

DOI:10.19651/j.cnki.emt.2312545

基于 GLCM-HOG 和 WOA-ELM 的 往复压缩机气阀故障诊断方法^{*}

李颖 吴仕虎 杨鑫杰 巴鹏

(沈阳理工大学机械工程学院 沈阳 110159)

摘要:气阀是往复压缩机在工作过程中极易发生故障的部件。从气阀时频图分析的角度,提出了一种基于 GLCM-HOG 和 WOA-ELM 的往复压缩机气阀故障诊断方法。首先,通过小波变换对各运行状态气阀的振动信号进行处理,生成时频图;用 GLCM 和 HOG 分别提取气阀时频图特征,融合形成 GLCM-HOG 特征。然后,利用 WOA 方法对 ELM 模型的输入层节点权值和隐藏层节点阈值进行优化,构建气阀故障诊断模型。最后,将 GLCM 特征和 GLCM-HOG 特征分别输入到 WOA-ELM 模型中,来证明本文所提方法的有效性和优越性,从而实现往复压缩机气阀故障的诊断。实验结果表明:与 GLCM 特征相比,构造的 GLCM-HOG 特征更能准确全面地反映气阀时频图特征;与 ELM 模型相比,WOA-ELM 模型诊断气阀故障的准确率更高。

关键词:往复压缩机气阀;GLCM-HOG;WOA-ELM;故障诊断

中图分类号: TH17; TP457 文献标识码: A 国家标准学科分类代码: 460.5599 530.31

Fault diagnosis method based on GLCM-HOG and WOA-ELM for reciprocating compressor valve

Li Ying Wu Shihu Yang Xinjie Ba Peng

(School of Mechanical Engineering, Shenyang Ligong University, Shenyang 110159, China)

Abstract: The reciprocating compressor valves are prone to fail during operation. From the perspective of the valve time frequency images analysis, it is proposed that fault diagnosis method based on GLCM-HOG and WOA-ELM for reciprocating compressor valves. First, the vibration signal of each operating valve is processed by wavelet generation time frequency images. The GLCM and the HOG were used to extract the time frequency image features of the valve, and fused to form GLCM-HOG features. Then, the WOA is used to optimize the ELM model for input layer node weight and hidden layer node and the valve fault diagnosis model is constructed. Finally, the GLCM features and GLCM-HOG features are fed into the WOA-ELM model to demonstrate the effectiveness and superiority of the proposed method for the diagnosis of reciprocating compressor valve fault. The experimental results show that compared with the GLCM features, the constructed GLCM-HOG features can accurately and comprehensively reflect the valve time frequency image features. The WOA-ELM model diagnoses valve failure with higher accuracy.

Keywords: reciprocating compressor valve; GLCM-HOG; WOA-ELM; fault diagnosis

0 引言

往复压缩机工作效率高,在工业生产中起着关键的作用^[1]。而气阀是往复压缩机的核心部件,在工作过程中极易出现故障,气阀的工作状态直接决定了往复压缩机运行的稳定性和安全性。因此,实现往复压缩机气阀故障的诊

断对工业生产具有重要的意义。

往复压缩机气阀运行过程中,其振动信号具有非线性的特点^[2]。气阀在发生微小故障时,故障信号微弱,给气阀状态的识别带来困难。时频分析从时间和频率两个方面对信号进行处理,得到信号的时频特征。李恒等^[3]利用短时傅立叶变换和卷积神经网络对滚动轴承的信号进行处理,

收稿日期:2023-01-03

*基金项目:辽宁省教育厅科学研究经费项目青年科技人才“育苗”项目(LG202031)、沈阳理工大学引进高层次人才科研支持计划项目(101014700081)、国家自然科学基金(51934002)项目资助

实现了滚动轴承的故障诊断。但由于输入的数据量不足,一定程度上影响了故障诊断的准确率。王志永等^[4]通过波形诊断和数值分析等方法对铣齿机的信号进行处理,实现了铣齿机故障的诊断。但采集得到的信号来自于特定型号的铣齿机,故障诊断的方法泛化性偏弱。与上述时频分析的方法相比,小波变换的时频图对信号时频的变化更直观^[5]。

对于时频图特征的提取,通常是基于外观、色彩和纹理等方法^[6]。基于外观的特征提取方法需要对图像进行分割,不能精准地获取图像外观特征参处理,但难以将色彩和局部具体位置精准对应;基于纹理的方法具有较强的鲁棒性和较好的泛化性。基于色彩的特征提取方法在整体上对图像进行须颖等^[7]使用灰度共生矩阵(gray level co-occurrence matrix,GLCM)提取滚动轴承时频图的故障特征,并输入堆栈去噪自编码网络模型中,实现滚动轴承的故障诊断。GLCM 方法提取时频图的整体纹理特征较为理想,但对边缘的纹理特征提取效果并不好。方向梯度直方图(histogram of oriented gradient,HOG)可以较好的提取不规则图像以及图像边缘的特征。梁铭裕等^[8]通过 HOG 和支持向量机相结合的方法进行分类,实现汽车油箱盖的定位。李平等^[9]采用 HOG 方法提取时频图特征,实现变压器放电类型的识别。拟将上面两种方法结合提取气阀时频图像特征。

