arXiv:2304.08249v1 [eess.AS] 14 Apr 2023

新型故障特征 铁路车辆轴承故障检测的特征

Matthias Kreuzer [1]多媒体通信与信号处理 埃朗根-纽伦堡弗里德里希·亚历山大大学
Cauerstraße 7, 91058 埃朗根，德国

Alexander Schmidt[2]多媒体通信与信号处理 埃朗根-纽伦堡弗里德里希·亚历山大大学
Cauerstraße 7, 91058 埃朗根，德国

Walter Kellermann[3]多媒体通信与信号处理 埃朗根-纽伦堡弗里德里希·亚历山大大学
Cauerstraße 7号，91058 埃朗根，德国

摘要

在本文中，我们探讨了从振动信号中检测轴承故障这一具有挑战性的问题。为此，过去已经提出了多种时间域和频域特征。然而，这些特征通常是在相对简单场景产生的数据上进行评估的；如果考虑更为现实的场景，则可以观察到显著的性能损失。为了解决这一问题，我们引入梅尔频率倒谱系数（*MFCCs*）以及从调幅频谱图（*AMS*）中提取的特征，将其用于轴承故障检测。*AMS* 和 *MFCCs* 最初都是在音频信号处理背景下提出的，但研究表明，使用这些特征可以显著提升分类性能。此外，为了解决轴承故障检测背景下典型的数据不平衡问题，即通常可获得的健康轴承数据远多于损坏轴承数据，我们提出仅使用健康轴承数据训练单类支持向量机（*SVM*）。随后通过检测离群点对轴承故障进行分类。我们使用在极具挑战性的场景中测量的数据对该方法进行了评估。该场景包含一台由工业功率变换器供电并与负载机耦合的先进通勤铁路机车。

1. 引言

轴承是旋转机械中的关键部件，例如风力涡轮机和铁路车辆中的轴承。由于轴承失效可能导致大量额外成本，并对其他部件造成损坏，

[1]matthias.kreuzer@fau.de[2]
alexander.as.schmidt@fau.de[3]
walter.kellermann@fau.de

版权归 INCE-USA 所有

因此，及早且可靠地检测轴承故障至关重要。由于这些部件通常难以接近，人工检查既耗时又昂贵。然而，轴承损坏会改变机器的振动特征，而安装在机器机壳上的加速度传感器可以捕捉到这种变化。因此，通过分析振动信号即可识别故障。

[{"id":0,"output":"为此，近几十年来人们开发了各种技术。振动信号的分析通常在时域或频域中进行。在这一背景下，所谓的故障频率尤其发挥着关键作用：如果四个主要轴承部件中的任何一个，即内圈、外圈、保持架或滚动体发生损坏，就可以在振动信号中观察到具有部件特定频率的脉冲。由于对信号进行解调后故障频率会更加明显，因此许多方法会分析振动信号包络的频谱 [1]。然而，与轴承故障相关的信号分量往往被其他机器部件产生的环境噪声所掩盖，因此有必要采用信号增强算法。为了将与故障相关的分量从环境噪声中分离出来，人们已将多种信号分解技术，例如经验模态分解 [2] 和小波变换 [3], 以及自适应滤波技术 [4]应用于这一问题。有关应用于轴承故障检测主题的信号处理技术的详细综述可见于 [3]。"}]

故障出现时，振动模式会发生变化，振动信号的统计特征（如方差、峰度等）也会随之变化，因此可用于检测故障。因此，可以利用从振动信号的时域和频域表示中提取的特征 [5], 训练数据驱动的机器学习分类算法，例如线性判别分析、k近邻、支持向量机和神经网络。这些分类器的性能很大程度上取决于所提取的特征。因此，确定最适合的特征对这类方法至关重要。近年来，端到端的基于深度学习的方法也广受欢迎 [6]。与前述分类算法不同，这类方法无需手动进行特征选择，因为特征由网络自身提取。 [6]中对多种深度学习架构进行了全面综述，其中包括自编码器、卷积神经网络和循环神经网络。尽管可以省去手动特征选择步骤，但这些方法大多存在一个问题：为了取得令人满意的结果，它们需要大量健康轴承和损坏轴承的带标签训练数据。然而，在实际场景中，数据往往并不平衡，因为损坏轴承的数据很难获取（例如出于安全考虑），而健康轴承的数据通常十分充足。此外，自然形成的损伤很难标注，因为难以准确确定故障最初显现的时间。因此，不依赖损坏轴承数据或仅需少量此类数据的方法，尤其适用于轴承故障分类。文献中将这类分类问题称为离群点检测或异常检测。

本文评估并比较了多种时域和频域特征，以应对极具挑战性的场景中的轴承故障检测问题。实验设置由一台与负载机相连的先进通勤铁路发动机组成。发动机和负载机均由工业功率变换器供电。与大多数公开数据集不同，本实验中的旋转频率和施加的转矩变化剧烈，且功率变换器对测得的振动模式有显著影响。除了文献中已有深入研究的特征外，我们还研究了音频信号处理和自动语音识别（ASR）领域的新型特征，即调幅频谱图（AMS）和梅尔频率倒谱系数（MFCCs）。结果表明，这些特征效果显著，优于传统的时域和频域特征。此外，为解决常见的数据不平衡问题，我们仅使用从健康轴承中提取的特征训练单类支持向量机（SVM），并将轴承故障分类视为异常检测任务。结果表明，即使采用

