

基于 U-Net++ 和对抗性学习网络的乳腺肿块分割

谢远志¹, 闫士举^{1*}, 魏高峰², 杨林英¹¹上海理工大学医疗器械与食品学院, 上海 200093;²海军军医大学热带医学研究院, 上海 200025

摘要 研究一种精确、可靠的乳腺病灶分割算法, 从钼靶图像中提取肿块区域, 以用于乳腺疾病的精细诊断。为了有效增强分割结果的高阶一致性, 在网络框架中引入对抗网络, 网络框架主要由分割网络和判别网络组成。采用改进的 U-Net++ 网络作为分割网络, 生成乳腺肿块分割图谱(掩码), 而判别网络对分割产生的掩码和真实的掩码进行识别, 进一步增强分割网络的性能。在公开数据集(CBIS-DDSM)上验证所提方法的有效性。实验结果显示, 所提方法得到的特异性、敏感度、准确性、Dice 系数分别为 99.7%、90.4%、98%、91%, 高于现有其他经典算法。改进模型(U-Net++)与生成对抗网络相结合的深度学习算法可提高钼靶图像中对乳腺肿块的分割性能。

关键词 乳腺肿块分割; 深度学习; U-Net++ 网络; 对抗学习

中图分类号 O436

文献标志码 A

DOI: 10.3788/LOP202259.1617002

Breast Mass Segmentation Based on U-Net++ and Adversarial Learning Network

Xie Yuanzhi¹, Yan Shiju^{1*}, Wei Gaofeng², Yang Linying¹

¹School of Medical Instrument and Food Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China;

²Institute of Tropical Medicine, Naval Medical University, Shanghai 200025, China

Abstract In this paper, an accurate and reliable breast lesion segmentation algorithm is examined to extract tumor regions from mammographic images for the diagnosis of breast diseases. Additionally, a framework incorporating an adversarial network, which is mainly composed of a segmentation network and a discriminant network, is used for the enhancement of the high-order consistency of the segmentation results. Here, an improved U-Net++ network is used as the segmentation network to generate a breast mass segmentation map (a mask), while the discriminant network is used to discriminate between the generated mask and the real mask to further enhance the performance of the segmentation network. The performance of the proposed method is verified on the public dataset (CBIS-DDSM). The experimental results show that the specificity, sensitivity, accuracy, and Dice coefficient of the proposed method are 99.7%, 90.4%, 98%, and 91%, respectively, which are higher than that of the classical algorithms. The deep learning algorithm combined with the improved model (U-Net++) and generated countermeasure network can improve the segmentation performance of breast mass in molybdenum target images.

Key words breast mass segmentation; deep learning; U-Net++ network; adversarial learning

1 引言

乳腺癌是全球女性最常见的恶性肿瘤之一, 严重威胁着女性的身心健康。根据 2019 年的预测, 在美国, 仅乳腺癌一项就占有所有新的癌症诊断的 30% 和女性死亡的 15%^[1]; 在中国, 乳腺癌的发病率在女性癌症中居首位, 根据报告, 2018 年乳腺癌占病例总数的

19.2%^[2]。到目前为止, 早期的乳腺癌检查对提高患者的生存率仍然是最有效的手段^[3]。

过去的几十年间, 研究者们已经广泛研究了乳腺肿块的分割技术, 并且依据传统的方法提出了许多乳腺肿块分割技术, 典型的如区域生长算法^[4-5]、基于轮廓的算法^[6-7]、聚类算法^[8], 然而这些基于传统学习的算法只能获取肿块区域的低层特征。最近, 基于全卷积

