

短期负荷预测的样本动态组织方法

程松^{1,2}, 周文华³, 赵登福¹, 郭志红⁴

(1. 西安交通大学电气工程学院, 710049, 西安; 2. 西北电网有限公司, 710048, 西安; 3. 苏州市职业大学, 215104, 江苏苏州; 4. 河南省电力公司安阳供电公司, 455000, 河南安阳)

摘要: 针对训练样本与负荷预测模型的构建及预测精度之间的强相关性,在对负荷变化规律深入研究的基础上,提出了样本动态组织理论与方法.根据负荷变化的横向与纵向特征、日期、季节特征和气象特征构建时间分类树和样本映射表,并通过对气象数据的模糊化处理进行样本初选,进而利用自组织网络(SOFM)的改进方法提取负荷水平变化趋势的特征曲线,以实现样本的动态精选.多种模型的预测结果表明,采用的由粗到精逐步细化,多层面、多角度的样本过滤机制,为预测日负荷建模提供了更加优质的历史样本,很好地抑制了不良样本对预测建模可能带来的各种干扰,有效提高了电力系统短期负荷预测精度.

关键词: 负荷预测;样本动态组织;模糊;特征曲线

中图分类号: TM715 **文献标志码:** A **文章编号:** 0253-987X(2009)04-0095-06

Dynamic Example Organization for Short-Term Load Forecasting

CHENG Song^{1,2}, ZHOU Wenhua³, ZHAO Dengfu¹, GUO Zhihong⁴

(1. School of Electrical Engineering, Xi'an Jiaotong University, Xi'an 710049, China; 2. Northwest China Grid Company Limited, Xi'an 710048, China; 3. Suzhou Vocational University, Suzhou, Jiangsu 215104, China; 4. Anyang Power Supply Company, Electric Power of Henan, Anyang, Henan 455000, China)

Abstract: For the strong correlations among training examples, load forecasting model construction and forecasting accuracy, on the basis of researching into the load changing law, the theory and corresponding method for dynamic example organization were presented. According to the horizontal and longitudinal load changing characters, date, season and weather characters, the time classification tree and example map were constructed. Then, the examples were selected preliminarily via fuzzily dealing with weather data, and the dynamic selection of examples was completed via extracting the characteristic curve of load level changing trend by the improved self-organizing feature map (SOFM). The results of several forecasting models indicate the filtration mechanism with several levels and perspectives can offer better training examples to inhibit interference from bad examples and get higher forecasting accuracy of short-term load.

Keywords: load forecasting; dynamic example organization; fuzzy; characteristic curve

要提高短期负荷预测精度,不仅需要泛化能力强的预测模型,同时还需构建模型所需训练样本的组织方式.目前对预测模型、气象映射模型的研究较多^[1-3],而对样本的组织研究较少.通常的方法是依据人工经验选择一批历史样本用于预测模型的构建,这种组织方法经常会因不良样本的引入,对建模预测造成干扰,影响了负荷预测精度的提高.本文利用负荷变化的横向与纵向特征,通过构建样本组织映射表、气象数据模糊化处理、负荷水平变化趋势的特征曲线提取 3 个层面的过滤机制进行样本动态组

织(DEO),有效提高了短期负荷预测精度.

1 样本初选

历史日负荷变化具有横、纵向特征^[4],气象因素的相关性特征以及周期性特征. 横向特征通过某一参考日之前连续多日的日平均负荷变化曲线来描述,用于刻画参考日负荷水平的变化趋势. 纵向特征则由参考日当天不同时段的负荷值描述,反映一日内的负荷变化特点. 与负荷变化相关的气象因素主要包括日最高温度、日最低温度、日降雨量等,如在低温情况下,取暖负荷增多,高温情况下空调负荷增多,整个变化曲线呈现出两边高中间低的形态. 负荷变化还具有周期性特点,包括一年中的季节性轮流更替、一周中工作日和双休日的交替变化以及按天的周期变化.

1.1 样本第一步初选

为保证样本动态组织效果,首先以日期特征进行样本筛选,即依据负荷变化受时间因素影响的特点,构建了一个时间分类树,如图 1 所示,时间分类树参数可按当地季节变化周期设置.




图 1 时间分类树

在构建时间分类树的同时,本文利用工作日与双休日、正常日与节假日之间负荷变化规律不同的特点,以及负荷变化相似程度近大远小的特点,构建了如表 1 所示的样本组织映射表.

