

DOI: 10.13382/j.jemi.B2003774

特征迁移结合主动标注的颅内病变鉴别方法^{*}

李杰文¹ 叶俊勇¹ 徐胜生² 伍文丽²

(1. 重庆大学 光电技术与系统教育部重点实验室 重庆 400044;

2. 重庆医科大学附属第一医院放射科 重庆 400042)

摘要:为了解决使用磁共振图像进行脑炎和胶质瘤的临床诊断时会出现误诊的问题,提出了一种卷积层特征迁移结合主动样本标注的分类方法。该方法首先采用卷积层特征参数迁移,利用磁共振成像(MRI)数据进行模型的微调,并验证了不同MRI模态特征的区分能力;其次针对样本标注困难问题,设计基于熵不确定性的样本主动标注算法,提取样本的不确定性信息,进一步提高模型的收敛速度以及泛化能力。在由重庆医科大学附属第一医院放射科纳入的175个病例(脑炎118例,胶质瘤57例)上进行实验,在交叉验证下分类准确率达到95.08%,曲线下面积达到0.98,模型的分类精度显著优于现阶段主要依靠医生经验的方法,准确率和曲线下面积分别提高17.51%和0.15;同时仅需要标注30%的数据样本,模型便能达到最优性能,减少大量数据标注工作,能够为初期诊断提供有意义的指导。

关键词:脑炎;胶质瘤;特征迁移;主动学习;熵不确定性

中图分类号: TN911.73 **文献标识码:** A **国家标准学科分类代码:** 520.20

Identification of intracranial lesions based on feature transfer and active labeling

Li Jiewen¹ Ye Junyong¹ Xu Shengsheng² Wu Wenli²

(1. Key Laboratory of Optoelectronic Technology and Systems of the Ministry of Education, Chongqing University, Chongqing 400044, China; 2. Department of Radiology, The First Affiliated Hospital, Chongqing Medical University, Chongqing 400042, China)

Abstract: In order to solve the misdiagnosis of encephalitis and glioma in clinical diagnosis while using MRI images, we proposed a classification method of convolutional layer feature transfer combined with active sample labeling. The method firstly adopts the convolutional layer features parameter transfer and uses the multi-modal MRI image data for the fine-tuning of models to verify the distinguishing ability of different MRI modal features. Secondly, in view of the difficulty of sample labeling, an entropy uncertainty based active labeling algorithm is designed to extract the uncertainty information of samples to further improve the convergence speed and generalization ability of the model. Experiments were carried out on a dataset of 175 cases (118 cases of encephalitis and 57 cases of glioma) collected by the radiology department of the First Affiliated Hospital of Chongqing Medical University. The results show that the classification accuracy under cross-validation reached 95.08% and area under the curve reached 0.98. The accuracy of the model was superior to the method mainly relying on the experience of doctors at present; and the accuracy and area under the curve was 17.51% and 0.15 higher than that of doctors, respectively. At the same time, only 30% of the data samples need to be annotated, so the model can achieve optimal performance, reduce a lot of data annotation work, and provide meaningful guidance for the initial diagnosis.

Keywords: encephalitis; glioma; feature transfer; active learning; entropy uncertainty

0 引言

脑炎和胶质瘤是常见的两种颅内病变,二者在病因、诊断和治疗等方面完全不同^[1-2]。脑炎是脑实质受到病原体侵袭导致的炎症性病变,而胶质瘤是先天的遗传高危因素和环境的致癌因素相互作用导致的。脑炎的治疗主要是抗感染、抗病毒、激素等内科治疗,而胶质瘤的治疗方法主要是手术切除和放疗化疗等。磁共振成像(magnetic resonance imaging, MRI)作为一种非侵入的检查诊断方法,对人体无任何伤害,且具有较高的软组织分辨率,可对颅内病灶进行准确的空间定位。当脑炎和胶质瘤的MRI影像表现以及临床症状表现典型时,医生可以比较容易的进行区分鉴别,但是当两种疾病的MRI检查结果不典型时,此时两者的鉴别诊断比较困难^[3],如何使用常规的MRI检查对两种疾病进行快速有效的诊断鉴别对临床的治疗以及预后具有重要意义。

