

基于深度分解的非平稳非高斯过程多步预测*

李春祥, 金梦雅

(上海大学土木工程系 上海, 200444)

摘要 首先,综合运用小波包分解(wavelet packet decomposition,简称 WPD)、样本熵、单位根检验法和变分模态分解(variational mode decomposition,简称 VMD),提出利用混合深度分解(hybrid deep decomposition,简称 HDD)对非平稳非高斯过程进行处理,降低实测风速风压复杂性,提升其可预测性;其次,根据 Mercer 定理构造了 Morlet+Hermite(MH)线性组合核函数,使其具有局部多分辨率和全局泛化性的优点,采用粒子群算法(particle swarm optimization,简称 PSO)对 MH 核进行参数优化,结合最小二乘支持向量机(least square support vector machine,简称 LSSVM)建立 HDD-MH-LSSVM 多步预测模型;然后,将该模型与常用核函数构成的 HDD-Poly-LSSVM, HDD-径向基函数(radial basis function,简称 RBF)-LSSVM 多步预测模型以及极限学习机(extreme learning machine,简称 ELM)多步预测模型形成对比;最后,采用下击暴流风速和台风天大跨膜结构表面实测风压进行大步数多步预测验证。结果表明, HDD-MH-LSSVM 预测算法预测精度高、稳定性好、通用性强。

关键词 非平稳非高斯过程; 极端风; 混合深度分解; 小波混合核; 最小二乘支持向量机; 多步预测

中图分类号 TU311

引言

在建筑 and 施工技术进步的同时,结构也呈现出轻质、高柔和低阻的特性,这会导致结构对风荷载有较大敏感性。为了获得更多在极端风作用下结构风振响应特性,需开展全尺度现场实测工作。建立风速风压多步预测模型不仅能够完善抗风分析所需的数据,还能为结构防风减灾提供决策辅助^[1]。在土木工程领域,恢复结构健康监测系统故障传感器数据,为结构抗风分析提供可靠信息^[2-3]。在交通运输领域,建立风速预警系统,减小恶劣强风对铁路行车危害^[4]。在风力发电领域,确定风电机组容量,避免极大风速对发电机损害等^[5]。

通过增大序列时间间隔的方法能获得更长时间的预测值,但这易丢失风速信息且不利于实时调度。多步预测需要解决误差积累、准确性降低和不确定性增加的问题,因此精度较低。风速预测算法主要分物理方法、统计学方法、智能方法和分解-组方法。物理方法对短期风速预测的精度较低。统计学方法是以时间序列法为代表的预测方法,如自回归模型(auto regressive,简称 AR)、自回归-滑动平均模型(auto regressive moving average,简称 AR-

MA)、累计自回归-滑动平均模型(auto-regressive integrated moving average,简称 ARIMA)等。Wang 等^[6]提出余项修正法改进 ARIMA 模型,预测结果证明改进 ARIMA 比传统方法预测精度更高。Liu 等^[7]提出用卡尔曼滤波法对 ARIMA 初始参数选择,预测精度进一步提升。

智能方法种类丰富且预测鲁棒性高。Mi 等^[8]运用 ELM 结合离群点剔除法建立预测模型展开风速预测。郑晓芬等^[9]利用改进的核极限学习机(kernel extreme learning machine,简称 KELM)对非平稳脉动风速进行预测,提高了风速预测精度和速度。支持向量机(support vector machine,简称 SVM)在解决小样本、非线性及高维模式识别问题上比神经网络优势突出,目前被成功用于风速风压预测。Li 等^[10]采用 3 种不同的核函数 SVM 模型分别进行非高斯脉动风压的预测,并与 BP 神经网络和广义回归神经网络模型的预测结果进行对比,显示了 SVM 预测模型的优势。迟恩楠等^[11]利用常见核函数进行组合,形成混合核 LSSVM,对 ARMA 模拟风速进行预测,展示了混合核的预测优势。文献^[12]利用小波支持向量机对非高斯风压展开空间预测,发现小波支持向量机的预测精度高。李春祥等^[13]提出混合蚁群和粒子群优化算法以及混合遗

