

# 基于无监督学习的健康指标构建方法研究

俎海东<sup>1</sup>, 焦晓峰<sup>1</sup>, 张万福<sup>2</sup>, 李 春<sup>2</sup>

(1. 内蒙古电力科学研究院分公司, 内蒙古 呼和浩特 010020; 2. 上海理工大学 能源与动力工程学院, 上海 200093)

**摘要:**针对设备健康指标构建方法依赖专家经验的问题, 本文结合基于情境化编码器-解码器架构的多尺度残差卷积神经网络与平方欧式距离(MSR-CNED-SE)提出了一种基于无监督数据集的健康指标构建方法, 利用深度学习模型实现剩余寿命预测, 并在轴承全寿命数据集上验证方法的可靠性。此外, 还研究了不同相似度与深度学习网络对健康指标的影响。结果表明:基于平方欧式距离作为相似度度量构建的指标更容易找到退化的起始点, 而Bi-LSTM网络在不同预测场景下表现出更好的稳定性和可靠性。

**关键词:**健康指标; 无监督学习; 剩余寿命预测; 平方欧式距离; Bi-LSTM网络

中图分类号: TH133 文献标识码: A DOI: 10.16146/j.cnki.rndlg.2024.07.019

[引用本文格式] 俎海东, 焦晓峰, 张万福, 等. 基于无监督学习的健康指标构建方法研究[J]. 热能动力工程, 2024, 39(7): 157-164. ZU Haidong, JIAO Xiaofeng, ZHANG Wanfu, et al. Research on unsupervised learning-based health indicator construction methods[J]. Journal of Engineering for Thermal Energy and Power, 2024, 39(7): 157-164.

## Research on Unsupervised Learning-based Health Indicator Construction Methods

ZU Haidong<sup>1</sup>, JIAO Xiaofeng<sup>1</sup>, ZHANG Wanfu<sup>2</sup>, LI Chun<sup>2</sup>

(1. Inner Mongolia Electric Power Research Institute Branch, Hohhot, China, Post Code: 010020;

2. School of Energy and Power Engineering, University of Shanghai for Science and Technology, Shanghai, China, Post Code: 200093)

**Abstract:** In response to the problem of relying on expert knowledge in health indicator construction methods, this paper proposed a method for constructing health indices based on unsupervised database, integrated with multi-scale residual convolutional neural network with contextualized encoder-decoder architecture and squared Euclidian distance (MSR-CNED-SE). Furthermore, it utilized deep learning models to predict remaining useful life. The reliability of the proposed method was validated on a comprehensive bearing life dataset. Additionally, the effects of different similarity and deep learning networks on health indicators were studied. The results indicate that health indicators constructed using the squared Euclidean distance as a similarity measure are more effective in identifying the onset of degradation. Moreover, the Bi-LSTM network exhibits better stability and reliability under different prediction scenarios.

**Key words:** health indicator, unsupervised learning, remaining useful life prediction, squared Euclidean distance, Bi-LSTM network

收稿日期: 2023-07-06; 修订日期: 2023-08-25

基金项目: 国家自然科学基金(52006148); 内蒙古电力科学研究院2022年自筹项目(510241220009)

**Fund-supported Project:** National Natural Science Foundation of China (52006148); Inner Mongolia Electric Power Research Institute Branch 2022 Self-funded Project (510241220009)

作者简介: 俎海东(1990-), 男, 内蒙古电力科学研究院分公司高级工程师。

通信作者: 张万福(1986-), 男, 上海理工大学教授。

引 言

随着全球对可再生能源需求的不断增加,风力发电逐渐成为一种重要的清洁能源来源。在风力机运行过程中,齿轮箱作为核心组成部分之一,极易出现故障并影响整个风力发电系统的安全性和可靠性。因此,齿轮箱故障诊断成为风力发电系统维护和管理的重要任务之一。

对风力机剩余寿命 (Remaining Useful Life, RUL) 的预测有助于降低风力机故障风险和维护成本,提高风力机可维护性、可靠性和生产率。因此,面向风力机的 RUL 预测近年来越来越受到关注<sup>[1-2]</sup>。在 RUL 预测中,关键步骤为构建设备性能退化/健康指标 (Degradation/Health Indicator, DI/HI)。该指标应该注重全寿命周期风力机状态的变化,可表达设备性能退化的规律。

