

基于 VMD-BA-LSTM 的短期风向预测研究^①

林 涛^② 王建君^③ 张 达

(河北工业大学人工智能与数据科学学院 天津 300130)

摘 要 准确的风电场风向预测对制定偏航控制策略、提高发电量及风电机组稳定运行具有重要意义。针对风向的随机性和不确定性的特点,提出一种变分模态分解(VMD)和蝙蝠算法(BA)优化长短期记忆(LSTM)神经网络的短期风向预测模型。首先,采用变分模态分解将原始序列分解为多个有限带宽的特征模态分量以降低原始数据的复杂度和非平稳性对预测精度的影响,然后将各分量分别建立 BA-LSTM 模型进行预测,最后将各分量预测结果叠加得到风向值,结合河北某风场的实测数据进行多时间尺度的风向预测。实验结果表明,本文所提方法相比于 LSTM 和最小二乘支持向量机(LSSVM)预测方法提高了预测精度,对后续研究偏航系统的最优调节提供了支持。

关键词 风向预测;变分模态分解;蝙蝠算法(BA);长短期记忆(LSTM)神经网络;多时间尺度

0 引 言

在世界能源日渐匮乏的大背景下,为了解决能源短缺问题和能源开发利用所引起的一系列环境问题,开发风力发电成了一种行之有效的选择^[1]。在风力发电中,偏航系统是风电机组的重要组成部分,它是风电机组快速高效地完成对风操作、减少风电机组功率损失的执行机构^[2]。由于风向本身的不稳定性,当风电机组正常发电时,偏航系统随着风向的不断变化而频繁启停以进行迎风控制,会减少偏航系统的使用寿命。目前,解决这一问题的研究方向是对未来风速和风向的掌控,通过预测风速和风向提升一定的对风精度,使偏航次数在没有明显增加的情况下尽可能创造更多的价值。因此,准确地预测风向对研究风电场偏航系统控制策略具有重要的指导意义。

目前,国内外学者针对偏航控制系统做了大量研究并提出很多方法。文献[3]利用 BP(back prop-

agation)神经网络的训练速度较快、学习速率快、泛化能力强的优点对风向进行预测,对偏航系统执行动作前做出预判。文献[4]采用将 ARIMA (autoregressive integrated moving average)模型集成到卡尔曼滤波器(Kalman filtering, KF)中的混合模型来对风向进行预测,相比于采用单变量 ARIMA 模型,提高了预测精度。文献[5]采用经验小波变换对风速数据进行分解,针对每个分量构建核极限学习机模型,叠加各个分量得到预测值,提高了预测精度。文献[6]提出了基于遗传算法(genetic algorithm, GA)优化加权最小二乘支持向量机(weighting least square support vector machine, WLSSVM)的短期风速预测模型。该模型以风电场实测数据作为模型的输入向量,根据遗传算法对加权最小二乘支持向量机的惩罚参数和核函数参数寻找最优解,建立起参数最优的风速预测模型。以上的风电场短期预测方法都在传统方法的基础上做了改进,虽然这些模型实现了风向预测,但是对于数据量大、预测误差等问题

① 河北省重点研发计划(20314501D,19214501D)和河北省科技计划(17214304D)资助项目。
 ② 男,1970 年生,博士,教授;研究方向:物联网,风电技术;E-mail: 15032525908@163.com
 ③ 通信作者,E-mail: 15032525908@163.com
 (收稿日期:2020-08-18)

不能满足需求,而深度学习的神经网络在这方面表现出了很好的优势。文献[7]提出一种结合卷积神经网络(convolutional neural network,CNN)和门控循环单元(gated recurrent unit,GRU)的短期风电预测模型,采用结合 CNN 和 GRU 网络对多变量时间序列进行动态时间建模,引入 CNN 来压缩 GRU 隐藏状态以减少计算模型的输出,克服训练过程中的梯度爆炸和消失问题,但 CNN 池化层会丢失大量有价值信息,对于时序序列不能准确预测。文献[8]针对时间序列不稳定导致难以准确预测的问题,采用变分模态分解(variational mode decomposition,VMD)分解原始时间序列,得到相对稳定的时间序列,降低了原始序列的不稳定性。文献[9]提出了一种基于长短期记忆(long short-term memory,LSTM)深度神经网络的短期风速预测方法,通过和其他预测方法预测结果进行对比,预测平均绝对误差最小,但 LSTM 的各项超参数难以确定,如时间步长、隐藏层单元个数等。单一的预测不能表现出很好的优势,为了提高预测精度,通过把各种模型的优点组合成混合预测模型越来越受到欢迎。

