

# 基于双模态深度自编码的孤立性肺结节诊断方法

赵鑫强 彦葛磊

(太原理工大学计算机科学与技术学院 太原 030024)

**摘要** 近年来,深度学习技术在肺癌诊断方面得到了广泛的应用,但现有的研究主要集中于肺部CT图像。为了有效提高肺结节的诊断性能,提出一种基于双模态深度降噪自编码的肺结节诊断方法。首先,分别从肺部CT和PET图像中得到肺结节区域的特征信息;然后,以候选结节的PET/CT图像作为整个深度自编码网络的输入,并对高层信息进行学习;最后,采用融合策略对多种特征进行融合并将其作为整个框架的输出。实验结果表明,提出的方法可以达到92.81%的准确率、91.75%的敏感度和1.58%的特异性,且优于其他方法的诊断性能,更适用于肺结节良/恶性的辅助诊断。

**关键词** 降噪自编码,双模态,深度学习,极限学习机,肺结节辅助诊断

**中图分类号** TP391 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2017.08.054

## Pulmonary Nodule Diagnosis Using Dual-modal Denoising Autoencoder Based on Extreme Learning Machine

ZHAO Xin QIANG Yan GE Lei

(College of Computer Science and Technology, Taiyuan University of Technology, Taiyuan 030024, China)

**Abstract** The existing deep learning framework used in diagnosing lung cancer still mainly focuses on lung Computed Tomography(CT) images, but it cannot obtain more higher diagnostic rate, when using only one images in the process of daily diagnosis. Therefore, in this paper, a new pulmonary nodule diagnosis method using dual-modal combined with CT and Positron Emission Tomography(PET) deep denoising autoencoder based on extreme learning machine (SDAE-ELM) was proposed to improve the diagnostic performance effectively. First of all, the method gets discriminative features information separate from the input data CT and PET. Secondly, it inputs CT and PET about candidate lung respectively in whole network. Thirdly, it extracts the high level discriminative features of nodules by alternating stack denoising autoencoder layers. Finally, it makes the fusion strategy of multi-feature fusion as the output of the whole framework. The experiment results show that classification accuracy of the proposed method can reach 92.81%, sensitivities up to 91.75% and specificity up to 1.58%. Meanwhile, the method achieves better discriminative results and is highly suited to be used for pulmonary nodule diagnosis.

**Keywords** Denoising autoencoder, Dual-modal, Deep learning, Extreme learning machine, Pulmonary nodule diagnosis

## 1 引言

孤立性肺结节(Solitary Pulmonary Nodule, SPN)是肺癌早期的重要表现。早期肺癌5年存活率可达60%,而晚期肺癌5年存活率仅有4%。因此,在早期对肺结节进行准确诊断,不仅可及时避免患者进行不必要的有创诊断,从而减轻患者的身心伤害,更能有效地提高患者的生存率。PET/CT作为一种将功能代谢活动显像和解剖结构显像两种先进影像技术进行有机结合的新型影像设备,在提高孤立性肺结节的诊断准确性上获得巨大成功,已成为常规定期肺部体检项目,但由此产生的大量医学影像也给人工阅片带来了误诊或者漏诊的情况。

深度学习网络具有分析和学习能力,能发现大量数据中

不同类型数据的分布式特征并予以表达;通过对底层结构特征的组合与学习形成更抽象的高级特征,用更为抽象的高级特征代替原始特征来表达事物的属性。

基于此,本文提出一种基于极限学习机的双模态深度无监督自编码网络框架,以对PET/CT图像中的肺结节进行学习。在这种双模态的深度学习框架中,PET/CT图像首先以图像对的形式输入到深度自编码框架中,然后以各自不同的深度学习结构对图像进行有监督特征学习,最后以线性组合的方式对学习到的不同模态的特征进行融合。

## 2 相关工作

肺结节的检测和诊断工作在国内外已有了一定的研究成

到稿日期:2017-02-07 返修日期:2017-05-16 本文受国家自然科学基金项目:基于医学影像结构和功能混合特征的周围型肺癌计算机辅助诊断方法(61373100),北京航空航天大学虚拟现实技术与系统国家重点实验室开放基金(BUAA-VR-17KF-14, BUAA-VR-17KF-15),山西省回国留学人员科研资助项目(2016-038)资助。

