

DOI:10.3969/j.issn.1001-4551.2020.12.016

基于神经网络和证据融合的液压泵故障诊断研究*

朱冠霖¹, 王兆强^{1*}, 王异凡², 李志峰³, 孙崇智⁴

(1. 上海工程技术大学 机械与汽车工程学院, 上海 201620; 2. 国网浙江省电力有限公司 电力科学研究院, 浙江 杭州 310007; 3. 甘肃省特种设备安全技术检查中心, 甘肃 兰州 730020; 4. 甘肃省特种设备检验检测研究院, 甘肃 兰州 730050)

摘要:针对单一传感器检测易受到环境干扰, 很难准确分辨出液压泵故障类型的问题, 将神经网络分类识别及证据理论融合技术应用到液压泵故障诊断中。对自适应调节方法优化的粒子群神经网络(PSO-BP)故障分类、D-S 证据理论中融合悖论及失效问题的改进进行了研究; 使用认知因子、社会因子动态指导粒子寻优, 并利用引力思想构造两条故障证据间新的冲突系数, 进而提出了符合液压泵故障诊断的多源传感器数据融合模型; 通过实验构造液压泵的 6 种运行状态并分别进行了故障诊断测试。研究表明: 使用自适应调节方法优化的粒子群神经网络对液压泵的故障诊断准确率有所提高, 分别达到 93.50%、93.67%, 融合诊断结果支持度均接近 1, 降低了诊断的模糊性。

关键词:柱塞泵; 液压故障诊断; 多源传感器; 神经网络; 证据融合

中图分类号: TH137.51; TP183

文献标识码: A

文章编号: 1001-4551(2020)12-1498-06

Hydraulic pump fault diagnosis based on neural network and evidence fusion

ZHU Guan-lin¹, WANG Zhao-qiang^{1*}, WANG Yi-fan², LI Zhi-feng³, SUN Chong-zhi⁴

(1. School of Mechanical and Automotive Engineering, Shanghai University of Engineering Science, Shanghai 201620, China; 2. National Network of Zhejiang Electric Power Corporation Power Science Research Institute, Hangzhou 310007, China; 3. Gansu Special Equipment Safety Technical Inspection Center, Lanzhou 730020, China; 4. Gansu Province Special Equipment Inspection and Testing Institute, Lanzhou 730050, China)

Abstract: Aiming at the problem that single sensor detection was susceptible to environmental interference, and it was difficult to accurately distinguish the type of hydraulic pump failure, the neural network classification recognition and evidence theory fusion technology were applied to hydraulic pump fault diagnosis. The particle swarm neural network (PSO-BP) fault classification optimized by the adaptive adjustment method, the fusion paradox and the improvement of the failure problem in the D-S evidence theory were studied. The cognitive factors and social factors were used to dynamically guide the particle optimization. A new conflict coefficient between two fault evidences was constructed by using the idea of gravitation. Furthermore, a multi-source sensor data fusion model which conformed to hydraulic pump fault diagnosis was proposed. Six operating states of hydraulic pumps were constructed through experiments and fault diagnosis tests were conducted respectively. The results indicate that the particle swarm neural network optimized by the adaptive adjustment method can improve the fault diagnosis accuracy of hydraulic pumps, reaching 93.50% and 93.67% respectively. The support degree of fusion diagnosis results is close to 1, which reduces the fuzziness of diagnosis.

Key words: plunger pump; hydraulic fault diagnosis; multisource sensors; neural network; evidence fusion

收稿日期: 2020-03-14

基金项目: 国家自然科学基金资助项目(51505272、51505274); 流体动力与机电系统国家重点实验室开放基金项目(GZKF-201514)

作者简介: 朱冠霖(1993-), 男, 江苏连云港人, 硕士研究生, 主要从事液压故障诊断及智能算法方面的研究。E-mail: glzhu_njfu@163.com

通信联系人: 王兆强, 男, 教授, 硕士生导师。E-mail: wangzhaoqiang_2008@126.com

0 引言

随着机械工业的发展,对机械设备故障诊断的要求也进一步提高^[1,2]。柱塞泵一类的液压泵是各类机械动力的输出端,由于其位置的重要性,已经有很多专家学者都对其展开了故障诊断方面的研究^[3,4],比如基于经验小波分解和卷积神经网络的液压泵故障诊断等。