关于往复压缩机气阀故障的诊断问题,研究人员开展了大量的工作。常见的方法有支持向量机(support vector machine,SVM)和极限学习机(extreme learning machine,ELM)等。肖幸鑫等^[10]采用 SVM 模型对离心泵转子不对中故障数据进行训练及诊断,故障诊断准确率达到 93%。顾鑫等^[11]选用 ELM 模型识别了滚动轴承故障。上述两种模型均能实现故障诊断,但存在一定缺陷:常规 SVM 模型只支持二分类,对多分类问题处理效果并不理想;由于输入层节点权值和隐藏层节点阈值两个参数随机生成的原因,导致 ELM 模型泛化性能不足以处理训练过程中未出现的非线性复杂特征集。鲸鱼优化算法(whale optimization algorithm,WOA)具有原理简单和参数优化效果好等特点。选用 WOA 优化 ELM 模型的输入层节点权值和隐藏层节点阈值,可以提高模型诊断气阀故障的能力。

综上所述,提出了一种基于 GLCM-HOG 和 WOA-ELM 的往复压缩机气阀故障诊断方法。通过小波变换对往复压缩机气阀信号进行时频域上的处理,得到相应的时频图;再分别用 GLCM 和 HOG 方法提取时频图特征,并融合形成 GLCM-HOG 特征;选用 WOA 对 ELM 模型进行优化,形成 WOA-ELM 模型,并用选定的特征集对 WOA-ELM 模型进行训练和分类,达到精准地实现往复压缩机气阀故障诊断的目的。

1 相关理论

1.1 小波变换

小波需要满足下述条件的信号 $\psi(x)$:

$$C_\psi = \int_{R^+} \frac{|\hat{\psi}(\omega)|^2}{|\omega|} d\omega < \infty \quad (1)$$

式中: $\hat{\psi}(\omega)$ 表示 $\psi(x)$ 的傅立叶变换, $R^* = R - \{0\}$ 表示全体非零实数, $\psi(x)$ 表示小波母函数。

在实数对 (a,b) 中, a 表示非零实数, b 表示任意实数。小波函数 $\psi(a,b)(x)$ 与小波母函数 $\psi(x)$ 的关系为:

$$\psi(a,b)(x) = \frac{1}{\sqrt{|a|}} \psi\left(\frac{x-b}{a}\right) \quad (2)$$

对于振动信号 $f(x)$ 连续小波变换的公式为:

$$W_f(a,b) = \frac{1}{\sqrt{|a|}} \int_R f(x) \psi\left(\frac{x-b}{a}\right) dx = \langle f(x), \psi_{a,b}(x) \rangle \quad (3)$$

1.2 灰度共生矩阵

灰度共生矩阵(gray-level co-occurrence matrix,GLCM)是一种基于纹理的图像分析方法^[12]。假设某一图片像素大小为 $(C \times E)$, $C = \{1, 2, \dots, C\}$ 是该图片像素矩阵的行向量; $E = \{1, 2, \dots, E\}$ 为该图片像素矩阵的列向量。 $G = \{1, 2, \dots, G\}$ 为该图片的像素级数。像素矩阵中,有两个参数:方向 θ 和步长 r 。在像素矩阵中取一点 (x, y) , 灰度级数 $G = i$ 。取另一点 $(x+c, y+e)$, 它的灰度级数 $g = j$ 。当这两个点被视为一个点对,那么这个点对的灰度是 (i, j) 。当 c, e 确定时,点 (x, y) 经过图像中的每一个像素点, G, g 也会随之发生变化。设 q 是点对的灰度值,则点对 (G, g) 将有 q^2 种情况。从图像矩阵出发,计算每组 (i, j) 出现的次数,并形成矩阵。同时,将出现的次数通过归一化表示为概率。数学表达式为:

$$P(i, j, \theta, d) = \{[(x, y), (x+c, y+e)] \in M \times N \mid f(x, y) = i; f(x+c, y+e) = j\} \quad (4)$$

式中: d 表示两灰度对的直线距离; θ 表示两灰度对所对应的角度。 P 表示直线距离为 d 而灰度值为 i 和 j 的像素点出现次数的频率。

从时频图的灰度共生矩阵中选择以下 4 种 GLCM 特征。

1) 对比度

对比度(contrast,CON)表示气阀时频图的分辨率。时频图的分辨率越低,相对应的对比度就越小。其表达式为:

$$CON = \sum_i \sum_j (i-j)^2 P(i, j) \quad (5)$$

2) 相关性

相关性(correlation,COR)表示在时频图在某一方向上的相似度,相似度与某一区域内的像素有关。其表达式为:

$$COR = \frac{\sum_{i=1}^k \sum_{j=1}^k [ij \times P(i, j, \theta, d) - u_x u_y]}{d_x d_y} \quad (6)$$

式中: $u_x = \sum i \sum p(i, j); u_y = \sum j \sum p(i, j); dx = \sum i (i - u_x)^2 \sum p(i, j); dy = \sum j (j - u_y)^2 \sum p(i, j)$ 。

3) 能量

能量(angular second moment, ASM)表示纹理的粗细程度。纹理分布越细,则能量越大。其表达式为:

$$ASM = \sum_{i=1}^k \sum_{j=1}^k P^2(i, j, \theta, d) \quad (7)$$

4) 同质

同质(inverse differential moment, IDM)表示局部内的纹理差异程度。不同区域之间的纹理差异越小,则同质越大。其表达式为:

$$IDM = \sum_{i=1}^k \sum_{j=1}^k \frac{P(i, j, \theta, d)}{1 + (i - j)^2} \quad (8)$$

