

控制与决策

Control and Decision

基于深度时序特征迁移的轴承剩余寿命预测方法

陈佳鲜, 毛文涛, 刘京, 张新明

引用本文:

陈佳鲜, 毛文涛, 刘京, 等. 基于深度时序特征迁移的轴承剩余寿命预测方法[J]. *控制与决策*, 2021, 36(7): 1699–1706.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2019.1809>

您可能感兴趣的其他文章

Articles you may be interested in

基于生成对抗网络学习被遮挡特征的目标检测方法

Object detection via learning occluded features based on generative adversarial networks

控制与决策. 2021, 36(5): 1199–1205 <https://doi.org/10.13195/j.kzyjc.2019.1319>

一种基于深度学习的时间序列预测方法

A time series prediction method based on deep learning

控制与决策. 2021, 36(3): 645–652 <https://doi.org/10.13195/j.kzyjc.2019.0809>

融合稀疏编码与深度学习的草图特征表示

A feature representation of sketch based on fusion of sparse coding and deep learning

控制与决策. 2021, 36(3): 699–704 <https://doi.org/10.13195/j.kzyjc.2019.0941>

基于改进堆叠自动编码器的循环冷却水系统工艺介质温度预测控制方法

Predictive control method of process medium temperature in circulating cooling water system based on improved stacked auto encoders

控制与决策. 2020, 35(12): 2835–2844 <https://doi.org/10.13195/j.kzyjc.2019.0694>

基于无标签、不均衡、初值不确定数据的设备健康评估方法

Equipment health risk assessment based on unlabeled, unbalanced data under uncertain initial condition

控制与决策. 2020, 35(11): 2687–2695 <https://doi.org/10.13195/j.kzyjc.2018.1493>

基于深度时序特征迁移的轴承剩余寿命预测方法

陈佳鲜¹, 毛文涛^{1,2†}, 刘京¹, 张新明^{1,2}

(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: 不同工况下轴承退化数据分布不一致导致深度学习等方法对剩余寿命预测效果有限, 而已有迁移学习预测方法未能充分挖掘不同工况退化序列的内在趋势性, 为此, 提出一种基于深度时序特征迁移的轴承剩余寿命预测方法. 首先, 提出一种深度时序特征融合的健康指标构建模型, 利用时间卷积网络挖掘退化趋势的内在时序特征, 得到源域多轴承的健康指标; 然后, 提出一种最小化序列相似度的领域自适应算法, 利用源域健康指标作为退化趋势元信息, 选取目标域与源域之间的公共敏感特征; 最后, 采用支持向量机构建预测模型. 在 IEEE PHM Challenge 2012 轴承全寿命数据集上进行实验, 结果表明, 所提出方法构建的健康指标可更有效地反映退化趋势, 同时明显提升剩余寿命预测的准确度.

关键词: 剩余寿命预测; 深度学习; 迁移学习; 健康指标; 时序特征; 轴承

中图分类号: TH17

文献标志码: A

DOI: 10.13195/j.kzyjc.2019.1809

开放科学(资源服务)标识码(OSID):



引用格式: 陈佳鲜, 毛文涛, 刘京, 等. 基于深度时序特征迁移的轴承剩余寿命预测方法[J]. 控制与决策, 2021, 36(7): 1699-1706.

Remaining useful life prediction of bearing based on deep temporal feature transfer

CHEN Jia-xian¹, MAO Wen-tao^{1,2†}, LIU Jing¹, ZHANG Xin-ming^{1,2}

(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: Due to the inconsistent distribution of bearing degradation data under different working conditions, the prediction performance of remaining useful life by using deep learning and other techniques is limited. Moreover, most of existing transfer learning-based prediction methods fail to fully exploit the inherent degradation trend under different working conditions. To solve these problems, a prediction method of bearing remaining useful life is proposed based on deep temporal feature transfer. Firstly, a health indicator (HI) construction model based on deep temporal features is proposed. The model uses the temporal convolutional network (TCN) to exploit inherent temporal features from the degradation trend of multiple bearings, and builds the HI sequence of the bearings in source domain. Then, a domain adaptation algorithm for minimizing sequence similarity is proposed. The HI sequence of source domain is used as meta-information of degradation trend for selecting common representative features between target domain and source domain. Finally, the support vector machine is used to construct the prediction model. Experiments are performed on the IEEE PHM Challenge 2012 bearing whole-life dataset, and the results show the proposed HI can effectively reflect the degradation trend, and significantly improve the prediction accuracy of remaining life.

