

DOI:10.19651/j.cnki.emt.2106266

基于 LS-SVM 的矿井提升机故障预测^{*}

张梅 陈万利 许桃

(安徽理工大学电气与信息工程学院 淮南 232001)

摘要: 矿井提升机是矿井生产的“咽喉”,其可靠性对煤矿安全高效生产起着至关重要的作用,提升机故障预测是提高提升机可靠性的重要措施。针对传统提升机故障预测模型相对误差较大的问题,建立了基于最小二乘支持向量机的提升机故障预测模型,并利用采集到的提升机相关数据对模型进行训练,再对提升机的实时数据进行预测,以发现是否可能异常。实验结果表明,该模型的平均绝对百分比误差和均方误差分别为 1.130 1% 和 1.166 3,较小波神经网络预测模型更低,且运行时间更短,收敛速度更快。该预测方法可以提前准确地发现提升机故障,为矿井提升机预知维修提供重要依据。

关键词: 矿井提升机;故障预测;最小二乘;支持向量机

中图分类号: TD676 文献标识码: A 国家标准学科分类代码: 510.4030

Fault prediction of mine hoist based on LS-SVM

Zhang Mei Chen Wanli Xu Tao

(School of Electrical and Information Engineering, Anhui University of Science & Technology, Huainan 232001, China)

Abstract: Mine hoist is the throat of mine production, and its reliability plays an important role in safe and efficient production of coal mine. Hoist fault prediction is an important measure to improve the reliability of hoist. Aiming at the problem of large relative error of traditional hoist fault prediction model, this paper establishes a hoist fault prediction model based on least squares support vector machine. After training the model with the collected data of the hoist, the real-time data of the hoist are predicted to find out whether it is possible to be abnormal. The experimental results show that the average absolute percentage error and mean square error of the model are 1.130 1% and 1.166 3 respectively, which are lower than the wavelet neural network prediction model, and it has shorter running time and faster convergence speed. The prediction method can accurately find the fault of mine hoist in advance and provide an important basis for the predictive maintenance of mine hoist.

Keywords: mine hoist; failure prediction; least squares; support vector machine

0 引言

矿井提升机是现代煤矿进行生产和运输过程中关键机械设备。一旦提升机发生故障,工作人员无法进行快速诊断和及时维修,将会对整个矿山生产造成极大损失^[1]。因此如何提前预测提升机故障,对其安全可靠地运行具有十分重要的意义。

矿井提升机故障预测是在提升机发生故障之前根据其稳定运行状态总结规律,判断下一时刻提升机的运行状态是否正常的一种估计方法^[2]。故障预测的其他应用研究较多,常用的故障预测方法有灰色模型理论、支持向量机方法、神经网络方法和时间序列分析方法等^[3-6]。目前国内外

在提升机故障预测方面的研究较少,最典型的是王冬梅^[7]提出的小波神经网络故障预测,该算法结构简单,对输入参数精确度要求高,在实际使用中易过拟合,在多步时间序列预测时 MSE 值较大。

支持向量机(support vector machine, SVM)是一种有效机器学习技术,选用风险最小化原则,拥有着强大学习能力和高泛化程度,被广泛应用于数据分析、图像识别、模式识别、故障预测等分类和回归分析问题中^[8-9]。传统的 SVM 存在计算量大,运行速度慢等缺点。最小二乘支持向量机(LS-SVM)将最小二乘损失函数的思想运用到 SVM 的二次规划问题的不等式约束条件中,改进成最小二乘法的约束条件,并通过用二次方代替经验风险中偏差的一次

收稿日期:2021-04-01

*基金项目:国家自然科学基金项目(51874010)、安徽高校自然科学研究项目(KJ2020A0309)资助

方,与传统 SVM 算法相比减少了多个优化变量,大大减少了计算耗时和计算过程的冗杂度^[10 11]。

本文将 LS-SVM 应用到提升机故障预测中,利用实时数据预测提升机运行数据,将预测值与设定的阈值进行比较,不超出阈值直接输出预测结果,超出阈值则发出预警信号,为矿井提升机预知维修提供可靠依据。

