

基于深度学习的肺结节 CT 图像自动分割算法优化

刘德洋

安徽中医药大学 医药信息工程学院, 安徽合肥, 231635;

摘要: 肺结节早期准确检测对于肺癌防治至关重要, CT 图像作为肺结节检测的重要手段, 其自动分割算法的优化是当前研究的热点。本文围绕深度学习的肺结节 CT 图像自动分割算法展开, 详细阐述了相关理论基础, 分析了现有算法存在的问题, 并提出了针对性的优化策略, 包括改进损失函数、引入新型卷积模块、融合多尺度特征等。通过实验验证, 优化后的算法在分割精度、召回率等指标上均有显著提升, 为肺结节的准确分割和临床诊断提供了更有效的方法。

关键词: 深度学习; 自动分割算法; 肺结节; CT 图像

DOI:10.69979/3029-2808.24.12.031

1 研究背景与意义

作为全球范围内发病率及病死率均居高不下的恶性肿瘤类型, 早期准确地识别及诊断肺结节对于显著提升肺癌患者的生存率有重要意义。其出色的高空间分辨率及多维图像生成能力, 计算机断层扫描成像技术能够细微地呈现肺组织的结构特征, 成为诊断及量化肺部结节的关键手段。然而, 当前在利用计算机辅助诊断系统解析 CT 影像方面仍面临挑战, 人工解读此类图像不仅耗时费力, 而且其准确性高度依赖于医生的专业知识、临床经验和潜在的主观判断, 增加了漏诊和误诊的可能性^[1]。

因此, 针对肺结节 CT 图像的自动化分割, 利用深度学习开发相关算法展现出卓越的临床应用价值与实践意义, 该算法显著提升了肺结节检测的效能与准确性。

2 理论基础

2.1 深度学习基础

2.1.1 人工神经网络

人工神经网络是深度学习基础框架。其核心神经元呈层次化结构, 有输入层、隐藏层和输出层, 可实现复杂模式识别与决策。神经元靠权重参数互连, 该参数量化连接紧密程度。训练时, 模型通过适配权重参数, 学习输入数据特征与内在模式。其数学模型可以表示为: 对于第 i 个神经元, 其输入 x_i 经过加权求和后, 再通过激活函数 σ 得到输出 y_i ^[2],

$$y_i = \sigma \left(\sum_{j=1}^n w_{ij} x_j + b_i \right),$$

即 $x =$

其中 w_{ij} 是连接第 j 个输入神经元和第 i 个神经元的权重, b_i 是偏置项。

2.1.2 卷积神经网络 (CNN)

卷积神经网络是针对格网结构数据 (如图像) 的深度学习模型, 包括卷积、池化、全连接等层。卷积层滑动卷积核提取局部特征, 池化层缩减特征图维度、增强鲁棒性, 全连接层整合特征^[3], 用于最终分类决策或分割。卷积操作的数学表达式为:

提取的特征进行整合, 输出最终的分类或分割结果, $y_{i,j} = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} x_{i+m,j+n} w_{m,n} + b$, 其中 x 是输入图像, w 是卷积核, b 是偏置项, M 和 N 是卷积核的尺寸。

2.2 医学图像分割概述

2.2.1 医学图像分割的定义与目标

医学图像分割是指将医学图像中的不同组织、器官或病变区域从背景中分离出来过程, 目标是准确地定位和勾勒出感兴趣区域的边界, 为后续的疾病诊断、治疗规划等提供基础^[4]。

2.2.2 医学图像分割的常用方法

医学图像分割技术大致可分为传统的处理策略和深度学习策略, 传统方法包括阈值分割、传统的图像分割技术, 如边缘检测与区域生长, 虽依据图像的灰度值与纹理等属性执行操作, 但在处理复杂医学影像时, 往往难以达到临床所需的精确度与准确性。深度学习策略, 尤其是利用卷积神经网络构建的模型, 凭借其突出的特征捕获效能, 能够自主生成并辨识图像的核心属性与模

式，因此在医学图像分割领域表现出了明显的成效与应用前景。

3 现有算法问题分析与优化策略

3.1 现有肺结节 CT 图像分割算法存在的问题

3.1.1 小目标分割精度不足

肺结节在 CT 图像中通常表现为小目标，现有算法对小尺寸肺结节的分割精度较低。这是因为小目标在图像中所占的像素比例较小，特征信息相对较少，容易被模型忽略。

3.1.2 对复杂肺部结构适应性差

肺部结构复杂，存在多种组织和器官，如血管、气管等，这些结构会干扰肺结节的分割。现有算法对复杂肺部结构的适应性不足，容易将非结节区域误分割为结节，或者遗漏一些位于复杂结构附近的结节。

