基于分解 – 优化 – 集成学习方法的电价预测

蒋锋^{1*}, 何佳琪¹, 曾志刚^{2*}, 田天海³

1. 中南财经政法大学统计与数学学院, 武汉 400073, 中国

2. 华中科技大学自动化学院, 武汉 430074, 中国

3. School of Mathematical Science, Monash University, Melbourne Clayton 3800, Australia

* 通信作者. E-mail: fjiang78@163.com, zgzheng@hust.edu.cn

收稿日期: 2018-03-30; 接受日期: 2018-05-25; 网络出版日期: 2018-10-09

国家自然科学基金 (批准号: 61773401, 61304067, 11601524, 61761130081, 11571368) 资助项目

摘要 随着新一轮电力市场改革的持续推进, 电价作为反映市场运营状况的重要指标, 准确预测电价能够帮助电力市场博弈方进行风险规避, 达到经济收益最大化. 本文提出了一种新的基于分解 – 优化 – 集成 (decomposition-optimization-ensemble, DOE) 的混合学习模型来预测电价, 首先利用快速集成经验模态分解方法将波动性较大的电价数据分解成一系列本征模态函数和一个残差序列. 然后对鲸鱼算法从收敛速度、精度和算法搜索能力 3 个方面进行改进, 再利用改进的鲸鱼算法优化径向基神经网络的扩展系数, 采用优化后的径向基神经网络模型对分解得到的本征模态函数和残差序列进行预测. 最后对分解后的子序列预测值进行集成, 得到电价的预测值. 为了验证混合学习模型的预测效果, 本文对美国宾夕法尼亚 – 新泽西 – 马里兰电力市场的电价进行中长期和短期预测. 实证结果显示 DOE 混合学习模型在水平精度和方向精度上均能获得很好的效果.

关键词 电价预测, 快速集成经验模态分解, 改进的鲸鱼算法, 径向基神经网络, 方向精度

1 引言

2015 年 3 月, 中共中央、国务院印发《关于进一步深化电力体制改革的若干意见》, 标志着新一轮电力市场改革正式开始. 新电改放开了电力市场的售电侧, 使我国的电力市场逐渐走向市场化. 电能作为电力市场中的一种特殊产品, 电价是反映电力市场运营情况、评价电力市场竞争效率的重要指标, 是电力市场各博弈方进行科学决策的基础. 对电价数据进行准确预测可以帮助售电企业决定市场的日前报价, 最大限度地规避风险、提高收益, 同时也能够为发电企业的发电扩容提供价格信号. 因此, 对波动频率较大的电价数据进行准确预测已经成为电力市场各交易方研究的核心问题.

近年来, 国内外诸多学者已经对电价的预测进行了深入研究, 并提出了一系列预测方法. 目前电价预测方法主要有经典的统计方法^[1,2]、机器学习 (machine learning, ML) 方法^[3,4]. 随着大数据时

引用格式: 蒋锋, 何佳琪, 曾志刚, 等. 基于分解 – 优化 – 集成学习方法的电价预测. 中国科学: 信息科学, 2018, 48: 1300–1315, doi: 10.1360/N112018-00075
Jiang F, He J Q, Zeng Z G, et al. Decomposition-optimization-ensemble learning approach for electricity price forecasting (in Chinese). Sci Sin Inform, 2018, 48: 1300–1315, doi: 10.1360/N112018-00075

代的到来, ML 方法吸引了学者们的目光. ML 方法可以更好地对非线性数据进行拟合, 目前已经在电价预测、太阳能辐射量预测、风电功率预测、股票数据等预测方面取得了较好的预测效果. 其中, 主要的 ML 方法包括: 人工神经网络^[5~10]、支持向量机^[11~14]、新型元启发式优化算法^[15~17]等. 比如, Maciejowska 等^[1]利用因子分位数回归平均法 (factor quantile regression averaging, FQRA) 对英国电力市场的电力现货价格进行了区间预测和精度检验, 相比较于基准的 ARX (autoregressive model with exogenous variables) 模型和 QRA 模型, FQRA 模型可以更好地对电价的预测区间进行估计和计算. Conejo 等^[2]提出了一种基于小波变换和自回归积分滑动平均模型的日前电价预测方法, 在利用小波变换方法对部分波动异常的电价数据进行分解后, 采用自回归积分滑动平均模型对西班牙 2002 年的电价进行了预测, 改进模型的预测误差略低于传统的自回归积分滑动平均模型. Özgüner 等^[9]运用波动分析、Bienayme-Chebyshev 不等式和人工智能神经网络模型预测土耳其电力市场 (Turkey electricity market, TEM) 的每小时市场出清价格, 同时根据 TEM 电力市场的历史电价数据优化了神经网络模型的网络结构, 实验结果表明该模型的预测值与 TEM 电价数据的真实值较为贴近, 但其预测结果仍会出现平均绝对百分比误差较大的情况, 其平均绝对百分比误差达到了 10% 以上. Yan 等^[14]在对电价进行模块分类后, 运用并行的最小二乘支持向量机模型对美国宾夕法尼亚 - 新泽西 - 马里兰 (Pennsylvania-New Jersey-Maryland, PJM) 电力市场的出清价格进行中期预测, 并行的最小二乘支持向量机模型的预测精度高于单一最小二乘支持向量机模型的预测精度.

由于电价、风速、太阳辐射量等数据具有强烈的波动性和非线性性以及预测精度要求的不断提高, 混合模型已经受到广泛关注^[18~20]. Wang 等^[21]利用多目标鲸鱼算法 (whale optimization algorithm, WOA) 对风速进行了预测. Bento 等^[22]提出了一种新的混合算法, 首先以量化共轭梯度算法作为多层前馈神经网络的训练算法, 其次利用蝙蝠算法对区域空间进行优化, 解决了神经网络和小波分析的参数优化问题, 最后运用小波分析和神经网络的方法对西班牙电力市场和 PJM 电力市场的电价数据进行了短期预测. Wang 等^[23]运用快速集成经验模态分解 (fast ensemble empirical mode decomposition, FEEMD) 和变分模态分解 (variational mode decomposition, VMD) 方法对澳大利亚和法国电力市场的原始电价数据进行了二次分解, 并利用萤火虫算法 (firefly algorithm, FA) 优化 BP 神经网络模型 (back propagation neural network, BPNN) 对电价数据的子序列分别进行短期预测, 结果显示基于混合算法的预测效果远优于 BPNN, FA-BPNN 等模型的预测效果. Shayaneghi 等^[24]提出了一种基于广义互信息 - 小波包变换 - 最小二乘支持向量机的混合算法对西班牙等 3 个电力市场的电价进行预测, 同时利用改进算法优化最小二乘支持向量机的主要参数, 有效提高了单一模型的预测性能.

