

小样本条件下基于 SGMM 模型的滚动轴承故障诊断研究

韩波^{1,2}, 章荣丽^{1,2}

(1. 商洛学院 数学与计算机应用学院, 陕西 商洛 726000;

2. 秦岭康养大数据陕西省高校工程研究中心, 陕西 商洛 726000)

摘要: 由于机械设备故障时间短, 信号捕获难度高等原因的存在, 会导致小样本故障集出现, 但小样本往往是机械故障诊断的关键; 针对小样本条件下传统滚动轴承故障诊断算法存在检测率偏低等问题, 提出一种基于 SGMM 模型的滚动轴承故障诊断算法; 先确定与故障建模策略相关的提取任务, 预估潜在的机械故障状态变化; 对故障信号进行变分模态分解, 得到最小熵解卷积结果, 并满足端点效应的处理需求, 实现对机械故障位置的精确定位与诊断; 实验结论表明, SGMM 模型更注重对故障脉冲成分的连续检测, 在以峭度作为衡量标准的条件下, 该方法增强故障冲击力的作用更强, 能更早诊断出轴承类机械元件的早期故障状态, 平均故障检测率能够达到 99.4%。

关键词: 小样本条件; SGMM 模型; 变分模态; 熵解卷积; 端点效应

Research on Rolling Bearing Fault Diagnosis Based on SGMM Model under Small Sample Condition

HAN Bo^{1,2}, ZHANG Rongli^{1,2}

(1. College of Mathematics and Computer Application, Shangluo University, Shangluo 726000, China;

2. Engineering Research Center of Qinling Health Welfare Big Data, Universities of Shaanxi Province, Shangluo 726000, China)

Abstract: Due to the short fault time of mechanical equipment and high difficulty of signal acquisition, it leads to small sample fault sets to occur, but small samples are often the key to mechanical fault diagnosis. A rolling bearing fault diagnosis algorithm based on subspace Gaussian mixture model (SGMM) model is proposed to address the problem of low detection rate in traditional rolling bearing fault diagnosis algorithms under small sample conditions. Firstly, identify the extraction tasks related to the fault modeling strategy and estimate potential changes in mechanical fault status; The variational modal on the fault signal is decomposed to obtain the minimum entropy deconvolution result, meet the processing requirements of endpoint effects, and realize the precise positioning and diagnosis of mechanical fault locations. The experimental conclusion shows that the SGMM model places more emphasis on continuous detection of fault pulse components. The kurtosis is taken as a measurement standard, this method has a stronger effect on enhancing fault impact and can diagnose the early fault status of bearing mechanical components, with an average fault detection rate of 99.4%.

Keywords: small sample condition; SGMM model; variational mode; entropy deconvolution; endpoint effect

0 引言

随着自动化控制技术和人工智能技术的发展, 机械设备都朝着大型化、复杂化和智能化的方向演进^[1]。以滚动轴承为代表的旋转类机械, 是用途最为广泛的机械零部件之一。作为支撑设备运转的核心部件之一, 几乎所有的旋转类机械结构都要使用到滚动轴承^[2]。由于工作时间较长

且承受巨大的挤压力, 滚动轴承类机械容易出现金属疲劳引起故障, 进而导致机械设备或整体生产线停工, 给企业的生产经营带来潜在损失。受作业现场环境噪声和设备系统噪声的影响, 有价值的信号可能被湮没; 此外, 受信号传感器工作频率、灵敏度等其他因素的综合影响, 所采集到的故障样本集合有效样本比例可能会低于 30%, 进而形

收稿日期: 2023-04-28; 修回日期: 2023-06-02。

基金项目: 国家社科基金西部项目(21XJY015); 陕西省教育厅基础教育重大招标项目(ZDKT1606); 陕西省社科联项目(2022HZ1800); 陕西省教育学会项目(SJHZDKT201605-04); 陕西省教育科学“十三五”规划项目(SGH17H342)。

作者简介: 韩波(1978-), 男, 硕士, 副教授。

通讯作者: 章荣丽(1980-), 女, 硕士, 副教授。

引用格式: 韩波, 章荣丽. 小样本条件下基于 SGMM 模型的滚动轴承故障诊断研究[J]. 计算机测量与控制, 2023, 31(9): 83-89.