版权归 INCE-USA 所有

这种相当简单的分类器和一组合适的特征，也能实现超过 98 % 的分类准确率。

本文的结构安排如下。第 2.1 节介绍基本信号模型，随后在第 2.2 节简要回顾用于轴承故障检测的时域和频域传统特征。接着，第 2.3 节和第 2.4 节分别详细讨论梅尔频率倒谱系数和幅值调制谱。第 2.5 节介绍单类支持向量机分类方法。第 3 节介绍实验设置（参见第 3.1 节）、数据生成、训练过程以及所采用的评估指标（参见第 3.2 节），随后在第 3.3 节详细讨论实验结果。第 4 节的总结为本文作结。

2. 轴承故障分类

本节介绍所研究的特征，重点介绍本文提出的幅值调制谱和梅尔频率倒谱系数，并描述分类方法。

2.1. 信号模型

下文将离散时域振动信号记为 $x[k]$ ，其中采样索引为 k。该信号由连续时域振动信号以采样频率 f_s采样得到。给定离散时间信号 $x[k]$, 的 K 个样本，其离散傅里叶变换（DFT）可定义如下

$$X[\mu] = \mathrm{DFT}_M\{x[k]\} = \sum_{k=0}^{K-1} x[k] e^{-j\frac{2\pi}{M}k\mu}, \tag{1}$$

其中，μ 和 M 分别表示频率箱索引和离散傅里叶变换的长度。长度为K 的片段的$x[k]$ 的短时傅里叶变换（STFT）定义为

$$X[\mu, n] = \sum_{k=n}^{n+K-1} x[k] w_M[k-n] e^{-j\frac{2\pi}{M}k\mu}, \tag{2}$$

其中n为时间帧索引。$w_M[k]$ 是长度为M [7]的窗函数。

2.2. 传统时域和频域特征

本节简要回顾时域和频域的传统特征。随后，第 2.3 节和第 2.4 节将分别介绍所提出的特征，即梅尔频率倒谱系数和幅值调制谱。选取的时域特征包括$x[k]$ 的平均值、方差、均方根值（RMS）、峰度、偏度、幅度范围和峰值与均方根比，相应的估计量汇总于表 1。这些特征已广泛用于轴承故障检测，例如见 [8–11]。下文将这组时域特征简称为TD。类似地，也可以从频域振动信号$X[\mu]$中提取统计特征。我们考虑谱质心、谱扩展、谱峭度、谱熵、谱峰值和谱滚降点（参见表 2）。这些特征已成功应用于 [9, 12, 13]中的轴承故障检测。此后，表 2 所列的特征集记为SD，即谱描述符。由于局部故障与特征频率相关，因此也将包络幅值谱中特征故障频率的各倍频处的幅值作为特征。这些特征的计算方式为

$$AMP_{fault} = \sum_{i=1}^{3} |X_{env}[i \cdot \mu_{fault}]| \tag{3}$$

其中 $\mu_{故障} \in \{\mu_{BPFO}、\mu_{BPFI}、\mu_{CA}、\mu_{RE}\}$，

其中 $X_{env}[\mu]$ 表示包络谱（参见 [1]），它通过应用希尔伯特变换 [7] 获得；$\mu_{故障}$ 表示对应于外圈、内圈、滚动体保持架和滚动体局部故障特征故障频率f_{BPFO}、f_{BPFI}、f_{CA} 和f_{RE} 的频率箱索引。确定特征故障频率的公式见 [1, 2]。

表 1：所考虑时域特征概述。

特征	**公式**
平均值 $\bar{x}$	$\frac{1}{K-1}\sum_{k=0}^{K-1} x[k]$
方差 $\sigma^2{}_x$	$\frac{1}{K-1}\sum_{k=0}^{K-1}(x[k]-\bar{x})^2$
均方根（RMS）x_{RMS}	$\sqrt{\frac{1}{K-1}\sum_{k}^{K} x[k]^2}$
峰度	$\frac{\frac{1}{K-1}\sum_{k=0}^{K-1}(x[k]-\bar{x})^4}{(\sigma^2{}_x)^2}$
偏度	$\frac{\frac{1}{K-1}\sum_{k=0}^{K-1}(x[k]-\bar{x})^3}{\left(\sqrt{\sigma^2{}_x}\right)^3}$
幅度范围	最大值$(x[k])$ –最小值$(x[k])$
峰值与均方根比	$\frac{\max(x[k])}{x_{\mathrm{RMS}}}$

2.3. 梅尔频率倒谱系数

梅尔频率倒谱系数是自动语音识别任务和声学场景分类领域的先进特征。顾名思义，梅尔频率倒谱系数将倒谱与梅尔频率标度相结合，从而能够紧凑地表示信号的频谱。在语音分析中，实倒谱（即信号的离散时间傅里叶变换（DTFT）对数幅度的离散傅里叶逆变换（IDFT））广泛应用于各种场景，例如基音检测和声学场景分类 [14]。梅尔频率倒谱系数特征提取方案可概括如下：

