

# Journal of System Simulation

---

Volume 33 | Issue 6

Article 13

---

6-23-2021

## Fault Diagnosis of Mechanical Equipment Based on GA-SVR with Missing Data in Small Samples

Jingjing Wei

*Business School, University of Shanghai for Science and Technology, Shanghai 200093, China;*

Qinming Liu

*Business School, University of Shanghai for Science and Technology, Shanghai 200093, China;*

Chunming Ye

*Business School, University of Shanghai for Science and Technology, Shanghai 200093, China;*

Guanlin Li

*Business School, University of Shanghai for Science and Technology, Shanghai 200093, China;*

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>

 Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

---

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

---

# Fault Diagnosis of Mechanical Equipment Based on GA-SVR with Missing Data in Small Samples

## Abstract

*Abstract:* In view of the equipment fault diagnosis with small and missing sample data, a *method of missing data filling based on support vector regression optimized by genetic algorithm is proposed to improve the accuracy of equipment fault diagnosis.* The support vector regression optimized by genetic algorithm was trained by other data values of missing data, and univariate prediction results were obtained. *The training set was reconstructed through correlation analysis,* so as to obtain the multivariate prediction results. *Dynamic weights were established to combine univariate prediction results and multivariate prediction results to fill in the missing data.* The complete data is taken as the input, and the equipment fault is diagnosed by support vector machine. Example analysis shows that the method proposed in this paper has a high fault diagnosis accuracy.

## Keywords

fault diagnosis, small sample, missing data, support vector machine, dynamic weight, combination prediction

## Recommended Citation

Wei Jingjing, Liu Qinming, Ye Chunming, Li Guanlin. Fault Diagnosis of Mechanical Equipment Based on GA-SVR with Missing Data in Small Samples[J]. Journal of System Simulation, 2021, 33(6): 1342-1349.

# 基于 GA-SVR 的小样本数据缺失下的设备故障诊断

位晶晶, 刘勤明, 叶春明, 李冠林

(上海理工大学 管理学院, 上海 200093)

**摘要:** 针对小样本数据缺失下的设备故障诊断问题, 提出基于遗传算法优化支持向量回归的缺失数据填补方法, 以改善设备故障诊断效果。利用缺失数据所属变量的数据, 训练遗传算法优化的支持向量回归, 得到单变量预测结果; 通过相关性分析重构训练集, 获得多变量预测结果。建立动态权重将单变量预测与多变量预测的结果相组合, 对缺失数据进行填补。将完整的数据作为输入, 利用支持向量机对设备进行故障诊断。实例分析表明, 所提出的方法具有较佳的故障诊断效果。

**关键词:** 故障诊断; 小样本; 数据缺失; 支持向量机; 动态权重; 组合预测

中图分类号: TP29; TP391 文献标志码: A 文章编号: 1004-731X (2021) 06-1342-08

DOI: 10.16182/j.issn1004731x.joss.20-0046

## Fault Diagnosis of Mechanical Equipment Based on GA-SVR with Missing Data in Small Samples

Weijingjing, Liu Qinming, Ye Chunming, Li Guanlin

(Business School, University of Shanghai for Science and Technology, Shanghai 200093, China)

**Abstract:** In view of the equipment fault diagnosis with small and missing sample data, a method of missing data filling based on support vector regression optimized by genetic algorithm is proposed to improve the accuracy of equipment fault diagnosis. The support vector regression optimized by genetic algorithm was trained by other data values of missing data, and univariate prediction results were obtained. The training set was reconstructed through correlation analysis, so as to obtain the multivariate prediction results. Dynamic weights were established to combine univariate prediction results and multivariate prediction results to fill in the missing data. The complete data is taken as the input, and the equipment fault is diagnosed by support vector machine. Example analysis shows that the method proposed in this paper has a high fault diagnosis accuracy.

**Keywords:** fault diagnosis; small sample; missing data; support vector machine; dynamic weight; combination prediction

## 引言

许多大型设备复杂度在随着科学技术的发展而越来越高, 对于设备的可靠性和安全性的要求也越来越高。因此, 对设备进行准确及时的故障诊断有着重要意义。对于设备的故障诊断问题, 国内外学者已经做出了大量的研究。

文献[1-2]提出将改进的 RBF 神经网络应用于

设备故障诊断与识别, 实验说明此方法能够有效提高故障诊断准确性和监测系统的实用性。王彬等<sup>[3]</sup>建立了基于 BP 神经网络的变压器故障诊断, 仿真实验表明, BP 神经网络能够有效运用于变压器的故障诊断领域中。但是基于神经网络的故障诊断需要足够量的故障样本数据, 不适用于小样本数据的设备故障诊断。