成小样本。而小样本集合中往往包含着关键的故障特征，是对滚动轴承故障类别判定和诊断的关键。因此，在小样本环境下实现对滚动轴承工作状态的故障诊断意义重大。

机械故障诊断技术已有上百年的历史，是现代工业领域较为成熟的技术。当前，国内外针对于滚动轴承的故障诊断技术研究，主要集中于专家经验法、基于信号的诊断方法和人工智能诊断法。随着机械设备复杂程度的逐渐提高，信号分析法和智能检测法的应用场景越来越广泛。基于时频域信号的故障诊断方法是较为常见且有效的方法之一^[3]，时域检测手段可用来排查机械设备的故障特征情况，若存在方差、均方值、峰值等量纲型时域统计量，可通过提取大量特征点信息的方式，确定故障发生的具体区段位置，适用环境机械设备的稳态振动及旋转故障等。

文献 [4] 提出一种基于时频域结合的机械故障信号诊断算法，通过提出滚动轴承工作中产生的脉冲分量特征和非平稳信号的振动特征，进而判断出故障的类别位置和程度。但该方法仅能够提取时频域信号的统计均值，而无法揭示出非平稳信号局部细节特征，尤其在小样本环境下，故障分类检测精度难度得到保证；文献 [5] 提出一种基于 EMD（经验模态分解）的在线机械故障诊断算法，该种算法基于内涵模态分量分解能够确定出故障信号的振动模态，还解决了非线性和非平稳型号的特征提取问题。但该方法对于输入故障集的有效样本要求较高，无法平衡故障集规模和有效样本比例的问题，因此适用性较差。在无量纲型时域统计量的情况下，往往采用峭度、散度等物理参量对故障节点的冲击特征进行判断^[6]。当机械设备所处的振动形式极为不平稳时，振动信号所表现出来的峭度值水平也会不断升高，这也是引发机械设备严重旋转故障的主要原因。对于故障行为的早期判别来说，由于时域统计量的存在，峭度值表现结果容易受到载荷、转速等指标参量的影响，从而呈现极度波动的变化状态，在这样的表现情况下，若不能针对旋转故障行为进行准确的定量分析，不但会导致故障检测结果的可靠性与准确性能力大打折扣，也会使所获运行数据的可参考性价值直线下降。尽管基于信号分析的故障诊断方法已经得到了较为普遍的应用，但是在生产线实际作业中，机械设备运行状况极为复杂，提取到的故障信号微弱且包含大量噪声干扰，尤其在小样本环境下信号处理难度会大大增加。因此，在实际故障检测工作中会将多种方案融合使用，以获得更好的故障诊断效果。

综上所述，故障集有效样本的规模是影响和制约机械故障诊断的关键因素之一，提升在小样本环境下机械故障诊断精度和分类精度具有重要的研究意义。以滚动轴承为代表的机械结构工作环境较为恶劣，存在大量的系统噪声和环境噪声，小样本条件准确提取少量故障样本的细节特征性，成为故障诊断的关键，为此本文提出一种基于 SGMM（subspace gaussian mixture model 子空间高斯混合模型）模型的机械故障诊断算法，该模型通过计算多个状

态量均值方差参数来表征输出结果的概率，而且每个状态向量仅仅关联位移的低维度映射向量，在有效样本有限的条件下提升对故障集的训练效率和效果，提升故障诊断和分类的精度。

1 小样本条件下的故障状态估计

通常可针对当前设备运动形式的不同，而对其所属故障类别进行初步判断，特别是在参考数值量相对较少的小样本条件下，该模型更是具备极强的可行性应用能力^[7]。对于大型机械设备来说，由于其轴系跨度较大、整体结构的复杂性水平较高，很容易因运转时间的延长，而出现严重的旋转故障问题。若以振动信号处理法作为参考标准，则需要截取大量故障数据，通过定性分析与定量分析的方式，确定不合理信息参量的表现形式，从而完成对故障行为的诊断。然而在面对连续故障脉冲成分时，此方法所定义的峭度值指标局限性过大，不足以增强故障行为的冲击力能力。迎合上述理论研究弊端，提出小样本条件下基于 SGMM 模型的机械故障诊断方法，在变换故障评估思路的同时，提取必要的故障行为建模任务，再按照端点效应的处理原则，对变分模态参量进行分解处理，从而计算得出关键性影响参数的具体数值水平。先对小样本条件下的机械故障状态进行评估，本章节从问题分析与解决思路入手，排查机械设备的旋转故障度量准则，从而提取得到最终的关键性故障建模任务。

1.1 SGMM 故障集诊断模型构建

SGMM 模型的最基本形式为高斯映射关系，表示为如下 3 个等式：

$$p(x_i | i) = \sum_{j=1}^N \omega_{ij} N(x, \eta_j, \sum i) \quad (1)$$

$$\eta_j = M_i \kappa_j \quad (2)$$

$$\omega_{ij} = \frac{\exp w_i^T \kappa_j}{\sum_{i=1}^N \exp w_i^T \kappa_j} \quad (3)$$

