

doi:10.3969/j.issn.1673-9833.2023.01.011

# 基于3D卷积神经网络的肺结节检测

黄冬云, 王欣, 秦斌

(湖南工业大学 轨道交通学院, 湖南 株洲 412007)

**摘要:** 针对肺结节自动检测模型精度较低, 假阳性较高等问题, 提出一种基于3D卷积神经网络的两阶段肺结节检测方法。第一阶段使用3D V-Net 检测出所有候选结节, 并融合残差跳转连接构建深层网络, 以保留上层网络一定比例输出, 实现图像特征重用, 引入改进的损失函数解决数据集正负样本失衡的问题; 第二阶段使用3D VGG 网络对候选结节分类, 以降低假阳性, 并加入残差连接防止梯度消失和退化, 以加速网络训练过程。实验结果表明, 该方法在候选结节检测阶段的敏感率为91.28%, 分类阶段的准确率为99.22%, 敏感率为96.60%, 可有效辅助放射科医生对肺结节进行检测。

**关键词:** 3D卷积; V-Net; 肺结节检测; 残差; 分类; VGG

**中图分类号:** TP391.41 **文献标志码:** A **文章编号:** 1673-9833(2023)01-0075-08

**引文格式:** 黄冬云, 王欣, 秦斌. 基于3D卷积神经网络的肺结节检测[J]. 湖南工业大学学报, 2023, 37(1): 75-82.

## Pulmonary Nodule Detection Based on 3D Convolutional Neural Network

HUANG Dongyun, WANG Xin, QIN Bin

(College of Railway Transportation, Hunan University of Technology, Zhuzhou Hunan 412007, China)

**Abstract:** In view of the low accuracy and high false positive of automatic detection model of pulmonary nodules, a two-stage detection method of pulmonary nodules has thus been proposed based on 3D convolution neural network. In the initial stage, 3D V-Net is used for the detection of all candidate nodules, with the residual jump connection integrated to build a deep network, so as to retain a certain proportion of output from the upper network, thus realizing image feature reuse, followed by an introduction of an improved loss function to solve the problem of imbalance between positive and negative samples in the data set. In the second stage, 3D VGG network is used to classify candidate nodules to reduce false positives, with the residual connection added to prevent gradient loss and degradation, thus accelerating the network training process. Experiments show that the proposed method achieves a sensitivity rate as high as 91.28% in candidate nodule detection stage, an accuracy rate of 99.22% and a sensitivity rate of 96.60% in classification stage respectively, which can effectively assist radiologists in the detection of pulmonary nodules.

**Keywords:** 3D convolution; V-Net; pulmonary nodule detection; residual error; classification; VGG

收稿日期: 2022-07-03

基金项目: 国家自然科学基金资助项目(61673166); 湖南省自然科学基金资助项目(2021JJ50006, 2022JJ50074)

作者简介: 黄冬云(1998-), 女, 湖南永州人, 湖南工业大学硕士生, 主要研究方向为图形图像处理,

E-mail: 2364190043@qq.com

通信作者: 王欣(1971-), 女, 山东青岛人, 湖南工业大学教授, 博士, 主要研究方向为复杂系统建模与智能控制, 图像识别, E-mail: 1114084900@qq.com

## 1 研究背景

肺癌被称为当今世界上最常见、最致命的恶性肿瘤之一<sup>[1]</sup>，因大多数患者被确诊为肺癌时已经是中期到晚期，此时癌细胞恶化或已经发生转移，导致患者因治疗不及时而出现较高的病死率。肺结节是肺部病变的重要症状，因此若能准确及时诊断出早期肺结节可以大大提高患者的治愈率<sup>[2]</sup>。计算机断层扫描（computed tomography, CT）筛查是目前肺癌早期临床筛查中最为有效的方法<sup>[3]</sup>。由于肺器官内部结构复杂，肺结节的大小、形状和位置千变万化，仅依靠肉眼识别难度较大，因此需要一个计算机辅助诊断（computer aided diagnosis, CAD）系统协助医生进行诊断。

传统的肺结节检测方法通常采用复杂的图像处理算法，其结节检测的准确性主要依赖人为设计的特征提取方法，若特征选取不好，容易丢失一些重要的结节信息，从而影响肺结节检测的准确性<sup>[4-6]</sup>。

近年来，针对医学图像中肺结节的自动检测与分类，科研工作者们提出了多种方法，主要为基于卷积神经网络（convolutional neural networks, CNN）的深度学习<sup>[7-11]</sup>。Shi H. 等<sup>[12]</sup>采用2D CNN肺结节两阶段检测框架，在LUNA16数据集上进行结节检测，得出其平均灵敏度为82.62%，但是该方法对直径小于3 mm的小结节检测效果较差。Wen C. R. 等<sup>[13]</sup>采用嵌入注意模块的3D卷积神经网络，并重新定义边界框回归，增强了收敛能力，获得了85.40%的灵敏度，且假阳性偏高。Liao F. Z. 等<sup>[14]</sup>采用改进的3D U-Net网络检测肺结节，并用Leaky Noisy-OR Gate模型评估被检测结节的癌变概率，两者结合可提高结节检测精度。A. Sreekumar 等<sup>[15]</sup>采用基于C3D网络架构的3D CNN模型检测肺结节，

