

考虑风速波动特性的 VMD-GRU 短期风电功率预测

王鑫¹, 李慧¹, 叶林², 范新桥¹, 刘思嘉¹

(1. 北京信息科技大学自动化学院, 北京 100192; 2. 中国农业大学信息与电气工程学院, 北京 100083)

摘要:提高风电功率预测的精准度能为大规模风电并网提供安全保障, 为此提出一种考虑风速波动特性的短期风电功率组合预测方法。首先, 定义5种风速波动类型, 对数值天气预报中的历史风速序列进行波动类型划分, 得到不同风速波动类型的天气时段; 其次, 将这些天气时段对应的历史风电功率序列进行分类, 采用变分模态分解算法对各类风电功率序列进行分频计算, 得到特征、频段互异的多个子模态; 然后, 利用门控循环单元神经网络建立每个子模态预测模型, 将各个子模态预测结果进行叠加, 得到风电功率预测值; 最后, 对待测时段的风速序列进行波动类型划分和识别, 选取相匹配的功率预测模型计算出最终预测值。利用某实际风电场的数值天气预报风速数据和功率数据进行仿真分析, 验证所提组合预测方法的有效性。

关键词:风电功率预测; 数值天气预报; 风速波动特性; 变分模态分解; 门控循环单元神经网络

DOI:10.19781/j.issn.1673-9140.2021.04.003 中图分类号: TM614 文章编号: 1673-9140(2021)04-0020-09

VMD-GRU based short-term wind power forecast considering wind speed fluctuation characteristics

WANG Xin¹, LI Hui¹, YE Lin², FAN Xinqiao¹, LIU Sijia¹

(1. School of Automation, Beijing Information Science and Technology University, Beijing 100192, China;

2. College of Information and Electrical Engineering, China Agricultural University, Beijing 100083, China)

Abstract: The accuracy of wind power prediction can improve the security environment of large-scale wind power integration. Under the background, a combined approach considering wind speed fluctuation characteristics for short-term wind power forecasting is proposed in this paper. Firstly, five types of wind speed fluctuations are defined, and the fluctuation type of historical wind speed series in numerical weather prediction is divided to get the time period of different wind speed fluctuation types. Secondly, the historical wind power series corresponding to these time periods are classified, and the variational mode decomposition algorithm is used to deal with various types of wind power series for obtaining multiple sub-modalities with different characteristics and frequency bands. Thirdly, a prediction model based on the gated recurrent unit neural network is constructed for each sub-mode, and the prediction results of

收稿日期: 2020-07-21; 修回日期: 2020-11-22

基金项目: 国家重点研发计划(2018YFB0904200); 北京市自然科学基金(3172015); 国家电网有限公司科技项目(SGLNDK00KJJS1800266);

北京市教委科技计划面上项目(KM201911232016)

通信作者: 李慧(1976-), 女, 博士, 教授, 主要从事柔性直流输电系统稳定与控制以及新能源发电技术研究; E-mail: lhbxy@bistu.edu.cn

each sub-mode are added to obtain the predicted value of the wind power. Finally, the wind speed series of the forecasted day is identified from the types of fluctuation, and the matching power prediction model is selected to calculate the final prediction value. The wind speed data in the numerical weather prediction and power data of an actual wind farm are used for simulation analysis to verify the effectiveness of the proposed combined forecasting method.

Key words: wind power forecasting; numerical weather prediction; wind speed fluctuation characteristics; variational mode decomposition; gated recurrent unit neural network

21 世纪以来,由于化石能源的不断消耗和环境问题日益严重,开发和利用清洁、高效的可再生能源已成为能源领域的研究重点。风能具有储量丰富、清洁和可再生等优点,在可持续发展的能源战略中得到广泛关注。但是,风能又具有间歇性、波动性和不确定性等特点^[1],大规模风电并网会对电力系统的安全稳定运行带来不利影响。提高风电功率预测的精准度是风电系统实现大规模并网的前提和安全保障^[2]。

风速变化存在很大波动性,呈现为非平稳的随机信号^[3]。文献[4]指出风速波动与风电功率波动存在一定的对应关系,定义了不同的波动类型,采用一些参数来定量刻画波动,通过分类匹配和修正技术建立了风速波动和风电功率波动之间的对应关系,有效提高了预测精度;文献[5]通过改进面板数据的距离指标对多维气象数据进行聚类分析,并对不同天气类型分别建立预测模型,识别出待预测日的天气类型,选取相应预测模型进行功率预测,达到选取合适样本集细化建模的目的,从而改善预测精度。借助数值天气预报(numerical weather prediction, NWP)的天气数据,按照波动类型构建不同预测模型成为一种提升风电功率预测精度的研究思路。