其中： x_i 为故障数据集的特征矢量， i 为特征索引的状态，每个状态对应一个高斯均值和权重，其中状态 j 由矢量映射 κ_j ， N 为子空间的数量， ω_{ij} 为不同状态之间的权重比例分配， M_i 是与 ω_{ij} 相对应的权重规则。SGMM 模型本质上一种启发算法，高斯混合模型可以视为一个通用型的背景模型，应用模型一方面可以实现对初始故障集的降噪，另一方面也更有助于在小样本环境下提取故障集中不同故障类型的细节特征。SGMM 模型的子状态，与高斯混合度和隐马尔可夫混合模型有一定的相似之处，但其处理小样本故障数据的能力更强。SGMM 模型参数设置相对于隐马尔可夫混合模型要更少，因此提升了参数优选和细化的空间。SGMM 模型的子状态数量可以根据故障集的规模和故障数据的复杂程度调整和拓展。

1.2 故障特征表征与提取

在小样本条件下，虽然单一估算方法能够反映机械设备的现有故障状态，但针对滚动轴承等旋转型故障形式来

说, 这种评估方法并不能准确说明各级机械节点所面临的具体故障严重程度, 从而易导致后续估计运算失去原有准确度, 最终抑制 SGMM 模型的应用能力^[8]。为避免后续估计运算复杂度过高, 且精度有所减低, 应针对旋转型机械故障特殊节点处的故障表现行为进行重新定义, 并联合 SGMM 模型, 对这种估算方法的实用性价值进行考量。规定在小样本条件下, 机械设备所表现出的旋转性故障均符合 SGMM 模型的作用标准, 在考虑差异性影响、关联度水平的情况下, 故障节点所处的位置深度值越大, 其最终表现出的故障行为也就越明显^[9]。故可设 i_1 代表故障点所处的初始位置深度值, i_2 代表运行结束后故障节点所处的位置深度值, 在机械旋转均值为 $\bar{\omega}$ 的情况下, 可将小样本条件下最原始的机械旋转故障行为定义为:

$$\mathfrak{S}(e_0) = \sum_{i_2=1}^{i_1} \left\| \frac{(e_0)^2 (\Delta T)}{\lambda |\omega_{i_1} - \omega_{i_2}|^2} \right\| \quad (4)$$

式中, e_0 为初始的旋转故障命名系数, ΔT 为单位估算时长, λ 为机械设备旋转周期, ω_{i_1} 、 ω_{i_2} 为两个不同的故障行为定义参考项。机械故障的状态根据环境和时长的变化会有所不同, 系统噪声和环境噪声的干扰也会使较为微弱的有用故障信号湮没高频振动之中, 因此需要对故障产生的具体环境和模态进行较为精确的度量。

1.3 故障模态的度量

度量准则是描述机械设备旋转故障行为的重要条件, 可清晰表述机械设备在固定区段内的运转形式, 并在特殊位置处, 针对旋转故障行为的表现形式进行说明^[10-11]。分析图 1 所示故障度量分解示意图可知, 在正常运作情况下, 旋转故障所带来的影响始终沿一条平滑曲线向前不断传播, 且随传播时间的延长, 曲线的偏转角度也会不断增大。而在此过程中, 受到 SGMM 模型诊断意识的影响, 会产生指向其他作用方向的度量曲线, 且在小样本条件下, 该曲线所指的传输方向, 才是故障度量准则的实际表现方向。为使该曲线的存在形式得到稳定控制, 必然会在其上、下两个方向上, 产生两个方向相反、大小相同的诊断意识。




图 1 机械旋转故障度量的分解示意图

若设 F_0 表示故障度量的原始诊断意识, F 表示故障度量的实际诊断意识, F_1 、 F_2 表示上下两个方向的诊断分量, 联立公式 (1), 可将基于 SGMM 模型的机械设备旋转故障度量准则定义为:

$$M = \mathfrak{S}(e_0) \left\| \frac{\frac{1}{n} \sum_{F=0}^{+\infty} \varphi_1(F_1 F_2)}{\frac{1}{m} \sum_{F=0}^{+\infty} \varphi_2(F_0 F)} \right\| \quad (5)$$

其中, φ_1 为与 F_1 和 F_2 度量分量相关的预估参量, φ_2 为与 F_0 和 F 相关的预估参量, n 、 m 为两个不同的故障行为为曲线传播系数。

