

DOI: 10.19650/j.cnki.cjsi.J1905247

# 基于 T-SNE 样本熵和 TCN 的滚动轴承状态退化趋势预测\*

于重重<sup>1</sup>, 宁亚倩<sup>1</sup>, 秦勇<sup>2</sup>, 高柯柯<sup>1</sup>

(1. 北京工商大学计算机与信息工程学院 北京 100048;

2. 北京交通大学轨道交通控制与安全国家重点实验室 北京 100044)

**摘要:**为了能够尽早发现滚动轴承开始出现显著退化的临界状态,精准预测滚动轴承的状态退化趋势,提出了 T-分布随机近邻嵌入(T-SNE)样本熵状态退化特征指标和基于时间卷积网络(TCN)的轴承状态退化趋势预测方法。首先利用 T-SNE 算法提取原始振动信号的低维流形特征,再计算低维流形特征的样本熵作为状态退化特征,最后基于历史状态退化特征通过 TCN 算法预测轴承的状态退化趋势。实验结果表明,相较于传统特征指标,T-SNE 样本熵特征指标能够至少提前 50 min 发现滚动轴承开始出现显著退化的临界状态,且 TCN 算法的预测误差仅为 0.45%,具有较高的工程应用价值。

**关键词:** T-分布随机近邻嵌入;样本熵;时间卷积网络;滚动轴承;状态退化趋势预测

**中图分类号:** TH165.3 TN911.2 **文献标识码:** A **国家标准学科分类代码:** 510.40

## Prediction of rolling bearing state degradation trend based on T-SNE sample entropy and TCN

Yu Chongchong<sup>1</sup>, Ning Yaqian<sup>1</sup>, Qin Yong<sup>2</sup>, Gao Keke<sup>1</sup>

(1. School of Computer and Information Engineering, Beijing Technology and Business University, Beijing 100048, China;

2. State Key Lab of Rail Traffic Control and Safety, Beijing Jiaotong University, Beijing 100044, China)

**Abstract:** To early discover the critical degradation status of rolling bearing and predict its degradation trend, T-distributed stochastic neighbor embedding (T-SNE) sample entropy state degradation feature index and the prediction method based on time convolutional network (TCN) are proposed. Firstly, the low-dimensional manifold features of original vibration signal are extracted by T-SNE algorithm. Then, sample entropy of low-dimensional manifold features are calculated as the status degradation. Finally, the degradation trend of the bearing is predicted by the TCN algorithm based on features of historical status degradation. Compared with traditional feature index, experimental results show that the T-SNE sample entropy feature index can detect the critical status of the bearing degradation significantly at least 50 minutes ahead of time and the prediction error of the TCN algorithm is only 0.45%. These results have high application values in engineering.

**Keywords:** T-distributed stochastic neighbor embedding(T-SNE); sample entropy; time convolutional network(TCN); rolling bearing; state degradation trend prediction

## 0 引言

滚动轴承作为大多数旋转机械设备的重要部件之一<sup>[1]</sup>, 现已被广泛应用于各行各业中。由于滚动轴承具有易失效、损坏频率高等特点,且失效或损坏时极易导致设备损坏,故而精准预测滚动轴承的状态退化趋势对实际生产具有重要的意义<sup>[2]</sup>。

滚动轴承从健康状态退化为失效状态的整个退化过程分为正常阶段和显著退化阶段<sup>[3]</sup>。正常阶段和显著退化阶段的分界点即为开始出现显著退化的临界状态点,在本文中将其定义为信号幅值首次高于或低于正常阶段幅值阈值 5% 的点。提取准确的状态退化特征<sup>[4]</sup>并建立符合滚动轴承特点的预测模型是滚动轴承状态退化趋势预测的关键,所提取的状态退化特征除能反映滚动轴承的状态退化趋势外还应能尽早发现滚动轴承开始出现显

