

利用深度学习网络对医学影像分类识别的比较研究

刘汉卿¹ 康晓东¹ 李博² 张华丽¹ 冯继超¹ 韩俊玲¹

1 天津医科大学影像学院 天津 300202

2 天津市第三中心医院 天津 300171

(hanqing0421@tmu.edu.cn)

摘要 计算机辅助诊断技术在临床医学中具有实际意义。分别以肺结节和髋关节骨折影像为典型的区域和边界特征影像,讨论其在不同网络中的适用性。首先,对肺结节 CT 图像和髋关节 X-ray 骨折图像进行信息标注,并分别以 CNN, Resnet, DBN 和 SGAN 预训练并调参至最优,通过 Softmax 分类器完成分类识别。其次,以图像空间分辨率和噪声作为不同深度学习网络的比较特征,从深度学习网络结构等方面分析了识别率。仿真实验结果表明,Resnet 在数据集皆有优异表现,且具有良好的泛化能力和鲁棒性。

关键词 深度学习; CNN; Resnet; DBN; SGAN; 图像分类

中图分类号 TP391

Comparative Study on Classification and Recognition of Medical Images Using Deep Learning Network

LIU Han-qing¹, KANG Xiao-dong¹, LI Bo², ZHANG Hua-li¹, FENG Ji-chao¹ and HAN Jun-ling¹

1 School of Medical Image, Tianjin Medical University, Tianjin 300202, China

2 Tianjin Third Central Hospital, Tianjin 300171, China

Abstract Computer-aided diagnosis technology has practical significance in clinical medicine. The images of lung nodules and articulation coxae fractures are used as typical regional and boundary feature images to discuss their applicability in different networks. First, the CT images of the lung nodules and the X-ray fracture images of the articulation coxae are labeled, and they are pre-trained with CNN, Resnet, DBN and SGAN and fine-tuned, and the classification and recognition are completed via the Softmax classifier. Secondly, the image spatial resolution and noise are used as the comparative characteristics of different deep learning networks, and the recognition rate is analyzed from the aspects of deep learning network structures. The simulation experiment results show that Resnet performs preeminently in all data sets, and has striking generalization ability and robustness.

Keywords Deep learning, CNN, Resnet, DBN, SGAN, Images classification

利用深度学习进行图像分类识别是当前的研究热点之一。图像分类识别是指一个模式的分类问题,医学影像分类识别的目的是将不同的图像正确地划分到属于各自的类别中,实现最小的分类误差^[1]。

Hinton 和 Salakhutdinov 于 2006 年提出深度网络及深度学习概念^[2],开启了深度学习的研究。深度学习是指通过一定的训练方式学习样本数据内在规律和表示层次的学习过程。浅层学习是将单个原始输入转换到特定问题空间特征,无法解决线性不可分问题(如异或问题);而深度学习可以通过对输入原始信号进行逐层的特征变换,将样本从低维特征空间转换到高维特征空间,通过特征的逐层变换完成最后的预测和识别。深度学习作为一个热门的研究方向^[3],已在计算机视觉^[4-7]、自然语言处理^[8-9]和语音识别^[10-11]领域取得前所未有的成就。

在医学影像分类识别领域, Antony 等结合深度卷积神经网络与支持向量机,根据膝关节 X 线图像对膝关节损伤的

严重程度进行病情分级,与传统方法相比能显著提高分类精度^[12]; Hashimoto 等将多实例学习和多尺度与卷积神经网络结合,根据病理学图像进行肿瘤亚型的分型,其分类效果明显优于标准卷积神经网络和其他传统方法,准确率也优于标准病理医师^[13]; Gao 等通过卷积神经网络与循环神经网络提取白内障图像特征,并运用支持向量机回归分析确定白内障分级,其分类精度优于传统方法,且有助于在人口众多的筛查中协助和改善该疾病的临床管理并延展于其他眼部疾病的检测^[14]; Talo 等运用多种卷积神经网络对磁共振脑部图像进行疾病诊断,其中 Resnet-50 获得 95.23%±0.6 的最佳精度,对脑部早期微小病变具有重要意义^[15]; Ahmed 等深度置信网络无监督路径方式,结合反向传播监督路径方法进行乳腺癌检测,其分类准确度达到 99.68%^[16]; Frid-Adar 等采用 GAN (Generative Adversarial Networks) 与 CNN (Convolution Neural Network) 结合的方式进行肝脏疾病 CT 图像分类,首先使用 GAN 进行数据增强,然后使用 CNN 进行肝脏疾病

基金项目:京津冀协同创新项目(17YEXTZC00020)

This work was supported by the Beijing-Tianjin-Hebei Collaborative Innovation Project(17YEXTZC00020).

