

DOI:10.3969/j.issn.1001-4551.2022.11.011

基于 DRN-BiGRU 模型的滚动 轴承剩余寿命预测*

陈倩倩, 林天然*

(青岛理工大学 机械与汽车工程学院, 山东 青岛 266520)

摘要: 深度神经网络在剩余寿命预测(RUL)领域已获得了广泛应用,为进一步优化预测模型,充分提取数据间的时序信息,提高寿命预测的准确率,提出了一种结合深度残差网络(DRN)和双向门控循环单元(BiGRU)的剩余寿命预测(RUL)模型。首先,采用滑动窗法对原始数据进行了重采样,对数据集进行了扩充;然后,设计了一种 DRN-BiGRU 网络模型,其中,利用 DRN 对输入数据进行空间特征提取,利用 BiGRU 捕获时域数据中包含的过去和未来两方向的相关特征,充分获取输入数据的时序退化信息,进一步改善了模型的特征提取效果;最后,采用公开发表的 PHM2012 数据集对模型进行了验证,并将得到的预测结果与采用 DRN、DRN-GRU 和全卷积神经网络(FCNN)模型获得的结果进行了对比。研究表明:在滚动轴承剩余寿命预测应用中,采用基于 DRN-BiGRU 模型的方法获得的 3 项误差值(MAE、MSE、RMSE)最低,预测 Score 值最高,分值为 0.985;该结果验证了基于 DRN-BiGRU 模型在轴承剩余寿命预测应用方面的准确性和有效性。

关键词: 预测与健康管理;数据驱动预测方法;剩余寿命预测模型;深度残差网络;双向门控循环单元;轴承加速退化数据集

中图分类号:TH133.33;TH17

文献标识码:A

文章编号:1001-4551(2022)11-1575-07

Remaining useful life prediction of rolling bearings based on DRN-BiGRU algorithm

CHEN Qian-qian, LIN Tian-ran

(School of Mechanical and Automotive Engineering, Qingdao University of Technology, Qingdao 266520, China)

Abstract: Deep neural networks have been widely used in remaining useful life (RUL) prediction of rolling element bearings, in order to further optimize the prediction model and fully extract the time series information of the data and improve the prediction accuracy, an RUL prediction algorithm combining deep residual network (DRN) and bidirectional gated recurrent unit (BiGRU) was proposed. Firstly, the sliding window method was used to resample the original data and expand the dataset. Then, a DRN-BiGRU model was designed, the spatial features of the input data were extracted by the DRN part, and BiGRU could capture the relevant features of the past and future directions contained in the time-domain data, fully obtain the time-series degradation information of the input data, and further improve the feature extraction effect of the model. Finally, the effectiveness of the model was validated using the published PHM2012 dataset, and the prediction results were compared with those obtained using DRN, DRN-GRU and full convolutional neural network (FCNN) models. The results show that, comparing with other deep neural networks considered in this study, the proposed algorithm has the smallest prediction error in the RUL prediction of bearings and also has the highest prediction score of 0.985, which verifies the accuracy and validity of this model in the application of rolling element bearings remaining useful life prediction.

Key words: prognostic and health management (PHM); data driven forecasting method; remaining useful life (RUL) prediction model; deep residual network (DRN); bidirectional gated recurrent unit (BiGRU); bearing accelerated degradation dataset

收稿日期:2022-01-25

基金项目:国家科技部高等学校学科创新引智计划项目(D21017);青岛市创新领军人才项目(181219ZHC)

作者简介:陈倩倩(1997-),女,山东日照人,硕士研究生,主要从事机械设备故障预测与健康管理方面研究。E-mail:qianqianchen19@163.com

通信联系人:林天然,男,教授,博士生导师。E-mail:trlin@qut.edu.cn

0 引 言

作为关键的传动部件,滚动轴承被广泛应用于各类旋转机械设备中。这些关键部件若发生故障,且没有得到及时维护,会引起旋转机械整机系统的故障,影响安全生产,甚至带来巨大的经济损失^[1,2]。

