF2	0.03	IMF7	0.12
IMF3	0.05	IMF8	0.13
IMF4	0.04	IMF9	0.30
IMF5	0.06	残差	0.09



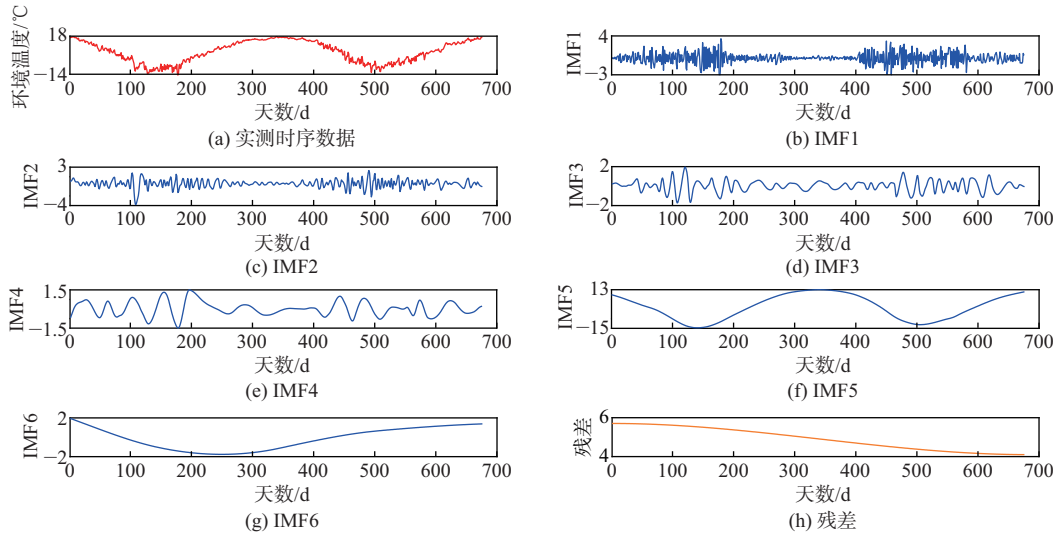


图 6 环境温度实测时序数据的 IMF 分量和残差

Fig. 6 IMF components and residuals of measured time-series data of environmental temperature

表 7 为不同环境温度 IMF 分量的周期. 可以看出: IMF1、IMF2、IMF3 分量的  $T < 30$  d; IMF4 分量的  $T \in [30, 365)$  d; IMF6 分量的  $T \geq 365$  d.

表 7 环境温度 IMF 分量的周期

IMF 分量	周期	IMF 分量	周期
IMF1	4.52	IMF4	44.41
IMF2	8.65	IMF5	482
IMF3	19.85	IMF6	733

表 8 为不同环境温度 IMF 分量和残差的均值、方差、标准差、相关系数计算结果. 可以看出:  $T \geq 365$  d 的分量与环境温度相关性最大, 可以较好地反映环境温度实测时序数据的变化情况.

表 9 为不同环境温度 IMF 分量对环境湿度实测时序数据的标准差贡献率. 可以看出:  $T \geq 365$  d 的分量对环境湿度变化趋势的影响最大,  $T \in [30, 365)$  d 的分量影响次之,  $T < 30$  d 的分量影响最小.

### 3 LSTM 网络模型的建立

本工作建立了云冈石窟环境参数预测的 LSTM 网络模型, 并主要从模型评价指标和模型参数选取等方面说明了这一模型的具体建立方法.

#### 3.1 模型评价指标

对于组合模型中的 LSTM 网络模型, 预测值与实测值的误差是评价模型优劣的重要指标. 本工作需要针对不同环境参数下 LSTM、EMD-LSTM 网络模型的预测效果进行综合评价. 在研究中, 常以反映预测结果平均误差值大小的平均绝对误差 (mean absolute error, MAE)、反映

表 8 环境温度 IMF 分量的统计结果

Table 8 Statistical results of IMF components of environmental temperature

IMF 分量	标准差	均值	方差	相关系数
IMF1	0.24	-0.01	0.06	0.08
IMF2	0.35	-0.02	0.12	0.11
IMF3	0.41	0.02	0.17	0.20
IMF4	0.62	0.03	0.38	0.42
IMF5	4.03	0.41	16.24	0.56
IMF6	0.71	-0.13	0.50	0.69
残差	0.56	4.90	0.31	0.48

