

## 基于粒化模糊熵的机载燃油泵故障诊断\*

戴邵武<sup>1</sup>, 陈强强<sup>1,4</sup>, 戴洪德<sup>2</sup>, 李娟<sup>3</sup>

- (1. 海军航空大学 岸防兵学院, 山东烟台 264000;
2. 海军航空大学 航空基础学院, 山东烟台 264000;
3. 鲁东大学 数学与统计科学学院, 山东烟台 264000;
4. 海军92728部队, 上海 200040)

**摘要:** 由于机械系统的复杂性, 机载燃油泵振动信号的随机性表现在不同尺度上, 因此需要对振动信号进行多尺度分析。为了实现机载燃油泵的故障状态特征提取, 以模糊熵作为机载燃油泵振动信号的基本特征, 提出了基于模糊信息粒化和模糊熵的机载燃油泵故障诊断方法。首先, 采用模糊信息粒化方法对振动信号进行粒化处理, 得到包含最小值、中值、最大值三组模糊信息粒; 其次, 计算模糊信息粒的模糊熵值; 最后, 将熵值作为特征向量, 输入基于粒子群优化支持向量机建立的分类器。将该方法应用于机载燃油泵及轴承实验数据, 分析结果表明, 该方法可有效实现故障诊断。

**关键词:** 特征提取; 模糊信息粒化; 模糊熵; 故障诊断; 机载燃油泵

**中图分类号:** TP206; TP911 **文献标识码:** A **文章编号:** 1001-4055 (2020) 10-2308-08

**DOI:** 10.13675/j.cnki.tjjs.190325

## A Fault Diagnosis Method of Airborne Fuel Pump Based on Granulation and Fuzzy Entropy

DAI Shao-wu<sup>1</sup>, CHEN Qiang-qiang<sup>1,4</sup>, DAI Hong-de<sup>2</sup>, LI Juan<sup>3</sup>

- (1. College of Coastal Defense, Naval Aviation University, Yantai 264000, China;
2. College of Basic Sciences for Aviation, Naval Aviation University, Yantai 264000, China;
3. College of Mathematics and Statistics, Ludong University, Yantai 264000, China;
4. Naval 92728, shanghai 200040, China)

**Abstract:** Due to the complexity of mechanical systems, the randomness of the vibration signal behave on different scales, making it necessary to analyze the vibration signal in a multi-scale way. In order to realize fault feature extraction of airborne fuel pump, Fuzzy entropy is used as the basic feature of vibration signal of airborne fuel pump, a new method of airborne fuel pumps fault diagnosis based on fuzzy information granulation (FIG) and fuzzy entropy (FE) is put forward. Firstly, the FIG method is used to granulate the vibration signal and the FIG particles made up of minimum, median, and maximum are obtained. Secondly, the FE of the particles is calculated. The entropies are accordingly seen as the characteristic vector, then input to the particle swarm optimization (PSO) - support vector machine (SVM) based classifier. Finally, the proposed method is applied to the airborne fuel pumps and bearing experimental data. The analysis results show that the proposed approach can effectively achieve fault diagnosis.

**Key words:** Feature extraction; Fuzzy information granulation; Fuzzy entropy; Fault diagnosis; Airborne fuel pump

\* 收稿日期: 2019-05-19; 修订日期: 2019-07-24。

基金项目: 山东自然科学基金面上项目 (ZR2017MF036); 国防科技项目基金 (F062102009)。

通讯作者: 戴邵武, 博士, 教授, 研究领域为飞行器综合导航, 故障诊断。E-mail:634382204@qq.com

引用格式: 戴邵武, 陈强强, 戴洪德, 等. 基于粒化模糊熵的机载燃油泵故障诊断[J]. 推进技术, 2020, 41(10):2308-2315. (DAI Shao-wu, CHEN Qiang-qiang, DAI Hong-de, et al. A Fault Diagnosis Method of Airborne Fuel Pump Based on Granulation and Fuzzy Entropy[J]. *Journal of Propulsion Technology*, 2020, 41(10):2308-2315.)

## 1 引言

机载燃油系统作为航空飞行系统的重要构件之一,为航空发动机提供一定压力及流量状态下的燃油<sup>[1]</sup>。由于机载燃油泵的精密性及工作环境的复杂性,在使用过程中易出现故障损伤,给机载燃油系统及航空发动机带来重大的安全隐患<sup>[2]</sup>。因此,在机械系统的使用过程中,准确检测并识别系统运行状态,同时实现准确的故障诊断具有十分重要的意义。

