

引用格式:魏江,刘潇,梅少辉. 基于卷积神经网络的遥感图像去噪算法 [J]. 微电子学与计算机,2019,36(8):59-62. [WEI J,LIU X,MEI S H. Remote sensing image denoising based on convolutional neural network [J]. Microeletronics & Computer, 2019,36(8): 59-62.]

基于卷积神经网络的遥感图像去噪算法

魏 江,刘 潇,梅少辉

(西北工业大学 电子信息学院,陕西 西安 710129)

摘 要: 由于成像设备的局限和外部环境的干扰等因素影响,遥感图像在信息数字化和传输过程中常常包含大量噪声,导致图像质量下降,对后续图像处理产生不利影响. 本文提出了一种基于卷积神经网络的遥感图像去噪算法,将图像去噪过程作为神经网络的拟合过程,使用含有批量正则化层的深度神经网络,利用残差学习策略,可以对多种噪声等级的遥感图像进行去噪处理. 实验表明,本文算法不仅有效提升了去噪效果,还缩短了网络的训练时间.

关键词: 图像去噪;卷积神经网络;遥感图像;深度学习

中图分类号: TP751

文献标识码: A

文章编号: 1000—7180(2019)08—0059—04

Remote sensing image denoising based on convolutional neural network

WEI Jiang,LIU Xiao,MEI Shao-hui

(School of Electronics and Information, Northwestern Polytechnical University, Xi'an, 710129, China)

Abstract: In the process of digitizing and transmitting information, due to the limitations of imaging equipment and the interference of external environment, remote sensing images often contain a lot of noise, which leads to the degradation of image quality and adversely affects subsequent image processing. In this paper, a remote sensing image denoising algorithm based on convolutional neural network is proposed. The algorithm considers the image denoising process as the neural network fitting process. Using the residual learning strategy and the deep neural network with batch regularization layer, it can denoise the remote sensing images with various noise levels. Experiments show that the proposed algorithm not only effectively improves the denoising effect, but also shortens the training time of the network.

Key words: image denoising; convolutional neural network; remote sensing image; deep learning

1 引言

深度学习最早应用于图像处理领域,卷积神经网络在图像处理领域应用也非常广泛. Michael Elad 于 2006 年提出了一种基于超完备稀疏分解的图像去噪算法 K-SVD^[1], Kostadin Dabov 于 2007 年提出了一种基于变换域中增强稀疏表示的图像去

噪方法 BM3D^[2],该算法通过将 2D 图像片段分组为 3D 数据阵列来实现稀疏性的增强. 2017 年, Kai Zhang 等人提出了一种基于卷积神经网络的图像去噪算法 DnCNN^[3],该算法利用深度学习方法来进行图像去噪.

传统图像去噪算法不能统筹算法适应性和结构性,一般会牺牲一方而保证另一方;不能批量处理图

片,效率相对低下.

运用卷积神经网络进行图像去噪的优势在于自适应性强,同时可以保留图片的结构信息;且可以批量处理图片,且采用 GPU 计算,计算效率较高.

由于遥感图像包含复杂的地物信息,对其使用卷积神经网络进行去噪有两大难点:(1)若直接学习干净图像,需要提取的特征信息过多,效果欠佳.(2)结构复杂的大型卷积神经网络参数过多,在训练和图像处理时也有效率较低的问题.

本文构造了一种端到端的、采用残差学习^[4]策略的五层深度神经网络,并将其用于遥感图像去噪.该网络充分考虑到了去噪效果和去噪效率两方面问题,综合性能优于传统算法和大型的卷积神经网络.

2 去噪算法

2.1 算法综述

本文提出的卷积神经网络算法的流程如图 1 所示.




图 1 网络算法流程图

图像去噪的目的就是从含有噪声信息的图像中恢复出尽可能多的原始图像信息.原始图像和噪声图像的关系可以由下式表示^[5]:

$$g(x,y) = f(x,y) + \eta(x,y) \tag{1}$$

式中, $g(x,y)$ 为含有噪声的遥感图像; $f(x,y)$ 为没有噪声的干净图像; $\eta(x,y)$ 为加性噪声.

本文算法采用残差学习策略,将含噪图像 $g(x,y)$ 经过网络的计算后,习得噪声图像 $\hat{\eta}(x,y)$,再通过下式:

$$\hat{f}(x,y) = g(x,y) - \hat{\eta}(x,y) \tag{2}$$

得到原始图像的估计值 $\hat{f}(x,y)$,即为去噪图像.

