

基于传递式领域自适应的异构样本增强方法

翟利志^{1,2}, 任一夫^{1,2}, 白洁¹, 高学攀¹, 贾庆超¹, 刘强³

(1. 中国电子科技集团公司第五十四研究所, 河北 石家庄 050081;

2. 河北省智能化信息感知与处理重点实验室, 河北 石家庄 050081;

3. 陆装驻石家庄地区第一军代室, 河北 石家庄 050081)

摘要:小样本问题广泛存在于数据驱动建模。领域自适应方法通过将源域中的样本知识迁移到目标域, 从而实现目标域中的小样本增强, 然而此类方法在实际应用中受限, 原因在于难以应对领域分布差异较大的样本增强场景。针对上述问题, 该文提出基于传递式领域自适应的异构样本增强方法。首先, 提出传递式探索策略, 通过私有特征和共享特征设计了面向异构域的领域分布探索策略, 有效地缓解了负迁移, 并为后续分布匹配提供支撑; 然后, 提出分布联合匹配机制, 通过联合匹配异构领域的边缘分布和条件分布, 并嵌入自适应机制, 从而保证了异构域分布的匹配精度。该方法在业界公认的田纳西-伊斯曼数据集进行验证, 实验结果表明该方法在异构域中的建模表现优于其他方法。

关键词:域适应; 样本增强; 迁移学习; 小样本; 数据驱动建模

中图分类号: TP39

文献标识码: A

文章编号: 1673-629X(2024)01-0017-06

doi:10.3969/j.issn.1673-629X.2024.01.003

Heterogeneous Sample Enhancement Based on Transitive Domain Adaptation

ZHAI Li-zhi^{1,2}, REN Yi-fu^{1,2}, BAI Jie¹, GAO Xue-pan¹, JIA Qing-chao¹, LIU Qiang³

(1. The 54th Research Institute of CETC, Shijiazhuang 050081, China;

2. Hebei Key Laboratory of Intelligent Information Perception and Processing, Shijiazhuang 050081, China;

3. The First Military Office in Shijiazhuang, Shijiazhuang 050081, China)

Abstract: Small sample problem exists widely in data-driven modeling. Domain adaptation achieves small sample enhancement in target domain by transferring sample knowledge from source domain to target domain. However, those methods are limited in practical application because it is difficult to deal with sample enhancement scenarios with large domain distribution differences. To solve these problems, we propose a heterogeneous sample enhancement method based on transitive domain adaptation. Firstly, a transitive exploration strategy is proposed. A domain distribution exploration strategy for heterogeneous domains is designed based on specific and common features, which effectively alleviates negative transfer and provides support for subsequent distribution matching. Then, a distributed joint matching mechanism is proposed to match the marginal distribution and conditional distribution of heterogeneous domain, and embed an adaptive mechanism to ensure the matching accuracy of heterogeneous domain distribution. The proposed method is verified by the industry-recognized Tennessee-Eastman dataset, and the experimental results show that the proposed method performs better than other methods in heterogeneous domain modeling.

Key words: domain adaptation; sample enhancement; transfer learning; small sample; data-driven modeling

0 引言

大规模类别均衡的训练故障样本, 是实现数据驱动故障诊断可靠建模的先决条件^[1-6]。然而, 受限于复杂的流程以及不稳定的监测环境, 完备的样本数据难以保证。这导致小样本普遍存在, 成为数据驱动建

模发展的“卡脖子”问题^[7-8]。因此, 如何增强小样本的数量和类型, 获得诊断精度高、泛化能力强的故障诊断模型, 成为数据驱动故障诊断建模的重要课题。

近年来, 样本增强研究被业界和学术界广泛关注。样本增强方法大致可分为三类: 采样方法、深度网络方

收稿日期: 2023-03-15

修回日期: 2023-07-18

基金项目: 河北省智能化信息感知与处理重点实验室发展基金项目(SXX22138X002); 国家自然科学基金(U21A20481, 61973071)

作者简介: 翟利志(1981-), 男, 高级工程师, 硕士研究生, 研究方向为大数据分析及其应用; 通信作者: 任一夫(1993-), 男, 工程师, 博士研究生, 研究方向为样本增强、大数据分析等。