风功率随风速变化而变化,也呈现出非平稳随机性。在风功率预测建模之前,采用信号分解处理手段可以有效降低风功率序列的非平稳性及非线性对预测精度的影响。除小波分解算法外,经验模态分解算法(empirical mode decomposition, EMD)也常应用于预测研究中,但是它存在模态混叠现象。集合经验模态分解(ensemble EMD, EEMD)是通过添加服从正态分布的白噪声序列来降低 EMD 的模态混叠现象^[6],但是引入的白噪声常残留于分解后的子序列中,成为一种干扰信号。完备经验模态分解(complete EEMD, CEEMD)通过引入正、负相反的 2 组白噪声来解决噪声残留问题^[7],但是它增加

了算法复杂度且难以保证引入的白噪声绝对抵消。

在预测建模中,好的预测算法对提升预测精度也起到一定的决定作用。目前,学习方法(如神经网络法^[8]、支持向量机、随机森林等^[9])广泛应用到风电功率预测中。它的核心在于利用大量样本数据进行训练和学习,通过捕捉数据之间的隐含规律和逻辑关系,使模型的映射能力更强,从而得到较准确的预测结果。文献[10]采用聚类算法和支持向量机(support vector machine, SVM)的组合模型进行了预测研究。SVM 模型与传统神经网络模型相比,虽然能避免陷入局部最优解,但是当数据规模较大时,仍出现收敛速度慢等问题。

随着机器学习的兴起,特别是深度学习理论的研究不断深入,给预测研究带来了新的思路。极限学习机^[11](extreme learning machine, ELM)作为机器学习的一种典型代表被广泛应用于预测研究。文献[12]应用基于特征选择和参数优化的 ELM 复合结构进行风速预测研究,ELM 算法比传统神经网络在预测精度上有所提高;文献[13]将经验小波变换和 2 种循环神经网络相结合构建预测模型,应用长短期记忆(long short-term memory, LSTM)神经网络建立风速低频子层部分的预测模型,利用 Elman 神经网络建立风速高频子层部分的预测模型,提升了预测精度。近年来,门控循环单元(gated recurrent unit, GRU)神经网络^[14]在预测研究中逐步被使用,它不仅在结构上简化于 LSTM,同时还能保证与 LSTM 相近地映射和拟合效果。

该文构造一种考虑风速波动特性的变分模态分解(variational mode decomposition, VMD)和门控循环单元(gated recurrent unit, GRU)神经网络的组合风电功率预测模型,目的是预测未来 72 h 的风电功率。首先,在分析历史 NWP 风速序列的波动特性基础上,进行波动类型划分,得到不同波动类型的天气时段;然后,将这些天气时段对应的历史风电

功率序列进行分类,分别建立每一类波动类型下相应的功率预测模型;最后,对待测时段的 NWP 风速波动类型加以分析,匹配出相应的功率预测模型进行预测。在预测建模过程中,采用一种完全非递归、自适应的 VMD 信号分解方法,将风功率序列分解为一系列有限带宽且特征、频段互异的子模态序列,再结合 GRU 神经网络对每个子模态序列构建预测模型,将多个模型的预测结果进行叠加,得到最终的功率预测结果。

1 风速波动特性划分及数学建模

风速与风电功率之间存在一定的内在对应关系。利用数值天气预报中的风速数据序列分析其波动特性,建立风速波动特性与风电功率之间的对应关系,能有效提高短期风电功率预测精度。文献[15]提出了风速“波”的定义:风速从某个最小值逐渐增至最大值,再减小到另一个最小值,这个过程称为一个“波”或者一个天气过程。通过分析风电场出力发现,不同波动的风速对风电功率预测精度的影响也不相同。根据 NWP 中的风速序列波动情况,按照一定方式对风速的波动类型进行定义和划分,其目的是将长时间、多变化、无规律的风速序列划分成若干种可研究的小单元时段,针对每一种风速波动类型下的风电功率序列进行分类建模和预测。

