文章编号:1674-2974(2025)03-0082-12 DOI:10.16339/j.cnki.hdxbzkb.2025029

基于改进经验模态分解与BiLSTM神经网络的低矮房屋脉动风压时程预测

邱冶 ,袁有明 ,伞冰冰 †
(河海大学 土木与交通学院, 江苏 南京 210098)

摘 要:为解决风压测量中传感器数据间歇性缺失问题,提出基于改进经验模态分解算法(IEMD)和双向长短期记忆网络(BiLSTM)的结构表面风压时程预测方法.首先,采用基于软筛分停止准则的改进经验模态分解方法,将风压时程自适应地分解为多个固有模态函数,并通过样本熵对其进行重构获得子序列;其次,针对各子序列完成双向长短期记忆网络的构建、训练及预测,并利用贝叶斯优化(BO)算法对神经网络超参数进行优化;最后,基于低矮房屋风洞测压试验数据进行了风荷载预测,验证了学习模型的有效性.研究表明,与传统预测模型(多层感知器、BiLSTM)相比,基于改进经验模态分解与BiLSTM神经网络的预测模型具有较高的预测精度和计算效率,适用于高斯与非高斯风压信号预测.

关键词:低矮房屋;风荷载;深度学习;双向LSTM;改进经验模态分解;贝叶斯优化;时程预测

中图分类号:TU352.2 **文献标志码**:A

Prediction of Fluctuating Pressure Time Series of Low-rise Buildings Based on Improved Empirical Mode Decomposition and BiLSTM Nueral Networks

QIU Ye, YUAN Youming, SAN Bingbing†
(College of Civil and Transportation Engineering, Hohai University, Nanjing 210098, China)

Abstract: To solve the problem of intermittent missing sensor data in wind pressure measurements, a method for predicting the wind pressure time series on the surface of structures by combining the improved empirical mode decomposition algorithm (IEMD) with bidirectional long short-term memory (BiLSTM) networks is proposed. First of all, intrinsic mode functions (IMFs) are obtained through the adaptive decomposition of wind pressure time series using the IEMD method with soft sifting stopping criterion. The sample entropy is adopted to reconstruct IMFs and obtain subsequences. Then, BiLSTM networks are established and trained with these subsequences, while the prediction is also conducted, in which the Bayesian algorithm is employed to optimize the hyperparameters of neural networks. Finally, a case study of wind load prediction based on the wind tunnel test data of low-rise buildings is conducted to validate the proposed model. The results show that, compared with the traditional prediction models (e.g. multi-layer perceptron, BiLSTM), the prediction model based on IEMD and BiLSTM presents higher accuracy

* **收稿日期**:2024-03-10
基金项目:国家自然科学基金资助项目(51808194, 51978240), National Natural Science Foundation of China(51808194, 51978240)
作者简介:邱冶(1985—),男,黑龙江哈尔滨人,河海大学副教授,博士
† 通信联系人,E-mail: sanbingbing@hhu.edu.cn

and calculation efficiency, which is capable of predicting Gaussian and non-Gaussian wind pressure signals.

Key words: low-rise building; wind load; deep learning; BiLSTM; improved empirical mode decomposition; Bayesian optimization; time series prediction

低矮房屋受特征湍流影响显著的区域，其表面风压会表现出明显的非高斯特性，易诱发围护结构风致破坏[1]. 设计风荷载的准确估计可通过现场实测或风洞测压试验实现，但在信号采集过程中，传感器数据间歇性缺失可能导致风荷载取值不准确. 近年来，众多学者采用机器学习方法从有限风压时程数据中提取出特征信息，建立了测压信号预测模型，弥补测量时因各种原因而缺失的时程数据，对于低矮房屋抗风设计具有重要的工程意义[2-4].

机器学习通过一些算法训练提取数据特征并建立模型，使之具备一定的判断和预测能力，该方法在风工程领域得到越来越广泛的应用. 常用的算法有神经网络（NNs）、随机森林（RF）和支持向量机（SVM）等. 基于机器学习的风压场和气动响应模型，可实现风荷载与风效应宏观指标的预测，如风速[5]、结构表面风压分布[6-10]、整体体型系数[11]和风力系数[12-13]等. 然而，相较于风压分布预测，结构的风压及响应时程预测通常因时程的非平稳特性而具有较大难度，相关研究较少.

相较于传统机器学习方法，深度学习方法具有更优异的特征识别和表达能力，在处理大量、复杂的数据时具有显著优势. 因此，部分学者尝试将深度学习应用于脉动风压、脉动流场和非定常气动力的时间序列预测中. Huang 等[14]分别使用深度神经网络（DNN）和支持向量机对超高层建筑表面非高斯风压时程进行了预测分析，并利用粒子群优化算法（PSO）来选择和优化模型参数，经对比发现 PSO-DNN 的预测性能具有一定优势. 陈伏彬等[15]结合反向传播神经网络（BPNN）与本征正交分解（POD）方法，准确预测了大跨度平屋盖模型测点的脉动风压时程. 长短期记忆网络（LSTM）与其变体双向长短期记忆网络（bidirectional LSTM，BiLSTM）具有更强大的非线性建模能力和泛化能力，逐渐受到诸多学者的青睐；Li 等[16]通过 LSTM 网络构建了风-桥相互作用的降阶模型，准确预测了桥梁结构的非线性非定常气动力；Lim 等[17]结合 LSTM 与时移数据校正方法构建了预测模型，成功预测了台风作用下桥梁周围的短期风速；武频等[18]结合 LSTM 和自编码器构建了降阶模型，对二维圆柱绕流流场进行特征提取和预测，得到了比传统模态分解法精度更高的结果；Li 等[19]分别将支持向量回归、随机森林、反向传播神经网络、LSTM 和 LSTM-SVR 这 5 种机器学习模型应用于低矮房屋表面非高斯脉动风压时程的预测，其中 LSTM 和 LSTM-SVR 深度学习模型具有最优的预测精度.

原始样本数据的非平稳和噪声将直接影响深度学习模型的泛化性能，也是限制该类模型的实际应用的重要因素[20]. 已有学者将信号分解技术与深度学习相结合，通过识别时序数据的内在特征，进一步改善模型的实际性能，并形成“分解—预测—重构”的主流方案. Li 等[21]将变分模态分解、粒子群优化算法与 BiLSTM 相结合，完成了台风风速时程的短期预测，由于原始时间序列经变分模态分解后非平稳特性大幅降低，模型的精度有显著提高；Lü 等[22]利用改进集成经验模态分解提高了 LSTM 模型预测性能，并使用多目标蚁狮优化方法进行训练，使模型在非平稳风速预测上达到更好的效果；Jaseena 和 Kovoor[23]提出了基于经验小波变换的 BiLSTM 预测模型，实现了实测场地风速时程预测，该方法相比于未进行数据分解的 BiLSTM 预测方法，能够显著提高风速时序的预测精度.

目前，针对低矮房屋风压时程的预测研究较少，结构表面风压呈现出的强烈非高斯随机特性将导致较大的预测误差. 另外，预测模型的最优超参数一般通过在训练数据集中进行交叉验证获得，而深度学习网络具有超参数选择困难、学习效率低的问题[24]. 因此，本文将改进经验模态分解技术（IEMD）与 BiLSTM 结合，通过对数据进行预分解，提高预测的稳定性和精度，并利用贝叶斯优化（BO）算法对 BiLSTM 模型进行超参数优化，使得预测结果更加精确.

本文以双向长短期记忆网络为基础，结合改进经验模态分解算法，构建了一种基于 IEMD-BiLSTM 的风压时间序列预测方法，依据样本熵理论降低计

算规模,并使用贝叶斯优化算法寻找性能最优的BiLSTM模型.以低矮房屋风洞测压试验数据为例,选取4组预测模型作为对照,验证本文所建立模型的有效性和准确性,对于高斯和非高斯风压信号具有稳定可靠的预测表现.该方法可以有效解决风场实测或风洞测压试验过程中风压测量数据间歇性缺失的问题,具有工程应用价值.

1 预测方法

1.1 改进经验模态分解

经验模态分解(EMD)是一种有效的非线性时间信号分解方法,常用于非平稳时间信号的分析[25].原始时间序列经过分解可转化为一系列固有模态函数(IMF),其过程如下:

1)识别时间序列$x(t)$中的所有极大、极小值点,以移动平均方法得到$x(t)$的极值包络线,并计算$x(t)$与包络线平均值$m_1(t)$的差值$h_1(t)$,即$h_1(t)=x(t)-m_1(t)$.

