

# 基于多模态 3D-CNNs 特征提取的 MRI 脑肿瘤分割方法

罗蔓黄靖\* 杨丰

(南方医科大学生物医学工程学院, 广州 510515)

**摘要** 针对目前 MRI 脑肿瘤分割中的无监督特征提取方法无法适应脑肿瘤图像的差异性, 提出一种基于多模态 3D 卷积神经网络(CNNs)特征提取的 MRI 脑肿瘤分割方法。将 2D 的多模态 MRI 图像组合成 3D 原始特征, 通过 3D-CNNs 提取特征, 更有利于提取各模态之间的差异信息, 去除各模态之间的冗余干扰信息, 同时缩小原始特征邻域大小, 以适应同一病人不同图像层肿瘤大小的差异变化, 进一步提高 MRI 脑肿瘤的分割精度。实验结果证明, 能适应不同病人各模态之间的差异性和多变性, 以提高脑肿瘤的分割精度。

**关键词** 卷积神经网络 深度学习 特征提取 脑肿瘤分割

**中图分类号** TP391.41; **文献标志码** A

核磁共振成像(magnetic resonance imaging, MRI)能够提供高分辨率、高品质的图像, 对大脑的解剖结构进行准确地描述, 是当前医学图像分析领域的研究热点之一<sup>[1]</sup>; 也是脑肿瘤诊断的重要辅助手段, 对脑肿瘤的诊断、治疗及手术引导具有重要的意义<sup>[2]</sup>。为了充分利用图像中的解剖信息, 为临床诊断提供量化、直观的参考, 首先必须精确的对脑肿瘤进行分割。然而, 由于脑肿瘤形状多变、结构复杂以及灰度不均匀, 脑肿瘤边界多伴有水肿存在, 不同病人不同模态图像之间差异信息大, 使得 MRI 脑肿瘤分割仍是一个值得深入研究的问题<sup>[3,4]</sup>。

基于像素的 MRI 脑肿瘤分割方法一直以来是研究的一大热点<sup>[4]</sup>。研究内容主要针对特征提取、特征选择和分类器设计, 好的特征提取能使得分类器的工作变得简单<sup>[5]</sup>。特征提取按方法主要分为统计方法、模型方法和信号处理方法, 其各有优势和不足<sup>[6]</sup>。统计方法简单, 易于实现, 对小图像具有一定的优势, 但其对全局信息的利用不足, 与人类视觉模型脱节; 模型方法能够兼顾纹理局部的随机性和整体上的规律性, 具有很大的灵活性, 不足是模型系数难以求解, 参数调节不方便; 信号处理方法善于捕捉纹理的细节信息, 能同时在空间和频域上表现

纹理特征, 然而小波往往忽视高频信息, 不善于提取非规则纹理特征。MRI 的不同模态图像能提供不同的纹理边界信息, 由于个体差异, 不同病人同一模态所表现的信息也大不相同<sup>[7]</sup>。由上可见, 没有一种特征提取方法适合所有 MRI 脑肿瘤的分割。

由 Yam LeCun 等人提出的卷积神经网络(convolutional neural networks, CNNs)<sup>[8]</sup>是有监督深度学习<sup>[9]</sup>方法的一种, 已在众多领域取得巨大的成功, 如图像识别<sup>[10,11]</sup>、语音识别<sup>[12,13]</sup>、自然语言处理<sup>[14]</sup>。CNNs 通过对原始输入数据进行循环卷积下采样, 以有监督训练的方式获取卷积权重, 最终实现直接从原始输入中提取有利于分类的特征, 在图像识别中特征表现为纹理、形状、结构等, 但是由于 CNNs 需要多次卷积与下采样, 输入对象通常是一幅图像, 邻域值较大, 并不适用于细节纹理丰富、变化多样的 MRI 脑肿瘤图像特征提取。