1.3 方向梯度分布直方图

方向梯度直方图(histogram of oriented gradient, HOG)^[13]是一种在图像处理中的目标判别方法。与GLCM方法相比,该方法能更加准确地提取图像边缘特征。将两种基于纹理的特征提取方法进行结合,能更加全面、准确地提取时频图特征。HOG方法的步骤为:

1) 将时频图灰度化后进行归一化处理,灰度变换(Gamma)的表达式为:

$$I(x, y) = I(x, y)^{\gamma_{gamma}} \quad (9)$$

2) 计算图像的梯度大小和梯度方向。设像素点的坐标为(x, y),则其梯度为:

$$\begin{cases} H_x(x, y) = G(x+1, y) - G(x-1, y) \\ H_y(x, y) = G(x, y+1) - G(x, y-1) \end{cases} \quad (10)$$

梯度幅值为:

$$H(x, y) = \sqrt{H_x(x, y)^2 + H_y(x, y)^2} \quad (11)$$

梯度方向为:

$$\alpha(x, y) = \tan^{-1} \left[\frac{H_x(x, y)}{H_y(x, y)} \right] \quad (12)$$

式中: H 表示幅值, α 表示方向。 $H_x(x, y), H_y(x, y), G(x, y)$ 分别表示水平方向梯度, 垂直方向梯度和像素值。

1.4 基于 WOA-ELM 的故障分类模型

1) 鲸鱼优化算法

鲸鱼优化算法(whale optimization algorithm, WOA)是一种群体智能算法。其算法主要分为逐渐搜索^[14]、螺旋搜索和随机搜索^[15]3 种模式。

(1) 逐渐搜索模型的表达式为:

$$D = |C \cdot X^*(t) - X(t)| \quad (13)$$

$$X(t+1) = X^*(t) - A \cdot D \quad (14)$$

式中: t 表示迭代次数; A 和 C 表示系数; $X(t)$ 表示位置; $X^*(t)$ 表示目前得到的最佳解的位置; $X(t+1)$ 表示下一次迭代后最佳解的位置; D 表示当前搜索个体到猎物处的

距离。

(2) 螺旋搜索模型的表达式为:

$$D' = |X^*(t) - X(t)| \quad (15)$$

$$X(t+1) = D' \times e^{ft} \times \cos(2\pi v) + X^*(t) \quad (16)$$

式中: D' 表示当前搜索个体与当前最优解的距离; f 表示螺旋形状参数; v 表示值域范围为 $[-1, 1]$ 均匀分布的随机数。

(3) 随机搜索模型的表达式为:

$$D'' = |C \cdot X_{rand}(t) - X(t)| \quad (17)$$

$$X(t+1) = X_{rand}(t) - A \cdot D \quad (18)$$

式中: D'' 表示当前搜索个体与随机个体的距离; $X_{rand}(t)$ 表示当前随机个体的位置。

2) 极限学习机(ELM)

ELM 模型算法具有学习速度快的优点^[16]。假设该算法有 N 个不同样本 $(x_m, y_m), m = 1, 2, \dots, N$ 。其中, $x_m = [x_{m1}, x_{m2}, \dots, x_{mn}] \in R_n$; $y_m = [y_{m1}, y_{m2}, \dots, y_{mo}] \in R_o$ 。假设 ELM 模型中, 输入层神经元为 m , 隐藏层神经元为 l , 输出层神经元为 o , 输入层节点权值为 w , 隐藏层节点阈值为 h , 隐藏层激活函数为 $g(x)$, 并通过计算确定隐藏层节点权值 β 。模型如图 1 所示。分类模型的输出 Y 为:

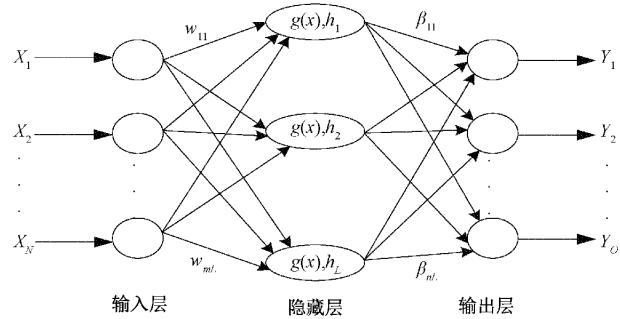


图 1 ELM 网络模型

$$\sum_{j=1}^l \beta_j g(\omega_j \cdot x_m + h_j) = Y_m \quad (19)$$

式中: $\beta_j = (\beta_{j1}, \beta_{j2}, \dots, \beta_{jo})^\top$ 表示第 j 个隐藏层节点权值向量; $\omega_j = (w_{1j}, w_{2j}, \dots, w_{nj})^\top$ 表示第 j 个输入层节点权值向量; h_j 表示第 j 个隐藏层节点阈值。

2 基于 GLCM-HOG 和 WOA-ELM 的往复压缩机气阀故障诊断流程

基于 GLCM-HOG 和 WOA-ELM 的往复压缩机气阀故障诊断具体流程如下:

1) 建立信号采集系统, 通过往复压缩机实验平台分别采集往复压缩机气阀正常工作、阀片缺口、断裂和缺少弹簧 4 种状态信号, 构建往复压缩机气阀四种状态下的信号数据集, 并对气阀不同状态的信号进行标记。

