[文章编号] 1003－4684(2025)02-0017-05

基于 VMD-BIGRU 与误差修正的风电功率预测

付 波[1]，聂兴宇[1,2]，赵熙临[1]，王诗雯[1]

(1 湖北工业大学电气与电子工程学院，湖北 武汉 430068；2 国网冀北电力有限公司唐山供电公司，河北 唐山 063000)

[摘 要] 针对风能的波动性和间歇性问题，提出了一种基于 VMD-BIGRU 与误差修正的风电功率预测模型。首先，使用变分模态分解(VMD)与样本熵(SE)结合方法分解风电时间序列；然后，使用双向门控循环单元(BIGRU)模型来预测风电的每个子序列并叠加得到初步预测结果；最后，构建基于时间卷积网络(TCN)的误差修正模型，对初步预测结果进一步优化。利用风电场的实际风电数据进行分析，结果表明所提方法具有更高的预测性能。

[关键词] 变分模态分解；双向门控循环单元；时间卷积网络；风电功率预测；误差修正

[中图分类号] TM614 [文献标识码] A

近年来，随着风电并网规模的扩大，风力发电正逐步向世界主流能源方向发展[1]。然而，风能的随机性和不确定性给电力系统的经济运行和安全调度带来严峻的影响。因此，高精度、可靠的预测模型受到了全世界的广泛关注[2]。

目前，国内外学者针对风电功率预测问题进行了广泛的研究，其中一种突出的预测方法是采用信号处理技术与人工智能模型结合，通过信号处理来消除数据的非平稳性，解决了单一的人工智能模型面对高度复杂性风电数据时预测精度不满足要求的问题。例如，文献[3]采用 VMD 与 SSA 组合对风电序列分解后，分别通过 ARIMA 与 LSTM 进行预测，有效提升了预测精度。文献[4]提出一种改进 VMD 的 GA-ANN 的短期风速预测模型，借助遗传算法的全局优化能力，对 BP 神经网络的初始权值和阈值进行优化，提高了神经网络的预测性能，但 VMD 的分解模态数对预测结果有较大影响。文献[5]中提出了 CEEMD 与 WOA 算法优化 KELM 的新型混合预测框架，能够以较小的重构误差降低预测的复杂度。文献[6]使用 CEEMDAN 和辛几何模态分解二次分解方法对风速和历史功率进行分解，并使用 PSO 对 BIGRU 进行优化，从而确定最优隐层节点数和最佳的网络权值，但忽略了气象变量与风速在时域和频域上的耦合关系。文献[7]使用最先进的时间卷积网络(TCN)并结合其它当地变量对风电功率进行预测，证明了除风速和风向外，其它变量(如地表温度、相对湿度、地表热通量和空气密度)对于预测风能的重要性。上述可知，由于风电信号分解与预测模型精度误差存在的一些问题，研究中所得的预测结果有待进一步精进。

为了提高风电预测的准确性，本文提出了一种新的 VMD-BIGRU 混合方法用于短期风电功率预测。首先，通过计算 SE 实现 VMD 最优预设参数 K 的选择；然后，引入 BIGRU 网络学习风电数据的前后信息完成初步预测；最后，使用 MIC 方法进行输入特征选择，构建基于 TCN 的误差修正模型。

1 研究方法

1.1 数据处理方法

1.1.1 变分模态分解 VMD 是一种自适应的、可预设尺度的信号分解技术[8]，可以将信号分解成数个有限带宽的固有模态(IMF)[9]，克服了传统递归分解算法存在的末端效应等问题，其分解过程主要分为变分约束问题的构造和求解两部分。

1)构造变分问题 假设原始信号通过数个带限本征模函数构成，通过构造使得 IMF 分量总带宽之和最小的公式，求使所有 $u_k(t)$ 的估计带宽之和取最小值时的解：

$$\min_{\{u_k\},\{\omega\}} = \left\{\sum_k \left\| \partial_t \left[(\delta(t)+\frac{j}{\pi t} * u_k(t))\exp(-j\omega_k t)\right]\right\|^2\right\} \quad (1)$$

$$\text{s.t}\sum_k u_k(t) = f(t) \quad (2)$$

[收稿日期] 2023－02－05
[基金项目] 湖北省重点研发计划项目(2021BAA193)
[第一作者] 付 波(1973－)，男，湖北武汉人，工学博士，湖北工业大学教授，研究方向为图像处理和智能控制。
[通信作者] 赵熙临(1968－)，男，山东郓城人，工学博士，湖北工业大学教授，研究方向为电力系统优化与控制。

