

基于主动学习的半监督领域自适应方法研究^①

姚明海^② 黄展聪

(浙江工业大学信息工程学院 杭州 310023)

摘要 传统机器学习算法都假定训练数据(源域)和应用场景数据(目标域)服从同一分布,而这种假设在实际应用中往往是不成立的。如果源域和目标域的分布差异较大,那么训练得到的分类器在目标域中性能将会降低,而为目标域数据收集所有标签并重新训练需要消耗大量资源。为了解决上述问题,本文提出了一种基于主动学习的半监督领域自适应方法,该方法首先利用已标记源域数和未标记目标域数据训练一个初始模型,然后利用主动学习从目标域中选择少量最具代表性的样本进行标记,并迭代训练已有模型,直到预先设置终点。本文在 SVHN、MNIST 和 USPS 数据集上分别进行了实验,实验结果表明,相比同类方法本文方法能更好地让源域上学习得到的分类器适用于目标域。

关键词 领域自适应; 主动学习; 神经网络; 图像识别

0 引言

自 2006 年 Hinton 等人^[1]采用逐层初始化解决深度神经网络训练以来,深度学习已广泛用于模式识别、图像理解、机器翻译等领域。2016 年,深度学习模型在 ImageNet 图像集上的识别错误率已经低于人类^[2]。然而,现有的深度学习模型训练都以监督学习为主^[3],为了训练包含巨大参数量的模型,需要大量的人工标注训练样本,并假设训练和应用场景数据属于同一分布。但在实际中,由于许多因素(如照明、姿态和图像质量等)的影响,训练和应用场景的样本分布往往不一致,使训练好的模型在应用场景下的性能严重降低。此时需要重新标注应用场景数据再进行训练,而为新任务标注数据集并重新训练是昂贵且耗时的过程,上述问题成为深层神经网络应用中新的难题。

领域自适应学习^[4]是一种解决如何将分类器从训练场景迁移到与之不同的应用场景的新型机器

学习方法,其中训练场景称为源域,应用场景称为目标域。源域和目标域的分布虽然不同,但是具有一定相关性,且只有源域数据具有标签信息,而目标域数据没有或者只有少量标签信息可用^[5]。从领域自适应学习提出至今,学者们已经提出了许多方法。Fetzer 等人^[6]引入了深度域混淆(DDC)架构来学习最后隐藏层中源域和目标域的域不变特征。Long 等人^[7]不局限于仅适配单一层,提出了一种深度自适应网络(DAN),进行多层适配来学习 2 个领域间的可迁移特征。之后,Long 等人^[8]在 DAN 的基础上,提出了联合自适应网络(JAN),基于联合最大均值差异(JMMD)进行多个领域特定层的联合分布,使得源域和目标域的分布更加可区分。

国内方面,袁丁等人^[9]在 DAN^[8]的基础上引入了聚类辅助特征对齐,该方法通过聚类获得目标域数据伪标记,并将聚类和域适应 2 个过程训练的分类器进行继承学习,以提升模型的最终效果。蔡瑞初等人^[10]提出类内最大均值差异技术对齐 2 个领域的类内分布,既保留分类信息,又减少了领域专用

① 国家自然科学基金(61871350)资助项目。

② 男,1963 年生,博士,教授;研究方向:模式识别和图像识别;联系人,E-mail: ymh@zjut.edu.cn
(收稿日期:2019-07-02)

信息的干扰。

文献[6-10]方法共同特点是训练时同时输入已标注源域样本和未标注目标域样本,训练中除了利用源域样本学习如何优化分类器外,还学习源域和目标域的数据关联,进而提取领域不变特征^[5],建立更优秀的学习模型。由于这些方法在训练时不需要任何目标域数据的标签信息,因此属于无监督学习范畴。虽然文献[6-10]的方法取得了一定效果,但从结果上可以发现仅使用源域标签信息学习得到的模型仍然无法完全适配目标域。

