

基于 t -SNE 降维方法的滚动轴承剩余寿命预测^{*}

REMAINING USEFUL LIFE OF ROLLING BEARING BASED ON t -SNE

钟建华^{**1,2} 黄 聪^{1,2} 钟舜聪^{***1,2} 肖顺根³

(1. 福州大学 机械工程及自动化学院, 福州 350116)

(2. 福建省太赫兹功能器件与智能传感重点实验室, 福州 350108)

(3. 宁德师范学院 信息工程学院, 宁德 352100)

ZHONG JianHua^{1,2} HUANG Cong^{1,2} ZHONG ShunCong^{1,2} XIAO ShunGen³

(1. School of Mechanical Engineering and Automation, Fuzhou University, Fuzhou 350116, China)

(2. Fujian Provincial Key Laboratory of Terahertz Functional Devices and Intelligent Sensing,
Fuzhou 350108, China)

(3. College of Information Engineering, Ningde Normal University, Ningde 352100, China)

摘要 由于实际工况下的轴承退化数据有限,无法获得足够的退化数据来训练神经网络,在深度学习网络中很难得到好的预测结果,所以提出一种新的结合机器学习和统计数据驱动的方法。首先对原始振动信号做特征提取,通过集合经验模态分解奇异值分解(Ensemble Empirical Mode Decomposition Singular Value Decomposition, EEMD+SVD)得到数十维特征,加上剩余寿命预测常用的诸如峭度、均值等有效特征,利用决策树筛选出 15 维特征;将所筛选特征进行双指数拟合并通过 t 分布随机近邻嵌入(t -distributed Stochastic Neighbor Embedding, t -SNE)将退化信号降维成线性趋势。线性退化趋势在预测上相比于指数趋势有更好的泛化性,同时预测准确度相比于指数模型支持向量回归(Support Vector Regression, SVR)和深度信念网络(Deep Belief Network, DBN)都有较高的提升。

关键词 特征提取 轴承 剩余寿命预测 双指数模型 t -SNE

中图分类号 TH17

Abstract Due to the limited bearing degradation data under actual working conditions, it is impossible to obtain enough degradation data to train the neural network, it is difficult to obtain good prediction results in the deep learning network, so a new fusion method was proposed. Firstly, the features of the original vibration signal was extracted, dozens of dimensional features were obtained through the ensemble empirical mode decomposition (EEMD) and the singular value decomposition (SVD), and the effective features such as kurtosis and mean value commonly used in remaining useful life prediction were added, then the decision tree to filter out 15-dimensional features was used the data was obtained by double exponential model fitting and the degraded signal was reduced to a linear trend through t -SNE. The linear degradation trend has better generalization in prediction than the exponential trend, and the prediction accuracy is superior to support vector regression (SVR) and deep belief network (DBN) model.

Key words Feature extraction; Bearing; Remaining useful life prediction; Double exponential model; t -distributed stochastic neighbor embedding

Corresponding author: ZHONG ShunCong, E-mail: sczhong@fzu.edu.cn, Tel/Fax: +86-591-22866790

The project supported by National Natural Science Foundation of China (No. 52275096), and the Key Technological Innovation Project in Fujian Province (No. 2022G02030).

Manuscript received 20220928, in revised from 20221212.

^{*} 20220928 收到初稿, 20221212 收到修改稿。国家自然科学基金项目(52275096), 福建省技术创新重点攻关项目(2022G02030)资助。

^{**} 钟建华, 男, 1985 年生, 福建福州人, 畲族, 福州大学机械工程及自动化学院副教授, 博士研究生, 主要研究方向为故障诊断、旋转设备信号处理。

^{***} 钟舜聪(通信作者), 男, 1976 年生, 福建漳州人, 畲族, 福州大学机械工程及自动化学院教授, 博士, 博士研究生导师, 主要研究方向为智能传感与诊断、光学和太赫兹仪器、无损检测等。