法以及域适应方法。具体而言,对于采样方法^[9-10],过采样策略通过直接扩充小样本的数量实现样本增强。然而,此类方法并没有在小样本中补充新的样本知识,这会严重影响建模的泛化性。相反,深度网络方法^[11-13]在解决建模泛化性这一问题上取得了令人瞩目的成果。具体而言,在文献[11-12]中,迭代机制和对抗机制被设计,并用来增强建模的泛化性。然而,这些深度网络方法的有效表现,是建立在充足的训练样本,或是预先得到一个拥有庞大网络结构的预训练模型的基础之上。众所周知,受限于故障样本的获取难度,这些要求在实际领域几乎不能满足。因此,上述方法在实际样本增强应用中难以普及。

随着迁移学习受到更多关注,域适应方法为样本增强提供了新思路。具体而言,域适应方法^[14-17]通过降低源域和目标域之间的分布差异,从而允许其他域中的样本知识增强小样本。然而,此类方法在实际小样本应用中依旧受限,这是因为:(1)区别于其他领域,故障样本的获取和标注成本更高,因此目标域中的小样本问题更加严峻;(2)由于不明确的故障机理,难以根据专家经验选取与目标域工况相似的源域;(3)由于工况差异较大,缺乏有效的技术来探索异构域中的样本,从而导致“负迁移”现象严重^[14],建模准确性大打折扣^[18-19]。受此启发,在文献[20]中,提出一个用于工业故障诊断的通用迁移框架,通过故障相似性对源域故障样本进行选择迁移,在实现目标域样本增强的同时,缓解了“负迁移”。在文献[21]中,多源迁移学习网络被提出,通过迁移多源域的故障样本实现目标域不可见故障的知识增强,成功解决了机器不可见故障的智能诊断,进一步拓展了迁移学习方法在工业故障诊断领域的应用范围。

基于上述讨论和分析,该文提出了一种基于传递式领域自适应的异构样本增强方法。首先,借助公共特征,在私有特征维度探索异构域样本。需要注意的是,在多源域传递式探索过程中,域内部的有用信息也能够被用来辅助探索异构域样本,因此文中方法在样本探索的同时,突破了源域选择困难的局限性。此外,从目标域角度来看,源域样本的介入,实质上增强了目标域样本的数量和种类,即样本增强。这一过程,由于只将源域样本迁移到目标域并用于目标域建模,不会影响目标域的工况建模,这意味着目标域故障信息被最大程度保留,因此目标域的故障诊断建模精度被保证;此外,由于源域故障样本的引入,目标域故障样本的故障多样性得到增强,所以目标域的建模泛化性得到提高。该文的主要创新点如下:

(1)针对异构域分布差异较大的问题,通过设计传递式探索策略以获得丰富种类的样本知识,从而提

高了小样本条件下建模的泛化性。

(2)针对异构域分布匹配困难的问题,通过联合匹配源域和目标域的边缘分布以及条件分布,实现异构域的可靠匹配,从而提高了小样本条件下建模的准确性。

1 异构样本传递式探索

在本节,提出一种异构样本传递式探索策略,通过学习异构域样本之间的共享映射,从而使异构域样本能够被用来增强小样本,因此提高建模的泛化性。对于异构域样本的探索,该文设计了基于最相关域的传递式策略。具体而言,首先在多个源域中选择与目标域最相关的源域,然后在公共特征的辅助下,设计支持域样本,从而获得这两个域的共享空间表示。同理地,在剩余的多个源域中,继续探索与当前已选择源域最相关的源域,并学习它们之间的共享空间表示。最后,异构域样本被传递式地探索,并用来增强小样本的数量和种类^[22-23]。

1.1 目标域-源域最相关样本搜寻

众所周知,相关的领域样本能够提供更丰富、更可靠的共享表示,这有助于提高域适应表现^[24-26]。本节中,在私有特征维度分析源域样本和目标域样本之间的相关性。最大信息数(Maximal Information Coefficient, MIC)能够可靠地发现不同样本之间的复杂、非线性关系^[18],受此启发, $x_{S_i}^i$ 和 x_{T_i} 之间的相关性被定义为:

$$\text{MIC}(x_{S_i}^i, x_{T_i}) = \max_{n_{ps}, n_{pt} < B(n)} \frac{I(x_{S_i}^i, x_{T_i})}{\log_2 \min(n_{ps}, n_{pt})} \quad (1)$$