本文提出了一种基于主动学习的半监督领域自适应方法,该方法与文献[6-10]方法的主要差别在于利用了少量的目标域标签信息辅助源域上学习得到的分类器更好地迁移到目标域。为了实现上述目标,首先用源域和未标记的目标域数据训练深层神经网络作为初始模型,该模型可以通过提取领域不变特征让源域上学习得到的特征分类器基本适用于目标域。然后结合主动学习进一步加强领域自适应效果,具体做法是通过特定的样本选择策略不断挑选目标域中最具代表性的样本进行人工标注,然后迭代训练已有模型,直到预先设置终点。最后,在 SVHN、MNIST 和 USPS 数据集上分别进行了实验,实验结果表明,本文方法的领域自适应能力优于目前具有竞争力的同类方法。

1 主动学习

在训练深度神经网络模型的时候,随着训练数据的增加,网络模型的精度会不断提升。但是当训练数据量达到临界值时,精度基本不会产生变化,而这个临界值和数据样本本身有关。主动学习^[11]可以通过挑选更具代表性的样本迭代训练模型使临界值更早地到来,既提升了模型收敛的速度,同时节省了人力标注的成本。

图1是主动学习的基本流程,主要包括“学习模块”和“选择策略”2个最基本的重要模块。“学习模块”通过不断地迭代训练网络模型来提高分类器的分类精度和鲁棒性;“选择策略”模块通过某种选择策略选择出更具代表性的样本进行标记之后送

入“学习模块”。

目前常见的领域自适应方法,如文献[6-10]仅利用已标注源域样本和未标注目标域样本本身数据关联性学习得到的模型仍然无法完全适配目标域数据,因此可以考虑适当利用少量的目标域标签信息提升领域自适应效果,主动学习正是用于解决标注样本短缺条件下如何训练机器学习模型。文献[12,13]的 ALDA (active learning for domain adaptation) 算法证明了这种结合的可行性,ALDA 包括 3 部分,源域分类器 W_{src} 、目标域分类器 W_{ds} 和域判别器 u_ϕ 。ALDA 使用 u_ϕ 从未标记的目标域样本中选择样本然后决定是使用 W_{src} 获取标签还是人工标注, u_ϕ 不断使用标注后的样本训练。

与 ALDA 不同,本文提出的方法使用了深层神经网络,网络中的域判别器除了在训练中帮助减小源域和目标域在特征空间上的差距外,还参与了样本选择。第 2 节将具体介绍本文算法。

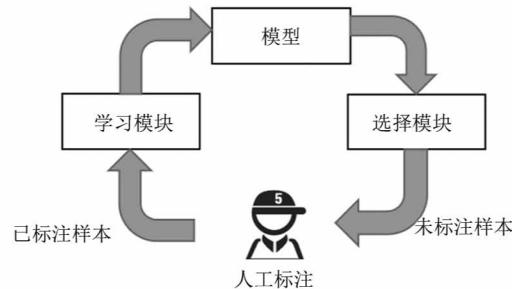


图1 主动学习基本流程

2 基于主动学习的半监督领域自适应方法

2.1 问题定义

本文以图像分类问题为背景,问题中的输入记为 $x \in X$, x 对应的标签记为 $y \in Y$, Y 是一个有限的集合, $Y = \{1, 2, \dots, L\}$ 。假设在 $X \otimes Y$ 上存在 2 个分布 $P_s(x, y)$ 和 $P_t(x, y)$, 代表源域数据分布和目标域数据分布。上述两者分布都是复杂且未知的,并存在一定差距。

根据源域和目标域分布的边缘分布 $P_s(x)$ 和 $P_t(x)$ 可以获得大量的训练样本集合 $\{x_1, x_2, \dots, x_N\}$ 。本文使用一个 0 或 1 的标量 d_i 代表第 i 个样本

x_i 来自哪一个域, d_i 等于 0 代表 $x_i \sim P_s(x)$, 反之 d_i 等于 1 代表 $x_i \sim P_T(x)$ 。为了后续描述方便, 源域样本集合记为 L_s , 目标域样本集合记为 U_T 。

