

DOI: 10.13382/j.jemi.B2205538

多源域子域自适应的滚动轴承剩余寿命预测方法*

黄庆卿^{1,2} 胡欣堪¹ 韩延^{1,2} 林志超¹ 张焱^{1,2}

(1. 重庆邮电大学自动化学院 重庆 400065; 2. 重庆邮电大学工业互联网研究院 重庆 401120)

摘要:针对单一源域信息有限、域自适应对齐粒度不足导致滚动轴承剩余寿命(remain useful life, RUL)预测精度低的问题,提出了一种多源域子域自适应(multi-source subdomain adaption network, MS_SAN)的滚动轴承剩余寿命预测方法。首先,将采集的原始振动信号进行快速傅里叶变换得到频域信号作为模型的输入。其次,利用一维卷积将多个源域与目标域数据映射到一个公共的特征空间,采用局部最大均值差异将每个源域与目标域的退化阶段在独立的特征空间进行领域自适应,缩小多个源域与目标域之间的分布差异。最后,通过综合各领域RUL预测模块的输出得到最终轴承剩余寿命预测结果。在PHM2012数据集上的测试结果表明该方法的预测准确率高于对比方法,能够对滚动轴承剩余寿命进行有效的预测。

关键词:滚动轴承;剩余使用寿命;多源域;子域自适应

中图分类号: TH165.3 **文献标识码:** A **国家标准学科分类代码:** 460.1520;510.4030

Remain useful life prediction of rolling bearing based on multi-source subdomain adaption network

Huang Qingqing^{1,2} Hu Xinkan¹ Han Yan^{1,2} Lin Zhichao¹ Zhang Yan^{1,2}

(1. Automation College, Chongqing University of Posts and Telecommunications, Chongqing 400065, China;

2. Institute of Industrial Internet, Chongqing University of Posts and Telecommunications, Chongqing 401120, China)

Abstract: To address the problem that low accuracy of rolling bearing remain useful life (RUL) prediction caused by the limited information of single source domain and the insufficient granularity of domain, a new method of RUL for rolling bearing based on multi-source subdomain adaption network is proposed. Firstly, fast fourier transform is applied to the collected raw vibration signals to obtain the frequency-domain signals and it takes the frequency-domain signals as the input of the model. Secondly, to reduce the distribution difference between multiple source domains and target domains, all domains are mapped to a common feature space by one-dimensional convolution, and the local maximum mean discrepancy is used to align the degradation stage of each source domain and target domain in an independent feature space. Finally, the RUL of rolling bearing is obtained by comprehensive output of the module in different domains. The results on PHM2012 data set show that the prediction accuracy of proposed method is higher than the comparison method, and can effectively predict the RUL of rolling bearing.

Keywords: rolling bearing; RUL; multi-source; sub-domain adaption

0 引言

滚动轴承是旋转机械中的关键部件,一旦发生故障将严重威胁生命和财产安全。因此,准确地预测滚动轴

承剩余寿命,对于保障设备安全稳定运行至关重要^[1-3]。

深度学习通过建立深层网络,可自适应提取轴承的退化特征^[4],近年来基于深度学习的滚动轴承剩余寿命预测在学术界得到广泛研究。王玉静等^[5]充分考虑轴承退化数据的时序性,结合卷积神经网络和长短期记忆神

收稿日期: 2022-05-27 Received Date: 2022-05-27

* 基金项目:国家自然科学基金(51605065)、重庆市博士后科学基金(cstc2021jcyj-bshX0094)、重庆市教委科学技术研究(KJQN202100612, KJQN202000611)项目资助

神经网络进行滚动轴承的寿命预测;Ding 等^[6]首先利用模糊 C 均值聚类将轴承全寿命数据分为正常运行、轻微退化和严重退化 3 个阶段,然后用 LSTM 进行 RUL 预测;Chen 等^[7]利用卷积自编码器建立轴承的健康指标,通过改进的门控循环单元预测轴承的剩余寿命。尽管上述方法对轴承剩余寿命取得了一定效果,但是以上方法的预测是建立在训练数据和测试数据处于相同分布基础上^[8]。然而,在实际应用场景中,大多数轴承运行工况多变导致数据分布存在差异,限制了深度学习方法在变工况下寿命预测的应用。

针对这一问题,不少学者将领域自适应引入到轴承寿命预测中,通过学习跨域不变的特征,减少源域和目标域之间的分布差异,提高寿命预测精度。Cheng 等^[9]针对源域和目标域不同的数据分布,采用多核最大均值差异(maximum mean discrepancy, MMD),利用多核来全面评估特征空间的分布差异,有效避免不同核对模型的影响;Ding 等^[10]考虑到源域与目标域之间的二阶差异,采用 MMD 和相关对齐将源域和目标域的一阶、二阶统计量对齐,并结合领域判别器进行不同工况下的轴承剩余寿命预测;Ding 等^[11]首先利用自编码器提取特征,通过核回归在特定的度量空间中计算误差损失,并使用多核 MMD 减少两域之间的分布差异进行轴承寿命预测。领域自适应方法在不同工况的轴承的寿命预测已经取得了较好的效果,但以上方法只将单一工况的数据作为源域,难以提取足够的域不变特征,并且忽略了不同退化阶段的特征存在差异,导致在域自适应过程中领域适应的粒度不足^[12]。

