

基于域自适应网络的跨场景摔倒检测算法研究

马永连*, 张登银

(南京邮电大学 物联网学院, 江苏 南京 210023)

摘要:目前,基于信道状态信息(Channel State Information, CSI)的室内摔倒检测(Fall Detection, FD)系统已被证明拥有巨大潜力,但是,不同室内布局带来的多径效应的差异往往使其无法实现跨场景使用。因此,该文提出了DA-Fall(Domain-adaptive Fall),通过结合两种自适应策略的域自适应方法来改进未标记噪声信号的泛化,从而提高对目标域的检测精度。在提出的摔倒检测系统中,引入了域鉴别器和域混淆自适应层来进行对抗性训练。首先,该算法通过引入依赖于相对值的相对鉴别器来优化对抗训练,从而更好地反映域间差异。其次,将基于多核架构的最大均值差异(Multiple Kernel Maximum Mean Difference, MK-MMD)作为域对抗损失的正则化项,进一步减小域间的边缘分布距离。实验分析表明,DA-Fall取得了比WiFall, RT-Fall, SignGAN更好的效果,在原场景与新场景中分别达到了96.83%和91.03%的检测精度。

关键词:信道状态信息;摔倒检测;域自适应网络;迁移学习;多核最大均值差异

中图分类号:TP393

文献标识码:A

文章编号:1673-629X(2023)10-0086-07

doi:10.3969/j.issn.1673-629X.2023.10.014

Cross-scene Fall Detection Algorithm Based on Domain Adaptive Network

MA Yong-lian*, ZHANG Deng-yin

(School of Internet of Things, Nanjing University of Posts and Telecommunications, Nanjing 210023, China)

Abstract: Indoor Fall Detection (FD) systems based on Channel State Information (CSI) have been proved to have great potential, but the difference in multipath effects caused by different indoor layouts often makes it impossible to achieve cross-scene use. Therefore, we propose DA-Fall (Domain-Adaptive Fall), which combines the domain adaptive methods of two adaptive strategies to improve the generalization of unlabeled noise signals, thereby improving the detection accuracy of the target domain. In the proposed fall detection system, a domain discriminator and a domain confusion adaptive layer are introduced for adversarial training. Firstly, such algorithm optimizes adversarial training by introducing a relative discriminator that depends on relative values, so as to better reflect the differences between domains. Secondly, the Multiple Kernel Maximum Mean Difference (MK-MMD) based on multi-core architecture is used as the regularization term of domain adversarial loss to further reduce the edge distribution distance between domains. Experiments show that DA-Fall achieves better results than Wi-Fall, RT-Fall, Sign-GAN and other systems. The detection accuracy of 96.83% and 91.03% was achieved in the original scene and the new scene, respectively.

Key words: channel state information; fall detection; domain adaptive network; transfer learning; MK-MMD

0 引言

当下,国内社会老龄化问题严重,独居的中老年人在缺少看护的情况下,在室内摔倒后果通常会很严重,甚至可能会导致死亡^[1]。采用摄像头监控^[2]的方式无法在无光环境中正常工作,并且会侵犯人们的隐私,而穿戴设备^[3]在实际应用时因忘记佩戴设备以及有限的电池容量对使用者不太友好。无线信号不受光的限制^[4],不侵犯人们的隐私,并且容易获取。

Seifeldin^[5]在2013年首次提出了基于WiFi信号接收强度RSSI(Received Signal Strength Information)的室内人体行为识别系统,但是研究者发现RSSI存在以下缺陷:(1)RSSI衡量的是多径信号传播的叠加效应,无法区分多条信号传播路径;(2)RSSI位于媒体访问控制(Medium Access Control, MAC)层,不包含可学习的物理层信息^[6]。因此,近些年来,RSSI在无线感知方面逐渐被信道状态信息(Channel State Information,

收稿日期:2022-12-20

修回日期:2023-04-21

基金项目:国家自然科学基金项目(61872423);江苏省高等学校自然科学研究重大项目(19KJA180006)

作者简介:马永连(1995-),男,硕士,通讯作者,研究方向为室内被动式行为识别;张登银(1964-),男,研究员,博导,CCF高级会员(E200012416S),研究方向为信号与信息处理。

CSI)^[7-10]所替代。C. Han 等人提出的摔倒检测系统 Wi-Fall^[7]是第一个使用 CSI 进行摔倒检测的,作者利用 CSI 的归一化标准差、信号强度偏移等七个特征作为联合特征,利用局部异常分量检测无线信号的异常变化,并通过 SVM 算法对动作进行分类。

