

蚁群灰色神经网络组合模型在电力负荷预测中的应用

王捷¹, 吴国忠¹, 李艳昌²

(1. 浙江大学, 浙江 杭州 310027; 2. 金华电业局, 浙江 金华 321000)

摘要: 灰色GM(1, 1)预测模型, 在负荷预测中得到了广泛应用, 但是也有其局限性。当数据灰度越大, 预测精度越差, 并且不太适合经济长期后推若干年的预测, 在一定程度上是由模型中的参数 a 造成的, 为此引入向量 θ , 建立蚁群灰色模型, 然后与神经网络模型相组合, 即建立蚁群灰色神经网络组合预测模型。实证分析表明, 该预测方法是合理有效的, 与传统的预测方法相比, 提高了预测精度, 具有较好的实用价值。

关键词: 负荷预测; GM(1, 1); 蚁群算法; BP神经网络; 蚁群灰色模型

Application of ant colony gray neural network combined forecasting model in load forecasting

WANG Jie¹, WU Guo-zhong¹, LI Yan-chang²

(1. Zhejiang University, Hangzhou 310027, China; 2. Jinhua Electric Power Bureau, Jinhua 321000, China)

Abstract: Although GM(1,1) forecasting model is extensively applied in the load forecasting, it has its localization. The greater the gray level of data is, the lower the prediction precision is. Besides, it is not suitable to long-term forecasting of economy to backstep for years, which, to a certain extent, is caused by parameter a in the model. To solve the problem, vector θ is introduced to set up Ant Colony Gray model, then combined with Neural Network model. Ant Colony Gray Neural Network combined forecasting model is set up. Case analysis shows that the forecast method is suitable and effective, improving prediction precision compared with traditional forecast methods, and has better utility value.

Key words: load forecast; GM(1,1); ant colony optimization; BP neural network; ACOGM

中图分类号: TM715 文献标识码: A 文章编号: 1674-3415(2009)02-0048-05

0 引言

电力负荷预测^[1]的实质是根据预测对象的历史数据建立相应的数学模型, 描述其发展规律。精确的负荷预测工作必须建立在大量、全面及准确的电力系统负荷及社会经济发展数据的基础之上, 受经济发展、产业结构、居民收入水平、气候、国家政策等诸多因素的影响, 是一个灰色系统。灰色系统理论通过生成变换和关联分析等技术, 为分析、处理贫瘠信息系统, 进而探求其演化规律、建立预测模型, 提供了有效的分析工具。

GM(1, 1)模型是最常用的一种灰色系统模型, 要求样本数据少、原理简单、运算方便、短期预测精度高、可检验等优点, 已得到了广泛的应用, 但是GM(1, 1)模型同其他预测方法一样, 也具有其局限性, 在实际应用中受到一定的限制。为此, 人们提出了一系列改进的算法^[2-4], 如新信息GM(1, 1)模型、新陈代谢GM(1, 1)模型、干涉因子灰色预测模型等, 在不同的场合下对GM(1, 1)模型进行了一定程度的

改进。其中, 残差GM(1, 1)模型在实际应用中最为广泛, 但其预测精度仍不够理想。研究发现引入背景值 $x^{(0)}(k)$ 是导致GM(1, 1)模型精度不高的主要原因^[5,6]。

为此, 引入向量 θ , 建立蚁群灰色GM(1,1, θ)预测模型。蚁群灰色预测模型在一定程度上提高了预测精度, 但是其只考虑了单一电力因素, 而电力负荷预测是受多种因素影响的复杂非线性系统, 亦不能在任何时刻充分反映电力负荷数据的变化。与此同时, 神经网络模型具有强大的处理非线性关系的能力, 对于大量非结构性、非精确性规律具有自适应功能、自主学习和优化计算的特点, 因此, 将蚁群灰色预测模型与神经网络预测模型相组合, 建立蚁群灰色神经网络优化组合预测新模型。

实证表明, 此模型兼顾了蚁群灰色模型和人工神经网络模型的建模优点, 克服了单一模型的缺陷, 组合优化, 较之其中任一单一式模型预测精度有较好的改善, 在进行电力负荷预测时, 展现出良好的效果, 进一步提高了预测精度, 具有一定的实用价

