

基于ARMA时间序列的电动汽车充电站运行状态预测及充电功率需求模型

提出了一种基于ARMA时间序列算法的电动汽车充电站运行状态预测模型及充电功率需求计算方法。首先定义了充电桩的五种状态来描述电动汽车充电站的运行规律,并利用ARMA算法理论基础建立充电站运行状态预测模型。其次以实际充电站运行数据为例,基于ARMA时间序列模型进行参数估计和建模,对预测过程作出了详细说明,并对预测模型进行误差分析和模型评价,以此验证模型的可靠性。最后,利用正在充电状态时间序列及充电桩的额定充电功率计算得到了充电站预测的充电功率曲线,与实际充电功率曲线进行了对比分析,证明了模型的有效性和适应性。

张曦予/广东省电力工业职业技术学校
张淼鑫/广州供电局变电管理一所

0 引言

在国家政策的大力扶持下,电动汽车的数量将在未来几十年内迅速增长,为之提供能量补给的充电站也将随之增加。若不提前对充电站的运行状态进行预测分析并加以调控性指导,可能会对配电网的安全可靠造成很大的影响。

对于已在多个城市示范运营的电动公交车和电动出租车充电站,基于历史运行数据,采集数据并分析充电站运行规律,由此建立起充电功率需求模型^[1]。而对于还未广泛使用的家用电动汽车,城市中还未建立起针对此种电动汽车的公共服务充电站,大多是以分散充电桩的形式对车辆进行充电,还未对其进行统一的管理和信息的监控采集。由于充电站中运行数据量太少不能形成有效的运行规律,给充电需求建模分析带来困难。

“十二五”国家科技支撑重大项目(2011BAG02 B14),
国家863高技术基金项目(2011AA05A109)。

ARMA时间序列模型在各种领域的研究中都得到了广泛应用。在电力系统领域,文献[2-5]分别介绍模型在水电和风电发电量预测中的应用,无论是参数估计还是定阶方法都具有很好的统计特性;文献[6]基于定阶方法验证了噪声场合下基于ARMA模型风力发电量预测的优越性;文献[7]利用最小二乘支持向量机进行短期负荷预测,建立自回归滑动平均误差预测模型来修正负荷预测结果,从而提高预测准确度。在其他领域,文献[8-13]分别将ARMA模型应用于网络流量预测、股市预测、故障率预测和公交客运流量预测等。

因此,本文针对历史数据量稀少且还未成熟运营的公共电动汽车充电站充电功率需求的建模,提出一种基于ARMA预测算法的充电站运行状态预测以及充电功率需求建模,从宏观的角度对电动汽车充电站的充电功率需求进行研究分析。并以实际电动出租车充电站运行数据为基础进行仿真对比。模型预测结果表明,基于ARMA时间序列模型的电动汽车充电站运行状态预测具有较高的准确度,能够满足实际工程应用的要求。

1 ARMA模型

1.1 基本思想

基于ARMA模型预测的基本思想是:时间序列中第 n 个时刻的观察值不仅与前 $n-1$ 个观察值有依存关系,且与前 $n-1$ 个时刻进入系统的扰动有依存关



张曦予/助理工程师

关键词/Keywords

电动汽车充电站 ·
ARMA模型 ·
运行状态预测 ·
非平稳时间序列 ·
模型识别 ·

系，由此建立预测模型预测未来值。

ARMA模型是用于分析平稳性且非纯随机性时间序列的一种模型。因此在获得原始时间序列时，首先对其平稳性进行检验。其次检验原始时间序列是否纯随机性，即序列是否存在显著的相关性。最后根据符合标准的时间序列建立ARMA模型，利用样本自相关系数图和偏自相关系数图的性质确定模型的阶数 (p,q) ，选择适当的ARMA模型拟合预测值序列。

1.2 模型描述

ARMA模型包括自回归过程AR模型和移动平均过程MA模型两部分。

(1) AR模型

AR模型称为自回归模型，预测原理是用现时的扰动和有限项过去的观测值来预测模型的现时值。 p 阶自回归模型表达式如下，即

$$Y_{tar} = \theta_1 Y_{t-1} + \theta_2 Y_{t-2} + \cdots + \theta_p Y_{t-p} + e_t \quad (1)$$

