

文章编号: 2095-2163(2020)06-0048-03

中图分类号: TP391.4

文献标志码: A

基于腐蚀损失的肿块分割算法

李响¹, 卜巍², 邬向前¹

(1 哈尔滨工业大学 计算机科学与技术学院, 哈尔滨 150001; 2 哈尔滨工业大学 媒体技术与艺术学院, 哈尔滨 150001)

摘要: 乳腺肿块分割的任务是在感兴趣区域内区分出肿块和正常组织。目前常用的病变分割算法主要包括区域生长等传统算法和全卷积网络等深度学习方法, 这些算法都忽略肿块分割的一个特异性。和自然场景中明显的梯度边缘相比, 乳腺肿块和背景的边缘是渐变的。标注的边缘不够准确, 训练过程中边缘周围错误标注的像素会影响网络的训练。因此, 本文提出了基于腐蚀损失的肿块分割算法。利用形态学腐蚀操作生成计算损失的掩码, 使错误可能性高的边缘周围部分不参与损失的计算, 将其结合到全卷积加条件随机场的网络中。边缘模糊的特性存在于多种医学图像中, 本文的方法具有普适性, 可应用于其他医学病变的分割算法。

关键词: 肿块分割; 腐蚀损失; 边缘模糊

Mass segmentation algorithm based on erosion loss

LI Xiang¹, BU Wei², WU Xiangqian¹

(1 School of Computer Science and Technology, Harbin Institute of Technology, Harbin 150001, China;

2 School of Media Technology and Art, Harbin Institute of Technology, Harbin 150001, China)

[Abstract] The breast mass segmentation task is to distinguish masses from normal tissues in the region of interest. At present, commonly used lesion segmentation algorithms mainly include traditional algorithms such as region growth and deep learning methods such as full convolutional networks. These algorithms all ignore the specificity of mass segmentation. Compared with the obvious edges in natural scenes, the edges of the breast mass are gradually changing. The annotated edges are not accurate enough. Pixels mislabeled around the edges will affect the training of the network during the training process. Therefore, this paper proposes a segmentation algorithm based on erosion loss. The morphological erosion operation is used to generate a mask for calculating the loss, so that the part around the edge with a high possibility of error does not participate in the loss calculation, and it is combined into a network with full convolution and conditional random field. The characteristics of blurred edges exist in a variety of medical images. The method in this paper is universal and can be applied to segmentation algorithms for other medical lesions.

[Key words] Mass segmentation; Erosion loss; Blurred edges

0 引言

医学病变分割是计算机视觉领域一个具有挑战的方向。肿块分割对于肿块的形状和病理分类都具有重要意义。钼靶图像的成像原理是光线通过越密集的组织剩余量越少, 成像越亮。由于肿块病变是一个类球的结构, 成像时从病变中心到边缘病变越来越薄, 因此病变边缘非常不明显。语义分割中有很多方法加入边缘检测, 有助于场景的分割, 而病变由于边缘渐变的特性, 标注的边缘不够准确, 训练过程中边缘周围错误标注的像素反而影响网络的训练。因此, 本文利用形态学腐蚀操作生成计算损失的掩码, 使错误可能性高的边缘周围部分不参与损失的计算。

1 相关工作

乳腺肿块任务可以看作是像素级分类任务, 也可看作是肿块的边缘检测任务。目前有许多传统方法被提出, 来解决乳腺肿块分割的问题, 包括基于阈值的方法, 迭代像素分类, 区域增长, 区域聚类, 边缘检测, 模板匹配和随机松弛的技术^[1-2]。经典的统计模型也用于分割问题, 例如, Dhungel 等人运用多个深度置信网络(DBN), 高斯混合模型分类器和先验作为潜在能量函数, 以及结构化支持向量机(SVM)进行分割^[3], 也提出了使用深度置信网络或卷及神经网络特征作为其潜在能量函数的结构化支持向量机^[4]。仅基于全卷积网络(FCN)方法也可进行图像分割^[5]。但是, 典型的全卷积网络结构不

基金项目: 国家自然科学基金(61672194); 国家重点研究与发展计划(2018YFC0832304); 中国黑龙江省杰出青年科学基金(JC2018021); 国家机器人与系统国家重点实验室项目(SKLR5-2019-KF-14); 中兴通讯产学研合作论坛合作项目。

作者简介: 李响(1995-), 女, 硕士研究生, 主要研究方向: 计算机视觉、医学图像识别等; 卜巍(1977-), 女, 博士, 副教授, 主要研究方向: 数字媒体技术、数字图像处理、医学图像分析等; 邬向前(1973-), 男, 博士, 教授, 博士生导师, 主要研究方向: 数字图像处理、模式识别、生物特征识别等。