一般来说,液压泵(柱塞泵)一旦发生故障,故障会反映在某些特征信号上,使用信号增强技术可对故障特征进行提取^[5]。故障检测可通过与已知的理论故障特征进行匹配来实现,但不同的故障类型往往具有相似的特征频率。此外,液压泵有些故障机制尚不清楚,很难给出相应的理论特征作为故障模式的标准^[6]。

神经网络算法可以有效解决这类问题,在液压故障诊断等领域得到广泛应用。文献[7]使用 PNN 概率神经网络,实验选取 5 阶固有频率作为特征值输入到诊断网络中,结果发现可以较好地识别出复杂环境下的液压系统漏油故障。文献[8]使用经验模态分解与神经网络相结合的方法对柱塞泵进行故障诊断,实验发现该方法可以大幅减少诊断时间。本文将基于神经网络算法对液压泵进行故障诊断。

另外,目前关于液压泵的故障诊断大多依赖于单一传感器来诊断,但是现实环境中由于高温、强电磁等复杂环境的影响,传感器并不总是可靠的^[9]。因此,可基于 D-S 证据理论对多源信息进行融合,从而提高诊断效果^[10]。

针对证据组合存在的问题^[11,12],笔者对原始证据进行修正,并通过类比引力定律定义两证据间的引力,进而提出新的衡量证据冲突程度的系数,最后通过案例验证该方法的有效性,为柱塞泵一类液压泵的故障诊断提供技术借鉴。

1 粒子群神经网络分类理论

目前,基于前馈型(BP)神经网络^[13]的故障识别技术在液压故障诊断领域得到了广泛的应用。可通过将粒子群(PSO)融入 BP 神经网络中^[14],以此提高 BP 网络的全局寻优能力。

设由 m 个粒子在 D 维目标搜索空间中组成一个群体,其粒子更新公式为:

$$x_{id}(t+1) = x_{id}(t) + v_{id}(t+1) \quad (1)$$

$$v_{id}(t+1) = v_{id}(t) + c_1 r_1 (p_{id} - x_{id}(t)) + c_2 r_2 (p_{gd} - x_{id}(t)) \quad (2)$$

式中: i —粒子序号; d —粒子维度; t —迭代次数; c_1 —认知因子; c_2 —社会因子; r_1, r_2 — $[0,1]$ 上的随机数; $x_{id}(t)$ —第 i 个粒子迭代 t 次后的位置; v_{id} —第 i 个粒子迭代 t 次后的速度; p_{id} —第 i 个粒子当前的最优位置; p_{gd} —粒子群当前的最优位置。

对于 c_1 和 c_2 ,加入动态调整参数如下所示:

$$c_1 = \alpha + \frac{i}{\maxgen} \cdot (\beta) \quad (3)$$

$$c_2 = \gamma + \frac{i}{\maxgen} \cdot (-\delta) \quad (4)$$

式中: $\alpha, \beta, \gamma, \delta$ —设定参数值; \maxgen, i —粒子群设定的最大进化代数、当前进化代数。

PSO - BP 中粒子的适应度函数如下所示:

$$E = \frac{1}{P} \sum_{\lambda=1}^P \sum_{k=1}^s (t_k^\lambda - y_k^\lambda)^2 (\lambda = 1, 2, \dots, P) \quad (5)$$

式中: P —样本总数; s —输出层个数; y_k —实际输出值; t_k —期望值。

2 证据理论

2.1 D-S 证据理论

在对液压泵中多个传感器信息融合时,由于人为或环境方面的原因导致测量值不准确甚至是出现缺失的情况,而 D-S 证据理论就可以处理这些信息融合中存在的确定性。

D-S 基本概率分配函数如下所示:

$$m(\emptyset) = 0, \sum_{A \in \Theta} m(A_i) = 1 \quad (6)$$

式中: A_i —概率分配函数焦点; Θ —辨识框架,满足 $2^\Theta \rightarrow [0,1]$ (2^Θ 是 Θ 中所有子集组成的集合)。

利用 D-S 证据理论进行组合的规则公式如下所示:

$$m(A) = \begin{cases} 0 & A = \emptyset \\ \frac{\sum_{A_i \cap B_j = A} m_1(A_i) \cdot m_2(B_j)}{1 - k} & A \neq \emptyset \end{cases} \quad (7)$$