针对风向的随机性以及强相关性的特征,本文提出了一种基于变分模态分解和蝙蝠算法(bat algorithm,BA)的长短期记忆神经网络的短期预测方法。在该算法中,首先对经过处理的风向数据在不同频域尺度上进行变分模态分解,然后用蝙蝠算法优化 LSTM 的时间窗步长(look_back, lb),隐藏层个数(num_units, nu)、学习率(learning rate, lr)和训练次数(epochs, ep)。最后,利用分解得到的固有模态分量(inherent modal function, IMF)分别建立短期风向预测模型,对子模型的预测值进行求和运算,得到的结果作为最终的预测值。实验采用河北某风场 SCADA 数据,对不同时间尺度的风向进行预测,验证了该模型的有效性。

1 变分模态分解

1.1 变分模态分解的步骤

VMD 包括约束变分模型、拉格朗日变换和交替更新 3 个主要步骤。

利用 VMD 算法将原始信号序列分解为一系列有限带宽模态函数 $u_k(t)$, 每个模态分量具有不同中心频率的有限带宽, 将分解的各模态函数解调到相应的基频带, 最终达到每个模态估计带宽之和最小的目的^[10]。为计算出各个模态函数的带宽, 对应的约束问题变为

$$\begin{cases} \min_{\{u_k\}, \{w_k\}} \left\{ \sum_{k=1}^k \left\| \partial_t \left(\left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) \right) e^{-jw_k t} \right\|^2 \right\} \\ \text{s. t.} \quad \sum_{k=1}^k u_k(t) = f \end{cases} \quad (1)$$

式中, $\{u_k\} = \{u_1, \dots, u_k\}$ 为分解得到的 k 个模态函数分量; $\{w_k\} = \{w_1, \dots, w_k\}$ 为各模态函数的中心频率; $\delta(t)$ 为单位脉冲信号。

为解决目标函数约束最优化问题, 引入二次惩罚项 α 和拉格朗日函数 λ , 将其转化为非约束变分问题:

$$\begin{aligned} L(\{u_k\}, \{w_k\}, \lambda) = & \alpha \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) \right] e^{-jw_k t} \right\|^2_2 \\ & + \left\| f(t) - \sum_k u_k(t) \right\|^2_2 \\ & + \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle \end{aligned} \quad (2)$$

利用交替方向乘积算子计算, 不断交替更新 u_k^{n+1} 、 w_k^{n+1} 和 λ^{n+1} 求拉格朗日增矩矩阵表达式的鞍点, 可求得固有模态的解:

$$\hat{u}_k^{n+1}(w) = \frac{\hat{f}(w) - \sum_{g=1}^k \hat{u}_g(w) + \frac{\hat{\lambda}(w)}{2}}{1 + 2\alpha(w - w_k)^2} \quad (3)$$

及中心频率的解:

$$w_k^{n+1} = \frac{\int_0^\infty w \left| \hat{u}_k^{n+1}(w) \right|^2 dw}{\int_0^\infty \left| \hat{u}_k^{n+1}(w) \right|^2 dw} \quad (4)$$

式中, $\hat{u}_k^{n+1}(w)$ 为剩余分量的维纳滤波, w_k^{n+1} 为当前模态函数的中心频率, 对 $\hat{u}_k(w)$ 进行傅里叶变化, 模态的时域分量取实部为 $u_k(t)$ 。

1.2 变分模态分解算法流程

VMD 算法的完整步骤如下。

(1) 初始化 $\hat{u}_k^1, \hat{w}_k^1, \hat{\lambda}^1$ 。

(2) 按照式(3)和式(4)更新 $\hat{u}_k^{n+1}(w)$ 和 w_k^{n+1} 。

(3) 按照式(5)对拉格朗日函数 λ 调整。

$$\hat{\lambda}^{n+1}(w) \leftarrow \hat{\lambda}^n(w) + \tau(\hat{f}(w) - \sum_k \hat{u}_k^{n+1}(w)) \quad (5)$$

