

基于典型医学图像的分类技术研究进展

张薇¹, 吕晓琪^{1,2*}, 吴凉¹, 张明¹, 李菁¹

¹内蒙古科技大学信息工程学院, 内蒙古 包头 014010;

²内蒙古工业大学, 内蒙古 呼和浩特 010051

摘要 分类是医学图像在计算机辅助诊断和模式识别领域的一个研究热点。精确地对人体解剖结构和病变区域进行分类能够最大程度辅助医生更精确、更快速地诊断病情。针对医学图像的特殊性,首先从图像预处理、图像分割、特征提取及分类方法 4 个方面对典型医学图像分类进行总结分析;然后介绍分析了深度学习理论在医学图像分类中的应用;最后提出现有的医学图像分类研究方法的不足,展望了深度学习领域的最新理论在医学图像分类领域的发展趋势。

关键词 医学图像; 分类; 解剖结构; 病变区域; 深度学习

中图分类号 TP391.4

文献标识码 A

doi: 10.3788/LOP55.120007

Advances in Classification Technology Based on Typical Medical Images

Zhang Wei¹, Lü Xiaoyi^{1,2*}, Wu Liang¹, Zhang Ming¹, Li Jing¹

¹School of Information Engineering, Inner Mongolia University of Science and Technology, Baotou, Inner Mongolia 014010, China;

²Inner Mongolia University of Technology, Hohhot, Inner Mongolia 010051, China

Abstract The classification of medical images is a research hotspot in the field of computer-aided diagnosis and pattern recognition. Accurately categorizing human anatomical structure and lesion areas can maximally assist doctors in diagnosing diseases more accurately and quickly. Herein, for the particularity of medical images, typical medical image classification is first summarized and then described according to four aspects: image preprocessing, image segmentation, feature extraction, and classification. Next, the application of deep learning theory to medical image classification is introduced and discussed. Finally, the shortage of the existing medical image classification methods is addressed, and the development trend of the latest theories of deep learning in the field of medical image classification is discussed.

Key words medical images; classification; anatomical structure; lesion area; deep learning

OCIS codes 000.1430; 100.2960; 150.0155; 340.7440

1 引言

随着计算机技术和信息化技术的发展,医学影像设备近年得到迅速发展,在临床和医疗信息化中得到广泛应用。在医学图像的多种类型中,以 X 光成像、计算机断层扫描(CT)成像、核磁共振(MR)成像及超声(UI)成像的医学图像较为典型。典型医学图像的分类处理及如何得到适合诊断和信息化处

理需求的图像,是重要的命题和研究内容^[1]。分类技术作为医学图像处理的重要技术之一,可以较精确地分析医学图像中人体的解剖结构以及病变区域。本文总结了图像分析任务及其技术,回顾和总结了图像分析任务在医学图像处理中的研究现状,并针对现有的研究提出不足并展望了未来医学图像的分类技术。本文为研究学者应用各类技术分析不同类型的典型医学图像提供参考。

收稿日期: 2018-06-12; 修回日期: 2018-06-26; 录用日期: 2018-07-12

基金项目: 国家自然科学基金(61771266,61179019)、包头市科技计划项目(2015C2006-14)

* E-mail: lxiaoqi@imut.edu.cn

2 传统医学图像分类技术概述

传统医学图像处理大致分为图像预处理、图像分割、特征提取、特征选择、训练分类器及对测试集进行测试。然而近几年,随着深度学习理论的出现,越来越多的研究学者将深度学习理论用于医学图像的处理。其中卷积神经网络(CNN)是深度学习中比较有代表性的网络结构,利用 CNN 对医学图像进行分类,减少了特征提取和特征选择的环节,可直接将图像作为网络的输入,避免了人为选择的特征不具有代表性而导致的分类精度过低引起的医学诊断错误的后果^[2]。

2.1 图像预处理

为了后期能够精确地对图像进行分类,首先需要对图像进行预处理,其主要目的是消除图像中的无用信息,恢复及增强有用的关键信息,最大限度地简化数据,提高图像后处理的可靠性。预处理主要包括图像去噪和图像增强。

由于成像技术的不同,产生的噪声也不同。X射

线照片影像上的噪声也称为 X 射线照片斑点。其实质是指 X 射线量子统计涨落在照片上的记录反应。照片影像分为模拟和数字两种,间接数字化 X 射线成像技术(CR)和数字摄影(DR)等 X 射线数字摄影设备出现后,形成影像斑点的因素增多,如量子噪声、A/D 转换及读取噪声等^[3]。CT 是电子计算机控制和 X 射线检查相结合的产物,CT 值的随机波动是 CT 图像噪声形成的实质,在成像过程中会影响 CT 图像的质量,容易导致误诊漏诊情况的发生^[4]。MR 成像的噪声主要包括热噪声和随机噪声。热噪声产生的原因是接收线圈电阻和成像物理电阻中电子的热运动;而随机噪声产生的原因是线圈电容器有阻抗效应,在高频电磁波的作用下,会在物体表面产生感应电流,从而削弱电磁波的强度,产生随机噪声。在 UI 成像过程中,由于超声波的相互干涉作用产生的噪声类型主要为散斑噪声,它与成像组织表面的粗糙程度有着密切的关系。该噪声最终在图像中以斑点形式分布^[5]。因此,需要根据不同噪声类型选择相应的去噪算法。图 1 为 4 类典型的医学图像。




