

基于粒子群优化支持向量机的火电厂主汽温预测模型

陈其松¹, 陈孝威¹, 张 欣², 戚 琳³, 吴茂念¹

(1 贵州大学 计算机科学与技术学院, 贵州 贵阳 550025; 2 贵州省光电子技术与应用重点实验室, 贵州 贵阳 550025;
3 贵州电力培训中心, 贵州 贵阳 550002)

摘 要: 针对支持向量机在大规模训练中算法收敛速度慢、复杂程度高等问题, 采用量子粒子群算法选取最小二乘支持向量机的模型参数, 避免了人为选择参数的盲目性, 提高了预测模型的训练速度和泛化能力. 实验结果表明, 该算法具有容易实现、节省计算成本、提高收敛速度等优点, 应用于火电锅炉主汽温预测模型, 取得良好的效果.

关键词: 量子粒子群算法; 支持向量机; 优化; 预测

中图分类号: TP301; TP18

文献标识码: A

文章编号: 1000-7180(2010)07-0218-04

Main Stream Temperature Forecasting Model Based on QPSO and SVM in Power Plant

CHEN Qi-song¹, CHEN Xiao-wei¹, ZHANG Xin², QI Lin³, WU Mao-nian¹

(1 School of Computer Science and Technology, Guizhou University, Guiyang 550025, China;

2 Guizhou Key Laboratory for Photoelectric Technology and Application, Guiyang 550025, China;

3 Guizhou Training Center, China South Power Grid, Guiyang 550025, China)

Abstract: According to the low speed of constringency and high complexity of training methods in SVM large scales training, quantum-behaved particle swarm algorithm (QPSO) is presented to solve the problem. Parameters selection is an important problem in the research area of support vector machines. Meanwhile, quantum-behaved particle swarm algorithm is used to choose the parameters of least square support vector machines, which can avoid the man-made blindness and enhance the efficiency and capability of forecasting. The experimental results indicate that this QPSO-SVM forecasting model can be trained quickly and good generalization, is easy to be realized, can save the calculating cost and improve the constringency speed.

Key words: QPSO; SVM; optimization; forecasting

1 引言

电站锅炉过热蒸汽温度(主汽温)是影响机组生产过程安全性和经济件的重要参数,也是重要的控制对象^[1].而电力系统现行短期负荷预测的方法很多^[2],传统的方法主要是时间序列预测法^[2],较新的如人工神经网络^[3-5]等.但是神经网络是一种基于渐进理论的机器学习方法,往往需要大量的数据样本或先验知识.

粒子群算法^[6]是一种新型的进化计算技术,通

过群体中个体之间的协作和信息共享来寻找最优解,收敛速度快,容易实现.因此,把粒子群算法和支持向量机相结合,利用 PSO 的全局搜索能力对模型参数进行优化,避免了人为选择参数的盲目性,提高了预测模型的训练速度和预测推广能力.

2 支持向量机及其优化算法

支持向量机本质思想^[7]是寻找分类间隙最大的最优超平面把属于两个类别的样本区分开.给定

收稿日期: 2009-02-13; 修回日期: 2009-05-18

基金项目: 贵州省自然科学基金项目(20092112)

l 个训练样本 $\{x_i, y_i\}_{i=1}^l, \{x_i\} \in R^n$ 为 n 维训练样本输入, $y_i \in \{+1, -1\}$ 为训练样本输出. 若样本线性可分则可以由超平面 $\omega \times x + b = 0$ 分开, 使得每个样本点都满足

$$y_i[(x_i \times \omega) + b] - 1 \geq 0, i = 1, 2, \dots, l \quad (1)$$

此时分类间隔为 $2/\omega$. 因此间隔最大等价于 $\|\omega\|^2$ 最小, 所以满足式(1)且使 $\|\omega\|^2$ 最小的分类面即为最优分类面.

利用 Lagrange 优化方法, 最优分类面问题转换为求解如下的 QP 问题:

$$\begin{aligned} \min W(\alpha) &= 1/2 \sum_{i,j} \alpha_i \alpha_j y_i y_j k(x_i, x_j) - \sum_{i=1}^l \alpha_i \\ \text{s.t. } \sum_{i=1}^l y_i \alpha_i &= 0, 0 \leq \alpha_i \leq C, i = 1, 2, \dots, l \end{aligned} \quad (2)$$

其中, α_i 是 QP 优化问题所求解的 Lagrange 乘子; C 为惩罚参数; $k(x_i, x_j)$ 为核函数. 常用的核函数有多项式核、径向基核、Sigmoid 核等.

