

# 基于深度迁移学习的大鼠肝纤维化诊断<sup>①</sup>



余文林, 陈振洲, 范冰冰, 黄穗

(华南师范大学 计算机学院, 广州 510631)

通讯作者: 余文林, E-mail: linpianshang@qq.com

**摘要:** 针对肝纤维化临床诊断方法具有有创性和传统机器学习方法特征提取的不完全性的缺陷, 本文采用深度迁移学习方法利用预训练的 ResNet-18 和 VGGNet-11 模型用于肝纤维化分期诊断. 使用南方医科大学提供的大鼠肝纤维化核磁共振影像数据集进行不同程度的迁移训练. 将两种模型在通过 4 种不同参数采集的核磁共振影像数据集上, 分别使用 6 种网络迁移配置训练. 实验结果表明, 使用 T1RHO-FA 参数采集的核磁共振影像和采用 VGGNet-11 模型更能提高肝纤维化分期诊断的准确率. 同时相对于 ResNet-18 模型, 深度模型迁移学习方法能稳定提升 VGGNet-11 模型进行肝纤维化分期诊断的准确率和训练速度.

**关键词:** 肝纤维化; 深度学习; 迁移学习; 分期诊断

引用格式: 余文林, 陈振洲, 范冰冰, 黄穗. 基于深度迁移学习的大鼠肝纤维化诊断. 计算机系统应用, 2019, 28(5): 18-27. <http://www.c-s-a.org.cn/1003-3254/6904.html>

## Diagnosis of Rat Liver Fibrosis Based on Deep Transfer Learning

YU Wen-Lin, CHEN Zhen-Zhou, FAN Bing-Bing, HUANG Sui

(School of Computer Science, South China Normal University, Guangzhou 510631, China)

**Abstract:** In view of the incompleteness of the clinical diagnosis method of liver fibrosis and the incompleteness of the feature extraction of traditional machine learning methods, by the deep transfer learning method, this study uses the pre-trained ResNet-18 and VGGNet-11 models for the diagnosis of liver fibrosis. Different degrees of transfer training were performed using the rat liver fibrosis nuclear magnetic resonance image dataset provided by Southern Medical University. The two models were trained using six network migration configurations on the MRI image datasets collected by four different parameters. The experimental results show that the use of T1RHO-FA parameters to acquire nuclear magnetic resonance images and the use of VGGNet-11 model can improve the accuracy of liver fibrosis staging diagnosis. At the same time, compared with the ResNet-18 model, the deep model migration learning method can stably improve the accuracy and training speed of the VGGNet-11 model for liver fibrosis staging diagnosis.

**Key words:** liver fibrosis; deep learning; transfer learning; staging diagnosis

## 1 引言

### 1.1 研究背景

肝纤维化 (Hepatic Fibrosis, HF) 是许多慢性肝脏疾病的常见表现, 是指由各种病因导致的肝脏损伤而进行的组织修复, 最终导致合成大量的胶原和蛋白多糖

等细胞外基质 (Extra Cellular Matrix, ECM) 过度沉积的病理过程.

有研究表明, 早期轻度肝纤维化是可以治愈, 并且肝纤维化 S2 期及以上具有明确的治疗指征, 这也是肝纤维化进展的标志<sup>[1]</sup>. 肝纤维化持续发展将会引发肝硬

<sup>①</sup> 收稿时间: 2018-11-30; 修改时间: 2018-12-18; 采用时间: 2018-12-26; csa 在线出版时间: 2019-05-01

化,甚至是引发肝细胞癌<sup>[2,3]</sup>.因此早期诊断肝纤维化并且区分肝纤维化分期及炎症活动度将会对临床治疗方案的选择提供重要依据及帮助<sup>[4]</sup>.

医学成像技术因其具有无创性和能直观检测体内器官的特性,现已广泛的被用于临床医学当中.用于评估肝纤维化的医学影像主要包括核磁共振成像(Magnetic Resonance Imaging, MRI)、超声弹性成像、计算机断层成像(Computed Tomography CT).相对于其他医学成像技术来说,磁共振成像可以生成多种多参数的高清软组织图像,包括弥散加权成像(Diffusion Weighted Imaging, DWI)、T1-weighted MRI、T2-weighted MRI等.在本实验中根据医生的建议采用了T1-weighted(T1)、T2-weighted TSE(T2)、T1RHO-FA(FA)、T1RHO-HS(HS)这4种MRI图像.

## 1.2 研究现状

目前国内外对肝纤维化的诊断方法主要分为有创性诊断和无创性诊断.其中有创性诊断主要是对肝脏进行肝活组织病理学检查,并将其检测结果作为肝纤维化分期阶段的“金标准”.然而这种诊断方法具有成本太高、有创性、有几率导致并发症等的弊端<sup>[5]</sup>;而非创性诊断技术有临床评估、诊断预测模型、血清标志物、医学成像等.医学成像技术凭借其相对无创性和可以对肝纤维化直观评估的特点,在临床应用中发挥了关键的作用.

