

传感器故障后多变量经验小波变换多点预测^{*}

李春祥， 张佳丽
(上海大学土木工程系 上海,200444)

摘要 为有效应对多点风速传感器或风压传感器故障而造成的损失,同时为了降低运算的复杂性和工程应用的难度,需要提出同步恢复缺失数据的模型。传统的多通道信号诊断采用多元经验模态分解(multivariate empirical mode decomposition,简称 MEMD),笔者提出多变量经验小波变换(multivariable empirical wavelet transform,简称 MEWT)来同步恢复多点缺失数据。具体应用时,首先,运用 MEWT 将多点信号同时分解为一系列模态;然后,利用核函数极限学习机(kernel-based extreme learning machine,简称 KELM)实现同步预测,同时运用杜鹃搜索(cuckoo search,简称 CS)算法对模型的正则化参数以及核参数进行智能寻优。多步预测时,采用多输入多输出(multi-input multi-output,简称 MIMO)策略代替传统的滚动策略。建筑物表面实测多点风压数据和实测多点下击暴流风速数据用于验证模型的可行性。与噪声辅助的多元经验模态分解核函数极限学习机的对比结果表明,该模型能更高精度地同步恢复多点多步信号。

关键词 传感器故障;核函数极限学习机;杜鹃搜索算法;多变量经验小波变换;同步多步预测
中图分类号 TU311; TH765

引 言

目前超高层建筑,特别是 600 m 以上超高层建筑需要安装结构健康监测(structural health monitoring,简称 SHM)系统,通过对结构响应等结构系统特性分析来监测结构损伤或退化。SHM 系统使用的传感器属于精密测量仪器,使用环境恶劣、操作不当和安装不稳定等因素都会导致故障发生。据资料显示,最严重的风灾往往由飓风和雷暴产生。在风灾发生时,一旦传感器发生故障,对数据记录造成缺失,后果难以挽回。另外,在结构振动的主动控制中,整个建筑物表面所受的力需要同时得知,若多个传感器同时发生故障,单点预测不能满足计算需要,因此多点同步预测模型的建立十分必要。

要同步恢复缺失信号,必须要考虑同步分解多变量信号。随着多变量信号分析的需求增加,Rehman 等^[1]提出 MEMD 算法来代替传统经验模态分解(empirical mode decomposition,简称 EMD)这种单通道信号分解方法。该算法能同步处理安放在不同位置的传感器采集来的多变量信号,保证了固有模态函数(intrinsic mode function,简称 IMF)在

数量和尺度上的统一。近年来,MEMD 常被用于机械状态的监测和故障的诊断,极大地提高了多变量信号分解的准确性,同时降低了运算的复杂程度。Yong 等^[2]验证了 MEMD 结合非局部均值(non-local means,简称 NL-means)降噪算法以及故障相关因素分析在滚动轴承故障诊断中的有效性。Huang 等^[3]提出一种部分噪声辅助的多元经验模态分解(partial noise assisted multivariate EMD,简称 PNA-MEMD)算法,利用高频窄带的噪声来取代传统的白噪声,获得稳定效果的同时简化了运算。熊忻等^[4]利用 MEMD 分解多通道振动信号来融合识别齿轮箱齿面点蚀故障信号的多通道数据。王恒等^[5]采用自适应噪声辅助的多元经验模态分解(noise assisted multivariate EMD,简称 NA-MEMD)来提取故障特征。段若晨等^[6]提出一种窄带噪声辅助多元经验模态分解(narrowband noise assisted multivariate empirical mode decomposition,简称 NNA-MEMD)算法,用来检测换流变压器用有载分接开关的机械状态。从以上发展看出,NA-MEMD 是一种常用多变量分析的算法,能一定程度上解决 MEMD 的模态混叠问题。考虑到经验小波变换(empirical wavelet transform,简称

^{*} 国家自然科学基金资助项目(51778354,51378304)
收稿日期:2018-07-09;修回日期:2018-08-21

EWT)在单点信号分解中有很好的效果,利用 EWT 基本框架构建 MEWT 算法,对故障后的多变量信号进行同步恢复,同时采用 MIMO 策略代替传统的滚动策略进行多步预测,提高精度的同时能获得更长时间的预测值,并与 NA-MEMD 模型进行对比,说明 MEWT 模型的优越性。

1 MEWT-KELM-CS-MIMO 多点同步多步预测模型

1.1 EWT 基本原理

近年来,在非线性、非平稳信号去噪方面,小波变换(wavelet transform, 简称 WT)和 EMD 等都取得了一定效果,但 WT 在强噪声情况下去噪效果会退化,EMD 存在数学理论缺失、对噪声和取样敏感的问题^[7]。Gilles 等^[8-9]基于小波变换和经验模态分解存在的问题,提出了经验小波变换。EWT

$$\hat{\phi}_n(\omega) = \begin{cases} 1 \\ \cos\left[\frac{\pi}{2}\beta\left(\frac{1}{2\tau_n}|\omega| - \omega_n + \tau_n\right)\right] \\ 0 \end{cases}$$
$$\hat{\psi}_n(\omega) = \begin{cases} 1 \\ \cos\left[\frac{\pi}{2}\beta\left(\frac{1}{2\tau_{n+1}}|\omega| - \omega_{n+1} + \tau_{n+1}\right)\right] \\ \sin\left[\frac{\pi}{2}\beta\left(\frac{1}{2\tau_n}|\omega| - \omega_n + \tau_n\right)\right] \\ 0 \end{cases}$$

用经典小波变换的方法构造滤波器。其中:近似系数 $W_f^e(0,t)$ 用于过滤得到信号的宏观尺度,即趋势项;细节系数 $W_f^e(n,t)$ 用于过滤得到信号的细节情况,即细节项。近似系数和细节系数分别为

$$W_f^e(0,t) = \langle f, \phi_1 \rangle = \int f(\tau) \overline{\phi_1(\tau - t)} d\tau \quad (4)$$

$$W_f^e(n,t) = \langle f, \psi_n \rangle = \int f(\tau) \overline{\psi_n(\tau - t)} d\tau \quad (5)$$

3) 重建信号。重建的序列和经验模态为

$$f(t) = W_f^e(0,t) * \phi_1(t) + \sum_{n=1}^N W_f^e(n,t) * \psi_n(t) \quad (6)$$

$$f_0(t) = W_f^e(0,t) * \phi_1(t) \quad (7)$$

$$f_k(t) = W_f^e(k,t) * \psi_k(t) \quad (8)$$

1.2 MEWT 技术框架

笔者提出多变量经验小波变换的概念,通过将经验小波变换分解后的模态进行相空间重构,模态

能够通过完全自适应小波基提取信号的固有模态,与经典小波变换一样具有完备的理论基础,可以显著降低 EMD 类分解方法存在的模态混叠现象。

EWT 的步骤总结如下:

1) 把原时间序列的傅里叶谱标准化为 $[0, \pi]$ 之间,通过找到傅里叶谱中 $N-1$ 个局部极值点和 $N+1$ 条边界线(0 和 π 分别是第一条和最后一条边界线),可以把标准化后的傅里叶谱分为 N 个连续的部分。其余的 $N-1$ 条边界线被定义为 $\omega_n (n=1, 2, \dots, N)$,每一段被定义为 $\Delta_n = [\omega_{n-1}, \omega_n]$,因此可知 $\bigcup_{n=1}^N \Delta_n = [0, \pi]$ 。宽度为 $2\tau_n$ 的过渡段 T_n 在每一个 ω_n 上被定义,其中: $\tau_n = \gamma\omega_n$; γ 的范围为

$$\gamma < \min_n \left(\frac{\omega_{n+1} - \omega_n}{\omega_{n+1} + \omega_n} \right) \quad (1)$$

2) 根据 Meyer 小波的构造方法构造一系列经验小波。对于任意的 $\forall n > 0$,经验尺度函数和经验小波函数分别为

$$\begin{aligned} &(|\omega| \leq (1-\gamma)\omega_n) \\ &((1-\gamma)\omega_n \leq |\omega| \leq (1+\gamma)\omega_n) \end{aligned} \quad (2)$$

其他

$$\begin{aligned} &(\omega_n(1+\gamma) \leq |\omega| \leq (1-\gamma)\omega_{n+1}) \\ &((1-\gamma)\omega_{n+1} \leq |\omega| \leq (1+\gamma)\omega_{n+1}) \end{aligned} \quad (3)$$

