

# 基于变分自编码器的轴承健康状态评估<sup>\*</sup>

尹爱军<sup>1</sup>, 王 昱<sup>1</sup>, 戴宗贤<sup>2</sup>, 任宏基<sup>1</sup>

(1. 重庆大学机械传动国家重点实验室 重庆, 400044) (2. 重庆市计量质量检测研究院 重庆, 401120)

**摘要** 针对现有数据驱动型轴承健康状态评估方法普遍存在的特征信息损失大、泛化能力弱和数据依赖强等问题,提出了一种面向高熵特征数据的变分自编码器(variational auto-encoder, 简称 VAE)轴承健康状态评估模型。该模型通过学习健康状态下轴承振动信号频谱在特征空间中的高维潜在概率分布,实现对轴承运行健康状态的定量评估。首先,对基于 VAE 的健康状态评估模型进行理论阐述;其次,建立基于变分证据下界的状态评估指标;最后,通过对比实验证明:变分自编码器在处理轴承运行状态评估方面具有良好的准确度,对异常状态更为敏感;无需人为提取特征和复杂的参数设置,不需对特定的系统进行针对性的参数设置和调校;在小容量训练数据集上仍具备良好的鲁棒性,在工程应用上具有一定的推广价值。

**关键词** 变分自编码器; 异常检测; 故障预测与健康管理的滚动轴承

**中图分类号** TH133.33

## 引 言

轴承运行健康状态评估(prognostics and health management, 简称 PHM)及其退化性能的侦测在现代机械设备中具有越来越重要的作用。近年来,学者们提出了诸多轴承运行健康状态评估方法<sup>[1-5]</sup>。张朝林等<sup>[6]</sup>提出了一种基于本征时间尺度分解(intrinsic time-scale decomposition, 简称 ITD)多尺度熵和极限学习机的轴承健康状态识别模型。朱朔<sup>[7]</sup>针对冗余特征降维问题,提出了一种基于改进局部保留投影算法的滚动轴承特征向量降维方法。刘小勇<sup>[8]</sup>提出了一种基于长短时记忆网络的评估方法,对轴承和涡轮的退化性能进行预测。Qiu 等<sup>[9]</sup>通过使用自组织映射方法将提取到的特征融合构建为轴承健康状态检测指标。

以上方法均通过人为提取数据特征或对数据的真实概率分布和组织形式进行某种假设,进而再通过实验对假设进行验证。该方法有如下限制:①基于人为假设数据,使用数据驱动构建模型的方法,评估效果依赖于模型的参数调校,难以在同类数据上具备较好的鲁棒性;②基于人工提取低维特征的方法损失了原始数据的信息量,冗余无法确定,且所提取的特征对状态评估的贡献度难以定量描述,造成

评估模型只能在特定工况下才能达到理想的效果,且大多数特征提取一般是基于某种特定的假设下;③基于支持向量机(support vector machine, 简称 SVM),神经网络(deep neural networks, 简称 DNN)等智能学习方法完全由数据驱动,缺乏理论背景且对数据的数量较为依赖。轴承在复杂多变的工况下运行并伴随大量环境噪声,在数据量较为缺失的情况下,使得该评估方法难以在轴承状态侦测方面具备较好的通用性。

由于信号频域幅值谱在其特征空间具有更为稳定的概率分布,提出了一种面向高熵特征的变分自编码器轴承健康状态评估模型。通过建立振动信号频谱在特征空间的概率分布量化模型并最大化其边缘似然概率,实现对振动信号频谱高维空间中真实复杂概率分布的精确逼近,完成对振动信号状态的定量评估。通过实验及对比,证明了变分自编码器在轴承运行健康状态评估上具有较好的准确性和鲁棒性。

## 1 变分自编码器

变分自动编码器模型源自于贝叶斯变分推断理论<sup>[10-13]</sup>。对于观测空间中独立同分布数据  $\mathbf{X} = \{\mathbf{x}^{(i)}\}_{i=1}^N$ , 变分自编码器设定观测数据由一个低维

\* 重庆市重点资助项目(cstc2017rgzn-zdyfx0007)

收稿日期:2018-12-12;修回日期:2019-04-16

基础先验分布和一个条件概率分布生成,即

$$P(\mathbf{x}^{(i)}) = \int P(\mathbf{x}^{(i)} | \mathbf{z}; \theta) P(\mathbf{z}) d\mathbf{z} \quad (1)$$

