

DOI:10.3969/j.issn.1003-5060.2026.03.022

CEEMDAN 和 LSTM 组合的高层建筑形变预测

罗时龙¹, 张巧娟², 李荣恒³, 李磊¹, 丁旭东¹, 刘兴涛³

(1. 淮安市水利勘测设计研究院有限公司, 江苏 淮安 223005; 2. 建设综合勘察研究设计院有限公司, 北京 100007; 3. 北京建筑大学测绘与城市空间信息学院, 北京 102616)

摘要:针对高层建筑形变监测时间序列非线性、非平稳性导致的预测精度较低的问题,文章提出一种基于自适应噪声完备集合经验模态分解(complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN)与长短期记忆网络(long short-term memory, LSTM)的形变预测组合模型。首先对高层建筑形变监测数据进行 CEEMDAN 分解,得到有限个本征模态函数(intrinsic mode function, IMF)和趋势项,然后使用 LSTM 分别对其进行预测,最后重构得到可用的形变预测结果,利用模拟数据与实测数据进行验证,通过多种指标评定预测精度。结果表明,与单一 LSTM 模型和 EMD-LSTM 模型相比,CEEMDAN-LSTM 模型能够更好地应对非线性、非平稳性特征,评价指标表现更优,特别对于 70 s 预测时长,均方根误差(root mean square error, RMSE)、平均绝对误差(mean absolute error, MAE)、平均绝对百分比误差(mean absolute percentage error, MAPE)指标至少分别降低 43%、50%、64%,显著提高预测精度。

关键词:高层建筑;形变预测;组合模型;自适应噪声完备集合经验模态分解(CEEMDAN);长短期记忆网络(LSTM)

中图分类号:P258

文献标志码:A

文章编号:1003-5060(2026)03-0426-07

Deformation prediction for high-rise buildings with CEEMDAN and LSTM

LUO Shilong¹, ZHANG Qiaojuan², LI Rongheng³, LI Lei¹, DING Xudong¹, LIU Xingtiao³

(1. Huai'an Water Conservancy Survey and Design Institute Co., Ltd., Huai'an 223005, China; 2. CIGIS(China) Ltd., Beijing 100007, China; 3. School of Geomatics and Urban Spatial Informatics, Beijing University of Civil Engineering and Architecture, Beijing 102616, China)

Abstract: Aiming at the lower prediction accuracy caused by nonlinear and non-stationary characteristics in the time series of deformation monitoring for high-rise buildings, a deformation prediction model intergrating complete ensemble empirical mode decomposition with adaptive noise(CEEMDAN) and long short-term memory(LSTM) was proposed. This model used CEEMDAN to decompose the monitoring data into a series of intrinsic mode function(IMF) and trend terms, which were then separately predicted using LSTM. Finally, available deformation prediction results were obtained by reconstitution. The model was validated using both simulated and measured data, and the prediction accuracy is evaluated through multiple indicators. The results show that the CEEMDAN-LSTM model outperforms the single LSTM model and EMD-LSTM model in addressing the nonlinear and non-stationary characteristics. Specifically, for a 70-second prediction horizon, the root mean square error(RMSE), mean absolute error(MAE), and mean absolute percentage error(MAPE) are reduced by at least 43%, 50%, and 64%, respectively, thus significantly improving the prediction accuracy.

Key words: high-rise building; deformation prediction; combined model; complete ensemble empirical mode decomposition with adaptive noise(CEEMDAN); long short-term memory(LSTM)

收稿日期:2025-07-11;修回日期:2025-11-14

基金项目:国家自然科学基金资助项目(42374024)

作者简介:罗时龙(1977—),男,江苏淮安人,淮安市水利勘测设计研究院有限公司高级工程师,通信作者, E-mail:luoshilong1977@126.com.