本文提出了一种新的分解 - 优化 - 集成 (decomposition-optimization-ensemble, DOE) 混合学习模型, 对电价进行中长期和短期预测. 本文主要贡献在于: (1) 为了克服电价数据的显著波动性和非线性, 采用 FEEMD 方法对电价进行分解; (2) 对经典 WOA 采用量子旋转门优化、随机参数的非线性变换以及对鲸鱼位置的动态权重赋值 3 个方面进行改进, 利用改进的鲸鱼算法 (improved whale optimization algorithm, IWOA) 优化径向基神经网络 (radical basis function, RBF) 的扩展系数, 提高了 RBF 的预测精度; (3) 提出的 FEEMD-IWOA-RBF 混合学习模型, 在电价的预测上具有更好的水平预测精度和方向预测精度.

2 方法与改进

电价数据具有强烈的非线性和波动性, 单一预测模型不能很好地拟合电价数据的变动情况, 因此通过分解、优化、集成的方式构建新的混合学习模型对电价进行预测.

2.1 快速集成经验模态分解

FEEMD 是由 Wang 等^[25] 在集成经验模态分解 (ensemble empirical mode decomposition, EEMD) 基础上改进的一种分解算法. FEEMD 能够快速、充分地分解非平稳、非线性的时间序列数据, 有效改善了经验模态分解 (empirical mode decomposition, EMD) 中的模态重叠效应以及 EEMD 算法中庞大的运算量问题, 其基本思想是 Hilbert-Huang 变换. FEEMD 优化了传统 EEMD 算法中样条差值过程和停止判断准则, 提高了算法执行的时效性, 能快速将原始序列拆解成一系列低频的本征模态函数 (intrinsic mode functions, IMFs) 和一个残差序列, 其具体步骤如下:

- (1) 输入原始信号, 设置集成数目和复制倍数, 同时在原始信号中添加一个 Gauss 白噪声序列;
- (2) 将添加白噪声后的信号分解成若干 IMFs 和一个残差序列;
- (3) 利用不同的白噪声序列重复上述步骤, 直到达到算法的最大迭代次数;
- (4) 求各本征模态函数和残差序列的均值, 即可得到原始信号的最终拆解序列.

2.2 径向基神经网络

RBF 与 BPNN 的结构相似, 是由输入层、隐藏层和输出层构成的一种前向神经网络. RBF 的基本思想是利用径向基函数作为隐单元的“基”构成隐藏层空间, 隐藏层对输入矢量进行变换, 将低维模式的输入数据变换到高维空间内, 使得在低维空间内线性不可分的问题在高维空间内线性可分. RBF 的收敛速度较快, 网络结构简单, 能够有效逼近任意非线性数据, 在时间序列的数据中具有广泛的应用. RBF 神经网络的网络输出为

$$y_j = \sum_{i=1}^h \omega_{ij} \exp \left(-\frac{1}{2\sigma^2} \|x_p - c_i\|^2 \right), \quad j = 1, 2, \dots, n, \quad (1)$$

其中 x_p 为第 p 个输入样本, c_i 为 RBF 隐藏层节点的中心, $\|x_p - c_i\|^2$ 为欧式范数, σ 为基函数的扩展常数, w_{ij} ($i = 1, 2, \dots, h$) 表示隐藏层与输出层之间的权值, y_j 为 RBF 的第 j 个输出值.

2.3 经典鲸鱼算法

WOA 是一种通过模拟座头鲸捕食过程寻求全局最优解的新兴元启发式群体算法, 算法主要模拟座头鲸利用气泡网攻击猎物的方式进行寻优, 座头鲸的气泡网攻击方式可以参考文献 [20] 中的图 2. 座头鲸的气泡网攻击方式主要分为收缩包围和螺旋曲线包围两种方法, 并假定两种方法发生概率相同.

当座头鲸采用气泡网包围的方式进行捕食时, 由于猎物位置的不确定性, WOA 将当前迭代次数中适应度最优的鲸鱼位置近似看作猎物的位置, 从而引导其他鲸鱼更新各自的位置坐标, 实现对猎物的收缩包围. 座头鲸的收缩包围过程如下:

$$\text{Dis} = |X(l) - C \cdot X_{\text{prey}}^*(l)|, \quad (2)$$

$$X(l+1) = X_{\text{prey}}^*(l) - A \cdot \text{Dis}, \quad (3)$$

$$\text{Dis} = |X(l) - C \cdot X_{\text{rand}}|, \quad (4)$$

$$X(l+1) = X_{\text{rand}}(l) - A \cdot \text{Dis}, \quad (5)$$

$$A = 2a \cdot r - a, \quad (6)$$

其中 l 代表迭代次数, $X(l)$, $X_{\text{prey}}^*(l)$ 分别表示当前迭代过程中鲸鱼和猎物的位置, $X_{\text{rand}}(l)$ 表示当前迭代过程中任意一只鲸鱼的位置, Dis 表示鲸鱼到猎物的距离.

C 和 a 为算法迭代过程中的两个重要参数, $C = 2 \cdot r$ (r 为 0 到 1 之间的随机数) 为算法施加给猎物位置的一个随机权重, 为了模拟自然界鲸鱼的捕食过程, 防止鲸鱼快速发现猎物, 随机权重增加了鲸鱼捕食的难度, 能够在一定程度上防止鲸鱼算法陷入局部最优值. 随机参数 a 提高了鲸鱼算法的全局搜索能力和局部搜索能力, 它是从 2 到 0 线性递减的. 当随机系数 $|A| < 1$ 时, 鲸鱼开始进行局部搜索, 鲸鱼根据 (3) 逐代更新位置坐标; 当随机系数 $|A| \geq 1$ 时, 鲸鱼开始跳出局部范围, 放弃当前的猎物开始进行全局搜索, 此时鲸鱼根据 (5) 来更新位置坐标.

