

DOI: 10.19650/j.cnki.cjsi.J2614931

基于混合噪声模型与极大似然比的滚动轴承 状态监测与故障诊断方法*

侯少锋¹, 张醴尹¹, 樊 薇^{1,2}, 陈 超¹, 韩丽玲¹

(1. 江苏大学机械工程学院 镇江 212013; 2. 中国矿业大学煤炭精细勘探与智能开发全国重点实验室 徐州 221116)

摘 要:针对滚动轴承在复杂噪声环境中早期故障特征信号微弱、状态监测与故障诊断环节相互割裂等问题,提出一种基于混合噪声模型与极大似然比(MLR)的滚动轴承状态监测与故障诊断一体化方法。首先,构建混合噪声的统计模型,利用期望最大化(EM)算法对健康状态下采集的振动信号进行参数估计与模型拟合,建立该状态下的模型作为健康基准;其次,构建极大似然比指标来量化监测信号与健康基准信号之间的概率分布差异,利用指数加权移动平均(EWMA)控制图处理健康监测指标序列,在保留故障特征的同时,可放大轴承的退化趋势。最后,通过复用频带 MLR 评价指标,对小波包分解后的子频带进行筛选,提取最优故障敏感频带,进而对该频带信号进行包络谱分析实现故障诊断。通过两组公开数据集上的实验和与其他方法的对比分析,在 IMS 数据集中,MLR 指标较注意力 Lempel-Ziv 复杂度早 2.048 s 监测到早期故障的发生,并分析出 230 Hz 的外圈故障特征频率,与理论故障特征频率(235 Hz)仅存在约 2.1% 的相对误差;在 XJTU-SY 轴承数据集中,MLR 指标较有效加权稀疏峰值提前 1.28 s 监测到故障,并分析得到 108 和 175 Hz 两种故障特征,与理论外圈故障特征频率(107 Hz)和内圈故障特征频率(172 Hz)分别存在 1.4% 和 1.7% 的相对误差,验证了所提方法的及时性与准确性。

关键词: 故障诊断;混合噪声模型;极大似然比;EWMA 控制图;状态监测

中图分类号: TH133.3 **文献标识码:** A **国家标准学科分类代码:** 460.35

A rolling bearing condition monitoring and fault diagnosis method based on a mixture noise model and maximum likelihood ratio

Hou Shaofeng¹, Zhang Liyin¹, Fan Wei^{1,2}, Chen Chao¹, Han Liling¹

(1. School of Mechanical Engineering, Jiangsu University, Zhenjiang 212013, China; 2. The State Key Laboratory for Fine Exploration and Intelligent Development of Coal Resources, China University of Mining and Technology, Xuzhou 221116, China)

Abstract: In response to challenges such as weak early fault characteristic signals in rolling bearings under complex noise environments and the disconnection between condition monitoring and fault diagnosis, this paper proposes an integrated method for condition monitoring and fault diagnosis of rolling bearings based on a hybrid noise model and the maximum likelihood ratio (MLR). First, a statistical model of hybrid noise is constructed, and the expectation-maximization (EM) algorithm is used to estimate parameters and fit the vibration signals collected under healthy conditions, establishing this model as the health baseline; Next, the MLR index is constructed to quantify the probability distribution differences between the monitored signals and the health reference signals. On this basis, the exponential weighted moving average (EWMA) control chart is employed to process the sequence of health monitoring indicators, thereby amplifying the bearing's degradation trend whilst retaining fault features. Finally, by reusing the band MLR evaluation index, the sub-bands after wavelet packet decomposition are screened to extract the optimal fault-sensitive frequency band. Subsequently, envelope spectrum analysis is performed on the signals of this frequency band to achieve fault diagnosis. Through experiments on two public datasets and comparative analysis with other methods, on the IMS dataset, the MLR index detects early faults 2.048 seconds earlier than the attention Lempel-Ziv complexity method and identifies an outer race fault characteristic frequency of 230 Hz. This result shows only about a 2.1% relative error compared to the theoretical fault characteristic frequency (235 Hz). On the XJTU-SY bearing dataset, the MLR index

收稿日期: 2026-02-04 Received Date: 2026-02-04

* 基金项目: 煤炭精细勘探与智能开发全国重点实验室开放研究课题项目 (SKLCRSM24KF009) 资助

detects faults 1.28 seconds earlier than the effective weighted sparse kurtosis method and identifies two fault characteristics at 108 Hz and 175 Hz. These correspond to the theoretical outer race fault characteristic frequency (107 Hz) and inner race fault characteristic frequency (172 Hz), with relative errors of 1.4% and 1.7%, respectively. These results verify the timeliness and accuracy of the proposed method for integrated condition monitoring and fault diagnosis of rolling bearings.

Keywords: fault diagnosis; mixed noise model; maximum likelihood ratio; EWMA control chart; condition monitoring

0 引言

滚动轴承作为旋转机械的核心支撑部件,广泛应用于风电机组、高速列车轴箱以及航空发动机等装备,其运行状态决定着系统的安全性与可靠性^[1-3]。在复杂的工业环境中,早期故障信号通常微弱且非平稳,极易被背景噪声、谐波成分等淹没^[4-5]。若未能及时开展状态监测与故障诊断,可能导致生产中设备突然停止工作从而引起一系列的事故^[6]。因此,开展复杂噪声条件下滚动轴承的健康管理研究具有重要意义。

