

# 融合 GA 优化算法的数字孪生模型在石油旋转机械诊断中的应用

朱传同<sup>1</sup>, 苑得鑫<sup>1</sup>, 吴义维<sup>2</sup>, 李卓军<sup>1</sup>

(1. 中国石油大学(华东), 山东 青岛 266580; 青岛石大石仪科技有限责任公司, 山东 青岛 266580)

**摘要:** 为根据模态信号频率水平确定石油旋转机械当前故障行为所属类别, 实现对机械故障行为的准确诊断, 针对融合 GA (genetic algorithm 遗传算法) 优化算法的数字孪生模型在石油旋转机械诊断中的应用展开研究; 定义 GA 算法优化规则, 并在此基础上, 建立数字孪生模型, 再联合相关故障行为数据, 完成对石油旋转机械运行数据的聚类运算, 实现基于数字孪生模型的石油旋转机械运行数据聚类处理; 计算运行数据损失情况, 通过模态分解描述性样本的方式, 将核心诊断信息重新耦合在一起, 联合求解所得的超参数指标, 定义具体的数据样本集中训练模式, 实现对石油旋转机械的诊断; 实验结果表明, 上述诊断方法的应用, 对于每一类故障行为模态信号频率的诊断都属于该信号的标准频率数值区段之内, 符合 100% 精准诊断机械故障行为的应用需求, 在准确诊断石油旋转机械故障行为方面的可行性能力较为突出。

**关键词:** GA 优化算法; 数字孪生; 石油旋转机械; 核模糊均值函数; 虚拟同源数据; 聚类运算; 数据损失; 模态分解

## Application of Digital Twin Model with GA Optimization Algorithm in Diagnosis of Petroleum Rotating Machinery

ZHU Chuantong<sup>1</sup>, YUAN Dexin<sup>1</sup>, WU Yiwei<sup>2</sup>, LI Zhuojun<sup>1</sup>

(1. China University of Petroleum (East China), Qingdao 266580, China;

2. Qingdao Shida Shiyi Technology Co., Ltd., Qingdao 266580, China)

**Abstract:** In order to determine the current fault behavior category of petroleum rotating machinery according to modal signal frequency level, and realize the accurate diagnosis of mechanical equipment fault behavior, the application of a digital twin model with fusion genetic algorithm (GA) optimization in the diagnosis of the petroleum rotating machinery is studied. The optimization rules of GA algorithm are defined, and on this basis, the digital twin model is established, and then the relevant fault behavior data are combined to complete the clustering operation of the petroleum rotating machinery operating data, and realize the petroleum rotating machinery operating data cluster processing based on the digital twin model. The loss of operating data is calculated, the core diagnostic information is recoupled together by means of the modal decomposition of descriptive samples, the obtained hyperparameter index is solved jointly, and the specific training mode of data samples is defined to realize the diagnosis of the petroleum rotating machinery. The experimental results show that the above diagnosis method is applied in the signal standard frequency value range for each type of fault behavior mode signal, which meets the application demand of 100% on the fault behavior of accurate diagnosis machinery, and it has outstanding feasibility in accurately diagnosing the fault behavior of the petroleum rotating machinery.

**Keywords:** GA optimization algorithm; digital twins; petroleum rotating machinery; kernel fuzzy mean function; virtual homologous data; clustering operation; data loss; mode decomposition

## 0 引言

石油旋转机械是指主要依靠旋转动作完成特定行为功能的石油驱动机械, 典型的机械设备包括石油发电机、石油轮机、石油发动机等。旋转类机械设备的故障行为较难预测, 且一旦发生故障大多数情况下会导致严重事故。随着石油旋转机械设计指标的不断提高, 机械系统的运行模式也在日渐趋于复杂, 多个系统部件之间的相互作用越来越频繁<sup>[1]</sup>。此外, 大型旋转机械设备普遍存在工况环境恶

劣、工作负载量大、持续运行时间长等问题。受到运行环境、自身运行能力等内外因素的影响, 设备元件产生故障的可能性也越来越高。对于石油旋转机械而言, 各类故障都会在不同程度上影响设备元件的旋转能力, 且这种影响行为可以直接反映在振动信号之中, 所以对于机械状态监测及故障诊断多以振动信号作为判定基础。

对于石油旋转机械故障行为的诊断, 周付明、刘武强、杨小强等人提出的基于精细化改进多尺度快速样本熵的诊断方法, 以快速样本熵作为研究对象, 利用重构向量代替

收稿日期: 2023-08-16; 修回日期: 2023-08-28。

作者简介: 朱传同(1985-), 男, 博士在读, 工程师。

引用格式: 朱传同, 苑得鑫, 吴义维, 等. 融合 GA 优化算法的数字孪生模型在石油旋转机械诊断中的应用[J]. 计算机测量与控制, 2023, 31(11): 137-141, 150.