传统基于医学图像对肝纤维化程度诊断的方法主要是先对图像进行人工特征提取和特征筛选,然后再通过传统机器学习的方法训练分类器进行肝纤维化分期分类<sup>[6,7]</sup>.虽然传统方法依旧取得了一定的效果但是由于得到的特征是基于人工提取的,效率不高而且覆盖的图像信息不全面.针对这些局限性,深度学习凭借其可以自动获取原始图像的一系列特征的特性,为医学图像研究提供了新方向<sup>[8,9]</sup>.Sarraf等人<sup>[10]</sup>通过对正常大脑和阿尔茨海默患者大脑的磁共振图像的训练获得了准确率达96.85%的LeNet模型.Marios等人<sup>[11]</sup>基于肺部的高清CT图像训练,实验模型最高分类准确率达到85.61%.在肝纤维化方面,孟丹等人<sup>[12]</sup>先利用在ImageNet上预训练的VGGNet网络提取感兴趣区域肝脏区域超声波特征,然后再将特征输入到他们提出的FCNet中,进行对肝纤维化正常、早期肝纤维化(S1-S3)和晚期肝纤维化(S4)三种阶段的判断,取得了超过80%的实验准确率.Wang等人<sup>[13]</sup>通过肝

纤维化患者的超声弹性成像图训练卷积神经网络取得了与肝脏穿刺活检诊断相当的效果.以上基于医学成像的肝纤维化诊断研究都是基于超声成像的且没有对肝纤维化分期做出具体的判断.相对于MRI来说超声成像具有图像分辨率较低的先天劣势,且采集可以诊断出肝纤维化分期的超声图像对采集人员有较高的医学专业要求且图像质量容易受操作者的经验影响.因此采集到的超声图像已经具有高度诊断辨识度.然而本实验采用分辨率较高和采集稳定的MRI图像作为肝纤维化诊断依据,同时也针对MRI图像特点和目标需求,优化设计了集成自动提取特征和对肝纤维化各分期诊断的综合模型.

## 2 深度迁移学习

### 2.1 深度学习

深度学习是由Geoffrey Hinton研究组在2006年提出的一个机器学习领域的新分支<sup>[14]</sup>.它通过构建具有多层的非线性模型来进行数据处理.深度学习能利用多层的特性自底层向高层逐步的学习自动提取特征,摒弃了人工特征提取所带来的先验性和不全面性的缺陷.近年来,深度学习在图像识别、自然语言处理、计算机视觉方面都举得了优秀成绩.其基本的网络层次如图1所示.

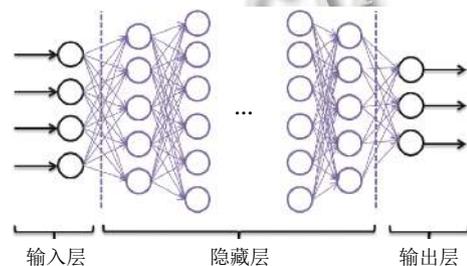


图1 深度网络的层次结构

除了基本的全连接层之外,常见的深度神经网络层还有:卷积层,池化层,批标准化层,随机失活层,激活层等.

自1962年Hubel和Wiesel在研究猫脑皮层中用于局部敏感和方向选择的神经元提出感受野(receptive field)概念后<sup>[15]</sup>,继而有人提出含有卷积层的卷积神经网络(CNN).而LeCun最早将CNN应用于手写数字识别并取得了突破性成绩<sup>[16]</sup>.

卷积神经网络利用了图像主体的平移不变性和像

素与近距离的像素之间的联系大于远距离像素的特性,采用不同的卷积核对图像进行卷积运算得到不同的特征图,在计算特征图时通过权值共享大大减少了深度神经网络的参数数量(图2)。

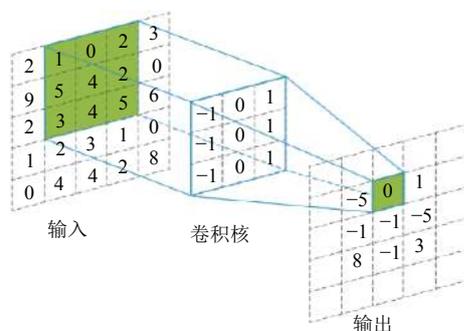


图2 卷积的工作方式

池化层是根据特征选择的区域按照池化方式提取出特征,同时能缩小特征图,减少模型的计算量,常用的池化方法有最大池化,最小池化,和平均池化.在本文实验中采用的均为最大池化.

深度模型在训练时,由于模型层次太深或采用了不适当的激活函数会导致模型梯度消失的问题.针对这一问题,2015年Google提出了批标准化(Batch Normalization)<sup>[17]</sup>.批标准化将输入的批次中的每一个feature map进行标准化操作,使数据满足标准正太分布.这样降低了数据的冗余性和特征的相关性,使得模型的梯度传导的更深缓解了梯度消失的问题.

随机失活(Dropout)层<sup>[18]</sup>是一种针对模型训练过程中出现的过拟合问题所提出的.它是在模型的训练中按照一定的概率,随机地选择上层的输出神经元而使其在本次的训练过程中处于失活的状态.当有多个随机失活层作用时,每次训练的过程中实际训练的模型都不同.这样大大的提高了模型的多样性,也让模型过度拟合训练数据变得困难.

如果不添加激活层,每一层的输出都是上层输入的线性函数,这样无论网络有多少层,输出都是输入的线性组合,无法拟合非线性函数.激活层将非线性特征引入到了网络中,使网络可以逼近任意非线性函数,让神经网络可以处理众多非线性问题.激活层中常用的激活函数有Sigmoid、Tanh、ReLU等.

## 2.2 迁移学习

迁移学习(transfer learning)是将在源域(source

domain)中学习到的知识应用于在目标域(target domain)知识学习中的一种学习方法<sup>[19]</sup>.通常源域和目标域的数据和任务都不相同,且目标域的数据获取成本较大导致已有数据不足以训练出可靠模型.迁移学习通过迁移在源域学习的知识去提升针对目标域任务建立的模型的效果(图3)。

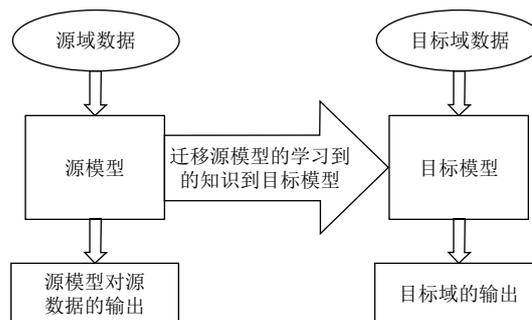


图3 迁移学习

迁移学习按照学习方式可以分为基于样本的迁移、基于特征的迁移、基于模型的迁移和基于关系的迁移.由于医学影像数据的难获取或者获取的成本较高的特性,迁移学习提供了一个恰当的途径.同时有研究表明在训练好的深度模型中,各层次学习到的知识不同,低层学习到的是偏向通用性的知识,如图的边缘、拐角等.而高层学到的是与学习任务相关的特征,如在人脸识别任务中,模型的高层学习到的就有如何识别眼睛和嘴巴等知识.在实现模型迁移时,可以通过固定不同数量的低层参数来实现不同程度的模型迁移.