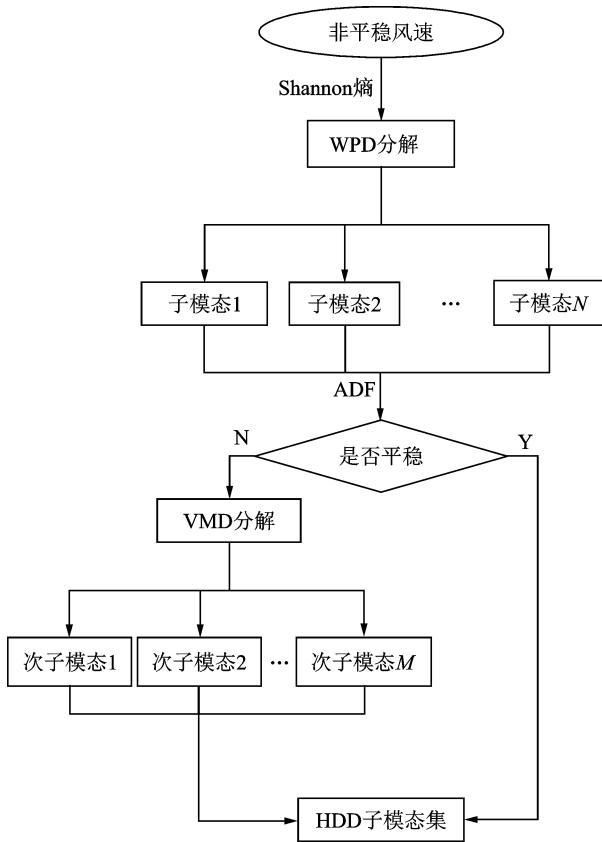
* 国家自然科学基金资助项目(51778354)

收稿日期:2019-06-07;修回日期:2019-08-30

传和粒子群优化的 LSSVM 参数优化算法非高斯脉动风速预测,表明优化算法可以提升预测精度。

分解-组合法是目前应对复杂风速预测最有效的方法。Liu 等^[14]引入小波分解、小波包分解(wavelet packet decomposition,简称 WPD)、经验模态分解(empirical mode decomposition,简称 EMD)、快速集成经验模态分解(fast ensemble empirical mode decomposition,简称 FEEMD)分别组合不同预测模型进行风速预测,取得良好效果。Du 等^[15]采用奇异值分解(singular value decomposition,简称 SVD)开展了多目标优化组合模型,提升风速多步预测有效性和稳定性。Jiang 等^[16]引入改进离散小波变换(discrete wavelet transform,简称 DWT)等分解方法建立实时分解风速预测组合模型。

以上预测模型对结构极端风预测研究较少,而建立的风速风压多步预测模型既能得到抗风分析所需的基本数据,又能为结构健康监测、建筑防风减灾提供丰富、全面的信息。



1 HDD-MH-LSSVM 分解-组合预测模型

1.1 HDD 混合深度分解

为了提高非平稳非高斯过程的预测精度,笔者提出一种综合运用 WPD、样本熵、单位根检验法和 VMD 的混合深度分解方法。在传统 WPD 基础上引入 Shannon 熵准则确定小波包最优分解,初步降低风速的非平稳性,得到多个相对平稳的子模态。为确定子模态平稳性,利用一种常用的单位根检验法——增广迪基夫勒检验法(augmented Dickey-Fuller test,简称 ADF)进行子模态平稳性分析,筛选出非平稳子模态,VMD 用于进一步降低子模态非平稳性,最后得到相应的平稳子模态集合。混合深度分解流程如图 1 所示。具体实现步骤为:

1) 利用 WPD 方法仅对选定样本中的测试集所

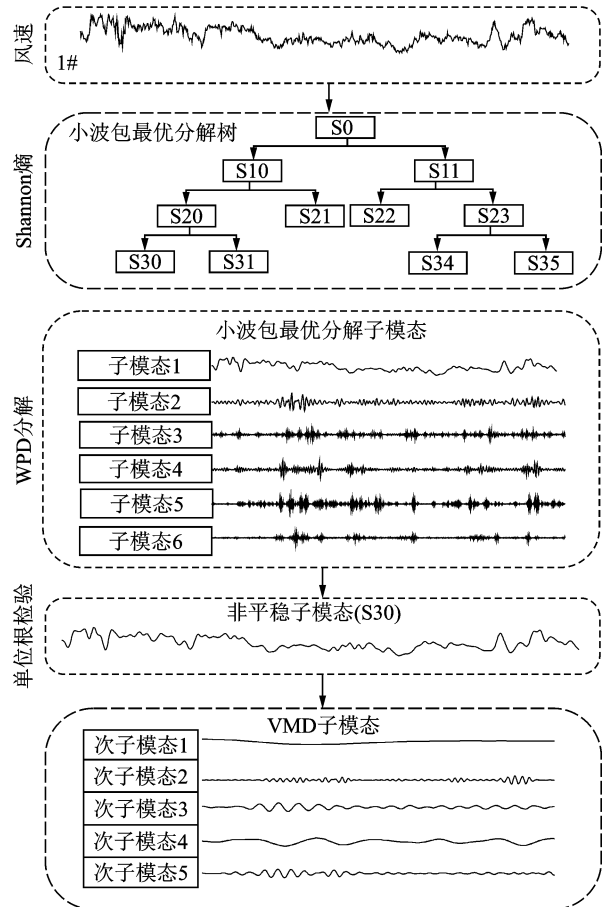


图 1 混合深度分解流程图

Fig. 1 Framework of hybrid deep decomposition

含数据进行 db10 小波 3 层分解,且 Shannon 熵准则确定小波包最优分解树,得到一系列 WPD 最优分解子模态;