值。

1 蚁群灰色预测模型

1.1 GM(1, 1, θ) 预测模型的建立

GM(1, 1)模型^[8,9]的实质是对原始序列做一次累加生成, 使生成序列呈一定规律性, 然后建立一阶线性微分方程模型, 求得拟和曲线对系统进行预测。

设用电量的原始时间序列为:

$$x^{(0)} = \{x^{(0)}(1), x^{(0)}(2), \dots, x^{(0)}(n)\}$$

用1-AGO生成一阶累加生成序列:

$$x^{(1)} = \{x^{(1)}(1), x^{(1)}(2), \dots, x^{(1)}(n)\}$$

$$\text{其中: } x^{(1)}(k) = \sum_{i=1}^k x^{(0)}(i)$$

构造一阶线性灰色微分方程后, 可得该方程的白化微分方程为

$$\frac{dx^{(1)}}{dt} + ax^{(1)} = u$$

$$\text{其中, } x^{(1)}(k) = [x^{(1)}(k+1) + x^{(1)}(k)]/2$$

利用最小二乘法求解, 有:

$$\hat{A} = [\hat{a}, \hat{u}]^T = (B^T B)^{-1} B^T Y$$

$$\text{式中: } B = \begin{bmatrix} -[x^{(1)}(1) + x^{(1)}(2)]/2 & 1 \\ -[x^{(1)}(2) + x^{(1)}(3)]/2 & 1 \\ \vdots & \vdots \\ -[x^{(1)}(n-1) + x^{(1)}(n)]/2 & 1 \end{bmatrix}, Y = \begin{bmatrix} x^{(0)}(2) \\ x^{(0)}(3) \\ \vdots \\ x^{(0)}(n) \end{bmatrix}$$

GM(1,1)模型的时间响应函数模型为:

$$x^{(1)}(k+1) = \left[x^{(0)}(1) - \frac{\hat{u}}{\hat{a}} \right] e^{-\hat{a}k} + \frac{\hat{u}}{\hat{a}}$$

上式是GM(1,1)模型灰色预测的具体计算公式, 对此式再做累减还原, 得原始数列 $x^{(0)}$ 的灰色预测模型为:

$$\hat{x}^{(0)}(k+1) = (1 - e^{-\hat{a}}) \left(x^{(0)}(1) - \frac{\hat{u}}{\hat{a}} \right) e^{-\hat{a}k}$$

深入分析 GM(1,1)模型的建模机理, 证明

GM(1,1)模型引入背景值 $x^{(1)}(k)$ 是导致模型精度不高的主要原因, 为此引入向量 θ 得到背景值序列的精确计算式, 将GM(1,1)模型推广为GM(1,1, θ)模型。

基于GM(1,1)建模机理与应用条件进行分析, 背景值的精确计算公式是:

$$z^{(1)}(k) = \theta_k x^{(1)}(k) + (1 - \theta_k) x^{(1)}(k+1) \\ (0 \leq \theta_k \leq 1)$$

计算可知, $\theta_k = 1/a - 1/(e^a - 1)$ 。当 $a > 0$ 时, $\theta_k > 0.5$; 当 $|a|$ 较大时, θ_k 与0.5偏离较大。不考虑 a 的大小而简单地取 $\theta_k = 0.5$ 是导致模型在 $|a|$ 较大时预测失效的重要原因。

因此, 引入向量 $\theta = (\theta_2, \dots, \theta_k, \dots, \theta_n)$, 构建包含修正向量的GM(1,1, θ)模型, 当 $\theta = (0.5, 0.5, \dots, 0.5)$ 时, GM(1,1, θ)模型即为GM(1,1)模型。

只要给出一组 θ_0 , 便有

$$B_0 = \begin{bmatrix} -[\theta_{02} x^{(1)}(1) + (1 - \theta_{02}) x^{(1)}(2)] & 1 \\ -[\theta_{03} x^{(1)}(2) + (1 - \theta_{03}) x^{(1)}(3)] & 1 \\ \vdots & \vdots \\ -[\theta_{0n} x^{(1)}(n-1) + (1 - \theta_{0n}) x^{(1)}(n)] & 1 \end{bmatrix}$$

将其代入 $\hat{A} = [\hat{a}, \hat{u}]^T$, 求解参数便可得改进的

灰色预测模型。

1.2 蚁群灰色预测模型

当原始序列确定后, 影响GM(1, 1, θ)模型预测精度的唯一因素便是 θ , 只要给出向量 θ 便可计算出预测值 $\hat{x}^{(0)}(k)$, 而应用传统优化方法很难求解出最优值, 因此采用蚁群优化算法^[10~12]来求解GM(1, 1, θ)模型。

