

基于对抗判别域适应的近红外与可见光异质人脸识别

张 帅, 谢志华, 牛杰一, 李 毅

(江西科技师范大学, 江西省光电子与通信重点实验室, 江西 南昌 330031)

[摘要] 本文从对抗判别域适应的角度出发, 利用无监督学习的方法缩小双模态图像之间的模态差异, 提出了一种基于对抗判别域适应的近红外与可见光异质人脸识别方法。首先, 联合交叉熵和中心损失函数预训练了一个基于卷积神经网络的可见光人脸识别网络, 赋予网络强的鉴别能力。其次, 利用对抗损失对抗地训练了一个网络结构一致的近红外人脸识别网络, 使得两个网络提取的特征的数据分布一致, 从而缩小模态之间的鸿沟。最后, 利用前一个网络提供的先验知识输出另一模态图像的后验概率。实验结果显示提出的算法在不需要近红外人脸图像的标签信息和大规模的训练集的情况下, 表现出了优良的性能。

[关键词] 异质人脸识别, 无监督学习, 对抗学习, 域适应

[中图分类号] TP39 [文献标志码] A [文章编号] 1001-4616(2020)04-0095-09

Near-infrared and Visible-light Image Heterogeneous Face Recognition Based on Adversarial Domain Adaptation Learning

Zhang Shuai, Xie Zhihua, Niu Jieyi, Li Yi

(Key Laboratory of Optic-Electronic and Communication, Jiangxi Sciences and Technology Normal University, Nanchang 330031, China)

Abstract: The paper uses innovatively the unsupervised learning method to reduce the modal difference between bimodal images from the perspective of adaptive domain discrimination. A new near-infrared and visible-light heterogeneous face recognition method is proposed based on adversarial domain adaption learning. Firstly, we use cross-entropy and central loss function to jointly pre-train a full-convolution network, which gives the network a strong discriminating ability and provides the prior knowledge to another network. Then, another structurally consistent full convolutional network is trained by the adversarial loss, so that the data distribution of features extracted by the two network is consistent which narrowing the gap between the modalities. Finally, using the prior knowledge provided by the previous network, we can output the posterior probability of another modal images. Experimental results show that the proposed method can achieve the good performance, without requiring of the label information of near-infrared face image or large-scale training dataset.

Key words: heterogeneous face recognition, unsupervised learning, adversarial learning, domain adaptation

随着应用场景的不断更新, 市场上待识别图像的模态已经不仅仅局限于可见光波段。近红外人脸图像、热红外人脸图像、素描人像等双模态或者多模态的异质人脸识别问题成为人脸识别的研究热点之一^[1]。异质人脸识别最大的挑战主要有两点^[2]: 第一, 其他模态的已标注人脸图像相较于可见光模态人脸图像来说规模太小, 而且现有的异质人脸图像库也不足; 第二, 不同模态图像之间存在巨大的模态鸿沟, 具体的模态差异如图 1 中的近红外和可见光人脸图像的 t-SNE (t distribution-stochastic neighbor embedding) 成分分布所示, 其中, ‘+’ 表示近红外数据, ‘o’ 表示可见光数据, 不同的数字代表不同的类别。近年来, 基于深度学习方法的近红外与可见光异质人脸识别方法, 以双模态图像对作为输入, 利用两个模态标签来提取“具有模态不变性”的特征, 或学习“公共子空间”来缩小模态间的差异。文献[1-2]尝试将在大规模可见光数据集学习到的先验知识迁移到近红外人脸图像上, 在可见光人脸数据集上预先训练一个 CNN 网络, 通过精调将 CNN 网络迁移到近红外域。He 等^[3]将 CNN 和子空间学习结合起来, 在大规模的可见光数

收稿日期: 2020-06-10.

基金项目: 国家自然科学基金项目(61861020)、江西省教育厅科技项目(GJJ190578)。

通讯作者: 谢志华, 博士, 教授, 研究方向: 计算机视觉与模式识别。E-mail: xie_zhihua68@aliyun.com

据集上训练网络底层的 CNN 网络,将网络高层分成 3 个部分,分别用于提取特征模态的特征和具有模态不变性的子空间映射共享特征. Reale 等^[4]训练了两个网络,一个用于可见光图像的 VISNet,另一个用于近红外图像的 NIRNet,通过孪生网络框架将两个网络的输出统一. Song 等^[5]将跨模态人脸生成的假象和判别性特征学习嵌入到一个端到端的对抗网络中.

