

基于深度学习的候选结节检测算法

张彩娣¹, 李岳阳², 崔方正², 罗海驰³, 顾中轩²

1. 江南大学附属医院呼吸内科, 江苏 无锡 214122; 2. 江南大学人工智能与计算机学院, 江苏 无锡 214122; 3. 江南大学物理网工程学院, 江苏 无锡 214122

【摘要】为提高候选结节检测性能,应用深度学习技术提出基于3DSCANet的候选结节检测算法。该算法提出增强坐标注意力机制模块(SCA),在坐标注意力机制的基础上做出改进,使之能提取三维(3D)特征,并引入自适应卷积提取跨通道特征,增加SCA注意力机制的特征提取能力;提出一种将3D长方体锚框转换为3D球体的方法,并进一步引入新的球体交并比损失函数SIoUX,以充分利用肺结节的球体形态特征。在实验阶段,该方法在LUNA16数据集上采用十折交叉验证的方法进行测试,平均召回率CPM达到0.94。

【关键词】候选结节检测;计算机辅助检测;增强坐标注意力机制模块;球体损失函数

【中图分类号】R318;TP391.4

【文献标志码】A

【文章编号】1005-202X(2024)09-1177-08

Nodule candidate detection algorithm based on deep learning

ZHANG Caidi¹, LI Yueyang², CUI Fangzheng², LUO Haichi³, GU Zhongxuan²

1. Department of Respiration, Affiliated Hospital of Jiangnan University, Wuxi 214122, China; 2. School of Artificial Intelligence and Computer Science, Jiangnan University, Wuxi 214122, China; 3. School of Internet of Things Engineering, Jiangnan University, Wuxi 214122, China

Abstract: A nodule candidate detection algorithm based on 3DSCANet utilizing deep learning techniques is proposed to improve nodule candidate detection performance. The algorithm employs a strengthen coordinate attention (SCA) module which improves upon the basic coordinate attention mechanism to enable it to extract three-dimensional (3D) features, and incorporates adaptive convolution to extract cross-channel features, thereby enhancing the feature extraction capability of the SCA mechanism. Additionally, a method to convert 3D rectangular anchor boxes into 3D spheres is proposed, along with the introduction of a sphere based intersection over union loss function (SIoUX) to fully leverage the morphological characteristics of lung nodules which are spherical in shape. During the experimental phase, the method is tested on the LUNA16 dataset using ten-fold cross-validation, and it achieves an average recall rate of 0.94.

Keywords: nodule candidate detection; computer-aided detection; strengthen coordinate attention module; sphere based loss function

前言

候选结节检测通过对肺部CT影像进行分析,自动识别候选结节,并将其标记,辅助医生在更短的时间内诊断肺结节是否为恶性肿瘤^[1]。候选结节检测是计算机辅助检测系统中的关键步骤,对肺结节的

检出效果具有决定性作用。但肺结节在大小、形状和密度上的多样性使得肺结节检测极具难度,此外肺部CT图像可能受到多种干扰因素的影响,如噪声、伪影和血管等,这些因素可能模糊了肺结节的边缘或导致假阳性结果,增加肺结节检测任务的难度。随着计算机视觉技术在医学图像上的广泛应用和深度学习方法的不断发展,基于深度学习技术的肺结节检测方法越来越受到关注^[2-5]。Ramachandran等^[6]提出一种基于YOLO的二维肺结节检测网络,但二维检测网络只考虑到图像的二维信息,无法考虑到结节在三维(3D)空间中的位置和形态,因此一些与肺结节相关的空间特征可能会丢失。针对这个问题,Zhu等^[7]提出DeepLung,利用肺部CT数据的3D

【收稿日期】2024-02-23

【基金项目】国家自然科学基金联合基金(U1836218)

【作者简介】张彩娣,硕士,主任医师,研究方向:医学图像处理、人工智能,E-mail: 15301516381@163.com

【通信作者】李岳阳,博士,副教授,研究方向:医学图像处理、人工智能,E-mail: lyueyang@jiangnan.edu.cn

特性和紧凑的双路径网络(DPN),设计两个深度的3D DPN,一个用于结节检测,另一个用于结节分类。Baumgartner 等^[8]采用3DRetinaNet的网络架构,对nnU-Net^[9]进行改进,使其适用于3D肺结节检测,并提出一种简单高效的基于Anchor-base的检测网络:Retina U-Net。但由于3D肺部CT影像中的肺结节与胸膜、气管和肺部血管等组织互相遮挡,现有检测模型效果不理想,假阳性率偏高,同时现有检测模型很少利用肺结节的类球体形态特征。因此,本研究提出增强坐标注意力机制模块(SCA),该模块通过注意力机制有效提取3D特征,同时为了充分利用肺结节的类球体形态学特征,提出一种将3D长方体锚框转换成3D球体的方法,并进一步提出新的球体交并比损失函数SIoUX,与其他模型相比,本研究提出的模型可以显著提升肺结节检测效果。