式中：∂_t 代表时间的导数，$\delta(t)$ 代表脉冲信号函数，j 代表虚数，$*$ 代表卷积计算的符号，$u_k(t)$ 代表 IMF 分量，ω_k 代表假设频率，$f(t)$ 代表原始信号。

2)变分问题求解　在构造好变分问题之后，引入二次惩罚因子 α 和拉格朗日乘子 $\lambda(t)$ 将上述约束变分问题转变为无约束变分问题：

$$\mathcal{L}(\{u_k\},\{\omega_k\},\lambda)=\alpha\sum_k\left\|\partial_t\left[(\delta(t)+\frac{j}{\pi t}*u_k(t))\exp(-j\omega_k t)\right]\right\|_2^2+\left\|f(t)-\sum_k u_k(t)\right\|_2^2+\langle\lambda(t),f(t)-\sum_k u_k(t)\rangle \quad (3)$$

引入拉格朗日算子可以将约束性问题转变为非约束性问题，保障了其严格约束性。此外，通过二次惩罚项使得高斯噪声产生的影响大大减小。在变分问题转换完成后，会通过乘法器的交替方向法（ADMM）调节各模态及其中心频率，交替更新 u_k^{n+1}、ω_k^{n+1} 和 λ^{n+1}，直至变分问题得到解决，得到最优的无约束优化问题的鞍点。

1.1.2　分解次数 K 的选择　样本熵是一种基于近似熵改进用于评估时间序列复杂度的方法，与数据长度无关，一致性更强。时间序列的自相似性越高，样本熵值越小。可表示为：

$$\mathrm{SampEn}(m,r,n)=\ln B^m(r)-\ln B^{m+1}(r) \quad (4)$$

式中：r 为相似度容差，m 为嵌入维度，B 为序列自相似概率。

在使用 VMD 分解之前需要预先设置参数 K。当分解次数 K 较小时，可能导致子序列中混入其它干扰项，即在同一个 IMF 中出现多个分量，甚至某个分量无法提取和分解。当 K 值合适时，子序列的样本熵变小，达到最佳分解。此后，随着 K 值的增加，样本熵值逐渐趋于稳定。当分解次数 K 较大时，可能导致模态混合。因此，为了防止过度分解，本文将趋于平滑的转折点作为 VMD 的分解次数。

1.2　双向门控循环单元

BIGRU 是 GRU 的改进。对于 BIGRU 的每个时间，它将提供两个相反方向的 GRU 输入，但两个方向的 GRU 不直接连接，输出由两个单向 GRU 决定。BIGRU 模型对非线性时间序列数据具有更好的预测性能。BIGRU 的结构如图 1 所示。

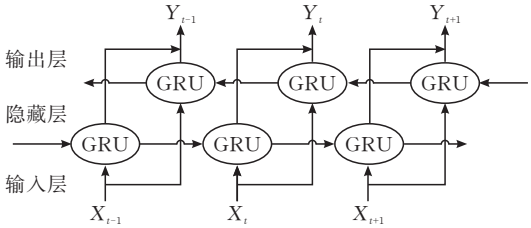


图 1　BIGRU 网络结构

1.3　时间卷积网络误差修正模型

1.3.1　时间卷积网络　TCN 是一种由因果扩张卷积和残差模块组成的新型神经网络，对时间序列的处理和分析非常有效。

因果扩张卷积如图 2 所示，图中给出了扩张因子 $d=1,2,4$ 和滤波器大小 $k=3$ 的示例。由图可以看出，输出序列的感受野大小通过 d 和 k 来调整且扩张因子 d 随着网络深度的增加呈指数式增加，通过灵活调整感受野，可以充分考虑风电序列的时域特征。

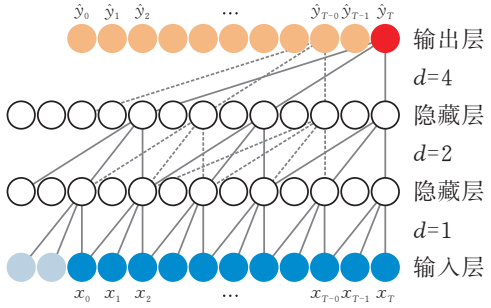


图 2　因果扩张卷积

残差模块如图 3 所示，在残差块中，TCN 由两层扩张因果卷积、非线性函数以及残差连接操作组成。因此使用整流线性单元 ReLU 作为激活函数，非线性函数采用批归一化用于卷积滤波器的正则化，为了防止模型过拟合，加入 Droput 层。