表 9 环境温度 IMF 分量的标准差贡献率

Table 9 Contribution rates of standard deviations of IMF components of environmental temperature

IMF 分量	标准差贡献率	IMF 分量	标准差贡献率
IMF1	0.04	IMF5	0.51
IMF2	0.05	IMF6	0.10
IMF3	0.07	残差	0.14
IMF4	0.09		

预测值误差百分比的平均绝对百分比误差 (mean absolute percentage error, MAPE)、反映预测值与实测值偏离程度的均方根误差 (root mean squared error, RMSE), 以及反映预测值与实测值拟合程度的决定系数 ( $R^2$ ) 作为评价预测模型的指标. 这 4 个评价指标的计算公式分别为

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i|, \quad (2)$$

$$\text{MAPE} = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right|, \quad (3)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2}, \quad (4)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (\bar{y}_i - y_i)^2}, \quad (5)$$

式中:  $n$  为实测环境参数样本数;  $y_i$  为环境参数实测值;  $\hat{y}_i$  为环境参数预测值;  $\bar{y}_i$  为环境参数平均值.

### 3.2 模型参数选取

本工作所建立的 LSTM 网络模型的主要参数包括隐藏层层数、隐藏层节点数、初始学

习率、迭代次数等. 下面以壁温实测时序数据相应的 LSTM 网络模型为例, 根据评价指标 (MAE、RMSE、MAPE、 $R^2$ ) 来说明这些模型参数的选取过程.

当隐藏层层数为 1、2、3 时, LSTM 网络模型评价指标的计算结果如表 10 所示. 可以看出: 当隐藏层层数从 1 增加到 2 时, 误差 (MAE、MAPE、RMSE) 减小, 决定系数 ( $R^2$ ) 增大, 模型的性能得以提高; 当隐藏层层数从 2 增加到 3 时, 误差 (MAE、MAPE、RMSE) 增大, 决定系数 ( $R^2$ ) 减小. 这一结果说明, 增加隐藏层层数可以在一定程度上提高学习能力, 但也会导致泛化能力减弱, 模型出现过拟合现象. 因此, 壁温实测时序数据 LSTM 网络模型的隐藏层层数宜取 2.

表 10 不同隐藏层层数时 LSTM 网络模型的评价指标

Table 10 Evaluation indices of LSTM-based neural network with various hidden layers

隐藏层层数	MAE/ $^{\circ}\text{C}$	MAPE/%	RMSE/ $^{\circ}\text{C}$	$R^2$ /%
1	0.16	23.65	0.44	97.75
2	0.12	16.45	0.39	98.42
3	0.18	24.39	0.43	98.03

本工作还通过不断缩小数值范围, 利用网格搜索和交叉验证两种方法确定了隐藏层节点数、初始学习率、迭代次数等超参数. 通过多次试验, 在本工作所建立的 EMD-LSTM 网络模型中, 当第一层和第二层隐藏层神经元数量分别取 86 和 62, 初始学习率取 0.001, 迭代次数取 250 时, 预测效果较好 (既可以提高模型预测精度, 也可以防止过拟合现象).

为了避免训练过程中出现过拟合现象, 本工作采用标准 Dropout 正则化技术, 通过弱化神经网络节点间的相互作用来进一步优化模型结构. Dropout 正则化技术是 Srivastava 等<sup>[23]</sup>提出的优化神经网络, 可用于解决过拟合问题, 其模型示意图如图 7 所示. 这一模型通过暂时随机丢弃部分隐藏层神经元, 优化更新保留的神经元, 达到增强网络单元泛化性、弱化网络节点间相互影响、防止过拟合现象的目的. 在网络实现时, 通过恢复随机丢弃的神经元进入下一个训练过程.




图 7 Dropout 模型示意图

Fig. 7 Schematic diagram of Dropout model

#### 4 基于 EMD-LSTM 组合模型的环境参数预测

本工作基于上述建立的 EMD-LSTM 组合模型和相应参数对环境参数进行了预测, 并对所建模型与单一 LSTM 网络模型的预测效果进行了对比分析. 环境参数预测模型所用参数值

如表 11 所示, 不同季节环境参数预测值与实测值的 MAE 如表 12 所示, 环境参数预测的总体评价指标如表 13 所示.