Keywords: remaining life prediction; deep learning; transfer learning; health indicator; temporal feature; bearing

0 引言

在机械工程领域, 滚动轴承作为机械设备最重要且最容易发生故障的部件之一, 其性能的好坏直接影响整个机械设备的使用期限. 滚动轴承的故障预测

与健康管理 (prognostics and health management, PHM) 包括异常检测、故障诊断和剩余使用寿命 (remaining useful life, RUL) 预测等环节, 其中轴承的 RUL 预测对于机械设备的使用周期、有效保养及维护有着重要

收稿日期: 2019-12-25; 修回日期: 2020-03-15.

基金项目: 国家重点研发计划专项项目 (2018YFB1701400); 国家自然科学基金项目 (U1704158); 河南省科技攻关项目 (212102210103); 河南师范大学面上项目培育项目 (2020PL09).

责任编辑: 董久祥.

†通讯作者. E-mail: maowt@htu.edu.cn.

的参考价值. 随着智能技术的快速发展, 进行基于数据驱动的RUL预测逐渐成为研究热点, 受到学术界和工业界的广泛关注.

基于数据驱动的方法主要是从运行监测数据中提取故障特征, 利用支持向量机(support vector machine, SVM)^[1]、主成分分析(principal component analysis, PCA)^[2]、隐马尔可夫^[3]等机器学习算法构建预测模型. 近年来, 深度学习技术开始引入轴承RUL预测. 由于神经网络可直接从原始数据中提取敏感特征, 与传统浅层模型相比, 基于深度学习的RUL预测方法具有自适应特征提取、模型泛化能力强等优点. 文献[4]将卷积神经网络(convolutional neural network, CNN)中的卷积和池化滤波器沿时间维度应用于多通道传感数据上, 以系统学习的方式自动学习特征, 同时, 特征学习和RUL估计通过监督反馈相互增强, 有效提高了RUL预测的准确性; 文献[5]提出了一种基于深度自动编码器的联合特征压缩和计算方法, 在不增加神经网络规模的情况下保留有效信息, 在RUL预测中具有较好的效果; 文献[6]从轴承退化过程的时序特征表示出发, 构建长短期记忆(long short-term memory, LSTM)网络, 充分融合长期与短期的记忆信息, 实现轴承在复杂工作条件、强噪声下的RUL预测. 上述方法均假设存在大量轴承数据、故障信息丰富、轴承退化过程满足独立同分布条件等, 然而在实际工程下, 上述假设较难以满足. 设备长期处于正常运行状态, 故障状态下的数据较少, 这种情况下, 传统的RUL预测方法难以达到理想效果.

为解决上述问题, 一个直观的作法是利用同一型号轴承在相近(但不同)工况下的历史积累数据构建RUL预测模型. 这一作法的出发点是从这些数据中寻找退化趋势的领域信息, 以此提高RUL预测模型的泛化能力. 但不同工况下的同型号轴承普遍具有不同的退化过程, 数据分布存在差异, 这违背了传统方法对数据独立同分布的假设. 因此, 寻找一种有效方法, 使得不同工况下轴承数据的特征分布尽可能相似, 以此解决数据量不足的问题, 是提高轴承RUL预测的关键问题之一.

近年来, 迁移学习得到了快速发展. 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, 从而提高目标任务的学习效果^[7], 并在计算机视觉^[8]、自然语言处理^[9]等领域得到了验证. 而根据文献调研, 迁移学习已在故障诊断领域取得了有效应用^[10], 但在故障RUL预测领域, 利用迁移学习方法的相关工作尚处于起步阶段. 其中, 文献[11-12]均利用源域训练好的深度网络模型, 在目标域中通过参数微调的方式实现信息迁移, 由此

构建具有良好特征表示效果的RUL预测模型. 文献[11-12]采用模型迁移策略, 但未根据退化序列的时序特点构建迁移模型. 文献[13]通过计算Mel频率倒谱系数建立轴承的退化曲线, 将超平面分类器的传递紧凑编码与指数半确定性扩展卡尔曼滤波器相结合, 用于预测RUL; 文献[14]采用迁移成分分析(TCA)寻找不同轴承之间的公共特征表示, 进而构建SVM预测模型, 实现RUL预测. 文献[13-14]在特征层面实现迁移, 但所用特征属于物理特征, 未充分利用轴承在衰退过程中的时序性特征.

