

多尺度膨胀卷积神经网络资源三号卫星影像云识别

高琳^{1,2**}, 宋伟东^{1*}, 谭海², 刘阳^{1,2}

¹ 辽宁工程技术大学测绘与地理科学学院, 辽宁 阜新 123000;

² 国家测绘地理信息局卫星测绘应用中心, 北京 100048

摘要 为提高影像云识别精度,提出一种多尺度膨胀卷积神经网络云识别方法。结合卫星影像特征,设计云识别卷积神经网络结构,该结构包含深层特征编码模块、局部多尺度膨胀感知模块以及云区预测解码模块。首先,编码模块中通过基础卷积层获取深度特征;其次,联合多尺度膨胀卷积和池化层共同感知,每层操作连接非线性函数,以提升网络模型的表达能力;最后,云区预测解码模块中融合对应编码模块的特征,再利用 L1 正则化上采样算法实现端对端的像素级云识别结果。选用典型云遮挡区域影像进行云识别实验,并与 Otsu 算法和 FCN-8S 算法进行对比。结果表明,本文所提算法的检测精度较高,Kappa 系数显著提升。

关键词 遥感;神经网络;膨胀卷积;云识别;资源三号卫星影像;全卷积网络

中图分类号 P237

文献标识码 A

doi: 10.3788/AOS201939.0104002

Cloud Detection Based on Multi-Scale Dilation Convolutional Neural Network for ZY-3 Satellite Remote Sensing Imagery

Gao Lin^{1,2**}, Song Weidong^{1*}, Tan Hai², Liu Yang^{1,2}

¹ School of Mapping and Geographical Science, Liaoning Technical University, Fuxin, Liaoning 123000, China;

² Satellite Surveying and Mapping Application Center, National Administration of Surveying, Mapping and Geoinformation, Beijing 100048, China

Abstract To improve the accuracy of cloud detection, we propose a multi-scale dilation convolutional neural network method. Combining with the characteristic of satellite images, we design the deep convolution network structure, which includes a deep-feature coding module, a local dilation perception module, and a cloud-dense decoding module. First, the deep-features of cloud are obtained by the basic convolutional layer in conjunction with the coding module. Second, multi-scale dilation convolution layers jointed with pooling layers are used to perceive corporately. A nonlinear function is employed in each block to improve the effectiveness of network model expression. Finally, the cloud-dense decoding module integrate the features corresponding to those included in the coding module and then utilize the L1 regularization upsampling algorithm to accomplish the end-to-end pixel-level cloud detection task. Cloud detection experiments are performed in the typical cloud mask areas; the results are compared with those of the Otsu algorithm and the FCN-8S method. The results indicate that the accuracy of proposed method is higher and the Kappa coefficient is effectively improved.

Key words remote sensing; neural network; dilation convolution; cloud detection; ZY-3 satellite imagery; fully convolution network

OCIS codes 040.1880; 100.2960; 100.3008

1 引 言

受大气中环境因素的影响,卫星遥感影像存在地物被遮挡,光谱信息失真等问题,严重影响影像的

分发与解译。因此,数据生产前的云识别检测具有重要意义^[1-2]。

目前,遥感影像云识别方法通常是利用云的光谱、频率^[3-6]、纹理^[7-10]等特性,结合阈值法^[11]、统计

收稿日期: 2018-08-08; 修回日期: 2018-08-22; 录用日期: 2018-09-10

基金项目: 国家自然科学基金青年基金(61601213)、中国博士后科学基金(2017M611252)、辽宁省公益研究基金计划(20170003)

