

DOI: 10.13382/j.jemi.B2205771

基于多源信号的单向阀内泄漏预测研究*

李 威 童成彪 吴家腾 伍奕桦

(湖南农业大学机电工程学院 长沙 410128)

摘要:单向阀作为液压系统重要元件,发生内泄漏故障时影响液压系统的工作效率和设备的安全稳定运行。针对单向阀内泄漏预测,提出了一种基于多源信号和布谷鸟搜索支持向量回归(CS-SVR)的单向阀内泄漏无损预测方法。首先建立单向阀内泄漏检测实验平台,获得不同工况不同故障特征下单向阀内泄漏的振动信号和声发射信号。然后利用小波包能量分析方法,提取两种信号最优频带重构信号的均方根值作为预测变量,并结合阀前压力建立基于布谷鸟算法优化的支持向量机回归(CS-SVR)的多源信号预测模型。最后,将模型进行对比分析。结果表明,布谷鸟搜索算法相对于网格搜索法(GS)和粒子群算法(PSO)对SVR模型参数寻优优势更大;基于多源信号输入的预测方法相对于单源输入的预测方法精确程度更高,同时该方法能实现不同压力、不同故障类别、不同故障程度的单向阀内泄率预测,平均相对误差为8.97%鲁棒性较高,为阀内泄漏无损检测应用技术的开发奠定了基础。

关键词:单向阀内泄漏;多源信号;小波包分析;支持向量机回归;布谷鸟搜索

中图分类号: TH133.33; TN98 **文献标识码:** A **国家标准学科分类代码:** 510.4030

Research on internal leakage prediction in check valve based on multi-source signals

Li Wei Tong Chengbiao Wu Jiateng Wu Yihua

(College of Mechanical and Electrical Engineering, Hunan Agricultural University, Changsha 410128, China)

Abstract: As an important component of the hydraulic system, check valve affects the work efficiency of the hydraulic system and the safe and stable operation of the equipment when internal leakage occurs. Aiming at the leakage prediction in check valve, a non-destructive leakage prediction method in check valve based on multi-source signal and cuckoo search support vector regression (CS-SVR) is proposed. Firstly, a leakage detection experimental platform in the check valve is established, and the vibration signal and acoustic emission signal leaking in the check valve under the different working conditions and the different fault characteristics are obtained on the platform. Secondly, wavelet packet energy analysis method is used to extract the root mean square (RMS) of optimal frequency band reconstruction signals which are as the predictors with the inlet pressure to establish a multi-source signal prediction model based in CS-SVR. Finally, with compared and analyzed the models, the results show that the cuckoo search (CS) has a greater advantage over the grid search (GS) and particle swarm optimization (PSO) for SVR model parameters. Prediction methods based on multi-source signal inputs are more accurate than single-source input prediction methods, and the proposed method can realize the prediction of the internal leakage rate of the check valve with different pressure, different fault categories and different fault degrees. The proposed method average relative error is 8.97% and has high robustness, which lays a foundation for the development of non-destructive testing application technology for valve leakage.

Keywords: internal leakage in check valve; multi-source signals; wavelet packet analysis; SVR; cuckoo search

0 引言

单向阀是一种只允许流体介质沿一个方向流动的方向阀,其作为一种重要的液压元件,广泛应用于石油化工、天然气、核电和冶金等重要领域。虽然在制造过程中经过了严格的质量检验,但在长期使用过程中,由于磨损、腐蚀、划痕等原因,单向阀常发生泄漏故障,导致液压系统维护成本提高并降低工作效率^[1]。因此,研究阀内泄漏在线监测技术,基于预防维护技术的前瞻性预测和分析,能为工业生产、品质控制、能源节约等活动提供保障^[2-3]。

国内外学者对阀的内泄漏预测研究主要基于回归分析法、神经网络、数学建模等方法并取得颇多成果。Ye等^[4]采用高斯过程回归建立了描述声发射信号特征和压力与泄漏率之间关系的多元数学模型,该模型不仅可以预测泄漏率,还可以根据预测的平均值和标准差得到泄漏率的概率分布;Zhao等^[5]将小波处理后的球阀内漏声发射信号特征参数作为输入,建立了BP神经网络预测模型,预测误差小于10%;Guo等^[6]对比研究了卷积神经网络、BP神经网络、T-S神经网络和埃尔曼神经网络对内泄漏率的预测,4种神经网络预测模型的精度均在90%以上,其中卷积神经网络的精度最高;Ewwaewhoi等^[7]通过机理分析,建立了阀内泄漏数学模型,并解释了泄漏率、入口压力水平、阀门尺寸和阀门类型等影响因素对声发射信号均方根值的影响;李振林等^[8]通过理论分析建立了阀内漏过程中气体体积泄漏率与声发射信号特征参数均方根量化关系,实验结果表明误差在10%以内。以上方法均采用了声发射检测技术来预测阀的泄漏状态,研究发现,阀内泄漏时介质流过产生的声发射信号为大于25 kHz的连续性高频信号^[9],声发射技术成为阀内漏故障的一种常见检测方法。振动检测作为在故障诊断中经典的方法,一些学者将其应用至阀内漏检测,效果明显^[10-11]。振动检测感知的是固体物质的振动信号,而声发射检测技术感知的是物质应变能的变化,两种检测方法测量的物理量不同,相比声发射信号适用于高频信号,振动检测在低频信号的检测中更有优势^[12]。

