文章编号: 2096-5125(2022)01-0011-12 DOI: 10.19705/j.cnki.issn2096-5125.2022.01.003 中图分类号: TM614

文献标志码: A

基于自适应移动平滑与时间卷积网络误差修正的 风电功率预测

孙蓉^{1*},李强¹,罗海峰²,窦迅²,邓叶航² (1.国网江苏省电力有限公司电力科学研究院,江苏省 南京市 211103; 2.南京工业大学,江苏省 南京市 211816)

Wind Power Forecasting Based on Error Correction Using Adaptive Moving Smoothing and Time Convolution Network

SUN Rong^{1*}, LI Qiang¹, LUO Haifeng², DOU Xun², DENG Yehang²

(1. State Grid Jiangsu Electric Power Co., Ltd. Research Institute, Nanjing 211103, Jiangsu Province, China;

2. Nanjing Tech University, Nanjing 211816, Jiangsu Province, China)

Abstract: To mitigate the impact of wind power prediction errors on power system dispatching operations, we proposed a wind power prediction method based on error correction using adaptive moving smoothing (AMS), and time convolution network (TCN). First, the spatio-temporal characteristics of wind power were extracted using variational modal decomposition, and TCN, to obtain preliminary prediction results. Subsequently, adaptive smoothing was applied to the prediction error series using the AMS model, to reduce the volatility of the error. Lastly, the temporal characteristics of the prediction error were extracted using the TCN model, to correct the preliminary prediction results, and improve the accuracy and stability of the prediction. The experimental comparison analysis was conducted based on the measured data from two wind farms in Shuangzitai, Liaoning, and Hexigten Banner, Inner Mongolia. Compared with other methods, the prediction results obtained at 15 min, 30 min and 1 h time scales, using the proposed method, improved the mean absolute error by more than 50.0%, and the mean relative error by more than 10.0%. Therefore, the superiority of the method proposed in this paper was verified.

Keywords: error correction; wind power forecasting; temporal convolutional network; adaptive moving smoothing

摘 要:为了解决风电功率预测误差对电力系统调度运行影响的问题,提出一种基于自适应移动平滑(adaptive movement smoothing, AMS)和时间卷积网络(temporal convolutional network, TCN)误差修正的风电功率预测方法。该方法首先利用变分模态分解和TCN提取风电功率的时空特性,得到初步预测结果;然后利用AMS模型对预测误差序列进行自适应平滑处理,降低误差的波动性;最后利用TCN模型提取预测误差的时间特性,对初步预测结果进行修正,提高预测的精度和稳定性。基于辽宁双子台和内蒙古克什克腾旗两个风电场的实测数据进行了实验对比分析,相较于其他方法,采用所提风电功率预测方法在15 min、30 min和1 h时间尺度下得到的预测结果,平均绝对误差降低50.0%以上,平均相对误差降低10.0%以上,验证了所提方法的有效性。

关键词:误差修正;风电功率预测;时间卷积网络;自适应 移动平滑

0 引言

风力发电技术不断成熟带动了风力发电装机容 量的增加,然而由于风功率具有波动性和间歇性的特 点,风电的大规模接入会对全网的电力平衡带来很大影 响^[1-3]。精准稳定的风电功率预测是保证调度计划有 效进行的重要手段^[4]。受现有预测技术的限制,预 测误差不可避免,亟需引入误差分析方法以挖掘风 电功率预测误差的时间变化特性,保障电力系统安 全可靠运行。

基金项目: 国网江苏省电力有限公司科技项目(基于实时资源和运行数据的高精度新能源功率在线预测, J2020128)。

Science and Technology Project of State Grid Jiangsu Electric Power Co., Ltd. (High-precision Online Prediction of New Energy Power Based on Real-time Resources and Operational Data, J2020128).

目前广泛使用的风电功率预测方法主要分为物 理法和统计法^[5],此外还有将多种方法组合起来的组 合预测法^[6]。物理法应用数值天气预报(numerical weather prediction, NWP)数据作为已知物理参数, 通过建立其与风电功率之间的物理关系式来对风电功 率进行预测^[7-8]。基于物理法预测风电功率的优点在 于不需要风电场历史功率数据,因此适用于新建风电 场^[9]; 依赖的数据量小,模型简单,预测方便快捷。 但是NWP数据与真实气象数据间存在着较大误差, 且NWP数据与风电场存在空间差异,这就使得物理 法对风电功率的预测精度普遍偏低。统计法通过挖 掘NWP数据和历史风场数据与风电功率之间的线性 和非线性映射关系,利用近期的NWP数据对风电功 率进行预测。该方法通常又被分为概率统计模型、机 器学习模型和深度学习模型。概率统计模型包括自回 归滑动平均(auto-regressive moving average model, ARMA)^[10]和自回归积分滑动平均(auto-regressive integrated moving average model, ARIMA)^[11-12]等, 相比于物理法能更好地跟随风电功率的变化趋势;机 器学习模型包括支持向量机(support vector machine, SVM)^[13-14]、随机森林(random forest, RF)^[15]和隐 马尔科夫模型(hidden Markov model, HMM)^[16]等, 其预测精度均优于传统概率模型:深度学习模型包括 神经网络模型^[17]、长短期记忆网络(long short term memory, LSTM)^[18]和门限循环网(gated recurrent unit, GRU)^[19]等,能充分挖掘输入序列的时间和空 间特性,进一步提高风电功率预测的精度。基于统计 法预测风电功率的优点在于利用预测值与真实值的误 差来更新和调整模型的权重和参数,相较于物理法能 够提高风电功率预测的精度,但是对历史数据的数量 和质量要求很高,一些新建风电场难以适用。统计法 与物理法一样,都没有对预测误差做进一步分析,都 存在预测稳定性差的问题。

