

# 残差神经网络及其在医学图像处理中的应用研究

周涛<sup>1,2,3</sup>, 霍兵强<sup>1</sup>, 陆惠玲<sup>2</sup>, 任海玲<sup>4</sup>

(1. 北方民族大学计算机科学与工程学院, 宁夏银川 750021; 2. 宁夏医科大学理学院, 宁夏银川 750004;  
3. 宁夏智能信息与大数据处理重点实验室, 宁夏银川 750021; 4. 宁夏医科大学公共卫生与管理学院, 宁夏银川 750004)

**摘要:** 残差神经网络(ResNet)是近几年来深度学习研究中的热点,在计算机视觉领域取得较好成就.本文对残差神经网络从以下几个方面进行总结:第一,阐述残差神经网络的基本结构和工作原理;第二,在模型发展方面,以时间为顺序总结了残差神经网络的8种网络模型;第三,在结构优化方面,从残差神经网络的卷积层、池化层、残差单元、全连接层以及整个网络5个方面进行总结;最后,将ResNet应用到医学图像处理领域,主要从图像识别和图像分割2个方面探讨.本文对残差神经网络的原理、模型、结构进行了系统地总结,对残差神经网络的研究发展具有一定的积极意义.

**关键词:** 残差神经网络;网络结构;医学图像

**中图分类号:** TP399

**文献标识码:** A

**文章编号:** 0372-2112 (2020)07-1436-12

**电子学报 URL:** <http://www.ejournal.org.cn>

**DOI:** 10.3969/j.issn.0372-2112.2020.07.024

## Research on Residual Neural Network and Its Application on Medical Image Processing

ZHOU Tao<sup>1,2,3</sup>, HUO Bing-qiang<sup>1</sup>, LU Hui-ling<sup>2</sup>, REN Hai-ling<sup>4</sup>

(1. School of Computer Science and Engineering, North Minzu University, Yinchuan, Ningxia 750021, China;

2. School of Science, Ningxia Medical University, Yinchuan, Ningxia 750004, China;

3. Ningxia Key Laboratory of Intelligent Information and Big Data Processing, Yinchuan, Ningxia 750021, China;

4. School of Public Health and Management, Ningxia Medical University, Yinchuan, Ningxia 750004, China)

**Abstract:** Residual neural network (ResNet) has witnessed tremendous amount of attention in deep learning research over the last few years and has made great achievements in computer vision. In this paper, the ResNet is summarized in the following aspects: Firstly, the basic structure and working principle of the ResNet are expounded; Secondly, in model development, the eight network models of the ResNet are summarized in time sequence; Thirdly, in structural optimization, the research progress is described from five aspects of ResNet, including convolutional layer, pooling layer, residual unit, fully connected layer and the whole network; Finally, the application of ResNet in medical images processing is mainly discussed from two aspects of image recognition and image segmentation. In this paper, the principles, models, and structures of ResNet are systematically summarized, which has positive significance to the research and development of ResNet.

**Key words:** residual neural network; network structure; medical image

## 1 引言

深度学习特别是卷积神经网络(CNN)能够从图像中自动提取特征,已经成为图像领域的研究热点. CNN<sup>[1]</sup>是一种基于感知器的模型结构,其优点在于可以直接输入原始图像,避免对图像的过度预处理,通过局

部感受野、权值共享、池化功能,使得CNN能在较低的模型复杂度下充分利用图像局部和全局信息,对图像的平移、旋转、缩放等具有一定鲁棒性. CNN经典模型包括: AlexNet、VGG、GoogleNet、残差神经网络(ResNet)等模型,其中残差神经网络<sup>[2]</sup>在深度卷积网络发展中具有里程碑式意义. 残差神经网络重构了学习过程,重

收稿日期:2019-07-19;修回日期:2020-01-11;责任编辑:孙瑶

基金项目:国家自然科学基金(No. 61561040);宁夏高等学校一流学科建设(数学学科)(No. NXYLXK2017B09);北方民族大学引进人才科研启动项目(No. 2020KYQD08);宁夏312优秀人才项目;北方民族大学创新创业项目(No. YCX19075)

定向了深层卷积神经网络信息流,从而很好地解决了深层卷积神经网络层数与准确度之间的矛盾,进而可以加深网络深度,解决了网络加深所出现的梯度消失问题,并且加速网络收敛。

2019年3月, Yoshua Bengio、Geoffrey Hinton、Yann LeCun 三人获得美国计算机协会授予的图灵奖,以表彰他们在深度学习领域做出的贡献。田娟秀<sup>[3]</sup>、Wells<sup>[4]</sup>等学者指出深度学习已经成为医学图像领域的研究热点。Geert Litjens<sup>[5]</sup>总结了深度学习在神经、数字病理、腹部等医学图像处理中的应用。大型互联网公司积极致力于深度学习在医学图像处理领域的产业化研究,2017年腾讯公司发布腾讯觅影<sup>[6]</sup>,万里云和阿里发布 Doctor you AI 系统<sup>[6]</sup>,这些智能医学辅助诊断系统涉及的疾病主要有食管癌、肺癌、糖尿病、宫颈癌和乳腺癌,积极推动腾讯觅影、Doctor you AI 等辅助诊断系统在临床上的应用是一件很有意义的工作。

残差神经网络在医学图像领域应用日益广泛,在恶性肿瘤、脑功能、心脑血管疾病等重大疾病的临床辅助分类、识别、检测、分割等方面取得良好效果。Andreas Maier<sup>[7]</sup>认为残差神经网络是对医学图像领域产生重要影响的网络。Nibali<sup>[8]</sup>将残差神经网络应用于肺结节良恶性分类中,实验效果良好;亢寒<sup>[9]</sup>指出在医学

图像分割时最先采用的是 U-Net 与残差神经网络结合模型;Michal Drozdal<sup>[10]</sup>首次将残差结构应用于图像分割的 FCN 网络中,实验证明改进的网络可以加速收敛,能训练更深层网络。

## 2 残差神经网络基本原理

残差神经网络是由用于特征提取的卷积层和用于特征处理的池化层交叠组成,并且用跨层连接(Shortcut Connections)、拟合残余项(Residual Representations)的手段来解决退化问题和梯度消失问题的多层神经网络。卷积神经网络随网络的加深而导致梯度逐渐消失,浅层的参数无法更新,而 Shortcut Connections 结构保证了反向传播参数的更新,避免了反向传播导致的梯度消失问题。残差神经网络使得优化深层模型更为简单。典型的残差神经网络结构如图 1 所示,输入图像经过若干个“卷积”和“池化”操作后,在全连接层网络实现“分类”效果,残差连接将多个卷积层跨层连接实现了恒等映射<sup>[2]</sup>(Identity Mapping),恒等映射保证了网络性能不会下降,使得网络在输入特征的基础上学习到新的特征,而恒等映射不会给网络增加额外的参数和计算量,却可以加快模型的训练速度,优化训练效果。

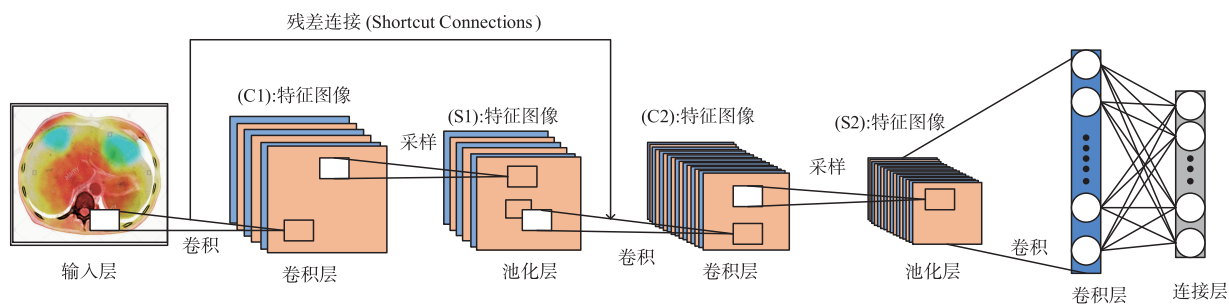


图1 残差神经网络经典结构图

残差神经网络的卷积层是由卷积核对前一层输入图像做卷积运算得到的多个特征图组成,卷积核是卷积层的重要组成部分,每个特征图由多个神经节点组成,特征图上的所有神经元共享同一个卷积核的参数,由卷积核对前一层输入图像做卷积运算得到。在卷积过程中通过局部连接和权值共享的特性实现特征提取。卷积核的两种特性在提取不同特征的同时极大的降低了参数量。

