

1-3-2019

Cloud Fraction of Satellite Imagery Based On Convolutional Neural Networks

Xia Min

1. Jiangsu Collaborative Innovation Center on Atmospheric Environment and Equipment Technology, Nanjing University of Information Science and Technology, Nanjing 210044, China; ;2. B-DAT, Nanjing University of Information Science and Technology, Nanjing 210044, China;

Maoyang Shen

1. Jiangsu Collaborative Innovation Center on Atmospheric Environment and Equipment Technology, Nanjing University of Information Science and Technology, Nanjing 210044, China; ;2. B-DAT, Nanjing University of Information Science and Technology, Nanjing 210044, China;

Jianfeng Wang

1. Jiangsu Collaborative Innovation Center on Atmospheric Environment and Equipment Technology, Nanjing University of Information Science and Technology, Nanjing 210044, China; ;

Yangguang Wang

1. Jiangsu Collaborative Innovation Center on Atmospheric Environment and Equipment Technology, Nanjing University of Information Science and Technology, Nanjing 210044, China; ;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research](#), [Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Cloud Fraction of Satellite Imagery Based On Convolutional Neural Networks

Abstract

Abstract: Cloud fraction is the basis for the application of meteorological satellite. Existing methods cannot use all the characteristics and optical parameters of the satellite cloud, which results in the inaccuracy of cloud detection and cloud fraction. In order to solve this problem, *convolutional neural network is used for cloud detection. Based on the improved convolutional neural network, the satellite cloud image is divided into thin cloud, thick cloud and clear sky. Based on the cloud detection, an improved spatial correlation method is used for cloud fraction.* The results for Chinese HJ-1A/B satellite imagery show that convolutional neural network can extract the features of cloud images effectively by optimizing the network structure and parameters, and the transition region between the thin cloud and thick cloud is clear for cloud classification. The simulation results show that the cloud classification and cloud fraction accuracy is better than traditional threshold, dynamic threshold method and extreme learning machine.

Keywords

cloud fraction, convolutional neural network, cloud detection, spatial correlation

Recommended Citation

Xia Min, Shen Maoyang, Wang Jianfeng, Wang Yangguang. Cloud Fraction of Satellite Imagery Based On Convolutional Neural Networks[J]. Journal of System Simulation, 2018, 30(5): 1623-1630.

基于卷积神经网络的卫星云图云量计算

夏旻^{1,2}, 申茂阳^{1,2}, 王舰锋¹, 王阳光¹

(1. 南京信息工程大学江苏省大气环境与装备技术协同创新中心, 南京 210044;

2. 南京信息工程大学江苏省大数据分析技术重点实验室, 南京 210044)

摘要: 卫星云图云量计算是卫星气象应用的基础, 目前的方法对卫星光学参数以及对卫星云图的特征利用率不高, 导致了云检测及云量计算不准确。针对这个问题, 利用卷积神经网络进行卫星云图的检测, 基于优化的卷积神经网络将云图分为厚云、薄云及晴空。在云检测的基础上利用“空间相关法”计算总云量。针对中国 HJ-1A/B 卫星图片的实验结果表明, 通过对卷积网络结构及参数的优化卷积神经网络可以很好的提取云图的特征, 云分类时厚云和薄云之间的过渡区域清晰, 云的识别率以及云量计算的准确率都比传统阈值法、动态阈值法以及极限学习机模型的结果要好。

关键词: 云量计算; 卷积神经网络; 云检测; 空间相关法

中图分类号: TP183

文献标识码: A

文章编号: 1004-731X (2018) 05-1623-08

DOI: 10.16182/j.issn1004731x.joss.201805001

Cloud Fraction of Satellite Imagery Based On Convolutional Neural Networks

Xia Min^{1,2}, Shen Maoyang^{1,2}, Wang Jianfeng¹, Wang Yangguang¹

(1. Jiangsu Collaborative Innovation Center on Atmospheric Environment and Equipment Technology, Nanjing University of Information Science and Technology, Nanjing 210044, China; 2. B-DAT, Nanjing University of Information Science and Technology, Nanjing 210044, China)

Abstract: Cloud fraction is the basis for the application of meteorological satellite. Existing methods cannot use all the characteristics and optical parameters of the satellite cloud, which results in the inaccuracy of cloud detection and cloud fraction. In order to solve this problem, convolutional neural network is used for cloud detection. Based on the improved convolutional neural network, the satellite cloud image is divided into thin cloud, thick cloud and clear sky. Based on the cloud detection, an improved spatial correlation method is used for cloud fraction. The results for Chinese HJ-1A/B satellite imagery show that convolutional neural network can extract the features of cloud images effectively by optimizing the network structure and parameters, and the transition region between the thin cloud and thick cloud is clear for cloud classification. The simulation results show that the cloud classification and cloud fraction accuracy is better than traditional threshold, dynamic threshold method and extreme learning machine.

