

基于多尺度结合全局和局部注意力的肺结节良恶性分类网络

李炳淑¹, 吕楠², 孙福振¹

(1. 山东理工大学 计算机科学与技术学院, 山东 淄博 255000; 2. 山东省慢性病医院(山东省康复中心), 山东 青岛 266071)

摘要: 由于肺结节具有不同尺寸大小, 基于固定感受野的网络结构无法充分捕获肺结节的尺度特征。针对该问题, 提出一种基于多尺度结合全局和局部注意力的肺结节良恶性分类网络, 首先通过设计的多尺度层动态学习肺结节不同大小尺度特征, 增强网络对于多尺度特征的学习能力, 然后使用注意力机制对通道特征以及空间特征进行增强, 提升网络对于全局以及局部特征的信息捕获, 最后在公开数据集 LIDC-IDRI 上进行性能验证, 并与其他先进方法进行对比。实验结果表明, 本研究提出的肺结节良恶性分类网络可以取得较好的分类结果。

关键词: 多尺度; 注意力机制; 卷积神经网络; 肺结节; 分类

中图分类号: TP183

文献标志码: A

Benign and malignant pulmonary nodule classification network based on multi-scale combined with global and local attention

LI Bingshu¹, LÜ Nan², SUN Fuzhen¹

(1. College of Computer Science and Technology, Shandong University of Technology, Zibo 255000, China;

2. Shandong Provincial Chronic Disease Hospital(Shandong Rehabilitation Center), Qingdao 266071, China)

Abstract: Due to the different sizes of pulmonary nodules, the existing fixed receptive field network structures cannot fully capture the multi-scale features of pulmonary nodules. To address this problem, this paper proposed a benign and malignant pulmonary nodule classification network based on multi-scale combined with global and local attention. Firstly, through the designed multi-scale network layer, the network dynamically learned the characteristics of different scales of pulmonary nodules to enhance the network's learning ability for multi-scale representations. then, the attention mechanism was used to enhance the channel and spatial information so as to improve the ability of capturing global and local features. Finally, in order to verify the effectiveness of the network, the performance was validated on the public LIDC-IDRI dataset and compared with other state-of-the-art methods. The experimental results show that the designed network can achieve preferable results on benign and malignant classification tasks for pulmonary nodules.

Key words: multi-scale; attention mechanism; convolutional neural network; pulmonary nodule; classification

肺癌是临床致病率、致死率较高的癌症, 对肺结节进行良恶性分类是针对肺癌早期诊断的重要环节, 临床上常采用计算机断层扫描(computer tomography, CT)图像对肺部的肺结节进行诊断^[1]。但人工诊断肺结节过程需依赖临床医生的诊断经验且过程耗时耗力, 采用计算机辅助诊断系统进行肺结节良恶性自动分

收稿日期: 2023-03-16

基金项目: 国家自然科学基金项目(61841602); 山东省自然科学基金项目(ZR2018PF005)

