

粒子群优化的最小二乘支持向量机在通信装备故障预测中的应用

李文元¹, 闫海华^{1,2}, 姚宏杰¹

(1 西安通信学院, 陕西 西安 710106; 2 解放军 75706 部队, 广东 广州 510500)

摘 要: 提出了一种通信装备故障预测的智能算法. 该方法将粒子群算法(PSO)和最小二乘支持向量机(LS-SVM)算法相结合, 采用 PSO 算法优化 LS-SVM 的参数, 克服了人为参数选择的盲目性, 在全局优化与收敛速度方面具有较大优势. 仿真实验表明, 相比 BP 神经网络、未经优化的支持向量机(SVM)和 LS-SVM 模型, 经 PSO 算法优化后的 LS-SVM 有更高的预测精度和运算速度, 具有较好的有效性和可行性.

关键词: 故障预测; 粒子群优化; 最小二乘支持向量机; 通信装备

中图分类号: E96

文献标识码: A

文章编号: 1000-7180(2013)02-0099-04

Application of LS-SVM Based on PSO to Fault Prediction of Communication Equipment

LI Wen-yuan¹, YAN Hai-hua^{1,2}, YAO Hong-jie¹

(1 Xi'an Communication Institute, Xi'an 710106, China; 2 Troop 75706, Guangzhou 510500, China)

Abstract: An intelligent algorithm for fault prediction of communication equipment is proposed, in which particle swarm optimization algorithm and least square support vector machine is combined and the particle swarm optimization algorithm is adopted to optimize the parameters of least square support vector machine. The method overcomes the human's blindness on parameters selection and has more superior performance on global optimization and convergence speed. The simulation results show that LS-SVM optimized by PSO has better prediction accuracy and better computing speed, compared with the method based on BP neural network and support vector machine and LS-SVM. The effectiveness and feasibility of the method is better.

Key words: fault prediction; particle swarm optimization; least square support vector machine; communication equipment

1 引言

及时、准确的对通信装备进行故障预测, 是实现预知维修和精确保障的重要方式, 对有效提高装备的战备完好性和持续作战能力有重要意义. 目前, 有关预测的方法很多, 如回归分析法、人工神经网络、灰色预测模型法、组合预测法等, 上述方法均有各自适用范围, 但在解决小样本、非线性、局部极小点等问题上还存在不足. Vapnik^[1]等人提出的建立在统计学理论和结构风险最小化原理上的支持向量机

(SVM)方法, 解决了以往困扰机器学习的问题. 然而, 标准支持向量机计算复杂, 运算速度比较缓慢. 最小二乘支持向量机(LS-SVM)作为标准支持向量机的一种拓展, 简化了计算复杂性, 运算简单, 收敛速度快, 精度高. 另外, 支持向量机的惩罚因子和核参数取值与预测精度有着较大关系^[2], 不同参数的作用下, 预测效果有较大的差别. 粒子群优化(PSO)算法是一种种群的随机优化方法, 可以同时搜索待优化目标函数解空间中的较多区域, 具有简单快速易实现等优点, 可以很好地解决 SVM 的参

数选择问题^[3].

基于此,本文提出了利用 PSO 方法优化最小二乘支持向量机(LS-SVM)进行通信装备故障预测的方法.

2 最小二乘支持向量机与粒子群算法

2.1 支持向量机

回归包括线性和非线性回归. 对于线性回归,回归函数为

$$f(x) = w \cdot x + b \quad (1)$$

设样本数据为 $\{(x_i, y_i), i = 1, 2, \dots, n\}$, $x_i \in R^d$, $y_i \in R$. 假定存在函数 f 在 ϵ 精度能够估计所有的 (x_i, y_i) 数据,那么寻找最小 w 的问题可以表示为凸优化问题,即

$$\min J = \frac{1}{2} \|w\|^2 \quad (2)$$

约束条件为

$$\begin{cases} y_i - w \cdot x_i - b \leq \epsilon \\ w \cdot x_i + b - y_i \leq \epsilon \end{cases} \quad (3)$$