2)判断差值$h_1(t)$是否为IMF.若否,则令$h_1(t)$为新循环中的原始序列,重复步骤1),直至$h_1(t)$为IMF;若是,则$h_1(t)$作为第1个IMF分量,$c_1(t)=h_1(t)$,将$x(t)$与IMF的差值记为残余分量$r_1(t)$,即$r_1(t)=x(t)-c_1(t)$.

3)将$r_1(t)$作为新的原始序列,重复步骤1)和步骤2),继续筛分得到其余IMF分量,直到残余分量$r_n(t)$很小或为一单调函数.$x(t)$可表示为

$$x(t)\sum_{i=1}^{n}c_i(t)+r_n(t) \tag{1}$$

上述EMD的筛分停止准则需要预先设定阈值,不具有自适应性,分解结果受人为因素的干扰较大.改进经验模态分解(IEMD)则采用软筛分停止准则(SSSC),首先提出一个描述包络均值信号的目标函数f_{ij}:

$$f_{ij}=\mathrm{RMS}_{ij}+\left|\mathrm{EK}_{ij}\right| \tag{2}$$

$$\mathrm{EK}_{ij}=\frac{\frac{1}{n_s}\sum_{k=1}^{n_s}\left(m_{ij}[k]-\bar{m}\right)^4}{\left[\frac{1}{n_s}\sum_{k=1}^{n_s}\left(m_{ij}[k]-\bar{m}\right)^2\right]^2} \tag{3}$$

$$\mathrm{RMS}_{ij}=\sqrt{\frac{1}{n_s}\sum_{k=1}^{n_s}\left(m_{ij}[k]\right)^2} \tag{4}$$

式中:$m_{ij}[k]$表示第i个IMF筛分j次后的包络均值信号,$k=1,2,\cdots,n_s$,n_s为总采样点数;EK_{ij}和RMS_{ij}分别为$m_{ij}[k]$的超峭度和均方根;m为所有$m_{ij}[k]$的算术平均值.

软筛分停止机制能够驱动算法自适应地确定单个筛分环节中的最优迭代次数,可有效地处理端点效应和模态混叠,改善时序信号的分解精度与效率,具体流程见文献[26].故本研究采用IEMD方法对风压时间序列进行分解.

1.2 样本熵算法

样本熵(SE)是一种时序信号复杂度的评价指标[27].该指标可评估序列的自相似性,时序的自相似程度和复杂度与样本熵成反比:

1)重构时序$\{x_i\}=\{x_1,x_2,\cdots,x_N\}$为一组$M$维向量,即$\boldsymbol{X}_i=[x_i,x_{i+1},\cdots,x_{i+M-1}]$,其中$i=1,2,\cdots,N-M+1$,$N$表示样本点总数.

2)定义向量$\boldsymbol{X}_i$与$\boldsymbol{X}_j$之间对应元素中最大差值的绝对值为两者之间的距离.

$$d_M\left(\boldsymbol{X}_i,\boldsymbol{X}_j\right)=\max_{q\in[0,M-1]}\left|\boldsymbol{X}_{i+q},\boldsymbol{X}_{j+q}\right| \tag{5}$$

3)计算所有i值中$d_M(\boldsymbol{X}_i,\boldsymbol{X}_j)<\varepsilon$ $(1\leqslant i,j\leqslant N-M+1,i\neq j)$的个数,记作$A_i$;类似地,将维数扩展至$M+1$,计算$d_{M+1}(\boldsymbol{X}_i,\boldsymbol{X}_j)<\varepsilon$ $(1\leqslant i,j\leqslant N-M,i\neq j)$的个数,并记作$B_i$.计算样本熵公式如下:

$$A_M(\varepsilon)=\frac{1}{N-M+1}\sum_{i=1}^{N-M+1}\frac{1}{N-M}A_i \tag{6}$$

$$A_{M+1}(\varepsilon)=\frac{1}{N-M}\sum_{i=1}^{N-M}\frac{1}{N-M+1}B_i \tag{7}$$

$$\mathrm{SE}=-\ln\left[B_{M+1}(\varepsilon)/A_M(\varepsilon)\right] \tag{8}$$

式中:ε表示相似容差.以样本熵为指标,对IMF分量进行归类叠加,从而生成子序列,再对子序列进行建模预测分析,以降低训练任务量.

1.3 双向长短期记忆网络(BiLSTM)

以循环神经网络为基础,长短期记忆神经网络(LSTM)克服了前者在反向传播过程中的梯度问题,具有较强的时序问题处理能力[28].

LSTM网络主要由记忆单元和门控单元(输入门、遗忘门和输出门)组成.记忆单元用于存储并更新状态信息,输入门决定输入序列中哪些信息可以被传入单元,遗忘门选择性遗忘上一单元隐藏状态的部分信息,输出门筛选被传入下一单元的信息.BiLSTM以由两层异向的LSTM网络为基础,考虑了前后不同时刻时序数据之间的相互影响,克服了

LSTM 中数据单向流动的局限性,宜作为本研究构建风压时程预测模型的核心算法. BiLSTM 的基本结构如图 1 所示,其记忆单元核心部分的数学表达式如下:

$$i(t)=\sigma\left[W_{\mathrm{i}}x(t)+U_{\mathrm{i}}h(t-1)+b_{\mathrm{i}}\right] \tag{9}$$

$$O(t)=\sigma\left[W_{\mathrm{o}}x(t)+U_{\mathrm{o}}h(t-1)+b_{\mathrm{o}}\right] \tag{10}$$

$$f(t)=\sigma\left[W_{\mathrm{f}}x(t)+U_{\mathrm{f}}h(t-1)+b_{\mathrm{f}}\right] \tag{11}$$

式中:$i(t)$、$O(t)$和$f(t)$分别为输入门、输出门和遗忘门的状态值;$\sigma[\cdot]$为 Sigmoid 激活函数;W和U为权重;b为偏置项.

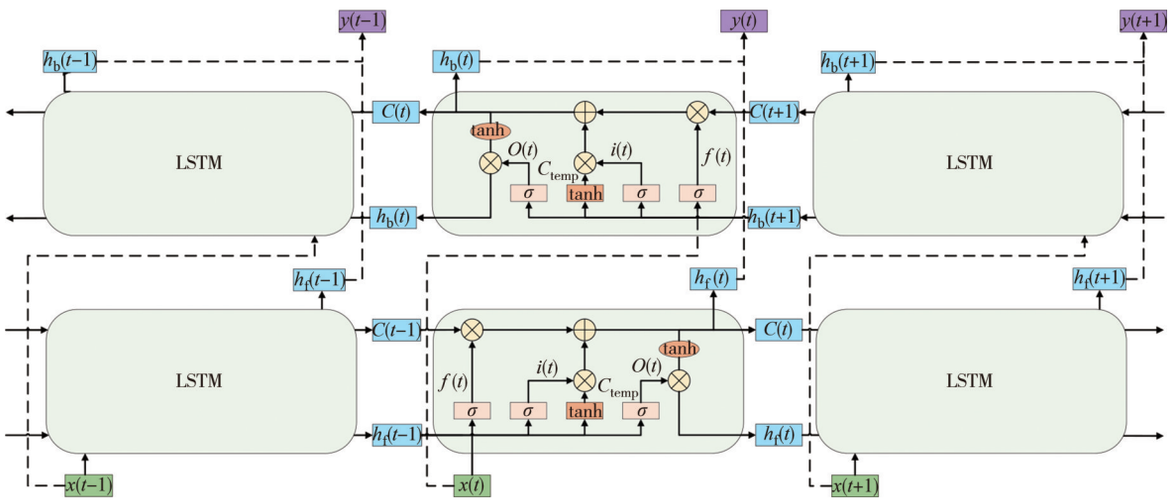


图 1　BiLSTM 神经网络结构

Fig.1　Structure of BiLSTM neural network

当前记忆单元在t时刻的状态值$C(t)$通过下式进行更新:

$$C_{\mathrm{temp}}(t)=\tanh\left[W_{\mathrm{c}}x(t)+U_{\mathrm{c}}h(t-1)+b_{\mathrm{c}}\right] \tag{12}$$

$$C(t)=i(t)\otimes C_{\mathrm{temp}}(t)+f(t)\otimes C(t-1) \tag{13}$$

式中:$C_{\mathrm{temp}}(t)$为记忆单元状态增量;$\otimes$表示矩阵逐元素相乘. $C(t)$经过 tanh 函数和输出门$O(t)$筛选后可得到输出结果$h(t)$:

$$h(t)=O(t)\otimes\tanh\left[C(t)\right] \tag{14}$$

如图 1 所示,BiLSTM 在同一时刻综合了两异向 LSTM 单元的状态信息,并得出最终输出值$y(t)$:

$$y(t)=W_y^{\mathrm{f}}h_{\mathrm{f}}(t)+U_y^{\mathrm{b}}h_{\mathrm{b}}(t)+b_y \tag{15}$$

式中:$h_{\mathrm{f}}(t)$和$h_{\mathrm{b}}(t)$分别表示向前层和向后层的单元输出. 通过这种双向结构,BiLSTM 每个时刻的记忆单元均包含时间序列的过去和未来数据信息,可以更充分地学习特征序列的时间依赖性,从而对未知时间序列进行有效预测.