其他

$$((1-\gamma)\omega_n \leq |\omega| \leq (1+\gamma)\omega_n)$$

数不等用零矩阵补齐后再重构来实现同步预测。

这里以三点信号为例来展示 MEWT 技术框架。首先,对每个信号通过 EWT 分解后的模态进行以下相空间重构,即将一维时间序列转换成矩阵的形式。第 i 个模态的训练集的时间序列 $\{x_{i1}, x_{i2}, \dots, x_{in}\}$ 进行嵌入维度为 d 的相空间重构,具体的输入和输出样本对为

$$\mathbf{X}_i = \begin{bmatrix} x_{i1} & x_{i2} & \cdots & x_{id} \\ x_{i2} & x_{i3} & \cdots & x_{i(d+1)} \\ \vdots & \vdots & \cdots & \vdots \\ x_{i(n-d)} & x_{i(n-d+1)} & \cdots & x_{i(n-1)} \end{bmatrix}$$
$$\mathbf{Y}_i = \begin{bmatrix} x_{i(d+1)} \\ x_{i(d+2)} \\ \vdots \\ x_{in} \end{bmatrix}$$

设 3 个信号分解后最大模态数为 m ,若 EWT 分解后的模态数不足 m 的信号用零矩阵来补齐缺失的模态。

最后,MEWT 多点同步相空间重构的方法以上述单点信号相空间重构为基础,令输入矩阵为 $\mathbf{X}_i = [\mathbf{X}_i^1 \ \mathbf{X}_i^2 \ \mathbf{X}_i^3]$,输出矩阵为 $\mathbf{Y}_i = [\mathbf{Y}_i^1 \ \mathbf{Y}_i^2 \ \mathbf{Y}_i^3]$,其中: \mathbf{X}_i^1 为第 i 个模态的同步预测相空间重构输入矩阵; $\mathbf{X}_i^1, \mathbf{X}_i^2, \mathbf{X}_i^3$ 分别为第 1 点、第 2 点和第 3 点信号的第 i 个模态的相空间重构输入矩阵; \mathbf{Y}_i 为第 i 个模态的同步预测相空间重构输出矩阵; $\mathbf{Y}_i^1, \mathbf{Y}_i^2, \mathbf{Y}_i^3$ 分别为第 1 点、第 2 点和第 3 点信号的第 i 个模态的相空间重构输出矩阵。矩阵归一化之后代入模型进行训练,用训练好的模型来进行测试集的预测,得到 3 点信号第 i 个模态的预测值 $\hat{\mathbf{Y}}^1, \hat{\mathbf{Y}}^2$ 和 $\hat{\mathbf{Y}}^3$ 。

从 MEWT 的技术框架以及矩阵的性质来看,若数据缺失点数多达 k 个, $k>3$,第 i 个模态的同步预测相空间重构输入矩阵变为 $\mathbf{X}_i = [\mathbf{X}_i^1 \ \mathbf{X}_i^2 \ \mathbf{X}_i^3 \ \cdots \ \mathbf{X}_i^k]$,每个信号的模态矩阵会被当作较独立的块代入矩阵,得到输出矩阵 $\mathbf{Y}_i = [\mathbf{Y}_i^1 \ \mathbf{Y}_i^2 \ \mathbf{Y}_i^3 \ \cdots \ \mathbf{Y}_i^k]$ 。由于信号都是单独分解再组合预测,3 个测点组合后的效果达到要求,更多测点预测效果也是相近的,因此笔者提出的 MEWT 算法理论上适用于更多测点数据缺失的情况,在之后的研究中,将从试验中探究多测点对 MEWT 性能的影响。

1.3 KELM 基本概念

给定 N 个样本 $\{(x_i, y_i) \mid i=1, 2, \cdots, N\}$,其中 $\mathbf{x}_i = [x_{i1} \ x_{i2} \ \cdots \ x_{in}]^T \in R^n$,要寻找预测函数 $f: \mathbf{x} \rightarrow y$,使得 $f(\mathbf{x}) \approx y$ 。在隐层神经元数目为 L 的 ELM 中,这个预测函数的形式可表述为

$$f(\mathbf{x}) = \sum_{j=1}^L g(\mathbf{a}_j^T \mathbf{x} + b_j) \beta_j = \mathbf{h}^T(\mathbf{x}) \boldsymbol{\beta} \quad (9)$$

其中: $\mathbf{a}_j = [a_{1j} \ a_{2j} \ \cdots \ a_{nj}]^T$ 为连接第 j 个隐层节点的输入权值向量; b_j 为第 j 个隐层节点偏置; $\boldsymbol{\beta} = [\beta_1 \ \beta_2 \ \cdots \ \beta_L]^T$ 为输出权值向量; $\mathbf{h}(\mathbf{x}) = [g(\mathbf{a}_1^T \mathbf{x} + b_1) \ \cdots \ g(\mathbf{a}_L^T \mathbf{x} + b_L)]^T$ 为特征映射; $g(x)$ 为隐层神经元激活函数。

在极限学习机(extreme learning machine, 简称 ELM)中,输入权值和隐层节点偏置都是事先设定好的,激活函数也是选定的,所以 ELM 的训练问题可归结为求解输出权值 $\boldsymbol{\beta}$ 的问题,建立如下的最优化问题

$$\begin{aligned} \min_{\boldsymbol{\beta}} \quad & \frac{1}{2} \|\boldsymbol{\beta}\|_2^2 + \frac{C}{2} \sum_{i=1}^N \epsilon_i^2 \\ \text{s. t.} \quad & \mathbf{h}^T(\mathbf{x}_i) \boldsymbol{\beta} = y_i - \epsilon_i \quad (i=1, 2, \cdots, N) \end{aligned} \quad (10)$$

其中: C 为正则化参数,可以人为设定; ϵ_i 为松弛变量,衡量实际值与预测值之间的误差。

求解式(10)得到

$$\boldsymbol{\beta} = \mathbf{H}^T \left(\frac{1}{C} \mathbf{I}_N + \mathbf{H} \mathbf{H}^T \right)^{-1} \mathbf{Y} \quad (11)$$

其中: $\mathbf{H} = [\mathbf{h}(\mathbf{x}_1) \ \cdots \ \mathbf{h}(\mathbf{x}_N)]^T$ 为隐层输出矩阵; $\mathbf{Y} = [y_1 \ \cdots \ y_N]^T$ 为输出向量; \mathbf{I}_N 为一个 $N \times N$ 维的单位矩阵。

类似于支持向量机(support vector machine, 简称 SVM)等办法,用核函数取代特征映射 $\mathbf{h}(\mathbf{x})$,定义核函数为 $k(\mathbf{x}, \mathbf{y}) = \langle \mathbf{h}(\mathbf{x}), \mathbf{h}(\mathbf{y}) \rangle$,这里 $\langle \cdot, \cdot \rangle$ 表示特征映射的内积。于是可以定义核矩阵 $\boldsymbol{\Omega}$ 为

$$\boldsymbol{\Omega} = \mathbf{H} \mathbf{H}^T : \Omega_{i,j} = \mathbf{h}(\mathbf{x}_i) \cdot \mathbf{h}(\mathbf{x}_j) = k(\mathbf{x}_i, \mathbf{x}_j) \quad (12)$$

将核函数带入式(9)和式(11),得到 KELM 的预测函数为

$$f(\mathbf{x}) = \mathbf{h}^T(\mathbf{x}) \boldsymbol{\beta} = \mathbf{h}^T(\mathbf{x}) \mathbf{H}^T \left(\frac{1}{C} \mathbf{I}_N + \mathbf{H} \mathbf{H}^T \right)^{-1} \mathbf{Y} = \begin{bmatrix} k(\mathbf{x}, \mathbf{x}_1) \\ \vdots \\ k(\mathbf{x}, \mathbf{x}_N) \end{bmatrix}^T \left(\frac{1}{C} \mathbf{I}_N + \boldsymbol{\Omega} \right)^{-1} \mathbf{Y} = \mathbf{k}(\mathbf{x}) \boldsymbol{\alpha} \quad (13)$$

其中: $\boldsymbol{\alpha} = \left(\frac{1}{C} \mathbf{I}_N + \boldsymbol{\Omega} \right)^{-1} \mathbf{Y}$ 为 KELM 的输出权值。