如果误差超过 ϵ ,则可以引入松弛因子 ξ, ξ^* , 因此式(2)、式(3)可以写为

$$\min J = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (4)$$

约束条件为

$$\begin{cases} y_i - w \cdot x_i - b \leq \epsilon + \xi_i \\ w \cdot x_i + b - y_i \leq \epsilon + \xi_i^* \end{cases} \quad (5)$$

其中, $\xi_i \geq 0$, $\xi_i^* \geq 0$, $i = 1, \dots, n$, 常数 C 控制着对超出误差限样本的惩罚与函数的平坦性之间的折中.

经过推导,可以得到由式(4)、式(5)构成的优化问题的对偶问题,即

$$\begin{aligned} \max_{a, a^*} W(a, a^*) = & -\frac{1}{2} \sum_{i,j=1}^n (a_i - a_i^*)(a_j - a_j^*) \\ & (x_i \cdot y_j) + \sum_{i=1}^n (a_i - a_i^*) y_i - \sum_{i=1}^n (a_i + a_i^*) \epsilon \end{aligned} \quad (6)$$

约束条件为

$$\sum_{i=1}^n (a_i - a_i^*) = 0 \quad (7)$$

其中, $0 \leq a_i, a_i^* \leq C$, $i = 1, \dots, n$.

回归函数的权值与对偶问题中的系数的关系为

$$w = \sum_{i=1}^n (a_i^* - a_i) x_i \quad (8)$$

在式(7)约束条件下,将最大化式(6)求得的参数 a_i, a_i^* 代入式(8),并由式(1)得回归函数为

$$f(x) = \sum_{i=1}^n (a_i^* - a_i)(x_i \cdot x) + b \quad (9)$$

其中 $a_i - a_i^* \neq 0$ 对应的样本数据就是支持向量.

对于非线性支持向量机回归,可以通过核函数间接进行非线性变换来实现非线性的支持向量机回归,可表示为

$$f(x) = \sum_{i=1}^n (a_i^* - a_i) k(x_i, x) + b \quad (10)$$

其中, $k(\cdot)$ 是核函数. 通过训练样本获得合适的 a_i, a_i^* 和 b , 就可以对数据进行预测.

2.2 最小二乘支持向量机

Suykens^[4]等人将最小二乘引入支持向量机中,提出了最小二乘支持向量机算法(LS-SVM). 该算法可以将原来的不等式约束条件转变成等式约束,用最小二乘线性系统代替二次规划方法解决函数估计问题.

对于某特征参量的样本 $0\{x_i\}, i = 1, 2, \dots, N$, 取前 n 个数据作为训练样本,后 $N-n$ 个数据作为测试样本,对其进行重构线性空间,找到输入输出的对应关系,建立预测模型^[5],经过变换,可以得到用于 LS-SVM 的学习的训练样本

$$\begin{cases} X = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_{n-m} \end{bmatrix} = \begin{bmatrix} x_1 & x_2 & \cdots & x_m \\ x_2 & x_3 & \cdots & x_{m+1} \\ \vdots & \vdots & \vdots & \vdots \\ x_{n-m} & x_{n-m+1} & \cdots & x_{n-1} \end{bmatrix} \\ Y = \begin{bmatrix} x_{m+1} \\ x_{m+2} \\ \vdots \\ x_n \end{bmatrix} \end{cases} \quad (11)$$

其中 m 为模型的嵌入维数,则可建立起映射 $f: R^m \rightarrow R$.

根据式(10),对训练样本进行训练的回归函数为

$$\begin{aligned} y_i = & \sum_{i=1}^{n-m} a_i \cdot k(x_i, x_{t-m}) + b, \\ t = & m+1, \dots, n \end{aligned} \quad (12)$$

由于 $x_{n-m+1} = \{x_{n-m+1}, x_{n-m+2}, \dots, x_n\}$, 则第 $n+1$ 的预测值为

$$y_{n+1} = \sum_{i=1}^{n-m} a_i \cdot k(x_i, x_{n-m+1}) + b \quad (13)$$

依此类推,可以得到其他预测值. 利用所得的预测值,即可实现对装备状态趋势及故障的预测.

