

用于肺结节影像分类识别的 DBN 与 CNN 的比较研究

张华丽¹ 康晓东¹ 冉华² 王亚鸽¹ 李博¹ 白放¹

¹ 天津医科大学医学影像学院 天津 300203

² 重庆市黔江中心医院 重庆 409000

(aszhanghuali@163.com)

摘要 针对肺结节图像的分类识别精度和效率问题,分别将 CNN(Convolution Neural Network)模型和 DBN(Deep Belief Network)模型用于肺结节分类识别,并评估不同的深度学习模型在肺结节图像分类方面的性能。首先,实验将预处理过的训练集和标签分别输入到 CNN 模型和 DBN 模型,达到训练模型的目的;其次,将测试集输入到参数最优的模型中,比较两种模型测试集分类的准确率、敏感性和特异性,并分析两种模型的分类识别性能。最后,从分类准确率、敏感性和特异性 3 个指标以及时间复杂度来分析比较两种模型,发现 CNN 模型在肺结节图像分类识别上更有优越性。

关键词:肺结节;DBN;CNN;图像分类识别

中图法分类号 TP391.41

Comparative Study of DBN and CNN for Pulmonary Nodule Image Recognition

ZHANG Hua-li¹, KANG Xiao-dong¹, RAN Hua², WANG Ya-ge¹, LI Bo¹ and BAI Fang¹

¹ School of Medical Imaging, Tianjin Medical University, Tianjin 300203, China

² Qian jiang Central Hospital of Chongqing, Chongqing 409000, China

Abstract Aiming at the classification and recognition accuracy and efficiency of pulmonary nodule images, CNN model and DBN model were used to classify pulmonary nodules, and the performance of different deep learning models in pulmonary nodule image classification was evaluated. Firstly, the experiment input the pre-processed training set and label into the CNN model and the DBN model respectively to achieve the purpose of training the models. Secondly, the test set was input into the parameter-optimized model, and the accuracy, sensitivity and specificity of the classification of the two models were compared. What's more, the classification and recognition performance of the two models was analyzed. Finally, the two models were analyzed and compared based on the three indicators: classification accuracy, sensitivity and specificity, as well as time complexity. It is found that the CNN model is more advantageous in the classification and recognition of pulmonary nodules.

Keywords Pulmonary nodules, DBN, CNN, Image classification and identification

1 引言

近年来,医学影像图像处理^[1]成为人们研究的一大热点,作为计算机辅助诊断(Computer Aided Diagnosis, CAD)^[2]的最新研究成果,深度学习(Deep Learning)能够准确检测出影像图像病变的部位,降低漏检率,辅助放射科诊断医生分析图像。在肺结节图像分类识别研究领域中,Shen 等^[3]设计深度卷积神经网络对肺结节图像进行特征提取,其分类准确率为 86.84%;Yang 设置一个 9 层卷积神经网络的肺结节图像分类模型,其分类的准确率为 89.0%,与传统分类方法相比,展现出了卷积神经网络自动提取图像特征的突出优势^[4]。Hinton 等^[5]于 2006 年提出深度置信网络,目前已广泛应用于时间序列预测^[6]、用户电影评估^[7]以及语音识别^[8]等领域。Yang 等自定义 5 层深度置信网络模型,并首次将目标追踪应用到肺部图像,快速提取出了肺部感兴趣区域,减少了像素样本量,较为准确地识别出了肉眼难以辨别的肺结节类型^[9];

Yan 等构建了一种基于卷积的玻尔兹曼机(Convolutional Restricted Boltzman Machine, CRBM)来自动学习肺结节图像特征,再将此特征作为分类受限玻尔兹曼机(ClassRBM)的输入,进而实现结节分类,实验引入了交叉熵稀疏惩罚对分类受限玻尔兹曼机进行优化,避免了在训练中出现特征同质化问题,提高了实验结果的可信度^[10];Yang 等先从多角度提取结节特征,特征向量能更加全面地描述结节细节,并首次尝试将特征向量输入到深度置信网络分类器,其算法分类准确率,敏感性和特异性分别为 95.3%,92.5%和 93.2%^[11];Liu 等针对孤立性肺结节 CT 图像分类较为困难这一问题,将深度置信网络模型用于孤立性肺结节图像分类中,并与基于纹理特征和高分辨率直方图特征的 SVM 模型进行对比,实验结果表明,与 SVM 分类器相比,多层的深度置信网络模型能提取出图像的更多细节特征,对孤立性肺结节图像的分类性能有了明显提高^[12]。由此可见,卷积神经网络和深度置信网络在肺结节的分类识别上都有一定的研究,并且与传统结节分类