其中:  $P(\mathbf{x}^{(i)})$  为观测数据  $\mathbf{x}^{(i)}$  的概率密度函数。

VAE 试图极大化  $P(\mathbf{x}^{(i)})$  的似然概率,从而估计观测数据的真实分布。

对于隐空间先验分布  $P(\mathbf{z})$ , VAE 指定其服从标准正态分布  $N(\mathbf{0}, \mathbf{I})$ 。其中:  $\mathbf{I}$  为  $z$  空间中的单位阵。同时,变分自编码器使用后验分布  $P(\mathbf{z} | \mathbf{x}^{(i)})$  对具体观测数据的隐空间分布进行度量。VAE 使用变分推断方法,构造可优化函数  $Q(\mathbf{z} | \mathbf{x}^{(i)}; \varphi)$ , 通过优化参数  $\varphi$ , 逼近真实后验分布  $P(\mathbf{z} | \mathbf{x}^{(i)})$ 。根据变分理论并考虑易优化性,优化目标通过 Kullback-Leibler(简称 KL)散度进行度量,即

$$\begin{aligned} \text{KL}[Q(\mathbf{z} | \mathbf{x}^{(i)}) \| P(\mathbf{z} | \mathbf{x}^{(i)})] = \\ E_{z \sim Q}[\log Q(\mathbf{z} | \mathbf{x}^{(i)}) - \log P(\mathbf{z} | \mathbf{x}^{(i)})] \end{aligned} \quad (2)$$

对式(2)运用贝叶斯定理变形可得

$$\begin{aligned} \log P(\mathbf{x}^{(i)}) - \text{KL}[Q(\mathbf{z} | \mathbf{x}^{(i)}) \| P(\mathbf{z} | \mathbf{x}^{(i)})] = \\ E_{z \sim Q}[\log P(\mathbf{x}^{(i)} | \mathbf{z})] - \text{KL}[Q(\mathbf{z} | \mathbf{x}^{(i)}) \| P(\mathbf{z})] \end{aligned} \quad (3)$$

式(3)包含了最初式(1)的优化目标  $P(\mathbf{x}^{(i)})$ , 由于  $\text{KL}[Q(\mathbf{z} | \mathbf{x}^{(i)}) \| P(\mathbf{z} | \mathbf{x}^{(i)})] \geq 0$  且无法直接计算,因此优化目标可变为极大化  $\log P(\mathbf{x}^{(i)})$  的变分证据下界(evidence lower bound, 简称 ELBO),即

$$\begin{aligned} \text{ELBO} = E_{z \sim Q}[\log P(\mathbf{x}^{(i)} | \mathbf{z}; \theta)] - \\ \text{KL}[Q(\mathbf{z} | \mathbf{x}^{(i)}; \varphi) \| P(\mathbf{z})] \end{aligned} \quad (4)$$

VAE 通过最大化变分下界来实现最大化边缘似然概率  $P(\mathbf{x}^{(i)})$ 。对于  $P_\theta$  和  $Q_\varphi$ , 一般可采用多层神经网络实现。在 VAE 中,  $Q(\mathbf{z} | \mathbf{x}^{(i)}; \varphi)$  被指定为一个具有对角协方差矩阵的多维高斯分布

$$Q(\mathbf{z} | \mathbf{x}^{(i)}; \varphi) = N(\mathbf{z}; \boldsymbol{\mu}^{(i)}, \boldsymbol{\sigma}^{(i)} \circ \mathbf{I}) \quad (5)$$

其中:  $\boldsymbol{\mu}^{(i)}, \boldsymbol{\sigma}^{(i)}$  可由一个多层神经网络输出,即 VAE 假设观测数据后验分布服从高斯分布。

对于  $E_{z \sim Q}[\log P(\mathbf{x}^{(i)} | \mathbf{z}; \theta)]$  项,为避免其对  $Q_\varphi$  梯度过大而引起计算不稳定问题,VAE 使用基于蒙特卡洛采样的随机梯度变分贝叶斯评估器(stochastic gradient variational Bayes, 简称 SGVB)对优化目标进行估计,同时使用自编码变分贝叶斯(auto-encoding variational Bayes, 简称 AEVB)算法<sup>[10]</sup>进行训练,并在实际模型中采用重参数技巧解决后验分布采样过程中梯度不可计算的问题,最终变分下界的估计值可表示为

$$\begin{aligned} L(\theta, \varphi; \mathbf{x}^{(i)}) = -\text{KL}[Q_\varphi(\mathbf{z} | \mathbf{x}^{(i)}) \| P(\mathbf{z})] + \\ \frac{1}{L} \sum_{i=1}^L \log P_\theta(\mathbf{x}^{(i)} | \mathbf{z}^{(i,D)}) \end{aligned} \quad (6)$$