作者简介: 李炳淑(1991—), 女, 山东淄博人, 硕士研究生, 主要从事智能信息处理研究。

孙福振(1978—), 男, 山东淄博人, 副教授, 博士, 主要从事数据挖掘、智能信息处理等方面研究, 本文通信作者。

E-mail: shanlijisuanji@163.com

类已经成为主流。

深度学习方法被越来越多的研究者应用到肺结节良恶性分类中。Song等^[2]采用经典卷积神经网络结构进行肺结节良恶性分析。Nibali等^[3]以残差神经网络(residual neural network, ResNet)架构为基础,分别结合课程学习、转移学习和不同网络深度,对比不同网络结构下肺结节良恶性的分类性能。为了验证不同网络结构性能,Agnes等^[4]对比了循环神经网络、长短时记忆力网络和卷积神经网络等多种深层网络结构。Shen等^[5]使用参数共享卷积神经网络实现肺结节图像特征提取以及多任务分类。为了解决样本量小的问题,王桂棠等^[6]提出一种联合生成对抗网络与卷积神经网络的分类结构,使用渐进式训练模式生成清晰图像作为扩充样本,并在公开数据集上验证了模型的可行性和有效性。Zhao等^[7]使用多个网络进行特征融合实现肺结节分类。朱辉等^[8]提出一种改进的U-Net卷积神经网络肺结节检测算法,采用卷积操作与池化操作获取高层特征,通过密集连接使特征信息在输入层和输出层之间流通,并结合膨胀卷积提高肺结节低层特征的利用率。杨杨等^[9]采用多视角结合挤压激励模块构建多视角肺结节良恶性识别模型以解决多视角差异性问题的。Kalaivani等^[10]提出一种采用密集连接卷积神经网络和自适应增强算法对肺部图像进行良恶性分类的方法。He等^[11]提出基于改进的Shapley加法扩展解释模型指导的肺部分类方法,通过使用医学先验知识和图像学习提取图像特征。Liu等^[12]提出一种多模型集成学习架构,该架构将结节掩码对应的强度图像、原始图像和增强图像拼接后进行输入,提取图像的高级特征,并通过动态选择不同结节大小所对应的模型进行预测。Yu等^[13]通过改进ResNet50,用三维卷积层代替二维卷积层,减小部分卷积核的大小,得到用于肺结节良恶性诊断的三维ResNet50网络。尽管现有方法已取得较好的肺结节良恶性分类结果,但由于肺结节一般具有不同尺寸大小,基于固定感受野的网络结构无法充分捕获图像的多尺度特征。与此同时,如何更加有效地学习肺结节图像中的全局和局部特征是提升肺结节良恶性分类性能的重要方面。文献[14]设计了多尺度特征融合网络,但未考虑网络因层次变化而带来的多尺度特征差异。

近年来,在提升分类算法准确度上研究人员提出一种借鉴人类视觉的注意力机制。注意力机制可以根据特征的重要性动态调整特征权重,使模型能够关注图像的重点区域,减少不必要信息干扰。Jiang等^[15]提出一种基于注意力机制以及上下文特征信息提取深层次特征的方法,实现肺结节智能化诊断,分类结果准确度较高。Huang等^[16]提取肺结节不同尺度特征并结合通道注意力和混合损失实现多种抽象图形特征学习,提高小恶性结节的预测精度。Fu等^[17]提出一种跨任务网络,通过注意力模块分析肺结节在CT图像上的不同临床特征属性,实现高准确度良恶性分类。Liu等^[18]设计了Res-trans网络学习肺结节局部和全局特征,对CT扫描中的肺结节进行分类,并在LIDC-IDRI数据集上验证了网络有效性。Al-Shabi等^[19]提出一种具有通道注意力和课程学习渐进生长网络的方法,通过学习肺结节全局特征,提升模型分类性能。

尽管上述方法在肺结节智能诊断任务上取得较好效果,但均未同时考虑多尺度、全局和局部特征,影响了网络对于不同尺度以及感受野下的特征学习。为此,本研究提出一种基于多尺度结合全局和局部注意力的肺结节良恶性分类网络,通过设计的多尺度层提取肺结节图像的多尺度特征,并结合注意力机制层学习肺结节图像的全局和局部特征。在公开数据集LIDC-IDRI上的测试结果证明,所提出的分类网络在准确度、敏感度、特异性和接收者操作特征曲线下面积等方面均获得良好的分类性能。

1 基于多尺度结合注意力机制的肺结节分类网络

本研究提出的基于多尺度结合全局和局部注意力的肺结节良恶性分类网络(以下简称本网络)结构如图1所示,通过有效学习输入图像的多尺度、全局和局部注意力特征提高分类性能。

对于输入的肺结节图像,网络首先经过卷积层提取浅层特征,卷积核大小和数量分别为 3×3 和64;然后通过设计的多尺度层,在不同感受野和深度网络层级下学习图像的多尺度特征,并通过连续的池化层、卷积层和多尺度层获得高层次的语义特征。另外,为了使网络能够充分学习全局和局部的注意力特征,将获取到的高层次语义特征输入到设计的注意力机制层进行特征增强。最后,将增强后的特征输入到全连接层,并通过Softmax函数实现肺结节良恶性分类。网络具体参数设定如表1所示。