池化层也称为“下采样”层,池化层的输入一般来源于上一个卷积层,主要作用是提供较强的鲁棒性。池化层有效地缩小参数矩阵的尺寸并减少全连层的参数量,从而在减少数据量的同时保留有用信息。常用的池化操作是最大池化和均值池化。

深度残差神经网络通常由多个残差块结构重叠构

成,相邻卷积层通过 Shortcut 实现残差连接,形成残差块(Residual Block),残差神经网络解决了深层神经网络层数与准确度之间的矛盾,加速网络收敛。残差块结构如图 2 所示。其中  $x$  表示输入, $H(x)$  表示输出。图 2 中原始映射为

$$H(x) = F(x) + x \quad (1)$$

其中残差映射表示为

$$F(x) = H(x) - x \quad (2)$$

何凯明<sup>[11]</sup>通过对残差结构分析证明,残差映射比原始映射更容易学习,因此残差神经网络是通过中间的堆叠层学习残差映射,残差映射  $F(x)$  对输出变化更敏感,参数的调整幅度更大,从而加快了学习速度,提高了网络优化性能。

全连接层在卷积层和池化层之后,每个神经元都




图2 残差块

会与下一层的每个神经元相连. 全连接层通过整合卷积层或者池化层中具有类别特征的特征信息并减少特征位置对分类的影响, 将提取的特征进行分类.

### 3 残差神经网络及其改进

近年来残差神经网络在计算机视觉领域取得了较好的效果. 残差神经网络模型改进如图 3 所示<sup>[12]</sup>, 这里将残差神经网络模型的发展进程映射到二维空间, 横轴表示模型及其改进, 纵轴表示时间. 这里从残差神经网络的基础模型 LeNet-5, AlexNet 模型入手, 围绕卷积功能改进、网络结构改进、与其他模型结合进行总结, 以时间为顺序综述其模型发展.

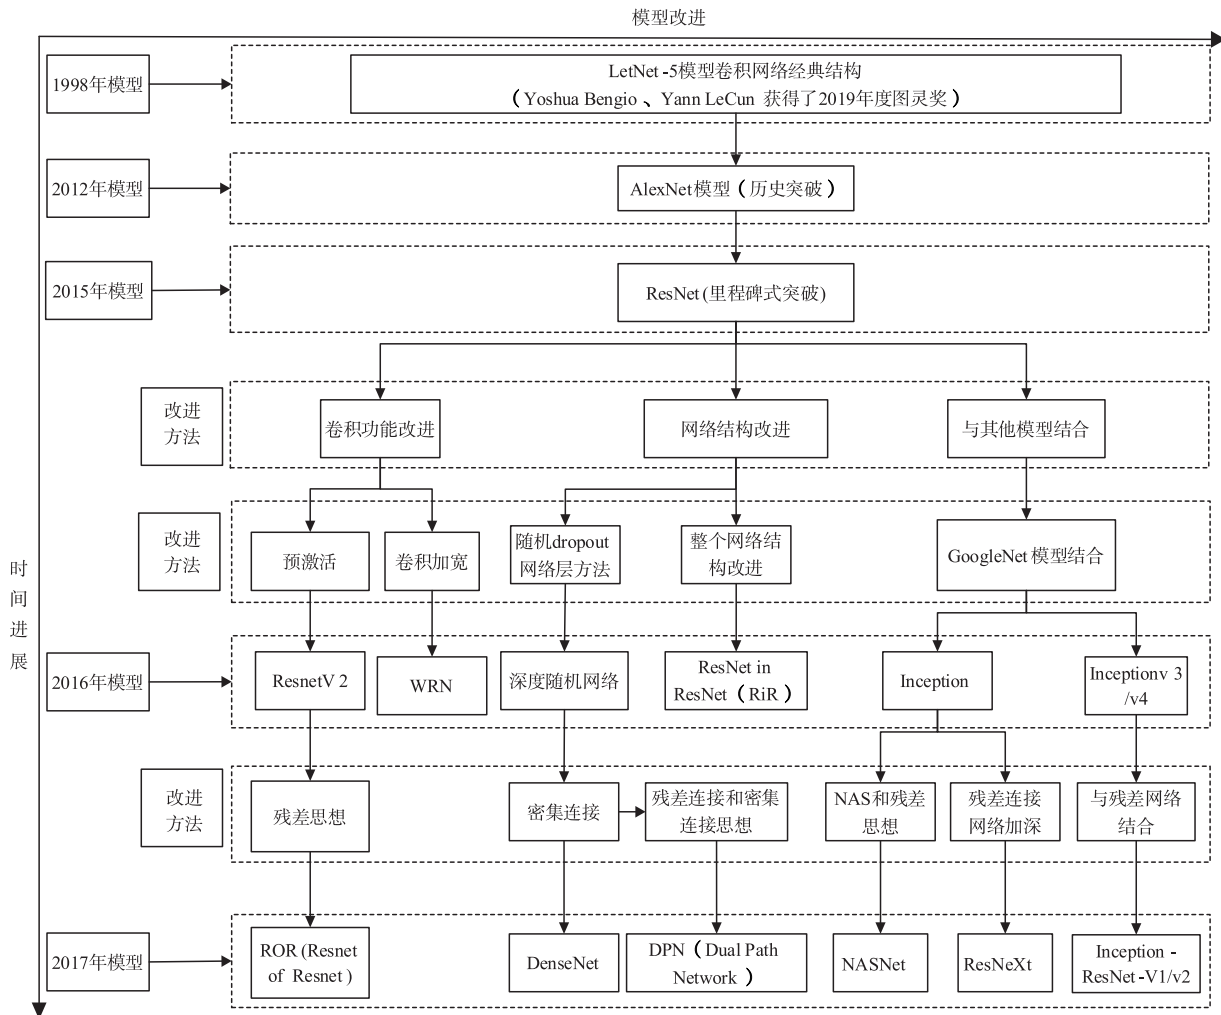


图3 残差神经网络模型改进图

#### (1) 基础模型

1998 年, Lecun Y<sup>[13]</sup> 提出 LeNet-5 模型, 网络中采用的卷积层、池化层、全连接层成为现代 CNN 网络的基本结构. 2012 年, Krizhevsky A<sup>[14]</sup> 提出了 AlexNet 网络, 奠定了现代深度神经网络结构的基础. 2014 年, Szegedy C<sup>[15]</sup> 提出 GoogLeNet 网络, 通过增加网络复杂度增强特征表达能力, 使得卷积网络达到新高度. 2015 年, 何凯明<sup>[2]</sup> 提出残差神经网络, 解决了网络加深性能退化问

题, 在深度卷积网络发展中具有里程碑式意义.

#### (2) 卷积功能改进

2016 年何凯明<sup>[11]</sup> 证明了残差结构有效性, 在此基础上提出 ResNetV2, ResNetV2 对 ResNet 残差单元进行优化, 具有网络容易训练, 泛化能力强的特点. 2017 年 Ke Zhang<sup>[16]</sup> 认为通过简单的堆叠残差块构建的网络会限制其优化能力, 为挖掘残差神经网络的优化能力, 提出 RoR (ResNet of ResNet), RoR 通过优化残差映射的

残差映射代替原始残差映射,加强网络学习能力.