分析 NWP 风速数据发现,一个有风的天气过程可能持续几个小时甚至十几个小时不等,此外每个天气过程中风速达到的最大值也不尽相同。根据一段时间内风速的大小不同,该文先将其划分为小幅度波动和大幅度波动两大类。换句话说,小幅度波动属于低风速时段,即在一段时间范围内,风速值始终小于风机保持稳定运行的某个阈值,反之则为大幅度波动。大幅度波动类型的风速变化相对复杂,该文根据持续时间和风速大小再划分为 4 种类型:从波动持续时长上将大幅度波动划分为短时和长时波动 2 种类型,反映了风速的持续性和完整性;在此基础上,依据风速的大小将其细分为大波动和小波动 2 种类型,体现了风机在额定风速左右运行的状况。该文定义的 5 种风速波动类型如图 1 所示,它们的数学模型如表 1 所示。




图 1 风速波动分类

Figure 1 Diagram of wind speed fluctuation classification

表 1 5 种风速波动的数学模型

Table 1 Five mathematical models of wind speed fluctuations

波动类型	数学模型
短时 小波动	$W_1 = \begin{cases} v_{\min 1}, v_{\min 2} \in (0, v_1) \\ v_{\max} \leq v_2 \\ n \leq N \end{cases}$
短时 大波动	$W_2 = \begin{cases} v_{\min 1}, v_{\min 2} \in (0, v_1) \\ v_{\max} > v_2 \\ n \leq N \end{cases}$
大幅度 波动 长时 小波动	$W_3 = \begin{cases} v_{\min 1}, v_{\min 2} \in (0, v_1) \\ v_{\max} \leq v_2 \\ n > N \end{cases}$
大幅度 波动 长时 大波动	$W_4 = \begin{cases} v_{\min 1}, v_{\min 2} \in (0, v_1) \\ v_{\max} > v_2 \\ n > N \end{cases}$
小幅度波动	$W_5 = \{0 < v \leq v_1\}$

图 1 中, $W_1 \sim W_5$ 分别表示 5 种波动类型; v 表示某时刻归一化的风速值; v_1 表示区分大、小幅度波动的风速阈值; v_{\max} 表示一段时间内的风速最大值,若 $v_{\max} > v_1$,则该波动类型为大幅度波动,反之为小幅度波动; $v_{\min 1}$ 、 $v_{\min 2}$ 表示小于 v_1 的 2 个相邻的风速最小值,将 $v_{\min 1}$ 和 $v_{\min 2}$ 之间的一段风速序列视为一个完整的大幅度波动; n 表示采样点个数, N 表示区分短时波动和长时波动的阈值,当 $n \leq N$ 时,定义该波动类型为短时波动,否则为长时波动; v_2 表示区分大、小波动的风速阈值,当一个时段内风速的最大值 $v_{\max} \leq v_2$ 时,定义为小波动,否则为大波动。于是,将风速波动类型分为短时小波动、短时大波动、长时小波动、长时大波动和小幅度波动,按照不同风速波动类型,将其对应的风电功率序列进行分类,分别建立预测模型。

2 VMD-GRU 短期风电功率预测建模

2.1 VMD 原理

VMD 作为一种完全非递归、自适应的信号分解方法,最早是由 Konstantin Dragomiretskiy 和 Dominique Zosso 在 2014 年提出的^[16]。它可以将非平稳的风电功率序列分解成多个子模态 u_k , 每一个子模态的中心频率记为 ω_k 。在分解时,需要预先设定分解阶次 K , 如对风电功率信号进行 K 阶 VMD 分解时,可以将其看作约束变分问题,即

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s. t. } \sum_{k=1}^K u_k = v(t) \end{cases} \quad (1)$$

式中 $\{u_k\} = \{u_1, u_2, \dots, u_K\}$ 、 $\{\omega_k\} = \{\omega_1, \omega_2, \dots, \omega_K\}$ 分别为各子模态分量、中心频率; $v(t)$ 为待分解的风电功率序列; δ 为狄拉克(Dirac)分布; $*$ 为卷积运算符。

为了得到变分方程式(1)的最优解,引入增广拉格朗日方程:

$$\begin{aligned} L(\{u_k\}, \{\omega_k\}, \lambda) = & \alpha \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \\ & \left\| v(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \left(\lambda(t), v(t) - \sum_{k=1}^K u_k(t) \right) \end{aligned} \quad (2)$$

式中 α 、 λ 分别为引入的二次惩罚因子参数、拉格朗日乘子。

于是,将求解变分方程式(1)的问题转化为求解增广拉格朗日方程式(2)的鞍点问题。利用乘子交替方向法(alternate direction method of multipliers, ADMM)求解式(2),迭代计算得到鞍点。由 ADMM 算法可以得到 u_k 、 ω_k 的迭代公式:

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{v}(\omega) - \sum_{i \neq k} \hat{u}_i^n(\omega) + \frac{\hat{\lambda}^n(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k^n)^2} \quad (3)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k^n(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^n(\omega)|^2 d\omega} \quad (4)$$

式中 \hat{u}_k^{n+1} 、 $\hat{v}(\omega)$ 、 $\hat{u}(\omega)$ 、 $\hat{\lambda}(\omega)$ 分别为 u_k^{n+1} 、 $v(t)$ 、 $u(t)$ 、 $\lambda(t)$ 的傅里叶变换。

VMD 计算步骤如下:

1)初始化,将 $\{\hat{u}_k^1\}$ 、 $\{\omega_k^1\}$ 、 $\hat{\lambda}^1$ 、 n 均置 0,并选取合适的分解阶次 K 作为预设值;

2)根据式(3)、(4)迭代计算,更新 u_k 和 ω_k ;

3)按照公式更新 $\hat{\lambda}$, 即

$$\hat{\lambda}^{n+1}(\omega) = \hat{\lambda}^n(\omega) + \tau \left[\hat{f}(\omega) - \sum_{k=1}^K \hat{u}_k^{n+1}(\omega) \right] \quad (5)$$

4)收敛条件为

$$\sum_{k=1}^K \frac{\|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2}{\|\hat{u}_k^n\|_2^2} < \epsilon \quad (6)$$

当满足收敛条件时,停止迭代,否则,返回步骤 2 重复计算步骤。

2.2 GRU 神经网络预测模型

基于递归神经网络理论产生的 GRU 神经网络也是一种机器学习方法,被逐步应用于时间序列的预测研究。它可以看作是对 LSTM 网络的改进,没有设置存储单元机制,引入更新门来替代 LSTM 的输入门和遗忘门,从而在结构上简化于 LSTM,提高了训练效率。该文采用 GRU 深度学习神经网络来构建风电功率预测模型。

GRU 神经网络的内部结构如图 2 所示,包括重置门(r)和更新门(z),其中 σ 和 \tanh 为网络的激活函数。 σ 代表 sigmoid 函数,其值域为 $(0, 1)$; \tanh 代表双曲正切函数,其值域为 $(-1, 1)$ 。

$$\text{sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (7)$$

$$\text{tanh}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (8)$$




图 2 GRU 内部结构

Figure 2 GRU internal structure diagram

假设给定输入为 x_t ，并将 h_t 记为隐藏层的输出，则可由更新门(z)、重置门(r)、候选值 \tilde{h}_t 计算求得输出候选值 h_t 。

$$z_t = \sigma(\mathbf{W}_{zh}h_{t-1} + \mathbf{W}_{zx}x_t) \quad (9)$$

$$r_t = \sigma(\mathbf{W}_{rh}h_{t-1} + \mathbf{W}_{rx}x_t) \quad (10)$$

$$\tilde{h}_t = \tanh(\mathbf{W}_{hh}(r_t \odot h_{t-1}) + \mathbf{W}_{hx}x_t) \quad (11)$$

$$h_t = (1 - z_t) \odot h_{t-1} + \tilde{h}_t \odot z_t \quad (12)$$

式(9)~(12)中 \mathbf{W}_{zh} 、 \mathbf{W}_{zx} 为更新门(z)权重矩阵； \mathbf{W}_{rh} 、 \mathbf{W}_{rx} 为重置门(r)权重矩阵； \mathbf{W}_{hh} 、 \mathbf{W}_{hx} 为计算输出候选值 \tilde{h}_t 时的权重矩阵； \odot 为矩阵的元素积。

从式(9)~(12)可以看出， r 是用来确定当前时刻输入 x_t 与 $t-1$ 时刻神经元状态 h_{t-1} 的相关度，其值的大小与 $t-1$ 时刻的相关度呈正比关系，当 r_t 接近于 0 时，与 h_{t-1} 几乎不相关； z 控制着 $t-1$ 时刻的隐藏状态 h_{t-1} 信息能保留在 t 时刻 h_t 的量，其值越小说明忽略的历史信息越多，当 z_t 的值接近 1 时，当前状态对 $t-1$ 时刻隐藏状态的信息利用充分。如果将 r_t 置 0、 z_t 置 1，则 GRU 呈现出传统 RNN 的结构性能。这种自适应的调整方式能够确保最有效的信息可以流向下一个 GRU 单元。