螺旋曲线包围是座头鲸对猎物的另一种攻击方式, 座头鲸根据 (7) 对位置坐标进行更新.

$$X(l+1) = \text{Dis}' \cdot e^{bt} \cos(2\pi l) + X_{\text{prey}}^*(l+1), \quad (7)$$

其中 $\text{Dis}' = |X_{\text{prey}}^*(l) - X(l)|$ 表示鲸鱼到猎物的距离, b 代表一个可以改变螺旋曲线形状的常数, t 为 0 到 1 之间的随机数.

2.4 改进的量子鲸鱼算法

为了有效提高 WOA 的寻优能力, 本文对鲸鱼的位置坐标采用量子旋转门优化、对随机参数进行非线性波变换, 以及权重的动态赋值 3 个方面对 WOA 进行改进.

诺贝尔物理学获得者 Richard Feynman 于 1982 年首次提出了量子计算的概念. 在量子信息论中, 信息的基本载体 – 量子比特状态可以表示为

$$|\varphi\rangle = \alpha|0\rangle + \beta|1\rangle, \quad |\alpha|^2 + |\beta|^2 = 1, \quad (8)$$

其中 α 和 β 分别为量子计算中的两个复数, $|0\rangle$ 和 $|1\rangle$ 分别表示量子比特的两种极化状态, $|\alpha|^2$ 和 $|\beta|^2$ 是量子比特处于两种极化状态的概率.

受到量子计算与遗传算法融合的思想^[26], 在 WOA 中我们引进量子旋转门 (9) 更新所有鲸鱼的位置坐标, 通过式 (10) 得到新的鲸鱼位置 QCX(l).

$$\begin{pmatrix} \alpha_i^t \\ \beta_i^t \end{pmatrix} = \begin{pmatrix} \cos(\theta_i) & -\sin(\theta_i) \\ \sin(\theta_i) & \cos(\theta_i) \end{pmatrix} \begin{pmatrix} \alpha_i \\ \beta_i \end{pmatrix}, \quad (9)$$

$$\text{QCX}(l) = |X(l) \cdot \cos(\theta) - \sqrt{1 - X(l)^2} \cdot \sin(\theta)|, \quad (10)$$

其中 (α_i, β_i) 为第 i 个量子比特, θ_i 为旋转角, QCX(l) 为在第 l 次迭代过程中经过量子旋转门更新后的鲸鱼位置. 在对鲸鱼位置进行量子旋转门更新后, 根据鲸鱼的适应度值择优进入下一次迭代, 量子旋转门优化能够有效提高鲸鱼群体的多样性和算法的收敛精度.

在量子优化的鲸鱼算法中, 随机参数 a 从 2 到 0 线性递减, a 的变化直接影响算法的局部搜索能力和全局搜索能力. 然而在算法的迭代过程中, a 的线性变化不能有效反应参数的收敛过程. 因此, 给出下面一种新的非线性收敛方式:

$$a = \frac{2}{1 + \exp(0.05l - 5)}, \quad (11)$$

显然随机参数 a 能够保证参数从 2 收敛到 0, 其收敛过程可以有效提高算法的局部和全局寻优能力, 令

$$\vartheta = \frac{f(x_{\text{prey}}^*)}{\sum_{i=1}^N f(x_i)}, \quad (12)$$

$$X(l+1) = \vartheta \cdot X_{\text{prey}}^*(l) - A \cdot \text{Dis}, \quad (13)$$

其中 $f(x_i)$ 表示在每次迭代过程中, 第 i 只鲸鱼的适应度值, $f(x_{\text{prey}}^*)$ 为猎物的适应度值, ϑ 为改进算法赋给猎物位置的动态权重. 为了提高算法的局部寻优能力, 受到粒子群算法^[27]的启发, 采用动态权重赋值的方式进一步对式 (3) 改进. 根据鲸鱼个体的适应度值, 利用式 (12) 和 (13) 更新鲸鱼的位置坐标, IWOA 算法的学习框架伪代码 (见算法 1).

算法 1 IWOA 算法

```

1: Initialize the whales' population  $X_i (i = 1, 2, \dots, n)$  and calculate the fitness of each whale;
2:  $X_{\text{prey}}^*$  = the fittest whale (a similar position of the prey);
3: while  $l < \text{maximum number of iterations}$ 
4:   for each whale
5:     Update  $a, A, C, t$  and  $p$ ;
6:     if1  $p < 0.5$ 
7:       if2  $|A| < 1$ 
8:         update the position of the current whale by (13);
9:       else if2  $|A| > 1$ 
10:        Select a random whale  $X_{\text{rand}}$ ;
11:        Update the position of the current whale by (5);
12:       end if2
13:     else if1  $p > 0.5$ 
14:       Update the position of the current whale by (7);
15:     end if1
16:   Using quantum method to update the positions of all the whales by (10);
17:   Choose the better updating method by comparing the fitness of (5), (7), (13) and (10);
18: end for
19:   Check if any whale goes beyond the search space and amend it;
20:   Calculate the fitness of each whale;
21:   Update  $X_{\text{prey}}^*$  if there is a better solution;
22:    $l = l + 1$ ;
23: end while
24: return  $X_{\text{prey}}^*$ .

```

2.5 FEEMD-IWOA-RBF 混合学习框架

为了提高非线性数据的水平预测精度和方向预测精度, 本文提出了一种新的 FEEMD-IWOA-RBF 的混合学习模型. 首先利用 FEEMD 算法对波动性较大的非线性时间序列进行分解; 其次利用 IWOA 优化 RBF 的扩展系数, 即以鲸鱼的位置坐标作为 RBF 的扩展系数, 逐代更新鲸鱼的位置, 当算法停止迭代时, 适应度最优的鲸鱼位置坐标就为 RBF 的最佳扩展系数; 再利用优化后的 RBF 分别对 FEEMD 分解出的本征模态函数和残差序列进行预测; 最后集成得到原始时间序列的预测值, FEEMD-IWOA-RBF 混合学习模型框架图如图 1 所示.

3 实证分析

本节利用提出的 DOE 混合学习方法对美国宾夕法尼亚 – 新泽西 – 马里兰电力市场 (PJM) 的数据进行中长期和短期预测, 并对算法的预测结果进行了误差分析、检验及对比分析与讨论.

