

DOI:10.16136/j.joel.2022.07.0734

# 基于半监督生成对抗网络的乳腺癌图像分类

宣 萌, 刘 坤\*

(上海海事大学 信息工程学院, 上海 201306)

**摘要:**本文针对仅有少量带标签样本时如何提高大量未标注样本分类的鲁棒性和准确性问题,提出一种基于改进的半监督生成对抗网络(semi-supervised generative adversarial networks, SGAN)的乳腺癌图像分类方法。该方法在输出层使用 Softmax 函数替代 Sigmoid 函数实现多分类。首先将随机向量输入到生成网络中,生成伪样本并标记为伪样本类进行训练。接着将真实标签样本、真实无标签样本和伪样本输入到判别网络中,输出为不同类概率值;然后采用半监督训练方法反向传播更新参数;最后实现对乳腺癌病理图像的分类,标注样本数量分别为 25、50、100 和 200,最终准确率达到 95.5%。实验结果表明,当标注样本有限时,本文算法的准确率具有良好的鲁棒性。本文算法相比于使用卷积神经网络和迁移学习(transfer learning, TL)等分类方法准确率有了显著提高。

**关键词:**半监督生成对抗网络;数据增强;注意力机制;批归一化处理;图像分类  
**中图分类号:**TP391.41 **文献标识码:**A **文章编号:**1005-0086(2022)07-0770-08

## Breast cancer image classification based on semi-supervised generative adversarial networks

XUAN Meng, LIU Kun\*

(College of Information Engineering, Shanghai Maritime University, Shanghai 201306, China)

**Abstract:** In this paper, aiming at the robustness and accuracy of classifying a large number of unlabeled samples with only a small number of labeled samples, we propose an improved semi-supervised generative adversarial networks (SGAN) method for breast cancer image classification. This method uses Softmax function instead of Sigmoid function to realize multi-classification in the output layer. Firstly, the random vector is input into the generation network to generate pseudo samples and be labeled as pseudo sample class for training. Then the real labeled samples, real unlabeled samples and pseudo samples are input into the discrimination network and output as different kinds of probability values. Then the semi-supervised training method is used to update the parameters by back propagation. Finally, the classification of breast cancer pathological images is realized. The number of labeled samples is 25, 50, 100 and 200 respectively. The final accuracy rate is 95.5%. The experimental results show that the accuracy rate of this algorithm has good robustness when the labeled samples are limited. Compared with the classification methods such as convolution neural networks and transfer learning (TL), the accuracy of this algorithm is significantly improved.

**Key words:** semi-supervised generative adversarial networks (SGAN); data augmentation (DA); attention mechanism (AM); batch normalization processing; image classification

## 1 引言

如何利用计算机辅助诊断系统进行医学图像

自动分类、识别等是目前研究的热点问题。计算机辅助诊断主要有两类方法:一类是基于人工特征提取并结合传统机器学习的方法,另一类是基

\* E-mail: kunliu@shmtu.edu.cn

收稿日期:2021-10-26 修订日期:2021-12-17

基金项目:航空科学基金(AFSC-20195501001)资助项目

于深度学习的方法。SPANHOL等<sup>[1]</sup>在公开的乳腺癌数据集上,利用局部二值模式、邻接阈值统计等6种人工特征提取方法进行特征提取,并采用决策树、支持向量机(support vector machanism, SVM)在内的4种传统分类方法进行分类,最终识别率达到了80%—85%。人工特征提取前期需要耗费人力去提取图像特征且在提取的过程中也存在人为误差。近年来,随着计算机技术和计算机视觉等的快速发展,基于深度学习的医学图像处理算法取得了显著成果。ARAUJO等<sup>[2]</sup>利用卷积神经网络模型对乳腺癌病理图像进行分类,最终识别率达到了85%。ZHOU等<sup>[3]</sup>提出一种基于特征映射的迁移学习(transfer learning, TL)方法对肺部X光图像进行分类,最终平均识别率达到了89.3%。何雪英等<sup>[4]</sup>利用TL模型对乳腺癌数据集进行分类,数据集经过数据增强(data augmentation, DA)后准确率最高可达91%。KHAN等<sup>[5]</sup>使用自然图像和部分医学图像作为源数据进行卷积神经网络模型预训练,并使用3种预训练模型用于乳腺癌细胞分类任务,迁移后模型的分类准确性可达94.5%。然而利用卷积神经网络等深度学习方法进行医学图像分类时,需要大量带标签的训练样本,受到隐私权、医疗行业标准以及医疗设备等各方面的限制,大量带标签的医学图像样本很难获取。目前在乳腺癌临床诊断阶段,广泛使用的方法是对病理图像进行组织病理学分析,对病理图像进行标注分析时需要多名医学专家共同诊断得出结论,该方法耗时耗力且存在人为因素的影响<sup>[6]</sup>。利用计算机辅助诊断系统可以协助医生提高诊断效率。

