

基于自纠错伪标签的无监督域自适应

林磊, 孙涵

(南京航空航天大学 计算机科学与技术学院/人工智能学院, 江苏 南京 211106)

摘要:当前不少域自适应方法采用为目标域生成伪标签的思想,但是由于源域数据的不充足以及源域和目标域之间的域差异,模型生成的伪标签往往含有大量错误信息,这些噪声会导致模型出现很严重的负迁移现象。针对伪标签可能带有噪声的情况,一个具有自纠错能力的双网络伪标签模型被提出,该模型拥有一个学生网络和一个教师网络。教师网络利用源域标注数据进行数据降维和子空间变换为目标域无标注数据生成伪标签,该伪标签基于源域类别信息与目标域结构信息。学生网络利用伪标签进行学习,并且将学习结果反馈给教师网络,教师网络根据反馈更新伪标签。通过这种循环自纠错的过程,目标域的伪标签会更加贴合目标域的真实空间,最终达到迁移的效果。所提方法在多个数据集下表现优异,实验结果证明了其有效性。

关键词:域自适应;伪标签;学生教师模型;数据降维;子空间变换

中图分类号:TP391

文献标识码:A

文章编号:1673-629X(2023)01-0193-07

doi:10.3969/j.issn.1673-629X.2023.01.029

Self-correcting Pseudo Label for Unsupervised Domain Adaptation

LIN Lei, SUN Han

(School of Computer Science and Technology/Artificial Intelligence, Nanjing University of
Aeronautics and Astronautics, Nanjing 211106, China)

Abstract: Many current domain adaptation methods use the idea of generating pseudo-labels for the target domain, but due to the insufficient data in the source domain and the domain differences between the source and target domains, the pseudo-labels generated by the model often contain a lot of noises, which can lead to a seriously negative migration phenomenon. To address the situation that pseudo-labels may be noisy, a two-network pseudo-label model with self-correcting capability is proposed, which has a student network and a teacher network. The teacher network uses the source domain labeled data to generate pseudo-labels by performing dimensionality reduction and subspace transformation to the target domain unlabeled data, which is based on the source domain category information and the target domain structure information. The student network uses the pseudo-labels to learn and feeds the learning results to the teacher network, which updates the pseudo-labels based on the feedback. Through this circular self-correcting process, the pseudo-labels will be more closely matched with the real label of the target domain after each update, and finally achieve the effect of migration. The proposed method achieves excellent results under the experiments of several datasets and proves its effectiveness.

Key words: domain adaptation; pseudo-label; student-teacher model; dimensionality reduction; subspace transformation

0 引言

随着深度学习的飞速发展,现实世界中也存在越来越多的域自适应问题,这些问题大部分是由于数据标注成本昂贵和深度模型对于不同任务的欠迁移性所导致的^[1]。无监督域自适应旨在解决有标记的训练样本和无标记的测试样本来自于不同领域(分别称为源域和目标域)的问题。若用源域的标记样本进行训练学习到的模型,在不进行域自适应的情况下直接应用

于目标域样本,则模型会出现明显的性能下降。这种性能的降低主要是由于两个领域之间存在因为数据分布差异而导致的域偏移所造成。不少域自适应方法采用伪标签^[2]的思想,利用源域数据训练出的模型为目标域生成伪标签。但是现存的伪标签方法存在两个不足之处:伪标签由源域数据训练的模型生成,这会导致伪标签受限于源域数据,因为域迁移现象,该伪标签无法完全适配目标域数据;在训练的早期,网络可能生成

收稿日期:2022-01-17

修回日期:2022-05-24

基金项目:中央高校基本科研业务费专项资金资助项目(NZ2019009)

作者简介:林磊(1996-),男,硕士,CCF会员(B5252G),研究方向为计算机视觉;通讯作者:孙涵(1978-),男,博士,副教授,CCF南京秘书长(33361M),研究方向为计算机视觉。

错误的伪标签,不进行修正继续训练则会导致网络学习的分布与目标域分布差异越来越大。根据目前基于伪标签域自适应方法的不足之处,该文从伪标签的选择和更新两个方面提出了改进方案。