传统的样本熵,在定义匹配机制的同时,完成对数据样本的多尺度、多方向拓展,并在此基础上,联合最大相关与最小冗余条件,完善分类器模型,一方面实现了对石油旋转机械故障行为的诊断,另一方面也可以判断出故障数据样本的大致传输方向<sup>[2]</sup>。张剑、程培源、邵思羽提出的基于改进残差卷积自编码网络的故障诊断方法首先对少量源域数据进行标记,根据目标域条件,创建故障数据样本的阈值空间;然后利用一维残差卷积自编码网络提取振动信号特征参量;最后联合均值差异原则,将不同域空间内的信息参量映射到同一个数据空间内,以便于主机元件对故障表现行为的逐一诊断<sup>[3]</sup>。

数字孪生是利用历史数据完成仿真处理的过程,整个映射环节只能在虚拟空间中进行,因此在全生命周期内,利用该方法进行运算,能够得到大量的真实数值解。由于虚拟数据、真实数据之间具有明显的数值对应关系,所以在运算过程中,不会出现多个自变量对应同一个因变量的情况<sup>[4]</sup>。GA算法是结合多元化思想与遗传运算思维的自适应型随机搜索算法,其运算流程不单纯依靠交叉计算,因此即便是在自变量种群较为复杂的情况下,应用该算法依然可以求解得到完全准确的数值解。在石油旋转机械故障表现行为较为复杂的情况下,传统方法所定义模态信号频率并不一定完全属于标准频率数值区段之内,故而在诊断准确性方面的能力相对较为欠缺。为解决上述问题,提出基于融合GA优化算法的数字孪生模型在石油旋转机械故障诊断方法,并对其应用能力展开研究。

## 1 基于数字孪生模型的石油旋转机械运行数据聚类处理

基于数字孪生模型的石油旋转机械运行数据聚类处理以完善GA算法优化规则为基础,利用已注入的虚拟同源数据,定义具体的聚类运算方案,本章节针对其具体实现方法展开研究。

### 1.1 GA算法优化规则

#### 1.1.1 GA参数编码

GA算法对于参数的编码遵循模糊性处理原则。对于石油旋转机械故障数据而言,GA算法首先利用固定数据对象完成对样本空间内所有参量指标的全局搜索,并根据关联信息参量之间的数值关系,建立初始聚类中心矩阵;然后按照既定编码条件,对所有一致数据样本进行指导性分类,从而达到提高信息参量收敛速度的目的;最后按照由小至大的顺序对初始聚类中心矩阵中的所有信息参量进行排列,达到注意编码数据对象的目的,上述处理过程所得到的最终编码结果,就是GA参数编码对象<sup>[5-6]</sup>。

$N$ 表示依照GA算法所定义的数据样本初始聚类中心矩阵,其定义式如下:

$$N = \{Q_1, Q_2, \dots, Q_n\} \quad (1)$$

$Q_1, Q_2, \dots, Q_n$ 表示矩阵中 $n$ 个由小至大排列的石油旋转机械故障数据对象,为避免主机元件在诊断故障行为时发生重复提取数据样本的情况,规定 $n$ 个数据对象不存在相

等的可能。

在公式(1)的基础上,推导GA参数编码表达式为:

$$W = \sum_{\alpha=1}^{+\infty} [Q_1 Q_2 \dots Q_n - \bar{Q}(\delta+1)]^{-1/\alpha} \quad (2)$$

$\bar{Q}$ 表示 $n$ 个石油旋转机械故障数据的平均值, $\delta$ 表示基于GA算法的数据样本计数值, $\alpha$ 表示指导性分类系数, $\gamma$ 表示聚类处理的顺序性标记参数。若石油旋转机械频繁出现一类或几类故障现象时,一个初始聚类中心矩阵可能无法满足数据样本的唯一性定义需求,当前情况下,可以建立多个矩阵集合,并分别求解不同矩阵所对应的GA参数编码结果,再对所得数值进行平均值运算。