图 1 典型医学图像。(a) X 射线图;(b) CT 图;(c) MR 图像;(d) 超声图像

Fig. 1 Images of typical medical. (a) X-ray image; (b) CT image; (c) MR image; (d) UI

Lu 等^[6]针对 X 射线图像在传输过程中可能受到椒盐噪声影响的问题,提出了一种三阶段去噪算法,实验结果表明该方法能够有效地去除不同噪声密度下的噪声,重构图像也不会模糊。Shang 等^[7]提出一种三维的低剂量 CT 去噪方法,利用三维块匹配方法处理图像,获得了高质量的低剂量 CT 图像,具有较高的主观视觉质量和峰值信噪比(PSNR)。Ali 等^[8]提出改进的中值滤波 MR 图像去噪方法。首先将高斯噪声和椒盐噪声添加到 MR 图像中;然后用不同过滤器去除 MR 图像中存在的附加噪声;最后利用峰值信噪比对过滤器的性能进行比较,结果表明中值滤波器具有更好的性能。Zhang 等^[9]结合超声图像散斑噪声和非采样轮廓系数的统计特性,提出了改进的图像去噪方法,实验结果表明,该方法的客观评价指标和去噪视觉效果质量均优于传统去噪算法。

图像经去噪或者受到其他因素的影响后,会出现对比度降低和细节模糊的现象。对图像增强可以显现那些模糊了的细节,提高图像的清晰度,从而得到有价值的信息以便对图像进行其他处理。侯园园等^[10]针对 X 光胸片图像提出小波变换的增强算法,小波分解后,该方法首先利用小波阈值进行去噪处理,然后对高频分量采用非线性增强方法,对低频分量采用反锐化掩模增强方法,最后利用小波反变换重构出增强后的图像。实验结果表明,该方法可以在去除噪声的同时保留图像细节信息。吕鲤志^[11]针对 CT 图像提出基于 Laplacian 金字塔和小波变换的增强算法。首先对原图像进行小波变换分解;再对原图像进行 Laplacian 金字塔分解,得到 CT 图像的高频信息;最后利用小波变换的结果和 Laplacian 金字塔分解的结果进行重构,最终得到增强后的图像。实验结果表明,该方法的增强效果明

显优于采用传统图像增强算法得到的结果,同时能更好地抵抗噪声。Anand 等^[12]采用在小波域中双边滤波的方法对 MR 图像进行增强和去噪。王绍波^[13]针对超声图像提出一种自适应低通滤波算法,该算法有效地实现了超声医学图像增强,突出了超声图像的细节,改善了视觉效果,并对噪声具有良好的抑制作用。

2.2 图像分割

为了提高分类的精确度,在对大型图像进行处理时,需要对候选目标区域进行分割。Sun 等^[14]提出一种并行的医学图像分割方法,将区域生长与支持向量机(SVM)相结合,实验结果证明该算法与传统分割算法相比分割速度较快,分割结果也比较理想。Saad 等^[15]提出一种基于阈值技术的脑损伤分割方法,在分割过程中,该方法被分成若干区域,然后计算每个区域的直方图,找出每个强度级别的最大像素个数,通过对正常和病变区域的比较确定最佳阈值并进行分割。随着分割技术的发展,图像自动分割方法逐渐增多,如模糊分割方法、基于先验知识的分割方法及人工神经网络分割方法等。Christ 等^[16]利用模糊 c -均值(FCM)方法对脑组织进行分割,取得了不错的分割效果。Dong 等^[17]提出一种基于随机游走的分割方法,该方法是以先验知识为基础,实现肝脏的自动分割,与传统分割算法相比,该方法分割精度有了很大的提高。邹瑜等^[18]针对自组织映射(SOM)网络在分割图像时随着神经元数量增加分割性能下降的问题提出一种改进的 SOM 网络方法,这种方法中,由各个神经元充当有限脉冲响应(FIR)系统,通过 FIR-SOM 分割后,采用合并聚类的方法连接各联合聚类对象,分割效果优于仅基于 SOM 的算法。对于不同类型的医学图像,目标区域的分割方法需要按需选取,选择正确的

分割方法能够辅助图像分类后期的处理。

2.3 特征提取

在传统的分类算法中,特征提取至关重要。所提取的特征大致包括几何特征^[19]、灰度特征^[20]及纹理特征^[20]三类。几何特征包括细长度、类圆度、紧凑度及周长等;灰度特征包括灰度均值、标准差、方差三(四)阶矩及区域对比度等;纹理特征包括直方图熵及基于灰度共生矩阵(GLCM, 4 维)等。以下选取部分特征进行介绍。

