

DOI: 10.19650/j.cnki.cjsi.J2312306

# 基于子空间域对抗判别网络的不同型号 滚动轴承剩余寿命预测\*

陈仁祥<sup>1</sup>, 张雁峰<sup>1</sup>, 徐向阳<sup>1</sup>, 张鹏博<sup>1</sup>, 杨宝军<sup>2</sup>

(1. 重庆交通大学交通工程应用机器人重庆市工程试验室 重庆 400074; 2. 重庆智能机器人研究院 重庆 400714)

**摘要:**针对不同型号滚动轴承因结构尺寸、运行工况等差异导致轴承退化数据分布和特征尺度不一致,引起剩余寿命预测精度下降的问题,提出基于子空间域对抗判别网络的不同型号滚动轴承剩余寿命预测方法。首先,通过高效通道注意力机制提升特征提取器各通道中重要特征的权重,自适应获取不同型号滚动轴承的深层性能退化特征,并以此预训练标签预测器;然后,在对抗判别网络框架上将域判别器与特征提取器对抗训练,最小化源域和目标域在表征子空间上的正交基距离,利用表征子空间正交基不受特征缩放影响的性质克服特征尺度变化过大引起的回归性能下降问题,实现不同型号滚动轴承间的域自适应;最后,利用训练好的特征提取器提取待预测轴承退化特征,输入标签预测器得到剩余寿命。在 PRONOSTIA、XJTU-SY 和自测数据集上进行了验证,实验结果表明所提方法能充分学习源域特征分布信息,有效克服不同型号下的特征尺度差异,相比其他域自适应方法效果提升 20% 至 40%。

**关键词:** 滚动轴承; 剩余寿命预测; 对抗判别域自适应; 时间卷积网络

**中图分类号:** TH165+.3 TP18 **文献标识码:** A **国家标准学科分类代码:** 510.40

## Remaining life prediction of different types of rolling bearings based on subspace domain adversarial discrimination network

Chen Renxiang<sup>1</sup>, Zhang Yanfeng<sup>1</sup>, Xu Xiangyang<sup>1</sup>, Zhang Pengbo<sup>1</sup>, Yang Baojun<sup>2</sup>

(1. Chongqing Engineering Laboratory for Transportation Engineering Application Robot, Chongqing Jiaotong University, Chongqing 400074, China; 2. Chongqing Robotics Institute, Chongqing 400714, China)

**Abstract:** A residual life prediction method for different types of rolling bearings is proposed based on the subspace domain adversarial discriminant network (SDADN) to address the issue of inconsistent distribution and characteristic scales of bearing degradation data caused by differences in structural dimensions, operating conditions, and other factors, leading to a decrease in life prediction accuracy. Firstly, the feature extractor can adaptively obtain deep degradation features for different types of rolling bearings by using an efficient channel attention mechanism to enhance the weight of important features in each channel and is used to train the label predictor. Then, in the asymmetric feature mapping framework, the domain discriminator and feature extractor are adversarially trained to minimize the orthogonal basis distance between the source and target domains in the representation subspace. By utilizing the property that the orthogonal basis in the representation subspace is not affected by feature scaling, the regression performance degradation caused by excessive feature scale changes is reduced, and domain adaptation among different types of rolling bearings is achieved. Finally, the trained feature extractor is used to extract the degradation features of the bearing, and the remaining lifespan is obtained by inputting them into the label predictor. The proposed method was validated on PRONOSTIA, XJTU-SY, and self-test datasets, and the experimental results showed that it can fully learn the distribution information of source domain features, effectively overcome the feature scale differences under different models, and improve the performance by 20% to 40% compared to other domain adaptive methods.

**Keywords:** rolling bearings; remaining useful life prediction; adversarial discriminative domain adaptation; time convolutional network

收稿日期: 2023-12-23 Received Date: 2023-12-23

\* 基金项目: 国家自然科学基金项目(51975079)、重庆市教委科学技术研究项目(KJZD-M202200701)、重庆市自然科学基金创新发展联合基金(CSTB2023NSCQ-LZX0127)、重庆市研究生联合培养基地项目(JDLHPYJD2021007)、重庆市专业学位研究生教学案例库(JDALK2022007)、重庆交通大学研究生科研创新项目(2023S0123)资助

## 0 引言

滚动轴承广泛应用于航空航天、汽车、工业制造等领域,其在负载、温度、磨损等综合因素作用下发生不同程度的性能退化甚至失效,对机械设备和操作人员安全产生威胁,在其发生失效之前预测其剩余寿命(remaining useful life, RUL)具有重大应用价值<sup>[1]</sup>。

在轴承剩余寿命预测领域已提出大量预测模型,但在实际工程中,同工况和型号的轴承参考数据样本少,传统预测模型更多关注同型号轴承,在工程应用中受到局限。迁移学习通过挖掘不同数据领域间的相似性关系,将源域学习到的知识应用于目标域,可提高跨域泛化能力<sup>[2]</sup>。近年来,深度迁移学习方法被逐渐应用于寿命预测领域。王新刚等<sup>[3]</sup>在 CNN-LSTM 上通过全局和局部域结合的方式降低不同工况下轴承数据的分布差异;Hu 等<sup>[4]</sup>通过自编码器自适应地分离域特定特征和域不变特征;Dong 等<sup>[5]</sup>通过最大平均差异(maximum mean difference, MMD)优化不同工况下源域和目标域的退化分布差异。可见迁移学习预测模型能克服不同工况数据分布和样本数量上的差异。在不同型号轴承剩余寿命预测任务中,受负载、转速、环境噪声、结构尺寸等因素的影响,其特征分布和特征尺度差异相对于不同工况时更大,可利用的公共特征更少,导致上述方法在不同型号和复杂工况下的预测准确性还有待提高。