随着网络的增加,残差神经网络会出现特征重用减少的问题,导致网络训练速度变慢,2016 年 Sergey<sup>[17]</sup>提出了宽残差神经网络(WRN: Wide Residual Network),通过减小网络的深度,增大网络的宽度,提高训练速度.实验表明 WRN 效果优于残差神经网络.

### (3) 网络结构改进模型

2016 年, Sasha Targ<sup>[18]</sup>对 ResNet 和标准的 CNN 进行了推广提出广义残差神经网络(RiR: ResNet in ResNet), RiR 保留了残差连接的优化特性,同时提高网络表达能力、减小去除冗余信息的难度.针对残差神经网络训练周期较长,在实际应用成本高的问题,2016 年, Gao Huang<sup>[19]</sup>提出深度随机神经网络,随机 dropout 中间层的方法显著提高残差神经网络的泛化能力,减少训练时间.深度随机神经网络在训练过程中,随机 dropout 很多层,却不影响算法的收敛性,说明残差神经网络具有冗余性.基于深度随机神经网络的结论,2017 年, Gao Huang<sup>[20]</sup>又提出 DenseNet, DenseNet 通过减少每层计算量以及重复利用特征,使得网络比残差神经网络更高效.2017 年 Yunpeng Chen<sup>[21]</sup>在深入讨论残差神经网络和 Densenet 优缺点后,认为残差神经网络是

DenseNet 在参数跨层共享时的特例,基于该结论,提出双通道网络(DPN: Dual Path Network), DPN 融合残差神经网络和 Densenet 优点,实现高性能、低资源功能.

### (4) 与其他模型结合

2016 年, Szegedy C<sup>[22,23]</sup>改进 GoogLeNet 提出 InceptionV3/V4 网络, InceptionV3 将卷积非对称分解,减小计算量,加深网络深度. InceptionV4 是对 InceptionV3 的参数优化的改进,将 Inception-V3/V4 网络融入残差思想得到 Inception-Resnet-V1/V2 模型,加速网络训练.2017 年, Barret Zoph<sup>[24,25]</sup>在 GoogLeNet 基础上使用强化学习方法提出了 NASNet 网络,解决了 NAS 无法应用到大数据集上的问题.针对提高网络准确率,除了网络加宽或加深, Saining Xiet<sup>[26]</sup>提出了 ResNeXt 网络,该网络在不增加参数复杂度的前提下提高网络准确率,减少参数数量.

## 4 残差神经网络结构改进

残差神经网络结构改进包括卷积层、池化层、残差单元、全连接层以及整个网络.由于各层的作用不同,本节从这 5 个方面分别总结改进方法,如图 4 所示.

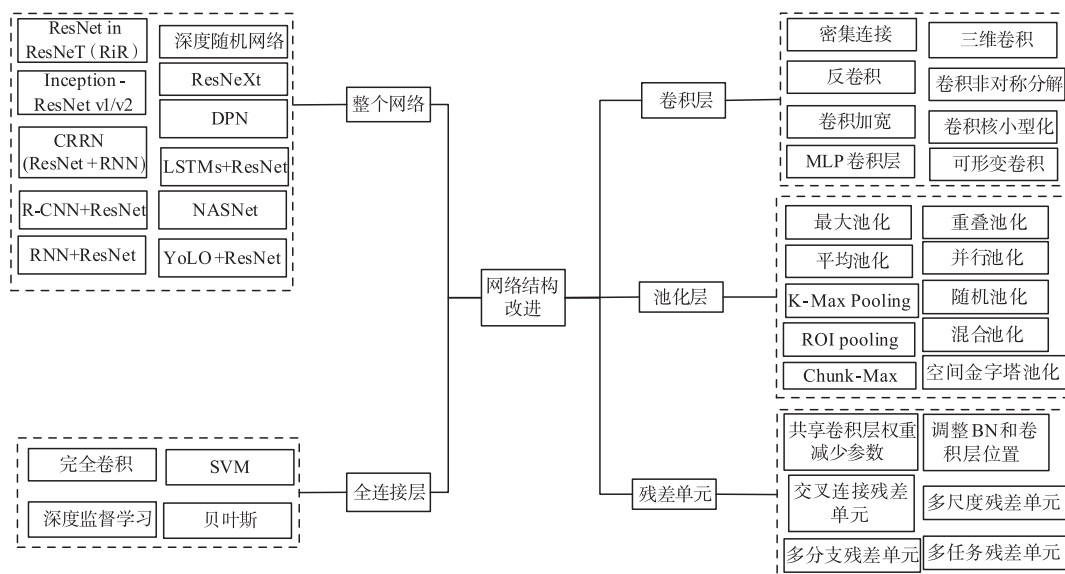


图4 残差神经网络结构改进图

### 4.1 卷积层

卷积核的本质是特征提取,通过“局部连接”和“权值共享”特性进行特征提取.通过卷积核对前一层输入图像做卷积运算得到的多个特征图,从而达到特征提取目的.卷积层改进有 8 种方法:卷积核小型化、卷积非对称分解、MLP 卷积层、卷积加宽、可形变卷积、密集连接、反卷积运算、三维卷积.具体如下:

第一,卷积核小型化是在网络中采用更小卷积核,

有利于减小参数,降低计算量.VGG<sup>[27]</sup>采用堆叠的  $3 \times 3$  的卷积取代 AlexNet 模型中的  $7 \times 7$  的卷积,减小参数数量.

第二,卷积非对称分解是 Szegedy C<sup>[24]</sup>在 InceptionV3 网络中提出,它是将  $n \times n$  卷积核分解  $1 \times n$  和  $n \times 1$  的卷积核,其作用加深网络,并减小计算量.

第三,MLP 卷积层是 Lin M<sup>[28]</sup>在 NIN 网络中提出的采用微神经网络(MLP 卷积层)代替传统卷积神经网络

络的卷积层。

第四,卷积加宽是 Zagoruyko<sup>[17]</sup>提出的通过增加卷积通道的数量来使模型变得更宽,其作用降低层数、加快计算速度,但并没有减少模型参数。

第五,可变形卷积是戴吉峰<sup>[29]</sup>在卷积层中引入学习空间几何形变的能力得到,对卷积核每个采样点的位置都增加偏移量,使得卷积核在当前位置附近随意的采样,解决了具有空间形变的图像识别任务。

第六,DenseNet 网络<sup>[20]</sup>的密集连接是将任意两个卷积层之间进行连接,有效地减少网络参数规模,达到减轻过拟合的效果。

第七,反卷积(转置卷积)通过反卷积将卷积得到的特征还原到像素空间,用以可视化卷积操作提取的特征。彭亚丽<sup>[30]</sup>在图像超分辨率算法方面使用深度反卷积神经网络,采用反卷积层对低分辨率图像进行上采样处理,使用残差学习降低网络复杂度。

第八,卷积是在二维图像上进行卷积,三维卷积是以立体卷积块的形式进行卷积。Hao Chen<sup>[31]</sup>提出的改进的残差神经网络(VoxResNet)用于 3D 核磁共振图像分割,使用三维卷积充分利用了不同模态的互补信息和不同尺度的特征,取得良好的分割结果。

## 4.2 池化层

池化层一般没有参数,其作用是对卷积层的特征进行“二次”提取。池化层保留主要特征的同时减少参数和计算量,防止过拟合现象的发生。池化主要的作用是提供了较强的鲁棒性。池化层的改进主要有均值池化、最大池化、随机池化、重叠池化、空间金字塔池化、ROI 池化、K-Maxing 池化、Chunk-Max 池化、混合池化、并行池化等 10 种方法。具体如下:

第一,在池化操作中,均值池化、最大池化、随机池化为常用方法;以步长为 2,池化窗口为  $2 \times 2$  为例,均值池化取 4 个特征值求平均,最大池化指取 4 个值中的最大值,随机池化指随机选择 4 个特征值的一个。

第二,Krizhevsky A<sup>[14]</sup>在 AlexNet 网络中采用重叠池化,在池化过程会有重叠区域,此方法提升预测精度并减缓过拟合问题。

第三,何凯明<sup>[32]</sup>提出的空间金字塔池化把任何尺度的图像的卷积特征转化成相同维度,让残差神经网络处理任意尺度的图像,具有重要意义。

第四,戴吉峰<sup>[29]</sup>采用 ROI 池化输入特征图尺寸不固定,但是输出特征图尺寸固定并极大地提高了处理速度。

第五,Nal Kalchbrenner<sup>[33]</sup>对最大池化改进的 K-Max Pooling 是把所有前  $k$  大的特征值连接成一个特征向量,而 Chunk-Max Pooling 把特征向量进行分段在每个分段里取最大特征值并拼接成一个特征向量,K-Max

Pooling 是全局特征提取方式,而 Chunk-Max Pooling 是局部特征提取方式。

第六,Zhiqiang Tong<sup>[34]</sup>使用混合池化方法随机选择每个池化层中的最大池化或平均池化,混合池化的特征为每个卷积层控制选择两种合并方法之一的概率,混合池化提高了卷积神经网络的泛化能力。

第七,张振焕<sup>[35]</sup>在解决多类别服装分类问题时,采用“最大池化 + 卷积层”的并行化模块的池化结构,卷积层加入进行特征学习,解决特征信息丢失的问题;最大池化层提取最大值有利于学习图像的纹理分布特征。

## 4.3 残差单元

残差单元包括相邻堆叠的卷积层进行残差连接,通过残差单元结构可以对网络进行有效的训练,很好地解决退化问题,加深网络层数并提高训练效果。残差单元的改进主要有多尺度残差单元、多分支残差单元、交叉连接的残差单元、共享卷积层权重减少参数、多任务残差单元、预激活残差单元 6 种方法。具体如下:

第一,多尺度残差神经网络可以灵活处理不同尺度的目标和不同精度的超分辨率任务,提取丰富的尺度特征提高网络性能。汪家明<sup>[36]</sup>采用多尺度残差深度神经网络提取低分辨率卫星图像的多尺度特征,对不同尺度特征建立自适应深度神经网络,然后使用融合网络进行残差融合,融合不同尺度高频信息,最终生成高分辨卫星图像。

第二,多分支残差神经网络可以缓解消失梯度问题,提高网络结构的拟合能力。Yifeng Xu<sup>[37]</sup>提出具有多分支残差神经网络架构,随机函数和多分支网络的结构提高网络拟合能力。

第三,交叉连接的残差块可以增加不同网络层之间的信息流。Linlin Shen<sup>[38]</sup>提出 HEp-2 细胞分类的深交叉残差神经网络,基于交叉连接的残差块增加不同网络层之间的信息流并取得较好实验效果。

第四,残差单元共享卷积层权重减少参数比残差神经网络更有效。Alexander<sup>[39]</sup>提出减少网络冗余信息的方法,在相同的空间尺度下,残差块之间共享卷积层的权值,共享网络的训练方式与常用的残差神经网络完全相同;在涉及较少参数的情况下,比具有相同数量参数的残差神经网络更有效。

第五,多任务残差同时进行不同任务检测。陈良甫<sup>[40]</sup>提出多任务残差神经网络,在残差神经网络结构中利用编码特征,同时作为语义分割和物体检测任务的输入,多任务模型一方面通过重复利用编码特征,提高了计算效率;另一方面,降低网络模型过拟合。

第六,何凯明<sup>[11]</sup>在 ResNetV2 网络中调整 BN 和卷积层位置实现预激活方式使得网络结构达到最优。戴

加明<sup>[41]</sup>在星系形态分类中采用预激活方式,即用 BN-ReLU-Conv 取代传统的 Conv-BN-ReLU 方式改进残差单元,减少了网络深度,并增加了网络宽度.

#### 4.4 全连接层

全连接层在整个神经网络中起到“分类器”的作用.如果说卷积层、池化层和激活函数层等操作是将原始数据映射到隐层特征空间的话,全连接层则起到将学到的“分布式特征表示”映射到样本标记空间的作用,能达到训练分类器、学习目标的全局特征的目的,大大减少特征位置对分类带来的影响.在实际使用中,全连接层可由卷积操作实现.全连接层总结 4 种方法:完全卷积层替代全连接层,SVM,贝叶斯,深度监督学习.具体如下:

第一,完全卷积网 (FCN)<sup>[42]</sup>是把最后的全连接层换成卷积层,使其恢复到输入图像相同的尺寸,从而可以对每个像素都产生了一个预测,同时保留了原始输入图像中的空间信息.

第二,SVM 是在分类与回归分析中分析数据的监督式学习模型.SVM 可以将复杂数据进行转化,根据输出结果进行有效分类.Sreela<sup>[43]</sup>等在对静止图像进行动作识别时提出了利用残差神经网络和支持向量机 (SVM) 的深神经网络,采用残差神经网络进行特征提取,SVM 进行分类的图像动作识别模型取得良好效果.

第三,贝叶斯方法用于训练神经网络各个层之间的权重和偏置分布.Dandan Zhu<sup>[44]</sup>等在凸目标的检测方面采用贝叶斯融合局部层面和全局层面的特征,得到最终的显著性图像.

第四,深度监督算法是对神经网络框架进行深度监控,直接指导网络上下级的训练,进一步提升分类性能.Haijun Lei<sup>[45]</sup>采用深度监督学习算法结合深度残差神经网络在医学图像领域 HEp-2 细胞图像进行分类,来提取丰富的判别特征.

#### 4.5 整个网络

在残差神经网络发展的基础上,为了对网络进行优化,对整个网络进行改进.本文共总结 11 种残差神经网络结构: RiR、Inception-ResNetV1/V2、ResNeXt、NAS-Net、LSTM + ResNet、深度随机网络、DPN 网络、CRRN、R-CNN + ResNet、RNN + ResNet、YOLO + ResNet.具体如下:

第一,广义残差神经网络<sup>[18]</sup>架构的模块化单元是一个并行结构的广义残差块,并行结构包含了一个残差通道和一个瞬变通道,残差通道采用残差神经网络的恒等映射连接,瞬变通道采用标准的卷积层.

第二,Inception-ResNet-v1/v2<sup>[24]</sup>将 Inception-v3/v4 将残差神经网络的思想进行融合,分别得到了 Inception-ResNet-v1/v2 两个模型,不仅提高了分类精度而且

训练的稳定性也得到增强.

第三,ResNeXt<sup>[26]</sup>同时采用 VGG 堆叠的思想和 Inception 的分割-转换-融合的思想,实现可较强扩展性,在增加准确率的同时基本不改变模型的复杂度.

第四,NASNet<sup>[25]</sup>采用残差神经网络和 Inception 等成熟的网络拓扑结构减少了网络结构优化的搜索空间.

第五,残差神经网络和双向 LSTMs 可以实现语音识别.Themos Stafylakisa<sup>[46]</sup>提出了一种基于残差神经网络、具有时空输入层和双向 LSTMs 的语音识别的深度学习体系结构在实验中取得优越成绩.

第六,随机深度网络在其训练过程中采用随机 dropout 一些中间层的方法改进残差神经网络.在训练时达到网络较深,训练时间较少效果,提高残差神经网络的泛化能力,随机深度网络<sup>[19]</sup>是残差神经网络变形.