文献 [3] 将经验模态分解 (Empirical Mode Decomposition, EMD) 算法与主成分分析法 (Principal Component Analysis, PCA) 结合,提取并构建滚动轴承退化指标,发现更全面的特征融合能准确描述轴承退化过程。文献 [4] 基于威布尔分布形状参数构建轴承退化指标,采用粒子群优化 (Particle Swarm Optimization, PSO) 对最小二乘支持向量机核参数进行优化,建立寿命预测模型,研究证明,通过威布尔分布形状参数可准确构建轴承退化过程,保证寿命预测的准确性。Wang 等人<sup>[5]</sup>将多个观测特征融合构建为单一退化指标以描述齿轮性能退化,证明了融合多个 HI 能够保证退化指标在面向结构损伤演化时的可靠性。Yan 等人<sup>[6]</sup>研究表明,连续尺度形态学构建的健康指标随轴承退化具有不同表现,通过隐马尔科夫模型对特征进行融合得到退化指标,融合特征能够准确描绘退化过程。Wang 等人<sup>[7]</sup>改进了图谱重构方法,实现信号增强并从频域中提取退化指标,从经过拉普拉斯映射的高维特征流形中提取固有流形作为表征性能退化指标,结果表明,此方法能够更早确定退化时间和退化趋势。以上研究表明,通过多源特征融合构建的退化指标比单一指标具有更可靠的退化描述性。因此,信号处理方法与特征融合方式对 HI 指标可靠性影响显著,基于多

特征融合以寻找可靠健康指标构建方式是本文研究内容之一。

在构建以上特征指标时,对方法的依赖以及特征值种类的选择强烈依赖专家经验和先验知识。为尽可能减少对先验知识的依赖,深度学习技术逐渐被应用于构建特征指标中。Cheng 等人<sup>[8]</sup>使用卷积神经网络 (Convolutional Neural Network, CNN) 从原始信号中提取基于完整集成经验模式的标签退化指标。Guo 等人<sup>[9]</sup>采用含线性标签的 CNN 对网络进行监督,并构建健康指标。此外,Guo 等人<sup>[10]</sup>使用带有基于峭度非线性标签的循环神经网络 (Recurrent Neural Network, RNN) 来构建用于轴承 RUL 预测的退化指标。Zhao 等人<sup>[11]</sup>利用 CNN 在特征提取方面的优势,构建健康指标进行轴承 RUL 估计。Chen 等人<sup>[12]</sup>研究了不同种类的神经网络,仅在有先验经验的情况下提取降解特征来构建健康指标。

然而,上述研究构建的 HI 均基于监督的神经网络学习模型实现,其中特征提取过程或多或少包含了先验知识,仍为非全自动智能 HI 构建方法。因此,本文构建了不依赖专家经验以及无先验信息参与的退化指标,开展不同距离计算方式对于构建退化指标影响可靠性的研究,验证了不同深度神经网络模型对建立退化指标与寿命预测标签映射可靠性影响的研究,实现不依赖先验知识的风力机轴承寿命预测。

1 健康指标和剩余寿命算法基础

1.1 健康指标基本原理

HI 一般分为两类:直接 HI 和间接 HI。直接 HI 一般基于光信号、放射信号和视觉信号等直接测量信号获得,但仅限于部分工程<sup>[13]</sup>。本研究所构建的 HI 均为间接构建<sup>[14]</sup>,基于正常运行至故障 (Run to Failure, R2F) 的历史数据和已知失效时间的历史数据对风力机轴承寿命预测方法进行研究。对于具备 R2F 的数据,基于机器学习的方法提取有效可靠 HI 监视轴承全寿命变化用于估计 RUL 寿命。HI 构建和 RUL 预测的关系及过程如图 1 所示。其中  $t_{\text{FPT}}$  表示起始退化时间点 (First Precition Time, FPT),  $t_k$  表示退化阶段某一时间点,  $t_{\text{EoL}}$  表示退化结束时间点,预警虚线代表退化过程预警线,界限虚线表示退化