赵鑫(1993-),女,硕士生,主要研究方向为医学图像处理、深度学习, E-mail: 1009646066@qq.com; 强彦(1969-),男,教授,博士生导师,主要研究方向为图像处理、云计算技术、物联网技术; 葛磊(1990-),男,硕士生,主要研究方向为医学图像处理与模式识别。

果。Lila 等<sup>[1]</sup>提出基于遗传算法构建的最优数据特征集,并利用支持向量机进行肺结节良/恶性的分类。Li 等人<sup>[2]</sup>使用 Logistic 多元回归分析对 CT 图像中结节的形态特征进行分析与选择,但仅局限于 CT 征象,并未考虑到结节的 PET 特征。国内则更多使用传统的方式,其中魏颖等人<sup>[3]</sup>利用局部灰度最大值对 ROI 区域进行预分割,并采用改进的马氏距离进行孤立型肺结节的分类,结果较好,但准确率较低;夏旭东等人<sup>[4]</sup>对孤立型肺结节辅助检测的相关研究进行了综述,指出目前使用较频繁的分类器为人工神经网络、基于规则的分类器、SVM 分类器等;孙申申等人<sup>[5]</sup>利用改进遗传算法选取最优特征组合并构造 SVM 分类器,特异度达到了 95.5%。

如今,深度学习开始被各界学者用于多个领域,其中包括被计算机辅助医学诊断研究专家广泛应用于医学数据的处理中。Hua 等<sup>[6]</sup>尝试利用卷积神经网络和深度信念网络来诊断 CT 图像中的肺结节,并通过与其他方法的比较证明了利用深度学习进行诊断的优势。Setio 等<sup>[7]</sup>提出基于多视角卷积神经网络的肺结节辅助检查系统,然后将输出进行融合得到最后的分类。Devinder<sup>[8]</sup>和 Jia<sup>[9]</sup>使用通过自编码(Auto Encoder)提取的特征来对 CT 图像的肺结节进行良/恶性诊断。Shen 等<sup>[10]</sup>使用多尺度卷积神经网络去捕获 LIDC 中肺部 CT 图像中具有区别性特征的结节,取得了 86.84% 的识别率。

基于深度学习给医学图像检测与分类带来的优势,将深度学习网络自编码与极限学习机分类器两者结合,从而实现从多种类型的图像上对肺结节进行一定的诊断和分类。

### 3 相关理论

#### 3.1 极限学习机

极限学习机(Extreme Learning Machine, ELM)<sup>[11]</sup>是一种执行速度快、泛化能力强的单隐层前馈神经网络算法。相比于传统的神经网络学习算法(BP 算法)需要人为设置大量的训练参数,极限学习机的训练只需设置网络中的隐层节点个数,不需要对网络的输入权重以及隐层神经元的偏置进行调整,且最终产生唯一最优解。Huang 等人<sup>[12]</sup>研究发现,将极限学习机用于深度学习时,不仅能保证准确率,训练速度也要比传统深度学习方法快几个数量级。因此,本节提出将自编码与极限学习机进行结合,结构图如图 1 所示。




图 1 SAE-ELM 网络结构图

在含有 L 个隐含层单元的极限学习机中, N 个随机样本(其中  $x_i = [x_{i1}, x_{i2}, \dots, x_{id}]^T \in R^d$ ) 在输出层通过式(1)被重构出来:

$$\sum_{i=1}^N \beta_j \cdot g(a_i \cdot x_j + b_i) = x_j, j \in [1, N] \tag{1}$$

其中,  $a_i = [a_{i1}, a_{i2}, \dots, a_{id}]^T$  是随机产生的输入权重,  $\beta = [\beta_1, \beta_2, \dots, \beta_{id}]^T$  是重构矩阵,  $g(\cdot)$  是隐含层的激励函数。式(1)可以写成矩阵的形式:

$$H\beta = X \tag{2}$$

SAE-ELM 的重构矩阵  $\beta$  可以由广义逆求出:

$$\hat{\beta} = H^+ T = H^T (\frac{1}{C} + HH^T)^{-1} X \tag{3}$$

其中,  $H = [h_1, h_2, \dots, h_N]$  表示 SAE-ELM 的隐含层矩阵,  $X = [x_1, x_2, \dots, x_n]$  表示 SAE-ELM 的输入和输出矩阵。因此,极限学习机对应的输出为:

$$f(x) = h(x) H^T (\frac{1}{C} + HH^T)^{-1} X \tag{4}$$

相比于传统学习算法,极限学习机不仅在训练错误率方面实现了最优,在优化整个网络的输出权重的选取上也达到了最优。

#### 3.2 降噪自编码

降噪自编码神经网络(Denoising AutoEncoder, DAE)<sup>[13]</sup>是 Vincent 等人在普通自编码网络基础上提出的一种可以明显提升网络鲁棒性的结构模型,其结构如图 2 所示。Vincent 等人认为,如果学习到的特征具有极强的表征能力,那么即使数据信息存在部分缺失,通过网络的重构也可以实现对原始数据的完整重构。因此, DAE 与普通自编码一样,同样需要编码和解码阶段来重构数据,唯一的区别在于 DAE 输入的是有噪声的样本数据,重构学习出的是一个无噪声的样本数据,网络具有较强的去噪能力,对噪声污染的样本具有一定的鲁棒性和泛化能力。这种方法的实现同时降低了网络模型过拟合带来的影响。




图 2 降噪自编码结构图

降噪自编码过程中,首先对样本  $x$  进行加噪处理,获得  $\tilde{x} \sim q_D(\tilde{x}|x)$ ,即以一定的概率强制使得输入层神经元的节点为 0;然后用“损坏”数据  $\tilde{x}$  作为输入向量,通过激活函数映射到隐含层的特征表示  $y = f_\theta(\tilde{x}) = s(W\tilde{x} + b)$ ;最后通过重构函数重构出原始未被污染的样本数据信息。通过式(5)最小化原始输入数据  $x$  与重构数据的平均重构误差来进行参数优化。

$$O_\beta = \arg \min_{\beta} \frac{1}{m} \sum_{i=1}^m (\frac{1}{2} \| f(\tilde{x}_i) \beta - x_i \|^2) \tag{5}$$

其中,  $x_i$  是原始未加入噪声的样本向量数据,  $\tilde{x}_i$  是加入随机噪声的样本向量数据,  $\beta$  是输出权重。

### 4 算法实现

本文提出了一种双模态肺结节诊断方法,如图3所示。首先,对给定的肺部CT和PET图像进行对应预处理以获得ROI区域;然后,通过降噪自编码分别从CT和PET图像的低层特征中挖掘出高层特征并进行表示;之后,将CT特征和PET特征进行线性组合以实现多模态特征融合,从而获得高层特征;最后,使用Logistic回归分析进行诊断。




图3 本文方法的示意图

#### 4.1 肺部CT与PET图像预处理

对CT图像进行预处理,以消除背景、机架和噪声等的影响,如图4所示。




图4 数据预处理

在提取ROI区域的过程中,采用结合多尺度分水岭与区域生长法的肺实质分割方法,并采用改进的滚球法对肺实质边缘进行一定修补<sup>[14-15]</sup>。在去除血管影响的前提下,对肺结节进行精确定位,并用肺结节的外接矩形作为ROI。PET图像则通过使用互信息的改进非刚性配准方法,与CT图像配准后获得相同位置区域作为ROI<sup>[16]</sup>,如图5所示。

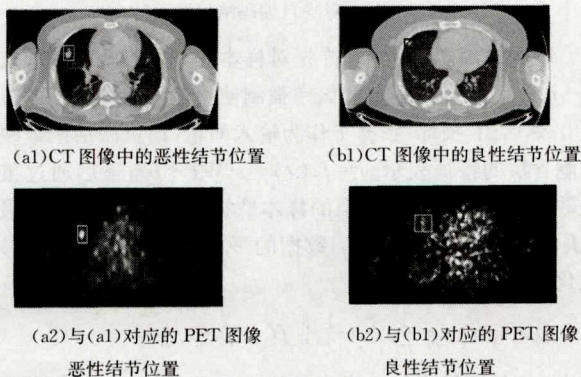


图5 PET/CT中肺结节的标注(方框位置)

#### 4.2 输入权重优化方法

医师主要依据不同性质的结节显现的不同征象对肺结节的良/恶性进行诊断,这些征象集中表现在结节的形状、纹理中,如图6所示。本文通过利用良性和恶性组织之间像素级的差异性构建自编码模块的初始权值和偏置,为之后的诊断做准备。




