

时序数据域自适应的时空卷积与对抗互学习*

孙 杰^{1,2,3}, 李贵宸², 陈仲珊³, 王小正¹, 郑 豪¹, 陈长伟¹, 常合友¹

¹(南京晓庄学院 信息工程学院, 江苏 南京 211171)

²(南京邮电大学 计算机学院, 江苏 南京 210023)

³(南京特殊教育师范学院 数学与信息科学学院, 江苏 南京 210038)

通信作者: 孙杰, E-mail: jie.sun@njxzc.edu.cn



摘 要: 在时序数据分析领域, 跨域数据分布的偏移显著削弱了模型的泛化性能. 为此, 开发一种称为 TPN 的端到端时序数据域自适应框架. 该框架融合了时序模式激活模块 (TPAM) 与 Transformer 编码器. TPAM 通过双层时空卷积操作捕捉序列特征的空间及时间依赖性, 结合 Sigmoid 和 tanh 激活函数对提取的特征进行非线性融合, 再经由线性投影恢复至原通道尺寸, 以此强化模型的时序特征提取能力. TPN 还引入了增强对抗范式 (EAP), 通过域分类损失和操作顺序预测损失, 增强生成器与判别器的协同对抗, 有效缩减源域与目标域间的数据分布差距, 提升模型的域适应性. 在 Opportunity、WISDM 及 HHAR 这 3 大公开人体活动识别数据集上的实证结果显示, TPN 在准确率和 F1 值方面较现有方法最高提升了 6%, 且参数量和运行时间较少. 深入的消融与可视化实验进一步验证了 TPAM 和 EAP 的有效性, 表明 TPN 在特征抽取与域对齐上具有良好表现.

关键词: 时序数据域自适应; 时序模式激活模块; 增强对抗范式

中图法分类号: TP18

中文引用格式: 孙杰, 李贵宸, 陈仲珊, 王小正, 郑豪, 陈长伟, 常合友. 时序数据域自适应的时空卷积与对抗互学习. 软件学报, 2026, 37(3): 1340–1356. <http://www.jos.org.cn/1000-9825/7430.htm>

英文引用格式: Sun J, Li SC, Chen ZS, Wang XZ, Zheng H, Chen CW, Chang HY. Temporal-spatial Convolution and Adversarial Mutual Learning for Time Series Domain Adaptation. Ruan Jian Xue Bao/Journal of Software, 2026, 37(3): 1340–1356 (in Chinese). <http://www.jos.org.cn/1000-9825/7430.htm>

Temporal-spatial Convolution and Adversarial Mutual Learning for Time Series Domain Adaptation

SUN Jie^{1,2,3}, LI Shi-Chen², CHEN Zhong-Shan³, WANG Xiao-Zheng¹, ZHENG Hao¹, CHEN Chang-Wei¹,
CHANG He-You¹

¹(School of Information Engineering, Nanjing Xiaozhuang University, Nanjing 211171, China)

²(School of Computer Science, Nanjing University of Posts and Telecommunications, Nanjing 210023, China)

³(School of Mathematics and Information Science, Nanjing Normal University of Special Education, Nanjing 210038, China)

Abstract: In the field of time series data analysis, cross-domain data distribution shifts significantly weaken model generalization performance. To address this, an end-to-end time series domain adaptation framework, called TPN, is developed. This framework creatively integrates a temporal pattern activation module (TPAM) with a Transformer encoder. TPAM captures spatial and temporal dependencies of sequence features through dual-layer spatio-temporal convolution operations, combines Sigmoid and Tanh activation functions for the non-linear fusion of extracted features, and restores the original channel dimensions via linear projection, thus enhancing the model's ability to extract temporal features. TPN also introduces an enhanced adversarial paradigm (EAP), which strengthens generator-

* 基金项目: 国家自然科学基金 (62177028); 江苏省教育科学“十四五”重点课题 (B-b/2024/01/145); 江苏省高等教育学会重点课题 (2024CXJG029); 江苏省高等学校自然科学研究面上项目 (22KJD520005)

收稿时间: 2024-08-05; 修改时间: 2024-10-29, 2025-01-03, 2025-03-12; 采用时间: 2025-03-18; jos 在线出版时间: 2025-07-09

CNKI 网络首发时间: 2025-07-10

discriminator-based collaborative adversarial learning through domain classification loss and operation order prediction loss. This effectively reduces data distribution discrepancies between source and target domains, improving the model's domain adaptability. Empirical results on three public human activity recognition datasets (Opportunity, WISDM, and HHAR) demonstrate that TPN improves accuracy and $F1$ by up to 6% compared to existing methods, with fewer parameters and shorter runtime. In-depth ablation and visualization experiments further validate the effectiveness of TPAM and EAP, showing TPN's strong performance in feature extraction and domain alignment.

Key words: time series domain adaptation; temporal pattern activation module (TPAM); enhanced adversarial paradigm (EAP)

时序数据是一种常见的数据类型,它指的是按照时间顺序排列的数据序列,如股票价格、心电图、语音信号等。时序数据具有丰富的时域和空域信息,能够反映数据的动态变化和内在规律,因此在各个领域都有着广泛的应用,如金融分析、医疗诊断、语音识别等^[1,2]。

时序数据的分析和挖掘是一项重要的研究课题,其中一个典型的任务是时序数据的分类,即根据时序数据的特征,将其划分为不同的类别,如根据心电图数据判断心脏病的类型,根据语音信号识别说话人的身份等。时序数据的分类任务通常需要大量的标注数据来训练分类模型,然而,在实际应用中,标注数据往往是稀缺的、昂贵的或不可用的,这给时序数据的分类带来了很大的挑战^[3]。

为了解决标注数据不足的问题,一种常用的方法是利用迁移学习的思想,即利用一个或多个已有的标注数据集(源域)来辅助另一个缺少标注数据的数据集(目标域)的分类任务,这称为时序数据的域自适应。时序数据的域自适应的核心问题是如何解决不同域之间的数据分布偏移,即源域和目标域的数据分布不一致,导致分类模型在目标域上的性能下降。数据分布偏移的原因可能有很多,如数据采集的设备、环境、参数等的差异,或者数据本身的复杂性和多样性等^[4,5]。

为了减轻或消除数据分布偏移,目前已有许多时序数据的域自适应方法被提出,主要可以分为两类:基于特征对齐的方法和基于模型对齐的方法。基于特征对齐的方法的思想是通过一些变换或映射,将源域和目标域的数据映射到一个共同的特征空间,使得不同域的数据分布更加接近,从而提高分类模型的泛化能力。例如, CALDA^[6]利用对抗学习来调整源和目标特征表征,从而实现特征对齐。基于模型对齐的方法的思想是通过一些正则化或约束,使得分类模型在源域和目标域上的输出更加一致,从而提高分类模型的适应能力。例如,对抗神经网络(adversarial neural network, ANN)^[7,8]是一种基于模型对齐的方法,它使用一个对抗判别器来区分源域和目标域的数据,同时使用一个分类器来优化分类任务,通过对抗训练的方式,使得分类器在源域和目标域上的输出更加相似,从而实现模型对齐。

尽管已有的时序数据的域自适应方法取得了一定的效果,但是仍然存在一些不足之处,主要有以下两个方面:一是已有的方法没有充分考虑时序数据的时域和空域特征,而是将时序数据作为静态数据来处理,忽略了时序数据的动态性和依赖性,导致特征提取的不充分和不准确;二是已有的方法没有充分利用时序数据的多维特征,如频域特征、相位特征等,而是只使用时序数据的一维特征,忽略了时序数据的复杂性和多样性,导致特征对齐的不完善和不稳定^[9]。

为了解决上述问题,本文提出了一种基于时序模式激活模块(temporal pattern activation module, TPAM)和增强对抗范式(enhanced adversarial paradigm, EAP)的时序数据域自适应方法(TPN),用于解决时序数据在不同域之间的分布偏移问题。本文的主要思想是利用时空卷积网络^[10,11]和对抗生成网络^[8,12],分别从时序和域两个方面提高下游任务的性能。其中,TPAM模块旨在通过时空卷积网络提取更具判别性和适应性的时序模式特征,以减小域间的特征差异,从而实现特征对齐。而EAP则利用对抗生成网络,通过域分类损失和操作顺序预测损失,增强生成器和判别器的协同对抗能力,促使模型在源域和目标域上输出一致,实现模型对齐。本文的主要贡献和创新点如下。

(1) 提出了时序模式激活模块(TPAM),能够自动地从时序数据中提取出具有判别能力和适应性的时序模式特征,有效地增强了时序建模网络的性能。

(2) 提出了增强对抗范式(EAP),能够利用域分类损失和操作顺序预测损失,增强生成器和判别器的协同对抗能力,有效地减少了源域和目标域之间的数据分布偏移。

(3) 在3个公开的人体活动识别数据集上进行了广泛的实验,验证了本文方法的有效性和优越性,与其他对比

方法相比,本文方法在准确率和 $F1$ 值上都取得了提升,同时具有较少的参数量和运行时间.