* E-mail: Lntu_swd@163.com; ** E-mail: gaolin19920324@163.com

学算法^[12]以及机器学习法^[13]等进行识别。光谱阈值法主要利用云在不同波长的光谱波段中具有不同的反射特性,利用波段间计算归一化阴影指数(NDSI)提取云区范围^[14],该类算法对阈值的敏感程度较高,同一卫星数据因时间、天气等原因,识别边界阈值会发生巨大变化,具有很大的识别局限性。频率阈值法主要运用影像中云遮挡部分的频率较低等特性,通过空频转换手段(傅里叶变换、小波变换)获取影像低频特征进行云识别,但是由于受地面低频地物(沙漠、水域等)干扰,通常采用多尺度小波分解算法进行处理,导致影像云识别效率显著降低。纹理特征法利用云与地面纹理特征的差异,结合灰度共生矩阵等方法获取纹理特征,该类方法需要提前获得准确的云覆盖区域才能保证分类精度,效率较低。为了增强边缘细节信息,基于统计学的算法相继被提出,其中马尔科夫随机场模型的云识别算法^[15]利用高斯混合模型作为后验概率进行识别。统计学算法虽然可以细化边缘信息,但需要人工对不同地物覆盖的影像进行特征分析,海量数据的处理将导致影像的云检测效率降低。以支持向量机为代表的机器学习算法虽然可以实现半自动化云识别,但是由于云的特征需要进行人工分析与选取,因此,该方法并不适用于海量数据的检测。自2014年起,深度学习算法迅速发展,不仅在图像分割分类等模式识别^[16]领域获得了很大的进展,而且在变化监测等相关任务中也取得了很好的效果^[17]。该算法是以卷积操作为核心,将样本在原空间的特征变换到新的特征空间,由计算机根据标签数据学习得到层次化的特征。但网络结构的层级过多,导致影像分辨率降低,网络训练难度增大,因此很难保证模型可训练到最优。

为提高云识别精度,提升数据分发效率,结合资源三号国产卫星数据的高空间分辨率特点,本文提出基于深度学习中卷积神经网络理论,构建深层网络结构,实现快速端对端的影像云识别。受人工智能相关理论^[18-19]启发,分析卷积神经网络核心层,联合多尺度膨胀卷积操作和池化操作共同扩大感知野范围,以损失有效信息最少为前提实现资源三号卫星遥感影像的云识别功能。

2 基本原理

2.1 基础理论

在机器学习理论中,卷积神经网络是通过相互连接的神经元进行消息传递。神经网络是利用简单

的线性模型来表征复杂的函数。

假设输入矢量为 $\mathbf{X} = \{x_1, x_2, \dots, x_n\}$, 输出特征为 $\hat{\mathbf{Y}} = \{\hat{y}_1, \hat{y}_2, \dots, \hat{y}_n\}$; 神经元的卷积过程定义如下:

$$\hat{y}^{(i)} = f(\mathbf{w} * x^{(i)} + b), \quad (1)$$

式中: i 为像元索引; \mathbf{w} 为权重矢量, 即卷积核矩阵; b 为神经元偏置; $*$ 为卷积操作; $f(\cdot)$ 为激活函数。权重和偏置是通过神经网络计算得到的用来定义函数的相关参数。在不同任务需求中, 训练网络的目的就是找到最优参数。激活函数通常为非线性函数, 其作用是提高线性函数的多样表达。常用的非线性激活函数为 Sigmoid 函数、ReLU 函数^[20-21]、Weak ReLU 函数等。ReLU 函数是分段函数, 具有在训练过程中加快收敛的优点, 已被广泛用于神经网络的激活函数。

在信息传递过程中, 受卷积核大小影响, 影像感知范围固定, 因此, 可通过池化层来扩大影像的感知野范围。池化为降采样操作, 常见的池化层模型主要有最大池化层模型和平均池化层模型, 本文使用最大池化层模型。

高分辨率影像的地物复杂, 通过多次降采样虽然能够感知全局特征, 但是也会丢失云区边缘等细节信息, 不能很好地挖掘影像特征。为解决多次池化过程中影像特征丢失的问题, 在多尺度感知模块中, 根据卷积原理, 通过稀疏扩张卷积核扩大感知野范围^[23]。扩张卷积的定义为

$$\hat{y}^{(i)} = f\left[\sum \mathbf{w}(k) * x^{(i)} + b\right], \quad (2)$$

式中: k 为卷积核的膨胀率, 扩张过程如图 1 所示。

图 1(a) 所示为 $3 \text{ pixel} \times 3 \text{ pixel}$ 的卷积核, 其膨胀率为 1, 当膨胀率为 6 时, 卷积核如图 1(b) 所示, 卷积核中相邻像元之间扩张 6 个像元, 每个扩充的像元值用 0 稀疏表示。图 1(c)、(d) 分别为 12 倍扩张和 18 倍扩张的稀疏卷积核。

