doi:10.3772/j.issn.1002-0470.2021.11.004

基于多尺度并行深度可拆分的 CNN 新冠肺炎 CT 图像去噪方法 $^{ m O}$

张 硕② 余世明③

(浙江工业大学信息工程学院 杭州 310023)

摘要 目前新冠肺炎(COVID-19)在全球蔓延,为了对新冠肺炎进行早期诊断,同时减轻医护人员的工作压力,使用深度学习对患者胸部电子计算机断层扫描(CT)图像进行分析变得越来越重要。针对肺炎图像中纹理细节较为丰富、边缘结构模糊、极易干扰机器及医生诊断的问题,本文提出一种基于多尺度并行深度可拆分卷积神经网络(MSP-ReC-NN),对新冠肺炎 CT 图像进行去噪处理,提升肺炎图像质量。多尺度特征提取模块从不同尺度提取肺炎图像中的纹理特征细节,采用深浅通道并行方式,分别提取肺炎图像中的高维度以及低维度的特征。为进一步优化网络模型,提出一种拆分卷积方式,可将特征图拆分为两类,一类为主要关注特征,另一类为次要关注特征。使用复杂度高的计算方式从主要关注特征中提取关键信息,对于次要关注特征,则采取复杂度低的计算方式提取补偿信息。通过与非局部均值(NLM)去噪算法、收缩卷积神经网络(SCNN)深度模型对比,以及网络消融实验,可以看出本文提出的模型能有效去除肺炎图像中的噪声,并且可以更好地保留原始图像中的纹理结构细节,为机器以及医生提供更可靠的辅助诊断。

关键词 新冠肺炎(COVID-19)电子计算机断层扫描(CT)图像,图像去噪,多尺度特征, 深浅通道并行,拆分卷积

0 引言

新冠肺炎(COVID-19)已经成为全球大流行病, 对全球经济和人类健康都产生了极其不利的影响。 截至2020年8月1日,全球累计确诊病例已经超过 600万例。医生需要对患者不同进展期进行多次电 子计算机断层扫描技术(computed tomography, CT) 影像检查随访对比,以便对患者的病情发展和治疗 效果进行精准评估。随着确诊人数不断攀升,采用 传统的人工检测肺炎 CT 图像不仅工作量巨大^[1], 而且也难以保证评测准确性。

随着深度学习^[24]不断发展进步,依靠大数据 进行网络学习,已经广泛应用在医学影像分析领域, 并取得了良好成效^[56]。因此使用深度学习对患者 胸部肺炎 CT 图像进行分析,从而缓解医疗资源紧 张以及医生超负荷工作等一系列问题显得尤为重 要。但是肺炎图像中的纹理细节比较复杂,边缘结 构也较为模糊,因此极易干扰机器以及医生的诊 断^[7]。为此,本文提出一种基于多尺度并行深度可 拆分卷积神经网络(multi-scale parallel deep split convolution neural network, MSP-ReCNN),对新冠肺 炎 CT 图像进行去噪处理,提升肺炎 CT 图像质量。

本文借鉴了目标检测^[8]中多尺度^[9]提取信息 的思想,在网络开始训练阶段,使用不同尺寸大小的 卷积核对输入图像进行卷积操作,再将提取出的特 征进行融合。接着将融合后的特征图分别放入深通

① 国家自然科学基金(61772471)资助项目。

② 男,1994 年生,硕士生;研究方向:图像处理;E-mail: zhangshuo4878@163.com。

③ 通信作者, E-mail: ysm@ zjut. edu. cn。 (收稿日期:2020-09-01)