建筑高度和结构特殊性导致高层建筑易受外界环境因素影响,发生震动和似静态形变^[1],随着服役时间增长,结构性能逐渐退化,带来安全隐患。准确预测变形对于安全运营、状态评估和安全预警有重要意义^[2],被视为智能化灾害防范和维护的重要部分^[3-4]。

国家自然科学基金委第266期双清论坛会议中提出建筑与基础设施全寿命周期智能化发展的总体思路,即未来工程结构及性能的可预测性将成为推动建筑业智能化发展的关键所在^[5],因此预测性维护概念在形变监测领域迅速发展,全球导航卫星系统(Global Navigation Satellite System,GNSS)与惯导的组合监测应用成为此概念的一种主要支撑手段^[6-10]。但是利用此手段采集的高层建筑形变监测时间序列呈现非线性、非平稳性特征,导致预测精度较低,无法达到预测性维护的预期。

近年来,经验模态分解(empirical mode decomposition,EMD)及改进、组合被广泛用于提取时间序列中的有效信息,文献[11]将EMD用于重力坝变形时间序列的分解重构,更好地模拟实际变化趋势;文献[12]构建小波-EMD耦合模型,剔除高频信号,获取最接近真实值的桥墩动态变形序列;文献[13]基于改进型互补集合经验模态奇异值分解消除高边坡变形时间序列中的噪声,具有较高自适应性。但是模态混叠、重构误差大等问题仍然存在,直至自适应噪声完备集合经验模态分解(complete ensemble empirical mode decomposition with adaptive noise,CEEMDAN)的提出,得到了广泛应用,文献[14]进行深基坑地表沉降时间序列的去噪预处理;文献[15]进行GNSS坐标时间序列中异常值探测;文献[16]进行河道径流时间序列中多种频率和趋势成分提取;文献[17]进行矿山微震信号中特征提取。相较EMD,以上应用中CEEMDAN的评价指标更优,如何预测变得至关重要。

关于预测,长短期记忆网络(long short-term memory,LSTM)深度学习模型凭借强大的数据处理和模式识别能力展现出巨大潜力,取得积极进展。文献[18]将LSTM用于桥梁形变监测,避免传统递归神经网络(recursive neural network,RNN)梯度消失等问题,提高了预测准确性;文献[19]将改进LSTM用于船舶极短期运动响应预报,提高了预报时长,且对突变信号的预报效果较优;文献[20]将其用于炼钢过程中碳质量分数、温度预测,实现冶炼过程的动态预测和控制;文献

[21]构建EMD-小波阈值-LSTM模型进行混凝土坝变形预测,保障安全稳定运行。虽然已有与EMD的组合预测模型,但是尚无与CEEMDAN的组合应用,而且在高层建筑形变预测领域的研究较少。因此,本文构建了基于CEEMDAN与LSTM的高层建筑形变预测组合模型,获取高精度的高层建筑形变预测结果来服务于评估、预警工作。

1 CEEMDAN-LSTM 组合模型

1.1 CEEMDAN 模型

CEEMDAN是通过自适应加入白噪声,得到本征模态函数(intrinsic mode function,IMF)分量,再加总平均计算,避免了模态混叠、重构误差大等EMD固有问题,具体步骤^[22]描述如下。

1) 对原始位移信号 $X(t)$ 添加白噪声,计算公式为:

$$X^e(t) = X(t) + \epsilon_0 \omega^e(t) \quad (1)$$

其中: ϵ_0 为噪声系数; $\omega^e(t)$ 为第 e ($e=1,2,\dots,E$)次添加的自适应白噪声; $X^e(t)$ 为添加 $\omega^e(t)$ 得到的待分解信号。

2) 对信号 $X^e(t)$ 进行EMD分解得到分量 $I_{IMF,e}$,再对所有 $I_{IMF,e}$ 取平均,得到最终的第1个分量 $I_{IMF,1}$ 及残差信号,即

$$I_{IMF,1} = \frac{1}{E} \sum_{e=1}^E I_{IMF,e} \quad (2)$$

$$r_1(t) = X(t) - I_{IMF,1} \quad (3)$$

3) 为残差信号 $r_1(t)$ 继续添加 $\omega^e(t)$,得到新的待分解信号,重复步骤2),得到最终的第2个模态分量 $I_{IMF,2}$ 及残差信号。

4) 重复步骤2)、步骤3),直至无法再进行EMD分解,可得 k 个 $I_{IMF,i}$,原始信号可表示为:

$$X(t) = \sum_{i=1}^k I_{IMF,i} + r_k(t) \quad (4)$$

1.2 LSTM 模型

LSTM是自循环结构,是用LSTM单元替换原隐层中的RNN单元并重置计算节点,避免RNN出现的梯度消失等问题^[23-25],提升对时间序列的长时间处理能力,结构如图1所示。




