

DOI: 10.19650/j.cnki.cjsi.J2007276

多元可逆深度概率学习及齿轮退化分析研究*

任宏基^{1,2}, 尹爱军^{1,2}, 陈义³

(1. 重庆大学机械工程学院 重庆 400044; 2. 重庆大学机械传动国家重点实验室 重庆 400044;
3. 重庆电子工程职业学院智能制造与汽车学院 重庆 401331)

摘要: 齿轮退化状态的准确评估对于设备安全运行具有重要意义。常规的齿轮退化状态评估方法的效果受特征提取、预处理等因素的影响。基于生成模型的状态评估方法利用原始观测进行评估,能够降低人为因素的影响。但传统生成模型如变分自编码器(VAE)存在边缘估计不准确的缺点。本文提出了多元可逆深度概率学习(MIDPL),通过叠加可以被优化的可逆变换实现从既定初始分布到未知观测分布的转换,将分布特性复杂的多观测序列转换至既定初始分布进行边缘概率计算继而实现状态评估。本文通过齿轮退化实验验证了MIDPL的有效性,与VAE相比,MIDPL在点蚀和断齿数据集下的评估误差分别降低了30.92%和69.25%,MIDPL能够实现更为稳定和准确的齿轮退化过程评估。

关键词: 齿轮;退化状态评估;生成模型;可逆深度概率学习

中图分类号: TH17 **文献标识码:** A **国家标准学科分类代码:** 510.40

Multivariate invertible deep probabilistic learning and gear degeneration evaluation

Ren Hongji^{1,2}, Yin Aijun^{1,2}, Chen Yi³

(1. College of Mechanical Engineering, Chongqing University, Chongqing 400044, China;
2. State Key Laboratory of Mechanical Transmission, Chongqing University, Chongqing 400044, China;
3. Intelligent Manufacturing and Automobile School, Chongqing College of Electronic Engineering, Chongqing 401331, China)

Abstract: The gear degeneration evaluation technology plays an important role in maintaining safety of various equipment operation. The traditional gear degeneration evaluation methods are susceptible to feature extraction and data pre-processing tricks. The methods based on the generative model use raw observations to perform evaluation. And the human factors can be effectively reduced. However, traditional generative models, such as variational autoencoder (VAE), are limited by poor performance in marginal probability density evaluation. In this study, multivariate invertible deep probabilistic learning (MIDPL) is proposed, which can establish the connection between a given distribution and an unknown observation distribution by stacking learnable invertible transformation. The marginal probability density evaluation of the multi observation sequence can be realized through the given distribution. The proposed MIDPL model is evaluated by gear degeneration experiments. Compared with VAE, the evaluation errors of MIDPL for gear pitting dataset and gear breaking dataset are reduced by 30.92% and 69.25%, respectively. The proposed MIDPL can achieve more accurate and stable degeneration evaluation.

Keywords: gear; degeneration evaluation; generative model; invertible deep probabilistic learning

0 引言

齿轮是现代工业的核心部件之一,其运行稳定性关

乎设备的使役性能^[1-3]。齿轮退化状态评估技术通过分析传感数据获取齿轮的健康程度,是保障设备运行安全的重要手段之一。由于齿轮退化早期具有信号微弱、不易发觉的特点,提高齿轮退化状态评估的准确性具

收稿日期:2020-12-21 Received Date: 2020-12-21

* 基金项目:国家重点研发计划(2020YFB1709800)项目资助

有重要意义^[4]。

现有的齿轮退化状态评估方法可以分为两大类:基于经典信号处理的退化状态评估和基于深度学习的退化状态评估^[5-6]。基于经典信号处理的方法侧重特征提取,针对振动监测信号,通过时域、频域、时频、小波等特征来表征齿轮的退化程度^[7-9]。这类方法的有效性受操作者水平及经验因素影响较大。基于深度学习的齿轮状态评估方法通过深度学习齿轮运行状态的模式继而实现退化程度评估,如长短期记忆网络(long and short term memory networks, LSTM)、卷积神经网络(convolutional neural network, CNN)、深度置信网络(deep belief networks, DBN)等^[10-14]。此类方法的局限性在于模型效果受预处理及网络结构影响严重。

生成模型作为深度学习方法的一种,其不依赖数据符合某种分布的假设,通过学习数据本身分布特点的方式实现基于原始数据的状态评估,大大降低了评估过程中人为因素的影响。目前被广泛应用于设备状态评估的生成模型为变分自编码器(variational autoencoder, VAE)^[15-16]。基于VAE等生成模型进行状态评估的流程为首先基于参考数据建立参照模型并依据模型损失最小的原则进行优化,然后将待评估样本在参照模型下的损失作为状态指标。VAE不能直接计算边缘估计,而是通过Kullback-Leibler散度等项进行间接逼近。与基于VAE的生成模型思路不同,基于可逆变换的生成模型通过一个已知分布实现与任意复杂分布的可逆转换。通过对中间过程的可逆变换进行优化实现任意复杂分布特点的学习,可以进行直接和显式的边缘估计。Kobyzev等^[17]对基于VAE的和基于可逆变换的生成模型进行了对比,VAE通过间接计算边缘估计的方式会引起边缘估计的不精确以及参照模型训练过程的不稳定,继而导致评估结果的不准确;基于可逆变换的生成模型可以实现更为准确的模型优化和估计。

