



计算机科学

COMPUTER SCIENCE

基于域自适应的肿瘤识别模型

田天祎, 孙福明

引用本文

田天祎, 孙福明. 基于域自适应的肿瘤识别模型[J]. 计算机科学, 2022, 49(12): 250-256.

TIAN Tian-yi, SUN Fu-ming. Tumor Recognition Method Based on Domain Adaptive Algorithm[J].

Computer Science, 2022, 49(12): 250-256.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

基于低开销可变形卷积的MobileNet再轻量化方法

Re-lightweight Method of MobileNet Based on Low-cost Deformable Convolution

计算机科学, 2022, 49(12): 312-318. <https://doi.org/10.11896/jsjcx.211200036>

PosNet:基于位置的因果关系抽取网络

PosNet:Position-based Causal Relation Extraction Network

计算机科学, 2022, 49(12): 305-311. <https://doi.org/10.11896/jsjcx.211100264>

标签约束图上的k步可达性查询

k-step Reachability Query Processing on Label-constrained Graph

计算机科学, 2022, 49(12): 283-292. <https://doi.org/10.11896/jsjcx.211000077>

基于高秩特征和位置注意力的RGBT目标跟踪

RGBT Object Tracking Based on High Rank Feature and Position Attention

计算机科学, 2022, 49(12): 236-243. <https://doi.org/10.11896/jsjcx.220600037>

面向深度卷积神经网络的小目标检测算法综述

Small Object Detection Based on Deep Convolutional Neural Networks:A Review

计算机科学, 2022, 49(12): 205-218. <https://doi.org/10.11896/jsjcx.220500260>

基于域自适应的肿瘤识别模型

田天祎 孙福明

大连民族大学信息与通信工程学院 辽宁 大连 116600

(499415709@qq.com)

摘要 关注人的生命健康,定期进行癌症筛查是一项极为重要的工作。针对肿瘤图像数据集数量较少且存在部分无标签的问题,提出了一种基于域自适应算法的肿瘤识别模型。其主干网络包括特征提取器、标签分类器和域判别器。其中,特征提取器对源域和目标域的特征进行提取,学习肿瘤特征;标签分类器对肿瘤图像进行分类输出;域判别器对数据特征的来源进行判定。标签分类器与域判别器博弈,获取源域和目标域的数据分布,直到二者在特征空间上的分布趋于一致,此时得到的分类器可对目标域的数据进行分类。在 BreakHis 数据集上的实验结果表明,所提算法的平均准确率达到 87.6%,与两种经典域自适应方法相比,其准确率分别提高了 16.2% 和 14.1%,并且在无标签的数据集上显示出了良好的性能。

关键词 域自适应;肿瘤识别;特征;标签;图像分类

中图分类号 TP391

Tumor Recognition Method Based on Domain Adaptive Algorithm

TIAN Tian-yi and SUN Fu-ming

School of Information and Communication Engineering, Dalian Minzu University, Dalian, Liaoning 116600, China

Abstract It is extremely important to focus on human life and health and to conduct regular cancer screening. A tumor recognition model based on domain adaptive algorithm is proposed to solve the problem of small number of tumor image data sets and some unlabeled ones. The structure of the backbone network is divided into three networks, feature extractor, domain discriminator and label classifier. The feature extractor extracts the features of source domain and target domain to learn tumor features. Label classifier is used to classify and output tumor images. The domain discriminator determines the source of data features. The label classifier plays a game with the domain discriminator to obtain the data distribution of the source domain and the target domain until the distribution of the source domain and the target domain tends to be consistent in the feature space. Then the classifier can classify the data of the target domain. Experimental results on BreakHis data set show that the average accuracy of the proposed model reaches 87.6%, which improves by 16.2% and 14.1% respectively compared with the two classical domain adaptive methods. The proposed method shows a good performance in the classification of unlabeled data sets.

Keywords Domain adaptation, Tumor recognition, Characteristics, Labels, Image classification

1 引言

近年来,社会经济繁荣发展,同时,人类生活环境逐渐恶化,罹患恶性肿瘤的人数越来越多。根据最新统计数据表明,全球每 5 人中就会有 1 人在一生之中罹患癌症,每 8 名男性和每 11 名女性之中,就有一人会因癌症去世,确诊罹患癌症后 5 年内仍然健在的人数为 5 060 万,癌症的负担在继续增加。目前,肿瘤图像分析是癌症诊断的基础,采用 X 射线、CT、磁共振、超声波等手段更具可靠性和准确性。由于癌细胞图像中包含了大量的干扰信息,人工诊断存在主观因素^[1],可能导致误诊,因此,需要一个准确的辅助诊断系统,协助医生对疾病及其病理原因做出判断并减少误诊。

随着深度学习的发展,辅助诊断系统也得到了很大程度

的发展,但仍存在挑战。早先用于处理肿瘤图像的方法均为传统的机器学习方法,如主成分分析、随机森林、支持向量机等。基于深度学习的肿瘤图像分类表现优异,Spanhol 等^[2]在对乳腺肿瘤病理图像数据集进行分类时不仅使用了卷积神经网络的模型,同时使用了其他技巧,即对图像的随机切分。此方法显著提高了分类准确率。除此之外,Bayramoglu 等^[3]在对乳腺肿瘤病理图像进行分类任务时,提出了处理不同倍数图像的方法,经过工作验证,该方法优于之前基于手工设计特征的方法。

为解决无标签数据的分类问题,研究者使用域自适应方法来降低训练样本和测试样本之间的分布差异^[4]。域自适应方法通过源域有类标签的样本和目标域无类标签的样例,来获得性能优良的目标域分类器,实现跨域的学习任务。域

到稿日期:2021-06-01 返修日期:2022-08-19

基金项目:国家自然科学基金(61976042)

This work was supported by the National Natural Science Foundation of China(61976042).