通信作者:康晓东(423065302@qq.com)

CT 图像分类,与经典数据增强相比,采用 GAN-CNN 的灵敏度和特异性分别增加至 85.7% 和 92.4%^[17]。由此可见,卷积神经网络和深度置信网络在医学图像分类上都已有一定研究成果,且与传统疾病分类方法相比均取得了良好改善。

为进一步研究卷积神经网络、残差网络、深度置信网络和生成式对抗网络在不同医学数据集中的分类识别性能,本文以肺结节 CT 图像和髌关节 X-ray 骨折图像作为典型的区域和边界特征影像,分别运用 CNN, Resnet, DBN 和 SGAN (Semi-supervised Generative Adversarial Networks)对区域和边界特征医学影像进行分类识别,以评估不同深度学习网络的应用特性,并尝试讨论不同网络在医学影像分类识别方面的适用性。

1 深度学习网络

1.1 卷积神经网络

经典的卷积神经网络包括卷积层、非线性层、池化层和全连接层^[2]。卷积层的作用是对输入图像进行抽象的操作,通过卷积运算提取出图像的特征值,其计算公式如式(1)所示:

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

其中, w_i 为权重, b 为偏置。

非线性层紧接卷积层后,其作用是在输入与输出之前生成非线性映射关系;池化层通过池化操作降低特征维数,减少计算量;全连接层的作用是将特征映射到样本标记空间。

1.2 残差网络 Resnet

残差网络是以残差块为基本单元构成的网络,一般由卷积层、批量处理归一化层和修正线性单元 Relu 堆叠而成。一个残差块的计算公式如式(2)所示:

$$x_{l+1} = f(x_l + \mathcal{F}(x_l, \mathcal{W}_l)) \quad (2)$$

其中, x_l 和 x_{l+1} 分别表示第 l 和第 $l+1$ 层残差单元的输入, $\mathcal{F}(x_l, \mathcal{W}_l)$ 表示残差函数, \mathcal{W}_l 表示第 l 层残差单元对应的权重, $f(\cdot)$ 表示修正线性单元 Relu。

残差网络通过学习残差和引入恒等映射的方式,有效地缓解了网络层数加深带来的梯度消失、梯度爆炸^[18]以及网络退化^[19]等问题。

1.3 深度置信网络 DBN

深度置信网络 DBN 是由多个受限玻尔兹曼机(RBM)堆叠而成,通过多个 RBM 与最终的分类器相结合,对输入样本数据进行识别与分类。RBM 的结构包括两个神经元:隐藏层(Hidden Layer)——用于接收输入数据;可视层(Visible layer)——用于高层特征提取。这两个神经元作为特征检测器和输入数据训练使用。RBM 的能量函数可用式(3)表示:

$$E(v, h; \theta) = -\sum_{i=1}^n \sum_{j=1}^m w_{ij} h_j v_i - \sum_{i=1}^n a_i v_i - \sum_{j=1}^m b_j h_j \quad (3)$$

其中, w_{ij} 表示可见层 i 与隐含层 j 之间的权重值; a_i 表示可视层 i 的偏置; b_j 表示隐藏层的偏置。

1.4 半监督生成对抗网络 SGAN

GAN 由生成器 G 和鉴别器 C 组成:生成器 G 通过输入噪声生成“假”的图片;鉴别器 C 通过输入真实样本与生成器 G 生成的样本,输出真实样本与生成样本的置信区间,并反馈生成器 G 进行参数更新。真实样本与生成样本未给予对应的标签,因此 GAN 属于无监督学习。

SGAN 在 GAN 的基础上做出改进,将鉴别器分为监督

分类器 C 和无监督分类器 D 。监督分类器 C 的作用是将标签样本按照各自的类别进行区分;无监督分类器 D 的作用是区分真实样本与生成样本。若标签样本的类别数为 n ,则将无监督分类器 D 判别生成样本归为第 $n+1$ 类。SGAN 进行图像分类识别的流程图如图 1 所示。