本文中实践验证了,通过迁移在ImageNet数据集上训练的VGGNet-11模型可以提升肝纤维化期数诊断模型的特征抽取能力和稳定性.

## 3 基于深度迁移学习的大鼠肝纤维化诊断

本文采用深度模型迁移学习方法,将ResNet-18和VGGNet-11作为基本参照模型.基于参照模型针对MRI图像的特点进行优化,然后对所有模型训练大鼠肝纤维化MRI图像,使模型自动提取图像特征和对肝纤维化期数诊断.对数据集,本文采用了基于随机的镜像和旋转的数据增强策略来提升模型的泛化性能和鲁棒性.同时在实验中,对两种对比模型都采用了迁移学习方法和不使用迁移学习方法分别训练.在使用迁移学习方法训练时,对模型都进行了不同程度的模型迁移对比实验.

### 3.1 数据集和数据增强

#### 3.1.1 数据集

本实验数据由南方医科大学提供. 采用实验大白鼠共计 95 只, 其中每只白鼠分别采用 T1、T2、T1RHO FA 和 T1RHO HS 磁共振参数对其肝脏的不同部位进行核磁共振影像采集. 然后将采集到的原始影像通过 RadiAntDICOMViewer 软件转换成 PNG 格式作为我们的数据集. 数据集的中 4 种不同参数的核磁共振影像图数量如表 1 所示.

表 1 数据集的采集情况

磁共振参数	T1	T2	FA	HS	总计
单只采集数	13	13	25	15	66
总样本数	1235	1235	2375	1425	6270

在实验过程中, 由于对同一只大鼠的不同肝脏切片采用了相同的采集参数, 因此它们有一定的相似性. 为防止相似性对模型的结果评定有影响, 在实验中都先以白鼠为单位随机分为 7:3 的比例. 然后将所有由同一只白鼠获取到的影像全部作为训练集数据或者测试集数据. 具体影像图见图 4.

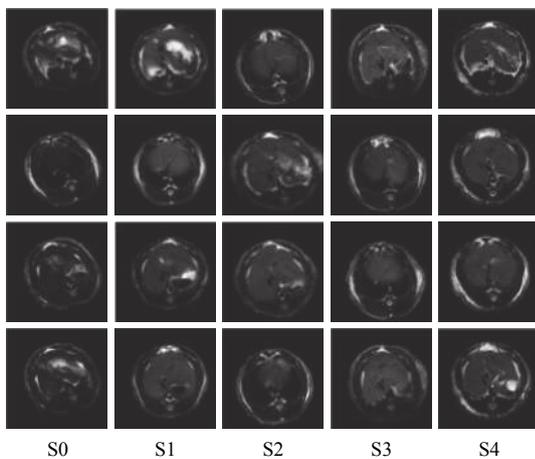


图 4 从 S0 到 S4 期大鼠肝纤维化 T2 核磁共振影像图

#### 3.1.2 数据增强

由于神经网络模型需要海量的数据来进行学习, 而我们数据集中的数据量远不及海量的要求. 所以在实验时需要对数据集进行适当的数据增强方法来扩充数据量, 这样训练出的模型具有更高的鲁棒性也不容易过拟合. 本实验采用的数据增强方法有以下两种:

1) 图像翻转: 图像翻转分为水平翻转和垂直翻转. 这是一种常规的数据增强方法. 在图像进行翻转后仍

然不影响图像表达的语义时, 我们应尽量采用这种图像增强方法. 在本实验中对图像进行水平翻转不会影响肝纤维化的诊断. 所以图像在训练前都会随机的进行水平翻转.

2) 图像旋转: 图像旋转也是一种常规的数据增强方法. 这是将图像按照中心点进行旋转的方法. 但是过量的旋转会改变图像的语义表达, 如在文字识别中, 过量的旋转会让图像产生歧义或者不能识别. 考虑到本数据集在获取数据的时候就存在一定的角度差别, 在实验中, 数据在训练前都会随机的在 -12 度到 12 度之间进行旋转.

同时采用随机水平翻转和随机旋转图像可以让同一张图像在输入到网络时都会有不同的差异, 这让模型不容易陷入过拟合而记住单一图像的特点. 同时在网络遇到新的图像时, 能提升图像的准确性. 为了防止数据增强所带来的影响, 在测试的过程中, 所有的数据增强策略都未使用. 这样保证的模型对目标数据预测结果的准确性. 图像对比结果如图 5 所示.