式中， $\theta_i (i=1,2,\cdots,p)$ 为模型的自回归系数； e_t 为均值为零方差不为零的白噪声； Y_{t-i} 为原始时间序列； Y_{tar} 为AR模型的预测值。

如果定义后移算子为 B ，则

$$BY_t = Y_{t-1} \quad (2)$$

$$B^i Y_t = Y_{t-i} \quad (3)$$

式(1)可以表示为

$$Y_{tar} = (\theta_1 B + \theta_2 B^2 + \cdots + \theta_p B^p) Y_t + e_t \quad (4)$$

(2) MA模型

MA模型称为移动平均模型，预测原理是用现时的干扰及过去干扰的有限项来预测模型的现时值。 q 阶移动平均模型 Y_{tma} 表达式为

$$Y_{tma} = (-W_1 B - W_2 B^2 - \cdots - W_q B^q) e_t \quad (5)$$

式中， $W_j (j=1,2,\cdots,q)$ 为模型的移动平均系数； Y_{tma} 为MA模型预测值。

(3) ARMA模型

将AR模型和MA模型结合起来便可用来描述平稳随机过程的自回归移动ARMA (p,q) 阶模型，数学表达式为

$$Y_{tarma} = (\theta_1 B + \theta_2 B^2 + \cdots + \theta_p B^p) Y_t + e_t - (W_1 B + W_2 B^2 + \cdots + W_q B^q) e_t \quad (6)$$

2 充电站运行状态建模

2.1 预测模型

根据对充电站运行规律相关数据进行分析，可由充电站中充电桩的状态来描述充电站的运行状态。统计处于各个充电状态的充电桩数量，便可预估充电功率需求、有序充电能力以及提供故障预警等功能。

将充电桩所有可能的状态定义为以下五种充电站运行状态。

正在充电(0)：电动汽车接入充电桩并处于充电阶段；充完等待(1)：电动汽车接入充电桩一段时间后，已充好电等待用户取车；空闲(2)：充电桩等待电动汽车接入；故障(3)：充电桩处于故障状态，不能提供充电服务；排队等待(4)：充电站内的充电桩都处于使用状态，电动汽车排队等待充电。

由定义可知，统计处于0状态下的充电桩数量便可估计充电站的充电功率需求，统计1状态下的充电桩数量可衡量有序充电的能力，统计2状态及4状态下的充电桩数量可对充电站中充电桩数量配置提供参考，监测3状态为充电站发出故障预警。由实时的充电桩状态历史数据，应用ARMA时间序列模型进行预测，便可得到预测的充电站运行状态规律。由以上五种随机变量可以完整且宏观地对充电站的运行状态进行建模和预测。

为了使ARMA模型适用于电动汽车充电站运行状态的预测，对于模型的改进，定义一个差分算子使充电桩运行状态时间序列 $\{Y_t\}$ 平稳化，定义如下

$$\Delta Y_t = Y_t - Y_{t-1} \quad (7)$$

式中， ΔY_t 为一阶差分后的时间序列。如果一阶差分化还不能满足时间序列的平稳性，则再次差分化，直到序列平稳为止。这样就使得具有增长趋势的时间序列变换为平稳随机时间序列。实际数据验证表明，对充电站运行状态原始时间序列进行二阶差分化，即将序列变为平稳序列。综上所述，得到充电站运行状态预测模型ARMA (p,q) 表达式，即

$$\Delta^2 S_t = \Delta^2 N_p S_{tp} + \varepsilon_t + M_q \varepsilon_{tq} \quad (8)$$

$$\begin{cases} S_t = \{X_t, W_t, F_t, B_t, Q_t\} \\ N_p = \{\rho_{pX}, \rho_{pW}, \rho_{pF}, \rho_{pB}, \rho_{pQ}\} \\ M_q = \{\phi_{qX}, \phi_{qW}, \phi_{qF}, \phi_{qB}, \phi_{qQ}\} \end{cases} \quad (9)$$

式中, S_t 为状态变量集合; 五个状态变量依次代表处于 0~4 状态的充电桩; Δ 为差分算子; N_p 为各状态变量 p 阶自相关系数集合; M_q 为各状态变量 q 阶偏相关系数集合; ρ_{pX} 为状态 X_{t-p} 的自相关系数, ϕ_{qX} 为 ε_{t-q} 的 q 阶偏相关系数, ρ_{pW} 等参数同理。