道和浅通道中进行学习。为进一步优化网络模型, 提出了拆分卷积操作,将特征图分为两类,即主要关 注特征和次要关注特征。

在新冠肺炎 CT 图像去噪研究中,本文主要工 作如下。

(1)使用多尺度特征提取模块,从不同尺度提 取图像特征信息。

(2)提出深、浅通道并行方式,分别提取肺炎 CT图像中的高维和低维特征。

(3)提出一种拆分卷积操作,进一步降低网络 参数量,加速模型推理速度,提升网络的去噪精度。

1 相关工作

医学图像去噪因其具有较高的实用价值,在过 去很长一段时间均得到广泛研究。目前医学图像去 噪主要分为两类方法,一类是基于传统技术的图像 去噪方法,另一类是基于人工智能的去噪方法。在 传统图像去噪方法中,文献[10]提出一种基于随机 微分的经验模态分解(empirical mode decomposition, EMD)图像去噪算法,该方法利用随机微分滤波策 略计算出各层滤波结果,最后将结果重组得到去噪 图。文献[11]和文献[12]分别将离散小波技术^[13] 用于医学图像去噪,该方法计算简单,运行速度也较 快,但对医学图像中存在的高斯白噪声去除效果不 好。文献[14] 提出一种非局部均值(non-local mean,NLM)图像去噪算法,该方法通过对图像中每 个像素点设置邻域窗口和搜索窗口,对搜索窗口中 所有像素值进行加权平均处理,并替换原始含噪图 像中的像素值,使目标像素值更接近周围邻域范围 内的像素值。文献[15]将像素离群度与 NLM 相结 合,提出一种 CT 图像去噪方法,可以有效地去除 CT 图像中的噪声。

传统医学图像去噪算法虽然可以在一定程度上 提升医学图像质量,但是往往无法有效抑制医学图 像中的噪声伪影,并且在纹理细节保留情况上也做 的不够理想^[16]。近些年来,深度卷积网络模型被广 泛应用在医学图像去噪领域,该模型不仅关注去噪 能力,而且更关注医学图像纹理细节的保留情况。 — 1146 — 文献[17]提出使用弹性收缩阈值作为激活函数的 收缩卷积神经网络(shrinkage convolutional neural network, SCNN)模型,进行图像去噪。文献[18]提 出一种针对高斯白噪声的去噪卷积神经网络(denosing convolutional neural network, DnCNN)模型, 将残差网络和批量正则化(batch normalization, BN) 技术相结合,可以有效地去除图像中广泛存在的高 斯噪声。文献[19]借鉴了 DnCNN 模型中残差网络 的设计思想,使用池化层,进一步降低了网络参数 量,在低剂量 CT 图像去噪问题上取得了不错的效 果。文献[20,21]提出一种残差编码器-解码器卷积 神经网络(residual encoder-decoder convolutional neural network, RED-CNN)模型,将卷积网络应用到低 剂量 CT 图像去噪问题上,与传统去噪算法进行对 比,在主观和客观评价方面都有所提升。但是新冠 肺炎图像纹理细节较为丰富,边缘轮廓也较为模糊, 对去噪精度与准确度都有非常高的要求,因此本文 针对这一问题,提出了 MSP-ReCNN 模型,通过多尺 度和深浅通道并行的方式可以有效提取网络中细节 特征,提升模型去噪精度。同时使用拆分卷积方式, 进一步优化网络模型、加快模型训练速度、缩短去噪 时间。

2 新冠肺炎 CT 图像去噪方法

本节首先阐述新冠肺炎 CT 图像的去噪过程, 接着,详细介绍模型 MSP-ReCNN 中重要组成模块, 最后引出模型整体结构。

2.1 问题描述

假设含噪肺炎 CT 图像为 X, 干净的 CT 图像设 为 Y, CT 图像中的噪声图像为 V, 可以得到式(1) 如下。

 $X = Y + V \tag{1}$

$$F(X) = Y \tag{2}$$

在传统卷积神经网络中,将含噪肺炎 CT 图像 X 作为网络输入,通过训练模型,直接学习从 X 到 Y 的映射模型式(2)。但是这样直接学习网络映射的 方式,其模型训练起来十分困难,并且去噪精度也不 高,为此本文使用残差学习策略来降低网络学习难 度。将网络的输出与输入构成一个大的残差单元, 让网络实际学习到的映射如式(3)所示,即网络学 习的是图像中噪声分布图像 V。

 $R(X) = X - Y \tag{3}$

通过残差学习方式,可以将直接学习得到的干 净图像映射、转化为学习含噪肺炎图像中的噪声分 布,降低了网络学习难度,并且提升了模型去噪精 度。

2.2 多尺度特征提取模块

在卷积神经网络中,感受野是卷积神经网络中 每一层输出图片对应输入图片上的映射区域。感受 野越大,关注的输入图片的区域也就越大。本文在 图像输入阶段,分别使用3种不同尺度的卷积核 (1×1、3×3、5×5)进行特征提取工作,大的卷积 核对应的感受野也就越大,可以提取大范围内的特 征,小的卷积核则可以提取小范围的细节特征。