收稿日期: 2021-08-13; 修回日期: 2021-08-23; 录用日期: 2021-08-30

通信作者: *yanshiju@usst.edu.cn

网络(FCN)^[9]的深度学习方法,尤其是U-Net网络^[10],已经在医学图像分割上取得了卓越的成果^[11-12],这可以归因于它们出色的分层特征表示。然而U-Net中的跳跃连接直接将高分辨率特征从编码器映射到解码器网络,从而导致语义上不同的特征映射融合^[13]。理论分析认为,当来自解码器和编码器网络的特征映射在语义上相似时,网络将更容易处理学习任务^[14]。为了避免U-Net在语义上不同的特征映射融合问题,有研究者采用了U-Net++作为分割网络^[15]。

近年来生成对抗网络(GAN)^[16]是发展最为快速的网络之一,最早由Goodfellow于2014年提出,在包括医学图像处理的多个领域展示出卓越的性能及强大的生命力,如已成功应用于图像配准^[17]、图像生成^[18]、图像分割^[19]等领域。它已经在各种任务中成为了一个强大的框架,由生成器和判别器组成,生成器试图产生接近真实样本的输出,而判别器试图区分真实样本和生成样本。本研究将GAN与U-Net++集成用于乳腺肿块的分割。

2 数据和方法

2.1 数据集的获取和预处理

在本次实验中,实验数据来自于Curated Breast Imaging Subset of DDSM (CBIS-DDSM)数据库^[20]。对于一个完整乳腺组织来说,由于乳腺肿块相对于背景区域尺寸较小,在研究中通过预先设定的标签提取乳腺肿块的大致区域。将该区域作为分割网络的输入,这样可以大大降低背景区域对乳腺肿块区域的干扰,具体流程如图1所示。首先通过裁剪的方式获取感兴趣区域,接着将感兴趣区域作为网络的输入,得到肿块的分割结果。为了防止图像在训练过程中出现过




图1 简明分割流程

Fig. 1 Concise segmentation process

拟合,主要采用水平镜像和随机翻转的方法扩充数据集。

本研究一共采用了2100张图片,按4:1将图片数据集分为训练集和测试集,采用五折交叉验证的方法训练网络模型。

2.2 方法内容

2.2.1 网络整体结构

所采用的模型包含两个子网络:一个是分割网络(SN),主要用于感兴趣区域分割,该分割网络采用了改进的U-Net++网络架构;另一个是评估网络(EN),主要用来判断分割的结果。评估网络主要由卷积模块和残差模块组成,残差模块可以解决在训练过程中的梯度消失和梯度爆炸的问题。整体框架如图2所示。将待分割的图片 x 及其对应掩模 Y_1 (GT)分别输入到分割网络中,也就是图2中的生成器网络 $G(x)$,该网络将产生对应图片 x 的分割图谱 Y_2 (fake);将分割图谱 Y_2 和对应的掩模 Y_1 分别输入到判别网络 $D(Y_1, Y_2)$ 中,判别网络将对二幅图片做出评价,1表示所对应的图片为掩模图像,0表示所对应的图像为分割网络分割出的图像;最后将判别器产生的分类损失传递给生成器,提高生成器的分割效果。