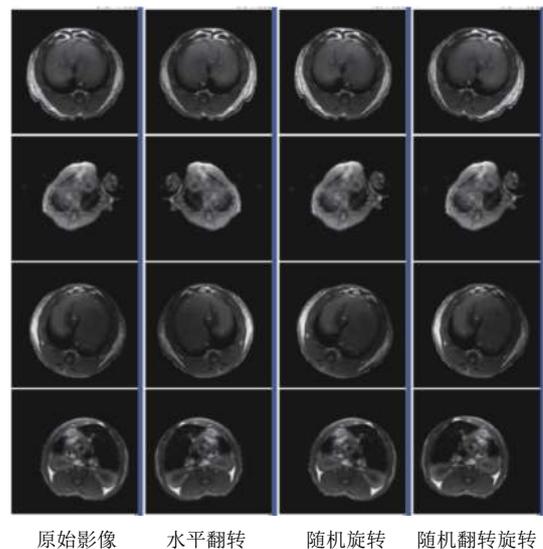


图 5 原始图像和数据增强后的图像

### 3.2 ResNet-18 和 VGGNet-11 神经网络

ResNet 的全名是 Residual Network, 又称为残差网络<sup>[20]</sup>. 通过在添加低层与高层之间的直通的残差块的设计, 在使用梯度优化类方法训练网络的时候这种残差块设计能让梯度传导到更深的层次, 因此能训练出层次更深的模型. 在 2015 年的各大图像算法比赛中, ResNet 在保证网络精度的前提下, 将网络深度达到了 152 层,

并以绝对优势取得了多个冠军. ResNet 根据不同的数据规模有 ResNet-18、ResNet-34、ResNet-50、ResNet-101 和 ResNet-152 等版本, 后面的数字代表着该模型的最大深度. 本文的实验在数据规模和分类类

别数目上远不及比 ImageNet 比赛中的规模, 采用的模型是 ResNet-18 网络结构. 为了方便实现对模型的不同程度的迁移, 本文将每两个残差合并为一个逻辑层. 其网络结构图如图 6 所示.

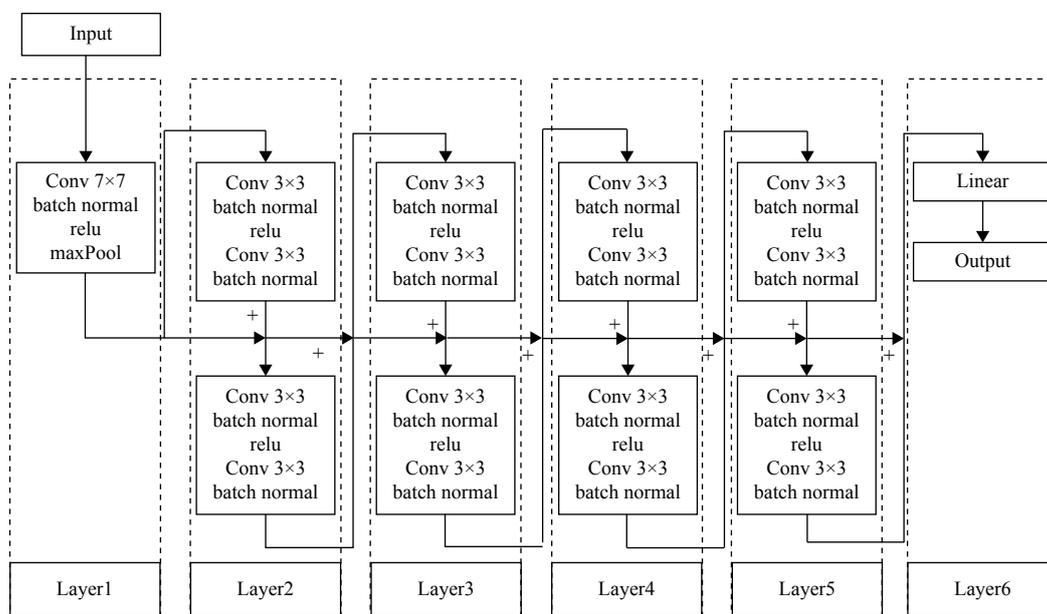


图 6 ResNet-18 网络结构

VGG 是参加 ILSVRC 2014 比赛时, 提交该网络的小组 Visual Geometry Group, Department of Engineering Science, University of Oxford 的缩写, 故该网络结构叫做 VGG 或者 VGGNet<sup>[21]</sup>. 该网络在当年的图像分类任务中获得第二名, 而第一名由 Google 提出的 GoogleNet 获得. VGGNet 也具有不同的层次版本.

主要有 VGG-11、VGG-13、VGG-16 和 VGG-19, 随着 Batch Normalization 的提出相继有了对应的添加 Batch Normalization 的版本. 在本文中所采用的对比网络模型为 VGG-11 的带 Batch Normalization 版本, 同样为了方便进行模型的部分迁移, 也进行了层次的合并, 其网络结构如图 7 所示.