支持向量机(Support Vector Machines, SVM)

收稿日期: 2020-01-15 修回日期: 2020-03-17

基金项目: 国家自然科学基金(71840003, 71471116); 上海市自然科学基金(19ZR1435600)

第一作者: 位晶晶(1994-), 女, 硕士生, 研究方向为设备维护。E-mail: 2388208985@qq.com

因所需样本量少和模型精度高等优点被广泛应用于设备的故障诊断中<sup>[4]</sup>。但 SVM 的关键参数对其性能有着较大影响, 因此需对其关键参数进行优化。卢向华等人提出一种利用改进人工鱼群算法优化 SVM 的变压器故障诊断方法, 引入柯西变异对人工鱼群算法进行改进, 然后利用改进后的人工鱼群算法优化 SVM 参数, 获得更高的故障诊断正确率<sup>[5]</sup>。Huang 和 Fei 等<sup>[6-7]</sup>使用遗传算法优化的 SVM(GA-SVM)模型进行设备故障诊断, 该模型能够以较高的准确度和较好的泛化能力确定 SVM 最优参数。Yang 等<sup>[8]</sup>提出了一种利用蚁群算法来优化 SVM 故障分类模型, 验证了该模型的有效性。卢亚洲等<sup>[9]</sup>提出粒子群优化 SVM (PSO-SVM) 方法应用于提升机设备的故障诊断, 表明了 PSO-SVM 的故障诊断准确率高且响应速度快。Zhang 等<sup>[10]</sup>将 SVM 与改进的帝国主义竞争算法(IICA)相结合, 对油浸变压器进行故障诊断, 结果表明, 该模型是一种有效的诊断方法。

针对设备的故障诊断, 目前大多数的研究都是在完整样本数据的情况下进行的。但在设备的运行过程中, 可能由于设备故障或人为原因造成样本数据的缺失, 对设备的故障诊断准确率影响较大。

Zhang 等<sup>[11]</sup>针对缺失数据, 提出了一种混合高斯输出(MT-DBNMG)的在线非归责推理方法进行故障检测和识别, 并通过实例证明该方法能准确识别故障。陈嘉宁等<sup>[12]</sup>针对变压器的故障诊断中监测数据缺失问题, 利用改进 k-最邻近和多分类 SVM 进行循环迭代。通过实例表明, 此方法可以有效减少数据缺失对变压器故障诊断准确率的影响。蒋少华等<sup>[13]</sup>针对密闭鼓风炉故障诊断中特征值缺失问题, 利用案例推理技术的相似度测量填补缺失特征值。结果表明, 该方法可以有效进行数据填补, 能够得到较高的诊断正确率。吴健飞等<sup>[14]</sup>针对缺失数据下的设备健康预测问题, 提出灰色启发式算法填补样本中的缺失数据。通过案例分析验证该方法对缺失数据填补的有效性。

此外, 针对小样本数据缺失下的故障诊断也

有一定量的研究。Liu 等<sup>[15]</sup>针对小样本数据缺失、专家知识匮乏情况下太阳能辅助热泵的故障诊断问题, 提出基于 BP 神经网络和最大似然估计的贝叶斯网络参数学习方法, 利用 BP 神经网络对缺失数据进行填补, 并通过仿真验证其方法的有效性。陈强强等<sup>[16]</sup>针对故障样本不足且存在缺失数据的故障诊断问题, 提出一种系统化的专家先验概率评估方法, 对故障样本中的缺失数据利用多重插补法进行概率插补, 并将其方法应用于大型桥式起重机的故障诊断, 验证了该方法的可靠性。Chen 等<sup>[17]</sup>针对完备样本量过小的故障诊断问题, 提出一种基于迁移学习的缺失数据故障诊断方法, 通过建立合适的迁移学习机制, 提高故障诊断的准确性, 并利用数据验证了此方法的有效性。

小样本数据缺失的情况不仅会加大数据分析的难度, 而且对设备故障诊断准确率影响较大。现有的针对数据缺失情况下的故障诊断大多需要大量的故障数据, 才能得到较为理想的诊断效果, 而对于小样本数据缺失下的故障诊断研究较少且不易获得理想的结果。由此, 本文利用支持向量回归(Support Vector Regression, SVR)预测所需样本较少的特性, 提出一种基于遗传算法优化支持向量回归(GA-SVR)的小样本数据缺失填补方法, 以改善设备故障诊断效果, 并通过仿真实验验证此方法的有效性与优越性。首先利用缺失数据所属变量的其他数据值, 对 GA-SVR 进行训练, 得到单变量预测结果; 同时, 通过相关性分析重构训练集, 利用与含缺失数据的变量相关变量的数据值, 对 GA-SVR 进行训练, 得到多变量预测结果。然后, 建立动态权重将单变量预测结果和多变量预测结果进行组合, 对缺失数据进行填补。最后, 将完整的数据作为输入, 利用 SVM 对设备进行故障诊断。