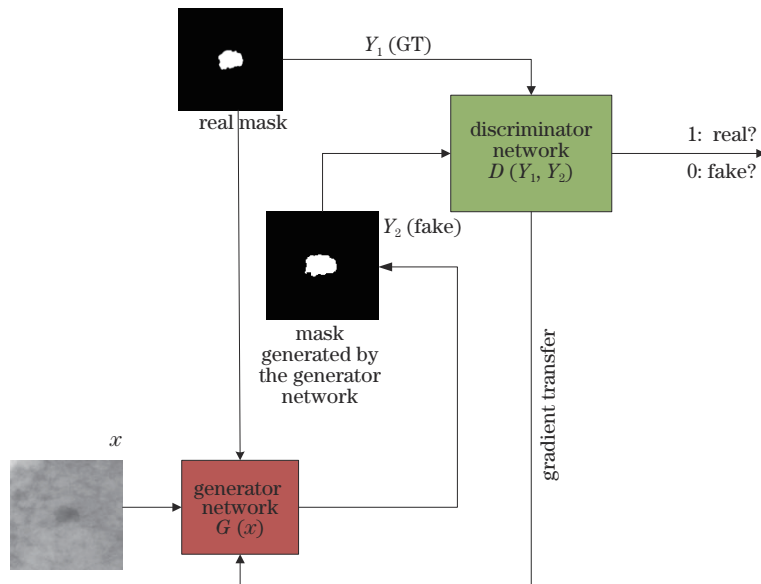


图2 乳腺肿块分割对应的整体框架图

Fig. 2 Overall frame diagram corresponding to the segmentation of breast mass

2.2.2 U-Net++ 网络

作为生成器,本研究采用改进后的 U-Net++ 网络结构,该网络由收缩路径和扩展路径组成,主要结构单元如图 3 所示。收缩路径主要用于学习输入图像中的上下文信息,扩展路径主要用于精确定位待分割区域的位置。在收缩路径上,每个编码模块由两个连续的卷积层和最大池化层组成,如图 3(a)所示。当特征

图谱通过每个模块时,除第一个模块外,它们的通道数量都会翻倍,特征图谱的宽度和长度都会减半。另一方面,扩展路径上的解码器模块的典型结构是两个卷积层,其后是反卷积层(注意,除最后一个是 Sigmoid 激活函数,扩展路径上的其他激活函数都是 ReLU),如图 3(b)所示。当特征图谱经过扩展路径时,其大小和通道变化与通过收缩路径时变化相反。

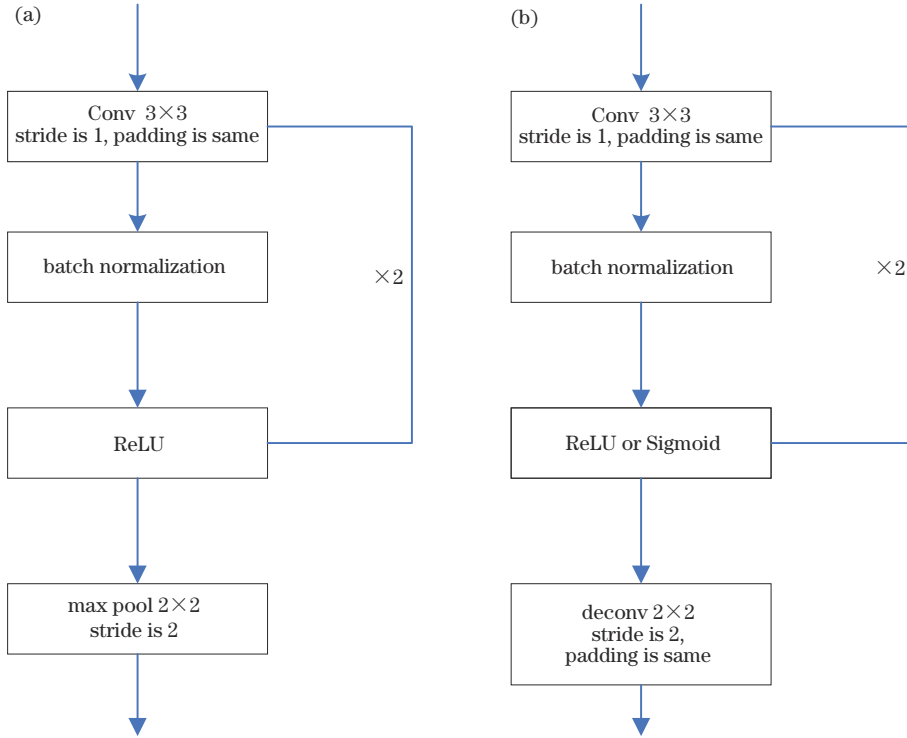


图 3 改进后的 U-Net++ 网络的主要模块。(a) 编码器结构单元; (b) 解码器结构单元

Fig. 3 Main modules of the improved U-Net++ network. (a) Encoder structure unit; (b) decoder structure unit

