

本文网址: <http://www.ship-research.com/cn/article/doi/10.19693/j.issn.1673-3185.03513>

期刊网址: www.ship-research.com

引用格式: 孙广西, 曹辉, 张子威, 等. 基于 GA-GMDH 算法的离心泵退化识别 [J]. 中国舰船研究, 2024, 19(5): 254–262.

SUN G X, CAO H, ZHANG Z W, et al. Centrifugal pump degradation identification based on GA-GMDH algorithm[J]. Chinese Journal of Ship Research, 2024, 19(5): 254–262 (in Chinese).

基于 GA-GMDH 算法的离心泵退化识别



扫码阅读全文

孙广西¹, 曹辉^{*1,2}, 张子威¹, 马振豪¹

1 大连海事大学 轮机工程学院, 辽宁 大连 116026

2 大连海大智船科技有限责任公司, 辽宁 大连 116026

摘要: [目的] 为实时监测离心泵的健康状态, 提出一种可实时识别离心泵退化状态的模型。[方法] 首先, 基于离心泵的运行参数和退化机理, 利用主客观相结合的组合赋权模型来计算组合权重, 进而构建离心泵退化过程中的健康指标; 然后, 基于现有离心泵的退化数据, 提出基于遗传优化-数据分组处理 (GA-GMDH) 算法的离心泵退化监测模型。[结果] GA-GMDH 监测模型的可靠性较高, 其健康指标输出值与真实值的均方根误差为 0.029 216, 依据该模型输出结果进行退化状态识别的精度为 93.333%。[结论] 研究成果可为离心泵的健康状态监测以及维护运营管理提供参考。

关键词: 离心泵; 组合赋权; 健康指标; 数据分组处理方法; 退化状态识别

中图分类号: U664.5⁸

文献标志码: A

DOI: 10.19693/j.issn.1673-3185.03513

Centrifugal pump degradation identification based on GA-GMDH algorithm

SUN Guangxi¹, CAO Hui^{*1,2}, ZHANG Ziwei¹, MA Zhenhao¹

1 Marine Engineering College, Dalian Maritime University, Dalian 116026, China

2 Dalian Maritime University Smart Ship Limited Company, Dalian 116026, China

Abstract: [Objective] In order to monitor the health status of a centrifugal pump in real time, this study proposes a model for the real-time identification of the degradation state of centrifugal pumps. [Methods] First, based on the operating parameters and degradation mechanism of the centrifugal pump, a combined weighting model using a combination of subjective and objective weights is used to calculate the combined weights, then a health index during the degradation process of the centrifugal pump is constructed. Second, based on the existing pump degradation data, a degradation identification model based on the genetic algorithm-group method of data handling (GA-GMDH) algorithm is proposed. [Results] The reliability of the GA-GMDH monitoring model is relatively high, with a root mean square error of 0.029 216 between the output values of the health index and the actual values. Based on the model's output results, the accuracy of degradation state identification is 93.333%. [Conclusion] The results of this study can provide valuable references for the health monitoring and maintenance operation management of centrifugal pumps.

Key words: centrifugal pump; combinatorial empowerment; health indicators; group method of data handling (GMDH); degenerate state identification

0 引言

在很多工业生产系统中, 离心泵是非常重要的设备, 也是系统的动力原件。离心泵的工作环境一般很恶劣, 且其性能退化不易被发现, 若发生

故障将对生产造成很大的影响, 严重时将威胁生命财产的安全, 因此, 为了保证系统的安全稳定运行, 有必要针对其性能退化展开研究。

目前, 国内外学者已针对该问题开展了一系列研究工作。刘祥楼等^[1]基于虚拟仪器技术的输油泵

收稿日期: 2023-08-15 修回日期: 2023-11-06 网络首发时间: 2024-02-26 15:42

基金项目: 国家重点研发计划资助项目 (2022YFB4301403); 辽宁省科技厅科学技术计划资助项目 (2022JH1/10800097)