## 1 遗传算法优化支持向量回归(GA-SVR)

支持向量机(SVM)是 Vapnik 等<sup>[18]</sup>提出的一种

学习方法，而支持向量回归(SVR)是将 SVM 应用于解决回归问题。SVR 的基本理论是以非线性变换的方式将数据集映射到一个高维空间，并在该空间进行回归，拟合出一个连续函数，使得损失函数最小<sup>[19]</sup>。

SVR 中常用的核函数有线性核函数、高斯径向基核函数(RBF)以及多项式核函数等<sup>[20]</sup>，本研究选择最为常用的 RBF 核函数，其数学关系表达式为

$$K(x_1, x_2) = \exp\left(-\frac{\|x_1 - x_2\|^2}{\sigma^2}\right) \quad (1)$$

其中  $\sigma > 0$  是核函数宽度因子，是核函数中的关键参数，对 SVR 的预测效果有着重要影响。

由于小样本数据缺失对诊断结果影响较大，本研究拟利用支持向量回归 SVR 对缺失数据进行拟合。但 SVR 的惩罚因子  $C$ 、核函数参数  $\sigma$  和损失系数  $\varepsilon$  对 SVR 拟合精度影响较大，本研究采用遗传算法 GA 对 SVR 关键参数进行优化，建立基于 GA-SVR 的缺失数据填补模型，填补后的完整数据通过 SVM 进行设备的故障诊断。

基于 GA-SVR 数据缺失下的设备故障诊断流程如图 1 所示。

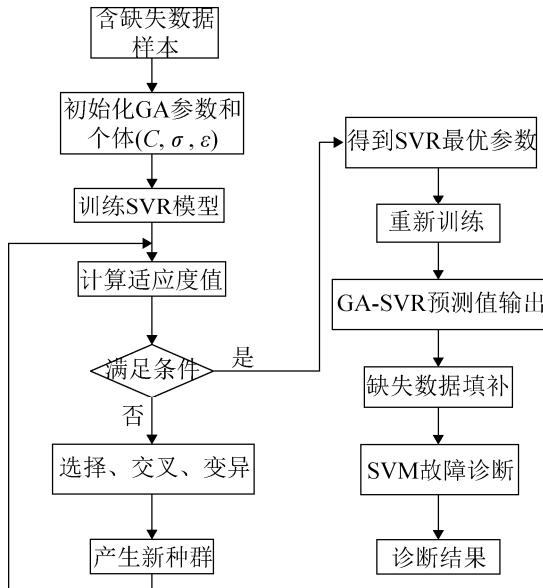


图 1 基于 GA-SVR 数据缺失下的设备故障诊断  
Fig. 1 Device fault diagnosis based on GA-SVR data missing

具体流程：

step 1：对含缺失数据的样本进行预处理，将与缺失数据同一属性的其他时刻点的监测数据划分为训练集与测试集；

step 2：初始化 GA 参数和 SVR 关键参数  $C$ 、 $\sigma$  和  $\varepsilon$ ，一组( $C, \sigma, \varepsilon$ )则表示 GA 算法中的一个个体；

step 3：为了评估 GA 选择 SVR 参数的优劣，采用  $K$  折交叉验证方式，将  $K$  次均方根误差的均值作为个体的适应度值，其计算公式为

$$F = \frac{1}{K} \sum_{i=1}^K \sqrt{\frac{1}{n} \sum_{j=1}^n (y_j - \hat{y}_j)^2} \quad (2)$$

step 4：判断是否满足终止迭代的条件，若不满足将进行选择、交叉、变异，产生新种群，返回 step3 继续迭代；

step 5：迭代结束后得到 SVR 参数( $C, \sigma, \varepsilon$ )的最优值，将最优参数代入 SVR 中重新训练，得到预测值。；

step 6：将预测值代入缺失数据进行填补，得到完整的小样本数据。

step 7：将数据填补后的完整数据划分训练集与测试集，利用 SVM 进行分类，得到设备的故障诊断结果。

## 2 基于 GA-SVR 的动态权重组合预测填补

### 2.1 基于 GA-SVR 的单变量预测填补

对设备运行状态的监测数据多为时间序列<sup>[21]</sup>，即按照时间顺序由多个传感器获得的一系列监测值  $X_t^q$ ，其中  $t(t=1, 2, \dots, n)$  代表第  $t$  个时刻点， $q(q=1, 2, \dots, m)$  代表第  $q$  个传感器， $X_t^q$  则意味着在第  $t$  个时刻点时第  $q$  个传感器的监测值。

