

基于时间序列迁移递归预测的未知工况下 滚动轴承在线剩余寿命评估

陈佳鲜¹, 毛文涛^{1,2†}, 刘京¹, 王港胜¹

(1. 河南师范大学 计算机与信息工程学院, 河南 新乡 453007;

2. 智慧商务与物联网技术河南省工程实验室, 河南 新乡 453007)

摘要: 深度迁移学习技术已经成功应用于跨工况的滚动轴承剩余寿命 (remaining useful life, RUL) 预测问题, 但针对在线场景的 RUL 评估仍存在如下不足: 在线工况存在漂移, 无法确定同工况的历史数据, 不能直接构建回归预测模型; 在线目标轴承只有正常状态和早期故障数据, 无法直接与离线轴承的快速退化期数据进行迁移学习. 鉴于此, 从时序退化信息迁移的角度提出一种面向未知工况的轴承在线 RUL 评估方法. 首先, 构建融合第三方退化信息的时间序列迁移递归预测模型, 利用张量长短时记忆网络提取离线工况全寿命数据的单调性和趋势性等时序信息, 并迁移到在线递归预测过程; 然后, 利用迁移成分分析对所预测的在线退化序列和已有离线序列进行公共特征空间适配, 提取域无关特征, 并构建支持向量机回归模型, 实现在线轴承剩余寿命评估. 在 IEEE PHM Challenge 2012 轴承数据集上的实验结果表明, 所提出方法可在只有早期故障数据的情况下准确预测退化趋势, 为未知工况下的轴承在线 RUL 评估提供一种有效的解决方案.

关键词: 剩余寿命评估; 深度学习; 迁移学习; 时间序列递归预测; 领域适配; 滚动轴承

中图分类号: TP17

文献标志码: A

DOI: 10.13195/j.kzyjc.2021.1011

引用格式: 陈佳鲜, 毛文涛, 刘京, 等. 基于时间序列迁移递归预测的未知工况下滚动轴承在线剩余寿命评估 [J]. 控制与决策, 2023, 38(1): 112-122.

Online remaining useful life estimation of bearing under unknown working conditions based on time series transfer recursive prediction

CHEN Jia-xian¹, MAO Wen-tao^{1,2†}, LIU Jing¹, WANG Gang-sheng¹

(1. School of Computer and Information Engineering, Henan Normal University, Xinxiang 453007, China; 2. Henan Engineering Laboratory of Smart Business and Internet of Things Technology, Xinxiang 453007, China)

Abstract: Deep transfer learning technology has been successfully applied to the remaining useful life (RUL) prediction of bearings across different working conditions. However, the existing methods encounter the following problems in online scenarios: 1) Due to the drift of online working conditions, it is hard to accumulate the historical data from the same working condition and then build a regression model for the prediction directly. 2) Online target bearing only has the data of the normal state and early fault state, so it is challenging to directly perform transfer learning with the offline bearing data of the fast degradation period. To solve these problems, an online RUL estimation method for unknown working conditions is proposed from the transfer of temporal degradation information. Firstly, a new time series transfer recursive prediction model integrating prior degradation information is constructed. Employing the tensor long short-term memory, the temporal information of the whole-life data in the offline working conditions, such as monotonicity and tendency, is extracted and transferred to the online recursive prediction process for getting online degradation sequence. Then, the transfer component analysis is adopted to adapt the common feature space of the predicted online degradation sequence and existing offline sequences. By extracting domain-invariant features and constructing support vector machine model, the RUL of online bearing can be evaluated. Experiments are conducted on the IEEE PHM Challenge 2012 bearing dataset. The results show that, the proposed method can accurately estimate the degradation trend only using early fault data, and provide an effective solution for the online RUL estimation under an unknown working condition.

Keywords: remaining life prediction; deep learning; transfer learning; time series recursive prediction; domain adaptation; rolling bearing

收稿日期: 2021-06-09; 录用日期: 2021-11-10.

基金项目: 国家重点研发计划重点专项项目 (2018YFB1701400); 国家自然科学基金项目 (U1704158); 河南省科技攻关重点项目 (212102210103).

责任编辑: 胡清华.

†通讯作者. E-mail: maowt@htu.edu.cn.

0 引言

作为机械设备中重要但易发生损坏的旋转部件,滚动轴承的健康状况直接影响到整个设备的运转状态.对滚动轴承进行有效的故障预测有利于预防重大事故的发生,其中,准确评估轴承的剩余可用寿命(remaining useful life, RUL)是故障预测与健康管理(prognostics and health management, PHM)的关键环节之一^[1].随着人工智能技术的发展,基于数据驱动的RUL预测方法受到工业界和学术界的关注,如何利用历史采集的状态监控数据提升目标轴承RUL预测效果具有明确的学术和应用价值.

本文关注未知工况下轴承的在线RUL评估问题,描述为在设备不停机状态下根据少量的在线数据进行实时的剩余寿命评估,避免因等待停机检查产生延误,造成损失,因此对未知工况下剩余寿命的在线评估越来越受到工业界的重视.由于在线应用场景的制约,与一般RUL预测问题相比,未知工况下在线RUL评估存在如下挑战:1)实际应用存在工况漂移现象,即在线工况无法预知,因此若直接利用离线数据构建回归预测模型则易产生模型偏差;2)在线目标轴承只有正常状态数据和部分早期故障数据已知,若利用离线工况的全寿命数据进行领域适配,则因缺乏在线的快速退化期数据而无法建立预测模型.上述问题如图1所示,其中离线工况下已积累多条同型号轴承的全寿命退化数据,而在线工况的具体信息未知,属于未知工况,目标轴承仅积累了正常状态数据和少量的早期故障数据(图1(b)中 t_1 时刻~ t_2 时刻),

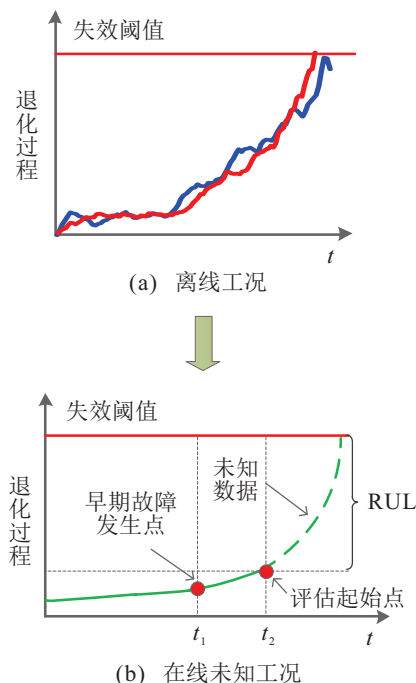


图1 未知工况下轴承在线RUL评估

无法提前采集在线工况下的全寿命退化数据,也无法储备其他同型号轴承的历史数据,因此不能直接构建RUL评估模型,即无法直接预测在线未知工况下轴承的RUL值.如何在早期故障发生之初即对在线未知工况下轴承的剩余寿命进行有效评估是本文要解决的核心问题.由于同型号轴承在不同工况下的退化趋势具有内在的相似性^[2],一个直观的思路是借助离线数据蕴含的故障演化信息实现对未知工况下轴承RUL的实时评估.