根据时间分类树和样本映射表,可按以下步骤进行样本第一步初选:

- (1)将预测日时间信息(年-月-日)输入时间分类树,得出该预测日的日期类别;
- (2)利用预测日的日期类别查询样本组织映射表,找出相应的样本筛选规则;
- (3)根据样本初选规则初步筛选训练样本;
- (4)筛选完毕后,将所选样本对应的时间信息(年-月-日)存入初始样本数据库.

表 1 样本映射表

待预测日		样本筛选规则
正常日	工作日	①待预测日前 30 日中工作日 ②前两年相同季节工作日
	双休日	①待预测日前 30 日中双休日 ②前两年相同季节双休日
节假日	劳动节	①待预测日前 14 日样本 ②前两年劳动节样本
	国庆节	①待预测日前 14 日样本 ②前两年国庆节样本
	春节	①待预测日前 14 日样本 ②前两年春节样本

1.2 样本第二步初选

1.2.1 Fisher 算法^[5] 设 n 个样本需分成 k 类,当 n 个样本有序时,则一切可能的分法只有 $R(n,k)$ 种

$$R(n,k) = C_{n-1}^{k-1} \tag{1}$$

Fisher 算法是在计算机列举了这 $R(n,k)$ 种分法的可能结果后,利用“高类聚、低耦合”的原则选取其中最佳的部分作为选定的分类结果. 所谓“高类聚、低耦合”是指基于类内距离平方和最小、类间距离平方和最大.

定义 1 设 m 维有序样本 $\mathbf{X}_1, \mathbf{X}_2, \mathbf{X}_3, \dots, \mathbf{X}_n$, 其中 $\mathbf{X}_i = (x_{i1}, x_{i2}, x_{i3}, \dots, x_{im})$, 若某类的样本为 $\{\mathbf{X}_i, \mathbf{X}_{i+1}, \mathbf{X}_{i+2}, \dots, \mathbf{X}_j\}, i \leq j$, 其均值向量定义为

$$\begin{aligned} \bar{\mathbf{X}}_{ij} &= \frac{1}{j-i+1} \sum_{l=i}^j \mathbf{X}_l = \\ &= \frac{1}{j-i+1} \left(\sum_{l=i}^j x_{l1}, \sum_{l=i}^j x_{l2}, \sum_{l=i}^j x_{l3}, \dots, \sum_{l=i}^j x_{lm} \right)^T \end{aligned} \tag{2}$$

类内的类直径为

$$\begin{aligned} D(\mathbf{X}_i, \mathbf{X}_j) &= D(i, j) = \\ &= \sum_{l=i}^j (\mathbf{X}_l - \mathbf{X}\bar{\mathbf{X}}_{ij})^T (\mathbf{X}_l - \mathbf{X}\bar{\mathbf{X}}_{ij}) \end{aligned} \tag{3}$$

定义 2 n 个样本 $\mathbf{X}_1, \mathbf{X}_2, \mathbf{X}_3, \dots, \mathbf{X}_n$ 分成 k 类,假定某分法表示为 $P(n,k): \{\mathbf{X}_{i_1}, \mathbf{X}_{i_1+1}, \dots, \mathbf{X}_{i_2-1}\} \{\mathbf{X}_{i_2}, \mathbf{X}_{i_2+1}, \dots, \mathbf{X}_{i_3-1}\}, \dots, \{\mathbf{X}_{i_k}, \mathbf{X}_{i_k+1}, \dots, \mathbf{X}_{i_{k+1}-1}\}$, 其中 $i_1=1 < i_2 < \dots < i_k \leq n$, 可定义该种分类方法的误差函数为

$$e(P(n,k)) = \sum_{j=1}^k D(i_j, i_{j+1} - 1) \tag{4}$$

定义 3 误差函数 $\min_{1 \leq i_1 < \dots < i_k \leq n} e(P(n,k))$ 的递推公式如下

$$\min_{1 \leq i_1 < \dots < i_k \leq n} e(P(n,k)) =$$

$$\min_{k \leq j \leq n} \{ \min_{1=i_1 < \dots < i_{k-1} \leq j-1} e(P(j-1, k-1)) + D(j, n) \} \tag{5}$$