其中:  $L$  为隐变量  $\mathbf{z}$  的采样次数;  $\mathbf{z}^{(i,D)} = \boldsymbol{\mu}^{(i)} + \boldsymbol{\sigma}^{(i)}$ 。

$\in^{(i)}; \in^{(i)} \sim N(\mathbf{0}, \mathbf{I})$ 。

变分自编码器实现采用最小化解码数据和观测数据  $L_2$  范数,从而间接优化  $\log P_\theta(\mathbf{X}^{(i)} | \mathbf{z})$ , 所以式(6)的优化目标为

$$\begin{aligned} L(\theta, \varphi; \mathbf{x}^{(i)}) = -\text{KL}[Q_\varphi(\mathbf{z} | \mathbf{x}^{(i)}) \| P(\mathbf{z})] - \\ \frac{1}{L} \sum_{i=1}^L \| f_\theta(\mathbf{z}^{(i,D)}) - \mathbf{x}^{(i)} \|_2 \end{aligned} \quad (7)$$

其中:  $f_\theta$  为解码器。

为使基于蒙特卡洛采样的 SGVB 优化器<sup>[10]</sup>获得收敛,VAE 对观测数据采用小批量多批次方式进行优化,使  $L(\theta, \varphi; \mathbf{x}^{(i)})$  达到最终稳定解。

## 2 基于 VAE 的轴承健康状态评估模型

### 2.1 评估模型及训练

基于 VAE 的轴承健康状态评估模型实质是健康状态下振动信号  $x(t)$  频谱  $\mathbf{X}(f)$  的边缘概率分布  $P(\mathbf{X}(f))$ , 对于轴承运行状态下频谱  $\mathbf{X}(f)$ , 评估模型  $P(\mathbf{X}(f))$ , 计算  $\mathbf{X}(f)$  所表征健康状态的概率值,从而实现对轴承健康状态的定量评估。由式(3)得

$$\begin{aligned} \log P(\mathbf{X}(f)) = L(\theta, \varphi; \mathbf{X}(f)) + \\ \text{KL}[Q(\mathbf{z} | \mathbf{X}(f)) \| P(\mathbf{z} | \mathbf{X}(f))] \end{aligned} \quad (8)$$

评估模型通过对  $P(\mathbf{X}(f))$  进行最大似然估计,从而使  $P(\mathbf{X}(f))$  逼近真实边缘概率分布。由于  $\text{KL}[Q(\mathbf{z} | \mathbf{X}(f)) \| P(\mathbf{z} | \mathbf{X}(f))] \geq 0$  且无法计算,因此采用变分下界  $L(\theta, \varphi; \mathbf{X}(f))$  作为  $\log P(\mathbf{X}(f))$  的估计。由于 AEVB 算法采用小批量多批次方式进行训练,若单批次训练数量达到一定规模(100 以上),根据均值场论<sup>[14]</sup>,  $L(\theta, \varphi; \mathbf{X}(f))$  中蒙特卡洛采样次数可降为一次<sup>[10]</sup>。笔者指定评估模型单批次训练数量为 128,每批次训练采样一次。因此,变分下界  $L(\theta, \varphi; \mathbf{X}(f))$  表示为

$$\begin{aligned} L(\theta, \varphi; \mathbf{X}(f)) = \frac{1}{128} \sum_{i=0}^{127} \{-\text{KL}[Q_\varphi(\mathbf{z} | \mathbf{X}(f)^{(i)}) \| \\ P(\mathbf{z})] - \| f_\theta(\mathbf{z}^{(i)}) - \mathbf{X}(f)^{(i)} \|_2\} \end{aligned} \quad (9)$$

在训练阶段,VAE 将轴承振动信号频谱解码为连续三维隐空间中后验分布参数,同时使后验分布与先验分布的 KL 散度及编解码前后频谱间  $L_2$  范数最小化,以此实现对所有训练数据的边缘似然概率最大化。图 1 为基于 VAE 的轴承健康状态评估模型及其训练,具体训练步骤如下。