目前,RUL预测的方法多基于数据驱动,主要做法是提取退化过程数据的故障特征,并利用支持向量机(support vector machine, SVM)^[3]、随机森林^[4]、隐马尔可夫^[5]等机器学习算法构建回归模型.近年来,深度学习方法已被引入轴承RUL预测领域,例如卷积神经网络(convolutional neural network, CNN)^[6]、长短时记忆网络(long short-term memory, LSTM)^[7].由于神经网络可以直接从原始数据中提取敏感特征,与传统的浅层模型相比,基于深度学习的RUL预测方法具有自适应特征提取、端到端建模等特点.Deutsch等^[8]使用故障特征的时间序列作为深度置信网络(deep belief networks, DBN)的输入,挖掘退化过程的时序信息,有效提高了RUL预测模型的准确性.但是,上述方法均假设存在大量的轴承数据,故障信息丰富,且轴承退化数据满足独立同分布条件.然而,对于在线RUL预测问题,受工况漂移现象的影响,实际在线工况难以确定,无法获取大量同分布的退化过程数据,限制了传统深度学习方法的RUL预测效果.

近几年,深度迁移学习开始应用于轴承RUL预测问题,并迅速成为研究热点.通过挖掘不同领域之间的相似性关系,迁移学习可将源域学习到的领域知识应用于目标域,提高目标任务的学习效果^[9].在轴承PHM领域,深度迁移学习已成功解决了剩余寿命预测问题^[2,10].其中,作为代表性工作,Zhu等^[2]通过多层感知机提取故障特征,利用最大均值差异(maximum mean discrepancy, MMD)适配不同工况数据的特征空间,实现基于特征迁移的RUL预测;Zhang等^[10]通过参数微调技术,将离线数据训练的双向LSTM模型参数迁移到目标数据的LSTM模型,实现基于参数迁移的RUL预测.此类方法在模型训练时均需借助部分目标域的全寿命数据进行微调或领域适配.目前已有少量工作解决目标域没有全寿命数据进行迁移学习的问题.Zhang等^[1]利用目标域贯序到达的少量状态监测数据,通过健康状态对

齐、退化方向对齐和退化信息融合等迁移策略,寻找源域和目标域的公共特征空间;Costa等^[11]采用无监督领域对抗训练的迁移策略,在特征提取器中利用LSTM提取源域和目标域贯序到达数据的公共特征,实现目标域轴承的RUL预测.上述两个工作虽然可以解决目标域没有全寿命数据情况下的RUL预测问题,但均需借助目标域贯序到来的部分数据与源域数据进行特征空间适配,利用迁移学习策略提取源域和目标域的公共特征空间.综合而言,以上两类RUL迁移预测方法均依赖于目标域的退化数据构建深度迁移学习模型,但当工况信息未知时,无法提前获取在线工况的退化数据和已有的全寿命退化历史数据,此时上述方法无法构建迁移学习模型,不适合于在线RUL预测.对于本文要解决的未知工况下的在线RUL预测问题,即在在线早期故障发生之初评估其剩余寿命,上述方法均无法在获得目标轴承贯序数据之前提供有效的RUL预测.

综上所述,当在线工况仅有少量早期故障数据时,实现在线RUL评估的关键在于提取并迁移离线数据蕴含的退化趋势信息.基于此,本文从时序退化信息迁移的角度出发,提出一种基于时间序列迁移递归预测的未知工况下滚动轴承在线RUL评估方法.该方法核心思路是通过将离线退化时序信息(即离线工况下轴承的退化趋势信息)迁移至在线工况,递归预测目标轴承的退化过程,以实现离线工况与在线工况的领域适配.具体而言,首先构建一个融合退化趋势信息的时间序列迁移递归预测模型,该模型以张量LSTM为基础算法,并融合离线工况全寿命数据的单调性和趋势性等时序信息,实现对目标轴承退化过程的有效递归预测.相比张量循环神经网络,张量LSTM可以避免梯度消失的问题,选择性地存储记忆信息,提高时序信息的传递效果;然后,考虑到在线工况缺乏全寿命数据,无法确定退化终止阈值,利用迁移成分分析(transfer component analysis, TCA)对所预测的在线退化序列和已有离线序列进行特征空间适配,提取域无关特征表示(即源域和目标域的公共特征),联合源域RUL值构建SVM回归模型,实现在线轴承的实时RUL评估;最后在IEEE PHM Challenge 2012轴承数据集上进行实验,结果验证了所提出方法的可行性和有效性.

本文的贡献可概括如下:

1) 提出一种未知工况下轴承在线RUL评估方法,适用于只有正常状态和部分早期故障数据的在线场景,可充分利用已知工况下退化数据对未知工况的

目标轴承进行有效RUL评估,工况依赖性低,具有易部署性.目前此问题的研究处于起步阶段.

2) 提出一种融合第3方退化信息(离线工况下的退化趋势信息)的时间序列迁移递归预测模型.该模型可充分挖掘退化趋势、演变规律等轴承退化机理,通过提取源域序列的趋势性和单调性,提高目标域时间序列的递归预测效果.根据调研,目前较少有文献研究时间序列递归预测的深度迁移学习算法.

1 问题描述

在不同工况下对同一型号轴承进行重复实验可得到不同的状态监测数据,设离线工况下全寿命退化数据为 $\{x_i^S\}_{i=1}^{n_s}$,其中 n_s 为样本数,样本 x_i^S 属于样本空间 χ^S ,数据生成服从边缘概率分布 $P(\chi^S)$;在线工况下采集到退化过程的部分数据 $\{x_i^T\}_{i=1}^{n_t}$,有 n_t 个样本,样本 x_i^T 属于样本空间 χ^T ,数据生成服从边缘概率分布 $P(\chi^T)$.受测量环境、操作条件差异等因素的影响,不同工况下采集的数据分布存在一定差异,从统计分析角度可认为 $P(\chi^S) \neq P(\chi^T)$.

参考迁移学习的相关概念和术语^[9],本文拟解决的轴承在线RUL评估问题应满足如下条件:

1) 不同工况下的同型号轴承从正常状态运行到完全失效的过程中,退化趋势虽存在差异,但内在的退化机理应保持一致性.

2) 源域 D^S 由离线工况下轴承的数据样本空间 χ^S 及其分布 $P(\chi^S)$ 组成,即 $D^S = \{\chi^S, P(\chi^S)\}$,为在线目标轴承RUL评估提供所需退化机理信息.