结合 GRU 神经网络单元构建预测模型，GRU 预测模型结构如图 3 所示，包括输入层、GRU 层、全连接层和输出层。

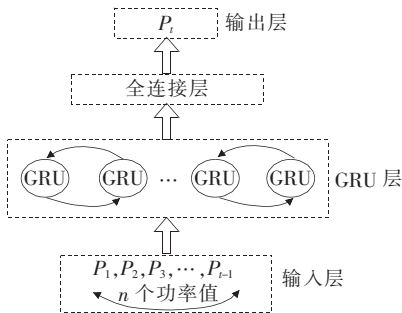


图 3 GRU 预测模型结构

Figure 3 GRU prediction model structure diagram

GRU 层中 GRU 单元的激活函数如上文所述，全连接层采用 ReLU 作为其激活函数，可以用来加快收敛速度并缓解消失梯度等问题。

$$f_{\text{ReLU}}(x) = \begin{cases} x, & x > 0 \\ 0, & x \leq 0 \end{cases} \quad (13)$$

预测模型采用均方误差(mean square error,

MSE)作为损失函数。在进行风电功率预测时，模型的输入为待测时刻 t 前的 n 个功率值，模型的输出为 t 时刻的功率值。

$$e_{\text{MSE}} = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (14)$$

2.3 短期风电功率组合预测

该文提出的组合预测方案如图 4 所示。

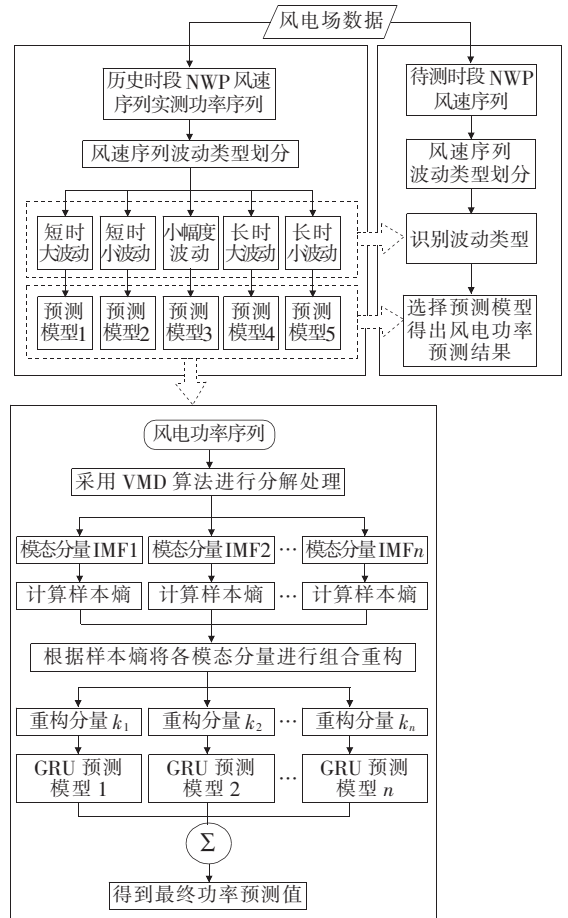


图 4 风电功率组合预测方案

Figure 4 The combined forecasting scheme for wind power

1)对历史 NWP 风速序列按照表 1 所示的 5 种风速波动类型的数学模型进行波动类型划分，将长时间、多变化的风速序列划分成若干种可探寻规律的研究时段。

2)对划分出的每一种风速波动类型所对应的功率序列分别建立 VMD-GRU 预测模型。建模时先对风电功率序列进行 VMD 分解，得到 n 个特征、频段互异的子模态序列分量(intrinsic mode functions, IMF)，记为 IMF_n ；为了减少建模数量，计算各子模态序列分量的样本熵^[17]，由样本熵的值确定新的子序列个数，再对每个子序列分别建立 GRU

预测模型;将各个子序列预测模型的预测结果进行叠加,得到最终的功率预测结果。

3)对待测时段的 NWP 风速序列进行波动特性划分,识别出各波动类型及相应的波动段,选取匹配的功率预测模型进行预测;将各波动段对应的预测值在时间轴上重构,得到待测时段最终的预测结果。

3 算例分析

以中国某实际风电场的 NWP 风速数据和实测风电功率数据为例进行仿真分析,采样周期为 15 min,预测未来 72 h 的风电功率。通过对比 VMD-BP、VMD-ELM、GRU 和 VMD-GRU 这 4 种预测模型下的风电功率预测结果,验证所提出的 VMD-GRU 预测模型的有效性。