上述方法均属于单一预测方法,受限于模型自身的缺陷,难以进一步提高预测精度和稳定性,因此将不同预测方法有机结合形成组合预测模型,规避单一预测方法的局限性,能够进一步提高预测精度^[20-21]。文献[22]提出变分模态分解(variational mode decomposition, VMD)和改进门控循环单元分位数回归相结合的超短期风电功率概率预测方法,获取不同置信水平下的风电功率区间,避免了传统构造概率分布的主观性与先验性。文献[23]结合求导环节和神经网络构成超短期风电功率预测模型,将

平均影响值(mean influence value, MIV)和主成 分分析(principal components analysis, PCA)方法 相结合,对预测模型进行了优化,降低模型复杂度, 保留原系统的重要信息,并降低模型引入噪声的风 险,使得风电功率预测精度得到显著提高。文献[24] 提出基于鲁棒回归(robust regression, RR)和VMD 的LSTM模型的风电功率预测方法,能够降低风电 功率预测误差。文献[25]利用GRU和VMD相结合的 方式来提升风电功率的预测精度。上述组合模型相 较于单一模型有更好的预测性能,但是与单一模型 一样都没有考虑对预测误差的再分析,导致预测不 稳定。

综上所述,现有的风电功率预测方法很少考虑 预测误差的分析和修正。为了解决此问题,本文 提出一种基于自适应移动平滑(adaptive movement smoothing, AMS)和时间卷积网络(temporal convolutional network, TCN)误差修正的风电功率 预测方法。该方法首先利用VMD和TCN提取风电功 率的时空特性,得到初步预测结果;然后利用AMS 模型对预测误差序列进行自适应平滑处理,降低误差 的波动性;最后利用TCN模型提取预测误差的时间特 性,对初步预测结果进行修正,提高预测的精度和稳 定性。为了验证本文所提模型的泛化能力和稳定性, 采用辽宁双子台和内蒙古克什克腾旗(克旗)两个风 电场的实测数据进行15 min、30 min和1 h时间尺度下 的预测实验。实验表明本文提出的基于AMS和TCN误 差修正的风电功率预测方法有更高精度和稳定的预测 输出。

1 模型基础理论

1.1 变分模态分解

变分模态分解(VMD)是一种基于希尔伯特变 换和维纳滤波理论的自适应、完全非递归模态变分和 信号处理的方法,适用于对复杂度高和非线性强的时 间序列进行平稳化处理,有着良好的噪声鲁棒性,且 相较于经验模态分解(empirical mode decomposition, EMD)能够更加灵活地确定分量数目。

假设输入信号信号*f*(*t*)被分解为*m*个分量 *u_i*(*t*),*i*=1,2,…,*m*,保证分解序列为具有中心频率的 有限带宽的模态分量,同时各模态的估计带宽之和最 小,约束条件为所有模态之和与原始信号相等,则相 应约束变分表达式为 式中: $u_m = \{ u_1, u_2, \dots, u_m \}$ 为分解风电功率信号的各模 态分量; $\omega_m = \{ \omega_1, \omega_2, \dots, \omega_m \}$ 为各模态分量的中心 频率; $\| * \|_2^2$ 为二范数的平方表达式; $\delta(t)$ 为冲激函数; ∂_t 为对时间t的一阶偏导。

为了求解式(1)构造的变分问题,可以通过引 入拉格朗日乘子λ(*t*)和二次罚函数α将其转换为非约束 性变分问题,具体公式如下:

$$L(\lbrace u_{m}\rbrace, \lbrace \omega_{m}\rbrace, \lambda) = \alpha \sum_{m} \left\| \partial_{t} [(\delta(t) + j/\pi t) * u_{m}(t)] e^{-j\omega_{m}t} \right\|_{2}^{2} + \left\| f(t) - \sum_{m} u_{m}(t) \right\|_{2}^{2} + \lambda(t) \left\{ f(t) - \sum_{m} u_{m}(t) \right\}$$
(2)