为解决训练样本大规模问题, 出现了一些优化算法. Vapnik 采用求解矩阵分块的算法, 大型 QP 问题可转换为一系列的小规模 QP 问题. 与分块算法不同, 分解算法每次迭代只更新若干个 Lagrange 乘子, 而其他的乘子保持不变. 将 SVM 中大型的 QP 问题转换为一系列的求解规模一定的子 QP 问题, 每一步都保持问题满足 Kuhn-Tucker 条件.

序列最小优化算法 (Sequential Minimal Optimization, SMO) 是分解算法的一个特例. 它将工作样本集的规模减小到了两个样本, 迭代过程中直接进行求解, 提高了子问题的运算速度.

3 QPSO

3.1 PSO

粒子群算法^[8]将优化问题的每个解称为粒子, 每个粒子表示在 n 维空间中的一个点, 用 $x_i = [x_{i1}, x_{i2}, \dots, x_{in}]$ 表示第 i 个粒子.

第 i 个粒子的个体最优解表示为 $pbest_i = [p_{i1}, p_{i2}, \dots, p_{in}]$; 全局最优解表示为 $gbest_i = [g_1, g_2, \dots, g_n]$; x_i 的第 k 次迭代修正量表示为: $v_i^k = [v_{i1}^k, v_{i2}^k, \dots, v_{in}^k]$. 每个粒子根据式(4)、(5)更新自己的速度和位置:

$$v_{id}^k = w_i v_{id}^{k-1} + c_1 \text{rand}_1(p_{id}^{k-1} - x_{id}^{k-1}) +$$

$$c_2 \text{rand}_2(g_d^{k-1} - x_{id}^{k-1}) \quad (4)$$

$$x_{id}^k = x_{id}^{k-1} + v_{id}^k \quad (5)$$

式中, $d = 1, 2, \dots, n$; m 为粒子群中粒子的个数; n 为解向量的维数; 正常数 c_1 和 c_2 为加速度因子; rand_1 和 rand_2 是两个独立的介于 $[0, 1]$ 之间的随机数; w_i 为动量项系数, 调整其大小可改变搜索能力的强弱.

3.2 QPSO

QPSO 是 Sun 等从量子力学的角度提出的一种新的算法模型^[9]. 该算法中, 每一个粒子按式(6)~(8)移动:

$$\begin{aligned} mbest &= (1/M) \sum_{i=1}^M P_i \\ &= [(1/M) \sum_{i=1}^M P_{i1}, P_{i2}, \dots, P_{ij}] \end{aligned} \quad (6)$$

$$\begin{aligned} pp_{ij} &= \varphi \cdot P_{ij} + (1 - \varphi) \cdot P_{gj}, \\ \varphi &= \text{rand}(0, 1) \end{aligned} \quad (7)$$

$$\begin{aligned} x_{ij} &= pp_{ij} + \alpha \cdot |mbest_j - x_{ij}| \cdot \ln(1/u), \\ u &= \text{rand}(0, 1) \end{aligned} \quad (8)$$

这里 $mbest$ 是粒子群 $pbest$ 的中间位置; pp_{ij} 为 P_{ij} 和 P_{gj} 之间的随机点; α 为 QPSO 的收缩扩张系数, 它是 QPSO 收敛的一个重要参数.

在 QPSO 算法中, 粒子的状态只需用位置向量来描述, 并且算法中只有一个控制参数 α . 对这个参数的选择和控制是非常重要的, 它关系到整个算法的收敛速度. QPSO 算法参数个数少, 在搜索能力上远远优于所有已开发的 PSO 算法^[8].

4 QPSO-SVM 算法用于火电厂主汽温预测

本研究针对 300MW 电力锅炉主汽温的变化, 提出综合考虑负荷变化的主汽温预测算法.