图6 不同性质的结节显现的不同征象

传统神经网络中,输入层到隐含层的输入权重为原始样本映射到有区分性的高维特征空间,实现对样本的较好分类<sup>[17]</sup>。在传统ELM算法中,输入权重和偏置随机生成,没有任何约束,分类也较少有区别。因此,在样本中引入类间约束<sup>[18]</sup>,样本类间差能够将样本映射到高维有区别的特征空间,使输入层到隐含层的权值向量映射具有一定的方向性。本文中使用的约束差分极限学习机(Constrained Difference Extreme Learning Machine, CDELM)算法的描述如算法1所示。

#### 算法1 约束差分极限学习机(CDELM)算法描述

输入:训练样本,隐含层结点数L,激活函数G(w,b,x)  
输出:CDELM模型参数(输入层到隐含层的权重矩阵 $W_{n \times L}$ 和偏置向量 $b_{1 \times L}$ ,隐含层到输出层的权重矩阵 $\beta_{L \times m}$ )  
步骤:

1. 当所选择的差分向量数小于L时,
  - 1.1. 随机选择训练样本 $x_{c1}$ 和 $x_{c2}$ ,并从任意两个不同类中生成差分向量 $x_{c2} - x_{c1}$ ;
  - 1.2. 归一化差分向量 $w = \frac{2(x_{c2} - x_{c1})}{\|x_{c2} - x_{c1}\|_{L_2}}$ ,并计算相应的偏差 $b = \frac{(x_{c1} + x_{c2})^T(x_{c1} - x_{c2})}{\|x_{c2} - x_{c1}\|_{L_2}^2}$ ;
  - 1.3. 使用向量w和偏置b构建权重矩阵 $W_{n \times L}$ 和偏置向量 $b_{1 \times L}$ 。
2. 使用CDELM方法计算隐含层输出矩阵:
3. 计算隐含层输出权值矩阵 $\beta_{L \times m}$ :

$$\beta = H^T T$$

$$H = \begin{bmatrix} h(x_1) \\ \vdots \\ h(x_N) \end{bmatrix} = \begin{bmatrix} G(a_1, b_1, x_1) & \cdots & G(a_L, b_L, x_1) \\ \vdots & \cdots & \vdots \\ G(a_1, b_1, x_N) & \cdots & G(a_L, b_L, x_N) \end{bmatrix}_{N \times L}$$

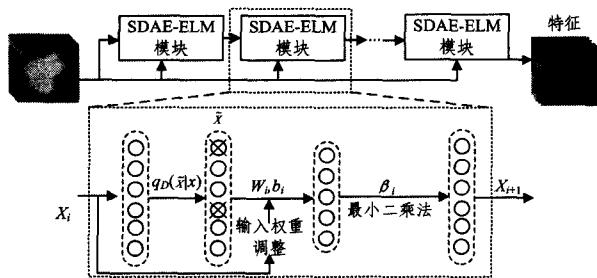
其中, $H^T$ 为广义逆矩阵, $T = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix}_{N \times m}$ 。

实验证明,采用CDELM分别对CT图像、PET图像以及

PET/CT 图像特征进行融合和分类,在准确率、敏感度和特异性上都有约 5% 的提高,更利于后期肺结节的诊断。

### 4.3 基于深度极限学习机的降噪自编码

与传统自编码算法不同的是,本文根据良/恶性肺结节在 PET/CT 上表现出的不同结构和灰度特征,在开始阶段使用类间差方式对自编码网络进行输入权重初始化;之后又将样本的标签信息加入到自编码网络,实现对网络的半监督。本文提出的自编码框架以模块的形式构建而成,将前一个模块的输出作为下一个模块的输入。每个模块的自编码过程如图 7 中虚线框所示。将每个模块的编码过程命名为基于 ELM 的降噪自编码(SDAE-ELM)。



虚线框中是单个 SDAE-ELM 模块流程图

图 7 深度降噪自编码特征学习的网络框架

对于 SDAE-ELM 网络结构,CT 图像使用 5 个隐含层, PET 图像使用 5 个隐含层,隐含层单元的节点个数与输入层的相同,这样的参数设置均是基于之前的实验的。这里, PET 和 CT 表示 PET 特征和 CT 特征融合成一个向量。