细长度:目标区域的长轴与短轴的比值。计算细长度的公式为

$$M_1 = \frac{\max(c, k)}{\min(c, k)}, \quad (1)$$

式中 c 和 k 分别为目标区域内接矩形的长和宽。

紧凑度:紧凑度既可以用来表示与圆的相似度,也可以表示边缘的光滑程度。圆的紧凑度为 1。边界越复杂越粗糙,紧凑度越小;同时形状越扁,紧凑度的值也越小。其计算公式为

$$M_2 = \frac{4\pi \times S}{P^2}, \quad (2)$$

式中 P 为区域轮廓的周长, S 为区域轮廓的面积。

灰度均值与标准差:反映图像灰度差异。灰度均值和标准差计算公式分别为

$$G_m = \frac{1}{S} \sum_{x \in R} \sum_{y \in R} f(x, y), \quad (3)$$

$$G_u = \sqrt{\sum_{x \in R} \sum_{y \in R} [f(x, y) - G_m]^2}, \quad (4)$$

式中 (x, y) 为图像 I 中像素的坐标, $f(x, y)$ 为 (x, y) 像素点的灰度值, R 为目标区域。

灰度共生矩阵:对图像中存在某种位置关系的像素的灰度分布情况的统计,也可以看作一种二阶直方图。设 Q 为区域 R 中具有特定位置关系的像素对的集合,则共生矩阵 P 可以定义为

$$P(i, j) = \frac{\#\{(x_1, y_1), (x_2, y_2)\} \in Q \mid f(x_1, y_1) = i \& f(x_2, y_2) = j\}}{\#Q}, \quad (5)$$

式中分子代表具有某种关系,灰度值分别为 i 和 j 的像素对的个数,分母为像素对总和的个数^[20]。

2.4 分类方法

传统的医学图像分类方法根据算法性质的不同,大致可以分类 4 类:1) 统计模式医学图像分类;2) 结构模式医学图像分类;3) 模糊模式医学图像分类;4) 基于人工神经网络的模式医学图像分类。主要从以上 4 个方面对传统的医学图像分类的方法

进行分析。

1) 统计模式医学图像分类

统计模式医学图像分类是众多学者选择分类方法时应用较为广泛的理论。其主要方法包括贝叶斯分类器、线性分类器、SVM 及聚类方法等。

Arias 等^[21]提出了利用离散贝叶斯网络分类器对生物医学图像模态进行分类,分类准确率为 69.21%,但是贝叶斯网络的样本空间的先验概率、

类条件概率密度函数及决策表难以获得的缺点,限制了其应用。荣晶施等^[22]首先提出了弱对称性和强对称性的定义,从不同粒度对医学图像的对称性进行了描述,然后将医学图像分类分成三个阶段:第一阶段提出基于灰度直方图相交性的弱对称判定算法,在较粗粒度上进行分类;第二阶段提出基于点对称的强对称性判定算法,结合第一阶段提出的弱对称算法,对第一阶段的分类结果在异常的图像进行了更细粒度的分类,定位了病变区域的位置;第三阶段,提取病变区域的特征,利用特征对病变区域进行分类,最终实现辅助医生诊断的效果。SVM由Vapnik等于1995年首次提出^[23-24],是建立在统计学习理论和结构风险最小原理基础上的,该理论在小样本、非线性以及高维数的情况下运用较有优势,并在医学图像处理方面取得了巨大的成功。Abdullah等^[25]利用SVM分类器将脑MR图像分为正常和脑瘤两类,取得了很好的结果。沈健等^[26]首先对乳腺X光医学图像进行图像去噪以及增强处理,再利用边缘检测获取乳腺图像中的肿块区域,对提取的区域使用灰度共生矩阵提取特征,然后利用SVM对提取的特征进行分类;可直接将检测不到肿块区域的乳腺X光医学图像归为无乳腺癌(即正常)类。Khachane等^[27]对脑MR图像和膝关节MR图像进行分类,基于灰度共生矩阵的纹理特征,和离散小波变换(DWT)与离散余弦变换(DCT)的变换特征以及不变矩,训练SVM分类器对数据进行分类。实验结果表明,所提系统具有较好的性能。

2) 结构模式医学图像分类

结构模式医学图像分类方法处理的图像结构信息通常比较丰富,其特点是将结构的信息进行突出。在医学图像分类中,常被用于心电图的识别分类。陈长亮等^[28]提出图像识别句法分析的心电图计算机自动分析,该方法通过采用标准正交 Hermite 核函数来扩展生成基元并将基元的参数作为神经网络的输入,网络的输出即为判别结果,实验结果表明图像识别效果非常明显。

3) 模糊模式医学图像分类

Zadeh教授^[29]在1965年首次提出了模糊集(Fuzzy Sets)的概念,为模糊性及不确定性的研究提供了理论基础。人们通常将模糊数学与一些传统的模式识别方法相结合,如FCM、模糊支持向量机(FSVM)及模糊神经网络方法,且这些方法都已被广泛应用于医学图像识别领域。但是,模糊规则往往是根据经验得来的,准确合理的隶属函数较

难获得,导致其应用受到限制。

邹丽等^[30]提出了一种基于遗传算法的决策树对支持向量机(GA-DTTSVM)多类分类算法,解决传统支持向量机多类分类算法(Multi-TWSVM)中出现的模糊性问题。GA-DTTSVM用遗传算法对特征数据建立决策树,通过构建决策树可以分离样本的模糊区域,提高模糊区域样本的识别率。在决策树的每个节点上用SVM训练分类器,最后用训练后的分类器对目标进行分类和预测。实验结果表明,与决策树对支持向量机(DTTSVM)多类分类算法以及Multi-TWSVM相比,GA-DTTSVM多类分类算法具有较高的分类精度和较快的训练速度。胡学伟等^[31]针对医学图像的特殊性,及目前提出的特征选择算法在应用于医学图像分类时效果不够理想等问题,提出了一种基于邻域关系的模糊粗糙集模型,基于该模型给出特征选择算法,并将其应用于乳腺X光图像。实验结果表明,同已有的算法相比,该方法能有效选择特征,分类精度得到了极大的提升。