1.4　贝叶斯优化算法

参数设置是影响深度学习模型性能的关键因素. 为确保模型精度与鲁棒性,本研究利用贝叶斯优化(BO)算法确定深度学习模型参数,其过程表示为:

$$\xi'=\underset{\xi\in\Psi}{\arg\max}f(\xi) \tag{16}$$

式中:ξ和ξ'分别为待优化超参数及其最优值;Ψ为超参数空间;f为目标函数.

BO 算法的核心是:1)运用代理模型拟合真实目标函数;2)依据后验信息构造样本点的采集方法,即采集函数.

1.4.1　代理模型

高斯过程回归是贝叶斯优化算法中的一种常用代理模型,适用于确定深度学习算法的超参数. 假设目标函数是由均值函数μ和协方差函数k构成的高斯函数的映射. 首先假定一个均值为 0 的先验分布:

$$P\left(f\,|\,\boldsymbol{X},\xi\right)=N\left(0,\boldsymbol{\Sigma}\right) \tag{17}$$

式中:$\boldsymbol{X}$表示训练输入集$\{\boldsymbol{x}_i\}_{i=1}^{n}$;$\boldsymbol{f}$为未知函数值$f$的集合;$\boldsymbol{\Sigma}$为协方差矩阵,其中$\boldsymbol{\Sigma}_{ij}=k(\boldsymbol{x}_i,\boldsymbol{x}_j)$.

考虑观测噪声ε满足高斯独立同分布,即$p(\varepsilon)\sim N(0,\sigma_\varepsilon^2)$,则似然分布为:

$$p\left(\boldsymbol{y}\,|\,\boldsymbol{f}\right)=N\left(\boldsymbol{f},\sigma_\varepsilon^2\boldsymbol{I}\right) \tag{18}$$

式中:$\boldsymbol{y}$表示观测值$y=f(\boldsymbol{x})+\varepsilon$的集合;$\boldsymbol{I}$为单位矩阵;$\sigma_\varepsilon^2$表示噪声$\varepsilon$的方差. 进一步可确定边际似然分布,使边际似然分布最大化可实现超参数ξ的优化.

$$p\left(\boldsymbol{f}\,|\,\boldsymbol{X},\xi\right)=N\left(0,\boldsymbol{\Sigma}+\sigma_\varepsilon^2\boldsymbol{I}\right) \tag{19}$$

根据高斯过程的性质,存在如下联合分布:

$$\begin{bmatrix} \boldsymbol{y} \\ \boldsymbol{f}_* \end{bmatrix} \sim N\left(0, \begin{bmatrix} \boldsymbol{\Sigma} + \sigma_\varepsilon^2 \boldsymbol{I} & \boldsymbol{K}_* \\ \boldsymbol{K}_*^{\mathrm{T}} & k(\boldsymbol{X}_*, \boldsymbol{X}_*) \end{bmatrix}\right) \tag{20}$$

式中:$\boldsymbol{f}_*$表示预测函数值集合;$\boldsymbol{X}_*$为预测输入集;$\boldsymbol{K}_* = [k(\boldsymbol{X}_*, \boldsymbol{x}_1), k(\boldsymbol{X}_*, \boldsymbol{x}_2), \cdots, k(\boldsymbol{X}_*, \boldsymbol{x}_n)]^{\mathrm{T}}$.可获得如下预测分布

$$p(\boldsymbol{f}_* | \boldsymbol{X}, \boldsymbol{y}, \boldsymbol{X}_*) = N[\langle \boldsymbol{f}_* \rangle, \mathrm{cov}(\boldsymbol{f}_*)] \tag{21}$$

$$\langle \boldsymbol{f}_* \rangle = \boldsymbol{K}_*^{\mathrm{T}} [\boldsymbol{\Sigma} + \sigma_\varepsilon^2 \boldsymbol{I}]^{-1} \boldsymbol{y} \tag{22}$$

$$\mathrm{cov}(\boldsymbol{f}_*) = k(\boldsymbol{X}_*, \boldsymbol{X}_*) - \boldsymbol{K}_*^{\mathrm{T}} [\boldsymbol{\Sigma} + \sigma_\varepsilon^2 \boldsymbol{I}]^{-1} \boldsymbol{K}_* \tag{23}$$

式中:$\langle \boldsymbol{f}_* \rangle$和$\mathrm{cov}(\boldsymbol{f}_*)$分别表示预测均值和协方差.

1.4.2 采集函数

预期改进(EI)函数具有整合提升概率,反映不同提升量的优点,故本研究采用EI作为采集函数,其计算公式如下:

$$\alpha_n(\boldsymbol{x}; D_{1:n}) = \begin{cases} (v^* \mu_n(\boldsymbol{x}) + \sigma_n(\boldsymbol{x})) \Phi\left(\dfrac{v^* \mu_n(x)}{\sigma_n(x)}\right), \sigma_n(\boldsymbol{x}) > 0 \\ 0, \ \sigma_n(\boldsymbol{x}) = 0 \end{cases} \tag{24}$$

式中:v^*为函数最优值;$\Phi(\cdot)$为标准正态密度函数.

2 风压时程预测模型

2.1 风压时程预测流程

建筑表面风压时序通常具有强烈的非高斯随机特性,针对原始数据进行预测会造成较大误差.本文通过改进经验模态分解降低模型训练的复杂度,再利用样本熵缩减计算规模,最后构建双向长短期记忆网络风压时程预测模型,并采用贝叶斯优化算法进行超参数优化,以提高预测的精确性.为便于后文分析,该方法简记为IEMD-SE-BO-BiLSTM,其预测流程如图2所示,具体步骤如下:

步骤1 对原始风压时间序列进行IEMD分解,以降低风压信号的非平稳性,得到一系列IMF分量及残余分量Res.

步骤2 以样本熵为指标对IMF分量的自相似特性进行分析,将样本熵值相近的IMF分量进行合并,由此得到新子序列(Sub).

步骤3 数据预处理与数据集划分.首先,创建时间序列滑动窗口,构造时程信号内部前后数据之间的映射关系,使预测任务转变为单个时间变量的回归问题,以便开展预测;其次,利用Z-Score标准化方法将时序数据转化为均值为0、方差为1的标准化数据.

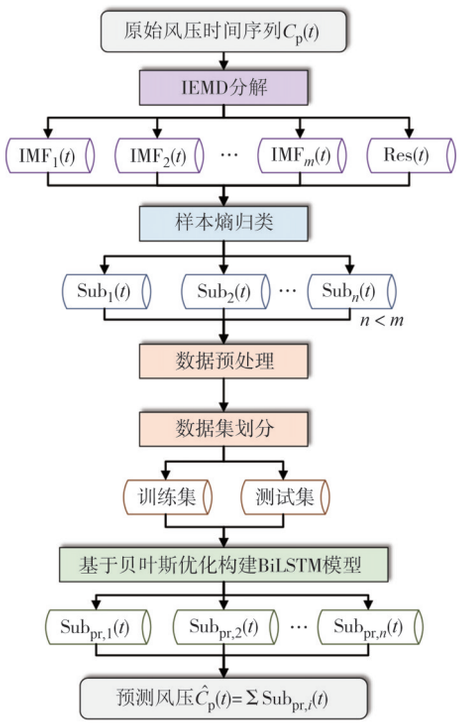


图2 风压时程预测流程图

Fig.2 Flow chart of wind pressure time series prediction

$$\mathrm{Sub}_{i,\,\mathrm{norm}} = \frac{\mathrm{Sub}_i - \mathrm{mean}(\mathrm{Sub}_i)}{\mathrm{Std}(\mathrm{Sub}_i)} \tag{25}$$

式中:$\mathrm{mean}(\mathrm{Sub}_i)$和$\mathrm{Std}(\mathrm{Sub}_i)$分别为第$i$个子序列的均值和标准差.