#### 1.1.2 核模糊均值函数

完善GA算法优化规则就是按照GA参数编码条件,求解核模糊均值函数,函数表达式的最终计算数值就是GA算法所对应的优化运算结果。整个函数流程的实现参考如下步骤。

1) GA参数编码条件初始化——设定石油旋转机械故障数据的聚类数目为定值,改变模糊指数与收敛精度,某一时刻GA参数编码条件的运算结果不再发生变化,表示当前时刻能够求得核模糊函数的最大值<sup>[7]</sup>。

2) 规定核模糊函数的初始遗传代数、模糊指数、收敛精度的取值均为“0”,在求解均值函数的过程中,每增加一个运算步骤,参数指标的增长幅度为自然数“1”,当其数值水平与GA参数编码条件保持对应状态时,就可以求得石油旋转机械故障数据的核模糊均值函数。

设 $e$ 表示基于GA参数编码的故障数据初始遗传代数, $\epsilon$ 表示模糊指数, $\gamma$ 表示收敛精度, $\beta$ 表示石油旋转机械故障数据的目标聚类数目, $\Delta R$ 表示GA参数编码过程中石油旋转机械故障数据的单位累积量。在上述物理量的支持下,联络公式(2),可将GA优化核模糊均值函数表示为:

$$E = \frac{\sqrt{\frac{1}{\beta} \sum_{\alpha=1}^{+\infty} (e+1)^2 \times W}}{|\Delta R|^{e+\gamma}} \quad (3)$$

3) 计算初始遗传代数、模糊指数、收敛精度在不同取值情况下所对应GA参数编码条件的具体运算数值,并从中去除数值重复的部分,以保证主机元件在诊断石油旋转机械故障行为时,不会提取到完全相同的数据样本。

### 1.2 融合GA优化算法的数字孪生模型构建

#### 1.2.1 虚拟同源数据注入

虚拟同源数据是指与原始石油旋转机械故障数据来源相同,但存储方式不同的非真实数据信息参量。功能性方面,虚拟同源数据与原始数据的能力基本相同;但在适应性方面,前者所能匹配的传输环境明显更多<sup>[8]</sup>。按照GA优化算法取样原始石油旋转机械故障数据,在单位时间内所能定义的数据信息样本总量相对有限,但若应用该算法,定义与之同源的虚拟数据,则可以获得更多的信息参量,对于主机元件而言,其在诊断机械故障行为时,如果能在更多的数据样本中完全对目标信息的取样,则可以大大增

强诊断结果的准确性。

利用 GA 算法优化规则完善数字孪生模型时, 一般只在一个数据集合中选择一个数据信息样本, 且所选参量不能等于已定义数据参量的最大值与最小值<sup>[9]</sup>。对于虚拟同源数据注入表达式的求解参考公式 (4)。

$$Y = (\varphi E)^2 + \log_i \left( \varphi \left| \frac{\hat{o}}{\vec{I}} \right| \right)^2 \quad (4)$$

其中:  $\varphi$  表示石油旋转机械故障数据的同源参量判定系数,  $\hat{o}$  表示虚拟同源数据的数值定义特征,  $\varphi$  表示虚拟同源数据与原始石油旋转机械故障数据之间的数值匹配参数,  $\vec{I}$  表示主机元件诊断所得的机械故障行为等级向量,  $\hat{o}$  表示数据样本的实时注入系数。

数字孪生模型对于虚拟同源数据的定义, 要求一个信息参量在单位传输周期内只能与一个同源信息保持数值对应关系, 且无论数据总量增大或减少, 这种数值对应关系都不能发生变化。

### 1.2.2 孪生数据特征生成

石油旋转机械运行过程中会产生大量的振动信号, 且这些信号所描述出的机械设备行为模式并不相同, 因此按照数字孪生模型诊断机械故障行为时, 可以将主机元件采集到的振动信号作为孪生数据特征。在虚拟同源数据的基础上, 孪生数据特征进一步描述了石油旋转机械的运行状态, 由于取样数据所代表的运行时刻真实存在, 所以在建立数字孪生模型的过程中, 不会出现错误诊断故障行为的情况。