本文基于可逆变换提出多元可逆深度概率学习(multivariate invertible deep probabilistic learning, MIDPL),继而提出了基于MIDPL的齿轮退化状态评估方法。通过高维正态分布链式连接多层可逆变换建立齿轮振动监测“生成-评估”模型,学习多维监测的联合分布特性,继而实现齿轮退化状态的准确评估。

1 多元可逆深度概率学习

1.1 多元可逆深度概率学习框架

设备状态的准确评估可以通过对其观测样本的分布特性进行深度概率学习实现。对于长度为 N 的观测序列 $y = (y^1, y^2, \dots, y^N)$,真实概率密度函数为 p_Y ,由于其物理过程复杂,分布特点未知,没有显式的概率估计

方法,不易进行状态评估。假设 y 可以从一个服从 p_U 概率密度函数的序列 $u = (u^1, u^2, \dots, u^N)$ 经可逆变换 f 得到,即:

$$\begin{cases} y = f(u) \\ u = f^{-1}(y) \end{cases} \quad (1)$$

对于此次变换,有:

$$p_Y(y) = p_U(u) \cdot \left| \det \frac{\partial f}{\partial u^T} \right|^{-1} \quad (2)$$

继而:

$$\log p_Y(y) = \log p_U(u) - \log \det \left| \frac{\partial f}{\partial u^T} \right| \quad (3)$$

其中 $|\det \partial f / \partial u^T|^{-1}$ 为变换 f 所导致的体积变化系数。同样的, y 可以通过一个服从 N 维初始分布的序列 x_0 叠加一系列的可逆变换 f_1, f_2, \dots, f_k ,得到,即:

$$\begin{cases} x_1 = f_1(x_0) \\ x_2 = f_2(x_1) \\ \vdots \\ x_{k-1} = f_{k-1}(x_{k-2}) \\ y = f_k(x_{k-1}) \end{cases} \quad (4)$$

记为:

$$y = f_k \circ f_{k-1} \circ \dots \circ f_2 \circ f_1(x_0) \quad (5)$$

设 x 的概率密度函数为 p_X ,则有:

$$\log p_Y(y) = \log p_X(x_0) - \sum_{k=1}^K \log \det \left| \frac{\partial f_k}{\partial x_{k-1}^T} \right| \quad (6)$$

其中,

$$x_0 = f_1^{-1} \circ f_2^{-1} \circ \dots \circ f_{k-1}^{-1} \circ f_k^{-1}(y) \quad (7)$$

式(5)和(7)分别对应了可逆深度概率学习的正向和逆向过程。图1所示为可逆深度概率学习框架在二维分布上的直观展示。 y 可以通过一个 N 维已知初始分布变换得到,初始分布的选择应考虑到采样及密度估计时的计算复杂度,一般选择多维高斯分布。通过可逆深度概率学习,正向地,观测序列可以由一个从多维高斯分布采样的序列 x_0 经一系列可逆变换得到;逆向地,对于对应状态未知的观测序列,可以经由式(6)将原始观测转换至初始多维高斯分布进行概率密度的计算。式(6)在训练阶段用于参照模型损失的计算及参照模型的优化,在评估阶段则作为状态指标。

考虑到基于单一观测无法准确反应构件退化过程的问题,本文提出了MIDPL,基于多个观测建立耦合分布学习模型,通过一系列可逆变换学习各观测在同一物理过程下的联合分布特性,提高模型的准确性及退化状态评估的灵敏性。

1.2 仿射变换

在初始分布及观测样本既定的条件下,MIDPL的性能取决于可逆变换序列。一组理想的可逆变换序列应具

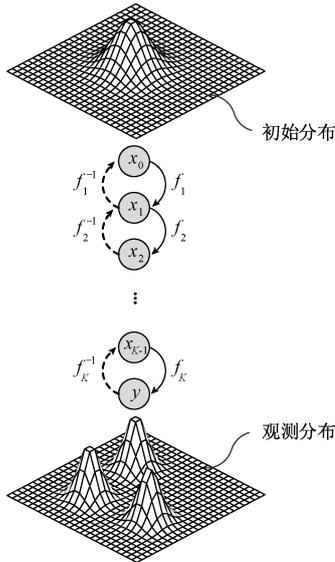


图 1 可逆深度概率学习框架

Fig. 1 Framework of the invertible deep probabilistic learning

有以下特点:1)具有足够丰富的表现力,即能够表现出多观测序列的复杂分布特点;2)计算上的简便性,便于进行边缘估计的计算。本文通过叠加仿射层的方式实现 MIDPL。

考虑通过一个仿射层完成式(1)中所述的变换。主流的实现方式有遮罩自回归流 (masked autoregressive flow, MAF)、逆自回归流 (inverse autoregressive flow, IAF)、实值体积不保持变换 (real-valued non-volume preserving, Real NVP) 等^[17]。Papamakarios 等^[18]论证了 MAF、IAF、Real-NVP 等方法的表现力。计算复杂度方面,文献[19]中对 3 种方法的具体结构和复杂度进行了比较,对于维度为 N 的数据,MAF 在进行正向过程时需要进行 N 轮前传计算,IAF 在进行逆向过程时需要进行 N 轮前传计算,Real NVP 与二者相比优点在于其进行正向过程和逆向过程时均只需 1 轮前传计算。因此本文采用 Real NVP 搭建仿射层^[20]。