图 1 (网络版彩图) FEEMD-IWOA-RBF 混合学习框架
Figure 1 (Color online) Hybrid learning framework of FEEMD-IWOA-RBF

3.1 数据来源与评价准则

本小节考察美国 PJM 电力市场 2017 年 1 月 1 日至 2018 年 2 月 28 日的 10176 个电价观测数据. 从图 2 我们看到电价数据同股票和债券等金融产品的数据相比, 电价数据的波动表现得异常频繁. 为了验证 FEEMD-IWOA-RBF 混合学习模型的适用性及可推广性, 对 PJM 电力市场的电价数据进行了中长期预测和短期预测. 其中中长期预测的训练集为 2017 年 1 月 1 日至 2018 年 1 月 31 日每小时的电价数据, 测试集为 2018 年 2 月份 4 周的电价数据; 电价短期预测的训练集为 2017 年 1 月 1 日至 2018 年 2 月 26 日的电价数据, 2018 年 2 月 27 日至 2018 年 2 月 28 日 48 小时的电价数据作为测试集. 接着为了从水平预测精度和方向精度来比较不同模型的预测性能, 我们选择均方根误差 (RMSE)、标准均方根误差 (NRMSE)、平均绝对百分比误差 (MAPE)、平均绝对误差 (MAE)、Theil 不等式系数 (TIC) 和方向统计量 (D_s) 6 个评价指标, 并采用 Diebold-Mariano (DM) 检验来比较不同预测模型的预测能力是否显著相同, 采用 Pesaran Timmermann (PT) 检验来验证模型预测值的方向变化是否与真实值的变化方向相同^[19]. 其中 DM 检验以预测误差平方作为损失函数, 原假设为测试模型的预测精度优于基准模型. D_s 统计量能够用来判断模型的预测结果是否与真实值的变动方向相同, D_s 统计量是方向维度上的一种误差评价标准, 常用在波动性较大的非线性数据中.

$$\text{RMSE} = \sqrt{\sum_{l=1}^M (\hat{Y}(l) - Y(l))^2 / M}, \quad \text{NRMSE} = \frac{100}{\bar{Y}} \sqrt{\sum_{l=1}^M (\hat{Y}(l) - Y(l))^2 / M},$$

图 2 (网络版彩图) PJM 电力市场原始电价数据

Figure 2 (Color online) Original data of electricity price in PJM market

$$\text{MAPE} = \frac{1}{M} \sum_{l=1}^M \left| \frac{\hat{Y}(l) - Y(l)}{Y(l)} \right| \times 100\%, \quad \text{MAE} = \frac{1}{M} \sum_{l=1}^M |\hat{Y}(l) - Y(l)|,$$

$$\text{TIC} = \frac{\sqrt{\sum_{l=1}^M (\hat{Y}(l) - Y(l))^2 / M}}{\sqrt{\sum_{l=1}^M (\hat{Y}(l))^2 / M} + \sqrt{\sum_{l=1}^M (Y(l))^2 / M}}, \quad D_s = \frac{1}{M} \sum_{l=1}^M \varphi(l) \times 100\%,$$

其中 M 为观测的样本个数, $Y(l)$ 和 $\hat{Y}(l)$ 分别为样本的真实值和预测值, $\bar{Y}$ 为样本真实值的平均值. 若 $(\hat{Y}(l+1) - Y(l))(Y(l+1) - Y(l)) \geq 0$, 则 $\varphi(l) = 1$; 否则 $\varphi(l) = 0$.

3.2 实证结果

本小节对混合模型的实证对比结果进行对比分析, 选取了包括单一模型和混合模型在内的 8 个对比模型. 同时, 从水平精度和方向精度两个方面进行误差分析, 并利用 DM 检验和 PT 检验对预测结果进行统计指标的检验, 进而与文献 [14, 23] 作对比分析, 验证新学习模型在电价预测中的优越性.

3.2.1 FEEMD 分解

对 PJM 电价数据进行 FEEMD 分解, 得到 8 个本征模态函数和 1 个残差序列. 并设所添加的白噪声标准差为 0.2, 本征模态函数的波动率从上至下依次递减. 图 3 显示了利用 FEEMD 分解后的电价序列, 其原始数据的波动性得到了较好的分解. 同时, VMD 算法 [23] 也是一种用来分解信号的常用方法, 为了综合验证分解 – 优化 – 集成混合学习模型的预测性能, 本文选择了 FEEMD-WOA-RBF, VMD-IWOA-RBF, VMD-WOA-RBF, SVR [14], BPNN, RBF, 鲸鱼算法优化径向基神经网络 (WOA-RBF), IWOA-RBF 作为 FEEMD-IWOA-RBF 学习方法的对比模型.

3.2.2 模型对比分析

本小节利用 IWOA-RBF 模型对分解出的 9 个时间序列进行中长期和短期预测, 并利用加性集成方法得到最终预测结果. 图 4~7 分别为 9 种预测模型中长期和短期预测的相对误差对比图, 图 8~13 分别展示了 9 种预测模型在 RMSE, NRMSE, MAPE, MAPE, TIC 以及 D_s 6 种统计评价指标下的误差结果对比; 表 1 和 2 为改进模型中长期预测和短期预测的误差结果对比表, 表 3 和 4 为检验中长期

图 3 (网络版彩图) FEEMD 算法分解后的电价序列

Figure 3 (Color online) Electricity price decomposed by FEEMD

图 4 (网络版彩图) 预测模型中长期预测相对误差

Figure 4 (Color online) Related error of mid-long-term prediction of forecasting models

预测和短期预测水平精度的 DM 检验结果, 表 5 为检验中长期预测和短期预测方向精度的 PT 检验结果.