0 引言

随着科学技术的发展和生产工艺的进步,当代设备的自动化和复杂化程度得到了日益提升。这类设备在受到内部因素和外部因素的综合作用下,性能与健康状态难免呈现出衰退的趋势,进而造成难以挽回的经济损失和资源浪费^[1-2]。预测与健康管理工作作为保障设备安全性和可靠性的一项关键技术,在过去几十年间取得了丰硕的理论成果并且得到了广泛的实际应用^[3-4],尤其是轴承的故障^[5],如果能在设备性能退化的初期就对设备的寿命进行预测和评估,并在此基础上确定设备监测和维修的最佳时机,制订相应的备件管理与订购方案,就能有效地提高设备的可靠性,降低设备的运行风险和运行成本^[6]。

数据驱动的方法可分为基于机器学习、深度学习的方法和统计数据驱动方法,是当前剩余寿命预测的主流方法。

深度学习方法的目的是在较低层次特征组成的层次结构中学习到适合分类的特征,在给定数据充足的情况下,不需要任何的信号处理,直接将原始信号输入到深度学习模型中,即可实现剩余使用寿命(Remaining Useful Life, RUL)的预测。

杨宇等^[7]提出了一种改进的深度信念网络——全参数动态学习深度信念网络(Deep Belief Network, DBN),并将其应用于滚动轴承寿命预测中,结果表明该预测模型能够有效加快收敛速度,减少模型的训练时间,且具有更高的预测精度。车畅畅等^[8]提出了将一维卷积神经网络和双向长短时记忆神经网络应用于航空发动机的 RUL 预测模型中。该方法与其他单一深度学习和传统模型相比,有更低的回归分析误差和退化预测误差,能够得到更准确可靠的 RUL 预测结果。目前的深度学习模型旨在堆叠网络,提高特征提取能力,但无法做出具体解释以及需要大量数据集做训练。

深度学习实际上是神经网络的特征提取与寿命预测相结合,故在寿命预测方向上,机器学习同样适用。支持向量机(Support Vector Machine, SVM)是由 CHERKASSKY V 等^[9]于 1995 年首次提出的,主要用于解决机器学习的分类和回归问题,适用于分析小样本和多维化数据。之后 SVM 开始受到可靠性工程领域专家学者的普遍关注^[10-11]。CHEN Z Z 等^[12]采用 SVM 对航空发动机的 RUL 进行预测,并且基于改进后的相似性理论结合发动机的 RUL 结果对运行设备的 RUL 进行预测,在分析过程中引入权重可调系数,最后将所提方法应用于 RUL 评估。

YAN T 等^[13]利用相关向量机提取相关向量等对

指数模型进行优化并利用双指数模型进行预测,但是双指数模型对故障早期的预测效果较差。王久健等^[14]^[88-95]提出了一种不需要先验知识的基于空间卷积长短时记忆神经网络的健康指标生成网络模型,该网络利用卷积长短时记忆神经网络直接从采集到的原始信号中挖掘反映退化程度的特征,构建健康指标,然后利用粒子滤波更新双指数寿命模型,实现 RUL 结果的输出,但是所提方法需要较大的完整的轴承退化数据做训练。葛阳等^[15]提出了一种基于 t 分布随机近邻嵌入(t -distributed Stochastic Neighbor Embedding, t -SNE)和长短期记忆网络的预测方法。该方法给出一个新的轴承失效指标,但由于仅针对一个轴承做寿命预测,不具泛化性。

目前在寿命预测方面依赖于轴承退化数据,需要前期大量的准备工作来保障,而在实际工作环境中很难获得大量轴承退化数据。在采用深度学习时无法保障预测结果的精度,从而导致预测结果严重偏离实际剩余寿命,同时由于深度学习在参数方面没有统一标准,需不断在已知实际寿命的情况下调节参数来提高预测准确性,缺少信服性。因此,提出一种新方法,由于 t -SNE 在降维方面的良好表现以及其对指数数据的线性化方面的特征,将原始数据经过特征提取,平滑处理后在 t -SNE 上降维,再将原始的指数特征降成线性趋势,最后通过线性拟合来进行寿命预测。