(4) 进行了消融实验和可视化实验,分析了本文方法中的各个组成部分对最终结果的影响,展示了本文方法在特征提取和域对齐方面的效果.

本文第 1 节介绍时序数据分析和域自适应的相关方法和研究现状.第 2 节介绍本文提出的时序数据域自适应框架.第 3 节介绍本文方法的实验结果及其分析.最后总结全文.

1 相关工作

本文的工作结合了时序数据分析和域自适应两个方面的研究.在这一部分,我们将对这两个方面的相关工作进行简要的回顾和分析.

1.1 时序数据分析

时序数据分析是指对随时间变化的数据进行处理、建模、预测和分类等操作的过程.时序数据分析在许多领域都有广泛的应用,如气象学、医学、金融、工业、交通等.由于时序数据具有高维、非线性、非平稳、多尺度、多周期等特点,时序数据分析面临着很多挑战.

为了有效地分析时序数据,需要从数据中提取有意义的特征,捕捉数据的时域和频域信息.传统的时序数据分析方法主要基于统计学和信号处理的理论,如自回归模型 (AR)、移动平均模型 (MA)、自回归移动平均模型 (ARMA)、自回归积分滑动平均模型 (ARIMA)、小波变换 (WT)、傅里叶变换 (FT) 等^[1,13].这些方法虽然具有一定的理论基础,但是也存在一些局限性,如参数选择困难、模型假设过强、泛化能力不足等^[14].

近年来,随着深度学习的发展,许多基于神经网络的时序数据分析方法被提出,如循环神经网络 (RNN)^[15]、长短期记忆网络 (LSTM)^[16]、门控循环单元 (GRU)^[17]、变换器网络 (Transformer)^[18,19]等.文献 [20] 提出了一种基于迁移学习的时序数据域自适应方法,该方法通过将源域的知识迁移到目标域,提高了目标域的分类性能. Transformer 模型是一种基于自注意力机制的深度学习神经网络,它在自然语言处理领域取得了巨大成功,并逐渐被应用于时序数据分析领域^[21,22].与循环神经网络 (RNN) 相比, Transformer 模型能够更好地捕捉长距离依赖关系,并且更容易进行并行计算.

然而,现有的时序数据分析方法仍然存在一些不足.首先,大多数方法将时序数据视为静态数据,忽略了其固有的动态性和时间依赖性,导致无法充分提取时序特征,尤其是在处理具有复杂模式和长程相关性的数据时,这一缺陷尤为明显.其次,现有方法通常忽略了时序数据在不同域之间数据分布的显著差异,这种差异源于环境、设备或测量条件的变化,导致特征对齐不充分,影响了跨域模型的泛化能力和预测精度.

1.2 域自适应

域自适应是指在训练数据 (源域) 和测试数据 (目标域) 之间存在分布偏移的情况下,利用目标域的无标签数据,提升模型在目标域的泛化能力的过程^[23,24].域自适应在许多领域都有重要的应用,如计算机视觉、自然语言处理、生物信息学等.

然而,域自适应面临着多重挑战.首先,不同域的数据可能由不同的数据采集方式产生,比如,图像数据可能来自不同类型的相机,文本数据可能来自不同作者或不同语境,这些差异可能导致数据的质量、格式和特征空间的不一致性.其次,源域和目标域的数据分布可能有显著差异,例如,图像中的物体位置、大小、颜色,或者文本中的词汇频率和语法结构可能在不同域中表现出不同的统计特性.

为了有效地进行域自适应,需要减少源域和目标域之间的分布差异,使得模型能够学习到域不变的特征,提高模型的适应能力.在时间序列领域,领域适应 (DA) 方法通过特征对齐 (如最大均值差异, MMD) 减少源域和目标域之间的分布差异,以及实例重加权使源域数据更接近目标域的数据分布,从而提高深度神经网络在目标域上的表现^[25].文献 [26] 将现有的 DA 方法主要分为以下几类:域不变特征学习 (通过最小化分布差异、重建和对抗学习),域映射 (主要采用条件 GAN 进行像素级别的映射),规范化统计 (通过调整每层批归一化层的统计信息),集成方法 (使用多个模型组合的预测) 和目标域判别方法 (利用聚类假设将决策边界移到数据密度较低的区域).从对齐

的目标角度出发, 本文将域适应方法分为两大类: 特征对齐与模型对齐, 前者改变数据的表示, 后者改变模型的行为。

基于特征对齐的方法旨在通过找到一个共同的特征空间来减小源域和目标域之间的分布差异, 例如 CALDA^[6]通过最大化域间特征的相关性来实现这一点。这类方法的优点在于可以直接对齐不同域的特征分布, 但可能难以处理复杂的数据分布。而基于模型对齐的方法则侧重于通过约束模型在不同域上的输出一致性来实现域自适应, 例如 MDLR^[20]利用对抗训练的方式来实现这一点。然而, 无论是基于特征对齐还是模型对齐的方法, 都存在一些局限性, 例如难以处理复杂的数据分布或对抗训练不稳定等问题。

本文提出的 TPN 方法结合了特征对齐和模型对齐的思想, 旨在克服上述局限性。其中, TPAM 模块通过时空卷积网络提取更具判别性和适应性的时序模式特征, 实现了特征对齐; 而 EAP 则利用对抗生成网络, 通过域分类损失和操作顺序预测损失, 增强生成器和判别器的协同对抗能力, 实现了模型对齐。

2 时序数据域自适应框架

本文提出了一种基于时序建模和域校正的传感器数据域自适应方法, 用于解决不同域之间的数据分布偏移问题。本方法的主要思想是利用时空卷积网络和对抗生成网络, 分别从时序和域两个方面提取和对齐特征, 从而提高下游任务的性能。本方法的整体框架如图 1 所示, 其中域校正模块利用域分类损失减轻域偏移。




图 1 本文方法的整体框架

如图 1 所示, 时序建模网络负责提取高质量的时序特征, 为域校正模块提供有效的输入。域校正模块则通过对抗训练和域分类损失, 引导时序建模网络学习域不变的特征表示, 从而实现域自适应的目标。

2.1 时序建模网络

时序建模网络的目的是从输入的时序数据中提取时序特征, 捕捉数据的时域和空域依赖。时序数据通常可以表示为一个矩阵, 其中每一行代表一个时间步, 每一列代表一个传感器或特征维度。时序数据的空域特征指的是不同传感器或特征维度之间的关系。例如, 在人体活动识别任务中, 加速度计的 3 个轴 (x, y, z) 之间就存在着空间上的关联关系, 这种关系可以反映人体的运动姿态和方向。本文采用 Transformer 模型作为时序建模网络的基础结构, 如图 2 所示。其中, 时序模式激活模块 (TPAM) 通过双路时空卷积分别提取时间和空间特征, 并采用 $\tanh$ (时间路径) 和 Sigmoid (空间路径) 的异构激活函数组合实现注意力引导的特征融合, 最后经线性投影将特征维度对齐以便与原始 Transformer 架构整合。

Transformer 模型是一种基于自注意力机制的深度学习神经网络, 能够有效地处理序列数据, 学习数据的长期依赖关系。Transformer 模型的结构主要由编码器和解码器组成, 其中编码器由多个相同的层堆叠构成, 每个层包含一个自注意力子层和一个前馈神经网络子层, 两个子层都有残差连接和层归一化。解码器的结构与编码器类似, 只是多了一个编码器-解码器注意力子层, 用于融合编码器的输出和解码器的输入。本文只使用了 Transformer 的编码器部分, 将其作为时序建模网络, 将输入的时序数据映射为时序特征。