### 4.4 多模态特征融合及分类

PET/CT 两者的特征具有相辅相成性,对提高医师对肺结节最后诊断的准确率有很大影响。因此,构建一种同时使用 PET 和 CT 特征的方法则显得极为重要。对于特征级融合而言, PET 和 CT 特征串行连接在特征级进行融合,使用 Logistic 回归分类器把融合后的特征(PET/CT)都作为输入数据输入到同一个网络中,最后的结果由多种特征在分类器中共同作用得到,如图 8 所示。




图 8 多模态特征融合

在充分利用不同特征之间互补信息的同时,对不同融合层次之间的互补信息加以利用。由于 PET/CT 图像的大小相同,将特征级融合分类结果进行自适应的再融合,将 PET 和 CT 特征进行线性组合,具体计算如式(6)所示:

$$S(Fusion) \propto \alpha \cdot S(CT) + (1-\alpha)S(PET) \quad (6)$$

其中,系数  $\alpha$  控制两种特征融合后的贡献度,并通过交叉验证不断进行优化。最后将融合后的特征输入到分类器中进行最后的决策。

## 5 实验结果分析和对比

### 5.1 实验环境和数据集

该方法的实验环境为 Matlab2012b, Intel(R) Core (TM)

i7 处理器, 3.40GHz 主频, 8GB 内存。

本文方法所使用的实验数据来自于山西某医院 PET/CT 中心,图像中共有结节 2810 个(最大直径范围为: 1.6 ~ 23mm,平均最大直径为 5.1mm)。该医院使用的是美国通用公司的 Discovery ST16 PET-CT, CT 采集参数为 150mA, 140kV, 层厚 3.75mm, CT 图像大小为 512×512。PET 采集参数为 150mA, 140kV, 厚度 3.75mm, PET 图像大小为 128×128。

本文使用的肺结节已至少获得两位放射学家的一致诊断。研究中使用 520 名患者病例,从中筛选出 800 个良性结节和 800 个恶性结节的 PET/CT 图像。

### 5.2 实验设置

在肺结节良/恶性分类实验中,肺结节 CT 和 PET 图像被用来对肺结节进行诊断。对于分类问题,使用 5-折交叉验证方式,随机将数据集分成 5 个子集,将 5 个子集中的 4 个子集用于训练,剩余的 1 个用于测试。重复这样的实验 5 次。

在最后的决策阶段,分类选取不同的经典分类器进行诊断,选取最优的分类器作为最终的诊断工具。采用分类的准确度、敏感度和特异性来评估整体的分类性能,最后的实验结果是在重复运行的基础上由平均值和标准差的形式给出。

### 5.3 实验结果与分析

#### 5.3.1 分类器选取

将通过深度自编码得到的高维特征信息输入到不同的分类器进行实验,从而得到最优的诊断性能。传统的分类算法包括: BP 神经网络、SVM 和逻辑回归。从表 1 中可以看出,对于 4 种不同特征, Logistic 回归分析的分类性能要优于其他分类器,并且对于特征层融合特征, Logistic 回归分析方法获得最好的分类性能,准确率为 92.81%, 敏感度为 91.75%, 特异性为 94.37%, 并且 Logistic 回归分析方法的标准差要普遍小于其他分类器,说明 Logistic 方法对于融合以后的特征具有较稳定的分类性能。

表 1 不同分类器对分类性能的影响/%

特征		BP	SVM	逻辑回归	ELM
CT	准确率	72.51±3.68	79.37±3.64	84.68±1.26	82.81±1.10
	敏感度	71.87±3.33	81.87±2.68	90.62±5.53	84.38±2.19
	特异性	73.12±3.39	76.87±2.53	78.75±3.62	81.25±2.70
PET	准确率	75.31±2.75	80.00±3.02	92.81±0.57	88.75±1.30
	敏感度	77.46±4.46	78.12±3.21	91.75±1.53	90.63±1.14
	特异性	73.13±4.25	81.87±4.03	94.37±0.62	86.87±4.21

