

# 小波软阈值去噪和 GRNN 网络在月度负荷预测中的应用

刘学琴<sup>1</sup>, 吴耀华<sup>2</sup>, 崔宝华<sup>1</sup>

(1. 保定电力职业技术学院电气工程系, 河北 保定 071051; 2. 陕西理工学院电气工程系, 陕西 汉中 723003)

**摘要:** 在介绍了小波阈值降噪理论和广义回归神经网络基本理论的基础上, 针对电力系统的月负荷数据同时具有趋势增长性和季节波动性的复杂非线性特征, 提出了一种月负荷预测新方法。首先对历史数据进行小波软阈值去噪, 以横向历史数据和纵向历史数据作为神经网络的输入, 建立了月度负荷预测模型, 并将其应用于我国某地区月度负荷预测, 结果表明: 该模型既具有较好的鲁棒性, 预测精度较高且较为稳定, 又具有良好的实用性。

**关键词:** 月度负荷预测; 广义回归神经网络; 小波软阈值; 去噪

## Application of wavelet soft-threshold de-noising and GRNN in monthly load forecasting

LIU Xue-qin<sup>1</sup>, WU Yao-hua<sup>2</sup>, CUI Bao-hua<sup>1</sup>

(1. Department of Electrical Engineering, North China Baoding Electric Power VOC.&TECH Institute, Baoding 071051, China;  
2. Department of Electrical Engineering, Shaanxi University of Technology, Hanzhong 723003, China)

**Abstract:** Based on the de-noising theory of wavelet soft-threshold and the general regression neural network (GRNN), according to the property of increase trend and seasonal fluctuation of monthly history load, the paper proposes a new monthly load forecasting model. First, it de-noises data of load using wavelet soft-threshold and uses the horizontal and vertical de-noised history data as input of GRNN building the monthly load forecasting model. Then the new model is applied to forecast monthly load of somewhere. The forecasting result shows that it has good robustness and practicality as well as high precision.

**Key words:** monthly load forecasting; general regression neural network (GRNN); wavelet soft-threshold; de-noising

中图分类号: TM715 文献标识码: A 文章编号: 1674-3415(2009)14-0059-04

## 0 引言

电力负荷预测是电力系统中一项重要的工作, 是电力系统运行、控制和规划不可缺少的组成部分, 特别是电力系统逐步过渡到商业化运行的情况下, 电力负荷预测工作更为重要。在保证系统安全可靠运行、满足用户需求的前提下, 电力企业必须更多地从经济效益方面考虑系统的规划、运行。而通过准确的负荷预测, 可以避免资源的浪费, 从而提高电力系统的经济效益。

负荷预测的核心是根据其历史变化规律, 推断出负荷未来的发展。电力系统的月负荷, 随着经济的发展, 人民生活水平的提高, 呈现不断增长的趋势; 同时, 由于各月的情况不同, 月负荷每年重复出现循环变动, 即以 12 个月为周期的季节性波动; 电网月负荷同时具有增长性和季节波动性的二重趋势, 因此使得负荷的变化呈现出复杂的非线性组合特征<sup>[1,2]</sup>。

基于此, 本文提出的预测方法仅仅是考虑负荷

数据本身, 不考虑其影响因素, 把负荷序列看作一个信号序列, 应用小波去噪原理, 将信号与噪声分离, 然后把去噪后的数据分解为反映负荷增长趋势的纵向历史负荷和反映负荷波动趋势的横向历史负荷, 最后将横向历史负荷和纵向历史负荷共同作为神经网络的输入神经元, 同时反映波动趋势和增长趋势这两种不同的变化, 预测未来月份的负荷数据。

## 1 小波阈值去噪理论简介

小波去噪的根本任务是在小波域将信号的小波变换与噪声的小波变换有效的分离。小波阈值收缩 (WaveShrink) 的方法是由 Donoho 和 Johnstone 于 1992 年提出的, 该方法在最小均方差意义下可达到近似最优, 并且可取得较好的视觉效果, 因而得到了深入的研究和广泛的应用<sup>[3]</sup>。

小波阈值收缩法去噪的主要理论依据是, 小波变换特别是正交小波变换具有很强的去数据相关性, 它能够使信号能量在小波域集中在一些大的小波系数中, 而噪声的能量却分布于整个小波域内,