因此,开展滚动轴承剩余寿命(RUL)预测研究,不仅能准确掌握其工作过程中的健康状态变化,还能够为设备健康管理策略的制定提供理论基础。在最大程度保证旋转机械正常运行的情况下,对其进行精确的寿命预测能有效节省设备的维护成本^[3,4]。

剩余寿命预测作为预测与健康管理的(PHM)领域的核心技术,在保障设备安全性和可靠性方面得到了实际应用^[5,6]。

常见的滚动轴承剩余寿命预测方法大致可分为基于物理模型方法和基于数据驱动方法。对于滚动轴承这种多元件组合式结构,很难准确建立贴合实际工况的具体物理模型,因而滚动轴承寿命预测更多地使用基于数据驱动的预测方法。数据驱动方法依靠采集的状态监测数据,建立表征设备退化程度的健康指标和预测模型,可以直接应用于滚动轴承的 RUL 预测。

近年来,随着计算机技术的发展,深度学习方法在滚动轴承的寿命预测中崭露头角^[7]。深度学习方法具有强大的非线性拟合能力,可以直接利用原始信号进行寿命预测。

张继冬等人^[8]将传统卷积神经网络(convolutional neural networks, CNN)改进为全卷积神经网络,利用卷积神经网络自学习特征预测轴承剩余寿命。在模型训练过程中,基于卷积神经网络的预测模型常会出现梯度消失和激增问题,导致预测结果产生较大偏差。为此 HE K 等人^[9,10]提出了残差网络结构,即通过在卷积层间加入“跳跃连接”结构,有效地解决了 CNN 模型训练中常见的梯度消失与激增问题,而且相较于传统 CNN 模型,其预测精度更高。目前,深度残差网络结构已经被成功应用于滚动轴承故障诊断。例如,徐卓飞等人^[11]提出了一种基于深度残差网络的轴承故障诊断方法,通过搭建多组卷积层、池化层及残差块,构成了深度网络模型,实现了故障特征的自动提取和训练。WEN L 等人^[12]提出了一种残差卷积网络模型,有效克服了卷积神经网络梯度消失问题并改善了(RUL)预测结果的平均值和偏差。

除卷积神经网络外,长短期记忆网络(long short-term memory network, LSTM)是另一种常用的预测网络。该网络通过引入“门结构”机制,增强网络对长时

间序列数据的学习记忆能力,极大程度地提高了寿命预测的准确性。而门控循环单元(gated recurrent unit, GRU)是 LSTM 的一种变形结构,具有与 LSTM 相同的优点,但其结构更为简单,同样在寿命预测领域获得了广泛应用。

肖丽^[13]以 GRU 网络为基础,结合粒子滤波方法,准确地跟踪了轴承的退化过程,并有效地提高了轴承 RUL 预测精度。韩林洁^[14]基于 CNN 和 GRU 网络,评估了滚动轴承的退化趋势,利用 GRU 处理时间序列的优势,建立了 GRU-HI 模型预测轴承退化趋势,并输出了寿命退化曲线。

BiGRU 是 GRU 算法的一个拓展,其通过采用 2 个 GRU 单元,同时处理数据的前向和后向时序信息,增强了模型的学习能力。例如,叶林峰等人^[15]提出了一种基于 BiGRU 的神经网络模型,用于锂离子电池的 RUL 预测,结果显示,该网络模型具有训练参数少、预测精度高的特点。

为了充分利用数据中包含的空间与时间特征信息,进一步提高轴承 RUL 预测的精确度,笔者提出一种结合深度残差网络(DRN)和双向门控循环单元(BiGRU)的滚动轴承 RUL 预测方法(模型)。