机载燃油泵在工作过程中运行状态复杂,振动信号呈现出强烈的非线性、非平稳性。因此,实现准确有效的故障诊断,其首要任务就是从复杂的非线性、非平稳信号中提取出不同故障状态的特征信息<sup>[3]</sup>。随着非线性理论在故障诊断领域不断的深入研究,许多非线性分析方法逐步得到应用。Logan等<sup>[4]</sup>研究了关联维数在机械系统中的应用,实现了非线性方法与故障诊断技术的结合。文献[5]将关联维数应用于航空发动机数据,实现了航空发动机的性能状态检测及故障监控。文献[6]通过小波分析对燃油泵故障进行区分,但在特征提取过程中所构建的特征集维数过大,存在着一定的数据冗余与冲突。文献[7]将多重分形技术应用于齿轮箱故障诊断。文献[8]采用广义分形维数方法,实现发动机故障诊断。文献[9]采用分形维数与模糊C均值聚类的方法,对机械系统中轴承的退化状态进行识别。文献[10]引入混沌理论应用于汽轮发动机系统的故障诊断。在这些经典的非线性方法中,关联维数在使用过程中易受到工作环境中的噪声干扰,自适应性较差。分形维数的计算过于依赖机械系统振动信号的长度,计算量较大。Lyapunov指数存在计算速度慢、精度不高等问题。这在一定程度上制约了机械系统的故障诊断精度。文献[11]针对发动机燃油泵轴承故障的研究主要集中在能谱分析及外观检测,不利于故障的在线检测及视情维修。

熵(Entropy)是对时间序列混乱程度的一种有效度量形式。随着熵理论的发展,Pincus等<sup>[12]</sup>提出了一种可以衡量时间序列复杂性的方法——近似熵,Yan等<sup>[13]</sup>将其应用于机械系统的健康状态监测。近似熵采用一个非负数对时间序列进行描述,在分析较短序列时,能够得到稳定可靠的结果,但在长时间序列中相对一致性较差。文献[14]提出了模糊熵方法,借用模糊函数的概念对两个向量的相似性进行表述。文献[15]将模糊熵运用于机械系统振动信号特征提取中,证明了模糊熵在机械系统应用方面的可

行性。但在对机载燃油泵系统振动信号分析过程中,由于机械系统比较复杂,信号不仅在单一尺度上包含了特征信息,在其他尺度上也有着重要信息,此时直接使用模糊熵存在着特征提取能力不足的问题。因此有必要在单尺度模糊熵的基础上,对振动信号特征向量进行深层次特征提取<sup>[16]</sup>。

为了在多个尺度下有效提取机载燃油泵振动信号的特征信息,本文提出了一种新的熵值理论,定义为模糊信息粒化-模糊熵(Fuzzy information granulation-fuzzy entropy, FIGFE),并实现机载燃油泵系统故障诊断。FIG较为广泛的应用在于对时间序列进行粒化,通过对粒化数据的预测实现对时间序列波动趋势的预测。本文借鉴FIG粒化特性,首次将其引入至故障诊断领域,并与熵值理论进行结合,定义新的熵值算法并进行故障诊断。首先,采用模糊信息粒化的方式对机械系统振动信号进行处理,得到包括低边界值Low,中值R和高边界值Up的3组模糊信息粒子;其次,对FIG粒化后的3组信息粒子求取其模糊熵值作为特征信息并组成特征向量。最后,采用基于机器学习理论的支持向量机(Support vector machine, SVM)进行故障识别,简单有效地完成故障诊断;同时,针对SVM计算过程中核函数参数及惩罚参数的选择问题,采用粒子群算法(Particle swarm optimization, PSO)进行参数优化选择,增强了SVM的自适应性及准确性,提高了SVM的故障诊断能力。

与传统的特征提取方法相比,本文提出的方法不是简单的基于信号时域统计特征,而是将单尺度的振动信号扩展为3组多尺度振动信号并分析其相似性与复杂度;在数据处理上,通过模糊信息粒化方式,将单尺度振动信号进行分解,深度提取了振动信号的特征信息。为了验证算法的合理性,将所提出的方法应用于机载燃油泵系统实验平台,同时为了验证算法的普适性,采用凯斯西储大学的滚动轴承公开实验数据进行验证分析,结果表明该方法能够有效区分机载燃油泵及滚动轴承的不同故障类型,是一种有效的故障诊断方法。

## 2 基于FIGFE的故障特征提取及故障诊断

### 2.1 模糊熵(FE)

模糊熵通过借用模糊函数概念,选择指数函数 $e^{-(d/r)^n}$ 作为模糊函数来测量两个向量之间的相似性。指数函数 $e^{-(d/r)^n}$ 具有以下特性<sup>[17]</sup>:

- (1) 连续性保证其函数值不会产生突变。

(2) 函数的凸性质保证了向量本身的自相似性值最大。

对长度为  $N$  的时间序列  $x(i)$ , 其模糊熵的定义如下:

(1) 按顺序定义  $m$  维向量

$$X_i^m = \{x(i), x(i+1), \dots, x(i+m-1)\} - x_0(i) \quad (1)$$

式中,  $i = 1, 2, \dots, N - m + 1$ 。  $X_i^m$  为从第  $i$  个点开始的连续  $m$  个去掉均值  $x_0(i)$  的  $x(i)$  值, 其中

$$x_0(i) = \frac{1}{m} \sum_{j=0}^{m-1} x(i+j) \quad (2)$$

(2) 定义  $X_i^m$  与  $X_j^m$  之间的距离为两者对应元素差值的最大值, 即

$$d_{ij}^m = d[X_i^m, X_j^m] = \max_{k \in (0, m-1)} \left\{ |x(i+k) - x_0(i) - (x(j+k) - x_0(j))| \right\} \quad (3)$$