2) 选用小波变换对气阀 4 种状态下的信号数据集进行处理, 生成相对应的时频图。

3) 通过 GLCM 方法中的对比度、相关性、能量、同质性

等 4 种代表特征对气阀 4 种状态下的时频图分别提取特征参数, 并形成 GLCM 特征; 再使用 HOG 方法提取 HOG 特征。以 GLCM 特征为基础, 加入 HOG 特征, 形成 GLCM-HOG 特征集。

4) 采用 WOA 优选 ELM 模型。首先, 随机选择 ELM 模型中的输入层权值 w 及隐藏层节点阈值 h ; 设置 WOA 的种群规模 s 和最大迭代次数 t_{\max} , 并初始化各个体坐标。然后, 令迭代次数 $t=0$, 将训练集的分类错误率作为适应度函数, 计算初始状态下各个体的适应度值, 选出适应度值最小的个体。迭代次数 $t=t+1$, 更新参数 A 和 C , 并生成 $[0,1]$ 区间内的随机数 p , 计算各个体下一步的空间坐标。当参数 $A < 1, p < 0.5$ 时, 则 WOA 采用逐渐搜索模型; 当参数 $A < 1, p \geq 0.5$ 时, 则 WOA 采用螺旋搜索模型; 当参数 $A \geq 1$ 时, 则 WOA 采用随机搜索模型; 当 $t=t_{\max}$ 时, 结束迭代, 得到最优解。输出 WOA 优化后的 w 和 h 两个参数, 并利用优化后的 WOA-ELM 模型对气阀的特征数据集进行训练。

5) 将气阀的 GLCM 特征和 GLCM-HOG 特征训练集分别输入到 WOA-ELM 模型中训练, 并对两种特征的测试集进行分类。往复压缩机气阀故障诊断流程图如图 2 所示。

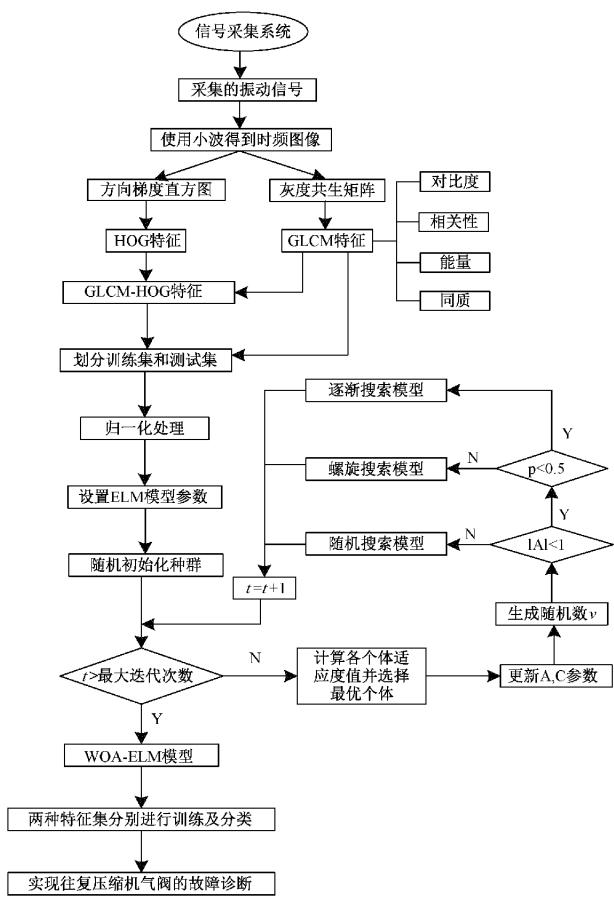


图 2 往复压缩机气阀故障诊断流程图

3 结果分析

信号采集系统由振动加速度传感器和 NI9231 振动信号采集卡组成, 使用该系统对信号进行采集并进行记录。气阀的信号状态有四种类型。采集的信号频率为 50 kHz, 采样时间 4 s。本文以 6 024 个采样点为一组数据进行分析, 选取每种气阀状态各 20 组数据, 总共 80 组数据。往复压缩机实验平台如图 3 所示。

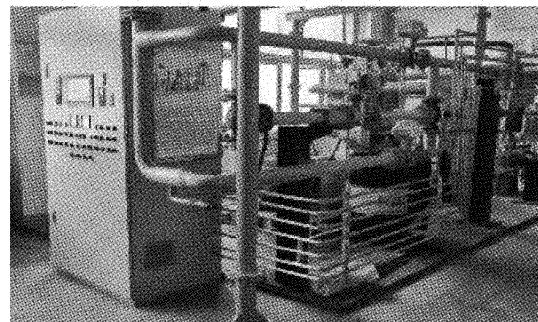


图 3 往复压缩机实验平台

3.1 小波变换

使用小波变换生成气阀各状态时频图, 四种状态的信号时频图分别选择一张进行展示。如图 4 所示。图 4(a)为气阀正常运行的时频图; 图 4(b)为气阀阀片存在缺口的时频图; 图 4(c)为气阀阀片断裂的时频图; 图 4(d)为气阀缺少弹簧的时频图。

