

# 基于模式识别的风电场风速和发电功率预测

吴兴华, 周晖, 黄梅

(北京交通大学电气工程学院, 北京 100044)

**摘要:** 风电场风速预测对电力系统的交易计划和可靠运行起着非常重要的作用。根据风的形成机理、影响因素及变化规律, 提出了一种基于模式识别技术选取风速样本, 利用自适应模糊神经网络法 (ANFIS) 进行风速预测的方法, ANFIS 利用混合学习算法训练网络的前件参数和结论参数, 然后输入选取的风速样本于训练好的自适应模糊神经网络中进行风速预测。以美国夏威夷 Maui 岛 1994 年的风速数据为例, 对上述方法进行验证, 结果表明该方法具有一定的实用性。

**关键词:** 风力发电; 风速预测; 模式识别; 自适应模糊神经网络; 发电功率预测

## Wind speed and generated power forecasting based on pattern recognition in wind farm

WU Xing-hua, ZHOU Hui, HUANG Mei

(School of Electric Engineering, Beijing Jiaotong University, Beijing 100044, China)

**Abstract:** Wind speed forecasting is very important to the transaction planning and the operation reliability of power system in wind farm. According to the mechanism that the wind is formed, the influencing factor and its variation rule, a method of pattern recognition and adaptive neuron-fuzzy inference system for wind speed forecasting is presented in this paper. The hybrid algorithm is used to train the parameter of the fuzzy inference system. Inputted the related data to the trained model and anticipated wind speed is gotten. The Maui island of Hawaii is used as our case study, the predicted result shows applying this approach into practice would be valid.

**Key words:** wind power generation; wind speed forecasting; pattern recognition; adaptive neuro-fuzzy inference system; generated power forecasting

中图分类号: TM71 文献标识码: A 文章编号: 1003-4897(2008)01-0027-06

## 0 引言

从20世纪70年代发生世界性能源危机以来, 能源问题和环境问题日益突出, 作为一种清洁的可再生能源, 风力发电越来越受到人们的重视, 许多国家把发展风力发电作为改善能源结构、减少环境污染和保护生态环境的一种措施, 纳入国家发展规划。随着我国能源结构的调整, 无污染可再生的风电也日益得到政府的重视, 并制订了相关政策支持风电的发展<sup>[1,2]</sup>。

目前, 德国、西班牙、美国等西方国家对于风力发电各种课题的研究较多<sup>[3~6]</sup>, 国内主要集中在风力发电机组的变频控制、风电场规划、对电力系统的影响等方面, 而关于风电场风速预测的研究才刚刚起步, 这主要是因为风速受温度、气压等多种因素的影响, 具有很强的随机性, 要得到较精确的预测结果难度很大。电力部门关心的是风力发电

率, 其值较小时, 可以用AGC调节, 其值较大时, 就可参加电力交易计划, 以保证电力系统的稳定运行, 它可根据风速数据和风电机功率特性曲线得到, 这是进行风力发电功率预测的有效途径之一<sup>[7]</sup>。

风电场风速预测的误差主要与预测方法、预测周期以及预测地点的风速特性有关, 一般来说, 预测周期越短, 预测地点的风速变化越缓和, 预测误差就会越小; 反之, 预测误差就会越大<sup>[7]</sup>。

风电场风速预测可分为短期风速预测和中长期风速预测。准确的短期风速预测, 有利于电网调度部门调整调度计划, 同时减轻风电场对电网的不利影响, 从而有效地减少电力系统的运行成本以及旋转备用, 并且有利于在开放的电力市场环境下制定正确的电能交换计划<sup>[8]</sup>; 准确的中长期风速预测则有利于风电场的规划设计。本文主要讨论了风速的短期预测。

