

DOI: 10.13382/j.jemi.B2003550

基于深度融合神经网络的轴承健康指标构建*

岳研^{1,2} 刘畅^{1,2} 刘韬^{1,2}

(1. 昆明理工大学 机电工程学院 昆明 650504;

2. 昆明理工大学 云南省先进装备智能制造技术重点实验室 昆明 650504)

摘要:基于深度学习方法构建轴承健康指标正成为机械故障诊断领域新的研究内容和应用热点。基于深度学习的指标构建容易受到前期人工特征提取和特征选择的影响,且缺乏对多通道传感器信息进行有效融合。针对上述问题,设计了一种基于深度融合神经网络(DFNN)的多通道信息融合健康指标构建方法。首先,提出一种多通道融合特征提取器(MFE)从传感器原始信号提取轴承退化特征,然后设计一种自适应特征选择器(AFS)进行特征选择,最后引入双向长短期记忆网络(BiLSTM)构建健康指标。所提出的方法在轴承全寿命数据集上进行实验验证,实验结果表明,相比现有基于深度学习的轴承健康指标构建方法,DFNN构建的健康指标趋势性指标高达98.4%,单调性指标增加44%,因而能够更准确的反映轴承实际性能退化趋势。

关键词:深度学习;健康指标;滚动轴承;特征提取

中图分类号: TH133.3; TN911.72 **文献标识码:** A **国家标准学科分类代码:** 510.4010

Deep fusion neural network for health indicator construction of bearings

Yue Yan^{1,2} Liu Chang^{1,2} Liu Tao^{1,2}

(1. Faculty of Mechanical and Electrical Engineering, Kunming University of Science and Technology, Kunming 650504, China;

2. Key Laboratory Advanced Equipment Intelligent Manufacturing Technology of Yunnan Province,

Kunming University of Science and Technology, Kunming 650504, China)

Abstract: Deep learning-based health indicator construction has become a new research and application hotspot in the field of machinery fault diagnostics. The performance of deep learning-based health indicators is largely depending on hand-craft feature extraction and selection. Moreover, the correlation of multi-channel sensor signals is not enough considered. In response to the above problems, a method for constructing health indicators based on multi-channel information fusion based on Deep Fusion Neural Network (DFNN) is designed. First, a multi-channel feature extractor (MFE) is proposed to extract bearing degradation features from the raw vibration signals. Then an adaptive feature selector (AFS) is designed to select useful features automatically. After MFE and AFS, we utilized a bidirectional long-short-term memory (BiLSTM) network to construct bearing health indicator. The proposed method is experimentally verified on the bearing life data set. The result shows that compared with some state-of-the-art methods, the health indicator by DFNN is up to 98.4%, and the monotonic indicator increases by 44%. Therefore, it is able to map the bearing degradation process effectively.

Keywords: Deep Learning; Health Indicators; Rolling Bearing; Feature Extraction

0 引言

机械设备关键零部件的健康状态管理和视情维修正在成为新的探索方向^[1]。得益于物联网和工业大数据的

发展,大量传感器被安装于机械设备上,用于实时监测设备运行状态。在基于数据的轴承状态监测系统中,构建合理有效的健康指标,实现对其退化过程定量衡量是非常重要的^[2]。轴承健康指标构建通常有两个主要步骤。首先对传感器采集信号进行特征提取,然后通过回归、距

收稿日期: 2020-10-26 Received Date: 2020-10-26

* 基金项目: 国家自然科学基金(51875272)、昆明理工大学引进人才科研启动基金(KK23201801048)项目资助

离判别等方法将提取到的特征与轴承的退化过程进行映射,以形成健康指标。季云等^[3]和王恒等^[4]首先基于 DPMM (dirichlet process mixture model) 获得稳定退化特征,再通过 CHMM (continuous hidden Markov model) 对滚动轴承全寿命数据进行健康状态识别;夏均忠等^[5]应用累计马氏距离实现特征降维提取,并通过改进的特征,再通过 CHMM (continuous hidden Markov model) 对滚动轴承全寿命数据进行健康状态识别。

随着深度学习^[6]与数据驱动方法的不断发展,一些研究开始将深度学习与轴承健康指标构建相结合^[7-10]。Guo 等^[11]提取时频域特征后输入循环神经网络 (recurrent neural network, RNN) 中构建轴承健康指标;Zheng 等^[12]提出了一种基于长短期记忆 (long short term memory, LSTM) 神经网络的健康指标构建方法;Guo 等^[13]验证了卷积神经网络 (convolutional neural network, CNN) 应用于轴承健康指标构建的可行性;Wang 等^[14]提出一种基于分离卷积的深度孪生神经网络 (deep separable convolutional network, DSCN) 模型用于构建轴承寿命指标;She 等^[15]先通过稀疏自编码器对轴承信号提取特征,再对特征进行选择以构建健康指标。

上述基于深度学习的轴承健康指标构建工作取得了一定成果,但仍存在如下不足:1) 输入神经网络的信息仍需进行手动特征提取和选择,大量的前期工作需要很强的先验知识和时间,并可能会造成信息损失;2) 基于深度学习的故障诊断方法一般选用特定一个方向的振动信息作为输入,对传感器采集到的多通道信息考量不足,因而可能导致对轴承早期退化判断不准确,影响模型性能;3) 现有的神经网络模型没有与经典故障诊断方法进行很好的结合。深度学习模型虽有一定适应性,但仍缺乏有效的特征选择过程。

