

# 基于部分注释 CT 图像的自监督迁移学习肺结节分类

黄鸿<sup>1\*</sup>, 彭超<sup>1</sup>, 吴若愚<sup>1</sup>, 陶俊利<sup>2</sup>, 张久权<sup>2</sup>

<sup>1</sup>重庆大学光电技术及系统教育部重点实验室, 重庆 400044;

<sup>2</sup>重庆大学附属肿瘤医院影像科, 重庆 400030

**摘要** 深度学习模型训练时需要大量的注释样本,但在医学领域注释数据难以获取。针对此问题,提出了一种结合部分注释数据的自监督学习算法,以提高 3D 肺结节的分类性能。在传统自监督训练的网络结构基础上,设计了一种多任务学习的网络结构,以同时利用医学图像处理任务中大量未注释数据和少量注释数据。通过先训练未注释数据然后加入注释数据继续训练的方式,实现了注释数据与未注释数据间部分网络结构和参数的共享。相较于传统自监督学习方法,所提算法在保证模型泛化能力的同时能够学习到更多与肺结节相关的鉴别特征,因此将模型迁移学习用于肺结节分类时也能表现出更佳的性能。所提算法在公开数据集 LIDC-IDRI 上的分类准确率达 0.886,曲线下面积(AUC)值达 0.929,实验结果表明,所提算法能够有效提升肺结节的分类性能。

**关键词** 图像处理; 肺结节分类; 特征提取; 自监督学习; 部分注释; 迁移学习

中图分类号 TP391

文献标志码 A

doi: 10.3788/AOS202040.1810003

## Self-Supervised Transfer Learning of Pulmonary Nodule Classification Based on Partially Annotated CT Images

Huang Hong<sup>1\*</sup>, Peng Chao<sup>1</sup>, Wu Ruoyu<sup>1</sup>, Tao Junli<sup>2</sup>, Zhang Jiuquan<sup>2</sup>

<sup>1</sup>Key Laboratory of Optoelectronic Technology & Systems, Ministry of Education, Chongqing University, Chongqing 400044, China;

<sup>2</sup>Department of Radiology, Chongqing University Cancer Hospital, Chongqing 400030, China

**Abstract** The process of training a deep learning model requires many annotation samples, even though annotation data is difficult to obtain in the medical field. A self-supervised learning algorithm combined with partial annotation data is proposed as a solution to this problem, in order to improve classification performance of 3D pulmonary nodules. Based on the traditional self-supervised training network structure, a multitask learning network structure is designed to address a large amount of unannotated data and a small amount of annotated data obtained from medical image processing tasks. First, the proposed algorithm trains the unannotated data, and then explores the annotation data to continuously train the model. Thus, this algorithm manages to share partial network structures and parameters between the annotated and unannotated data. Compared to traditional self-supervised learning methods, the proposed algorithm can learn to recognize the discriminant features of pulmonary nodules to ensure the model's capacity to generalize, therefore, model transfer learning can also perform better when applied to the classification of pulmonary nodules. The classification accuracy of the proposed algorithm on LIDC-IDRI dataset is 0.886, and the area under the curve (AUC) is 0.929. The results of the investigation indicate that the proposed algorithm can effectively improve classification performance of pulmonary nodules.

**Key words** image processing; pulmonary nodule classification; feature extraction; self-supervised learning; partial annotation; transfer learning

**OCIS codes** 100.4996; 100.3020; 150.1135

收稿日期: 2020-04-17; 修回日期: 2020-06-02; 录用日期: 2020-06-11

基金项目: 中央高校基本科研业务费“医工融合项目”(2019CDYGYB008)、重庆市科卫联合项目医学科研项目(2019ZDXM007)、重庆市科研院所绩效激励引导专项(cstc2018jxjl130072)、中华国际医学交流基金会 2019 SKY 影像科研基金(Z-2014-07-1912-10)