结合 MRI 多模态信息, 将 CNNs 扩展到 3D, 由多个模态共同构成 3D 的原始数据, 用 3D 卷积模板提取有利于分割的特征, 并将提取到的特征通过支持向量机(SVM)分类器实现分割。首先, 引入 CNNs 作为 MRI 脑肿瘤分割的特征提取方法, 有监督的方法使得分类特征是根据不同病人的差异信息自动生成, 克服了无监督特征提取方法只对某类特征具有针对性的缺点; 其次, 将 2D-CNNs 扩展到多模态 3D-CNNs, 三个方向同时获取纹理信息, 不仅解决了 2D-CNNs 原始输入需要大邻域的缺点, 同时能更好的提取各模态之间的差异信息, 实现适应范围更广的 MRI 脑肿瘤分割。

2014年6月6日收到 国家自然科学基金(81000624)、  
国家自然科学基金(61271155)资助

第一作者简介: 罗蔓(1989—), 女, 硕士研究生。研究方向: 生物医学信号处理。E-mail: luomannj@sina.com。

\* 通信作者简介: 黄靖(1981—), 男, 博士, 副教授。研究方向: 生物医学信号处理。

## 1 多模态 3D-CNNs

### 1.1 CNNs 基本原理

CNNs<sup>[8]</sup>自 1998 年首次提出后,便作为一种高效识别方法受到研究者的广泛重视。随着 2006 年深度学习<sup>[9]</sup>概念的提出,CNNs 作为有监督深度学习的代表,再一次成为众多学科领域的研究热点之一,在图像识别领域,由于该网络直接输入原始图像,而不需要对图像进行复杂的前期预处理,因而得到了广泛的应用。

CNNs 通过三个方法来实现特征的抽取<sup>[15]</sup>:局域感受野、权值共享和次抽样。局域感受野指每一层网络层的神经元只与上一层的一个小邻域内的神经元连接,通过局域感受野,每个神经元可以提取初级的视觉特征,如方向线段、端点、角点等。权值共享使得卷积神经网络具有更少的参数,需要相对少的训练数据。次抽样可以减少特征的分辨率,实现对位移、缩放和其他形式扭曲的不变性。

在卷积层,前一层的特征图与一个可学习的核进行卷积,卷积的结果经过激活函数后得到这一层的特征图。常用的激活函数有 Sigmoid 函数和双曲正切函数<sup>[16]</sup>,双曲线正切函数如式(1),当  $a = 1.7159, b = 2/3$  时,  $f(\pm 1) = \pm 1$ ; 每一个输出的特征图可能与前一层的几个特征图的卷积建立关系。一般地,卷积层的形式如式(2)所示。

$$f(x) = a \tanh(bx) \quad (1)$$

$$a_j^l = f\left(\sum_{i \in M_j} a_i^{l-1} k_{ij}^l + b_j^l\right) \quad (2)$$

式中,  $l$  代表层数,  $k$  是卷积核,  $M_j$  代表输入特征图的一个选择。每个输出图有一个偏置  $b$ 。

次抽样层对输入进行抽样操作。如果出入的特征图为  $n$  个,则经过次抽样层后特征图的个数仍为  $n$ ,但是输出的特征图要变小。次抽样层的一般形式如式(3)。

$$a_j^l = f[\beta_j^l \text{down}(a_j^{l-1}) + b_j^l] \quad (3)$$

式(3)中,  $\text{down}(\cdot)$  表示次抽样函数。次抽样函数一般是对该层输入图像的一个  $n \times n$  大小的区域求和,因此,输出图像的大小是输入图像大小的  $1/n$ 。每一个输出的特征图有自己的  $\beta$  和  $b$ 。

### 1.2 多模态 3D-CNNs 特征提取

经典的 2D 卷积神经网络结构图<sup>[15]</sup>如图 1 所示,若原始输入层为  $32 \times 32$ ,将原始输入分别经过 6 个  $5 \times 5$  邻域卷积后得到 C1 层,其包含 6 个特征图; C1 层下采样后得到 S2 层,其大小为  $28 \times 28$ ; 经过两次卷积与下采样后得到一维特征 F5 层,再用径向基函数对特征进行分类,分类结果反向传播来修改各