针对以上问题,本文提出了一种针对多通道传感器信号构建健康指标的深度学习模型-深度融合神经网络 (deep fusion neural network, DFNN)。该方法首先构建了一个多通道融合的特征提取器 (MFE),从采集到的原始信号中自适应提取本征特征;然后,结合深度学习方法和经典故障诊断思想,构建了一种自适应特征选择器,对前级提取到的特征进行自动选择;最后引入双向长短期记忆网络 (bidirectional long short term memory, BiLSTM),实现对特征数据进行健康指标构建或预测。DFNN 的基本结构如图 1 所示。通过在 XJTU-SY 轴承全寿命数据集上与现有方法进行对比,验证 DFNN 为多通道振动信号健康指标构建提供了行之有效的解决方案。

1 DFNN

本文提出一种基于 DFNN 的健康指标构建方法。

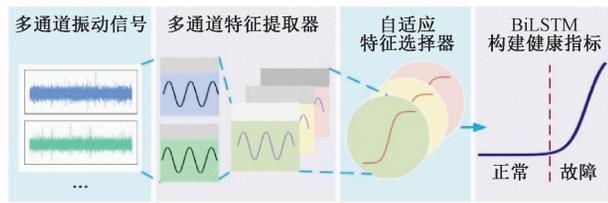


图 1 DFNN 基本功能构造

Fig. 1 Basic construction of deep fusion neural network

DFNN 通过多通道特征提取器 (multi-channel feature extractor, MFE) 从原始信号直接提取特征,经自适应特征选择器 (adaptive feature selector, AFS) 进行筛选,并最终通过 BiLSTM 构建一个 $[0, 1]$ 之间量化的健康状态指标。

1.1 多通道特征提取器

轴承的实际工作位置往往位于设备内部,对其进行监测的振动传感器多安装于轴承支座上。多通道振动传感器通过实时测量多个方向的加速度信号,对轴承的运行状态进行监控。受轴承工作环境的影响,振动传感器所测得的信号常包含较强的背景噪声,也可能包含其他部件传递的机械冲击。这使得根据单一方向加速度信号构建健康指标可能存在信息考量不够充分、判断不准确的风险。因此,本文首先改进了传统 CNN 卷积算法,提出一种基于一维通道卷积的特征提取器,对轴承振动信号进行多通道融合特征提取。

对于实验测试中的 n 向加速度传感器获取的数据 \mathbf{x}^n ,首先按照时间方向对数据进行 z -score 标准化,以确定通道数据的中心并修正偏移。

$$\mathbf{x}_{norm}^n = \frac{\mathbf{x}^n - \mu^n}{\sigma^n} \quad (1)$$

式中: \mathbf{x}_{norm}^n 为传感器第 n 通道标准化得到的数据; μ^n 和 σ^n 为该通道对应的数学期望和标准差。对于得到的一维时序数据 \mathbf{x}_{norm}^n ,先对每个通道进行逐点重采样。其过程可以表达为:

$$\mathbf{X}_C = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_c\} = \mathbf{R}_C * \mathbf{x}_{norm}^n + \mathbf{b}_C \quad (2)$$

式中: \mathbf{X}^C 表示输出特征向量的集合; $\mathbf{R}_C = \{R_1, R_2, \dots, R_c\}$ 表示重采样系数; $\mathbf{b}_C = \{b_1, b_2, \dots, b_3\}$ 为每个特征向量对应的偏置项。该过程可以等效为分别使用单一参数卷积核对每个输入信号进行卷积操作 ($*$),输出的特征向量数量由集合 \mathbf{R}_C 的参数数量 C 决定。重采样过程对于输入信号的幅值能够起到微调的作用,并对特征通道数实现 $n \rightarrow C$ 的升维,使得特征提取过程能够在高维空间中进行。

对于多通道传感器数据,合理的考虑各通道之间的相互关系并进行特征融合是非常重要的。现有基于 CNN 的轴承诊断或预测模型多采用数个标准卷积核,同步的

对各通道数据进行处理。然而振动信号特征提取与图像处理等应用场合不同,各个通道对于轴承故障的敏感性是不相同的。使用标准卷积核同步的处理各通道的特征向量可能忽略了通道间信息的独立性,因而导致模型下降。针对该问题,本文提出一种一维向量的独立通道卷积方法,对于第 $l-1$ 层输出的一维特征向量集合 $\mathbf{X}_c^{l-1} = \{\mathbf{x}_1^{l-1}, \mathbf{x}_2^{l-1}, \dots, \mathbf{x}_c^{l-1}\}$, 分别使用对应的一维卷积核 $\mathbf{k}_1^l, \mathbf{k}_2^l, \dots, \mathbf{k}_c^l$ 和偏置 $b_1^l, b_2^l, \dots, b_c^l$ 进行独立的卷积运算,即

$$\mathbf{X}_c^l = \left\{ \mathbf{x}_c^{l-1} * \mathbf{k}_c^l + b_c^l \right\}_{c=1}^C \equiv$$

$$1DChannelConv_{k_c^l, b_c^l}(\mathbf{x}_c^{l-1}) \quad (3)$$

由于 DFNN 的输入数据经过 z-score 标准化,其分布满足均值为 0 方差为 1 的特性,因此使用软阶跃函数 (Softsign) 作为其激活函数,即:

$$Softsign(x) = \frac{x}{1 + |x|} \quad (4)$$

经过通道卷积后的输出特征向量集合 \mathbf{Y}_c^l 可表示为:

$$\mathbf{Y}_c^l = \{\mathbf{y}_1^l, \mathbf{y}_2^l, \dots, \mathbf{y}_c^l\} =$$

$$Softsign(\mathbf{x}_c^{l-1} * \mathbf{k}_c^l(\mathbf{x}_c^{l-1} * \mathbf{k}_c^l + b_c^l))_{c=1}^C \quad (5)$$

