

· 负荷预测专题 ·

基于 EEMD-ARIMA 模型的地区月负荷量预测

郭建鹏¹, 余颖铃², 温步瀛²

(1. 国网福建综合能源服务有限公司, 福建 福州 350007;

2. 福州大学电气工程与自动化学院, 福建 福州 350100)

摘要: 负荷预测是电网规划运行安排的基础, 预测的准确性关系到电网安全、可靠和经济运行。为了解决原始数据不平稳造成预测精度低下的问题, 本文提出了基于集合经验模态分解(EEMD)的自回归积分滑动平均(ARIMA)预测模型, 对某地区的月负荷量做加噪处理后进行经验模态分解, 使其分量平稳化, 再对各分量进行 ARIMA 模型预测, 最后将各预测结果相加得到最终预测值。算例表明, 基于 EEMD-ARIMA 模型的地区月负荷量预测精度高于传统 ARIMA 模型。

关键词: 集合经验模态分解; ARIMA 模型; 月负荷量预测

中图分类号: TM714

文献标志码: A

文章编号: 2096-3203(2018)06-0028-05

0 引言

合理的预测是正确决策的基础和保证。负荷预测就是在考虑电力系统、气候、经济等各种因素的前提之下, 通过对已有数据的挖掘和分析, 对未来负荷量做出预先估计。负荷预测常运用于电网的规划、调度等问题, 是其中不可或缺的一环^[1]。

月度负荷预测可用于安排月度检修计划、水力调度计划、煤电计划等, 是电力生产, 检修, 销售决策的重要依据。企业可以通过合理安排发电计划来降低生产成本、提高供电可靠性^[2]。国内外关于负荷预测的方法有回归分析法^[3]、灰色预测法^[4]、模糊预测法^[5]、时间序列法^[6]、专家预测法^[7]、神经网络法^[8-9]等。文献[10]通过最小二乘法建立中长期负荷预测模型, 其原理简单, 但是对以往数据要求严格, 影响因素的选取存在一定难度。文献[11]利用层次分析法结合专家经验, 对城市化要素主观赋权, 采用模糊聚类分析预测多因素影响下的中长期负荷。文献[12]使用灰色模型增加变权缓冲算子, 并通过灰色关联分析和粒子群算法来确定模型的最佳参数。灰色预测要求历史数据呈指数变化趋势, 数据灰度越大, 预测精度越低。文献[9]分析了影响负荷模型的因素, 采用人工神经网络对负荷模型参数进行预测, 人工神经网络具有很好的自适应能力, 但存在学习速度慢和局部极小点等问题。

在电力系统负荷预测中, 时间序列法使用较为广泛, 这类方法仅根据以往负荷数据建立随时间变化的数学模型, 具有所需数据量少、工作量小、计算

速度快等优点, 对于平稳序列的预测精度高, 对于非平稳序列则需要进行平稳化处理。文献[13]采用季节差分方法对数列进行平稳化; 文献[14]根据月售电量的规律, 利用 X12 季节调整法将月售电量分解为趋势量、季节周期量和随机量 3 个分量, 从而提高预测量的稳定性; 文献[15]利用小波分解将负荷分解为季节性需求负荷、需求响应信号及各种气象因素作用的负荷, 然后利用自回归积分滑动平均(auto regressive integrated moving average, ARIMA)模型对季节性需求负荷进行预测, 用支持向量回归模型对需求响应信号及受气象因素影响的负荷进行预测; 文献[16]根据协整理论建立电力负荷序列与输入“温度”序列之间的 ARIMAX 模型, 其信息量比经典自回归积分滑动平均(auto regressive moving average, ARMA)模型的信息量小, 拟合结果更精确; 文献[17]考虑离群值对月度负荷的影响, 建立计及离群值影响的季节性 ARIMA 月度负荷预测模型(reg ARIMA), 预测精度比普通 ARIMA 模型有所提高。

本文应用集合经验模态分解(ensemble empirical mode decomposition, EEMD)将负荷序列分解成若干分量, 使得各分量平稳化, 再通过 ARIMA 模型对各分量进行预测, 基于某地区的月负荷量数据进行算例分析, 结果表明经过 EEMD 分解后的预测值相比于未经过分解的预测值精度更高, 误差更小, 表明了 EEMD-ARIMA 模型在月负荷量预测中的实用性。