对抗判别域自适应(adversarial discriminative domain adaptation, ADDA)<sup>[6]</sup>的源域与目标域网络使用独立参数权值,可学习更多域私有特征,有利于解决型号不同导致可利用特征较少的问题。但 ADDA 采用二分类标签作为判别结果,在域间特征尺度差异较大时无法准确表示域间距离,导致预测结果偏离真实值。因此在判别器中引入表征子空间距离损失衡量域间差异<sup>[7]</sup>,同时利用表征子空间距离不受特征尺度影响的特性,提高不同型号轴承的域自适应回归性能。

基于上述分析,提出基于子空间域对抗判别网络(subspace domain adversarial discriminant network, SDADN)的不同型号滚动轴承剩余寿命预测方法。首先,通过高效通道注意力机制(efficient channel attention, ECA)自适应提高不同数据集下获取的退化特征信息质量,并依此预训练标签预测器;其次,在非对称映射域自适应框架基础上,用表征子空间距离(representation subspace distance, RSD)和碱基错配惩罚(bases mismatch penalization, BMP)作为域判别器损失函数,最小化源域和目标域在表征子空间上的正交基距离,避免不同轴承特征尺度变化引起的域自适应回归精度下降。将域判别器与目标域特征提取器进行对抗训练,实现目标域特征

分布向源域特征分布适配;最后,用训练后的特征提取器获取待预测轴承特征,输入标签预测器中得到轴承剩余寿命,通过实验验证了方法的有效性和可行性。

## 1 特征提取器

为使网络能够充分学习每个域的总体特征分布,需将多个轴承数据作为源域同时输入网络以获取融合退化特征。由于不同轴承数据集寿命和采样参数有差异,每个轴承数据样本的长度并不统一,增大了将多个轴承同时作为训练数据输入的难度。时间卷积网络(temporal convolutional networks, TCN)<sup>[8]</sup>可并行处理任意长度的序列,并能通过因果膨胀卷积层改变感受野的大小,易于适应不同领域。TCN 通过残差结构避免了网络深度增加引起的梯度爆炸,其输入  $X$  和输出  $Y$  关系如下:

$$Y = \text{Activation}(X + F(X)) \quad (1)$$

式中:  $\text{Activation}$  为激活函数。选用 ELU 为激活函数代替 ReLU 函数,其函数表示如下:

$$f(x) = \begin{cases} x, & x \geq 0 \\ \alpha(e^x - 1), & x < 0 \end{cases} \quad (2)$$

式中:  $\alpha$  为超参数,取值为  $-1$ , ELU 激活函数在输入小于零时仍具有较为平滑的梯度,以避免 ReLU 函数处理负值时的梯度消失问题。

为提高 TCN 对不同数据集的特征表达能力,在 TCN 残差连接的卷积操作中嵌入 ECA 机制<sup>[9]</sup>,通过执行卷积核大小为  $k$  的一维卷积来计算每个通道特征图的全局平均值生成特征权重。由于 ECA 不改变输出特征图的大小和维度,因此对通道维度上的特征自适应加权的同时保留了特征尺度信息,  $k$  通过式(3)自适应确定。

$$k = \left\lfloor \frac{\log_2 C + b}{\gamma} \right\rfloor_{\text{odd}} \quad (3)$$

式中:  $C$  表示通道数;  $\text{odd}$  表示  $k$  只能取奇数,  $\gamma$  和  $b$  用于改变通道数核卷积核大小和之间的比例。

依此构建特征提取器,其网络结构如图 1 所示。

## 2 子空间域对抗判别剩余寿命预测网络

### 2.1 域对抗判别网络

ADDA 框架中引入域判别器  $G(d)$  鉴别一个特征来自源域还是目标域,并通过  $G(d)$  的对抗性训练来最小化域间的距离,当  $G(d)$  无法分辨特征提取器输出的特征来自源域还是目标域时,意味着两域特征分布已尽可能接近。在对抗性训练中,最小化特征提取器的损失  $L_{adv_M}$  同时最大化域判别器的损失  $L_{adv_D}$ ,二者满足以下关系:

$$L_{adv_M} = -L_{adv_D} \quad (4)$$

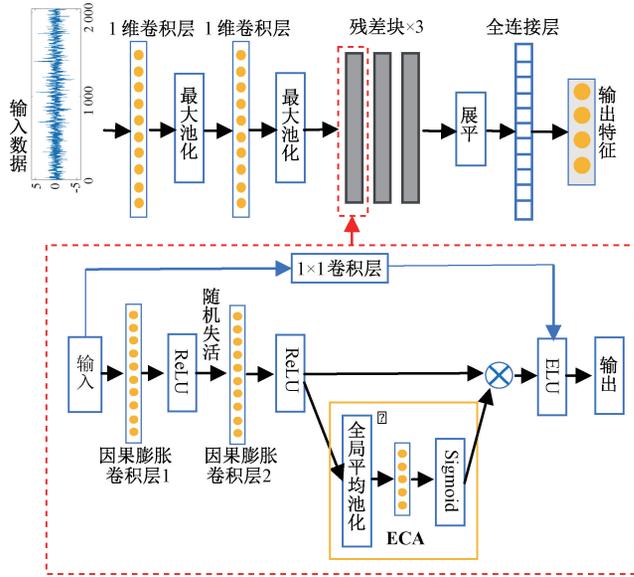


图 1 特征提取器结构

Fig. 1 Feature extractor structure

训练过程中仅更新目标域特征提取器参数,在不改变源域特征分布的情况下进行分布适配,可有效保留源域的特征分布信息。源域和目标域采用域间参数不共享的非对称映射形式,可以学习更多的域私有特征。

