

引用格式:鞠建波,胡胜林,祝超,等.一种改进的支持向量机回归故障预测方法[J].电光与控制,2018,25(1):6-9.JU J B, HU S L, ZHU C, et al. A fault prediction method based on improved SVM algorithm[J]. Electronics Optics & Control, 2018, 25(1):6-9.

一种改进的支持向量机回归故障预测方法

鞠建波, 胡胜林, 祝超, 徐永力
(海军航空大学, 山东 烟台 264001)

摘要:为实现装备的故障预测,把支持向量机(SVM)作为基础学习算法,采用加权支持向量机回归方法,对突变点赋予较大的权值,增强对突变点的训练,提高故障预测精度。采用权重自适应裁剪方法,通过计算样本点的回归权重,剔除权重较小的样本点,减少每次参与训练的样本个数,提高预测速度。选定合适的核函数及相关参数,建立故障预测模型,研究以某通信电台为例,验证了算法的有效性和优越性。

关键词: 故障预测; 支持向量回归; 突变点; 自适应裁剪算法; 核函数

中图分类号: TP206 文献标志码: A doi:10.3969/j.issn.1671-637X.2018.01.002

A Fault Prediction Method Based on Improved SVM Algorithm

JU Jian-bo, HU Sheng-lin, ZHU Chao, XU Yong-li
(Naval Aeronautical University, Yantai 264001, China)

Abstract: In order to realize fault prediction of equipments, the paper uses the Support Vector Machine (SVM) as the basic learning algorithm, and adopts the weighted SVM regression method to assign relatively larger weight to the mutation point, so as to enhance the training of the mutation point and improve the fault prediction accuracy. By using the adaptive weight clipping method, the sample points with smaller weights are eliminated by calculating the regression weights of the sample points. Meanwhile, the number of samples participating in the training is reduced so as to improve the forecasting speed. Finally, the fault prediction model is established by selecting the appropriate kernel function and related parameters. The validity and superiority of the algorithm are verified by taking a certain type of communication station as an example.

Key words: fault prediction; support vector regression; catastrophic point; adaptive clipping algorithm; kernel function

0 引言

大部分电子设备的工作模式和故障机理相对复杂,难以建立准确的数学模型,导致基于模型的预测方法在应用上受到了较大限制。基于数据驱动的故障预测^[1]方法不需要建立系统的数学模型,通过对测试点输出信号进行采集与特征提取获得故障数据及相关信息,同时通过设计先进的算法挖掘故障数据的隐含规律来进行故障预测。

传统的支持向量回归故障预测方法精度较低,速

度较慢。文献[2]提出一种基于最小二乘支持向量机的电力电子电路故障预测方法,提高了预测的速度;文献[3]基于加权支持向量回归的在线训练算法及应用,利用加权方法,提高了故障预测的准确度。

本文以标准支持向量机(SVM)作为基础学习算法,采用加权支持向量机回归方法,对突变点赋予较大的权值,增强对突变点的训练,提高故障预测精度。采用权重自适应裁剪方法,通过计算样本点的回归权重,剔除权重较小的样本点,减少每次参与训练的样本个数,提高预测速度。选定合适的核函数及相关参数,建立故障预测模型,实现装备的故障预测。

1 改进的 SVM 回归算法

标准 SVM 回归算法能够解决小样本情况下的数据回归估计问题。

收稿日期:2017-03-16 修回日期:2017-11-10

基金项目:国家自然科学基金(60874112);军队科研专项资助项目(41512322)

作者简介:鞠建波(1961—),男,山东烟台人,硕士,教授,研究方向为军事装备故障分析和水下目标探测与识别。

假设训练样本集为 $\{x_i, y_i\}$,其中输入变量值 $x_i \in \mathbf{R}^n$,输出变量值 $y_i \in \mathbf{R}$,训练样本个数为 n ,SVM 回归^[2]的基本思想是通过某种事先选择的非线性映射 ϕ 将输入变量映射到一个高维特征空间 F ,并在该高维特征空间 F 中利用线性回归函数进行线性回归,是一种将低维空间非线性问题转换成高维空间线性问题的方法,该方法分为两步:

1) 使用一个非线性映射将数据变换到一个高维特征空间 F ;

2) 在空间 F 中利用映射变量的线性特点进行线性回归,线性回归函数为

$$f(x) = \boldsymbol{\omega}^T \phi(x) + b \quad (1)$$

式中: $\boldsymbol{\omega}$ 为权值; b 为偏差。

目标是在使风险函数最小化的基础上,寻找合适的 $\boldsymbol{\omega}$ 和 b 。由于 $\phi(x)$ 即事先选择的非线性映射函数是不变的,则基于 SVM 回归的最优回归函数就是在结构风险最小化原理的基础上,极小化目标函数,即

$$\min R(\boldsymbol{\omega}) = \min \left[\frac{1}{2} \|\boldsymbol{\omega}\|^2 + C \sum_{i=1}^n (\varepsilon_i^* + \varepsilon_i) \right] \quad (2)$$

$$\text{s. t. } \begin{cases} y_i - \boldsymbol{\omega}^T \phi(x_i) - b \leq g + \varepsilon \\ \boldsymbol{\omega}^T \phi(x_i) + b - y_i \leq g + \varepsilon^* \\ \varepsilon, \varepsilon^* \geq 0 \end{cases}$$

式中: C 为惩罚因子,实现置信风险和经验风险的折衷,当 C 越大时,其数据拟合能力越高; $\varepsilon, \varepsilon^*$ 为松弛因子; g 为不敏感损失函数,定义为

$$g(f(x_i) - y_i) = \begin{cases} 0 & |f(x_i) - y_i| \leq g \\ |f(x_i) - y_i| - g & \text{其他} \end{cases} \quad (3)$$

核函数体现了支持向量与未知样本之间的相似度。为有效求解式(3),可以通过引入核函数将支持向量回归问题转化为二次规划问题。最终获得 SVM 回归函数为

$$f(x) = \sum_{i,j=1}^n (\alpha_i - \alpha_i^*) (\phi(x_i), \phi(x_j)) + b = \sum_{i,j=1}^n (\alpha_i - \alpha_i^*) k(x_i, x_j) + b \quad (4)$$

式中: α_i, α_i^* 为拉格朗日乘子; $k(x_i, x_j)$ 为核函数。 $\boldsymbol{\omega} = \sum_{i=1}^n (\alpha_i - \alpha_i^*)$ 。

1.1 加权 SVM 回归算法

标准 SVM 算法具有较好的平滑性,对数据有平滑作用,但却消除了部分突变点的影响,导致难以预测突变故障,数据中包含的突变点与拐点影响了标准 SVM 方法的训练效果,造成回归预测的准确度不高的问题。

加权 SVM^[3]对每个训练样本定义一个权函数 $\omega(i)$,

其初始值为 $1/m$,且该权系数通过算法更新。

给定训练样本集和 SVM 参数,以及最大的迭代次数 T , ω_i^t 表示第 i 个样本经过 SVM 学习 t 次后获得的权值。

1) 设所有的样本在初始状态的权值相等,都是 $\omega_i^1 = 1/m$ 。

2) 令 $t = 1$ 到 $t = T$ 。根据所述的方法得到回归函数 $f_t(x_i)$,计算错误回归权重 $e_t = \sum \omega^t(i)$,若 $e_t > 1/2$ 则退出循环。

3) 利用错误回归权重 e_t ,由

$$\omega^{t+1}(i) = \omega^t(i) \ln \left[\frac{(1-e_t)/e_t}{2} \right] \quad (5)$$

更新样本权值。

标准 SVM 算法对于训练数据中所有样本的惩罚程度都相同,然而故障数据中的某些突变点对于回归曲线拟合有重要影响,故需要对突变点赋予较大的权值,增加该类训练样本个数,增强对此类突变点的训练,从而提高对突变训练点的训练精度。加权 SVM 的详细算法可参考文献[3]。