为了进一步增强时序建模网络的时序建模能力, 本文在 Transformer 的编码器中, 插入了时序模式激活模块 (TPAM)。TPAM 的结构如图 2 左侧所示。

为了应对变量间相关性随时间变化的问题, TPAM 模块在时间维度上使用了较小的卷积核, 以捕捉局部时间相关性。同时, 为了避免对预设的变量顺序产生依赖, TPAM 模块直接利用 Transformer 编码器学习到的特征表示, 其中已经包含了变量间的交互关系信息。

具体来说, TPAM 模块首先将输入的时序特征 $H \in \mathbb{R}^{T \times D}$ 视为一个长度为 T 、维度为 D 的特征图. 然后, TPAM 分别应用空间卷积核 W_{s1} , W_{s2} 和时间卷积核 W_{t1} , W_{t2} 对输入特征图进行两层时空卷积操作. 第 1 层空间卷积和时间卷积操作可以分别表示为:

$$F_{s1} = W_{s1} \otimes H \quad (1)$$

$$F_{t1} = W_{t1} \otimes H \quad (2)$$

其中, F_{s1} 和 F_{t1} 分别表示第 1 层空间卷积和时间卷积的输出特征图, $\otimes$ 表示卷积运算.




图 2 基于时空特征融合的时序建模网络架构图

第 2 层空间卷积和时间卷积操作以第 1 层的输出作为输入:

$$F_{s2} = W_{s2} \otimes F_{s1} \quad (3)$$

$$F_{t2} = W_{t2} \otimes F_{t1} \quad (4)$$

其中, F_{s2} 和 F_{t2} 分别表示第 2 层空间卷积和时间卷积的输出特征图.

接着 TPAM 模块分别对 F_{s2} 和 F_{t2} 应用 Sigmoid 和 tanh 激活函数, 并将激活后的特征图进行 Hadamard 乘积, 得到融合了时空信息的特征图:

$$F_{st} = \sigma(F_{s2}) \odot \phi(F_{t2}) \quad (5)$$

其中, Sigmoid 函数 σ 用于空间特征, 将输出范围控制在 0–1 之间, 可解释为空间维度上的注意力权重; tanh 函数 ϕ 用于时间特征, 输出范围在 $[-1, 1]$ 之间, 保留了时间特征的方向信息. 通过 Hadamard 乘积 $\odot$ 将两种激活后的特征进行融合, 使得空间特征可以作为门控机制来控制时间特征的信息流动. 当空间特征的 Sigmoid 输出接近 1 时会保留相应的时间特征, 而输出接近 0 时则会抑制相应的时间特征. 这种设计既实现了特征的选择性融合, 也保持了时间特征的动态变化信息.

最后 TPAM 模块通过一个线性投影层将 F_{st} 的通道数映射回原始维度 D (即 H 的通道数), 并将结果与输入特征 H 相加, 得到最终的输出特征 H' :

$$H' = H + W_p F_{st} \quad (6)$$

其中, W_p 是线性投影层的权重矩阵.

TPAM 模块通过时空卷积, 同时捕捉时序数据的空域和时域特征. 空间卷积提取特征维度间的依赖关系, 时间卷积捕捉数据随时间变化的动态模式. 这两种卷积结合, 使 TPAM 模块能学习到全面的特征表示.

如图 2 所示, 我们采用了一种层次化的特征提取策略, 将 TPAM 模块嵌入到 Transformer 架构中. 具体地, 我

们选择在第3层和第5层替换原有的 Encoder 层为 TPAM 模块, 并在其前后保留 Transformer 的 Encoder 层. 这种设计基于以下考虑: 首先, 浅层 Encoder (第1、2层) 主要提取基础特征表示, 为 TPAM 模块的时空特征建模提供良好的基础; 其次, 中层的 TPAM 模块 (第3、5层) 能够在初步语义信息的基础上进行时空特征建模, 实现局部时空模式与语义信息的有效融合; 最后, 深层 Encoder 继续提取高层语义特征, 并通过残差连接机制与 TPAM 提取的时空特征进行深度整合. 这种间隔分布的设计不仅确保了特征提取的渐进性, 也避免了 TPAM 模块过度集中可能带来的信息冗余. 通过这种多层次的特征提取和融合机制, 模型能够同时捕获数据的局部时空依赖关系和全局语义信息, 从而生成更具判别力的特征表示.

2.2 域校正模块

域校正模块的目的是减轻不同域之间的数据分布偏移, 使得不同域的数据分布更加一致, 从而提高域分类的准确率. 为了实现这一目的, 本文采用了对抗生成网络 (generative adversarial network, GAN) 作为域校正模块的基础结构, 其具体结构如图3所示. 其中, G 为生成器, D 为判别器, Z 表示随机噪声, 虚线箭头表示反向传播过程中的梯度流.




图3 域校正模块

GAN 是一种基于对抗训练的深度学习神经网络, 能够通过生成器和判别器的博弈, 学习数据的真实分布, 生成高质量的数据. 本文将时序建模网络的输出 (包括源域与目标域) 作为生成器的输入, 将生成器的输出作为域分类器 C 的输入, 将域分类器的输出作为域分类的结果.

域校正模块中的判别器 D 和域分类器 C , 两者都是分类器, 但目标不同. 判别器 D 的目的是区分源域和目标域的特征表示, 它试图区分哪些特征来自真实的目标域数据, 哪些特征是由生成器生成的. 而域分类器 C 的目的是区分源域和目标域的数据样本, 它接收生成器生成的特征作为输入, 并判断这些特征属于哪个域. 简单来说, 判别器 D 关注的是特征的真假, 而域分类器 C 关注的是特征的来源.

为了加强域校正模块的域校正能力, 本文在对抗训练的过程中, 引入了操作顺序互学习 (operation sequence mutual learning, OSML) 的策略. 传统的 GAN 训练过程中, G 和 D 的优化顺序是固定的, 这可能导致 G 和 D 陷入局部最优解, 或出现模式崩溃等问题. OSML 的思想是: 在每个训练迭代中, 操作顺序预测器 P 根据 G 和 D 的输出, 预测下一个操作顺序是更新 G 还是更新 D . 操作顺序预测器 P 由一个全连接层和一个 Softmax 层组成, 输入是 G 和 D 的输出的拼接, 输出是一个二维向量, 表示更新 G 或更新 D 的概率. 在每个训练迭代中, 随机选择一个操作顺序, 即先更新 G 还是先更新 D , 然后将这个操作顺序作为一个额外的监督信号, 用于指导 G 或 D , 使其能够预测下一个操作顺序, 并根据预测结果调整自己的参数. 这样, G 和 D 的博弈过程更加公平、高效, 最终达到纳什均衡. OSML 的数学表达式为:

$$\min \max_G L(D, G) = \mathbb{E}_{x \sim p_d} [\log D(x)] + \mathbb{E}_{z \sim p_z} [\log (1 - D(G(z)))] - \eta \mathbb{E}_{z \sim p_z} [H(p_g)] + \gamma \mathbb{E}_{z \sim p_z} [L_{\text{OSML}}(P, D, G)] \quad (7)$$

其中, $L(D, G)$ 是生成器和判别器的对抗损失, 表示 D 尽可能地区分真实数据和假数据, G 尽可能地欺骗 D . $H(p_g)$ 是生成的假数据分布 p_g 的熵, 表示生成分布的不确定性, 值越大表示生成样本越丰富多样. $L_{\text{OSML}}(P, D, G)$ 是操作顺序互学习的损失函数, 表示生成器和判别器互相预测对方的操作顺序, 并根据预测结果调整自己的参数. η 和 γ 是权重超参数, 用于平衡不同的损失项.