图1 LSTM单元内部结构

图 1 中: x_t 为当前时刻 t 的输入; h_t 和 h_{t-1} 分别为当前时刻 t 和上一时刻 $t-1$ 的隐藏层的状态; C_t 和 C_{t-1} 为当前时刻 t 和上一时刻 $t-1$ 的单元状态; x_t, h_t, C_t 为 t 时刻通过这 3 个门结构输入 LSTM, 每个门计算输入信息, 根据其逻辑功能决定是否激活; 遗忘门 f_t 丢弃记忆单元认为不重要信息; 输入门 i_t 识别单元状态中需保留新信息并用激活函数更新; 输出门 O_t 根据单元状态决定输出。以上过程可以表示为:

$$i_t = \sigma(T_i x_t + V_i h_{t-1} + q_i) \quad (5)$$

$$f_t = \sigma(T_f x_t + V_f h_{t-1} + q_f) \quad (6)$$

$$C_t = f_t \otimes C_{t-1} + i_t \otimes \tanh(T_c x_t + V_c h_{t-1} + q_c) \quad (7)$$

$$O_t = \sigma(T_o x_t + V_o h_{t-1} + q_o) \quad (8)$$

$$h_t = O_t \otimes \tanh(C_t) \quad (9)$$

$$\sigma = \text{sigmoid}(x) \quad (10)$$

其中: T, V 为矩阵参数; q_i 为偏置向量元素; \otimes 表示元素相乘; \tanh 表示非线性激活函数。

1.3 CEEMDAN-LSTM 组合预测模型流程

本文构建了基于 CEEMDAN 与 LSTM 组合的形变预测模型, 基本思路分为“分解、预测、重构”, 实现了对高层建筑形变监测数据的挖掘, 具体模型预测流程如图 2 所示。

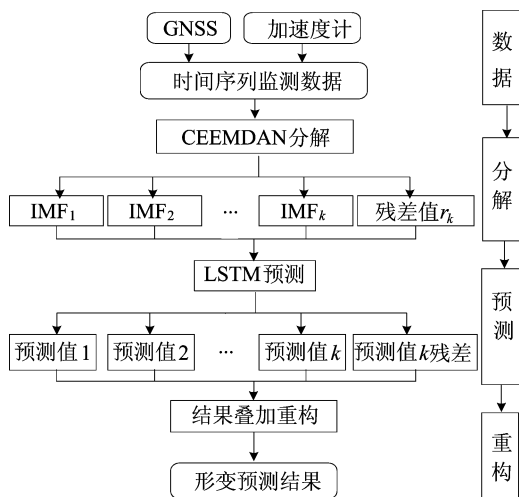


图 2 CEEMDAN-LSTM 组合模型预测流程

2 振动台模拟实验

振动台模拟高层建筑形变是一种结构实验重要手段, 能够在模拟真实环境中对建筑结构的动态响应进行模拟和评估。本文所用的振动台安装有 5 Hz 的 GNSS 传感器、100 Hz 的惯导, 控制终端以不同频率和振幅沿平面 X、Y 轴方向运动, 具体安装结构如图 3 所示。




图 3 振动台装置及设备

2.1 数据预处理和位移重构

振动台上惯导内加速度计原始数据如图 4 所示。由图 4 可知, 加速度计能够精准捕捉到加速度瞬时增大的关键时刻。




图 4 X 轴加速度

局部时段 GNSS 原始数据经过解算后得到的北向位移和加速度情况如图 5 所示。为更准确地识别真实形变, 提升对高层建筑振动微形变监测能力, 本文通过位移重构方法对数据进行预处理, 以便更好反映其形变特征。




图 5 位移和加速度

首先将北向位移进行滤波处理, 得到低频动态位移; 随后对加速度进行去噪及去除趋势项, 得到二次积分后的高频动态位移; 最后利用位移插值方式将 2 种传感器的位移进行整体重构, 重构后的位移如图 6 所示。




图 6 整体重构位移

2.2 LSTM 参数设置与训练

本实验中选取 GPS 时间 364 060~364 218 s 共 158 个历元数据作为模型输入,以前 150 个历元数据作为训练集,以后 8 个历元数据作为验证集。

针对训练集,通过循环遍历发现,设置初始学习率为 0.001、网络层数为 1、丢弃层概率为 0.5、隐藏单元数量为 370、衰减率一阶设置为 0.99、衰减率二阶设置为 0.999 时,性能最佳。