轴承健康管理包含信号预处理、特征提取、状态监测、故障诊断等环节。信号预处理是轴承状态监测及故障诊断策略中的重点,其核心目的是增强故障特征与噪声干扰成分的可分离性^[7]。现有的方法在信号分析时通常认为噪声为高斯分布,往往忽略了复杂噪声分布在实际生产中的干扰。如刘小峰等^[6]采用共振稀疏分解(resonance sparse decomposition, RSD)对信号中的高、低频振动成分进行分离,从而获得其中的冲击成分,但其中的品质因子往往依赖经验或单一策略,复杂噪声干扰下易出现共振频带误判;刘方等^[8]基于 Laplace 小波的瞬态匹配方法虽能适应多普勒畸变等确定性干扰,但未对非高斯、复杂噪声情况进行统计建模分析,在非高斯噪声背景下的表现能力较差;针对非高斯条件下信号建模的问题, Wang 等^[9]提出了用广义交互多模型卡尔曼滤波算法(interacting multiple model Kalman filtering algorithm, GIMM-KF),通过多模型的联合来适配非高斯分布,其非高斯分布建模思想为机械故障诊断中的复杂噪声处理提供了新思路。

健康指标构建方面,早期故障的有效捕捉需依托能够表征信号微弱变化的特征指标^[10]。针对故障的周期性、脉冲性,刘小峰等^[11]提出的循环脉冲指数(cyclic pulse index, CPI)通过峰值矩变异系数进行综合度量,然而该方法对噪声分布变化的适应性有限,复杂噪声下鲁棒性不足;张焱等^[12]基于包络信号与同步压缩小波变换的参考转频量化方法,通过模型重构与广义解调提取时变频率脊线故障特征,但依赖频率脊线精准估计,非高斯、多成分叠加噪声下易因脊线提取偏差降低特征表征效果。罗鹏等^[13]提出了改进相空间曲变法(improved phase space warping, IPSW),其基于相空间重构,利用综

合互信息熵最大化准则优化了重构参数,结合模态分量与工况相关性分析构建健康指标,平稳噪声下特征表征效果良好,但未考虑复杂噪声干扰导致的早期故障灵敏度衰减问题。综上,现有指标多侧重某一类特征强化,对复杂噪声环境下的鲁棒性与早期故障的敏感性不足。

为了更好地实现状态监测与故障诊断,许多研究致力于构建高敏感性和高鲁棒性的监测与诊断模型^[14]。如 Han 等^[15]提出的自适应最大广义高斯循环平稳盲解卷积(adaptive maximum generalized Gaussian cyclostationarity blind deconvolution, ACYCBD _{ρ}),通过增强包络谐波能量显著性谱实现了非高斯噪声下故障频率的准确估计,以此来进行故障诊断,但监测与诊断的流程较为割裂。为提高轴承健康管理的效率,一些研究集成化监测及诊断流程,如 Fan 等^[16]提出了增强抗噪声相关(reinforced noise resistant correlation, RE-NRC)方法,该方法在 NRC 的基础上通过添加系数补偿构建了一个新的相关函数,而基于该相关函数构建的健康指标在早期退化阶段可以敏感地监测到异常变化,同时从当前监测数据的 RE-NRC 曲线中能分析出故障成分,从而实现状态监测及故障诊断的一体化,但同样的,该方法仅建立在白噪声背景下,缺少对复杂噪声条件的考虑^[17-18]。

综上,现有研究主要存在3个方面问题:1)健康基准建模多采用单一噪声假设,难以适配工业场景中多类型噪声干扰共存的复杂环境;2)状态监测指标依赖单一特征或统计量,对早期故障敏感性有限;3)监测与诊断过程孤立,二者之间缺乏联系。

针对上述3个层面存在的问题,本文提出一种基于高斯-拉普拉斯混合噪声模型与极大似然比的轴承状态监测及故障诊断方法,首先,建立混合噪声模型,并通过期望最大化(expectation-maximization, EM)算法对正常运行状态下的数据进行拟合从而得到健康基准模型;其次,基于监测数据与健康基准模型之间分布的变化来构建极大似然比检测指标,捕捉早期故障信号变化,并结合指数加权移动平均(exponentially weighted moving average, EWMA)控制图来监测恶化程度不断增大的故障;最后,对故障点信号用小波包分解划分频带,并复用极大似然比指标筛选最优故障频带,利用包络谱分析提取特征频率,实现精准诊断。

1 理论分析

1.1 基于高斯-拉普拉斯混合噪声模型的建立

1) 混合噪声模型的概率建模

传统故障检测方法多假设噪声服从高斯分布,然而仅用高斯分布难以刻画实际振动信号中常见的尖峰厚尾与脉冲干扰特性,为此,本文采用高斯-拉普拉斯混合噪声模型建模,其概率密度函数如式(1)所示。

$$p(x|\theta) = w_g \cdot N(x|\mu_g, \sigma_g) + w_l \cdot L(x|\mu_l, b_l) \quad (1)$$

式中: $\theta = (w_g, w_l, \mu_g, \mu_l, \sigma_g, b_l)$ 为模型参数, w_g, w_l 分别为高斯和拉普拉斯分量的权重 ($w_g + w_l = 1$); $N(x|\mu_g, \sigma_g)$ 为高斯分布概率密度函数; $N(x|\mu_g, \sigma_g) =$

$$\frac{1}{\sqrt{2\pi}\sigma_g} \exp\left(-\frac{(x-\mu_g)^2}{2\sigma_g^2}\right); L(x|\mu_l, b_l) \text{ 为拉普拉斯分布}$$

$$\text{概率密度函数, } L(x|\mu_l, b_l) = \frac{1}{2b_l} \exp\left(-\frac{|x-\mu_l|}{b_l}\right)。$$

该模型通过高斯分布表征平稳背景噪声,通过拉普拉斯分布刻画冲击性噪声的尖峰重尾特性,从而更能刻画实际振动信号的统计分布。

2) 混合模型参数集合 θ_0 的估计

对于健康数据 $X = \{x_1, x_2, \dots, x_N\}$, 采用 EM 算法估计健康条件下模型参数 θ_0 。参数的初始化策略为:

高斯分量参数:以样本均值和标准差作为 μ_g 和 σ_g 的初始值;

拉普拉斯分量参数:以样本中位数作为 μ_l 的初始值,以平均绝对偏差作为 b_l 的初始值;