采用归一化平均绝对误差和归一化均方根误差作为预测结果的评价指标,计算公式分别为

$$e_{\text{NMAE}} \% = \frac{1}{nP_{\text{cap}}} \sum_{i=1}^n |\hat{y}_i - y_i| \times 100 \quad (15)$$

$$e_{\text{NRMSE}} \% = \frac{1}{P_{\text{cap}}} \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \times 100 \quad (16)$$

式中 n 为风电功率的采样点数; y_i 和 \hat{y}_i 分别为 i 时刻的风电功率实际值和预测值; P_{cap} 为所研究风电场的总装机容量。

3.1 预测模型建立与测试

对归一化的历史 NWP 风速序列和实测功率序列进行波动分类和建模。选取紧支撑双正交小波 Daubechies 作为基小波,对 NWP 风速序列进行 5 尺度分解,过滤掉高频信号,保留风速趋势信号,避免非趋势性的小细节波动对风速波动特性划分的干扰。

依照文 1 中方法对该趋势项信号进行波动特性划分。经过对大量历史风速数据的统计分析发现:一部分完整的风速波动持续时长小于 48 h,另一部分大于 48 h,该文考虑到风速的持续性与完整性,故选取 $N=192$ 作为区分短时和长时波动的阈值;由于风机的启动风速为 3.5~4.0 m/s,故选取预报风速 5.7 m/s(归一化值 $v_1=0.2$)作为区分大、小幅度波动的风速阈值;由于风机的额定风速为 11.5~12.0 m/s,故选取预报风速 11.4 m/s(归一化值 $v_2=0.4$)作为大、小波动的风速阈值,由此得到 5 种风速波动类型。样本集由 10 540 个采样点组成,其

中 9 733 个采样点为训练样本集,807 个采样点为测试样本集,5 种风速波动类型的样本集统计结果如表 2 所示,测试集波动类型划分如图 5 所示。

表 2 5 种波动类型样本集统计

Table 2 Statistics of sample sets of five wave types

波动段	波动类型	训练集	测试集
b_1	短时小波动	2 016	99
b_2	短时大波动	1 618	104
b_3	小幅度波动	1 722	96
b_4	长时小波动	1 895	234
b_5	长时大波动	2 482	274
采样点总数		9 733	807




图 5 测试集风速波动类型划分

Figure 5 Classification of wind speed fluctuation types in the test set

对每一种波动类型的风电功率序列进行 VMD 模态分解,建立预测模型。以短时大波动类型为例,对其功率序列进行 VMD 分解,统计分析各模态分量的中心频率,确定分解阶次 $K=10$,得到一系列子模态分量,记为 $\text{IMF}_1 \sim \text{IMF}_{10}$,如图 6 所示。

计算各个子模态分量的样本熵,根据熵值的大小确定子序列个数为 3,将相应的子模态加和重构得到 3 组子序列 k_1 、 k_2 和 k_3 ,其中 k_1 为模态 $\text{IMF}_1 \sim \text{IMF}_4$ 的组合, k_2 为模态 $\text{IMF}_5 \sim \text{IMF}_9$ 的组合, k_3 为 IMF_{10} 。对重构的子序列 k_1 、 k_2 、 k_3 分别建立子序列的 GRU 预测模型。使用 Python 基于 TensorFlow 为后端的 Keras 框架搭建基于 GRU 的风电功率预测模型。其中,GRU 层神经元个数为 150,全连接层单元数为 128,迭代次数为 500 次,输出层单元数为 1,并采用线性函数“linear”作为激活函数。将各子序列预测模型的预测结果相叠加,得到最终功率预测结果。




图6 短时大波动类型序列的VMD分解结果

Figure 6 VMD decomposition of short-time large fluctuation type sequences

采用4种预测方法分别得到短时大波动类型测试集的对比结果,如图7所示。4种预测方法下5种波动类型测试集的误差对比如表3所示,可知同一种预测模型下不同波动类型对应的预测精度不同。从波动幅度的角度来看,小幅度波动类型的预测精度最高,小波动类型的预测精度次之,大波动类型的预测精度最低;从波动时长的角度来看,短时波动类型的预测精度略高于长时波动模型的预测精度。

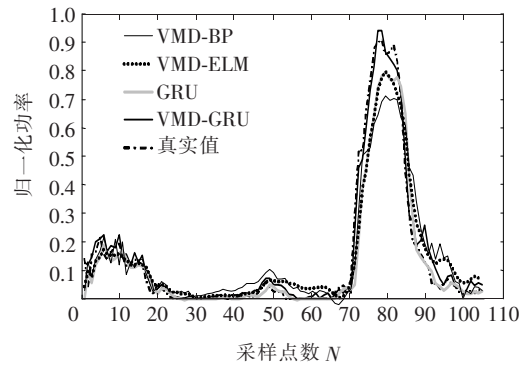


图7 4种预测方法下短时大波动类型测试集的结果

Figure 7 Results of a test set of short-time large fluctuation types under four prediction methods