式中 τ 为更新参数。

(4) 直到满足式(6),迭代结束,输出模态子序列;否则回到步骤 2。

$$\sum_k \|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2 / \|\hat{u}_k^n\|_2^2 < \varepsilon \quad (6)$$

由此得到分解后的风向 k 个子序列,其模态函数为 u_k , 中心频率为 w_k 。

2 蝙蝠算法-长短期记忆神经网络

采用蝙蝠算法确定长短期记忆神经网络的预测参数,结合蝙蝠算法具有很好的收敛性的同时,保留了长短期记忆神经网络在分类和预测上的优点,使风向的预测精度得到了很大的提高。

2.1 长短期记忆神经网络

LSTM 是循环神经网络(recurrent neural network, RNN)的一种改进算法^[11]。传统的 RNN 随着训练深度的增加会出现梯度消失或膨胀问题,无法适应于深度学习的神经网络或长时序序列的学习与训练^[12]。长短期记忆神经网络为了解决这些问题应运而生。LSTM 是由多个单元格(Cell)组成,如图 1所示为 LSTM 结构单元格,每个单元格由遗忘门(forget gate)、输入门(input gate)、输出门(output gate)和一个记忆单元(cell)4个主要元素构成。3个

门的 sigmoid 激活函数的取值范围为(0,1),这 3 个门的作用相当于对历史输入、当前输入和历史输出进行加权学习,进而达到对历史输入、历史输出的记忆功能^[13]。LSTM 单元格 t 时刻计算过程如下。

输入门的值:

$$I_t = \sigma(W_i \cdot [h_{t-1}, z_t] + b_i) \quad (7)$$

式中, h_{t-1} 为上一时刻 LSTM 单元格输出的风向值, z_t 为当前时刻输入风向值, W_i 为前两项的细胞单元输出对输入门的连接权值; b_i 为输入门的偏置。

遗忘门的值为

$$F_t = \sigma(W_f \cdot [h_{t-1}, z_t] + b_f) \quad (8)$$

式中, W_f 为前两项的细胞单元输出对遗忘门的连接权值; b_f 为遗忘门的偏置。

候选记忆单元状态值为

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, z_t] + b_c) \quad (9)$$

式中, W_c 为前两项的细胞单元输出之间连接权值; b_c 为遗忘门的偏置。

当前记忆单元状态值为

$$C_t = F_t \times C_{t-1} + I_t \times \tilde{C}_t \quad (10)$$

输出门的值为

$$O_t = \sigma(W_o \cdot [h_{t-1}, z_t] + b_o) \quad (11)$$

式中, W_o 为前两项的细胞单元输出对输出门的连接权值; b_o 为遗忘门的偏置。

最后得到 LSTM 单元格在 t 时刻的输出为

$$h_t = O_t \times \tanh(C_t) \quad (12)$$

LSTM 神经网络以反向传播方式进行训练,根据式(7)~(12)计算 LSTM 细胞的输出值,从时间层和网络层两个方向反向计算 LSTM 的误差项,通过误差项的值计算出权重,进而计算得到对应的梯度,通过随机梯度下降找到全局最优解。LSTM 模型预测精度虽然比较高,但时间窗步长、隐藏层单元个数、学习率和训练次数的设定也会影响准确度,采用优化算法进行寻优可以很好地解决这一问题。

2.2 蝙蝠算法

蝙蝠算法是一种新兴的优化算法,通过模拟蝙蝠的脉冲回声来搜寻目标的具体位置进行建模,该模型在全局搜索和局部搜索中表现出相比于传统智能算法在性能上的优势。同时,蝙蝠算法通过与遗传算法和粒子群算法在准确性和有效性方面的对比




图 1 LSTM 记忆单元结构图

分析,表明蝙蝠算法均优于这两种算法^[14-15]。在模拟蝙蝠算法过程中,假设蝙蝠算法的搜索空间为 d 维,那么在下一时刻更新的公式为

$$v_m^t = v_m^{t-1} + (x_m^t - x_{best})l_m \tag{13}$$

$$l_m = l_{min} + (l_{max} - l_{min})\xi \tag{14}$$

$$x_m^t = x_m^{t-1} + v_m^t \tag{15}$$

上述公式描述的是蝙蝠算法全局搜索过程,其中 v_m^t 和 x_m^t 分别表示在 t 时刻搜索空间中第 m 只蝙蝠的位置和速度, l_i 表示第 m 只蝙蝠算法发出的频率, x_{best} 表示当前全局最优解, l_{max} 和 l_{min} 表示蝙蝠算法发出频率的最大值和最小值, $\xi \in [0,1]$ 的随机数。

