

基于EEMD,SVM和ARMA组合模型的电价预测

张金良,王明雪

(华北电力大学 经济与管理学院,北京 102206)

Electricity price forecasting based on EEMD, SVM and ARMA combination model

ZHANG Jinliang, WANG Mingxue

(Economics and management College, North China Electric Power University, Beijing 102206, China)

摘要:随着我国电力体制改革的不断深入,售电公司作为电力市场的主要参与者,其主要获利方式是从电力市场中购买电量并销售给用户。因此准确预测现货市场价格变化趋势,是售电公司降低购售电风险的重要保障。为此,根据现货市场中电价的特性,提出基于集成经验模态分解(ensemble empirical mode decomposition, EEMD)、支持向量机(support vector machine, SVM)和自回归移动平均模型(autoregressive moving average, ARMA)的组合预测模型。首先利用EEMD将历史数据分解成一系列相对比较平稳的分量序列;其次,利用遗传算法(genetic algorithm, GA)优化的SVM预测高频分量,利用自回归移动平均模型预测低频分量;最后将各子序列的预测结果求和作为最终预测结果。用美国售电公司真实数据进行预测,并与其它模型进行比较。算例结果表明所提模型的预测精度更高。

关键词:电价预测;集成经验模态分解;支持向量机;自回归移动平均模型

Abstract: With the continuous deepening of China's electric power system reform, as a major participant in the electric power market, the main way for electric power company to profit is to buy electricity from the electric power market and sell it to users. Therefore, accurately predicting the change trend of spot market electricity price is an important guarantee for electric power companies to reduce the risk of electricity buying and selling. For this purpose, based on the characteristics of electricity prices in the spot market, composite prediction models is proposed based on integrated empirical mode decomposition (EEMD), support vector machine (SVM) and autoregressive moving average (ARMA). Firstly, EEMD is used to decompose historical data into a series of relatively stable component sequences. Secondly, the SVM optimized by genetic algorithm (GA) is used to predict the high-frequency components, and the autoregressive moving average model is used to predict the low-frequency components. Finally, the final prediction result is the sum of the predicted results of each subsequence. The prediction is made using real data from American electric power companies and compared with other models. The numerical results show that the forecasting accuracy of the proposed model is higher.

Key words: electricity price forecasting; integrated empirical modal decomposition; support vector machine; autoregressive moving average model

0 引言

伴随我国现货市场试点的开展和实施,电价预测对电力市场各主体的重要性不断显现。同时,随着我国电力市场建设的不断深入,各省电力市场结构逐渐趋于市场化,这标志着我国已经跨越了现货市场的门槛。售电公司作为售电侧主体受现货市场价格的不确定性的影响,售电公司要根据用户的需求量在不同电力市场中以最低的成本买入,并根据合理的价格模式售出。售电公司如何更大获利,就需要依赖准确的电价预测。

收稿日期:2019-11-03;修回日期:2020-01-04

基金项目:国家自然科学基金(71774054);中央高校基本科研业务专项资金项目(2019MS055)

This work is supported by National Natural Science Foundation of China (No. 71774054); Special Fund Project for Basic Scientific Research of Central Universities (No. 2019MS055)

目前,电价预测方法较多,由于单一模型较难提高预测精度,因此,国内外学者集中于组合预测模型的研究。现有方法可以归结为以下几类。

(1) 时间序列的组合模型

时间序列模型是根据历史数据的变化趋势来预测未来发展的一种方法。文献[1]提出一种基于EEMD和自回归滑动积分模型(autoregressive integrated moving average, ARIMA)的组合模型;文献[2]建立ARIMA和广义自回归条件异方差模型(generalized autoregressive conditional heteroskedasticity, GARCH)的组合模型预测电价;文献[3]利用小波变换将历史电价分解成不同序列,在此基础上,建立ARIMA-GARCH预测电价;文献[4]提出一种基于小波变换和时间序列组合模型,结合多变量影响因素对日前电价进行预测;文献[5]提出在进行常规电价预测模型后,对预测后的电价残差序列也迭代地建立预测模型,并用ARIMA模型修正电价预测结果。时间序