1 LS-SVM 预测原理

基于 LS-SVM 的数据预测原理如图 1 所示。

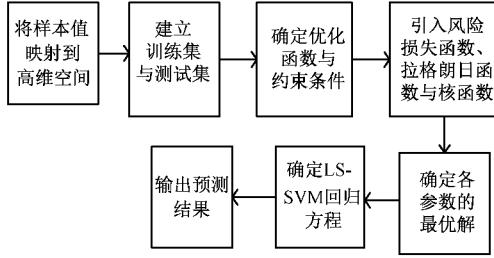


图 1 基于 LS-SVM 的预测模型原理

通过非线性的映射函数,把初始数据样本映射至相应高维特征空间 $\phi(x)$,同时在其中建立出最优函数:

$$f(x) = \omega\phi(x) + b \quad (1)$$

式中: $\phi(x)$ 为输入样本点从低维向高维的映射, ω 为样本权值系数, b 为偏移量,可以利用结构风险最优化原则,确定 ω 和 b 的最优解。

为了平衡 SVM 模型中的经验风险范围与复杂程度,引入损失函数:

$$R = C \frac{1}{n} \sum_{i=1}^n L_g(f(x_i), y_i) + \frac{1}{2} \|\omega\|^2 \quad (2)$$

$$L_g(f(x_i), y_i) = \begin{cases} 0, & |f(x) - y| < \epsilon \\ |f(x) - y| - \epsilon, & |f(x) - y| \geq \epsilon \end{cases} \quad (3)$$

式中: $L_g(f(x_i), y_i)$ 为损失函数; C 为惩罚系数,限制对超过误差的样本的惩罚程度,可以利用经验风险和置信区间的手段获得; $\|\omega\|^2$ 为控制模型的复杂度; ϵ 为损失系数。

引入松弛因子 ξ 和 ξ^* ,松弛因子目的是为了平衡寻找最优超平面和使得偏差量最小,则可转化为约束条件最小值问题:

$$f(x) = \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n \xi_i \quad (4)$$

同时:

$$\text{s. t. } \begin{cases} y_i - f(x_i) \leq \epsilon + \xi_i \\ f(x_i) - y_i \leq \epsilon + \xi_i^* \end{cases} \quad (5)$$

其中, $i=1,2,3,\dots,n$, ξ 为实际松弛变量, ξ^* 为估计松弛变量。

对于最小二乘的支持向量机,优化目标采用松弛因子的平方计算,同时将不等式约束变成等式约束,则优化问题变为:

$$f(x) = \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n \xi_i^2 \quad (6)$$

而约束条件则变为:

$$y_i = \omega\phi(x_i) + b + \xi_i, i=1,2,\dots,n$$

为了进一步求解优化情况,在对偶空间内引入拉格朗日函数,这样就把原问题转化成对单一参数也就是拉格朗日乘子 α_i 的求解问题,其拉格朗日函数为:

$$L(\omega, b, \xi_i, \alpha_i) = \frac{1}{2} \|\omega\|^2 + \frac{1}{2} C \sum_{i=1}^n \xi_i^2 - \sum_{i=1}^n \alpha_i \{ \omega\phi(x_i) + b + \xi_i - y_i \} \quad (7)$$

遵循结构风险最小化准则对公式中 $L(\omega, b, \xi, \alpha)$ 进行偏微分求导,有:

$$\begin{cases} \frac{\partial L}{\partial \omega} = 0 \Rightarrow \omega = \sum_{i=1}^n \alpha_i \phi(x_i) \\ \frac{\partial L}{\partial b} = 0 \Rightarrow \sum_{i=1}^n \alpha_i = 0 \\ \frac{\partial L}{\partial \xi} = 0 \Rightarrow C\xi_i = \alpha_i \\ \frac{\partial L}{\partial \alpha} = 0 \Rightarrow \omega\phi(x_i) + b + \xi_i - y_i = 0 \end{cases} \quad (8)$$