### 2.2 表征子空间距离

ADDA 域判别器中的二分类损失只能区分 2 个领域之间边缘分布,在域间特征尺度差异较大时无法准确表示域间距离。由于表征子空间距离的计算基于特征在表征子空间中的相对位置关系,通常不会受到特征尺度的影响,因此可以有效衡量不同型号轴承特征之间的相似程度。在 ADDA 网络的判别器中引入 RSD 构建出子空间域对抗判别网络,降低表征子空间之中标准正交基的全局相似性差异,其函数表示如下:

$$dis_{RSD}^{S^{*T}}(\mathbf{F}_s, \mathbf{F}_t) = \|\sin \Theta^{S^{*T}}\|_1 \quad (5)$$

式中:  $\mathbf{F}_s$  和  $\mathbf{F}_t$  分别为源域和目标域特征,  $b$  为子空间维度,  $\Theta^{S^{*T}}$  为源域和目标域在子空间中标准正交基的主角, RSD 表示源域和目标域在子空间中的距离。为使式(5)在计算 RSD 时匹配相同权重的正交基,让模型可以正确适配私有特征,需在判别器中添加 BMP 损失以正确匹配子空间中正交基顺序,其函数表示如下:

$$(\mathbf{U}_s)^T \mathbf{U}_t = \mathbf{P}_s (\text{diag}(\cos \Theta)) (\mathbf{P}_t)^T \quad (6)$$

$$\text{reg}(\mathbf{F}_s, \mathbf{F}_t) = \|\|\mathbf{P}_s\| - \|\mathbf{P}_t\|\|_F^2 \quad (7)$$

式中:  $\mathbf{U}_s$  和  $\mathbf{U}_t$  分别为源域和目标域子空间的正交基矩阵  $\Theta = \theta_1, \theta_2, \dots, \theta_i, \mathbf{P}_s$  和  $\mathbf{P}_t$  由式(6)获得。

### 2.3 SDADN 模型构建

经过改进后的 SDADN 网络架构如图 2 所示。

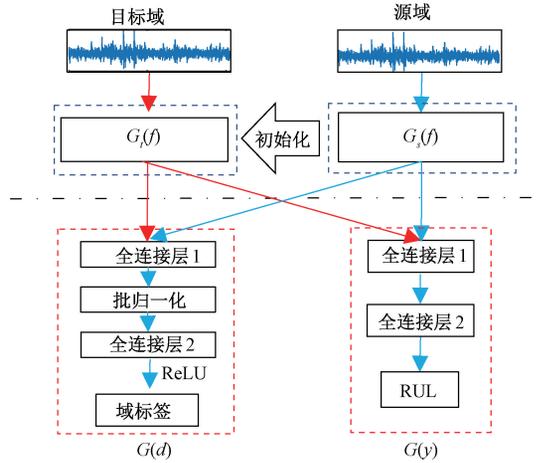


图 2 SDADN 网络结构

Fig. 2 Structure of SDADN

SDADN 网络包括特征提取器  $G_s(f)$  和  $G_t(f)$ 、标签预测器  $G(y)$ 、域判别器  $G(d)$  四部分。源域特征提取器  $G_s(f)$  和目标域特征提取器  $G_t(f)$  均由 ECATCN 构成,二者网络结构相同,用于构建源域与目标域特征的非对称映射关系。标签预测器  $G(y)$  由 2 层全连接层组成,用于生成退化特征的剩余寿命。域判别器  $G(d)$  由 2 层全连接层构成,通过  $G(d)$  与  $G_s(f)$  对抗训练,使目标域能学习到源域的特征分布信息。网络详细的参数见表 1 所示。

表 1 SDADN 参数

Table 1 Parameters for SDADN

模块	层名	网络结构参数
$G(f)$	1 维卷积层	Kernel:13, stride:3, channel:32
	最大池化层	Kernel:5, stride:5
	1 维卷积层	Kernel:9, stride:2, channel:16
	最大池化层	Kernel:2, stride:2
	随机失活	Dropout rate:0.4, channel:16
	ECA 残差块 1	Kernel:12, dilation rate:1, channel:16
	ECA 残差块 2	Kernel:5, dilation rate:2, channel:8
	ECA 残差块 3	Kernel:3, dilation rate:4, channel:4
	全连接层	Channel:300
	$G(y)$	全连接层 1
全连接层 2		Channel:1
$G(d)$	全连接层 1	Channel:200
	全连接层 2	Channel:1

## 3 基于 SDADN 的剩余寿命预测流程

所提方法流程如图 3 所示,具体步骤为:

(1)对数据进行预处理,使用有标签的源域数据预训练源域特征提取器  $G_s(f)$  以及标签预测器  $G(y)$ ,最小化标签预测器在源域轴承数据上的剩余寿命预测损失  $L_y$ :

$$L_y(\theta_f, \theta_y) = \frac{1}{b} \sum_{i=1}^b (Rul_p - Rul_i)^2 \quad (8)$$

式中:  $\theta_f, \theta_y$  分别为  $G(f), G(y)$  的参数,  $Rul_p$  和  $Rul_i$  分别为预测 RUL 和实际 RUL,  $b$  为一批次源域数据的样本个数。

