

基于 D-S 证据理论的 相似日支持向量机短期负荷预测

李鑫滨¹, 张娟¹, 张岩², 卢志刚¹

(1. 电力电子节能与传动控制河北省重点实验室(燕山大学), 河北省 秦皇岛市 066004;
2. 河北建材职业技术学院 党委宣传部, 河北省 秦皇岛市 066004)

Short-Term Load Forecasting for Similar Days Based on Support Vector Machine and Dempster-Shafer Theory

LI Xin-bin¹, ZHANG Juan¹, ZHANG Yan², LU Zhi-gang¹

(1. Key Lab of Power Electronics for Energy Conservation and Motor Drive of Hebei Province (Yanshan University), Qinhuangdao 066004, Hebei Province, China; 2. Party Committee Propaganda, Hebei Vocational and Technical College of Building Materials, Qinhuangdao 066004, Hebei Province, China)

ABSTRACT: In view of the defects in the load forecasting based on support vector machine (SVM) such as high dimensionality of input data and long training period, an evidence fusion-based load forecasting method, in which the SVM is utilized, for similar days is proposed. During the choosing of similar days the range of average load, the shape of load curve and the difference of temperature are considered, and by means of evidence fusion the similar day, whose load is highly similar to the forecasted day, is obtained and is taken as the training data of SVM while a lot of redundant data are rejected, thus the dimensions of the input is decreased and the forecasting accuracy is improved. Applying this method to short-term load forecasting and comparing the forecasting results with those by standard SVM, it is proved that the forecasting accuracy is evidently improved.

KEY WORDS: short-term load forecasting; similar days; support vector machine (SVM); evidential theory

摘要: 针对基于支持向量机(support vector machine, SVM)的负荷预测方法存在数据输入维数大、训练时间长等缺点,提出了一种基于证据融合的相似日支持向量机预测方法。选取相似日时考虑平均负荷的大小、负荷曲线形状和温度差值,通过证据融合得到与预测日负荷高度相似的相似日,以此作为支持向量机的训练数据,剔除了大量的冗余数据,减少了输入维数,提高了预测精度。将该方法用于短期负荷预测,并与采用标准支持向量机法得到的结果进行对比,发现该方法可显著提高预测精度。

关键词: 短期负荷预测; 相似日; 支持向量机; 证据理论

0 引言

在电力市场环境下,影响负荷预测精度的因素

相对更多,如气象、经济发展、日期类型、市场对电价的预测等^[1],负荷往往呈现明显的波动性,预测难度更大。

国内外研究人员提出了很多的方法来提高预测精度和预测时间。目前,神经网络和支持向量机(support vector machine, SVM)方法应用得最广泛。神经网络方法用在负荷预测方面已经取得了很大的成果^[2-4],但如果将一组相关的或非显著相关的变量选进输入变量集,会使神经网络的训练时间加长,预测结果变差^[3]。支持向量机法能够很好地解决小样本、非线性、高维数等问题,因此在负荷预测中得到了广泛应用。文献[5]采用数据挖掘和 SVM 进行短期负荷预测,利用数据挖掘技术寻找与预测日同等气象类型的多个历史短期负荷,减少 SVM 的训练数据。文献[6]利用 EMD 的信号处理方法对原始负荷数据进行分解,得到各信号的分解值,再对其进行预测。文献[7-8]运用优化算法对 SVM 的参数进行优化,然后建立模型进行预测。经验模式分解法^[9-10]、事例推理法^[11]、混沌相空间重构法^[12]、组合预测法^[13]等均应用于短期负荷预测领域。

现有的相似日理论一般从 2 方面考虑:各种影响因素分析^[14-15]和负荷曲线的相似度^[16-17]。文献[14]运用时间序列相似搜索技术法构造相似度量对数据进行分析,找出数据间关联强度大的作为相似日。文献[15]深入分析了常见因素对负荷影响的一般规律,给出了各种影响因素的相似度函数,再