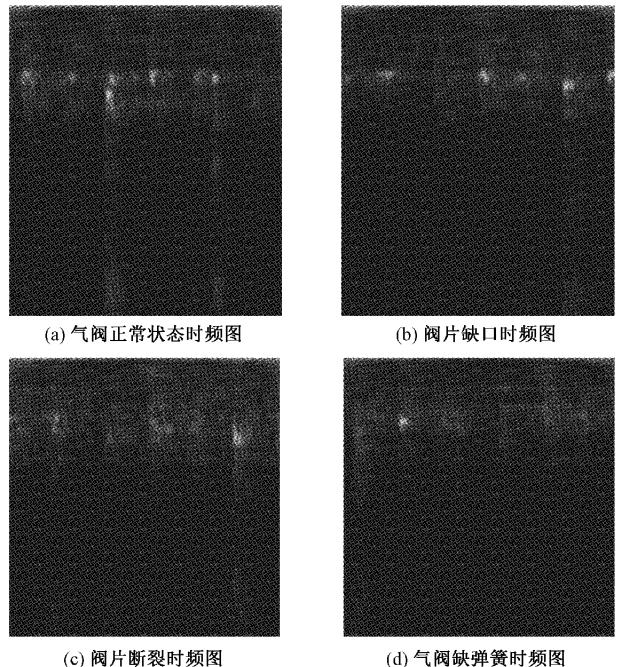


图 4 气阀 4 种状态时频图

提取气阀时频图中可以反映信号特征的信息, 构建高度表征时频图信息的特征集, 并输入 WOA-ELM 模型中实现气阀时频图的识别, 以完成气阀故障的诊断。但在气阀

时频图像中存在冗余数据,对特征的提取存在干扰。因此,在气阀的故障诊断过程中,特征提取方法的选择尤为重要。

3.2 GLCM-HOG 特征提取

1) GLCM 特征提取

利用灰度共生矩阵(gray-level co-occurrence matrix, GLCM)提取气阀 4 种状态时频图的 GLCM 特征。选择一张时频图上 $0^\circ, 45^\circ, 90^\circ, 135^\circ$ 4 个方向上对比度、相关性、能量、同质的特征值,则一张时频图上 GLCM 特征值数为 $4 \times 4 = 16$ 。气阀每种状态中选取了一张时频图的数据。如下表所示,表 1~4 为往复压缩机气阀的四种状态下的 GLCM 特征值。从总体分析,GLCM 特征所包含的 4 种特征值中,对比度特征值最小,同质特征值最大。从气阀状态分析,以表 1 为例,表 1 表示气阀正常状态下的 GLCM 特征值。在 0° 方向上,气阀的相关性特征值最大,则该方向上时频图像相似度最高;在 45° 方向上,对比度特征值最大,则该方向上图像分辨率最高;在 90° 方向上,能量和同质特征值最大,则该方向上图像纹理分布最为均匀,纹理差异性最小;在 135° 方向上,时频图像 GLCM 特征中各项特征无突出数值。

表 1 气阀正常状态下的 GLCM 特征

方向	对比度	相关性	能量	同质
0° 方向	0.096 4	0.868 5	0.472 4	0.952 7
45° 方向	0.148 1	0.791 3	0.448 6	0.931 6
90° 方向	0.099 7	0.860 0	0.478 0	0.954 7
135° 方向	0.147 3	0.792 5	0.448 8	0.932 0

表 2 气阀阀片缺口状态下的 GLCM 特征

方向	对比度	相关性	能量	同质
0° 方向	0.086 7	0.793 4	0.509 6	0.957 0
45° 方向	0.134 1	0.861 9	0.485 7	0.936 6
90° 方向	0.090 2	0.794 2	0.514 2	0.957 6
135° 方向	0.133 4	0.794 2	0.485 9	0.936 5

表 3 气阀阀片断裂状态下的 GLCM 特征

方向	对比度	相关性	能量	同质
0° 方向	0.092 2	0.881 1	0.459 4	0.954 9
45° 方向	0.140 8	0.812 1	0.441 4	0.937 2
90° 方向	0.096 1	0.872 8	0.468 4	0.958 7
135° 方向	0.140 4	0.812 7	0.441 4	0.937 2

表 4 气阀阀片少弹簧状态下的 GLCM 特征

方向	对比度	相关性	能量	同质
0° 方向	0.072 4	0.875 8	0.537 2	0.963 9
45° 方向	0.115 7	0.795 7	0.513 7	0.944 7
90° 方向	0.083 6	0.852 8	0.535 2	0.960 6
135° 方向	0.116 2	0.794 8	0.513 3	0.944 5

GLCM 方法从 4 个角度全面地提取气阀四种状态下时频图的对比度、相关性、能量以及同质特征,并组合形成气阀不同状态下的 GLCM 特征。

2) HOG 特征提取

将气阀时频图进行灰度化和归一化,并把处理后的时频图划分。梯度被分成 9 个方向范围,如图 5 所示,范围为 $Z_1 \sim Z_9$ 。统计像素点梯度方向 $\alpha(x, y)$ 和梯度幅值 $H(x, y)$,并形成直方图。

