

DOI:10.19651/j.cnki.emt.2212295

基于对抗迁移的旋转组件 RUL 预测方法研究*

刘夏丽 邓耀华 郭承旺

(广东工业大学机电工程学院 广州 510006)

摘要: 目前大多数旋转组件深度学习剩余使用寿命(RUL)预测方法通常是假设训练数据和测试数据有相同的数据分布,造成模型在不同工况下的预测准确率比较低。为了解决上述问题,以旋转多组件RUL预测模型为迁移对象,针对源域与目标域工况存在差异,目标域缺乏标签样本的迁移场景,引入了域分类器,结合源域的标签数据目标域的无标签数据重新训练RUL预测模型中的特征提取网络,在训练过程中加入自关联性及对应性约束,提升其对公共特征的提取能力,从而实现模型在不同场景的迁移应用。利用XJTU-SY公开数据集对迁移模型测试结果表明,相对于原预测模型,本文所述方法在新工况下的预测准确率更高;相比于其他迁移方法,本文方法预测误差更小,在变工况下的旋转组件剩余使用寿命预测迁移问题上具有更好的效果。

关键词: 旋转组件;剩余使用寿命预测;迁移学习;对抗训练

中图分类号: TP18 文献标识码: A 国家标准学科分类代码: 520.20

Prediction method of RUL of rotating units based on adversarial transfer learning

Liu Xiali Deng Yaohua Guo Chengwang

(School of Electro-Mechanical Engineering, Guangdong University of Technology, Guangzhou 510006, China)

Abstract: Most methods for predicting the Remaining useful life of deep learning of rotating units usually assume that the data distribution of training data and test data is the same, resulting in low prediction accuracy of the model under different working conditions. For the above problems, this paper proposed a model transfer method based on adversarial training, where the transfer object is a rotating multi-unit RUL prediction model. Aiming at the transfer scenario where the source domain and target domain have different working conditions and the target domain lacks label samples, a domain classifier was introduced to extract the common features of the source domain and target domain data. The feature extraction network in the RUL prediction model was retrained by combining the labeled data in the source domain with the unlabeled data in the target domain. In the training process, auto association and correspondence constraints were added to improve the ability to extract common features, thus realizing the migration application of the model in different scenarios. The test results of the transfer model using the XJTU-SY public dataset revealed that the prediction accuracy of the method described in this paper is higher than that of the original prediction model under the new working conditions. Compared with other transfer methods, the prediction error of this method is smaller, and it has a better effect on predicting the remaining useful life of rotating units under variable working conditions.

Keywords: rotating unit; prediction of remaining useful life; transfer learning; adversarial training

0 引言

旋转组件是高端精密电子制造装备的重要组成部件,对于装备的正常运行至关重要,其工作状况是否正常对装备性能有很大影响,一旦发生疲劳破坏失效,会对关联组件

造成二次损伤,进而导致整体系统的瘫痪^[1]。因此,对旋转多组件系统进行剩余使用寿命预测具有重要的实际意义。

目前,大多数深度学习剩余使用寿命(remaining useful life, RUL)预测模型,是基于大量数据样本且样本数据训练集和测试集的数据分布一致^[2]。而在实际运行场景下,由

收稿日期:2022-12-06

*基金项目:国家自然科学基金(52175457)、广东省重点领域研发计划(2019B010154001)项目资助

于工作载荷、转速、温度等环境的不同,训练数据和预测数据之间的数据分布存在偏差,又因为实际场景下的有标签数据获取难度高,样本量较小,无法获得足够数量的有标签数据重新训练模型,导致 RUL 预测准确率低。

迁移学习下的领域自适应(domain adaptation)方法能有效解决数据分布差异造成的预测准确率低的问题^[3]。领域自适应适用于解决源域与目标域具有相同任务但样本标签数据分布不同的问题,通过从源域的大量有标签样本中学习必要的知识,并将这些知识转移到目标域以解决相同的问题。

Yosinski 等^[4]探究了不同层次的特征在深度神经网络中的可迁移性,量化了原始任务和目标任务之间的差异对迁移特征效果的影响,证明了迁移学习对模型的泛化效果。Long 等^[5]提出了一种深度自适应网络(deep adaptation network,DAN)框架,将深度卷积神经网络扩展到领域自适应场景中,DAN 中所有任务层的隐藏表示都能嵌入到 Hilber 空间中,然后用最优的多元选择方法来适应这些嵌入输出的均值嵌入,而其他层保持不变。这个迁移学习框架显著提高了迁移过程中的模型训练速度。Wen 等^[6]使用自动编码器进行特征提取,并应用最大均值差异(maximum mean discrepancy,MMD)减小源域和目标域数据集的分布差异,以进行不同工作条件下的轴承故障诊断。Li 等^[7]通过最小化多核最大均值差异(MK-MMD)实现跨域轴承故障诊断。Ragab 等^[8]针对训练数据和测试数据分布不同,提出了一种基于对比对抗域自适应(CADA)的 RUL 预测方法,考虑目标特定的信息以获得领域固定特征。