受到半监督学习中元伪标签^[3]的启发,提出了基于自纠错伪标签的无监督域自适应方法(Self-correcting Pseudo Label for unsupervised domain adaptation, SPL)。首先,在伪标签生成阶段,主要使用源域子空间对齐和目标域聚类对齐结合的方法选择更优的初始伪标签。然后,在训练过程中,利用学生教师双网络模型进行伪标签的更新。具体而言,教师网络使用源域和目标域数据一起训练,生成最优伪标签,学生网络则使用目标域数据和伪标签进行有监督训练。接着,根据学生网络在伪标签目标域数据集上的表现,同步优化教师网络的参数,并且相应地调整伪标签,以进一步提高学生网络的表现。在多个标准域自适应数据集上的实验结果证明了该方法在域自适应问题的有效性。

1 相关工作

在无监督域自适应问题中,因为源域的标记样本和目标域的无标记样本在训练阶段都是可用的,所以它是一个可以进行归纳学习的过渡性学习问题。早期的方法试图通过学习一个联合子空间来调整源域和目标域,从而使任何一个域的样本都能被投射到这个共同的子空间中,然后采用不同的算法来促进目标域样本在这个子空间中的可分离性^[4]。然后,使用在大规模 ImageNet 数据集上预训练的深度模型提取特征的方法进一步促进了这些基于特征转换的方法。随后,梯度反转^[5]和对抗学习^[6]的方法被用于深度域自适应,以学习端到端方式学习域不变特征。另一种有效的方式则是为目标域样本生成伪标签^[7-8]。

尽管伪标签方法的性能很好,但是它们都有两大不足之处。首先,伪标签主要由有标记的源域数据训练的分类器生成,这样生成的伪标签会过度依赖于源域数据,而源域和目标域之间存在域偏移,所以这种伪标签就可能携带噪声信息,导致最后训练出来的网络在目标域上出现性能下降的情况。此外,目前伪标签主要分为硬伪标签和软伪标签。硬伪标签的策略是为每一个未标记的目标域样本都分配一个伪标签,然后将有伪标签的目标域样本和源域样本一起进行学习来改进分类模型。这种硬伪标签的问题是,在训练初期,弱分类器误标的样本可能会对后续学习过程造成严重伤害。弱伪标签则是为目标域样本分配每个类的条件概率,从而得到一个伪标签向量,并且在每次迭代训练的过程中都更新这个伪标签向量。虽然弱伪标签优于

硬伪标签,但是如果弱伪标签更新方法的不佳同样会导致出现硬伪标签的问题。所以,针对目前伪标签方法存在的问题,该文提出了一种更加稳定的可以进行自纠错的伪标签域自适应方法。

2 自纠错伪标签网络

2.1 总体框架

在无监督域自适应问题中,给定一个有标记的源域数据集 $D^s = \{(x_i^s, y_i^s)\}, i = 1, 2, \dots, n_s$, 来自于源域 S , $x_i^s \in \mathbb{R}^d$ 表示源域中第 i 个标签样本的特征向量, d 则是特征维度, $y_i^s \in Y^s$ 表示对应的标签。目标域 T 的数据集 $D^t = \{(x_i^t)\}, i = 1, 2, \dots, n_t$, $x_i^t \in \mathbb{R}^d$ 表示目标域中的特征向量。源域的标签空间和目标域的标签空间一致,即 $Y^s = Y^t$ 。在无监督域自适应问题中,有标签的源域样本 D^s 和无标签的目标域样本 D^t 都可用于模型训练^[9]。

提出的网络主要由学生网络 S 和教师网络 T 组成,它们对应的参数分别为 θ_s 和 θ_t 。教师网络的作用是利用有标记源域数据和无标记目标域数据训练,然后进行子空间对齐,将源域和目标域数据映射到易于区分特征的子空间内。接着,在该子空间内进行双重伪标签生成,分别从源域和目标域两个角度生成伪标签,综合考虑源域中可迁移知识和目标域内的结构信息。然后,从候选伪标签中选择最优伪标签加入伪标签集。接着,学生网络利用目标域数据集和伪标签集进行训练。但是,这个时候的伪标签集与真实的目标域标签集还存在一定的差异,需要进行自纠错更新。具体而言,设置一个反馈信号,用于反馈学生网络在伪标签集上的表现,然后将这一信号传递给教师网络更新教师网络的参数。学生网络和教师网络是并行训练的:学生网络从教师网络生成的伪标签数据中进行学习;教师网络从反馈信号中学习学生网络在伪标签数据上的表现,从而更新伪标签。经过这样的自纠错过程,网络可以学习到越来越贴合目标域的伪标签,成功实现从源域到目标域的迁移。