收稿日期:2019-06-09 Received Date:2019-06-09

\* 基金项目:国家重点研发计划重点专项(2018YFC0807900, 2018YFC0807903)资助

著退化的临界状态。目前,针对滚动轴承的振动信号提取其状态退化特征并采用数据驱动的预测模型进行故障诊断或状态退化趋势预测取得了良好的效果<sup>[5]</sup>。Rai等<sup>[6]</sup>提出一种基于自组织映射的滚动轴承性能退化指标自组织映射-最小量化误差演化(self-organising map-minimum quantization error evolution, SOM-MQEE),利用该指标获取轴承健康指数,输入后向支持向量回归预测模型,实现轴承的剩余使用寿命预测,该指标依赖于对故障敏感的时域和频域特征。Zhang等<sup>[7]</sup>利用长短时记忆递归神经网络(long short-term memory recurrent network, LSTMRNN)时间序列模型识别轴承的退化状态,将振动信号的波形熵作为状态退化指标,通过实验表明该指标能全面反映轴承的退化状态,但无法模拟轴承退化过程中的随机突变。Lu等<sup>[8]</sup>针对现有轴承退化预测模型仅适用于特定工作条件下的轴承这一问题,提出一种结合了变量遗忘因子递归最小二乘和自回归移动平均模型的自适应轴承退化趋势预测算法,经验证该模型能准确的预测轴承退化趋势。但该模型的建立十分依赖实时监测到的轴承振动信号,若误将噪声当作振动信号输入可能导致模型输出产生较大的偏差。Yu等<sup>[9]</sup>提出一种复合加权核极值学习机预测模型,输入各熵特征后通过显式和隐式加权增强各样本表征不同退化状态的能力,获得了较高的预测精度。

基于信息熵理论的特征提取算法所提取的滚动轴承退化特征能够很好的表征滚动轴承的退化趋势,其中包括能量谱熵<sup>[10]</sup>、排列熵<sup>[11]</sup>、多尺度熵<sup>[12]</sup>、多尺度排列熵<sup>[13-14]</sup>和模糊熵<sup>[15]</sup>等。样本熵是由Richman和Moorman于2000年提出的,该方法对噪声的敏感性较低,且具有较强的抗干扰能力。Chen等<sup>[16]</sup>提出了一种基于样本熵和深度神经网络的BBS帖子时间序列建模和预测方法,利用样本熵能够度量时间序列复杂性的特点来提高时间序列的预测性能。李永健等<sup>[17]</sup>利用改进的多尺度样本熵(improved multiscale sample entropy, IMSE)方法提取具有非线性和非平稳性的轴承振动信号特征,以揭示时间序列振动信号中蕴含的关键状态信息,通过实验表明了IMSE方法具有优异的性能。T-分布随机近邻嵌入(T-distributed stochastic neighbor embedding, T-SNE)算法是由Maaten和Hinton于2008年提出用于可视化高维数据的一种非线性流形学习算法<sup>[18]</sup>。Zhou等<sup>[19]</sup>利用T-SNE算法对局部特征分解-样本熵算法提取的特征向量进行降维,实验结果表明T-SNE降维后故障诊断的准确性得到了提高,即表明了T-SNE算法的有效性。Li等<sup>[20]</sup>采用稀疏滤波与T-SNE混合的方法提取原始振动信号中的故障特征,并通过实例证明了该方法具有较强的特征提取能力。在现有工作中,T-SNE算法多用于对自原始信号中提取到的高维特征进行降维处理,结合了T-SNE算法

的特征提取方法表现出优越的性能,鲜有将T-SNE算法直接用于提取滚动轴承原始振动信号的流形特征后基于流形特征提取其时域、频域或时频域信号特征的方法。

综上所述,诸多提取滚动轴承退化特征的方法未从原始振动信号的时间序列特性出发进行退化特征提取与退化趋势预测建模。本文旨在以滚动轴承的原始时间序列振动信号为研究对象,提出一种将T-SNE算法与样本熵结合的状态退化特征提取算法,该算法首先通过分段构造原始时间序列数据的高维振动数据,再利用T-SNE算法降维获取低维流形特征,之后计算样本熵后获取时序状态特征,最后将所提取的状态退化特征输入时间卷积网络(temporal convolutional network, TCN)预测滚动轴承的状态退化趋势,通过公开的滚动轴承数据集验证了所提方法。

## 1 基于T-SNE样本熵的状态特征提取方法

### 1.1 T-SNE流形学习

滚动轴承工作环境的复杂性和不确定性决定了时间序列数据样本的高度非线性,常规时间序列特征提取算法已经无法获取时间序列样本数据的内蕴低维时序特征。流形学习算法旨在发现数据样本蕴含在高维空间的低维流形结构,该算法假设输入数据位于嵌入到高维欧氏空间的某低维流形,再利用高维输入数据恢复低维流形结构,求得相应的低维嵌入映射,其学习过程的数学描述如下:对于样本集 $\mathbf{X} = \{x_1, x_2, \dots, x_n\} \subset \mathbf{R}^D$ ,在一定约束条件下获得其低维映射 $\mathbf{Y} = \{y_1, y_2, \dots, y_n\} \subset \mathbf{R}^d$ ,其中,样本集 $\mathbf{X}$ 采样于 $D$ 维空间的某一 $d(d < D)$ 维流形。