Keywords: cloud fraction; convolutional neural network; cloud detection; spatial correlation

引言

基于卫星图像开展的云检测、云分类并且计算



收稿日期: 2016-06-01 修回日期: 2016-08-04;
基金项目: 国家自然科学基金(61532009), 江苏省六
大人才高峰基金(2014-XXRJ-007), 江苏省自然科学
基金(BK20161533);
作者简介: 夏旻(1983-), 男, 江苏东台, 博士, 副教
授, 研究方向为机器学习和智能计算。

云量是获取全球云量分布的主要方式。目前, 国际上卫星云量计算方法主要有 ISCCP^[1]方法, 通过 ISCCP 多阈值云检测方法, 将像元分为晴空和有云两类; 有 CLAVR-1^[2]方法, 将像元分为晴空、混合和有云三类; 有 CLAVR-X^[3]方法, 将像元分为全云、混合云、混合晴空和晴空四类; 还有 MODIS^[4]方法, 将像元分为四类, 包括确定云、可能云、可

<http://www.china-simulation.com>

• 1623 •

能晴空和确定晴空；还有比如 UW HIRS^[5]、NIR/VIS^[6]等方法。上述云量计算方法可以大体上分为两类：一是基于区域内有云像素点与总像素点之比计算云量^[7-8]；另一种是基于像素点辐射量/反射率计算等效云量^[9-10]。第一类方法操作简单，但不能分析亚像元云量，常导致计算结果偏高；第二类方法一定程度解决了亚像元云量问题，但对于多层云和地表类型变化剧烈的情况不太适用^[11]。不论使用哪一种计算方法，云检测结果的准确率将直接影响着云量计算的准确度。

目前，国际上云检测主要以阈值法和聚类法为主，阈值法^[12-13]主要采用红外温度阈值、可见光阈值等。但是由于卫星图像非常复杂多变，很难找出一种通用的阈值标准，因此检测精度并不是很理想。聚类法^[14]主要采用直方图聚类、动态阈值聚类等，云图特征特别复杂，云的类别一般是由多个特征所确定的，而现有的研究都重点在云图的个别特征提取上，并未有效利用云图像的各种有效信息，因此以上方法得到的云检测正确率不高。另外基于特征的云检测的分类器研究主要有K近邻^[15]，模糊策略^[16]，支持向量机^[17-18]和神经网络^[19]，其中神经网络分类器的识别精度被普遍认为高于其它分类器。但是由于这些方法的云图特征利用率不高，从而导致了检测精度不是很可靠。近年来深度学习^[20]，特别是卷积神经网络在很多应用领域都表现出强大的适应性和鲁棒性，卷积神经网络具有良好的容错、并行处理和自学习能力。卷积神经网络作为特殊设计的类多层感知器，可以自主的提取

有效的特征，对云图进行云检测。

针对卫星云量计算中存在的以上问题，本文利用卷积神经网络对卫星云图的云进行检测，并对卷积神经网络的结构参数进行优化，寻找到最优的结构参数。基于云检测的结果，本文利用“空间相关法”计算总云量。实验结果表明，本文方法得到的结果比传统阈值法、动态阈值法以及极限学习机神经网络结果要好，适合业务需求。

1 基于卷积神经网络的云检测模型及优化

本文所用卫星资料为 HJ-1A/1B 卫星图像，HJ-1A/1B 主要是用作环境与灾害监测预报的小卫星，两种卫星中，HJ-1A 卫星搭载的是 CCD 相机和超光谱成像仪，HJ-1B 卫星同样搭载了 CCD 相机以及红外相机。

本文所采用的样本均出自大气类专家采集，包括厚云、薄云和晴空三部分各 3 000 样本，测试样本同样包括厚云、薄云和晴空各 1 000 样本。每个样本的大小为 32×32 像素的图像。在基于训练好的卷积神经网络实现整幅卫星图像的云检测。卷积神经网络的实现需要的输入图像的尺寸大小要相同，所有的云图图像都被分割成许多 32×32 像素图像，以此来作为卷积神经网络的输入。