2.2 子空间对齐

该文主要利用教师网络训练源域和目标域数据,实现两者的子空间对齐,并且生成相应的伪标签。为了免除冗余噪声信息的干扰和简化计算,需要对这些高维深度特征进行降维处理,这里主要采用主成分分析的方法进行数据降维。具体而言,对于源域和目标域样本的总和 $\mathbf{X} = [x_1^s, \dots, x_{n_s}^s, x_1^t, \dots, x_{n_t}^t] \in \mathbb{R}^{m \times n}$, $n = n_s + n_t$, 将 \mathbf{X} 作为输入数据,中心矩阵为 \mathbf{H} , 主成分分析的优化目标就是寻找一个正交变换矩阵 $\mathbf{A} \in \mathbb{R}^{m \times m}$, 使得变换后数据的方差最大化:

$$\max_{A^T A = I} \text{tr}(A^T X H X^T A) \quad (1)$$

其中, $\text{tr}(\cdot)$ 表示矩阵的秩, 中心矩阵 $H = I - \frac{1}{n} \mathbf{1} \mathbf{1}^T$, $\mathbf{1}$ 表示 $n \times n$ 的单位矩阵。该方法可以通过特征分解的方法进行求解:

$$X H X^T a = \varphi a \quad (2)$$

所以, 降维矩阵 $A = [a_1, a_2, \dots, a_{m_1}] \in \mathbb{R}^{m \times m_1}$ 可以由协方差矩阵 $X H X^T$ 的前 k 个特征值对应的特征向量构成。应用主成分分析降维后的数据 $\tilde{X} \in \mathbb{R}^{m_1 \times n}$ 为:

$$\tilde{X} = A^T X \quad (3)$$

因为源域和目标域数据来自于不同分布的数据集, 特别是当域间差异比较大的时候, 两者的分布差异也会有明显的不同, 所以无法直接进行特征的对齐。而主成分分析作为一种线性的特征变换, 可以在不改进特征分布的情况下对数据进行降维。然后, 再对特征矩阵 \tilde{X} 的每一个特征进行 L2 范数约束: $\tilde{x} \leftarrow \frac{\tilde{x}}{\|\tilde{x}\|_2}$ 。原本距离较远的源域数据和目标域数据被降维到同一个球体表面之上, 在这个球体表面上进行源域和目标域的分布对齐就会更加容易。

在应用主成分分析进行降维和 L2 范数进行约束后, 源域和目标域之间的分布相较于最初已经有所拉近, 但是想要直接进行对齐难度还是比较大。又因为源域中的标签还未使用, 所以可以使用源域标签对特征矩阵 \tilde{X} 进行有监督的位置保留映射。通过这种映射, 可以从特征矩阵 \tilde{X} 中学习出一个域不变但是又具有辨别力的子空间 $S = [s_1, s_2, \dots, s_n] \in \mathbb{R}^{m_1 \times n}$ 。为了获得这种子空间 S , 需要求得一个投影变换 $B \in \mathbb{R}^{m_1 \times m_2}$, 使得 $s_i = B^T \tilde{x}_i$ 。

在这个子空间 S , 目的是拉近源域和目标域之间的分布, 但是因为域偏移, 想要整体匹配源域和目标域是不现实的, 但是源域和目标域的标签空间是一致的。在一致的标签空间内, 可以将源域和目标域数据一起进行类别的对齐。因为对于同一类别的样本, 无论其来自于哪个域, 在子空间 S 中投影应该是相近的。所以投影矩阵 B 的优化方式如下:

$$\min \frac{1}{2} \sum_{i,j} (s_i - s_j)^2 w_{ij} \quad (4)$$

其中, W 表示源域和目标域样本数据之间的相似矩阵。因为源域数据是有标注的, 所以这里利用标注数据对相似矩阵进行优化, 即同一类别的样本在映射空间内的距离应该是相近的, 所以它们之间的权重可以设为 1。

$$w_{ij} = \begin{cases} 1, & y_i = y_j \\ 0, & \text{其他} \end{cases} \quad (5)$$

其中, w_{ij} 表示样本 \tilde{s}_i 和 \tilde{s}_j 的相似度。

然后, 利用 MMD 的优化方式, 投影变换可以优化为:

$$\begin{aligned} \min \frac{1}{2} \sum_{i,j} (s_i - s_j)^2 w_{ij} = \\ \min \frac{1}{2} \sum_{i,j} (B^T \tilde{x}_i - B^T \tilde{x}_j)^2 w_{ij} = \\ \min \sum_i B^T \tilde{x}_i D_{ii} \tilde{x}_i^T - \sum_{ij} B^T \tilde{x}_i w_{ij} \tilde{x}_j^T = \\ \min B^T \tilde{X} (D - W) \tilde{X}^T B = \\ B^T \tilde{X} L \tilde{X}^T B \end{aligned} \quad (6)$$