过程失效线。由图 1(a)可知,退化过程包含正常运行阶段(阶段 I)和退化阶段(阶段 II)。阶段 I 的 HI 是稳定的,表示设备健康运行。当故障发生时,进入设备的退化阶段,即从阶段 I 进入阶段 II,HI 将随着故障演化而变化。阶段 I 的任务是监测健康状况并检测初期故障,因此此阶段故障诊断起着重要作用。将检测出故障的第一时间定义为退化起始时间并在阶段 II 进行 RUL 预测,图中  $t_{FPT}$  是阶段 I 和阶段 II 的分界线。由图 1(b)可知,阶段 II 的实时 RUL 预测,通过连续执行每个  $t_k$  的预估,其中  $t_k \in [t_{FPT}, t_{EoL}]$ ,实现实时 RUL 预测。




图 1 HI 构建和 RUL 预测的关系及过程

Fig. 1 Relation of HI construction and RUL prediction and its process

1.2 剩余寿命预测的可靠性评价指标

为了评估构建的 HI 对寿命预测的精确性和可靠性,在对寿命预测进行评估时,分别使用了均方根误差(Root Mean Square Error, RMSE)以及 2008 年 PHM 竞赛中所使用的 score 这两个指标<sup>[15]</sup>:

$$RMSE = \sqrt{\sum_{i=1}^N (\hat{y}_i - y_i)^2 / N} \tag{1}$$

$$score = \begin{cases} \sum_{i=1}^N e^{-\frac{error_i}{13}-1}, & error < 0 \\ \sum_{i=1}^N e^{\frac{error_i}{10}-1}, & error \geq 0 \end{cases} \tag{2}$$

式中:score—RUL 估计的可靠性得分; $N$ —测试样本的个数; $\hat{y}_i$ —估计寿命; $y_i$ —真实寿命; $error = \hat{y}_i - y_i$ 。

1.3 依赖专家经验的健康指标构建

构建特征矩阵以描述设备退化过程是工程中常见的方法,谱峭度(Spectral Kurtosis, SK)作为一种

统计方法用于检查频域信号中非平稳及非高斯行为<sup>[16-17]</sup>。因此,SK 成为监测并提取故障信息的有效参数之一。信号的  $x(t)$  的峭度谱  $K(f)$  通过短时傅里叶变化(Short-Time Fourier Transform, STFT)计算求得<sup>[18]</sup>:

$$S(t, f) = \int_{-\infty}^{+\infty} x(t) w(t - \tau) e^{-2\pi i f \tau} d\tau \tag{3}$$

$$K(f) = \frac{\langle |S(t, f)|^4 \rangle}{\langle |S(t, f)|^2 \rangle^2} - 2, f \neq 0 \tag{4}$$

式中: $w(t)$ —短时傅里叶变化所需的窗宽函数; $\tau$ —相对于时间  $t$  的“短时间”; $\langle \cdot \rangle$ —时间均值计算函数; $f$ —频率; $S(t, f)$ —短时傅里叶变化计算中间参数。

谱峭度峰值将随设备退化而变化,因此轴承可通过谱峭度监测设备健康状况随时间的变化。图 2 为某风力机轴承的谱峭度峰值随时间变化的三维图。其中,故障严重程度 0 表示健康,1 表示故障。由图 2 可知,随着轴承损伤的不断恶化,轴承故障频率 20 kHz 附近的谱峭度峰值逐渐增大。传统 HI 构建常结合时域统计值形成高维统计特征矩阵,以供退化过程评估。




图 2 谱峭度随时间变化三维图

Fig. 2 3D plot of spectral kurtosis with respect to time

单一的特征指标难以表征复杂的轴承退化过程。因此,相关学者采用机器学习方法从退化特征矩阵中提取综合指标以构建 HI。其核心思想就是从统计值构成的高维退化指标矩阵中提取一维向量得到退化指标。基于机器学习的构建 HI 流程如图 3 所示。




图 3 基于机器学习的 HI 构建流程

Fig. 3 Process of constructing HI based on machine learning

近年来,为解决传统机器学习方法人工特征提取严重依赖专家经验与先验知识的问题,相关学者从特征学习角度出发,将特征学习方法用于旋转机械寿命预测领域。图 4 为基于特征学习的 HI 构建流程。