卷积神经网络的组成由图 1 所示，CNN 架构包含输入层、卷积层、最大池化层、全连接层和最后的 Softmax 分类层以及输出层组成。

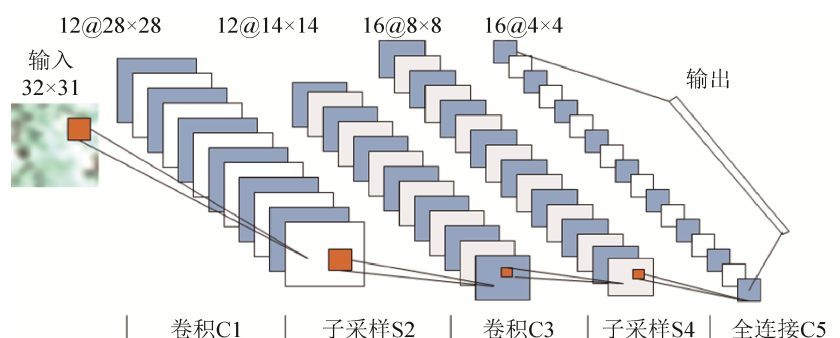


图 1 卷积神经网络结构

Fig. 1 Convolution neural network structure

<http://www.china-simulation.com>

• 1624 •

卷积层: 假设网络的第 l 层中的滤波器组为 $W^l = (w_1^l, w_2^l, \dots, w_{d^l}^l)$, 其中每一个 w_k^l 是第 l 层的一个 $m^l \times m^l$ 滤波器, 其中 $k \in \{1, 2, \dots, d^l\}$, 第 l 层滤波器组 W^l 中滤波器个数为 d^l . 输入图块是从每一个卫星云图中提取出来, 由 I^{l-1} 来表示第 l 层的输入, 假设其大小是 $\omega^{l-1} \times \omega^{l-1}$, 由于有 d^l 个滤波器, 所以生成的特征 map 也是 d^l 个, 经过滤波后特征图片大小就变成 $(\omega^{l-1} - m^l + 1) \times (\omega^{l-1} - m^l + 1)$, 滤波操作可以表示为:

$$g_k^l = I^{l-1} \times w_k^l \quad (1)$$

式中: g_k^l 代表通过第 k 个滤波器卷积得到的结果. 本文采用的是简单的线性滤波器, 也可以很好的提取比较良好的特征, 但是滤波器的数量和大小选择会对网络产生一定的影响, 如果每层的滤波器数量较少, 相应的生成的特征图也比较少, 可能一些比较好的特征就没有提取到, 就会影响分类的精度; 加入每层的滤波器较多, 提取的特征图特征并不是有用的特征, 造成信息的过度冗余, 分类效果也会变差, 而且由于要处理的特征图变多, 处理的速度也会减慢. 通过不断的尝试不同的滤波器, 不同的滤波器大小, 最终选择识别率比较高的, 综合性能比较好的, 为了模仿人脑神经元的工作原理, 更好的拟合数据, 通常对每一层线性滤波后的特征 map 加上一个激活函数来进行激活, 激活函数的表达式如式(2).

$$f(g_k^l) = \frac{1}{1 + \exp(-g_k^l)} \quad (2)$$

池化层: 在卷积层后, 通过在局部感受野, 提取其最大值为下一层的特征值, 因为池化层没有参数, 所以只要做非线性操作就行, 由于卫星云图非常的大, 局部区域存在冗余信息, 所以云图中我们只需要提取最能反映其特征的特征就可以了, 此时, 图像的特征映射图的尺寸大小为(其中 s 为下采样模板的大小, 本文中 $s=2$, 即模板的大小为 2×2):

$$\frac{(\omega^{l-1} - m^l + 1)}{s} \times \frac{(\omega^{l-1} - m^l + 1)}{s} \quad (3)$$

Softmax 输出层: Softmax 输出层主要解决多

分类的问题, 是 logistic 回归模型的推广, 最后输出得到一个概率值, 它的取值在 0~1 中间, 全连接层共有 256 个连接点, 而输出层则是 3 类, 分别代表厚云、薄云和晴空.

本文首先对卷积神经网络的层数进行选择优化, 如果网络层太少, 图像的有效特征可能就无法提取, 同时表达特征的信息还过于冗余, 如果网络的层数太多, 有效特征信息的提取会相对多很多, 但是层数的过多, 每层网络的有效信息也会损失一些, 有效特征信息的损失也会增大, 也就提取不到相对有用的特征信息. 深度神经网络的优化问题一直是机器学习领域的一个重要问题和热点问题. 目前学术界和工业界对深度学习的优化还是以经验优化为主, 即通过工程人员的经验和大量的仿真实验得到最优的结构和参数.