规定  $i_0$  表示石油旋转机械的原始故障诊断数据,  $i_1$  表示数据  $i_0$  的孪生对象, 由参数  $i_0$  到参数  $i_1$  的数值转化关系可以表示为:

$$i_0 \rightarrow i_1 = \eta \frac{\iota_1 i_1}{\iota_0 i_0} \quad (5)$$

$\eta$  表示基于数字孪生模型的数据录入效率, 其取值恒属于 (0,1) 的数值区间,  $\iota_0$  表示原始故障诊断数据记录参数,  $\iota_1$  表示孪生故障诊断数据记录参数。

GA 优化算法规定, 对于石油旋转机械的诊断, 在建立数字孪生模型时, 应将数据样本的数值镜像问题考虑在内<sup>[10]</sup>。所谓数值镜像就是指数据对象的数值水平相等, 但取值符号相反, 在推导模型计算式的过程中, 为避免造成运算方向性的错误, 可以对所有数据对象进行求解有效值的处理。

联立公式 (4)、公式 (5), 可将孪生数据特征计算式表示为:

$$P_{i_1} = \kappa \hat{y} - \tilde{U} \left( \frac{Y | i_1 |}{| \hat{i}_0 |} \right)^2 \quad (6)$$

其中:  $\hat{y}$  表示石油旋转机械故障数据的孪生数值定义向量,  $\kappa$  表示基于 GA 优化算法数据样本孪生判定参数,  $\tilde{U}$  表示数据样本的镜像判定系数。融合 GA 优化算法构建数字孪生模型, 要求在同一数据样本集合中, 求解所得的孪生数据特征必须指向同一类数据对象。

### 1.3 石油旋转机械运行数据聚类运算

完成石油旋转机械运行数据聚类运算, 首先需要构造一个具有约束能力的目标聚类函数, 然后通过持续优化的方式, 搜寻数据样本集合中的局域性最优解, 接着再以该数值解为标准, 实现对运行数据的模糊性划分。在融合 GA 优化算法的数字孪生模型的作用下, 持续进行数据聚类运算, 能够将数据集合中的非标准信息参量过滤出来, 从而在保证运算结果准确性的同时, 为主机元件提供更多的可参考诊断信息<sup>[11]</sup>。

$F$  表示依照融合 GA 优化算法的数字孪生模型所定义的目标聚类函数, 其计算式如下:

$$F = \lambda \cdot P_{i_1} \cdot \left| \frac{\vec{a}}{A} \right|^{-1} \quad (7)$$

$\lambda$  表示基于数字孪生模型所选择的数据样本定义项,  $\vec{a}$  表示 GA 优化算法作用下孪生数据与非孪生数据之间的数值映射向量,  $A$  表示基于数字孪生模型的石油旋转机械运行数据绝对取样数值。

在公式 (7) 的基础上, 推导石油旋转机械运行数据聚类运算表达式如下:

$$S = \left[ \sum_{v=1}^{+\infty} \left( \frac{F}{fd} \right)^{2/\mu-1} \right]^{-1} \quad (8)$$

$v$  表示目标聚类项,  $d$  表示聚类运算过程中所设置的石油旋转机械运行数据取样特征,  $f$  表示基于数字孪生模型的数据样本聚类运算阈值,  $\mu$  表示数据信息过滤参数。石油旋转机械运行数据聚类处理是准确诊断机械设备故障行为的基础环节, 因此依照融合 GA 优化算法的数字孪生模型选择数据样本时, 既要保证孪生数据、非孪生数据之间数值映射关系的稳定性, 也要避免在单位运算周期内选取过多的数据对象<sup>[12]</sup>。

## 2 石油旋转机械的诊断

为实现对石油旋转机械的精准诊断, 本章节根据运行数据损失情况, 建立具体的模态分解条件, 再通过重耦合运算的方式, 确定超参数指标的取值范围, 以便于主机元件可以根据超参数样本的集中训练结果总结出具体机械诊断与执行方案。

### 2.1 运行数据损失计算

对于石油旋转机械运行数据而言, 数据参量的损失与输入数据的正向传播与信息量差的反向传播行为有关。数字孪生模型通过计算输出数据与数据样本真实值之间的差异来调整和优化整个数据样本空间<sup>[13]</sup>。其中, 用以计算和度量数据样本之间差异性的信息参量被称为运行数据损失量, GA 优化算法规定, 数据样本的实时损失量越大, 主机元件在诊断石油旋转机械运行数据过程中, 所需处理的相关性参数就越多。