2.3 评价指标

本文选用均方根误差 (root mean square error, RMSE)、平均绝对误差 (mean absolute error, MAE)、平均绝对百分比误差 (mean absolute percentage error, MAPE) 指标来评价本文所提模型的优劣,其中 RMSE、MAE 和 MAPE 越小,表示模型的预测精度越高。相关指标的具体计算公式为:

$$E_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (11)$$

$$E_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i) \quad (12)$$

$$E_{\text{MAPE}} = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{\max(\epsilon, |y_i|)} \times 100\% \quad (13)$$

其中: \hat{y}_i 为预测值; y_i 为原始真实值; n 为预测值的总数; ϵ 为一个任意小但严格意义上的正数,以避免当 ϵ 为 0 时出现无法定义的结果。

2.4 预测结果分析

为了验证本文所提模型的有效性,本文选取单一 LSTM、EMD-LSTM 组合模型作为对照,分别计算以上 3 个模型的 RMSE、MAE、MAPE 指标,结果见表 1 所列,其中 8 个预测历元共有数据点 801 个。

由表 1 可知:本文所提模型与 EMD-LSTM 组合相比, RMSE、MAE、MAPE 3 个指标值分别降低了 45.5%、46.1%、65.2%;与单一 LSTM 相比,效果进一步提升,各降低了 54.9%、55.0%、83.6%。因此本文所提模型的整体效果更为理想、优势显著,预测的可靠性更高。

表 1 CEEMDAN-LSTM 有效性验证

指标	本文模型	EMD-LSTM	单一 LSTM
RMSE/mm	0.012 8	0.023 4	0.028 4
MAE/mm	0.010 3	0.019 1	0.022 9
MAPE/%	1.129 5	3.253 2	6.885 6

同时,以便直观对比分析,将预测结果与参照值同幅绘制折线,结果如图 7 所示。

从图 7 可以看出,单一 LSTM、EMD-LSTM 的预测精度皆不稳定,不符点较多,本文所提模型的预测值已与参考值整体趋势基本一致,仅有少量不符,由此可见在拟合程度上优于单一 LSTM 和 EMD-LSTM,在捕捉数据变化的规律上有着显著优势。




图 7 模型预测结果折线图

3 高层建筑形变监测应用

为了验证 CEEMDAN-LSTM 组合模型用于高层建筑动态监测预警方面的可靠性和性能,本文将该组合模型应用于某地一座超高层建筑的监测,监测方式同样为 GNSS 与加速度计融合监测,共选取 4 180 个历元的监测数据进行分析 and 处理。

经预处理后得到 E、N、U 这 3 个方向的位移序列,如图 8 所示,以前 4 100 个历元根据为训练数据,以后 80 个历元作为验证数据。




图 8 3 个方向位移序列

与振动台模拟实验一致,继续选用取单一 LSTM、EMD-LSTM 模型作为对照,即用 3 种模型分别按 3 种时长(10、30、70 s)分别对 3 个方向 (E、N、U) 时间序列进行预计与性能验证,对比曲线如图 9 所示。