基于 Real NVP,式(1)的变换过程可以表示为:

$$\begin{cases} y^{1:n} = u^{1:n} \\ y^{n+1:N} = u^{n+1:N} \odot \exp(s(u^{1:n})) + t(u^{1:n}) \end{cases} \quad (8)$$

$$\begin{cases} u^{1:n} = y^{1:n} \\ u^{n+1:N} = (y^{n+1:N} - t(y^{1:n})) \odot \exp(-s(y^{1:n})) \end{cases} \quad (9)$$

其中, $s(u^{1:n})$ 和 $t(u^{1:n})$ 为变换 f 的缩放和平移系数; $s(y^{1:n})$ 和 $t(y^{1:n})$ 为变换 f^{-1} 的缩放和平移系数。基于 Real NVP 的变换中,对于长度为 N 的序列,前 n 个数据点不做处理,后 $N-n$ 个数据点进行缩放和平移变换且缩放和平移系数由前 n 个数据点

确定。

对于式(8),有:

$$\frac{\partial f}{\partial u^T} = \begin{bmatrix} \mathbf{I}_n & 0 \\ \frac{\partial f}{\partial (u^{1:n})^T} & \text{diag}(\exp[s(u^{1:n})]) \end{bmatrix} \quad (10)$$

其中, \mathbf{I}_n 为 $n \times n$ 且对角线元素为 1 的矩阵,对于式(10),进行式(6)中 $\log \det |\partial f / \partial u^T|$ 计算时只需将 f 变换缩放系数累加,简化了计算复杂度。

本文通过神经网络进行每个仿射变换中缩放和平移系数的计算,仿射层的性能由神经网络决定,单次仿射变换的结构如图 2 所示。

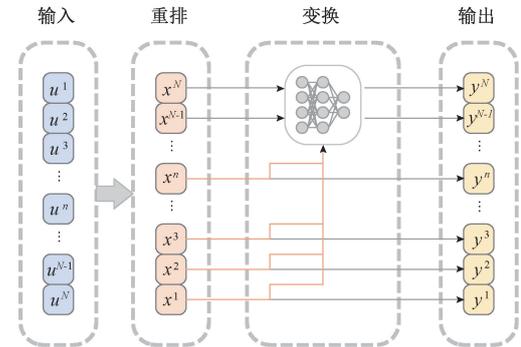


图 2 单次仿射变换结构

Fig. 2 The structure of the single affine transformation

图 2 中,在仿射变换中引入了“重排”步骤以调整相邻仿射变换中 n 个未作变换的数据点对应的原始数据的维度。 $x^1 = u^1, x^2 = u^2, \dots, x^N = u^N$,则变换至 y 时未作变换的 $x^{1:n}$ 对应 $u^{1:n}$ 。一次仿射变换的输出为下次仿射变换的输入,即在与图 2 连接的变换中未作处理的数据对应 $u^{(N-n+1):N}$ 。因此,只要 $n \leq N/2$ 即可保证在相邻的两次变换中输入的 N 个维度的数据得到充分耦合以提高表现力。

至此,MIDPL 的结构已清晰,一端为真实的多观测序列样本,另一端为一个维度与监测长度相同的多维正态分布,二者通过 K 个仿射变换连接。采用如图 2 所示的仿射结构可以在保证表现力的同时减小进行边缘估计时的计算复杂度。

2 基于多元可逆深度概率学习的齿轮退化状态分析

在多观测联合分布特性深度学习的基础上,本文提出了基于 MIDPL 的齿轮退化状态分析方法,流程如图 3 所示。退化状态评估原理为:通过稳定状态下的振动监测数据建立及优化对应的可逆变换序列,得到稳定状态