在该模型中,笔者通过将深度残差网络引入 RUL 预测模型中,在保证提取更多特征信息的同时,利用“跳跃连接”结构的恒等映射,解决深层网络的性能退化问题;并通过 BiGRU 同时捕获时域数据包含的过去和未来两个方向的相关信息,更准确地获取时域数据的退化特征,提高预测准确率;最后,通过分析一组公开发布的轴承退化数据集,验证该方法的有效性及其优越性。

1 基础理论

1.1 深度残差网络

深度残差网络(DRN)是在经典卷积神经网络基础上发展出来的一种深度神经网络模型,其通过引入一个“跳跃连接(shortcut connection)”结构,有效地改进了经典卷积神经网络存在的梯度消失和训练退化问题。

深度残差网络的基本残差单元(residual block, RB)如图 1 所示。

通过将实际映射表示为 $H(\mathbf{x}) = F(\mathbf{x}) + \mathbf{x}$,就可以将原本直接拟合 $H(\mathbf{x})$ 的问题转换为拟合残差函数 $F(\mathbf{x})$ 问题。当 $F(\mathbf{x}) = 0$ 时,就得到网络的最佳映射解 $H(\mathbf{x}) = \mathbf{x}$ 。




图 1 基本残差单元

x —输入; $H(x)$ —输出; $F(x)$ —残差映射函数

假设一个 DRN 网络由 L 组基本残差单元(图 1)构成,其中,每一个残差单元的输入、输出和参数分别为 x_i, x_{i+1} 与 W_i , 则可以得到:

$$y_i = h(x_i) + F(x_i, W_i) \quad (1)$$

$$x_{i+1} = f(y_i) \quad (2)$$

式中: $F(\cdot)$ —残差函数; $f(\cdot)$ —ReLU 函数。

当 $h(x_i) = x_i, f(y_i) = y_i$ 时,式(2)可转化为:

$$x_{i+1} = x_i + F(x_i, W_i) \quad (3)$$

然后,通过递归迭代方法可以推导出第 L 组残差块的输出为:

$$x_L = x_1 + \sum_{i=1}^{L-1} F(x_i, W_i) \quad (4)$$

1.2 GRU 和 BiGRU

GRU 是 LSTM 的一种变体,其结构相比 LSTM 更加简单,同时可以克服循环神经网络(recurrent neural network, RNN)存在的长依赖问题^[16]。GRU 主要由更新门和重置门组成,其中,更新门决定将多少过去的信息保存到当前时间步,而重置门则决定历史信息被遗忘的程度。

GRU 的基本结构如图 2 所示。




图 2 GRU 结构图

r_t, z_t —重置门和更新门的状态

将输入时间序列表示为 x_t , 上一时刻和当前状态记忆量分别表示为 h_{t-1} 和 h_t , 输出序列表示为 y_t , 则 GRU 网络的计算公式如下:

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t]) \quad (5)$$

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t]) \quad (6)$$

$$\tilde{h}_t = \tanh(W_h \cdot [r_t \times h_{t-1}, x_t]) \quad (7)$$

$$h_t = (1 - z_t) \times h_{t-1} + z_t \times \tilde{h}_t \quad (8)$$

$$y_t = \sigma(W_o \cdot h_t) \quad (9)$$

式中: W_r, W_z, W_h, W_o —权重矩阵; \tilde{h}_t —新的记忆内容; $\sigma(\cdot)$ —sigmoid 激活函数; $\tanh(\cdot)$ —tanh 激活函数。

通过式(5,6)计算的重置门和更新门状态,均是将经过线性变化后的输入向量 x_t 和上一时刻的记忆量 h_{t-1} 传递给 sigmoid 激活函数,输出结果将介于 0~1 之间;

将重置门 r_t 和上一时刻的记忆量 h_{t-1} 相乘,并与同样经过线性变换的输入向量 x_t 相加,然后传递到 tanh 函数中,得到新的记忆内容 \tilde{h}_t , 计算过程如式(7)所示;