T-SNE算法将欧氏距离转化为条件概率来表征数据点之间的相似度,并假设高维数据服从高斯分布,低维数据服从T分布。该算法以尽可能的保持高维数据与低维数据邻域分布特性一致为目标,采用(Kullback-Leibler(KL))散度衡量两分布间的差异,并通过梯度下降法最小化分布差异。算法具体步骤如下:

1) 给定高维样本数据 $\mathbf{X} = \{x_1, x_2, \dots, x_n\}$ ,任意两个样本数据点 $x_i$ 和 $x_j$ 相似的条件概率为:

$$P_{ji} = \frac{\exp(-\|x_i - x_j\|^2/2\delta_i^2)}{\sum_{k \neq i} \exp(-\|x_i - x_k\|^2/2\delta_i^2)} \quad (1)$$

式中: $\delta_i$ 为以 $x_i$ 为中心点的高斯分布方差,可根据用户指定的困惑度 $Perp$ 经二分搜索确定,困惑度定义为:

$$Perp(P_i) = 2^{-\sum P_{ij} \log_2 P_{ij}} \quad (2)$$

2) 计算高维样本数据的联合概率密度:

$$P_{ij} = \frac{P_{ji} + P_{nj}}{2n} \quad (3)$$

3) 初始化低维数据解 $y^{(0)} = \{y_1, y_2, \dots, y_n\}$ 。

4) 计算低维数据相似度:

$$q_{ij} = \frac{(1 + \|y_i - y_j\|^2)^{-1}}{\sum_{k \neq l} (1 + \|y_k - y_l\|^2)^{-1}} \quad (4)$$

5) 使用  $KL$  散度量高维数据分布  $P$  和低维数据分布  $Q$  的相似度:

$$C = KL(P \| Q) = \sum_i \sum_j p_{ij} \log \frac{p_{ij}}{q_{ij}} \quad (5)$$

6) 计算梯度:

$$\frac{\delta_c}{\delta_{y_i}} = 4 \sum_j (p_{ij} - q_{ij})(y_i - y_j)(1 + \|y_i - y_j\|^2)^{-1} \quad (6)$$

7) 获取低维数据:

$$y^{(t)} = y^{(t-1)} + \eta \frac{\delta C}{\delta y} + \alpha(t)(y^{(t-1)} - y^{(t-2)}) \quad (7)$$

式中:  $\eta$  为学习率; 动量  $\alpha(t)$  为优化参数;  $t$  表示第  $t$  次迭代。

8) 重复步骤 4)~7), 直到满足迭代次数  $T$ , 经  $T$  次迭代得到低维数据  $y^{(T)} = \{y_1, y_2, \dots, y_n\}$ 。

### 1.2 样本熵

样本熵是一种通过度量信号中产生新模式的概率大小来衡量时间序列复杂性的方法, 其计算不依赖数据长度且具有更好的一致性。对于给定时间序列  $X = \{x_1, x_2, \dots, x_N\}$ , 样本熵计算方法如下:

1) 将原始时间序列重构为  $m$  维的向量序列:

$$X_i^m = \{x(i), x(i+1), \dots, x(i+m-1)\}, \quad 1 \leq i \leq N-m+1 \quad (8)$$

2) 计算向量  $X_i^m$  与  $X_j^m$  之间的距离:

$$d_{ij}^m = d[X_i^m, X_j^m] = \max_{k \in (0, m-1)} (|x(i+k) - x(j+k)|) \quad (9)$$

3) 给定相似容限  $r$ , 当  $d_{ij}^m \leq r$  时, 认为  $X_i^m$  和  $X_j^m$  为匹配向量对, 统计  $m$  维下匹配向量对的个数, 记为  $A^m$ 。

4) 增加维数至  $m+1$ , 重复步骤 1)~3), 计算匹配度向量对的数量, 记为  $A^{m+1}$ 。

5) 有限长度时间序列的样本熵定义如下:

$$SampEn(X, m, r, N) = \ln A^m - \ln A^{m+1} \quad (10)$$

### 1.3 T-SNE 样本熵状态特征提取

滚动轴承的振动信号中含有丰富的隐藏信息, 为了获得能够准确表征滚动轴承运行状态的特征信息, 本文提出一种将 T-SNE 流形学习算法与样本熵结合的状态特征提取方法。该方法的基本流程如图 1 所示, 主要包括轴承全寿命周期振动信号获取与分段、T-SNE 流形特征提取、求取样本熵和平滑处理 4 部分。