生成对抗网络(generative adversarial networks, GAN)由Goodfellow于2014年首次提出,借助从无标签样本中学习到的样本内在联系,来提高分类器在包含少量标签信息情况下的学习能力,从而获得更高的分类准确率。自此大量研究人员的眼光开始聚焦于此。李莉等<sup>[7]</sup>结合GAN和半监督模糊C均值聚类方法对肺结节图像进行分类,最终识别率达到了90.96%。欧莉莉等<sup>[8]</sup>提出一种基于GAN的脑梗死图像分类方法,在生成网络中使用特征匹配损失代替传统的交叉熵损失,使生成器生成与真实图像特征分布一致的伪图像,最终识别率达到了95.05%。

基于此,针对少量标签样本及多分类问题,本文提出一种基于半监督生成对抗网络(semi-supervised GAN, SGAN)的乳腺癌图像多分类方法。首先,该方法将输出层二分类Sigmoid函数换成多分类Softmax函数。然后生成器和判别器使用卷

积神经网络代替并在相关特征层后加入注意力机制(attention mechanism, AM)模块,以便用于图像关键特征提取<sup>[9]</sup>;最后使用半监督训练方法训练模型。实验结果表明,通过对比不同模型在该数据集上的实验结果,证明该模型具有良好的鲁棒性。该方法不仅可应用于乳腺癌图像分类,还可应用于宫颈癌等医学图像分类。

## 2 基于SGAN的乳腺图像分类模型

GAN是一种常见的深度学习模型,它的思想来源于博弈论中的“二人零和博弈”<sup>[10]</sup>。GAN由两部分组成。一个是生成器 $G$ ,输入随机向量 $z$ ,输出生成样本 $G(z)$ 。生成器的目标是使生成的伪样本与数据集中的真实数据的特征分布无法区分;另一个是判别器 $D$ ,输入有来自数据集的真实样本 $x$ 和生成器生成的伪样本 $G(z)$ ,输出为预测输入样本真实的概率是多少。判别器的目标是准确判别出哪些是来自数据集的真实样本,哪些是来自生成器生成的伪样本。训练时经过不断的迭代优化,反向传播更新参数。其损失函数为:

$$\min_G \max_D V(D, G) = E_{x \sim P_{\text{data}}(x)} [\log_2 D(x)] + E_{z \sim P_z(z)} [\log_2 (1 - D(G(z)))], \quad (1)$$

式中, $x \sim P_{\text{data}}(x)$ 表示真实数据 $x$ 服从分布 $P_{\text{data}}(x)$ , $z \sim P_z(z)$ 表示随机向量 $z$ 服从分布 $P_z(z)$ , $D(x)$ 和 $D(G(z))$ 分别表示真实数据 $x$ 和生成数据 $G(z)$ 判别为真的概率。

常见的生成器和判别器由全连接神经网络构成,为了自动提取乳腺癌病理图像深层的特征信息,借鉴深度卷积生成对抗网络(deep convolutional GAN, DCGAN)模型,将有监督学习的卷积神经网络与无监督学习的生成对抗网络结合。在DCGAN模型中有以下几个特点<sup>[11]</sup>:

- 1) 使用带步幅卷积替代池化层。
- 2) 删除网络中的全连接层,直接使用卷积网络连接输入和输出。
- 3) 在生成器和判别器中使用批归一化处理<sup>[12]</sup>,避免出现模型崩溃。

4) 在生成器输出层使用Tanh激活函数,其他层使用Relu激活函数;在判别器输出层使用Sigmoid激活函数,其他层使用Leaky Relu激活函数。

DCGAN常用于图像生成和二分类问题,SGAN模型将输出层判断真实样本和伪样本的二分类Sigmoid函数使用判别真实标签多分类的Softmax函数替代,使得GAN不仅具备生成和判别真假的能力,

还具备多分类的能力。SGAN 模型中判别器的输入除了无标签样本  $x$  和生成样本  $G(z)$ , 还有带标签样本  $(x, y)$  指导训练,  $y$  表示真实样本的标签。假设对于一个  $N$  分类的问题, 将生成器生成的伪样本标记为  $N+1$  类, 最后经过 Softmax 函数输出的结果由  $N$  维扩展至  $N+1$  维, 即  $y \in (1, 2, 3, \dots, N, N+1)$ 。故基于 SGAN 的乳腺癌图像分类模型结构如图 1 所示。