由上述分析可知, 基于迁移学习的RUL预测的关键是在预测模型构建中引入辅助的退化信息, 从而增强数据量不足情况下的模型预测能力^[11,13]. 因此, 寻找具有较好表示效果的退化趋势特征, 成为利用迁移学习提高RUL预测效果的关键问题. 鉴于此, 本文以退化趋势的时序特性为切入点, 提出一种基于深度时序特征的故障剩余寿命预测方法. 该方法通过构建轴承退化序列的健康指标(health indicator, HI), 提取源域和目标域轴承数据的公共深度时序特征, 在此基础上构建SVM预测模型, 实现利用同型号轴承在不同工况下的辅助数据提高目标轴承RUL预测效果的目的, 并在IEEE PHM Challenge 2012轴承数据集上进行对比实验. 本文研究内容概括为: 1) 提出一种新的HI构建模型, 与现有方法不同, 该模型采用时间卷积网络(temporal convolutional network, TCN)提取轴承原始振动信号的深度特征和退化序列的时序特征, 因此具有良好的故障敏感性和趋势性; 2) 提出一种面向时间序列的领域自适应算法, 与现有绝大多数迁移学习算法不同, 该算法通过最小化序列相似度, 选择源域和目标域中序列的公共特征, 实现深度时序特征迁移, 根据文献调研, 目前针对时序数据的领域自适应研究尚不多见.

1 问题描述

设在不同工况下对同一型号轴承进行重复试验, 可得到不同工况下的监测数据集. 设某一工况下监测数据为 $\{x_i^s\}_{i=1}^{n_s}$, 包含 n_s 个样本, 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 $P(\chi^s)$; 另一工况下监测数据为 $\{x_i^t\}_{i=1}^{n_t}$, 包含 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 $P(\chi^t)$. 受测量环境多样、操作条件差异等复杂因素的影响, 不同工况下采集的数据分布存在较大差异, 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^[7], 本文涉及的轴承RUL预测问题应该满足以下条件:

1) 从正常状态到故障状态的过程中, 同型号轴承在不同工况下的退化趋势存在差异, 但相近工况的退

化过程信息具有一定程度的辅助建模作用。

2) 源域 D^s 由某一工况下轴承的数据样本空间 χ^s 及其服从的数据分布 $P(\chi^s)$ 组成, 即 $D^s = \{\chi^s, P(\chi^s)\}$, 为目标轴承的 RUL 预测提供所需的退化机理。

3) 目标域 D^t 由另一工况下轴承的数据样本空间 χ^t 及其服从的数据分布 $P(\chi^t)$ 组成, 即 $D^t = \{\chi^t, P(\chi^t)\}$, 目标域中采集的数据量通常较少, 同时需要实现快速、准确的预测。

与故障诊断不同, RUL 预测问题本质为回归问题, 即通过分析历史监测数据, 预测剩余寿命的变化情况。通过源域监测数据进行训练, 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 $f: \chi^s \mapsto \gamma^s$, 即为轴承的 RUL 预测模型。由于目标域数据量通常较少, 所建立的 RUL 预测模型 $f: \chi^t \mapsto \gamma^t$ 通常存在较大误差, 本文旨在利用源域故障特征与剩余寿命值之间反映的内在退化机理, 协助提高目标域轴承的 RUL 预测效果。上述过程中, 迁移学习的作用体现在: 1) 适配源域和目标域的监测数据分布, 建立退化过程的公共特征表示; 2) 借助源域中故障特征与剩余寿命之间的映射关系, 促进目标域 RUL 预测模型的准确性和有效性。

2 基于深度时序特征迁移的轴承剩余寿命预测方法

整体而言, 所提方法主要包括 3 部分: 1) 利用 TCN 提取源域和目标域轴承退化序列的深度时序特征, 并构建反映退化趋势的 HI; 2) 以 RUL 退化序列为迁移对象, 通过最小化序列相似度, 构建面向时间序列的领域自适应算法, 实现退化信息从源域到目标域的迁移; 3) 构建 SVM 回归模型作为 RUL 预测模型。具体表述如下。

2.1 基于深度时序特征的 HI 构建

目前, HI 构建方法多采用对传统特征^[15]和深度特征^[16]降维的策略。考虑到轴承退化序列本质上是一种时间序列, 对应的 HI 应具有良好的趋势性、单调性和故障敏感性, 因此, 在现有方法的基础上, 本节引入时序特征提取能力更强的时间卷积网络 (TCN) 构建 HI, 简述如下: 首先, 对于源域多个轴承的退化序列, 采用 TCN 提取各退化序列的深度时序特征; 其次, 对于所获取的 TCN 特征, 采用 PCA 提取一维主成分, 作为最终 HI。