$i, j = 1, 2, \dots, N - m, i \neq j$

(3) 通过定义模糊函数  $\mu(d_{ij}^m, n, r)$ , 确定矢量  $X_i^m$  与  $X_j^m$  之间的相似度  $D_{ij}^m$

$$D_{ij}^m = \mu(d_{ij}^m, n, r) = e^{-(d_{ij}^m/r)^n} \quad (4)$$

式中模糊函数  $\mu(d_{ij}^m, n, r)$  为指数函数,  $n, r$  分别表示边界梯度和宽度。

(4) 定义函数

$$\phi^m(n, r) = \frac{1}{N - m} \sum_{i=1}^{N-m} \left( \frac{1}{N - m - 1} \sum_{\substack{j=1 \\ j \neq i}}^{N-m} D_{ij}^m \right) \quad (5)$$

(5) 对维数进行  $m+1$  处理, 重复步骤(1)~(4), 得

$$\phi^{m+1}(n, r) = \frac{1}{N - m} \sum_{i=1}^{N-m} \left( \frac{1}{N - m - 1} \sum_{\substack{j=1 \\ j \neq i}}^{N-m} D_{ij}^{m+1} \right) \quad (6)$$

(6) 当  $N$  为有限长度时, 可定义 FE 的表现形式为

$$FE(m, n, r, N) = \ln \phi^m(n, r) - \ln \phi^{m+1}(n, r) \quad (7)$$

模糊熵的物理意义在于衡量时间序列在维数变化时产生新模式的概率大小。FE 的熵值大小取决于序列产生新模式的概率, 熵值越大表明序列的复杂程度越大。在使用 FE 进行特征向量提取的过程中, 为了解决单一尺度下 FE 特征提取能力不足的问题并扩展 FE 性能, 本文采用模糊信息粒化方式对模糊熵进行粒化处理及多尺度分析。

## 2.2 模糊信息粒化

20 世纪 60 年代, 美国数学家 Zadeh 教授首次提出模糊集合论; 1979 年 Zadeh 教授在模糊集合论的基础上首次提出模糊信息粒化, 主要解决信息粒的形

成、表示、粗细及语义解释等问题<sup>[18]</sup>。信息粒化通过将整体分解为多个独立的部分进行研究, 从集合理论而言, 信息颗粒是通过不可区分性、功能相近性、相似性及函数性等特征来划分对象。模糊信息粒化的定义为

$$g \triangleq (x \text{ is } G) \text{ is } \lambda \quad (8)$$

式中  $x$  是论域  $U$  中的取值变量,  $G$  为论域  $U$  的模糊子集, 通过隶属函数  $\mu_G$  来刻画。  $\lambda$  为可能性概率。一般假设论域  $U$  为实数集合  $\mathbf{R}(R^n)$ ,  $G$  为  $U$  的凸模糊子集,  $\lambda$  为位区间的模糊子集。

模糊信息粒化通过模糊集的形式对信息粒进行表示, 其主要步骤为窗口划分和模糊化。其中, 窗口划分即通过设置窗口大小将时间序列数据分割成若干小块, 并以此作为操作窗口; 模糊化即通过把产生的每一个窗口数据进行模糊化, 从而获得模糊集(模糊信息粒)。

在模糊粒子的选择中, 有三角型、梯形、抛物型和 Gaussian 型等<sup>[19]</sup>。现有的关于 FIG 应用的文献一般采用三角型粒子, 因此本文选择三角型模糊粒子对采集到的振动信号进行模糊信息粒化。三角型模糊粒子的隶属函数为

$$A(x, l, z, u) = \begin{cases} 0 & (x < l) \\ \frac{x-l}{z-l} & (l \leq x \leq z) \\ \frac{u-x}{u-z} & (z < x \leq u) \\ 0 & (x > u) \end{cases} \quad (9)$$

式中  $l, z, u$  分别为模糊粒子的 3 个参数。以振动信号为例, 如果  $X = \{x_1, x_2, \dots, x_n\}$  作为一个粒化窗口, 则  $z$  表示该窗口中的大体平均水平;  $l$  表示该窗口的最小值,  $u$  表示最大值。

## 2.3 FIGFE 特征向量提取

模糊熵确定的是时间序列在单一尺度上的不规则程度, 熵值越小, 序列的自相似性就越高; 熵值越大, 序列越复杂。模糊熵值的求解局限于待求解时间序列的信号特征, 仅从单一尺度对时间序列复杂程度进行刻画。而针对机械系统故障诊断问题, 振动信号往往过于复杂, 此时单一的对其进行信号特征提取存在着信息表达不足、无法全面概括不同故障类型的特征信息, 从而无法准确完成机械系统故障诊断过程<sup>[20]</sup>。本文采用模糊信息粒化方式, 通过设置粒化窗口大小, 将原始机械系统振动信号用 3 组模糊信息粒进行表示, 记为 Low, R 与 Up。分别对应式(9)中的  $l, z, u$  ( $l, z, u$  可理解为原始振动信号粗粒化

后的下界、中间值及上界)。模糊信息粒化通过 Low, R 与 Up 完整地概括了原始时间序列的信息,相比之下所获取的振动信号特征向量也更加完备,其示意图如图 1 所示。