对这些相似度进行组合，以求取相似日。这 2 种方法一般不考虑负荷记录水平，仅仅根据日类型、天气状况、电价等因素(非负荷记录数据)来确定相似日，所以这种方法导致负荷水平预测存在困难^[18]。文献[16]运用混沌相空间重构法提取负荷的平衡点、准周期，找到由当前特征聚类出的各个历史相似日。文献[17]用趋势相似度和形状相似度选择相似日，选取了合适的相似日，提高了预测精度。文献[16]和[17]的方法虽然不同，但都考虑了日负荷的平均值和日负荷曲线形状，文献[17]的仿真实例更验证了这种提取相似日方法的正确性。

基于以上分析，通过对数据进行预处理，可简化支持向量机的输入，提高训练速度和精度。本文提出的证据融合相似日支持向量机方法就是先对历史负荷数据进行预处理，综合各个因素对负荷的影响，再用其进行预测。由于数据的原因，本文选用的 3 个特征量为平均负荷大小、负荷曲线形状、温度差值。实例研究结果表明，预测的精度明显高于 SVM 方法。

1 相似日理论

1.1 证据理论

1.1.1 证据 1 的识别框架及其基本信度分配

D-S 证据理论是目前信息融合中最常用的一种方法，它采用信任函数而不是概率作度量，通过对一些事件的概率加以约束，建立信任函数，不必说明精确的难以获得的概率。

某 2 日(第 i 日和第 j 日)及其附近几日的平均负荷变化曲线形状非常相似，这说明这 2 日前后几日的平均负荷变化规律很相似，故称它们及它们附近几日的平均负荷曲线形状的相似程度为这 2 日的“趋势相似度”。该“趋势相似度”量化了这 2 日及前后几日的负荷水平变化规律的相似程度。

证据 1 的识别框架为相似度和非相似度，非相似度和相似度之和为 1。证据 1 的基本信度分配，第 i, j 日的“趋势相似度”可按式计算：

$$T_{ij} = 2[E(\bar{X}_i \bar{X}_j) - E(\bar{X}_i)E(\bar{X}_j)]/[D(\bar{X}_i) + D(\bar{X}_j)] \quad (1)$$

式中： $\bar{X}_i = [\bar{x}_{i-K}, \dots, \bar{x}_{i-k}, \bar{x}_{i-1}, \bar{x}_i]$ ，其中 K 一般的取值范围为 4~7； $\bar{X}_j = [\bar{x}_{j-K}, \dots, \bar{x}_{j-k}, \bar{x}_{j-1}, \bar{x}_j]$ ； \bar{x}_i 为第 i 日的平均负荷值。

1.1.2 证据 2 的识别框架及其基本信度分配

同样，称日负荷曲线形状相似的 2 日互为“负荷曲线形状相似日”，简称“形状相似日”。这 2 日

负荷曲线形状的相似程度称为它们的“形状相似度”。证据 2 的识别框架和证据 1 类似。证据 2 的基本信度分配，第 i, j 日的“形状相似度”可按式计算：

$$S_{ij} = 2[E(X_i X_j) - E(X_i)E(X_j)]/[D(X_i) + D(X_j)] \quad (2)$$

1.1.3 证据 3 的识别框架及其基本信度分配

由于温度和负荷有一定的相关性，本文选取平均温度和预测日温度的差值作为证据 3。把所选温度的好坏分为好、中、差 3 个等级，分别记为 F, M, S ，证据 3 的识别框架的最小基本元素取为 $\{F, M, S\}$ 。

温度在一定的范围内变化时，对负荷的影响相似，因此可对温度进行分段处理：根据对人体温度的舒适度调查结果，可认为人体舒适温度区间为 15~25℃，所以温度在 15~25℃时对负荷的影响较小，可近似量化取值为 0；温度低于 15℃或高于 25℃时对负荷的影响较大。温度对应的量化取值见图 1。对温度量化后，再用其与待预测日温度取差值 t 进行信度分配。