4) 基于人工神经网络模式医学图像分类

人工神经网络(ANN)是一种模仿人的大脑神经突触结构及其活动而建立的一个理论化的数学模型,它由众多的神经元连接而成,具有大规模并行处理、分布式信息存储及良好的自组织和自学习等特点。根据网络拓扑结构的不同,人工神经网络大致可分为前馈型神经网络、反馈型神经网络及自组织神经网络。

El Abbadi等^[32]利用神经网络对MR图像进行分类,提取灰度共生矩阵等18个特征,然后选择合适的特征训练分类器,准确率达98%。周慧等^[33]提出一种径向基函数(RBF)神经网络的医学图像分类算法,该算法利用像素的特征信息作为训练样本对RBF神经网络进行训练,实验结果表明,RBF神经网络的结构简单、学习权值数量少且收敛速度快,网络学习性能较强,能够达到良好的分类效果。刘霏等^[34]提出一种基于反向传输(BP)神经网络的虹膜图像质量分类方法,该方法解决了在虹膜图像采集过程中由光照条件不足、眼镜反光和眼皮遮挡等因素造成的虹膜图像质量不理想的问题。该方法首先利用小波变换对虹膜图像进行特征提取,然后将提取的归一化数据作为网络的输入用于网络的训练,最终将3种不同的影响因素影响的虹膜图像成功进行分类。实验结果表明,所提算法误差率较低,分类精度较高。

3 深度学习理论在医学图像分类中的应用

深度学习是近几年备受关注的理论,该理论通过建立和模拟人脑的分层结构来实现对外部输入的数据进行从低级到高级的特征提取,进而解释外部数据,深度学习可以自动提取隐藏在数据间的多层特征表示,已经被成功应用于语音识别,图像识别与分类分割等领域^[35]。深度学习作为机器学习的一个分支,其学习方法可以分为监督学习和无监督学习。两种方法都具有其独特的学习模型:监督学习包括多层感知机(Multilayer Perceptron)和 CNN 等;无监督学习包括深度置信网(DBNs)、自动编码器(Auto Encoders)、去噪自编码器(Denoising Autoencoders)及稀疏自编码(Sparse Coding)等。CNN 是深度学习算法在图像处理领域的重要应用,近几年在图像识别与分类中应用广泛。Setio 等^[36]利用二维 CNN 进行肺结节检测,通过提取肺结节二维层面上的大量特征进行训练,该方法的肺结节检测率达 85.4% 以上。da Silva 等^[37]利用二维 CNN,提取二维候选结节,对肺结节进行良恶性分类,正确率达到 82.3%。中国科学技术大学的薛迪秀^[38]针对内镜图像,利用 CNN 与 SVM 相结合对微血管进行分型识别,利用数据扩增技术增加了 CNN 特征的不变性,引入 SVM 替换 CNN 中的 softmax 来增强系统的泛化能力,最终识别准确率达 92.74%。稀疏自编码器(SAE)是深度学习中较流行的代表性学习方法之一,该方法能实现良好的性能,并具有较少的调节参数和较低的计算代价,在图像特征表达中得到广泛的运用。刘洋洋等^[39]针对 Image CLEFMed 2009 中的医学图像数据,首先利用多尺度的单层 SAE 产生局部特征检测器,通过与图像卷积得到特征映射,然后对这些特征映射进行主成分分析(PCA)降维,可以将不同长度的输入转换成一个固定长度的特征向量,最后采用稀疏表示分类(SRC)进行图像分类,分类精度达 99.0%。哈尔滨工业大学的魏存超^[40]首先利用深度学习理论对医学图像进行分类,又将深度学习方法与传统方法的优势相结合,构建 CNN-SVM 与 CNN-RF 分类器,通过实验对比,这两种方法的分类精度都可以达到 98% 以上。张娟等^[41]针对乳腺 X 光图像,利用深度学习的新方法——卷积受限玻尔兹曼机模型,采用改进的快速持续对比散度算法对模型进行训练,最后利用学到的特征对图像进行分类,平均分

类准确率为 88.63%。Roth 等^[42]针对 CT 图像,利用 CNN 对医学图像中的器官或者身体特定部位进行分类,特异性分类误差为 5.9%,平均 ROC (Receiver Operating Characteristic) 曲线下的面积(AUC)为 0.998。Khan 等^[43]提出一种改进的 CNN,设置多个卷积层和池化层以学习更高层次的特征,然后对医学图像的解剖部分进行分类,最终分类精度达 81%。Yu 等^[44]提出一种医学图像模态分类模型,利用深度学习理论,搭建三个不同深度的 CNN,最终在两个数据集上进行训练测试,分类精度分别达 76.87% 和 87.37%。

4 讨 论

4.1 传统医学图像分类方法的缺陷性

传统分类方法需要计算目标区域大量的特征,再对提出的特征进行选择,接着训练分类器,最后对测试集进行测试。在选择特征时,人为选择会使得所选特征不具有代表性,导致最终的分类精度较低,进而影响后期医生的诊断。