在初始训练时, 源域样本的标签是已知的, 而目标域样本的标签是未知的。之后的训练中, 需要从目标域中挑选样本进行人工标注加入源域数据并重新训练模型。

本文最终的目标是给定来自目标域分布的输入 x 时, 能够预测它的标签。

2.2 网络结构

现定义一个深层神经网络, 其作用是对于每一个样本 x 预测其分类标签 $y \in Y$ 和领域标签 $d \in \{0, 1\}$ 。为了完成上述映射, 网络结构分成 3 部分, 如图 2 所示。先让输入 x 通过一个特征提取网络 G_f , 其把 x 映射成一个 D 维特征向量 $f \in R^D$ 。 G_f 由一系列卷积层和激活函数层组成, 其参数记为 θ_f , 此时有 $f = G_f(x; \theta_f)$ 。然后, 使用另一个卷积神经网络 G_y 作为标签预测网络把 f 映射成分类标签 y , G_y 参数记为 θ_y 。同时, 使用另一个卷积神经网络 G_d 作为域预测网络把 f 映射成领域标签 d , G_d 参数记为 θ_d 。

在训练时, 首先希望减小源域数据的标签预测损失, 并基于此优化 G_f 和 G_y 的参数。这使得不同类别的输入训练得到的特征 f 具有区分性, 并保证 G_f 和 G_y 的组合对于源域数据能成功地预测其标签。

同时, 特征向量 f 应具有领域不变性, 即源域数据和目标域数据都通过 G_f 映射到同一个特征空间, 映射后的特征分布 $P_s(f)$ 和 $P_T(f)$ 尽量一致, 从而让标签分类网络 G_y 适用于目标域数据的特征图, 保证总体上源域和目标域数据标签预测准确率一致。

受到对抗神经网络^[14] (generative adversarial network, GAN) 的启发, 本文使用额外的网络 G_d 来衡量 $P_s(f)$ 和 $P_T(f)$ 一致性。在训练中, G_f 尽量输出让 G_d 分辨不出来自源域还是目标域的特征向量, G_d 尽量分辨出数据来自于哪一个域, 最终, G_f 与 G_d 博弈的结果是源域和目标域的数据在特征空间上分布一致, 继而可以用 G_f 来分类目标域的数据。

为了实现上述训练目标, 本文设计损失函数如下, 其中 λ 是权重系数, L_c 是交叉熵。

$$E(\theta_f, \theta_y, \theta_d) = \lambda E_{x \sim P_s(x)} [L_c(G_y(G_f(x)), y)]$$

$$\begin{aligned} & + E_{x \sim P_s(x)} [\log G_d(G_f(x))] \\ & + E_{x \sim P_T(x)} [\log(1 - G_d(G_f(x)))] \end{aligned} \quad (1)$$

与 GAN 网络的对抗训练方式一致, 利用上述损失函数在训练中更新 θ_f 和 θ_y 时需固定 θ_d , 反之在更新 θ_d 时需固定 θ_f 和 θ_y , 即,

$$\begin{aligned} (\hat{\theta}_f, \hat{\theta}_y) &= \operatorname{argmin}_{\theta_f, \theta_y} E(\theta_f, \theta_y, \hat{\theta}_d) \\ \hat{\theta}_d &= \operatorname{argmax}_{\theta_d} E(\hat{\theta}_f, \hat{\theta}_y, \theta_d) \end{aligned} \quad (2)$$