研究显示,KELM 比起 ELM 有更好的泛化性能的同时需要更少的迭代参数^[10],KELM 往往能和 SVM 达到相同的精度,但训练预测花费的时间更少^[11],因此笔者选用 KELM 作为预测模型。径向基核函数(radial basis kernel function, 简称 RBF)是适应性最好、使用最为普遍的一种核函数,其表达式为

$$K(\mathbf{x}, \mathbf{x}_i) = \exp(-\|\mathbf{x} - \mathbf{x}_i\|^2 / (2\sigma^2)) \quad (14)$$

其中: σ 为 RBF 的宽度,也叫核参数。

1.4 CS 算法概述

杜鹃搜索算法是文献[12]提出的一种新兴启发算法,采用相关的 Lévy 飞行搜索机制。用杜鹃鸟的蛋来代表新的解,目的是使用新的和潜在的解来代替不那么好的解。该算法基于 3 个理想化规则:
a. 每个杜鹃下一个蛋,堆放在一个随机选择的巢中;
b. 最好的高品质的鸟巢将转移到下一代;
c. 巢数量固定,杜鹃的蛋被发现的概率为 $[0, 1]^{[13]}$ 。研究表明,杜鹃搜索比其他群体优化算法更有效。

笔者采用 CS 对 KELM 的正则化参数 C 和核函数参数 σ 进行优化, C 的取值范围设定为 $[2^{-8}, 2^8]$, σ^2 的取值范围设定为 $[0.01, 100]$,具体步骤如下:

- 1) 初始化参数 C 和 σ ,生成初始种群。
- 2) 将平均绝对误差(mean absolute error,简称

MAE)作为适应度函数计算每个鸟巢的适应度,求出种群最优位置。

3) 用 $x_i(t+1)=x_i(t)+\alpha \oplus \text{levy}(\lambda)$ 更新鸟巢位置,其中: $x_i(t)$ 代表第 i 个鸟巢在 t 代的鸟巢位置; α 为步长; \oplus 代表点对点乘法; $\text{levy}(\lambda)$ 表示莱维 (Lévy) 随机搜索路径,且 $\text{levy}(\lambda) \sim u=t^{-\lambda} (1<\lambda<3)$ 。将现有鸟巢位置与上一代鸟巢位置进行对比,择优作为当前最优位置。

4) 用随机数 $r \in [0,1]$ 与鸟巢主人发现外来鸟概率 P_a 对比,若 $r > P_a$,则随机地改变鸟巢位置,得到一组新的鸟巢位置。

5) 比较各鸟巢适应度值,更新当前鸟巢最优位置。

6) 满足容许值停止迭代,否则重新执行步骤 3。

7) 得到最优参数。

有研究表明,由于 CS 算法搜索过程采用 Lévy 飞行,短距离的探索与长距离探索相间,因此 CS 在迭代后期有更强的优化能力^[14]。同时,有研究指出,CS 算法和粒子群优化 (particle swarm optimization, 简称 PSO) 算法都能收敛到全局最优,但是仍有机会陷入局部最优^[15],因此对每种情况运行 10 次求平均值得到最终结果^[16]。

1.5 MIMO 策略用于多步预测

在时间序列预测中,往往希望了解未来一段时间的数值或者趋势,为了获得更长时间的预测值而增大序列的间隔时间往往导致信号信息丢失和预测值不能用于实时调度的问题,多步预测就成为一种重要方法。因为采用多输入单输出函数,先前的多步预测策略,例如滚动策略、直接策略和直接滚动策略被认为是单输出的策略,影响多步预测精度的主要因素有误差的积累、准确性的降低和不确定性的增加^[17]。MIMO 策略能避免上述单输出策略引起的未来预测值之间的联系被丢失的情况,提高准确性,降低不确定性,同时 MIMO 策略一次输出所有步长预测值,消除了滚动法中的误差积累现象,因此 MIMO 策略相比于其他多步预测策略有更高的预测精度。近年来,多篇文献也反应 MIMO 策略相比于其他多步预测策略有更高的预测精度^[17-19]。另外,与直接策略以及直接滚动策略需要构建多个模型相比,MIMO 策略仅需一个模型,建模简便。

MIMO 策略仅需通过时间序列 $[x_1, \dots, x_N]$ 来训练一个多输出模型 F

$$[x_{t+H}, \dots, x_{t+1}] = F(x_t, \dots, x_{t-d+1}) + w$$

$$t \in \{d, \dots, N-H\} \quad (15)$$

其中: $F: \mathbf{R}^d \rightarrow \mathbf{R}^H$ 为一个向量值函数; $w \in \mathbf{R}^H$ 为一个不一定具有对角协方差的噪声向量; d 为重构的时间序列维数; N 为时间序列的长度; H 为预测步长。

以矩阵的形式表现更为直观, MIMO 策略训练模型时输入矩阵为

$$\begin{bmatrix} x_1 & x_2 & \cdots & x_{d-1} & x_d \\ x_2 & x_3 & \cdots & x_d & x_{d+1} \\ x_3 & x_4 & \cdots & x_{d+1} & x_{d+2} \\ \vdots & \vdots & & \vdots & \vdots \\ x_{N-H-d+1} & x_{N-H-d} & \cdots & x_{N-H-3} & x_{N-H-2} \end{bmatrix}$$

输出矩阵为

$$\begin{bmatrix} x_{d+1} & \cdots & x_{d+H} \\ x_{d+2} & \cdots & x_{d+H+1} \\ x_{d+3} & \cdots & x_{d+H+2} \\ \vdots & & \vdots \\ x_{N-H-1} & \cdots & x_N \end{bmatrix}$$

训练好模型后预测值通过多输出模型 \hat{F} 得出

$$[\hat{x}_{N+H}, \dots, \hat{x}_{N+1}] = \hat{F}(x_N, \dots, x_{N-d+1}) \quad (16)$$

笔者按照训练集占比 75% 左右的标准,选取前 800 个点作为训练集,即 N 取 800,预测后 200 个点。在超前 3 步和超前 6 步的预测中, H 分别取 3 和 6,每次预测得到后一步长所有的预测值,循环得到后 200 个点的预测值。

1.6 信号恢复流程

笔者创新性地提出用 MEWT-KELM-CS-MIMO 模型来对多点缺失数据进行同步恢复,多步预测得到未来一段时间的预测值。整个流程框架如图 1 所示。具体步骤如下:

1) 按 MEWT 的技术框架,将多点中断信号前一定长度的时间序列进行同步相空间重构后组合成新的矩阵;

2) 将重构后的矩阵分为训练集和测试集;

3) 归一化处理能提高预测的精度和收敛的速度,将新组合成的矩阵归一化到 $[-1,1]$;

4) 径向基核函数极限学习机用来训练和预测,其中正则化参数和核参数用 CS 算法优化。

5) 将各模态的预测值相加得到预测结果,计算评价指标评价模型;

6) MIMO 策略用来实现模型的 1 步预测、3 步预测和 6 步预测,并与滚动策略对比。所提出的模型还与 EWT-KELM-CS 单点模型、NA-MEMD-KELM-