近年来,深度学习的发展使得卷积神经网络(convolutional neural networks, CNN)被人们广泛关注,其强大的特征提取能力和表达能力,大幅度提升了深度学习模型的性能^[4-5]。越来越多的研究人员结合卷积神经网络的优点与影像组学的特点,提出了基于卷积神经网络方法来解决医学问题^[6-8]。针对不同的医学图像任务,如病变的分级^[9],病变的良性与恶性^[10],设计出了不同的深度学习模型结构来提取相应的特征鉴别来进行分类。一些研究工作达到了较高的准确率,具有一定的参考价值^[11-12]。

然而,不同于自然图像,在医学图像任务中应用卷积神经网络的方法普遍存在一个问题:用于训练深度学习模型的医学图像样本的获取是十分困难的,训练样本的匮乏制约了医学图像任务中基于深度学习方法的发展。针对该问题,部分方法采用在大规模自然图像数据集(ImageNet^[13])上对模型进行预训练然后进行迁移的方法^[14-16],一定程度上解决了在医学图像任务中数据集稀少的问题。Yang等^[17]使用Alexnet^[5]和GoogLeNet^[18]两种深度学习模型,利用参数迁移的方法对胶质瘤进行分级,达到了90.9%的准确率,AUC为0.939;Deepak等^[19]使用预训练的GoogLeNet模型对脑肿瘤进行分类,准确率达到97.1%;Deniz等^[14]针对乳腺癌的良性和恶性的鉴别任务,提出了使用深度学习模型对组织病理学图像进行特征提取并晚融合,结合支持向量机进行分类的方法,达到了91.37%的准确率。

此外,现有的相关工作忽视了样本标注带来的问题:在医学图像任务中,对医学样本的标注,不同于对自然图像的标注,不仅需要大量时间和精力,还需要专业知识和技能。现有的研究工作都需要进行长时间的人工标注,

并且需要对原始的MRI切片进行病灶区域的勾画,过程十分繁琐耗时,如何减少样本的标注工作也具有十分重要的意义。

基于以上相关研究和存在的问题,本文提出了特征迁移结合样本主动标注的方法,使用患者的常规MRI检查图像,对脑炎和胶质瘤进行鉴别诊断。针对训练样本较少的情况,本文使用卷积层特征迁移的方式,首先对3个深度学习模型(Alexnet, ResNet-50^[20]以及Inception-V3^[21])进行了结构改进,使用ImageNet数据集对模型进行预训练,然后使用不同模态的MRI数据对模型进行微调,达到有效区分两种病变的能力;其次,针对未标注样本充足的情况,本文设计了一个基于熵不确定性的样本主动标注算法来进行模型的优化,有效地提升了模型的收敛速度和泛化能力。不同于之前的研究主要集中在对同一病变的恶性和良性或者亚型进行分类鉴别,本文的研究工作关注于脑炎和胶质瘤在非典型情况下的鉴别区分,对比现有的相关工作,本文的主要工作如下:1)使用患者的常规MRI检查结果,不同于现有临床上需要进行进一步进行非常规检查,采用卷积层参数迁移的方式进行特征提取并分类,显著提高了两种病变的鉴别能力;2)只需对原始MRI数据进行简单裁剪的预处理,保留存在病灶的脑实质部分,不需要进行复杂的病灶区域勾画分割以及特征提取和筛选等,简化了预处理工作;3)针对医学图像中未标注样本充足的特点,提出样本主动标注算法,充分提取未标注数据样本集中的特征信息,在较少的标注工作下提高了模型的收敛速度。

1 方法

1.1 数据预处理

本文所用样本数据的收录对象为重庆医科大学第一附属医院2012年1月~2020年1月连续入组的164例(56例胶质瘤,108例脑炎)患者,并且征得所有患者的同意,在隐私保护下进行实验。收录的标准如下:1)经组织病理证实为胶质瘤;2)MRI表现不典型,如MRI上斑片状或大斑片状异常信号、增强不明显、无肿块效应、坏死,难以与脑炎鉴别的胶质瘤患者;3)脑炎经脑脊液(CSF)分析、抗体检测、病毒检查、手术或病理活检确诊,或病灶完全或大部分消失而确诊,或在随访期间转变为脑软化。此外,所有患者均进行FLAIR、CE-T1WI、T2WI三种常规MRI检查,检查前未做过脑活检或脑治疗,所有MRI图像均由配备八通道头圈的GE 3.0 T扫描仪(美国通用电气医疗系统公司)获得。所有164例的MRI图像均由两位神经放射学家独立审阅,从患者的3个序列中筛选出含有病灶的切片,经过筛选后的每一个序列的数据数量,如表1所示。