(2)将  $G_s(f)$  和  $G(y)$  的参数固定,  $G_i(f)$  用  $G_s(f)$  的参数初始化后,  $G_i(f)$  与  $G(d)$  进行对抗式的训练,  $G(d)$  会判别输入特征来自源域或目标域,以最小化域判别器在源域和目标域上的域判别损失  $L_d$  为目标优化目标域特征提取器参数,缩小源域和目标域特征分布差异,如下式:

$$L_d(\theta_f, \theta_d) = \sum_{d \in \{s, t\}} E_{x_d \sim X_d} [\beta \| \sin \Theta^{s \rightarrow t} \|_1 + \gamma ( \| |P_s| - |P_t| \|_F^2 )] \quad (9)$$

式中:  $\theta_d$  为  $G(d)$  的参数,  $E_{x_d \sim X_d}$  表示从分布  $X_d$  中采样得到样本  $x_d$  期望。整体目标函数为剩余寿命预测的损失函数  $L_y(\theta_f, \theta_y)$  减去领域判别器损失函数  $L_d(\theta_f, \theta_d)$ , 即:

$$L_{total}(\theta_f, \theta_d, \theta_y) = L_y(\theta_f, \theta_y) - \lambda L_d(\theta_f, \theta_d) \quad (10)$$

(3)网络训练完成后,将测试数据输入  $G_i(f)$ , 通过  $G(y)$  获得轴承的剩余寿命。

在训练过程中,为尽可能混淆源域与目标域特征,需最小化  $G_i(f)$  的  $L_y(\theta_f, \theta_y)$  并最大化  $L_d(\theta_f, \theta_d)$ , 即:

$$\theta_d = \arg_{\theta_d} \max L_{total}(\theta_f, \theta_d, \theta_y) \quad (11)$$

$$(\theta_f, \theta_y) = \arg_{\theta_f, \theta_y} \min L_{total}(\theta_f, \theta_d, \theta_y) \quad (12)$$

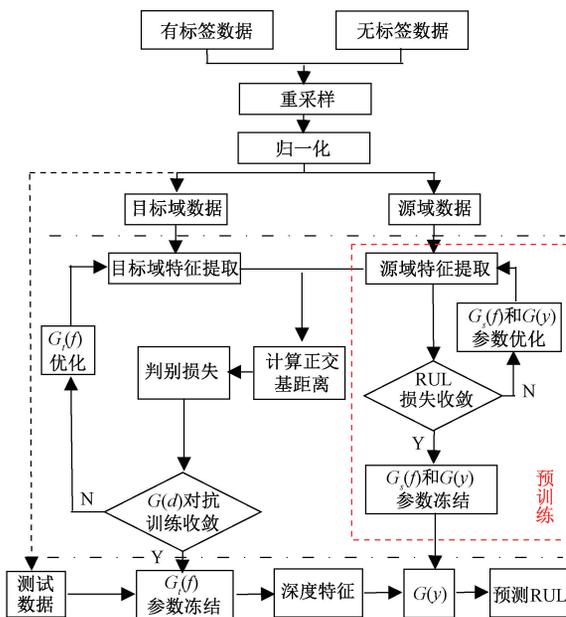


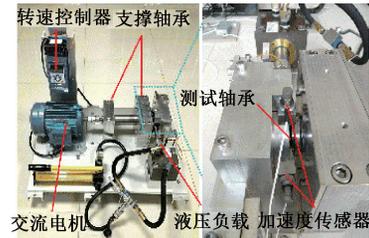
图3 SDADN 预测方法流程图

Fig. 3 Flow chart of SDADN

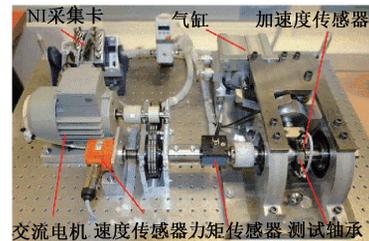
## 4 实验验证与分析

### 4.1 数据处理

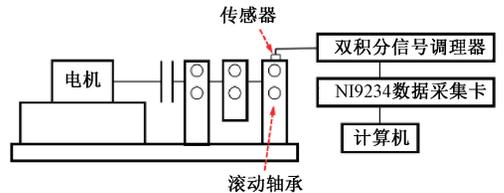
实验数据来自 XJTU-SY 实验台<sup>[10]</sup>与 PRONOSTIA 实验台<sup>[11]</sup>的轴承加速寿命试验公开数据集,以及自测轴承加速全寿命数据集,具体实验台配置和数据集采样参数和工况信息如图4和表2所示。



(a)XJTU-SY实验台  
(a)XJTU-SY test platform



(b) PRONOSTIA实验台  
(b) PRONOSTIA test platform



(c) 自测轴承加速试验台  
(c) Self-test bearing acceleration test platform

图4 滚动轴承试验平台

Fig. 4 Rolling bearing test platform

不同型号轴承全寿命数据序列长度不一,利用所设计特征提取器能处理不同长度序列的优势进行训练,将不同型号全寿命数据序列划分成不同样本数、相同样本点(即序列长度=样本数×样本点)的形式输入网络,网络输入形状为[样本数,通道数,样本长度]。为加快训练速度、提高模型的收敛性,在输入预测模型前通过式(13)将每一维数据归一化至[-1,1]范围内:

$$x'_{i,j} = \frac{x_{i,j} - x_{mean}^j}{x_{max}^j - x_{min}^j}, \quad \forall i, j \quad (13)$$

式中:  $x'_{i,j}$  为  $x_{i,j}$  的归一化值,原始数据  $X = [x_1, x_2, \dots, x_L]$ ,  $X = [x_{i,1}, x_{i,2}, \dots, x_{i,j}]$ ,  $x_{i,j}$  表示第  $i$  个数据点的第  $j$  个传感器数据。

