

DOI: 10.7667/PSPC151318

基于数据挖掘的楼宇短期负荷预测方法研究

林顺富^{1,2}, 郝朝¹, 汤晓栋³, 李东东^{1,2}, 符杨¹

(1. 上海电力学院电气工程学院, 上海 200090; 2. 上海高校高效电能应用工程研究中心, 上海 200090;
3. 上海电器科学研究所, 上海 200063)

摘要: 楼宇短期负荷预测是楼宇能效管理系统中对用能子系统进行评估诊断、优化控制以及调度规划的重要基础。针对智能楼宇参与需求响应所需高精度、实时负荷信息的要求, 提出一种基于数据挖掘支持向量机的楼宇短期负荷预测方法。选择与待预测时点相似相近的样本数据集, 采用 K -means 算法对样本数据集中的温度、湿度、气压等气象数据进行聚类, 根据聚类结果提取训练样本, 最后采用支持向量机(SVM)算法建立负荷预测模型。实际应用结果表明, 该方法预测结果平均相对误差为 1.34%, 相对误差在 1% 以内的概率达到 67.5%, 优于现有的时间序列法、同结构 SVM 法、不考虑气象因素的 DMSVM 等方法。

关键词: 楼宇能效管理; 负荷预测; 数据挖掘; 支持向量机; 聚类分析

Study of short-term load forecasting method based on data mining for buildings

LIN Shunfu^{1,2}, HAO Chao¹, TANG Xiaodong³, LI Dongdong^{1,2}, FU Yang¹

(1. College of Electrical Engineering, Shanghai University of Electric Power, Shanghai 200090, China; 2. Shanghai Higher Institution Engineering Research Center of High Efficiency Electricity Application, Shanghai 200090, China; 3. Shanghai Electrical Apparatus Research Institute, Shanghai 200063, China)

Abstract: The load forecasting is the important basis of the energy management systems for the evaluation and diagnosis, optimized control, and scheduling of the energy subsystems in buildings. In order to obtain real-time and high accuracy load information, this paper proposes a short-term load forecasting method based on data mining for buildings. It firstly finds the sample datasets that are similar to the forecasted time points from the historical data, and then performs the K -means cluster analysis on the meteorological data, such as temperature, humidity, barometric pressure, etc., and finally adopts the support vector machine (SVM) for short term forecasting. The practical application results prove that the ϵ_{MAPE} of the proposed method is 1.34%, and the probability of the relative error less than 1% is 67.5%, which are obviously better than that of the ARIMA, SVM and DMSVM without meteorological data.

This work is supported by National Natural Science Foundation of China (No. 51207088).

Key words: energy management of buildings; load forecasting; data mining; support vector machine; cluster analysis

0 引言

楼宇建筑能耗约占全球总能源消耗的 40%, 是温室气体排放的重要来源之一。我国楼宇耗电量约占全国城镇总耗电量的 27%, 95% 以上建筑属于高耗能建筑, 单位建筑能耗是发达国家的 1.5~2 倍^[1]。随着我国经济发展和产业结构调整, 楼宇建筑能耗比重将继续上升。为了应对能源危机和环境恶化,

楼宇建筑的节能工作及能效管理受到政府以及学界的重要关注^[2]。楼宇负荷预测是楼宇能效管理系统对建筑内的各个用能子系统进行评估诊断、优化控制用电以及调度规划的重要基础。结合精确的负荷预测, 可以分析用户曲线高峰以及可控负荷的节能潜力, 并为制定基于需求响应的柔性负荷控制机制提供支撑。

目前常用的负荷预测方法有时间序列法、灰色预测法、BP 神经网络以及组合预测法等。时间序列法、灰色预测法等方法在面对办公楼宇非线性、周期性的负荷特点时预测难度较大^[3]。此外, 楼宇负荷受诸多随机因素尤其是气象因素的直接干扰, 要排除这些干扰因素或者将其考虑到负荷预测模型中

基金项目: 上海市科委科创项目 (14DZ1201602); 国家自然科学基金项目 (51207088); 上海绿色能源并网工程技术研究中心 (13DZ2251900); 国网公司科技项目 (SGRI-DL-71-14-004)