目前,较少的工作关注基于无监督域适应学习的方式来解决异质人脸的跨域识别任务. 在域适应工作中,利用生成对抗网络的对抗原理使得鉴别器无法区分其源域和目标域的数据分布,以达到缩小域偏移的目的^[6]. 因此,受对抗损失在域适应任务上优异性能的启发,本文将对判别域适应的无监督学习框架(如 ADDA^[7])引入到近红外和可见光跨域识别领域中. ADDA 框架主要解决了 3 方面的问题:基础模型的选择(选择判别模型)、是否权值共享的选择(选择不进行权值共享)、损失函数选择(选择对抗损失). 在 ADDA 中,分析特定域的特征,改善对分类器性能具有重要作用,因此,将源网络固定,让目标网络的参数分布靠近源网络,实现域适应,然后将域适应后的目标网络用于目标数据集,实现无监督学习. 最近 Laradji 等对 ADDA 做了改进,首次将度量学习(Metric learning)引入到无监督域适应任务上,其框架(M-ADDA^[8])主要分为两步:首先在源数据上用 triplet 损失作为监督信号预训练源网络,使源网络模型带有鉴别信息;然后对抗性地训练目标网络使目标网络提取的特征与源网络提取的拥有近似相同的分布,同时引入中心损失约束目标网络的嵌入层,使源网络和目标网络的嵌入层的聚类拥有相似的结构.

本文基于 ADDA 框架聚焦无监督异质人脸识别问题,由于 ADDA 处理的是简单手写字识别任务,而本文处理是人脸识别问题,相对于手写字来说更为复杂,将 ADDA 框架中的经典手写字网络 LeNet^[9],用全卷积网络取代,并与鉴别器网络结合. 本文的第二个改进有:在训练源网络即可见光网络时,在原有交叉熵损失函数的基础上,引入基于度量学习的中心损失函数来约束监督信号,使得到的特征具有更好的鉴别性能. 提出方法的具体效果见图 2,从图中可以清晰地看到,近红外数据被拉到了可见光域中,而且大部分同类别的近红外和可见光人脸图像聚类更集中.




图 1 近红外和可见光人脸图像的 T-SNE 成分初始分布

Fig. 1 The distribution of the T-SNE of near-infrared and visible-light face image




图 2 近红外和可见光人脸域适应后的 T-SNE 成分分布

Fig. 2 The distribution of the T-SNE of near-infrared and visible-light face image after domain adaptation

1 对抗域适应相关工作

基于迁移学习的异质图像识别,由于预训练网络的数据样本与训练任务的样本存在不同的数据分布,模型学到的是基于原数据的特征表示,因此这些特征对其他域作用有限. 为缓解这个问题,近年来涌现了一系列域适应的工作,目的是确定源的域和目标域两个域之间的共同潜在空间,利用域适应来改善域偏移对模型的影响^[10]. 一些方法使用最大平均差异(MMD)^[11]作为损失,即计算两个域均值之间差异的范数. DDC 方法^[12]除了在源数据上使用常规分类损失函数之外,还使用 MMD 来学习既具有判别性又具有域不变性的特征表示. 深度适应网络(DAN)^[13]将 MMD 嵌入到 Hilbert 空间中,有效地匹配两个分布的高阶统计量. 深度相关对齐(CORAL)^[14]方法提出匹配两个分布的均值和协方差. 对抗性损失方法基于相对域鉴别器的对抗性目标来最小化近似域的偏移距离. 文献[15]提出增加域分类器(单个全连接层),预测基于域的二分类标签,并设计域混淆损失,以指导预测的域标签的概率分布尽可能接近均匀分布. 梯度反转算法(Reverse grad)也将域不变性视为二分类问题^[16],通过反转其梯度来直接最大化域分类损失. DRCN^[17]采用了类似的方法也实现了重建目标域图像. CoGAN^[18]通过训练两个 GAN 分别生成源图像和

目标图像,将 GAN 应用于域的偏移问题,该方法通过固定两个 GAN 的高级层参数来实现域不变特征空间,并应用于 MNIST 和 USPS 数字数据集之间的转换.但是,该方法依赖于生成器找到从共享高级层特征空间到两个域中的完整图像映射.这些方法的出发点都是生成对抗网络(GAN)原理,基于两个相互对立的网络(一个生成器、一个判别器),生成器通过生成近似逼真图像来混淆判别器,而判别器又努力将生成的图像与真实图像区分开.在域适应的研究中,可以利用生成对抗网络原理,达到网络无法区分其源域和目标域的数据分布的目的.对抗判别域适应(ADDA),统一了原来的域适应的设计选择,如是否共享权重,基础模型是利用生成模型还是对抗模型?