4.1 预测模型

本预测模型如图 1. 先对初始数据进行小波分解及相空间重构, 再进行预测. SVM 分类器的超参数由 QPSO 算法优化. 原锅炉主汽温自动调节采用串级系统, 调节系统框图见图 2.

$$W_1(s) = \frac{9}{1 + 87s} e^{-54s},$$

$$W_2(s) = \frac{2}{1 + 37s} e^{-7s},$$

$$\gamma_1 = \gamma_2 = 0.1 \text{ mA/}^\circ\text{C}$$

4.2 数据预处理和小波分解

首先对历史负荷数据中包含的非真实数据进行




图1 预测模型结构图




图2 主汽温串级调节系统框图

预处理,然后采用小波变换^[10]对数据进行多尺度分解.采用db4小波,进行3层分解,采用sqtwolog的阈值形式,阈值为 $\sqrt{2\log(\text{length}(X))}$.

4.3 相空间重构

将采集到的负荷值视为时间序列,则可采用时间序列预测的方法对历史数据进行学习得到一个非线性映射,逼近数据中隐含的非线性机制 f ,并利用该映射进行预测.

设此非平稳时间序列长度为 N ,可以在一个高维的相空间中恢复系统的演化规律,因此复杂时间序列 $\{x_t\}, t=1,2,\dots,N$ 是短期可预测的.在一定条件下对满足特定条件的 m ,存在一个光滑映射 $f: R^m \rightarrow R$,使得

$$x_t = f(x_{t-m}, x_{t-m+1}, \dots, x_{t-1}) \quad (9)$$

其中 m 称作嵌入维,使式(10)成立的最小 m 被称为最小嵌入维,时间序列的预测问题,即是利用 $N-m$ 个 R^m 中的点 $x_t = \{x_{t-m}, x_{t-m+1}, \dots, x_{t-1}\}$ 和 $Y_t = x_t$ 组成样本 $(X_i, Y_i), i=m+1, m+2, \dots, N$,利用这些样本估计映射 f ,再计算出 x_{N+1} .

在本研究中,与一般时间序列预测不同的是进行相空间重构的是经过小波分解和重构的各层时间序列,即

$$x(t_i) = A_j(t_i) + D_1(t_i) + D_2(t_i) + \dots + D_J(t_i) \quad (10)$$

其中 $A_j(t_i)$ 为近似序列, $D_1(t_i) \dots D_J(t_i)$ 为各尺度细节序列.分别采用选定的嵌入维数 m 建立训练样本 (X_i, Y_i) ,利用SVM分别建立一步回归预测模型,得到回归函数 f_{A_j} 和 $f_{D_1} \dots f_{D_J}$,则预测值:

$$\hat{Y} = f_{A_j}(X_{A_j}) + f_{D_1}(X_{D_1}) + \dots + f_{D_J}(X_{D_J}) \quad (11)$$

SVM预测模型只需根据优化准则选择输入节

点数 m (时间序列嵌入维数)和支持向量机的参数,网络结构由支持向量数SV决定,连接权由算法自动确定.

文中采用平均绝对百分比误差作为嵌入为选取的标准,对各层分解信号采用不同的嵌入维 m 作为滑动窗口建立训练样本和测试样本数据,构建预测模型和进行预测误差估计.定义平均绝对百分比误差为:

$$\text{MAPE} = \frac{1}{n} \sum_{t=1}^n \frac{|y_t - \hat{y}_t|}{|y_t|} \quad (12)$$

测试结果均取为5组交叉验证平均值,结果表明当维数小于15时精度较差,当维数大于18时精度不再有明显提高,经过测试嵌入维数取为17.

4.4 LS-SVM核函数选择和超参数优化

标准的SVM算法,随着样本数据个数的增多,其所求解的二次规划问题显得越复杂,计算速度越慢;同时,抗噪声能力较差.解决此类问题的一个有效方法就是LS-SVM算法.

在最小二乘支持向量回归估计中,假设最优解是 $\alpha^* = \{\alpha_1, \alpha_2, \dots, \alpha_l\}$,则最终所得到的决策函数为

$$f(x_i) = \sum_{i=1}^l \alpha_i^* k(x, x_i) + b \quad (13)$$

其中, $f(x_i)$ 为SVM相对于第 i 个样本的输出,值的正负表明其归属哪一类.