步骤4 构建BiLSTM预测模型并划分数据集,设置模型待优化的超参数(初始学习率、最小批量尺寸等)及其区间,以训练集中子序列预测值与实际值之间的均方误差作为评价函数,进行贝叶斯优化直至收敛;得到性能最优的模型.

步骤5 反标准化子序列,并对其进行叠加求和,实现对风压时间序列的预测,并对最终的预测模型性能进行评价与分析.

2.2 模型性能评价指标

选取下列4种指标评估模型实际性能,各指标计算公式如下:

$$\mathrm{MAE} = \frac{1}{n} \sum_{i=1}^{n} \left| \hat{C}_{\mathrm{p}i} - C_{\mathrm{p}i} \right| \tag{26}$$

$$\mathrm{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^{n} \left(\hat{C}_{\mathrm{p}i} - \bar{C}_{\mathrm{p}i} \right)^2} \tag{27}$$

$$\mathrm{MAPE} = \frac{1}{n} \sum_{i=1}^{n} \left| \frac{\hat{C}_{\mathrm{p}i} - C_{\mathrm{p}i}}{C_{\mathrm{p}i}} \right| \times 100\% \tag{28}$$

$$R^2 = 1 - \frac{\sum_{i=1}^{n}\left(\hat{C}_{pi} - C_{pi}\right)^2}{\sum_{i=1}^{n}\left(\bar{C}_{pi} - C_{pi}\right)^2} \tag{29}$$

式中:n为时程样本点的数量;C_{pi}和$\hat{C}_{pi}$分别为风压系数实际值和预测值;$\bar{C}_{pi}$为所有风压系数实际值的算术平均值.

式(26)~式(29)依次为平均绝对误差、均方根误差、平均绝对百分比误差和决定系数.R^2与精度成正比,其余指标与精度成反比.

3　基于风洞测压数据的预测算法验证

本文依据日本东京工艺大学低矮建筑气动数据库中的刚性模型风洞测压试验结果,以长宽高之比为6:4:1的平屋盖建筑为研究对象,开展了风压时程预测研究.

3.1　风洞试验数据概述

平屋盖风洞试验模型及测点布置见图3,模型几何尺寸为24 cm×16 cm×4 cm,几何缩尺比为1:100.风洞试验采样频率为500 Hz,采样时长T=18 s.风洞试验的平均风速和湍流度剖面与日本规范RLB-AIJ(2004)的对比情况如图4所示,其中U_H为屋盖高度H处的平均风速.不同特征湍流(锥形涡或柱状涡)作用会导致结构表面的风压脉动剧烈程度存在较大差异,为考察其对风压时程预测结果的影响,选取0°、45°和90°三组代表性风向角工况进行讨论.首先,对三组风向角下平屋盖表面各测点脉动风压的高阶统计量进行分析,以偏度值(|S|>0.5)和峰度值(K>3.5)为标准来判断测点时程的非高斯特性.三种风向角下屋盖表面的平均风压系数和非高斯分区结果如图5所示,区域Ⅰ为非高斯区,区域Ⅱ为高斯区.

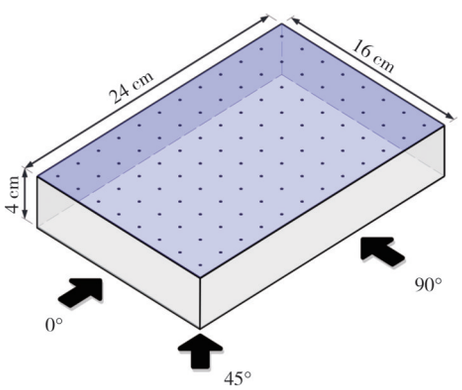


图3　风洞试验模型及测点布置

Fig.3　Wind tunnel test model and measuring taps arrangement

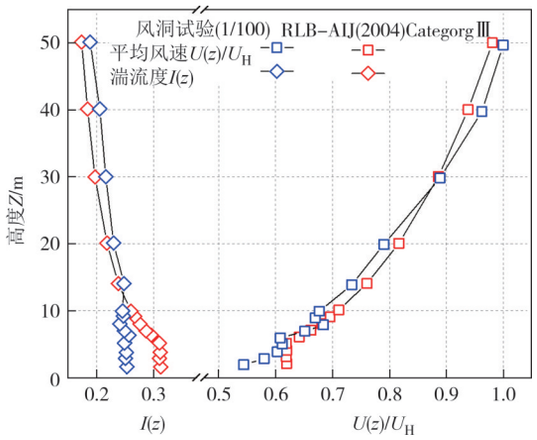
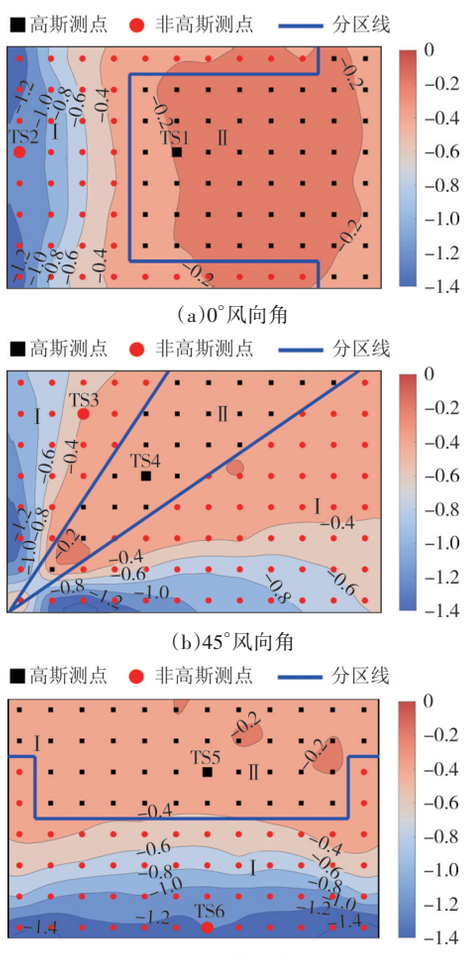


图4　风洞试验平均风速和湍流度剖面

Fig.4　Mean wind speed and turbulence intensity profiles of the wind tunnel test



(a)0°风向角

(b)45°风向角

(c)90°风向角

图5　非高斯区域划分以及平均风压系数分布

Fig.5　Division of non-Gaussian regions and mean pressure coefficient distribution

本研究随机选取6个测点的风压系数时间序列进行建模预测,其统计信息结果如表1所示,其中,TS1、TS4和TS5测点时程为高斯风压信号,TS2、TS3

和TS6测点时程为非高斯风压信号,每个测点的风压时程共计9 000个数据点.

表1 输入时程的统计信息

Tab. 1 Statistics of input time series

风向角/(°)	测点	偏度	峰度	高斯与非高斯判断
0	TS1	−0.251 0	3.146 4	高斯
	TS2	−1.179 1	5.068 0	非高斯
45	TS3	−1.621 7	7.408 7	非高斯
	TS4	−0.072 4	3.477 5	高斯
90	TS5	−0.133 5	3.633 1	高斯
	TS6	−1.057 3	4.604 7	非高斯

3.2 基于IEMD和样本熵的风压信号处理

首先,采用IEMD对原始风压数据进行自适应分解,图6为非高斯风压时程的分解结果.分析图6可得,原始风压数据被分解为由高频向低频递减排列的8个固有模态函数(IMFs)分量以及1个残余分量Res,每个IMF分量代表风压时程的不同时间局部特征.从分解结果不难发现,原始数据的复杂程度降低,有效削弱了风压时序的非平稳性.但由于所选取数据的非高斯特性显著,前1~2阶高频分量通常呈现较为紊乱的状态.中低频分量则具有一定的规律性,能够较为准确地描述原始风压时程的非线性波动,使得基于深度学习方法的风压时程高精度预测成为可能.由于固有模态函数的数量较多,对所有IMF分量分别开展预测,将导致计算成本和时间成本大幅增加.