2.2 预测流程

应用 ARMA 时间序列模型进行预测的流程如图 1 所示。




图1 ARMA建模流程图

1) 数据预处理。由于电动汽车充电站内充电桩的运行状态随机变化具有一定的不平稳性, 为了应用 ARMA 时间序列的算法进行预测, 就需要将其变为平稳的随机信号。通常引用差分算子, 对原非平稳时间序列施行二阶差分变换变为平稳时间序列, 并运用 ADF 方法进行平稳性检验。模型所适合的建模对象应是均值为零的平稳随机序列, 所以还需要进行零均值检验。

2) 模型识别及定阶。ARMA 模型定阶的标准是自相关和偏相关系数以负指数速度收敛到零。由此计算二阶差分后序列的自相关系数和偏相关系数, 通过自相关系数图及偏相关系数图的分析, 初步确定适合于给定样本的 ARMA 模型 p 、 q 值, 选择一个合适的 ARMA(p, q) 模型。

3) 参数估计。采用最小二乘法及式 (8)、式 (9) 得到模型中的参数估计值。

4) 模型检验。对估计得到的模型, 进行 LM 检验。可重新改进模型, 直到得到满足要求的模

型为止。如果模型的某些参数估计值不能通过显著性检验, 则应重新对模型进行识别。如果上述两个问题都不存在, 就可接受所建立的模型。

5) 充电功率需求预测及评价。设定一定的样本数量, 得到一天时间段内电动汽车充电站实时运行状态预测值。利用预测的正在充电状态时间序列及充电桩的额定充电功率, 预估充电站的充电功率需求。最后利用相关误差参数对预测结果进行评价, 以此证明模型的可靠性和有效性。

3 实例分析

所提出的充电站功率需求预测建模对于不同类型的电动汽车充电站都适用。为了说明建模过程, 本节以北京市延庆区电动出租车充电站为例。充电相关参数如表 1 所示。

表1 延庆区电动出租车充电相关参数

充电模式	充电功率/kW	车载电量/kW·h	充电周期/h
慢速充电	10	30	8

在实际运营中, 电动出租车完成一个充电周期后平均运行约为 80~110 km。以预测正在充电状态的数据为示例, 运用 EViews 软件作预测流程的说明。利用后台监控系统采集一周 2016 个正在充电状态时间序列数据点, 应用式 (8)、式 (9) 进行预测。

3.1 数据预处理

统计原始数据中一周的数据作为原始时间序列 $\{Y_t\}$, 采样间隔为 5 min, 共 2 016 个数据点。原始数据时间序列图如图 2 所示。




图2 原始时间序列图

延庆区面积为 12 km², 且延庆区距离北京市

区较远，出租车并不进市区，仅在区内运营。因此，延庆区电动出租车的运行半径小于5 km，行驶范围小，大多集中在中午和晚间对车辆进行充电，充电行为具有一定的规律性。在没有发生导致路况出现非规律变化的特殊事件（例如重大节日、举行大型运动会和恶劣天气等）的情况下，七日内的正在充电数量变化规律之间的差异不大。且原始时间序列具有一定的非平稳性。为了应用ARMA预测模型，将原始时间序列二阶差分化，其表达式为

$$X_t = \Delta^2 Y_t \tag{10}$$

式中， Δ 为差分算子； $\{X_t\}$ 为二阶差分化后的时间序列。

将 $\{X_t\}$ 进行ADF检验，EViews软件运行得到的结果如表2所示。

表2 ADF检验统计表

result	level	t-Statistic
ADF test statistic		-23.390 19
	1%	-3.433 412
Test critical values	5%	-2.862 779
	10%	-2.567 476

从表2中可以看出， $\{X_t\}$ 的ADF检验统计量-23.390 19远小于1%、5%和10%显著性水平的临界值。根据ADF假设检验判据，表明在99%的置信水平拒绝原假设，认为此时间序列没有单位根，序列是平稳的。

用 $\{X_t\}$ 样本均值作为样本均值的估计，即零均值检验，检验图如图3所示。




图3 零均值检验结果图

由图3可知， $\{X_t\}$ 样本均值在 $0 \pm 2\sqrt{S_t}$ 区间内。根据零均值检验判据，接受均值为零的原假设，表明二阶差分化后的时间序列已经是一个零均值序列。