1 EEMD 算法基本理论

1.1 EMD 算法

经验模态分解(empirical mode decomposition,

收稿日期: 2018-07-09; 修回日期: 2018-08-14

基金项目: 福建省自然科学基金资助项目(2018J01482)

EMD)最早由美国科学家黄愕提出,能够将非平稳、非线性的时间序列信号自适应分解为若干个单分量信号^[18]。EMD 不需要同小波分析一样预先选定小波基函数,其基本思想是根据信号的局部时变特性,将原始信号筛分为若干个本征模态函数(intrinsic mode function, IMF),各 IMF 分量都应满足 2 个条件:

(1) 任意 IMF 分量的极点和零点数量之差不大于 1;

(2) 任意 IMF 的局部极大值和局部极小值的包络线之和的均值为 0。

EMD 的基本理论就是将频率混合的时间序列分解为频率规律的 IMF 分量和残余分量(residual component, RES),过程如下:

(1) 找到时间序列 $x(t)$ 的所有局部极大值点和极小值点,利用三次样条函数对原信号所有极大值点和极小值点分别进行拟合,构成原信号的上下包络线;

(2) 将上下包络线形成的时间序列相加,并求取其平均值 $a_1(t)$,将原信号序列与 $a_1(t)$ 相减得到新的信号序列 $h_{1,1}(t)$,即:

$$h_{1,1}(t) = x(t) - a_1(t) \quad (1)$$

(3) 判别 $h_{1,1}(t)$ 是否满足 IMF 的 2 个条件,如果满足,则 $h_{1,1}(t)$ 为 EMD 分解的第一阶 IMF 分量;若 $h_{1,1}(t)$ 不满足 IMF 条件,则将 $h_{1,1}(t)$ 定义为原信号序列,重复步骤(1)~(2)直到前提满足,此时得到的信号序列为第 1 个 IMF 分量,记为 $c_1(t)$;

(4) 将原信号序列 $x(t)$ 减去 $c_1(t)$ 得到 $r_1(t)$:

$$r_1(t) = x(t) - c_1(t) \quad (2)$$

(5) 将 $r_1(t)$ 作为下一个要分解的原信号,重复(1)~(4)步骤 n 次,直到残余分量 $r_n(t)$ 小于预设值,或为单调函数、常数,分解完毕,最终 $x(t)$ 可以表示为:

$$x(t) = \sum_{i=1}^n c_i(t) + r_n(t) \quad (3)$$

事实上 IMF 的上下包络线很难始终为 0,因此采用 2 个连续结果的标准差作为筛分终止判据:

$$S_D = \sum_{k=0}^r \frac{(h_{1,k-1} - h_{1,k})^2}{h_{1,k-1}^2} \quad (4)$$

一般 S_D 的取值在 0.2~0.3 之间,本文 S_D 取 0.3。

直接对原始序列进行 EMD 分解,容易在序列两端产生发散,为了避免端点问题导致的模型失真,这里采用镜像拟合算法。

1.2 EEMD 算法

当原始信号中掺杂幅值较小的间断性噪声时,

EMD 分解会产生模态混叠问题,这会使得 IMF 分量平稳性较差,为了改善这种情况,出现了通过噪声辅助的 EEMD 算法^[19]。

EEMD 算法的核心就是将高斯白噪声加入待分解序列,从而改变原序列的极值点分布,解决模态混叠问题。由于加入的白噪声会对原信号的分解结果产生一些影响,因此利用多重白噪声求均值为零的特性,将加入白噪声扰动后的原始分量分解得到的 IMF 分量分别求其平均值来控制噪声对分解结果的影响。其具体分解步骤如下:

(1) 初始化添加白噪声的次数(即试验总次数) N_e 和幅值系数 ε ;

(2) 在原序列中加入随机高斯白噪声序列,其中 $S_j(t)$ 是第 j 次加入的白噪声序列, $x_j(t)$ 是染噪信号:

$$x_j(t) = x(t) + \varepsilon s_j(t) \quad (5)$$

(3) 对染噪信号 $x_j(t)$ 进行 EMD 分解,得到 i 个 IMF 分量 $c_{ij}(t)$ 和剩余分量 $r_j(t)$;