SGAN 在训练时采用半监督训练方法, 通过不断的迭代优化, 反向传播更新参数。它的损失函数包括无监督损失和有监督损失。SGAN 模型训练过程如图 2 所示。

数据集各类特征之间差异明显, 经过卷积层特

征提取之后, 为了进一步锁定图像关键局部特征, 减少分类中无关信息的干扰, 在判别器第 2 层和第 3 层特征层后引入 AM 模块。

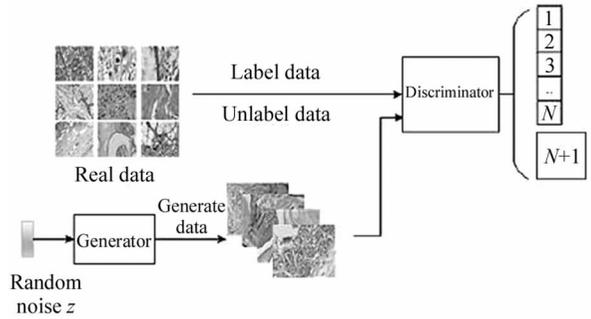


图 1 SGAN 模型  
Fig. 1 SGAN model

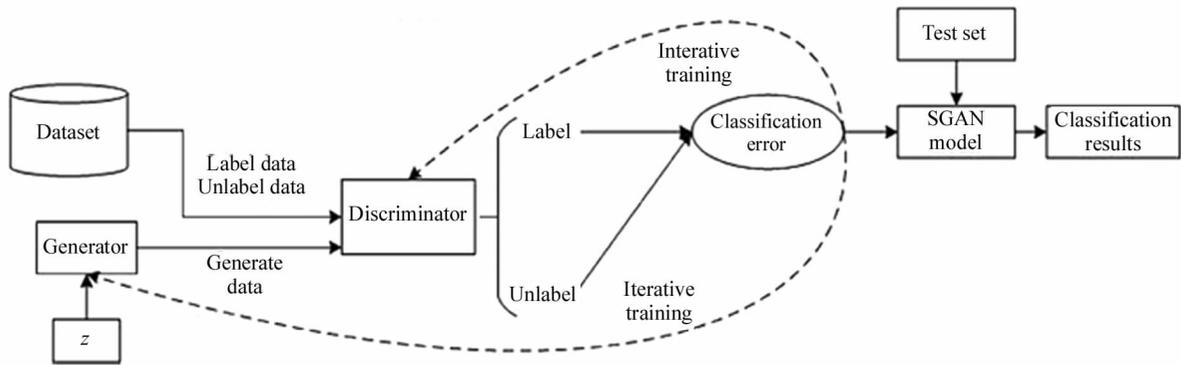


图 2 SGAN 模型训练过程  
Fig. 2 SGAN model training process

### 2.1 生成器

将 1 个 100 维的随机噪声向量  $z$  输入到生成器中, 通过 Reshape 改变输入为  $16 \times 16 \times 256$  的 3 维张量。经过 3 层转置卷积进行上采样, 卷积核的大小为  $3 \times 3$ , 步长为 2, 每一层转置卷积使用填充操作和批归一化处理。输出层使用 Tanh 激活函数, 转置卷积层使用 Relu 激活函数。3 次转置卷积后, 最后输出为  $128 \times 128 \times 3$  的张量, 即为生成的伪样本。SGAN 模型生成器结构如图 3 所示。

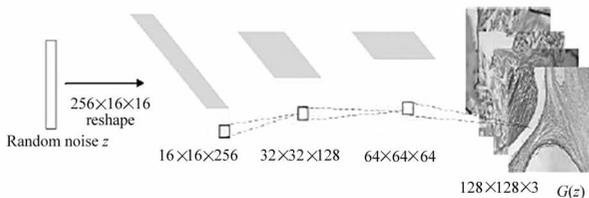


图 3 SGAN 生成器  
Fig. 3 SGAN generator

### 2.2 判别器

在判别器中, 使用 4 层卷积层和 1 层全连接层。

首先将有标签样本、无标签样本和生成器生成的伪样本图像输入到判别器中, 经过卷积层进行特征提取, 卷积层中卷积核大小为  $3 \times 3$ , 每个卷积网络的步长为 2, 使用填充操作。不同卷积层卷积核数目不同。每一层卷积层后使用批归一化处理, 激活函数为 Leaky Relu, 它在负半轴的斜率  $\alpha$  设为 0.01。

考虑到实验所用的卷积神经网络的深度, 本文选用了即插即用的卷积 AM<sup>[13]</sup>。该模型包括通道注意力模块(channel attention mechanism, CAM)和空间注意力模块(spatial attention mechanism, SAM)两部分。CAM 首先使用全局最大池化和全局平均池化对输入的特征  $F$  进行压缩, 得到 2 个不同的特征, 并利用多层感知器组成的共享网络进行相加计算后经过 Sigmoid 激活函数得到权重系数  $M_c(F')$ , 最后将  $M_c(F')$  与  $F$  相乘输出特征  $F'$ 。与 CAM 不同, SAM 主要关注位置信息。首先对  $F'$  进行全局最大池化和全局平均池化操作得到 2 个不同的特征, 接着将 2 个特征拼接并使用卷积操作, 经过 Sigmoid 函数得到权重系数  $M_s(F')$ , 最后将  $M_s(F')$  与  $F'$  相

乘,得到输出特征  $F''$ 。综合两部分的特征信息,引入残差<sup>[14]</sup>的思想,将输入特征  $F$  与输出特征  $F''$  相加进行特征融合,从而得到更可靠的特征信息。改进的