若 $Rand > r$, 适应度最好的蝙蝠按照式(16)生成局部解。

$$x_{new} = x_{old} + \psi A^t \tag{16}$$

其中, ψ 属于 $[-1,1]$ 的随机数, x_{old} 代表了从当前最优解中随机选取的一个; A^t 代表了蝙蝠种群响度的平均值。

蝙蝠算法在觅食过程中,随着与猎物的靠近,响度 A 会逐渐下降,脉冲频率 R 会不断上升,第 i 只蝙蝠算法的 A_i 和 R_i 更新公式如下,其中 $0 < k < 1$, 是声波响度衰减函数。

随机生成 $Rand$, 假如 $Rand < A_i$, 同时满足 $l(x_i) < l(x_{best})$, 产生的新解需要按下式更新。

$$A_i^{t+1} = nA_i^t \tag{17}$$

$$r_i^{t+1} = r_i^0 [1 - e^{-\gamma t}] \tag{18}$$

其中, $\gamma > 0$ 是脉冲频率增强系数, r_i^0 表示蝙蝠 i 初始频率,且均为常数。可以看到,当 $t \rightarrow \infty$ 时, $A_i^t \rightarrow 0$, $r_i^t \rightarrow r_i^0$ 。

3 基于 VMD-BA-LSTM 的风向预测方法

3.1 实验方法

风向作为一种时间序列,具有复杂的不确定性、非线性和不稳定性。为了准确地预测风向,采用变分模态分解方法把风向分解为不同频率尺度上的平稳的模态分量。由于 LSTM 的网络结构的某些超参数对网络的性能影响较大,无法准确获得这些参数。为了使得模型网络结构和风向数据相匹配,本文将利用 BA 优化 LSTM 的时间窗步长、隐藏层单元个数、学习率和训练次数得到的最优参数值来构建 BA-LSTM 神经网络模型。用构建的模型分别对 IMF 分量进行预测,然后把预测得到的风向值叠加得到预测结果,相比于直接预测,可以有效提高预测精度。本文所提模型流程图如图 2 所示,具体步骤如下。

步骤 1 对预处理后的风向时间序列进行变分模态分解,将分解好的实验数据进行归一化处理,并划分为训练集和测试集。

步骤 2 将 LSTM 网络模型中时间窗步长、隐藏层单元个数、学习率和训练次数作为优化对象,并初始化 BA 算法的参数(蝙蝠数量、增加系数、衰减系




图 2 BA-LSTM 的流程图

数、最大迭代次数和搜索精度等)。

步骤 3 设置蝙蝠的位置和速度。

步骤 4 计算每个蝙蝠的适应度值。通过式(19)作为蝙蝠的适应度值。

步骤 5 找出全部蝙蝠适应度值最好的一个,对蝙蝠进行速度和位置更新。

步骤 6 重复式(13)~(18),直到符合设定的最优解要求结束,输出模型参数到 LSTM。

步骤 7 利用最优的时间窗步长、隐藏层单元个数、学习率和训练次数构建 LSTM 网络模型。

步骤 8 模型通过训练数进行训练,测试集进行预测,得到预测结果。

步骤 9 对子序列测试集得到的预测结果进行叠加得到最终预测结果。

3.2 误差评价指标

实验中采用平均绝对百分比误差(mean absolute percentage error, MAPE)、均方根误差(root mean square error, RMSE)、平均绝对误差(mean absolute error, MAE)作为指标判断预测效果,即:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_{true} - y_{pre}}{y_{true}} \right| \quad (19)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_{true} - y_{pre})^2} \quad (20)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_{true} - y_{pre}| \quad (21)$$