式(8)给出的是当前时间步的最终记忆量 h_t 的计算过程,最后通过式(9)的 sigmoid 函数计算得到输出序列 y_t 。

BiGRU 通过组合正序和逆序 2 个 GRU, 充分利用 GRU 对时间序列顺序的敏感性,从不同方向对输入数据进行特征提取,能够捕捉到被单向 GRU 忽略的时序特征,提高特征提取的准确度^[17]。

BiGRU 网络结构如图 3 所示。




图 3 BiGRU 网络结构

BiGRU 独特的网络结构使得每个隐藏层在一个特定时间步长内可以同时捕获过去(前向)和未来(后向)的时序信息,因此, BiGRU 可以获得更加全面的特征信息,提高网络的预测性能。

2 滚动轴承的 RUL 预测模型

为了充分利用数据中的特征信息,提高轴承 RUL 预测的精度,笔者提出一种结合 DRN 和 BiGRU 的滚动轴承 RUL 预测网络结构模型。

DRN 继承了卷积网络典型的 3 大结构特性:局部连接(local connectivity)、权值共享(parameter sharing)和下采样(down sampling),并创新性地引入了残差连接结构,能更好地发挥深层网络的特征提取能力。

BiGRU 特有的双向结构有助于提取被卷积层忽略的特征信息。

两种方法结合有望提高预测的准确性。

DRN-BiGRU 模型的结构框图如图 4 所示。

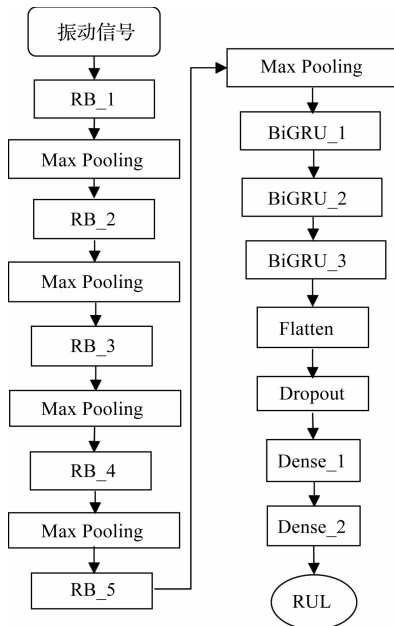


图 4 DRN-BiGRU 模型的结构框图

图 4 中：

该网络模型的 DRN 部分包含 5 个残差单元,每个残差单元的卷积核的数目和尺寸各不相同,其主要作用是对输入数据进行空间特征提取;在每一个残差单元后面都有一个最大池化层,其作用是对数据进行降采样;

在 DRN 后面添加 3 层 BiGRU,用来捕获数据的时序特性,提高模型的非线性拟合能力;网络模型末端是全连接层部分,用于输出模型预测结果。

3 实验及结果分析

3.1 数据集简介及其预处理

笔者使用的数据集是 2012 年发表在 IEEE 2012 PHM 数据挑战赛上的滚动轴承加速退化数据集^[18]。

该数据集所使用的轴承加速退化 PRONOSTIA 实验平台,如图 5 所示。




图 5 轴承加速退化 PRONOSTIA 实验平台

图 5 中,通过安装在轴承座上的加速度传感器进行数据采集,每隔 10 s 采集一次数据,采样频率为 25.6 kHz,每次采样时长为 0.1 s,即每次采集 2 560 个数据点,当数据点的加速度幅值大于 20 g 时则视为轴承失效。

该数据集包含 3 种工况,共获得 17 组滚动轴承全寿命退化数据。这 17 组数据被划分为训练集和测试集,分别用于模型的训练阶段和模型最终预测效果的测试阶段。

17 组数据的详细划分如表 1 所示。

表 1 PHM 2012 轴承退化数据集

	工况 1	工况 2	工况 3
载荷/N	4 000	4 200	5 000
转速/(r · min ⁻¹)	1 800	1 650	1 500
训练集	轴承 1—1 轴承 1—2 轴承 1—3 轴承 1—4	轴承 2—1 轴承 2—2 轴承 2—3 轴承 2—4	轴承 3—1 轴承 3—2
测试集	轴承 1—5 轴承 1—6 轴承 1—7	轴承 2—5 轴承 2—6 轴承 2—7	轴承 3—3

