



计算机科学

COMPUTER SCIENCE

基于机器学习的剩余使用寿命预测实证研究

王加昌, 郑代威, 唐雷, 郑丹晨, 刘梦娟

引用本文

王加昌, 郑代威, 唐雷, 郑丹晨, 刘梦娟 [基于机器学习的剩余使用寿命预测实证研究](#) [J]. 计算机科学, 2022, 49(11A): 211100285-9.

WANG Jia-chang, ZHENG Dai-wei, TANG Lei, ZHENG Dan-chen, LIU Meng-juan. [Empirical Research on Remaining Useful Life Prediction Based on Machine Learning](#) [J]. Computer Science, 2022, 49(11A): 211100285-9.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[对抗性网络流量的生成与应用综述](#)

Generation and Application of Adversarial Network Traffic:A Survey

计算机科学, 2022, 49(11A): 211000039-11. <https://doi.org/10.11896/jsjcx.211000039>

[R-YOLOv5:自动切割的旋转的文本检测模型](#)

R-YOLOv5:Auto-cutting,Rotated Text Detection Model

计算机科学, 2022, 49(11A): 210900185-6. <https://doi.org/10.11896/jsjcx.210900185>

[基于注意力机制的手写体数字识别](#)

Handwritten Digit Recognition Based on Attention Mechanism

计算机科学, 2022, 49(11A): 211100009-5. <https://doi.org/10.11896/jsjcx.211100009>

[多字体印刷体维-哈-柯文关键词图像识别](#)

Multi-font Printed Uyghur-Kazakh-Kirghiz Keyword Image Recognition

计算机科学, 2022, 49(11A): 211100038-6. <https://doi.org/10.11896/jsjcx.211100038>

[融合ViT卷积神经网络的木板表面缺陷识别](#)

Wood Surface Defect Recognition Based on ViT Convolutional Neural Network

计算机科学, 2022, 49(11A): 211100090-6. <https://doi.org/10.11896/jsjcx.211100090>

基于机器学习的剩余使用寿命预测实证研究

王加昌¹ 郑代威² 唐雷¹ 郑丹晨¹ 刘梦娟²

¹ 中国核动力研究设计院核反应堆系统设计技术重点实验室 成都 610213

² 电子科技大学网络与数据安全四川省重点实验室 成都 610054

摘要 剩余寿命预测是设备预测性维护的3个核心任务之一。目前最新的研究进展是利用机器学习来建立剩余使用寿命预测模型。论文首先梳理了设备剩余使用寿命预测主要采用的机器学习模型,包括支持向量回归模型、多层感知机模型、卷积神经网络和循环神经网络;然后介绍了3个在剩余使用寿命(Remaining Useful Life, RUL)预测中主要采用的公开数据集,以及两个广泛采用的预测性能评价指标。特色之处是基于NASA提供的涡扇发动机仿真数据集C-MAPSS展示了RUL预测建模的基本步骤和关键技术细节,详细比较了几种代表性预测模型的性能。实验结果显示浅层结构的支持向量回归模型的性能确实显著弱于包含深度神经网络的模型;而在深度神经网络中,卷积神经网络和循环神经网络又显示出了各自在挖掘复杂特征交互以及时序特征交互之间的强大能力。最后展望了剩余寿命预测技术的发展前景并讨论了面临的主要挑战。

关键词: 预测性维护; 剩余使用寿命预测; 机器学习; 支持向量回归; 多层感知机; 卷积神经网络; 循环神经网络

中图分类号 TP393

Empirical Research on Remaining Useful Life Prediction Based on Machine Learning

WANG Jia-chang¹, ZHENG Dai-wei², TANG Lei¹, ZHENG Dan-chen¹ and LIU Meng-juan²

¹ Science and Technology on Reactor System Design Technology Laboratory, Nuclear Power Institute of China, Chengdu 610213, China

² Network and Data Security Key Laboratory of Sichuan Province, University of Electronic Science and Technology of China, Chengdu 610054, China

Abstract Remaining useful life(RUL) prediction is one essential task of the predictive maintenance system. This paper investigates the latest RUL prediction methods, focusing on direct RUL prediction based on machine learning. Firstly, we describe the four representative machine learning models adopted by the RUL prediction methods, including support vector regression(SVR), multilayer perceptron(MLP), convolutional neural network(CNN), and recurrent neural network(RNN). And then, we give the three primary benchmark datasets and two performance evaluation metrics widely used in RUL prediction. The contribution of this paper is to demonstrate the steps and key technical details of how to build the RUL prediction models over the benchmark dataset(C-MAPSS) provided by NASA. We also compare the performance of these representative prediction models in detail and visually analyze the experimental results. Experimental results show that the performance of SVR with a shallow structure is significantly weaker than those based on deep neural networks. CNN and RNN based models have a solid ability for mining complex feature interaction and temporal feature interaction. Finally, we provide an outlook on the future of predictive maintenance technology and discuss the main challenges.

Keywords Predictive maintenance, Remaining useful life prediction, Machine learning, Support vector regression, Multilayer perceptron, Convolutional neural network, Recurrent neural network

1 引言

随着人工智能、工业物联网、云计算等技术的飞速发展,智能制造已经成为工业发展的一个重要趋势。其目的是利用人工智能技术将行业知识与海量产业数据融合,从而优化工业的生产方式和决策模式,提升效率,降低成本。目前智能制造的研究和应用大都还处于起步阶段,其中设备的预测性维护作为代表性应用近年来受到了学术界和工业界的广泛关注^[1]。工业设备在长期运行中发生故障是无法完全避免的,

如果故障不能得到有效应对,轻则造成生产中断、经济损失,重则造成人员伤亡甚至公众安全危害^[2]。而预测性维护技术旨在根据设备运行的实时数据,结合设备的退化机理,利用人工智能技术对设备运行状态进行监测,在故障(退化)早期进行预警,并诊断故障类型及预测设备剩余使用寿命,最后据此制定最优的应对方案。预测性维护技术不仅能够保障设备的可靠性和安全性,而且能够有效降低维修成本,减少停机时间以及提高生产任务的完成率^[3]。

图1给出了预测性维护技术的基本步骤和主要功能。首先

基金项目:国家自然科学基金(61202445);中央高校基本业务费项目(ZYGX2016J096)

This work was supported by the National Natural Science Foundation of China(61202445) and Fundamental Research Funds for the Central Universities of Ministry of Education of China(ZYGX2016J096).