表 2 轴承工况和编号  
Table 2 Bearing conditions and numbers

数据集	轴承编号	负载/kN	转速/rpm	采样时间/s	采样频率/kHz	轴承型号	代号
PRONOSTIA	Bearing1_1~1_7	4	1 800	0.1	25.6	C61804	A
	Bearing2_1~2_7	4.2	1 650				
XJTU-SY	Bearing1_1~1_5	12	2 100	1.28	25.6	LDK UER204	B
	Bearing2_1~2_5	11	2 250				
自测轴承数据	Bearing1_1~1_3	5	1 000	4	25.6	C36018	C
	Bearing2_1~2_3	5	3 000				

4.2 实验设置

分别从 PRONOSTIA 轴承数据集、XJTU-SY 轴承数据集和自测轴承数据集的前两种工况中,取一种工况下所有轴承数据作为源域,取另一数据集一种工况中两个轴承数据作为目标域,一个轴承数据作为验证数据。源域数据包含百分比寿命标签,目标域数据均无寿命标签,训练目标如表 3。

表 3 轴承训练目标

Table 3 Training objectives for bearings

数据来源	训练目标	训练数据(源域 ∨ 目标域)	验证数据
公开轴承数据集	任务 1	A1-1~A1-7 ∨ B1-1, B1-2	B1-3
	任务 2	A1-1~A1-7 ∨ B2-1, B2-2	B2-3
	任务 3	A2-1~A2-7 ∨ B1-1, B1-2	B1-3
	任务 4	A2-1~A2-7 ∨ B2-1, B2-2	B2-3
	任务 5	B1-1~B1-5 ∨ A1-1, A1-2	A1-3
	任务 6	B1-1~B1-5 ∨ A2-1, A2-2	A2-3
	任务 7	B2-1~B2-5 ∨ A1-1, A1-2	A1-3
	任务 8	B2-1~B2-5 ∨ A2-1, A2-2	A2-3
自测轴承数据集	任务 9	A1-1~A1-7 ∨ C1-1, C1-2	C1-3
	任务 10	A1-1~A1-7 ∨ C2-1, C2-2	C2-3
	任务 11	B2-1~B2-5 ∨ C1-1, C1-2	C1-3
	任务 12	B2-1~B2-5 ∨ C2-1, C2-2	C2-3

网络运行软件环境为 Python+Torch, 优化器初始学习率 0.01, 衰减因子 0.5, 衰减间隔步数 30。对比方法的优化器选择 Adam, 初始学习率 0.01, 批量为 200, 其余网络结构与原始网络相同, 每组实验重复验证 5 次取平均值。采用 MMD 作为领域间分布差异的评估指标, 公式如下:

$$MMD = \sup \left( \frac{1}{m} \sum_{i=1}^m f(x_i) - \frac{1}{n} \sum_{i=1}^n f(y_i) \right) \quad (14)$$

式中: sup 表示求最大值,  $f(x_i)$  和  $f(y_i)$  分别表示两个域的样本集合,  $m$  和  $n$  分别表示样本集合的大小。

采用平均绝对误差(mean absolute error, MAE)和均方根误差(root mean square deviation, RMSE)作为预测结果的评估指标, RMSE 和 MAE 的值越小, 说明预测性能越好。计算公式下:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Rul_p - Rul_t)^2} \quad (15)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |Rul_p - Rul_t| \quad (16)$$

4.3 特征提取器性能实验

为验证 SDADN 特征提取器的性能, 在相同域自适应策略下, 将所提特征提取器与嵌入通道注意力(squeeze-and-excitation, SE)的 SETCN、单一的 TCN 与单一的 LSTM 进行对比, 结果如表 4。展示任务 2 的预测曲线如图 5。在样本点 400 之前, 本文方法预测结果比 LSTM 更接近轴承真实寿命, 这是由于因果膨胀卷积层具有更灵活的感受野, 更容易获得轴承早期退化信息的特征。

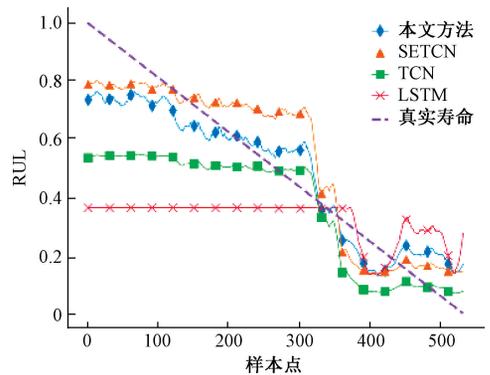


图 5 不同特征提取器性能对比

Fig. 5 Comparison of different feature extractors

结合表 4, 不同数据集预测任务中, SETCN 相比 TCN 的 MAE 和 RMSE 平均提升了 11%, 这是因为 SE 通道注意力能够在通道维度上关注重要的特征信息。本文方法相比 SETCN 的 MAE 和 RMSE 平均提升了 19% 和 14%, 这是因为 ECA 通道注意力使用一维卷积捕获不同通道之间的信息, 避免输入特征图的降维操作对预测产生