再由单一参数卷积核 $\mathbf{P}_N = \{P_1, P_2, \dots, P_n\}$ 及对应的偏置项 b_n 进行特征向量之间的信息融合和 $C \rightarrow n$ 降维。该过程可以表示为:

$$\mathbf{Z}_n^l = \{\mathbf{z}_1^l, \mathbf{z}_2^l, \dots, \mathbf{z}_n^l\} = \sum_{c=1}^C P_n * \mathbf{y}_c^l + b_n \quad (6)$$

此外,在该一维通道卷积过程中,本文使用了批正规化 (batch normalization, BN) 算法^[16] 以稳定数值并加快模型训练。对于训练的输入批次 $\mathbf{x}_B = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_c\}$, BN 过程可表达为:

$$\hat{\mathbf{x}}_c = \frac{\mathbf{x}_c - \mu_{x_B}}{\sqrt{\sigma_{x_B}^2 + \epsilon}} \quad (7)$$

$$\mathbf{y}_c = \gamma_c \hat{\mathbf{x}}_c + \beta_c \equiv BN_{\gamma_c, \beta_c}(\mathbf{x}_B) \quad (8)$$

其中, \mathbf{y}_c 为经过正规化的输出特征向量; μ_{x_B} 和 σ_{x_B} 为批次数据 \mathbf{x}_B 对应第 C 个通道的均值和标准差; ϵ 为一小量以防零除; γ_c 和 β_c 为可训练的缩放系数,用于增强算法的灵活性。一个完整的多通道特征提取器结构如图 2 所示。

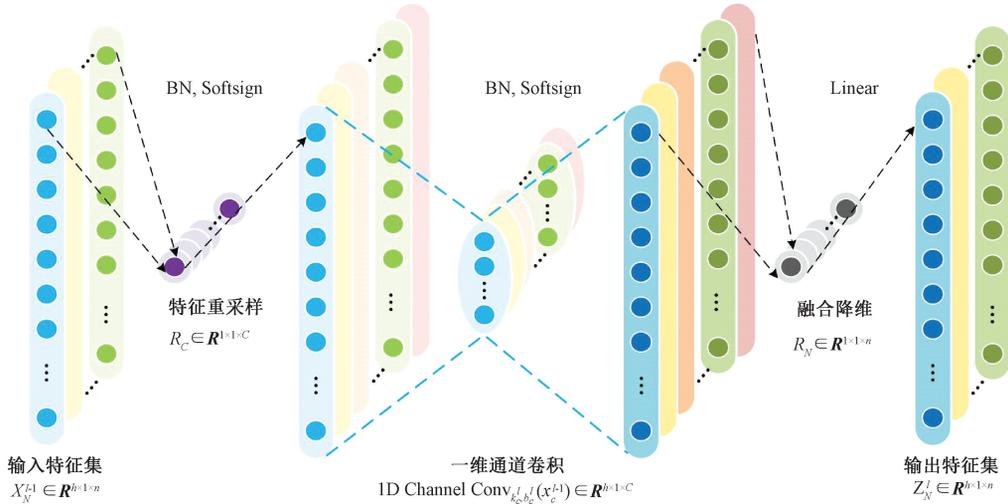


图 2 多通道特征提取器结构

Fig. 2 Construction of multi-channel feature extractor

1.2 自适应特征选择器

对轴承的振动信号进行特征提取之后,往往需要衡量特征的相关性和趋势性,以对所提取到的特征进行适当筛选。特征选择可以表达为:

$$\mathbf{Y}_n = F(\mathbf{X}_n) \quad (9)$$

式中: \mathbf{Y}_n 表示经过筛选的特征向量集; \mathbf{X}_n 表示原始特征集。通过选择函数 $F(\mathbf{X}_n)$ 的筛选,对轴承退化较敏感,且有直接关联性的指标得以保留,而冗余的不相关特征被剔除。然而,由多层神经网络提取到的本征特征与经

典时频域方法获得的特征不相同,其不具备明确的物理或统计学意义。这使得要想构造一个固定且明确的函数,对基于卷积神经网络提取到的特征进行筛选是很困难的。然而,神经网络本身能够根据样本进行学习,对权重进行更新。受文献[17]启发,本文设计一种基于神经网络方法的 AFS,对 MFE 提取到的特征进行自动筛选。

对于输入的特征集 \mathbf{X}_n ,首先对集合内的每个长度为 L 的特征向量计算其均值系数:

$$\mathbf{u}_n = \frac{1}{l} \sum_{i=1}^l \mathbf{X}_n \quad (10)$$

构造 k 对可学习的权重系数 \mathbf{w}_n^k 和偏置 b_n^k , 对得到的均值系数集合 \mathbf{u}_n 进行多层加权。加权后的均值集合 \mathbf{u}_n^* 作为选择系数, 与特征集 \mathbf{X}_n 中的每个特征向量对应相乘并通过激活函数引入非线性成分。该过程可表达为:

$$\mathbf{Y}_n = \mathbf{u}_n^* \cdot \mathbf{X}_n = \text{Sigmoid}(\mathbf{w}_n^k \cdot \text{Softsign}(\mathbf{w}_n^1 \cdot \mathbf{u}_n + b_n^1) + b_n^k) \cdot \mathbf{X}_n \quad (11)$$

由于权重系数 \mathbf{w}_n^k 和偏置 b_n^k 可以通过神经网络的梯度进行更新, 因此特征集 \mathbf{X}_n 的选择函数 $F(\mathbf{X}_n)$ 是可学习的。其能够根据 \mathbf{X}_n 内每个特征向量对模型总体误差的贡献程度, 自适应的调整选择函数 $F(\mathbf{X}_n)$ 。一个自适应特征选择器的结构如图3所示。

