

基于隐变量解耦学习的时间序列领域自适应方法^{*}

李梓健¹, 蔡瑞初¹, 陈浩芝¹, 姜志帆¹, 陈道鑫¹, 郝志峰²

¹(广东工业大学 计算机学院, 广东 广州 510006)

²(汕头大学 工学院, 广东 汕头 515063)

通信作者: 蔡瑞初, E-mail: cairuichu@gmail.com; 郝志峰, E-mail: haozhifeng@stu.edu.cn



摘 要: 领域自适应旨在利用带标签的源域数据和无标签的目标域数据来解决机器学习泛化性不足的问题. 现有领域自适应工作主要针对计算机视觉任务. 为了解决针对时间序列数据的领域自适应挑战, 现有的方法将针对图片数据的方法直接应用于时间序列数据中. 这些方法虽然一定程度上解决了模型的泛化能力, 但是这些方法依然不能很好地提取解耦的领域不变的特征, 从而使得模型的泛化性能依然不尽人意. 为了解决这个挑战, 提出基于隐变量解耦学习的无监督领域自适应算法. 首先, 提出针对时间序列数据的因果数据生成过程, 在这个生成过程中, 假设观测数据背后的隐变量分为变化部分和不变部分, 并且将这些部分用隐变量表示. 基于这个数据生成过程, 提出可识别性理论证明领域变化的隐变量是可以被识别的. 在可识别性理论的基础上, 设计针对时间序列的隐变量解耦学习领域自适应模型 (time series domain adaptation via disentangling invariant and variant latent variables, DIVV). 该模型一方面利用变分推断解耦领域变化的隐变量, 另一方面采用基于正交特征的对齐模块以解耦领域不变的隐变量. 最后该模型采用领域不变特征进行时间序列分类. 在多个真实数据集上进行验证, 并且取得了最有效的实验结果, 证明所提理论和模型在真实场景中的有效性.

关键词: 迁移学习; 时间序列领域自适应; 时间序列分类; 因果数据生成过程; 可识别性

中图法分类号: TP181

中文引用格式: 李梓健, 蔡瑞初, 陈浩芝, 姜志帆, 陈道鑫, 郝志峰. 基于隐变量解耦学习的时间序列领域自适应方法. 软件学报, 2025, 36(12): 5554–5571. <http://www.jos.org.cn/1000-9825/7398.htm>

英文引用格式: Li ZJ, Cai RC, Chen HZ, Jiang ZF, Chen DX, Hao ZF. Time Series Domain Adaptation Method via Disentangling Invariant and Variant Latent Variables. Ruan Jian Xue Bao/Journal of Software, 2025, 36(12): 5554–5571 (in Chinese). <http://www.jos.org.cn/1000-9825/7398.htm>

Time Series Domain Adaptation Method via Disentangling Invariant and Variant Latent Variables

LI Zi-Jian¹, CAI Rui-Chu¹, CHEN Hao-Zhi¹, JIANG Zhi-Fan¹, CHEN Dao-Xin¹, HAO Zhi-Feng²

¹(School of Computer Science and Technology, Guangdong University of Technology, Guangzhou 510006, China)

²(College of Engineering, Shantou University, Shantou 515063, China)

Abstract: Since the currently popular deep learning models are often influenced by the notorious phenomenon known as distribution shift, domain adaptation has been proposed to enhance the generalization of these models, transferring knowledge from labeled source data to unlabeled target data. Existing methods for domain adaptation primarily focus on computer vision tasks, leading to the application of models devised for image data to time series data to address the domain adaptation problem for time series data. Although these methods mitigate distribution shift to some extent, they struggle to effectively extract disentangled domain-invariant representations for time series data, resulting in suboptimal performance. To address this issue, a disentangled invariant and variant latent variable model for time series domain adaptation (DIVV) is proposed. Specifically, a causal generation process for time series data is introduced, where the latent

* 基金项目: 科技创新 2030—“新一代人工智能”重大项目 (2021ZD0111501); 国家自然科学基金优秀青年科学基金 (62122022); 国家自然科学基金 (62206064)

收稿时间: 2024-02-29; 修改时间: 2024-06-30; 采用时间: 2025-01-23; jos 在线出版时间: 2025-08-01

CNKI 网络首发时间: 2025-08-12

variables are partitioned into domain-specific and domain-invariant latent variables. Based on this data generation process, the identifiability of domain-specific latent variables is established. The DIVV model, built on this identification theory, disentangles domain-specific and domain-invariant latent variables using variational influence and an orthogonal basis alignment module. Finally, the DIVV model leverages domain-invariant representations for time series classification. Experimental results demonstrate that the DIVV model outperforms existing domain adaptation methods for time series data across various benchmark datasets, highlighting its effectiveness in real-world applications.

Key words: transfer learning; time series domain adaptation; time series classification; causal generation process; identifiability

针对时间序列数据的领域自适应^[1-3]旨在利用带标签的源域数据和不带标签的目标域将源域的语义信息迁移到目标域中,以缓解深度学习模型^[4-8]在目标域上的分布偏移现象.具体而言,本文用 S 和 T 来表示源域和目标域分布,而且 $x = \{x_1, \dots, x_T\}$, y, u 分别表示长度为 T 的时间序列,类别标签以及领域标签.本文进一步令 $(x^S, y^S) = (x_i^S, y_i^S)_{i=1}^{m^S}$ 表示从源域分布 $p(x, y, u_S)$ 采样获得的带标签源域数据,而令 $(x^T) = (x_i^T)_{i=1}^{m^T}$ 表示从目标域分布 $p(x, u_T)$ 采样获得的不带标签目标域数据.基于上述符号定义,基于时间序列的领域自适应的目标是利用带标签的源域数据和不带标签的目标域数据来识别目标域的联合分布 $p(x, y, u_T)$.

为了识别目标域的联合分布 $p(x, y, u_T)$,仅利用带标签的源域数据和不带标签的目标域数据来识别目标域的联合分布 $p(x, y, u_T)$ 并非一件容易的事情,因为在没有其他假设的条件下 $p(x, y, u_T)$ 和 $p(x, u_T)$ 有无数种对应关系.为了解决这个难题,不少研究人员采用了不同的假设并且将这些假设应用到针对时间序列数据的领域自适应方法中.其中最经典的一种假设为协变量偏移假设^[9-11],它假设边缘分布是变化的,即 $p(x^S) \neq p(x^T)$ 而条件分布是不变的,即 $p(y^S|x^S) = p(y^T|x^T)$.基于协变量偏移假设,不少研究人员利用针对时间序列的特征提取器或者进一步假设频域的边缘分布是不变的来提取领域不变信息.例如Cai等人^[12]及Li等人^[13]提出通过自注意力机制提取的跨领域的稀疏关联结构进行对齐.随后,Li等人^[14]提出了用于可转移时间序列预测的格兰杰(Granger)因果关系对齐模型,借助格兰杰因果关系的帮助该模型可以同时发现因果结构并预测未来值.Liu等人^[15]使用混合谱网络来最小化时间序列数据的频率差异.而He等人^[16]通过使用辛克霍恩(Sinkhorn)散度约束来对齐时间和频率特征,以解决特征变化的问题.总的来说,这些方法通过限制隐变量联合分布的不变性来减轻分布偏移的影响.

尽管这些方法一定程度上缓解了时间序列数据中的分布偏移,但是它们依然不能识别出目标域的联合分布 $p(x, y, u_T)$,造成上述情况的根本原因是即使这些方法限制了隐变量 z 联合分布的不变性,即 $p(z^S) = p(z^T)$,此类方法不能很好地将领域变化隐变量和领域不变隐变量解耦出来.图1提供了一个简单易懂的例子,图1(a)是源域和目标域时间序列数据,这些观测数据由频率、振幅和上下偏移3种不同隐变量生成,其中不同频率决定不同类别,即正类/负类,振幅和上下偏移随不同领域变化而变化;图1(b)现有的方法因为领域变化和不变的隐变量发生耦合,从而导致不准确的预测结果;图1(c)通过解耦领域变化和不变的隐变量,从而获得良好的预测结果.如图1(a)所示,不同领域的时间序列数据由频率、振幅和上下偏移3个隐变量所影响,其中频率决定了一个时间序列样本的类别,而振幅和上下偏移是随着领域变化而变化的因素.如图1(b)所示,现有基于边缘分布不变性的方法并不能很好地将领域变化和领域不变的特征解耦出来,从而使得提出的特征依然含有领域变化的部分,最终导致分类效果不尽人意.如图1(c)所示,当领域变化和领域不变的特征被完全地解耦出来,模型就可以将领域不变的特征用于分类,从而使模型更好地克服分布偏移的影响,获得理想的分类效果.

基于以上例子,为了将时间序列数据中领域变化和领域不变的隐变量解耦,我们假设不同领域的时间序列数据中部分语义信息是稳定不变的,并且提出了针对时间序列的隐变量解耦学习领域自适应模型(time series domain adaptation via disentangling invariant and variant latent variables, DIVV).为此首先提出一个针对时间序列分类的因果数据生成过程.在合理的假设下,进一步证明了领域变化的隐变量是可识别的.基于上述可识别性理论,本文进一步设计了基于隐变量解耦学习的时间序列自适应模型,该模型包括两个组成部分:1)基于变分推断的数据生成过程拟合模块;2)基于正交特征对齐的不变特征提取模块.其中,基于变分推断的数据生成过程拟合模块用于结合可识别性理论,将领域变化隐变量识别出来.基于正交特征对齐的不变特征提取模块则通过约束不同领域之间的正交特征不变性使得领域不变特征得以解耦.所提DIVV方法不仅拥有因果可识别性方面的理论优势,并且在多个时间序列分类领域自适应基准数据集(UCIHAR、HHAR和WISDM)上获得了最好的实验效果.




图1 两种基于不变特征提取方法及其相应结果的说明

1 相关工作

1.1 无监督领域自适应

为了解决机器学习模型的分布偏移问题,无监督领域自适应^[1,12,17-39]应运而生,它主要研究如何通过使用有标签的源数据和无标签的目标数据来提升模型的泛化能力^[9,10,40-45].基于不同的假设,目前的无监督领域自适应方法^[46-50]可以分成协变量偏移假设、条件偏移假设和标签偏移假设^[51].

① 协变量偏移假设认为边缘分布是变化的,即 $p(x^s) \neq p(x^t)$,而条件分布是不变的,即 $p(y^s|x^s) = p(y^t|x^t)$.常见的基于协变量偏移假设的建模方式有重加权法、不变特征学习法以及循环一致性约束法.例如 Tzeng 等人^[3]提出深度领域混淆方法,以最小化源域特征分布和目标域特征分布之间的 MMD 距离^[52,53];Chen 等人^[19]根据回归任务中特征尺度敏感的性质,利用奇异值分解获得特征的基,进一步通过约束正交基以缩小领域距离;Ganin 等人^[54]利用生成对抗网络思路,提出了对抗网络^[54-61]来提取领域不变特征.