作者简介: 孙广西, 男, 1999 年生, 硕士生。研究方向: 轮机自动化与智能化。E-mail: sgx215215@hrbeu.edu.cn

曹辉, 男, 1979 年生, 博士, 教授, 博士生导师。研究方向: 轮机自动化与智能化。E-mail: lustersoft@gmail.com

*通信作者: 曹辉

机组整体运行噪声,提出了电磁噪声的辨识与特征提取方法,并自主研发了输油泵机组电磁噪声自动监测分析仪,但该方法的数据获取难度较高,且无法实时识别设备的退化状态。刘锐等^[2]在离心泵流速公式的基础上,结合流速和间隙之间的物理关系,提出了一种离心泵的寿命评价方法。郭文琪^[3]发现矿井主排水泵的寿命预测方法需要多样化的指标支撑,故可结合多种预测模型来提高其准确性,并以卡尔曼滤波法为依据,实现了对离心泵关键参数的预测。王炳波等^[4]以无迹卡尔曼滤波法为依据,通过分析离心泵的工作参数,建立了其剩余寿命的预测模型。景博等^[5]提出了一种基于失效物理与数据驱动融合的燃油泵在线退化建模与寿命预测方法。姜万录等^[6]提出了基于完备总体经验模态分解和模糊熵结合的液压泵性能退化特征提取方法。Cao 等^[7]利用小波变换对泵的原始振动信号进行了滤波处理,并以隐马尔可夫模型为工具,提出了一种概率驱动辨识机制。Guo 等^[8]针对变速工况下轴向柱塞泵特征难以抽取等问题,提出了一种结合线性调频小波变换、自适应线性调频模式追踪和极限梯度提升的轴向柱塞泵的退化状态识别方法。然而,国内外的研究方法均需大量的数据作为驱动,且大部分利用的是振动数据,而该类型数据在实际应用过程中的采集难度较高,无法实时监测泵的健康状态。由于泵的退化具有多样性,因此应融入多个维度的数据,从而使模型更具有普适性。

针对离心泵使用过程中退化状态难以识别的问题,本文拟基于离心泵使用过程中的特征参数,综合考虑主客观因素,搭建一种可实时识别离心泵退化状态的模型。首先,将利用主客观相结合的组合赋权模型来计算组合权重;然后,基于现有离心泵的退化数据来计算离心泵退化过程中的健康指标;最后,以数据分组处理(group method of data handling, GMDH)方法作为工具来训练离心泵退化状态识别模型,并对模型的超参数进行寻优,从而实现对离心泵退化状态的实时识别。

1 退化分析及建模

1.1 离心泵退化机理建模

离心泵的健康状态涉及多个影响因素,例如叶轮磨损、轴承磨损、密封失效等。在离心泵性能衰退的过程中,其扬程、功率、效率等参数均会发生变化,所以可采用这 3 个参数对离心泵的健康状态进行表征^[9]。

根据离心泵的扬程 H -流量 Q 特性曲线,扬程与流量的函数关系为

$$H = K_1 + K_2Q + K_3Q^2 \tag{1}$$

式中, K_1, K_2, K_3 均为常数。

离心泵的实际扬程^[3]为

$$H = \frac{\mu}{g} \left[\sigma\mu - \frac{Q}{F} \cot\beta \right] - KQ^2 \tag{2}$$

式中: $\mu = D\pi n/60$, 为离心泵叶轮外径的线速度,其中 D 为叶轮的外圈直径, n 为泵的转速; g 为重力加速度; $\sigma = 1 - \pi \sin\beta/z$, 为离心泵斯托道拉修正系数,其中 β 为叶片与密封环的安放倾角, z 为叶片数量; $F = 2\pi R d \Phi$, 为叶轮出口的截面积,其中 R 为叶轮外圆半径, d 为叶片出口宽度, Φ 为叶轮出口排挤系数; K 为常数。联合式(1)和式(2),得 $K_1 = \mu^2\sigma/g$, $K_2 = -\mu \cot\beta/(g2\pi R d \Phi)$, $K_3 = -K$ 。