表 11 环境参数预测模型中的参数值

Table 11 Parameter values in environmental parameters estimation

环境参数	模型参数				
	LSTM 隐藏层层数	隐藏层节点数		初始学习率	迭代次数
		第一层	第二层		
壁温	2	85	60	0.001	250
环境湿度	2	88	65	0.001	200
环境温度	2	86	62	0.001	250

表 12 不同季节环境参数预测值与实测值的 MAE

Table 12 MAE of estimated and measured environmental parameters in different seasons

环境参数	季节			
	春季	夏季	秋季	冬季
壁温/ $^{\circ}\text{C}$	0.087	0.14	0.10	0.15
环境湿度/%	2.41	1.17	1.95	1.38
环境温度/ $^{\circ}\text{C}$	0.095	0.15	0.12	0.17

表 13 环境参数预测的评价指标

Table 13 Evaluation indices in environmental parameters estimation

环境参数	预测模型	评价指标			
		MAE	MAPE/%	RMSE	$R^2$ /%
壁温	LSTM	0.17 $^{\circ}\text{C}$	24.89	0.46 $^{\circ}\text{C}$	97.26
	EMD-LSTM	0.12 $^{\circ}\text{C}$	16.45	0.39 $^{\circ}\text{C}$	98.42
环境湿度	LSTM	2.24%	30.15	0.52%	96.95
	EMD-LSTM	1.57%	21.32	0.41%	98.29
环境温度	LSTM	0.20 $^{\circ}\text{C}$	27.62	0.49 $^{\circ}\text{C}$	97.93
	EMD-LSTM	0.14 $^{\circ}\text{C}$	18.59	0.44 $^{\circ}\text{C}$	98.86

#### 4.1 壁温的预测

壁温的预测结果如图 8 所示. 结合图 8 和表 12 可知: 预测值与实测值的 MAE 为 0.12  $^{\circ}\text{C}$ , 整体误差较小; 当数据变化幅度较小 (春季和秋季) 时, MAE 分别为 0.087 和 0.10  $^{\circ}\text{C}$ , 预测值

与实测值吻合得很好; 当数据变化幅度较大 (夏季和冬季) 时, MAE 分别为  $0.14$  和  $0.15$   $^{\circ}\text{C}$ , 预测值与实测值的误差要大于春季和秋季. 因此, 壁温预测效果的主要影响因素为壁温的变化幅度, 即春季和秋季的壁温变化幅度较小, 预测效果较好; 夏季和冬季的壁温变化幅度较大, 预测效果较差.




图 8 壁温的预测值与实测值

Fig. 8 Estimated and measured wall temperatures

由表 13 可知: EMD-LSTM 组合模型比单一 LSTM 网络模型的 MAE、RMSE、MAPE 分别降低了 29.41%、33.91%、15.22%,  $R^2$  提高了 1.19%. 因此, 两种模型均能对壁温进行有效预测, 但 EMD-LSTM 组合模型的预测效果更好. 这是由于使用单一 LSTM 网络模型时, 规律性不明显或噪声干扰会影响预测精度; EMD-LSTM 组合模型基于 EMD 可得到频率不同且规律性明显的 IMF 分量, 进而对每个分量和残差分别构建 LSTM 网络模型, 可以有效消除噪声的干扰.

#### 4.2 环境湿度的预测

环境湿度的预测结果如图 9 所示. 结合图 9 和表 12 可知: 预测值与实测值较为吻合; 夏季和冬季环境湿度变化幅度较小, 预测值与实测值的 MAE 分别为 1.17% 和 1.38%, 二者吻合较好; 春季和秋季环境湿度变化幅度较大, 预测值与实测值的 MAE 分别为 2.41% 和 1.95%, 略差于夏季和冬季. 因此, 环境湿度预测主要受环境湿度季节变化幅度的影响, 即夏季和冬季的环境湿度变化幅度较小, 预测效果较好; 春季和秋季的环境湿度变化幅度较大, 预测效果较差.