1) 从训练集数据中随机选取 128 个观测数据点,组成单批训练集  $\{\mathbf{X}(f)^{(i)} | i=0,1,\dots,127\}$ 。

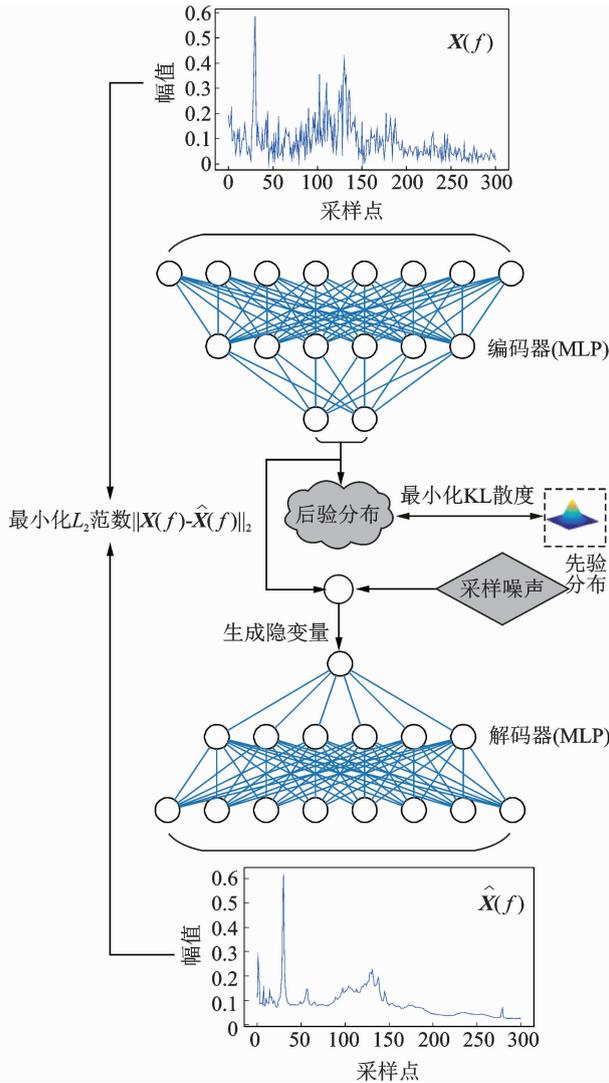


图 1 基于 VAE 的轴承健康状态评估模型

Fig. 1 Model architecture for the bearing health status evaluation with VAE

2) 将单批训练集中每个数据点  $\mathbf{X}(f)^{(i)}$  送入编码器,得到对应后验分布  $N(\mathbf{z}; \boldsymbol{\mu}^{(i)}, \boldsymbol{\sigma}^{2(i)} \circ \mathbf{I})$ 。

3) 从三维标准正态分布中采样 128 个噪声  $\{\epsilon^{(i)} | i = 0, 1, \dots, 127\}$ , 结合对应后验分布生成隐变量  $\{\mathbf{z}^{(i)} | \mathbf{z}^{(i)} = \epsilon^{(i)} \circ \boldsymbol{\sigma}^{2(i)} + \boldsymbol{\mu}^{(i)}\}$ 。

4) 将所有隐变量送入解码器,解码得到解码数据  $\{\hat{\mathbf{X}}(f)^{(i)} | \hat{\mathbf{X}}(f)^{(i)} = f_{\theta}(\mathbf{z}^{(i)})\}$ , 计算编解码前后

数据平均  $L_2$  范数损失  $\frac{1}{128} \sum_{i=0}^{127} \|\hat{\mathbf{X}}(f)^{(i)} -$

$\mathbf{X}(f)^{(i)}\|_2$  以及平均 KL 散度  $\frac{1}{128} \sum_{i=0}^{127} \text{KL}[N(\mathbf{z};$

$\boldsymbol{\mu}^{(i)}, \boldsymbol{\sigma}^{2(i)} \circ \mathbf{I}) \| N(\mathbf{0}, \mathbf{I})]$ , 通过随机梯度下降法使得以上两项之和最小。其中, ‘ $\circ$ ’ 为矩阵元素级乘法。