列组合模型虽然简单易懂,工作量小,计算速度快。但其只反映数据的自身线性变化趋势,未能考虑外在的影响因素,所以预测精度不高。

(2) 智能模型的组合模型

为了提高预测精度,部分学者利用神经网络的组合模型进行预测^[6]。部分学者利用组合径向基(radial basis function,RBF)神经网络^[7-8]和广义回归神经网络模型(generalized regressive neural network,GRNN)^[9],小波神经网络^[10-11]进行预测。其中,文献[7]建立了RBF神经网络和自适应神经网络相结合的短期负荷预测模型;文献[8]采用混合粒子群算法优化最近邻聚类的聚类半径,从而确定归一化径向基神经网络的参数的预测模型;文献[9]提出了一种基于时间输入的GRNN预测模型;文献[10]先采用EEMD分解后,再使用小波神经网络;文献[12]提出了一种基于快速集成经验模态分解、变分模态分解的2层分解技术和反向传播(back propagation,BP)神经网络的组合模型,以此提高预测精度;文献[13]利用遗传算法对极度学习机(extreme learning machine,ELM)模型的输入权重和隐藏节点偏置进行优化,克服了传统ELM模型预测精度不高且波动性大的缺陷;文献[14]利用遗传算法对BP神经网络和最小二乘支持向量机组合变权模型的权重进行优化,用于预测边际电价。智能模型的组合模型能够有效的提高预测精度,但其不能刻画电价序列中的线性变化趋势,预测精度有待提高;文献[15]将小波神经网络与随机矢量函数连接型网络相融合构建一种新型小波链神经网络模型。

(3) 时间序列模型和智能模型的组合模型

为了克服上述两个组合模型的缺点,部分学者提出时间序列模型和智能模型的组合模型。文献[16]提出了一种基于ARIMA-GARCH和神经网络的组合模型来预测PJM市场日前电价;文献[17]提出一种基于GARCH和遗传算法优化的向量机(GA-SVM)的组合模型;文献[18]利用小波分析和神经网络来分预测电价。基于此,本文提出基于集成经验模态分解、遗传算法优化的支持向量机和自回归移动平均模型的组合预测模型。

1 模型基本原理

1.1 集合经验模态分解

为了解决模态混叠问题,在2005年有学者将经验模态分解进行改造,提出了集合经验模态分解法,这一模型在信号上引入高斯白噪声,利用白噪声的零均值特性,将时间序列进行连续性整合,然后继续运用EDM模型的原理进行分解,最后求加和。

具体步骤如下。

(1) 将原有时间序列引入高斯白噪声,然后得到第一个新的时间序列。

$$Y(t)=y(t)+k\cdot n(t) \quad (1)$$

式中: $y(t)$ 为原时间序列; $Y(t)$ 为新的时间序列; k 为白噪声标准差与信号标准差比值系数; $n(t)$ 为 n 组噪声序列。

(2) 将新时间序列用EDM模型进行分解,分解成 n 个本征模态函数(intrinsic mode function,IMF)和一个剩余量。

$$Y(t)=\sum_{i=1}^n IMF_i(t)+R_n(t) \quad (2)$$

式中: $R_n(t)$ 为剩余分量。

(3) 继续对原有时间序列引入不同的高斯白噪声,得到 N 组不同的IMF分量和 N 个不同的剩余量 $R(t)$ 。

(4) 对所求得 N 组数据求算数平均值。

$$C_i(t)=\frac{1}{N} \sum_{i=1}^N IMF_i(t) \quad (3)$$

$$R(t)=\frac{1}{N} \sum_{i=1}^N R_i(t) \quad (4)$$

式中: $C_i(t)$ 为最后分解结果; $R(t)$ 为最后剩余分量。

1.2 支持向量机

支持向量机是模式分类和回归的常用经典方法,对有限的数据进行观测,推断出相应的分类关系,进而得到回归模型,对未来的数据进行预测。支持向量机可以将给定的一组训练实例,可以对训练集进行回归拟合,进而对预测集映射到相同的区间,从而得出预测结果。线性可分类数据是最早的二分类问题,这时的总决策函数可以表示为