权重参数: $w_g = w_l = 0.5$ 。

EM 算法采用 E 步(期望步)和 M 步(最大化步)更替迭代的方式实现参数的估计。

E 步:计算样本数据对应于不同噪声成分的概率。

对于第 i 个样本 x_i , 其属于各分量的后验概率如式(2)和(3)所示。

$$\gamma_g^{(i)} = \frac{w_g N(x_i|\mu_g, \sigma_g)}{w_g N(x_i|\mu_g, \sigma_g) + w_l L(x_i|\mu_l, b_l)} \quad (2)$$

$$\gamma_l^{(i)} = \frac{w_l L(x_i|\mu_l, b_l)}{w_g N(x_i|\mu_g, \sigma_g) + w_l L(x_i|\mu_l, b_l)} \quad (3)$$

式中: $\gamma_g^{(i)}$ 和 $\gamma_l^{(i)}$ 称为责任值,反映了当前样本属于各分量的接近程度。

M 步:基于责任值更新模型参数。

(1) 更新后的权重参数如式(4)和(5)所示。

$$w_g^{(t+1)} = \frac{1}{N} \sum_{i=1}^N \gamma_g^{(i)} \quad (4)$$

$$w_l^{(t+1)} = \frac{1}{N} \sum_{i=1}^N \gamma_l^{(i)} \quad (5)$$

(2) 更新后高斯分布参数如式(6)和(7)所示。

$$\mu_g^{(t+1)} = \frac{\sum_{i=1}^N \gamma_g^{(i)} x_i}{\sum_{i=1}^N \gamma_g^{(i)}} \quad (6)$$

$$(\sigma_g^{(t+1)})^2 = \frac{\sum_{i=1}^N \gamma_g^{(i)} (x_i - \mu_g^{(t+1)})^2}{\sum_{i=1}^N \gamma_g^{(i)}} \quad (7)$$

(3) 更新后拉普拉斯分布参数如式(8)和(9)所示。

$$\mu_l^{(t+1)} = \text{加权中位数}\{x_i, \gamma_l^{(i)}\} \quad (8)$$

$$b_l^{(t+1)} = \frac{\sum_{i=1}^N \gamma_l^{(i)} |x_i - \mu_l^{(t+1)}|}{\sum_{i=1}^N \gamma_l^{(i)}} \quad (9)$$

EM 算法循环 E 步和 M 步,最终得到健康条件下混合噪声模型的参数估计结果。

1.2 基于混合噪声模型的指标设计

似然比检验通过比较两类假设模型对观测数据的拟合程度构造统计量。设有两个参数化概率模型 M_0 和 M_1 , 对应的参数空间分别为 θ_0 和 θ_1 。对于观测数据 $X = \{x_1, x_2, \dots, x_N\}$, 似然比统计量如式(10)所示。

$$\Lambda(X) = \frac{\sup_{\theta \in \theta_0} L(\theta|X)}{\sup_{\theta \in \theta_1} L(\theta|X)} \quad (10)$$

式中: $L(\theta|X)$ 是似然函数。当 $\Lambda(X)$ 超过某个阈值时,拒绝零假设 M_0 。

早期故障会导致信号的统计特性偏离健康状态,基于健康基准模型的似然比指标可捕捉分布上的微小偏离,实现早期故障检测。本文将监测问题表述为:

H_0 : 数据来自健康基准混合模型 θ_0 。

H_1 : 数据来自不同于 θ_0 的混合模型 θ_1 。

对于当前监测数据段 X_t (包含 N 个样本), 似然比统计量的构造步骤为:

1) 计算基准模型的对数似然,如式(11)所示。

$$\log L_0 = \log L(\theta_0|X) = \sum_{i=1}^N \log p(x_i|\theta_0) \quad (11)$$

式中: $p(x_i|\theta_0)$ 是基准混合模型的概率密度函数。

2) 对当前数据进行模型拟合并计算对数似然。EM 算法估计参数 $\hat{\theta}_t$, 如式(12)所示。

$$\log L_t = \log L(\hat{\theta}_t|X_t) = \sum_{i=1}^N \log p(x_i|\hat{\theta}_t) \quad (12)$$

式中: $p(x_i|\hat{\theta}_t)$ 是当前数据的概率密度函数。

3) 构造似然比统计量。采用对数形式,避免数值下溢,如式(13)所示。

$$LR_t = -2(\log L_0 - \log L_t) \quad (13)$$

该指标衡量了当前数据段相对于健康基准的偏离程度,相较于传统指标, LR_t 基于整个概率密度函数,对分

布的整体性变化较为敏感。当 LR_t 接近 0 时,说明当前数据的统计分布特性与健康基准高度一致,设备处于正常状态;当 LR_t 显著大于 0 时,意味着当前数据的统计分布已经偏离了健康基准,设备出现了异常。

1.3 结合 EWMA 控制图的早期监测策略

1) EWMA 统计量

EWMA 控制图是用来检测运行过程中小偏移量的统计过程控制工具。其核心思想是通过指数加权方式融合历史信息,赋予近期数据更高权重,同时保留一定的历史记忆。

递推公式的统计推导:

设 $\{LR_t, t = 1, 2, \dots\}$ 为独立的似然比统计量序列。EWMA 统计量的表达式如式 (14) 所示。

$$Z_t = \lambda \times LR_t + (1 - \lambda) \times Z_{t-1}, t = 1, 2, \dots \quad (14)$$

式中: λ 为平滑常数; Z_0 通常初始化为目标值均值。

将式 (14) 展开,得到结果如式 (15) 所示。

$$Z_t = \lambda \sum_{i=0}^{t-1} (1 - \lambda)^i LR_{t-i} + (1 - \lambda)^t Z_0 \quad (15)$$