3.1.3 模型泛化能力有限

由于不同患者的肺部结构和肺结节特征存在差异，以及 CT 扫描设备和参数的不同，现有算法的泛化能力有限。在不同数据集上的分割效果可能会有较大波动。

3.2 优化策略

3.2.1 改进损失函数

传统的交叉熵损失函数在处理不平衡数据时效果不佳，由于肺结节在 CT 图像里所占比例往往较小，为提升肺结节的分割精准度，采取 Dice 损失函数与 Focal 损失函数相结合方式。Dice 损失函数定义为：

$$L_{Dice} = 1 - \frac{2\sum_{i=1}^N p_i g_i}{\sum_{i=1}^N p_i^2 + \sum_{i=1}^N g_i^2}, \text{ 其中 } p_i \text{ 是预测的分割}$$

结果， g_i 是真实的标签， N 是像素的总数。Focal 损失函数则通过对难分类样本增加权重，解决数据不平衡问题，其表达式为： $L_{Focal} = -(1 - p)^\gamma \log(p)$ ，其中 p 是预测概率， γ 是调节因子。组合损失函数为 $L = \alpha L_{Dice} + (1 - \alpha) L_{Focal}$ ，通过调整 α 的值来平衡两种损失函数的作用。

3.2.2 引入新型卷积模块

为提升模型对小目标特征的提取能力，引入可变形卷积模块。该模块在传统卷积的架构上，增加了对偏移量的学习机制。借助这一机制，卷积核能够在图像上开展不规则采样，进而更有效地捕捉小目标的特征^[5]。其数学表达式为： $y(p_0) = \sum_{p_n \in R} w(p_n) \cdot x(p_0 + p_n + \Delta p_n)$ ，其中 p_0 是输出特征图的位置， p_n 是卷积核的位置，

Δp_n 是学习到的偏移量， $w(p_n)$ 是卷积核的权重， x 是输入特征图。

3.2.3 融合多尺度特征

为了增强模型在区分及精确分割不同大小肺结节方面的效能，实施了多级特征融合策略。通过利用多层次卷积神经网络提炼特征并实施特征聚合策略，该模型有效地捕获了肺结节在各类空间尺度下的关键属性。在该框架内，对编码器各个阶段的特征表示进行上采样操作，并将其与解码器相应阶段的特征表示进行整合，进而生成集成的特征表示。

4 优化算法模型

4.1 整体模型架构设计

对优化算法模型进行了基于 U-Net 架构的改进设计，整体架构采用编码器 - 解码器的设计方案。编码器的主要功能是提取图像中的各类特征，而解码器会将提取到的特征映射进行处理，使其恢复到原始图像的尺寸，达成精细程度较高的图像分割。

针对编码器部分，集成了一种可变形卷积模块以强化其在捕获微小目标特征方面的表现。而在解码器环节，则实施了多尺度特征融合策略，旨在提升对各类尺寸肺结节的精确分割能力。

4.2 编码器部分

编码器组件主要由多层卷积层与下采样层组成，每层卷积配置有可变形卷积模块，旨在高效提取图像特征。下采样层运用了最大池化技术，旨在缩减特征图的尺寸。具体地，输入的 CT 影像首先经由可变形卷积层处理，接着经历最大池化阶段，以产出供后续环节利用的输入信息。重复此过程，直至达到最基础的特征图。

4.3 解码器部分

在解码器组件中，主要集成了多层次上采样模块与卷积层。上采样模块借助反卷积运算逐步放大特征图的规模。在每次上采样步骤之后，编码器的每一层特征图均被提升到相应的分辨率等级，接着与解码器生成的特征图进行聚合，从而实现多层次特征的高效集成。随后，借助卷积操作实现特征整合与细化，最终生成分割结果。

4.4 模型训练过程

在模型训练过程中，使用改进的组合损失函数 $L = \alpha L_{Dice} + (1 - \alpha) L_{Focal}$ 调优模型参数。在使用随机

梯度下降优化器时,需要调整学习率和动量等参数来控制模型的训练动态。将训练数据集划分为多个小批次,每个批次集中处理特定数量的 CT 图像及其对应的精确标注,用于模型训练。训练过程中,不断优化模型参数,确保损失函数值递减,直至模型实现收敛。