1.2 权重自适应裁剪 SVM 算法

权重裁剪方法能够减少 SVM 算法每次学习所需的训练样本个数^[4],加快算法的训练速度。本节提出权重自适应裁剪算法,定义裁剪系数为每次剔出的样本权重之和,通过计算当前加权 SVM 算法的错误回归权重^[5]自动调整权重裁剪系数。算法的具体步骤如下所述。

1) 设置初始的裁剪系数 μ_0 。

2) 计算当前赋权样本集 $\{S, \omega^t(i)\}$ 的错误回归权重 e_t ,并根据权重大小将 S 中的训练样本依次排列。从权重最小的样本开始,依次将样本权重相加获得权重和为 μ 的样本集,从 $\{S, \omega^t(i)\}$ 中删除这部分权重较小的样本得到裁剪后的样本集 $\{S', \omega^t(i')\}$,将 $\{S', \omega^t(i')\}$ 作为当前的训练样本,获得回归函数 $f_t(x')$ 。

3) 将原样本集输入回归函数 $f_t(x')$,重新计算错误回归权重 e'_t 。

4) 当错误回归权重 $e'_t = 0$ 或者 $e'_t \geq 0.5$ 且 $S' = S$ 时,停止训练。

根据上述分析设计权重自适应裁剪系数 μ 为

$$\mu = \mu_0 e^{-e'_t} \quad (6)$$

由负指数函数的特点可知,如果权重 e'_t 较大,则裁剪系数 μ 较小,训练样本数量的增加可以使 SVM 回归的准确度提高^[6];反之, e'_t 较小时,较大的裁剪系数能够舍去权重较小的训练样本,减少训练时间。虽然训练权重较大的样本(个数较少)时,增加了样本个数,但由于舍弃了许多权重较小的训练样本,对总体而言,训

练习样本的个数还是减少了,因此在算法中应用权重自适应裁剪方法不仅能够加快训练速度,同时也避免裁剪系数选择不合理而影响回归精度。

1.3 算法步骤

基于前面改进的 SVM 算法^[7]的步骤如下:给定训练样本集和 SVM 参数,以及最大的迭代次数 T , ω_i^t 表示第 i 个样本经过 SVM 学习 t 次后获得的权值。

1) 设所有的样本在初始状态的权值相等,都是 $\omega_i^1 = 1/m$;

2) 令 $t = 1$ 到 $t = T$,根据所述的方法得到回归函数 $f_t(x_i)$,计算错误回归权重 $e_t = \sum \omega^t(i)$;

3) 根据自适应裁剪算法获得裁剪后的赋权样本集 $\{S', \omega'(i)\}$ 以及新的错误回归权重 e'_t 和裁剪系数 μ ,利用

$$\omega^{t+1}(i) = \omega^t(i) \ln \left[\frac{(1 - e'_t)/e'_t}{2} \right] \quad (7)$$

更新样本权值;

4) 循环结束后得到最终的回归函数为

$$f(x) = \sum_{i,j=1}^n (\alpha_i - \alpha_i^*) k(x_i, x_j) + b \quad (8)$$

2 故障预测模型与步骤

2.1 故障预测模型

本文利用改进的 SVM 方法进行故障预测。对于某特征参量的训练样本 $\{x_i, i = 1, 2, 3, \dots\}$,取前 n 个数据作为训练样本,后 $N-n$ 个数据作为测试样本,对其进行

相空间重构^[8],则用于学习的输入样本为 $X = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_{n-m} \end{bmatrix} =$

$\begin{bmatrix} x_1 & \cdots & x_m \\ \vdots & & \vdots \\ x_{n-m} & \cdots & x_{n-1} \end{bmatrix}$,输出样本为 $Y = \begin{bmatrix} x_{m+1} \\ x_{m+2} \\ \vdots \\ x_n \end{bmatrix}$, m 为模型