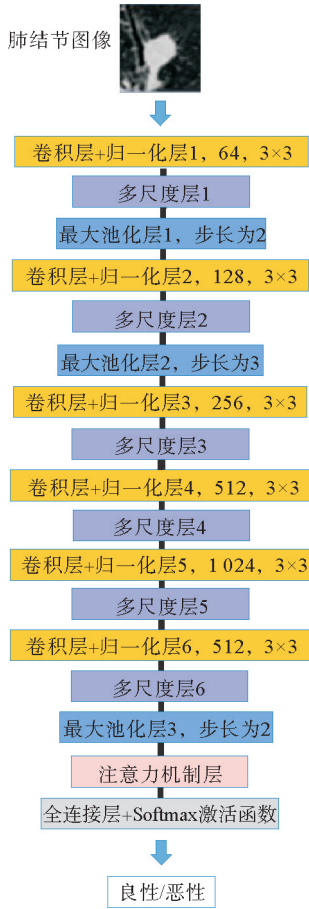


图 1 基于多尺度结合全局和局部注意力的肺结节良恶性分类网络结构示意图

Fig. 1 Benign and malignant pulmonary nodule classification network based on multi-scale combined with global and local attention

表 1 网络结构参数设定

Table 1 Parameter setting of the network

网络层	输出尺寸	卷积核大小	卷积核数量
卷积层+归一化层 1	128×128	{3×3}	64
多尺度层 1	128×128	{1×1,3×3,6×6}	64
最大池化层 1	64×64	{2×2}	—
卷积层+归一化层 2	64×64	{3×3}	128
多尺度层 2	64×64	{1×1,3×3,6×6}	128
最大池化层 2	32×32	{2×2}	—
卷积层+归一化层 3	32×32	{3×3}	256
多尺度层 3	32×32	{1×1,3×3,6×6}	256
卷积层+归一化层 4	32×32	{3×3}	512
多尺度层 4	32×32	{1×1,3×3,6×6}	512
卷积层+归一化层 5	32×32	{3×3}	1024
多尺度层 5	32×32	{1×1,3×3,6×6}	1024
最大池化层 3	16×16	{2×2}	—
注意力机制层	8×8	{3×3}	64
输出层	全连接层+Softmax 激活函数		2

1.1 多尺度层

肺结节往往存在不同尺寸,传统的网络结构无法充分学习肺结节的尺度特征。因此,设计一种多尺度层,在不同的感受野和网络深度下充分学习肺结节的尺度特征,结构如图 2 所示。

定义 F_i 为第 i 层卷积层的输出,将 F_i 输入到多尺度层中,并分别设定三条特征提取路径,每条路径设置卷积层的卷积核大小分别为 $\{1 \times 1, 3 \times 3, 6 \times 6\}$ 、 $\{3 \times 3, 1 \times 1, 6 \times 6\}$ 、 $\{6 \times 6, 3 \times 3, 1 \times 1\}$ 。这里 $\{1 \times 1\}$ 可以有效学习肺结节细节特征信息, $\{3 \times 3\}$ 获取中级尺寸特征信息, $\{6 \times 6\}$ 学习较大尺寸特征信息。三条特征提取路径分别表示为:

$$F_i^1 = \text{Conv}_6^1(\text{Conv}_3^1(\text{Conv}_1^1(F_i))), \quad (1)$$

$$F_i^2 = \text{Conv}_6^2(\text{Conv}_1^2(\text{Conv}_3^2(F_i) + \text{Conv}_1^2(F_i))), \quad (2)$$

$$F_i^3 = \text{Conv}_1^3(\text{Conv}_3^3(\text{Conv}_6^3(F_i) + \text{Conv}_1^3(\text{Conv}_3^3(F_i) + \text{Conv}_1^3(F_i)))). \quad (3)$$