利用 GA-SVR 对缺失数据进行单变量预测，即是利用含缺失数据的变量的其他数据作为输入对 GA-SVR 进行训练，预测缺失数据的值。

首先，设缺失数据段长度为  $l$ ，确定缺失数据

所属变量  $q$ , 以第  $q$  个变量维度上的  $(n-l-1)$  个数据值作为输入, 剩余一个数据值作为输出, 对 GA-SVR 进行训练。然后利用训练后的 GA-SVR 模型预测缺失数据, 获得单变量预测结果。

## 2.2 基于 GA-SVR 的多变量预测填补

利用 GA-SVR 对缺失数据进行多变量预测, 即利用与含缺失数据的变量相关变量的数据作为输入对 GA-SVR 进行训练, 预测缺失数据的值。

首先利用相关性分析, 寻找与变量  $q$  的相关变量构成训练集  $X_1, \dots, (X_i), \dots, X_k$ 。变量间的相关性根据相关系数  $R$  评判, 若相关系数  $R \geq 0.8$ , 即为强相关关系。其计算公式为

$$R = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (3)$$

以训练集中其他  $(n-l)$  个时刻上的数据值为输入, 以缺失数据所属时刻上的数据值作为输出, 训练 GA-SVR。然后利用训练好的 GA-SVR 模型对缺失数据进行预测, 获得多变量预测结果。

## 2.3 基于 GA-SVR 的组合预测填补

为提高数据预测的准确度, 降低预测值与真实值之间的误差, 以改善设备故障诊断的效果, 提出一种基于 GA-SVR 的动态权重组合预测方法对缺失数据进行填补。首先利用 GA-SVR 分别进行单变量预测及多变量预测; 然后建立动态权重组合单变量预测结果和多变量预测结果, 得到缺失数据的填补结果; 最后在完整数据的基础上, 利用 SVM 对设备进行故障诊断。图 2 为基于 GA-SVR 的组合预测流程图。

均方根误差 RMSE 可以度量预测值与真实值的偏差, 因此用 RMSE 来评价预测结果的好坏, RMSE 越小对缺失数据的预测效果越好。均方根误差表达式为

$$RMSE = \sqrt{\sum_{j=1}^n (y_j - \hat{y}_j)^2 / n} \quad (4)$$

式中:  $y_i$  为真实值;  $\hat{y}_i$  为预测值;  $n$  为预测次数。

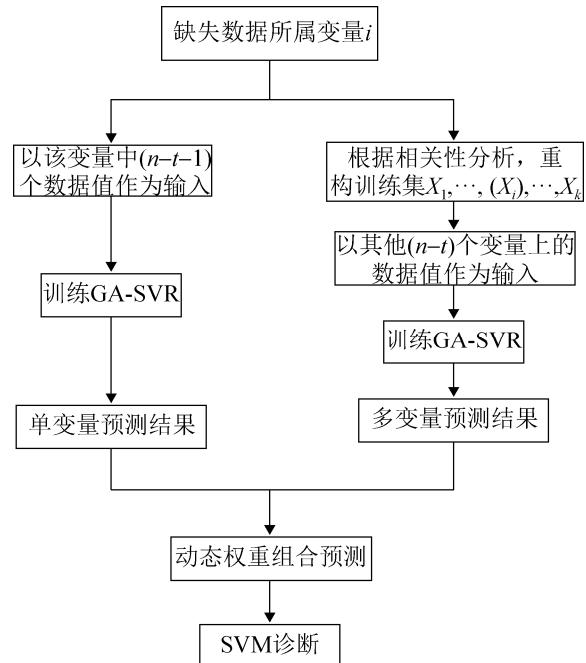


图 2 基于 GA-SVR 的组合预测流程图  
Fig. 2 Combined prediction flow chart based on GA-SVR

单变量预测结果和多变量预测结果在组合预测中的权重值取决于其均方根误差值的大小, 均方根误差越小, 权重越大。由式(5)推导可得缺失数据的预测结果为

$$\begin{cases} w_1 = k / R_1 \\ w_1 = k / R_2 \\ w_1 + w_2 = 1 \\ y_i^* = w_1 \hat{y}_{1i} + w_2 \hat{y}_{2i} \end{cases} \quad (5)$$

$$y_i^* = \frac{R_2}{R_1 + R_2} \hat{y}_{1i} + \frac{R_1}{R_1 + R_2} \hat{y}_{2i} \quad (6)$$

式中:  $\hat{y}_{1i}$ ,  $\hat{y}_{2i}$  分别为单变量预测结果和多变量预测结果;  $R_1$ ,  $R_2$  分别为单变量预测和多变量预测的 RMSE 值;  $y_i^*$  为最终的缺失数据填补值。