求解上述的线性方程组得到 b 和 α_i 的值,进而 ω 的值也已确定,最后求得 LS-SVM 的回归方程为:

$$f_{LS}(x) = \sum_{i=1}^n \alpha_i K(x, x_i) + b \quad (9)$$

对 LS-SVM 进行训练的回归函数为:

$$y_t = \sum_{i=1}^m \alpha_i K(x_i, x_t) + b \quad (10)$$

式中: $t=m+1, m+2, \dots, n$ 。

根据上式可得到第 $(n+1)$ 点的预测值以及一个新的样本:

$$y_{n+1} = \sum_{i=1}^{n-m} \alpha_i K(x_i, x_{n-m+1}) + b \quad (11)$$

$$x_{n-m+2} = \{x_{n-m-2}, x_{n-m+3}, \dots, x_n, \hat{x}_{n+k-1}\} \quad (12)$$

其中, \hat{x}_{n+k-1} 表示第 $(n+1)$ 时刻的预测值,依次类推可以预测 $(n+2)$ 、 $(n+3)$ 等时刻的值。

2 基于 LS-SVM 的提升机故障预测流程

基于 LS-SVM 的提升机故障预测步骤如下。

1) 确定提升机故障特征参数,进行数据预处理

矿井提升机故障监测涉及到的量很多,需要用到电流、电压、位移、温度、油压、钢绳拉力等多种参数^[12]。这些参数被提升机相应部位铺设的传感器监测采集上传,这些采集到的量含有干扰和噪声的信号,需要进行数据预处理,去除干扰与噪声,并将数据归一化。本文采用数据预处理方法依次为奇异值检验和归一化处理。

(1) 奇异值检验

为避免异常值影响训练模型的精确度,采用拉依达准

则处理数据,剔除无效数据组,具体过程如下。

设提升机数据采集的一个观测序列为 $\{x_1, x_2, \dots, x_n\}$, 则该序列的数据可以表述为:

$$d_j = 2x_j - (x_{j+1} - x_{j-1}) \quad (13)$$

式中: $j=2, 3, \dots, n-1$ 。

对于 n 各观测数据就可以得到 $(n-2)$ 个变化特征序列, 再由 d_j 计算序列变化的统计均值 \bar{d} 和均方差 δ_d :

$$\bar{d} = \sum_{j=2}^{n-1} \frac{d_j}{n-2} \quad (14)$$

$$\delta_d = \sqrt{\sum_{j=2}^{n-1} \frac{(d_j - \bar{d})^2}{n-3}} \quad (15)$$

则有:

$$q_i = \frac{|d_i - \bar{d}|}{\delta_d} \quad (16)$$

如果 $q_i > 3$, 则称 x_i 为奇异值, 应该舍去。

(2) 数据归一化处理

由于影响矿井提升机运行的各因素物理意义不同, 所参考的数据量纲也不一致, 无法直接共同处理。想要解决这一问题就意味着需要解决量纲不同对数据分析带来的影响, 本文采用区间值化法对有区别的数据进行归一化处理, 以此将数据按比例缩放特定区间, 避免数值之间的相互影响。这里选择极值法进行线性函数转化:

$$X_i(d) = \frac{X_i - \min X_i}{\max X_i - \min X_i} \times (0.9 - 0.1) + 0.1 \quad (17)$$

其中, $X_i(d)$ 为归一化处理后的数据, 映射区间为 $[0.1, 0.9]$; $i=1, 2, \dots, n$; X_i 为原始数据; $\max X_i$ 为数据样本中的最大值; $\min X_i$ 为数据样本中的最小值。

2) 建立样本训练集和测试集

给定一组特征数据点集:

$$A = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}^n \quad (18)$$

其中, x_i 表示给定的特征样本点, y_i 表示样本期望, n 代表的是更新样本库总和, 样本采集时间数的表示用 i 。取一段时间内矿井提升机各状态特征值数据序列, 把前 n 个数据当做训练样本, 后 $N-n$ 个当做测试样本, 以 m 为嵌入维数, 不宜过大也不宜过小, 有 $n > m > 1$, 确定输入和输出之间的映射联系。