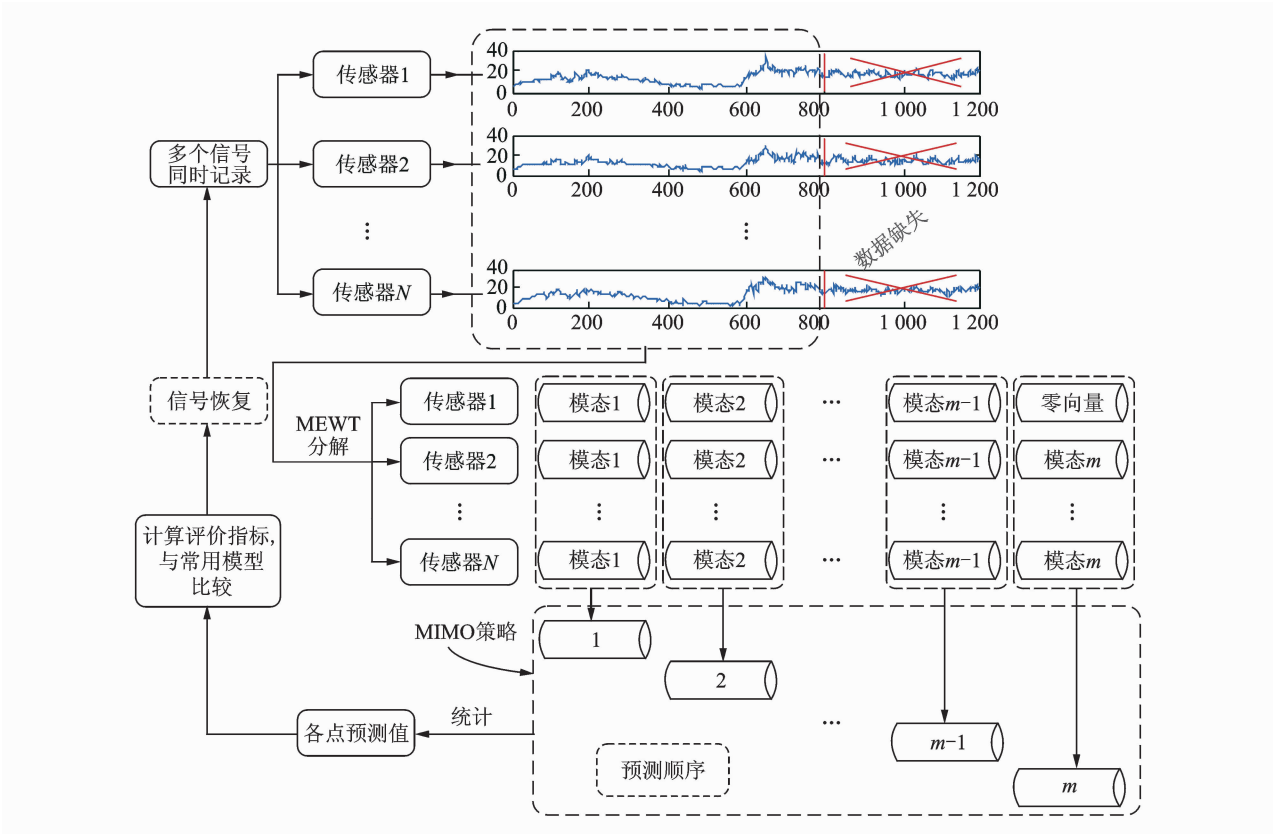


图 1 信号恢复流程图
Fig. 1 Flowchart of signal recovery

CS 多点同步模型通过评价指标进行对比,最终证明 MEWT-KELM-CS-MIMO 多点同步模型的优越性;

7) 多步预测结果可用于传感器信号恢复,也可在结构振动控制的主动控制中提前计算结构下一步荷载。

2 基于实测风压数据的模型验证

对某办公楼楼顶砌筑的矩形结构在 2012 年 11 月 23 日测得的实测风压数据^[20]进行研究。该测试结构位于办公楼楼顶,视野开阔,当天风向为东北风,风力为 3 至 4 级,实测方案和实测平面布置图如图 2 所示。在结构 AB 墙表面,沿竖向每隔 21 cm 布置 1#~5# 风压传感器,DA 墙表面,沿竖向每隔 21 cm 布置 6#~10# 风压传感器,1# 和 6# 风压传感器距离结构顶面 18 cm,同时,所有传感器距角 A 水平距离均为 23 cm。可知,6#~10# 风压传感器位于迎风面,1#~5# 风压传感器位于背风面,笔者取其中 2#~4# 和 7#~9# 传感器的实测数据来分析。

现场采样频率为 20 Hz,取 1 000 个数据点用于模型的训练和测试,为了获得较长的时间序列,采样点之间间隔取 0.8 s。

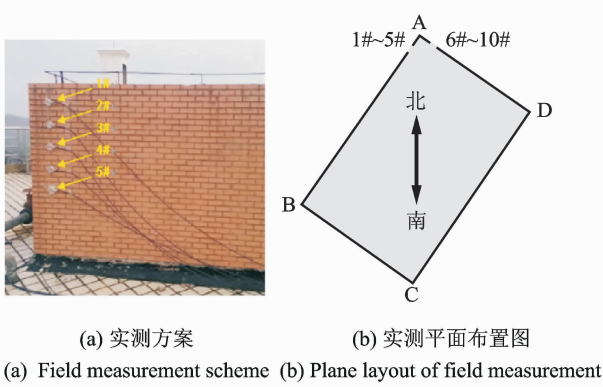


图 2 实测方案和平面布置图
Fig. 2 Field measurement scheme and plane layout

2.1 迎风面模型验证

假设迎风面 3 点数据同时缺失,用 MEWT-KELM-CS-MIMO 模型对这 3 点数据同步恢复。7#、8# 和 9# 风压数据用 EWT 分解后产生的模态数分别为 11、12 和 11,嵌入维度 d 取 10,MEWT 确定模态数为 12,不足 12 个模态的用零矩阵补齐后重构为新矩阵,之后将其分为训练集和测试集两部分。训练集取 790 个 30 维向量,测试集取 200 个 30 维向量。3 种常见模型和所提出的 MEWT-

KELM-CS-MIMO 分别预测后对比,采用以下 4 个指标评价 4 种模型的预测效果。

平均绝对误差

$$MAE = \frac{1}{L} \sum_{i=1}^L |X(i) - \hat{X}(i)|$$

(17)

均方根误差

$$RMSE = \sqrt{\frac{1}{L} \sum_{i=1}^L (X(i) - \hat{X}(i))^2}$$

(18)

相关系数

$$R = \frac{\text{cov}(X(i), \hat{X}(i))}{\sqrt{\text{cov}(X(i), X(i)) \text{cov}(\hat{X}(i), \hat{X}(i))}}$$

(19)

平均绝对相对误差

$$MAPE = \frac{1}{L} \sum_{i=1}^L \left| \frac{X(i) - \hat{X}(i)}{X(i)} \right| \times 100$$

(20)