第七,双通道网络<sup>[21]</sup>结合残差神经网络和 DenseNet 两者的优点,残差神经网络通过跨层参数共享和保留中间特征的方式降低特征冗余度,重复利用已有特征,缺点是难以利用高层信息再发掘底层特征;DenseNet 有效地利用高层信息再次发掘底层新特征,缺点是特征冗余;双通道网络结合两者的优点实现高性能、低资源占用的网络结构.

第八,Hoang Ngan Le T<sup>[47]</sup>在场景标注中提出了上下文递归残差神经网络 (CRRN),它能够同时处理丰富的视觉信息和远程上下文建模完全端到端深度网络,在四个数据集取得良好成绩.

第九,Hyojoo Son<sup>[48]</sup>对建筑工人在不同姿态和背景下的图像检测采用残差神经网络和 R-CNN 结合的深度网络进行检测,实验取得良好效果.

第十,Junbo Zhang<sup>[49]</sup>在预测城市每个区域的两种人群流动(即流入和流出)算法方面设计端到端的 ST-ResNet 结构,使用残差神经网络框架来模拟人群流量的时间贴适度、周期和趋势特性;该结构采用残差神经网络和 RNN 结合方式,实验表现良好.

第十一,郝旭政<sup>[50]</sup>针对行人特征提出一种融合深度残差神经网络和 YOLO 方法的行人检测和识别的方法,该方法拥有良好的实时性和泛化能力,实用性强.

## 5 残差神经网络在医学图像领域应用

随着大规模图像数据<sup>[12]</sup>的产生和计算能力的快速发展,尤其是残差神经网络在计算机视觉和图像处理领域取得了突破性成果,其强大的特征学习能力引起了研究者关注,并将其应用于医疗图像领域.2017 年 Litjens G<sup>[5]</sup>对深度学习在医学图像分类、检测和分割、配准、和检索等方面的研究进行了较全面的归纳总结.目前,医学临床需求也推动着医学图像计算机辅助诊

断的发展,郑光远<sup>[51]</sup>指出计算机辅助诊断能够提高诊断的准确性,减少假阳性的产生,为医生提供有效的诊断决策支持;不仅能够提高处理效率,而且为后续医生进行病情分析提供辅助. 残差神经网络的实用性在医学图像应用领域包括图像识别、分割、配准、重建、融合等方面,但其技术研究和改进主要集中在图像识别和图像分割两个方面;因此,本节从医学图像识别和分割两个方面总结,希望为临床医护人员提供相关的帮助.

### 5.1 医学图像分类识别

医学图像分类识别是医学图像处理的主要方面,临床医生常需要借助医学图像来辅助诊断人体内是否有病灶,并对病灶的轻重程度进行量化分级,因此自动识别图像中的病灶区域和正常组织器官是医学图像分析的基本任务,通过图像识别,能辨别出人体组织器官中肿瘤的良恶性、检测结节等状态以方便医生进行诊断治疗. 本节从残差神经网络模型的改进和残差神经网络与其他方法的结合两个角度对医学图像识别方法进行总结,如图5所示.

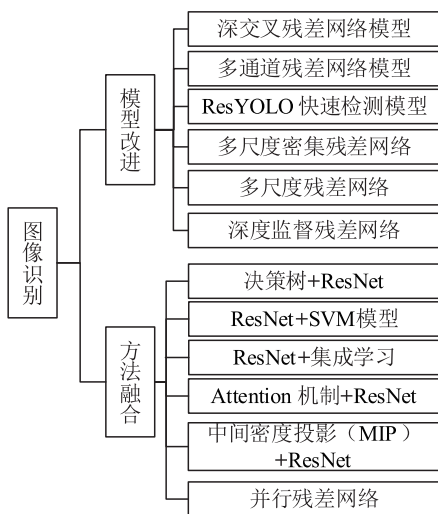


图5 基于残差神经网络医学图像分类识别改进

#### 5.1.1 残差神经网络模型改进

残差神经网络由于其实用性和可扩展性在识别医学图像方面逐渐被广泛应用,目前采用主要方法是对残差神经网络模型的改进和基于网络模型结合其他算法的改进;在医学图像领域中,残差神经网络模型的改进主要有深度监督残差神经网络、深交叉残差神经网络、多尺度残差神经网络、多尺度密集残差神经网络、多通道残差神经网络、ResYOLO快速检测网络共6种方法. 具体如下:

第一,Haijun Lei<sup>[45]</sup>采用深度监督学习算法结合深度残差神经网络在医学图像领域 HEp-2 细胞图像进行分类,来提取丰富的判别特征.

第二,深交叉残差神经网络通过交叉连接的残差

块,以增加不同网络层之间的信息,优化网络结构;Linlin Shen<sup>[38]</sup>提出 HEp-2 细胞分类的深交叉残差神经网络(DCRNet; Deep Cross-Residual Network),基于交叉连接的残差块增加不同网络层之间的信息流并取得较好实验效果.

第三,多尺度特征融合的网络针对同一物体在不同图像上呈现尺度大小不同的问题,可以分割出任意尺度物体. 刘振丙<sup>[52]</sup>提出多尺度残差神经网络(MSResnet),采用不同大小的卷积核对图像进行多尺度信息采集,并对神经网络进行残差学习,该方法实现多尺度特征学习,较传统深度卷积网络分类效果良好.

第四,应自炉<sup>[53]</sup>在图像超分辨率重建方面,采用多尺度密集残差网络能够较好地恢复低分辨率图像的边缘和纹理信息.

第五, Songtao Guo<sup>[54]</sup>针对黑色素瘤检测的皮肤病变分析中采用多通道残差神经网络,其效果优于原始残差神经网络.

第六, Ruikai Zhang<sup>[55]</sup>在结肠镜检查时训练 ResYOLO 的快速目标检测算法,对 ResYOLO 给出的检测结果进行细化能够检测出具有息肉的图像.

#### 5.1.2 残差神经网络与其他方法融合

除了对 ResNet 本身的改进方法,ResNet 与其他方法相结合的方法在临床上的应用减少医生工作量,提高效率. 本文共总结了6种改进方法:决策树+ResNet、并行残差神经网络、Attention机制+ResNet、集成学习+ResNet、中间密集投影+ResNet、SVM+ResNet. 残差神经网络和决策树、支持向量机(SVM)算法结合的神经网络作为分类器,进行特征提取的图像识别模型可以提高算法的准确率. 具体如下:

第一,Ziba Gandomkar<sup>[56]</sup>利用深层残差神经网络对乳腺组织病理学图像进行多分类问题时,将恶性图像细分为4个癌症亚型,良性图像分为4个亚型,最后,通过使用元决策树将不同放大因子处理后的图像的输出组合起来进行分类.

第二,Feng Sha<sup>[57]</sup>在超分辨率图像处理上对分支层进行分类,通过并行局部残差学习使系统训练速度加快,提高图像质量.

第三,姚宇瑾<sup>[58]</sup>使用三维全卷积网络与基于注意力机制(Attention)的多尺度三维残差神经网络相结合的方法检测肺结节,提高检测的灵敏度并有效控制假阳性.

第四,胡海根<sup>[59]</sup>针对黑色素瘤分类识别任务中存在对比度低、信息干扰大等问题,采用基于掩盖的数据增强与深度残差神经网络相结合的集成分类方法,该集成分类模型弥补单一残差神经网络在黑色素瘤分类中的缺陷.