1 算法原理

1.1 模型总体结构

由于CT图像中的肺结节是具有尺寸、形状多样

性的类球体小目标,且不同结节样本之间存在较大的形态差异,因此多尺度特征提取更适用于肺结节检测。本文提出的候选结节检测模型总体结构如图1所示。输入 $512\times512\times N$ (N 为CT图像的深度)的3D数据块,采用大小为 $96\times96\times80$ 的滑动窗口对输入图像进行检测,输出的锚框加上滑动偏移量就是候选结节检测框的具体位置。选用3DSCANet作为主干网络,3DSCANet主要分为4个阶段,每个阶段包含若干个由3D ResBlock和SCA构成的模块,数量分别为3、4、6、3,在这些阶段之间采用池化层进行下采样操作,用来缩小特征图分辨率,提取更高层次的特征。将主干网络的最后3层特征图传递给特征金字塔网络,进行多尺度特征融合的操作。随后,通过两个不同的子网络,即分类子网络和回归子网络,分别提取并输出关于候选结节框的信息。其中,分类子网络用于确定候选结节框的置信度,表明其是否包含结节,而回归子网络负责预测候选结节框的中心坐标和直径。根据肺结节类球体的形态特征,在训练过程中引入球体交并比损失函数SIoUX。

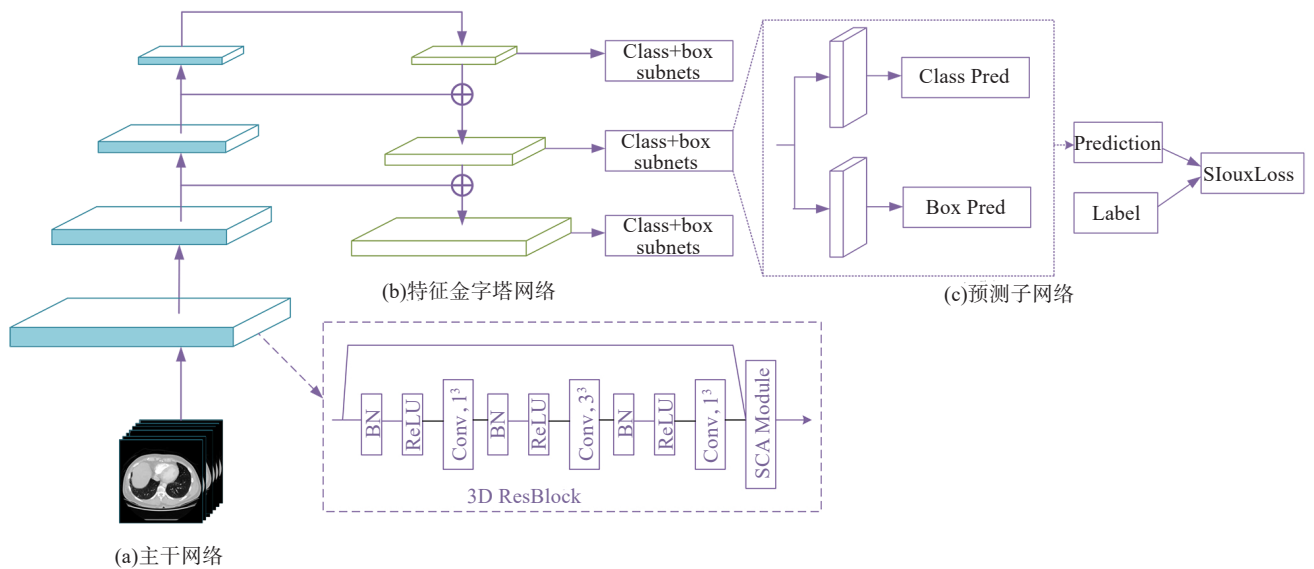


图1 模型总体结构

Figure 1 Overall structure of the model

1.2 SCA

近年来,注意力机制在特征提取网络中的运用越来越广泛。最新研究成果表明,通道注意力机制对于提升特征提取网络性能具有显著作用^[10]。但通道注意力机制也存在缺点,往往只注意张量的通道信息,忽略了位置信息。而位置信息对于生成具有空间选择性的特征图非常重要。Hou等^[11]提出坐标

注意力机制(Coordinate Attention, CA)解决了该问题,将通道注意力分解为两个一维特征编码过程分布沿着两个空间方向聚合。本文对CA进行改进,提出SCA,使之能适用于3D目标检测的特征提取网络,并采用自适应卷积(ConvAS)^[12]捕捉相邻通道的信息,SCA的结构如图2所示。