TCN^[17]于 2018 年被首次提出, 是一种能够有效处理时间序列数据的网络结构。与现有的时序深度模型 LSTM、循环神经网络相比, TCN 通过使用残差层增强和膨胀因果卷积, 具有更好的从原始振动信号

自适应提取特征的能力, 而与普通的卷积神经网络不同, TCN 的卷积具有因果关系, 感受野灵活, 适合于构建具有记忆能力的时序网络。

TCN 主要包括 3 个模块: 1) 膨胀因果卷积, 2) 残差模块, 3) 1 维全卷积网络 (1D fully-convolutional network, 1D FCN)。为了接受长距离的历史信息, TCN 采用膨胀因果卷积替代传统的因果卷积, 即对一个一维序列输入 $\mathbf{x} \in \mathbf{R}^n$ 和一个过滤器 $f: \{0, 1, \dots, k-1\} \rightarrow \mathbf{R}$, 在元素 s 上采用如下膨胀卷积的操作: $F(s) = (\mathbf{x} *_d f)(s) = \sum_{i=0}^{k-1} f(i) \cdot \mathbf{x}_{s-di}$ 。其中: $*_d$ 是膨胀卷积算子, d 是膨胀因子, k 是过滤器的大小。这样做保证了对于输出 t 时刻的数据 y_t , 其输入只可能是 t 以及 t 以前的时刻。其次, 为了避免较深的网络结构引起的梯度消失问题, TCN 采用残差块结构代替层与层之间的简单连接, 用以提高模型泛化能力, 其函数表达式为 $o = \text{Activation}(\mathbf{x} + F(\mathbf{x}))$ 。最后, TCN 利用 1D FCN 的结构, 每一个隐层的输入输出的时间长度都相同, 使得每个时间步的输入都有对应的输出。因此, 对于输入时间序列 $\{x_0, x_1, \dots, x_T\}$, TCN 序列模型的训练目标就是找到一个时序网络模型 f , 使得实际输出与预期输出的损失最小化。

2.2 面向序列迁移的领域自适应

现有领域自适应算法多采用模型迁移和特征迁移的策略^[18]。但是, 对于不同工况下的 RUL 预测, 不仅要提取域之间的公共特征表示, 同时需要充分考虑退化序列前后数据之间的时序关系, 所提取的公共特征应同样具有良好的趋势性、单调性等性质。基于这一思路, 本节采用特征迁移的策略, 将 2.1 节构建的 HI 作为退化趋势的元信息, 通过计算目标域中每一维深度特征与 HI 的序列相似度, 提取走势与 HI 接近的特征作为公共特征, 以此实现退化信息的迁移。具体而言, 本节采用动态时间规整 (dynamic time warping, DTW) 距离^[19]度量序列相似度。与传统的欧式距离、模式距离、形状距离相比, DTW 距离使用动态规划思想, 可以有效解决图形平移问题, 适合度量不等长序列的形状相似性, 因此适用于度量每一维深度特征与 HI 的相似度。具体算法如下。

算法 1 最小化序列相似度的领域自适应算法。

input: 1) 轴承的特征集 $\mathbf{F} = [\mathbf{F}_1, \mathbf{F}_2, \dots, \mathbf{F}_N]$, $\mathbf{F}_i = [x_1, x_2, \dots, x_M](i = 1, 2, \dots, N)$ 表示目标域的轴承, M 表示所提取的特征维度, x_j 表示轴承从退化开始到结束的第 j 维特征, $j = 1, 2, \dots, M$; N 表示目标域轴承的数量。2) 源域数据所提取的健康指标为 HI。

output: 公共敏感特征集 $\mathbf{F}' = [\mathbf{F}'_1, \mathbf{F}'_2, \dots, \mathbf{F}'_N]$ 。

step 1: 计算特征矩阵 \mathbf{F}_i 的每一维特征 x_j 和健康

指标HI的DTW距离,获得第*i*个轴承与HI的相似度矩阵 $\mathbf{R}_i = [r_1, r_2, \dots, r_M]^T$.

step 2: 对目标域所有轴承计算相似度矩阵,得到相似度矩阵 $\mathbf{R} = [\mathbf{R}_1, \mathbf{R}_2, \dots, \mathbf{R}_N]$.

step 3: 构建一个权重矩阵 $\mathbf{W} = [w_1, w_2, \dots, w_M]$,其中 w_j 表示每一维特征的权重系数,计算方法为 $w_j = \sum_{i=1}^N M - \text{Index}_i$. 这里 Index_i 表示相似度向量 \mathbf{R}_i 按照升序排列后的相似度矩阵,相似度越高, r_i 值越小,所对应的权重越高.

step 4: 对权重矩阵进行降序排序,权值大的特征重要性相应也大,由此选择得到各个特征的重要性排序,并依次向其中添加特征,选择使得预测误差最小的特征数量,最终得到公共敏感特征集 $\mathbf{F} = [\mathbf{F}'_1, \mathbf{F}'_2, \dots, \mathbf{F}'_N]$.