3) 目标域 D^T 由在线工况下轴承部分早期故障数据的样本空间 χ^T 及其服从的数据分布 $P(\chi^T)$ 组成,即 $D^T = \{\chi^T, P(\chi^T)\}$.由于在线场景限制,目标轴承只有正常状态数据和部分早期故障数据已知,需在快速退化期发生前尽可能快地预估RUL值,后续可利用贯序到达的数据块动态更新预测模值.目标轴承的正常状态数据虽可获得,但RUL评估通常由早期故障所触发,因此在迁移学习过程中无需考虑.

RUL评估问题本质为回归问题,即分析历史监测数据、预测剩余寿命的变化情况.通过源域数据进行训练,可以建立样本空间 χ^S 至剩余寿命标记空间 γ^S 的非线性映射关系 $f: \chi^S \mapsto \gamma^S$,此为轴承的RUL评估模型.由于目标域缺乏全寿命数据,无法获得快速退化期数据和对应的剩余寿命标签,也就无法直接建立目标域样本空间 χ^T 至剩余寿命标签空间 γ^T 的非线性映射关系 $f: \chi^T \mapsto \gamma^T$,即无法直接构建目标域的RUL评估模型.因此,本文旨在利用源域轴承全寿命退化数据所蕴含的内在退化机理,通过深度迁移

学习,实现目标域轴承的在线RUL评估。

上述过程中深度迁移学习的作用体现在: 1) 利用源域轴承的退化趋势,提高目标域轴承退化过程的递归预测效果; 2) 基于预测得到的目标域退化序列,适配源域和目标域的特征空间,建立退化过程的域无关特征表示; 3) 借助源域中退化趋势特征与剩余寿命值之间的映射关系,促进目标域RUL评估模型的准确性和有效性。

2 所提方法

本节提出一种基于时间序列迁移递归预测的未知工况下滚动轴承在线RUL评估方法,流程如图2所示。该方法主要包括两部分:时间序列迁移递归预测和RUL评估模型构建,详细步骤如下。

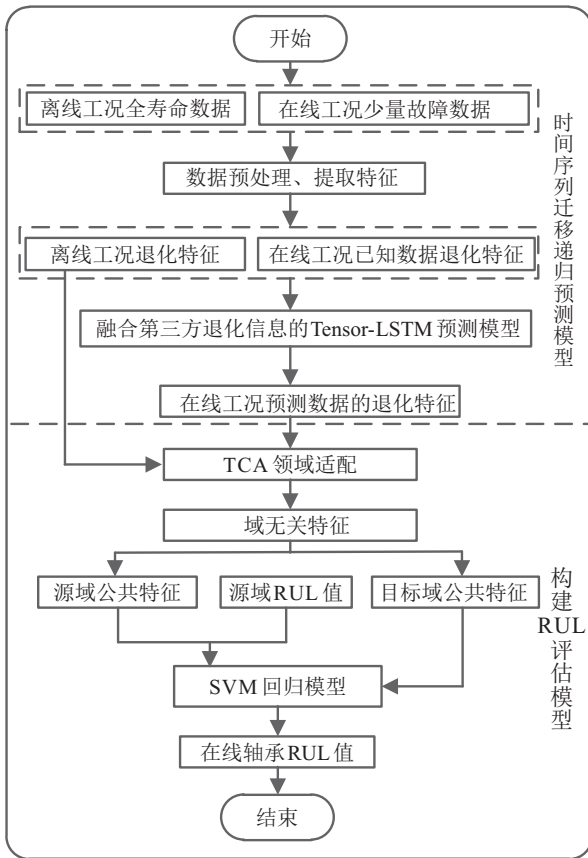


图2 所提出方法流程

step 1: 对离线工况全寿命数据和在线工况早期故障数据进行特征提取,输入融合第3方退化信息的Tensor-LSTM模型进行迁移递归预测,得到目标轴承退化过程的特征序列。

step 2: 利用TCA对在线和离线退化特征序列进行特征空间适配,得到域无关特征表示。

step 3: 提取源域公共特征作为输入,计算源域特征对应的RUL值为输出,构建SVM回归模型。

step 4: 利用目标轴承的特征序列提取目标域公共特征,并输入到训练好的SVM回归模型,实现在线

工况下目标轴承的RUL评估。

该方法借助离线工况下的退化趋势信息,只依赖少量的在线早期故障数据即可实现在线未知工况下目标轴承的RUL评估,具有较强的实际应用。

2.1 时间序列迁移递归预测

为利用目标轴承部分早期故障数据实现在线退化过程的合理预测,需要从已有离线全寿命退化数据中提取所蕴含的退化机理信息。目前,自回归模型、指数平滑模型等传统时间序列预测算法多集中于挖掘序列前后时刻的线性或非线性关系,但面对中长期的时间序列预测,现有算法极易产生误差累积,无法有效实现只有少量初始数据的递归预测。由于轴承退化过程在数据层面表现出中长期的时序依赖关系和高阶相关性,本质是一个高阶非线性动力学模型,同时具有明显的趋势性和单调性。从离线数据中提取高阶状态演化信息(即轴承退化特征经过多次线性-非线性组合操作之后形成的高阶抽象特征)并迁移到在线退化过程递归预测是可行的。

基于此,本文构建一个融合第3方退化信息的时间序列迁移递归预测模型。为了从离线退化序列中提取和表示高阶状态演化信息,引入张量化LSTM(Tensor-LSTM),以实现轴承退化机理信息的有效迁移和传递。该问题可表述为:设目标域已知序列 x_1^T, \dots, x_t^T 和源域序列 x_1^S, \dots, x_N^S ,利用融合源域趋势信息的Tensor-LSTM模型,递归预测出目标域接下来的趋势 x_{t+1}, \dots, x_{t+H} ,模型结构如图3所示。

如图3所示, Tensor-LSTM采用编码(encoder)-解码(decoder)结构进行模型的训练和预测。首先编码器学习初始序列 x_1, \dots, x_t 的隐层表示,解码器使用此隐层表示进行初始化并生成输出序列。同时, Tensor-LSTM在传统LSTM基础上,通过将网络模型参数转化为张量表示,提取高阶时序依赖关系,构建张量 s_{t-1} 连接过去 L 个时刻的隐层状态,从而提高中长期预测的准确性,使模型更易收敛,训练速度更快。参考Tensor-LSTM的定义^[12],首先利用离线退化数据训练一个源域预测模型,有

$$\begin{cases} [i_t^S, g_t^S, f_t^S, o_t^S] = \\ \sigma\left(W_{hx}x_t^S + \sum_{i_1, \dots, i_p} W_{i_1 \dots i_p} s_{t-1; i_1} \otimes \dots \otimes s_{t-1; i_p}\right), \\ s_{t-1}^T = [1 \quad h_{t-1}^T \quad \dots \quad h_{t-L}^T], \\ h_t = \\ f\left(W_{hx}x_t + \sum_{i_1, \dots, i_p} W_{i_1 \dots i_p} s_{t-1; i_1} \otimes \dots \otimes s_{t-1; i_p}\right). \end{cases} \quad (1)$$