2 基于 SGMM 模型的机械故障识别与诊断

在小样本条件支持下, 针对机械旋转故障状态估计中的关键系数指标, 进行变分模态分解, 再从中提取重要影响参数, 利用最小熵解卷积处理方法, 定义诊断指令的端点效应。

2.1 变分模态分解

变分模态是一种阶段性的机械故障行为诊断与分析背景, 可在已知建模任务的基础上, 完善度量准则的提出条件, 从而使得诊断主机能够准确掌握机械设备旋转故障行为的表现强度, 并最终迎合小样本条件, 制定相对较为可行的诊断实施方案^[12]。在 SGMM 模型的作用下, 机械设备所表现出的旋转故障行为并不能保持完全稳定的存在状态, 而是会随诊断时间的延长, 而出现不可控的变化形式。在变分模态条件的理解范围中, 机械旋转故障可被人为分割成多个小的物理表现区间, 且在每一区间内, 允许不同旋转角速度值与线速度值的同时存在^[13]。设 f 代表旋转故障行为的保真项, 1、2、...、 v 分别代表多个不同的变分模态区间分解参量, 联立公式 (3), 可将机械旋转故障诊断的变分模态分解结果表示为:

$$L = \sqrt{\frac{\mathbb{R} \cdot |f_1 - f_2 - \dots - f_v|^2}{1 + \alpha \omega^2}} \quad (6)$$

其中: α 代表旋转角速度值, ω 代表旋转线速度值, φ 代表单一区间内的旋转故障行为维稳系数。

2.2 重要影响参数分析

为保证机械故障诊断指令的顺利执行, SGMM 模型在小样本条件下必须存在一个关键的检测影响系数, 成为重要影响参数。若将变分模态分解条件考虑在内, 则可认为机械设备的旋转故障诊断是一类非定向检测问题, 随机提取一个故障参量作为待参考数值, 将其置于绝对稳定的区间环境中, 忽略周围参量对该项物理系数值的影响, 认为在该环境中, 已被定义的故障参量具有绝对性影响能力, 因此若不考虑故障参量的明显迁移行为, 则可直接过滤所有非必要的系数参量指标^[14-15]。规定 \bar{d} 表示区间环境中的机械旋转故障行为为量均值, $h(\bar{d})$ 表示关于故障行为量均值的诊断定义式, 联立公式 (4), 可将重要影响参数表达式定义为:

$$G = \frac{\left(\mu L + \frac{\bar{j}}{\Delta C} \right) * h(\bar{d})}{\int_R M \times N} \quad (7)$$

式中, μ 为变分模态量的分解权限值, \bar{j} 为绝对性影响参量特征值, ΔC 为单位时间内的系数指标过滤量, R 为故障行为参

量的诊断权限极小值, M 、 N 为两个不同的参量值表现系数。

2.3 最小熵解卷积

在面对机械设备的旋转故障行为时, 最小熵解能够描述 SGMM 模型的现有诊断能力, 并可借助已知的小样本条件, 对相关数值解参量的真实性进行判定, 一般来说, 最小熵解集合中包含的数值参量越多, 机械设备的旋转故障强度等级也就越高^[16-17]。最小熵解卷积则是一种有效的熵解数值处理方法, 可在 SGMM 模型的作用下, 借助重要影响参数项, 确定现有数值解与机械旋转故障行为之间的函数对应关系, 再通过判断数值解存在个数的方式, 得到最终的卷积处理结果。




图 2 最小熵解卷积处理流程

设 p 表示数据集中的熵解指标个数, g_1 、 g_2 代表两个不同的熵解指标分离系数, 联立公式 (5), 可将机械旋转故障行为的最小熵解卷积处理标准定义为:

$$A = \frac{\sum_p \left[\alpha G + \frac{(g_2 - g_1)^2}{h \times V} \right]}{\sqrt{\epsilon_G^2 - \epsilon_0^2}} \quad (8)$$

其中: φ 为重要影响参数的平均参考条件, h 为熵解指标分离权限量, V 实值分离项, ϵ_G 为卷积分析的实际迭代值, ϵ_0 为卷积分析的理想迭代值。

2.4 端点效应处理与故障诊断的实现

在实际诊断过程中, 脉冲成分可用来表示机械旋转故障的表现强度, 对于一般性故障行为来说, 峭度数值越大, 脉冲成分的连续性就越强, 由旋转故障带来的故障冲击力也就越大。而所谓端点效应则是对脉冲成分连续性能力的描述, 在固定端节点处, 若故障行为满足一次定义条件, 则可认为其脉冲成分具有较强的连续性, 与之相关的故障冲击力水平也就较高, 反之则较低^[18]。规定 \bar{I} 表示机械旋转故障行为的脉冲量均值, O_s 表示端节点所处位置, δ 表示端点编号, 在公式 (6) 的支持下, 可将端点效应原理表

