



# 面向工业监控典型监督任务的深度迁移学习方法: 现状、挑战与展望

柴铮<sup>1</sup>, 汪嘉业<sup>1</sup>, 赵春晖<sup>1\*</sup>, 丁进良<sup>2</sup>, 孙优贤<sup>1</sup>

1. 浙江大学控制科学与工程学院, 杭州 310027

2. 东北大学流程工业综合自动化国家重点实验室, 沈阳 110819

\* 通信作者. E-mail: chhzha@zju.edu.cn

收稿日期: 2022-08-19; 修回日期: 2022-11-13; 接受日期: 2022-12-19; 网络出版日期: 2023-05-12

国家自然科学基金杰出青年基金 (批准号: 62125306)、国家自然科学基金重点项目 (批准号: 62133003) 和流程工业综合自动化国家重点实验室开放课题基金 (批准号: 2020-KF-21-07) 资助

**摘要** 基于深度迁移学习的工业监控方法在近年来获得了大量研究关注, 特别是在以故障诊断、软测量等为代表的工业监控典型监督任务中. 通过挖掘与迁移相似源域的知识来完成对目标域的建模, 这类方法为实际工业场景中变工况等原因导致的跨域监控问题提供了新的思路. 本文系统梳理了面向工业监控典型监督任务的深度迁移学习方法, 并将其分为基于模型迁移、基于样例迁移与基于特征迁移的工业监控方法. 在此基础上, 对不同类方法的基本研究思想在故障诊断与软测量任务中的研究进展进行了详细阐述. 随后, 从实际工业场景的复杂欠数据问题、可迁移性的量化与负迁移问题、工业过程的动态特性问题等角度, 指出了当前基于深度迁移学习的工业监控研究中存在的挑战, 并对该领域的未来研究方向做出进一步展望.

**关键词** 迁移学习, 深度学习, 跨域工业监控, 故障诊断, 软测量

## 1 引言

随着现代工业不断向高端化、复杂化趋势发展, 系统运行的安全性、可靠性面临着更大挑战<sup>[1~3]</sup>. 作为保障工业安全可靠运行的必要手段, 以数据驱动的故障诊断与软测量为典型代表的工业监控任务在近年来获得了大量关注<sup>[4~6]</sup>. 故障诊断旨在识别出当前系统所发生的故障类型, 而软测量往往利用过程中较易测得的变量实现对质量变量的回归建模. 其中, 质量变量一般指在工业过程中与产品质量紧密相关的、需加以监控的过程变量, 这类变量往往具有获取成本较高、测量具有一定延迟等特点<sup>[7]</sup>. 由于这两类任务往往基于工业过程历史运行过程中积累的标注样本, 有监督机器学习方法目前在这两

**引用格式:** 柴铮, 汪嘉业, 赵春晖, 等. 面向工业监控典型监督任务的深度迁移学习方法: 现状、挑战与展望. 中国科学: 信息科学, 2023, 53: 821-840, doi: 10.1360/SSI-2022-0328

Chai Z, Wang J Y, Zhao C H, et al. Deep transfer learning methods for typical supervised tasks in industrial monitoring: state-of-the-art, challenges, and perspectives (in Chinese). Sci Sin Inform, 2023, 53: 821-840, doi: 10.1360/SSI-2022-0328

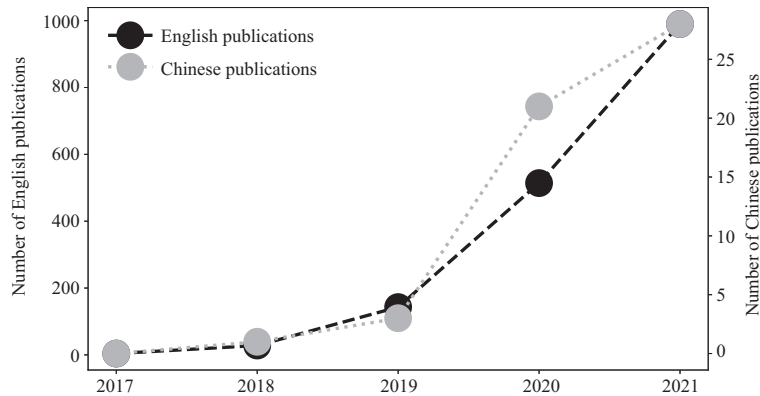


图 1 本领域近五年文献数量发展趋势

Figure 1 Publication numbers in this field in the past five years

类任务中得到了广泛应用<sup>[8~10]</sup>. 近十年来, 得益于深度学习算法的蓬勃发展与各类工业传感器的广泛部署, 基于深度学习的方法在工业监控领域大放异彩. 例如, 基于各类卷积神经网络<sup>[11~14]</sup>、递归神经网络<sup>[15, 16]</sup>与 Transformer<sup>[17]</sup>的方法在工业故障诊断、工业过程软测量任务中相较传统机器学习方法获得了显著性能提升. 然而, 这些方法往往假设训练数据与测试数据具有相同的分布<sup>[18]</sup>. 在实际工业场景中, 操作条件改变、给料变化等复杂工况现象<sup>[19~22]</sup>导致了显著的训练与测试数据分布不一致问题. 这一问题为传统深度学习方法的广泛应用带来了挑战.

近年来, 随着深度迁移学习方法的兴起, 通过挖掘与迁移相似源域的知识完成对目标域的建模, 为解决上述问题提供了新的思路<sup>[23]</sup>. 一般来说, 深度迁移学习方法以神经网络为基础, 通过利用源域中的数据或模型, 进一步结合目标域中的有限数据, 以完成知识的迁移过程. 不同于传统基于机器学习的工业监控方法对不同域单独建模并决策, 基于深度迁移学习的工业过程监控方法往往利用源域中的知识来协助目标域中模型的建立. 这一过程本质上模仿了人类可以利用从历史经验中学习到的知识轻松适应新的场景这一能力. 基于此理念, 近年来深度迁移学习方法在工业监控领域中受到了大量关注. 在谷歌学术网站<sup>1)</sup>中分别以“deep transfer learning”“fault diagnosis”OR “soft sensor”和“深度迁移学习”“故障诊断”OR “软测量”作为组合关键词进行中英文文献搜索, 可以得到相关领域历年中英文发表文章数量的发展趋势. 如图 1 所示, 在过去的五年中, 本领域的相关研究经历了飞速发展, 其中, 英文文献数量从 2017 年的 4 篇增长至 2021 年的 990 篇, 中文文献数量从 0 篇增长至 28 篇, 显示出相关学者对本领域的关注不断提升. 当前, 国内外学者针对基于深度迁移学习的故障诊断与软测量问题进行了大量的研究, 也有一些工作对相关研究进行了整理与综述. 例如, 文献 [23] 根据传统迁移学习中的不同任务场景, 将迁移学习分为归纳式、直推式以及无监督的迁移学习. Tan 等<sup>[24]</sup>根据在深度迁移学习任务中使用的具体方法不同, 将深度迁移学习进一步分为基于样例、基于映射、基于网络与基于对抗的方法. 在机械设备的故障诊断方面, 目前已有若干前人工作<sup>[25, 26]</sup>. 例如, Li 等<sup>[27]</sup>对深度迁移学习的分类与工业应用场景进行了总结与综述. 此外, 针对流程工业的软测量问题, Curreri 等<sup>[28]</sup>根据迁移学习在不同类型工业过程中的应用进行了梳理与讨论. Maschler 等<sup>[29]</sup>对深度迁移学习在工业自动化领域的若干研究进行了简要回顾, 并讨论了该类方法在印刷电路组件制造等任务中的应用. 总体来看, 目前工业领域中的大多数综述工作主要关注机械设备的故障诊断问题, 从深度迁移学习的角度出发对工业监控中的工业故障诊断与工业过程软测量领域研究进行梳理总结的文章相对

1) <https://scholar.google.com/>.

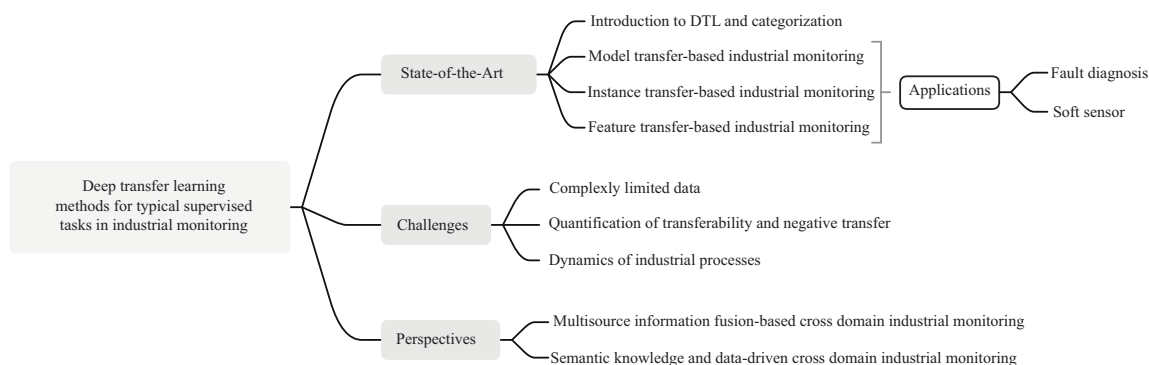


图 2 本文的组织结构

Figure 2 The outline of this survey

较少. 基于此, 本文面向工业监控中的两种典型有监督任务, 即故障诊断与软测量, 对深度迁移学习方法展开了相关综述. 其中, 故障诊断和软测量任务一方面对提高系统安全性、提升产品质量有重要意义; 另一方面其建模往往基于工业过程历史运行过程中积累的有监督样本, 属于工业监控中有监督学习的典型代表. 此外, 在这两个场景中的深度迁移学习相关研究也在近年来获得了大量学者的研究关注, 属于工业监控领域的热门研究方向之一.