#### 5.3.2 不同自编码模型的比较

实验中将所提出的 SDAE-ELM 模型与其他深度自编码模型进行比较。比较模型包括自编码(AE)和降噪自编码(DAE)和受限波尔兹曼机(RBM)。为了保证对比的有效性,所有提到的自编码均使用随机分配的初始权重,使用 sigmoid 作为激活函数,使用重构误差作为目标函数,采用梯度下降法进行参数寻优。所有的模型都通过单模型堆叠起来对本文肺结节数据进行分类,并且按表 2 设置相关参数,使得网络取得最优的分类性能。

表2 不同深度学习网络的参数设置

参数	SAE	SDAE	DBN
隐含层结点	500	800	900
隐含层数	2AE	3DAE	3RBMs
Epoch	900/900	500/500/500	600/600/400
块尺寸	200	200	200

每个自编码模型均使用单模态 CT 图像作为输入,将其输入到栈式自编码网络后,使用自带的分类器进行分类诊断。表3列出了不同自编码方法的实验结果。网络的分类能力通常使用准确率、敏感度、特异性及其训练时间进行多方考量。如表3中的实验数据所示,相比之下,本文提出的 SDAE-ELM 自编码模型分别获得  $82.81 \pm 1.10\%$  的准确率、 $84.38 \pm 2.19\%$  的敏感度、 $81.25 \pm 2.70\%$  的特异性,用时 28.37s,证明所提方法在训练时间和分类性能上都优于其他方法。此外,所提方法将极限学习机用于编码模块,以保证每个模块重构误差最小化,使得到的特征具有最强的表征能力。

表3 不同自编码方法的实验结果

深度框架	准确率/%	敏感度/%	特异性/%	训练时间/s
AE	72.19±3.43	75.62±4.09	68.75±3.68	366.15
DAE	75.20±3.43	76.25±4.09	73.75±3.68	377.03
RBM	78.43±2.69	80.00±3.12	76.87±2.89	523.71
Ours	92.81±1.10	86.38±2.19	91.25±2.70	28.37

### 5.3.3 不同诊断方法的比较

为进一步阐明本文方法在肺结节诊断方面的有效性,现将其与其他基于深度学习技术的肺结节诊断的有效方法进行比较,最终结果以它们在肺结节辅助诊断中的分类准确率、敏感度和假阳性率作为评价标准。

最终实验结果如表4所列。

表4 不同肺结节诊断方法的诊断性能比较

方法	准确率/%	敏感度/%	假阳性率	AUC
Setio <sup>[7]</sup>	85.63±3.42	86.87±2.88	2.08	0.87
Devinder <sup>[8]</sup>	74.69±2.53	71.25±1.06	5.00	0.81
Jia <sup>[9]</sup>	80.01±2.58	82.50±3.06	3.86	0.85
Shen <sup>[10]</sup>	88.75±8.46	91.84±8.24	1.92	0.90
Ours	92.81±0.57	91.75±1.53	1.58	0.94

Setio 和 Shen 的方法由于分别使用多尺度和多视角的深度学习技术,因此其诊断性能在一定程度上要优于单一尺度的方法,但其中所阐述的多尺度或多视角都仅是相同模态图像在不同方式下的具体呈现;而本文所提的多模态深度学习技术则是采用不同成像原理或技术呈现出肺结节的特征,这样从深度学习框架中输出的则是不同模态图像特征的融合,这种融合特征呈现要比单一模态的特征具有更好的分类性能。

表4所列实验结果表明,本文方法在准确率、敏感度方面都明显优于其他4种肺结节诊断方法,且网络中融合特征的改进使分类诊断中每个病人的假阳性从5降到1.58。同时,图9示出不同诊断模型的 ROC 曲线,该曲线反映了不同模型的诊断性能,曲线下面积越大,说明模型的诊断效果越好。因此,从图9中也可以明显地看出,本文所提方法在肺结节诊断方面所具有的优势。




图9 不同诊断模型的 ROC 曲线

**结束语** 本文以肺结节 PET/CT 图像为研究对象,提出了一种基于双模态的深度自编码框架(SDAE-ELM),其通过无监督降噪自编码的方式学习不同模态的医学图像特征,从而实现肺结节的良/恶性诊断。

实验中从不同角度对本文算法进行了相关评价,结果本文的方法都取得了较高的诊断准确率,表明本文的方法在肺结节诊断方面具有较高的实用价值。在未来的研究工作中,我们将进一步扩展不同模态的数据,如核磁共振图、病理切片和病例的文本信息,继续在多模态深度学习方面进行探索。