(4) 重复步骤(2)~(3) N_e 次;

(5) 对 N_e 次重复操作后的信号进行 EMD 分解,对得到的 IMF 分量和剩余分量分别求均值:

$$\bar{c}_i = \frac{1}{N_e} \sum_{j=1}^{N_e} c_{ij}(t) \quad (6)$$

$$\bar{r}(t) = \frac{1}{N_e} \sum_{j=1}^{N_e} r_j(t) \quad (7)$$

(6) 最终 $x(t)$ 的分解结果为:

$$x(t) = \sum_{i=1}^n \bar{c}_i(t) + \bar{r}(t) \quad (8)$$

2 ARIMA 模型

ARIMA 模型是由 Box 和 Jenkins 于 1970 年提出的一种时间序列分析方法^[20-21],在平稳序列预测方面应用较多。

ARIMA 模型可以表示为 $ARIMA(p, q, d)$ 。其中, d 为对非平稳时间序列 $Y(t)$ 差分的次数, d 次差分后得到平稳序列 $X(t)$; p 为自回归阶数; q 为滑动平均阶数。

差分得到的 $X(t)$ 可以用自回归移动平均模型 ARMA(p, q) 来拟合,即:

$$X_t = c + \varphi_1 X_{t-1} + \varphi_2 X_{t-2} + \cdots + \varphi_p X_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \cdots + \theta_q \varepsilon_{t-q} \quad (9)$$

式中,前半部分为自回归过程, c 为常量, $\varphi_1, \varphi_2, \cdots, \varphi_p$ 为自回归系数;后半部分为滑动平均过程, $\theta_1, \theta_2, \cdots, \theta_q$ 为移动平均系数, ε_t 为未检测的白噪声序列。

当 $q=0$ 时,该模型为自回归模型 $AR(p)$,式

(9)可表达为:

$$X_t = c + \varphi_1 X_{t-1} + \varphi_2 X_{t-2} + \cdots + \varphi_p X_{t-p} + \varepsilon_t \quad (10)$$

当 $p=0$ 时,该模型为滑动平均模型 $MA(q)$,式

(9)可表达为:

$$X_t = c + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \cdots + \theta_q \varepsilon_{t-q} \quad (11)$$

其具体流程如图 1 所示。

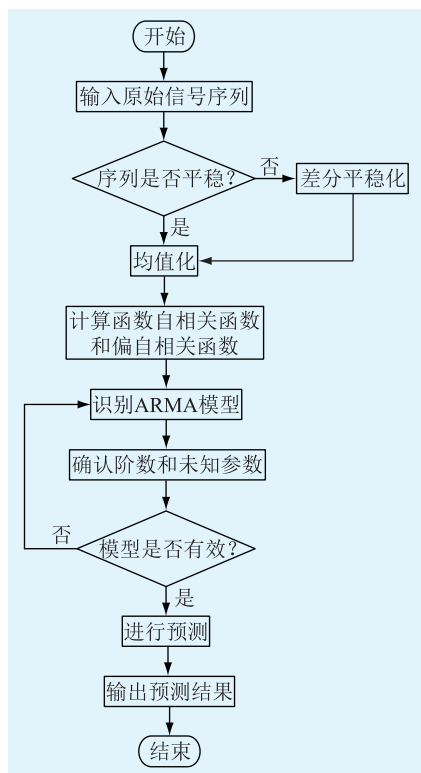


图 1 ARIMA 模型建模流程

Fig.1 ARIMA modeling process

ARIMA 模型预测的基本思路是:先建立预测值的时间序列,对其进行差分平稳化,通过自相关系数和偏自相关系数来确定模型阶数,然后进行参数的估计和检验,最后用参数合适的模型对预测量进行预测。

3 基于 EEMD-ARIMA 模型的月度负荷预测

3.1 EEMD-ARIMA 模型

受经济、气候等因素影响,月负荷量是非平稳序列,所以要先对其进行平稳化。因此,本文建立基于 EEMD 分解的月度负荷量预测模型,以下简称 EEMD-ARIMA 预测模型。具体步骤如下:

(1) 对月负荷量进行 EEMD 分解,将其分解为不同时间尺度的分量;

(2) 对各分量分别进行 ARIMA 模型预测;