个层的卷积权值与偏置,构成一个有监督的深度学习算法。




图 1 经典 2D-CNNs 结构图

Fig. 1 Struct chart of Classical 2D-CNNs

经典的 2D-CNNs 主要用于数字识别,其输入的图像总能大小固定,然后对整幅图像提取特征,将其运用到 MRI 脑肿瘤分割会出现如下问题:首先,要对脑肿瘤图像进行分割,必须对单个像素点进行分类,所以原始输入只能是单个像素点的邻域,而这个邻域的大小难以把握;其次,不同病人脑肿瘤大小不一,同一病人不同图像层脑肿瘤的大小也不一样,即使通过训练层确定了原始输入层的邻域值,也难以保证此邻域适合这个病人所有的肿瘤点;第三,如何充分利用 MRI 的多模态信息,实现更高精度的分类。

为了解决上述问题,对经典的 2D-CNNs 做出如下改进。

多模态 3D-CNNs 如图 2 所示,取四个模态的相同位置的小邻域如  $14 \times 14$  (具体邻域大小根据训练数据网格寻优所得),组成 3D ( $14 \times 14 \times 4$ ) 原始输入层,用 6 个权值共享的大小为  $3 \times 3 \times 2$  的卷积模板对原始输入层进行卷积,得到 6 个  $12 \times 12 \times 3$  特征图 C1; 6 个 C1 层的特征图分别经过 2D 平均下采样得到 S2 层; S2 层所有特征求和后经过 12 个  $3 \times 3 \times 2$  的卷积模板后得到 12 个  $6 \times 6 \times 2$  的特征图 C3 层; C3 层经过平均下采样后得到 S4 层; S4 层按列归一化后得到 96 维的特征向量 F5。




图 2 多模态 3D-CNNs

Fig. 2 Multimodal 3D-CNNs

多模态 3D-CNNs 原始输入层由四个模态共同构成,通过 3D 卷积,自动提取各个模态之间的差异信息;有监督学习方法实现了针对不同病人差异信息提取不同的分类特征;下采样使得特征提取包含更多的结构边缘信息,同时剔除冗余信息和噪声;多

模态共同输入使得原始输入需要更少的邻域信息,以适应不同图像层的肿瘤点,提高脑肿瘤的分割精度。

## 2 基于多模态 3D-CNNs 特征提取的 MRI 脑肿瘤分割

基于多模态 3D-CNNs 特征提取的 MRI 脑肿瘤分割分为图像预处理、特征提取、特征选择、训练分类器、分割图像等过程。本文具体分割过程如图 3 所示。

在特征提取方面,多模态 3D-CNNs 虽能提取更有利于分类的各模态间的差异信息,但深度学习会导致原始输入信息有部分损失,而 Haar 小波变换作为一种简单有效的信号处理方法,是基于像素的 MRI 脑肿瘤分割中的首选特征提取方法<sup>[17]</sup>。故在获取多模态 3D-CNNs 特征的同时,参考文献[18],采用各个模态 MRI 图像的 3D 邻域灰度信息、邻域内均值、标准差、Haar 小波低频系数与多模态 3D-CNNs 特征共同构成本文分割方法的初始特征,其中 3D 邻域取  $5 \times 5 \times 5$ ,并采用主成分分析(PCA)方法对初始特征集进行特征选择,达到降维和剔除冗余信息的目的。选用基于径向基核函数的支持向量机(SVM)作为像素分类器,在分类器的训练上,随机选取病人一层含中肿瘤图像,肿瘤内外各取 60 个点作为训练样本。