\* E-mail: hhuang@cqu.edu.cn

# 1 引 言

作为全球发病率和死亡率最高的癌症之一,肺癌在我国 5 年内的生存率仅有 16.1%<sup>[1]</sup>,因此早发现、早治疗是提高患者生存率的重要医学手段。由于肺癌早期表现形式为肺结节,因此对肺癌的早期诊断主要是对病人计算机断层扫描(CT)图像中的肺结节进行判断<sup>[2-3]</sup>。但一个病人往往就有上百张 CT 图像,依靠人工对 CT 图像进行诊断时工作量大、易漏诊,并且高强度的工作也容易使医生产生误诊<sup>[4-5]</sup>。计算机辅助诊断技术的发展为医生提供了有效的帮助<sup>[6]</sup>。早期的计算机辅助诊断技术主要是在分割好的肺结节上手构建特征输入分类器进行分类。Chen 等<sup>[7]</sup>通过对肺结节进行分析,提取出了纹理、形状、强度、小波 4 种特征,并将这些特征输入到支持向量机(SVM)分类器对肺结节进行分类。Dhara 等<sup>[8]</sup>根据肺结节的 2D、3D 几何和纹理特征对数据集进行良恶性分类。这些方法对肺结节分类进行了积极的探索,但在实际应用中鲁棒性较低。

基于深度学习的计算机辅助诊断技术则解决了上述问题,深度学习通过网络学习自动获取数据的鉴别特征,在简化步骤的同时还能有效地提升分类精度<sup>[9]</sup>。Nibali 等<sup>[10]</sup>将 ResNet 18 网络应用于肺结节的分类中,解决了人工制定的诊断规则不够全面和无法持续提高准确率等问题。针对 2D 网络会丢失肺结节空间信息的问题,Polat 等<sup>[11]</sup>设计了含 Softmax 层的传统 3D 卷积神经网络(CNN)和含 SVM 的混合 3D CNN 分别对肺部 CT 图像中的结节进行分类。上述算法对肺结节分类进行了积极的探索,但却需要大量的注释样本来训练模型,而要获得大量的医学注释数据十分不易。解决医学领域样本不足问题的常用方法是在大型自然数据集上预训练好的模型迁移学习至医学领域,但自然图像与医学图像模态之间存在特征差异,并不能取得很好

的结果<sup>[12-13]</sup>。为有效利用大量的未注释医学数据,国内外学者开始探索基于自监督训练的迁移学习方法。Chen 等<sup>[14]</sup>提出了一种基于上下文还原的新型自监督学习策略,以便更好地利用未注释的数据集,该策略在多个医学数据集上都取得了不错的分割、分类、检测结果。Zhou 等<sup>[15]</sup>利用大量未注释的医学图像进行自监督学习,提出了 Models Genesis 模型,其实验结果也证明了自监督迁移学习方法的有效性。虽然大量注释的医学数据难以获取,但获取少量注释数据相对比较容易。上述自监督学习方法处理的都是未注释数据,完全没有利用注释的 CT 图像数据,虽然提高了模型的性能但也学到很多与目标任务无关的冗余特征。

本文提出了一种结合部分注释信息的自监督迁移学习算法。该算法为了学习未注释数据与注释数据各自的特征信息,在自监督训练网络设计上采用共享部分结构,从而两类数据可使用共同的特征提取网络。该网络设计使模型能结合两部分数据进行训练学习,同时该算法使用加权损失函数对两类数据在训练过程中的重要度进行设置。通过这种结合部分注释数据的自监督训练方式,模型能够学到更多与肺结节相关的鉴别特征,在肺结节分类上能表现出更好的性能。

## 2 自监督学习方法

### 2.1 自监督学习方法原理

医学图像自监督学习包含两个步骤,即对待训练图像进行变换处理,然后通过自监督网络对变换后的图像进行学习得到重建图。用于自监督学习的网络模型包含两部分:特征提取和图像重建,具体如图 1 所示。其中,特征提取部分对网络输入的图片进行卷积和下采样等操作生成特征图,而图像重建部分通过反卷积和上采样操作将特征图变为输出图像。