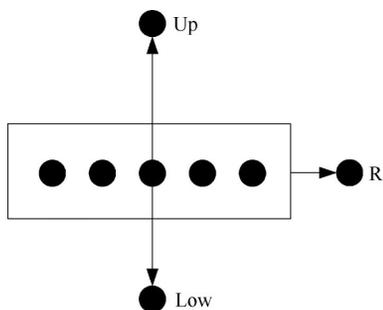


Fig. 1 Graining results

如图 1 所示,单一尺度下的特征提取方法仅对原始信号求取 FE 熵值;而本文所提出的基于 FIGFE 的特征提取方法则对粒化后的三组 Low, R, Up 求取模糊熵值,相比之下能够提取更为丰富的故障特征信息。综上所述,基于 FIGFE 的特征向量提取步骤为:

(1)对于长度为  $N$  的振动信号  $x$ ,设置粒化窗口大小  $win$ ,进行模糊信息粒化。

(2)在粒化窗口  $win$  下,得到 3 组粒化数据,分别记为 Low, R, Up。3 组粒化数据的长度均为  $[N/win]$ ;其中  $[ \cdot ]$  为取整运算。

(3)对步骤(2)中所得的三组粒化数据进行 FE 求解,分别记为  $FE_{Low}^{win}, FE_R^{win}, FE_{Up}^{win}$ 。

(4)将步骤(3)中得到的三组模糊熵值组成特征向量,作为后续故障诊断的特征信息。

根据 FIGFE 的计算步骤,定义参数  $win$  的选择标准:

粒化的意义是在每个粒化窗口下求取 3 组模糊信息粒子,因此  $win$  的取值不宜过小,否则失去粒化意义(例如当  $win = 1$  时即不进行模糊粒化,此时 FIGFE 为普通模糊熵值);同时,经过 FIG 粒化后,时间序列的长度变为  $[N/win]$ ,因此  $win$  的选择不宜过大,因为窗口过大会导致时间序列长度过短,信息过于平均(例如长度为 2000 的时间序列经过  $win = 5$  的粒化后,长度仅为 400),影响后续模糊熵值求解。因此本文选择窗口  $win = 3$ 。

式(7)中参数的选择参考文献[21]。考虑嵌入维数  $m$  越大,对应所需的数据长度越长,因此选择  $m = 2$ ;  $n$  决定了相似容限边界的梯度,  $n$  越大则梯度越大,但会导致细节信息的丧失,因此选择  $n = 2$ ;相似容限  $r$  表示模糊函数边界的宽度,  $r$  过大会丢失统

计信息,  $r$  过小会增加对结果噪声的敏感性,且估计出的统计特性效果不理想,本文参照文献[21]选择  $r = 0.15$ 。经过 FIGFE 对振动信号进行特征提取,即可实现不同故障类型的故障诊断。

### 2.4 基于 FIGFE 的故障诊断

SVM 于 1995 年由 Vapnik 等首次提出,是机器学习算法的典型代表。SVM 以统计学习为理论基础,通过非线性映射,将原始空间样本数据由低维特征空间映射到高维特征空间,从而实现 SVM 的理论分析<sup>[22]</sup>。利用 SVM 对 2.3 节中所提取出的 FIGFE 特征向量进行故障诊断时,涉及到自身核函数参数及惩罚参数的选择问题。针对这一问题,采用 PSO 优化方法来实现。

PSO 优化算法是智能领域算法中的一种基于群体智能的优化算法。PSO 方法于 1995 年由 Kennedy 和 Eberhart 提出并得到广泛应用,通过粒子在解空间追随最优粒子进行搜索<sup>[23]</sup>。

综上所述,本文所提出的基于 FIGFE-PSOSVM 机载燃油泵故障诊断方法如下:

首先,设置粒化窗口大小  $win$ ,对原始振动信号进行模糊信息粒化,得到粒化后的三组数据序列 Low, R, Up。

然后,设置 FE 参数,对粒化后的 3 组数据序列分别进行 FE 熵值求解,得到由粒化后 3 组数据序列的 FE 熵值组成的特征向量。

$$T = [FE_{Low}^{win}, FE_R^{win}, FE_{Up}^{win}] \quad (10)$$

最后,以特征向量  $T$  作为 SVM 的属性参数,设置不同故障类型的 SVM 标签,对采集到的不同故障类型的机载燃油泵振动信号建立 PSOSVM 分类器并进行故障诊断。

基于 FIGFE-PSOSVM 的机载燃油泵故障诊断方法流程图如图 2 所示。

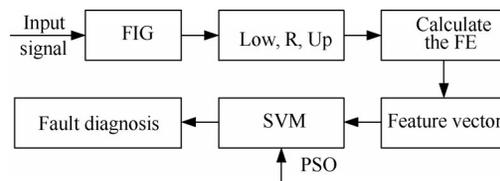


Fig. 2 Flow chart of fuel pumps fault diagnosis based on FIGFE-PSOSVM

## 3 实验分析

### 3.1 公开数据集验证

为验证所提出的 FIGFE-PSOSVM 算法的有效性

和准确性,采用美国凯斯西储大学电气工程实验室的滚动轴承故障实验数据作为验证数据<sup>[24]</sup>。实验对象为 6205-2RS JEM SKF 深沟球轴承。电机负载为 735.5W,轴承转速为 1772r/min;除正常状态外,三种故障状态分别记为滚动体故障、内圈故障和外圈故障;故障通过电火花技术布置,直径为 0.3556mm,数据样本长度为 2048;取正常状态(记为 NORM)、滚动体故障(记为 REF)、内圈故障(记为 IRF)及外圈故障(记为 ORF)4种状态的样本各 80组,共计 320组数据。