获得了86.00%的检测灵敏度。Xie H. T. 等<sup>[16]</sup>采用2D Faster R-CNN网络检测候选结节，其灵敏度为86.42%，再使用2D CNN网络减少假阳性，但其准确性仍有提升空间。A. Pezeshk 等<sup>[17]</sup>采用3D CNN网络检测肺结节，其候选结节检测灵敏度达91%，相比2D CNN肺结节检测网络，检测性能显著提升。目前基于卷积神经网络的肺结节自动检测方法取得了较为满意的结果，但还是存在假阳性高的问题，需进一步提升模型检测性能，降低结果中的假阳性。

上述研究中设计的肺结节检测系统有两个基本任务：1) 结节候选检测；2) 减少假阳性。且都是运用2D或3D卷积神经网络实现肺结节自动检测。由于肺部CT图像是3D的，运用2D神经网络会忽视结节的三维空间信息，影响结节检测精度，3D卷积神经网络考虑肺部CT图像三维特征，能有效提取肺结节空间信息，故采用3D网络的结节检测效果更优。

此外，肺部CT图像数据集虽然较大，但是样本却很少，正负样本存在严重失衡问题，导致复杂的网络模型过拟合，造成结节检测的假阳性偏高。因此，针对肺结节自动检测中存在的精度低、假阳性高等问题，提出了一种基于3D卷积神经网络的肺结节两阶段检测方法。实验结果表明，该方法能有效提高肺结节检测敏感度，降低假阳性数量。

## 2 算法设计

基于3D卷积神经网络两阶段肺结节检测方法如下：第一阶段，使用融合残差结构3D V-Net网络定位结节位置，检测出所有候选结节；第二阶段，使用融合残差结构的3D VGG（visual geometry group）网络进行良恶性结节分类，进一步提高检测准确率，降低假阳性。肺结节两阶段检测的总体框架如图1所示。

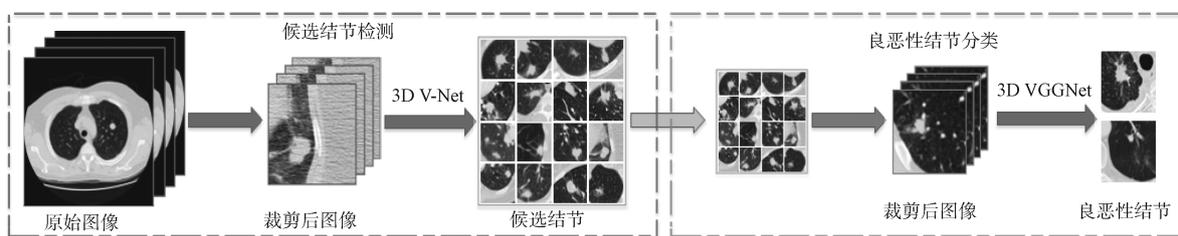


图1 肺结节两阶段检测总体框架

Fig. 1 Overall framework for two-stage detection of pulmonary nodules

### 2.1 候选肺结节检测

本文采用的3D V-Net候选结节检测网络主要分为下采样和上采样两部分。其中，下采样部分经过连续的三维卷积层和池化层提取高阶语义特征；上采样部分经过连续的三维反卷积操作将高阶语义特征进

行放大，并将放大后的高阶特征与相应下采样过程的高阶特征进行拼接。加入残差跳连接的3D V-Net网络，可在充分利用空间信息下提高肺结节检测的敏感度和准确度，3D V-Net候选肺结节检测网络结构如图2所示。

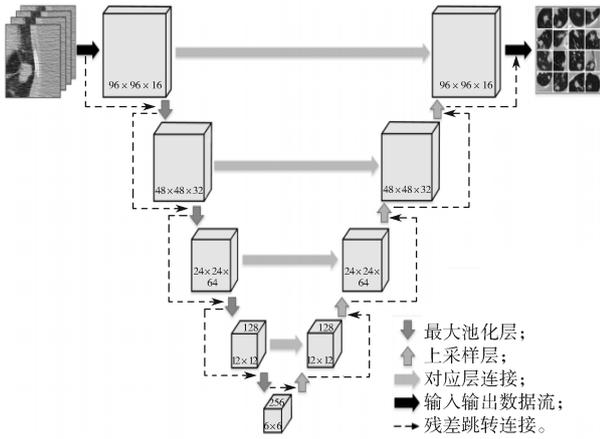


图 2 3D V-Net 候选肺结节检测网络结构图  
Fig. 2 3D V-Net detection network structure of pulmonary nodule candidates

3D V-Net 的输入和输出都是  $96 \times 96 \times 16$  的肺部 CT 图像, 包括 4 个下采样层和 4 个上采样层, 每个下采样层进行 2 次  $3 \times 3 \times 3$  卷积操作和 1 次  $2 \times 2 \times 2$  最大池化操作, 每个上采样层进行 1 次  $3 \times 3 \times 3$  反卷积操作和 3 次  $3 \times 3 \times 3$  卷积操作。反卷积操作后, 在对应层级间进行拼接, 且相邻两层间设计了残差跳转连接, 最后采用  $1 \times 1 \times 1$  的卷积核连接最终输出。

上采样过程中, 每层采用 2 个  $3 \times 3 \times 3$  的卷积核; 下采样过程中, 每层采用 3 个  $3 \times 3 \times 3$  的卷积核。虽然采用大卷积核比小卷积核更能捕捉到肺部 CT 图片的全局特征, 但采用 2 个  $3 \times 3 \times 3$  的小卷积核可以实现与 1 个  $5 \times 5 \times 5$  的卷积核同样的感受野, 采用 3 个  $3 \times 3 \times 3$  的小卷积核可以实现与 1 个  $7 \times 7 \times 7$  的卷积核同样的感受野。可见, 小卷积核不仅增加了卷积块的深度, 提高肺结节检测性能, 还能减少参数量, 提升运算速率。