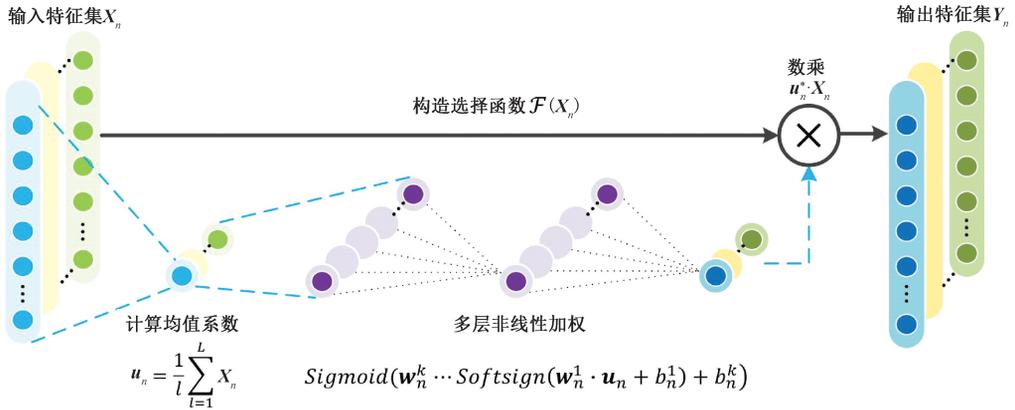


图3 自适应特征选择器结构

Fig. 3 Construction of adaptive feature selector

1.3 BiLSTM 构建健康指标

在提取得到轴承的退化特征后, 需要将特征构建为健康指标。基于经典统计方法构建的健康指标往往具有一定的数值浮动范围, 使得根据健康指标合理设置故障阈值存在难度。文献[11]指出, 经过特征提取、选择后得到的轴承退化指标特征能够通过深度 RNN 模型构建为健康指标。基于 RNN 方法构建的健康指标分布于 $[0, 1]$ 的范围之内, 拥有很好的尺度范围和数值稳定性。这使得 RNN 构建的健康指标能够直观的反应轴承的性能衰退过程, 进而很方便的根据指标数值设定故障阈值。因此, 本文将经过多通道提取、自适应选择后得到的轴承振动信号特征向量输入传统 RNN 的改进型 BiLSTM 构建健康指标。相比于单方向 LSTM, 双向 BiLSTM 的优势在于某一时刻特征的构建能够由之前若干时刻状态和之后若干时刻状态共同决定。这种特性使 BiLSTM 构建的健康指标更加准确。BiLSTM 的原理和基本结构如图4所示。

1.4 DFNN 模型构建

本文提出的 DFNN 模型主要由 MFE、AFS 和 BiLSTM 三个子模型组成。本文的多通道特征提取器使用平均池化 (average pooling)^[18] 以逐级减少特征向量的长度。DFNN 模型的结构如表1所示, 该模型直接以原始信号作为输入, 并根据输入的轴承样本直接输出构建一个健

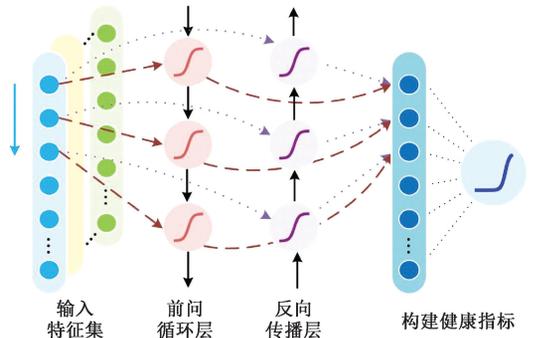


图4 BiLSTM 基本结构和原理

Fig. 4 Basic structure and principles of BiLSTM

康指标 h_k 。当健康指标 $h_k \rightarrow 0$ 时, 轴承工作在正常状态; 反之, 当指标 $h_k \rightarrow 1$ 时, 则认为轴承已经处于寿命的终点。在训练阶段, DFNN 模型采用以下损失函数进行优化:

$$L(\mathbf{h}_i, \mathbf{h}_p) = \frac{1}{2} \sum_{i=0}^T \|h_i - h_k\|_2^2 \quad (12)$$

式中: h_i 为训练阶段的样本标签; $\|\cdot\|_2$ 表示 2-范数。在验证阶段, 轴承的实测振动信号被直接输入 DFNN 模型中以构建健康指标。在一个轴承全寿命周期上, 指标应当具有明显的趋势性和较好的单调性。

表 1 DFNN 模型结构

Table 1 Architecture of DFNN model

操作层	输出特征向量
多通道特征提取器 1	$h \times 1 \times n \rightarrow C \rightarrow n$
自适应特征选择器 1	$h \times 1 \times n$
平均池化 1	$h/s \times 1 \times n$

2 实验研究与结果分析

2.1 实验数据

为验证 DFNN 模型效果,本实验使用 XJTU-SY 轴承数据集评估其性能。XJTU-SY 轴承数据集^[19]是由西安交通大学和昇阳科技联合构建的开源轴承全寿命数据集,该数据集包含 3 种工况下共计 15 个 LDK-UER204 轴承的加速退化寿命实验数据。根据数据集综述,液压加载系统施加负载力于轴承支座上,轴承的水平方向和垂直方向振动数据由 PCB 352C33 加速度传感器采集。采集仪的采样频率设置为 25.6 kHz,单次采样时长为 1.28 s,采样间隔为 1 min,即每分钟可获得长度为 32 768 个数据点的双通道加速度数据。根据实验设置,当被测轴承的振动幅值超过正常工作状态最大幅值 10 倍时,则判定该轴承失效。考虑到轴承的退化模式存在差异,本文分别选择一个缓慢退化(Bearing 1_2)轴承和一个快速退化(Bearing 1_3)轴承构建测试数据集。除两个测试轴承外,其余轴承均参与训练。在所有训练轴承上,参考文献[13]所述标签构建方法,本文将每个时刻轴承已运转时间按照该轴承全寿命周期时间进行归一化,并将该归一化后的数值作为训练样本的标签。对于轴承寿命初始状态样本,其训练标签为 0,而在该轴承寿命终止状态时,对应样本的训练标签为 1。两种退化模式轴承的水平方向、垂直方向振动信号分别如图 5 所示。