本文的结构如图 2 所示. 首先, 对基于深度迁移学习的工业监控方法现状进行介绍. 其中, 先对深度迁移学习进行概述, 进而将面向工业监控典型监督任务的深度迁移学习方法分为 3 个类别, 即基于模型、基于样例与基于特征迁移的工业监控方法. 在每种类别下分别对故障诊断与软测量两种应用场景进行介绍. 其次, 从跨域工业监控中的复杂欠数据问题、可迁移性的量化与负迁移问题, 以及工业过程的动态特性问题等角度, 对当前基于深度迁移学习的工业监控方法所面临的挑战进行了分析. 最后对本领域的未来研究方向, 包括多源信息融合的跨域工业监控以及语义知识与数据联合驱动的跨域工业监控做出进一步展望.

## 2 面向工业监控典型监督任务的深度迁移学习方法研究现状

本节将首先对深度迁移学习进行概述. 随后, 将基于深度迁移学习的工业监控方法分为基于模型、基于样例与基于特征迁移的方法, 进而对 3 种类别的研究现状进行介绍.

### 2.1 深度迁移学习概述与分类

迁移学习是机器学习的一个重要分支, 旨在解决机器学习场景中的数据分布不一致、数据不足等问题 [23, 24, 30]. 本小节首先对迁移学习及深度迁移学习进行概述, 进而对基于深度迁移学习的工业监控方法进行分类.

#### 2.1.1 迁移学习

本小节对迁移学习中的若干基本概念进行介绍. 首先介绍迁移学习中域与任务的定义.

在迁移学习场景中, 一个域 (domain) 被定义为  $\mathcal{D} = \{\mathcal{X}, P(X)\}$ . 其中,  $\mathcal{X}$  表示特征空间,  $P(X)$  代表数据集  $X$  的边缘分布, 其中数据集  $X$  由  $N$  条样本构成, 即  $X = \{x|x_i \in \mathcal{X}, i = 1, 2, \dots, N\}$ . 进而, 一个任务 (task) 被定义为  $\mathcal{T} = \{\mathcal{Y}, f(\cdot)\}$ , 其中  $\mathcal{Y}$  表示标签空间,  $f(\cdot)$  是映射函数. 从概率的角度看, 映射函数  $f(\cdot)$  也可以写成条件分布函数  $P(y|x)$  的形式. 基于如上定义, 给定若干源域及其任务、目标域

及其任务, 迁移学习是指充分利用源域中的知识并将其迁移至目标域中, 从而提升目标域模型性能的一种学习范式<sup>[23]</sup>.

注意到, 传统的机器学习算法假设源域  $\mathcal{D}_S$  与目标域  $\mathcal{D}_T$  相同, 即  $\mathcal{D}_S = \mathcal{D}_T$ , 同时假设源域中的任务  $\mathcal{T}_S$  与目标域中的任务  $\mathcal{T}_T$  相同, 即  $\mathcal{T}_S = \mathcal{T}_T$ . 在实际的工业场景中, 这两个假设往往难以严格保证. 就假设  $\mathcal{D}_S = \mathcal{D}_T$  而言, 例如, 在多速率系统中, 具有不同采样速率的变量组成了不同的域, 不同的域具有不同的特征空间, 即  $\mathcal{X}_S \neq \mathcal{X}_T$ ; 再如, 不同操作条件下工业过程采集的数据往往具有不同边缘分布, 即  $P(X_S) \neq P(X_T)$ . 就假设  $\mathcal{T}_S = \mathcal{T}_T$  而言, 当两个域的标签空间  $\mathcal{Y}$  或映射函数  $P(y|x)$  存在差异时, 有  $\mathcal{T}_S \neq \mathcal{T}_T$  成立. 在跨域与跨任务迁移场景中, 一般来说仅当不同域间或不同任务间存在相关性与相似性时才具有可迁移性<sup>[23]</sup>. 例如, 在跨任务迁移中, 两个任务同属于故障诊断, 但不同域发生的故障类型不完全一致; 或两个任务同属于软测量, 但待预估的质量变量分布存在差异时, 有  $\mathcal{T}_S \neq \mathcal{T}_T$ . 若不同域间或任务间差异过大甚至完全不同, 则可能会产生负迁移现象, 从而影响模型效果<sup>[23,31]</sup>. 综上, 当不同域或不同任务间具有相关性与相似性且下式成立时, 有必要进行迁移学习:

$$\mathcal{D}_S \neq \mathcal{D}_T \text{ 或 } \mathcal{T}_S \neq \mathcal{T}_T. \quad (1)$$

### 2.1.2 深度迁移学习

深度迁移学习是迁移学习中一类特殊且重要的方法, 其出现和流行主要归因于深度学习的发展<sup>[32]</sup>. 近年来, 得益于深度神经网络的复杂特征学习能力与灵活的结构设计优势, 深度神经网络方法在工业监控领域受到了大量关注. 具体而言, 对于由  $\{\mathcal{D}_S, \mathcal{D}_T, \mathcal{T}_S, \mathcal{T}_T\}$  形式描述的迁移学习任务, 当映射函数  $f_T(\cdot)$  由深度神经网络来实现时, 迁移学习任务将转化为深度迁移学习任务<sup>[24]</sup>.

### 2.1.3 基于深度迁移学习的工业监控方法分类

近年来, 由于深度迁移学习方法在多个领域获得了众多研究关注, 关于深度迁移学习方法的分类亦有若干工作. 然而, 在基于深度迁移学习的工业监控领域, 目前相关工作较少. 受 Tan 等<sup>[24]</sup> 工作启发, 按在迁移学习中“迁移什么”与“如何迁移”的准则, 本文进一步将基于深度迁移学习的工业监控方法分为三类: 基于模型迁移、基于样例迁移与基于特征迁移的工业监控方法. 第 2.2~2.4 小节将分别对这三部分进行研究现状综述与分析.

## 2.2 基于模型迁移的工业监控方法

顾名思义, 在基于模型迁移的工业监控方法中, 往往将神经网络模型作为对象来进行跨域迁移. 此类方法将神经网络本身作为知识, 将源域中训练得到的神经网络部分结构与参数迁移至目标域中作为目标域神经网络模型的初始化, 进而基于目标域数据对模型进一步调整. 例如, 如图 3 所示, 当源域的标签空间是目标域标签空间的子集时, 可利用源域模型中可迁移参数作为目标域模型的部分初始化, 新增参数进行随机初始化, 随后基于目标域数据进行目标域模型的微调. 其中, 图 3 橘色部分所示为目标域模型新增神经元及对应新增参数. 因此, 基于模型迁移的工业监控方法往往遵循预训练与微调的学习范式, 即利用目标域的少量数据  $\{X_T, Y_T\}$  对源域得到的模型参数  $\theta_S$  进行进一步微调以极小化目标域上的风险  $\mathcal{R}_T$ :

$$\begin{aligned} \min_{\theta_T} \mathcal{L}(\theta_T) &= \mathcal{R}_T(f_T(X_T, \theta_T), Y_T) \\ \text{s.t. } \theta_T &\text{ 由 } \theta_S \text{ 中的部分参数初始化,} \end{aligned} \quad (2)$$

其中  $\mathcal{L}(\theta_T)$  表示目标域模型的损失函数,  $f_T$  表示目标域模型,  $\theta_T$  表示目标域的模型参数.

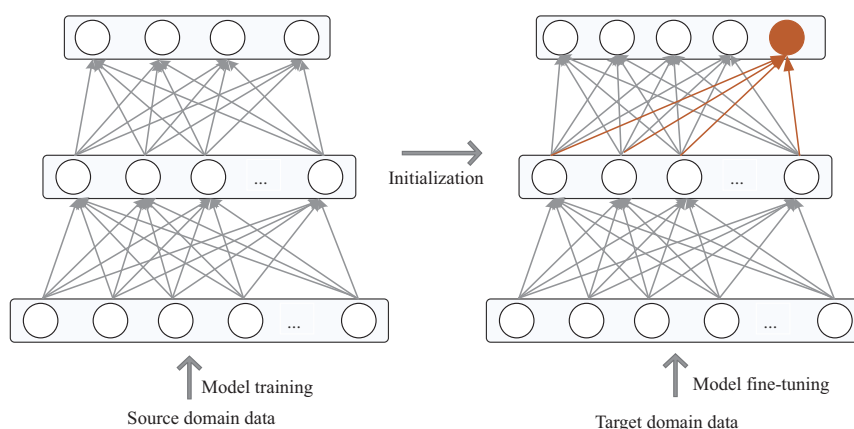


图 3 (网络版彩图) 基于模型迁移的工业监控方法示意图

Figure 3 (Color online) Illustration of model transfer-based industrial monitoring




图 4 基于模型迁移的工业监控方法发展脉络

Figure 4 A timeline of model transfer-based industrial monitoring methods

近年来, 由于其简单有效的训练方式, 基于模型迁移的方法已经在自然语言处理和计算机视觉等领域大放异彩<sup>[33~35]</sup>, 而目前流行的 PyTorch<sup>2)</sup> 与 TensorFlow<sup>3)</sup> 等深度学习平台也提供了诸多友好的深度模型迁移实践教程, 这进一步降低了模型迁移方法的使用门槛. 在工业监控领域, 由于充足的故障标注样本或软测量标注样本往往十分稀缺, 这种基于少量目标域标注样本微调的方式在实际的工业过程中非常适用, 因而在近年来获得了大量的研究关注. 图 4 展示了基于模型迁移的工业监控方法发展脉络, 其中, 时间线以上表示工业故障诊断相关工作, 时间线以下表示工业软测量相关工作. 由图可以看出, 基于模型迁移的故障诊断相关研究相对起步较早, 而软测量相关研究从 2021 年开始吸引相关学者的注意. 接下来, 将对这两部分研究分别进行回顾.

