

基于 GA 和 SVM 的电力负荷预测方法研究

孟凡喜 屈 鸿 侯孟书

(电子科技大学计算机科学与工程学院计算智能实验室 成都 611731)

摘 要 提出一种基于支持向量机(SVM)技术和遗传算法优化技术(GA)的电力系统短期负荷预测算法。以历史数据、气象因素和日历因素等作为输入,建立预测模型,对未来1个小时的电力负荷值进行预测。该模型采用结构风险最小化原则替代传统的经验风险最小化,以充分提炼出原始数据和其它数据的一些信息,并采用遗传算法对支持向量机中的参数进行优化来提高预测模型的预测能力和训练速度,并具有良好的泛化能力。实验表明,使用上述方法进行短期电力负荷预测,具有良好的有效性和可行性,与BP网络法预测的结果相比具有更好的精度和较强的鲁棒性。

关键词 电力系统负荷预测,短期电力负荷预测,支持向量机,遗传算法优化

中图分类号 TP391 文献标识码 A

Method of Short-term Load Forecasting Based on GA and SVM

MENG Fan-xi QU Hong HOU Meng-shu

(Computing Intelligence Lab, School of Computer Science and Engineering, University of Electronic Science and Technology of China, Chengdu 611731, China)

Abstract In this paper, a method based on support vector machine and genetic algorithm was proposed for the power system load forecasting. In this method, a next hour load forecast is developed by using structure risk minimization instead of traditional empiric risk minimization to mine more information from the original data. The genetic algorithm is used to optimize the SVM parameters to improve the performance of forecasting and the training speed. Historical load, atmospheric data and the calendar factors are the model inputs. Forecasting results show that this model is effective and feasible, as well as the better robustness and forecast accuracy than the BP neural method.

Keywords Power system load forecasting, Short-term load forecasting, Support vector machine, Genetic algorithm optimization

电力负荷预测对于电力系统的建设和运行均有着极其重要的意义和作用。电力负荷预测按时间段的长短可分为短期、中期和长期电力负荷预测。短期电力负荷预测一般预测1小时到几天不等,其对电力系统的最优运行和调度有直接的影响[1]。

长期以来,人们对电力系统负荷预测进行了大量的研究,其主要方法可以分为两类,人工智能的方法和基于统计的方法。人工智能的方法是模拟人类思维,让机器像人类一样思考、学习,从而建立复杂输出与输入间的非线性关系来对输出进行预测,这类方法主要有神经网络法[2,3]、灰色理论法、模糊推理法[4]、专家系统法[5]、混沌蚁群最优化法[6]。基于统计的方法通过对历史数据的分析,归纳出负荷和相关影响因素之间的关系式,这类方法主要有基于时间序列的简单移动平均法[8]、趋势外推法、指数平滑法、单耗法、回归分析法等、卡尔曼滤波法[7]。支持向量机(SVM)是根据统计学习理论提出的一种机器学习方法,它采用的不是经验风险最小化原则,而是结构风险最小化原则。其推广泛化能力也好于一般的机器学习方法。由于支持向量机SVM的求解最后转化成二次规划问题的求解,因此SVM的解是全局唯一的最优

解。除此之外,SVM在解决小样本、非线性及高维模式识别问题中表现出许多特有的优势,其在分类和回归方面也表现出了较好的优势[9]。本文主要研究未来一个小时的负荷预测问题,针对模型参数,提出一种基于遗传算法(GA)优化的SVM的负荷预测模型。

1 支持向量机(support vector machine)

1.1 支持向量机原理

SVM是建立在小样本上理论基础的通用学习机器,它基于统计学习理论和结构风险最小化,根据有限的样本信息在模型复杂性和学习能力之间寻求最佳的折中,以获得较好的泛化能力。给定数据集 $D = \{x_i, y_i\}_{i=1}^N$, 其中 $x_i \in R^n$ 是输入向量, $y_i \in R^n$ 是输出向量。支持向量机就是将输入数据非线性地映射到一高维空间,并在高维空间上采用结构风险最小化进行线性回归,从而解决原来空间的非线性回归问题。

具体而言,其公式如下:

$$y_i = w^T \varphi(x_i) + b + e_i$$

其中, $x_i \in R^n$, $y_i \in R^n$, φ 是未知映射函数, b 是偏置, e_i 是白噪声, w^T 是权值向量。

根据统计机器学习理论, w^T 和 b 通过最小化目标函数来确定, 因此可转化为

$$\min R = \frac{1}{2} w^T w + C R_{emp}$$

$\frac{1}{2} w^T w$ 是控制模型的复杂度, C 是误差惩罚因子, R_{emp} 是误差控制函数, 即不敏感损失函数。常用的损失函数有二次损失函数、线性损失函数、Huber 损失函数等, 不同的损失函数可形成不同形式的支持向量机。标准的支持向量机是用误差 e_i 作为损失函数。此时的支持向量机可转化为目标函数:

$$J(w, b, e_i) = \frac{1}{2} w^T w + C \sum_{i=1}^n e_i$$

约束条件:

$$y_i = w^T \varphi(x_i) + b + e_i$$

这是一个带约束条件的二次规划问题, 引入朗格朗日函数:

$$L(w, b, e_i, a) = \frac{1}{2} w^T w + C \sum_{i=1}^n e_i - \sum_{i=1}^n a_i (w^T \varphi(x_i) + b + e_i - y_i)$$