2.3 RUL预测模型构建

本节以2.2节得到的公共敏感特征为输入,以同一时刻点特征所对应的RUL值为输出,构建SVM回归预测模型. TCN可以提供端到端的回归建模,但考虑到小样本环境,本文在获取到的公共敏感特征集基础上,采用基于结构风险最小化的SVM构建回归预测模型,以此获得不充足数据量下良好的泛化能力,避免端到端模型在小样本问题上可能存在的过学习现象. RUL的计算公式为 $RUL = T_2 - T_1$. 其中: T_2 是认为完全损坏的时刻, T_1 是损坏之前的各个采样时刻. 此时 T_2 的计算采用文献[14]中的方法,对均方根(RMS)值不足20G的序列,依靠拟合和外推的方法确定完全损坏的时刻. 具体流程如图1所示.

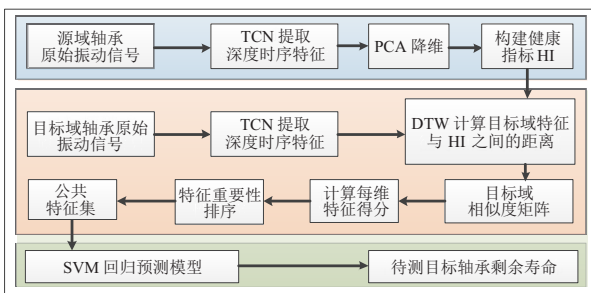


图1 本文所提方法流程

3 实验结果

为了验证所提方法的有效性,本文在IEEE PHM 2012数据集^[20]上进行实验. 算法运行环境是Matlab R2014和Python3.6,实验所用电脑配置为i5-8400处理器,16G内存. 所有数据提前归一化到 $[-1, +1]$.

3.1 数据介绍

IEEE PHM 2012数据集来源于PRONOSTIA试验台^[20],如图2所示. 该平台通过加速寿命退化实验提供滚动轴承从正常到故障的整个生命周期的实验

数据.




图2 PRONOSTIA试验平台^[7]

IEEE PHM 2012数据集包含了3个不同工况下的轴承数据:第1个工况下电机转速为1800 rpm,负载为4000 N;第2个工况下电机转速为1650 rpm,负载为4200 N;第3个工况下电机转速为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.

本节实验中,采用工况1作为源域,工况2作为目标域. 其中:工况2下第1~第7个轴承轮流作为待预测的目标轴承,其他6个轴承作为工况2下的可用数据,用来执行算法1,提取两个工况的公共特征.

3.2 HI构建结果

由于RUL预测主要是对早期故障出现后的退化过程进行预测,本文参考文献[14]的做法,选择工况1下7个轴承的最后100个样本作为源域,工况2下7个轴承的最后100个样本作为目标域,这100个样本均已涵盖少量正常状态和所有的退化阶段. 首先,用TCN提取源域数据的100维时序特征. 为进行直观展示,随机选择二维特征,如图3所示.




图3 源域轴承TCN特征走势

由图3可看到TCN特征随着轴承的退化过程表现出明显的趋势性. 在此基础上,利用PCA将特征降至1维,构建源域HI,如图4所示.

用移动平均法对样本进行平滑处理,由于本文迁移学习模型关注的是样本的总体趋势,本文选择前30个特征作为基准,利用平滑函数smooth进行平滑处理(见图4),如果取值过小,则容易受数据局部波动的干扰,不利于总体趋势的构建,可以看出,所得到的HI具有整体的趋势性和单调性,并且对早期故障呈现出较明显的变化,验证其具有良好的故障敏感性.






图4 经平滑的源域轴承HI


将本文方法与两种代表性的HI构建方法进行对比,如图5所示.