2.2 评价指标

为了能够定量评价模型构建的健康指标,本文采用趋势性、单调性和尺度相似性指标进行衡量^[13]。

1) 趋势性指标,用于衡量构建的健康指标和轴承退化时间趋势的相关性。其可以定义为:

$$Tred(H, T) = \frac{\left| \sum_{k=1}^K (h_k - \bar{H})(t_k - \bar{T}) \right|}{\sqrt{\sum_{k=1}^K (h_k - \bar{H})^2}} \quad (13)$$

式中: $\bar{H} = \left(\frac{1}{K}\right) \sum_{k=1}^K h_k$, $\bar{T} = (1/K) \sum_{k=1}^K t_k$, K 为每个轴承构建的健康指标 H 的长度, h_k 为 t_k 时刻的健康指标。

2) 单调性指标,由于故障的产生和演化过程往往是不可逆的,所构建的健康指标应当具有较好的单调性。单调性指标定义如下:

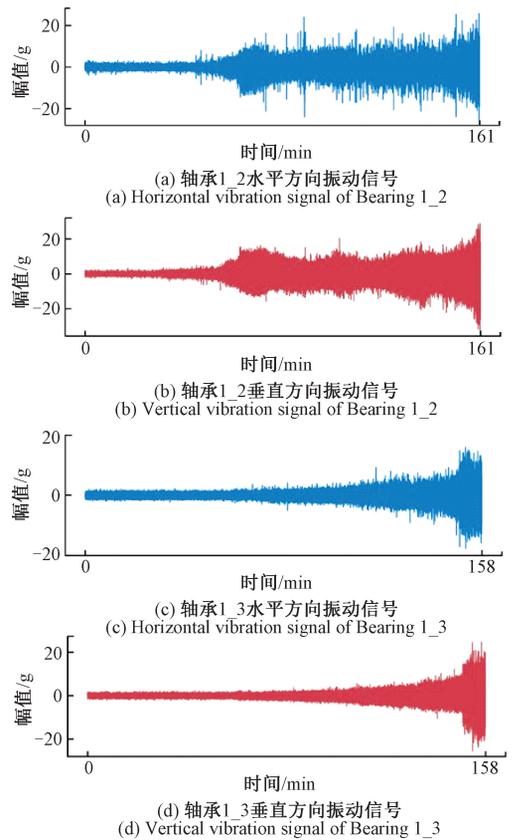


图 5 两种退化模式轴承的双通道振动信号

Fig. 5 Dual channel vibration signals of two bearings with different degradation modes

$$Mon(H) = \left| \frac{Num. \text{ of } dH > 0 - Num. \text{ of } dH < 0}{K - 1} \right| \quad (14)$$

式中: $Num. \text{ of } dH > 0$ 为每个轴承健康指标 H 的微分 $dH > 0$ 的个数, K 为健康指标 H 的长度。

3) 尺度相似性指标。在实际工业场景中,很难针对每一个轴承按其指标确定特定的故障阈值,为了方便。

4) 故障阈值的设定,所构建的轴承健康指标应当与已知的轴承退化模式相近^[13]。尺度相似性能够衡量构建的指标与训练集中已知指标的尺度和和退化趋势上的一致程度,可以通过式(15)得到。

$$SS(H) = \frac{1}{N_{tr}} \sum_{j=1}^{N_{tr}} \left(1 - \frac{|h_{max} - h_{max}^j| + |h_{min} - h_{min}^j|}{L(H) + L(H^j)} \right) \quad (15)$$

式中: N_{tr} 为训练集所包含的轴承数量; h_{max} 和 h_{min} 为所构建健康指标的最大和最小值; h_{max}^j 和 h_{min}^j 为训练集中第 j 个轴承健康指标的最大值和最小值; $L(H)$ 和 $L(H^j)$ 分别为构建的健康指标和训练集中健康指标的幅值长度。尺度相似性介于 $[0, 1]$, 趋近于 1 表示构建的健康指标与已知健康指标接近。

上述 3 个评价指标可组成一个综合评价系数:

$$HM = \frac{Tred + Mon + SS}{3} \quad (16)$$

2.3 数据的时序组合

由于轴承的退化是持续性过程,对于采集到的信号,如果仅按照当前采集时间点得到的数据构建健康指标,就可能忽视退化过程时间上的连续性,因而造成偏差。因此,任意一时间点的健康指标都应当综合考虑过去一段时间内轴承的运行状态。为解决时间连续性问题,本文采取时序组合的方式,每次健康指标推断均基于过去一段时间内的 t 次采集得到的数据进行。如图6所示,对于 XJTU-SY 轴承数据集,其单次采样时长为 1.28 s,采样间隔为 1 min。对单次 1.28 s 的采样数据,从中以等间隔采样的方式取 2 560 个数据点, t 次采样共计抽取 2 560 t 个数据点,时间跨度为 t min。这些数据点拼接组成一条完整的样本输入 DFNN 模型中。

