DOI: 10. 13382/j. jemi. B2306766

# 领域对抗与分类差异的变工况球磨机负荷识别\*

蔡改贫1,2 肖文聪1 黄耀锋1

(1. 江西理工大学机电工程学院 赣州 341000;2. 江西省矿冶机电工程技术研究中心 赣州 341000)

**摘 要:**在变工况球磨机负荷识别过程中,针对域适应方法在源域和目标域的特征迁移中没有考虑目标域样本而导致域适应效 果不好的问题,本文提出一种基于领域对抗与分类差异的域适应方法。该方法使用域对抗训练方式实现源域和目标域之间的 特征的对齐;同时,引入两个分类器用于检测远离目标域中的样本,利用最大化和最小化分类器之间的不一致性,实现目标域和 源域特征的自适应匹配,达到更好的域适应效果。为了验证训练分类器误差的方法能够考虑类内边界提高目标域上的负荷识 别准确率,设计了迁移实验分析其差异损失函数对模型迁移性能的影响,实验表明,当分类器损失值大于 0.02 时预测模型的准 确率会下降 0.8%~1.2%,且较未引入分类器差异损失模型的负荷精度高,可达到 95.78%。通过与两类经典的迁移方法进行 对比,验证了该方法在变工况下磨机负荷识别应用中的优势。

关键词:迁移学习:领域对抗:分类差异:域适应:负荷识别

中图分类号: TD453 文献标识码: A 国家标准学科分类代码: 510.4

## Load identification of ball mill under off-design conditions based on domain confrontation and classification difference

Cai Gaipin<sup>1,2</sup> Xiao Wencong<sup>1</sup> Huang Yaofeng<sup>1</sup>

(1. School of Mechanical and Electrical Engineering, Jiangxi University of Technology, Ganzhou 341000, China;2. Jiangxi Mechanical and Electrical Engineering Technology Research Center of Mining and Metallurgy, Ganzhou 341000, China)

**Abstract**: In the process of load identification of ball mill under varying working conditions, a domain adaptation method based on domain antagonism and classification difference is proposed to solve the problem that domain adaptation method does not consider the target domain sample in the feature transfer between source domain and target domain. The method uses domain adversarial training to align the features between source domain and target domain. At the same time, two classifiers are introduced to detect samples far away from the target domain, and the inconsistency between the maximization and minimization of the classifiers is utilized to realize the adaptive matching of the features of the target domain and the source domain to achieve a better domain adaptation effect. In order to verify that the method of training the classifier error can consider the in-class boundary to improve the load recognition accuracy on the target domain, a migration experiment is designed to analyze the impact of its difference loss function on the model migration performance. The experiment shows: When the classifier loss value is greater than 0.02, the accuracy of the prediction model will decrease by 0.8% ~ 1.2%, and the load accuracy is higher than that of the model without the classifier differential loss, which can reach 95.78%. Compared with two classical transfer methods, the advantages of this method in the application of mill load identification under varying working conditions are verified.

Keywords: transfer learning; domain confrontation; classification difference; domain adaptation; load identification

收稿日期:2023-07-24 Received Date: 2023-07-24

<sup>\*</sup>基金项目:国家自然科学基金(52364025)、江西省科技厅重点研发计划项目(20181ACE50034)资助

## 0 引 言

基于数据驱动的状态识别模型不需建立研究对象系统的动力学模型,只需通过大量的历史数据建立和优化 模型,可得到良好的识别结果<sup>[1-2]</sup>。但是实际运行过程 中,由于设备重组、设备运行参数和运行环境的变化导致 实际运行工况复杂多变,测试数据(目标域)与训练数据 (源域)的特征空间分布不一致,模型的性能通常受到限 制。迁移学习放宽了深度学习和机器学习中测试数据与 训练数据需独立同分布的约束,在实际工作场景中,迁移 学习能够挖掘两个域之间相关的领域不变特征<sup>[34]</sup>。

近年来,变工况条件下的设备状态预测方法逐渐成 为研究重点[5-7]。罗宏林等[8]提出一种针对有限数量变 工况下的轴承故障诊断方法,通过构造自编码器实现特 征值集的映射迁移,再利用基于卷积神经网络的模型对 迁移后的特征集进行诊断以实现变工况下轴承故障的准 确诊断。针对多工况条件下故障诊断难度大的问题,周 长巍等<sup>[9]</sup>提出域适应和流形正则化的故障诊断建模方 法。将基于区分性联合概率分布差异的域适应项施加在 结构风险最小化域不变分类器上,并将建模数据及待测 数据投影到公共特征空间,对齐同类别样本分布,最大化 不同类别样本之间的分布差异,利用流形正则化方法稳 定数据的局部几何结构。陈仁祥等<sup>[10]</sup>提出自适应正则 化迁移学习的轴承故障诊断方法,该方法利用联合分布 适配减少领域的分布差异,通过流形正则化挖掘目标域 数据的潜在分布几何结构,学习目标域数据分布信息,提 高模型判别结构与目标域流形结构的一致性。上述方法 虽然取得了较好结果,但上述归类为浅层的域适应方法, 其基本思路是在低维流形中找到一个变换,使得源域和 目标域子空间更加相似,当两域的数据特征分布差异较 大时,无法将共同特征进行迁移。