目前风速的预测方法主要有以下几种, 例如卡

尔曼滤波法<sup>[3]</sup>、随机时间序列法<sup>[4,8]</sup>、人工神经网络法<sup>[5]</sup>、模糊逻辑法<sup>[6]</sup>、空间相关性法<sup>[6]</sup>等。其中卡尔曼滤波法是在假定噪声的统计特性已知的情况下得出,事实上估计噪声的统计特性是比较困难的;随机时间序列法需要大量的历史数据来建模,但该方法只需知道风电场的单一风速或功率时间序列即可建立模型预测;人工神经网络法具有并行处理、分布式存储与容错性等特征,具有自学习、自组织和自适应能力,对复杂问题的求解十分有效,可用于风速预测,存在着训练速度慢等问题;单纯的模糊逻辑法用于风速预测,效果往往不佳,通常要与其它方法配合使用,如遗传算法、人工神经网络法等;空间相关性法需要考虑风电场以及与之相近几个地点的多组风速数据,运用几个地点风速之间的空间相关性,进行风速预测,它对原始数据收集量很大,但由于预测过程中考虑的因素增多,所以预测效果较好,适用于气象部门作为公共数据服务用。

通过以上讨论可知,采用时间序列预测方法对数据要求不高,用于预测的成本也低,适合于风电企业运用;考虑到风速数据的高度非线性,拟采用智能方法(ANFIS),鉴于训练样本集对预测模型外推结果影响比较大,所以采用了模式识别技术来解决这一问题,不仅提高了预测精度,还减少了训练样本,节省了计算时间。因此,提出基于模式识别的风速ANFIS预测模型,利用夏威夷Maui岛风速数据,针对提前一小时给出预测值的要求,进行了模型的验证。

## 1 风的形成、影响因素及变化规律简介

风<sup>[9,10]</sup>,就是空气的流动,在气象学上叫做气流。由于各地的空气温度、地形以及水汽含量的不同,引起地面上有些地方气压低,有些地方气压高,高压与低气压之间就产生了气压差异,这种差异在气象学上就叫做“气压差”,并且将单位距离内的气压差称为气压梯度,也就是说,气压梯度表示了单位距离内气压变化的大小,气压梯度就把空气从气压高的一边推向气压低的一边,这种推动力就是气压梯度力,在它的作用下,空气开始流动,从而形成了风。

但风并不完全是由高压一边沿气压梯度的方向吹向低压一边的,还受地球自转作用的影响,不断偏转着方向,这就是地球自转偏差。地球的自转是自西向东运行的,因此,在北半球由南向北流动的空气(南风)愈向北流动就愈向东偏离,这就使得本来是向北流动的空气(南风)偏向东北的方向流去(成为西南风),同理,北风成为东北风。

此外,风还受摩擦力的影响,一般把由地面至1000米这一层叫做“摩擦层”,风速会受到山地、树林、房屋等阻力的影响而减小,所以一般情况下,开阔水面上的风速要大于陆地上的,平原上的风速要大于山区的,乡村的风速要大于城市的,离地面越高,风受的摩擦力也越小,风速也越大。

风本身具有一定的变化规律,分为:

### 1) 风的日变化

风速随昼夜的更替而产生有规律的变化。白天气温高,夜间气温低,风速也随着气温的升降而不断变化,在近地面层,正常的风速日变化是午后最大,此后逐渐减小,到清晨最小,日出后风速又随着增强,白天风速变化较夜间快的多,在夏季和晴天的日子尤为显著。而在近地面层以上,风速的日变化恰好相反,最大值出现在夜间,最小值出现在白天。

### 2) 风的年变化

风与气压的分布紧密相关,而风速的大小则与高低气压的相对强度紧密相关。一年内的风速变化与季节有着较大的关系,在冬季,冷空气盛行,冷高压势力强大;在夏季,暖湿空气盛行,高气压势力达不到冬季那样的强大,相对弱些。在我国大部分地区,最大风速多见于春季的三、四月,而最小风速则多见于夏季的七、八月。

### 3) 风随高度的变化而变化

风速是随高度的增加而增大的。在“摩擦层”中,由于摩擦力随着高度的增加而减小,因此,一般越是在低层风速越小,越是在高层风速越大;在“摩擦层”以上,摩擦力的影响基本消失,气流速度主要取决于该高度上气压梯度大小。