选择4种状态下各80组数据中的40组作为训练集,余下40组作为测试集,训练集与测试集均为样本数据的50%,以验证算法的有效性。

首先,对4种状态的320组样本进行FIG处理,每个样本经过粒化处理后可得到3组数据序列Low,R,Up。选择窗口大小 $win = 3$ ,以ORF状态为例,粗粒化结果如图3所示。

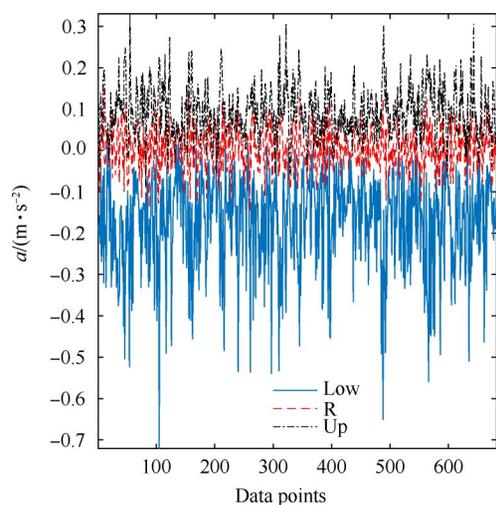


Fig. 3 ORF graining results figure ( $win = 3$ )

如图3所示,经过粗粒化后的滚动轴承故障振动信号,通过Low,R,Up三组具有更明显特征的模糊粒化数据,弥补了直接对滚动轴承故障振动信号进行特征提取的不足。粗粒化的时间序列既保留了原始振动信号的特征信息,同时用3组模糊粒子对特征信息进行了深层次刻画,提高了对原始振动信号特征信息的提取能力。在 $win = 3$ 的条件下,对Low,R,Up三个尺度进行FE求解,并将所求得的熵值组成特征向量

$$T = [FE_{Low}^3, FE_R^3, FE_{Up}^3] \quad (11)$$

为了对比验证本文所提出的FIGFE-PSOSVM算法的合理性,选用直接对振动信号的FE特征提取进

行对比分析;同时,为了说明PSO算法对SVM的优化效果,每种方法均与未使用优化算法的SVM分类器进行对比。训练集的组成结构为式(11)中的三个属性值及标签值。其中标签1,标签2,标签3,标签4分别对应正常状态、内圈故障、滚动体故障及外圈故障

$$T' = [FE_{Low}^3, FE_R^3, FE_{Up}^3, label] \quad (12)$$

首先验证基于FE算法的故障诊断性能,直接对滚动轴承故障信号进行FE解算,并将FE熵值作为特征向量输入至PSOSVM分类器中,结果如图4所示。

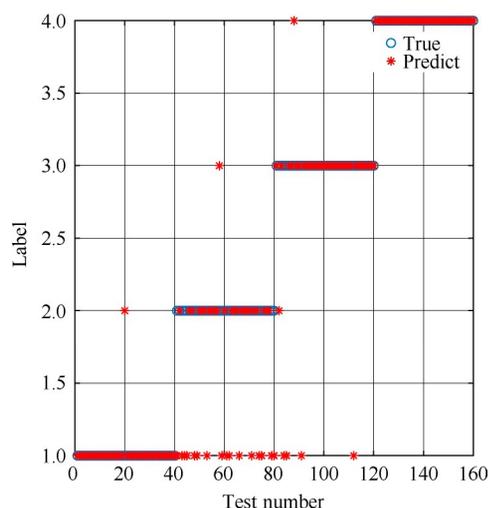


Fig. 4 PSOSVM diagnosis results of rolling bearing (FE)

采用滚动轴承故障信号的模糊熵值作为特征向量,针对160个测试集,采用FE-SVM的故障诊断精度为75%(120/160);采用FE-PSOSVM的故障诊断精度为85%(136/160)。其中,经过PSO优化后,SVM惩罚参数为66.9967,核函数参数为138.3893。

采用本文所提出的FIEFE-PSOSVM方法进行故障诊断,首先对滚动轴承故障信号进行窗口大小为 $win = 3$ 的粗粒化处理,然后对得到的Low,R,Up三组粗粒化时间序列进行FE熵值求解,将FE熵值作为特征向量并输入至PSOSVM分类器中,结果如图5所示。

采用本文提出的窗口大小为 $win = 3$ 的FIGFE方法,针对160个测试集,采用FIGFE-SVM算法的故障诊断精度为98.75%(158/160);采用FIGFE-PSOSVM的故障诊断精度为100%(160/160)。在SVM分类器未进行PSO优化的情况下,诊断精度也有着明显的提高。其中,经过PSO优化后,SVM惩罚参数为3.7132,核函数参数为4.819。