算法的基本思想是:

假定GM(1, 1, θ)模型中的参数 θ 有 $n-1$ 个, 首先对 θ 进行排序, 记为 $\theta_1, \theta_2, \dots, \theta_{n-1}$, 对于参数 $\theta_i (1 \leq i \leq n-1)$, 将其设置为 N 个随机非零值, 形成集合 I_{θ_i} 。然后定义蚂蚁的数目为 m , 这些蚂蚁从蚁巢出发去寻找食物。每只蚂蚁从第一个集合出发, 根据集合中每个元素的信息素状态, 随机地从每个集合 I_{θ_i} 中选择一个元素, 并对所选元素的信息素做相应调节。当蚂蚁在所有集合中完成元素的选择后, 它就到达了食物源, 并按原路径返回蚁巢, 同时调节集合中所选元素的信息素。这一过程反复进行,

当全部蚂蚁收敛到同一路径时，或达到给定的迭代数时搜索结束。

求解蚁群灰色预测模型的主要步骤如下：

1) 初始化：令集合 I_{θ_i} ($1 \leq i \leq n-1$) 中的元素 j 的信息素 $\tau_j(I_{\theta_i})(t) = C$, ($1 \leq j \leq N$)，最大循环次数 NC_{max} ，蚂蚁的数目为 m ，全部蚂蚁置于蚁巢。

2) 启动所有蚂蚁，每只蚂蚁从第一个集合开始，按照下述规则依次在每个集合中选择一个元素。

路径选择规则：对于集合 I_{θ_i} ，任意一只蚂蚁 k ($k = 1, 2, \dots, m$)，根据下式计算的随机概率随机地选择它的第 j 个元素。

$$Prob(\tau_j^k(I_{\theta_i})) = (\tau_j(I_{\theta_i})) / \sum_{u=1}^N \tau_u(I_{\theta_i})$$

直到蚁群全部到达食物源。

3) 当所有蚂蚁在每个集合中都选择了一个元素，并按照原路径返回蚁巢，设该过程经历的时间为 n 个时间单位，则所选择的元素的信息素按下式做相应调节。

$\tau_j(I_{\theta_i})(t+n) = \rho \tau_j(I_{\theta_i})(t) + \Delta \tau_j(I_{\theta_i})$ ，其中参数 ρ ($0 \leq \rho < 1$) 表示信息素的持久性，则 $1-\rho$ 表示信息素的消逝程度。

$$\Delta \tau_j(I_{\theta_i}) = \sum_{k=1}^m \Delta \tau_j^k(I_{\theta_i})$$

$\Delta \tau_j^k(I_{\theta_i})$ 表示第 k 只蚂蚁在本次循环中，在集合 I_{θ_i} 的第 j 个元素 $p_j(I_{\theta_i})$ 上留下的信息素，可用下式来计算。

$$\Delta \tau_j^k(I_{\theta_i}) = \begin{cases} Q/e, & \text{若第 } k \text{ 只蚂蚁在本次循环中选择元素 } p_j(I_{\theta_i}) \\ 0, & \text{否则} \end{cases}$$

式中： Q 是常数，用于调节信息素的调整速度； e 是所有蚂蚁选择的元素作为灰色预测模型参数 θ 的

均方差，定义为 $e = \sqrt{\sum_{k=1}^n (x_k - x_k')^2}$ 。

式中： n 是蚁群采集的样本数目，也即创建灰色 GM(1, 1, θ) 模型的历史数据数目， x_k 、 x_k' 是灰色预测模型 GM(1, 1, θ) 的实际输出和期望输出。由此可见，误差越小，相应信息素的增加就越多。

4) 重复上述步骤，如果蚂蚁群全部收敛到一条路径或循环次数 $NC \geq NC_{max}$ ，则循环结束，输出最佳路径。

2 BP 神经网络预测模型

人工神经网络 ANN (Artificial Neural Network)，是反映人脑结构及功能的一种抽象数学模型。一个神经网络是由大量神经元节点互连而成的复杂网络，用以模拟人类进行知识的表示与存储以及利用知识进行推理的行为。