因此遥感图像去噪问题可以转化为一个回归问题,目标函数如下所示,

$$J = \frac{1}{2} \| F(g(x,y)) - \eta(x,y) \|^2 \tag{3}$$

式中, F 为复合网络映射函数.

2.2 网络结构

本文提出了一种端到端的基于卷积神经网络的深度学习框架,并将此用于遥感图像的去噪处理.

本文设计的卷积神经网络包括输入层、输出层、

卷积层、批量正则化层 (Batch Normalization, BN)^[6]和激活层(ReLU)等.该网络充分考虑到了由含噪图像到去噪图像的非线性映射关系,采用残差学习策略,刻画恒等映射或近似的恒等映射,构建出的网络模型可以更好地提升去噪效率.




图 2 CNN 网络结构

如图 2 所示,本文卷积神经网络模型的输入是含噪声的彩色遥感图像(包含 RGB 三个通道),输出是去噪后的遥感图像(包含 RGB 三个通道).网络的隐含层均由特征图组成.

网络隐含层由五个卷积层组成,含噪声的遥感图像输入卷积神经网络后,在 C1 层,对图像进行卷积操作,再进行 ReLU 操作;C2、C3、C4 是三个较为复杂的隐藏层,为了使网络更好的收敛,加速训练且提升性能,使用了 Batch Normalization、ReLU 的方法;C5 层运算后输出一张特征图,即学习到的噪声图像.最后在输出层用输入的含噪图像减去学习到的噪声图像,即可得到去噪后的图像,即干净图像的估计值.

2.3 网络详细设置

2.3.1 输入和输出层

网络采取端到端的设置,输入输出均为图像.其中输入为待去噪遥感图像,在经过输入层后,待去噪图像转化为一个三维矩阵,在隐含层学习到噪声图像,最后在输出层采用残差学习策略,得到去噪图像矩阵的估计值,并将其转为去噪图像输出保存.在训练模型的过程中,输出层得到去噪图像矩阵的估计值后,会进行损失函数的计算、修改权值并将其返回到网络中,进行网络参数的优化.

本文网络具有输入灵活的特点,可以接受任意尺寸与长宽比的图像作为输入.输出图像与输入的待去噪图像大小一致,这样可以减少以片段形式输出所需要的拼接工作,从而减少处理时间.

2.3.2 卷积层

卷积层是卷积神经网络的关键部分.卷积神经网络虽然可以通过感受野和权值共享减少神经网络需要训练的参数个数,但复杂的深度神经网络所需参数依然很多,并且模型复杂.相比于浅层神经网络

络,深度神经网络不仅训练时长大幅增加,图像去噪耗时也会增加,还易产生过拟合现象.

本文设计的网络具有五层卷积层,其中三层卷积层使用了 Batch Normalization、ReLU 的方法,可以在简化模型、减少参数的基础上保证图像去噪的性能.

2.3.3 批量正则化层

最大值池化的方法在传统图像识别中有着平滑输入,能对特征提供平移不变性,也可以减少训练参数,具有很多优点.但是对于具有复杂地物信息的遥感图像,池化层的降采样操作可能会导致图像丢失有效的信息.

因此,本文没有使用卷积层加池化层的网络结构,而是选择使用批量正则化层对卷积层获得的特征进行归一化处理,使网络进行更好的收敛,并且可以使用更大的学习率(learning rate,lr)以加速训练过程.

2.4 网络参数设置

本文所设计网络的结构参数如表 1 所示,定义卷积(C)+批量标准化(B)+RELU(R)为 CBR.

表 1 CNN 网络参数设置

层	输入	CR	CBR1	CBR2	CBR3	C
卷积核	3×3	3×3	3×3	3×3	3×3	3×3
通道数	3	32	64	64	32	3
扩张	1	1	2	2	1	1
图大小	256×256	256×256	256×256	256×256	256×256	256×256

待去噪图像通过输入层进行处理,转化为矩阵送往卷积层.若输入的遥感图像是一个彩色 RGB 图像,输入层的通道数为 3(网络也可接受灰度图像作为网络输入,此时输入层通道数改为 1).

在设置卷积核时,需要考虑不同尺寸卷积核对网络训练效果和效率的影响.大尺寸的卷积核虽然可以带来更大的感受野,可以捕捉到更多的信息,但也意味着网络会有更多的参数,由此会导致卷积计算量增加.例如,在卷积核数量相同的情况下,5×5 的卷积核比 3×3 的卷积核计算量大 2.78 倍.为了降低计算量,压缩训练时间,提升网络性能,本文网络所用卷积核尺寸为 3×3,步长为 1.