式中: m_1, m_2 —概率分配函数; B_j —概率分配函数的焦点; k —冲突系数。

其中:

$$K = \sum_{A_i \cap B_j = \emptyset} m_1(A_i) \cdot m_2(B_j) \quad (8)$$

2.2 证据融合改进

证据理论对信息进行合成时,往往会出现与事实相悖甚至是融合算法失效的问题^[15]。本文在传统的证据融合基础上进行相应的改进,以两条证据融合为例,具体步骤如下:

(1) 修正原始故障证据分配值,如下所示:

$$m_{1,2}(A_i) = \begin{cases} 10^{m_{1,2}(A_i)}, & m_{1,2}(A_i) < \frac{1}{n} \\ 10^{m_{1,2}(A_i) + \frac{1}{n}}, & m_{1,2}(A_i) \geq \frac{1}{n} \end{cases} \quad (9)$$

式中: n —焦元 A 对应的事件个数。

然后对各个数据进行权重计算,方法如下所示:

$$m'_i(A_j) = \frac{m_i(A_j)}{\sum_{j=1}^n m_i(A_j)} \quad (10)$$

(2) 计算证据体间的距离,如下所示:

$$d = \sqrt{\frac{1}{2}(\vec{m}_1 - \vec{m}_2)^T \cdot (\vec{m}_1 - \vec{m}_2)} \quad (11)$$

(3) 计算两条证据间的熵值 H_1, H_2 , 如下所示:

$$H_1 = - \sum_{i=1}^n p'_i \log_2 p'_i \quad (12)$$

$$H_2 = - \sum_{i=1}^n q'_i \log_2 q'_i \quad (13)$$

式中: p_i — m_1 函数对应的各概率分配值; q_i — m_2 函数对应的各概率分配值。

(4) 计算两条证据间的引力 F , 如下所示:

$$F = \frac{H_1 \times H_2}{d^2} = \frac{(- \sum_{i=1}^n p'_i \log_2 p'_i)(- \sum_{i=1}^n q'_i \log_2 q'_i)}{\frac{1}{2}(\vec{m}_1 - \vec{m}_2)^T D (\vec{m}_1 - \vec{m}_2)} \quad (14)$$

(5) 计算两条故障证据间新的冲突系数 F^* , 即将式(14)中计算得到的作用力映射到区间 $[0, 1]$ 上,计算方法如下式所示:

$$F^* = 1 - \frac{\arctan F}{\frac{\pi}{2}} \quad (15)$$

(6) 对证据体进行融合,公式如下:

$$m(A) = \begin{cases} 0, & A = \emptyset \\ \frac{1}{1 - F^*} \sum_{B \cap A = A} m'_1(B) m'_2(A), & A \neq \emptyset \end{cases} \quad (16)$$

(7) 对冲突系数设置阈值 T , 当 $F^* > T$ 时,直接输出第 6 步中的融合结果。若 $F^* < T$, 说明两者间不是高冲突故障证据,进入下一步;

(8) 对初始融合的故障结果设置阈值,当 $m(A) < \lambda$ 时,对结果乘以一个衰减系数 α , 以进一步减小故障支持度较低的权重大小,然后计算各个数据权重,得到最后结果。

3 故障诊断模型搭建

笔者设计故障诊断模型,选择出油口的振动信号、外泄口温度以及系统出油口的压力信号作为传感器测试源,以此作为模型的入口。

具体故障诊断融合模型如图 1 所示。

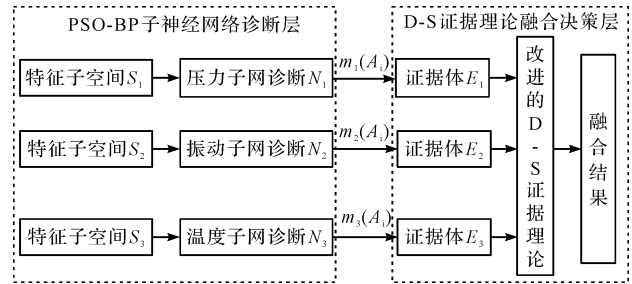


图 1 故障诊断融合模型

笔者将采集的振动和压力信号分别计算出 8 个特征指标(峰值、波形指标、脉冲、裕度指标、峭度指标、频域方差、功率谱重心指标、相关因子)来构造特征空间,并和温度数据进行归一化处理,分别构造正常及故障状态下的数据训练库。使用三级 PSO - BP 分类算法、改进的 D-S 证据理论进行融合诊断。