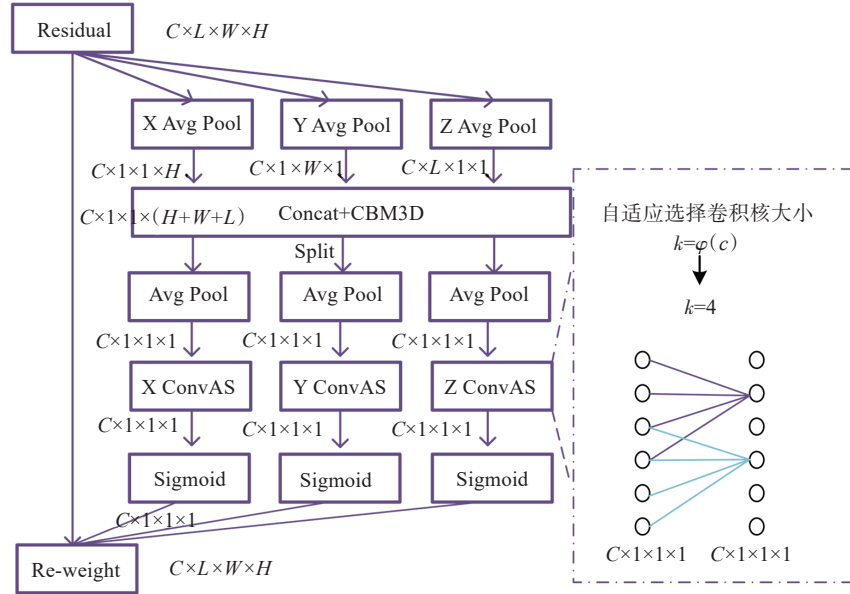


图2 SCA结构图

Figure 2 Structure diagram of strengthen coordinate attention module

假设输入的特征向量 \mathbf{x} 为 $C \times L \times H \times W$, 其中 C, L, H 和 W 分别表示通道、深度、高度和宽度的尺寸大小。首先, 使用3种不同的池化核大小 $(H, 1, 1)$ 、 $(1, W, 1)$ 和 $(1, 1, L)$ 分别对每个通道沿着高度、宽度以及深度进行编码。通道 c 上高度 h 的特征输出可以表述为:

$$\mathbf{z}_c^h = \frac{1}{W \times L} \sum_{j=0}^W \sum_{m=0}^L \mathbf{x}_c(h, j, m) \quad (1)$$

同样地, 通道 c 上宽度 w 和深度 l 的特征输出可以分别表述为:

$$\mathbf{z}_c^w = \frac{1}{H \times L} \sum_{i=0}^H \sum_{m=0}^L \mathbf{x}_c(i, w, m) \quad (2)$$

$$\mathbf{z}_c^l = \frac{1}{H \times W} \sum_{i=0}^H \sum_{j=0}^W \mathbf{x}_c(i, j, l) \quad (3)$$

将特征向量 \mathbf{z}_c^h 、 \mathbf{z}_c^w 和 \mathbf{z}_c^l 在通道 c 上进行拼接, 并经过一次 CBM 操作 (卷积+归一化+激活函数) 得到包含位置信息的坐标特征 \mathbf{x}'_c :

$$\mathbf{x}'_c = \text{CBM}(\text{concat}(\mathbf{z}_c^h, \mathbf{z}_c^w, \mathbf{z}_c^l)) \quad (4)$$

为了精确捕捉通道间的关系, CA 运用卷积的方法再次将特征沿着 (H, W, L) 编码以便得到更精确的通道特征。与 CA 不同的是, 本文采用一种自适应卷积方法动态调整卷积核大小, 从而实现跨通道交互。通常卷积核大小 k 与通道数 c 成正比, 即 k 和 c 之间可能存在映射 ϕ :

$$c = \phi(k) \quad (5)$$

最简单的映射是线性函数, 即 $\phi(k) = \gamma k - b$, 但是因为线性函数对于某些相关特征具有局限性, 且通道数通常是 2 的指数倍, 因此采用 2 为底的指数函

数表示非线性映射关系:

$$c = \phi(k) = 2^{(\gamma k - b)} \quad (6)$$

因此, 当通道数 c 固定时, 卷积核大小 k 可以通过如下公式得到:

$$k = \psi(c) = \left\lceil \frac{\log_2 c}{\gamma} + \frac{b}{\gamma} \right\rceil \quad (7)$$

本文所有实验将 γ 和 b 设置为 2 和 1。高维特征通过非线性映射具有更远的通道信息交互, 而低维特征经历更短范围的通道信息交互。与普通卷积相比, 自适应卷积更适合捕捉通道间的关系。将坐标特征 \mathbf{x}'_c 沿着 (H, W, L) 分解经过平均池化层后得到转换特征 \mathbf{x}'_h 、 \mathbf{x}'_w 和 \mathbf{x}'_l , 分别经过 ConvAS, 得到基于通道 c 的一维特征权重 w , 最后输入特征图乘以通道权重得到输出 \mathbf{x}_{out} :

$$\mathbf{x}_{\text{out}} = \mathbf{x} \times \sigma(\text{ConvAS}(\mathbf{x}'_h)) \times \sigma(\text{ConvAS}(\mathbf{x}'_w)) \times \sigma(\text{ConvAS}(\mathbf{x}'_l)) \quad (8)$$