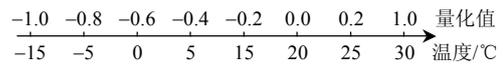


图 1 温度对应的量化取值

Fig. 1 Quantified value of the corresponding temperature

1.2 Dempster 合成法则

设 m_1 和 m_2 是同一识别框架上基于 2 个独立证据的基本信度分配，焦点元素分别为 $A_1 \sim A_k$ 和 $B_1 \sim B_k$ ， $\sum_{A_i \cap B_j = \emptyset} m_1(A_i)m_2(B_j) < 1$ ，则

$$m(A) = \begin{cases} 0, & A = \emptyset \\ \frac{1}{1-k} \sum_{A_i \cap B_j = A} m_1(A_i)m_2(B_j), & A \neq \emptyset \end{cases} \quad (3)$$

式中： $\frac{1}{1-k}$ 为规范化因子，用以避免在合成时将非空的概率赋值给空集； k 为冲突值， $k = \sum_{A_i \cap B_j = \emptyset} m_1(A_i)m_2(B_j) < 1$ ，这反映了由于证据不同产生

的冲突，若 $k \neq 1$ ，则 m 确定一个基本概率赋值，若 $k=1$ ，则认为 m_1 和 m_2 矛盾，不能对基本概率赋值进行组合。由定义得到的证据组合规则为 Dempster 组合规则。对于多个证据的组合，可用该定义对证据进行两两综合。设常数 ε 为允许的证据冲突程度，只有 $k < \varepsilon$ 时才能对证据进行合成，本文取 $\varepsilon=0.7$ 。

根据基本信度分配公式，对不同的已知日与待预测日之间的基本信度处理后，再用证据理论进行融合。本文用 1997 年 1 月—1999 年 1 月 4 日之前的数据作为原始数据选择相似日，运用 D-S 理论选

取相似日。

2 SVM 原理

SVM 用来估计回归函数，其基本思想是通过一个非线性映射，把输入空间的数据映射到一个高维空间，然后在此空间中作线性回归。对于回归预测问题，设训练样本 x_i 为输入向量， $x_i \in \mathbf{R}^n$ ， y_i 为相应的输出值， $y_i \in \mathbf{R}$ ， d_i 为期望值， $d_i \in \mathbf{R}$ ， $\{x_i, d_i\}$ 为训练数据，其中 $i=1,2,\dots,n$ ，采用如下的回归函数：

$$y = f(x) = w\varphi(x) + b \quad (4)$$

式中 $\varphi(x)$ 是从输入空间到高维特征空间的非线性映射。

系数 w 和 b 由下式来估计：

$$R(w) = \frac{c}{n} \sum_{i=1}^n L_i[d_i, w\varphi(x_i) + b] + \frac{1}{2} \|w\|^2 \quad (5)$$

式中 c 是惩罚因子，它决定着经验风险与正则化部分之间的平衡。

为寻找系数 w 和 b ，引入松弛变量 ξ_i 和 ξ_i^* ，则

$$R(w, \xi, \xi^*) = \frac{1}{2} \|w\|^2 + c \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (6)$$

$$\text{s.t.} \begin{cases} w\varphi(x_i) + b_i - d_i \leq \varepsilon + \xi_i^*, & \xi_i^* \geq 0 \\ d_i - w\varphi(x_i) - b_i \leq \varepsilon + \xi_i, & \xi_i \geq 0 \end{cases} \quad (7)$$

利用核函数的特性，运用对偶技巧，引入拉格朗日乘子 α_i 和 α_i^* ，就可把式(6)的凸优化问题简化为一个 2 次优化问题。在这种情况下，有

$$w = \sum_{i=1}^n (\alpha_i - \alpha_i^*) x_i \quad (8)$$

将式(8)带入式(6)得如下回归函数：

$$f(x) = wx + b = \sum_{i=1}^n (\alpha_i^* - \alpha_i) K(x_i, x) + b \quad (9)$$

式中： $K(\)$ 为核函数；只有少数 α_i 和 α_i^* 不为 0，这些 α_i 、 α_i^* 所对应的点就是支持向量。

显然，式(6)是一个凸规划问题，它得到的是全局最优解，这避免求解陷入局部极小。

3 基于 D-S 相似日的 SVM 预测模型

3.1 基于 D-S 相似日的 SVM 结构

采用 SVM 处理信息时，当输入信息空间维数较大时，SVM 训练时间较长，而证据理论相似日的原理是通过对电力负荷的各个特征量进行融合，对数据进行预处理，去掉数据中的冗余信息，简化输入信息的数据空间维数。