使用并行叠加的特征融合方式^[22],将所有特征 图融合在一起,作为深浅通道的输入。如图1所示, 其中 ReLU 层是激活函数层,目的是用来提高模型 的非线性,如式(4)所示。



在实际模型训练中,使用空洞步长为2的5×5 卷积核,在扩大感受野的同时,保持模型参数量不 变。

2.3 深浅通道并行方法

本文使用深浅通道并行的方式来提取新冠肺炎 图像中不同维度的特征信息。其中浅层通道由6层 神经网络构成,主要用于提取低维度的特征信息。 深层通道则由16层神经网络构成,用于提取高维度 的特征信息。使用并行叠加的特征融合方式^[23],将 深浅通道信息进行合并处理。

2.4 拆分卷积操作

为进一步优化网络模型,提出了拆分卷积操作 如图 2 所示。从图像中提出的同一层的特征图往往 会存在相似的结果,出现特征冗余的情况。为此,本 文按照二等分的原则,将每层特征图拆分为两部分, 进行独立卷积操作。使用卷积核大小为 3 × 3 、组数 为 2 的分组卷积对部分特征图进行分组卷积操作, 得到主要关注特征。同时,对剩下的特征图使用卷 积核大小为 1 × 1 的点卷积操作,得到次要关注特 征。接着利用式(5) 在特征图 U_c 上进行全局平均 池化操作,生成每个通道的权重初始值^[24-25],分别 得到 S_1 和 S_2 ,其中 H 和 W 分别代表特征图的高和 宽。

$$S_{c}(x) = F(U_{c}) = \frac{1}{H \times W} \sum_{i=1}^{H} \sum_{j=1}^{W} U_{c}(i, j)$$

$$c \in \{1, 2\} \quad (5)$$

为了能动态地调整每个通道的权重,将生成的 $S_1 和 S_2 堆叠一起,传给全连接层。再使用 Softmax$ 函数,重新生成主要和次要关注特征各个通道的权 $重 <math>\alpha$ 和 β , 如式(6)所示。



$$\alpha = \frac{e^{S_1}}{e^{S_1} + e^{S_2}} \quad \beta = 1 - \alpha \tag{6}$$

经过拆分卷积处理后的网络输出为

$$Y = \alpha \cdot U_1 + \beta \cdot U_2 \tag{7}$$

2.5 MSP-ReCNN 模型整体结构

如图 3 所示,模型 MSP-ReCNN 的整体框架由 4 部分构成。在网络初始阶段使用了多特征提取模 块,使用不同尺寸的卷积核多尺度地提取肺炎 CT 图像中的细节特征。模型的上半部分是 Sconv Block 模块,其中 Sconv 是可拆分卷积操作,BN 是批 量正则化。浅通道模块一共由 6 层网络构成,每次 可拆分卷积操作之后,都会跟着一个 BN 和 ReLU。 深通道模块一共由 16 层网络构成,为降低网络学习 难度,首先使用残差网络,将第1 层可拆分卷积处理 之后的特征直接传给第5、9、13 层。接着使用并行 叠加的特征融合模块,将深浅通道提取出的信息进 行合并。最后再使用一层卷积操作,将特征图转化 为一层的输出图像。为了降低整个网络的学习难 度,将整个网络构成一个大的残差单元,输入与输出 构成一个相减操作,这样就使得网络直接学习肺炎 图像中的噪声分布,而不是直接学习得到干净的去 噪图像。



图 3 MSP-ReCNN 模型

本文使用均方误差作为模型的损失函数,如式(8)所示,其中 *R*(*X_i*)代表网络学习得到的残差 图像块, *X_i* - *Y_i*代表实际残差图像块,也就是标签。

$$Loss_MSE = \frac{1}{N} \sum_{i=1}^{N} \| R(X_i) - (X_i - Y_i) \|_{2}^{2}$$
(8)