其中, D 是相似矩阵更新的一个对角矩阵, $D_{ii} = \sum_j w_{ij}$, D_{ii} 越大说明 s_i 越重要。 $L = D - W$ 是一个拉普拉斯矩阵。然后引入约束 $B^T \tilde{X} D \tilde{X}^T B = 1$, 采用有监督局部保留投影优化算法, 投影矩阵的广义特征解可以优化为:

$$\tilde{X}^T D \tilde{X}^T B = \lambda (\tilde{X}^T L \tilde{X}^T + I) B \quad (7)$$

所以根据协方差 $\tilde{X}^T D \tilde{X}^T$ 的前 k 个特征值对应的特征向量, 可以得到最优映射 B 。其中 \tilde{X}^T 表示原始输入特征 X 经过数据降维后的带有标签的特征。不过学习域对齐的投影矩阵 B 需要源域和目标域的标签, 在训练早期目标域是没有标签的, 所以投影矩阵 B 刚开始是由源域样本优化生成。然后在教师网络生成伪标签之后, 投影矩阵 B 同时使用源域标签和目标域伪标签进行优化。假设 $P = AB$, 对于输入特征 x , 可以得到转换后的特征 $s = P^T x$ 。

2.3 双重伪标签生成

对于源域样本 x^s 和目标域样本 x^t , 经过子空间对齐之后, 可以获得其对应的映射 s^s 和 s^t 。因为源域数据是有标注的, 所以可以根据标注信息找出源域样本的分布结构。为了简化空间分布, 可以利用最近邻的思想生成源域中的类原型 \bar{s}^s , 即对所有源域样本中同一类别的映射求均值:

$$\bar{s}_y^s = \frac{1}{|S_y^s|} \sum_{s_i^s \in S_y^s} s_i^s \quad (8)$$

其中, S_y^s 表示子空间内所有源域样本标签为 y 的集合, $y = 0, 1, \dots, |Y|$, $|Y|$ 表示数据集中类别的数量。在子空间内部, 源域样本和目标域样本的类别空间是一致的, 虽然源域和目标域之间存在域间差异, 但是两者的条件分布是相似的。所以, 可以利用目标域映射特征 s^t 和源域类原型特征 \bar{s}^s 之间的差异来代表源域和目标域之间的差异:

$$d(\bar{s}_y^s, s^t) = \|s^t - \bar{s}_y^s\|_2 \quad (9)$$

其中, $d(S_y, T)$ 表示目标域特征 s^t 与类别为 y 的源域

类原型特征的距离。所以,可以利用目标域特征 s' 与每一个类的源域原型特征之间的差异表示目标域特征 s' 的条件概率:

$$p_s(y | x') = \frac{e^{-d(\bar{s}_y, s')}}{\sum_{y=0}^{|Y|} e^{-d(\bar{s}_y, s')}} \quad (10)$$

根据源域的标签信息,获得了基于源域原型的条件概率 $p_s(y | x')$ 。这一概率主要依赖于源域的内分布,但是目标域的内分布和源域之间还是存在一定差异的,所以只是使用源域类别信息的条件概率是不完善的,并且忽略了目标域自身的类别结构。为了获取目标域样本的内在结构,该文基于目标域类别空间生成新的伪标签。

具体而言,使用 K-means 聚类算法在所有目标样本的投影向量 s' 生成 $|Y|$ 个聚类族群,聚类的中心位置使用源域原型进行初始化。假设存在一个目标域映射和源域映射一对一的相关矩阵 $C \in \mathbb{R}^{|Y| \times |Y|}$,并且对于任意的 $c_{ij} \in C$ 存在以下关系:

$$\begin{aligned} \forall i, \forall j, c_{ij} &\in [0, 1] \\ \forall i, \sum_j c_{ij} &= 1 \\ \forall j, \sum_i c_{ij} &= 1 \end{aligned} \quad (11)$$

其中, c_{ij} 表示目标域中的第 i 个族群与类别 j 的相关性。该相关矩阵的优化方式如下:

$$\min_C \sum_{i=1}^{|Y|} \sum_{j=1}^{|Y|} d(s'_i, \bar{s}^j) \cdot C_{ij} \quad (12)$$