为确保测量阀内漏故障信号的完整性和多源性,提高预测精度,本文综合单向阀不同工况下内泄漏时的声发射信号和振动信号,提出了一种基于多源信号的单向阀内泄漏率无损预测的方法。首先使用小波包对两种故障信号进行分解与重构,通过重构系数选取最大能量频带的重构信号进行特征参数提取,并将提取的两个特征参数和对应的阀前压力一起输入经布谷鸟搜索算法优化(cuckoo search, CS)的支持向量机回归(support vector regression, SVR)模型,建立基于振动信号、声发射信号、

阀前压力的CS-SVR单向阀内泄漏多源信号预测模型,并与单变量预测模型做对比,结果证明该方法是准确和有效的。

1 方法原理

1.1 小波包能量谱

小波包分解是利用一组正交的小波基将输入信号分解成高频和低频部分,在分解过程中,尺度函数 $\omega(t)$ 和小波函数 $\varphi(t)$ 满足方程:

$$\begin{cases} \omega(t) = \sqrt{2} \sum_n h(n) \omega(2t - n) \\ \varphi(t) = \sqrt{2} \sum_n g(n) \varphi(2t - n) \end{cases} \quad (1)$$

式中: n 为平移幅度, $h(n)$ 和 $g(n)$ 为多尺度函数中滤波器的低通和高通滤波器;小波包分解公式为:

$$d_{i+1}^{2k} = \sum_n h(n - 2t) d_i^k(n) \quad (2)$$

$$d_{i+1}^{2k+1} = \sum_n g(n - 2t) d_i^k(n) \quad (3)$$

式中: $d_i^k(n)$ 为小波包分解后第 i 层第 k 个节点的第 n 个小波包系数。分解公式逆运算得到小波包重构算法^[13],小波包重构函数为:

$$d_i^k(n) = 2 \left[\sum_t h(n - 2t) d_{i+1}^{2k+1}(n) + \sum_t g(n - 2t) d_{i+1}^{2k}(n) \right] \quad (4)$$

由Parseval恒等式原理,得到原始信号能量和小波包系数相等关系为:

$$\int_{-\infty}^{+\infty} |f(x)|^2 dx = \sum |d_i^k(n)|^2 \quad (5)$$

小波包分解后,利用重构系数得到不同频带的能量计算公式:

$$E_{i,k} = \sum_{n=1}^N |d_i^k(n)|^2, k = 1, 2, \dots, 2^i \quad (6)$$

式中: $E_{i,k}$ 为第 i 层第 k 个频带的能量, N 为信号长度。所有的 $E_{i,k}$ 构成小波能量谱,小波包能量占比 $P_{i,k}$ 关系式为:

$$P_{i,k} = \frac{E_{i,k}}{\sum_{i=1}^{2^k} E_{i,k}} \quad (7)$$

1.2 SVR模型

SVR源自于分类决策,其原理是找到一个最优拟合超平面,使所有样本与该平面的偏差最小。假设样本集为 $(x_i, y_i), i = 1, 2, \dots, l$ 其中 l 为样本数, x_i 为输入多维变量, y_i 为输出变量,此时高维特征空间的回归模型为:

$$y_i = \omega^T(x_i) + b \quad (8)$$

式中: ω 为权重向量, b 为偏置值。通过最小化结构风险

原则,引入不敏感损失函数 ε ,正负松弛因子 ξ, ξ' ,目标函数为求回归函数和拟合误差之和的最小值,优化模型为:

$$\begin{cases} \min_{\omega, b} \frac{1}{2} \omega^2 + C \sum_{i=1}^l (\xi_i + \xi'_i) \\ \text{s. t.} \begin{cases} \omega^T(x_i) + b - y_i \leq \varepsilon + \xi_i \\ y_i - \omega^T(x_i) - b \leq \varepsilon + \xi'_i \\ \xi_i, \xi'_i \geq 0 \end{cases} \end{cases} \quad (9)$$

式中: C 为惩罚系数,为将模型的输入从低维向高维映射并提高模型的非线性处理能力,引入核函数^[14]。常见的核函数有多项式核函数、Sigmoid 核函数和径向基核函数(radial basis function, RBF)等,本文选用多维输入变量,因输入量与输出量两者明显为非线性关系,故选用 RBF 核函数^[15],以 RBF 核函数建立的 SVR 模型表达式为:

$$y = \sum_{i=1}^n (\alpha_i^* - \alpha_i) e^{-\gamma \|x - x_i\|^2} + b \quad (10)$$

式中: γ 为核函数的尺度参数, α_i^* 和 α_i 为拉格朗日乘子。

1.3 CS 算法

CS 算法是一种新型基于自然元启发式算法,具有全局搜索能力强、搜索路径优和能多目标求解等优点,该算法是通过全局游走进行种群寻优。

1) 首先在规定范围内随机生成 N 组位置 $\mathbf{x} = (x_1, x_2, \dots, x_n)$, 其中第 i 组位置 $\mathbf{x}_i = (a_{i1}, a_{i2}, \dots, a_{in})$, n 为需要求解的参数个数。

