

基于可变形卷积的轴承剩余寿命预测

周立俭, 卜振飞, 耿增荣, 孙伊萍, 周玉国*

(青岛理工大学 信息与控制工程学院, 青岛 266525)

摘要: 针对在滚动轴承剩余寿命(RUL)预测任务中神经网络的普通卷积核提取到的特征分布不均问题, 建立了基于注意力的深度可变卷积残差网络(ADRN)以提取轴承的退化特征并计算健康因子(HI)。通过连续小波变换(CWT)提取轴承的时频特征, 采用 ADRN 提取轴承时频图中的退化特征, 并通过 Tanh 激活函数得到 HI。为提升对异常值的约束能力, 在整个网络中采用提出的动态损失函数进行训练。使用 Savitzky-golay 滤波器平滑 HI 后, 由多项式函数拟合 HI 得到回归方程, 预测出轴承的 RUL。在 PHM2012 数据集上的实验仿真证明, 提出的方法得到了更准确的预测结果。

关键词: 滚动轴承剩余寿命预测; 可变形卷积; 注意力机制; 动态损失函数; 连续小波变换

中图分类号: TP277; TH17 **文献标志码:** A **文章编号:** 1673-4602(2024)01-0141-10

Remaining useful life prediction of bearings based on deformable convolution

ZHOU Lijian, BU Zhenfei, GENG Zengrong, SUN Yiping, ZHOU Yuguo*

(School of Information and Control Engineering, Qingdao University of Technology, Qingdao 266525, China)

Abstract: To address the problem of uneven distribution of features extracted from the standard convolutional kernel in the neural network for the prediction task of the Remaining Useful Life (RUL) of rolling bearings, this paper establishes an Attention-based deep Deformable convolutional Residual Network (ADRN) to extract the degradation features of the bearing and calculate the Health Indicator (HI). The time-frequency features of the bearing are extracted by Continuous Wavelet Transform (CWT). The degenerate features of the time-frequency map of the bearing are extracted by ADRN and the HI is computed by Tanh activation function. To improve the constraint ability for abnormal value, the dynamic loss function proposed in this paper is used in the training process for overall network. The HI is smoothed by Savitzky-golay filter, and the regression equation is obtained by fitting the HI with polynomial function to predict the RUL of the bearing. The experimental simulations on the PHM2012 data set prove that the proposed method obtains more accurate prediction results than other methods.

Key words: remaining useful life prediction of rolling bearings; deformable convolution; attention mechanism; dynamic loss function; continuous wavelet transform

收稿日期: 2023-04-14

基金项目: 山东省自然科学基金青年科学基金资助项目(ZR2020QF101)

作者简介: 周立俭(1970-), 女, 山东青岛人。博士, 教授, 主要从事信号处理与故障诊断等方面的研究。E-mail: zhoulujian@qut.edu.cn.

* 通信作者: 周玉国(1967-), 男, 山东日照人。博士, 教授, 主要从事故障诊断与模式识别等方面的研究。E-mail: zhouyuguo@qut.edu.cn.

轴承是机械设备运转过程最容易损坏的部件,例如在交流同步、交流异步、直流电机中轴承的损坏比例分别为 51%,41%和 42%^[1]。为了避免轴承损坏造成安全生产事故,建立了基于数据驱动的健康评估框架、工业装备故障预测与健康管理系统(简称 PHM)系统^[2]。轴承作为 PHM 中的核心,对其进行剩余寿命(RUL)预测可以避免机械设备突发事故造成的损失,具有重要的现实意义。

随着深度学习技术的发展,相关理论的完善,基于数据驱动的预测方法中,利用深度学习进行 RUL 预测逐渐成为主流。马占伟等^[3]建立了多尺度卷积神经网络(CNN)对轴承数据进行特征提取,构建退化指标;张继冬等^[4]则是建立了基于全卷积的预测网络,去掉神经网络中的全连接层来减少神经网络需要训练的参数。为了利用轴承数据之间的时序相关性,蔡薇薇等^[5]先对轴承数据进行频域特征提取,然后利用卷积神经网络(CNN)与长短期记忆网络(LSTM)组成的预测模型进行深层特征提取和 RUL 预测。孙世岩等^[6]利用动态时间规整算法扩增数据集训练预测网络 BLSTM;而为了使网络在特征提取时得到更为有效的退化特征,DU 等^[7]将全局注意力结构加入预测网络用以调整退化特征的贡献度。