$$\gamma_i = \text{sgn}((w \cdot x) + b) \quad (5)$$

给定训练样本 $D=\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$, x 为预报因子; y 为预报对象值。向量机模型会寻找最优的函数 $f(x)$ 使得 x, y 样本拟合最好。当给出一定预测集样本时,会用同样的函数进行预测。在回归分析中,必须要考虑的就是误差因子,这是评价函数优良的标准。本文使用的是均方误差(mse)。在总偏差为0的情况下,要求所有样本到超平面的点都小于 ε 这时寻优过程就转化为凸优化问题。

$$\min = \left\{ \frac{1}{2} \|w\|^2 \right\} \quad (6)$$

约束条件为

$$\begin{aligned} y_i - (w^T x) - b &\leq \varepsilon \\ (w^T x) + b - y_i &\leq \varepsilon \quad (i=1, 2, \dots, l) \end{aligned} \quad (7)$$

式中: w, x 为 n 维向量; b 为阈值; ε 为误差函数。

实际问题中往往都是不可分,具有一定的噪音干扰,对于实际线性不可分问题就要引入松弛变量来解决了。由此转化成的新的凸规划问题为

$$\min = \left\{ \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \xi_i + \xi_i^* \right\} \quad (8)$$

约束条件:

$$\begin{aligned} y_i - (w^T x) - b &\leq \varepsilon + \xi_i \\ (w^T x) + b - y_i &\leq \varepsilon + \xi_i^* (\xi_i \geq 0, \xi_i^* \geq 0) \end{aligned} \quad (9)$$

式中: C 为惩罚系数,它表示对于错分的惩罚力度。 C 越大,惩罚力度越大; ξ_i 、 ξ_i^* 为松弛因子。但是因为讨论的样本往往是非线性且不可分的,需要引入核函数进行简化。在 SVM 转换最优解问题公式计算都是以内积的形式出现的,因此采用高斯径向基核函数来简化计算过程,其计算公式为

$$K(x_i, x_j) = e^{-\frac{(x_i - x_j)^2}{2\sigma^2}} \quad (10)$$

当核函数满足 Mercer 定理时,甚至可以用其来解决高维的非线性内积运算问题。因此最后总决策式子为

$$M(x) = \operatorname{sgn} \left(\sum_{i=1}^n a_i^* y_i K(x_i, x) \right) + b^* \quad (11)$$

1.3 遗传算法

遗传算法是仿照达尔文生物进化论的自然选择和遗传学机理的生物进化过程延伸出来的一种数学计算模型,是一种通过模拟自然进化过程搜索最优解的方法。这种方法不需要考虑函数的可导性,直接视一个种群中所有个体为对象,是随机的对一串已经编码的参数空间进行高效的搜索最优解的过程。通过选择,交叉,变异 3 种方法改变染色体上的基因编码。本文基于遗传算法对支持向量机的分类参数进行优化。具体步骤如下。

(1) 编码:将问题的解以遗传算法表示,在交叉、变异等操作之前进行编码,因此我们往往才有二进制来进行简化操作,就是整个字符串中,用“1”表示该对应的基因处于激活状态,为有效可遗传基因,相反“0”则表示对应的基因处于休眠状态,视为无效基因,不一定遗传。利用遗传算法对支持向量机参数进行优化时,首先对支持向量机分类参数(惩罚参数 c 和核函数参数 $g = 1/2\sigma^2$)进行编码。

(2) 初始化种群:按照所需要的结果设定规则,然后挑选一定数量的个体作为初始种群,由随机生成的(C, g, p)组成。

(3) 初始化种群选定以后,进行适当的解码,并根据需求设定目标函数对初始种群进行回归训练,将训练结果的均方误差作为目标函数值,并确定适应度值。

(4) 将支持向量机分类正确率作为适应度,采用赌轮盘选择法,在二进制编码的条件下,对初始种群进行选择,同时这个过程中还根据自然遗传学的遗传算子产生着基因的交叉和变异,会产生新一代个体(C, g, p)。