1 t -SNE 原理

t -SNE 是用于降维的一种机器学习算法。对于 N 个高维数据 $\{x_1, x_2, \dots, x_N\}$, 高维数据点两两之间的概率分布为

$$p_{ij} = \frac{p_{ij} + p_{ji}}{2N} \quad (1)$$

其中, p_{ij} 表示中心为 x_i 时, x_j 为其临近点的概率,采用高斯分布:

$$p_{ij} = \frac{\exp(-\|x_j - x_i\|^2/2\sigma_i^2)}{\sum_{k \neq i} \exp(-\|x_j - x_k\|^2/2\sigma_i^2)} \quad (2)$$

设在低维空间的模拟数据点为 $\{y_1, y_2, \dots, y_N\}$, 采用自由度为 1 的 t 分布,其概率分布为

$$q_{ij} = \frac{(1 + \|y_i - y_j\|^2)^{-1}}{\sum_{k \neq i} (1 + \|y_k - y_i\|^2)^{-1}} \quad (3)$$

低维空间模拟点对应高维空间的准确性用 KL 散度表示:

$$C = \text{KL}(P \| Q) = \sum_i \sum_j p_{ij} \log_2 \frac{p_{ij}}{q_{ij}} \quad (4)$$

C 值越小表明模拟准确性越高,使用梯度下降法优化 KL 散度:

$$\frac{\partial C}{\partial y_i} = 4 \sum_j (p_{ij} - q_{ij})(y_i - y_j)(1 + \|y_i - y_j\|^2)^{-1} \quad (5)$$

相较于 SNE 网络, t -SNE 将数据的趋势很好地保留下来, 同时将非对称的 p_{ij} 和 p_{ji} 改为对称的 p_{ij} 和 p_{ji} , 即无论是以 x_i 还是以 x_j 为中心点, 其出现在对方附近的概率是相等的。

t -SNE 作为非线性降维算法, 非常适用于高维数据降维到二维或者三维, 进行可视化, 相较于主成分分析 (Principal Component Analysis, PCA) 的线性降维方式有明显的优势, 更能合理地处理特征之间的复杂非线性关系 (如指数关系)。

2 基于 t -SNE 方法的特征聚类及阶段划分

2.1 t -SNE 特征聚类

以西安交通大学的轴承数据作为原始数据^[16-17]。相比于美国辛辛那提大学 IMS 中心发布的轴承数据集和法国 FEMTO-ST 研究所发布的轴承数据集, 本数据集在给出全寿命周期振动数据的基础上, 提供了多样的工况类型, 明确列出了各失效轴承的故障位置, 频率分辨率较高, 这使得数据集的应用场景得到拓宽。

RUL 通常取平均值、均方根、峰值、峰度、波峰因数、峭度等时间特征。同时常用小波包分解和经验模态分解对原始信号进行细分和重组, 滤除噪声等不良信号^[18]。而小波分解的效果与小波基的选取有关, 同时经验模态分解存在模态混叠现象, 本文采用集合经验模态分解 (Ensemble Empirical Mode Decomposition, EEMD)^[19] 分解成若干本征模态函数 (Intrinsic Mode

Function, IMF), 通过奇异值分解得到奇异值, 经过决策树筛选计算出每个特征所能表达退化特性的权重, 得到前 10 个特征。同时考虑整体信号特征, 加入平均值、均方根、峰值、峭度、脉冲因子 5 个特征, 其中峭度和脉冲因子用于评估波形表面状态和检测有无冲击, 具体流程如图 1 所示。