2) 利用 ADF 方法对步骤 1 得到的所有子模态进行单位根检验,判断子模态的平稳性;

3) 利用 VMD 方法对筛选出的非平稳子模态

再分解,进一步降低其非平稳性,得到一系列 VMD 次子模态;

4) WPD 平稳子模态和 VMD 次子模态构成混合深度分解的子模态。

1.2 MH-LSSVM 小波混合核支持向量机

LSSVM 的非线性回归函数为

$$f(x) = \sum_{i=1}^l \alpha_i K(x, x_i) + b \quad (1)$$

核函数是 LSSVM 解决实际问题的核心。不同核函数决定了不同的高维特征空间,也决定了不同的支持向量机类型。因此,核函数的选择尤其重要。小波函数具有稀疏变化和尺度性质,可提高模型精度和迭代的收敛速度的同时,还能对存在的局部非平滑样本进行尺度插值。Morlet 小波函数可表示为 $h(x) = \cos(-x^2/2)$,由其生成的 Mercer 平移不变的核函数为

$$K(x, x_i) = \prod_{i=1}^l h\left(\frac{x-x_i}{l}\right) = \prod_{i=1}^l \left[\cos\left(-\frac{x-x_i}{2l^2}\right) \right] \quad (2)$$

Morlet 核函数满足 Mercer 核定理为 LSSVM 的允许核

$$\begin{aligned} K(\omega) &= (2\omega)^{-n/2} \int_{R^N} \exp(-i(\omega x)) K(x) dx = \\ (2\pi)^{-n/2} \int_{R^N} \left\{ \exp(-i(\omega x)) \prod_{i=1}^l \left[\cos\left(-\frac{x-x_i}{2l^2}\right) \right] \right\} dx = \\ (2\pi)^{-n/2} \prod_{i=1}^l \int_{-\infty}^{+\infty} \cos\left(-\frac{x-x_i}{2l^2}\right) \exp(-i(\omega x)) dx \geq 0 \end{aligned} \quad (3)$$

埃尔米特多项式是一组正交的多项式,由其构造的埃尔米特核函数(Hermite 核)在分类问题显示出良好的性能^[17]。Hermite 多项式定义为

$$He_0(x) = (-1)^n e^{\frac{x^2}{2}} \frac{d^n}{dx^n} e^{-\frac{x^2}{2}} \quad (n=0,1,\dots) \quad (4)$$

令权函数 $\omega(x) = e^{\frac{x^2}{2}}$,得到 Hermite 多项式递推式为

$$\begin{cases} He_0(x) = 1 \\ He_1(x) = x \\ He_n(x) = xHe_{n-1}(x) - (n-1)He_{n-1}(x) \end{cases} \quad (5)$$

Hermite 核函数为

$$K(x, x_i) = \sum_{m=0}^n He_m(x) He_m(x_i) \quad (6)$$

Hermite 核函数也满足 Mercer 定理,可作为 LSSVM 允许核

$$\iint K(x, x_i) g(x) g(x_i) dx dx_i =$$

$$\begin{aligned} & \iint \left[\left(\sum_{m=0}^n He_m(x) He_m(x_i) \right) g(x) g(x_i) dx dx_i \right] = \\ & \sum_{m=0}^n \iint \left[He_m(x) He_m(x_i) g(x) g(x_i) dx dx_i \right] = \\ & \sum_{m=0}^n \left[\int He_m(x) g(x) dx \right] \left[\int He_m(x_i) g(x_i) dx_i \right] = \\ & \sum_{m=0}^n \left[\int He_m(x) g(x) dx \right]^2 \geq 0 \end{aligned} \quad (7)$$

根据 Mercer 定理,选用一阶 Hermite 核作为全局核、Morlet 小波核作为局部核,通过线性组合成为 MH 小波混合核函数用于 LSSVM 进行预测, MH 核函数表达式为

$$K_{MH} = (1-\alpha)(1+4(xx_i)) + \alpha \prod_{i=1}^l \left[\cos\left(-\frac{x-x_i}{2l^2}\right) \right] \quad (8)$$