是提高负荷预测精度的常用方法^[4-8]。人工智能预测法可以胜任考虑多因素的预测工作，但是训练这些大量的非线性影响因素数据，不仅导致训练速度降低，非有效样本的输入会大大降低训练的精度。数据挖掘可以提取海量数据中相似相近样本，将智能预测法与数据挖掘技术联合，可以极大地降低非有效训练样本的输入，提高训练速度和精度^[9-12]。

文献[13]提出了一种提高负荷预测精度的方法，通过对历史数据的预处理方式进行改进，得到较高的预测精度。文献[14]联合聚类分析和神经网络预测法并应用到商业办公区的负荷预测，比时间序列法(ARIMA)预测精度提高 50%。文献[15]将自回归小波神经网络负荷预测方法应用于微网的楼宇建筑中，考虑了微电网负荷时间序列的波动性和不光滑的特点，并且通过增加日期类型影响因素来提高负荷预测精度。文献[16]采用混沌时间序列法对微网中居民小区负荷进行预测，但混沌理论不适于周期性负荷预测中。

本文针对智能楼宇负荷特点结合实时气象数据提出一种 DMSVM 负荷预测方法，首先选择待预测整时点的相似相近历史数据；然后采用数据挖掘中 *K-means* 聚类算法对待预测整时点的气象因素聚类，根据聚类结果提取与待预测整时点同类的历史负荷数据；最后选择支持向量机建立负荷预测模型。将本方法应用到上海某办公楼宇证明本文 DMSVM 方法预测精度更高。

1 DMSVM 负荷预测流程

采用联合聚类分析和支持向量机的负荷预测方法，通过提取历史数据集中相关负荷数据，并考虑气象因素进行负荷预测，可以充分发挥聚类分析和支持向量机各自的优势，实现高精度快速度负荷预测^[17-19]。在进行负荷预测前首先要进行数据预处理，针对待预测时点，收集相关预测影响因素的数据，如气温、气压、湿度等，组成如下的历史数据集记录：

整点时刻 负荷 气温 气压 湿度 …

基于数据挖掘的负荷预测方法流程如图 1 所示，主要分为以下几个步骤：

1) 对预处理后的数据记录，按照预测的相似相近原则，选择与待预测点相关的历史负荷数据，组成待预测点的聚类输入样本集；

2) 对上述得到的数据集中的气象因素(气温、气压、湿度)进行聚类分析，根据聚类结果选择与待预测点的气象因素同类的历史数据集作为训练样本数据集；

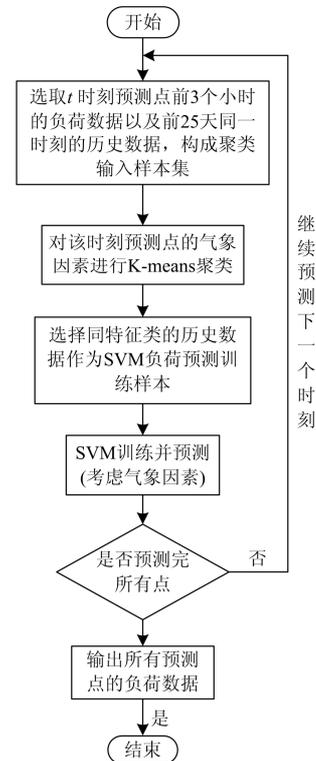


图 1 负荷预测流程图

Fig. 1 Flowchart of load forecasting

3) 对上述得到的数据集运用 SVM 算法进行训练并预测。

2 关键技术

2.1 聚类分析

K-means 算法是一种基于原型的、划分的动态聚类技术，通过计算两个对象间欧氏距离来评价相似度，即距离越近其相似度越高^[20]。本文对历史数据集中整时点的温度、湿度、气压等气象因素进行聚类，其目标是：类内的气象数据相互之间是相似相近的，而不同类间的气象数据是差异较大的。同类内的相似性越大，类间的差别越大，聚类效果就越好^[21-23]。具体步骤如下：

1) 对于给定的一个包含 n 个 d 维数据点的数据集 $X = \{x_1, x_2, \dots, x_i, \dots, x_n\}$ ，其中 $x_i \in R^d$ ，选择数据集中 K 个点作为初始聚类中心，每个对象代表一个类别的中心 $\mu_k (k=1, 2, \dots, K)$ 。