(5) 产生的更适应环境的新的解码种群,这时候的解码就是跟接近问题的最优近似解。如果不满足终止条件,则要返回(3)降低适应度的值,继续运算。

1.4 ARMA 模型

若序列 y_t 是现在和过去的误差以及先前序列值的线性组合,即

$$yt = \sum_{i=1}^p \alpha_i y_{t-i} + U_t + \sum_{i=1}^q \theta_i U_{t-i} \quad (12)$$

式中: p, q 为自回归和滑动平均的阶数; α_i, θ_i 分别为自回归和滑动平均参数。若时间序列 y_t 为非平稳原时间序列,则可通过若干次差分将其变为平稳序列。

2 组合模型的构建

影响电价的因素众多,既包括发电侧和需求侧的因素,同时也包括电力系统方面的因素、厂商报价策略等。本文主要选择对电价影响较大的 2 个因素:历史电价和负荷。由于原始时间序列具有较强的非线性、非平稳性,直接进行建模预测效果不佳,为此,本文首先采用 EEMD 对原始电价进行分解,在此基础上,利用遗传算法优化的 SVM 以及 ARMA 分别对不同的子序列进行预测,具体步骤如下。

(1) 采用 EEMD 将原有历史电价分解为若干个 IMF 分量和一个剩余分量。

(2) 对每个 IMF 分量和剩余分量进行预处理。采用 mapminmax 函数将样本数据归一化到 $[-1, 1]$ 的范围内。同时确定 IMF 的频率,分为高频和低频。

(3) 高频分量用遗传算法优化后的支持向量机进行预测,低频分量使用 ARMA 进行预测。

(4) 最后将高频和低频的预测结果相加,得到最终的预测值。具体步骤如图 1 所示。

为了验证预测模型的准确性,利用平均绝对百分比误差(MAPE)和绝对百分比误差(APE)对各预测模型进行对比分析。

$$MAPE = \frac{1}{m} \sum_{i=1}^m \left| \frac{Y_i - Y'_i}{Y_i} \right| \quad (13)$$

$$APE = \left| \frac{Y_i - Y'_i}{Y_i} \right| \times 100\% \quad (14)$$

式中: Y_i 和 Y'_i 分别为第 i 个实际值和预测值; m 为

样本的个数。

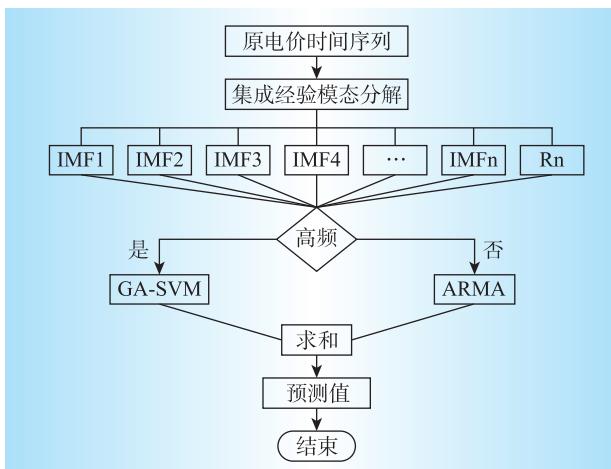


图1 模型流程图

Fig. 1 Model flow chart

3 算例分析

为验证本文模型有效性,现以美国某电力市场数据为例进行分析。选取2018年11月1日至11月30日共30天历史电价数据,采样周期为小时,其中将前23天,共552个小时样本数据作为训练样本,后7天为预测集,共168个小时数据样本。首先在利用EEMD进行分解时,给原始时间序列添加50组白噪声序列,每组白噪声的幅值设为0.1,此时,产生8个IMF和一个R8,分解结果从高频到低频排列如图2所示。