经过这些定性的分析,可帮助预测员在预测模型完成后进行局部修改,这对风速的预测精度有一定帮助,从而实现预测的人机结合。

## 2 模式识别技术在风速预测中的应用

模式识别技术<sup>[11,12]</sup>在数据的处理、特征的提取等方面有一定的优越性,且在各行业中应用广泛,因此本文利用该方法进行风速数据特征信息的提取。

考虑到气象部门利用其大气监测系统,能为社会提供免费的未来日的重要气象信息,而这些信息一方面能大致决定全天的气象状况,同时对我们需要估计的全天各时点的气象参数,也是有帮助的。故采用模式识别技术,以未来日的部分气象参数作为识别矢量,对历史日进行搜索,构成训练样本集,将有利于提高预测模型的外推效果。

在下面的算例中, 本文选取了风速样本每日的局部信息作为风速模式的一个分量, 这些局部信息可由气象部门提供的免费信息中得到, 风速模式如下:

$$M(i) = (v_{\max,i}, v_{\min,i}, t_{1,i}, t_{2,i}) \quad (1)$$

式中:  $v_{\max,i}$  为  $i$  日的风速最大值;  $v_{\min,i}$  为  $i$  日的最小风速值;  $t_{1,i}$  为  $i$  日最大风速值出现的时刻;  $t_{2,i}$  为  $i$  日最小风速值出现的时刻。

确定了风速模式后, 就需要对模式的各个分量进行量化归一化, 从而为运用模式识别甄别历史风速数据奠定基础。本文采用“极差化”方法对各分量进行归一化, 公式如下:

$$x_i(j) = \frac{y_i(j) - m}{M - m} \quad (2)$$

式中:  $y_i(j)$  为分量因素;  $m, M$  为分量因素的最小值和最大值。

取临近预测日  $N$  天的风速数据作为风速预测的样本, 预测日的模式分量已知, 利用模式识别选取风速预测样本的步骤如下:

1) 从最临近预测日的历史日开始, 逆向逐日计算每个历史日与预测日的相似度值  $r_{i,j}$ ,  $i$  日和  $j$  日的模式相似度采用加权的海明距离, 公式如下:

$$r_{i,j} = r(M(i), M(j)) = 1 - \sum_{l=1}^k a_l (x_{i,l} - x_{j,l}) \quad (3)$$

且  $\left( \sum_{l=1}^k a_l = 1, l=1, 2, 3, \dots, k \right)$

式中:  $x_{i,l}, x_{j,l}$  为风速模式中的模式分量  $(v_{\max,i}, v_{\min,i}, t_{1,i}, t_{2,i})$ ;  $k$  为模式分量的个数, 这里  $k=4$ 。

2) 选取最近  $N$  天中相似度最高的  $n$  天或者相似度  $r_{i,j} > r$  ( $r$  为一定的数值, 如  $r=0.95$ ) 的  $n$  天作为预测最终的风速样本。

### 3 风速自适应模糊神经网络预测模型

自适应模糊神经网络 (ANFIS) [13~16] 在负荷预测中的应用表明其在计算速度、预测精度较其它方法有一定的提高, 因此本文选取该智能方法进行风速预测。ANFIS 是一种利用特殊结构实现模糊推理系统的神经网络, 它综合利用了模糊系统规则的可解释性和神经网络自适应学习的特点, 可以有效地解决非线性系统的建模与控制问题。

应用神经网络于模糊推理中, 神经网络的自适应和自学习能力, 使得其能有效调节隶属函数及其它权重参数, 模糊规则由人定义转为由系统的学习产生, 扩展了模糊推理系统的应用空间。ANFIS 的典型两输入如下图:

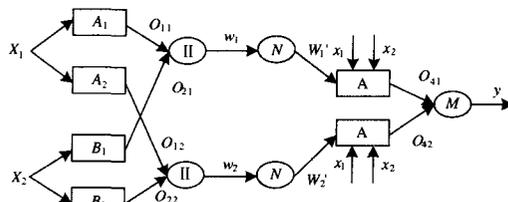


图1 ANFIS结构

Fig.1 The Structure of ANFIS

其同一层的每个节点具有相似的功能 (这里用  $O_{1,i}$  表示第一层的第  $i$  个节点的输出):