其中, σ 表示激活函数。

SCA 同通道注意力机制一样, 如图 1 所示, 插入在残差块 ResBlock 的后方。本文选用 3DResNet 和 SCA 注意力模块一起构成主干网络 3DSCANet 对肺部 CT 图像数据进行特征提取。

1.3 基于 SLoUX 的 3D 目标检测损失函数

由于肺结节类球体的形状特性, 在临床肺结节诊断中, 通常使用结节中心坐标和结节直径来表示 3D 空间中的肺结节。因此, 肺结节检测结果用 3D 球体锚框比 3D 长方体锚框能更好地描述肺结节的形状特征。本文采用的是一种 Anchor Base 的目标检测方

法,其输出的是3D长方体锚框。因此将3D长方体锚框转换成3D球体锚框,不仅可以更好地表示模型检出的肺结节的真实形状,还可以更方便地与原本类球体的标签做损失比较,在几何层面上提高模型的检出能力。

本文提出一种将3D长方体锚框转换成3D球体的方法(Anchor to Sphere, ATS)。如图3所示,假设锚框的中心点为 o ,长宽高分别为 dx 、 dy 和 dz ,取该锚框的最小相切球体作为输出。




图3 3D锚框自适应转换成球体示意图

Figure 3 Schematic diagram of adaptively converting 3D anchor box into 3D sphere

最小相切球体的直径就是 dx 、 dy 和 dz 的最小值,球体的半径 R 计算公式如下:

$$R = \frac{\min(dx, dy, dz)}{2} \quad (9)$$

CPMNet^[13]基于肺结节的类球体特性,提出球体交并比(Sphere based Intersection-over-Union, SIoU)。SIoU可以定义为:

$$\text{SIoU} = \frac{|S^a \cap S^b|}{|S^a \cup S^b|} \quad (10)$$

其中, S^a 和 S^b 分别表示预测球体和标签的球体。SIoU的各个计算指标定义如图4所示。




图4 SIoU示意图

Figure 4 Schematic diagram of SIoU

设两个球体的质心分别为 $A(x_1, y_1, z_1)$ 和 $B(x_2, y_2, z_2)$ 。 r^a 和 r^b 代表球体 A 和 B 的半径, d^{AB} 表示两个质心之间的欧式距离。当球体 AB 不相交时, $r^a + r^b \leq d^{AB}$, $|S^a \cap S^b|$ 为0。当球体 AB 相交时, $r^a + r^b > d^{AB}$ 。 ϕ^a 和 ϕ^b 表示两个球体的中心角,设 ϕ^{ab} 表示交角, h_1 和 h_2 表示相交弦与弧的距离。则 $|S^a \cap S^b|$ 和 $|S^a \cup S^b|$ 可以通过如下公式计算:

$$\cos(\phi^a) = \frac{(r^a)^2 + (d^{AB})^2 - (r^b)^2}{2r^a d^{AB}} \quad (11)$$

$$\cos(\phi^b) = \frac{(r^b)^2 + (d^{AB})^2 - (r^a)^2}{2r^b d^{AB}} \quad (12)$$

$$\cos(\phi^{ab}) = \frac{(r^a)^2 + (r^b)^2 - (d^{AB})^2}{2r^a r^b} \quad (13)$$

$$h_1 = r^b (1 - \cos(\phi^b)) \quad (14)$$

$$h_2 = r^a (1 - \cos(\phi^a)) \quad (15)$$

$$|S^a \cap S^b| = \pi r^a h_2^2 - \frac{\pi h_2^3}{3} + \pi r^b h_1^2 - \frac{\pi h_1^3}{3} \quad (16)$$

$$|S^a \cup S^b| = \frac{4\pi((r^a)^3 + (r^b)^3)}{3} - |S^a \cap S^b| \quad (17)$$

代入式(10)计算可以得到SIoU。那么球体损失函数可以表示为:

$$L_{\text{SIoU}} = 1 - \text{SIoU} \quad (18)$$

与传统的IoU损失一样, L_{SIoU} 仅在预测球体和ground truth球体相交时有效。为了处理两个球体不相交的情况,引入距离和半径的比值 R_{DR} 进行优化:

$$R_{\text{DR}} = \frac{d^{AB}}{d^{AB} + r^a + r^b} \quad (19)$$

另外,球体的交角 ϕ^{ab} 也可以描述球体的回归损失 η :

$$\eta = \begin{cases} 0, & \text{if } d^{AB} \geq (r^a + r^b) \\ \frac{\arccos(\cos(\phi))}{\pi}, & \text{otherwise} \end{cases} \quad (20)$$

将描述几何信息的损失球面SIoU[式(18)]、距离半径比 R_{DR} [式(19)]和交角 η [式(20)]整合为一个联合损失 $L_{\text{SIoU}++}$:

$$L_{\text{SIoU}++} = \begin{cases} R_{\text{DR}}, & \text{if } d^{AB} \geq (r^a + r^b) \\ 1 - \text{SIoU} + R_{\text{DR}} + \eta, & \text{otherwise} \end{cases} \quad (21)$$