其中: $X(i)$ 为原始信号; $\hat{X}(i)$ 为预测后的信号; i 为采样点; L 为信号采样点总数; cov 表示求协方差矩阵。

由于篇幅限制,8#超前1步、3步和6步的预测结果及误差分布图如图3所示。三点的各模型预测性能评价指标如表1所示。

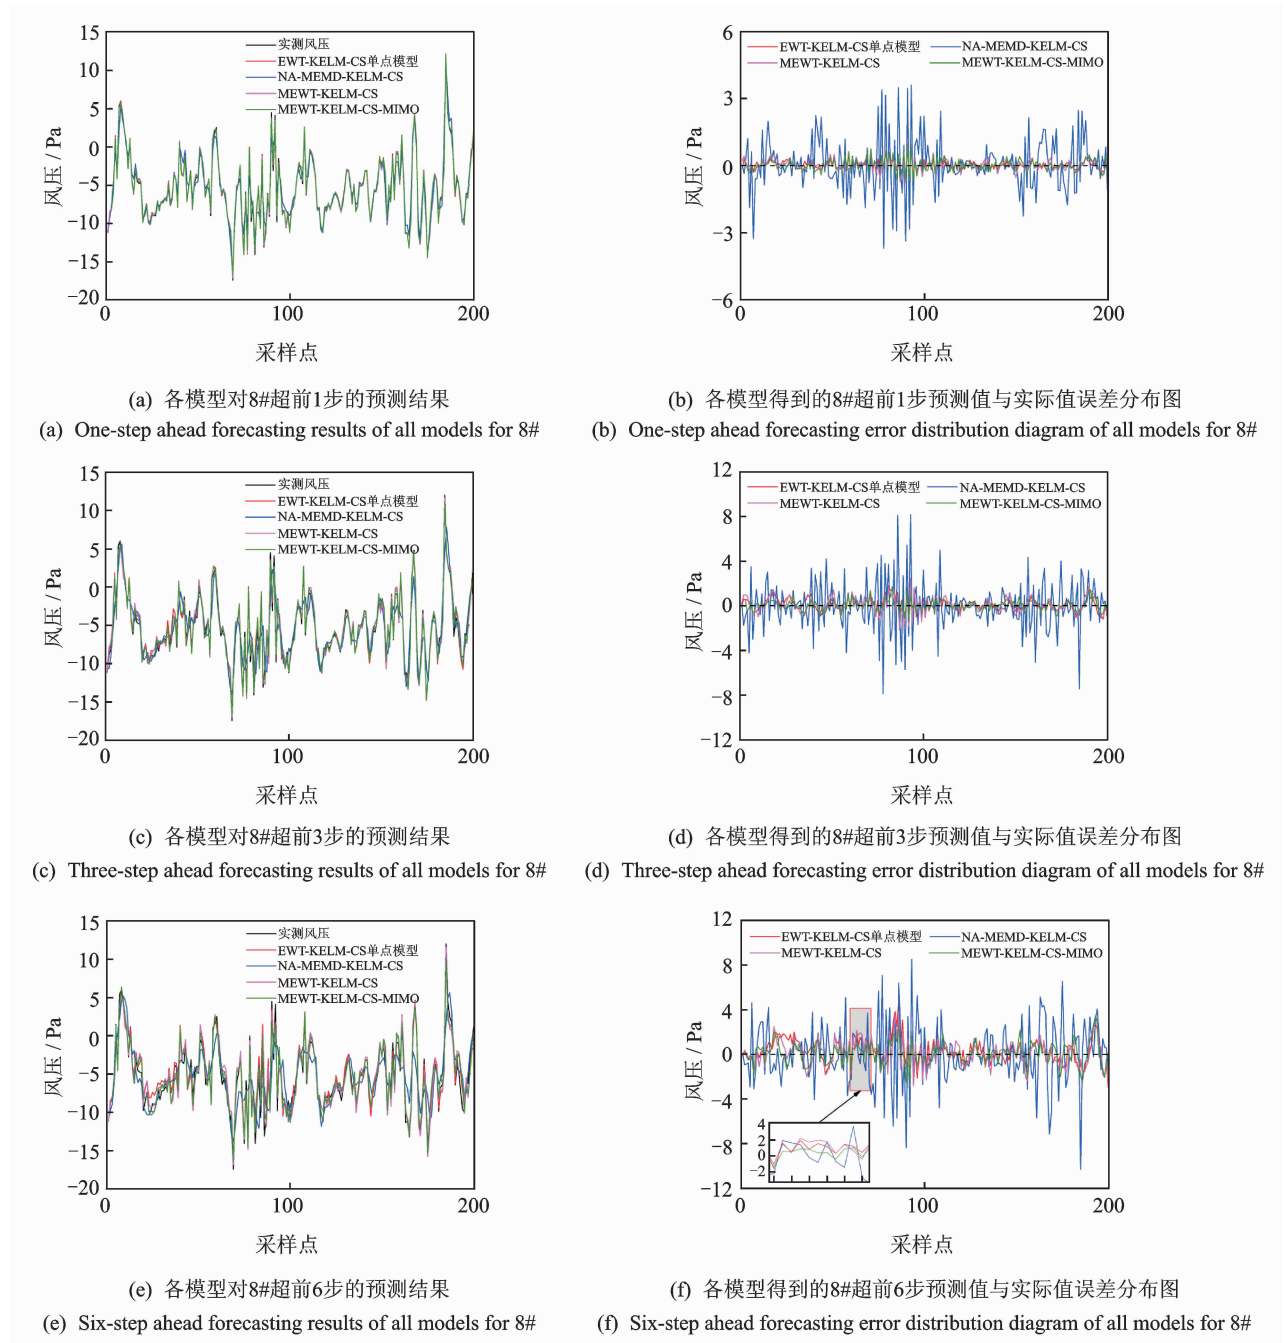


图 3 8# 预测结果和误差分布图

Fig. 3 Forecasting results and Error distribution diagram of 8#

表 1 4 种预测模型的预测性能评价指标对比(8#)
Tab.1 Prediction performance indexes of four predicting models(8#)

模型	1 步预测				3 步预测				6 步预测			
	MAE	RMSE	R	MAPE	MAE	RMSE	R	MAPE	MAE	RMSE	R	MAPE
7#												
A	0.132	0.171	0.999	0.111	0.438	0.571	0.992	0.354	1.330	1.565	0.940	1.278
B	0.889	1.256	0.962	0.676	1.729	2.373	0.855	1.078	2.147	2.881	0.778	1.410
C	0.194	0.242	0.999	0.139	0.471	0.580	0.992	0.455	0.977	1.208	0.965	1.031
D	0.175	0.221	0.999	0.138	0.402	0.519	0.994	0.249	0.709	0.925	0.980	0.468
8#												
A	0.156	0.208	0.999	0.046	0.469	0.604	0.991	0.132	0.910	1.187	0.965	0.285
B	0.858	1.211	0.962	0.504	1.658	2.310	0.848	1.059	2.090	2.762	0.774	1.049
C	0.208	0.276	0.998	0.078	0.542	0.711	0.987	0.192	0.948	1.206	0.961	0.311
D	0.202	0.268	0.998	0.073	0.370	0.488	0.994	0.120	0.743	0.978	0.975	0.297
9#												
A	0.122	0.148	0.999	0.033	0.392	0.499	0.992	0.142	0.713	0.931	0.972	0.215
B	0.756	1.065	0.962	0.214	1.401	1.914	0.872	0.394	1.674	2.263	0.816	0.473
C	0.186	0.231	0.998	0.054	0.458	0.574	0.989	0.146	0.929	1.145	0.956	0.315
D	0.180	0.223	0.998	0.051	0.359	0.469	0.993	0.115	0.626	0.849	0.976	0.185

A 为 EWT-KELM-CS 单点模型;B 为 NA-MEMD-KELM-CS;C 为 MEWT-KELM-CS;D 为 MEWT-KELM-CS-MIMO

由表 1 可知,在超前 1 步预测时,所提出的模型接近 EWT-KELM-CS 单点模型,在超前 3 步预测和超前 6 步预测中,所提出的模型要优于其他 3 种模型。为了更好地评价各模型的预测性能,采用相对提升指标 $\rho_{MAE} = \left(\frac{MAE1 - MAE2}{MAE1} \right) \times 100\%$ 来说明提升的精度。在超前 3 步预测时,7# 所提出的模型 D 相对于模型 A,B,C 的 ρ_{MAE} 达到 8.2%,76.7%,14.6%;8# 模型 D 相对于模型 A,B,C 的 ρ_{MAE} 达到 21.1%,77.7%,31.7%;9# 模型 D 相对于模型 A,B,C 的 ρ_{MAE} 达到 8.4%,74.4%,21.6%。在超前 6 步预测时,7# 所提出的模型 D 相对于模型 A,B,C 的 ρ_{MAE} 达到 46.7%,70.0%,27.4%;8# 模型 D 相对于模型 A,B,C 的 ρ_{MAE} 达到 18.4%,64.4%,21.6%;9# 模型 D 相对于模型 A,B,C 的 ρ_{MAE} 达到 12.2%,62.6%,32.6%。

2.2 背风面模型验证

假设背风面 3 点数据同时缺失,用 MEWT-KELM-CS-MIMO 模型对这 3 点数据同步恢复。2#,3# 和 4# 风压数据用 EWT 分解后产生的模态

数分别为 9,8 和 8,嵌入维度 d 取 10,MEWT 确定模态数为 9,不足 9 个模态的用零矩阵补齐后重构为新矩阵,之后将其分为训练集和测试集两部分。训练集取 790 个 30 维向量,测试集取 200 个 30 维向量。3 种常见模型和所提出的 MEWT-KELM-CS-MIMO 分别预测后对比,采用上述评价指标对各模型进行评价。3# 超前 1 步、3 步和 6 步的预测结果及误差分布图如图 4 所示。3 点的各模型预测性能评价指标如表 2 所示。

由表 2 可知,在超前 1 步预测时,提出的模型接近 EWT-KELM-CS 单点模型,在超前 3 步预测和超前 6 步预测中,对于 3# 和 4#,所提出的模型要优于其他 3 种模型,对于 2#,模型 D 效果和模型 A 在超前 3 步预测时相差不多,但是优于模型 B,C。在超前 3 步预测时,2# 模型 D 相对于模型 B,C 的 ρ_{MAE} 达到 78.4%,17.5%;3# 模型 D 相对于模型 A,B,C 的 ρ_{MAE} 达到 9.7%,76.0%,28.8%;4# 模型 D 相对于模型 A,B,C 的 ρ_{MAE} 达到 9.7%,71.3%,25.4%。在超前 6 步预测时,2# 所提出的模型 D 相对于模型 A,B,C 的 ρ_{MAE} 达

到 30.8%, 57.7%, 33.2%; 3# 模型 D 相对于模型 A, B, C 的 ρ_{MAE} 达到 33.7%, 54.8%, 35.8%; 4# 模型 D 相对于模型 A, B, C 的 ρ_{MAE} 达到 20.4%, 44.6%, 33.3%。