## 3 仿真分析

用美国卡特彼勒公司液压泵 A, B, C 3 个液压泵的状态数据作为实验数据进行仿真, 验证本研究提出的模型对设备故障诊断的有效性和实用性。液压泵分为“好、中、差、坏”4 种状态。液压泵 A, B, C 均有 80 组实验数据, 每组数据包含

32个变量(32个传感器)。以第3个传感器的监测值作为实验对象,删除第75~80个时间点的监测值。分别利用单变量预测,多变量预测以及动态权重组预测对缺失数据进行填补,比较其填补效果及填补后的设备故障诊断效果。

### 3.1 重构训练集

多变量预测选择与传感器3强相关的传感器作为训练集,对缺失数据值预测。根据式(3)分别计算液压泵A,B,C中传感器3与其他传感器的相关系数,其中相关系数 $R \geq 0.8$ 则表示该传感器与传感器3具有强相关关系,以此来重新构建训练集,如表1~3所示。重新构造的训练样本仅为6维,在能反映原始数据特征的前提下,降低了计算量,有益于缩短预测时间。

表1 液压泵A中与传感器3具有强相关关系的传感器

Tab. 1 Sensors with strong correlation with sensor 3 of hydraulic pump A

	CH2	CH5	CH7	CH13	CH16	CH32
R	0.826	0.872	0.908	0.911	0.956	0.858

表2 液压泵B中与传感器3具有强相关关系的传感器

Tab. 2 Sensors with strong correlation with sensor 3 of hydraulic pump B

	CH2	CH5	CH7	CH13	CH16	CH32
R	0.819	0.863	0.895	0.902	0.938	0.838

表3 液压泵C中与传感器3具有强相关关系的传感器

Tab. 3 Sensors with strong correlation with sensor 3 of hydraulic pump C

	CH2	CH5	CH7	CH13	CH16	CH32
R	0.821	0.867	0.901	0.907	0.944	0.843

### 3.2 缺失值填补效果比较

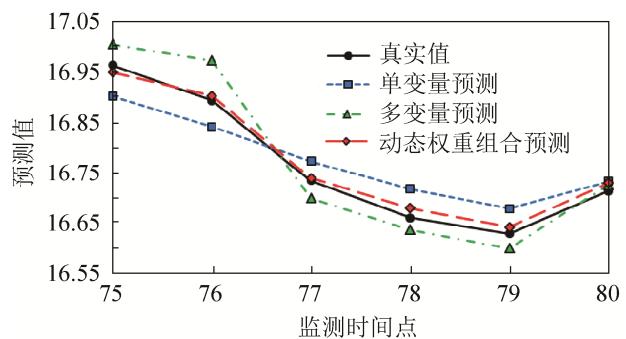
利用GA-SVR分别对液压泵A,B,C中的缺失值进行单变量预测、多变量预测及动态权重组预测填补,比较填补效果。其中GA的参数均设置为:种群规模为20,最大迭代次数为100。SVR的关键参数设置均为: $0.1 \leq C \leq 1000$ , $0.01 \leq \sigma \leq 100$ , $0.01 \leq \varepsilon \leq 1$ 。利用均方根误差RMSE和平均绝对百分比误差MAPE作为评价指标,平均绝对

百分比误差MAPE的表达式为

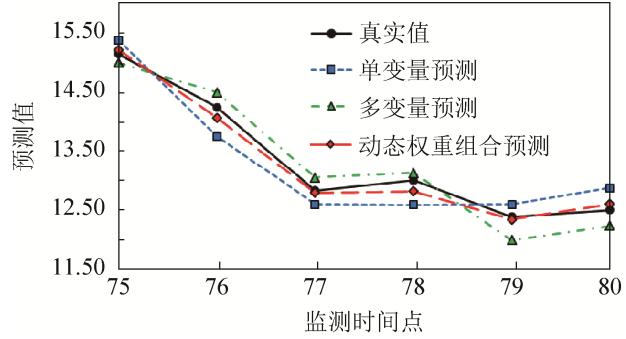
$$MAPE = \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \cdot \frac{100\%}{n} \quad (7)$$