然后利用交替方向乘子法迭代算法结合Parseval、 Plancherel定理和傅里叶等距变换,优化得到各模态分 量和中心频率,交替寻优迭代后的*u_m、ω_m和λ*的表达 式为

$$\hat{u}_m^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq m} \hat{u}_i^n(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + \alpha(\omega - \omega_m)^2}$$
(3)

$$\omega_m^{n+1} = \frac{\int_0^\infty \omega \left| \hat{u}_m^{n+1}(\omega) \right|^2 \mathrm{d}\omega}{\int_0^\infty \left| \hat{u}_m^{n+1}(\omega) \right|^2 \mathrm{d}\omega} \tag{4}$$

$$\hat{\lambda}^{n+1}(\omega) = \hat{\lambda}^{n}(\omega) - \tau \left(\hat{f}(\omega) - \sum_{m} \hat{u}_{m}^{n+1}(\omega) \right)$$
(5)

式中: τ 为噪声容忍度,满足风电功率信号分解的保 真度; $\hat{u}_m^{n+1}(\omega)$ 、 $\hat{u}_i(\omega)$ 、 $\hat{f}(\omega)$ 和 $\hat{\lambda}(\omega)$ 分别为 $u_m^{n+1}(t)$ 、 $u_i(t)$ 、 f(t)和 $\lambda(t)$ 的傅里叶变换。

1.2 自适应移动平滑

自适应移动平滑(AMS)方法是利用滑窗内序列 的方差对参与平滑的数据进行筛选的一种改进移动平 均平滑法。引入3σ原则排除滑窗范围内离群点,相较 于传统的均值平滑法,改进方法能减少离群点对平滑 的影响,减少平滑后序列与原序列的误差。在确定初 始平滑窗口长度后,AMS能够自适应调节滑窗长度, 有效提取时间序列的不同分布特征,从而准确跟踪原 序列变化趋势,同时实现去噪。算法流程如图3右边 部分所示,具体原理如下。 假设经预测误差序列 $E = \{ e_1, e_2, \dots, e_T \}$,其中T为 序列的长度,移动窗口的长度为N,则[t, t+N]时刻移 动窗口内序列的均值 μ_e 和方差 σ_e^2 可表示为

$$\mu_{\rm e} = \frac{e_{t+1} + e_{t+2} + \dots + e_{t+N}}{N}, t \in [1, T - N] \quad (6)$$

$$\sigma_{\rm e}^{2} = \frac{\sum_{i=l+1}^{l+N} (e_{i} - \mu_{\rm e})^{2}}{N}$$
(7)

利用 μ_{e} 和 σ_{e}^{2} 可将t时刻平滑后的噪声信号表示为

$$\hat{e}_{t} = \frac{\sum_{i=t}^{t+N} f\left(e_{i}, \mu_{e}, \sigma_{e}^{2}\right)}{\sum_{i=t}^{t+N} g\left(e_{i}, \mu_{e}, \sigma_{e}^{2}\right)}$$
(8)

式中: $f(e_i, \mu_e, \sigma_e^2)$ 为滑窗范围内符合3 σ 原则点的误差 值总和, $g(e_i, \mu_e, \sigma_e^2)$ 为滑窗范围内符合3 σ 原则点的个 数总和, 具体可表示为

$$f\left(e_{i}, \mu_{e}, \sigma_{e}^{2}\right) = \begin{cases} e_{i}, \left|e_{i} - \mu_{e}\right| < 3\sigma_{e}^{2} \\ 0, \text{else} \end{cases} \quad i \in [t, t+N] \quad (9)$$

$$g\left(e_{i}, \mu_{e}, \sigma_{e}^{2}\right) = \begin{cases} 1, \left|e_{i} - \mu_{e}\right| < 3\sigma_{e}^{2} \\ 0, \text{else} \end{cases} \quad i \in [t, t+N] \quad (10)$$

1.3 时间卷积网络

时间卷积网络(TCN)模型以卷积神经网络 (convolutional neural networks, CNN)模型为基 础,运用因果卷积(causal convolution)、空洞卷积 (dilated convolution)和残差模块(residual block)对 CNN进行了改进,TCN相比于CNN、LSTM和GRU有 更加轻便的网络结构,且可以根据滤波器大小改变网 络的感受野,更加有利于对时间序列的预测。TCN模 型的原理如下。

设滤波器 $F = \{f_1, f_2, \dots, f_k\}$, 输出序列信息为 $Y = \{y_1, y_2, \dots, y_T\}$, 输入序列为 $S = \{s_1, s_2, \dots, s_T\}$, 其中 $s_i(i=1,2,\dots,T)$ 为列向量, t时刻 s_i 的空洞卷积为

$$F(s_t) = (S *_d F)(s_t) = \sum_{k=1}^{K} f_k \cdot s_{t-d(K-k)}$$
(11)