深度学习在提取信号深度特征信息方面更具优势, 基于映射的深度迁移方法通过深度神经网络将源域和目 标域的深度特征信息映射到特征空间,在特征空间中,通 过距离度量使域散度最小化,从而将共同的特征知识迁 移。王琦等<sup>[11]</sup>将利用最大均值差异(maximum mean discrepancy,MMD)度量源域和目标域在预训练模型中各 层上的特征分布距离,通过 MMD 判断特征在连接层和 卷积层能否迁移,通过该方法将源域与目标域的特征进 行迁移,进而对目标域的故障数据进行识别。Qian 等<sup>[12]</sup> 等提出一种改进的联合分布适应机制,该机制结合最大 平均差异和 CORAL 关系对齐组合为一个新的分布差异 度量。针对 MMD 分布距离测量方法忽略数据的标签信 息和空间结构的关系,Xiao 等<sup>[13]</sup>提出一种具有度量结构 的深度迁移学习故障诊断方法,该方法结合 MMD 和度 量矩阵设计了一个新颖的领域适应模块,将两个领域中 平均差异和质量结构上相似特征进行迁移。除了使用特 征度量方法完成迁移任务外,基于对抗性的深度迁移方 法,能够解决迁移学习中某些重要的问题。针对变工况 下,源域和目标域数据分布的域偏移和域移位导致燃气 轮机的故障诊断精度下降,Liu 等<sup>[14]</sup>提出一种基于对抗 判别域自适应迁移学习网络的燃气轮机故障诊断方法, 该方法采用源域与目标域之间的深度对抗训练,自适应 优化目标域网络的参数,减少域偏移,提高故障诊断 精度。

鉴于迁移学习有效解决数据分布差异导致模型的预测精度下降的问题,学者们进一步对如何提高迁移学习 模型的泛化性能进行研究。Liu 等<sup>[15]</sup>提出一种深度多源 对抗差异匹配自适应网络,应用差异匹配技术动态对齐 不同域的特征分布,更好的缓解域偏移现象;结合对抗分 类器训练方法,考虑特定任务的决策边界,提高可转移性 和泛化性能。Chen 等<sup>[16]</sup>提出一种新的对抗域自适应无 监督学习方法,该方法使用信道残差对特征信息较弱的 信道应用残差技术实现数据增强并且通过将边际特征输 入判别器以提高模型的收敛速度和泛化能力。

以上的深度迁移方法分别从提取数据的深度特征, 构造度量方法和特征迁移方式等方面提高模型在目标域 上的预测准确率,然而领域适应方法直接使用源域和目 标域的特征进行完全匹配却不考虑样本的类别,导致域 适应的效果并不好。针对这个问题本文提出一种基于领 域对抗分类器差异迁移学习的磨机负荷识别模型,针对 知识迁移中域适应方法存在源域与目标域难以完全对齐 的问题,提出一种领域对抗的跨领域知识迁移方法。针 对域适应过程中并没有考虑样本之间的决策边界问题, 提出最大化分类器的方法,通过度量两个分类器之间的 概率差异,使差异最大化从而最大化样本类别之间的决 策边界。通过磨矿实验验证该方法的可行性。

## 1 分类差异与领域对抗

#### 1.1 分类差异网络

根据目标域样本期望界限理论<sup>[17]</sup>可知,目标域上的 误差限  $R_{T}(h)$ 分别与源域样本数据上的误差  $R_{s}(h)$ ,度 量两分类器差异的距离 $\pi$ 和常数  $\lambda$ ,3个因素有关,使用 表示分类器假设空间。

对于给定的源域 S 和目标域 T:

1

$$d_{\mathcal{H}\Delta\mathcal{H}}(S,T) = 2 \sup_{(h,h') \in \mathcal{H}^2} \begin{vmatrix} E_{x-S} I \\ \neq h'(x) \end{bmatrix} \\ - \sum_{x-T} \left[ \begin{pmatrix} h(x) \\ \neq h'(x) \end{bmatrix} \right] \\ d_{\mathcal{H}}(S,T) = 2 \sup_{h \in \mathcal{H}} \begin{vmatrix} E_{x-S} I \\ - E_{x-T} I \\ + R_{x}(h) \end{bmatrix} \end{vmatrix},$$

$$\lambda = \min[R_{s}(h) + R_{r}(h)] \qquad (2)$$

 $\lambda = \min[R_s(h) + R_r(h)]$ 式中: I[a] 是一个二值函数。

当两函数预测结果相同时 I[*a*] 的值为 0,两函数预测的结果不同时值为 1,对于  $d_{\mathcal{H}\Delta\mathcal{H}}(S,T)$ ,利用源域数据 对两函数进行有监督训练时,两函数对源域数据样本预 测准确率非常高,故两函数都能准确预测结果即  $EI[h(x) \neq h'(x)]$ 的值为 0,因此可以近似认为:

$$d_{\mathcal{H}\Delta\mathcal{H}}(S,T) = \sup_{(h,h') \in \mathcal{H}^{2x-T}} E_{I}[h(x) \neq h'(x)]$$
(3)