通信作者:王加昌(jiachang.wang@163.com)

通过设备上的仪表和嵌入式传感器采集设备运行的实时工况数据。这些数据可能是不同量纲的数值特征,如温度、压强、振动幅度等,因此需要对数据进行预处理,将其映射为适合模型学习的特征表示。对于复杂工业设备,通常会有大量的工况参数,不同的参数代表了不同的物理含义,有的与设备的退化有关,有的与设备的退化无关,因此,如何选择对建模最有效的工况参数(或参数组合)将是解决问题的关键点之一。可以通过统计学方法实现特征自动选择,也可以依赖于有经验的领域专家来手动选择。如图 1 所示,预测性维护的实现依赖于 3 个核心任务,分别是设备运行状态的评估,设备故障类型的智能诊断,以及设备剩余寿命预测^[4]。这 3 类任务通常都采用基于数据驱动方法来建模实现。目前已有大量文献针对这 3 类任务的建模展开研究^[4-6]。本文主要聚焦在设备剩余寿命(Remaining Useful Life, RUL)预测任务的研究,准确的说是利用机器学习方法来建立 RUL 预测模型。

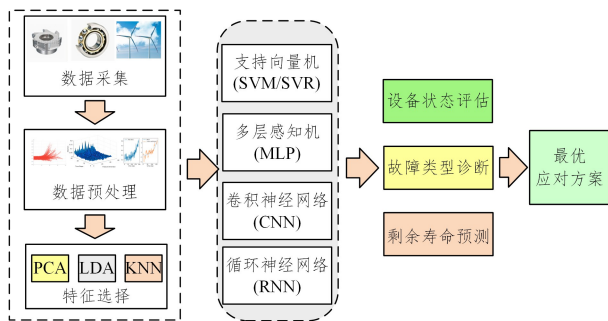


图 1 预测性维护的基本框架

Fig. 1 Primary framework of predictive maintenance

本文首先对代表性的基于机器学习的 RUL 预测模型进行了梳理,分析了各自的特点;然后对主要的公开基准数据集进行了总结并给出了主要的性能评价指标;在此基础上,论文基于美国航空航天局(NASA)提供的涡扇发动机退化仿真数据集(C-MAPSS)^[7]展示了 RUL 预测建模的基本步骤和关键技术细节,并对实验结果进行了讨论;最后对 RUL 预测技术的发展前景进行了展望并讨论了面临的主要挑战。本文的工作将为不同领域的研究人员利用机器学习方法建立 RUL 预测模型提供有益的指导和建议。

2 基于机器学习的 RUL 预测建模

设备的 RUL 预测一直是学术界和工业界的关注重点。早期的研究主要集中在通过实验数据基于物理学定律来建立精确的失效模型^[8-9]。这类物理模型通常使用一组动态常微分方程或偏微分方程来描述,然后利用拉格朗日对偶原理、哈密顿动力学等方法求解。其中比较典型的是针对材料裂纹的疲劳过程建模,建立裂纹的总应变寿命方程^[8]。基于物理模型的 RUL 预测通常只适合简单故障引起的寿命退化,对于复杂设备很难用简单的物理模型准确描述,因此在近期的预测性维护研究中,更倾向于采用数据驱动的 RUL 预测方法。

数据驱动方法又可进一步细分为基于统计学的方法和基于机器学习的方法,如图 2 所示。统计学方法通常采用自回归移动平均、马尔可夫模型、维纳过程等。例如文献^[10]首先将电梯的运行状态利用逻辑回归估计发生故障的概率,然后以概率值作为健康状态因子,输入到自回归移动平均模型中估计电梯正常运行的剩余寿命。这类方法主要依靠专业领域

知识来建立模型,通常是利用已知数据拟合随机过程模型或系数模型,在描述退化过程的不确定性及其对预测结果的影响时非常有效。

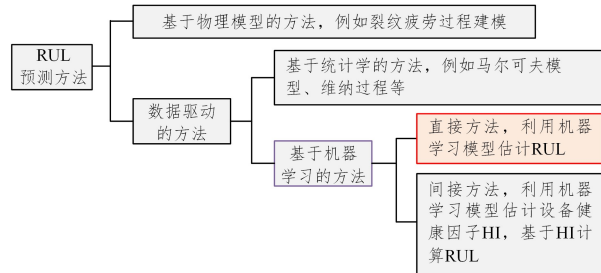


图 2 RUL 预测方法分类

Fig. 2 Classification of RUL prediction methods

近年来,机器学习方法特别是深度学习方法也被广泛应用于 RUL 预测并取得了令人满意的效果,包括:支撑向量回归模型(SVR)^[11]、多层感知机(MLP)^[12]、卷积神经网络(CNN)^[13-14]、循环神经网络(RNN)^[15-16]等。这类方法根据是否需要构建健康因子(Health Index, HI)分为直接预测法和间接预测法^[17]。本文主要对代表性的基于机器学习的 RUL 直接预测方法进行梳理,从而归纳出 RUL 预测建模的基本步骤。

2.1 基于机器学习的直接预测方法

通过端到端的方式学习 RUL 预测模型是目前 RUL 研究中采用最多的方法,它直接将设备的运行状态参数预处理后输入到机器学习模型中,机器学习模型直接输出 RUL 预测值,如图 3 所示。这类端到端的方法充分利用了机器学习模型对非线性特征的学习能力,具有良好的预测效果。通常直接预测方法包括构建样本集、特征预处理及特征工程、模型选择、模型训练 4 个基本步骤。这里,构建样本集是指基于设备历史的从正常运行到失效(run-to-failure)的周期性参数记录构建时序的训练样本。每个样本的特征由设备运行的工况参数组成,标记是当前设备运行周期距离设备失效时间周期的差值。由于设备的状态参数是时序的,因此需要考虑一个样本是只需要包含当前时间周期的工况参数,还是需要冗余地包含前序若干时间周期的设备工况参数。




图 3 基于机器学习的直接预测方法示意图

Fig. 3 Illustration of the direct RUL prediction method based on machine learning

另一个挑战是当设备处于正常运行状态或故障初期时,虽然可以准确计算出当前时间周期到设备失效的准确时间(如图 4 中的黑色线段),但是学习这个时间对于 RUL 预测模型来说是非常困难的,因为设备的工况参数在正常运行周期内是无显著变化的。只有当设备进入显著的退化状态时,工况参数才会有显著的变化,剩余使用寿命(RUL)才会随着运行时间呈单调递减趋势。因此,在标记样本的真实 RUL 值时,通常采用分段线性模型进行简化,即设置一个距离设备失效的运行时间阈值 RUL_m ,当剩余使用寿命大于阈值时,认为设备仍然处于正常运行状态,设置剩余使用寿命为一个恒定的常数值;当剩余使用寿命小于或等于阈值时,认为设备进入显著退化状态,此时设置剩余使用寿命为设备剩余的运行

时间周期,如式(1)所示:

$$RUL_t = \begin{cases} RUL_{th}, & \text{if } (T-t) > RUL_{th} \\ T-t, & \text{else} \end{cases} \quad (1)$$