上述基于深度学习网络建立的预测模型,不管是利用 CNN 还是 LSTM 进行特性提取时,数据稍微平移,绝大多数 CNN 的输出会发生变化,而可变形卷积^[8]在每个卷积采样点上增加了偏移量,可以获得不规则数据的不变特征。但因为可变形卷积的参数计算量较大,太多可变形卷积的堆叠会造成计算负担太大,因此本文在使用较少可变卷积核的基础上进一步利用注意力机制、普通的卷积计算和残差结构构建了基于可变形卷积的 RUL 预测模型(ADRN),减小计算负担的同时也提高了预测精度。又因为预测网络越来越复杂,如果不对网络训练加以约束,网络权重更新就变得不稳定,为使网络在面对异常数据时也能有效调节网络训练的权重,本文在训练过程中提出了基于均方误差(MSE)与均方根对数误差(RMSLE)的动态损失函数。

因为原始的轴承数据变化是非平稳的,很难体现出轴承的退化趋势,ZHU 等^[9]在轴承的 RUL 预测工作中,采用小波变换获得轴承原始数据的时频特征图作为模型输入,与使用原始信号或时域、频域特征相比,在 CNN 预测网络中取得了更好的 RUL 预测精度。因此本文首先使用了连续小波变换(CWT)提取轴承数据的时频特征图作为网络的输入。

综上所述,本文首先利用 CWT 变换提取轴承的时频退化特征,然后,建立了使用可变形卷积、普通卷积、注意力机制与残差结构的 ADRN 预测网络,最后,为了对网络的训练加以约束,构建了动态损失函数。

1 基础工作

1.1 数据集介绍

本文使用 IEEE PHM2012 轴承数据集^[10]来进行实验。PHM2012 数据由 IEEE 可靠性协会和法国 FEMTO-ST 提供,在 PRONOSTIA 平台(图 1)上进行,该平台通过传感器收集来自水平和垂直方向的振动加速度信号,传感器每 10 s 收集 1 次 0.1 s 的数据(频率 25.6 kHz)。PHM2012 采集了 3 种不同转速负载下 17 个滚动轴承的数据,其测试集与训练集的划分如表 1 所示。




图 1 PRONOSTIA 实验台^[10]

表 1 PHM2012 数据集中训练集与测试集划分

工况	转速/(r·min ⁻¹)	负载/N	训练集	测试集
1	1800	4000	Bearing1-1,Bearing1-2	Bearing1-3,Bearing1-4,Bearing1-5,Bearing1-6,Bearing1-7
2	1650	4200	Bearing2-1,Bearing2-2	Bearing2-3,Bearing2-4,Bearing2-5,Bearing2-6,Bearing2-7
3	1500	5000	Bearing3-1,Bearing3-2	Bearing3-3

1.2 评价指标

本文使用预测误差评价预测效果,对模型整体的精度使用分数(S)作为评价标准。

1) 预测误差:

$$E = \frac{A_{RUL} - P_{RUL}}{A_{RUL}} \times 100\% \quad (1)$$

式中: E 为预测误差; A_{RUL} 为轴承的真实剩余寿命; P_{RUL} 为轴承的预测剩余寿命。

2) 分数:

在实际的生产生活中,欠预测($E > 0$)优于过预测($E < 0$),因此在后续的实验,使用评价指标分数来描述这种影响,第 i 个轴承的评价分数 A_i 为

$$A_i = \begin{cases} e^{-\ln(0.5 \cdot \frac{E_i}{5})}, & \text{if } E_i \leq 0 \\ e^{\ln(0.5 \cdot \frac{E_i}{20})}, & \text{if } E_i > 0 \end{cases} \quad (2)$$

A_i 越接近 1,预测的精度越高。在同精度下,欠预测得分是高于过预测的。为评价模型的整体精度,将所有 N 个测试轴承的评价指标求平均得到模型的评价分数,记作 S 。

$$S = \frac{1}{N} \sum_{i=1}^N A_i \quad (3)$$

1.3 可变形卷积

相较于可变形卷积,普通卷积固有的几何结构对未知形状的数据特征建模存在不足。以图 2 为例,在对时频图进行卷积计算时,普通卷积的卷积核为固定的矩形,而可变形卷积则可以通过一个偏移量来适应特征的几何形状。

普通卷积与可变形卷积的计算输出定义如下。

1) 普通卷积计算。使用规则网格 G 对二维特征图采样时,对于一个膨胀率为 1 的 3×3 卷积核而言, G 可表示为

$$G = \{(-1, -1), (-1, 0), \dots, (0, 1), (1, 1)\} \quad (4)$$

其中, G 的每个元素代表卷积核的所有位置相对于中心位置的偏移量。

因此对于采样中心位置为 p_0 的普通卷积而言,其计算输出为

$$y(p_0) = \sum_{p_n \in G} \omega(p_n) \cdot x(p_0 + p_n) \quad (5)$$

式中: p_n 为采样点位置; $\omega(\cdot)$ 为卷积得到的当前位置权值; $x(\cdot)$ 为输入对应的位置值。

2) 可变形卷积计算。对于可变形卷积而言,通过在 G 上增加偏移量得到式(6):

$$y(p_0) = \sum_{p_n \in G} \omega(p_n) \cdot x(p_0 + p_n + \Delta p_n) \cdot \Delta m_n \quad (6)$$