模型;对于待评估样本,基于式(6)计算模型损失作为退化状态指标。

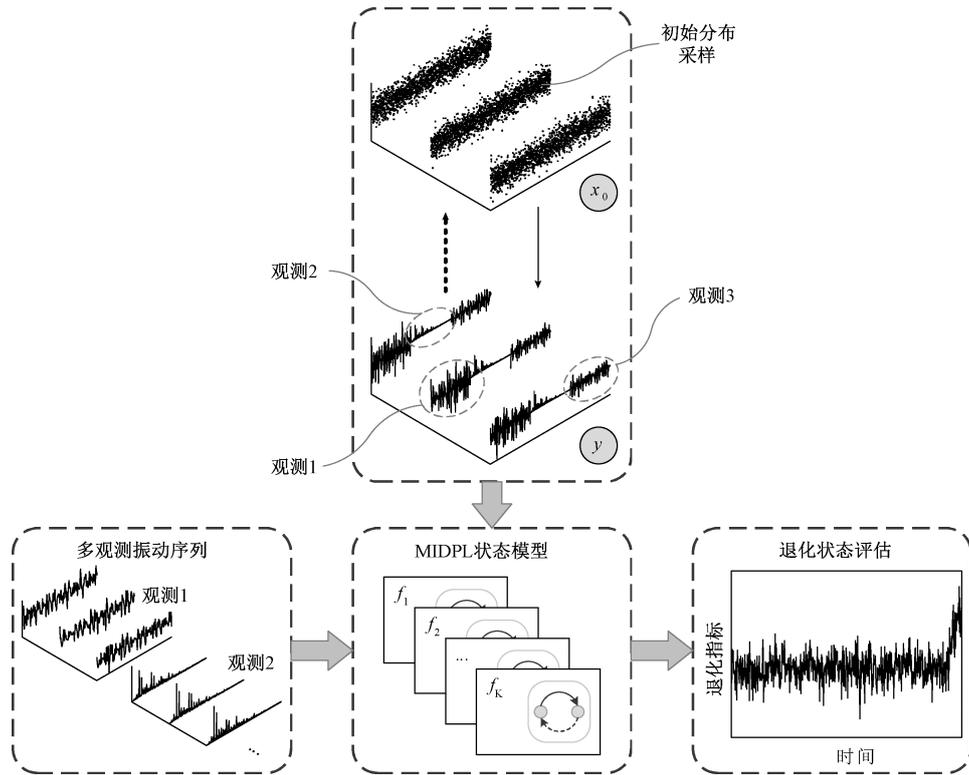


图3 基于多元可逆深度概率学习的齿轮退化状态评估

Fig. 3 Gear degeneration evaluation based on MIDPL

基于多个齿轮退化过程的观测建立状态模型使各观测维度充分耦合。对于振动观测,不同的观测可以是方向或位置不同的同类型观测,也可以为针对同一测点的不同类型观测。

3 实验验证

3.1 齿轮退化实验

本文通过齿轮退化实验证明所提出方法的有效性。齿轮接触疲劳实验平台包括电机驱动的齿轮箱、扭矩负载加载器、冷却与润滑系统、实验控制平台。整体结构如图4所示^[3]。齿轮1、4的齿数为31,齿轮2、3的齿数为25。采集的参数为齿轮箱壳体上的振动加速度。实验平台的主要实验参数如表1所示。

表1 齿轮接触疲劳实验参数

Table 1 Parameters of the gear contact fatigue experiment

| 参数 | 值 |
|---------|--------|
| 齿轮材料 | 40Cr |
| 齿轮模数 | 5 |
| 冷却温度/℃ | 70 |
| 采样频率/Hz | 50 000 |

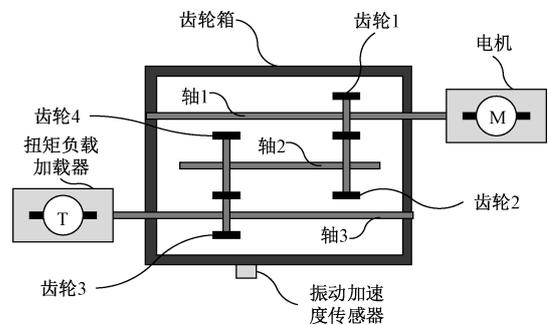


图4 齿轮接触疲劳实验示意图

Fig. 4 Set-up for the gear contact fatigue experiment

接触疲劳实验平台在每个采样间隔内截取10 s长度的数据。实验平台运转至振动加速度达到阈值后停止,保存停止运转前600次的采样结果。通过接触疲劳实验得到了点蚀和断齿两组退化数据集,数据集的参数如表2所示。点蚀和断齿样本的退化程度如图5所示。

3.2 数据集描述

对点蚀与断齿数据集分别提取常用时域、频域特征,如图6和7所示。

表 2 点蚀与断齿数据集的实验参数
Table 2 Parameters for gear tooth pitting and breaking datasets

| | 点蚀数据集 | 断齿数据集 |
|-------------------------|-------|-------|
| 转速/ $r \cdot \min^{-1}$ | 1 000 | 500 |
| 扭矩/ $N \cdot m$ | 1 300 | 1 400 |
| 采样周期/s | 60 | 30 |
| 样本个数 | 600 | 600 |
| 采样间隔/s | 60 | 30 |

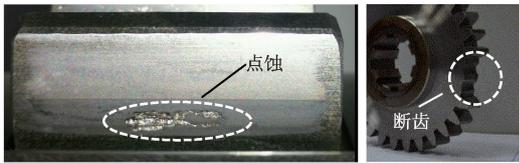


图 5 点蚀与断齿样本的退化状态

Fig. 5 Degeneration conditions for gear pitting and gear breaking samples

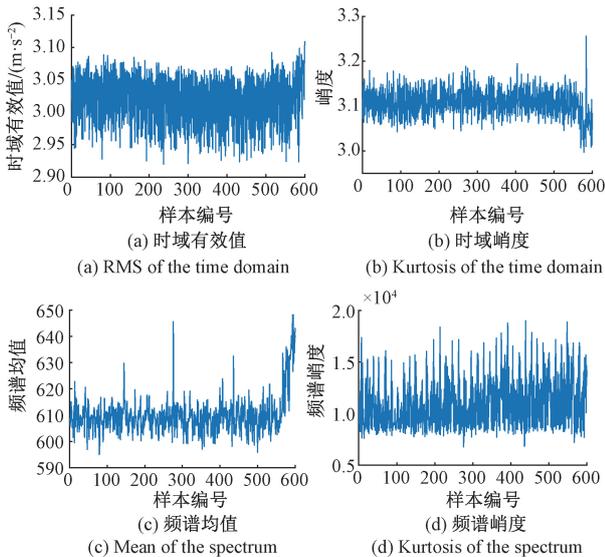


图 6 点蚀数据集时域、频域特征

Fig. 6 Time domain and frequency domain features for the pitting dataset

从图 6 和 7 可知,不同特征对于齿轮退化过程的敏感性差异大,基于常规特征难以实现退化过程的准确描述。时域有效值及频域峭度均无法反应齿轮退化过程。对于点蚀数据集,从图 6(b)、(c)可以大致看出在第 550 个样本后退化程度加剧。对于断齿数据集,从图 7(b)、(c)可以大致看出在第 560 个样本后退化程度加剧。