$L_{\text{SIoU}++}$ 是基于Anchor Free的方法,对球体的坐标和半径进行损失计算。而本文基于Anchor base的框架利用自适应方法ATS[式(9)],将坐标转换为球体半径 R 以此来使用 $L_{\text{SIoU}++}$ 计算损失。这一过程实际上已经是将Anchor Free的损失函数跨界应用到

Anchor base 的检测框架上,故本文将这种损失函数计算方法命名为 SIoUX。

$$L_{\text{SIoUX}} = \begin{cases} \frac{d^{AB}}{d^{AB} + r^a + r^b}, & \text{if } d^{AB} \geq (r^a + r^b) \\ 1 - \text{SIoU} + \frac{d^{AB}}{d^{AB} + r^a + r^b} + \eta, & \text{otherwise} \end{cases} \quad (22)$$

本文对肺结节的损失计算函数 L_{total} 可以表示为:

$$L_{\text{total}} = L_{\text{cls}} + \alpha L_{\text{SIoUX}} + (1 - \alpha) L_{\text{smoothL1}} \quad (23)$$

其中, L_{cls} 为交叉熵,表示对检测目标的分类; α 为权重系数,设置为 0.2; L_{smoothL1} 表示 SmoothL1 损失,相较于 L1 损失改进了零点不平滑问题。

2 结果与分析

2.1 实验数据集

为了验证检测框架对肺结节的检出能力,本章实验采用 Lung Nodule Analysis 2016 数据集(以下简称 LUNA16),LUNA16 是在肺结节检测领域公认的研究性数据集,由 888 个低剂量扫描的 CT 图像构成,包含专业放射科医生标注位置和大小 1 186 个阳性结节,结节大小为 3~30 mm。该数据集分为 10 个子集,使用十折交叉验证的方法进行验证比较。

2.2 数据预处理

肺质分割是肺结节检测的第一步,通过肺实质分割可以剔除 CT 扫描图像中很多无关的病灶和组织^[14]。在原始 CT 图像中,采集得到的是 X 射线衰减值,单位为 HU。物质的 CT 值反映其密度,CT 值越高表示物质密度越高。肺部的 HU 值约为 -500,因此在对肺部进行实质分割时,可将阈值区间设为 [-1 000, 400],即 HU 值大于 400 的值置为 400, HU 值小于 -1 000 的值置为 -1 000;然后可使用归一化方法将 HU 值转换至 [0, 255] 内。

LUNA16 数据集的存储格式为 mhd+raw, mhd 格式数据存放数据的非图像信息,如图像大小、切片大小、像素大小等, raw 存储 3D 图像数据。LUNA16 数据集使用世界坐标描述结节的具体位置,为了便于坐标计算,本文将结节的世界坐标 v_{world} 转换成体素坐标 v_{voxel} :

$$v_{\text{voxel}} = \frac{v_{\text{world}} - v_{\text{origin}}}{d_{\text{spacing}}} \quad (24)$$

其中, v_{origin} 表示肺部中心点坐标, d_{spacing} 表示像素间隔。为了提高数据读取效率,本文将处理后的肺部 CT 保存成 nii.gz 的格式以便读取。

2.3 评价指标

LUNA16 数据集采用非限制受试者工作特征曲线 (Free-Response Receiver Operating Characteristic Curve, FROC) 作为评价指标。FROC 曲线表示平均

每个样本检测出的假阳性样本的数量与灵敏度的关系^[15]。曲线的横坐标表示平均假阳性数量 (False Positives Per Scan, FPPS), 又称为假阳性率 (False Positive Rate, FPR), 纵坐标表示灵敏度 (Sensitivity)。灵敏度的计算方法如下:

$$\text{Sensitivity} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (25)$$

其中, TP 表示样本结节被正确检测的数量, FN 表示样本结节未被检出的数量。

LUNA16 采用平均召回率 CPM 作为得分标准, 即取 FROC 曲线中 7 个具有代表性的 FPR 对应的灵敏度的平均值:

$$\text{CPM} = \frac{1}{N} \sum_i^d \text{Sensitivity}_{\text{FPR} = i} \quad (26)$$

其中, d 为 {0.125, 0.25, 0.5, 1, 2, 4, 8}。CPM 得分越高表示模型性能越好。

2.4 实验环境及参数设置

本文所用实验平台是 Linux, 操作系统是 Ubuntu20.04, 所用显卡为 4 块 NVIDIA GeForce3090, 开发语言是 Python, 深度学习框架是 Pytorch1.11。训练过程中参数主要包含初始学习率、衰减率、批大小以及 Epoch。初始学习率和衰减率影响着模型能否及时收敛, 经过测试, 本实验将初始学习率和衰减率分别设置为 0.001 和 0.000 03。批大小是每批次中训练样本数量, 为了平衡效率和内存容量, 本实验将批大小设置为 4。Epoch 表示用训练集中全部样本训练的次数, 本实验的 Epoch 设置为 350。