然而不同室内布局带来的多径效应的差异,使得上述摔倒检测系统无法实现跨场景使用,即在源域场景训练得到的摔倒检测模型应用到目标域时,检测精度会急剧下降。针对于跨场景检测的需求,诸如 RT-Fall^[9]等摔倒检测方法,当环境改变后会出现明显的性能下降。FallDeFi^[10]使用 STFT 提取 CSI 中的时频特征,使用 SVM 实现准确的摔倒检测。为了确保摔倒检测系统能够适应环境变化,作者还设计了一种鲁棒的顺序前向选择算法挑选能够适应环境变换的特征,在环境发生变化时,取得了接近 80% 的平均精度,使得跨场景识别成为可能。域自适应的思想现已被证明在计算机视觉、语音增强等领域拥有巨大潜力,在摔倒检测、行为识别等研究中并不常见。SignGAN^[11]引入了一个基于标准的生成对抗网络(GAN)的域自适应网络,该网络可以将源域的真实样本转换为具有目标域样式的目标域,消除了特定环境和用户的影响,最终达到了 91.25% 的平均检测精度。

该文提出了一种新的摔倒检测域自适应框架 DA-Fall,该框架结合了两种领域自适应策略。一是通过最小化域差异的距离度量将源域与目标域迁移到同一子空间,以弥合源域和目标域。另一种策略是使用域对抗训练来提取域不变特征,即在特征提取器和域判

别器之间采用极小极大博弈。DA-Fall 关键思想是联合训练特征提取器和域判别器,域判别器尝试区分源域和目标域的数据,而特征提取器尝试混淆判别器,在域对抗训练过程中,该文使用最大均值差异(MK-MMD)作为域对抗损失的正则化项,进一步最小化域偏移。因此,针对高精度的跨场景摔倒检测,该文的主要贡献如下:

首先,在所提出的摔倒检测系统中,引入了域鉴别器和域混淆自适应层进行对抗性训练。该算法通过引入依赖于应用差异的相对值的相对鉴别器来优化对抗训练,从而更好地反映域间差异;

其次,将多核架构下改进的 MMD 作为域对抗损失的正则化项,在模型的梯度更新中添加约束,进一步减小域间的混合分布(边缘分布和条件分布)距离,从而促进整体迁移学习的效果。

1 系统设计

该文旨在解决跨场景摔倒检测问题。在源域中可以获得大量有噪 CSI 信号及其标签(即含有尽可能少的噪声干扰的 CSI 信号),在目标域中只有有噪 CSI 信号。该文的目标是通过域自适应方法提高摔倒检测模型对目标域的检测性能。基准模型为特征编码器-解码器结构,并将 CSI 特征作为模型的输入和输出来执行回归任务。最终将在实际环境中采集的有噪 CSI 信号通过适配的自适应模型以获得估计的干净 CSI 特征,并将其输入 CNN 网络中进行分类。摔倒检测系统 DA-Fall 架构如图 1 所示。

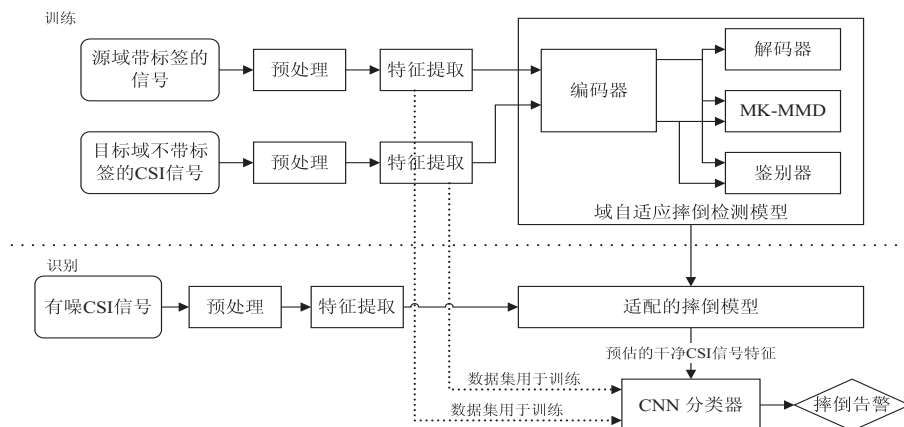


图 1 系统架构

1.1 信号预处理与特征提取

系统第一部分为信号预处理与特征提取,其中信号预处理主要分为去噪和降维两个阶段:该文使用 Hampel 滤波器去除远离相邻数据的异常值,具体来说,它使用移动平均窗口查找异常值并将其替换为数据的均值,从而消除无效数据的负面影响。异常值去除后,CSI 数据中残留大量噪声,由于人体活动引起的

Wi-Fi 信号变化主要集中在低频分量,而噪声主要存在于高频分量,巴特沃斯低通滤波器在通带内具有最大的平坦特性,不会对运动造成的信号波动产生太大的扭曲,因此,该文使用巴特沃斯低通滤波器消除高频分量并保留低频分量。该文采用主成分分析(Principal Component Analysis, PCA)进行信号的降维,PCA 是把给定的一组相关变量通过线性变换转为