2.3 双面模型验证

随机选取迎风面和背风面的数据点用 MEWT-

KELM-CS-MIMO 对数据进行同步预测, 结果和单独预测迎风面或单独预测背风面结果相差不多。同时, 从以上结果看出, 3 点同步预测结果中中间点和两端点效果相近, 反映出笔者采用的多点同步模型不受空间的限制, 仅用各点以往的数据样本来训练模型, 同步预测之后的信号能达到比空间点预测更高的精度。

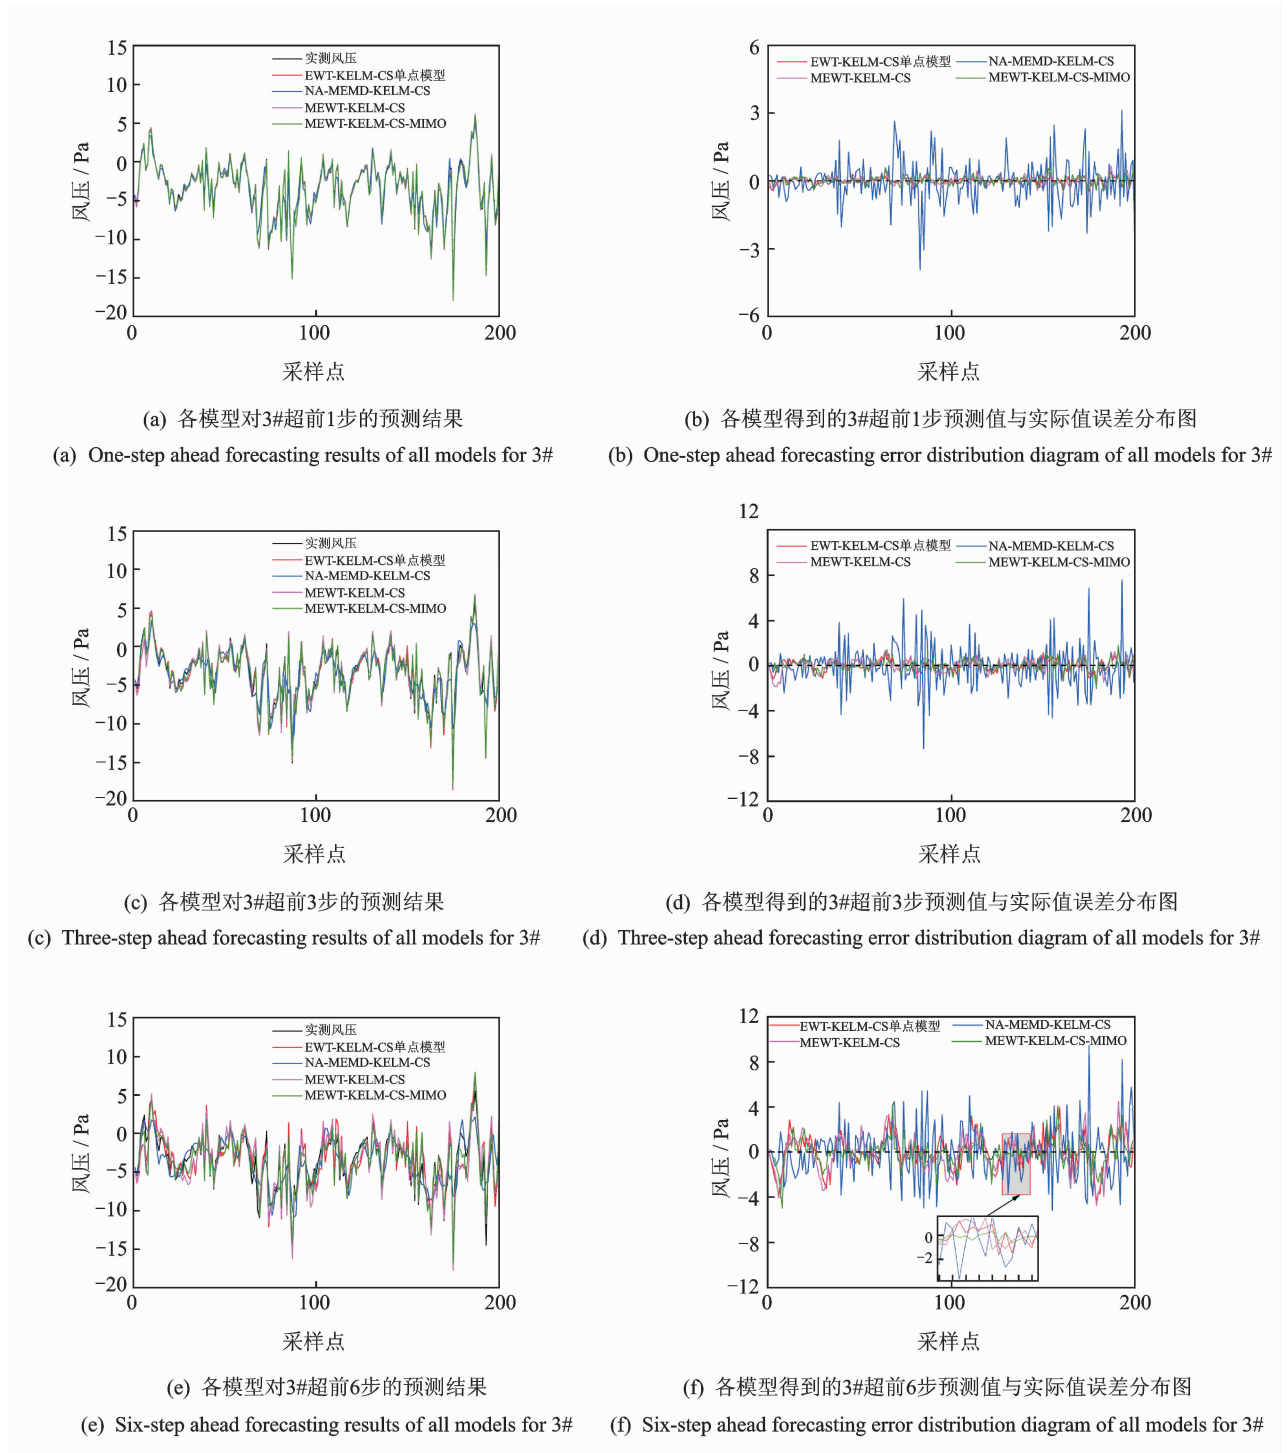


图 4 3# 预测结果和误差分布图

Fig. 4 Forecasting results and Error distribution diagram of 3#

表 2 4 种预测模型的预测性能评价指标对比(3#)
Tab. 2 Prediction performance indexes of four predicting models(3#)

模型	1 步预测				3 步预测				6 步预测			
	MAE	RMSE	R	MAPE	MAE	RMSE	R	MAPE	MAE	RMSE	R	MAPE
2#												
A	0.089	0.115	0.999	0.315	0.313	0.448	0.993	0.518	1.099	1.385	0.930	2.493
B	0.753	1.064	0.957	1.474	1.530	2.108	0.817	3.295	1.797	2.393	0.757	7.862
C	0.121	0.157	0.999	0.367	0.401	0.519	0.991	1.626	1.139	1.473	0.923	5.576
D	0.127	0.162	0.999	0.332	0.331	0.454	0.992	1.387	0.761	1.097	0.954	8.236
3#												
A	0.096	0.129	0.999	0.711	0.372	0.481	0.991	2.794	1.207	1.554	0.906	8.253
B	0.713	0.983	0.962	7.468	1.406	1.966	0.831	10.782	1.770	2.339	0.751	7.834
C	0.149	0.189	0.999	1.177	0.473	0.597	0.986	3.842	1.246	1.580	0.907	7.846
D	0.143	0.181	0.999	0.760	0.337	0.469	0.991	1.484	0.800	1.164	0.945	1.663
4#												
A	0.097	0.134	0.999	0.077	0.423	0.537	0.989	0.298	1.182	1.498	0.913	1.069
B	0.711	1.032	0.959	0.518	1.333	1.852	0.860	1.250	1.699	2.310	0.771	1.130
C	0.141	0.178	0.999	0.092	0.512	0.647	0.984	0.326	1.411	1.787	0.878	1.396
D	0.137	0.175	0.999	0.070	0.382	0.517	0.990	0.272	0.941	1.344	0.930	0.899