2.5 实验结果与分析

2.5.1 消融实验 本文与现有的检测方法对比创新点主要表现在两个方面: 添加了 SCA 来提高主干网络的特征提取能力; 根据肺结节类球体的特性引入球体交并比损失函数 SIoUX 来约束模型训练过程中的收敛效果。为了验证以上两个模块的有效性, 本文针对两个模块进行消融实验。由于十折交叉验证训练时间较长, 因此本文的消融实验部分采用训练集、验证集和测试集比例为 8:1:1 的划分进行。如表 1 所示, 本文针对 SCA 模块做了消融实验, 主要是为了验证自适应卷积方法 ConvAS 的有效性, 与普通的 3D 卷积相比, 采用跨通道自适应卷积 ConvAS 后, CPM 上升 0.3%。

如表 2 所示, 本文使用 nnDetection^[8] 在 LUNA16 上按照划分的数据集的复现结果作为 Baseline。表 2 第 2 行同 Baseline 相比在检测损失上添加 SIoUX, CPM 同 Baseline 相比增加 1.6%, 由此可知在引入了球体交并比损失函数 SIoUX 后, 模型的检出能力有了一定的提升。为了验证 SCA 注意力机制的有效

表 1 SCA 模块消融实验
Table 1 Ablation study of SCA modules

模块	灵敏度							CPM
	FPPS=0.125	FPPS=0.25	FPPS=0.5	FPPS=1	FPPS=2	FPPS=4	FPPS=8	
ConvAS	0.830	0.884	0.911	0.955	0.964	0.974	0.981	0.929
Conv3D	0.825	0.885	0.911	0.952	0.964	0.968	0.979	0.926

性,本文在 Baseline 的基础上添加通道注意力 SE 模块,使得 ResNet 变换成 SENet。表 2 第 3 行结果证明在损失函数没有改变的情况下对主干网络添加注意力机制,可以使得 CPM 有 0.6% 的提升。表 2 第 4 行是在 ResNet 的基础上添加 SCA 模块,可见 SCA 模块的引入,改进了主干网络的特征提取能力,相较于使用 SENet,在 CPM 上有了 0.7% 的提升。表 2 第 5 行是

同时添加了 SCA 模块和球体交并比损失的结果,同 Baseline 相比,CPM 提升 1.9%。在引入 SCA 模块和 SIoUX 后,模型在低 FPPS,如 0.125、0.25 和 0.5 FPPS 对应的灵敏度有了部分提升。相较于采用以 ResNet 为主干网络和 SmothL1 为损失函数的 Baseline,平均召回率 CPM 有了部分提升。

表 2 不同模块组合消融实验
Table 2 Ablation study of different module combinations

模块	灵敏度							CPM
	FPPS=0.125	FPPS=0.25	FPPS=0.5	FPPS=1	FPPS=2	FPPS=4	FPPS=8	
Baseline(ResNet+SmothL1)	0.821	0.839	0.920	0.938	0.952	0.965	0.975	0.916
ResNet+SmothL1+SIouxLoss	0.813	0.875	0.919	0.946	0.982	0.990	0.991	0.932
SENet+SmothL1	0.830	0.848	0.920	0.938	0.960	0.981	0.982	0.922
SCANet+SmothL1	0.830	0.884	0.911	0.955	0.964	0.974	0.981	0.929
SCANet+SmothL1+SIouxLoss	0.848	0.875	0.929	0.955	0.964	0.982	0.991	0.935

2.5.2 现有检测算法比较 为了验证本文提出的肺结节检测算法的有效性,本文使用检测模型在 LUNA16 数据集上做了十折交叉验证,并选取部分现有检测算法^[16-22]进行对比,如表 3 所示。与其他方法相比,

本文方法在 FPPS 为 0.25 时略逊色于 nnDetection (BaseLine),但是在其他 FROC 指标上相比其他方法表现较好,十折交叉验证的平均召回率 CPM 达到 0.94。

表 3 现有算法比较结果
Table 3 Comparison with the existing methods

方法	灵敏度							CPM
	FPPS=0.125	FPPS=0.25	FPPS=0.5	FPPS=1	FPPS=2	FPPS=4	FPPS=8	
Khosravan 等 ^[16] ,2018 年	0.709	0.838	0.921	0.953	0.953	0.953	0.953	0.897
Liao 等 ^[17] ,2019 年	0.817	0.851	0.869	0.883	0.891	0.907	0.914	0.878
Tang 等 ^[18] ,2019 年	0.629	0.701	0.784	0.844	0.897	0.931	0.955	0.820
Liu 等 ^[19] ,2019 年	0.848	0.875	0.905	0.933	0.943	0.957	0.970	0.919
Song 等 ^[13] ,2020 年	0.723	0.838	0.887	0.911	0.928	0.934	0.948	0.881
Baumgartner 等 ^[8] ,2021 年	0.812	0.885	0.927	0.950	0.969	0.979	0.985	0.930
Zhou 等 ^[20] ,2022 年	0.742	0.840	0.899	0.925	0.944	0.954	0.959	0.895
Mei 等 ^[21] ,2022 年	0.718	0.802	0.865	0.901	0.937	0.946	0.988	0.874
Akila Agnes 等 ^[22] ,2022 年	0.803	0.875	0.927	0.959	0.967	0.979	0.981	0.930
本文方法	0.848	0.875	0.929	0.964	0.982	0.989	0.993	0.940