通信作者:孙福明(sunfuming@dlnu.edu.cn)

自适应方法中对数据分布的差异度量包含参数度量和非参数度量,一般采用最大化均值差异方法^[5]。Long 等^[6]在对 MMD 的特性进行深入研究后,实现了在多个网络层中提取可迁移特征的功能。与此同时,在分类器结构中加入了残差模块,该操作促进了域自适应方法的进一步发展。Long 等^[7]从生成对抗网络中获得灵感,在域对抗网络中设计与生成对抗网络类似的网络,即最小-最大化博弈机制;在此基础上设计域判别器,以判定域类别。不仅如此,研究者们还设计了特征提取器以提取域中的特征,并对特征进行学习,使特征提取器与域判别器互相博弈,混淆域判别器的判定,此方法在肿瘤识别分类任务上展现出了优势。

在此基础上,本文提出了一种基于域自适应的肿瘤识别模型,该模型可准确地对无标注的数据集进行分类,以解决肿瘤图像数据集数量较少且存在部分无标签的问题。本文设计的识别模型的识别过程为:1)进行域自适应训练,为使训练模型适合目标域,需要降低源域与目标域之间的分布差异,域自适应训练可以达到该要求;2)迁移模型,将训练完成的模型迁移至目标数据集以提高分类精度。

本文的主要贡献如下:

(1)设计了基于域自适应的识别模型,混淆源域和目标域的分布,解决了跨域迁移中特征分布差异与类别差异的问题。

(2)设计了特征提取器的结构,使结构能提取到图像中的最优特征。

本文方法在 Breakhis 数据集上与域自适应方法(Deep Domain Confusion, DDC^[8])和 DAN^[9](Deep Adaptation Networks)进行对比,准确率分别提高了 16.2% 和 14.1%,且在无标签的数据集上显示出了良好的性能。

2 相关工作

2.1 肿瘤识别

传统医学图像分类方法是基于特征工程的传统分类方法,主要分为两部分:提取医学图像数据的强鲁棒性特征以及选取分类能力强的分类器。在特征提取方面,通常使用全局特征(包括纹理、灰度等)或局部特征(包括尺度不变特征变换、方向梯度直方图等)来进行图像的描述。在分类器选择上,通常使用传统机器学习方法进行分类,但随着医学影像技术的不断发展,肿瘤诊断应用愈发深入,不同图像之间的纹理和组织结构均不相同,特征提取需要一定的经验,而特征提取的效果是决定分类性能的关键,但在多数情况下,很难找到具有鲁棒性的特征提取方式。

随着深度学习的兴起,研究人员提出基于深度学习的方法来进行肿瘤识别,其采用 Resnet50, Xception, InceptionV3 等网络来提取特征,随后采用前向神经网络进行分类,深度学习自动化的特征学习过程极大地节省了人们在特征提取工作上的时间和精力,并且极大地提升了分类性能。但在医学肿瘤图像领域中,仍面临着较多的困难。

(1)医学肿瘤图像数据库建设待完善。卷积神经网络对特征进行深度提取的根本在于存在大规模数据以供训练,反之,若数据较少,则会导致特征难以提取,在识别任务中效果不明显。相较于自然图像,肿瘤图像涉及个体隐私且数据量偏小,这就导致构建一个医学图像数据库非常困难。综上,

目前应解决的问题为建立完善的医学图像数据库与处理小样本数据集的划分问题。

(2)医学图像维度高。医学影像技术日趋成熟,当前阶段采集到的医学图像大部分为三维数据,但深度学习针对的对象为二维图像,其对三维图像的处理并不成熟,这为模型的训练带来了困难。

(3)医学图像清晰度不够。医学影像在形成图像时会因采集图像时所处人体位置的不同而受到不利影响,这导致生成的图像可能出现灰度范畴内不清晰的问题。图像存在问题时,将给实验中模型的训练增加难度,不仅如此,图像存在问题还会影响医生的判断。综上所述,模型训练的结果依赖于图像数据的清晰度。

(4)实际应用较少。眼下医学图像分类设计较广,但大部分探索仅停留在局限的工作室中,能够直接用于临床诊断的少之又少,因而在实际应用的方向上应继续努力。

综上所述,尽管医学肿瘤图像仍存在许多问题,但其未来发展潜力巨大。

2.2 域自适应

域自适应属于迁移学习的一种^[10],是迁移学习涵盖的子问题之一,主要研究如何将已标记的源域模型迁移至其他稀疏标记或未标记的目标域上,使域自适应被广泛应用于多种计算机视觉任务中。域自适应的目的是解决源样本和目标域样本之间存在分布差异的问题。域自适应方法根据源域数据和目标域数据的不同,可分为边缘分布自适应、条件分布自适应和联合分布自适应。不同数据分布的目标域的数据如图 1 所示。