2) 计算并保留 x 中使目标函数最小的解向量 \mathbf{x}_i , 然后结束此次迭代。

3) 设定概率 Pa 判断是否接受解,对未淘汰的解借助莱茵飞行搜索机制更新上次迭代解的参数 a , 更新公式^[16]为:

$$a_i^{t+1} = a_i^t + \alpha \otimes L(\lambda) \quad (11)$$

式中: α 为步长因子, a_i^{t+1} 为更新后参数, λ 为莱茵指数, $L(\lambda)$ 为随机搜索路径,其公式为^[17]:

$$L(\lambda) = \frac{\mu}{|\nu|^{1/\lambda}} \quad (12)$$

式中: μ 和 ν 为随机数。完成位置更新后,重新返回步骤 2) 进行迭代,当迭代次数达到最大时,输出最优解。

2 实验

实验装置由故障模拟实验台和自搭建的故障信号检测系统两部分组成。

阀内泄漏故障模拟实验台选用 RCYCS-G 液压系统故障实验台,该实验台由液压泵、压力表、溢流阀、单向阀、量杯、液压升降台等组成,通过溢流阀实现对阀前压

力进行调节,为单向阀提供不同值的液体压力。对单向阀阀芯进行预加工处理以模拟各类故障,故障阀芯如图 1 所示。试验工况与阀芯故障种类如表 1 所示。测量表 1 工况下各故障类型阀芯内泄漏时的声发射信号与振动信号,结合量杯与液压升降台的下降速度计算故障单向阀芯的内泄漏率。

表 1 实验参数

Table 1 Parameters of the experiment

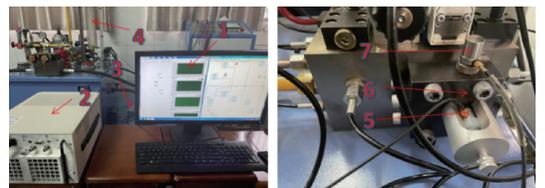
故障类型	故障程度	阀前压力
粗糙度	Ra3.2	6~9 MPa
	Ra6.3	6~9 MPa
	Ra12.5	6~9 MPa
径向偏心	0.05 mm	6~9 MPa
	0.1 mm	6~9 MPa
	0.2 mm	6~9 MPa
局部受损	轻微	6~9 MPa
	中等	6~9 MPa
	严重	6~9 MPa



图 1 实验故障单向阀阀芯

Fig. 1 Faulty check spool for experiments

信号采集系统如图 2 所示,在本故障信号采集系统中,声发射传感器选用谐振频率为 50 kHz 的日本富士 AE503S 谐振式声发射传感器,工作频率范围为 10 ~ 500 kHz,并配置 40 dB 放大器提高系统信噪比,电信号采集选用 NI PXI 6259 数据采集卡,采样率为 1 MHz; 振动传感器为东华测试的 IEPE 压电式加速度传感器 1A113E,频率响应为 0.5 ~ 5 000 Hz,采样率为 2 kHz,振动采集卡为 NI PXI 4462。两种传感器位置如图 2(b) 所示。为确保数据的同步性,信号由 LabVIEW 软件编写的测控程序进行同步采样。



(a) 信号采集系统 (b) 传感器位置
(a) Signal acquisition system (b) The location of sensors

图 2 信号采集实验

Fig. 2 Signal acquisition experiment

3 实验信号分析与处理

3.1 频谱分析

图3和4显示了3种不同泄漏率下声发射信号和振动信号的频谱,可见振动和声发射信号的频谱都集中在频谱图的前部分,其中图3对频谱密集段进行了放大处理。从频谱图中还可以发现,信号的幅值随着泄漏率的增大而增大,两者呈正相关关系,从而可选择与幅值相关性大的特征参数作为单向阀内泄漏的预测变量。从图3可以看出,声发射信号的频率集中在0~170 kHz,且声发射信号中各频段的干扰信号较多,在泄漏小的时候尤为明显;从图4可以看出,振动信号的频率集中在0~60 Hz,60 Hz之后的幅值接近0。