因此，经小波分解后，信号的小波系数幅值要大于噪声的系数幅值，可以认为，幅值比较大的小波系数一般以信号为主，而幅值比较小的系数在很大程度上是噪声。于是，采用阈值的方法可以把信号系数保留，而使大部分噪声系数减少至零。

小波阈值收缩法去噪的具体处理过程为：将含噪信号在各尺度上进行小波分解，保留大尺度低分辨率下的全部小波系数；对于各尺度高分辨率下的小波系数，可以设定一个阈值，幅值低于该阈值的小波系数置为 0，高于该阈值的小波系数或者完全保留，或者作相应的“收缩”(shrinkage)处理。最后将处理后获得的小波系数利用逆小波变换进行重构，恢复出有效的信号。

目前，人们提出了多种阈值的选取方法：VisuShrink、RiskShrink、SureShrink、WaveJSShrink 等。最常用的是 VisuShrink，这种方法采用全局统一阈值  $\sigma\sqrt{2\log N}$ ，其中  $\sigma$  是噪声信号的标准差(度量噪声的强弱)， $N$  是信号长度。去噪算法如下：

1) 计算含噪信号的正交小波变换。对于长度为  $N$  的含噪信号  $X$ ，不妨设  $N = 2^J$ ，利用正交小波变换的快速算法获得低分辨率  $L$  ( $0 \leq L < J$ ) 下的尺度系  $\{v_{L,k}, k = 1, \dots, 2^L\}$ ，及各分辨率下的小波系数  $\{w_{j,k}, j = L, L+1, \dots, J-1, k = 1, \dots, 2^j\}$  后，其中尺度系数和小波系数共  $N$  个，在处理边界时，常采用周期延拓方法。

2) 对小波系数进行非线性阈值处理。为保持信号的整体形状不变，保留所有的低频系数  $\{v_{L,k}, k = 1, \dots, 2^L\}$ 。取阈值  $\lambda = \sigma\sqrt{2\log N}$ ，对每个小波系数，采用软阈值方法进行处理：

$$\text{软阈值: } \tilde{w}_{j,k} = \begin{cases} w_{j,k} - \lambda, & w_{j,k} \geq \lambda \\ 0, & |w_{j,k}| < \lambda \\ w_{j,k} + \lambda, & w_{j,k} \leq -\lambda \end{cases}$$

即，将含噪信号的小波系数与所选定的阈值进行比较，大于阈值的点收缩为该点值与阈值的差值；小于阈值相反数的点收缩为该点与阈值的和；幅值小于等于阈值的点变为零。

3) 进行逆小波变换。由所有低频尺度系数，以及经由阈值处理后的小波系数做逆小波变换进行重构，得到恢复的原始信号的估计值。

## 2 广义神经网络模型

GRNN 网络是由 The Lockheed Palo Alto 研究实验室的 Donald Specht 提出的一种新型的神经网络，它建立在数理统计的基础上，能够根据样本数据逼近其中隐含的隐射关系，主要用于系统模型和预测。优点是学习速度快，网络最后收敛于样本量集聚最多的优化回归面，一旦学习样本确定，则相应的网络结构和神经元之间的连接权值也随之确定，网络训练过程实际上只是确定平滑参数的过程，并且在样本数据较稀少时，效果也很好，网络可以处理不稳定的数据。人为调节的参数少，只有一个阈值。网络的学习全部依赖数据样本。这个特点决定了网络得以最大限度地避免人为主观假定对预测结果的影响。GRNN 用标准的统计学公式来计算在随机变量  $x$  的给定测量值  $X$  时，变量  $y$  的有条件平均值  $Y$ 。在计算这个条件平均值是要用到相关可能性密度函数(pdf)，在 GRNN 中，相关的 pdf 使用泊松估计，由训练矢量近似来得到<sup>[4,5]</sup>。

### 2.1 广义回归神经网络的算法理论

广义回归神经网络的理论基础是非线性回归分析。当给定矢量随机变量  $x$  的一个测量值  $X$  时，随机变量  $Y$  的条件平均为

$$\bar{Y}(X) = \frac{\int_{-\infty}^{\infty} yf(X/y)dy}{\int_{-\infty}^{\infty} f(X/y)dy} \quad (1)$$