另一组各维度线性无关的变量的技术,能在基本保留原始数据重要信息的基础上降低数据维数,进而提取数据的主特征分量。

特征提取方面,该文沿用了文献[9]从实时捕获的 CSI 流中提取的 8 个特征进行活动分类:(1)归一化均方差(STD);(2)中值绝对偏差(MAD);(3)信号强度偏移;(4)四分位范围(IR);(5)信号熵;(6)信号变化速度;(7)时间滞后;(8)功率下降比(PDR)。

1.2 域自适应网络

系统第二部分为域自适应网络,在此阶段,网络中共包含了两个数据流,分别是源域中的有噪 CSI 样本及其相应的标签,以及目标域中不含标签的有噪 CSI 样本。首先,将采集到的 CSI 原始信号分别进行去噪、降维等预处理操作,并提取预处理之后的 CSI 信号的特征(带有标签 CSI_s^y 的 CSI_s^x 以及 CSI_t)。该文所提出的 DA-Fall 具有特征编码器-解码器结构,将两个数据流同时经过特征编码器,并在训练过程中共享权重。这两个数据流有三个不同流向。其中,只有源域数据流会继续到特征解码器并且重建 $\widehat{CSI_s^y}$ 特征,通过计算 CSI_s^y 的 CSI_s^x 之间的平均绝对误差来计算网络的回归损失,其次需要设置自适应层来计算源域数据与目标域数据之间的 MK-MMD,最后设置了域判别器来提供域之间的相对对抗损失,并采用域对抗训练来更新模型的参数。整个网络通过域对抗损失,域混淆损失(即基于 MK-MMD 的损失)和回归损失之间的极大极小博弈进行域自适应迁移学习。

1.3 CNN 分类器

摔倒检测系统的最后一个组件是基于 CNN 的分类器。该文有大量不同类别环境的标签数据,这些数据被输送到 CNN 网络进行分类。在实际检测阶段,从目标域的噪声信号中提取 CSI 特征,并在通过自适应摔模型得到估计的干净 CSI 特征,最终输入到基于 CNN 的分类器。具体 CNN 网络结构包含卷积层、批量正则化层、激活层、池化层、Dropout 层等结构。

实际检测阶段,采集到目标域环境中带有噪声的信号,同样通过预处理并进行特征提取,通过适配的域自适应模型以获得估计的干净的 CSI 特征,最终输入到训练好的 CNN 分类器得到最终的识别结果。

2 提出的跨场景摔倒检测算法

2.1 相对生成对抗网络(RGAN)

标准的生成式对抗网络(Generative Adversarial Network, GAN)^[12]由蒙特利尔大学的 Ian J. Goodfellow 等人提出,其核心思想为:生成器与判别器之间相互对抗竞争,二者通过极大极小博弈。一方面,生成器不断生成假样本,另一方面,鉴别器不断提高区

分真假样本的判别能力。在此过程中,通过损失函数不断更新生成器和鉴别器的参数,直到两者达到动态平衡,即判别器无法判断输入的样本是真实的还是虚假生成的。GAN 可被如下定义:

$$\begin{aligned} L_D &= -E_{x_r \sim P}[\log \sigma(C(x_r))] - \\ &\quad E_{x_f \sim Q}[\log(1 - \sigma(C(x_f)))] \\ L_G &= -E_{x_f \sim Q}[\log(1 - \sigma(C(x_f)))] \end{aligned} \quad (1)$$

其中, P 和 Q 分别是真实样本和假样本的分布, $E(\cdot)$ 为期望运算, $C(x)$ 将非转换层表示为 $D(x) = \sigma(C(x))$, 是一个 sigmoid 函数。

然而,文献[13]认为在提升假数据为真实的概率(即 $D(x_f)$)的同时还应该降低真实数据为真实的概率(即 $D(x_r)$)。对于标准的 GAN 来说, $D(x_r)$ 不能受生成器的影响,因为判别器是独立操作的;在训练生成器时真实样本不参与,因此判别器需要记录下真实样本的所有属性来指导生成器,这对训练来说是一种负担。所以,引入 RGAN 的方法,使得判别器的输出依赖于真实数据和假数据的相对值。判别器是相对的 $D(\tilde{x}) = \sigma(C(x_r) - C(x_f))$, 其中 $\tilde{x} = (x_r, x_f)$ 是从真、假数据对中采样的。相应地,给定的假数据比随机采样的真实数据更真实的概率可定义为 $D_{\text{rev}}(\tilde{x}) = \sigma(C(x_r) - C(x_f))$ 。根据相对鉴别器的特性:

$$\begin{aligned} 1 - D_{\text{rev}}(\tilde{x}) &= 1 - \sigma(C(x_r) - C(x_f)) = \\ &\quad \sigma(C(x_r) - C(x_f)) = D(\tilde{x}) \end{aligned} \quad (2)$$