示为:

$$E = \frac{\bar{I}}{A \left(1 + \frac{\psi^2}{O_s} \right)} \quad (9)$$

式中, ψ 表示故障冲击力强度, ν 表示旋转故障冲击项。由于机械故障行为的连续传导性, 可认为在已知机械结构体端点效应的基础上, 可联合小样本条件借助 SGMM 模型实现对故障行为的实时诊断。为构建 SGMM 模型, 可将机械设备旋转故障分为训练集合与测试集合两部分, 且在整个故障诊断指令的操作过程中, 待建模的数据集样本必须由标签和特征同时组成。所谓训练集合可用来训练所有可能出现的机械旋转故障数据, 具备较强的统筹性能力, 在 SGMM 模型的约束作用下, 满足小样本条件筛查标准的训练集合样本越多, 机械旋转故障的可能出现概率也就越低。测试集合则更注重对机械旋转故障数据的收集, 随着机械设备旋转速度的加快, 所产生的故障数据信息量也会逐渐增大^[19], 在这样一种变化情况下, 小样本条件的筛查能力开始不断增强, 从而导致 SGMM 模型的记忆能力下降, 并最终失去对机械设备旋转故障行为准确诊断的能力。规定在实施故障建模处理时, 训练集合样本与测试集合之间不存在明显的干扰影响^[20], 且由于 SGMM 模型的存在, 小样本条件下任何机械设备的旋转故障行为都能得到准确诊断。设 q_1 代表训练集合中一个随机的机械旋转故障数据, q_2 代表测试集合中一个随机的机械旋转故障数据, 在单位诊断时长 Δt 内, $q_1 \neq q_2$ 的表达式恒成立。联立公式 (2), 可将小样本条件下所提取的机械旋转故障建模任务定义为:

$$\mathbb{R} = \left\| \frac{\sum_{u_{\min}}^{u_{\max}} \chi_1(y_1)}{q_1} - \frac{\sum_{u_{\min}}^{u_{\max}} \chi_2(y_2)}{q_2} \right\|_{\theta \cdot \Delta t} \quad (10)$$

式中, u_{\min} 为最小的故障任务诊断残差值, u_{\max} 为最大的故障任务诊断残差值, χ_1 、 χ_2 为训练集合与测试集合的故障数据样本排查系数, y_1 、 y_2 为训练集合与测试集合的实际故障数据排查样本, θ 为弹性建模系数。在数据训练前先对 SGMM 模型进行初始化处理, 模型初始化的目标是提升训练过程中的迭代效率, 初始化后模型的子状态是一一对应的关系, 而子空间的维度可实现自由制定。对于空间内的故障状态向量而言, 故障定位与检测概率计算的效率较低, 要提升 SGMM 模型子空间维度, 实现全局范围内优先级计算和检测。高斯子状态概率计算过程如下:

$$\log p(x(t), N, i | j) = \chi(x_i) + \sum_{j=1}^N \exp w_j^T \kappa_j y_j \quad (11)$$

机械故障的分类检测过程中, 要在小样本环境下确保对故障分类诊断的精度, 要实现 SGMM 模型参数集的实时同步更新, 并在迭代中获取到故障检测概率的累计量。基于 SGMM 模型故障训练时, 在一个迭代周期内无法实现对全部参数的实时更新, 当状态向量数量较多或输入故障集的规模较大时, 参数更新的难度同步增加。而通过对训

练集和测试集的双重故障判断, 并确定出任务模型, 将有助于消除端点效应, 并准确判定故障点的位置、故障类型及故障的程度。

3 实验分析与讨论

3.1 实验环境设置与故障集的构建

在小样本条件下, SGMM 模型通过脉冲成分分析的方式, 对机械设备的旋转类故障问题进行诊断, 特别是针对滚动轴承型机械元件来说, 若将峭度量作为唯一的衡量条件, 则可认为阶段时间内, 脉冲成分的连续性越强, 旋转故障行为的冲击性能力也就越强, 获得准确故障裁定结果所需的诊断时间就越短。由于脉冲成分之间的相关性较强, 本次实验将以子波形、边界波形之间的相关程度作为参考标准。规定在峭度量数值不断增大的情况下, 子波形、边界波形在正方向上匹配度增强, 才能表示原始脉冲成分的连续性较强。