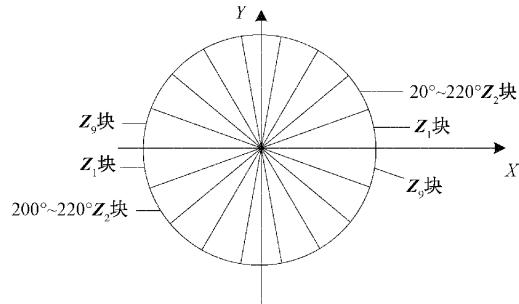


图 5 梯度方向划分示意图

小波变换生成一张时频图的像素为 236×236 。在 HOG 方法中,16×16 个像素为一个胞元,2×2 个胞元为一个块,一个胞元有 9 个特征值,那么一个块内就有 $2 \times 2 \times 9 = 36$ 个特征值。以步长为 16 个像素扫描整张时频图像,水平和垂直方向为 14 个扫描窗口,则胞元个数为 $(14-1) \times (14-1) = 169$,则一张时频图上特征为 $169 \times 36 = 6084$ 。如下表所示,由于篇幅原因,表 5~8 所示为部分 HOG 特征值。气阀正常时 HOG 特征值区间为 $[0.0025, 0.1517]$;气阀阀片存在缺口 HOG 特征值区间为 $[0.0007, 0.1499]$;阀片断裂 HOG 特征值区间为 $[0.0028, 0.1168]$;阀片缺少弹簧 HOG 特征值区间为 $[0.0006, 0.1822]$ 。气阀 4 种状态的 HOG 特征值分布在不同的区间。同时,HOG 特征值分布在小区间 $[0.0006, 0.1822]$ 之间,能够有效降低由于时频图局部像素点剧烈变化所产生的影响,较好地处理像素点之间的梯度关系。

表 5 气阀正常状态下的 HOG 特征值

特征值	1	2	3	4	5
1	0.0185	0.0054	0.0073	0.0293	0.1517
2	0.0086	0.0043	0.0132	0.0324	0.1512
3	0.0120	0.0044	0.0047	0.0287	0.1417
4	0.0140	0.0025	0.0062	0.0280	0.1475
5	0.0160	0.0042	0.0136	0.0242	0.1196

表 6 气阀阀片缺口状态下的 HOG 特征值

特征值	1	2	3	4	5
1	0.0249	0.0043	0.0197	0.0109	0.1172
2	0.0270	0.0030	0.0083	0.0135	0.1137
3	0.0154	0.0035	0.0029	0.0211	0.1306
4	0.0119	0.0004	0.0057	0.0214	0.1254
5	0.0149	0.0012	0.0007	0.0143	0.1499

将同一张时频图的 GLCM 特征值和 HOG 特征值进行归一化处理后融合并形成 GLCM-HOG 特征集。一张时频图的 GLCM-HOG 特征值数量为 $16 + 6084 = 6100$ 。

表 7 气阀阀片断裂状态下的 HOG 特征值

特征值	1	2	3	4	5
1	0.0200	0.0049	0.0163	0.0206	0.1012
2	0.0193	0.0082	0.0341	0.0251	0.1168
3	0.0288	0.0028	0.0138	0.0355	0.1079
4	0.0250	0.0070	0.0092	0.0260	0.1085
5	0.0197	0.0028	0.0031	0.0257	0.1141

表 8 气阀阀片少弹簧状态下的 HOG 特征值

特征值	1	2	3	4	5
1	0.0010	0.0014	0.0034	0.0081	0.1822
2	0.0101	0.0026	0.0080	0.0110	0.1653
3	0.0064	0.0021	0.0140	0.0258	0.1156
4	0.0145	0.0024	0.0035	0.0155	0.1459
5	0.0037	0.0006	0.0032	0.0065	0.1638

3.3 WOA-ELM 模型分类

1) ELM 模型

气阀 4 种状态的特征分别用标签 1、2、3、4 来标记。标签 1 表示气阀正常状态下的特征, 标签 2 表示阀片出现缺口的特征, 标签 3 表示阀片断裂的特征, 标签 4 表示阀片缺少弹簧的特征。分别随机选取 64 组 GLCM 特征和 GLCM-HOG 特征为 ELM 模型的训练集, 两种类的其余 16 组特征为测试集。再使用两种特征的训练集分别对 ELM 模型进行训练, 并用各自的特征测试集进行分类。图 6、7 为一次分类结果。在图 6 中, 16 组 GLCM 特征测试集有 12 组分类正确。在标签 4 中, 4 组 GLCM 特征测试集预测值与真实值完全一致; 在标签 2 和标签 3 中, 3 组预测值与真实值相同; 在标签 1 中, 2 组预测值与真实值相同。ELM 模型对 GLCM 特征测试集的分类正确率为 75.00%。

在图 7 中, 16 组 GLCM-HOG 特征测试集有 13 组分类正确。其中, 在标签 1 和 4 中, 4 组 GLCM-HOG 特征测试集预测值与真实值完全一致; 在标签 2 中, 3 组预测值与真实值相同; 在标签 3 中, 2 组预测值与真实值相同。ELM 模型对 GLCM-HOG 特征测试集的分类正确率为 81.25%。通过实验发现: ELM 模型的分类正确率并不高。通过上文分析, 其原因是 ELM 模型在学习过程中随机选择有关参数所导致的。故选择 WOA 优化 ELM 模型参数。

2) WOA-ELM 模型

WOA 的基本参数为: s 为 20, t_{\max} 为 50, 激活函数为 Sigmoid 函数。同时, 确定最优的隐藏层神经元个数 l 能提高 WOA-ELM 模型学习能力, 通过选用不同的个数 l 对模型进行训练, 计算相应训练集结果的误差, 最终确定个数