### 2.1.1 残差结构

通常设计更深层次的 CNN 网络可以提高肺结节检测的准确性, 但对于传统的卷积神经网络来说, 随着网络深度加深, 容易造成梯度消失问题。残差结构通过在网络中增加跨层连接, 可以保留先前网络层的一定比例输出, 实现图像特征重用, 是缓解深度网络梯度消失问题的一种有效方法, 同时融合残差跨层连接还可以加速超深神经网络的训练过程。

残差网络由若干残差块组成, 残差块主要包括直接映射部分和残差部分。当神经网络输入为  $x$ , 学习到的特征输出为  $H(x)$  时, 其学习到的残差为  $F(x)=H(x)-x$ , 在网络中增添直接映射通道, 将原先学习到的特征转变成  $F(x)+x$ , 构成残差块<sup>[18]</sup>, 基础残差块见图 3a。本文的残差块含 2 个  $3 \times 3 \times 3$  的卷积操作, 且在 ReLU 函数激活前进行了批量归一化

(batch normalization, BN) 处理, 其结构见图 3b。

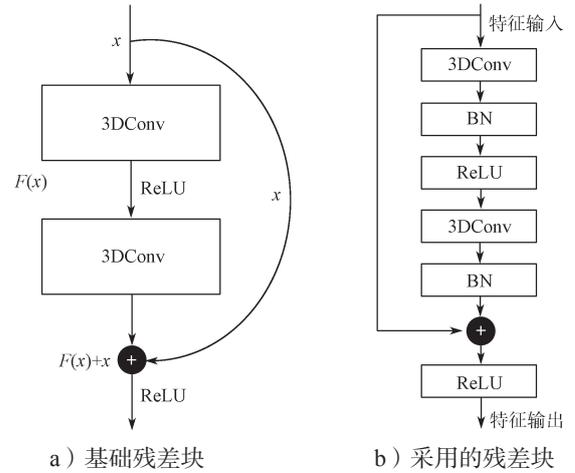


图 3 残差块构成示意图

Fig. 3 Schematic diagram of residual block composition

由图 3 可知, 本文设计的残差块通过 BN 处理, 将数据强制集中到统一的数据分布下, 再输入到下一层, 可以使中间层输出更稳定, 加快模型的训练速度, 缓解梯度消失问题, 提高模型的泛化能力。将残差块与 3D V-Net 融合, 不仅能够增加网络的深度, 提高肺结节检测的准确率, 还能加快训练速率, 提高候选结节检测模型的检测性能。

### 2.1.2 损失函数

损失函数用于评估模型预测结果与真实结果不一致的程度, 它可以决定神经网络训练的学习方向, 鲁棒性越好的模型, 其损失函数值越小。原始肺结节检测网络采用的损失函数为 Dice 函数, 其定义如下:

$$Dice(X, Y) = \frac{2|X \cap Y|}{|X| + |Y|}, \quad (1)$$

式中:  $X$  为预测值;  $Y$  为真实结果。

使用 Dice 系数作为损失函数, 能够提升模型训练的准确度, 但同时可能会丢失一些真实肺结节, 使得模型训练结果精度偏低。为了提高模型检测的敏感度, 本文采用了改进的损失函数。

为了解决医学图像数据正负样本失衡的问题, S. S. M. Salehi 等<sup>[19]</sup> 提出了基于 Tversky 系数的广义损失函数, 该函数对 Dice 系数进行了推广, Tversky 系数的定义如下:

$$T(X, Y; \alpha, \beta) = \frac{|X \cap Y|}{|X \cap Y| + \alpha|X - Y| + \beta|Y - X|}. \quad (2)$$

式中:  $|X - Y|$  代表假阳性 ( $F_p$ );  $|Y - X|$  代表假阴性 ( $F_n$ );  $\alpha$  和  $\beta$  为控制  $F_p$  和  $F_n$  之间平衡的超参数。

当设置超参数  $\alpha = \beta = 0.5$  时, 其实质为 Dice 系数, 当设置超参数  $\alpha = \beta = 1$  时, 其实质为 Jaccard 系数。

由于一张肺部 CT 图像中结节体素的数量远低于

非结节体素的数量, 这会造成数据的不平衡问题, 使用正负样本失衡的数据进行模型训练可能会造成预测的结果更偏向于精度高但灵敏度低的一方。本文采用 Tversky 系数作为损失函数, 通过调整超参数的取值, 在训练融合残差的 3D V-Net 网络时平衡敏感度和准确率, 提高肺结节自动检测的灵敏度。