在统计模式医学图像分类方法中,对于大规模的医学影像数据,难以应用经典的 SVM 分类器训练样本,这将会耗费大量的机器内存,增加运算时间,并且 SVM 只针对二类分类,对于多分类问题存在一定的局限性。在医学图像分类中,要想能够尽快精确地确定病情,需要精确地分类解剖结构或者病变区域,所以随着医学影像设备不断发展,SVM 算法将很难再辅助医生的诊断。贝叶斯分类器在属性较多的情况下难以提高分类效率,并且二次利用贝叶斯分类器时,需要知道先验概率,在这种情况下,会增加运算的时间,限制分类效率。

结构模式医学图像分类方法适用范围比较单一,难以对多类型的医学图像进行分类,这限制了它的应用。结构模式医学图像分类方法大多用于心电图的分类。

模糊模式医学图像分类方法中,大多是在传统分类方法中引入模糊理论,如 FCM 及模糊支持向量机等。模糊模式医学图像分类方法不完全依赖于纯粹的数学模型,而加入模糊规则。模糊规则是操作者经过大量的操作实践总结出来的,在用于不同的医学图像分类时,需要根据已有的经验来确定规则,随着图像数据量的不断增大,已有的规则可能已不再适用,根据现有数据重新确定规则需要耗费更多的时间,分类效率降低。

在人工神经网络模式医学图像分类方法中,应

用神经网络需要调节大量的参数,如网络拓扑结构、权值和阈值的初始值,难以确定最优的网络结构;并且无法监测各结构之间的学习过程,这会影响到结果的可信度和可接受程度。在这类方法中,如果网络学习时间过长,甚至可能达不到学习的目的。

4.2 深度学习理论分类方法的缺陷

随着深度学习的快速发展,CNN在图像处理领域的应用也愈加广泛^[45-46]。研究之初,为了提高分类的精度,对医学图像进行分类时需要计算大量的特征才能更加精确地对医学图像进行分类。研究学者不断地探索及应用深度学习理论,在图像处理领域选择CNN对图像进行分类,可以直接将图像作为输入,然后训练以及测试,使得分类精度提高,程序运行时间也将有所降低。

随着网络深度的增加,网络性能也不断增强。He等^[47]也已证明,在两种时间复杂度相同的网络中,深度越深的网络其性能也会相对地提升,然而,并不是网络越深越好,持续增加层数并不能提高性能,反而在增加一定程度后会出现退化现象。通过众多研究学者的分析可知,该问题并非完全由梯度消失造成。为了解决出现的问题,新的网络结构应运而生。

4.3 深度学习新理论

1) 深度残差学习(Deep Residual Learning)

在CNN中,网络深度越深,学习性能越强,因此,在网络搭建过程中,大多学者都将网络深度设置得比较深,但随着网络深度的不断加深,网络的训练过程更加困难,导致准确率开始达到饱和甚至下降^[48]。当搭建完成的网络达到最佳的训练效果,对网络的某些层的输入和输入要求应完全一致,此时网络层学习值为0的残差函数比学习恒等函数更加容易。因此,深层残差网络将残差表示运用于网络中,提出了残差学习的思想。图2为残差网络结构图,将适当的方法运用于网络中部分层之间的连接,在保证网络层数增加的同时,准确率能够不断提高。

残差网络结构较简单,解决了网络极深条件下

胶囊网络由胶囊组成。每一个胶囊单元是一组神经元,用于学习检测数据中某一特定区域,然后输出一个向量,该向量的长度用于表示特定物体出现的概率,物体的姿态由向量的方向编码表示。如果物体发生移动、旋转及调整大小等变换,胶囊将输出相同长度的向量,但是方向会有所不同。因此,胶囊是等变的。胶囊网络和普通神经网络一样,由许多层组成。初级胶囊层是最底层的胶囊层,每一个胶

深度CNN性能退化的问题,使得分类性能表现出色。自ILSVRC 2015至今,残差网络已逐渐应用于计算机视觉各领域,其性能也明显优于其他网络。同时,残差网络也表现出良好的图像分类性能。例如,在人脸识别领域,使用残差网络可以大幅提升人脸识别性能。在人脸识别准确率每3个月提升一个数量级的今天,残差网络及未来更高性能的网络结构必定会将这个周期进一步缩短。




图2 残差网络结构图

Fig. 2 Structure diagram of residual network

2) 胶囊网络

众所周知,如果利用CNN对图像进行分类,需要大量的图片来训练网络,或者复用训练好的CNN网络来填充当前网络的某些层;CNN不能很好地处理复杂的图像,在引入池化层后,会主动丢失大量的图像信息,池化层降低了空间分辨率,所以CNN对于输入的微小变化是不敏感的,如果要求网络保存细节信息时,利用CNN则效果不佳;另外CNN需要额外的组件来识别图像中元素的归属关系。为了解决上述问题,Sabour等^[49]提出胶囊网络(Capsule Network)理论,随即在机器学习领域造成相当震撼的影响。图3为胶囊网络结构图。该理论能更好地替代CNN方法,是当前计算机视觉领域的最新技术。囊单元都接收图像的一块区域作为输入,检测特定物体的存在和姿态。更高层则能够检测更大更复杂的物体,如船只等。