5) 重复步骤 1~4, 直至模型总体损失函数值低于设定值, 保存模型参数  $Q_{\varphi}$  及  $P_{\theta}$ 。

## 2.2 基于变分下界的状态评估指标

轴承健康状态评估指标即为对应频谱  $\mathbf{X}(f)$  的边缘似然概率响应值  $P(\mathbf{X}(f))$ 。由分析可知,  $P(\mathbf{X}(f))$  无法直接计算, 而是通过其变分下界  $L(\theta, \varphi; \mathbf{X}(f))$  对其对数值  $\log P(\mathbf{X}(f))$  进行估计, 且由于高斯后验分布的简化假设导致变分推断存在一定误差<sup>[15]</sup>, 因此  $P(\mathbf{X}(f))$  不能直接作为轴承健康状态评估指标。  $L(\theta, \varphi; \mathbf{X}(f))$  作为  $\log P(\mathbf{X}(f))$  的一个下界逼近, 同样可作为预测阶段的健康状态评价指标, 由此得出的评价结果是偏严格的, 即真实退化程度不会高于评估退化程度, 这对发现轴承运行早期故障是有益的。

为了避免计算解码器解码期望而带来的额外采样运算, 直接使用后验高斯分布期望值作为采样隐变量。设某时间段轴承振动信号为  $x(t)$ , 频谱为  $\mathbf{X}(f)$ , 则基于变分下界的健康状态评估指标  $E$  表示为

$$E[x(t)] = \|\mathbf{f}_{\theta}[\mathbf{u}(\mathbf{X}(f))] - \mathbf{X}(f)\|_2 + \text{KL}[Q_{\varphi}(\mathbf{z} | \mathbf{X}(f)) \| P(\mathbf{z})] \quad (10)$$

其中:  $\mathbf{u}(\mathbf{X}(f))$  为  $\mathbf{X}(f)$  后验分布期望值。

$E(x(t))$  值越大, 表明其退化程度越严重。对轴承振动频谱  $\mathbf{X}(f)$ , 首先通过解码器  $Q_{\varphi}(\mathbf{X}(f))$  得到其高斯后验分布期望  $\mathbf{u}$  及方差  $\boldsymbol{\sigma}$ , 通过  $\mathbf{u}, \boldsymbol{\sigma}$  构建后验分布  $N(\mathbf{u}, \boldsymbol{\sigma})$ , 并计算其和先验分布的 KL 散度  $\text{KL}[N(\mathbf{u}, \boldsymbol{\sigma}) \| N(\mathbf{0}, \mathbf{I})]$ 。同时, 将期望  $\mathbf{u}$  送入解码器  $f_{\theta}$ , 得到解码值  $f_{\theta}(\mathbf{u})$ , 并计算解码值与真实值间  $L_2$  范数  $\|\mathbf{f}_{\theta}(\mathbf{u}) - \mathbf{X}(f)\|_2$ , 最终  $\text{KL}[N(\mathbf{u}, \boldsymbol{\sigma}) \| N(\mathbf{0}, \mathbf{I})]$  与  $\|\mathbf{f}_{\theta}(\mathbf{u}) - \mathbf{X}(f)\|_2$  之和即为轴承健康状态评估指标。

## 3 实验结果及分析

为了验证变分自编码器对轴承振动信号状态评估效果, 笔者选取辛辛那提大学智能维护系统实验室开源滚动轴承加速退化实验数据集<sup>[16]</sup>。试验台传动轴由交流电机通过皮擦带轮驱动测试轴旋转, 转速恒定为 2 kr/min。实验共有 4 个数据采集通道, 均采用加速度传感器收集对应轴承振动信号, 采样频率为 20 kHz。笔者使用轴承 1 振动数据作为数据集。实验历时 9 840 min 后, 轴承 1 出现外圈故障, 停止实验。