2 提出的异质人脸识别方法

基于 ADDA(对抗判别域适应),本文提出一种对抗判别谱域适应(Spectral-ADDA)的方法用于异质人脸识别.提出的 Spectral-ADDA 人脸识别框架主要分为两步:

首先,在可见光人脸数据集上用分类损失函数训练可见光人脸识别网络,从而使网络能够学到“具有判别能力”的特征(见图 3).

然后,通过对抗损失函数用非对称映射的方法将近红外域的人脸映射到可见光域的空间,从而使得近红外和可见光域人脸的类后验概率分布更为相似(见图 4,红色代表近红外数据分布,蓝色代表可见光数据分布).

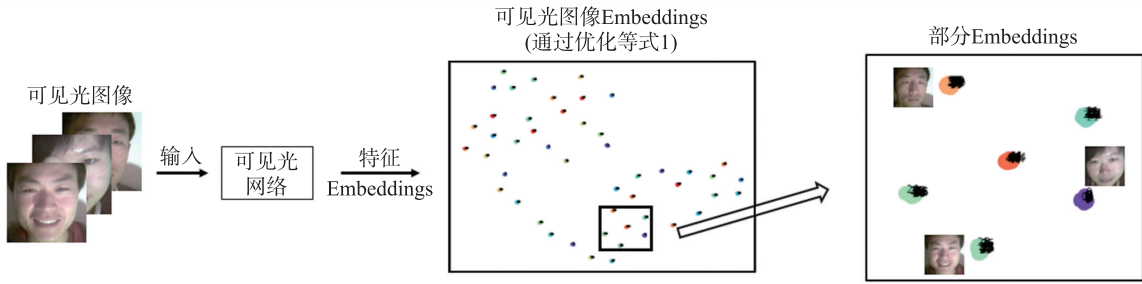


图 3 训练可见光网络

Fig. 3 The process of training the visible network

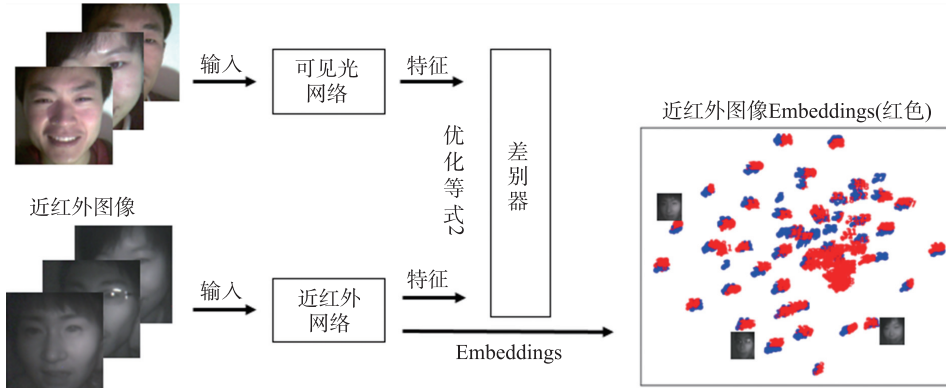


图 4 对抗近红外训练网络

Fig. 4 The process of adversarial training the near-infrared network spectral-ADDA

人脸识别框架是由可见光人脸识别网络(源模型)和近红外人脸识别网络(目标模型)两个深度网络模型组成,两个模型拥有相同的网络结构.假设,现有可见光数据集 (X_{vis}, Y_{vis}) 和近红外数据集 (X_{nir}, Y_{nir}) ,具体的训练过程为如下两个网络.

