

应用小波变换和支持向量机的 商业电力负荷预测

杨屹洲¹, 方瑞明¹, 黄文权¹, 梁颖¹, 汪亮²

(1. 华侨大学 信息科学与工程学院, 福建 厦门 361021;

2. 厦门埃锐圣电力科技有限公司, 福建 厦门 361002)

摘要: 提出一种基于小波分解和支持向量机相结合的模式, 将其应用于预测商业建筑电力负荷. 首先, 基于商业建筑配电系统的数据采集系统实时监测数据, 分析商业负荷用电特性, 指出商业负荷的随机特性造成单一预测模型精度难以满足要求. 其次, 提出了一种基于小波分解和粒子群支持向量机的商业电力负荷预测算法. 通过小波变换把负荷序列分解为不同频段的子序列, 再对这些子序列分别采用不同的粒子群支持向量机模型进行预测, 引入粒子群算法对支持向量机模型参数进行寻优. 最后, 将各分量预测值重构得到最终预测值. 实验结果证明: 小波分解后和粒子群支持向量机相结合的模型精度明显优于单一支持向量机模型.

关键词: 商业电力; 负荷预测; 支持向量机; 小波分解; 节能; 数据采集系统; 粒子群算法

中图分类号: TM 715

文献标志码: A

随着经济的高速发展和城市化进程的不断加快, 商业用电在能源消耗中所占比重越来越大. 对商业建筑电力负荷进行准确预测, 能够使管理者及时掌握用电情况, 灵活调整用电节能策略, 这对于提高商业建筑的用电效率和节能降耗具有十分重要的意义^[1]. 目前, 预测模型大多是依据天气和历史负荷数据对商业电力负荷进行预测^[1-5], 常用的预测模型主要有: 人工神经网络法、支持向量机法、时间序列法等. 其中支持向量机(SVM)是根据结构风险最小化准则取得最小的实际风险, 在电力负荷预测领域已取得较好的效果^[6-7]. 商业建筑配电系统安装的数据采集系统 SCADA(supervisory control and data acquisition)采集到的负荷数据表明: 商业电力负荷有明显的日、周、月、年等周期变化的特性, 包含规律性较好的低频分量; 然而受到天气等随机因素的影响, 又具有波动性较大的高频分量. 单纯使用 SVM 模型对负荷进行预测, 无法反映出众多不同规律的叠加影响, 短期规律被极大削弱、甚至消失. 而适当的小波变换能有效地分离和提取负荷不同的周期性、非线性和依赖关系, 使每个分解序列都具有较好的规律性^[8]. 因此, 本文提出了一种将小波变换和粒子群优化 SVM 相结合的组合预测模型——小波粒子群支持向量机(PSO-WSVM), 并用其对商业电力负荷进行预测.

1 小波变换

多尺度小波分解可通过 Mallat 算法实现, 即

$$c_{j+1} = Hc_j, \quad d_{j+1} = Gc_j, \quad (1)$$

式(1)中: c_j 和 d_j 分别为低通滤波器和高通滤波器输出对应信号的高频部分(细节分量)和低频部分(近似分量), $j=0, 1, \dots, J$, J 为最大分解层数.

经滤波分解会产生多于原数据点的数据序列, 因此, Mallat 算法分解后的信号, 可采用降采样的方

收稿日期: 2013-11-26

通信作者: 方瑞明(1972-), 男, 教授, 博士, 主要从事电气装置智能诊断、特种电机分析与设计的研究. E-mail: fangrm@hqu.edu.cn.

基金项目: 福建省自然科学基金资助项目(2012J01223)

法完整包含原信号的信息内容^[9].

2 支持向量回归算法

支持向量机算法应用于回归领域,先给定 i 组关系未知的样本 $(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_i, y_i)$, 其中 \mathbf{x}_i 为输入向量, y_i 为输出值. 采用的回归函数为

$$f(x) = \omega \varphi(x) + b. \tag{2}$$

$\varphi(x)$ 将 x 映射到 l 维特征空间中, 在该特征空间中进行线性回归, 回归问题转化优化问题为

$$\min_{\omega, b} \frac{1}{2} \|\omega\|^2 + C \frac{1}{l} \sum L_{\epsilon}(y_i, f(\mathbf{x}_i)). \tag{3}$$

式(3)中: 第 1 项是使函数更为平坦, 从而提高函数的泛化能力; 第 2 项为减小误差.