## 2.2 良恶性结节分类

在良恶性结节分类阶段, 为了从大量候选肺结

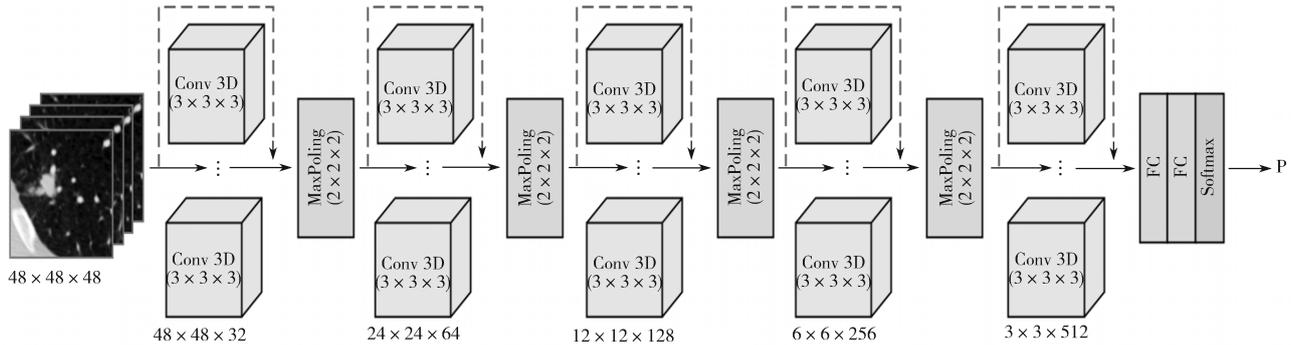


图4 3D VGG 分类模型结构

Fig. 4 3D VGG classification model structure

如图4所示, 本研究构建的3D VGG分类网络模型由10个3D卷积层、4个最大池化层、2个全连接层和1个Softmax分类层构成。其中, 卷积层均采用 $3 \times 3 \times 3$ 大小的过滤器。最大池化层采用 $2 \times 2 \times 2$ 的过滤器, 第一个全连接层以及所有卷积层采用ReLU激活函数, 第二个全连接层使用Softmax激活函数。第一层卷积核的个数为32, 随后每一层都在前一层的基础上翻倍, 最后得到的网络宽度为512。为了避免网络训练过程中的梯度消失问题, 本研究设计了残差跨层连接。

## 3 实验设置与结果分析

### 3.1 实验数据

本文采用LUNA16<sup>[20]</sup>数据集对两阶段肺结节检测进行验证。该数据集剔除了最大的公开肺结节参考数据库LIDC-IDRI中一些切片缺失、切片厚度大于3 mm, 及切片间距不一致的CT, 共组成888幅含多个 $512 \times 512$ 切片的三维肺部图像数据集。对于每个CT扫描图像, 由4名专业放射科医生对结节大小、结节坐标等进行标注, 共标记了1 186个肺结节, 肺结节直径范围为3.3~30.6 mm, 平均长度为8.3 mm, 结节大小偏小。得到的LUNA16数据集的候选节点信息共有551 065个, 每个候选节点都提供相应的类别标签: 非结节为0, 结节为1。肺结节信息标注示例如表1所示。

节中准确筛选出真阳性肺结节, 提高检测的灵敏度, 需要从中剔除假阳性肺结节。本文采用3D VGG分类网络, 通过两个 $3 \times 3 \times 3$ 的卷积核替代 $5 \times 5 \times 5$ 的卷积核, 保证在具有相同感受野的条件下增加网络深度, 能够充分利用真实结节丰富的空间上下文特征, 以便准确无误地获得真阳性肺结节, 3D VGG分类模型结构见图4。

表1 LUNA16数据集结节信息标注示例

Table 1 Sample illustration of the node information annotation for LUNA16 dataset

序号	坐标			直径/mm
	X	Y	Z	
1	122.740 3	-3.364 3	-222.394 2	3.341 5
2	-109.180 2	70.159 3	-107.622 8	8.391 7
3	-147.952 9	-164.169 4	-273.434 2	5.898 2
4	-59.562 4	-21.607 5	-184.870 1	6.096 4
5	-106.773 3	143.134 1	-711.111 6	15.130 8

### 3.1.1 数据预处理

由于肺器官的内部结构较为复杂, 肺部图像预处理主要如下: 1) 根据肺部区域CT值的取值范围在-500亨氏单位(Hounsfield unit, HU)左右, 过滤掉CT图像中骨骼、金属床亮斑以及其他组织器官等无关信息, 增强肺结节信息的可检测性, 简化数据, 以提高肺结节检测的准确度和训练速度; 2) 根据肺结节坐标信息, 将2D数据堆叠成需要的3D数据, 以保留肺结节的空间信息; 3) 结节数据增强, 避免网络训练过拟合, 提升模型的泛化能力。

预处理LUNA16数据集步骤如下: 1) 生成肺结节掩膜图像。以肺结节的坐标为中心点, 生成以结节直径为边长的正方体区域, 最后生成包含所有结节的掩膜文件(都是3D), 原始CT图像与对应结节掩膜, 如图5所示。2) 图像去噪与归一化处理。根据肺部HU的取值范围, 设置上下限, 去除原始CT图像中存在的噪声, 然后将图像像素进行归一化处理至(0,

1), 加快网络收敛, 提高运算速率。3) 生成候选结节检测数据。将经过处理后的CT图像及对应掩膜图像, 分别使用线性插值和最邻近插值进行采样, 并在CT图像和对应掩膜图像上, 根据设定步长生成大小为(96, 96, 16)的小块图像, 判断并保留有效的小块CT图像及对应小块图像的掩膜图像, 小块CT图像与对应结节掩膜图像如图6所示; 4) 生成结节分类数据。根据候选结节文件的坐标信息, 以该坐标为中心, 截取大小为(48, 48, 48)的区域作为候选结节图像, 根据候选结节文件内标注的良恶性结节信息, 将图像分为0(非结节)和1(结节)两类。