(3) 将各分量预测值相加,从而得到最终的月负荷量预测值。

3.2 评价指标

为了评价不同的模型对预测结果的影响,本文从准确度和相似度 2 个方面对模型进行评价。

(1) 准确度。在数值方面,本文使用了归一化绝对误差 E_{AE} 和归一化均方根误差 E_{RMSE} 来对模型进行衡量:

$$E_{AE} = \frac{1}{n} \sum_{i=1}^n \frac{|x_i - \bar{x}_i|}{x_{\max}} \quad (12)$$

$$E_{RMSE} = \frac{1}{x_{\max}} \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x}_i)^2}{n}} \quad (13)$$

式中: x_i 为实际负荷值; \bar{x}_i 为预测负荷值; x_{\max} 为实际负荷值的最大值; n 为预测序列的长度,本文中 n 值为 12。两者越小,误差越小,准确度越高。

(2) 相似度。在负荷曲线变化方面,本文用如下指标^[18]:

$$\sigma = \frac{\vec{x} \cdot \vec{x}'}{|\vec{x}| \cdot |\vec{x}'|} \quad (14)$$

式中: \vec{x} 为实际值向量; \vec{x}' 为预测值向量; σ 表示两者之间的相似度。 σ 越趋近于 1,则预测值与实际值的变化趋势越一致。

4 算例分析

4.1 实验数据

为了验证模型的可靠性与预测精度,本文基于某市 2010 年 1 月到 2016 年 7 月共 79 个月的负荷量数据来预测 2016 年 8 月到 2017 年 7 月 12 个月份的负荷量。

4.2 月售电量预测及结果分析

本文应用 Matlab 软件对月负荷量进行预测,先对原始序列进行 ADF 单位根检验, Tau 统计量的 P 值为 0.767 3,远大于 0.05,说明原序列是非平稳序列。对负荷量进行 EEMD 自适应分解(取 N_e 为 100, ε 为 0.1),根据信号的局部时变特性将负荷量进行筛分,得到 5 个 IMF 分量和 1 个 RES 分量,各分量具有不同的时间尺度,其中 IMF1 和 IMF2 不具有规律性,为随机分量,IMF3 和 IMF4 为负荷量中的周期分量,而 IMF5 和 RES 分量为负荷量中的趋势分量。其分量如图 2 所示。

对各分量进行平稳性检验,若不平稳则进行差分平稳化,观察各分量的自相关系数和偏自相关系数,初步确定 p 和 q 的取值范围为 $[0, 10]$,选取置信水平为 95%,通过信息最小准则(Akaike's information criterion, AIC)确定具体参数如表 1。




图2 月负荷量的 EEMD 分解结果

Fig.2 EEMD decomposition results of monthly load

表1 模型参数的选取

Tab.1 Selection of model parameters

模型	p	q	d
ARIMA	4	4	1
IMF1	3	5	0
IMF2	4	3	0
IMF3	3	2	2
IMF4	2	4	1
IMF5	2	2	2
IMF6	5	4	0

负荷实际值、反向后传(back propagation, BP)神经网络预测值、ARIMA 模型预测值以及 EEMD-ARIMA 模型的预测值结果如图 3 所示。

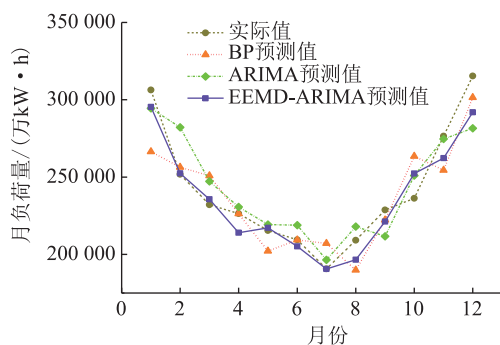


图3 月负荷量预测结果

Fig.3 Monthly load forecast results

3 种模型预测结果的准确度和相似度数值如表 2 所示。在数值方面,不论是绝对误差还是均方根误差,本文模型的预测值误差都小于其他 2 种模型,在 4%以内。而相似度方面,本文模型的相似度为 0.999 2,比 ARIMA 模型的相似度更高,与实际负荷变化趋势更相似。从数值和相似度 2 个方面,都可