2.2.3 判别器网络

判别器网络采用二分类网络,用来区分输入数据是由生成器产生的还是来自于真实的掩模图,结构如

图 4 所示。该二分类网络主要由卷积层、残差模块、全连接层组成,由于数据量较少,本研究仅仅采用了 8 层卷积、1 个残差模块、1 个全连接模块、1x1 的卷积

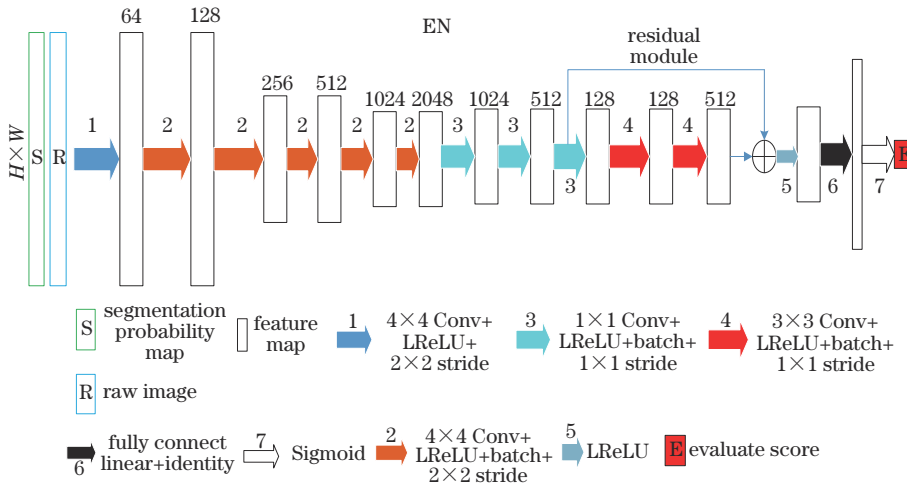


图 4 判别器网络框架图

Fig. 4 Discriminator network framework diagram

核,降低参数量。在激活函数方面,由于二分类模型,采用 Sigmoid 函数作为网络全连接层的激活函数,该函数常被用来作为交叉熵损失函数,衡量预测值和真实值之间的误差。在卷积层和残差模块中均采用 LeakReLU(LReLU)作为激活函数,增强网络的非线性建模能力,同时也为了避免出现梯度消失等情况。

2.2.4 对抗训练

在所提模型训练的过程中,判别网络应给真实的掩模图像较高的分数(1),对于分割网络产生的掩模图像,应给予较低的分(0)。一共有 M 个样本 X_M ,样本所对应的标签 Y_M ,损失函数定义为

$$l(\theta_s, \theta_E) = \sum_{m=1}^M l_{\text{Dice} + \text{bce}}[S(X_m), Y_m] - \lambda \left\{ \sum_{m=1}^M l_{\text{bce}}\{E[S(X_m)], 0\} + \sum_{n=1}^N l_{\text{bce}}\{E(Y_M), 1\} \right\}, \quad (1)$$

式中: θ_s 和 θ_E 分别表示分割网络(SN)和判别网络(EN)中所对应的参数; l_{Dice} 表示 Dice 系数, l_{bce} 表示两类别交叉熵。式(1)中的第一项表示对分割网络的有监督训练损失函数,第二项表示对于对抗网络的损失

函数。该网络的训练过程:优化参数 θ_E 使对抗网络损失函数达最大,优化参数 θ_s 使分割网络的损失函数最小,即最大最小化过程。更精确地说,训练 EN 是为了最小化

$$\lambda \left\{ \sum_{m=1}^M l_{\text{bce}}\{E[S(X_m)], 0\} + \sum_{n=1}^N l_{\text{bce}}\{E(Y_M), 1\} \right\}, \quad (2)$$

更新判别器网络所对应的参数 θ_E 。训练 SN 是为了最小化

$$\sum_{m=1}^M l_{\text{Dice} + \text{bce}}[S(X_m), Y_m] - \lambda \left\{ \sum_{n=1}^N l_{\text{bce}}\{E[S(X_M)], 0\} \right\}, \quad (3)$$