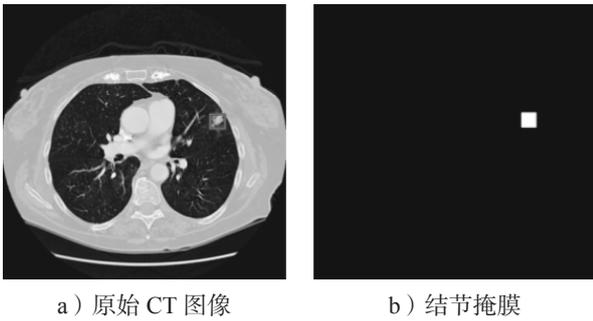


图5 原始数据与对应结节掩膜

Fig. 5 Original data and corresponding nodule mask

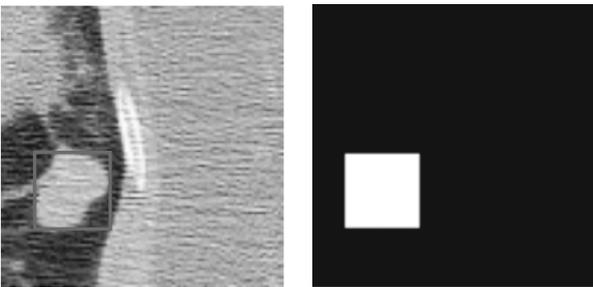


图6 小块CT图像与对应结节掩膜

Fig. 6 Small CT images with its corresponding nodule mask

### 3.1.2 数据增强

训练神经网络需要大量的训练样本才能训练得到一个泛化性能较好、鲁棒性较强的模型。在训练数据量少或正负样本失衡的情况下, 可以利用数据增强方式来增加训练样本的多样性, 避免网络训练出现过拟合现象, 提升模型的泛化性能。

肺部CT图像数据经过预处理后, 得到1351个有结节的图像和549714个没有结节的图像, 结节与非结节图像数量相差特别大。为了避免网络训练过拟合, 提升模型的泛化能力, 从1351个有结节的图像中先随机选取20%的图像作为测试数据, 剩下的作为训练数据, 再对该训练和测试数据分别作平移、旋转及翻转操作进行数据增强, 将有结节图像的数量扩大30倍, 得到40530个结节图像集; 从549714

个非结节图像中随机选取30%的数据, 组成164914个非结节图像集, 再对164914个非肺结节图像进行随机采样20%的图像数据作为分类测试集, 剩下的图像数据作为分类训练集。将结节和非结节训练数据和测试数据合并, 得到最终分类训练集和测试集。

### 3.2 实验环境

本次实验使用Window10操作系统, 处理器为Intel(R)Xeon(R)CPU E5-2680 v4@2.4 GHz(2处理器), 计算机内存为64GB, 整个网络模型代码都使用Python 3.8版本进行编写, 并在Tensorflow-gpu2.8.0深度学习框架下搭建, 同时使用显存为11455 MiB的NVIDIA Tesla M40显卡, 在GPU上加速模型训练。

### 3.3 评价指标

为了评估肺结节检测网络的有效性和检测的准确性, 本文采用敏感度(sensitivity)  $S_{EN}$ 、准确率(accuracy)  $A_{CC}$ 、受试者工作特性曲线(receiver operating characteristic curve)  $R_{OC}$ 、曲线  $R_{OC}$  下方面积(area under the curve)  $A_{UC}$  及混淆矩阵5个指标, 整体评估网络性能, 具体定义如下, 其中下标P表示阳性结节, N表示阴性结节:

$$S_{EN} = \frac{T_p}{T_p + F_N}, \quad (3)$$

$$A_{CC} = \frac{T_p + T_N}{T_p + T_N + F_p + F_N}, \quad (4)$$

式(3)(4)中:  $T_p$  为真阳性;  $F_p$  为假阳性;  $T_N$  为真阴性;  $F_N$  为假阴性。

预测结果描述如表2所示。

表2 混淆矩阵

Table 2 Confusion matrix

实际标签	预测结果	
	P	N
P	$T_p$	$F_N$
N	$F_p$	$T_N$

候选结节检测主要使用敏感度和Dice系数作为模型性能评估指标, 性能好的模型应该具有较高的敏感度和Dice系数。敏感度用来评估模型检测出的真实结节占全部候选结节的比例, 敏感度越高, 则漏检率越低; Dice系数用于评估预测结果与真实标签的相似度, Dice系数越大, 相似度越高。通过混淆矩阵、 $R_{OC}$ 曲线图及  $A_{UC}$  直观评估良恶性结节分类模型性能,  $R_{OC}$ 曲线是反映特异性和敏感性连续变量的综合指标, 曲线越接近左上角, 模型的分类性能越好, 误诊和漏诊的可能性越小。  $A_{UC}$  是指  $R_{OC}$  曲线下方的面积,  $A_{UC}$  越大, 分类性能越好。

### 3.4 参数设置

模型中仅在分类网络最后一个全连接层使用

Softmax 激活函数, 其余均使用 ReLU 作为激活函数, 并采用 Adam 作为网络训练优化方法, Adam 是一种高效的随机优化方法, 它结合了目前流行的 AdaGrad 和 RMSProp 两种优化方法的优点<sup>[21]</sup>, 可以使肺结节检测模型拥有更好的性能。在一定范围内, 不同批处理大小对实验结果影响不大, 其设置主要依据数据集大小, 批处理设置越大, 模型分类性能相对越好; 迭代次数主要影响模型的训练速度, 其设置越大, 训练时长越长; 学习率控制权重更新步长, 其设置太大可能导致不收敛, 而设置太小导致收敛速度过慢。综合考虑, 将 Batchsize 大小设为 16, 迭代次数设为 10, 学习率设为 0.001, 以收获较为满意的实验结果。