在此  $f(X/y)$  是  $y$  和  $x$  的相关可能性密度函数。

在 GRNN 中， $f(X/y)$  用泊松来近似，其窗口为常对角斜方差矩阵。

$$\hat{f}(X/y) = \frac{1.0}{(2\pi\sigma^2)^{\frac{N+1}{2}} T} \sum_{i=1}^T [\exp(-\frac{D_i^2}{2\sigma^2}) \exp(-\frac{(y-Y^{(i)})^2}{2\sigma^2})] \quad (2)$$

式中： $\{(X^{(i)}, Y^{(i)}), i = 1, \dots, T\}$  是一组输入输出值，并且

$$D_i = \|x - X^{(i)}\| = \sqrt{\sum_{i=1}^N (x_i - X_i^{(i)})^2} \quad (3)$$

为  $x$  和  $X^{(i)}$  之间的欧几里德距离， $N$  是输入空间的维数，即在网络中的输入单元数。

$\sigma$  是一个宽度函数，当泊松窗口的数量  $T$  变化大时，必须满足下列的趋势。

$$\lim_{T \rightarrow \infty} \sigma(T) = 0$$

$$\text{且 } \lim_{T \rightarrow \infty} (T\sigma^N(T)) = 0$$

将 pdf 的估计方程 (2) 直接带入 (1)，改变积分求和顺序，可得到下面的条件平均估计。

$$\bar{Y}(X) = \frac{\sum_{i=1}^T [\exp(-\frac{D_i^2}{2\sigma^2})] \int_{-\infty}^{\infty} y \exp[-\frac{(y-Y^{(i)})^2}{2\sigma^2}] dy}{\sum_{i=1}^T [\exp(-\frac{D_i^2}{2\sigma^2})] \int_{-\infty}^{\infty} \exp[-\frac{(y-Y^{(i)})^2}{2\sigma^2}] dy} \quad (4)$$

若设变量  $z = y - Y^{(i)}$ , 分子的积分项可化简为

$$\int_{-\infty}^{\infty} y \exp[-\frac{(y - Y^{(i)})^2}{2\sigma^2}] dy = \int_{-\infty}^{\infty} (z + Y^{(i)}) \exp(-\frac{z^2}{2\sigma^2}) dz = Y^{(i)} \int_{-\infty}^{\infty} \exp(-\frac{z^2}{2\sigma^2}) dz \quad (5)$$

分母中的积分项化简为

$$\int_{-\infty}^{\infty} \exp[-\frac{(y - Y^{(i)})^2}{2\sigma^2}] dy = \int_{-\infty}^{\infty} \exp(-\frac{z^2}{2\sigma^2}) dz \quad (6)$$

将式 (5)、(式 6) 代入式 (4), 可得到

$$\bar{Y}(X) = \frac{\sum_{i=1}^T [\exp(-\frac{D_i^2}{2\sigma^2}) Y^{(i)} \int_{-\infty}^{\infty} \exp(-\frac{z^2}{2\sigma^2}) dz]}{\sum_{i=1}^T [\exp(-\frac{D_i^2}{2\sigma^2}) \int_{-\infty}^{\infty} \exp(-\frac{z^2}{2\sigma^2}) dz]} = \frac{\sum_{i=1}^T [Y^{(i)} \exp(-\frac{D_i^2}{2\sigma^2})]}{\sum_{i=1}^T \exp(-\frac{D_i^2}{2\sigma^2})} \quad (7)$$

### 2.2 广义回归神经网络的结构

GRNN 结构如图 1 所示, 包括输入层, 模式层, 求和层与输出层四层神经元。对应网络输入  $X = [X_1, X_2, \dots, X_m]^T$ , 其输出为  $Y = [y_1, y_2, \dots, y_l]^T$ 。

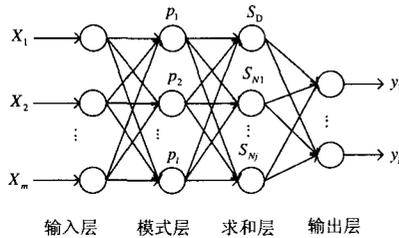


图 1 广义回归神经网络模型

Fig.1 Generalized regression neural network

输入层的神经元数目等于学习样本中输入层的维数  $m$ , 各神经元是简单的分布单元, 直接将输入变量传递给隐含层。

模式层的神经元数目等于学习样本的数目  $n$ , 各神经元对应不同的样本, 模式层中神经元  $i$  的传递函数为

$$P_i = \exp[(X - X_i)^T (X - X_i) / 2\sigma^2] \quad i = 1, 2, \dots, n \quad (8)$$