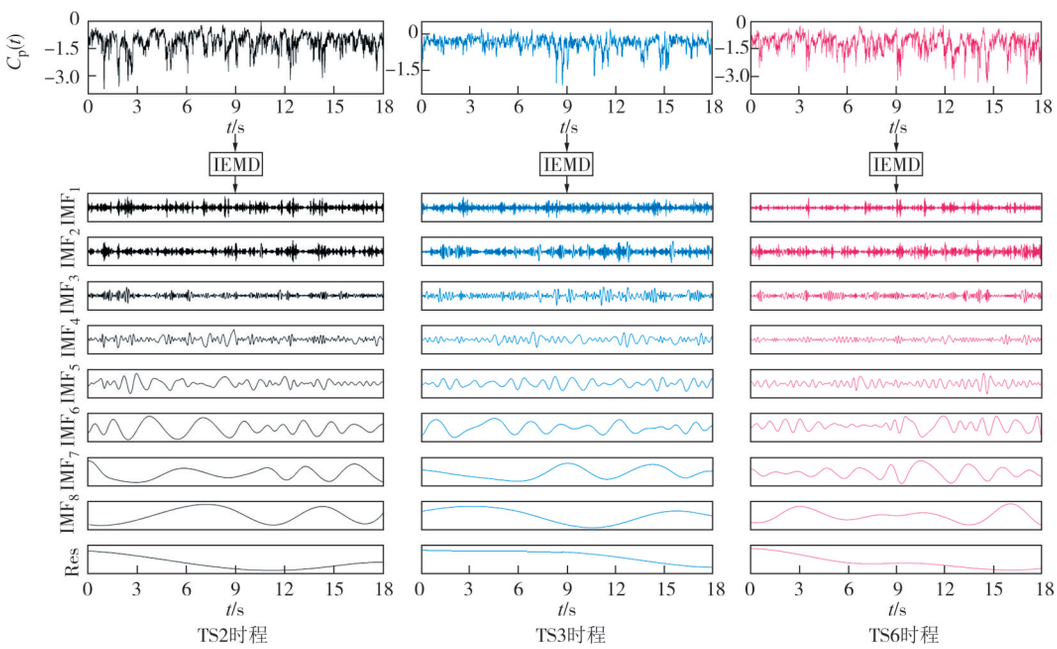


图6 非高斯风压时程的IEMD分解

Fig.6 Decomposition of non-Gaussian wind pressure time series by using IEMD

图7为各IMF分量的样本熵分布情况,各分量的SE值呈逐渐递减趋势,表明其复杂度不断下降.为降低风压预测任务量,通过SE值对近似IMF分量进行归类:将SE值大于0.5的高频分量作为随机性信号;SE值在0.1~0.5和0.01~0.10之间的中频分量作为周期性信号;SE值低于0.01的低频和残余分量则视为趋势性信号.

基于以上分类标准对各IMF分量进行归类合并,得到子序列,合并结果如表2所示.本研究将对新的子序列分别构建组合预测模型,再将预测结果线性累加,最终得到风压时程预测值.

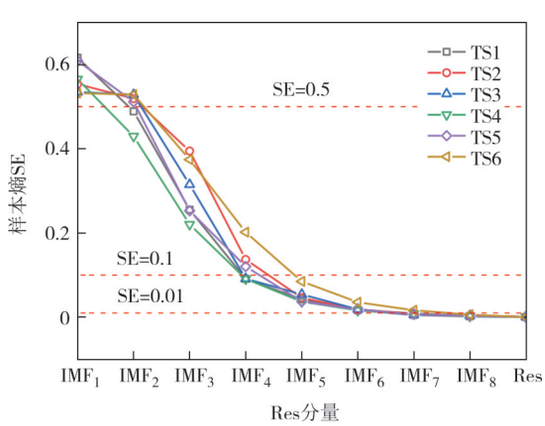


图7 各IMF分量的样本熵

Fig.7 Sample entropy of each IMF component

表2　IMF分量的子序列归类结果

Tab.2　Results of the new subsequences by classifying and merging IMF component

子序列号	原IMF分量序列号						
	TS1		TS2	TS3	TS4	TS5	TS6
Sub1	1	1,2	1,2	1	1	1,2	1,2
Sub2	2,3	3,4	3	2,3	2,3	3,4	3,4
Sub3	4,5,6	5,6	4,5,6	4,5,6	4,5,6	5,6	5,6,7
Sub4	7,8,Res	7,8,Res	7,8,Res	7,8,Res	7,8,Res	7,8,Res	8,Res

3.3　预测模型性能验证与对比

为了验证本文所提出IEMD-SE-BO-BiLSTM预测模型的有效性和可靠性,选取多层感知器(MLP),双向长短期记忆网络(BiLSTM),使用改进经验模态分解(IEMD)的BiLSTM,结合改进经验模态分解和样本熵的BiLSTM作为对照模型.其中,MLP和BiLSTM模型直接针对6组原始风压数据进行学习与预测;对于分解算法和深度学习组合的预测模型,将对分解后的各IMF分量进行预测,简称为IEMD-BiLSTM;基于分解算法与样本熵的组合预测模型简称为IEMD-SE-BiLSTM,将选取重构后的各子序列(Sub)作为训练数据.

上述预测模型的部分参数设置如表3所示,本文所提出模型的超参数使用贝叶斯优化算法进行率定,对照模型参数则通过传统的交叉验证方法确定,限于篇幅,其确定过程不做详细阐述.为保证比较结果的客观性,所有模型均采用90%数据作为训练集,剩余10%用于测试或验证不同模型预测性能.

表3　预测模型参数设置

Tab.3　Parameters setting of the prediction models

预测模型	参数描述
MLP	训练集:验证集:测试集(18:1:1);隐藏层数:2;神经元数:(5,5);交叉验证次数:10
BiLSTM、IEMD-BiLSTM、IEMD-SE-BiLSTM	训练集:测试集(9:1);隐藏层数:3;神经元数:(20,15,12);Dropout值:0.2;学习率:0.01;交叉验证次数:10
IEMD-SE-BO-BiLSTM	训练集:测试集(9:1);隐藏层数范围:[2,3];神经元数范围:[10,50];Dropout值:0.2;学习率范围:[10^{-4},10^{-2}]

采用2.2节提出的4个评价指标对5种模型的风压时程预测结果进行对比,如图8所示.总体而言,以BiLSTM模型为基础构建的各个复合模型均能准确地挖掘风压时程的潜在统计规律,进而得到较为准确的预测结果,表明基于深度学习方法的风压系数时程预测是准确且可行的.