更新分割网络所对应的参数 θ_s 。正如其他文献中所提到,可以用 $\lambda \left\{ \sum_{n=1}^N l_{\text{bce}}\{E[S(X_M)], 1\} \right\}$ 来替代

$$-\lambda \left\{ \sum_{n=1}^N l_{\text{bce}}\{E[S(X_M)], 0\} \right\},$$

这样就可以采用标准的随机梯度下降法来获得分割网络所对应的最优参数。图 5 展示了网络的训练过程。

Algorithm: adversarial training for generator and discriminator

```

Input: the initial weight corresponding to the pre-trained segmentation network  $\theta_0^G$ 
Output: update the weight parameters corresponding to the segmentation network  $\theta_1^G$ 
1 for number of epochs do
2   for  $k_D$  steps do
3     select small batches of samples from training samples  $x \sim p_{\text{data}}$ 
4     send a small batch of samples into the segmentation network  $G(x; \theta_0^G)$  to generate the
       corresponding segmentation result  $y_{\text{pred}}$ 
5     by calculating  $\nabla \mathcal{L}_D(y_{\text{GT}}, y_{\text{pred}})$ , the gradient descent method is used to update the
       parameter  $\theta^D$  corresponding to the discriminator
6   end
7   for  $k_G$  steps do
8     select small batches of samples from training samples  $x \sim p_{\text{data}}$ 
9     the segmentation network  $G(x; \theta_0^G)$  generates the corresponding segmentation result
        $y_{\text{pred}}$  according to the sample  $x$  and calculates  $D[G(x)]$ 
10    by calculating  $\nabla \mathcal{L}_G(y_{\text{GT}}, y_{\text{pred}})$ , the gradient descent method is used to update the
       corresponding parameters of the segmentation network  $\theta^G$ 
11  end
12   $\theta_0^G \leftarrow \theta_1^G$ 
13 end

```

图 5 生成器和判别器的对抗训练过程

Fig. 5 Adversarial training process of generator and discriminator

3 结果和分析

3.1 评价标准

为了评估所提网络的有效性,使用总体准确率、敏感度、特异度和 Dice 系数来定量地表征网络在该数据集上的分割性能。这些指标定义为

$$A_{\text{accuracy}} = \frac{N_{\text{TP}} + N_{\text{TN}}}{N_{\text{TP}} + N_{\text{FN}} + N_{\text{TN}} + N_{\text{FP}}} \times 100\%, \quad (4)$$

$$S_{\text{sensitivity}} = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FN}}} \times 100\%, \quad (5)$$

$$S_{\text{specificity}} = \frac{N_{\text{TN}}}{N_{\text{TN}} + N_{\text{FP}}} \times 100\%, \quad (6)$$

$$D_{\text{Dice}} = \frac{2 \times N_{\text{TP}}}{2 \times N_{\text{TP}} + N_{\text{FP}} + N_{\text{FN}}} \times 100\%, \quad (7)$$

式中: N_{TP} 、 N_{TN} 、 N_{FP} 、 N_{FN} 分别表示真阳性、真阴性、假阳性和假阴性像素样本的数目。

3.2 结果和分析

为了测试所提算法的乳腺肿块分割性能,对其与现有典型算法进行比较,包括 U-Net 网络、U-Net++ 网络、U-Net++ 加对抗网络(U-Net++ + adv)、所提 U-Net++ 加对抗网络和批归一化处理(U-Net++ +

adv+batch normalization)。

表 1 显示了四种网络框架的分割结果,可以看出:U-Net 网络结构的 Dice 系数可以达 87.8%,U-Net++网络结构的 Dice 系数达到 89.0%,从该结果看出 U-Net++ 更适合处理乳腺肿块的分割任务;所提网络模型的所有计算指标都优于其他模型,具有非常显著的 Dice 系数、准确率、敏感度、特异性(分别为 91%、98%、90.4%、99.7%)。表 1 结果表明,对抗性训练确实可以提高乳腺肿块分割结果的质量,批归一化操作^[21]可以在一定程度上缓解深层网络中的梯度弥散问题,从而使得训练深层的网络模型更加容易和稳定,获得更好的结果。表 1 还显示了四种网络的 area under curve (AUC),图 6 为四种网络的 receiver operating