这表明 Z_t 是历史 LR 值的指数加权平均。

2) 基于蒙特卡洛模拟的控制限自适应确定

受控时,控制限的计算如式 (16) 和 (17) 所示。

$$UCL_t = \mu_0 + L\sigma_0 \sqrt{\frac{\lambda}{2 - \lambda} [1 - (1 - \lambda)^{2t}]} \quad (16)$$

$$LCL_t = \mu_0 - L\sigma_0 \sqrt{\frac{\lambda}{2 - \lambda} [1 - (1 - \lambda)^{2t}]} \quad (17)$$

式中: L 为控制限的系数; μ_0 与 σ_0 分别为受控状态下 EWMA 统计量的均值与标准差。

考虑到混合噪声条件下 LR_t 的分布难以满足经典控制图假设,本文基于健康基准模型 θ_0 采用蒙特卡洛模拟来确定控制限。如式 (18) 所示,从 $p(\cdot | \theta_0)$ 生成 M 组独立数据(每组包含 N 个样本):

$$X^{(m)} \sim p(\cdot | \theta_0), m = 1, \dots, M \quad (18)$$

如式 (19) 所示,对第 m 组数据计算似然比:

$$LR^{(m)} = -2[\log L(\theta_0 | X^{(m)}) - \log L(\hat{\theta}^{(m)} | X^{(m)})] \quad (19)$$

式中: $\hat{\theta}^{(m)}$ 是第 m 组数据的 MLE。

取 $\{LR^{(m)}\}$ 的 $1 - \alpha$ 分位数为控制限,如式 (20) 所示。

$$UCL_{LR} = \hat{Q}_{1-\alpha}(\{LR^{(m)}\}_{m=1}^M) \quad (20)$$

当 $Z_t > UCL_{LR}$ 时,判定检测到早期异常并触发报警。

1.4 基于小波包分解与似然比复用的故障诊断方法

当 $Z_t > UCL_{LR}$ 时,对信号采用小波包分解,并用统一的似然比统计量来度量信号统计分布相对健康基准的偏离程度。具体而言,时域监测阶段以 LR_t 表征当前数据段与健康基准的分布差异;故障诊断阶段在各频带上构

造 LR_b , 以量化频带系数分布相对健康频带基准的偏离程度,从而筛选故障敏感频带。对得到的频带进行包络谱分析来实现故障类型的辨别。

1) 小波包频带划分

设故障信号为 $x(t)$, 小波包基函数由尺度函数 $\phi(t)$ 和小波函数 $\psi(t)$ 生成,如式 (21) 和 (22) 所示。

$$\phi(t) = \sqrt{2} \sum_{k \in Z} h(k) \phi(2t - k) \quad (21)$$

$$\psi(t) = \sqrt{2} \sum_{k \in Z} g(k) \phi(2t - k) \quad (22)$$

式中: $h(k)$ 和 $g(k)$ 为低通滤波器和高通滤波器的系数。

设第 j 层小波包分解的第 n 个频带分量为 $W_{j,n}(t)$ ($j \geq 0, n = 0, 1, \dots, 2^j - 1$), 则分解递推关系如式 (23) 和 (24) 所示。

$$W_{j+1,2n}(t) = \sum_{k \in Z} h(k) W_{j,n}(2t - k) \quad (23)$$

$$W_{j+1,2n+1}(t) = \sum_{k \in Z} g(k) W_{j,n}(2t - k) \quad (24)$$

式中: $W_{j+1,2n}(t)$ 与 $W_{j+1,2n+1}(t)$ 为低、高通分解分量。

2) 基于频带似然比的最优故障特征频带筛选

为量化不同频带在故障前后的统计分布变化,本文对每个频带分别建立高斯-拉普拉斯混合模型,并计算该频带相对健康基准的似然比统计量。

对于健康信号在第 b 个频带上的系数为 $C_{h,b} = \{C_{h,1}, \dots, C_{h,n}\}$, 对其拟合混合模型,如式 (25) 所示,得到健康基准参数 $\theta_{h,b}$ 。

$$p_b(c | \theta_{h,b}) = w_{g,b} N(c | \mu_{g,b}, \sigma_{g,b}) + w_{l,b} L(c | \mu_{l,b}, b_{l,b}) \quad (25)$$

同理,故障信号在第 b 个频带上的系数为 $C_{f,b}$, 拟合混合模型得到 $\theta_{f,b}$ 。

如式 (26) 所示,计算第 b 个频带的似然比指标:

$$LR_b = -2[\log L(\theta_{h,b} | C_{h,b}) - \log L(\theta_{f,b} | C_{f,b})] \quad (26)$$

式中: $\log L(\theta | C) = \sum_{i=1}^{N_b} \log p(c_i | \theta)$ 。

LR_b 越大,表明故障导致该频带分布偏离健康基准的程度越高。

3) 基于包络谱的故障特征频率提取与识别

对故障频带用希尔伯特包络解调提取包络信号,并通过包络谱分析可获得故障频率。对信号 $x_b(t)$, 其希尔伯特变换如式 (27) 所示。

$$H[x_b(t)] = \frac{1}{\pi} P.V. \int_{-\infty}^{\infty} \frac{x_b(\tau)}{t - \tau} d\tau \quad (27)$$

式中: $P.V.$ 表示柯西主值。如式 (28) 所示,由原信号与正交信号构建解析信号:

$$z_b(t) = x_b(t) + jH[x_b(t)] \quad (28)$$

其幅值为包络信号,如式 (29) 所示。

$$e_b(t) = |z_b(t)| = \sqrt{x_b^2(t) + H^2[x_b(t)]} \quad (29)$$

对 $e_b(t)$ 频谱分析可得到故障特征频率等成分。
所提方法流程图如图 1 所示。




图 1 所提方法流程
Fig. 1 Flowchart of the proposed method

2 实验验证

2.1 仿真实验分析

1) 轴承故障信号数学模型

轴承局部缺陷引起的周期性冲击可建模为脉冲响应。设系统固有频率为 f_n , 阻尼比为 ζ , 则单位冲击响应函数如式 (30) 所示。

$$h(t) = A \cdot e^{-\zeta\omega_n t} \cdot \sin(\omega_d t) \cdot u(t) \tag{30}$$