域分类器 C 是一个神经网络模型, 它接收生成器 G 的时序特征输出, 通过隐藏层提取高层特征, 并通过输出

层的 Softmax 函数输出数据的域概率分布. C 的目标是增强 G 的域适应能力, 减少源域和目标域的数据分布差异. 在训练过程中, 我们先更新 C 的参数以区分真实和生成数据的域标签, 然后更新 G 的参数以欺骗 C , 使生成数据的域标签与目标域一致. 这两步反复进行, 直到 C 和 G 达到动态平衡, 即 C 无法区分真实和生成数据的域标签, 且 G 的输出与目标域的数据分布相似.

2.3 增强对抗范式

增强对抗范式 (EAP) 是本文提出的一种改进的对抗训练策略, 用于提高域校正模块的对抗性能和适应性. EAP 包含一个生成器 G , 一个判别器 D , 一个域分类器 C 和一个操作顺序预测器 P , 其中 G 和 D 构成对抗生成网络, C 和 P 分别用于增强域分类能力和操作顺序互学习能力. EAP 的损失函数包含 3 部分: 对抗损失、域分类损失和操作顺序预测损失, 其数学表达式为:

$$L_{\text{EAP}} = \min \max_G L_{\text{GAN}}(D, G) + \lambda L_{\text{DA}}(C, G) + \mu L_{\text{OSML}}(P, G, D) \quad (8)$$

其中, λ 和 μ 是两个超参数, 用于控制不同损失函数的权重, $L_{\text{GAN}}(D, G)$ 是对抗生成网络的损失函数, 与标准的 GAN 相同, 用于训练生成器和判别器的对抗能力:

$$L_{\text{GAN}}(D, G) = \mathbb{E}_{x \sim p_x} [\log D(x)] + \mathbb{E}_{z \sim p_z} [\log (1 - D(G(z)))] \quad (9)$$

域分类损失 $L_{\text{DA}}(C, G)$ 是一个交叉熵损失函数, 表示域分类器 C 尝试将生成器 G 的输出正确地分类为目标域, 而生成器 G 尝试使其输出被误分类为源域. 其计算公式为:

$$L_{\text{DA}}(C, G) = -\mathbb{E}_{x \sim p_g} [\log C(x)] - \mathbb{E}_{x \sim p_d} [\log (1 - C(x))] \quad (10)$$

其中, p_g 是 G 的输出分布, p_d 是目标域的数据分布, $C(x)$ 是域分类器 C 对输入 x 的分类概率, 取值为 0 或 1, 表示 x 属于源域或目标域.

操作顺序预测损失 $L_{\text{OSML}}(P, G, D)$ 是一个均方误差损失函数, 表示操作顺序预测器 P 尝试根据 G 和 D 的输出, 预测下一个操作顺序是更新 G 还是更新 D , 而 G 和 D 尝试使其输出难以被预测. 其计算公式为:

$$L_{\text{OSML}}(P, G, D) = \mathbb{E}_{x \sim p_g, y \sim p_d} [(P(G(x), D(y)) - s)^2] \quad (11)$$

其中, s 是一个随机变量, 取值为 0 或 1, 表示下一个操作顺序是更新生成器还是更新判别器, $P(G(x), D(y))$ 是操作顺序预测器 P 对输入 $G(x)$ 和 $D(y)$ 的预测概率, 取值为 0 或 1, 表示预测的操作顺序是更新生成器还是更新判别器.

假设 G 的输出为 $G(x) = [0.2, 0.4, 0.6]$, D 的输出为 $D(y) = [0.8, 0.7, 0.5]$, C 的输出为 $C(G(x)) = 0.3$, P 的输出为 $P(G(x), D(y)) = 0.4$, 下一个操作顺序的真实值为 $s = 1$, 则域分类损失和操作顺序预测损失分别为:

$$L_{\text{DA}}(C, G) = -\log 0.3 - \log 0.7 \approx 1.203 \quad (12)$$

$$L_{\text{OSML}}(P, G, D) = (0.4 - 1)^2 = 0.36 \quad (13)$$

其中, 1.203 是域分类损失, 这个值越小, 说明域分类器 C 的域分类能力越强, G 的域适应能力越强. 0.36 是操作顺序预测损失的值, 这个损失值越小, 说明操作顺序预测器 P 的预测能力越强.

增强对抗范式部分是本文方法与传统 GAN 的不同之处, 即引入了新的训练机制, 目的不是生成新数据, 而是通过增强判别器的判别、对抗和适应能力, 从而提高域自适应中的分类性能.

3 实验结果及分析

在端到端的训练过程中, 源域和目标域的时序数据首先被输入到时序建模网络以获取特征表示. 这些特征随后被输入到域校正模块, 其中生成器试图生成与目标域数据分布相似的特征. 这些生成的特征和目标域的真实特征都被输入到判别器和域分类器. 判别器的目标是区分真实特征和生成特征, 而生成器的目标是生成能欺骗判别器的特征. 域分类器用于引导生成器生成更接近目标域分布的特征. 此外, 生成器和判别器之间采用了互学习机制, 以提高对抗训练的稳定性和效率.

3.1 实验设置

表 1 展示了我们在实验中使用的 Transformer 模型的具体参数设置. 参数的选择基于: (1) 数据集的规模和复

杂度; (2) 计算资源的限制. 在保证模型性能的同时, 也能控制模型的计算复杂度和训练时间. 表 1 中的参数分别表示模型的层数 (L)、自注意力头数 (H)、隐藏维度 (HD) 和前馈神经网络维度 (F).

表 2 列出了域校正模块的参数设置, 包括生成器 G 和判别器 D 的层数 (L)、卷积核大小 (K)、卷积核数量 (N)、步长 (S)、批归一化 (BN)、激活函数 (AF)、损失函数 (LF) 和优化器 (OP). 参数的选择关乎模型的对抗性能和稳定性. 一般而言, 参数越大, 模型的表达能力越强, 但计算复杂度和训练难度也会随之增加. 考虑到数据集的规模、复杂度和实验环境的限制, 我们选择了适中的参数, 以确保模型在对抗性能和稳定性之间取得平衡.

表 1 Transformer 模型的参数设置

参数	UCI HHAR dataset	Opportunity dataset
L	4	6
H	8	8
HD	64	128
F	256	512

表 2 GAN 模块的参数设置

参数	生成器 G	鉴别器 D
L	6	6
K	3	3
N	64	64
S	2	2
BN	是	否
AF	ReLU	LeakyReLU
LF	LSGAN	LSGAN
OP	Adam	Adam

TPAM 模块中, 时间卷积核的大小设置为 $K_t = 3$, 空间卷积核的大小设置为 $K_s = 1$. 两层时空卷积层的通道数分别设置为 64 和 128. OSML 模块中, 操作顺序预测器 P 由一个 512 维的全连接层和一个 Softmax 层组成. 其损失函数采用交叉熵损失, 优化器为 Adam, 学习率为 0.0001, 动量为 0.9, 权重衰减为 0.0001.

3.2 数据集

不同场景下收集的数据分布不同, 这种差异称为域差距. 为了评估我们方法的域适应性能, 我们选择了 3 个人体活动识别数据集作为基准. 本文提出的 TPN 方法采用只在源域上训练和验证, 而在目标域上测试的策略. 图 4 和后文图 5、图 6 分别是用 PCA 对 3 个数据集降维后的数据分布示意图, 两个轴的括号里显示了主成分的百分比. 后文表 3 给出了 3 个数据集的统计信息.




图 4 Opportunity 数据集的 4 个受试者的数据分布示意图

3.2.1 Opportunity 数据集

Opportunity 数据集是一个人类活动识别基准测试集^[27], 包含 72 个传感器分布在环境、物体和人体上, 模拟公寓环境中的日常活动. 这些活动包括短动作 (如打开冰箱)、手势 (如与咖啡机交互)、行走方式等. 这种多模态特性为域适应问题提供了丰富的研究场景. 本研究主要分析了 5 种高级行为, 包括放松、喝咖啡时间、早晨、清理和做三明治时间. 选择这 5 种高级行为是因为它们代表了日常生活中的常见活动.

在 Opportunity 数据集中, S1、S2、S3 和 S4 是不同的受试者. 本文选择 S1 作为源域, S2、S3 和 S4 作为目标域.