式中: Δp_n 为采样点位置 p_n 的偏移量; Δm_n 为权值调制参数, $\Delta m_n \in [0, 1]$ 。

Δp_n 与 Δm_n 通过额外的卷积层计算得到,额外卷积层在计算时所使用的学习率为原有卷积层的 0.1 倍, Δp_n 与 Δm_n 的初始值分别为 0 和 0.5。

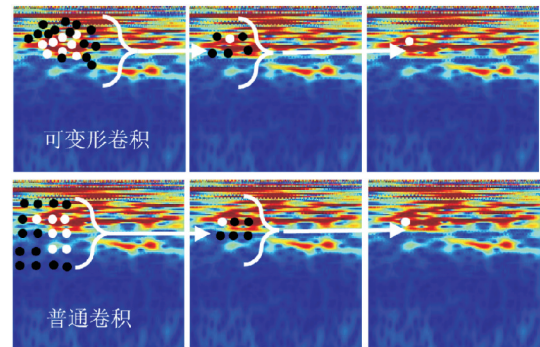


图 2 可变形卷积与普通卷积示意

2 基于可变形卷积的轴承 RUL 预测方法

为了对滚动轴承进行准确地 RUL 预测,本文构建了基于图像化轴承时频特征数据与深度神经网络的预测方法,如图 3 所示。该方法由数据预处理、ADRN 预测网络和 RUL 预测 3 个模块组成。

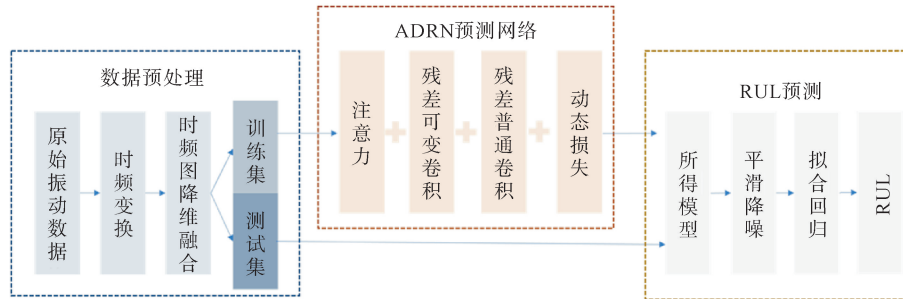


图 3 轴承 RUL 预测方法流程

数据预处理模块:①利用 CWT 提取轴承的时频特征,并生成时频图;②使用双线性插值对原始的轴承时频图进行降维;③将每个采样时刻水平与垂直方向的时频图利用通道拼接构建成新的轴承退化数据。

ADRN 预测网络模块:ADRN 预测网络主要由注意力、残差可变卷积与残差普通卷积构成,并使用动态损失减少网络训练中的异常值。①在轴承深层退化特征提取过程中,注意力机制为初级退化特征分配贡献权值;②使用残差可变卷积与普通卷积自动提取轴承深层退化特征;③在网络训练过程中利用由 MSE 与 RMSLE 组成的动态损失函数约束预测网络;④通过全连接层对深层退化特征下采样,并使用 Tanh 激活函数计算并输出健康因子。

RUL 预测模块:①将预处理后的数据测试集输入训练好的预测网络,得到预测健康因子(HI);②为去除 HI 中的异常值并加强轴承的退化趋势,使用 Savitzky-golay 滤波器平滑预测 HI;③利用多项式函数精确拟合平滑后的 HI,得到轴承的预测 RUL。

2.1 数据预处理

当滚动轴承运行到生命后期,由于脉冲变载荷原因造成轴承处于非平稳的状态,因此收集到的轴承原始振动信号也是非平稳、非线性的^[11],不能清晰和准确描述轴承的退化特征,降低了 RUL 预测效果。因此本文通过 CWT 提取轴承的时频故障特征图。以训练集 Bearing1-1 第 2600 个采样时刻的原始振动数据为例,轴承原始振动数据与 CWT 时频如图 4(a)和(b)所示,轴承时频特征图中的故障特征更为清晰丰富。

