

基于改进深度残差网络的计算断层扫描图像分类算法

黄盛, 李菲菲**, 陈虬*

上海理工大学光电信息与计算机工程学院, 上海 200093

摘要 基于改进的深度残差网络(ResNet), 提出更加适合肺部组织的计算断层扫描(CT)图像模式分类模型。为克服医学图像分析中可用数据集稀少的困难, 采用迁移学习方法来减小神经网络模型对数据量大的需求, 以减小过拟合。迁移学习的策略是将肺内大量可用的无标签区域作为预训练的数据, 使用深度互信息最大化和先验分布匹配的方法进行无监督表征学习。通过对比实验发现, 改进的深度 ResNet 可以得到更高的分类精度, 迁移学习算法可以有效地利用肺内无标签区域的数据, 从而提升网络模型的分类表现。

关键词 图像处理; 卷积神经网络; 医学图像分析; 计算断层扫描图像; 迁移学习

中图分类号 TP301

文献标志码 A

doi: 10.3788/AOS202040.0310002

Computed Tomography Image Classification Algorithm Based on Improved Deep Residual Network

Huang Sheng, Li Feifei**, Chen Qiu*

School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China

Abstract We propose a deep model for pattern classification of computed tomography (CT) images of lung tissues based on the improved deep residual network (ResNet). To address the problem of lack of availability training data, we adopt a transfer learning method to reduce the requirement of a neural network model for large data, thereby decreasing overfitting. The transfer learning strategy uses massively available unlabeled lung CT data as the pre-training data. We perform unsupervised representation learning by maximizing the deep mutual information and matching the prior distribution. The results of contrast experiments show that the improved ResNet achieves improved classification accuracy, the effectiveness of utilizing the unlabeled lung CT data for transfer learning and the classification performance of the network model is improved.

Key words imaging processing; convolutional neural network; medical image analysis; computed tomography image; transfer learning

OCIS codes 100.4996; 170.4580; 110.6955

1 引 言

近年来, 计算机硬件计算力的提升以及大型数据集的出现, 使得深度学习技术得到快速的发展。与传统的图像处理和特征提取方法相比, 深度学习使用神经网络经过大量的数据训练能够学习高度表达的特征, 在图像分类、目标检测^[1]、图像分割以及图像去噪^[2]等任务上表现出优越的性能。由于深度学习在自然图像分析任务上的成功, 越来

越多的研究着眼于结合深度学习技术开发一套性能良好的计算机辅助诊断系统^[3], 帮助减少医生的工作量与误诊率, 进而提高诊断效率。比如在肺炎检测^[4]、肺结节识别^[5]、脑肿瘤分割^[6]上, 深度学习方法的诊断结果准确率达到了接近专业医师的水平。在医疗图像分析领域出现了越来越多专门为疾病诊断而设计的神经网络模型, 深度学习已经成为该领域的首选^[7-8]。然而, 医疗领域存在一定的特殊性, 比如隐私、来源、标注成本等因素, 难以形成比较

收稿日期: 2019-09-03; 修回日期: 2019-09-28; 录用日期: 2019-10-21

基金项目: 上海市高校特聘教授(东方学者)岗位计划(ES2012XX, ES2014XX)

* E-mail: q.chen@ieee.org; ** E-mail: feifeilee@ieee.org

大的数据集用于复杂神经网络的训练,如果仅使用数据量稀少的医疗图像数据集从头开始对神经网络进行训练,极易导致过拟合。因此在医疗图像分析领域,如何在小数据集的情况下提升神经网络模型的性能成为目前研究的热点。

在算法设计时需要兼顾训练集数据量的大小与网络模型的复杂程度。常用于解决神经网络训练数据不足导致的过拟合问题的方法是迁移学习方法^[9]。在医学图像分析领域,最常见的迁移学习方法是大型自然数据集上预训练好的模型进行微调,如文献[10]将预训练好的 AlexNet^[11] 和 GoogLeNet^[12] 在腹部疾病和肺部疾病数据集上进行微调,然后直接用于图像的分类,可以得到较好的分类精度。但是这样的迁移学习方式忽略了自然图像与医学图像模态之间存在的特征差异,迁移学习的效果可能会受到影响,因此如何在医学图像分析任务中实现更有效的迁移学习也是目前具有价值的研究方向。