第一层: 输入参数的选择和模糊化。

$$\begin{cases} O_{1,i} = u_{A_i}(x_1), i=1, 2 \\ O_{2,i} = u_{B_i}(x_2), i=1, 2 \end{cases} \quad (4)$$

其中:  $x_i$  为节点  $i$  的输入;  $A_i$  (或  $B_i$ ) 为与该节点相关的模糊变量;  $O_{1,i}$ 、 $O_{2,i}$  分别为模糊集  $A_i$  和  $B_i$  的隶属函数。

第二层: 模糊规则激励强度的计算, 用  $\Pi$  表示, 将输入信号相乘, 而将其乘积输出。

$$O_{2,i} = \omega_i = u_{A_i}(x_1) u_{B_i}(x_2), i=1, 2 \quad (5)$$

第三层: 激励强度归一化, 用  $N$  表示。

$$O_{3,i} = \omega'_i = \frac{\omega_i}{\omega_1 + \omega_2}, i=1, 2 \quad (6)$$

第四层: 该层每个节点为自适应节点, 其输出为:

$$O_{4,i} = \omega'_i (p_i x_1 + q_i x_2 + r_i), i=1, 2 \quad (7)$$

第五层: 计算所有输入信号的总输出, 用  $M$  表示。

$$O_{5,i} = \sum_i \omega'_i f_i = \frac{\sum_i \omega_i f_i}{\sum_i \omega_i}, i=1, 2 \quad (8)$$

ANFIS 的结构是一个多层前馈网络, 各层之间的连接权值可以通过给定的样本数据来进行自适应调节, 其参数学习采用混合学习算法, 即:

在前向传递时, 输入一组历史风速数据后, 数据通过各节点函数计算网络每层各节点的输出, 然后通过线性最小二乘估计对模糊规则后件的结论参

数进行辨识, 计算每组输入数据的输出误差;

在反向传递时, 将误差用最速梯度下降法从输出节点反向传递到输入节点, 并对模糊规则的前件参数(也就是隶属度函数形状参数)进行调整, 反复循环, 直到满足误差标准或达到迭代次数为止。

相对于反向传播算法而言, 混合学习算法大大地提高了参数的训练速度。

#### 4 算例分析

采用美国夏威夷Nauai岛统计的1994年10月份的历史风速数据作为预测源数据, mauai岛是夏威夷众火山岛中的一个, 地处热带, 属海岛型气候, 终年有季风调节, 风力资源丰富, 属于海岛型风力发电场。一般在白天, 陆地温度高于海洋, 海风最强出现在13~15时, 夜里, 海洋温度高于陆地, 海风最弱一般出现在20~22时。10月23日为预测日, 由下面的图形也可以看出, 预测日风的变化符合上述规律。衡量预测结果时, 使用传统的统计学指标-百分比误差  $\delta_{APE}$  和平均百分比误差  $\delta_{MAPE}$ , 其定义如下:

$$\delta_{APE} = |x - x'| / x \times 100\% \quad (9)$$

$$\delta_{MAPE} = \frac{1}{T} \sum_{i=1}^T \frac{|x_i - x_i'|}{x_i} \quad (10)$$

其中:  $T$ 表示预测值个数;  $x_i$ 表示风速实测值;  $x_i'$ 表示风速预测值。

用Matlab实现该程序。由文献[3]可知, 风电场风速预测的误差一般在25%~40%左右。

利用模式识别技术对预测源数据进行甄别处理, 由海明距离以及历史数据的波形曲线可得出相似度最高的6天, 相似度值如表1, 6天样本的风速曲线如图2所示。

表1 相似度计算

Tab.1 Calculation of similarity degree

日期	4日	5日	6日	9日	10日	14日
相似度值	0.93	0.86	0.91	0.83	0.95	0.94

获得风速预测所需样本后, 利用自适应模糊神经网络(ANFIS)方法对风速进行预测。自适应模糊神经网络模型采用psigmf隶属度函数, 9、10、14日的训练数据输出曲线如图3所示: 折线表示实际值, 虚线表示拟合值。得到10月23日24点的风速预测值和实际值的输出拟合曲线如图4所示。

