Smart Grid 智能电网, 2018, 8(6), 473-488
Published Online December 2018 in Hans. http://www.hanspub.org/journal/sg
https://doi.org/10.12677/sg.2018.86052

Short-Term Electricity Price Forecasting Based on VMD and BP Neural Network

Yuguo Chen[1], Zhanqing Cheng[2], Xiaohao Hou[3], Hongbo Liu[3]

[1]Guangdong Power Grid Dispatching Control Center, Guangzhou Guangdong
[2]Guangdong Baolihua Electric Power Limited Company, Meizhou Guangdong
[3]School of Electrical Engineering and Automation, Harbin Institute of Technology, Harbin Heilongjiang
Email: chenyg1987819@126.com, zhanqing123488@163.com, houxiaohaoee@163.com, liuhongbo_huster@foxmail.com

Received: Oct. 2nd, 2018; accepted: Oct. 16th, 2018; published: Oct. 30th, 2018

Abstract

Electricity price is one of the most important indexes in electricity market transactions. Electricity market participants adjust their investment strategies to participate in power transactions based on forecast prices. To improve the accuracy of short-term price forecasting in electricity market, a short-term electricity price forecasting method based on VMD and BP neural network is proposed in the paper. The proposed method has the following three steps: 1) VMD is used to decompose historical electricity price data into different modal functions. 2) BP neural network is applied to forecast the results of decomposition. 3) The forecasting results are reconstructed to get the short-term electricity price prediction results. Finally, this method is applied to the PJM electricity market in the United States, and the superiority of using VMD as a preconditioning algorithm for historical electricity price signals is verified. Simulation results shows that the forecasting result can fit the actual data well and have a higher prediction accuracy comparing with the forecasting results based on BP neural network only.

Keywords

Short-Term Electricity Price Forecasting, Variational Mode Decomposition (VMD), BP Neural Network, Electricity Market

基于VMD与BP神经网络的短期电价预测

陈雨果[1]，程占清[2]，侯晓豪[3]，刘宏波[3]

[1]广东电网电力调度控制中心，广东 广州
[2]广东宝丽华电力有限公司，广东 梅州
[3]哈尔滨工业大学电气工程及自动化学院电气工程系，黑龙江 哈尔滨
Email: chenyg1987819@126.com, zhanqing123488@163.com, houxiaohaoee@163.com, liuhongbo_huster@foxmail.com

文章引用: 陈雨果, 程占清, 侯晓豪, 刘宏波. 基于 VMD 与 BP 神经网络的短期电价预测[J]. 智能电网, 2018, 8(6): 473-488. DOI: 10.12677/sg.2018.86052

收稿日期：2018年10月2日；录用日期：2018年10月16日；发布日期：2018年10月30日

摘　要

电价是电力市场交易中最重要的指标之一。电力市场参与者根据预测电价调整其投资策略，参与电力交易。为了提高电力市场短期电价预测的准确性，本文提出了一种基于VMD和BP神经网络的短期电价预测方法。该方法包括以下三个步骤：1) 利用VMD将历史电价数据分解为不同的模态函数；2) 应用BP神经网络对分解得到的模态函数进行预测；3) 对预测结果进行重构，得到短期电价预测结果。最后，采用美国PJM电力市场实际数据对本方法进行仿真验证，验证了VMD作为历史电价信号预处理算法的优越性，仿真结果表明，预测结果能够很好地拟合实际数据，与仅用BP神经网络预测的结果相比较具有较高的预测精度。

关键词

短期电价预测，变分模态分解，BP神经网络，电力市场

Copyright © 2018 by authors and Hans Publishers Inc.
This work is licensed under the Creative Commons Attribution International License (CC BY).
http://creativecommons.org/licenses/by/4.0/
Open Access

1. 引言

在电力市场交易中，电价作为电能交易的重要指标，一直受到人们的关注。电价预测是指运用数学工具，利用现有的电价数据，综合考虑供需、电价等影响因素，对未来电价进行分析和预测[1]。电价预测主要包括长期电价预测、中期电价预测和短期电价预测。中长期电价预测主要是对未来一段时间内的电价走势进行预测，其预测结果可为电网规划提供参考。短期电价预测主要是对未来几小时或几天的电价变化进行预测，预测结果可以为电力市场交易提供指导。本文主要研究短期电价预测方法的建立。

在短期电价预测的研究中，许多学者已经对各种短期电价预测方法进行了研究。这些方法可以分为两大类：一类方法是通过分析电力市场的动态有效参数直接预测未来电价，另一类方法是基于黑箱理论，根据电价统计数据预测电价[2]。在文献[3] [4] [5] [6] [7]中，学者们用人工神经网络来预测电价，在文献[8] [9] [10] [11] [12]中，将自回归积分滑动平均模型应用于电价预测。文献[13] [14]利用粒子群算法对电价进行预测。还有一些研究者通过引入数据挖掘，结合影响电价的因素来预测电价，如文献[15] [16] [17] [18] [19]。为了得到较好的预测结果，文献[15] [20] [21]提出了综合预测模型。然而，在目前的研究中，很少有研究基于信号处理来提高短期电价预测的准确性。

变分模态分解(Variational Mode Decomposition, VMD)是一种自适应的、准正交的、完全非递归的信号分解方法。VMD 可以将由多个分量组成的信号分解为有限带宽的几种固有模式。VMD 算法解决了传统经验模式分解(Empirical Mode Decomposition, EMD)算法中由于包络误差和噪声干扰引起的模式混叠问题，提高了信号处理的鲁棒性[22] [23] [24] [25]。本文针对 VMD 算法在处理信号上的优势，结合 VMD 和 BP 神经网络，提出了一种新的短期电价预测方法。该方法利用 VMD 对历史电价进行分解，得到多个模态函数。将 VMD 分解结果作为 BP 神经网络的输入数据，得到相应的模态预测值。对模型预测值进行重构，得到短期电价预测结果。为了验证该方法的正确性，利用美国 PJM 电力市场数据进行了仿真验证。

2. 原理和方法

2.1. 变分模态分解

VMD 算法通过搜索约束变分模型最优解来实现信号的自适应分解[26] [27]，迭代求解变分模型，最终可以根据被分解信号的频域特性完成信号频带的自适应分解。对于原始信号 f，其对应的约束变分模型表达式如公式(1)所示。

$$\begin{cases} \min\limits_{\{u_k\},\{\omega_k\}} \left\{ \sum\limits_{k=1}^{K} \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) \right] \mathrm{e}^{-j\omega_k t} \right\|_2^2 \right\} \\ s.t. \sum\limits_{k=1}^{K} u_k = f \end{cases} \tag{1}$$

式中：$\{u_k\}$ 为分解得到的 K 个模态分量，$\{\omega_k\}$ 为各模态分量的中心频率。

引入增广 Lagrange 函数求解上述约束变分问题的最优解，如公式(2)所示。

$$L(\{u_k\},\{\omega_k\},\{\lambda\}) = \alpha \sum_{k=1}^{K} \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) \right] \mathrm{e}^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_{k=1}^{K} u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_{k=1}^{K} u_k(t) \right\rangle \tag{2}$$

式中：α 为二次惩罚因子，可在高斯噪声存在的情况下保证信号的重构准确度；λ 为 Lagrange 算子，用来保持约束条件的严格性。

利用交替方向乘子法求取上述增广 Lagrange 函数的鞍点，即通过交替更新 $\{u_k^{n+1}\}$，$\{\omega_k^{n+1}\}$ 和 $\{\lambda^{n+1}\}$ 寻求式(2)的最优解，其中 u_k^{n+1} 由式(3)求得。

$$u_k^{n+1} = \arg\min_{u_k \in X} \left\{ \alpha \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] \mathrm{e}^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_{i \neq k} u_i(t) + \frac{\lambda(t)}{2} \right\|_2^2 \right\} \tag{3}$$

利用 Parseval/Plancherel 傅里叶等距变换将式(1)变换到频域，求得二次优化问题的解见式(4)。

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum\limits_{i<k} \hat{u}_i^{n+1}(\omega) - \sum\limits_{i>k} \hat{u}_i^{n}(\omega) + \hat{\lambda}(\omega)/2}{1 + 2\alpha(\omega - \omega_k)^2} \tag{4}$$

同理为求解 ω_k^{n+1} 的最小值问题，将中心频率更新问题转换到频域，如公式(5)所示。

$$\omega_k^{n+1} = \arg\min_{\omega_k} \left\{ \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] \mathrm{e}^{-j\omega_k t} \right\|_2^2 \right\} \tag{5}$$

中心频率的计算结果如式(6)所示。

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega \left| \hat{u}_k^{n+1}(\omega) \right|^2 \mathrm{d}\omega}{\int_0^\infty \left| \hat{u}_k^{n+1}(\omega) \right|^2 \mathrm{d}\omega} \tag{6}$$

式中：$\hat{u}_k^{n+1} a$ 为当前剩余量 $\hat{f}(\omega) - \sum\limits_{i \neq k} \hat{u}_i(\omega)$ 的维纳滤波；ω_k^{n+1} 为当前模态函数功率谱的中心频率。

对 $|\hat{u}_k(\omega)|$ 进行傅里叶逆变换，取实部即可得到时域模态分量 $\{u_k(t)\}$。Lagrange 算子 λ 按式(7)更新。

$$\hat{\lambda}^{n+1}(\omega) = \hat{\lambda}^{n}(\omega) + \tau \left(\hat{f}(\omega) - \sum_{k} \hat{u}_k^{n+1}(\omega) \right) \tag{7}$$