通过大量的实验, 本文选取的 6 层的网络结构. 确定了网络的层数之后, 本文对卷积神经网络的滤波器个数进行选择, 本文采用的是简单的线性滤波器, 效果却非常好, 但是滤波器的个数选择对特征提取效果也是有一定的影响. 假如滤波器的个数比较少, 那么提取的特征图也就比较少, 获取的特征信息就少, 可能影响分类效果, 假如滤波器数量比较多, 提取的特征图较多, 但是可能有些不是所需要的特征信息, 数据过于冗余, 而且因此处理的速度就相对太慢. 同样, 我们固定网络层数和滤波器的大小, 表 1 中 8-12 表示第一层卷积滤波器是 8 个, 第二层卷积滤波器是 12 个.

表 1 卷积滤波器个数选择
Tab. 1 Number selection of convolution filter

滤波器个数	6-12	8-12	12-16	12-18
训练时间/min	18	23	32	35
准确率/%	84.67	87.46	91.51	90.53

从表 1 中, 可以看出, 网络的训练时间是随着滤波器的个数的递增而递增的, 当第一层滤波器个数是 6 时候, 因为卷积后的滤波图比较少, 处理时间短, 但是因此提取的有用信息就减少, 网络的准确率不高, 而当滤波器是 12-18 时, 训练时间最长,

但网络的准确率比 12-16 却下降了, 因为云图样本太小, 滤波器过多, 造成特征信息过于冗余, 所以准确率不好, 因此, 本文选择的第一层滤波器是 12 个, 第二层滤波器是 16 个。

固定网络层数、滤波器个数后, 本文对滤波器的大小进行寻找优化, 滤波器的大小同样对网络的准确率影响很大, 滤波器的大小具体也要参照训练样本的大小, 表中 5-7 指的是第一层的滤波器是 5×5, 第二层的滤波器大小是 7×7, 得到如表 2 所示。

表 2 网络滤波器大小选择
Tab. 2 Selection of network filter size

滤波器大小	5-5	5-7	5-9
训练时间/min	25	32	34
准确率/%	88.75	91.51	89.86

分析表 2 可以看出, 当两层滤波器是 5×5 和 7×7 的时候, 网络的准确率是最高的, 当网络滤波器大小都是 5×5 时候, 滤波器提取时间最少, 要处理的特征图也小, 而当滤波器大小为 5×5 和 5×9 时候, 速度较慢, 而且精度也不高, 因此, 本文卷积神经网络选择的第一层滤波器大小是 5×5, 第二层滤波器大小为 7×7。通过以上优化过的卷积神经网络的特征学习示意图见图 2。如图 2 所示, 卷积神经网络进行特征提取并进行云分类的步骤为:

步骤 1: 将卫星图片分成 32×32 的小块, 以 32×32 的图像作为卷积神经网络的输入。

步骤 2: 通过 12 个 5×5 的滤波器分别对 32×32 的输入图像进行卷积, 得到 12 个 28×28 的特征图像。

步骤 3: 池化下采样操作, 对于步骤 2 中的每张图片每邻域四个像素求平均变为一个像素, 得到 12 个 14×14 的特征图。

步骤 4: 利用 16 个 7×7 的滤波器对步骤 3 中的 12 个 14×14 的特征图进行卷积操作得到 16 个特征图。这 16 个特征图中的每个特征图是连接到步骤 3 结果中的所有特征图的。

步骤 5: 池化下采样操作, 对于步骤 4 中的每张图片每邻域四个像素求平均变为一个像素, 得到 16 个 7×7 的特征图。

步骤 6: 把步骤 5 中的 16 个特征图变成一个长向量, 作为最后一层分类器的输入。通过 Softmax 的概率得到云的分类。

神经网络分类通过 Softmax 的概率值来确定, 通过对概率最大的值判定来确定是哪种云, 但是, 其重叠部分比较难判断, 因此, 我们利用厚云和薄云概率值通过相减来确定重叠部分, 其中厚云和薄云的重叠部分, 可以通过式(4)计算出。