基金项目:京津冀协同创新项目(17YFXTZC0020)

The work was supported by Beijing-Tianjin-Hebei Collaborative Innovation Project (17YFXTZC0020).

通信作者:冉华(1319466165@qq.com)

方法相比都取得了良好的改善,但通过进一步的对比实验,分析两种模型的机制,评估两种模型的性能,可以进一步提升分类的识别效果和效率。

本文分别设计了 6 层深度置信网络和 7 层卷积神经网络,为防止网络出现过拟合现象和提升网络结构的鲁棒性,对 LUNA16 数据集进行了数据增强处理;将预处理过的肺部图像数据样本输入到深度置信网络和卷积神经网络,并对两种模型的性能进行对比评估。实现结果表明,与本文 DBN 模型、文献[11]和文献[12]的分类识别模型相比,本文 CNN 模型达到了更好的分类识别效果。

2 深度置信网络和卷积神经网络

2.1 深度置信网络

深度置信网络是由多个无监督学习受限玻尔兹曼机(Restricted Boltzmann Machine, RBM)和最后一层 Softmax 分类器堆叠而成^[13]。

受限玻尔兹曼机是一个基于能量的模型^[14],涉及到能量函数和概率分布。给定状态 (v, h) 的 RBM 模型的能量函数为:

$$E(v, h | \theta) = - \sum_{i=1}^n a_i v_i - \sum_{j=1}^m b_j h_j - \sum_{i=1}^n \sum_{j=1}^m w_{ij} h_j v_i \quad (1)$$

其中, n 代表可见节点数, m 代表隐藏节点数, w_{ij} 表示可见节点 i 与隐藏节点 j 之间的权重, a_i 表示可见节点的偏置, b_j 是隐藏节点的偏置, v_i 表示第 i 个可见单元的状态, h_j 表示第 j 个隐藏单元的状态。简单起见,假设每个节点的状态取值都是 0 或 1, 即 $v_i \in \{0, 1\}$, $h_j \in \{0, 1\}$, $i \in \{1, \dots, n\}$, $j \in \{1, \dots, m\}$ 。

根据能量函数,定义一个可见节点和隐藏节点的联合概率,则联合概率分布为:

$$\begin{cases} P(v, h | \theta) = \frac{1}{Z(\theta)} e^{-E(v, h | \theta)} \\ Z(\theta) = \sum_{v, h} e^{-E(v, h | \theta)} \end{cases} \quad (2)$$

其中, $Z(\theta)$ 为归一化因子。

又由联合概率可计算 $P(h_j = 1 | v)$ 和 $P(v_i = 1 | h)$:

$$\begin{cases} P(h_j = 1 | v) = \sigma(b_j + \sum v_i w_{ij}) \\ P(v_i = 1 | h) = \sigma(a_i + \sum w_{ij} h_j) \end{cases} \quad (3)$$

其中, $\sigma(x)$ 函数为神经网络的激活函数。

对于给定训练样本,训练 RBM 的目的是调整参数以拟合给定的训练数据集。对于参数的求解往往采用极大似然函数求导的方法。极大似然函数的定义为:

$$\theta^* = \arg \theta \max_{\theta} \sum_{t=1}^T \ln P(v^{(t)} | \theta) \quad (4)$$