式中, y_{true} 为测试样本中输出的实际测量值, y_{pre} 为测试样本中预测值, n 为测试样本中的样本数。

4 实验分析

本文选取河北某风场从 2018 年 8 月 16 日到 10 月 2 日每 5 min 间隔的 13 742 个实测风向数据作为样本,选择风向作为输入。首先用变分模态分解方法把风向数据分解为 4 组不同频率尺度的子序列,如图 3 所示,子序列 1 为趋势分量,反映了风向序列的总体变化趋势。子序列 2~4 为波动分量,反映了曲线的随机波动细节。分解的序列与原始序列相比在平稳性和平滑性方面表现更好,相似的细节信息更集中,对下一步的准确预测奠定了基础。




图 3 原始风向序列变分模态分解

BA-LSTM 模型由输入层、隐藏层和输出层组成。该模型将时间窗步长、隐藏层单元个数、学习率和训练次数设置为 LSTM 的超参数,结合多次实验测试,对超参数的取值范围如下,指定时间窗口大小取值范围[1, 20],隐藏层单元个数取值范围[10, 40],学习率取值范围[0.01, 0.045],训练次数取值范围[10, 500]。同时设置 BA 的种群大小为 20,最小频率 l_{min} 和最大频率 l_{max} 分别取 0 和 100,响度 A 取 1,速率 r 取[0, 1]内的随机数。图 4 为归一化适应度值收敛曲线,从图中可以看出,需要迭代 340 次才能达到最优,迭代时间为 806 s。表 1 为通过 BA 算法求出的子序列 LSTM 的网络超参数,把得到的子序列预测值叠加得到最后预测结果。

为了验证本文所提模型性能,并与进行变分模态分解的 LSTM 模型、LSTM 模型和最小支持向量机(least square support vector machine, LSSVM)模型进行对比,各模型测试结果如图 5 所示,同时表 2 给出了各个预测模型的预测误差指标。从实验结果中可以看出, VMD-BA-LSTM 预测的各项指标均优于对比模型。采用 LSTM 预测模型的绝对百分比误差小于 LSSVM 预测方法,证明了 LSTM 神经网络在风电场风向预测方面相比于 LSSVM 具有更好的预测效果,而变分模态分解也可以提高预测精度。




图 4 适应度值的收敛曲线

表 1 子序列分量预测参数表

分量	时间窗	隐藏层单元数	学习率	训练次数
IMF1	5	18	0.016	325
IMF2	7	15	0.022	210
IMF3	8	13	0.027	120
IMF4	6	10	0.035	85




图 5 提前 5 min 风向预测结果

表 2 风向预测性能对比

	MAPE/%	RMSE	MAE/°
LSSVM	2.384	6.237	3.615
LSTM	2.152	5.342	3.271
VMD-LSTM	1.937	5.215	3.053
VMD-BA-LSTM	1.845	4.723	2.651

图 6 和图 7 展示了不同时间尺度的预测结果,在不同时间尺度情况下,通过构建 VMD-BA-LSTM

模型本文所提模型均能准确预测,并与其他算法进行对比,也验证了所提模型的泛化能力。误差指标如表 3 所示,可见随着时间尺度的增加,预测误差虽有增加,但本文所提模型均能准确预测各时间尺度。




图 6 提前 15 min 风向预测结果




图 7 提前 30 min 风向预测结果

表 3 风向预测性能对比

预测时间尺度	MAPE/%	RMSE	MAE/°
15 min	2.351	4.954	2.832
30 min	3.153	5.451	3.725

5 结 论

随着风电场风机越来越多,传统的风机偏航系统会制定同一种控制策略,然而不同风场偏航控制策略不一定适用。当机舱轴线和风向的夹角超过偏航阈值时进行风向预测,让偏航的机舱轴线正对下

一时刻风向,可以在发电量不降低的同时减少偏航次数。为了设计符合本地区偏航控制系统,需要建立准确的预测风向。针对这一问题,提出了基于变分模态分解和蝙蝠优化 LSTM 神经网络的风电场风向预测方法,分别以 5 min、15 min、30 min 为时间尺度进行风向预测,结合实测数据进行对比研究得到以下结论。

(1)VMD 分解将原始序列分解为相对稳定的 IMF 分量,可以降低风向非线性、非平稳性及随机性特征对预测准确性的难度,增强时间序列的可预报性。

(2)相比于 VMD-LSTM,采用 BA 优化 LSTM 的时间窗步长、隐藏层单元个数、学习率和训练次数得到的最优参数值来构建 BA-LSTM 神经网络模型,预测精度得到了提高。