假设 h 和 h' 共享特征提取部分,将 h(x) 函数用特 征提取器 F 和分类器 C1 表示, h'(x) 函数用特征提取器 F 和分类器 C2 表示,则式(3)可以表示为:

 $d_{\mathcal{H}\Delta\mathcal{H}}(S,T) = \sup_{C1,C2x\sim T} E_1[F \circ C1(x) \neq F \circ C2(x)]$ (4) 式中:•表示特征提取器和分类器之间的网络结构的连接 方式。

进一步,利用对抗训练的方法对式(4)进行优化,用 max 替代 sup,并最小化关于 F 的项,可得:

$$d_{\mathcal{H}\Delta\mathcal{H}}(S,T) = \min_{F} \max_{C1,C2x \sim T} \begin{bmatrix} F \circ C1(x) \\ \neq F \circ C2(x) \end{bmatrix}$$
(5)

通过式(5)可知,分类差异域迁移算法的目的是通 过分类器差异和对抗训练的方法训练一个特征提取器和 两个分类器将不同域数据之间的距离缩少,实现两个域 之间的特征分布对齐。同时考虑目标域数据分布与决策 边界的关系,提高目标域内不同负荷状态的识别准确率。

分类网络差异结构如图 1 所示。该网络由一个特征 提取器 F、两个分类器 C1 和 C2 组成,。对于特征提取 器,源域和目标域是权重共享。其中特征提取器主要由 卷积层和池化层组成,用于对信号进行特征提取。



图 1 分类器差异网络结构 Fig. 1 Classifier differential network structure diagram

特征提取器 F 的提取过程如下:

$$x_{i}^{l+1} = f\Big(\sum_{j \in M_{j}} x_{j}^{l} \cdot w_{ij}^{l+1} + b_{i}^{l+1}\Big)$$
(6)

式中:  $f(\cdot)$  表示激活函数;  $w_{ij}^{l+1}$  表示  $l \in \Re i$  个神经元对 应第  $l + 1 \in \Re j$  个神经元的权重; b 表示偏置。

两个分类器的分类损失函数为 Softmax 交叉熵损失:

$$loss_{c}(X_{s}, Y_{s}) = -\frac{1}{K} \sum_{i=1}^{K} I(i = y_{s}^{(i)}) \log p_{s}(x_{s}^{(i)})$$
(7)

式中:  $I(i = y_s^{(i)})$  是一个二值函数,当 $i = y_s^{(i)}$ 时其值为1, 否则为0;  $p_s$  是经过 Softmax 函数计算得到的分类概率输出,在分类器 C1 中  $p_s = C1(F(x_s^{(i)}))$ ,分类器 C2 中  $p_s = C2(F(x_s^{(i)}))$ 。

令两个分类器的密度概率之差的 L1 距离作为分类 差异损失:

$$L_{d}(X_{i}) = d(p_{1}(y | x_{i})),$$

$$p_{2}(y | x_{i})) = \frac{1}{K} \sum_{i=1}^{K} |p_{1k} - p_{2k}|$$
(8)

式中: d 为度量函数;  $p_1(y|x_t)$ ,  $p_2(y|x_t)$ 分别为分类器 C1 和 C2 的概率输出;  $p_{1k}$ 和  $p_{2k}$ 为两个分类器对第 K 为 类的输出概率。

#### 1.2 深度领域对抗网络

迁移学习的核心是将磨机源域与目标域数据映射到 公共特征空间,并且在该空间进行分布对齐,领域对抗学 习利用生成对抗学习的思想,在网络中设计一个域判别 器,通过对抗训练使源域与目标域在特征空间中对齐从 而特征提取器能够学习两个域的共同特征。深度域对抗 网络包含特征提取器、域判别器和分类器 3 部分其基本 结构图如图 2 所示。





域判别器判别特征是属于源域或是目标域,特征提 取器提取源域与目标域的共同特征混淆判别器,特征提 取器与域判别器就形成竞争对抗的关系,最终实现变工 况下磨机负荷识别。

磨机负荷识别分类器的损失为:

$$L_{y} \{ G_{y} [ G_{f}(x_{i}) ], y_{i} \} = \log \frac{1}{G_{y} [ G_{f}(x_{i}) ]_{y_{i}}}$$
(9)

式中:  $y_i$  为负荷状态,  $G_f(x_i)$  为信号经过特征提取器的特征,  $G_y[G_f(x_i)]$  为特征  $G_f(x_i)$  经过 Softmax 函数后的输出结果。

领域分类器的损失度量领域自适应的效果,其损失 函数为:

$$L_{d} \{ G_{d} [ G_{f}(x_{i}) ], d_{i} \} = d_{i} \log \frac{1}{G_{d} [ G_{f}(x_{i}) ]} + (1 - d_{i}) \log \frac{1}{G_{d} [ G_{f}(x_{i}) ]}$$
(10)

式中:  $d_i$  为领域的二元标签,  $G_f(x_i)$  为信号经过特征提取器的特征,  $G_d[G_f(x_i)]$  为特征  $G_f(x_i)$  经过 Sigmoid 激活函数后的输出。

最后整个领域对抗网络的损失函数为:

$$E(\theta_f, \theta_y, \theta_d) = \frac{1}{n_s} \sum_{x_t \in D_s} L_y(G_y(G_f(x_i)), y_i) - \frac{1}{n_t} \sum_{x_t \in D_s \cup D_t} L_d(G_d(G_f(x_i)), d_i)$$
(11)