$D_{\text{rev}}(\tilde{x})$ 不需要包含在损失函数中。因此 RGAN 鉴别器与生成器的损失函数可以定义为:

$$\begin{aligned} L_D^{\text{RGAN}} &= -E_{(x_r, x_f) \sim (P, Q)}[\log \sigma(C(x_r) - C(x_f))] \\ L_G^{\text{RGAN}} &= -E_{(x_r, x_f) \sim (P, Q)}[\log \sigma(C(x_f) - C(x_r))] \end{aligned} \quad (3)$$

该文将相对鉴别器用于域对抗训练。将原先鉴别器所依赖的真实、虚假数据对替换为来自源域和目标域的样本。理论上, RGAN 使鉴别器只依赖相对值进行差分,从而避免了鉴别器可能的偏差,并使梯度更加稳定,这有利于域对抗训练。此外,与标准 GAN 鉴别器相比,相对鉴别器可以更好地反映源域数据和目标域数据之间的距离,这有助于缩短域间距离。

该文引入了文献[14]中提出的梯度惩罚正则化方法,来惩罚批评者相对其输入的梯度范数,以避免训练过程中出现的梯度的极端情况(梯度消失和爆炸)。使用对随机样本的梯度范数具有惩罚约束的软版本来实现梯度惩罚:

$$L_{\text{GP}}(D) = -E_{\hat{x} \sim P_{\hat{x}}}[(\|\nabla_{\hat{x}} C(\hat{x})\|_2 - 1)^2] \quad (4)$$

其中, $P_{\hat{x}}$ 为 $\hat{x} = \varepsilon x_r + (1 - \varepsilon) x_f$ 的分布, $x_r \sim P, x_f \sim Q$, ε 从 $[0, 1]$ 中的均匀分布中采样。因此,应用梯度惩罚后判别器的损失为 $L_D + \lambda_{\text{GP}} L_{\text{GP}}(D)$, 其中 λ_{GP} 是用于调整梯度惩罚权重的超参。文献[13]中提到,在判别器中应用梯度惩罚可以稳定 RGAN 模型的训练,并实

现收敛的加速。

2.2 多核最大均值差异 (MK-MMD)

最大均值差异 MMD 通过核双样本检验比较两个数据集之间的分布,它是迁移学习中最常用的有效度量^[15]。MMD 使用核映射方法将两个分布的关键统计特征嵌入到高维可再生核希尔伯特空间 (RKHS)。然后计算核平均嵌入之间的距离。

令 $P(x_s)$ 和 $P(x_t)$ 分别为源域和目标域 CSI 特征的边缘分布,其 MMD 可以表示为:

$$\text{MMD}^2(X, Y) = D[P(x_s), P(x_t)] = \|E_{P(x_s)}(\varphi(x_s)) - E_{P(x_t)}(\varphi(x_t))\|_{H_k}^2 \quad (5)$$

其中, $E_{P(x_s)}(\cdot)$ 和 $E_{P(x_t)}(\cdot)$ 分别表示 X_s 和 X_t 的边缘分布为 $P(x_s)$ 和 $P(x_t)$ 时的期望运算,由于无法计算源域和目标域所有 CSI 的总体均值 (即期望运算),该文通过计算源域与目标域 CSI 的样本均值将上式近似为:

$$D[P(x_s), P(x_t)] = \left\| \frac{1}{n_s} \sum_{i=1}^{n_s} \varphi(x_i) - \frac{1}{n_t} \sum_{j=1}^{n_t} \varphi(x_j) \right\|_{H_k}^2 \quad (6)$$

其中, $\|\cdot\|_{H_k}^2$ 表示 RKHS 中的 2-范数运算, $\varphi(\cdot)$ 表示将 CSI 特征映射到 RKHS 的映射函数,这里使用高斯核,其对应的映射函数可以映射到无穷维上; x_i 、 y_j 分别为 n_s 、 n_t 中的第 i 、 j 个数据,维度一致。

在 MMD 的计算中,给定 $D_{X_s} = \{x_i^s\}_{i=1}^{n_s}$, $D_{X_t} = \{x_j^t\}_{j=1}^{n_t}$ 特征映射函数 $\varphi(\cdot)$ 对应的核映射函数为 $k(X_s, X_t) = \langle \varphi(X_s), \varphi(X_t) \rangle$, 给定 H_k 中的特征核 k , 上述 MMD 可以描述为:

$$\begin{aligned} \text{MMD}^2(x_s, x_t) &\triangleq \frac{1}{n_s^2} \sum_{i=1}^{n_s} \sum_{j=1}^{n_s} k(x_i, x_j) + \\ &\frac{1}{n_t^2} \sum_{i=1}^{n_t} \sum_{j=1}^{n_t} k(y_i, y_j) - \\ &\frac{2}{n_s n_t} \sum_{i=1}^{n_s} \sum_{j=1}^{n_t} k(x_i, y_j) \end{aligned} \quad (7)$$