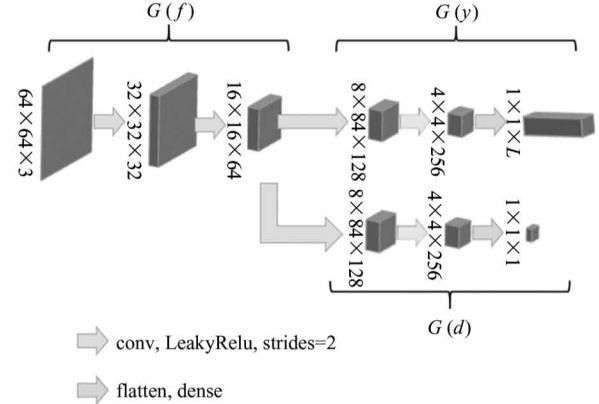


图 2 网络结构图

2.3 重要性分数

通过训练上述网络得到的模型 M 已经具备对 U_t 样本分类的能力, 但训练过程中仅利用了源域标签, 最终预测精度具有局限性, 在实验分析部分可看到具体结果。因此本文选择从 U_t 中选择少量重要的样本标注后迭代训练 M , 以提升 M 分类精度, 本小节介绍如何计算 U_t 中样本重要性分数用以后续选择。

文献[15]提出了一种带权重的领域自适应损失函数, 如式(3)所示:

$$\min_{\theta_f, \theta_y} E_{(x, y) \sim P_s(x, y)} \left[\frac{p_T(x)}{p_S(x)} L_c(G_y(G_f(x)), y) \right] \quad (3)$$

其中, $P_T(x)$ 、 $P_S(x)$ 分别代表目标域和源域数据的边缘分布, $w(x) = \frac{p_T(x)}{p_S(x)}$ 代表权重系数。从式(3)可知具有如下特征的样本在反向传播时更为重要: (1) 有更高的经验风险 $L_c(G_y(G_f(x)), y)$; (2) 有更高的权重系数。

本文将上述 2 个特征用于目标域样本重要性分数计算,但直接应用存在困难,首先因为 $w(x)$ 计算时无法直接估计源域和目标域 2 个高维分布,其次由于目标域样本没有标记导致无法计算其经验风险。

针对第 1 个问题,可以通过计算最优的域判别网络 $G_d^*(x)$ 求得 $w(x)$:

$$G_d^*(x) = \frac{p_s(x)}{p_s(x) + p_t(x)} \Rightarrow w(x) = \frac{1 - G_d^*(x)}{G_d^*(x)} \quad (4)$$

针对第 2 个问题,本文使用目标域样本的熵近似交叉熵^[16]。最终定义样本的重要性分数 $s(x)$ 如下,其中 $H(\cdot)$ 代表熵值。 $s(x)$ 越大表示该样本越值得标注。

$$s(x) = \frac{1 - G_d^*(G_f(x))}{G_d^*(G_f(x))} H(G_y(G_f(x))) \quad (5)$$

2.4 主动学习过程描述

输入 已标记源域数据 L_s , 未标记目标域数据 U_t , 已标记目标域数据 L_T , 预设轮数 b 。

模型 $M = \{G_y, G_f, G_d\}$, 具体结构及目标函数见 2.2 节。

步骤 1 利用 L_s 和 U_t 训练 M , 训练采用目前常见的小批量训练梯度下降(mini-batch gradient descent)法^[17], 每个批次从 L_s 和 U_t 中随机采样。

步骤 2 根据 2.3 节的方法, 使用训练完成的 M 计算 U_T 所有样本的重要性分数 $s(x)$, 降序排序选取前 b 个进行人工标注, 其集合记为 L_T , 此时 $U_T = U_T / L_T$ 。

步骤 3 使用 L_s, L_T, U_T 重新训练 M 。与初始阶段只有一个源域不同, 现在有 L_s 和 L_T 2 个源域。此类多源域领域自适应问题的泛化边界^[18]如下:

$$\begin{aligned} \varepsilon_T(\hat{h}) &\leq \varepsilon_T(h^*) + \varepsilon_a(h) + d_{H\Delta H}(L_s \cup L_T, U_T) \\ &+ 4 \sqrt{\left(\frac{a_s^2}{\beta_s} + \frac{a_t^2}{\beta_t}\right) \left(\frac{d \log(2m) - \log(\delta)}{2m}\right)} \end{aligned} \quad (6)$$