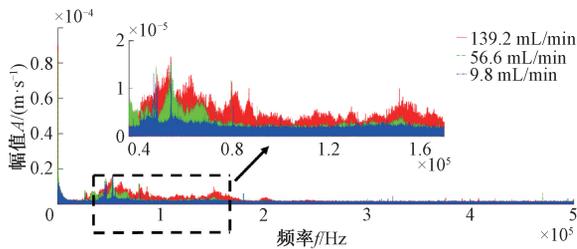


图3 声发射信号频谱图

Fig. 3 The spectrogram diagram of the AE signal

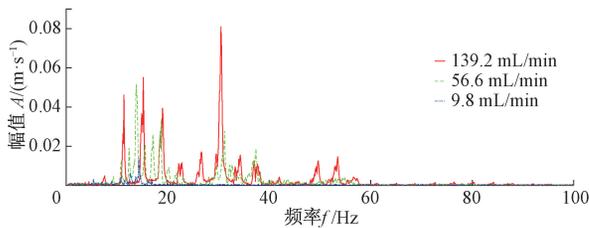


图4 振动信号频谱图

Fig. 4 The spectrogram diagram of the vibration signal

3.2 小波包能量分析

考虑到时域信号无法完全反映出信号的本质特征,且从前述频谱图发现两种故障信号的频率较集中,故需要对信号基于频率进行分割处理。本文采用小波包分解将故障信号无泄漏、无冗余的正交分解到相邻的各频段上。对不同小波基信号下频谱在各子信号的集中性进行对比,选用具有对称性的 Meyer 为小波基函数,将故障信号分解到第3层,共得到 $2^3 = 8$ 个频段。而从3.1节可知,故障阀芯内漏的振动信号的频率集中在0~60 Hz,属于对应的第1频段,其余频段的频率幅值接近0,因此内漏振动信号的能量在第1频段接近100%。为更好分析

内漏声发射信号,补测正常阀芯时的声发射信号,并以阀前压力为8 MPa下,阀芯偏心、局部受损、粗糙3种故障阀芯和正常阀芯采集到的声发射信号为例,计算信号能量在不同频段的分布,得到图5能量分布柱状图。从图5可看出不同故障的单向阀阀芯声发射信号能量主要集中在第1频段,而第4~8频带的能量远小于第1频段,其中第1频段、第2频段、第3频段能量平均比例为12:5:4。当阀芯正常时,第1、2、3频段能量占比高于第4~8频段,但远不如泄漏状态突出。此外,正常和3种泄漏状态的声发射信号第4~8频带的能量占比分别基本相等。

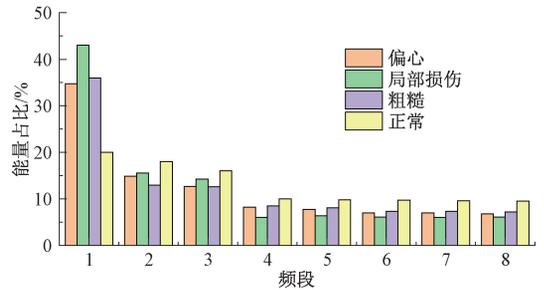


图5 声发射信号各频段能量占比

Fig. 5 The proportion of energy in each frequency band of the acoustic emission signal

3.3 特征参数提取

从前述分析可知故障信号主要集中在频谱的第1频段。类似研究表明,由于阀的内泄漏信号的能量来自阀内部泄漏流体的射流,泄漏微通道对于同一故障类型的阀芯是相似的,相同故障类型的阀芯的内漏信号能量会集中在同一频段内^[18],由于声发射传感器的高灵敏度,在采集信号过程中很容易被噪声干扰^[19],根据白噪声在所有频段的能量密度相同的定义^[20],因为所有阀芯的声发射信号分别在第4~8频段能量分别基本相等,再结合频谱图3中第4~8频段对应频率的频谱图分布均匀可判断第4~8频段为白噪声的能量。又由于第2和第3频段的能量与第1频段相比,其大于高频段能量的程度较低,故该频段信号夹杂大量外界干扰,因此声发射信号中第1频段包含的有效信息占比最大。综上所述,选择单向阀内漏声发射信号和振动信号的第1频段信号进行重构并提取故障信号特征,特征参数选取重构信号的均方根值。由于阀前压力的改变对单向阀的内泄漏率影响较大,因此把单向阀的阀前压力也作为特征参数。由于篇幅有限,仅列举3个径向偏心故障阀芯的特征参数如表2所示,可以看出故障信号的均方根值和阀前压力与泄漏率具有一定的正相关性,即故障越严重,阀前压力越高,泄漏率越高。

表 2 偏心故障阀芯在不同压力下的特征参数

Table 2 Characteristic parameters of eccentric fault spools at different pressures

偏心程度/mm	阀前压力/MPa	频段 1 声发射信号均方根值	频段 1 振动信号均方根值	泄漏率/(mL·min ⁻¹)
0.05	6.0	0.000 442	0.010 5	19.58
0.10	6.0	0.000 446	0.033 2	22.64
0.20	6.0	0.000 889	0.033 7	29.33
0.05	6.5	0.000 628	0.015 8	20.68
0.10	6.5	0.000 522	0.038 2	23.98
0.20	6.5	0.000 958	0.045 7	35.10
0.05	7.0	0.000 431	0.017 4	21.89
0.10	7.0	0.000 475	0.047 5	28.54
0.20	7.0	0.000 423	0.048 4	36.81
0.05	7.5	0.000 431	0.023 8	21.16
0.10	7.5	0.000 422	0.046 0	32.65
0.20	7.5	0.000 484	0.059 3	50.72
0.05	8.0	0.000 409	0.053 9	22.13
0.10	8.0	0.000 459	0.107 9	35.69
0.20	8.0	0.000 457	0.083 2	55.22
0.05	8.5	0.000 457	0.060 3	24.20
0.10	8.5	0.000 490	0.116 4	50.12
0.20	8.5	0.000 535	0.165 4	67.96
0.05	9.0	0.000 457	0.066 0	25.14
0.10	9.0	0.000 483	0.120 1	54.36
0.20	9.0	0.000 496	0.201 9	71.54