其中, $B(n) = n^{0.6}$, n 是样本点的数量。 n_{ps} 和 n_{pt} 分别是 $x_{S_i}^i$ 轴和 x_{T_i} 轴的网格数量。 $\text{MIC}(x_{S_i}^i, x_{T_i})$ 值的浮动范围是 0 到 1, 值越大表明 $x_{S_i}^i$ 和 x_{T_i} 的相关性越强。选择 $\text{MIC}(x_{S_i}^i, x_{T_i})$ 最大的一组, 作为与目标域最相关的源域样本。 $I(x_{S_i}^i, x_{T_i})$ 的计算过程如下所示:

$$\begin{aligned} I(x_{S_i}^i, x_{T_i}) &= H(x_{S_i}^i) + H(x_{T_i}) - H(x_{S_i}^i, x_{T_i}) = \\ &= \sum_{n=1}^{n_{ps}} p(x_{S_i}^i) \log_2 \frac{1}{p(x_{S_i}^i)} + \\ &= \sum_{m>n}^{n_{pt}} p(x_{T_i}) \log_2 \frac{1}{p(x_{T_i})} - \\ &= \sum_{n=1}^{n_{ps}} \sum_{m>n}^{n_{pt}} p(x_{S_i}^i, x_{T_i}) \log_2 \frac{1}{p(x_{S_i}^i, x_{T_i})} \quad (2) \end{aligned}$$

然后,支持域样本被设计用来学习目标域与源域的共享表示。支持域样本可以看作匹配目标域与源域的桥梁。支持域通过公共特征,可支持源域样本和目标域样本的连接,并能传递源域和目标域的维度、分布信息,便于更好地匹配源域和目标域^[26]。特征映射 φ_s 和 φ_t 用来连接公共特征和私有特征,优化目标表示

如下:

$$\begin{aligned} \min_{\varphi_i} & \| \varphi_{s1}(x_{Sc}^i) - x_{Ss}^i \|_F^2 \\ \min_{\varphi_i} & \| \varphi_t(x_{Tc}^i) - x_{Ts}^i \|_F^2 \end{aligned} \quad (3)$$

另外,源域支持样本 $x_{S^1}^{\text{sup}}$ 和目标域支持样本 x_T^{sup} 可以表示如下:

$$\begin{aligned} x_{S^1 \leftarrow T}^{\text{sup}} &= \varphi_{s^1}(x_{Tc}^i) \\ x_{T \leftarrow S^1}^{\text{sup}} &= \varphi_t(x_{Sc}^i) \end{aligned} \quad (4)$$

通过 $x_{S^1 \leftarrow T}^{\text{sup}}$ 和 $x_{T \leftarrow S^1}^{\text{sup}}$, x_{Sc}^i 和 x_{Tc}^i 被嵌入到共享空间 $x_m^{T * S^1}$, 表示如下:

$$x_m^{T * S^1} = \begin{bmatrix} x_m^T \\ x_m^{S^1} \end{bmatrix} = \begin{bmatrix} x_{T \leftarrow S^1}^{\text{sup}} x_m^T \\ x_{Ss}^i x_{S^1 \leftarrow T}^{\text{sup}} \end{bmatrix} \quad (5)$$

其中, $x_{S^1 \leftarrow T}^{\text{sup}} \in \mathbb{R}^{I \times n_i}$, $x_{T \leftarrow S^1}^{\text{sup}} \in \mathbb{R}^{s \times n_i}$ 。令 $x_m^{S^1} = [x_{Ss}^i x_{S^1 \leftarrow T}^{\text{sup}}]$ 以及 $x_m^T = [x_{T \leftarrow S^1}^{\text{sup}} x_m^T]$, 可得 $x_m^{S^1} \in \mathbb{R}^{(s+t) \times n_i}$, $x_m^T \in \mathbb{R}^{(s+t) \times n_i}$ 。

最终,共享空间 $x_m^{T * S^1}$ 优化如下:

$$\begin{aligned} \arg\max_{\psi_{T, S^1}} & I(x_m^T, x_m^{S^1}) = \\ & \arg\max_{\psi_{T, S^1}} \left\{ \sum_{n=1}^{n_{ST}} p(x_m^T) \log_2 \frac{1}{p(p(x_m^T))} + \right. \\ & \left. \sum_{m>n}^{n_{ST}} p(x_m^{S^1}) \log_2 \frac{1}{p(x_m^{S^1})} - \right. \\ & \left. \sum_{n=1}^{n_{ST}} \sum_{m>n} p(x_m^T, x_m^{S^1}) \log_2 \frac{1}{p(x_m^T, x_m^{S^1})} \right\} \end{aligned} \quad (6)$$