其中, T 表示设备从开始运行到最终停止的总的运行周期数, t 表示设备当前运行周期。




图4 设备寿命的分段性示意图

Fig. 4 Illustration of the piece-wise RUL prediction

样本集构建完成后,每个样本包含多个传感器采集的实时工况参数。首先,这些工况参数的量纲是各异的,如温度、转速、排量等,因此需要对这些参数进行归一化处理,以使其适合于模型学习。其次,众多的特征参数只有部分与设备退化状态相关,而无关特征参数如果被输入到模型中,会对最终的RUL预测产生干扰。因此需要对这些参数进行特征工程,选择对最终RUL预测有关联的特征参数或特征参数组合。特征工程可以采用主成分分析、自编码器编码^[18]等复杂方法将多个特征编码为一个状态向量,也可以采用简单的单变量进行退化趋势分析。

在机器学习中,最重要的环节是设计模型结构,其本质是通过不同的模型来对非线性的RUL预测函数进行模拟。本文对RUL预测中主要采用的几种机器学习模型进行了梳理,分别是支持向量回归模型、多层感知机模型,以及深度结构的卷积神经网络和循环神经网络。图5给出了SVR的原理示意,对于一组训练样本, $\mathbf{X} = \{(x_1, RUL_1), (x_2, RUL_2), \dots, (x_N, RUL_N)\}$, 希望学习回归函数 $f(x) = \mathbf{w}^T \mathbf{x} + b$, 使得 $f(x_i)$ 与 RUL_i 尽可能接近。这里, \mathbf{w} 和 b 是模型参数,可通过拉格朗日对偶原理求解。SVR问题可描述为式(2)的形式。SVR非常适合小样本场景的预测问题,因此是早期RUL预测最常采用的机器学习模型之一。

$$\begin{aligned} \min_{\mathbf{w}} & \frac{1}{2} \|\mathbf{x}\|^2 + C \sum_{i=1}^N (\xi_i + \xi_i^*) \\ \text{s. t. } & y_i - \mathbf{w}^T \mathbf{x}_i - b \leq \varepsilon + \xi_i, \mathbf{w}^T \mathbf{x}_i + b - y_i \leq \varepsilon + \xi_i^*, \\ & \xi_i, \xi_i^* \geq 0 \end{aligned} \quad (2)$$




图5 支持向量回归模型示意图

Fig. 5 Illustration of SVR

另一种RUL预测在早期采用较多的模型是多层感知机(Multilayer Perceptron, MLP),它通过模拟神经元的工作原理来实现预测任务。MLP的基本结构如图6所示,包括一个

输入层,若干隐层和一个只包含一个神经元的输出层。MLP的模型参数可以采用随机梯度算法调优。早期由于硬件计算能力的限制,MLP只能包含两个隐层,导致模型对非线性特征组合的挖掘能力受到限制,随着硬件计算能力的提升,MLP的隐层数量可以根据需要增加,使得可以通过挖掘更复杂高阶特征组合的信息,来提升模型的预测性能。




图6 多层感知机模型示意图

Fig. 6 MLP structure

随着深度学习模型的提出,具有更强非线性特征挖掘能力的深度神经网络已经被广泛应用到RUL预测中。比较有代表性的是卷积神经网络和循环神经网络。图7展示了一个二维卷积神经网络的结构示意图,它包括卷积层(包含激活)、池化层、全连接层以及最后的输出层。对于输入的二维数据进行卷积操作,不仅可以挖掘特征之间的隐含关联,还可以挖掘不同时间周期特征之间的隐含关联;池化层的作用是降低卷积后的特征表示维度,从而减少参数数量,提高抗噪声的鲁棒性;最后需要预测RUL值,因此需要将二维的特征表示展开为一维的特征向量,通过全连接层来实现预测。




图7 卷积神经网络模型示意图

Fig. 7 CNN structure

SVR, MLP和CNN这3种模型都不能直接学习特征之间的时序关系,为了挖掘时序特征的信息,通常只能在构建样本时,同时包含当前以及之前若干时间周期的特征参数。而循环神经网络因为其本身的神经元具有记忆能力,因此具有良好的处理时序数据的能力。但是RNN通常存在梯度消失(爆炸)的问题,因此目前更多的是采用RNN的两种变形(GRU和LSTM)来替代RNN。图8给出了一个包含多个隐层的RNN结构。神经网络模型(MLP, CNN, LSTM)是通过最小化损失函数来对模型参数进行调优的。因此定义合适的损失函数对模型性能有重要的影响。在RUL预测任务中,可以采用预测值与真实值的均方误差(MSE),也可以采用如3.2节中式(4)定义的预测评分(Score)均值。

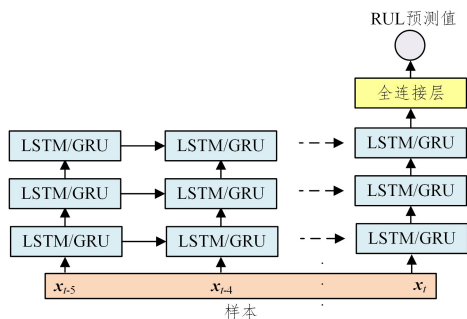


图8 循环神经网络(LSTM/GRU)模型示意图

Fig. 8 RNN (LSTM/GRU) structure

表 1 列出了几种代表性的机器学习模型的优缺点。其中,SVR 只需要少量的训练样本,即可得到较为准确的 RUL 预测性能,模型原理简单,可解释性强。SVR 是线性回归的变形,因此只能挖掘单个特征携带的信息,预测性能有限。MLP 通过隐层的神经元对所有特征进行不同模式的线性组合来挖掘多个特征之间的复杂交互,因此预测性能相比最简单的线性回归有所提升,但是由于 RUL 预测的应用场景中样本数量相对较少,过多的参数会导致模型欠拟合,从而影响预测性能。

SVR 和 MLP 都不能学习特征的时序信息,即使在一个样本中包含了特征在多个连续时间周期的参数值,模型只能将这些参数值分别作为独立的特征参数来进行处理。CNN 虽然也不能处理时序信息,但是它能将包含多个连续时间周期特征参数的样本作为一个二维矩阵输入到模型,通过卷积操作来挖掘特征之间,以及特征在不同时序之间的信息。需要说明的是,CNN 的神经元没有记忆能力,实质上仍然是将特征在不同时序上的参数值作为独立特征来进行处理。不同于 SVR,MLP 和 CNN,LSTM 和 GRU 本身带有记忆单元,

能够记忆前一时间周期的处理结果,因此能直接挖掘特征的时序信息。另一方面,由于采用了深度神经网络,基于 MLP, CNN,LSTM,GRU 的预测模型都很难在物理意义上进行解释。这些代表性模型都是通用模型,可以应用在各种设备、零部件的 RUL 预测上。采用哪种模型建模主要根据样本数量决定,如果样本数量少,建议采用 SVR 和 MLP;如果样本数量多,建议采用 CNN 和 LSTM 以及 GRU。