2) 计算各点到中心 μ_k 的欧氏距离，按距离最近的准则分别将它们分配给与其最相似的聚类中心代表的类，形成 K 个簇 $C = \{c_k, k=1, 2, \dots, K\}$ 。每个簇 c_k 代表一个类。计算该类各点到聚类中心 μ_k 的距离平方和 $J(c_k)$ ：

$$J(c_k) = \sum_{x_i \in C_k} \|x_i - \mu_k\|^2 \quad (1)$$

3) 计算各类样本到其所在类别聚类中心 μ_k 总的距离平方和 $J(C)$, 直至最小。

$$J(C) = \sum_{k=1}^K J(c_k) = \sum_{k=1}^K \sum_{x_i \in C_k} \|x_i - \mu_k\|^2 = \sum_{k=1}^K \sum_{i=1}^n d_{ki} \|x_i - \mu_k\|^2 \quad (2)$$

式中: 若 $x_i \in c_i$, $d_{ki}=1$; 若 $x_i \notin c_i$, $d_{ki}=0$ 。

最后计算类内所有对象的均值作为该类的新聚类中心。

4) 判断聚类中心和 $J(C)$ 值是否发生改变, 若发生改变则转步骤 2), 若不再改变则聚类结束。

2.2 支持向量机

针对楼宇负荷的非线性、日周期性等特点以及预测过程考虑气象等因素, 本文选取支持向量机算法建立负荷预测模型。支持向量机在 20 世纪 90 年代提出, 其实现结构风险最小化训练样本, 克服了神经网络经验风险最小化的局限。支持向量机的训练等价于解一个线性约束的二次规划问题, 因此存在唯一解。通过数据挖掘提取有效训练样本可提高训练速度和精度, 支持向量机被认为是替代神经网络方法的较好选择^[24-27]。支持向量机原理模型如下: 假定一组样本数据集:

$$G = \{x_i, y_i\}_{i=1}^n$$

式中: x_i 是输入向量; y_i 是相应输出; n 为数据总数。支持向量机非线性回归的核心思想是样本映射到高维特征空间, 然后在此高维特征空间进行线性回归, 回归函数为

$$f(x) = w\phi(x) + b \quad (3)$$

其函数逼近问题通过最小化下式来实现:

$$R(c) = (c/n) \sum_{i=1}^n L_\varepsilon[x_i, y_i - f(x_i)] + \|w\|^2 / 2 \quad (4)$$

$$L_\varepsilon(x, y - f(x)) = \begin{cases} 0, & |y - f(x)| \leq \varepsilon \\ |y - f(x)| - \varepsilon, & |y - f(x)| > \varepsilon \end{cases} \quad (5)$$

式中: $\|w\|^2 / 2$ 表示平滑程度; $L_\varepsilon(x, y - f(x))$ 为 Vapnik 的 ε 不敏感损失函数, 对 SVM 结构风险进行度量。

为了寻找系数 w 、 b , 引入两个松弛变量 ξ 、 ξ^* , 上式可以写成如下形式:

$$\begin{aligned} R(w, \xi, \xi^*) &= \|w\|^2 / 2 + c \sum_{i=1}^n (\xi + \xi^*) \\ \text{s.t.} & \\ w\phi(x_i) + b_i - d_i &\leq \varepsilon + \xi_i^*, \\ d_i - w\phi(x_i) - b_i &\leq \varepsilon + \xi_i, \\ \xi_i &\geq 0, \xi_i^* \geq 0, i = 1, 2, \dots, n \end{aligned} \quad (6)$$

$c(c>0)$ 是惩罚参数, 表示对误分训练实例的惩罚。引入拉格朗日乘子 β 、 β^* , 可以得到支持向量

机回归函数:

$$f(x, \beta, \beta^*) = \sum_{i=1}^n (\beta_i - \beta_i^*) K(x, x_i) + b \quad (7)$$

其中

$$b = \begin{cases} y_j - \sum_{i=1}^n (\beta_i^* - \beta_i) K(x_i, x_j) + \varepsilon, \beta_j \in (0, c) \\ y_j - \sum_{i=1}^n (\beta_i^* - \beta_i) K(x_i, x_j) - \varepsilon, \beta_j^* \in (0, c) \end{cases}$$