4 液压故障诊断案例

4.1 实验描述

为了验证故障诊断模型及对应算法的有效性,笔者设计柱塞泵模型诊断实验,通过放置已知故障类型的柱塞泵,或者更换内部故障的滑靴、配流盘等构造故障模型,进行模拟实验。

一般情况下,带有故障的柱塞泵自吸性能差,所以在测试系统油路中加入两个叶片泵进行补油。

实验原理图如图 2 所示。

分别构造正常状态、失效油封漏油故障、缸体切割深度 0.5 mm, 宽度 0.3 mm、轴承切割深度 0.5 mm, 宽度 0.2 mm、配流盘磨损 0.3 mm、活塞间隙 0.25 mm 的松靴故障这 6 种状态进行检测,即模式输出 $Y = \{f_1, f_2, f_3, f_4, f_5, f_6\}$, 每种模式对应的故障输出训练矩阵如表 1 所示。

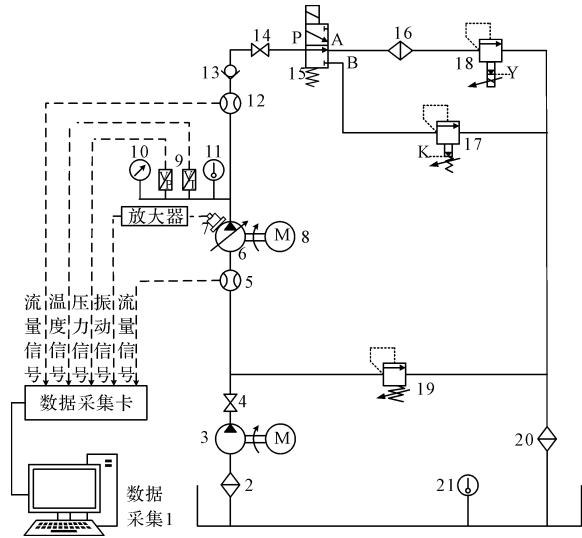


图 2 实验原理图

1 - 油箱;2,16,20 - 粗过滤器;3 - 叶片泵;4,14 - 截止阀;5,12 - 流量计;6 - 被测轴向柱塞泵;7 - 振动传感器;8 - 变频电机;9 - 信号调理模块;10 - 压力计;11 - 温度传感器;13 - 单向阀;15 - 二位三通电磁换向阀;17 - 先导式溢流阀;18 - 先导式比例溢流阀;19 - 直动式溢流阀;21 - 油液温度计

表 1 故障输出训练矩阵


故障模式	f_1	f_2	f_3	f_4	f_5	f_6
正常	1	0	0	0	0	0
漏油	0	1	0	0	0	0
缸体磨损	0	0	1	0	0	0
轴承磨损	0	0	0	1	0	0
配流盘磨损	0	0	0	0	1	0
松靴故障	0	0	0	0	0	1

4.2 结果分析

笔者对每个子网测试提取的指标数据各选取 500 条作为网络训练集,500 条作为故障诊断测试集进行故障类型分析。构造 3 层子神经网络,输入层对应特征指标的个数为 8,输出层对应故障类型数量为 6,根据实验经验,这里设置隐含层数为 15,粒子群规模 20,迭代次数 1 000 次。两个学习因子中的参数分别取 0.5、1、2、1。


由实验得出振动分类混淆矩阵结果如图 3 所示。

未优化前故障分类混淆矩阵 准确率=88.833 333%



(a) 优化前混淆矩阵结果

优化后故障分类混淆矩阵 准确率=93.500 000%




(b) 优化后混淆矩阵结果

图 3 振动分类混淆矩阵结果

对于振动子网诊断结果可知,优化前的故障分类准确率为 88.83%,优化后的故障分类准确率为 93.5%。其中优化后的混淆矩阵显示:模式 2 的 4.762% 被识别为模式 1;模式 3 的 8.511% 被识别为模式 2;模式 4 的 5.208% 被识别为模式 3;模式 5 的 1% 被识别为模式 6,错误率较未分类均有所改善。