Fisher 算法的具体步骤是:

- (1)根据定义 1 计算类内直径 $D(i, j)$;
- (2)设已知的分类数为 k ,则分割点个数为 $k' = k-1$,根据定义 2 及定义 3 计算误差函数 $e(P(i, j))$;
- (3)由 $e(P(i, j))$ 矩阵,求使 $e(P(n, k))$ 达到极小的最后一个分割点号 g ,再找出使 $e(P(g-1, k-1))$ 达到极小的分割点号 g_1 ,进一步找出使 $e(P(g_1-1, k-2))$ 达到极小的分割点号 g_2 ,依此类推,最后找到最优两类分割点号 $g_{k'-1}$.

1.2.2 气象数据模糊化 以最高温度模糊化为例,本文将历史气象数据中最高温度数据最终划分成高温、中温和低温 3 个等级,用 0、1、2 表示,具体步骤如下:

- (1)将历史气象数据库中最高温度数据由低到高排序;
- (2)调用有序聚类算法对排序后最高温度序列聚类分析,找出分割点 $T_{\max 1}$ 和 $T_{\max 2}$;
- (3)依据分割点对最高温度数据进行模糊化处理,处理规则为

$$T'_{\max} = \begin{cases} 0 & T'_{\max} \leq T_{\max 1} \\ 1 & T_{\max 1} < T'_{\max} \leq T_{\max 2} \\ 2 & T'_{\max} > T_{\max 2} \end{cases}$$

按照同样方法,分别对最低温度、日降雨量数据进行有序聚类分析,找出分割点,从而可构建相应的模糊化模型.

1.2.3 样本第二步初选 模糊化处理完毕后,可得到待预测日及历史样本的模糊化气象特征向量

$$\boldsymbol{F} = [T'_{\max}, T'_{\min}, R']^T$$

式中: $T'_{\max}$ 、 $T'_{\min}$ 代表最高温度、最低温度,取值为 0~2 中某一离散值; R' 为日降雨量,取 0~3 中某一离散值.

设待预测日特征向量用 $\boldsymbol{F}_d$ 表示,初步筛选的 n 个历史样本,其特征向量表示为 $\boldsymbol{F}_i, i=1, 2, \dots, n$.

将 $\boldsymbol{F}_d$ 与 $\boldsymbol{F}_i$ 进行比较,当 $\boldsymbol{F}_i \equiv \boldsymbol{F}_d$ (列向量每个元素对应相等)时,该样本称为相似样本,并将其存入初选我们样本数据库,否则将其剔除.经过 n 次比较,最终得到一个初选样本数据库,样本数计为 N' ,其中每一样本均满足

$$\boldsymbol{F}_i \equiv \boldsymbol{F}_d \quad i = 1, 2, \dots, N' \tag{6}$$

2 样本精选

在形成初选样本数据库后,对该数据库中样本所对应的负荷水平变化趋势向量(横向特征)进行智能化自组织聚类分析^[6-7],提取隐含在初选样本数据库中的多条负荷水平变化趋势特征曲线,再通过待预测日对应的负荷水平变化趋势与多条负荷水平变化趋势进行相似性比较,找出最为相似的变化趋势特征曲线,将该特征曲线所对应的样本子集作为预测日最终建模所需要的精选样本数据库.

2.1 改进自组织网络(SOFM)

SOFM 学习时不只是对兴奋的那个神经元所对应的权进行调整,而且对其周围区域内的神经元同时进行调整.对于在该区域内的神经元可以代表的不只是一类样本,而是与该类样本比较相近的都可以在该区域得到反映.网络具有对于样本畸变、噪声容差大和网络拓朴有序性的特点,已被广泛应用于模式识别、机器学习等领域的聚类分析,本文将其应用于负荷水平变化特征曲线的提取.本文在 SOFM 学习补偿的计算中引入了模糊 C 均值聚类中模糊度与隶属度的概念,以 SOFM 对邻域内神经元权值进行修改时可能出现的死点问题,并加快了收敛速度.

SOFM 由 n 维输入层和 m 维输出层组成,网络结构如图 2 所示.