的嵌入维数,可建立起映射 $f: \mathbf{R}^m \rightarrow \mathbf{R}$ 。

根据式(4),则对训练样本可按回归函数进行训练,即

$$y_t = \sum_{i=1}^{n-m} \alpha_i k(x_i, x_{t-m}) + b \quad t = 1, 2, \dots, n \quad (9)$$

则第 $n+1$ 个预测值为

$$x_{n+1} = \sum_{i=1}^{n-m} \alpha_i k(x_i, x_{n+m-1}) + b \quad (10)$$

以此类推,可得到最后的预测值。

2.2 故障预测步骤

本文将 SVM 应用于复杂装备的故障预测,以满足

在有限装备故障信息条件下,实现对装备故障趋势的预测。其具体步骤为:

1) 对现有装备工作原理及电路特性进行分析,筛选出合理有效的表征各模块运行状态的特征参数,对 ATE 设备提供的历史数据进行处理,确定训练样本及测试样本,并选取嵌入维数;

2) 选择合适的核函数,常用的核函数有多项式函数、径向基函数和 Sigmoid 函数,常用的径向基函数是高斯核函数,本文采用的高斯核函数 $k(x, x_i) = \exp\left(-\frac{\|x - x_i\|^2}{2\sigma^2}\right)$, σ 是取定的核参数;

3) 计算模型初始化,用核函数求解回归问题,获得迭代次数 T 和初始化自适应裁剪系数 μ_0 ;

4) 利用加权支持向量机回归模型对训练样本集进行学习,获得样本预测值,然后根据权重自适应裁剪算法计算错误回归权重并更新样本权值,由式(6)更新裁剪系数,判断算法是否满足终止条件,如不满足,保持当前裁剪系数不变继续训练,否则训练完毕,获得预测网络;

5) 将待测样本集输入训练好的预测网络,选择预测步数并根据 2.1 节所述方法计算待测样本的单步和多步预测值,从而实现对未来时刻的特征参数值预测。

3 实例验证

本文以某通信电台为例进行故障预测。该电台中激励模块的主要特征参数有 UUT 发信端电流、频率误差、发射功率等。对其 UUT 发信端电流进行采集,采集历史数据为 25 个,将采集的历史数据进行分类整理,剔除非正常测量值。前 20 个数据作为训练样本集,后 5 个数据为测试样本集,用训练样本集建立预测网络模型,并用测试样本集进行验证。

取高斯核函数的核参数 $\sigma = 1$,根据文献[9]的最终预测误差准则(FPE)确定最佳嵌入维数^[9] $m = 7$ 。本文算法中,最大迭代步数 $T = 20$,设初始权重裁剪系数 $\mu_0 = 0.3$ 。采用 5 折交叉验证法选择最佳的 C 和 g 参数,假设 C 和 g 取一定的范围值,然后利用 K-CV 方法获得训练验证时回归最准确的那组 C 和 g ,将其作为最佳参数。如果得到了多组 C 和 g ,那么选取 C 最小的那组为最佳参数。针对 UUT 输入端电流历史数据,通过该方法选择出的最佳参数 C 和 g 分别为 $C = 256$, $g = 0.0055243$,如图 1 所示。

在选择以上参数的条件下,完成对 5 个测试样本的数据预测。实际数据与不同算法的一步预测数据对比情况如图 2 所示,不同算法测试样本的 1~3 迭代步数的状态预测值,如表 1 所示。