其中: $\alpha \in (0,1)$ 为混合核函数权重。

LSSVM 参数对于预测结果有很大影响,其中正则化参数 γ 控制对样本超出计算误差的惩罚程度,核参数包括核宽度以及混合核中的权重。核宽度控制着函数回归误差,直接影响初始特征值和特征向量,过小会导致过拟合,过大则会导致提前收敛。为了提高预测效果,选用 PSO 进行参数寻优。为了验证所提出的小波混合核 MH 核预测性能,利用 PSO 对传统常用核函数 RBF 核、Poly 核以及 MH 核进行参数寻优,步骤如下。

- 1) 粒子群初始化参数设置:种群规模 $M=20$,最大迭代次数 $Z=150$ 。
- 2) 确定每种核函数表达式及其待优化参数的取值范围,如表 1 所示。

表 1 核函数及其参数取值范围

Tab. 1 Different kernel functions and their parameters		
核函数	公式	参数取值范围
Poly 核	$K(x, x_i) = [(xx_i) + 1]^q$	$q = 1, 2, 3$
RBF 核	$K(x, x_i) = \exp\left[-\frac{(x-x_i)^2}{2\sigma^2}\right]$	$2\sigma^2 \in [0.01, 100]$
MH 核	式(8)	$\alpha \in [0, 1]$ $l \in [0.1, 10]$

3) 定义粒子适应度 $F(x_i)$ 为均方根误差函数,将 $F(x_i)$ 与自身最优解与全局最优比较,以此调整粒子位置。适应度函数为

$$F(x_i) = \sqrt{\frac{1}{n} \sum_{i=1}^n (f_i - y_i)^2} \quad (9)$$

其中: y_i 为第 i 个样本的实测值; f_i 为第 i 个样本的预测值。

4) 更新粒子速度和位置, 获得新参数直到迭代次数达到最大值或适应度满足要求时终止迭代, 得到最优参数。

1.3 HDD-MH-LSSVM 的多步预测流程

结构防风减灾需要获得较长时间的预测值, 可采用滚动策略进行多步预测。滚动多步预测是指在已经进行预测的基础上, 再建立模型, 以预测值作为新的训练样本完成预测。将单步预测值替换测试集输入矩阵对应位置的输入值, 重复一步预测就可以得到超前两步的预测值, 依此类推, 得到超前 N 步预测值。图 2 为预测模型流程图, 多步预测步骤如下。

1) 风速风压样本处理。为降低样本的复杂性, 提升预测精度, 利用所提出的混合深度分解对样本的训练集进行分解处理, 得到多个相对平稳子模态集合。

2) 数据归一化。为避免样本数据中过大或小数对预测精度有干扰, 需对样本进行归一化处理, 使数据分布在 $[0, 1]$ 区间内, 归一化数值为

$$x' = (x - x_{\min}) / (x_{\max} - x_{\min}) \quad (10)$$

其中: x' 为归一化值, 其预测值 y' 对应的实际预测值需反归一化, 即

$$y = (x_{\max} - x_{\min})y' + x_{\min} \quad (11)$$

3) 确定样本训练集和测试集。将分解并归一化得到的子模态分为训练集数据和测试集数据, 分别用于模型训练和模型验证。

4) PSO 优化参数。对样本进行相空间重构, 延时为 1, 嵌入维度为 10, 形成 10 为输入矩阵, 利用核函数映射到特征空间后, 按照流程寻找最优核参数。

5) 建立多步预测模型。利用最优参数构造预测函数 $f(x) = \sum_{i=1}^l \alpha_i \text{best} K(x, x_i) + b$, 输入测试集数据, 得到单步预测值。不断用预测值替换测试集数据, 得到超前多步时刻的模态预测值。

6) 模态预测。重复步骤 3~5, 对每个模态分别进行寻优并预测, 将各步预测值叠加重构并反归一化。

2 预测效果评价标准

为定量评价 HDD-MH-LSSVM 模型预测精度, 采用图形定性评价和指标定量评价两种方式进行综合比较。采用预测风压时程图、功率谱图和自相关函数图定性评价预测效果, 预测曲线越接近真实曲线, 说明预测效果越好。为了更直观表征各模