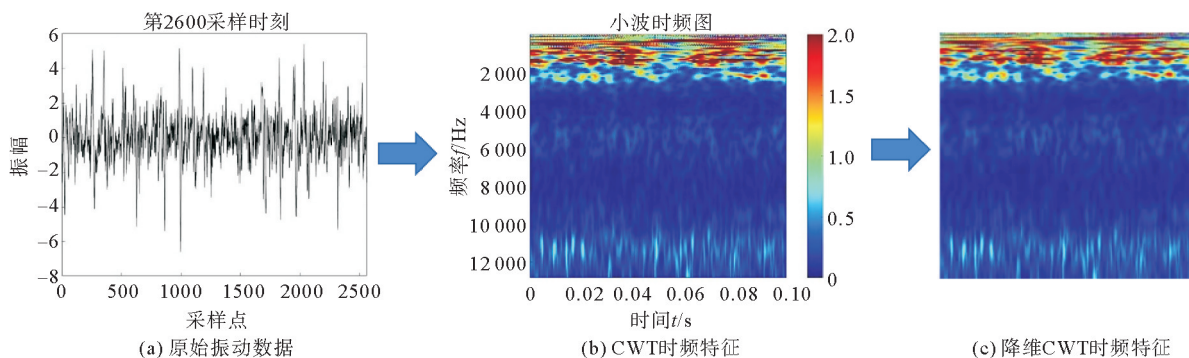


图 4 数据预处理过程

进行预测网络训练时,时频图的尺寸过大会影响到网络训练的效率。因此本文首先对原始 CWT 时频图($840 \times 840 \times 3$)使用双线性插值将其缩小到适合处理尺寸($224 \times 224 \times 3$),如图 4(b)和(c),最后将得到的每一采样时刻水平与垂直方向的时频图利用通道拼接构成新的退化数据特征($n \times 224 \times 224 \times 6$, n 为

采样时刻)。

2.2 ADRN 预测网络

本文的预测网络具体结构如图 5 所示,其中,降级卷积降采样层由 1 层 7×7 的二维卷积与 1 层二维全局平均池化组成;注意力结构由通道与空间注意力组成;可变卷积层则是由可变卷积块与下采样可变卷积块组成。




图 5 ADRN 预测网络结构

2.2.1 注意力

预测网络在训练时,首先将输入尺寸为 224×224 的时频退化数据通过卷积核为 7×7 的二维卷积进行降采样,得到退化特征(F);之后由通道与空间注意力为退化特征重新分配权重;最后,在全连接层将深度退化特征计算为健康因子 HI 之前,使用通道与空间注意力为深度退化特征(F')重新分配权重,使网络在特征提取时关注到更为重要的退化特征。具体流程如图 6 所示。

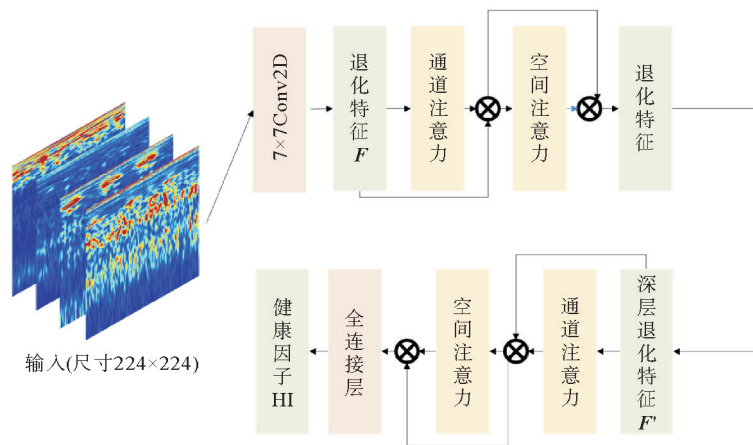


图 6 注意力机制

退化特征中的每一个通道都代表一个特征的表达,因此,为了在特征提取时充分利用特征图中的有效特征数据,使用通道注意力为特征图中的每一个通道赋予一个数值,将该数值与对应的特征图元素进行相乘计算,得到加权后的退化特征。为确定特征图不同空间方位重要程度,通过空间注意力的像素级的计算,可以得到特征图中每一通道上的每一像素值的权重。

2.2.2 深度残差可变卷积

轴承的 CWT 时频图中不同特征之间的边界划分较为复杂,而且时频图中的特征形状是不规则的,如图 4(b)所示。因此,为了获得更为准确的特征信息,本文利用可以适应特征的几何形状可变形的二维卷积构建了可变卷积层,而构成可变卷积层的可变卷积层块与下采样可变卷积块的结构如图 7 所示。