神经网络的反向传播 BP (Back Propagation) 算法是多层感知器的一种有效学习算法，它的模型为前向多层网络，如图1所示。

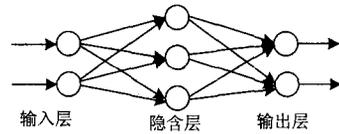


图 1 BP 网络结构

Fig.1 BP Network structure

BP神经网络预测模型的步骤可描述为：

- (1) 权值和阈值初始化：随机给全部权值和神经元的阈值赋以较小的初始值；
- (2) 给定输入 x_k 和目标输出 y_k ；
- (3) 计算实际输出 \hat{y}_k (正向过程)；
- (4) 修正权值(反向过程)：

$$W_{ij}^{(l)} = W_{ij}^{(l)} - \eta \frac{\partial E_k}{\partial W_{ij}^{(l)}} = W_{ij}^{(l)} - \eta \delta_{ik}^l O_{jk}^l, \quad \eta > 0$$

式中： $W_{ij}^{(l)}$ 为第 l 层第 j 个神经元到第 $l+1$ 层的第 i 个神经元的权系数； η 为增益项； δ_{ik}^l 为第 l 层 i 个神经元的模式的误差项。且有：

a. 若 i 为输出节点，则

$$\delta_{ik}^l = -\hat{y}_k (1 - \hat{y}_k) (y_k - \hat{y}_k)$$

b. 若 i 为隐节点，则

$$\delta_{ik}^l = O_{ik}^{(l)} [1 - O_{ik}^{(l)}] \sum_m \delta_{mk}^{(l+1)} W_{mi}^{(l+1)}$$

(5) 达到误差精度要求，则输出结果，否则回到 (3)。

由于节点输出值在 [0,1] 之间，故对训练样本的输入量和输出量均作以下初始化处理：

$$x = \frac{x_n - a}{b - a}$$

式中： x 为经过标准化的值， x_n 为实际负荷值， a 为最小负荷值的 0.7 倍， b 为最大负荷值的 1.3 倍。

3 蚁群灰色神经网络组合预测模型

设 f_1 是蚁群灰色预测值, f_2 是 BP 神经网络预测值, f_c 是加权平均的组合预测值。预测误差分别为 e_1 、 e_2 和 e_c , 取 w_1 和 w_2 为相应权系数, 且 $w_1 + w_2 = 1$, 有 $f_c = w_1 f_1 + w_2 f_2$, 要求 f_c 也是无偏的, 且误差及其方差分别是:

$$e_c = w_1 e_1 + w_2 e_2$$

$$\text{var}(e_c) = w_1^2 \text{var}(e_1) + w_2^2 \text{var}(e_2) + 2w_1 w_2 \text{cov}(e_1, e_2)$$

关于 w_1 对 $\text{var}(e_c)$ 求极小值, 可得:

$$w_1 = \frac{\text{var}(e_2) - \text{cov}(e_1, e_2)}{\text{var}(e_1) + \text{var}(e_2) - 2\text{cov}(e_1, e_2)}$$

记 $\text{var}(e_1) = \delta_{11}$, $\text{var}(e_2) = \delta_{22}$, $\text{cov}(e_1, e_2) = \delta_{12}$, 则组合预测权系数分别为:

$$w_1 = \frac{\delta_{22} - \delta_{12}}{\delta_{11} + \delta_{22} - 2\delta_{12}}, \quad w_2 = \frac{\delta_{11} - \delta_{12}}{\delta_{11} + \delta_{22} - 2\delta_{12}}$$

由于 f_1 和 f_2 是相互独立的负荷预测模型, 显

然有 $\text{cov}(e_1, e_2) = 0$, 即 $\delta_{12} = 0$, 所以:

$$w_1 = \frac{\delta_{22}}{\delta_{11} + \delta_{22}}, \quad w_2 = \frac{\delta_{11}}{\delta_{11} + \delta_{22}}$$

从式中, 不难看出: $\lim_{\delta_{11} \rightarrow \infty} w_1 = 0$,

$\lim_{\delta_{11} \rightarrow \infty} w_1 = 1, \lim_{\delta_{22} \rightarrow \infty} w_1 = 1, \lim_{\delta_{22} \rightarrow \infty} w_2 = 0$ 。因此, 预测值 f_1 越可靠, f_1 的权数值越大, 反之亦然。

显而易见, $\text{var}(e_c)_{\min} \leq \delta_{11}, \text{var}(e_c)_{\min} \leq \delta_{22}$, 蚁群灰色神经网络组合预测模型优于各单一模型。

4 实证分析

为了验证这一改进预测模型的预测结果, 本文对某地区工业产值、农业产值、GDP 值及用电量情况进行了调研, 根据上述建模的理论方法与步骤, 运用 Matlab 6.5, 以 1999~2006 年的用电量的历史数据为基础, 分别使用 GM(1, 1) 方法、BP 神经网络方法、蚁群灰色神经网络组合预测方法进行预测, 预测结果见表 1。