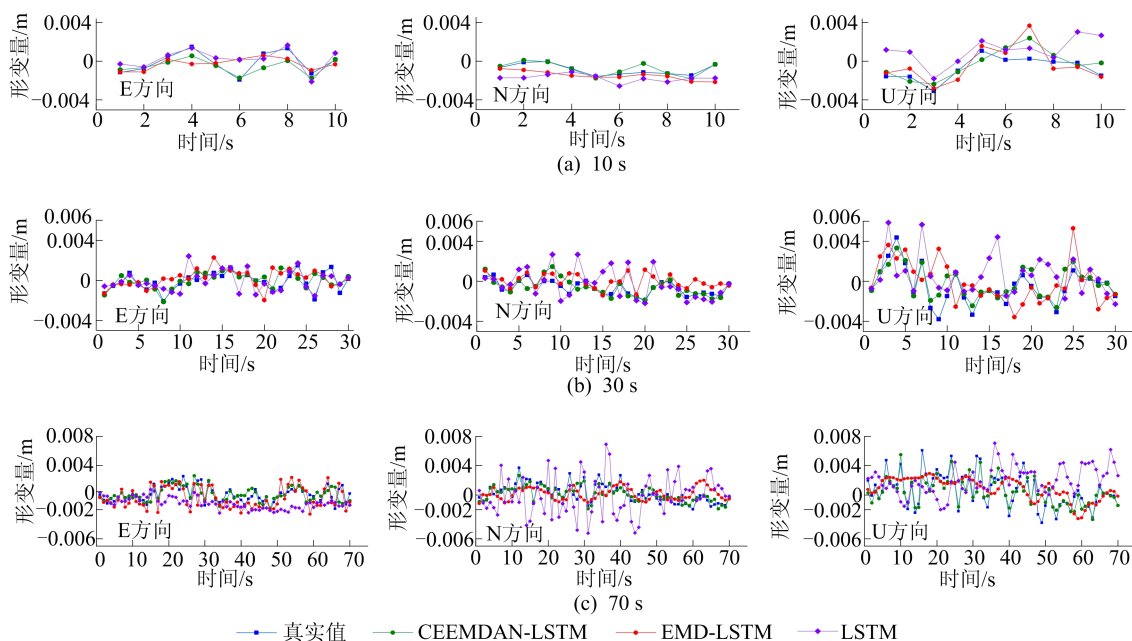



图9 不同方向在预测时长为 10、30、70 s 时的预测误差

从图 9a 可以看出:预测时长为 10 s 时,3 种模型形变量的整体表现相近,波动范围较小,但在 U 方向上仍有优劣,单一 LSTM 模型在 0~2 s、9~10 s 时偏差较大,占比较高;EMD-LSTM 模型在 7 s 时偏差较大,占比较低;本文所提模型的偏差最大值同样出现在 7 s,但是在图像上而言,其偏差值仅为 EMD-LSTM 模型的 60%。

从图 9b 可以看出:预测时长为 30 s 时,3 种模型预测形变量仅在 E 方向上表现相近,波动较小;在 N 方向上,单一 LSTM 模型仅在前 7 s 的波动较小,随后波动较大,效果较差,特别在中段偏差明显,EMD-LSTM 模型仅有少量偏差较大点位,多数预测值优于单一 LSTM 模型,本文所提模型仍较平稳,未见偏差较大点位,仅在 10 s 时的偏差略大于 EMD-LSTM 模型;在 U 方向上,各自变化趋势基本与 N 方向一致,而且

EMD-LSTM 模型出现了更多的偏差较大点位,效果进一步降低。从图 9c 可以看出:预测时长为 70 s 时,单一 LSTM 模型在 3 个方向上的预测效果均较差,在 E 方向上图像异常平稳,集中在 0 mm 附近,与实际数据趋势不符,而在 N、U 方向上图像波动异常,已无法用于预测、预警;EMD-LSTM 模型在 E 方向上效果尚可,仅在 40 s 处附近偏差略大,而在 N、U 方向上出现“过拟合”现象,已与实际数据趋势明显不符;本文所提模型在 3 个方向上均与实际数据趋势基本一致,未见偏差较大点位,但是部分点位偏差较整体较差。

为更加直观地反映 3 种模型的预测误差极值及稳定性,给出 3 种模型在不同预测时长时的误差曲线,但因在短预测时长 10 s 的表现相近,不再进行误差曲线分析,故而仅绘制 30、70 s 时长的误差曲线,如图 10 所示。






图 10 3 种模型误差曲线

由图 10 可知:预测时长为 30 s 时,单一 LSTM 模型仅在 E 方向上较平稳,在 N、U 方向上不平稳,极值由 $[-1.8, 2.2]$ m 扩大到 $[-3.8, 5.5]$ m, EMD-LSTM 在 E、N、U 方向上平稳性相当,极值在 $[-1.8, 3.6]$ m 内,本文所提模型在 3 个方向上的平稳性有进一步提升,极值在 $[-1.5, 2.6]$ m 内,且只有少量点位触发、临近极值;预测时长为 70 s 时,单一 LSTM 模型同样仅在 E 方向上较平稳,在 N、U 方向上反复震荡,极值已扩大到 $[-5.2, 7.7]$ m,平稳性进一步降低,EMD-LSTM 模型已无法在 E、N、U 方向上均平稳,特别在 U 方向上反复

震荡,极值扩大到 $[-3.8, 5.2]$ m,本文所提模型在 E、N、U 方向上仍较平稳,除 4 个点位的误差值较大(U 方向的最小 3.6 m、最大 4.9 m),极值仍稳定在 $[-2.3, 3.0]$ m 内,与 30 s 基本一致,未见反复震荡现象。