表 1 数据的获取情况

Table 1 Data acquisition results

序列	脑炎(118 人)	脑肿瘤(57 人)
FLAIR(切片数量)	636	408
CE-T1WI(切片数量)	798	763
T2WI(切片数量)	745	402

针对患者的 3 个不同 MRI 序列,本文分别从原始的 MRI 扫描文件中提取出患者对应的每一层切片,保存为图片格式,以便于后续处理的存储和读取。由于大部分图片中存在冗余信息,如时间信息等,本文对原始的图片进行必要裁剪,去除噪声,使图片基本只保留颅内脑实质




图 1 数据预处理流程

Fig. 1 Workflow of data preprocessing

1.2 卷积层参数迁移

本文采用卷积层参数迁移的方法提取特征,不同于人工设计特征需要仔细考虑采用的特征种类和数量。本文首先使用大规模的自然图像 ImageNet 对模型进行预

训练,使得模型具有较强的特征提取能力,随后进行模型卷积层迁移,去除模型原始的全连接层,根据卷积层提取得到的特征大小以及脑炎和胶质瘤的分类任务,重新设计新的分类器(图 2)。




图 2 卷积层迁移方法

Fig. 2 Convolutional layer transfer method

本文尝试了不同的全连接层的层数和节点数量,实验结果得到最佳性能的全连接层数为 2,对应节点数量分别为 512 和 256。输出层使用 sigmoid 激活函数直接输出预测的概率,原始 3 个模型信息如表 2 所示。

1.3 主动标注策略

理论上,随着训练数据的增加,模型学习到的特征相

表 2 三种深度学习模型的对比

Table 2 Comparison of three deep learning models

模型	年份	参数量(万)	top5 正确率(IISVRC)/%
Alexnet	2012	6 237.8	84.7
ResNet-50	2015	2 558.3	92.9
Inception-V3	2015	2 473.4	94.4

应增加,其性能应该一直上升,如图3(a)所示。然而在实际应用中,一开始随着训练集的增加,分类器的性能可以随着数据样本的增加而上升,当训练集的数量达到一个临界值后,性能基本不会再有提升,如图3(b)所示,此时如果再花费时间或者金钱进行更多的数据标注就没有意义了。主动学习就是使得这个临界值变小(图3(b)中虚线),即从样本池中选择出信息丰富、难以鉴别的样本进行标注,利用较少的数据使模型收敛更快。Wang等^[22]首次将主动学习应用到深度学习上,他们提出3个不确定性样本的采样策略,即边缘采样、最低置信度和熵;Zhou等^[23]将迁移学习和主动学习相结合,提出一个渐进式的训练策略,在3个不同的医学图像数据集上进行了实验,提出的方法能够至少减少一半的训练数据;Wang等^[24]也在深度学习任务中使用了主动学习的策略,将文献[22]提出的3个不确定性采样策略进行了融合,即将一个样本的熵、边缘采样和最低置信度进行综合考量,通过阈值衰减的方式进行样本采样,使用65%左右的样本就可以达到最优性能。

主动学习就是主动选择信息量大的样本,若当前分类器对于某样本的分类结果和真实的样本标签存在较大误差,说明此样本的特征信息对模型是有用的,则应该使用此样本对当前模型进行调整,重复进行测试和选择,则在一定阶段后,模型的性能能够达到最优。这些信息量大的样本使用“不确定性”进行量化,对于本文的二分类的问题,其预测概率越靠近0.5的样本,则其不确定性越