为解决上述问题,本文提出多源域子域自适应的滚动轴承剩余寿命预测方法。首先,针对轴承在不同的工况下具有不同的退化特征,使用多源域自适应提取不同工况下的域不变特征;其次,由于轴承的退化有明显的阶段性,利用局部最大均值差异将源域与目标域轴承根据退化阶段对齐,提高了对齐的粒度。最后,在 PHM2012 数据集上的测试结果表明该方法的预测准确率高于对比方法,能够对滚动轴承剩余寿命进行有效的预测。

1 相关理论

迁移学习的定义如下:给定一个源域 D_s 和目标域 D_t ,源域和目标域上有任务 T_s 和 T_t ,且有 $D_s \neq D_t$ 和 $T_s \neq T_t$,领域自适应可通过 D_s 和 D_t 上的知识来提升目标域上的预测函数 $f_t(\cdot)$,其中域的定义为 $D = \{\chi, P(X)\}$,即由特征空间 χ 和边缘概率分布 $P(X)$ 组成;任务定义为 $T = \{y, P(Y|X)\}$,即由标签空间 y 和条件概率分布 $P(Y|X)$ 组成^[13]。

最大均值差异常用于来度量源域和目标域之间的分

布差异^[14],MMD 的定义如下:

$$d_H(p, q) = \left\| \sum_{x_i \in D_s} \phi(x_i^s) - \sum_{x_j \in D_t} \phi(x_j^t) \right\|_H^2 \quad (1)$$

其中, $\phi(\cdot)$ 为特征映射, $\|\cdot\|_H$ 是再生核希尔伯特空间, x^s 和 x^t 是 D_s 和 D_t 中的样本。

2 多源域子域自适应的轴承剩余寿命预测方法

滚动轴承在不同的工况下会的退化特征分布存在差异,若直接采用深度学习进行不同工况下的轴承寿命预测效果较差。目前,基于领域自适应的轴承寿命预测方法虽然通过学习跨域不变的特征,减少源域和目标域之间的分布差异,取得了一定效果,但是仅依靠单源域难以提取足够的域不变特征^[15],并且忽略了不同退化阶段的特征存在差异,导致领域自适应的粒度不足。

为了解决上述问题,本文提出基于 MS_SAN 的滚动轴承剩余寿命预测方法。首先,在模型中将各个源域与目标域在相互独立的特征空间中进行对齐,有效的利用了多个源域中的信息。然后,将轴承退化过程等分为多个阶段,使用局部最大均值差异计算源域与目标域的分布差异,提升了对齐粒度,进一步提升轴承寿命预测精度。

2.1 MS_SAN 整体框架

MS_SAN 网络整体结构如图 1 所示,主要由公共特征提取器 $F(\cdot)$ 、特定域特征提取器 $H_k(\cdot) |_{k=1}^N$ 、特定域退化阶段分类器 $C_k(\cdot) |_{k=1}^N$ 、特定域 RUL 预测器 $P_k(\cdot) |_{k=1}^N$ 组成。其中公共特征提取器 $F(\cdot)$ 用于初步提取输入数据的共有空间特征;特定域特征提取器 $H_k(\cdot) |_{k=1}^N$ 针对每一个领域将公共特征空间中的特征进一步变化到特定领域空间;特定域退化阶段分类器 $C_k(\cdot) |_{k=1}^N$ 、特定域 RUL 预测器 $P_k(\cdot) |_{k=1}^N$ 分别用于完成 RUL 退化阶段分类和剩余寿命预测任务。

设 x_i 为输入到第 k 个源域样本,在经过公共特征提取器 $F(\cdot)$ 后输出为 $F(x_i)$,经过特定域特征提取器 H_k 的输出为 z_i ,定义为:

$$z_i = H_k(F(x_i)) \quad (2)$$

设 C_k 和 P_k 的输出分别为 y_i 和 r_i ,结合式(2),将其定义为:

$$y_i = C_k(z_i) \quad (3)$$

$$r_i = P_k(z_i) \quad (4)$$

由于目标域输入样本 x_j^t 经过 N 个特定域网络后会得到 N 个分类输出和 N 个 RUL 预测输出,即 $\{y_j^{tk}\}_{k=1}^N$ 和 $\{r_j^{tk}\}_{k=1}^N$,因此需要综合每一个输出的信息。由于依赖于先验知识的综合方式会提升模型的复杂性,本文在损失中加入分类器自适应损失 L_{disc} 来解决上述问题,它可以