VMD 算法的交替迭代过程如图 1 所示。

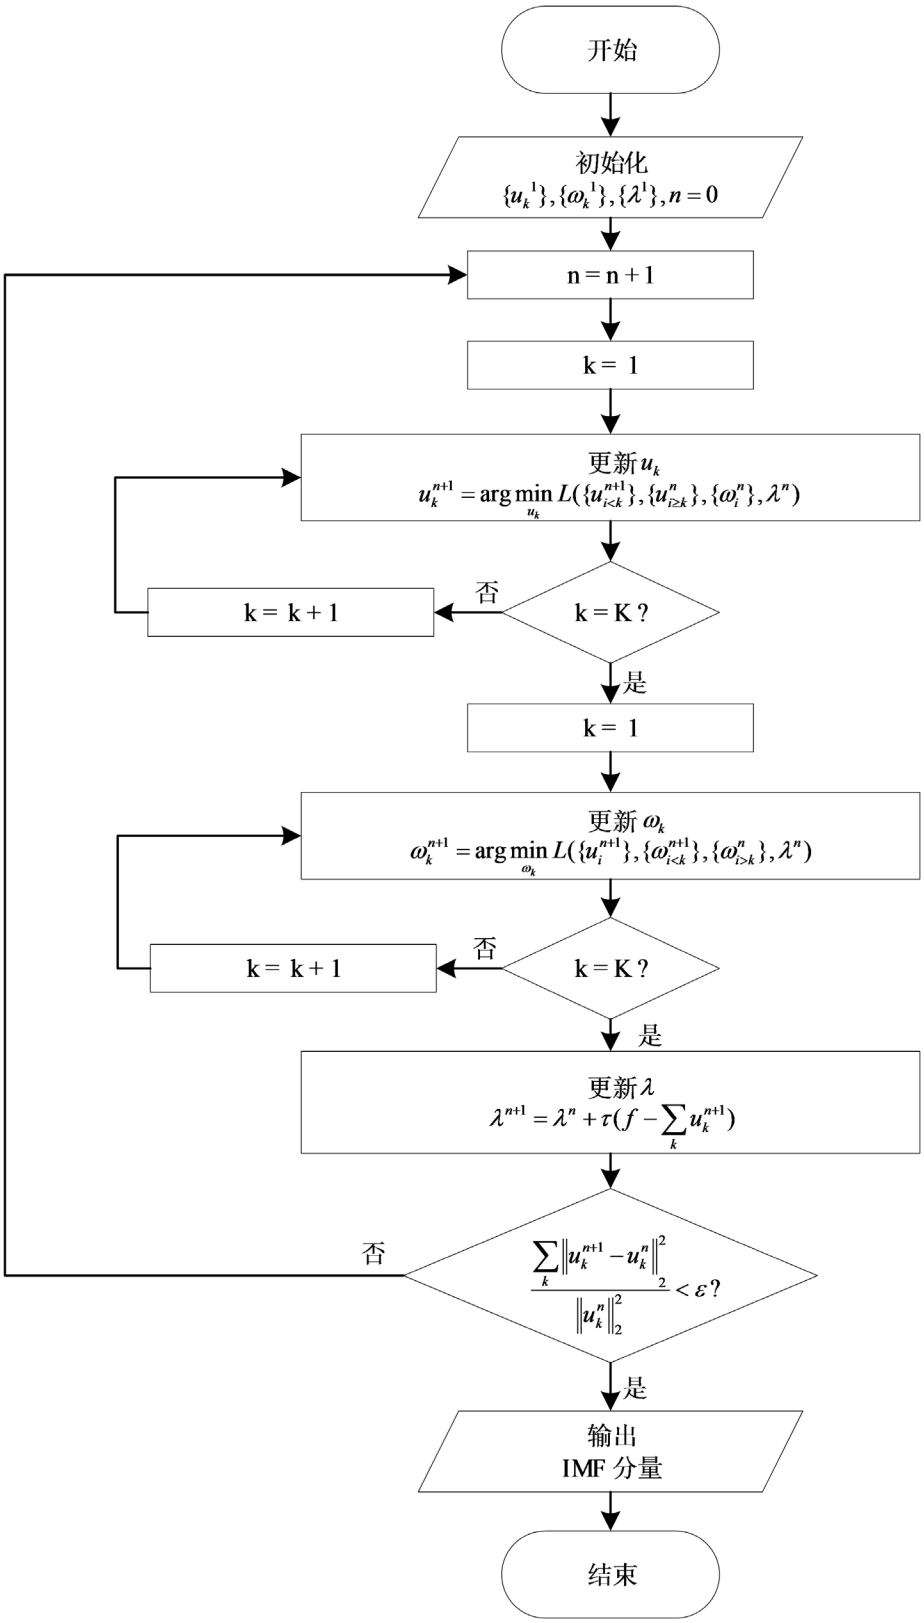

Figure 1. VMD flowchart
图 1. VMD 算法流程图

2.2. BP 神经网络

BP 神经网络是一种多层前馈神经网络，其结构主要由输入层、隐层和输出层三部分组成，BP 网络的学习过程由前向计算和误差反向传播两部分组成[28]。假设在一个 BP 神经网络中有 N 个输入、K 个隐层和 M 个输出。如果 BP 神经网络的输入是 X_{pn}，期望输出是 T_{pm}，隐藏层输出是 $Y1_{pk}$，输出层输出是 $Y2_{pm}$，输入层和隐藏层的连接权重是 $W1_{nk}$，隐层和输出层的连接权重是 $W2_{km}$，允许误差是 ε，则 BP 神经网络的结构图如图 2 所示。

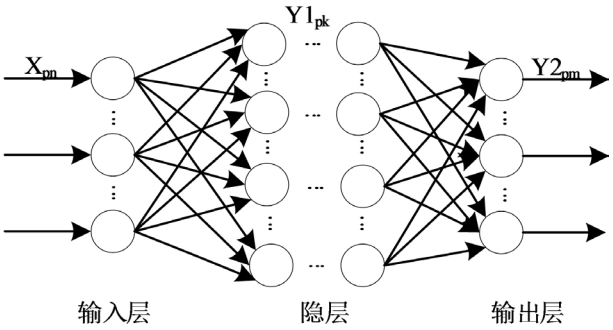

Figure 2. The structure diagram of the BP neural network
图 2. BP 神经网络结构图

在 BP 神经网络的学习过程中，迭代次数从 1 开始。在前向计算过程中，输入 X_{pn} 经过输入层输入到神经网络中，并通过隐层逐层计算，最终从输出层输出，其计算公式如式(8)所示。

$$\begin{aligned} Y1_{pk}(i) &= f\left(\sum_{n=1}^{N} W1_{nk}(i) X_{pn}\right) \\ Y2_{pm}(i) &= f\left(\sum_{k=1}^{K} W2_{km}(i) Y1_{pk}(i)\right) \end{aligned} \tag{8}$$

式中：f 为激励函数，一般认为 $f(x) = 1/\left(1+\mathrm{e}^{-x}\right)$。

经过前向计算，得到输出 $Y2_{pm}$，计算 $Y2_{pm}$ 与期望输出 T_{pm} 之间的均方误差 E，并于允许误差 ε 对比，如果 $E \le \varepsilon$，则计算终止，若 $E > \varepsilon$，则进入误差反向传播过程。

误差信号通过反向传播过程，修改隐藏层到输出层的连接权重，以及输入层到隐藏层的连接权重。它的校正方程如式(9)所示。

$$\begin{aligned} W1_{nk}(i+1) &= W1_{nk}(i) + \Delta W1_{nk}(i+1) \\ W2_{km}(i+1) &= W2_{km}(i) + \Delta W2_{km}(i+1) \end{aligned} \tag{9}$$

修正权重后，进行前向计算和误差反向传播过程。在连续调整各层权重后，当 BP 神经网络的输出和期望输出满足误差要求时，学习过程结束。

2.3. 短期电价预测方法

短期历史电价数据是典型的非平稳随机信号。利用 BP 神经网络直接预测短期电价，预测结果难以满足精度要求。VMD 算法在变分框架内完成信号筛选过程，通过求解约束变分模型的最优解，实现信号的自适应分解。经过 VMD 算法处理，能够获得信号的局部特征，而不需要平稳性假设和其他先验条件。故考虑用 VMD 算法处理历史电价数据。