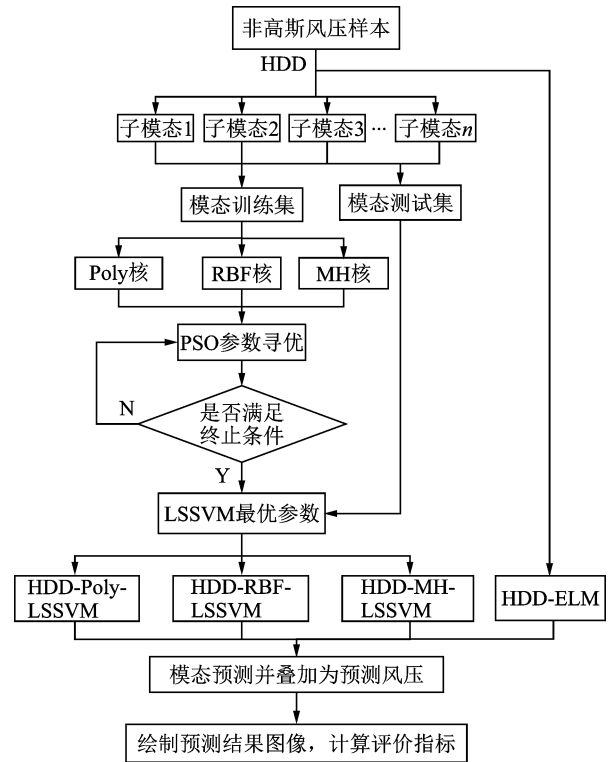


图 2 预测模型流程图

Fig. 2 The flow chart of prediction model

型产生误差的情况, 绘制预测风压相对误差图和误差分布情况。相对误差图是预测值与真实值直接相减产生, 图像越接近水平线, 预测效果越好。误差分布散点情况(如图 4(a) 右上角)是以真实值为纵坐标, 预测值为横坐标, 散点分布越集中于对角线, 预测越准确。采用平均绝对误差(mean absolute error, 简称 MAE)、平均绝对百分比误差(mean absolute percentage error, 简称 MAPE)、均方根误差(root mean square error, 简称 RMSE)和皮尔逊相关系数(Pearson correlation coefficient, 简称 R)定量评价预测精度。其中: MAE, MAPE 及 RMSE 从误差角度评价预测精度, 值越小说明效果越好; R 是从相关性角度评价预测效果, 值越大代表预测效果越好。4 个指标的计算公式分别为

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

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (13)$$

$$\text{MAPE} = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (14)$$

$$R = \left(\sum_{i=1}^N y_i \hat{y}_i \right) / \left(\sqrt{\sum_{i=1}^N y_i^2} \sqrt{\sum_{i=1}^N \hat{y}_i^2} \right) \quad (15)$$

其中: y_i, \hat{y}_i 分别为风速、风压真实值; N 为样本数量。

3 基于实际工程的风速风压预测试验

极端风主要是指诸如台风、下击暴流、龙卷风等非平稳性强、破坏力大的风。图 3 为德州理工大学瑞茜技术中心观测到的全尺度下击暴流风速数据。其采样频率为 1 Hz,总时长为 30 min,提取 10 号测点 500 s 时长的风速作为模型验证样本 1。对某大跨膜结构表面进行台风风压特性研究,其测点及样本如图 4 所示。现有 21 个测点的上下风压传感器监测到的上下膜表面风压数据,其采样频率为 2 Hz,降采样因子取 2(符合奈奎斯特采样定理),提取其中某一测点 500 s 时长的风压作为样本 2。

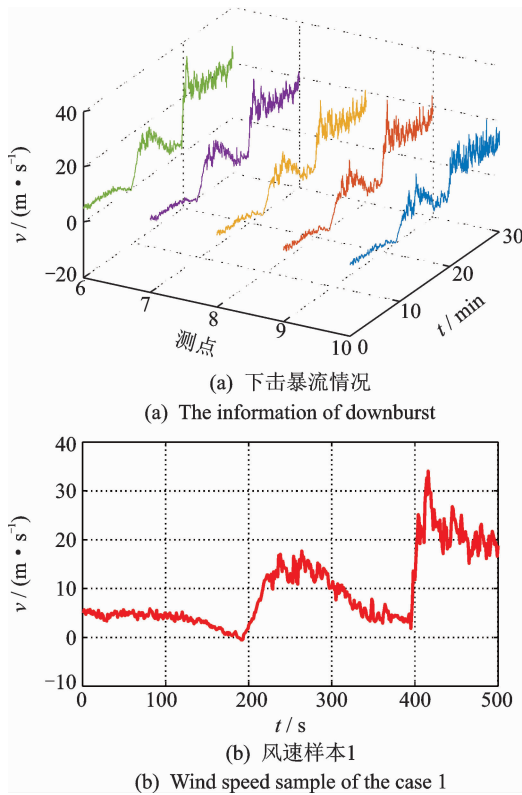



图 3 下击暴流情况及风速样本 1
Fig. 3 The information of downburst and wind speed sample of the case 1