1. 通过加窗将时域信号划分为帧。2. 对加窗输入样本计算 N 点离散傅里叶变换。3. 然后使用梅尔滤波器组对所得的功率幅度谱进行滤波，例如，可通过在离散傅里叶变换域应用三角窗来近似梅尔滤波器组 [14]。4. 最后，对滤波器组能量之和的对数计算离散余弦变换（DCT），从而得到梅尔频率倒谱系数。

版权归 INCE-USA 所有

表 2：所考虑的频域特征概览。$\mu_1 = 0$ 和 $\mu_2 = K - 1$ 分别表示下限和上限频率箱索引，f_μ 表示对应于频率箱 μ 的频率。κ 设为 0.95。

特征	公式
谱质心（SC）	$\frac{\sum_{\mu=\mu_1}^{\mu_2} f_\mu \lvert X[\mu]\rvert}{\sum_{\mu=\mu_1}^{\mu_2} \lvert X[\mu]\rvert}$
谱扩展（SSpr）	$\sqrt{\frac{\sum_{\mu=\mu_1}^{\mu_2} (f_\mu - \mathrm{SC})^2 \lvert X[\mu]\rvert}{\sum_{\mu=\mu_1}^{\mu_2} \lvert X[\mu]\rvert}}$
谱峭度	$\frac{\sum_{\mu=\mu_1}^{\mu_2} (f_\mu - \mathrm{SC})^4 \lvert X[\mu]\rvert}{(\mathrm{SSpr})^4 \sum_{\mu=\mu_1}^{\mu_2} \lvert X[\mu]\rvert}$
谱熵	$\frac{-\sum_{\mu=\mu_1}^{\mu_2} \lvert X[\mu]\rvert \log(\lvert X[\mu]\rvert)}{\log(\mu_2 - \mu_1)}$
谱峰值	$\frac{\max(\lvert X[\mu]\rvert)}{\frac{1}{\mu_2 - \mu_1 + 1} \sum_{\mu=\mu_1}^{\mu_2} \lvert X[\mu]\rvert}$
谱滚降点	$\sum_{\mu=\mu_1}^{i} \lvert X[\mu]\rvert = \kappa \sum_{\mu=\mu_1}^{\mu_2} \lvert X[\mu]\rvert$

对于时间帧 n，时间帧 i（其中 $i = 0, \ldots, K-1$）的频谱能量 $X_i[n]$ 可计算为 as

$$X_i[n] = \sum_{\nu=0}^{N-1} g_{i\nu} \left| \sum_{k=0}^{N-1} x[n-k] w[k] e^{-\frac{2\pi k \nu}{N}} \right|^2, \tag{4}$$

其中，$x[k]$ 为输入采样，$w[k]$ 为窗函数，$g_{i\nu}$ 为梅尔滤波器组的三角窗函数。梅尔滤波器模拟人类听觉系统，该系统对较低频率区域的分辨率高于对较高频率区域的分辨率。实际使用的梅尔滤波器带宽在中心频率低于 500 Hz 时保持恒定，而在中心频率较高时近似呈指数增长。子带数（即滤波器数）通常为 $K = 24$ 到 $K = 40$ 个。滤波后，对结果应用离散余弦变换（DCT），即可得到梅尔频率倒谱系数$c[\mu]$

$$c[\mu] = \sum_{i=1}^{K} \log X_i[n] \cos\left(\frac{\pi(2i-1)\mu}{2K} \right), \ \mu = 1, \ldots, K. \tag{5}$$

该变换消除了重叠滤波器组引入的倒谱系数之间的相关性。

2.4. 幅度调制谱图

幅值调制谱（AMS）是听觉相关信号处理和语音识别中常用的一种特征，因有助于检测语音信号的包络波动而广为人知 [15]。计算幅值调制谱所需的信号处理步骤如图 2.4 的框图所示。首先，将时域信号 $x[k]$ 变换到短时傅里叶变换域。接下来，对每个频率

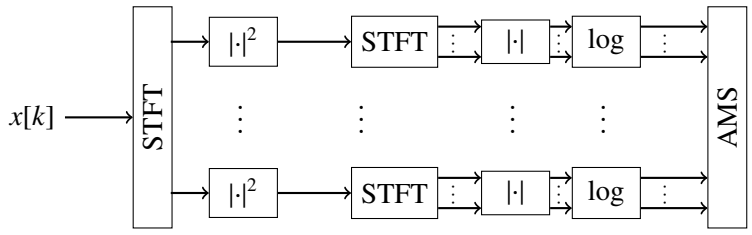

图 1：幅值调制谱的框图。

子带的复值短时傅里叶变换系数的幅值平方进行第二次短时傅里叶变换。平方运算后的子带信号可视为各子带频谱幅度的包络信号。第二次短时傅里叶变换可理解为计算给定频率箱对应的时域包络信号的傅里叶级数，从而检测给定频率子带中的周期性成分（调制频率）。最后，通过对幅值进行对数压缩，得到幅值调制谱。有时，在进行第二次短时傅里叶变换之前，会使用梅尔滤波器组或巴克滤波器组来减少子带数量 [15, 16]。本文省略滤波步骤，并采用表 2.4 所列参数计算连续两次短时傅里叶变换。