为了提高短期电价预测的精度，提出了一种基于 VMD 与 BP 神经网络的短期电价预测方法。短期电价预测方法的流程图如图 3 所示。该方法的建立过程如下：

1) 利用 VMD 算法将历史电价数据分解为 K 个模态函数。

2) 将得到的 K 个模态函数分别作为 BP 神经网络输入层的输入量，经 BP 神经网络计算，BP 神经网络输出层输出每个模态函数的预测值。

3) 将各模态函数的预测值叠加，得到短期电价的预测值。

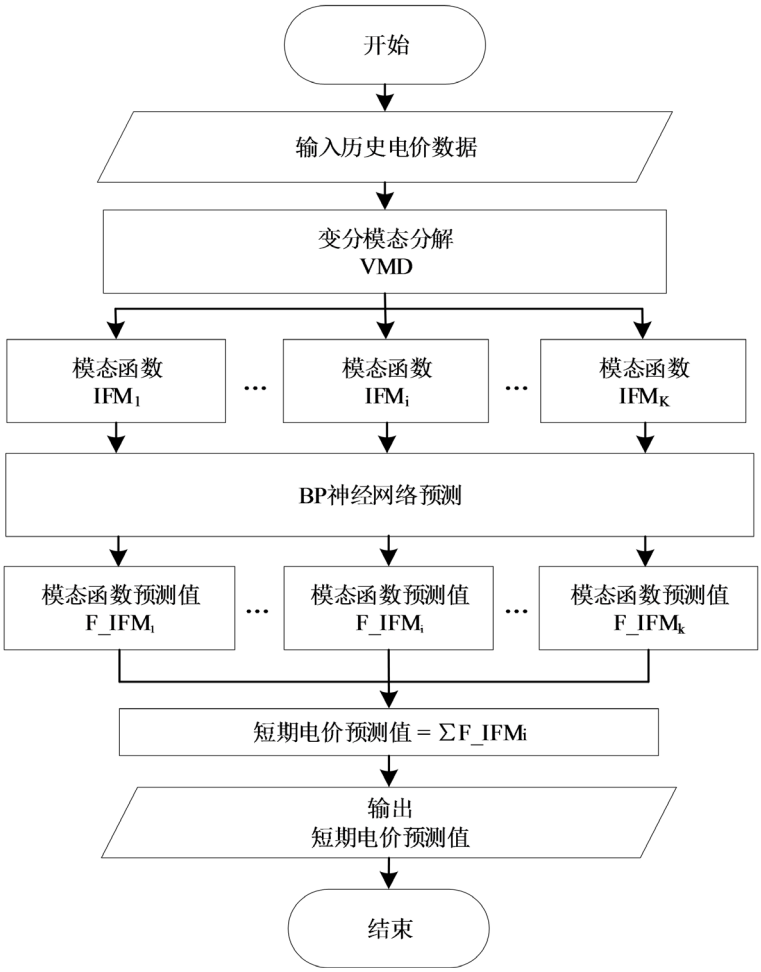

Figure 3. The flowchart of the short-term electricity price forecasting
图 3. 短期电价预测方法流程图

3. 算例分析

本节利用美国 PJM 电力市场的实际电价数据进行仿真分析，验证所提出方法的有效性。分析了各种信号处理算法在处理历史电价信号时的特点，指出了 VMD 算法相比于 EMD 和 LMD 算法的优越性，将基于 VMD 和 BP 神经网络的短期电价预测仿真结果与基于 BP 神经网络的直接电价预测仿真结果进行了比较，证明了所提方法的优越性。

3.1. 历史电价信号模态分解

短期电价预测是基于历史电价数据来预测未来短期电价的。本文选取美国 PJM 电力市场从 2018 年 2 月 22 日到 2018 年 3 月 17 日的实际电价数据作为历史电价数据。利用过去 24 天的电价数据预测第 25 天的电价数据。历史电价的变化趋势如图 4 所示。

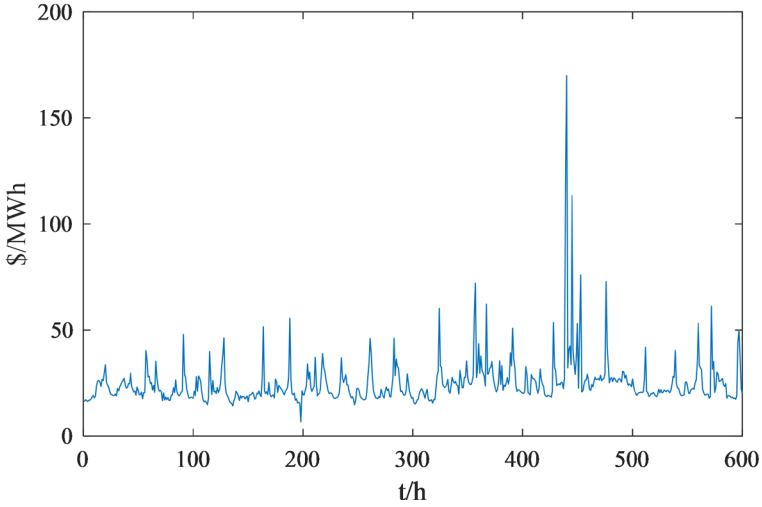

Figure 4. Historical electricity price data
图 4. 历史电价数据

在短期电价预测之前，需要对历史电价信号进行分解，并将分解得到的一些模态函数作为 BP 神经网络的输入，以得到各模态函数的预测值。为了体现 VMD 分解的优越性，将历史电价信号分别用 EMD、LMD 和 VMD 进行分解，并将 VMD 分解结果与 EMD、LMD 分解结果进行比较。

将历史价格数据由 EMD 分解为 6 个模态函数：IMF_1、IMF_2、IMF_3、IMF_4、IMF_5 和 IMF_6，如图 5 所示。分解得到的各个模态分量包括了历史电价信号在不同时间下的局部特征。

将历史电价数据经 LMD 分解为 6 个模态函数：IMF_1、IMF_2、IMF_3、IMF_4、IMF_5 和 IMF_6，如图 6 所示。

利用 VMD 对历史电价进行分解。经过大量的仿真实验，当选择模态数 K 的个数为 6 时，分解结果是最优的。历史价格数据分解为 6 个模态函数：IMF_1、IMF_2、IMF_3、IMF_4、IMF_5 和 IMF_6，如图 7 所示。

电价波动是由负荷变化决定的，当电力负荷增加时，电价上升，当电力负荷降低时，电价下降。在电力负荷中，日常的民用负荷、工业负荷和商业负荷相对稳定，这类负荷有规律地变化，具有较低的变化频率，占据了日常负荷的很大一部分。根据历史电价数据的模态分解结果，稳定负荷产生的电价变化如图 5(d)~图 5(f)，图 6(d)~图 6(f)和图 7(a)~图 7(c)所示，可见这些模态函数值大，且变化频率不高，模态函数变化相对平稳。