高,对于当前的模型来说其信息量越大。根据主动学习的思想,本文提出了基于熵不确定性样本主动标注策略(图4),每次从未标记样本中使用模型选出不确定样本,然后用人工标注的方法,得到他们的标签,加入到训练集中进行模型优化训练,重复迭代这一过程直到模型的性能达到收敛或者未标注数据中没有信息可用。本文使用熵作为不确定性样本选择策略,熵可以用来对样本的不确定性进行量化。本文使用预训练后的模型,对未标注样本进行预测,根据模型输出的概率计算出熵,选择出熵较大的那些样本,即信息量较大的样本。熵的计算如式(1)。

$$en_i = \sum_j p(y_i = j | x_i; w) \log p(y_i = x_i; w) \quad (1)$$

式中: en_i 代表第 i 个样本的熵; y_i 代表样本 i 的标签; x_i 代表第 i 个样本; w 为模型的权重参数; p 为使用当前的模型预测得到 x_i 的属于第 j 类样本的概率。本文 j 的取值为0和1,分别代表脑炎和胶质瘤。初始时以病人为单位随机从未标注样本集合 D^U 中选择一部分样本,使用临床诊断的正确结果或者随访证实进行正确标注,添加到 D^L 中来对模型进行参数 w 初始化。初始化结束后使用模型对所有未标注样本集合进行预测,得到每个样本的概率并利用式(1)计算出每个样本的熵。选择 K 个熵最大的样本进行人工标注然后加入到 D^L 中,迭代进行,直到未标注样本的熵低于某一个阈值 δ 或者未标注样本使用完毕。主动学习的算法如算法1。




图3 深度学习模型性能变化情况

Fig. 3 Performance changes of deep learning model

算法1 基于熵的主动学习算法

Algorithm 1 Entropy-based active learning algorithm

输入: 未标记样本集合 D^U , 初始的已标记样本集合 D^L , 不确定性样本的选择大小 K , 模型预测的最小熵阈值 δ 。
输出: CNN 模型的参数 w

- 1: 使用对 CNN 模型的参数 w 进行初始化
- 2: While 未达到最小熵阈值 δ 或者未达到最优性能 do
- 3: 使用 CNN 模型对未标记样本集合 D^U 中每一个样本进行预测, 得到其概率, 然后基于式(1)计算出每一个未标记样本的熵, 选择出 K 个熵最大的样本
- 4: 根据临床的诊断结果等, 用人工标记的方法对这 K 个样本进行标记, 标记完成后加入 D^L 到中
- 5: 使用新的已标记样本集合 D^L 对 CNN 模型的参数进行微调, 得到更新的参数 w
- 6: end while
- 7: return w




图 4 样本主动标注流程
Fig. 4 Workflow of sample active annotation

2 实验和结果

2.1 实验和评估

本文基于 python 和 Keras 深度学习库编写了数据预处理、模型建立、训练和分类的代码,运行环境为操作系统 ubuntu 16. 04,处理器 Intel Xeon E5 2 687 W V3, 显卡 NVIDIA GeForce GTX 1080ti,内存 16×8 GB。设定所有实验的超参数相同: Epoch 为 50; Batch 大小为 32; 使用 Adam^[25] 优化器; 初始的学习率为 0. 001, 在每一次更新参数后设定学习率下降为上一次的 0. 9。

在主动学习的实验中,本文设定初始已标记样本集合大小为 400, $K=50$, 最小熵阈值为 0. 3, 当计算得到的样本熵小于 0. 3 时,说明未标注样本中的特征信息基本提取完成。本文还进行了随机的从未标注样本集合选择 K 个样本进行标注,然后加入到已标注样本集合中,与主动样本标注形成对比实验。

如表 1 所示,由于数据样本存在不平衡的问题,为了减少误差,本文使用了 5 折交叉验证的方法来评估模型的分类性能,实验最终的结果是在 5 折交叉验证下取得的平均值。使用假正率(false positive rate, FPR)和真正率(true positive rate, TPR)计算出受试者工作特征曲线(receiver operating characteristic, ROC),ROC 代表了分类器的分类能力。F1 值兼顾了精准率(precision)和召回率(Recall)。此外,曲线下面积(area under the curve, AUC)和准确率(accuracy, ACC)也用来对模型进行了分类性能的评估。

2.2 结果

表 3~5 是分别使用 FLAIR、CE-T1WI 以及 T2WI 三个序列在 3 个模型上进行卷积层参数迁移训练的分类性能评估结果。从表 3~5 可以看出,使用 CE-T1WI 序列,

在 Inception-v3 模型上的鉴别分类性能最好,正确率能够达到 95. 08%,曲线下面积为 0. 97, F1 值为 95. 08%。表 6 是两个有经验放射科医生的分类结果和 3 个模型的平均正确率、平均 AUC 和平均 F1 值对比,可以看出,相对于依靠医生自身经验进行分类鉴别,采用本文方法的 3 个模型分类性能都要更优,模型的平均准确率分别高出人工分类平均准确率 6. 62%、12. 23%、12. 52%。