式中: d为膨胀因子; K表示滤波器大小,感受野的公式为 $R_F = (K-1)d+1$ 。图1给出TCN中k=3的因果与空洞卷积。

TCN模型引入残差模块,以解决深层传统神经网络中梯度爆炸和网络退化的问题。图2给出了TCN模型的残差模块。这种残差结构可以在特征提取过程中避免丢失较多的信息,提高了模型的准确率。



图 1 TCN中的因果卷积与空洞卷积

Fig. 1 Causal convolution and null convolution in TCN



图 2 TCN模型的残差模块 Fig. 2 Residual module of the TCN model

2 算法流程

本文提出的基于AMS-TCN误差修正的风电功率 预测方法的算法流程如图3所示,具体步骤如下。

步骤1:对输入t时刻前的所有原始风电功率序列 P进行预处理,主要包括异常值处理(负值、超出满 载功率值和乱码)和空缺值填补,处理后的风电功率 序列为P'。

步骤2:对P'进行VMD分解,得到主成分序列 F_{IMFs}= {F_{IMF1}, F_{IMF2}, …, F_{IMFM}},本文采用*M*=20,使分 解误差的波动范围在-1.0%~1.0%,分解结果如附录A 所示。

步骤3:利用TCN空间维度上的卷积核提取F_{IMFs}序 列的各分量间的空间特征,时间维度上的卷积核提取 风电功率随时间的变化特性,建立F_{IMFs}输入序列与风 电功率间的映射关系,得到*t*时刻初步预测输出P_{fpre}。

步骤4:利用步骤3训练得到的预测模型,将t时 刻前所有的历史数据作为输入集合,得到预测结果 后计算出t时刻前所有风电功率的误差集合E。

步骤5:利用AMS对预测误差集合*E*进行平滑处理,得到波动更小、更平稳的误差序列*E*'。



图 3 算法流程图 Fig. 3 Algorithm flowchart

步骤6:将E'作为训练集,训练基于TCN网络的误差预测模型,利用t时刻前T个误差值作为该模型的输入得到t时刻误差预测结果E_{rre}。

步骤7:最后将步骤3的预测结果P_{fpre}和步骤6的 预测结果*E_{pre}相加得到1*时刻的最终预测结果。

3 算例分析

3.1 数据来源

本文对辽宁双子台风电场和内蒙古克旗风电场 2019年12月至2020年10月的场站实测数据进行分析, 采样间隔为15 min。共有数据10 000余条,取打乱后 的80%作为训练数据集,其他20%作为测试数据集。

3.2 数据处理

本文所使用的数据存在负值、超满发值、乱码和 空缺值,采用直接置零的方式对负值进行处理,利用 前后两个时刻的风电功率值对超满发值、乱码和空缺 值进行修正或填充。由于不同风力发电站装机容量不 同,发电功率存在差异,为了更好地评价实验结果, 对处理后的数据进行归一化处理,具体方法为

$$P''_{i} = \frac{P'_{i} - \min(P')}{\max(P') - \min(P')}$$
(12)

式中: P' 为第i个处理后的风电功率值。

3.3 评价指标

本文采用4种指标对模型的性能进行评价,包括 平均绝对误差(mean absolute error, MAE)和平均相 对误差(mean relative error, MRE)以及判断两模型 间性能提升度的指标P_{MAE}和P_{MRE},下面给出具体公式:

$$I_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^{n} |y_i - \hat{y}_i|$$
(13)

$$I_{\rm MRE} = \frac{1}{n} \sum_{i=1}^{n} \left| \frac{y_i - \hat{y}_i}{y_i} \right|$$
(14)

$$P_{\rm MAE} = \frac{M_{2,\rm MAE} - M_{1,\rm MAE}}{M_{2,\rm MAE}}$$
(15)

$$P_{\rm MRE} = \frac{M_{2,\rm MRE} - M_{1,\rm MRE}}{M_{2,\rm MRE}} \tag{16}$$

式中: y_i 为i时刻真实值; \hat{y}_i 为i时刻预测值; M_{MAE} 为模型的MAE指标; M_{MRE} 为模型的MRE指标; M_1 和 M_2 将在后文运用中具体给出。

3.4 单一模型对比实验

本文通过对比LSTM、CNN-LSTM、TCN模型在 3种不同时间尺度下(15 min, 30 min, 1 h)的功率 预测性能,来验证TCN模型在风电功率预测中的优越 性。两风电场实验结果如图4所示,各单一模型的预 测性能指标如表1所示。