深度学习领域中主流的上采样算法为双线性插值法, 这种算法的优点是简单、快速、高效, 缺点是简单的内插算法会在上采样过程中出现边缘锯齿效应。因此, 结合 L1 惩罚项的稀疏性质, 提出基于 L1 正则惩罚项的上采样解码算法。

当高分辨率影像降采样为低分辨率时, M 为影像运动估计参数, B 为模糊参数, D 为低分辨率降采样参数, 假设三者已知, 则上采样过程的代价函数为

$$J(y) = \operatorname{argmin} \sum (x - MBDy) + \alpha \|\mathbf{C}\mathbf{Y}\|_1, \quad (3)$$




图 1 不同膨胀率 r 的卷积核。(a) $r=1$; (b) $r=6$; (c) $r=12$; (d) $r=18$

Fig. 1 Convolution kernel with different dilation rates. (a) $r=1$; (b) $r=6$; (c) $r=12$; (d) $r=18$

式中: α 为正则化参数, 控制保真项与惩罚项的权重因子; \mathbf{C} 是二维拉普拉斯滤波矩阵, 可锐化图像以减少图像的边缘锯齿问题。正则化项 $\alpha \|\mathbf{C}\mathbf{Y}\|_1$ 是对特征图上采样过程的约束, L1 范数的稀疏特性使得上采样过程中约束平滑的同时保持较好的边缘信息。因此, 对(3)式进行求导, 可以得到:

$$\nabla_y J = \nabla_y \sum (x - \mathbf{M}\mathbf{B}\mathbf{D}\mathbf{y}) + \alpha \text{sign}(\mathbf{C}\mathbf{Y}), \quad (4)$$

式中: $\text{sign}(\cdot)$ 为符号函数。采用梯度下降法迭代求得(4)式的最优解:

$$J(y) \leftarrow J(y) - \lambda \nabla_y J, \quad (5)$$

式中: λ 为控制梯度下降的步长。在迭代过程中, 若相邻两次上采样结果小于阈值, 则迭代终止。

云识别任务的目标是预测云遮挡的正确位置。当信号传递到最后一层时, 利用损失函数 L 计算预测云位置与实际云位置的差异。假设标签数据记作

$\mathbf{Y} = \{y_1, y_2, \dots, y_n\}$, 预测数据为 $\hat{\mathbf{Y}} = \{\hat{y}_1, \hat{y}_2, \dots, \hat{y}_n\}$, 交叉熵损失函数定义为

$$L = -\frac{1}{n} \sum_{i=1}^n \sum_{k=1}^2 y_k^{(i)} \lg \hat{y}_k^{(i)}. \quad (6)$$

在卷积神经网络的训练过程中, 交叉熵损失函数具有快速收敛的能力, 当与 softmax 归一化相结合时, 具有较好的稳定性。

2.2 多尺度膨胀卷积神经网络结构

资源三号卫星影像具有分辨率高的特点, 而且该特征在云识别任务中至关重要。因此, 在云检测过程中要考虑保留云区地物的背景信息和分辨率。

图 2 所示为所提出的神经网络结构, 该神经网络结构主要包括深层特征编码模块、局部多尺度膨胀感知模块和云区预测解码模块。所有的模块设计是通过结合池化层与膨胀卷积层降低云检测过程中的信息损失, 扩大感知野范围, 挖掘影像中云层的深层特征信息。深层特征编码模块可用于全局云覆盖区域深层特征的提取, 卷积核尺寸不变, 设计两层池化层。每一次最大池化操作后, 保证卷积核尺寸不变, 成倍增加特征图的数量。随后, 局部多尺度膨胀

感知模块包含 4 个不同尺度且彼此独立的膨胀卷积层, 每个膨胀尺度后增加局部全卷积层。为减少降采样带来的薄云区域等高频信息损失, 融合深层特征编码特征, 逐层上采样, 利用 1×1 卷积大小的全卷积层输出与输入分辨率相同的云识别概率图。在后处理过程中, 对云的概率图进行检测, 利用阈值法提取云区掩膜。