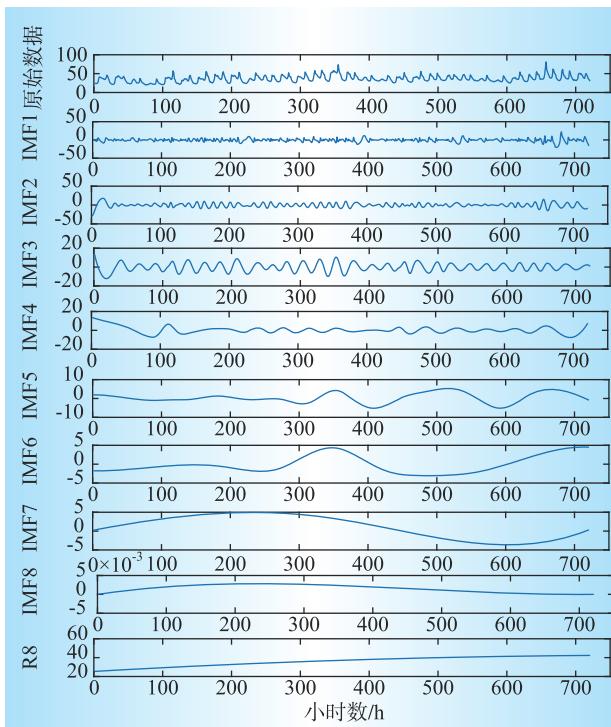


图2 EEMD分解图

Fig. 2 EEMD decomposition

由图2可知,IMF1-IMF6分量周期短,波动大,将其分为高频分量,此时利用GA优化SVM算法对高频分量进行预测。IMF7,IMF8和R8波动较小,波动平缓,周期长,将其划分为低频分量,可以利用线性模型AMRA进行预测。最后将所有分量预测值求和得到最终结果。为了验证本文预测模型有效性,本文使用Matlab 2016b编程建立模型。并与ARMA-GARCH时间序列模型,GA-SVM智能算法模型两种不同的组合预测模型进行结果对比。

由于时间序列预测不考虑外界影响因素,因此存在较大的误差,仅仅反映大体波动趋势,预测结果如图3所示。

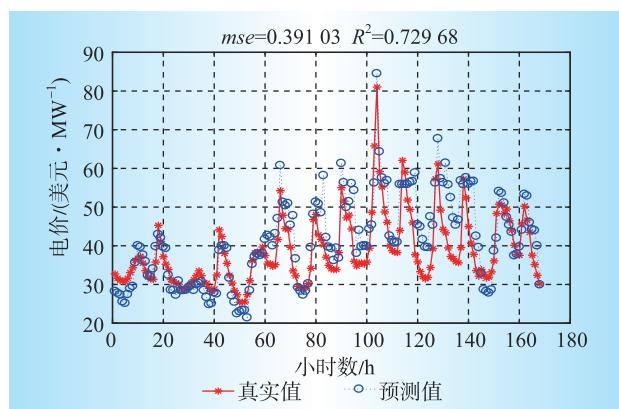


图3 ARMA-GARCH模型预测结果

Fig. 3 Prediction results of ARMA-GARCH model

遗传算法优化的支持向量机可以克服时间序列的缺点,能够进一步提高预测精度,如图4所示。考虑到时间序列和支持向量机的优点,本文将2者进行组合,同时采用EEMD对原始电价序列进行分解,在此基础上,再利用遗传算法优化的支持向量机和自回归移动平均模型分别进行预测,结果如图5所示。