图 1 SGAN 图像分类识别流程图

Fig. 1 Image classification recognition flowchart of SGAN

2 本文研究方法

本文对肺结节 CT 图像 LUNA16 数据集与髌关节 X-ray 骨折图像数据集的分类识别流程主要包括以下 3 个部分。

(1)根据 LUNA16 数据集标注信息进行数据归一化、数据增强处理。

(2)根据髌关节 X-ray 骨折图像数据集进行人工标注,对目标区域裁剪,改变图像空间分辨率,并进行数据增强,归一化等处理。

(3)构建 CNN, Resnet, DBN 和 SGAN 并设计网络参数,进行网络模型预训练和进行参数调整。最后进行测试分类,通过评价指标对各模型进行比较。

2.1 数据集和预处理

本文实验选用肺结节 CT 图像 LUNA16 (Lung Nodule Analysis)数据集和非公开髌关节 X-ray 骨折图像数据集,下面给出其预处理的过程。

(1)LUNA16 是最大公用肺结节数据集 LIDC-IDRI 的子集,其在 LIDC-IDRI 的基础上删除了切片厚度大于 3 mm 和结节小于 3 mm 的数据,其包含 888 份低剂量肺部 CT 影像数据和 1186 个结节部位。LUNA16 共有 10 个文件夹,每个文件夹中都是由后缀为“. mhd”和“. raw”的文件组成,其中“. mhd”存储 CT 图像的基本信息,“. raw”用于存储 CT 图像的具体数据。LUNA16 数据集的预处理步骤如下:首先,将所有体素值限制在 0~255 范围之内,然后经归一化处理至 0~1 之间;其次,根据数据集中“. txt”文件所给的标注信息提取出结节病灶信息和候选结节信息,并使标签保存为 0 或 1,其中 0 表示阴性,1 表示阳性;最后,考虑到阴性样本与阳性样本数据量不平衡,做数据增强处理,包括旋转和平移等方式,扩增阳性样本。将扩增之后的图像保存为 50 * 50. jpg 格式。肺结节原始图像及预处理后的图像如图 2 所示。




图 2 肺结节图像

Fig. 2 Pulmonary nodule

(2)髋关节 X-ray 图像数据集包含两个子集,其中阳性样本 77 份,阴性 147 份。原始图像空间分辨率有两种规格,分别为 3056×2544 和 2969×2252 ,图像以“.jpg”格式的文件保存。首先,对原始髋关节 X-ray 图像进行标注并使标签保存为 0 和 1 两种格式,其实 0 表示阴性,1 表示阳性。然后,根据背景噪声与空间分辨率对图像分类的影响,对髋关节 X-ray 图像数据集进行预处理:对目标区域的图像大小进行限制,在原始图像的基础上对图像进行裁剪,经裁剪过后的图像尽可能只保留髋关节和股骨头部位,去除腹部及骶髂骨等噪声信息的干扰,经裁剪过后的阳性样本 100 份,阴性样本 100 份。髋关节 X-ray 阳性样本未裁剪和裁剪图像如图 3 所示。



(a)未裁剪的图像 (b)裁剪后的图像 (c)裁剪后进行翻转并平移后的图像

图 3 髋关节 X-ray 图像

Fig. 3 X-ray image of articulation coxae

然后通过数据增强的方式扩充数据集样本量,经数据增强后如图 3 所示,并进行归一化处理,其目的是提高特征提取精度,加快模型收敛速度。最后,将图像按不同的空间分辨率调整为 128×128 .jpg 和 256×256 .jpg 两种格式。按不同空间分辨率和有无裁剪将髋关节 X-ray 图像数据集分为 4 组数据集,分别命名为 128×128 resized, 128×128 unresized, 256×256 resized 和 256×256 unresized。经预处理的数据集及数据集个数如表 1 所列。

表 1 实验数据集个数

Table 1 Amount of dataset

	Positive	Negative	Train	Test
LUNA16	1127	5681	5186	1622
128×128 resized	1877	1877	3002	752
128×128 unresized	1578	2780	3486	872
256×256 resized	1877	1877	3002	752
256×256 unresized	1578	2780	3486	872

2.2 构建网络模型

本实验采用的 CNN 包含 6 层网络结构,其中卷积层和池化层分别为 4 层,全连接层 2 层,各层网络参数如下。

(1)Conv₁:使用 32 个 (3×3) 的滤波器,步长为 (2×2) ,接着使用窗口为 (3×3) 和步长为 (2×2) 的最大池化层;