2.5.3 可视化展示 为了直观展示模型的检测效果,图5展示了一阶段候选结节检测效果较好的部分结节的预测框和真实框的对比。本文选取结节预测中心点所在的切片(Z轴)做了可视化处理,在X轴和Y轴上进行标注(左边一列为切片显示图,右边一列为检测结果放大图),其中红色框为预测框,黄色框为真实框。图5a展示结节直径为13.5 mm的实性结节检测结果,预测框基本与真实框重合,本文的检测网络对于较大直径结节的检出效果比较好。图5b展示结节直径为3.9 mm的磨玻璃结节的检测结果,预测框相对于真实框检出区间较小,但是位置基本无误。经过对检测结果的分析,发现检出的假阳性结节的直径一般在10 mm以下。




图5 检测出的高置信度候选框及其对应的真实框
Figure 5 Detected high-confidence candidate boxes and the corresponding ground truth boxes

图6显示了部分一阶段候选结节检测过程中出现直径小于10 mm的假阳性结节,其中图6a、图6c、图6e检出的假阳性结节密度较高能够掩盖正常的肺纹理,形状特征完全与实性结节相同,这给候选结节检测带来非常大的负面影响,容易造成误检。图6d中检出的假阳性结节呈云雾状,形态特征类似磨玻璃结节,这也给检测带来一定难度。图6b、图6f检出的假阳性结节在形态上与肺结节并无太关联,但

是仍然造成误检。这说明在候选结节检测的过程中,不可避免地检出大量无关的假阳性肺结节,因此添加假阳性减少算法,使用二阶段的方法对候选结节检出的结果进行复检,可以大幅度提高肺结节计算机辅助检测系统的检测精确度。




图6 检测出的部分高置信度假阳性结节
Figure 6 Some detected high-confidence false positive nodules

3 总结与展望

本文基于3DSCANet的目标检测网络,利用滑动窗口的方法对输入的CT图像进行候选结节检测,并对网络进行优化改进,主要有两个方面:(1)提出SCA增强空间特征注意力机制模块,相较于坐标注意力机制,SCA注意力机制能够提取3D特征,且引入自适应卷积,提升跨通道特征提取的能力。通过引入SCA注意力机制,优化主干网络的特征提取能力。(2)针对肺结节类球体形态学特征,提出一种ATS方法,将3D长方体锚框转换成3D球体,进而构建出包含ATS转换的球体损失计算方法SIoUX,适配Anchor-base检测方法。实验结果表明引入形态信息可以显著提升结节检测效果。

在与其他候选结节检测网络进行对比实验中,本文方法取得有竞争力的结果,提出的候选结节检测算法平均召回率达到0.94。然而,候选结节检测中容易出现大量假阳性结节,在后续的工作可以引入假阳性减少算法进一步提升肺结节检测模型的性能^[23-25]。