4 泄漏率预测

4.1 CS-SVR 预测模型参数与流程

实验测得 7 种工况下 9 种故障阀芯共 63 组数据样本,将阀前压力、振动、声发射重构信号的均方根值作为模型输入,阀泄漏率作为样输出。为消除指标变量在量纲上的差异,首先将样本输入量和输出量进行归一化处理,然后随机选取标准化后 63 组数据的 80% 共 50 组数

据作为训练集,剩余 20% 共 13 组数据作为测试集^[21]。由于 SVR 模型的性能受惩罚因子 C 和核函数参数 γ 影响较大,基于前述建立的数据集,采用布谷鸟算法对 SVR 的参数进行优化。布谷鸟搜索算法每个对应位置设为 $x_i = (C_i, \gamma_i)$,利用 SVR 模型的均方误差 (mean squared error, MSE) 作为评价指标,算法最大迭代次数为 100,巢穴数量 N 为 20,接受位置概率设为 75%, C 和 γ 的取值范围为 $(0, 100]$ 。CS-SVR 预测模型流程如图 6 所示,最后需要将 CS-SVR 模型的预测值进行数据反归一化。

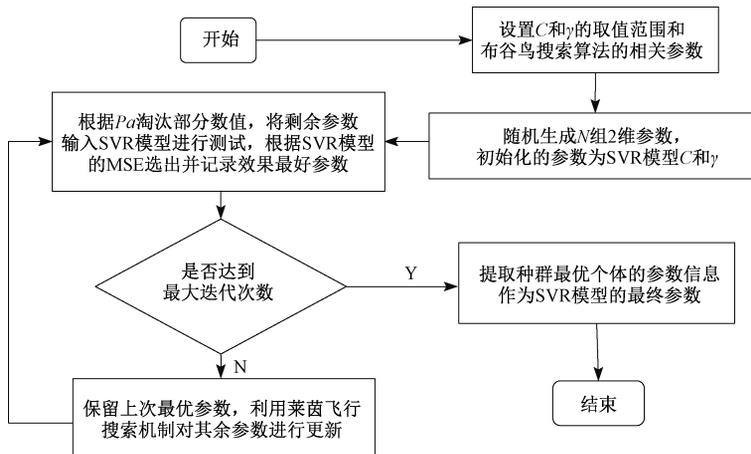


图 6 CS-SVR 流程

Fig. 6 Flow chart of CS-SVR

4.2 泄漏率预测模型准确性

本文分别利用布谷鸟搜索算法、粒子群算法 (particle swarm optimization, PSO)、网格搜索法 (grid search, GS) 对 SVR 模型进行参数寻优, 然后将各方法寻优的结果输入 SVR 模型, 用测试集 50 组数据来验证模型的可行性。为判断不同方法的寻优结果, 引入均方根误差 MSE 和决定系数 R^2 , 其中均方根误差越小, 决定系数越接近 1, 则预测结果越好。预测结果如图 7 所示, 从图 7 中可以看出 CS-SVR、PSO-SVR 和 GS-SVR 三个模型对于单向阀的内泄漏预测都有较好精度。对比图 7(a)、(b)、(c) 可以看出基于布谷鸟搜索算法优化的 SVR 单向阀内泄漏预测模型预测结果与实验测量结果拟合度较高。从表 3 寻优所用时间可以看出, 布谷鸟搜索算法在收敛速度方面具有优势。表 3 中 CS-SVR 模型在 3 种模型中精拟合精度最高, 其中均方根误差为 26.57, 决定系数为 0.998 5。分析认为, 粒子群算法过于依赖当前最优粒子, 网格搜索算法过于依赖网格的划分程度, 导致两种寻优方法在寻优过程中具有局限性, 而布谷鸟搜索算法利用莱茵飞行搜索机制, 相比于前两种方法更稳定, 适用性更强。从表 4 中可以看出, CS-SVR 模型的支持向量最多, 这是模型准确的原因之一, 虽然稀疏性较差会导致计算量加大, 但在小量数据处理时可以忽略。

表 3 不同寻优方法预测结果参数

Table 3 Parameter of prediction results with the different optimization methods

寻优方法	C	γ	MSE	R^2	时间/s
CS	45.507 4	0.016 9	26.570	0.998 5	2.95
PSO	14.457 2	0.062 8	35.698	0.998 0	16.8
GS	2.265 8	0.574 3	512.04	0.971 3	3.12

表 4 模型数据

Table 4 Model data

模型	支持向量个数	偏置值 b
CS-SVR	44	1.084 4
PSO-SVR	43	0.305 0
GS-SVR	42	0.167 6

4.3 输入信号影响研究

为研究不同输入变量对预测结果的影响, 本文把样本的声发射信号均方根值和振动信号均方根值分别作为唯一变量输入 CS-SVR 模型同压力-声发射-振动同时作为变量输入 CS-SVR 模型进行对比, 模型预测结果如图 8 和表 5、6 所示。从图 8 可以 3 种不同输入变量预测模型中多变量预测模型拟合度最高, 振动信号输入模型预测存在预测错误点。从表 5 可以看出, CS-SVR 模型在多源