(a) HI-TCN 及 RMS 走势



(b) HI-CNN 及 RMS 走势



(c) HI-ISOMAP 及 RMS 走势

图5 3种HI构建方法对比效果

在图5中:方法1^[16]采用CNN提取深度特征,并降维构建HI,简称HI-CNN;方法2^[15]通过小波包分解从原始监测信号中提取RMS、FFT、小波包等传统特征,并采用非线性流形降维算法ISOMAP(isometril mappind)进行降维,获得最终的HI,简称HI-ISOMAP.为直观对比,另外绘制了轴承退化序列的RMS值.可以看出:虽然CNN也可以提取深度特征,但在时序特性上表现较弱,如图5(b)所示,趋势性表现不够明显;ISOMAP采用传统特征,对早期故障不

够敏感;本文所提方法(HI-TCN)与RMS走势最为接近,在早期故障发生阶段也存在明显的跃升趋势,表明该方法具有良好的故障敏感性.

为进一步对比效果,采用目前普遍使用的HI评价指标^[21]Corr和Mon,对图5所示的3种HI进行数值对比,结果如表1所示.

表1 3种HI构建方法的评价指标得分

方法	Mon	Corr	Mic	Cri
HI-TCN	0.94	0.97	0.97	0.96
HI-CNN	0.74	0.98	0.87	0.86
HI-ISOMAP	0.87	0.98	0.95	0.93

在表1中: $Mon = \left| \frac{dF > 0}{T-1} - \frac{dF < 0}{T-1} \right|$ 表示单调性, dF 表示特征序列的微分; $Corr = \frac{\left| \sum_{t=1}^T (F_t - \tilde{F})(l_t - \tilde{l}) \right|}{\sqrt{\sum_{t=1}^T (F_t - \tilde{F})^2 (l_t - \tilde{l})^2}}$ 表示HI与时间的相关性, F_t 和 l_t 分别表示第 t 时刻样本的特征值和时间值.此外,考虑到相关系数Corr适合于线性相关分析,而文中HI与时间呈现一定的非线性关系,因此,本文引入最大信息系数Mic^[22]进一步度量HI与时间的相关性,该指标被广泛用于度量数据的非线性相关性,即

$$Mic = \frac{\max_{F_t T_t < B(n)} \left(\max_{F_t \in F, T_t \in T} P(F_t, T_t) \times \log \frac{P(F_t, T_t)}{\sum_{F_t \in F} P(F_t, T_t) \sum_{T_t \in T} P(F_t, T_t)} \right)}{(\log \min F_t, T_t)}$$

其中: F_t 和 T_t 分别表示第 t 时刻样本的特征值和时间值; $B(n) = n^{0.6}$, n 表示数据集的数量.

考虑到上述3种指标的侧重点有所不同,本文将3种指标的平均值作为综合性能指标,表示为

$$Cri = \frac{Mon + Corr + Mic}{3}$$

指标Cri的值越大,其对应的HI性能越好.可以看到,表1中本文所提方法的Cri值明显超过另两种方法,这验证了利用时序深度特征构建HI的合理性.

3.3 领域自适应结果

用2.2节提出的序列领域自适应算法对目标域轴承特征进行选择,通过DTW计算每一维深度特征与HI的相似度,相似度越大,特征得分越高,重要性越高,其特征重要性得分如图6所示.可以看出,部分特征重要性明显偏低,这意味着此类特征走势与HI偏差较大,不具有合理的时序特性.此时选取得分较高的特征建立预测模型,为了验证迁移学习的有效性,图7给出了迁移前后的概率密度函数.







图6 目标域特征重要性得分




(a) 轴承1-6、2-6 迁移前概率密度分布



(b) 轴承1-6、2-6 迁移后概率密度分布



(c) 轴承1-5、2-4 迁移前概率密度分布



(d) 轴承1-5、2-4 迁移后概率密度分布


图7 源域和目标域的概率密度分布

从图7可以看出,在迁移之前,源域和目标域的数据概率密度分布有较大差异,而运行算法1后,敏感特征的概率密度分布一致性有明显提高,这表明本


文所提出的序列领域自适应算法能够有效获取公共敏感特征,有利于构建RUL预测模型。

3.4 RUL预测结果

限于篇幅,本文选择目标域中轴承2和轴承4作为待预测轴承,进行效果展示,如图8所示。



(a) 工况2下轴承2 预测结果



(b) 工况2下轴承4 预测结果

图8 RUL预测对比结果

在图8中,未迁移方法直接用TCN提取工况1和工况2可用数据的特征,进而在待测目标轴承上进行预测.可以看出,方块针状图显示的误差整体上要低于圆圈针状图,说明采用算法1所示的序列领域自适应算法后,所提公共特征对退化趋势的表示能力更强,由此可提高预测效果.此外,为验证本文方法的整体性能,依次选择工况2下7个轴承作为待预测的目标轴承,分别采用本文方法和未迁移方法,所得的均方根差(root mean square error, RMSE)和平方绝对百分比误差(mean absolute percentage error, MAPE)误差结果如表2所示.在表2中:轴承1~7依次选为待预测的目标轴承,其余6个轴承作为目标域的可用数据进行领域自适应计算.