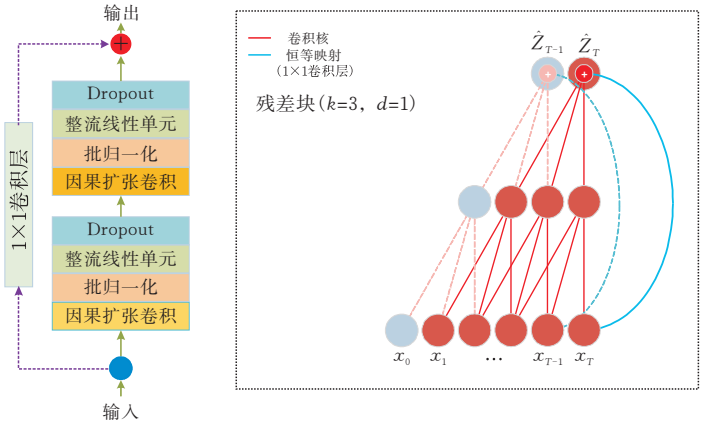


图 3　残差模块

1.3.2　最大互信息系数　互信息是信息论的一种信息度量方式，用于表征变量间相互依赖的程度。互信息具体定义如下：

$$MI(X;Y)=\sum_{y\in Y}\sum_{x\in X}p(x,y)\log\left(\frac{p(x,y)}{p(x)p(y)}\right) \tag{5}$$

式中：$p(x)$ 和 $p(y)$ 分别表示 X 和 Y 的边缘密度函数，$p(x,y)$ 为 X 和 Y 的联合密度函数。

将 X 和 Y 构成的散点图进行网格化，计算不同网格下最大值互信息值并归一化，最大互信息系数 MIC 则表示为不同尺度下最大值互信息值，如：

$$MIC(X;Y)=\max_{|X|*|Y|<B}\frac{\max\limits_{\text{不同网格}}MI(x;y)}{\log\min(|X|,|Y|)} \tag{6}$$

式中：默认设置为数据总量的 0.6 次方。

1.3.3　误差修正模型　由于在模型预测过程中产生的误差导致预测精度下降，为进一步提升预测模型精度，提出了基于 TCN 误差预测的修正方法。首先对原始风电功率序列 $x(t)=x(1),x(2),\cdots x(n)$，使用预测方法进行预测得到初步预测结果 $\hat{x}(t)=\hat{x}(1),\hat{x}(2),\cdots\hat{x}(n)$，则初步预测的输出误差序列为 $e(t)=x(t)-\hat{x}(t)$，在预测误差序列 $e(t)$ 时，采用最大相关系数法作为衡量各变量与风电预测误差相关性的指标，选择与风电功率相关性强的变量作为修正模型的输入。时间卷积网络可以结合历史信息挖掘影响风特性的因素与功率预测残差之间的潜在关系，得到对应的误差修正结果 $\hat{e}(t)=\hat{e}(1),\hat{e}(2),\cdots\hat{e}(n)$，利用误差修正的结果和初步预测的结果进行叠加得到最终预测结果 $y(t)=\hat{x}(t)+\hat{e}(t)$。