由于叶轮磨损将主要影响特性曲线的常数项 K_1 ,以 f 作为叶轮磨损的加速度,则叶轮磨损的公式为

$$K_1^* = K_1 - ft^2 \tag{3}$$

式中: K_1^* 为 K_1 的迭代量; 叶轮磨损加速度 f 为大于 0 的随机变量; t 为运行时间。

轴承磨损将主要影响泵的转速 n ,以 b 作为轴承磨损的速度,则轴承磨损的公式为

$$n^* = n - bt \tag{4}$$

式中, n^* 为 n 的迭代量。

为同时考虑 2 种磨损,将式(3)和式(4)代入式(1)和式(2),经过求解可得

$$H = K_1 + K_2Q + K_3Q^2 + (K_1b^2/n^2 - f)t^2 - (2K_1/n + K_2Q/n)bt \tag{5}$$

鉴于 K_1b^2/n^2 和 K_2Q/n 均趋近于 0,其对 H 的影响较小,故式(5)可简化为

$$H = K_1 + K_2Q + K_3Q^2 - ft^2 - 2K_1bt/n \tag{6}$$

综上所述,离心泵扬程在 2 种磨损下的退化与时间关系方程^[9]为

$$H = K_1 + K_2Q + K_3Q^2 - At_1^2 - Bt_1 \tag{7}$$

式中: 常数 $A=f/b^2$, 且 $A>0$; 常数 $B=2K_1/n$, 且 $B>0$; $t_1 = bt$ 。

离心泵的功率 P_e 及效率 η 为

$$\begin{cases} P_e = \rho g Q H \\ \eta = P_e/P \end{cases} \tag{8}$$

式中: ρ 为运输液体的密度; P 为电机的轴功率。

在离心泵实际退化过程中,其扬程、功率、效率数据分别如图 1~图 3 所示。




图 1 离心泵实际退化时所采集的扬程数据

Fig. 1 Lift data collected from actual degradation of centrifugal pump




图 2 离心泵实际退化时所采集的功率数据

Fig. 2 Power data collected from actual degradation of centrifugal pump




图 3 离心泵实际退化时所采集的效率数据

Fig. 3 Efficiency data collected from actual degradation of centrifugal pump

由式(7)可以看出,离心泵的扬程性能衰退曲线是二次函数;由式(8)可以看出,离心泵的功率、效率均与其扬程成正比,故该功率和效率的性能衰退曲线也是二次函数。为了更全面地评价离心泵的性能衰退情况,通过综合考虑功率、效率等多个性能衰退指标,将引入健康指标 $I_h = h(f, b, t_1)$ 。组合赋权的模型求解流程如图 4 所示,首先

结合层次分析法(analytic hierarchy process, AHP)^[9-10]和客观权重赋权法(criteria importance through intercriteria correlation, CRITIC)^[11-12]来计算组合权重,然后计算健康指标 I_h ,最后依据专家经验及健康指标对离心泵的退化状态进行划分。




图 4 AHP-CRITIC 组合赋权的求解流程

Fig. 4 Solution process of AHP-CRITIC combination weighting approach

采用最小鉴别信息原理^[13]将 2 种方法融合,即可计算组合权重 Y 。设定 AHP 法的权重向量 $W_j = [W_{j1}, W_{j2}, \dots, W_{jp}]$,其中 W_{jp} 为每个评价指标的相对权重,且 $j = 1, 2, \dots, J$,表示样本数量;设定 CRITIC 法的权重向量 $T_j = [T_{j1}, T_{j2}, \dots, T_{jp}]$,其中 T_{jp} 为每个评价指标的客观权重;设定组合权重向量 $\zeta_j = \zeta_1 W_j + \zeta_2 T_j$,其中 ζ_1 和 ζ_2 为组合系数。

建立目标函数 E :

$$\begin{cases} \min E(\zeta_j) = \left(\zeta_j \ln \frac{\zeta_j}{W_j} + \zeta_j \ln \frac{\zeta_j}{T_j} \right) \\ \text{s.t. } \sum_{j=1}^J \zeta_j = 1, \text{ 且 } \zeta_j \geq 0 \end{cases} \quad (9)$$

经求解,即可得到组合权重 Y :

$$\begin{cases} Y = [\zeta_1, \zeta_2, \dots, \zeta_J] \\ \zeta_j = \frac{\sqrt{W_j \cdot T_j}}{\sum_{j=1}^J \sqrt{W_j \cdot T_j}} \end{cases} \quad (10)$$

则健康指标 I_h 为

$$I_h = \zeta_H H_y + \zeta_P P_y + \zeta_\eta \eta_y \tag{11}$$

式中: $\zeta_H, \zeta_P, \zeta_\eta$ 分别为扬程、功率、效率等指标的组
合权重; H_y, P_y, η_y 分别为归一化后的扬程、功率
和效率。

1.2 GMDH 网络

GMDH 是借鉴了神经网络思想的一种复杂
系统自组织建模的算法。首先, 通过对系统的输
入特征进行组合, 从而生成一系列活动神经元,
并让每个神经元自主选择最适合的传递函数; 然
后, 在已生成的一代神经元中, 选择与目标变量
最接近的神经元, 并从中选取性能最优的组合作
为新一代神经元。这种算法可以自动发现数据中的
特征和模式, 无需手动干预而构建更准确的模型,
由此最终获得最优模型^[14-15]。图 5 所示为 GMDH
神经网络的结构示意图, 包含 4 个输入节点 $m_1, m_2,$
 m_3, m_4 和 1 个输出节点 y^* 。