其中, ψ_{T, S^1} 表示目标域 T 和源域 S^1 映射到共享空间的映射矩阵。 $\| \bullet \|_H$ 表示再生希尔伯特空间。

1.2 源域-源域最相关样本传递式搜寻

在剩余源域中,搜寻与 x_{Ss}^i 最相关的 x_{Ss}^j , x_{Ss}^i 和 x_{Ss}^j 的相关性定位如下:

$$\text{MIC}(x_{Ss}^i, x_{Ss}^j) = \max_{n_{ps^i}, n_{ps^j} < B(n)} \frac{I(x_{Ss}^i, x_{Ss}^j)}{\log_2 \min(n_{ps^i}, n_{ps^j})} \quad (7)$$

由 $\min_{\varphi_j} \| \varphi_j(x_{Sc}^j) - x_{Ss}^j \|_F^2$, $\min_{\varphi_i} \| \varphi_i(x_{Sc}^i) - x_{Ss}^i \|_F^2$

可得 $x_{S^1 \leftarrow S^2}^{\text{sup}}$ 和 $x_{S^2 \leftarrow S^1}^{\text{sup}}$ 如下:

$$\begin{aligned} x_{S^1 \leftarrow S^2}^{\text{sup}} &= \varphi_{s^1}(x_{Sc}^j) \\ x_{S^2 \leftarrow S^1}^{\text{sup}} &= \varphi_{s^2}(x_{Sc}^i) \end{aligned} \quad (8)$$

同时, x_{Ss}^j 和 x_{Ss}^i 嵌入到共享空间 $x_m^{S^1 * S^2}$ 如下:

$$x_m^{S^1 * S^2} = \begin{bmatrix} x_m^{S^1} \\ x_m^{S^2} \end{bmatrix} = \begin{bmatrix} x_{S^1 \leftarrow S^2}^{\text{sup}} x_{Ss}^j \\ x_{S^2 \leftarrow S^1}^{\text{sup}} x_{Ss}^i \end{bmatrix} \quad (9)$$

其中,共享空间 $x_m^{S^1 * S^2}$ 优化如下:

$$\arg\max I(x_m^{S^1}, x_m^{S^2}) \quad (10)$$

需要注意的是,处理多源域问题时(例如 T , S^1 和 S^2),除了需要在共享空间内部优化 $[x_m^T, x_m^{S^1}]$ 和 $[x_m^{S^1}, x_m^{S^2}]$ 外,还需要优化 $[x_m^{T * S^1}, x_m^{S^1 * S^2}]$, 从而得到从目标域 T 到源域 S^2 的传递式遥远域适应如下:

$$\begin{aligned} \arg\max_{\psi_{T, S^2}} & \{ I(x_m^T, x_m^{S^1}) + I(x_m^{S^1}, x_m^{S^2}) \} + \\ & I(x_m^{T * S^1}, x_m^{S^1 * S^2}) \} \end{aligned} \quad (11)$$

同理,基于支持样本可得到传递样本,因此传递域表示如下:

$$\{ x_m^{T * S^1}, x_m^{S^1 * S^2}, x_m^{S^2 * S^3}, \dots, x_m^{S^{N-1} * S^N} \} \quad (12)$$

由此,从 T 到 S^N 的遥远域传递式域适应优化如下:

$$\begin{aligned} \arg\max_{\psi_{T, S^N}} & \{ I(x_m^T, x_m^{S^1}) + \dots + I(x_m^{S^{N-1}}, x_m^{S^N}) \} + \\ & [I(x_m^{T * S^1}, x_m^{S^1 * S^2}) + \dots + I(x_m^{S^{N-2} * S^{N-1}}, x_m^{S^{N-1} * S^N})] \} \end{aligned} \quad (13)$$