为说明幅值调制谱可作为检测轴承故障的有效特征，我们考察图 2 和图 3。图 2 展示了外圈存在局部故障、旋转频率为 500 rpm（≈ 8.33 Hz）、采样频率为 51.2 kHz 的轴承振动信号片段（时长 2 s）的谱图（上）和幅值调制谱（下）。可以注意到，谱图中呈现出明显的周期性垂直线。图 2 下方的子图展示了相应的幅值调制谱，其中第一步短时傅里叶变换的子带沿 y 轴排列，调制频率沿 x 轴展示。可以观察到，中心频率高于 20 kHz 时存在较强的调制。然而，在相同运行条件下运行的健康轴承振动信号的幅值调制谱中则没有这种现象（参见图 3）。谱图中上述明显的垂直线在 15 kHz 以上的高频区域尤为显著（以红色虚线标出），且能量幅值调制谱很好地捕捉到了这些特征。有人可能会认为，检查图 2 和图 3 中的谱图就足以检测故障。然而，在所考察的频率范围内，幅值调制谱呈现出更大的能量差。为使用单个标量量化这些差异，我们建议对中心频率高于 20 kHz 且调制频率低于 80 Hz 的幅值求和。

表 3：计算两种短时傅里叶变换所用的参数。样本数以 f_s = 51.2 kHz 的采样频率为准。

参数	1. 短时傅里叶变换	2. 短时傅里叶变换
窗长	25 毫秒（1280 个样本）	512 毫秒（128 个样本）
步长	4 毫秒（205 个样本）	256 毫秒（64 个样本）
N-FFT	512	256

2.5. 单类支持向量机

单类支持向量机是一种灵活且有效的离群点检测方法。Schölkopf 等人最初在新颖性检测的背景下提出了这种方法，[17] 旨在估计一个边界函数：对于属于给定类别的数据点，该函数返回正值；对于其他类别的数据点和离群点，该函数返回负值。

下面我们将简要回顾单类支持向量机的基本思想。为此，我们考虑一个属于同一类别的训练数据集 $\{\mathbf{x}_n\}_{n=1,\dots,N}$，其中$N$是训练样本的总数。边界函数是在所谓的核诱导特征空间中估计的，在该空间中，