图 5 GMDH 算法的网络结构示意图
Fig. 5 Network structure diagram of GMDH algorithm

对于给定的输入向量 $M=[m_1, m_2,...,m_q]$, 通过
搜寻函数 $\hat{f}$, 即可使搜索的结果尽量接近实际输
出值。针对复杂的非线性系统, 多输入、单输出
数据对的函数形式为

$$y_i = f(m_{i1}, m_{i2}, \dots, m_{iq}) \tag{12}$$

式中: y_i 为实际输出值, 其中 $i=1, 2,...,N$, 表示输入
变量的数量, N 为最大数量; $m_{i1}, m_{i2},...,m_{iq}$ 为输入
变量。

基于搜寻函数 $\hat{f}$, GMDH 神经网络的输出值
 y_i^* 为

$$y_i^* = \hat{f}(m_{i1}, m_{i2}, \dots, m_{iq}) \tag{13}$$

y_i^* 与实际值 y_i 之间一般存在偏差, 其残差的
平方和 z 为

$$z = \sum_{i=1}^N [\hat{f}(m_{i1}, m_{i2}, \dots, m_{iq}) - y_i]^2 \tag{14}$$

通过使 z 最小化, 即可获得 GMDH 网络。在
GMDH 网络的建立过程中, 除了网络权值、多项式
系数将对 GMDH 输出效果产生直接影响之外,
GMDH 网络层的最大神经元数、最大网络层数、学
习率等关键参数对模型监测性能的影响也较大^[16]。

遗传算法 (genetic algorithm, GA) 是一种模拟
自然界演化规律的随机全局优化方法, 具有搜索
简单、可避免局部最优、执行高效等优势, 其通过
基因遗传、交叉和变异而逐代优化解决方案, 已
广泛应用于求解复杂的优化问题^[17]。本文将 GA
算法对 GMDH 网络层的最大神经元数、最大网
络层数、学习率进行优化, 从而提升 GMDH 网络
的监测性能。

1.3 GA-GMDH 建模流程

GA-GMDH 模型监测及识别的流程如图 6 所
示, 具体实现步骤如下:

- 1) 利用离心泵现有的历史退化数据来计算
健康指标, 以确定模型的输入、输出向量, 进而划分
训练、测试样本。

2) 采用均方根误差 (root mean squared error,
RMSE) 作为 GA-GMDH 模型的适应度函数:

$$\begin{cases} \min f(m', r, v) = \sqrt{\frac{\sum_{x=1}^S (G_x - \hat{G}_x)^2}{S}} \\ \text{s.t. } m' \in [m'_{\min}, m'_{\max}], r \in [r_{\min}, r_{\max}] \\ v \in [v_{\min}, v_{\max}] \end{cases} \tag{15}$$

式中: m' 为网络层的最大神经元数, 下标 min
和 max 分别表示最小值和最大值; r 为最大网络
层数; v 为学习率; S 为训练集样本的最大数目; G_x
和 $\hat{G}_x$ 分别为第 x 个健康指标的实际值和模型输出
值, 其中 $x=1, 2,...,S$ 。

- 3) 设置 GA 算法的种群规模和迭代次数,
设置寻优参数的范围。

4) 计算适应度值。

5) 采用交叉、变异、选择等遗传算子处理当前
种群, 并产生下一代。

6) 判断是否满足收敛条件。若满足, 则执行
下一步; 不满足, 则执行步骤 3)、步骤 4)。

7) 输出 GMDH 最优参数 (最大神经元数 m' 、
最大网络层数 r 、学习率 v), 从而得到最优 GMDH
模型。

8) 利用 RMSE、平均绝对百分比误差 (mean




图 6 GA-GMDH 监测模型的基本流程图
Fig. 6 Basic flow chart of GA-GMDH model

absolute percentage error, MAPE)、平均绝对误差 (mean absolute error, MAE)对各模型的有效性进行评估,即

$$\begin{cases} e_{\text{RMSE}} = \sqrt{\frac{1}{R} \sum_{u=1}^R (G_u - \hat{G}_u)^2} \\ e_{\text{MAPE}} = \frac{1}{R} \sum_{u=1}^R \left| (G_u - \hat{G}_u) / G_u \right| \times 100\% \\ e_{\text{MAE}} = \frac{1}{R} \sum_{u=1}^R |G_u - \hat{G}_u| \end{cases} \quad (16)$$

式中:验证集样本数量 $u=1,2,\dots,R$,其中 R 为样本的最大数量; $G_u, \hat{G}_u$ 分别为第 u 个健康指标的实际值和模型输出值。