在可变卷积块中,首先由普通卷积对退化特征 D 进行 3×3 的卷积计算,并由批标准化(BachNorm2D)与激活函数(ReLU)进行处理得到退化特征 D_1 ;然后使用卷积尺寸为 3×3 的可变卷积计算 D_1 ,得到退化特征 D_2 ;最后在残差结构中 D 与 D_2 逐点相加,得到退化特征 D_3 。较于可变卷积块,下采样可变卷积块,则是在残差结构中加入了 1×1 的二维卷积,对特征进行升维和下采样处理。

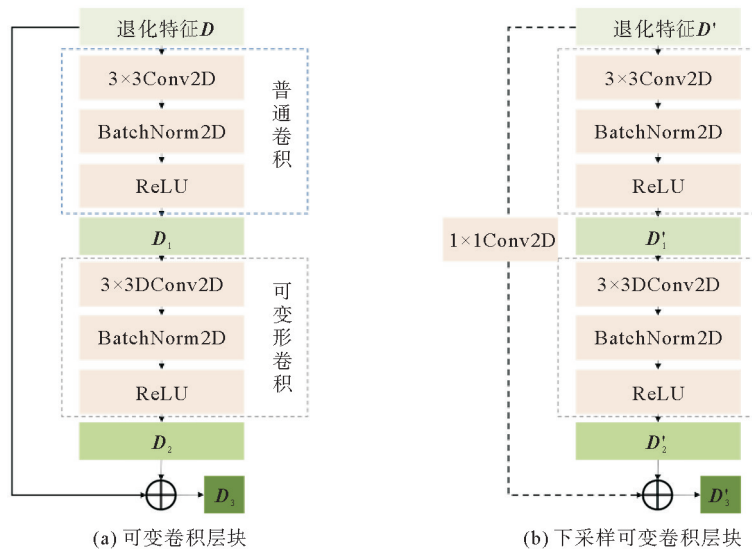


图 7 可变卷积层

可变形卷积计算时会对采样点的权重再次分配,因此在可变卷积块与下采样可变卷积块中,并没有加入空间与通道注意力。但是因为可变形的卷积计算和采样点权重分配会成倍地增加模型参数,因此本文的卷积计算并没有全部使用可变形卷积,而是加入了普通卷积来增加网络计算复杂度。同时为避免网络深度增加造成梯度的不稳定,在网络构建时加入了残差结构。

2.2.3 动态损失

滚动轴承在退化过程中经常出现瞬时突发故障,而在网络训练过程中,这些突发故障数据有可能造成影响网络精度与稳定性的异常值出现;并且随着网络的加深,计算复杂度的上升,在网络训练过程中难免出现异常值。而为了减少网络训练时异常值影响,本文将 MSE 与 RMSLE 损失函数相结合,当训练集的真实值与预测值的差小于阈值(σ)时,网络利用 MSE 损失函数训练,而当真实值与预测值的差大于阈值(σ)时则使用 RMSLE 损失函数,即

$$L = \begin{cases} \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 & |y_i - \hat{y}_i| \leq \sigma \\ \sqrt{\frac{1}{N} \sum_{i=1}^N [\ln(y_i + 1) - \ln(\hat{y}_i + 1)]^2} & |y_i - \hat{y}_i| > \sigma \end{cases} \quad (7)$$

式中: L 为损失函数; y_i 与 \hat{y}_i 分别为第 i 采样时刻的真实值与预测值; N 为总采样时刻。

当面对较小的训练误差时,MSE 可以有效地将网络收敛到最小值;而当面对较大的训练误差时,RMSLE 因对数的计算所以几乎不受影响。

为了对比不同阈值设置下的网络训练结果,本文分别设置阈值 0.01,0.05,0.1,0.5,1 和 5 进行对比训练。在训练过程中,测试集数据设置退化标签用以监督,其定义为:当前运行时刻/总运行时间,分布于 0~1 之间,代表了轴承运行到此时的损坏程度,0 为完全健康、1 为完全失效,并使用 Adam 优化器、学习率为 0.001、批量大小为 4、训练周期为 50 作为网络训练的超参数设置。PHM2012 中所有训练集的平均误差(MAE)与确定系数(R^2)的平均值如表 2 所示。

表 2 不同阈值设置下的训练结果

阈值	0.01	0.05	0.1	0.5	1	5
MAE	0.0758	0.0164	0.0198	0.0174	0.0193	0.0195
R^2	0.8696	0.9941	0.9919	0.9932	0.9926	0.9928

由表 2 可以观察到,当阈值设置为 0.01 时网络训练效果较差,而其余阈值的设置下网络训练结果非常相近,当阈值为 0.01 时网络的损失函数为 RMSLE。为了进一步选取合适的阈值设置,本文使用测试集轴承 Bearing1-6(退化过程存在异常故障)对比了不同阈值设置下的 HI 预测结果(图 8)。