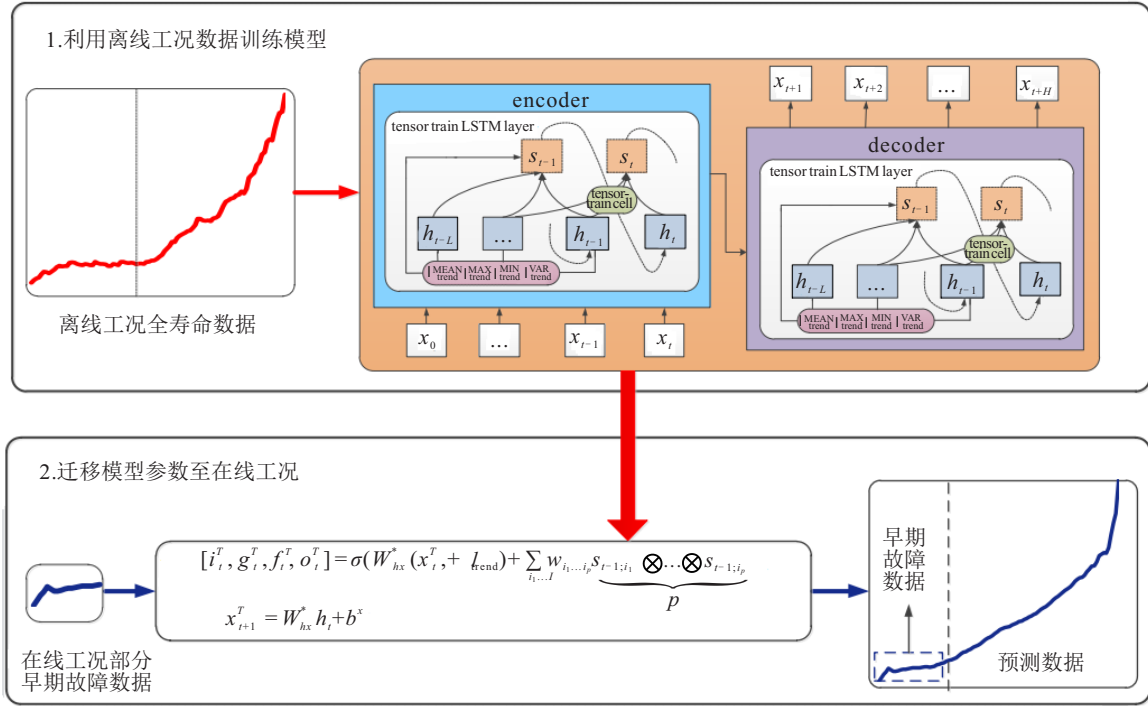


图3 融合第3方退化信息的时间序列迁移递归预测模型

其中: W_{hx} 为输入权重矩阵; W 为 P 维张量权重矩阵; i_1, \dots, i_p 为高阶项; \otimes 为克罗内克积; s_{t-1} 为 t 之前 L 个时刻隐层状态信息的增广矩阵, 1 代表偏置项, $s_{t-1; i_1} \otimes \dots \otimes s_{t-1; i_p} = [1, h_t, h_t h_{t-1}, \dots]$ 表示所有 L 个时刻隐层状态的 P 阶多项式组合; h_t 为当前时刻的隐层状态信息, 由当前时刻的输入 x_t 和 s_{t-1} 组成; $f(\cdot)$ 为激活函数, 通常选用 Tanh 函数。

此外, 为进一步挖掘退化过程信息, 将源域序列的趋势性信息 (退化过程趋势的特征表示) 引入到 Tensor-LSTM 模型中进行趋势约束, 其损失函数为

$$\ell_{trend} = \alpha \ell_{trend}^{MEAN} + \beta \ell_{trend}^{MAX} + \lambda \ell_{trend}^{MIN} + \gamma \ell_{trend}^{VAR}, \quad (2)$$

$$\ell_{trend}^{MEAN}(\phi) = \frac{1}{n} \sum_{t=t_1}^{t_n} \|\text{mean}(\hat{y}_{t-\phi+1}, \dots, \hat{y}_t) - \text{mean}(y_{t-\phi+1}, \dots, y_t)\|^2, \quad (3)$$

$$\ell_{trend}^{MAX}(\phi) = \frac{1}{n} \sum_{t=t_1}^{t_n} \|\max(\hat{y}_{t-\phi+1}, \dots, \hat{y}_t) - \max(y_{t-\phi+1}, \dots, y_t)\|^2, \quad (4)$$

$$\ell_{trend}^{MIN}(\phi) = \frac{1}{n} \sum_{t=t_1}^{t_n} \|\min(\hat{y}_{t-\phi+1}, \dots, \hat{y}_t) - \min(y_{t-\phi+1}, \dots, y_t)\|^2, \quad (5)$$

$$\ell_{trend}^{VAR}(\phi) = \frac{1}{n} \sum_{t=t_1}^{t_n} \|\text{var}(\hat{y}_{t-\phi+1}, \dots, \hat{y}_t) - \text{var}(y_{t-\phi+1}, \dots, y_t)\|^2. \quad (6)$$

其中: ℓ_{trend}^{MEAN} 、 ℓ_{trend}^{MAX} 、 ℓ_{trend}^{MIN} 、 ℓ_{trend}^{VAR} 分别为均值趋势损失、最大趋势损失、最小趋势损失和波动趋势损

失^[13], ϕ 为趋势窗宽, $\alpha, \beta, \lambda, \gamma$ 为正则化参数. 源域时间序列递归预测模型的优化目标函数为

$$J = L_{main} + \ell_{trend}. \quad (7)$$

其中: $L_{main} = L(y, \hat{y}) = \sum_{t=t+1}^{t+H} \|\hat{y}_t - y_t\|_2^2$ 为 H 时刻内的最小二乘预测误差, \hat{y}_t 为递归预测值, $y_t = x_{t+1}$ 为序列真实值. 通过 Adam 算法进行训练, 得到最优权重矩阵 W_{hx}^* .

将源域训练的模型权重矩阵迁移到目标域中, 得到 $t+1$ 时刻的预测值 x_{t+1}^T 为

$$\begin{cases} [i_t^T, g_t^T, f_t^T, o_t^T] = \\ \sigma\left(W_{hx}^* x_t^T + \sum_{i_1, \dots, i_p} W_{\alpha i_1 \dots i_p} \underbrace{s_{t-1; i_1} \otimes \dots \otimes s_{t-1; i_p}}_P\right), \\ c_t = c_{t-1} \circ f_t + i_t \circ g_t, \\ h_t = c_t \circ o_t, \\ x_{t+1}^T = W_{hx}^* h_t + b^x. \end{cases} \quad (8)$$

将 x_{t+1}^T 作为下一时刻的输入, 再次代入式 (8), 得到 $t+2$ 时刻的预测值, 以此迭代进行, 最终完成序列的递归预测, 实现对目标轴承在线退化过程的估计. 该模型利用张量分解的方式提取时序数据所蕴含的高阶结构, 在保存模型信息的同时减少模型参数, 其参数量由原来的 $(HL+1)^P$ 减少至 $(HL+1)R^2P$. 其中: H 为隐藏层大小, L 为预测每一样本时

所使用的隐藏层数量, R 为张量的秩, P 为高阶项阶数. 本文中 $H = 16, L = 2, R = 2, P = 4$.