3.2.2 WISDM 数据集

WISDM 数据集是一个广泛应用于人体活动识别研究的数据集^[28], 它由 36 个参与者的三轴加速度计数据构

成, 这些数据以 20 Hz 的频率采集. 该数据集包含 6 种主要的人体活动: 行走、慢跑、坐、立、上、下楼梯. 然而, 参与者之间存在着行为差异和类别不平衡问题. 例如参与者 9 只进行了步行, 但参与者 5 执行了所有的活动. 我们将每个研究对象视为一个单独的领域, 并随机选择 3 个跨领域场景. 与 RAINCOAT^[29]以及 CALDA^[6]一样, 每个场景都执行了所有的活动.




图 5 WISDM 数据集上 4 个受试者的数据分布示意图




图 6 HHAR 数据集上手表加速度计的 4 个受试者的数据分布示意图

表 3 数据集的统计特性

数据集	受试者 (个)	通道数	类别数	训练集	测试集
Opportunity	4	3	5	S1	S2, S3, S4
WISDM	36	3	6	3	5, 6, 7
HHAR	9	3	6	a	b, c, d
人工合成	4	3	6	a	b, c, d

3.2.3 HHAR 数据集

异质性人类活动识别 (HHAR) 数据集是一个用于研究传感器异质性对人类活动识别算法影响的数据集^[30]. 它包含了来自智能手机和智能手表的传感器读数, 记录了 9 位用户执行的活动. 用户的 6 类活动没有特定的顺序: 骑自行车、坐着、站立、走路、上楼和下楼. 用户的智能手机和智能手表都具有两种类型的传感器, 即加速度计和陀螺仪, 以各自设备允许的最高频率进行采样. 考虑到每个受试者的行为差异, 本文将手表加速度计 (watch acc) 中的 9 个受试者作为单独的域, 选择其中 4 个构建了 3 种跨域场景, 如表 3 所示.

在图 4—图 6 中, 源域或目标域不同的形状表示不同的类别. 可以看出, 我们选择的数据集的源域与目标域的数据分布存在较大的差异, 适合具有挑战性的域适应研究.

3.2.4 人工合成数据集

为进一步验证 TPN 在不同类型时序数据上的泛化能力, 并弥补现有真实数据集在数据分布和复杂性上的局限, 我们采用 Prophet 模型生成了一组人工合成数据集. Prophet^[31]是一种基于时间序列分解的预测模型, 能够模拟

时间序列的趋势、周期性和季节性等特征. 我们利用 HHAR 数据集中的活动时序数据, 通过 Prophet 模型生成了具有相似动态特征但数据分布更加多样的人工合成数据. 该数据集涵盖了不同的活动类型和传感器模式, 并引入了可控的噪声和扰动, 从而为评估 TPN 在不同数据条件下, 特别是存在数据分布偏移情况下的泛化能力提供了一个新的维度, 能更全面验证模型的鲁棒性.

为了直观展示生成的数据, 我们对经过下采样处理的部分原始加速度数据 (x 、 y 、 z 轴) 与 Prophet 模型生成的相应数据进行了时间维度上的对比分析 (如图 7 所示). 可以观察到, 生成的数据在保留原始数据动态特征的同时, 引入了更多的变化.




图 7 原始数据与 Prophet 生成数据的对比波形图

3.3 时序特征的可视化分析

为了直观地展示本文方法在时序建模方面的优势, 本文以 HHAR 数据集的手表加速度计的受试者 a 的时序数据为例, 采用了 PCA 算法对时序特征进行了降维和可视化. 本文将时序建模网络的输出作为输入, 将维度降到 2 维, 然后用不同的颜色和形状表示不同的域和类别, 得到了如图 8 所示的可视化结果. 其中, 不同的颜色表示不同的域, 图 8(a)–(c) 分别表示域校正前的站、坐和走路的时序特征; 图 8(d)–(f) 分别表示域校正后的站、坐和走路的时序特征.




图8 HHAR 的手表加速度计 a 用户的时序特征的可视化结果

从图8中可以看出,不使用TPAM和EAP时,直接使用PCA降维方法获得的时序特征的可视化结果如图7(a)–(c)所示,时序特征的分布差异较大,3个不同的类别的域之间的界限明显.图7(d)–(f)是我们方法得到的时序特征,我们的方法经过了域校正,3个不同类别的源域与目标域的特征分布靠得更近了,显著降低了域偏移的影响.因此,本文方法能够有效地区分不同的域和类别,表明时序特征具有较强的判别能力和适应能力.

为了定量地评估时序特征的质量,本文还计算了时序特征的内部距离 (*Intra-distance*) 和外部距离 (*Inter-distance*). 内部距离表示同一域同一类别的数据点之间的平均欧氏距离,反映了时序特征的紧凑性; 外部距离表示不同域不同类别的数据点之间的平均欧氏距离,反映了时序特征的分异性. 理想的时序特征应该具有较小的内部距离和较大的外部距离,从而实现不同域和类别的数据点的有效区分. 本文将内部距离和外部距离的比值作为时序特征的质量指标,记为 Q , 其计算公式为:

$$Q = \frac{\text{Intra-distance}}{\text{Inter-distance}} \quad (14)$$

以HHAR数据集的手表的加速度计为例,后文图9展示了本文提出的方法与4种基线方法(LSTM、CALDA、Transformer和TCN)在时序特征质量指数 Q 上的对比结果. 为保证公平性,所有方法采用相同的主要参数设置,即输入维度为3,隐藏层维度为128,输出维度为6. 实验结果表明,本文方法在6个不同类别上的 Q 值均显著低于4种基线方法. 这表明,本文方法所提取的时序特征具有更高的质量,更适合域适应分类任务.

3.4 域分类的性能评估

为了验证所提出方法的有效性,我们在3个公开的数据集上进行了实验,这些数据集都包含了由多个传感器采集的人体活动数据,它们具有不同的特点和复杂性. 我们将所提出的方法与几种基准方法进行了比较. 所有方法

都采用了 6 层的堆叠结构, 隐藏层维度为 512, 模型的输出与输入一致, 最后连接到一个多层感知器 (MLP) 进行分类. 参与比较的基准方法如下.




图 9 HHAR 数据集加速度计的时序特征质量指数 Q 的对比结果

1) 1D-CNN^[32]: 一个基于卷积神经网络的模型, 它使用一维卷积层和池化层来提取时序数据的特征. 本文采用文献 [32] 一样的 CNN 网络架构.

2) RAINCOAT^[29]: 通过同时考虑时间和频率特性、跨域对齐和校正错位来解决特征和标签偏移问题.

3) LSTM^[16]: 一个基于长短期记忆网络的模型, 它使用循环神经网络来建模时序数据的长期依赖关系.

4) TCN^[33]: 一个基于时空卷积网络的模型, 它使用多层时空卷积层来捕捉时序数据的时域和频域特征.

5) ADDA^[34]: 一种通过结合判别建模、无限制权重共享和 GAN 损失, 简单且有效的对抗性域适应通用框架.

6) DANN^[35]: 一种域适应的表示学习方法, 通过在神经网络中引入梯度反转层, 使特征既能区分源域任务, 又对域转换不敏感, 从而实现有效的域适应.

7) MCD^[36]: 一种无监督域适应的方法, 通过最大化两个分类器输出的差异来检测远离源域支持的目标样本, 并利用特定任务的决策边界对齐源和目标分布, 从而提升域适应性能.

8) CALDA^[6]: 利用对抗学习来调整源和目标特征表征, 不需要数据增强和伪标签, 通过对比学习重塑了特征空间.

9) MDLR^[20]: 一个基于对抗神经网络的模型, 它使用一个对抗判别器来减少源域和目标域之间的分布差异.

我们使用了两种评价指标来衡量模型的性能, 分别是准确率 (Accuracy) 和 $F1$ 值 ($F1$). 准确率表示模型正确分类的样本数占总样本数的比例, $F1$ 值表示模型的精确率 (Precision) 和召回率 (Recall) 的调和平均值.