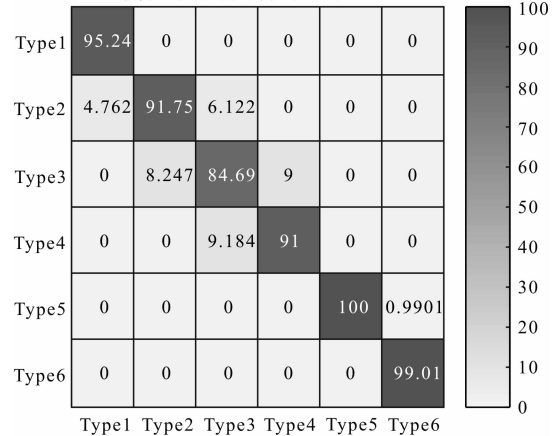
对于压力子网分类混淆矩阵结果如图 4 所示。

未优化前故障分类混淆矩阵 准确率=89.833 333%



(a) 优化前混淆矩阵结果

优化后故障分类混淆矩阵 准确率=93.666 667%



(b) 优化后混淆矩阵结果

图 4 压力分类混淆矩阵结果

对于压力子网,优化前的故障分类准确率为 89.83%,优化后的故障分类准确率为 93.67%。其中,优化前的混淆矩阵显示,模式 3 的 12.5% 被识别为模式 2,模式 4 的 16.94% 被识别为模式 3,错误率较高,这两者经过优化后结果分别为 8.247% 和 9.184%。同样,对于温度子网来说,优化后的效果要优于优化前的诊断效果,这里不再详细分析。

以 f_5 类故障为例,设置证据融合阈值 λ 为 0.5,衰减系数 α 取 0.2,利用 3 个独立子网及改进的 D-S 算法诊断输出结果如表 2 所示。

表 2 各诊断输出结果

子网类型	诊断支持度 (%)					
	f_1 类	f_2 类	f_3 类	f_4 类	f_5 类	f_6 类
压力子网	0.5	19.3	0.9	1.3	76.5	1.5
振动子网	14.8	11.1	0.2	10	62.5	1.4
温度子网	1.3	4.4	7.8	2.5	78.5	5.5
融合结果	0.15	0.34	0.13	0.14	99.12	0.12

由表 2 可知:三级子网对 f_5 类故障诊断输出结果分别是 76.5%、62.5%、78.5%。经过融合算法联合诊断结果输出为 99.12%。

各输出结果对比如图 5 所示。




图 5 各输出结果对比

由图 5 可知:改进的融合算法对 f_5 类轴承磨损故障支持度接近 100%,对比其他子网,基本排除了其他故障类型的可能性。

同理,设置证据融合阈值值为 0.5,衰减系数取 0.2,将 f_3 类故障类型分别使用子网及改进的 D-S 算法诊断,各诊断输出结果如表 3 所示。

由表 3 可知:各诊断子网对 f_3 类缸体磨损故障诊断输出结果分别是 78.4%、70.4%、70.5%,经过改进 D-S 数据融合处理后的诊断输出提高到 99.17%。

表 3 各诊断输出结果

子网类型	诊断支持度 (%)					
	f_1 类	f_2 类	f_3 类	f_4 类	f_5 类	f_6 类
压力子网	2.1	15.7	78.4	2.4	1.2	0.2
振动子网	1.5	5.9	70.4	0.9	0.2	21.1
温度子网	2.7	15.9	70.5	5.1	3.5	2.3
融合结果	0.11	0.23	99.17	0.12	0.11	0.25

各输出结果对比如图 6 所示。




图 6 各输出结果对比

由图 6 可以发现,相比各子网结果,使用改进的融合算法对 f_3 类缸体磨损故障支持度进一步提高,降低了结果的模糊性。

通过以上实验可知:采用自适应调节认知因子、社会因子优化网络分类法,对轴承磨损以及缸体磨损准确度均有一定的提升,但其正确率依赖于相关参数的选取,还需要作进一步的优化,以增强模型的稳定性。