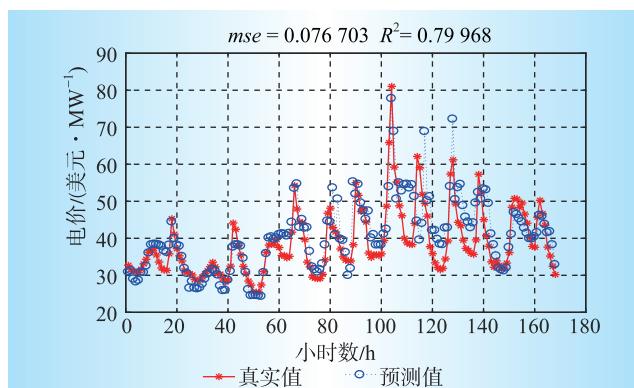


图4 GA-SVM模型预测结果

Fig. 4 Prediction results of GA-SVM model

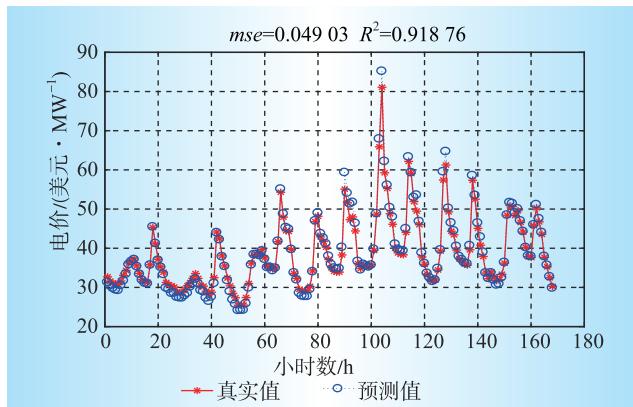


图5 本文组合模型预测结果

Fig. 5 Prediction results of the combined model in this paper

为了进一步说明不同模型的预测性能,表1给出了3种模型的预测结果。

表1 3种模型预测结果比较

Table 1 Comparison of prediction results of three models
美元/MW

日期	本文模型		GA-SVM		ARMA-GARCH	
	MAPE	APE (max)	MAPE	APE (max)	MAPE	APE (max)
11月24日	0.020	4.950	0.063	18.525	0.088	18.122
11月25日	0.039	6.197	0.063	14.691	0.070	15.072
11月26日	0.019	5.869	0.083	28.031	0.128	42.534
11月27日	0.035	8.719	0.114	44.488	0.128	50.876
11月28日	0.024	8.410	0.201	42.431	0.144	56.041
11月29日	0.021	5.731	0.195	30.723	0.272	49.817
11月30日	0.013	3.262	0.070	18.841	0.086	24.903

由表1可知,本文模型的MAPE和APE明显小于ARMA-GARCH和GA优化SVM2个对比模型。本文的组合模型预测未来1星期结果APE都在10%以下,但是智能算法APE范围扩大到15%~45%之间,误差波动相对较大,而时间序列预测结果APE更大,甚至高达56.041%。

为了更加直观的了解每个时刻的预测误差,表2和图6给出24日24个时刻预测结果。由表2和图6可以看出,本文的预测精度要高于对比模型,本文模型的预测值在每个时刻都更接近真实电价,且APE几乎每个时刻都是最小的,最小的是下午16:00,只有0.163%,最大的也只有4.950%。智能算法在12:00~15:00时预测结果误差较大,APE到达15%左右,但是ARMA-GARCH模型却在9:00~16:00电价波动较小时,预测要比智能算法准确。

表2 11月24日电价预测对比

Table 2 Comparison of electricity price forecasting on November 24

美元/MW

时刻	真实电价	本文模型 p'	本文模型 APE/%	GA-SVM p'	GA-SVM APE/%	ARMA-GARCH p'	ARMA-GARCH APE/%
0:00	32.71	31.35	4.172	30.92	5.486	28.24	13.680
1:00	31.60	30.47	3.574	31.34	0.818	27.78	12.076
2:00	31.06	29.84	3.941	29.02	6.559	27.40	11.791
3:00	30.94	29.41	4.950	28.25	8.699	25.57	17.372
4:00	30.71	29.28	4.667	28.68	6.612	25.14	18.122
5:00	31.62	30.54	3.412	30.85	2.434	27.43	13.239
6:00	33.08	31.71	4.139	30.80	6.898	28.93	12.537
7:00	34.32	33.44	2.568	32.53	5.203	29.53	13.954
8:00	36.23	35.85	1.046	36.07	0.444	35.66	1.578
9:00	36.76	36.62	0.385	38.28	4.138	40.04	8.916
10:00	37.28	37.15	0.361	38.43	3.092	39.65	6.364
11:00	35.50	35.36	0.404	38.41	8.202	37.64	6.018
12:00	33.57	33.38	0.554	38.25	13.948	35.94	7.054
13:00	31.96	31.89	0.230	37.88	18.525	32.27	0.985
14:00	31.40	31.11	0.922	36.66	16.738	31.99	1.891
15:00	31.32	30.96	1.160	36.24	15.698	34.07	8.785
16:00	35.79	35.73	0.163	38.18	6.671	39.83	11.284
17:00	45.30	45.49	0.414	44.49	1.798	42.97	5.151
18:00	41.11	41.25	0.351	39.98	2.757	42.02	2.208
19:00	37.18	36.95	0.606	38.23	2.819	39.67	6.695
20:00	35.26	35.18	0.217	37.93	7.562	39.36	11.621
21:00	33.88	33.34	1.585	35.11	3.629	32.45	4.221
22:00	31.26	29.89	4.376	31.89	2.028	28.56	8.622
23:00	30.67	29.57	3.581	30.55	0.408	28.51	7.059