其中:  $X$  为网络输入变量,  $X_i$  为神经元  $i$  对应的学习样本,  $\sigma$  为平滑参数, 也就是说, 神经元  $i$  的输出为输入变量  $X$  与其对应的样本  $X_i$  之间的 Euclid 距离平方的指数形式

$$D^2 = (X - X_i)^T (X - X_i) \quad (9)$$

求和层包括两种类型神经元, 其中一种神经元对所有模式层神经元的输出进行算术求和, 模式层各神

经元与该神经元的连接权值为 1, 传递函数为

$$S_D = \sum_{i=1}^n P_i, \quad i = 1, 2, \dots, L \quad (10)$$

其它神经元对所有模式层神经元的输出进行加权求和, 模式层中第  $i$  个神经元与求和层中第  $j$  个求和神经元之间的连接权值为第  $i$  个输出样本  $Y_i$  中的第  $j$  个元素  $y_{ij}$ , 求和神经元的传递函数为

$$S_{Nj} = \sum_{i=1}^n y_{ij} P_i, \quad j = 1, 2, \dots, L \quad (11)$$

输出层中的神经元数目等于学习样本中输出向量的维数  $L$ , 各神经元将求和层的输出相除, 即

$$y_j = \frac{S_{Nj}}{S_D}, \quad j = 1, 2, \dots, L \quad (12)$$

### 2.3 光滑因子的确定

对于广义回归神经网络, 其初始化就是对训练样本的学习过程, 学习样本确定, 则相应的网络结构和各神经元之间的连接权值也随之确定, 网络的训练实际上只是确定光滑因子的过程。与传统的误差反向传输算法不同, 广义回归神经网络的学习算法在训练过程中无需调整神经元之间的连接权值, 而是改变光滑因子, 从而调整各单元的传递函数, 以获得最佳回归估计结果。

由式 (7) 可以看出, 光滑因子  $\sigma$  对网络的预测性能影响较大, 令平滑参数以增量  $\Delta\sigma$  在一定范围  $[\sigma_{\min}, \sigma_{\max}]$  内递增变化; 在学习样本中, 除去一个样本, 用剩余的样本构造广义回归神经网络对该样本进行估计, 得到估计值与样本值之间的误差, 对每一样本重复该过程, 得到误差序列, 将误差序列的均方值

$$E = \frac{1}{n} \sum_{i=1}^n [\hat{Y}_i(X_i) - Y_i]^2 \quad (13)$$

作为网络性能的评价指标, 将最小误差对应的平滑参数用于最后的广义回归神经网络。在确定平滑参数的过程中, 初始值  $\sigma_{\min}$  太小, 式 (4) 可能会出现除以 0 的情况, 给出如下  $\sigma_{\min}$  的计算方法

$$\sigma_{\min} = [-D_{\min}^2 / 2 \ln \epsilon]^{\frac{1}{2}}$$

其中:  $D_{\min}$  为学习样本中各输入样本之间 Euclid 距离的最小值,  $\epsilon > 0$  为计算机能够表达的最小正数。

平滑参数的确定过程隐含了网络性能的验证过程。因此, 在网络的学习样本中不需要另外的验证数据。

### 3 研究算例

本文所取负荷数据是以月为单位的时间序列,

负荷数据由陕西某供电局提供,资料取自 1989 年—2005 年共 17 年 (204 个月) 的历史负荷数。

### 3.1 原始数据分析

首先基于 Matlab 语言对 1989—2004 这连续 192 个月的负荷数据应用小波软阈值进行去噪处理,小波去噪前后数据曲线如图 2,由图可以看出,软阈值法去噪不仅几乎完全可以抑制噪声,而且可很好地保留反映原始信号的特征尖峰点,因而具有较好的去噪效果<sup>[6]</sup>。