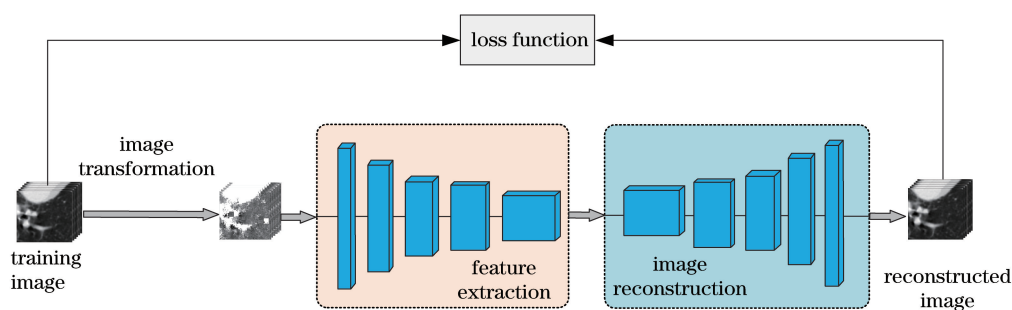


图 1 自监督学习原理图

Fig. 1 Schematic of self-supervised learning principle

## 2.2 用于自监督的 CT 图像变换

由自监督学习原理可知,对图像采取不同的变换处理方法将直接影响模型的性能。一般来说,对图像




图 2 肺部 CT 图像的变换方法。(a)原图;(b)非线性变换;(c)局部像素改变;(d)外部像素改变;(e)内部像素改变

Fig. 2 Transformation method of lung CT images. (a) Original image; (b) nonlinear transformation;

(c) local pixel change; (d) external pixel change; (e) internal pixel change

### 1) 非线性变换

CT 图像中的像素值为各组织与 X 线衰减系数相当的对应值,用亨氏单位(HU)表示,不同的 HU 对应人体不同的组织。用非线性函数对输入图像的 HU 进行非线性变换,通过自监督模型学习以恢复变换前的像素值,达到对不同组织进行识别的目的。

### 2) 局部像素改变

在 CT 图像  $I$  上随机确定一个小立方体  $c$ ,将立方体  $c$  内的像素位置随机打乱得到  $c'$ ,用  $c'$  替换  $c$ ,多次重复这个过程得到变换后的 CT 图像  $\tilde{I}$ 。在整体图像形状不发生大变化的前提下,模型可学习到局部的结构和纹理特征。

### 3) 外部像素改变

外部像素改变就是对原图的边缘进行不规则遮挡,让网络能够通过内部的像素最大可能地恢复图像的边缘信息。

### 4) 内部像素交换

随机在 CT 图像  $I$  上选择两个立方块  $c_1$  和  $c_2$ ,且满足  $c_1 \cap c_2 = \emptyset$ ,交换两个立方块的像素值,即  $c'_1 = c_2, c'_2 = c_1$ ,多次重复这个过程,得到变换后的图像  $\tilde{I}$ 。

由于局部像素改变与内部像素交换都是对图像内部像素进行改变操作,因此在具体实施中,局部像素改变与内部像素交换不同时进行,通过一定的概率随机选择。

## 2.3 部分注释自监督迁移学习模型

所提算法流程如图 3 所示,实现过程包含三个阶段:未注释数据训练、注释数据与未注释数据共同训练、迁移学习肺结节分类。

下面对所提算法进行具体介绍。

### 1) 未注释数据训练

将未注释的图像输入自监督学习网络,并进行

进行变换处理的目的是要能够学习到图像的重要特征且不应太复杂,根据这个原则和医学图像自身的特性,对研究对象进行了图 2 所示的 4 种变换<sup>[14-15]</sup>。

少量 epochs 训练初始化模型。

考虑到自监督学习网络需要特征提取部分和图像重建部分,而 Unet 网络的 encoder 部分和 decoder 部分刚好可以实现特征提取与图像重建的功能,因此选用 3D Unet 作为自监督学习网络。方均误差(MSE)为训练的损失函数,表达式为

$$E_{MS} = \frac{1}{K} \sum_{k=1}^K (y_k - y'_k)^2, \quad (1)$$

式中: $K$  为数据集大小; $k$  为数据集中第  $k$  个样本; $y_k$  为数据集中第  $k$  个样本的真实值; $y'_k$  为模型对第  $k$  个样本的重建值。

### 2) 注释数据与未注释数据共同训练

用未注释图像对模型进行初始化训练后,为实现未注释图像与注释图像多输入多输出的多任务学习,在 3D Unet 上新加了一路 decoder 网络即重建网络,两路重建网络共享特征提取网络。用未注释图像训练得到的参数初始化特征提取网络与两路重建网络,第一路重建网络仍对应未注释图像的重建图像输出,注释图像的重建图像则从第二路重建网络输出。用加权损失函数对多任务自监督学习过程进行评估。加权损失函数为

$$L = k_1 \frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2 + k_2 \frac{1}{m} \sum_{j=1}^m (y_j - y'_j)^2, \quad (2)$$