图1 集合经验模态分解+决策树信号处理

Fig. 1 Signal processing of EEMD and the decision tree

将原始振动信号等距取每分钟 1 280 个点三组轴承的时域图如图 2 所示。

采用 EEMD+决策树信号处理, 对每个工况下的轴承 1 分别处理, 得到 15 维特征, 选取部分维度特征进行归一化处理, 并对图中指数部分放大处理, 得到如图 3 所示曲线, 提取出具有初步指数退化趋势的特征。

t -SNE 方法的降维和聚类相较于 PCA 方法有较大的优势, 以轴承 3-1 为例, 将所提取特征分别做 t -SNE




图2 三种工况下轴承时域图

Fig. 2 Time-domain diagram of bearings under three working conditions




图3 三种工况下轴承部分特征曲线

Fig. 3 Partial characteristic curves of bearings under three working conditions




图 4 两种方法的降维聚类对比
Fig. 4 Comparison of dimensionality reduction clustering between two methods

和 PCA 处理,使 15 维数据降维成二维数据,所得降维后的特征如图 4 所示,横坐标和纵坐标表示降维后的数据。 t -SNE 算法使具有较大相似度的点在低维空间中的整体距离稍小,而对于低相似度的点, t 分布在低维空间中的距离较远,以此达到不同类别点的聚集和分类效果,如图 4(a) 所示,不同故障阶段的点会出现明显区域划分;而在同一故障阶段,该算法使得具有一定比例或函数关系的点的距离和位置保持一致,从而达到线性关系。

t -SNE 处理后的数据对不同的阶段做出了聚类处理,同时其在单调性、相关性和鲁棒性等方面同样表现很好,具体结果如表 1 所示。

表 1 相关指标对比 (以轴承 3-1 为例)
Tab. 1 Comparison of relational indicators
(take bearing 3-1 as an example)

方法 Method	相关性 Correlation	鲁棒性 Robustness	单调性 Monotonicity
t -SNE	0.916 7	0.854 9	0.663 3
PCA	0.782 9	0.748 5	0.535 2

2.2 健康阶段的划分

PCA 作为一种降维方式,同样可以用于健康阶段的划分。王鹏^[20]利用传统的 17 维特征信号通过 PCA 得出 4 个主成分特征,根据其不同的权值合并 4 个主成分特征,得到一维的退化特征。通过对一维信号的 6 阶多项式拟合,得到拟合曲线,并对曲线 1 阶微分得到突变拐点,从而根据拐点划分健康阶段。该方法由于对退化信号进行多项式拟合,所以在应对信号突变时存在过早的反应,即拐点过早出现。由于主成分特征 PC_1 贡献率均大于 85%,如表 2 所示,故仅选取 PC_1 作为拟合数据,结果如图 5 所示。

DUAN A D Z 等^[21]在轴承故障诊断中使用 $\mu + 3\sigma$ 作为判定标准,可以直接通过原始数据直接得到故障阶段与正常阶段的划分,缺点是无法直接划分多个阶




图 5 6 阶多项式拟合
Fig. 5 Six-order polynomial fitting

段以及划分过程。其中, μ 为前 n 个信号均方根值 (Root Mean Square, RMS) 的均值; σ 为前 n 个信号 RMS 的标准差。若当前信号的 RMS 大于 $\mu + 3\sigma$, 则认为该点为故障发生点。

基于 t -SNE 降维方法的健康阶段划分为:利用 t -SNE 在降维和数据划分聚类方面的优势,将处理后的 15 维数据放入该网络中,降为二维特征,得到理想的健康阶段,如图 4(a) 所示。

表 2 主成分分析权值

PCA weights				%
主成分特征 Principal component characteristics	轴承 1-1 Bearing1-1	轴承 2-1 Bearing2-1	轴承 3-1 Bearing3-1	
PC_1	92	91	85	
$PC_1 + PC_2$	96	97	92	

健康阶段划分如表 3 所示。由表 3 可知, t -SNE 可以将轴承划分为 4 个阶段,相较于 PCA 法,该方式划分阶段数更加确定且不会因为信号突变而使拐点提前,从而使阶段划分更加准确。而阈值法因阈值设置而无法对早期磨损点蚀等故障做出判定,故阶段划分有延迟和不确定性,只能做初步诊断。

2.3 t -SNE 降维方法应用于 RUL 预测

在对退化数据进行信号处理和健康阶段划分后,实际的指数退化趋势已经初步展现,若直接将所得结果用于双指数模型预测,会出现以下问题:

1) 由于前两个工况下的轴承数据量较小,指数趋势不明显,若使用双指数模型做预测,效果较差。

2) 由于振动信号的不平稳,在不同阶段的退化指数模型参数不一致,在采用双指数模型拟合预测时,预测结果与实际寿命存在差异,在故障初期表现明显。如图 6 所示,在 $t=2\ 380$ 时的预测结果明显小于实际寿命,而 $t=2\ 410$ 时又大于实际寿命,存在预测结果变化幅度过大的问题。

表 3 轴承阶段划分

Tab. 3 Stage division of bearings

	正常阶段 Normal stage	故障早期 Early failure	故障中期 Mid failure	故障后期 End of fault
PCA	轴承 1-1 Bearing 1-1	0~62	63~103	104~117
	轴承 2-1 Bearing 2-1	0~443	—	444~491
	轴承 3-1 Bearing 3-1	0~2 250	—	2 251~2 538
$\mu + 3\sigma$	轴承 1-1 Bearing 1-1	0~83	—	84~123
	轴承 2-1 Bearing 2-1	0~468	—	467~491
	轴承 3-1 Bearing 3-1	0~2 424	—	2 425~2 538
t -SNE	轴承 1-1 Bearing 1-1	0~65	66~78	79~110
	轴承 2-1 Bearing 2-1	0~454	455~465	465~476
	轴承 3-1 Bearing 3-1	0~2 341	2 342~2 379	2 380~2 464
				2 465~2 538




图 6 轴承 3-1 双指数模型预测

Fig. 6 Double exponential model prediction of bearing 3-1

针对上述两点问题,提出一种新的解决思路,即将指数趋势转化为线性趋势; t -SNE 降维。当退化趋势为线性时在故障早期由指数带来的梯度问题就可解决,使得预测结果更加稳定。

阈值的确定同样是寿命预测的另一个重要问题。在考虑到无完整轴承做训练的前提下,王久健等^[14]88-95 利用神经网络将所提取的有效信息降维成低维,并归一化实现阈值的统一,但该方法需要将若干完整的轴承退化数据做训练以达到阈值的可靠性。雷亚国等^[16]1-6 将其失效阈值由原始振动信号的最大振幅

决定,在最大振幅达到 20 时即认为失效,虽然摆脱了数据量不足的问题,但同样也有缺点:在不同工况下,判定失效的形式不只有最大振幅,还包含其他多种形式。故需要一种新的阈值来判定轴承失效点。

本文给出将其他轴承的失效点信号作为预测轴承的失效点,RUL 的预测过程如图 7 所示。

3 基于 t -SNE 的 RUL 预测

根据上述健康阶段的划分,在预测过程中,由于正常信号特征不明显,预测效果差,所以将故障早期阶段作为预测起始点,取各轴承预测点如表 4 所示。

表 4 各轴承寿命预测位置

Tab. 4 Predicted position of each bearing

	轴承 1-1 Bearing1-1	轴承 2-1 Bearing2-1	轴承 3-1 Bearing3-1
运行时间 Operating time/min	123	491	2 538
预测点 Point/min	75	460	2 360

由于只取其他轴承的失效点作为阈值,在 t -SNE 降维时会出现分类不明显问题,需要增强数据来提高不同数据的聚类。本文采用的是将同种工况下的具有最小生命周期的轴承的失效点数据作为预测轴承的失




图 7 t -SNE 方法预测流程

Fig. 7 Prediction process of t -SNE method

效点,如表 5 所示。

失效段数据划分时,将所选取的失效轴承经双曲线拟合后等距分成 50 个数据点,分别取 10, 20, 30, 40, 50 个点做寿命预测并做准确度分析,如表 6 所示。结果表明,在数据量为 30 时,对轴承预测的准确率最高,超过 30 时,准确率会逐步下降。

表 5 失效轴承选取

Tab. 5 Selection of failed bearings

	工况 1	工况 2	工况 3
	Condition 1	Condition 2	Condition 3
轴承 Bearing	1-5	2-4	3-5
运行时间			
Operating time t /min	52	42	114