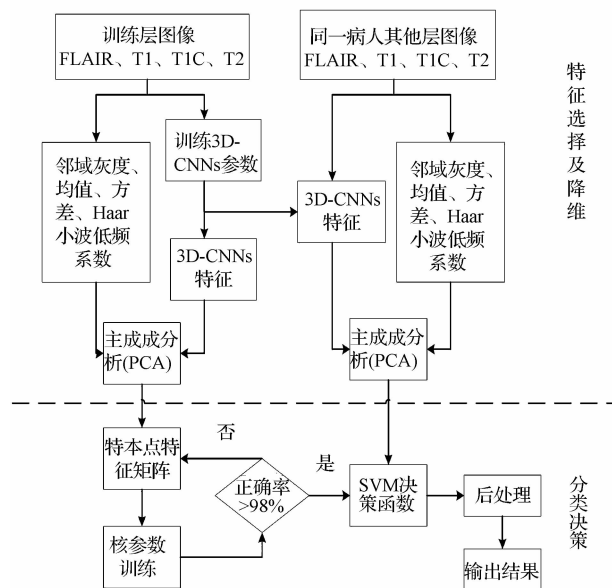


图3 本文方法系统流程图

Fig. 3 Flow diagram of the testing phase of the proposed method

在多模态 3D-CNNs 参数的训练上,随机选择一层含肿瘤层图像,选择所有的肿瘤点和相同数目的

背景点作为训练样本,由于不同病人肿瘤位置不一,肿瘤周围的邻域信息不近相同,故对于不同病人,通过网格寻优的方法,自适应确定最优的原始输入层邻域大小;确定邻域大小后,通过对训练样本的多次学习获得最终的多模态 3D-CNNs 各层卷积权值与偏置等参数。

## 3 实验结果与分析

在本节实验中,我们首先通过实验确定多模态 3D-CNNs 原始输入层邻域的取值范围;然后用加入多模态 3D-CNNs 特征的方法实现对脑肿瘤 MRI 图像的分割,并逐一分析相较于未加入多模态 3D-CNNs 特征的方法,不同病人所表现出来的差异性;最后将基于多模态 3D-CNNs 特征的方法和基于多模态 2D-CNNs 特征的方法进行对比,以验证本文方法的有效性与必要性,采用 dice 系数(dice similarity coefficient)、Sensitivity<sup>[3]</sup>和假阳性率(FP)<sup>[18]</sup>等技术指标评价分割结果,其中 dice 系数表示实验分割结果与专家手动分割结果的相似程度,Sensitivity 表示分割正确的肿瘤点所占比例。计算环境为 Matlab2011a, CPU3.40 GHz, RAM4.00 GB, Windows XP Professional。

这里所用的 MR 图像来自同文献中相同的在线图库 MICCAI2012 (<http://www.imm.dtu.dk/projects/BRATS2012>),该图库由 B. Menze, A. Jakab, S. Bauer, M. Reyes, M. Prastawa 和 K. VanLeemput 等人组建,有包括 ETH Zurich, University of Bern, University of Debrecen 和 University of Utah 在内的机构提供完全匿名的病人数据。图库中给出病人的 FLAIR、T1、T2、T1C 四种已配准图像 ( $512 \times 512 \times 176, 1 \times 1 \times 1\text{mm}$ )。选择 10 例真实病人数据进行脑肿瘤分割实验。

### 3.1 参数范围确定

多模态 3D-CNNs 的原始输入层要经过两次卷积和两次下采样才能得到初始特征,故原始输入层大小必须是  $(10 + 4n) \times (10 + 4n) \times 4$ , 其中  $n$  为自然数。图 4 是不同邻域大小对同一病人训练层平均分割结果,从图中可以看出,最优邻域大小在 14 ~ 26 出现,且考虑分割时间与小肿瘤部位分割精度,邻域值不宜取得过大,故邻域寻优范围为 10 ~ 30。

### 3.2 不同病人本文方法结果分析

图 5 为 10 个病人各自训练层的分割结果,从图中可以看出,病人 1、2、6、7、8 加上多模态 3D-CNNs 特征后分割精度无明显变化,这是由于邻域灰度和 Haar 小波低频系数已经能很好的描述各像素点的特征,而对于病人 3、4、5、9、10,加上 3D-CNNs 特征