其中, $\varepsilon_a(h) = a_s \varepsilon_s(h) + a_t \varepsilon_t(h)$ 是源域和目标域经验风险的凸组合, a_s 和 a_t 是权重系数, m 是 $L_s \cup L_t$ 的数量, d 代表假设集合 H 的 VC 维度, $\hat{h} = \operatorname{argmin}_{h \in H} \varepsilon_a(h)$, $h^* = \operatorname{argmin}_{h \in H} \varepsilon_t(h)$ 。 β_s 和 β_t 分别是 L_s

和 L_t 中样本数量占两者总和的百分比, 当 $a_s = \beta_s$, $a_t = \beta_t$ 时, $\varepsilon_T(\hat{h})$ 上界接近最小。此时有:

$$\begin{aligned} \varepsilon_a(h) &= a_s \varepsilon_s(h) + a_t \varepsilon_t(h) \\ &= \beta_s \times \frac{1}{\beta_s m_{x \in L_T}} \sum L_c(G_y(G_f(x)), y) \\ &+ \beta_t \times \frac{1}{\beta_t m_{x \in L_S}} \sum L_c(G_y(G_f(x)), y) \\ &= \frac{1}{m_{x \in L_T \cup L_S}} \sum L_c(G_y(G_f(x)), y) \end{aligned} \quad (7)$$

因此, 使用 L_s, L_t, U_t 重新训练模型 M 时可以把 L_s, L_t 看成整体, 同样采用步骤 1 的小批量训练梯度下降法, 每个批次从 L_s, L_t, U_t 随机采样。

步骤 4 重复步骤 2 和 3, 直到 M 的总训练次数到达预设值 b 。

3 实验与分析

3.1 数据集介绍

本文选择 MNIST 数据集, SVHN 数据集和 USPS 数据集作为本文的实验对象。MNIST 数据集^[19]是一种广泛使用的灰度手写数字数据集, 包含 60 000 个训练图像和 10 000 个测试图像。USPS 数据集^[20]是美国邮政服务手写数字识别库, 库中共有 9 298 个手写数字图像, 均为灰度图像, 灰度值已被归一化。街景门牌号码(SVHN)^[21]则是包含来自 Google Street View 的各种房屋号码, 图像具有一定的实际背景。利用上述 3 个数据可以构建以下 3 项任务: SVHN → MNIST、MNIST → USPS 和 USPS → MNIST。在每项任务中, 左边的数据集作为源域, 右边的数据集作为目标域, 其中所有图像都重新调整为 32×32 的像素分辨率。

3.2 实验设置

本文实验运行在搭载 GTX1080 显卡的机器上, 使用 Python 语言编写程序, 其中图像预处理的部分使用了 OpenCV3.4 库, 检测算法使用 Keras2.0 搭建模型, TensorFlow1.4 作为后端, 使用 Adam 优化算法训练网络参数, 初始学习率 $lr = 2e^{-3}$, 动量参数 $\beta_1 = 0.5$, $\beta_2 = 0.999$ 。

在主动学习的每一轮训练中训练 20 个周期, 其中每个批次的大小为 128, $\lambda = 0.1$, 样本选择的数

量为 20,共进行 20 轮。

3.3 结果分析

3.3.1 交叉实验

本文算法的目的是结合主动学习让源域上学习得到的分类器更好适配到目标域,主要依赖解决以下 2 个问题:(1)选择哪些目标域样本进行标注?(2)样本标注后如何训练模型?针对上面 2 个问题,本文选择了一些其他方法展开交叉实验,实验中样本的选择策略如下:

(1) 依据重要性分数:如 2.3 节所述。

(2) K-Means 聚类^[22]:对特征向量 $G_f(x)$, $\forall x \in U_t$ 进行聚类,共选择 b 个聚类中心,对每个类选择离其中心最近的类。