式中: $\omega_n = 2\pi f_n$ 为固有角频率; $\omega_d = \omega_n \times \sqrt{1 - \zeta^2}$ 为阻尼固有角频率; A 为幅值; $u(t)$ 为单位阶跃函数。

外圈故障信号如式 (31) 所示。

$$x_{\text{outer}}(t) = \sum_{k=0}^{K-1} A_0 \cdot h(t - kT_{\text{BPFO}}) \tag{31}$$

式中: $T_{\text{BPFO}} = \frac{1}{f_{\text{BPFO}}}$; A_0 为幅值。内圈故障信号如式 (32) 所示。

$$x_{\text{inner}}(t) = \sum_{k=0}^{K-1} [1 + m\cos(2\pi f_r t_k)] \cdot h(t - kT_{\text{BPFI}}) \tag{32}$$

式中: $T_{\text{BPFI}} = \frac{1}{f_{\text{BPFI}}}$; f_r 为轴转频; m 为调制深度。

仿真参数设置如表 1 所示。

2) 全寿命周期仿真实验设计

本文采用高斯-拉普拉斯混合噪声模型进行仿真实验分析, 如式 (33) 所示。

$$n_{\text{mix}}(t) = n_g(t) + n_l(t) \tag{33}$$

式中: $n_g(t)$ 为高斯噪声分量, 均值为 0, 标准差为 0.1; $n_l(t)$ 为拉普拉斯噪声分量, 均值为 0, 尺度参数为 0.1。

表 1 仿真信号参数
Table 1 Simulated signal parameters

参数类别	符号	数值	说明
采样参数	f_s	5 000 Hz	采样频率
	T	2 s	单信号时长
	N	10 000	单信号点数
轴承参数	f_r	30 Hz	轴转频
	f_{BPFO}	100 Hz	外圈故障特征频率
	f_{BPFI}	150 Hz	内圈故障特征频率
	f_n	3 000 Hz	系统固有频率
	ζ	0.05	阻尼比

为模拟轴承全寿命过程, 设计仿真数据集:

(1) 健康阶段 (样本 1~200): 仅含混合噪声, 模拟正常运行状态, 健康阶段的第 i 个样本如式 (34) 所示。

$$X_i^{\text{healthy}}[n] = n_g[n] + n_l[n], n = 0, \dots, N - 1 \tag{34}$$

(2) 故障发展阶段 (样本 201~400): 故障信号逐渐增强, 故障发展阶段的第 i 个样本如式 (35) 所示。

$$X_i^{\text{fault}}[n] = \alpha_i \times x_{\text{fault}}[n] + n_g[n] + n_l[n] \tag{35}$$

式中: $\alpha_i = \frac{i - 200}{200/3}$ 为故障增长函数。

3) 单故障仿真实验

在故障阶段叠加持续增强的内圈故障信号 $X_i^{\text{inner}}[n]$, 基于健康阶段部分样本构建基准健康模型, 并对后续样本逐段计算似然比统计量 LR_i , 再经 EWMA 统计量 Z_i 实现状态监测。结果如图 2 所示。




图 2 单故障数据状态监测结果
Fig. 2 Single-fault data status monitoring results

由图 2 可见, 控制图在第 201 个样本处触发报警, 且统计量持续上升, 表明信号分布偏离健康基准, 判定故障进入发展阶段。对该样本进行小波包分解, 计算各频带似然比统计量 LR_b , 结果如图 3 所示。




图3 频带似然比统计量

Fig. 3 Band-limited likelihood ratio statistic

图3显示,第3层分解的第3个频带(B3)对应的 LR_b 最大,说明B3内含有更多的故障信息。对B3信号进一步分析,如图4所示。




图4 最优频带包络谱分析

Fig. 4 Optimal frequency band envelope spectrum analysis

可以看出,在151.5 Hz处,信号的频谱图中出现最大值,与内圈的故障特征频率 $f_{BPF1} = 150$ Hz接近,说明频带似然比筛选可定位故障敏感频带,并与包络谱特征频率识别形成诊断证据链。判定该样本处发生内圈局部损伤。

4) 复合故障实验

在单故障的基础上叠加外圈故障信号 $x_{outer}(t)$,并保持相同的健康基准建模方式。监测结果如图5所示。




图5 复合故障数据状态监测结果

Fig. 5 Composite fault data status monitoring results

由图5中的监测结果可以看出,在第201个样本处控制图同样触发报警,且统计量上升更为陡峭。对该处进行小波包分解并计算各频带 LR_b ,结果如图6所示。




图6 频带似然比统计量

Fig. 6 Band-limited likelihood ratio statistic

图6显示,第3层分解的第3个频带(B3)对应的 LR_b 最大。对B3进行分析,结果如图7所示。




图7 最优频带包络谱分析

Fig. 7 Optimal frequency band envelope spectrum analysis

由图7可知,频谱中出现了100和151.5 Hz两个显著峰值,分别对应外圈故障特征频率(100 Hz)与内圈故障特征频率(150 Hz)。该结果验证了构建的似然比指标所选频带对复合故障特征的敏感性与有效性。

2.2 实际数据分析及方法对比

1) 案例1

本节采用辛辛那提大学智能维护系统中心(IMS)的加速轴承寿命测试台公开数据集(访问地址: <https://ti.arc.nasa.gov/tech/dash/groups/pcoe/prognostic-data-repository/>)进行验证,并与注意力 Lempel-Ziv 复杂度^[19]和有效加权稀疏峰值^[20]对比。试验台如图8所示,配备4个恒速驱动的轴承,负载6 000磅。采样频率为20 kHz;每条记录包含20 480点(≈ 1.024 s),每10 min采集1次,本文选取轴承1的984段连续数据,最终发生外圈故障。