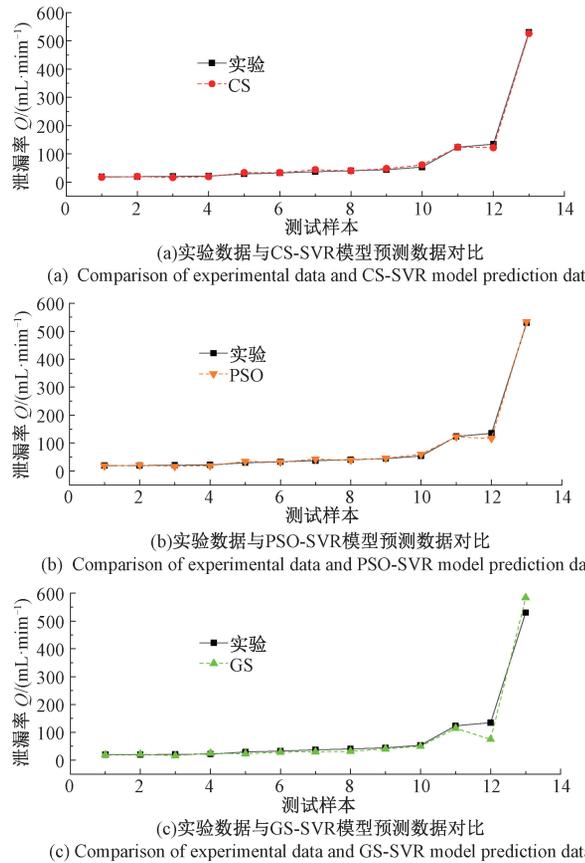


图 7 不同寻优方法预测结果对比

Fig. 7 Comparison of prediction results with the different optimization methods

信号输入下可以实现不同故障阀芯内泄漏率的准确预测, 而单信号模型输出的部分预测值与实验值相差较大。表 6 可看出, 当振动信号作为单源信号输入时因个别数据误差过大, 导致模型的拟合优度较差, 但在低于 100 ml/min 的泄漏率预测上精度尚可。当声发射信号作为单源信号输入时模型的决定系数为 0.985 4, 预测模型的拟合优度相对于振动信号输入具有优势, 但其在较低泄漏率的预测上敏感度较差。而多源信号输入预测模型在所有预测模型中均方根误差最小, 决定系数最接近 1, 平均相对误差为 8.97%, 在 3 种输入模型中预测效果最好。从图 8 可明显看出声发射信号均方根或振动信号均方根作为唯一特征参数时, 模型在进行预测时无法兼顾单向阀内泄漏时的变量, 而导致单变量时模型预测结果和实验测量结果较不理想。因此, 多源信号作为模型输入相对于单源信号对单向阀的内泄漏预测具有较大优势。

4.4 泄漏模型鲁棒性验证

为进一步验证模型的鲁棒性, 在与前期实验不同的阀前压力 5.5 MPa 下重新测得故障阀芯内泄漏的声发射

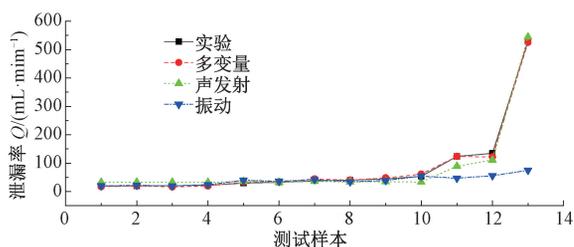


图 8 不同输入变量预测结果对比

Fig. 8 Comparison of prediction results with the different input variables

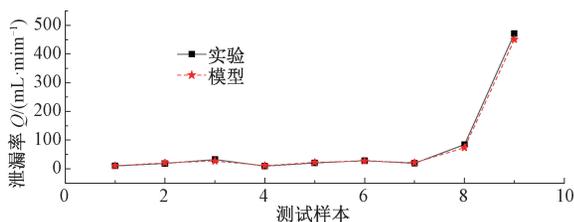


图 9 阀前压力 5.5 MPa 模型预测结果

Fig. 9 Prediction results of the pre-valve pressure 5.5 MPa model

和振动信号,其中 1~3 号样本为径向偏心故障,4~6 号样本为局部损伤故障,7~9 号样本为阀芯粗糙故障。经过小波包分析提取特征参数后与阀前压力一起作为变量输入 CS-SVR 预测模型,模型预测结果如图 9 所示。可以看出在新的阀前压力下,预测模型依旧有较好的准确性,因此认为该模型具有较强的鲁棒性。