卷积 AM 结构如图 4 所示。

经过 4 层卷积层后进行 Flatten 操作,展平特征参数。然后使用随机丢弃部分信息(Dropout),可减

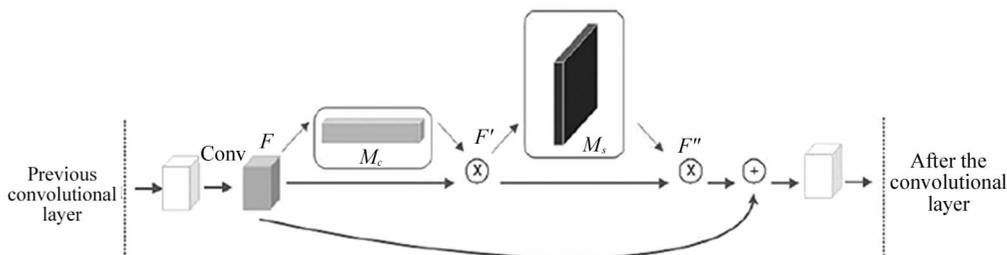


图 4 改进卷积 AM

Fig. 4 Improved convolutional block AM

少过拟合现象,随机失活率设为 0.5。为了加快收敛速度,最后经过一层全连接层,激活函数为 Softmax,输出  $N+1$  个类别概率值。判别器结构如图 5 所示。

类损失更新参数,使损失越小越好。

#### 4) 训练判别器(无监督)

固定生成器  $G$ ,随机取批量无标签的真实样本  $x$ ,计算给定批量的  $D(x)$  并反向传播二分类损失更新参数,以使损失越小越好。随机取批量的随机噪声  $z$  生成的伪样本  $G(z)$ ,计算给定批量的  $D(G(z))$  并反向传播二元分类损失更新参数,使损失越小越好。

#### 5) 训练生成器

固定判别器  $D$ ,将随机噪声输入生成器  $G$ ,得到伪样本  $G(z)$ 。随机取批量的随机噪声  $z$  生成的伪样本  $G(z)$ ,计算给定批量的  $D(G(z))$  并反向传播二分类损失更新参数,使损失越大越好。

6) 重复上述 1—5 的步骤,直到设置的迭代次数结束。

7) 将测试集应用到该模型上,输出图像的分类。

### 3.1 数据预处理

本实验所用的数据集是 2016 年 SPANHOL 等<sup>[1]</sup>公开的 Breakhis 数据集,该数据集包含 24 名良性乳腺肿瘤患者共 2480 张显微活检图像和 58 名恶性乳腺肿瘤患者共 5429 张显微活检图像。图像的大小为 700 pixel×460 pixel,格式为“png”的彩色图像。良性包含腺病(adenosis)、纤维腺瘤(fibroadenoma)、叶状肿瘤(phylloid tumor)和肾小管腺瘤(tubular adenoma)4 种。恶性包含导管癌(ductal carcinoma)、小叶癌(lobular carcinoma)、粘液癌(mucinous carcinoma)和乳头状癌(papillary carcinoma)4 种。一共有 8 种类型。如图 6 所示。每一种类型下有 40×、100×、200×和 400×共 4 种放大倍数。

首先每类选取 150 张乳腺肿瘤图像作为训练集,50 张乳腺肿瘤图像作为测试集,剩余所有图像归

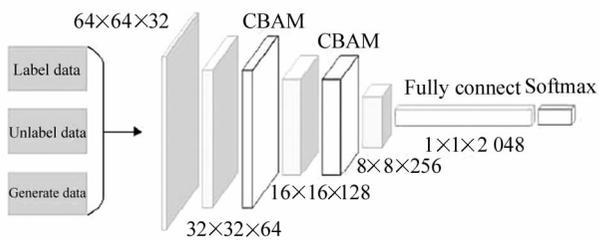


图 5 SGAN 判别器

Fig. 5 SGAN discriminator

## 3 基于 SGAN 的乳腺癌图像分类

基于上述网络模型结构,针对乳腺癌图像分类任务中有标签样本有限的问题,提出一种 SGAN 模型的半监督学习方法来实现乳腺癌病理图像分类。首先对数据进行预处理,接着将随机噪声  $z$  输入到判别器中上采样成伪样本后与真实样本一起输入到判别器中,然后通过有监督损失和无监督损失共同训练来实现对网络参数的更新,最后使用测试集对模型进行测试,最终使分类的准确率得到提高和具有良好的鲁棒性。训练步骤如下:

1) 将随机噪声向量  $z$  输入到生成器中,生成伪样本  $G(z)$ 。

2) 将有标签和无标签的真实样本以及生成的伪样本输入到判别器中,通过 Softmax 函数输出每一类的概率。

#### 3) 训练判别器(有监督)

固定生成器  $G$ ,随机取批量有标签的真实样本  $(x, y)$ 。计算给定批量的  $D(x, y)$  并反向传播多分

为无标签类。将图像大小统一压缩为 128 pixel × 128 pixel, 确保每张图像的大小一致。随后对原始图像(original image)进行 DA<sup>[15]</sup>, 包括随机裁剪(random clipping), 中心裁剪(center clipping), 水平翻转(flip horizontally), 30°旋转(30°), 60°旋转(60°)。将 DA 后的图像加到数据集内。DA 使数据得到扩充, 避免由于数据量过少而产生过拟合现象, 提高模型的泛化能力。最后将数据样本进行归一化, 映射到 [-1, 1], 加快模型的收敛速度。DA 的效果如图 7 所示。