基于预测、误差曲线的直观分析,本文所提模型在不同方向、不同时长上均更优,且随着预测时长的延长,本文所提模型已是唯一可靠的模型。为进一步定量统计 3 种模型的精度表现,计算出以上 3 种模型预测结果的 RMSE、MAE 和 MAPE,结果见表 2 所列。

表 2 3 种模型在不同预测模型时的评价指标表

模型	指标	预测时长 10 s			预测时长 30 s			预测时长 70 s		
		E	N	U	E	N	U	E	N	U
CEEMDAN-LSTM	RMSE/mm	0.723	0.335	1.014	0.853	0.595	0.966	0.829	0.752	1.311
	MAE/mm	0.535	0.214	0.843	0.605	0.429	0.709	0.594	0.576	0.867
	MAPE/%	0.611	0.505	2.293	2.171	4.745	1.238	1.800	5.484	0.716
EMD-LSTM	RMSE/mm	0.967	0.794	1.221	1.137	1.051	2.324	1.132	1.333	2.192
	MAE/mm	0.667	0.605	0.829	0.845	0.768	1.661	0.907	1.121	1.758
	MAPE/%	0.789	6.318	3.488	3.804	12.86	3.027	4.615	7.264	2.153
LSTM	RMSE/mm	0.834	1.020	2.188	0.770	1.374	2.286	1.670	2.881	3.509
	MAE/mm	0.642	0.883	1.857	0.561	0.956	1.750	1.396	2.357	2.985
	MAPE/%	1.059	8.073	4.915	4.150	7.681	1.914	4.802	13.03	5.196

由表 2 可知:对于 RMSE、MAE 模型,本文所提模型在不同方向、不同时长时皆优于其他 2 种,可见其最优性,其仅在 U 方向、70 s 时长时略大于 1.0 mm; EMD-LSTM 次之,最大值在 U 方向、30 s 时长时(2.3 mm),多小于 2.0 mm;单一 LSTM 最差,最大值在 U 方向、70 s 时长时为 3.5 mm,多于 2.0 mm。

对于 MAPE 指标,本文所提模型在 N 方向和 30、70 s 时长时较大,但是仍优于其他 2 种,余下情况均小于 2.5%;同样,EMD-LSTM 次之,但多数大于 3.0%;单一 LSTM 最差,最大值高达 13.0%,且多数大于 4.5%。

比较而言,本文所提模型在 E、N、U 这 3 个方向上的最优 RMSE、MAE、MAPE 与 EMD-

LSTM 模型相比分别降低了 43%、50%、64%;与单一 LSTM 相比分别降低了 73%、75%、87%,精度提升显著,预测性能更优。

综上所述,本文所提模型能够提高预测的准确性和稳定性,特别是对于长预测时长,避免单一 LSTM、EMD-LSTM 的不可用性,为高层建筑形变监测应用提供更可靠的预测结果。

4 结 论

针对高层建筑的形变预测问题,本文提出一种基于 CEEMDAN-LSTM 的形变预测组合模型,通过模拟实验和监测数据进行了全面验证。基于以上研究,得出结论如下:

- 1) GNSS 与加速度计结合的方式可实现全

频域的高精度结构微变形位移重构,反映了高层建筑真实的形变信息,能够有效地减少粗差对于该模型预测精度的影响。

2) 利用 CEEMDAN 进行高层建筑形变监测时间序列的预处理,能够获得更贴近实际的时间序列分量,进而为后续的模型预测提供更可靠的输入,保障预测精度。

3) 对比实验进一步验证了本文所提模型的优越性。与 EMD-LSTM、单一 LSTM 模型相比,CEEMDAN-LSTM 模型在预测精度、稳定性等方面均表现出明显的优势。

综上,基于 CEEMDAN 与 LSTM 的高层建筑形变预测组合模型具有较高的预测精度和稳定性,能为高层建筑的安全监测和预警提供有力的技术支持。未来将继续深入研究该模型的优化方法,以期提高性能,并探索在更多领域的应用潜力。

[参 考 文 献]