2.1 训练可见光网络模型

参数为 θ_{vis} 的可见光网络 $f_{vis}(\cdot)$,在可见光人脸数据上进行训练,网络优化的损失函数如式(1)所示:

$$\min_{f_{vis}} \mathcal{L}(\theta_{vis}) = \mathcal{L}_s(f_{vis}(\theta_{vis})) + \lambda * \mathcal{L}_c(f_{vis}(\theta_{vis})) = - \sum_{i=1}^m \log(S) + \lambda * \frac{1}{2} \sum_{i=1}^m \|x_i - c_{y_i}\|_2^2, \quad (1)$$

式中,

$$S_j = \frac{e^{x_{i,j}}}{\sum_{k=1}^C e^{x_{i,k}}}, \quad (2)$$

等式(1)中, L_s 和 L_c 分别代表交叉熵损失函数和中心损失函数, λ 是一个可调的高参, y_i 表示第 i 个输入数据的类别, c_{y_i} 代表第 y_i 类的人脸的特征中心, $x_i \in \mathbf{R}^d$ 表示第 i 个输入数据通过网络 $f(\cdot)$ 后的特征输出, d 是特征的维度, m 表示最小批次的大小, S 代表 x_i 的 softmax 输出, C 表示数据集中总的类别数.

2.2 训练近红外人脸识别网络模型

首先,固定可见光网络,然后参数为 θ_{nir} 的近红外人脸识别网络 $f_{nir}(\cdot)$ 在近红外人脸数据上训练,优化下面的损失函数:

$$\min_{f_{nir}} \max_D \mathcal{L}_{adv D}(D, f_{nir}) = -\mathbf{E}_{x_{vis} \sim X_{vis}} \log D(f_{vis}(x_{vis})) - \mathbf{E}_{x_{nir} \sim X_{nir}} \log(1 - D(f_{nir}(x_{nir}))), \quad (3)$$

式中, $D(\cdot)$ 代表判别器,用来拉近由可见光和近红外人脸数据集两者提取特征的分布. 训练判别器 $D(\cdot)$ 主要用于最大化可见光人脸识别网络和近红外人脸识别网络分别提取特征的分布,或者说,判别器 $D(\cdot)$ 主要用于区分近红外和可见光人脸被网络提取的特征,赋予近红外数据一个数值较高的标签(接近于 1),而赋予可见光数据一个数值较低的标签(接近于 0). 同时 $f_{nir}(\cdot)$ 被训练来迷惑判别器,使判别器无法区分数据的来源. 这种判别学习的方式使得由 $f_{nir}(x_{nir})$ 和 $f_{vis}(x_{vis})$ 提取特征的分布较为相似(注:在训练过程中,为提高模型的稳定,加入一些域噪声标签信息).

在训练过程中,等式(3)可以拆分成等式(4)和等式(5)两个优化目标,固定可见光网络的参数后先优化判别器,然后固定判别器优化近红外人脸识别网络

$$\max_D \mathcal{L}_{adv D}(X_{vis}, X_{nir}, f_{vis}, f_{nir}) = -\mathbf{E}_{x_{vis} \sim X_{vis}} \log D(f_{vis}(x_{vis})) - \mathbf{E}_{x_{nir} \sim X_{nir}} \log(1 - D(f_{nir}(x_{nir}))), \quad (4)$$

$$\min_{f_{vis}, f_{nir}} \mathcal{L}_{adv f}(X_{vis}, X_{nir}, D) = -\mathbf{E}_{x_{nir} \sim X_{nir}} \log D(f_{nir}(x_{nir})). \quad (5)$$

3 数据集及网络参数

为了验证本文的方法对于无监督谱域适应任务的有效性,在一个标准的可见光近红外异质人脸数据集(HITSZ LAB2^[19])上进行测试,数据集存在两个域:近红外域和可见光域,都包含 50 个类别,每个类别下均有 20 幅图像,共计 1 000 幅近红外人脸图像和 1 000 幅可见光人脸图像,和正常的模型评价方式一样,本文将数据集分成了两部分(训练集和验证集),分割比率为 8:2,即 800 幅用于训练,200 幅用于验证(近红外和可见光数据集都是按照这样的方式分割). 因为本文采取的方式是无监督的,近红外域的所有图像无标签信息.