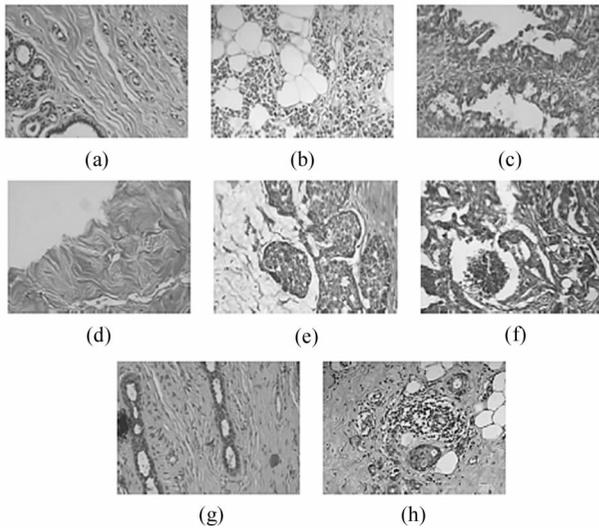


图 6 数据集:(a) 腺病;(b) 导管癌;(c) 纤维腺瘤;  
(d) 小叶癌;(e) 粘液癌;(f) 乳头状癌;  
(g) 叶状肿瘤;(h) 肾小管腺瘤

Fig. 6 Dataset:(a) Adenosis;(b) Ductal carcinoma;  
(c) Fibroadenoma;(d) Lobular carcinoma;  
(e) Mucinous carcinoma;(f) Papillary carcinoma;  
(g) Phylloid tumor;(h) Tubular adenoma

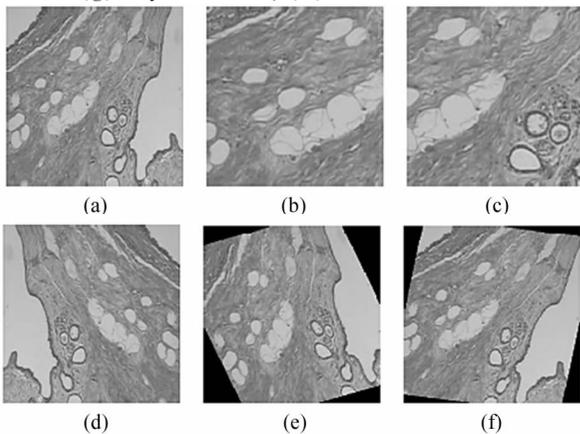


图 7 DA 效果:(a) 原始图像;(b) 随机裁剪;

(c) 中心裁剪;(d) 水平翻转;(e) 30°旋转;(f) 60°旋转

Fig. 7 Effect of DA:(a) Original image;

(b) Random clipping;(c) Center clipping;

(d) Flip horizontally;(e) 30° rotation;(f) 60° rotation

### 3.2 SGAN 训练模型

在 SGAN 模型中, 对  $N=8$  类乳腺癌病理图像进行分类。将生成器生成的伪样本添加到真实数据中, 并标记为第  $N+1=9$  类, 将有标签真实样本和无标签真实样本与生成的伪样本作为判别器的输入, 输出一个 9 维的逻辑向量  $l_i (i=1, 2, 3, \dots, 9)$ , 通过 Softmax 函数得到归一化概率为:

$$P_{\text{model}}(y = i | x) = \frac{\exp(l_i)}{\sum_{j=1}^{N+1} \exp(l_j)}, \quad (2)$$

式中,  $P_{\text{model}}(y = i | x)$  表示输出的归一化概率值,  $i = 1, 2, \dots, 9$ , 哪一类值最大表示判别为该类别。

训练模型的过程其实就是优化损失函数的过程, SGAN 模型中损失函数包括有监督损失和无监督损失, 其中无监督损失包括无标签真实样本损失和生成样本损失。

有标签样本, 其损失为真实类标签和预测类标签的交叉熵损失。

$$L_{\text{label}} = -E_{x, y \sim \text{data}} [\log_2 P_{\text{model}}(y | x, y < N + 1)]. \quad (3)$$

无标签样本, 其损失是无标签样本判断为“真”的损失, 此时的  $y \neq N + 1$ 。

$$L_{\text{unlabel}} = -E_{x \sim \text{data}} [\log_2 (1 - P_{\text{model}}(y = N + 1 | x))]. \quad (4)$$

生成样本, 其损失是将生成的伪样本判断为“假”的损失, 此时  $y = N + 1$ 。

$$L_{\text{generate}} = -E_{x \sim G} [\log_2 P_{\text{model}}(y = N + 1 | x)], \quad (5)$$

式中,  $x$  为样本,  $y$  为标签,  $x \sim \text{data}$  表示  $x$  是真实样本中的无标签数据,  $x, y \sim \text{data}$  表示带有标签  $y$  的真实样本,  $x \sim G$  表示  $x$  为生成器生成的伪样本,  $P_{\text{model}}(\cdot | \cdot)$  表示判别每一类的概率。