图 4 基于特征学习的 HI 构建流程

Fig. 4 Process of constructing HI based on feature learning

基于特征学习的 HI 构建通过 HI 历史标签库对训练数据(所采集的振动信号)进行监督学习以提取关键特征,再将测试数据导入训练完毕的带参模型进行 HI 构建。此过程也包含监督学习,实则也需要引入先验知识对数据进行标注,仍依赖专家经验。

2 健康指标构建

2.1 基于 POA-VMD-PCA 的 HI 构建

为构建优秀的健康指标以表征轴承退化过程,利用变分模态分解算法在非平稳信号处理中的强鲁棒性对采集的风力机轴承振动信号进行面向寿命预

测的自适应变分模态分解算法 (Prognosis Oriented Adaptive Variational Mode Decomposition, POA-VMD), 计算分解所获固有模态函数 (Intrinsic Mode Function, IMF) 分量的时域、频域、分形维数、信息熵以及 Lyapunov 指数等非线性特征值构建高维特征矩阵<sup>[19-21]</sup>。通过单调性指标评估每个特征在退化过程的可靠性,采用主成分分析法 (Principal Component Analysis, PCA) 计算所有满足阈值标准特征向量的主成分系数,基于此系数对退化过程的特征矩阵进行特征融合以构建 HI。图 5 为基于 POA-VMD 构建的 HI 流程。特征融合方法如式 (5) 所示:

$$HI_i = (\mathbf{X}_{n,i}^{\text{selected}} - \bar{\mathbf{X}}_{n,i}^0) / \left( \sqrt{\frac{\sum_{j=1}^n (x_j - \bar{x})^2}{n-1}} \cdot \text{coeff}_{n,i} \right), i \in 1, 2 \quad (5)$$

式中:  $HI_i$ —第  $i$  个健康指标;  $\mathbf{X}_{n,i}^{\text{selected}}$ —满足阈值筛选的特征矩阵;  $n$ —采样次数;  $\bar{\mathbf{X}}_{n,i}^0$ —筛选前的特征矩阵均值;  $x_j \in \mathbf{X}^0$ ;  $\text{coeff}_{n,i}$ —主成分系数。




图 5 基于 VMD-PCA 的 HI 构建流程

Fig. 5 Process of constructing HI based on VMD-PCA

2.2 基于多尺度特性的健康指标构建

采用 VMD-PCA 方法可以有效提取风力机轴承退化过程的健康指数,但该方法存在对领域专家经验依赖的问题,在后期维护和应用过程中不具有优势。轴承的退化会引起异常振动,导致当前异常状态与正常状态之间存在不同的动态响应,而 HI 可以通过计算两种状态相似度的差异来评估轴承的退化情况。但由于噪声的存在,直接基于状态相似度构建的 HI 非常不稳定。为了解决这个问题,本研究借鉴了卷积自编码器的信号重塑能力,并考虑信号的多尺度特性,提出了一种基于现有状态编码信息与健康状态之间相似性来表征轴承退化的 MSR-CNED (Multi-Scale Residual Convolutional Neural Network with Contextualized Encoder-Decoder architecture) 自编码器模型。该模型结合了卷积自编码器的重塑性能和多尺度分析,有效解决了直接相似度计算受噪声影响而不稳定的问题。

在 MSR-CNED 自编码器拓扑结构下采样的过程中,卷积滤波器的数量将递增;在每次下采样过程中,将上级特征的长度减半,同时对每个特征一并执行深度采样,从而保持上级特征与下采样中特征尺寸相同;每次上采样都会使特征的长度加倍,与深度特征拼接以形成编码特征。训练损失函数采用均方根误差,优化器采用 ADAM,最大迭代次数为 500。

3 实验数据验证

3.1 实验数据来源

本文采用轴承加速退化实验数据,验证了基于 MSR-CNED 退化指标构建并与深度学习算法结合从而实现无人干预轴承寿命预测方法的可靠性和优越性。轴承数据如表 1 所示<sup>[19]</sup>。表中,轴承 I-1 表示 1 号轴承退化类型 I,以此类推。下文将通过不同退化类型和不同轴承的组合验证所提出方法的可靠性、外推性和优越性。