本文通过构建 Tensor-LSTM 网络模型, 可提取有效的退化趋势特征, 与传统的时间序列预测模型相比, 该模型提取的特征趋势性强, 可以消除部分累积误差; 另一方面, 融合离线工况的第3方退化信息, 修正在线工况的时间序列预测结果, 可进一步消除累积误差, 具有良好的时间序列迁移预测效果.

2.2 RUL 评估模型构建

构建 RUL 预测模型需要将不同特征所对应的 RUL 值设为模型输出. 通常计算剩余寿命需要设定振动信号的失效阈值(例如 20 G), 但在线场景下失效阈值无法提前得知, 需要借助源域已有的 RUL 值辅助评估目标域轴承的 RUL 值. 因此, 首先需要进行特征空间适配, 提取公共特征, 进而利用源域 RUL 值构建回归预测模型, 用于评估目标域轴承的剩余寿命.

采用迁移成分分析(transfer component analysis, TCA)将源域真实退化序列和目标域递归预测得到的退化序列一起映射到一个高维的再生核希尔伯特空间, 实现二者的特征空间适配, 以减少数据分布差异. 为提高可读性, 给出 TCA 的核心实现步骤. TCA 的目的是寻找合适的映射函数 ϕ , 使得源域数据空间 χ^S 和目标域数据空间 χ^T 的平均差异最小. 该差异^[14]可表示为

$$\text{dist}(x_{\text{src}}, x_{\text{tar}}) = \left\| \frac{1}{n_1} \sum_{i=1}^{n_1} \phi(x_{\text{src}_i}) - \frac{1}{n_2} \sum_{i=1}^{n_2} \phi(x_{\text{tar}_i}) \right\|_{\mathcal{H}}. \quad (9)$$

为最小化式(9), TCA 引入核矩阵

$$K = (KK^{-1/2}\tilde{W})(\tilde{W}K^{-1/2}K) = KWW^TK \quad (10)$$

和矩阵

$$L_{ij} = \begin{cases} \frac{1}{n_1^2}, & x_i, x_j \in x_{\text{src}}; \\ \frac{1}{n_2^2}, & x_i, x_j \in x_{\text{tar}}; \\ -\frac{1}{n_1 n_2}, & \text{otherwise.} \end{cases} \quad (11)$$

则 TCA 的优化问题为

$$\min_W \text{tr}(W^TKLW) + \mu \text{tr}(W^TW); \quad (12)$$

$$\text{s.t. } W^TKHKW = I_m. \quad (13)$$

其中: μ 为正则化参数, I_m 为单位矩阵, $H = I_{n_1+n_2} - \frac{1}{n_1+n_2} \mathbf{1}\mathbf{1}^T$. 通过求解式(12), 确定最优公共特征矩阵 W , 实现源域和目标域的特征适配.

为确定源域退化序列的 RUL 值, 采用文献[15]的计算方法, 选取固定的 RMS 阈值确定轴承失效状

态. 考虑到整体数据量较少, 在构建最终的 RUL 评估模型时, 以源域公共特征集为输入, 以对应的 RUL 值为输出, 训练得到 SVM 回归模型. 相比于深度模型, 浅层回归模型处理小样本数据的效果更优, 同时具有速度优势, 因此本文选择 SVM 回归算法构建 RUL 评估模型. 在对在线 RUL 值进行预测时, 需将递归预测得到的退化序列提取 TCA 公共特征再次代入 SVM 模型, 得到对应的 RUL 值. 整个预测过程无需用到目标轴承的在线退化数据, 主要借助离线退化数据提取公共特征和确定 RUL 值, 为未知工况下的在线 RUL 评估提供辅助信息.

3 实验结果

为了验证所提出方法的有效性, 在 IEEE PHM Challenge 2012 轴承全寿命数据集^[16]上进行实验. 算法环境是 Matlab R2014 和 Python3.6, 实验所用电脑配置为 i5-8400 处理器, 16 G 内存.

3.1 数据介绍

IEEE PHM Challenge 2012 数据集来自 PRONOSTIA 实验台^[16], 如图4所示. 通过加速寿命退化实验提供从正常到故障的全寿命实验数据.




图4 PRONOSTIA 实验平台

IEEE PHM 2012 数据集包含 3 个不同工况下的轴承数据. 工况 1 电机转速为 1800 rpm, 负载为 4000 N; 工况 2 电机转速为 1650 rpm, 负载为 4200 N; 工况 3 电机转速为 1500 rpm, 负载为 5000 N. 其中工况 1 和工况 2 各包含 7 个轴承, 工况 3 包含 3 个轴承. 本节实验选用工况 1 的 7 个轴承作为离线数据, 工况 2 中的轴承 1、轴承 2、轴承 5、轴承 6 依次作为在线目标轴承.

IEEE PHM Challenge 2012 数据为全寿命数据, 包含正常期、早期衰退期和快速退化期. 各轴承退化过程的采样点不等长, 但由于正常期样本较多, 当轴承进入快速退化期其样本特征才表现出明显的趋势性, 如图5所示. 可以看到, 最后 100 个样本均已涵盖了部分早期故障和全部快速退化期的数据, 退化趋势较为

明显. 考虑到轴承的剩余寿命预测是针对快速退化期数据进行计算, 为简化起见, 实验均选取各轴承最后 100 个样本进行实验. 对于测试轴承, 首先进行状态划分, 通过计算样本之间的奇异值相关系数界定快速退化期的起始点, 以此确定快速退化期范围进行实验结果绘图和误差计算.




图5 工况1下轴承3的退化过程

3.2 时间序列迁移递归预测结果

首先通过时间卷积网络提取时序深度特征, 将所提取连续 12 个样本的早期故障特征作为时间序列迁移递归预测模型的输入, 预测剩余数据的特征走势. 此处需要说明的是, 时间卷积网络能够有效处理时间序列数据, 通过使用残差层和膨胀因果卷积, 具有更好的从原始振动信号自适应提取特征的能力, 适合构建具有记忆能力的时序网络. 实验所用学习率设置为 0.001, 衰减率为 0.8, $P = 4$, $L = 2$.

图6给出了在线轴承退化序列的递归预测结果, 其中, 实线为预测值, 虚线是上下 95% 的置信区间. 可以看到, 仅用目标轴承少量早期样本, 借助源域数据的退化信息, 即可预测出目标轴承剩余的特征走势. 虽然预测值与真实值波动并不完全一致, 但整体趋势较为一致, 这为下一步轴承的 RUL 评估提供了具有良好趋势的特征.