采用 ϵ 不灵敏惩罚函数, 常数 $C > 0$ 控制对超出误差样本的惩罚程度, 且有

$$L_{\epsilon}(y_i - f(\mathbf{x}_i), \mathbf{x}_i) = \max(|y_i - f(\mathbf{x}_i)| - \epsilon, 0). \tag{4}$$

寻找核函数 $K(\mathbf{x}_i, \mathbf{x}_j)$, 可将问题转化对偶优化问题, 即

$$\left. \begin{aligned} \min_{i=1}^N \quad & \frac{1}{2} \sum_{i,j=1}^N (a_i^* - a_i)(a_j^* - a_j) K(\mathbf{x}_i - \mathbf{x}_j) + \epsilon \sum_{i=1}^N (a_i^* - a_i) - \sum_{i=1}^N y_i (a_i^* - a_i), \\ \text{s. t.} \quad & \sum_{i=1}^N (a_i - a_i^*) = 0, \quad 0 \leq a_i - a_i^* \leq \frac{C}{N}. \end{aligned} \right\} \tag{5}$$

并求得最优解为

$$\bar{\mathbf{a}} = [\bar{a}_1, \bar{a}_1^*, \dots, \bar{a}_N, \bar{a}_N^*],$$

从而构造回归函数, 有

$$f(x) = \sum_{i=1}^N (\bar{a}_i^* - \bar{a}_i) K(x, \mathbf{x}_i) + \bar{b}, \tag{6}$$

$$\bar{b} = y_i - \sum_{j=1}^N (\bar{a}_j^* - \bar{a}_j) K(x, \mathbf{x}_i) + \epsilon. \tag{7}$$

3 预测模型

商业电力负荷预测流程图, 如图 1 所示. 预测过程为: 1) 首先将商业建筑 SCADA 系统采集的负荷序列数据进行小波分解; 2) 应用支持向量机分别针对不同的分量进行预测, 获取各分量的预测值, 流程如图 2 所示; 3) 将各分量对应的预测结果重构得到最终预测值.




图 1 商业电力负荷预测流程图

Fig. 1 WSVM load forecasting model

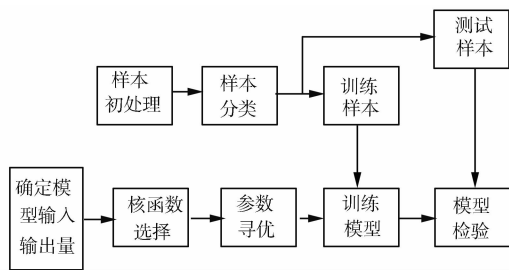


图 2 SVM 回归建模流程图

Fig. 2 Flow chart of SVM modeling

4 实例仿真

4.1 小波分解

选用了厦门某商场连续 600 h 的历史负荷数据, 采用 db3 小波基进行小波分解^[10]. 原始负荷及其分解后的各分量曲线, 如图 3 所示. 图 3 中: a_0 为原始负荷曲线, 由于商场用电高峰时段有较频繁的负荷波动, 这给预测结果准确性的提高增加了难度; a_3 为分解后序列的低频部分, 是负荷的基荷部分, a_3

曲线降低了负荷序列的非平稳性特征,具有明显的日周期性,并保持了原负荷曲线的基本形状,因此,可预测性较强;高频分量 d_2 、 d_3 具有隐含的日周期性;高频分量 d_1 数值较小,表现出较强的随机性.

4.2 各分量进行 SVM 建模

4.2.1 输入量的选择 对于商业负荷短期预测,其输入量的选择对负荷预测的精度有很大影响,而影响负荷变化的因素多种多样.参考文献[11],结合商业负荷特性进行分析,影响商业负荷变化的因素主要有:周期性变化因素、相似日因素和天气变化因素.各分量预测模型的输入量,如表 1 所示.表 1 中: $P_{LA3}(d,h)$, $P_{LD3}(d,h)$, $P_{LD2}(d,h)$, $P_{LD1}(d,h)$ 表示各分量负荷序列在第 d 天, h 时刻的负荷; T_{avg} 表示日平均气温; F 表示天气类型; D 表示日期类型.