### 3.5 实验结果

#### 3.5.1 候选结节检测结果

在候选结节检测阶段, 本文使用融合残差结构的 3D V-Net 网络, 在相同的 LUNA16 数据集下, 对比了其他肺结节检测网络在本阶段的模型性能, 所得结果见表 3。

表 3 不同候选结节检测网络性能对比

Table 3 Performance comparison of different candidate nodule detection networks

检测算法	模型	敏感度 /%
文献 [12]	2D CNN	82.62
文献 [13]	3D CBAM	85.40
文献 [14]	3D CNN	85.62
文献 [15]	3D CNN	86.00
文献 [16]	Faster R-CNN	86.42
文献 [17]	3D CNN	91.00
本文算法	3D V-Net	91.28

表 3 所示实验结果表明: 在候选结节检测阶段, 本文提出的融合残差结构的 3D V-Net 网络的敏感度为 91.28%, 高于其他文献所提算法的敏感度, 从而验证了融合残差结构的 3D V-Net 网络在肺结节检测阶段的网络性能高于其他算法的。

候选结节检测阶段训练过程中的损失函数变化情况见图 7。

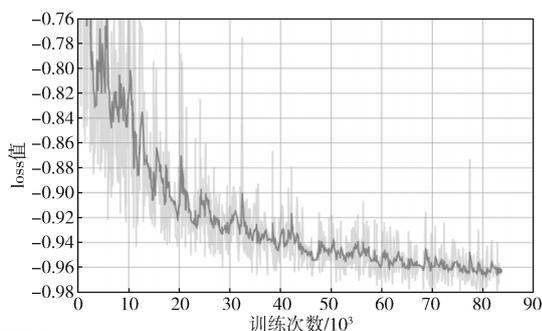


图 7 候选结节训练过程损失函数变化图

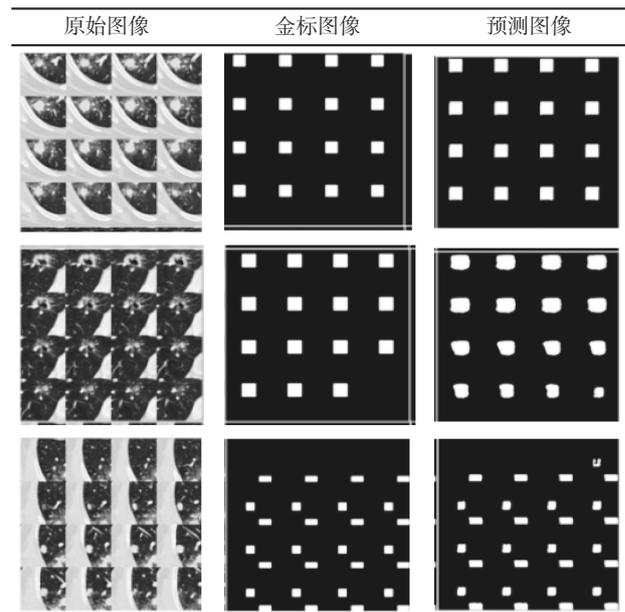
Fig. 7 Variation chart of loss function during the training process of candidate nodules

从图 7 所示损失函数曲线可以看出, 随着训练次数的增加, loss 值的变化逐渐趋于稳定, 且收敛速度较快, 整个训练过程中损失很小。

本文提出的融合残差结构的 3D V-Net 网络在测试集上对原始图像进行预测的结果如表 4 所示。对比分析预测结果图像与金标图像可知, 模型预测图像与金标图像差别不大, 这一结果说明本文提出的算法检测性能较好。

表 4 融合残差结构的 3D V-Net 网络预测结果

Table 4 Prediction results of 3D V-Net network integrating residual structure



#### 3.5.2 良恶性肺结节分类结果

在良恶性结节分类阶段, 采用融合残差结构的 3D VGG 网络对结节与非结节进行分类, 获得真阳性结节, 在相同数据集 LUNA16 下, 对比其他结节检测网络在本阶段的模型性能, 结果见表 5。

表 5 不同分类模型性能对比

Table 5 Performance comparison of different classification models

检测算法	2D/3D	准确率 /%	敏感度 /%
文献 [14]	3D	85.96	85.62
文献 [22]	3D	83.40	86.50
文献 [23]	3D	-	92.00
文献 [24]	2D	95.70	93.80
文献 [25]	3D	-	95.70
文献 [26]	3D	-	96.20
本文算法	3D	99.22	96.60

表 5 所示实验结果表明: 本文在良恶性肺结节分类阶段采用融合残差结构的 3D VGG 网络, 最终获得了 99.22% 的分类准确率和 96.60% 的敏感度, 相较于表中其他文献的算法, 本文提出的良恶性结节分

类网络在准确率和灵敏度上更优。

良性结节分类阶段训练过程的损失函数变化如图8所示,由损失函数曲线可看出,随着训练次数的增加, Loss 值先急剧下降,随后小幅波动,收敛速度较快,表明分类模型在训练过程中损失很小。