表 1 4 种代表性模型的特点及研究文献整理

Table 1 Characteristics of four representative models and their literature

模型	优缺点	研究文献
SVR	适合小样本学习,无法挖掘复杂的高阶特征信息,无法挖掘特征的时序信息	[11,19-20]
MLP	支持挖掘复杂的高阶特征,无法挖掘特征的时序信息	[12,21-22]
CNN	能够将包含时序特征的样本以二维形式输入,通过卷积操作挖掘特征间的复杂交互信息以及特征自己的时序信息	[13-14,23-24]
LSTM/GRU	能够将包含时序特征的样本以二维形式输入,模型具有记忆能力,能够有效挖掘特征的时序信息以及高阶交互信息	[15-16, 25-28]




图 9 基于相似度的 RUL 间接预测方法示意图

Fig. 9 Illustration of the indirect RUL prediction method based on HI similarity

2.2 基于机器学习的间接预测方法

除了端到端的直接训练 RUL 预测模型,还有一类基于相似度的间接预测方法,如文献[17]提出的 BiLSTM-ED 和文献[29]提出的 GRU-ED。这类方法的基本思路如图 9 所示。在离线阶段,模型基于设备的历史运行数据训练设备的健康因子(HI)预测模型,从而构建健康因子退化曲线库;在线阶段,对于一个给定设备的运行状态序列参数,首先基于 HI 预测模型计算给定序列状态的一系列 HI 值,得到该设备的运行状态的 HI 曲线,然后寻找与测试设备 HI 曲线最相似的历史 HI 曲线,并基于若干相似的 HI 曲线来计算测试设备的剩余寿命。

基于相似性的预测方法中的主要问题在于 HI 指标的构建、相似度评估时间范围确定、相似度的定量评估以及基于相似度的权重构建等。不同于端到端的直接预测方法,这种基于相似度的间接预测方法,主要利用机器学习模型来计算设备在每个时间周期的 HI 值,目前广泛采用的机器学习模型包括线性回归模型、支持向量回归模型、GRU、LSTM 等。这类方法的好处是无论设备状态处于哪个阶段都可以进行预测,且具有良好的可解释性,对于相关领域的研究人员来说非常容易理解。但是相比直接预测法,间接预测方法额外引入了 HI 指标,步骤更为繁琐,反而影响了 RUL 估计的准确性。因此,本文主要集中在直接预测法。

2.3 基于融合模型的直接预测方法

2.1 节主要介绍了单个机器学习模型进行 RUL 直接预测的方法。目前最新的研究是将多个机器学习模型或者机制

应用到 RUL 预测中。例如,文献[26]提出将 Attention 机制引入特征的表示学习中,从而实现在输入最终的预测模型之前进行关键特征参数的增强。文献[30]提出的 CNN-LSTM 方法,其基本思路是将原始的样本输入到 CNN 中进行特征表示学习,再将 CNN 加强后的特征表示输入到 LSTM 模型中进行 RUL 预测。这类方法的基本思路如图 10(a)所示。

这里,研究人员可以根据 RUL 预测任务的具体场景,引入适合场景的机器学习模型来对特征表示进行学习。不同于这类串行结构的融合模型,文献[31]提出了一种新的并行结构的融合模型,如图 10(b)所示。实验证明这种新模型可以利用不同的机器学习模型来同时学习原始特征的高阶表示,从而提升 RUL 预测模型性能。

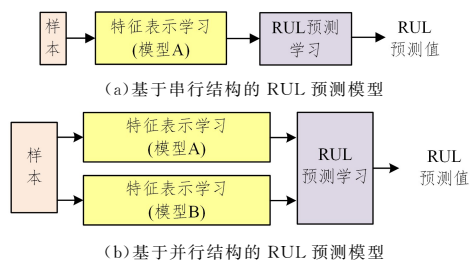


图 10 基于融合学习模型的 RUL 预测

Fig. 10 RUL prediction models based on joint learning

3 基准数据集及评价指标

3.1 基准数据集

收集设备从运行到失效的轨迹数据是利用机器学习建立

RUL 预测模型的关键。但是由于技术、商业、安全等原因导致目前公开的设备运行状态数据非常少。在设备 RUL 预测方面,目前研究主要采用 3 类数据集,分别是涡扇发动机仿真数据集、轴承实验数据集、铣刀数据集。本节对这 3 类数据集进行了简单整理,如表 2 所列。通过调研发现 C-MAPSS 数据集是研究中最常采用的基准数据集(篇幅原因,只列出部分引用文献),因此本文也采用这个数据集进行实证研究。需要说明的是,随着我国对预测性维护技术的逐渐重视,也出现了一些设备的运行状态数据集,如轴承、风机等。但是由于缺少统一的平台对这些数据集进行长期维护,很快就无法找到这些数据集的有效下载地址。因此,建立类似于 NASA Prognostics Center of Excellence(PCoE)这样的针对预测性维护的技术中心,对相关领域的发展具有长远的意义。

表 2 可用于 RUL 预测的基准数据集

Table 2 Benchmark datasets for RUL prediction

设备	数据集	描述	相关文献
涡扇发动机	C-MAPSS	由 NASA 的 C-MAPSS 仿真软件生成的涡扇发动机退化仿真数据	[13-16, 24-26, 28]
	PHM 08		[15, 22, 24-25, 26, 30]
轴承	PHM 12	由 FEMTO-ST 研究所提供的轴承退化数据	[18, 23, 33-35]
铣刀	milling	由 UC Berkeley 提供的铣刀磨损退化数据	[15, 17, 32]

3.2 评价指标

本文主要采用均方误差 (RMSE) 和评分 (Score) 作为 RUL 预测模型的性能评价指标,定义分别如式 (3) 和式 (4) 所示。

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2} \quad (3)$$

$$Score = \sum_{i=1}^N A_i, A_i = \begin{cases} e^{-\frac{\hat{y}_i - y_i}{13}} - 1, & \hat{y}_i - y_i < 0 \\ e^{\frac{\hat{y}_i - y_i}{10}} - 1, & \hat{y}_i - y_i \geq 0 \end{cases} \quad (4)$$

其中, N 表示测试集中测试样本的数量, \hat{y}_i 和 y_i 分别是第 i 个测试样本的预测 RUL 和标记 RUL。对于 Score 指标, A_i 表示单个测试样本的得分, Score 指标对于 RUL 预测值小于真实值的情况惩罚分数较低,对于大于真实值的情况惩罚分数较高。这是因为在 RUL 预测场景中,预测值偏大导致的危害远大于预测值小于真实 RUL 值的危害。