1) 深层特征编码模块

深层特征编码模块的作用是提取云层的深层特征, 提高网络结构对薄雾、薄云等区域的识别度。目前, 许多模式识别网络中利用多层(5 层)池化层来扩大感知野尺寸。然而, 多次降采样虽然可以减少参数数量, 但大大降低了特征的空间分辨率。而摒弃池化操作的结果不仅会导致参数灾难, 而且无法获取全局目标的特征。

为满足扩大感知野范围和保证较高的分辨率, 在深层特征编码模块中设计两层降采样操作, 参考遥感领域中神经网络算法中的双层池化层设计, 通过实验发现, 单层降采样提取的云特征效果不明显, 对雾及薄云区域识别度较低。如图 2 所示, 该模块卷积层中卷积核的尺寸为 $3 \text{ pixel} \times 3 \text{ pixel}$, 为保证卷积输入流与输出流的尺寸一致, 设置像元值为 0 的补边, 特征图像的数量为 64。ReLU 函数对卷积操作进行非线性变换, 使得简单的线性函数具有复杂的表示。随后连接降采样操作层, 由于尺寸的缩小限制了特征的表达能力, 卷积输出的特征图成倍增加。尽管文献[22]完全摒弃了池化层操作, 利用膨胀卷积来扩大感知野范围, 但这种网络结构对训练图像尺寸的依赖性较大; 同时, 虽然利用卷积核的稀疏表示能够在一定程度上扩大感知范围, 但在分辨率不变的情况下, 会出现维度灾难等问题。因此, 设计尽可能少的池化层不仅能够获取图像的全局深层特征, 而且可以节约了训练时间成本。然而, 该模块仅提供云的深层特征, 并没有对信息进行深入挖掘。

2) 局部多尺度膨胀感知模块

局部多尺度膨胀感知模块的作用是弥补感知野

范围受限导致的特征不足等缺陷。本文方法对深层特征进行多尺度膨胀卷积,通过膨胀率控制尺度大小,依照经验,利用尺寸为 $3 \text{ pixel} \times 3 \text{ pixel}$ 的卷积核分别对膨胀率为 1、2、3、4、6、12、18、24 的尺度进行测试,结果表明膨胀率分别为 6、12、18、24 的测试结果较优,因此,本文在局部多尺度膨胀感知模块中膨胀参数选取的依据是相关文献经验结合测试验证。在该模块中,由于影像的分辨率恒定,因此特征图像的数量恒定为 512。不同尺度的特征挖掘均是基于上一模块的深层特征,感知野范围形成金字塔形状。如图 2 所示,红色单元与浅蓝色单元相连接,浅蓝色单元为全卷积层,是为保留像元之间的相对位置关系而设计的特征缓冲层。根据膨胀卷积原理,随着卷积核尺度增大,特征感知过程中相邻像元

的无重叠区域增大,从而实现局部特征感知。为防止尺度差异导致卷积输出特征尺寸不同,在卷积过程中设置补边参数,保证输入与输出的图像大小相同。最后,将 4 个尺度的特征图融合,提取影像中的云特征。

3) 云区预测解码模块

为了解决云特征分辨率与原始输入数据分辨率不一致的问题,提出云区预测解码模块,该模块是基于 L1 正则化的上采样算法。为了减少池化层带来的高频信息损失,融合与深层编码模块中尺寸一一对应的特征图像,并对融合影像进行特征还原,以降低由于直接上采样而产生的锯齿边缘效应的影响。云区的深层特征与输入数据相差 4 倍,因此在云区预测解码模块中包括两层上采样模块。