从图 4~13 中, 可以得出如下结论: (1) 根据预测模型相对误差对比结果可以看出, FEEMD-IWOA-RBF 模型的预测效果最佳, 可以很好地对电价数据进行中长期和短期预测, 而 VMD-WOA-RBF 和 SVR 模型的预测效果最差; (2) 在中长期和短期预测中, IWOA 能够有效优化 RBF 的扩展系数, 提高了 RBF 的预测精度, FEEMD 分解算法能够将波动性较大的电价数据分解成波动率较小的子序列, 利用 IWOA-RBF 模型可以更好地对分解后的数据进行预测, FEEMD-IWOA-RBF 混合学习模型的预测

图 5 (网络版彩图) 预测模型短期预测相对误差

Figure 5 (Color online) Related error of short-term prediction of forecasting models

图 6 (网络版彩图) 混合模型中长期预测相对误差

Figure 6 (Color online) Related error of mid-long-term prediction of hybrid models

精度远高于利用其他模型; (3) 在预测模型中, SVR 的预测性能在水平精度和方向精度上均为所有模型中最低的, 而 BPNN 和 RBF 在不同维度上的预测效果相当, 但总体来看 RBF 的预测效果略高于 BPNN; (4) FEEMD-IWOA-RBF 混合学习模型在中长期预测和短期预测中, 其 NRMSE 的值分别为 9.1719% 和 12.3808%, 而其他模型的 NRMSE 远远高于 15%, 根据 Lewis^[28] 的研究结果显示, NRMSE 在 5%~15% 之间的模型可以对被研究对象进行准确预测, 因此, 本文提出的混合学习模型可以更好地对电价进行预测; (5) TIC 系数是衡量 RMSE 的另一项重要指标, TIC 的取值在 0 到 1 之间, TIC 越趋近于 0, 模型的预测效果越好. 在预测结果中, FEEMD-IWOA-RBF 模型的 TIC 值均保持在 0.05 左右, 其预测效果远优于其他 8 个对比模型的预测效果; (6) 本文提出的新混合学习模型的 D_s 均达到 84% 以上, 而未利用 FEEMD 分解方法的预测模型, 最大的 D_s 统计量的值仅为 63.83%, 从方向的维度上验证了 FEEMD-IWOA-RBF 混合学习模型预测的优越性; (7) 在 4 种混合分解模型中, VMD-IWOA-RBF 和 VMD-WOA-RBF 的预测精度最低, 远低于 FEEMD-IWOA-RBF 模型的预测精度, 说明 FEEMD 方法更适用于对非线性数据进行分解.

通过表 1 和 2 可以得出如下结论: (1) 无论是电价数据的中长期预测还是短期预测, IWOA 都能够对 RBF 的参数进行有效寻优, 在两次预测过程中, IWOA 将原始 RBF 的预测误差分别降低了 30% 和

图 7 (网络版彩图) 混合模型短期预测相对误差

Figure 7 Related error of short-term prediction of hybrid models

图 8 (网络版彩图) 模型的 RMSE 结果对比图

Figure 8 (Color online) RMSE of predicting models

图 9 (网络版彩图) 模型的 NRMSE 结果对比

Figure 9 (Color online) NRMSE of predicting models

图 10 (网络版彩图) 模型的 MAPE 结果对比图

Figure 10 (Color online) MAPE of predicting models

图 11 (网络版彩图) 模型的 MAE 结果对比

Figure 11 (Color online) MAE of predicting models

50% 以上; (2) FEEMD 是一种有效的分解方法, 能够对波动率较大的非线性数据进行合理分解, 降低了模型的预测难度, FEEMD-IWOA-RBF 混合学习能够将 IWOA-RBF 的预测误差降低 50%~60%; (3) FEEMD 方法的分解效果远远优于 VMD 分解, 相较于 VMD-IWOA-RBF 模型, FEEMD-IWOA-RBF 混合模型的预测效果在水平精度上将误差降低了 50% 以上。

在表 1 中, 利用 FEEMD 方法对电价进行分解后, 虽然混合模型 FEEMD-IWOA-RBF 的平均绝

图 12 (网络版彩图) 模型的 TIC 结果对比图
Figure 12 (Color online) TIC of predicting models

图 13 (网络版彩图) 模型的 D_s 结果对比
Figure 13 (Color online) D_s of predicting models

表 1 改进模型的中长期预测误差对比

Table 1 Error analysis results of improved models of mid-long-term prediction

Evaluating indicator	Error reduction (100%)				
	FEEMD-IWOA-RBF vs. VMD-IWOA-RBF	FEEMD-IWOA-RBF vs. IWOA-RBF	FEEMD-IWOA-RBF vs. RBF	IWOA-RBF vs. WOA-RBF	IWOA-RBF vs. RBF
RMSE	89.6009	64.0848	77.8211	17.1842	38.2465
NRMSE	89.6047	64.1062	77.8208	17.1842	38.2088
MAPE	92.9205	60.0071	72.0683	8.6842	30.1584
MAE	57.3394	-350.000	10.5769	82.6923	82.6923
TIC	88.2116	63.9967	77.3153	5.9384	36.9927
D_s	38.5564	34.6831	33.6268	0.5392	1.5915

表 2 改进模型的短期预测误差对比

Table 2 Error analysis results of improved models of short-term prediction

Evaluating indicator	Error reduction (100%)				
	FEEMD-IWOA-RBF vs. VMD-IWOA-RBF	FEEMD-IWOA-RBF vs. IWOA-RBF	FEEMD-IWOA-RBF vs. RBF	IWOA-RBF vs. WOA-RBF	IWOA-RBF vs. RBF
RMSE	88.0326	54.2226	77.1650	20.2163	50.1173
NRMSE	88.0379	54.2376	77.1725	20.2168	50.1174
MAPE	92.9313	54.0561	75.1738	21.5856	45.9642
MAE	85.6757	48.6835	89.4479	79.4372	79.4372
TIC	63.4663	54.3258	76.3710	73.8163	48.2661
D_s	46.3414	36.5854	26.8292	-10.3449	10.3449

对误差比 IWOA-RBF 的平均绝对误差提高了 350%, 但是平均绝对误差属于一种绝对值统计量, 不能很好地度量两种模型的预测效果. 本文通过进行 DM 检验来从统计学的意义上评价两种模型的预测性能, 从表 3 中可以看出, 在置信度为 95% 的水平下, FEEMD-IWOA-RBF 的预测效果明显优于 IWOA-RBF. 因此, 不能单一地通过计算 MAE 等统计评价指标来判断模型的预测性能, 而是需要根据统计学检验方法来对模型的预测效果进行综合评价. 表 2 中 IWOA-RBF 将 WOA-RBF 方向统计量的误差提高了 10.3449%, 但根据 PT 检验的结果, 由于电价具有强烈的波动性, IWOA-RBF 和 WOA-RBF 都难以对电价的变动方向进行有效预测, 表明了 FEEMD 分解方法在电价预测中的必要性.