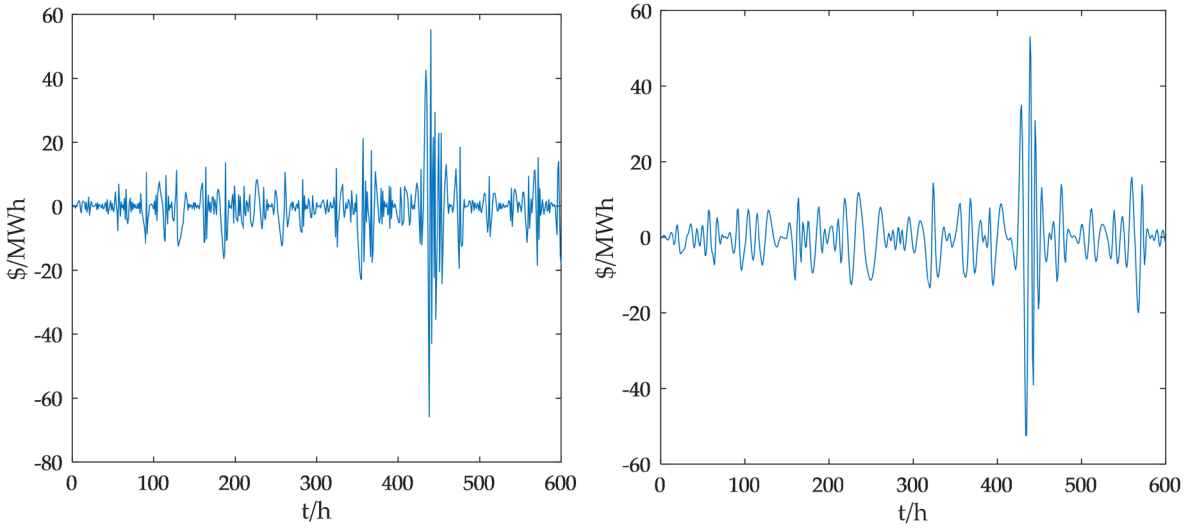

(a) IMF_1　　(b) IMF_2

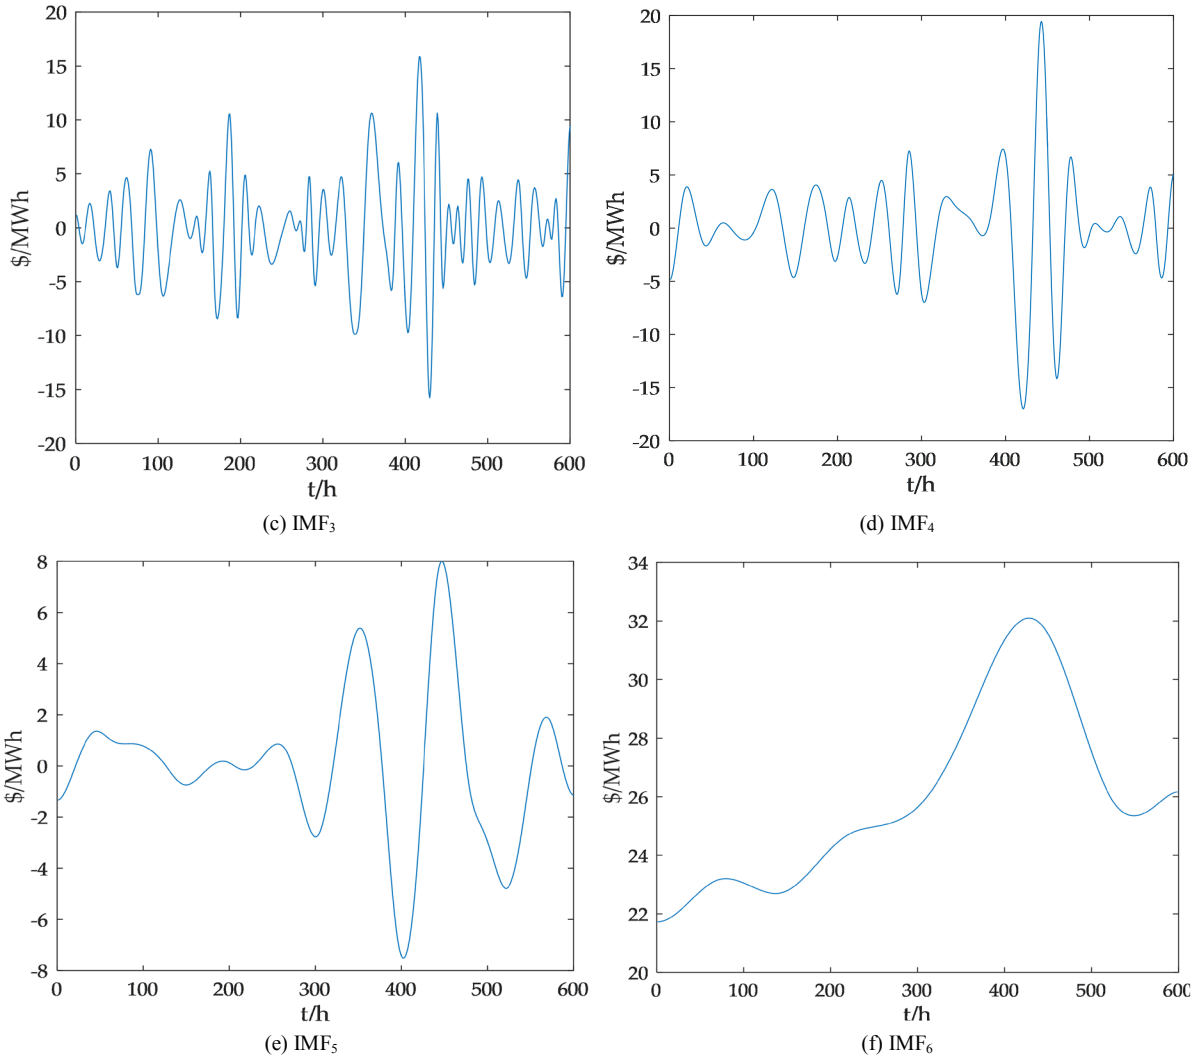

(c) IMF$_3$ (d) IMF$_4$

(e) IMF$_5$ (f) IMF$_6$

Figure 5. Modal functions of EMD

图 5. EMD 的模态函数

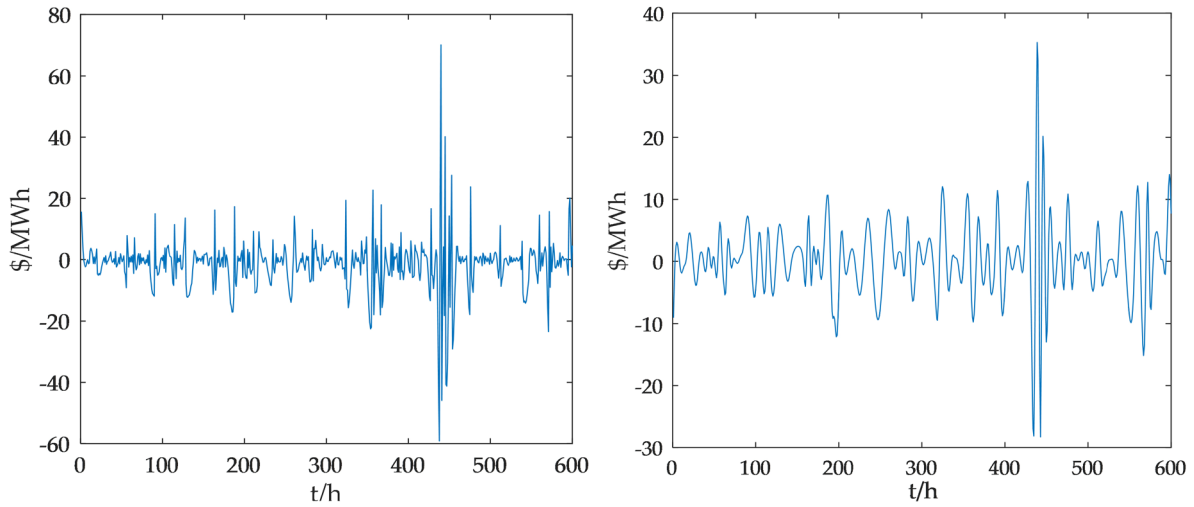

(a) IMF$_1$ (b) IMF$_2$

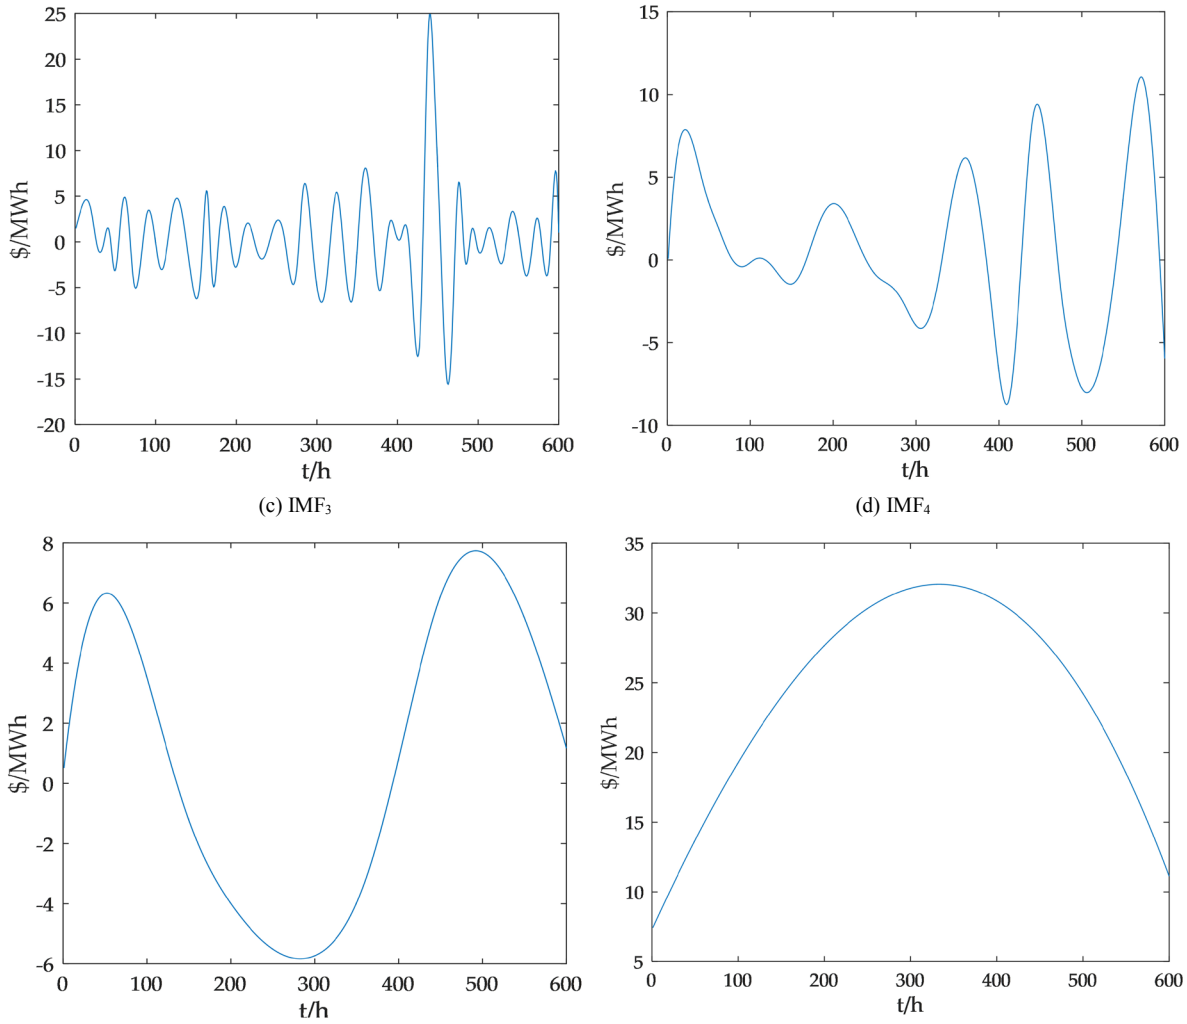

(c) IMF_3 (d) IMF_4

(e) IMF_5 (f) IMF_6

Figure 6. Modal functions of LMD

图 6. LMD 的模态函数

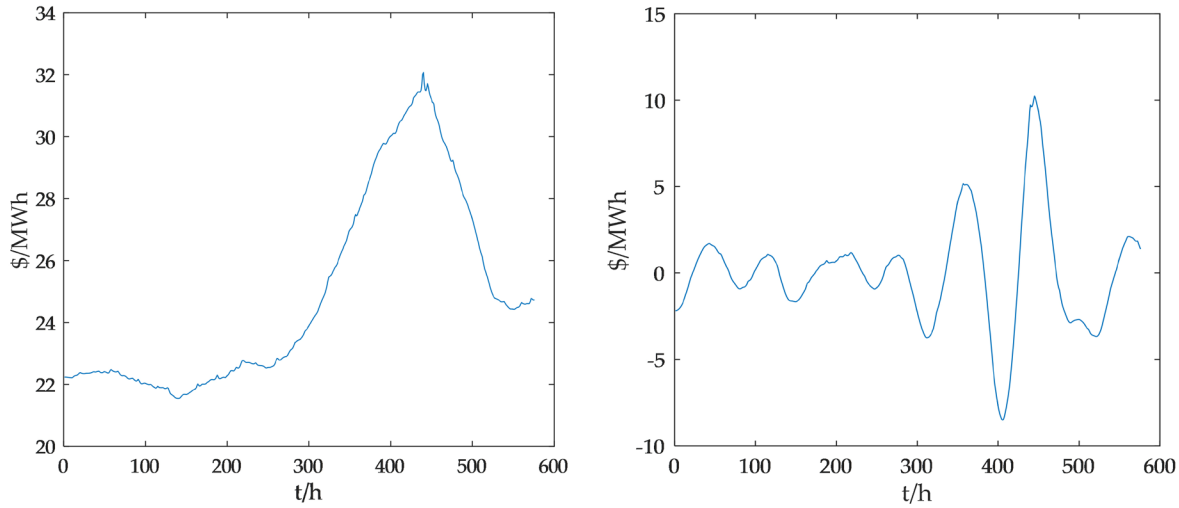

(a) IMF_1 (b) IMF_2

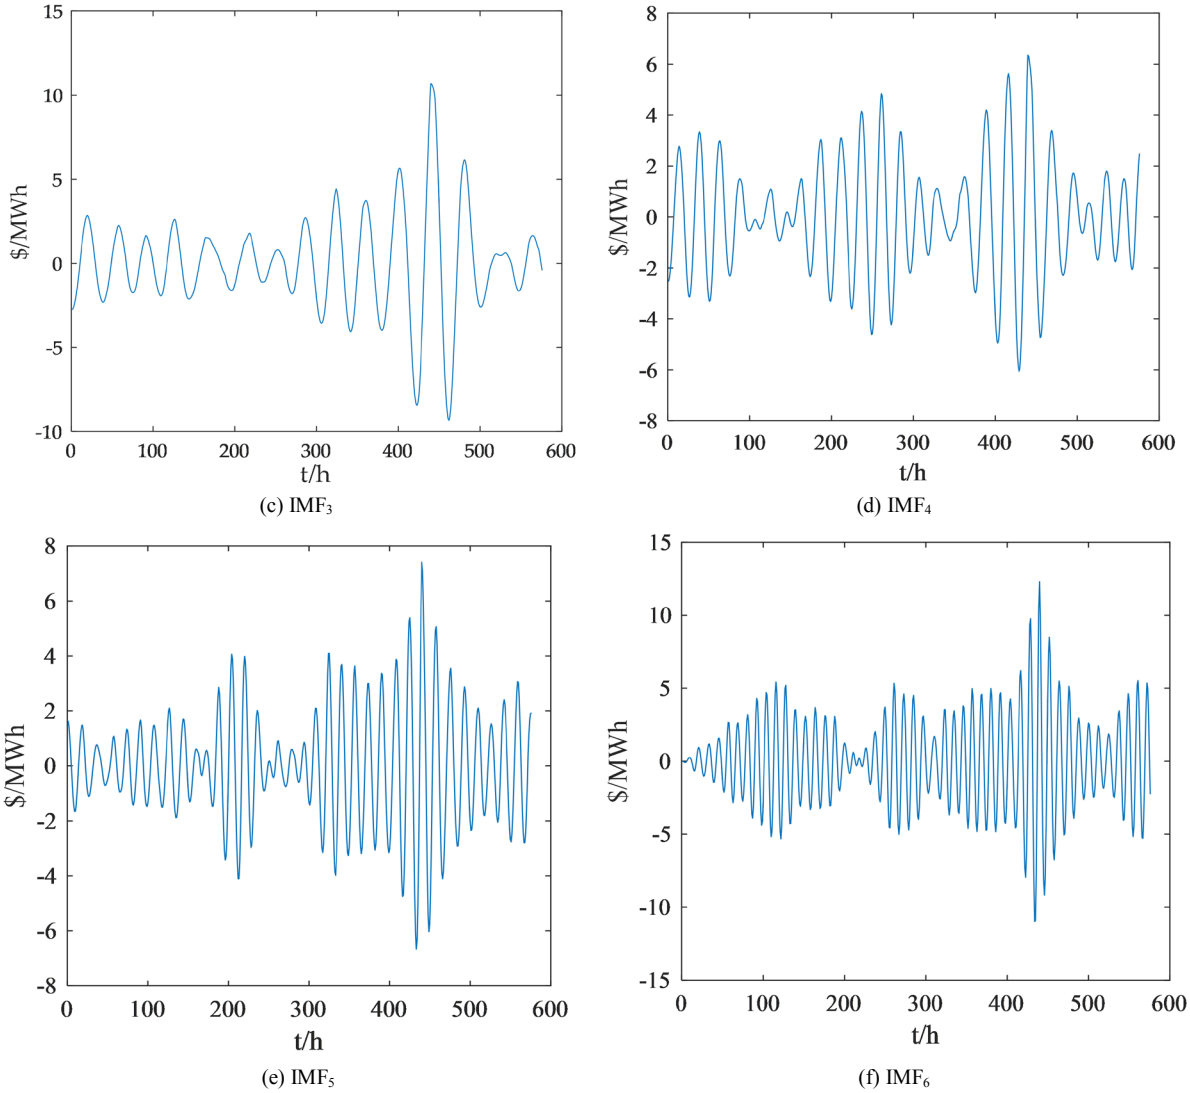

Figure 7. Modal functions of VMD
图 7. VMD 的模态函数