表 6 不同数据量预测准确率

Tab. 6 Prediction accuracy under different data volumes

数据量	轴承 1-1	轴承 2-1	轴承 3-1
Data	Bearing 1-1	Bearing 2-1	Bearing 3-1
10	0.273 8	0.315 9	0.394 2
20	0.602 4	0.582 1	0.696 5
30	0.859 9	0.786 6	0.882 2
40	0.803 6	0.769 7	0.881 7
50	0.811 2	0.760 8	0.819 0

以轴承 2-1 为例,在预测运行至 460 min 时的剩余寿命时,在 t -SNE 一维处理后,得到的结果采用双指数拟合预测,如图 8 所示。




图 8 $1n$ - t -SNE 剩余寿命预测($t=460$ min)


Fig. 8 $1n$ - t -SNE remaining life prediction ($t=460$ min)

在预测运行至 460 min 时的剩余寿命时,为保证预测的精度,将该轴承 400~460 min 的特征曲线进行双曲线拟合,采用双指数曲线拟合后的数据相比于原始的数据,在单调性上有 27% 的提高,如表 7 所示,同时结合轴承 2-4 的失效数据进行 t -SNE 处理,得到的结果采用直线拟合,预测结果如图 9 所示。

表 7 单调性对比

Tab. 7 Monotonic contrast

	2n-t-SNE	R-2n-t-SNE
单调性 Monotonicity	0.772 3	0.980 8

图 9 R-2n-t-SNE 剩余寿命预测 ($t=460$ min)Fig. 9 R-2n-t-SNE remaining life prediction ($t=460$ min)

为确保该方法的有效性,对比支持向量回归 (Support Vector Regression, SVR)、DBN 的回归预测方法以及 t -SNE 降维方法将数据降为一维,采用本文的信号方式得到的 15 维信号,以最大幅值为失效阈值进行双指数预测,对比该方法得到结论。同时提出判定标准方差 (Standard Deviation, SD) 和累积相对精度 (Cumulative Relative Accuracy, CRA):

$$C_{CRA} = \sum_{k=1}^K \omega_k RA(T_k) \quad (6)$$

其中,

$$RA(T_k) = 1 - \frac{|ActRUL(T_k) - RUL(T_k)|}{ActRUL(T_k)} \quad (7)$$




图 10 不同方法的预测效果

Fig. 10 Prediction effect of different methods

表 8 不同方法的评价

Tab. 8 Evaluation of different methods

方法 Method	轴承 1-1 Bearing 1-1			轴承 2-1 Bearing 2-1			轴承 3-1 Bearing 3-1		
	CRA	R-CRA	SD	CRA	R-CRA	SD	CRA	R-CRA	SD
1n-t-SNE	-0.871 7	0.263 2	180.953 1	0.648 7	0.557 2	53.835 8	0.351 1	0.509 1	96.775 8
DBN	0.369 0	0.192 8	47.865 7	0.659 2	0.472 8	46.041 9	0.486 7	0.652 3	64.525 8
SVR	0.094 5	0.219 8	24.547 6	0.186 7	0.268 2	12.888 2	0.684 3	0.646 8	13.780 6
2n-t-SNE	0.443 8	0.238 1	78.547 1	0.340 1	-0.448 5	124.183 8	0.704 0	0.302 4	67.680 3
R-2n-t-SNE	0.786 3	0.859 9	10.480 7	0.812 9	0.786 6	11.979 5	0.874 4	0.872 2	12.002 8

式中, T_k 为某一检测时刻, ω_k 为该时刻的对应权值,

$\omega_k = k / \sum_{k=1}^K k$; $ActRUL(T_k)$ 表示检测时间为 T_k 时轴承的真实剩余寿命; $RUL(T_k)$ 表示该时刻下的本文所提方法的预测剩余寿命; $RA(T_k)$ 为检测时间为 T_k 时的相对预测精度。