近年来,生成对抗网络(generative adversarial networks,GAN)^[9]以其独特的架构在深度学习领域掀起了一股浪潮。Ganin 等^[10]提出了领域对抗神经网络(domain-adversarial neural network,DANN),把对抗网络的思想引入到迁移学习中。Li 等^[11]在机械设备的 RUL 预测研究中提出了一种结合 DANN 与 GAN 的思想的预测方法。Han 等^[12]通过对抗性学习策略将源域的标记数据与目标域中的无标签数据对齐,从而减小源域和目标域数据的分布差异,实现故障诊断模型的迁移。然而要调整整个模型的网络参数是一个相对繁琐的过程。Liu 等^[13]将 DANN 模型与双向长短时记忆(Bi-LSTM)神经网络相结合,对滚动轴承剩余使用寿命(remaining useful life,RUL)进行了估计,只训练同一工况下的源域数据时,源域和目标域的分布差异降低了 RUL 预测模型的精度。针对这一问题,Ding 等^[14]提出了一种基于域自适应 LSTM-DNN 网络的滑动轴承 RUL 预测方法,收集了不同工况下的多传感器运行失效数据集,验证了模型的领域适应性。综上所述,基于对抗训练的迁移方法更多关注迁移后的公共特征在数据分布差异以及分类预测精度上的表现。当目标域数据标签缺失的情况下,有可能出现数据与特征的错误映射,导致

分类预测结果出错。当前的迁移研究中并未针对这种情况提出系统的优化解决方法。

本文针对源域与目标域工况存在差异,目标域缺乏标签样本的迁移场景,引入了域分类器用于提取源域和目标域数据的公共特征,在特征提取器与域分类器的对抗训练过程中引入了解码器和 RUL 预测器的约束,从而实现模型在不同场景的迁移应用,并采用公开数据集进行了实验验证,证明了本文所提方法的有效性和优越性。

1 基于对抗迁移学习的旋转多组件剩余使用寿命预测框架

1.1 迁移学习问题分析

迁移学习包含领域 D 和任务 T 两个特定的概念,其中领域 $D = \{X, P(x)\}$, X 为特征空间, $(x_1, x_2, \dots, x_n) \in X$ 为总体样本, $P(x)$ 为该特征空间中数据的边缘分布概率,任务 $T = \{Y, f\}$, Y 表示标签类别空间, f 表示 X 与 Y 之间的映射关系,即存在 $f(X) = y$ 。给定带标签的源域 D_s ,不带标签的目标域 D_t ,源任务 T_s ,目标任务 T_t ,迁移学习的目的是利用源任务预测函数 f_s 的知识改进目标任务预测函数 f_t ,其中 $D_s \neq D_t$ 或 $T_s \neq T_t$ 。

本文针对的是不同工况下的旋转多组件的主要部件轴承,采集不同工况下的轴承振动信号数据,源域与目标域的特征空间 X 相同,概率分布 $P(X)$ 不同。RUL 预测模型迁移问题相关要素可以归纳为两部分:特征的边缘概率分布 $P(X)$ 以及映射模型 f ,记 X_s, f_s 分别为源域特征及映射模型, X_t, f_t 分别为目标域特征及映射模型,其中 f_t 是迁移学习的目的,本文的迁移模型所要解决的问题可以定义为,当 $P(X_s) \neq P(X_t), f_s \neq f_t$,求取新的映射模型 f' ,使得 $f'(X_t) = Y$ 。迁移学习的目标如图 1 所示。

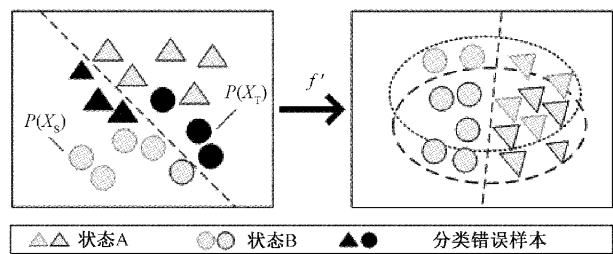


图 1 迁移学习的目标

在旋转多组件系统 RUL 预测模型的迁移过程中,工况(应用场景)发生改变,数据的边缘分布同样会发生偏移,源域与目标域中相同的数据可能对应不同的标签,本文采用基于特征的迁移方法(feature based transfer learning),训练特征提取网络关注目标域与源域的共同特征,并根据源域的标签数据调整公共特征与标签的映射关系,实现不同分布数据的差异最小化,以预测目标域数据的分类。

1.2 剩余使用寿命预测的对抗迁移模型

GAN 由 Goodfellow 等^[9]在 2014 年提出,模型框架中

至少包含两个模块:生成网络和判别网络,生成网络用来生成与真实样本类似的假数据样本,判别网络则用来区分真假样本。生成网络训练的目的是尽可能骗过判别网络,而判别网络的目的是尽可能提高判别准确率,两个网络相互对抗,不断调整优化,最终使判别网络无法判断输入数据到底来自生成网络还是实际样本。

Ganin 等^[10]提出的域对抗迁移网络(DANN),将目标域中的数据看作生成的样本,生成网络不再是生成样本而是从源域和目标域中提取特征,使得判别网络无法区分提取的特征来自源域还是目标域,重点关注如何在不同域之间选择可供迁移的特征。DANN 结构主要包含 3 个部分:

特征提取器,标签预测器,域分类器,特征提取器用于将数据映射到特定的特征空间,使标签预测器能够分辨出来自源域数据的类别的同时,域分类器无法区分数据来自哪个域。标签预测器对来自源域的数据进行分类,尽可能分出正确的标签。域分类器对特征空间的数据进行分类,尽可能分出数据来自源域还是目标域。