2　基于 VMD-BIGRU 与误差修正的风电功率预测框架

基于 VMD-BIGRU 与误差修正的风电功率预测总体框架如图 4 所示。

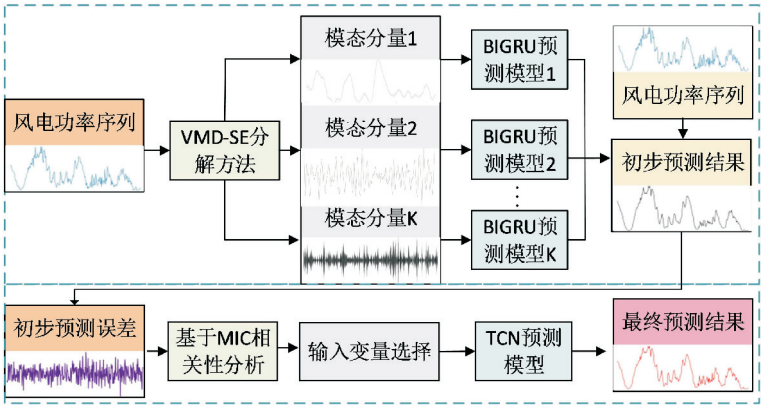


图 4　VMD-BIGRU 与误差修正的风电功率预测框架

详细步骤如下：

1）采用 VMD 算法将原始风电功率序列分解为多个不同中心子序列，并分别计算每个子序列的样本熵；

2）比较不同 K 值的样本熵，选取样本熵趋于平滑的转折点作为最终 VMD 预设 K 值，以增强可预测性；

3）使用 MIC 方法风电功率数据进行特征选择，并计算最佳延迟阶数，以降低修正模型输入数据规模；

4）利用 BIGRU 网络来预测分解后子序列，将各分量的预测结果进行线性叠加得到初步预测结果；

5）利用 BIGRU 模型的预测误差序列与数据集中经 MIC 筛选的重要特征作为 TCN 模型的输入，进行误差修正，得到最终预测结果；

6）使用平均绝对误差（MAE）、平均绝对百分误差（MAPE）和均方根误差（RMSE）作为标准来定量评价所提出的混合模型的性能。

3　算例分析

3.1　数据介绍

为了验证预测模型的有效性，本文选取了我国西北某风电场的风电数据进行实验。风电场每 10 min收集一次风电数据，每天可收集 144 个数据。本实验选取了 30 天的风电数据，共计 4320 个数据点，训练集与测试集比例为 8∶2。图 5 为该风电场 30 天风电分布曲线。

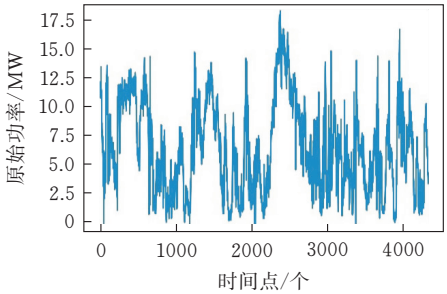


图 5　原始风电功率序列

3.2 VMD-SE 分解结果

对风电原始序列进行适当的分解可有效提高预报性能。本文利用 VMD 对原始风电功率序列进行分解，在分解前，应选择合适的 VMD 分解数。本文采用样本熵值来判断 VMD 的分解数。首先，在不同 K 值下，通过 VMD 对原始风电功率进行分解并计算它们的样本熵值。接下来，按顺序比较不同 K 值的样本熵，以获得适当的分解次数。不同 K 值子序列的样本熵结果如图 6 所示。

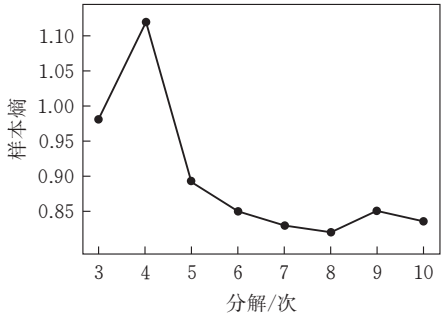


图 6 不同 K 值的样本熵

从图 6 可以看出，当 K 值较小时，样本熵值较大，说明风速序列分解不足，导致模态混叠现象和子模型的复杂性。序列变大，当 $K=6$ 时，样本熵值变小，然后处于稳定状态，说明风速序列分解是合适的。因此本实验选用 $K=6$ 对风电数据进行 VMD 分解。分解结果如图 7 所示。