图 2 SOFM 连接图

设输入样本及单元 k 的权向量分别为 $\boldsymbol{X}_j = [x_{j1}, x_{j2}, \dots, x_{jn}]^T \quad j = 1, 2, \dots, N'$ $\boldsymbol{W}_k = [w_{k1}, w_{k2}, \dots, w_{kn}]^T \quad k = 1, 2, \dots, m$

将样本按顺序依次输入 SOFM,每输入一个样本 $\boldsymbol{X}_j$,首先寻找权向量 $\boldsymbol{W}_k$ 与 $\boldsymbol{X}_j$ 有最佳匹配的单元 i ,设各单元域值相同,则应找出两个向量 ($\boldsymbol{W}_k$ 与 $\boldsymbol{X}_j$) 间欧氏距离最小值,即求

$$i(\boldsymbol{X}_j) = \min_k \| \boldsymbol{X}_j - \boldsymbol{W}_k \| \quad k = 1, 2, \dots, m \tag{7}$$

其次应确定最佳匹配单元的邻域,此邻域随迭代次

数 t 变化,所以称邻域函数 $\Delta_i(t)$. 最后,应确定一个在 $\Delta_i(t)$ 内单元的权值修正公式,即

$$\begin{cases} \mathbf{W}_k(t+1) = \mathbf{W}_k(t) + \eta(t)[\mathbf{X}_j - \mathbf{W}_k(t)] & k \in \Delta_i(n) \\ \mathbf{W}_k(t) & \text{否则} \end{cases} \quad (8)$$

式中: $\eta(t)$ 为第 t 次迭代的学习步长.

由式(8)不难看出, SOFM 正是通过权值向量的调整达到对样本数据聚类的作用,而权向量 $\mathbf{W}_k(k=1,2,\cdots,m)$ 即为样本曲线的 m 个类中心.

本文将 FCM 中模糊度与隶属度的概念引入到 SOFM 学习步长 $\eta(t)$ 的计算,第 t 次迭代的权值修正公式为

$$\mathbf{W}_k(t+1) = \mathbf{W}_k(t) + \eta_{kj}(t)[\mathbf{X}_j - \mathbf{W}_k(t)] \quad k=1,2,\cdots,m \quad (9)$$

$\eta_{kj}(t)$ 为学习步长,计算公式为

$$\left. \begin{aligned} d_{kj}(t) &= \|\mathbf{X}_j - \mathbf{W}_k(t)\| \\ u_{kj}(t) &= \left[\sum_{i=1}^c \left(\frac{d_{kj}}{d_{ij}} \right)^{\frac{2}{m(t)-1}} \right]^{-1} \\ \eta_{kj}(t) &= (u_{kj}(t))^{m(t)} \\ m(t) &= m_0 - \frac{(m_0 - 1)t}{T} \end{aligned} \right\} \quad (10)$$

式中: $u_{kj}(t)$ 为样本 $\mathbf{X}_j$ 与权向量 $\mathbf{W}_k$ 的隶属度; T 为最大迭代次数; m_0 为迭代初始模糊度,取大于 1 的常数.

2.2 样本精选

根据初选样本数据库中的样本形成 N' 个负荷变化趋势向量,其中负荷水平变化趋势向量为某一样本待预测日前 30 日的平均负荷(向量维数 $n=30$),但不包括样本日前一日的平均负荷(因为待预测日前一日的负荷未知),设最终的趋势向量矩阵为

$$\mathbf{X} = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1n} \\ x_{21} & x_{22} & \cdots & x_{2n} \\ \vdots & \vdots & & \vdots \\ x_{N'1} & x_{N'2} & \cdots & x_{N'n} \end{bmatrix} \quad (11)$$

每一行元素代表某一样本对应的负荷水平变化趋势向量,将这 N' 个趋势量依次反复输入改进 SOFM 进行聚类分析. 设聚类数为 K ,则网络训练收敛后,提取出 K 条特征各异的负荷水平变化趋势特征曲线 $\mathbf{X}_{T1}, \mathbf{X}_{T2}, \cdots, \mathbf{X}_{TK}$. 将 N' 个样本对应的趋势向量依次重新输入训练好的 SOFM 进行样本分类,设原初选样本数据库 E 最终被划分为 K 个样本子集 $E_1, E_2, \cdots, E_K$,则各子集满足

$$\left. \begin{aligned} E_i \cap E_j &= \emptyset \quad 1 \leq i, j \leq K \\ E_1 \cup E_2 \cup \cdots \cup E_K &= E \end{aligned} \right\} \quad (12)$$