$$|S_h - S_b| < 0.12 \tag{4}$$

式中: S_h 是代表检测后厚云的概率值; S_b 代表检测后薄云的概率值, 通过这个公式, 大体可以计算出厚云和薄云的重叠部分。

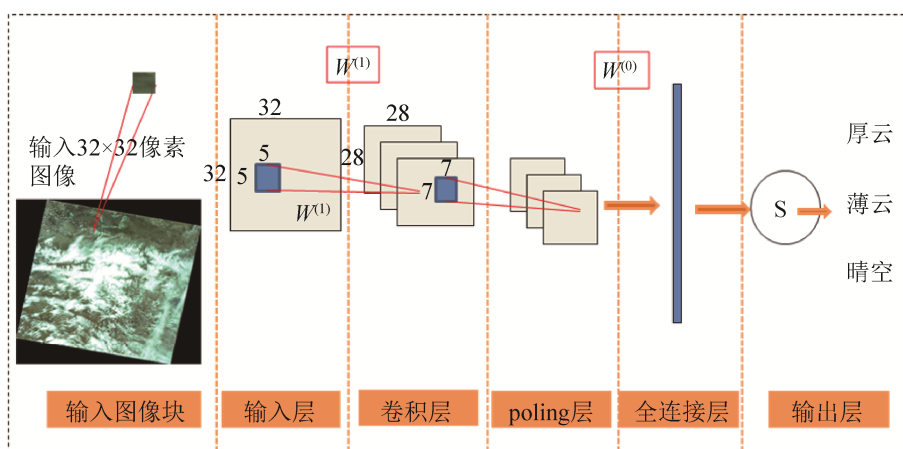


图 2 特征学习示意图
Fig. 2 Feature learning schematic

2 基于云检测的云量计算

基于 CCD 数据的特征和在云检测的基础上, 本文采用的是基于反射率检测的算法来开展总云量的计算, 利用 HJ-1A/1B 卫星 CCD 通道作为数据源, 开展总云量计算研究, 为了解决部分云覆盖的问题, 本文采用空间相关法来计算总云量。

空间相关法的基本原理是对单个像元辐射量的厚云、晴空覆盖情况下辐射量的检测, 来获得总云量, 公式如下:

$$I = (1 - A_c)I_{clr} + A_c I_{cld} \quad (5)$$

式中: I 是像元接收的辐射量; A_c 是总云量; I_{clr} 是晴空像元亮度的上界; I_{cld} 是厚云像元亮度的下界。转换公式, 总云量的公式为:

$$A_c = \frac{I - I_{clr}}{I_{cld} - I_{clr}} \quad (6)$$

本文的云量计算模型主要针对部分云和薄云的情况, 厚云的云量默认为 1, 晴空为 0。接下来给出具体的基于卫星云图检测的云量计算实验结果。

3 实验结果分析

3.1 基于优化的卷积神经网络进行卫星云图的云检测分析

云检测是云量计算的基础, 本文采用卷积神经网络进行云检测。图 3 给出了不同方法下的云检测的效果图。图 3(a)是卫星云图原图, 图 3(b)是采用传统阈值法检测的结果, 图 3(c)是采用 OTSU 动态阈值法检测的结果, 图 3(d)是采用极限学习机 (ELM)检测的结果, 图 3(e)是采用卷积神经网络检测的结果。图中, 红色区域代表的是厚云, 白色区域代表的是薄云和厚云的交界重叠处, 黑色区域代表的是晴空, 蓝色部分代表的是薄云。

分析图 3 中的各个检测图, 可以观察到: 图 3(b)整体上白色区域明显较多, 也就是厚云和薄云的交界过多, 和图 3(b)一样, 传统阈值法过多的当作了有云, 忽略了厚云和薄云以及晴空的清晰的界限表达。而图 3(c)中, 动态阈值法的红色区域比卷积神经网络的要多, 白色区域也较多, 交界比较明

显, 图 3(d)中可以看出极限学习机在厚云、薄云分界处处理的比较简单, 薄云和厚云的交界白色区域过多, 而图 3(e)更清晰的还原了原图, 看上去更加细腻, 丰富。

卷积神经网络根据厚云、薄云和晴空的训练样本来检测, 所以交界处区域较少, 也就是白色部分比较少。我们采用的空间相关法计算云量, 所以只需要计算出明确的厚云部分就可以, 其中的交界和薄云部分, 我们采用了线性计算方法, 可以更好的计算出交界部分和薄云的云量值, 因此, 可以看出图 3(e)的效果要比图 3(b)和图 3(c)图 3(d)更符合我们的要求。