通过控制 c 和 ε 两个参数以及核函数可以实现支持向量机非线性回归预测。式中 $K(x, x_i)$ 称为核函数, 需要满足 Mercer 条件, 本文选取高斯核函数:

$$K(x, x_i) = \exp(-\|x - x_i\|^2 / 2\sigma^2) \quad (8)$$

3 案例分析

3.1 数据处理

本文历史负荷数据来自于上海某办公楼宇 2014 年 7 月 26 至 2014 年 8 月 31 日的整时点负荷数据, 只考虑工作日共得到 25 天的历史数据 L (取每小时 1 个点, 每日 24 点, 共 600 点), 如图 2。历史数据中还包括温度、湿度、气压等整点气象因素数据, 分别如图 3—图 5 所示。

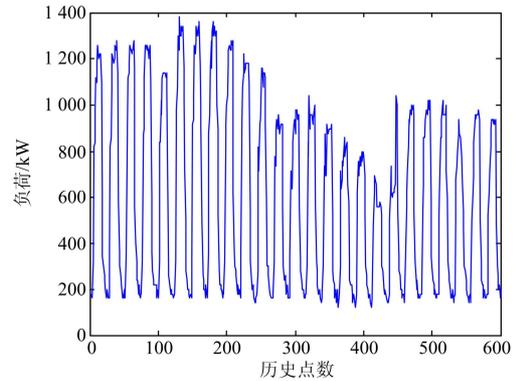


图 2 历史负荷数据集

Fig. 2 Historical data set of load

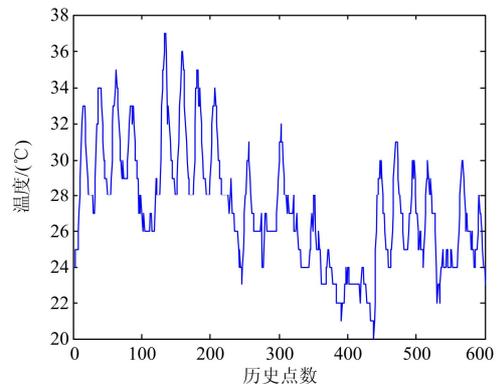


图 3 历史温度数据集

Fig. 3 Historical data set of temperature

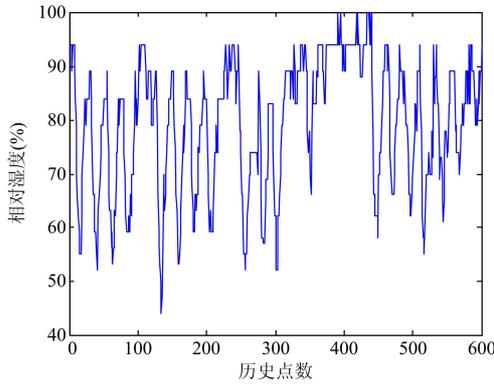


图 4 历史湿度数据集

Fig. 4 Historical data set of humidity

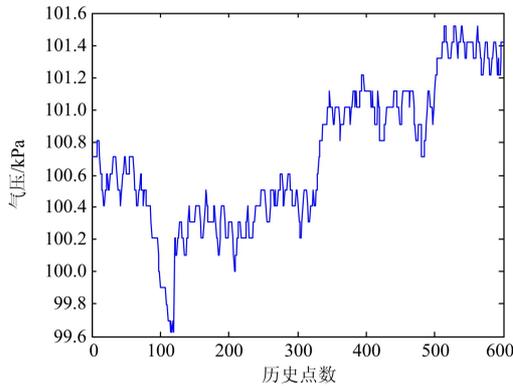


图 5 历史气压数据集

Fig. 5 Historical data set of barometric pressure

对接下来的一周 2014 年 9 月 1 日至 2014 年 9 月 5 日内各个整时点负荷进行预测。首先选取待预测时点 t 的前 3 个小时的历史数据 $L(t-i)$ 和前 25 天中与待预测时点同一时刻的历史数据 $L(t-24j)$ 作为聚类分析的样本数据集, 其中 $i=1,2,3; j=1,2,3,\dots, 25$ 。对得到的样本数据集中的气象因素数据进行聚类分析, 根据聚类结果选择与待预测时点属于同类气象因素的历史负荷作为负荷预测的训练样本数据集。

3.2 预测结果

提出的 DMSVM 预测方法, 与时间序列法 ARIMA(1,1,1)、同结构 SVM(考虑气象因素但未经过聚类分析)、不考虑气象因素 DMSVM 方法(聚类过程考虑气象因素, 在 SVM 训练时不考虑气象因素)程序均在 Matlab 平台上成功运行, 将其结果进行对比, 图 6 是 2014 年 9 月 3 日的预测结果。