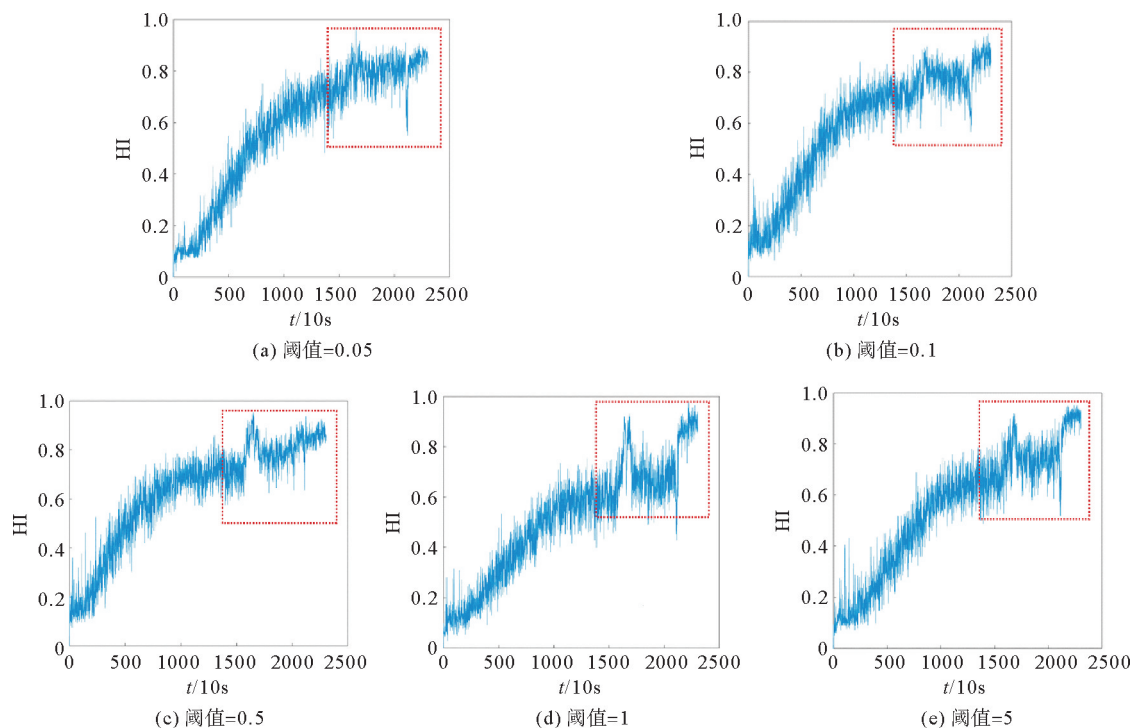


图 8 不同阈值设置下的 Bearing1-6 的预测结果

由图 8 可以看到,5 种不同阈值设置下的轴承退化趋势较为相似,但是在异常故障发生时(红色方框所标记的区域)只有阈值为 0.05 时预测结果的波动较小。因此,本文选取阈值为 0.05 的动态损失作为本文网络的损失函数。

2.2.4 HI 预测

可变形卷积层与注意力将轴承退化数据计算为深度退化特征后,首先使用展平层将退化特征转变为一维数据;然后由全连层对一维的退化特征进行下采样,并由 \tanh 激活函数输出健康因子 HI。

2.3 HI 平滑与 RUL 预测

在得到轴承的预测 HI 后,为了避免 HI 的分布震荡导致预测结果不准确,本文首先使用了 Savitzky-golay 滤波器对预测 HI 进行平滑处理;之后利用多项式拟合平滑后的 HI,得到回归函数并计算出轴承的预测 RUL。图 9 为 Bearing1-5 和 Bearing2-3 的原始预测 HI 与平滑后的 HI 对比,可见经过平滑后预测 HI 中的异常值被剔除,轴承整体退化趋势更加清晰,减少了后续 HI 拟合的误差。

测试集中轴承在不同工况下的振动表现与故障类型是不同的,因此它们的退化趋势也是不同的。如果对不同轴承使用相同的拟合函数来拟合回归 HI,会造成欠拟合现象,无法有效且准确地预测 RUL。因此,本文拟合过程中,选择均方根误差(RMSE)落在 $[0.01 \sim 0.04]$ 的多项式函数作为每一个轴承的最终拟合回归函数,图 10 为 3 种不同工况下的轴承拟合回归曲线。由图 10 可以看出,本文所选用的多项式拟合函数可以较好地拟合 HI。图 10 红框中为拟合曲线纵坐标为 1 时(轴承完全失效)的波形,其中图 10(a)与图 10(b)非常符合整体的退化趋势,因此,得出来的预测结果更加真实地反应了本文模型的预测能力。图 10(c)的退化趋势较为复杂,而本文的拟合回归函数也可以有效地拟合 HI,说明本文模型的预测能力较强。