运行数据损失计算的本质就是通过最小化数据损失来达到准确诊断机械设备运行状态的目的, 从某种程度上来说, 只有将数据样本损失量控制在既定数值范围之内, 才能够保证诊断结果的可参考性价值<sup>[14]</sup>。此外, 按照数字孪

生模型的应用特性,运行数据损失条件的取值情况还能够决定主机元件对于数据样本的优化处理方向,只要在保证运算方法不发生改变的的前提下,相同数据样本所对应的诊断结果均相同。

利用公式(8),可将石油旋转机械运行数据损失量计算结果表示为:

$$D = -\frac{1}{\omega^2} \sum_{\theta} \sum_{-\infty}^{+\infty} S \times \log(\hat{g}_{\max} - \hat{g}_{\min})^2 \quad (9)$$

$\omega$ 表示取样数据的优化运算参数, $\theta$ 表示从数值角度定义的数据样本度量值, $\hat{g}_{\max}$ 表示数据样本差异性量化参数的最大取值结果, $\hat{g}_{\min}$ 表示差异性量化参数的最小取值结果。单位诊断周期内,主机元件所需处理的石油旋转机械运行数据样本类别并不固定,且每一个数据样本所对应向量的数值情况也可能随时发生变化,所以一个精确的诊断结果往往需要多种类型数据损失条件的共同支持。

## 2.2 描述性样本模态分解

数据样本模态是指在一个本征模函数中包含差异最大的时间特征尺度,也可以理解为相近或相似时间特征尺度在不同本征模函数中的分布情况。参照融合 GA 优化算法的数字孪生模型在石油旋转机械诊断方法而言,本征模函数就是指融合 GA 优化算法的数字孪生模型函数表达式,时间尺度就是指主机元件诊断单一运行数据样本所需时长<sup>[15]</sup>。单纯从分解流程的角度来看,数据样本模态的存在是为了避免所取样运行数据在既定节点处出现数值跳转行为,从而使得最终诊断结果的真实性出现偏差。

规定  $G$  表示基于石油机械设备运行数据的样本模态值,其定义式如下:

$$G = \sum_{-\infty}^{+\infty} |(\tilde{h} + \tilde{k})_{j_{\vartheta}}|^{-\sqrt{1+\sigma}/D} \quad (10)$$

$\tilde{h}$ 表示基于函数角度的运行数据样本模态定义向量, $\tilde{k}$ 表示基于时间角度的运行数据样本模态定义向量, $\vartheta$ 表示时间定义项, $j_{\vartheta}$ 表示基于参数的 $\vartheta$ 运行数据样本数值描述性参量, $\sigma$ 表示基于数字孪生模型的数据样本时间尺度规划参数。

利用公式(10),推导描述性样本模态分解表达式为:

$$G' = \zeta \cdot G \quad (11)$$

$\zeta$ 表示数据样本分解尺度参数。 $\zeta > 0$ 成立时,表示数据样本模态分解的行为方向为正向,经过分解处理后,每一个石油旋转机械运行数据参量都能对应一个与之相关的正向分解系数; $\zeta < 0$ 成立时,表示数据样本模态分解的行为方向为负向,经过分解处理后,每一个石油旋转机械运行数据参量都能对应一个与之相关的负向分解系数。

## 2.3 核心诊断信息的重耦合

诊断信息重耦合是指按照融合 GA 优化算法的数字孪生模型,对石油选择机械诊断过程中可能出现的信息参量进行重新组合的处理行为。对于系统主机元件而言,其对于诊断条件的定义除了参考故障数据的取样情况,还应保证诊断信息之间的相互组合关系,特别是在故障表现行为较为类似的情况下,只要保证诊断信息组合关系的绝对准

确,才有可能获得较为理想的诊断结果<sup>[16-17]</sup>。关于重耦合,也可以理解为重新定义,完成模态分解后描述性样本的取值保持为固定状态,因此只要针对所得样本参量进行分别赋值,就可以保证重耦合计算结果的准确性。

对于核心诊断信息重耦合表达式的计算参考公式(12)。

$$L = (\tau X)^2 - (|\tilde{l}G'|^{1/2})^2 \quad (12)$$

其中: $\tau$ 表示耦合计算向量, $X$ 表示核心诊断信息之间的数值组合关系, $\tilde{l}$ 表示基于数字孪生模型所定义的诊断数据样本实时模态分解向量, $z$ 表示待耦合处理的诊断信息组合运算幅值。GA 优化算法规定,重耦合是一个不可逆的运算过程,诊断信息在经过重耦合计算后,即便没有得到符合诊断需求的数据对象,当前所应用数据信息也不可以在参与后续计算流程。