### 2.2.1 基于模型迁移的工业故障诊断

如前文所述, 基于模型迁移的方法主要面向目标域中标注样本稀缺的情况, 因此, 在历史工况中标注样本充足而新的目标域中标注样本难以大量采集的情况下, 这类方法将具有较大实用价值. 例如, Zhang 等<sup>[36]</sup> 较早地设计了一种基于模型迁移的故障诊断方法, 该方法首先在数据量丰富的源域中进行模型构建. 进而, 在数据量较少的目标域中, 首先将源域模型的输出层按目标域的任务情况进行调整, 进而利用有限的目标域数据对整个模型进行参数微调. 实验结果表明, 相比于直接在目标域中训练且不进行任何迁移的神经网络, 基于模型迁移的方法在多种故障类别上获得了平均 6% 的诊断精度

2) [https://pytorch.org/tutorials/beginner/transfer\\_learning\\_tutorial.html](https://pytorch.org/tutorials/beginner/transfer_learning_tutorial.html).

3) [https://www.tensorflow.org/tutorials/images/transfer\\_learning](https://www.tensorflow.org/tutorials/images/transfer_learning).

提升. 类似地, Han 等<sup>[37]</sup>提出了一种基于卷积神经网络迁移的方法, 并通过冻结不同的源域神经网络层, 提出了 3 种预训练与微调的策略. 最后分别在开源数据与真实数据中对不同的策略进行了详细对比. Shao 等<sup>[38]</sup>针对工业系统中的红外热图像数据, 通过使用随机池化与 Leaky ReLU 激活函数, 设计了一种改进的迁移卷积神经网络模型来解决跨域故障诊断问题.

除了此类方法, 受计算机视觉领域中基于 ImageNet<sup>[39]</sup>预训练模型方法的启发, 许多工业故障诊断的工作事先将振动信号预处理为图像类型, 进而在目标域中对 ImageNet 预训练模型进行微调以提高目标域中的故障分类性能. 例如, Shao 等<sup>[40]</sup>将在 ImageNet 中预训练的 VGG-16 神经网络<sup>[41]</sup>作为源域模型并将若干浅层卷积层进行参数冻结, 将在目标域中收集的机械振动数据处理为时频图像以进一步微调模型, 模型的输出层则根据目标域的实际输出标签空间进行调整. 结果表明, 这种预训练的方式实现了大约 6% 的分类性能的提升. 此外, Chakraborty 等<sup>[42]</sup>进一步针对在 ImageNet 上预训练得到的 AlexNet, Inception V3, GoogLeNet 等经典卷积神经网络进行了故障诊断性能对比, 发现基于 AlexNet 的迁移卷积神经网络在公开数据集中获得了最佳性能.

### 2.2.2 基于模型迁移的工业过程软测量

在故障诊断任务之外, 基于模型迁移的工业过程软测量在近年来也获得了一些研究关注. 例如, Curreri 等<sup>[43]</sup>基于模型迁移方法, 在硫磺回收过程中的硫化氢与二氧化硫浓度软测量任务中开展了针对递归神经网络与长短期记忆网络的可迁移性实验. 此外, 由于实际工业过程中获得准确的标注数据较为困难, Hsiao 等<sup>[44]</sup>针对炼油装置中的 C4 分离塔, 首先利用 MATLAB 软件<sup>4)</sup>对过程进行仿真, 从而产生大量仿真数据以完成对源域的建模. 进而, 利用在真实工厂中的少量数据对模型进行微调, 从而利用真实的过程知识来修正模型以提高预测精度.

### 2.3 基于样例迁移的工业监控方法

不同于基于模型的方法, 基于样例迁移的工业监控方法通常针对样本本身进行迁移学习建模. 如图 5 所示, 样例迁移方法往往通过对源域与目标域样本的权重学习, 在建模过程中发掘跨域可迁移的样本并在模型迭代过程中不断对可迁移性较高的样本给予较高权重, 进而完成迁移过程. 例如, 在图 5 中, 首先利用源域与目标域数据进行模型训练, 进而基于模型的预测结果对原始数据进行加权, 从而对模型进一步更新, 并以此类推. 这一思想一定程度上受 TrAdaBoost 方法<sup>[45]</sup>启发. 在 TrAdaBoost 算法中, 有标记的源域与目标域样本共同组合成训练数据集, 进而在模型迭代过程中, 该方法为源域和目标域样本动态分配不同的权重, 以实现可迁移样本的学习. 具体地, 记源域与目标域样本数量分别为  $N_S$  与  $N_T$ , 样本  $x_i$  经目标域模型的输出与真实标签分别为  $h_t(x_i)$  与  $c(x_i)$ , 经第  $t+1$  轮迭代后的样本权重  $w_i^{t+1}$  可由下式计算:

$$w_i^{t+1} = \begin{cases} w_i^t \beta^{|h_t(x_i) - c(x_i)|}, & 1 \leq i \leq N_S, \\ w_i^t \beta^{-|h_t(x_i) - c(x_i)|}, & N_S \leq i \leq N_S + N_T, \end{cases} \quad (3)$$

其中  $\beta \leq 1$  为超参数,  $\beta_t = \epsilon_t / (1 - \epsilon_t)$ ,  $\epsilon_t < 1/2$  为目标域样本上的预测误差.

由上可以看到, 在迭代过程中, 具有较大分类误差的源域样本被认为与目标域较不相似, 因此将在下轮迭代中被赋予较小权重; 而具有较大误差的目标域样本将被赋予较大权重, 以保证模型对目标域中困难样本的识别能力.

4) <https://www.mathworks.com/>.



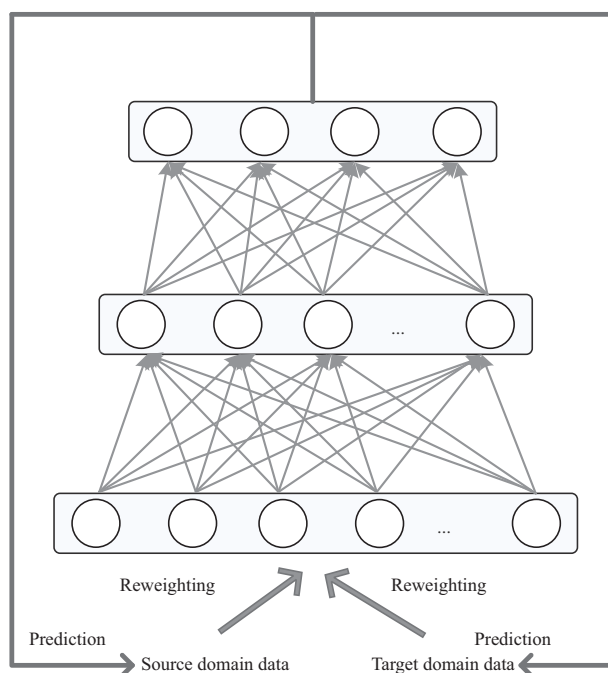


图 5 基于样例迁移的工业监控方法示意图

Figure 5 Illustration of instance transfer-based industrial monitoring




图 6 基于样例迁移的工业监控方法发展脉络

Figure 6 A timeline of instance transfer-based industrial monitoring methods

近年来, 基于样例迁移的方法在工业监控中受到了广泛关注, 图 6 展示了基于样例迁移的工业监控方法发展脉络. 由图 6 可以看出, 不同于模型迁移方法, 基于样例迁移的工业软测量方法早在 2016 年便吸引了相关学者的注意. 接下来将分别按工业故障诊断与工业软测量应用, 对基于样例迁移的工业监控方法进行讨论.

### 2.3.1 基于样例迁移的工业故障诊断

Pan 等<sup>[46]</sup> 基于深度信念网络与 TrAdaBoost 方法, 提出了一种对高压断路器的跨域故障诊断方法. 该方法基于高压断路器弹簧机构的电磁系统数学模型, 利用仿真的方式生成了大量辅助样本. 进而, 利用基于 TrAdaBoost 的方法动态地为辅助样本与目标域样本施加权重, 从而实现样例迁移. 类似地, Zhang 等<sup>[47]</sup> 设计了一种基于样本的集成深度迁移学习网络. 在该方法中, 首先利用迭代训练的方式学习多个堆叠自编码器, 从而筛选出与目标域有关的源域样本. 进而, 基于在源域上训练完成的多个堆叠自编码器, 利用目标域的训练样本进行模型集成, 最后得到测试样本的诊断结果. 该方法

的效果通过真实的滚珠螺杆案例进行了验证. 此外, Lee 等<sup>[48]</sup>设计了一种多目标的样例加权迁移方法. 在该方法中, 通过同时计算源域与目标域的 Kullback-Leibler 散度 (KL 散度) 差异与最大平均差异 (maximum mean discrepancy, MMD) 来得到每个源域样本的相似性权重, 进而基于此权重来确定不同源域样本在迁移过程中发挥的重要性.

除上述工作外, 样例迁移方法在源域与目标域具有不同故障标签空间的任任务 (如, 部分迁移学习 (partial transfer learning, PTL) 任务) 中同样得到了广泛关注. 在 PTL 中, 目标域的故障标签空间属于源域的一个子集. 因此, 得益于深度神经网络可以端到端优化的特点, 样例迁移方法可以自适应地调整源域样本的权重, 从而自动选择出那些源域与目标域共享的类别. 例如, Jiao 等<sup>[49]</sup>提出了一种基于分类器不一致性的域适应网络用于解决部分迁移学习下的故障诊断. 该方法利用目标域样本预测概率来评估源域中不同类别的重要性, 进而增大来自共享故障类别样本的权重, 弱化来自源域独有故障类别的影响. Li 等<sup>[50]</sup>使用域预测损失作为揭示源域与目标域共享类别的指导, 即, 若域判别器倾向于为某源域样本提供错误的预测结果, 则该样本对应的源域类别有较大可能与目标域共享. 除以上学习源域类别粒度权重的方法之外, 针对源域样本粒度权重的学习也得到了一些研究关注. 例如, Li 等<sup>[51]</sup>引入了一个辅助对抗判别器来学习每个样本的权重, 其中每个源域样本的权重反比于该样本的域判别误差, 从而实现更精细的样例迁移.