3.3 RUL 评估结果

由于在线工况下轴承的失效阈值未知, 首先利用 TCA 适配离线工况和在线轴承的特征空间, 提取公共特征, 从而借助离线工况训练的 RUL 回归模型评估在线轴承的剩余寿命. 此处与未迁移方法进行




图6 在线目标轴承时间序列迁移递归预测结果

对比, 该方法不进行第 3 方退化信息融合和特征空间适配, 直接将在线轴承的递归预测特征输入离线模型中, 进行 RUL 预测, 结果如图 7 所示. 图中下方条形方块为各个样本预测值与真实值的绝对误差值, 绝对误差 = |预测值 - 真实值|, 此处为保持 Y 轴坐标一致, 结果取绝对误差的负值, 且图中 RUL 值为根据失效阈值归一化后的结果. 由图 7 可见, 所提出方法的误差整体上远低于未迁移方法的误差, 表明在线目标轴承在融合离线工况的趋势性信息并进行领域适配后, 所提出的公共特征对退化趋势的表示能力更强, 可提高在线轴承的 RUL 评估效果.

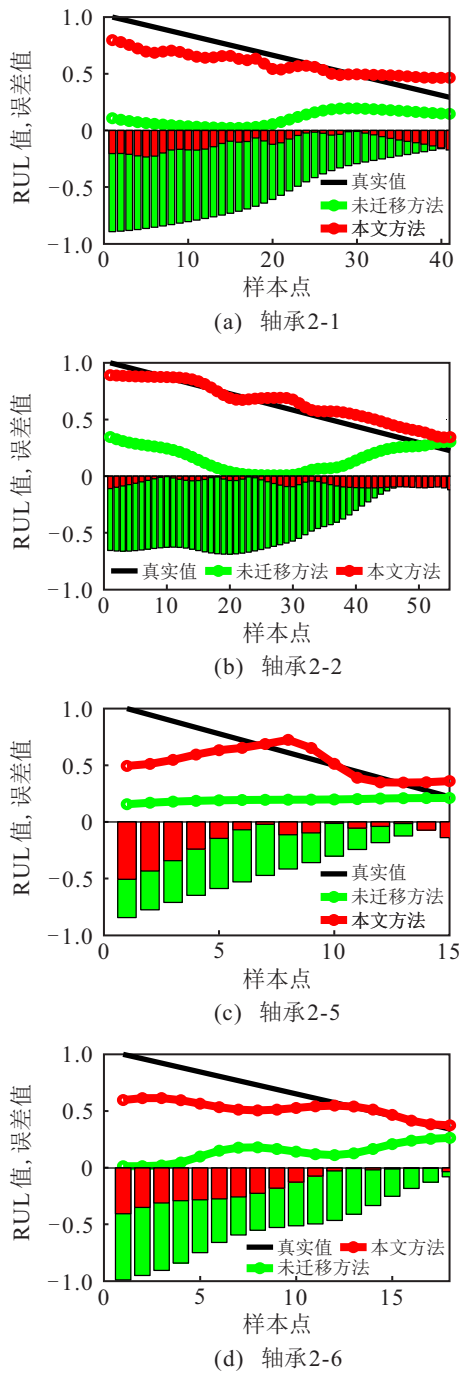


图7 在线目标轴承RUL评估结果

将所提出方法与使用真实在线数据的RUL预测方法进行对比,后者将目标轴承的真实数据输入到源域的SVM回归模型中得到RUL值.图8给出了快速退化期全部样本的RUL预测误差.可以看出,虽然所提出方法在预测之初效果不好,但后期评估效果越来越好.这是因为对于快速退化期,不同工况的轴承在初始退化阶段所蕴含的故障退化信息相对差异较少,将真实在线数据代入离线RUL预测模型不会产生大的预测偏差;而随着故障演化,不同工况数据之间的分布差异逐渐增大,此时直接使用真实在线数据进行评估效果会越来越差.相反,所提出方法从递归预测

入手,借助少量早期故障数据和离线工况退化信息,在线目标轴承可递归得到趋势性退化特征,从而使得RUL评估效果逐渐变好.需要注意的是,图8仅仅是为验证所提出方法的有效性,而实际未知工况下在线RUL评估问题中,真实在线数据无法提前得知,因此也就无法获得图8中初始阶段的真实在线数据.

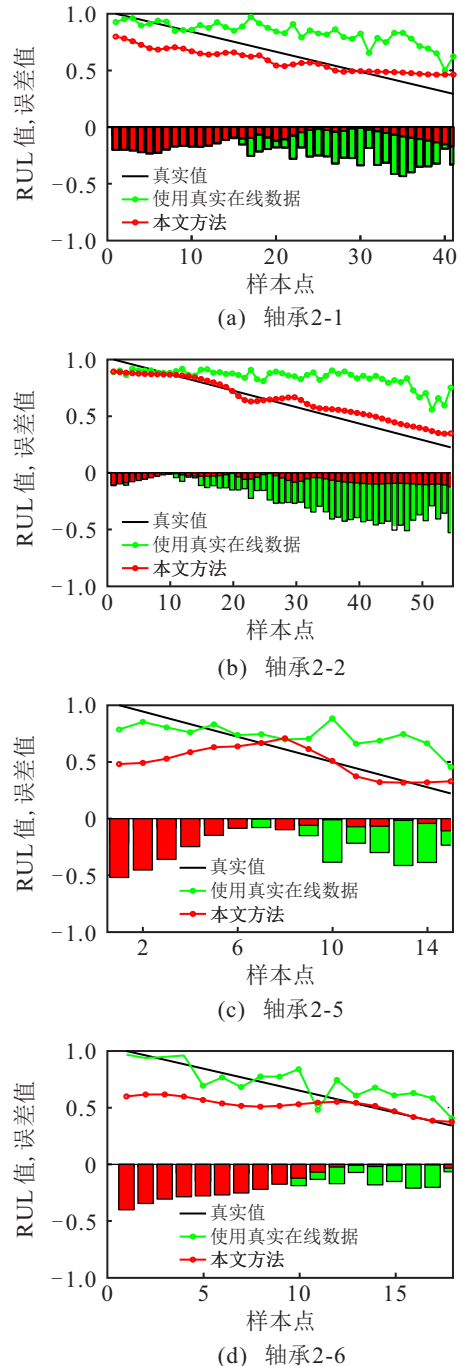


图8 本文方法与使用真实数据的在线轴承RUL预测效果

此外,选用均方根误差(root mean squared error, RMSE)和平均绝对百分比误差(mean absolute percentage error, MAPE)作为模型的评价指标,从量化指标上评估本文方法的整体性能.表1给出了所提出方法、采用真实数据预测方法和未迁移方法在快

表1 快速退化期全部样本上的RUL评估误差数值

	RMSE			MAPE		
	未迁移方法	使用真实数据	本文方法	未迁移方法	使用真实数据	本文方法
轴承 2-1	249.36	92.99	53.73	0.80	0.40	0.18
轴承 2-2	284.83	160.98	40.26	0.69	0.59	0.15
轴承 2-5	73.32	41.30	32.28	0.60	0.58	0.23
轴承 2-6	107.15	28.72	37.47	0.73	0.26	0.19
平均值	178.67	81.00	40.94	0.71	0.46	0.19