## 2.4 超参数求解

超参数指标的选择至关重要,直接影响计算机设备对石油旋转机械的诊断能力。对于超参数指标可以从批量归一化、学习率、激活函数三个角度进行理解。

1) 批量归一化:由于必要诊断信息、非必要诊断信息之间存在对抗博弈关系,所以在求解超参数的过程中,必须在稳固上一层数据样本权重赋值的基础上,才能对下一层数据样本权重进行计算,且处于准确性考虑,在批量诊断机械故障数据时,必须将每一个数据样本的实际赋值都归于自然数“1”后,才能进行后续计算<sup>[18]</sup>。

2) 学习率:学习率作为一项重要的参数指标,其取值影响主机元件对石油旋转机械故障数据的赋值,特别是在求解超参数的过程中,由于数据样本的自由化程度相对较高,所以为保证诊断结果的唯一性,要求两类数据样本的学习率水平必须保持不相等的数值状态<sup>[19]</sup>。

3) 激活函数:由于石油旋转机械故障数据的排列保持线性状态,所以在求解超参数指标时,只能定义保持线性状态的数值激活函数。

在公式(12)的基础上,推导超参数计算式为:

$$C = \frac{xL}{\sum_{\vartheta \rightarrow \infty} \hat{b} \times \omega} \quad (13)$$

$x$ 表示石油旋转机械故障数据的批量归一化处理参数, $v$ 表示数据样本的实时学习率, $\hat{b}$ 表示数据样本的激活函数定义指征, $\omega$ 表示线性取样参数。超参数运算具有不可逆的特性,所以在诊断石油旋转机械时,主机元件可以根据已获取数据样本,求解超参数指标,但却不可以根据超参数指标反推数据样本取值范围。

## 2.5 超参数样本集中训练

超参数样本集中训练就是按照数字孪生模型,对超参数指标取样结果进行的统一运算处理。GA 优化算法规定,待训练的超参数样本数量越多,主机元件所需处理的石油旋转机械运行数据对象就越多<sup>[20]</sup>。由于不同超参数指标所对应的诊断结果并不相同,所以在进行集中训练运算时,只能针对一种类型的超参数指标进行取样。

设  $M$  表示超参数指标的数值类项定义系数, $N$  表示依

照数字孪生模型所定义的超参数指标运算参数,  $m_1, m_2, \dots, m_n$  分别表示  $n$  个不同的数据样本训练特征, 其取值恒属于  $(0, +\infty)$  的数值区间。在上述物理量的支持下, 联立公式 (13), 可将超参数样本集中训练表达式定义为:

$$B = (M + 1)^2 \cdot \frac{N \times C}{m_1^2 + m_2^2 + \dots + m_n^2} \quad (14)$$

超参数样本集中训练条件影响主机元件对石油旋转机械的诊断能力, 特别是在多种故障模态信号同时存在的情况下, 保证超参数样本集中训练的准确性, 才能得到较为理想的诊断结果。

### 3 实验分析与研究

本次实验选择融合 GA 优化算法的数字孪生模型的石油旋转机械诊断方法、基于精细化改进多尺度快速样本熵的诊断方法、基于改进残差卷积自编码网络的故障诊断方法三组不同的技术手段进行实验, 记录在不同方法作用下, 模态信号频率检测结果与真实模态信号频率之间的数值符合情况。

#### 3.1 实验原理描述

以 MT-A202 型号的检测机台, 作为实验诊断的装置, 首先将融合 GA 优化算法的数字孪生模型的石油旋转机械诊断方法的执行程序输入检测主机之中, 记录在该方法作用下, 故障行为模态信号频率的检测数值, 所得结果为实验组变量; 其次将基于精细化改进多尺度快速样本熵的诊断方法的执行程序输入检测主机之中, 记录在该方法作用下, 故障行为模态信号频率的检测数值, 所得结果为对照 1 组变量; 接着将基于改进残差卷积自编码网络的故障诊断方法的执行程序输入检测主机之中, 记录在该方法作用下, 故障行为模态信号频率的检测数值, 所得结果为对照 2 组变量; 然后将实验组、对照 1 组、对照 2 组模态信号频率检测频率与真实模态信号频率进行对比; 最后根据差值情况总结实验规律。存在故障行为的情况下, 石油旋转机械模态信号频率水平可以用来描述故障行为所属类别, 且对于检测主机而言, 只有保证检测频率值与真实频率区段的完全符合, 才表示当前所应用方法的诊断结果具有可参考价值。