A 为 EWT-KELM-CS 单点模型;B 为 NA-MEMD-KELM-CS;C 为 MEWT-KELM-CS;D 为 MEWT-KELM-CS-MIMO

3 基于实测强非平稳风速数据的模型验证

Derecho 是一种典型的风暴,通常可以存活超过 8 h 以上,其特点在于具有大面积超过 65 节(1 节=1.852 km/h)的持续强风,移速较高,破坏力很强。2002 年 5 月 20 日至 7 月 15 日德克萨斯理工大学大气科学系在瑞茜技术中心由北向南布置了 7 个便携式塔,测得了 Derecho 水平风速数据。塔间间隔为 263 m,其中塔 1 和塔 7 最高观测点位置高为 3 m,塔 2,3,5,6 最高观测点位置高为 10 m,塔 4 最高观测点位置高为 15 m。选取塔 4 上高度为 3.96, 6.10 以及 10.06 m 处的水平风速数据来验证多点同步模型,将 3.96 m 处的点记为 1#, 6.10 m 处的点记为 2#,10.06 m 处的点记为 3#。各塔布置图及观测点位置如图 5 所示。原始采样频率为 2 Hz,笔者采用 1 Hz,各点实测数据如图 6 所示。以 3#为例,运用增广的迪基-福勒检验法(augmented dickey-fuller test,简称 ADF)检验时间序列平稳性。若存在单位根,则为非平稳时间序列;否则为平稳时间序列。风速样本检验值为-2.820,大于




图 5 各塔布置图及观测点位置
Fig. 5 The layout of towers and the location of observation points




图 6 各点实测数据图
Fig. 6 Original wind speed time series

1%, 5% 显著性水平下的临界值 -3.437 和 -2.864 , 存在单位根的原假设成立, 所以样本为非平稳时间序列。2# 超前 1 步、3 步和 6 步的预测结果及误差分布图如图 7 所示。2# 的各模型预测性能评价指标如表 3 所示。

由表 3 可得, 在超前 1 步预测和超前 3 步预测中, 提出的模型效果接近 EWT-KELM-CS 单点模型, 优于其他 2 种模型。但在超前 6 步预测时, 模型 D 相对于模型 A, B, C 的 ρ_{MAE} 达到 15.1%, 62.3%, 28.0%。

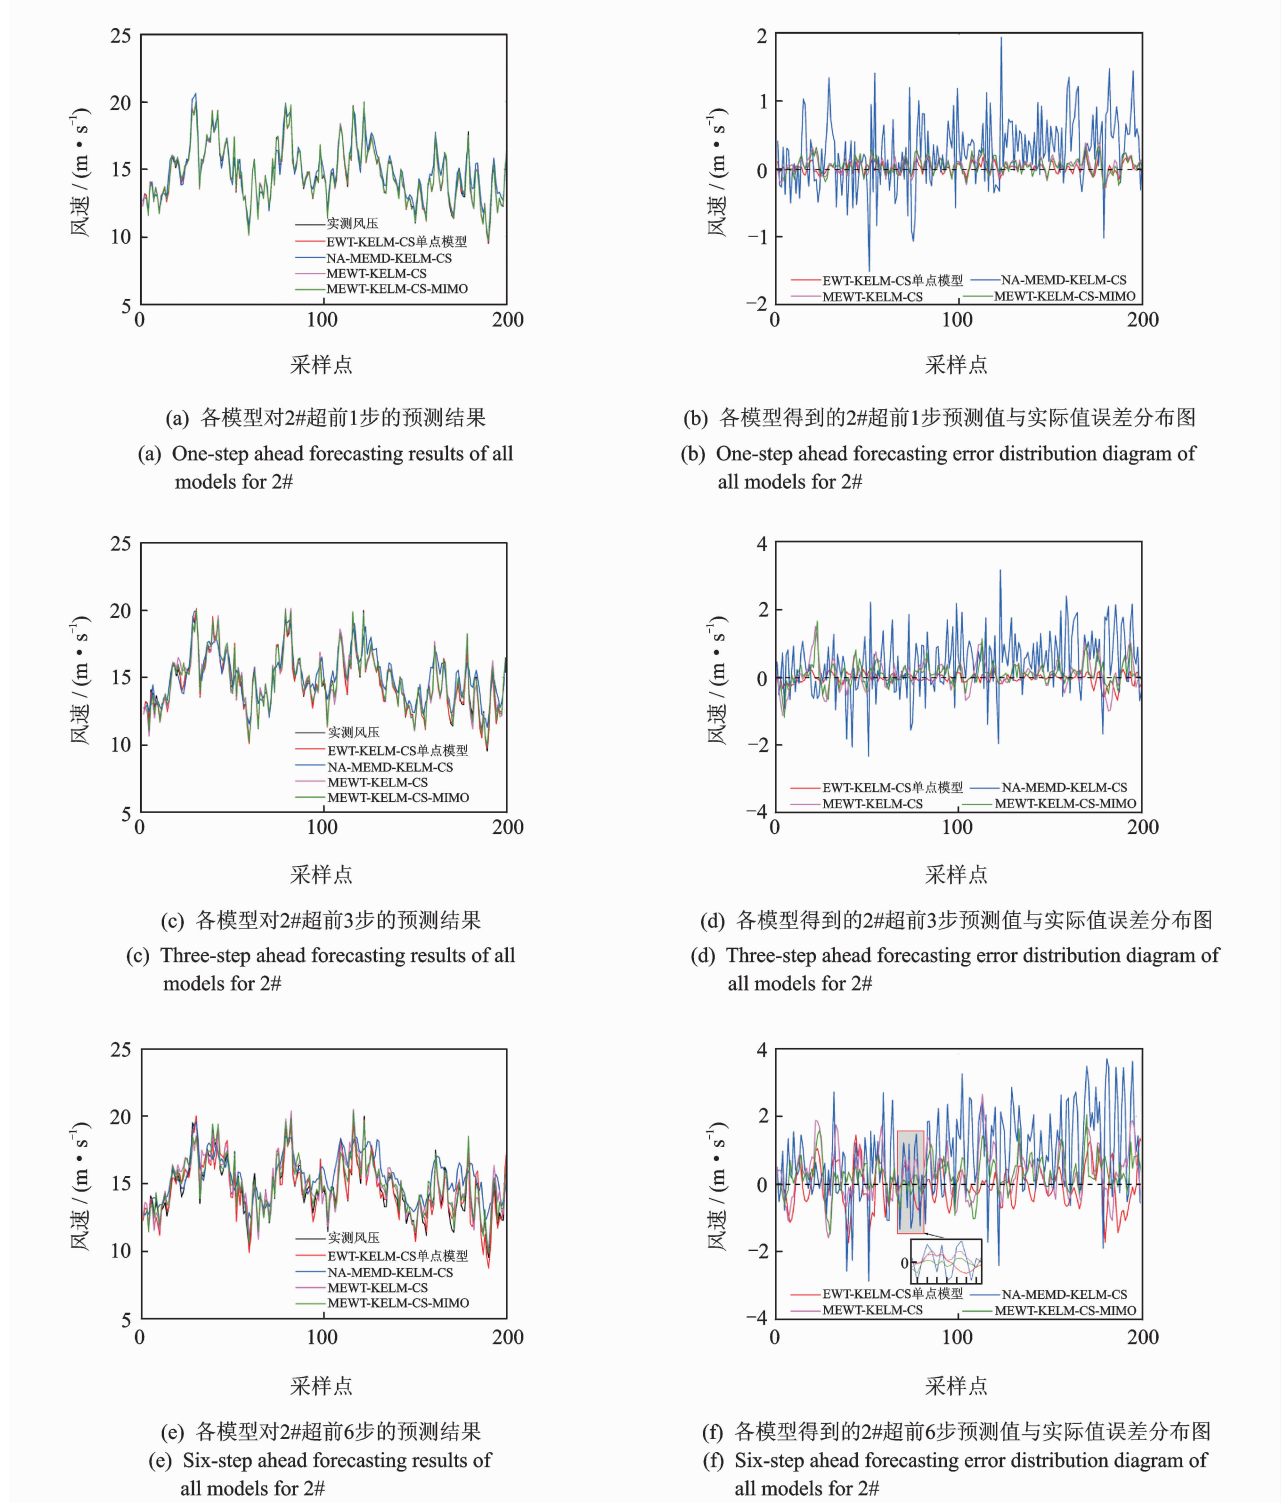


图 7 2# 预测结果和误差分布图
Fig. 7 Forecasting results and Error distribution diagram of 2#