4 实证分析

4.1 数据集介绍

本文的特色是以 NASA 的 C-MAPSS 涡扇发动机仿真数据集为例,介绍 RUL 预测模型建立的基本步骤和技术细节。本节首先简单描述 C-MAPSS 数据集,它包括 4 个子集: FD001, FD002, FD003, FD004。在每个子集中记录了同类发动机在各种故障模式及工况下,从正常运行到失效的状态参数轨迹。表 3 列出了每个数据子集的具体情况,其中 FD001 中的发动机在仿真时只设置了 1 种故障模式和 1 种工况,因此运行状态最简单,工况参数随时间的变化比较一致; FD002 和 FD004 有 6 种工况设置,因此运行状态比较复杂,不同工况设置下同一个传感器参数的变化趋势可能完全相反,如果直接使用参数值可能会影响 RUL 预测模型的性能,因此需

要先将不同工况的发动机运行轨迹记录进行聚类,再进行预处理。此外,训练集中,给出了每台发动机从正常运行到失效的完整轨迹;测试集中,只给出了发动机运行状态参数的一段轨迹,以及轨迹的最后时间周期距离发动机失效的真实 RUL 值。

表 3 数据集的统计情况

Table 3 Statistics on four subsets

	FD001	FD002	FD003	FD004
故障模式	1	1	2	2
工况类型	1	6	1	6
训练集中发动机数	100	260	100	249
测试集中发动机数	100	259	100	248

4.2 样本构建及特征预处理

首先需要构建训练和测试样本集。如前所述,为了使每个训练样本中包含时序的状态参数特征,引入了步长为 1 个时间周期的滑动窗口机制,如图 11 所示。假设一个涡扇发动机的总的运行周期是 T ,滑动窗口的大小为 W ,则这个运行轨迹可以构建 $T - W + 1$ 个样本。训练样本的标记采用式 (1) 所示的分段线性函数进行标记。测试集中每个发动机轨迹构建 1 个测试样本,如果轨迹中包含的时间周期数不足窗口大小,则用轨迹中最早的时间周期的参数值填充样本。

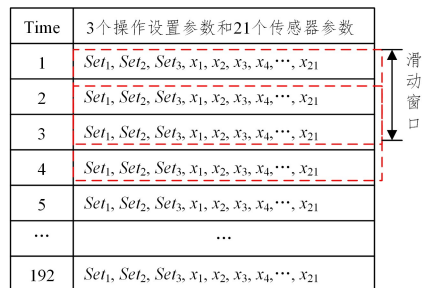


图 11 利用滑动窗口构建训练样本示意图

Fig. 11 Illustration of constructing sample using sliding window

在样本集构建完成后,需要对数据集提供的参数进行预处理。由于 FD002 和 FD004 有 6 种工况设置,不同工况设置可能导致某些参数在退化过程中表现出不同的趋势。因此,首先将这两个子集中的发动机基于 3 个运行参数进行聚类,得到 6 种不同工况设置下的发动机运行轨迹。在每种工况类别下,利用式 (5) 对样本的每个参数进行归一化,这里 $x_{m,k}$ 表示样本中第 m 个传感器参数在第 k 种工况设置下的值, $\mu_{m,k}$ 是第 m 个传感器参数在第 k 种工况下的均值, $\sigma_{m,k}$ 是该传感器参数在第 k 种工况设置下取值的方差。

$$x_{m,k} = \frac{x_{m,k} - \mu_{m,k}}{\sigma_{m,k}} \quad (5)$$

在此基础上,可以得到每个参数在退化过程中的变化曲线。通过简单的单因素趋势分析,可以发现 21 个传感器参数中,某些参数在退化过程中无显著变化,如果将这些参数作为特征可能会干扰模型的预测性能,因此本文的实验中只选择了在退化过程中有显著变化趋势的 14 个传感器参数,序号分别是 2, 3, 4, 7, 8, 9, 11, 12, 13, 14, 15, 17, 20, 21。结合 3 个工况设置参数,每个样本中包含的特征数为 17 个,样本的 RUL 标记采用如图 4 所示的分段线性法, RUL_{th} 设置为 125。

4.3 模型调优及性能比较

4.3.1 基于 SVR 的预测模型性能调优

机器学习模型结构设计是 RUL 预测建模的关键。本节

对几个代表性的机器学习模型的预测性能进行评价。由于训练集样本的构建依赖于对滑动窗口大小的设置,因此首先通过简单的 SVR 模型讨论不同窗口大小对性能的影响,从而确定本实验中设置的窗口大小。SVR 的核函数为高斯核函数,依次设置窗口大小为 1,10,20,30,40,50,得到的性能指标如表 4 所列。

表 4 基于 SVR 的 RUL 预测性能

Table 4 Performance of RUL prediction models based on SVR

滑动窗口大小		1	10	20	30	40	50
FD001	RMSE	19.03	20.09	18.56	16.12	14.55	14.44
	Score	1587	1998	1242	633	411	333
FD002	RMSE	18.50	17.43	16.06	15.18	14.00	13.44
	Score	8020	2295	1405	1140	840	793
FD003	RMSE	21.56	22.06	20.88	19.11	17.68	16.90
	Score	3122	3208	2278	1462	1066	1062
FD004	RMSE	21.56	19.70	19.16	17.84	16.77	16.22
	Score	5733	3587	3626	2269	1565	1370

可以发现,随着滑动窗口大小增加,样本中包含的时序特征越多,模型的预测误差呈显著的递减趋势。这是因为随着滑动窗口大小的增加,样本中包含的特征数也随之增多,使得预测模型可以利用的信息也增加,从而提升了模型预测性能。

表 5 基于 MLP 的 RUL 预测性能

Table 5 Performance of RUL prediction models based on MLP

(a)FD001 上的性能评价结果

评价指标	隐层数	隐层节点数				
		100	200	300	400	500
RMSE	1	13.76	14.24	14.11	14.20	14.47
Score		333	349	341	332	323
RMSE	3	14.82	14.40	14.22	13.95	14.35
Score		392	331	348	318	373
RMSE	5	15.38	14.07	13.19	13.52	13.56
Score		375	337	274	328	311
RMSE	7	15.47	13.03	13.68	13.70	13.51
Score		394	289	366	308	291

(c)FD003 上的性能评价结果

评价指标	隐层数	隐层节点数				
		100	200	300	400	500
RMSE	1	12.54	12.71	13.04	13.09	12.79
Score		286	310	333	327	291
RMSE	3	13.23	12.86	12.82	13.42	12.62
Score		361	353	340	391	302
RMSE	5	13.94	13.63	12.77	13.44	13.29
Score		292	375	387	359	357
RMSE	7	17.22	14.38	13.81	15.05	14.57
Score		422	410	369	428	412

(b)FD002 上的性能评价结果

评价指标	隐层数	隐层节点数				
		100	200	300	400	500
RMSE	1	13.82	14.27	14.57	14.81	14.77
Score		794	875	937	922	938
RMSE	3	15.95	15.71	14.89	14.40	14.83
Score		1165	1074	1108	937	967
RMSE	5	16.86	15.87	14.58	14.75	14.45
Score		1143	978	901	800	971
RMSE	7	18.77	15.56	14.79	15.81	15.58
Score		1202	1111	1005	1109	934