为了直观说明对滚动轴承振动信号的故障诊断效果,将4种状态测试集的诊断结果列于表1所示。

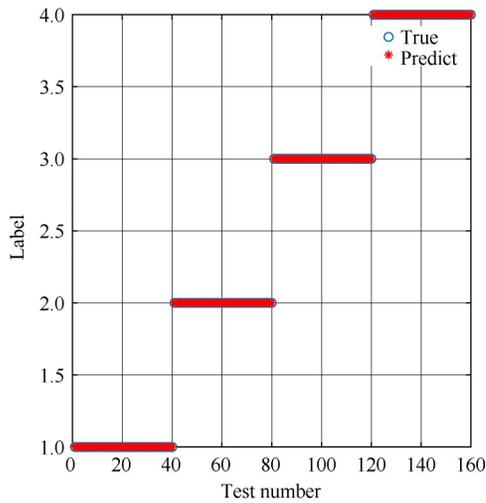


Fig. 5 PSOSVM diagnosis results of rolling bearing (FIGFE)

表中数值含义为:对于4种不同状态的40个测试集样本,选择不同方法所得到的正确分类样本数目; $C_a$ 表示精度。

Table 1 Accuracy rate comparison of fault diagnosis algorithm

Algorithm	NORM	IRF	REF	ORF	$C_a/\%$
FE-SVM	40	13	27	40	75
FE-PSOSVM	39	23	34	40	85
FIGFE-SVM	40	40	38	40	98.75
FIGFE-PSOSVM	40	40	40	40	100

如表1所示,经过PSO优化的SVM分类器,通过确定合适的惩罚参数和核函数参数,能够有效提高SVM算法的分类效果。基于FE的故障诊断中,经过优化后的SVM诊断精度提高了10%;基于FIGFE的故障诊断中,经过优化后的SVM诊断精度提高了1.25%;证明了采用PSO算法对SVM进行参数优化的合理性。在同时选择PSOSVM分类器的情况下,本文提出的FIGFE算法在诊断精度上相比FE提高了15%,识别率达到了100%,证明了本文所提出的FIGFE算法在故障特征提取中的优势,同时证明了本文算法的有效性。

为了进一步验证算法的有效性,选择窗口大小为  $win = 3$ ,对原始滚动轴承振动信号进行粗粒化处

理。针对每个状态的80个样本,在训练集的选择中,分别选择10%训练集(训练集8个,测试集72个)、20%训练集(训练集16个,测试集64个)、30%训练集(训练集24个,测试集56个)、40%训练集(训练集32个,测试集48个)及上文的50%训练集进行对比,对不同状态下的滚动轴承振动信号进行故障诊断,所得结果如表2所示。

如表2所示,在窗口大小为  $win = 3$  条件下,除10%训练集的情况下诊断精度较差外,其余状态下经过PSO优化SVM的故障诊断精度均能达到100%的故障诊断精度。证明了本文提出的FIGFE方法的合理性,通过对原始信号序列进行粗粒化,然后分别对粗粒化序列进行FE熵值求解,能够深层次、多尺度提取滚动轴承振动信号的特征信息。

### 3.2 机载燃油泵数据验证

某型机载燃油泵故障检测系统通过振动传感器采集燃油泵工作过程中正常状态和不同故障状态的振动信号。振动传感器安装于电机轴承处,所使用的电机为定频电机。采集到除正常状态(记为NORM)外的3种故障状态,分别为扩散管损伤(记为KSG)、扩散管损伤加叶轮损伤(记为KSYL)及渗漏状态(拆掉密封圈,记为SL)。每组状态各获得30组样本。

与轴承数据相比,机载燃油泵系统属于典型机械系统之一,采集到的信号均为轴承振动信号。由于机载燃油泵系统是一种高可靠、长寿命的机械系统,在实验采集过程中,故障信号通过更换不同的故障件获取,因此故障数据相比滚动轴承数据而言要少。选取其中某种状态进行窗口大小  $win = 3$  的FIG处理,得到3组数据序列Low, R, Up。粗粒化结果如图6所示。

对比图3及图6可知,机械系统的振动信号具有较强的非线性及非平稳性,且通过FIG模糊信息粒化后所得到的3组模糊粒化数据之间具有明显的特征信息。

为了对比验证FIGFE算法对于提高FE性能方面的有效性,首先将采集到的4种状态下各30组数据中的15组作为训练集,余下15组作为测试集,训练集与

Table 2 Comparison of different training sets

Algorithm	Amount of training sets				
	10%	20%	30%	40%	50%
FIGFE-SVM	93.0556%	96.0938%	98.2143%	98.9583%	98.75%
FIGFE-PSOSVM	97.2222%	100%	100%	100%	100%

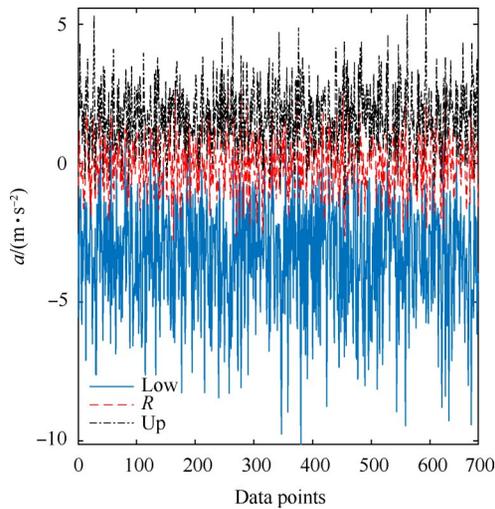


Fig. 6 Graining results figure ( $win = 3$ )