版权归 INCE-USA 所有

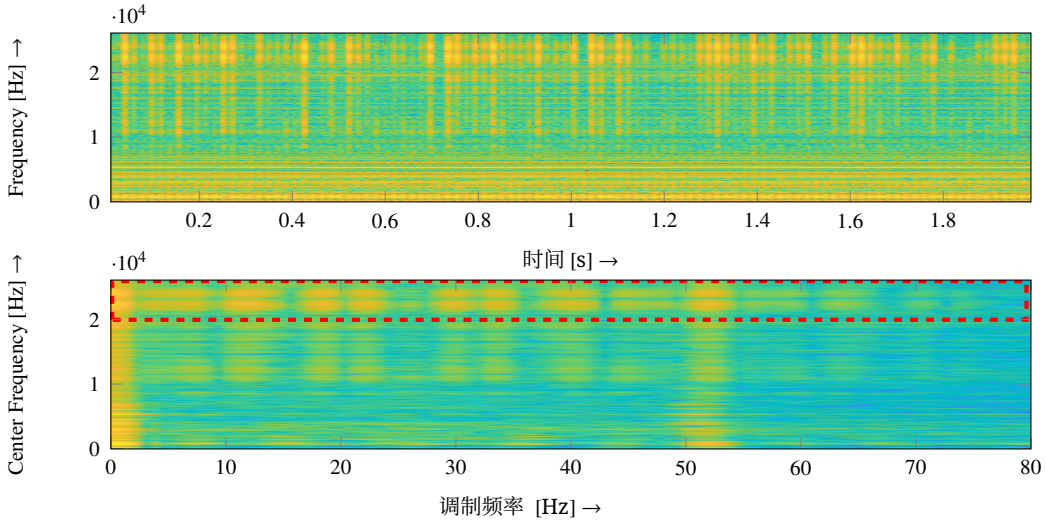

图 2：损伤轴承外圈故障的谱图（上）和幅值调制谱（下）。

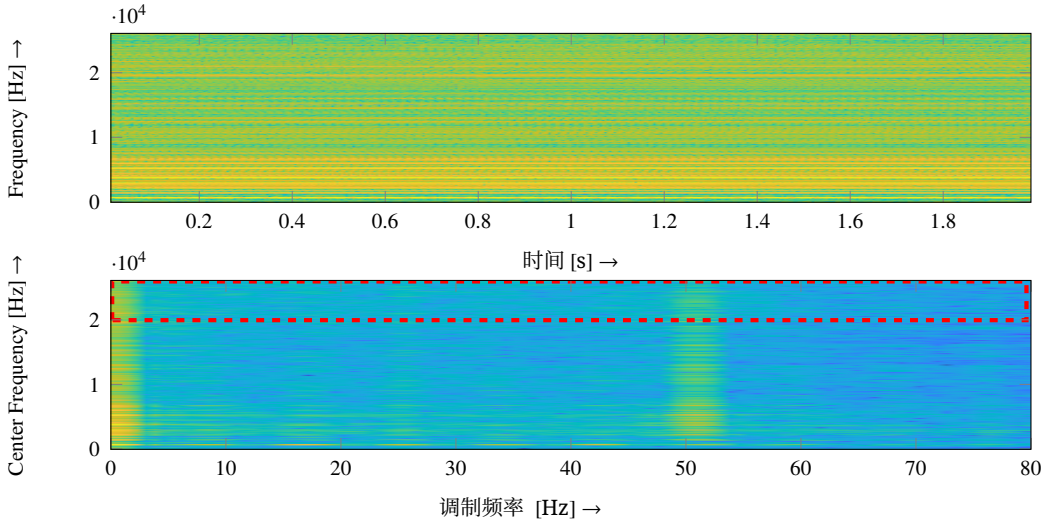

图 3：健康轴承的谱图（上）和幅值调制谱（下）。

训练数据被假定为与原点线性可分。相应的决策边界可表示为

$$f(\mathbf{x}) = \mathbf{w}^{\mathrm{T}}\phi(\mathbf{x}) + b, \tag{6}$$

其中，b 和$\mathbf{w}$ 分别表示到原点的距离和法向量。 $\phi(\cdot)$ 是映射到核诱导特征空间的映射函数。与传统支持向量机类似， $\phi(\cdot)$ 无需显式知晓，这通常称为核技巧 [18]。必须优化$f(\cdot)$ 的参数，使训练数据与原点之间的距离最大化，并确保$f(\mathbf{x}_n) \geq 0$ 对所有n均成立。考虑到任意点$\mathbf{x}$ 到$f(\cdot)$ 的欧几里得距离为 $f(\mathbf{x})/\|\mathbf{w}\|_2$ ，且确保 $\phi(\mathbf{0}) = 0$ 成立，通过求解以下优化问题，可以得到与原点距离最大的边界：

$$\begin{aligned} \underset{\mathbf{w},\, b}{\text{minimize}} \quad & \|\mathbf{w}\|_2 - b \\ \text{subject to} \quad & \mathbf{w}^{\mathrm{T}}\phi(\mathbf{x}_n) + b \geq 0, \forall n. \end{aligned} \tag{7}$$

方程 7 可以使用约束优化中的方法求解，例如求解拉格朗日函数[18]。与传统的支持向量机类似，超平面 $f(\cdot)$ 将仅由训练数据中的部分数据点定义。

版权归 INCE-USA 所有

这些数据点称为支持向量。此外， [17]表明，所得决策边界是对生成训练数据点的密度支撑集的估计。请注意，可以通过引入松弛变量扩展方程 7，以权衡间隔的宽度和误分类数据点的数量，参见 [17]。

如上所述，我们无需明确知晓 $\phi(\cdot)$ 对 $\mathbf{x}$ 的隐式映射，因为我们只关注映射后输入的内积，而内积可通过核函数计算。通常，单类支持向量机使用高斯核 $e^{-\gamma\|\mathbf{x}_i-\mathbf{x}_j\|}$ 处理数据点 $\mathbf{x}_i$ 和 $\mathbf{x}_j$。高斯核只有一个自由参数 γ，称为核函数的宽度 。请注意，高斯核可确保存在由单类支持向量机优化问题定义的超平面 [17]。

3. 评估

以下将介绍实验设置（参见第 3.1 节）、数据生成与训练过程，以及所采用的评估指标（参见第 3.2 节），然后在第 3.3 节中详细讨论所得结果。

3.1. 实验设置

本实验研究了一台先进的通勤铁路感应电机，其额定容量为 405 kW、额定负载为 1800 Nm，额定转速为 2150 rpm。研究共涉及 3 个不同的轴承，包括一个健康轴承和两个存在不同类型损伤的轴承。其中一个轴承的外圈有一处人为引入的损伤，故障直径约为 3.5 mm，深度约为 1.5 mm。外圈宽度为 22 mm。这可视为处于较早阶段的局部故障。第二个轴承在铁路车辆上实际使用约 150 万 km 后从现场拆回；该轴承的多个部件存在分布式故障，包括外圈、滚动体、保持架和滚动体。该轴承代表了处于发展后期的自然形成的轴承损伤。下文将这两种损伤模式分别称为人为引入的损伤和自然形成的损伤。所研究的轴承（型号 6016）安装在感应电机的驱动端位置。

图4所示的实验设置还包括另一台类型相同的感应电机，该电机在背靠背配置中用作负载机。总共安装了两个加速度传感器（传感器A和传感器B，f_s = 51，2 kHz），分别位于感应电机机壳的驱动端位置和非驱动端位置。另有一个传感器用于跟踪转速。此外，实验中使用了铁路牵引变流器，这会显著影响感应电机的振动模式。施加的转矩范围为–2900 Nm至2900 Nm，分别采用四个不同的转矩等级（0%、33%、66%、100%）进行加速和制动。施加的转速呈阶梯式特性，共有8个不同的转速等级：500 rpm、750 rpm、1000 rpm、1500 rpm、2000 rpm、2500 rpm、3000 rpm和3500 rpm。转速曲线如图5所示。可以观察到，对于每个转速，转速均保持恒定约60 s。总体而言，所研究的场景极具挑战性，并且接近现场运行工况，因为转速和转矩变化显著；而公开数据集（例如凯斯西储大学（CWRU）数据集 [6]）并不具备这种情况。