表 1 某地区年度用电量预测分析

Tab.1 Analysis of consumption load forecasting some area

年度	实际值 /万 kWh	GM(1, 1)		BP 神经网络		蚁群灰色神经网络组合预测	
		预测值 /万 kWh	相对 误差	预测值 /万 kWh	相对 误差	预测值 /万 kWh	相对误差
99	776 628	784 903	-1.065 5%	779 625	0.901 7%	7 750 49	0.203 3%
00	914 389	875 782	4.222 2%	929 657	-1.669 7%	9 105 29	0.422 2%
01	979 987	977 182	0.286 2%	983 648	-0.373 6%	9 813 52	-0.139%
02	1 085 024	1 090 323	-0.488 4%	1 089 876	-0.447 2%	1 090 034	-0.462%
03	1 197 362	1 216 563	-1.603 6%	1 207 653	-1.132 0%	1 194 048	-1.124%
04	1 321 800	1 357 421	-2.694 9%	1 313 253	0.646 6%	1 328 935	-0.54%
05	1 528 890	1 514 587	0.935 5%	1 535 427	-0.427 6%	1 528 028	0.056 4%
06	1 716 323	1 689 950	1.536 6%	1 724 385	-0.469 7%	1 712 159	0.242 6%

由表 1 可知, 蚁群灰色神经网络组合预测模型的预测精度明显优于 GM(1,1) 和 BP 神经网络模型, 其最大相对误差为 1.124%, 最小相对误差仅为 0.056 4%, 很好地满足了电力系统运行调度规划的需要, 在中长期负荷预测中具有一定的实际应用价值。

基于蚁群灰色神经网络预测模型的方法及原理, 对此地区 2007 年、2008 年及 2009 年的用电量进行预测, 预测结果分别为: 1 939 245 万 kWh、2 158 360 万 kWh 和 2 367 539 万 kWh。

5 结论

(1) 针对传统的 GM(1,1) 预测模型精度不高的

主要原因, 建立蚁群灰色模型, 在一定程度上提高了预测精度。

(2) 利用蚁群灰色模型和 BP 神经网络模型的优点, 建立蚁群灰色神经网络组合预测模型, 较好地拟合了电力负荷用电量的二重趋势, 进一步提高了预测精度, 达到了良好的预测效果。

(3) 经实证分析, 基于蚁群灰色神经网络组合预测模型的预测方法是可行有效的, 是一种可靠的方法, 具有一定的实用价值。

参考文献

- [1] 牛东晓, 曹树华, 赵磊. 电力负荷预测技术及其应用[M]. 北京, 中国电力出版社, 1998, 10.

- NIU Dong-xiao, CAO Shu-hua, ZHAO Lei. Power Load Forecast Technology and Application[M]. Beijing:China Electric Power Press, 1998,10.
- [2] 吴宏晓,候志俭,邹能灵. 灰色神经网络模型 GNNM(1,1) 在城市年用电量预测中的应用[J]. 中国电力,2005,38(2):45-48.
WU Hong-xiao, HOU Zhi-jian, TAI Neng-ling. Application of Grey Neural Network Model GNNM(1,1) in City Electricity Demand Forecasting[J]. Electric Power:2005,38(2):45-48.
- [3] 周平,杨岚,周家启. 电力系统负荷灰色预测的新方法[J]. 电力系统及其自动化学报,1998,10(3):45-50.
ZHOU Ping, YANG Lan, ZHOU Jia-qi. The New Method of Electric Power System Load Gray Forecast[J]. Proceedings of the EPSA, 1998, 10(3):45-50.
- [4] 周铭,王洪发. 基于遗传算法的灰色GM(1,1)模型[J]. 南昌大学学报,2002,26(4):331-333.
ZHOU Ming, WANG Hong-fa. Gray Model GM(1,1) Based on Genetic Algorithm[J]. Journal of Nanchang University, 2002,26(4):331-333.
- [5] 张大海,史开泉,江世芳. 灰色负荷预测的参数修正法[J]. 电力系统及其自动化学报,2001, 13(2): 20-22.
ZHANG Da-hai, SHI Kai-quan, JIANG Shi-fang. Coefficient Modification of Grey Load Prediction Forecast[J]. Proceedings of the EPSA, 2001, 13(2):20-22.
- [6] 肖俊,孙德宝,秦元庆. 灰色模型在电力负荷预测中的优化与应用[J]. 控制理论与应用,2005, 24(2): 19-21.
XIAO Jun, SUN De-bao, QIN Yuan-qing. Application of the Grey Model in Electric Power Prediction and its Optimization[J]. Control Theory and Applications, 2005,24(2):19-21.
- [7] 牛东晓,张博,陈立荣,等. 智能优化灰色模型在中期用电量预测中的应用[J]. 华电电力, 2006, 34(1): 8-11.
NIU Dong-xiao, ZHANG Bo, CHEN Li-rong, et al. Application of Intelligent Optimization Grey Model in Middle-term Electricity Demand Forecasting[J]. East China Electric Power, 2006, 34(1):8-11.
- [8] 高尚,杨靖宇. 群智能算法及其应用[M]. 北京,中国水利水电出版社, 2006, 5.
GAO Shang, YANG Jing-yu. Swarm Intelligence Algorithms and Applications[M]. Beijing: China Water Power Press, 2006,5.