(3) BVSF 法^[23]:对于 U_t 的每个样本, G_y 会输出其对应每个分类标签的置信度,BVSF 值是最大的置信度和第 2 大置信度之间的差值,代表该样本的不确定性,BVSF 值越大代表分类器对该样本越不确定其属于哪个类别。

(4) 随机选择:从 U_t 中随机选择待标注样本。

对于标注后的训练有如下选择:

1) 对抗训练:如 2.4 节所述,使用 $\{L_s, L_t, U_t\}$ 重新训练。

2) 微调^[24]:固定特征提取网络 G_f 、域判别网络 G_d ,仅使用 L_t 更新标签分类器 G_y 的参数。

图3是不同采样策略的实验对比结果,训练方

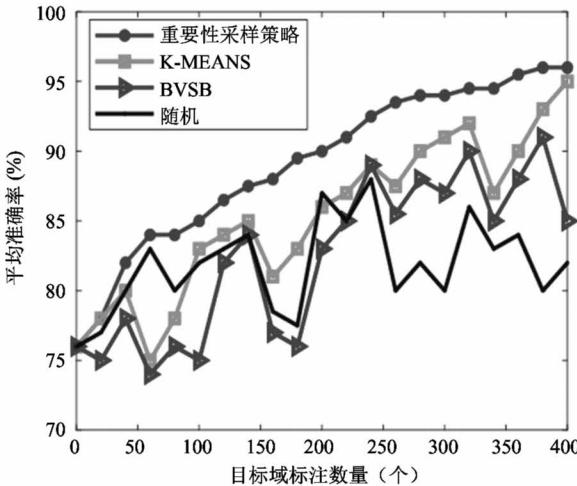


图 3 不同采样策略的对比结果

法都使用 $\{L_s, L_t, U_t\}$ 重新训练,其中横坐标是标注样本的总数,纵坐标是 3 个任务的平均准确率。从图 4 中看到本文方法的准确率基本在每一轮都高于其他方法,此外在标注样本增多时能保证准确率持续上升,而其他方法均不能保证。这是由于其他方法可能使某一类别的分类准确率很高,而其他类别较低,从而整体平均准确率反而下降。

图 4 是不同训练方法实验对比结果,样本选择策略都依据 2.3 节。从图中可以看到标注数量小于 300 时,对抗训练效果明显优于微调。而在标注数量超过 300 后,两者准确率提升都不明显,微调方法的准确率略高于对抗训练。整体上,采用对抗训练能比微调获得更好的效果。

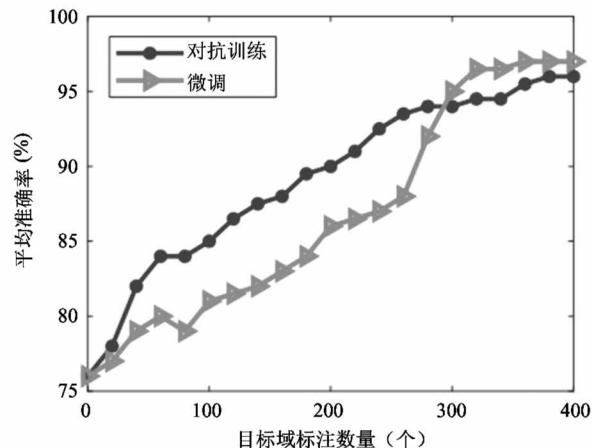


图 4 不同训练方法对比结果

3.3.2 同类方法比较

除了上述实验外,本文与目前主流方法 ALDA^[12,13]进行了对比。图 5 是准确率上的对比结果,可以看到本文算法整体效果都优于 ALDA,当标注样本数达到 340 时,本文算法平均准确率比 ALDA 高出 7.8%。