表 1 轴承数据表  
Tab. 1 Bearing data table

| 轴承退化类型  | 轴承寿命/min |
|---------|----------|
| I - 1   | 123      |
| II - 1  | 491      |
| III - 1 | 2 538    |
| I - 2   | 161      |
| II - 2  | 161      |
| III - 2 | 2 496    |
| I - 3   | 158      |
| II - 3  | 563      |
| III - 3 | 371      |
| I - 4   | 122      |
| II - 4  | 42       |
| III - 4 | 1 515    |
| I - 5   | 52       |
| II - 5  | 359      |
| III - 5 | 112      |

3.2 相似度指标性能对比

为克服监督学习对先验知识的依赖,基于深度学习技术建立编码-解码器对振动信号进行编码和解码。训练自编码器时,采用正常运行情况时的数据。当轴承发生损伤进入退化阶段时,疵点的发展会导致基编码特征和测试数据现行编码特征的距离增大,这种变化反映了不同状态下振动信号之间的差异。然而,光靠距离的变化无法完全捕捉到振动信号的复杂特性,因此引入了异常状态和正常状态相似度的概念。通过比较状态相似度,能够更准确地评估训练数据和检验数据编码特征之间的差异性<sup>[20]</sup>,进而更好地识别出振动信号中的异常变化。

图 6 为引入相似度的 HI 构建流程图。由图 6 可知,采用轴承健康状态的数据训练自编码器得到基编码特征,采用轴承测试现场的数据训练自编码器得到测试编码特征,将基编码特征与测试编码特征进行相似度计算,从而得到测试现场数据的 HI 值。

文献[21]采用欧式距离作为相似度估计 HI,而本文将讨论欧式距离、绝对值与平方欧式距离 3 种不同相似度函数对估计 HI 可靠性的影响。

欧式距离:

$$D_1(\boldsymbol{X}_{\text{base}}, \boldsymbol{Y}_{\text{current}}) = \sqrt{\sum_{i=1}^l (x_i - y_i) \cdot (x_i - y_i)}$$

(6)

绝对值:

$$D_2(\mathbf{X}_{\text{base}}, \mathbf{Y}_{\text{current}}) = \sum_{i=1}^l \sqrt{(x_i - y_i) \cdot (x_i - y_i)}$$

(7)

平方欧式距离:

$$D_3(\mathbf{X}_{\text{base}}, \mathbf{Y}_{\text{current}}) = \sum_{i=1}^l (x_i - y_i) \cdot (x_i - y_i)$$

(8)

式中: $l$ —编码特征所在层的个数; $\mathbf{X}_{\text{base}}$ 和 $\mathbf{Y}_{\text{current}}$ —基编码特征矩阵和测试编码特征矩阵; $D$ —相似度; $x_i$ 和 $y_i$ —基编码特征和测试编码特征 $i$ 层数值。




图 6 引入相似度的 HI 构建流程

Fig. 6 Process of constructing HI with the introduction of similarity

用 3 种不同距离度量作为状态相似度函数构建 HI 时的效果进行对比,结果如图 7 所示。由图 7 可知,5 号轴承随着退化呈现出不同的 HI 曲线,当轴承开始进入失效期时,HI 曲线上升。轴承退化有 3 个阶段:损伤起始、扩展和疲劳。可靠的 HI 应能够准确描述性能退化过程和第 1 个预测点。以轴承 II-5 为例,在寿命周期约为 200 min 时,轴承由于疲劳而出现裂纹,进入加速退化阶段,导致轴承的振动发生变化。退化过程具有规律性是稳定预测剩余寿命的前提,用绝对值描述的相似度和欧式距离构建的 HI 在损伤演化过程中波动较大,而用平方欧式距离构建的 HI 具有较好的稳定性。因此,在本研究中使用平方欧式距离 (Squared Euclidean, SE) 计算状态相似度来构造 HI,结合 MSR-CNED 自编码器模型组成 MSR-CNED-SE 模型用于寿命预测。