近年来,深度学习理论快速发展,目前的研究已表明医学图像分类采用深度学习方法能够大大提高分类精度,辅助医生快速确定病情。随着深度学习新理论不断出现,由其衍生出来的新型网络结构性能更加优良,应用于医学图像也将是必然趋势。同时,大规模图像数据的产生使得对计算机硬件的要求也提高,图像处理器(GPU)在这种趋势下飞速发展,将其应用于医学图像处理领域,能够加快病情的确诊,防止病情的延误,加速医学图像处理的发展^[50]。




图3 胶囊网络结构图

Fig. 3 Structure of capsule network

5 结束语

由于医学影像数据蕴含着大量人体信息,对医学图像进行正确分类是计算机辅助诊断的核心和基本技术。医学图像分类精度的提高,也在一定程度上为医生的诊断提供了较精确的客观依据,避免了不相关图像的干扰及主观因素对病例诊断时产生的不利影响,进而从医学图像和生物信息等多角度辅助医生进行图像分析及医学诊断。随着深度学习的迅速发展,将深度学习理论运用到医学图像分类领域是必然选择,通过深度学习理论可以不断学习图像深层特征,能够提高医学图像的分类精度,对医生的诊断有重要的辅助作用。

参 考 文 献

- [1] Smitha P, Shaji L, Mini M G. A Review of Medical Image Classification Techniques [C] // International conference on VLSI, Communications and instrumentation, Karunagapally. International Journal of Computer Applications, 2011(11): 34-38.
- [2] Yang J L, Zhao J J, Qiang Y, *et al.* A classification method of pulmonary nodules based on deep belief network[J]. Science Technology and Engineering, 2016, 16(32): 69-74.
杨佳玲, 赵涓涓, 强彦, 等. 基于深度信念网络的肺结节良恶性分类[J]. 科学技术与工程, 2016, 16(32): 69-74.
- [3] Li Y Q, Qiu J F, Zhang W M, *et al.* Medical imaging theory [M]. 2nd ed. Beijing: People's Medical Publishing House, 2010.
李月卿, 邱建峰, 章伟敏, 等. 医学影像成像理论 [M]. 第二版. 北京: 人民卫生出版社, 2010.
- [4] Lü X Q, Wu L, Gu Y, *et al.* Low dose CT lung denoising model based on deep convolution neural network[J]. Journal of Electronics & Information Technology, 2018, 40(6): 1353-1359.

吕晓琪, 吴凉, 谷宇, 等. 基于深度卷积神经网络的低剂量CT肺部去噪[J]. 电子与信息学报, 2018, 40(6): 1353-1359.

- [5] Bamber J C, Daft C. Adaptive filtering for reduction of speckle in ultrasonic pulse-echo images [J]. Ultrasonics, 1986, 24(1): 41-44.
- [6] Lu C T, Chen M Y, Shen J H, *et al.* X-ray bio-image denoising using directional-weighted-mean filtering and block matching approach[J]. Journal of Ambient Intelligence & Humanized Computing, 2018: 1-18.
- [7] Shang X B, Ding Y, Ding R Z, *et al.* A three-dimensional denoising method for low-dose computed tomography [J]. Journal of Medical Imaging & Health Informatics, 2017, 7(1): 283-287.
- [8] Ali H M. High-resolution neuroimaging-basic physical principles and clinical applications. Chapter 7: MRI medical image denoising by fundamental filters[M]. London: 2018: 111-124.
- [9] Zhang X, Gu H B, Zhou L, *et al.* Improved dual-domain filtering and threshold function denoising method for ultrasound images based on non-subsampled contourlet transform [J]. Journal of Medical Imaging and Health Informatics, 2017, 7(7): 1624-1628.
- [10] Hou Y Y, Zhou P. Approach on digital chest radiographs enhancement based on wavelet transform [J]. Chinese Journal of Medical Imaging Technology, 2010, 26(10): 1976-1979.
侯园园, 周萍. 基于小波变换的数字胸片增强[J]. 中国医学影像技术, 2010, 26(10): 1976-1979.
- [11] Lü L Z, Qiang Y. Medical CT image enhancement algorithm based on Laplacian pyramid and wavelet transform[J]. Computer Science, 2016, 43(11): 300-303.
吕鲤志, 强彦. 基于Laplacian金字塔和小波变换的医学CT图像增强算法[J]. 计算机科学, 2016, 43(11): 300-303.