模型 MSP-ReCNN 每一层卷积核大小及输出通 道数如表1 所示。其中第1 层是多特征提取层,一 共由48 个1×1 的卷积核、64 个3×3 的卷积核以 及32 个5×5(空洞步长为2)的卷积核构成。深浅 通道中,首先使用可拆分的卷积操作,其中主要关注 - 1148 —

表1 模型 MSP-ReCNN 网络结构参数

卷积层	卷积核	输出通道
第1层	$1 \times 1, 3 \times 3, 5 \times 5$	48,64,32
浅通道	分组卷积:3×3	38
第2~5层	点卷积:1×1	26
深通道	分组卷积:3×3	38
第2~13 层	点卷积:1×1	26
特征融合层	None	64×2
第15 层	3 × 3	1

特征采用组数为2、38个大小为3×3的卷积操作,次要关注特征使用26个1×1大小的卷积核进行特

征补全操作。接着将深浅通道的各 64 个特征层并 行叠加在一起,经过最后一层 1 输出通道的卷积层, 得到残差图像块。

3 实验结果分析

为进一步验证模型 MSP-ReCNN 在新冠肺炎 CT 图像中的去噪效果,本文与传统去噪算法 NLM 以及 基于神经网络的去噪模型 SCNN、DnCNN 的去噪结 果进行了对比分析。同时,本文还使用模型消融实 验,探究了各个方法对去噪结果的影响。

本实验的配置环境为:硬件配置为 Intel(R) Core(TM) i7-7700HQ, CPU 主频为 2.80 GHz, GPU 配置为 Nvidia GeForce GTX 1050;软件环境为 64 位 Windows 操作系统,使用 Pytorch 深度学习框架,在 Pycharm 平台下进行训练和测试。

3.1 实验数据及训练过程

本文使用 COVID-CT 数据集^[26],其中包含 349 张 COVID-19 检测呈阳性的 CT 图像,还有 397 张检 测呈阴性的 CT 图像。如图 4 所示,其中图 4(a)是 阳性的 CT 图像,图 4(b)是阴性的 CT 图像。该数 据中肺部 CT 图像大部分都有明显的斑片状阴影以 及毛玻璃状的浑浊。为了能更明显地显示图片中的 纹理细节,从数据集中剔除分辨率小于 300 × 300 dpi 的 CT 图像,共计得到350张图像。本文从阳性和



(a) 新冠肺炎阳性 CT 图像



(b) 新冠肺炎阴性 CT 图像

图 4 COVID-CT 数据集图像

阴性 CT 图像中各取出 15 张 CT 图像作为测试集, 剩下 320 张作为模型训练数据。同时为丰富训练数 据及降低训练时间,本文对原始数据进行切片处理, 采样图像块大小为 100 × 100 dpi,采样间隔为25 dpi, 共计得到 212 224 个图像块,作为干净的原始图像。

3.2 实验结果对比

本文采用主观以及客观两种评价方法对各个算 法去噪后的 CT 图像进行对比分析。其中主观评价 方法主要是通过分析去噪后图像的整体视觉效果, 以及局部纹理细节的保存情况来评价各个算法的去 噪性能。客观评价是使用一些图像去噪邻域中广泛 认可的客观评价指标,通过计算去噪后的图像与原 图之间的差异性,来客观地分析各去噪算法的能力。 本文采用的图像去噪指标有峰值信噪比(peak signal to noise ratio, PSNR)、均方根误差(root mean square error, RMSE)和结构相似性(structual similarity, SSIM)。PSNR 和 RMSE 是衡量算法去噪能力 的指标,PSNR 值越高,对应算法的去噪能力也就越 好。RMSE 的值越小,则说明对应算法去噪效果越 好。SSIM 是衡量去噪前后两张图像的相似度,取值 范围是[0,1],其值越大,对应算法在保存肺炎 CT 图像纹理细节方面就做得越好。

如图 5 和图 6 所示,从测试集中选取了肺炎阳性 CT 图像和肺炎阴性 CT 图像各一张,并将加噪结果以及本文提出的各个算法的去噪结果进行展示。图5(c)和图6(c)是NLM算法的去噪结果,可以看