其中, T 表示样本数。

受限玻尔兹曼机各参数的更新主要是采用对比散度算法^[15](CD 算法),具体内容如下:

$$\begin{aligned} \Delta w_{ij} &= \epsilon (\langle v_i h_j \rangle_{\text{data}} - \langle v_i h_j \rangle_{\text{recon}}) \\ \Delta a_i &= \epsilon (\langle v_i \rangle_{\text{data}} - \langle v_i \rangle_{\text{recon}}) \\ \Delta b_j &= \epsilon (\langle h_j \rangle_{\text{data}} - \langle h_j \rangle_{\text{recon}}) \end{aligned} \quad (5)$$

其中, ϵ 为预训练学习率, $\langle \cdot \rangle_{\text{data}}$ 为训练数据集定义分布上的数学期望, $\langle \cdot \rangle_{\text{recon}}$ 为重构后模型所定义分布上的数学期望。

2.2 卷积神经网络

卷积神经网络是常用的深度神经网络模型。完整的卷积神经网络包括输入层(Input Layer)、卷积层(Convolution

Layer)、池化层(Pooling Layer)、全连接层(Full Connect Layer)和 Softmax 层^[16]。

(1)卷积层。卷积层是整个卷积神经网络的核心结构,其主要作用是将输入的图像通过卷积核进行卷积,进而提取特征。卷积层的计算公式如下:

$$y = f(\sum_{i=1}^n w_i x_i + b) \quad (6)$$

其中, w_i 为权重, b 为偏置。

(2)池化层。常见的池化层主要有两种处理方式:最大池化(Max Pooling)和平均池化(Mean Pooling)。池化层不会改变特征矩阵的深度,但可以缩小矩阵的大小,提取更抽象的特征。池化层的计算公式如下:

$$y'_j = f(\beta'_j \text{down}(x_j^{-1}) + b'_j) \quad (7)$$

其中, $\text{down}()$ 表示下采样函数, β'_j 和 b'_j 分别表示对应的权重和偏置。

(3)全连接层。全连接层的作用是将特征图像转化为一维的特征向量,并利用反向传播算法对整个网络的参数进行调整,提高卷积神经网络的准确度。


3 研究方法

本文中整个肺结节图像分类识别实验流程主要包含 3 步:1)根据 LUNA16 数据集中的标注信息制作实验数据集,包括数据归一化、数据增强;2)设计网络参数,进行 CNN 模型和 DBN 模型训练;3)从分类准确率、敏感性、特异性和模型训练时间等方向来评估模型分类结果。

3.1 数据集预处理

本文所采用的图像数据来自公开的 LUNA16 (Lung Nodule Analysis 16)数据集的部分样本和重庆黔江中心医院提供的肺部 CT 图像。LUNA16 数据集是数据集 LIDC-IDRI^[17]的子集,即去除掉 LIDC-IDRI 数据集中切片厚度大于 3mm 和结节小于 3mm 的 CT 图像后,剩下的就是 LUNA16 数据集。LUNA16 数据集由 10 个文件夹组成,每个文件夹包括 .mhd 格式文件和 .raw 格式文件。mhd 文件存储着 CT 图像的基本信息,raw 文件保存着 CT 图像的实际数据。来自医院的 CT 图像为 512x512 的 DICOM 格式,其中包括有结节图像和无结节图像。选取数据的患者均有完备的临床信息和 CT 资料。

将图像样本输入模型之前需要对数据样本做预处理,处理步骤如下:首先,进行归一化处理,将所有体素的值截取到 -1000~400 这个范围,小于 -1000 的体素设为 -1000,大于 400 的体素设为 400,然后再归一化至 0~1;其次,对于 LUNA16 数据集,根据数据集中 .csv 文件给出的标注信息提取出结节病灶信息和候选结节信息,并把图像保存为 50x50 .jpg 图片格式,如图 1 所示,对于来自医院的图像数据,由多个专业的影像诊断医生做标注,根据标注信息提取出感兴趣区域,并且标签保存为 0 或 1,其中 0 代表无结节,1 代表有结节;最后,数据样本不平衡,具体表现为阴性样本较多、阳性样本较少,为提高模型的泛化性和鲁棒性,对含结节的 CT 图像进行增强处理,即把原始图像旋转 90° 和 180°,由此扩增阳性样本。