根据 SVM 和证据理论的互补性，用证据理论对原始数据进行预处理，使原数据中与预测日负荷

特征相差太远的被剔除掉，简化包含气象信息的历史数据序列的变化规律，从而使模型训练速度明显加快，预测结果更准确。

3.2 SVM 预测流程

本文用序列最小最优化(sequential minimal optimization, SMO)算法得到 α_i 、 α_i^* 和 b ，它将大规模的原始问题分解成若干小规模子问题，通过迭代求得原问题的解。图 2 为 SVM 预测流程。

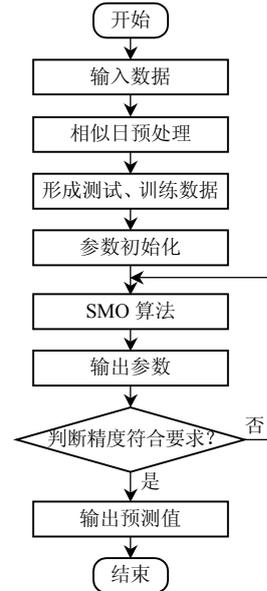


图 2 SVM 预测流程

Fig. 2 Forecasting flow chart of SVM

其具体步骤如下：

- 1) 输入历史数据，用证据理论相似日进行预处理，形成具有高度相似性的训练和测试数据集。
- 2) 初始化 SVM 的参数，将拉格朗日乘子 α_i 、 α_i^* 和 b 赋以随机的初始值。
- 3) 利用训练数据建立式(6)所示的目标函数，采用 SMO 算法求解目标函数式，得到 α_i 、 α_i^* 和 b 。
- 4) 将 α_i 、 α_i^* 和 b 代入式(9)，利用训练数据计算未来某时刻的预测值。
- 5) 计算误差函数，当误差的绝对值小于预先设定的某个正数时，结束学习过程，否则返回步骤 3)。

4 算例结果与分析

4.1 数据和样本来源

本文采用 East-Slovakia Power Distribution Company 提供的电网数据。该地区负荷变化受气象因素影响显著，季节气温变化明显，年温差较大。选取该电网 1997 年 1 月—1999 年 1 月 4 日的负荷数据为训练数据，取 1999 年 1 月 5 日后的数据为预测数据。用本文的相似日理论方法来提取和预测

日负荷曲线相似的训练数据，并以此作为 SVM 中的 y ，相应的 x 如下：预测日前 nd 同一时刻的负荷值；预测日前 nd 预测时刻前 m 个时刻的负荷值；预测日前 1 周的预测时刻的负荷值；预测日的平均温度；星期类型，其中相似日的星期类型为 1，非星期类型为 0。

4.2 参数分析

本文采用高斯核函数为核函数，即

$$K(x_i, x_j) = \exp[-1/\delta^2(x_i - x_j)^2] \quad (10)$$

式中 δ^2 是高斯核函数的宽度。

在确定的数据子空间中， c 值小，表示对经验误差的惩罚小，SVM 的复杂度小，经验风险值较大，这种现象称为“欠学习”；反之称为“过学习”。每个数据子空间至少存在 1 个合适的 c ，使 SVM 的推广性能最好。当 c 超过一定值时，SVM 的复杂度达到了数据子空间允许的最大值，经验风险和推广性能几乎不再变化。

上述结论表明，每个样本集和数据子空间都有自己的参数。通过仿真，适合本文所用样本集的参数如下： $\delta^2=0.5$ ； $c=100$ ； $\varepsilon=0.001$ 。 δ^2 和 ε 确定，标准均方差随 c 的变化关系见表 1。 c 和 ε 确定，标准均方差随 δ^2 变化关系见表 2。 c 和 δ^2 确定，标准均方差随 ε 变化关系见表 3。