5 结束语

液压泵(柱塞泵)一旦发生故障,故障会反映在某些特征信号上,使用信号增强技术可对故障特征进行提取,但液压元件在工作环境中易受到各类噪声的污染,而且存在传感器自身发生故障的情况。

笔者采用加入调节参数优化的 PSO-BP 局部诊断网络,发现构建的振动子网诊断正确率由 88.83% 提高到 93.50%,压力子网诊断准确率由 89.83% 提高到 93.67%,进一步使用所提出的改进证据理论步骤进行融合诊断,发现各故障类型诊断支持度均接近于 1,有效避免了子网识别的模糊性。由此可见,其对柱塞泵的故障诊断具有一定的工程实用价值。

另外还需要指出的是,本文参数的选取具有一定

的经验性,因此,将来还要进一步研究自适应工况最优参数选取的问题,这是今后研究的一个方向。

参考文献 (References):

- [1] 杜名喆,王宝中. 基于经验小波分解和卷积神经网络的液压泵故障诊断[J]. 液压与气动,2020(1):163-170.
- [2] 张旭. 装载机液压系统故障诊断分析[J]. 机电工程技术,2018,49(10):159-160.
- [3] WANG S, XIANG J. A minimum entropy deconvolution-enhanced convolutional neural networks for fault diagnosis of axial piston pumps [J]. **Soft Computing**, 2020, 24(4): 2983-2997.
- [4] LI H R, TIAN Z K, YU H, et al. Fault Prognosis of Hydraulic Pump Based on Bispectrum Entropy and Deep Belief Network [J]. **Measurement Science Review**, 2019, 19(5):195-203.
- [5] HE Q. Time-frequency manifold for nonlinear feature extraction in machinery fault diagnosis [J]. **Mechanical systems & Signal Processing**, 2013, 35(1-2):200-218.
- [6] KUMAR S, BERGADA J M, WATTON J. Axial piston pump grooved slipper analysis by CFD simulation of three-dimensional NVS equation in cylindrical coordinates [J]. **Computers and Fluids**,2009,38(3):648-663.
- [7] 王立文,刘 强,霍金鉴,等. 基于概率神经网络的液压管路泄漏故障程度识别[J]. 机床与液压,2020,48(4):159-164.
- [8] 杜振东,赵建民,李海平,等. 基于 SA-EMD-PNN 的柱塞泵故障诊断方法研究[J]. 振动与冲击,2019,38(8):145-152.
- [9] 王异凡,朱冠霖,王兆强,等. 基于改进小波阈值的 GIS 局部放电在线监测白噪声干扰抑制研究[J]. 高压电器,2019,55(3):37-43,50.
- [10] 王鸿飞,刘海斌,邓鑫洋,等. 基于幂均算子和证据理论的故障诊断方法[J]. 信息与控制,2019,48(5):567-572.
- [11] 张 欢,陆见光,唐向红. 面向冲突证据的改进 DS 证据理论算法[J]. 北京航空航天大学学报,2020,46(3):616-623.
- [12] 冯玉萍. 基于聚类证据理论的数据融合算法研究[D]. 长沙:湖南大学信息科学与工程学院,2016.
- [13] 苏一新,马彦会,石 倩,等. 基于 BP 神经网络模型的磁悬浮水泵 PID 多数优化[J]. 压力容器,2018,46(1):20-24,33.
- [14] 王 磊,李双喜,朱乔峰,等. 基于 PSO-BP 的调控型气体密封状态多数智能计算方法研究[J]. 流体机械,2017,45(11):10-16.
- [15] 宋 轲. 基于集合经验模态分解和 D-S 证据理论的异质数据融合[D]. 上海:上海交通大学机械与动力工程学院,2018.

[编辑:冯黎雅]

本文引用格式:

朱冠霖,王兆强,王异凡,等. 基于神经网络和证据融合的液压泵故障诊断研究[J]. 机电工程,2020,37(12):1498-1503.

ZHU Guan-lin, WANG Zhao-qiang, WANG Yi-fan, et al. Hydraulic pump fault diagnosis based on neural network and evidence fusion[J]. *Journal of Mechanical & Electrical Engineering*, 2020,37(12):1498-1503.

《机电工程》杂志: <http://www.meem.com.cn>