图 3 原始负荷曲线及其小波分解分量
Fig. 3 Original load curves and its wavelet decomposition components

表 1 各分量预测模型输入量
Tab. 1 Input of each components of the forecasting models

分量	各层输入变量
A3	$P_{LA3}(d-7,h)$, $P_{LA3}(d-2,h)$, $P_{LA3}(d-1,h)$, $P_{LA3}(d-1,h-1)$, $P_{LA3}(d-7,h+1)$, $T_{avg}(d)$, $F(d)$, $D(d)$,
D3	$P_{LD3}(d-7,h)$, $P_{LD3}(d-2,h)$, $P_{LD3}(d-1,h)$, $P_{LD3}(d-1,h-1)$, $P_{LD3}(d-7,h+1)$, $T_{avg}(d)$, $F(d)$, $D(d)$
D2	$P_{LD2}(d-7,h)$, $P_{LD2}(d-2,h)$, $P_{LD2}(d-1,h)$, ..., $P_{LD2}(d-1,h-11)$
D1	$P_{LD1}(d-7,h)$, $P_{LD1}(d-2,h)$, $P_{LD1}(d-1,h)$, ..., $P_{LD1}(d-1,h-11)$

4.2.2 模型参数的选择 选择径向基函数作为 ϵ -SVR 模型的核函数^[12]. 研究中发现:惩罚系数 C 和核宽参数 σ 的选择对 SVM 回归估计的精度影响很大,PSO 对模型参数进行寻优. 粒子群算法具有分布性、自组织性、鲁棒性强等优点,已被成功地应用于函数优化、神经网络等领域^[13]. PSO 对各层 SVM 模型参数进行以下寻优步骤.

- 步骤 1 初始化得到一群随机粒子(随机解),设其种群规模为 20,最大迭代次数为 200.
- 步骤 2 通过 libsvm 调用训练数据集,使用当前解作为参数进行回归训练,使用训练精度作为其函数适应值.
- 步骤 3 通过对适应值的比较,更新个体最优值 p_{best} 和全局最优值 g_{best} .
- 步骤 4 更新粒子速度和位置为

$$v_{i+1} = \omega \cdot v_i + c_1 \cdot \text{rand} \cdot (p_{best} - x_i) + c_2 \cdot \text{rand} \cdot (g_{best} - x_i),$$

(8)

$$x_{i+1} = x_i + v_{i+1}.$$

(9)

式(8),(9)中: ω 是惯性因子; $\text{rand}()$ 代表 0 到 1 之间的随机数; x_i 是粒子位置; v_i 为粒子速度; p_{best} 和 g_{best} 是粒子群搜索到的个体最优值和全局最优值.

步骤 5 判断是否满足迭代次数,若是则停止迭代,输出最优解;若否,则转至步骤 2^[14].

使用粒子群法对各层 SVM 模型参数寻优之后,分别采用模型对预测日各层分量进行预测,最后重构. 将预测日 24 h PSO 和网格寻优结果与误差进行对比,测试结果如表 2 所示. 表 2 中: E_{MAPE} 为平均相对误差. 由表 2 可知: PSO-WSVM 的精度高于网格法 WSVM.

表 2 两种算法得到的最优参数和测试结果
Tab. 2 Optimal parameters and result of two algorithms

WSVM	A3		D3		D2		D1		$E_{MAPE}/\%$
	C	σ	C	σ	C	σ	C	σ	
PSO	100	0.503 12	1.053 6	0.010 0	0.100 00	1.752 3	8.265 2	0.010 00	4.43
网格法	4	0.125 00	9.189 6	3.031 4	0.108 82	3.031 4	0.062 5	0.031 25	4.93

4.3 预测结果分析


选取厦门市某商场 380 V 母线预测日的前 4 周,共 672 h 的历史负荷数据作为训练样本,提前预测日一日进行连续预测.表 3 为 24 h 预测误差指标.表 3 中:平均相对误差为 E_{MAPE} ;均方误差为 E_{MSE} ;最大绝对误差为 E_{MAE} .从表 3 中可以看出:PSO-WSVM 在 E_{MAPE} , E_{MSE} , E_{MAE} 上均优于其他两种模型,并能达到实际应用要求.

采用文中方法训练的预测模型,休息日和工作日的预测结果,如图 4 所示.图 4 中:9:00 至 20:00 是商场客流量较大的时间段.为了进一步探讨模型性能,同时采用 SVM 和 BP 神经网络预测模型进行对比研究.从图 4 可以看出:3 种模型都较好地跟踪了商业负荷的变化趋势,体现了 3 种预测模型的有效性,PSO-WSVM 在负荷曲线突变处和总体的预测精度好于其他方法.