本文使用与文献[7]采用的手写字网络^[9]完全不同的网络结构,因为人脸比手写数据更为复杂,经典的手写字网络 LeNet 结构无法学到判别特征表示,而 Inception 结构在物体分类任务应用较为广泛,并且本文的数据量较少,因此本文在 InceptionV4-Base 的基础上增加了 3 层卷积层,具体网络结构如图 5

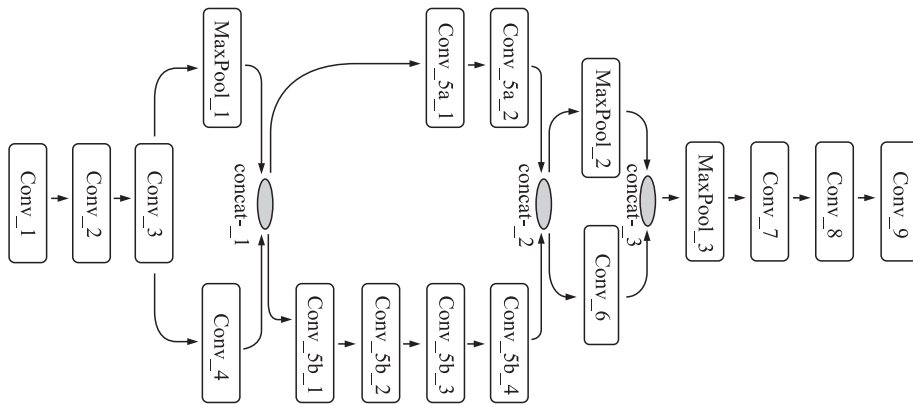


图 5 网络具体结构

Fig. 5 The details of network structure

所示,通过在 Base 的池化层后增加 3 层卷积层将网络的输出整合成特定维度的网络输出,网络的具体参数见图 6. 所有卷积层的 pad 标签为 S 意味着他们的输入和输出的尺寸相同,以 same-padding 的方式进行卷积,而 pad 标签为 V 意味着以 valid-padding 的方式进行卷积,不会对前一层的特征图进行补零,相应地输出激活映射的尺寸也减小了. 对于判别器,则使用和 ADDA 相同的结构,3 层全连接层:前两层包含 512 神经元,最后一层为判别器输出. 前两层后使用 Leaky_ReLU 作为激活函数.

层	0	1	2	3	4	5	6	7	8
类型	输入	卷积	卷积	卷积	池化	卷积	卷积	卷积	卷积
名字	-	Con_1	Con_2	Con_3	MaxPool_1	Con_4	Con_5_1a	Con_5_2a	Con_5_1b
	-	3	3	3	3	3	1	3	1
	-	3	3	3	3	3	1	3	1
	-	32	32	64	-	96	64	96	64
步长	-	2	1	1	2	2	1	1	1
Pad	-	V	V	S	V	V	S	S	S
层	9	10	11	12	13	14	15	16	19
类型	卷积	卷积	卷积	池化	卷积	池化	卷积	卷积	卷积
名字	Con_5_2b	Con_5_3b	Con_5_4b	MaxPool_2	Conv_6	MaxPool_3	Conv_7	Conv_8	Conv_9
	7	1	3	3	3	3	8	1	1
	1	7	3	3	3	3	8	1	1
	64	64	96	-	192	-	256	128	类别数
步长	1	1	1	2	2	-	1	1	1
Pad	S	S	V	V	V	V	V	S	S

图 6 网络具体参数

Fig. 6 The detail of the network parameters

4 实验结果及分析

在实验中,为了更好地评价提出方法的性能,将实验分成 A 和 B,两者不同在于训练集和测试集的分割比.

4.1 实验 A

首先,预训练可见光人脸识别网络 300 个周期(epoch),然后对抗训练近红外人脸识别网络和判别器 400 个周期,最后在近红外测试集上验证测试效果.

图 7 显示了可见光网络的训练过程,红色代表基于交叉熵损失函数,蓝色代表基于交叉熵和中心联合损失函数. 图 8 展示了训练前后可见光数据的 Embeddings 的 t-SNE 成分,图 8(a) 显示了可见光数据 Embeddings 的原始分布,可以看出初始数据分类非常杂乱也没有聚类;图 8(b) 表示仅使用交叉熵损失函数作为监督训练了 300 个周期后的可见光数据 Embeddings 分布,可以看出数据已经聚类,但类内距离仍然很大;图 8(c) 表示使用交叉熵和中心损失函数共同作为监督训练了 30 个周期后可见光数据




图 7 可见光网络的训练过程

Fig. 7 The training process of VIS Net

Embeddings 的分布,可以看出类内距离在缩小;图 8(d)表示使用交叉熵和中心损失函数共同作为监督训练了 300 个周期后可见光数据 Embeddings 的分布,数据分布非常理想,类内距较小,类间距较大.