本文在此基础上,结合具体 RUL 预测模型的迁移任务,对特征做出自关联性、区分性以及公共性 3 方面的优化约束,提出基于对抗迁移学习的旋转多组件 RUL 预测框架,通过特征迁移模块实现特征在新旧任务之间的映射转化,从而解决预测准确度低的问题,总体框架如图 2 所示。

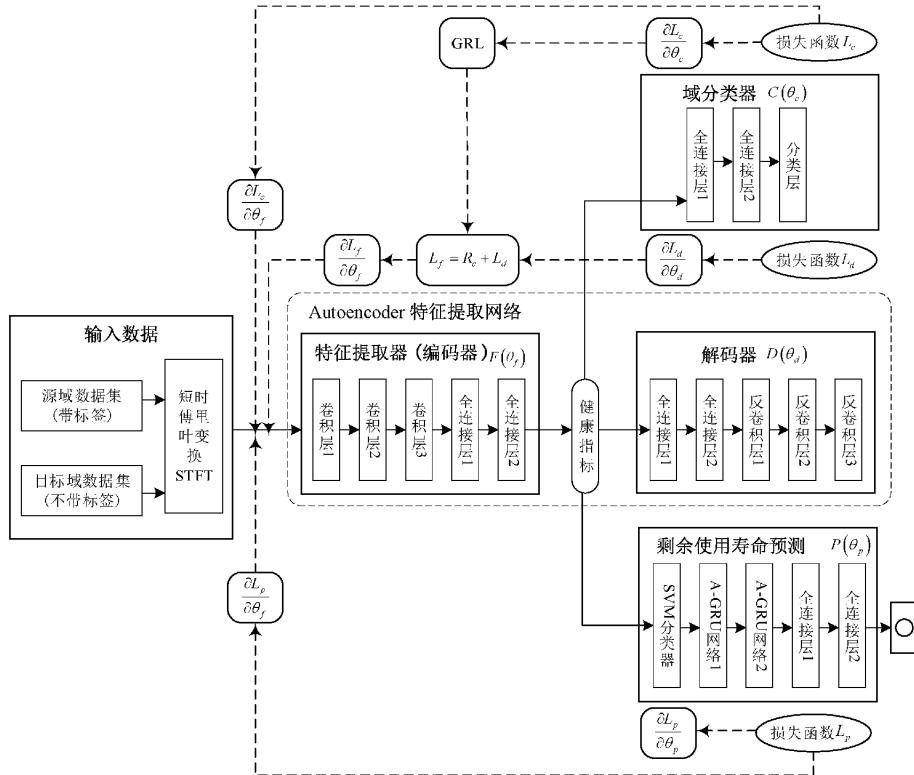


图 2 迁移模型的结构

旋转多组件 RUL 预测方法,首先通过 STFT 方法对原始信号进行特征变换,再应用 Autoencoder 特征提取网络对特征进一步降维,获得旋转多组件系统的健康指标,在 SVM 划分旋转组件性能状态演变阶段的基础上,采用注意力机制(attention)介入的循环神经网络的变体网络 GRU(gated recurrent unit),对输入数据的每个部分赋予不同的权重,提取出更关键和更重要的信息用于多组件的剩余使用寿命预测。

在对抗迁移模型中:特征提取器 $F(\theta_f)$: 该网络是特征提取网络的 encoder 部分,是迁移学习的训练对象,用于提取源域和目标域的公共特征。解码器 $D(\theta_d)$: 该网络是特征提取网络的 decoder 部分,可以将 encoder 提取得到的特征重构成时频特征,通过对比重构特征与原输入特征保

持迁移过程中特征的自关联性。域分类器 $C(\theta_c)$: 其实质是一个分类网络,由两层全连接层以及一层 softmax 层组成,用于区分提取所得的特征是属于源域还是目标域,与特征提取器对抗训练,交替迭代更新,用于减小源域与目标域之间的数据分布差异。RUL 预测器 $P(\theta_p)$: 基于 Attention-GRU 的 RUL 预测网络,是预测模型的主干功能网络,模型迁移的目的就是让该网络能在目标域场景下获得与源域相近的预测能力,在迁移流程中保持模型所提取的公共特征的区分性。

特征的自关联性是指网络提取所得的特征能重构并与原数据相对应,因为目标域的数据并没有标签,难以判断提取得到的特征是否与原数据相对应,自关联性的约束能保留特征的结构信息,避免出现特征提取器对数据的无

差别压缩提取。特征的区分性是指提取得到的特征不丢失分类预测的能力,依然保留与样本标签的关联。特征的公共性是指从源域和目标域提取得到的特征可以去除域偏置信息,具有相同的边缘概率分布。

1.3 迁移模型的训练

RUL 预测模型基于对抗训练的思想实现在不同场景下的迁移应用,特征提取器 $F(\theta_f)$ 的参数通过解码器 $D(\theta_d)$ 、域分类器 $C(\theta_c)$ 、RUL 预测器 $P(\theta_p)$ 这 3 个网络的对抗训练进行调整,以实现 3 个目标:1) 源域数据集的准确分类,最小化分类误差;2) 提取源域与目标域数据的公共特征,最大化域分类误差;3) 确保提取的特征与原始数据的一致性,最小化重建误差。