表 5 不同输入信号预测数据对比

Table 5 Comparison of prediction data of different input signals

实验编号	故障状态	输入变量预测结果/(mL·min ⁻¹)			实验数据/(mL·min ⁻¹)
		多变量	声发射信号	振动信号	
1	偏心 0.05 mm	17.508	32.911	19.841	19.581
2	粗糙度 Ra3.2	19.985	33.017	21.504	19.817
3	粗糙度 Ra3.2	16.515	33.421	19.666	20.518
4	偏心 0.05 mm	19.345	32.791	23.724	21.890
5	粗糙度 Ra3.2	33.864	35.322	39.872	29.207
6	偏心 0.1 mm	33.939	32.700	35.950	32.655
7	粗糙度 Ra6.3	43.980	35.260	41.987	36.816
8	偏心 0.2 mm	40.567	33.716	34.587	40.162
9	粗糙度 Ra12.5	48.177	34.395	38.784	44.178
10	轻度局部损伤	60.938	33.316	54.060	53.227
11	中度局部损伤	123.41	89.329	46.696	123.70
12	中度局部损伤	122.16	111.00	55.757	134.30
13	严重局部损伤	525.58	544.08	75.068	530.14

表 6 不同输入变量模型结果对比

Table 6 Comparison of model results with the different input variables

输入变量	MSE	R ²	最大相对误差
多变量	26.57	0.998 5	8.97%
声发射信号	259.88	0.985 4	31.4%
振动信号	16878	0.052 7	24.4%

5 结 论

受压力、结构、环境等多种因素的影响,单向阀的内

泄漏测定非常复杂,本文提出了一种基于多源信号和 CS-SVR 的单向阀泄漏率无损检测方法。利用不同工况和多种故障下单向阀阀芯内泄漏的实验数据对模型进行训练,构建了单向阀内泄漏预测模型并进行了鲁棒性验证。具体结论如下:

1) 对比声发射信号、振动信号、多源信号分别作为泄漏量预测模型输入的预测结果,以平均相对误差比值作为评价指标,得多源信号:声发射:振动为 1.0 : 3.5 : 2.7,说明多源信号的预测精度最高。

2) 基于多源信号的预测模型可实现不同压力、不同故障程度、不同故障类别的单向阀内泄漏率准确预测,平均相对误差为 8.97%,表明了本方法具有非常好的鲁棒性。

3) CS 方法对 SVR 进行参数寻优取得了较高的精度。布谷鸟搜索算法对 SVR 模型进行参数寻优,使得模型能根据输入的样本自动寻找模型的最优参数,该寻优方法相对于粒子群算法和网格搜索法具有较大优势。

4) 单向阀内泄漏时,声发射信号的频率集中在 0~170 kHz,且声发射信号中各频段的干扰信号较多,在泄漏小的时候尤为明显,振动信号的频率集中在 0~60 Hz,60 Hz 之后的幅值基本为 0。两种故障信号的幅值均随着泄漏率的增加而增加。

本文提出的方法针对单向阀内泄漏检测有较好的鲁棒性,为开发实用的阀内泄漏无损检测技术提供基础支持。

参考文献

[1] XIE X L, HE D. Hydraulic decoder flow control valve leakage simulation based on AMESim [J]. Scientific Journal of Intelligent Systems Research, 2020, 2(12): 30-35.

[2] ZHU S B, LI Z L, LI X, et al. Convolutional neural networks-based valve internal leakage recognition model [J]. Measurement, 2021, 178: 109395.

[3] LI L, HUANG Y X, TAO J F, et al. Featured temporal segmentation method and AdaBoost-BP detector for internal leakage evaluation of a hydraulic cylinder [J].