其中, $a_i \in R$ 是拉格朗日算子, 对上述公式进行求偏导数, $\frac{\partial L}{\partial w}$

$$= 0, \frac{\partial L}{\partial b} = 0, \frac{\partial L}{\partial e_i} = 0, \frac{\partial L}{\partial a} = 0, \text{化简后得到 } w = \sum_{i=1}^n a_i \varphi(x_i), 0 = \sum_{i=1}^n$$

$$a_i, a_i = C e_i, y_i = w^T \varphi(x_i) + b + e_i。$$

把化简后的第一个公式带入最后一个公式得到:

$$y_i = \sum_{i=1}^N a_i \varphi(x_i)^T \varphi(x_i) + b + e_i$$

根据 Mercer 定理, 核函数 $K(x_i, x_i) = \varphi(x_i)^T \varphi(x_i)$, 其中 $K(x_i, x_i)$ 是满足 Mercer 条件的对称函数, 带入上式得:

$$y_i = \sum_{i=1}^n a_i K(x_i, x_i) + b + e_i$$

建立核矩阵方程 $\Omega_{ij} = K(x_i, x_j)$, 因此整个支持向量机可以转化为如下的线性方程组:

$$\begin{bmatrix} \Omega + \frac{1}{C} I & 1 \\ 1^T & 0 \end{bmatrix} \begin{bmatrix} a \\ b \end{bmatrix} = \begin{bmatrix} y \\ 0 \end{bmatrix}$$

其中, $a = [a_1, \dots, a_N]$ 是拉格朗日算子, $y = [y_1, \dots, y_N]$ 是输出向量, 因此支持向量机的函数估计为:

$$f(x_i) = \sum_{i=1}^N a_i K(x_i, x_i) + b$$

1.2 核函数

常见的核函数主要有以下几种:

线性核函数: $K(x, x_i) = x^T x_i$;

多项式核函数: $K(x, x_i) = (\gamma x^T x_i + r)^p, \gamma > 0$;

径向基(RBF)核函数:

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

两层感知器核函数:

$$K(x, x_i) = \tanh(\gamma x^T x_i + r)$$

由于径向基核函数具有非线性、核函数参数少、映射到的空间维数高等优点, 因此本次支持向量机的负荷预测采用的是径向基核函数。

2 遗传算法

遗传算法是一种借鉴生物界自然选择和自然遗传机制的

随机搜索算法, 其在搜索过程中自动获取和积累有关搜索空间的知识, 并自适应地控制搜索过程, 以求得最优解。它借鉴了达尔文的进化论和孟德尔的遗传学说, 其本质是一种高效、并行、全局搜索的方法^[10]。

遗传算法的一般步骤主要有编码、初始化群体、适应度评估检测、选择、交叉和变异。

3 基于 GA 和 SVM 的电力系统负荷预测方法

3.1 电力负荷预测方法总体框架

总体框架如图 1 所示。



图 1 负荷预测方法的总体框架

3.2 支持向量机回归预测模型的输入与输出

对于短期或超短期预测, 输入变量的选择至关重要。根据短期负荷预测对大量历史数据进行分析, 将短期负荷分为以下几个主要组成部分^[11,12]:

1) 气象影响分量。因为电力负荷受气象因素影响较大, 所以要加入气象分量。气象分量主要有温度(日最高温度、日最低温度、日平均温度)、湿度、风速等。

2) 典型负荷分量。典型负荷分量反映的是负荷具有周期性。当前负荷值与同一周期的同一时刻或前几时刻的负荷相关。

3) 随机负荷分量。负荷的随机性导致了负荷中的随机负荷分量, 可通过模型或算法考虑这一部分。

4) 异常或特殊事件分量。异常或特殊事件对负荷有较大的影响, 如节假日、自然灾害、拉闸限电等; 这些事件的发生往往使负荷发生较大的变化。

对于未来一个小时的负荷预测, 其主要成分与上述基本相似, 具体而言输入向量主要包括:

(1) 自回归变量。主要包括 12 个自回归变量: 预测点前一时刻的负荷值 V_{t-1} 、预测点前 2 时刻 V_{t-2} 、预测点前 3 时刻

的负荷值 V_{t-3} 、预测点前一天同一时刻的负荷值 V_{t-24} 、预测点前一天前一时刻的负荷值 V_{t-25} 、预测点前一天后一时刻 V_{t-23} 、预测点前 2 天至前 7 天同一时刻的负荷值。