样本非平稳非高斯性检验值如表 2 所示。运用 ADF 进行非平稳性检验,高阶统计矩进行非高斯性检验,如表 2 所示。ADF 假设待检验的时间序列存在单位根,若检验值大于 1%,5%和 10%显著性水平下的 ADF 临界值,则不能拒绝原假设,表明待检验时间序列具有非平稳性。一个随机变量概率分布形式的对称性和陡峭性,分别被称为偏度(SK)和峰度(K)。偏度指概率密度曲线是否相对均值对称,峰度指概率密度曲线是否相对高斯分布更为陡峭或平缓。满足高斯分布的高阶统计矩偏度和峰度分别



(a) 膜结构风压测点

(a) The measure point of long span system




图 4 膜结构风压测点及样本 2

Fig. 4 The measure point of long span system and wind speed sample of the case 2

为 $SK=3, K=0$ 。


表 2 样本非平稳非高斯性检验值

Tab. 2 The non-stationary and non-gaussian test values of samples

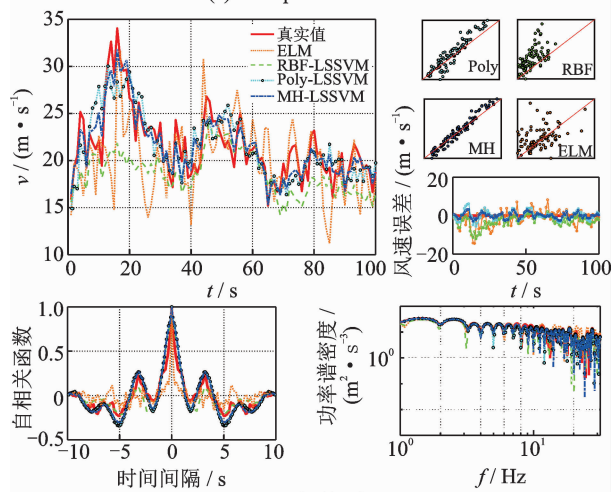
样本	非平稳性检验值		非高斯性检验值	
	t	p	SK	K
1	-0.562 4	0.473 6	-0.970 6	6.174 9
2	-0.634 8	0.442 1	1.902 2	6.204 8

从表 2 可以看出,两样本检验值 t 均大于临界值,且 p 值说明在显著性水平分别为 47.36%和 44.21%时,才可以拒绝原假设,因此样本具有强烈的非平稳性;且两者高阶统计矩偏度 $SK > 3$,峰度 $K \neq 0$,呈现非高斯性。可见,样本 1,2 属于非平稳非高斯过程,可作为验证预测模型的样本。取样本前 1~400 s 作为训练集进行信号分解及模型训练,后 401~500 s 作为测试集进行验证。同时,PSO-ELM 方法被用于对比说明不同预测方法的有效性:利用 PSO 优化 ELM 参数,将经过不分解技术的训练集数据进行相空间重构,形成输入矩阵训练 ELM 模型,测试集数据进行预测验证。利用 4 种预测模型对样本 1,2 进行预测验证,如图 5,6 所示,预测评价指标如表 3,4 所示。


从图 4,5 看到, LSSVM 模型比 ELM 模型的预测风压与真实风压更接近,且预测风压相对误差



(a) 超前6步
(a) 6-step ahead in case 1



(b) 超前8步
(b) 8-step ahead in case 1

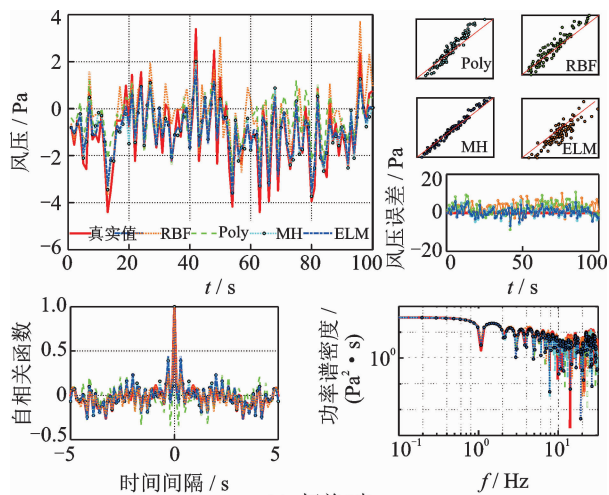


(c) 超前10步
(c) 10-step ahead in case 1


图5 样本1 预测结果对比

Fig. 5 The comparison diagram of prediction results in case 1


波动小,误差散点集中。ELM的MAE误差小,但RMSE和RMSE误差较大,相关性R最低,且幅值出现“尖点”表明ELM会产生一定过拟合,因此总体误差大于LSSVM。LSSVM不同模型中,随着预