3) 确定核函数

支持向量机游刃有余地处理各种非线类型的问题的能力是通过核函数功能发挥支撑的, 对待各异的问题选用合适的核函数才能实现非线性问题的映射解决^[13-14]。

本文采用径向基核函数, 径向基核函数在很多时候又被叫做高斯函数, 按照径向对称的标量完成运算。其表达式为:

$$K(x, x') = \exp(-\gamma \|x - x'\|^2) \quad (19)$$

x 表示核函数的中心, 被使用限制函数径向覆盖的范围用核参数 γ 代表, $K(x, x')$ 在中心点 x 的位置最大量, 随着 $\|x - x'\|$ 的增大, $K(x, x')$ 迅速减小为 0。

4) 初始化 LS-SVM 模型参数

LS-SVM 模型参数的初始化主要是对 α_i, b, C 等赋予随机的初始值, 利用核函数求解回归问题, 找到训练样本中的支持向量 x_i , 并求解得到 α_i 和 b 。

5) LS-SVM 模型训练

将数据训练集输入模型进行训练。

6) 数据预测

利用输入训练好的模型对数据测试集进行预测。

7) 模型评价

通过平均绝对百分比误差(MAPE)和均方根误差(MSE)进行预测精度的判断, 这是用于评估一个模型优劣的重要标准。

预测模型的平均绝对百分比误差为:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - y'_i|}{y_i} \times 100\% \quad (20)$$

其中, y_i 为实际值, y'_i 为预测值。

预测模型均方根误差为:

$$MSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2} \quad (21)$$

将得到的预测结果和实际结果输入预测评价模型中, 计算结果。

8) 实时预测提升机故障

利用确定好的模型对实际提升机数据进行预测, 将得到的预测值与设定的阈值进行比较, 不超出阈值直接输出预测结果, 超出阈值, 则发出预警信号。

3 实例分析

为了验证本文提出的基于 LS-SVM 的矿井提升机故障预测方法的准确性与可行性, 本文对矿井提升机的电动机温度进行实验仿真。

3.1 数据样本选择

本文采取某矿的主提升机电动机温度作为测试数据, 提升机运作 1 次加打包货物约需 1 h, 检测提升机运作的数据, 时间跨度 20 天, 数据采集间隔 1 h, 其数据容量为 481 组。每组数据除包含温度外, 还包含电机转速、电流、电压、有功功率、无功功率等 22 个参数变量。选取前 450 组的数据作为训练集样本, 后 31 组数据作为测试集样本。

3.2 数据处理

采用前面所描述的拉依达准则处理数据, 剔除无效数据组, 当 $q_i > 3$ 的时候, 该数据为异常值, 影响训练模型的精确度, 需要被及时剔除。

经拉依达准则处理后剔除 31 个异常数据组, 其原始电机温度样本数据和处理后的样本数据如图 2 和 3 所示。

将输入的 23 组变量利用主成分分析(PCA)方法进行降维, 得到 4 组新变量, 以代替原来 23 组变量。在不降低预测性能的情况下, 降低数据维度, 并尽可能保留原变量的数据内容, 新变量之间相互正交, 消除原变量的共线性问题。