通过 ψ_{T, S^N} , 遥远域 S^N 被探索并用于增强目标域小样本的种类。

2 异构域样本分布联合匹配

在衡量域之间的分布差异时,边缘分布和条件分布有着不同的影响权重。受此启发,为了获得更可靠的分布匹配性能,提出了一种分布联合匹配机制,该机制关注异构数据的边缘分布和条件分布,并针对不同的数据集自适应调整两个分布的权重。因此,所设计的分布联合匹配机制在不同工况下会具有更强的适应性。将分布差异嵌入到最大均值差异模型,表示如下:

$$\begin{aligned} M(x_{Sd}, x_{Td}) &= \\ & \sum_{i=1}^{n_s} \sum_{j=1}^{n_t} [D_m(x_{Sd}^i, x_{Td}^j) + \lambda D_c(x_{Sd}^i, x_{Td}^j)] = \\ & \| \frac{1}{n_s} \sum_{i=1}^{n_s} E(x_{Sd}^i) - \frac{1}{n_t} \sum_{j=1}^{n_t} E(x_{Td}^j) \|_H^2 + \\ & \lambda \| \frac{1}{n_s} \sum_{i=1}^{n_s} E(x_{Sd}^i)^{(y_i)} - \frac{1}{n_t} \sum_{j=1}^{n_t} E(x_{Td}^j)^{(y_j)} \|_H^2 \end{aligned} \quad (14)$$

其中, n_s 和 n_t 分别表示待评估的异构域的样本数量。 $x_{Sd}^{(y_i)}$ 表示 x_{Sd} 的条件分布。 D_m 和 D_c 分别表示 x_{Sd} 和 x_{Td} 的边缘分布和条件分布。 $\| \bullet \|_H$ 表示希尔伯特再生空间, λ 是超参数。令 $D_M = [\lambda, M(x_{Sd}, x_{Td})]$, 通过最大化后验概率,可以得到优化后的 λ 如下:

$$\begin{aligned} \lambda^* &= \arg \max_{\lambda > 0} \prod_{i=1}^z p(\lambda_i | D_M) = \\ & \arg \max_{\lambda > 0} \prod_{i=1}^z \frac{p(D_M | \lambda_i) P(\lambda_i)}{p(D_M)} \end{aligned} \quad (15)$$

其中, $p(\lambda_i)$ 表示 λ_i 的先验概率, z 表示其他工况中样本集的数量。 $p(D_M)$ 等价于系数,可以通过核函数求得。

3 实验验证

在本节,验证了传递式探索策略以及工业小样本增强的有效性。数据集来自世界公认的田纳西-伊斯

曼仿真工业流程数据集,该工业流程属于分类建模^[27]。实验中使用的故障数据包括 No. 1, No. 8, No. 13, No. 14 和 No. 21,更多故障数据细节见文献[28]。同时,参与训练的源域样本和目标域样本分别为 500 个和 30 个,测试样本为 24 个。为了避免随机性,所有实验结果都是取 10 次实验结果的平均值作为最终结果。

实验中,利用 Accuracy, Recall 和 Precision 评估文中方法的故障诊断表现。

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{FP} + \text{TN} + \text{TP} + \text{FN}}$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}}$$

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (16)$$

其中,TP,TN,FP 和 FN 分别表示真阳性、真阴性、假阳性和假阴性。

实验设置:为了评估遥远域传递式探索的表现,将文中方法与各个领域具有代表性的域适应方法作对比:单源域适应、多源域适应以及遥远域适应。为了避免不同数量的训练样本对方法评估产生影响,保证上述方法的训练样本数量是一致的。另外,对于单源域适应,选择表现最好的域适应结果作为最终结果。对于多源域适应,采用了对不同数量的源域建模的策略。对于遥远域适应,选择不同的源域作为初始域来探索目标域^[29]。