3.2. 数据生成、训练和评估指标

为生成训练集和测试集，将振动信号划分为长度均为 2 秒、互不重叠的帧。分段后，剔除了包含旋转频率变化过程的帧。对于两个传感器，健康

版权归 INCE-USA 所有

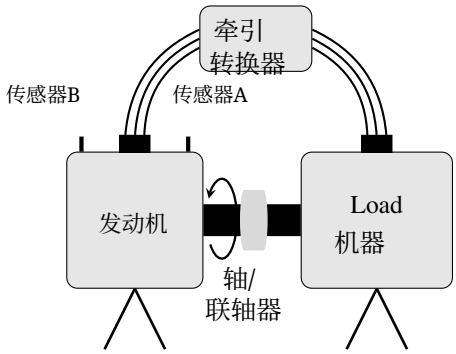

图 4：实验设置。

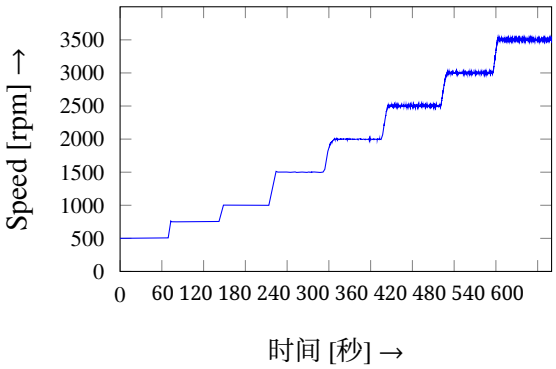

图 5：转速曲线。

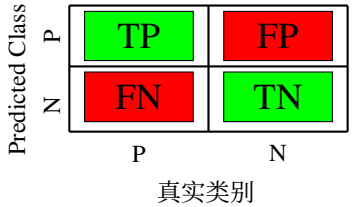

图6：二分类问题的混淆矩阵。

表4：评估指标。

Name	公式
真正率（真阳性率）	$\frac{TP}{TP+FN}$
真负率（TNR）	$\frac{TN}{TN+FP}$
平衡准确率（BA）	$\frac{TPR+TNR}{2}$

测量得到 1558 帧，人工损伤轴承得到 2512 帧，自然形成的损伤得到 2728 帧。训练单类支持向量机时，从健康轴承中随机选取 500 个样本作为训练集。另有一个小型数据集，其中包含从健康轴承测量数据中额外选取的 50 个样本，并将其用作评估数据集，通过网格搜索过程优化单类支持向量机的参数。

下面介绍用于评估分类性能的指标。我们考虑一个二分类问题，其中需要区分P类（正类，健康轴承）和N类（负类，损伤轴承）。分类器的性能可以通过一种称为混淆矩阵（CM）的直观方式进行评估（参见图6）。在混淆矩阵中，预测类别标签（y轴）与真实类别标签（x轴）进行比较。因此，对角线上的元素，即真正例（TP）和真负例（TN），表示正确分类的测试实例数量；而非对角线上的元素，即假负例（FN）和假正例（FP），则表示错误预测的数量。在轴承故障分类中，假负例值对应于被错误分类为损伤轴承的健康轴承数量，假正例则反之。由于构造方式所致，我们的测试数据集高度不平衡，因为负类测试实例的数量远多于正类测试实例。因此，准确率或F1分数等指标并不适用，我们改为采用真阳性率（TPR）和真负率（TNR），分别表示对正类和负类的预测效果。TPR和TNR的算术平均值即为平衡准确率（BA）。表4汇总了TPR、TNR和BA的计算公式。此外，假阴性率（FNR）和假阳性率（FPR）表示被误分类为P类或N类的测试实例所占比例，分别表示为 1 – FNR和 1 – FPR。

3.3. 结果

在评估中，使用第2.2–2.3节介绍的五种不同特征集训练单类支持向量机：时域特征（时域特征）、谱描述符（标准差特征）、包络谱中特征故障频率处的幅值（包络幅值）、从调幅频谱图中提取的标量

特征，以及前13个梅尔频谱系数（*13*个梅尔频谱系数）。此外，为了研究加入旋转频率f_r 是否有益，在特征向量中追加f_r 后，再次评估所有特征集。使用不同的训练集和测试集实例，重复训练和测试10次。表5汇总了传感器A的真阳性率、真阴性率和平衡准确率的平均结果。总体而言，特征集*13*个梅尔频谱系数带来的分类结果最佳；在特征集中追加旋转频率后，平衡准确率分别达到98.79%和98.91%。只有包络幅值 + f_r 和幅值调制谱+f_r 的平衡准确率超过90%，分别为91.58%和94.81%；而时域特征和标准差特征表现最差。令人意外的是，将f_r 添加到标准差特征后，性能大幅下降（平衡准确率从88.33%降至82.81%）。其原因仍有待研究。不过，对于其他特征集，在特征向量中加入f_r 总能至少略微改善分类结果。然而，真阳性率并非总会提高，这有待进一步调查。最显著的差异出现在幅值调制谱上，其平衡准确率从85.13%提高至94.81%。检查图7中不同f_r 条件下的幅值调制谱特征即可解释这一性能的大幅提升；图中展示了健康（蓝色）、人工损伤（红色）和自然损伤（黄色）轴承的数据。人工损伤轴承与健康轴承之间存在明显的间隔。自然损伤轴承的幅值调制谱特征值分布在另外两类之间。不过，在f_r > 30Hz条件下，自然损伤轴承与健康轴承也能明显区分。只考虑来自人工损伤轴承的测试实例时，平衡准确率达到99.65%，进一步验证了幅值调制谱特征非常适用于人工损伤轴承的分类。不过，在这种情况下，所有其他特征集的分类性能也显著提高。