(2)Conv₂:使用 64 个 (3×3) 的滤波器,步长为 (2×2) ,接着使用窗口为 (3×3) 和步长为 (2×2) 的最大池化层;

(3)Conv₃:使用 128 个 (3×3) 的滤波器,步长为 (2×2) ,接着使用窗口为 (3×3) 和步长为 (2×2) 的最大池化层;

(4)Conv₄:使用 256 个 (3×3) 的滤波器,步长为 (2×2) ,接着使用窗口为 (3×3) 和步长为 (2×2) 的最大池化层;

(5)全连接层:分别使用 2 层全连接层,依次为 256 和 2 个神经元,最后使用 Softmax 激活函数输出置信区间。

作为对比研究,本实验采用 50 层 Resnet 神经网络,重复

叠加卷积块(Convolutional Block)和识别块(Identify Block),其网络结构如图 4 所示,各层网络参数如下。

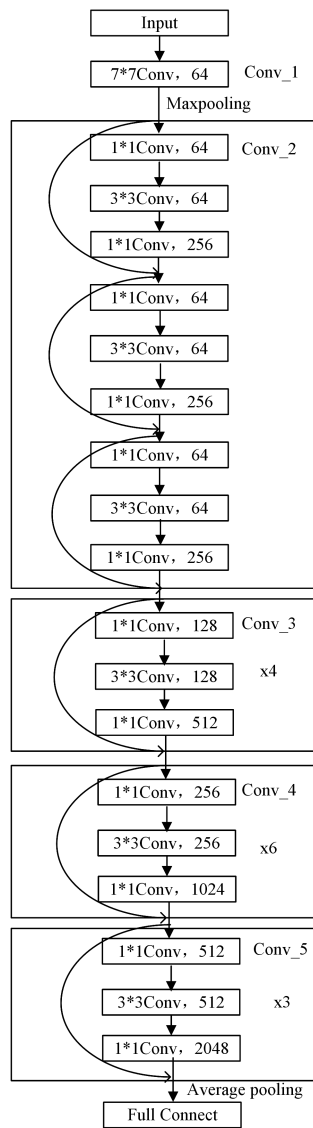


图 4 Resnet 结构图

Fig. 4 Structure pattern of Resnet

(1)Conv₁:使用 64 个 (7×7) 的滤波器,步长为 (2×2) ,然后使用 Batchnormalization 进行正则化处理;接着使用窗口为 (3×3) 和步长为 (2×2) 的最大池化层;最后对输入的图像进行零填充(Zero Padding),使输入与输出图像大小保持一致。

(2)Conv₂:依次按先后顺序使用 64 个 (1×1) 的滤波器、64 个 (3×3) 的滤波器和 256 个 (1×1) 的滤波器,其步长均为 (1×1) ,按此顺序叠加 3 层。

(3)Conv₃:依次按先后顺序使用 128 个 (1×1) 的滤波器,128 个 (3×3) 的滤波器和 512 个 (1×1) 的滤波器,其步长均为 (1×1) ,按此顺序叠加 4 层。

(4)Conv₄:依次按先后顺序使用 256 个 (1×1) 的滤波器、256 个 (3×3) 的滤波器和 1024 个 (1×1) 的滤波器,其步长均为 (1×1) ,按此顺序叠加 6 层。

(5)Conv₅:依次按先后顺序使用 512 个 (1×1) 的滤波器、512 个 (3×3) 的滤波器和 2048 个 (1×1) 的滤波器,其步

长均为 (1×1) , 按此顺序叠加 3 层。

(6) Average pool 和 fc: 使用窗口为 (2×2) 的平均池化层; 最后通过全连接层使用 Softmax 激活函数将输出降低至类别数。

本实验所使用的 DBN 是由 1 个输入层、1 个 Softmax 输出层和 4 个 RBM 隐藏层构成。输入层是一个 RBM 可见层, 该层的节点为输入图像像素矩阵的大小。4 个隐藏层的节点数由上到下依次为 1 500, 1 000, 500 和 200 个。最后通过 Softmax 输出类别的置信区间。