收稿日期: 2020-03-08

能准确地保留肿块边界。为了克服这个缺点, Wentao Zhu 等人将全卷积网络与循环神经网络实现的条件随机场连接在一起, 可增强分割结果的结构性^[6]。Vivek Kumar Singh 等人应用条件生成对抗网络结构实现肿块分割, 并以分割结果为输入对肿块形状进行分类。

2 算法详述

2.1 算法概况

肿块分割网络的基线网络总体结构借鉴目前分割结果较好的 Wentao Zhu 等人提出的网络结构。本文在基线网络上利用形态学腐蚀操作, 生成计算损失的掩码, 掩码将损失计算分为三部分: 病变区、背景区和模糊区, 改变分割结果的对数损失计算, 去除模糊区部分损失。整个肿块分割网络结构如图 1 所示。

2.2 基于腐蚀损失的肿块分割算法

输入为 40×40 的图像块, 图像输入 4 个不同感受野的全卷积网络, 每个全卷积网络包含 3 个卷积层、两个池化层, 实现特征编码, 编码结果为一个特征向量, 通过一个反卷积层解码特征向量, 获得初步分割结果。4 个全卷积网络的前两层感受野分别为 2、3、4 和 5, 这样递增的设置可以使网络学习不同尺度上下文细节特征。以可学习的权重加权融合 4 个分割结果, 融合结果输入条件随机场。自适应的

权重使网络可以根据数据集的特性选择不同分割结果的比例, 加权求和实现了多分类器投票的效果, 提高分割准确性。条件随机场是给定一组输入随机变量 X 的条件下, 另一组输出随机变量 Y 的条件概率分布模型。实验中应用全连接的成对条件随机场, 以全卷积网络的分割结果为条件, 将像素标签建模为马尔可夫随机场中的随机变量。Zheng 等人将条件随机场实现为循环神经网络, 每次循环经过四步优化。应用对抗性训练增强深层网络的鲁棒性, 对抗性训练的思想是, 如果模型足够强大, 它应该对训练示例的小扰动保持不变。网络训练过程中损失函数对输入图像求导, 梯度矩阵方向的小向量作为对抗扰动, 叠加到图像上, 再一次计算损失函数。

根据像素级分割标签的结构, 生成损失选择掩码。将分割标签分为肿块标签和背景标签两部分, 应用直径为 3 的滤波核两部分分别进行形态学腐蚀, 腐蚀操作消除了肿块标注边缘的标签, 结合腐蚀后的两部分生成掩码。掩码白色区域是肿块中心部分, 为正样本, 损失函数为 $-\log(p)$, 掩码黑色区域是远离肿块的背景部分, 为负样本, 损失函数为 $-\log(1 - p)$ 。灰色部分损失为 0。因为分割任务即为像素级分类, 部分区域不计算损失不会影响网络的反向传播参数更新。

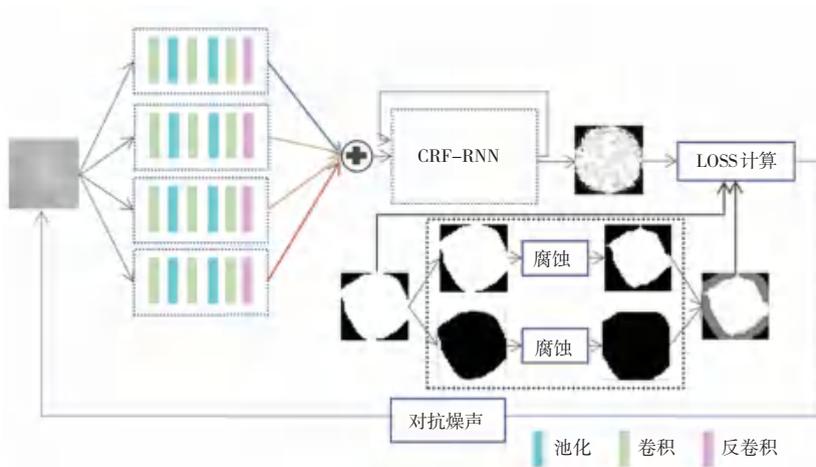


图 1 网络结构

Fig. 1 Network structure

3 实验

3.1 实验参数

实验应用 DDSM-BCRP 数据集, 该数据集为划分好训练测试集的 DDSM 子集。在钼靶图像上采集肿块所在图像块, 缩放到 40×40 大小。网络为端到端训练, 训练学习率为 0.003, 以 28 的批量大小训

练 5 000 epoch。训练采用 Adam 优化方法。

3.2 实验结果

医学病变分割算法的评估, 主要应用 DICE 系数。为了证明本文方法的有效性, 对基线方法和目前较好的肿块分割方法进行了实验对比, 对比结果见表 1。本文的基线网络精度达到了 91.04%, 加入