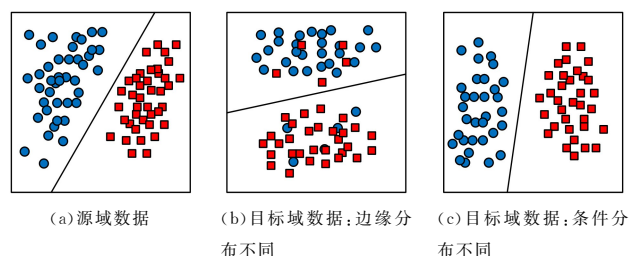


图 1 不同数据分布的目标域数据

Fig. 1 Target domain data with different data distributions

域自适应方法采用两个分支的体系结构来表示源域和目标域的模型,并结合其他的损失来处理域变化问题,如差异损失、重构损失和对抗性损失等。基于差异损失的方法度量源域和目标域对应的激活层的差异,例如 CORAL^[11]基于最后一个全连接层和最后一个卷积层的最大均值差异。基于重构的方法通过结合重构损失来最小化输入和重构输入之间的差异,例如 Ghifary 等^[11]设计了一个在多个输出层的多任务的自编码器,每个输出对应一个域。域自适应方法广泛采用基于生成对抗网络模型(Generative Adversarial Networks, GAN)。Bousmalis 等^[12]提出的模型利用 GAN 调整源域图像,使之看起来源于目标域,为了惩罚源域和生成图像在像素上的差异,提出了最小化源域图像和生成图像掩码像素的平均均方误差,并泛化到在训练阶段未出现过的对象上,模型将域自适应的过程从特定的任务框架中分离出来。Hoffman 等^[13]强调循环一致性损失,提出了像素级和特征级的域自适应。Zhu 等^[14]提出了循环一致对抗网络(CycleGAN),在

没有成对训练图像的情况下,通过一个反向的生成网络来迫使生成的目标域图像恢复成源域的图像,即经过一个循环能恢复输入的图像,使得生成的图像看起来源于目标域,但内容还是源域图像的内容。

2.3 生成对抗网络

生成对抗网络模型(GAN)是一种具有生成数据的模型,其在深度学习领域非常强大,自被 Goodfellow 等提出之后,受到了学术界和工业界的瞩目^[15]。其在各领域中的应用广泛,在自然语言、半监督学习中均可应用。生成式对抗网络的作用是生成数据,判定 GAN 是否合格的标准为生成数据的质量。

GAN 的模型受博弈论的影响,可将数据的生成看作网络之间的对抗,且对抗和博弈发生在判别器和生成器上。生成器合成数据的基础为噪声变量,噪声变量通过生成器后输出合成数据,判别器分辨数据的来源,其中数据来自生成器的输出数据和真实数据。前者尽自己最大努力生成与真实数据难辨真假的数据,后者尝试准确判定数据的分类,二者相互博弈,在对抗中进步,在进步后继续对抗,致使生成器输出的数据愈发真实,真假难辨。

在 GAN 模型中,生成式模型是可导的函数,判别式模型同理。将判别器设定为 D ,输出为 x ,参数为 θ_D ,生成器设定为 G ,输入为 z ,参数为 θ_G 。为了使生成式模型学习训练集的数据分布的能力足够出色,从而生成与训练集分布一致的数据,生成对抗网络的过程是首先使用随机噪声 $p_z(z)$ 作为经验,继而输入到生成器 G 中,随后投射入一个数据空间, $G(z; \theta_G)$ 代表经过生成器在空间中的特征映射。然后将生成器的特征映射 $G(z; \theta_G)$ 输入到判别器 D 中进行评价估计,判别器 $D(z; \theta_D)$ 表示数据 x 来自于真实数据(即训练集数据)而不是 $G(z; \theta_G)$ 的概率。训练过程中,生成网络 G 的目标就是生成接近训练集的图片骗过判别网络 D 。而 D 的目的是对 G 合成的假图和真实图像进行判定并划分类别。这个过程是一个最小最大博弈的问题,优化的目的是实现非合作博弈均衡,使生成器与判别器构成彼此的支配性策略,达到最优效果。

不同于其他算法,GAN 模型分为两个网络,即生成网络和判别网络。利用对抗网络可以得到生成的细胞图像,从而增加少量样本,提高对肿瘤细胞识别的能力。但由于在生成网络中输入的是随机噪声,生成的数据质量并不高,这限制了 GAN 在该课题中的应用。

基于此,本研究设计了基于域自适应算法的肿瘤识别模型。

3 详细方法

3.1 模型框架

在医学图像处理领域中,有诸多方式可以实现肿瘤图像的分类,并且数据集的种类繁多,这些数据集包含的图像各不相同,原因是用于采集的设备不同,除此之外,也受拍摄时间、拍摄角度的影响^[16]。基于这种情况,如果先对数据集进行训练得到分类模型,随后将该分类模型迁移至新数据集中,容易产生较大的效果损失;同时,迁移后的数据集将会受到标注问题的困扰^[17]。为了解决这一问题,本文提出了肿瘤识别模型,该模型的构建基于域自适应算法并借助了域判别器的作用,计算有标记的源域和没有标记的目标域分布,并设法