图 9 环境湿度的预测值与实测值

Fig. 9 Estimated and measured environmental humidity

由表 13 可知, EMD-LSTM 组合模型比单一 LSTM 网络模型的 MAE、RMSE、MAPE 分别降低了 28.64%、29.29%、21.15%,  $R^2$  提高了 1.38%. 因此, 两种模型均能对环境湿度进行有效预测, 但 EMD-LSTM 组合模型的预测效果更好. 环境湿度的预测效果比壁温差, 原因是环境湿度实测数据变化幅度较大、规律性不明显.

### 4.3 环境温度的预测

环境温度的预测结果如图 10 所示. 结合图 10 和表 12 可知: 预测值与实测值吻合较好; 夏季和冬季环境温度变化幅度较大, 预测值与实测值的 MAE 分别为 0.15 和 0.17 °C; 春季和秋季环境温度变化幅度较小, 预测值与实测值的 MAE 分别为 0.095 和 0.12 °C, 优于夏季和冬季. 因此, 影响环境温度预测效果的主要因素为环境温度变化幅度, 即环境温度变化幅度越小, 则组合模型的预测效果就越好.

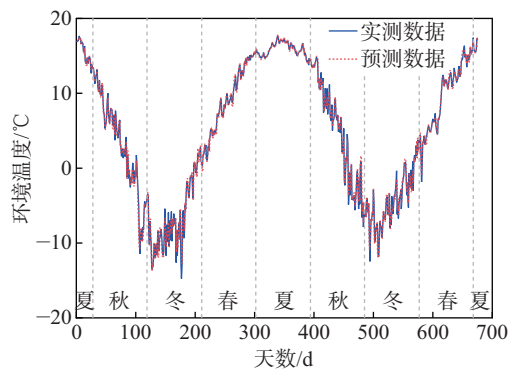


图 10 环境温度的预测值与实测值

Fig. 10 Estimated and measured environmental temperatures

由表 13 可知: 单一 LSTM 网络模型和 EMD-LSTM 组合模型均能对环境温度进行有效预测, 但组合模型的预测效果更好; 环境温度实测时序数据变化幅度介于壁温和环境湿度之间, 组合模型的预测效果也介于壁温和环境湿度之间. 因此, 影响组合模型预测效果的主要因素是实测时序数据的变化幅度.

综上所述, 单一 LSTM 网络模型和 EMD-LSTM 组合模型均能对环境参数进行有效预测, 但组合模型预测效果更好; 环境参数预测效果的主要影响因素为环境参数的变化幅度.

## 5 结束语

本工作以云冈石窟第十窟为例, 建立了基于 EMD-LSTM 神经网络的环境参数组合预测模型, 并以 MAE、RMSE、MAPE、 $R^2$  为评价指标, 比较了组合模型和单一 LSTM 网络模型对环境参数 (壁温、环境湿度、环境温度) 的预测效果, 得到以下结论.

- (1) EMD 中 IMF 分量与实测时序数据相关性由高到低的顺序为  $T \geq 365$  d、 $T \in [30, 365)$  d、 $T < 30$  d, 其中  $T \geq 365$  d 的分量可以较好反映环境参数的变化情况.
- (2) 当隐藏层层数为 2、初始学习率为 0.001 时, 所建 EMD-LSTM 组合模型的预测效果更好, 对环境参数的预测效果都优于单一 LSTM 网络模型.
- (3) 影响环境参数预测效果的主要因素为环境参数的变化幅度, 其中环境湿度的变化幅度最大, 环境温度次之, 壁温最小.
- (4) 单一 LSTM 网络模型和 EMD-LSTM 组合模型均能对环境参数进行有效预测, 但组



合模型的预测效果更好.