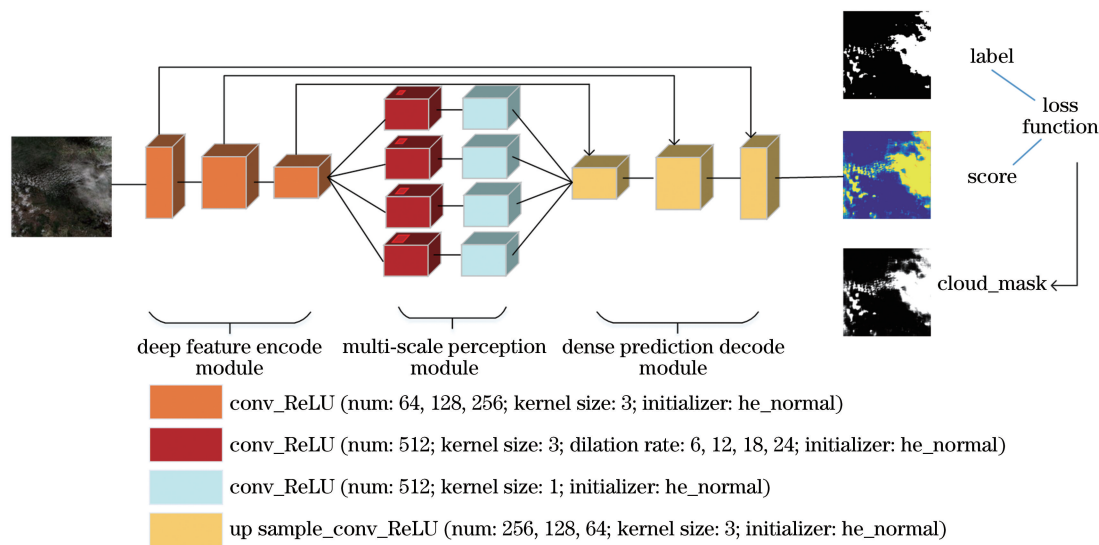


图 2 深度多尺度膨胀全卷积神经网络结构

Fig. 2 Schematic of deep multiscale dilation fully convolutional neural network architecture

2.3 神经网络结构分析

与自然图像不同,遥感影像的分辨率高、覆盖范围广,当今流行的网络结构在高分辨率遥感影像云识别任务中的结果差强人意。深度学习算法中,核心池化层可以降低参数数量、扩大卷积核的感知范围,其分辨率可降低 32 倍。然而,在遥感影像的云检测任务中,5 层池化操作会使云遮挡区域的边缘信息损失严重,不能体现高分辨率的优势;而以 Alexnet 网络为主的两层池化操作使得薄云的误检率较高,说明两层池化操作并不能提取到影像的深层特征信息。实验结果表明,与两层池化网络相比,三层池化网络可以获取深层信息。

当网络结构深度不同时,各层级所反映出的云量不尽相同。以 Alexnet 为基础,即包括两层池化

层的 U 型网络及本文所提网络,对比分析如图 3 所示。由于中间层的尺寸为高维度数据,为清晰细化不同层级下的云量特征,本研究提取网络中间数据,采用主成分变换(PCA)对超高维度的云层特征的第一主成分进行可视化分析。两层池化与三层池化网络模块即使在相同层级下传递的特征信息也不尽相同。如图 3 所示,对本文所提网络结构与 Alex U net 网络进行对比,分析不同池化层对云特征的敏感程度。可以看出:Alex U net 网络对与云具有相同反射率的地物较为敏感,存在云层边界特征模糊的问题;而本文所提的三层网络结构在特征学习的过程中能够细化云遮挡区域的边界。