对于判别器来说, 希望上述的各个损失越小越好。引入权重  $\omega$ , 得到判别器的损失函数为:

$$L_D = L_{\text{label}} + \frac{\omega}{2} (L_{\text{unlabel}} + L_{\text{generate}}), \quad (6)$$

式中,  $L_{\text{unlabel}}, L_{\text{generate}}$  为无监督损失,  $L_{\text{label}}$  为有监督损失。

对于有标签真实样本, 其损失相当于 1 个有监督分类训练过程。对于 1 个  $N$  分类任务, 需要使真实样本和模型预测之间的交叉熵损失越小越好, 通过反向传播优化网络参数。对于无标签样本, 在训练时要使无标签样本为真实样本的概率越大越好, 所以式(4)中  $1 - P_{\text{model}}(y = N + 1 | x)$  的值越大越好; 对于生成样本, 要使判别器的性能好, 判别为生成样本

的概率越大越好,即式(5)中  $P_{\text{model}}(y=N+1|x)$  越大越好。

对于生成器来说,希望其输出的伪样本可以骗过分类器。生成器的损失函数越大越好,表达式为:

$$L_G = E_{x \sim G}[\log_2 P_{\text{model}}(y = N + 1 | x)], \quad (7)$$

为了提高模型的泛化能力,将有监督损失和无监督损失结合,共同对模型的参数进行更新,在训练时,判别器与生成器不断进行迭代训练。更新判别器的参数时,判别器中有标签样本参数的更新通过最小化真实样本和预测之间的交叉熵损失,无标签样本和伪样本需要通过最小化损失函数来进行参数的更新。更新生成器参数时,采用的是最大化损失函数来进行参数的更新。SGAN 模型通过有监督和无监督共同训练来寻找最优模型实现乳腺癌病理图像分类。

## 4 分析与讨论

本文实验环境为 Windows10,64 位的操作系统,运行内存 RAM 为 16 G,CPU 版本为 Intel(R)Core(TM)i7-8700,GPU 版本为 NVIDIA GeForce GTX 1660 SUPER。软件配置,Python 版本为 Python 3.6,深度学习框架为 Keras,集成开发环境为 Pycharm,主要使用的库有 Numpy、Matplotlib 和 Keras 等。

训练过程中批量处理数据的大小设为 32,即每训练 1 个 batch\_size 随机取 32 张图片。采用 Adam 优化器去优化损失函数,学习率设为 0.0001,beta1 设为 0.9,beta2 设为 0.999。迭代次数设为 1200。

将标签数为 200 的乳腺癌数据集在 SGAN 模型上训练 1200 次,当迭代训练完成后,判别器损失和生成器损失值的变化趋势如图 8 所示。

从图 8 中可以看出,判别器损失包括监督损失和无监督损失,前期处于下降趋势并出现小幅震荡现象,后期处于平稳震荡状态。生成器损失前期出现上升趋势,后期出现大幅震荡现象。原因是训练时生成网络和判别网络相互博弈,生成器不断学习真实数据的特征,最终 2 个网络的学习能力在博弈中都有所提高,就会出现图中所显示的震荡现象,此时判别器要优于生成器。

本文使用准确率(0%—100%)和 AUC(area under the curve)值(0—1)2 个评价指标对 SGAN 模型进行评价。当模型的准确率越高,AUC 的值越大时,说明模型的效果越好。

SGAN 模型的准确率如图 9 所示,迭代完成后,

准确率达到 95.5%。由此可以看出,乳腺癌数据集在 SGAN 模型上训练得到了较高的准确率。

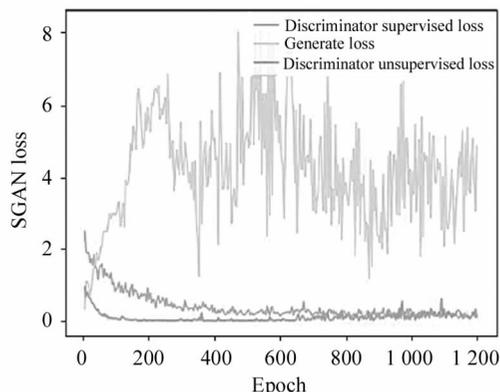


图 8 损失函数

Fig. 8 Loss function

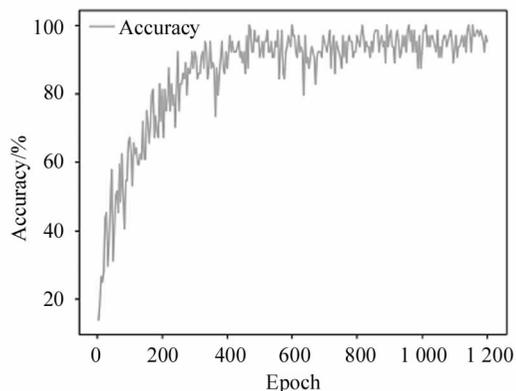


图 9 准确率

Fig. 9 Accuracy

SGAN 模型的 ROC 曲线如图 10 所示,ROC 曲线(ceiver operating characteristic curve)下包含的面积为 AUC 值,迭代完成后,AUC 的值达到 0.966。