- [1] 王亚荣,黄声亭,匡翠林. 融合 GNSS 和加速度计监测数据的超高建筑动态特性分析[J]. 测绘通报,2019(8):14-19.
- [2] 林巍,黄铭枫,郭中秀,等. 台风下香港 K11 大楼风振响应实测及分析[J]. 深圳大学学报(理工版),2012,29(1):45-50.
- [3] 杨静,李大鹏,翟长海,等. 城市抗震韧性的研究现状及关键科学问题[J]. 中国科学基金,2019,33(5):525-532.
- [4] 杨静,李大鹏,岳清瑞,等. 建筑与基础设施全寿命周期智能化的研究现状及关键科学问题[J]. 中国科学基金,2021,35(4):620-626.
- [5] 单伽程,张茜,吕西林,等. 多元特征驱动的超高层建筑变形状态智能学习与预测[J]. 建筑结构学报,2024,45(3):101-112.
- [6] YI Z, KUANG C, WANG Y, et al. Combination of high-and low-rate GPS receivers for monitoring wind-induced response of tall buildings[J]. Sensors,2018,18(12):4100.
- [7] OGAIA C, WANG J, RIZOS C. Detection of wind-induced response by wavelet transformed GPS solutions[J]. Journal of Surveying Engineering,2003,129(3):99-104.
- [8] HAN H, LI R, XU T, et al. A similarity clustering deformation prediction model based on GNSS/accelerometer time-frequency analysis[J]. Applied Sciences,2024,14(16):6889.
- [9] HAN H, MA W, XU Q, et al. A Welch-EWT-SVD time-frequency feature extraction model for deformation monitoring data[J]. Measurement,2023,222:113709.
- [10] 易黄智,高飞. 基于 GA-BP 神经网络的地铁变形预测模型[J]. 合肥工业大学学报(自然科学版),2021,44(11):1513-1517.
- [11] 田紫圆,何佳楠,吴震宇,等. 基于 EMD 的重力坝变形监测统计模型及应用[J]. 人民黄河,2022,44(10):108-112.
- [12] 梁永平,王江荣. 基于小波-EMD 耦合模型的桥墩变形信息提取研究[J]. 海洋测绘,2023,43(2):25-29.
- [13] 段青达. 基于改进型 CEEMD-SVD 的高边坡变形数据消噪分析及建模研究[D]. 桂林:桂林理工大学,2020.
- [14] 周博韬,彭浩,卢海林,等. CEEMDAN-改进小波阈值联合去噪算法在地表沉降预测中的应用[J]. 武汉工程大学学报,2025,47(4):455-460.
- [15] 李爱国,平书哑,郭敏. CEEMDAN 和 3σ 组合的 GNSS 坐标时间序列粗差探测[J]. 测绘科学,2023,48(4):60-67,191.
- [16] 何立新,伍玉龙,龙岩,等. 基于 CEEMDAN 分解与混合神经网络的径流预报模型[J]. 南水北调与水利科技(中英文),2025,23(6):1379-1389.
- [17] 赵云锋,陈林林,罗忠浩,等. 基于 CEEMDAN 的矿山微震信号特征提取和分类方法[J]. 矿业安全与环保,2025,52(2):105-112,120.
- [18] 杨国林,孙学先,锁旭宏,等. 桥梁形变监测中 LSTM 预测方法研究[J]. 兰州交通大学学报,2022,41(5):1-5.
- [19] 洪智超,丁羿杰,刘蕾,等. 一种改进的 LSTM 船舶运动极短期预报方法[J]. 船舶力学,2025,29(9):1383-1396.
- [20] 刘增山,冯亮花,孔令种,等. 基于长短期记忆网络模型的转炉吹炼过程预测[J]. 钢铁研究学报,2025,37(8):1023-1031.
- [21] 欧斌,张才溢,陈德辉,等. 基于 EMD-小波阈值-LSTM 模型的混凝土坝变形预测[J]. 排灌机械工程学报,2025,43(4):379-386.
- [22] 林子安. 滑坡多源信息融合及预测预警方法研究[D]. 桂林:桂林电子科技大学,2023.
- [23] GUO T, XU Z, YAO X, et al. Robust online time series prediction with recurrent neural networks [C]//2016 IEEE International Conference on Data Science and Advanced Analytics (DSAA). Montreal, Q C: IEEE, 2016:816-825.
- [24] WANG X, LIU W, WANG Y, et al. A hybrid NO_x emission prediction model based on CEEMDAN and AM-LSTM[J]. Fuel,2022,310:122486.
- [25] 戴邵武,陈强强,刘志豪,等. 基于 EMD-LSTM 的时间序列预测方法[J]. 深圳大学学报(理工版),2020,37(3):265-270.

(责任编辑 吴 亮)