(a) 有结节

(b) 无结节

图1 肺结节 CT 图像样例

Fig. 1 Examples of CT images of lung nodules

如表 1 所列,选自 LUNA16 数据集中部分样本加上由增强处理得到的数据样本作为训练集,来自重庆黔江中心医院的样本数据加上由增强处理后得到的数据样本作为测试集,并运用不同的数据集进行交叉验证,提高了网络的泛化性。

表 1 实验中用于训练和测试的有/无结节样本数

Table 1 Number of nodular/non-nodular samples used for training and testing in the experiment

	有结节样本数	无结节样本数	总计
训练集	1069	5415	6484
测试集	282	1340	1622

3.2 构建网络模型

3.2.1 深度置信网络

本文实验中,DBN 模型是由 4 个受限玻尔兹曼机和 Softmax 层堆叠而成的 6 层网络结构,即 1 个输入层、4 个 RBM 隐藏层和 1 个输出层由低至上依次排列,具体内容如表 2 所列。

表 2 深度置信网络的总体结构

Table 2 General structure of deep belief network

层数	每层结构	类型	节点数
1	RBM1	可见层 v^1	2500
2	RBM1	隐藏层 h^1	1500
3	RBM2	隐藏层 h^2	1000
4	RBM3	隐藏层 h^3	500
5	RBM4	隐藏层 h^4	200
6	Softmax	—	2

本文所搭建的 DBN 模型共 6 层结构,如图 2 所示。

第 1 层是输入层,也是第一个 RBM 模型(RBM1)的可见层,该层的节点数为 2500,2500 表示输入图像像素矩阵的大小。

第 2 层是 RBM1 的隐藏层 h^1 ,该层与第 1 层通过层间全连接的方式相互关联,本文实验设置其节点数为 1500,此层的单元节点被训练以提取出与可见层高阶数据的相关数据。

第 3 层是第二个 RBM 模型(RBM2)的隐藏层 h^2 ,RBM1 的隐藏层作为 RBM2 的可见层,并与第二个隐藏层构成 RBM2。本文实验设置该层的节点数为 1000。

第 4 层是第三个 RBM 模型(RBM3)的隐藏层 h^3 ,RBM2 的隐藏层作为 RBM3 的可见层,并与第三个隐藏层构成 RBM3。本文实验设置该层的节点数为 500。

第 5 层是第四个 RBM 模型(RBM4)的隐藏层 h^4 ,由上述可推得,RBM3 的隐藏层作为 RBM4 的可见层,并与第四个隐藏层构成 RBM4。本文实验设置该层的节点数为 200。

第 6 层是 Softmax 层,实验结果只有两个类别,即有结节与无结节,因此设置此层节点数为 2,2 为输出的类别数。

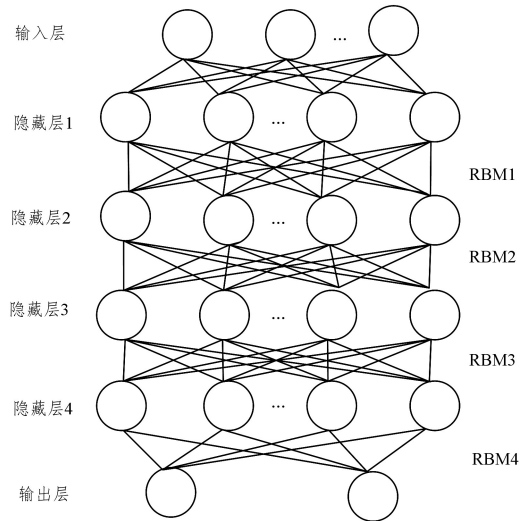


图 2 深度置信网络结构图

Fig. 2 Structure pattern of deep belief network

深度置信网络训练包括两个阶段:1)预训练:预训练过程是无监督学习的过程,不需要标签信息,由低至上逐层训练,首先训练第一个 RBM,然后将隐藏层的激活单元作为下一层 RBM 的输入数据,第二层 RBM 的激活概率作为第三层 RBM 的可见层输入数据,之后各层以此类推训练;2)微调(Fine-tuning),微调过程是有监督学习的过程,借助标签信息采用反向传播算法由上至下微调网络参数,通过有效地调整权值来改善网络的性能。