查看传感器B的结果（参见表6）可以发现，传感器B位于感应电机的另一端，与轴承之间的距离较远，这对分类结果造成了显著影响。根据表6，*TD* 和*SD* 的平衡准确率下降了约10个百分点，而*ENVAMP* 和*AMS* 则下降了7个百分点。真阴性率显著降低，也就是说，许多轴承故障未能被检测到，而被误分类为健康状态。只有梅尔频率倒谱系数，以及在一定程度上的*AMS* + f_r 特征集，能够取得较高的真阴性率。鉴于梅尔频率倒谱系数已证明是最有效的特征，因此进一步考察了梅尔频率倒谱系数数量变化对性能的影响。图8展示了传感器B在使用不同数量的梅尔频率倒谱系数时的准确率、假阳性率、假阴性率和平衡准确率。图8显示，当传感器B所用的梅尔频率倒谱系数超过23个时，性能显著提升，假阴性率（即被误分类的健康轴承数量）也明显下降。然而，对于传感器A，仅使用前五个梅尔频率倒谱系数便已能取得非常好的分类结果。传感器B也呈现出类似的情况：在用于优化支持向量机参数的评估数据集中加入少量损坏轴承样本后，分类结果有所改善。不过，对于其他特征集，使用此类评估数据集并未带来同等程度的分类性能提升。

4. 总结

本文研究了用于检测轴承故障的成熟特征，以及音频信号处理领域最先进的特征。我们采用异常检测方法对轴承故障进行分类，其中单类支持向量机仅使用从健康轴承获取的数据进行训练。在具有挑战性的场景下，针对一台先进的通勤铁路感应电机开展了大量实验，结果证明，梅尔频率倒谱系数和幅值调制谱特征对于检测轴承故障非常有效。

版权归 INCE-USA 所有

表5：传感器A的分类结果。

特征集	TPR	TNR	BA
TD	97.81	80.51	89.16
时域特征 + f_r	97.22	82.58	89.90
SD	98.53	78.13	88.33
标准差特征 + f_r	99.34	66.29	82.81
包络幅值	85.55	95.32	90.44
包络幅值 + f_r	86.73	96.44	91.58
AMS	97.35	72.92	85.13
幅值调制谱 + f_r	99.33	90.29	94.81
MFCC	98.23	99.34	98.79
梅尔频率倒谱系数 + f_r	98.20	99.62	98.91

表6：传感器B的分类结果。

特征集	TPR	TNR	BA
TD	96.67	60.91	78.79
时域特征 + f_r	97.57	62.11	79.84
SD	97.66	65.37	81.51
标准差特征 + f_r	99.34	66.29	82.81
包络幅值	96.65	71.99	84.32
包络幅值 + f_r	97.96	71.24	84.60
AMS	94.19	50.37	72.28
幅值调制谱 + f_r	91.15	82.95	87.05
MFCC	98.30	94.39	96.35
梅尔频率倒谱系数 + f_r	98.25	95.32	96.79