数据集在使用前需要进行数据增强处理,即采用滑窗法对数据进行重叠采样,重叠采样增加了数据集的特征量,有利于增强深度神经网络模型的泛化能力^[19]。

滑窗法示意图如图 6 所示。




图 6 滑窗法示意图

此处,笔者设置窗口长度为 3,移动步长为 2,重叠率为 66.7%;原始数据集每个样本的序列为 2 560 × 1,重采样后的样本序列为 7 680 × 1。

笔者对重构后的数据集进一步处理,按照“端到端”寿命预测方式,添加寿命标签,将轴承全寿命周期退化数据进行归一化处理,即:

$$\text{Label}_i = \frac{S-i}{S} \quad (10)$$

式中:S—样本数;i—时间点;Label_i—第 i 个时间点的寿命标签。

笔者将轴承的全寿命退化数据映射到 0 ~ 1 之间,即当第 i 个时间点的寿命标签 Label_i = 1 时,表示轴承为全新轴承;当 Label_i = 0 时,则表示轴承已经完全

失效。

3.2 预测流程详解及模型参数设置

整个预测流程可以划分为 3 个部分,如图 7 所示。

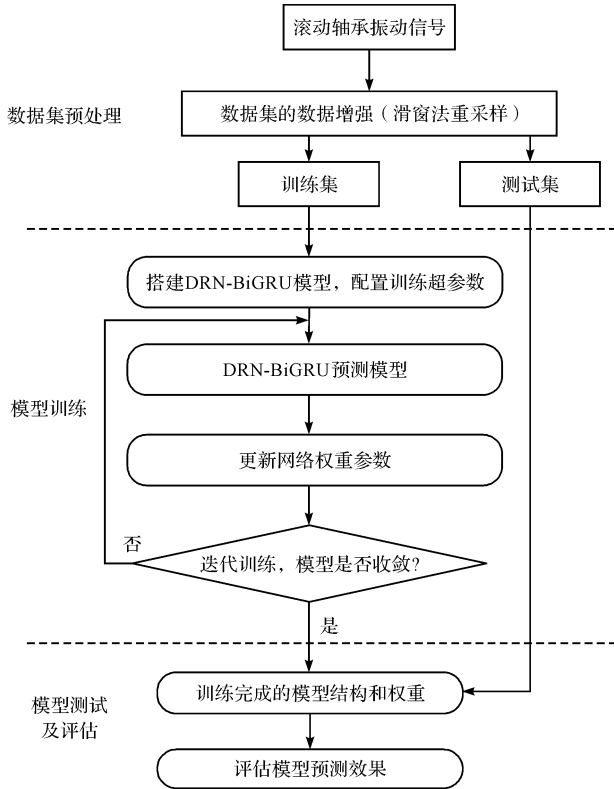


图 7 预测流程图

具体的预测流程如下：

(1) 数据集预处理。首先采用滑窗法对数据集进行重采样,再对重采样后的每组数据分别添加寿命标签；

(2) 模型训练。根据 DRN-BiGRU 模型结构,通过优化配置好结构参数和训练超参数后,将训练集的 6 组数据一次性输入模型中进行训练,输入模型的训练集又会按照 8 : 2 的比例,随机划分为训练部分和验证部分。训练过程中通过反向传播算法,使权重和配置得到优化,代价函数取最小值；

(3) 模型的测试及评估。利用已训练好的网络模型对测试集进行测试,选取评价指标,对模型进行综合评估。

为构建最优模型结构,笔者搭建了多个不同层数的网络,然后分别从训练所耗时长、训练效果和预测效果等方面进行比较分析,并根据最优原则确定模型的最佳参数,如表 2 所示。