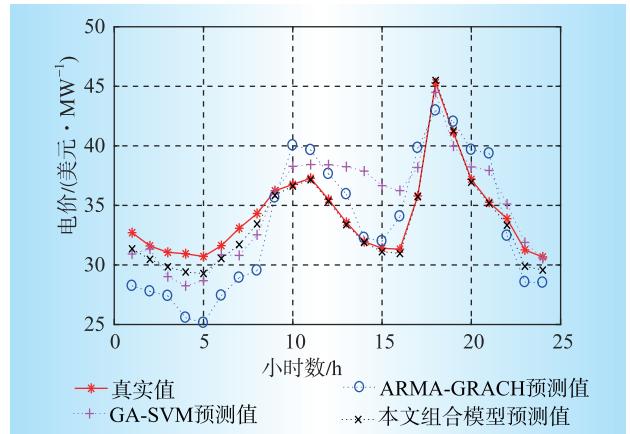


图6 11月24日电价预测对比

Fig. 6 Comparison of electricity price forecast on November 24

4 结论

本文提出一种基于EEMD,GA-SVM,ARMA的组合电价预测模型。通过对美国某电力市场电价的验证,得出结论如下。

(1) EEMD将非平稳的电价序列变成较平稳的子序列,ARMA和GA-SVM可以捕捉到电价序列中线性和非线因素。

(2) 由于影响电价的因素很多,本文仅考虑了负荷因素,如何综合考虑其他因素是今后需要研究的问题。

(3) 为我国售电公司开展电价预测提供一种有效的方法,该组合模型可以结合时间序列的历史性因素以及智能算法精确性的优势,提高预测准确性。■

参考文献:

- [1] DONG J, DOU X, LIU D, et al. Market-based short-term electricity price forecast based on ARIMA [P]. 2018 4th International Conference on Social Science and Higher Education, 2018.
- [2] 李停. 基于ARMA-GARCH模型的电价预测与研究[D]. 重庆:重庆师范大学,2015.
- LI Ting. Electricity price prediction and research based on arma-garch model[D]. Chongqing:Chongqing Normal University, 2015.
- [3] 邓佳佳,黄元生,宋高峰. 基于非参数GARCH的时间序列模型在日前电价预测中的应用[J]. 电网技术, 2012, 36(4):190-196.
- DENG Jiajia, HUANG Yuansheng, SONG Gaofeng. Application of non-parametric GARCH based time series model in day-ahead price prediction[J]. Power Grid Technology, 2012, 36(4):190-196.
- [4] 谭忠富,张金良. 利用多因素小波变换和多变量时间序列模型的日前电价预测[J]. 中国电机工程学报, 2010, 30(1):103-110.
- TAN Zhongfu, ZHANG Jinliang. Prediction of day-ahead electricity price using multi-factor wavelet transform and multivariate time series model [J]. Proceedings of the CSEE, 2010, 30(1):103-110.
- [5] 周明,严正,倪以信,等. 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):63-68.
- ZHOU Ming, YAN Zheng, NI Yixin, et al. A new method of ARIMA electricity price prediction with error prediction correction [J]. Proceedings of the CSEE, 2004, 24 (12):63-68.
- [6] 杨婵,舒崇军. 基于神经网络的电力市场电价预测[J]. 电气开关,2010,48(6):35-40.
- YANG Chan, SHU Chongjun. Prediction of electricity market price based on neural network [J]. Electrical Switch, 2010, 48(6):35-40.
- [7] 雷绍兰,孙才新,周涛建,等. 基于径向基神经网络和自适应神经模糊系统的电力短期负荷预测方法[J]. 中国电机工程学报,2005,25(22):78-82.
- LEI Shaolan, SUN Caixin, ZHOU Quan, et al. Based on RBF neural network and adaptive neural fuzzy system of electric power short-term load forecasting method[J]. Proceedings of the CSEE, 2005, 25(22):78-82.
- [8] 段其昌,赵敏,王大兴,等. 基于混合粒子群算法和NRBF神经网络的短期电价预测[J]. 电力系统保护与控制,2009,37(18):38-42.
- DUAN Qichang, ZHAO Min, WANG Daxing, et al. Short-term price prediction based on hybrid particle swarm optimization and NRBF neural network [J]. Power system protection and control, 2009, 37(18):38-42.
- [9] ANBAZHAGAN S, KUMARAPPANT N, GNANAPRAKASAM. A temporal input based day-ahead price fore-
- casting in Asia's first liberalized electricity market using GRNN[P]. International Conference on Sustainable Energy and Intelligent Systems, 2011:42-46.
- [10] 郭欣欣. 基于EEMD和小波神经网络的短期电价组合预测[J]. 重庆工商大学学报(自然科学版),2016,33 (2):21-25.
- GUO Xinxin. Short - term electricity price combination prediction based on EEMD and wavelet neural network [J]. Journal of Chongqing Technology and Business University(natural science edition), 2016, 33(2):21-25.
- [11] SAÂDAOUI F, RABBOUCH H. A wavelet-based hybrid neural network for short-term electricity prices forecasting[J]. Artificial Intelligence Review, 2019, 52(1):649.
- [12] 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 [J]. Applied Energy, 2017, 190:390-407.
- [13] 郑健,曹炜. 基于GA-ELM神经网络的日前电价预测[J]. 上海电力学院学报,2018,34(1):90-94.
- ZHENG Jian, CAO Wei. Prediction of day-ahead electricity price based on GA-ELM neural network[J]. Journal of Shanghai Electric Power University, 2008, 34(1):90-94.
- [14] 黄元生,张利君. 基于遗传算法的BP-LSSVM组合变权模型权重优化的短期电价预测研究[J]. 煤炭工程, 2019, 51(5):172-176.
- HUANG Yuansheng, ZHANG Lijun. Study on short-term electricity price prediction based on weight optimization of BP-LSSVM combined variable weight model based on genetic algorithm [J]. Coal Engineering, 2019, 51 (5) : 172-176.
- [15] 杨春霞,王耀力,王力波,等. 基于一种NW-FLNN神经网络的短期电价预测[J]. 电测与仪表,2019,56 (10):82-86,98.
- YANG Chunxia, WANG Yaoli, WANG Libo, et al. Short-term electricity price prediction based on nw-flnn neural network [J]. Electrical Measurement & Instrument, 2019, 56(10):82-86, 98.
- [16] 胡峰,彭力. 基于时间序列模型的电价预测方法[J]. 继电器,2008,36(2):35-40.
- HU Feng, PENG Li. Electricity price prediction method based on time series model[J]. Relay, 2008, 36(2):35-40.
- [17] 刘达,牛东晓,邢棉,等. 基于GARCH误差校正的遗传支持向量机日前电价预测[J]. 电力系统自动化, 2007, 31(11):31-34.
- LIU Da, NIU Dongxiao, XING Mian, et al. Prediction of day-ahead electricity price of genetic support vector machine based on GARCH error correction [J]. Power System Automation, 2007, 31(11):31-34.
- [18] 张显,王锡凡,陈芳华,等. 分时段短期电价预测[J]. 中国电机工程学报,2005,25(15):1-6.
- ZHANG Xian, WANG Xifan, CHEN Fanghua, et al. Prediction of time-division short-term electricity price [J]. Proceedings of the CSEE, 2005, 25(15):1-6.

作者简介:

张金良(1981),男,江苏常州人,副教授,主要研究方向为技术经济评价;

王明雪(1995),女,河北沧州人,硕士研究生,主要研究方向为电价预测。

(责任编辑 柴明哲)