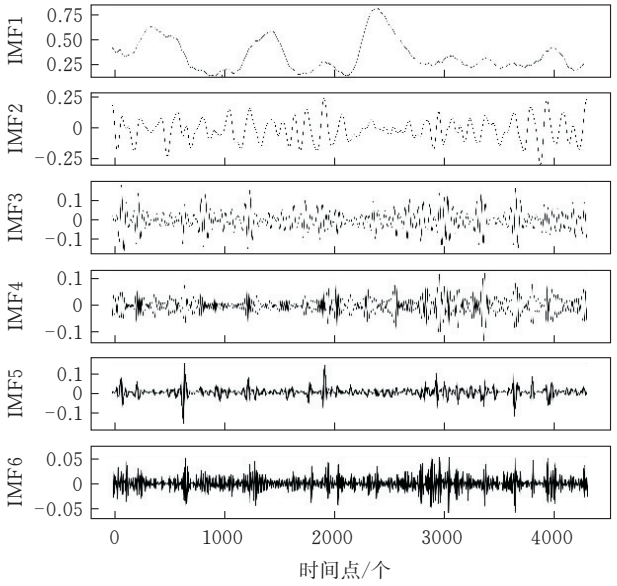


图 7 风电序列 VMD 分解

3.3 MIC 特征选择分析

输入特征的选择对基于人工智能的模型的预测性能具有重要意义。风电数据全部维度的输入特征不仅产生过多参数，导致网络训练慢，还会影响模型预测精度。因此本文使用 MIC 对风电数据集中影响功率因素进行特征选择，用于在使用 TCN 预测残差时选择模型的输入特征。图 8 展示为经 MIC 计算选择后与风电功率相关性最高的 8 个变量，从左至右依次为：1 风速、2 发电机转速、3 叶轮转速、4 齿轮箱油温、5 有功功率、6 发电机发电量、7 风向角、8 机舱温度。

此外，在风电功率预测中，建模输入特征的滞后阶数与模型预测精度有直接联系，随着滞后阶数的增加，历史功率与当前功率的相关性呈递减趋势，如图 8 所示，因此本文选用 MIC 大于 0.6 的采样时刻作为预测模型的输入。

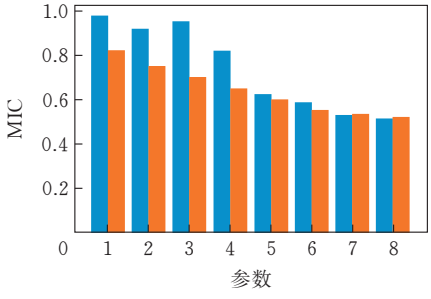


图 8 各参数与风电功率 MIC

3.4 预测结果分析

3.4.1 实验 1：数据预处理方法评估 在实验 1 中，为研究数据预处理方法对预测效果提升的影响。本实验分别选取基于时域数据分解的 EMD 和 EEDM 方法与基于时频域的 WD 方法进行比较，这些模型之间的唯一区别是在数据预处理阶段应用不同的预处理方法。实验结果如表 1 和图 9 所示。

表 1 不同数据处理评价指标

方法	MAPE	MAE	RMSE
不使用分解模型	10.527	0.776	0.935
基于 EMD 模型	6.671	0.318	0.366
基于 EEMD 模型	6.439	0.305	0.353
基于 WD 模型	7.062	0.324	0.385
本文所提模型	5.156	0.223	0.279

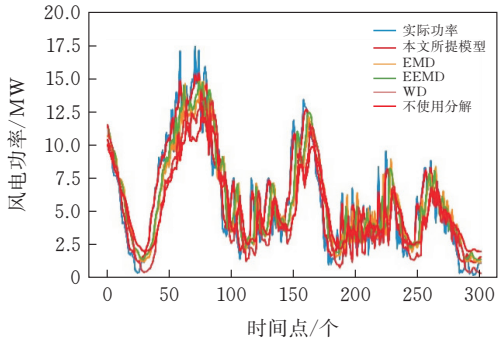


图 9 不同数据处理的功率预测

1）比较 VMD 与其它数据预处理技术。结果表明，基于 VMD 的模型比其它比较模型具有更好的能力。其中，基于 VMD 模型的 MAPE 值为 5.156%，相较于其它数据处理技术提高了 1 到 5 个百分点，说明了 VMD 方法在数据预处理方面的优

异性能。观察图 9 可以看出，本文所提的预测模型在预测时的拟合值与真实值更贴近，不仅预测精度变高，更能有效学习风电时间序列的趋势。

2）比较未经数据预处理的组合模型与其它预处理模型。结果表明，无论采用何种预处理方法，模型的预测精度都有很大提高，其主要原因是数据经分解后，能够有效提升模型挖掘风电序列深度特征能力，满足更高的精度要求。

3.4.2　实验 2：模型预测性能评估　在实验 2 中，为验证初步预测模型与误差修正模型的性能。本实验不采用误差修正的 BIGRU、VMD-LSTM、VMD-GRU、VMD-TCN、VMD-BIGRU 与本文所提模型进行对比。预测结果如表 2 和图 10 所示。