世刊	时间口度	辽宁双子台风电场				内蒙古克旗风电场			
快空	的间代度	$I_{\rm MAE}/{ m MW}$	$I_{\rm MRE}$	$P_{\rm MAE}$	$P_{\rm MRE}$	I _{MAE} /MW	I _{MRE}	$P_{\rm MAE}$	$P_{\rm MRE}$
LSTM (M_2)	15 min	1.690 8	2.621 0×10 ⁻³	6.3%	89.5%	1.720 5	0.709 4×10 ⁻³	5.4%	79.8%
	30 min	2.071 5	3.003 9×10 ⁻³	1.7%	78.3%	2.228 2	0.666 1×10 ⁻³	3.4%	63.3%
(***2)	1 h	2.761 1	3.507 3×10 ⁻³	4.3%	43.9%	3.386 4	3.260 8×10 ⁻³	7.9%	89.2%
CNN-LSTM	15 min	2.200 9	1.362 0×10 ⁻³	28.0%	79.7%	3.796 0	3.771 1×10 ⁻³	57.1%	96.2%
	30 min	2.481 8	4.815 3×10 ⁻³	18.0%	86.4%	2.259 3	$0.860.2 \times 10^{-3}$	4.1%	71.6%
(2)	1 h	3.305 9	3.835 3×10 ⁻³	20.1%	48.7%	3.696 1	$0.858.9 \times 10^{-3}$	3.4% 7.9% 57.1% 4.1% 15.6%	59.0%
$TCN(M_1)$	15 min	1.584 8	$0.276 \ 3 \times 10^{-3}$			1.628 0	0.143 4×10 ⁻³		
	30 min	2.035 6	$0.652 8 \times 10^{-3}$			2.152 4	0.244 3×10 ⁻³		
	1 h	2.642 8	1.966 5×10 ⁻³			3.118 3	$0.353 \ 0 \times 10^{-3}$		

表 1 各单一模型预测性能指标 Table 1 Predictive performance metrics of each single model

从表1中可以看出,TCN模型在MAE和MRE指标 上的表现均优于其他两个模型,两个风电场3种不同 时间尺度的MAE均值分别为1.606 4 MW、2.094 0 MW 和2.8806MW, MRE均值分别为0.2099×10⁻³、0.4486 ×10⁻³和1.1598×10⁻³,相较于LSTM和CNN-LSTM两 种模型,MAE提升度均在1.5%以上,MRE提升度均



Fig. 4 Prediction curves of single model of two wind farms

在40.0%以上。TCN模型引入的因果卷积和空洞卷积, 能够使其有更广的感受野,更有利于挖掘风电功率的 变化特性,以提高风电功率的预测精度。

3.5 加入VMD后的组合模型对比实验

为了验证VMD对提升风电功率预测精度的效果, 本文运用VMD-LSTM、VMD-CNN-LSTM和VMD-TCN模型与3.4节中3种单一模型进行对比实验。将 VMD-LSTM、VMD-CNN-LSTM和VMD-TCN作为 *M*₁, LSTM、CNN-LSTM和TCN模型作为*M*₂。实验结 果如图5所示,各模型的预测性能指标如表2所示。

通过对表2所得实验结果进行分析可知,加入 VMD能够有效降低LSTM、CNN-LSTM和TCN模型 在3种不同时间尺度下预测结果的MAE和MRE。加入 VMD的组合预测模型相较于未加入VMD的单一预测 模型,其MAE提升度均在40.0%以上,MRE提升度 在15.0%以上。VMD给预测性能带来巨大的提升主要 依赖于其能够分解得到更加有利于预测的中心频率对 称的平稳信号分量,能够有效减小原风电功率噪声对 预测的影响。另外VMD-TCN模型在两风电场下相较 于VMD-LSTM和VMD-CNN-LSTM模型有着更好的 预测性能:VMD-TCN模型在3种不同时间尺度下预 测结果的MAE均值分别为0.2750MW、0.3891MW 和0.7932MW,优于VMD-CNN-LSTM的0.8011MW、 1.2032MW和1.6029MW,以及VMD-LSTM的 0.4099MW、0.5106MW和1.0325MW;VMD-TCN 模型在3种不同时间尺度下预测结果的MRE均值分 别为0.0852×10⁻³、0.2991×10⁻³和0.6416×10⁻³,优 于VMD-CNN-LSTM的0.2711×10⁻³、0.9095×10⁻³ 和2.1076×10⁻³,以及VMD-LSTM的0.6082×10⁻³、 0.4818×10⁻³和0.9238×10⁻³。



Fig. 5 Prediction curves of the combined VMD model of two wind farms

	表 2 VMD组合模型预测性能指标	
Table 2	Predictive performance metrics of combined VMD mo	odel