9) 将随机抽取的测试集输入 GA-GMDH 模型,即可依据模型输出的健康指标值进行离心泵的退化识别。

10) 利用识别准确率 R_r 对已保存模型的识别精度进行评判,即

$$R_r = P_r / S_c \quad (17)$$

式中: P_r 为根据模型输出进行退化等级识别时,与真实退化等级一致的样本数量; S_c 为测试集的样本数量。

2 模型验证及可行性分析

根据文献[3]的离心泵加速退化试验数据,本节将对模型进行验证,其数据集是在流量一定时,每间隔 2 h 记录一次泵扬程、功率及效率,运行时间 200 h,最终总计获取了 100 组数据。

2.1 健康指标的计算及退化程度划分

根据 Satty1-9 标度值法,经专家对 3 个特征参数进行相对重要性打分,即可构建 AHP 法的判断矩阵。AHP 法得到权重 0.139 65, 0.332 52, 0.527 84, CRITIC 权重法得到权重 0.574 52, 0.215 08, 0.210 4, 由式(9)到组合权重 0.320 444 695, 0.302 544 275, 0.377 011 03。

理论情况下,将 Q 取为额定流量 100 m³/h。根据需验证的离心泵类型,设置 K_1, K_2, K_3 数值,并将式(7)、式(8)及组合权重代入式(10)、式(11),即得额定流量下该类型离心泵的理论健康指标:

$$I_h = 10.162 - 0.638(f/b^2)t_1^2 - 0.008\,358t_1 \quad (18)$$

由式(18)可知,健康指标的性能退化曲线可以采用二次函数予以表示,其与轴承的磨损系数 b 及叶轮的磨损系数 f 密切相关。

将所采集的离心泵的扬程、功率、效率参数代入式(11),即可得出真实情况下离心泵的 100 组健康指标(无量纲参数),如图 7 所示。由图可知,离心泵的退化过程并非一直保持平稳,实际上存在一定的波动。

综合考虑离心泵的扬程、功率、效率因素,以健康指标作为标准进行退化等级识别,即可较好地避免因某个参数不满足其他参数对应的退化等级等问题。依据健康指标对退化等级进行划分,结果如表 1 所示。

2.2 健康指标有效性验证

通过调整式(18)中的参数 f 和 b ,即可使理论




图 7 离心泵的健康指标
Fig. 7 Health index of centrifugal pump

表 1 退化等级划分				
Table 1 Degradation classification				
扬程/m	功率/kw	效率	健康指标	退化程度
19.5~20.0	6.8~7.0	0.65~0.70	9.8以上	正常
18.0~19.5	6.0~6.8	0.60~0.65	9.0~9.8	轻微退化(A)
10~18	3.5~6.0	0.33~0.60	4~9	中度退化(B)
5~10	2.0~3.5	0.20~0.33	1~4	重度退化(C)
0~5	0~2.0	0~0.20	0~1	故障(D)

情况下的健康指标退化曲线发生变化,进而获得逼近实际健康指标的二次函数曲线。由图 8 可知,理论健康指标退化曲线与真实拟合的健康指标退化曲线较为接近,而真实健康指标在 2 条健康曲线之间波动,所以可用二次函数建立离心泵运行时间与健康指标之间的关系。




图 8 AHP-CRITIC 组合赋权得到的健康指标
Fig. 8 Health index obtained by AHP-CRITIC combination weighing approach

2.3 健康指标的监测模型

2.3.1 模型参数设置

利用 GA 算法对 GMDH 网络的参数进行寻优时,参数的寻优范围对模型构建存在很大的影响。由于学习率 v 的寻优范围 $[0.01, 0.9]$ 已知^[16],本文将针对 GMDH 的 3 个参数进行寻优。为了验证学习率的选取对其他 2 个参数的较优寻优范围的

影响较小,将学习率暂定为 0.5 和 0.7。通过控制变量法对基础模型进行参数设定,进而对最大网络层数 $r_{\max}$ 、最大神经元数 $m'_{\max}$ 的寻优范围进行初步寻找,多次实验得到的结果如表 2 所示。

表 2 基础模型的实验结果
Table 2 Experimental results of basic model

最大网络层数 $r_{\max}$	最大神经元数 $m'_{\max}$	学习率 v	训练集 e_{RMSE}
10	20	0.5	0.038 813
20	20	0.5	0.028 996 1
30	20	0.5	0.032 643
20	10	0.5	0.028 638
20	30	0.5	0.032 87
10	20	0.7	0.031 638
20	20	0.7	0.016 241
30	20	0.7	0.019 75
20	10	0.7	0.018 223
20	30	0.7	0.020 01