表4 与相关方法结果对比

Table 4 Comparison with related methods

方法	指标	任务 1	任务 2	任务 3	任务 4	任务 5	任务 6	任务 7	任务 8	任务 9	任务 10	任务 11	任务 12	平均值
本文方法	MAE	<b>0.07</b>	<b>0.10</b>	<b>0.07</b>	<b>0.09</b>	<b>0.11</b>	<b>0.11</b>	<b>0.08</b>	<b>0.08</b>	<b>0.08</b>	<b>0.11</b>	<b>0.13</b>	<b>0.12</b>	<b>0.09</b>
	RMSE	<b>0.08</b>	<b>0.12</b>	<b>0.08</b>	<b>0.11</b>	<b>0.14</b>	<b>0.14</b>	<b>0.12</b>	<b>0.13</b>	<b>0.10</b>	<b>0.13</b>	<b>0.15</b>	<b>0.14</b>	<b>0.12</b>
SETCN	MAE	0.09	0.11	0.08	0.10	0.14	0.13	0.12	0.14	0.10	0.14	0.14	0.13	0.12
	RMSE	0.10	0.13	0.10	0.12	0.16	0.16	0.14	0.16	0.12	0.16	0.17	0.16	0.14
TCN	MAE	0.11	0.11	0.10	0.09	0.15	0.15	0.16	0.15	0.11	0.15	0.17	0.15	0.13
	RMSE	0.13	0.14	0.12	0.12	0.18	0.17	0.18	0.17	0.14	0.17	0.19	0.17	0.16
LSTM	MAE	0.18	0.15	0.15	0.18	0.20	0.21	0.16	0.22	0.16	0.22	0.23	0.22	0.19
	RMSE	0.21	0.19	0.18	0.22	0.24	0.26	0.21	0.26	0.19	0.25	0.27	0.26	0.23

负面影响。因此本文所提特征提取器在不同型号数据集下能自适应获取较好的全局退化特征,具有较好泛化能力。

#### 4.4 域自适应性能实验

使用 SDADN 进行域自适应学习,将源域与目标域轴承提取到的特征进行适配,以任务 4 为例,域自适应前后剩余寿命预测结果如图 6 所示。由图 6,在使用 SDADN 迁移之前,网络对轴承剩余寿命预测具有较大偏差,在经过域自适应以后,剩余寿命预测精度大幅提高,说明本文方法具有实现了良好的迁移效果。

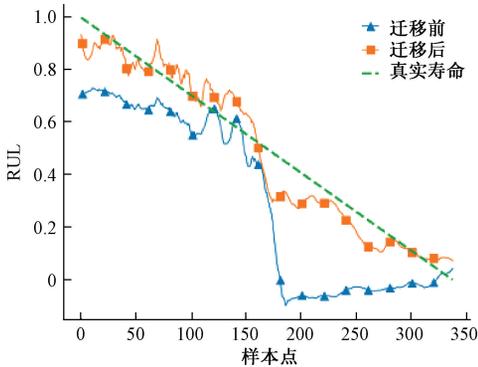


图6 域自适应前后预测对比

Fig. 6 Comparison of prediction before and after domain adaptation

为进一步评估 SDADN 的域自适应性能,在相同特征提取器下,将 RUL 预测结果与采用 DANN、MMD、DSAN<sup>[12]</sup> 的 3 种域自适应方法进行对比,同时计算源域和目标域间的 MMD 以分析两个领域之间的分布差异,任务 4 各方法概率密度图如图 7。在未进行域自适应时,源域与目标域特征分布和特征尺度差异较大,预测误差较大。由于 SDADN 采用非对称映射,只有目标域特征提取器被训练,因此源域的特征分布未发生改变,但目标域的特征分布向源域趋同,目标域学习到源域的特征分布结构信息。

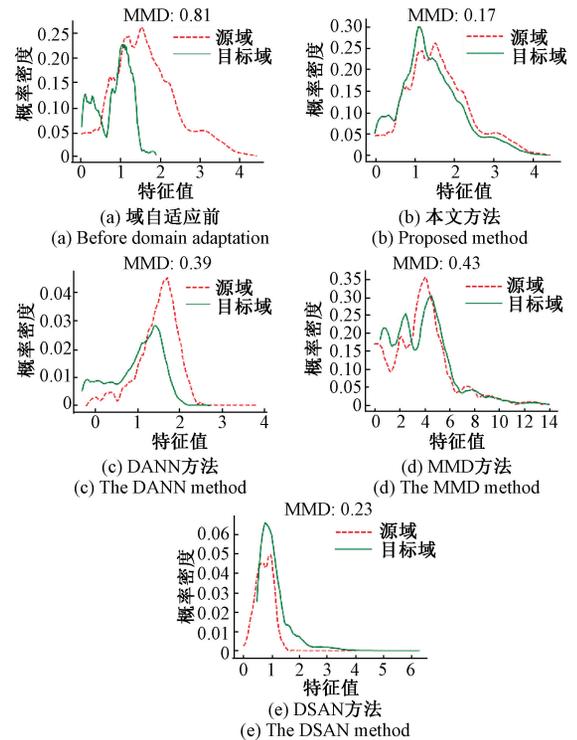


图7 域自适应前后概率密度

Fig. 7 Comparison of Domain Adaptation Before and After

相关域自适应方法预测结果如表 5 所示,可见基于特征距离的 MMD 方法虽然能在一定程度上减小域间分布差异,但在不同数据集这类特征尺度差异较大的数据集下效果依然不佳;由于 SDADN 关注两域之间的私有特征,并且表征子空间域判别器能更精确衡量域间距离,相比二分类域判别器具有更好的回归适用性,因此所提域自适应方法相较其他法具有更低的 MAE 和 RMSE。