本实验采用的 SGAN 包括 3 个部分: 生成器 G 、监督分类器 C 和无监督分类器 D 。其结构如图 5 所示, 生成器 G 包含 4 层结构, 依次为 1 个全连接层、2 层含有 128 个 4×4 滤波器的逆卷积层 ConvTranspose 和 1 个含有 7×7 滤波器的卷积层, 最后使用激活函数 tanh 输出生成图像; 监督分类器 C 包含 4 层结构, 依次为 3 层含有 128 个 3×3 滤波器的卷积层和 1 个全连接层, 全连接层后使用 Softmax 激活函数输出结果; 无监督分类器 D 包含 4 层结构, 依次为 3 层含有 128 个 3×3 滤波器的卷积层和一个全连接层, 全连接层后使用 Custom Activation 激活函数输出结果。Custom Activation 激活函数的作用是将输出值限定在 0.0 到 1.0 之间, 即小激活或负激活输出接近 0.0 的值, 大激活或正激活输出接近 1.0 的值。

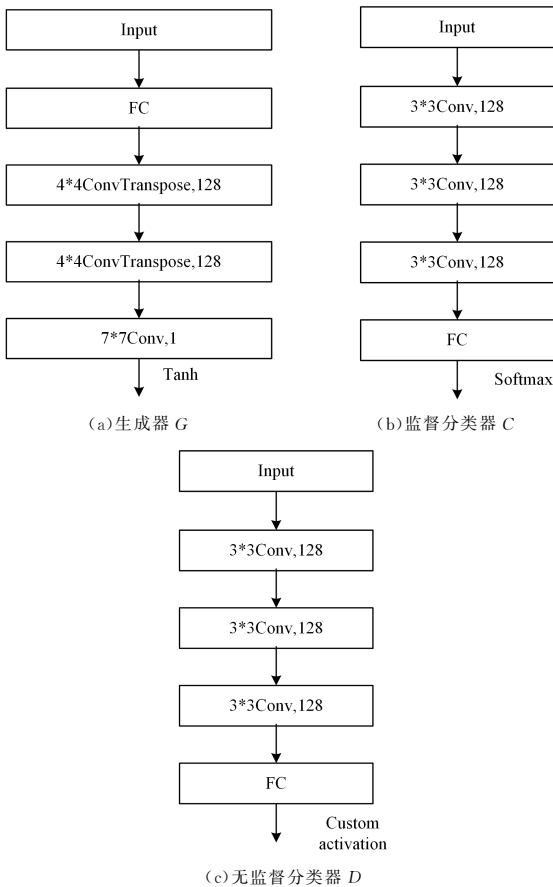


图 5 SGAN 结构图

Fig. 5 Structure pattern of SGAN

上述 4 种网络均使用 Adam 优化算法, 学习率为 0.0001, 每批次载入图像数为 20 张, 训练次数为 100 轮。

2.3 实验环境与评价指标

本实验所用硬件为 Dell PowerEdge T630 (E5 2600 v3) 和

NVIDIA GeForce GTX 1080Ti 显卡, 软件采用 64 位 Windows10 操作系统, 深度学习开源框架 TensorFlow, 版本为 2.1, 程序使用 Python3.6 编写。

为描述正负样本个数不均衡问题并进一步分析每类图像正确分类的个数, 使用准确率和混淆矩阵作为评价指标。混淆矩阵包括 4 个指标。

(1) 真正类 (True Positive, TP): 实际为正类且预测也为正类的样本。

(2) 假正类 (False Positive, FP): 实际为负类且预测为正类的样本。

(3) 真负类 (True Negative, TN): 实际为负类且预测也为负的样本。

(4) 假负类 (False Negative, FN): 实际为正类且预测为负类的样本。

准确率 (Accuracy, ACC) 表示分类样本所有判断正确的结果占总观测值的比重, 其表达式如式 (4) 所示:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (4)$$

3 结果与分析

将预训练好且参数微调的 CNN, Resnet, DBN 和 SGAN 分别在 LUNA16, 128×128 resized, 128×128 unresized, 256×256 resized 和 256×256 unresized 这 5 组数据集上进行不同网络模型分类识别效果的比较, 其分类识别不同数据集中阳性和阴性样本的结果如图 6 所示, 分类准确率如表 2 所列。对于不同数据集, 通过建立混淆矩阵分析 4 种模型的表现, 图 6(a) 给出 4 种模型在 LUNA16 的分类识别效果, 图 6(b) 给出 4 种模型在 128×128 resized 的分类识别效果, 图 6(c) 给出 4 种模型在 128×128 unresized 的分类识别效果, 图 6(d) 给出 CNN, Resnet 和 SGAN 在 256×256 resized 的分类识别效果, 图 6(e) 给出 CNN, Resnet 和 SGAN 在 256×256 unresized 的分类识别效果。