在轴承运行全过程 9 840 min 内, 选取前 100

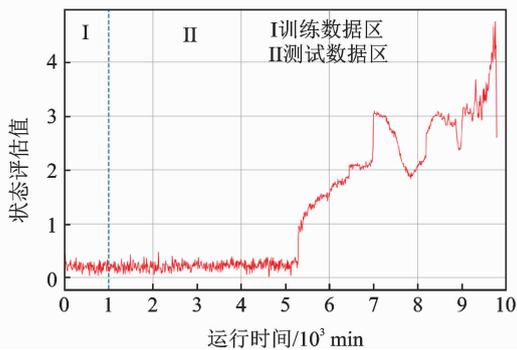


图2 VAE 轴承健康状态评估结果

Fig. 2 Evaluation results of bearing health status with VAE

个数据集(前 1 000 min)作为训练数据集,其余数据均作为测试集。为了降低训练数据维度,每个数据集选取转子旋转一圈时间(5 s)的采样信号作为训练数据维度,对模型进行随机多批次训练。训练完后对轴承全退化过程健康状态进行评估,图 2 为 VAE 轴承健康状态评估结果。区域 I 为早期训练数据状态评估结果,区域 II 为轴承后续运行状态评估结果。可见,在 1 000~5 000 min 时间段内,轴承未表现出退化迹象,其健康状态评估值和训练阶段的评估值具有相同的变化波动趋势,这说明基于 VAE 的轴承健康状态评估指标在测试集同类数据上具有良好的泛化能力。

基于 VAE 的轴承健康状态评估模型通过隐变量来表征振动信号的潜在状态,隐变量蕴含解码器对原始信号特征的有效转化和提取。因此,对于一个有效的评估模型,其隐变量的分布状态及变化趋势应当和评价指标结果相似。为了验证 VAE 对轴承振动信号状态的隐变量解码分布,在轴承运行全过程中每间隔 10 min 对解码后隐变量进行可视化分析。

图 3 为全退化过程振动信号频谱隐变量分布。

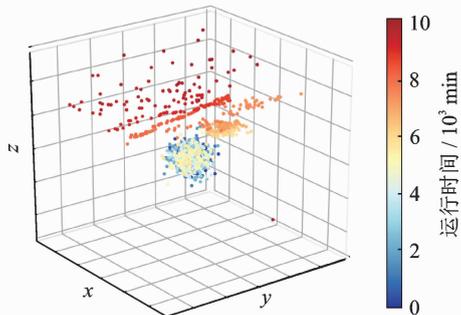


图3 全退化过程振动信号频谱隐变量分布

Fig. 3 Embedding hidden space of vibration spectrum point overall test time

图中,三维坐标系建立在三维先验标准正态分布空间,坐标原点位于先验高斯分布均值处。由于 VAE 使用标准正态分布作为先验分布,因此前 1 000 min 内测试数据隐变量分布符合高斯分布先验假设,且在 1 000 min 至轴承开始退化前时间段内,隐变量分布仍符合高斯分布,这进一步说明了模型在测试数据集同类数据上具有良好的泛化能力。随着轴承退化性能逐渐加重,隐变量开始逐渐偏离先验分布,且偏离程度基本和退化性能成正比。这说明 VAE 正是通过调整隐变量在其空间分布,从而达到表征轴承振动信号频谱有效特征的目的,而不是强行通过编解码器对训练数据进行强行记忆,由此也证实了解码器学习到了从高维原始特征空间到低维有效特征空间的平滑映射。

为验证基于 VAE 的轴承健康状态评估模型对轴承退化性能评估的准确性和敏感性,将其评估结果分别与传统健康状态评估指标的结果进行对比,所有评估指标的评估值均被归一化到 0~1 区间,结果如图 4 所示。

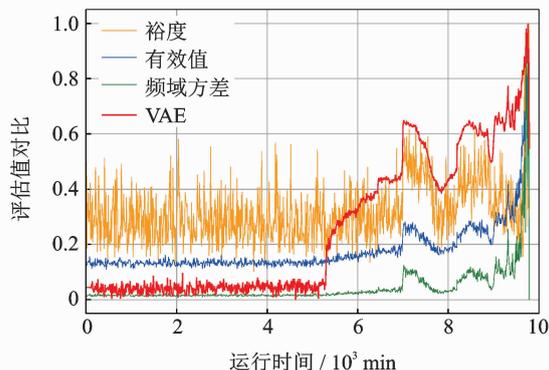


图4 VAE 状态评估归一化值及对比

Fig. 4 Normalized evaluation value and comparison with other methods

从图 4 可以看出,基于 VAE 的轴承健康状态评价方法对退化数据的评估结果与传统健康状态评估结果的曲线走势基本一致,证明了其对轴承退化性能评估的准确性。图 4 表明,基于 VAE 的评价方法在轴承退化早期状态评估敏感度上大大优于其他评估方法,在轴承开始进入退化时,评估值发生了明显变化,这有利于尽早对轴承退化状态进行判断,避免进入二次突变恶化造成更严重的事故。