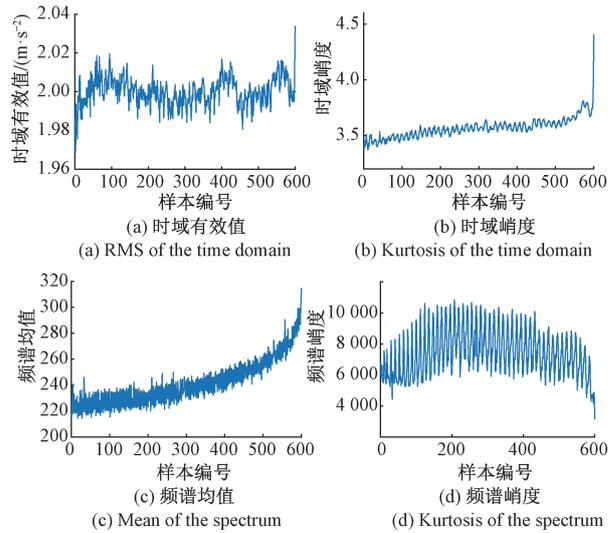


图 7 断齿数据集时域、频域特征

Fig. 7 Time domain and frequency domain features for the breaking dataset

3.3 基于 MIDPL 的齿轮退化状态评估

本文分别选择前 150 个稳定状态下的样本用于建立 MIDPL 状态模型。退化实验每个监测样本长度为 500 000,从中截取 80 个长度为 2 500 的振动序列用于训练。考虑到本文的齿轮退化实验只有 1 个振动测点,建立 MIDPL 模型时采用两个观测,即原始的时域观测以及频谱观测。对于点蚀数据集,组成单个 MIDPL 模型样本的两个观测如图 8 所示。考虑到频谱观测中状态信息主要处在频谱的前半部分,与时域观测拼接时截取频谱前 600 个(即 12 000 Hz 以下)数据点。

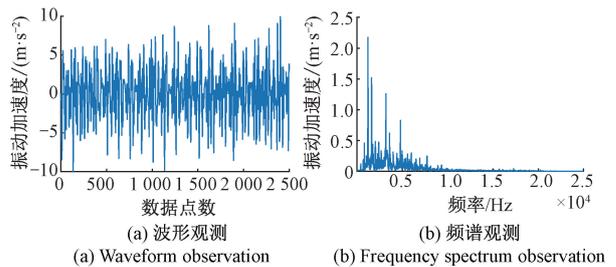


图 8 点蚀数据集的波形和频谱观测

Fig. 8 Waveform and frequency spectrum observations for pitting dataset

本文中初始分布是维度为 3 100 的多维高斯分布,即维度为各观测长度之和。MIDPL 模型中仿射变换层数为 10 层,每层仿射变换中一半的数据不做变换,另一半按图 2 所示进行变换,神经网络大小为 1 024×1 024。每个训练步长内随机选取 32 个样本优化模型,总训练步长为 10 000。测试样本涵盖所有监测样本编号,基于

MIDPL 的两组数据的状态评估结果如图 9 所示。

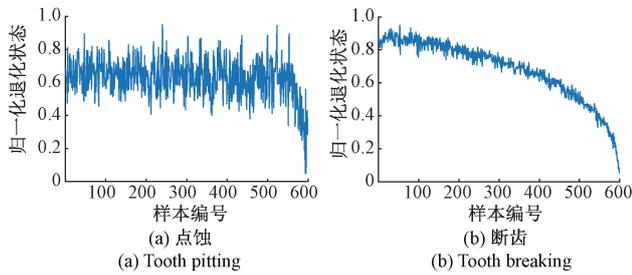


图 9 基于 MIDPL 的齿轮退化状态评估

Fig. 9 Gear degeneration evaluation using MIDPL

由图 9 可知,相较于传统特征提取,本文所提出的 MIDPL 可以实现更为准确的退化状态评估。对于点蚀,基于 MIDPL 的评估方法在准确识别齿轮退化趋势的同时避免了图 6(c) 中的前期波动。对于断齿,与图 7(c) 相比,基于 MIDPL 的退化状态评估更为准确。

3.4 与其他方法的对比

针对两组数据集,采用主流退化状态评估方法的结果如图 10 所示。本文采用了隐马尔可夫模型(hidden Markov model, HMM)、DBN、VAE 三种对比方法。HMM 与 DBN 的对比流程及主要参数参考文献[21],VAE 的流程和主要参数参考文献[15]。由 3.3 节内容可知断齿的退化趋势较点蚀明显。