3.2 模型的识别和定阶

首先，对 $\{X_t\}$ 进行自相关、偏相关分析，计算结果如图4所示。




图4 自相关系数和偏相关系数图

第一列和第二列为 $\{X_t\}$ 序列的自相关和偏相关分析图，数字编号表示滞后期数，AC表示自相关系数，PAC表示偏相关系数，Q-Stat表示独立性检验统计量，Prob表示相伴概率。

由图4可以看出，样本的自相关系数 ρ_1 较大，当滞后期 $k > 1$ 时，自相关函数都落在该范围内，所以时间序列 $\{X_t\}$ 在1步后是截尾的，因此可以用MA(1)模型进行拟合。对于偏相关系数，可以看出，偏相关系数在4步之后截尾，因此可以用AR(4)来对数据拟合。

3.3 参数估计

确定了模型的阶数后就需要对式（8）中的未知参数进行估计，本文中采用最小二乘估计。图5为最小二乘法的计算结果。

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.151855	0.022246	6.826155	0.0000
AR(2)	0.143319	0.022333	6.417366	0.0000
AR(3)	0.108471	0.022331	4.857460	0.0000
AR(4)	0.150844	0.022222	6.788168	0.0000
MA(1)	-0.997214	0.004072	-244.8750	0.0000
R-squared	0.423845	Mean dependent var	-0.000498	
Adjusted R-squared	0.422696	S.D. dependent var	1.539427	
S.E. of regression	1.169665	Akaike info criterion	3.153796	
Sum squared resid	2743.072	Schwarz criterion	3.167741	
Log likelihood	-3164.565	Hannan-Quinn criter.	3.158915	
Durbin-Watson stat	2.012063			
Inverted AR Roots	.80	-.04+.57i	-.04-.57i	-.57
Inverted MA Roots	1.00			

图5 最小二乘估计值

由图5可以写出此模型的表达式,即

$$X_t = 0.15188X_{t-1} + 0.143319X_{t-2} + 0.108471X_{t-3} + 0.150844X_{t-4} + \varepsilon_t + 0.997214\varepsilon_{t-1} \quad (11)$$

3.4 模型检验

将此模型进行LM检验,结果如图6所示。

Breusch-Godfrey Serial Correlation LM Test			
F-statistic	1.281636	Prob. F(2,2003)	0.2778
Obs*R-squared	2.550479	Prob. Chi-Square(2)	0.2794

Test Equation:
Dependent Variable: RESID
Method: Least Squares
Date: 07/23/13 Time: 10:31
Sample: 7 2016
Included observations: 2010
Presample missing value lagged residuals set to zero.

图6 LM检验图

图6中,Obs*R-squared为LM统计量值,数值为2.55。查询卡方分布表,可得显著性水平为5%时, $\chi^2_{0.05}(4)=9.488$;显著性水平为10%时, $\chi^2_{0.01}(4)=7.7779$ 。在此两种显著性水平下, $LM < \chi^2_{\alpha}(p)$,所以不能拒绝原假设,故残差序列不存在二阶自相关,模型对应的残差序列为白噪声序列。

3.5 模型预测

基于一周的运行数据,利用上述模型对一天中充电站内正在充电的充电桩数量进行预测,如图7所示。




图7 模型预测值

图7中,蓝色线条为模型预测值,红色线条为预测值95%的置信区间。将预测得到的数据与实际数据进行对比,如图8所示。

从图8中可以看出,模型拟合的较好,预测值接近真实值。Corrcoef语句计算得到两条曲线的相




图8 日正在充电状态预测与真实值对比图

关程度为97.1%。由图可知,电动出租车司机倾向于集中在中午和晚间23:00停运之前回充电站补充电量,其余时刻在路上行驶载客。此运行规律符合实际情况。

对预测结果的准确度和可靠性评价是预测分析的重要组成部分。预测分析中常用多种误差表现形式来对预测结果进行评价,以此判定方法的可行性和优劣性。以下从均方根误差、绝对误差、Theil不等系数和偏倚比率四个方面对预测结果的准确度和可靠性进行评价。