VAE 通过建立轴承振动数据的概率模型从而对其健康状态进行定量评估。基于隐马尔科夫模型(hidden Markov model,简称 HMM)、深度信念网络(deep belief network,简称 DBN)等代表性概率

推断模型在轴承状态评估方面得到广泛研究<sup>[17-20]</sup>。

图5为VAE,HMM和DBN评估结果对比,评估值被归一化在0~1区间。为了量化不同评价方法下的临界退化时间点,采用 $3\sigma$ 原则<sup>[21]</sup>确定出4 000 min前轴承的健康状态评估值上界,并以此上界作为健康状态至退化状态的评估值转变点,由此确定不同方法下轴承退化的临界时间点,结果如表1所示。

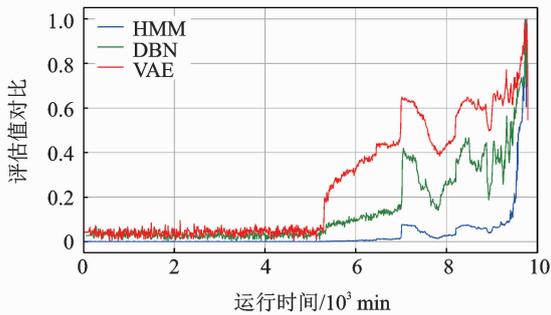


图5 VAE,HMM和DBN评估结果对比

Fig. 5 Evaluation results in comparison with VAE, HMM, and DBN

表1 VAE,DBN和HMM临界退化时间

Tab.1 Threshold degradation time of VAE,DBN and HMM

评估方法	临界退化时间 min
VAE	5 285.8
DBN	5 295.7
HMM	5 305.6

可见,基于HMM的评估方法对轴承早期故障的侦测较为迟滞,在后期退化状态的侦测上敏感度也较弱。基于DBN的评估方法在轴承健康状态转变临界时间点判断上稍落后于VAE评估方法,退化后期对轴承退化状态的评估敏感度也不及VAE方法强。基于VAE的评估方法仅需要少量样本进行训练,其状态评估结果不仅在进入轴承退化临界点时具有敏感的变化趋势,且在相同退化状态下的评估敏感度均高于HMM和DBN。因此,基于VAE的轴承健康状态评估方法相比其他概率推断方法更为准确、高效。

## 4 结束语

提出了一种基于变分自编码器的轴承状态评估方法。通过变分推断的方式,从振动信号频域中自动学习潜在的状态概率分布,并将其应用于轴承运

行状态评估中,取得了较好的效果。证明了变分自编码器在处理轴承运行状态评估方面具有良好的准确度,对异常状态更为敏感,且无需人为提取特征和复杂的参数设置,不需要对特定的系统进行针对性的参数设置和调校。在小容量训练数据集上具备良好的鲁棒性,工程应用上具有一定的推广价值。

## 参 考 文 献

- [1] 康守强,王玉静,崔历历,等. 基于CFOA-MKHSVM的滚动轴承健康状态评估方法[J]. 仪器仪表学报, 2016, 37(9): 2029-2035.  
KANG Shouqiang, WANG Yujing, CUI Lili, et al. Health evaluation method of rolling bearing based on CFOA-MKHSVM[J]. Chinese Journal of Scientific Instrument, 2016, 37(9): 2029-2035. (in Chinese)
- [2] 胡雷,范彬,胡葛庆,等. 变工况下轴承健康监测的相关向量机与自适应阈值模型方法[J]. 国防科技大学学报, 2016, 38(1):168-174.  
HU Lei, FAN Bin, HU Yingqing, et al. Correlation vector machine and adaptive threshold model method for bearing health monitoring under variable working conditions[J]. Journal of National University of Defense Technology, 2016, 38(1): 168-174. (in Chinese)
- [3] 江国乾,谢平,王霄,等. 基于排序模式相异性分析的轴承健康监测[J]. 中国机械工程, 2017, 28(6): 714-720,727.  
JIANG Guoqian, XIE Ping, WANG Xiao, et al. Bearing health monitoring based on sorting mode phase analysis[J]. China Mechanical Engineering, 2017, 28(6): 714-720,727. (in Chinese)
- [4] 余道明,贾民平,张菡. 一种新型深度自编码网络的滚动轴承健康评估方法[J]. 东南大学学报(自然科学版), 2018, 48(5): 801-806.  
SHE Daoming, JIA Minping, ZHANG Wan. A new method for health assessment of rolling bearings with deep self-coding network[J]. Journal of Southeast University(Natural Science Edition), 2018, 48(5): 801-806. (in Chinese)
- [5] YILMAZ M S, AYAZ E. Adaptive neuro-fuzzy inference system for bearing fault detection in induction motors using temperature, current, vibration data[C] // IEEE Eurocon 2009. [S. l.]: IEEE, 2009: 1140-1145.
- [6] 张朝林,范玉刚,冯早. ITD-多尺度熵和ELM的风电轴承健康状态识别[J]. 机械科学与技术, 2018, 37