表 3 4 种预测模型的预测性能评价指标对比(2#)
Tab.3 Prediction performance indexes of four predicting models (2#)

模型	1 步预测				3 步预测				6 步预测			
	MAE	RMSE	R	MAPE	MAE	RMSE	R	MAPE	MAE	RMSE	R	MAPE
2#												
A	0.019	0.026	0.999	0.001	0.117	0.153	0.997	0.008	0.522	0.664	0.951	0.037
B	0.455	0.575	0.969	0.032	0.767	0.978	0.906	0.055	1.176	1.495	0.802	0.086
C	0.102	0.127	0.998	0.007	0.327	0.434	0.979	0.023	0.615	0.786	0.939	0.043
D	0.097	0.123	0.999	0.007	0.228	0.337	0.988	0.016	0.443	0.585	0.969	0.031

A 为 EWT-KELM-CS 单点模型;B 为 NA-MEMD-KELM-CS;C 为 MEWT-KELM-CS;D 为 MEWT-KELM-CS-MIMO

4 结 论

参 考 文 献

1) MEWT-KELM-CS-MIMO 的多点同步多步预测模型预测精度高,与 EWT-KELM-CS 单点模型接近,满足精度要求,同时发展多点同步多步预测模型能大大提升工程应用效率。

2) MEWT-KELM-CS-MIMO 模型的预测精度高于 MEWT-KELM-CS 模型,说明多步预测时 MIMO 策略优于滚动策略,与国际文献结论一致。

3) 随着步数的增加,MEWT-KELM-CS-MIMO 模型精度可以超过 EWT-KELM-CS 单点模型,可以实现更长时间预测的同时保证精度。多点同步多步预测模型能提高计算的效率,比单点模型具有更大的工程应用价值。

4) 传统使用 NA-MEMD 对多维信号进行分解的方法精度较低,因为加入噪声的 MEMD 不能完全解决模态混叠问题,采用有良好数学基础的 EWT 能很好地解决这个问题,但是无法保证多点分解后模态数一致。笔者创新性采用零矩阵来补齐模态数,提出 MEWT 概念,得到更高精度的同步预测结果,证明了 MEWT 结合传统的 KELM 适用于多点同步预测。

5) 若传感器彻底损坏,无法带入新鲜样本,只能恢复后面一个步长的数据,要想恢复很长一段时间的数据,可以将采样间隔加大或将预测值不断滚动迭代实时分解后预测下一步长。同时多点同步多步预测模型在结构振动控制的主动控制中应用前景广阔,可以提前计算结构整个面的受力,让结构提前知道下一步的反应,减小时滞,提高效率。

[1] Rehman N, Mandic D P. Multivariate empirical mode decomposition[J]. Proceedings Mathematical Physical & Engineering Sciences, 2010,466(2117):1291-1302.

[2] Lü Yong, Yuan Rui, Song Gangbing. Multivariate empirical mode decomposition and its application to fault diagnosis of rolling bearing[J]. Mechanical Systems & Signal Processing, 2016,81:219-234.

[3] Huang Weiping, Zeng Jing, Wang Ziyang, et al. Partial noise assisted multivariate EMD: an improved noise assisted method for multivariate signals decomposition[J]. Biomedical Signal Processing & Control, 2017,36:205-220.

[4] 熊旸, 杨世锡, 甘春标,等. 齿轮点蚀的多通道数据融合识别方法[J]. 振动、测试与诊断, 2014,34(1):63-68.

Xiong Xin, Yang Shixi, Gan Chunbiao, et al. Multi-channel data fusion for the identification of gear pitting [J]. Journal of Vibration, Measurement & Diagnosis, 2014, 34(1):63-68. (in Chinese)

[5] 王恒, 杜世昌, 奚立峰,等. 基于改进多元经验模态分解的多通道振动信号融合分析[J]. 机械设计与研究, 2018(2):31-36.

Wang Heng, Du Shichang, Xi Lifeng, et al. Multi-channel vibration signal analysis based on improved multivariate empirical mode decomposition[J]. Machine Design & Research, 2018(2):31-36. (in Chinese)

[6] 段若晨,王丰华,周荔丹,等. 利用窄带噪声辅助多元经验模态分解算法检测换流变压器用有载分接开关机械状态[J]. 电工技术学报,2017,32(10):182-189.

Duan Ruochen, Wang Fenghua, Zhou Lidan, et al. Mechanical condition detection of on-load tap-changer

in converter transformer based on narrowband noise assisted multivariate empirical mode decomposition algorithm[J]. Transactions of China Electrotechnical Society, 2017,32(10):182-189. (in Chinese)

[7] Zhang Chu, Zhou Jianzhou, Li Chaoshun, et al. A compound structure of ELM based on feature selection and parameter optimization using hybrid backtracking search algorithm for wind speed forecasting[J]. Energy Conversion & Management, 2017,143:360-376.

[8] Gilles J. Empirical wavelet transform [J]. IEEE Transactions on Signal Processing, 2013, 61 (16): 3999-4010.

[9] Gilles J, Heal K. A parameterless scale-space approach to find meaningful modes in histograms u2014 Application to image and spectrum segmentation[J]. International Journal of Wavelets Multiresolution & Information Processing, 2014,12(6):191-209.

[10] Huang Gao, Huang Guangbin, Song Shiji, et al. Trends in extreme learning machines: a review[J]. Neural Networks the Official Journal of the International Neural Network Society, 2015,61(C):32.

[11] Cheng Chi, Tay W P, Huang Guangbin. Extreme learning machines for intrusion detection[C]//International Joint Conference on Neural Networks. [S. l.]: IEEE, 2012:1-8.

[12] Yang Xinshe, Deb S. Cuckoo search: recent advances and applications [J]. Neural Computing & Applications, 2014,24(1):169-174.

[13] Zhang Kequan, Qu Zongxi, Wang Jianzhou, et al. A novel hybrid approach based on cuckoo search optimization algorithm for short - term wind speed forecasting[J]. Environmental Progress & Sustainable Energy, 2017,36(3):943-952.

[14] 叶志伟,赵伟,王明威,等. 一种基于杜鹃搜索算法的图像自适应增强方法[J]. 测绘科学技术学报,2016,33(1):38-42.

Ye Zhiwei, Zhao Wei, Wang Mingwei, et al. An adaptive image enhancement approach based on cuckoo search algorithm[J]. Journal of Geomatics Science and Technology, 2016,33(1):38-42. (in Chinese)

[15] Civicioglu P, Besdok E. A conceptual comparison of the Cuckoo-search, particle swarm optimization, differential evolution and artificial bee colony algorithms [J]. Artificial Intelligence Review, 2013,39(4):315-346.

[16] Wong P K, Wong K I, Vong C M, et al. Modeling and optimization of biodiesel engine performance using kernel-based extreme learning machine and cuckoo search[J]. Renewable Energy, 2015,74:640-647.

[17] Taieb S B, Bontempi G, Atiya A F, et al. A review and comparison of strategies for multi-step ahead time series forecasting based on the NN5 forecasting competition[J]. Expert Systems with Applications, 2012,39(8):7067-7083.

[18] Zhao Jing, Wang Jianzhou, Liu Feng. Multistep forecasting for short-term wind speed using an optimized extreme learning machine network with decomposition-based signal filtering[J]. Journal of Energy Engineering, 2016,142(3):04015036-1-21.

[19] Yang Dixiong, Yang Kaisheng. Multi-step prediction of strong earthquake ground motions and seismic responses of SDOF systems based on EMD-ELM method [J]. Soil Dynamics & Earthquake Engineering, 2016,85:117-129.

[20] 李锦华,吴春鹏,陈水生. 矩形结构非高斯风荷载特性研究[J]. 振动、测试与诊断,2014,34(5):951-959.

Li Jinhua, Wu Chunpeng, Chen Shuisheng. Characteristics of non-Gaussian wind pressures on rectangular structure[J]. Journal of Vibration, Measurement & Diagnosis, 2014,34(5):951-959. (in Chinese)



第一作者简介:李春祥,男,1964 年 12 月生,博士、教授、博士生导师。主要研究方向为结构抗震与风工程、结构振动控制、人工智能与结构健康监测。曾发表《Non-Gaussian non-stationary wind pressure forecasting based on the improved empirical wavelet transform》(《Journal of Wind Engineering and Industrial Aerodynamics》2018 年 179 卷)等论文。
E-mail: li-chunxiang@vip. sina. com