3.2.2 卷积神经网络

本文实验搭建了 7 层网络结构,包含 3 个卷积层、2 个池化层、1 个全连接层和 Softmax 层,具体内容如表 3 所列,其结构如图 3 所示。

表 3 卷积神经网络的总体结构

Table 3 General structure of the convolutional neural network

层数	类型	卷积核	输出特征图	输出特征图
		大小	大小	数量
1	conv1	3×3	48×48	32
2	max_pool1	2×2	24×24	32
3	conv2	3×3	22×22	64
4	conv3	3×3	20×20	64
5	max_pool2	2×2	10×10	64
6	fc1	10×10	1×1	512
7	Softmax	—	—	2

第 1 层是卷积层,卷积核大小为 3×3 ,卷积核个数是 32,步长为 1,对输入的 50×50 大小的图像进行卷积操作,输出的特征图像大小为 48×48 ,数量为 32。

第 2 层是最大池化层,池化核大小为 2×2 ,步长为 2,对上一层的输出特征图进行降维操作,输出特征图大小变为 24×24 ,但数量仍为 32。

第 3 层是卷积层,卷积核大小为 3×3 ,卷积核个数为 64,步长为 1,输出特征图像大小为 22×22 ,数量为 64。

第 4 层是卷积层,卷积核大小、步长和个数同第 3 层,输出特征图像大小为 20×20 ,数量为 64。

第 5 层是最大池化层,池化核大小和步长同第 2 层,输出特征图大小降为 $20/2=10$,数量为 64。

第 6 层是全连接层,由 512 个神经单元组成,最终得到 512 个 1×1 的特征图。

第7层是Softmax层,是CNN常用的分类器,用Softmax层进行最后的分类。




图3 卷积神经网络结构图

Fig. 3 Structure pattern of convolutional neural network

3.3 评价指标

针对二分类问题,将数据样本分为正类(Positive)和负类(Negative)。但实际分类中,会出现4种情况。

(1)真正类(True Positive, TP):被模型预测为正类的正样本;

(2)假正类(False Positive, FP):被模型预测为正类的负样本;

(3)真负类(True Negative, TN):被模型预测为负类的负样本;

(4)假负类(False Negative, FN):被模型预测为负类的正样本;

准确率(Accuracy)作为分类性能的评价指标,用来直观表达模型总体分类的准确程度。计算准确率的公式如下:

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \times 100\% \quad (8)$$

敏感性(Sensitivity),又称真阳性率(TPR)或召回率,用来描述模型对阳性样本的敏感程度。计算敏感性的公式如下:

$$TPR = \frac{TP}{TP + FN} \times 100\% \quad (9)$$

特异性(Specificity),又称为真阴性率(TNR)或精度,用来反映漏诊率。计算特异性的公式如下:

$$TNR = \frac{TN}{TN + FP} \times 100\% \quad (10)$$

4 实验条件与结果

本文实验环境是Windows10 64位操作系统,处理器为Intel(R) Xeon(R),主频为2.9GHz,内存为16G和实验平台采用Python 3.6版本并搭建TensorFlow环境。实验数据来自LUNA16数据集和重庆黔江中心医院的图像数据。

4.1 实验结果

为客观地评价DBN模型和CNN模型对肺结节影像图像分类识别的性能,本文从分类识别准确率、Loss值和训练时间等各方面进行比较。在本实验中,设置同样的epoch参数,观察不同模型分类识别准确率、Loss值变化趋势。如图4所示,图4(a)和图4(b)分别是DBN模型和CNN模型的训练次数与测试集准确率的关系图,图中横坐标表示实验的训练次数,纵坐标表示测试集图像分类识别的准确率。从两个图中可以看出,随着训练次数的增加,CNN模型对测试集分类识别的准确率曲线收敛得更快,图4(a)的准确率最大值明显大于图4(b),图4(b)中epoch为62左右时,曲线总体趋势呈现出平缓的状态,准确率没有大幅度升高。由此可知,CNN模型分类识别准确率高于DBN模型。图4(c)和图4(d)分别是CNN模型和DBN模型的训练次数与Loss值的关系图,图中横坐标表示实验训练次数,纵坐标表示Loss值。从两个图中可以看出,随着训练次数的增加,Loss值不断降低,CNN模型对测试集分类识别的Loss曲线收敛得更快,且图4(c)的Loss最小值明显低于图4(d)。