表 4 给出了 Opportunity 数据集的实验结果. 从表 4 可以看出, 本文方法在 Opportunity 数据集上取得了最优的结果, 显著优于其他对比方法. 与传统方法 (如 1D-CNN 和 LSTM) 相比, TPN 在所有实验场景中都表现出明显的优势, 这说明了深度迁移学习在跨域人体活动识别任务中的重要性. 同时, 相比于近期提出的域自适应方法 (如 MCD、CALDA 和 MDLR), TPN 仍然保持了稳定的领先优势, 这进一步证实了本文提出的时序原型网络在捕捉时序特征和对齐域分布方面的创新性和有效性. 特别地, 在实验 $S1 \rightarrow S3$ 和 $S1 \rightarrow S4$ 中, 本文方法的准确率和 $F1$ 值相比其他方法平均提高了 3~4 个百分点. 这一提升不仅体现了 TPN 在处理复杂人体活动识别任务时的鲁棒性和泛化能力, 还凸显了其在应对不同域之间较大分布差异时的优越性.

表 5 和表 6 分别展示了我们在 WISDM 和 HHAR 数据集上的实验结果, 本文提出的 TPN 方法的实验结果仍然优于其他方法, 这进一步证实了我们方法的稳健性和适用性.

在表 7 中, 我们展示了在人工合成数据集上的实验结果, 可以看到, 人工合成数据集上的结果普遍低于真实数据集上的结果. 我们认为, 生成的数据在某些细节和复杂性上无法完全模拟真实数据的多样性, 此外, 人工合成数据的噪声和扰动可能与实际环境中的噪声特征存在差异. 然而, 表 7 的结果依然证明了 TPN 在处理具有一定噪声和数据分布偏移的时序数据上的有效性.

表 4 Opportunity 结果比较

模型	S1→S2		S1→S3		S1→S4	
	Accuracy	F1	Accuracy	F1	Accuracy	F1
ID-CNN	0.65	0.64	0.66	0.65	0.87	0.87
LSTM	0.69	0.70	0.71	0.69	0.88	0.85
ADDA	0.74	0.73	0.77	0.74	0.90	0.88
TCN	0.73	0.72	0.74	0.72	0.91	0.88
RAINCOAT	0.73	0.73	0.76	0.75	0.85	0.83
DANN	0.78	0.76	0.80	0.78	0.91	0.89
MCD	0.80	0.78	0.81	0.78	0.92	0.90
CALDA	0.77	0.76	0.78	0.75	0.92	0.89
MDLR	0.81	0.79	0.84	0.82	0.93	0.90
TPN (ours)	0.85	0.84	0.86	0.85	0.98	0.97

注: 粗体表示最优值

表 5 WISDM 实验结果比较

模型	3→5		3→6		3→7	
	Accuracy	F1	Accuracy	F1	Accuracy	F1
ID-CNN	0.63	0.62	0.64	0.63	0.67	0.64
LSTM	0.68	0.68	0.69	0.67	0.69	0.65
ADDA	0.74	0.72	0.73	0.71	0.76	0.73
TCN	0.75	0.73	0.75	0.72	0.77	0.75
RAINCOAT	0.78	0.76	0.76	0.75	0.78	0.74
DANN	0.79	0.76	0.78	0.76	0.79	0.78
MCD	0.82	0.79	0.81	0.78	0.80	0.78
CALDA	0.81	0.79	0.79	0.77	0.82	0.81
MDLR	0.83	0.81	0.85	0.83	0.83	0.80
TPN (ours)	0.86	0.83	0.87	0.85	0.88	0.87

注: 粗体表示最优值

表 6 HHAR 实验结果比较

模型	a→b		a→c		a→d	
	Accuracy	F1	Accuracy	F1	Accuracy	F1
ID-CNN	0.71	0.69	0.76	0.75	0.73	0.73
LSTM	0.71	0.70	0.74	0.73	0.78	0.75
ADDA	0.73	0.72	0.76	0.74	0.80	0.78
TCN	0.75	0.74	0.77	0.73	0.79	0.78
RAINCOAT	0.83	0.80	0.86	0.85	0.84	0.83
DANN	0.82	0.79	0.86	0.84	0.87	0.85
MCD	0.84	0.81	0.87	0.85	0.88	0.86
CALDA	0.83	0.83	0.87	0.85	0.89	0.86
MDLR	0.84	0.82	0.88	0.84	0.91	0.89
TPN (ours)	0.87	0.85	0.88	0.87	0.93	0.91

注: 粗体表示最优值

表 7 人工合成数据集实验结果比较

模型	a→b		a→c		a→d	
	Accuracy	F1	Accuracy	F1	Accuracy	F1
ID-CNN	0.68	0.65	0.73	0.70	0.70	0.69
LSTM	0.68	0.66	0.72	0.71	0.75	0.72
ADDA	0.70	0.69	0.73	0.72	0.76	0.74
TCN	0.72	0.71	0.74	0.71	0.77	0.75
RAINCOAT	0.80	0.76	0.83	0.80	0.82	0.80
DANN	0.79	0.75	0.82	0.80	0.83	0.81
MCD	0.81	0.78	0.84	0.82	0.85	0.83
CALDA	0.80	0.78	0.84	0.82	0.85	0.82
MDLR	0.81	0.79	0.85	0.81	0.88	0.85
TPN (ours)	0.84	0.82	0.86	0.83	0.90	0.87

注: 粗体表示最优值

为了全面评估和说明本文方法与其他 9 个实现之间的差异, 我们在图 10 中显示了基于准确性的临界差异 (critical difference, CD) 图. CD 图用于比较多个分类器的性能并展示它们之间的统计显著性差异. 我们从 3 个不同的数据表 (表 4–表 6) 中提取每个分类器的准确率数据, 并计算了各分类器在所有实验设置中的平均准确率作为比较依据. 在图 10 中, 10 个分类器按照平均排名从低到高进行了排序, 其中, 指示水平线表示一组实现没有显著差异. 结果显示, 在我们的实验设置下, TPN 的平均排名最小, 这表明它在所测试的数据集上整体表现最佳. CD 图清晰地展示了各方法之间的临界差异区间, 提供了不同方法性能的直观比较以及统计显著性差异的可视化.




图 10 10 个分类算法 CD 图, 置信度为 95%

3.5 参数敏感性实验

为了探究 TPN 模型的参数设置对模型性能和效率的影响, 本文随机选择了如下两个数据集, 进行了不同参数设置下的对比实验, 结果如表 8 和表 9 所示. 表 8 和表 9 中的指标分别表示模型的准确率 (Accuracy)、F1 值 (F1)、参数量 (Params) 和运行时间 (Time).

表 8 HHAR 上实验 a→b 时不同参数的敏感性

参数	Accuracy	F1	Params (M)	Time (s)
$L=2, H=4, HD=32, F=128$	0.80	0.78	0.4	3
$L=4, H=8, HD=64, F=256$	0.83	0.82	0.8	6
$L=6, H=12, HD=96, F=384$	0.87	0.85	1.1	12

表 9 Opportunity 上 S1→S2 时不同参数的敏感性

参数	Accuracy	F1	Params (M)	Time (s)
$L=4, H=8, HD=64, F=256$	0.70	0.77	0.8	14
$L=6, H=8, HD=128, F=512$	0.83	0.81	1.6	28
$L=8, H=12, HD=192, F=768$	0.85	0.84	3.2	45

从表 8 和表 9 可以看出, 随着参数的增大, 模型的性能有所提升, 但是也导致了参数量和运行时间的增加. 例如, 在 Opportunity 上实验 S1→S2 时, 当 L 从 4 增加到 6 时, 模型的准确率和 F1 值分别提高了 2%, 但是参数量和运行时间也分别增加了一倍. 这说明 Transformer 模型的参数设置需要根据具体的任务和环境来进行权衡和选择, 以达到最佳的效果.

3.6 消融实验

为了探究本文方法中的各个组成部分对最终结果的影响, 本文进行了消融实验, 即分别去掉时序模式激活模块 (TPAM) 和增强对抗范式 (EAP), 观察模型的性能变化. 表 10 给出了消融实验的结果, 其中 TPN 表示完整的本文方法, TPN-T 表示去掉 TPAM 的方法, TPN-E 表示去掉 EAP 的方法, TPN-T-E 表示去掉 TPAM 和 EAP 的方法, TPN-OS 表示去除 OSML 策略, TPN-DL 表示去除域分类损失.