HMM 隐状态数为 2,混合高斯函数个数为 3,观测序列长度为 20。HMM 用于点蚀数据集时由于无法得到有效的模型损失,不能完成参照模型的建立及优化。因此 HMM 无法进行点蚀数据集的退化状态评估,此现象可能是由点蚀数据集退化趋势不明显且 HMM 无法基于联合观测进行隐含状态信息的挖掘所致。HMM 应用于断齿数据集时在后期样本上也一定程度上存在此问题,如图 10(a) 所示后期样本编号下无退化指标的现象,但整体而言 HMM 能基本完成断齿退化过程的刻画。

DBN 隐含层数为 2 层,每层节点数为 50。DBN 则在两组数据集下均表现不佳。VAE 隐空间数为 3,编码器网络尺寸为 $256 \times 64 \times 6$,解码器网络尺寸为 $32 \times 256 \times 6$ 。VAE 可以较为准确地描述点蚀及断齿的退化趋势。

图 10 中基于 VAE 的退化评估结果与图 9 中基于 MIDPL 的评估结果较为接近,因此对二者进行量化对比分析。通过 7 次多项式拟合方法对点蚀、断齿数据集下 MIDPL、VAE 的退化评估结果进行对比,如图 11 所示。图 11 中浅色线条为原始状态评估结果,深色线条为 7 次多项式拟合趋势。计算各原始状态评估结果与相应的拟合趋势之间的均方误差,如表 3 所示。从表 3 可以看出,MIDPL 具有较小的评估误差,与 VAE 相比,MIDPL 在点

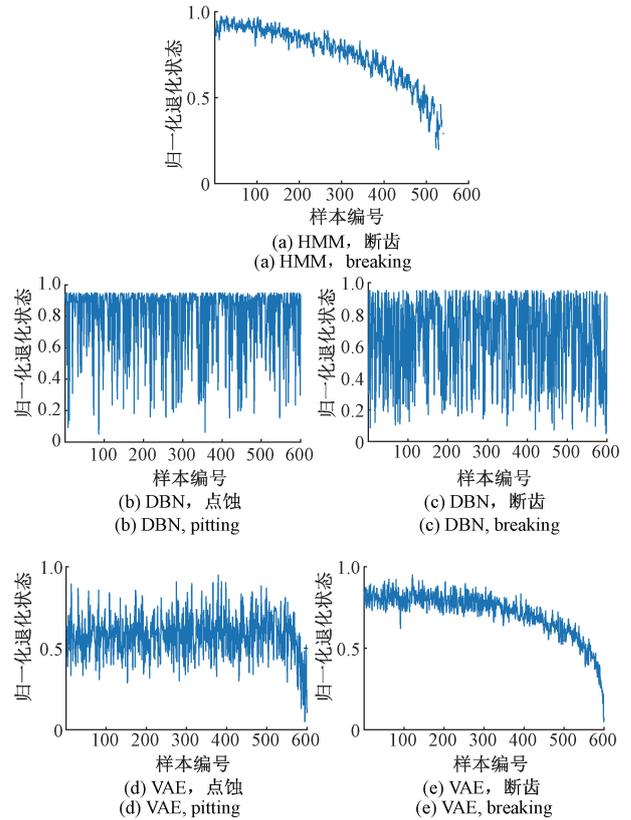


图 10 基于 HMM、DBN、VAE 的齿轮退化状态评估

Fig. 10 Gear degeneration evaluation using HMM, DBN and VAE

蚀和断齿数据集下的评估误差分别降低了 30.92% 和 69.25%,因此,基于 MIDPL 的评估结果对退化过程的刻画更为稳定和准确。

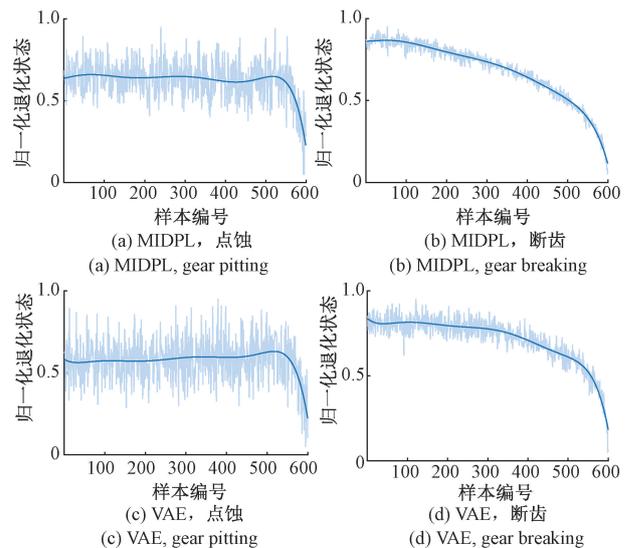


图 11 MIDPL 与 VAE 7 次多项式拟合对比

Fig. 11 Comparison between MIDPL and VAE by using the 7-order polynomial fitting

表3 归一化退化状态与拟合趋势间的均方误差

Table 3 Mean-square errors between normalized degeneration indicators and the fitting results

| | 点蚀数据集 | 断齿数据集 |
|-------|---------|---------------------------|
| MIDPL | 0.010 5 | $7.071\ 5 \times 10^{-4}$ |
| VAE | 0.015 2 | 0.002 3 |