表 1 标准均方差随 c 的变化关系

Tab. 1 Standard mean square error versus c

| δ^2 | ε | c | 标准均方差 |
|------------|---------------|---------|--------|
| 0.5 | 0.001 | 0 → 100 | 迅速减小 |
| 0.5 | 0.001 | 100 → ∞ | 基本维持不变 |

表 2 标准均方差随 δ^2 的变化关系

Tab. 2 Standard mean square error versus δ^2

| c | ε | δ^2 | 标准均方差 |
|-----|---------------|------------|--------|
| 100 | 0.001 | 0 → 0.5 | 基本维持不变 |
| 100 | 0.001 | 0.5 → 1 | 增大 |
| 100 | 0.001 | 1 → ∞ | 迅速增大 |

表 3 标准均方差随 ε 的变化关系

Tab. 3 Standard mean square error versus ε

| c | δ^2 | ε | 支持向量数目 | 标准均方差 |
|-----|------------|---------------|--------|-------|
| 100 | 0.5 | 0 → 0.001 | 减少 | 几乎不变 |
| 100 | 0.5 | 0.001 → ∞ | 迅速减少 | 急剧增大 |

4.3 误差测量与结果分析

用相对误差 e 为判断各方法预测结果的依据，即

$$e = (x_i - y_i) / y_i \times 100\% \quad (11)$$

式中： x_i 为 i 时刻的预测负荷值； y_i 为 i 时刻的实际负荷值。本文以 3% 作为最大允许误差(maximum permit error, MPE)，若某点的 $e > 3\%$ ，则判定该点预测结果为不合格。定义某预测日负荷预测结果的

合格率为预测误差小于 3% 的点与总预测点的比值。

为突出本文方法的优越性，选用基于 D-S 证据理论相似日支持向量机(DS-SVM)和标准支持向量机对 1999 年 1 月 5 日的 24 点负荷值进行预测，并比较预测精度，结果见表 4。

表 4 1999 年 1 月 5 日 24 h 的预测误差比较

Tab. 4 Forecasting error comparison of the 24 hour on January 5th, 1999

| 预测时刻 | $e/\%$ | | 预测时刻 | $e/\%$ | |
|----------|--------|--------|----------|--------|--------|
| | DS-SVM | SVM | | DS-SVM | SVM |
| 00:00:00 | 0.3828 | 1.7177 | 12:00:00 | 2.8689 | 4.4470 |
| 01:00:00 | 0.7242 | 4.7931 | 13:00:00 | 1.1796 | 5.4816 |
| 02:00:00 | 0.1810 | 3.2085 | 14:00:00 | 0.5858 | 4.0061 |
| 03:00:00 | 2.9902 | 2.8099 | 15:00:00 | 2.9232 | 6.5462 |
| 04:00:00 | 2.3140 | 3.6579 | 16:00:00 | 1.8059 | 3.8203 |
| 05:00:00 | 0.8356 | 5.0655 | 17:00:00 | 1.7688 | 2.8134 |
| 06:00:00 | 1.2119 | 1.1389 | 18:00:00 | 0.4144 | 4.3066 |
| 07:00:00 | 0.9268 | 1.8569 | 19:00:00 | 2.8595 | 1.5982 |
| 08:00:00 | 1.2112 | 2.6216 | 20:00:00 | 0.2845 | 4.3689 |
| 09:00:00 | 1.9504 | 5.9324 | 21:00:00 | 0.2845 | 4.8951 |
| 10:00:00 | 0.5022 | 5.7971 | 22:00:00 | 0.3357 | 1.7900 |
| 11:00:00 | 2.0677 | 4.6071 | 23:00:00 | 0.7894 | 3.3953 |

从表 4 可以看出，采用本文方法得到的预测误差比采用标准 SVM 得到的小很多。根据表 4 的数据进行计算，可知：采用本文方法得到的平均绝对误差(mean absolute percentage error, MAPE)为 1.3083%，而采用 SVM 方法得到的的 MAPE 为 3.6089%；本文方法的合格率为 100%，比 SVM 的 33.3333% 小；本文方法的均方差(mean square error, MSE)为 1.6069，比 SVM 的 4.0564 小。