速退化期全部样本上的RMSE和MAPE误差结果。可以看出,本文方法预测误差显著降低,这表明本文方法可以借助离线工况的退化趋势中挖掘出有效的退化机理信息,提升在线轴承的RUL评估效果。

为了验证本文领域空间适配的有效性,选用其他领域适配方法SA^[17]、GFK^[18]、KMM^[19]进行对比。具体实现上,仅将本文方法的TCA替换为上述3种算法,其余部分不变。限于篇幅,图9仅给出了目标轴承2-1的RMSE和MAPE误差。可以看到,在RMSE指标上,TCA方法取得的误差最小;在MAPE上,TCA方法的误差与SA保持一致。综合来看,TCA方法的性能最优。需要强调的是,TCA只是领域空间适配算法的一种实现,在进行实际应用时也可采用其他领域空间适配方法替代进行。

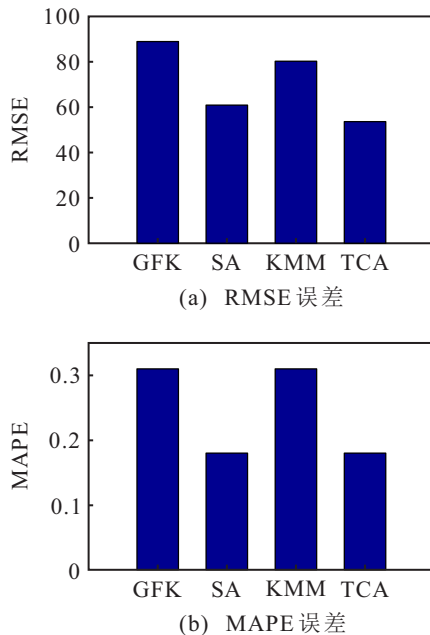


图9 不同领域适配算法的在线RUL评估效果对比

3.4 对比实验

为验证所提出方法的有效性,选择3种基于深度学习的预测方法和4种基于深度迁移学习的预测方法进行对比。文献[8]方法以故障特征的时间序列为

输入,以对应RUL值为输出,构建基于DBN的RUL预测模型,网络结构为[2560, 25, 1]。文献[7]方法使用奇异值分解进行轴承状态划分,然后使用CNN提取特征,作为LSTM的输入,构建RUL预测模型,其LSTM的隐藏层数量为100,输入维度为25,输出维度为1,时间步长为5。文献[6]方法利用连续小波变换获取退化过程的时频域特征,通过多尺度CNN建立RUL预测模型,网络结构为[[30, 30], 200, 1]。文献[2]方法利用多层感知机提取深度特征,通过在回归层前中加入MMD正则项实现源域数据与目标域数据的领域适配,并构建RUL预测模型,网络结构为[2560, 25, 1]。文献[20]方法利用堆叠自编码器和Kullback-Leibler散度提取公共特征,实现RUL的跨工况迁移预测,本实验所采用堆叠自编码器的网络结构为[2560, 521, 1]。文献[10]方法通过微调源域双向LSTM模型实现RUL预测,其双向LSTM隐藏层数量为100,输入维度为2560,输出维度为1,时间步长为5。文献[21]方法在CNN中增加MMD正则项,提取源域数据与目标域数据的公共特征,以此作为LSTM的网络输入,构建回归预测模型,所采用LSTM的隐藏层数量为100,输入维度为25,输出维度为1,时间步长为5。

图10和表2给出了本文方法与8种方法对比实验的结果。需要强调的是,在线场景下,退化数据未知,因此对比方法均使用真实退化数据作为模型输入。可以看出,仅使用退化过程开始部分的12个样本,本文方法依然可以取得最好的预测效果,然而3种使用深度神经网络的RUL预测方法^[6-8]普遍效果较差,这是由于直接利用离线模型未考虑到工况之间的差异,导致模型偏差。4种基于深度迁移学习的预测方法^[2,10,20-21]均出现明显的结果波动,而本文方法即使未使用真实退化数据,也可以达到较好的预测,在两种误差指标上均取得最小误差,再次表明了本文方法的有效性。