表 3 电价中长期预测的 DM 检验结果表^{a)}

Table 3 DM test results of electricity price mid-long-term forecasting

Tested model	Benchmark model							
	FEEMD- WOA-RBF	VMD- IWOA-RBF	VMD- WOA-RBF	IWOA- RBF	WOA-RBF	RBF	BPNN	SVR
FEEMD- IWOA-RBF	1.1368 (0.8720)	9.2603 (1.0000)	9.2547 (1.0000)	0.4285 (0.9546)	2.1887 (0.9855)	1.6479 (0.9501)	3.3695 (0.9996)	42.7820 (1.0000)
FEEMD- WOA-RBF		4.3688 (1.0000)	4.3695 (1.0000)	-0.7944 (0.2136)	-0.6698 (0.2516)	2.2486 (0.9876)	1.0601 (0.8533)	6.6285 (1.0000)
VMD- IWOA-RBF			1.0925 (0.8621)	-10.8100 (2E-16)	-10.6180 (2E-16)	-2.1621 (0.0155)	-4.2964 (9.9E-6)	1.7575 (0.9604)
VMD- WOA-RBF				-10.8030 (2E-16)	-10.6120 (2E-16)	-2.1632 (0.0154)	-4.2976 (9.9E-6)	1.7535 (0.9600)
IWOA-RBF					2.0274 (0.9875)	1.4617 (0.9278)	2.9284 (0.9982)	28.5080 (1.0000)
WOA-RBF						1.3862 (0.9169)	2.8616 (0.9978)	27.7560 (1.0000)
RBF							-0.1602 (0.4364)	3.0827 (0.9989)
BPNN								8.3562 (1.0000)

a) 表中未加括号的指标为 DM 统计量, 括号中的指标为 DM 统计量对应的 p 值.表 4 电价短期预测的 DM 检验结果^{a)}

Table 4 DM test results of electricity price short-term forecasting

Tested model	Benchmark model							
	FEEMD- WOA-RBF	VMD- IWOA-RBF	VMD- WOA-RBF	IWOA- RBF	WOA-RBF	RBF	BPNN	SVR
FEEMD- IWOA-RBF	1.3318 (0.9053)	3.6532 (0.9997)	3.6557 (1.0000)	1.6066 (0.9426)	1.8730 (0.9855)	1.2870 (0.9664)	2.3400 (0.9882)	-0.5259 (0.3007)
FEEMD- WOA-RBF		3.6433 (0.9997)	3.6459 (0.9997)	1.4351 (0.9211)	1.7937 (0.9604)	1.2824 (0.8970)	2.3266 (0.9878)	2.7214 (0.9955)
VMD- IWOA-RBF			0.7011 (0.7566)	-3.7150 (0.0003)	-3.5472 (0.0004)	-0.5841 (0.2810)	-1.8705 (0.0338)	1.8132 (0.9619)
VMD- WOA-RBF				-3.7182 (0.0003)	-3.5506 (0.0003)	-0.5862 (0.2803)	-1.8738 (0.0036)	1.8121 (0.9618)
IWOA-RBF					1.2284 (0.8873)	1.2394 (0.8893)	2.2119 (0.9841)	2.7012 (0.9952)
WOA-RBF						1.2368 (0.8889)	2.1159 (0.9802)	2.6719 (0.9948)
RBF							-0.5259 (0.3007)	1.9896 (0.9738)
BPNN								2.5081 (0.9922)

a) 表中未加括号的指标为 DM 统计量, 括号中的指标为 DM 统计量对应的 p 值.

DM 检验被用来检验两个模型的预测精度之间是否具有明显的差异, PT 检验用来检验预测值和真实值是否具有相同的变化方向, 中长期预测和短期预测的 DM 和 PT 检验结果如表 3~5 所示. 检验

表 5 电价预测的 PT 检验结果 ^{a)}

Table 5 PT test results of electricity price forecasting

	FEEMD-IWOA-RBF	FEEMD-WOA-RBF	VMD-IWOA-RBF	VMD-WOA-RBF	IWOA-RBF	WOA-RBF	RBF	BPNN	SVR
Mid-long-term forecasting	24.9790 (0.0000)	20.5746 (0.0000)	-8.1915 (2.0000)	-8.1915 (2.0000)	4.5563 (5.2E-6)	4.1174 (3.8E-5)	4.7664 (1.8E-6)	0.1540 (0.8876)	0.9324 (0.3511)
Short-term forecasting	7.9825 (1.3E-15)	7.3510 (2.0E-13)	NAN NAN	NAN NAN	0.6061 (0.5444)	1.7474 (0.0806)	2.0263 (0.0427)	0.9509 (0.3417)	0.6397 (0.5224)

a) 表中未加括号的指标为 PT 统计量, 括号中的指标为 PT 统计量对应的 p 值.

表 6 对比模型的中长期预测误差

Table 6 Error analysis results of compared models of mid-long-term prediction

Evaluating indicator	FA-BP	VMD-FA-BP	FEEMD-FA-BP	FEEMD-VMD-FA-BP
RMSE	9.2260	27.4947	6.3783	5.8784
NRMSE	35.9376	107.0991	24.8451	22.8979
MAPE	20.9548	102.1828	14.0246	14.2400
MAE	0.0010	0.0269	0.0102	0.0072
TIC	0.1841	0.3227	0.1714	0.1709
D_s	55.5887	52.0119	53.8003	55.8867

表 7 对比模型的短期预测误差

Table 7 Error analysis results of compared models of short-term prediction

Evaluating indicator	FA-BP	VMD-FA-BP	FEEMD-FA-BP	FEEMD-VMD-FA-BP
RMSE	9.2260	23.7100	6.4677	5.1113
NRMSE	39.9836	105.1287	28.6773	22.6630
MAPE	26.7387	101.5876	13.8441	12.2035
MAE	14.3056	19.4101	2.7301	3.0527
TIC	0.1917	0.3760	0.2068	0.2036
D_s	61.7021	46.8085	53.1915	63.8298

结果显示: (1) FEEMD-IWOA-RBF 的预测效果明显优于其他 8 个模型, DM 检验的结论与上述统计评价指标的结论相同; (2) DM 检验的结果显示, 9 种预测模型中, FEEMD-IWOA-RBF 的预测效果优于 IWOA-RBF, 而 SVR、VMD-IWOA-RBF 和 VMD-WOA-RBF 模型的预测精度最低. 根据 DM 检验的结果显示, BPNN 和 RBF 的预测效果相当; (3) FEEMD-IWOA-RBF 混合学习模型在方向上的精度远高于其他 8 个对比模型, 因此在方向精度上本文提出的 FEEMD-IWOA-RBF 混合学习模型能够准确地预测电价的变动方向.