定义域标签为 $U \in \{0,1\}$, 源域标签为 0, 目标域标签为 1, 源域有标签数据集为 X_s , 目标域无标签数据集为 X_t , 令 L_d 表示解码器的损失函数, L_c 表示域分类器的损失函数, L_p 表示 RUL 预测器的损失函数, X_s^H 和 X_s^F 分别表示源域有标签数据集的健康数据集和退化数据集(退化开始、退化加剧)。迁移模型的总体损失函数 $E(\theta_f, \theta_p, \theta_d, \theta_c)$ 为式(1):

$$E(\theta_f, \theta_p, \theta_d, \theta_c) = U(L_d(D(F(X_t; \theta_f); \theta_d), X_t) - L_c(C(F(X_t; \theta_f); \theta_c), U)) + (1-U)(L_p(P(F(X_s^F; \theta_f); \theta_p), R) - L_c(C(F(X_s^H; \theta_f); \theta_c), U)) \quad (1)$$

根据数据的来源将迁移训练过程分为目标域训练和源域训练两个部分。目标域训练包括特征提取器、解码器、域分类器 3 个主体模块,其目的是将目标域的数据投射到新的特征空间中,在新特征空间中与源域进行数据对齐,通过数据对齐学习到源域与目标域的公共特征。在迁移场景中,目标域数据都是无标签的,为了确保特征提取器获得的特征与原数据存在对应关系,通过解码器重构特征,与特征提取器形成 encoder-decoder 结构实现自监督约束。如果将旋转多组件系统的全寿命周期数据都用于提取公共特征,由于标签的缺失,可能会导致与源域数据的误匹配,出现负迁移现象。而旋转多组件系统在运行初期都处于健康状态,为了更为准确提取公共特征,加快训练的收敛速度,选择采用系统前期运行数据与源域的健康数据进行数据对齐,使用目标域进行训练时的损失函数如式(2)所示。

$$E(\theta_f, \theta_d, \theta_c) = L_d(D(F(X_t; \theta_f); \theta_d), X_t) - L_c(C(F(X_t; \theta_f); \theta_c), U) \quad (2)$$

又因为特征空间 X_t 和域标签 U 都已确定,将损失函数进一步简化为式(3):

$$E(\theta_f, \theta_d, \theta_c) = L_d(\theta_f, \theta_d) - L_c(\theta_f, \theta_c) \quad (3)$$

由上式可知,在目标域训练过程中,特征提取器会根据解码器和域分类器的误差调整网络参数,其含义是减小新的特征映射空间中目标域与源域之间的数据分布差异,并保持数据自身的识别度。解码器则会接收自身的误差进行调整,含义是通过调整网络自身的参数,适应新的公

共特征与原数据的重构关系。当特征提取器和解码器完成更新后,对抗训练的另一主体域分类器随之进行更新。域分类器通过更多的带有域标签的样本数据以及训练次数提高分类准确率,其含义是为了减少公共特征的域偏置信息,提高域分类器的分辨能力。目标域训练的对抗优化过程如式(4)~(5)所示。

$$(\hat{\theta}_f, \hat{\theta}_d) = \underset{\theta_f, \theta_d}{\operatorname{arg\,min}} E(\theta_f, \theta_d, \hat{\theta}_c) \quad (4)$$

$$\hat{\theta}_c = \underset{\theta_c}{\operatorname{arg\,min}} E(\hat{\theta}_f, \hat{\theta}_d, \theta_c) \quad (5)$$

域分类器的目标是最小化分类误差,而特征提取器要令分类误差最大化,两个网络对于分类误差的优化路径相反,通常情况下需要先固定一个网络,对另一个网络进行训练,训练过程交替进行。为了简化训练过程,提高训练效率,引入梯度反转层(gradient reversal layer, GRL),GRL 的原理如式(6)~(7)所示。

$$R(x) = x \quad (6)$$

$$\frac{\partial R}{\partial \theta} = -\frac{\partial L}{\partial \theta} \quad (7)$$

令 δ 表示梯度下降算法的学习率, $f_{Adam,f}, f_{Adam,d}, f_{Adam,c}$ 分别表示特征提取器 $F(\theta_f)$, $D(\theta_d)$ 表示编码器, 域分类器 $C(\theta_c)$ 的 Adam 优化器, R_c 表示 L_c 经过 GRL 转换后的损失函数,采用均方误差 MSE 作为损失函数,通过 Adam 算法优化训练过程,并在反向传播中使用 GRL, 网络参数的优化过程如式(8)~(10)所示。

$$\theta_f \leftarrow \theta_f - \delta f_{Adam,f} \left(\frac{\partial L_d}{\partial \theta_f} + \frac{\partial R_c}{\partial \theta_f} \right) \quad (8)$$

$$\theta_d \leftarrow \theta_d - \delta f_{Adam,d} \frac{\partial L_d}{\partial \theta_d} \quad (9)$$

$$\theta_c \leftarrow \theta_c - \delta f_{Adam,c} \frac{\partial L_c}{\partial \theta_c} \quad (10)$$