图 9 Bearing1-5与Bearing2-3的HI与平滑HI对比

— HI; — 平滑HI




图 10 Bearing1-3、Bearing2-4与Bearing3-3的RUL预测结果

— HI; — 回归拟合

3 实验与结果分析

3.1 消融实验

为了证明本文提出的可变形卷积与注意力机制在轴承 RUL 预测任务中的有效性,设计了 4 个消融实验:a. 普通卷积+无注意力;b. 普通卷积+有注意力;c. 可变卷积+无注意力;d. 可变卷积+有注意力。

在相同的硬件环境下 4 个网络对 3 种不同工况下的轴承预测结果如表 3 所示。实验 d 在 Bearing1-3、Bearing1-4、Bearing2-5、Bearing2-6 上预测误差的绝对值最小,意味着预测的 RUL 更接近于真实 RUL;而在 Bearing1-3、Bearing1-4、Bearing2-5、Bearing3-3 上实验 d 的预测均为欠预测,意味着预测结果更贴合实际预测需求。因此,消融实验的结果证明可变卷积计算表达能力要强于普通卷积,预测结果更接近真实寿命。

表 3 消融实验预测结果

轴承	a		b		c		d	
	$P_{RUL}/10s$	误差/%	$P_{RUL}/10s$	误差/%	$P_{RUL}/10s$	误差/%	$P_{RUL}/10s$	误差/%
Bearing1-3	878.5	-53.22	617.1	-7.69	315.4	44.95	533.6	6.87
Bearing1-4	65.5	80.67	189.6	44.07	207.3	38.85	329.5	2.95
Bearing2-5	1093.4	-253.85	370.8	-19.93	282.3	8.64	286.5	7.28
Bearing2-6	233.1	-80.70	316.8	-145.58	203.5	-57.75	133.9	-3.80
Bearing3-3	141.2	-73.41	80.4	0.73	104.9	-27.92	63.3	22.8

3.2 对比实验

为了证明本文提出方法的有效性,在 PHM2012 数据集上使用预测误差与评价分数作为评价指标,与已被证明有效的 4 种方法^[12-15]进行了结果对比,如表 4 所示,由轴承真实 RUL、本文预测的 RUL、每个轴承预测误差(E)计算得到平均预测误差和预测分数 S 。文献[12]首先将原始数据处理为时频谱图,之后利用残差神经网络与时间卷积神经网络(R-T)进行退化建模;文献[13]利用长短期记忆循环网络构成的编码解码结构预测模型(LSTM-ED)进行 RUL 预测;文献[14]利用模态分解提取其中具有代表性的模态分量作为特征数据,使用循环神经网络(EMD-RL)进行预测建模;文献[15]为 PHM2012 挑战赛获胜算法(PHM2012)。

通过表 4 可以看出,与已被公开证明的方法相比,本文所提出方法的预测平均误差要小于其他方法,而且评价分数也要高一些,证明本文方法可以有效进行剩余寿命预测。

表 4 PHM2012 数据集中不同方法的预测结果对比

轴承	RUL/10s		$E/\%$				
	真实值	本文方法 预测值	本文方法	R-T ^[12]	LSTM-ED ^[13]	EMD-RL ^[14]	PHM2012 ^[15]
Bearing1-3	573	533.6	6.87	-1.37	36.30	17.28	37
Bearing1-4	339	329.5	2.95	-87.50	13.49	40.34	80
Bearing1-5	161	206.0	-27.95	-5.16	2.48	-27.33	9
Bearing1-6	146	140.1	4.04	-0.51	-12.33	-34.25	-5
Bearing1-7	757	537.1	29.40	-4.63	57.60	5.15	-2
Bearing2-3	753	756.7	-0.49	38.91	67.86	-11.69	64
Bearing2-4	139	126.2	9.20	0.77	7.91	-31.65	10
Bearing2-5	309	286.5	7.28	39.88	-41.74	-9.06	-440
Bearing2-6	129	133.9	-3.80	1.15	3.10	-13.95	49
Bearing2-7	58	74.1	-27.76	-54.17	25.86	50.00	-317
Bearing3-3	82	63.3	22.80	-57.46	6.10	-30.20	90
$ \bar{E} $	—	—	12.95	26.50	24.98	22.84	100.27
S	—	—	0.584	0.475	0.465	0.310	0.307

4 结论

本文在建立轴承预测网络时利用可变形卷积取代了部分普通卷积,并通过注意力机制与动态损失函数提升了预测网络的复杂度与稳定性。在 PHM2012 数据集中,与其他方法的预测结果相比,预测精度有较大提升。