计算断层扫描(CT)是医学图像中常见的模态,本文对一种使用 CT 模态图像的肺部疾病,即间质性肺病^[13] 的病理模式进行分类。先前的研究尝试使用结构比较浅的神经网络模型进行分类实现^[14-16],但是这些研究方法无法达到足够高的分类精度,所以本文尝试使用更深的神经网络,提出改进的残差网络(ResNet)模型,该模型更适合用于间质性肺病模式特征的提取。此外,为在小数据集的情况下训练含有大量参数的神经网络模型,本文提出一种无监督预训练的迁移学习策略,采用深度互信息最大化(DIM)与先验分布匹配(PM)结合的方法进行无监督预训练,最后微调模型完成迁移,以此提升深度卷积神经网络在间质性肺病病理模式分类上的准确率。

2 改进的残差网络模型

卷积神经网络对图像特征的提取过程是低级特征到高级特征的逐层映射和学习的过程,一般情况下,越深的神经网络模型具有越优异的特征提取性能。为获得更好的间质性肺病病理模式分类效果,本文选择较深且更易于训练的残差网络模型^[17]。

2.1 残差模块

残差神经网络是 He 等^[17] 2016 年提出的一种深层的神经网络模型,作者指出随着网络的加深,在反向传播过程中梯度很容易消失,导致参数无法更

新从而影响到网络的收敛,此外神经网络的深度加深会引起网络退化的问题。残差网络中的残差模块能很好地解决这些问题,使得神经网络模型可以达到几十层甚至上百层的深度。近几年该网络模型由于其优越的性能被广泛地应用于许多应用中。具体的残差模块构造如图 1 所示,可以看到 x 作为输入值,经过卷积映射变换之后再经过批归一化(BN)和激活函数 ReLU 得到残差 $F(x)$,在激活前将 $F(x)$ 与 x 用 shortcut 连接相加即为残差模块的主要思想,这样可以保证恒等变换和反向传播时的梯度传递。




图 1 残差模块

Fig. 1 Residual block

2.2 小卷积核残差网络 SK-ResNet

在深度残差网络的基础上,对模型结构进行改进,使其更适合间质性肺病的病理模式特征。由于间质性肺病病理模式的特征并不复杂,因此选择结构相对简单的 ResNet-18。在卷积神经网络中,卷积核的作用是对图像的特征进行提取,尺寸越大的卷积核能获得更大的感受野,但是会造成较大的参数量。间质性肺病的病理模式是基于纹理特征进行区分的,而且每种病理之间的纹理特征的相似程度较高,表现为微小特征上的差别。所以为了提取微小的特征以及减小网络模型的参数量,选择尺寸为 2×2 的卷积核最为合适。

本文的改进方案是在 ResNet-18 的基础上,除了第一层的卷积核改为 3×3 之外,后面所有卷积层的卷积核大小设置为 2×2 。虽然卷积核尺寸的减小会影响感受野,但足够的卷积层的叠加可以获得足够的感受野,本文改进的网络模型 SK-ResNet 结构如图 2 所示,其中 global avg pool 表示全局平均池化。在 ResNet-18 的基础上,将其简化成 14 层,以此进一步减小网络的参数量;为适应数据集的特点,该网络的输入大小设置为 32×32 ;为了在全局平均池化前保证足够尺寸的卷积特征,只在第 10 层与第 12 层进行步长为 2 的卷积操作。




图 2 SK-ResNet 的结构

Fig. 2 Architecture of SK-ResNet

3 迁移学习与无监督预训练

因可用于间质性肺病分类任务的数据集非常少,所以选择迁移学习的方法来解决数据集过小而造成的训练过拟合问题。迁移学习^[18]是将一个模型在其他领域学习到的知识迁移到另一个领域上。对于神经网络的可迁移性质,低层的特征是通用的,越高的层特征越具有任务特定性,可以经过微调或针对高层重新训练的方法实现知识的迁移^[19]。

迁移学习过程中需要避免源域与目标域之间的语义鸿沟过大而造成的“负迁移”现象,比如自然图像与医学图像之间的差别会影响迁移的效果。本文迁移学习方法不采用自然图像数据集作为预训练的源域数据,而是选择使用肺内大量可用的无标签区域作为预训练的数据。

3.1 深度互信息最大化的无监督学习方法

由于选择用来预训练的数据集没有标签信息,本文选择无监督学习的方式进行网络模型的预训练。深度互信息最大化^[20]提供了一种灵活的方式同时进行互信息的估计和最大化,通过最大化输入与输出表征之间的互信息,网络可以在无监督的情况下学习输入数据的特征。