式中, F_i^s 表示第 $s \in \{1, 2, 3\}$ 条路径的特征输出, Conv 表示卷积运算。特别地,在设计的多尺度层中采用横向路径残差




图 2 多尺度层结构示意图

Fig. 2 Multi-scale layer

连接,可以使网络学习更多异化尺度特征。最终多尺度层的输出 F_m 为 F_i^1, F_i^2, F_i^3 特征拼接,

$$F_m = \text{Concat}(F_i^1, F_i^2, F_i^3)。$$
 (4)

式中,Concat 表示特征拼接。

1.2 注意力机制层

1.2.1 通道注意力模块

在肺结节分类任务中,为了使本网络聚焦在肺结节主体区域,抑制非主体区域的影响,本研究使用加权通道注意力机制,动态学习不同通道特征的重要性,增强主体区域的特征表达,抑制非主体区域的特征表达,使本网络能够有效地聚焦在全局重要信息,其结构如图 3 所示。




图 3 通道注意力模块的结构示意图

Fig. 3 Structure of channel attention module

首先,定义最后一层多尺度层的输出为 $F \in \mathbf{R}^{H \times W \times C}$, H, W 和 C 分别表示特征 F 的高度、宽度、通道数。为了学习不同通道的重要性,增强有效信息,抑制无效信息,对于输入 F 采用全局最大池化(global max pooling, GMP)和全局平均池化(global average pooling, GAP),得到:

$$m_c = \max(F_c(x, y))，$$
 (5)

$$a_c = \frac{1}{H \times W} \sum_x^H \sum_y^W F_c(x, y)。$$
 (6)

式中: m_c 和 a_c 分别表示第 c 个特征通道的全局最大池化层权重和全局平均池化层权重, $F_c(x, y)$ 表示第 c 个特征通道 (x, y) 位置的特征像素。为了获取更多的非线性信息,将 m_c 和 a_c 分别经过 2 个全连接层 (fully connected layers, FC) 进行处理,并加入 ReLU 非线性激活函数。这里定义非线性化处理后的特征输出分别为 F_M 和 F_A 。为了获得对应权重矩阵,对 F_M 和 F_A 分别使用 Sigmoid 激活函数计算权重:

$$\sigma(p) = \frac{e^p}{e^p + 1}。$$
 (7)

式中, p 表示输入特征 F_M 和 F_A 每个像素位置的具体值,则权重计算过程可以表示为:

$$M_w = \sigma(W_2 \delta(W_1 m_c))，$$
 (8)

$$A_w = \sigma(W_4 \delta(W_3 a_c))。$$
 (9)

式中: M_w 和 A_w 分别表示所计算的全局最大池化层权重矩阵和全局平均池化层权重矩阵, δ 为 ReLU 激活函数, W_1, W_2, W_3, W_4 分别表示全连接层的权重参数。

然后,将获得的权重矩阵与输入的多尺度特征进行式(10)、式(11)的点乘运算,以获得增强后的通道注意力特征。

$$F_M = F \odot M_w，$$
 (10)

$$F_A = F \odot A_w。$$
 (11)

式中, \odot 表示点乘运算。

最后,由 F_M 和 F_A 共同连接组成通道注意力模块的输出特征 F_C , 即:

$$F_C = \text{Concat}(F_M, F_A)。$$
 (12)

1.2.2 空间注意力模块

为了使本网络能够充分学习肺结节的局部细节特征信息,设计一种空间注意力模块,通过学习像素级空间注意力特征增强本网络对肺结节细节信息的捕获能力,其具体结构如图4所示。




图4 空间注意力模块的结构

Fig. 4 Structure of spatial attention module

类似地,定义最后一层多尺度层的输出为 $F \in \mathbf{R}^{H \times W \times C}$,在对特征进行处理前,首先进行特征压缩,即采用卷积核大小为 1×1 ,通道数为1的卷积层对 F 进行压缩得到 F_d ,然后采用 Sigmoid 激活函数对 F_d 进行权重计算:

$$W_d = \frac{e^{F_d}}{1 + e^{F_d}} \quad (13)$$

式中, W_d 表示所计算的位置权重矩阵。下一步将 W_d 和输入的特征 F 进行像素逐元素相乘,同时为进一步提高本网络的收敛性,采用残差连接将特征进行点加操作:

$$F_p = F \odot W_d \oplus F \quad (14)$$

通过本节设计的空间注意力模块,本网络能够更加高效地学习肺结节图像的高层次位置以及细节特征信息,提高网络对于肺结节局部信息的捕获能力,提升网络对于肺结节的分类性能。