② 条件偏移假设则认为边缘分布是不变的,即 $p(y^s) = p(y^t)$,而条件分布是变化的,即 $p(x^s|y^s) \neq p(x^t|y^t)$.例如 Cai 等人^[18]利用因果生成过程来提取分解的语义表示.Kong 等人^[61]进一步使用了分量式识别结果来解决领域自适应问题.

③ 标签偏移假设恰恰相反,它认为条件分布是不变的,即 $p(x^s|y^s) = p(x^t|y^t)$,而标签的边缘分布是变化的,即 $p(y^s) \neq p(y^t)$.Lipton 等人^[62]关于标签偏移做出了比较有名的研究.

1.2 时间序列领域自适应

第 1.1 节中的方法大多都是为计算机视觉中的静态数据例如图片数据而设计的,但是由于时间数据^[63-68]也是现实世界中一种常见的数据,因此针对时间序列的领域自适应^[61,69-74]成为一个亟需解决的问题.不少研究人员简单地采用经典领域自适应的方法,直接在基于静态数据的领域自适应方法^[1-3,34,36]的基础上拓张,例如采用基于循环神经网络 (RNN)^[75]的特征提取器和长短时记忆神经网络 (LSTM)^[76]的神经网络结构来提取领域不变的特征.这些方法虽然简单,但是碍于时间序列数据存在复杂的依赖关系,往往在不少场景中难以获得理想的效果.为了解决这个难题,不少研究者重新从假设出发,提出了适合时间序列领域自适应^[30,32,77,78]场景的假设.例如,基于时间序列

内部稀疏的关联结构不变性的假设, 文献 [12,13] 提出的稀疏关联结构对齐模型 (SASA) 首先解决时间序列领域自适应的难题. 此外, Li 等人 [14] 进一步假设时间序列数据的因果机制是不变的, 因此他们提出了基于格兰杰因果结构对齐的半监督时间序列领域自适应模型, 以解决时间序列上的领域自适应问题. 另外一部分学者考虑到时间序列数据在时域上是复杂而难以处理的, 所以他们假设时间序列数据在频域上是简单而容易处理的. 例如, Liu 等人 [15] 提出了 AdvSKM, 该方法是通过混合谱核网络来对频率差异进行约束, 从而提取领域不变的基特征. 与此相似的是 He 等人 [16] 提出了 RAINCOAT, 此方法通过时间和频率特征对齐来解决特征和标签的变化.

除此之外, 还有研究者利用时间序列数据的其他性质解决了基于时序数据的领域自适应问题, 例如 Furqon 等人 [79] 从时序统计量出发, 考虑了时间序列数据的周期项和趋势项, 并且使用周期项和趋势项交替进行预测, 并不断优化预测结果和序列分解从而分解出变化和不变的信息. Ragab 等人 [60] 考虑到特征学习和不同领域对齐过程中数据的时间动态性质, 通过利用自监督预训练方法和伪标签方式来提升模型在目标域中的性能, 从而减轻了分布偏移 [80] 对深度模型带来的影响.

1.3 深度生成模型的可识别性理论

深度生成模型由于其强大的性能和多种的应用场景, 得到了越来越多的青睐. 但是如何为深度生成模型提供更加强大的泛化性和可解释性成为一个难题, 而因果表征学习恰好可以满足这个需求. 所谓因果表征学习, 即通过识别出观测数据背后的隐变量从而刻画隐含因果过程. 其中一种提取因果表征的方法是独立成分分析 (independence component analysis, ICA) [81]. 在独立成分分析中, 隐变量通常被假设为相互独立的, 并且隐变量到观测变量之间的关系是线性的, 而非线性的独立成分分析之所以是困难的是因为在非线性条件下隐变量是难以被识别的.

近年来, Khemakhem 等人 [82] 在非线性独立成分分析上得到了突破, 他们证明了在有辅助变量的情况下隐变量是可识别的, 这些辅助变量可以是领域标签、时间序列索引等可观测监督信号. 但是这些方法通常假设隐变量是条件独立的, 并且隐变量的分布服从指数族分布. 最近, Kong 等人 [61] 突破了指数族分布的约束并且利用了非线性独立成分分析, 提出了静态数据下的逐维可识别理论 (component-wise identification). 基于这个理论, Yao 等人 [75] 进一步将过去的历史信息作为监督信号, 解决了稳态和非稳态下的隐变量可识别性难题. 另外, Li 等人 [83] 提出了子空间可识别性并解决了多源领域自适应问题, 相比逐维可识别的 $2n+1$ 个辅助变量, 该方法只需要 $n+1$ 个监督信号便可以获得相同的可识别性效果. 本文利用逐维可识别性质理论使得领域变化的隐变量可以识别, 并进一步解决了时序数据中的领域自适应难题.

2 基于数据生成的目标域联合分布可识别

2.1 基于隐变量的数据生成过程

考虑到观测变量 (如图片) 通常由低维的隐变量 (如语义信息, 图像风格等) 生成, 研究人员通常在数据建模过程中引入隐变量, 然后将特定的隐变量解耦, 并且用于下游任务中. 例如, Cai 等人 [18] 和 Li 等人 [13] 在解决领域自适应问题中引入了解耦的领域变化和领域不变的隐变量; Kong 等人 [61] 进一步为解耦的隐变量提供了可识别性的理论保证; Yao 等人 [75] 则在时间序列建模中引入隐变量. 类似地, 本文在不同领域的时间序列建模中考虑了隐变量, 其中包括领域变化的隐变量 (如振幅和上下偏移变量) 和领域不变的隐变量 (如不同的频率变量).

2.2 数据生成过程

为了证明目标域的联合分布是可识别的, 本文首先介绍基于隐变量的数据生成过程, 该生成过程如图 2 所示, 其中观测变量 $x = \{x_1, \dots, x_t, \dots, x_T\}$ 由领域变化的隐变量 $z_d \in \mathbb{R}^{n_d}$ 和领域不变的隐变量 $z_c \in \mathbb{R}^{n_c}$ 通过一个非线性函数 g 生成, 领域变化隐变量 z_d 由领域变量 u 决定, 领域不变隐变量 z_c 由于标签类别 y 决定.

为了更好地理解图 2 所示的数据生成过程, 本文进一步结合图 1 提供一个简单易懂的例子. 例如 $x = \{x_1, \dots, x_t, \dots, x_T\}$ 表示不同的观测正弦曲线, z_d 表示振幅和上下偏移变量, z_c 表示不同的频率变量. 振幅和上下偏移变量随着不同领域变化而变化, 不同的频率由不同的标签 y 所决定. 本文使用符号及含义如表 1 所示.




图2 时间序列数据的因果生成过程

表1 符号和对应描述

Symbol	Meaning
x, y	多维时间序列变量和对应的标签
X	多维时间序列变量集合
z_c	领域不变隐变量
z_d	领域变化隐变量
u	领域
S, T	源域, 目标域
T	时间序列长度
n	隐变量维度
$L(\cdot)$	损失函数
∂	偏导
$\mathbb{R}$	自然数
$\prod$	连乘操作
$\sum$	连加操作

2.3 目标域联合分布的可识别性

基于第 2.1 节数据生成过程, 本节将展示如何恢复目标域的联合分布 $p(x, y, u_T)$. 通过引入领域变化的隐变量 z_d 和领域不变的隐变量 z_c , 可得以下公式:

$$p(x, y, u_T) = \int p(x, y, u_T, z_c, z_d) dz_c dz_d = \int p(x|z_c, z_d) p(y|z_c) p(u_T|z_d) p(z_d) p(z_c) dz_c dz_d \quad (1)$$

由公式 (1) 可知, 为了识别目标域的联合分布 $p(x, y, u_T)$, 需要识别以下几个分布.

- 1) 条件分布 $p(x|z_c, z_d)$, 该分布表示隐变量到观测变量的重构过程, 可以通过最小化观测变量 x 的重构误差恢复这个分布.
- 2) 条件分布 $p(y|z_c)$, 该分布表示通过领域不变隐变量 z_c 重构标签 y , 可以通过一个分类器并且最小化分类器误差来实现.
- 3) 条件分布 $p(u_T|z_d)$, 该分布表示领域变化的隐变量 z_d , 领域标签 u 的条件分布, 可以通过一个分类器并且最小化分类器误差来实现.
- 4) $p(z_c)$ 和 $p(z_d)$, 这两个分布分别表示领域不变的隐变量 z_c 和变化的隐变量 z_d 的先验分布. 本文假设该先验分布为高斯分布, 并且通过基对齐模块使得该隐变量得以恢复来识别 $p(z_c)$, 并且通过领域标签分类器来识别 $p(z_d)$.

3 领域变化隐变量的可识别性理论分析

在本节, 我们将介绍如何利用领域标签使得领域变化的隐变量 z_d 可识别. 为方便阐述, 本文先令 $z \in \mathbb{R}^n$, $z = \{z_d, z_c\}$, 且 $n = n_c + n_d$. 本文进一步令 $z_c = \{z_{c,i}\}_{i=1}^{n_c}$, $z_d = \{z_{d,i}\}_{i=n_c+1}^n$, 且令 $g: Z \rightarrow X$ 表示一个由隐变量到观测变量的可逆平滑函数. 所谓子空间可识别, 则是对于每一个真实的隐变量 z_d 和估计的隐变量 $\hat{z}_d$, 存在一个可逆函数 $h: \mathbb{R}^{n_d} \rightarrow \mathbb{R}$, 使得 $z_d = h(\hat{z}_d)$ 成立. 基于以上定义, 本文给出以下领域变化隐变量的可识别理论.

定理 1. 领域变化隐变量的子空间可识别性.

本文遵循图 2 所示的数据生成过程, 并做出以下假设.

- 1) 光滑且恒为正的假设: 隐变量的概率密度函数是光滑且恒为正的, 即对于任意取值的 z 和 u , 有 $p(z|u) > 0$.
- 2) 条件独立性假设: 给定领域标签 u 的条件下, 对于 $i, j \in \{1, \dots, n\}$, 每一维 z_i 独立于任意一维 z_j , 即 $\log p(z|u) = \sum p(z_i|u)$.
- 3) 线性独立假设: 对于任意的 $z_d \in Z_d \subseteq \mathbb{R}^{n_d}$, 存在 $n_d + 1$ 个不同的领域标签使得 n_d 个向量 $w(z_d, u_j) - w(z_d, u_0)$ 是线性独立的, 其中 $j \in \{1, \dots, n_d\}$, 且 $w(z_d, u_j)$ 的定义如下所示:

$$w(z_d, u_j) = \left(\frac{\partial \log p(z_{d,1}|u_j)}{\partial z_{d,1}}, \dots, \frac{\partial \log p(z_{d,i}|u_j)}{\partial z_{d,i}}, \dots, \frac{\partial \log p(z_{d,n_d}|u_j)}{\partial z_{d,n_d}} \right) \quad (2)$$

那么, 当通过模拟上述数据生成过程, 领域变化隐变量则是子空间可识别的.

证明: 当模型可以正确模拟图 2 所示的数据生成过程的时候, 有 $p(x|u) = p(\hat{x}|u)$. 接着, 本文通过以下推导构建真实隐变量 z 和估计隐变量 $\hat{z}$ 之间的关系.