缩小二者的差异,将在源域中学习到的类别区分能力迁移至目标域。其框架结构如图 2 所示。

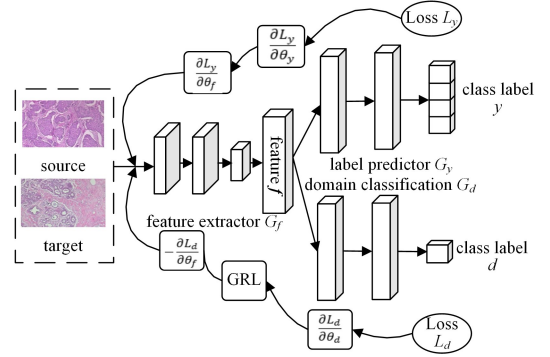


图 2 基于域自适应的肿瘤识别模型框架

Fig. 2 Tumor recognition model based on domain adaptation

该框架主要由 3 个模块构成,分别是特征提取器 $G_f(x; \theta_f)$ 、标签分类器 $G_y(G_f(x))$ 和域判别器 $G_d(G_f(x); \theta_d)$ 。特征提取器主要用于学习域不变特征,在辨别数据来源时,让判别器无法确定是源域还是目标域;标签分类器用于预测输入的医学肿瘤图像,并将获取到的结果进行输出;域判别器用于辨别数据特征的来源,确定其来自于源域或者目标域。

主要流程为输入图像 x , x 首先经过特征提取器 G_f ,属于源域的图像通过 G_f 得到源域的特征向量 f_s ,属于目标域的图像通过 G_f 得到目标域的特征向量 f ,随后映射到 D 维特征向量 $f \in R^D$,将特征向量输入到域判别器 G_d 中进行相关运算,获取对应的域标签 d ,从域标签中提取出判定结果,然后再利用梯度反转层完善结构,实现 G_f 的优化。此过程循环往复,即 G_f 与 G_d 互相博弈,从而获取源域与目标域的数据的分布,而循环的终点就是二者在特征空间上的分布朝着一致的方向逼近,直到无法判别。此时得到的分类器即优化好的分类器,可用它来对目标域中的数据进行分类。

分类损失函数与域损失函数分别定义为:

$$L_y^i(\theta_f, \theta_y) = L_y(G_y(G_f(x_i; \theta_f); \theta_y), y_i) \quad (1)$$

$$L_d^i(\theta_f, \theta_d) = L_d(G_d(G_f(x_i; \theta_f); \theta_d), d_i) \quad (2)$$

其中, $G_f(x; \theta_f) = f(Wx + b)$, $G_y(G_f(x; \theta_f); \theta_y) = \text{softmax}(VG_f(x) + c)$,在 softmax 函数的运算下, $G_y(G_f(x))$ 的每个分量表示神经网络将 x 分配给该分量表示的 Y 中的类的条件概率。给定一个源域样本 (x_i, y_i) ,这个样本的分类损失是:

$$L_y(G_y(G_f(x_i; \theta_f); \theta_y), y_i) = \log \frac{1}{G_y(G_f(x_i; \theta_f); \theta_y)_{y_i}} \quad (3)$$

对神经网络进行训练后,会出现以下优化问题,且此优化问题是在源域上出现的:

$$\min_{W, b, V, c} \left[\frac{1}{n} \sum_{i=1}^n L_y^i(W, b, V, c) + \lambda \cdot R(W, b) \right] \quad (4)$$

其中,

$$\begin{aligned} L_y^i(W, b, V, c) &= L_y(G_y(G_f(x_i; W, b); V, c), y_i) \\ &= L_y(G_y(G_f(x_i; \theta_f); \theta_y), y_i) \end{aligned} \quad (5)$$

且 $R(W, b)$ 是由超参数 λ 加权的正则化项。该方法的核心就是设计一个域正则化项。

由于本文研究的是肿瘤分类问题,且肿瘤分为良性与恶性两种,因此在源域和目标域上设计二分类的分类器 G_d ,对

于未知域的特征,其经过域判别器后的结果为:

$$G_d(G_f(x); u, z) = \text{sig } m(\mu^T G_f(x) + z) \quad (6)$$

因此,得到的最终的域分类的损失函数为:

$$L_d(G_d(G_f(x_i; \theta_f); \theta_d), d_i) = d_i \log \frac{1}{G_d(G_f(x_i))} + (1 - d_i) \log \frac{1}{1 - G_d(G_f(x_i))} \quad (6)$$

其中, d_i 为第 i 个样本中的二进制变量即域标签。对于源领域中的数据样本,在训练时已知其标签 $y_i \in \mathbf{Y}$, 而目标领域中的数据样本的标签在训练时并不知道,而任务即要对目标领域中的样本进行预测,因此在式(5)中加入域正则项,得到一个新的正则化项,表达式如下:

$$R(W, b) = \max_{u, z} \left[-\frac{1}{n} \sum_{i=1}^n L_d^i(W, b, u, z) - \frac{1}{n'} \sum_{i=n+1}^N L_d^i(W, b, u, z) \right] \quad (7)$$

其中, $L_d^i(W, b, u, z) = L_d(G_d(G_f(x_i; \theta_f); \theta_d), d_i)$, 需要使用一个超参数 λ 对训练过程中源领域中的分类损失和域判别的损失进行衡量比较。