【参考文献】

- [1] 邢学忠, 高燕宁, 张德超. 肺癌的早期诊断[J]. 癌症, 2003, 22(2): 221-223.
Xing XZ, Gao YN, Zhang DC. Early diagnosis of lung cancer[J]. Chinese Journal of Cancer, 2003, 22(2): 221-223.
- [2] 王杜春, 任龙, 刘宁川, 等. 人工智能+医学影像在肺结节检测中的应用研究[J]. 影像研究与医学应用, 2019, 3(16): 39-41.
Wang DC, Ren L, Liu NC, et al. Application of artificial intelligence and medical imaging in the detection of pulmonary nodules[J]. Journal of Imaging Research and Medical Applications, 2019, 3(16): 39-41.
- [3] Zhou ZW, Sodha V, Rahman Siddiquee MM, et al. Models genesis: generic autodidactic models for 3D medical image analysis[C]//Medical Image Computing and Computer Assisted Intervention-MICCAI 2019. Cham: Springer International Publishing, 2019: 384-393.
- [4] Harsono IW, Liawatimena S, Cenggoro TW. Lung nodule detection and classification from Thorax CT-scan using RetinaNet with transfer learning[J]. J King Saud Univ-Comput Inf Sci, 2022, 34(3): 567-577.
- [5] Yang J, Jiang LF, Xie K, et al. Lung nodule detection algorithm based on rank correlation causal structure learning[J]. Expert Syst Appl, 2023, 216: 119381.
- [6] Ramachandran S, George J, Skaria S, et al. Using YOLO based deep learning network for real time detection and localization of lung nodules from low dose CT scans[C]//Proceedings Volume 10575, Medical Imaging 2018: Computer-Aided Diagnosis. Bellingham, WA, USA: SPIE, 2018: 105751I.
- [7] Zhu WT, Liu CC, Fan W, et al. DeepLung: deep 3D dual path nets for automated pulmonary nodule detection and classification[C]//2018 IEEE Winter Conference on Applications of Computer Vision (WACV). Piscataway, NJ, USA: IEEE, 2018: 673-681.
- [8] Baumgartner M, Jäger PF, Isensee F, et al. nnDetection: a self-configuring method for medical object detection[C]//Medical Image Computing and Computer Assisted Intervention-MICCAI 2021. Cham: Springer International Publishing, 2021: 530-539.
- [9] Isensee F, Jaeger PF, Kohl SA, et al. nnU-Net: a self-configuring method for deep learning-based biomedical image segmentation[J]. Nat Methods, 2021, 18(2): 203-211.
- [10] Hu J, Shen L, Sun G. Squeeze-and-excitation networks [C]//Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2018: 7132-7141.
- [11] Hou QB, Zhou DQ, Feng JS. Coordinate attention for efficient mobile network design[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2021: 13708-13717.
- [12] Wang QL, Wu BG, Zhu PF, et al. ECA-net: efficient channel attention for deep convolutional neural networks [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2020: 11531-11539.
- [13] Song T, Chen JE, Luo XD, et al. CPM-net: a 3D center-points matching network for pulmonary nodule detection in CT scans[C]//Medical Image Computing and Computer Assisted Intervention-MICCAI 2020. Cham: Springer International Publishing, 2020: 550-559.
- [14] Sun J, Ma B, Liang H, et al. Research on the clinical value of CT in diagnosing peripheral lung cancer clinical staging [C]//2018 International Conference on Biomedical Engineering, Machinery and Earth Science. Cham: WOP in Engineering and Science Research, 2018: 77-80.
- [15] Moskowitz CS. Using free-response receiver operating characteristic curves to assess the accuracy of machine diagnosis of cancer[J]. JAMA, 2017, 318(22): 2250-2251.
- [16] Khosravan N, Bagci U. S4ND: single-shot single-scale lung nodule detection [C]//Medical Image Computing and Computer Assisted Intervention-MICCAI 2018. Cham: Springer International Publishing, 2018: 794-802.
- [17] Liao FZ, Liang M, Li Z, et al. Evaluate the malignancy of pulmonary nodules using the 3-D deep leaky noisy-OR network[J]. IEEE Trans Neural Netw Learn Syst, 2019, 30(11): 3484-3495.
- [18] Tang H, Zhang CP, Xie XH. NoduleNet: decoupled false positive reduction for pulmonary nodule detection and segmentation[C]//Medical Image Computing and Computer Assisted Intervention-MICCAI 2019. Cham: Springer International Publishing, 2019: 266-274.
- [19] Liu JY, Cao LL, Akin O, et al. 3DFPN-HS2: 3D feature pyramid network based high sensitivity and specificity pulmonary nodule detection [C]//Medical Image Computing and Computer Assisted Intervention-MICCAI 2019: 22nd International Conference, Shenzhen, China, October 13-17, 2019, Proceedings, Part VI. Heidelberg: Springer-Verlag, 2019: 513-521.
- [20] Zhou ZX, Gou FF, Tan YL, et al. A cascaded multi-stage framework for automatic detection and segmentation of pulmonary nodules in developing countries[J]. IEEE J Biomed Health Inform, 2022, 26(11): 5619-5630.
- [21] Mei J, Cheng MM, Xu G, et al. SANet: a slice-aware network for pulmonary nodule detection[J]. IEEE Trans Pattern Anal Mach Intell, 2022, 44(8): 4374-4387.
- [22] Akila Agnes S, Anitha J, Arun Solomon A. Two-stage lung nodule detection framework using enhanced UNet and convolutional LSTM networks in CT images[J]. Comput Biol Med, 2022, 149: 106059.
- [23] Gu ZX, Li YY, Luo HC, et al. Cross attention guided multi-scale feature fusion for false-positive reduction in pulmonary nodule detection[J]. Comput Biol Med, 2022, 151(Pt A): 106302.
- [24] Lu XQ, Gu Y, Yang LD, et al. Multi-level 3D densenets for false-positive reduction in lung nodule detection based on chest computed tomography[J]. Curr Med Imaging, 2020, 16(8): 1004-1021.
- [25] Farhangi MM, Petrick N, Sahiner B, et al. Recurrent attention network for false positive reduction in the detection of pulmonary nodules in thoracic CT scans[J]. Med Phys, 2020, 47(5): 2150-2160.

(编辑:陈丽霞)