表 3 3 种预测模型预测误差

Tab.3 Error comparison of the three forecasting models

预测方法	工作日			休息日		
	$E_{MAPE}/\%$	$E_{MSE}/\%$	E_{MAE}/kW	$E_{MAPE}/\%$	$E_{MSE}/\%$	E_{MAE}/kW
SVM	6.67	8.78	37.6	7.30	9.58	35.5
BP	6.94	8.81	36.9	7.74	11.10	37.3
PSO-WSVM	4.43	5.70	35.2	5.66	8.32	33.1



(a) 工作日



(b) 休息日

图 4 工作日负荷预测结果
Fig.4 Forecasting load for workday

5 结论

基于 SCADA 系统,采用小波变换和 SVM 相结合的模型对商业电力负荷预测进行了研究.利用小波变换对商业负荷序列进行分解,获得的分量规律性更强.对不同分量建立不同的 SVM 模型使负荷预测更具针对性.实验结果表明:与网格 WSVM 和直接使用 SVM 及 BP 神经网络的预测结果相比,应用文中方法得到预测精度更高,并且易于推广到其他地区和建筑.

参考文献:

[1] DONG Bing,CAO Cheng,LEE S E. Applying support vector machines to predict building energy consumption in tropical region[J]. Energy and Buildings,2005,37(5):545-553.
[2] KISSOCK J K. A methodology to measure retrofit energy savings in commercial buildings[D]. Texas:Texas A and M University,1993:32-57.
[3] DHAR A,REDDY T A,CLARIDGE D E. A fourier series model to predict hourly heating and cooling energy use in commercial buildings with outdoor temperature as the only weather variable[J]. Journal of Solar Energy Engineering,1999,121(1):47-53.

[4] DONG B,LEE S E,SAPAR M H. A holistic utility bill analysis method for baselining whole commercial building energy consumption in Singapore[J]. Energy and Building,2005,37(2):167-174.

[5] GUILLERMO E. New artificial neural network prediction method for electrical consumption forecasting based on building end-uses[J]. Energy and Building,2011,43(11):3112-3119.

[6] 方瑞明. 支持向量机理论及其应用分析[M]. 北京:中国电力出版社,2007:15-19.

[7] 曾劭炜,徐知海,吴键. 基于粒子群优化和支持向量机的电力负荷预测[J]. 微电子与计算机,2001,28(1):147-153.

[8] 王红瑞,刘晓红,唐奇,等. 基于小波变换的支持向量机水文过程预测[J]. 清华大学学报:自然科学版,2010,50(9):1378-1381.

[9] 张华,郁永静,冯志军. 基于小波分解与支持向量机的风速预测模型[J]. 水利发电学报,2012,31(1):208-212.

[10] 韩勇,李红梅. 基于小波分解的支持向量机母线负荷预测[J]. 电力自动化设备,2012,32(4):88-91.

[11] 李元诚,方廷健,郑国祥. 短期电力负荷预测的小波支持向量机方法研究[J]. 中国科学技术大学学报,2003,33(6):726-732.

[12] 梁颖,方瑞明. 基于 SCADA 和支持向量回归的风电机状态在线评估方法[J]. 电力系统自动化,2013,37(14):8-12.

[13] 付宝英,王启志. 自适应粒子群优化 BP 神经网络的变压器故障诊断[J]. 华侨大学学报:自然科学版,2013,34(3):262-266.

[14] 路志英,李艳英,陆洁,等. 粒子群算法优化 RBF-SVM 沙尘暴预报模型参数[J]. 天津大学学报:学报自然科学版,2008,41(4):413-418.

Commercial Power Load Forecasting Using
Wavelet Transform and SVM

YANG Yi-zhou¹, FANG Rui-ming¹, HUANG Wen-quan¹,
LIANG Ying¹, WANG Liang²

(1. College of Information Science and Engineering, Huaqiao University, Xiamen 361021, China;
2. Akson Power Technology Limited, Xiamen 361002, China)

Abstract: A model based on wavelet transform and support vector machine (SVM) was proposed, and which is applied to power load forecasting of commercial buildings. Firstly, this paper is based on real time monitoring data of the data acquisition system of the electrical distribution system for commercial buildings which analyzes the characteristics of commercial model load, and states the fact that the precision of single forecasting model is difficult to meet the requirement because of the random characteristic of commercial load. Secondly, a predictive algorithm for commercial power load based on wavelet transform and particle swarm optimization (PSO)-SVM is proposed through the wavelet transform decomposition of load sequence into the components of different frequencies, then a PSO-SVM model is built for each component to forecast and the PSO algorithm is used to output the optimal parameters. Finally, reconstruct the forecasting result of each component to obtain the final forecast. Experimental result shows that the wavelet PSO-SVM model is a more accurate model to predict electricity consumption than that of the model only based on SVM.

Keywords: commercial power; load forecasting; support vector machine; wavelet transform; saving energy; data acquisition system; particle swarm optimization

(责任编辑: 陈志贤 英文审校: 吴逢铁)