以看出 EEMD-ARIMA 模型的优势,经过 EEMD 分解后,其分量比原始序列平稳,而 ARIMA 模型对平稳性好的信号序列预测精度高,采用 EEMD-ARIMA 模型预测可有效降低误差,提高预测精度。

表2 各类模型的性能比较

Tab.2 Comparison of models

模型	E_{AE}	E_{RMSE}	σ
BP 神经网络	0.048 1	0.059 6	0.997 2
ARIMA	0.044 4	0.055 2	0.997 8
EEMD-ARIMA	0.030 3	0.038 2	0.999 2

5 结语

考虑到负荷量受气候、经济等因素影响及平稳性较差的问题,普通 ARIMA 模型难以取得较高精度,因此本文采用 EEMD 分解,用于原始数据,得到有限个更为平稳的分量,对各分量分别建立 ARIMA 预测模型。经实验对比,针对地区月负荷量预测,不管在数值方面还是相似度方面,EEMD-ARIMA 预测模型都优于 ARIMA 模型。

参考文献:

- [1] 袁铁江, 袁建党, 晁勤, 等. 电力系统中长期负荷预测综合模型研究[J]. 电力系统保护与控制, 2012, 40(14): 143-146, 151.
YUAN Tiejia, YUAN Jiandang, CHAO Qin, et al. Study on the comprehensive model of mid-long term load forecasting[J]. Power System Protection & Control, 2012, 40(14): 143-146, 151.
- [2] 刘文颖, 门德月, 梁纪峰, 等. 基于灰色关联度与 LSSVM 组合的月度负荷预测[J]. 电网技术, 2012, 36(8): 228-232.
LIU Wenying, MEN Deyue, LIANG Jifeng, et al. Monthly load forecasting based on grey relational degree and least squares support vector machine[J]. Power System Technology, 2012, 36(8): 228-232.
- [3] 毛李帆, 江岳春, 龙瑞华, 等. 基于偏最小二乘回归分析的中长期电力负荷预测[J]. 电网技术, 2008, 32(19): 71-77.
MAO Lifan, JIANG Yuechun, LONG Ruihua, et al. Medium and long-term load forecasting based on partial least squares regression analysis[J]. Power System Technology, 2008, 32(19): 71-77.
- [4] 焦润海, 苏辰隽, 林碧英, 等. 基于气象信息因素修正的灰色短期负荷预测模型[J]. 电网技术, 2013, 37(3): 720-725.
JIAO Runhai, SU Chenjun, LIN Biying, et al. Short-term load forecasting by grey model with weather factor-based correction[J]. Power System Technology, 2013, 37(3): 720-725.
- [5] 张平, 潘学萍, 薛文超. 基于小波分解模糊灰色聚类 and BP 神经网络的短期负荷预测[J]. 电力自动化设备, 2012, 32(11): 121-125, 141.
ZHANG Ping, PAN Xueping, XUE Wenchao. Short-term load