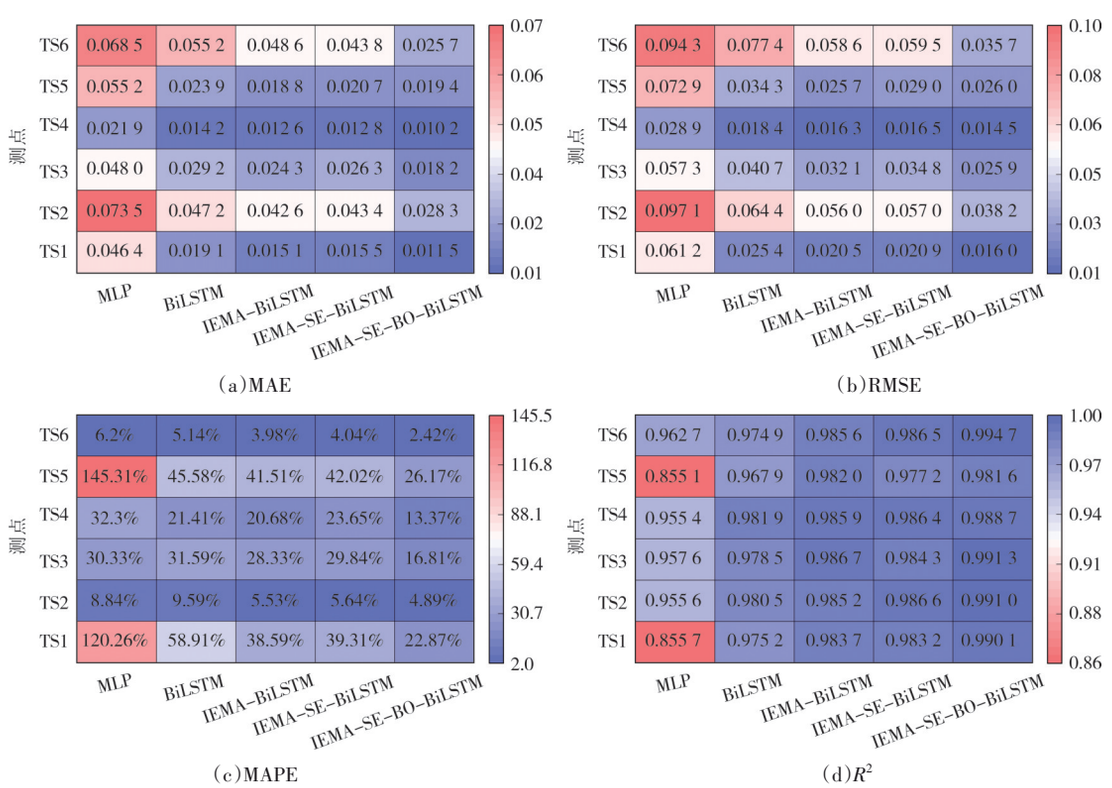


图8　不同预测模型评价指标对比

Fig.8　Comparison of performance indexes of different prediction models

比较不同高斯和非高斯风压测点工况可发现，相较于两种单一预测模型(MLP和BiLSTM)，与信号分解算法结合后的预测模型均具有更高的预测精度.由于IEMD将原始时序分解为一系列更为规律的IMF分量，可显著降低训练数据的复杂度，有助于深度学习算法提取其非线性特征.

对比0°、45°和90°三组风向角工况预测结果的MAE和RMSE值，如图8(a)和8(b)所示，可知不同风向角下高斯测点(TS1、TS4和TS5)的预测效果相对优于非高斯测点(TS2、TS3和TS6).此外，本文所提模型的各项预测精度指标均显著优于其他对照模型，在高斯和非高斯风压时程预测上都展示出更高的精确度和稳定性.值得注意的是，部分均值较小的高斯风压时程预测结果的MAPE值偏差较大，其主要原因是当时序中某一时刻的实际值接近0时，极小的误差都会给MAPE值带来较大的波动.

为检验改进经验模态分解和样本熵相结合的预测模型的执行效率，图9比较了IEMD-BiLSTM、IEMD-SE-BiLSTM和本文所提模型的总训练用时，以及各IMF分量或重构子序列的平均样本熵值，用来综合衡量训练数据的复杂程度.

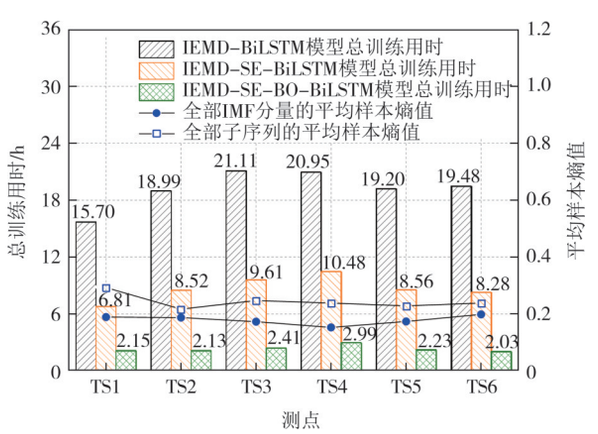


图9 三种组合模型的总训练用时及平均样本熵值对比

Fig.9 Comparison of total training time and average sample entropy values of the three combined models

由图8和图9可知，采用IEMD-SE技术处理后的BiLSTM模型总训练用时仅为IEMD-BiLSTM组合模型的50%，但是其预测性能的优越性并不显著.造成两种模型评价指标差异的原因是，使用样本熵重构的各子序列包含了多个不同频率和变化趋势的IMF分量，其复杂度略大于重构前各IMF分量.

由于BiLSTM结构复杂，通过交叉验证方法确定各深度学习模型的超参数将耗费大量的时间成本，即便采用经验模态分解与样本熵相组合的时序预处理方法，训练时长仍会以子序列的总个数为单位成倍地增加，由此对复合模型的预测效率产生较大影响.因此本文引入贝叶斯优化算法率定深度学习模型的各项超参数，使得训练效率和预测精度得到大幅度提升，各测点总训练用时均小于3 h.

为进一步量化分析本文模型的预测性能，以TS6测点的非高斯风压数据为例，图10给出了各模型相较于MLP模型的各项评价指标改进量.本文所提出的IEMD-SE-BO-BiLSTM模型的各项指标均有显著改善，具有最高的预测精度，主要原因如下：① 借助IEMD技术处理非高斯不平稳时序，再利用样本熵重构的子序列具有更好的规律性，能更好地被预测模型识别；② 贝叶斯优化算法的寻优能力强于传统的交叉验证法，能够充分发挥模型的最大性能.

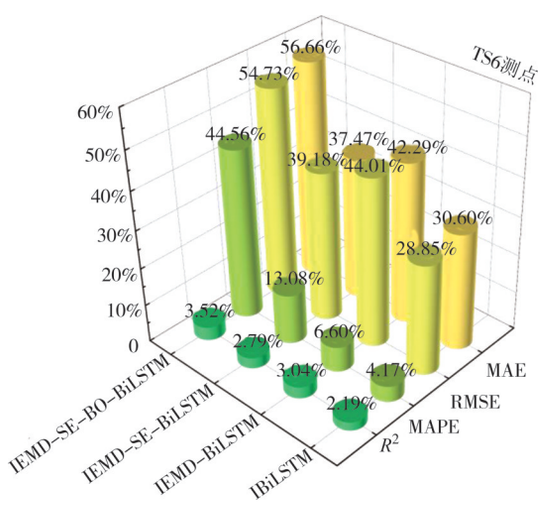


图10 各预测模型相较于MLP模型的评价指标改进量

Fig.10 Performance index improvements of each prediction model compared to MLP model

为便于分析，选取TS6测点预测结果中的第17~18 s时间段进行对比，如图11所示.观察图11可发现，MLP和BiLSTM的预测值与实测值相比，呈现出明显的极值错位问题，且存在一定的时间滞后现象，主要是因为风压时程数据的非平稳性与自相关性，使得单一模型无法准确地学习时序的变化规律.与改进经验模态分解算法组合后，深度学习模型的预测效果整体有所提升，基本消除滞后现象，但也存在局部范围误差较大的情况.在风压脉动性强的峰值处，IEMD-SE-BO-BiLSTM的预测值较IEMD-BiLSTM和IEMD-SE-BiLSTM的预测值更加接近实际值.