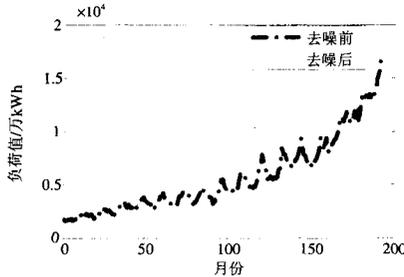


图 2 去噪前后负荷曲线

Fig.2 The de-noised data and the history data of load

### 3.2 样本选择

通过分析月度负荷特性数据序列可知,随时间的推移,月度负荷和往年同一月的历史负荷相比具有明显的增长趋势;同时,月度负荷随季节变化与最近相邻几个月的历史负荷呈现出某种波动趋势。因此,考虑将横向历史负荷和纵向历史负荷共同作为广义神经网络的输入神经元,同时反映波动趋势和增长趋势这两种不同的变化<sup>[7]</sup>。

将待预测年某月的负荷数据用  $f(i, j)$  表示,其中  $i$  代表年,  $j$  代表月,  $j=1, \dots, 12, i=4, \dots, 16$ 。未来一年各月负荷  $f(i, j)$  预测模型如下:

样本输入:  $f(i, j-1), f(i, j-2), f(i, j-3), f(i-1, j), f(i-1, j-1), f(i-1, j-2), f(i-2, j), f(i-2, j-1)$ ,

其中:

$$f(i, j-k) \begin{cases} \text{当 } j-k=0 & \text{表示 } i-1 \text{ 年 } 12 \text{ 月份的负荷数据} \\ \text{当 } j-k=-1 & \text{表示 } i-1 \text{ 年 } 11 \text{ 月份的负荷数据} \\ \text{当 } j-k=-2 & \text{表示 } i-1 \text{ 年 } 10 \text{ 月份的负荷数据} \end{cases}$$

$f(i-k, j)$  表示  $i-k$  年  $j$  月的负荷数据。

样本输出:  $f(i, j)$

### 3.3 模型结构

其网络结构如图 1。输入层为 8 个神经元,输出层为 1 个神经元,模式层为 11 个,求和层 2 个,网络结构为 8-11-2-1<sup>[8]</sup>。根据反复实验确定最优平滑

参数取为 0.1547。

### 3.4 预测结果

以 1989 年—2004 年历史负荷数据为依据,采用了直接用 GRNN 和历史负荷数据经小波去噪两种方法,分别预测 2005 年 12 个月的负荷数据,预测结果见表 1。从结果可以看出:如果不采用小波阈值去噪,而直接用 GRNN 神经网络预测,其相对误差较大,相对误差最大已超过 6%,平均相对误差达 4.755%,而用本文介绍的方法预测,相对误差最大不超过 3%,平均相对误差为:2.236%,预测精度比较高。

表 1 2005 年月负荷预测结果 (单位 万 kWh)

Tab.1 Monthly load forecasting result of 2005

(unit ten thousand kwh)

月份	实际值	未去噪 GRNN 预测法		去噪后 GRNN 预测法 (本文预测法)	
		预测值	相对误差 / (%)	预测值	相对误差 / (%)
一月	17 180	16 404	-4.514 4	16 360	2.852 2
二月	15 866	16 880	6.257 1	16 210	-2.168 3
三月	16 863	17 794	5.523 3	16 601	1.553 7
四月	16 008	16 511	3.147 7	15 715	1.830 3
五月	15 592	14 662	-5.962 1	15 281	1.994 6
六月	15 287	16 134	5.542 3	15 595	2.015 2
七月	16 489	17 456	5.866 1	16 123	2.219 7
八月	16 979	17 697	4.231 1	17 505	-2.509 1
九月	17 173	16 804	-2.146 6	16 890	1.647 9
十月	17 109	16 259	-4.965 5	16 845	1.543 0
十一月	18 938	20 071	5.987 4	18 431	2.677 2
十二月	21 647	22 777	5.221 2	20 986	2.730 2

## 4 结论

首先对负荷数据进行小波软阈值处理,然后将去噪后的数据送入广义神经网络进行预测。考虑到月度负荷具有趋势增长性和季节波动性的二重特性,该神经网络预测模型以横向负荷数据和纵向负荷数据作为神经网络的输入神经元,使得预测模型更合理。

通过实例应用表明,该模型具有较好的鲁棒性,预测精度较高且较为稳定,既有良好的实用性,且可适用于周,季负荷特性等具有二重趋势的序列的预测。

(下转第 85 页 continued on page 85)

输网络传给分散的测控单元驱动智能开关完成整个逻辑功能。模拟量的采集采用 IEC61850 标准 SMV 服务报文传输给测控装置,开关量以及判别逻辑输出的传输采用 GOOSE 通道。该方法已成功应用到洛阳金谷园 110 kV 数字化变电站改造中。