### 2.3.2 基于样例迁移的工业过程软测量

在实际风场中, 新建的风场往往难以在短期内获得大量数据, 而已有风场往往采集了长期的风速记录. 因此, Hu 等<sup>[52]</sup>设计了一种基于神经网络迁移的方法用于解决风力发电过程中的风速预报问题. 该工作基于堆叠降噪自编码器结构, 利用多个风场的数据进行统一建模以提取共有特征, 进而利用每个风场的独有数据进行输出层的参数训练. Liu 等<sup>[53]</sup>提出了一种域适应极限学习机 (domain adaptation extreme learning machine, DAELM) 方法, 该方法同时基于源域与目标域的训练数据进行 ELM 建模, 并为源域与目标域的样本施加不同的损失权重. 在此基础上, Liu 等<sup>[54]</sup>随后又设计了一种基于对抗迁移学习的 DAELM 方法. 该方法首先通过对抗迁移学习进行源域与目标域样本的特征层面对齐, 随后利用 DAELM 方法在样例层面实现迁移学习. 该方法在连续搅拌釜反应过程的软测量任务中进行了验证.

## 2.4 基于特征迁移的工业监控方法

深度学习在工业监控中获得大量研究关注的主要原因之一在于其对复杂非线性特征的较强刻画能力. 因此, 如何在跨域知识迁移过程中充分利用深度神经网络的复杂特征学习能力, 正是基于特征迁移的工业监控方法重点关注的问题. 如图 7 所示, 基于特征的迁移方法往往先将源域与目标域数据充分投射至特征空间中, 进而在特征空间中对源域与目标域的特征分布进行对齐, 即尽量弱化二者的差异. 随后, 基于可迁移的特征即可进行后续下游任务建模, 例如, 故障诊断与软测量等.

一般来说, 基于特征的迁移方法有两种实现方式: 基于域差异度量与基于对抗训练. 前者往往采用定量的方式对源域与目标域的特征进行差异量化, 进而将其作为损失函数的一部分进行优化; 后者受生成式对抗网络 (generative adversarial net, GAN)<sup>[55]</sup>启发, 通过对特征提取器与域判别器进行对抗式训练, 从而实现源域与目标域的不可判别性.

具体地, 基于域差异度量的方法往往设计如下形式的损失函数以优化神经网络:

$$\mathcal{L}(\theta) = \mathcal{L}_{\text{task}}(\theta_f, \theta_t) + \mathcal{L}_{\text{disc}}(\theta_f), \quad (4)$$






图 7 (网络版彩图) 基于特征迁移的工业监控方法示意图

Figure 7 (Color online) Illustration of feature transfer-based industrial monitoring

其中,  $\mathcal{L}_{\text{task}}$  表示任务相关损失, 如, 故障分类损失或软测量误差损失等,  $\mathcal{L}_{\text{disc}}$  表示源域与目标域的特征分布差异损失.  $\theta$  为模型参数, 具体包括了特征提取器参数  $\theta_f$  与任务相关学习器参数  $\theta_t$ .

基于对抗训练的方法往往使用如下损失函数以优化神经网络:

$$\mathcal{L}(\theta) = \mathcal{L}_{\text{task}}(\theta_f, \theta_t) - \mathcal{L}_{\text{adv}}(\theta_f, \theta_a), \tag{5}$$

其中,  $\mathcal{L}_{\text{adv}}$  表示对抗训练损失,  $\theta_a$  表示域对抗器参数. 不同于域差异度量方法可以直接极小化损失函数以优化参数  $\theta$ , 域对抗训练方法通过对参数  $\theta_a$  与  $\theta_f$  进行对抗训练以完成网络优化:

$$\begin{aligned} (\hat{\theta}_f, \hat{\theta}_t) &= \arg \min_{\theta_f, \theta_t} \mathcal{L}(\theta_f, \theta_t, \theta_a), \\ \hat{\theta}_a &= \arg \max_{\theta_a} \mathcal{L}(\theta_f, \theta_t, \theta_a). \end{aligned} \tag{6}$$

得益于特征迁移方法对深度模型刻画复杂特征能力的充分挖掘, 该类方法近年来在工业监控中得到了大量研究. 图 8 展示了基于特征迁移的工业监控方法发展脉络. 如图 8 所示, 相较于前两类方法, 基于特征迁移的方法无疑收获了更多的研究关注, 成为近年来迁移学习领域炙手可热的研究方向之一. 特别地, 自 2020 年之后该方法在故障诊断和软测量领域的相关工作数量均表现出显著增长态势. 鉴于此, 本节将以应用任务为区分, 分别介绍基于特征迁移的工业故障诊断方法与软测量方法.

### 2.4.1 基于特征迁移的工业故障诊断

如前所述, 基于特征迁移的工业故障诊断可被进一步分为基于域差异度量的方法与基于对抗训练

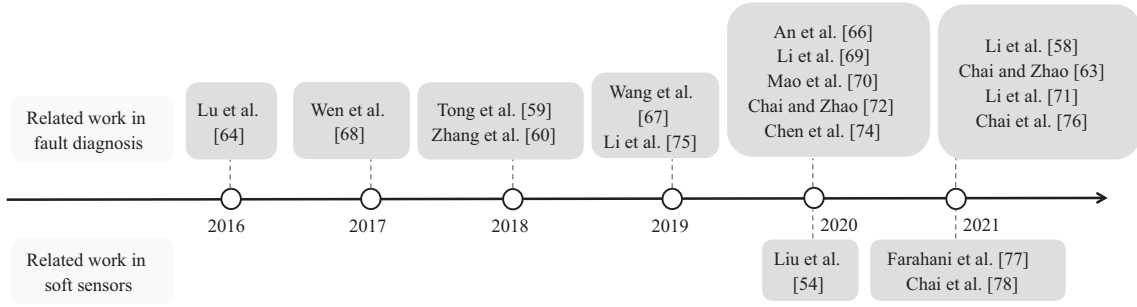


图 8 基于特征迁移的工业监控方法发展脉络

Figure 8 A timeline of feature transfer-based industrial monitoring methods

的方法. 本小节将分别对这两类方法进行介绍.

基于域差异度量的方法由于其设计简单、易于实践, 已成为深度迁移学习中最为流行的方法之一. 这其中最具代表性的域差异度量指标包括最大平均差异 MMD<sup>[56~60]</sup>、相关性对齐 (correlation alignment, CORAL)<sup>[61]</sup>、KL 散度<sup>[62]</sup>、Bregman 散度<sup>[63]</sup> 等指标. 以 MMD 指标与 KL 散度指标为例, 二者分别定义如下:

$$\text{MMD}(F_S, F_T) = \left\| \frac{1}{|F_S|} \sum_{f_S \in F_S} \phi(f_S) - \frac{1}{|F_T|} \sum_{f_T \in F_T} \phi(f_T) \right\|_{\mathcal{H}}^2, \quad (7)$$

其中,  $\mathcal{H}$  表示再生核希尔伯特 (Hilbert) 空间,  $F_S$  与  $F_T$  分别表示源域与目标域特征,  $\phi$  为映射函数.

$$D_{\text{KL}}(P||Q) = \sum_{i=1}^k P(i) \ln \left( \frac{P(i)}{Q(i)} \right), \quad (8)$$

其中,  $P$  与  $Q$  分别表示两个维度为  $k$  的边缘分布.

基于上述理念, Lu 等<sup>[64]</sup> 首次提出了一种基于最大平均差异指标的跨域故障诊断方法. 该方法在传统自编码器的损失函数之外引入了一项最大平均差异损失, 用于减小源域与目标域特征的分布差异. 进而, 基于该模型提取的可迁移特征, 通过在源域中训练支持向量机模型来实现故障类型的识别. 除此之外, 由于工业过程中往往存在大量变量, 为确定不同变量对迁移过程的贡献大小, Wang 等<sup>[65]</sup> 为传统的最大平均差异损失指标引入了变量重要性, 即通过线性判别分析事先计算不同变量在区分源域与目标域时的重要性, 进而利用该重要性对最大平均差异指标进行加权. 在仿真过程和实际加氢裂化过程中的实验结果表明, 这种加权的最大平均差异指标比传统指标具有更好的泛化性能. 不同于最大平均差异指标计算了源域与目标域特征的一阶统计量差异, 相关性对齐指标通过计算两个域的二阶统计量来得到二者差异. 基于此指标, An 等<sup>[66]</sup> 为机械滚动轴承故障诊断任务设计了一种基于一维卷积神经网络的模型. 此外, Wang 等<sup>[67]</sup> 提出了一种用于故障诊断的层次深度域自适应方法. 具体来说, 该方法对堆叠去噪自编码器的每一层特征计算边缘和条件相关性对齐指标, 以充分地多种粒度上进行特征迁移. 该方法在一个 600 兆瓦燃煤发电机组的实际给水加热器系统上进行了验证, 结果表明, 它的精度比使用最大平均差异指标<sup>[68]</sup> 的深度迁移学习方法提高了 3.99%.

除了基于域差异度量的方法, 基于对抗训练的方法同样在近年来获得了大量关注<sup>[69~72]</sup>. 这是因为域差异度量往往需要从定量的角度显式计算两个分布之间的差异, 而不同的指标往往会有各自的特点与局限性, 例如, 最大平均差异指标主要关注分布的一阶统计量对齐, 而相关性对齐则关注了分布

的二阶统计量. 不同于此, 基于对抗训练的方法从另一种角度来解决此问题: 训练一个二分类器, 若该分类器无法较好地地区分源域与目标域特征, 则说明二者之间具有较好的可迁移性<sup>[18,73]</sup>. 基于这种理念, Chen 等<sup>[74]</sup> 提出了一种用于针对旋转机械故障诊断任务的域对抗迁移网络, 该方法利用域对抗的训练方式来最小化源域数据和目标域数据分布之间的差异. 此外, 基于对抗训练的多源域迁移也得到了大量研究. 例如, Li 等<sup>[75]</sup> 基于对抗训练的方式, 解决了在多源域知识可获得的情况下, 如何针对目标域中少量监督样本进行迁移的问题. Chai 等<sup>[76]</sup> 设计了一种多源精细迁移网络, 从而解决了同时具有多源域且域间类别不一致的跨域故障诊断问题.