- [12] Anand C S, Sahambi J S. Wavelet domain non-linear filtering for MRI denoising [J]. *Magnetic Resonance Imaging*, 2010, 28(6): 842-861.
- [13] Wang S B, Guo Y C, Gao M, *et al.* Method of medical ultrasonic image de-noising based on fuzzy PCNN in the wavelet domain [J]. *Journal of Optoelectronics • laser*, 2010, 21(3): 476-480.
王绍波, 郭业才, 高敏, 等. 基于模糊 PCNN 的小波域超声医学图像去噪方法 [J]. *光电子 • 激光*, 2010, 21(3): 476-480.
- [14] Sun Y Q, Liang X. A new parallel segmentation algorithm for medical image [J]. *International Journal of Signal Processing, Image Processing and Pattern Recognition*, 2015, 8(2): 139-146.
- [15] Saad N M, Abu-Bakar S A R, Muda S, *et al.* Segmentation of brain lesions in diffusion-weighted MRI using thresholding technique [C] // 2011 IEEE International Conference on Signal and Image Processing Applications, November 16-18, 2011, Kuala Lumpur, Malaysia. New York: IEEE, 2012: 249-254.
- [16] Jobin Christ M C, Parvathi R M S. Fuzzy c-means algorithm for medical image segmentation [C] // 2011 3rd International Conference on Electronics Computer Technology, April 8-10, 2011, Kanyakumari, India. New York: IEEE, 2011: 33-36.
- [17] Dong C H, Chen Y W, Tateyama T, *et al.* A knowledge-based interactive liver segmentation using random walks [C] // 2015 12th International Conference on Fuzzy Systems and Knowledge Discovery, August 15-17, 2015, Zhangjiajie, China. New York: IEEE, 2015: 1731-1736.
- [18] Zou Y, Shuai R J. Improved segmentation algorithm of medical images based on SOM neural network [J]. *Computer Engineering and Design*, 2016, 37(9): 2533-2537, 2581.
邹瑜, 帅仁俊. 基于改进的 SOM 神经网络的医学图像分割算法 [J]. *计算机工程与设计*, 2016, 37(9): 2533-2537, 2581.
- [19] Chen S Y, Chao Y, Zou L. Detection of solitary pulmonary nodules based on geometric features [J]. *Journal of Biomedical Engineering*, 2016, 33(4): 680-685.
陈树越, 晁亚, 邹凌. 基于几何特征的孤立性肺结节检测 [J]. *生物医学工程学杂志*, 2016, 33(4): 680-685.
- [20] Guo H. Research on solitary lung nodule detection of low dose CT image [D]. Xi'an: Xidian University, 2010.
郭浩. 低剂量 CT 孤立肺结节检测方法研究 [D]. 西安: 西安电子科技大学, 2010.
- [21] Arias J, Martínez-Gómez J, Gámez J A, *et al.* Medical image modality classification using discrete Bayesian networks [J]. *Computer Vision and Image Understanding*, 2016, 151: 61-71.
- [22] Rong J S, Pan H W, Gao L L, *et al.* Medical image multi-stage classification algorithm based on the theory of symmetric [J]. *Chinese Journal of Computers*, 2015, 38(9): 1809-1824.
荣晶施, 潘海为, 高琳琳, 等. 基于对称性理论的医学图像多阶段分类算法 [J]. *计算机学报*, 2015, 38(9): 1809-1824.
- [23] Cortes C, Vapnik V. Support-vector networks [J]. *Machine Learning*, 1995, 20(3): 273-297.
- [24] Lü J, Zhu W Y, Qing C, *et al.* Estimation of atmospheric optical turbulence at near surface of Chengdu with support vector machine [J]. *Chinese Journal of Lasers*, 2018, 45(4): 0404001.
吕洁, 朱文越, 青春, 等. 支持向量机估算成都近地面大气光学湍流 [J]. *中国激光*, 2018, 45(4): 0404001.
- [25] Abdullah N, Ngah U K, Aziz S A. Image classification of brain MRI using support vector machine [C] // 2011 IEEE International Conference on Imaging Systems and Techniques, May 17-18, 2011, Penang, Malaysia. New York: IEEE, 2011: 242-247.
- [26] Shen J, Jiang Y, Zhang Y N, *et al.* Multi-class medical image classification approach based on edge detection [J]. *Journal of Data Acquisition and Processing*, 2016, 31(5): 1028-1034.
沈健, 蒋芸, 张亚男, 等. 基于边缘检测的多类别医学图像分类方法 [J]. *数据采集与处理*, 2016, 31(5): 1028-1034.
- [27] Khachane M Y. Organ-based medical image classification using support vector machine [J]. 2017, 8(1): 18-30.
- [28] Chen C L, Yang W J, Chen Z S. Electrocardiogram computer automatic analysis based on pattern recognition syntax analysis [J]. *China Medical Devices Information*, 2006, 12(3): 17-18, 22.
陈长亮, 杨伟杰, 陈振生. 基于图像识别句法分析的心电图计算机自动分析 [J]. *中国医疗器械信息*, 2006, 12(3): 17-18, 22.
- [29] Zadeh L A. Fuzzy sets [J]. *Information and Control*, 1965, 8(3): 338-353.