模型训练阶段以均方误差 (mean square error, MSE) 作为模型的代价函数,每次实验进行 30 轮次,训练批量为 16,学习率为 0.001,优化算法选用 Adam 算法。

表 2 模型结构参数配置表

网络结构	单元名称	卷积核大小	参数数目	激活函数
DRN 部分	RB_1	16 × 1	16	ReLU
	RB_2	16 × 1	32	ReLU
	RB_3	8 × 1	64	ReLU
	RB_4	4 × 1	128	ReLU
	RB_5	4 × 1	256	ReLU
	Max Pooling	4 × 1	—	—
BiGRU 部分	BiGRU_1	—	50	tanh
	BiGRU_2	—	50	tanh
	BiGRU_3	—	50	tanh
全连接部分	Flatten	—	—	—
	Dropout	—	0.5	—
	Dense_1	—	16	ReLU
	Dense_2	—	1	Sigmoid

3.3 性能评价指标

在神经网络模型训练过程中,笔者使用 MSE 作为损失函数。

为更全面的评价预测结果,笔者选用平均绝对误差 (mean absolute error, MAE)、MSE、均方根误差 (root mean squared error, RMSE) 以及 Scoring 函数作为评价指标用于评估模型的有效性。

各函数计算公式如下：

$$MAE = \frac{1}{N} \sum_{i=1}^N |f(i) - \hat{f}(i)| \quad (11)$$

$$MSE = \frac{1}{N} \sum_{i=1}^N [f(i) - \hat{f}(i)]^2 \quad (12)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N [f(i) - \hat{f}(i)]^2} \quad (13)$$

$$Error_i = \frac{RUL_i - \widehat{RUL}_i}{RUL_i} (100\%) \quad (14)$$

$$A_i = \begin{cases} \exp^{-\ln(0.5) \cdot (Error_i/5)}, & Error_i \leq 0 \\ \exp^{\ln(0.5) \cdot (Error_i/20)}, & Error_i > 0 \end{cases} \quad (15)$$

$$Score = \frac{1}{N} \sum_{i=1}^N (A_i) \quad (16)$$

式中: N —样本数量; $f(i)$ —样本的真实 RUL 标签; $\hat{f}(i)$ —神经网络预测的轴承 RUL 值; RUL_i —轴承的实际 RUL 值; \widehat{RUL}_i —轴承的预测 RUL 值; $Error_i$ —第 i 个样本的百分比误差。

Scoring 函数的图像如图 8 所示。

从图 8 中可以看出：

得分函数的横坐标 $Error_i$ 介于 -50 和 50 之间,当 $Error_i$ 为 0 时,代表此时预测误差为 0,得分为 1;

Scoring 函数的图像是非对称的,因为轴承寿命的低估更能体现 RUL 预测的意义。




图 8 Scoring 函数

3.4 结果对比分析

实验中所使用的深度学习框架为 TensorFlow 1.14 平台版本,使用的编程软件为 Python3.6;工作站使用的中央处理器(CPU)为 Intel i7-6700。

在此框架下,笔者搭建了网络模型,并进行模型训练。

表 3 测试集预测 Score 平均值

轴承	1-3	1-4	1-5	1-6	1-7	2-3	2-4	2-5	2-6	2-7	3-3
Score	0.983	0.952	0.891	0.924	0.922	0.859	0.819	0.881	0.961	0.808	0.912

从表 3 中可以看出:Score 值普遍高于 0.85,在轴承 1~3 上的预测效果最佳,平均 Score 值达到 0.983。由此验证了该模型在滚动轴承 RUL 预测中的有效性。为了验证该模型的优越性,笔者选择 3