表 2　不同模型评价指标

方法	MAPE	MAE	RMSE
BIGRU	13.872	0.829	0.963
VMD-LSTM	7.821	0.331	0.413
VMD-GRU	7.855	0.346	0.429
VMD-TCN	7.585	0.325	0.396
VMD-BIGRU	6.359	0.294	0.358
本文所提模型	5.156	0.223	0.279

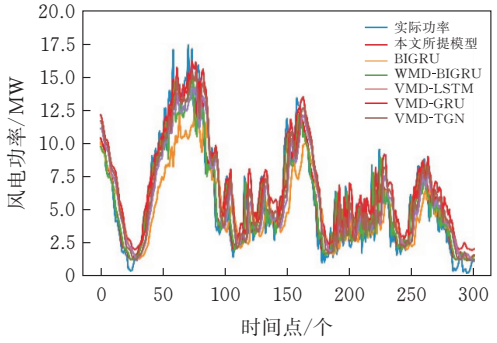


图 10　不同模型的功率预测

1）初步预测结果分析。将初步预测模型 VMD-BIGRU 与三种相同数据预处理模型的 VMD-LSTM、VMD-GRU、VMD-TCN 进行对比。结果表明，VMD-BIGRU 在预测中得到的 MAPE、MAE、RMSE 分别为 6.359、0.294、0.358，均小于其它三个对比模型的对应误差。观察图 10 可知，相较于 LSTM、GRU 和 TCN 的预测曲线，BIGRU 的预测性能更加优秀，在风电功率变化的波峰与波谷都有明显的改善。同时，将 BIGRU 与 VMD-BIGRU 对比，发现数据经 VMD 处理后，可有效提升模型预测性能，与实验 1 中结论相同，证明了数据预处理的重要性。

2）误差修正分析。将本文模型与其它不经误差修正模型对比。结果表明，本文混合模型的评价指标在所有模型中均达到最佳值，结合所设计模型的点预测结果，证明了误差修正是一种很有前景的预测方法。

4　结论

1）提出一种基于 VMD-BIGRU 的风电功率初步预测方法，通过实验发现该方法可有效提取风电功率深度特征，提升模型预测精度。

2）提出一种基于 TCN 的风电功率误差修正方法，实验表明使用误差修正可有效降低预测误差。

3）研究不足与展望：本文使用的预测模型超参数选择自由度较高，在后续工作中将考虑使用优化算法与网络结合，以降低模型设计成本。

[参　考　文　献]

[1] SHUAI H, YUE X, et al. An improved deep belief network based hybrid forecasting method for wind power[J]. Energy, 2021,224(2):120185.1-120185.16.

[2] 康文豪，徐天奇，王阳光，等. 基于特征选择和改进深度森林的短期风电功率预测[J].陕西科技大学学报，2021,39(06):148-153.

[3] 王瑞，冉锋，逯静.基于游程判别法和 VMD 残差修正的风电功率预测[J].湖南大学学报(自然科学版)，2022，49(08):128-137.

[4] ZHANG Y, PAN G, CHEN B, et al. Short-term wind speed prediction model based on GA-ANN improved by VMD[J]. Renewable Energy, 2020, 156(08): 1373-1388.

[5] DING Y, CHEN Z, ZHANG H, et al. A short-term wind power prediction model based on CEEMD and WOA-KELM[J]. Renewable Energy, 2022,189(04): 188-198.

[6] 董雪，赵宏伟，赵生校，等.基于二次分解和多目标优化的超短期海上风电功率预测[J].高电压技术，2022，48(08):3260-3270.

[7] Meka R, Alaeddini A, Bhaganagar K. A robust deep learning framework for short-term wind power forecast of a full-scale wind farm using atmospheric variables [J]. Energy, 2021, 221(15):119759.1-119759.11.

[8] ZHAO X, LIU J, YU D, et al. One-day-ahead probabilistic wind speed forecast based on optimized numerical weather prediction data[J]. Energy Convers Management,2018,164(05):560-569.

[9] XIAO L, SHAO W, YU M, et al. Research and application of a hybrid wavelet neural network model with the improved cuckoo search algorithm for electrical power system forecasting[J]. Applied Energy 2017,198(07):203-222.

（下转第 28 页）