图4 多模态 3D-CNNs 与输入邻域大小(size)关系曲线图

Fig.4 Curve graph of multimodal 3D-CNNs and neighbor size

后,训练层的分割精度得到明显的改善,这是由于多模态 3D-CNNs 自适应的提取了有利于分类的特征。实验证明即使是训练层,主观的特征提取适用性并不高。

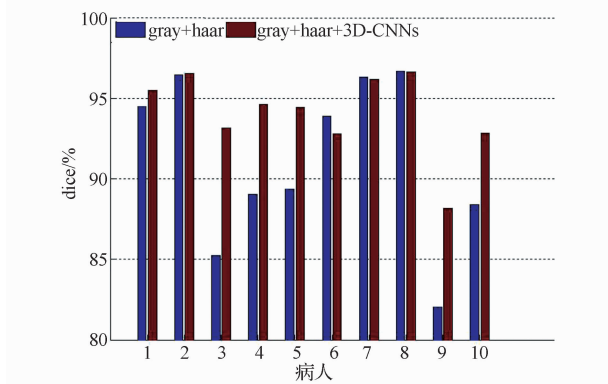


图5 不同特征训练层分割结果对比  
Fig.5 The comparison of different features in training layer

表1 7个病人平均分割结果

Table 1 The average segmentation result of 7 patients

特征种类	dice/%	sens./%	FP/%
gray + haar	83.38 ± 3.63	87.30 ± 5.10	19.94 ± 11.36
gray + haar + 3D-CNNs	87.14 ± 3.72	92.20 ± 4.17	19.59 ± 8.28

图6为其中7个病人的分割结果的不同系数表示,表1为与之相对应的7个病人的平均分割结果,从图6和表1可以看出,对于这7个病人,加上多模态 3D-CNNs 特征后,7个病人的 dice 系数都有不同程度的提高,且主要体现在 sensibility 系数上,即假阴性率得到明显改善,平均 dice 系数从 83.38 提高到 87.14。实验结果证明,多模态 3D-CNNs 这种有监督的特征提取方法,大邻域的原始特征能获得更多的边界信息,通过机器学习得到的卷积模板能获得更有利于分类的特征信息,同时下采样又去掉了部分冗余信息,使得特征数不是过于庞大,使得最终的分割精度得到大的改善。

但并不是所有的病人,加上多模态 3D-CNNs 特征后分割精度都会得到提高,如图7所示,对病人6,7,8这三个病人,加上新特征后,dice 系数并无明显变化,这是由于对于这三个病人,肿瘤周边水肿区域小,肿瘤区域与肿瘤区域灰度及纹理特征明显,邻域灰度加 Haar 小波系数已经能很好的区分肿瘤点与非肿瘤点。

图8为病人5(上排)和病人6(下排)的多模态 MRI 图,从图中可以看出,对于病人5,肿瘤与周边水肿区分度极差,T1 模态基本上不能提供任何灰度和纹理信息用于分类,T1C 模态肿瘤中心区域纹理信息丰富,但 T1C 和 T2 模态都很难区分肿瘤和非肿瘤区域边界,从训练层到测试层,病人5的分割精度都显著提高;而对于病人6,FLAIR 和 T1 模态的灰度信息,T1C 和 T2 模态的纹理信息都能很好的区分肿瘤点与非肿瘤点,且肿瘤周边水肿少,因此仅用邻域灰度和 Haar 小波低频系数便能得到高的分割精度,而病人6的分割进度并无改善。

图9为病人5训练层的分割结果,从真值中可以看出,肿瘤与非肿瘤边界很模糊,对于邻域灰度和 Haar 小波特征,分割结果将周围大面积水肿区域划分成了肿瘤,加上多模态 3D-CNNs 特征后,这种情况得到明显改善。