采用IEMD-SE-BO-BiLSTM模型对所有测点的风压系数预测值与实际值进行对比，如图12所示.其

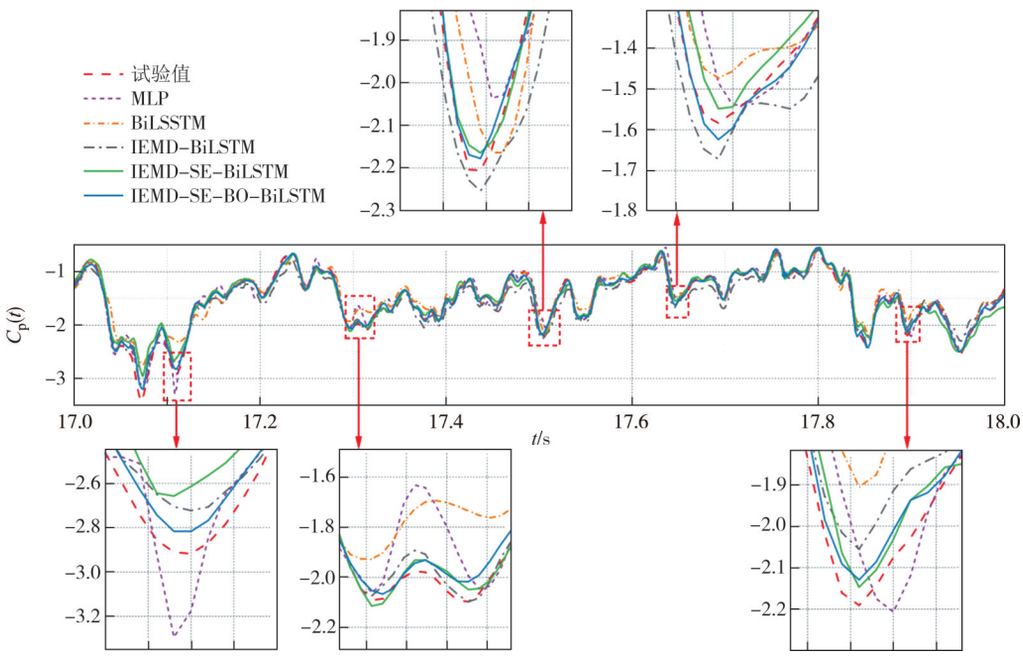


图 11　TS6测点处各模型预测风压与实际风压时程对比

Fig.11　Comparison of predicted and actual wind pressure time series using different prediction models for pressure tap TS6

中,前 16.2 s(8 100 个样本点)为训练集,16.2~18.0 s(900个样本点)为测试集,最后 1.8 s 为未知样本点的预测集,作为间歇性缺失信号的补充.从图 8 和图 12可以看出,在已知数据时段(T=18 s)内,本文模型的预测结果与实际值非常接近,所有测点的平均绝对误差、均方根误差和平均绝对百分比误差最大值分别为0.028 3、0.038 2 和 26.17%,最小相关系数为0.981 6,说明该模型可以对低矮房屋表面风压进

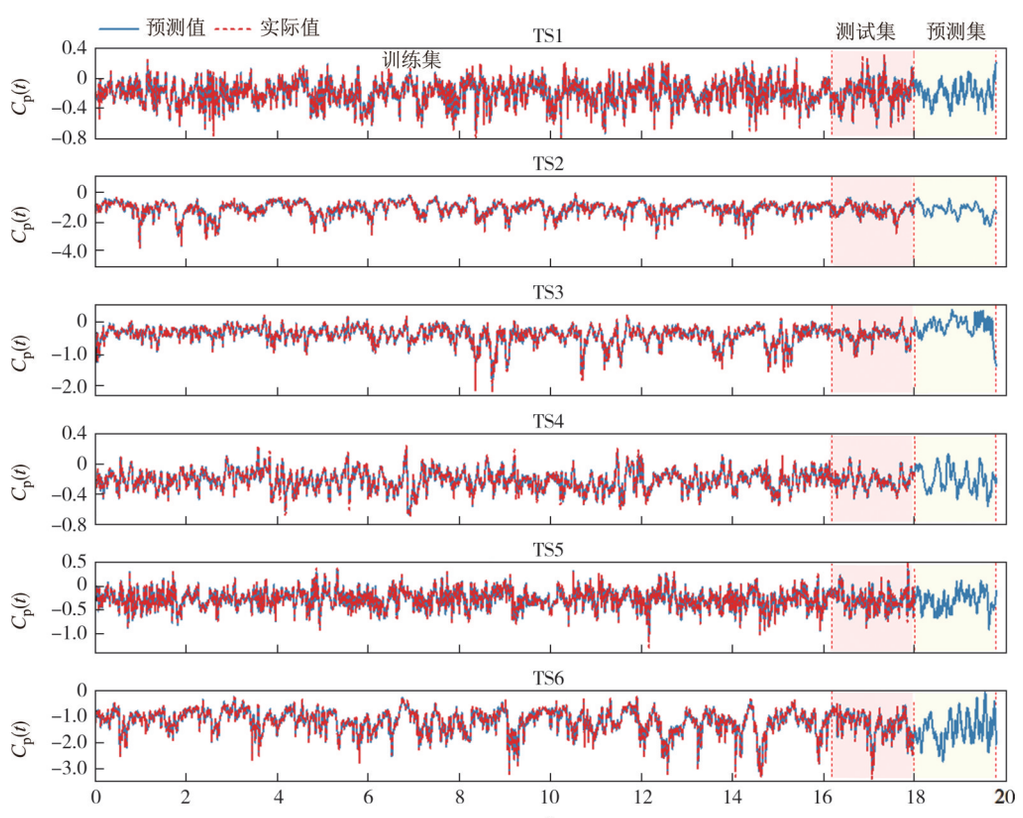


图 12　不同测点处IEMD-SE-BO-BiLSTM模型的风压时程预测结果

Fig.12　Predicted results of wind pressure time series for different pressure taps by using IEMD-SE-BO-BiLSTM model

行准确预测.

表4给出了不同时段内(T_0和T_1)风压系数预测值的前四阶统计矩.其中,T_1=T_0+1.8 s表示在已知样本时距T_0的基础上又进行了1.8 s时长(10%T_0)的未知样本预测.将预测结果与已知样本时距内(T=18 s)实际值的统计结果进行了对比.由表4可知,在两组时距内,模型预测结果能够保持良好的脉动风压非高斯统计特性.但随着未知样本预测时间的增加,预测所依赖的历史数据不断减少,模型预测精度会逐渐降低.

表4 不同时距下风压时程实际值与模型预测值的统计矩对比

Tab.4 Comparison of the statistical moments of wind pressure time series between actual data and prediction model results at different time intervals

测点	均值			方差			偏度			峰度		
	T	T_0	T_1	T	T_0	T_1	T	T_0	T_1	T	T_0	T_1
TS1	−0.193 6	−0.193 5	−0.193 2	0.025 2	0.024 7	0.024 5	−0.251 0	−0.243 4	−0.235 6	3.146 4	3.049 9	3.171 8
TS2	−1.117 8	−1.117 9	−1.124 9	0.224 4	0.220 0	0.219 6	−1.179 1	−1.170 6	−1.126 0	5.068 0	5.065 1	4.928 9
TS3	−0.389 9	−0.388 9	−0.364 9	0.072 4	0.068 6	0.079 2	−1.621 7	−1.519 4	−1.337 9	7.408 7	6.656 5	6.750 3
TS4	−0.216 4	−0.215 6	−0.215 1	0.017 9	0.016 6	0.018 4	−0.072 4	−0.082 5	−0.032 6	3.477 5	3.281 5	3.313 6
TS5	−0.272 3	−0.271 3	−0.272 6	0.036 7	0.034 8	0.039 0	−0.133 5	−0.122 9	−0.152 5	3.633 1	3.332 9	3.671 5
TS6	−1.196 5	−1.198 1	−1.221 6	0.225 5	0.214 8	0.234 9	−1.057 3	−1.016 1	−0.916 5	4.604 7	4.421 1	4.108 2

注:时距T=18 s对应实际值;时距T_0及T_1对应模型预测值(T_0=16.2 s+1.8 s, T_1=T_0+1.8 s).

4 结 论

低矮房屋表面脉动风压的非高斯性十分显著,直接采用原始数据进行预测会导致预测效果较差.本文提出一种基于IEMD和BiLSTM网络的风压时程预测模型,并利用风洞试验数据进行了模型验证,得到以下结论:

1)采用IEMD对非平稳风压时序进行特征提取,获得一系列表征局部特征且相对平稳的IMF分量;以样本熵为指标分析IMF分量的自相似特性和紊乱程度,同时合并样本熵值相近的IMF分量,得到一系列具有较大非线性程度差异的子序列,使模型的预测精度大幅提高.

2)BiLSTM模型超参数的选取会直接影响模型的泛化性能和预测效果.从预测模型验证算例中得知,运用贝叶斯优化算法可以实现深度学习模型超参数的高效筛选,充分利用历史信息来提高搜索效率,确定使模型性能最优的超参数组合.