表 2 分类准确率

Table 2 Accuracy of classification

	(单位: %)			
	CNN	Resnet	DBN	SGAN
LUNA16	92.5	93.1	89.4	80.0
128×128 resized	89.2	95.2	76.2	75.0
128×128 unresized	82.6	93.6	70.1	69.5
256×256 resized	86.0	90.1	—	74.4
256×256 unresized	80.7	87.5	—	64.1

由表 2 可见, CNN, Resnet 和 SGAN 3 种网络模型在 128×128 resized 上分类识别的准确率均高于 256×256 resized; CNN, Resnet, DBN 和 SGAN 4 种网络模型在 128×128 resized 上的表现均优于 128×128 unresized, 且 CNN, Resnet 和 SGAN 在 256×256 resized 上的表现也均优于 256×256 unresized, 因此对图像目标区域进行裁剪, 减少无关噪声信息能提高图像分类的准确率。实验结果还进一步显示, Resnet 在 5 组数据集上分类识别的表现均为最优, 该方法的识别精度最高, 更适用于具有复杂性和特殊性的医学图像分类, 该网络有高精度、鲁棒性和延展性的特点。

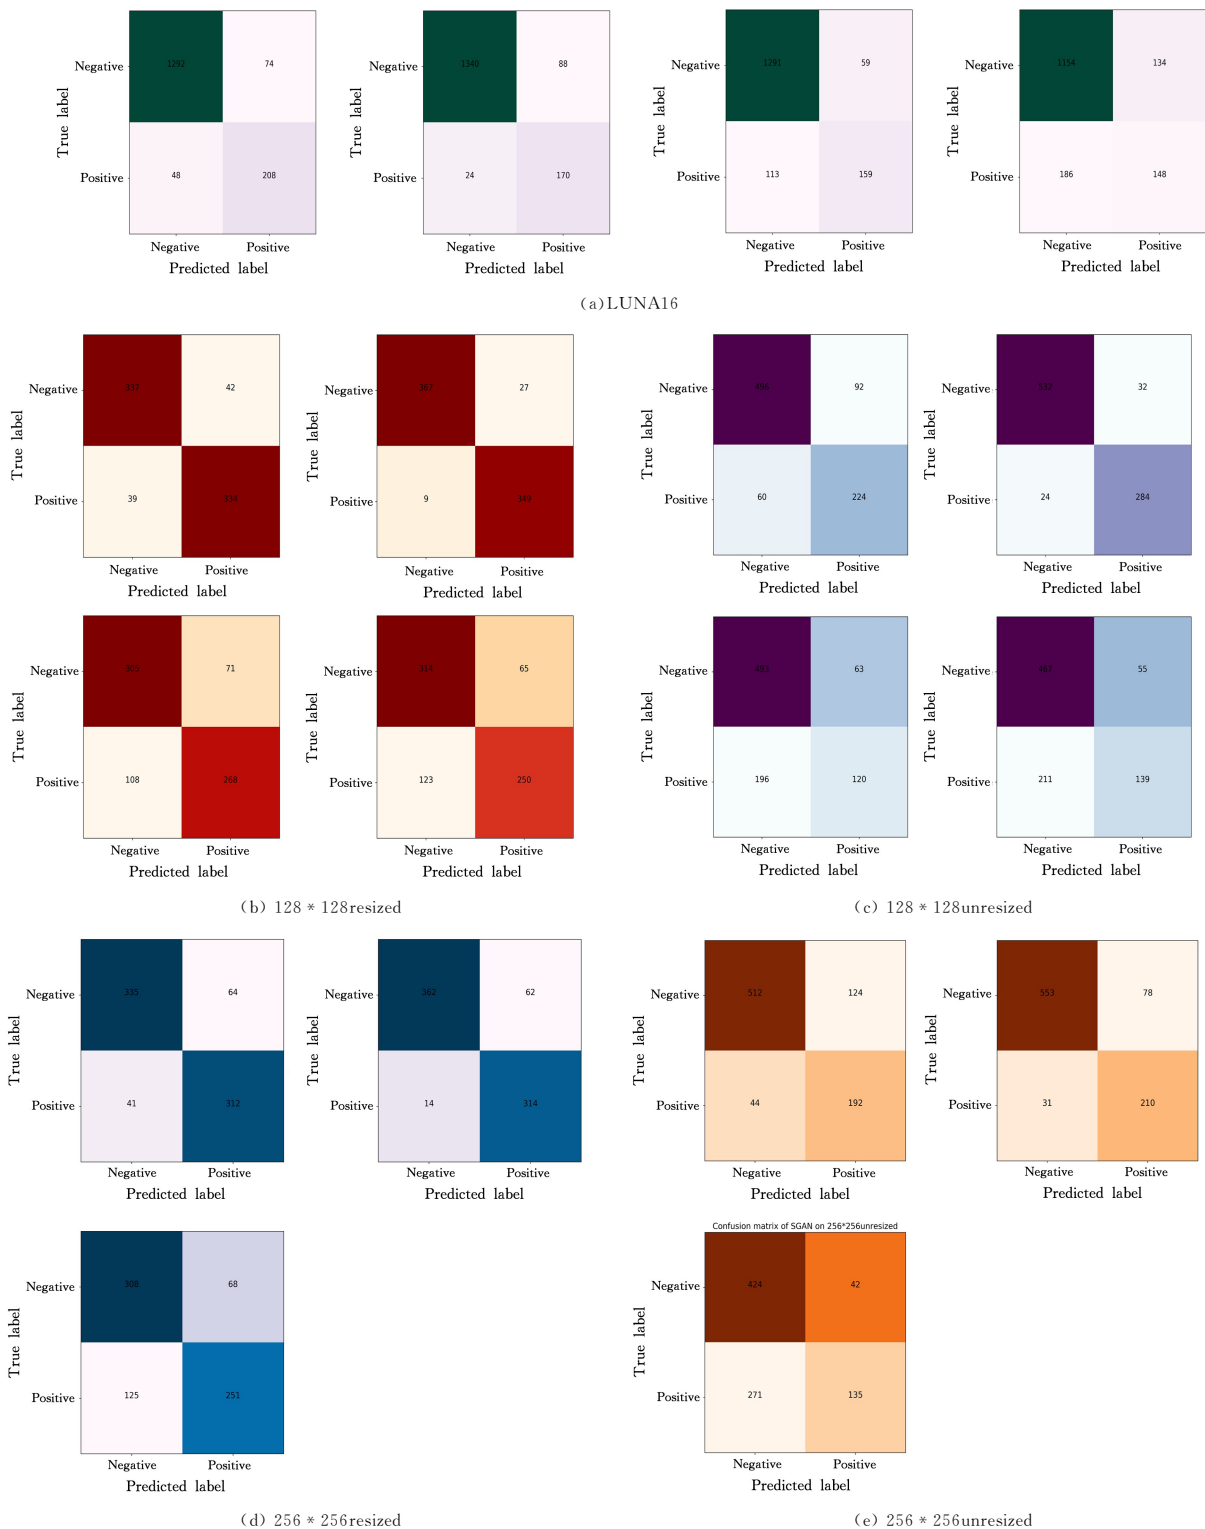


图 6 不同数据集混淆矩阵结果的比较

Fig. 6 Comparison of confusion matrix results of different datasets

结束语 本文针对肺结节 CT 与髋关节 X-ray 骨折图像的分类问题, 基于 4 种深度学习网络结构对目标进行特征学习, 完成图像分类识别。为了对比不同数据预处理对分类识别的影响, 根据空间分辨率和背景噪声将髋关节 X-ray 骨折图像扩充至 4 组数据集, 并与肺结节 CT 图像输入至 CNN, Resnet, DBN 和 SGAN 中进行预训练并微调参数, 最后将预训练好的模型分别进行分类识别。

本实验采用深层残差网络, 使得网络随着深度增加, 低维特征向高维特征映射得到更好的表达, 同时使用捷径连接的

方式使得网络随着深度不断增加而不会降低其网络的性能。此外, 当使用深层的 Resnet 时会采用“Bottleneck”的结构, 其目的是减少参数的数量, 保持精度, 同时又减少了计算量。残差网络能够很好地解决卷积神经网络由于网络深度的增加带来的梯度爆炸导致网络无法收敛等问题。

与卷积神经网络相比, 深度置信网络采用层间全连接的形式, 对于数据量大的图像分类任务面临参数量大、计算度复杂以及训练时间长等挑战。此外, 深度置信网络不具备平移不变的性质, 导致图像局部信息扭曲而损失有用信息。深度