表 10 消融实验的准确率对比

方法	S1→S4	3→7	a→c	a→d
TPN-T-E	0.90	0.72	0.79	0.85
TPN-T	0.92	0.77	0.83	0.88
TPN-E	0.95	0.83	0.86	0.90
TPN-OS	0.96	0.84	0.87	0.91
TPN-DL	0.93	0.81	0.84	0.86
TPN	0.98	0.88	0.88	0.93

从表 10 中可以看出, 去掉 TPAM 或 EAP 都会导致模型的性能下降, 说明 TPAM 和 EAP 都对时序建模和域校正有正向的贡献. 其中, 去掉 TPAM 的影响更大, 表明时序模式特征对于时序数据的域自适应是非常重要的. 另外, 去掉 TPAM 和 EAP 的方法 (TPN-T-E) 的性能与基线方法 (LSTM) 相当, 说明本文方法的优势主要来自 TPAM 和 EAP 的结合. 去掉 OSML (TPN-OS) 或域分类损失 (TPN-DL) 都会导致模型性能下降. 其中, 去掉 OSML 带来的性能下降更明显, 说明 OSML 对稳定对抗训练过程、提升模型泛化能力起着更重要的作用. 同时, TPN-OS 的性能优于 TPN-DL, 这说明了在 EAP 中, OSML 和域分类损失的结合能够带来更大的性能提升, 证明了我们提出的 EAP 的有效性.

3.7 可视化实验

为了直观地展示本文方法在特征提取和分类的效果, 本文对 TPN 的注意力权重进行了可视化, 并通过 t-SNE 算法对模型的输出进行了可视化. 注意力权重可以揭示序列中不同元素之间的关系, 注意力权重越高, 对应的特征就越重要. t-SNE 算法是一种非线性降维方法, 能够有效地保留高维数据的局部结构, 使得相似的数据点在低维空间中更加靠近, 不相似的数据点更加远离^[37].

图 11 展示了本文方法在实验 S1→S3 时 5 个不同类别样本的时序数据及其自注意力权重可视化结果, 左侧的图是 S3 的一类样本的归一化时间序列, 右边是 TPN 编码器第 1 层的自注意力的权重可视化, y 轴数据越大表示对预测结果的贡献越大. 对于不同类别的样本, 基于 Transformer 的时序自注意力机制特征能够对不同时序位置产生不同程度的注意力, 因此是一种动态的加权机制.

图 12 展示了本文方法和基线方法 LSTM 在 S1→S4 实验中的 t-SNE 结果, 其中不同的颜色表示不同的类别. 从图 12 中可以看出, 本文方法分类器的性能良好, 不同类别的数据点在 t-SNE 图中被清晰地分离开来, 即同一类别的数据点聚集在一起, 不同类别的数据点能够区分开来. 而基线方法的某些类别的数据点在 t-SNE 图中重叠, 意味着分类器在这些类别上的性能较差, 这些类别之间的边界不清晰, 导致域分类的性能下降.




图 11 S1→S4 时 5 类高级活动样本的时序数据
及注意力权重可视化





图 12 实验 S1→S4 时两种方法的 t-SNE 对比

4 总结和未来工作

本文提出了一种基于时序建模和域校正的传感器数据域自适应方法. 该方法提出了时序模式激活模块 (TPAM) 和增强对抗范式 (EAP), TPAM 能够自动地从时序数据中提取出具有判别能力和适应能力的时序模式特征, 有效地增强了时序建模网络的性能; EAP 能够利用域分类损失和操作顺序预测损失, 增强生成器和判别器的协同对抗能力, 有效地减少了源域和目标域之间的数据分布偏移. 在 3 个公开的人体活动识别数据集上进行了广泛的实验, 验证了本文方法的有效性和优越性, 与其他对比方法相比, 本文方法在准确率和 $F1$ 值上都得到了提升, 同时具有较少的参数数量和运行时间. 本文还通过消融实验和可视化实验, 分析了本文方法中的各个组成部分对最终结果的影响, 展示了本文方法在特征提取和域对齐方面的效果.

本文的方法在时序数据域自适应方面取得了较好的结果, 但是仍然存在一些可以改进的地方. 未来研究的一个重要方向是探索如何将 TPN 扩展应用于更复杂和异构的数据集. 不同数据集之间可能存在数据采集方式、传感器类型、采样频率等方面的差异, 这会导致诸如域偏移和协变量偏移等问题, 从而给跨域对齐带来更大的挑战. 例如, 如何有效地对齐来自不同类型的传感器 (如加速度计、陀螺仪、心率计等) 的数据, 需要进一步研究多模态学习和表征学习方法, 从而学习到更具判别性和鲁棒性的共享特征表示. 此外, 探索如何在异构数据集中有效地利用迁移学习技术, 例如, 通过预训练和微调策略将知识从资源丰富的传感器数据迁移到数据稀缺的传感器数据, 也

是一个值得深入研究的问题. 这将有助于提高模型在不同数据集上的泛化性能和实际应用价值.