(d)FD004 上的性能评价结果

评价指标	隐层数	隐层节点数				
		100	200	300	400	500
RMSE	1	15.59	15.69	16.12	15.24	15.31
Score		999	1121	1644	1027	1011
RMSE	3	15.40	15.35	15.43	15.53	15.37
Score		1147	1047	1162	1158	1177
RMSE	5	16.31	15.54	15.01	14.93	14.61
Score		1378	1257	1124	1263	1112
RMSE	7	23.77	14.74	14.94	15.13	14.63
Score		2345	1101	1151	1090	1265

4.3.3 基于 CNN 的预测模型性能调优

第三组实验用于评价基于 CNN 的 RUL 预测模型的性能。首先评价文献[24]和文献[13]这两个代表性的 CNN 方案的性能,模型结构分别如图 12 和图 13 所示。其中,文献[24]利用卷积操作同时挖掘特征之间和特征时序之间的复杂交互关系;而文献[13]利用卷积操作只挖掘时序特征上的交互信息,保持各个特征之间的空间关系不变。实验结果如表 6 所列,可以看到文献[13]的预测性能显著优于文献[24],分析原因是文献[24]的卷积操作同时考虑了所有传感器特征的交互,因此卷积操作后样本的特征表示变为了一维特征向量,虽然采用了多个卷积核,但是样本中包含的信息被大幅压缩,同时它采用“池化”操作进行降维,也使得特征表示向量中

当窗口大小增加到 50 时,SVR 的性能达到最优。但是,由于测试集中每台发动机只给出了部分运行状态轨迹,最少的运行状态轨迹只包含 31 个时间周期,如果设置窗口太大,会导致重复填充信息过多,可能会影响预测性能。因此,在本文的后续实验中设置窗口大小为 40。同时,表 4 的结果也显示 SVR 能取得较好的 RUL 预测效果。

4.3.2 基于 MLP 的预测模型性能调优

第二组实验用于评价 MLP 模型的 RUL 预测性能。为了探索最优的模型结构,依次设置模型隐层数为 1,3,5,7,设置隐层节点数为 100,200,300,400,500,隐层节点采用 ReLU,实验结果如表 5 所列。从实验结果中可以观察到,不同数据子集对应的最优 MLP 结构有差异。在本文实验中以 Score 分数最小作为最优选择的依据,因此 FD001 中是 5 个隐层,每个隐层 300 个节点时取得的 Score 分数最低;FD002,FD003,FD004 都是 1 个隐层,每个隐层 100 个节点时取得的 Score 分数最低。这一实验结果说明了并非隐层数越多,隐层节点数越多,模型预测性能就越好。这是因为在训练样本有限的情况下,一直提升隐层数或隐层节点数,会使得模型需要学习的参数过多,从而导致模型欠拟合,影响模型的预测性能。

包含的信息一定程度减少,从而导致预测性能差强人意。文献[13]取得了不错的性能,说明利用卷积操作来挖掘样本中的时序特征信息是有效的。

虽然文献[24]在每次卷积操作中考虑所有特征,导致模型的预测性能不理想,但是利用卷积同时挖掘特征之间以及特征时序之间的复杂交互信息仍是一种可行的方案,为此本组实验通过修改卷积核的大小和卷积核数量,探索是否有更优的 CNN 模型结构。通过设置较小的卷积核,避免卷积操作后特征表示从矩阵变为向量,同时放弃池化,避免“降维”导致信息损失。实验结果如表 7 所列。实验结果显示,在 4 个测试子集上,文献[13]的方案仍然非常有竞争力。




图 12 文献[24]采用的卷积神经网络结构

Fig. 12 CNN structure in [24]




图 13 文献[13]采用的卷积神经网络结构

Fig. 13 CNN structure in [13]

表 6 文献[24]和文献[13]的 RUL 预测模型性能

Table 6 Performance of RUL prediction models in [24] and [13]

文献	评价指标	FD001	FD002	FD003	FD004
[24]	RMSE	16.03	18.46	18.04	20.31
	Score	461	2807	918	3363
[13]	RMSE	11.43	12.83	12.62	13.90
	Score	241	660	310	862

表 7 基于 CNN 的预测模型性能

Table 7 Performance of RUL prediction models based on CNN

数据集	卷积核数	卷积核[1×1]		卷积核[3×3]		卷积核[5×5]	
		RMSE	Score	RMSE	Score	RMSE	Score
FD001	4	12.72	264	14.00	327	14.28	403
	6	13.07	280	13.48	316	13.62	340
	8	12.98	277	13.50	288	14.33	483
FD002	4	13.05	801	13.47	948	13.46	780
	6	13.09	852	13.16	865	13.28	867
	8	13.04	826	13.45	854	13.46	846
FD003	4	13.75	609	14.47	720	14.54	691
	6	14.35	867	14.48	801	14.54	635
	8	14.62	1010	15.17	1091	14.20	637
FD004	4	14.30	964	14.20	941	14.81	1050
	6	14.29	926	13.94	965	14.54	1040
	8	14.41	948	14.50	1039	14.70	1237

4.3.4 基于 LSTM 的预测模型性能调优

第四组实验用于评价 LSTM 模型的性能。与 MLP 类似,依次设置模型隐层数为 1,3,5,7,设置隐层神经元数为 100,200,300,400,500,隐层神经元采用 ReLU,实验结果如表 8 所列。从实验结果中可以观察,当隐层的层数设置为 7 时,模型性能显著下降。FD001,FD002,FD003 子集中最优 LSTM 结构均是隐层数 1,FD001 中隐层节点数目为 200,FD002 中隐层节点数为 400,FD003 中隐层节点数目为 300,FD004 中最佳结构为隐层数是 3,隐层节点数目为 500。这说明对于设备 RUL 预测这样的小样本数据集场景,隐层数和隐层节点数都不宜设置过多,以避免模型训练不充分。

表 8 基于 LSTM 的 RUL 预测性能

Table 8 Performance of RUL prediction models based on LSTM

(a)FD001 上的性能评价结果

评价指标	隐层数	隐层节点数				
		100	200	300	400	500
RMSE	1	13.60	12.85	13.37	13.60	13.46
Score		342	282	328	364	352
RMSE	3	14.28	14.15	13.86	31.21	22.42
Score		439	369	364	8802	5207
RMSE	5	14.57	14.76	40.25	40.64	40.16
Score		429	405	14371	18886	12970
RMSE	7	31.53	40.42	40.20	40.35	40.30
Score		10486	16860	13552	16026	14871