1) 轴承全寿命周期振动信号获取与分段

采用实时监测的方法获取滚动轴承全寿命周期的振

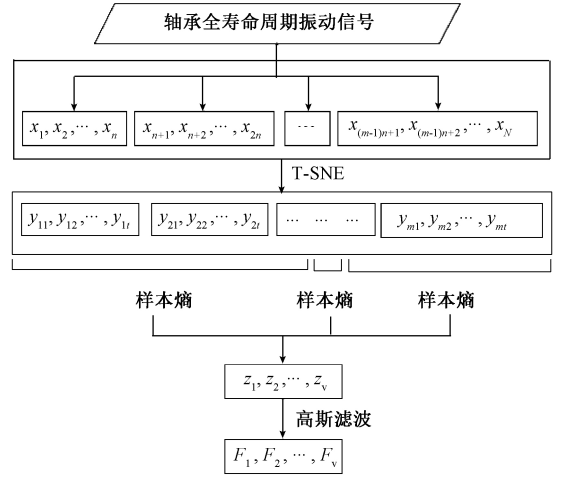


图 1 T-SNE 样本熵状态特征提取流程

Fig.1 Process of extracting T-SNE sample entropy status features

动信号, 所获振动信号为离散时间序列数据, 用  $X = \{x_1, x_2, \dots, x_N\}$  表示。将信号按序平均分为  $m$  段并构成  $m \times n (n = N/m)$  维矩阵  $A$ 。

$$A = \begin{bmatrix} x_1 & x_2 & \dots & x_n \\ x_{n+1} & x_{n+2} & \dots & x_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ x_{(m-1)n+1} & x_{(m-1)n+2} & \dots & x_N \end{bmatrix}$$

此特征提取过程实质上也是降维的过程, 本文中为  $n$  维降为  $t$  维。分段时, 应综合考虑特征提取过程中计算量的大小和信号特征的保留程度, 以降低计算量的同时很好的保留信号特征为目标, 经过反复测试确定  $m$  的值。

2) T-SNE 流形特征提取

通过 T-SNE 算法提取矩阵  $A$  的  $t$  维流形特征并构成  $m \times t$  维矩阵  $B$ 。

$$B = TSNE(A) = \begin{bmatrix} y_{11} & y_{12} & \dots & y_{1t} \\ y_{21} & y_{22} & \dots & y_{2t} \\ \vdots & \vdots & \ddots & \vdots \\ y_{m1} & y_{m2} & \dots & y_{mt} \end{bmatrix}$$

3) 求取样本熵

按序取出矩阵  $B$  中的所有行向量构成一维时间序列, 再按序不重复的取出时间序列中的数据, 对所取的每段数据求取其样本熵, 并将所得样本熵按相应顺序排列即可得到原始数据的初始 T-SNE 样本熵状态特征向量  $\{z_1, z_2, \dots, z_v\}$ 。

4) 平滑处理

对所得初始 T-SNE 样本熵状态特征向量利用高斯滤

波法去除噪声并进行平滑处理,最后得到轴承全寿命周期的 T-SNE 样本熵状态特征向量  $\{F_1, F_2, \dots, F_v\}$ 。

## 2 基于 T-SNE 样本熵和 TCN 的滚动轴承状态退化趋势预测

### 2.1 时间卷积网络

Bai 等<sup>[21]</sup>首次提出用于序列建模的时间卷积网络,其实质是将一维卷积“时序化”,即由一维卷积结合多种卷积方法产生更适用于时间序列数据的卷积网络。TCN 是由结合了扩张卷积和因果卷积的残差模块堆叠而成,残差模块的结构如图 2 所示。每个残差模块中包含两层扩张因果卷积,并对卷积核的权重进行了归一化处理,通过激活函数修正线性单元 (rectified linear unit, ReLU) 增加卷积层间的非线性关系,添加 Dropout 防止过拟合。其核心思想包括因果卷积、一维全卷积、扩张卷积和残差连接,具体如下:

#### 1) 因果卷积

TCN 通过因果卷积<sup>[22]</sup>使卷积存在因果关系,即不会产生从未来到过去的信息“泄漏”,从而使预测精度更高。假设模型输入序列为  $\{x_0, x_1, \dots, x_T\}$ ,期望的预测输出为  $\{y_0, y_1, \dots, y_T\}$ ,因果卷积使得  $t$  时刻的输出预测值  $y_t$  仅由  $\{x_0, x_1, \dots, x_t\}$  决定,不受  $\{x_{t+1}, x_{t+2}, \dots, x_T\}$  的影响。