因此,式(5)可以重新改写为:

$$\begin{aligned} E(\theta_f, \theta_y, \theta_d) &= E(W, V, b, c, u, z) \\ &= \frac{1}{n} \sum_{i=1}^n L_y^i(W, b, V, c) - \lambda \left(\frac{1}{n} \sum_{i=1}^n L_d^i(W, b, u, z) + \frac{1}{n'} \sum_{i=n+1}^N L_d^i(W, b, u, z) \right) \\ &= \frac{1}{n} \sum_{i=1}^n L_y^i(\theta_f, \theta_y) - \lambda \left(\frac{1}{n} \sum_{i=1}^n L_d^i(\theta_f, \theta_d) + \frac{1}{n'} \sum_{i=n+1}^N L_d^i(\theta_f, \theta_d) \right) \end{aligned} \quad (8)$$

本文设计了一种具有特征分布一致性的对抗网络,其目的在于在特征采集时能够学习到数据集域不变的特征,使域判别器难以分辨出自己判定的数据是来自源域的数据还是目标域的数据。因此,我们的目的是使分类器的损失最小、域判别器的损失最大,即:

$$(\hat{\theta}_f, \hat{\theta}_y) = \arg \min_{\theta_f, \theta_y} E(\theta_f, \theta_y, \hat{\theta}_d) \quad (9)$$

$$\hat{\theta}_d = \arg \min_{\theta_d} E(\hat{\theta}_f, \hat{\theta}_y, \theta_d) \quad (10)$$

其中, θ_d 为域判别器中的参数,它决定了域判别器是否能够对来自源域和目标域中的特征进行分辨; θ_y 为分类器中的参数,它决定了标签分类器在分类时是否能够将效率最大化; θ_f 为特征提取器的参数,它可以使特征提取器在满足域不变性的同时,最大化标签分类器的效率。

但在式(10)中, $E(\hat{\theta}_f, \hat{\theta}_y, \theta_d)$ 是一个求解最大值的问题,而在求解最大值的问题中不可以使用梯度下降法。为了使用梯度下降法,可以在过程中定义一个中间函数:

$$\begin{aligned} R(x) &= x \\ \frac{\partial R(x)}{\partial x} &= -I \end{aligned} \quad (11)$$

在前向传播时,式(11)不会产生任何作用;相反,在反向传播时,特征参数向前传递时,需要在原本值基础上乘以 $-I$, 因此 $R(x)$ 为梯度反转层。梯度反转层参数保持原样,无须更新,并且该方法可以推动预设目标的实现。

$$\theta_f \leftarrow \theta_f - \mu \left(\frac{\partial L_y}{\partial \theta_f} - \lambda \frac{\partial L_d}{\partial \theta_f} \right) \quad (12)$$

$$\theta_y \leftarrow \theta_y - \mu \frac{\partial L_y}{\partial \theta_y} \quad (13)$$

$$\theta_d \leftarrow \theta_d - \mu \lambda \frac{\partial L_d}{\partial \theta_d} \quad (14)$$

其中, μ 为学习速率。设置的梯度反转层可以保证源域与目标域上的特征分布是相近的,从而使得域判别器难辨真假。

3.2 网络优化过程

本方法的网络优化过程为:输入样本后,首先经过特征提取器,得到相应的特征向量 f , 随后将特征向量输入到域判别器中进行相关运算,得到相应的域标签 d 和域判别损失 L_d , 之后利用梯度反转层进行反向传播,对特征提取器进行优化,此过程循环往复,直至达到理想精度或最大迭代次数。网络优化过程如算法 1 所示。

算法 1 参数优化过程

输入:有少量标记的数据集作为源域 $S = \{(x_i, y_i)\}_{i=1}^n \sim (D_s)^n$, 进行

训练;无标记的数据集作为目标域 $T = \{x_i\}_{i=1}^n \sim (D_T)^n$

输出:优化好的特征提取器、域判别器域分类器参数

1. 权重参数随机初始化
2. while 最大迭代次数未达到 do
3. 选取数据
4. 获取特征向量 f
5. 获取分类器种类划分结果
6. 获取域判别器分类结果
7. 前向传播,获得域判别器的损失 L_d
8. 利用域判别器的损失进行反向传播,更新参数 θ_f 和 θ_y
9. L_d 和 L_f 互相博弈进行对抗训练,从而优化参数 $\theta_f, \theta_y, \theta_d$
10. End while
11. Return 优化后网络参数

3.3 特征提取器

在图像处理过程中一般采取卷积神经网络进行特征提取,基于肿瘤数据集的高维小样本的特性,决定了特征提取器无需太深,因此本课题自建特征提取器的结构,负责将处理后的数据映射到特征空间,进入分类判别过程。标签分类器负责将源域数据进行分类,域判别器与特征提取器完成互相博弈、网络优化的过程。

该特征提取器的结构为 8 层的卷积神经网络,由卷积层和池化层两种层次结构更替堆叠而成,其层数各占总深度的一半,卷积层分别命名为 $C1, C2, C3, C4$, 池化层分别为 $P1, P2, P3, P4$ 。卷积层的卷积核结构如下:前两层设定矩阵大小为 5×5 , 后两层设置为 3×3 , 矩阵步长均设置为 1, 激活函数采用的 ReLU 函数。池化层均采用最大池化法,步长都为 1, 前两个池化层采用 2×2 的, 其余两个采用 3×3 的。特征提取器的结构如图 3 所示。