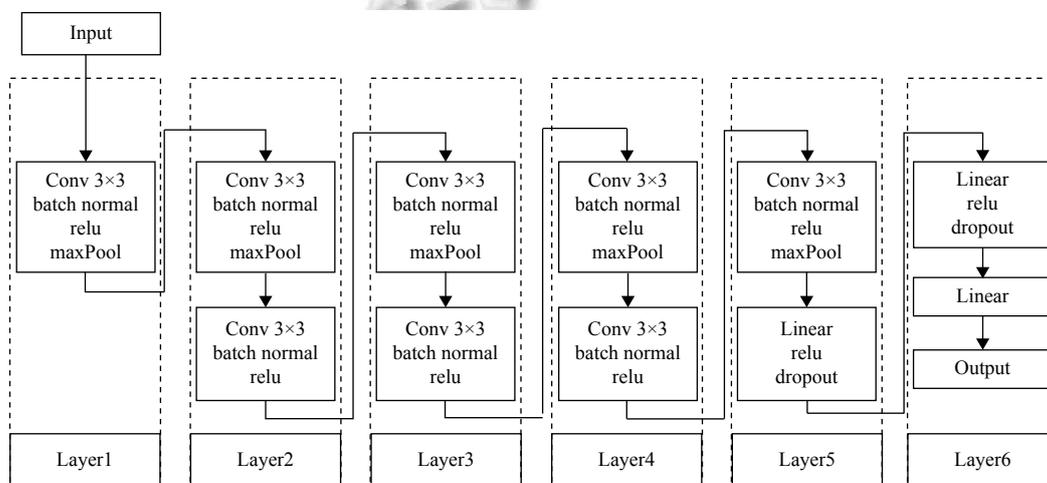


图 7 VGGNet-11 网络结构

本实验将原模型的最后线性层都由原输出类目数的 1000 调整为输出类目为 5 的线性层. 这样模型的 5 个输出就可以更好的表示模型对输入图像中肝纤维化程度的判断. 在实验过程中, 本文采用了批量训练的训练方法, 每次训练时都随机选择小批量数据进行训练. 把每张图像的原始所属于的分期和模型对图像判断所给的输出, 根据交叉熵 (Cross Entropy) 函数计算出模型对本张图像的输出和真实类别之间的差距损失, 然后根据批量数据的累加损失, 按照梯度反向传播法则依次调整模型中的所有未固定且可训练的参数.

## 4 实验和结果

### 4.1 实验结果

如图 6 和图 7 所示, 本文将 ResNet-18 和 VGG-11 都分成 6 个逻辑层. 分别在 T1, FA, HS 和 T2 每个数据集上进行了 6 次实验. 由未采用迁移学习训练和依次迁移模型低层参数并固定, 作为模型特征提取的一部分. 具体实验配置如表 2 所示.

实验均在, CPU Intel(R) Core(TM) i7-4790、GPU NVIDIA GeForce GTX 1080, 内存 DDR3 16 GB, Windows 10 专业版环境下, 使用 PyTorch 0.40 实现模型的构建和训练. 各组模型训练依次进行, 每次模型训练的 80 个周期共需 30 分钟左右, 训练结果如图 8 至

图 11 所示.

表 2 实验中模型的迁移设置

模型	配置名称	迁移并固定参数的层
ResNet-18	Res-lock0	未迁移
	Res-lock1	layer1
	Res-lock2	layer1、layer2
	Res-lock3	layer1、layer2、layer3
	Res-lock4	layer1、layer2、layer3、layer4
	Res-lock5	layer1、layer2、layer3、layer4、layer5
VGGNet-11	VGG-lock0	未迁移
	VGG-lock1	layer1
	VGG-lock2	layer1、layer2
	VGG-lock3	layer1、layer2、layer3
	VGG-lock4	layer1、layer2、layer3、layer4
	VGG-lock5	layer1、layer2、layer3、layer4、layer5

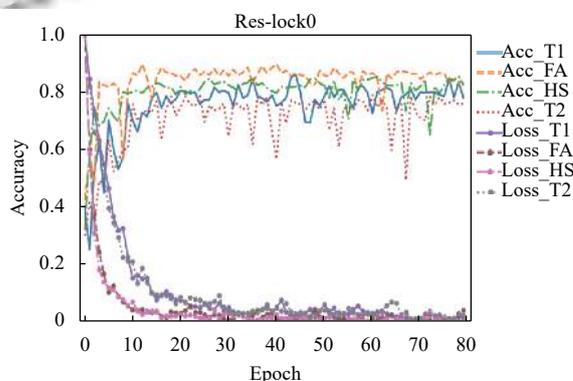


图 8 采用 RetNet-18 在各数据集上的模型准确

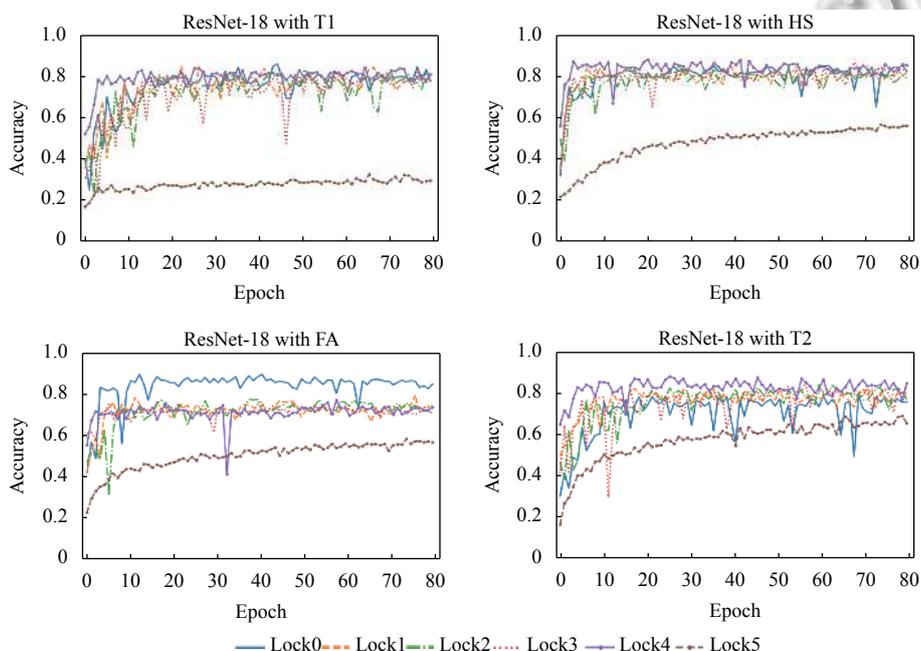


图 9 ResNet-18 在 4 种数据集下的训练过程

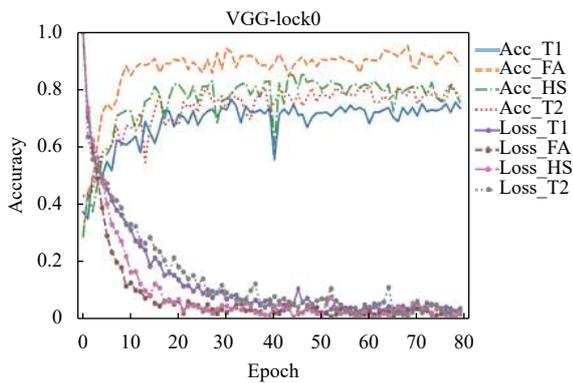


图10 VGG-lock0 在4种数据集上训练过程

4.1.1 ResNet-18 的实验结果

采用 Res-lock0 配置时, ResNet-18 在4种不同数据集上训练不同的模型, 平均在15个周期模型都能达到自己稳定后的平均准确率. 其中的采用 FA 数据训练的模型的平均准确率最高为 86.06%, 最高准确率为