为了进一步测试 SGAN 模型的性能,在带标签数量较少的数据集上训练,同时将该模型结果与文献[2]卷积神经网络(网络模型为 ResNet50)、文献[4]基于 ResNet50 的 TL,文献[8]半监督深度卷积生成对抗网络(semi-supervised deep convolutional generative adversarial networks, SS-DCGAN)和文献[1]SVM 等 4 种分类方法进行对比。首先将不同标签数量的数据集在不同的模型上训练,标签数量包括 25,50,100,200。在 BreakHis 数据集下经过 DA 处理后,传统的机器学习分类方法 SVM 最终准确率达到 78.3%,AUC 值为 0.802;卷积神经网络全监督模型最终准确率达到 83.9%,AUC 值为 0.857;TL 最终准确率为 91.5%,AUC 值为 0.922;这种方法的预训练模型来自 ImageNet 数据集,ImageNet

数据集中的样本基本都是自然场景图像,与医学图像有所不同,2 个领域之间有所差距,故提升效果有限。文献[8]所提的 SS-DCGAN 最终准确率达到 93.7%,AUC 值为 0.946。结果表明,提出的 SGAN 模型要优于其他模型,所提模型具有良好的鲁棒性。具体的分类准确率如表 1 所示。不同模型的 AUC 值如表 2 所示。

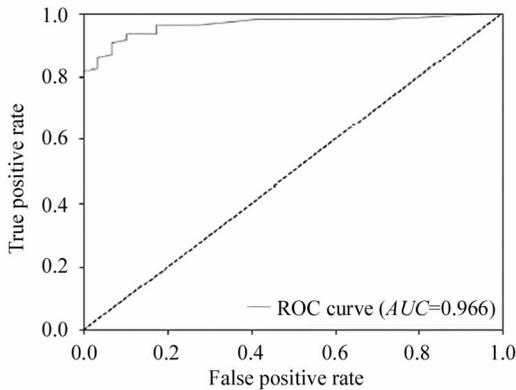


图 10 ROC 曲线  
Fig. 10 ROC curve

表 1 不同标签数量准确率

Tab. 1 Accuracy of different label numbers

Label quantity	SVM	ResNet50	TL	SS-DCGAN	SGAN
25	65.3%	72.5%	74.6%	81.2%	80.6%
50	71.8%	76.3%	80.5%	85.4%	86.3%
100	76.1%	80.3%	87.7%	88.3%	89.9%
200	78.3%	83.9%	91.5%	93.7%	95.5%

表 3 收敛速度

Tab. 3 Convergence rate

Label quantity	SVM/min	ResNet50/min	TL/min	SS-DCGAN/min	SGAN/min
25	4.5±0.3	3.1±0.3	2.6±0.2	1.1±0.3	1.2±0.2
50	5.2±0.2	4.7±0.2	2.8±0.4	1.7±0.3	1.5±0.3
100	7.1±0.4	4.9±0.3	3.5±0.4	1.9±0.1	1.8±0.3
200	7.4±0.3	5.2±0.2	3.9±0.2	1.9±0.3	1.9±0.2

表 4 其他数据集准确率

Tab. 4 Accuracy of other datasets

Label quantity	Cervical carcinoma	Colon cancer
25	81.3%	80.4%
50	86.1%	85.6%
100	88.2%	89.3%
200	94.3%	94.6%

表 2 AUC 值

Tab. 2 AUC value

Label quantity	SVM	ResNet50	TL	SS-DCGAN	SGAN
25	0.687	0.751	0.782	0.832	0.823
50	0.724	0.796	0.826	0.864	0.883
100	0.779	0.832	0.892	0.903	0.921
200	0.802	0.857	0.922	0.946	0.966

其次为了进一步比较不同模型的收敛速度,在不同标注样本数量的乳腺癌数据集下进行测试,结果显示,所提模型的收敛速度要快于其他模型。不同的模型收敛速度如表 3 所示。

同时,将 SGAN 模型应用于不同的医学数据集上,在 SIPaKMeD 宫颈癌(cervical carcinoma)和在公共数据集 TCGA 结肠癌(colon cancer)图像数据集上使用标注数量为 25、50、100 和 200 进行分类测试,与乳腺癌做相同的数据预处理,最终准确率分别达到了 94.3%和 94.6%。不同标注准确率如表 4 所示。结果表明,提出的 SGAN 模型泛化能力强。

最后为了验证 SGAN 模型中 DA 和 AM 对网络性能的影响,使用控制变量法进行了消融实验。实验在标签数量为 200 的数据集下训练模型,消融实验结果如表 5 所示。