- forecasting based on wavelet decomposition, fuzzy gray correlation clustering and BP neural network[J]. Electric Power Automation Equipment, 2012, 32(11): 121-125,141.
- [6] 万 昆, 柳瑞禹. 区间时间序列向量自回归模型在短期电力负荷预测中的应用[J]. 电网技术, 2012, 36(11): 77-81.
WAN Kun, LIU Ruiyu. Application of intervaltime-series vector autoregressive model in short-term load forecasting[J]. Power System Technology, 2012, 36(11): 77-81.
- [7] 胡国胜, 任 震. 基于支持向量机混合模型的短期负荷预测方法[J]. 高电压技术, 2006, 32(4): 101-103.
HU Guosheng, REN Zhen. Short-term load forecasting based on support vector machines mixture models[J]. High Voltage Engineering, 2006, 32(4): 101-103.
- [8] DING N, BENOIT C, FOGGIA G, et al. Neural network-based model design for short-term load forecast in distribution systems[J]. IEEE Transactions on Power Systems, 2015, 31(1): 72-81.
- [9] 李 龙, 魏 靖, 黎灿兵, 等. 基于人工神经网络的负荷模型预测[J]. 电工技术学报, 2015, 30(8): 225-230.
LI Long, WEI Jing, LI Canbing, et al. Prediction of load model based on artificial neuralnetwork [J]. Transactions of China Electrotechnical Society, 2015, 30(8): 225-230.
- [10] 王雁凌, 吴梦凯. 经济新常态下基于偏最小二乘回归的中长期负荷预测模型[J]. 电力自动化设备, 2018, 38(3): 133-139.
WANG Yanling, WU Mengkai. Medium and long term load forecasting model based on partial least-square regression under new normal economy[J]. Electric Power Automation Equipment, 2018, 38(3): 133-139.
- [11] 李亦言, 严 正, 冯冬涵. 考虑城市化因素的中长期负荷预测模型[J]. 电力自动化设备, 2016, 36(4): 54-61.
LI Yiyang, YAN Zheng, FENG Donghan. Mid / long-term load forecasting model considering urbanization characteristics [J]. Electric Power Automation Equipment, 2016, 36(4): 54-61.
- [12] 王大鹏, 汪秉文. 基于变权缓冲灰色模型的中长期负荷预测[J]. 电网技术, 2013, 37(1): 167-171.
WANG Dapeng, WANG Bingwen. Medium-and long-term load forecasting based on variable weights buffer grey model [J]. Power System Technology, 2013, 37(1): 167-171.
- [13] 崔和瑞, 王 娣. 基于季节 ARIMA 模型的华北电网售电量预测研究[J]. 华东电力, 2009, 37(1): 70-72.
CUI Herui, WANG Di. Study of electricity salesforecasting for North China power grid based on seasonal ARIMA model[J]. East China Electric Power, 2009, 37(1): 70-72.
- [14] 颜 伟, 程 超, 薛 斌, 等. 结合 X12 乘法模型和 ARIMA 模型的月售电量预测方法[J]. 电力系统及其自动化学报, 2016, 28(5): 74-80.
YAN Wei, CHENG Chao, XUE Bin, et al. Forecasting for monthly electricity consumption using X12 multiplication method and ARIMA mode[J]. Proceedings of the CSUEPSA, 2016, 28(5): 74-80.
- [15] 苏小林, 刘孝杰, 阎晓霞, 等. 计及需求响应的主动配电网短期负荷预测[J]. 电力系统自动化, 2018, 42(10): 60-66,134.
SU Xiaolin, LIU Xiaojie, YAN Xiaoxia, et al. Short-term load forecasting of active distribution network based on demand response[J]. Automation of Electric Power Systems, 2018, 42(10): 60-66,134.
- [16] 崔和瑞, 彭 旭. 基于 ARIMAX 模型的夏季短期电力负荷预测[J]. 电力系统保护与控制, 2015, 43(4): 108-114.
CUI Herui, PENG Xu. Summer short-term load forecasting based on ARIMAX model [J]. Power System Protection & Control, 2015, 43(4): 108-114.
- [17] 苏振宇, 龙 勇, 赵丽艳. 基于 regARIMA 模型的月度负荷预测效果研究[J]. 中国电力, 2018, 51(5): 166-171.
SU Zhenyu, LONG Yong, ZHAO Liyan. Study on the monthly power load forecasting performance based on regARIMA model [J]. China Electric Power, 2018, 51(5): 166-171.
- [18] 汤庆峰, 刘 念, 张建华, 等. 基于 EMD-KELM-EKF 与参数优选的用户侧微电网短期负荷预测方法[J]. 电网技术, 2014, 38(10): 2691-2699.
TANG Qingfeng, LIU Nian, ZHANG Jianhua, et al. A short-term load forecasting method for micro-grid based on EMD-KELM-EKF and parameter optimization [J]. Power System Technology, 2014, 38(10): 2691-2699.
- [19] 朱永利, 王刘旺. 并行 EEMD 算法及其在局部放电信号特征提取中的应用[J/OL]. 电工技术学报: 1-12 [2018-05-28]. <https://doi.org/10.19595/j>.
ZHU Yongli, WANG Liuwang. Parallel ensemble empirical mode decomposition and its application in feature extraction of partial discharging signals[J]. Transactions of China Electrotechnical Society: 1-12 [2018-05-28]. <https://doi.org/10.19595/j>.
- [20] 麦鸿坤, 肖坚红, 吴熙辰, 等. 基于 R 语言的负荷预测 ARIMA 模型并行化研究[J]. 电网技术, 2015, 39(11): 3216-3220.
MAI Hongkun, XIAO Jianhong, WU Xichen, et al. Research on ARIMA model parallelization in load prediction based on R language [J]. Power System Technology, 2015, 39(11): 3216-3220.
- [21] HUANG S J, SHIH K R. Short-term load forecasting via ARMA model identification including non-Gaussian process considerations[J]. IEEE Transactions on Power Systems, 2003, 18(2): 673-679.