源域训练包括特征提取器、RUL 预测器以及域分类器 3 个主体模块,目的是提升公共特征的 RUL 预测能力。由于是有标签数据训练,并不需要依靠网络模型区分数据的健康状态,因此在源域训练过程中跳过 SVM 分类器,当特征提取器及 RUL 预测器训练完成后,再更新 SVM 分类器的参数。在实际场景中,目标域只选取旋转多组件系统的前期运行数据进行迁移学习,而前期数据是健康数据,因此在源域训练中也要选取健康标签的数据进行数据对齐,从而提取有效的公共特征。

源域训练需要分为健康数据训练和退化数据训练两个步骤。在源域训练过程中,特征提取器分别接收来自 RUL 预测器以及域分类器的误差以调整网络参数,RUL 预测器也会对自身的网络参数进行调整,寻找新的公共特征与 RUL 标签间的映射关系。与目标域训练的步骤相同,当特征提取器及 RUL 预测器完成优化后,继续对域分类器进行更新调整,通过迭代训练使得 3 个网络逐渐趋于平衡。源域训练延续了目标域训练的优化结果,源域训练

的整体损失函数及参数的最优值如式(11)~(13)所示。

$$E(\theta_f, \theta_p, \theta_c) = L_p(P(F(X_S^F; \theta_f); \theta_p), R) - \\ L_c(C(F(X_S^H; \theta_f); \theta_c), U) \quad (11)$$

$$\hat{(\theta'_f, \hat{\theta}_p)} = \underset{\hat{\theta}_f, \hat{\theta}_p}{\operatorname{argmin}} E(\hat{\theta}_f, \hat{\theta}_p) \quad (12)$$

$$\hat{\theta}'_c = \underset{\hat{\theta}_c}{\operatorname{argmin}} E(\hat{\theta}_f, \hat{\theta}_c) \quad (13)$$

参数的更新优化方法如式(14)~(16)所示。

$$\theta_f \leftarrow \theta_f - \delta f_{Adam, f} \frac{\partial L_p}{\partial \theta_f} \quad (14)$$

$$\theta_p \leftarrow \theta_p - \delta f_{Adam, p} \frac{\partial L_p}{\partial \theta_p} \quad (15)$$

$$\theta_c \leftarrow \theta_c - \delta f_{Adam, c} \frac{\partial L_c}{\partial \theta_c} \quad (16)$$

旋转多组件系统 RUL 预测模型的迁移流程如图 3。

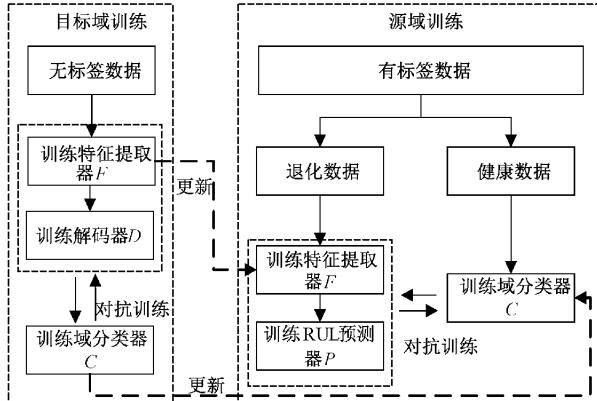


图 3 迁移模型对抗训练流程

2 实验验证与对比分析

为验证本文提出的方法,采用 XJTU-SY 滚动轴承加速寿命试验数据集^[15]进行训练及验证模型。

试验所用轴承为 LDK UER204 滚动轴承,轴承内径 29.30 mm,外径 39.80 mm,滚珠数量为 8,滚珠直径 7.92 mm。轴承的振动信号通过水平竖直方向的 PCB 352C33 加速度传感器以及 DT9837 动态信号采集器进行采集,采样频率为 25.6 kHz,采样间隔为 1 min,每次采样时长为 1.28 s。为安全起见,通过相对阈值法确定轴承的失效阈值,即当轴承振动幅值超过 $10 \times A_h$ 时认为轴承已经完全失效并立刻终止试验(A_h 为轴承在正常运行阶段的最大幅值)。数据集主要包含了正常、内圈损伤、外圈损伤、保持架断裂 4 种类别(如图 4 所示),共 15 组测试的轴承数据,符合本文所提出模型算法的分析需求。



(a) 正常 (b) 内圈磨损 (c) 外圈磨损 (d) 保持架断裂

图 4 典型失效类型的轴承图片

2.1 数据集设置

XJTU-SY 数据集包含表 1 所示的 3 类工况,为模拟旋转多组件系统的迁移场景,选取表 1 对应的工况 2 的数据集作为源域数据集,工况 1 的数据集作为目标域数据集。其中工况 2 包含 5 组轴承全寿命周期数据,囊括了内圈、外圈、保持架三个类别的独立故障类型,具体数据如表 2 所示。工况 1 同样包含 5 组轴承全寿命周期数据,故障类型与工况 2 不同,囊括了外圈、保持架、内圈外圈同时故障的故障类型,具体数据如表 3 所示。图 5、6 为工况 2、工况 1 条件下轴承性能时域数据波形图(图 5(a)以数据集 B2_1 为例,图 5(b)以数据集 B2_5 为例,图 6(a)以数据集 B1_1 为例,图 6(b)以数据集 B1_5 为例),工况 1 的数据分布与工况 2 的数据分布不一致。