自适应的减少 N 个分类器的输出差异,具体定义为:

$$L_{disc} = \frac{2}{N \times (N - 1)} \sum_{k_1=1}^{N-1} \sum_{k_2=k_1+1}^N [| C_{k_1}(H_{k_1}F(x'_i)) - C_{k_2}(H_{k_2}F(x'_j)) |] \quad (5)$$

加入式(5)后可以保证所有特定域的分类网络输出基本一致,使用 $\{y_j^{tk}\}_{k=1}^N$ 和 $\{r_j^{tk}\}_{k=1}^N$ 的平均值 $y_{aver_j}^t = \frac{1}{N} \sum_{k=1}^N y_j^{tk}$ 和 $r_{aver_j}^t = \frac{1}{N} \sum_{k=1}^N r_j^{tk}$ 来代表对目标域样本 x'_j 最终的分类结果和 RUL 预测结果。综上,MS_SAN 通过将多个源域与目标域进行域自适应,充分利用多个源域的信息,实现多源域轴承寿命预测。

2.2 子域自适应

由于滚动轴承不同退化阶段的特征存在差异,基于 MMD 的特征迁移方法忽略了领域对齐的粒度问题^[16]。为了进一步提高轴承寿命预测精度,本文引入局部最大均值差异(local maximum mean discrepancy, LMMD)将每个源域与目标域的退化阶段在独立的特征空间进行对齐,缩小每个退化阶段之间的分布差异。

与 MMD 类似, LMMD 也表征数据在映射空间中的分布差异,但不同的是 LMMD 只考虑源域和目标域上相同子领域间的分布差异。LMMD 定义如下:

$$d_H(p, q) \triangleq E_c \| E_{p^{(c)}}[\phi(x^s)] - E_{q^{(c)}}[\phi(x^t)] \|_H^2 \quad (6)$$

其中, $\| \cdot \|_H$ 是再生核希尔伯特空间, x^s 和 x^t 是 D_s 和 D_t 中的样本, $p^{(c)}$ 和 $q^{(c)}$ 是 $D_s^{(c)}$ 和 $D_t^{(c)}$ 的分布。通过最小化式(6)来拉近源域与目标域上同一子类的数据的分布。

将式(6)无偏估计公式化为式(7):

$$\hat{d}_H(p, q) = \frac{1}{C} \sum_{c=1}^C \left\| \sum_{x_i \in D_s^c} w_i^{sc} \phi(x_i^s) - \sum_{x_j \in D_t^c} w_j^{tc} \phi(x_j^t) \right\|_H^2 \quad (7)$$

其中, $\hat{d}_H(p, q)$ 是 $d_H(p, q)$ 的无偏估计, w_i^{sc} 和 w_j^{tc} 表示样本 x_i^s 和 x_j^t 属于 c 类的权重,且 $\sum_{i=1}^{n_s} w_i^{sc}$ 和 $\sum_{j=1}^{n_t} w_j^{tc}$ 都等于 1,样本 x_i 对应 w_i^c 定义为:

$$w_i^c = \frac{y_{ic}}{\sum_{(x_j, y_j) \in D} y_{jc}} \quad (8)$$

其中, y_{ic} 为向量 y_i 的第 c 个元素。

在 MS_SAN 中,采用 LMMD 来计算源域和目标域之间的分布差异。假设源域 k 上输入的样本为 x_i^{sk} ,目标域输入的样本为 x'_j ,它们经过 H_k 的输出分别为 $z_i^{sk} = H_k(F(x_i^{sk}))$ 和 $z_j^{tk} = H_k(F(x'_j))$,结合目标域分类平均值 $y_{aver_j}^t$,展开式(7),将代表源域与目标域之间分布差异的 LMMD 损失记为:

$$L_{LMMD} = \frac{1}{NC} \sum_{k=1}^N \sum_{c=1}^C \left[\sum_{i=1}^{n_s^k} \sum_{j=1}^{n_t^k} w_i^{sk} w_j^{tk} k(z_i^{sk}, z_j^{tk}) + \sum_{i=1}^{n_s^k} \sum_{j=1}^{n_t^k} w_i^{tc} w_j^{tk} k(z_i^{tk}, z_j^{tk}) - 2 \sum_{i=1}^{n_s^k} \sum_{j=1}^{n_t^k} w_i^{sk} w_j^{tc} k(z_i^{sk}, z_j^{tk}) \right] \quad (9)$$

其中, w_i^{sk} 使用源域真实退化阶段分类标签来计算,由于目标域无标签,使用 $y_{aver_j}^t$ 来代替,计算方法如式(8)所示。

2.3 优化目标

对于 N 个源域上的所有样本 $\{X_k\}_{k=1}^N$,其中 $X_k = \{x_i^{sk}\}_{i=1}^{n_s^k}$,将分类损失 L_{cls} 和 RUL 预测损失 L_{RUL} 定义为:

$$L_{cls} = \sum_{k=1}^N \sum_{i=1}^{n_s^k} J(C_k(H_k(F(x_i^{sk}))), \bar{y}_i^{sk}) \quad (10)$$

$$L_{RUL} = \sum_{k=1}^N \sum_{i=1}^{n_s^k} L_R(P_k(H_k(F(x_i^{sk}))), \bar{r}_i^{sk}) \quad (11)$$