LS-SVM模型只关心对象的输入与输出,而不关心对象的具体结构,在具体建模时,首先确定输入输出变量,然后用式(13)实现输入输出的非线性函数关系.

进行LS-SVM建模,如何寻找最佳正规化参数 σ 和核参数的问题是最佳模型选择问题.本研究选择径向基核函数,利用QPSO算法对核参数 σ 和惩罚系数 C 进行优化选择,最终使模型的估计值与期望值的逼近程度达到预期的目标.其算法步骤如下:

(1) LS-SVM初始化;

(2) 初始化粒子群.对每个粒子初始化一个满足约束条件的 α_w 值;初始化加速因子 c_1 和 c_2 、惯性权重 w 及最大进化迭代次数 $T_{\max}$;并把正规化参数 C 和核参数 σ 映射为一群粒子,初始化粒子的位置与速度,将每个粒子的初始位置设为初始最好位置,再根据适应度函数计算每个粒子的适应值,将粒子中最小的适应值所对应的初始位置设为初始群体最好位置;

- (3) 按式(4) 和式(5) 更新粒子的速度和位置, 生成新一代的种群;
- (4) 根据式(6) 计算 $mbest$; 根据式(7) 计算每个粒子随机点 pp_{ij} ; 根据式(8) 更新每个粒子的 α_w 值, 使拉格朗日乘子的值在 $[0, C]$ 内;
- (5) 根据设定的适应度函数, 评价每个粒子的适应值. 粒子的适应值越小, 则粒子的位置越好;
- (6) 检查终止条件, 若满足, 则将全局最优粒子映射为正规化参数 C 和核参数 σ , 并以此为优化结果, 得到一个建立好的 LS - SVM 模型. 否则转入 (3). 终止条件为寻优达到最大进化代数 T_{max} 或者评价值小于给定精度;
- (7) 用建立好的 LS - SVM 模型进行预测;
- (8) 结束.

5 实验结果分析

将样本分为 288 组训练验证集和 72 组测试集, 其中测试集取连续三天的数据. 将训练验证集随机均分为 4 组, 用 3 组数据训练, 用 1 组数据验证. 程序运行计算至迭代结束, 搜索得到支持向量机的选定惩罚因子 C 为 237, 高斯核函数参数 σ 为 3.99. 预测结果如图 3 所示.




图 3 锅炉负荷实测值与预测值的比较

对比 QPSO - SVM 预测模型和神经网络预测模型、贝叶斯框架下的 LS - SVM 预测模型的性能如表 1 所示. 可以看出 QPSO - SVM 模型的预测精度明显高于 BP 神经网络, 而贝叶斯框架下的 LS - SVM 预测模型的预测精度与 QPSO - SVM 预测模型相当, 但使用 QPSO 算法可以较快地获得最佳参数. 另外, 在训练阶段, QPSO 性能也高于 LS - SVM, 对 288 组训练样本集, LS - SVM 预测模型的训练时间为 40212.71(s), QPSO 算法的训练时间为 2010.26(s).

表 1 几种预测模型的性能对比

		QPSO - SVM	贝叶斯框架 LS - SVM	BP NN
误差	0~5	86.15	87.02	56.17
分布	5~10	12.56	11.74	28.54
%	10~15	1.29	1.24	15.29
获得最优参数 的运算时间(s)		21.3	25.9	324.8

6 结束语

文中利用粒子群算法优化支持向量机, 构建时间序列的多尺度预测模型, 对原始时间序列进行小波分解和分层及相空间重构, 分别建立 SVM 预测模型并将预测模型用于火电锅炉负荷预测. 结果表明该模型预测精度优于传统的 ANN 和未优化的 SVM 预测方法.

参考文献:

[1] 张洁琦,刘弘. 神经 PID 控制在电厂主汽温控制中的应用[J]. 计算机工程与应用, 2006, 42(30): 202 - 204.

[2] 刘峰,瞿俊. 基于聚类分析和神经网络的时间序列预测方法[J]. 微电子学与计算机, 2006, 23(9): 85 - 87.

[3] 高琴. 人工神经网络在股市预测模型中的应用[J]. 微电子学与计算机, 2007, 24(11): 147 - 151.