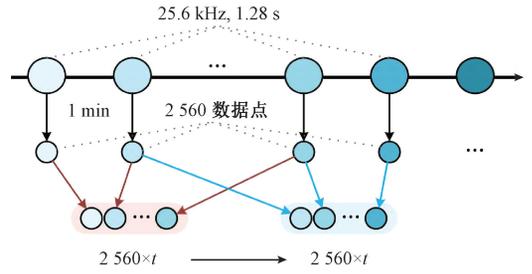


图6 时序组合方法

Fig. 6 Detail of time series embedding

由于 XJTU-SY 轴承数据集中振动信号包含两个通道,因此 DFNN 的实际输入形状为 $2\,560\,t \times 1 \times 2$ 。如果时间步长 t 的取值为 1,则对于某时刻构建的健康指标仅考虑当前时刻的状态;如果 $t > 1$,则考虑过去 t 个时间步长的历史监测数据。因此,合理的设置时间步长 t 是非常重要的。 t 取值为 1、2、5、10 时,DFNN 在两个测试轴承上构建的健康指标分别如图7(a)和(b)所示。

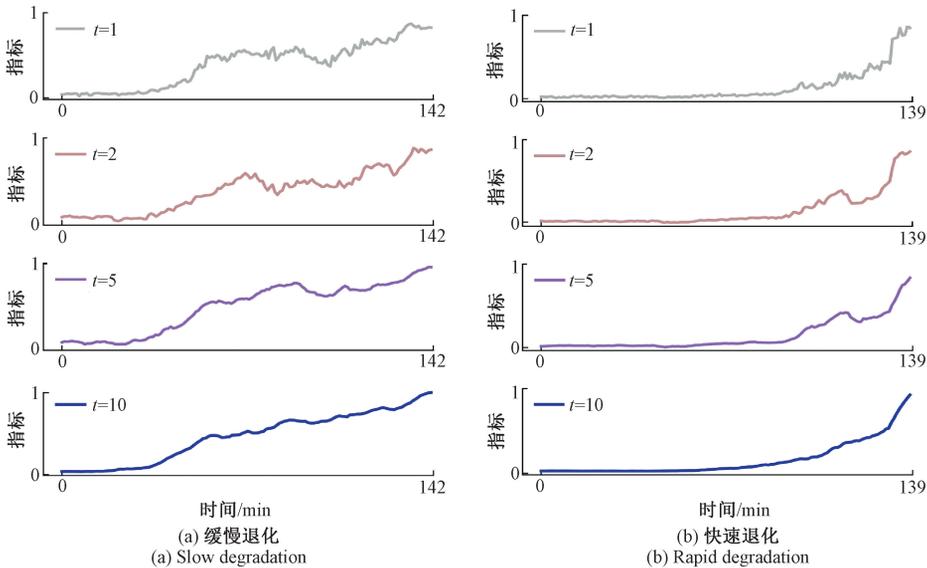


图7 不同时间步长 t 下 DFNN 构建的健康指标

Fig. 7 Health indicator construction based on DFNN with different time series length t

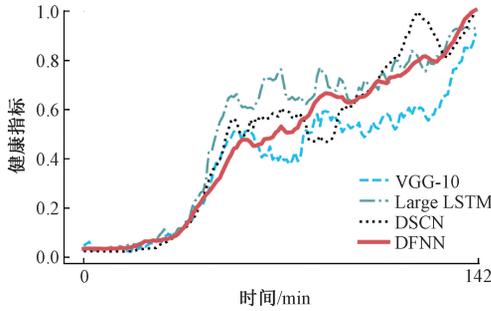
图7表明,时间步长 t 对于构建指标的趋势性和平稳性有很大影响。随着 t 逐渐增大,构建的指标逐渐趋向平稳,其数值突变也相对更少。时间步长 t 直接影响了输入 DFNN 模型的样本长度。将 t 翻倍意味着样本长度也将翻倍,因而构建健康指标的过程也将花费更多的时间,占用更多计算资源。在本实验中,为了得到相对平滑可靠的健康指标,所有实验和对比方法均采取 $t = 10$ 进行设置。

2.4 健康指标构建性能

为直观衡量 DFNN 模型性能,本文分别与基于深度学习的健康指标构建方法包含基于 CNN 的 VGG-10 模

型,基于 RNN 的大型 LSTM 模型^[12],基于通道分离卷积的 DSCN 模型^[14]进行对比实验。为使对照模型均能够满足在 XJTU-SY 数据集上构建健康指标所必要的性能需求,对原文构造的 LSTM 模型、DSCN 模型均扩大了深度。4 个模型都能够从采集到的原始振动数据直接提取特征构建健康指标,并使用相同的训练和测试数据集进行对比。DFNN 的具体配置如表 2 所示。每个实验均重复进行 10 次并取平均值,以消除随机误差对结果造成的影响。在缓慢退化和快速退化两种退化模式的轴承上,4 种模型构建的健康指标如图 8 所示。可以看出,DFNN 模型构建的健康指标更平滑。平滑的指标能够使状态相

对容易,因而具有更好的性能为量化所构建健康指标的性能,表 3 计算了缓慢退化、快速退化轴承健康指标的评价指标,最佳结果由粗体展示。其结果表明,对于两种退化状态的轴承,DFNN 模型构建的健康指标均具有更好的综合性能。在尺度相似性相近的情况下,DFNN 构建的指标相比 VGG-10、大型 LSTM 构建的指标具有更好的趋势性和单调性,这些结果验证了 DFNN 构建健康指标方法比当前基于深度学习的健康指标构建方法更具性能



优势。

表 2 DFNN 模型配置

Table 2 Configuration of DFNN

	值	参数名称	值
输入长度 h	25 600	卷积核长度	11
输出通道数 n	16	LSTM 单元	128-64-32
升维通道数 C	64	优化器	Adam
MFE 深度 i	3	学习率	1×10^{-4}
BiLSTM 深度 j	3	训练世代数	100