其中, \bar{y}_i^{sk} 和 \bar{r}_i^{sk} 是真实标签, $J(\cdot, \cdot)$ 是交叉熵损失函数, $L_R(\cdot, \cdot)$ 为 MSE 损失函数。设全局损失为 L_{total} ,结合式(8)、(9),将 L_{total} 定义为:

$$L_{total} = \alpha L_{LMMD} + \beta L_{disc} + L_{cls} + L_{RUL} \quad (12)$$

其中, α 和 β 为动态损失系数,用来在不同训练阶段动态调整优化对象。

模型各部分参数为 $\theta_F, \theta_H, \theta_C, \theta_P$,总优化目标为:

$$L_{total}(\theta_F, \theta_H, \theta_C, \theta_P) = \alpha L_{LMMD}(\theta_F, \theta_H, \theta_C) + \beta L_{disc}(\theta_F, \theta_H, \theta_C) + \min_{\theta_F, \theta_H, \theta_C} L_{cls}(\theta_F, \theta_H, \theta_C) + \min_{\theta_F, \theta_H, \theta_P} L_{RUL}(\theta_F, \theta_H, \theta_P) \quad (13)$$

使用随机梯度下降算法对各模块参数 θ 进行更新,参数 θ 更新如下:

$$\theta \leftarrow \theta - \eta \left(\alpha \frac{\partial L_{LMMD}}{\partial \theta} + \beta \frac{\partial L_{disc}}{\partial \theta} + \frac{\partial L_{LMMD}}{\partial \theta} + \frac{\partial L_{LMMD}}{\partial \theta} \right) \quad (14)$$

其中, η 为模型的学习率。

3 基于多域多阶段轴承寿命预测的流程

如图 2 所示,基于 MS_SAN 的轴承剩余寿命预测方法分为 3 个步骤:数据预处理与数据集构建,MS_SAN 网络模型的建立与训练、测试集数据寿命预测验证。

1) 数据采集及信号预处理,采集不同工况下轴承的振动信号,将轴承振动信号在一段采样时间内的时域数据进行快速傅里叶变换得到频域数据。将数据依照工况划分为不同源域和目标域以及训练集和测试集;

2) 网络模型的建立与训练,搭建 MS_SAN 网络,使用多个工况下的训练集进行模型训练,对模型参数进行调整以及可视化分析;

3) 测试集数据验证,MS_SAN 网络模型训练完成

后,使用测试集进行验证,并计算各项误差指标,证明模型的有效性。

4 实验验证

4.1 实验数据集介绍

本文所用的实验数据为 IEEE 2012 年的 PHM 数据挑战赛提供的数据集,该数据集由 PRONOSTIA 试验台

获取,数据采集平台如图 3 所示。在轴承箱上一共安装了两个加速度计,以用来测量垂直和水平方向的振动。数据采样间隔 10 s,采样频率为 25.6 kHz,持续时间为 0.1 s,即每隔 10 s 采集 2 560 个数据点。当轴承振动信号的振幅超过 20 g 时认为轴承失效,实验停止。实验一共设置了 3 种工况,各工况下负载和转速如表 1 所示。为了验证本文方法的有效性,共采用 3 个领域自适应任务来评估模型的性能,数据集的划分如表 2 所示。