图 3 故障脉冲波收发装置

故障脉冲波收发装置的最高冲击高压要低于 30 kV, 测试脉冲幅值为 150~380 VP-P 之间, 数据信号采样频率包括 4 种, 分别为 30 MHz, 60 MHz, 90 MHz, 120 MHz。基于脉冲收发装置, 模拟了滚动轴承外圈故障、内圈故障、支架故障和滚子故障等四种不同的状态, 所构建的故障样本集, 如表 1 所示 (将所构建的 2 000 个样本分为 10 组, 每组 200 个样本, 4 种故障类型被随机分布于每组故障集之中):

表 1 滚动轴承的故障集分布

分组	故障样本数量				
	正常样本	外圈故障	内圈故障	支架故障	滚子故障
1	181	15	1	2	1
2	176	17	2	4	1
3	167	25	3	1	4
4	173	18	4	2	3
5	172	19	2	3	4
6	180	15	1	1	3
7	179	13	2	2	4
8	181	14	3	1	1
9	178	16	2	2	2
10	175	17	3	2	3

故障集的分布特征显示: 由 10 组样本特征可知绝大多数故障样本属于正常样本, 故障样本所占总体比例较低符合小样本环境的要求。最主要的故障类型为外圈故障, 这也是滚动轴承最容易发生故障的区域, 因为轴承外圈承受

着巨大的外部挤压力。

3.2 外圈故障特征的峭度量检测

由于故障集中外圈故障较为集中, 以外圈故障的峭度量检测为例, 验证提出 SGMM 模型在故障定位检测的实际效果。开始进行消融实验时, 首先打开脉冲输出机, 控制其在单位时间内所输出脉冲波的稳定性; 其次打开集波器装置, 令两个设备元件分别对脉冲输出机所发出信号的子波形与边界波形进行记录; 最后打开波量分析仪, 分别提取子波形、边界波形的记录数据, 具体的外圈故障峭度量子波形变化形式和边界表现变化, 如图 4~5 所示。




图 4 子波形




图 5 边界波形

当峭度量 τ 为零情况下, 三组脉冲波子波形与边界波形的实际变化情况。根据公式 (8), 计算得到峭度量 τ 的实际数值。

$$\tau = \frac{\sum_{r_0}^{\infty} E^1(z)}{\left[\sum_{r_0}^{\infty} E^2(z) \right]^2} \quad (12)$$

其中: z 表示滚动轴承在发生旋转故障行为时的转速值, r_0 表示脉冲系数项。

当峭度量 τ 的计算结果为整数时, 可按照表 2 对转速值 z 、脉冲系数项 r_0 进行取值。

当峭度量 τ 量保持不变时, 控制其他脉冲波影响条件保持不变。取 τ 值在 1~9 时, 子波形、边界波形的实际波形情况, 如图 6、图 7 所示。

对比图 6 与图 4 可知, 随峭度量 τ 取值结果的增大, 子波形频率并未出现变化, 极大值、极小值结果虽有一定的上

表 2 峭度计算取值表

峭度量 τ	转速值 z	脉冲系数项 r_0
0	3.145 802...	4.222 123...
1	4.002 157...	4.673 840...
2	4.876 231...	4.978 531...
3	5.142 832...	5.343 328...
4	5.653 379...	5.979 826...
5	5.921 815...	6.313 421...
6	6.339 746...	6.875 436...
7	6.820 513...	7.231 438...
8	7.240 897...	7.767 533...
9	7.656 431...	8.141 892...
10	8.010 024...	8.553 579...




图 6 τ 取值 1—9 时的子波形




图 7 τ 取值 1—9 时的边界波形

升与下降，但整体变化量较小，可以忽略不计，一部分子波形出现了重叠现象，但总体变现并不十分明显。

对比图 7 与图 5 可知，随峭度量 τ 取值结果的增大，边界波形频率也没有出现变化，极大值、极小值结果变化量甚至比子波形极大值、极小值变化情况更为细微，也可忽略不计，但在整个实验过程中，边界波形的行为则比子波形更为明显。受到脉冲成分之间相关性的影响，一般来说，在峭度量数值不断增大的情况下，相邻脉冲波波形之间的变化量越细微，代表原始波形的连续性越强，且子动形、边界波形之间的相似性变化关系越明显，代表二者之间的关联关系越紧密，即原始波形的连续性越强。由此可见，