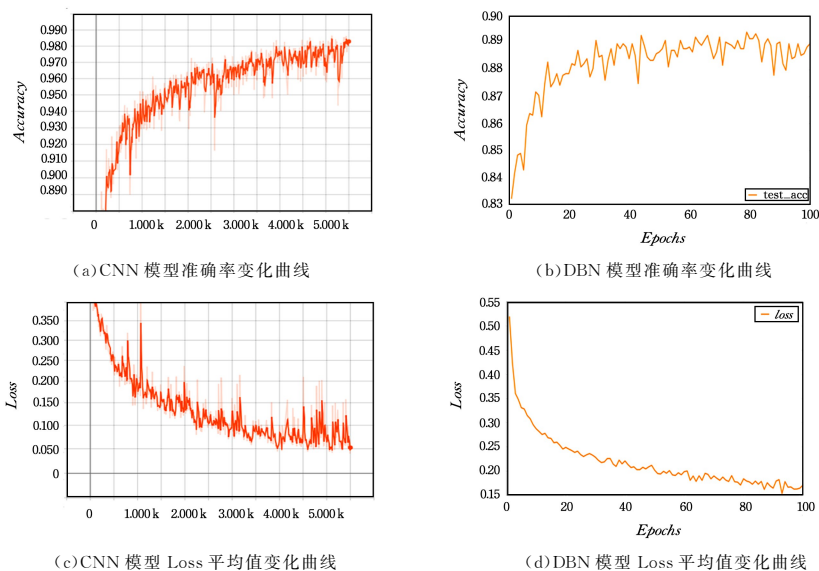


图4 CNN模型和DBN模型的训练过程

Fig. 4 Training process of CNN model and DBN model

混合矩阵(Confusion Matrix),又称为误差矩阵,常用来可视化地评估不同算法的分类性能。图5给出了CNN模型和DBN模型的混合矩阵。将对应的混合矩阵中的数值分别代入式(8)一式(10),可计算出CNN模型分类识别准确率、

敏感性和特异性的值分别为98.46%,77.66%和96.94%;DBN模型准确率、敏感性和特异性的值分别为89.39%,58.45%和95.62%。由此可见,CNN模型分类识别准确率、特异性两个评价指标均优于DBN模型。




图 5 CNN 模型和 DBN 模型的混合矩阵

Fig. 5 Confusion matrix of CNN model and DBN model

在分类识别模型中,ROC 曲线(又称受试者工作特性曲线)和 AUC 值常被作为衡量一个二值分类器优劣的指标^[18]。如图 6 所示,图 6(a)和图 6(b)分别是 CNN 模型和 DBN 模型的 ROC 曲线图,ROC 曲线横坐标是假阳性率(False Positive Rate, FPR),纵坐标是真阳性率(True Positive Rate, TPR)。AUC(Area Under Curve ROC)被定义为 ROC 曲线下的面积,由图 6(a)和图 6(b)可知,CNN 模型和 DBN 模型曲线下的面积分别为 0.97 和 0.78。由此可知,CNN 模型的 AUC 值明显高于 DBN 模型,表明 CNN 模型更适用于肺结节 CT 图像的分类识别,分类识别效果更好。




图 6 CNN 模型和 DBN 模型的 ROC 曲线

Fig. 6 ROC curve of CNN model and DBN model

图 7 给出了在同一数据集下、不同训练次数条件下,分别基于 CNN 模型与 DBN 模型对测试集分类识别的准确率,其横坐标是训练次数,纵坐标是测试集准确率。从图 5 中可明显看出,无论训练次数的多少,CNN 模型曲线均位于 DBN 模型曲线上方,且随着训练次数的增加,CNN 模型的分类准确率趋于平稳,在 95% 以上小范围波动;DBN 模型的曲线有明显的起伏波动,且波动幅度较大。由此可见,CNN 模型更易收敛,模型更稳定。