参考文献(References):

- [1] CHOUDHARY A, GOYAL D, SHIMI S L, et al. Condition monitoring and fault diagnosis of induction motors: A review[J]. Archives of Computational Methods in Engineering, 2019, 26: 1221-1238.
- [2] 李彦夫, 韩特. 基于深度学习的工业装备 PHM 研究综述[J]. 振动、测试与诊断, 2022, 42(5): 835-847.
LI Yanfu, HAN Te. Deep learning based industrial equipment prognostics and health management: A review[J]. Journal of Vibration, Measurement & Diagnosis, 2022, 42(5): 835-847.
- [3] 马占伟, 袁逸萍, 樊盼盼, 等. 基于多尺度卷积神经网络的轴承剩余寿命预测[J]. 机械设计与制造, 2023(1): 5-8.
MA Zhanwei, YUAN Yiping, FAN Panpan, et al. Prediction of bearing residual useful life based on multi-scale convolutional neural network[J]. Machinery Design & Manufacture, 2023(1): 5-8.

- [4] 张继冬,邹益胜,邓佳林,等. 基于全卷积层神经网络的轴承剩余寿命预测[J]. 中国机械工程,2019,30(18):2231-2235.
ZHANG Jidong,ZOU Yisheng,DENG Jialin,et al. Bearing remaining life prediction based on full convolutional layer neural networks[J]. China Mechanical Engineering,2019,30(18):2231-2235.
- [5] 蔡薇薇,徐彦伟,颀潭成. 基于 CNN-LSTM 的轴承剩余使用寿命预测[J]. 机械传动,2022,46(10):17-23.
CAI Weiwei,XU Yanwei,XIE Tancheng. Prediction of bearing remaining service life based on CNN-LSTM[J]. Journal of Mechanical Transmission,2022,46(10):17-23.
- [6] 孙世岩,张钢,梁伟阁,等. 基于时间序列数据扩增和 BLSTM 的滚动轴承剩余寿命预测方法[J]. 系统工程与电子技术,2022,44(3):1060-1068.
SUN Shiyan,ZHANG Gang,LIANG Weige,et al. Remaining using life prediction method of rolling bearings based on time series data augmentation and BLSTM[J]. Systems Engineering and Electronics,2022,44(3):1060-1068.
- [7] DU Xianjun,JIA Wenchao,YU Ping,et al. RUL prediction based on GAM-CNN for rotating machinery[J]. Journal of the Brazilian Society of Mechanical Sciences and Engineering,2023,45(3):142.
- [8] ZHU Xizhou,HU Han,LIN Stephen,et al. Deformable convnets V2:More deformable,better results[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach,CA,USA,2019:9308-9316.
- [9] ZHU Jun,CHEN Nan,PENG Weiwen. Estimation of bearing remaining useful life based on multiscale convolutional neural network[J]. IEEE Transactions on Industrial Electronics,2018,66(4):3208-3216.
- [10] NECTOUX P,GOURIVEAU R,MEDJAHHER K,et al. PRONOSTIA:An experimental platform for Bearings accelerated degradation tests[C]//IEEE International Conference on Prognostics and Health Management. IEEE,2012:1-8.
- [11] 颜少廷,周玉国,任艳波,等. 基于 RLMD 和 Kmeans++ 的轴承故障诊断方法[J]. 机械传动,2021,45(2):163-170.
YAN Shaoting,ZHOU Yuguo,REN Yanbo,et al. Bearing fault diagnosis method based on RLMD and Kmeans++[J]. Journal of Mechanical Transmission,2021,45(2):163-170.
- [12] 马俊添,张素明,阎小涛,等. 基于图像识别的机械振动信号特征提取与寿命预测方法研究[J]. 宇航总体技术,2021(4):33-42.
MA Juntian,ZHANG Suming,YAN Xiaotao,et al. Research on feature extraction and remaining useful life prediction for mechanical vibration signal based on image recognition[J]. Astronautical Systems Engineering Technology,2021(4):33-42.
- [13] LIU Lu,SONG Xiao,CHEN Kai,et al. An enhanced encoder-decoder framework for bearing remaining useful life prediction[J]. Measurement,2021,170:108753.
- [14] GUO Runxia,WANG Yu,ZHANG Haochi,et al. Remaining useful life prediction for rolling bearings using EMD-RISI-LSTM[J]. IEEE Transactions on Instrumentation and Measurement,2021,70:3509812.
- [15] 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 Management. Denver,CO,USA;IEEE,2012:1-7. DOI:10.1109/ICPHM.2012.6299548.

(责任编辑 赵金环;英文校审 程文华)