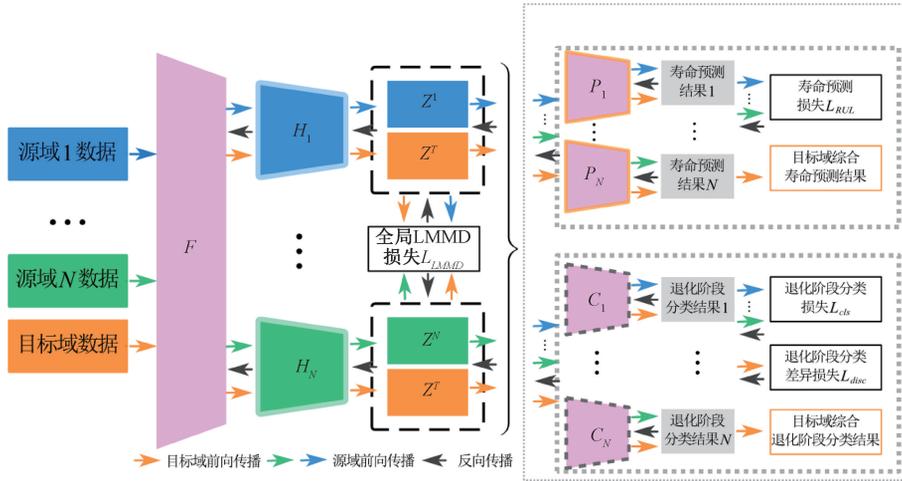


图 1 MS_SAN 网络结构

Fig. 1 The network structure of MS_SAN

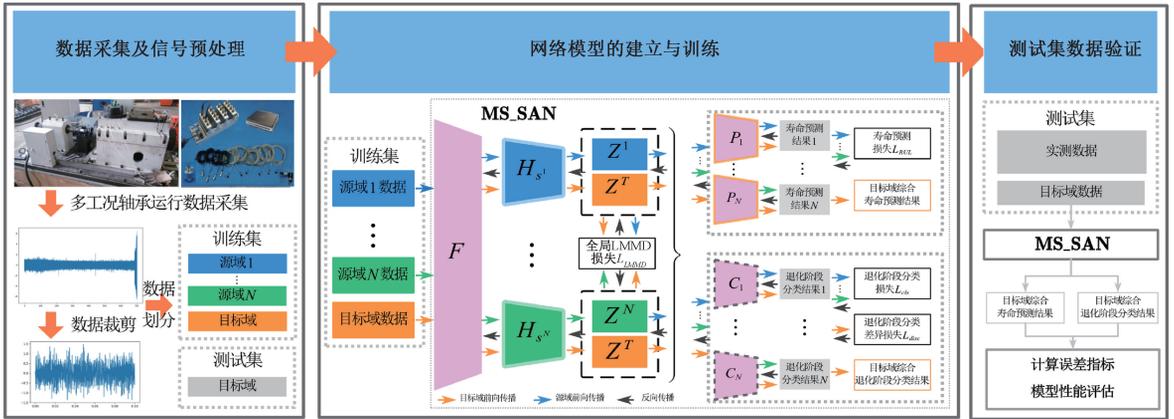


图 2 本文提出方法的总体流程

Fig. 2 The overall flow of the proposed method

表 1 实验数据说明

Table 1 Description of the experiment data

变量	工况 1	工况 2	工况 3
转速/(r · min ⁻¹)	1 800	1 650	1 500
压力/N	4 000	4 200	5 000

表 2 数据集划分

Table 2 Partition of the dataset

领域自适应任务	训练集源域	训练集目标域	测试集
工况 1、3 → 工况 2	工况 1、3 所有轴承	轴承 2_1、2_2	轴承 2_4
工况 1、3 → 工况 2	工况 1、3 所有轴承	轴承 2_1、2_2	轴承 2_6
工况 1、2 → 工况 3	工况 1、2 所有轴承	轴承 3_1、3_2	轴承 3_3

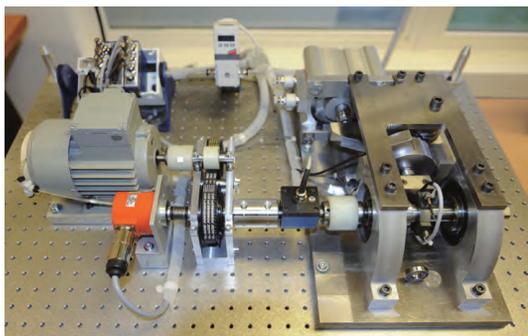


图 3 轴承测试台

Fig. 3 The bearing test bench

4.2 数据预处理

本文对 3 种工况下轴承的水平方向振动时域信号进行快速傅里叶变换、归一化处理获得信号频谱。以提取轴承 1_1 的频域特征为例,轴承 1_1 的全寿命时域信号如图 4 所示,实验开始时 0.1 s 内采集的振动数据及相应的频域信号如图 5 所示。以实际剩余寿命作为训练的标签,以 1 代表轴承完好,以 0 代表轴承达到失效状态。由于轴承从开始运行到完全损坏可以认为是一个持续的过程,因此本文提出的方法将轴承运行的起始点作为退化点。同时,由于轴承不同退化阶段的特征存在差异,本文将轴承全生命周期划分为 10 个阶段。

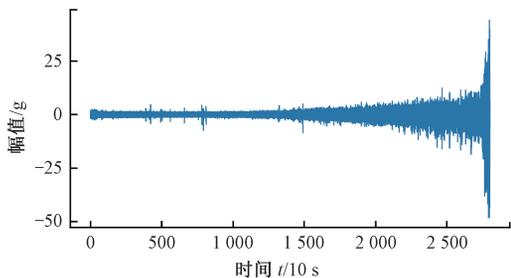
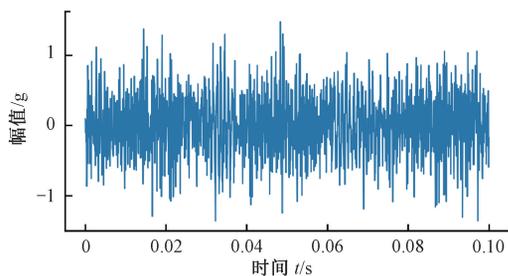