测试集均为样本数据的50%,以验证算法的有效性。

首先验证基于FE算法的故障诊断性能,直接对机载燃油泵系统振动信号进行FE解算,并将FE熵值作为特征向量输入至PSOSVM分类器中,记NORM状态为标签1,KSG状态为标签2,KSYL状态为标签3,SL状态为标签4,所得结果如图7所示。

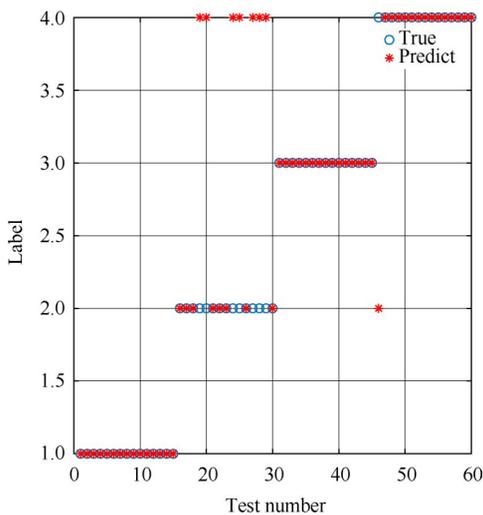


Fig. 7 PSOSVM diagnosis results of fuel pump (FE)

在滚动轴承的故障诊断过程中,论证了PSO对于提高支持向量机诊断能力的可行性。因此在机载燃油泵系统故障诊断中仅采用PSOSVM分类器进行故障诊断。采用机载燃油泵振动信号的模糊熵值作为特征向量时,针对60个测试集,故障诊断精度为86.6667%(52/60)。其中KSG状态有7个样本被错分至SL状态;SL状态有1个样本被错分至KSG状态。

采用本文所提出的FIEFE-PSOSVM方法进行故障诊断,首先对机载燃油泵振动信号进行窗口大小为 $win = 3$ 的粗粒化处理,然后对得到的Low, R, Up

三组粒化数据进行FE熵值求解,将FE熵值作为特征向量并输入至PSOSVM分类器中,结果如图8所示。

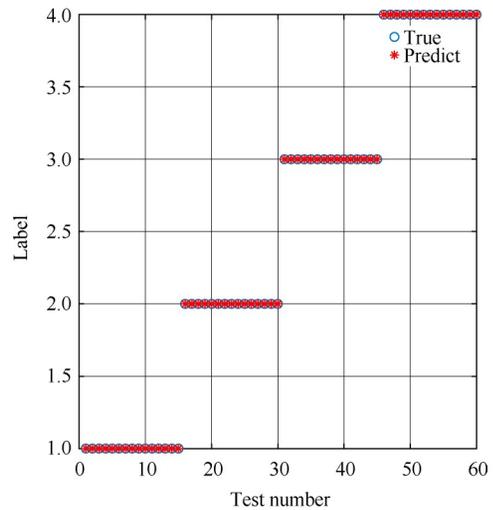


Fig. 8 PSOSVM diagnosis results of fuel pump (FIGFE)

采用本文提出的窗口大小为 $win = 3$ 的FIGFE方法,针对60个测试集,故障诊断精度为100%(60/60),所有故障状态均得到了正确的分类识别。

所采集到的机载燃油泵故障状态与滚动轴承故障状态均为基于轴承的振动信号,信号具有非线性及非平稳性。受到机械系统复杂性影响,信号的随机性表现在多个尺度上,此时采用常规的FE熵值算法不能完整地提取故障信息。本文提出的基于FIGFE特征提取算法,通过在窗口大小 $win = 3$ 下对原始振动信号进行模糊信息粒化,得到3组特征信息区分明显的模糊粒化数据,有效地概括了机械系统的故障信息,提高了FE熵值的特征提取能力,证明了基于FIGFE振动信号特征提取的有效性。

## 4 结论

本文结合模糊信息粒化与模糊熵对机载燃油泵系统振动信号进行分析,提出了新的FIGFE熵值求解方法,在多个粗粒化序列下对振动信号的特征向量进行了深层次提取,并成功应用于机载燃油泵及滚动轴承不同故障状态诊断。实验结果表明:

(1)相比基于模糊熵的特征提取算法而言,FIGFE方法通过粗粒化方式得到3组粗粒化序列的信息,所提取的故障状态特征向量更加完备,具有一定的精度优势。

(2)FIGFE算法简单,参数设置较少且定义了窗口设置标准,所提取的特征向量仅有3组,既避免了较多特征向量造成的数据冗余及冲突,也提高了算法的自适应性。

(3)采用 PSO 方法优化 SVM,可以更加准确地选取 SVM 计算过程中的惩罚参数和核函数参数,提高了 SVM 的分类能力。

(4)采用机载燃油泵系统及滚动轴承系统进行分析,证明了 FIGFE 算法在机械系统振动信号特征提取方面的适用性,具有一定的应用价值。

致谢:感谢山东自然科学基金面上项目、国防科技项目基金的资助。

## 参考文献

- [ 1 ] 刘晓东,景博,石慧,等. 燃油泵故障诊断试验装置及试验方案优化设计[J]. 振动.测试与诊断, 2017, 37(6): 1187-1194.
- [ 2 ] 丁锋,栗祥,韩帅. EEMD 与 NRS 在涡桨发动机转子故障诊断中的应用[J]. 航空动力学报, 2018, 33(6): 1423-1431.
- [ 3 ] 焦晓璇,景博,羌晓清,等. 机载燃油泵故障诊断及实验平台研究[J]. 振动与冲击, 2017, 36(1): 120-128.
- [ 4 ] Logan D, Mathew J. Using the Correlation Dimension for Vibration Fault Diagnosis of Rolling Element Bearings [J]. *Mechanical Systems & Signal Processing*, 1996, 10 (3): 241-250.
- [ 5 ] 李晓娟,曲建岭,邹文栋,等. 航空发动机状态参数的关联维数分析[J]. 计算机仿真, 2013, 30(9): 56-59.
- [ 6 ] Muralidharan V, Sugumaran V. Rough Set Based Rule Learning and Fuzzy Classification of Wavelet Features for Fault Diagnosis of Monoblock Centrifugal Pump[J]. *Measurement*, 2013, 46(9): 3057-3063.
- [ 7 ] 林近山,窦春红,张妮. 基于多重分形去趋势互相关分析的齿轮箱故障诊断[J]. 机械传动, 2016, 40 (1): 91-94.
- [ 8 ] 李兵,张培林,任国全,等. 形态学广义分形维数在发动机故障诊断中的应用[J]. 振动与冲击, 2011, 30(10): 208-211.
- [ 9 ] 王冰,李洪儒,陈强华,等. 基于数学形态分形维数与模糊 C 均值聚类的滚动轴承退化状态识别[J]. 兵工学报, 2015, 36(10): 1982-1990.
- [ 10 ] 侯荣涛,闻邦椿,周颀. 基于现代非线性理论的汽轮机发电机组故障诊断技术研究[J]. 机械工程学报, 2005, 41(2): 142-147.
- [ 11 ] 胡春燕,刘新灵,李莹. 某发动机主燃油泵轴承失效分析[J]. 金属热处理, 2011, 36(9): 64-67.
- [ 12 ] Pincus S M. Approximate Entropy as a Measure of System Complexity[J]. *Proceedings of the National Academy of Sciences of the United States of America*, 1991, 88(6): 2297-2301.
- [ 13 ] Yan R, Gao R X. Approximate Entropy as a Diagnostic Tool for Machine Health Monitoring[J]. *Mechanical Systems and Signal Processing*, 2007, 21(2): 824-839.
- [ 14 ] Chen W, Wang Z, Xie H, et al. Characterization of Surface EMG Signal Based on Fuzzy Entropy [J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2007, 15(2): 266-272.
- [ 15 ] 王付广. 基于 ELM 的滚动轴承退化趋势与剩余寿命预测方法研究[D]. 马鞍山:安徽工业大学, 2018.
- [ 16 ] 戴洪德,陈强强,戴邵武,等. 基于平滑先验分析和排列熵的滚动轴承故障诊断[J]. 推进技术, 2020, 41 (8). (DAI Hong-de, CHEN Qiang-qiang, DAI Shao-wu, et al. A Rolling Bearing Fault Diagnosis Method Based on Smoothness Priors Approach and Permutation Entropy [J]. *Journal of Propulsion Technology*, 2020, 41(8).)
- [ 17 ] 郑近德,姜战伟,代俊习,等. 基于 VMD 的自适应复合多尺度模糊熵及其在滚动轴承故障诊断中的应用[J]. 航空动力学报, 2017, 32(7): 1683-1689.
- [ 18 ] Zadeh L A. Toward a Theory of Fuzzy Information Granulation and Its Centrality in Human Reasoning and Fuzzy Logic[J]. *Fuzzy Sets and Systems*, 1997, 90(2): 111-127.
- [ 19 ] 陈强强,戴邵武,戴洪德,等. 基于分解-粒化和优化极限学习机的燃油泵性能退化趋势预测[J]. 推进技术, 2020, 41(8). (CHEN Qiang-qiang, DAI Shao-wu, DAI Hong-de, et al. Forecasting of Fuel Pump Performance Trend Based on Decomposition-Granulation and Optimized Extreme Learning Machine [J]. *Journal of Propulsion Technology*, 2020, 41(8).)
- [ 20 ] 郑近德,程军圣,杨宇. 基于 LCD 和排列熵的滚动轴承故障诊断[J]. 振动.测试与诊断, 2014, 34(5): 802-806.
- [ 21 ] 郑近德,陈敏均,程军圣,等. 多尺度模糊熵及其在滚动轴承故障诊断中的应用[J]. 振动工程学报, 2014, 27(1): 145-151.
- [ 22 ] Wu S, Wu P, Wu C, et al. Bearing Fault Diagnosis Based on Multiscale Permutation Entropy and Support Vector Machine[J]. *Entropy*, 2012, 14(8): 1343-1356.
- [ 23 ] Garcíagonzalo E, Fernándezmartínez J L. A Brief Historical Review of Particle Swarm Optimization (PSO) [J]. *Journal of Bioinformatics & Intelligent Control*, 2012, 1 (1): 3-16.
- [ 24 ] Smith W A, Randall R B. Rolling Element Bearing Diagnostics Using the Case Western Reserve University Data: a Benchmark Study[J]. *Mechanical Systems and Signal Processing*, 2015, 64-65: 100-131.

(编辑:梅 瑛)