表 1 四种网络对乳腺肿块的分割结果

Table 1 Segmentation results of four types of networks for breast masses

Method	Specificity	Sensitivity	Accuracy	Dice	AUC
U-Net	0.968	0.842	0.957	0.878	0.8561
U-Net++	0.974	0.864	0.964	0.890	0.8745
U-Net+++adv	0.988	0.880	0.973	0.906	0.9085
Proposed method	0.997	0.904	0.980	0.910	0.9362




图 7 乳腺肿块分割结果。(a)待分割的乳腺肿块区域;(b)金标准;(c)U-Net产生的掩模图;(d)U-Net++产生的掩模图;(e)U-Net+++adv产生的掩模图;(f)U-Net+++adv+batch normalization产生的掩模图

Fig. 7 Segmentation results of a breast mass. (a) Region of the breast mass to be segmented; (b) gold standard; (c) mask image produced by U-Net; (d) mask image produced by U-Net++; (e) mask image generated by U-Net+++adv; (f) mask image generated by U-Net+++adv+batch normalization

4 讨论

近年来,深度学习发展迅速,以U-Net网络为代表基于FCN的方法出现在多数医学图像分割任务中。然而,由于乳腺肿块在乳房钼靶图像中呈现出不同的




图 6 四种网络的 ROC 曲线

Fig. 6 ROC curves of four types of networks

characteristic curve (ROC) 曲线。所提方法的 ROC 曲线位于左上方,并且 AUC (0.9362) 大于其他三个网络。

除了定量测量外,还对乳房的数据集进行了可视化分析,给出了一些随机选择的分割结果。图 7 展示了 U-Net、U-Net++、U-Net+++adv、U-Net+++adv+batch normalization 对几个乳腺肿块的分割结果。显然,对抗网络在对图像细节和边缘上处理的效果更好,因为它的训练方式强制输出空间连续。

形状和大小,如参考文献[22]所示,这些方法只能独立对每个像素进行预测,无法从全局上捕捉像素之间的相互作用。本研究将对抗学习框架应用到图像分割网络中,经过实验证明,它适合解决乳腺肿块分割任务中的空间不连续性问题。

首先,所采用的框架结合编码-解码模块、跳级连接、深监督模块、对抗学习模块;其次,在训练 U-Net++ 网络结构时,采用了深监督的训练方法,相当于同时训练 U-Net++ 网络的 4 个子模块,通过其对验证集表现得好坏,选择其中的一个子网络进行下一步的对抗学习训练,在这里选择模块的 4 层网络结构进行下一步训练;最后,虽然在网络结构中增加了对抗学习的方式,在训练数据集时增加了网络模型的复杂度,由于对抗网络在这里起到的作用是对 U-Net++ 网络模型的优化和监督,在对数据集进行测试时,仅需要 U-Net++ 网络,所以这种模型的复杂度并不会给模型的应用(测试)带来影响。

分析本次的训练过程,本研究的分割网络采用 U-Net++,其损失函数采用交叉熵减去 Dice 系数方式。在训练过程中,首先将 U-Net++ 网络训练了 40 个 epoch,最终的损失函数值稳定在 -0.88 左右;接着将对抗网络加入预训练的 U-Net++ 网络,判别器训练真掩模和假掩模时的损失值随着训练次数的增加在不断减小,当训练次数达到 35 左右时,判别器可以完全判断该掩模图像是来自于真实的掩模还是由生成器产生的。同时生成器的对抗损失随着训练次数的增加在不断增大,当训练次数达到 50 时,该损失函数接近平滑,说明由生成器产生的对抗损失通过梯度更新的方式得到优化。生成器总的损失函数由生成器的对抗损失和分割的损失函数构成,随着训练次数的增加,损失函数值越来越小,最后稳定在 -0.96 左右,在原损失值的基础上降低了 6%,体现出了判别器网络在训练过程中对分割网络的监督和强化作用。