表 1 对比方法在不同数据集下的故障诊断表现


Ref. [17]	No. 1	No. 8	No. 13	No. 14	No. 21	Ref. [14]	No. 1	No. 8	No. 13	No. 14	No. 21
No. 1	—	64.2	56.2	55.1	60.2	No. 1	—	66.2	59.2	58.7	61.1
No. 8	68.7	—	58.0	58.6	69.6	No. 8	68.9	—	59.4	59.2	69.2
No. 13	61.2	60.7	—	65.6	69.2	No. 13	62.1	62.1	—	67.2	69.0
No. 14	60.1	58.2	66.6	—	64.8	No. 14	61.7	60.2	64.2	—	65.5
No. 21	65.6	67.7	68.1	62.1	—	No. 21	64.3	68.7	69.0	64.5	—
Avg.	63.9	62.7	62.2	60.4	66.0	Avg.	64.3	64.3	63.0	62.4	66.2
Ref. [15]	No. 1	No. 8	No. 13	No. 14	No. 21	Ref. [18]	No. 1	No. 8	No. 13	No. 14	No. 21
No. 1	—	68.4	64.1	63.0	68.8	No. 1	—	68.4	63.4	63.7	68.4
No. 8	70.3	72.4	68.5	68.7	66.4	No. 8	69.3	—	64.6	72.4	69.6
No. 13	64.5	64.0	71.7	66.7	65.2	No. 13	68.5	65.5	—	70.1	64.3
No. 14	65.1	66.7	65.2	70.5	63.0	No. 14	65.3	68.7	69.7	—	70.1
No. 21	64.7	65.0	67.2	63.3	69.8	No. 21	66.0	71.1	69.8	68.8	—
Avg.	66.2	67.3	67.3	66.4	66.6	Avg.	67.3	68.4	66.9	68.8	68.1
Ref. [19]	No. 1	No. 8	No. 13	No. 14	No. 21	Ours	No. 1	No. 8	No. 13	No. 14	No. 21
No. 1	—	70.3	69.5	68.5	71.4	No. 1	—	79.4	79.2	78.1	80.2
No. 8	74.5	—	69.7	73.3	69.5	No. 8	76.5	—	77.9	77.0	76.0
No. 13	70.6	72.5	—	72.4	70.0	No. 13	80.1	77.5	—	78.6	76.7
No. 14	67.7	73.7	72.4	—	72.2	No. 14	78.3	78.0	77.0	—	79.2
No. 21	68.5	72.2	71.7	72.7	—	No. 21	78.5	79.2	77.2	79.2	—
Avg.	70.3	72.2	70.8	71.7	70.8	Avg.	78.4	78.5	77.8	78.2	78.0

注:表中实验结果为 Accuracy, Recall 和 Precision 的平均值。


从表 1 可以看出,在不同数据集下,文中方法与上述方法相比有很好的表现,特别是当源域和目标域有显著差异时。具体而言,从图 1(a)可以看出,数据 No. 1 与数据 No. 13, No. 14 存在显著差异,这导致上述提到的方法在这两组数据集中有较差的域适应表现(No. 1 与 No. 13 以及 No. 1 与 No. 14)。相比之下,所

提方法在这两组数据集中的平均精度为 78.65%,与文献[18–19]相比分别提高了 23.8% 和 14.0%。这归功于传递式探索的策略,其利用了中间域的有用信息来辅助对远域样本的探索。值得注意的是,从图 1(b)可以看出,使用文中方法探索遥远域后,所有源域与目标域之间的相关性都有所提高,特别是对于差异

较大的域,这进一步验证了文中方法的有效性。



(a)原始域



(b)使用文中方法探索后的域

图1 不同域相关性的可视化

4 结束语

通过提出基于传递式领域自适应的异构样本增强方法,实现了异构场景下的小样本增强。该网络允许工况差异较大的异构源域样本,借助中间领域的样本知识,用于当前工况中目标域小样本的增强。这也意味着,该方法拓展了领域自适应方法在小样本增强领域的应用范围。在田纳西-伊斯曼仿真工业流程开展了对比实验来验证该方法的有效性。实验结果表明,与最先进的方法相比,该方法在异构领域自适应以及小样本增强的实验中均取得了最优表现。该方法能够有效地实现异构域样本迁移增强。

参考文献:

- [1] 徐丽燕,徐 康,黄兴挺,等. 基于 Transformer 的时序数据异常检测方法[J]. 计算机技术与发展,2023,33(3):152-160.
- [2] 李贝贝,彭 力,戴菲菲. 结合马氏距离与自编码器的网络流量异常检测方法[J]. 计算机工程,2022,48(4):133-142.
- [3] HAN C, LEI Y, XIE Y, et al. Learning smooth representations with generalized softmax for unsupervised domain adaptation[J]. Information Sciences, 2021, 544(1):415-426.
- [4] 方 涛,刘 涛,李 龙. 基于自适应步长 FOA-SVM 算法的卡泵故障诊断[J]. 计算机技术与发展,2021,31(4):153-157.
- [5] JIA X, FENG X, LIU S. Dual non-autonomous deep convolutional neural network for image denoising[J]. Information Sciences, 2021, 572(1):263-276.
- [6] TENG S, WU N, ZHU H, et al. SVM-DT-based adaptive and collaborative intrusion detection[J]. IEEE/CAA J. Automatica Sinica, 2018, 5(1):108-118.
- [7] 郭丽丽,丁世飞. 深度学习研究进展[J]. 计算机科学, 2015, 42(5):28-33.
- [8] LIU B. Morphological attribute profile cube and deep random forest for small sample classification of hyperspectral image[J]. IEEE Access, 2022, 8(1):117096-117108.
- [9] MEASE D, WYNER A J, BUJA A. Boosted classification trees and class probability/quantile estimation[J]. Machine Learning Research, 2007, 8(3):409-439.
- [10] YEN S, LEE Y. Cluster-based under-sampling approaches for imbalanced data distributions[J]. Expert. Syst. Appl., 2009, 36(1):5718-5727.
- [11] KINGMA D P, WELING M. Auto-encoding variational bayes[J]. arXiv:1312.6114, 2013.
- [12] LIU J, QU F, HONG X, et al. A small-sample wind turbine fault detection method with synthetic fault data using genera-

- tive adversarial nets[J]. IEEE Trans. Ind. Informat, 2019, 15(7):3877–3888.
- [13] JUNG H G, LEE S W. Few-shot learning with geometric constraints[J]. IEEE Trans. Neural Netw. Learn. Syst, 2020, 31(11):4660–4672.
- [14] LONG M, WANG J, DING G, et al. Transfer feature learning with joint distribution adaptation[C]//Proceedings of the IEEE international conference on computer vision. Sydney: IEEE, 2013:2200–2207.
- [15] LI H, PAN S, WAN R, et al. Heterogeneous transfer learning via deep matrix completion with adversarial kernel embedding[C]//Proceedings of the AAAI conference on artificial intelligence. Hawaii: AAAI, 2019:8602–8609.
- [16] MANSOUR Y, MOHRI M, ROSTAMIZADEH A. Domain adaptation with multiple sources[C]//Advances in neural information processing systems 21. Anchorage: NIPS, 2009: 1041–1048.
- [17] PAN S J, TSANG I W, KWOK J T, et al. Domain adaptation via transfer component analysis[J]. IEEE Trans. Neur. Net. Lear, 2011, 22(2):199–210.
- [18] TAN B. Transitive transfer learning[C]//Proceedings of the 21th ACM SIGKDD international conference on knowledge discovery and data mining. Sydney: KDD, 2015:1155–1164.
- [19] TAN B. Distant domain transfer learning[C]//Proceedings of the AAAI conference on artificial intelligence. San Francisco: AAAI, 2017:2604–2610.
- [20] LIU J, REN Y. A general transfer framework based on industrial process fault diagnosis under small samples[J]. IEEE Trans. Ind. Inform, 2021, 17(9):6073–6083.
- [21] YANG B. Multi-source transfer learning network to complement knowledge for intelligent diagnosis of machines with unseen faults[J]. Mechanical Systems and Signal Processing, 2022, 162:1–19.
- [22] PENG X, BAI Q, XIA X, et al. Moment matching for multi-source domain adaptation[J]. arXiv:1812.01754v4, 2019.
- [23] ZHU Y, ZHUANG F, WANG D. Aligning domain-specific distribution and classifier for cross domain classification from multiple sources[C]//Proceedings of the AAAI conference on artificial intelligence. Hawaii: AAAI, 2019:5989–5996.
- [24] PAN S, YANG Q. A survey on transfer learning[J]. IEEE Trans. Knowl. Data Eng, 2010, 22(10):1345–1359.
- [25] RESHEF D, RESHEF Y, FINUCANE H, et al. Detecting novel associations in large data sets[J]. Science, 2011, 334(6062):1518–1524.
- [26] REN Y. HSELL-Net: a heterogeneous sample enhancement network with lifelong learning under industrial small samples[J]. IEEE Transactions on Cybernetics, 2022, 53(2):793–805.
- [27] 吴卓卓. 基于田纳西—伊斯曼过程故障检测方法研究[D]. 南昌: 华东交通大学, 2017.
- [28] 边双微. 田纳西—伊斯曼化工过程的故障诊断[D]. 武汉: 华中科技大学, 2012.
- [29] XU R, CHEN Z, ZUO W, et al. Deep cocktail network: multi-source unsupervised domain adaptation with category shift[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Salt Lake City: IEEE, 2018: 3964–3973.