表 3 模型在 FLAIR 序列上的分类结果

Table 3 Classification results on FLAIR sequences			
模型	Acc/%	AUC	F1 值/%
Alexnet	78. 53	0. 86	78. 43
Resnet-50	82. 3	0. 94	86. 22
Inception-v3	84. 64	0. 91	84. 81

表 4 模型在 CE-T1WI 序列上的分类结果

Table 4 Classification results on CE-T1WI sequences			
模型	Acc/%	AUC	F1 值/%
Alexnet	92. 82	0. 95	92. 83
Resnet-50	94. 12	0. 97	94. 23
Inception-v3	95. 08	0. 98	95. 08

表 5 模型在 T2WI 序列上的分类结果

Table 5 Classification results on T2WI sequences			
模型	Acc/%	AUC	F1 值/%
Alexnet	81. 22	0. 89	81. 23
Resnet-50	89. 75	0. 95	89. 82
Inception-v3	89. 67	0. 95	89. 80

表 6 人工分类结果和模型分类结果对比

Table 6 Comparison of artificial and proposed method classification results			
方法	Acc/%	AUC	F1 值/%
reader1	81. 82	0. 89	73. 22
reader2	73. 33	0. 77	60. 72
Alexnet	84. 19	0. 90	84. 13
Inception-v3	89. 80	0. 95	89. 86
Resnet-50	90. 09	0. 95	90. 06

图 5 所示为每个模型在每个序列上进行评估得到的受试者工作特征曲线和对应的曲线下面积。图 6~8 所示为 3 个不同模型和两位有经验的医生的分类结果,可以看出使用本文提出的方法,性能最差的 Alexnet 网络模型的性能优于人工鉴别。




图 5 三个模型在不同 MRI 模态序列上的分类 ROC 曲线

Fig. 5 ROC curves of the three models on different MRI modal sequences




图 6 Alexnet 模型和人工分类的 ROC 曲线对比

Fig. 6 Comparison of ROC curve between Alexnet and manual classification

此外,本文将提出的方法同现有的相关工作的方法进行了对比,使用[9-12]中的方法在本文的数据集上进行实验,结果如表 7 所示。根据迁移学习的实验结果,本文选择了平均性能较优的 ResNet-50 模型,分别在 3 个不同序列上进行主动学习实验。实验的结果如图 9~11 所示。从图 9~11 可以看出,使用本文提出的主动学习算法,相对于随机选择样本进行标注,模型的分类正确率能够更快的收敛。使用 FLAIR 序列进行 6 次迭代训练就可以达到使用全部未标记样本的性能,此时主动学习比随机选择样本的精度高 7.76%;使用 CE-T1WI 序列时,进行 8 次迭代就可以达到最优性能,此时主动学习的准确率较随机选择样本高 6.94%;使用 T2WI 序列进行实验,进行 9 次迭代基本达到了最优性能,此时主动学习算法的性能高于随机选择样本 10.53%。在主动学习实验中,




图 7 ResNet-50 模型和人工分类的 ROC 曲线对比

Fig. 7 Comparison of ROC curve between ResNet50 and manual classification




图 8 Inception-V3 模型和人工分类的 ROC 曲线对比

Fig. 8 Comparison of ROC curve between Inception-V3 and manual classification

使用全部样本进行训练的样本数量平均为 2 600 张图像。在主动标注算法中,用每次添加 K 个样本的方式来模拟专家对医学图像的标注工作。平均添加 8 次样本后的训练集数量为 800 张,此时模型的分类准确度已经完全收敛,平均减少大约 70%标注工作。

表 7 现有方法和提出方法的分类结果

Table 7 Classification results of existing methods and proposed methods

工作	方法	Acc/%	AUC	F1 值/%
文献[9]	CNN	84.79	0.90	84.33
文献[10]	CNN	82.39	0.88	81.86
文献[11]	CapsNet ^[26]	85.56	0.91	85.5
文献[12]	CNN-F ^[27]	83.41	0.89	82.63
本文	Inception-v3	95.08	0.98	95.05