89.79%; 其次是通过 HS 训练的模型, 平均准确率为 81.84% 最高准确率为 85.51%; 最低准确率的模型是采用 T2 数据训练, 其最高模型准确率为 79.04%, 平均准确率为 73.60%. 通过 FA 训练出模型的准确率具有最高的稳定性, 其准确率的方差为 5.09. 而通过 T1 和 HS 训练模型稳定后的准确率的方差为 10.04 和 10.69, 通过 T1 训练的模型最不稳定, 准确率方差为 32.47. 其训练结果如表3所示.

表3 ResNet-18 在 Res-lock0 网络设置下模型的结果

数据集	网络配置	准确率 (%)		准确率方差	首次达到平均准确率
		最高	平均		
T1	Res-lock0	86.20	78.93	10.04	15
T2	Res-lock0	79.04	73.60	32.47	10
FA	Res-lock0	<b>89.97</b>	<b>85.98</b>	<b>6.02</b>	<b>10</b>
HS	Res-lock0	85.51	81.85	10.53	14

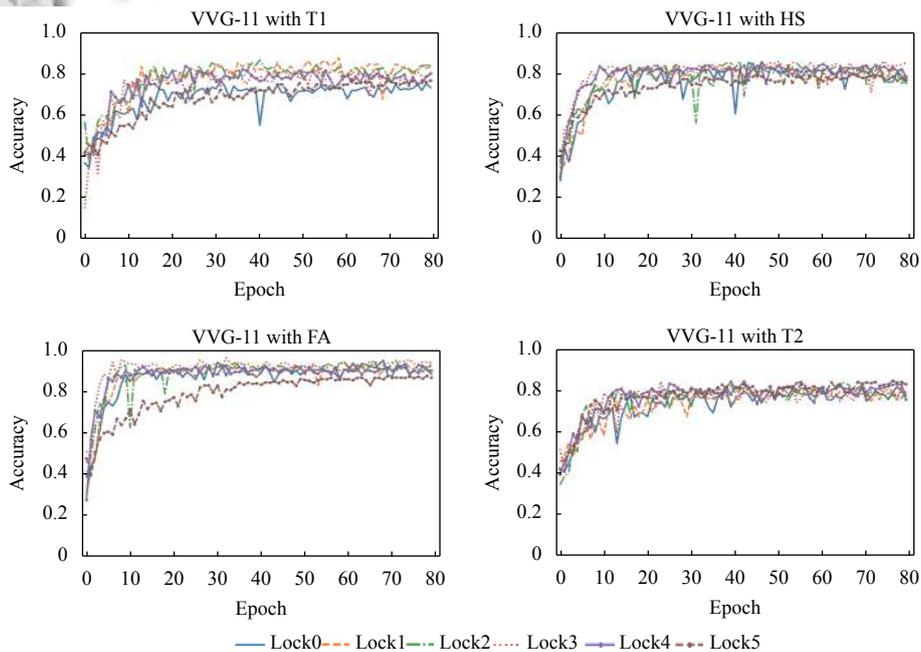


图11 VGG-11 在4种数据集下的训练过程

采用 FA 数据集训练时, 当使用 Res-lock1 至 Res-lock4 配置训练, 模型的最高准确率依次为 79.58%、77.93%、76.69% 和 77.24%. 采用模型迁移后, 模型平均在第7个周期就能达到模型的平均准确率, 训练速度提升了一倍. 然而模型的准确率却是不采用模型迁移时最优. 而当采用其他3种数据集训练时, 适量采用

模型迁移均能提升模型的训练速度和提升模型的准确率. 在采用 Res-lock4 配置的模型, 在3种数据集下模型效果都最优. 在4种数据集中, 采用 Res-lock5 配置训练的模型效果都明显低于其他配置的模型, 因为采用这种配置时, 模型的大部分参数都已固定, 模型的拟合能力大大下降不能拟合出能良好分类的模型, 因此

其效果与其他模型差距较大. 训练结果如表 4 所示.

表 4 ResNet-18 在 4 种数据集下的训练结果

数据集	网络配置	准确率 (%)		准确率方差	首次达到平均准确率
		最高	平均		
T1	Res-lock0	<b>86.20</b>	78.93	10.04	15
	Res-lock1	85.14	76.92	21.11	9
	Res-lock2	83.02	76.67	19.44	17
	Res-lock3	82.49	75.83	36.04	13
	Res-lock4	84.61	<b>80.64</b>	<b>4.69</b>	12
	Res-lock5	32.89	29.31	1.63	29
T2	Res-lock0	79.04	73.57	30.42	10
	Res-lock1	82.49	77.99	8.84	8
	Res-lock2	84.35	79.44	<b>6.91</b>	21
	Res-lock3	85.14	78.50	20.72	16
	Res-lock4	<b>88.32</b>	<b>83.52</b>	8.23	6
	Res-lock5	69.23	63.62	8.1	37
FA	Res-lock0	<b>89.97</b>	<b>85.98</b>	6.02	10
	Res-lock1	79.58	73.05	5.35	5
	Res-lock2	77.93	73.46	6.08	7
	Res-lock3	76.68	72.48	<b>4.93</b>	5
	Res-lock4	77.24	71.67	15.03	2
	Res-lock5	58.75	55.36	2.6	42
HS	Res-lock0	85.51	81.85	10.53	14
	Res-lock1	85.05	80.68	<b>3.77</b>	6
	Res-lock2	85.28	79.51	10.75	6
	Res-lock3	87.12	80.87	8.77	8
	Res-lock4	<b>88.27</b>	<b>84.11</b>	8.81	3
	Res-lock5	57.01	53.61	2.91	38