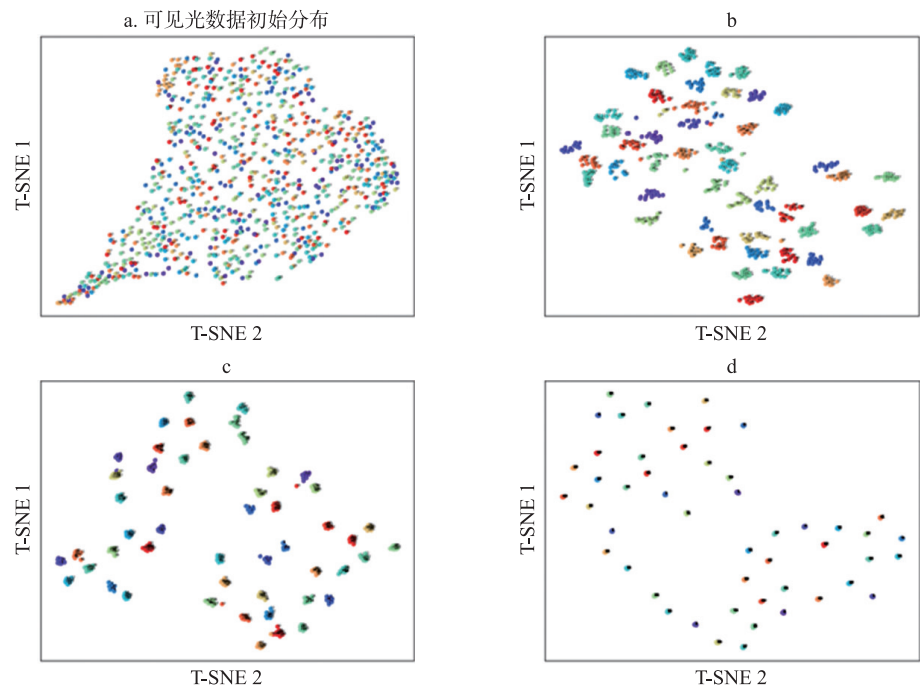


图 8 训练过程中可见光图像的 T-SNE 成分分布
Fig. 8 The T-SNE distribution of visible image with training