(2) 气象分量。主要包括预测点时刻的实时温度。

(3) 日历因素。有 26 维的日历因素,其中 1 维标示是工作日还是休息日,1 维标示是否是节假日,余下的 24 维标示一天的 24 个小时。

这样,输入向量加起来总共有 39 维,输出向量只有一维,即所在时刻的负荷预测值。

3.3 支持向量机回归预测模型的参数

选定径向基函数后,支持向量机回归预测模型便有两个参数:误差惩罚项和核参数。它们决定了训练误差的大小和泛化能力的强弱,反映了训练样本数据的分布或范围特性。研究证明,这两个参数直接影响着回归预测模型的预测能力和算法效率,也影响着回归预测模型的鲁棒性。对于参数的选取,通常采用网格搜索法,这种方法盲目性大、效率低。而要寻求最佳的和是一个假设空间的优化搜索问题,遗传算法具有快速和全局优化的特点,因此,本文用遗传优化技术对 SVM 的模型参数进行优化选择,从而提高预测准确率。

3.4 遗传算法对模型参数寻优

用遗传算法优化支持向量机参数的主要过程如图 2 所示。




图 2 遗传算法寻优流程图

计算种群中各个个体的适应度。这里将支持向量机回归的 MSE 误差的倒数作为目标函数值,即个体的适应度,个体对应的参数的 MSE 误差的倒数越大,则该个体的适应度越大。

$$MSE(i) = \frac{1}{N} \sum_{i=1}^N \left| \frac{\text{predict}(i) - \text{true}(i)}{\text{true}(i)} \right|$$

根据个体适应度,按照一定规则(这里采用轮盘赌法)从当前种群中选出个体进入下一代。

终止条件判断。若 $t \leq T$,则转到步骤 2;若 $t > T$ 或平均适应度值变化持续小于某一常数,超过一定代数,则所得到的

具有最大适应的个体作为最优解输出,算法终止。

3.5 模型的流程图

预测模型的流程如图 3 所示。




图 3 支持向量机回归预测流程图

4 实例分析

4.1 样本的选取

样本的数据取自某城市步行街一大型购物中心两年的负荷数据(来自 EUNITE Network 竞赛数据^[13]),主要包括两年内 24 个月的负荷值、每天的实时气温和节假日等数据。在我们的方法中,采用 1—6 月份的负荷数据作为训练数据,7 月 1 日—30 日的作为测试数据,然后利用滑动窗口对 31 号 24 个小时的负荷进行预测。具体来说,先预测 1:00 的负荷值,得到真实值后,再以真实值作为输入,预测 2:00 的负荷值,以次类推。

遗传算法优化过程中的各个参数如下:交叉概率为 0.7,变异概率为 0.05,最大迭代次数为 200,群体初始规模为 100,参数 C 和 σ 的编码长度均为 10。参数 C 的变化区间为: $1 \leq C \leq 8000$,参数 σ 的变化范围为: $0.001 \leq \sigma \leq 800$ 。

4.2 误差、性能的分析

将相对误差和 MAPE 作为衡量标准,见表 1。

$$MAPE(I) = 100 \times \frac{1}{N} \sum_{i=1}^N \left| \frac{\text{predict}(i) - \text{true}(i)}{\text{true}(i)} \right|$$

根据表 1 所列,得出相应的误差图,如图 4 所示。从图中可以看出,BP 网络预测模型的相对误差大部分分布在 $-4\% \sim 4\%$,而且有两个时刻的预测误差超过了 -10% 。网格搜索法的支持向量机回归预测模型的相对误差大部分分布在 $-4\% \sim 4\%$,而且相对于 BP 网络,误差更集中一些,不过还是有两个预测时刻的误差超过 6%。而遗传算法优化的支

(下转第 117 页)

- [7] Magnusson P S, Christensson M, Eskilson J, et al. Simics: A full system simulation platform[J]. Computer, 2002, 35(2): 50-58
- [8] Dropsho S, Buyuktosunoglu A, Balasubramonian R, et al. Integrating Adaptive On-Chip Storage Structures for Reduced Dynamic Power[C]// Int. Conf. on Parallel Architectures and Compilation Techniques, 2002: 141-152
- [9] Seyedi A, Armejach A, Cristal A, et al. Novel SRAM bias control circuits for a low power L1 data cache[C]// NORCHIP, 2012: 1-6