5 结 论

采用深度学习网络对乳腺钼靶图像中的肿块区域进行分割。所提基于 U-Net++ 的对抗学习网络不需要像传统分割算法那样人工提取特征和选择某些参数,可以实时分割出乳腺肿块。所采用的 U-Net++ 网络结构可以解决 U-Net 网络中编码器和解码器之间的特征映射不匹配的问题,这样优化器将更容易处理学习任务。在原始 U-Net++ 网络的基础上,在每个卷积层之后加入了批归一化,可以防止梯度弥散等问题,使网络模型的训练过程更稳定。为了防止网络出现过拟合的现象,对原始数据集进行数据扩增。将 GAN 框架应用于对乳腺肿块的分割,可以增强输出模板的高阶一致性。该网络分割精度的提高在于 U-Net++ 网络和 GAN 的组合。乳腺肿块分割精度的提高可以给乳腺肿块良恶性的分类带来潜在的好处。

相对于其他研究,本课题组根据预先设定区域获取肿块的位置,因此很难处理没有标签的乳腺,所以在下一阶段会采用目标检测网络模块提取出乳腺肿块的位置,提高整个网络的适应性。目前相关文献对图像边界信息丢失的问题做了相关探索,比如 Deeplabv 系

列^[23]从引入空洞卷积模块到新的编码器-解码器模块来获取更清晰的图像边界,在下一步工作计划中将引入相应的模块,对肿块的边界信息进行处理。

参 考 文 献

- [1] Siegel R L, Miller K D, Jemal A. Cancer statistics, 2016 [J]. CA: A Cancer Journal for Clinicians, 2016, 66(1): 7-30.
- [2] Feng R M, Zong Y N, Cao S M, et al. Current cancer situation in China: good or bad news from the 2018 global cancer statistics? [J]. Cancer Communications (London, England), 2019, 39(1): 22.
- [3] DeSantis C E, Ma J M, Goding Sauer A, et al. Breast cancer statistics, 2017, racial disparity in mortality by state[J]. CA: A Cancer Journal for Clinicians, 2017, 67(6): 439-448.
- [4] Guliato D, Rangayyan R M, Carnielli W A, et al. Segmentation of breast tumors in mammograms using fuzzy sets[J]. Journal of Electronic Imaging, 2003, 12(3): 369-378.
- [5] Kinnard L, Lo S C B, Wang P, et al. Automatic segmentation of mammographic masses using fuzzy shadow and maximum-likelihood analysis[C]//Proceedings IEEE International Symposium on Biomedical Imaging, July 7-10, 2002, Washington, DC, USA. New York: IEEE Press, 2002: 241-244.
- [6] Timp S, Karssemeijer N. A new 2D segmentation method based on dynamic programming applied to computer aided detection in mammography[J]. Medical Physics, 2004, 31(5): 958-971.
- [7] Rahmati P, Adler A, Hamarneh G. Mammography segmentation with maximum likelihood active contours [J]. Medical Image Analysis, 2012, 16(6): 1167-1186.
- [8] Cao A Z, Song Q, Yang X L, et al. Breast mass segmentation on digital mammograms by a combined deterministic annealing method[C]//2004 2nd IEEE International Symposium on Biomedical Imaging: Nano to Macro, April 18, 2004, Arlington, VA, USA. New York: IEEE Press, 2004: 1303-1306.
- [9] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition, June 7-12, 2015, Boston, MA, USA. New York: IEEE Press, 2015: 3431-3440.
- [10] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation[M]//Navab N, Hornegger J, Wells W M, et al. Medical image computing and computer-assisted intervention-MICCAI 2015. Lecture notes in computer science. Cham: Springer, 2015, 9351: 234-241.
- [11] 黄泳嘉, 史再峰, 王仲琦, 等. 基于混合损失函数的改进型 U-Net 肝部医学影像分割方法[J]. 激光与光电子学进展, 2020, 57(22): 221003.
Huang Y J, Shi Z F, Wang Z Q, et al. Improved U-Net based on mixed loss function for liver medical image segmentation[J]. Laser & Optoelectronics Progress, 2020, 57(22): 221003.