其中, s'_i 表示目标域映射中属于 i 族群的聚类中心, $d(\cdot)$ 表示 Euclidean 度量方式。公式 12 可以根据线性编程的方式求解出相关矩阵 $C = [\bar{s}_1^T, \bar{s}_2^T, \dots, \bar{s}_{|Y|}^T]^T$, 由此可以获得目标域原型特征 \bar{s}' 。类似于公式 9, 目标域映射特征和目标域原型特征之间的差异表示目标域样本类内之间的结构差异:

$$d(\bar{s}'_y, s') = \|s' - \bar{s}'_y\|_2 \quad (13)$$

借此,可以得到基于目标域类别结构信息的条件概率:

$$p_t(y | x') = \frac{e^{-d(\bar{s}'_y, s')}}{\sum_{y=0}^{|Y|} e^{-d(\bar{s}'_y, s')}} \quad (14)$$

使用迭代学习策略,交替学习用于域对齐的投影矩阵 P 和用于目标样本的双伪标签。尽管上述两种伪标签方法中的任何一种都能够为下一次迭代中的投影学习提供有用的伪标签,但它们在本质上是不同的。通过最近的源域类原型进行的伪标签倾向于向靠近源数据的样本输出高概率,而基于目标域结构化预测则对靠近目标域的聚类中心的样本具有高置信度,无论它们离源域有多远。所以,该文主张通过公式 10 和公

式 14 的简单组合来利用这两种方法的互补性:

$$p(y | x') = \max\{p_s(y | x'), p_t(y | x')\} \quad (15)$$

$$y' = \operatorname{argmax}_{y \in Y} (p(y | x')) \quad (16)$$

通过结合源域标签空间信息和目标域类内结构信息,获得了跨域的更符合目标域类内分布的伪标签 \hat{y}' 。拥有目标域的伪标签之后,就可以像训练源域一样,对目标域进行有监督训练。但是光依赖网络本身产生的伪标签优化网络存在一定局限性,容易因为伪标签的不准确导致出现确认偏差的问题。所以,该文将伪标签的生成和伪标签的训练分开,采用学生教师模型,教师网络利用所有的源域和目标域进行训练生成目标域伪标签,然后学生网络利用目标域数据和伪标签进行训练,实现源域到目标域的迁移。

2.4 自纠错伪标签更新

在半监督学习领域中,学生教师模型的方法已经被广泛应用到伪标签生成中,但是大部分的方法都是学生和教师之间无反馈的训练。受到元伪标签的启发,该文在域自适应学生教师模型中引入自纠错的伪标签更新方式。具体而言,存在一批源域数据 x^s 及其标签 y^s , 目标域数据 x' , 对于学生网络 S 和教师网络 T , 可以获得相应的软预测值 $S(x'; \theta_s)$, $T(x^s; \theta_t)$ 和 $T(x'; \theta_t)$ 。其中,学生网络只使用目标域数据,教师网络则同时使用源域和目标域数据。所以在有监督训练中,可以使用 $\text{CE}(y^s, S(x'; \theta_s))$ 作为典型的交叉熵损失。在伪标签训练过程中,往往通过最小化目标域数据的交叉熵损失来优化学生网络的参数:

$$\theta'_s = \operatorname{argmin}_{\theta_s} \mathbb{E}_{x'} [\text{CE}(T(x'; \theta_t), S(x'; \theta_s))] \quad (17)$$

其中, $T(x'; \theta_t)$ 表示经过训练后的教师网络,并且教师网络的参数 θ_t 是固定的。但是在这一框架之下,通过学生网络的参数 θ'_s 始终依赖于教师网络的参数 θ_t , 所以存在学生网络和教师网络之间的依赖关系 $\theta'_s(\theta_t)$ 。原本对于学生网络的损失 $\mathcal{L}_s(\theta'_s(\theta_t))$, 同样也是教师网络的函数。

$$\begin{aligned} \min_{\theta_t} \mathcal{L}_s(\theta'_s(\theta_t)), \theta'_s(\theta_t) = \\ \operatorname{argmin}_{\theta_s} \mathbb{E}_{x'} [\text{CE}(T(x'; \theta_t), S(x'; \theta_s))] \end{aligned} \quad (18)$$