- [30] Zhou L, Jiang Y, Chen N, *et al.* New medical image classify approach based on decision tree twin support vector machine [J]. *Computer Engineering and Applications*, 2016, 52(21): 76-80.
邹丽, 蒋芸, 陈娜, 等. 基于决策树对支持向量机的医学图像分类新方法[J]. *计算机工程与应用*, 2016, 52(21): 76-80.
- [31] Hu X W, Jiang Y, Zou L, *et al.* Medical image classification based on neighborhood relation fuzzy rough set [J]. *Computer Engineering & Science*, 2016, 38(4): 739-746.
胡学伟, 蒋芸, 邹丽, 等. 基于邻域关系模糊粗糙集的医学图像分类研究[J]. *计算机工程与科学*, 2016, 38(4): 739-746.
- [32] El Abbadi N K, Kadhim N E. Brain cancer classification based on features and artificial neural network [J]. *International Journal of Advanced Research in Computer and Communication Engineering*, 2017, 6(1): 123-134.
- [33] Zhou H, Zhang Y S, Gong M. The classification of medical image based on the RBF neural network[J]. *International Electronic Elements*, 2017, 25(3): 113-116, 120.
周慧, 张尤赛, 龚森. 基于 RBF 神经网络的医学图像分类算法研究[J]. *电子设计工程*, 2017, 25(3): 113-116, 120.
- [34] Liu F, Gu W J, Wang G T, *et al.* BP neural network based classification method for iris image quality[J]. *Shandong Science*, 2015, 28(2): 108-112.
刘霏, 谷文静, 王公堂, 等. 基于 BP 神经网络的虹膜图像质量分类方法[J]. *山东科学*, 2015, 28(2): 108-112.
- [35] Liu Z, Huang J T, Feng X. Action recognition model construction based on multi-scale deep convolution neural network [J]. *Optics and Precision Engineering*, 2017, 25(3): 799-805.
刘智, 黄江涛, 冯欣. 构建多尺度深度卷积神经网络行为识别模型[J]. *光学精密工程*, 2017, 25(3): 799-805.
- [36] Setio A 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): 1160-1169.
- [37] da Silva G L F, Silva A C, de Paiva A C, *et al.* Classification of malignancy of lung nodules in CT images using convolutional neural network [J]. *Workshop de Informática Médica*, 2016(16): 2481-2489.
- [38] Xue D X. Research on cancer image recognition based on convolutional neural networks [D]. Hefei: University of Science and Technology of China, 2017.
薛迪秀. 基于卷积神经网络的医学图像癌变识别研究[D]. 合肥: 中国科学技术大学, 2017.
- [39] Liu Y Y, Tang Q L. Medical image classification based on the multi-scale single-layer SAE [J]. *The Guide of Science & Education*, 2017(5): 20-21, 192.
刘洋洋, 唐奇伶. 基于多尺度单层自编码器的医学图像分类[J]. *科教导刊(下旬)*, 2017(5): 20-21, 192.
- [40] Wei C C. Research on medical image classification method based on convolutional neural network [D]. Harbin: Harbin Institute of Technology, 2017.
魏存超. 基于卷积神经网络的医学图像分类的研究[D]. 哈尔滨: 哈尔滨工业大学, 2017.
- [41] Zhang J, Jiang Y, Hu X W, *et al.* A new medical image classification method based on convolution restricted Holtzman machine [J]. *Computer Engineering & Science*, 2017, 39(2): 323-329.
张娟, 蒋芸, 胡学伟, 等. 基于卷积受限玻尔兹曼机的医学图像分类新方法[J]. *计算机工程与科学*, 2017, 39(2): 323-329.
- [42] Roth H R, Lee C T, Shin H C, *et al.* Anatomy-specific classification of medical images using deep convolutional nets[C] // 2015 IEEE 12th International Symposium on Biomedical Imaging, April 16-19, 2015, New York. New York: IEEE, 2015: 101-104.
- [43] Khan S, Yong S P. A deep learning architecture for classifying medical images of anatomy object [C] // 2017 Asia-Pacific Signal and Information Processing Association Summit and Conference, December 12-15, 2017, Malaysia. 2017: 1661-1668.
- [44] Yu Y, Lin H, Meng J, *et al.* Deep transfer learning for modality classification of medical images [J]. *Information*, 2017, 8(3): 91.
- [45] Yang N, Nan L, Zhang D Y, *et al.* Research on image interpretation based on deep learning [J]. *Infrared and Laser Engineering*, 2018, 47(2): 18-25.
杨楠, 南琳, 张丁一, 等. 基于深度学习的图像描述研究[J]. *红外与激光工程*, 2018, 47(2): 18-25.
- [46] Feng X Y, Mei W, Hu D S. Aerial target detection based on improved faster R-CNN [J]. *Acta Optica Sinica*, 2018, 38(6): 0615004.
冯小雨, 梅卫, 胡大帅. 基于改进 Faster R-CNN 的空中目标检测 [J]. *光学学报*, 2018, 38(6): 0615004.

- [47] He K M, Zhang X Y, Ren S Q, *et al.* Deep residual learning for image recognition [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, USA. New York: IEEE, 2016: 770-778.
- [48] Zhang M, Lü X Q, Wu L, *et al.* Multiplicative denoising method based on deep residual learning[J]. Laser & Optoelectronics Progress, 2018, 55(3): 031004.
张明, 吕晓琪, 吴凉, 等. 基于深度残差学习的乘性噪声去噪方法[J]. 激光与光电子学进展, 2018, 55(3): 031004.
- [49] Sabour S, Frosst N, Hinton G E. Dynamic routing between capsules [C] // 31st Conference on Neural Information Processing Systems, 2017, Long Beach, CA, USA. 2017: 3856-3866.
- [50] Chang L, Deng X M, Zhou M Q, *et al.* Convolutional neural networks in image understanding[J]. Acta Automatica Sinica, 2016, 42(9): 1300-1312.
常亮, 邓小明, 周明全, 等. 图像理解中的卷积神经网络[J]. 自动化学报, 2016, 42(9): 1300-1312.