式中: $n$  为未注释图像数据集的大小, $m$  为注释图像数据集的大小; $y_i$  为未注释图像数据集中第  $i$  个样本的真实值, $y'_i$  为对应的重建值; $y_j$  为注释图像数据集中第  $j$  个样本的真实值, $y'_j$  为对应的重建值; $k_1$  和  $k_2$  为两路图像重建网络损失函数所占的权重, $k_1 = k_2 = 0.5$ 。

### 3) 迁移学习肺结节分类

完成训练之后,对自监督模型的特征提取网络

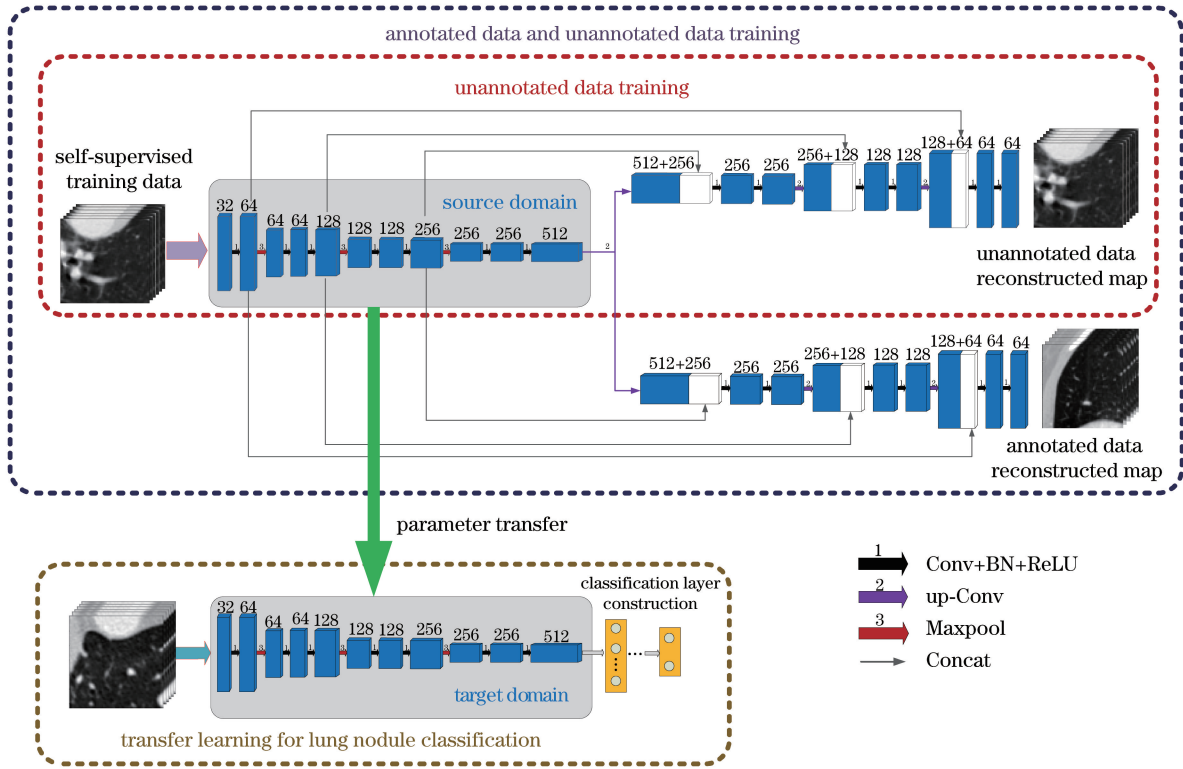


图 3 所提算法流程图

Fig. 3 Flow chart of proposed algorithm

进行参数迁移,添加全连接(FC)层和 Softmax 层,并利用 3D 肺结节图像对所提肺结节分类网络进行微调,进而实现分类。

### 3 数据集和实验设置

#### 3.1 数据集

为了验证所提算法的有效性,选择在公开数据集 LIDC-IDRI 上进行实验评估,该数据集共包含 1018 位病例。其中,每位病例数据都由临床胸部 CT 扫描图像和对应的 xml 文件组成。xml 文件通过 4 名有经验的胸部放射科医生标注,包括结节位置、边缘、纹理等信息。结节的等级从 1 到 5,其中 1 和 5 分别是良性和恶性的极端。对结节进行选取时,考虑至少由 3 位放射科医生诊断出的肺结节,计算结节的带注释等级的中位数,将小于 3 的中位数视为良性,将大于 3 的中位数视为恶性,并排除中位数等于 3 的所有结节,另外丢弃缺少切片或切片厚度不均匀的一些肺结节。