#### 4.5 剩余寿命预测对比实验

为进一步验证所提方法对不同型号轴承上的预测性能,与 3 种近年的 RUL 预测方法进行比较,包括基于时

表 5 迁移结果与相关方法对比

Table 5 Comparison with related methods

方法	指标	任务 1	任务 2	任务 3	任务 4	任务 5	任务 6	任务 7	任务 8	任务 9	任务 10	任务 11	任务 12	平均值
本文方法	MAE	<b>0.07</b>	<b>0.10</b>	<b>0.07</b>	<b>0.09</b>	<b>0.11</b>	<b>0.11</b>	<b>0.08</b>	<b>0.08</b>	<b>0.08</b>	<b>0.11</b>	<b>0.13</b>	<b>0.12</b>	<b>0.09</b>
	RMSE	<b>0.08</b>	<b>0.12</b>	<b>0.08</b>	<b>0.11</b>	<b>0.14</b>	<b>0.14</b>	<b>0.12</b>	<b>0.13</b>	<b>0.10</b>	<b>0.13</b>	<b>0.15</b>	<b>0.14</b>	<b>0.12</b>
DANN	MAE	0.10	0.11	0.09	0.11	0.15	0.13	0.10	0.11	0.11	0.12	0.15	0.13	0.12
	RMSE	0.12	0.14	0.11	0.14	0.19	0.16	0.13	0.14	0.13	0.14	0.17	0.16	0.14
MMD	MAE	0.18	0.14	0.16	0.11	0.16	0.13	0.18	0.21	0.15	0.16	0.18	0.16	0.16
	RMSE	0.21	0.17	0.19	0.14	0.22	0.18	0.20	0.24	0.17	0.18	0.20	0.19	0.17
DRSN	MAE	0.16	0.11	0.11	0.09	0.15	0.15	0.16	0.14	0.12	0.13	0.15	0.14	0.13
	RMSE	0.18	0.14	0.15	0.12	0.18	0.17	0.18	0.16	0.14	0.16	0.17	0.16	0.16
无域自适应	MAE	0.32	0.30	0.27	0.27	0.47	0.42	0.29	0.34	0.30	0.37	0.41	0.39	0.34
	RMSE	0.35	0.33	0.30	0.31	0.51	0.46	0.34	0.38	0.33	0.41	0.45	0.44	0.38

间卷积网络的迁移学习方法<sup>[13]</sup>、基于动态对抗适应的迁移学习方法<sup>[14]</sup>、基于改进 ECANet 网络的迁移学习方法<sup>[15]</sup>。任务 7、任务 9 预测效果见图 8,全部任务结果见表 6。

根据图 8 和表 6,所提方法在不同型号轴承数据集之间的预测效果更好,平均预测性能分别提升 20%、40% 和 32%。证明所提方法通过非对称映射形式学习域私有特征,降低了模型训练过程对公共特征的依赖,在克服域间较大的分布差异的同时具有较好的泛用性,相较常规域对抗和特征距离域自适应更适用于不同型号轴承预测任务。

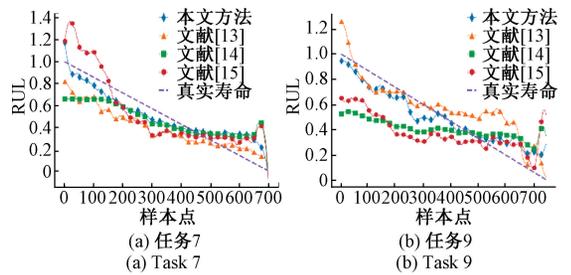


图 8 不同方法预测效果对比

Fig. 8 Prediction effects comparison of different methods

表 6 与其他方法结果对比

Table 6 Comparison with other model results

方法	指标	任务 1	任务 2	任务 3	任务 4	任务 5	任务 6	任务 7	任务 8	任务 9	任务 10	任务 11	任务 12	平均值
本文方法	MAE	<b>0.07</b>	<b>0.10</b>	<b>0.07</b>	<b>0.09</b>	<b>0.11</b>	<b>0.11</b>	<b>0.08</b>	<b>0.08</b>	<b>0.08</b>	<b>0.11</b>	<b>0.13</b>	<b>0.12</b>	<b>0.09</b>
	RMSE	<b>0.08</b>	<b>0.12</b>	<b>0.08</b>	<b>0.11</b>	<b>0.14</b>	<b>0.14</b>	<b>0.12</b>	<b>0.13</b>	<b>0.10</b>	<b>0.13</b>	<b>0.15</b>	<b>0.14</b>	<b>0.12</b>
文献[13]	MAE	0.13	0.11	0.08	0.11	0.13	0.12	0.14	0.15	0.12	0.15	0.16	0.16	0.13
	RMSE	0.15	0.13	0.10	0.14	0.15	0.14	0.16	0.17	0.14	0.17	0.19	0.18	0.15
文献[14]	MAE	0.14	0.13	0.10	0.14	0.16	0.19	0.16	0.20	0.21	0.21	0.23	0.22	0.17
	RMSE	0.16	0.16	0.13	0.17	0.19	0.21	0.18	0.22	0.24	0.25	0.26	0.25	0.20
文献[15]	MAE	0.11	0.12	0.10	0.12	0.13	0.14	0.15	0.18	0.19	0.2	0.21	0.21	0.16
	RMSE	0.13	0.14	0.12	0.15	0.15	0.16	0.17	0.20	0.21	0.23	0.24	0.23	0.18

## 5 结 论

本文中运用子空间域对抗判别网络对不同型号的滚动轴承进行剩余寿命预测。通过改进时间卷积网络嵌入高效通道注意力机制实现不同型号下滚动轴承退化特征的有效提取;同时结合域对抗判别网络和表征子空间距离损失学习实现目标域特征分布向源域的迁移,克服了