图 3 特征提取器网络结构

Fig. 3 Network structure of feature extractor

3.4 梯度反转层

梯度反转层(Gradient Reversal Layer, GRL)的作用是让

特征提取器和域判别器实现对抗,从而不断减小源域和目标域在特征空间中的距离,让源域和目标域在特征空间中逼近,达到源域分类器可对目标域进行分类的目的。它主要应用于反向传播过程中,使域判别器的域判别损失的梯度在反向传播到特征提取器中的参数之前自动取反,进而实现类似 GAN 的对抗损失。GAN 中生成器负责生成以假乱真的样本,判别网络负责判别样本是真实的还是由生成器生成的,形成生成器与判别器的对抗训练。然而在迁移学习中存在源域和目标域,因此可省去生成样本的过程,直接将其中一个领域的数据(通常为源域)当作生成的样本。此时,生成器仅用于特征提取,不断学习领域数据的特征,使得判别器无法分辨两个领域。

若没有使用梯度反转层,特征提取器的优化目标是尽可能区分特征来自哪个域,域判别器的优化目标是尽可能区分特征提取出的特征是来自主域还是目标域,它们的优化目标相同。而加入梯度反转层后,特征提取器的优化目标就会与域判别器的优化目标相反,优化目标变成了尽可能无法判断特征来自于哪个域。

4 实验验证

4.1 数据集分析

BreakHis 数据集包含良性和恶性乳腺肿瘤的显微活检图像,提供了在多个缩放级别(40×,100×,200×,400×)下拍摄的约 8 000 张良性和恶性肿瘤图片。这些样本是从 82 个患者中采集到的,表 1 列出了数据集的具体分布情况,图像大小为 700×460 像素,模式为 RGB 三通道图像,源域采用胃上皮肿瘤细胞数据集。

表 1 BreakHis 数据集的具体分布

Table 1 Specific distribution of BreakHis dataset

Multiple	Benign/ Magnitude	Malignant/ Magnitude	Total/ frame
40×	625	1 370	1 995
100×	644	1 437	2 081
200×	623	1 390	2 013
400×	588	1 232	1 820
Patient Number	24	58	82

4.2 实验细节

实验采用 Pytorch 框架,在 NVIDIA GeForce 2080 Ti GPU(Ubuntu 18.04 系统)上进行训练和测试。实验过程中,特征提取器的基本结构为自建的卷积结构,图像生成器和域判别器选用 Cycle GAN 中的结构。Batch 大小设置为 8,最初的学习率设置为 0.001,epoch 的最大训练值设置为 500,域判别损失函数权重 λ 设置为 6。选取随机梯度下降法(Stochastic Gradient Descent,SGD)优化器进行模型训练。在整个实验过程中,源域为有标记的数据集,目标域为无标记的图像数据。

4.3 实验评价标准

本文方法的性能评价标准包括准确率(Accuracy)、精确率(Precision)、召回率(Recall)和 F1 分数(F1-score)、受试者工作特征(Receiver Operating Characteristic,ROC)曲线与曲线下面积(Area Under Curve,AUC)这 6 种。准确率、精确率、召回率和 F1-分数的运算准则如下:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (15)$$

$$Precision = \frac{TP}{TP + FP} \quad (16)$$

$$Recall = \frac{TP}{TP + FN} \quad (17)$$

$$F1-score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (18)$$

其中,TP 代表分类器预测为 true 的正样本;TN 代表分类器预测为 true 的负样本;FP 表示分类器预测为 false 的正样本;FN 代表为分类器预测为 false 的负样本;Accuracy 是指分类器预测为 true 的样本占有所有样本的比例;Precision 代表分类器预测为正类的样本中真正的正样本所占的比例,也称查准率;Recall 表示真正的正样本中被分类器预测正确的比例,该指标衡量了实际正类样本的覆盖率并反映了预测正确的病例,也称召回率;F1-score 表示 Precision 和 Recall 两个指标的调和平均值。

4.4 实验结果

为了验证肿瘤细胞图像的分类能力,在 BreakHis 数据集的 4 种倍数下分别进行性能测试。实验结果如表 2 所列。

表 2 肿瘤识别模型在 BreakHis 数据集上的分类结果

Table 2 Classification results of tumor recognition model on BreakHis dataset

Multiple	Accuracy	Precision	Recall	F1-score
40×	85.3	86.7	85.1	86.0
100×	88.8	88.7	87.3	88.2
200×	88.6	89.3	86.4	87.6
400×	87.8	88.6	86.3	87.8
Average	87.6	88.3	86.3	87.4

(单位:%)

在已有的对肿瘤进行识别分类的工作中,绝大部分分类以二分类为主,即分为良性和恶性两种。有少部分工作在肿瘤识别分类的工作中将其作为多分类任务。本实验是基于 BreakHis 数据集进行的二分类实验,此前 AlexNet 在基于 BreakHis 不同放大倍数下的实验达到了接近 90% 的平均准确率。