## 参考文献

- [1] LILLA B, LUYIN Z, LEE K P. Feature subset selection for improving the performance of false positive reduction in lung nodule CAD[J]. IEEE Transactions on Information Technology in Biomedicine A Publication of the IEEE Engineering in Medicine & Biology Society, 2006, 10(3): 85-90.
- [2] LI Y, CHEN K Z, WANG J. Development and validation of a clinical prediction model to estimate the probability of malignancy in solitary pulmonary nodules in Chinese people[J]. Clinical Lung Cancer, 2011, 12(5): 313-319.
- [3] WEI Y, GUO W, SUN Y F, et al. A Lung Nodule Detection Algorithm Based on Local Maximum Gray Segmenting and Improved Mahalanobis Distance Classifying[J]. Journal of Image and Graphics, 2008, 13(9): 1720-1726. (in Chinese)  
魏颖, 郭毅, 孙月芳, 等. 基于局部灰度最大和改进 Mahalanobis 距离分类的肺结节检测算法[J]. 中国图象图形学报, 2008, 13(9): 1720-1726.
- [4] NIE S D, SUN X W, CHEN Z X. Progress on Computer-Aided Detection for Pulmonary Nodule Using CT Image[J]. Chinese Journal of Medical Physics, 2009, 26(2): 1075-1079. (in Chinese)  
聂生东, 孙希文, 陈兆学. 基于 CT 图像的肺结节计算机辅助检测技术的研究进展[J]. 中国医学物理学杂志, 2009, 26(2): 1075-1079.
- [5] SUN S S, REN H Z, KANG Y, et al. Lung Nodule Detection by GA and SVM[J]. Journal of System Simulation, 2011, 23(3): 497-501. (in Chinese)  
孙申申, 任会之, 康雁, 等. 基于遗传算法和支持向量机的肺结节检测[J]. 系统仿真学报, 2011, 23(3): 497-501.
- [6] HUA K L, HSU C H, HIDAYATI S C, et al. Computer-aided classification of lung nodules on computed tomography images via deep learning technique[J]. OncoTargets and therapy, 2015, 8: 2015-2022.

- [7] SETIO A A, CIOMPI F, LITJENS G, et al. Pulmonary nodule detection in CT images; false positive reduction using multi-view convolutional networks. [J]. IEEE Transactions on Medical Imaging, 2016, 35(5): 1.
- [8] KUMAR D, WONG A, CLAUSI D A. Lung Nodule Classification Using Deep Features in CT Images[C]//Computer and Robot Vision. IEEE, 2015: 110-116.
- [9] JIA T, ZHANG H, BAI Y K. Benign and Malignant Lung Nodule Classification Based on Deep Learning Feature[J]. Journal of Medical Imaging & Health Informatics, 2015, 5(8): 1936-1940.
- [10] WEI S, MU Z, FENG Y, et al. Multi-scale Convolutional Neural Networks for Lung Nodule Classification [M] // Information Processing in Medical Imaging. Springer International Publishing, 2015: 588-99.
- [11] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: Theory and applications[J]. Neurocomputing, 2006, 70(1-3): 489-501.
- [12] HUANG G B, BAI Z, KASUN L L C, et al. Local Receptive Fields Based Extreme Learning Machine[J]. IEEE Computational Intelligence Magazine, 2015, 10(2): 18-29.
- [13] VINCENT P, LAROCHELLE H, LAJOIE I, et al. Stacked Denoising Autoencoders: Learning Useful Representations in a Deep Network with a Local Denoising Criterion[J]. Journal of Machine Learning Research, 2010, 11(12): 3371-3408.
- [14] QIANG Y, JI G, HAN X, et al. Coarse-to-Fine Lung Segmentation in Computed Tomography Images[J]. Journal of Computational and Theoretical Nanoscience, 2015, 12(2): 330-334.
- [15] ZHAO J, MA R, QIANG Y, et al. Solitary Pulmonary Nodule Segmentation Based on the Rolling Ball Method[J]. Journal of Computational and Theoretical Nanoscience, 2015, 12(8): 1977-1983.
- [16] QIANG Y, ZHANG X, JI G, et al. Automated Lung Nodule Segmentation Using an Active Contour Model Based on PET/CT Images[J]. Journal of Computational and Theoretical Nanoscience, 2015, 12(8): 1972-1976.
- [17] TANG J, DENG C, HUANG G B. Extreme Learning Machine for Multilayer Perceptron. [J]. IEEE Transactions on Neural Networks & Learning Systems, 2015, 27(4): 809-821.
- [18] ZHU W, MIAO J, QING L. Constrained Extreme Learning Machines: A Study on Classification Cases[J/OL]. Computer Science, <https://arxiv.org/ftp/arxiv/papers/1501/1501/06115.pdf>.