令 $\hat{g}: Z \rightarrow X$ 表示一个估计的、可逆的生成函数, 于是可得公式 (3):

$$\forall u \in U, p(\hat{x}|u) = p(x|u) \iff p(\hat{g}(\hat{z})|u) = p(g(z)|u) \quad (3)$$

于是, 由变量变化定义可进一步得到公式 (4):

$$p(\hat{g}(\hat{z})|u) = p(g(z)|u) \iff p(g^{-1} \circ \hat{g}(\hat{z})|u) \Big|_{J_{g^{-1}}} = p(z|u) \Big|_{J_{g^{-1}}} \iff p(h(\hat{z})|u) = p(z|u) \quad (4)$$

其中, $h := g^{-1} \circ \hat{g}$ 表示从真实隐变量到估计隐变量之间的转换函数, $|J_{g^{-1}}|$ 表示 g^{-1} 的雅各比矩阵的行列式. 因为本文假设 g^{-1} 和 $\hat{g}$ 是可逆的, 所以 $|J_{g^{-1}}|$ 不等于 0 且 h 是可逆的.

然后由于独立性假设, 本文进一步可得公式 (5)、公式 (6):

$$p(z|u) = \prod_{i=1}^n p(z_i|u) \quad (5)$$

$$p(\hat{z}|u) = \prod_{i=1}^n p(\hat{z}_i|u) \quad (6)$$

然后通过联合公式 (6) 和公式 (3) 可得:

$$p(z|u) = p(h(\hat{z})|u) \iff p(\hat{z}|u) = p(z|u) |J_{h^{-1}}| \iff \sum_{i=1}^n \log p(z_i|u) + \log |J_{h^{-1}}| = \sum_{i=1}^n \log p(\hat{z}_i|u) \quad (7)$$

其中, $|J_{h^{-1}}|$ 表示 h^{-1} 的雅各比矩阵的行列式.

对于任意的 $j \in \{1, \dots, n_c\}$, 本文对公式 (7) 关于 $\hat{z}_j$ 求导然后可进一步得到:

$$\sum_{i=1}^n \frac{\partial \log p(z_i|u)}{\partial z_i} \cdot \frac{\partial z_i}{\partial \hat{z}_j} + \frac{\partial \log |J_{h^{-1}}|}{\partial \hat{z}_j} = \frac{\partial \log p(\hat{z}_i|u)}{\partial \hat{z}_j} \quad (8)$$

接着本文令 $u = u_0, \dots, u_k, \dots, u_{n_d}$, 通过将 u_k 和 u_0 分别代入公式 (8), 并且相减可得到公式 (9):

$$\sum_{i=1}^n \left(\frac{\partial \log p(z_i|u_k)}{\partial z_i} - \frac{\partial \log p(z_i|u_0)}{\partial z_i} \right) \cdot \frac{\partial z_i}{\partial \hat{z}_j} = \frac{\partial \log p(\hat{z}_i|u_k)}{\partial \hat{z}_j} - \frac{\partial \log p(\hat{z}_i|u_0)}{\partial \hat{z}_j} \quad (9)$$

由于估计隐变量 $\hat{z}_j$ 的分布不随着领域变化而变化, 因此可知 $\frac{\partial \log p(\hat{z}_i|u_k)}{\partial \hat{z}_j} - \frac{\partial \log p(\hat{z}_i|u_0)}{\partial \hat{z}_j} = 0$. 此外, 由于对于任意 $i \in \{1, \dots, n_c\}$, $\frac{\partial \log p(z_i|u_k)}{\partial z_i}$ 不会随着不同领域变化而变化, 因此 $\frac{\partial \log p(z_i|u_k)}{\partial z_i} = \frac{\partial \log p(z_i|u_0)}{\partial z_i}$. 因此公式 (9) 可以进一步写成如下形式:

$$\sum_{i=n_c+1}^n \left(\frac{\partial \log p(z_i|u_k)}{\partial z_i} - \frac{\partial \log p(z_i|u_0)}{\partial z_i} \right) \cdot \frac{\partial z_i}{\partial \hat{z}_j} = 0 \quad (10)$$

接下来, 根据线性独立假设, 可知由公式 (10) 组成的齐次线性方程组有 n_d 个未知数, 且具有唯一解, 即 $\frac{\partial z_i}{\partial \hat{z}_j} = 0$. 由于 $h(\cdot)$ 在 Z 上是连续的, 所以它的雅各比矩阵可以写成如下形式:

$$J_h = \begin{bmatrix} A := \frac{\partial z_d}{\partial \hat{z}_d} & B := \frac{\partial z_d}{\partial \hat{z}_c} \\ C := \frac{\partial z_c}{\partial \hat{z}_d} & D := \frac{\partial z_c}{\partial \hat{z}_c} \end{bmatrix} \quad (11)$$

其中, 对于 $\frac{\partial z_i}{\partial \hat{z}_j} = 0$ 且满足 $i \in \{n_c + 1, \dots, n\}$, $j \in \{1, \dots, n_c\}$ 的时候, 公式 (11) 所示的 $B = 0$. 由于 $h(\cdot)$ 是可逆的, 所以 J_h 是满秩矩阵. 结合 $B = 0$, 则 A 非零, 这意味着对于每一个 $z_{d,i}$ 存在一个 h_i , 使得 $z_{d,i} = h(\hat{z}_d)$, 因此 z_d 是子空间可识别的.

4 针对时间序列的隐变量解耦学习领域自适应模型

基于第 3 节理论结果, 本文提出针对时间序列的隐变量解耦学习领域自适应模型 (time series domain adaptation via disentangling invariant and variant latent variables, DIVV). 如图 3 所示, 图 3(a) 基于变分自动编码器的神经网络结构, 其中包括了时序编码器, 时序解码器, 标签预测器, 领域预测器和正交特征对齐模块. 图 3(b) 正交特征对齐模块框架图.




图 3 针对时间序列的隐变量解耦学习领域自适应模型框架图

4.1 基于变分自动编码器的神经网络结构

根据图 2 所示的数据生成过程, 本文首先推导出变分证据上界 (evidence lower bound) 以逼近观测变量的联合分布, 推导过程可分为以下 3 步.

首先本文使用贝叶斯定义了将观测变量的联合分布推导成如下形式:

$$\ln p(x, y, u) = \ln \frac{p(x, y, u, z_c, z_d)}{p(z_c, z_d | x, y, u)} = \ln \frac{p(x | z_c, z_d) p(y | z_c) p(u | z_d) p(z_c) p(z_d)}{p(z_c | x, y, u) p(z_d | x, y, u, z_c)} \quad (12)$$

然后, 本文通过对公式 (12) 两侧加上期望, 得到如下所示的公式 (13):

$$\begin{aligned} \mathbb{E}_{q(z_d|x)} \mathbb{E}_{q(z_c|x)} \ln p(x, y, u) &= D_{KL}(q(z_d|x) \| p(z_d|x, y, u, z_c)) + D_{KL}(q(z_c|x) \| p(z_c|x, y, u)) + \mathbb{E}_{q(z_d|x)} \mathbb{E}_{q(z_c|x)} \ln p(x | z_c, z_d) \\ &\quad + \mathbb{E}_{q(z_c|x)} \ln p(y | z_c) + \mathbb{E}_{q(z_d|x)} \ln p(u | z_d) - D_{KL}(q(z_c|x) \| p(z_c)) - D_{KL}(q(z_d|x) \| p(z_d)) \end{aligned} \quad (13)$$

最后由于 KL 散度总是非零值, 因此公式 (13) 可进一步化简成如下形式的变分证据上界.

$$\ln p(x, y, u) \geq \mathbb{E}_{q(z_d|x)} \mathbb{E}_{q(z_c|x)} \ln p(x | z_c, z_d) + \mathbb{E}_{q(z_c|x)} \ln p(y | z_c) + \mathbb{E}_{q(z_d|x)} \ln p(u | z_d) - D_{KL}(q(z_c|x) \| p(z_c)) - D_{KL}(q(z_d|x) \| p(z_d)) \quad (14)$$

通过以上变分证据上界, 本文将变分上界写成损失函数形式, 即:

$$\begin{cases} -ELBO = L_y + L_{VAE} \\ L_y = \mathbb{E}_{q(z_c|x)} \ln p(y | z_c) \\ L_{VAE} = \mathbb{E}_{q(z_d|x)} \mathbb{E}_{q(z_c|x)} \ln p(x | z_c, z_d) + \mathbb{E}_{q(z_d|x)} \ln p(u | z_d) - D_{KL}(q(z_c|x) \| p(z_c)) - D_{KL}(q(z_d|x) \| p(z_d)) \end{cases} \quad (15)$$

接下来本文进一步结合图 3(a) 所示的基于变分自动编码器的神经网络结构对模型进行进一步介绍.

4.1.1 时序编码器

时序编码器主要用于提取出时间序列数据的语义信息, 为了更好地提取语义信息, 本文提出的时序编码器包含两个组成部分: 1) 基于语义信息保留的数据增广; 2) 基于卷积神经网络的信息提取.

首先是基于语义信息的数据增广. 对于每一个时间序列样本 x , 本文采用不同的数据增广方式如: 添加参数为 0 均值, 1 方差的高斯噪声, 对时序数据进行随机维度置零操作 (dropout). 本文令增广后的数据用 $\tilde{x}$ 表示, 增广过程如公式 (16) 和公式 (17) 所示:

$$\text{添加高斯噪声: } \tilde{x} = x + \epsilon \quad (16)$$

$$\text{随机维度进行置零: } \tilde{x} = \text{dropout}(x) \quad (17)$$

通过数据增广后的数据, 本文采用基于卷积神经网络的结构进行信息提取, 过程如公式 (18) 所示:

$$z_k = f_k(CNN(x), \theta_k) \quad (18)$$

$$z_q = f_q(CNN(\tilde{x}), \theta_q) \quad (19)$$

$$\hat{z}_c, \hat{z}_d = f_m([z_k; z_q], \theta_m) \quad (20)$$

其中, f_k 表示原始数据特征提取网络, f_q 表示增广数据特征提取网络, f_m 用于将混合特征转换成领域变化特征和领域不变特征; $\theta_k, \theta_q, \theta_m$ 表示网络结构的参数. 本文令 f_m 前 n_c 维表示 $\hat{z}_c$, 其余维度表示 $\hat{z}_d$.

4.1.2 时序解码器

基于时序编码器获得的隐变量 $\hat{z}_c$ 和 $\hat{z}_d$, 本文进一步设计出时序解码器用于重构观测变量以保证隐变量 $\hat{z}_c$ 和 $\hat{z}_d$ 中的语义信息没有丢失, 其过程如公式 (21) 所示:

$$\hat{x} = \hat{g}(\hat{z}_c, \hat{z}_d; \theta_g) \quad (21)$$

其中, θ_g 表示神经网络参数, $\hat{x}$ 表示重构的时序数据.