- [10] Ahmed R E. Energy-Aware Cache Coherence Protocol for Chip-Multiprocessors[C]// Electrical and Computer Engineering, 2006: 82-85
- [11] Martin M M K, et al. Multifacet's general execution-driven multiprocessor simulator (GEMS) toolset[C]// Comput Archit News, 2005: 92-99
- [12] Merino J, Puente V, Gregorio J A. ESP-NUCA: A low-cost adaptive Non-Uniform Cache Architecture[C]// Digital Object Identifier, 2012: 1-10

(上接第 93 页)

持向量机预测模型的误差集中在 $-2\% \sim 2\%$, 只有少数几个时刻的预测误差超出了上述范围。综上所述, 可以得出, 遗传算法优化的支持向量机预测模型是一个较好的预测模型。

表 1 不同模型预测误差

时间	BP 网络	网格搜索 SVM	GA 优化 SVM
1:00	-0.04564	-0.00926	-0.00933
2:00	0.025376	-0.01128	-0.01045
3:00	-0.00481	0.068517	0.008078
4:00	0.011247	0.006784	-0.01978
5:00	0.020977	-0.01017	-0.0184
6:00	-0.10938	0.018498	0.047694
7:00	0.03598	0.016409	-0.00267
8:00	0.02058	0.063782	0.004284
9:00	0.034773	-0.01973	-0.03155
10:00	-0.02022	-0.01946	-0.01807
11:00	-0.02114	-0.02237	-0.00154
12:00	0.04302	0.014751	-0.01171
13:00	-0.03949	-0.02391	0.009531
14:00	0.041753	-0.01363	-0.00626
15:00	0.011474	0.000754	0.008032
16:00	0.0308	0.03925	0.016115
17:00	0.010898	-0.02791	0.02619
18:00	-0.01345	-0.01175	-0.00986
19:00	0.018411	-0.01082	-0.02473
20:00	-0.10802	-0.02632	-0.00862
21:00	0.017756	-0.02032	-0.00359
22:00	0.044645	-0.01133	-0.01882
23:00	-0.00808	-0.0238	-0.00015
24:00	0.058198	-0.00484	-0.02198
MAPE	79.61	49.56	33.74




图 4 不同模型相对误差分布

结束语 由于支持向量机可以将原空间的非线性问题映射到一个高维空间而转化为一个线性问题, 因此实际上它是一个二次规划问题, 所求的解是全局最优解。它在小样本、非线性的回归问题上有着较好的优势。

采用径向基核函数的支持向量机, 其误差惩罚项和核参数直接影响着回归预测模型的计算速度和泛化能力。本文提出了利用改进遗传算法来优化支持向量机的参数, 其具有收敛速度快、得到的解是所求的最优解等特点。实例证明, 用遗传算法来优化支持向量机回归预测模型, 相对于 BP 网络和网格搜索寻优, 具有较好的预测性能和稳定性、鲁棒性。

参考文献

- [1] 康重庆, 夏清, 刘楠. 电力系统负荷预测[M]. 北京: 中国电力出版社, 2007
- [2] 庞清乐. 基于粗糙集理论的神经网络预测算法及其在短期负荷预测中的应用[J]. 电网技术, 2010, 34(12): 168-173
- [3] Cai Y, Wang J Z, Tang Y, et al. An efficient approach for electric load forecasting using distributed ART (adaptive resonance theory) & HSARTMAP (hyper-spherical ARTMAP network) neural network[J]. Energy, 2011, 36
- [4] 马文晓, 白晓民, 沐连顺. 基于人工神经网络和模糊推理的短期负荷预测方法[J]. 电网技术, 2003, 27(5): 29-32
- [5] Rahman S, Bhatnagar R. An expert system based algorithm for short term load forecast[J]. IEEE Transactions on Power Systems, 1998, 3(2)
- [6] Hong W C. Application of chaotic ant swarm optimization in electric load forecasting[J]. Energy Policy, 2010, 38(10)
- [7] Al-Hamadi H M, Soliman S A. Short-term electric load forecasting based on Kalman filtering algorithm with moving window weather and load model[J]. Electric Power Systems Research, 2004, 68(1)
- [8] Huang S J, Shih K R. Short-term load forecasting via ARMA model identification including nongaussian process considerations[J]. IEEE Transactions on Power Systems, 2003, 18(2): 673
- [9] Keerthi S, Gibert E. Convergence of a generalized SMO algorithm for SVM classifier design[J]. Machine Learning, 2002, 46(3): 351-360
- [10] 雷英杰, 张善文, 李续武, 等. MATLAB 遗传算工具箱及其应用[M]. 西安: 西安电子科技大学出版社, 2005
- [11] Reis A J R, Silva A P A. Feature extraction via multi-resolution analysis for short-term load forecasting[J]. IEEE Trans on Power Systems, 2006, 21(1): 392-401
- [12] 赵杰辉, 葛少云, 刘自发. 基于主成分分析的径向基函数神经网络在电力系统负荷预测中的应用[J]. 电网技术, 2004, 28(5): 35-40