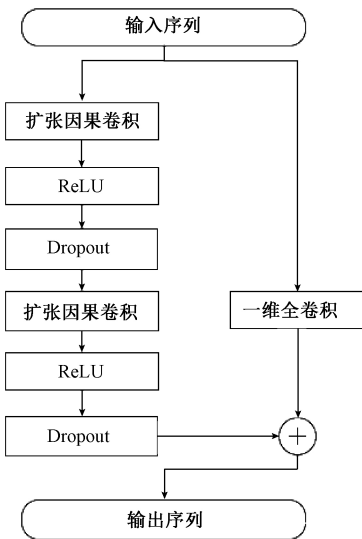


图 2 残差模块结构

Fig.2 Structure diagram of the residual module

#### 2) 一维全卷积

TCN 使用一维全卷积<sup>[23]</sup>产生与输入序列等长的输出序列,能够保留整个输入序列数据包含的信息,从而有利于构建长期记忆。

#### 3) 扩张卷积

TCN 采用扩张卷积以获得更大的感受野。对于一维序列  $x \in R^n$  和卷积核  $f: \{0, 1, \dots, k-1\} \rightarrow R$ , 序列元素  $s$  上的扩张卷积运算  $F$  定义为:

$$F(s) = \sum_{i=0}^{k-1} f(i) \cdot x_{s-d \cdot i} \quad (11)$$

式中:  $d$  为扩张系数;  $k$  为卷积核大小;  $(s - d \cdot i)$  表示采用上层的第  $(s - d \cdot i)$  个元素。

由式(11)可知,增大卷积核大小  $k$  或增加扩张系数  $d$  均可以增大网络的感受野,通常第  $i$  层网络的扩张系数为:

$$d = O(2^i) \quad (12)$$

#### 4) 残差连接

TCN 通过残差连接保证了深层网络的准确度。输入为  $x$ , 输出为  $y$  的残差模块定义如下:

$$y = H(x, W) + x \quad (13)$$

式中:  $H$  表示一系列卷积运算函数;  $W$  为卷积核的权重矩阵。

由式(13)可知,残差模块的输出结合了输入信息与卷积运算的输出信息,从而保证了深层 TCN 网络模型的准确度。

### 2.2 基于 T-SNE 样本熵和 TCN 的状态退化趋势预测

所提出的基于 T-SNE 样本熵和 TCN 的滚动轴承状态退化趋势预测方法具体步骤为:

1) 获取轴承的振动信号,并提取 T-SNE 样本熵状态特征,将其划分为训练集和测试集;

2) 初始化 TCN 网络的权重,设置迭代次数、残差模块的个数即网络层数、扩张系数、卷积核大小、学习率及隐层神经元个数等参数;

3) 以批量的方式将训练数据输入 TCN 网络,计算有效历史长度的输出误差,并将误差反向传播以更新网络参数;

4) 重复步骤 3),直到网络精度满足要求或达到迭代次数,完成训练;

5) 输入测试数据输出预测结果,实现轴承的状态退化趋势预测。

## 3 实例分析

### 3.1 实验数据

采用美国密西根大学的智能维修中心 (center for intelligent maintenance systems, IMS) 实测的滚动轴承全生命周期振动数据对本文所提方法进行验证,轴承实验台如图 3 所示,安装了 4 个 RexnordZA-2 115 双列轴承,始终保持在 2 000 rpm 的转速,并通过弹簧系统向轴和轴承施加 2 721.5 kg 的径向载荷。采样频率为 20 kHz,采

集间隔为 10 min,每次采集 1 s 的数据共 20 480 个点。在相同的实验条件下做了 3 组实验,每组采集 4 个轴承从开始运行直到失效的全寿命周期振动信号。





图 3 全寿命数据采集实验台

Fig.3 Experiment platform full-life data acquisition

第 2 组实验中轴承 1 在运行到第 7 天时失效,失效原因是外圈故障,本文采用该轴承的全寿命周期振动信号完成分析。截至第 2 组实验轴承 1 失效,共采集了 984 个样本,即采集了 984×20 480 个数据点,且所有数据点均是时间序列数据。


### 3.2 基于 T-SNE 样本熵的滚动轴承状态特征提取

均方根值 (root mean square, RMS) 和峭度因子是最常见的能够有效反映滚动轴承振动状态变化的时域特征,为了验证 T-SNE 流形学习对于状态特征提取的必要性和 T-SNE 样本熵状态特征提取的有效性,本文提取了滚动轴承全生命周期的 RMS 特征、峭度因子特征、局部均值分解 (local mean decomposition, LMD) PF1 归一化能量熵特征和样本熵特征,还提取了滚动轴承全寿命周期的 T-SNERMS 特征、T-SNE 峭度因子特征和 T-SNE 样本熵特征,并做了相应比较。在提取 RMS 和峭度因子等特征时,对数据做与 T-SNE 样本熵特征提取过程相同的分段处理。实验中提取 T-SNE 样本熵状态特征的具体步骤为:首先对 984×20 480 个数据点分段并将每段数据作为一个行向量按序构成  $m \times n$  维矩阵,经过测试取分段数  $m = 984 \times 512$ ,即分段后每段数据包含 40 个数据点 ( $n = 40$ );然后利用 T-SNE 算法提取流形特征,流形特征维数  $t = 2$ ,即将  $m \times 40$  维矩阵降维至  $m \times 2$ ;接着取出  $m \times 2$  维矩阵中的所有行向量并按序排列构成一维时间序列,则此一维时间序列共包含  $m \times 2 = 984 \times 512 \times 2$  个数据点,按序对每 512 个数据点求取样本熵,得到长度为  $v = 984 \times 2 = 1\ 968$  的初始 T-SNE 样本熵状态特征向量;最后利用高斯滤波法去除噪声并进行平滑处理,滤波窗口长度为 100。所提取的轴承全生命周期状态特征共包含 1 968 个状态点,提取结果如图 4~7 所示。