### 3.3 与 2D-CNNs 方法比较

表2为10个病人分别用邻域灰度和 Haar 小波




图6 不同特征测试层分割结果对比

Fig.6 The comparison of different features in test layers

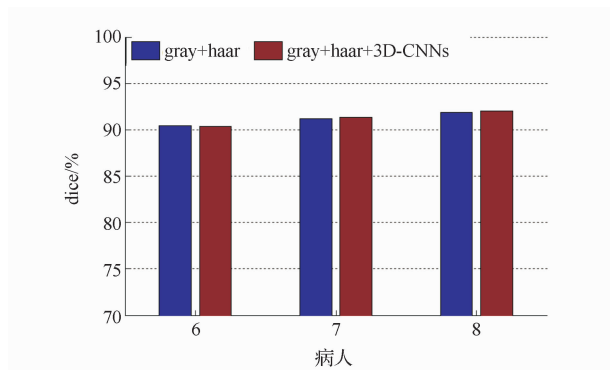


图7 不同特征测试层分割结果

Fig. 7 The comparison of different features in test layers




图8 多模态 MRI 图

Fig. 8 Multimodal MRI images




图9 病人5分割结果

Fig. 9 Segmentation of patient 5

低频系数(基本特征)、基本特征加多模态 3D-CNNs 及基本特征经典 2D-CNNs 提取特征的平均分割结果,其中经典 2D-CNNs 是对 4 个模态分别用不同邻域大小的 4 个 CNNs 进行特征学习,邻域大小通过网格寻优在 20 ~ 50 内获得。表 2 结果说明,多模态 3D-CNNs 特征提取方法明显优于经典 2D-CNNs,加上多模态 3D-CNNs 特征,dice 系数变成 88.37%,明显优于经典 2D-CNNs 的 83.93%;且加上经典 2D-CNNs 特征后,分割结果比仅用邻域灰度和 Haar 小

波低频系数还差。这是由于,首先,脑肿瘤一般都接近于球形,同一病人不同层肿瘤大小不一样,在训练层上训练得到的 2D-CNNs 模型很难适应整个病人肿瘤层图像;其次,分别对 4 个模态进行 2D-CNNs 特征提取,理论上能获得更丰富的不同模态之间的差异信息,但过多的特征信息增加了各像素线性不可分的程度,使得分割结果反倒变得更差;多模态 3D-CNNs,不仅克服了以上经典 2D-CNNs 的不足,四个模态的三维结合,更有利于各模态间差异信息的结合,同时去除冗余信息,促进有效分类的实现。

表 2 10 个病人平均分割结果

Table 2 The average segmentation result of 10 patients

特征提取方法	dice/%	sens./%	FP/%
gray + haar + 3D-CNNs	88.37 ± 3.65	91.84 ± 3.55	16.07 ± 8.94
gray + haar + 2D-CNNs	83.93 ± 4.51	91.85 ± 4.41	27.52 ± 12.08
gray + haar	85.71 ± 4.80	88.19 ± 4.44	16.31 ± 11.03

## 4 结论

提出一种基于多模态 3D-CNNs 特征提取的 MRI 脑肿瘤分割方法。图像分割中的特征提取方法很多,但由于所有特征提取方法都是根据主观经验事先设定好的,并不适合脑肿瘤大小、形状、灰度的特异性。CNNs 是一种针对分类对象特异性学习的一种有监督特征提取方法,已在很多领域有成功的应用,但对于图像分割,尤其是多模态 MRI 脑肿瘤分割,常规的 2D-CNNs 并不能很好的实现特征提取已达到高精度分割的目的。针对以上,结合多模态 MRI 图像的特点,本文提出一种多模态 3D-CNNs 特征提取方法,既能充分利用各个模态的差异信息,同时兼顾肿瘤大小的差异变化,提取更丰富的邻域信息及边界信息,更好的区分边界模糊的肿瘤点与非肿瘤点。实验结果表明,该方法能够适应多变化的多模态 MRI 脑肿瘤图像,准确地分割脑肿瘤。

在接下来的研究中,将进一步分析如何更好的结合多模态和同模态 3D 邻域 CNNs,使得特征提取时能更充分利用 3D 的 MRI 图像信息,以及如何更有效的提高分割速度,以期进一步完善本文所提出的分割策略。

## 参考文献

- 刘利雄,马忠梅,赵恒博,等. 一种基于主动轮廓模型的心脏核磁共振图像分割方法. 计算机学报, 2012;35(1):146—153  
Liu Lixiong, Ma Zhongmei, Zhao Hengbo, et al. A method for segmenting cardiac magnetic resonance images using active contours. Chinese Journal of Computers, 2012;35(1):146—153
- Wong K. Medical image segmentation: methods and applications in functional imaging. Handb Biomed Image Anal Segmentation Models