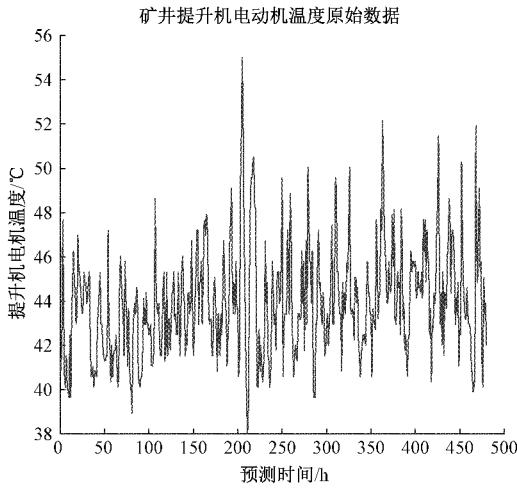


图 2 矿井提升机电动机温度数据样本

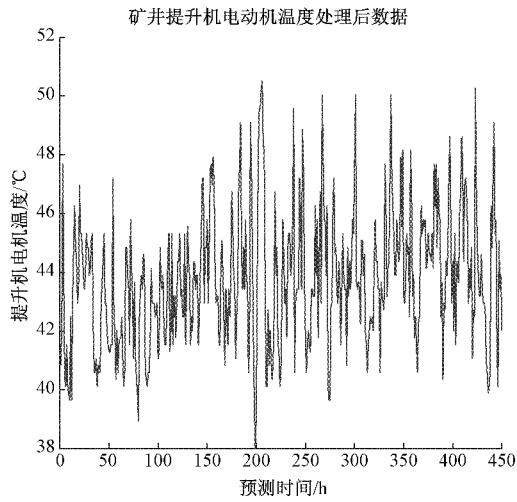


图 3 处理后的电动机温度数据

3.3 参数寻优

LS-SVM 的预测模型精确度极大程度受正则化参数 λ 和平方带宽 σ^2 影响。

正则化参数 λ 与惩罚系数 C 关系为:

$$\lambda = \frac{1}{C} \quad (22)$$

核参数 γ 与平方带宽 σ^2 关系为:

$$\gamma = \frac{1}{1 + \sigma^2} \quad (23)$$

本模型采用改进的网格搜索法寻找最优 λ 和 σ^2 , 网格搜索法采用二次寻优方式: 第 1 次设置 λ 和 σ^2 的初始范围, 采用粗略搜索设置较大步长确定最优参数范围; 第 2 次在最优范围内设置最小搜索步长精细寻优, 找到其最优参数^[15-16]。网格搜索法的寻优结果如图 4 所示。

网格搜索法优化后得到 λ 和 σ^2 分别为 0.43 与 6.06, MSE 值为 0.045。

3.4 预测结果分析

分别采用 LS-SVM 和小波神经网络对提升机温度进

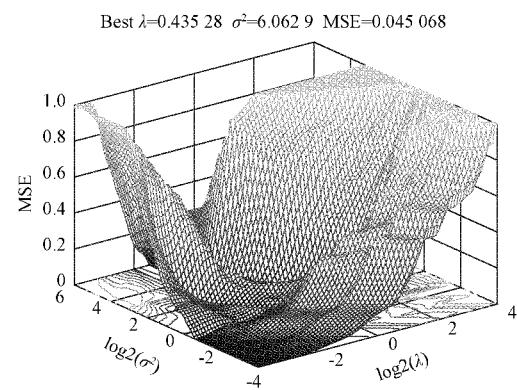


图 4 网格搜索法参数选择结果

行预测。LS-SVM 的模型参数设置为: 核函数采用径向基(RBF)核函数, 正则化参数 $\lambda = 0.43$ 和平方带宽 $\sigma^2 = 6.06$ 。小波神经网络的模型参数设置为: 隐藏层节点 $n = 12$, 输入层与隐藏层学习率为 0.01, 输出层与隐藏层学习率为 0.001, 迭代次数为 100。LS-SVM 和小波神经网络预测曲线如图 5 所示, 模型性能如表 1 所示。

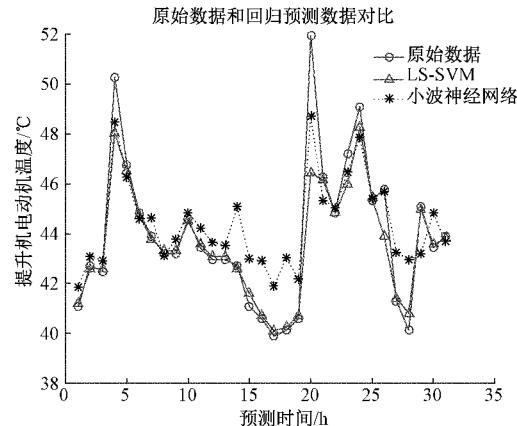


图 5 预测结果对比曲线

表 1 预测结果参数

性能指标	LS-SVM	小波神经网络
MAPE/%	1.130 1	2.899 3
MSE	1.166 3	1.574 4
拟合优度(R^2)	0.902 6	0.789 5
运行时间 t/s	1.071 1	2.143 1