经典的 MMD 基于单核变换,单个内核不够灵活,无法充分描述不同的分布。其仅可以减小源域 CSI 特征与目标域 CSI 特征之间的整体差异性,但无法保证源域与目标域中同一类 CSI 特征的差异性最小化。

基于多核架构,该文将多个核函数组成的子空间映射来组合各个子空间不同的特征映射能力,从而更加准确地获得高维组合空间的特征表达^[16]。多个特征核 k 可以定义为 G 个核的凸组合:

$$k \triangleq \{k = \sum_{g=1}^G \alpha_g f_g(\cdot) : \sum_{g=1}^G \alpha_g = 1, \alpha_g \geq 0, \forall g\} \quad (8)$$

具体而言,令正定核函数为 $k = \sum_{g=1}^G \alpha_g f_g(\cdot)$, 其

中, $f_g(\cdot)$ 为第 g ($g = 1, 2, \dots, G$) 个核函数, $\alpha_g \geq 0$ 为第 g 个常数且 $\sum_{g=1}^G \alpha_g = 1$, G 表示核函数的数量。

2.3 提出的算法

在源域中,该文可以采集丰富的样本并进行标记,但是由于不同室内环境下的多径效应,它们与目标域样本分布不一致。此外,目标域的样本不包含标记。因此,仅仅通过微调^[17]直接将源域中训练出的原始模型应用在目标域是不可行的。假设存在一个高维特征空间,可以分别代表源域和目标域的关键特征。然后,这种域不变特征可以缩短源域和目标域之间的边缘分布距离。针对以上目标,结合 2.1 与 2.2 中所提到的 RGAN 与 MK-MMD,设计了基于摔倒检测模型的域自适应框架,如图 2 所示。

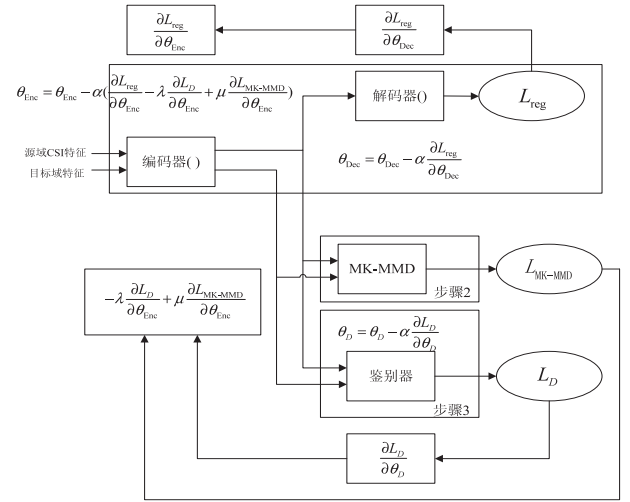


图 2 域自适应框架

框架主要由四部分组成:将 CSI 特征嵌入高维特征空间的特征编码器 ($\text{Enc}(\theta_{\text{enc}})$)、用于预测无噪声情况下干净的 CSI 特征的特征解码器 ($\text{Dec}(\theta_{\text{dec}})$)、用于计算基于 MK-MMD 损失的自适应层和用于计算域对抗损失的域鉴别器 ($D(\theta_d)$)。这里 θ_{enc} 、 θ_{dec} 和 θ_d 是网络中的参数,自适应层仅用于计算 MK-MMD 度量,不会参与网络的梯度更新。具体流程如下:

步骤 1:对源域样本 (带有干净标签) 和目标域样本 (未标记) 分别进行去噪、降维、特征提取以获得 CSI 特征。然后,它们被发送到编码器以获得 X_s 和 X_t :

$$X_s = \text{Encoder}(\theta_{\text{enc}}, \text{CSI}_s)$$

$$X_t = \text{Encoder}(\theta_{\text{enc}}, \text{CSI}_t) \quad (9)$$

X_s 和 X_t 按以下三个方向进行处理,第一种方式将标记的 X_s 发送到解码器以重建估计的 CSI 特征,然后使用源域标签计算平均绝对损失 (MAE),最小化 MAE 可以使模型最适合源域数据集,以此来衡量源域回归任务的表现:

$$L_{\text{reg}} = \frac{1}{N} \sum_{i=1}^N |\text{Dec}(X_s(i)) - Y(i)| \quad (10)$$