训练阶段的损失函数收敛过程如图 9 所示。




图 9 模型训练损失曲线

图 9 中,训练损失与验证损失的曲线拟合效果较好,波动较小,整体过程运行稳定。

为了验证该模型的有效性,笔者随机选取 10 个训练完成的模型,利用测试集上的 11 个轴承进行测试,计算其 Scoring 函数得分的平均值,如表 3 所示。

种深度学习方法与之进行比较,分别是 DRN、DRN-GRU、FCNN。

3 种模型在轴承 1~3 和轴承 2~6 两个测试集上的预测效果,如表 4 所示。

表 4 不同方法预测结果

模型	DRN		DRN-GRU		FCNN		DRN-BiGRU	
	轴承 1-3	轴承 2-6	轴承 1-3	轴承 2-6	轴承 1-3	轴承 2-6	轴承 1-3	轴承 2-6
MAE	0.079	0.089	0.075	0.089	0.070	0.075	0.036	0.069
MSE	0.010	0.013	0.009	0.016	0.007	0.010	0.002	0.010
RMSE	0.098	0.116	0.096	0.125	0.084	0.098	0.044	0.095
Score	0.975	0.933	0.980	0.923	0.977	0.951	0.985	0.954

从表 4 结果可以看出:

DRN-BiGRU 模型预测结果的 3 项误差最低,Score 值最高。单使用 DRN 模型预测剩余寿命,在轴承 1-3 数据上 Score 值最高可达 0.975,在轴承 2-6 数据上的预测效果一般,且 3 项误差值偏高。将 DRN 和 GRU 网络相结合得到的预测模型,预测效果并没有明显提高,但引入 GRU 网络后模型的稳定性得到明显改善。

为保留 GRU 网络的优点,采用 BiGRU 网络,可以更加全面地提取退化特征,提高网络的预测性能。

从表 4 的结果可以得出:DRN-BiGRU 模型预测结果的 3 项误差最小,且轴承 1-3 数据预测结果的 Score 值相比较 DRN 模型、DRN-GRU 模型和 FCNN 模型分别提高 1.035%、0.510% 和 0.819%,轴承 2~6 数据预测结果的 Score 值分别提高 2.25%、3.10% 和 0.315%。

从综合所有评价指标可以看出,DRN-BiGRU 模型预测效果最优。

4 个模型在轴承 1~3 数据上的预测结果,如图 10 所示。

从预测结果上能明显看出:DRN-BiGRU 模型预测曲线与实际值最符合,且没有明显的波动趋势。

综上所述,笔者所提出的方法能更有效地预测滚动轴承的剩余寿命。

4 结束语

笔者结合深度残差网络和双向门控循环单元两种算法,提出了一种用于滚动轴承 RUL 预测的 DRN-BiGRU 模型,并利用 PHM2012 轴承退化数据集验证了模型的有效性。




图 10 轴承 1-3 剩余寿命预测结果

研究表明:

(1) DRN-BiGRU 模型通过 DRN 部分实现对输入数据的空间特征提取,然后利用 BiGRU 对数据时序信息的敏感性,充分提取了轴承退化数据里包含的过去和未来两个方向的时序退化信息,改善了模型的特征提取能力;

(2) 模型利用残差网络的“跳跃连接”结构,充分发挥了深层网络良好的特征提取性能,避免了深度神经网络训练过程中存在的梯度消失等问题;

(3) 与 DRN、DRN-GRU 和 FCNN 这 3 个模型相比,DRN-BiGRU 模型不仅预测的 3 项误差值最低,而且对轴承 1~3 的预测 Score 值分别提高 1.035%、0.510% 和 0.819%,轴承 2~6 的预测 Score 值分别提高 2.25%、3.10% 和 0.315%。由此验证了 DRN-BiGRU 模型具有较高的 RUL 预测准确率。

笔者采用的验证数据集为定转速数据,但在实际工业生产过程中存在变转速、变载等的工况,轴承健康监控数据多为非稳态数据。因此,在下一步的工作中,笔者将对利用非稳态数据预测轴承 RUL 的方法做进一步的研究。

参考文献 (References):

[1] 雷亚国,贾峰,周昕,等. 基于深度学习理论的机械装备大数据健康监测方法[J]. 机械工程学报,2015,41(21):49-56.