图 4 轴承 1_1 时域波形

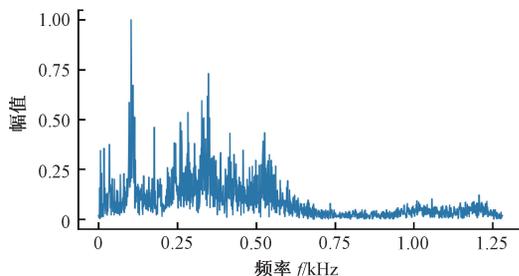
Fig. 4 The time domain waveform of the bearing1_1

4.3 模型参数设置

MS_SAN 各模块参数设置如表 3、4 所示,特征提取器 F 主要采用 2 个一维卷积层和 2 个最大池化层,特定域模块均采用全连接层。为了提高模型稳定性,对模型的训练分两个阶段进行:在训练初期分类器识别准确率不高,如果将被错误分类的目标域数据进行子域自适应会影响网络的收敛速度和准确率,因而在前 400 次训练将网络损失权重系数 α 与 β 设置为 0,用带标签的源域数据训练网络,使用 Adam 优化器对网络进行更新,学习率为 0.001,训练批次大小为 500。完成前 400 次训练后设置网络损失权重系数 α 与 β 分别为 1 和 0.1,其余的参数不变。为避免随机初始化对实验结果的波动,在每一组



(a) 时域振动信号
(a) The time domain vibration signal



(b) 归一化后的频域信号
(b) The normalized frequency domain signal

图 5 轴承 1_1 的时域及频域特征

Fig. 5 The time domain and frequency domain waveform of a sample of the bearing 1_1

实验中采用 3 个不同的随机数种子,将 3 次实验结果的平均值作为实验的结果。

表 3 特征提取器 F 结构及参数

Table 3 Structure and parameters of feature extractor F

描述	参数
卷积层 1	卷积核尺寸 3
	数量 64
卷积层 2	卷积核尺寸 3
	数量 64
池化层 1	核大小 2
池化层 2	核大小 2

表 4 特定域模块结构及参数

Table 4 Structure and parameters of the domain-specific module

描述	参数
全连接层 H1	神经元数量 64
全连接层 H2	神经元数量 64
全连接层 P1	神经元数量 10
全连接层 P2	神经元数量 1
全连接层 C	神经元数量 10

4.4 实验结果与对比分析

为验证本文所提方法对于轴承寿命预测的有效性,将 MS_SAN 与单源域领域适应 (single-source domain adaption network, SS_DAN)、单源域子域自适应方法

(single-source subdomain adaption network, SS_SAN)、多源域领域适应方法 (multi-source domain adaption network, MS_DAN) 进行对比分析。其中, SS_DAN 利用单一源域数据, 采用 MMD 距离进行领域自适应; SS_SAN 利用单一源域数据, 采用 LMMD 距离进行领域自适应, 不同领域适应任务使用的源域数据如表 5 所示。MS_DAN 利用多源域数据, 采用 MMD 作为域分布差异损失, 以上模型参数和本文提出的 MS_SAN 相同。

表 5 SS_DAN 和 SS_SAN 方法的数据集

Table 5 The dataset of SS_DAN and SS_SAN

领域适应任务	训练集源域	训练集目标域	测试集
工况 1 → 工况 2	工况 1 所有轴承	轴承 2_1、2_2	轴承 2_4
工况 1 → 工况 2	工况 1 所有轴承	轴承 2_1、2_2	轴承 2_6
工况 1 → 工况 3	工况 1 所有轴承	轴承 3_1、3_2	轴承 3_3

将预处理好的测试数据集输入不同寿命预测模型进行轴承 RUL 预测, 轴承 2_4、轴承 2_6 和轴承 3_3 在不同方法下寿命预测结果分别如图 6(a)、(b)、(c) 所示。从图中可以看出, 通过多源域子域自适应后, 轴承剩余寿命更加接近轴承真实寿命, 所提出的方法对于进行不同工况下轴承的 RUL 更加有效。

为了定量分析本文提出 MS_SAN 方法的有效执行, 本文采用绝对误差 (mean absolute error, MAE)、均方根误差 (root mean squared error, RMSE) 衡量 3 组实验的 RUL 预测结果。MAE 和 RMSE 的计算公式如式 (15)、(16) 所示。为避免随机初始化对实验结果的影响, 重复每组实验 3 次, 取平均值作为实验结果。不同方法对比分析结果如表 6 所示。

$$MAE = \frac{1}{N} \sum_{i=1}^N |\hat{y}_i - y_i| \quad (15)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2} \quad (16)$$

表 6 不同方法下轴承 RUL 预测误差对比

Table 6 Prediction error of bearing RUL by different methods

测试轴承	指标	SS_DAN	SS_SAN	MS_DAN	MS_SAN
轴承 2_4	MAE	0.161	0.149	0.128	0.113
	RMSE	0.188	0.173	0.152	0.136
轴承 2_6	MAE	0.178	0.166	0.135	0.093
	RMSE	0.208	0.189	0.155	0.112
轴承 3_3	MAE	0.180	0.115	0.136	0.079
	RMSE	0.208	0.136	0.162	0.095