假设 x 表示某一输入图像, z 表示经过网络模型编码后的编码向量, $p(z|x)$ 表示 x 所产生的编码向量的分布, $\tilde{p}(x)$ 表示原始数据的分布, $p(z)$ 表示确定 $p(z|x)$ 后整个编码向量空间的分布,根据互信息的定义,互信息等于联合分布与边缘分布乘积之间的 KL 散度(Kullback-Leibler divergence),即

$$\hat{I}(x; z) = \iint p(z|x)\tilde{p}(x) \log \frac{p(z|x)\tilde{p}(x)}{p(z)\tilde{p}(x)} dx dz. \quad (1)$$

深度互信息最大化^[20]使用生成对抗训练^[21]的思想来最大化互信息,以此使得编码器学习有效的表征,完成无监督学习过程。假设神经网络的编码

过程为 $f_e(\cdot)$,用于生成对应 x 的高级特征向量, $T[\cdot]$ 为引入的判别器,则根据生成对抗训练的思想,互信息等价于

$$\hat{I}[x; f_e(x)] = E_p \{ \sigma \{ T[x; f_e(x)] \} \} + E_{p \times \tilde{p}} \{ -\sigma \{ T[x'; f_e(x')] \} \}, \quad (2)$$

式中: $\sigma(x) = \log(1 + e^x)$; x' 为生成对抗训练过程中使用的假样本; E_p 为当前变量服从于分布 p 的数学期望。判别器需要在编码器生成的特征对与含有假样本的特征对之间进行判别,使得编码器生成的高级特征和输入数据间拥有较大的互信息,这样实现编码器对输入样本特征的学习。

为了使得学习到的特征更具有代表性,选择计算输入每个像素点与输出特征向量之间的互信息。假设将神经网络前 5 层 $f_{\circ}(\cdot)$ 的输出作为低级特征,则高级特征向量 $f_e(\cdot)$ 先经过复制扩张成与低级特征一样的尺寸大小,再与之拼接形成送入判别器的特征对 $[x; f_e(x)]$ 。

本文使用的判别器结构如图 3 所示,由三层卷积核大小为 1×1 的卷积层构成,输出通道数量分别为 512、512、1,最后一层输出经过 Sigmoid 函数计算特征对的得分值。




图 3 判别器结构图

Fig. 3 Structure of discriminator

3.2 添加先验分布限制

单纯使用深度互信息最大化的方法学习到的无监督特征会与目标域失去关联,本文在进行无监督表征学习时添加了一个限制条件。编码器能够将输入样本 x 编码成一个分布式特征表示,添加限制条件目的是迫使该输出分布与一个先验分布 U 接近或者匹配,间接使得模型在无监督训练时得到来自无标签信息的弱监督。假设先验分布也由一个网络模

型生成,对于一个输入样本 \mathbf{x} ,模型生成的分布为 $q(\mathbf{z}|\mathbf{x})$,本文直接计算并最小化这两个分布之间的 KL 散度,即

$$\arg \min \text{KL}[U \| V] = \int p(\mathbf{z}|\mathbf{x}) \log \frac{p(\mathbf{z}|\mathbf{x})}{q(\mathbf{z}|\mathbf{x})} d\mathbf{z} \quad (3)$$

先验分布 V 的确定方案为:首先利用原始 SK-ResNet 模型在目标域的训练集上进行预训练,其中用于训练的损失函数为交叉熵损失函数;对训练好的网络参数进行固定,即可作为一个直接计算无标签样本对应特征分布的模型。在进行无监督训练时,将每一个无标签样本同时输入该固定的网络模型和正在训练的网络模型中,得到一个先验分布和正在训练的输出分布,将两者的 KL 散度并入优化的目标函数中。

3.3 迁移学习的总体架构

迁移学习策略是将神经网络模型在无标签样本上进行预训练,再将预训练好的模型在目标域的训

练集上进行微调,以此完成整个迁移学习过程。完整的无监督训练流程如图 4 所示,包含深度互信息最大化过程和先验分布的匹配过程。其中,本文改进的 SK-ResNet 作为图像特征学习的编码器。图 4 上半部分利用参数随机初始化的原始 SK-ResNet 模型,在目标域的训练集上进行预训练,得到一个完成预训练的 SK-ResNet,将该训练好的网络模型的参数进行固定,在进行无监督训练时,输入样本经过该网络模型输出一个先验分布 V ;中间部分是输入样本经过一个全新的随机初始化的 SK-ResNet 进行训练的过程,同时可以输出对应的分布 U 与先验分布 V ,可计算出 KL 散度;下半部分则是深度互信息最大化的过程,即低级特征与高级特征形成特征对输入到判别器中进行计算。其中在训练时,假样本不由编码器生成,而是采用其他与训练样本无关的图像样本。为了直接形成无关的低级特征与高级特征拼接,本文将每次编码器生成的低级特征在维度上进行打乱以作为训练的假样本。