- [12] 牟海维, 郭颖, 全星慧, 等. 基于改进 U-Net 的磁共振成像脑肿瘤图像分割[J]. 激光与光电子学进展, 2021, 58(4): 0410022.
Mu H W, Guo Y, Quan X H, et al. Magnetic resonance imaging brain tumor image segmentation based on improved U-Net[J]. Laser & Optoelectronics Progress, 2021, 58(4): 0410022.
- [13] Peng D F, Zhang Y J, Guan H Y. End-to-end change detection for high resolution satellite images using improved UNet++[J]. Remote Sensing, 2019, 11(11): 1382.
- [14] Li C, Tan Y S, Chen W, et al. Attention unet++: a nested attention-aware U-net for liver CT image segmentation[C]//2020 IEEE International Conference on Image Processing, October 25-28, 2020, Abu Dhabi, United Arab Emirates. New York: IEEE Press, 2020: 345-349.
- [15] Zhou Z W, Siddiquee M M R, Tajbakhsh N, et al. UNet++: a nested U-net architecture for medical image segmentation[M]//Stoyanov D, Taylor Z, Carneiro G, et al. Deep learning in medical image analysis and multimodal learning for clinical decision support. Lecture notes in computer science. Cham: Springer, 2018, 11045: 3-11.
- [16] Goodfellow I J, Pouget-Abadie J, Mirza M, et al. Generative adversarial networks[J]. Communications of the ACM, 2020, 63(11): 139-144.
- [17] Tanner C, Ozdemir F, Profanter R, et al. Generative adversarial networks for MR-CT deformable image registration[EB/OL]. (2018-07-19)[2020-08-09]. <https://arxiv.org/abs/1807.07349>.
- [18] Nie D, Trullo R, Lian J, et al. Medical image synthesis with deep convolutional adversarial networks[J]. IEEE Transactions on Bio-Medical Engineering, 2018, 65(12): 2720-2730.
- [19] 张琦, 叶波, 罗思琦, 等. 基于改进生成对抗网络的铝板缺陷电涡流检测图像分割[J]. 激光与光电子学进展, 2021, 58(8): 0815002.
Zhang Q, Ye B, Luo S Q, et al. Aluminum plate defect image segmentation using improved generative adversarial networks for eddy current detection[J]. Laser & Optoelectronics Progress, 2021, 58(8): 0815002.
- [20] Lee R S, Gimenez F, Hoogi A, et al. A curated mammography data set for use in computer-aided detection and diagnosis research[J]. Scientific Data, 2017, 4: 170177.
- [21] Ioffe S, Szegedy C. Batch normalization: accelerating deep network training by reducing internal covariate shift [C]//Proceedings of the 32nd International Conference on Machine Learning, July 6-11, 2015, Lille, France. Cambridge: PMLR, 2015: 448-456.
- [22] Luc P, Couprie C, Chintala S, et al. Semantic segmentation using adversarial networks[EB/OL]. (2016-11-25)[2021-05-03]. <https://arxiv.org/abs/1611.08408>.
- [23] Chen L C, Zhu Y K, Papandreou G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[M]//Ferrari V, Hebert M, Sminchisescu C, et al. Computer vision-ECCV 2018. Lecture notes in computer science. Cham: Springer, 2018, 11211: 833-851.