该评价标准具有一定的局限性,即在故障末期的权重过大而故障早期的权重较小,故提出改进的准确

率 R-CRA,使权值 $\omega_k = l_k / \sum_{k=1}^K k$, 其中 $l_k = K - k + 1$ 。

该评价指标与改进前相比,更加注重早期故障的权重,对实际问题更具指导意义。

图 10 中, $2n$ -t-SNE 为未进行双指数拟合的数据,在预测效果上不理想,尤其是在故障发生早期对轴承的剩余寿命预测,相较于 SVR 和 DBN 方法有较大的误差。R-2n-t-SNE 为双指数模型拟合后的数据,由图 10 可以看出其在 3 个轴承上的良好表现。其中在轴承 1-1 和轴承 2-1 上的表现相较于其他方法具有很高的预测精度和趋势性,在数据量较小的情况下表现突出。

表 8 所示为不同方法的准确率和标准方差。由表 8 可以看出,本文所提方法在不同指标下的准确率均为最高,且在 R-CRA 指标下其他方法的准确率有较为明显的下降,凸显了本文所提方法在故障早期的预测准确性和实际应用价值。

4 结论

针对轴承的剩余寿命预测,提出一种基于新的数据驱动方法的剩余寿命模型,将经双指数模型拟合后故障特征提取信号,加入同种工况下的轴承失效信号点作为失效阈值,由 t -SNE 降维得到的线性趋势进行预测。所得结果相比于指数模型 SVR 提升了 51%,相比于 DBN 提升了 40%。得到的主要结论如下:

1) 采用双指数模型拟合,将轴承的退化过程与真实轴承的振动信号相结合,使轴承指数退化趋势融合进真实轴承中,提高了预测的准确性。

2) t -SNE 线性降维,相较于指数模型,在故障早期体现出很好的预测效果。

3) 对于样本的需求量相较于深度学习较小,不需要大量的完整寿命周期信号做模型训练,未来可结合迁移学习做出较好的预测结果。

参考文献 (References)