4.1.3 标签预测器和领域预测器

基于提取到的领域变化和领域不变的隐变量, 本文进一步设计出标签预测器和领域预测器用于估计时间序列数据的标签和领域标签, 如公式 (22) 和公式 (23) 所示:

$$\hat{y} = C_y(\hat{z}_c; \theta_c) \quad (22)$$

$$\hat{d} = C_d(\hat{z}_d; \theta_d) \quad (23)$$

其中, C_y 和 C_d 表示标签分类器和领域分类器, θ_c 和 θ_d 分别表示对应模块的参数.

4.2 正交特征对齐模块不变约束

为了保证 $\hat{z}_c$ 中包含领域不变的信息, 现有的领域自适应方法通常采用不同的约束方法如生成对抗网络来保证不同领域中 $\hat{z}_c$ 的分布一致. 和针对具有固定特征尺度的图片数据不同, 因为不同领域的时间序列数据容易受到由上下偏移和振幅引起的特征尺度不同带来的影响, 所以采用经典的约束方法对特征进行约束容易导致语义信息的丢失. 为了解决这个问题, 发现特征矩阵通过奇异值分解 (singular value decomposition) 后可以分解为正交基和奇异值, 如公式 (24) 所示:

$$\hat{z}_c = U\Sigma V \quad (24)$$

其中, U 和 V 表示正交基, Σ 表示奇异值. 其中, 奇异值只和特征尺度有关而正交基用于保留语义信息. 因此只需要约束不同领域的正交基之间的距离即可以提取领域不变的特征. 为限制不同领域的正交基距离, 本文采用了文献 [59] 中使用的主角, 其定义如下:

定义 1. 主角 (principal angle). 给定 1 组源域的正交基 $B^S = [b_1^S, \dots, b_m^S]$ 和 1 组目标域的正交基 $B^T = [b_1^T, \dots, b_m^T]$, 则这两组正交基的主角定义如下:

$$\left\{ \begin{array}{l} \alpha_1^{S \leftrightarrow T} = \min_{b_1^S \in B^S, b_1^T \in B^T} \arccos \left(\frac{(b_1^S)^T b_1^T}{\|b_1^S\| \cdot \|b_1^T\|} \right) \\ \alpha_2^{S \leftrightarrow T} = \min_{\substack{b_2^S \in B^S, b_2^T \in B^T \\ b_2^S \perp b_1^S, b_2^T \perp b_1^T}} \arccos \left(\frac{(b_2^S)^T b_2^T}{\|b_2^S\| \cdot \|b_2^T\|} \right) \\ \dots \\ \alpha_m^{S \leftrightarrow T} = \min_{\substack{b_m^S \in B^S, b_m^T \in B^T \\ b_m^S \perp b_1^S, \dots, b_{m-1}^S \\ b_m^T \perp b_1^T, \dots, b_{m-1}^T}} \arccos \left(\frac{(b_m^S)^T b_m^T}{\|b_m^S\| \cdot \|b_m^T\|} \right) \\ \Theta^{S \leftrightarrow T} = [\alpha_1^{S \leftrightarrow T}, \alpha_2^{S \leftrightarrow T}, \dots, \alpha_m^{S \leftrightarrow T}] \end{array} \right. \quad (25)$$

基于以上定义, 本文进一步利用主角进一步限制源域和目标域之间的特征距离, 如公式 (26) 所示:

$$L_{pa} = \|\sin \Theta^{S \leftrightarrow T}\|_1 = \sum_{i=1}^m \sin \alpha_i^{S \leftrightarrow T}$$

(26)

4.3 模型总结

基于以上模型介绍, 本文给出目标函数, 如公式 (27) 所示:

$$L(\theta_k, \theta_q, \theta_m, \theta_g, \theta_c, \theta_d) = \gamma L_{VAE} + \beta L_{pa} + L_y$$

(27)

其中, β, γ 为超参数. 在上述目标函数下, 本文的模型在源域和目标域上使用 Adam 的优化算法进行训练:

$$\theta_k, \theta_q, \theta_m, \theta_g, \theta_c, \theta_d = \arg \min L(\theta_k, \theta_q, \theta_m, \theta_g, \theta_c, \theta_d).$$

本方法的时间消耗主要来自奇异值分解. 对于一个大小为 $m \times n$ 的矩阵, 它的 SVD 分解的时间复杂度为 $O(\min(m^2n, mn^2))$. 在实际场景下, 可以通过 GPU 进行加速, 每一个批次所消耗的时间为 0.25 s.

5 实验设计及结果分析

本文在 3 个公开基准数据集上进行了实验验证: UCI 人类活动识别 (UCI human activity recognition, UCIHAR)^[84]数据集, 异质性人类活动识别 (heterogeneity human activity recognition, HHAR)^[85]数据集, 以及人体行为姿势识别 (wireless sensor data mining, WISDM)^[86]数据集. 实验结果展示了在这些数据集上的 $F1$ 结果. 所有实验均采用了 3 个不同的随机种子进行多次重复实验, 并报告了多次随机种子结果的平均值. 所有数据集的参数设置如表 2 所示.

表 2 实验超参数描述以及取值

参数	描述	UCIHAR	HHAR	WISDM
optimizer	优化器	Adam	Adam	Adam
epoch	训练轮次	40	40	40
batch size	训练批次大小	32	32	32
Sequence len	时间序列长度	50	50	50
predict len	预测序列长度	50	50	50
Learning rate	学习率	0.005	0.0005	0.003

本次实验使用图形加速器的型号为 NVIDIA RTX A5000, 操作系统为 Linux (Ubuntu 版本为 16.04), CUDA 版本为 11.6, 程序在 PyTorch 1.12.0 框架下构建和训练, 采用的编程语言环境为 Python 3.9.16.

此外, 为了验证本文提出的 DIVV 的时间序列领域自适应方法中的每一个模块的有效性, 本文做了一系列消融实验并提供了可视化结果.

本文将在第 5.1 节中介绍数据集, 第 5.2 节简要介绍对比方法, 第 5.3–5.5 节展示并分析实验结果, 第 5.6 和 5.7 节对本文模型各模块的消融实验进行可视化.

5.1 数据集

5.1.1 UCIHAR 数据集

UCIHAR 数据集 (University of California, irvine-human activity recognition dataset) 是人体活动识别领域的一个重要资源, 旨在促进机器学习和数据挖掘算法的发展和评估. 该数据集由智能手机上的加速度计和陀螺仪传感器收集, 用于记录来自 30 名志愿者的活动数据. 数据集包含 6 种常见的人体活动类别, 涵盖站立、坐着、躺着、行走、上楼梯和下楼梯. 每个数据样本都包含了在 3 个轴 (X、Y、Z) 上的加速度和角速度数据, 以及相应的活动标签. 通常, UCIHAR 数据集被划分为训练集和测试集, 用于机器学习模型的训练和评估. 这个数据集在健康监测、智能设备和运动跟踪等领域具有广泛的应用潜力, 为研究人员和开发者提供了有效的工具, 以提高人体活动识别的准确性和应用水平. 通过对 UCIHAR 数据集的分析和理解, 可以为健康监测、智能技术和人体动作分析等领域的创新提供坚实的基础. 因此, 本文选择使用这个数据集来评估所提出的 DIVV 的时间序列预测领域自适应方法模型的性能.

5.1.2 HHAR 数据集

HHAR 数据集, 由智能手机和智能手表传感器异质数据组成, 旨在探究传感器异质性对人类活动识别算法 (包括分类、自动数据分割、传感器融合和特征提取等) 的影响. 该数据集包含来自 9 位用户的数据, 这些用户按特定顺序执行了包括骑单车、坐、站、走、上楼和下楼等 6 种活动. 数据集记录了两种常见智能手机运动传感器的读数, 即加速度传感器和陀螺仪, 这些传感器以各自设备所支持的最高采样频率记录了用户的活动数据. 该数据集的目的在于研究和理解传感器异质性对人类活动识别算法性能的影响. 在我们的实验中, 将每个用户视为一个领域. HHAR 数据集的数据样本维度为 128×3 . 本文将对数据进行切割, 取前 100×3 维度的数据, 并将其对半分两份 50×3 的数据, 前半部分用于训练, 后半部分与相应的序列标签对应.

5.1.3 WISDM 数据集

WISDM 数据集 (wireless sensor data mining) 是一个重要的开源数据集, 旨在支持人体活动识别领域的研究和算法开发. 该数据集收集了在真实世界环境中使用智能手机的加速度计和陀螺仪传感器所记录的多种人体活动, 包括步行、跑步、上下楼梯、坐着、站立和自行车骑行等. 这些活动数据包含了多个特征, 如 3 个轴上的加速度和角速度, 以及时间戳信息. WISDM 数据集的独特之处在于它模拟了日常生活中的多样性和复杂性, 涵盖了真实世界中多种活动场景. 因此, 本文选择使用这个数据集来评估所提出的 DIVV 的时间序列预测领域自适应方法模型的性能. WISDM 数据集的数据样本维度同样为 128×3 , 具体数据切割与 HHAR 数据集相同.

5.2 对比方法

除了传统的适用于静态数据的领域自适应方法, 本文还考虑了不变的时间依赖性提取方法, 以及其他从不同角度出发的时间序列领域自适应方法.

传统的适用于静态数据的领域自适应方法有: DDC^[87]通过最小化源域与目标域的最大平均差异 (MMD)^[88]来学习领域不变特征, 设计了梯度反转层对特征提取器网络的领域分类器进行反向训练; HoMM^[89]通过匹配源域和目标域的高阶矩, 最小化不同领域之间的差异; DSAN^[90]通过对齐相关子领域分布的局部最大平均差异 (LMMD) 来最小化源域和目标域之间的差异. 不变的时间依赖性提取方法有: SASA-IV^[12]利用因果关系的稳定性探索数据的领域不变结构, 并在领域间进行对齐.

此外, 本文还考虑了最新的基于频率的方法. 例如, AdvSKM^[15]利用对抗性光谱核匹配来解决时间序列数据中的非平稳性和非单调性问题. 另外, 本文还研究了 Raincoat^[16]方法. 此外, 本文在分析中还纳入了其他几种时间序列领域自适应方法, 例如 CoDATS^[79]和 CLUDA^[91].

对于所有的数据集, 本文采用 $F1$ 得分作为评价指标, 其计算方式如下所示:

$$F1 = 2 \times \frac{\text{精确率} \times \text{召回率}}{\text{精确率} + \text{召回率}}$$

5.3 UCIHAR 实验结果

本节展示并分析了本文所提出的基于 DIVV 的时间序列领域自适应方法在 UCIHAR 数据集下的实验结果. 本文从大量的跨域组合中随机选择了 12 组跨域场景进行实验, 分别为 $12 \rightarrow 16$, $14 \rightarrow 24$, $19 \rightarrow 16$, $1 \rightarrow 18$, $23 \rightarrow 21$, $24 \rightarrow 16$, $24 \rightarrow 18$, $3 \rightarrow 16$, $25 \rightarrow 16$, $3 \rightarrow 18$, $5 \rightarrow 16$, $8 \rightarrow 18$. 其中“ $\rightarrow$ ”两边的数字分别代表源域和目标域.

表 3 展示了 UCIHAR 数据集的实验结果, 通过实验结果, 本文可得出以下结论.