图 7 轴承 II-5 3 种相似度函数的 HI

Fig. 7 Three types of similarity functions of bearing II-5 for HI

3.3 不同深度学习模型 HI 性能对比

为了体现 MSR-CNED-SE 在建立 HI 度量方面的优势,将其与基于深度卷积神经网络 (Deep Convolutional Neural Network, DCN) 和注意力机制的多通道卷积神经网络 (Multi-Channel Attention Network, MCAN) 模型的编码器-解码器进行了比较。以轴承 I-1 和轴承 II-1 为例,基于 MSR-CNED 建立的 HI 曲线比 DCN 和 MCAN 更稳定,图 8 为不同方法使用不同相似度函数的 HI 曲线,可以看出基于 MSR-CNED-SE 所建立的 HI 随时间变化非常平稳,并

且当信号健康状态发生改变时,其响应更为迅速。




图 8 不同方法使用不同相似度函数的 HI  
Fig.8 Various similarity functions used by different methods for HI

3.4 轴承退化寿命预测

为准确建立 HI 与剩余寿命标签的映射关系,研究 CNN、门控循环单元 ( Gated Recurrent Unit, GRU)、长短期记忆网络 ( Long Short-Term Memory, LSTM) 和双向长短期记忆网络 ( Bidirectional Long Short-Term Memory, Bi-LSTM) 4 个 DL 模型在估计剩余寿命时的可靠性。

对轴承 I - 1 和 I - 3 进行 RUL 预测。使用轴承的部分数据进行训练,剩余数据作为测试数据,训练集和测试集数据是独立的。图 9 为 4 种神经网络模型寿命预测性能对比。箱形图反映寿命预测误差数据对称性、分散情况等,不受异常误差值影响。箱形图包含 6 个特征值:上限、上四分位数、中位数、下四分位数、下限和异常值。上限是最上端横线,指除异常误差值外的最大值;上四分位数是长方形上边线,中位数是长方形中部线,下四分位数是长方形下边线,分别指误差值从小到大依次排列,序列数为 75% ,50% 和 25% 时的误差值;下限是最下端横线,指除异常误差值外的最小值;异常误差值是上限和下限之外的短线。可以看到,轴承 I - 1,使用 CNN 的剩余寿命预测误差最大,而 Bi-LSTM 网络的误差最小,轴承 I - 3 使用 Bi-LSTM 进行剩余寿命预测时更为准确。

为了进一步体现所提出寿命预测方法的外推性。

分别训练神经网络构建 RUL 预测器,比较不同轴承退化类型下预测的准确性。图 10 为基于 1 号轴承数据所得神经网络模型预测 5 号轴承 RUL 的结果。




图 9 4 种神经网络模型寿命预测性能对比  
Fig.9 Comparison of life prediction performance among four neural network models




图 10 轴承寿命预测外推性能测试  
Fig.10 Bearing life prediction performance testing by extrapolation method

由图 10(a)可知,CNN、LSTM 和 GRU 在估计剩余寿命时随着退化而存在较大的误差。使用 Bi-LSTM 作为预测器来估计预测值,结果与实际剩余寿命最吻合。由图 10(b)可知,Bi-LSTM 对 RUL 的预测比 CNN、LSTM 和 GRU 更准确,其预测误差中值接近零。

4 结 论

(1) 基于 MSR-CNED-SE 建立的 HI 无需依赖专家经验,可有效判断轴承是否进入退化状态。

(2) 通过建立多尺度分辨率自编码器,使用测试数据与基线数据的编码特征“距离”来构建健康指标,研究发现,基于平方欧式距离构建的健康指标更易找到起始退化点。

(3) 通过研究不同深度学习网络对构建多尺度健康指标与剩余寿命映射精度的影响,发现 Bi-LSTM 网络在面向不同预测场景时更具稳定性与可靠性。

参考文献:

[1] LIU H,SONG W,NIU Y, et al. A generalized Cauchy method for remaining useful life prediction of wind turbine gearboxes[J]. Mechanical Systems and Signal Processing,2021,153:107471.

[2] CHENG F,QU L,QIAO W. Fault prognosis and remaining useful life prediction of wind turbine gearboxes using current signal analysis[J]. IEEE Transactions on Sustainable Energy,2017,9(1):157-167.

[3] 马艳丽,金 兵,张学欣,等. 滚动轴承退化指标选取方法研究[J]. 机械设计与制造,2018(5):170-172,176.  
MA Yanli,JIN Bing,ZHANG Xuexin, et al. Method study of selecting indicator of rolling bearing degradation process[J]. Machinery Design and Manufacture,2018(5):170-172,176.