2 网络训练与配置

经过注意力机制层的特征学习后,将获取的特征输入到线性层中并使用 Softmax 激活函数,进行特征到类别的概率映射,其中 Softmax 函数 σ 定义为:

$$\sigma(p)_j = \frac{e^{p_j}}{\sum_{k=1}^K e^{p_k}} \quad (15)$$

式中: $K=2$,表示类别总数; $\sigma(p)_j$ 表示第 j 个类别的概率, $j=1,2$ 。网络在训练过程中采用交叉熵损失函数 L 进行优化,具体表达式为:

$$L = \frac{1}{N} \sum_n L_n = \frac{1}{N} \sum_n [y_n \cdot \ln p_n + (1 - y_n) \cdot \ln(1 - p_n)] \quad (16)$$

式中: L_n 表示第 n 个样本的损失, y_n 表示第 n 个样本的真实标签, p_n 表示第 n 个样本的预测概率。网络训练过程中,采用 Xavier 算法初始化网络学习参数,使用随机梯度下降法进行网络优化。

3 实验结果与分析

本网络在训练过程中,采用 NVIDIA GTX 1080Ti 进行加速训练,运行系统为 Linux Ubuntu 16,编程代码平台为 Pytorch,在初始训练过程中设置学习率为 0.000 1。当在验证集上的损失经过 10 个步长不再变化时,将学习率进行衰减,为了防止本网络过拟合,采用 Dropout 层进行训练。

3.1 LIDC-IDRI 数据集

LIDC-IDRI 公开数据库共有 1 018 名患者的 CT 扫描图像,每个患者 CT 图像的切片厚度为 0.6~5 mm,具体诊断信息由 4 位放射科医生诊断标注,标注的信息包含肺结节的位置、直径、良恶性、钙化程度、

毛刺程度等属性特征。本网络主要用于良恶性分类,在该数据集中对于良恶性的诊断分为 1~5 分。为了获得每个肺结节最终的真实标签类别,采用投票策略进行判定,即对于单一肺结节,若专家有一半及以上人数打分大于 3 则认定为恶性肺结节,若专家有一半及以上人数打分小于 3 则认定为良性肺结节。为了降低网络复杂度,采用肺结节中心横截面作为输入图像,在网络的训练过程中,采用随机旋转、翻转、放大和缩小等数据扩增方法进行数据扩充。

3.2 评价标准

为评估本网络的性能,在实验部分采用准确度(accuracy)、敏感度(sensitivity)、特异性(specificity)、接收者操作特征曲线(receiver operating characteristics, ROC)以及接收者操作特征曲线下面积(area under receiver operating characteristics curve, AUC)进行量化评估。具体地,定义真阳性、假阳性、真阴性、假阴性分别表示为 T_p 、 F_p 、 T_n 、 F_n 。则准确度为:

$$A = \frac{T_p + T_n}{T_p + F_p + T_n + F_n}, \tag{17}$$

敏感度为:

$$S_e = \frac{T_p}{T_p + F_n}, \tag{18}$$

特异性为:

$$S_p = \frac{T_n}{T_n + F_p}. \tag{19}$$

3.3 实验结果对比

3.3.1 多尺度层不同大小卷积组合的性能比较

为获取不同层次的多尺度特征,在多尺度层中采用大小分别为 $\{1 \times 1, 3 \times 3, 6 \times 6\}$ 的卷积进行特征学习,同时将该层分别放在卷积层后和池化层前,以便随着网络深度增加不断学习层次化抽象特征。本节设计了不同大小卷积组合,验证多尺度层中卷积大小对网络性能的影响,具体对比结果如表 2 所示。