本文针对 DBN 和 VAE 进一步进行了基于单独频谱观测的断齿退化状态评估,结果如图 12 所示,此处 VAE 解码器网络尺寸为 $32 \times 256 \times 1\ 200$ 。对于 DBN,与图 10(c) 相比图 12(a) 可以准确的描述断齿退化过程。对于 VAE,由图 12(b) 可知 VAE 在单独频谱观测下的退化状态评估表现明显优于图 10(e) 的联合观测。时域波形观测是原始观测,频谱观测与之相比是更为结构化的特征观测。DBN、VAE 等方法对数据要求较高,在联合观测下的性能较差可能是由其难以基于联合观测实现准确的退化状态评估所致。

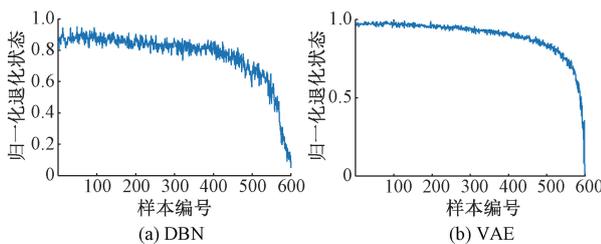


图 12 基于频谱观测的 DBN、VAE 的齿轮断齿退化状态评估

Fig. 12 Gear breaking degeneration evaluation based on frequency spectrum observation using DBN and VAE

VAE 与本文的 MIDPL 模型同为生成模型,但进行优化的方式不同。VAE 不能直接进行目标边缘概率的计算,而是通过变分下界的方式间接地实现参照模型的优化和状态指标的计算。其在处理联合观测下的退化评估时会引起参照模型和后续状态指标的不准确。本文提出的 MIDPL 通过可逆变换实现从已知分布到复杂未知分布的转换,可以有效处理多观测间的联合分布问题并实现准确的退化状态评估。

4 结 论

针对现有齿轮退化状态评估方法效果差的缺点,本文提出了 MIDPL 并在此基础上提出了基于 MIDPL 的齿轮退化状态评估方法。MIDPL 的原理为,通过一系列可以被优化的仿射变换实现从已知初始分布到复杂振动监

测序列的可逆变换;基于多个观测以充分学习振动监测多参数间的联合分布特性,将复杂多观测联合分布变换至已知分布下进行边缘概率计算继而实现准确的退化状态评估。本文通过齿轮退化实验制备的点蚀和断齿两组数据集验证了 MIDPL 的有效性,并通过与其他主流方法对比证明了其的优点。本文着重利用了 MIDPL 的逆向过程,后续工作中将探究其正向过程在故障诊断即状态评估领域内的应用。本文中齿轮退化评估的对象为实验台,MIDPL 在实际齿轮退化案例的应用研究也是后续研究方向之一。

参考文献

- [1] 李辉,郝如江. 基于循环多核相关熵的故障检测方法及应用[J]. 仪器仪表学报,2020,41(5):252-260.
LI H, HAO R J. Fault detection method based on cyclic multiple kernel correntropy and its application [J]. Chinese Journal of Scientific Instrument, 2020, 41(5): 252-260.
- [2] 孔子迁,邓蕾,汤宝平,等. 基于时频融合和注意力机制的深度学习行星齿轮箱故障诊断方法[J]. 仪器仪表学报,2019,40(6):221-227.
KONG Z Q, DENG L, TANG B P, et al. Fault diagnosis of planetary gearbox based on deep learning with time-frequency fusion and attention mechanism [J]. Chinese Journal of Scientific Instrument, 2019, 40(6): 221-227.
- [3] QIN Y, XIANG S, CHAI Y, et al. Macroscopic-microscopic attention in lstm networks based on fusion features for gear remaining life prediction [J]. IEEE Transactions on Industrial Electronics, 2020, 67(12): 10865-10875.
- [4] ZHANG H, CHEN X, CHEN W, et al. Collaborative sparse classification for aero-engine's gear hub crack diagnosis [J]. Mechanical Systems and Signal Processing, 2019, 141:106426.
- [5] 陈是扞,彭志科,周鹏. 信号分解及其在机械故障诊断中的应用研究综述[J]. 机械工程学报,2020,56(17): 91-107.
CHEN SH Q, PENG ZH K, ZHOU P. Review of signal decomposition theory and its applications in machine fault diagnosis [J]. Journal of Mechanical Engineering, 2020, 56(17): 91-107.
- [6] KUMAR A, GANDHI C P, ZHOU Y Q, et al. Latest developments in gear defect diagnosis and prognosis: A