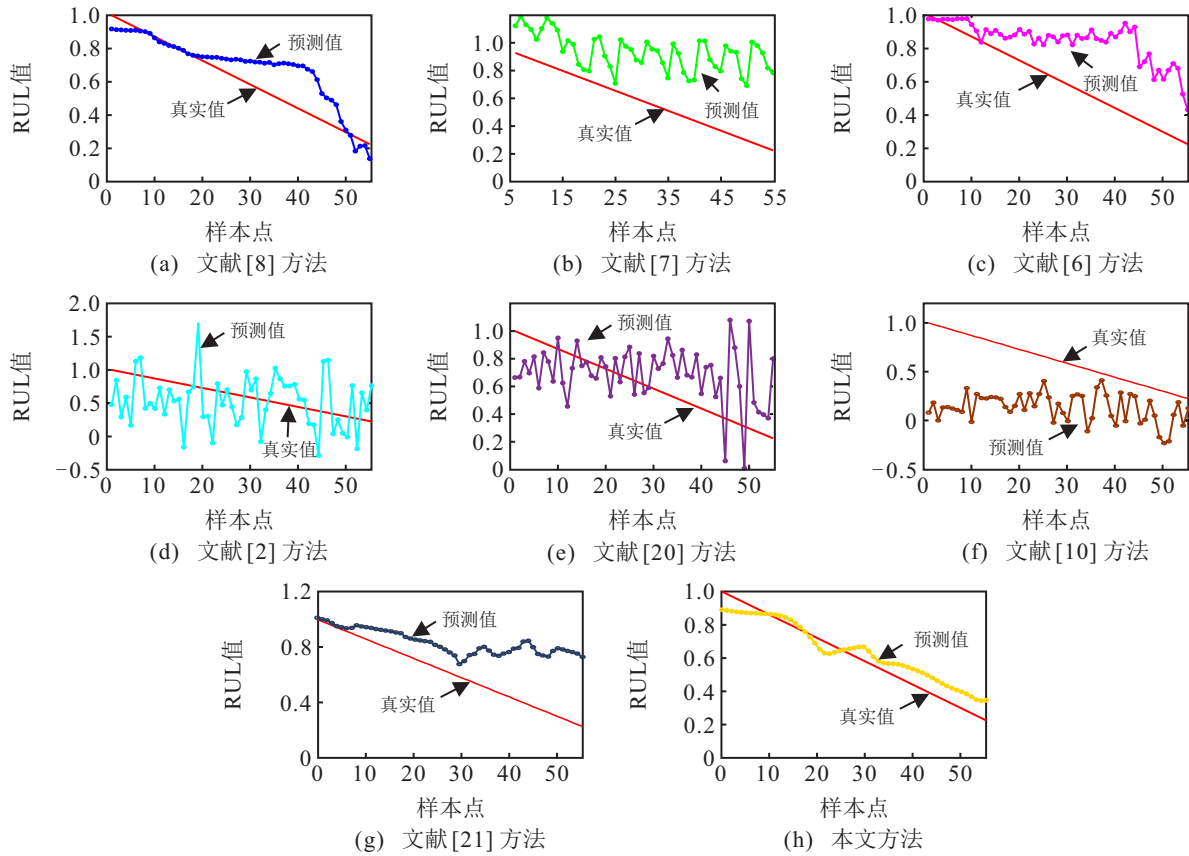


图 10 在线目标轴承2-2在8种方法上的预测结果

表 2 8种方法重复运行20次的平均误差对比

	文献[8]方法	文献[7]方法	文献[6]方法	文献[2]方法	文献[20]方法	文献[10]方法	文献[21]方法	本文方法
RMSE	72.29	82.09	63.56	73.28	50.12	41.17	53.22	40.26
MAPE	0.21	0.99	0.77	0.71	0.24	0.57	0.79	0.15

4 结论

本文针对未知工况下在线轴承的RUL评估问题,提出了一种基于时间序列迁移递归预测的RUL评估方法.该方法通过引入同型号轴承在离线工况下的状态监测数据,有效提高了在线目标轴承在仅有少量故障数据情况下的RUL评估效果.利用融合第3方退化信息的时间序列迁移递归预测模型有效实现了对目标轴承退化过程的预测,而利用深度特征适配方法,可以有效解决未知工况下在线轴承失效阈值未知的问题,通过特征空间适配方法,利用离线轴承RUL值能够实现在线工况下RUL的准确评估.未来计划进一步挖掘退化序列的机理信息,完成机理模型到数据模型的迁移和融合,进一步提高在线RUL预测的准确性和鲁棒性.

参考文献(References)

[1] Zhang W, Li X, Ma H, et al. Transfer learning using deep representation regularization in remaining useful life prediction across operating conditions[J]. Reliability

Engineering & System Safety, 2021, 211: 107556.
 [2] Zhu J, Chen N, Shen C Q. A new data-driven transferable remaining useful life prediction approach for bearing under different working conditions[J]. Mechanical Systems and Signal Processing, 2020, 139: 106602.
 [3] 申中杰, 陈雪峰, 何正嘉, 等. 基于相对特征和多变量支持向量机的滚动轴承剩余寿命预测[J]. 机械工程学报, 2013, 49(2): 183-189.
 (Shen Z J, Chen X F, He Z J, et al. Remaining life predictions of rolling bearing based on relative features and multivariable support vector machine[J]. Journal of Mechanical Engineering, 2013, 49(2): 183-189.)
 [4] Prasad A M, Iverson L R, Liaw A. Newer classification and regression tree techniques: Bagging and random forests for ecological prediction[J]. Ecosystems, 2006, 9(2): 181-199.
 [5] Dong M, He D. A segmental hidden semi-Markov model (HSMM)-based diagnostics and prognostics framework and methodology[J]. Mechanical Systems and Signal

- Processing, 2007, 21(5): 2248-2266.
- [6] Zhu J, Chen N, Peng W W. Estimation of bearing remaining useful life based on multiscale convolutional neural network[J]. IEEE Transactions on Industrial Electronics, 2019, 66(4): 3208-3216.
- [7] Mao W T, He J L, Zuo M J. Predicting remaining useful life of rolling bearings based on deep feature representation and transfer learning[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(4): 1594-1608.
- [8] Deutsch J, He D. Using deep learning-based approach to predict remaining useful life of rotating components[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2018, 48(1): 11-20.
- [9] Pan S J, Yang Q. A survey on transfer learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(10): 1345-1359.
- [10] Zhang A S, Wang H L, Li S B, et al. Transfer learning with deep recurrent neural networks for remaining useful life estimation[J]. Applied Sciences, 2018, 8(12): 2416.
- [11] Costa P R, Akçay A, Zhang Y Q, et al. Remaining useful lifetime prediction via deep domain adaptation[J]. Reliability Engineering & System Safety, 2020, 195: 106682.
- [12] Yu R, Zheng S, Anandkumar A, et al. Long-term forecasting using higher order tensor RNNs[J/OL]. 2017, arXiv: 1711.00073.
- [13] 徐任超, 阎威武, 王国良, 等. 基于周期性建模的时间序列预测方法及电价预测研究[J]. 自动化学报, 2020, 46(6): 1136-1144.
(Xu R C, Yan W W, Wang G L, et al. Time series forecasting based on seasonality modeling and its application to electricity price forecasting[J]. Acta Automatica Sinica, 2020, 46(6): 1136-1144.)
- [14] Pan S J, Tsang I W, Kwok J T, et al. Domain adaptation via transfer component analysis[J]. IEEE Transactions on Neural Networks, 2011, 22(2): 199-210.
- [15] Mao W T, He J L, Zuo M J. Predicting remaining useful life of rolling bearings based on deep feature representation and transfer learning[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(4): 1594-1608.
- [16] Patrick N, Rafael G, Kamal M, et al. Pronostia: An experimental platform for bearings accelerated life test[C]. IEEE International Conference on Prognostics and HealthManagement. Piscataway: IEEE, 2012: 1-8.
- [17] Fernando B, Habrard A, Sebban M, et al. Unsupervised visual domain adaptation using subspace alignment[C]. IEEE International Conference on Computer Vision. Sydney, 2013: 2960-2967.
- [18] Gong B Q, Shi Y, Sha F, et al. Geodesic flow kernel for unsupervised domain adaptation[C]. IEEE Conference on Computer Vision and Pattern Recognition. Providence, 2012: 2066-2073.
- [19] Huang J Y, Smola A, Gretton A, et al. Correcting sample selection bias by unlabeled data[C]. International Conference on Neural Information Processing Systems. Vancouver: MIT Press, 2006: 601-608.
- [20] Sun C, Ma M, Zhao Z B, et al. Deep transfer learning based on sparse autoencoder for remaining useful life prediction of tool in manufacturing[J]. IEEE Transactions on Industrial Informatics, 2019, 15(4): 2416-2425.
- [21] Cheng H, Kong X G, Chen G G, et al. Transferable convolutional neural network based remaining useful life prediction of bearing under multiple failure behaviors[J]. Measurement, 2021, 168: 108286.

作者简介

陈佳鲜(1997—), 女, 硕士生, 从事机器学习、时间序列预测、故障预测的研究, E-mail: jxchen@foxmail.com;

毛文涛(1980—), 男, 教授, 博士, 从事机器学习、智能故障诊断等研究, E-mail: maowt@htu.edu.cn;

刘京(1996—), 男, 硕士生, 从事机器学习、剩余寿命预测的研究, E-mail: liujing5955@qq.com;

王港胜(1997—), 男, 硕士生, 从事深度学习、异常检测的研究, E-mail: 583067042@qq.com.

(责任编辑: 郑晓蕾)