基于 SGMM 模型能够提取到滚动轴承外圈故障波形变化具体情况和细节特征，并根据提取到的故障特征提升对故障类型定位和检测的精度。

消融实验结果显示：在小样本条件下，应用 SGMM 模型对滚动轴承型机械设备的旋转故障问题进行诊断，原始故障波的子波形与边界波形随峭度量增大，均表现出极不明显的变化情况，且二者的变化规律始终保持一致；在阶段时间内，可验证原脉冲成分具有极强的连续性。基于上述结论可认为，应用 SGMM 模型的诊断方法，能够在保障滚动轴承型机械设备旋转故障行为冲击性能力的同时，可在较短时间内获得最终的故障诊断结果，在旋转故障问题的早期诊断方面具备较强的实际应用可行性。

3.3 总体故障检测率和不同类型故障分类检测率对比

在线故障检测的目标是在提升总体故障检测率的同时，也提高对不同类型故障定位检测率。其中三个指标的计算方法如下（总体故障检测率指标定义为 s_1 ，分类故障检测率指标定义为 s_2 ，故障误检率指标定位为 s_3 ）：

$$s_1 = \frac{H_T}{P_T} \times 100\% \quad (13)$$

$$s_2 = \frac{h_k}{P_T} \times 100\% \quad (14)$$

$$s_3 = \frac{F_k}{P_T} \times 100\% \quad (15)$$

其中： P_T 代表总体样本的数量， H_T 表示真实故障样本的数量， h_k 表示真实单一故障类别的数量， k 的取值为 1—4， F_k 为错误检测故障样本的数量。为了是结果对比更加直观，引入两种传统的故障定位与检测算法，总体故障检测率指标定义为 s_1 的检测结果，具体如表 3 所示。

表 3 总体故障率检测率对比分析

分组	故障样本数量	各算法的总体故障检测率 %		
		SGMM	时频域检测	EMD 检测
1	19	99.4	97.5	96.0
2	24	99.5	97.0	97.5
3	33	99.8	96.5	95.5
4	27	99.0	97.0	94.0
5	28	98.5	96.5	93.0
6	20	99.5	95.0	95.5
7	21	99.2	95.5	95.0
8	19	99.6	96.0	94.5
9	22	99.5	96.5	95.0
10	25	99.7	95.0	95.5
均值	—	99.4	96.3	95.2

数据分析结果显示：本文提出的 SGMM 模型各组样本的故障检测率较高，平均检测率达到了 99.4%，远高于传统时频域检测算法和 EMD 检测算法。不同故障类型检测难度更大，但对不同故障类型定位与检测也十分必要，这关系到对滚动轴承预期寿命的准确评估，对分类故障检测率指标 s_2 的数据统计结果，如表 4 所示。

表 4 各算法的分类检测率对比分析

分组	故障样本数量	各算法的分类故障检测率 %		
		SGMM	时频域检测	EMD 检测
外圈	169	99.2	95.2	94.7
内圈	20	99.6	97.1	96.8
支架	23	99.8	98.3	95.7
滚子	26	99.7	96.0	96.3

故障分类检测率统计结果显示: 针对于故障率较多的外圈故障, SGMM 故障检测模型的分类检测率能够达到 99.2%, 其他的少量故障分类检测率值也超过了 90%, 两种传统故障检测算法的分类检测率值, 均低于本文提出的算法。最后, 统计了各算法在机械故障检测中误检率的指标, SGMM 故障检测模型依然具有较为明显的优势, 统计结果如表 5 所示。

表 5 各算法的误检率指标对比分析

分组	故障样本数量	各算法误检率 %		
		SGMM	时频域检测	EMD 检测
外圈	169	0.12	0.35	0.57
内圈	20	0.11	0.50	0.52
支架	23	0.13	0.61	0.66
滚子	26	0.11	0.79	0.68

从对各种算法的滚动轴承的故障检测率、分类检测率和误检率等指标的数据分析可知, 在小样本条件下 SGMM 算法的分类检测精度高, 误检率较低, 由此可以证明提出滚动轴承故障检测算法在小样本故障集环境下的适用性更好。

4 结束语

为实现在小样本条件下, 对机械设备故障的精确诊断, 设计了一种 SGMM 模型, 并重点研究了 SGMM 模型实用性。结合现有的建模条件, 确定关键的故障度量准则, 再联合变分模态原理, 得到最小熵解的卷积处理结果, 并将其计算数据用于后续的端点效应分析与研究。以滚动轴承型机械零部件作为参考, 可知在峭度量数值不断增大的情况下, 故障输出波始终具备较强的连续性, 不但能够增强机械设备的旋转故障行为冲击性能力, 也可在较短时间内获得更为准确的诊断结果。实验结果也验证了, 在有效故障样本十分有限的条件下 SGMM 模型能够提取到滚动轴承外圈故障波形变化具体情况和细节特征, 具有良好的实际应用效果; 在与传统故障检测算法的实验对比中, SGMM 模型在总体故障检测率、分类故障检测率及误检率等三项指标中有具有一定优势。