(上接第 300 页)

- [3] GILL G, TOEWS M, BEICHEL R R. Robust Initialization of Active Shape Models for Lung Segmentation in CT Scans: A Feature-Based Atlas Approach[J]. International Journal of Biomedical Imaging, 2014, 2014(1/2): 479154-479154.
- [4] CAO L, ZHAN J, YU X E, et al. Fast lung segmentation algorithm for thoracic CT based on automated thresholding [J]. Computer Engineering and Applications, 2008, 44(12): 178-181. (in Chinese)  
曹蕾, 占杰, 余晓镔, 等. 基于自动阈值的 CT 图像快速肺实质分割算法[J]. 计算机工程与应用, 2008, 44(12): 178-181.
- [5] MANSOOR A, BAGCI U, MOLLURA D J. Near-optimal keypoint sampling for fast pathological lung segmentation[C]//2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). IEEE, 2014: 6032-6035.
- [6] SHOJAII R, ALIREZAIE J, BABYN P. Automatic segmentation of abnormal lung parenchyma utilizing wavelet transform [C]//IEEE International Conference on Acoustics, Speech and Signal Processing, 2007 (ICASSP 2007). IEEE, 2007: 1217-1220.
- [7] QIANG Y, ZHANG X, JI G, et al. Automated Lung Nodule Segmentation Using an Active Contour Model Based on PET/CT Images[J]. Journal of Computational and Theoretical Nanoscience, 2015, 12(8): 1972-1976.
- [8] REN X, MALIK J. Learning a classification model for segmentation[C]//Ninth IEEE International Conference on Computer Vision, 2003. IEEE, 2003: 10-17.
- [9] WEN W X, LIU H, JENNINGS A. Self-generating neural networks[C]//International Joint Conference on Neural Networks. IEEE, 1992: 850-855.
- [10] ZHAO J, JI G, XIA Y, et al. Cavitory nodule segmentation in computed tomography images based on self-generating neural networks and particle swarm optimisation [J]. International Journal of Bio-Inspired Computation, 2015, 7(1): 62-67.
- [11] WU H, WANG R G, FANG S, et al. Image segmentation algorithm research based on minimum within-cluster difference and maximum between-cluster difference[J]. Journal of Engineering Graphics, 2011, 32(1): 67-75. (in Chinese)  
吴昊, 汪荣贵, 方帅, 等. 基于最小类内差和最大类间差的图像分割算法研究[J]. 图学学报, 2011, 32(1): 67-75.
- [12] LI L. Optimized self-generating neural network for image segmentation[J]. Infrared Technology, 2010, 32(4): 198-203. (in Chinese)  
李露. SGNN 优化算法的研究及其在图像分割中的应用[J]. 红外技术, 2010, 32(4): 198-203.
- [13] JI G H, ZHAO J J, PAN L. Classification of solitary pulmonary nodules based on improved self-generating neural network[J]. Journal of Taiyuan University of Technology, 2015, 46(6): 754-759. (in Chinese)  
纪国华, 赵涓涓, 潘玲. 基于改进自生成神经网络的孤立性肺结节分类[J]. 太原理工大学学报, 2015, 46(6): 754-759.
- [14] LI D W, WANG J, CHEN J H, et al. Liver segmentation by using an optimal framework for CT images[J]. Chinese Journal of Computers, 2016, 39(7): 1-13. (in Chinese)  
李登旺, 王杰, 陈进璇, 等. 基于最优值搜索框架的 CT 序列图像肝脏分割[J]. 计算机学报, 2016, 39(7): 1-13.
- [15] UNNIKRIISHNAN R, HEBERT M. Measures of similarity[C]//Seventh IEEE Workshops on Application of Computer Vision, 2005(WACV/MOTIONS'05). IEEE, 2005, 1: 394.