- review [J]. *Measurement*, 2020, 158: 107735.
- [7] 古莹奎, 曾磊, 张敏, 等. 基于 CEEMDAN-SQI-SVD 的齿轮箱局部故障特征提取[J]. *仪器仪表学报*, 2019, 40(5): 78-88.
- GU Y K, ZENG L, ZHANG M, et al. Feature extraction method for gearbox local fault based on CEEMDAN-SQI-SVD [J]. *Chinese Journal of Scientific Instrument*, 2019, 40(5): 78-88.
- [8] 丁显, 徐进, 滕伟, 等. 基于无参数经验小波变换的风电齿轮箱故障特征提取[J]. *振动与冲击*, 2020, 39(8): 99-105, 117.
- DING X, XU J, TENG W, et al. Fault feature extraction of a wind turbine gearbox using adaptive parameterless empirical wavelet transform [J]. *Journal of Vibration and Shock*, 2020, 39(8): 99-105, 117.
- [9] QIN Y, MAO Y F, TANG B P, et al. M-band flexible wavelet transform and its application to the fault diagnosis of planetary gear transmission systems [J]. *Mechanical systems and signal processing*, 2019, 134: 106298.
- [10] LI C, ZHANG S, QIN Y, et al. A systematic review of deep transfer learning for machinery fault diagnosis [J]. *Neurocomputing*, 2020, 407: 121-135.
- [11] LI F, PANG X, YANG Z. Motor current signal analysis using deep neural networks for planetary gear fault diagnosis [J]. *Measurement*, 2019, 145: 45-54.
- [12] YAN H, QIN Y, XIANG S, et al. Long-term gear life prediction based on ordered neurons LSTM neural networks [J]. *Measurement*, 2020, 165: 108205.
- [13] 汤宝平, 熊学嫣, 赵明航, 等. 多共振分量融合 CNN 的行星齿轮箱故障诊断 [J]. *振动. 测试与诊断*, 2020, 40(3): 507-512, 625.
- TANG B P, XIONG X Y, ZHAO M H, et al. A multi-resonance component fusion based convolutional neural network for fault diagnosis of planetary gearboxes [J]. *Journal of Vibration, Measurement & Diagnosis*, 2020, 40(3): 507-512, 625.
- [14] 陈保家, 刘浩涛, 徐超, 等. 深度置信网络在齿轮故障诊断中的应用 [J]. *中国机械工程*, 2019, 30(2): 205-211.
- CHEN B J, LIU H T, XU CH, et al. Gear fault diagnosis based on DBNS [J]. *China Mechanical Engineering*, 2019, 30(2): 205-211.
- [15] 尹爱军, 王昱, 戴宗贤, 等. 基于变分自编码器的轴承健康状态评估 [J]. *振动·测试与诊断*, 2020, 40(5): 1011-1016, 1030.
- YIN AI J, WANG Y, DAI Z X, et al. Evaluation method of bearing health state based on variational auto-encoder [J]. *Journal of Vibration, Measurement & Diagnosis*, 2020, 40(5): 1011-1016, 1030.
- [16] KINGMA D P, WELING M. Auto-encoding variational bayes [C]. *International Conference on Learning Representations*, 2014: 1-14.
- [17] KOBYZEV I, PRINCE S, BRUBAKER M. Normalizing flows: An introduction and review of current methods [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2020, DOI: 10.1109/TPAMI.2020.2992934.
- [18] PAPAMAKARIOS G, NALISNICK E, REZENDE D J, et al. Normalizing flows for probabilistic modeling and inference [J]. *ArXiv Preprint*, 2019: 1-60.
- [19] PAPAMAKARIOS G, PAVLAKOU T, MURRAY I. Masked autoregressive flow for density estimation [C]. *Advances in Neural Information Processing Systems*, 2017: 2338-2347.
- [20] DINH L, SOHL-DICKSTEIN J, BENGIO S. Density estimation using real NVP [C]. *International Conference on Learning Representations*, 2017: 1-32.
- [21] 李江. 基于流形空间主曲线相似度的状态评估方法研究 [D]. 重庆: 重庆大学, 2017.
- LI J. Research on state evaluation based on similarity analysis of principal curves in manifold space [D]. Chongqing: Chongqing University, 2017.

作者简介



任宏基, 2013 年于重庆大学获得学士学位, 2016 年于重庆大学获得硕士学位, 现在重庆大学攻读博士学位, 主要研究方向为故障诊断与智能信息处理。

E-mail: adm@cqu.edu.cn。

Ren Hongji received his B.Sc. degree and M.Sc. degree both from Chongqing University in 2013 and 2016, respectively. He is currently pursuing his Ph.D. degree at Chongqing University. His current research interests include fault diagnosis and intelligent information processing.



尹爱军(通信作者),2001年于重庆大学获得学士学位,2003年于重庆大学获得硕士学位,2006年于重庆大学获得博士学位,现为重庆大学机械工程学院教授,主要研究方向为机器视觉与图像处理、机器学习、智能诊断与仪器、信号处理、故障诊断。

E-mail: aijun.yin@cqu.edu.cn

Yin Aijun (Corresponding author) received his B. Sc., M. Sc. and Ph. D. degrees all from Chongqing University in 2001, 2003, and 2006, respectively. He is currently a professor with the College of Mechanical Engineering at Chongqing University. His current research interests include machine vision and image processing, machine learning, intelligent test and instruments, nondestructive testing and evaluation, modern signal

analysis and processing, and fault detection and diagnosis.



陈义,2013年于河北工程大学获得学士学位,2016年于重庆大学获得硕士学位,现为重庆电子工程职业学院智能制造与汽车学院工程师,主要研究方向为智能制造与工业工程。

E-mail: 412492751@qq.com

Chen Yi received his B. Sc. degree from Hebei University of Engineering in 2013, and received his M. Sc. degree from Chongqing University in 2016. He is currently an engineer with the Intelligent Manufacturing and Automobile School at Chongqing College of Electronic Engineering. His current research interests include intelligent manufacturing and industrial engineering.