图 9 FLAIR 序列主动学习实验结果

Fig. 9 Active learning experimental results of FLAIR sequence




图 10 CE-T1WI 序列主动学习实验结果

Fig. 10 Active learning experimental results of CE-T1WI sequence




图 11 T2WI 序列主动学习实验结果

Fig. 11 Active learning experimental results of T2WI sequence

3 结 论

针对临床诊断上脑炎和胶质瘤难以鉴别的问题,本文提出了使用 3 种常规 MRI 检查图像序列,结合卷积层参数迁移的方法,来对胶质瘤和脑炎进行鉴别。为了解决样本稀少的问题,本文首先使用卷积特征迁移的方法,来对两种颅内病变进行区分。对 3 个深度学习模型进行

了结构上的改进,分别在患者的 3 个常规 MRI 序列上进行了实验,模型的准确率分别达到 84.19%、89.80% 和 90.09%,对应的 AUC 为 0.90、0.95 和 0.95。使用 Inception-V3^[24]模型在 CE-T1WI 序列上达到最佳分类性能,准确率为 95.05%,AUC 为 0.98。其次,根据主动学习设计了基于熵的样本主动标注算法,减少了数据的标注工作,使用更少的标注数据使模型更快的收敛。实验结果表明,能够减少约 70% 的样本标注工作,能够节省大量的标注工作时间,极大的提高模型收敛速度,能够为临床诊断提供有意义的指导。

本文研究了 3 个常规 MRI 序列图像的特征区分能力,不同的模态特征的区分鉴别效果差异较大,如何综合利用不同模态的特征信息,是一个重要的研究方向。在下一步的工作中可以分别使用 CNN 模型对 3 个 MRI 序列图像进行特征提取,然后进行特征融合,最后利用融合特征进行分类的方式,综合利用不同 MRI 提供的特征信息来提高模型的区分鉴别能力。

参考文献

- [1] 冯绵烨,姜燕. 病毒性脑炎的诊治研究进展 [J]. 中华诊断学电子杂志, 2019, 7(1): 66-70.
FENG M Y, LOU Y. Progress in diagnosis and treatment of viral encephalitis [J]. Chinese Journal of Diagnostics (Electronic Edition), 2019, 7(1): 66-70.
- [2] 杨学军,江涛. 脑胶质瘤临床诊断与治疗: 积于跬步蓄势超越 [J]. 中国现代神经疾病杂志, 2019, 19(11): 801-806.
YANG X J, JIANG T. Clinical diagnosis and treatment of glioma: Accumulation of small steps to exceed [J]. Chinese Journal of Contemporary Neurology and Neurosurgery, 2019, 19(11): 801-806.
- [3] 王钧. 脑低级别胶质瘤与病毒性脑炎的诊断及鉴别诊断 [J]. 现代医用影像学, 2019, 28(11): 2394-2396.
WANG J. Diagnosis and differential diagnosis of low grade glioma and viral encephalitis [J]. Modern Medical Imageology, 2019, 28(11): 2394-2396.
- [4] LECUN Y, BENGIO Y, HINTON G. Deep learning [J]. Nature, 2015, 521(7553): 436-444.
- [5] KRIZHEVSKY A, SUTSKEVER I, HINTON G. ImageNet classification with deep convolutional neural networks [C]. Proceedings of the 25th International Conference on Neural Information Processing Systems, 2012: 1097-1105.
- [6] 林桢哲,王桂棠,陈建强,等. 基于残差网络深度学习的肺部 CT 图像结节良恶性分类模型 [J]. 仪器仪表学报, 2020, 41(3): 250-258.