5 实验设计与结果分析

5.1 实验数据集

本研究选取了公有领域的肺结节计算机断层扫描(CT)图像数据集,即 UIDC-IDRI,作为实验的基础资源。该数据集整合了大规模的患者肺部计算机断层扫描影像以及配套的肺段标注信息。将数据集按照 7: 2: 1 比例划分为训练集、验证集和测试集三部分。

5.2 实验环境与参数设置

实验环境采用 NVIDIA GPU 进行加速计算,使用 PyTorch 深度学习框架实现模型。模型训练的参数设置如下:学习率设置为 0.001,动量设置为 0.9,批次大小设置为 4,训练轮数设置为 100 轮。组合损失函数中的 α 值设置为 0.5。

5.3 评价指标

使用 Dice 系数、采用交并比 (IoU)、召回率 (Recall) 和精确率 (Precision) 作为评估指标来度量分割效果。Dice 系数被用于度量预测分割与真实标注之间的匹配程度,其计算逻辑如上所述^[6]。LOU 被界定为预测分割区域与真实标签区域交集面积与两者的联合面积的比例值。

$$\text{IoU} = \frac{\sum_{i=1}^N p_i g_i}{\sum_{i=1}^N p_i + \sum_{i=1}^N g_i - \sum_{i=1}^N p_i g_i}$$

Recall 衡量的是模型准确标识出的肺结节面积与实际存在的肺结节面积之间的比率,而 Precision 代表模型判定为肺结节的区域中,确实属于肺结节的比例。

5.4 实验结果与分析

5.4.1 不同损失函数的实验结果比较

比较了使用传统交叉熵损失函数、Dice 损失函数、Focal 损失函数和组合损失函数的分割结果。实验结果表明,组合损失函数在 Dice 系数、IoU、召回率和精确率等指标上均优于其他,组合损失函数能够更好地平衡不同类别的分割精度,提高对肺结节的分割效果。

表 1 不同损失函数的实验结果比较

损失函数	Dice 系数	交并比	召回率	精确率
交叉熵损失函数	0.70	0.54	0.72	0.75
Dice 损失函数	0.73	0.58	0.75	0.77
Focal 损失函数	0.74	0.59	0.76	0.78
组合损失函数	0.78	0.64	0.80	0.82

5.4.2 引入可变形卷积模块的实验结果比较

在分割任务的背景下,比较分析了基础 U-Net 模型与集成可变形卷积模块的模型的表现差异。基于实验数据分析,集成可变形卷积模块后,所述模型在各个评价指标上的性能展现出显著提升。据此得出结论,可变形卷积模块具备显著增强模型在微小目标特征捕获方面的效能,从而有效提升了对于细小肺结节分割精度的能力。

表 2 引入可变形卷积模块的实验结果比较

损失函数	Dice 系数	交并比	召回率	精确率
原始 U-Net	0.73	0.58	0.75	0.77
引入可变形卷积的 U-Net	0.76	0.61	0.78	0.79

6 结论与展望

本文针对基于深度学习的肺结节 CT 图像自动分割算法进行了优化。通过改进损失函数、引入可变形卷积模块和融合多尺度特征等策略,提高了肺结节分割的精度和模型的泛化能力。实验结果表明,优化后的算法在 Dice 系数、交并比、召回率和精确率等指标上都有显著提升,能够更准确地分割肺结节,为临床诊断提供更可靠的支持。

参考文献

- [1]徐茂丽,阮志兵,刘欢,等.基于增强 CT 影像组学鉴别胰腺癌与肿块型慢性胰腺炎的价值[J].贵州医科大学学报,2022,47(11):1325-1331.
- [2]李聂.针对转移性肝癌的 CT 图像分类与靶向点预测研究[D].河北大学,2023.
- [3]刘政君.基于深度学习的多模态目标识别技术研究[D].西安工业大学,2024.
- [4]唐琴,刘志勤,王庆凤,等.基于混合损失注意力的 CT 气胸自动分割与量化[J].计算机应用与软件,2024,41(12):214-222.
- [5]任鑫.基于深度学习的交通标志检测识别研究[D].中北大学,2024.
- [6]刘金辉,童晶,倪佳佳,等.基于改进 U-Net 的下肢骨骼 CT 图像分割[J].计算机系统应用,2022,31(10):134-141.