式中:  $L_y$  和  $L_a$  分别为分类器  $G_y$  和域判别器  $G_a$  的损失,  $\theta_f, \theta_a$  和  $\theta_y$  分别是  $G_f, G_a$  和  $G_y$  的网络参数。

## 2 基于领域对抗与分类差异的变工况球磨 机负荷识别方法

## 基于领域对抗与分类差异的变工况球磨机负荷识 别网络的建立

借鉴文献[18]和[19]的思想,提出一种基于领域对 抗与分类器差异的迁移学习网络,用于变工况下磨机负 荷识别。网络结构如图3所示,该网络共包含3个部分: 特征提取、域对抗模块和磨机负荷识别。



g. 3 Load identification model of ball mill under off-design conditions 所提方法采用残差网络作为特征提取器 G<sub>f</sub> 从原始 磨机筒体振动信号中直接提取高维特征,对源域数据利 用有监督训练方法分别训练两个独立的分类器 C1 和 C2,让两个分类器准确识别源域的负荷状态。两个分类 器的决策边界不同,对目标域的预测具有差异性,构造两 个分类器的判别误差度量这种差异性。在域适配阶段, 基于领域对抗的思想将特征提取器 G<sub>f</sub> 和与判别器 G<sub>a</sub> 进 行对抗学习增强 G<sub>f</sub> 学习源域和目标域公共特征能力,从 而减少领域差异。另一方面固定特征提取器 G<sub>f</sub> 的参数, 训练两个分类器,使两个分类器的分类差异最大化。

## 2.2 基于领域对抗与分类差异的变工况球磨机负荷识 别模型的识别流程

迁移学习的目的是从大量有标签的源域数据及无标签的目标域数据中学习相似的特征用于目标域的状态识别。假设源域为实验室模拟磨矿实验在工况1下采集的磨机负荷状态信号,目标域为工况2下采集到的磨机负荷状态信号。源域 $D_s = \{(x_i^s, y_i^s)\}_{i=1}^{n_s}, 其中 n_s$ 为源域的磨机振动数据样本量, $x_i^s$ 为源域中第i个样本, $y_i^s$ 为其对应负荷状态标签,且 $y_i^s \in R^c$ ,是一个 one-hot 向量标签, $y_{ij}^s = 1$ 表示样本属于第j类负荷状态,C为负荷的总类;目标域 $D_i = \{(x_i^t)\}_{j=1}^{n_t}, n_i$ 为目标域的磨机振动样本数量, $x_j^s$ 为目标域中第j个样本。由于 $D_s$ 和 $D_i$ 是不同工况下的数据,它们服从不同的数据分布 p和q。

基于领域对抗与分类差异的变工况球磨机负荷识别 方法的具体流程如图 4 所示。步骤如下:

1)模型预训练

模型预训练的目的是利用源域数据训练特征提取器和分类器,使特征提取器和分类器具有提取特定任务的特征,准确识别源域数据上磨机的负荷状态。将源域磨机筒体振动数据 x<sup>\*</sup><sub>i</sub>输入特征提取器,特征提取器提取数据的高维特征输入两个分类器中,训练直至两个分类器 C1 和 C2 准确识别磨机的负荷状态。在模型预训练中通 过式(12)最小化损失函数的方法优化特征提取器 G<sub>f</sub>,分 类器 C1 和 C2 的参数。

$$(\theta_{c_1}, \theta_{c_2}, \theta_F) = \min_{c_f, c_1, c_2} loss_c(X_s, Y_s)$$
(12)

式中: $\theta_{C1}$ 和 $\theta_{C2}$ 分别是分类器 C1和C2的参数, $\theta_{F}$ 为特征提取器的参数。

2)分类器差异最大化

在这一步更深入的训练两个分类器,使两个分类器 能更好检测到目标域数据决策边界上附近的样本。在步 骤 1)中保证两个分类器准确识别源域数据负荷状态的 基础上构建度量两个分类器差异的损失函数。之后,固 定特征提取器 *C<sub>f</sub>* 的参数,训练分类器 *C*1 和 *C*2 并且确定 优化其参数 θ<sub>C1</sub> 和 θ<sub>C2</sub>,分别计算两分类器输出结果的信 息熵,度量判别函数计算两分类器的差异,通过反向传播





的方法使两个分类器的差异最大。同时,为了实现域对 抗将来自源域与目标域的数据样本打上新标签,这个标 签与磨机的负荷状态无关,称为域标签。利用拥有域标 签的源域与目标域数据训练域判别器  $G_a$ ,优化判别器的 参数  $\theta_a$  使其具有域识别能力。

$$(\theta_{c1}, \theta_{c2}, \theta_d) = \underset{c1, c2, c_d}{\operatorname{argmin}loss_c}(X_s, Y_s) - L_{dis}(X_s) + L_{domain}(X_s, X_t)$$
(13)

其中.

$$L_{dis}(X_{t}) = L_{d}(X_{t}) = \frac{1}{K} \sum_{j=1}^{K} \| C1(F(x_{j}^{t})) - C2(F(x_{j}^{t})) \|$$
(14)