表3 4种预测方法下5种波动类型测试集的误差对比

Table 3 The error comparison of five wave type test sets under four forecasting methods

波动类型	e_{NMAE}				e_{NRMSE}				%
	VMD-BP	VMD-ELM	VMD-GRU	GRU	VMD-BP	VMD-ELM	VMD-GRU	GRU	
短时小波动	4.92	3.71	2.51	3.02	5.36	4.65	2.73	3.94	
短时大波动	6.33	4.84	2.89	3.79	9.34	7.14	4.36	6.32	
长时小波动	7.57	6.64	2.62	3.56	9.08	7.91	3.22	5.82	
长时大波动	7.99	5.73	3.91	6.24	11.61	9.16	4.78	10.42	
小幅度波动	2.88	2.10	1.62	2.01	4.10	2.80	2.20	3.32	

3.2 未来72 h风电功率预测

选取某3天72 h共288个采样点的数据组成预测集,预测集的NWP风速数据波动类型划分的结果如图8所示,其中, c_1 和 c_2 为短时大波动段, c_3 为短时小波动段。按照划分得到的短时大波动和短时小波动风速类型选择相应的功率预测模型,获得对应波动段的功率预测值,最后,在时间轴上重构得到最终预测结果。预测集的归一化绝对误差曲线如图9所示(绝对误差为预测值与真实值之差的绝对

值)。

4种预测方法的误差对比如表4所示,对比GRU和VMD-GRU,它们的 e_{NMAE} %分别为4.19、3.08, e_{NRMSE} %分别为5.87、3.95,说明采用VMD分解的组合方法比单一GRU方法的预测精度高;对比VMD-BP、VMD-ELM和VMD-GRU,它们的 e_{NMAE} %分别为6.21、4.38和3.08, e_{NRMSE} %分别为8.54、5.71和3.95,说明VMD-GUR方法的预测效果最佳。






图 8 预测集的 NWP 风速数据波动类型划分


Figure 8 Classification of NWP wind speed data fluctuation types of prediction sets



(a)1~96 个采样点



(b)97~192 个采样点



(c)193~288 个采样点

图 9 预测集的归一化绝对误差

Figure 9 The normalized absolute error of the prediction set

表 4 预测集的误差对比

Table 4 The error comparison of the prediction set

预测模型	e_{NMAE}	e_{NRMSE}
VMD-BP	6.21	8.54
VMD-ELM	4.38	5.71
VMD-GRU	3.08	3.95
GRU	4.19	5.87

4 结语

在考虑风速波动特性的基础上,该文利用风速波动特性与风电功率之间的对应关系,建立了不同风速波动类型下的短期风电功率预测模型。采用 VMD 分解算法,降低了原始风电功率序列的不平稳性对预测精度的影响,并结合 GRU 深度学习神经网络构建组合预测模型,提高了短期风电功率预测精度。

在该文的后续工作中,将进一步优化风速波动特性阈值参数的提取方法,使风速波动特性划分更加精准,更有效地建立风速与风电功率之间的匹配关系,从而提高短期风电功率预测精度。

参考文献:

- [1] 施涛,李春来,朱慧敏. 考虑功率预测不确定性的风电消纳随机调度[J]. 电网与清洁能源,2019,35(4):55-59.
SHI Tao, LI Chunlai, ZHU Huimin. Stochastic dispatching of wind power accommodation considering uncertainty of power prediction[J]. Power System and Clean Energy, 2019, 35(4): 55-59.
- [2] 杨茂,张罗宾. 基于数据驱动的超短期风电功率预测综述[J]. 电力系统保护与控制,2019,47(13):171-186.
YANG Mao, ZHANG Luobin. Review on ultra-short term wind power forecasting based on data-driven approach[J]. Power System Protection and Control, 2019, 47(13): 171-186.
- [3] 叶林,滕景竹,蓝海波,等. 变尺度时间窗口和波动特征提取的短期风电功率组合预测[J]. 电力系统自动化,2017,41(17):29-36+59.
YE Lin, TENG Jingzhu, LAN Haibo, et al. Combined prediction for short-term wind power based on variable time window and feature extraction[J]. Automation of Electric Power Systems, 2017, 41(17): 29-36+59.
- [4] 丁明,缪乐颖,车建峰,等. 基于波动过程匹配技术的短期风电功率预测[J]. 电网技术,2018,42(11):3652-3659.
DING Ming, MIAO Leying, CHE Jianfeng, et al. Short-term wind power forecasting based on fluctuation process matching technology[J]. Power System Technology, 2018, 42(11): 3652-3659.