[4] 傅德胜,谢忠红. 基于 BP 神经网络的路面性能预测方法[J]. 微电子学与计算机, 2003, 20(7): 21 - 22.

[5] 杨居义. 基于 BP 网络的交通运输能力预测[J]. 微电子学与计算机, 2008, 25(9): 202 - 205.

[6] Kennedy J, Eberhart R C. Particle swarm optimization [C]// Proc of the IEEE International Conference on Neural Networks. Perth, Australia, Piscataway, NJ: IEEE Press, 1995: 1942 - 1948.

[7] Sanchez A D. Advanced support vector machines and kernel methods[J]. Neurocomputing, 2003, 55(1): 5 - 20.

[8] Shen Yan, Guo Bing, Gu Tianxiang. Particle swarm optimization algorithm and comparison with genetic algorithm [J]. Journal of University of Electronic Science and Technology of China, 2005, 34(5): 696 - 699.

[9] Sun J, Feng B, Xu W B, et al. Particle swarm optimization with particles having quantum behavior[C]// IEEE Proc of Congress on Evolutionary Computation. United States: Portland, 2004: 619 - 623.

[10] Satish L, Nazneen B. Wavelet - based denoising of partial discharge signals buried in excessive noise and interference [J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2003, 10(2): 354 - 367. (下转第 224 页)

择准确与否对衰落信道预测的准确度影响较大. 在实际应用中, 可用如图 2 所示方式来选取嵌入维的最优值.




图 1 Jakes 衰落信道系数的真实值、预测值以及预测误差曲线




图 2 Jakes 衰落信道预测均方误差(MSE)随嵌入维的变化曲线

5 结束语

文中将最小二乘支持向量机用于 Jakes 衰落信道预测, 进而提出了一种新的信道预测算法, 并用实验验证了算法的可行性和有效性. 讨论了嵌入维参

数对预测准确度的影响, 通过分析预测均方误差随嵌入维的变化规律, 给出最优嵌入维的选取方法. 下一步的研究工作将包括: (1) 定量分析加性噪声对预测准确度的影响; (2) 从理论上分析 Jakes 衰落信道的可预测性.

参考文献:

- [1] Suykens J A K, Vandewalle J. Recurrent least squares support vector machines[J]. IEEE Trans. on Circuits and Syst. I, 2000(47):1109-1114.
- [2] Baesens B, Viaene S. An empirical assessment of kernel type performance for least squares support vector machine classifiers[C]// 4th Int. Conf. knowledge-Based Intelligent Engineering Systems and Allied Technologies. Brighton, UK, 2000:313-316.
- [3] Suykens J A K, Vandewalle J. Multi-class least squares support vector machines[C]// Int. Joint Conf. on Neural Networks (IJCNN'99). Washington DC, 1999:900-903.
- [4] Tung Sheng Yang, Duel Hallen A, Hallen H. Long range fading prediction to enable adaptive transmission at another carrier[C]// 4th IEEE Workshop on Signal Processing Advances in Wireless Communications. USA: North Carolina State University, 2003:195-199.
- [5] Gao X M, Tanskanen J M A, Ovaska S J. Comparison of linear and neural network-based power prediction schemes for mobile DS/CDMA systems[C]// VTC'96. Atlanta: IEEE press, 1996:61-65.
- [6] 孙建成, 张太猛, 刘枫. 一种新的快速衰落信道非线性预测算法[J]. 北京航空航天大学学报, 2005, 31(5):499-503.
- [7] Jakes W C. Microwave mobile communications[M]. Piscataway, NJ: IEEE Press, 1994.

作者简介:

何 昊 女, (1988-). 研究方向为智能信息处理、模式识别等.

(上接第 221 页)

作者简介:

陈其松 男, (1974-), 博士研究生, 副教授. 研究方向为信号处理、自动控制、网络与通讯技术等.

陈孝威 男, (1945-), 教授, 博士生导师. 研究方向为多媒体技术、网络与通讯.

张 欣 男, (1976-), 博士研究生. 研究方向为激光与机械加工.

戚 琳 女, (1972-), 高级工程师. 研究方向为热工自动化.

吴茂念 男, (1976-), 博士, 副教授. 研究方向为人工智能.