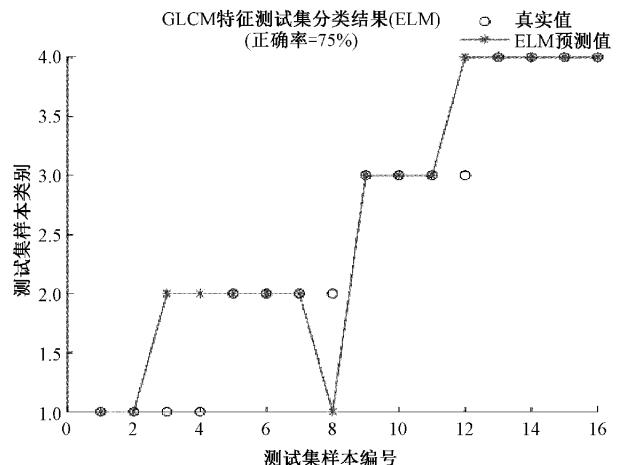


图 6 GLCM 特征 ELM 模型分类结果

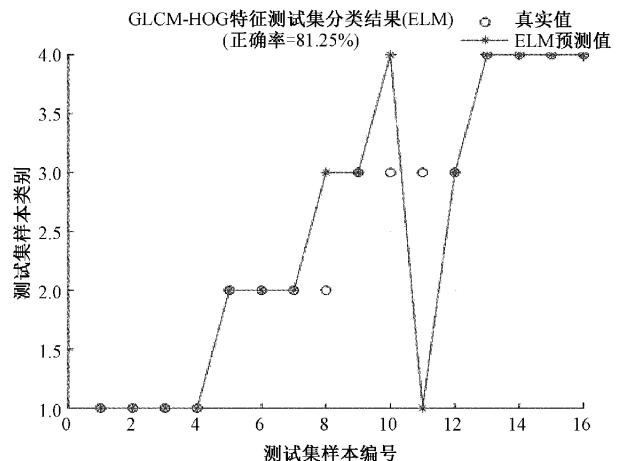


图 7 GLCM-HOG 特征的 ELM 模型分类结果

$l=20$ 。WOA-ELM 模型分别对 GLCM 特征和 GLCM-HOG 特征进行训练及分类。图 8、9 为一次分类结果。在图 8 中, 16 组 GLCM 特征测试集中有 14 组分类正确。在标签 1 和 3 中, 4 组 GLCM 特征测试集预测结果与真实值保持一致; 在标签 2 和 4 中, 3 组预测结果与真实值保持一致。WOA-ELM 模型分类正确率为 87.50%。

在图 9 中, 16 组 GLCM-HOG 特征测试集中有 15 组分类正确。在标签 1、3 和 4 中, 4 组 GLCM-HOG 特征测试集分类结果与真实结果保持一致; 在标签 2 中, 3 组分类结果与真实值保持一致。WOA-ELM 模型分类的正确率为 93.75%。

采用不同故障诊断模型对气阀多种故障进行分类, 重复 5 次试验, 分类平均结果如表 9 所示。通过分析表中结果, 得到如下结论: 1) 在众多故障诊断模型, 所提的 GLCM-HOG-WOA-ELM 故障诊断模型平均准确率为 93.75%, 在所有模型中平均准确率最高, 证明所提模型性能的优越性。2) 在分类模型保持不变的情况下, 使用 GLCM-HOG 方法提取时频图特征的平均准确率比单独使用 GLCM 或

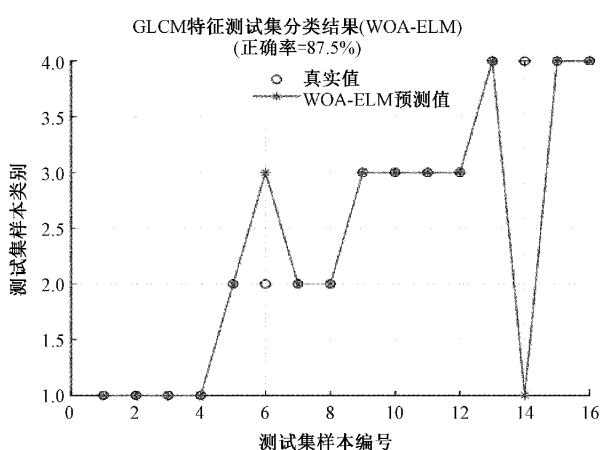


图8 GLCM特征的 WOA-ELM 模型分类结果

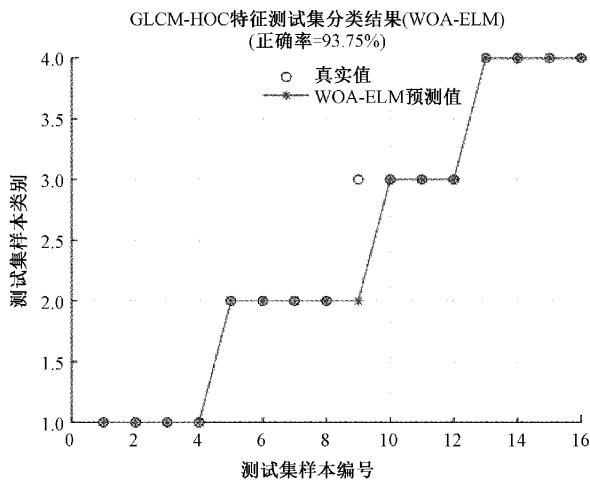


图9 GLCM-HOG特征的 WOA-ELM 模型分类结果

表9 不同故障诊断模型的平均准确率

故障诊断模型	模型平均准确率/%
GLCM-SVM	66.25
GLCM-ELM	67.50
GLCM-WOA-ELM	78.75
HOG-SVM	65.00
HOG-ELM	67.50
HOG-WOA-ELM	77.50
GLCM-HOG-SVM	82.55
GLCM-HOG-ELM	85.00
GLCM-HOG-WOA-ELM	93.75