2.3 粒子群算法

粒子群算法^[6]是一种基于群体和适应度的具有全局寻优能力的优化算法。在 PSO 中,优化问题的所有可能解被视为搜索空间中的一个位置,称为“粒子”,所有的粒子都被赋予位置和速度两个特征且有一个由被优化的函数决定的适应值。PSO 初始化为一群随机粒子(随机解),然后通过迭代找到最优解。在每一次迭代中,粒子通过跟踪两个极值来更新自己;第一个就是粒子本身所找到的最优解,这个解称为个体极值 P_{best} ;另一个极值是整个种群找到的最优解,这个解是全局极值 G_{best} 。在找到这两个最优解时,每个粒子根据下式更新自己的速度和位置:

$$v_{ij}(t+1) = \omega \cdot v_{ij}(t) + c_1 \cdot r_1 \cdot (P_{best}(t) - x_{ij}(t)) + c_2 \cdot r_2 \cdot (G_{best}(t) - x_{ij}(t)) \quad (14)$$

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (15)$$

其中 t 表示第 t 次迭代, ω 是惯性权值, c_1 和 c_2 为学习因子,也称加速系数, r_1 和 r_2 为 $[0,1]$ 范围内的随机数。式(14)右边由三部分组成,第一部分为“惯性”部分,反映了粒子的运动“习惯”,代表粒子有维持自己先前速度的趋势;第二部分为“认知”部分,反映了粒子对自身历史经验的记忆,代表粒子有向自身历史最佳位置逼近的趋势;第三部分为“社会”部分,反映了粒子间协同合作与知识共享的群体历史经验,代表粒子有向群体最佳位置逼近的趋势。式(15)是粒子 i 的新位置。

3 基于粒子群优化的最小二乘支持向量机

3.1 参数选择

设计 LS-SVM 的一个重要步骤是选择核函数和核参数。Vapnik 等人在研究中发现,核函数的参数和误差惩罚因子 C 是影响 SVM 性能的关键因素^[7]。

本文以高斯径向基函数作为核函数,为

$$k(x, x_i) = \exp \left[-\frac{\|x - x_i\|^2}{\sigma^2} \right] \quad (16)$$

LS-SVM 需要选择的参数有 2 个,即超参数 γ 和核参数 σ^2 。其中, γ 对应向量机中的惩罚因子 C ,它决定了训练误差的大小和泛化能力的强弱; σ^2 反映了训练样本数据的分布或范围特征。

3.2 粒子群优化最小二乘支持向量机

最小二乘支持向量机的预测精度与其相关参数的取值有着较大关系。因此,需通过 PSO 算法对支持向量机的参数的最优值进行搜索,进而获得优化的最小二乘支持向量机预测模型。本文选取均方误

差(MSE)作为 PSO 算法的适应度函数,其表达式为

$$f_{mse} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (17)$$

式中, n 为训练样本个数; y_i 为实际值; $\hat{y}_i$ 为预测值。

在优化算法中,每一个粒子代表 LS-SVM 的 1 组参数,分别为惩罚因子 C 和核参数 σ^2 ,粒子所对应的适应度是该组参数下算法的性能,基于 PSO 的 LS-SVM 优化过程的步骤如下:

(1)初始化粒子种群,设定迭代次数、粒子维数、群体规模,随机产生 1 组参数作为粒子初始解空间位置和初始速度。

(2)用粒子对应的最小二乘支持向量机模型对测试样本进行预测,采用式(17)进行适应度评估。

(3)对每个粒子,比较它的经历过的最好的 P_{best} 的适应度值和群体经历过的最好位置 G_{best} 的适应度值,若比 P_{best} 、 G_{best} 好,则更新 P_{best} 、 G_{best} ,否则保持原来的数据。