(a) 肺炎阳性CT图 (b) 噪声图

(c) NLM



图 5 肺炎阳性 CT 图像去噪结果

— 1149 —





出,该算法去除了大部分的噪声,但依旧有明显的噪 声残留。图5(d)、6(d)和图5(e)、6(e)分别是模 型 SCNN 和模型 DnCNN 的去噪结果。通过与原图 对比可以发现,两者可以很好地去除肺炎 CT 图像 中的噪声,但在纹理细节保存方面做得不好,特别是 肺间的毛玻璃纹理部分都有不同程度的模糊。 图 5(f)、6(f)是本文提出的模型 MSP-ReCNN 的去 噪结果。与其他算法相比,模型 MSP-ReCNN 无论 是在去除噪声方面,还是保留肺部间纹理细节方面 都有更好的表现。

为了进一步证明模型 MSP-ReCNN 保留肺炎 CT 图像纹理细节的能力,本文从测试集中选取了一张 肺炎阳性 CT 图像,并且对去噪结果进行了局部区 域放大处理。图 7(d) 是干净的原始肺炎 CT 局部 区域放大图像。图7(e)对应的是 NLM 算法的去噪 结果,可以看出其局部区域放大图像块中依旧有明 显的噪声残留。图7(f)和图7(g)分别是模型SC-NN 和模型 DnCNN 的去噪结果,从局部区域放大图 像中可以看出,虽然二者噪声去除效果要好于 NLM 算法,但是肺部间毛玻璃结节部分的纹理结构并没 有很好地保留。图7(h)对应的是模型 MSP-ReCNN 的去噪结果图,可以看出其在去除噪声的同时,保留 了肺部间大量的纹理结构细节。



(d) 原图像块



表2是对应去噪算法在测试集上的客观评价指 标的平均值。从表中可以看出,模型 MSP-ReCNN 的客观评价指标相较于 NLM 算法、模型 SCNN 和模 型 DnCNN,都有明显提升。其 PSNR 值比 NLM 算法、 模型 SCNN 和模型 DnCNN 分别提高了 4.0301 dB、 -1150 -

0.4092 dB和 0.2679 dB, SSIM 值则分别提高了 0.1201、0.0484 和 0.0252。这从客观评价方面证明 了模型 MSP-ReCNN 在去除噪声以及保留纹理细节 方面的能力。

(h) MDP-ReCNN

	PSNR/dB	RMSE	SSIM
含噪 CT 图	15.1030	51.3311	0.4673
NLM	29.1894	7.9106	0.7472
SCNN	32.8103	5.1035	0.8189
DnCNN	32.9516	5.1480	0.8421
MSP-ReCNN	33.2195	4.9503	0.8673

表 2 测试集客观评价指标的平均值

3.3 MSP-ReCNN 模型消融实验

为了进一步探究本文提出的多尺度特征提取模块、深浅通道并行策略,以及可拆分卷积操作对模型 MSP-ReCNN带来的影响,本节分别将默认的网络结构做如下改动。

(1)将可拆分卷积全部替换回普通的卷积操作,得到"Without Sconv"模型。

(2)将6层的浅通道模块全部移除,得到"Without shallow channel"模型。

(3)将特征提取模块从默认网络中移除,得到 "Without multiscale moudle"模型。

表3 是修改默认网络模型后,对应的各个模型在 测试集上的客观评价指标的平均值。从表中可以看 出,本文提出的3 种去噪结构对模型去噪结果都有 一定程度的提升。其中可拆分卷积操作可以将 PSNR 提升 0.5648 dB,深浅通道并行策略可以提升 0.4611 dB,多尺度特征提取模块可以提升 0.2461 dB。 SSIM 值则分别提升了 0.0688、0.0319 和 0.0103。 这说明 3 种去噪结构对改善模型的去噪准确度和精 度都有积极的作用。

表 3 不同网络结构的对比

	PSNR/dB	RMSE	SSIM
Without Sconv	32.6547	5.6845	0.7985
Without shallow channel	32.7584	5.4982	0.8354
Without multiscale moudle	32.9734	5.1584	0.8570
默认网络模型	33.2195	4.9503	0.8673