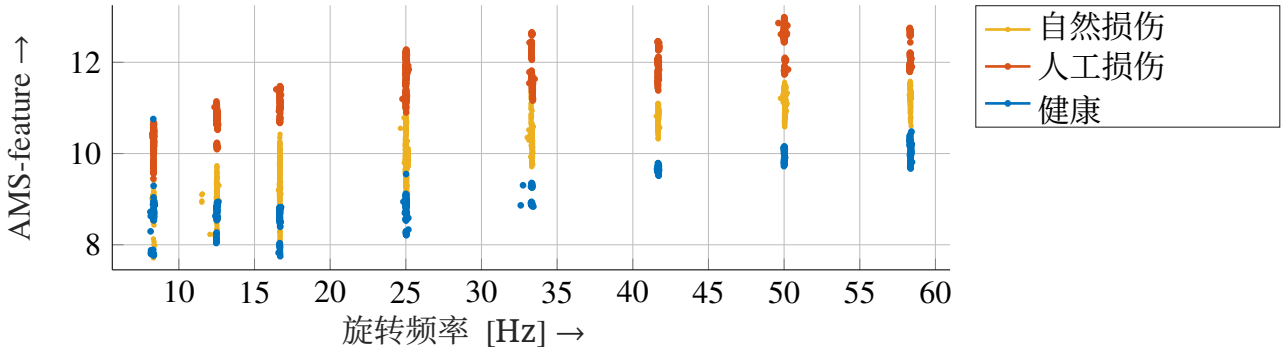

图7：健康（蓝色）、人工损伤（红色）和自然损伤（黄色）轴承的调制谱特征与旋转频率的关系。

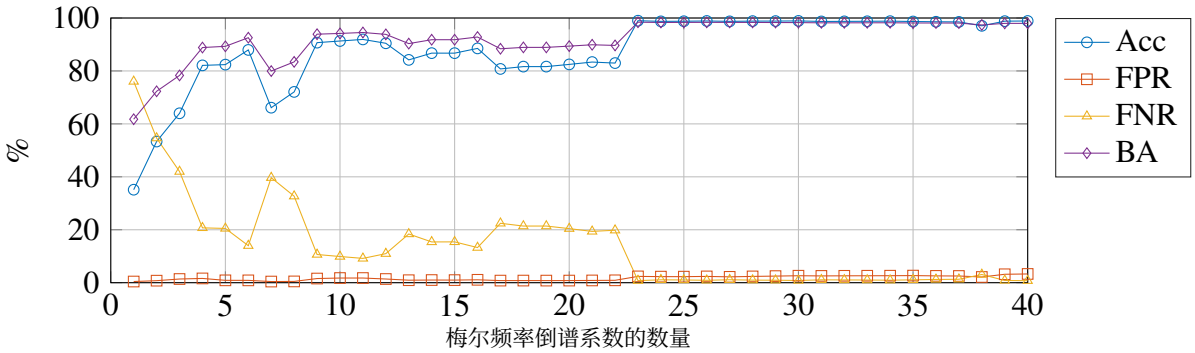

图8：　传感器的准确率、假阳性率、假阴性率和平衡准确率与梅尔频率倒谱系数数量的关系　B

参考文献

[1] Randall, R.B. and Antoni, J. 滚动轴承诊断——教程。《机械系统与信号处理》，25(2):485–520,2011.

[2] Zhang, Z., Entezami, M., Stewart, E., and Roberts, C. 结合经验模态分解和最小熵反卷积增强滚子轴承元件故障诊断。机械工程师学会论文集 *C* 部分：机械工程

工程科学, 231(4):655–671, 2017.[3] Wei, Y., Li, Y., Xu, M., and Huang, W. 旋转机械早期故障诊断方法及其应用综述。《熵》, 21(4):409–435, 2019年4月.[4] Elasha, F., Ruiz-Carcel, C., Mba, D., and Chandra, P. 自适应滤波算法、谱峭度和线性预测在检测齿轮箱中自然劣化轴承方面的有效性比较研究。《失效分析与预防杂志》, 14(5):623–636, 2014年1月.[5] Hamadache, M., Jung, J. H., Park, J., and Youn, B. D. 基于人工智能的滚动轴承故障预测与健康管理方法综述：浅层学习与深度学习。《*JMST Advances*》, pages 1–27, 2019.[6] Neupane, D. and Seok, J. 使用深度学习方法和凯斯西储大学数据集进行轴承故障检测与诊断：综述。《*IEEE Access*》, pages 1–26, 2020.[7] Oppenheim, A. V. and Schafer, R. W. 《离散时间信号处理》. Prentice Hall Press, 美国, 第3版, 2009.[8] Vakharia, V., Gupta, V. K., and Kankar, P. K. 滚珠轴承故障诊断中特征排序技术的比较。《软计算》, 20(4):1601–1619, 2016年4月.[9] Vargas-Machuca, J., Garcia, F., and Coronado, A. M. 使用噪声测量对轴承故障分类的方法详尽比较。《失效分析与预防杂志》, 20(3):744–754, 2020 年 6 月 .[10] Nayana, B. R. and Geethanjali, P. 统计时域特征在利用振动信号识别轴承故障中的有效性分析。《*IEEE*传感器期刊》, 17(17):5618–5625, 2017年9月.[11]BR, N. and Geethanjali, P. 噪声环境下轴承故障诊断的特征提取：一项研究。载于*2019*年电力与先进计算技术创新（*i-PACT*）, 第1卷, pages 1–5, 2019年3月.[12] Arun, P., Abraham Lincon, S., and Prabhakaran, N. 根据振动的频域特征检测并表征轴承故障。《*IETE*研究期刊》, 64(5):634–647, 2018.[13] Yuan, Y., Chen, C., and Yuan, Y. 基于主成分分析和经验模态分解的滚动轴承故障检测。《*AIMS*数学》, 5(6):5916–5938, 2020.[14] Lawrence, R. W. and Schafer, R. W. 《数字语音处理导论》. Now Publishers Inc., 马萨诸塞州, 美国, 2007.[15] Kollmeier, B. and Koch, R. 基于调制感知生理和心理声学模型及双耳交互的语音增强。《美国声学学会杂志》, 95(3):1593—1602, 1994年3月.[16] Tchorz, J. 用于声学场景分类的幅度调制频谱图特征与梅尔频率倒谱系数的结合。技术报告, DCASE2018挑战赛，2018年9月.[17] Schölkopf, B., Platt, J. C., Shawe-Taylor, J., Smola, A. J., and Williamson, R. C. 估计高维分布的支撑集。《神经计算》, 13(7):1443–1471, 2001.[18] Bishop, C. M. 《模式识别与机器学习》. Springer, 柏林, 德国, 2006。

版权归 INCE-USA 所有