由表 2 可知:当模型的最大神经元数 $m'_{\max}$ 和学习率 v 一定时,训练集的 e_{RMSE} 将随着最大网络层数 $r_{\max}$ 的增加呈现先减小后增加的趋势,故可将模型的 $r_{\max}$ 的寻优范围设定为 $[10, 30]$;当模型的 $r_{\max}$ 一定,且学习率 v 为 0.7 时,训练集 e_{RMSE} 将随着最大神经元数 $m'_{\max}$ 的增加而呈现先减小后增加的趋势;当模型的 $r_{\max}$ 一定,且 v 为 0.5 时,训练集 e_{RMSE} 将随着 $m'_{\max}$ 的增加而增加,且前期的增加趋势较为缓慢,故可将 $m'_{\max}$ 的寻优范围设定为 $[10, 30]$ 。当 v 从 0.7 变为 0.5 时, $r_{\max}$ 及 $m'_{\max}$ 的寻优范围并未发生变化,因此 v 的选取对其他 2 个参数寻优范围的影响较小。

GA-GMDH 模型的设置参数如表 3 所示。

表 3 GA-GMDH 模型参数设置
Table 3 Parameter settings of GA-GMDH model

参数	参数大小/范围
遗传代数	20
种群规模	20
选择概率	0.15
交叉概率	0.40
变异概率	0.10
最大网络层数 $r_{\max}$ 寻优范围	10~30
最大神经元数 $m'_{\max}$ 寻优范围	10~30
学习率 v 寻优范围	0.1~0.9

2.3.2 模型监测结果分析

将 k 时刻离心泵的扬程、功率、效率作为模型的输入,健康指标作为输出,单步计算该时刻的

健康指标。从数据集中随机抽取 15 组数据作为测试集, 将去除测试集之后的数据集取前 65 组数据作为训练集, 取后 20 组数据作为验证集, 得到如图 9 所示的输出结果。




图 9 GA-GMDH 的验证集结果
Fig. 9 GA-GMDH verification set result

由图 9 可以看出, 离心泵健康指标的输出结果与验证集样本数据之间存在良好的一致性, 可以据此推算后续健康指标的样本数据。根据式(15), 模型的适应度曲线如图 10 所示, 经过 GA 算法寻优的最大网络层数、网络层最大神经元数及学习率分别为 17, 21, 0.5827。




图 10 适应度收敛曲线
Fig. 10 Fitness value convergence curve

为了验证本文 GA-GMDH 模型的优越性, 本节选取较常见的小样本数据处理方法, 分别建立最小支持向量机(least squares support vector machine, LSSVM)模型、支持向量机(support vector machine, SVM)模型、GMDH 模型与本文所提 GA-GMDH 模型进行对比, 并选取 e_{RMSE} 、 e_{MAPE} 和 e_{MAE} 作为评判指标, 结果如图 11 和表 4 所示。为得到最优的 LSSVM 模型进行对比分析, 经多次调整 LSSVM 模型的参数, 最终将 LSSVM 的高斯径向基核函数设置为 154, 惩罚因子设置为 141; 为得到最优的 SVM 模型进行对比, 经过多次调整 SVM 模型参数, 最终将 SVM 的惩罚因子设定为 18, 核函数参数设定为 0.01。




图 11 不同模型健康指标的对比结果
Fig. 11 Comparison of health indices among different models

表 4 不同模型的监测结果对比
Table 4 Comparison of monitored values via different models

评判指标	模型的监测结果			
	LSSVM	SVM	GMDH	GA-GMDH
e_{RMSE}	0.074 585	0.227	0.032 074	0.021 267
e_{MAE}	0.059 777	0.175 38	0.029 045	0.018 681
e_{MAPE}	2.072 3%	7.690 5%	0.130 63%	0.017 823%

由对比结果可知, GA-GMDH 模型监测的结果最接近真实的健康指标, 其中: e_{RMSE} 比 LSSVM, SVM, GMDH 方法分别降低了 0.053 318, 0.205 733, 0.010 807, e_{MAE} 分别降低了 0.041 096, 0.156 699, 0.010 364, e_{MAPE} 分别降低了 2.054 477%, 7.672 677%, 0.112 807%。由此可见, GA-GMDH 模型可以更准确地计算离心泵的健康指标, 其输出结果的可信度较高。根据 GA-GMDH 模型的输出结果并结合表 1, 即可初步判断运行过程中离心泵的退化程度。