直观而言,可以根据学生网络在伪标签数据上的表现优化教师的参数,相应地调整教师网络生成的伪标签质量,进一步提高学生网络的表现。但是,直接计算 $\theta'_s(\theta_t)$ 关于 θ_t 的梯度过于复杂,所以,采用 θ_s 的一步梯度更新来近似多步的 $\operatorname{argmin}_{\theta_s}$:

$$\begin{aligned} \theta'_s(\theta_t) \approx \theta_s - \eta_s \cdot \\ \nabla_{\theta_s} \mathbb{E}_{x'} [\text{CE}(T(x'; \theta_t), S(x'; \theta_s))] \end{aligned} \quad (19)$$

其中, η_s 表示学习率。所以,可以获得最终的学生网络优化目标:

$$\min_{\theta_s} \mathcal{L}_S \{ \theta_s - \eta_s \cdot \nabla_{\theta_s} E_{x'} [\text{CE}(T(x'; \theta_T), S(x'; \theta_s))] \} \quad (20)$$

对于教师网络生成的伪标签 $\hat{y}^t = T(x'; \theta_T)$, 利用这一伪标签有学生网络的损失 \mathcal{L}_S 以及教师网络的源域损失 $\mathcal{L}_{T,s}$ 和目标域损失 $\mathcal{L}_{T,t}$:

$$\mathcal{L}_S = \text{CE}(\hat{y}^t, S(x'; \theta_s)) \quad (21)$$

$$\mathcal{L}_{T,s} = \text{CE}(y^s, S(x^s; \theta_T)) \quad (22)$$

$$\mathcal{L}_{T,t} = \text{CE}(\hat{y}^t, S(x^t; \theta_T)) \quad (23)$$

3 实验与分析

主要使用三组域自适应任务中通用的数据集对上述方法进行了对比实验, 分别是 Office-31^[10] 数据集、Office-Home^[11] 数据集以及 VisDA-2017^[12] 数据集。为了验证提出的基于自纠错伪标签算法的有效性, 选择与多个无监督域自适应的方法相比较, 这些方法中有的使用了对抗学习的方法, 有的则使用了伪标签的思想。

该文主要使用 Pytorch 深度学习框架来实现基于

自纠错伪标签的无监督域自适应方法。为了公平比较, 每次实验都用相同的网络结构。利用不包含最后全连接层的, 在 ImageNet 上进行预训练的 ResNet50 作为特征提取器。使用了源域中所有的标签数据和目标域中所有的无标签数据, 最终在目标域数据集上比较算法的图像分类的准确率。主要使用的 GPU 为 Nvidia Titan Xp 显卡, 主要环境是在 Ubuntu16.04 操作系统下。

根据表 1 的实验结果, 提出的 SPL 算法在六种迁移任务上的平均准确率都优于其他对比算法。SPL 算法相较于不进行域自适应的 ResNet-50, 在平均准确率上提高了近 13.9 个百分点。相较于同样使用聚类伪标签但是伪标签没有更新的 CAT 方法也有不错的提升, 平均准确率比 CAT 高了 2.4 个百分点。具体到每一个迁移任务, SPL 的方法虽然在 A→W、D→W 和 A→D 任务上稍低于 REN, 但是在迁移任务更加困难的 D→A 和 W→A 上, SPL 的方法明显优于 REN, 分别提升 3.1 和 1.1 百分点。

表 1 Office-31 实验结果

							%
Method	ResNet-50 ^[13]	JAN ^[14]	MCD ^[15]	CDAN ^[16]	CAT ^[8]	REN ^[17]	SPL(Ours)
A→W	68.4	86.0	88.6	93.1	94.4	95.0	94.7
D→W	96.7	96.7	98.5	98.2	98.0	99.2	99.0
W→D	99.3	99.7	100.0	100.0	100.0	100.0	100.0
A→D	68.9	85.1	92.2	89.8	90.8	94.6	93.1
D→A	62.5	69.2	69.5	70.1	72.2	74.1	77.2
W→A	60.7	70.7	69.7	68.0	70.2	74.8	75.9
Avg	76.1	84.6	86.5	86.6	87.6	89.6	90.0

Office-Home 数据集的实验结果如表 2 所示。Office-Home 数据集相较于 Office-31 数据集更加困难。不过基于自纠错伪标签的 SPL 在面临这类困难情况时, 发挥出了伪标签自纠错的优势, 最终平均准确率比 ResNet-50 高了 22.6 百分点, 证明该算法具有不错的泛化能力。对于 12 个不同的迁移任务, SPL 在多个迁移任务上都表现最佳, 尤其是 Ar→Cl、Cl→Ar 和