### 参考文献:

- [1] 黄继忠, 郑伊, 张悦, 等. 云冈石窟砂岩水汽扩散特性研究 [J]. 西北大学学报 (自然科学版), 2021, 51(3): 370-378.
- [2] 富中华, 孙瑜. 山西大同雕落寺石窟病害调查研究及保护对策 [J]. 工业建筑, 2019, 49(3): 191-197.
- [3] 任建光, 黄继忠, 王旭升. 云冈石窟龙王庙沟风化砂岩风化深度与风化速度环境磁学无损探测 [J]. 工程勘察, 2013, 41(9): 69-74.
- [4] 张景科, 张理想, 郭青林, 等. 庆阳北石窟寺砂岩表层风化特征与地层岩性的关系研究 [J]. 西北大学学报 (自然科学版), 2021, 51(3): 344-352.
- [5] 曹赤鹏, 王慧琴, 王可, 等. 基于多光谱成像和随机森林算法的石窟表面风化智能评估方法 [J]. 光学学报, 2020, 40(22): 201-211.
- [6] 任建光, 王书, 孟田华, 等. 超声波无损检测技术在世界文化遗产地云冈石窟保护中的应用 [J]. 工程勘察, 2021, 49(6): 68-73.
- [7] D'AGOSTINO D, CONGEDO P M, CATALDO R. Computational fluid dynamics (CFD) modeling of microclimate for salts crystallization control and artworks conservation [J]. Journal of Cultural Heritage, 2014, 15(4): 448-457.
- [8] RIJNERS L A, PEL L, HUININK H P, et al. Salt crystallization as damage mechanism in porous building materials: a nuclear magnetic resonance study [J]. Magnetic Resonance Imaging, 2005, 23(2): 273-276.
- [9] 王彦武, 韩增阳, 郭青林, 等. 甘肃庆阳北石窟寺水环境特征研究 [J]. 西北大学学报 (自然科学版), 2021, 51(3): 360-369.
- [10] 马江丽, 徐方圆, 全定可. 利用 K 线图分析馆藏文物保存环境中温湿度研究 [J]. 文物保护与考古科学, 2019, 31(3): 127-132.
- [11] 李娟, 罗昔联, 常彬, 等. 回风口位置对文物保存环境置换通风调控性能的影响 [J]. 西安交通大学学报, 2019, 53(5): 115-122.
- [12] 金涛. 海洋条件下的水下文物埋藏环境概述 [J]. 文物保护与考古科学, 2017, 29(1): 98-107.
- [13] 周文静, 潘辰, 连宾. 环境污染加剧石质文物风化: 机理、过程及防护措施 [J]. 地球与环境, 2013, 41(4): 451-459.
- [14] 徐方圆, 吴来明, 解玉林, 等. 文物保存环境中温湿度评估方法研究 [J]. 文物保护与考古科学, 2012, 24(增刊 1): 6-12.
- [15] 宁武霆, 赵春菊, 周宜红, 等. 混凝土坝光纤测温噪声特征及降噪方法 [J]. 水电能源科学, 2021, 39(6): 73-76.
- [16] 张晓晗, 冯爱民. 基于经验模态分解和长短期记忆神经网络的短期交通流量预测 [J]. 计算机应用, 2021, 41(1): 225-230.
- [17] 朱玥, 顾洁, 孟璐. 基于 EMD-LSTM 的光伏发电预测模型 [J]. 电力工程技术, 2020, 39(2): 51-58.
- [18] NAPOLITANO G, SERINALDI F, SEE L. Impact of EMD decomposition and random initialisation of weights in ANN hindcasting of daily stream flow series: an empirical examination [J]. Journal of Hydrology, 2011, 406(3): 199-214.

- [19] LI X, ZHANG L, WANG Z, et al. Remaining useful life prediction for lithium-ion batteries based on a hybrid model combining the long short-term memory and Elman neural networks [J]. Journal of Energy Storage, 2019, 21: 510.
- [20] 刘艳, 杨耘, 聂磊, 等. 玛纳斯河出山口径流 EEMD-ARIMA 预测 [J]. 水土保持研究, 2017, 24(6): 273-280.
- [21] ZHENG L L, FU X Z, CHU F. Grey incidence analyze of environment monitoring SATA and research on the disease prevention measures of Longmen Grottoes [J]. IOP Conference Series: Earth and Environmental Science, 2018, 153(6): 1-8.
- [22] WANG X S, WAN L, HUANG J Z, et al. Variable temperature and moisture conditions in Yungang Grottoes, China, and their impacts on ancient sculptures [J]. Environmental Earth Sciences, 2014, 72(8): 3079-3088.
- [23] SRIVASTAVA N, HINTON G, KRIZHEVSKY A, et al. Dropout: a simple way to prevent neural networks from overfitting [J]. Journal of Machine Learning Research, 2014, 15(1): 1929-1958.

(责任编辑: 丁嘉羽)