

文章编号: 1671-6612 (2025) 04-578-06

# 基于支持向量机的 地铁车辆空调压缩机性能评估方法

崔德安

(中车南京浦镇车辆有限公司 南京 210000)

**【摘要】** 地铁车辆空调压缩机故障频发, 导致空调压缩机的维修成本居高不下, 为了减小压缩机维修维护成本, 需要对压缩机的维修维护策略进行优化, 而对空调压缩机性能进行准确评估是维修维护策略优化研究的基础。为此, 提出了基于支持向量机的地铁车辆空调压缩机性能评估方法。首先对不同服役时间的空调压缩机进行试验, 采集压缩机的振动和声发射信号等数据, 对振动数据和声发射数据集进行归一化预处理后, 作为评估模型的输入数据, 基于支持向量机搭建地铁车辆空调压缩机的性能评估模型, 采用振动数据和声发射数据对模型进行训练并确定模型的参数, 测试结果表明, 模型性能评估精度较高。提出的基于支持向量机的地铁车辆空调压缩机性能评估结果可作为压缩机维修维护策略优化的理论依据。

**【关键词】** 地铁车辆; 空调压缩机; 支持向量机; 性能评估方法

中图分类号 U224.4 文献标志码 A

## Performance Evaluation Method of Air Conditioning Compressor for Metro Vehicle Based on Support Vector Machine

Cui De'an

(CRRC Nanjing Puzhen Vehicle Co., Ltd, Nanjing, 210000)

**【Abstract】** Frequent failures of air-conditioning compressors in subway vehicles have resulted in high maintenance costs. To reduce these costs, it is essential to optimize the maintenance strategies for compressors. Accurate performance evaluation of air-conditioning compressors forms the foundation for optimizing these strategies. To address this, a performance evaluation method for subway vehicle air-conditioning compressors based on support vector machines (SVM) is proposed. First, experiments were conducted on compressors with varying service durations to collect vibration and acoustic emission signal data. After normalizing the collected vibration and acoustic emission data, they were used as input for the SVM-based performance evaluation model. The model was trained using the vibration and acoustic emission data, and its parameters were determined. Test results demonstrate that the model achieves high evaluation accuracy. The proposed SVM-based performance evaluation results can serve as a theoretical basis for optimizing the maintenance strategies of compressors.

**【Keywords】** Subway vehicles; Air conditioning compressor; Support Vector Machine; Performance evaluation methods

## 0 引言

空调压缩机在空调制冷工作过程中起驱动压缩制冷剂的作用, 空调发生的故障一半以上由空调

压缩机引起, 故每次空调发生故障都会替换压缩机。这样一来, 其定期维护和故障检修的成本较高, 准确判断压缩机的性能, 了解其运行状态, 及时发

现性能衰退较大的设备并更换，不仅能够提高运营效率，降低维护的金钱时间成本，保证空调正常工作，还可以降低当前维修维护模式的经济损失。一般来说，使用年限越长的压缩机性能越差。

国内外学者对空调压缩机检测领域研究较少，王崇亮<sup>[1]</sup>针对符合国家标准 GB/T 5773-2004 的压缩机性能试验系统，提出了基于 BP 神经网络的故障检测及可靠性分析方法。王腾<sup>[2]</sup>提出一种基于矢量空间分解的可选故障检测机制，并可实现将矢量空间分解故障检测方法扩展到具有不同状态、模型预测控制策略和运行故障类型的多维压缩机故障检测中。空调压缩机因为拆卸不易，所以很难对内部零件进行实验检测，故一般直接采集压缩机运行的振动以及噪声信号。随着机器学习领域研究的深入，越来越多的智能学习方法被用于检测领域，但由于神经网络算法有随机性，训练结果通常不可复制，而且神经网络的收敛速度慢，并不适合快速、稳定的诊断工作<sup>[3]</sup>。