参考文献:

[1] 鄢小安, 贾民平. 基于参数自适应特征模态分解的滚动轴承故障诊断方法 [J]. 仪器仪表学报, 2022, 43 (10): 252-259.
 [2] 宋向金, 赵文祥. 交流电机信号特征分析的滚动轴承故障诊断方法综述 [J]. 中国电机工程学报, 2022, 42 (4): 1582-1598.

[3] 孙仕鑫, 高洁, 王伟, 等. 基于多通道时频域信号的卷积神经网络智能故障诊断技术 [J]. 科学技术与工程, 2021, 21 (15): 6386-6393.
 [4] 柳素红, 孙晓, 李春彬. 基于位置信息重建与时频域信息融合的脑电信号情感识别 [J]. 计算机工程, 2021 (12): 95-102.
 [5] 阳瑞霖, 何葵东, 胡蝶, 等. 基于振动信号 EMD 分解与支持向量机的有载分接开关机械故障诊断 [J]. 变压器, 2022, 59 (7): 29-33.
 [6] 孟晓承, 韩学山, 许易经, 等. SF6 高压断路器机械故障概率的非精确条件估计 [J]. 电工技术学报, 2019, 34 (4): 693-702.
 [7] 张新军, 江良, 林志兴. 基于 GMM 方法跳聚集的短期利率模型参数估计 [J]. 系统科学与数学, 2019, 39 (1): 92-107.
 [8] 张淑清, 苑世钰, 姚玉永, 等. 基于 ICEEMD 及 AWOA 优化 ELM 的机械故障诊断方法 [J]. 仪器仪表学报, 2019, 40 (11): 175-183.
 [9] 夏小飞, 芦宇峰, 苏毅, 等. 基于 CEEMDAN-LMD-KFCM 的断路器操动机构机械故障诊断方法 [J]. 高压电器, 2020, 56 (6): 159-165.
 [10] 郑州, 黄天富, 郭志伟, 等. 基于交叉验证深度置信网络的少样本柔直计量装置故障诊断方法研究 [J]. 电网与清洁能源, 2019, 35 (1): 62-67.
 [11] 卢树峰, 李志新, 黄奇峰, 等. 新型信号处理方法 VMD 在电能计量故障识别中的应用 [J]. 电测与仪表, 2020, 57 (10): 76-80.
 [12] 魏传芝, 施啸寒, 张恒旭, 等. 考虑电流指令跟踪能力的 PQ 控制逆变型分布式电源故障模型 [J]. 电力自动化设备, 2020, 40 (1): 59-65.
 [13] 吴肖龙, 许元武, 胡荣, 等. 两种固体氧化物燃料电池系统的故障建模与仿真对比研究 [J]. 控制理论与应用, 2019, 36 (3): 408-419.
 [14] 李卫国, 焦盘龙, 刘新宇, 等. 基于变分模态分解的储能辅助传统机组调频的容量优化配置 [J]. 电力系统保护与控制, 2020, 48 (6): 49-58.
 [15] 施杰, 伍星, 柳小勤, 等. 变分模态分解结合深度迁移学习诊断机械故障 [J]. 农业工程学报, 2020, 36 (14): 137-145.
 [16] 朱建新, 陈学东, 吕宝林, 等. 基于多维高斯贝叶斯的机械设备失效/故障智能诊断及参数影响分析 [J]. 机械工程学报, 2020, 56 (4): 51-57.
 [17] 赵鑫, 蔡琦, 张黎明, 等. 基于迭代退火算法优化的 SVR 在核动力装置故障诊断中的应用 [J]. 海军工程大学学报, 2020, 32 (1): 74-79.
 [18] 齐咏生, 樊估, 李永亭, 等. 一种改进的解卷积算法及其在滚动轴承复合故障诊断中的应用 [J]. 振动与冲击, 2020, 39 (21): 147-157.
 [19] 代丽丽. 一类具退化强化的椭圆方程熵解的存在性 [J]. 华东师范大学学报 (自然科学版), 2019, 2019 (4): 52-61.
 [20] 宿文才, 张树团, 刘陵顺. 基于改进极值波延拓的极点对称模态分解端点效应抑制方法 [J]. 电工技术学报, 2020, 35 (S1): 300-307.