- (11): 1731-1736.
- ZHANG Chaolin, FAN Yugang, FENG Zao. ITD-multiscale entropy and ELM wind power bearing health status identification[J]. Mechanical Science and Technology for Aerospace Engineering, 2018, 37(11): 1731-1736. (in Chinese)
- [7] 朱朔. 滚动轴承故障预测关键方法研究[D]. 无锡: 江南大学, 2018.
- [8] 刘小勇. 基于深度学习的机械设备退化状态建模及剩余寿命预测研究[D]. 哈尔滨: 哈尔滨工业大学, 2018.
- [9] QIU H, LEE J, LIN J, et al. Robust performance degradation assessment methods for enhanced rolling element bearing prognostics[J]. Advanced Engineering Informatics, 2003, 17(3/4): 127-140.
- [10] GOODFELLOW I, BENGIO Y, COURVILLE A. Deep learning[M]. [S. l.]: MIT Press, 2016: 629-716.
- [11] ZHANG H, XU T, LI H, et al. Stackgan: text to photo-realistic image synthesis with stacked generative adversarial networks[C]//Proceedings of the IEEE International Conference on Computer Vision. [S. l.]: IEEE, 2017: 5907-5915.
- [12] CHEN R T, RUBANOVA Y, BETTENCOURT J, et al. Neural ordinary differential equations[C]//Advances in Neural Information Processing Systems. [S. l.]: MIT Press, 2018: 6571-6583.
- [13] HOFFMAN M D, BLEI D M, WANG C, et al. Stochastic variational inference[J]. The Journal of Machine Learning Research, 2013, 14(1): 1303-1347.
- [14] KADANOFF L P. More is the same; phase transitions and mean field theories[J]. Journal of Statistical Physics, 2009, 137(5/6): 777.
- [15] 李鹏. 基于高斯混合模型的变分自动编码器[D]. 哈尔滨: 哈尔滨工业大学, 2017.
- [16] LEE J, QIU H, YU G, et al. IMS, University of Cincinnati. Bearing data set, NASA ames prognostics data repository[R/OL]. Moffett Field, CA, USA: NASA Ames Research Center, 2007. [2018-12-12]. <http://ti.arc.nasa.gov/project/prognostic-data-repository>.
- [17] SHAO H, JIANG H, LI X, et al. Rolling bearing fault detection using continuous deep belief network with locally linear embedding[J]. Computers in Industry, 2018, 96: 27-39.
- [18] TONG Q, CAO J, HAN B, et al. A fault diagnosis approach for rolling element bearings based on RSGW-PT-LCD bilayer screening and extreme learning machine[J]. IEEE Access, 2017, 5: 5515-5530.
- [19] ANGER C, SCHRADER R, KLINGAUF U. Unscented Kalman filter with gaussian process degradation model for bearing fault prognosis[C]//Proceedings of the European Conference of the Prognostics and Health Management Society. [S. l.]: PHM Society, 2012.
- [20] SOHAIB M, KIM C H, KIM J M. A hybrid feature model and deep-learning-based bearing fault diagnosis[J]. Sensors, Multidisciplinary Digital Publishing Institute, 2017, 17(12): 2876-2891.
- [21] PUKELSHEIM F. The three sigma rule[J]. American Statistician, 1994, 48(2): 88-91.



**第一作者简介:**尹爱军,男,1978年5月生,教授、博士生导师。主要研究方向为智能测试与仪器、无损检测技术、大数据分析的人工智能、装备状态评估与寿命预测、智能装备与机器人、机器视觉等。曾发表《Thermography spatial-transient-stage mathematical tensor construction and material property variation track》(《International Journal of Thermal Science》2014, Vol. 85)等论文。  
E-mail: aijun.yin@cqu.edu.cn