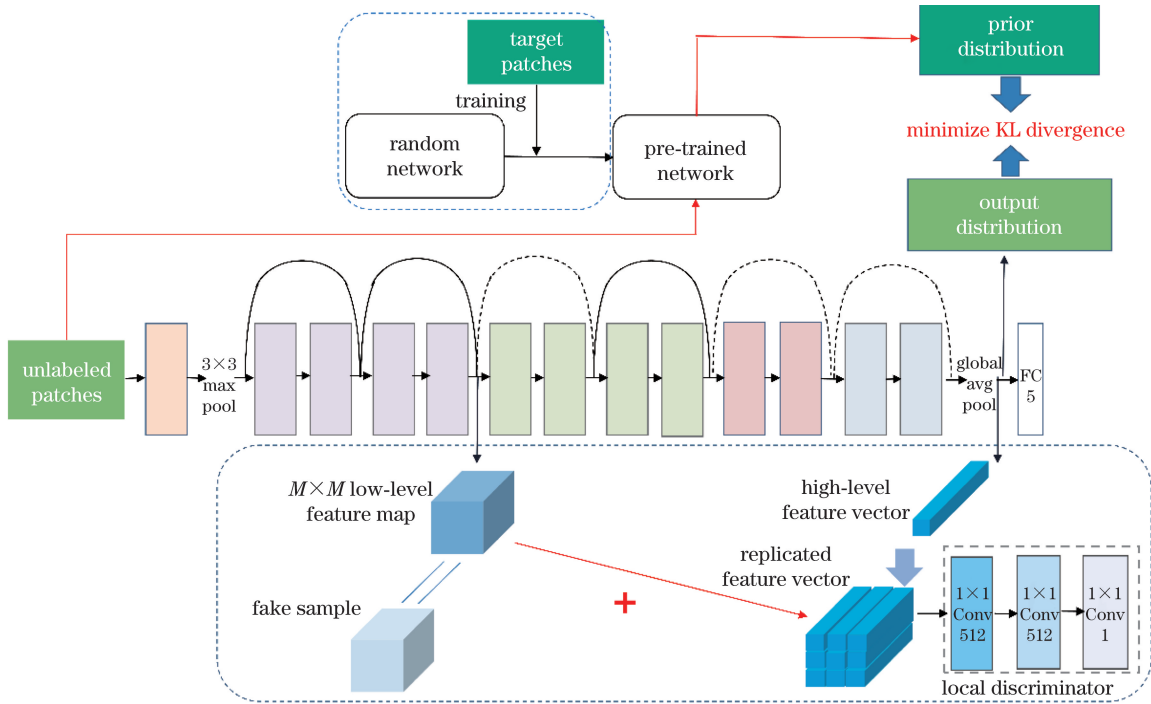


图 4 无监督预训练流程图

Fig. 4 Process of unsupervised pre-training

综上,无监督预训练网络模型总体的优化目标函数为

$$\arg \max \frac{\alpha}{M^2} \sum_{i=1}^{M^2} \hat{I}[f_{e_0}^i(\mathbf{x}); f_e(\mathbf{x})] + \beta \arg \min \text{KL}[U \| V], \quad (4)$$

式中: M 为低级特征的尺寸,代表在每个像素点上计算输入与输出特征之间的互信息; α 和 β 为超参

数,用于权衡互信息最大化和先验匹配在训练过程中的影响作用。

4 实验与分析

4.1 数据集准备

间质性肺病数据集来自一个公开的 HUG 数据集^[22],该数据集包含 108 个病人的肺部高分辨率

CT 图像,每个病例平均含有 25 张 CT 横向切片,每张切片厚度为 12 mm,大小为 512×512 。三位经验丰富的医生对每种间质性肺病病理区域进行标注,在每张切片上,对应病理的区域使用多边形标注出来,如图 5 所示。本文选取数据量比较多的 5 种病理进行研究,分别是正常(NM)、磨玻璃(GG)、气肿(EM)、微小结节(MN)和纤维化(FB)。为数据统一,进一步对每张切片的尺度进行调整,将像素间距调整为 1 mm,且为了更适用于本文网络结构,为每张切片设置 3 种不同的 CT 衰减值,并将 3 张图像合成一张 3 通道的图像。完成图像数据的预处理之后,从每个病理区域中裁剪出大小为 32×32 的图像块,最后得到每种病理各含有 1020 张图像块的数据量。