- LIN ZH ZH, WANG G T, CHEN J Q, et al. A benign and malignant classification model of pulmonary nodules in CT images based on residual network deep learning [J]. Chinese Journal of Scientific Instrument, 2020, 41(3): 250-258.
- [7] 章黎明, 贾智伟, 谢俊力, 等. 近四年胶囊内镜图像病灶的深度学习识别研究进展[J]. 电子测量与仪器学报, 2019, 33(08): 75-83.
- ZHANG L M, JIA ZH W, XIE J L, et al. Research progress of deep learning recognition of lesions in capsule endoscopic images in the past four years[J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(8): 75-83.
- [8] SHEN D, WU G, SUK H I. Deep learning in medical image analysis [J]. Annual Review of Biomedical Engineering, 2017, 19: 221-248.
- [9] DIAMANT A, CHATTERJEE A, VALLIÈRES M, et al. Deep learning in head & neck cancer outcome prediction [J]. Scientific Reports, 2019, 9(1): 2764.
- [10] KIRYU S, YASAKA K, AKAI H, et al. Deep learning to differentiate parkinsonian disorders separately using single midsagittal MR imaging: a proof of concept study [J]. European Radiology, 2019, 29: 6891-6899.
- [11] AFSHAR P, PLATANIOTIS K, MOHAMMADI A. Capsule networks for brain tumor classification based on MRI images and course tumor boundaries [C]. Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing, 2019: 1368-1372.
- [12] LIU R H, HALL L O, GOLDFELD D B, et al. Exploring deep features from brain tumor magnetic resonance images via transfer learning [C]. Proceedings of the 2016 International Joint Conference on Neural Networks, 2016: 235-242.
- [13] DENG J, DONG W, SOCHER R, et al. ImageNet: A large-scale hierarchical image database [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2009: 248-255.
- [14] DENIZ E, ABDULKADIR E, KADIROLU Z, et al. Transfer learning based histopathologic image classification for breast cancer detection [J]. Health Information ENCE and Systems, 2018, 6(1): 1-7.
- [15] TALO M, BALOGLU U B, YILDIRIM O, et al. Application of deep transfer learning for automated brain abnormality classification using MR images [J]. Cognitive Systems Research, 2019, 54: 176-188.
- [16] XU Y, JIA Z P, WANG L B, et al. Large scale tissue histopathology image classification, segmentation, and visualization via deep convolutional activation features [J]. Bioinformatics, 2017, 18(1): 281.
- [17] YANG Y, YAN L F, ZHANG X, et al. Glioma grading on conventional MR images: A deep learning study with transfer learning [J]. Frontiers in Neuroscience, 2018(12): 163-175.
- [18] SZEGEDY C, LIU W, JIA Y Q, et al. Going deeper with convolutions [C]. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2015: 1-9.
- [19] DEEPAK S, AMEER P M. Brain tumor classification using deep CNN features via transfer learning [J]. Computers in Biology and Medicine, 2019, 111: 103345.
- [20] HE K M, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [21] SZEGEDY C, VANHOUCKE V, IOFFE S, et al. Rethinking the inception architecture for computer vision [C]. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016: 2818-2826.
- [22] WANG D, SHANG Y. A new active labeling method for deep learning [C]. Proceedings of the International Joint Conference on Neural Networks, 2014: 112-119.
- [23] ZHOU Z W, SHIN J, ZHANG L, et al. Fine-tuning convolutional neural networks for biomedical image analysis: Actively and incrementally [C]. Proceedings 30th IEEE Conference on Computer Vision and Pattern Recognition, 2017: 4761-4772.
- [24] WANG K, ZHANG D, LI Y, et al. Cost-effective active learning for deep image classification [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2017, 27(12): 2591-2600.
- [25] KINGMA D, BA J. Adam: A method for stochastic optimization [C]. Proceedings of the 3rd International Conference on Learning Representations, 2015.
- [26] SABOUR S, FROSST N, HINTON G E. Dynamic routing between capsules [C]. Advances in Neural Information Processing Systems, 2017: 3856-3866.
- [27] CHATFIELD K, SIMONYAN K, VEDALDI A, et al.

Return of the devil in the details: Delving deep into convolutional nets [C]. BMVC, 2014.

作者简介



李杰文, 2018 年于武汉理工大学获得学士学位, 现为重庆大学硕士研究生, 主要研究方向为医学图像、计算机视觉。

E-mail: 578257651@qq.com

Li Jiewen received his B. Sc. Degree from Wuhan University of Technology in 2018. Now he is a M. Sc. candidate at Chongqing University. His main research interests include image processing and computer vision.



E-mail: ygyocr@cqu.edu.cn

叶俊勇 (通信作者), 1995 年于重庆大学获得工学学士学位, 1998 年于重庆大学获得硕士学位, 2002 年于重庆大学获得博士学位, 现为重庆大学副教授, 主要研究方向为图像识别、信号处理、无损检测。

Ye Junyong (Corresponding author) received his B. Sc. degree in 1995 from Chongqing University, M. Sc. degree in 1998 from Chongqing University, and Ph. D. degree in 2002 from Chongqing University. Now he is an associate professor at Chongqing University. His main research interests include image recognition, signal processing and nondestructive testing.