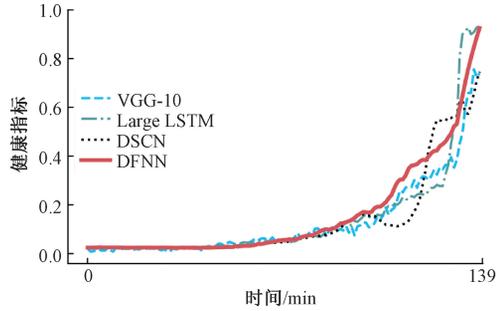


图 8 在缓慢退化和快速退化轴承上深度学习方法构建的健康指标

Fig. 8 Deep learning-based health indicators of slowly/rapidly degraded bearings

表 3 构建健康指标的评价指标

Table 3 Assessment of health indicator of rapidly degraded bearing

指标\模型	缓慢退化轴承				快速退化轴承			
	DFNN	VGG-10	LSTM	DSCN	DFNN	VGG-10	LSTM	DSCN
趋势性指标	0.983 7	0.938 4	0.924 9	0.960 5	0.809 2	0.804 2	0.718 2	0.762 3
单调性指标	0.574 5	0.191 5	0.148 9	0.347 5	0.550 7	0.159 4	0.173 9	0.391 3
尺度相似性指标	0.969 5	0.923 9	0.936 2	0.971 0	0.931 7	0.828 6	0.938 8	0.817 4
综合评价系数	0.842 5	0.684 6	0.670 0	0.759 7	0.763 9	0.597 4	0.610 3	0.657 0

2.5 性能分析

为了深入探究 DFNN 模型的性能,特别是所设计的 MFE 和 AFS 对健康指标构建性能影响,本实验构建了两个模型,分别为 CNN-BiLSTM 模型和无特征选择器的 DFNN 模型(DFNN without AFS)。此外,为了衡量深度学习自适应特征提取方法和传统人工提取特征再由机器学习模型进行回归两类方法之间的性能差异,本实验在

XJTU-SY 轴承数据集上人工提取了 18 个常用特征,包括时域方差、均方根值、绝对平均值、波形指标、峰度指标、裕度指标、峭度指标、歪度指标、频域均值、频域方差和 8 个小波变换能量比特征,输入多层回归器 (multi-layer regressor, MLR) 中进行健康指标构建。构建的健康指标实验结果如图 9 所示,表 4 为所构建的健康指标对应的评价指标。

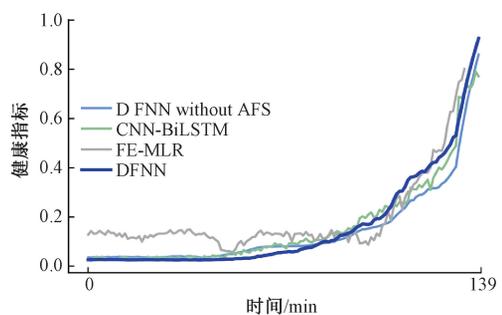
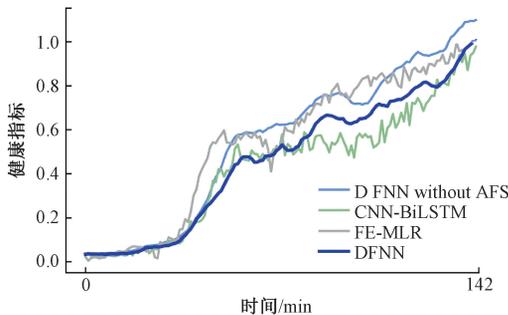


图 9 对比模型构建的健康指标

Fig. 9 Health indicators of constructed on comparison methods

表4 对比模型构建健康指标的评价指标

Table 4 Assessment of health indicators constructed by comparison models

指标\模型	缓慢退化轴承				快速退化轴承			
	DFNN	DFNN without AFS	CNN- BiLSTM	FE-MLR	DFNN	DFNN without AFS	CNN- BiLSTM	FE-MLR
趋势性指标	0.983 7	0.976 1	0.962 6	0.961 6	0.809 2	0.774 7	0.824 1	0.632 9
单调性指标	0.574 5	0.619 6	0.134 8	0.147 1	0.550 7	0.623 2	0.058 0	0.233 1
尺度相似性指标	0.969 5	0.923 5	0.962 0	0.924 9	0.931 7	0.890 3	0.848 1	0.843 3
综合评价系数	0.842 5	0.839 7	0.686 4	0.677 8	0.763 9	0.762 8	0.576 7	0.569 8

图9结果表明,DFNN模型在结合了自适应特征选择器之后,对健康指标终值的确定更为准确。这说明AFS能够改善模型对于退化过程的映射能力。反映在评价指标上,其尺度相似性相对与无AFS的DFNN更好。对于CNN-BiLSTM模型,实验结果显示其构建的健康指标具有很好的趋势性,但不够平滑,因而单调性指标较差。这说明与传统CNN相比,DFNN的特征提取器结构能够提取到更稳定的轴承退化特征。对于人工进行提取特征的MLR模型,实验结果表明其也能够构建具有一定趋势性的健康指标,但构建结果存在较为明显的偏离,且综合评价指标相对很差。因而可以得出,基于深度学习的自适应健康指标方法能够提取轴承振动信号所蕴含的本征特征,且这种特征提取方法相对于人工特征提取更为有效。

3 结 论

本文提出了一种基于DFNN的多通道信息融合健康指标构建方法。DFNN直接以实测的多通道振动传感器信号作为输入,先通过多通道融合特征提取器进行特征提取,然后构建了一种基于深度学习的特征选择器进行自适应特征选择。经过多层结构后,特征被输入双向长短期记忆网络构建为健康指标。本文通过XJTU-SY轴承全寿命数据集进行验证,并于现有的基于深度学习方法进行对比。由实验结果可知,深度融合神经网络构建的健康指标曲线更加平滑稳定,一定程度上避免了寿命周期内指标的突变,因而相对可靠;健康指标的量化评价指出,本文方法所构建的指标在保证尺度相似性的同时,具有更好的单调性和趋势性,更贴合轴承的实际性能退化趋势。因此,本文所提出的DFNN模型进一步推进了深度学习在健康指标构建方面的研究和应用,为智能运维和健康管理的工业化应用提供了潜在的解决方案。

参考文献

[1] LEI Y G, JIA F, KONG D T, et al. Opportunities and challenges of machinery intelligent fault diagnosis in big data era [J]. Journal of Mechanical Engineering, 2018,

54(5): 94-104.