步骤 2: 计算 X_s 和 X_t 的多核最大均值差异损失 (L_{MK-MMD})。通过最小化 L_{MK-MMD} , 可以使 X_s 和 X_t 的分布尽可能接近, 最终使编码器产生针对不同域中噪声的域不变特征。

$D_{X_s} = \{x_i^s\}_{i=1}^n$, $D_{X_t} = \{x_i^t\}_{i=1}^n$ 分别为 X_s 和 X_t 的样本集, 其中 n 为批次大小, 并将单核 k 替换为多个特征核 K , K 可以定义为个核的凸组合。系数 α_g 的约束选择为 $1/m$ 。多个特征核 m 总数在实验中设置为 13。它们的参数 d_2 是 0.001、0.01、0.1、1、5、10、15、20、25、30、35、100 和 1 000。

$$L_{MK-MMD} = MKMMD^2(x_s, x_t) \triangleq \frac{1}{n^2} \sum_{i=1}^{n_s} \sum_{j=1}^{n_t} K(x_i, x_j) + \frac{1}{n^2} \sum_{i=1}^{n_s} \sum_{j=1}^{n_t} K(y_i, y_j) - \frac{2}{n^2} \sum_{i=1}^{n_s} \sum_{j=1}^{n_t} K(x_i, y_j) \quad (11)$$

步骤 3: X_s 和 X_t 被发送到域鉴别器, 它可以看作是源域和目标域之间的分类器, 其最后一层是一个密集层, 其中一个单元使用 sigmoid 函数作为激活值为 0-1 的鉴别器的输出用于计算相对对抗损失 L_D :

$$L_D = -E_{x_s \sim \hat{s}, x_t \sim \hat{t}} [\log \sigma(C(x_t) - C(x_s))] \quad (12)$$

最小化 L_D 实际上意味着鉴别器可以更好地区分来自源域和目标域的样本。该阶段的目标是在编码器和鉴别器之间进行极小极大博弈。如上所述, 鉴别器通过训练以获得对样本更精确的判断, 然而编码器则用于提取源域和目标域之间的域不变特征来混淆鉴别器。如果鉴别器无法区分 X_s 和 X_t , 则说明从源域到目标域的迁移学习是成功的。为了实现极小极大博弈, 该文在鉴别器和编码器之间插入了一个梯度反转层 (GRL)。在前向传播过程中, GRL 充当恒等变换, 以保持输入不变。在反向传播期间, GRL 从后续级别获取梯度并将其符号更改为 $-\lambda$, 以在编码器和鉴别器之间形成对抗。

使用梯度下降法更新整个网络的参数, 使用 Adam 算法^[18]进行训练, 总体更新规则如下:

$$\begin{aligned} \theta_{Enc} &= \theta_{Enc} - \alpha \left(\frac{\partial L_{reg}}{\partial \theta_{Enc}} - \lambda \frac{\partial L_D}{\partial \theta_{Enc}} + \mu \frac{\partial L_{MK-MMD}}{\partial \theta_{Enc}} \right) \\ \theta_{Dec} &= \theta_{Dec} - \alpha \frac{\partial L_{reg}}{\partial \theta_{Dec}} \\ \theta_D &= \theta_D - \alpha \frac{\partial L_D}{\partial \theta_D} \end{aligned} \quad (13)$$

其中, α 为学习率, 权重参数 λ 和 μ 用于平衡判别器损耗和 MK-MMD 损耗对编码器参数更新的影响。

在整个网络的参数更新过程中, 通过编码器与判别器的对抗, 期望编码器产生域不变特征。引入的 MK-MMD 损失可以看作是域对抗性损失的整体正则

化项, 即在模型的梯度更新中添加约束, 使其能够向减小域间混合分布距离的方向更新, 从而促进整体迁移学习的效果。

3 实验结果与讨论

3.1 实验设置

该文在一个卧室布局的室内 WiFi 环境中进行实验, 分别在阳台部署了 AP-1、MP-1, 卧室部署了 AP-2、MP-2, 洗手间部署了 AP-3、MP-3。AP 为商用路由器作为发射端, MP 则为配备英特尔 5300 网卡的笔记本电脑作为接收端, 发包率为 100 pkts/s。它们通过一发三收提供 3 个无线链路, 共 90 个子载波。笔记本电脑在 Ubuntu 环境下安装了 CSI-tool 进行数据采集分析工作。在上述环境中, 共安排了 10 位实验人员 (其中男生 6 位, 女生 4 位), 每位人员分别在阳台、卧室、洗手间中做弯腰、蹲下、坐下、躺下、摔倒等动作各 20 次。

3.2 权重参数的分析与选取

在本次实验当中, 分析了两个域自适应损失的权重参数 λ 和 μ 对系统性能的影响。首先, 在不引入多核最大均值差异损失 (MK-MMD Loss) 的情况下, 分析了相对鉴别器损失权重 λ 对训练的影响。