表 1 是 2014 年 9 月 3 日不考虑气象因素的 DMSVM 方法和本文提出的 DMSVM 预测结果统计表, 并计算其平均相对误差:

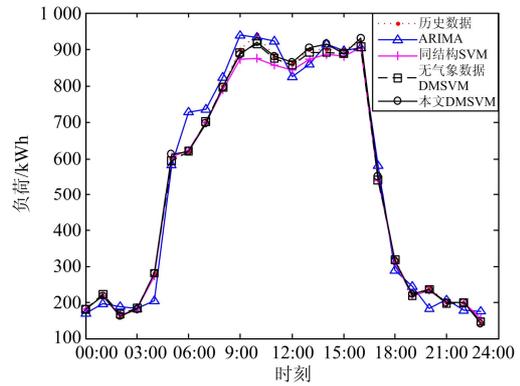


图 6 2014 年 9 月 3 日的负荷预测结果

Fig. 6 Forecasting results in Sep.3, 2014

$$e_{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{L(i) - F(i)}{L(i)} \right| \times 100\% \quad (9)$$

表 1 2014 年 9 月 3 日的负荷预测结果

Table 1 Forecasting results in Sep.3, 2014

时刻	实际 负荷/ kW	不考虑气象 DMSVM		改进 DMSVM	
		预测 负荷/kW	相对 误差	预测 负荷/kW	相对 误差
0:00	180	179.29	0.39%	179.47	0.29%
1:00	220	221.21	-0.55%	218.06	0.88%
2:00	160	165.88	-3.68%	161.91	-1.20%
3:00	180	184.08	-2.27%	180.31	-0.18%
4:00	280	280.04	-0.02%	280.02	-0.01%
5:00	600	594.49	0.92%	611.67	-1.95%
6:00	620	619.21	0.13%	620.30	-0.05%
7:00	700	702.00	-0.29%	697.31	0.38%
8:00	800	796.76	0.40%	794.88	0.64%
9:00	900	891.06	0.99%	885.71	1.59%
10:00	940	913.75	2.79%	920.79	2.04%
11:00	880	874.42	0.63%	880.07	-0.01%
12:00	860	855.46	0.53%	863.21	-0.37%
13:00	900	891.06	0.99%	903.11	-0.35%
14:00	900	890.55	1.05%	913.44	-1.49%
15:00	900	887.48	1.39%	888.67	1.26%
16:00	920	906.53	1.46%	929.84	-1.07%
17:00	540	539.95	0.01%	550.52	-1.95%
18:00	320	316.59	1.06%	315.41	1.43%
19:00	220	217.15	1.29%	223.53	-1.61%
20:00	240	234.86	2.14%	235.97	1.68%
21:00	200	196.48	1.76%	199.59	0.20%
22:00	200	197.84	1.08%	199.55	0.22%
23:00	140	146.20	-4.43%	141.03	-0.74%
e_{MAPE}			1.26%		0.90%

从表 1 结果来看, 本文中提出的 DMSVM 预测结果的平均相对误差为 0.90%, 相比不考虑气象因素的 DMSVM 降低了 0.36%; DMSVM 最大相对误差为 2.04%, 最小相对误差为 0.01%。将 9 月 1 日至 9 月 5 日的四种方法预测结果的平均相对误差落在某一范围内的频数用直方图表示, 得到了图 7—图 10 所示的四种方法的预测误差分布直方图。9 月 1 日至 9 月 5 日的预测结果平均相对误差如表 2 所示。

从图 7—图 10 的直方图中, 可以看出本文提出的改进 DMSVM 方法相对误差在 0 附近更加集中, 表 2 中时间序列法、同结构 SVM 法、不考虑气象因素 DMSVM 法预测结果相对误差控制在 1% 以内分别为 12.5%、46.7%、55.8%, 而改进 DMSVM 预测结果相对误差控制在 1% 以内概率达到 67.5%, 极端相对误差只是小概率事件。综上所述, 改进 DMSVM 在办公楼宇负荷预测中具有更低的相对误差, 预测结果整体的误差指标更好, 为下一步楼宇负荷优化运行和需求响应策略制定提供可靠依据。