表 1 轴承加速寿命实验工况

工况编号	1	2	3
转速/(r·min ⁻¹)	2 100	2 250	2 400
径向力/kN	12	11	10

表 2 XJTU-SY 工况 2 的轴承数据集

工况	数据集	样本总数	L ₁₀ /h	实际寿命	失效位置
2	B2_1	491		8 h11 min	内圈
	B2_2	161		2 h41 min	外圈
	B2_3	533	6.789~11.726	8 h53 min	保持架
	B2_4	42		42 min	外圈
	B2_5	339		5 h39 min	外圈

表 3 XJTU-SY 工况 1 的轴承数据集

工况	数据集	样本总数	L ₁₀ /h	实际寿命	失效位置
1	B1_1	123		2 h3 min	外圈
	B1_2	161		2 h41 min	外圈
	B1_3	158	5.600~9.677	2 h38 min	外圈
	B1_4	122		2 h2 min	保持架
	B1_5	52		52 min	内圈、外圈

2.2 数据处理

1) 数据集处理

为了贴合本文所提出的模型对样本的要求,对原数据集进行标签标注处理。从采集到的连续振动数据中提取数据样本,记总样本量为 S,设第 j 组轴承数据中包含的样本数为 S_j,每个样本包含 D_{input} 个点, $x_{ji}^{n_i} \in R^{D_{input}}$, ($i = 1, 2, \dots, S_j$) 表示第 j 组轴承数据的第 i 个样本里的第 n_i 个点。对原始数据集的基本处理方法为:分析各轴承的振动幅值,利用相对阈值法结合应用场景预定义边界序列 i_E, i_E 用于区分信号的“正常”和“异常”阶段,在边界序列

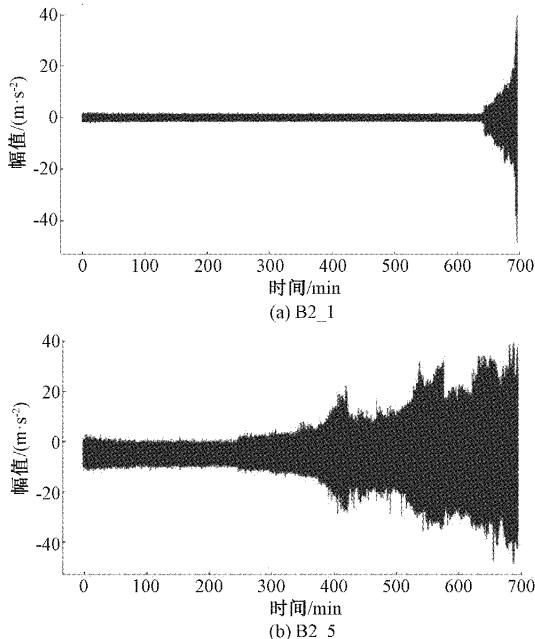


图 5 工况 2 条件下的轴承性能时域数据波形图

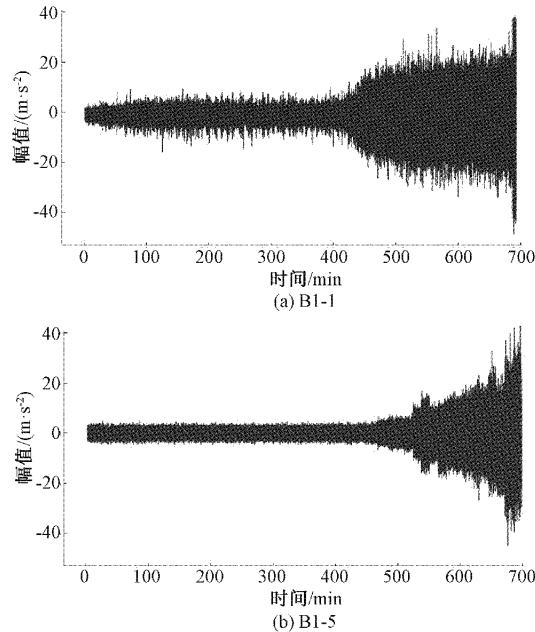


图 6 工况 1 条件下的轴承性能时域数据波形图

之前的正常阶段中,各轴承表征相似且波动小,而边界序列之后轴承的衰退趋势变化明显,故以下实验均选择边界序列 i_E 之后的异常阶段数据开展研究。

设第 j 组轴承的失效类别为 l_j , $l_j \in L$ 。 $L(x_{ji})$ 表示第 j 组轴承数据集第 i 个样本的故障类别标签,其确定方法如式(17)所示。

$$L(x_{ji}) = \begin{cases} l_1, & i < T_s \\ l_j, & T_s \leq i \leq S_j \end{cases} \quad (17)$$

其中, T_s 是边界序列 i_E 在数据集中的序列数, S_j 为

第 j 组轴承的总样本数。

2) RUL 标签定义

XJTU-SY 原始数据集的寿命值计算方法是统计从轴承开始转动至轴承振动幅值达到失效这一过程的持续时间,为了便于验证本文所提算法模型的效果,需要重新定义轴承的寿命区间。由于标签为 l_1 的样本点无需进行 RUL 预测,在进行 RUL 标记时剔除该类标签的样本点,同时将 T_s 所在位置作为轴承退化的起点,寿命标签 R 以百分比的形式表示,第 j 组轴承数据集第 i 个样本的剩余使用寿命 $R(x_{ji})$ 确定方法如式(18)所示。

$$R(x_{ji}) = \begin{cases} None, & i < T_s \\ \frac{i - S_j}{T_s - S_j} \times 100\%, & T_s \leq i \leq S_j \end{cases} \quad (18)$$