使用卷积神经网络, 本文给出了另外一组实验结果, 如图 4 所示。从图中可以看出极限学习机在厚云、薄云分界处的处理情况不是很好, 导致厚云被误检。

为了做有效的定量分析, 将传统阈值法(TT)和动态阈值法(OTSU)还有极限学习机(ELM)和卷积神经网络(CNN)做对比, 图 5 给出了对比图。图 5 中的统计结果是通过 350 张卫星云图的测试结果得到的, 这 350 张图片包括不同区域的卫星图片。从图 5 可以看出, 传统阈值法的准确率最低, 而阈值法的准确率在于不断的去改变阈值, 这种方法比较笨拙, 其次是动态阈值法, 动态阈值法可以做到自适应的去调整阈值, 因此准确率比传统阈值法要高很多, 接着是神经网络模型, 可以看出基于神经网络模型的 CNN 和极限学习机比其它两种基于阈值法的方法更有优势, 而相比较极限学习机, CNN 模型的分检测准确率是最高的。表 3 给出了各种方法测试的时间效率对比, 传统阈值法(TT)和动态阈值法(OTSU)比较简单, 根据不同的阈值设定来检测云图, 因此阈值法的测试时间比较短, 极限学习机(ELM)作为神经网络模型, 速度优势也体现的非常明显, 不管训练时间还是测试时间, 极限学习机所用的时间对比卷积神经网络(CNN)都要快很多, 其中, CNN 是根据单个训练集的时间, 这个单个训练集的大小可以人为的调整, 而 CNN 由于云图的整体过于庞大, 因此训练和学习的速度比较慢。




图3 不同方法的云检测对比图

Fig. 3 Cloud detection contrast diagram of different methods




图4 不同方法的云检测对比图

Fig. 4 Cloud detection contrast diagram of different methods




图5 不同方法云检测准确率对比图

Fig. 5 Contrast diagram of cloud detection accuracy

表3 TT, OTSU, ELM, CNN 耗时比较

Tab. 3 Time consuming comparison of TT, OTSU, ELM, CNN

方法	训练时间/s	测试时间/s
TT		5.46
OTSU		6.78
ELM	16.45	9.76
CNN	1 927	48.56

3.2 云量计算结果分析

基于云图云检测的结果,利用空间相关法进行云图的云量计算。图6给出了一组云量计算结果图,图中彩色颜色是由黑到白,右边对照显示从1到0的过程。从图6云量计算图中可以明显看出,总体上,图6(b)、6(c)、6(d)、6(e)从色彩鲜艳程度来说是逐渐递进的过程,图6(d)、6(e)的识别伪色彩比图

6(b)、6(c)更加平滑、生动,说明了我们的算法能更好的还原图中的细节,更加准确的计算整体的云量。

接下来给出另一组云量计算图,如图7所示:可以明显看出图7(e)卷积神经网络和图7(d)极限学习机的优势,更好的说明了算法能够更好的分析变化的细节,更加准确的计算了整体的云量,但图7(d)色彩有些过于鲜艳,导致计算的云量过高,图7(b)和图7(c)几乎以白色为主,本文的方法比这两类更具有优势。

图8给出了几种方法云量计算的准确性对比图,云量计算准确率的对比仍旧采用传统阈值法(TT)、动态阈值法(OTSU)、极限学习机模型(ELM)和卷积神经网络模型(CNN)。图8中的测试数据和图5中的测试数据一致。可以明显看出因为云检测的效果较差,因此在云量计算方面的准确率,TT的准确率依然是最低的,其次是OTSU,动态阈值法下的云量准确率相比较TT有了明显的提高,ELM模型和OTSU的准确率差距不是很大,虽然ELM的运行速度相比较CNN较快,但CNN的云量计算准确率比较高,更加符合总云量计算的要求,因此,基于卷积神经网络CNN的方法更适合卫星云图的总云量计算研究。