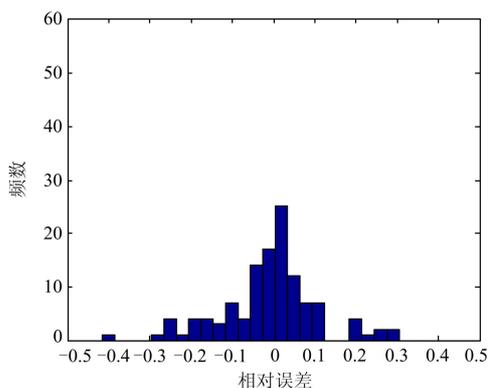


图 7 时间序列法误差分布图

Fig. 7 Distribution histogram of ARIMA

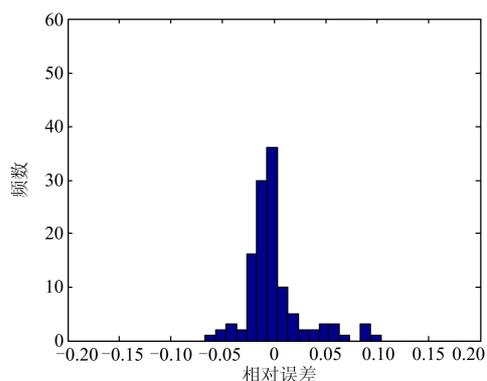


图 8 同结构 SVM 误差分布图

Fig. 8 Distribution histogram of SVM with same structure

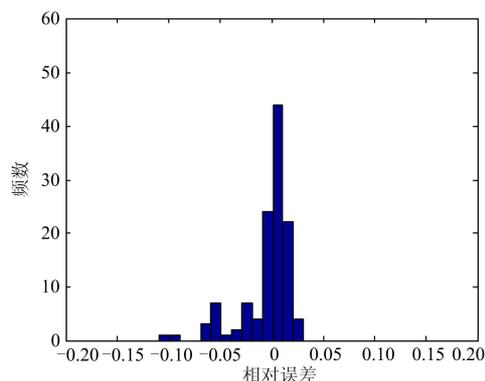


图 9 不考虑气象因素 DMSVM 误差分布图

Fig. 9 Distribution histogram of DMSVM without meteorological data

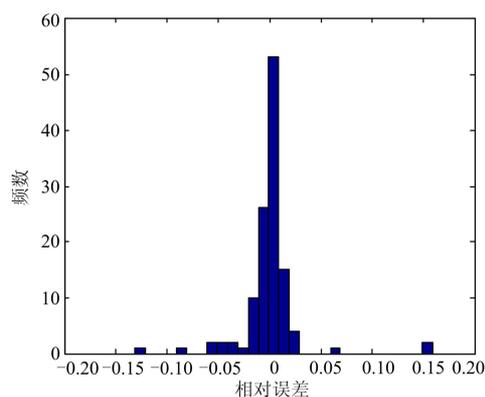


图 10 改进 DMSVM 误差分布图

Fig. 10 Distribution histogram of improved DMSVM

表 2 四种方法预测结果误差对比

Table 2 Comparison of forecasting errors among four methods

预测方法	ARIMA	同结构 SVM	不考虑气象因素 DMSVM	改进 DMSVM
平均相对误差	8.26%	1.74%	1.49%	1.34%
误差控制在 1% 内概率	12.5%	46.7%	55.8%	67.5%

4 结论

本文通过将数据挖掘技术与负荷预测技术有效联合, 针对楼宇负荷非线性、周期性的特点, 同时考虑温度、湿度、气压等气象因素, 建立了基于数据挖掘的负荷预测技术模型。并且与时间序列法、同结构 SVM、不考虑气象因素 DMSVM 法预测结果相比较, 证明了本文提出的方法整体预测指标更好, 相对误差控制在 1% 以内的概率达到 67.5%。高精度的负荷预测可为楼宇能效有效管理提供依据, 并为下一步基于需求响应的柔性负荷控制奠定基

础。当然本文还存在些不足之外：*K-means* 是一种贪心算法，容易获得局部最优而非全局最优聚类结果；提出的负荷预测模型中支持向量机算法自选参数的选取对其他应用领域的拓展还有待通过其他案例进行验证。