#### 2.4.2 基于特征迁移的工业过程软测量

除了在故障诊断领域的诸多应用, 基于特征迁移的方法在工业过程软测量中也受到了大量关注. Liu 等<sup>[54]</sup> 较早地研究了基于对抗训练的特征迁移方法在工业过程软测量中的应用. 具体来说, 该工作利用两个 GAN 分别将源域特征映射至目标域与将目标域特征映射至源域中来计算循环一致性损失, 从而实现特征的对齐. 此外, 受原始域对抗训练神经网络 (domain adversarial training of neural networks, DANN) 方法的启发, Farahani 等<sup>[77]</sup> 设计了一种基于 DANN 的模型用于发电厂的软测量建模, 并将该模型命名为 DANN-Regression. 和 DANN 结构类似, DANN-Regression 模型由特征提取器、回归器和域判别器组成, 并通过域对抗训练的方式进行优化. 该方法在一个天然气发电厂的 SCADA 系统中收集的工业过程数据集上进行了验证. 由于在实际的工业场景中传感器故障等原因导致的变量缺失问题十分普遍, Chai 等<sup>[78]</sup> 进一步设计了一种面向缺失数据的跨域工业过程软测量方法. 该方法基于随机梯度变分贝叶斯 (Bayes) 框架, 从概率的角度对可迁移的隐空间进行建模, 使模型具有更好的应对不确定性数据的能力.

### 2.5 小结

#### 2.5.1 基于深度迁移学习的工业监控方法总结

本小节将基于模型迁移、基于样例迁移与基于特征迁移的工业监控方法的应用任务、典型工作、方法特点与适用场景总结于表 1 中. 如表 1 所示, 总体来看, 基于模型迁移的工业监控方法往往要求目标域中包含少量标注数据. 若源域中包含充足标注数据, 即可基于源域工况建立基础模型; 反之, 可利用 ImageNet 预训练模型或计算仿真等方式实现源域模型的构建. 对于样例迁移类方法, 往往针对源域与目标域均具有标注样本的情况, 通过对源域与目标域数据进行权重学习, 从而实现可迁移样例的挖掘. 此外, 样例迁移学习对域间差异较大或不同域间具有不同故障标签空间的场景较为适用. 最后, 基于特征迁移的工业监控方法相较于其余两类方法, 在近年来获得了更多的研究关注. 该类方法目前的主流方式是通过利用域差异度量指标或域对抗训练的方式进行迁移, 较适用于目标域中只有无标注样本的场景.

#### 2.5.2 基于深度迁移学习的工业监控常用数据集总结

开源数据是进一步促进领域发展的基础. 在本研究领域, 较常用的数据集包括凯斯西储大学轴承数据集 (Case Western Reserve University (CWRU) Dataset)<sup>5)</sup> 与三相流工业过程数据集<sup>[79]</sup>. CWRU 数据由凯斯西储大学的轴承数据中心提供, 该数据由电机驱动端的加速度计测得, 适用于故障诊断任务. 该数据集使用电火花加工技术, 为轴承设备分别引入内圈故障、外圈故障与滚珠故障, 因此, 包含正常工况在内, 共产生 4 种工作状态. 每种故障的直径分别包括 7 密耳、14 密耳、21 密耳、28 密耳与

5) <https://engineering.case.edu/bearingdatacenter>.

表 1 基于深度迁移学习的工业监控方法总结

Table 1 Summary of deep transfer learning-based industrial monitoring methods

方法分类	应用任务	典型工作	方法特点	适用场景
基于模型迁移的工业监控方法	工业故障诊断	[36~38]	跨工况迁移, 对源域模型进行微调	源域工况有充足标注数据, 目标域有少量标注数据
		[40, 42]	不需源域工况, 只需目标域标注数据对预训练模型进行微调	目标域有少量标注数据
	工业过程软测量	[44]	通过计算机仿真得到源域数据, 利用真实数据进行模型迁移与修正	源域工况有充足标注数据, 目标域有少量标注数据
		[43]	跨工况迁移, 对源域模型进行微调	可在域间差异较大时使用
基于样例迁移的工业监控方法	工业故障诊断	[46~48]	样本权重动态调整以挑选出和目标域相似的源域样本	源域与目标域具有不同故障标签空间
		[49~51]		源域与目标域样本均有标注, 对数据量无特别要求
	工业过程软测量	[52]	统一建模后独立微调	
基于特征迁移的工业监控方法	工业故障诊断	[58~60, 63, 64, 66~68]	利用域差异度量指标进行特征迁移	多用于目标域缺少标注样本时
		[69~72, 74~76]	利用域对抗训练方式进行特征迁移	
	工业过程软测量	[54, 77, 78]		

40 密耳. 由于每组故障都在不同的负载下获得, 因此不同负载下的工况天然形成了不同的域, 数据采集频率为 12 kHz. 三相流工业过程由克兰菲尔德大学 (Cranfield University) 提供<sup>[79]</sup>. 该系统可由单相空气、水、油或其混合物供应, 旨在为加压系统提供受控和测量的水、油和空气流量. 该工业过程共包括两个输入变量, 即空气流速与水流速, 通过调整不同的流速设定, 即可使过程运行在不同工况下. 所有数据均以 1 Hz 的采样率获得. 该数据提供了正常工况以及 6 种故障状态下的数据, 并且在每种状态下都包含了两种及以上的运行工况. 因此, 在正常工况下的数据集可用于验证跨域软测量的性能, 在故障状态下的数据集可用于验证跨域故障诊断的性能. 除以上数据外, 其他数据集 (包括 PHM2009 数据集<sup>6)</sup>、田纳西伊斯曼数据集<sup>[80]</sup>) 也在一些研究中得到了使用<sup>[25, 65, 81]</sup>.

### 3 基于深度迁移学习的工业监控研究中现存问题与挑战

尽管深度迁移学习方法已经在工业过程监控中得到了一些研究, 但深度迁移学习方法在工业监控应用中仍受到诸多问题的限制. 本节将针对基于深度迁移学习的工业过程监控研究中的现存问题, 分别从欠数据问题、可迁移性问题与过程动态特性问题 3 个方面进行分析.

6) <https://phmsociety.org/data-analysis-competition/apparatus/>.

### 3.1 跨域工业监控中的复杂欠数据问题

本质上,跨域工业监控任务主要解决了目标域中的数据稀缺的问题,包括目标域总体样本数量稀缺、目标域标注样本数量稀缺等.而实际上,真实的工业监控任务将面临更为复杂的欠数据问题.例如,由于工业传感器技术的限制,在实际工业场景中往往难以采集变量完整的样本,即许多传感器采集的变量将包含缺失值<sup>[82,83]</sup>.在此情况下,假设输入数据完整的传统深度学习模型难以直接适用.此外,基于不同工业过程变量获取难度的差异与实际部署成本的考量,多速率采样现象在工业过程中也比较普遍<sup>[84,85]</sup>.多速率采样是指工业过程中的变量存在两种以上采样速率,而不同采样速率差异往往十分悬殊,甚至可能从数秒钟到数天之间不等.这一现象造成的工业数据大规模有规律缺失问题同样为传统深度学习模型带来了挑战.此外,除了域分布的不一致,故障类别不一致同样是实际工业场景中常见的问题.在实际工业场景中,不同域中往往只发生过有限类型的故障,而机器学习模型往往假设训练数据完备地包含了所有故障类型.这一差异使得传统方法利用单个源域内有限的故障历史数据进行模型训练的做法难以适应在未知测试数据集上可能出现的其他故障情况<sup>[86]</sup>.

### 3.2 跨域工业监控中的可迁移性量化与负迁移问题

相比于解决“如何迁移”的问题,在实际任务中,如何评估两个域之间是否可迁移往往更为重要.目前的研究大多集中于跨工况、跨设备、从仿真到实际等案例.但实际中,不同案例之间可能千差万别,也很难保证任意案例中都可以成功迁移.因此,如何定量地衡量不同域之间的可迁移性,在实际的工业监控任务中具有重要意义.

具体来说,可迁移性评估是指定量地估计从源域向目标域迁移知识的有效性或困难程度<sup>[87]</sup>.近年来,一些学者已经注意到了这个问题,并尝试从多种角度对这一问题进行了解答.例如,从深度神经网络的预训练和微调的角度来看,卷积神经网络<sup>[88,89]</sup>、基于 BERT 的语言模型<sup>[90]</sup>等都详细研究了基于神经网络的迁移学习中微调的影响.在工业监控领域,对可迁移性评估的研究仍然较少.Jia 等<sup>[91]</sup>利用最大平均差异指标设计了一种在设备健康管理任务中的数据适用性评估方法,该方法旨在帮助开发者从故障可检测性、可诊断性和趋势性 3 个方面快速确定当前使用数据是否适合于设备健康管理建模.从特征迁移性的角度来看,Chen 等<sup>[92]</sup>提出了一种由特征特异性指标和特征通用性指标联合构成的特征迁移性指标 (feature transferability index, FTI) 用于定量评估特征的可迁移性,该指标定义如下:

$$FTI = \frac{\omega_1 \cdot FGI - \omega_2 \cdot FSI}{\omega_1 + \omega_2}, \quad (9)$$

其中, FGI 与 FSI 分别表示由迁移前后性能变化描述的特征通用性 (feature generality index) 与特征特异性 (feature specificity index) 指标,  $\omega_1$  与  $\omega_2$  为二者的权重系数.