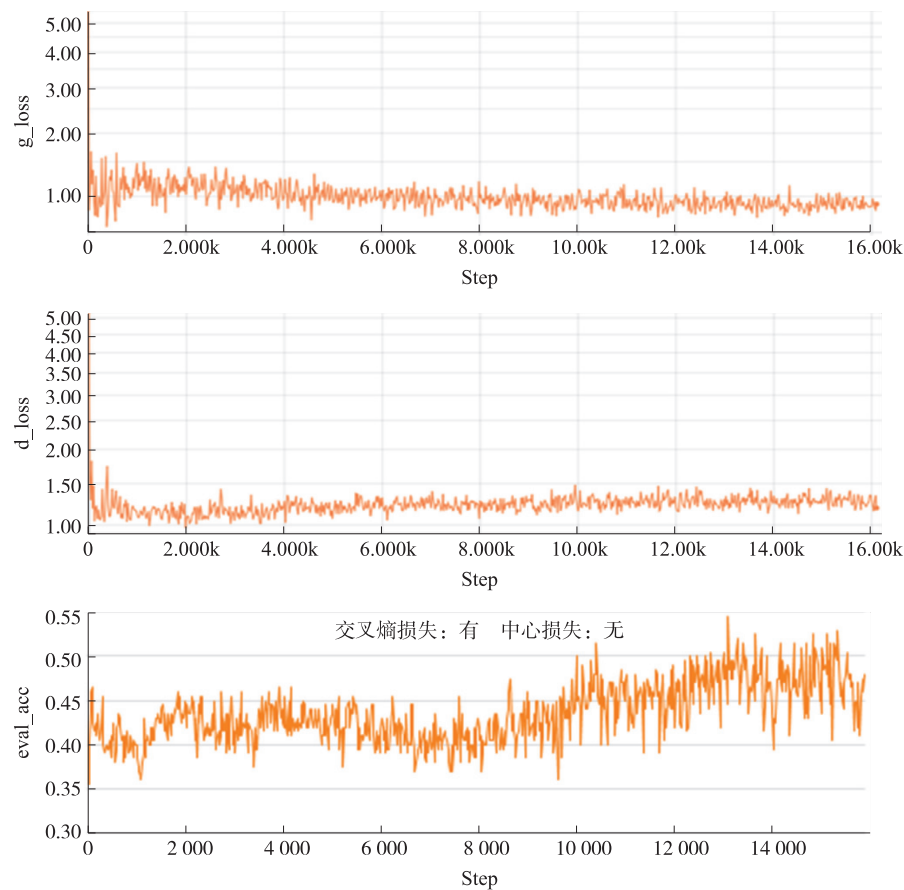


图 9 域适应训练过程 A
Fig. 9 The training process A of domain adaptation

对抗域适应的对比训练过程如图 9(仅交叉熵损失函数)和图 10(交叉熵和中心联合损失函数)所示.从图中可以看出,随着训练的增加,判别器 D 的损失在增加(如图 9(a)和图 10(a)所示),近红外人脸识别网络 $f_{\text{mir}}(\theta_{\text{mir}})$ 的损失在降低(如图 9(b)和图 10(b)所示),这意味着判别器随着训练的增加,对近红外和可见光数据的区分能力变弱,且近红外人脸识别网络输出的分布与可见光人脸识别网络输出的分布也更相似.




图 10 域适应训练过程 B

Fig. 10 The training process B of domain adaptation

表 1 展示了在近红外和可见光人脸数据集上的实验结果.从表 1 中可以看到,当没有做对抗域适应时,即使用带有标签信息的可见光人脸数据训练可见光网络,然后使用可见光网络预测近红外人脸数据,无论仅使用交叉熵损失作为监督,还是使用交叉熵和中心损失函数共同作为监督,近红外数据的识别率都很低,这也证明了近红外和可见光数据分布之间存在巨大差异,因此有必要使用无监督域适应的方法来缩小模态间的差异.

当仅使用交叉熵作为监督,训练对抗域适应网络时,近红外人脸数据的识别率从 35.5% 提高到了 54%,提高了将近 19%,当以联合中心损失函数作为监督时,识别率又提高了 12%,这证明了我们方法的有效性.

4.2 实验 B

本文采用的域适应的方法是无监督的,在训练过程中不会使用任何近红外人脸数据集的标签信息,而

表 1 实验 A 的结果

Table 1 The results of experiment A

方式	识别率
可见光人脸识别网络(仅交叉熵)	0.355
对抗域适应(仅交叉熵)	0.540
可见光人脸识别网络(交叉熵+中心损失)	0.350
对抗域适应(交叉熵+中心损失)	0.660

为了更好地验证模型的性能,在本次实验中,网络结构和损失函数仍按照上面实验的方式,可见光数据集依然按照上面的方式进行训练和验证集的分割,近红外数据集将整体同时作为训练集和验证集.

实验过程如下,首先预训练可见光人脸识别网络 300 个周期,然后对抗训练近红外人脸识别网络和判别器 400 个周期,最后在近外红测试集验证实验效果. 在本次实验中,仅仅改变了近红外数据集的训练集和验证集的分割,近红外数据集同时作为训练集和验证集,在验证时第 0 个周期计算的是未做对抗域适应的近红外数据在已经预训练可见光网络的输出结果,即表 2 中的仅训练可见光网络方式. 可见光网络的训练过程和实验 A 相同,具体情况见图 7 和图 8. 后续的对抗训练也和实验 A 相同,训练过程见图 9 和图 10. 表 2 的结果显示,较表 1 又提高了 7.6%,最终结果为 73.6%. 因此,我们提出的方法在无监督近红外和可见光人脸数据间的谱域适应上有着巨大的潜力.