			1						
枯刑	时间日度	辽宁双子台风电场				内蒙古克旗风电场			
侯空	的间代度	$I_{\rm MAE}/{ m MW}$	I_{MRE}	P_{MAE}	P_{MRE}	I _{MAE} /MW	I_{MRE}	电场 P _{MAE} 73.8% 78.4% 72.5% 79.3% 48.0% 62.9% 83.0% 85.0% 82.6%	P_{MRE}
	15 min	0.368 3	$0.470.7 \times 10^{-3}$	78.2%	82.0%	0.451 5	I_{MRE} P_{MAE} 0.745 6×10 ⁻³ 73.8% 0.223 3×10 ⁻³ 78.4% 0.833 7×10 ⁻³ 72.5% 0.096 3×10 ⁻³ 79.3% 0.237 8×10 ⁻³ 48.0% 0.991 5×10 ⁻³ 62.9%	-5.1%	
VMD-LSTM (M_1)	30 min	0.539 6	0.740 3×10 ⁻³	74.0%	75.4%	0.481 6	0.223 3×10 ⁻³	78.4%	66.5%
(1)	1 h	1.133 2	1.013 8×10 ⁻³	59.0%	71.1%	0.931 7	$0.8337 \times 10^{-3} \qquad 72.5\%$	74.4%	
VMD-CNN-	15 min	0.817 4	0.445 9×10 ⁻³	40.0%	67.3%	0.784 8	0.096 3×10 ⁻³	79.3%	97.4%
LSTM	30 min	1.231 2	$1.581.2 \times 10^{-3}$	74.4%	67.2%	1.175 2	0.237 8×10 ⁻³	48.0%	72.4%
(M_1)	1 h	1.836 2	3.223 6×10 ⁻³	52.1%	15.9%	1.369 5	0.991 5×10 ⁻³	62.9%	-15.4%
VMD-TCN (M ₁)	15 min	0.272 6	0.111 8×10 ⁻³	82.8%	59.5%	0.277 3	0.058 6×10 ⁻³	83.0%	59.1%
	30 min	0.456 6	$0.525 \ 9 \times 10^{-3}$	77.6%	19.4%	0.321 6	0.072 3×10 ⁻³	85.0%	70.4%
	1 h	1.042 3	1.161 0×10 ⁻³	60.6%	41.0%	0.544 1	0.122 1×10 ⁻³	82.6%	65.4%

3.6 VMD-TCN-AMS-TCN预测模型实验

本文采用AMS-TCN模型对预测误差做进一步分析,形成本文的基于AMS-TCN误差修正的风电功率 组合预测模型VMD-TCN-AMS-TCN,以提高风电功 率预测的精度和稳定性。利用VMD-TCN-AMS-TCN 模型与其他模型进行对比实验,将VMD-TCN-AMS-TCN模型作为*M*₁,3.5节中表现最好的VMD-TCN模型

表 3

作为*M*₂。实验结果如图6所示,模型的预测性能指标如表3所示。

由表3可知,加入AMS-TCN模块进行预测误差修 正后,能够有效降低3种时间尺度下的MAE和MRE, 其MAE的提升度均在50.0%以上,MRE的提升度均在 10.0%以上。实验结果表明AMS-TCN能够有效提取预 测误差的时间特性,减少预测误差的同时增加预测的 稳定性。

Table 3 Predictive performance metrics of VMD-TCN-AMS-TCN model									
模型	时间尺度	辽宁双子台风电场				内蒙古克旗风电场			
		I _{MAE} /MW	I _{MRE}	$P_{\rm mae}$	$P_{\rm MRE}$	$I_{\rm MAE}/{ m MW}$	$I_{\rm MRE}$	$P_{\rm mae}$	$P_{\rm MRE}$
	15 min	0.016 9	0.073 9×10 ⁻³	93.8%	33.9%	0.068 9	0.030 5×10 ⁻³	75.2%	48.0%
VMD-TCN- AMS-TCN (M_1)	30 min	0.061 1	0.141 4×10 ⁻³	86.6%	73.1%	0.137 6	0.063 6×10 ⁻³	57.2%	12.0%
	1 h	0.412 6	0.548 1×10 ⁻³	60.4%	52.8%	0.250 2	0.100 4×10 ⁻³	54.0%	17.8%

VMD-TCN-AMS-TCN模型预测性能指标





4 结论

为了解决传统模型预测风电功率稳定性和预测精 度较低的问题,提出一种基于AMS-TCN误差修正的 风电功率预测方法。通过和其他模型的对比实验,验 证了本文所提预测方法优势。主要结论如下。

1)将TCN与LSTM和CNN-LSTM深度学习模型进行对比,TCN模型预测结果的MAE提升度在1.5%以上, MRE提升度在40.0%以上,验证了TCN模型对风电功率多时间尺度预测的准确性。

2) VMD能够分解得到更加有利于预测的中心频 率对称的平稳信号分量,能够有效减小原风电功率噪 声对预测的影响,提高预测精度。与未加入VMD的 模型相比,VMD预测结果的MAE提升度在40.0%以上, MRE提升度在15.0%以上。