另一方面,准确地量化可迁移性对于规避负迁移现象的发生也具有积极作用.根据相关研究<sup>[23]</sup>,当源域数据对目标域的学习有负面贡献时,将导致负迁移现象的发生.负迁移是指经过迁移学习后的模型性能比只基于目标域数据建立的模型更差. Rosenstein 等<sup>[93]</sup>强调,如果源域和目标域的两个任务差异性较大,即当不同域之间差异太大或者可迁移性太小时,迁移学习实际上可能会妨碍模型性能的提升.为了解决这一问题,一些基于样例迁移的方法在一定程度上提供了可行的解决方案,即选择那些能够对目标域学习任务有正面贡献的源域样本进行建模<sup>[48]</sup>.除了本身数据分布差异过大的问题,当源域和目标域具有不同的标签空间时,同样可能导致较严重的负迁移问题. Pei 等<sup>[31]</sup>通过实验表明,当源域数据的标签规模大于目标域数据的标签规模,即存在许多与目标域不相关的源域样本时,就会出现负迁移.这一问题在工业故障诊断领域也较为常见.如 2.1 小节所讨论的,在某工况或某设备中往

往难以采集完备的故障数据, 因此不同工况或设备上得到的故障类别情况大多情况下只是完整故障空间的一个子集<sup>[76]</sup>. 此时, 直接采用传统深度迁移学习方法往往会适得其反, 难以获得满意性能. 近年来相关学者也开发了一些条件域自适应<sup>[72,94]</sup>或部分域自适应方法<sup>[49,95]</sup>, 试图解决此问题. 然而, 这类方法仍受到需对源域和目标域故障标签具有一定先验知识的限制.

综上, 尽管从迁移方法上来看, 已出现了基于模型、基于样例与基于特征迁移的一些研究, 然而从可迁移性与负迁移问题的理论解释上, 目前还相对欠缺. 如何在迁移之前回答好是否可迁移的问题, 将成为深度迁移学习在工业过程监控领域获得进一步应用的一个重要挑战.

### 3.3 工业过程的动态特性问题

机器学习驱动的工业过程监控研究大多隐含了采样点的独立性假设, 而工业过程的复杂动态特性为这一假设带来了一大挑战<sup>[96]</sup>. 受工业过程机理特性的影响, 采样点之间的动态相关性在不同的工业过程与工况下往往展示出不同的影响<sup>[97,98]</sup>. 受此问题启发, 传统数据驱动的工业过程监控领域中已发展出一些相关工作. 例如, 一些方法将原始数据按时间方向进行扩展, 进而将传统多元统计监控方法(如, 主成分分析(principal component analysis, PCA)、独立成分分析(independent component analysis, ICA))进一步扩展为动态主成分分析(dynamic PCA)<sup>[99]</sup>、动态独立成分分析(dynamic ICA)<sup>[100]</sup>等方法. 此外, 慢特征分析(slow feature analysis, SFA)方法<sup>[101]</sup>从时序数据中提取慢变化特征的能力使其在近年来在过程监控领域得到了大量关注<sup>[102~106]</sup>. 该方法通过极小化特征动态变化值, 从而实现对工业过程的静态与动态特性的单独提取与独立监控. 此外, 由于对时序数据的深度特征刻画能力, 以递归神经网络等为代表的模型同样在工业过程监控任务中获得了关注<sup>[107]</sup>.

尽管上述方法已经在工业过程监控中得到了应用, 但工业过程的动态特性目前在基于深度迁移学习的过程监控相关研究中尚未得到充分关注. 在统计机器学习方面, Xie等<sup>[81]</sup>提出了一种迁移慢特征分析方法(transfer SFA). 该方法基于变分推断理论与概率慢特征分析方法, 将多个源域的动态模型迁移至目标域中, 从而增强目标域的预测性能. 然而, 在基于深度迁移学习的工业监控领域, 相关研究还未将工业过程的动态特性进行考虑与解决.

## 4 基于深度迁移学习的工业监控研究展望

如何增强工业监控的准确性和可靠性, 始终是基于深度迁移学习的工业监控研究的重要目的之一. 受限于第3节所述的现存问题, 基于深度迁移学习的工业监控在未来仍有大量方向值得探索. 本文对深度迁移学习在工业监控中的进一步发展, 从多源信息融合与数据和知识联合建模两个角度做出研究展望.

### 4.1 多源信息融合的跨域工业监控

本文在第2节中将基于迁移学习的工业监控研究分为基于模型、基于样例与基于特征迁移的方法. 这些方法大多假设了单源域与单目标域的设定. 实际中, 某个工业过程可能有多种历史操作条件, 在不同操作条件下往往采集了多种不同分布的数据. 这些数据为工业监控中的知识迁移提供了宝贵资源. 因此, 不同于传统的单源域设定, 如何将多源域信息融合从而增强目标域中的监控任务性能, 是一个很有价值的研究方向. 除了提升目标域任务性能这一目标之外, 多源信息融合的跨域工业监控往往受如下两个实际问题驱动:

(1) 当前绝大多数跨域工业监控的研究都假设了目标域样本是可获得的. 而实际中, 由于目标域



往往运行时间较短,难以获得大量数据,即目标域的样本在实际中多数是难以访问的.为此,域泛化(domain generalization)技术<sup>[108]</sup>提供了一种可行的解决方案:利用多个源域的信息来学习可以在未知域中可泛化的监控知识,从而将模型直接应用至新域中.相比于传统方法大多关注于直推式的迁移学习范式,域泛化更接近于传统机器学习任务中的归纳式监督学习,即通过学习多个源域中的知识将模型直接泛化至未知的目标域中.

(2) 实际工业监控任务中的单个源域中信息十分有限.如 2.1 小节中讨论的,以工业故障诊断任务为例,不同的运行工况或不同的工业设备上往往会发生不同的故障类型.因此,实际中很难从单个源域中采集到完备标签的故障数据.另一方面,目标域中的故障标签空间甚至可能大于单源域的故障标签空间.此时,有必要充分收集多个源域中的历史故障数据,从而尽可能完备地包含目标域中可能发生的故障,进而提升目标域中的故障诊断性能.

## 4.2 语义知识与数据联合驱动的跨域工业监控

目前的跨域工业监控,例如,故障诊断与软测量等任务,大多基于数据驱动,即通过采集设备运行数据、振动信号等记录,结合人工标注的方式进行建模.然而这一方式忽略了对工业过程语义知识的利用,例如,故障描述、专家设定的工作指令等<sup>[109]</sup>.

Löwenmark 等<sup>[110]</sup>指出,在工业数据集中,关于故障特性与故障严重程度的领域特定知识可以作为自然语言监督(natural language supervision)信息,从而提供知识与数据联合引导的工业监控手段.例如,Xu 等<sup>[111]</sup>提出一种基于原始信号振动特征的语义生成模块,进而根据故障数据映射与故障语义映射的相似度来实现进一步的故障判别.该文献同时指出,由于不同故障的自然语言命名在词向量空间中较为接近,因此单纯基于故障名称的语义知识难以获得较好效果.尽管这一工作对语义知识的设定仍有改进空间,但这一框架事实上联合了语义知识与故障数据,为模型融入了比传统独热编码标签更为丰富的故障信息.

以上工作目前还仅限于传统工业故障诊断任务中.在基于深度迁移学习的跨域工业监控领域,由于不同的域往往产生于不同的工业过程、不同设备,或不同的操作条件下,这些域本身包含的语义信息如何在跨域监控中进行合理应用,同样为未来提供了一个值得探索的研究方向.

## 5 结论

基于深度迁移学习方法的工业监控方法方兴未艾,是当前工业监控领域的研究热点,特别是在典型监督任务(如,故障诊断与软测量领域)中.本文针对基于深度迁移学习的故障诊断与软测量研究现状进行了较为全面的文献综述与梳理,并按基于方法的不同,将现有研究分为基于模型迁移、基于样例迁移与基于特征迁移的工业监控方法.此外,基于深度迁移学习的工业监控研究目前还受限于诸多问题,包括跨域工业监控中的复杂欠数据问题、可迁移性量化问题以及工业过程典型动态特性问题等.这些问题对传统深度迁移学习方法提出了挑战,同时也为深度迁移学习在工业监控中的进一步发展指明了方向.有鉴于此,本文最后从多源信息融合的跨域工业监控与语义知识和数据联合驱动的跨域过程监控两个方面提出了未来展望.

## 参考文献

- 1 Chai T Y. Industrial process control systems: research status and development direction. *Sci Sin Inform*, 2016, 46: 1003–1015 [柴天佑. 工业过程控制系统研究现状与发展方向. *中国科学:信息科学*, 2016, 46: 1003–1015]