获取实验所用数据之后,将所有 CT 图像的 HU 截取到 $[-1000, 400]$ 并进行归一化,公式为

$$X'_i = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}}, \quad (3)$$

式中: $X_{\max}$  和  $X_{\min}$  分别为每个 CT 序列 HU 的最大

和最小值; $X'_i$ 为对应每个点归一化后的值。

#### 3.2 实验设置

实验的硬件环境基于 PANYAO 7048GR 服务器,包含 6 张 TITAN RTX 显卡,192GB 内存;软件环境是基于 Ubuntu 19.10 系统的 Keras 深度学习框架(Keras 1.13.1 版本),编程语言为 Python (Python3.6 版本)。

首先在 LIDC-IDRI 数据集上选取 512 个 CT 序列,并从每个 CT 序列里随机截取 20 个  $64 \times 64 \times 32$  大小的 3D 图像块作为未注释图像数据集,同时在这 512 个 CT 序列中选取 367 个  $64 \times 64 \times 32$  大小且含肺结节的 3D 图像块作为注释图像数据集,都对注释图像与未注释图像进行图像变换处理。自监督训练选择的优化器为 Adam, batch-size 为 64, 初始学习率设置为 0.1,随着训练次数增加,若连续 10 个 epochs 验证集损失值无下降,学习率则变为原来的 0.5。先用未注释数据训练 7 个 epochs 以初始化模型,然后加入注释数据共同训练。“Early Stopping”作为模型训练的结束条件,即在验证集上若连续 40 个 epochs 损失函数的值都不减小就自动停止训练。

在迁移学习实验阶段,为了保证源域与目标域信息没有相互泄露,选用 LIDC-IDRI 数据集中用于



上述自监督训练之外的数据进行分类实验,即在余下的 506 个 CT 序列上进行筛选,一共获得 534 个  $64 \times 64 \times 32$  大小含肺结节的图像块,其中良性与恶性比例为 241:293。使用五折交叉验证策略来评估模型的性能。

### 3.3 评价指标

在机器学习中,通常将二分类的样本分为正类和负类两大类。 $N_{TP}$  表示模型正确识别正类样本的数目, $N_{FP}$  表示模型将负类样本识别为正类样本的数目, $N_{TN}$  表示模型正确识别负类的数目, $N_{FN}$  表示模型将正类样本识别为负类样本的数目。基于这些定义,用以下指标对所提分类模型进行综合评估。

准确率:

$$A_{cc} = \frac{N_{TP} + N_{TN}}{N_{TP} + N_{FP} + N_{TN} + N_{FN}}, \quad (4)$$

即模型正确分类的样本数占总样本数的比例。

敏感性:

$$S_{en} = \frac{N_{TP}}{N_{TP} + N_{FN}}, \quad (5)$$

表示在所有的正类样本中,正确分类的正类样本数所占的比例。

特异性:

$$S_{pe} = \frac{N_{TN}}{N_{FP} + N_{TN}}, \quad (6)$$

表示在所有的负类样本中,正确分类的负类样本数所占的比例。

## 4 实验结果

用训练好的自监督网络模型进行迁移学习分类实验,添加不同数目的全连接层会改变网络深度,这直接影响网络对数据的拟合度,进而影响分类精度。为了获取所提算法最佳的全连接层数,选择全连接层的层数 1、2 和 3 进行对比实验,实验结果如表 1、2 所示,其中 AUC 为曲线下面积。

表 1 不同全连接层数量下分类性能对比

Table 1 Comparison of classification performance under different number of fully connected layers