支持向量机以结构风险最小化原理为基础，泛化能力比较强，能够在很大程度上避免过拟合问题。

Bensaoucha 等<sup>[4]</sup>使用支持向量机对三相异步电动机匝间短路故障进行有效的检测和定位，并对所有分类器（SVM、MLPNN、RBFNN 和 ELM）进行了测试，结果表明 SVM 的效果更好。Cai 等<sup>[5]</sup>研究了一种基于优化变分模分解和支持向量机的智能检测算法，在恶劣条件下也有很好的检测效果。

本文提出了基于支持向量机的空调压缩机性能评估方法，利用三个位置的振动传感器获取压缩机运行时的关键振动数据，将数据用于模型训练后便可实现压缩机的性能诊断，实验结果证明基于支持向量机的空调压缩机性能评估方法对不同运行年份都有良好的辨识度，是一种实用的性能评估方法。

## 1 基于 SVM 的故障检测方法

### 1.1 SVM 简介

支持向量机是一种被广泛使用的二分类方法，它使用的数学模型是在特征空间上距离间隔最大的线性分类器<sup>[6]</sup>。基于支持向量机的非线性分类方法的基本思想如下。

对于非线性分类问题，通过使用非线性变换即可将其转化为更高维空间的线性分类问题<sup>[7]</sup>。

对于输入的训练数据集  $T=\{(X_1,Y_1),(X_2,Y_2),\dots,(X_m,Y_m)\}$ ，其中输入的特征向量  $X_i \in R^n$ ，标签  $Y_i \in \{-1,1\}$ ， $i=1,2,\dots,m$ ，得到输出的分离超平面和分类决策函数。其步骤可总结为<sup>[8]</sup>：

(1) 超平面通过式 (1) 的解来确定，选取适当的核函数  $K(X,Z)$  和惩罚参数  $C>0$ ，构造并求解凸二次规划问题：

$$\min \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N a_i a_j Y_i Y_j K(X_i, X_j) - \sum_{i=1}^N a_i \quad (1)$$

式中： $a_i Y_i$  的为 0， $0 \leq a_i \leq C$ ， $i=1,2,\dots,N$ ，得到最优解  $\alpha^*$ ；

(2) 选择  $\alpha^*$  的一个分量  $\alpha_j^*$  满足条件  $0 < \alpha_j^* < C$ ，计算式 (2)：

$$b^* = Y_j - \sum_{i=1}^N a_i^* Y_i K(X_i, X_j) \quad (2)$$

(3) 通过式 (3) 构造分裂决策函数。

$$f(x) = \text{sign} \left( \sum_{i=1}^N a_i^* Y_i K(X, X_i) + b^* \right) \quad (3)$$

### 1.2 性能评估方法介绍

如图 1 所示为故障检测方法示意图，示意图分为构建模型与诊断性能两部分。




图 1 性能评估方法示意图

Fig.1 Schematic diagram of the performance evaluation method

阶段 1：构建模型，首先将采集到的数据分为训练集和测试集，数据包括不同使用年份压缩机的运行数据，包括振动数据和噪声数据，然后对数据进行处理用于检测模型的训练。

阶段 2：诊断性能，将测试集的数据进行处理，将处理完的数据输入到阶段 1 构建的模型进行状态判别，将判别结果与实际结果进行对比，输出准确率以评价模型的性能。

本实验在构建性能评估模型的过程中，训练 SVM 模型时使用了 Python 中的 SVM 模型进行训练，最大迭代次数选择不受限制，混洗数据时使用

np.random 作为伪随机数发生器的种子，采用启发式收缩方式，寻找最优核函数和惩罚系数。

### 2 实验设备简介及数据采集

实验设备主要分为四部分：试验台、压缩机、传感器以及数据记录设备。使用压缩机作为实验对象，利用性能试验台驱动不同使用年限压缩机在不同工作频率上进行工作。使用振动传感器以及噪声传感器采集实验数据。

压缩机选择地铁车辆使用的卧式涡旋压缩机，如图 2 所示，工作频率为 30-100Hz，额定工作频率为 60Hz。在现场拆下了不同使用年限的机器进行实验，分别为新机、3 年、5 年、7 年、10 年。