3) AMS-TCN模型能够有效提取预测误差的时间特性,有利于提高预测的精度和稳定性。相较于VMD-TCN模型,其MAE提升度在50.0%以上,MRE提升度在10.0%以上。

参考文献

- 张丽英,叶廷路,辛耀中,等.大规模风电接入电网的相 关问题及措施[J].中国电机工程学报,2010,30(25):1-9. ZHANG Liying, YE Tinglu, XIN Yaozhong, et al. Problems and measures of power grid accommodating large scale wind power[J]. Proceedings of the CSEE, 2010, 30(25): 1-9(in Chinese).
- [2] 赵福林,俞啸玲,杜诗嘉,等. 计及需求响应的含大规模风电并网下电力系统灵活性评估[J]. 电力系统保护与控制,2021,49(1):42-51.
 ZHAO Fulin, YU Xiaoling, DU Shijia, et al. Assessment on flexibility of a power grid with large-scale wind farm integration considering demand response[J]. Power System Protection and Control, 2021, 49(1): 42-51(in Chinese).
- [3] 郭树锋,李威,胡珊珊,等.考虑风机一次调频的风电高 占比电网机组组合[J].电力工程技术,2020,39(4):61-67.
 GUO Shufeng, LI Wei, HU Shanshan, et al. Unit commitment considering the primary frequency regulation of wind turbine in grids with a high proportion of wind power[J]. Electric Power Engineering Technology, 2020, 39(4): 61-67(in Chinese).
- [4] 汪欣,蔡旭,李征.结合交叉局部异常因子和注意力机 制的超短期风电功率预测方法[J].电力系统保护与控制, 2020,48(23):92-99.
 WANG Xin, CAI Xu, LI Zheng. Ultra-short-term wind power

forecasting method based on a cross LOF preprocessing algorithm and an attention mechanism[J]. Power System Protection and Control, 2020, 48(23): 92-99(in Chinese).

- [5] 范高锋, 裴哲义, 辛耀中. 风电功率预测的发展现状与展望[J]. 中国电力, 2011, 44(6): 38-41.
 FAN Gaofeng, PEI Zheyi, XIN Yaozhong. Wind power prediction achievement and prospect[J]. Electric Power, 2011, 44(6): 38-41(in Chinese).
- [6] LIU Z K, JIANG P, ZHANG L F, et al. A combined forecasting model for time series: application to short-term wind speed forecasting[J]. Applied Energy, 2020, 259: 114137.
- [7] 冯双磊,王伟胜,刘纯,等.风电场功率预测物理方法研究[J].中国电机工程学报,2010,30(2):1-6.
 FENG Shuanglei, WANG Weisheng, LIU Chun, et al.
 Study on the physical approach to wind power prediction[J].
 Proceedings of the CSEE, 2010, 30(2):1-6(in Chinese).
- [8] EL-FOULY T H M, EL-SAADANY E F, SALAMA M M A. One day ahead prediction of wind speed using annual trends[C]//2006 IEEE Power Engineering Society General Meeting. June 18-22, 2006, Montreal, QC, Canada. IEEE, 2006.
- [9] 薛禹胜,郁琛,赵俊华,等.关于短期及超短期风电功率 预测的评述[J].电力系统自动化,2015,39(6):141-151.
 XUE Yusheng, YU Chen, ZHAO Junhua, et al. A review on short-term and ultra-short-term wind power prediction[J].
 Automation of Electric Power Systems, 2015, 39(6): 141-151(in Chinese).
- [10] 刘帅,朱永利,张科,等.基于误差修正ARMA-GARCH 模型的短期风电功率预测[J].太阳能学报,2020,41(10): 268-275.

LIU Shuai, ZHU Yongli, ZHANG Ke, et al. Short-term wind power forecasting based on error correction arma-garch model[J]. Acta Energiae Solaris Sinica, 2020, 41(10): 268-275(in Chinese).

- [11] 曹俊波,周任军,邓学华,等.考虑优化ARIMA模型差分 次数的风功率预测[J]. 电力系统及其自动化学报,2019, 31(1): 105-111.
 CAO Junbo, ZHOU Renjun, DENG Xuehua, et al. Wind power forecast considering differential times of optimal ARIMA model[J]. Proceedings of the CSU-EPSA, 2019, 31(1): 105-111(in Chinese).
- [12] 张立栋,李继影,吴颖,等.不同时间分辨率的风功率时间序列ARIMA模型预测[J].中国电力,2016,49(6):176-180.

ZHANG Lidong, LI Jiying, WU Ying, et al. ARIMA model forecast for wind power time series with different temporal resolutions[J]. Electric Power, 2016, 49(6): 176-180(in Chinese).

[13] 刘爱国,薛云涛,胡江鹭,等.基于GA优化SVM的风电功率的超短期预测[J].电力系统保护与控制,2015,43(2): 90-95.