基于多尺度膨胀卷积神经网络的资源三号卫星影像云识别方法主要贡献为:1)制作影像云识别数

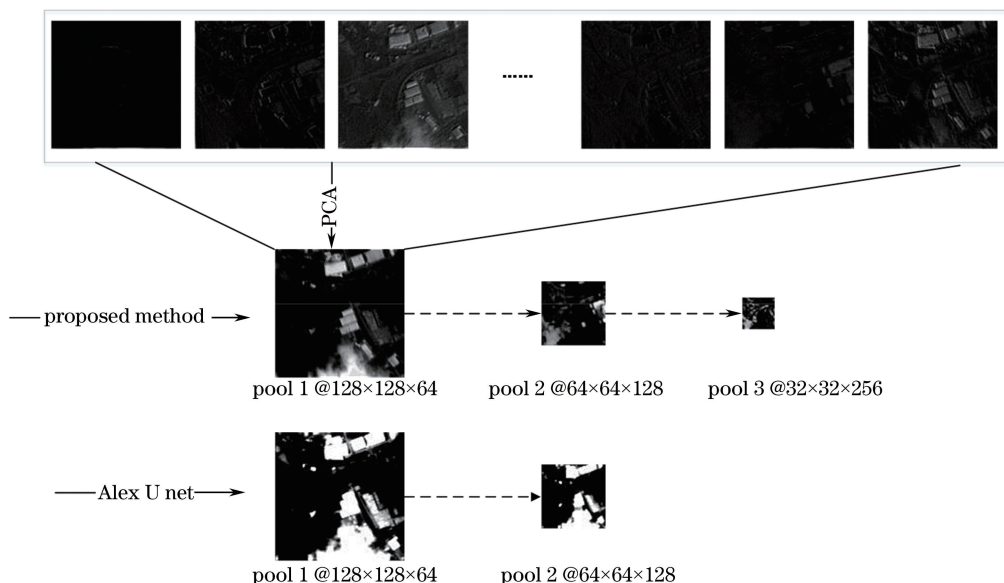


图 3 不同池化层级的云量可视化分析

Fig. 3 Visual analysis on cloud area for different pooling layers

数据集(训练集、验证集及测试集); 2) 提出新的卷积神经网络结构,通过实验分析,验证所提网络的有效性与可行性;3)针对传统插值上采样算法,提出基于L1正则化的上采样算法,经实验证明该算法能够降低锯齿效应所带来的影响,保留更丰富的边缘信息。

3 实验与分析

选取资源三号卫星影像作为实验数据。数据相

关参数如表 1 所示。在制作训练集过程中,为防止出现过拟合与欠拟合现象,制作了 1400 个含标签数据的云识别影像用于网络训练与验证;选取 100 张影像进行测试。考虑到卷积操作过程中的影像边缘问题,本研究增加边缘保护操作,以保证影像四周能够参与卷积感知。

由于卷积操作导致影像边缘无法被识别与分割,因此基于深度学习感知野范围分析理论^[25],设

表 1 资源三号卫星多光谱影像训练集参数

Table 1 Multi-spectral image parameters of ZY-3 satellite

Index	Parameter
Resolution /m	5.8
Wavelength /nm	Band 1: 450-520; Band 2: 520-590 Band 3: 630-690; Band 4: 770-890
Width /km	52
Single scene /km ²	2704
Latitude range	upper left: 30.5633N; upper right: 30.4678N lower left: 30.1186N; lower right: 30.0234N
Longitude range	upper left: 113.7162E; upper right: 114.2382E lower left: 113.6103E; lower right: 114.1299E

计影像边缘保护法,对影像进行边缘填充,以影像边缘为基础,从影像中心向外扩充 5 行 5 列,将训练图像分为有效识别区域与边缘保护区域。而保护区域的尺寸由训练网络的最大卷积核尺寸决定。例如,当设计的神经网络最大卷积核为 7×7 时,以影像中心为原点,边缘向外部扩充 2 层,当原始训练影像为 250 pixel×250 pixel 时,实际训练影像的尺寸为 256 pixel×256 pixel。如图 4 所示,红色边框内部

为影像的有效训练区域,红色边框的值是图像四周像元值的复制,为训练保护区,这就解决了影像周围无法识别的问题。

为验证所设计网络的可行性,选取相同云区标签数据集为训练对象,并与文献[26]提出的 FCN-8S 网络结构进行对比(表 2)。与 FCN-8S 网络相比,本文提出的多尺度膨胀卷积神经网络的结构精度提升了 9.9%。在时间成本方面,由于 FCN-8S 网



图 4 训练影像边缘保护示意图

Fig. 4 Diagram of edge protection of training image
 网络的训练是在 FCN-32S 与 FCN-16S 的基础上进一步移植训练得到的,首先训练 FCN-32S 网络模型,根据该模型,然后训练 FCN-16S,最后在 FCN-16S 模型的基础上训练 FCN-8S,因此整个 FCN-8S 网络训练过程包括 3 次训练,总训练时长为 36 h,而本文所提算法不需要依赖其他网络结构,因此本文所提算法的训练时间较短。

表 2 网络结构精度对比

Table 2 Comparison of the accuracy of different network structures

Method	Accuracy /%	Training time /h
FCN-8S	86.9	36
Proposed	96.8	14

本实验环境在 Mint 17.3 系统下的 Keras 深度学习框架,硬件环境为 Intel(R) Xeon(R) CPU@ 2.20 Hz GPU NVIDIA Quadro M6000 16 G 内存。神经网络结构如图 2 所示。为了验证多尺度膨胀卷积神经网络的资源三号卫星遥感影像云识别方法的