图 2 地铁车辆用的卧式涡旋压缩机

Fig.2 Horizontal scroll compressor for subway vehicles

试验台使用购买的电动压缩机性能试验台，试验台正面主要有四部分组成，如图 3 所示，分别为控制台、冷媒输入口、运行状态显示屏和压缩机安装间。



图 3 电动压缩机性能试验台正面

Fig.3 Front view of the electric compressor performance test bench

实验首先要将压缩机在试验台中安装好，在压缩机的头部、中部和上部放置振动传感器 1、2、3

号，测量振动信号如图 4 所示，同时在压缩机旁悬吊放置声音传感器，测量压缩机产生的噪声。通过试验台上的控制计算机将回流率等压缩机参数设置好，并且给定工作频率后，启动试验台，压缩机开始工作，等待较长运行时间后压缩机稳定，各项运行指标达到要求，再经过稳定观察时间开始采集数据，受数据记录设备限制，一次只采集 15 分钟并多次采集。




图 4 振动传感器位置图

Fig.4 Diagram of vibration sensor placement

在采集运行数据的过程中，利用传感器采集的数据包括振动数据和噪声数据，利用实验台计算机记录的数据包括回流率、压缩机电流电压、制冷量等数据，对应传感器型号、量程和精度如表 1 所示。考虑到外界工作环境采集信号的难易程度，使用振动数据与噪声数据作为模型的特征数据。

表 1 传感器参数

Table 1 Sensor parameters

传感器类型	型号	量程	精度
噪声传感器	INV9206	-1000~1000g	0.1%
振动传感器	B01Y31	20~146dB	±0.5dB
电流、电压传感器	WT500	0.5~40A& 15~1000V	0.1%

### 3 数据介绍

实验时的采样频率为 8200Hz，采样时间平均分为两段，总时间为 30 分钟，采样通道为 8，通道 1、2、3 为一号振动传感器的 x、y、z 方向，通道 4、5 为 2 号传感器的 x、y 方向，通道 6、7 为 3 号传感器的 x、y 方向，通道 8 为声音传感器的信号，每台设备根据工作频率不同分为 5 个工况，分

别为 30、45、60、75、90Hz。图 5 为新机在 30Hz 时的通道 1 原始数据，图 6 是其在 30Hz 通道 8 的原始数据。




图 5 新机 30Hz 通道 1

Fig.5 Channel 1 at 30Hz for new compressor




图 6 新机 30Hz 通道 8

Fig.6 Channel 8 at 30Hz for new compressor

为进一步分析不同使用年限压缩机的性能变化情况，使用峭度来评价振动信号与噪声信号，峭度与转速、尺寸、载荷等无关，对冲击信号敏感，适用于早期表面损伤类故障的诊断。峭度是无量纲因子，定义如式（4）所示。不同年限压缩机振动和噪声的峭度变化如图 7、图 8 所示。同时对不同使用年限压缩机的电流电压参数进行对比，如图 9 所示。

$$K = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^4}{\left( \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} \right)^4} \quad (4)$$

式中： $x_i$  为时域波形离散序列点对应的振动幅值； $\bar{x}$  为离散序列的平均幅值； $n$  为离散序列点数。




图 7 振动信号峭度变化

Fig.7 Variation of Kurtosis in Vibration Signal




图 8 噪声信号峭度变化

Fig.8 Variation of Kurtosis in Noise Signal

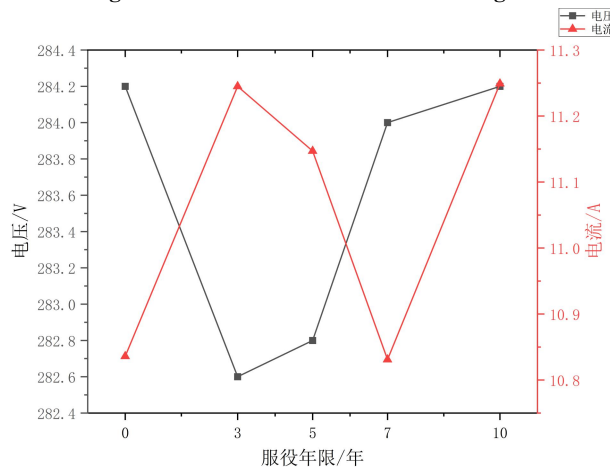


图 9 电流与电压参数变化

Fig.9 Variation of Current and Voltage Parameters

随着服役年限的增加，振动信号的峭度呈现先增大后减小的变化趋势，噪声信号的峭度呈现先减小后增加的变化趋势。在压缩机使用年限七年之前，其电流和电压参数呈现相反的变化趋势，总功耗维持在一定范围内。压缩机使用年限达到十年