通过上述步骤可以获得拥有故障类别及剩余使用寿命标签的样本数据集合 $\{X, (L, R)\}$,充分满足模型的训练需求。记经过处理后得到的工况 1 的标签数据集为 S_1 , $S_1 = \{X_1, (L_1, R_1)\}$,其中 X_1 是工况 1 的轴承数据, L_1 , R_1 分别为数据对应的故障类型及 RUL 标签。

2.3 实验结果与分析

为了验证本文所提出的迁移方法的有效性,采用相同的特征提取模型,不同的迁移模型进行比较分析。迁移对象是已在工况 2 数据集上训练好的 RUL 预测模型,迁移目的是将该模型迁移至工况 1 数据集中应用。这些方法的实验设置和网络结构与本文所提方法相似,但在迁移训练过程中有所区别,各方法的设置如下:

- 1) Basic: 该方法作为基本的效果比对网络,并不进行网络结构更改或参数更新,直接将源域模型应用于目标域数据;
- 2) Nopredictor: 该方法引入域分类器,在迁移过程中会进行解码器、特征提取器以及域分类器的对抗训练,但不更新 RUL 预测网络的参数;
- 3) Nodecoder: 该方法引入域分类器,通过 RUL 预测器、特征提取器以及域分类器不更新 decoder 的网络参数,其余结构与本文方法一致。
- 4) Noalign: 该方法在源域训练过程中并不将健康数据与退化数据分开训练。

各方法在测试集的实验结果如图 7 所示。分析可知:Basic 的预测误差较大,说明在源域与目标域存在数据分布差异时,原预测模型直接应用于新环境中的预测准确率不高;Nopredictor 的迁移方法预测效果也相对较差,预测误差与未进行迁移操作的 Basic 方法相近,甚至更高。这是因为特征提取器经过与域分类器的对抗训练后,网络参数发生变化,提取得到的公共特征与原特征存在差异,原来的特征与寿命间的映射关系在新特征空间中并不适用,出现了负迁移的情况。Nodecoder 和 Noalign 的方法相较于 Basic 都有明显的提升,其中 Noalign 的综合表现更加优异。结合数据分析可知,Noalign 方法能取得更好的表现。

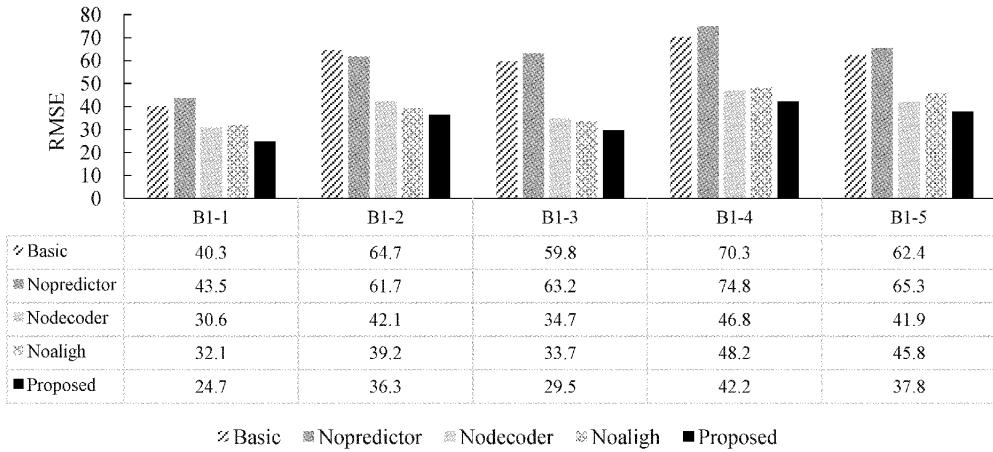


图 7 不同迁移模型的 RUL 预测 RMSE 结果

可能是由于数据中的退化样本相对于健康样本数量较少，在随机的训练过程中错误匹配的概率较低，从而能够获得更加接近本文所述方法的性能。

从整体上看，本文所提出的基于对抗训练的模型迁移方法明显优于 Basic 基本模型，同时相较于其他方法也具有更小的预测误差，证明了该迁移方法的有效性。通过该方法迁移得到的模型在工况 1 数据集的预测效果如图 8 所示（以 B1-1, B1-5 为例）。

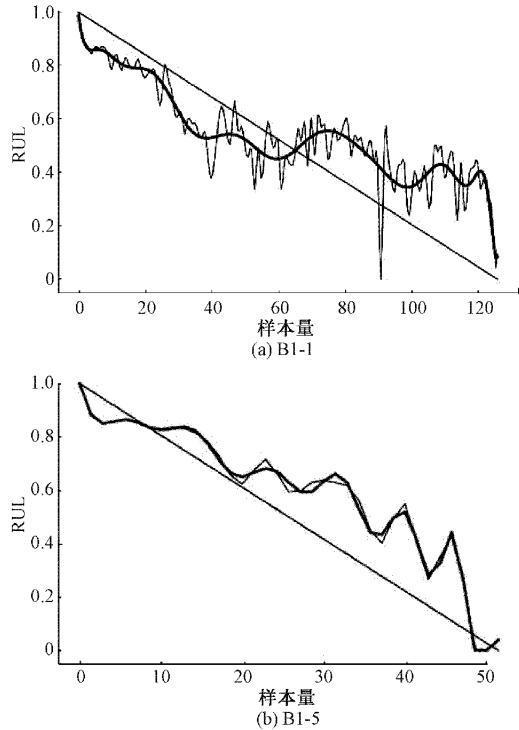


图 8 RUL 预测模型在工况 1 数据集的预测曲线

由图 8 可知，模型在迁移后依旧能够获得较为准确的预测值，预测误差较小，说明迁移方法有效地提升了模型提取公共特征的能力，且提取后的特征有较好自关联性和对应性，能够准确捕捉数据的变化趋势。