图 7 不同训练次数与测试集准确率的结果对比图

Fig. 7 Comparison of different training times and accuracy results of test sets

图 8 为同一数据集下,CNN 模型与 DBN 模型不同训练次数与消耗时间的对比图,其横坐标是实验训练次数,纵坐标

是对应的耗时。从图 8 中可以明显看出,随着训练次数的增加,两种模型消耗的时间都在增加,且无论训练次数为多少,DBN 模型的训练时间明显长于 CNN 模型。由此可见,CNN 模型学习的效率更高。




图 8 不同训练次数与消耗时间的结果对比图

Fig. 8 Comparison of different training times and consumption time

4.2 不同算法分类结果的比较

为进一步说明在肺部图像分类识别方法上 CNN 模型算法优于 DBN 模型算法,本文根据准确率、敏感性和特异性 3 个指标以及 AUC 值,将 CNN 模型与本文 DBN 模型、文献^[11]和文献^[12]中的模型进行了比较,具体内容如表 4 所列。由表 4 可知,CNN 模型的分类识别准确率、特异性和 AUC 值均优于 DBN 模型。由此可见,CNN 模型比 DBN 模型在肺部图像分类识别上更有优势。对于敏感性这个指标,CNN 模型的敏感性低于 DBN 模型,由于医学图像的复杂性和特殊性以及分类识别准确率、敏感性和特异性 3 个指标大小相互影响,在理想情况下 3 个数值都高,但是实际情况常常很难达到理想状态。因此,在实际中常常在保证准确率的情况下提高敏感性。综上所述,CNN 模型对肺结节图像特征的描述更准确,在结节分类识别方面表现得更好,对有无结节诊断的误差率低,而 DBN 模型分类识别性能还待进一步的提升。

表 4 不同算法的识别效果比较

Table 4 Recognition effect comparison of different algorithms

分类模型	准确率/%	敏感性/%	特异性/%	AUC 值
文献 ^[11] 的模型	95.3	92.5	93.23	0.92
文献 ^[12] 的模型	86.0	96.0	75.0	0.85
DBN 模型	89.39	58.45	95.62	0.78
CNN 模型	98.46	77.66	96.94	0.97

结束语 鉴于肺部图像的复杂性和特殊性,本文分别把卷积神经网络和深度置信网络应用于肺部图像的分类识别,并评估了两种深度学习网络在肺部图像分类识别方面的性能。深度置信网络属于无监督学习方法,由多个受限玻尔兹曼机叠加构成。首先,深度置信网络采用层间全连接的形式且图像样本数据量大,将深度置信网络用于图像分类识别中面临着参数相对较多、计算复杂度高和训练缓慢的挑战。其次,深度置信网络的输入向量是简单的一个图像矩阵一维化,没有考虑图像的二维结构信息。然后,图像的有用信息往往分布在图像的局部,这就要求模型提取出的特征对输入向量的局部变换具有不变性,而深度置信网络没有平移不变性的性质,由此导致图像特征可能扭曲了图像局部的有用信息。最后,深度置信网络是一种生成模型,擅长探索图像中不同元素之间的概率关系,更适用于增量学习。卷积神经网络属于有监督学习方法,卷积操作是卷积神经网络提取特征的主要方式。首先,卷积操作利用局部感知的原理善于找出图像局

部空间的相关性,提取局部特征;其次,卷积神经网络凭借权重共享的原理,可以明显减少参数的生成,由此计算简便、省时;最后,卷积神经网络具有平移不变性的特质,即特征向量对输入向量的局部变换具有平移不变性。卷积神经网络在影像图像细节处理方面具有较高的敏感度,因此卷积神经网络在肺结节图像识别任务上具有一定的优势。