腐蚀损失后方法提高了 0.02%。较目前比较好的方法都有超过 1% 的显著提高。分割可视化结果如图 2 所示。病变边缘渐变的现象并不只存在于钼靶图像中,大部分医学图像都有该现象,因此掩码选择计算损失方法可扩展到多种病变分割模型中。

表 1 分割结果对比

Tab. 1 Comparison of segmentation results

方法	DICE/%
本文方法	91.06
基线方法	91.04
Deep Structure Learning + CNN ^[4]	90
全卷积神经网络迁移学习 ^[7]	89.4
TRW Deep Structure Learning ^[8]	89
Deep Structure Learning ^[3]	87

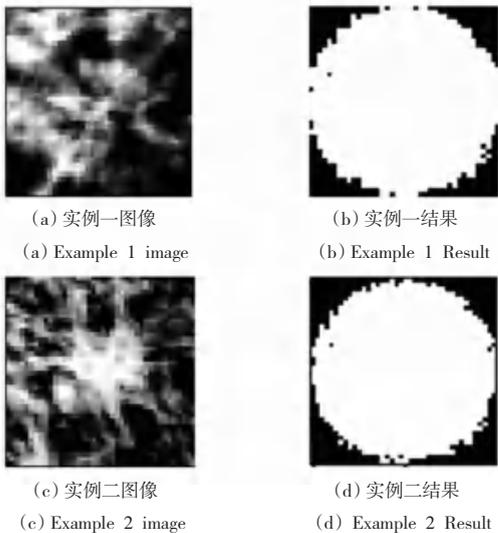


图 2 分割实例

Fig. 2 Segmentation instance

4 结束语

肿块分割与判断肿块形状、肿块分类和确定治疗方案都有相关性。肿块分割可获得肿块的形状和边缘。边缘信息反映了其生长方式和生物学特性。边缘不规则的、有毛刺状的肿块通常是恶性的,边缘

光滑、形状规则的肿块一般是良性的。本文提出了基于腐蚀损失的肿块分割算法,利用形态学腐蚀操作生成计算损失的掩码,使错误可能性高的边缘周围部分不参与损失的计算,进一步提高目前较好的应用全卷积网络和条件随机场进行肿块分割的方法的分割性能。实验证明了本文的方法要比目前较好的几个分割方法都更加有效。同时,边缘模糊的特性存在于多种医学图像中,本文的方法具有普适性,后续可应用于其他医学病变的分割算法。

参考文献

- [1] CHENG H D, SHI X J, MIN R, et al. Approaches for automated detection and classification of masses in mammograms[J]. Pattern recognition, 2006, 39(4): 646-668.
- [2] OLIVER A, FREIXENET J, MARTI J, et al. A review of automatic mass detection and segmentation in mammographic images[J]. Medical image analysis, 2010, 14(2): 87-110.
- [3] DHUNGEL N, CARNEIRO G, BRADLEY A P. Deep structured learning for mass segmentation from mammograms[C]//2015 IEEE international conference on image processing (ICIP). IEEE, 2015: 2950-2954.
- [4] DHUNGEL N, CARNEIRO G, BRADLEY A P. Deep learning and structured prediction for the segmentation of mass in mammograms[C]//International Conference on Medical image computing and computer-assisted intervention. Springer, Cham, 2015: 605-612.
- [5] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2015: 3431-3440.
- [6] ZHU W, XIANG X, TRAN T D, et al. Adversarial deep structured nets for mass segmentation from mammograms[C]//2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018). IEEE, 2018: 847-850.
- [7] 徐胜舟, 程时宇. 基于全卷积神经网络迁移学习的乳腺肿块图像分割[J]. 中南民族大学学报(自然科学版), 2019, 38(2): 278-284.
- [8] DHUNGEL N, CARNEIRO G, BRADLEY A P. Tree re-weighted belief propagation using deep learning potentials for mass segmentation from mammograms[C]//2015 IEEE 12th international symposium on biomedical imaging (ISBI). IEEE, 2015: 760-763.

(上接第 47 页)

- [8] YANG M, YU K, ZHANG C, et al. Denseaspp for semantic segmentation in street scenes[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018: 3684-3692.
- [9] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2017: 4700-4708.
- [10] SAXENA A, SUN M, NG A Y. Make3d: Learning 3d scene structure from a single still image[J]. IEEE transactions on

pattern analysis and machine intelligence, 2008, 31(5): 824-840.

- [11] RUSSAKOVSKY O, DENG J, SU H, et al. Imagenet large scale visual recognition challenge[J]. International journal of computer vision, 2015, 115(3): 211-252.
- [12] EIGEN D, PUHRSCHE C, FERGUS R. Depth map prediction from a single image using a multi-scale deep network[C]//Advances in neural information processing systems. 2014: 2366-2374.