(a) 超前6步
(a) 6-step ahead in case 2



(b) 超前8步
(b) 8-step ahead in case 2



(c) 超前10步
(c) 10-step ahead in case 2

图6 样本2 预测结果对比

Fig. 6 The comparison diagram of prediction results in case 2

测步数不断增大,RBF核预测效果最差,预测风速风压曲线与真实值差距越来越大,相对误差波动剧烈且误差散点图无法集中。主要原因是样本非平稳

非高斯性表现为曲线幅值脉冲性、波动性,RBF 核在脉动性强的极值处陷于局部最优解,导致预测值与实际值有偏差,产生了欠拟合。Poly 预测性能较 RBF 有所提升,时程曲线与真实值较为接近,相对误差波动幅度较低,误差散点分布较集中。Poly 核是全局核有较好外推泛化能力,但局部学习能力较差,在训练集中对样本极值拟合能力低。相较于 RBF 和 Poly 核,MH 核的预测模型在 6 步、8 步及 10 步的大步数预测中得到风速风压曲线与真实曲线最吻合,曲线极值预测效果较好,表现出非平稳非高斯过程的复杂性。当步数增加时,相对误差波动不明显,误差散点分布集中程度高。功率谱在低频和高频段更贴近真实值,更好地反映风压能量分布。MH 核利用小波函数具有稀疏变化和尺度分析能力,在不够平滑的脉冲极值处,可以尺度插值,利用稀疏变化的核矩阵拟合极值,且 Hermite 作为全局

表 3 样本 1 预测评价指标

Tab. 3 The evaluation index of prediction for case 1

评价指标	预测模型				
	ELM	Poly	RBF	MH	
MAE	6 步	0.160 0	0.344 2	0.454 9	0.248 2
	8 步	0.377 3	0.564 4	0.595 9	0.426 6
	10 步	0.608 4	0.678 0	0.777 6	0.523 3
MAPE	6 步	0.056 2	0.057 7	0.069 7	0.041 1
	8 步	0.099 6	0.067 9	0.086 9	0.047 9
	10 步	0.149 3	0.075 3	0.113 6	0.053 7
RMSE	6 步	0.532 5	0.586 6	0.585 2	0.416 7
	8 步	0.967 2	0.727 3	0.692 1	0.470 7
	10 步	1.443 9	0.964 1	0.727 2	0.525 4
R	6 步	0.968 2	0.997 8	0.974 8	0.998 7
	8 步	0.964 6	0.998 5	0.965 0	0.998 4
	10 步	0.952 5	0.997 3	0.961 5	0.998 0

表 4 样本 2 预测评价指标

Tab. 4 The evaluation index of prediction for case 2

评价指标	预测模型				
	ELM	Poly	RBF	MH	
MAE	6 步	0.566 7	0.319 3	0.355 4	0.266 5
	8 步	0.575 8	0.322 5	0.383 9	0.291 9
	10 步	0.591 5	0.341 4	0.386 0	0.314 9
MAPE	6 步	0.094 1	0.081 9	0.109 9	0.050 4
	8 步	0.136 0	0.085 6	0.113 1	0.054 2
	10 步	0.167 6	0.088 5	0.146 0	0.059 0
RMSE	6 步	2.665 7	2.218 9	3.676 0	1.307 1
	8 步	4.223 5	2.335 9	4.088 0	1.469 5
	10 步	4.767 8	2.360 1	4.449 6	1.562 4
R	6 步	0.992 6	0.993 5	0.994 8	0.998 2
	8 步	0.982 2	0.991 3	0.994 3	0.997 7
	10 步	0.976 1	0.989 2	0.994 2	0.997 5

核能在特征空间全面学习,把握风速风压整体趋势,在测试集中表现出较高的预测精度。

表 3,4 中,RBF 预测精度较差,Poly 各步数 MAE,MAPE 和 RMSE 较 RBF 有所降低,但较 MH 仍有差距。以样本 2 的 10 步预测为例,计算 MH 核相较其他核模型 MAE,MAPE 和 RMSE 误差下降率,如表 5 所示,进一步证明了该模型的预测性能优越。

表 5 样本 2 的 10 步预测误差指标下降率

Tab. 5 The decrease rate of error index for case 2 in 10-step

评价指标	%		
	MHvs. ELM	MHvs. Poly	MHvs. RBF
MAE	7.51	12.88	19.54
MAPE	47.11	16.74	35.82
RMSE	46.64	29.45	16.11

4 结 论

1) 基于混合深度分解的 HDD-MH-LSSVM 方法对于非平稳非高斯过程的预测行之有效,在大步数多步预测中均取得良好效果,混合深度分解提升了复杂时序的可预测性。

2) 基于 Morlet 核与 Hermite 核的 MH 小波混合核预测模型是一种稳定高精度模型,在不同样本、不同步数的预测结果均优于常用核预测模型,非线性映射能力强,具有较高的工程应用价值。

致谢 本研究样本 1 风速数据来源于德州理工大学,样本 2 风压数据来源于上海师范大学张志宏教授,在此表示衷心感谢!