(a) RMS特征

(a) The RMS feature




(b) T-SNERMS特征

(b) The T-SNERMS feature


图 4 滚动轴承全寿命周期 RMS 状态特征

Fig.4 Full life cycle RMS status features of rolling bearing



(a) 峭度因子特征

(a) Kurtosis factor feature



(b) T-SNE峭度因子特征

(b) T-SNE Kurtosis factor feature

图 5 滚动轴承全寿命周期峭度因子状态特征

Fig.5 State features of kurtosis factor of rolling bearing

in its whole life cycle




图 6 滚动轴承全寿命周期 LMD 状态特征

Fig.6 Full life cycle LMD state features of rolling bearing




图7 滚动轴承全寿命周期样本熵状态特征

Fig.7 Entropy state features of rolling bearing samples during its whole life cycle

图4中,RMS特征在点1382(即第6910min)开始出现显著的状态退化,而经过流形学习的T-SNERMS特征在点1278(即第6390min)开始出现显著的状态退化,后者比前者早约8.6h发现滚动轴承开始出现显著退化的临界状态。图5中,峭度因子特征在点1281(即第6410min)开始出现显著的状态退化,而T-SNE峭度因子特征在点1264(即第6320min)开始出现显著的状态退化,后者比前者早约1.5h发现滚动轴承开始出现显著退化的临界状态。图6中,LMD分解PF1归一化能量熵特征在点1083(即第5420min)开始出现显著的状态退化。图7中,样本熵特征在点1290(即第6450min)开始出现显著的状态退化,而T-SNE样本熵特征在点1074(即第5370min)开始出现显著的状态退化,后者比前者早约18h发现滚动轴承开始出现显著退化的临界状态,且比图6中所示特征早约50min发现滚动轴承开始出现显著退化的临界状态。各特征开始出现显著状态退化的时刻对比如表1所示。

表1 不同特征出现临界状态的时刻对比

Table 1 Comparison of the critical state of different features

特征提取方法	开始出现显著状态退化的状态点	开始出现显著状态退化的时刻/min
RMS	1382	6910
T-SNERMS	1278	6390
峭度因子	1281	6410
T-SNE峭度因子	1264	6320
LMD分解PF1归一化能量熵	1083	5420
样本熵	1290	6450
T-SNE样本熵	1074	5370

经比较可知,经过T-SNE流形学习的特征能更早发现轴承显著退化的临界状态,且能很好的保留其状态退化趋势。在实际生产中,尽早发现滚动轴承开始出现显著退化的临界状态,就能尽早的采取措施,避免设备损坏造成更大的损失,故本文采用T-SNE样本熵作为滚动轴承的状态特征。

### 3.3 基于TCN的滚动轴承状态退化趋势预测

由上述方法提取T-SNE样本熵状态特征后,将其划分为训练集和测试集。考虑到尽早掌握滚动轴承退化状态对于视情维修十分重要,本文结合图7(b)所示的滚动轴承状态特征,将发现滚动轴承开始出现显著退化的临界状态后的状态作为测试集,即将原始状态特征数据集划分为55%的训练集和45%的测试集。

训练TCN网络时,设置最大迭代次数为100次,网络层数为4层,扩张因果卷积的卷积核大小为3,Dropout为0.45,滑动窗口长度为8,隐层神经元个数为8,学习率为4,采用随机梯度下降优化器。将训练数据输入模型后,计算预测数据与原始数据的均方误差并通过反向传播更新网络参数。训练完成后将测试数据输入训练好的模型对滚动轴承的状态退化趋势进行预测,预测结果如图8所示。由图8可看出,TCN算法的预测结果能够完全拟合滚动轴承的状态退化趋势,有很好的预测效果。