3.3 讨论

为了进一步讨论本文提出的 FEEMD-IWOA-RBF 混合学习模型在电价预测中的优越性, 本节将与文献 [23] 中的 FA-BP, VMD-FA-BP, FEEMD-FA-BP, FEEMD-VMD-FA-BP 方法进行对比讨论.

根据表 6 和 7, 本文提出的 FEEMD-IWOA-RBF 混合学习模型在电价的中长期和短期预测中, 在水平精度和方向精度两个方面, 其预测效果均优于文献 [23] 中给出的模型. 在水平精度上, 本文提出的混合模型可以准确预测波动性较大的电价数据, 各项误差远低于文献 [23] 中的电价预测模型. 在方

向精度上, 本文提出的学习算法的方向统计量达到了 84% 以上, 而在文献 [23] 的各类方法中, 最高的方向统计量仅为 63.8298%. FEEMD-IWOA-RBF 模型预测精度较高的主要原因是 RBF 在波动率较大的非线性数据中的拟合效果优于较为基础的 BPNN, 同时利用 IWOA 对 RBF 的扩展系数进行寻优, 可以进一步提高模型的预测精度. 其中, 利用 IWOA-RBF 模型对 FEEMD 分解后得到的本征模态函数和残差序列进行预测时, 对于波动率最大的 IMF1 序列进行中长期和短期预测时, RMSE 已经远小于 3, 此时再对 IMF1 进行 VMD 分解可能会造成过拟合现象. 因此, 从预测模型运行的时效性和模型复杂度的角度考虑, 是否需要对 IMF1 序列进行二次分解, 是要依据实际预测情况进行分析和判断. 与此同时, 根据上述统计误差分析结果以及水平精度和方向精度的检验结果, 我们可以得到如下结论:

(1) 相比于 SVR, BPNN, RBF, IWOA-RBF, WOA-RBF, FEEMD-WOA-RBF, VMD-IWOA-RBF 和 VMD-WOA-RBF 8 个对比模型, 本文提出的 FEEMD-IWOA-RBF 混合学习模型在电价的中长期预测和短期预测中, 无论是在水平精度和方向精度上均更优;

(2) IWOA 可以对 RBF 的扩展系数进行有效优化, 可以显著提高 RBF 的预测精度;

(3) FEEMD 比 VMD 更适用于分解波动性较大的非线性数据, 采用 FEEMD 分解更能降低 IWOA-RBF 的预测难度, 改进了混合模型的预测效果.

4 结论与展望

本文提出了一种基于分解 – 优化 – 集成的 FEEMD-IWOA-RBF 混合学习模型对电价进行预测. 该模型首先利用 FEEMD 对波动性较大的电价数据进行分解; 其次采用 IWOA 优化 RBF 的扩展系数; 最后, 利用 IWOA-RBF 对 FEEMD 分解出的子序列进行预测, 得出电价的预测值. 为了进一步检验新模型的预测性能, 本文对美国 PJM 市场的电价进行中长期和短期预测. 实证结果显示, IWOA 可以有效优化 RBF 的参数, 提高 RBF 的预测性能; 新混合学习模型对电价中长期和短期预测效果明显优于单一模型和其他混合模型. 通过分析统计误差结果以及 DM 和 PT 检验结果, 本文所提出的分解 – 优化 – 集成学习方法无论是在水平精度上还是方向精度上均更能对电价进行有效预测. 本文提出的新混合学习模型可以更好地预测波动较大的非线性时间序列, 该混合学习模型可以推广至风速预测、风电负荷预测、太阳能辐射量预测等诸多方面. 在今后的研究中, 还可以考虑其他影响电价的因素作为输入变量, 来对电价数据进行多变量预测; 与此同时, 也可以利用深度学习算法, 如卷积神经网络等代替 RBF 对电价进行建模预测.

参考文献

- 1 Maciejowska K, Nowotarski J, Weron R. Probabilistic forecasting of electricity spot prices using factor quantile regression averaging. *Int J Forecast*, 2016, 32: 957–965
- 2 Conejo A J, Plazas M A, Espinola R, et al. Day-ahead electricity price forecasting using the wavelet transform and ARIMA models. *IEEE Trans Power Syst*, 2005, 20: 1035–1042
- 3 Xu W, Zhou H, Cheng N, et al. Internet of vehicles in big data era. *IEEE/CAA J Autom Sin*, 2018, 5: 19–35
- 4 Zhang C S. Challenges in machine learning. *Sci Sin Inform*, 2013, 43: 1612–1623 [张长水. 机器学习面临的挑战. *中国科学: 信息科学*, 2013, 43: 1612–1623]
- 5 Itaba S, Mori H. An electricity price forecasting model with fuzzy clustering preconditioned ANN. *IEEE Trans Power Energy*, 2018, 138: 90–98
- 6 Saâdaoui F. A seasonal feedforward neural network to forecast electricity prices. *Neural Comput Applic*, 2017, 28: 835–847