References

- [1] Kumar R, Kumar P, Kumar Y. Multi-step time series analysis and forecasting strategy using ARIMA and evolutionary algorithms. *Int'l Journal of Information Technology*, 2022, 14(1): 359–373. [doi: [10.1007/s41870-021-00741-8](https://doi.org/10.1007/s41870-021-00741-8)]
- [2] Wen QS, Zhou T, Zhang CL, Chen WQ, Ma ZQ, Yan JC, Sun L. Transformers in time series: A survey. In: *Proc. of the 32nd Int'l Joint Conf. on Artificial Intelligence*. Macao, 2023. 6778–6786. [doi: [10.24963/ijcai.2023/759](https://doi.org/10.24963/ijcai.2023/759)]
- [3] 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)]
- [4] Liu Y, Zhang L, Deng PL, He Z. Common subspace learning via cross-domain extreme learning machine. *Cognitive Computation*, 2017, 9(4): 555–563. [doi: [10.1007/s12559-017-9473-5](https://doi.org/10.1007/s12559-017-9473-5)]
- [5] Kute RS, Vyas V, Anuse A. Cross domain association using transfer subspace learning. *Evolutionary Intelligence*, 2019, 12(2): 201–209. [doi: [10.1007/s12065-019-00211-y](https://doi.org/10.1007/s12065-019-00211-y)]
- [6] Wilson G, Doppa JR, Cook DJ. CALDA: Improving multi-source time series domain adaptation with contrastive adversarial learning. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 2023, 45(12): 14208–14221. [doi: [10.1109/TPAMI.2023.3298346](https://doi.org/10.1109/TPAMI.2023.3298346)]
- [7] Goodfellow I, Pouget-Abadie J, Mirza M, Xu B, Warde-Farley D, Ozair S, Courville A, Bengio Y. Generative adversarial networks. *Communications of the ACM*, 2020, 63(11): 139–144. [doi: [10.1145/3422622](https://doi.org/10.1145/3422622)]
- [8] Hong HT, Li X, Pan YG, Tsang IW. Domain-adversarial network alignment. *IEEE Trans. on Knowledge and Data Engineering*, 2022, 34(7): 3211–3224. [doi: [10.1109/TKDE.2020.3023589](https://doi.org/10.1109/TKDE.2020.3023589)]
- [9] Lyu H, Huang DS, Li S, Ng WWY, Ma QL. Multiscale echo self-attention memory network for multivariate time series classification. *Neurocomputing*, 2023, 520: 60–72. [doi: [10.1016/j.neucom.2022.11.066](https://doi.org/10.1016/j.neucom.2022.11.066)]
- [10] Deihim A, Alonso E, Apostolopoulou D. STTRE: A spatio-temporal Transformer with relative embeddings for multivariate time series forecasting. *Neural Networks*, 2023, 168: 549–559. [doi: [10.1016/j.neunet.2023.09.039](https://doi.org/10.1016/j.neunet.2023.09.039)]
- [11] Djenouri Y, Belbachir AN, Cano A, Belhadi A. Spatio-temporal visual learning for home-based monitoring. *Information Fusion*, 2024, 101: 101984. [doi: [10.1016/j.inffus.2023.101984](https://doi.org/10.1016/j.inffus.2023.101984)]
- [12] Kamsu-Foguem B, Msouobu Gueuwou SL, Kounta CAKA. Generative adversarial networks based on optimal transport: A survey. *Artificial Intelligence Review*, 2023, 56(7): 6723–6773. [doi: [10.1007/s10462-022-10342-x](https://doi.org/10.1007/s10462-022-10342-x)]
- [13] Zhou K, Wang WY, Hu T, Wu CH. Comparison of time series forecasting based on statistical ARIMA model and LSTM with attention mechanism. *Journal of Physics: Conf. Series*, 2020, 1631(1): 012141. [doi: [10.1088/1742-6596/1631/1/012141](https://doi.org/10.1088/1742-6596/1631/1/012141)]
- [14] Dabral PP, Murry MZ. Modelling and forecasting of rainfall time series using SARIMA. *Environmental Processes*, 2017, 4(2): 399–419. [doi: [10.1007/s40710-017-0226-y](https://doi.org/10.1007/s40710-017-0226-y)]
- [15] Sherstinsky A. Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network. *Physica D: Nonlinear Phenomena*, 2020, 404: 132306. [doi: [10.1016/j.physd.2019.132306](https://doi.org/10.1016/j.physd.2019.132306)]
- [16] 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)]
- [17] Dey R, Salem FM. Gate-variants of gated recurrent unit (GRU) neural networks. In: *Proc. of the 60th IEEE Int'l Midwest Symp. on Circuits and Systems (MWSCAS)*. Boston: IEEE, 2017. 1597–1600. [doi: [10.1109/MWSCAS.2017.8053243](https://doi.org/10.1109/MWSCAS.2017.8053243)]
- [18] Vaswani A, Shazeer N, Parmar N, Uszkoreit J, Jones L, Gomez AN, Kaiser Ł, Polosukhin I. Attention is all you need. In: *Proc. of the 31st Int'l Conf. on Neural Information Processing Systems*. Long Beach: Curran Associates Inc., 2017. 6000–6010.
- [19] Li J, Wang X, Tu ZP, Lyu MR. On the diversity of multi-head attention. *Neurocomputing*, 2021, 454: 14–24. [doi: [10.1016/j.neucom.2021.04.038](https://doi.org/10.1016/j.neucom.2021.04.038)]
- [20] Liu Y, Li DTC, Wang J, Li B, Hang B. MDLR: A multi-task disentangled learning representations for unsupervised time series domain adaptation. *Information Processing & Management*, 2024, 61(3): 103638. [doi: [10.1016/j.ipm.2023.103638](https://doi.org/10.1016/j.ipm.2023.103638)]
- [21] Wu HX, Xu JH, Wang JM, Long MS. Autoformer: Decomposition Transformers with auto-correlation for long-term series forecasting. In: *Proc. of the 31st Int'l Conf. on Neural Information Processing Systems*. Curran Associates Inc., 2021. 22419–22430.
- [22] Zhou T, Ma ZQ, Wen QS, Wang X, Sun L, Jin R. FEDformer: Frequency enhanced decomposed Transformer for long-term series forecasting. In: *Proc. of the 39th Int'l Conf. on Machine Learning*. Baltimore: PMLR, 2022. 27268–27286.
- [23] Ajith A, Gopakumar G. Domain adaptation: A survey. In: *Tistarelli M, Dubey SR, Singh SK, Jiang XY, eds. Computer Vision and Machine Intelligence*. Singapore: Springer, 2023. 591–602. [doi: [10.1007/978-981-19-7867-8_47](https://doi.org/10.1007/978-981-19-7867-8_47)]
- [24] Wang JY, Chen LK, Al Faruque MA. DOMINO: Domain-invariant hyperdimensional classification for multi-sensor time series data. In: *Proc. of the 2023 IEEE/ACM Int'l Conf. on Computer Aided Design (ICCAD)*. San Francisco: IEEE, 2023. 1–9. [doi: [10.1109/ICCAD57390.2023.10323848](https://doi.org/10.1109/ICCAD57390.2023.10323848)]
- [25] Singhal P, Walambe R, Ramanna S, Kotecha K. Domain adaptation: Challenges, methods, datasets, and applications. *IEEE Access*, 2023,

- 11: 6973–7020. [doi: [10.1109/ACCESS.2023.3237025](https://doi.org/10.1109/ACCESS.2023.3237025)]
- [26] Wilson G, Cook DJ. A survey of unsupervised deep domain adaptation. *ACM Trans. on Intelligent Systems and Technology*, 2020, 11(5): 51. [doi: [10.1145/3400066](https://doi.org/10.1145/3400066)]
- [27] Chavarriaga R, Sagha H, Calatroni A, Digumarti ST, Tröster G, Millán JDR, Roggen D. The Opportunity challenge: A benchmark database for on-body sensor-based activity recognition. *Pattern Recognition Letters*, 2013, 34(15): 2033–2042. [doi: [10.1016/j.patrec.2012.12.014](https://doi.org/10.1016/j.patrec.2012.12.014)]
- [28] Kwapisz JR, Weiss GM, Moore SA. Activity recognition using cell phone accelerometers. *ACM SIGKDD Explorations Newsletter*, 2011, 12(2): 74–82. [doi: [10.1145/1964897.1964918](https://doi.org/10.1145/1964897.1964918)]
- [29] 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.org, 2023. 12746–12774.
- [30] Kumar P, Suresh S. DeepTransHHAR: Inter-subjects heterogeneous activity recognition approach in the non-identical environment using wearable sensors. *National Academy Science Letters*, 2022, 45(4): 317–323. [doi: [10.1007/s40009-022-01126-6](https://doi.org/10.1007/s40009-022-01126-6)]
- [31] Taylor SJ, Letham B. Forecasting at scale. *The American Statistician*, 2018, 72(1): 37–45. [doi: [10.1080/00031305.2017.1380080](https://doi.org/10.1080/00031305.2017.1380080)]
- [32] Yang JB, Nguyen MN, San PP, Li XL, Krishnaswamy S. Deep convolutional neural networks on multichannel time series for human activity recognition. In: *Proc. of the 24th Int'l Joint Conf. on Artificial Intelligence*. Buenos Aires: AAAI Press, 2015. 3995–4001.
- [33] Lea C, Vidal R, Reiter A, Hager GD. Temporal convolutional networks: A unified approach to action segmentation. In: *Proc. of the 2016 Conf. on Computer Vision*. Amsterdam: Springer, 2016. 47–54. [doi: [10.1007/978-3-319-49409-8_7](https://doi.org/10.1007/978-3-319-49409-8_7)]
- [34] 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)]
- [35] Ganin Y, Ustinova E, Ajakan H, Germain P, Larochelle H, Laviolette F, Marchand M, Lempitsky V. Domain-adversarial training of neural networks. *Journal of Machine Learning Research*, 2016, 17(1): 2096–2030.
- [36] Saito K, Watanabe K, Ushiku Y, Harada T. Maximum classifier discrepancy for unsupervised domain adaptation. *arXiv:1712.02560*, 2018.
- [37] Belkina AC, Ciccolella CO, Anno R, Halpert R, Spidlen J, Snyder-Cappione JE. Automated optimized parameters for T-distributed stochastic neighbor embedding improve visualization and analysis of large datasets. *Nature Communications*, 2019, 10(1): 5415. [doi: [10.1038/s41467-019-13055-y](https://doi.org/10.1038/s41467-019-13055-y)]

作者简介

孙杰, 博士, 教授, 主要研究领域为机器学习, 深度学习, 时间序列分析.

李贵宸, 硕士生, 主要研究领域为机器学习, 时间序列分类.

陈仲珊, 博士, 教授, CCF 专业会员, 主要研究领域为机器学习, 大数据分析 & 处理.

王小正, 讲师, CCF 高级会员, 主要研究领域为软件工程, 软件开发技术, 数据可视化.

郑豪, 博士, 教授, CCF 高级会员, 主要研究领域为机器学习, 模式识别.

陈长伟, 博士, 副研究员, CCF 专业会员, 主要研究领域为机器学习, 时间序列预测.

常合友, 博士, 副教授, CCF 专业会员, 主要研究领域为机器学习, 模式识别, 计算机视觉.