3种方法的监测结果如图9所示,其中,使用第1~200段健康数据建立健康基准模型,基准混合模型参数估计为:高斯分量权重 $w_g = 0.6572$ 、均值 $\mu_g = -0.0035$ 、




图 8 IMS 数据试验台

Fig. 8 IMS data testing platform

标准差 $\sigma_g = 0.075\ 0$; 拉普拉斯分量位置 $\mu_l = -0.002\ 0$ 、尺度 $b_l = 0.065\ 0$ 。




图 9 3 种健康指标的监测结果

Fig. 9 Monitoring results of three health indicators

基于该模型进行 $M = 1\ 000$ 次蒙特卡洛模拟来计算控制限。显著性水平取 $\alpha = 0.002\ 7$ (对应正态分布约 $\pm 3\sigma$ 的尾部概率)，上控制限定义为： $UCL_{LR} = \hat{Q}_{1-\alpha}(\{LR^{(m)}\}_{m=1}^M)$ 。本文实验中得到 $UCL_{LR} = 19.172\ 466$ 。

根据监测结果可知，在图 9(a) 中，所提方法的运行轨迹在健康阶段保持稳定，随后在第 534 个样本点超过控制限并持续上升，显示出理想的早期且持续的故障退化特征。在图 9(b) (注意力 Lempel-Ziv 复杂度) 中，第 536 个样本点处统计量突破上控制限 (upper control limit, UCL)。该曲线同样体现出故障不断恶化的趋势。这是由于注意力 Lempel-Ziv 复杂度是计算信号的符号复杂度来表征故障引起的整体变化。而故障的持续冲击使局部序列复杂度维持上升，虽然指标可表征上升趋势，但指标对早期微弱分布变化的捕捉灵敏度低于基于整体概率分布的极大似然比 (maximum likelihood ratio, MLR) 指标。而在图 9(c) (有效加权稀疏峰度) 中，UCL 在第 654 个样本点被突破，该指标的特征表征维度单一，无法适配复杂混合噪声下轴承早期故障信号的统计分布整体性变化特征。

对第 534 段数据进行小波包分解，并计算各频带的频带似然比统计量 LR_b ，结果如图 10 所示。




图 10 频带似然比统计量

Fig. 10 Band-limited likelihood ratio statistic

由图 10 可见，第 3 层分解的第 5 个频带 (B5) 对应的 LR_b 最大，对 B5 进行分析，结果如图 11 所示。




图 11 最优频带包络谱分析

Fig. 11 Optimal frequency band envelope spectrum analysis

在第5个子频带的包络谱分析中,观测到显著的谱峰位于230 Hz左右及其谐波处。该频率与理论的外圈故障特征频率(235 Hz)仅存在约2.1%的相对误差,可确认该频率对应外圈故障特征频率。

2) 案例2

为验证复合故障场景下的性能,用XJTU-SY轴承数据集^[21]进行实验分析。试验台如图12所示,由数字

式力显示器、加速度传感器与测试轴承等组成。在3种工况下测试5个轴承,安装在轴承座上的加速度计采集得到轴承的信号。每分钟记录一次数据,每段包含32 768点(1.28 s),采样频率为25.6 kHz。本文选取轴承1_5的52段数据;实验结束时其外圈(理论特征频率)与内圈(理论特征频率172 Hz)均发生故障。





图12 XJTU-SY 数据试验台
Fig. 12 XJTU-SY data testing platform


本文方法使用第1~10段健康数据建立健康基准模型,基准混合模型参数估计为:高斯噪声分量权重 $w_g = 0.747\ 9$ 、均值 $\mu_g = -0.000\ 6$ 、标准差 $\sigma_g = 0.969\ 1$;拉普拉斯噪声分量位置 $\mu_l = -0.035\ 3$ 、尺度 $b_l = 0.605\ 5$ 。

对后续样本计算似然比统计量并监测,同样与案例1中两种方法进行对比,结果如图13所示。

由图13(a)可知,控制图在第35段触发报警,并呈现良好地持续退化趋势,这是由于MLR指标是基于高斯-拉普拉斯混合噪声模型,通过监测信号与健康基准间的对数似然比来捕捉信号概率密度函数的整体性变化,




(b) 注意力Lempel - Ziv复杂度
(b) Attention Lempel-Ziv complexity



(c) 有效加权稀疏峰度
(c) Effective weighted sparseness kurtosis

图13 3种健康指标的监测结果

Fig. 13 Monitoring results of three health indicators



(a) 所提出方法
(a) The proposed method

从而能够更加灵敏地识别到混合噪声下早期故障引发的微弱的统计分布偏离,以此来实现持续性的退化表征状态。而在图 13(b)中,注意力 Lempel-Ziv 复杂度指标虽在第 34 段触发报警,但很快又落回控制限中,这是因为注意力 Lempel-Ziv 复杂度仅能捕捉故障冲击带来的局部特征变化,而非振动信号的全局统计分布偏离。因此在早期故障突发时,故障的冲击虽能短暂提升信号复杂度,使其突破控制限,但轴承早期故障的微弱冲击信号易被高斯-拉普拉斯混合噪声所掩盖,从而使复杂度指标快速回归正常区间;有效加权稀疏峰值指标为单一统计量,对混合噪声下的分布变化适应性有限,因此在图 13(c)中对早期微弱分布变化的捕捉灵敏度低于基于整体概率分布的 MLR 指标。

对第 35 段进行小波包分解并计算各频带的 LR_b , 结果如图 14 所示。




图 14 频带似然比统计量

Fig. 14 Band-limited likelihood ratio statistic

由图 14 可见,第 3 层分解的第 8 个频带(B8)对应的 LR_b 最大。对 B8 进行分析,如图 15 所示。




图 15 最优频带包络谱分析

Fig. 15 Optimal frequency band envelope spectrum analysis

在 B8 的包络谱中可观测到外圈故障特征频率约 108 Hz(与理论 107 Hz 相对误差为 1.4%)以及内圈故障特征频率约 175 Hz(与理论 172 Hz 相对误差为 1.7%)。该结果表明外圈与内圈故障特征同时出现,验证了本文