(3)风向数据具有强相关性、不稳定性等特点,设计一种 VMD-BA-LSTM 算法对风向准确预测,通过对不同时间尺度的风向预测,证明了模型的预测准确性,具有良好的泛化能力。

参考文献

- [1] 王维,王剑峰. 风力发电的现状与发展分析[J]. 黑龙江科技信息, 2014(36):22
- [2] Salem A A, Abu-Siada A, Islam S. Condition monitoring techniques of the wind turbines gearbox and rotor[J]. *International Journal of Electrical Energy*, 2013, 2(1):

- 53-56
- [3] 张东东,崔新维. BP 神经网络在风力发电机风向预测中的应用[J]. 太阳能, 2015(3):47-49
- [4] Lynch C, Omahony M J, Scully T. Simplified method to derive the Kalman filter covariance matrices to predict wind speeds from a NWP model[J]. *Energy Procedia*, 2014, 62:676-685
- [5] 卓泽赢,曹茜,李青. 基于 EWT-KELM 方法的短期风电功率组合预测[J]. 电测与仪表, 2019, 56(2):83-89
- [6] 梁涛,孙天一,邹继行,等. 基于 GA 优化的加权 LSSVM 短期风速预测[J]. 高技术通讯, 2019, 29(2):142-148
- [7] 薛阳,王琳,王舒,等. 一种结合 CNN 和 GRU 网络的超短期风电预测模型[J]. 可再生能源, 2019, 37(3):456-462
- [8] 吴小涛,严世伦. 基于相关性的最优变分模态分解算法[J]. 黄冈师范学院学报, 2019, 39(3):6-10
- [9] 李冰,张妍,刘石. 基于 LSTM 的短期风速预测研究[J]. 计算机仿真, 2018, 35(11):456-461
- [10] Dragomiretskiy K, Zosso D. Variational mode decomposition[J]. *Transaction on Signal Processing*, 2014, 62(3):531-544
- [11] 王刚,武毅,王梓,等. 基于大数据技术的电力系统谐波分析及治理方案[J]. 电力系统及其自动化学报, 2016, 28(S1):46-50
- [12] 林涛,赵参参,赵成林,等. 计及频率分析的风电场短期功率预测[J]. 计算机仿真, 2020, 37(6):81-84
- [13] 唐振浩,赵赓楠,曹生现,等. 基于 SWLSTM 算法的超短期风向预测[J]. 中国电机工程学报, 2019, 39(15):4459-4468
- [14] 李枝勇,马良,张惠珍. 蝙蝠算法收敛性分析[J]. 数学的实践与认识, 2013, 43(12):182-190
- [15] Khan K, Sahai A. A Comparison of BA, GA, PSO, BP and LM for training feed forward neural networks in e-learning context[J]. *International Journal of Intelligent Systems and Applications*, 2012, 4(7):23-29

Short-term wind direction prediction research based on VMD-BA-LSTM

Lin Tao, Wang Jianjun, Zhang Da

(School of Artificial Intelligence, Hebei University of Technology, Tianjin 300130)

Abstract

Accurate wind farms wind direction prediction is important for evaluating yaw control strategies, improving electric energy production capacity and steady operation of wind turbines. According to the randomness and uncertainty of wind direction, a short-term wind direction prediction model is proposed based on variational mode decomposition (VMD) and bat algorithm (BA) optimized long short term memory (LSTM). Firstly, the original sequence is decomposed into multiple finite-band eigen-mode modal components by using VMD to reduce the influence of the complexity and non-stationarity of the original data on the prediction accuracy. Then the BA-LSTM model for each component is established to predict separately, and finally the wind direction values are obtained by superimposing the prediction results of each component. The multi-time-scale wind direction prediction is carried out based on the measured data of a wind field in Hebei Province. Experimental results show that the proposed method improves the prediction accuracy compared with the LSTM and least square support vector machine (LSSVM) prediction methods, which provides support for the subsequent research on the optimal adjustment of the yaw system.

Key words: wind direction prediction, variational mode decomposition, bat algorithm (BA), long-short term memory (LSTM) neural network, multi-time-scale