(4)整个群体粒子计算后,判断是否满足终止条件,若不满足则粒子依照式(14)、(15)更新,产生新的粒子群,返回步骤(2)。如果满足最大迭代次数或结束条件,计算结束并输出计算结果。

4 装备故障预测实例验证及分析

4.1 样本获取及粒子群参数设置

基于上述 LS-SVM 的数学模型,本文利用某型通信电台功率放大器单元的输出功率的监测数据进行验证。在正常使用过程中,它的性能是逐渐衰减的,故监测到的数据总体成缓慢下降趋势,这是因为装备在长时间连续工作时,自身损耗不断增加所造成的。本文取该型通信电台监测值的 40 组数据,其中前 30 组数据作为训练样本,后 10 组数据作为测试样本(见表 1)。

PSO 中涉及参数设置:种群规模 $L = 60$, $c_1 = c_2 = 1.31$, $\omega = 1.08$,最大迭代 $t = 50$ 。

表 1 某型通信电台输出功率监测值后 10 组

时间/h	功率/W	时间/h	功率/W
750	124.23	875	123.93
775	124.15	900	123.93
800	124.11	925	123.81
825	124.05	950	123.77
850	124.02	975	123.76

4.2 仿真结果分析

将表 1 中的数据输入最小二乘支持向量机数学

模型进行预测,不同模型的预测分布结果如图 1 所示.




图 1 不同模型的预测分布

将获得的 BP、SVM、LS-SVM、PSO-LS-SVM 模型的预测值与实际值进行对比. 从结果对比可以看出, BP 模型运行时间比未优化的 SVM、LS-SVM 模型要短,但由于波动幅度有时明显增大,其误差值最大,未优化 SVM、LS-SVM 模型由于参数的选择采用交叉验证和人为试算的方法,所需运行时间较长. 而经 PSO 优化的 LS-SVM 模型不仅预测误差值小,而且运行时间最短,充分表明 PSO-LS-SVM 模型的有效性.

5 结束语

文中提出了在通信装备故障预测的应用方面的 PSO-LS-SVM 模型. 采用某型通信电台输出功率监测值作为实验数据,运用 PSO-LS-SVM 模型进行仿真实验,并与 BP、SVM、LS-SVM 模型相比,结果验证了该模型具有训练时间短、精度高等优点,在通信装备故障预测中的有效性和可行性,具有

较高的实用价值.

参考文献:

- [1] Vladimir N Vapnik. The Nature of Statistical Learning Theory Second Edition[M]. Berlin: Springer - Verlag, 2000.
- [2] Matteo Pardo, Giorgio Sberveglieri. Classification of electronic nose data with support vector machines[J]. Sensors and Actuators B: Chemical, 2005, 107(2): 730-737.
- [3] 张俊才,张静. 使用粒子群算法进行特征选择及对支持向量机参数的优化[J]. 微电子学与计算机, 2012, 29(7): 138-141.
- [4] Suykens J A K, Vandewalle J. Least squares support vector machine classifiers[J]. Neural Processing Letters, 1999, 9(3): 293-300.
- [5] 张军峰,胡寿松. 基于聚类和支持向量机的非线性时间序列预报[J]. 控制理论与应用, 2007, 24(1): 64-68.
- [6] Kennedy J, Eberhart R C. Particle swarm optimization [C]// Proceedings of IEEE International Conference on Neural Networks, Perth; IEEE, 1995: 1942-1948.
- [7] 朱凤明,樊明龙. 混沌粒子群算法对支持向量机模型参数的优化[J]. 计算机仿真, 2010, 27(11): 183-186.

作者简介:

李文元 男, (1964-), 副教授. 研究方向为通信装备保障与通信装备抗干扰.

闫海华 男, (1987-), 硕士. 研究方向为军事装备建设与发展.

姚宏杰 男, (1981-), 硕士. 研究方向为军事装备建设与发展.