后,压缩机总功耗有较明显的上升趋势,表明其性能已明显退化。

为了更好地训练分类器模型,需要给数据正确的标签。在文中,使用五个类型的分类:新机、3年、5年、7年和10年。分别用0-4五个数字表示。

### 4 实验结果与分析

由于原始数据集非常庞大,所以随机选择了部分数据用来训练模型,从每个年份随机选择700数据共3500个,数据集被随机打乱,分为训练数据集和测试数据集,其中80%用于训练共2800个,其余20%用于测试共700个。因为数据的范围大小不同,因此对所有数据都进行归一化处理<sup>[9]</sup>,如式(5)所示。

$$x = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (5)$$

为了反应性能评估模型的正确率,引入正确率 $Acc^{[10]}$ ,其定义为式(6)。

$$Acc = \frac{T}{S} \times 100\% \quad (6)$$

式中: $T$ 为分类正确的测试数据的数量; $S$ 为总样本数。对用于训练SVM模型的超参数包括核函数和惩罚参数 $C$ 分别取不同的值,对比正确率,从而得到最适合的超参数<sup>[11]</sup>。

表2 核函数和C的取值

Table 2 Values of kernel functions and parameter C

超参数	取值
核函数	'sigmoid', 'linear', 'poly', 'rbf'
C	0.01, 0.1, 1, 10, 100

在惩罚参数默认值为1的情况下,对比不同的核函数的结果如表3所示。

表3 不同核函数的正确率

Table 3 Accuracy of different kernel functions

核函数	正确率
sigmoid	18.14%
linear	38.57%
poly	99.71%
rbf	100%

选择径像核函数作为核函数,对比不同惩罚参数C的结果如表4所示。

表4 不同惩罚参数的正确率

Table 4 Accuracy with different penalty parameters

惩罚参数	正确率
0.01	18.14%
0.1	93.86%
1	100%
10	100%
100	100%

C越大,对分类错误的时候惩罚越大,训练集全分对的概率越大,从而对训练集验证时准确率很高,这样对训练集测试时准确率很高,但泛化能力会相应变弱,C值小,对分类错误的惩罚减小,允许分类时犯错误,因此泛化能力会相应变强<sup>[12-16]</sup>,所以综合来说,将模型惩罚参数选择1。

为了缩短模型训练时间,故减小随机选取的数据量,在惩罚参数为1,核函数为径像核函数的情况下,通过对比正确率可以发现,当数据选取量为2500的时候,模型正确率即可达到100%。

表5 不同数据选取量的正确率

Table 5 Accuracy with different data selection quantities

总选取数据量	正确率
500	95%
1000	98.5%
1500	99.67%
2000	99.75%
2500	100%
3000	100%

### 5 结论

针对地铁车辆空调压缩机故障频发、维修成本高昂的问题,本文基于支持向量机(SVM)算法构建了一种地铁空调压缩机性能评估方法,通过不同使用年限的压缩机进行数据采集,构建压缩机的性能退化数据集,对SVM模型的超参数进行优化,获得了评估效果更优的模型。结果表明,该模型能够准确的区分不同服役年限的压缩机,为地铁空调压缩机的状态监测与维护优化提供了重要参考。

本文模型试验所涉及的压缩机使用年限跨度较大,试验工况相对单一。未来的研究可尝试获取更复杂工况下的适用数据,或引入噪声干扰以提升模型的鲁棒性。同时,可对压缩机进行全寿命周期试验,以全面获取其整个寿命周期内的退化数据,