特征尺度和分布信息差异导致不同型号轴承数据集之间域自适应回归性能下降问题。该方法优势在于:

- 1) 改进后的特征提取器能够根据输入数据调整中不同通道的特征权重,在不同型号数据中自适应提取到反映轴承退化趋势的深层特征;
- 2) 结合域对抗判别网络和表征子空间距离损失的域自适应方法能够有效克服不同型号轴承的特征分布和尺度差异,充分学习更多的域私有特征,对比相关方法,剩

余寿命预测准确率在不同数据集上分别提升 20%、40% 和 32%，表明所提方法的可行性和有效性。

## 参考文献

- [1] LEI Y G, LI N P, GUO L, et al. Machinery health prognostics: A systematic review from data acquisition to RUL prediction [J]. *Mechanical Systems and Signal Processing*, 2018, 104: 799-834.
- [2] 罗宏林, 柏林, 侯东明, 等. 有限变工况特征迁移学习方法及其在高速列车轴箱轴承故障诊断中的应用[J]. *仪器仪表学报*, 2022, 43(3): 132-145.
- LUO H L, BO L, HOU D M, et al. A transfer learning method for bearing fault diagnosis under finite variable working conditions and its application in train axle-box bearings fault diagnosis[J]. *Chinese Journal of Scientific Instrument*, 2022, 43(3): 132-145.
- [3] 王新刚, 韩凯忠, 王超, 等. 基于迁移学习的轴承剩余使用寿命预测方法[J]. *东北大学学报(自然科学版)*, 2021, 42(5): 665-672.
- WANG X G, HAN K ZH, WANG CH, et al. Bearing remaining useful life prediction method based on transfer learning[J]. *Journal of Northeastern University(Natural Science)*, 2021, 42(5): 665-672.
- [4] HU T, GUO Y M, GU L D, et al. Remaining useful life prediction of bearings under different working conditions using a deep feature disentanglement based transfer learning method[J]. *Reliability Engineering and System Safety*, 2022, 219: 108265.
- [5] DONG SH J, XIAO J F, HU X L, et al. Deep transfer learning based on Bi-LSTM and attention for remaining useful life prediction of rolling bearing[J]. *Reliability Engineering and System Safety*, 2023, 230: 108914.
- [6] TZENG E, HOFFMAN J, SEANKO K, et al. Adversarial discriminative domain adaptation[C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2017: 7167-7176.
- [7] CHEN X Y, WANG S N, WANG J M, et al. Representation subspace distance for domain adaptation regression [C]. *International Conference on Machine Learning*, 2021: 1749-1759.
- [8] 高学金, 马东阳, 韩华云, 等. 基于 DAE 和 TCN 的复杂工业过程故障预测[J]. *仪器仪表学报*, 2021, 42(6): 140-151.
- GAO X J, MA D Y, HAN H Y, et al. Fault prediction of complex industrial processes based on DAE and TCN[J]. *Chinese Journal of Scientific Instrument*, 2021, 42(6): 140-151.
- [9] WANG Q, WU B, ZHU P, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks[C]. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2020: 11534-11542.
- [10] WANG B, LEI Y G, LI N P, et al. A hybrid prognostics approach for estimating remaining useful life of rolling element bearings[J]. *IEEE Transactions on Reliability*, 2018, 69(1): 401-412.
- [11] NECTOUX P, GOURIVEAU R, MEDJAHER K, et al. PRONOSTIA: An experimental platform for bearings accelerated degradation tests [C]. *IEEE International Conference on Prognostics and Health Management*, 2012: 23-25.
- [12] ZHU Y CH, ZHUANG F ZH, WANG J D, et al. Deep subdomain adaptation network for image classification[J]. *IEEE Trans Neural Netw Learn Syst*, 2021, 32(4): 1713-1722.
- [13] LI W X, SHANG ZH W, GAO M SH, et al. Remaining useful life prediction based on transfer multi-stage shrinkage attention temporal convolutional network under variable working conditions [J]. *Reliability Engineering and System Safety*, 2022, 226: 108722.
- [14] 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.
- CHEN J X, MAO W T, LIU J, et al. Remaining useful life prediction of bearing based on deep temporal feature transfer [J]. *Control and Decision*, 2021, 36(7): 1699-1706.
- [15] 王焱, 丁华, 孙晓春, 等. 基于改进 ECANet-TCN 和迁移学习的轴承剩余寿命预测[J]. *振动与冲击*, 2023, 42(21): 149-159.

WANG Y, DING H, SUN X CH, et al. Bearing residual life prediction based on improved ECANet-TCN and transfer learning [J]. Journal of Vibration and Shock, 2023, 42(21): 149-159.

## 作者简介



陈仁祥(通信作者),分别在2007年和2012年于重庆大学获得学士学位和博士学位,现为重庆交通大学教授、博士生导师,主要研究方向为智能测试技术与信号处理。

E-mail: manlou.yue@126.com

**Chen Renxiang** (Corresponding author) received his B. Sc. and Ph. D. degree both from Chongqing University in 2007 and

2012, respectively. He is currently a professor and a Ph. D. advisor at Chongqing Jiaotong University. His main research interests include intelligent testing technology and signal processing.



张雁峰,2017年于西南科技大学获得学士学位,现为重庆交通大学硕士研究生,主要研究方向为故障预测与健康管管理。

E-mail: 622210991015@ mails. cqjtu. edu. cn

**Zhang Yanfeng** received his B. Sc. degree from Southwest University of Science and Technology in 2017. He is currently a master student at Chongqing Jiaotong University. His main research interest is prognostics and health management.