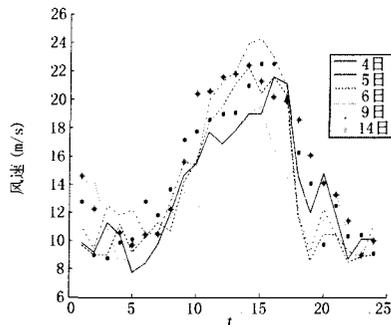


图2 风速数据曲线

Fig.2 Curve of wind speed data

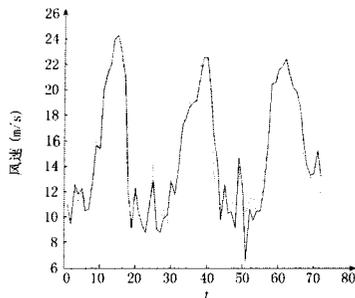
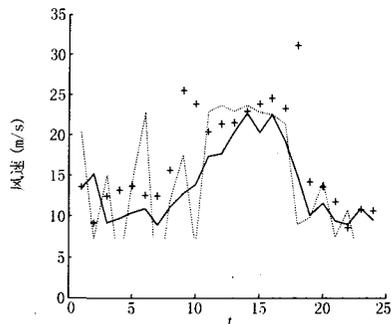


图3 训练数据输出曲线

Fig.3 Output curve of training data



其中: 折线表示实际输出; 虚线表示没有模式识别的模型输出曲线; '+'表示带有模式识别的模型输出曲线。

图4 实测与拟合的日分布

Fig.4 Observed and simulated daily distributions of wind speed

10月23日的实际风速值、带模式识别的预测风速值、百分比误差如表2所示, 预测平均百分比误差  $\delta_{MAPE}$  为29.82%, 24个点中有两个值偏离较大, 如果不将这两个异常点计算在内, 误差能达到21%, 不带模式识别的风速预测平均百分比误差  $\delta_{MAPE}$  为38.79%, 由图形和误差结果可以看出, 经过模式识别后, 风速预测精度大大提高。由于风速的影响因素很多, 随机性很强, 特别是海风, 所以预测效果

并不像负荷预测那样准确, 但误差在允许的范围之内。

其中:  $v$ 单位为m/s;  $P$ 单位为kw

表2 风速预测结果

Tab.2 Results of wind speed forecasting

预测时刻	10月23日 实际值m/s	10月23日 预测值m/s	10月23日 误差 (%)
1	13.4	13.5722	1.29
2	15.2	9.1106	40.06
3	9.2	12.3958	34.74
4	9.7	13.1139	35.19
5	10.4	13.712	31.85
6	10.9	12.4945	14.63
7	8.9	12.4762	40.18
8	11.1	15.733	41.74
9	12.7	25.6327	101.83
10	13.9	23.9134	72.04
11	17.3	20.3909	17.87
12	17.7	21.4514	21.19
13	20.3	21.5801	6.31
14	22.8	23.0171	0.95
15	20.3	23.9399	17.93
16	22.6	24.6062	8.88
17	19.3	23.4025	21.26
18	15	31.194	107.96
19	10.1	14.1308	39.91
20	11.5	13.5762	18.05
21	9.4	11.6785	24.24
22	9	8.5634	4.85
23	10.9	10.8012	0.91
24	9.5	10.6147	11.73

### 5 风力发电功率计算

上述方法得到风速预测值后, 可根据风速数据和风电机组功率特性曲线, 得到风力发电功率的预测值<sup>[7]</sup>, 这是进行风力发电功率预测的有效途径之一。具体的风力发电机型号和参数可参照有关专业资料, 图5是某风力发电机风速与功率间的转换特性曲线, 由上文预测的24点风速值可根据功率曲线和参数得到发电功率预测值如表3。