参考文献

- [1] LAUSTEN J. Energy efficiency requirements in building codes, energy efficiency policies for new buildings[R]. Paris, France: International Energy Agency, 2008.
- [2] 清华大学建筑节能研究中心. 中国建筑节能年度发展研究报告 2013[M]. 北京: 中国建筑工业出版社, 2013.
- [3] 廖旋焕, 胡智宏, 马莹莹, 等. 电力系统短期负荷预测方法综述[J]. 电力系统保护与控制, 2011, 39(1): 147-152.
LIAO Nihuan, HU Zhihong, MA Yingying, et al. Review of the short-term load forecasting methods of electric power system[J]. Power System Protection and Control, 2011, 39(1): 147-152.
- [4] 高赐威, 李倩玉, 苏卫华, 等. 短期负荷预测中考虑积温效应的温度修正模型研究[J]. 电工技术学报, 2015, 30(4): 242-248.
GAO Ciwei, LI Qianyu, SU Weihua, et al. Temperature correction model research considering temperature cumulative effect in short-term load forecasting[J]. Transactions of China Electrotechnical Society, 2015, 30(4): 242-248.
- [5] CHATURVEDI D K, SINHA A P, MALIK O P. Short term load forecast using fuzzy logic and wavelet transform integrated generalized neural network[J]. Electrical Power and Energy Systems, 2015, 67: 230-237.
- [6] LU Xin, DONG Zhaoyang, LI Xue. Electricity market price spike forecast with data mining techniques[J]. Electric Power Systems Research, 2005, 73(1): 19-29.
- [7] SAJJAD K, FARSHID K, SAJJAD N R. A new short-term load forecast method based on neuro-evolutionary algorithm and chaotic feature selection[J]. Electrical Power and Energy Systems, 2014, 62: 862-867.
- [8] 方鸽飞, 胡长洪, 郑奕辉, 等. 考虑夏季气象因素的短期负荷预测方法研究[J]. 电力系统保护与控制, 2010, 38(22): 100-104.
FANG Gefei, HU Changhong, ZHENG Yihui, et al. Study on the method of short-term load forecasting considering summer weather factors[J]. Power System Protection and Control, 2010, 38(22): 100-104.
- [9] 王惠中, 刘轲, 周佳. 基于综合气象指数和日期类型的电力系统负荷预测[J]. 电网与清洁能源, 2015, 31(9): 67-71.
WANG Huizhong, LIU Ke, ZHOU Jia. Power system load forecasting based on comprehensive meteorological index and date type[J]. Power System and Clean Energy, 2015, 31(9): 67-71.
- [10] 郝爽, 仲林林, 王小华, 等. 基于支持向量机的高压断路器机械状态预测算法研究[J]. 高压电器, 2015, 51(7): 155-165.
HAO Shuang, ZHONG Linlin, WANG Xiaohua, et al. Mechanical life prognosis of high voltage circuit breaker based on support vector machine[J]. High Voltage Apparatus, 2015, 51(7): 156-165.
- [11] 范山东, 赵宏宇. 基于模糊神经网络的电力负荷短期预测[J]. 电气与自动化, 2013, 41(2): 182-184.
FAN Shandong, ZHAO Hongyu. Short-term load forecast based on fuzzy neural network[J]. Electrical and Automation, 2013, 41(2): 182-184.
- [12] 荀挺, 张珂珩, 薛浩然, 等. 电网调控数据综合智能分析决策架构设计[J]. 电力系统保护与控制, 2015, 43(11): 121-127.
XUN Ting, ZHANG Keheng, XUE Haoran, et al. Framework design of the analysis decision system about the power grid data[J]. Power System Protection and Control, 2015, 43(11): 121-127.
- [13] 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.
- [14] JORJETA G J, MOSTAFA M, CHEN Weipeng. Neural network model ensembles for building-level electricity load forecasts[J]. Energy and Buildings, 2014, 84: 214-223.
- [15] HAMED C, HAMID S, HAMIDREZA Z, et al. Short-term electricity load forecasting of buildings in microgrids[J]. Energy and Buildings, 2015, 99: 50-60.
- [16] 李东东, 覃子珊, 林顺富, 等. 基于混沌时间序列法的微网短期负荷预测[J]. 电力系统及其自动化学报, 2015, 27(5): 14-18.
LI Dongdong, QIN Zishan, LIN Shunfu, et al. Short-term load forecasting for microgrid based on method of chaotic time series[J]. Proceedings of the CSU-EPSA, 2015, 27(5): 14-18.
- [17] 牛东晓, 邢棉, 孟明. 基于联合数据挖掘技术的神经网络负荷预测模型研究[J]. 电工技术学报, 2004, 19(9): 62-68.
NIU Dongxiao, XING Mian, MENG Ming. Research on