作者简介:



郭建鹏

郭建鹏(1988—),男,硕士,工程师,从事节能与电能替代技术、电能质量分析方面研究工作(E-mail: 997994506@qq.com);

余颖铃(1994—),女,硕士研究生,研究方向为电力市场(E-mail: 820102499@qq.com);

温步瀛(1967—),男,博士,教授,研究方向为电力系统优化运行与电力市场、风电并网。

(下转第 74 页)

Reactive Power Optimization of Distribution Network With Distributed Generation Based on Improved Particle Swarm Optimization Algorithm

LU Yuting¹, ZHAO Tianle¹, DU Hongji¹, ZHU Xinyao²

- (1. College of Automation, Nanjing University of Science and Technology, Nanjing 210094, China;
2. State Grid Jiangsu Electric Power Co., Ltd. Research Institute, Nanjing 211103, China)

Abstract: Reactive power optimization in distributed network with distributed generation is a complex nonlinear optimization problem. In this paper, the improved particle swarm optimization algorithm is used for the reactive power optimization of distribution network. The optimization model is established with the minimum system loss and average deviation of voltage as the objective function and the node voltage and capacitor switching capacity as the constraints. The position variance is introduced into the particle swarm optimization to prevent the particle swarm algorithm from falling into the local optimal solution. The particle is mutated according to the fitness value of the particle in the population, and the performance of algorithm is improved on the basis of guaranteeing the convergence speed of the algorithm. IEEE14 node distribution system with distributed generation as an example is simulated, the results demonstrate that distributed generation can enhance the stability of the power grid and the algorithm has better optimization performance.

Key words: reactive power optimization; improved particle swarm optimization algorithm; location variance

(编辑 杨卫星)

(上接第 32 页)

Regional Monthly Load Forecast Based on EEMD-ARIMA Model

GUO Jianpeng¹, SHE Yingling², WEN Buying²

- (1. State Grid Fujian Integrated Energy Services Co., Ltd., Fuzhou 350007, China;
2. School of Electrical Engineering and Automation, Fuzhou University, Fuzhou 350100, China)

Abstract: Load forecasting is the basis for planning of the grid. The accuracy of the forecast is related to the safe, reliable and economic operation of the grid. In order to solve the problem of low prediction accuracy due to the unstable original data, this paper proposes an ARIMA prediction model based on the ensemble empirical mode decomposition (EEMD), which performs the noise processing on the monthly load of a certain area, and then performs empirical mode decomposition to make the components smoothed. Each component is predicted by ARIMA model. Finally, the component prediction results are added to obtain the final predicted value. The example shows that the prediction accuracy of the regional monthly load of the EEMD-ARIMA model is higher than that of the ARIMA model.

Key words: ensemble empirical mode decomposition; ARIMA model; monthly load forecast

(编辑 胡昊明)

(上接第 48 页)

A Frequency-tuned Resonant System for PD Measurement and Withstand Test

LU Yuxin¹, LI Bo², ZHI Yawei², CHEN Yufei¹, ZENG Xiaoming¹, YAN Yuan¹

- (1. State Key Laboratory of Electrical Insulation and Power Equipment (Xi'an Jiaotong University), Xi'an 710049, China;
2. State Grid Jiangsu Electric Power Co., Ltd. Research Institute, Nanjing 211103, China)

Abstract: XLPE cables have become an important part of urban transmission and distribution networks in recent years. As cable systems become more complex, simple withstand voltage test can not meet the needs of cable fault detection. However, the traditional frequency-tuned resonant system has a large amount of pulse interference, which makes it impossible to use for partial discharge (PD) measurement. It introduces an improved frequency-tuned resonant system, using pulse width modulation and time domain elimination to achieve PD measurement and withstand test at the same time. The effectiveness of the system is verified by experiments.

Key words: XLPE cables; frequency-tuned resonant system; partial discharge; pulse width modulation; time domain elimination

(编辑 钱悦)