第五,戴焱均<sup>[60]</sup>针对肺结节良恶性分类问题,采用中间密度投影方法将肺结节的三维信息输入 DenseNet 模型进行训练,改进后模型判断良恶性肺结节准确率较高。

第六,李航<sup>[61]</sup>针对黑色素瘤识别问题,采用残差神经网络提取皮肤病变图像特征,用 SVM 对特征进行分类,该方法表达特征区分性能更强。

## 5.2 医学图像分割

ResNet 在图像分割中的应用是医学图像处理的另一重要领域,医学图像的感兴趣区分割研究,是医学图像分析中最重要的基础,也为图像引导手术、放疗计划和治疗评估<sup>[12]</sup>等重要临床应用奠定了最根本的基础。有效、自动的器官分割具有非常大的挑战性:各个脏器之间的亮度差异不明显、与周围脏器相连且边界模糊,此外还存在图像伪影、噪声等干扰因素;传统的分割算法难以精确分割处理图像,残差神经网络应用使得医学图像分割效果提升。目前对医学图像分割主要总结 7 种模型:DenseNet + FCN、全卷积多尺度残差神经网络、多重监督残差神经网络、完全卷积残差神经网络、U-NET + ResNet、RU-Net 和 R2U-Net、U-NET + DenseNet。如图 6 所示。

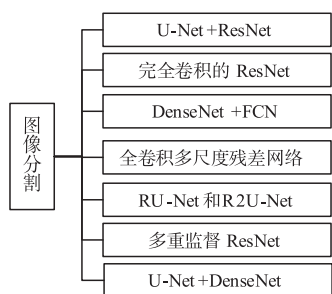


图6 基于残差神经网络医学图像分割改进

医学图像分割是医学图像处理与分析领域的复杂而关键的步骤,其目的是将医学图像中具有某些特殊含义的部分分割出来,并提取相关特征,为临床诊疗和病理学研究提供可靠的依据,辅助医生做出更为准确的诊断。医学图像分割是图像分割领域的难题<sup>[62]</sup>,医学图像具有较高的复杂性且缺少简单的线性特征;此外分割结果的准确率还受到部分容积效应、灰度不均匀性、伪影、不同软组织间灰度的接近性等因素的影响。因此完成医学图像的精确分割往往需要与其他方法相结合,通过图像与计算机技术相结合,能够辅助临床医师发现病灶,并显示分离,提高诊断精确性。目前研究人员所面临的难题仍是数据的获取、标注以及医学知识技术的转化等一系列相关技术问题。

第一,Mahendra Khened<sup>[63]</sup>采用基于 DenseNet 的心脏分割 FCN 体系结构用于心脏疾病分割,该网络是全

卷积多尺度残差神经网络,同时也是端到端学习和残差神经网络结合的分割框架;该框架计算效率较高,可用于临床应用的计算机辅助诊断。

第二,Rui Zhang<sup>[64]</sup>在 CT 图像骨肉瘤分割方面提出多重监督残差神经网络,在残差神经网络中增加了三个受监督的侧输出模块,浅边输出模块提取图像的边缘特征和纹理特征等形状特征,深层输出模块提取语义特征。

第三,Juan Mo<sup>[65]</sup>在渗出液的糖尿病黄斑水肿视网膜图像采用完全卷积的残差神经网络,它融合了多层次的层次化信息,以快速准确的分割渗出物。

第四,Guofeng Tong<sup>[66]</sup>在肺结节分割问题中提出了一种改进的基于 U-NET 网络的肺结节分割算法,引入残差思想,提高网络训练效果。

第五,Alom<sup>[67]</sup>将 U-Net、残差神经网络结构与循环神经网络结构结合,提出了 RU-Net 和 R2U-Net,并使用该网络进行视网膜图像中的血管分割、皮肤癌分割和肺损伤分割。

第六,徐光柱<sup>[68]</sup>提出基于 U-Net 与 DenseNet 相结合的视网膜血管提取方法,采用基于 U-Net 网络中的层次化对称结构和 DenseNet 网络中的密集连接方式的深度神经网络模型用于视网膜血管精准提取。

## 6 总结与展望

本文阐述残差神经网络的基本结构和工作原理,以时间为顺序总结了残差神经网络在模型方面发展,在结构优化方面进行归纳;最后,将 ResNet 应用到医学图像处理领域,主要从图像识别和图像分割两方面探讨残差神经网络在医学图像中的应用,为临床计算机辅助诊断提供参考。

深度学习在医学图像未来的发展方向应集中以下三个方面:

第一,多源异构数据具有丰富语义信息;构建融合多源数据的泛化模型<sup>[69]</sup>及综合辅助诊断,将帮助医生更好地获得丰富图像信息从而提高诊断效果和效率。

第二,由于大量的临床癌症图像数据缺乏有效的数据标注,发展以非监督(无监督)和弱监督(半监督)学习<sup>[51]</sup>为主的深度学习模型完成数据的自动标注,具有重要的意义。

第三,AI 医疗在国家政策、行业巨大需求的背景下,AI 产业蓬勃发展,互联网+医疗云平台等前沿科技迅速发展,促进了科研与临床实践相结合的研究,为 AI 医疗影像的发展夯实基础。

综上所述,在大数据和 AI 的第四次工业革命的背景下,可预见 AI 技术有望进一步推动医疗水平的发展,取得巨大的医疗效益和社会经济学效益,具有无限

广阔的应用前景.

#### 参考文献

- [1] 肖焕辉,袁程朗,冯仕庭,等. 基于深度学习的癌症计算机辅助分类诊断研究进展[J]. 国际医学放射杂志, 2019,42(1):22-25.  
XIAO Huan-hui, YUAN Cheng-lang, FENG Shi-ting, et al. Research progress of computer aided diagnosis in cancer based on deep learning[J]. Int J Med Radiol, 2019, 42(1):22-25. (in Chinese)
- [2] He K M, Zhang X Y, Ren S Q, Sun J. Deep residual learning for image recognition[A]. Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)[C]. Las Vegas, NV, USA; IEEE, 2016. 770-778.
- [3] 田娟秀,刘国才,谷珊珊,等. 医学图像分析深度学习研究方法研究与挑战[J]. 自动化学报, 2018,44(3):401-424.  
TIAN Juan-xiu, LIU Guo-cai, GU Shan-shan, et al. Deep learning in medical image analysis and its challenges[J]. Acta Automatica Sinica, 2018,44(3):401-424. (in Chinese)
- [4] Wells III W M. Medical image analysis-past, present, and future[J]. Medical Image Analysis, 2016,33:4-6.
- [5] Geert Litjens, Thijs Kooi, Babak Ehteshami Bejnordi, et al. A survey on deep learning in medical image analysis[J]. Medical Image Analysis, 2017,42:60-88.
- [6] AI 医疗影像辅助诊断系统发展研究报告[R]. 海松医疗基金, <http://www.oceanpinecap.com/documents/view20180205.pdf>.
- [7] Andreas Maier, Christopher Syben, Tobias Lasser, et al. A gentle introduction to deep learning in medical image processing[J]. Computer Vision and Pattern Recognition, 2019,29(2):86-101.
- [8] Nibali A, He Z, Wollersheim D. Pulmonary nodule classification with deep residual networks[J]. Int J Comput Assist Radiol Surg, 2017,12:1799-1808.
- [9] 亢寒,张荣国,陈宽. 基于深度学习的医学图像分割技术[J]. 人工智能, 2018,4:30-37.
- [10] Michal Drozdal, Eugene Vorontsov, Gabriel Chartrand, et al. The importance of skip connections in biomedical image segmentation[J]. arXiv Preprint, 2016, arXiv:1608.04117.
- [11] He K, Zhang X, Ren S, et al. Identity mappings in deep residual networks[A]. Proceedings of the 2016 Computer Vision-ECCV 14th European Conference[C]. Amsterdam, Netherlands, 2016. 630-645.
- [12] 梁蒙蒙,周涛,张云飞,等. 卷积神经网络及其在医学图像分析中的应用研究[J]. 生物医学工程学杂志, 2018,35(6):977-985.  
LIANG Meng-meng, ZHOU Tao, ZHANG Fei-fei, et al. Research on convolutional neural network and its application on medical image[J]. Journal of Biomedical Engineering, 2018,35(6):977-985. (in Chinese)
- [13] Lecun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition[J]. IEEE, 1998,86(11):2278-2324.
- [14] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks[A]. International Conference on Neural Information Processing Systems[C]. Lake Tahoe, USA; Curran Associates, 2012. 1097-1105.
- [15] Szegedy C, Liu W, Jia Y Q, et al. Going deeper with convolutions[A]. Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition[C]. Boston, MA, USA; IEEE, 2015. 1-9.
- [16] Ke Zhang, Miao Sun, Tony X, et al. Review: RoR-ResNet of ResNet/Multilevel ResNet (Image Classification)[J]. arXiv Preprint, 2017, arXiv:1608.02908.
- [17] Zagoruyko S, Komodakis N. Wide residual networks[A]. Proceedings of the 2016 British Machine Vision Conference[C]. York, UK; BMVC, 2016. 1-12.
- [18] Sasha Targ, Diogo Almeida, Kevin Lyman. Resnet in resnet: generalizing residual architectures[J]. arXiv Preprint, 2016, arXiv:1603.08029.
- [19] Gao Huang, Yu Sun, Zhuang Liu, et al. Deep networks with stochastic depth[J]. arXiv Preprint, 2016, arXiv:1603.09382.
- [20] Gao Huang, Zhuang Liu, Laurens van der Maaten, et al. Densely connected convolutional networks[J]. arXiv Preprint, 2017, arXiv:1608.06993.
- [21] Yunpeng Chen, Jianan Li, Huaxin Xiao, et al. Dual path networks[J]. arXiv Preprint, 2017, arxiv:1707.01629.
- [22] Szegedy C, Vanhoucke V, Ioffffe S, et al. Rethinking the inception architecture for computer vision[A]. Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition[C]. Las Vegas, NV, USA; IEEE, 2016. 2818-2826.
- [23] Szegedy C, Ioffffe S, Vanhoucke V, et al. Inception-v4, Inception-ResNet and the impact of residual connections on learning[J]. arXiv Preprint, 2016, arXiv:1602.07261.
- [24] Zoph B, Le Q V. Neural architecture search with reinforcement learning[J]. arXiv Preprint, 2016, arXiv:1611.01578.
- [25] Barret Zoph, Vijay Vasudevan, Jonathon Shlens, et al. Learning transferable architectures for scalable image recognition[J]. arXiv Preprint, 2017, arXiv:1707.07012.
- [26] Saining Xie, Ross Girshick, Piotr Dollár, et al. Aggregated residual transformations for deep neural networks[J]. arXiv Preprint, 2017, arXiv:1611.05431.
- [27] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[J]. arXiv Preprint, 2014, arXiv:1409.1556.