方法在复合故障条件下的频带定位能力与诊断有效性。

2.3 计算效率分析

在计算控制限时,本文蒙特卡洛模拟的耗时与模拟次数 M 、样本大小 N 强相关,在硬件环境(12th Gen Intel(R) Core(TM) i9-12900K (3.20 GHz), 64 G 内存, MATLAB R2022b 平台)下,对两个案例及仿真实验中的蒙特卡洛模拟过程进行记录,得到的具体情况如表 2 所示。

表 2 蒙特卡洛模拟耗时

Table 2 Monte Carlo simulation time

数据集	样本大小 N	模拟次数 M	耗时/min
IMS	20 480	500	0.983
IMS	20 480	1 000	1.933
XJTU-SY	32 768	500	1.542
XJTU-SY	32 768	1 000	3.033
仿真实验	10 000	1 000	1.283

表中结果为 5 次重复实验取均值的结果,可以看出蒙特卡洛模拟过程耗时很短,可快速完成健康基准与控制图参数配置;而在线监测阶段无需模拟过程,仅需完成单次 LR_i 计算与 EWMA 统计量更新。以实验中用到的案例进行分析,IMS 数据集中采样频率为 20 kHz,数据段长度为 20 480 点,采集的数据段时长为 1.024 s,而对于单个样本点的监测计算耗时约为 0.05 s,处理速度与采集速度比为 1.024/0.05 $\approx$ 20 倍,所提方法的处理速度要远高于数据采集速度,具备实时在线监测的能力。

3 结 论

本文提出了一种基于混合噪声模型与极大似然比的滚动轴承状态监测与故障诊断方法,针对当前研究普遍采用单一噪声假设的问题,构建了高斯-拉普拉斯混合噪声模型;并针对故障信号与健康信号在统计分布上的差异性构建了可监测也可定位故障频带的极大似然比健康指标,将监测与诊断过程联系起来。两组轴承全寿命对比实验验证表明,所提方法可更早地监测到早期故障的发生并实现故障诊断。在 IMS 数据集中,所提方法较注意力 Lempel-Ziv 复杂度方法早 2.048 s 监测到故障的发生,并分析出 230 Hz 的外圈故障特征频率,与理论故障特征频率(235 Hz)仅存在约 2.1%的相对误差;在 XJTU-SY 轴承数据集中,所提方法较有效加权稀疏峰值提前 1.28 s 监测到故障,并分析得到 108 和 175 Hz 两种故障特征,与理论外圈故障特征频率(107 Hz)和内圈故障特征频率(172 Hz)分别存在 1.4% 和 1.7%的相对误差,验

证了所提方法的及时性与准确性。未来研究将致力于优化混合模型的参数计算效率,在现有基础上更进一步提升似然比指标构建时的计算速度,减少因数据增长带来的计算负担,提升实时性。

参考文献

- [1] WANG H T, WANG R H, YANG J. Unsupervised domain adaptive migration learning-based approach to bearing remaining useful life prediction [J]. Instrumentation, 2025, 12(1): 37-47.
- [2] WANG H T, LIU X. Research on rotating machinery fault diagnosis based on improved multi-target domain adversarial network[J]. Instrumentation, 2024, 11(1): 38-50.
- [3] ZHOU J, WANG L D, CHEN CH H, et al. Fault diagnosis method of rolling bearing based on weighted fractional range entropy infogram[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 3390161.
- [4] LIU B, JIANG X F, WANG F R, et al. Enhanced bearing fault diagnosis under strong noise: A deep residual network with combined attention mechanisms [J]. Knowledge-Based Systems, 2025, 330: 114678.
- [5] JIA Y R, YAO D CH, YANG J W, et al. A multi-scale wavelet and spectral kurtosis-guided framework for noise-resistant rolling bearing fault diagnosis[J]. Mechanical Systems and Signal Processing, 2026, 242: 113662.
- [6] 刘小峰, 黄洪升, 柏林, 等. 循环脉冲指数最大化的共振稀疏分解法及应用[J]. 仪器仪表学报, 2022, 43(5): 209-217.
- LIU X F, HUANG H SH, BAI L, et al. A resonance sparse decomposition method based on maximizing cyclic pulse index and its application[J]. Chinese Journal of Scientific Instrument, 2022, 43(5): 209-217.
- [7] ZHANG G Y, WANG Y, QIN Y, et al. Statistical distribution measures based on amplitude normalization for wind turbine generator bearing condition monitoring under variable speed conditions[J]. Mechanical Systems and Signal Processing, 2025, 228: 112464.
- [8] 刘方, 翟涛涛, 侯超强, 等. 基于多普勒调制时移 Laplace 小波的列车轴承故障声信号瞬态成分快速提取方法[J]. 仪器仪表学报, 2022, 43(3): 40-48.
- LIU F, ZHAI T T, HOU CH Q, et al. A fast transient component extraction method of train bearing fault acoustic signal based on Doppler modulated time-shifting Laplace wavelet [J]. Chinese Journal of Scientific Instrument, 2022, 43(3): 40-48.
- [9] WANG J, HE J, PENG B, et al. Generalized interacting multiple model Kalman filtering algorithm for maneuvering target tracking under non-Gaussian noises [J]. ISA Transactions, 2024, 155: 148-163.
- [10] SUN T D, YIN CH, ZHENG H L, et al. An unsupervised framework for dynamic health indicator construction and its application in rolling bearing prognostics[J]. Reliability Engineering & System Safety, 2025, 260: 111039.
- [11] 刘小峰, 李俊锋, 毕远亮, 等. 基于最优频段循环脉冲指数谱的轴承故障诊断方法[J]. 仪器仪表学报, 2024, 45(6): 297-306.
- LIU X F, LI J F, BI Y L, et al. Bearing fault diagnosis method based on cyclic pulse index spectrum of optimal band [J]. Chinese Journal of Scientific Instrument, 2024, 45(6): 297-306.
- [12] 张焱, 何姝钊, 王平, 等. 无转速计下变工况滚动轴承故障特征量化表征提取[J]. 仪器仪表学报, 2021, 41(8): 104-114.
- ZHANG Y, HE SH B, WANG P, et al. Tacholeless quantitative characterization of rolling bearing fault feature under varying conditions[J]. Chinese Journal of Scientific Instrument, 2021, 41(8): 104-114.
- [13] 罗鹏, 胡芑庆, 程哲, 等. IPSW 方法及其在变工况滚动轴承退化状态跟踪中的应用[J]. 仪器仪表学报, 2021, 42(2): 33-44.
- LUO P, HU N Q, CHENG ZH, et al. IPSW method and its application in the state tracking of rotating bearing degradation under variable working conditions[J]. Chinese Journal of Scientific Instrument, 2021, 42(2): 33-44.
- [14] ZHANG ZH W, JIAO Z H, LI Y J, et al. Intelligent fault diagnosis of bearings driven by double-level data fusion based on multichannel sample fusion and feature fusion under time-varying speed conditions [J]. Reliability Engineering & System Safety, 2024, 251: 110362.
- [15] HAN D F, QI H Y, WANG SH X, et al. Adaptive maximum generalized Gaussian cyclostationarity blind deconvolution for the early fault diagnosis of high-speed train bearings under non-Gaussian noise [J]. Advanced Engineering Informatics, 2024, 62: 102731.
- [16] FAN W, CHEN ZH Q, LI Y X, et al. A reinforced noise