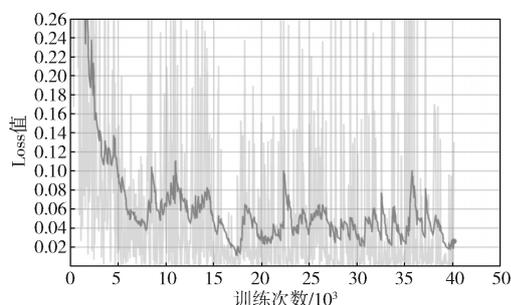


图8 分类阶段训练过程损失函数变化曲线

Fig. 8 Change curve of loss function during the training process at classification stage

图9为分类阶段训练过程准确率函数变化图,从图中曲线可以得出,随着训练次数增加,准确率最终趋于稳定,整个过程收敛速度较快,当训练次数达30 000时,分类准确率达0.99,随后小幅波动。

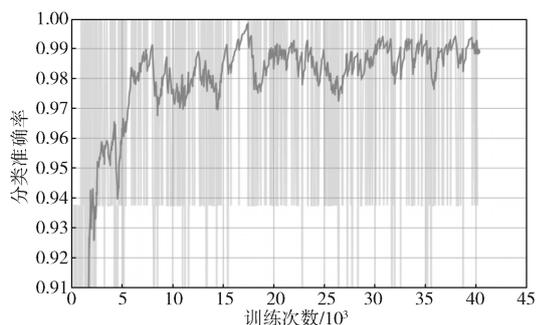


图9 分类阶段训练过程准确率函数变化图

Fig. 9 Variation of accuracy function during training in classification stage

使用  $R_{OC}$  曲线直观分析分类模型性能,结果见图10。曲线越靠近左上角,模型敏感性和特异性越高,从图中可看出,  $R_{OC}$  曲线距离  $(0, 1)$  点较近,通过计算曲线下方面积,获得的  $A_{UC}$  达99.90%,验证了本文方法在数据集LUNA16上的分类性能。

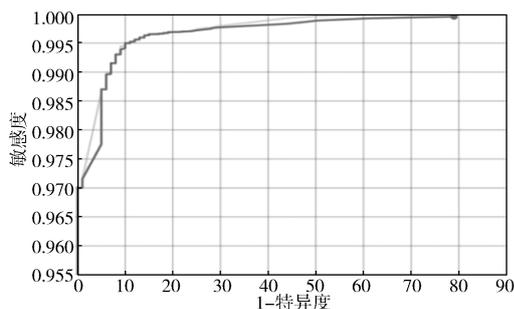


图10 模型的  $R_{OC}$  曲线图

Fig. 10  $R_{OC}$  curve of the model

表6所示混淆矩阵直观展示了分类结果,分析表中矩阵数据可知,分类模型的准确率达99.22%,假阳率只0.11%,漏检率为3.40%,准确率偏高,可能与分类数据集正负样本不平衡有关,假阳率较低,漏检率相对偏高,分类结果符合预期,这表明模型分类性能较好。

表6 分类结果混淆矩阵

Table 6 Confusion matrix of classification results

实际标签	预测结果	
	P	N
P	8 115	286
N	37	32 946

## 4 结语

在CT中准确检测出早期肺结节是肺癌诊断和治疗的关键步骤。针对现有肺结节自动检测模型精度较低、假阳性较高等问题,本文提出了一种融合残差结构的3D V-Net网络和3D VGG网络的两阶段肺结节检测方法,实现了对肺结节的准确检测。在肺结节检测阶段,通过在3D V-Net网络的基础上融合残差结构,加深网络深度,并实现图像特征的重复利用,为解决数据集正负样本失衡的问题,引入改进的损失函数,提高了模型的检测效率和灵敏度;在良恶性分类阶段,采用融合残差连接的3D VGG网络对良恶性结节进行分类,以降低假阳性,获得真阳性结节。实验结果表明,本文方法对比目前其他检测方法,在检测准确率和灵敏度方面均有所提升,可用来辅助放射科医生对肺结节进行检测。

## 参考文献:

- [1] SIEGEL R L, MILLER K D, FUCHS H E, et al. Cancer Statistics, 2022[J]. CA: A Cancer Journal for Clinicians, 2022, 72(1): 7-33.
- [2] MONKAM P, QI S L, MA H, et al. Detection and Classification of Pulmonary Nodules Using Convolutional Neural Networks: A Survey[J]. IEEE Access, 2019, 7: 78075-78091.
- [3] GU D D, LIU G C, XUE Z. On the Performance of Lung Nodule Detection, Segmentation and Classification[J]. Computerized Medical Imaging and Graphics, 2021, 89: 101886.
- [4] LI G, ZHOU W, CHEN W B, et al. Study on the Detection of Pulmonary Nodules in CT Images Based on Deep Learning[J]. IEEE Access, 2020, 8: 67300-67309.
- [5] UPADHYAY S, TANWAR P S. Classification of Benign-Malignant Pulmonary Lung Nodules Using Ensemble