- 1) 本方法在 $F1$ 指标上表现总体优于其他 10 个对比方法, 具体而言, 本文所提出的方法对比 SASA-IV 提升了 4% 的准确率. 这些实验结果验证了本方法在时间序列分类任务上的优越泛化性能.
- 2) 传统的基于静态数据的领域自适应方法在时间序列数据集中难以取得良好表现, 这证明了针对时间序列数据的领域自适应面临挑战, 需要有针对性地设计模型.
- 3) 现有基于频率进行对齐的方法如 AdvSKM 在与本文 DIVV 方法相比存在不足, 因为这些方法不能保证学到的领域不变信息是可识别的, 有可能混杂了领域变化的特征, 导致效果变差. 而本文的 DIVV 方法成功地将领域变化和不变的信息解耦, 从而在预测任务上能够更好地排除领域偏移的影响.

4) 基于因果启发式学习的方法 SASA-IV 利用了稀疏结构对齐, 同样在时间序列分类的领域自适应任务中有良好的表现, 证明了因果知识在解决领域自适应问题上的优势.

表 3 UCIHAR 实验结果及其对比实验 (%)

Models	12→16	14→24	19→16	1→18	23→21	24→16	24→18	25→16	3→16	3→18	5→16	8→18
DDC	59.99	71.34	66.62	86.69	83.41	63.62	77.8	65.17	70.11	80.66	48.85	85.43
DANN	66.68	73.55	63.5	77.5	80.73	66.65	86.14	63.95	69.21	88.98	48.88	80.16
HoMM	54.16	90.55	61.19	93.95	81.42	63.72	85.79	67.28	73.54	93.01	49.97	92.56
CoDATS	63.65	89.98	56.91	93.56	90.34	59.00	85.11	65.58	68.42	88.01	50.02	92.85
DSAN	61.71	90.37	57.95	95.35	90.4	64.99	88.26	62.21	59.09	87.18	55.83	92.51
AdvSKM	58.47	77.91	40.00	93.23	73.06	65.89	84.63	67.43	68.57	85.31	46.48	86.89
SASA	63.68	85.65	63.51	84.3	87.24	62.73	82.66	69.2	74.49	92.06	51.92	87.77
CLUDA	54.13	82.42	45.01	72.47	84.45	59.84	68.98	58.72	53.85	67.42	41.55	67.90
Raincoat	68.04	77.02	49.87	74.77	79.25	65.27	79.85	62.83	69.82	85.41	51.87	88.04
SASA-IV	65.95	86.88	66.66	79.12	90.45	62.80	83.92	71.02	73.92	91.26	52.83	88.91
DIVV	68.81	91.49	68.04	95.73	92.2	67.43	89.42	72.58	76.7	93.41	56.16	93.47

5.4 HHAR 实验结果

本节展示并分析 DIVV 的时间序列领域自适应方法在 HHAR 数据集下的实验结果. 与 UCIHAR 数据集类似, 本文将每个主题视为一个单独的领域, 并随机选择 12 组跨域场景, 分别为 0→1, 0→8, 1→7, 2→1, 3→1, 4→1, 4→5, 6→1, 7→1, 7→6, 8→0, 8→1.

表 4 展示了 HHAR 数据集的实验结果, 通过实验结果, 本文可得出以下结论: 1) 在 10 组跨域场景实验下, 本方法实验结果在 $F1$ 指标上均优于其他 10 个对比方法. 在部分迁移方向中, 例如 0→8 和 8→1, 相比最新的对比方法, 本文获得 6.5%–10% 的提升. 2) 相比对抗和缩小域间差距, 基于频率对齐的方法如 AdvSKM 实验效果总体更好, 因为时间序列数据对频率敏感, 此类方法更能很好地完成这个任务. 3) 基于频率建模的方法比如 AdvSKM 和 DIVV 的效果总体优于基于 CNN 提取特征进行对齐的方法比如 DDC, 因为 HHAR 具有一定的周期信息, 基于频率建模的方法可充分学习其中频域信息.

表 4 HHAR 实验结果及其对比实验 (%)

Models	0→1	0→8	1→7	2→1	3→1	4→1	4→5	6→1	7→1	7→6	8→0	8→1
DDC	43.56	47.27	63.45	34.41	90.14	78.38	84.05	83.8	80.55	85.85	29.69	85.54
DANN	54.3	54.17	82.26	50.24	94.59	94.54	87.98	93.48	83.65	95.82	32.41	92.72
HoMM	49.56	68.54	86.35	40.17	96.09	86.84	90.64	89.44	81.19	86.68	37.95	92.87
CoDATS	55.74	71.91	89.51	44.59	96.35	94.65	92.96	92.1	87.91	95.11	41.84	93.76
DSAN	63.82	71.51	89.48	41.95	95.55	95.99	96.06	93.43	92.52	95.16	38.53	96.81
AdvSKM	42.17	54.95	67.62	41.24	87.45	78.51	87.14	87.06	75.66	85.71	37.78	86.81
SASA	60.4	63.78	89.9	47.17	94.73	85.5	89.7	93.38	86.54	94.34	38.31	91.93
CLUDA	59.87	61.28	89.28	50.9	95.05	92.1	88.77	91.32	91.56	90.55	40.35	90.47
Raincoat	47.82	44.42	86.81	35.19	91.66	76.57	63.8	91.26	78.22	90.01	34.56	94.75
SASA-IV	61.86	66.04	88.06	43.22	91.86	88.95	89.81	92.18	89.30	91.69	39.74	91.70
DIVV	64.64	73.71	91.28	53.57	96.5	96.36	96.85	94.2	93.56	96.59	43.05	97.46

5.5 WISDM 实验结果

本节展示并分析 DIVV 的时间序列领域自适应方法在 WISDM 数据集下的实验结果. 与 UCIHAR 数据集类似, 本文将每个主题视为一个单独的领域, 并随机选择了 12 组跨域场景, 分别为 4→8, 13→7, 34→10, 13→2, 10→1, 13→10, 5→10, 17→10, 33→7, 2→10, 35→10, 12→10.

表 5 展示了 WISDM 数据集的实验结果. 通过这些结果, 本文得出以下结论.

表 5 WISDM 实验结果及其对比实验 (%)

Models	4→8	13→7	34→10	13→2	10→1	13→10	5→10	17→10	33→7	2→10	35→10	12→10
DDC	73.23	65.56	68.11	57.38	69.06	40.78	69.98	42.61	63.55	72.21	55.43	52.67
DANN	69.44	68.52	67.82	61.48	77.15	53.01	71.17	61.17	59.64	68.9	58.86	67.37
HoMM	71.27	69.17	64.21	66.34	66.98	58.36	71.87	59.37	65.9	65.97	51.05	64.77
CoDATS	72.3	65.15	63.35	59.1	70.01	65.69	74.32	69.06	59.73	67.59	60.37	67.45
DSAN	82.15	57.28	66.62	56.78	78.7	66.89	73.68	65.63	50.28	70.09	61.19	51.59
AdvSKM	68.43	67.2	68.75	67.82	71.91	46.12	69.7	49.14	60.68	70.86	54.61	62.27
SASA	73.53	55.72	64.92	66.71	76.18	65.08	64.14	64.5	43.92	66.64	55.81	64.23
CLUDA	64.46	55.5	67.38	57.37	67.63	59.99	69.68	43.99	60.3	66.98	42.63	59
Raincoat	77.45	56.65	64.07	56.53	68.42	66.49	64.08	64.6	51.91	64.1	50.67	61.5
SASA-IV	82.35	58.15	61.41	64.62	79.58	63.51	62.48	65.75	58.02	67.27	57.22	64.43
DIVV	82.96	70.97	69.07	69.01	81.1	67.54	75.26	67.47	67.18	74.27	63.12	68.54

1) 本方法在 $F1$ 指标上表现总体优于其他 10 个对比方法, 证明了本方法优越的泛化性能.

2) 基于因果性学习的方法 SASA-IV 效果比传统的领域自适应方法如 DDC、HoMM 要好. 这是因为 WISDM 数据集的数据维度包括加速度、角速度和时间戳信息, 不同变量之间存在一定的时延因果关系, 因此 SASA-IV 能更充分地学习该数据集的信息.

3) 时间序列领域自适应方法如 DIVV 相比于非时间序列领域自适应方法如 DANN 效果更好, 这表明将非时间序列领域自适应方法应用于时间序列数据中存在局限性.

5.6 消融实验结果

为了更直观地体现本方法各模块的有效性, 本文提出了 3 种不同的模型变种, 如下所示.

a) 为了验证本文提出的基特征对齐不变约束的有效性, 本文将 L_{pa} 项去掉, 并且将得到的模型变种称为 DIVV-w 方法.

b) 为了验证本文提出的基于可识别理论的解耦模型的有效性, 本文将 L_{VAE} 去掉, 并且将得到的模型变种称为 DIVV-d 方法.

c) 为了验证本文提出的数据增广操作的有效性, 本文将数据增广操作去掉, 并且将得到的模型变种称为 DIVV-r 方法.

此外, 为了验证不同的对齐方法, 本文将正交特征对齐模块对齐替换成欧氏距离对齐和 MMD (maximum mean discrepancy) 对齐, 并且分别将得到的模型变种成为 DIVV-O 和 DIVV-M.

为了对比不同模型变种之间的性能, 本文在 UCIHAR 和 WISDM 数据集上分别随机选择 4 组跨域场景来做消融实验, 并将各消融实验的结果以柱状图形式进行可视化, 如后文图 4 和后文图 5 所示, 可得出以下结论: 1) 本文所提出方法优于各消融模型, 证明了本文提出的各个组件的必要性和有效性. 2) 在 UCIHAR 数据集上的 12→6 和 23→12 以及 WISDM 数据集上的 13→10 和 12→10 方向中, DIVV-w 方法相对于标准的 DIVV 方法性能下降最多, 证明了本文提出的基特征对齐不变约束的有效性. 3) 本文进一步通过去除 L_{VAE} , 发现在多个方向中实验结果都有不同程度的下降, 证明了本文基于可识别性的解耦理论在真实场景下的有效性. 4) 通过去除数据增广操作, 本文发现在大多数的迁移任务中都有下降, 证明了数据增广操作的可以有效地提升模型的泛化性. 5) 本文另外发现在 UCIHAR 数据集上的 23→21 迁移任务中 DIVV-d 和 DIVV-r 的实验结果变化不大, 这是因为这个迁移任务本身比较简单, 难以体现不同模型变种的差异性.

为了验证正交特征对齐模块的有效性, 本文进一步使用欧氏距离或者 MMD 进行替代并且在 WISDM 数据集上进行实验, 实验结果如后文表 6 所示. 由实验结果可知, 本文所提出的正交特征对齐模块能够更好地提取到解耦特征, 从而在下游任务中取得更好的分类效果.