表 2 多尺度层不同大小卷积组合的性能比较

Table 2 Performance comparison of multi-scale convolution combinations with different sizes

方法	准确度/%	敏感度/%	特异性%	AUC
No Multi-Conv	88.5	89.1	90.6	0.931
Multi-Conv(1)	88.7	89.7	91.2	0.935
Multi-Conv(1,3)	89.6	91.1	92.7	0.946
Multi-Conv(1,3,6)	90.9	92.3	94.9	0.953

表 2 中,“No Multi-Conv”表示无多尺度卷积层,“Multi-Conv(1)”“Multi-Conv(1,3)”“Multi-Conv(1,3,6)”分别表示多尺度卷积层卷积大小为 1,1 和 3 组合,1,3,6 组合 3 种不同网络设置。实验结果表明,随着卷积组合增多,网络的性能不断提升,但考虑到网络的复杂度,本网络中采用卷积大小为(1,3,6)作为多尺度卷积层最终配置。

3.3.2 不同网络层的性能比较

表 3 不同网络层的性能比较

Table 3 Performance comparison of different network layers

方法	准确度/%	敏感度/%	特异性%	AUC
无 MSL/CHA/PAS	85.3	85.1	87.6	0.916
仅 MSL	88.6	89.3	90.2	0.933
仅 CHA	87.3	88.9	89.9	0.921
仅 SSA	86.7	88.3	88.7	0.919
含 MSL/CHA/SSA	90.9	92.3	94.9	0.953

本节通过消融实验验证本网络中多尺度层和注意力机制层的作用。将多尺度层命名为“MSL”,通道注意力模块命名为“CHA”,空间注意力模块命名为“SSA”,对所设计的不同部分实验结果对比如表 3 所示。实验结果表明,通过增加任意一多尺度层或者注意力机制层都可以有效提升网络的性能。

与注意力机制层相比,多尺度层可以取得更好的分类结果,这表明在肺结节分类任务中多尺度特征对于良恶性分类具有重要的作用。同时,从实验结果中还发现,“CHA”的性能要高于“SSA”性能,表明全局特征在此次分类任务中具有更重要作用。

3.3.3 不同图像输入尺寸的性能比较

为探寻不同图像输入尺寸对本网络性能的影响,分别输入图像尺寸 $\{32 \times 32, 64 \times 64, 128 \times 128, 256 \times 256, 512 \times 512\}$ 进行性能比较。为保证网络的深度不受原始图像分辨率影响,在网络训练过程中只采用池化层对图像特征进行降维,不同图像输入尺寸对比实验结果如图 5 所示。实验结果表明,网络的性能随着输入尺寸的增加而提升,但当图像输入尺寸达 128×128 时,网络的性能变化无太大差异,这是由于多尺度层在该尺寸下已经充分学习多种不同尺度特征,因而随着图像输入尺寸的增加而性能变化不大。因此,综合考虑网络的复杂度及性能,最终设定输入尺寸为 128×128 。

3.3.4 注意力模块在不同层位置性能比较

对注意力模块在网络中的位置性能进行实验对比,将注意力模块放在网络的浅层、中层和深层,实验结果如图 6 所示。实验结果表明,随着注意力模块的位置不断加深,网络的性能不断提升,这可以解释为越深层的注意力特征可以为肺结节的良恶性分类提供越抽象化的特征信息,从而提升网络整体分类性能。最终,本研究将注意力模块放在网络深层,分类结果的准确度、敏感度、特异性分别为 90.9%、92.3%、94.9%。

3.3.5 与传统分类方法的性能比较

将本网络与传统的深度学习网络 VGG、ResNet18、DenseNet 进行实验对比,对比时采用网络原始参数和相同数据集,对比结果如图 7 所示。对比结果表明,与传统的分类网络相比,本网络性能更好,再次验证了注意力机制层和多尺度层的作用。