3)领域对抗训练

为消除目标域决策边界附近的模糊特征,使模型重新学习任务的特异性特征,训练模型学习两域的最小化差异。在这步骤中,固定特征分类器 C1 和 C2 的参数,优化特征提取器 G<sub>f</sub>,使度量函数的损失值最小化。同时,本文借助对抗性领域自适应的方法优化特征提取器 G<sub>f</sub>。为实现对领域对抗自适应,将有域标签的源域数据与目标域数据输入到特征提取器 G<sub>f</sub>,得到数据特征后,并进一步输入到域判别器 G<sub>d</sub>中,通过判别器判特征的来源,

对判别的误差进行反向传播使特征提取器向着提取域共同特征的方向更新参数。该过程利用公式可以表示为:

$$L_{dis}(X_{t}) = L_{d}(X_{t}) = \frac{1}{K}$$

$$\sum_{j=1}^{K} \| C1(F(x_{j}^{t})) - C2(F(x_{j}^{t})) \|$$
(15)

4)将目标域的数据输入到训练好的识别模型中,测 试模型的负荷识别准确率。

#### 3 实验验证

为了验证本章方法的有效性,设置多组变工况迁移 实验。磨矿实验采用 bond 式实验型球磨机,分别设置了 4 种不同的工况,充填率为 20%、30%、40%、50%。在 4 种不同的工况下,预测料球比为 0.5、0.6、0.7、0.8 的负 荷参数。为了验证网络的迁移性能,采用某一工况(如填 充率为 20%)的磨机筒体振动信号作为源域数据训练模 型,另外一种工况(如填充率为 30%)下的振动信号作为 目标域数据测试模型,识别目标域工况磨机的料球比参 数。采用交叉验证的方法设计了 12 组迁移实验,如表 1 所示。

表 1 迁移任务设置 Table 1 Migration task Settings

		0	<b>8</b>	
$D_s \rightarrow D_t$	$D_t = 1$	$D_t = 2$	$D_t = 3$	$D_i = 4$
$D_s = 1$		$1 \rightarrow 2$	$1 \rightarrow 3$	$1 \rightarrow 4$
$D_s = 2$	$2 \rightarrow 1$		$2 \rightarrow 3$	$2 \rightarrow 4$
$D_s = 3$	$3 \rightarrow 1$	$3 \rightarrow 2$		$3 \rightarrow 4$
$D_s = 4$	$4 \rightarrow 1$	$4 \rightarrow 2$	$4 \rightarrow 3$	

#### 3.1 分类器误差的性能分析

为了验证领域对抗与分类差异域适应方法能够考虑 类内的边界提高目标域上的负荷识别准确率,在迁移实 验(1→2)中,将分类差异损失值、含分类器差异损失模 型的准确率和不含分类差异损失模型的准确率可视化, 分析分类器差异损失函数对模型迁移性能的影响,可视 化结果如图 5 所示。

根据图 5 的实验结果可以发现,在模型的训练过程中,带有分类差异损失函数的迁移模型对变工况下的磨机负荷预测准确精度一直上升,最终可以达到 95.78%。没有采用分类差异损失函数的迁移模型,在训练过程中准确率最开始为 55%,经过 1 500 迭次数后,负荷识别准确率降至 47%。此外,通过观察含有分类差异损失函数的模型预测准确率曲线和分类差异损失曲线,可以发现,当分类差异损失值大于 0.02 时,预测模型的准确率会呈现下降趋势,模型的负荷识别准确率大约会下降 0.8%~ 1.2%。综合图 4 可以看出,迁移学习模型在最大和最小化分类差异损失函数的过程中,成功地考虑了目标域的



类内边界特征,从而提高了变工况磨机负荷识别模型的 迁移效果和准确率。

#### 3.2 不同方法的对比

为了验证基于领域对抗与分类差异变工况球磨机负 荷识别方法的优越性,采用了两类经典的迁移学习方法 与本章方法进行对比。

1)基于映射的深度迁移学习方法,通过深度神经网 络将源域和目标域的实例映射到特征空间,在特征空间 中,通过距离度量使域散度最小化,例如多核最大均值误 差(multi-kernel MMD, MK-MMD)<sup>[20]</sup>或联合最大均值差 异(joint maximum mean discrepsncy, JMMD)<sup>[21]</sup>度量距离 的域适应方法。MK-MMD 准则经常结合卷积神经网络 一起使用,利用神经网络提取源域与目标域的特征,通过 MK-MMD 距离度量两个域的特征差异,利用反向传播算 法将差异减少从而实现特征迁移。JMMD 方法在深度学 习域适应中起到了减小源域和目标域分布差异的作用, 从而实现深度学习模型在目标域上的良好性能。

2)基于对抗性的深度迁移学习,利用域鉴别器减少 深度特征提取器产生的源域和目标域之间特征分布差 异,例如对抗领域自适应网络(domain-adversarial neural networks, DANN)<sup>[22]</sup>或深层域混淆(deep domain confusion,DDC)<sup>[23]</sup>方法,通过对抗学习的方法训练特征 提取器和域判别器使特征提取器提取两个域的共同特 征。DANN作为一种用于域适应的神经网络方法,通过 将源域和目标域的特征投影到同一特征空间中,实现对 不同领域数据的有效转移学习,可有效解决样本不足的 问题。DDC可利用在类混淆指导下的迁移干扰因子约 束分类器以消除难以迁移的样本对模型的影响,同时在 分类器前嵌入一个自适应辅助组件更好地拟合分类器, 实现两域共同特征的提取。