表2 目标域的RUL预测误差

	RMSE		MAPE	
	未迁移方法	本文方法	未迁移方法	本文方法
轴承1	53.44	61.69	0.17	0.20
轴承2	100.19	60.75	0.21	0.12
轴承3	44.63	28.71	0.73	0.42
轴承4	11.72	10.65	0.08	0.07
轴承5	31.92	30.94	0.27	0.26
轴承6	10.37	8.35	0.06	0.05
轴承7	22.11	15.59	0.57	0.32
平均值	39.20	30.96	0.30	0.21


由表2可以看到,在轴承1之外的6个轴承上,本文方法均取得了更低的预测误差,这表明本文方法可以从不同工况的数据中有效挖掘退化机理信息,从而提升数据量有限情况下的RUL预测效果。

为了验证时序特性在序列迁移中的作用,将本文方法与4种经典的领域自适应方法SA^[23]、GFK^[24]、KMM^[25]和TCA^[26]进行对比.为保持对比公正,仅将本文方法中的算法1替代为上述4种领域自适应算法,其余部分不变.与表2一致,此处采用目标域7个轴承的平均RUL预测误差,结果如图9所示.可以看到,无论是RUL预测的RMSE还是MAPE误差,本文方法均取得最小值,这表明相比于传统对序列数据直接寻找公共特征子空间的做法,在寻找公共特征时引入序列自身的时序特性,有助于提升序列迁移的效果,同时也可看到,对时序特征的迁移有助于降低RUL预测误差。

本文选择4种代表性的RUL预测方法进行实验对比,结果如表3所示。



(a) 不同领域自适应方法的RMSE误差



(b) 不同领域自适应方法的MAPE误差

图9 不同领域自适应算法的目标域RUL预测平均误差对比结果

表3 5种方法的目标域RUL预测平均误差对比结果

	文献[27]方法	文献[14]方法	文献[28]方法	文献[29]方法	本文方法
RMSE	34.50	31.03	39.50	43.92	30.96
MAPE	0.36	0.57	0.35	0.68	0.21

此处同样采用在目标域7个轴承上的平均RUL预测误差.这4种方法包括一种基于浅层模型的特征选择方法和3种深度学习方法.其中:文献[27]使用故障特征选择和SVM构建预测模型;文献[14]从迁移学习出发,利用深度特征和迁移成分分析进行RUL预测;文献[28]利用小波变换获取时频特征,然后通过多尺度卷积神经网络建立RUL预测模型;文献[29]使用故障特征的时间序列作为深度置信网络的输入,建立RUL预测模型.可以看出,本文方法在两种误差指标上均取得最小的预测误差,虽然文献[14]同样采用迁移学习方法,但本文方法仍在MAPE误差上取得了明显降低,这再次说明对轴承退化序列采用时序迁移学习的优势。

4 结论

本文针对不同工况下轴承的剩余寿命预测问题,提出了一种基于深度时序特征迁移的RUL预测方法.通过引入同型号轴承在不同工况下的监测数据,该方法可有效解决已有轴承数据量不足情况下RUL预测结果受限的问题.利用深度时序特征构建的HI可有效描述退化趋势,同时具有良好的单调性和故障敏感性,而在退化序列数据的信息迁移中着重考虑序

列的时序特性,可有效提高目标轴承的RUL预测效果。

在下一步工作中,计划进一步挖掘退化序列数据的时序特征,通过引入注意力机制,寻找具有更优判别能力的故障特征.此外,由于迁移过程中可能存在负迁移的现象,需要在理论上分析和评估不同工况的轴承数据在迁移学习过程中的信息损失,这是构建一个良好的序列迁移学习模型的关键问题之一。

参考文献(References)

- [1] 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.
- [2] Zhang B, Wang H, Tang Y, et al. Residual useful life prediction for slewing bearing based on similarity under different working conditions[J]. Experimental Techniques, 2018, 42(3): 279-289.
- [3] 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.
- [4] 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: 1-11.