为了进一步对比,本文还统计了不同方法达到指定平均准确率所需的人工成本和模型收敛时间,分别如图 7 和图 8 所示。结合主动学习的领域自适应方法的人工成本主要在于目标域样本的标注,从表 1 可以看到,本文方法达到指定平均准确率所需要的人工成本比 ALDA 分别减少了 33.33%、54.54%、35.48%、26.53%。

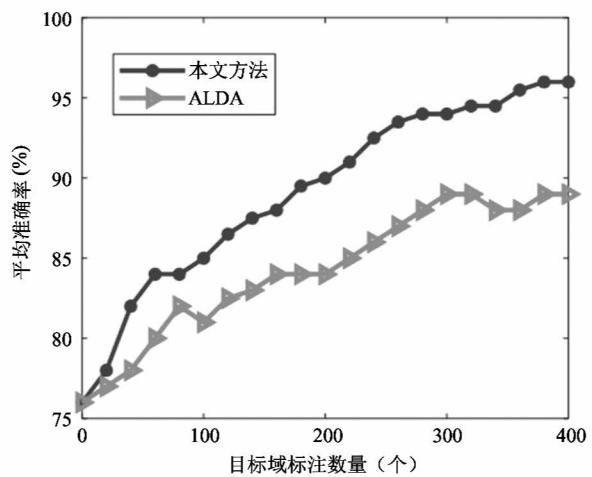


图 5 与 ALDA 对比结果

表 1 不同方法达到指定平均准确率所需的标注数量

平均准确率	80%	85%	90%	95%
本文方法	40	120	200	360
ALDA	60	220	310	490

另外,表 2 为不同方法不同标注数量所需的收敛时间,其中标注数量 0 对应 2.4 节中步骤 1 所用的时间,由于本文方法参数数量大于 ALDA,因此在初始训练时所花的时间大于 ALDA 方法。

其余标注数量为 100、200、300 和 400 对应 2.4 节中步骤 4 的时间,这部分中本文方法与 ALDA 所用时间相差不大,这是因为此时训练时的初始参数是上一次收敛后的参数,因此都能较快收敛。同时,随着标注数量的增加,收敛时间逐渐减少,这是因为目标域标注数量增加时,准确率提升的程度逐渐减小,从而模型参数变化程度减小,导致收敛越来越快。总体上,本文方法能更好地让源域上学习得到的分类器适用于目标域。

表 2 不同方法不同标注数量所需的收敛时间 (s)

标注数量	0	100	200	300	400
本文方法	2 010	150	142	61	48
ALDA	1 618	145	130	62	55

4 结 论

本文提出了一种基于主动学习的半监督领域自适应方法,它可以解决机器学习应用中由于训练场景和测试场景不一致带来的性能下降问题。该方法利用深层神经网络对齐源域和目标域的数据表示学习域不变特征,让源域上学习得到的分类器在目标域上基本可用。同时,结合主动学习方法,不断选取最重要的目标域数据标记,然后提升已有模型的精度。实验结果表明,本文提出的方法实现了具有较高准确度的跨域分类性,通过标记少量的目标域样本就可以获得较好的领域自适应效果。后续的研究主要会对网络结构进行进一步的优化处理,改善整个网络结构,使其整体性能朝着更快更准确方向发展。

参 考 文 献

- [1] Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks [J]. *Science*, 2006, 313(5786): 504-507
- [2] 孙志军, 薛磊. 深度学习研究综述[J]. 计算机应用研究, 2012, 29(8):2806-2810
- [3] 郭丽丽, 丁世飞. 深度学习研究进展[J]. 计算机科学, 2015, 42(5):28-33
- [4] 张博, 史忠植, 赵晓非, 等. 一种基于跨领域典型相关性分析的迁移学习方法[J]. 计算机学报, 2015(7): 1326-1336
- [5] Yang F, Enzner G, Yang J. A unified approach to the statistical convergence analysis of frequency-domain adaptive filters[J]. *IEEE Transactions on Signal Processing*, 2019, 67(7):1785-1796
- [6] Fetzer M, Scherer C W, Veenman J. Invariance with dynamic multipliers[J]. *IEEE Transactions on Automatic Control*, 2018, 63(7):1929-1942
- [7] Long M S, Cao Y, Wang J M, et al. Learning transferable features with deep adaptation networks [C] // Proceedings of 32nd International Conference on Machine Learning, New York, USA, 2015: 97-105
- [8] Long M S, Zhu H, Wang J M, et al. Deep transfer learning with joint adaptation networks [J]. *arXiv*: 1605.06636, 2017
- [9] 袁丁, 王茜. 聚类辅助特征对齐的域适应方法[J]. 计算机科学, 2019, 46(3):221-226
- [10] 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[J]. 计算机应用研究, 2019,