网络训练的迭代次数(epoch)为 200 个,最小批量(mini-batch)设为 32,以便对网络进行充分训练.

由于学习率小的时候收敛速度慢,且容易过拟合,训练时采用学习率衰减的策略,学习率由 0.01 衰减至 0.001.

梯度下降优化方法使用 Adam(Adaptive Moment Estimation)方法^[7].Adam 方法利用梯度的一阶矩估计和二阶矩估计对每个参数的学习率进行动态调整.经过偏置校正之后,每一次迭代学习率的范围都是确定的,可以使参数比较平稳.Adam 结合了 Adagrad 和 RMSprop 的优点,能够很好地处理稀疏梯度和非平稳目标,且对内存的需求较小,有利于对大数据集和高维空间进行训练.

损失函数使用均方误差函数(Mean Square Error,MSE).Pytorch 框架的神经网络库(torch.nn)带有流动的损失函数的功能,其中使用最广泛的就是 MSE 损失函数.

网络模型训练充分后,为了对图像去噪效果进行定量与定性的对比,对测试集进行测试时将会计算出输入遥感图像的 PSNR、经网络处理后输出的去噪图像的 PSNR 以及计算耗时作为定量对比数据,并输出去噪前后的图像作为定性对比图.

3 实验验证

3.1 遥感图像数据集

数据集的原始图像选用 Google Earth 提供的遥感图像与航拍遥感图像.为了得到更多的边缘信息,对网络进行充分有效的训练,将遥感图像按 256×256(pixel)尺寸进行裁剪作为 Ground truth.然后对 Ground truth 中的小块遥感图像进行加噪处理(方差分别为 0.001,0.005,0.01 的高斯白噪声),作为待去噪样本.构建出待恢复图像与原始图像的配对,形成数据集,用于神经网络的学习.

本去噪实验从数据集中随机选取十张遥感图像做测试集,其余图像(11000 张)为训练集.

3.2 实验环境配置

实验中工作站配置信息如表 2 所示.

表 2 网络训练计算机配置信息

中央处理器	i7-6700K
内存	DDR4 64G
显卡	英伟达 GTX-1080
操作系统	Ubuntu 16
语言开发工具	PyCharm 2016.3.2

3.3 实验结果

本文所用对比算法为传统去噪算法 K-SVD、BM3D 以及深度神经网络 DnCNN 算法,评价指标包括 PSNR、处理耗时以及人的主观判断(即去噪效果图).

针对三种不同噪声等级的遥感图像进行去噪,

得到结果如表 3 所示,其中 PSNR 单位为分贝,运行时间单位为秒.

由表 3 可以看出,就 PSNR 而言,K-SVD 算法不适用于较大噪声方差的图像,适应性较差,而 BM3D 和 DnCNN 算法去噪结果同本文算法相比也具有一定差距,这很好地体现出了本文算法适应性强的优点,即对于不同噪声方差的图片都具有良好的去噪结果;就处理耗时而言,基于深度学习的 DnCNN 算法和本文算法可以对图像进行批量处理,相较于传统去噪算法有着显著优势,但是本文算法在训练所耗时间上花费更少,效率更高:在同样的训练样本,同样的运行环境下,本文算法训练一次迭代所用时间大约为 5 分钟,而 DnCNN 算法所用时间大约为 20 分钟.

表 3 不同噪声水平下各方法去噪结果

噪声方差	评判标准	方法				
		噪声图像	K-SVD	BM3D	DnCNN	本文算法
0.001	PSNR	30.008	33.775	35.734	36.070	36.064
	运行时间		19.57	1.6	0.03	0.01
0.005	PSNR	22.998	25.567	32.286	32.057	32.228
	运行时间		10.42	1.5	0.03	0.01
0.01	PSNR	20.008	22.590	30.608	30.970	31.056
	运行时间		11.87	1.6	0.03	0.01

本文算法与 K-SVD、BM3D、DnCNN 去噪算法的效果对比如图 3 所示(仅展示噪声方差为 0.01 的遥感图像去噪效果).

从图 3 可以看到,K-SVD 算法和 BM3D 算法对图像处理时做了过多的平滑处理,丢失了很多原图信息,效果欠佳;本文算法和 DnCNN 算法则很好地保留了遥感图像的地物信息,去噪效果相对较好.

K-SVD 和 BM3D 算法只能对灰度图像进行去噪,而本文算法与 DnCNN 算法既可以对彩色 RGB 图像进行去噪处理,也可以对灰度图像进行去噪处理.这表明本文算法和 DnCNN 算法都具有更好的泛化能力.