resistant correlation method for bearing condition monitoring [J]. IEEE Transactions on Automation Science and Engineering, 2023, 20(2): 995-1006.

- [17] ZHANG W, LU H, ZHANG Y Q, et al. Enabling accurate detection and localization of bearing faults under noise and vibration[J]. Applied Acoustics, 2025, 233: 110528.
- [18] DONG ZH L, JIANG Y H, JIAO W D, et al. Double attention-guided tree-inspired grade decision network: A method for bearing fault diagnosis of unbalanced samples under strong noise conditions[J]. Advanced Engineering Informatics, 2025, 64: 103004.
- [19] YIN J CH, SUI W T, ZHUANG X Y, et al. Attention Lempel-Ziv complexity: An improved Lempel-Ziv complexity with high computational efficiency for bearing early fault detection[J]. Results in Engineering, 2025, 26: 105518.
- [20] CHEN B J, CHEN X L, CHEN F F, et al. Integrated early fault diagnosis method based on direct fast iterative filtering decomposition and effective weighted sparseness kurtosis to rolling bearings[J]. Mechanical Systems and Signal Processing, 2022, 171: 108897.
- [21] 雷亚国, 韩天宇, 王彪, 等. XJTU-SY 滚动轴承加速寿命试验数据集解读[J]. 机械工程学报, 2019, 55(16): 1-6.
- LEI Y G, HAN T Y, WANG B, et al. XJTU-SY rolling element bearing accelerated life test datasets: A tutorial[J]. Journal of Mechanical Engineering, 2019, 55(16): 1-6.

作者简介



侯少锋, 2023 年于成都理工大学获得学士学位, 现在江苏大学攻读硕士学位, 主要研究方向为机械设备的状态监测及故障诊断。

E-mail: 2222303014@stmail. ujs. edu. cn

Hou Shaofeng received his B.Sc. degree from Chengdu University of Technology in 2023. He is currently pursuing his master's degree at Jiangsu University. His main research interests include condition monitoring and fault diagnosis of mechanical equipment.



张醴尹, 2025 年于江苏大学获得学士学位, 现在江苏大学攻读硕士学位, 主要研究方向为机械设备的状态监测及故障诊断。

E-mail: 2222503014@stmail. ujs. edu. cn


Zhang Liyin received her B. Sc. degree from Jiangsu University in 2025. She is currently pursuing her master's degree at Jiangsu University. Her main research interests include condition monitoring and fault diagnosis of mechanical equipment.



樊薇 (通信作者), 2012 年和 2015 年于苏州大学分别获学士和硕士学位, 2018 年于香港城市大学获博士学位。现为江苏大学机械工程学院教授。主要研究方向为信号处理和机械故障诊断。

E-mail: weifan@ ujs. edu. cn

Fan Wei (Corresponding author) received her B. Sc. degree and M. Sc. degree both from Soochow University in 2012 and 2015, respectively, and her Ph. D. degree from City University of Hong Kong in 2018. She is currently a professor with the School of Mechanical Engineering, Jiangsu University. Her main research interests include signal processing and machinery fault diagnosis.



陈超, 2011 年和 2014 年于江苏大学分别获得学士和硕士学位, 2020 年于东南大学获博士学位, 现为江苏大学讲师、硕士生导师, 主要研究方向为信号处理、机械系统状态监测与智能故障诊断。

E-mail: chenchaoy@ ujs. edu. cn

Chen Chao received his B. Sc. and M. Sc. degrees both from Jiangsu University in 2011 and 2014, respectively, and his Ph. D. degree from Southeast University in 2020. He is currently a lecturer and M. Sc. supervisor at Jiangsu University. His main research interests include signal processing, machine condition monitoring and intelligent fault diagnosis.



韩丽玲, 2019 年于合肥工业大学获得博士学位, 现为江苏大学讲师。主要研究方向为微纳驱动与测试、压电驱动器。

E-mail: llhan@ ujs. edu. cn

Han Liling received her Ph. D. degree from Hefei University of Technology in 2019. She is currently a lecturer at Jiangsu University. Her main research interests include micro-nano actuation and testing, and piezoelectric actuators.