图 8 所示是各个模型训练误差随训练步长变化的曲线图。平滑曲线对应的是模型 MSP-ReCNN 的训练变化图,下三角标记和圆形标记的曲线分别对应的是去掉浅通道和去掉拆分卷积后的模型训练变

化图,菱形标记的曲线是去掉特征提取模块后的训 练误差变化曲线。从图中可以看出,下三角标记和 圆形标记的曲线在训练过程中稳定性不好,波动范 围较大,并且损失函数值也较高。菱形标记的曲线 在训练刚开始波动较大,之后才慢慢趋于稳定。模 型 MSP-ReCNN 对应的平滑曲线下降速度最快,收 敛时间也最短,由此说明,本文提出的3种网络结构 可以加快网络的训练和收敛速度,同时模型的鲁棒 性也比较好。



4 结论

为了能在去除新冠肺炎 CT 图像噪声的同时, 尽可能地保留图像中的纹理结构细节,本文设计了 一种基于多尺度并行深度可拆分卷积神经网络 MSP-ReCNN。通过对比实验结果可以看出,相较于 其他对比算法,模型 MSP-ReCNN 无论是在主观视 觉效果还是客观评价指标方面都有更好的表现。同 时,通过网络消融实验可以证明,本文提出的多尺度 特征提取模块以及深浅通道并行策略,可以更好地 提取肺炎 CT 图像中的纹理结构细节,去噪准确度 和精度也有进一步提升。拆分卷积操作进一步降低 了网络模型的参数量,并且改善了传统卷积神经网 络中特征冗余的情况,加速了网络的训练以及收敛 速度。总体实验说明,模型 MSP-ReCNN 可以更快 更好地完成肺炎 CT 图像去嗓任务,在新冠肺炎蔓 延全球之际,可以提升肺炎 CT 图像质量,辅助机器

— 1151 —

以及医护人员完成更精准的诊断。在未来的研究规 划中,会继续研究三维立体的肺炎 CT 图像去噪以 及真实含噪肺炎 CT 图像去噪问题。

参考文献

- [1] Oh Y, Park S, Ye J C. Deep learning COVID-19 features on CXR using limited training data sets[J]. *IEEE Transactions on Medical Imaging*, 2020, 39(8): 2688-2700
- [2] Lecun Y, Bengio Y, Hinton G. Deep learning [J]. Nature, 2015, 521(7553): 436
- [3] Schmidhuber J, Rgen. Deep learning in neural networks: an overview [J]. Neural Networks, 2015, 61: 85-117
- [4] 王金甲,陈浩,刘青玉.大数据下的深度学习研究[J].高技术通讯,2017,27(1):27-37
- [5] Wang S, Sun J, Mehmood I, et al. Cerebral micro-bleeding identification based on a nine-layer convolutional neural network with stochastic pooling[J]. Concurrency and Computation Practice and Experience, 2020,32(1):1-16
- [6] Litjens G J S, Kooi T, Bejnordi B E, et al. A survey on deep learning in medical image analysis [J]. Medical Image Analysis, 2017, 42: 60-88
- [7] Jin Y, Jiang X B, Wei Z K, et al. Chest X-ray image denoising method based on deep convolution neural network
 [J]. *IET Image Processing*, 2019,13(11):1970-1978
- [8] Ren S, He K, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks
 [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149
- [9] Nah S, Kim T H, Lee K M. Deep multi-scale convolutional neural network for dynamic scene deblurring [C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition, Hawaii, USA, 2017: 3883-3891
- [10] 贺静波, 彭复员. 基于随机微分的 EMD 图像去噪算 法[J]. 高技术通讯, 2010, 20(10): 1046-1048
- [11] Mondal T, Maitra M. Denoising and compression of medical image in wavelet 2D[J]. International Journal on Recent and Innovation Trends in Computing and Communication, 2014, 2(2): 1-4
- [12] Raj V N P, Venkateswarlu T. Denoising of medical images using undecimated wavelet transform [C] //2011 IEEE Recent Advances in Intelligent Computational Systems, Trivandrum, India, 2011: 483-488
- [13] 吴游,殷奎喜,赵华,等. 基于正交复小波变换和小
 1152 —