### 参考文献

- [1] 甘景福.一起备自投装置拒动事故的分析[J].电力系统自动化,2004,28(17):97-99.  
GAN Jing-fu. Analysis of the Maloperation of Spare Power Automatic Switching Device[J]. Automation of Electric Power Systems,2004,28 (17): 97-99.
- [2] IEC61850-7-2:2003. IDT 变电站通信网络和系统 第7-2 部分:变电站和馈线设备的基本通信结构 抽象通信服务接口(ACSI) [S].  
IEC 61850-7-2:2003, IDT Communication Networks and Systems in Substations Part7-2:Basic Communication Structure for Substation and Feeder Equipment Abstract Communication Service Interfaces[S].
- [3] IEC61850-9-1:2003, IDT 变电站通信网络和系统 第9-1 部分:特定通信服务映射(SCSM)通过单向多路点对点串行通信链路的采样值[S].  
IEC 61850-9-1:2003. IDT Communication Networks and Systems in Substations Part9-1:Specific Communication Service Mapping(SCSM) Sampled Values over Serial Unidirectional Multidrop Point to Point Link[S].

- [4] IEC61850-9-2:2003. IDT 变电站通信网络和系统 第9-2 部分:特定通信服务映射(SCSM)通过 ISO/IEC8802-3 的采样值[S].  
IEC 61850-9-1:2003, IDT Communication Networks and Systems in Substations Part9-2:Specific Communication Service Mapping(SCSM) Sampled values over ISO/IEC 8802-3 Link[S].
- [5] 梅德冬,黄国方.符合 IEC61850 标准的分布式备自投的设计[J].电网技术,2006,30(增刊)471-475.  
MEI De-dong, HUANG Guo-fang. Design of Distributed Reserve Power Source Automatic Switching Device According IEC61850[J].Power System Technology,2006,30(S):471-475.
- [6] CBZ-8000 变电站自动化系统技术说明书[Z].2006,05 51-54.  
Technology Introduction of CBZ-8000 Substation Automation System[Z].2006,05 51-54.

收稿日期:2008-09-04

作者简介:

李海星(1963-),男,高级工程师,长期从事电力系统变电技术管理工作;E-mail:hndlwr@tom.com

王政涛(1962-),男,高级工程师,长期从事电力技术继电保护研究与技术管理工作;

王锐(1957-),女,高级工程师,长期从事继电保护技术研究与管理工。

(上接第 62 页 continued from page 62)

### 参考文献

- [1] 刘晨晖.电力系统负荷预报理论与方法[M].哈尔滨:哈尔滨工业大学出版社,1987.
- [2] 牛东晓,曹树华,赵磊,等.电力负荷预测技术及其应用[M].北京:中国电力出版社,1998.
- [3] 杨福生.小波变换的工程分析与应用[M].北京:科学出版社,1998.
- [4] 张立明.人工神经网络的模型及其应用[M].上海:复旦大学出版社,1993.
- [5] 张际先,宓霞.神经网络及其在工程中的应用[M].北京:机械工业出版社,1996.
- [6] 吴耀华.小波软阈值去噪在电压变换器选型中的应用[J].继电器,2008,36(4):47-49.  
WU Yao-hua. Application of Wavelet Soft-threshold Denoising in Voltage Converter Selection[J].Relay, 2008, 36 (4): 47-49.

- [7] 刘学琴.小波和神经网络在电力系统中长期负荷预测中的应用研究[D].西安:西安理工大学,2007.  
LIU Xue-qin. Apply Wavelet and Neural Network to Power System Mid-Long Term Load Forecasting[D]. Xi'an: Xi'an University of Technology,2007.
- [8] 吴耀华.基于 GM-GRNN 的电力系统长期负荷预测[J].继电器,2007,35(6):50-53.  
WU Yao-hua. Long Term Load Forecasting Based on GM-GRNN in Power System[J].Relay, 2007, 35 (6): 50-53.

收稿日期:2008-08-16; 修回日期:2008-11-09

作者简介:

刘学琴(1973-),女,硕士,讲师,主要从事电力系统自动化教学与研究工;E-mail:liu2291292@126.com

吴耀华(1970-),男,讲师,主要从事电力系统自动化教学与研究工。