47(4):228-210

- [11] Tong S, Koller D. Support vector machine active learning with applications to text classification [J]. *Machine Learning Research*, 2002, 2(1):999-1006
- [12] Persello C, Bruzzone L. Active learning for domain adaptation in the supervised classification of remote sensing images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2012, 50(11):4468-4483
- [13] Deng C, Liu X, Li C, et al. Active multi-kernel domain adaptation for hyperspectral image classification [J]. *arXiv*:1904.05200v1, 2019
- [14] Goodfellow I J, Pouget-Abadie J, Mirza M, et al. Generative adversarial networks[J]. *Advances in Neural Information Processing Systems*, 2014, 3:2672-2680
- [15] Ratle F, Camps-Valls G, Weston J. Semisupervised neural networks for efficient hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2010, 48(5):2271-2282
- [16] Hoi S C H, Jin R, Zhu J, et al. Semisupervised SVM batch mode active learning with applications to image retrieval[J]. *ACM Transactions on Information Systems*, 2009, 27(3):1-29
- [17] Mu L, Tong Z, Chen Y, et al. Efficient mini-batch training for stochastic optimization[C]//ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, Kobe, Japan, 2014: 1488-1495
- [18] Ben-David S , Blitzer J , Crammer K , et al. A theory of learning from different domains[J]. *Machine Learning*, 2010, 79(1-2):151-175
- [19] Lecun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition[C]//Proceedings of the IEEE, Los Angeles, USA, 1998: 2278-2324
- [20] Hull J J. A database for handwritten text recognition research[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1994, 16(5) : 550-554
- [21] Netzer Y, Wang T, Coates A, et al. Reading digits in natural images with unsupervised feature learning[C]//NIPS Workshop on Deep Learning and Unsupervised Feature Learning, Los Angeles, USA, 2011: 1-9
- [22] Mao D. Improved canopy-kmeans algorithm based on MapReduce[J]. *Computer Engineering and Applications*, 2012(21):115-117
- [23] Huang S, Xu H, Xia X. Active deep belief networks for ship recognition based on BvSB[J]. *Optik-International Journal for Light and Electron Optics*, 2016, 127(24): 11688-11697
- [24] Tajbakhsh N, Shin J Y, Gurudu S R, et al. Convolutional neural networks for medical image analysis: full training or fine tuning? [J]. *IEEE Transactions on Medical Imaging*, 2016, 35(5):1299-1312

Research of semi-supervised domain adaptation based on active learning

Yao Minghai, Huang Zhancong

(College of Information Engineering, Zhejiang University of Technology, Hangzhou 310023)

Abstract

Traditional machine learning algorithms assume that the training data (source domain) and test data (target domain) obey the same distribution, but this assumption is often not true in practical applications. If the distribution of source domain and target domain is very different, the performance of the trained classifier will be reduced. In order to solve this problem, a semi-supervised domain adaptive method based on active learning is proposed. Firstly, an initial model is trained by using the number of source domains and target domain data, then the most representative samples are selected from the target domain for marking, and the existing models are trained again until the end point set in advance. Results of experiments on SVHN, MNIST and USPS datasets show that the proposed method can make the classifiers learned from source domain more suitable for target domain than the similar methods.

Key words: domain adaptation, active learning, neural network, image recognition