波去噪的改进系统 De-OCWDM [J]. 高技术通讯, 2011, 21(4): 374-379

- [14] Buades A, Coll B, Morel J M. A non-local algorithm for image denoising[C] // 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, San Diego, America, 2005: 60-65
- [15] 肖贵仁,谢芳森,胡海江.改进型 Q-NLM 算法在医学
 图像去噪中的应用[J].计算机工程与应用,2015,51
 (10):174-176
- [16] 吕鲤志. 医学 CT 图像去噪和增强方法的研究应用
 [D]. 太原:太原理工大学计算机科学与技术学院,
 2016:16-20
- [17] Isogawa K, Ida T, Shiodera T, et al. Deep shrinkage convolutional neural network for adaptive noise reduction
 [J]. IEEE Signal Processing Letters, 2018, 25(2): 224-228
- [18] Zhang K, Zuo W, Chen Y, et al. Beyond a Gaussian denoiser: residual learning of deep CNN for image denoising
 [J]. IEEE Transactions on Image Processing, 2017, 26 (7): 3142-3155
- [19] 吕晓琪, 凉吴, 宇谷, 等. 基于深度卷积神经网络的 低剂量 CT 肺部去噪[J]. 电子与信息学报, 2018, 40
 (6): 87-93
- [20] Chen H, Zhang Y, Kalra M K, et al. Low-dose CT with a residual encoder-decoder convolutional neural network (RED-CNN) [J]. *IEEE Transactions on Medical Ima*ging, 2017, 36(99): 2524-2535
- [21] Hu C, Yi Z, Weihua Z, et al. A low-dose CT via convolutional neural network [J]. Biomedical Optics Express, 2017, 8(2): 679-694
- [22] Liu C J, Wechsler H. A shape- and texture-based enhanced Fisher classifier for face recognition [J]. IEEE Trans Image Process, 2001, 10(4): 598-608
- [23] Yang J, Yang J Y. Generalized K-L transform based combined feature extraction [J]. Pattern Recognition, 2002, 35(1): 295-297
- [24] Hu J, Shen L, Sun G. Squeeze-and-excitation networks [C] // 2018 IEEE Conference on Computer Vision and Pattern Recognition, Salt Lake City, USA, 2018:7132-7141
- [25] Li X, Wang W, Hu X, et al. Selective kernel networks [C] // 2019 IEEE Conference on Computer Vision and Pattern Recognition, Long Beach, USA, 2019: 510-519
- [26] COVID-CT. A CT Scan Dataset about COVID-19[EB/

OL]. https://github.com/UCSD-AI4H/COVID-CT:University of California San Diego, 2020

COVID-19 CT images denoising method based on multi-scale parallel deep split CNN

Zhang Shuo, Yu Shiming

(College of Information Engineering, Zhejiang University of Technology, Hangzhou 310023)

Abstract

The coronavirus disease 2019 (COVID-19) has spread worldwide. To early diagnose COVID-19 and reduce the pressure of medical staff, using deep learning methods to analyze chest computed tomography (CT) images of patients becomes more and more important. The images of pneumonia have rich texture details and fuzzy edge structure, which are easy to interfere with the diagnosis of machine and doctor. COVID-19 CT images denoising method based on multi-scale parallel deep split convolution neural network (MSP-ReCNN) is proposed in this paper to enhance the quality of pneumonia images. Multi scale feature extraction module can extract the details of texture features in pneumonia images from different scales. The parallel method of deep and shallow channels are utilized to extract the high-dimensional and low-dimensional features of pneumonia images. To further optimize the network model, the split convolution method is proposed. The feature graph can be divided into two categories, one is the primary concern feature, the other is the secondary concern feature. High complexity computing method is used to extract the core information from the primary concern features, and the low complexity calculation method is used to extract the compensation information for others. Compared with non-local mean (NLM) denoising algorithm, shrinkage convolutional neural network (SCNN) model, denosing convolutional neural network (DnCNN) model, and through network ablation experiments, it can be drawn that the proposed model can effectively remove the noise in COVID-19 CT images, and can retain the texture structure details of the original image, as well as provide more reliable auxiliary diagnosis for machines and doctors.

Key words: coronavirus disease 2019 (COVID-19) computed tomography (CT) image, image denoising, multi-scale feature, deep and shallow parallel channel, split convolution