式中: $y_i$ 为真实值; $\hat{y}_i$ 为预测值。

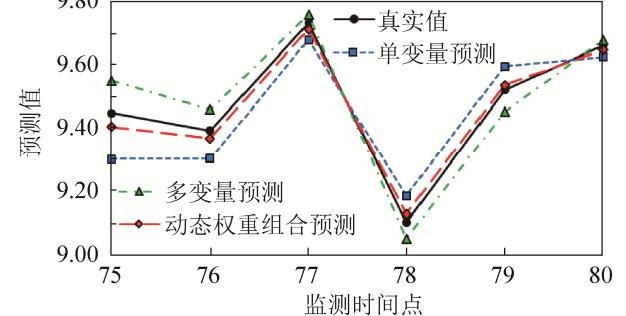
图3(a)~(c)分别是液压泵A,B,C基于GA-SVR的缺失数据拟合曲线。从图3(a)~(c)可以看出3个数据集的仿真结果基本一致:动态权重组预测的拟合曲线相较于单变量预测及多变量预测的拟合曲线更贴合真实值曲线,表示动态权重组预测的效果比单独进行单变量预测或者多变量预测的效果要好。



(a) 液压泵A基于GA-SVR的缺失数据拟合曲线



(b) 液压泵B基于GA-SVR的缺失数据拟合曲线



(c) 液压泵C基于GA-SVR的缺失数据拟合曲线

图3 液压泵基于GA-SVR的缺失数据拟合曲线  
Fig. 3 Missing data fitting curve based on GA-SVR of hydraulic pump

表 4~6 分别为 3 种不同的预测模型对液压泵 A, B, C 的缺失数据填补效果。表 4~6 均表明: 同一种预测模型的动态权重组预测的 RMSE 值相比单变量预测和多变量预测的 RMSE 和 MAPE 值最小, 对于不同种预测模型的同一种预测方式, GA-SVR 模型的 RMSE 和 MAPE 值最小。综合来看, 基于 GA-SVR 的缺失数据动态权重组预测效果最佳。

表 4 3 种不同模型的液压泵 A 缺失数据预测效果  
Tab. 4 Prediction effect of missing data of hydraulic pump A in three different models

预测效果	单变量预测		多变量预测		动态权重组合预测	
	RMSE	MAPE/%	RMSE	MAPE/%	RMSE	MAPE/%
GA-SVR	0.048 6	0.28	0.042 3	0.22	0.013 8	0.08
SVR	0.073 7	0.40	0.050 0	0.25	0.030 3	0.16
BPNN	0.092 0	0.52	0.064 4	0.36	0.054 7	0.28

表 5 3 种不同模型的液压泵 B 缺失数据预测效果  
Tab. 5 Prediction effect of missing data of hydraulic pump B in three different models

预测效果	单变量预测		多变量预测		动态权重组合预测	
	RMSE	MAPE/%	RMSE	MAPE/%	RMSE	MAPE/%
GA-SVR	0.342 0	2.44	0.250 0	1.80	0.118 5	0.76
SVR	0.654 7	2.90	0.398 9	2.13	0.215 8	1.12
BPNN	0.883 2	3.28	0.515 0	2.82	0.299 0	1.98

表 6 3 种不同模型的液压泵 C 缺失数据预测效果  
Tab. 6 Prediction effect of missing data of hydraulic pump C in three different models

预测效果	单变量预测		多变量预测		动态权重组合预测	
	RMSE	MAPE/%	RMSE	MAPE/%	RMSE	MAPE/%
GA-SVR	0.087 8	0.85	0.0621	0.59	0.026 3	0.26
SVR	0.143 9	1.69	0.1219	1.33	0.049 8	0.73
BPNN	0.229 3	2.12	0.1580	1.83	0.072 4	1.20

### 3.3 设备故障诊断效果比较

为了比较不同的缺失数据预测模型及预测方式对设备故障诊断效果的影响, 利用将缺失数据填补后的完整数据进行设备的故障诊断。对液压泵 A, B, C 数据集分别随机选取 50 组数据用作训练样本, 其余 30 组数据用作测试样本, 利用 SVM 进行故障诊断。

表 7~9 分别是不同的缺失数据填补模型对液压泵 A, B, C 故障诊断效果的影响。从表 7~9 均可以看出, 对于不同种缺失数据填补模型而言, GA-SVR 相较于 SVR 及 BPNN 得到的故障诊断率基本都是最高, 诊断时间比 BPNN 短, 相较于 SVR 的诊断时间较长但相差不大。由此可得, 本文提出的基于 SVR 的小样本缺失数据下的故障诊断方法应用于液压泵 A, B, C 均是有效的, 具有一定的普适性。

总体而言, 基于 GA-SVR 的动态权重组预测的缺失数据填补方法可以得到最佳的诊断效果。

表 7 不同缺失数据填补模型对液压泵 A 故障诊断效果影响  
Tab. 7 Influence of different missing data filling models on fault diagnosis of hydraulic pump A