在日常电力负荷中，除了民用负荷和工业负荷等稳定负荷外，还存在大量的随机负荷。随机负荷变化主要是由用户需求、气象条件、重大政治和经济活动等高度不确定的随机因素引起的。随机负荷的变化一般比较复杂，没有明确的规律，变化频率也比较大。随机负荷在日负荷中只占很小的一部分，因此它所产生的电价在日电价中只占很小的一部分。但随机负荷变化的不确定性导致了日电价变化的随机性。根据历史电价的模态分解结果，由随机负荷产生的电价变化如图 5(a)~图 5(c)、图 6(a)~图 6(c)和图 7(d)~图 7(f)所示，可见这些模态函数值小，但变化频率高。

3.2. 模态函数预测

利用信号分解算法将历史电价信号分解为多个模态函数，将得到的模态函数作为 BP 神经网络的输入，分别进行预测，可以得到各模态函数的预测值。同时，利用相应的信号分解算法对第 25 天的实际电价进行分解，并与各模态函数的预测值进行比较，可以观察各模态函数的预测精度。

将历史电价信号的分解结果输入 BP 神经网络，分别对模态函数进行预测。BP 神经网络输出预测值为

F_IMF$_1$、F_IMF$_2$、F_IMF$_3$、F_IMF$_4$、F_IMF$_5$ 和 F_IMF$_6$。EMD 算法得到的模态函数的预测结果如图 8 所示。由 LMD 算法得到的模态函数的预测结果如图 9 所示。VMD 算法得到的模态函数的预测结果如图 10 所示。