对于某一趋势向量 $\mathbf{X}_j$,网络输出向量为 $\{y_1, y_2, \cdots, y_K\}^T$,由改进 SOFM 聚类特性可知

$$y_s = \max_i \{y_i, i=1,2,\cdots,K\} \Rightarrow \mathbf{X}_j \in E_s \quad (13)$$

特征曲线提取与样本分类完毕后,计算待预测日对应的负荷水平变化趋势向量 $\mathbf{X}_d$ 与 K 条变化趋势特征曲线 $\mathbf{X}_{T1}, \mathbf{X}_{T2}, \cdots, \mathbf{X}_{TK}$ 之间的欧氏距离 $\|\mathbf{X}_d - \mathbf{X}_{Ti}\|_2, i=1,2,\cdots,K$,找出距离最小值对应的负荷变化趋势特征曲线 $\mathbf{X}_{Ti^*}$. 由此不难断定,该特征曲线所对应的样本子集 E_{i^*} 即为待预测日负荷建模所需的精选样本数据库.

3 算例分析

本文应用日平均相对误差 δ 作为各种方法预测效果判断的根据

$$\delta = \frac{1}{m} \sum_{i=1}^m \left| \frac{E_i}{Y_i} \right| = \frac{1}{m} \sum_{i=1}^m \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| \times 100\% \quad (14)$$

式中: E_i 为第 i 个预测值和实际值的绝对误差; $Y_i, \hat{Y}_i$ 分别为第 i 个实际负荷值、预测负荷值.

算例 1: 为验证改进后网络的收敛性和精选有效性,样本采用杭州 2005 年 7 月 1 日到 2007 年 6 月 30 日两年历史负荷数据及气象数据,通过时间分类树和样本映射表进行样本第一步初选,采用 Fisher 算法对气象数据进行模糊化处理,进而进行样本第二步初选. 在此基础上,分别采用 SOFM 与改进 SOFM 进行样本精选,并使用人工神经网络^[8] (ANN)方法预测杭州电网 2007 年 7 月 1 日到 7 日的负荷,网络收敛时间及预测误差对比见表 2.

表 2 SOFM 收敛时间及 ANN 预测误差比较

日期	SOFM		改进 SOFM	
	t/s	$\delta/\%$	t/s	$\delta/\%$
2007-7-1	11.028	2.171	7.387	1.874
2007-7-2	10.562	3.392	7.484	2.127
2007-7-3	11.966	3.558	7.219	3.230
2007-7-4	11.265	4.322	6.766	2.675
2007-7-5	10.969	2.406	8.719	2.044
2007-7-6	12.766	3.407	7.172	3.257
2007-7-7	13.896	4.115	6.954	3.721
平均	11.779	3.338	7.385	2.704

由表 2 可见,改进后的 SOFM 由于所有节点对应的权值向量均得到了修正,并且距离聚类中心近的节点其权值调整力度较大,距离聚类中心远的节

点其权值调整力度较小,权值调整更加符合数据实际特点,从而其收敛速度比原 SOFM 要快,而且特征曲线的提取及样本精选更加有效,降低了 ANN 方法的预测误差。

算例 2:为验证本文样本动态组织(DEO)的有效性,样本采用西安 2005 年 1 月 1 日到 2006 年 12 月 31 日两年历史负荷数据及气象数据,通过时间分类树和样本映射表进行样本第一步初选,采用 Fisher 算法对气象数据进行模糊化处理,进而进行样本第二步初选.在此基础上,采用改进 SOFM 进行样本精选,并将动态组织的样本用于 ANN^[8]与支撑向量机^[9](SVM)负荷预测模型的训练,西安 2007 年冬季 1 月 1 日到 16 日的负荷预测结果对比见表 3.