除了平均准确率之外,本文还从其他方面对所提方法进行了效果展示,包括网络层的特征图可视化、ROC 曲线、训练和测试损失曲线图、准确率变化曲线图、混淆矩阵 5 项。

(1) 特征图可视化

在整个模型的流程中,第一步为特征提取,这一步非常重要,本文采用了自建的网络对特征进行学习。为体现该网络的提取特征的性能,我们对提取的特征进行了可视化的操作。图 4 给出了部分特征图,从特征图可以看出由自建的网络提取到的特征图边缘较为平滑且特征突出,便于对图像进行下一步的操作。




图 4 肿瘤图像特征可视化

Fig. 4 Tumor image characteristics visualization

(2) ROC 曲线

为进一步验证模型的有效性,采用 ROC 曲线对方法中的分类器性能进行验证,如图 5 所示,ROC 曲线展示了本文方法在数据集的不同倍数下得到的分类效果,可知该模型在 4 个倍数的数据集的训练中的 AUC 值均达到了 0.80,证明所提模型对肿瘤图像有一定的预测价值。

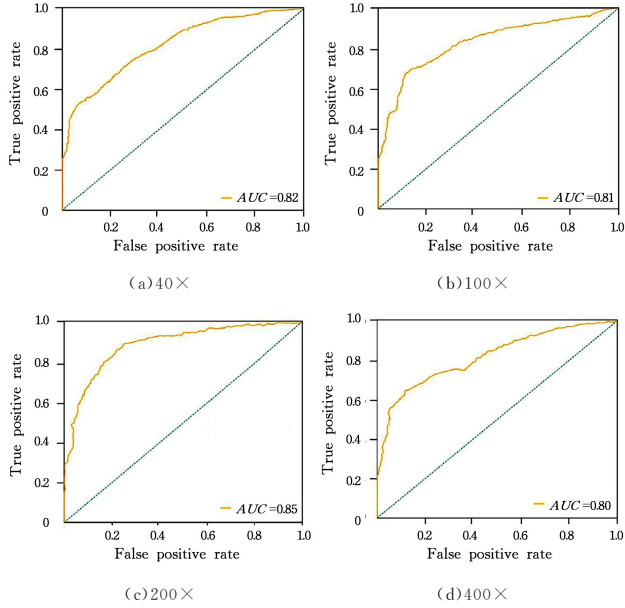


图 5 不同倍数的 ROC 曲线

Fig. 5 ROC curve with different multiples

(3) 损失变化与准确率变化

选择 BreakHis 中的 100x 的图像数据,对迭代过程中的损失变化和准确率变化进行展示,如图 6 所示。

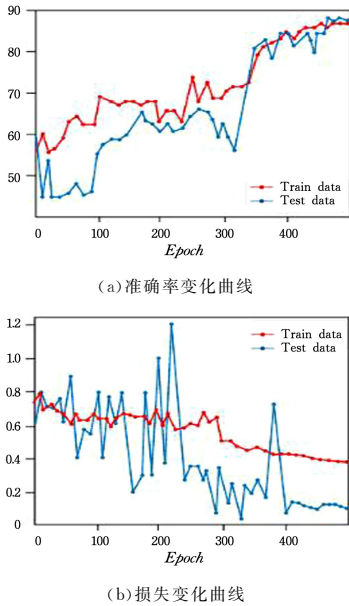


图 6 肿瘤识别模型在训练集和测试集上的损失变化和准确率变化曲线图

Fig. 6 Loss change and accuracy curve of tumor recognition model in training set and test set

从图 6 中可看出,在迭代过程中,最初损失变化曲线下降速度较快,这表明选取了合适的学习率。并且在准确率变化

曲线中可看到,在训练阶段的准确率变化曲线上升较快,而到了训练即将结束的阶段,准确率的变化曲线均趋于平稳。

(4) 混淆矩阵

混淆矩阵可以对分类结果进行直观展示,可以明确地看出数据的正确与错误分类,图 7 中的元素代表样本个数,分别为真实样本的个数和预测样本的个数,其中标签 CLASS0 表示恶性肿瘤类,CLASS1 表示良性肿瘤类,由混淆矩阵可得,本文模型对恶性肿瘤的分类比其他类更准确。




图 7 分类结果混淆矩阵

Fig. 7 Confusion matrix of classification results

从图 7 中可明显地看出该方法将恶性肿瘤分类错误的个数少于将良性肿瘤分类错误的个数,凭借这一特点,该方法可以被广泛应用于临床应用中,能够有效提高癌症检验的成功率。

4.5 不同算法性能对比分析

本文提出的肿瘤识别模型主要分为两部分:分类器和判别器。因此,本文使用 100x 放大倍数的数据集与不添加判别器的结构模型进行对比实验,以验证判别器模块对实验的贡献;并与先前的研究工作进行了对比实验,以验证该方法的有效性。表中的 SLY 表示仅用源域训练出的网络对目标域的数据进行分类,即没有添加域判别器的结构;DDC^[8]表示在分类器前加入了域适应层,用于单独判定域判别器的能力;DAN^[9]表示多层适配和多核 MMD 的结构;Ours 为本文提出的方法。实验结果如表 3 所列。各方法准确率的变化对比如图 8 所示。

表 3 对比实验结果

Table 3 Comparative experimental results

(单位:%)

Method	Accuracy	Precision	Recall	F1-score
SLY	67.6	69.7	66.5	67.1
DDC	71.4	72.0	69.6	72.2
DAN	73.5	76.1	72.0	74.3
Ours	87.6	88.0	86.2	87.0