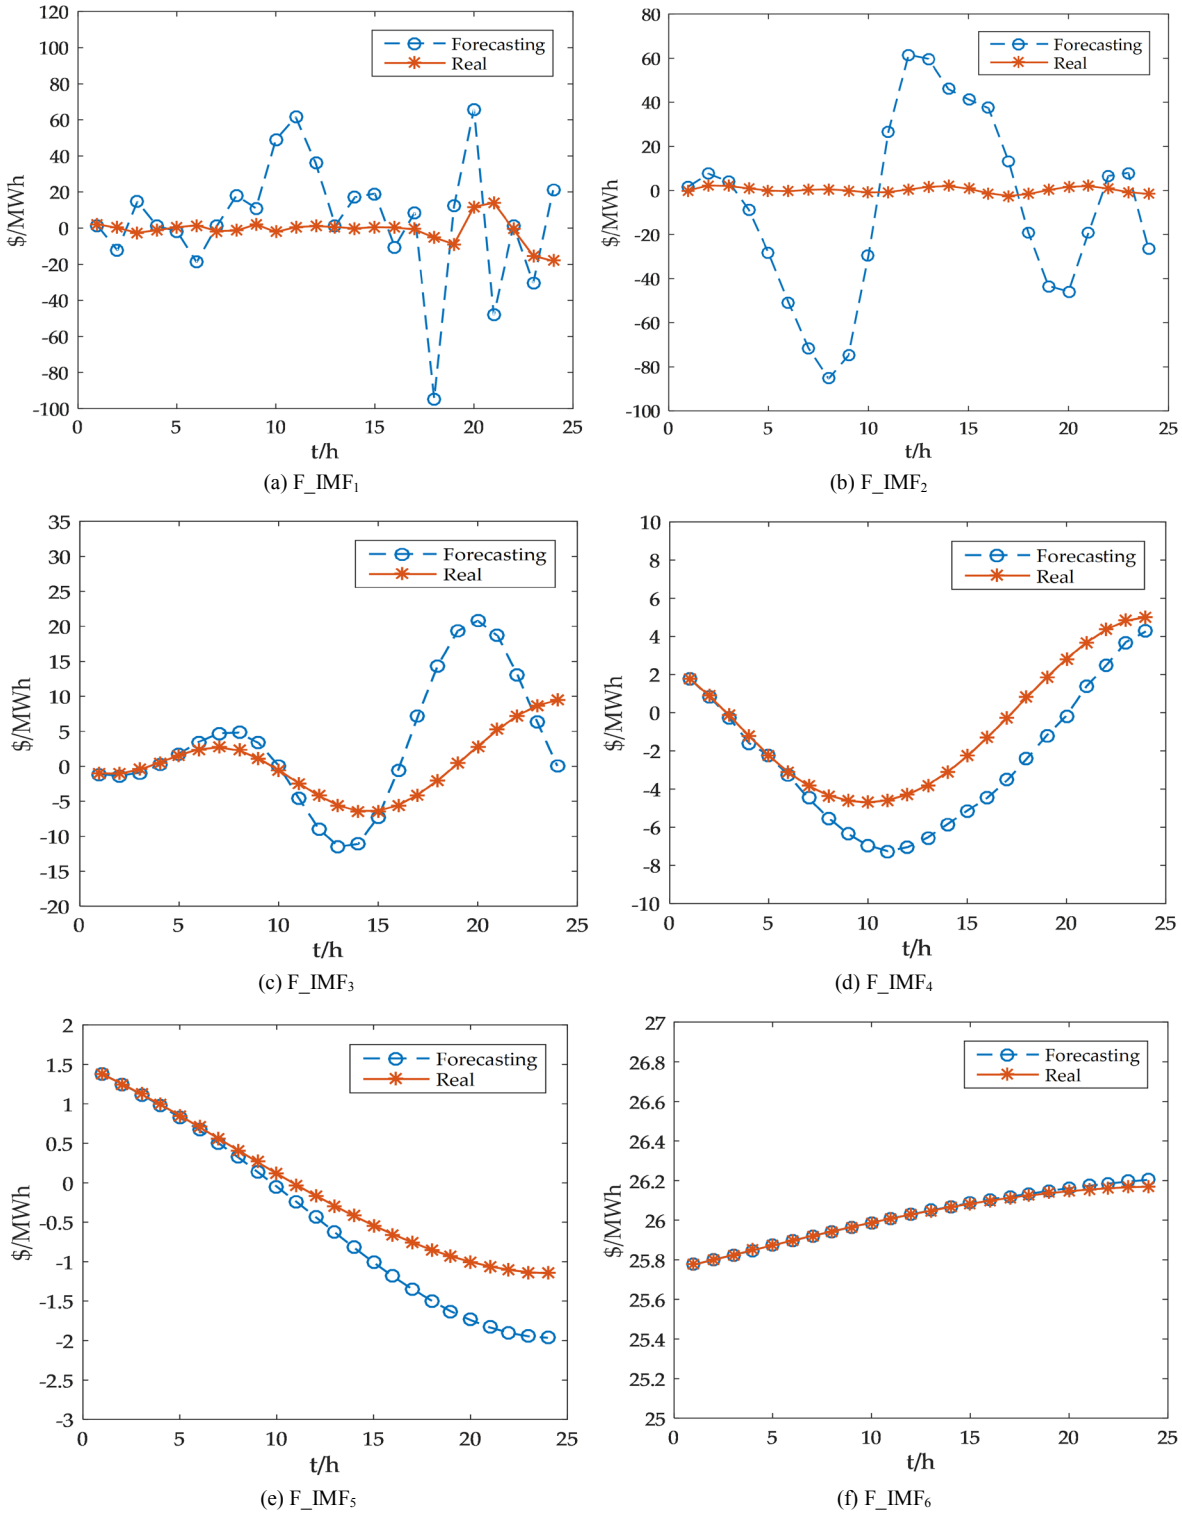

Figure 8. Modal functions forecasting of EMD
图 8. EMD 的模态函数预测

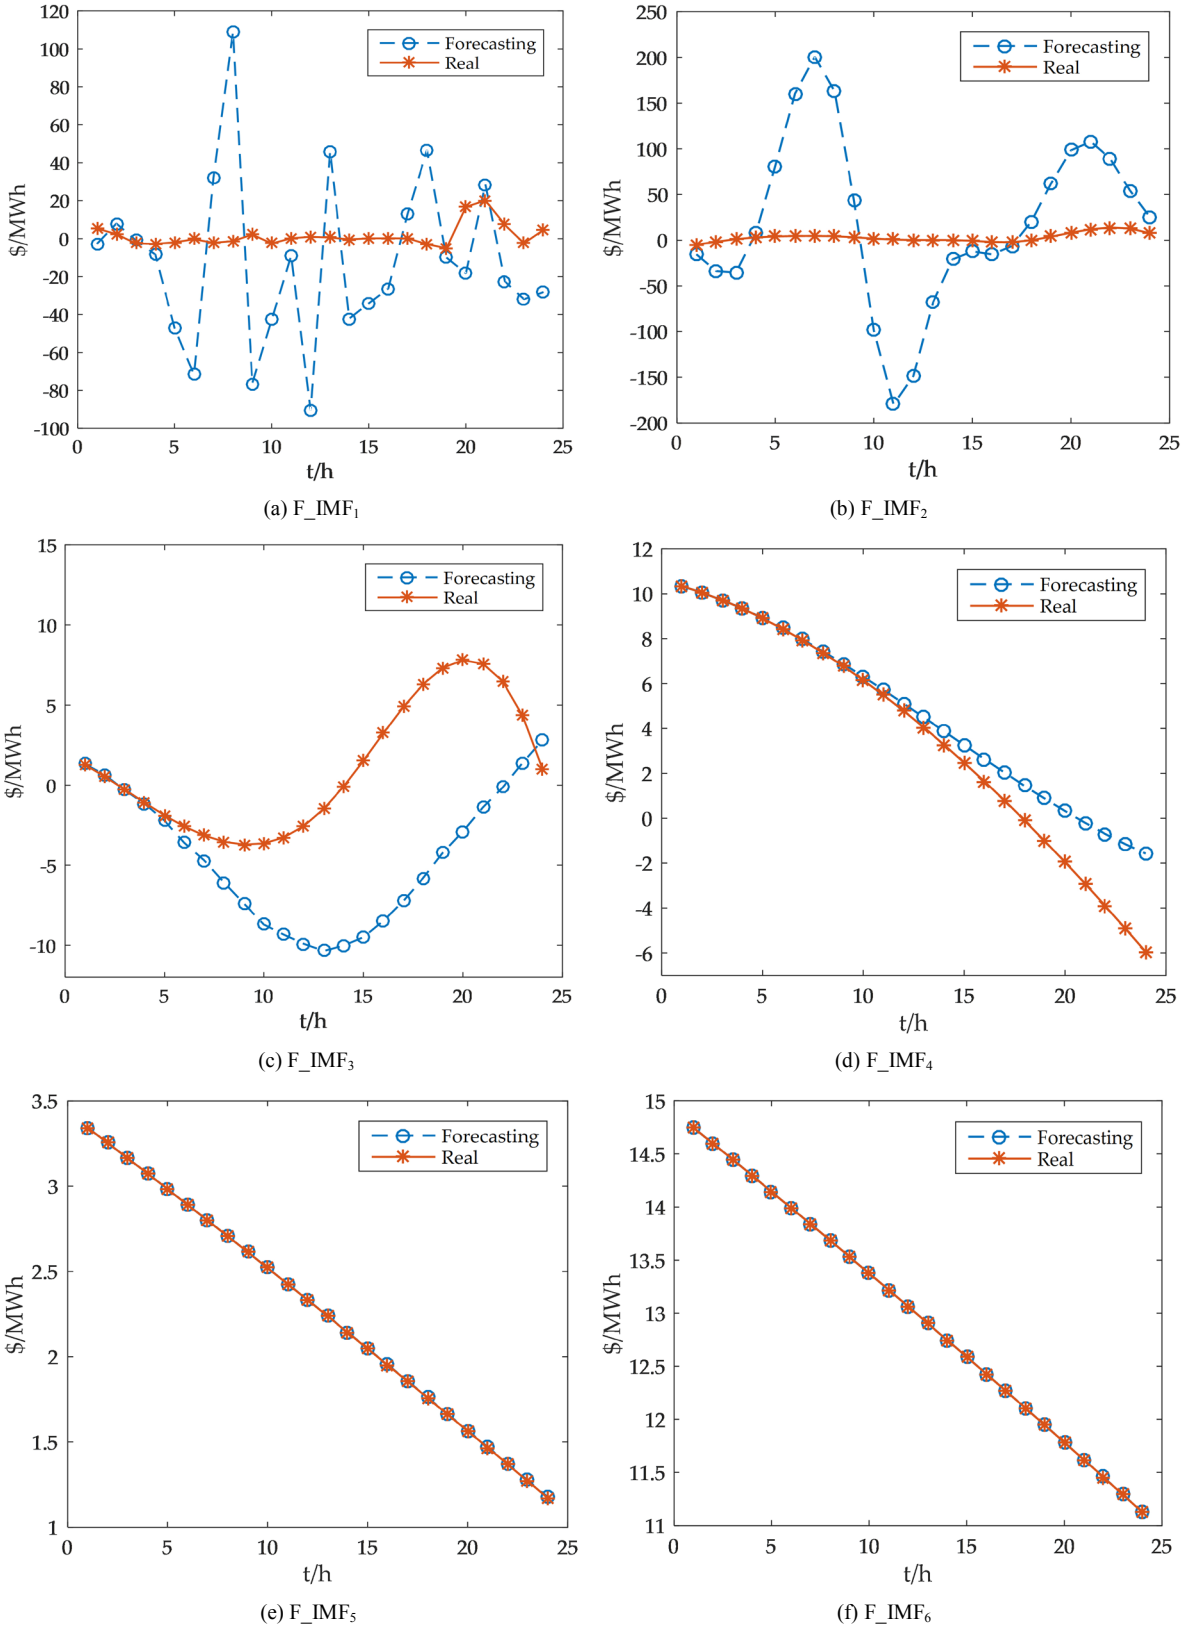

Figure 9. Modal functions forecasting of LMD
图 9. LMD 的模态函数预测

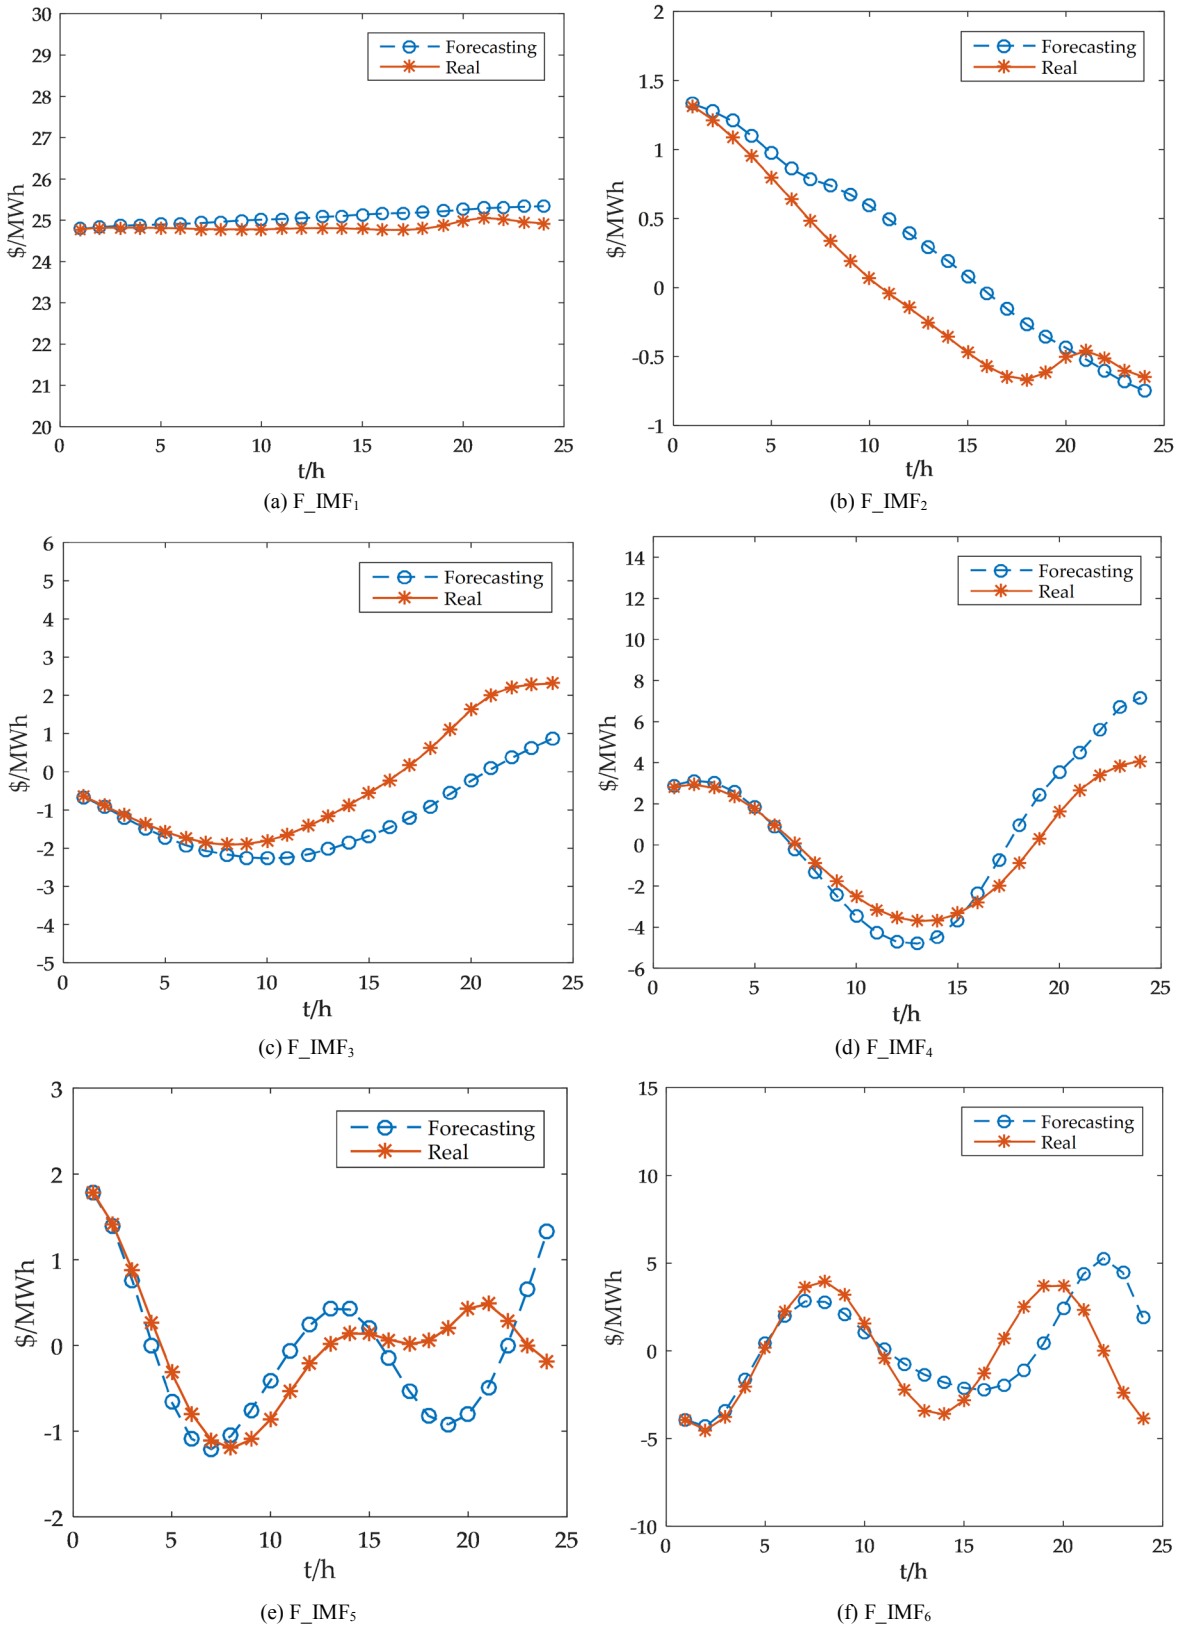

(a) F_IMF$_1$ (b) F_IMF$_2$ (c) F_IMF$_3$ (d) F_IMF$_4$ (e) F_IMF$_5$ (f) F_IMF$_6$

Figure 10. Modal functions forecasting of VMD
图 10. VMD 的模态函数预测

通过 EMD、LMD 和 VMD 对历史电价信号进行分解得到的低频模态函数具有低的变化频率、平稳的信号变化和明显的变化趋势。从图 8(d)~图 8(f)，图 9(d)~图 9(f)和图 10(a)~图 10(c)中可以看出，当这些低频模态函数被用作 BP 神经网络的输入时，得到的模态函数预测结果是准确的。因此，这些低频模态函数的预测结果对短期电价预测的准确性影响不大。