- [28] Lin M, Chen Q, Yan S C. Network in network[J]. arXiv Preprint, 2014, arXiv:1312. 4400.
- [29] Dai J F, Qi H Z, Xiong Y W, et al. Deformable convolutional networks[J]. arXiv Preprint, 2017, arXiv:1703. 06211.
- [30] 彭亚丽, 张鲁, 张钰, 等. 基于深度反卷积神经网络的图像超分辨率算法[J]. 软件学报, 2018, 29(4): 926 - 934.  
PENG Ya-li, ZHANG Lu, ZHANG Yu, et al. Deep deconvolution neural network for image super-resolution[J]. Journal of Software, 2018, 29(4): 926 - 934. (in Chinese)
- [31] Hao Chen, Qi Dou, Lequan Yu, et al. VoxResNet: Deep voxel wise residual networks for brain segmentation from 3D MR images[J]. Neuro Image, 2018, 170: 446 - 455.
- [32] He K M, Zhang X Y, Ren S Q, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(9): 1904 - 1916.
- [33] Nal Kalchbrenner, Edward Grefenstette, Phil Blunsom. A convolutional neural network for modelling sentences[J]. arXiv Preprint, 2015, arXiv:1404. 2188.
- [34] Zhiqiang Tong, Gouhei Tanaka. Hybrid pooling for enhancement of generalization ability in deep convolutional neural networks[J]. Neurocomputing, 2019, 333: 76 - 85.
- [35] 张振焕, 周彩兰, 梁媛. 基于残差的优化卷积神经网络服装分类算法[J]. 计算机工程与科学, 2018, 40(2): 355 - 360.  
ZHANG Zhen-huan, ZHOU Cai-lan, LIANG Yuan. An optimized clothing classification algorithm based on residual convolutional neural network[J]. Computer Engineering & Science, 2018, 40(2): 355 - 360. (in Chinese)
- [36] 汪家明, 卢涛. 多尺度残差深度神经网络的卫星图像超分辨率算法[J]. 武汉工程大学学报, 2018, 40(04): 439 - 443.  
WANG Jia-ming, LU Tao. Satellite imagery super-resolution algorithm via multi-scale residual deep neural network[J]. Journal of Wuhan Institute of Technology, 2018, 40(04): 439 - 443. (in Chinese)
- [37] Yifeng Xu, Huigang Wang, Xing Liu, et al. An improved multi-branch residual network based on random multiplier and adaptive cosine learning rate method[J]. Journal of Visual Communication and Image Representation, 2019, 59: 363 - 370.
- [38] Linlin Shen, Xi Jia, Yuexiang Li. Deep cross residual network for HEp-2 cell staining pattern classification[J]. Pattern Recognition, 2018, 82: 68 - 78.
- [39] Alexandre Boulch. Reducing parameter number in residual networks by sharing weights[J]. Pattern Recognition Letters, 2018, 103: 53 - 59.
- [40] 陈良甫, 杨曾. 一种基于残差网络的多任务模型[J]. 中国集成电路, 2017, 26(8): 64 - 71.  
CHEN Liang-fu, YANG Zeng. A residual network based multi-task model[J]. China Integrated Circuit, 2017, 26(8): 64 - 71. (in Chinese)
- [41] 戴加明, 佟继周. 基于深度残差网络的星系形态分类[J]. 天文学进展, 2018, 36(20): 385 - 397.  
DAI Jia-ming, TONG Ji-zhou. Galaxy morphology classification with deep convolutional neural networks[J]. Progress in Astronomy, 2018, 36(20): 385 - 397. (in Chinese)
- [42] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation[A]. Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition [C]. Boston, Massachusetts, USA: IEEE, 2015. 3431 - 3440.
- [43] Sreela S R, Sumam Mary Idicula. Action recognition in still images using residual neural network features[J]. Procedia Computer Science, 2018, 143: 563 - 569.
- [44] Dandan Zhu, Ye Luo, Lei Dai, et al. Salient object detection via a local and global method based on deep residual network[J]. Journal of Visual Communication and Image Representation, 2018, 54: 1 - 9.
- [45] Haijun Lei, Tao Han, Feng Zhou, et al. A deeply supervised residual network for HEp-2 cell classification via cross-modal transfer learning[J]. Pattern Recognition, 2018, 79: 290 - 302.
- [46] Themis Stafylakisa, Muhammad Haris Khanab, Georgios Tzimropoulosa. Pushing the boundaries of audiovisual word recognition using residual networks and LSTMs[J]. Computer Vision and Image Understanding, 2018, 176 - 177: 22 - 32.
- [47] Hoang Ngan Le T, Chi Nhan Duong, Ligong Han, et al. Deep contextual recurrent residual networks for scene labeling[J]. Pattern Recognition, 2018, 80: 32 - 41.
- [48] Hyojoo Son, Hyunchul Choi, Hyeonwoo Seong, et al. Detection of construction workers under varying poses and changing background in image sequences via very deep residual networks[J]. Automation in Construction, 2019, 99: 27 - 38.
- [49] Junbo Zhang, Yu Zheng, Dekang Qi, et al. Predicting city-wide crowd flows using deep spatio-temporal residual networks[J]. Artificial Intelligence, 2018, 259: 147 - 166.
- [50] 郝旭政, 柴争义. 一种改进的深度残差网络行人检测方法[J]. 计算机应用研, 2019, 36(6): <http://www.aocmag.com/article/02-2019-06-057.html>.  
HAO Xu-zheng, CHAI Zheng-yi. Improved pedestrian detection method based on depth residual network[J]. Application Research of Computers, 2019, 36(6): <http://www.aocmag.com/article/02-2019-06-057.html>.