诊断效果	单变量预测		多变量预测		动态权重组合预测	
	填补	准确率/%	填补	准确率/%	填补	准确率/%
GA-SVR	83.33	20.84	90.00	41.20	96.67	41.64
SVR	80.00	21.33	83.33	39.86	90.00	41.50
BPNN	76.67	50.8	90.00	87.23	93.33	88.92

表 8 不同缺失数据填补模型对液压泵 B 故障诊断效果影响  
Tab. 8 Influence of different missing data filling models on fault diagnosis of hydraulic pump B

诊断效果	单变量预测		多变量预测		动态权重组合预测	
	填补	准确率/%	填补	准确率/%	填补	准确率/%
GA-SVR	86.67	16.43	93.33	23.45	100.00	24.29
SVR	83.33	14.50	90.00	22.76	96.67	23.40
BPNN	76.67	31.80	86.67	59.80	93.33	61.02

表9 不同缺失数据填补模型对液压泵C故障诊断效果影响  
Tab. 9 Influence of different missing data filling models on fault diagnosis of hydraulic pump C

诊断效果模型	单变量预测		多变量预测		动态权重组合	
	填补		填补		预测填补	
	准确率/%	t/s	准确率/%	t/s	准确率/%	t/s
GA-SVR	86.67	9.43	93.33	13.45	96.67	14.23
SVR	83.33	8.55	86.67	10.98	93.33	11.45
BPNN	80.00	15.78	83.33	21.50	90.00	23.27

## 4 结论

本文针对小样本数据的缺失会影响设备故障诊断效果的问题，提出一种基于GA-SVR的缺失数据填补方法，进而改善设备故障诊断效果。首先进行单变量预测，同时通过相关性分析重构训练集，以便进行多变量预测。然后，建立动态权重将单变量预测结果和多变量预测结果进行组合，对缺失数据进行填补。最后，将完整的数据作为输入，利用SVM对设备进行故障诊断。通过实例分析，将本文提出的方法与基于SVR、BPNN的单变量预测、多变量预测以及动态权重组合预测效果在多个数据集上进行比较，并对比最终的故障诊断效果。结果表明，本文提出的方法具有最佳的预测效果及较佳的故障诊断效果。

## 参考文献：

- [1] 张远绪, 程换新, 宋生建. 基于改进的 RBF 神经网络的滚动轴承故障诊断[J]. 工业仪表与自动化装置, 2018(6): 31-34.  
Zhang Yuanxu, Cheng Huanxin, Song Shengjian. Fault Diagnosis of Rolling Bearing based on Improved RBF Neural Network[J]. Industrial Instruments and Automation Equipment, 2018(6): 31-34.
- [2] Xing C H, Xu F T, Yao Z Y, et al. A Fault Diagnosis Method of Reciprocating Compressor based on Sensitive Feature Evaluation and Artificial Neural Network[J]. High Technology Letters (S1006-6748), 2015, 21(4): 422-428.
- [3] 王杉, 范津莎, 张卫华. 基于 BP 神经网络的变压器故障诊断[J]. 科学技术创新, 2011(29): 40-41.  
Wang Shan, Yuan Jinsha, Zhang Weihua. Transformer Fault Diagnosis based on BP Neural Network[J]. Science and Technology Innovation, 2011(29): 40-41.
- [4] 胡杰, 刘博, 颜伏伍, 等. 汽油机失火诊断 GA-SVM 方法研究[J]. 汽车技术, 2017(1): 38-42.  
Hu Jie, Liu Bo, Yan Fuwu, et al. Study on GA-SVM Method for Engine Fire Diagnosis[J]. Automotive Technology, 2017(1): 38-42.
- [5] 卢向华, 舒云星. 改进 AFSA 算法优化 SVM 的变压器故障诊断[J]. 计算机工程与应用, 2017, 53(17): 173-179.  
Lu Xianghua, Shu Yunxing. Improved AFSA Algorithm to Optimize Transformer Fault Diagnosis based on SVM [J]. Computer Engineering and Application, 2017, 53(17): 173-179.
- [6] Huang J, Hu X G. Support Vector Machine with Genetic Algorithm for Machinery Fault Diagnosis of High Voltage Circuit Breaker[J]. Measurement (S0263-2241), 2011, 44(6): 1018-1027.
- [7] Fei S W, Zhang X B. Fault Diagnosis of Power Transformer based on Support Vector Machine with Genetic Algorithm[J]. Expert Systems with Applications (S0957-4174), 2009, 36(8): 11352-11357.
- [8] Yang D L, Liu Y L. Gear Fault Diagnosis based on Support Vector Machine Optimized by Artificial Bee Colony Algorithm[J]. Mechanism and Machine Theory (S0094-114X), 2015(90): 219-229.
- [9] 卢亚洲, 王学文, 杨兆建, 等. PSO-SVM 在提升机制动系统故障诊断中的应用[J]. 机械设计与制造, 2018(6): 246-249.  
Lu Yazhou, Wang Xuewen, Yang Zhaojian, et al. Application of PSO-SVM in Fault Diagnosis of Lifting Mechanism Dynamic System[J]. Machinery Design and Manufacturing, 2018(6): 246-249.
- [10] Zhang Y Y, Wei H, Liao R J, et al. A New Support Vector Machine Model Based on Improved Imperialist Competitive Algorithm for Fault Diagnosis of Oil-immersed Transformers[J]. Journal of Electrical Engineering and Technology (S1975-0102), 2017, 12(2): 830-839.
- [11] Zhang Z D, Dong F L. Fault Detection and Diagnosis for Missing Data Systems with a Three Time-slice Dynamic Bayesian Network Approach[J]. Chemometrics and Intelligent Laboratory Systems (S0169-7439), 2014, 138.
- [12] 陈嘉宁, 杨翾, 叶承晋, 等. 基于缺失数据修复的变压器在线故障诊断方法[J]. 电力系统保护与控制, 2019, 47(15): 86-92.  
Chen Jianing, Yang Xuan, Ye Chengjin, et al. Transformer On-line Fault Diagnosis Method based on Missing Data Repair[J]. Power System Protection and Control, 2019, 47(15): 86-92.