LIU Aiguo, XUE Yuntao, HU Jianglu, et al. Ultra-short-term wind power forecasting based on SVM optimized by GA[J]. Power System Protection and Control, 2015, 43(2): 90-95(in Chinese).

- [14] 刘家敏,李聪睿,周志浩,等.基于WD-CS-SVM的超短期风电功率组合预测[J].电力工程技术,2019,38(5):24-29.
 LIU Jiamin, LI Congrui, ZHOU Zhihao, et al. Combination ultra-short-term prediction of wind power based on WD-CS-SVM[J]. Electric Power Engineering Technology, 2019, 38(5):24-29(in Chinese).
- [15] LAHOUAR A, BEN HADJ SLAMA J. Hour-ahead wind power forecast based on random forests[J]. Renewable Energy, 2017, 109: 529-541.
- [16] 周玮,钟佳成,孙辉,等.基于隐马尔可夫模型的日内风 电功率预测误差区间滚动估计[J].电力系统自动化,2018, 42(21):90-95.

ZHOU Wei, ZHONG Jiacheng, SUN Hui, et al. An interval rolling estimation method for daily wind power forecast errors based on hidden Markov model[J]. Automation of Electric Power Systems, 2018, 42(21): 90-95(in Chinese).

- [17] XI L, WU J N, XU Y C, et al. Automatic generation control based on multiple neural networks with actor-critic strategy[J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 32(6): 2483-2493.
- [18] 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.
 LI Bing, ZHANG Yan, LIU Shi. Wind speed short term prediction study based on LSTM[J]. Computer Simulation, 2018,35(11):456-461(in Chinese).
- [19] LI C S, TANG G, XUE X M, et al. Short-term wind speed interval prediction based on ensemble GRU model[J]. IEEE Transactions on Sustainable Energy, 2020, 11(3): 1370-1380.
- [20] 钱政, 裴岩, 曹利宵, 等. 风电功率预测方法综述[J]. 高电压技术, 2016, 42(4): 1047-1060.
 QIAN Zheng, PEI Yan, CAO Lixiao, et al. Review of wind power forecasting method[J]. High Voltage Engineering, 2016, 42(4): 1047-1060(in Chinese).
- [21] 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(in Chinese).
- [22] 刘云凯,彭显刚,袁浩亮,等.基于VMD与改进QRGRU的 超短期风电功率概率预测[J].电力工程技术,2021,40(3): 72-77.

LIU Yunkai, PENG Xiangang, YUAN Haoliang, et al. Ultrashort-term wind power probability prediction based on VMD and improved QRGRU[J]. Electric Power Engineering Technology, 2021, 40(3): 72-77(in Chinese).

- [23] 徐龙博, 王伟, 丁煜函, 等. 基于MIV-PCA的超短期风电功 率预测模型优化[J]. 电力工程技术, 2019, 38(5): 107-113. XU Longbo, WANG Wei, DING Yuhan, et al. Optimization of ultra-short-term wind power predicting model based on MIV-PCA[J]. Electric Power Engineering Technology, 2019, 38(5): 107-113(in Chinese).
- [24] 史加荣,赵丹梦,王琳华,等.基于RR-VMD-LSTM的短期风电功率预测[J].电力系统保护与控制,2021,49(21):
 63-70.

SHI Jiarong, ZHAO Danmeng, WANG Linhua, et al. Shortterm wind power prediction based on RR-VMD-LSTM[J]. Power System Protection and Control, 2021, 49(21): 63-70(in Chinese).

[25] WANG R H, LI C S, FU W L, et al. Deep learning method based on gated recurrent unit and variational mode decomposition for short-term wind power interval prediction[J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 31(10): 3814-3827.

收稿日期:2021-08-18;修回日期:2021-09-22。 作者简介:

孙蓉

孙蓉 (1979), 女, 硕士, 研究 员级高级工程师, 主要从事电力系统 分析、新能源技术领域的生产科研工 作。通信作者, E-mail: 49958045@ qq.com。

李强 (1981),男,博士,研 究员级高级工程师,研究方向为新 能源发电及电力系统分析,E-mail:

35830342@qq.com。

罗海峰 (1997), 男, 硕士研究生, 研究方向为新能 源功率预测, E-mail: lhf19970718@163.com。

窦迅(1980), 女, 副教授, 研究方向为新能源功率 预测, E-mail: dxnjut@njtech.edu.cn。

邓叶航 (1999), 男, 硕士研究生, 研究方向为新能 源功率预测, E-mail: 2367132582@qq.com。

(责任编辑 李锡)



附录A VMD结果

Fig. A1 VMD of wind power sequence of wind farm in Hexigten Banner, Inner Mongolia

100

^{采样点} 内蒙古克旗风电场风电功率序列VMD示意图

125

150

175

200

75

Ó

25

50

图 A1



Fig. A2 VMD of wind power sequence of wind farm in Shuangzitai, Liaoning