- 2 Zhao C H, Yu W K, Gao F R. Data analytics and condition monitoring methods for nonstationary batch processes—current status and future. *Act Autom Sin*, 2020, 46: 2072–2091 [赵春晖, 余万科, 高福荣. 非平稳间歇过程数据解析与状态监控——回顾与展望. *自动化学报*, 2020, 46: 2072–2091]
- 3 Raveendran R, Kodamana H, Huang B. Process monitoring using a generalized probabilistic linear latent variable model. *Automatica*, 2018, 96: 73–83
- 4 Yu W, Zhao C, Huang B. MoniNet with concurrent analytics of temporal and spatial information for fault detection in industrial processes. *IEEE Trans Cybern*, 2022, 52: 8340–8351
- 5 Reis M, Gins G. Industrial process monitoring in the big data/industry 4.0 era: from detection, to diagnosis, to prognosis. *Processes*, 2017, 5: 35
- 6 Zhao C, Chen J, Jing H. Condition-driven data analytics and monitoring for wide-range nonstationary and transient continuous processes. *IEEE Trans Automat Sci Eng*, 2021, 18: 1563–1574
- 7 Fortuna L, Graziani S, Rizzo A, et al. *Soft Sensors for Monitoring and Control of Industrial Processes*. London: Springer, 2007
- 8 Chiang L H, Russell E L, Braatz R D. Fault diagnosis in chemical processes using Fisher discriminant analysis, discriminant partial least squares, and principal component analysis. *Chemometr Intell Lab Syst*, 2000, 50: 243–252
- 9 Zhao C, Gao F. A nested-loop Fisher discriminant analysis algorithm. *Chemometr Intell Lab Syst*, 2015, 146: 396–406
- 10 Chai Z, Zhao C. Enhanced random forest with concurrent analysis of static and dynamic nodes for industrial fault classification. *IEEE Trans Ind Inf*, 2020, 16: 54–66
- 11 Wu H, Zhao J. Deep convolutional neural network model based chemical process fault diagnosis. *Comput Chem Eng*, 2018, 115: 185–197
- 12 Jiao J, Zhao M, Lin J, et al. A comprehensive review on convolutional neural network in machine fault diagnosis. *Neurocomputing*, 2020, 417: 36–63
- 13 Yu W, Zhao C. Broad convolutional neural network based industrial process fault diagnosis with incremental learning capability. *IEEE Trans Ind Electron*, 2020, 67: 5081–5091
- 14 Chang S, Zhao C, Li K. Consistent-contrastive network with temporality-awareness for robust-to-anomaly industrial soft sensor. *IEEE Trans Instrum Meas*, 2021. doi: 10.1109/TIM.2021.3129879
- 15 de Bruin T, Verbert K, Babuska R. Railway track circuit fault diagnosis using recurrent neural networks. *IEEE Trans Neural Netw Learn Syst*, 2017, 28: 523–533
- 16 Yuan X, Wang Y, Yang C, et al. Weighted linear dynamic system for feature representation and soft sensor application in nonlinear dynamic industrial processes. *IEEE Trans Ind Electron*, 2018, 65: 1508–1517
- 17 Nath A G, Udmale S S, Raghuvanshi D, et al. Structural rotor fault diagnosis using attention-based sensor fusion and transformers. *IEEE Sens J*, 2022, 22: 707–719
- 18 Ben-David S, Blitzer J, Crammer K, et al. A theory of learning from different domains. *Mach Learn*, 2010, 79: 151–175
- 19 Zhang S, Zhao C. Slow-feature-analysis-based batch process monitoring with comprehensive interpretation of operation condition deviation and dynamic anomaly. *IEEE Trans Ind Electron*, 2019, 66: 3773–3783
- 20 Chai Z, Zhao C. Deep transfer learning based multisource adaptation fault diagnosis network for industrial processes. *IFAC-PapersOnLine*, 2021, 54: 49–54
- 21 Wang X, Liu X, Li Y. An incremental model transfer method for complex process fault diagnosis. *IEEE CAA J Autom Sin*, 2019, 6: 1268–1280
- 22 Zhao C H, Hu Y Y, Zheng J L, et al. Data-driven operating monitoring for coal-fired power generation equipment: the state of the art and challenge. *Act Autom Sin*, 2021, 47: 1–23 [赵春晖, 胡赞昀, 郑嘉乐, 等. 数据驱动的燃煤发电装备运行工况监控——现状与展望. *自动化学报*, 2021, 47: 1–23]
- 23 Pan S J, Yang Q. A survey on transfer learning. *IEEE Trans Knowl Data Eng*, 2010, 22: 1345–1359
- 24 Tan C, Sun F, Kong T, et al. A survey on deep transfer learning. In: *Proceedings of Artificial Neural Networks and Machine Learning*. Berlin: Springer, 2018. 270–279
- 25 Zhao Z, Zhang Q, Yu X, et al. Applications of unsupervised deep transfer learning to intelligent fault diagnosis: a survey and comparative study. *IEEE Trans Instrum Meas*, 2021. doi: 10.1109/TIM.2021.3116309
- 26 Yan R, Shen F, Sun C, et al. Knowledge transfer for rotary machine fault diagnosis. *IEEE Sens J*, 2020, 20: 8374–8393
- 27 Li W, Huang R, Li J, et al. A perspective survey on deep transfer learning for fault diagnosis in industrial scenarios:

- Theories, applications and challenges. *Mech Syst Signal Process*, 2022, 167: 108487
- 28 Curreri F, Patané L, Xibilia M G. Soft sensor transferability: a survey. *Appl Sci*, 2021, 11: 7710
- 29 Maschler B, Weyrich M. Deep transfer learning for industrial automation: a review and discussion of new techniques for data-driven machine learning. *IEEE Ind Electron Mag*, 2021, 15: 65–75
- 30 Wang J, Zhao C. Mode-cloud data analytics based transfer learning for soft sensor of manufacturing industry with incremental learning ability. *Control Eng Pract*, 2020, 98: 104392
- 31 Pei Z, Cao Z, Long M, et al. Multi-adversarial domain adaptation. In: *Proceedings of the 32nd AAAI Conference on Artificial Intelligence*, 2018
- 32 LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*, 2015, 521: 436–444
- 33 Devlin J, Chang M, Lee K, et al. BERT: pre-training of deep bidirectional transformers for language understanding. In: *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*, 2019. 4171–4186
- 34 Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need. In: *Proceedings of the 31st International Conference on Neural Information Processing Systems*, 2017. 6000–6010
- 35 Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2015. 3431–3440
- 36 Zhang R, Tao H, Wu L, et al. Transfer learning with neural networks for bearing fault diagnosis in changing working conditions. *IEEE Access*, 2017, 5: 14347–14357
- 37 Han T, Liu C, Yang W, et al. Learning transferable features in deep convolutional neural networks for diagnosing unseen machine conditions. *ISA Trans*, 2019, 93: 341–353
- 38 Shao H, Xia M, Han G, et al. Intelligent fault diagnosis of rotor-bearing system under varying working conditions with modified transfer convolutional neural network and thermal images. *IEEE Trans Ind Inf*, 2021, 17: 3488–3496
- 39 Deng J, Dong W, Socher R, et al. ImageNet: a large-scale hierarchical image database. In: *Proceedings of 2009 IEEE Conference on Computer Vision and Pattern Recognition*, 2009. 248–255
- 40 Shao S, McAleer S, Yan R, et al. Highly accurate machine fault diagnosis using deep transfer learning. *IEEE Trans Ind Inf*, 2019, 15: 2446–2455
- 41 Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. 2014. ArXiv:1409.1556
- 42 Chakraborty S, Shamrat F, Afrin S, et al. Industrial fault detection using transfer learning models. In: *Proceedings of the 2nd International Conference on Smart Electronics and Communication (ICOSEC)*, 2021. 1–6
- 43 Curreri F, Patané L, Xibilia M G. RNN- and LSTM-based soft sensors transferability for an industrial process. *Sensors*, 2021, 21: 823
- 44 Hsiao Y D, Kang J L, Wong D S H. Development of robust and physically interpretable soft sensor for industrial distillation column using transfer learning with small datasets. *Processes*, 2021, 9: 667
- 45 Dai W, Yang Q, Xue G, et al. Boosting for transfer learning. In: *Proceedings of the 24th International Conference on Machine Learning*, 2007. 193–200
- 46 Pan Y, Mei F, Miao H, et al. An approach for HVCB mechanical fault diagnosis based on a deep belief network and a transfer learning strategy. *J Electr Eng Technol*, 2019, 14: 407–419
- 47 Zhang L, Guo L, Gao H, et al. Instance-based ensemble deep transfer learning network: a new intelligent degradation recognition method and its application on ball screw. *Mech Syst Signal Processing*, 2020, 140: 106681
- 48 Lee K, Han S, Pham V H, et al. Multi-objective instance weighting-based deep transfer learning network for intelligent fault diagnosis. *Appl Sci*, 2021, 11: 2370
- 49 Jiao J, Zhao M, Lin J, et al. Classifier inconsistency-based domain adaptation network for partial transfer intelligent diagnosis. *IEEE Trans Ind Inf*, 2020, 16: 5965–5974
- 50 Li X, Zhang W, Ma H, et al. Partial transfer learning in machinery cross-domain fault diagnostics using class-weighted adversarial networks. *Neural Networks*, 2020, 129: 313–322
- 51 Li W, Chen Z, He G. A novel weighted adversarial transfer network for partial domain fault diagnosis of machinery. *IEEE Trans Ind Inf*, 2021, 17: 1753–1762
- 52 Hu Q, Zhang R, Zhou Y. Transfer learning for short-term wind speed prediction with deep neural networks. *Renew Energy*, 2016, 85: 83–95
- 53 Liu Y, Yang C, Liu K, et al. Domain adaptation transfer learning soft sensor for product quality prediction.

- Chemometrics Intelligent Laboratory Syst, 2019, 192: 103813
- 54 Liu Y, Yang C, Zhang M, et al. Development of adversarial transfer learning soft sensor for multigrade processes. *Ind Eng Chem Res*, 2020, 59: 16330–16345
- 55 Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets. In: *Proceedings of the 27th International Conference on Neural Information Processing Systems*, 2014. 2672–2680
- 56 Gretton A, Borgwardt K, Rasch M, et al. A kernel method for the two-sample-problem. In: *Proceedings of the 19th International Conference on Neural Information Processing Systems*, 2006. 19: 513–520
- 57 Pan S J, Tsang I W, Kwok J T, et al. Domain adaptation via transfer component analysis. *IEEE Trans Neural Netw*, 2011, 22: 199–210
- 58 Li Y, Ren Y, Zheng H, et al. A novel cross-domain intelligent fault diagnosis method based on entropy features and transfer learning. *IEEE Trans Instrum Meas*, 2021, 70: 1–14
- 59 Tong Z, Li W, Zhang B, et al. Bearing fault diagnosis under variable working conditions based on domain adaptation using feature transfer learning. *IEEE Access*, 2018, 6: 76187–76197
- 60 Zhang B, Li W, Li X L, et al. Intelligent fault diagnosis under varying working conditions based on domain adaptive convolutional neural networks. *IEEE Access*, 2018, 6: 66367–66384
- 61 Sun B, Feng J, Saenko K. Return of frustratingly easy domain adaptation. In: *Proceedings of the AAAI Conference on Artificial Intelligence*, 2016
- 62 Sugiyama M, Suzuki T, Nakajima S, et al. Direct importance estimation for covariate shift adaptation. *Ann Inst Stat Math*, 2008, 60: 699–746
- 63 Chai Z, Zhao C. Fault-prototypical adapted network for cross-domain industrial intelligent diagnosis. *IEEE Trans Automat Sci Eng*, 2022, 19: 3649–3658
- 64 Lu W, Liang B, Cheng Y, et al. Deep model based domain adaptation for fault diagnosis. *IEEE Trans Ind Electron*, 2017, 64: 2296–2305
- 65 Wang Y, Wu D, Yuan X. LDA-based deep transfer learning for fault diagnosis in industrial chemical processes. *Comput Chem Eng*, 2020, 140: 106964
- 66 An J, Ai P, Liu D. Deep domain adaptation model for bearing fault diagnosis with domain alignment and discriminative feature learning. *Shock Vib*, 2020, 2020: 1–14
- 67 Wang X, He H, Li L. A hierarchical deep domain adaptation approach for fault diagnosis of power plant thermal system. *IEEE Trans Ind Inf*, 2019, 15: 5139–5148
- 68 Wen L, Gao L, Li X. A new deep transfer learning based on sparse auto-encoder for fault diagnosis. *IEEE Trans Syst Man Cybern Syst*, 2019, 49: 136–144
- 69 Li X, Zhang W, Ma H, et al. Domain generalization in rotating machinery fault diagnostics using deep neural networks. *Neurocomputing*, 2020, 403: 409–420
- 70 Mao W, Liu Y, Ding L, et al. A new structured domain adversarial neural network for transfer fault diagnosis of rolling bearings under different working conditions. *IEEE Trans Instrum Meas*, 2020, 70: 1–13
- 71 Li Q, Shen C, Chen L, et al. Knowledge mapping-based adversarial domain adaptation: a novel fault diagnosis method with high generalizability under variable working conditions. *Mech Syst Signal Process*, 2021, 147: 107095
- 72 Chai Z, Zhao C. A fine-grained adversarial network method for cross-domain industrial fault diagnosis. *IEEE Trans Automat Sci Eng*, 2020, 17: 1432–1442
- 73 Ganin Y, Ustinova E, Ajakan H, et al. Domain-adversarial training of neural networks. *J Mach Learn Res*, 2016, 17: 2096–2030
- 74 Chen Z, He G, Li J, et al. Domain adversarial transfer network for cross-domain fault diagnosis of rotary machinery. *IEEE Trans Instrum Meas*, 2020, 69: 8702–8712
- 75 Li X, Zhang W, Ding Q, et al. Diagnosing rotating machines with weakly supervised data using deep transfer learning. *IEEE Trans Ind Inf*, 2020, 16: 1688–1697
- 76 Chai Z, Zhao C, Huang B. Multisource-refined transfer network for industrial fault diagnosis under domain and category inconsistencies. *IEEE Trans Cybern*, 2022, 52: 9784–9796
- 77 Farahani H S, Fatehi A, Nadali A, et al. Domain adversarial neural network regression to design transferable soft sensor in a power plant. *Comput Industry*, 2021, 132: 103489
- 78 Chai Z, Zhao C, Huang B, et al. A deep probabilistic transfer learning framework for soft sensor modeling with