图 8 各方法的准确率变化曲线

Fig. 8 Accuracy curve of each method

为了更直观地比较各种方法对肿瘤的识别分类能力,可

以将这几种方法的 ROC 曲线画到同一 ROC 空间中,这样可以更清晰地鉴别各方法的优劣。所用数据集仍为 BreakHis 中的 100×100 图像,如图 9 所示。由图中可以看出,本文方法在肿瘤识别的诊断上性能更好,而没有添加域判别器的方法用于诊断肿瘤的性能最差。




图 9 各方法 ROC 对比曲线图

Fig. 9 ROC comparison curve of each method

结束语 本文基于域自适应方法,设计了肿瘤识别的模型。通过跨域损失约束将提取到的数据特征映射到一个跨域特征空间中,进而降低源域和目标域之间的特征分布差异,之后在训练过程中通过分类器和域判别器的相互博弈,学习到适合目标域的分类器,从而达到了较好的分类效果。尽管本文提出的方法取得了一些不错的阶段性进展,但在实际生活中,医学肿瘤图像的分类任务依然存在多个挑战,主要表现在以下两个方面。

(1) 样本噪声问题

在基于域自适应的肿瘤识别模型中,尽管可以学习到有关源域和目标域特征匹配的方法,但由于医学图像的关键信息区域较小,会存在样本噪声的问题,这些样本噪声会影响到特征空间的鲁棒性。在接下来的工作中,将考虑在模型中引入注意力机制,以提高提取特征的能力。

(2) 负迁移问题

本文主要研究正迁移的情况,选取的数据集均为医学肿瘤数据,存在一定的相似性,但当源域数据和目标域数据无联系时,就会发生负迁移的问题,接下来的工作将尝试解决此问题。

参考文献

- [1] ZHENG G Y, LIU X B, HAN G H. Review of computer-aided detection and diagnosis systems for medical imaging[J]. Journal of Software, 2018, 29(5): 1471-1514.
- [2] SPANHOL F A, OLIVEIRA L S, PETITJEAN C, et al. Breast cancer histopathological image classification using convolutional neural networks[C]// International Joint Conference on Neural Networks. 2016: 2560-2567.
- [3] BAYRAMOGLU N, KANNALA J, HEIKKILÄ J. Deep learning for magnification independent breast cancer histopathology image classification[C]// International Conference on Pattern Recognition. 2016: 2440-2445.
- [4] FARAHANI A, VOGHOEI S, RASHEED K, et al. A Brief Review of Domain Adaptation [J]. arXiv: 2010. 03978, 2020.
- [5] LONG M S. Transfer Learning Problems and Methods [D]. Beijing: Tsinghua University, 2014.
- [6] LONG M S, ZHU H, WANG J, et al. Deep Transfer Learning

with Joint Adaptation Networks [C]// International Conference on Machine Learning. 2017: 2208-2217.

- [7] ZHANG Y, LIU T, LONG M, et al. Bridging Theory and Algorithm for Domain Adaptation[C]// International Conference on Machine Learning. 2019: 7404-7413.
- [8] TZENG E, HOFFMAN J, ZHANG N, et al. Deep Domain Confusion: Maximizing for Domain Invariance [J]. arXiv: 1412. 3474, 2014.
- [9] LONG M, CAO Y, WANG J, et al. Learning Transferable Features with Deep Adaptation Networks [C]// International Conference on Machine Learning. 2015: 97-105.
- [10] ZHUO J, WANG S, ZHANG W, et al. Deep Unsupervised Convolutional Domain Adaptation [C]// Proceedings of the 25th ACM International Conference on Multimedia. 2017: 261-269.
- [11] GHIFARY M, KLEIJN W B, ZHANG M, et al. Domain Generalization for Object Recognition with Multi-task Autoencoders [C]// Proceedings of the IEEE International Conference on Computer Vision. 2015: 2551-2559.
- [12] BOUSMALIS K, SILBERMAN N, DOHAN D, et al. Unsupervised Pixel-Level Domain Adaptation With Generative Adversarial Networks [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2017: 3722-3731.
- [13] HOFFMAN J, TZENG E, PARK T, et al. Cycada: Cycle-consistent adversarial domain adaptation [C]// International Conference on Machine Learning. 2018: 1989-1998.
- [14] ZHU J Y, PARK T, ISOLA P, et al. Unpaired Image-To-Image Translation Using Cycle-Consistent Adversarial Networks [C]// Proceedings of the IEEE International Conference on Computer Vision. 2017: 2223-2232.
- [15] YUE X, ZHENG W, ZHANG S, et al. Prototypical cross-domain self-supervised learning for few-shot unsupervised domain adaptation [C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2021: 13834-13844.
- [16] GUAN H, LIU M. Domain Adaptation for Medical Image Analysis: A Survey [J]. IEEE Transactions on Biomedical Engineering, 2022, 69(3): 1173-1185.
- [17] ZHANG Y, TANG H, JIA H, et al. Domain-Symmetric Networks for Adversarial Domain Adaptation [C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2019: 5031-5040.



TIAN Tian-yi, born in 1996, postgraduate. Her main research interests include transfer learning and machine learning.



SUN Fu-ming, born in 1972, Ph.D., professor, Ph.D supervisor, is a member of China Computer Federation. His main research interests include content-based image retrieval, image content analysis and pattern recognition.