由表 1 可知, LS-SVM 的 MSE 值和 MAPE 值分别为 1.166 3 和 1.130 1%, 明显优于小波神经网络的 1.574 4 和 2.899 3%。

由图 5 和表 1 可看出基于 LS-SVM 的提升机电动机温度预测, 精度明显优于小波神经网络, 且运行时间更短, 收敛速度更快。

4 结 论

针对矿井提升机的特点, 本文提出一种基于 LS-SVM

的故障预测方法,分析了该预测方法原理,给出了具体实现步骤,并对提升机电动机温度进行了实例分析。结果表明,本文所提出的故障预测方法要优于基于小波神经网络的提升机故障预测方法。需要指出的是,该预测方法的支持向量机核函数选择及各参数之间存在一个最优匹配,如果选择不恰当的参数设置可能会恶化其性能。

综上,利用本文提出的 LS-SVM 预测方法可以提前准确地发现提升机故障,减少检修反应时间,具有一定的可行性和实用价值。

参考文献

- [1] 高晓东. 矿井提升机故障类型及诊断技术研究[J]. 机械管理开发, 2020, 17(7): 136-139.
- [2] 赵宝宝. 煤矿提升机故障预警系统研究[J]. 机电工程技术, 2019, 48(6): 163-165.
- [3] LI J, JIANG S, LI M, et al. A fault diagnosis method of mine hoist disc brake system based on machine learning[J]. Applied Science, 2020, 10(5): 1768-1778.
- [4] 马海龙. 基于主元特征融合和 SVM 的轴承剩余寿命预测[J]. 工矿自动化, 2019, 45(8): 77-81.
- [5] 宫少琦, 张伟, 国明笛. 基于 FTA 和 SVM 优化算法的矿井提升机故障诊断方法研究[J]. 煤矿机械, 2017, 38(4): 180-183.
- [6] 宫文峰, 陈辉, 张美玲, 等. 基于深度学习的电机轴承微小故障智能诊断方法[J]. 仪器仪表学报, 2020, 41(1): 195-205.
- [7] 王冬梅. 基于小波神经网络的提升机液压站故障预测的研究[J]. 煤矿机械, 2014, 35(1): 228-229.
- [8] 戴钢, 王景成, 葛阳, 等. 城市小时级需水量的改进型引力搜索算法-最小二乘支持向量机模型预测[J]. 控制理论与应用, 2016(10): 95-100.
- [9] 史庆军, 戚常林, 杨松涛, 等. 基于改进 VMD 与 GS-SVM 的轴承故障诊断[J]. 电子测量技术, 2020, 43(21): 71-76.
- [10] 徐言沁, 李春祥. 基于优化组合核最小二乘支持向量机的脉动风速预测[J]. 上海大学学报(自然科学版), 2018, 24(4): 627-633.
- [11] 曾小钦, 侯正男, 庄圣贤, 等. 基于 LSSVM 和 GMM 的风电机组传动系统故障预测研究[J]. 可再生能源, 2019, 37(10): 1533-1538.
- [12] 常用根, 江帆, 陈潇. 矿井提升装备健康状态监测系统设计[J]. 工矿自动化, 2018, 44(2): 38-42.
- [13] 何怡刚, 李凯伟, 朋张胜, 等. 基于改进最小二乘支持向量机的 IGBT 模块键合线状态评估方法研究[J]. 电子测量与仪器学报, 2019, 33(9): 170-176.
- [14] 李帅, 王瑛, 薛占龙, 等. 基于 LS-SVM 的接地电阻监测数据回归预测方法[J]. 国外电子测量技术, 2019, 38(8): 19-22.
- [15] 叶永伟, 陆俊杰, 钱志勤, 等. 基于 LS-SVM 的机械式温度仪表误差预测研究[J]. 仪器仪表学报, 2016, 37(1): 57-66.
- [16] 曲健, 陈红岩, 刘文贞, 等. 基于改进网格搜索法的支持向量机在气体定量分析中的应用[J]. 传感技术学报, 2015, 28(5): 774-778.

作者简介

张梅,工学硕士,副教授,主要研究方向为物联网应用、智能控制。

E-mail: xwz098@163.com