HOG方法提取时频图特征的平均准确率要高,证明了GLCM-HOG方法提取时频图特征更为全面准确。3)在特征提取方法不变的情况下,采用WOA-ELM分类模型对气阀故障分类平均准确率得到了显著提升,证明WOA方法有效地优化了ELM分类模型。4)当特征提取方法不变

时,SVM分类模型的平均准确率略低于ELM分类模型。验证了SVM分类模型对无法精准地处理多分类问题。

4 结论

针对往复压缩机气阀振动信号的非线性特性,提出了基于GLCM-HOG和WOA-ELM的往复压缩机气阀故障诊断方法,并得到以下结论:

1)通过小波变换将往复压缩机气阀的振动信号转换成时频图。由此,将气阀的故障诊断问题转化为时频图的特征提取及分类问题,为往复压缩机气阀故障诊断提供了一种新思路。

2)对于气阀时频图提取特征的方法,提出基于GLCM-HOG方法提取时频图特征。通过与GLCM方法提取气阀时频图特征相比,GLCM-HOG方法可以更加全面、准确地包含气阀时频图特征。为后续的故障诊断打下基础。

3)选用WOA优化ELM模型,利用WOA-ELM模型对往复压缩机气阀时频图的两种特征进行分类并比较分类结果。与ELM模型相比,WOA-ELM模型对气阀故障诊断的正确率更高、稳定性也更强。实现了WOA-ELM模型在往复压缩机气阀故障诊断方向的应用。

参考文献

- [1] 余良俭.往复压缩机故障诊断技术现状与发展趋势[J].流体机械,2014,42(1):36-39.
- [2] 潘云杰,李颖,吴仕虎,等.基于GWO-SPA和MSE的往复压缩机气阀故障特征提取方法[J].机床与液压,2022,50(13):193-199.
- [3] 李恒,张氢,秦仙蓉,等.基于短时傅里叶变换和卷积神经网络的轴承故障诊断方法[J].振动与冲击,2018,37(19):124-131.
- [4] 王志永,杜伟涛,王习文,等.基于振动信号时域分析法的铣齿机故障诊断[J].科学技术与工程,2017,17(32):55-62.
- [5] 王亚萍,许迪,葛江华,等.基于SPWVD时频图纹理特征的滚动轴承故障诊断[J].振动、测试与诊断,2017,37(1):115-119,203.
- [6] LI Y, PAN Y J, BA P, et al. Fault feature extraction method of reciprocating compressor valve based on SPA-MF[J]. IEEE Access, 2022,10: 127182-127191.
- [7] 须颖,李昊东,安冬.基于GLCM-SDAE的滚动轴承故障诊断方法[J].沈阳建筑大学学报(自然科学版),2020,36(4):720-728.
- [8] 梁铭裕,黄平,刘修泉.非结构环境下基于HOG与SVM的汽车油箱盖视觉检测方法[J].机床与液压,2022,50(8):20-25.
- [9] 李平,田秋松,霍明,等.基于小波变换和HOG特征的变压器局部放电类型识别方法[J].电气传动,2021,51(24):52-56,62.

- [10] 肖幸鑫, 宋礼威, 张翊勋, 等. 基于 CEEMD 与 SVM 的离心泵转子不对中故障诊断方法研究[J]. 流体机械, 2022, 50(7): 85-92.
- [11] 顾鑫, 唐向红, 陆见光, 等. 基于深度 CNN 和 ELM 的滚动轴承故障诊断研究[J]. 兵器装备工程学报, 2020, 41(3): 154-158.
- [12] 蔡航, 茅健, 杨杰, 等. 基于 GLCM 和 FCM 算法融合的铣削零件缺陷提取方法[J]. 电子测量技术, 2022, 45(23): 166-173.
- [13] 高庆吉, 张金宁, 谈政. 基于旋转 FHOG-LBP 特征的旋翼无人机动态检测算法[J]. 科学技术与工程, 2019, 19(26): 270-275.
- [14] 吴加奇, 赵春明, 许文燮, 等. 基于 WOA-ELM 算法的变压器油纸绝缘等效模型参数辨识[J]. 水电能源科学, 2021, 39(8): 190-193.
- [15] 李鹏, 常思婕. 鲸鱼优化算法下气体泄漏源波达方向估计法[J]. 中国安全科学学报, 2021, 31(3): 19-27.
- [16] 何怡刚, 陶琳, 施天成, 等. 基于改进 BREMD 与 ELM 的断路器机械故障诊断[J]. 电子测量技术, 2018, 41(21): 81-88.

作者简介

李颖, 博士, 副教授, 研究方向为机械设备故障诊断。

E-mail: liyingnpu@126.com

吴仕虎(通信作者), 硕士研究生, 研究方向为机械设备故障诊断。

E-mail: 1786269290@qq.com