2.3.3 模型测试

为测试上文训练模型的有效性, 从数据集中随机抽取 15 组数据输入至已保存的模型中, 该模型的输出结果如图 12 所示。测试集模型的健康指标输出值与真实值吻合良好, 其中, 测试集的 e_{RMSE} 为 0.029 216, e_{MAE} 为 0.020 88, e_{MAPE} 为 0.164 05%, 均保持在较低水平。因此, GA-GMDH 模型的输出结果可以作为判断离心泵退化等级的指标, 其退化等级评判结果与真实退化等级的对比情况如图 13 所示。

从图 13 可以看出, 根据 GA-GMDH 模型输出的结果进行退化状态识别时, 在测试集的 15 个样本中, 只有第 6 样本与真实的退化状态存在差别, 剩余 14 组的识别退化等级与真实退化等级完全一致。第 6 个样本处于中度退化与重度退化的分界线, 模型的输出为 3.991 524 57, 而实际的健康指标为 4.111 800 776 3, 两者较为接近, 因此本文所构建的离心泵退化监测模型的识别精度相对较高(其

值为 $14/15 = 93.333\%$), 由此验证了 GA-GMDH 模型进行退化等级识别的可行性及可靠度。




图 12 测试集模型的输出值与真实值对比

Fig. 12 Comparison of health indices between the output value and the true value of the test set model




图 13 退化等级的真实结果与测试集模型监测结果对比

Fig. 13 Comparison of degradation levels between real and monitored via the test set model

3 结 语

基于离心泵的退化机理, 本文构建了离心泵健康指标, 提出了离心泵退化监测模型的 GA-GMDH 算法。该离心泵退化监测模型在离心泵健康指标拟合过程中的 e_{RMSE} 较低、监测性能良好, 依据该模型输出结果进行退化状态识别的精度为 93.333%。所提模型对于离心泵健康指标的监测而言具有一定的参考价值, 适用于离心泵的运营管理。在后续研究中, 拟将该模型应用于船舶海水系统, 以实现海水泵退化的监测, 并将进一步增加模型输入参数的维度 (例如电机电流、流量、出口压力等参数), 从而根据模型监测结果实现海水泵的预测性维护保养。

参考文献:

[1] 刘祥楼, 刘瑞男, 闫东旭, 等. 基于虚拟仪器技术的输油泵机组整体运行噪声中电磁噪声的辨识与特征提取 [J]. 自动化与仪器仪表, 2018(10): 169–172.

LIU X L, LIU R N, YAN D X, et al. Identification and feature extraction of electromagnetic noise in whole operating noise of oil pump unit based on virtual instrument technology[J]. Automation & Instrumentation, 2018(10): 169–172 (in Chinese).

[2] 刘锐, 黄政, 白云. 基于物理模型的水泵寿命评估 [J]. 装备制造技术, 2012(6): 13–14,37.

LIU R, HUANG Z, BAI Y. Life assessment of centrifugal pump based on physical model[J]. Equipment Manufacturing Technology, 2012(6): 13–14,37 (in Chinese).

[3] 郭文琪. 基于物联网的矿井主排水设备状态监测及寿命管理系统的开发 [D]. 太原: 太原理工大学, 2018.

GUO W Q. Development of IoT based monitoring and life management system for drainage equipment in mine [D]. Taiyuan: Taiyuan University of Technology, 2018 (in Chinese).

[4] 王炳波, 刘赓传. 基于无迹卡尔曼滤波的离心泵剩余寿命研究 [J]. 石油机械, 2021, 49(11): 31–38.

WANG B B, LIU G C. Research on residual life of centrifugal pump based on unscented Kalman filter[J]. China Petroleum Machinery, 2021, 49(11): 31–38 (in Chinese).

[5] 景博, 崔展博, 孙宏达, 等. 失效物理与数据驱动融合的燃油泵在线寿命预测 [J]. 仪器仪表学报, 2022, 43(3): 68–76.

JING B, CUI Z B, SUN H D, et al. Online life prediction of the fuel pump based on failure physics and data-driven fusion[J]. Chinese Journal of Scientific Instrument, 2022, 43(3): 68–76 (in Chinese).

[6] 姜万录, 孔德田, 李振宝, 等. 基于完备总体经验模态分解和模糊熵结合的液压泵退化特征提取方法 [J]. 计量学报, 2020, 41(2): 202–209.

JIANG W L, KONG D T, LI Z B, et al. Degradation feature extraction method of hydraulic pump based on integrated complete ensemble empirical mode decomposition and fuzzy entropy[J]. Acta Metrologica Sinica, 2020, 41(2): 202–209 (in Chinese).

[7] CAO R J, YUAN J P, ZHAO F, et al. Probability-driven identification mechanism for degradation of magnetic drive pumps[J]. Measurement Science and Technology, 2022, 33(11): 115302.