由表 6 可知, 当采用 SS_DAN 方法时, MAE 和 RMSE

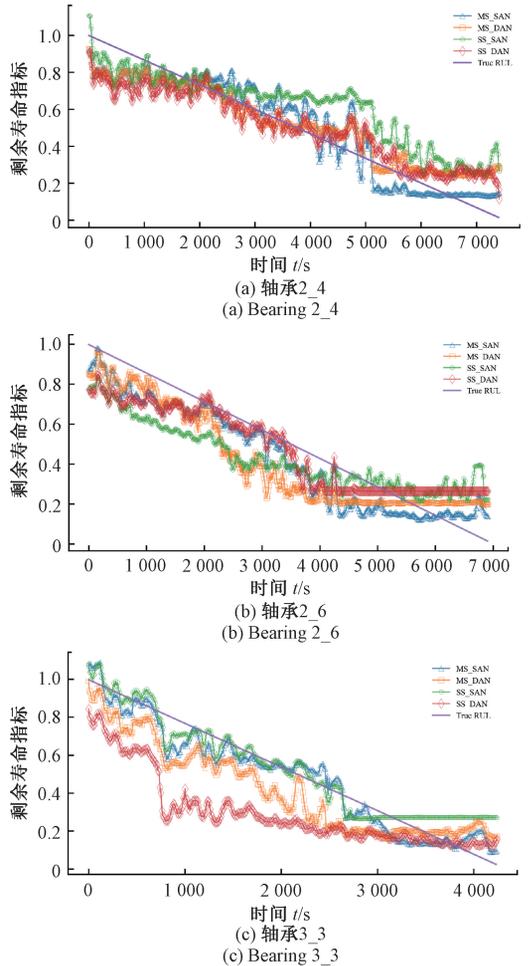


图 6 不同方法的轴承寿命预测结果对比

Fig. 6 The RUL result of different method

的预测误差都是最大的。SS_DAN 方法虽然通过 MMD 距离拉近了不同工况下轴承退化特征的分布, 但是 DAN 方法仅采用单一源域数据, 信息有限, 同时 MMD 距离仅仅只考虑了整体分布, 对齐粒度不足, 寿命预测精度有待进一步提高。相比于 SS_DAN 方法, 采用 SS_SAN 方法时轴承 MAE 和 RMSE 的平均误差降低了 0.030 和 0.035, 主要原因是 SS_SAN 方法采用 LMMD 进行子域自适应, 将轴承退化划分为多个阶段, 根据不同阶段进行自适应, 提高了特征粒度, 提高了寿命预测精度。对比单一源域 SS_DAN 方法, MS_DAN 能够从多个源域提取轴承退化的特征, 在一定程度上提高模型的预测精度, 但采用 MMD 进行整体退化特征自适应, 其效果差于 SS_SAN 方法。MS_SAN 在两种不同工况下的 MAE 和 RMSE 的预测误差都是最小的, 表明本文方法特征提取器能够有效地捕捉轴承信号中的退化特征。其主要原因是 MS_SAN 同时解决了单源域数据不足和自适应粒度不足两个方面的问题, 表中结果可见本文模型在两个预测任务中都优于其余模型, 证明了本文提出方法的有效性。

5 结 论

本文针对单一源域信息有限、域自适应粒度不足导致滚动轴承 RUL 预测精度低的问题,提出了 MS_SAN 的轴承 RUL 预测方法。MS_SAN 在融合了多个源域数据中退化特征基础上,进一步使用 LMMD 以减小不同工况数据之间的距离,提升了退化特征自适应的粒度。通过对不同轴承 RUL 寿命预测对比实验证明,MS_SAN 方法其他模型相比,在两种不同工况下本文提出方法预测结果上更贴近实际寿命曲线,拟合程度高,MAE 和 RMSE 的预测误差都是最小,表明本文模型在两个领域自适应任务中都优于其余模型,证明了本文提出方法的有效性,为旋转机械中的滚动轴承剩余寿命预测提供一种新思路。