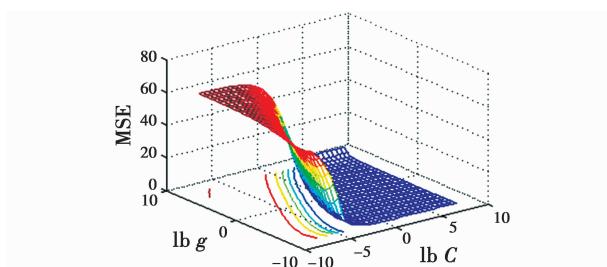


图1 基于UUT输入电流历史数据选择最佳C和g参数

Fig. 1 The best C and g based on historical data
of UUT input current

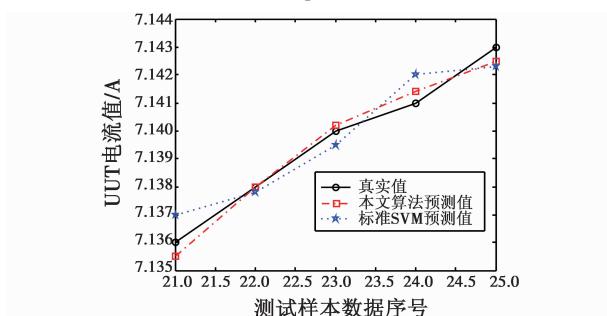


图2 不同算法一步预测结果对比图

Fig. 2 One-step prediction results of different algorithms

表1 不同迭代步数下的预测结果

Table 1 Predictive results under different

iteration steps

	数据序号					A
	21	22	23	24	25	
UUT 电流真实值	7.1360	7.1380	7.1400	7.1410	7.1430	
单步预 SVM 算法 测值	7.1370	7.1378	7.1395	7.1420	7.1423	
本文算法 测值	7.1355	7.1380	7.1402	7.1414	7.1425	
两步预 SVM 算法 测值	7.1369	7.1376	7.1394	7.1418	7.1422	
本文算法 测值	7.1357	7.1378	7.1401	7.1413	7.1426	
三步预 SVM 算法 测值	7.1368	7.1377	7.1396	7.1417	7.1423	
本文算法 测值	7.1358	7.1379	7.1400	7.1412	7.1427	

由图表可知,本文改进的算法比标准的SVM算法的预测值更加接近真实值,预测结果更加准确。

将标准的SVM算法和本文改进的算法对样本的训练时间与故障预测总时间进行比较,在实验环境完全相同的情况下,结果如表2所示。

由此可知,采用自适应权重裁剪方法,通过减少每次迭代时的训练样本个数,降低加权SVM的输入样本维数,从而提高算法的速度,减少了预测时间。

表2 不同算法预测时间比较

Table 2 Prediction time for different algorithms s

算法	训练时间	预测总时间
本文算法	7.3	8.5
标准SVM算法	10.5	11.7

4 结束语

本文提出了一种改进的SVM方法对设备进行故障预测。加权支持向量机回归算法能够增强对突变点的训练,有效地提高了算法对突变故障的预测精度;利用自适应权重裁剪方法,舍去权重较小的样本点,从而提高算法的训练速度。最后以某通信电台为例,验证了算法的有效性和优越性。

参考文献

- [1] 彭宇,刘大同,彭喜元.故障预测与健康管理技术综述[J].电子测量与仪器学报,2010,24(1):1-9.
- [2] 姜媛媛,王友仁,崔江,等.基于LS-SVM的电力电子电路故障预测方法[J].电机与控制学报,2011,15(8):64-68.
- [3] 刁翔,李奇.基于加权支持向量回归的在线训练算法及应用[J].系统仿真学报,2007,17(9):3970-3973.
- [4] 孙永奎,陈光,李辉.基于自适应小波分解和SVM的模拟电路故障诊断方法研究[J].仪器仪表学报,2008,29(10):2105-2109.
- [5] CHEN J X. Support vector regression based on optimal training subset and adaptive particle swarm optimization algorithm[J]. Applied Soft Computing, 2013, 13(2):3473-3481.
- [6] 李应红,尉训楷,刘建勋.支持向量机的应用工程[M].北京:兵器工业出版社,2004.
- [7] 孙永奎.基于支持向量机的模拟电路故障诊断方法研究[D].成都:电子科技大学,2009.
- [8] 李建云,曾次玲,谢培元.基于组合预测模型的长沙市长期负荷预测[J].长沙电力学院学报:自然科学版,2005,20(3):23-26.
- [9] SUYKENS J A, VANDEWALLE J. Recurrent least squares support vector machines[J]. IEEE Transactions on Circuits and Systems, 2000, 47(7):1109-1114.