收稿日期: 2008-03-20; 修回日期: 2008-04-01

作者简介:

王捷(1975-), 男, 硕士研究生, 工程师, 研究方向为电力系统经济运行及电力系统调度自动化、电力企业信息化建设; E-mail:hd_lyc@163.com

吴国忠(1944-), 男, 教授, 主要从事电力系统自动化专业的教学及相关研究工作。

(上接第 27 页 continued from page 27)

- DING Ming, WANG Min. Distributed Generation Technology[J]. Electric Power Automation Equipment, 2004,24(7):31-36
- [3] 王辉,邱毓昌,李汝彪. 分布式发电技术发展概况[J]. 西北电力技术,2005
WANG Hui, QIU Yu-chang, LI Ru-biao. Development of Distributed Generation Technologies[J]. Northwest China Electric Power,2005.
- [4] 崔金兰,刘天琪. 分布式发电技术及其并网问题研究综述[J]. 现代电力,2007,24(3):53-57.
CUI Jin-lan, LIU Tian-qi. Distributed Generation and Its Grid Interconnection Issue[J]. Modern Electric Power, 2007,24(3):53-57
- [5] IEEE 1547. IEEE Standard for Interconnecting Distributed Resources with Electric Power Systems. 2003
- [6] 王志群,朱守真,周双喜,等. 分布式发电对配电网电压分布的影响[J]. 电力系统自动化,2004,28(16):56-60.
WANG Zhi-qun, ZHU Shou-zhen, ZHOU Shuang-xi, et al. Impacts of Distributed Generation on Distribution System Voltage Profile[J]. Automation of Electric Power Systems,2004,28(16):56-60.
- [7] 李蓓,李兴源. 分布式发电及其对配电网的影响. 国际电力,2005.9(3):46-49.
LI Bei, LI Xing-yuan. Distributed Generation Sources and Their Effects on Distribution Networks. International Electric Power for China, 2005.9(3):46-49.
- [8] 石嘉川,刘玉田. 计及分布式发电的配电网多目标电压优化控制[J]. 电力系统自动化,2007,31(13):47-51.
SHI Jia-chuan, LIU Yu-tian. Multi-objective Voltage Control in Distribution Networks with Distributed Generation[J]. Automation of Electric Power Systems, 2007,31(13):47-51.
- [9] Reddy K N, Agarwal V. Utility-Interactive Hybrid Distributed Generation Scheme With Compensation Feature[J]. IEEE trans. Energy Convers., vol.22, no.3, pp.666-673, Sep.2007.
- [10] Chen Z, Blaabjerg F, Pedersen J K. A Multi-Functional Power Electronic Converter in Distributed Generation Power Systems[J]. Proc. of PESC, 2005.1738-1744.
- [11] 宁艳,钱科军,袁越. 分布式发电对配电网的影响研究[J]. 电力系统自动化[J],2005.
NING Yan, QIAN Ke-jun, YUAN Yue. Impacts of Distributed Generation on Distribution System[J]. Automation of Electric Power Systems,2005

收稿日期: 2008-03-18; 修回日期: 2008-04-30

作者简介:

王瑞(1984-), 女, 硕士研究生, 主要从事分布式发电系统的研究; E-mail:06121943@bjtu.edu.cn

林飞(1975-), 男, 博士, 副教授, 研究方向为交流调速技术、分布式发电等。