Number	Model	$A_{cc}$	$S_{en}$	$S_{pe}$	AUC
FC is 1	Scratch model	$0.815 \pm 0.018$	$0.698 \pm 0.065$	$0.908 \pm 0.046$	$0.879 \pm 0.022$
	Self-supervised model	$0.828 \pm 0.001$	$0.684 \pm 0.113$	$0.903 \pm 0.043$	$0.895 \pm 0.008$
	Proposed model	$0.843 \pm 0.039$	$0.754 \pm 0.103$	$0.914 \pm 0.020$	$0.924 \pm 0.015$
FC is 2	Scratch model	$0.817 \pm 0.018$	$0.751 \pm 0.080$	$0.867 \pm 0.054$	$0.870 \pm 0.026$
	Self-supervised model	$0.864 \pm 0.013$	$0.812 \pm 0.048$	$0.903 \pm 0.050$	$0.915 \pm 0.009$
	Proposed model	$0.886 \pm 0.009$	$0.839 \pm 0.054$	$0.920 \pm 0.044$	$0.929 \pm 0.016$
FC is 3	Scratch model	$0.819 \pm 0.048$	$0.767 \pm 0.011$	$0.861 \pm 0.065$	$0.878 \pm 0.039$
	Self-supervised model	$0.830 \pm 0.025$	$0.768 \pm 0.068$	$0.877 \pm 0.057$	$0.905 \pm 0.030$
	Proposed model	$0.841 \pm 0.049$	$0.855 \pm 0.030$	$0.831 \pm 0.100$	$0.906 \pm 0.038$

表 2 不同全连接层数量下不同模型的运行时间对比

Table 2 Comparison of running time of different models under different number of fully connected layers

Number	Scratch model	Self-supervised model	Proposed model
FC is 1	5.04	4.31	4.34
FC is 2	5.08	4.69	4.68
FC is 3	5.34	4.87	5.39

由表 1 可以发现,网络深度越深,模型的特征提取能力越强,但会导致过拟合,网络深度浅,模型提取特征的能力较弱,这两种情况都会降低模型的性能。对肺结节分类实验,全连接层数为 2 时,模型的性能最好,因此将其作为自监督迁移学习的网络深度。同时也可以发现,针对 3D 肺结节分

类问题,用自监督模型进行迁移学习微调比直接对网络从头训练有更高的精度,表现了自监督迁移学习的有效性。而结合了部分注释信息的自监督模型通过同时利用注释数据与未注释数据能更好地提取肺结节的特征,有效地提高了肺结节分类性能。

为进一步评估所提算法的性能,在表 1 基础上对各模型的肺结节分类时间进行对比,实验设置与表 1 一致。从表 2 可知,Scratch 模型、Self-supervised 模型及所提模型的运行时间并没有明显差异,这是因为从网络结构上分析,这几种分类模型都是一致的,只是预训练方式不同。该实验结果表明,结合部分注释 CT 图像对模型进行预训练的方式在有效提升分类精度的同时,并不需要耗费更多的运行时间。

源域迁移到目标域进行微调时,模型收敛速度

越快,源域学习的参数与目标域参数相关度越高。为验证所提算法学到了肺结节分类相关的重要特征,绘制了训练的损失精度图,如图 4 所示。可以发现,将训练的参数模型迁移学习微调用于 3D 肺结节分类时,分类模型在少量的迭代之后就能很好收敛,从侧面说明,结合部分注释信息的自监督模型有效地提取到了肺结节的鉴别特征。

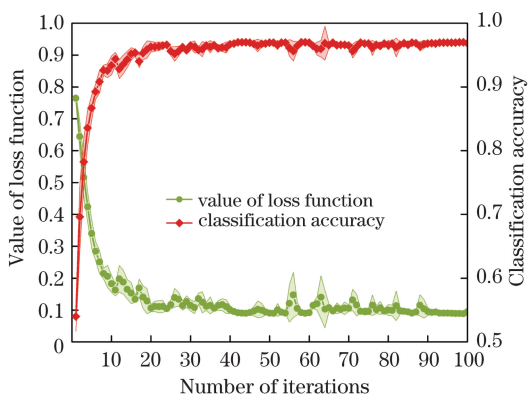


图 4 FC 为 2 时所提模型的损失-准确率图

Fig. 4 Loss-accuracy graph of proposed model when FC is 2

为进一步直观反映分类模型的性能,绘制了受试者工作特征(ROC)曲线。对不同分类模型而言,只要 AUC 值越大,模型的分类性能就越好。图 5 为

全连接层数为 2 时从头训练模型、传统自监督迁移学习模型及所提模型的 ROC 曲线。可以看出,所提模型曲线最高,AUC 值最大,分类性能最强,表明了结合部分注释信息的自监督迁移学习算法对分类性能提升的重要性。