- [1] MOGHADDASS R, ZUO M J. An integrated framework for online diagnostic and prognostic health monitoring using a multistate deterioration process[J]. Reliability Engineering and System Safety, 2014, 124: 92-104.
- [2] QIAO W, ZHANG P J, CHOW M Y. Condition monitoring, diagnosis, prognosis, and health management for wind energy conversion systems[J]. IEEE Transactions on Industrial Electronics, 2015, 62(10): 6533-6535.
- [3] LAU D, FONG B. Special issue on prognostics and health management[J]. Microelectronics Reliability, 2010, 51(2): 253-254.
- [4] ZHAO Z Y, QUAN Q, CAI K Y. A profust reliability based approach to prognostics and health management [J]. IEEE Transactions on Reliability, 2014, 63(1): 26-41.
- [5] 季云,王恒,朱龙彪,等. 基于 HMM 的机械设备运行状态评估与故障预测研究综述[J]. 机械强度, 2017, 39(3): 511-517.
- JI Yun, WANG Heng, ZHU LongBiao, et al. Review on operation state assessment and prognostics for mechanical equipment based on hidden markov model[J]. Journal of Mechanical Strength, 2017, 39(3): 511-517 (In Chinese).
- [6] 吴定海,任国全,王怀光,等. 基于卷积神经网络的机械故障诊断方法综述[J]. 机械强度, 2020, 42(5): 1024-1032.
- WU DingHai, REN GuoQuan, WANG HuaiGuang, et al. The review of mechanical fault diagnosis methods based on convolutional neural network [J]. Journal of Mechanical Strength, 2020, 42(5): 1024-1032 (In Chinese).
- [7] 杨宇,张娜,程军圣. 全参数动态学习深度信念网络在滚动轴承寿命预测中的应用[J]. 振动与冲击, 2019, 38(10): 199-205.
- YANG Yu, ZHANG Na, CHENG JunSheng. Global parameters dynamic learning deep belief networks and its application in rolling bearing life prediction [J]. Journal of Vibration and Shock, 2019, 38(10): 199-205 (In Chinese).
- [8] 车畅畅,王华伟,倪晓梅,等. 基于 1D-CNN 和 Bi-LSTM 的航空发动机剩余寿命预测[J]. 机械工程学报, 2021, 57(14): 304-312.
- CHE ChangChang, WANG HuaWei, NI XiaoMei, et al. Residual life prediction of aero engine based on 1D-CNN and Bi-LSTM [J]. Journal of Mechanical Engineering, 2021, 57(14): 304-312 (In Chinese).
- [9] CHERKASSKY V, MA Y. Practical selection of SVM parameters and noise estimation for SVM regression [J]. Neural Networks, 2004, 17(1): 113-126.
- [10] ROCCO C M, MORENO J A. Fast Monte Carlo reliability evaluation using support vector machine [J]. Reliability Engineering and System Safety, 2002, 76(3): 237-243.
- [11] HONG W C, PAI P F. Predicting engine reliability by support vector machines [J]. The International Journal of Advanced Manufacturing Technology, 2006, 28(1/2): 154-161.
- [12] CHEN Z Z, CAO S C, MAO Z J. Remaining useful life estimation of aircraft engines using a modified similarity and supporting vector machine (SVM) approach[J]. Energies, 2017, 11(1): 28.
- [13] YAN T G, LEI Y G, LI N P, et al. Degradation modeling and remaining useful life prediction for dependent competing failure processes[J]. Reliability Engineering & System Safety, 2021, 212: 107638.
- [14] 王久健,杨绍普,刘永强,等. 一种基于空间卷积长短期记忆神经网络的轴承剩余寿命预测方法[J]. 机械工程学报, 2021, 57(21): 88-95.
- WANG JiuJian, YANG ShaoPu, LIU YongQiang, et al. A method of bearing remaining useful life estimation based on convolutional long short term memory neural network [J]. Journal of Mechanical Engineering, 2021, 57(21): 88-95 (In Chinese).
- [15] 葛阳,郭兰中,牛曙光,等. 基于 t -SNE 和 LSTM 的旋转机械剩余寿命预测[J]. 振动与冲击, 2020, 39(7): 223-231.
- GE Yang, GUO LanZhong, NIU ShuGuang, et al. Remaining life prediction of rotating machinery based on t -SNE and LSTM [J]. Journal of Vibration and Shock, 2020, 39(7): 223-231 (In Chinese).
- [16] 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 YaGuo, HAN TianYu, WANG Biao, et al. XJTU-SY rolling element bearing accelerated life test datasets: a tutorial [J]. Journal of Mechanical Engineering, 2019, 55(16): 1-6 (In Chinese).
- [17] SUTRISNO E, OH H, VASAN A S S, et al. Estimation of remaining useful life of ball bearings using data driven methodologies [C]//2012 IEEE Conference on Prognostics and Health Managment. Denver, Colorado, USA, 2012: 18-21.
- [18] ZHONG J H, WONG P K, YANG Z X. Fault diagnosis of rotating machinery based on multiple probabilistic classifiers[J]. Mechanical Systems and Signal Processing, 2018, 108: 99-114.
- [19] 薛曼. 总体平均经验模式分解法的理论研究[D]. 哈尔滨: 哈尔滨工程大学, 2007: 1-64.
- XUE Man. Theoretical research on the overall average empirical mode decomposition method [D]. Harbin: Harbin Engineering University, 2007: 1-64 (In Chinese).
- [20] 王鹏. 基于 PCA 特征建模的轴承寿命分析研究[D]. 大连: 大连交通大学, 2019: 1-109.
- WANG Peng. Research on bearing life analysis based on PCA feature modeling [J]. Dalian: Dalian Jiaotong University, 2019: 1-109 (In Chinese).
- [21] DUAN A D Z, GUO L, GAO H L, et al. Deep focus parallel convolutional neural network for imbalanced classification of machinery fault diagnostics [J]. IEEE Transactions on Instrumentation and Measurement, 2020(11): 8680-8689.