(b)FD002 上的性能评价结果

评价指标	隐层数	隐层节点数				
		100	200	300	400	500
RMSE	1	13.11	13.25	12.91	12.81	12.95
Score		852	856	855	755	795
RMSE	3	13.44	13.28	13.49	13.42	33.43
Score		855	855	894	886	35983
RMSE	5	13.40	13.24	13.37	33.60	23.13
Score		970	863	839	36760	16897
RMSE	7	13.84	23.40	24.03	23.49	23.02
Score		999	17099	19485	14442	15311

(c)FD003 上的性能评价结果

评价指标	隐层数	隐层节点数				
		100	200	300	400	500
RMSE	1	13.96	12.50	12.05	12.61	12.82
Score		528	336	288	319	308
RMSE	3	13.00	12.75	13.10	32.40	41.05
Score		482	288	401	22780	28832
RMSE	5	12.93	12.89	23.13	41.06	21.52
Score		302	380	11020	29048	8755
RMSE	7	13.46	41.33	41.59	31.07	41.02
Score		713	31542	34381	16363	28382

(d)FD004 上的性能评价结果

评价指标	隐层数	隐层节点数				
		100	200	300	400	500
RMSE	1	13.76	13.59	13.21	13.23	13.62
Score		903	919	843	911	921
RMSE	3	13.93	13.70	13.07	13.69	13.48
Score		889	1064	875	1015	820
RMSE	5	14.01	13.88	23.55	24.09	43.70
Score		915	1040	25593	27374	80982
RMSE	7	13.95	33.96	34.15	34.11	44.48
Score		956	67368	73415	58534	114521

4.3.5 实证结果总结

基于上述实验结果,选择每种代表性方案在每个子集中性能最优的模型结构用于综合比较,如表9所列。总体来说,浅层结构的SVR模型的预测性能最差,显著弱于采用神经网络的模型;而在神经网络模型中,不同于集上,3个模型的性能表现各有优劣,在FD001和FD002上,CNN具有较好的表现;在FD003和FD004上,具有时序特征挖掘能力的LSTM表现较好。说明CNN更适合于故障模式比较单一的数据集,而LSTM更适合于故障模式比较复杂的数据集。但是对于RUL预测这样的小样本学习场景,神经网络的隐层数、隐层节点数并非越多越好,因为这样模型需要学习的参数就越多,会导致模型学习不充分,欠拟合。因此,建议在进行模型调优时,可从1个隐层开始,逐层递增比较模型性能。此外,考虑到LSTM和CNN在挖掘特征交互关键信息方面都有良好表现,如果能将两者优势进行融合,相信对于提升RUL预测模型的性能有一定帮助。

表9 4个代表性模型的最优性能

Table 9 Performance of four representative models

模型	FD001		FD002		FD003		FD004	
	RMSE	Score	RMSE	Score	RMSE	Score	RMSE	Score
SVR	14.44	333	13.44	793	16.90	1062	16.22	1370
MLP	13.19	274	13.82	794	12.54	286	15.59	999
LSTM	12.85	282	12.81	755	12.05	288	13.48	820
CNN	11.43	241	12.83	660	12.62	310	13.90	862

5 挑战与研究趋势

本文对预测性维护中的设备剩余使用寿命预测技术进行了调研,特别介绍了基于机器学习的RUL直接预测方法并进行了量化的实证分析。实验结果表明,利用机器学习方法确实可以建立有效的RUL预测模型,且步骤简单,易于扩展到不同领域的应用场景中。然而,在实际应用调研中,发现基于机器学习的RUL预测技术仍然停留在研究阶段,在现实设备维护中真正落地应用还存在较多的阻碍。本文最后对RUL预测在研究和应用中面临的关键挑战进行分析,并对该领域的研究趋势进行展望。

RUL预测研究面临的第一个挑战是缺乏高质量基准数据集。如前所述,绝大多数研究人员都采用NASA提供的涡扇发动机仿真数据集,或者来自于实验平台的轴承和铣刀数据集。这3类数据集的仿真和实验场景设计都非常简单,与真实设备运行工况有较大的差距。而数据集对于机器学习方法来说是至关重要的,因此建立更多设备的复杂工况数据集将是RUL预测研究的一个重要方向和必要基础。

RUL预测研究面临的第二个挑战是工况参数的理解与预处理困难。不同设备的运行工况是复杂的,如何将工况参数预处理为机器能理解的形式,同时挖掘参数对于RUL预测隐含的关键信息对于单个的领域专家或者数据科学家是非常困难的,如采集的振动信号、音频信号、电流信号等,通常需要领域专家进行专业分析后才能应用于机器学习模型。因此建立针对不同场景的通用信号处理方法或工具箱可以进一步促进RUL预测的研究,提升预测性能。

RUL预测研究面临的第三个挑战是数据集样本数量有限。机器学习方法本质是通过学习大量的样本来优化模型参数,从而达到准确预测,而RUL预测任务中构建样本需要完

整的设备从正常运行到失效的轨迹数据,现实生产系统中,设备数量有限,且设备非计划停机本身是小概率事件,从而导致搜集到的数据集样本数量是有限的。因此,设计适合于小样本数据集的机器学习模型或模型预训练方法将是RUL预测研究的另一个重要方向,如使用迁移学习等。

RUL预测研究面临的第四个挑战是机器学习模型缺乏可解释性。传统的剩余使用寿命预测都是基于物理模型,如变形失效、断裂失效、腐蚀失效、磨损失效等,每种情况都是通过实验得到可解释的物理模型来进行估计的。而机器学习模型,特别是包含深度神经网络的模型,目前的工作机理还不明确,难以进行解释。因此,引入具有一定可解释性的模型来建立RUL预测模型将是RUL预测研究的另一个热点。

RUL预测研究面临的第五个挑战是模型超参数的自动优化问题。目前针对小数据样本,模型超参数的设置通常通过手动调整,例如根据模型性能选择适合于当前数据集的隐层数,隐层节点数等。然而,当数据样本非常多时,模型超参数优化会成为一个难点。关于这个问题最新的研究思路是利用自动机器学习技术(Automated Machine Learning)自动探索。

最后,虽然预测性维护技术在我国的研究应用还处于起步阶段,但是随着工业互联网技术在我国广泛普及,大规模收集设备运行工况数据将变得可行,相信RUL预测技术将会获得更多来自工业界的关注和真实落地应用。