图8 基于TCN的滚动轴承状态退化趋势预测结果

Fig.8 Prediction result of TCN-based rolling bearing state degradation trend

为了定量分析本方法的优越性,在由T-SNE样本熵算法提取滚动轴承的状态特征后,使用在诸多时间序列预测问题上取得了很好效果的LSTM算法和GRU算法对滚动轴承的状态退化趋势进行预测。LSTM网络中,输入维数为8,隐层维数为8,输出维数为1。GRU网络中,输入维数为6,隐层维数为8,输出维数为1。LSTM和GRU均采用Adam优化器,最大迭代次数为100次,损失函数为均方误差函数。预测结果如图9和10所示,并使

用预测得到的均方根误差 (root mean squared error, RMSE) 对 3 种算法的预测结果进行比较, 如表 2 所示。




图 9 基于 LSTM 的滚动轴承状态退化趋势预测结果  
Fig.9 Prediction result of LSTM-based rolling bearing state degradation trend




图 10 基于 GRU 的滚动轴承状态退化趋势预测结果  
Fig.10 Prediction result of GRU-based rolling bearing state degradation trend

表 2 不同方法之间的误差对比

Table 2 Error comparison between different methods

预测方法	RMSE/%
LSTM	2.69
GRU	2.40
TCN	0.45

从图 9 和 10 中可以看出, 基于 LSTM 和 GRU 的预测方法均可实现滚动轴承状态退化趋势预测, 所得预测曲线均能较好的跟踪原始曲线, 且相较于 LSTM, 基于 GRU 的预测方法具有更好的跟踪效果。然而, 通过与图 8 所示 TCN 算法的预测结果对比可以发现基于 TCN 的滚动轴承状态退化趋势预测方法中预测曲线几乎可以完全覆盖原始数据的相应曲线, 具有非常高的预测精度, 对比表 2 中各方法的 RMSE 值也可以得出此结论。

## 4 结 论

本文重点考虑滚动轴承原始振动信号的时间序列特性, 针对滚动轴承的状态特征提取及退化趋势预测问题, 提出一种基于 T-分布随机近邻嵌入样本熵和时间卷积网络的滚动轴承状态退化趋势预测方法。首先, 该方法采用 T-SNE 算法提取滚动轴承全生命周期振动信号的低维流形特征, 然后计算其样本熵作为滚动轴承的状态特征, 所提取的状态特征较其他特征能更好的表征滚动轴承开始出现明显退化的临界状态。最后, 将状态特征输入 TCN, 构造预测模型实现对滚动轴承状态退化趋势的预测, 实验结果表明, TCN 算法能够非常精准的预测滚动轴承的状态趋势, 有利于早期发现潜在故障便于维护, 对视情维修具有指导意义。

## 参考文献

[ 1 ] WANG X L, GU H, XU L, et al. A SVR-based remaining life prediction for rolling element bearings[J]. Journal of Failure Analysis and Prevention, 2015, 15(4): 548-554.

[ 2 ] 李锋, 陈勇, 向往, 等. 基于量子加权长短时记忆神经网络的状态退化趋势预测[J]. 仪器仪表学报, 2018, 39(7): 217-225.

LI F, CHEN Y, XIANG W, et al. State degradation trend prediction based on quantum weighted long short-term memory neural network[J]. Chinese Journal of Scientific Instrument, 2018, 39(7): 217-225.

[ 3 ] LI Q, LIANG S Y. Degradation trend prognostics for rolling bearing using improved R/S statistic model and fractional brownian motion approach[J]. IEEE Access, 2018, 6: 21103-21114.

[ 4 ] 周勃, 张士伟, 陈长征, 等. 风力机叶片多裂纹扩展声发射信号的特征识别[J]. 仪器仪表学报, 2015, 36(1): 110-117.

ZHOU B, ZHANG SH W, CHEN CH ZH, et al. Feature identification of acoustic emission signals of multiple propagating crack on wind turbine blade[J]. Chinese Journal of Scientific Instrument, 2015, 36(1): 110-117.

[ 5 ] CUI L, ZHANG Y, ZHANG F, et al. Vibration response mechanism of faulty outer race rolling element bearings for quantitative analysis[J]. Journal of Sound and Vibration, 2016, 364: 67-76.