Pr→Cl 任务上, 相较于第二名提升了 2~3 百分点。这是因为在这些难度较大的任务上, 源域和目标域之间的差异过大, 之前的方法大部分都过分依赖于源域的标签信息, 而 SPL 充分考虑到了目标域的结构信息, 根据源域和目标域的结合提取出了更优的伪标签, 并且在后续更新中一直优化伪标签, 从而迁移能力更强。

表 2 Office-Home 实验结果

							%
Method	ResNet-50 ^[13]	DANN ^[6]	JAN ^[14]	CDAN ^[16]	MSTN ^[18]	REN ^[17]	SPL(Ours)
Ar→Cl	34.9	45.6	45.9	49.0	49.8	54.4	56.6
Ar→Pr	50.0	59.3	61.2	69.3	70.3	73.6	73.3
Ar→Rw	58.0	70.1	68.9	74.5	76.3	77.4	78.1
Cl→Ar	37.4	47.0	50.4	54.4	60.4	61.6	63.1
Cl→Pr	41.9	58.5	59.7	66.0	68.5	71.1	70.2
Cl→Rw	46.2	60.9	61.0	68.4	69.6	71.7	70.5
Pr→Ar	38.5	46.1	45.8	55.6	61.4	61.0	61.3
Pr→Cl	31.2	43.7	43.4	48.3	48.9	52.2	55.2
Pr→Rw	60.4	68.5	70.3	75.9	75.7	78.8	77.5

续表 2

Method	ResNet-50 ^[13]	DANN ^[6]	JAN ^[14]	CDAN ^[16]	MSTN ^[18]	REN ^[17]	SPL(Ours)
Rw→Ar	53.9	63.2	63.9	68.4	70.9	73.1	72.6
Rw→Cl	41.2	51.8	52.4	55.4	55.0	59.4	61.9
Rw→Pr	59.9	76.8	76.8	80.5	81.1	83.5	84.4
Avg	46.1	57.6	58.3	63.8	65.7	68.2	68.7

对于 VisDA-2017 数据集,只使用了其中的合成数据集到真实数据集的迁移任务。因为 VisDA-2017 数据集比较复杂,所以采用 ResNet-101 作为主干网络。因为该数据集的复杂性,大部分对比算法都无法在所有类别上表现良好,比如 MSTN 虽然在类别 aero

和 mcycl 上取得了最好的效果,但是其在 truck 的准确率只有 18.5%。文中方法虽然只在类别 horse 和 person 上表现最佳,但是基本上在其他类别上效果也不错,所以最终的平均准确率要优于其他的对比算法。

表 3 VisDA-2017 实验结果

%

Method	ResNet-101 ^[13]	DANN ^[6]	MSTN ^[18]	JAN ^[14]	MCD ^[15]	SPL(Ours)
aero	55.1	81.9	89.3	75.7	87.0	81.1
bike	53.3	77.7	49.5	18.7	60.9	70.7
bus	61.9	82.8	74.3	82.3	83.7	79.8
car	59.1	44.3	67.6	86.3	64.0	85.1
horse	80.6	81.2	90.1	70.2	88.9	90.2
knife	17.9	29.5	16.6	56.9	79.6	70.9
mcycl	79.7	65.1	93.6	80.5	84.7	80.8
person	31.2	28.6	70.1	53.8	76.9	78.1
plant	81.0	51.9	86.5	92.5	88.6	84.1
skbrd	26.5	54.6	40.4	32.2	40.3	47.7
train	73.5	82.8	83.2	84.5	83.0	86.8
truck	8.5	7.8	18.5	54.4	25.8	37.3
Avg	52.4	57.4	65.0	65.7	72.0	74.4

移能力。

4 结束语

探讨了域自适应问题中如何有效地使用伪标签方法,提出了基于自纠错伪标签的无监督域自适应方法,不仅提出了更优的伪标签选择方案,而且使用了可以自动纠错的伪标签更新方案。在伪标签选择阶段,充分考虑了源域的分类信息和目标域的内在结构信息,从这两方面出发提出了双重伪标签,使生成的伪标签避免受限于源域知识,并且更符合目标域的特征分布。鉴于单网络生成的伪标签可能无法完全监督该网络的训练,使用了学生教师模型,利用教师网络同时训练源域和目标域特征,然后为学生网络生成伪标签,使伪标签的生成与使用分离。但是只有教师到学生网络的单向反馈是不足的,该文使用元伪标签的思想,通过学生网络在利用伪标签进行训练时的反馈,反向优化教师网络,使其形成一个循环优化的过程。提出的 SPL 方法在 Office-31、Office-Home 和 VisDA-2017 数据集上进行了大量的实验,并且与多个不同无监督域自适应方法进行了比较,验证了 SPL 方法的有效性以及迁