置信网络是基于贝叶斯思想,寻找出数据的联合概率分布,获取潜藏在数据中的高层信息。卷积神经网络通过卷积操作提取局部关联特征,通过由低到高层卷积操作,对提取的特征进行抽象,具有适应数据变换的能力。卷积神经网络在图像细节方面较为敏感,因此对肺结节和髌关节骨折数据集卷积神经网络具有一定的优势。

实验表明,残差网络能在不同医学影像数据集上实现高精度分类识别,而且在正负样本数不均衡的数据集中同样表现优异,其具有精度更高、泛化能力更好等特点,为计算机辅助诊断应用于实际临床诊断提供了有效指导。

参 考 文 献

- [1] KANG X D. Medical Image Processing [M]. People's Medical Publishing House, 2009: 200.
- [2] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks [J]. Science, 2006, 313(5786): 504-507.
- [3] GUO L L, DING S F. Research Progress on Deep Learning [J]. Computer Science, 2015, 42(5): 28-33.
- [4] KRIZHEVSKY A, SUTSKEVER I, INTON G E. Imagenet classification with deep convolutional neural networks [C] // Advances in Neural Information Processing Systems, 2012: 1097-1105.
- [5] RUSSAKOVSKY O. Imagenet large scale visual recognition challenge [J]. International Journal of Computer Vision, 2015, 115(3): 211-252.
- [6] SUN Y, WANG X, TANG X. Deep learning face representation from predicting 10,000 classes [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2014: 1891-1898.
- [7] YANG W G, HUAI Y J. Flower Image Enhancement and Classification Based on Deep Convolution Generative Adversarial Network [J]. Computer Science, 2020, 47(6): 182-185.
- [8] HAO Y, DONG L, WEI F, et al. Visualizing and understanding the effectiveness of BERT [J]. arXiv: 1908. 05620, 2019.
- [9] VASHISHTH S, UPADHYAY S, TOMAR G S, et al. Attention interpretability across nlp tasks [J]. arXiv: 1909. 11218, 2019.
- [10] GRAVES A, MOHAMED A R, HINTON G. Speech recognition with deep recurrent neural networks [C] // 2013 IEEE International Conference on Acoustics, Speech and Signal Processing. IEEE, 2013: 6645-6649.
- [11] SAK H, SENIOR A, RAO K, et al. Fast and accurate recurrent neural network acoustic models for speech recognition [J]. arXiv: 1507. 06947, 2015.
- [12] ANTONY J, MCGUINNESS K, O'CONNOR N E, et al. Quantifying radiographic knee osteoarthritis severity using deep convolutional neural networks [C] // 2016 23rd International Conference on Pattern Recognition (ICPR). IEEE, 2016: 1195-1200.
- [13] HASHIMOTO N. Multi-scale Domain-adversarial Multiple-instance CNN for Cancer Subtype Classification with Unannotated Histopathological Images [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 3852-3861.
- [14] GAO X T, LIN S, WONG T Y. Automatic feature learning to grade nuclear cataracts based on deep learning [J]. IEEE Trans on Biomedical Engineering, 2015, 62(11): 2693-2701.
- [15] TALO M, YILDIRIM O, BALOGLU U B, et al. Convolutional neural networks for multi-class brain disease detection using MRI images [J]. Computerized Medical Imaging and Graphics, 2019, 78: 101673.
- [16] ABDEL-ZAHER A M, ELDEIB A M. Breast cancer classification using deep belief networks [J]. Expert Systems with Applications, 2016, 46: 139-144.
- [17] FRID-ADAR M, DIAMANT I, KLANG E, et al. GAN-based synthetic medical image augmentation for increased CNN performance in liver lesion classification [J]. Neurocomputing, 2018, 321: 321-331.
- [18] GLOROT X, BENGIO Y. Understanding the difficulty of training deep feedforward neural networks [C] // Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics, 2010: 249-256.
- [19] HE K, ZHANG X, REN S, et al. Identity mappings in deep residual networks [C] // European Conference on Computer Vision. Springer, 2016: 630-645.



LIU Han-qing, born in 1997, M. S. candidate. His main research interest includes medical image processing and so on.



KANG Xiao-dong, born in 1964, Ph.D., professor. His main research interests include medical image processing and medical information system integration.