[8] GUO R, LIU Y T, ZHAO Z Q, et al. Research on degradation state recognition of axial piston pump under variable rotating speed[J]. Processes, 2022, 10(6): 1078.

[9] 李振华. 基于层次分析法的沉船扳正作业钢缆安全性评价模型 [J]. 中国水运, 2023, 23(1): 22–24.

LI Z H. Safety evaluation model of steel cable in shipwreck correction operation based on analytic hierarchy process[J]. China Water Transport, 2023, 23(1): 22–24 (in Chinese).

[10] 王娜, 李晏丞, 刘方, 等. 基于层次分析法的“船舶类专业教学与技能竞赛融合”效果评价研究 [J]. 科技风, 2022(2): 35–37.

WANG N, LI Y C, LIU F, et al. Research on effect evaluation of "integration of teaching and skill competition of ship majors" based on analytic hierarchy process [J]. Science and Technology Wind, 2022(2): 35–37 (in Chinese).

[11] 张瑞起. 基于模糊理论和 CRITIC 客观赋值法的简化接触网的技术性能评价 [J]. 铁路工程技术与经济, 2023, 38(2): 43–48.

ZHANG R Q. Technical performance evaluation of simplified catenary based on fuzzy theory and CRITIC objective assignment method[J]. Railway Engineering Technology and Economy, 2023, 38(2): 43–48 (in Chinese).

[12] 王春燕, 史可, 王梦珂, 等. 基于 AHP-CRITIC 法醋炙青皮有效成分与颜色值的相关性研究 [J]. 中华中医药学刊, 2023, 41(11): 208–214.

WANG C Y, SHI K, WANG M K, et al. Study on the correlation between effective components and color value of vinegar-processed green peel based on AHP-CRITIC method[J]. Chinese Archives of Traditional Chinese Medicine, 2023, 41(11): 208–214 (in Chinese).

[13] 杨锡运, 刘欢, 张彬, 等. 组合权重相似日选取方法及光伏输出功率预测 [J]. 电力自动化设备, 2014, 34(9): 118–122.

YANG X Y, LIU H, ZHANG B, et al. Similar day selection based on combined weight and photovoltaic power output forecasting[J]. Electric Power Automation Equipment, 2014, 34(9): 118–122 (in Chinese).

[14] OH S K, PEDRYCZ W. The design of self-organizing neural networks based on PNs and FPNs with the aid of genetic optimization and extended GMDH method[J]. International Journal of Approximate Reasoning, 2006, 43(1): 26–58.

[15] SAKAGUCHI A, YAMAMOTO T. A design of predictive PID control systems using GA and GMDH network[C]// International Conference on Control Applications. Glasgow: IEEE, 2002: 266–271.

[16] 杨琼波, 崔东文. 基于小波包分解的 AJS-GMDH 月径流时间序列预测研究 [J]. 水力发电, 2022, 48(6): 45–51.

YANG Q B, CUI D W. Research on AJS-GMDH monthly runoff time series forecast based on wavelet packet decomposition[J]. Water Power Generation, 2022, 48(6): 45–51 (in Chinese).

[17] 席裕庚, 柴天佑, 恽为民. 遗传算法综述 [J]. 控制理论与应用, 1996, 13(6): 697–708.

XI Y G, CHAI T Y, YUN W M. Survey on genetic algorithm[J]. Control Theory & Applications, 1996, 13(6): 697–708 (in Chinese).

相关论文

[1] 魏云毅, 赵存生, 崔哲. 离心泵口环间隙对外特性和激励特性的影响 [J]. 中国舰船研究, 2021, 16(3): 189–193. <https://www.ship-research.com/article/doi/10.19693/j.issn.1673-3185.01832>

[2] 赵存生, 韩小溪, 崔哲. 离心泵口环间隙流动特性的数值模拟 [J]. 中国舰船研究, 2020, 15(4): 159–167. <https://www.ship-research.com/article/doi/10.19693/j.issn.1673-3185.01806>

[3] 周海军, 王超伟, 周国敬, 等. 基于随机森林的离心泵滚动轴承故障诊断 [J]. 中国舰船研究, 2020, 15(3): 129–135. <https://www.ship-research.com/article/doi/10.19693/j.issn.1673-3185.01646>

[4] 吴英友, 邢维升, 朱显明, 等. 某型离心水泵振动特性分析 [J]. 中国舰船研究, 2008, 3(1): 51–54. <https://www.ship-research.com/article/doi/10.3969/j.issn.1673-3185.2008.01.012>