5.7 预测结果可视化

为了验证本文提取的领域不变特征的有效性和本文基于可识别性理论的解耦方法的正确性, 本文进一步提供了基于 T-SNE 的可视化分析, 并与 CLUDA 和 Raincoat 两个基于时间序列数据的领域自适应方法进行比较, 实验

结果如图 6 所示, 其中红色和蓝色表示不同的领域. 通过以上的实验结果, 本文可以得出以下结论: 1) CLUDA 和 Raincoat 方法所对应的图中, 蓝色和红色的点簇不能很好地重叠, 这证明了这些方法不能很好地将领域变化和领域不变的特征解耦出来, 所以最终导致不理想的实验效果. 2) 由本文提出的 DIVV 方法所对应的可视化结构可以看出, 红色和蓝色的点比较好地重叠, 难以分开, 证明了领域不变特征的分布相似, 可以比较好地提取出领域不变信息, 从而获得比较好的分类效果.




图 4 UCIHAR 数据集消融实验结果可视化




图 5 WISDM 数据集消融实验结果柱状图

表 6 DIVV, DIVV-O 和 DIVV-M 在 WISDM 数据集上的实验结果 (%)

Models	4→8	13→7	34→10	13→2	10→1	13→10	5→10	17→10	33→7	2→10	35→10	12→10
DIVV	82.96	70.97	69.07	69.01	81.1	67.54	75.26	67.47	67.18	74.27	63.12	68.54
DIVV-O	81.36	69.88	68.75	67.82	78.51	66.24	73.7	63.48	65.28	71.86	60.00	65.71
DIVV-M	80.12	70.50	67.79	68.54	77.10	65.45	72.88	62.97	65.82	70.71	63.25	67.84




图 6 DIVV 和 CLUDA 和 Raincoat 的预测结果可视化

6 结束语

本文提出了一种基于可识别性基特征对齐的无监督领域自适应算法, 旨在解决时间序列数据领域自适应挑战. 通过针对时间序列数据的因果数据生成过程, 本文假设特征分为变化部分和不变部分, 并将这些部分用隐变量

表示. 基于可识别性理论, 本文设计了可识别基特征对齐领域自适应模型 (DIVV), 利用变分推断解耦领域变化的隐变量, 并采用基于正交特征对齐模块以解耦领域不变的隐变量. 最终, 本文采用领域不变特征进行时间序列分类, 并在多个真实数据集上进行验证. 实验结果表明, 本文提出的理论和模型在真实场景中具有显著的有效性, 为解决时间序列数据领域自适应问题提供了新的思路和方法.

References:

- [1] de Oliveira da Costa PR, Akçay A, Zhang YQ, Kaymak U. Remaining useful lifetime prediction via deep domain adaptation. *Reliability Engineering & System Safety*, 2020, 195: 106682. [doi: [10.1016/j.ress.2019.106682](https://doi.org/10.1016/j.ress.2019.106682)]
- [2] Purushotham S, Carvalho W, Nilanon T, Liu Y. Variational recurrent adversarial deep domain adaptation. In: *Proc. of the 5th Int'l Conf. on Learning Representations*. Toulon: OpenReview.net, 2017.
- [3] Tzeng E, Hoffman J, Saenko K, Darrell T. Adversarial discriminative domain adaptation. In: *Proc. of the 2017 IEEE Conf. on Computer Vision and Pattern Recognition (CVPR)*. Honolulu: IEEE, 2017. 2962–2971. [doi: [10.1109/CVPR.2017.316](https://doi.org/10.1109/CVPR.2017.316)]
- [4] Ganin Y, Ustinova E, Ajakan H, Germain P, Larochelle H, Laviolette F, Marchand M, Lempitsky V. Domain-adversarial training of neural networks. *The Journal of Machine Learning Research*, 2016, 17(1): 2096–2030.
- [5] Hoffman J, Tzeng E, Park T, Zhu JY, Isola P, Saenko K, Efros AA, Darrell T. Cycada: Cycle-consistent adversarial domain adaptation. In: *Proc. of the 35th Int'l Conf. on Machine Learning*. Stockholm: PMLR, 2018. 1989–1998.
- [6] Long MS, Cao Y, Wang JM, Jordan MI. Learning transferable features with deep adaptation networks. In: *Proc. of the 32nd Int'l Conf. on Machine Learning*. Lille: JMLR, 2015. 97–105.
- [7] Ozyurt Y, Feuerriegel S, Zhang C. Contrastive learning for unsupervised domain adaptation of time series. *arXiv:2206.06243*, 2023.
- [8] Stojanov P, Li ZJ, Gong MM, Cai RC, Carbonell JG, Zhang K. Domain adaptation with invariant representation learning: What transformations to learn? In: *Proc. of the 35th Int'l Conf. on Neural Information Processing Systems*. Curran Associates Inc., 2021. 24791–24803.
- [9] Bickel S, Brückner M, Scheffer T. Discriminative learning under covariate shift. *The Journal of Machine Learning Research*, 2009, 10: 2137–2155.
- [10] Gretton A, Smola A, Huang JY, Schmittfull M, Borgwardt K, Schölkopf B. Covariate shift by kernel mean matching. In: Quiñero-Candela J, Sugiyama M, Schwaighofer A, Lawrence ND, eds. *Dataset Shift in Machine Learning*. Cambridge: MIT Press, 2008. 131–160. [doi: [10.7551/mitpress/7921.003.0013](https://doi.org/10.7551/mitpress/7921.003.0013)]
- [11] Schölkopf B, Locatello F, Bauer S, Ke NR, Kalchbrenner N, Goyal A, Bengio Y. Toward causal representation learning. *Proc. of the IEEE*, 2021, 109(5): 612–634. [doi: [10.1109/JPROC.2021.3058954](https://doi.org/10.1109/JPROC.2021.3058954)]
- [12] Cai RC, Chen JW, Li ZJ, Chen W, Zhang KL, Ye JJ, Li ZZ, Yang XY, Zhang ZJ. Time series domain adaptation via sparse associative structure alignment. In: *Proc. of the 35th AAAI Conf. on Artificial Intelligence*. AAAI, 2021. 6859–6867. [doi: [10.1609/aaai.v35i8.16846](https://doi.org/10.1609/aaai.v35i8.16846)]
- [13] Li ZJ, Cai RC, Chen JW, Yan YG, Chen W, Zhang KL, Ye JJ. Time-series domain adaptation via sparse associative structure alignment: Learning invariance and variance. *arXiv:2205.03554*, 2022.
- [14] Li ZJ, Cai RC, Fu TZJ, Hao ZF, Zhang K. Transferable time-series forecasting under causal conditional shift. *arXiv:2111.03422*, 2023.
- [15] Liu Q, Xue H. Adversarial spectral kernel matching for unsupervised time series domain adaptation. In: *Proc. of the 30th Int'l Joint Conf. on Artificial Intelligence*. Montreal, 2021. 2744–2750.
- [16] He H, Queen O, Koker T, Cuevas C, Tsiligkaridis T, Zitnik M. Domain adaptation for time series under feature and label shifts. In: *Proc. of the 40th Int'l Conf. on Machine Learning*. Honolulu: JMLR, 2023. 12746–12774.
- [17] Ben-David S, Blitzer J, Crammer K, Pereira F. Analysis of representations for domain adaptation. In: *Proc. of the 20th Int'l Conf. on Neural Information Processing Systems*. Vancouver: MIT Press, 2006. 137–144.
- [18] Cai RC, Li ZJ, Wei PF, Qiao J, Zhang K, Hao ZF. Learning disentangled semantic representation for domain adaptation. In: *Proc. of the 28th Int'l Joint Conf. on Artificial Intelligence*. Macao: AAAI Press, 2019. 2060–2066.
- [19] Chen C, Fu ZH, Chen ZH, Jin S, Cheng ZW, Jin XY, Hua XS. HoMM: Higher-order moment matching for unsupervised domain adaptation. In: *Proc. of the 34th AAAI Conf. on Artificial Intelligence*. New York: AAAI Press, 2020. 3422–3429. [doi: [10.1609/aaai.v34i04.5745](https://doi.org/10.1609/aaai.v34i04.5745)]
- [20] Kim T, Cha M, Kim H, Lee JK, Kim J. Learning to discover cross-domain relations with generative adversarial networks. In: *Proc. of the 34th Int'l Conf. on Machine Learning*. Sydney: JMLR, 2017. 1857–1865.
- [21] Zhuang FZ, Luo P, He Q, Shi ZZ. Survey on transfer learning research. *Ruan Jian Xue Bao/Journal of Software*, 2015, 26(1): 26–39 (in