参考文献

- [1] KOTHAMASU R, HUANG S H, VERDUIN W H. System health monitoring and prognostics—a review of current paradigms and practices [J]. *International Journal of Advanced Manufacturing Technology*, 2006, 28(9/10): 1012-1024.
- [2] ZENG Y Y. Research on life prediction algorithm of Nuclear power plant based on condition monitoring data [D]. Beijing: Tsinghua University, 2017.
- [3] CHEN H Y. Research on condition prediction and diagnosis method of thermal hydraulic System in nuclear Power plant [D]. Heilongjiang: Harbin Engineering University, 2018.
- [4] REZAEIANJOUYBARI B, YI S. Deep learning for prognostics and health management: State of the art, challenges, and opportunities [J]. *Measurement*, 2020, 163: 107929.
- [5] ZHANG L, LIN J, LIU B, et al. A Review on Deep Learning Applications in Prognostics and Health Management [J]. *IEEE Access*, 2019, 7(1): 162415-162438.
- [6] SI X S, WANG W, HU C H, et al. Remaining useful life estimation—A review on the statistical data driven approaches [J]. *European Journal of Operational Research*, 2011, 213(1): 1-14.
- [7] 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.
- [8] WANG Y R, YANG S, LI H X, et al. Determination and life prediction of fatigue parameters in total strain life equation [J]. *Chinese Journal of Aerospace Power*, 2018, 33(1): 1-14.
- [9] WU X R, LIU J Z. Fatigue life prediction of aerospace materials based on small crack theory [J]. *Chinese Journal of aviation*, 2006, 27(2): 219-226.
- [10] YANG J H, KOC M, LEE J. A prognostic algorithm for machine performance assessment and its application [J]. *Production Planning & Control*, 2007, 15(8): 796-801.

- [11] WANG X L, HAN G, LI X, et al. A SVR-Based Remaining Life Prediction for Rolling Element Bearings [J]. *Journal of Failure Analysis and Prevention*, 2015, 15(4): 548-554.
- [12] TIAN Z. An artificial neural network method for remaining useful life prediction of equipment subject to condition monitoring [J]. *Journal of Intelligent Manufacturing*, 2012, 23(2): 227-237.
- [13] LI X, DING Q, SUN J Q. Remaining useful life estimation in prognostics using deep convolution neural networks [J]. *Reliability Engineering & System Safety*, 2018, 172(APR.): 1-11.
- [14] SONG Y, GAO S, LI Y, et al. Distributed Attention-Based Temporal Convolutional Network for Remaining Useful Life Prediction [J]. *IEEE Internet of Things Journal*, 2020, 8(12): 9594-9602.
- [15] SHUAI Z, RISTOVSKI K, FARAHAT A, et al. Long Short-Term Memory Network for Remaining Useful Life estimation [C] // 2017 IEEE International Conference on Prognostics and Health Management (ICPHM). IEEE, 2017.
- [16] LIAO Y, ZHANG L, LIU C. Uncertainty Prediction of Remaining Useful Life Using Long Short-Term Memory Network Based on Bootstrap Method [C] // 2018 IEEE International Conference on Prognostics and Health Management (ICPHM). IEEE, 2018: 1-8.
- [17] YU W, KIM I Y, MECHEFSKE C. Remaining useful life estimation using a bidirectional recurrent neural network based autoencoder scheme [J]. *Mechanical Systems and Signal Processing*, 2019, 129(AUG. 15): 764-780.
- [18] REN L, SUN Y, CUI J, et al. Bearing remaining useful life prediction based on deep autoencoder and deep neural networks [J]. *Journal of Manufacturing Systems*, 2018, 48: 71-77.
- [19] LIU X Y, XIONG Z G, YAN C G. A fusion support vector machine-Prediction of residual service life of machinery by high order particle filter method [J]. *Journal of Guizhou University: Natural Science Edition*, 2018, 35(5): 74-80.
- [20] HU J, QIAN X, CHENG H, et al. Remaining useful life prediction for aircraft engines based on phase space reconstruction and hybrid VNS-SVR model [J]. *Journal of Intelligent and Fuzzy Systems*, 2021, 41(2): 3415-3428.
- [21] RH A, LX A, XL B, et al. Residual life predictions for ball bearings based on self-organizing map and back propagation neural network methods [J]. *Mechanical Systems and Signal Processing*, 2007, 21(1): 193-207.
- [22] PEEL L. Data driven prognostics using a Kalman filter ensemble of neural network models [C] // 2008 International Conference on Prognostics and Health Management. IEEE, 2008.
- [23] WANG X, WANG T, MING A, et al. Deep Spatiotemporal Convolutional Neural Network-based Remaining Useful Life Estimation of Bearings [J]. *Chinese Journal of Mechanical Engineering*, 2021, 34: 1-15.
- [24] BABU G S, ZHAO P, LI X L. Deep Convolutional Neural Network Based Regression Approach for Estimation of Remaining Useful Life [C] // International Conference on Database Systems for Advanced Applications. Cham: Springer, 2016.
- [25] LU Y W, HSU C Y, HUANG K C. An Autoencoder Gated Recurrent Unit for Remaining Useful Life Prediction [J]. *Processes*, 2020, 8(9): 1-18. .
- [26] CHEN Z, WU M, ZHAO R, et al. Machine Remaining Useful Life Prediction via an Attention Based Deep Learning Approach [J]. *IEEE Transactions on Industrial Electronics*, 2021, 68(3): 2521-2531.
- [27] REN L, CHENG X, WANG X, et al. Multi-scale Dense Gate Recurrent Unit Networks for bearing remaining useful life prediction [J]. *Future generation computer systems*, 2019, 94(MAY): 601-609.
- [28] ELSHEIKH A, YACOUT S, OUALI M S. Bidirectional handshaking LSTM for remaining useful life prediction [J]. *Neurocomputing*, 2019, 323(Jan. 5): 148-156.
- [29] GUGULOTHU N, VISHNU T V, MALHOTRA P, et al. Predicting remaining useful life using time series embeddings based on recurrent neural networks [C] // 2nd ML PHM Work. SIGKDD 2017, Halifax, Canada, 2017.
- [30] CHEN Z Q. Research on equipment health condition evaluation and residual life prediction method based on LSTM network [D]. Anhui: University of Science and Technology of China, 2019.
- [31] AL DULAIMI A, ZABIHI S, ASIF A, et al. A multimodal and hybrid deep neural network model for Remaining Useful Life estimation [J]. *Computers in Industry*, 2019, 108: 186-196.
- [32] EKER, Ö F, CAMCI F, JENNIONS I K. Major Challenges in Prognostics: Study on Benchmarking Prognostics Datasets [C] // Proceedings of the European Conference of the PHM Society 2012. PHM Society, 2012.
- [33] ZHANG L Z. Research on Residual Service Life prediction of Rolling Bearings based on time-frequency analysis and deep learning [D]. Shandong: Shandong University, 2021.
- [34] FAN B. Research on fault prediction method for health management of aircraft Key Components [D]. Hunan: National University of Defense Technology, 2015.
- [35] LI X, ZHANG W, DING Q. Deep learning-based remaining useful life estimation of bearings using multi-scale feature extraction [J]. *Reliability Engineering & System Safety*, 2019, 182(FEB.): 208-218.



WANG Jia-chang, born in 1978, post-graduate, senior engineer. His main research interests include nuclear reactor simulation and data mining.