此处采用 MK-MMD、JMMD、DANN 和 DDC 4 种迁移

方法,以及本章提出的领域对抗与分类差异域适应方法 进行对比。图6展示了5种迁移方法在迁移任务3→4 的测试集上的预测准确率。



图 6 5 种迁移方法在测试集上的准确率

Fig. 6 Accuracy of five migration methods on the test set

根据图 6 可知,在迁移任务 3→4 中,本章的迁移方 法在训练约 60 次之后准确率超过 90%,并且相对于其他 4 种迁移方法,收敛速度更快,变工况下对球磨机负荷识 别效果最好。基于 MK-MMD 和 JMMD 迁移方法大概在 训练 180 次后才开始收敛,由于 MK-MMD 方法是集成多 个核作为总的核,其识别效果比 JMMD 的更好。但这两 个迁移方法收敛后对磨机负荷预测准确率并不高,其只 考虑两个域的差异并没有将类内差异考入到距离公式。

为分析 5 种迁移模型在每个迁移任务上的迁移效 果,显示 12 个迁移任务的球磨机负荷识别准确率,如表 2 所示。

表 2 不同方法对于不同任务的识别准确率 Table 2 Recognition accuracy of different methods for different tasks

迁移学习	MK-MMD	DANN	DDC	JMMD	本文方法
1→2	90.14	79.07	95.45	95.16	96.11
1→3	89.56	87.95	88.77	86.25	85.26
1→4	83.35	82.45	70.01	69.91	89.75
2→1	90.44	90. 98	93.62	92.22	85.50
2→3	88.00	90.37	89.90	90.34	92.67
2→4	87.50	88.63	79.51	76.63	95.41
3→1	74.56	76.07	73.73	62.38	86.10
3→2	91.17	89.97	83.30	81.71	95.15
3→4	88.50	89.18	75.98	83.19	95.44
4→1	83.15	76.24	68.89	60.16	94.75
4→2	70.92	83.54	75.50	76.62	94.04
4→3	90.83	82.24	78.01	77.40	93. 99
平均精度	85.68	84.72	81.06	79.33	92.01

分析表2可知:

1)在12种迁移任务上,本章提出的领域对抗与分类

• 73 •

差异迁移方法在负荷识别方面取得了较好的效果。从表2中可知本章方法的平均精度为92.01%,在5种迁移学 习模型中最高。在5种方法中,JMMD取得最小的平均 识别精度,只有79.33%。DDC的平均识别精度为 81.06%,DANN和MK-MMD的平均识别精度分别为 84.72%和85.68%。

2) 经过对单个迁移任务的分析发现, 与本章的方法 相比, 在某些迁移任务上, 其他的迁移方法的表现更佳。 如, 在迁移任务 1→3 中, MK-MMD 方法的负荷识别准确 率最高; 而在迁移任务 2→1 中, DDC 方法的表现最佳。 在不同的迁移任务中, 有些方法的表现可能更加优秀, 但 总体来看, 领域对抗与分类差异迁移方法在多数情况下 仍然表现出色。

3) MK-MMD 和 JMMD 方法在负荷识别方面的准确 率分别为 85.68% 和 79.33%。这两种方法都是基于深度 迁移学习的映射方法,可以在特征空间上减少源域和目 标域之间的特征差异。其中,MK-MMD 方法是通过计算 最大均值距离来衡量不同域之间的距离,而 JMMD 方法 则是使用联合概率密度函数的积分计算距离。在本研究 的球磨机迁移任务中,MK-MMD 方法表现更好。

4) 在基于域对抗迁移方法方面,迁移任务中 DANN 方法的负荷识别准确率比 DDC 方法高。DDC 方法是基 于域混淆损失减少域之间的分布差异,而 DANN 则通过 生成对抗模式使特征生成器学习域之间的共同特征。本 次迁移实验中,基于生成对抗的方式实现域之间的知识 迁移效果更好。

#### 3.3 实验效果可视化

为了检验迁移学习方法对迁移效果的影响,利用 t-SNE 特征降维方法<sup>[24]</sup>将迁移任务 4→3 中的高维特征提 取结果可视化。

图 7(a)是本章方法的特征可视化结果,从图 7(a) 中可以看出 4 种工况的源域与目标源特征的距离都比较 近,表明本章方法能够更好的将两个域的特征拉近,因此 该方法能有效将源域的特征知识迁移到目标域。此外, 图 7(a)中不同工况的特征都相隔较远,所以该方法将分 类差异作为损失函数后能将目标域类内的决策边界明确 分开,从而使目标域内不同的料球比特征分开,这些决策 边界明显的特征为后续变工况下的球磨机负荷识别任务 提供重要的前提。