均方根误差是对预测误差的等可能加权平方和求平方根。平均绝对误差是预测误差绝对值的平均值。均方根误差和绝对误差的值越小,说明误差越小,预测效果越好。Theil不等系数由均方根误差、预测值等可能加权平方和的平方根以及实际值等可能加权平方和的平方根这三个数据计算而来。这一系数的取值区间为0~1,越靠近0,即预测值与实际值越靠近,模型拟合效果越好。偏移比率说明了预测均值与实际值的偏离程度,值越小,预测越准确。

由表3可知,模型的预测效果较好,预测误差较小,预测方法对各个预测点的预测准确度较高。

表3 预测结果评价

均方根误差	绝对误差	Theil不等系数	偏倚比率
1.008 9	0.645	0.027	0.000 13

3.6 充电站运行状态模型

同理按照上述方法,预测0~4状态及累计出

站车辆数的ARMA时间序列预测模型, 结合实际情况, 此出租车慢充站的充电桩数量大于出租车的数量, 所以排队等待的状态可以置为0。观测三个月的历史数据中没有故障记录, 同样可置故障状态的参数为0。由此利用式(8)、式(9)预测得到的相关参数值, 从而可以得到各个状态的模型表达式为

$$X_t = 0.152X_{t-1} + 0.143X_{t-2} + 0.108X_{t-3} + 0.15X_{t-4} + \varepsilon_t + 0.997\varepsilon_{t-1} \quad (12)$$

$$W_t = 0.029W_{t-1} + 0.064W_{t-2} + 0.05W_{t-3} + 0.01W_{t-4} + 0.04W_{t-5} + 0.02W_{t-6} + \varepsilon_t + 0.9\varepsilon_{t-1} \quad (13)$$

$$F_t = 0.019F_{t-1} + 0.018F_{t-2} + 0.009F_{t-3} + 0.088F_{t-4} + 0.058F_{t-5} + \varepsilon_t + 0.91\varepsilon_{t-1} \quad (14)$$

3.7 充电站功率需求预测

对于充电站的功率需求计算, 将充电过程简化为恒功率过程, 由此预测的充电站充电功率 $P_f(t)$ 计算式为

$$P_f(t) = \sum_{i=0}^{288} X_i P_v \quad (15)$$

式中, $\{X_i\}$ 为一天中的正在充电状态时间序列; P_v 为表1中的额定充电功率。由此得到的ARMA预测充电功率曲线, 将其与实际充电功率曲线进行对比, 如图9所示。




图9 实际及预测功率曲线对比图

由图9可以看出, 实际充电功率曲线较预测曲线更为平滑, 且峰值重叠的时间为11:00~15:00以及20:00~23:00。用Corrcoef语句计算得知两条曲线的相关度为81%。为了提高预测的准确

性, 可以对模型的阶数以及参数进行多次修正, 直到改进的模型可以达到预测的准确度。

4 结束语

提出一种基于ARMA算法的电动汽车充电站运行状态预测与充电功率建模方法。预测模型将充电站中的充电桩定义为五种状态, 利用处于不同状态的充电桩数量随时间变化的过程描述充电站的运行规律。

1) 电动汽车到达充电站充电以及离开充电站这两种事情皆具有一定的随机性, 所以充电桩的状态随时间的变化也是随机的。本文将充电站内的充电桩状态分为正在充电、充完等待、空闲、故障和排队等待五种类型。由此五种状态时间序列可完整描述充电站的运行状态。

2) 基于ARMA时间序列预测算法理论基础对建模及预测的流程作出说明。算例分析中, 以延庆区电动出租车充电站相关数据为例, 运用EViews软件进行建模和算例验证, 预测结果具有较高的准确度。其次, 基于正在充电状态时间序列以及充电桩额定充电功率建立充电站预测充电功率需求模型, 并与实际充电功率曲线对比, 证明了模型的合理性和有效性。

3) 基于ARMA算法的充电站运行状态预测及其充电功率需求建模的提出, 为衡量规模化后电动汽车充电站的充电负荷对电网的影响提供了借鉴。未来可进一步按文中定义的充完等待状态时间序列建立有序充电调度模型, 为以后电动汽车参与有序充电提供了理论基础; 排队以及空闲时间状态序列建立充电站优化配置模型, 从而合理利用充电站的基础充电设施, 提高充电站的经济性。

参考文献

- [1] 张曦予, 李秋硕, 陶顺, 等. 电动公交车充电站功率需求影响因素分析及建模[J]. 现代电力, 2014, 31(1): 28-33.
- [2] 胡百琳, 李晓明, 李小平, 等. 基于ARMA模型的水电站概率性发电量预测[J]. 电力系统及其自动化学报, 2003, 15(3): 63-65.