图 5 不同图像输入尺寸的准确度比较

Fig. 5 Accuracy comparison of different image input sizes

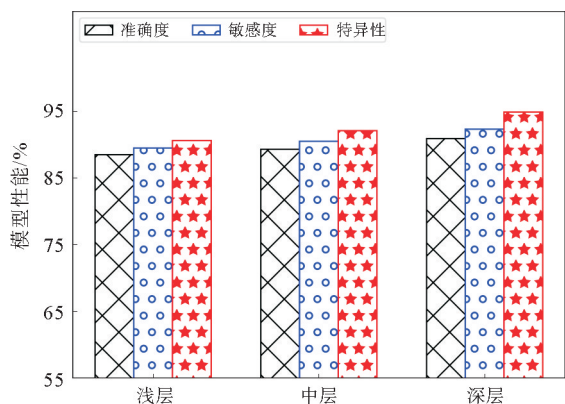


图 6 注意力模块在不同层位置的性能比较

Fig. 6 Performance comparison of attention module in different layer positions




图 7 与不同网络结构对比的 ROC 曲线

Fig. 7 ROC curves compared with different network structures

3.3.6 与现有分类方法的性能比较

在相同数据集上与现有分类方法进行性能比较,对比结果如表 4 所示。可以看出,本网络在准确度、敏感度、特异性、AUC 上均取得较好的分类表现。特别是敏感度达到 92.3%,相比其他方法有较大提升。图 8 展示了本网络方法对于不同肺结节预测的概率,概率越高表示恶性程度越大,从预测结果可以看出,本网络方法能够准确地预测肺结节良恶性。

表 4 不同分类方法的性能比较

Table 4 Performance comparison of different methods

方法	准确度/%	敏感度/%	特异性/%	AUC
文献[4]	87.3	81.0	91.9	0.944
文献[10]	90.9	86.9	82.3	—
文献[11]	87.3	86.2	88.5	0.941
文献[12]	90.6	83.7	93.9	0.939
文献[13]	87.3	—	—	0.907
本研究方法	90.9	92.3	94.9	0.953




图 8 不同肺结节良恶性预测结果以及对应类别概率

Fig. 8 Prediction results of benign and malignant tumors of different pulmonary nodules and the corresponding category probability

4 结论

本研究提出一种多尺度结合全局和局部注意力的肺结节分类网络,通过加入多尺度层和注意力机制层,学习肺结节的多尺度、全局和局部特征信息,提高网络分类性能。在公开数据集 LIDC-IDRI 上验证表明,本网络具有良好的分类效果。由于考虑到模型复杂性,本网络仅采用二维结构进行特征学习,在获取肺结节空间特征方面有所缺失。下一步,将扩展网络到三维结构,并验证其有效性。

参考文献:

[1] SNOECKX A, REYNTIENS P, DESBUQUOIT D, et al. Evaluation of the solitary pulmonary nodule: Size matters, but do not ignore the power of morphology[J]. Insights into Imaging, 2018, 9(1): 73-86.

[2] SONG Q Z, ZHAO L, LUO X K, et al. Using deep learning for classification of lung nodules on computed tomography images[J/OL]. Journal of Healthcare Engineering, 2017. DOI:10.1155/2017/8314740.

[3] NIBALI A, HE Z, WOLLERSHEIM D. Pulmonary nodule classification with deep residual networks[J]. International Jour-