- 7 Xiao Q, Zeng Z. Scale-limited lagrange stability and finite-time synchronization for memristive recurrent neural networks on time scales. *IEEE Trans Cybern*, 2017, 47: 2984–2994
- 8 Wu A, Liu L, Huang T, et al. Mittag-Leffler stability of fractional-order neural networks in the presence of generalized piecewise constant arguments. *Neural Netw*, 2017, 85: 118–127
- 9 Özgüner E, Tör O B, Güven A N. Probabilistic day-ahead system marginal price forecasting with ANN for the Turkish electricity market. *Turk J Elec Eng Comp Sci*, 2017, 25: 4923–4935
- 10 Zhu S, Yang Q, Shen Y. Noise further expresses exponential decay for globally exponentially stable time-varying delayed neural networks. *Neural Netw*, 2016, 77: 7–13
- 11 Zhang W, Zhang H, Liu J, et al. Weather prediction with multiclass support vector machines in the fault detection of photovoltaic system. *IEEE/CAA J Autom Sin*, 2017, 4: 520–525
- 12 Ma Z, Zhong H, Xie L, et al. Month ahead average daily electricity price profile forecasting based on a hybrid nonlinear regression and SVM model: an ERCOT case study. *J Mod Power Syst Clean Energy*, 2018, 6: 281–291
- 13 Shao Z, Yang S L, Gao F, et al. A new electricity price prediction strategy using mutual information-based SVM-RFE classification. *Renew Sustain Energy Rev*, 2017, 70: 330–341
- 14 Yan X, Chowdhury N A. Mid-term electricity market clearing price forecasting using multiple least squares support vector machines. *IET Gener Transm Distrib*, 2014, 8: 1572–1582
- 15 Mareda T, Gaudard L, Romero F. A parametric genetic algorithm approach to assess complementary options of large scale windsolar coupling. *IEEE/CAA J Autom Sin*, 2017, 4: 260–272
- 16 Gu W, Yu Y, Hu W. Artificial bee colony algorithm based parameter estimation of fractional-order chaotic system with time delay. *IEEE/CAA J Autom Sin*, 2017, 4: 107–113
- 17 Heydari A, Keynia F. A new intelligent heuristic combined method for short-term electricity price forecasting in deregulated markets. *Australian J Electrical Electron Eng*, 2016, 13: 258–267
- 18 Liu H, Mi X, Li Y. An experimental investigation of three new hybrid wind speed forecasting models using multi-decomposing strategy and ELM algorithm. *Renew Energy*, 2018, 123: 694–705
- 19 Sun S, Wang S, Zhang G, et al. A decomposition-clustering-ensemble learning approach for solar radiation forecasting. *Sol Energy*, 2018, 163: 189–199
- 20 Mirjalili S, Lewis A. The whale optimization algorithm. *Adv Eng Softw*, 2016, 95: 51–67
- 21 Wang J, Du P, Niu T, et al. A novel hybrid system based on a new proposed algorithm-multi-objective whale optimization algorithm for wind speed forecasting. *Appl Energy*, 2017, 208: 344–360
- 22 Bento P M R, Pombo J A N, Calado M R A, et al. A bat optimized neural network and wavelet transform approach for short-term price forecasting. *Appl Energy*, 2018, 210: 88–97
- 23 Wang D, Luo H, Grunder O, et al. Multi-step ahead electricity price forecasting using a hybrid model based on two-layer decomposition technique and BP neural network optimized by firefly algorithm. *Appl Energy*, 2017, 190: 390–407
- 24 Shayeghi H, Ghasemi A, Moradzadeh M, et al. Day-ahead electricity price forecasting using WPT, GMI and modified LSSVM-based S-OLABC algorithm. *Soft Comput*, 2017, 21: 525–541
- 25 Wang Y H, Yeh C H, Young H W V, et al. On the computational complexity of the empirical mode decomposition algorithm. *Phys A-Stat Mech Appl*, 2014, 400: 159–167
- 26 Gu J, Gu M, Cao C, et al. A novel competitive co-evolutionary quantum genetic algorithm for stochastic job shop scheduling problem. *Comput Operations Res*, 2010, 37: 927–937
- 27 Zhan S, Huo H. Improved PSO-based task scheduling algorithm in cloud computing. *J Inf Computat Sci*, 2012, 9: 3821–3829
- 28 Lewis C. *International and Business Forecasting Methods*. London: Butter-Worths, 1982

Decomposition-optimization-ensemble learning approach for electricity price forecasting

Feng JIANG^{1*}, Jiaqi HE¹, Zhigang ZENG^{2*} & Tianhai TIAN³

1. School of Statistics and Mathematics, Zhongnan University of Economics and Law, Wuhan 430073, China;

2. School of Automation, Huazhong University of Science and Technology, Wuhan 430074, China;

3. School of Mathematical Science, Monash University, Melbourne Clayton 3800, Australia

* Corresponding author. E-mail: fjiang78@163.com, zgzenq@hust.edu.cn

Abstract The accurate forecasting of electricity price, which is an indispensable indicator of the current market situation, can help market players avoid risks and maximize economic profits as the electricity market undergoes continuous development and reform. This study aims to propose decomposition-optimization-ensemble (DOE), which is a new hybrid approach, for the predicting electricity price data in the power market. First, we decomposed electricity price data into a series of intrinsic mode functions and a residual sequence using the fast ensemble empirical mode decomposition method. Next, we optimized the convergence speed, accuracy, and searching ability of the whale optimization algorithm. We then used the improved whale optimization algorithm to optimize the expansion coefficient of the RBF neural network. The improved model was used to predict the values of intrinsic mode functions and the residual sequence. Finally, we applied the ensemble method to calculate the final predicted values of the original electricity price data. We performed mid-long-term and short-term predictions with the electricity price data of the PJM electricity market in the United States to verify the forecasting performance of the DOE model. The empirical results showed that the DOE model can achieve high accuracy in both horizontal and directional precisions.

Keywords electricity price forecasting, fast ensemble empirical mode decomposition, improved whale optimization algorithm, RBF neural network, direction precision

Feng JIANG received his Ph.D. degree from Huazhong University of Science and Technology, Wuhan, in 2011. From 2011 to 2013, he was a postdoctoral fellow with the Huazhong University of Science and Technology. From 2015 to 2016, he was a visitor of Monash University. He is currently an associate professor at the School of Statistics and Mathematics, Zhongnan University of

Economics and Law. His research interests include simulation, stochastic control, and neural networks. He has published over 50 papers in international journals.

Jiaqi HE received her B.S. degree in statistics from the Harbin University of Commerce in 2017. Currently, she is an M.S. candidate of applied statistics at the School of Statistics and Mathematics, Zhongnan University of Economics and Law. Her research interests focus on statistical learning, optimization algorithms, machine learning, neural networks, and their applications.

Zhigang ZENG received his Ph.D. degree in systems analysis and integration from Huazhong University of Science and Technology, Wuhan, in 2003. He is currently a professor at the School of Automation at Huazhong University of Science and Technology and at the Key Laboratory of Image Processing and Intelligent Control of the Education Ministry of China in Wuhan. His research

interests include the theory of differential equations with discontinuous right-hand sides and their applications in the dynamics of neural networks, memristive systems, and control systems.

Tianhai TIAN received his Ph.D. degree in mathematics from the University of Queensland, Australia, in 2001. Currently, he is an associate professor at Monash University. He was an Australian Research Council (ARC) Australian Fellow at the University of Queensland, the Lord Kelvin Fellow at the University of Glasgow, and ARC Future Fellow at Monash University. His research interests include stochastic modeling, simulation, and complex

networks in biology, finance, and social science.