- [3] Torres J, De Blas G M. Forecast of hourly average wind speed with ARMA models in Navarre (Spain) [J]. Solar Energy, 2005, 79 (1): 65-77.
- [4] 高阳, 朴在林, 张旭鹏, 等. 基于噪声场合下 ARMA模型的风力发电量预测 [J]. 电力系统保护与控制, 2010, 38 (20): 164-167.
- [5] Shan Gao, Yu He, Hao Chen. Wind speed forecast for wind farms based on ARMA-ARCH model [C]. International Conference on Sustainable Power Generation and Supply, 2009: 6-7.
- [6] 曾鸣, 李树雷, 王良, 等. 基于ARMA模型和BP神经网络组合优化算法的风电预测模型 [J]. 华东电力, 2013, 41 (2): 348-352.
- [7] 黄元生, 邓佳佳, 苑珍珍. 基于ARMA误差修正和自适应粒子群优化的SVM短期负荷预测 [J]. 电力系统保护与控制, 2011, 39 (14): 26-32.
- [8] 王丽娜, 肖冬荣. 基于ARMA模型的经济非平稳时间序列的预测分析 [J]. 武汉理工大学学报, 2004, 28 (1): 133-136.
- [9] 段智彬, 孙恩昌, 张延华, 等. 基于ARMA模型的网络流量预测 [J]. 中国电子科学研究院学报, 2009, 4 (4): 352-356.
- [10] 李瑞莹, 康锐. 基于ARMA模型的故障率预测方法研究 [J]. 系统工程与电子技术, 2008, 30 (8): 1588-1591.
- [11] 李捷, 刘先省, 韩志杰. 基于ARMA的无线传感器网络流量预测模型的研究 [J]. 电子与信息学报, 2007, 29 (5): 1224-1227.
- [12] 李捷, 刘先省, 韩志杰. 基于ARMA模型对沪市股票指数的预测 [J]. 电子与信息学报, 2007, 29 (5): 1224-1227.
- [13] Fangge Li, Peixian Luan. ARMA model for predicting the number of new outbreaks of Newcastle disease during the month [C]. International Conference on Computer Science and Automation Engineering, 2011: 10-12.

(收稿日期: 2015-09-02) **EA**

(上接第51页)

- [5] 王兴贵, 杨维满. 一种微源逆变器串联连接型微网特性研究 [J]. 电力系统保护与控制, 2013, 41 (21): 129-135.
- [6] 张兴, 季建强, 张崇巍, 等. 基于内模控制的三相电压型PWM整流器不平衡控制策略研究 [J]. 中国电机工程学报, 2005, 25 (13): 51-56.
- [7] 霍群海, 孔力, 唐西胜. 微源逆变器不平衡非线性混合负载的控制 [J]. 中国电机工程学报, 2010, 30 (15): 10-15.
- [8] Amin Ghazanfari, Mohsen Hamzeh, Hossein Mokhtari. Active power management of multihybrid fuelcell/ supercapacitor power conversion system in a medium voltage microgrid [J]. IEEE Transactions on Smart Grid, 2012, 3 (4): 1903-1909.
- [9] 方超. 逆变器带非线性负载的控制方法研究 [D]. 哈尔滨: 哈尔滨工程大学, 2013.
- [10] 王建伟, 胡晓光, 陈松松, 等. 具有谐波补偿功能的动态电压恢复器控制策略 [J]. 电网技术, 2013, 37 (6): 1700-1705.
- [11] Hosseini S H, Ahmadi M, Ghassem S Zadeh. Reduce the output harmonics of cascade h-bridge multilevel inverter for electric vehicle applications [C]. International Conference on Electrical Power System, 2011: 752-755.
- [12] 王宝安, 唐钰政, 黄学良, 等. 馈能式非线性负载模拟装置电流跟踪无差拍控制策略 [J]. 电力系统自动化, 2013, 37 (10): 113-117.
- [13] 戴珂, 刘聪, 李彦龙, 等. 并联型APF对两类非线性负载的谐波补偿特性研究 [J]. 电工技术学报, 2013, 28 (9): 79-85.

(收稿日期: 2015-03-19) **EA**