图 7(b)为 MK-MMD 方法的特征迁移结果可视化, 其中 MBVR=0.5 时,大部分目标域的特征与源域的特征 非常接近,但仍有一小部分目标域的特征分散在源域特 征之外。当 MBVR=0.6 时,目标域的特征与源域的特征 严重偏移;MBVR=0.7 和 MBVR=0.8 的目标域特征大 部分都分布在源域特征范围内,但有部分 MBVR=0.7 的 目标域特征错迁移至 MBVR=0.8 的特征上,4 种状态之 中 MBVR=0.5 与其他3种负荷状态的距离较远决策边 界明显,而 MBVR=0.6、MBVR=0.7和 MBVR=0.83种 负荷的决策边界不明显,故基于 MK-MMD 的迁移模型在 样本迁移过程中虽然可减少源域样本与目标域样本的分 布差异,但不能有效的解决目标域数据分布与决策边界 的问题。

图 7(c)为 DANN 对抗迁移方法的特征迁移可视化 图,与图 7(a)和(b)对比可知,基于 DANN 的对抗迁移 方法的迁移效果比本章方法和 MK-MMD 差,其中在 MBVR=0.7类别的目标域特征大部分错迁移到 MBVR= 0.8上。

图 7(d)和(e)分别是 DDC 迁移方法和 JMMD 迁移 方法的特征迁移可视化图,对比图 7(d)和(e)可知,DCC 的迁移效果比 JMMD 的好,JMMD 除了 MBVR=0.5 以外 的其他 3 种负荷状态的特征都混叠在一起。DCC 方法在 特征迁移时也有特征混叠现象,但是其混叠的程度没有 JMMD 严重,除了 MBVR=0.5 的负荷状态与其他 3 种负 荷的特征有明显的决策边界外,其他 3 种负荷的边界并 不明确。



图 7 不同迁移方法的特征迁移结果



由图 8 可知,所提的领域对抗与分类差异方法在预测 MBVR=0.7 时,将部分特征误识别为 MBVR=0.6,误 识别率为 14%,同时在预测 MBVR=0.6 时,将部分特征 误识别为 MBVR=0.7,误识别率为 10.04%。所以在最 终的负荷识别结果中,领域对抗与分类差异方法的识别 准确率没有达到 100%,这与表中的结果一致,领域对抗

与分类差异方法在迁移任务 4→3 上的准确率 93.99%。 与其他几种迁移学习算法相比,本章所提的方法获得更 好的识别效果,验证了其更优的迁移能力。



## 4 结 论

本文提出了一种基于领域对抗与分类差异的负荷识 别模型,用于解决球磨机在变工况下负荷识别存在的域 偏移问题。利用领域对抗方法减少源域与目标域的分布 差异,通过构建两个独立的分类器建立源域与目标域决 策边界之间的关系,在模型训练过程中依次最大和最小 化分类差异,实现磨机特征的迁移。为验证所提方法的 优势,采用实验数据集的4个工况迁移学习任务对模型 进行验证。验证结果证明,在增大分类差异时,模型能有 效检测到源域之外的目标域样本,且当分类器误差的值 大于 0.02 时,训练过程中的模型负荷识别准确率会下降 0.8%~1.2%;与其他4种迁移方法比较中,领域对抗与 分类差异迁移方法的平均识别准确率最高,并且误识别 率较低。上述结果分析表明,领域对抗与分类差异迁移 策略不仅有效地将源域的特征知识迁移到目标域,而且 在迁移过程中还考虑了目标域类内的决策边界。这不仅 有助于拉近不同域之间的距离,还能增加不同类别数据 之间的距离,更适合球磨机变工况的负荷识别特征知识 迁移任务。

### 参考文献

- [1] 代浩,金铭,陈星,等.数据驱动的应用自适应技术综述[J].计算机研究与发展,2022,59(11):2549-2568.
  DAI H, JIN M, CHEN X, et al. Survey of data-driven application self-adaptive technology [J]. Journal of Computer Research and Development, 2022, 59 (11): 2549-2568.
- [2] 陈晶. 基于数据驱动的网络安全数据分类方法[J]. 国

外电子测量技术,2021,40(4):42-46.

CHEN J. Network security data classification method based on data driven [ J ]. Foreign Electronic Measurement Technology, 2021, 40(4):42-46.

- [3] LI W H, HUANG R Y, LI J P, et al. A perspective survey on deep transfer learning for fault diagnosis in industrial scenarios: Theories, applications and challenges [J]. Mechanical Systems and Signal Processing, 2022, 167: 108487.
- [4] HAKIM M, OMRAN A A B, AHMED A N, et al. A systematic review of rolling bearing fault diagnoses based on deep learning and transfer learning: Taxonomy, overview, application, open challenges, weaknesses and recommendations [J]. Ain Shams Engineering Journal, 2022: 101945.
- [5] ZHANG L W, FAN Q, LIN J, et al. A nearly end-toend deep learning approach to fault diagnosis of wind turbine gearboxes under nonstationary conditions [J]. Engineering Applications of Artificial Intelligence, 2023, 119: 105735.
- [6] 王雷,何坤,李宗帅,等. 基于 BiLSTM-Attention 的迁移 学习变工况故障识别方法研究[J]. 电子测量与仪器 学报,2023,37(7):205-212.
  WANG L, HE K, LI Z SH, et al. Transfer learning based on BiLSTM-Attention research on fault identification methods for variable operating conditions [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(7):205-212.
- [7] 于波,李建成,陈先瑞,等. 基于 CNN 的轴承变工况故 障识别系统[J]. 电子测量技术,2022,45(19):25-29. YU B, LI J CH, CHEN X R, et al. Bearing fault identification system based on CNN [J]. Electronic Measurement Technology, 2022, 45(19): 25-29.
- [8] 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.
- [9] 周长巍,李国勇,任密蜂,等.基于区分性联合概率分 布的域适应故障诊断[J].振动与冲击,2023,42(7): 170-179.