#### 4.1.2 VGG-11 的实验结果

采用 VGG-lock0 配置训练时, 在 4 种数据集上训练的模型平均在 15 周期达到模型稳定后的模型准确率. 在 FA 数据集上训练的模型准确率最高, 最高准确率为 95.31% 平均准确率为 90.11%, 其次是在 HS 上训练的模型最高模型准确率为 85.97%, 平均准确率为 79.63%. 在 T1 上训练的模型的准确率最低, 其最高模型准确率为 76.65%, 平均准确率为 71.87%. 在 FA 上训练的模型具有最高的模型稳定性, 其准确率方差为 4.94, 其次是 T1 数据集, 模型准确率方差为 8.34. 通过 HS 训练的模型准确率最差, 其模型准确率方差为 16.66, 是在 FA 上训练模型的 3.37 倍. 其训练结果见表 5.

表 5 VGG-lock0 在 4 种数据集上训练结果

数据集	网络配置	准确率 (%)		准确率方差	首次达到平均准确率
		最高	平均		
T1	VGG-lock0	76.65	71.87	8.34	17
T2	VGG-lock0	82.22	76.91	11.12	16
FA	VGG-lock0	<b>95.31</b>	<b>90.11</b>	<b>4.94</b>	<b>15</b>
HS	VGG-lock0	85.97	79.63	16.66	<b>15</b>

在 T1 数据集下, 采用 VGG-lock1 至 VGG-lock5 训练的模型的准确率均比未使用 VGG-lock0 配

置训练的模型的准确率都高. 其中在使用 VGG-lock1 配置时, 模型具有最高的平均准确率 81.52%, 较使用 VGG-lock0 时的平均准确率提升了 13.42%, 但其模型的稳定性不及使用 VGG-lock0 的模型. 在使用 VGG-lock4 时模型具有最高的稳定性, 其准确率的方差为 4.88 仅为使用 VGG-lock0 配置的 58.51%. 同时除了使用 VGG-lock5 配置时, 所有配置下的模型训练速度都不低于使用 VGG-lock0 的配置. 在 T2 数据集下, VGG-lock1 至 VGG-lock5 配置的模型准确率和模型稳定性都优于 VGG-lock0 配置下的模型, 但是各种配置下的模型结果之间的差别不大. 其中使用 VGG-lock5 配置下的模型具有最高的模型准确率 84.88%, 比不使用模型迁移时的最高准确率提升了 3.23%, 平均准确率也提升了 6.09%, 但是其模型需要 30 个周期才能达到平均准确率. 使用 FA 数据集训练时, 在使用 VGG-lock0 配置训练时能获得准确率高达 95.31% 的模型. 但是使用 VGG-lock3 配置能训练出准确率超过原来 1.3% 的模型. 在使用 HS 数据集训练时, 使用 VGG-lock3 配置训练的模型取得高的模型准确率和平均准确率. 同时训练速度最快比不使用模型迁移时提升了 40%. 其训练结果如表 6 所示.

表 6 VGG-11 在 4 种数据集下的训练过程

数据集	网络配置	准确率 (%)		准确率方差	首次达到平均准确率
		最高	平均		
T1	VGG-lock0	76.65	71.87	8.34	17
	VGG-lock1	<b>87.79</b>	<b>81.52</b>	11.56	13
	VGG-lock2	86.73	81.44	6.33	16
	VGG-lock3	83.28	78.59	6.47	17
	VGG-lock4	83.81	78.45	<b>4.88</b>	14
	VGG-lock5	77.45	73.17	8.36	24
T2	VGG-lock0	82.22	76.91	11.12	16
	VGG-lock1	82.75	78.00	6.46	24
	VGG-lock2	84.08	78.87	7.17	13
	VGG-lock3	84.61	78.20	11.06	<b>10</b>
	VGG-lock4	84.61	80.10	6.01	13
	VGG-lock5	<b>84.88</b>	<b>81.76</b>	<b>3.32</b>	30
FA	VGG-lock0	95.31	90.11	4.94	15
	VGG-lock1	94.62	90.85	3.19	17
	VGG-lock2	94.62	90.84	15.83	8
	VGG-lock3	<b>96.55</b>	<b>93.00</b>	2.49	<b>6</b>
	VGG-lock4	93.65	90.47	1.84	12
	VGG-lock5	87.72	85.68	<b>1.53</b>	35
HS	VGG-lock0	85.97	79.63	16.66	15
	VGG-lock1	84.59	80.26	6.18	12
	VGG-lock2	<b>86.20</b>	80.77	22.55	13
	VGG-lock3	<b>86.20</b>	<b>82.29</b>	8.13	9
	VGG-lock4	84.82	81.83	3.62	9
	VGG-lock5	80.22	77.53	<b>1.77</b>	28

## 4.2 结果分析

在没有使用模型迁移训练模型情况下,具有最多数据的FA数据集在两种模型下都获得了最高的模型准确率,但是VGG-11的效果优于ResNet-18.在使用模型迁移训练时,迁移训练对ResNet-18结果的影响不稳定.在FA数据集上,迁移训练的模型结果都不及未使用迁移的模型结果,在T2和HS模型下有模型的准确率提升.特别在使用Res-lock4时,模型的训练速度和模型的准确率在T1、T2和HS数据集下都优于其他配置.对于VGG-11,在4种数据集上使用迁移训练都能稳定地为模型带来准确率和训练速度的提升并且训练结果都优于ResNet-18.在ResNet-18和VGG-11使用Res-lock5和VGG-lock5配置时,模型的准确率和训练速度都远不及其他配置.因为过度的迁移,使模型剩下的可变参数大量减少,大大消减了模型的表达能力不能学到良好的模型.比较分析实验结果我们,可以得出结论使用T1RHO-FA核磁共振影像具有较其他3种影像就肝纤维化分期诊断具有更优的区分特征.同时在训练核磁共振影像时,VGG-11网络结构比ResNet-18具有高的模型准确率,并且在使用在ImageNet数据上训练的模型进行迁移时,能对结果有稳定的准确率和训练速度的提升.