图 3 是采用 DS-SVM 和 SVM 对 1999 年 1 月 5 日 24 点负荷预测后预测值与实际值的对比。从图 3 可以看出，本文方法的预测精度高、效果好，很实用。

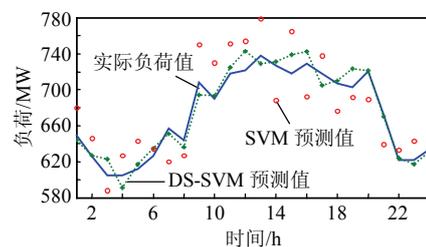


图 3 采用 2 种模型得到的日负荷预测曲线

Fig. 3 Forecasting curves of day load by two models

5 结论

1) 本文采用证据理论对原始数据进行预处理，选取形状相似度、趋势相似度和温度差值为证据理论的基本证据，找到了预测日负荷特征相似的相似日，减少了支持向量机的输入向量维数，简化了预测模型。

2) 用相似日进行预处理后, 用具有更好泛化性能和全局搜索能力的 SVM 进行预测建模, 简化了模型, 较好地解决了小样本、高维数的问题。

3) 与采用标准 SVM 方法得到的预测精度相比, 采用本文方法得到的预测精度更高, 验证了本文方法的实用性和有效性。

参考文献

- [1] 莫维仁, 张伯明, 孙宏斌, 等. 扩展短期负荷预测的原理和方法[J]. 中国电机工程学报, 2003, 23(3): 1-4.
Mo Weiren, Zhang Boming, Sun Hongbin, et al. Extended short term load forecasting principle and method[J]. Proceedings of the CSEE, 2003, 23(3): 1-4(in Chinese).
- [2] 谢开贵, 李春燕, 周家启. 基于神经网络的负荷组合预测模型研究[J]. 中国电机工程学报, 2002, 22(7): 85-89.
Xie Kaigui, Li Chunyan, Zhou Jiaqi. Research of the combination forecasting model for load based on artificial neural network[J]. Proceedings of the CSEE, 2002, 22(7): 85-89(in Chinese).
- [3] 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 Yuanda. Novel input variable selection for ANN short-term load forecasting[J]. Automation of Electric Power Systems, 2001, 25(22): 41-44(in Chinese).
- [4] 陈刚, 周杰, 张雪君, 等. 基于 BP 与 RBF 级联神经网络的日负荷预测[J]. 电网技术, 2009, 33(12): 101-105.
Chen Gang, Zhou Jie, Zhang Xuejun, et al. A daily load forecasting method based on cascaded back propagation and radial basis function neural networks[J]. Power System Technology, 2009, 33(12): 101-105(in Chinese).
- [5] 牛东晓, 谷志红, 邢棉, 等. 基于数据挖掘的 SVM 短期负荷预测方法研究[J]. 中国电机工程学报, 2006, 26(18): 6-12.
Niu Dongxiao, Gu Zhihong, Xing Mian, et al. Study on forecasting approach to short-term load of SVM based on data mining[J]. Proceedings of the CSEE, 2006, 26(18): 6-12(in Chinese).
- [6] 祝志慧, 孙云莲, 季宇. 基于 EMD 和 SVM 的短期负荷预测[J]. 高电压技术, 2007, 33(5): 118-122.
Zhu Zhihui, Sun Yunlian, Ji Yu. Short-term load forecasting based on EMD and SVM[J]. High Voltage Engineering, 2007, 33(5): 118-122(in Chinese).
- [7] Sun Wei, Zhang Jie. Short time load forecasting based on simulated annealing and genetic algorithm improved SVM[C]. The 27th Chinese Control Conference, Yunnan, China, 2008.
- [8] Wang Yongli, Niu Dongxiao, Wang Weijun. SVM model based on particle swarm optimization for short-term load forecasting[C]. Advances in Neural Networks, 5th International Symposium on Neural Networks, Beijing, China, 2008.
- [9] 牛东晓, 李媛媛, 乞建勋, 等. 基于经验模式分解与因素影响的负荷分析方法[J]. 中国电机工程学报, 2008, 28(16): 96-102.
Niu Dongxiao, Li Yuanyuan, Qi Jianxun, et al. A novel approach for load analysis based on empirical mode decomposition and influencing factors[J]. Proceedings of the CSEE, 2008, 28(16): 96-102(in Chinese).