- Learning Classifiers[C]//2021 6<sup>th</sup> International Conference on Communication and Electronics Systems (ICCES). Coimbatore: IEEE, 2021: 1–8.
- [6] SHAFFIE A, SOLIMAN A, KHALIFEH H A, et al. Radiomic-Based Framework for Early Diagnosis of Lung Cancer[C]//2019 IEEE 16<sup>th</sup> International Symposium on Biomedical Imaging. Venice: IEEE, 2019: 1293–1297.
- [7] ZHANG W G, CUI L F. Detection Algorithm of Pulmonary Nodules Based on Deep Learning[C]//2021 2<sup>nd</sup> International Conference on Big Data & Artificial Intelligence & Software Engineering (ICBASE). Zhuhai: IEEE, 2021: 185–188.
- [8] XIE D, TANG C R, LI Y B, et al. Pulmonary Nodules Detection via 3D Multi-Scale Dual Path Network[C]//2021 7<sup>th</sup> International Conference on Computer and Communications (ICCC). Chengdu: IEEE, 2021: 980–984.
- [9] YUAN H Y, WU Y R, CHENG J P, et al. Pulmonary Nodule Detection Using 3-D Residual U-Net Oriented Context-Guided Attention and Multi-Branch Classification Network[J]. IEEE Access, 2022, 10: 82–98.
- [10] YE Y Y, TIAN M, LIU Q Y, et al. Pulmonary Nodule Detection Using V-Net and High-Level Descriptor Based SVM Classifier[J]. IEEE Access, 2020, 8: 176033–176041.
- [11] CAI L Q, LONG T, DAI Y H, et al. Mask R-CNN-Based Detection and Segmentation for Pulmonary Nodule 3D Visualization Diagnosis[J]. IEEE Access, 2020, 8: 44400–44409.
- [12] SHI H, PENG Z W, WAN H L. Pulmonary Nodules Detection Based on CNN Multi-Scale Feature Fusion[C]//2019 IEEE 11<sup>th</sup> International Conference on Advanced Infocomm Technology. Jinan: IEEE, 2019: 86–90.
- [13] WEN C R, HONG M J, YANG X H, et al. Pulmonary Nodule Detection Based on Convolutional Block Attention Module[C]//2019 Chinese Control Conference (CCC). Guangzhou: IEEE, 2019: 8583–8587.
- [14] LIAO F Z, LIANG M, LI Z, et al. Evaluate the Malignancy of Pulmonary Nodules Using the 3-D Deep Leaky Noisy-OR Network[J]. IEEE Transactions on Neural Networks and Learning Systems, 2019, 30(11): 3484–3495.
- [15] SREEKUMAR A, NAIR K R, SUDHEER S, et al. Malignant Lung Nodule Detection Using Deep Learning[C]//2020 International Conference on Communication and Signal Processing (ICCSP). Chennai: IEEE, 2020: 209–212.
- [16] XIE H T, YANG D B, SUN N N, et al. Automated Pulmonary Nodule Detection in CT Images Using Deep Convolutional Neural Networks[J]. Pattern Recognition, 2019, 85: 109–119.
- [17] PEZESHK A, HAMIDIAN S, PETRICK N, et al. 3-D Convolutional Neural Networks for Automatic Detection of Pulmonary Nodules in Chest CT[J]. IEEE Journal of Biomedical and Health Informatics, 2019, 23(5): 2080–2090.
- [18] HE K M, ZHANG X Y, REN S Q, et al. Deep Residual Learning for Image Recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016: 770–778.
- [19] SALEHI S S M, ERDOGMUS D, GHOLIPOUR A. Tversky Loss Function for Image Segmentation Using 3D Fully Convolutional Deep Networks[C]//Proceedings of the 8<sup>th</sup> International Workshop on Machine Learning in Medical Imaging. Quebec City, QC, Canada: [s.n.], 2017: 379–387.
- [20] SETIO A A A, TRAVERSO A, DE BEL T, et al. Validation, Comparison, and Combination of Algorithms for Automatic Detection of Pulmonary Nodules in Computed Tomography Images: The LUNA16 Challenge[J]. Medical Image Analysis, 2017, 42: 1–13.
- [21] CHANG Z H, ZHANG Y, CHEN W B. Effective Adam-Optimized LSTM Neural Network for Electricity Price Forecasting[C]//2018 IEEE 9<sup>th</sup> International Conference on Software Engineering and Service Science. Beijing: IEEE, 2018: 245–248.
- [22] ZHAO A Q, DENG J, ZHONG L C, et al. Research on Automatic Detection Algorithm of Pulmonary Nodules Based on Deep Learning[C]//2019 4<sup>th</sup> International Conference on Mechanical, Control and Computer Engineering (ICMCCE). Hohhot: IEEE, 2019: 893–8934.
- [23] SUN L M, WANG Z R, PU H, et al. Attention-Embedded Complementary-Stream CNN for False Positive Reduction in Pulmonary Nodule Detection[J]. Computers in Biology and Medicine, 2021, 133: 104357.
- [24] NGUYEN C C, TRAN G S, NGUYEN V T, et al. Pulmonary Nodule Detection Based on Faster R-CNN with Adaptive Anchor Box[J]. IEEE Access, 2021, 9: 154740–154751.
- [25] GONG L, JIANG S, YANG Z Y, et al. Automated Pulmonary Nodule Detection in CT Images Using 3D Deep Squeeze-and-Excitation Networks[J]. International Journal of Computer Assisted Radiology and Surgery, 2019, 14(11): 1969–1979.
- [26] YUAN H Y, FAN Z W, WU Y R, et al. An Efficient Multi-Path 3D Convolutional Neural Network for False-Positive Reduction of Pulmonary Nodule Detection[J]. International Journal of Computer Assisted Radiology and Surgery, 2021, 16(12): 2269–2277.