3.2.1 权重参数 λ 对损失曲线的影响

分别对权重参数 λ 取值 0.05、0.1、0.15、0.2 进行实验。图 3 显示了权重参数 λ 对三种损失曲线的影响, 即来自源域和目标域的编码特征之间的 MK-MMD 度量损失 (暂时不参与训练, 仅用于显示效果) 曲线、重建的目标域样本 (测试集中不包含样本) 的鉴别器损失曲线和损失曲线。

当权重参数 λ 较小时 ($\lambda = 0.05$), 相对鉴别器的损失将持续减少, 并在一定迭代次数后收敛到最小值。这将导致梯度消失, 使相对鉴别器无法为特征编码器提供合理的指导。在训练的初始阶段, 特征编码器的能力相对较弱, 并且它在鉴别器也较弱的同时, 仍然可以区分来自源域和目标域的样本。但是, 权重较小, 因此对抗性训练不足。这使得相对鉴别器的训练快速饱和, 后续网络进一步重新调整难以进行。因此, $\lambda = 0.05$ 的目标损失曲线收敛到较高的位置。

区间 $[0.05, 0.2]$ 内加权参数 λ 的增大对相对鉴别器损耗的影响更为明显, 随着该区间内权重 λ 的增大, 鉴别器损耗曲线上升并最终收敛在较高值, 这表明通过权重参数 λ 加强相对鉴别器与特征编码器之间的对抗在一定程度上有利于域不变特征的生成, 但当参数 λ 继续增大, 尽管判别器损耗仍然上升, 但目标域的损耗曲线并没有进一步降低。这表明此时特征编码器无法学习更多的目标域知识, 域对抗训练也无法通过

增加权重参数达到更多可转移的特征,因此将 $\lambda = 0.15$ 固定为相对鉴别器损失的权重,以获得更好的自适应性能。




图 3 权重参数 λ 相应的损失曲线

3.2.2 权重参数 μ 对损失曲线的影响

在接下来的阶段中,将 MK-MMD 作为权重 $\lambda = 0.15$ 的域对抗损失的正则化项。图 4 所示的三个损

失曲线将用于分析权重参数 μ 对系统性能的影响。参数在 $\{0, 0.01, 0.05, 0.1, 0.15\}$ 中取值。此外, $\mu = 0$ 表示没有引入 MK-MMD。




图 4 权重参数 μ 相应的损失曲线

从 MK-MMD 损失曲线的趋势可以看出,引入 MK-MMD 作为正则化项可以有效地降低源域和目标域之间的 MK-MMD 度量,当权重参数较小时 ($\mu = 0.01$),这并不可观。然而,当权重增加时,影响会扩大,相对鉴别器的损失也增加,表明域间对抗加强,目标域损失的减少已经证明, MK-MMD 损失的引入使模型朝着产生域不变特征的方向优化,与鉴别器权重 λ 相比,模型对 MK-MMD 权重 μ 更具鲁棒性。当 μ 值高于 0.05 时,虽然 MK-MMD 损失仍有所降低,但相对鉴别器的损失没有增加,目标域损失也没有减少,表明此时增加 MK-MMD 的权重参数不能进一步加强域间对抗以达到更好的自适应效果。为了平衡 MK-MMD 和相对鉴别器的损失,最终分别选择 $\lambda = 0.15, \mu = 0.05$ 作为权重。

3.3 评估指标


为了验证提出的摔倒检测系统 DA-Fall 的性能,将敏感性和特异性两个标准用于性能评估。其中,敏感性定义为正确检测出摔倒的概率:

$$\text{sensitivity} = \frac{TP}{TP + FN} \quad (14)$$


而特异性定义为正确检测到除摔倒以外的其他活动的概率:

$$\text{specificity} = \frac{TN}{TN + FP} \quad (15)$$

其中, TP、TN、FP、FN 分别代表真阳性、真阴性、假阳性、假阴性的数量。敏感性和特异性证明了 DA-Fall 系统检测摔倒的能力。评估结果基于各系统分别在室内阳台、卧室、洗手间三个场景的检测平均值。具体结果展示在图 5 中。



(a) 敏感性



(b) 特异性

图 5 检测性能对比

3.4 评估结果分析

从上节实验结果可以看出,文中系统的检测精度在不考虑环境迁移的情况下,与 WiFall、RT-Fall 和 SignGAN 等都能达到 90% 以上的检测精确度,当检测系统被移动到一个未经训练的场景时,从图中很明显能看出 WiFall 以及 RT-Fall 出现了检测精度骤降的情况。由于 WiFall 使用局部异常因子来检测人在环境中的摔倒活动,对环境的变化更加敏感,但无法细分具体动作,因此无论在哪个房间,识别度都不是很高。而检测系统 SignGAN 仍然能达到平均 83% 以上的检测精度,得益于其引入的与文中相似的基于 GAN 的域自适应网络,该网络可以将源域的真实样本转换为具有目标域样式的目标域,消除了特定环境和用户的影响。