表3 发电功率预测值

Tab.3 Results of generated power forecasting

$v$	13.57	9.11	12.4	13.11	13.71
$P$	53.69	16.24	40.96	48.41	55.36
$v$	12.49	12.48	15.73	25.63	23.91
$P$	41.86	41.76	83.62	361.7	293.7
$v$	20.39	21.45	21.58	23.02	23.94
$P$	182.1	212.0	215.9	262.1	294.8
$v$	24.61	23.4	31.19	14.13	13.58
$P$	320.2	275.3	361.7	60.61	53.8
$v$	11.68	8.56	10.8	10.61	
$P$	34.23	13.48	27.06	25.66	

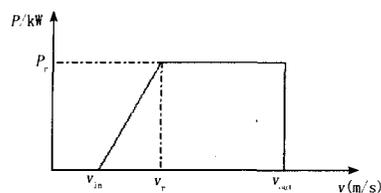


图5 风电机组功率特性曲线

Fig.5 Power curve of a wind power generator

### 6 结论

通过以上所做的工作, 可以得出以下结论:

1) 在风速预测中, 时间序列预测方法对数据要求不高, 只需知道风电场的单一风速时间序列即可, 简单可行; 考虑到风速数据的高度非线性, 采用智能方法 (ANFIS); 模式识别时应用的风速局部信息, 可由气象部门提供的免费信息中得到, 因此节省了预测成本, 适合于风电企业运用。所以本文提出了基于模式识别的风速ANFIS预测模型。

2) 采用模式识别技术对风速数据进行甄别和预处理, 筛选出某些特征相似、适于进行预测的风速样本, 作为自适应模糊神经网络的输入, 由于筛选出的这些样本相似度高, 所以对风速的预测精度有很大的帮助, 进而可以较准确的预测发电功率, 有利于电力部门做电力交易计划, 保证电力系统的运行稳定。

3) 应用美国夏威夷Maui岛的数据对上述方法进行验证, 其预测精度和计算时间是令人满意的, 该方法具有一定的经济实用性。

此外, 如果能得到与风速密切相关的各种因素的数据资料, 应用到该模型中去, 将能大大提高风速的预测精度。

### 参考文献

- [1] 杨秀媛, 梁贵书. 风力发电的发展及其市场前景[J]. 电网技术, 2003,23(7):78-79.  
YANG Xiu-yuan, LIANG Gui-shu. Development of Wind Power Generation and Its Market Prospect[J]. Power System Technology, 2003,23(7):78-79.
- [2] 王晓蓉, 王伟胜, 戴慧珠. 我国风力发电现状和展望[J]. 中国电力, 2004, 37(1):81-84.  
WANG Xiao-rong, WANG Wei-sheng, DAI Hui-zhu. Present Status and Prospect of Wind Power in China[J]. Electric Power, 2004,37(1):81-84.
- [3] Bossanyi E A. Short-term Wind Prediction Using Kalman Filters[J]. Wind Engineering, 1985,9(1): 1-8.