有效性,与 Otsu^[27]算法和 FCN-8S 网络进行对比。测试数据为资源三号卫星的多光谱影像,中心经纬度为 (115.034577E, 30.286345N),获取时间为 2017 年 10 月 22 日,分辨率为 5.8 m,原始影像尺寸为 8820 pixel×8787 pixel;由于 GPU 内存限制,将测试数据裁剪为 256 pixel×256 pixel 的影像块。

由图 5 可知,本文提出的云识别算法测试结果中,云遮挡部分的边界较清晰,薄云也能够较好地被识别与定位。在同时分布薄云和厚云的影像中,本文提出的方法能够准确识别出复杂环境下薄云和厚云分布,误检率低。Otsu 算法在背景环境相对简单的影像中能够准确识别云区范围,但将厚云边界存在的中厚云覆盖区域误检为无云遮挡;在背景相对复杂区域,Otsu 算法存在边缘误检现象,将具有同类高反射率的地物如建筑物屋顶、道路等误检为云遮挡。FCN-8S 算法丢失云区边缘细节,针对厚云和薄云共存的背景,FCN-8S 算法虽能够识别到云区的位置,但是边界模糊,边缘缺失带来的误检现象较多。由此可见,本文所提算法可提高复杂环境下的云识别精度,并能够实现端对端的检测,减少云检时间。

为了定量评价所提出云识别方法的可靠性,选用通过混淆矩阵计算总体精度(OA)、F1-measure 和 Kappa 系数三项指标来定量评价云识别结果精度,结果如表 3 所示,其中 D_{OA} 和 D_{Kappa} 分别为对比算法与本文所提算法的总体精度和 Kappa 系数的差值。

表 3 不同算法的定量评估参数

Table 3 Quantity evaluation parameters of different algorithms

Fig.	Detection algorithm	OA	D_{OA}	F1-measure	Kappa	D_{Kappa}
Fig. 5(a)	Otsu	0.9444	-0.0458	0.9668	0.7990	-0.1687
	FCN-8S	0.9661	-0.0241	0.9793	0.8867	-0.081
	Proposed	0.9902	—	0.9936	0.9677	—
Fig. 5(b)	Otsu	0.8413	-0.0895	0.8412	0.6869	-0.1705
	FCN-8S	0.9096	-0.0212	0.9150	0.8189	-0.0385
	Proposed	0.9308	—	0.9416	0.8574	—
Fig. 5(c)	Otsu	0.8580	-0.1075	0.8837	0.7075	-0.2106
	FCN-8S	0.8841	-0.0814	0.9076	0.7544	-0.1637
	Proposed	0.9655	—	0.9755	0.9181	—
Fig. 5(d)	Otsu	0.9731	-0.0146	0.9855	0.8100	-0.0686
	FCN-8S	0.9789	-0.0069	0.9886	0.8440	-0.0346
	Proposed	0.9858	—	0.9928	0.8786	—
Fig. 5(e)	Otsu	0.7649	-0.2275	0.1277	0.0987	-0.6152
	FCN-8S	0.9767	-0.0157	0.5386	0.5279	-0.0186
	Proposed	0.9924	—	0.7175	0.7139	—




图 5 不同区域的云识图像对比。(a)厚云覆盖区域;(b)中厚云覆盖区域;(c)厚云与薄云共存区域;(d)厚云和薄雾共存区域,且地物环境较复杂;(e)大比例厚云覆盖区域

Fig. 5 Comparison of cloud detection results at different areas using different algorithms. (a) Area covered by thick cloud; (b) area covered by middle-thick cloud; (c) area covered by thick and thin clouds; (d) area covered by thick cloud and haze with the a complex scene; (e) area covered by a large range of thick cloud

混淆矩阵中的参考影像是基于原始影像,利用 Photoshop 软件人工绘制,在模糊云遮挡区域边缘羽化为 3 个像元,清晰云遮挡区域边缘精度为 1 个像元。由表 3 可知,与 Otsu 算法相比,本文算法提取的云遮挡区域边缘得到明显细化;与 FCN-8S 算法相比,本文算法的 Kappa 系数能够提高 0.1 以上,例如:对于图 5(e)所示的厚云占很大比例,边缘细节比较模糊的区域,Otsu 算法无法识别出薄云范围,FCN-8S 算法在云区边缘识别能力较差,本文所提算法在厚云薄云共存时的云识别能力较好;对于图 5(c)所示的复杂地物下薄云覆盖区域,本文提出的网络算