对于用于预训练的源域数据集,本文采集肺部未标注区域。如图 5 所示,未标注区域的纹理特征与标注区域中的特定病理的纹理非常相似,非常适

用于该任务的知识迁移,而且这些未标注区域的面积非常大,由此可以获得大量的图像块用于预训练。同样地,从这些区域中裁剪出的图像块的大小为 32×32 ,最终获得总共 18706 张无标签的图像块,一些图像块样本如图 6 所示。




图 5 肺部标注区域展示(区域 1、2 为病理区域)
Fig. 5 Example of labeled areas of lung
(areas 1, 2 denote pathology area)




图 6 图像块样本示例。(a)源域;(b)目标域
Fig. 6 Image patch examples. (a) Source domain; (b) target domain

为充分地对本方法方法进行验证,使用 3 种不同的方案对所裁剪出的数据集进行分离,分离结果如表 1 所示。对于方案 A,采用 5 折-交叉验证的方式,将整个数据集等分为 5 组,每次实验选择其中 4 组作为训练集,剩下的 1 组作为测试集。对于方案 B,本文进行特定病例的挑选,即有些病例完全用于测试而不会出现在训练集中,为此可以验证本文

表 1 几种不同的数据集分离方案

Table 1 Different dataset separation schemes

Scheme	Size of training set	Size of test set	Split manner
A	4132	1031	5-fold
B	2560	2479	Case select
C	11289	750	Random select

模型的泛化性。对于方案 C,随机挑选 750 张图像块作为测试集,同样随机挑选出 750 张作为验证集,剩下的样本全部用于训练集。为使该训练集拥有更多的样本,可进一步进行数据增广,比如旋转和翻转。

4.2 网络模型训练

实验中的网络都使用 pytorch 框架进行搭建,利用 Python 进行编程。所有实验在一台搭载 Linux 系统的计算机上完成,其处理器为 Intel Xeon(R) E5-2630 v3, 2.40 GHz, 显卡型号为 NVIDIA Tesla K40C, 内存大小为 12 GB。

对本文改进的残差网络进行训练时,使用 Adam 优化器。根据多次实验经验,初始学习率设置为 0.0005,并且每 20 个 epoch 之后将学习率减小

10%，所采用批的大小设置为 64，这样的参数设置可以使网络训练稳定且收敛迅速。当对预训练好的网络模型进行微调时，将最后一层全连接层(FC)重新初始化，初始学习率设置为更小的 0.0003，并且以每 20 个 epoch 减小 10% 的设置进行学习率的衰减。以上的训练和微调过程最多进行 100 个 epoch，当训练的损失不再明显下降时停止训练。对于有验证集的数据集分离方案 C，选择训练过程中在验证集上表现最好的模型进行测试。

4.3 实验结果与分析

实验中，使用平均 F1-score 作为评价指标，该指标的计算公式为

$$f_{avg} = \frac{1}{5} \sum_{c=1}^5 2 \times \left(\frac{r \times p}{r + p} \right), \quad (5)$$

式中： r 为分类的召回率，即所有被正确分类的样本与总样本的比值； p 为分类精度，即对应标签为 c 的被正确分类的样本与所有被分为 c 的总样本的比值。为减小数据浮动所带来的误差，每个实验进行 10 次然后取平均值。

首先研究网络模型的深度对分类精度结果的影响。残差网络模型的深度由相应的 4 种残差模块中包含的卷积层数量控制，这里采用 4 种不同的调整设置方案。将这几种不同深度的网络模型在三种不同分离方案的数据集上进行验证和对比，表 2 为不同深度的网络模型相应的分类结果。

表 2 不同深度的 SK-ResNet 分类结果对比

Table 2 Comparison of classification results of SK-ResNet with different depths

Network	Structure of ResNet block	f_{avg}		
		A	B	C
SK-ResNet 10	[1,1,1,1]	0.9586	0.9453	0.9651
SK-ResNet 14	[2,2,1,1]	0.9609	0.9476	0.9640
SK-ResNet 18	[2,2,2,2]	0.9533	0.9354	0.9553
SK-ResNet 34	[3,4,6,3]	0.9497	0.9329	0.9549