- ANN power load forecasting based on united data mining technology[J]. Transactions of China Electrotechnical Society, 2004, 19(9): 62-68.
- [18] 李霄, 王昕, 郑益慧, 等. 基于改进最小二乘支持向量机和预测误差校正的短期风电负荷预测[J]. 电力系统保护与控制, 2015, 43(11): 63-69.
- LI Xiao, WANG Xin, ZHENG Yihui, et al. Short-term wind load forecasting based on improved LSSVM and error forecasting correction[J]. Power System Protection and Control, 2015, 43(11): 63-69.
- [19] 刘巍, 黄墨, 李鹏, 等. 面向智能配电网的大数据统一支撑平台体系与构架[J]. 电工技术学报, 2014, 29(1): 486-491.
- LIU Wei, HUANG Zhao, LI Peng, et al. Summary about system and framework of unified supporting platform of big data for smart distribution grid[J]. Transactions of China Electrotechnical Society, 2014, 29(1): 486-491.
- [20] TAN Pangning, MICHAEL S, VIPIN K. 数据挖掘导论[M]. 北京: 人民邮电出版社, 2011: 202-228.
- [21] HAN Jiawei, MICHELINE K, JIAN Pei. 数据挖掘概念与技术[M]. 北京: 机械工业出版社, 2012: 132-161.
- [22] 王志勇, 郭创新, 曹一家. 基于模糊粗糙集和神经网络的短期负荷预测方法[J]. 中国电机工程学报, 2005, 25(19): 7-11.
- WANG Zhiyong, GUO Chuangxin, CAO Yijia. A method for short term load forecasting integrating fuzzy-rough set with artificial neural network[J]. Proceedings of the CSEE, 2005, 25(19): 7-11.
- [23] 崔和瑞, 彭旭. 基于 ARIMAX 模型的夏季短期电力负荷预测[J]. 电力系统保护与控制, 2015, 43(4): 108-114.
- CUI Herui, PENG Xu. Summer short-term load forecasting based on ARIMAX model[J]. Power System Protection and Control, 2015, 43(4): 108-114.
- [24] 牛东晓, 曹树华, 卢建昌, 等. 电力负荷预测技术及其应用[M]. 北京: 中国电力出版社, 2009.
- [25] 穆钢, 侯凯元, 杨右虹, 等. 负荷预报中负荷规律性评价方法的研究[J]. 中国电机工程学报, 2001, 21(10): 96-101.
- MU Gang, HOU Kaiyuan, YANG Youhong, et al. Studies on load regularity evaluating method for load forecasting[J]. Proceedings of the CSEE, 2001, 21(10): 96-101.
- [26] 李龙, 魏靖, 黎灿兵, 等. 基于人工神经网络的负荷模型预测[J]. 电工技术学报, 2015, 30(8): 225-230.
- LI Long, WEI Jing, LI Canbing, et al. Prediction of load model based on artificial neural network[J]. Transactions of China Electrotechnical Society, 2015, 30(8): 225-230.
- [27] 任志玲, 郭超, 徐丽霞. QGA-SVM 在弓网滑动电接触下的最优载荷研究[J]. 高压电器, 2015, 51(4): 133-138.
- REN Zhiling, GUO Chao, XU Lixia. Application of QGA-SVM to load optimization for pantograph-catenary system sliding electrical contact[J]. High Voltage Apparatus, 2015, 51(4): 133-138.

收稿日期: 2015-07-30; 修回日期: 2015-12-18

作者简介:

林顺富(1983-), 男, 博士, 教授, 研究方向为智能用电及用户侧技术研究; E-mail: shunfu.lin@163.com

郝朝(1990-), 男, 硕士研究生, 研究方向为智能用电及用户侧技术研究; E-mail: haochao_1990@163.com

汤晓栋(1983-), 男, 工程师, 研究方向为智能电网用户端能源管理。E-mail: tangxd@serei.com.cn

(编辑 周金梅)