ZHOU CH W, LI G Y, REN M F, et al. Domain adaptive fault diagnosis based on differentiated joint probability distribution difference [J]. Journal of Vibration and Shock, 2023, 42(7):170-179. [10] 陈仁祥,朱玉清,胡小林,等.自适应正则化迁移学习的不同工况下滚动轴承故障诊断[J].仪器仪表学报, 2021,41(8):95-103.

CHEN R X, ZHU Y Q, HU X L, et al. Fault diagnosis of rolling bearing under different working conditions using adaptation regularization based on transfer learning [J]. Chinese Journal of Scientific Instrument, 2021,41(8): 95-103.

[11] 王琦,邓林峰,赵荣珍. 基于一维 CNN 迁移学习的滚动轴承故障诊断[J]. 振动. 测试与诊断, 2023, 43(1):
 24-30, 195.

WANG Q, DENG L F, ZHAO R ZH. Fault diagnosis of rolling bearing based on one-dimensional CNN transfer learning [J]. Vibration, Test and Diagnosis, 2023, 43(1):24-30,195.

- [12] QIAN Q, QIN Y, LUO J, et al. Deep discriminative transfer learning network for cross-machine fault diagnosis [J]. Mechanical Systems and Signal Processing, 2023, 186: 109884.
- [13] XIAO Y Q, WANG J Q, HE Z M, et al. Deep transfer learning with metric structure for fault diagnosis [J]. Knowledge-Based Systems, 2022, 256: 109826.
- LIU S C, WANG H J, TANG J P, et al. Research on fault diagnosis of gas turbine rotor based on adversarial discriminative domain adaption transfer learning [J]. Measurement, 2022, 196: 111174.
- [15] LIU S W, JIANG H K, WU Z H, et al. Intelligent fault diagnosis of rotating machinery using a multi-source domain adaptation network with adversarial discrepancy matching[J]. Reliability Engineering & System Safety, 2023, 231: 109036.
- [16] CHEN Q T, CHEN L, LI Q, et al. A lightweight and robust model for engineering cross-domain fault diagnosis via feature fusion-based unsupervised adversarial learning [J]. Measurement, 2022, 205: 112139.
- [17] ZHOU K, LIU Z, QIAO Y, et al. Domain generalization: A survey [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 45(4):4396-4415.
- SAITO K, WATANABE K, USHIKU Y, et al. Maximum classifier discrepancy for unsupervised domain adaptation[C]. Pro-ceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018; 3723-3732.

[19] 陈祝云,钟琪,黄如意,等.基于增强迁移卷积神经网络的机械智能故障诊断[J].机械工程学报,2021, 57(21):96-105.
CHEN ZH Y, ZHONG Q, HUANG R Y, et al. Intelligent fault diagnosis for machinery based on

enhanced transfer convolutional neural network [ J ]. Chinese Journal of Mechanical Engineering, 2021, 57(21):96-105.

- [20] XU B, WU K W, WU Y, et al. Dynamic adversarial domain adaptation based on multikernel maximum mean discrepancy for breast ultrasound image classification [J]. Expert Systems with Applications: An International Journal, 2022, 207: 117978.
- [21] WANG J Y, ZHANG Y J, LUO C, et al. Deep learning domain adaptation for electro-mechanical actuator fault diagnosis under variable driving waveforms [J]. IEEE Sensors Journal, 2022, 22(11): 10783-10793.
- [22] XU Y J, LIU J Z, WAN Z, et al. Rotor fault diagnosis using domain-adversarial neural network with timefrequency analysis[J]. Machines, 2022, 10(8): 610.
- [23] HU H T, JI X G, CHI S W, et al. Conditional domain confusion networks for cross-domain detection [J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71:1-13.
- [24] 郭艳萍,高云,吕丙东. 基于 t-SNE 降维的数据可视化 分析研究[J]. 电子技术与软件工程, 2021 (21): 166-170.

GUO Y P, GAO Y, LYU B D. Research on data visualization analysis based on t-SNE dimensionality reduction [J]. Electronic Technology and Software Engineering, 2021(21):166-170.

#### 作者简介



**蔡改贫**(通信作者),2006 年于北京科 技大学获得博士学位,现为江西理工大学教 授,博士生导师,主要研究方向为智能矿山 装备技术、智能监控及工业机器人。 E-mail: cgp4821@163.com

E-mail: cgp4821@105.com

Cai Gaipin (Corresponding author) received his Ph. D. degree from University of Science and Technology Beijing in 2006. Now he is a professor and doctoral supervisor at Jiangxi University of Science and Technology. His main research interests include intelligent mining equipment technology, intelligent monitoring and industrial robotics.