- [5] 熊音笛,刘开培,秦亮,等. 基于时序数据动态天气划分的短期风电功率预测方法[J]. 电网技术,2019,43(9): 3353-3359.
XIONG Yindi,LIU Kaipei,QIN Liang,et al. Short-term wind power prediction method based on dynamic wind power weather division of time sequence data[J]. Power System Technology,2019,43(9): 3353-3359.
- [6] 张鑫磊,李根. 基于 IEEMD 与 LS-SVM 组合的短期风电功率多步预测方法[J]. 电测与仪表,2020,57(6):52-60.
ZHANG Xinlei,LI Gen. Multi-step prediction method of short-term wind power based on the IEEMD and LS-SVM[J]. Electrical Measurement & Instrumentation, 2020,57(6): 52-60.
- [7] 刘强,胡志强,周宇,等. 基于 CEEMD 和随机森林算法的短期风电功率预测[J]. 智慧电力,2019,47(6):71-76+94.
LIU Qiang, HU Zhiqiang, ZHOU Yu, et al. Short-term wind power forecasting based on CEEMD and Random forest algorithm[J]. Smart Power,2019,47(6):71-76+94.
- [8] 何廷一,田鑫萃,李胜男,等. 基于蜂群算法改进的 BP 神经网络风电功率预测[J]. 电力科学与技术学报,2018,33(4):22-28.
HE Tingyi, TIAN Xincui, LI Shengnan, et al. Improved BP neural network based on artificial bee colony algorithm for wind power prediction[J]. Journal of Electric Power Science and Technology,2018,33(4):22-28.
- [9] 马愿,张倩,李国丽,等. 基于频域分解的短期负荷预测研究分析[J]. 中国电力,2020,53(4):114-121.
MA Yuan,ZHANG Qian,LI Guoli,et al. Research and analysis of short-term load forecasting based on frequency domain decomposition[J]. Electric Power,2020, 53(4):114-121.
- [10] 张雨金,杨凌帆,葛双冶,等. 基于 Kmeans-SVM 的短期光伏发电功率预测[J]. 电力系统保护与控制,2018,46(21):118-124.
ZHANG Yujin, YANG Lingfan, GE Shuangye, et al. Short-term photovoltaic power forecasting based on Kmeans algorithm and support vector machine[J]. Power System Protection and Control,2018,46(21): 118-124.
- [11] 朱抗,杨洪明,孟科. 基于极限学习机的短期风力发电预测[J]. 电力科学与技术学报,2019,34(2):106-111.
ZHU Kang, YANG Hongming, MENG Ke. Short-term wind power forecast using extreme learning machine [J]. Journal of Electric Power Science and Technology, 2019,34(2):106-111.
- [12] Zhang Chu, Zhou Jianzhong, 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 and Management,2017,143:360-376.
- [13] Liu Hui, Mi Xiwei, Li Yanfei. Wind speed forecasting method based on deep learning strategy using empirical wavelet transform, long short term memory neural network and Elman neural network[J]. Energy Conversion and Management,2018,156:498-514.
- [14] 牛哲文,余泽远,李波,等. 基于深度门控循环单元神经网络的短期风功率预测模型[J]. 电力自动化设备,2018,38(5):36-42.
NIU Zhewen, YU Zeyuan, LI Bo, et al. Short-term wind power forecasting model based on deep gated recurrent unit neural network[J]. Electric Power Automation Equipment,2018,38(5): 36-42.
- [15] Zhao Jing, Guo Yanling, Xiao Xia, et al. Multi-step wind speed and power forecasts based on a WRF simulation on and an optimized association method[J]. Applied Energy,2017,197:183-202.
- [16] Konstantin Dragomiretskiy, Dominique Zosso. Variational mode decomposition[J]. IEEE Transactions on Signal Processing,2014,62(3):531-544.
- [17] 魏乐,李思莹. 基于 MEEMD-LSSVM 的风电功率超短期预测研究[J]. 智慧电力,2020,48(5):21-26.
WEI Le, LI Siying. Ultra-short-term forecast for wind power based on MEEMD-LSSVM[J]. Smart Power, 2020,48(5):21-26.