利用 EMD 和 LMD 对历史电价信号进行分解得到的高频模态函数与通过 VMD 分解得到的高频模态函数不同。从图 5(a)~图 5(c)和图 6(a)~图 6(c)可以看出，EMD 和 LMD 分解得到的高频模态函数包含了原始历史电价信号的不同时间尺度的局部特征，模态函数具有高频、不规则、大波动等特点。因此，将其作为 BP 神经网络的输入，其预测结果如图 8(a)~图 8(c)和图 9(a)~图 9(c)所示，预测结果与真实值之间存在较大误差，直接影响短期电价预测的精度。

利用 VMD 对历史电价信号进行分解，得到高频模态函数，如图 7(d)~图 7(f)所示。可以看出，由 VMD 分解得到的高频模态函数呈现规律性变化，不反映历史电价信号的随机性和波动性。将其作为 BP 神经网络的输入，其预测结果如图 10(d)~图 10(f)所示，预测结果与真实值相差不大。因此，由 VMD 得到的高频模态函数的预测值并不影响短期电价预测的精度。

通过以上分析，利用 VMD 对历史电价信号进行分解得到的高频模态函数的预测精度优于 EMD 和 LMD 分解得到的高频模态函数的预测精度。因此，本文选择 VMD 作为历史电价信号预处理算法。

3.3. 短期电价预测

选择 VMD 作为历史电价预处理算法，得到各模态函数，并利用各模态函数作为 BP 神经网络的输入，得到各模态函数的预测值。未来 24 小时的预测电价可以通过叠加每个模态函数的预测值来获得。

利用历史电价数据直接作为 BP 神经网络的输入层数据，对未来 24 小时内的电价进行预测，预测结果称为直接预测结果。将本文所提方法得到的预测电价与实际电价和直接预测结果进行比较，如图 11 所示，可以看出，本文所提预测方法的预测结果反映了未来 24 小时电价的变化趋势，且预测结果优于直接预测结果。