- [2] MEEKER W Q, HONG Y. Reliability meets big data: Opportunities and challenges [J]. Quality Engineering, 2014, 26(1):102-116.
- [3] 季云,王恒,朱龙彪,等.基于DPMM-CHMM的机械设备性能退化评估研究[J].振动与冲击,2017,36(23):170-174.
- JI Y, WANG H, ZHU L B, et al. Performance degradation assessment for mechanical equipment based on DPMM-CHMM [J]. Journal of Vibration and Shock, 2017, 36(23):170-174.
- [4] 王恒,季云,朱龙彪,等.基于HDP-CHMM的机械设备性能退化评估[J].振动,测试与诊断,2018,38(4):91-95,229-230.
- WANG H, JI Y, ZHU L B, et al. Performance degradation evaluation of mechanical equipment based on HDP-CHMM [J]. Journal of Vibration, Measurement and Diagnosis, 2018, 38(4):91-95,229-230.
- [5] 夏均忠,吕麒麟,陈成法,等.基于MD-CUSUM和TD-SVR的滚动轴承健康状态预测[J].振动与冲击,2018,37(19):83-88.
- XIA J ZH, LU Q L, CHEN CH F, et al. Health state prediction of rolling bearings based on MD-CUSUM and TD-SVR [J]. Journal of Vibration and Shock, 2018, 37(19):83-88.
- [6] YANN L C, YOSHUA B, Geoffrey H. Deep learning [J]. Nature, 2015, 521(7553):436-444.
- [7] DONG X, GAO H L, GUO L, et al. Deep cost adaptive convolutional network: A classification method for imbalanced mechanical data [J]. IEEE Access, 2020, DOI:10.1109/ACCESS.2020.2986419.
- [8] 董勋,郭亮,高宏力,等.代价敏感卷积神经网络:一种机械故障数据不平衡分类方法[J].仪器仪表学报,2019,40(12):208-216.
- DONG X, GUO L, GAO H L, et al. Cost sensitive convolutional neural network: a classification method for imbalanced data of mechanical fault [J]. Journal of Electronic Measurement and Instrumentation, 2019, 40(12):208-216.

- [9] 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, DOI:10.1109/TIM.2020.2998233.
- [10] 谢佳琪, 尤伟, 沈长青, 等. 基于改进卷积深度置信网络的轴承故障诊断研究 [J]. 电子测量与仪器学报, 2020, 34(2):36-43.
XIE J Q, YOU W, SHEN CH Q, et al. Bearing fault diagnosis based on improved convolution deep belief network [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(2):36-43.
- [11] GUO L, LI N P, JIA F G, et al. A recurrent neural network based health indicator for remaining useful life prediction of bearings [J]. Neurocomputing, 2017, 240: 98-109.
- [12] ZHENG S, RISTOVSKI K, FARAHAT A, et al. Long short-term memory network for remaining useful life estimation [C]. IEEE International Conference on Prognostics and Health Management, 2017: 19-21.
- [13] 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.
- [14] WANG B, LEI Y G, LI N P, et al. Deep separable convolutional network for remaining useful life prediction of machinery [J]. Mechanical Systems and Signal Processing, 2019, DOI:10.1016/j.ymssp.2019.106330.
- [15] SHE D, JIA M, PECHT M. Sparse auto-encoder with regularization method for health indicator construction and remaining useful life prediction of rolling bearing [J]. Measurement and Technology, 2020, 31(10):105005.
- [16] IOFFE S, SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift [J].

Computer Science, 2015, arXiv1502.03167.

- [17] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-excitation networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42 (8): 2011-2023.
- [18] GU J X, WANG Z H, KUEN J K, et al. Recent advances in convolutional neural networks [J]. Pattern Recognition, 2018, 77:354-377.
- [19] WANG B, LEI Y G, LI N P, et al. A hybrid prognostics approach for estimating remaining useful life of rolling element bearings [J]. IEEE Transactions on Reliability, 2020, 69(1): 401-412.

作者简介



岳研, 2017 年于安徽工业大学获得学士学位, 现为昆明理工大学硕士研究生, 主要研究方向为机械故障诊断。

E-mail: yueyan9511@foxmail.com

Yue Yan received B. Sc. from Anhui University of Technology in 2017. Now She is a M. Sc. candidate at Kunming University of Science and Technology. Her main research interest includes machine fault diagnosis.



刘畅 (通信作者), 2017 年于昆明理工大学获得博士学位, 中国振动工程学会故障诊断专业委员会委员, 主要研究方向为信号处理理论与方法、压缩感知与稀疏表示、机械故障诊断。

E-mail: Liuchang2019@aliyun.com

Liu Chang (Corresponding author) received Ph. D. from Kunming University of Science and Technology in 2017. He is also a member of the Fault Diagnosis Professional Committee of the Chinese Society of Vibration Engineering. His main research interests include signal processing theory and methods, compressed sensing and sparse representations, machinery fault diagnosis.