- nal of Computer Assisted Radiology and Surgery, 2017, 12(10):1799-1808.
- [4] AGNES S A, ANITHA J. Automatic 2D lung nodule patch classification using deep neural networks[C]//2020 Fourth International Conference on Inventive Systems and Control(ICISC). IEEE, 2020:500-504.
- [5] SHEN S, HAN S X, ABERLE D R, et al. An interpretable deep hierarchical semantic convolutional neural network for lung nodule malignancy classification[J]. Expert Systems with Applications, 2019, 128:84-95.
- [6] 王桂棠, 林楨哲, 符秦沈, 等. 联合生成对抗网络的肺结节良恶性分类模型[J]. 仪器仪表学报, 2020, 41(11):188-197.
WANG Guitang, LIN Zhenzhe, FU Qinshen, et al. Joint generative adversarial network model for classification of benign and malignant pulmonary nodules[J]. Journal of Instrumentation, 2020, 41(11):188-197.
- [7] ZHAO X Z, LIU L Z, QI S L, et al. Agile convolutional neural network for pulmonary nodule classification using CT images [J]. International Journal of Computer Assisted Radiology and Surgery, 2018, 13(4):585-595.
- [8] 朱辉, 秦品乐. 基于多尺度特征结构的 U-Net 肺结节检测算法[J]. 计算机工程, 2019, 45(4):254-261.
ZHU Hui, QIN Pinle. U-Net pulmonary nodule detection algorithm based on multi-scale feature structure[J]. Computer Engineering, 2018, 45(4):254-261.
- [9] 杨杨, 李晓琴, 韩振波, 等. 基于三维多视角挤压激励卷积神经网络的肺结节良恶性分类研究[J]. 生物医学工程学杂志, 2022, 39(3):452-461.
YANG Yang, LI Xiaoqin, HAN Zhenbo, et al. Research on classification of benign and malignant lung nodules based on three-dimensional multi-view squeeze-and-excitation convolutional neural network[J]. Journal of Biomedical Engineering, 2022, 39(3):452-461.
- [10] KALAIIVANI N, MANIMARAN N, SOPHIA S, et al. Deep learning based lung cancer detection and classification[C/OL] //IOP Conference Series: Materials Science and Engineering. IOP Publishing, 2020, 994(1). DOI:10.1088/1757-899X/994/1/012026.
- [11] HE W L, LI B, LIAO R Q, et al. An ISHAP-based interpretation-model-guided classification method for malignant pulmonary nodule[J/OL]. Knowledge-Based Systems, 2022, 237. DOI:10.1016/j.knsys.2021.107778.
- [12] LIU H, CAO H C, SONG E M, et al. Multi-model ensemble learning architecture based on 3D CNN for lung nodule malignancy suspiciousness classification[J]. Journal of Digital Imaging, 2020, 33(5):1242-1256.
- [13] YU H, LI J, ZHANG L, et al. Design of lung nodules segmentation and recognition algorithm based on deep learning[J/OL]. BMC Bioinformatics, 2021, 22. DOI:10.1186/s12859-021-04234-0.
- [14] 顾军华, 孙哲然, 王锋, 等. 基于多尺度特征融合的肺结节良恶性分类方法[J]. 深圳大学学报(理工版), 2020, 37(4):417-424.
GU Junhua, SUN Zheran, WANG Feng, et al. Classification of benign and malignant pulmonary nodules based on multi-scale feature fusion[J]. Journal of Shenzhen University Science and Engineering, 2020, 37(4):417-424.
- [15] JIANG H L, GAO F, XU X X, et al. Attentive and ensemble 3D dual path networks for pulmonary nodules classification [J]. Neurocomputing, 2020, 398:422-430.
- [16] HUANG Y S, WANG T C, HUANG S Z, et al. An improved 3-D attention CNN with hybrid loss and feature fusion for pulmonary nodule classification[J/OL]. Computer Methods and Programs in Biomedicine, 2023, 229. DOI:10.1016/j.cmpb.2022.107278.
- [17] FU X H, BI L, KUMAR A, et al. An attention-enhanced cross-task network to analyse lung nodule attributes in CT images [J/OL]. Pattern Recognition, 2022, 126. DOI:10.1016/j.patcog.2022.108576.
- [18] LIU D X, LIU F H, TIE Y, et al. Res-trans networks for lung nodule classification[J]. International Journal of Computer Assisted Radiology and Surgery, 2022, 17(6):1059-1068.
- [19] AL-SHABI M, SHAK K, TAN M. ProCAN: Progressive growing channel attentive non-local network for lung nodule classification[J/OL]. Pattern Recognition, 2022, 122. DOI:10.1016/j.patcog.2021.108309.

(责任编辑:傅 游)