- [13] 蒋少华, 桂卫华, 阳春华. 基于不完备数据的密闭鼓风炉故障诊断[J]. 华中科技大学学报(自然科学版), 2009, 37(增 1): 122-125.  
Jiang Shaohua, Gui Weihua, Yang Chunhua. Fault Diagnosis of Closed Blast Furnace based on Incomplete Data[J]. Journal of Huazhong University of Science and Technology (Natural Science Edition), 2009, 37(S1): 122-125.
- [14] 吴健飞, 刘勤明, 吕文元, 等. 基于灰色 EM-SHSMM 的缺失数据下设备健康预测研究[J]. 计算机应用研究, 2018, 35(11): 3255-3258.  
Wu Jianfei, Liu Qinming, Lu Wenyuan, et al. Research on Equipment Health Prediction based on Grey Em-shsomm Missing Data[J]. Computer Application Research, 2018, 35(11): 3255-3258.
- [15] Liu Z K, Liu Y H, Zhang D W, et al. Fault Diagnosis for a Solar Assisted Heat Pump System under Incomplete Data and Expert Knowledge[J]. Energy (S0360-5442), 2015, 87: 41-48.
- [16] 陈强强, 陈志平, 李春光, 等. 贝叶斯网络故障诊断的先验概率评估研究[J]. 电子机械工程, 2017, 33(2): 56-60, 64.  
Chen Qiangqiang, Chen Zhiping, Li Chunguang, et al. Study on Prior Probability Assessment of Bayesian Network Fault Diagnosis[J]. Electro-Mechanical Engineering, 2017, 33(2): 56-60, 64.
- [17] Chen D M, Yang S, Zhou F N. Transfer Learning Based Fault Diagnosis with Missing Data Due to Multi-Rate Sampling [J]. Sensors (Basel, Switzerland) (S1424-8220) 2019, 19: 1826.
- [18] 杨金芳, 翟永杰, 王东风, 等. 基于支持向量回归的时间序列预测[J]. 中国电机工程学报, 2005, 25(17): 110-114.  
Yang Jinfang, Zhai Yongjie, Wang Dongfeng, et al. Time Series Prediction based on Support Vector Regression[J]. Chinese Journal of Electrical Engineering, 2005, 25(17): 110-114.
- [19] 董辉, 傅鹤林, 冷伍明. 支持向量机的时间序列回归与预测[J]. 系统仿真学报, 2006, 18(7): 1785-1788.  
Dong Hui, Fu Helin, Leng Wuming. Time Series Regression and Prediction of Support Vector Machine[J]. Journal of System Simulation, 2006, 18(7): 1785-1788.
- [20] 石怀涛, 赵纪宗, 宋文丽, 等. 基于人工蜂群优化核主元分析故障检测方法[J]. 控制工程, 2018, 25(9): 1686-1691.  
Shi Huaitao, Zhao Jizong, Song Wenli, et al. Fault Detection Method based on Core Principal Component Analysis of Artificial Bee Colony Optimization[J]. Control Engineering, 2008, 25(9): 1686-1691.
- [21] 郭洋. 深度学习在时间序列模式识别中的研究与应用[D]. 北京: 北京邮电大学, 2018.  
Guo Yang. Research and Application of Deep Learning in Time Series Pattern Recognition[D]. Beijing: Beijing University of Posts and Telecommunications, 2018.