参考文献

- [1] 王久健,杨绍普,刘永强,等. 一种基于空间卷积长短时记忆神经网络的轴承剩余寿命预测方法[J]. 机械工程学报, 2021, 57(21): 88-95.
WANG Y J, YANG SH P, LIU Y Q, et al. A method of bearing remaining useful life estimation based on convolutional long short-term memory neural network[J]. Journal of Mechanical Engineering, 2021, 57 (21): 88-95.
- [2] 冯兆熙,邱度金,孔令驹,等. 基于深度置信网络的轴承剩余使用寿命预测[J]. 电子测量与仪器学报, 2021, 35(10): 124-129.
FENG ZH X, QIU D J, KONG L J, et al. Remaining useful life prediction of bearing based on deep belief network[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(10): 124-129.
- [3] 康守强,邢颖怡,王玉静,等. 基于无监督深度模型迁移的滚动轴承寿命预测方法[J/OL]. 自动化学报, 2021;1-11[2022-05-19].
KANG SH Q, XING Y Y, WANG Y J, et al. Rolling bearing life prediction based on unsupervised deep model transfer[J/OL]. Acta Automatica Sinica, 2021; 1-11 [2022-05-19].
- [4] 周哲韬,刘路,宋晓,等. 基于 Transformer 模型的滚动轴承剩余使用寿命预测方法[J/OL]. 北京航空航天大学学报;2021;1-17[2022-05-19].
ZHOU ZH T, LIU L, SONG X, et al. Remaining useful life prediction method of rolling bearing based on Transformer model[J/OL]. Journal of Beijing University of Aeronautics and Astronautics, 2021;1-17[2022-05-19].
- [5] 王玉静,李少鹏,康守强,等. 结合 CNN 和 LSTM 的滚动轴承剩余使用寿命预测方法[J]. 振动. 测试与诊断, 2021, 41(3): 439-446, 617.
WANG Y J, LI SH P, KANG SH Q, et al. Method of predicting remain useful life of rolling bearings combining CNN and LSTM[J]. Journal of Vibration, Measurement & Diagnosis, 2021, 41(3): 439-446, 617.
- [6] DING N, LI H, YIN Z, et al. Journal bearing seizure degradation assessment and remaining useful life prediction based on long short-term memory neural network[J]. Measurement, 2020, 166: 108215.
- [7] CHEN D, QIN Y, WANG Y, et al. Health indicator construction by quadratic function-based deep convolutional auto-encoder and its application into bearing RUL prediction[J]. ISA Transactions, 2021, 114:44-56.
- [8] ZHU J, CHEN N, SHEN C. 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.
- [9] CHENG H, KONG X, CHEN G, et al. Transferable convolutional neural network based remaining useful life prediction of bearing under multiple failure behaviors[J]. Measurement, 2021, 168: 108286.
- [10] DING N, LI H, YIN Z, et al. A novel method for journal bearing degradation evaluation and remaining useful life prediction under different working conditions [J]. Measurement, 2021, 177: 109273.
- [11] DING Y, JIA M, MIAO Q, et al. Remaining useful life estimation using deep metric transfer learning for kernel regression[J]. Reliability Engineering & System Safety, 2021, 212: 107583.
- [12] 陈保家,陈学力,肖文荣,等. 小样本下滚动轴承故障的多源域迁移诊断方法[J]. 电子测量与仪器学报, 2022, 254(2): 219-228.
CHEN B J, CHEN X L, XIAO W R, et al. Multi-source domain transfer diagnosis method for rolling bearing faults under small samples [J]. Journal of Electronic Measurement and Instrumentation, 2022, 254 (2): 219-228.
- [13] 雷亚国,杨彬,杜兆钧,等. 大数据下机械装备故障的深度迁移诊断方法[J]. 机械工程学报, 2019, 55(7): 1-8.
LEI Y G, YANG B, DU ZH J, et al. Deep transfer diagnosis method for machinery in big data era [J]. Journal of Mechanical Engineering, 2019, 55(7): 1-8.
- [14] CAO Y, JIA M, DING P, et al. Transfer learning for remaining useful life prediction of multi-conditions bearings based on bidirectional-GRU network [J].

Measurement, 2021, 178: 109287.

- [15] YANG S, KONG X, WANG Q, et al. A multi-source ensemble domain adaptation method for rotary machine fault diagnosis[J]. Measurement, 2021, 186: 110213.
- [16] 董绍江, 朱朋, 裴雪武, 等. 基于子领域自适应的变工况下滚动轴承故障诊断[J]. 吉林大学学报(工学版), 2022, 52(2): 288-295.
- DONG SH J, ZHU P, PEI X W, et al. Fault diagnosis of rolling bearing under variable operating conditions based on subdomain adaptation [J]. Journal of Jilin University (Engineering and Technology Edition), 2022, 52(2): 288-295.

作者简介



黄庆卿, 2009 年于重庆大学获得学士学位, 2015 年于重庆大学获得博士学位, 现为重庆邮电大学副教授, 主要研究方向为工业物联网、边缘计算、机械故障预测与健康

管理。
E-mail: huangqq@cqupt.edu.cn

Huang Qingqing received the B. Sc. degree in 2009 and the Ph. D. degree in 2015 from Chongqing University. He is currently an associate professor at Chongqing University of Posts and Telecommunications. His main research interests include industrial internet of things, edge computing, and prognostics and health management of machine.



韩延(通信作者), 2012 年于重庆大学获得学士学位, 2015 年于重庆大学获得硕士学位, 2020 年于重庆大学获得博士学位, 现为重庆邮电大学讲师, 主要研究方向为装备智能运维、深度学习、边缘计算等。

E-mail: hanyan@cqupt.edu.cn

Han Yan (Corresponding author) received the B. Sc. degree, M. Sc. degree and Ph. D. degree from Chongqing University in 2012, 2015 and 2020, respectively. He is currently a lecturer at Chongqing University of Posts and Telecommunications. His main research interests include equipment intelligent operation and maintenance, deep learning and edge computing.