- [5] Ren L, Sun Y Q, Cui J, et al. Bearing remaining useful life prediction based on deep autoencoder and deep neural networks[J]. *Journal of Manufacturing Systems*, 2018, 48(C): 71-77.
- [6] Wu Y T, Yuan M, Dong S P, et al. Remaining useful life estimation of engineered systems using vanilla LSTM neural networks[J]. *Neurocomputing*, 2018, 275(31): 167-179.
- [7] Pan S J, Yang Q. A survey on transfer learning[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2009, 22(10): 1345-1359.
- [8] Quattoni A, Collins M, Darrell T. Transfer learning for image classification with sparse prototype representations[C]. *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Anchorage: IEEE, 2008: 1-8.
- [9] Dai W, Xue G R, Yang Q, et al. Transferring naive ayes classifiers for text classification[C]. *Proceedings of the 22nd AAAI Conference on Artificial Intelligence*. Vancouver: AAAI Press, 2007: 540-545.
- [10] Lei Y G, Yang B, Du Z J, et al. Deep transfer diagnosis method for machinery in big data era[J]. *Journal of Mechanical Engineering*, 2019, 55(7): 1-8.
- [11] 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.
- [12] 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.
- [13] Shen F, Xu J W, Sun C, et al. Transfer between multiple working conditions: A new TCCHC-based exponential semi-deterministic extended Kalman filter for bearing remaining useful life prediction[J]. *Measurement*, 2019, 142: 148-162.
- [14] Mao W, He J L, Tang 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.
- [15] Benkedjouh T, Medjaher K, Zerhouni N, et al. Remaining useful life estimation based on nonlinear feature reduction and support vector regression[J]. *Engineering Applications of Artificial Intelligence*, 2013, 26(7): 1751-1760.
- [16] 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(31): 142-150.
- [17] Bai S J, Koltur J, Koltun V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling[DB/OL]. (2018-04-19)[2021-01-11]. <https://arxiv.org/pdf/1803.01271.2018>.
- [18] 庄福振, 罗平, 何清, 等. 迁移学习研究进展[J]. *软件学报*, 2015, 26(1): 26-39.
(Zhuang F Z, Luo P, He Q, et al. Survey on transfer learning research[J]. *Journal of Software*, 2015, 26(1): 26-39.)
- [19] Keogh E J, Pazzani M J. Derivative dynamic time warping[C]. *SIAM International Conference on Data Mining*. Chicago: Society for Industrial and Applied Mathematics, 2001: 1-11.
- [20] Medjaher K, Zerhouni N, Baklouti J, et al. Data-driven prognostics based on health indicator construction: Application to PRONOSTIA's data[C]. *European Control Conference (ECC)*. Zurich: IEEE, 2013: 1-8.
- [21] Guo L, Li N P, Jia F, et al. A recurrent neural network based health indicator for remaining useful life prediction of bearings[J]. *Neurocomputing*, 2017, 240: 98-109.
- [22] Reshef D N, Reshef Y A, Finucane H K, et al. Detecting novel associations in large data sets[J]. *Science*, 2011, 334(6062): 1518-1524.
- [23] Fernando B, Habbar A, Sebban M, et al. Unsupervised visual domain adaptation using subspace alignment[C]. *IEEE International Conference on Computer Vision*. Sydney: IEEE, 2013: 2960-2967.
- [24] Kristen G. Geodesic flow kernel for unsupervised domain adaptation[C]. *IEEE Conference on Computer Vision and Pattern Recognition*. Providence: IEEE, 2012: 2066-2073.
- [25] Huang J Y, Smola A, Gretton A, et al. Correcting sample selection bias by unlabeled data[C]. *International Conference on Neural Information Processing Systems (NIPS)*. Vancouver: MIT Press, 2006: 601-608.
- [26] Pan S J, Tsang I, Kwok J, et al. Domain adaptation via transfer component analysis[J]. *IEEE Transactions on Neural Networks*, 2021, 22(2): 199-210.
- [27] Liu Z L, Zuo M J, Yong Q. Remaining useful life prediction of rolling element bearings based on health state assessment[J]. *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*, 2016, 230(2): 314-330.
- [28] Zhu J, Chen N, Peng W, et al. Estimation of bearing remaining useful life based on multiscale convolutional neural network[J]. *IEEE Transactions on Industrial Electronics*, 2019, 66(4): 3208-3216.
- [29] 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*, 2017, 48(1): 11-20.

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: jxchenhtu@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;

张新明(1963—), 男, 教授, 博士, 从事模式识别、最优化理论等研究, E-mail: xinmingzhang@126.com.

(责任编辑: 闫妍)