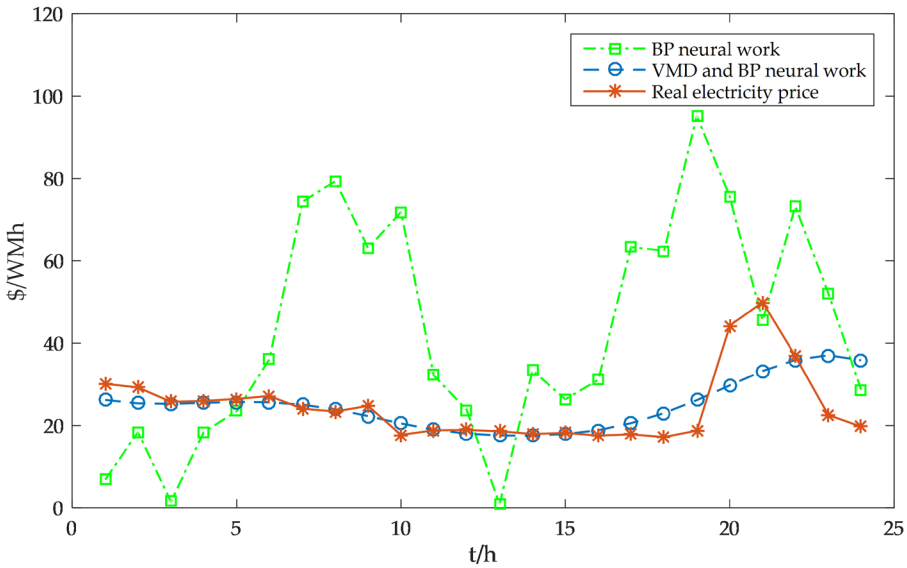

Figure 11. Comparison of forecasting results
图 11. 预测结果比较

从图 11 可以看出，用 BP 神经网络直接预测短期电价的误差较大，其原因可以归纳如下：

1) 影响短期电价的因素很多，不同的因素对短期电价有不同的影响。因此，仅使用 BP 神经网络进行电价预测会产生误差。

2) 由于电价的采样时间间隔为一小时，历史电价数据波动较大，历史电价数据中存在许多尖点，导致直接预测结果不准确。

利用本文建立的方法对短期电价进行预测，与直接预测相比，该方法具有以下优点：

1) 通过对历史电价进行 VMD 分解，可以得到多个模态函数，并且通过分解得到的每个模态函数表示不同因素对电价的影响。因此，利用各模态函数对电价进行预测，可以提高预测精度。

2) VMD 分解结果既保持了原电价的趋势，又具有相对平滑的波形，克服了数据波动大的问题。

通过以上分析，可以看出本文所建立的短期电价预测方法优于基于 BP 神经网络的直接预测方法。基于 VMD 和 BP 神经网络的短期电价预测方法的预测结果反映了短期内未来电价的走势，可以为电力市场提供价格指引。

4. 结论

电价作为电力市场重要的参考指标之一，获得准确电价的预测结果至关重要。为了提高短期电价预测的精度，本文提出了一种基于 VMD 和 BP 神经网络的短期电价预测方法。通过对比 EMD、LMD 和 VMD 三种不同信号处理算法在处理历史电价数据的结果，验证了 VMD 作为历史电价信号预处理算法的优越性。将历史价格数据进行 VMD 分解得到固有的模态函数，将每个模态函数分别作为 BP 神经网络的输入，得到各模态函数的预测值。通过叠加各模态函数的预测值，得到短期电价的预测值。同时，将该方法的预测结果与直接预测结果进行了比较，表明了该方法的优越性和实用性。

参考文献

[1] Zhang, X. and Wang, X.F. (2006) Review of the Short-Term Electricity Price Forecasting. *Automation of Electric Power Systems*, **30**, 92-101.

[2] Catalão, J.P.S. (2017) Electric Power Systems Advanced Forecasting Techniques and Optimal Generation Scheduling. CRC Press, Boca Raton.

[3] Keles, D., Scelle, J., Paraschiv, F., *et al*. (2016) Extended Forecast Methods for Day-Ahead Electricity Spot Prices Applying Artificial Neural Networks. *Applied Energy*, **162**, 218-230. https://doi.org/10.1016/j.apenergy.2015.09.087

[4] Hernandez, L., Baladrón, C., Aguiar, J.M., *et al*. (2013) Short-Term Load Forecasting for Microgrids Based on Artificial Neural Networks. *Energies*, **6**, 1385-1408. https://doi.org/10.3390/en6031385

[5] 周黎英, 赵国树. 人工神经网络在电价预测中的应用[J]. 水电能源科学, 2010, 28(6): 153-156.

[6] Szkuta, B.R., Sanabria, L.A. and Dillon, T.S. (1999) Electricity Price Short-Term Forecasting Using Artificial Neural Networks. *IEEE Transactions on Power Systems*, **14**, 851-857. https://doi.org/10.1109/59.780895

[7] Alanis, A.Y. (2018) Electricity Prices Forecasting Using Artificial Neural Networks. *IEEE Latin America Transactions*, **16**, 105-111. https://doi.org/10.1109/TLA.2018.8291461

[8] López, A.S.D.L.N., González, V. and Contreras, J. (2016) Portfolio Decision of Short-Term Electricity Forecasted Prices through Stochastic Programming. *Energies*, **9**, 1-19.

[9] Zhou, M., Yan, Z., Ni, Y.X., *et al.* (2006) Electricity Price Forecasting with Confidence-Interval Estimation through an Extended ARIMA Approach. *IEE Proceedings—Generation*, *Transmission and Distribution*, **153**, 187-195. https://doi.org/10.1049/ip-gtd:20045131

[10] Conejo, A.J., Plazas, M.A., Espinola, R., *et al.* (2005) Day-Ahead Electricity Price Forecasting Using the Wavelet Transform and ARIMA Models. *IEEE Transactions on Power Systems*, **20**, 1035-1042. https://doi.org/10.1109/TPWRS.2005.846054

[11] 周明, 严正, 倪以信, 李庚银. 含误差预测校正的 ARIMA 电价预测新方法[J]. 中国电机工程学报, 2004, 24(12): 67-72.

[12] Contreras, J., Espinola, R., Nogales, F.J., *et al*. (2003) ARIMA Models to Predict Next-Day Electricity Prices. *IEEE Transactions on Power Systems*, **18**, 1014-1020. https://doi.org/10.1109/TPWRS.2002.804943

[13] Osório, G.J., Gonçalves, J.N.D.L., Lujano-Rojas, J.M., *et al.* (2016) Enhanced Forecasting Approach for Electricity Market Prices and Wind Power Data Series in the Short-Term. *Energies*, **9**, 693. https://doi.org/10.3390/en9090693

[14] Jiang, P., Liu, F. and Song, Y. (2016) A Hybrid Multi-Step Model for Forecasting Day-Ahead Electricity Price Based on Optimization, Fuzzy Logic and Model Selection. *Energies*, **9**, 618. https://doi.org/10.3390/en9080618

[15] Cerjan, M., Matijaš, M. and Delimar, M. (2014) Dynamic Hybrid Model for Short-Term Electricity Price Forecasting. *Energies*, **7**, 3304-3318. https://doi.org/10.3390/en7053304

[16] 林其友, 陈星莺, 王之伟. 数据挖掘技术在电价预测中的应用[J]. 电网技术, 2006(23): 83-87.

[17] Zhao, J.H., Dong, Z.Y., Li, X., *et al*. (2007) A Framework for Electricity Price Spike Analysis with Advanced Data Mining Methods. *IEEE Transactions on Power Systems*, **22**, 376-385. https://doi.org/10.1109/TPWRS.2006.889139

[18] 袁贵川, 程利, 王建全. 利用数据挖掘进行短期电价预测[J]. 电力系统及其自动化学报, 2003(2): 19-23.

[19] Huang, D., Zareipour, H., Rosehart, W.D., *et al*. (2012) Data Mining for Electricity Price Classification and the Application to Demand-Side Management. *IEEE Transactions on Smart Grid*, **3**, 808-817. https://doi.org/10.1109/TSG.2011.2177870

[20] Neupane, B., Wei, L.W. and Aung, Z. (2016) Ensemble Prediction Model with Expert Selection for Electricity Price Forecasting. *Energies*, **10**, 77. https://doi.org/10.3390/en10010077

[21] Gonzalez, V., Contreras, J. and Bunn, D.W. (2012) Forecasting Power Prices Using a Hybrid Fundamental-Econometric Model. *IEEE Transactions on Power Systems*, **27**, 363-372. https://doi.org/10.1109/TPWRS.2011.2167689

[22] Dragomiretskiy, K. and Zosso, D. (2014) Variational Mode Decomposition. *IEEE Transactions on Signal Processing*, **62**, 531-544. https://doi.org/10.1109/TSP.2013.2288675

[23] 贾亚飞, 朱永利, 王刘旺, 李莉. 基于 VMD 和多尺度熵的变压器内绝缘局部放电信号特征提取及分类[J]. 电工技术学报, 2016, 31(19): 208-217.

[24] 张宁, 朱永利, 高艳丰, 赵磊, 陈旭, 郭小红. 基于变分模态分解和概率密度估计的变压器绕组变形在线检测方法[J]. 电网技术, 2016, 40(1): 297-302.

[25] Sun, G., Chen, T., Wei, Z., *et al*. (2016) A Carbon Price Forecasting Model Based on Variational Mode Decomposition and Spiking Neural Networks. *Energies*, **9**, 54. https://doi.org/10.3390/en9010054

[26] Lin, Y., Luo, H., Wang, D., *et al*. (2017) An Ensemble Model Based on Machine Learning Methods and Data Preprocessing for Short-Term Electric Load Forecasting. *Energies*, **10**, 1186. https://doi.org/10.3390/en10081186

[27] 梁智, 孙国强, 李虎成, 卫志农, 臧海祥, 周亦洲, 陈霜. 基于 VMD 与 PSO 优化深度信念网络的短期负荷预测[J]. 电网技术, 2018, 42(2): 598-606.

[28] Li, J., Shi, J. and Li, J. (2016) Exploring Reduction Potential of Carbon Intensity Based on Back Propagation Neural Network and Scenario Analysis: A Case of Beijing, China. *Energies*, **9**, 615. https://doi.org/10.3390/en9080615

Hans 汉斯

知网检索的两种方式：

1. 打开知网页面 http://kns.cnki.net/kns/brief/result.aspx?dbPrefix=WWJD
   下拉列表框选择：[ISSN]，输入期刊 ISSN：2161-8763，即可查询
2. 打开知网首页 http://cnki.net/
   左侧“国际文献总库”进入，输入文章标题，即可查询

投稿请点击：http://www.hanspub.org/Submission.aspx
期刊邮箱：sg@hanspub.org