相对于 DnCNN 算法,本文算法在去噪效果上并无显著优势,但在训练时间比上有着高效的优点.

4 结束语

本文提出了一种新的卷积神经网络结构用于遥感图像去噪,具有比现有的传统图像去噪算法以及常用的深度神经网络更好的去噪效果.对本文算法和 K-SVD 算法、BM3D 算法、DnCNN 算法等常用




图 3 不同去噪算法效果图

算法进行的对比实验结果表明,使用本文提出的遥感图像去噪算法效果优于其他算法.

参考文献:

[1] AHARON M, ELAD M, BRUCKSTEIN A. The K-SVD: An algorithm for designing of overcomplete dictionaries for sparse representation[J]. IEEE Transactions on Signal processing, 2006, 54(11): 4311- 4322.

s,通用 CPU 耗时 30.225 s,此时的加速比为 6.44,而且处理的图像越多,加速效果越明显,具有一定的意义.

5 结束语

本系统在 ZYNQ-7020 处理器上采用 HLS 的方式设计 CNN IP 用于执行卷积神经网络算,并采用流水线、展开的技术对 CNN IP 核进行优化,旨在提高嵌入式处理器计算 CNN 的速度.通过实验证明,本方案对嵌入式处理器针对 CNN 的计算速度有显著的提升.在 ZYNQ-7020 中当对第三层循环进行流水线处理时,就几乎消耗了全部 PL 的存储资源,若采用资源更多 ZYNQ-7030、ZYNQ-7040 处理器可将更高层的循环进行流水线处理,从而可以将 CNN IP 的计算速度进一步提升.

参考文献:

[1] ZHANG C, LI P, SUN G, et al. Optimizing fpga-based accelerator design for deep convolutional neural networks[C]// Acm/sigda International Symposium on Field-programmable Gate Arrays. ACM, 2015.

[2] LI H, FAN X, JIAO L, et al. A high performance

FPGA-based accelerator for large-scale convolutional neural networks[C]// 2016 26th International Conference on Field Programmable Logic and Applications (FPL). IEEE, 2016.

[3] Xilinx. ds187-XC7Z010-XC7Z020-Data-Sheet [EB/OL]. (2018-07-02)[2018-07-02]<https://china.xilinx.com/support/>[8]范秋香. FPGA 高级开发技术的研究[D]. 北京:北京理工大学,2015.

[4] Xilinx. UG902-vivado-high-level-synthesis[EB/OL]. https://china.xilinx.com/support/documentation/sw_manuals/xilinx2015_4/ug902-vivado-high-level-synthesis.pdf.

[5] 余子健, 马德, 严晓浪, 等. 基于 FPGA 的卷积神经网络加速器[J]. 计算机工程, 2017, 43(1):109-114.

[6] 陈岩, 李洋洋, 余乐, 等. 基于卷积神经网络的手写体数字识别系统[J]. 微电子学与计算机, 2018, 35(2): 71-74.

作者简介:

彭鑫磊 男,(1993-),硕士研究生.研究方向为数字集成电路设计、嵌入式开发.

余乐(通讯作者) 男,(1983-),博士,讲师.研究方向为计算视觉与类脑芯片. E-mail:ladd_u@163.com

(上接第 62 页)

[2] DABOV K, FOI A, KATKOVNIK V, et al. Image denoising by sparse 3-D transform-domain collaborative filtering [J]. IEEE Transactions on Image Processing, 2007, 16(8):2080-2095.

[3] 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.

[4] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]. Proceedings - 29th IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE Computer Society, 2016:770-778.

[5] PORTILLA J, STRELA V, WAINWRIGHT M J, et al. Image denoising using scale mixtures of Gaussians in the wavelet domain [J]. IEEE Transactions on Image Processing, 2003, 12(11): 1338- 1351.

[6] IOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift [C]. 32nd International Conference on Machine Learning. Lile: International Machine Learning Society, 2015: 448-456.

[7] KINGMA D P, BA J. Adam: A Method for Stochastic Optimization [C]. 3rd International Conference on Learning Representations. San Diego, 2015; arXiv: 1412.6980.

作者简介:

魏江 男,(1968-),硕士,副教授.研究方向为智能信息处理、嵌入式系统应用. E-mail:joeway@nwpu.edu.cn.

刘潇 女,(1996-),硕士研究生.研究方向为智能信息处理、人工智能与机器学习.

梅少辉 男,(1984-),博士,副教授.研究方向为智能信息处理、人工智能与机器学习.