- www. arocmag. com/article/02-2019-06-057. html. ( in Chinese)
- [51] 郑光远,刘峡壁,韩光辉. 医学影像计算机辅助检测与诊断系统综述[J]. 软件学报, 2018, 29(5): 1471 - 1514.  
ZHENG Guang-yuan, LIU Xia-bi, HAN Guang-hui. Survey on medical image computer aided detection and diagnosis systems[J]. Journal of Software, 2018, 29(5): 1471 - 1514. ( in Chinese)
- [52] 刘振丙,方旭升,杨辉华,等. 基于多尺度残差神经网络的阿尔茨海默病诊断分类[J]. 山东大学学报(工学版), 2018, 48(06): 1 - 7 + 18.  
LIU Zhen-bing, FANG Xu-sheng, YANG Hui-hua, et al. The diagnosis of Alzheimer's disease classification based on multi-scale residual neural network [J]. Journal of Shandong University ( Engineering Science ), 2018, 48(06): 1 - 7 + 18. ( in Chinese)
- [53] 应自炉,龙祥. 多尺度密集残差网络的单幅图像超分辨率重建[J]. 中国图象图形学报, 2019, 24(3): 0410 - 0419.  
YING Zi-lu, LONG Xiang. Single-image super-resolution construction based on multi-scale dense residual network [J]. Journal of Image and Graphics, 2019, 24(3): 0410 - 0419. ( in Chinese)
- [54] Songtao Guo, Zhouwang Yang. Multi-Channel-ResNet: An integration framework towards skin lesion analysis[J]. Informatics in Medicine Unlocked, 2018, 12: 67 - 74.
- [55] Ruikai Zhang, Yali Zheng, Carmen C, et al. Polyp detection during colonoscopy using a regression-based convolutional neural network with a tracker[J]. Pattern Recognition, 2018, 83: 209 - 219.
- [56] Ziba Gandomkar, Patrick C. Brennan, et al. MuDeRN: Multi-category classification of breast histopathological image using deep residual networks[J]. Artificial Intelligence in Medicine, 2018, 88: 14 - 24.
- [57] Feng Sha, Seid Miad Zandavi, Yuk Ying Chung. Fast deep parallel residual network for accurate super resolution image processing [J]. Expert Systems with Applications, 2019, 128: 157 - 168.
- [58] 姚宇瑾,张利. 基于混合损失联合调优与多尺度分类相结合的肺结节检测算法[J]. 计算机应用研究, 2019, 36(9): <http://www. arocmag. com/article/02-2019-09-020. html>.  
YAO Yu-jin, ZHANG Li. Pulmonary nodule detection via hybrid loss based joint fine-tuning and multi-scale classification[J]. Application Research of Computers, 2019, 36(9): <http://www. arocmag. com/article/02-2019-09-020. html>. ( in Chinese)
- [59] 胡海根,孔祥勇,周乾伟,等. 基于深层卷积残差网络集成的黑色素瘤分类方法[J]. 计算机科学, 2019, 46(5): 248 - 253.  
HU Hai-gen, KONG Xiang-yong, ZHOU Qian-wei, et al. Melanoma classification method by integrating deep convolutional residual network [J]. Computer Science, 2019, 46(5): 248 - 253. ( in Chinese)
- [60] 戴垚均,宋成利,闫士举. 基于密集网络改进的肺结节良恶性分类模型[J]. 中国医学影像技术, 2018, 34(7): 1104 - 1109.  
DAI Yao-jun, SONG Cheng-li, YAN Shi-ju. Benign or malignant lung nodules classification model based on modified DenseNet [J]. China J Med Imaging Technol, 2018, 34(7): 1104 - 1109. ( in Chinese)
- [61] 李航,余镇,倪东,等. 基于深度残差网络的皮肤镜图像黑色素瘤的识别[J]. 中国生物医学工程学报, 2018, 37(3): 275 - 282.  
LI Hang, YU Zhen, NI Dong, et al. Melanoma recognition in dermoscopy images via deep residual network [J]. Chinese Journal of Biomedical Engineering, 2018, 37(3): 274 - 282. ( in Chinese)
- [62] 罗希平,田捷. 一种改进的交互式医学图像序列分割方法[J]. 电子学报, 2003, 31(1): 30 - 32.  
LUO Xi-ping, TIAN Jie. A modified interactive segmentation of medical image series [J]. Acta Electronica Sinica, 2003, 31(1): 30 - 32. ( in Chinese)
- [63] Mahendra Khened, Varghese Alex Kollerathu, Ganapathy Krishnamurthi. Fully convolutional multi-scale residual DenseNets for cardiac segmentation and automated cardiac diagnosis using ensemble of classifiers [J]. Medical Image Analysis, 2019, 51: 21 - 45.
- [64] Rui Zhang, Lin Huang, Wei Xia, et al. Multiple supervised residual network for osteosarcoma segmentation in CT images [J]. Computerized Medical Imaging and Graphics, 2018, 63: 1 - 8.
- [65] Juan Mo, Lei Zhang, Yangqin Feng. Exudate-based diabetic macular edema recognition in retinal images using cascaded deep residual networks [J]. Neurocomputing, 2018, 290: 161 - 171.
- [66] Guofeng Tong, Yong Li, Huairong Chen, et al. Improved U-NET network for pulmonary nodules segmentation [J]. Optik, 2018, 174: 460 - 469.
- [67] Md Zahangir Alom, Mahmudul Hasan, Chris Yakopcic, et al. Recurrent residual convolutional neural network based on U-Net ( R2U-Net ) for medical image segmentation [J]. arXiv Preprint, 2018, arXiv: 1082. 06955.
- [68] 徐光柱,胡松,陈莎,等. U-Net 与 DenseNet 相结合的视网膜血管提取 [J]. 中国图象图形学报, 2019, 24(9): 1569 - 1580.  
XU Guang-zhu, HU Song, CHEN Sha, et al. Retinal blood

vessel extraction by combining U-net and Dense-net[J].  
Journal of Image and Graphics, 2019, 24 (9): 1569 -  
1580. (in Chinese)

[69] 周沛, 陈后金, 于泽宽, 等. 跨模态医学图像预测综述

[J]. 电子学报, 2019, 47(1): 221 - 226.

ZHOU Pei, CHEN Hou-Jin, YU Ze-kuan, et al. Review of  
cross-modality medical image prediction [J]. Acta Elec-  
tronica Sinica, 2019, 47(1): 220 - 226. (in Chinese)

#### 作者简介



**周 涛 (通讯作者)** 男, 1977 年生, 宁夏同心人. 博士, 教授, 硕士生导师, 2010 年于西北工业大学获工学博士学位, 现为北方民族大学计算机学院教授, 主要研究方向为医学图像分析处理、深度学习、大数据、云计算等.  
E-mail: zhoutaonxmu@126.com



**霍兵强** 男, 1994 年生, 河北石家庄人. 硕士, 现为北方民族大学计算机学院研究生, 主研领域: 智能医学影像图像处理, 深度学习.  
E-mail: 2916656832@qq.com



**陆惠玲** 女, 1976 年, 河北定兴县人. 副教授, 硕士, 主要研究医学图像分析处理、机器学习.



**任海玲** 女, 1993 生, 四川人. 现为宁夏医科大学公共卫生与管理学院研究生, 主研领域为智能医学影像图像处理及计算机辅助诊断.  
E-mail: renhailingnxmu@163.com