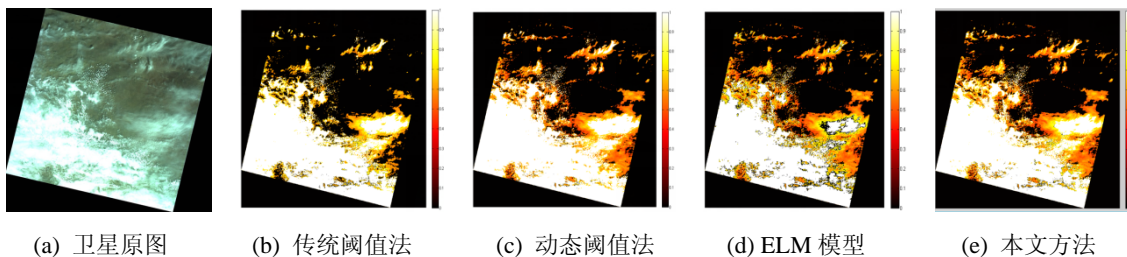


图 6 不同方法的云量计算对比图
Fig. 6 Contrast diagram of cloud fraction by different methods

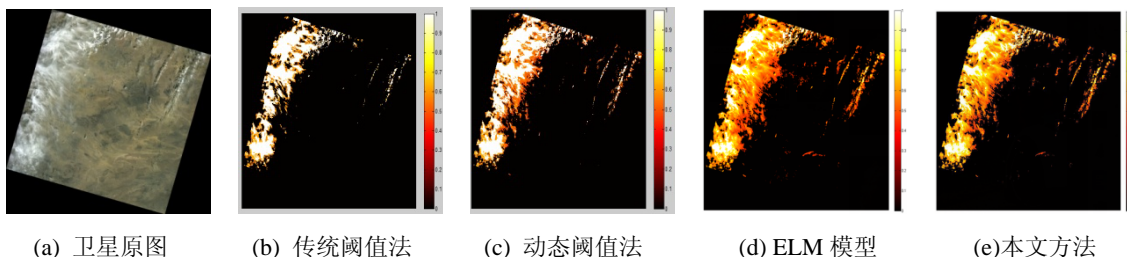


图 7 不同方法的云量计算对比图
Fig. 7 Contrast diagram of cloud fraction by different methods




图 8 不同方法的云量计算准确率对比
Fig. 8 Contrast diagram of cloud fraction accuracy

4 结论

本文针对卫星光学参数以及对卫星云图的特征利用率不高的问题,利用卷积神经网络对卫星云图进行云的检测分类。本文首先对卷积神经网络的层数、卷积核大小以及卷积核个数进行优化,然后基于优化的卷积神经网络将云图分为厚云、薄云及晴空。在此基础上利用“空间相关法”计算总云量。本文利用中国 HJ-1A/B 卫星图片作为数据来检测卷积神经网络进行云量计算的可靠性。试验结果表明,卷积神经网络在云分类中可以很好的把厚云和薄云分开,过渡区域清晰。通过和传统阈值法、动态阈值法以及极限学习机模型的结果作比较证实了卷积神经网络的优势。卷积神经网络云量计算的

准确率能达到 88% 以上。

本文主要采用了卷积神经网络对卫星云图进行研究,虽然取得了一些工作进步,但利用神经网络应用在云图领域还处于开始研究阶段,仍然存在着一些不足的地方,还需要进一步的去深入研究,主要有一下几个方面: 1) 本文基于卷积神经网络的研究,在云分类过程中,模型的训练和识别速度相比较有点慢,因此接下来将重点提高检测的速度,而且在识别精度上,还不是特别高,因此应该进一步优化网络结构,对云图的特征研究更加深入。2) 本文对卫星云图中的厚云、薄云、晴空以及厚云、薄云重叠处进行分类实验,但在云图中,一些冰川,雾霾等会对分类研究产生影响,因此,接下来也将着重提高检测的干扰。3) 未来的自动卫星云图的云量计算工作需要更快,更加结合气象业务的需求,因此,不仅要提高模型的性能,也要与实际的硬件设备结合,提高云量计算处理效率。

参考文献:

[1] Rossow W B, Garder L C. Cloud Detection Using Satellite Measurements of Infrared and Visible Radiances for ISCCP[J]. Journal of Climate (S0894-8755), 1994, 6(12): 2341-2369.