表 2 实验 B 的结果

Table 2 The results of experiment B

方式	识别率
可见光人脸识别网络(交叉熵)	0.377
对抗域适应(交叉熵)	0.541
可见光人脸识别网络(交叉熵+中心损失)	0.281
对抗域适应(交叉熵+中心损失)	0.736

5 结论

本文提出了一种基于无监督域适应的可见光和近红外异质人脸识别方法. 首先,在可见光人脸数据集上用交叉熵损失和中心损失函数联合预训练一个基于全卷积网络的可见光网络. 然后,对抗地训练了一个与可见光网络结构一致的近红外人脸识别网络,拉近两个网络提取特征的分布. 实验结果表明,通过对抗域学习,近红外人脸特征表示与可见光人脸特征表示的分布更相似,并且获得了 73.6%的识别率.

[参考文献]

[1] LIU X,SONG L,WU X,et al. Transferring deep representation for NIR-VIS heterogeneous face recognition[C]//2016 international conference on biometrics(ICB). IEEE:Halmstad,Sweden,2016.

[2] SAXENA S,VERBEEK J. Heterogeneous face recognition with CNNs[C]//European conference on computer vision. Springer, Cham,Switzerland,2016:483-491.

[3] HE R,WU X,SUN Z,et al. Wasserstein cnn:learning invariant features for nir-vis face recognition[J]. IEEE transactions on pattern analysis and machine intelligence,2019,41(7):1761-1773.

[4] REALE C,NASRABADI N M,KWON H,et al. Seeing the forest from the trees:a holistic approach to near-infrared heterogeneous face recognition[C]//Proceedings of the IEEE conference on computer vision and pattern recognition workshops. New Jersey,USA:IEEE Press,2016:54-62.

[5] SONG L,ZHANG M,WU X,et al. Adversarial discriminative heterogeneous face recognition[C]//Thirty-second AAAI conference on artificial intelligence. New Orleans,USA,2018.

[6] 王格格,郭涛,余游,等. 基于生成对抗网络的无监督域适应分类模型[J]. 电子学报,2020,48(6):1190-1197.

[7] TZENG E,HOFFMAN J,SAENKO K,et al. Adversarial discriminative domain adaptation[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. New Jersey,USA:IEEE Press,2017:7167-7176.

[8] LARADJI I,BABANEZHAD R. M-ADDA:Unsupervised domain adaptation with deep metric learning[J]. arXiv preprint arXiv:1807.02552,2018.

[9] LE C Y,BOTTOU L,BENGIO Y,et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE,1998,86(11):2278-2324.

[10] JIA X,JIN Y,SU X,et al. Domain-invariant representation learning using an unsupervised domain adversarial adaptation deep neural network[J]. Neurocomputing,2019,355(8):209-220.

[11] TZENG E,HOFFMAN J,ZHANG N,et al. Deep domain confusion:maximizing for domain invariance[J]. arXiv preprint arXiv:1412.3474,2014.

[12] GRETTON A,SMOLA A,HUANG J,et al. Covariate shift by kernel mean matching[J]. Dataset shift in machine learning,2009,3(4):5-12.

[13] LONG M,CAO Y,WANG J,et al. Learning transferable features with deep adaptation networks[J]. arXiv preprint arXiv:1502.02791,2015.

- [14] SUN B, SAENKO K. Deep coral: correlation alignment for deep domain adaptation[C]//European conference on computer vision. Springer, Cham, Switzerland, 2016: 443–450.
- [15] TZENG E, HOFFMAN J, DARRELL T, et al. Simultaneous deep transfer across domains and tasks[C]//Proceedings of the IEEE international conference on computer vision. New Jersey, USA: IEEE Press, 2015: 4068–4076.
- [16] GANIN Y, LEMPITSKY V. Unsupervised domain adaptation by backpropagation[J]. arXiv preprint arXiv:1409.7495, 2014.
- [17] GHIFARY M, KLEIJN W B, ZHANG M, et al. Deep reconstruction-classification networks for unsupervised domain adaptation [C]//European conference on computer vision. Springer, Cham, Switzerland, 2016: 597–613.
- [18] LIU M Y, TUZEL O. Coupled generative adversarial networks[C]//30th conference on neural information processing systems. Barcelona, Spain, 2016: 469–477.
- [19] XU Y, ZHONG A, YANG J, et al. Bimodal biometrics based on a representation and recognition approach [J]. Optical engineering, 2011, 50(3): 037202–037202–7.

[责任编辑:陆炳新]