[4] 陈 昌,汤宝平,吕中亮. 基于威布尔分布及最小二乘支持向量机的滚动轴承退化趋势预测[J]. 振动与冲击,2014,33(20):52-56.  
CHEN Chang,TANG Baoping,LYU Zhongliang. Degradation trend prediction of rolling bearings based on Weibull distribution and least squares support vector machine[J]. Journal of Vibration and Shock,2014,33(20):52-56.

[5] WANG D,TSE P W,GUO W, et al. Support vector data description for fusion of multiple health indicators for enhancing gearbox fault diagnosis and prognosis[J]. Measurement Science & Technology,2011,22(2):025102.

[6] YAN X,TANG G,WANG X. Bearing performance degradation assessment based on the continuous-scale mathematical morphological particle and feature fusion [J]. Measurement,2022,188:110571.

[7] WANG X,CUI L,WANG H, et al. A generalized health indicator

for performance degradation assessment of rolling element bearings based on graph spectrum reconstruction and spectrum characterization[J]. Measurement,2021,176(6):109165.

[8] CHENG Y,HU K,WU J, et al. A convolutional neural network based degradation indicator construction and health prognosis using bidirectional long short-term memory network for rolling bearings[J]. Advanced Engineering Informatics,2021,48(1):101247.

[9] GUO L,LEI Y G,LI N P, et al. Machinery health indicator construction based on convolutional neural networks considering trend burr[J]. Neurocomputing,2018,292:142-150.

[10] GUO L,LI N,JIA F, et al. A recurrent neural network based health indicator for remaining useful life prediction of bearings[J]. Neurocomputing,2017,240:98-109.

[11] ZHAO B,ZHANG X,ZHAN Z, et al. A robust construction of normalized CNN for online intelligent condition monitoring of rolling bearings considering variable working conditions and sources[J]. Measurement,2021,174:108973.

[12] CHEN Y,PENG G,ZHU Z, et al. A novel deep learning method based on attention mechanism for bearing remaining useful life prediction[J]. Applied Soft Computing,2019,86:105919.

[13] WANG L,ZHANG J,LIU P, et al. Spectral-spatial multi-feature-based deep learning for hyper-spectral remote sensing image classification[J]. Soft Computing,2017,21(1):213-221.

[14] BAUR M,ALBERTELLI P,MONNO M. A review of prognostics and health management of machine tools[J]. International Journal of Advanced Manufacturing Technology,2020,107:1-4.

[15] SAXENA A,KAI G,SIMON D, et al. Damage propagation modeling for aircraft engine run-to-failure simulation[C]//2008 International Conference on Prognostics and Health Management. IEEE,2008:1-9.

[16] ANTONI J. The spectral kurtosis: A useful tool for characterising non-stationary signals[J]. Mechanical Systems and Signal Processing,2006,20(2):282-307.

[17] ANTONI J,RANDALL R B. The spectral kurtosis: Application to the vibratory surveillance and diagnostics of rotating machines[J]. Mechanical Systems & Signal Processing,2006,20(2):308-331.

[18] 肖俊青,金江涛,李 春,等. 基于优化 CEEMDAN-CNN 的轴承故障诊断研究[J]. 热能动力工程,2022,37(4):166-174.  
XIAO Junqing,JIN Jiangtao,LI Chun, et al. Research on bearing fault diagnosis based on optimized CEEMDAN-CNN[J]. Journal of Engineering for Energy and Power,2022,37(4):166-174.

[19] WANG B,LEI Y,LI N, et al. A hybrid prognostics approach for estimating remaining useful life of rolling element bearings[J]. IEEE Transactions on Reliability,2022,69(1):401-412.

[20] PALIWAL K K,AGARWAL A,SINHA S S. A modification over Sakoe and Chiba's dynamic time warping algorithm for isolated word recognition[J]. Signal Processing,1982,4(4):329-333.

[21] GUO L,YU Y,DUAN A, et al. An unsupervised feature learning based health indicator construction method for performance assessment of machines[J]. Mechanical Systems and Signal Processing,2022,167:108573.

(刘 颖 编辑)