参考文献:

- [1] 龙明盛. 迁移学习问题与方法研究[D]. 北京:清华大学, 2014.
- [2] 周志华. 基于分歧的半监督学习[J]. 自动化学报, 2013, 39(11):1871-1878.
- [3] PHAM H, DAI Z, XIE Q, et al. Meta pseudo labels[C]// Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. [s. l.]: IEEE, 2021: 11557-11568.
- [4] 刘建伟, 孙正康, 罗雄麟. 域自适应学习研究进展[J]. 自动化学报, 2014, 40(8):1576-1600.
- [5] GANIN Y, LEMPITSKY V. Unsupervised domain adaptation by backpropagation[C]// International conference on machine learning. Lille: ACM, 2015: 1180-1189.
- [6] GANIN Y, USTINOVA E, AJAKAN H, et al. Domain-adversarial training of neural networks[J]. The Journal of Machine Learning Research, 2016, 17(1):2096-2030.
- [7] 余游, 冯林, 王格格, 等. 一种基于伪标签的半监督少

- 样本学习模型[J]. 电子学报, 2019, 47(11): 2284–2291.
- [8] DENG Z, LUO Y, ZHU J. Cluster alignment with a teacher for unsupervised domain adaptation[C]//Proceedings of the IEEE/CVF international conference on computer vision. Seoul: IEEE, 2019: 9944–9953.
- [9] 范苍宁, 刘 鹏, 肖 婷, 等. 深度域适应综述: 一般情况与复杂情况[J]. 自动化学报, 2021, 47(3): 515–548.
- [10] SAENKO K, KULIS B, FRITZ M, et al. Adapting visual category models to new domains[C]//European conference on computer vision. Berlin: Springer, 2010: 213–226.
- [11] VENKATESWARA H, EUSEBIO J, CHAKRABORTY S, et al. Deep hashing network for unsupervised domain adaptation [C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Honolulu: IEEE, 2017: 5018–5027.
- [12] PENG X, USMAN B, KAUSHIK N, et al. Visda: the visual domain adaptation challenge[J]. arXiv: 1710. 06924, 2017.
- [13] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Las Vegas: IEEE, 2016: 770–778.
- [14] LONG M, ZHU H, WANG J, et al. Deep transfer learning with joint adaptation networks[C]//International conference on machine learning. Sydney: ACM, 2017: 2208–2217.
- [15] SAITO K, WATANABE K, USHIKU Y, et al. Maximum classifier discrepancy for unsupervised domain adaptation [C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Salt Lake City: IEEE, 2018: 3723–3732.
- [16] LONG M, CAO Z, WANG J, et al. Conditional adversarial domain adaptation[J]. arXiv: 1705. 10667, 2017.
- [17] SUN H, LIN L, LIU N, et al. Robust ensembling network for unsupervised domain adaptation [C]//Pacific rim international conference on artificial intelligence. [s. l.]: Springer, 2021: 530–543.
- [18] XIE S, ZHENG Z, CHEN L, et al. Learning semantic representations for unsupervised domain adaptation[C]//International conference on machine learning. Stockholm: ACM, 2018: 5423–5432.
-
- (上接第 177 页)
- cing model[J]. IEEE Transactions on Industrial Informatics, 2018, 14(3): 1220–1231.
- [14] WANG S, BI S, ZHANG Y A. Reinforcement learning for real-time pricing and scheduling control in EV charging stations[J]. IEEE Transactions on Industrial Informatics, 2021, 17(2): 849–859.
- [15] WAN Zhiqiang, LI Hepeng, HE Haibo, et al. Model-free real-time EV charging scheduling based on deep reinforcement learning[J]. IEEE Transactions on Smart Grid, 2019, 10(5): 5246–5257.
- [16] MNIH V, MIRZA M, GRAVES A, et al. Asynchronous methods for deep reinforcement learning[C]//Proc of 33rd international conference on machine learning. New York: ICML Press, 2016: 1928–1937.
- [17] LINCOLN R, GALLOWAY S, STEPHEN B, et al. Comparing policy gradient and value function based reinforcement learning methods in simulated electrical power trade [J]. IEEE Transactions on Power System, 2012, 27(1): 373–380.