## 5 结论

本实验优化了ResNet-18和VGG-11网络结构,使用了迁移和未迁移的训练方法对模型进行分组对比实验.对实验结果分析得出,T1RHO-FA参数的核磁共振影像相对于T1-weighted、T2-weighted TSE、和T1RHO-HS更适合用于深度模型的训练.同时相对于ResNet-18网络结构,VGG-11更适用于核磁共振成像数据集的训练,并且可以实用深度模型迁移提升模型的准确率和训练速度.对于今后医学图像分类模型的训练的网络结构设计和影像数据的选择提供了参考因素.对肝纤维化分期的诊断提供了无创和全自动的参考方案也为肝纤维化分期的诊断提供了研究意义.

### 参考文献

- 1 陆伦根,曾民德.肝纤维化的诊断和评估.中华肝脏病杂志,2005,13(8):603-604.[doi:10.3760/j.issn:1007-3418.2005.08.013]
- 2 Brenner DA. Reversibility of Liver Fibrosis. Gastroenterology

- & Hepatology, 2013, 9(11): 737-739.
- 3 Lee YA, Wallace MC, Friedman SL. Pathobiology of liver fibrosis: A translational success story. Gut, 2015, 64(5): 830-841. [doi: 10.1136/gutjnl-2014-306842]
- 4 夏璐,杨长青.肝纤维化治疗的研究进展.中华肝脏病杂志,2017,25(8):566-570.[doi:10.3760/cma.j.issn.1007-3418.2017.08.003]
- 5 Sattar A, Khan AM, Anjum S, et al. Role of ultrasound guided fine needle aspiration cytology in diagnosis of space occupying lesions of liver. Journal of Ayub Medical College, Abbottabad: JAMC, 2014, 26(3): 334-336.
- 6 曾民德,王泰龄,王宝恩.肝纤维化诊断及疗效评估共识.肝脏,2002,7(2):147-148.[doi:10.3760/j.issn:1007-3418.2002.02.032]
- 7 刘平,高云华,谭开彬,等.声学造影对早期肝纤维化诊断的实验研究.中国超声医学杂志,2002,18(12):897-899.[doi:10.3969/j.issn.1002-0101.2002.12.005]
- 8 葛永祥,王丽辉.肝纤维化诊断新进展.医学综述,2011,17(19):2952-2955.[doi:10.3969/j.issn.1006-2084.2011.19.025]
- 9 张弘,陶森,郝彧,等.国外肝纤维化诊断的研究热点分析.首都医科大学学报,2016,37(1):83-88.[doi:10.3969/j.issn.1006-7795.2016.01.016]
- 10 Sarraf S, Tofighi G. Classification of alzheimer's disease using fMRI data and deep learning convolutional neural networks. arXiv preprint arXiv:1603.08631, 2016.
- 11 Anthimopoulos M, Christodoulidis S, Ebner L, et al. Lung pattern classification for interstitial lung diseases using a deep convolutional neural network. IEEE Transactions on Medical Imaging, 2016, 35(5): 1207-1216. [doi: 10.1109/TMI.2016.2535865]
- 12 孟丹.基于深度学习的图像分类方法研究[博士学位论文].上海:华东师范大学,2017.
- 13 Wang K, Lu X, Zhou H, et al. Deep learning Radiomics of shear wave elastography significantly improved diagnostic performance for assessing liver fibrosis in chronic hepatitis B: A prospective multicentre study. Gut, 2018: gutjnl-2018-316204. [doi: 10.1136/gutjnl-2018-316204]
- 14 Hinton GE, Osindero S, Teh Y. A fast learning algorithm for deep belief nets. Neural Computation, 2006, 18(7): 1527-1554. [doi: 10.1162/neco.2006.18.7.1527]
- 15 Hubel DH, Wiesel TN. Receptive fields, binocular interaction and functional architecture in the cat's visual cortex. The Journal of Physiology, 1962, 160(1): 106-154. [doi: 10.1113/jphysiol.1962.sp006837]
- 16 Sermanet P, Eigen D, Zhang X, et al. OverFeat: Integrated

- recognition, localization and detection using convolutional networks. arXiv preprint arXiv:1312.6229, 2013.
- 17 Ioffe S, Szegedy C. Batch normalization: Accelerating deep network training by reducing internal covariate shift. Proceedings of the 32nd International Conference on Machine Learning. Lille, France. 2015. 448–456.
  - 18 Srivastava N, Hinton G, Krizhevsky A, *et al.* Dropout: A simple way to prevent neural networks from overfitting. The Journal of Machine Learning Research, 2014, 15(1): 1929–1958.
  - 19 Pan SJ, Yang Q. A survey on transfer learning. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(10): 1345–1359. [doi: 10.1109/TKDE.2009.191]
  - 20 He KM, Zhang XY, Ren SQ, *et al.* Deep residual learning for image recognition. Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA. 2016. 770–778.
  - 21 Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556, 2014.

WWW.C-S-A.ORG.CN

WWW.C-S-A.ORG.CN