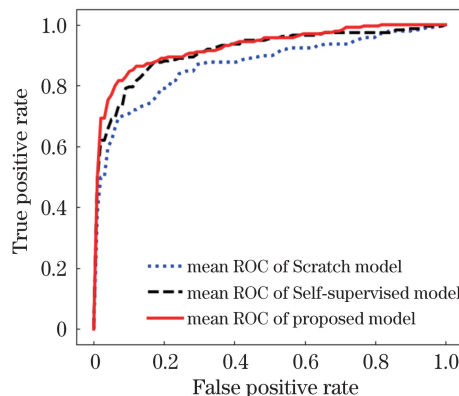


图 5 FC 为 2 时不同分类模型的 ROC 曲线

Fig. 5 ROC curves of different classification models when FC is 2

表 3 不同算法的分类性能对比

Table 3 Comparison of classification performance of different algorithms

Algorithm	$A_{cc}$	$S_{en}$	$S_{pe}$	AUC
SVM	$0.746 \pm 0.032$	$0.660 \pm 0.061$	$0.814 \pm 0.027$	$0.802 \pm 0.025$
3D CNN	$0.811 \pm 0.054$	$0.740 \pm 0.116$	$0.868 \pm 0.040$	$0.872 \pm 0.055$
3D ResNet	$0.826 \pm 0.040$	$0.758 \pm 0.121$	$0.880 \pm 0.050$	$0.906 \pm 0.026$
3D DenseNet	$0.851 \pm 0.028$	$0.847 \pm 0.034$	$0.854 \pm 0.036$	$0.908 \pm 0.010$
Proposed algorithm	$0.886 \pm 0.009$	$0.839 \pm 0.054$	$0.920 \pm 0.044$	$0.929 \pm 0.016$

表 4 不同算法的运行时间对比

Table 4 Comparison of running time of different algorithms

Algorithm	SVM	3D CNN	3D ResNet	3D DenseNet	Proposed algorithm
Time /s	0.08	5.30	7.19	15.23	4.68

由表 3 可知,自监督学习模型虽然能够有效提取肺结节的特征,但由于自监督训练阶段未对肺结节分类任务进行参数学习,因此将其直接作为特征提取器时并不能取得较好的结果;相较于 3D CNN、3D ResNet 及 3D DenseNet 算法,所提算法直接在 3D Unet 的 decoder 部分后面添加全连接层和 Softmax 层,在网络上并没有采用更复杂的结构。表 4 为运行时间对比实验结果,数据集划分情况与

在 LIDC-IDRI 数据集上对所提算法、SVM、3D CNN、3D ResNet 及 3D DenseNet 算法进行对比实验,结果如表 3、4 所示。Time 指标为模型在测试集上进行分类时所用时间的平均值。

表 3 相同,可以看到,由于所提算法的复杂度比 3D CNN、3D ResNet、3D DenseNet 更低,因此模型运行速度也更快。在肺结节分类问题上,综合精度与分类所用时间,所提算法整体表现优于 3D CNN、3D ResNet 及 3D DenseNet 算法,这表明在有限的肺结节数据集上,结合部分注释信息的自监督迁移学习算法能够很好地弥补肺结节数据的不足,提高模型的泛化能力,进而提升肺结节的分类性能。

## 5 结 论

针对医学图像分析领域肺部 CT 图像大量标记数据难以获取的问题,提出一种结合部分注释数据的改进自监督迁移学习肺结节分类算法。该算法将自监督训练过程分为两步:第一步是针对大量无注释信息数据的训练,第二步则在前一步基础上加入少量含有注释信息的数据继续训练。医学图像自监督学习可以解决医学领域迁移学习源域与目标域差异过大的问题,并且所提算法同时利用了大量无注释信息的肺部 CT 图像和少量注释的肺部 CT 图像,这使得训练的模型能够提取出对肺结节分析更有用的特征,进一步提高后续迁移学习分类的准确性。同时所提算法在自监督训练阶段与后续迁移学习分类阶段使用的是不同的数据,因此只要在合适的数据上就可以对其他 CT 图像进行肺结节分类,从而为医生提供可靠的决策支持。