3 结 论

本文针对 RUL 预测模型在新场景中应用准确率低，且缺乏标签样本难以重新训练的问题，提出了一种基于对抗训练的迁移方法。该方法将 Autoencoder 特征提取网络中的 encoder 网络用作特征提取器 $F(\theta_f)$ ，来提取源域和目标域的公共特征，decoder 网络用作编码器 $D(\theta_d)$ ，使得新提取的公共特征兼顾自关联性、对应性以及公共性，同时引入域分类器，用于与特征提取器对抗训练，减小源域和目标域之间的数据分布差异。由于目标域数据都是无标签数据，为了保证迁移后模型的预测效果，将迁移的训练过程分为了源域训练和目标训练两个部分。先通过源域训练的健康数据以及目标域的运行前期数据进行数据对齐，提取公共特征，再通过源域训练的退化数据提高公共特征的预测准确性。最后选取了 XJTU-SY 公开数据集中不同工况的数据集模拟迁移场景，将所提出的迁移方法与其他方法进行了比较分析，验证了方法的有效性。

参考文献

- [1] BIEBL F, GLAWAR R, JALALI A, et al. A conceptual model to enable prescriptive maintenance for etching equipment in semiconductor manufacturing[J]. Procedia CIRP, 2020, 88:64-69.
- [2] 刘晓磊, 刘连胜, 王璐璐, 等. 基于状态空间模型的飞机 APU 在翼 RUL 预测方法[J]. 仪器仪表学报, 2021, 42(2):45-54.
- [3] WILSON G, COOK D J. A survey of unsupervised deep domain adaptation [J]. Acm Transactions on Intelligent Systems and Technology, 2020, 11 (5): 1-46.
- [4] YOSINSKI J, CLUNE J, BENGIO Y, et al. How transferable are features in deep neural networks[J]. Advances in Neural Information Processing Systems, 2014, DOI:10.48550/arXiv.1411.1792.

- [5] LONG M S, CAO Y, WANG J M, et al. Learning transferable features with deep adaptation networks[C]. International Conference on Machine Learning, PMLR, 2015; 97-105.
- [6] WEN L, GAO L, LI X Y. A new deep transfer learning based on sparse auto-encoder for fault diagnosis[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2019, 49(1): 136-144.
- [7] LI X, ZHANG W, XU N X, et al. Deep learning-based remaining useful life estimation of bearings using multi-scale feature extraction [J]. Reliability Engineering & System Safety, 2019, 182: 208-218.
- [8] RAGAB M, CHEN Z, WU M, et al. Contrastive adversarial domain adaptation for machine remaining useful life prediction [J]. IEEE Transactions on Industrial Informatics, 2021, 17(8): 5239-5249.
- [9] GOODFELLOW I J, POUGET A J. Generative adversarial networks [J]. Advances in Neural Information Processing Systems, 2014, 3: 2672-2680.
- [10] GANIN Y, USTINOVA E, AJAKAN H, et al. Domain-adversarial training of neural networks [J]. The Journal of Machine Learning Research, 2016, 17(1): 2030-2096.
- [11] LI X, ZHANG W, MA H, et al. Data alignments in machinery remaining useful life prediction using deep adversarial neural networks [J]. Knowledge-Based Systems, 2020, 197, DOI: 10.1016/j.knosys. 2020.105843.
- [12] HAN T, LIU C, YANG W G et al. Deep transfer network with joint distribution adaptation: A new intelligent fault diagnosis framework for industry application[J]. ISA Transactions, 2020, 97:269-281.
- [13] LIU C, GRYLLIAS K. Unsupervised domain adaptation based remaining useful life prediction of rolling element bearings [C]. 2020 European Conference of the PHM Society, 2020.
- [14] DING N, LI H L, YIN Z W, et al. A novel method for journal bearing degradation evaluation and remaining useful life prediction under different working conditions [J]. Measurement, 2021, 177, DOI:10.1016/j.measurement.2021.109273.
- [15] 雷亚国, 韩天宇, 王彪, 等. XJTU-SY滚动轴承加速寿命试验数据集解读[J]. 机械工程学报, 2019, 55(16):1-6.

作者简介

刘夏丽,硕士,工程师,主要研究方向为智能制造、设备可靠性建模。

E-mail:lxl@gdut.edu.cn

邓耀华(通信作者),博士,教授,主要研究方向为工业智能维护,可靠性工程等。

E-mail:dengyaohua@gdut.edu.cn

郭承旺,硕士,主要研究方向为智能运维。

E-mail:2111901389@mail2.gdut.edu.cn