由实验结果可以看出，具有 10 层深度的网络模型的性能与 14 层的性能相当，而随着网络层的加深，模型分类的性能逐渐下降，尤其是 14 层增加到 18 层深度，分类准确率约下降 1%，这表明神经网络模型在训练时因参数过多发生了过拟合现象。由于 SK-ResNet 14 具有更少的参数量和更优越的分类性能，因此选择该深度的网络模型结构进行后面的实验及分析。

根据改进的神经网络模型和迁移学习算法，进

行模型迁移前后的实验对比。基准线为本文神经模型，利用目标训练集从头开始训练，然后在测试集上进行测试。对于迁移学习，则按照第 3 节里描述的算法进行。总体流程：先在源域数据集上进行无监督预训练；然后再在目标训练集上进行微调；最后使用微调好的模型在测试集上进行测试。这里还单独研究了只使用深度互信息最大化(DIM)而没有结合先验分布匹配(PM)进行无监督训练的表现。该组实验结果如表 3 所示。

表 3 SK-ResNet 使用迁移学习方法前后对比

Table 3 Comparison of results on SK-ResNet before and after using transfer learning

Method	A	B	C
Without transfer	0.9609	0.9476	0.9640
DIM	0.9799	0.9654	0.9707
DIM+PM	0.9818	0.9677	0.9756

从实验结果可以看出：利用微调预训练模型的迁移学习方法所得到的分类精度比不进行迁移学习高，说明迁移学习可以在训练数据稀少的时候提高模型的泛化能力，减小过拟合现象；肺内无标签区域的图像数据可以有效地用于迁移学习的预训练，微调时可以将学习到的知识迁移到目标域中。此外，无监督预训练时，相较于单个优化目标函数，DIM 和 PM 结合可以得到更好的分类结果。

为更好地研究神经网络模型在不同规模训练集上的分类效果和迁移学习效果，本文在数据集分离方案 C 的基础上进行进一步实验。同样采用与 C 方案相同的验证集和测试集，而训练集不进行数据增广，采用训练集数据量的 20%、40%、60%、80%、100% 进行 5 组实验。图 7 为使用迁移学习前后的神经网络模型在不同训练集规模上的对比结果。可以发现，在使用本文迁移学习方法后，神经网络模型对肺部病理模式分类的准确率有很大的提升，并且随着训练数据规模的减少，迁移学习对网络模型分类性能的提升更加明显。

为进一步展现分类结果，更好地体现迁移学习方法的有效性，这里给出神经网络模型在 B 方案数据集上使用迁移学习前后的分类混淆矩阵，如表 4、5 所示。可以看出使用迁移学习方法后，网络模型在对气肿(EM)、正常(NM)和微结节(MN)的分类上有了很大的性能提升，使得混淆矩阵变得更加平衡，说明迁移学习可以使网络模型展现出更好的泛化性。模型分类混淆的类基本是正常(NM)和微结

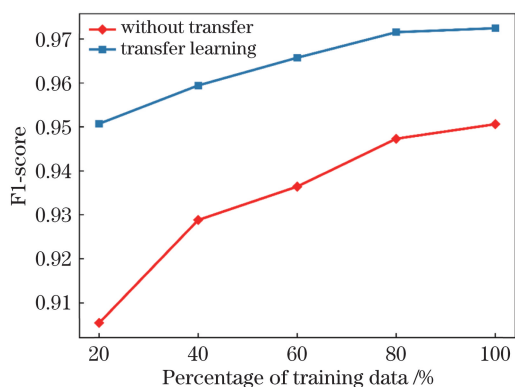


图 7 不同规模训练集 SK-ResNet 分类结果趋势图

Fig. 7 Trend graph of classification results for training sets with different scales

节(MN)及纤维化(FB)和磨玻璃(GG),是由于这些病理的纹理相似度极高。最终在使用迁移学习算法之后仍存在未被正确分类的图像,主要原因是神经网络模型仍然无法区分这些相似度过高的样本。图 8 为一些错误分类的样本(标签-预测),可以发现,由于混淆的类别非常相似,神经网络模型难以正确区分。

表 4 SK-ResNet 的分类混淆矩阵

Table 4 Classification confusion matrix of SK-ResNet

Ground truth	Predicted result				
	EM	FB	GG	NM	MN
EM	0.91	0	0	0.08	0.01
FB	0	0.96	0.04	0	0
GG	0	0.02	0.98	0	0
NM	0	0	0.03	0.94	0.03
MN	0	0	0	0.06	0.94