进一步构建完整的地铁车辆空调压缩机退化模型。

#### 参考文献:

- [1] 王崇亮.压缩机性能试验系统的故障检测及可靠性研究[D].上海:上海交通大学,2017.
- [2] 王腾.多维感应空调压缩机的矢量空间模型预测故障检测[J].信息技术,2020,44(03):44-49.
- [3] Hao MA, Feng DING, Yan WANG. A novel multi-innovation gradient support vector machine regression method[J]. ISA TRANSACTIONS, 2022,130: 343-35.
- [4] Bensaoucha SADDAM, Youcef BRIK, Sandrine MOREAU, et al. Induction machine stator short-circuit fault detection using support vector machine[J]. COMPEL-THE INTERNATIONAL JOURNAL FOR COMPUTATION AND MATHEMATICS IN ELECTRICAL AND ELECTRONIC ENGINEERING, 2021,40(3):373-389.
- [5] Xuerong CAI, Rong-Jong WAI. Intelligent DC Arc-Fault Detection of Solar PV Power Generation System via Optimized VMD-Based Signal Processing and PSO-SVM Classifier[J]. IEEE JOURNAL OF PHOTOVOLTAICS, 2022,12(4):1058-1077.
- [6] Anderson ARA, Mateus MAIA, Francisco LOUZADA, et al. Regression random machines: An ensemble support vector regression model with free kernel choice [J]. Expert Systems with Applications, 2022, 202: 117107-117107.
- [7] Wunna TUN, Johnny Kwok-Wai WONG, Sai-Ho LING. Hybrid Random Forest and Support Vector Machine Modeling for HVAC Fault Detection and Diagnosis[J]. SENSORS, 2021,21(24):8163.
- [8] Lei YAO, Zhanpeng FANG, Yanqiu XIAO, et al. An Intelligent Fault Diagnosis Method for Lithium Battery Systems Based on Grid Search Support Vector Machine[J]. ENERGY, 2021,214.
- [9] Hongshan ZHAO, Yufeng GAO, Huihai LIU, et al. Fault diagnosis of wind turbine bearing based on stochastic subspace identification and multi-kernel support vector machine[J]. 现代电力系统与清洁能源学报(英文), 2019,(2):350-356.
- [10] Min-Chan KIM, Jong-Hyun LEE, Dong-Hun WANG, et al. Induction Motor Fault Diagnosis Using Support Vector Machine, Neural Networks, and Boosting Methods[J]. SENSORS, 2023,23(5).
- [11] Shuiguang TONG, Zilong FU, Zheming TONG, et al. Fault diagnosis for gearboxes based on Fourier decomposition method and resonance demodulation[J]. 浙江大学学报(英文版)A辑:应用物理与工程,2023, 24(5):404-418.
- [12] Zahra ARASTE, Ali SADIGHI, Mohammad JAMIMOGHADDAM. Fault Diagnosis of a Centrifugal Pump Using Electrical Signature Analysis and Support Vector Machine[J]. JOURNAL OF VIBRATION ENGINEERING & TECHNOLOGIES, 2023,11(5): 2057-2067.
- [13] Weiwei HUO, Weier LI, Chao SUN, et al. Research on Fuel Cell Fault Diagnosis Based on Genetic Algorithm Optimization of Support Vector Machine[J]. ENERGIES, 2022,15(6):2294-2294.
- [14] Haiyang PAN, Haifeng XU, Jinde ZHENG, et al. Non-parallel bounded support matrix machine and its application in roller bearing fault diagnosis[J]. INFORMATION SCIENCES, 2023,624:395-415.
- [15] Xuezhen CHENG, Dafei WANG, Chuannuo XU, et al. Sensor Fault Diagnosis Method Based on alpha-Grey Wolf Optimization-Support Vector Machine[J]. COMPUTATIONAL INTELLIGENCE AND NEUROSCIENCE, 2021,2021.
- [16] Mingliang CUI, Youqing WANG, Xinshuang LIN, et al. Fault Diagnosis of Rolling Bearings Based on an Improved Stack Autoencoder and Support Vector Machine[J]. IEEE SENSORS JOURNAL, 2021,21(4): 4927-4937.