- [4] Torres J L,Garcia A,Blas M D,et al. Forecast of Hourly Average Wind Speed with ARMA Models in Navarre(Spain)[J].Solar Energy, 2005,79:65-77.
- [5] Barbounis T G,Theocharis J B, Alexiadis M C,et al .Long-term Wind Speed and Power Forecasting Using Local Recurrent Neural Network Models[J].Transactions on Energy Conversion, 2006,21(1):273-284.
- [6] Alexiadis M,Dokopoulos P,Sahsamanoglou H, et al.Short term Forecasting of Wind Speed and Related Electrical Power[J].Solar Energy,1998, 63(1): 61-68.
- [7] 杨秀媛,肖洋,陈树勇.风电场风速和发电功率预测研究[J].中国电机工程学报,2005, 25(11):1-5.  
YANG Xiu-yuan,XIAO Yang,CHEN Shu-yong. Wind Speed and Generated Power Forecasting in Wind Farm[J].Proceedings of CSEE, 2005, 25(11):1-5.
- [8] 吴国场,肖洋,翁莎莎.风电场短期风速预测探讨[J].吉林电力,2005, (6):21-24.  
WU Guo-yang,XIAO Yang,WENG Sha-sha. Discussion About Short-term Forecast of Wind Speed on Wind Farm[J]. Ji-lin Electric Power, 2005,(6): 21-24.
- [9] 王承煦,张源.风力发电[M].北京:中国电力出版社,2003.  
WANG Cheng-xu, ZHANG Yuan. Wind Power Generation[M].Beijing: China Electric Power Press,2003.
- [10] 陆同文,田宜泉.风[M].北京:民族出版社,1985.  
LU Tong-wen,TIAN Yi-quan.Wind[M]. Beijing: Nationalites Press,1985.
- [11] 赵凯,彭建春,石峰.基于模式识别技术的短期负荷预测[J].湖南电力,2000,20(6):1-3,12.  
ZHAO Kai,PENG Jian-chun,SHI Feng. Short-term Load Forecasting Based on Pattern Recognition[J].Hunan Electric Power, 2000,20(6):1-3,12.
- [12] 边肇祺,张学工,等.模式识别[M].北京:清华大学出版社,2000.  
BIAN Zhao-qi,ZHANG Xue-gong,et al. Pattern Recognition[M].Beijing:Tsinghua University Press,2000.
- [13] 雷绍兰,孙才新,张晓星,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 Shao-lan,SUN Cai-xin,ZHANG Xiao-xing, et al. Short-Term Load Forecasting Method Based on RBF Neural Network and ANFIS System[J].Proceedings of the CSEE, 2005, 25(22):78-82.
- [14] 张国江,邱家驹,李继红.基于模糊推理系统的多因素电力负荷预测[J].电力系统自动化,2002,26(5):49-53.  
ZHANG Guo-jiang,QIU Jia-ju,LI Ji-hong. Multi-Factor Short-Term Load Forecasting Based on Fuzzy Inference System[J]. Automation of Electric Power Systems, 2002,26(5):49-53.
- [15] 高山,单渊达.神经网络短期负荷预测输入变量选择新方法[J].电力系统自动化,2001, 25(22):41-44.  
GAO Shan,SHAN Yuan-da.Novel Input Variable Selection for ANN Short-Term Load Forecasting[J]. Automation of Electric Power Systems, 2001,25(22):41-44.
- [16] 楼顺天,胡昌华,张伟.基于MATLAB的系统分析与设计-模糊系统[M].西安:西安电子科技大学出版社,2001.  
LOU Shun-tian, HU Chang-hua, ZHANG Wei. The Analysis and Design of Fuzzy System Based on Matlab[M]. Xi'an: Xidian University Press, 2001.

收稿日期:2007-05-28; 修回日期:2007-08-17

作者简介:

吴兴华(1982-),男,硕士研究生,研究方向为电力市场运营,电价预测,分散发电;E-mail:dqwuxh@163.com

周晖(1964-),女,副教授,硕士生导师,研究方向为负荷预测、电力市场、电力规划等;

黄梅(1959-),女,研究员,硕士生导师,研究方向为电力系统建模仿真及控制保护、新能源发电。

(上接第11页 continued from page 11)

- [2] 苗睿锋.USB接口芯片FT245AM的原理[J].国外电子元器件,2004,(4).
- [3] 贺家李,宋从矩.电力系统继电保护原理[M].北京:水利电力出版社,1985.

作者简介:

李磊(1979-),男,本科,助理工程师,从事铁道继电保护方面的研究;E-mail:lilei@swjtu-xj.com

张亮(1980-),男,本科,助理工程师,从事铁道继电保护方面的研究;

张相志(1979-),男,本科,助理工程师,从事铁道继电保护方面的研究。

收稿日期:2007-06-18; 修回日期:2007-08-29