表 5 使用迁移学习的 SK-ResNet 的分类混淆矩阵

Table 5 Classification confusion matrix of SK-ResNet using transfer learning

Ground truth	Predicted result				
	EM	FB	GG	NM	MN
EM	0.97	0	0	0.03	0
FB	0	0.96	0.04	0	0
GG	0	0.02	0.98	0	0
NM	0	0	0.03	0.96	0.01
MN	0	0	0	0.03	0.97

为体现本文网络模型和迁移学习方法的优越性,这里给出与其他方法比较的结果。在数据对比时,对比实验都是在相同数据集、相同条件下进行的。表 6 为对比结果。




图 8 错误分类的样本

Fig. 8 Misclassified examples

表 6 SK-ResNet 与不同方法分类表现的对比

Table 6 Comparison of classification performances of SK-ResNet and other methods

Method	A	B	C
Ref.[14]	0.7725	0.7644	0.7987
Ref. [16]	0.9465	0.9215	0.9392
Ref. [23]	0.9483	0.9269	0.9554
AlexNet ^[11]	0.8962	0.8821	0.9226
Pre-trained AlexNet ^[11]	0.9471	0.9337	0.9609
Pre-trained VGG-16 ^[24]	0.9603	0.9435	0.9664
ResNet-18 ^[17]	0.9371	0.9306	0.9432
Pre-trained ResNet-18 ^[17]	0.9581	0.9443	0.9651
Pre-trained DenseNet-121 ^[25]	0.9741	0.9579	0.9715
SK-ResNet	0.9609	0.9476	0.9640
SK-ResNet (transfer)	0.9818	0.9677	0.9756

文献[14]使用了较浅的神经网络模型进行分类,可以发现,这种方法无法获得很好的分类精度,这是由于较浅的模型提取图像特征的能力比较弱。文献[16]和文献[23]中的模型分别是两个专门为间质性肺炎病理模式分类而设计的神经网络模型,可以看到,本文改进的残差网络的分类表现明显优于这两种方法。此外,本文还与其他主流的神经网络模型进行比较,如 AlexNet^[11]、VGG-16^[24]、ResNet-18^[17]、DenseNet-121^[25]及它们在大型数据集上预训练的模型。从实验结果可以看出: AlexNet、VGG-16、ResNet-18 及它们的预训练模型分类表现都

没有超过本文改进的残差网络;而预训练好的 DenseNet-121 的分类表现超于本文改进的残差网络,原因是该网络模型深度更深,具有更好的特征提取性能。最终分类表现最好的是本文迁移学习方法之后的改进的残差网络。实验结果说明,本文迁移学习方法对模型的性能有明显的提升作用。

根据以上实验结果可以看出,使用神经网络对图像特征进行提取时,应该保证神经网络具有足够的深度,并且最好根据所要实现的任务专门设计或者改进网络模型结构。同时也需兼顾训练数据集和网络模型的复杂程度,当用于训练的数据集太小时,使用迁移学习方法可以有效地避免数据不足造成的过拟合。间质性肺病病理模式的分类是根据病理纹理模式进行分类的,而肺内无标签区域的纹理特征与间质性肺病病理的纹理具有较高的相似度,因此可将这些数据作为迁移学习时预训练的源域,有利于体现迁移的效果。

5 结 论

针对间质性肺病病理模式分类任务中数据集小的问题,提出改进的残差网络模型;基于无监督预训练方法提出迁移学习策略。经过实验对比可知:本文改进的残差网络模型具备良好的特征提取性能,可以得到更高的分类精度;本文迁移学习算法可有效地利用肺内无标签区域的数据,从而提升网络模型的性能,分类表现明显高于先前的研究成果。在间质性肺部疾病病理模式分类问题上,本文算法的思想,即采用更深但是更适合特定任务的网络模型、充分利用大量可用的无标签样本进行迁移学习,对未来该任务或者其他医学图像分析任务具有很好的启发意义。