- [10] 李媛媛, 牛东晓, 乞建勋, 等. 基于因散经验模式分解的电力负荷混合预测方法[J]. 电网技术, 2008, 32(18): 58-62.
Li Yuanyuan, Niu Dongxiao, Qi Jianxun, et al. A novel hybrid power load forecasting method based on ensemble empirical mode decomposition[J]. Power System Technology, 2008, 32(18): 58-62(in Chinese).
- [11] 贺军磊, 陈延枫. 基于事例推理原理的陕西省电网短期负荷预测[J]. 电网技术, 2008, 32(1): 131-133.
He Junsun, Chen Yanfeng. Case-based reasoning based short-term load forecasting of Shaanxi power grid[J]. Power System Technology, 2008, 32(1): 131-133(in Chinese).
- [12] 谷子, 唐巍. 电力短期负荷时间序列混沌相空间重构参数优选法[J]. 中国电机工程学报, 2006, 26(14): 18-23.
Gu Zi, Tang Wei. Parameter optimization of phase space reconstruction for short-term load time series[J]. Proceedings of the CSEE, 2006, 26(14): 18-23(in Chinese).
- [13] 吴昌友, 王福林, 董志贵, 等. 改进粒子群优化算法在电力负荷组合预测模型中的应用[J]. 电网技术, 2009, 33(2): 27-30.
Wu Changyou, Wang Fulin, Dong Zhigui, et al. Application of improved particle swarm optimization in power load combination forecasting model[J]. Power System Technology, 2009, 33(2): 27-30(in Chinese).
- [14] 李邦云, 袁贵川, 丁晓群. 基于相似搜索和加权回归技术的短期电价预测[J]. 电力自动化设备, 2004, 24(1): 42-45.
Li Bangyun, Yuan Guichuan, Ding Xiaogun. Electricity price forecasting based on similarity search & weighted regression[J]. Electric Power Automation Equipment, 2004, 24(1): 42-45(in Chinese).
- [15] 黎灿兵, 李晓辉, 赵瑞, 等. 电力短期负荷预测相似日选取算法[J]. 电力系统自动化, 2008, 32(9): 69-73.
Li Canbing, Li Xiaohui, Zhao Rui, et al. A novel algorithm of selecting similar days for short-term power load forecasting[J]. Automation of Electric Power Systems, 2008, 32(9): 69-73(in Chinese).
- [16] 杨正瓴, 田勇, 张广涛, 等. 相似日短期负荷预测的非线性理论基础与改进[J]. 电网技术, 2006, 30(6): 63-66.
Yang Zhengling, Tian Yong, Zhang Guangtao, et al. Nonlinear theoretical foundation and improvement of similar days method for short term load forecasting[J]. Power System Technology, 2006, 30(6): 63-66(in Chinese).
- [17] 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: 自然科学版, 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: Science & Technology, 2004, 44(1): 106-109(in Chinese).
- [18] 鞠平, 王俊锴, 赵夏阳. 96 点短期负荷预测方法及其应用[J]. 电力系统自动化, 2001, 25(22): 32-36.
Ju Ping, Wang Junkai, Zhao Xiayang. Ninety-six points short-term load forecasting-theory and applications[J]. Automation of Electric Power Systems, 2001, 25(22): 32-36(in Chinese).



李鑫滨

收稿日期: 2010-05-21。

作者简介:

李鑫滨(1969—), 男, 博士, 副教授, 研究方向电力系统控制、智能算法及其应用, E-mail: lixb@ysu.edu.cn;

张娟(1982—), 女, 硕士研究生, 研究方向为电力系统负荷预测, E-mail: zhangjuan2888@163.com;

张岩(1978—), 女, 硕士研究生, 研究方向计算机科学与技术;

卢志刚(1963—), 男, 博士, 教授, 博士生导师, 研究方向电力系统经济运行分析与控制, E-mail: zhglu@ysu.edu.cn。

(责任编辑 杜宁)