3)基于IEMD与BiLSTM的组合预测模型是一种高精度预测模型,其在高斯和非高斯测点的预测结果均优于传统的MLP模型和BiLSTM模型.另一方面,将IEMD-SE技术与基于贝叶斯优化的BiLSTM模型相结合所建立的组合预测模型,具有更优越的预测性能且耗时大幅降低,预测结果与原始风压时序保持相当高的吻合度,可靠地反映出非高斯风压尖峰脉冲特性.本文所提出的预测方法具有较强的非线性问题处理能力,在高斯和非高斯风压时程预测中均取得良好的效果.此外,本文模型还可推广至风电场风速或结构响应时程预测研究,具有广阔的发展空间,但尚存在一些不完善的地方:本文仅针对单测点风压进行预测,无法实现空间多测点同步预测,将在后续研究中解决这一问题.

参考文献

[1] 杨庆山, 陈飞新, 赵乐, 等. 基于大涡模拟的大气边界层湍流强度对低矮房屋风荷载特性影响研究[J]. 工程力学, 2021, 38(12): 25-38.
YANG Q S, CHEN F X, ZHAO L, et al. Effects of upstream turbulence intensity on aerodynamic loads of low-rise buildings in atmospheric boundary layer flow using large eddy simulation[J]. Engineering Mechanics, 2021, 38(12): 25-38. (in Chinese)

[2] 李春祥, 张浩怡. 基于混合多变量经验模态分解和极限学习机的非平稳过程预测[J]. 上海交通大学学报, 2020, 54(4): 376-386.
LI C X, ZHANG H Y. Hybridizing multivariate empirical mode decomposition and extreme learning machine to predict non-stationary processes[J]. Journal of Shanghai Jiao Tong University, 2020, 54(4): 376-386. (in Chinese)

[3] LI L C, ZHOU H J, LIU H L, et al. A hybrid method coupling empirical mode decomposition and a long short-term memory network to predict missing measured signal data of SHM systems [J]. Structural Health Monitoring, 2021, 20(4): 1778-1793.

[4] CHEN Z S, ZHANG L K, HUA J M, et al. A framework of data-driven wind pressure predictions on bluff bodies using a hybrid deep learning approach [J]. Measurement and Control, 2023, 56(1/2): 237-256.

[5] 郑晓芬,钟旺,李春祥. 基于核极限学习机的多变量非平稳脉动风速预测[J]. 振动与冲击, 2017, 36(18): 223-230.
ZHENG X F, ZHONG W, LI C X. Multivariate nonstationary fluctuating wind velocity prediction using kernel-based extreme learning machine [J]. Journal of Vibration and Shock, 2017, 36(18): 223-230.(in Chinese)

[6] CHEN Y, KOPP G A, SURRY D. Interpolation of wind-induced pressure time series with an artificial neural network [J]. Journal of Wind Engineering and Industrial Aerodynamics, 2002, 90(6): 589-615.

[7] HUANG D M, HE S Q, HE X H, et al. Prediction of wind loads on high-rise building using a BP neural network combined with POD [J]. Journal of Wind Engineering and Industrial Aerodynamics, 2017, 170: 1-17.

[8] CHEN F B, WANG X L, LI X, et al. Prediction of wind pressures on tall buildings using wavelet neural network [J]. Journal of Building Engineering, 2022, 46: 103674.

[9] GAVALDA X, FERRER-GENER J, KOPP G A, et al. Interpolation of pressure coefficients for low-rise buildings of different plan dimensions and roof slopes using artificial neural networks [J]. Journal of Wind Engineering and Industrial Aerodynamics, 2011, 99(5): 658-664.

[10] BRE F, GIMENEZ J M, FACHINOTTI V D. Prediction of wind pressure coefficients on building surfaces using artificial neural networks[J]. Energy and Buildings, 2018, 158: 1429-1441.

[11] MALLICK M, MOHANTA A, KUMAR A, et al. Prediction of wind-induced mean pressure coefficients using GMDH neural network [J]. Journal of Aerospace Engineering, 2020, 33 (1): 04019104.

[12] 李春祥,殷潇. 基于小波支持向量机的非高斯空间风压内外插预测[J]. 上海交通大学学报,2018,52(11):1516-1523.
LI C X, YIN X. Interpolation prediction and extrapolation prediction of non-gaussian spatial wind pressure using LSSVM with wavelet kernel function [J]. Journal of Shanghai Jiao Tong University, 2018, 52(11): 1516-1523.(in Chinese)

[13] 迟恩楠, 李春祥, 郑晓芬. 基于小波和乘法混合核函数LSSVM的顺风向非高斯空间风压预测[J]. 振动与冲击,2017,36(9): 116-121.
CHI E N, LI C X, ZHENG X F. Forecasting non-Gaussian spatial along-wind pressure using wavelet kernel and multiplicative mixed kernel functions based LSSVM[J]. Journal of Vibration and Shock, 2017, 36(9): 116-121.(in Chinese)

[14] HUANG J X, LI Q S, HAN X L. Recovery of missing field measured wind pressures on a supertall building based on correlation analysis and machine learning [J]. Journal of Wind Engineering and Industrial Aerodynamics, 2022, 231: 105237.

[15] 陈伏彬,唐宾芳,蔡虬瑞,等. 大跨平屋盖风荷载特性及风压预测研究[J]. 振动与冲击, 2021, 40(3): 226-232.
CHEN F B, TANG B F, CAI Q R, et al. Wind load characteristics and wind pressure prediction of long-span flat roof[J]. Journal of Vibration and Shock, 2021, 40(3): 226-232.(in Chinese)

[16] LI T, WU T, LIU Z. Nonlinear unsteady bridge aerodynamics: reduced-order modeling based on deep LSTM networks [J]. Journal of Wind Engineering and Industrial Aerodynamics, 2020, 198: 104116.

[17] LIM J Y, KIM S, KIM H K, et al. Long short-term memory (LSTM)-based wind speed prediction during a typhoon for bridge traffic control [J]. Journal of Wind Engineering and Industrial Aerodynamics, 2022, 220: 104788.

[18] 武频, 孙俊五, 封卫兵. 基于自编码器和LSTM的模型降阶方法[J]. 空气动力学学报, 2021, 39(1): 73-81.
WU P, SUN J W, FENG W B. Reduced order model based on autoencoder and long short-term memory network [J]. Acta Aerodynamica Sinica, 2021, 39(1): 73-81.(in Chinese)

[19] LI J H, ZHU D S, LI C X. Comparative analysis of BPNN, SVR, LSTM, Random Forest, and LSTM-SVR for conditional simulation of non-Gaussian measured fluctuating wind pressures [J]. Mechanical Systems and Signal Processing, 2022, 178: 109285.

[20] 李金龙,王义民,畅建霞,等. 基于并行机器学习的风功率超短期预测[J]. 水力发电学报, 2023, 42(1): 40-51.
LI J L, WANG Y M, CHANG J X, et al. Ultra-short-term predictions of wind power based on parallel machine learning[J]. Journal of Hydroelectric Engineering, 2023, 42(1): 40-51.(in Chinese)

[21] LI J L, SONG Z H, WANG X F, et al. A novel offshore wind farm typhoon wind speed prediction model based on PSO-Bi-LSTM improved by VMD[J]. Energy, 2022, 251: 123848.

[22] LÜ M Z, LI J, NIU X S, et al. Novel deterministic and probabilistic combined system based on deep learning and self-improved optimization algorithm for wind speed forecasting[J]. Sustainable Energy Technologies and Assessments, 2022, 52: 102186.

[23] JASEENA K U, KOVOOR B C. Decomposition-based hybrid wind speed forecasting model using deep bidirectional LSTM networks [J]. Energy Conversion and Management, 2021, 234: 113944.

[24] 崔佳旭, 杨博. 贝叶斯优化方法和应用综述[J]. 软件学报, 2018, 29(10): 3068-3090.
CUI J X, YANG B. Survey on Bayesian optimization methodology and applications [J]. Journal of Software, 2018, 29(10): 3068-3090.(in Chinese)

[25] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis [J]. Proceedings of the Royal Society of London Series A, 1998, 454(1971): 903-998.

[26] LIU Z L, PENG D D, ZUO M J, et al. Improved Hilbert-Huang transform with soft sifting stopping criterion and its application to fault diagnosis of wheelset bearings [J]. ISA Transactions, 2022, 125: 426-444.

[27] TAN H C, XIE S C, LIU R D, et al. Fatigue condition diagnosis of rolling bearing based on normalized balanced multiscale sample entropy[J]. International Journal of Fatigue, 2023, 172: 107642.

[28] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural Computation, 1997, 9(8): 1735-1780.