表 3 西安电网 2007 年 1 月 1 日到 16 日的
预测误差比较

日期	$\delta/\%$			
	ANN	DEOANN	SVM	DEOSVM
2007-1-1	2.108	2.063	3.657	2.231
2007-1-2	1.688	1.441	2.160	2.278
2007-1-3	2.511	1.676	2.649	3.656
2007-1-4	2.728	1.881	2.922	2.387
2007-1-5	2.335	2.114	2.854	1.464
2007-1-6	1.639	1.730	1.776	1.318
2007-1-7	2.084	2.415	2.618	1.278
2007-1-8	3.681	1.311	3.601	1.509
2007-1-9	1.963	1.034	1.865	1.527
2007-1-10	1.344	1.311	2.008	1.814
2007-1-11	4.875	2.136	5.094	1.671
2007-1-12	2.019	1.031	2.735	2.072
2007-1-13	2.092	2.516	2.216	1.668
2007-1-14	1.713	1.096	2.207	1.248
2007-1-15	1.401	1.233	1.874	1.434
2007-1-16	2.131	1.208	3.115	2.352
平均	2.269	1.637	2.709	1.869

由表 3 知,使用本文方法为 ANN 与 SVM 提供训练样本,平均相对误差得到了显著降低,预测效果优于仅使用 ANN 及 SVM 的情况.采用 ANN 和 SVM 方法进行样本动态组织后,西安电网的预测误差分别降低了 0.632%和 0.813%,可见对于夏季和冬季,由于受气象因素影响,预测精度普遍较低,而

采用本文方法对训练样本进行合理选取,则取得了很好的预测效果。

为验证本文样本组织对节假日的预测效果,采用 DEOANN 和 DEOSVM 对杭州电网 2007 年 10 月 1 日 96 点负荷进行预测,并与仅使用 ANN 及 SVM 方法预测进行对比,采用 ANN 方法进行样本组织后,误差降低了 0.882%,采用 SVM 方法误差降低了 1.269%。图 3、图 4 为使用 DEOANN、ANN、DEOSVM 及 SVM 4 种方法预测的负荷曲线与实际日负荷曲线的比较。




图 3 ANN、DEOANN 预测的负荷与实际负荷曲线比较




图 4 SVM、DEOSVM 预测的负荷与实际负荷曲线比较

由图 3、图 4 可以看出,本文方法应用于预测模型的样本组织,避免了不良样本带来的误差干扰,使得节假日的负荷预测精度同样得到了有效提高。

4 结 论

在对负荷变化规律深入研究的基础上,以负荷变化特征的普遍性结论提出了样本动态组织理论与方法,并给出了相应的算例分析.实际预测结果表明,本文采用的由粗到精逐步细化,多层面、多角度的样本过滤机制,为预测日负荷建模提供了更加优质的历史样本,很好地抑制了不良样本对预测建模

可能带来的各种干扰,有效提高了电力系统短期负荷的预测精度.

参考文献:

- [1] 牛东晓,曹树华,赵磊,等. 电力系统负荷预测技术及其应用[M]. 北京:中国电力出版社,1998.
- [2] GROSS G, GALIANA F D. Short-term load forecasting[J]. Proceedings of the IEEE, 1987, 75(12): 1537-1558.
- [3] MORI H, KOBAYASHI H. Optimal fuzzy inference for short-term load forecasting [J]. IEEE Trans on Power Systems,1996,11(1): 390-396.
- [4] 莫维仁,张伯明,孙宏斌,等. 短期负荷预测中选择相似日的探讨[J]. 清华大学学报,2004,44(1):106-109. MO Weiren, ZHANG Boming, SUN Hongbin, et al. Method to select similar days for short-term load forecasting[J]. Journal of Tsinghua University, 2004, 44(1):106-109.
- [5] 余锦华. 多元统计分析与应用[M]. 广州:中山大学出版社,2005.
- [6] 高新波. 模糊聚类分析及其应用[M]. 西安:西安电子科技大学出版社,2004.
- [7] KOHONEN T. The self-organizing map[J]. Proceedings of the IEEE, 1990,78(6):1464-1480.
- [8] 夏经德,夏道止. 带温度补偿的神经网络用于电力系统短期负荷预测[J]. 西北电力技术,2006,34(3):1-3. XIA Jingde, XIA Daozhi. Short-term load forecasting by neural network with temperature compensating [J]. Northwest China Electric Power, 2006,34(3):1-3.
- [9] 赵登福,王蒙,张讲社,等. 基于支撑向量机方法的短期负荷预测[J]. 中国电机工程学报,2002,22(4):26-30. ZHAO Dengfu, WANG Meng, ZHANG Jiangshe, et al. A support vector machine approach for short term load forecasting[J]. Proceedings of the CSEE, 2002, 22(4):26-30.

(编辑 杜秀杰)