从表 5 中可以看出,DA 对分类结果的提升效果有限,是因为 DA 只是在原始图像上进行的操作,并没有改变图像的深层信息,因此 DA 对模型的提升

表 5 消融实验结果

Tab. 5 Ablation results

DA	SGAN	AM	Accuracy
✓	✓	✓	95.5%
	✓	✓	93.7%
✓	✓		90.9%
	✓		89.3%

效果有限。使用 AM 对模型提升效果明显,因为

AM能够加强网络对关键特征的提取。通过调整不同特征的权重,AM能够使网络提取到对分类更有效的特征。因此将二者结合,不仅可以解决少量标签样本多分类问题,也可以提取有效特征提高分类准确率。

## 5 结 论

SGAN模型对少量带标签的乳腺癌图像样本进行分类,取得了良好的识别分类效果。与其他深度学习方法进行对比,模型结果更优。SGAN可以生成与真实样本特征分布一致的伪图像,有效解决医学领域数据不足的问题。下一步准备针对在训练过程中判别器优于生成器的问题,在生成器中加入约束条件,生成特定类的数据,并用于后续模型效果的研究。

### 参考文献:

- [1] SPANHOL F A, OLIVERIA L S, PETITJEAN C, et al. A dataset for breast cancer histopathological image classification[J]. *IEEE Transactions on Biomedical Engineering*, 2016, 63(7): 1455-1462.
- [2] ARAUJO T, ARESTA G, CASTRO E, et al. Classification of breast cancer histology images using convolutional neural networks[J]. *PLoS One*, 2017, 12(6): e0177544.
- [3] ZHOU H Y, YU S, BIAN C, et al. Comparing to learn: Surpassing imageNet pretraining on radiographs by comparing image representations[C]//International Conference on Medical Image Computer Assisted Intervention, October 4-8, 2020, Lima, Peru. Berlin: Springer-Verlag, 2020: 398-407.
- [4] HE X Y, HAN Z Y, WEI B Z. Automatic classification of breast cancer pathological images based on deep learning[J]. *Computer Engineering and Application*, 2018, 54(12): 121-125.  
何雪英, 韩忠义, 魏本征. 基于深度学习的乳腺癌病理图像自动分类[J]. *计算机工程与应用*, 2018, 54(12): 121-125.
- [5] KHAN S U, ISLAM N, JAN Z, et al. A novel deep learning based framework for the detection and classification of breast cancer using transfer learning[J]. *Pattern Recognition Letters*, 2019, 125: 1-6.
- [6] VU T H, MOUSAVI H S, MONGA V, et al. Histopathological image classification using discriminative feature-oriented dictionary learning[J]. *IEEE Transaction on Medical Imaging*, 2016, 35(3): 738-751.
- [7] LI L, ZHANG Y H, QIAO L. Classification of benign and malignant lung nodules based on improved depth convolutional generative adversarial networks[J]. *Computer Engineering*, 2020, 46(12): 262-269.  
李莉, 张浩洋, 乔璐. 基于改进深度卷积对抗生成网络的肺结节良恶性分类[J]. *计算机工程*, 2020, 46(12): 262-269.
- [8] OU L L, SHAO F J, SUN R C, et al. Cerebral infarction image recognition based on semi-supervised method[J]. *Computer Application*, 2021, 41(4): 1221-1226.  
欧莉莉, 邵峰晶, 孙仁诚, 等. 基于半监督方法的脑梗死图像识别[J]. *计算机应用*, 2021, 41(4): 1221-1226.
- [9] LIU G, REDA F A, SHIH K J, et al. Image inpainting for irregular holes using partial convolutions[EB/OL]. (2018-12-15)[2021-9-29]. <https://arxiv.org/pdf/1804.07723.pdf/>.
- [10] LUO J, HUANG J Y. A survey of generative adversarial networks[J]. *Journal of Instrumentation*, 2019, 40(3): 74-84.  
罗佳, 黄晋英. 生成式对抗网络研究综述[J]. *仪器仪表学报*, 2019, 40(3): 74-84.
- [11] TANG X L, DU Y M, LIU Y W, et al. Image recognition method based on conditional depth convolution to generative adversarial networks[J]. *Journal of Automation*, 2018, 44(5): 855-864.  
唐贤伦, 杜一铭, 刘雨微, 等. 基于条件深度卷积生成对抗网络的图像识别方法[J]. *自动化学报*, 2018, 44(5): 855-864.
- [12] IOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift [EB/OL]. (2015-02-11)[2021-10-26]. <https://arxiv.org/abs/1502.03167>.
- [13] WOO S, PARK J, LEE J. Convolutional block attention module[C]//Proceeding of the European Conference on Computer Vision, September 8-14, 2018, Munich, Germany. Berlin: Springer, 2018: 3-19.
- [14] HE K, ZHANG X, REN S, SUN J. Deep residual learning for Image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, June 26-July 1, 2016, Las Vegas, America. New York: IEEE, 2016: 770-778.
- [15] PEREZ L, WANG J. The effectiveness of data augmentation in image classification using deep learning[EB/OL]. (2017-12-13)[2021-10-12]. <https://arxiv.org/abs/1712.04621v1>.

### 作者简介:

刘 坤 (1982—), 女, 博士, 副教授, 硕士生导师, 主要从事智能信息处理、深度学习方面的研究。