- Measurement, 2018, 130: 279-289.
- [4] YE G Y, XU K J, WU W K. Multivariable modeling of valve inner leakage acoustic emission signal based on Gaussian process [J]. Mechanical Systems and Signal Processing, 2020, 140: 106675.
- [5] ZHAO H, LI Z, ZHU S, et al. Valve internal leakage rate quantification based on factor analysis and wavelet-BP neural network using acoustic emission [J]. Applied Sciences, 2020, 10(16): 5544.
- [6] GUO Y, XIONG G, ZENG L C, et al. Modeling and predictive analysis of small internal leakage of hydraulic cylinder based on neural network [J]. Energies, 2021, 14(9): 2456-2456.
- [7] EWAEWNOI W, PRATEEPASEN A, KAEWTRAKU-LPONG P. Investigation of the relationship between internal fluid leakage through a valve and the acoustic emission generated from the leakage [J]. Measurement, 2010, 43(2): 274-282.
- [8] 李振林, 张海峰, 夏广辉. 基于声发射理论的阀门气体内漏量化检测研究 [J]. 振动与冲击, 2013, 32(15): 77-81.
LI ZH L, ZHANG H F, XIA G H. Quantitative detection of valve internal air leakage based on acoustic emission theory [J]. Journal of Vibration and Shock, 2013, 32(15): 77-81.
- [9] 林伟国, 吴石恩. 阀门内漏声波监测及其信号特征提取方法 [J]. 振动与冲击, 2018, 37(9): 120-126.
LIN G W, WU SH EN. Acoustic monitoring and signal feature extraction for valve internal leakage [J]. Journal of Vibration and Shock, 2018, 37(9): 120-126.
- [10] 付乃政, 黄国勇. 小样本下基于 GADF 和 ProNet 的单向阀故障诊断方法 [J]. 机械设计与研究, 2022, 38(4): 132-137.
FU N ZH, HUANG G Y. A fault diagnosis method of check valve based on GADF and prototype network under small samples [J]. Machine Design and Research, 2022, 38(4): 132-137.
- [11] 师冲, 任燕, 汤何胜, 等. 基于经验模式分解和一维密集连接卷积网络的电液换向阀内泄漏故障诊断方法 [J]. 液压与气动, 2021(1): 36-41.
SHI CH, REN Y, TANG H SH, et al. Fault diagnosis for internal leakage of electro-hydraulic directional valve based on EMD and one-dimensional densely connected convolutional networks [J]. Chinese Hydraulics & Pneumatics, 2021(1): 36-41.
- [12] 翟小婕. 数据驱动的滚动轴承故障诊断与剩余寿命预测 [D]. 北京: 北京交通大学, 2021.
- ZHAI X J. Rolling bearing fault diagnosis and remaining life prediction based on data-driven [D]. Beijing: Beijing Jiaotong University, 2021.
- [13] 王一鹏, 陈学振, 李连玉. 基于小波包混合特征和支持向量机的机床主轴轴承故障诊断研究 [J]. 电子测量与仪器学报, 2021, 35(2): 59-64.
WANG Y P, CHEN X ZH, LI L Y. Research on fault diagnosis of machine spindle bearing based on wavelet packet mixing feature and SVM [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(2): 59-64.
- [14] 何彦, 肖圳, 李育锋, 等. 使用 CNN-SVR 的汽车组合仪表组装质量预测方法 [J]. 中国机械工程, 2022, 33(7): 825-833.
HE Y, XIAO ZH, LI Y F, et al. An assembly quality prediction method for automotive instrument clusters using CNN-SVR [J]. China Mechanical Engineering, 2022, 33(7): 825-833.
- [15] 魏许杰, 王红军, 邢济收, 等. 基于 CGA-SVR 的电机主轴磨损故障诊断方法研究 [J]. 电子测量与仪器学报, 2022, 36(6): 107-112.
WEI X J, WANG H J, XING J SH, et al. Research on wear fault diagnosis of motorized spindle based on CGA-SVR [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(6): 107-112.
- [16] 格兴. 基于 CS-SVR 模型的典型间隙击穿电压计算 [D]. 北京: 华北电力大学(北京), 2021.
GE X. Calculation of typical gap breakdown voltage based on CS-SVR model [D]. Beijing: North China Electric Power University (Beijing), 2021.
- [17] 徐宏东, 高海波, 徐晓滨, 等. 基于证据推理规则 CS-SVR 模型的锂离子电池 SOH 估算 [J]. 上海交通大学学报, 2022, 56(4): 413-421.
XU H D, GAO H B, XU X B, et al. State of health estimation of lithium-ion battery using a CS-SVR model based on evidence reasoning rule [J]. Journal of Shanghai Jiao Tong University, 2022, 56(4): 413-421.
- [18] 高倩霞, 李录平, 饶洪德, 等. 阀门泄漏率的声发射测定技术研究 [J]. 动力工程学报, 2012, 32(1): 42-46.
GAO Q X, LI L P, RAO H D, et al. Acoustic emission theory and testing technology for quantitative diagnosis of valve leakages [J]. Journal of Chinese Society of Power Engineering, 2012, 32(1): 42-46.
- [19] KIM S J, KIM K, HWANG T, et al. Motor-current-

based electromagnetic interference de-noising method for rolling element bearing diagnosis using acoustic emission sensors[J]. *Measurement*, 2022, 193: 110912.

- [20] 邱增明, 翟敬宇, 陈玉刚, 等. 宽带白噪声激励下粘弹性阻尼薄板的振动分析[J]. *机电工程技术*, 2016, 45(4): 84-88.

QIU Z M, ZHAI J Y, CHEN Y G, et al. Vibration analysis of constrained viscoelastic plate under broadband white noise excitation [J]. *Mechanical & Electrical Engineering Technology*, 2016, 45(4): 84-88.

- [21] 张铭, 王文芳, 郜一川. 基于光谱技术检测梨果实可溶性糖含量的方法[J]. *河北农业大学学报*, 2022, 45(1): 79-84.

ZHANG M, WANG W F, GAO Y CH, et al. Method for detecting soluble sugar content of pear based on spectroscopic technique [J]. *Journal of Hebei Agricultural University*, 2022, 45(1): 79-84.

作者简介



童成彪(通信作者), 2017 年于湖南大学获得博士学位, 现为湖南农业大学教授, 主要研究方向为机械设备故障诊断与性能优化。

E-mail: tongcb@163.com

Tong Chengbiao (Corresponding author) received his Ph. D. degree from Hunan University in 2017. Now he is a professor at Hunan Agricultural University. His main research interests include mechanical equipment fault diagnosis and performance optimization.



李威, 2020 年与湖南农业大学获得学士学位, 现为湖南农业大学硕士研究生, 主要研究方向为机械故障诊断。

E-mail: 847553546@qq.com

Li Wei received his B. Sc. degree from Hunan Agricultural University in 2020. Now he is a M. Sc. candidate at Hunan Agricultural University. His main research interest includes mechanical fault diagnosis.