参 考 文 献

- [1] Pang J M, Chen K, Shi J P, et al. Libra R-CNN: towards balanced learning for object detection[C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, June 16-20, 2019, Long Beach, CA. New York: IEEE, 2019: 821-830.
- [2] Peng Y L, Zhang L, Liu S G, et al. Dilated residual networks with symmetric skip connection for image denoising[J]. Neurocomputing, 2019, 345: 67-76.
- [3] van Ginneken B, Schaefer-Prokop C M, Prokop M. Computer-aided diagnosis: how to move from the laboratory to the clinic[J]. Radiology, 2011, 261(3): 719-732.
- [4] Liu K, Wang D, Rong M X. X-ray image classification algorithm based on semi-supervised generative adversarial networks[J]. Acta Optica Sinica, 2019, 39(8): 0810003.
- 刘坤, 王典, 荣梦学. 基于半监督生成对抗网络 X 光图像分类算法[J]. 光学学报, 2019, 39(8): 0810003.
- [5] Feng Y, Yi B S, Wu C Y, et al. Pulmonary nodule recognition based on three-dimensional convolution neural network[J]. Acta Optica Sinica, 2019, 39(6): 0615006.
- 冯雨, 易本顺, 吴晨玥, 等. 基于三维卷积神经网络的肺结节识别研究[J]. 光学学报, 2019, 39(6): 0615006.
- [6] Chen L, Bentley P, Mori K, et al. DRINet for medical image segmentation[J]. IEEE Transactions on Medical Imaging, 2018, 37(11): 2453-2462.
- [7] Litjens G, Kooi T, Bejnordi B E, et al. A survey on deep learning in medical image analysis[J]. Medical Image Analysis, 2017, 42: 60-88.
- [8] Altaf F, Islam S, Akhtar N, et al. Going deep in medical image analysis: concepts, methods, challenges and future directions[J/OL]. (2019-02-15) [2019-09-02]. <https://arxiv.org/abs/1902.05655>.
- [9] Liu X P, Luan X D, Xie Y X, et al. Transfer learning research and algorithm review[J]. Journal of Changsha University, 2018, 32(5): 28-31, 36.
- 刘鑫鹏, 栾悉道, 谢毓湘, 等. 迁移学习研究和算法综述[J]. 长沙大学学报, 2018, 32(5): 28-31, 36.
- [10] Shin H C, Roth H R, Gao M C, et al. Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning [J]. IEEE Transactions on Medical Imaging, 2016, 35(5): 1285-1298.
- [11] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks [C] // Advances in Neural Information Processing Systems, December 3-6, 2012, Lake Tahoe, Nevada, United States. Canada: NIPS, 2012: 1097-1105.
- [12] Szegedy C, Liu W, Jia Y Q, et al. Going deeper with convolutions[C] // 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 7-12, 2015, Boston, MA, USA. New York: IEEE, 2015: 15523970.
- [13] Devine M S, Garcia C K. Genetic interstitial lung disease[J]. Clinics in Chest Medicine, 2012, 33(1): 95-110.
- [14] Li Q, Cai W D, Wang X G, et al. Medical image classification with convolutional neural network[C] // 2014 13th International Conference on Control Automation Robotics & Vision (ICARCV), December

- 10-12, 2014, Singapore. New York: IEEE, 2014: 844-848.
- [15] Wang Q C. Research on lung tissue classification based on deep learning [D]. Jinan: Shandong University, 2016.
王强昌. 基于深度学习的肺部组织分类研究[D]. 济南: 山东大学, 2016.
- [16] Anthimopoulos M, Christodoulidis S, Ebner L, et al. Lung pattern classification for interstitial lung diseases using a deep convolutional neural network [J]. *IEEE Transactions on Medical Imaging*, 2016, 35(5): 1207-1216.
- [17] 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 (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE, 2016: 770-778.
- [18] Pan S J, Yang Q. A survey on transfer learning[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2010, 22(10): 1345-1359.
- [19] Yosinski J, Clune J, Bengio Y, et al. How transferable are features in deep neural networks?[C]//Advances in Neural Information Processing Systems, December 8-13, 2014, Montreal, Quebec, Canada. Canada: NIPS, 2014: 3320-3328.
- [20] Hjelm R D, Fedorov A, Lavoie-Marchildon S, et al. Learning deep representations by mutual information estimation and maximization [J/OL]. (2019-02-22) [2019-09-02]. <https://arxiv.org/abs/1808.06670>.
- [21] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets[C]//Advances in Neural Information Processing Systems, December 8-13, 2014, Montreal, Quebec, Canada. Canada: NIPS, 2014: 2672-2680.
- [22] Depeursinge A, Vargas A, Platon A, et al. Building a reference multimedia database for interstitial lung diseases[J]. *Computerized Medical Imaging and Graphics*, 2012, 36(3): 227-238.
- [23] Guo W P, Xu Z M, Zhang H B. Interstitial lung disease classification using improved DenseNet [J]. *Multimedia Tools and Applications*, 2018: 1-12.
- [24] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition [J/OL]. (2015-04-10) [2019-09-02]. <https://arxiv.org/abs/1409.1556>.
- [25] Huang G, Liu Z, van der Maaten L, et al. Densely connected convolutional networks [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE, 2017: 2261-2269.