参 考 文 献

[1] 焦英立,刘记军. 沿海重要区域建筑结构防台风灾害综合技术措施研究[J]. 建筑结构, 2009(S2): 249-251.
JIAO Yingli, LIU Jijun. Synthetical technology research of defending typhoon disaster on building structure in coastal important region[J]. Building Structure, 2009(S2): 249-251. (in Chinese)

[2] LI Z, LI C X. Non-Gaussian non-stationary wind pressure forecasting based on the improved empirical wavelet transform[J]. Journal of Wind Engineering and Industrial Aerodynamics, 2018, 179: 541-557.

[3] 李春祥,张佳丽. 传感器故障后多变量经验小波变换多点预测[J]. 振动、测试与诊断, 2019, 39(1): 197-208.
LI Chunxiang, ZHANG Jiali. Multivariable empirical

- wavelet transform for multipoint forecasting after sensor fault[J]. *Journal of Vibration, Measurement & Diagnosis*, 2019, 39(1): 197-208. (in Chinese)
- [4] YU C J, LI Y L, XIANG H Y, et al. Data mining-assisted short-term wind speed forecasting by wavelet packet decomposition and Elman neural network[J]. *Journal of Wind Engineering and Industrial Aerodynamics*, 2018, 175: 136-143.
- [5] SONG J J, WANG J Z, LU H Y. A novel combined model based on advanced optimization algorithm for short-term wind speed forecasting[J]. *Applied Energy*, 2018, 215: 643-658.
- [6] WANG Y Y, WANG J Z, ZHAO G, et al. Application of residual modification approach in seasonal ARIMA for electricity demand forecasting: a case study of China[J]. *Energy Policy*, 2012, 48: 284-294.
- [7] LIU H, TIAN H Q, LI Y F. Comparison of two new ARIMA-ANN and ARIMA-Kalman hybrid methods for wind speed prediction[J]. *Applied Energy*, 2012, 98: 415-424.
- [8] MI X W, LIU H, LI Y F. Wind speed forecasting method using wavelet, extreme learning machine and outlier correction algorithm[J]. *Energy Conversion and Management*, 2017, 151: 709-722.
- [9] 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 Xiaofen, ZHONG Wang, LI Chunxiang. 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)
- [10] LI C X, LI J H. Support vector machines approach to conditional simulation of non-Gaussian stochastic process[J]. *Journal of Computing in Civil Engineering*, 2012, 26(1): 131-140.
- [11] 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 Ennan, LI Chunxiang, ZHENG Xiaofen. Forecasting non-Gaussian spatial along-wind pressure using wavelet kernel and multiplicative mixed kernel functions based LSSVM[J]. *Journal of Computing in Civil Engineering*, 2017, 36(9): 116-121. (in Chinese)
- [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 Chunxiang, YING Xiao. 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] 李春祥, 丁晓达, 郑晓芬. 基于混合智能优化 LSSVM 的非高斯脉动风速预测[J]. *振动与冲击*, 2017, 36(20): 52-58.
LI Chunxiang, DING Xiaoda, ZHENG Xiaofen. Predicting non-Gaussian wind velocity using hybridizing intelligent optimization based LSSVM[J]. *Journal of Vibration and Shock*, 2017, 36(20): 52-58. (in Chinese)
- [14] LIU H, TIAN H Q, LI Y F. Four wind speed multi-step forecasting models using extreme learning machines and signal decomposing algorithms[J]. *Energy Conversion & Management*, 2015, 100:16-22.
- [15] DU P, WANG J Z, YANG W D, et al. Multi-step ahead forecasting in electrical power system using a hybrid forecasting system[J]. *Renewable Energy*, 2018, 122: 533-550.
- [16] JIANG Y, HUANG G Q, PENG X Y, et al. A novel wind speed prediction method: Hybrid of correlation-aided DWT, LSSVM and GARCH[J]. *Journal of Wind Engineering & Industrial Aerodynamics*, 2018, 174: 28-38.
- [17] MOGHADDAM V, HAMIDZADEH J. New hermite orthogonal polynomial kernel and combined kernels in support vector machine classifier[J]. *Pattern Recognition*, 2016, 60: 921-935.



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《传感器故障后多变量经验小波变换多点预测》(《振动、测试与诊断》2019年第39卷第1期)等论文。

E-mail: li-chunxiang@vip.sina.com