实验结果表明,虽然 CNN 模型和 DBN 模型都有较强的提取特征和分类的性能,但两种模型特征提取的机制不同,卷积神经网络能更有效地提取复杂的肺结节图像特征,该模型对肺结节识别分类的准确率有一定的提高,且网络训练效率较高,有更强的鲁棒性,综合分类效果优于深度置信网络分类模型。在今后的研究中,将密切关注深度学习方法的发展,对肺结节图像处理问题做进一步的研究。

参 考 文 献

- [1] KANG X D. Medical Image Processing [M]. People's Medical Publishing House, 2009: 200.
- [2] DOI K. Computer-aided diagnosis in radiology: potential and pitfalls[J]. European Journal of Radiology, 1997, 31.
- [3] SHEN W, ZHOU M, YANG F, et al. Multi-scale Convolutional Neural Networks for Lung Nodule Classification[J]. Inf Process Med Imaging, 2015, 24: 588-599.
- [4] YANG F. Study on classification algorithm of pulmonary nodules based on convolutional neural network[D]. Taiyuan University of Technology, 2018.
- [5] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7): 1527-1554.
- [6] KUREMOTO T, KIMURA S, KOBAYASHI K, et al. Time series forecasting using a deep belief network with restricted Boltzmann machines[J]. Neurocomputing, 2014, 137(15): 47-56.
- [7] SALAKHUTDINOV R, MNH A, HINTON G. [ACM Press the 24th international conference-Corvalis, Oregon (2007. 06. 20-2007. 06. 24) [C] // Proceedings of the 24th International Conference on Machine Learning-ICML 07-Restricted Boltzmann Machines for Collaborative Filtering. 2007: 791-798.
- [8] DAHL G E, RANZATO M, MOHAMED A R, et al. Phone Recognition with the Mean-Covariance Restricted Boltzmann Machine[C] // International Conference on Neural Information Processing Systems. Curran Associates Inc. 2010.
- [9] YANG J L. Classification of pulmonary nodules based on deep belief network [D]. Taiyuan: Taiyuan University of Technology, 2017.
- [10] YAN X F, QIANG Y, YUAN J. Diagnosis of benign and malignant

pulmonary nodules based on mixed-restricted Boltzmann machine, December 19, 2016 [J]. Computer Engineering and Applications, 2016.

- [11] ZHAO W, YANG J L, QIANG Y, et al. A classification method for benign and malignant pulmonary nodules based on deep belief network[J]. Science Technology and Engineering, 2016.
- [12] LIU L, YANG P L, SUN W, et al. Classification of benign and malignant solitary pulmonary nodules by deep belief network [J]. Journal of Harbin University of Science and Technology, 2018, 23(3): 13-19.
- [13] HINTON G, DAYAN P, FREY B, et al. The wake-sleep algorithm for unsupervised neural networks [J]. Science, 1995, 268(5214): 1158-1161.
- [14] ZHANG Z, ZHAO J. A deep belief network based fault diagnosis model for complex chemical processes [J]. Computers & Chemical Engineering, 2017; S0098135417301059.
- [15] FISCHER A, IGEL C. An Introduction to Restricted Boltzmann Machines[J/OL]. 2012. https://www.researchgate.net/publication/243463621_An_Introduction_to_Restricted_Boltzmann_Machines?ev=prf_cit.
- [16] KRIZHEVSKY A, SUISEKVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[C] // International Conference on Neural Information Processing Systems. Curran Associates Inc, 2012: 1097-1105.
- [17] NOVO J, GONCALVES L, MENDONCA A M, et al. 3D lung nodule candidate detection in multiple scales[C] // Proceedings of the 14th IAPR International Conference on Machine Vision Applications (MVA 2015). IEEE, 2015.
- [18] PAN Q, CHEN H, MA Y J, et al. Analysis of parameter method ROC curve in imaging diagnostic evaluation[J]. Chinese Journal of Medical Imaging Technology, 2011, 27(8).



ZHANG Hua-li, born in 1995, M. S. candidate. Her main research interest includes medical image processing.



RAN Hua, born in 1965, bachelor, chief physician in Chongqing Qianjiang Central Hospital. His main research interest includes medical imaging intervention.