提出的系统 DA-Fall 引入了域鉴别器和域混淆自适应层来进行对抗性训练,其通过引入依赖于相对值的相对鉴别器来优化对抗训练更好地反映域间差异,并将多核 MMD (MK-MMD) 作为域对抗损失的正则化项,在模型的梯度更新中添加约束,进一步减小域间差异和域间的分布距离,促进了整体迁移学习的效果。最终 DA-Fall 在原场景(数据及训练充分)中达到了 96.83% 的精度,在新场景中仅需要少量数据即可达到 91.03% 的精度。

4 结束语

在提出的摔倒检测系统中,引入了域鉴别器和域混淆自适应层进行对抗性训练。首先,该算法通过引入依赖于相对值的相对鉴别器来优化对抗训练,从而更好地反映域间差异。其次,将基于多核架构的最大均值差异作为域对抗损失的正则化项,进一步减小了域间的边缘分布距离。通过实验分析证明了该算法的优越性。

参考文献:

- [1] LORD S R, SHERRINGTON C, MENZ H B, et al. Falls older people: risk factors strategies prevention [M]. Cambridge: Cambridge Univ. Press, 2007: 157-160.
- [2] FOROUGH I H, ASKI B S, POURREZA H. Intelligent video surveillance for monitoring fall detection of elderly in home environments[C]//Proc. 11th IEEE int. conf. comput. inform. technol. Khulna: IEEE, 2008: 219-224.
- [3] RIMMINEN H, LINDSTROM J, LINNAVUO M, et al. Detection of falls among the elderly by a floor sensor using the electric near field[J]. IEEE Trans. Inform. Technol. Biomed., 2010, 14(6): 1475-1476.
- [4] LI Q, YANG W, CHEN X, et al. Temporal segment connection network for action recognition[J]. IEEE Access, 2020, 8: 179118-179127.
- [5] SEIFELDIN M, SAEED A, KOSBA A E, et al. Nuzzer: a large-scale device-free passive localization system for wireless environments[J]. IEEE Transactions on Mobile Computing, 2012, 12(7): 1321-1334.
- [6] LONG M, CAO Y, CAO Z, et al. Transferable representation learning with deep adaptation networks[J]. IEEE Trans. Pattern Anal. Mach. Intell., 2019, 41(12): 3071-3085.
- [7] WANG Y X, WU K, NI L M. Wifall: device-free fall detection by wireless networks[J]. IEEE Transactions on Mobile Computing, 2017, 16(2): 581-594.
- [8] 杨志勇, 王俊杰, 金磊. 基于 SE-CNN 的人体摔倒检测方法[J]. 计算机工程, 2022, 48(6): 270-277.
- [9] WANG H, ZHANG D Q, WANG Y S, et al. RT-Fall: a real-time and contactless fall detection system with commodity WiFi devices[J]. IEEE Transactions on Mobile Computing, 2017, 16(2): 511-526.
- [10] 于东辉, 汤霖, 王潮. 基于 CSI 的摔倒检测系统[J]. 微型电脑应用, 2021, 37(7): 1-4.
- [11] ZHANG Hebao, CHEN Xin, CHEN Sheng. Cross-domain Wi-Fi sign language recognition with GANs[C]//Proceedings of the 10th international conference on communications and broadband networking (ICCBN). New York: Association for Computing Machinery, 2022: 60-65.
- [12] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[C]//Proceedings of the 27th international conference on neural information processing systems. Cambridge: ACM, 2014: 2672-2680.
- [13] JOLICOEUR-MARTINEAU A. The relativistic discriminator: a key element missing from standard GAN[J]. IEEE Access, 2018, 6: 1807-1839.
- [14] GULRAJANI I, AHMED F, ARJOVSKY M, et al. Improved training of Wasserstein GANs[J]. arXiv: 1704. 00028, 2017.
- [15] WANG Mei, DENG Weihong. Deep visual domain adaptation: a survey[J]. Neurocomputing, 2018, 23(5): 135-153.
- [16] 汪洪桥, 孙富春, 蔡艳宁, 等. 多核学习方法[J]. 自动化学报, 2010, 36(8): 1037-1050.
- [17] FANG Y, XIAO F, SHENG B, et al. Cross-scene passive human activity recognition using commodity WiFi[J]. Frontiers of Computer Science, 2022, 16(1): 83-93.
- [18] KINGMA D, BA J. Adam: a method for stochastic optimization[J]. IEEE Access, 2014, 16(3): 1412-1431.