[ 6 ] RAI A, UPADHYAY S H. Intelligent bearing performance degradation assessment and remaining useful life prediction based on self-organising map and support vector regression[J]. Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical



- Engineering Science, 2017, 232(6): 1118-1132.
- [7] ZHANG B, ZHANG S, LI W. Bearing performance degradation assessment using long short-term memory recurrent network [J]. Computers in Industry, 2019, 106: 14-29.
- [8] LU Y, LI Q, PAN Z, et al. Prognosis of bearing degradation using gradient variable forgetting factor RLS combined with time series model [J]. IEEE Access, 2018, 6: 10986-10995.
- [9] YU H, LI H R, TIAN Z K, et al. Rolling bearing fault trend prediction based on composite weighted KELM[J]. The International Journal of Acoustics and Vibration, 2018, 23(2): 217-225.
- [10] 艾延廷, 费成巍. 转子振动故障的小波能谱熵 SVM 诊断方法[J]. 航空动力学报, 2011, 26(8): 1830-1835.  
AI Y T, FEI CH W. Rotor vibration fault diagnosis method based on wavelet energy spectrum entropy and SVM[J]. Journal of Aerospace Power, 2011, 26(8): 1830-1835.
- [11] 陈祥龙, 张兵志, 冯辅周, 等. 基于改进排列熵的滚动轴承故障特征提取[J]. 振动工程学报, 2018, 31(5): 902-908.  
CHEN X L, ZHANG B ZH, FENG F ZH, et al. Fault feature extraction of rolling bearings based on an improved permutation entropy [J]. Journal of Vibration Engineering, 2018, 31(5): 902-908.
- [12] LIU H, HAN M. A fault diagnosis method based on local mean decomposition and multi-scale entropy for roller bearings [J]. Mechanism and Machine Theory, 2014, 75: 67-78.
- [13] ZHAO L Y, WANG L, YAN R Q. Rolling bearing fault diagnosis based on wavelet packet decomposition and multi-scale permutation entropy [J]. Entropy, 2015, 17(12): 6447-6461.
- [14] 崔鹏宇, 王泽勇, 邱春蓉, 等. 基于多尺度排列熵与双核极限学习机的滚动轴承故障诊断方法[J]. 电子测量与仪器学报, 2019, 33(5): 142-147.  
CUI P Y, WANG Z Y, QIU CH R, et al. Fault diagnosis of rolling bearings based on multi-scale permutation entropy and dual kernel extreme learning machine [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(5): 142-147.
- [15] ZHENG J, CHENG J, YANG Y. A rolling bearing fault diagnosis approach based on LCD and fuzzy entropy [J]. Mechanism and Machine Theory, 2013, 70: 441-453.
- [16] CHEN J, DU Y, LIU L, et al. BBS posts time series analysis based on sample entropy and deep neural networks [J]. Entropy, 2019, 21(1): 57-72.
- [17] 李永健, 刘吉华, 张卫华, 等. 改进样本熵及其在列车轴承损伤检测中的应用 [J]. 仪器仪表学报, 2018, 39(9): 179-186.  
LI Y J, LIU J H, ZHANG W H, et al. Improved multiscale sample entropy and its application in train axle bearing fault detection [J]. Chinese Journal of Scientific Instrument, 2018, 39(9): 179-186.
- [18] LAURENS V D M, HINTON G. Visualizing data using t-SNE [J]. 2008, 9(2605): 2579-2605.
- [19] ZHOU D, CHEN J, LYU C, et al. Feature reconstruction based on t-SNE: an approach for fault diagnosis of rotating machinery [J]. Journal of Vibroengineering, 2017, 19(7): 5047-5060.
- [20] LI S, WANG J, JIANG X, et al. An automatic feature extraction method and its application in fault diagnosis [J]. Journal of Vibroengineering, 2017, 19(4): 2521-2533.
- [21] BAI SH J, ZICO KOLTER J, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling [M]. 2018, arXiv:1803.01271v2.
- [22] OORD A V D, DIELEMAN S, Zen H, et al. WaveNet: A generative model for raw audio [J]. 2016, arXiv:1609.03499v2.
- [23] LONG J, SHELHAMER E, DARRELL T, et al. Fully convolutional networks for semantic segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(4): 640-651.

### 作者简介



于重重, 1996年于中国矿业大学获得硕士学位, 2013年于北京科技大学获得博士学位, 现为北京工商大学计算机与信息工程学院教授、硕士生导师, 主要研究方向为人工智能、机器学习与模式识别。

E-mail: chongzhy@vip.sina.com

**Yu Chongchong** received her M.Sc. degree from China University of Mining and Technology in 1996, and received her Ph.D. degree from University of Science & Technology Beijing in 2013. She is currently a professor and supervisor for Master students at Beijing Technology and Business University. Her research interests include artificial intelligence, machine learning and pattern recognition.



宁亚倩, 2018年于北京工商大学获得学士学位, 现为北京工商大学硕士研究生, 主要研究方向为工业大数据分析与挖掘。

E-mail: daydayupnyq@163.com

**Ning Yaqian** received her B.Sc. degree from Beijing Technology and Business University. She is currently a M.Sc. candidate at Beijing Technology and Business University. Her main research interest is analysis and mining of industrial big data.