- [2] Stowe L L, Davis P A, McClain E P. Scientific Basis and Initial Evaluation of the CLAVR-1 Global Clear/Cloud Classification Algorithm for the Advanced Very High Resolution Radiometer[J]. *Journal of Atmospheric & Oceanic Technology (S0739-0572)*, 2010, 16(6): 656-681.
- [3] Thomas S M, Heidinger A K, Pavolonis M J. Comparison of NOAA's Operational AVHRR-Derived Cloud Amount to Other Satellite-Derived Cloud Climatologies[J]. *Journal of Climate (S0894-8755)*, 2004, 17(24): 4805-4822.
- [4] Usman M, Liedl R, Shahid M A, et al. Land use/land cover classification and its change detection using multi-temporal MODIS NDVI data[J]. *Journal of Geographical Sciences (S1009-637X)*, 2015, 25(12): 1479-1506.
- [5] Wylie, D P, Menzel, W P. Two Years of Cloud Cover Statistics Using VAS[J]. *Journal of Climate (S0894-8755)*, 1989, 2(4): 380-392.
- [6] R W SAUNDERS, K T KRIEBEL. An improved method for detecting clear sky and cloudy radiances from AVHRR data[J]. *International Journal of Remote Sensing (S0143-1161)*, 1988, 9(1): 123-150.
- [7] Mackie S, Embury O, Old C. Generalized Bayesian cloud detection for satellite imagery. Part 1: Technique and validation for night-time imagery over land and sea[J]. *International Journal of Remote Sensing (S0143-1161)*, 2010, 31(10): 2573-2594.
- [8] 郑晓辉, 徐国强, 魏荣庆. GRAPES 新云量计算方案的引进和影响试验[J]. *气象*, 2013, 39(1): 57-66.
Zheng X H, Xu G Q, Wei R Q. Introducing and Influence Testing of the New Cloud Fraction Scheme in the GRAPES[J]. *Meteorological*, 2013, 39(1): 57-66.
- [9] Maddy E S, King T S, Sun H, et al. Using Met Op-AAVHRR Clear-Sky Measurements to Cloud-Clear Met Op-AIASI Column Radiances[J]. *Journal of Atmospheric & Oceanic Technology (S0739-0572)*, 2011, 28(28): 1104-1116.
- [10] 周文君, 牛生杰, 许潇锋. 全天空成像仪云量计算方法的改进[J]. *大气科学学报*, 2014, 37(3): 289-296.
Zhou W J, Niu S J, Xu X F. Improvements of computational methods for cloud cover based on the total sky imager[J]. *Transactions of Atmospheric Sciences*, 2014, 37(3): 289-296.
- [11] 蔡强, 薛子育, 毛典辉, 等. 具有目标偏见的全局对比度显著性区域检测[J]. *系统仿真学报*, 2015, 27(10): 2489-2496.
- Cai Q, Xue Z Y, Mao D H, et al. Salient Region Detection based on Object-Biased Gaussian Refinement and Global Contrast[J]. *Journal of System Simulation*, 2015, 27(10): 2489-2496.
- [12] 马芳, 张强, 郭锐, 等. 多通道卫星云图云检测方法的研究[J]. *大气科学*, 2007, 31(1): 119-128.
Ma F, Zhang Q, Guo N, et al. The Study of Cloud Detection with Multi-Channel Data of Satellite[J]. *Chinese Journal of Atmospheric Sciences*, 2007, 31(1): 119-128.
- [13] Barnes B B, Hu C. A Hybrid Cloud Detection Algorithm to Improve MODIS Sea Surface Temperature Data Quality and Coverage Over the Eastern Gulf of Mexico[J]. *IEEE Transactions on Geoscience & Remote Sensing (S0196-2892)*, 2013, 51(6): 3273-3285.
- [14] Li X L, Tian Y C, Xing K Z, et al. Cloud Extraction of Satellite Image Using Fuzzy C-Means Clustering Approach[J]. *Applied Mechanics & Materials (S1662-7482)*, 2015, 743: 289-292.
- [15] Shi B Q, Liang J, Liu Q. Adaptive simplification of point cloud using k-means clustering[J]. *Computer-Aided Design (S0010-4485)*, 2011, 43(8): 910-922.
- [16] Long C N, Sabburg J M, Calbó J, et al. Retrieving Cloud Characteristics from Ground-Based Daytime Color All-Sky Images[J]. *Journal of Atmospheric & Oceanic Technology (S0739-0572)*, 2006, 23(5): 633-652.
- [17] Gomez-Chova L, Camps-Valls G, Bruzzone L, et al. Mean Map Kernel Methods for Semisupervised Cloud Classification[J]. *IEEE Transactions on Geoscience & Remote Sensing (S0196-2892)*, 2010, 48(1): 207-220.
- [18] Taravat A, Del Frate F, Cornaro C, et al. Neural Networks and Support Vector Machine Algorithms for Automatic Cloud Classification of Whole-Sky Ground-Based Images[J]. *IEEE Geoscience & Remote Sensing Letters (S1545-598X)*, 2015, 12(3): 666-670.
- [19] J Alonso-Montesinos, M Martínez-Durbán, J del Sagrado, et al. The application of Bayesian network classifiers to cloud classification in satellite images[J]. *Renewable Energy (S0960-1481)*, 2016, 97: 155-161.
- [20] Tian H, Zhuang B, Hua Y, et al. Depth inference with convolutional neural network[C]// *Visual Communications and Image Processing Conference. USA: IEEE*, 2014.