[2] 赵广谦,姜培刚,林天然. 基于 CNN-BiLSTM 网络及注意力机制的智能滚动轴承剩余寿命预测方法[J]. 机电工程,2021,38(10):1253-1260.

[3] 赵磊,张永祥,朱丹宸. 复杂装备滚动轴承的故障诊断与预测方法研究综述[J]. 中国测试,2020,46(3):17-25.

[4] YU K, LIN T R, et al. A bearing fault and severity diagnostic technique using adaptive deep belief networks and Dempster-Shafer theory [J]. **Structural Health Monitoring**,2019,19(1):240-261.

[5] 张小丽,陈雪峰,李兵,等. 机械重大装备寿命预测综述[J]. 机械工程学报,2011,47(11):100-116.

[6] CUI L, WANG X, WANG H, et al. Remaining useful life prediction of rolling element bearings based on simulated performance degradation dictionary [J]. **Mechanism and Machine Theory**,2020,153(6):103967.

[7] 沈保明,陈保家,赵春华,等. 深度学习在机械设备故障预测与健康管理中的研究综述[J]. 机床与液压,2021,49(19):162-171.

[8] 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.

[9] HE K, ZHANG X, REN S, et al. Deep Residual Learning for Image Recognition [C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE,2016.

[10] HE K, ZHANG X, REN S, et al. Identity Mappings in Deep Residual Networks [C]. Berlin: Springer, Cham,2016.

[11] 徐卓飞,武丽花,黄卿,等. 基于深度残差网络的滚动轴承故障诊断方法[J]. 机械设计与研究,2021,37(3):78-83.

[12] WEN L, DONG Y, GAO L. A new ensemble residual convolutional neural network for remaining useful life estimation [J]. **Mathematical Biosciences and Engineering**,2019(16):862-880.

[13] 肖丽. 基于 GRU 网络的滚动轴承剩余寿命预测研究[D]. 武汉:武汉科技大学信息科学与工程学院,2020.

[14] 韩林洁. 基于 CNN 和 GRU 的滚动轴承退化状态评估及剩余寿命预测[D]. 北京:机械科学研究总院,2020.

[15] 叶林峰,石元博,黄越洋. 基于 BiGRU 网络的锂电池寿命预测[J]. 电源技术,2021,45(5):598-601.

[16] 霍爱清,张文乐,李浩平. 基于深度残差网络和 GRU 的 SqueezeNet 模型的交通路标识别[J]. 计算机工程与科学,2020,42(11):2030-2036.

[17] 张兰霞,胡文心. 基于双向 GRU 神经网络和双层注意力机制的中文文本中人物关系抽取研究[J]. 计算机应用与软件,2018,35(11):130-135,189.

[18] NECTOUX P, GOURIVEAU R. PRONOSTIA: An Experimental Platform for Bearings Accelerated Degradation Tests [C]. IEEE International Conference on Prognostics and Health Management. IEEE,2012.

[19] 张伟. 基于卷积神经网络的轴承故障诊断算法研究[D]. 哈尔滨:哈尔滨工业大学机电工程学院,2017.

[编辑:雷敏]

本文引用格式:

陈倩倩,林天然. 基于 DRN-BiGRU 模型的滚动轴承剩余寿命预测[J]. 机电工程,2022,39(11):1575-1581.

CHEN Qian-qian, LIN Tian-ran. Remaining useful life prediction of rolling bearings based on DRN-BiGRU algorithm [J]. *Journal of Mechanical & Electrical Engineering*, 2022,39(11):1575-1581.

《机电工程》杂志: <http://www.meem.com.cn>