本文用于自监督学习的网络模型为 3D Unet,该网络为目前主流的分割网络,而在迁移学习阶段只使用了 3D Unet 的 encoder 部分进行分类实验,没有利用 decoder 部分。因此下一步研究工作考虑将所提算法用于肺结节分割上,同时也考虑对自监督训练所用网络结构进行进一步改进,使得自监督训练能够最大可能地学习到数据的特征信息。

## 参 考 文 献

- [1] Chen W Q, Zheng R S, Baade P D, et al. Cancer statistics in China, 2015 [J]. CA: a Cancer Journal for Clinicians, 1900, 66(2): 115-132.
- [2] Jacobs C, van Rikxoort E M, Scholten E T, et al. Solid, part-solid, or non-solid: classification of pulmonary nodules in low-dose chest computed tomography by a computer-aided diagnosis system [J]. Investigative Radiology, 2015, 50(3): 168-173.
- [3] Feng Y, Yi B S, Wu C Y, et al. Pulmonary nodule recognition based on three-dimensional convolution neural network [J]. Acta Optica Sinica, 2019, 39(6): 0615006.  
冯雨, 易本顺, 吴晨玥, 等. 基于三维卷积神经网络的肺结节识别研究 [J]. 光学学报, 2019, 39(6): 0615006.
- [4] Zhao Q Y, Kong P, Min J Z, et al. A review of deep learning methods for the detection and classification of pulmonary nodules [J]. Journal of Biomedical Engineering, 2019, 36(6): 1060-1068.
- [5] Miao G, Li C F. Detection of pulmonary nodules CT images combined with two-dimensional and three-dimensional convolution neural networks [J]. Laser & Optoelectronics Progress, 2018, 55(5): 051006.  
苗光, 李朝锋. 二维和三维卷积神经网络相结合的 CT 图像肺结节检测方法 [J]. 激光与光电子学进展, 2018, 55(5): 051006.
- [6] Setio A A A, Jacobs C, Gelderblom J, et al. Automatic detection of large pulmonary solid nodules in thoracic CT images [J]. Medical Physics, 2015, 42(10): 5642-5653.
- [7] Chen C H, Chang C K, Tu C Y, et al. Radiomic features analysis in computed tomography images of lung nodule classification [J]. PLoS One, 2018, 13(2): e0192002.
- [8] Dhara A K, Mukhopadhyay S, Dutta A, et al. A combination of shape and texture features for classification of pulmonary nodules in lung CT images [J]. Journal of Digital Imaging, 2016, 29(4): 466-475.
- [9] Anwar S M, Majid M, Qayyum A, et al. Medical image analysis using convolutional neural networks: a review [J]. Journal of Medical Systems, 2018, 42(11): 1-13.
- [10] Nibali A, He Z, Wollersheim D. Pulmonary nodule classification with deep residual networks [J]. International Journal of Computer Assisted Radiology and Surgery, 2017, 12(10): 1799-1808.
- [11] Polat H, Mehr H D. Classification of pulmonary CT images by using hybrid 3D-deep convolutional neural network architecture [J]. Applied Sciences, 2019, 9(5): 940.
- [12] Tajbakhsh N, Shin J Y, Gurudu S R, et al. Convolutional neural networks for medical image analysis: fine tuning or full training? [J]. IEEE Transactions on Medical Imaging, 35(5): 1299-1312.
- [13] Huang S, Li F F, Chen Q. Computed tomography image classification algorithm based on improved deep residual network [J]. Acta Optica Sinica, 2020, 40(3): 0310002.  
黄盛, 李菲菲, 陈虬. 基于改进深度残差网络的计算断层扫描图像分类算法 [J]. 光学学报, 2020, 40(3): 0310002.
- [14] Chen L, Bentley P, Mori K, et al. Self-supervised learning for medical image analysis using image

- context restoration[J]. Medical Image Analysis, 2019, 58: 101539.
- [15] Zhou Z W, Sodha V, Rahman Siddiquee M M, et al. Models genesis: generic autodidactic models for 3D medical image analysis[M]//Sheng D G, Liu T M, Peters T M, et al. Medical image computing and computer assisted intervention-MICCAI 2019. Cham: Springer, 2019, 11767: 384-393.