- Chinese with English abstract). <http://www.jos.org.cn/1000-9825/4631.htm> [doi: 10.13328/j.cnki.jos.004631]
- [22] Fu JH. On the deep transfer learning and its applications [MS. Thesis]. Nanjing: Nanjing University of Posts and Telecommunications, 2020 (in Chinese with English abstract). [doi: 10.27251/d.cnki.gnjdc.2020.000222]
 - [23] Li X. Research on cross domain image classification via transfer learning [Ph.D. Thesis]. Xi'an: Xidian University, 2017 (in Chinese with English abstract).
 - [24] Qin JW. Research of transfer learning and its application in classifying cross-domain data [Ph.D. Thesis]. Guangzhou: South China University of Technology, 2011 (in Chinese with English abstract).
 - [25] Li JJ, Meng LC, Zhang K, Lu K, Shen HT. Review of studies on domain adaptation. Computer Engineering, 2021, 47(6): 1–13 (in Chinese with English abstract). [doi: 10.19678/j.issn.1000-3428.0060659]
 - [26] Gu X. A study on cross-domain classification and its application [Ph.D. Thesis]. Wuxi: Jiangnan University, 2014 (in Chinese with English abstract).
 - [27] Tang S, Ye M, Li XD. Domain adaptation object recognition. ZTE Technology Journal, 2017, 23(4): 25–31 (in Chinese with English abstract). [doi: 10.3969/j.issn.1009-6868.2017.04.005]
 - [28] Xu M. A study on domain adaptation algorithm and its application [Ph.D. Thesis]. Wuxi: Jiangnan University, 2014 (in Chinese with English abstract).
 - [29] Sun Q, Ling WX. Source domain selection in transfer learning based on domain similarity rank. Science Technology and Engineering, 2020, 20(20): 8245–8251 (in Chinese with English abstract).
 - [30] Liang HT, Liu S, Du JW, Hu Q, Yu X. Review of deep learning applied to time series prediction. Journal of Frontiers of Computer Science and Technology, 2023, 17(6): 1285–1300 (in Chinese with English abstract). [doi: 10.3778/j.issn.1673-9418.2211108]
 - [31] Wei CX, Wang ZH, Yuan JD, Lin QH. Time series pattern discovery and classification with variable scales in time-frequency domains. Ruan Jian Xue Bao/Journal of Software, 2022, 33(12): 4411–4428 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/6346.htm> [doi: 10.13328/j.cnki.jos.006346]
 - [32] Mao YH, Sun CC, Xu LY, Liu X, Chai B, He PC. A survey of time series forecasting methods based on deep learning. Microelectronics & Computer, 2023, 40(4): 8–17 (in Chinese with English abstract). [doi: 10.19304/J.ISSN1000-7180.2022.0725]
 - [33] Zang WH. Research on transfer learning based on generative adversarial networks [MS. Thesis]. Chengdu: University of Electronic Science and Technology of China, 2018 (in Chinese with English abstract).
 - [34] Wang YY, Sun GW, Zhao GX, Xue H. Unsupervised new-set domain adaptation with self-supervised knowledge. Ruan Jian Xue Bao/Journal of Software, 2022, 33(4): 1170–1182 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/6478.htm> [doi: 10.13328/j.cnki.jos.006478]
 - [35] Jiang LL, Luo JJ, Zhu YP, Zhou DQ. A survey on adversarial attacks against deep learning. Aerospace Electronic Warfare, 2023, 39(1): 10–18, 50 (in Chinese with English abstract). [doi: 10.16328/j.htdz8511.2023.01.011]
 - [36] Xu XD. A classification method of visible digital watermarks based on transfer learning. Technology Innovation and Application, 2023, 13(8): 139–142 (in Chinese). [doi: 10.19981/j.CN23-1581/G3.2023.08.032]
 - [37] Han X. Domain adaptation based open set classification and semantic segmentation [MS. Thesis]. Nanjing: Nanjing University, 2019 (in Chinese with English abstract).
 - [38] Wang SC, Zheng F, Zhang L. Learning causal relationship from time series based on Bayesian network. Ruan Jian Xue Bao/Journal of Software, 2021, 32(10): 3068–3084 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/6012.htm> [doi: 10.13328/j.cnki.jos.006012]
 - [39] Cai RC, Li JH, Hao ZF. Unsupervised domain adaptive algorithm with intra-class maximum mean discrepancy. Application Research of Computers, 2020, 37(8): 2371–2375 (in Chinese with English abstract). [doi: 10.19734/j.issn.1001-3695.2019.03.0042]
 - [40] Locatello F, Tschannen M, Bauer S, Rätsch G, Schölkopf B, Bachem O. Disentangling factors of variation using few labels. arXiv:1905.01258, 2020.
 - [41] Tzeng E, Hoffman J, Zhang N, Saenko K, Darrell T. Deep domain confusion: Maximizing for domain invariance. arXiv:1412.3474, 2014.
 - [42] Wen J, Zheng NG, Yuan JS, Gong ZF, Chen CY. Bayesian uncertainty matching for unsupervised domain adaptation. arXiv:1906.09693, 2019.
 - [43] Wilson G, Doppa JR, Cook DJ. Multi-source deep domain adaptation with weak supervision for time-series sensor data. In: Proc. of the 26th ACM SIGKDD Int'l Conf. on Knowledge Discovery & Data Mining. ACM, 2020. 1768–1778. [doi: 10.1145/3394486.3403228]
 - [44] Yan HL, Ding YK, Li PH, Wang QL, Xu Y, Zuo WM. Mind the class weight bias: Weighted maximum mean discrepancy for unsupervised domain adaptation. In: Proc. of the 2017 IEEE Conf. on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017. 945–954. [doi: 10.1109/CVPR.2017.107]

- [45] Zhu YC, Zhuang FZ, Wang JD, Ke GL, Chen JW, Bian J, Xiong H, He Q. Deep subdomain adaptation network for image classification. *IEEE Trans. on Neural Networks and Learning Systems*, 2021, 32(4): 1713–1722. [doi: [10.1109/TNNLS.2020.2988928](https://doi.org/10.1109/TNNLS.2020.2988928)]
- [46] Long MS, Cao ZJ, Wang JM, Jordan MI. Conditional adversarial domain adaptation. In: *Proc. of the 32nd Int'l Conf. on neural Information Processing Systems*. Montréal: Curran Associates Inc., 2018. 1647–1657.
- [47] Pan SJ, Yang Q. A survey on transfer learning. *IEEE Trans. on Knowledge and Data Engineering*, 2010, 22(10): 1345–1359. [doi: [10.1109/TKDE.2009.191](https://doi.org/10.1109/TKDE.2009.191)]
- [48] Sakai H. On the spectral density matrix of a periodic ARMA process. *Journal of Time Series Analysis*, 1991, 12(1): 73–82. [doi: [10.1111/j.1467-9892.1991.tb00069.x](https://doi.org/10.1111/j.1467-9892.1991.tb00069.x)]
- [49] Liu GS, Zheng Y, Xie XR, Huang L, Ding HL. A dual active domain adaptation algorithm based on loss prediction strategy. *Chinese Journal of Computers*, 2023, 46(3): 579–593 (in Chinese with English abstract). [doi: [10.11897/SP.J.1016.2023.00579](https://doi.org/10.11897/SP.J.1016.2023.00579)]
- [50] Tang JK, Zhang H, Zhang ZQ, Wu TY. Image classification for unsupervised domain adaptation based on task relevant feature separation network. *Computer Science*, 2023, 50(11A): 230100068 (in Chinese with English abstract). [doi: [10.11896/jsjcx.230100068](https://doi.org/10.11896/jsjcx.230100068)]
- [51] Anguita D, Ghio A, Oneto L, Parra X, Reyes-Ortiz JL. A public domain dataset for human activity recognition using smartphones. In: *Proc. of the 2013 European Symp. on Artificial Neural Networks*, 2013. 437–442.
- [52] Zhang K, Schölkopf B, Muandet K, Wang ZK. Domain adaptation under target and conditional shift. In: *Proc. of the 30th Int'l Conf. on Machine Learning*. Atlanta: JMLR, 2013. III-819–III-827.
- [53] Zhao H, Melibari M, Poupart P. On the relationship between sum-product networks and Bayesian networks. In: *Proc. of the 32nd Int'l Conf. on Machine Learning*. Lille: JMLR, 2015. 116–124.
- [54] Ganin Y, Lempitsky V. Unsupervised domain adaptation by backpropagation. In: *Proc. of the 32nd Int'l Conf. on Machine Learning*. Lille: JMLR, 2015. 1180–1189.
- [55] Zhao H, Zhang SH, Wu GH, Costeira JP, Moura JMF, Gordon GJ. Adversarial multiple source domain adaptation. In: *Proc. of the 32nd Int'l Conf. on Neural Information Processing Systems*. Montréal: Curran Associates Inc., 2018. 8568–8579.
- [56] Alam F, Joty S, Imran M. Domain adaptation with adversarial training and graph embeddings. In: *Proc. of the 56th Annual Meeting of the Association for Computational Linguistics (Vol. 1: Long Papers)*. Melbourne: Association for Computational Linguistics, 2018. 1077–1087. [doi: [10.18653/v1/P18-1099](https://doi.org/10.18653/v1/P18-1099)]
- [57] Wright D, Augenstein I. Transformer based multi-source domain adaptation. In: *Proc. of the 2020 Conf. on Empirical Methods in Natural Language Processing (EMNLP)*. Association for Computational Linguistics, 2020. 7963–7974. [doi: [10.18653/v1/2020.emnlp-main.639](https://doi.org/10.18653/v1/2020.emnlp-main.639)]
- [58] Hochreiter S, Schmidhuber J. Long short-term memory. *Neural Computation*, 1997, 9(8): 1735–1780. [doi: [10.1162/neco.1997.9.8.1735](https://doi.org/10.1162/neco.1997.9.8.1735)]
- [59] Chen XY, Wang SN, Wang JM, Long MS. Representation subspace distance for domain adaptation regression. In: *Proc. of the 38th Int'l Conf. on Machine Learning*. PMLR, 2021. 1749–1759.
- [60] Ragab M, Eldele E, Chen ZH, Wu M, Kwok CK, Li XL. Self-supervised autoregressive domain adaptation for time series data. *arXiv:2111.14834*, 2021.
- [61] Kong LJ, Xie SA, Yao WR, Zheng YJ, Chen GY, Stojanov P, Akinwande V, Zhang K. Partial disentanglement for domain adaptation. In: *Proc. of the 39th Int'l Conf. on Machine Learning*. Baltimore: PMLR, 2022. 11455–11472.
- [62] Lipton Z, Wang YX, Smola A. Detecting and correcting for label shift with black box predictors. In: *Proc. of the 35th Int'l Conf. on Machine Learning*. Stockholm: PMLR. 3122–3130.
- [63] Graves A. Long short-term memory. *Supervised Sequence Labelling with Recurrent Neural Networks*. Springer, 2012. 37–45. [doi: [10.1007/978-3-642-24797-2_4](https://doi.org/10.1007/978-3-642-24797-2_4)]
- [64] Sun BC, Feng JS, Saenko K. Correlation alignment for unsupervised domain adaptation. In: Csurka G, ed. *Domain Adaptation in Computer Vision Applications*. Cham: Springer, 2017. 153–171. [doi: [10.1007/978-3-319-58347-1_8](https://doi.org/10.1007/978-3-319-58347-1_8)]
- [65] Jin Y, Wang XM, Long MS, Wang JM. Minimum class confusion for versatile domain adaptation. In: *Proc. of the 16th European Conf. on Computer Vision*. Glasgow: Springer. 2020. [doi: [10.1007/978-3-030-58589-1_28](https://doi.org/10.1007/978-3-030-58589-1_28)]
- [66] Vaswani A, Shazeer N, Parmar N, Uszkoreit J, Jones L, Gomez AN, Kaiser L, Polosukhin I. Attention is all you need. *arXiv:1706.03762*, 2023.
- [67] Vapnik VN. *The Nature of Statistical Learning Theory*. 2nd ed., New York: Springer, 2000. [doi: [10.1007/978-1-4757-3264-1](https://doi.org/10.1007/978-1-4757-3264-1)]
- [68] Stacke K, Eilertsen G, Unger J, Lundstrom C. Measuring domain shift for deep learning in histopathology. *IEEE Journal of Biomedical and Health Informatics*, 2021, 25(2): 325–336. [doi: [10.1109/jbhi.2020.3032060](https://doi.org/10.1109/jbhi.2020.3032060)]
- [69] Peharz R, Tschitschek S, Pernkopf F, Domingos P. On theoretical properties of sum-product networks. In: *Proc. of the 18th Int'l Conf. on Artificial Intelligence and Statistics*. San Diego: JMLR, 2015. 744–752.
- [70] Gens R, Domingos P. Learning the structure of sum-product networks. In: *Proc. of the 30th Int'l Conf. on Machine Learning*. Atlanta:

- JMLR, 2013. III-873–III-880.
- [71] Shi YJ, Ying XH, Yang JF. Deep unsupervised domain adaptation with time series sensor data: A survey. *Sensors*, 2022, 22(15): 5507. [doi: [10.3390/s22155507](https://doi.org/10.3390/s22155507)]
 - [72] Hu HL, Tang MJ, Bai CC. Datsing: Data augmented time series forecasting with adversarial domain adaptation. In: *Proc. of the 29th ACM Int'l Conf. on Information & Knowledge Management*. ACM, 2020. 2061–2064. [doi: [10.1145/3340531.3412155](https://doi.org/10.1145/3340531.3412155)]
 - [73] Lim B, Zohren S. Time-series forecasting with deep learning: A survey. *Philosophical Trans. of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 2021, 379(2194): 20200209. [doi: [10.1098/rsta.2020.0209](https://doi.org/10.1098/rsta.2020.0209)]
 - [74] Locatello F, Bauer S, Lucic M, Rätsch G, Gelly S, Schölkopf B, Bachem O. Challenging common assumptions in the unsupervised learning of disentangled representations. In: *Proc. of the 36th Int'l Conf. on Machine Learning*. Long Beach: PMLR, 2019. 4114–4124.
 - [75] Yao WR, Chen GY, Zhang K. Temporally disentangled representation learning. *arXiv:2210.13647*, 2022.
 - [76] Delalleau O, Bengio Y. Shallow vs. deep sum-product networks. In: *Proc. of the 25th Int'l Conf. on Neural Information Processing Systems*. Granada: Curran Associates Inc., 2011. 666–674.
 - [77] Ma DW. Time series forecasting based on causal network learning method [MS. Thesis]. Dalian: Dalian University of Technology, 2022 (in Chinese with English abstract). [doi: [10.26991/d.cnki.gdlu.2022.002228](https://doi.org/10.26991/d.cnki.gdlu.2022.002228)]
 - [78] Jin XY, Park Y, Maddix D, Wang H, Wang YY. Domain adaptation for time series forecasting via attention sharing. In: *Proc. of the 39th Int'l Conf. on Machine Learning*. Baltimore: PMLR, 2022. 10280–10297.
 - [79] Furqon MT, Pratama M, Shiddiqi AM, Liu L, Habibullah H, Dogancay K. Time and frequency synergy for source-free time-series domain adaptations. *Information Sciences*, 2025, 695: 121734. [doi: [10.1016/j.ins.2024.121734](https://doi.org/10.1016/j.ins.2024.121734)]
 - [80] Sugiyama M, Krauledat M, Müller KR. Covariate shift adaptation by importance weighted cross validation. *The Journal of Machine Learning Research*, 2007, 8: 985–1005.
 - [81] Zheng Y, Ng I, Zhang K. On the identifiability of nonlinear ICA: Sparsity and beyond. In: *Proc. of the 36th Conf. on Neural Information Processing Systems (NeurIPS 2022)*. New Orleans, 16411–16422.
 - [82] Khemakhem I, Kingma D, Monti R, Hyvarinen A. Variational autoencoders and nonlinear ICA: A unifying framework. In: *Proc. of the 23rd Int'l Conf. on Artificial Intelligence and Statistics*. Palermo: PMLR, 2020. 2207–2217.
 - [83] Li ZJ, Xu ZH, Cai RC, Yang ZH, Yan YG, Hao ZF, Chen GY, Zhang K. Identifying semantic component for robust molecular property prediction. *arXiv:2311.04837*, 2023.
 - [84] Stisen A, Blunck H, Bhattacharya S, Prentow TS, Kjærgaard MB, Dey A, Sonne T, Jensen MM. Smart devices are different: Assessing and mitigating mobile sensing heterogeneities for activity recognition. In: *Proc. of the 13th ACM Conf. on Embedded Networked Sensor Systems*. Seoul: ACM, 2015. 127–140. [doi: [10.1145/2809695.2809718](https://doi.org/10.1145/2809695.2809718)]
 - [85] Abdel-Basset M, Hawash H, Chang V, Chakraborty RK, Ryan M. Deep learning for heterogeneous human activity recognition in complex IoT applications. *IEEE Internet of Things Journal*, 2022, 9(8): 5653–5665. [doi: [10.1109/JIOT.2020.3038416](https://doi.org/10.1109/JIOT.2020.3038416)]
 - [86] Nair R, Ragab M, Mujallid OA, Mohammad KA, Mansour RF, Viju GK. Impact of wireless sensor data mining with hybrid deep learning for human activity recognition. *Wireless Communications and Mobile Computing*, 2022, Article ID 9457536. [doi: [10.1155/2022/9457536](https://doi.org/10.1155/2022/9457536)]
 - [87] Hu H, Ji X, Chi S, Jiao X. Conditional domain confusion networks for cross-domain detection. *IEEE Trans. on Instrumentation and Measurement*, 2022, 71(10): 1–13. [doi: [10.1109/TIM.2022.3203453](https://doi.org/10.1109/TIM.2022.3203453)]
 - [88] Gretton A, Borgwardt KM, Rasch MJ, Schölkopf B, Smola A. A kernel two-sample test. *The Journal of Machine Learning Research*, 2012, 13: 723–773.
 - [89] Peng XC, Bai QX, Xia XD, Huang ZJ, Saenko K, Wang B. Moment matching for multi-source domain adaptation. In: *Proc. of the 2019 IEEE/CVF Int'l Conf. on Computer Vision*. Seoul. 2019. 1406–1415. [doi: [10.1109/ICCV.2019.00149](https://doi.org/10.1109/ICCV.2019.00149)]
 - [90] Nejjar I, Geissmann F, Zhao MJ, Taal C, Fink O. Domain adaptation via alignment of operation profile for remaining useful lifetime prediction. *Reliability Engineering & System Safety*. 2024, 242: 109718. [doi: [10.48550/arXiv.2302.01704](https://doi.org/10.48550/arXiv.2302.01704)]
 - [91] Fang YQ, Wu JJ, Wang QQ, Qiu SJ, Bozoki A, Liu MX. Source-free collaborative domain adaptation via multi-perspective feature enrichment for functional MRI analysis. *Pattern Recognition*, 2025, 157(c): 110912. [doi: [10.1016/j.patcog.2024.110912](https://doi.org/10.1016/j.patcog.2024.110912)]

附中文参考文献:

- [21] 庄福振, 罗平, 何清, 史忠植. 迁移学习研究进展. *软件学报*, 2015, 26(1): 26–39. <http://www.jos.org.cn/1000-9825/4631.htm> [doi: [10.13328/j.cnki.jos.004631](https://doi.org/10.13328/j.cnki.jos.004631)]
- [22] 付家慧. 深度迁移学习算法及其应用研究 [硕士学位论文]. 南京: 南京邮电大学, 2020. [doi: [10.27251/d.cnki.gnjdc.2020.000222](https://doi.org/10.27251/d.cnki.gnjdc.2020.000222)]
- [23] 李晓. 基于迁移学习的跨域图像分类方法研究 [博士学位论文]. 西安: 西安电子科技大学, 2017.

- [24] 覃姜维. 迁移学习方法研究及其在跨领域数据分类中的应用 [博士学位论文]. 广州: 华南理工大学, 2011.
- [25] 李晶晶, 孟利超, 张可, 鲁珂, 申恒涛. 领域自适应研究综述. 计算机工程, 2021, 47(6): 1–13. [doi: 10.19678/j.issn.1000-3428.0060659]
- [26] 顾鑫. 跨领域分类学习方法及应用研究 [博士学位论文]. 无锡: 江南大学, 2014.
- [27] 唐宋, 叶茂, 李旭冬. 领域自适应目标识别综述. 中兴通讯技术, 2017, 23(4): 25–31. [doi: 10.3969/j.issn.1009-6868.2017.04.005]
- [28] 许敏. 领域自适应学习算法及其应用研究 [博士学位论文]. 无锡: 江南大学, 2014.
- [29] 孙俏, 凌卫新. 基于域间相似度序数的迁移学习源领域的选择. 科学技术与工程, 2020, 20(20): 8245–8251.
- [30] 梁宏涛, 刘硕, 杜军威, 胡强, 于旭. 深度学习应用于时序预测研究综述. 计算机科学与探索, 2023, 17(6): 1285–1300. [doi: 10.3778/j.issn.1673-9418.2211108]
- [31] 魏池璇, 王志海, 原继东, 林钱洪. 时间序列可变尺度的时频特征求解及其分类. 软件学报, 2022, 33(12): 4411–4428. <http://www.jos.org.cn/1000-9825/6346.htm> [doi: 10.13328/j.cnki.jos.006346]
- [32] 毛远宏, 孙琛琛, 徐鲁豫, 刘曦, 柴波, 贺鹏超. 基于深度学习的时间序列预测方法综述. 微电子学与计算机, 2023, 40(4): 8–17. [doi: 10.19304/J.ISSN1000-7180.2022.0725]
- [33] 臧文华. 基于生成对抗网络的迁移学习算法研究 [硕士学位论文]. 成都: 电子科技大学, 2018.
- [34] 汪云云, 孙顾威, 赵国祥, 薛晖. 基于自监督知识的无监督新集域适应学习. 软件学报, 2022, 33(4): 1170–1182. <http://www.jos.org.cn/1000-9825/6478.htm> [doi: 10.13328/j.cnki.jos.006478]
- [35] 蒋玲玲, 罗娟娟, 朱玉鹏, 周东青. 基于深度学习的对抗攻击技术综述. 航天电子对抗, 2023, 39(1): 10–18, 50. [doi: 10.16328/j.htdz8511.2023.01.011]
- [36] 许宪东. 基于迁移学习的一种可见数字水印分类方法. 科技创新与应用, 2023, 13(8): 139–142. [doi: 10.19981/j.CN23-1581/G3.2023.08.032]
- [37] 韩旭. 基于领域自适应的开放集图像分类与语义分割 [硕士学位论文]. 南京: 南京大学, 2019.
- [38] 王双成, 郑飞, 张立. 基于贝叶斯网络的时间序列因果关系学习. 软件学报, 2021, 32(10): 3068–3084. <http://www.jos.org.cn/1000-9825/6012.htm> [doi: 10.13328/j.cnki.jos.006012]
- [39] 蔡瑞初, 李嘉豪, 郝志峰. 基于类内最大均值差异的无监督领域自适应算法. 计算机应用研究, 2020, 37(8): 2371–2375. [doi: 10.19734/j.issn.1001-3695.2019.03.0042]
- [49] 刘贵松, 郑余, 解修蕊, 黄鹂, 丁浩伦. 一种基于损失预测的双主动域适应算法研究. 计算机学报, 2023, 46(3): 579–593. [doi: 10.11897/SP.J.1016.2023.00579]
- [50] 唐琨琨, 张辉, 张邹铨, 吴天月. 基于任务关联特征解耦网络的无监督领域自适应图像分类. 计算机科学, 2023, 50(11A): 230100068. [doi: 10.11896/jsjcx.230100068]
- [77] 马德伟. 基于因果网络学习方法的时间序列预测研究 [硕士学位论文]. 大连: 大连理工大学, 2022. [doi: 10.26991/d.cnki.gdlu.2022.002228]



李梓健(1994—), 男, 博士, 主要研究领域为迁移学习.



姜志帆(2000—), 男, 硕士生, 主要研究领域为因果表征学习, 多模态时间序列学习.



蔡瑞初(1983—), 男, 博士, 教授, 博士生导师, CCF 高级会员, 主要研究领域为因果发现, 图神经网络, 领域自适应学习, 自然语言处理.



陈道鑫(1996—), 男, 硕士, 主要研究领域为领域自适应学习.



陈浩芝(2001—), 男, 硕士生, 主要研究领域为时间序列分割.



郝志峰(1968—), 男, 博士, 教授, 博士生导师, CCF 专业会员, 主要研究领域为因果发现, 图神经网络, 领域自适应学习, 自然语言处理.