- missing data. *IEEE Trans Neural Netw Learn Syst*, 2022, 33: 7598–7609
- 79 Ruiz-Cárcel C, Cao Y, Mba D, et al. Statistical process monitoring of a multiphase flow facility. *Control Eng Pract*, 2015, 42: 74–88
- 80 Downs J J, Vogel E F. A plant-wide industrial process control problem. *Comput Chem Eng*, 1993, 17: 245–255
- 81 Xie J, Huang B, Dubljevic S. Transfer learning for dynamic feature extraction using variational bayesian inference. *IEEE Trans Knowl Data Eng*, 2022, 34: 5524–5535
- 82 Yao Z, Zhao C. FIGAN: a missing industrial data imputation method customized for soft sensor application. *IEEE Trans Automat Sci Eng*, 2022, 19: 3712–3722
- 83 Yu W, Zhao C. Low-rank characteristic and temporal correlation analytics for incipient industrial fault detection with missing data. *IEEE Trans Ind Inf*, 2021, 17: 6337–6346
- 84 Chai Z, Zhao C, Huang B. Variational progressive-transfer network for soft sensing of multirate industrial processes. *IEEE Trans Cybern*, 2022, 52: 12882–12892
- 85 Chai Z, Zhao C, Sun Y. A sequentially-adaptive deep variational model for multirate process anomaly detection. In: *Proceedings of the 3rd International Conference on Industrial Artificial Intelligence (IAI)*, 2021. 1–6
- 86 Chai Z, Zhao C. Multiclass oblique random forests with dual-incremental learning capacity. *IEEE Trans Neural Netw Learn Syst*, 2020, 31: 5192–5203
- 87 Nguyen C, Hassner T, Seeger M, et al. LEEP: a new measure to evaluate transferability of learned representations. In: *Proceedings of International Conference on Machine Learning*, 2020. 7294–7305
- 88 Yosinski J, Clune J, Bengio Y, et al. How transferable are features in deep neural networks? 2014. ArXiv:1411.1792
- 89 Djolonga J, Yung J, Tschannen M, et al. On robustness and transferability of convolutional neural networks. In: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2021. 16458–16468
- 90 Tamkin A, Singh T, Giovanardi D, et al. Investigating transferability in pretrained language models. 2020. ArXiv:2004.14975
- 91 Jia X, Zhao M, Di Y, et al. Assessment of data suitability for machine prognosis using maximum mean discrepancy. *IEEE Trans Ind Electron*, 2018, 65: 5872–5881
- 92 Chen J, Lécué F, Pan J, et al. Knowledge-based transfer learning explanation. In: *Proceedings of 16th International Conference on Principles of Knowledge Representation and Reasoning*, 2018
- 93 Rosenstein M, Marx Z, Kaelbling L, et al. To transfer or not to transfer. In: *Proceedings of NIPS 2005 Workshop on Transfer Learning*, 2005. 1–4
- 94 Han T, Liu C, Yang W, et al. Deep transfer network with joint distribution adaptation: a new intelligent fault diagnosis framework for industry application. *ISA Trans*, 2020, 97: 269–281
- 95 Cao Z, Long M, Wang J, et al. Partial transfer learning with selective adversarial networks. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2018. 2724–2732
- 96 Zhao C. Perspectives on nonstationary process monitoring in the era of industrial artificial intelligence. *J Process Control*, 2022, 116: 255–272
- 97 Zheng J, Zhao C, Gao F. Retrospective comparison of several typical linear dynamic latent variable models for industrial process monitoring. *Comput Chem Eng*, 2022, 157: 107587
- 98 Zhao C, Wang W, Tian C, et al. Fine-scale modeling and monitoring of wide-range nonstationary batch processes with dynamic analytics. *IEEE Trans Ind Electron*, 2021, 68: 8808–8818
- 99 Chen J, Liu K C. On-line batch process monitoring using dynamic PCA and dynamic PLS models. *Chem Eng Sci*, 2002, 57: 63–75
- 100 Hsu C C, Chen M C, Chen L S. A novel process monitoring approach with dynamic independent component analysis. *Control Eng Pract*, 2010, 18: 242–253
- 101 Wiskott L, Sejnowski T J. Slow feature analysis: unsupervised learning of invariances. *Neural Computation*, 2002, 14: 715–770
- 102 Shang C, Yang F, Gao X, et al. Concurrent monitoring of operating condition deviations and process dynamics anomalies with slow feature analysis. *AIChE J*, 2015, 61: 3666–3682
- 103 Song P, Zhao C. Slow down to go better: a survey on slow feature analysis. *IEEE Trans Neural Netw Learn Syst*, 2022. doi: 10.1109/TNNLS.2022.3201621
- 104 Song P, Zhao C, Huang B. SFNet: a slow feature extraction network for parallel linear and nonlinear dynamic process

- monitoring. *Neurocomputing*, 2022, 488: 359–380
- 105 Zou X, Zhao C. Concurrent assessment of process operating performance with joint static and dynamic analysis. *IEEE Trans Ind Inf*, 2020, 16: 2776–2786
- 106 Zheng J, Zhao C. Online monitoring of performance variations and process dynamic anomalies with performance-relevant full decomposition of slow feature analysis. *J Process Control*, 2019, 80: 89–102
- 107 Yuan X, Li L, Shardt Y A W, et al. Deep learning with spatiotemporal attention-based LSTM for industrial soft sensor model development. *IEEE Trans Ind Electron*, 2021, 68: 4404–4414
- 108 Wang J, Lan C, Liu C, et al. Generalizing to unseen domains: a survey on domain generalization. In: *Proceedings of the 28th International Joint Conference on Artificial Intelligence*, 2021
- 109 Feng L, Zhao C. Fault description based attribute transfer for zero-sample industrial fault diagnosis. *IEEE Trans Ind Inf*, 2021, 17: 1852–1862
- 110 Löwenmark K, Taal C, Schnabel S, et al. Technical language supervision for intelligent fault diagnosis in process industry. 2021. *ArXiv:2112.07356*
- 111 Xu J, Zhou L, Zhao W, et al. Zero-shot learning for compound fault diagnosis of bearings. *Expert Syst Appl*, 2022, 190: 116197

## Deep transfer learning methods for typical supervised tasks in industrial monitoring: state-of-the-art, challenges, and perspectives

Zheng CHAI<sup>1</sup>, Jiaye WANG<sup>1</sup>, Chunhui ZHAO<sup>1\*</sup>, Jinliang DING<sup>2</sup> & Youxian SUN<sup>1</sup>

1. *College of Control Science and Engineering, Zhejiang University, Hangzhou 310027, China;*

2. *State Key Laboratory of Synthetical Automation for Process Industries, Northeastern University, Shenyang 110819, China*

\* Corresponding author. E-mail: chhzhao@zju.edu.cn

**Abstract** Deep transfer learning-based industrial monitoring methods have received considerable research attention in recent years, especially in typical industrial monitoring tasks, including fault diagnosis and soft sensor developments. Such methods mine and transfer knowledge from similar source domains to model the data in the target domain. They provide a new perspective for cross-domain industrial monitoring problems caused by varying conditions in actual scenarios. This survey systematically sorts the deep transfer learning methods for typical supervised tasks in industrial monitoring and classifies them into model-based, instance-based, and feature-based approaches. Subsequently, it introduces the basic ideas and state-of-the-art approaches in fault diagnosis and soft sensor development of different categories. Finally, from the perspectives of complexly limited data, evaluation of transferability and negative transfer problems, and the dynamic characteristics of industrial processes, the survey highlights the current challenges in cross-domain industrial monitoring and points to future research areas in this field.

**Keywords** transfer learning, deep learning, cross-domain industrial monitoring, fault diagnosis, soft sensor