应用 MT-A202 检测机台对石油旋转机械的故障模态信号频率进行测量。表 1 记录了真实模态信号频率的数值水平及其所属的具体故障行为类别。

表 1 真实模态信号频率分类

组别	模态信号频率/Hz	故障行为类别
1	0.00~0.50	第 I 类故障
2	0.51~0.97	第 II 类故障
3	1.00~1.24	第 III 类故障
4	1.25~1.86	第 IV 类故障
5	1.90~2.33	第 V 类故障
6	2.35~2.79	第 VI 类故障

根据表 1 可知, 各类故障行为的模态信号频率不存在相互重叠的情况, 且每一类模态信号频率的数值宽度水平

并不相同, 单从数值角度来看, 第 IV 类故障行为为模态信号频率的数值宽度水平最大, 第 III 类故障行为为模态信号频率的数值宽度水平最小。

#### 3.2 步骤与数据处理

选择 6 个不同的故障模态信号作为实验对象, 其数值编号与故障行为类别的对应关系如下: 1 号实验对象——第 II 类故障、2 号实验对象——第 VI 类故障、3 号实验对象——第 I 类故障、4 号实验对象——第 V 类故障、5 号实验对象——第 II 类故障、6 号实验对象——第 I 类故障, 分别应用实验组、对照 1 组、对照 2 组方法对 6 个不同实验对象的故障模态信号频率进行诊断, 具体实验情况如图 1 所示。

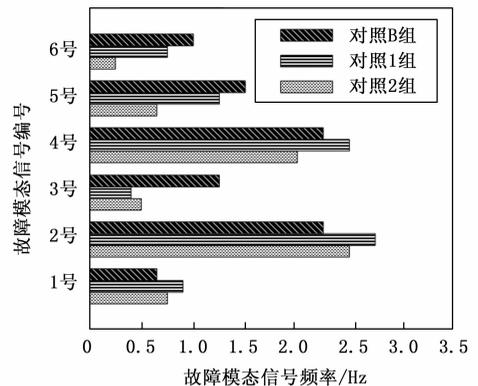


图 1 故障模态信号频率实验数值

实验组: 1~6 号故障模态信号频率的诊断值分别为 0.75 Hz、2.50 Hz、0.50 Hz、2.00 Hz、0.70 Hz、0.25 Hz, 其所属故障行为类别分别为第 II 类故障、第 VI 类故障、第 I 类故障、第 V 类故障、第 II 类故障、第 I 类故障, 与各个实验对象的真实故障情况相同。

对照 1 组: 1~6 号故障模态信号频率的诊断值分别为 0.70 Hz、2.75 Hz、0.37 Hz、2.50 Hz、1.25 Hz、0.75 Hz, 其所属故障行为类别分别为第 II 类故障、第 VI 类故障、第 I 类故障、第 VI 类故障、第 IV 类故障、第 II 类故障, 第 1 号、第 2 号、第 3 号实验对象的故障诊断结果与真实情况相同, 第 4 号、第 5 号、第 6 号实验对象的故障诊断结果与真实情况不同。

对照 2 组: 1~6 号故障模态信号频率的诊断值分别为 0.75 Hz、2.25 Hz、1.25 Hz、2.25 Hz、1.50 Hz、1.00 Hz, 其所属故障行为类别分别为第 II 类故障、第 V 类故障、第 IV 类故障、第 V 类故障、第 IV 类故障、第 III 类故障, 第 1 号、第 4 号实验对象的故障诊断结果与真实情况相同, 第 2 号、第 3 号、第 5 号、第 6 号实验对象的故障诊断结果与真实情况不同。

综上所述可知本次实验结论为: 基于精细化改进多尺度快速样本熵的诊断方法、基于改进残差卷积自编码网络的故障诊断方法的应用能力有限, 不能实现对石油旋转机械故障模态信号频率的精准诊断; 融合 GA 优化算法的数字孪生

(下转第 150 页)