- Part B,2005;2:111—182
- 3 Jiang Jun, Wu Yao, Huang Meiyang, *et al.* 3D brain tumor segmentation in multimodal MR i-mages based on learning population-and patient-specific feature sets. *Computerized Medical Imaging and Graphics*,2013;27:512—521
  - 4 Gordillo N, Montseny E, Sobrevilla P. State of the art survey on MRI brain tumor segmentation. *Magnetic Resonance Imaging*,2013;31:1426—1438
  - 5 Duda R O, Hart P E, Stork D G. *Pattern classification, Second Edition.* John Wiley & Sons, Inc,2004
  - 6 刘 丽, 匡纲要. 图像纹理特征提取方法综述. *中国图象图形学报*,2009;14(4):622—635  
Liu Li, Kuang Gangyao. Overview of image textural feature extraction methods. *Journal of Image and Graphics*, 2009;14(4):622—635
  - 7 Atlas S W. *Magnetic resonance imaging of the brain and spine.* Lippincott Williams & Wilkins,2009
  - 8 LeCun Y, Bottou L, Bengio Y, *et al.* Gradient-based learning applied to document recognition. *Proc IEEE*, 1998; 86 ( 11 ): 2278—2324
  - 9 Hinton G E, Osindero S, Teh Y. A fast learning algorithm for deep belief nets. *Neural Computation*, 2006; 18:1527—1554
  - 10 Farabet C, Couprie C, Najman L, *et al.* Learning hierarchical features for scene labeling. *Transactions on Pattern Analysis and Machine Intelligence*,2013;35(8):1915—1929
  - 11 Krizhevsky A, Sutskever I, Hinton G. ImageNet classification with deep convolutional neural networks. *NIPS*, 2012
  - 12 Mohamed A, Sainath T N, Dahl G E, *et al.* Deep belief networks using discriminative features for phone recognition. *Acoustics, Speech and Signal Processing (ICASSP)*, 2011 IEEE International Conference on, IEEE, 2011:5060—5063
  - 13 Dahl G E, Yu Dong, Deng Li, *et al.* Large vocabulary continuous speech recognition with context-dependent DBN-HMMS. *Proc of IEEE International Conference on Acoustics, Speech and Signal Processing.* 2011:4688—4691
  - 14 Deselaerst, Hasans, Bendero, *et al.* A deep learning approach to machine transliteration. *Proc of the 4th Workshop on Statistical Machine Translation*, 2009:233—241
  - 15 LeCun Y, Bottou L, Bengio Y, *et al.* Gradient-based learning applied to document recognition. *Proc IEEE*, 1998: 2278—2324
  - 16 LeCun Y, Bottou L, Orr G B, *et al.* Efficient backprop. *Lecture Notes Comput Sci*, 1998;1524:9—50
  - 17 Zhang Yudong, Dong Zhengchao, Wu Lenan, *et al.* A hybrid method for MRI brain image classification. *Expert Systems with Applications*,2011;38: 10049—10053
  - 18 Nan Zhang, Su Ruan, Lebonvallet S, *et al.* Kernel feature selection to fuse multispectral MRI images for brain tumor segmentation. *Computer Vision and Image Understanding*, 2011;115:256—269

## Multimodal 3D Convolutional Neural Networks Features for Brain Tumor Segmentation

LUO Man, HUANG Jing\*, YANG Feng

(School of Biomedical Engineering, Southern Medical University, Guangzhou 510515, P. R. China)

[**Abstract**] Because the feature extraction in MRI brain tumor segmentation can not adapt to the arbitrary and differential of the brain images, this paper proposed a novel segmentation method based on multimodal 3D convolutional neural networks (CNNs) features. As a supervised features extraction method, CNNs can extract the texture, shape and structure characteristics automatically according to the characteristics of the image itself in the training process. By combining the 2D multimodal MR images into 3D primitive characteristics and utilizing 3D-CNNs to extract features, it is more conducive to extract the different information between different modal, remove the interference information among the different modal, shrink the neighborhood size of the original characteristics, and adapt to different tumor size change image layer on the same and further improve the accuracy of MRI brain tumor segmentation. The experimental results showed that compared with the current unsupervised feature extraction method and 2D-CNNs, this method can adapt to the diversity and dynamics of different patients and modals, and improve the segmentation accuracy of brain tumors.

[**Key words**] convolutional neural networks    deep learning    feature extraction    brain tumor segmentation