法总体精度比 Otsu 算法提升 10%;比 FCN-8S 算法提升 8%;Kappa 系数分别提升了 0.2106 和 0.1637。通过定量评估方法验证了本文所提网络结构能够提高资源三号卫星影像云检测精度。

通过定性与定量方法对多尺度膨胀卷积神经网络进行评估,发现本文所提云识别算法的效果较好,这主要是因为多尺度膨胀卷积操作和池化操作联合感知影像中云覆盖区域,基于 L1 正则项的上采样方法,能够有效保证边缘细节的高频信息,很好地定位复杂的云区域,实现端对端的云检测任务,并取得较好的检测结果。

4 结 论

多尺度膨胀卷积神经网络算法在资源三号卫星影像的云识别任务中,弥补了传统算法的不足,提高了云识别定位精度,该方法可用于资源三号卫星影像的质量检查与云区提取等,以提高数据分发的效率。与机器学习算法和现有 FCN-8S 网络云识别算法相比,多尺度膨胀卷积神经网络算法的优势在于细化云区边界,并具有较高的测量精度和较低的误检率,适用于薄云和厚云共同存在的影像,弥补了国产卫星影像波段少的缺点。

随着人工智能技术的发展,深度卷积神经网络算法在云识别领域具有较大潜力,在国产资源三号卫星质量检查过程中能够实现快速云检功能,降低了质量检查的时间成本。然而,本文提出的云识别方法还存在诸多不足,例如没有进行参数以及超参数设置的对比依据,薄雾的识别率较低,无法区分具有相同光谱及纹理特性的地物(建筑物屋顶、雪覆盖区域)等。下一步工作将在网络结构中引入云区的光谱特性,及找寻优化依据等方面进行研究,期待能在复杂的环境下进一步提高云识别精度,并应用于实际生产。

参 考 文 献

- [1] Pan H B, Zhang G, Tang X M, *et al.* The geometrical model of sensor corrected products for ZY-3 satellite[J]. *Acta Geodaetica et Cartographica Sinica*, 2013, 42(4): 516-522.
潘红播, 张过, 唐新明, 等. 资源三号测绘卫星传感器校正产品几何模型[J]. *测绘学报*, 2013, 42(4): 516-522.
- [2] Chen Y, Fan R S, Wang J X, *et al.* Cloud detection of ZY-3 satellite remote sensing images based on deep learning [J]. *Acta Optica Sinica*, 2018, 38 (1): 0128005.
陈洋, 范荣双, 王竞雪, 等. 基于深度学习的资源三号卫星遥感影像云检测方法[J]. *光学学报*, 2018, 38 (1): 0128005.
- [3] Chen P Y, Srinivasan R, Fedosejevs G, *et al.* An automated cloud detection method for daily NOAA-14 AVHRR data for Texas, USA[J]. *International Journal of Remote Sensing*, 2002, 23(15): 2939-2950.
- [4] Otsu N. A threshold selection method from gray-level histograms[J]. *IEEE Transactions on Systems, Man, and Cybernetics*, 1979, 9(1): 62-66.
- [5] Zhu Z, Woodcock C E. Object-based cloud and cloud shadow detection in Landsat imagery [J]. *Remote Sensing of Environment*, 2012, 118: 83-94.
- [6] Panem C, Baillarin S, Latry C, *et al.* Automatic cloud detection on high resolution images [C]//Proceedings of IEEE International Geoscience and Remote Sensing Symposium. Seoul: IEEE, 2005: 1-4.
- [7] Qin Y, Fu Z L, Zhou F, *et al.* A method of automatic cloud detection using TM images [J]. *Geomatics and Information Science of Wuhan University*, 2014, 39(2): 234-238.
秦永, 付仲良, 周凡, 等. 一种利用 TM 影像自动检测云层的方法 [J]. *武汉大学学报(信息科学版)*, 2014, 39(2): 234-238.
- [8] Liu J. Improvement of dynamic threshold value extraction technic in FY-2 cloud detection[J]. *Journal of Infrared and Millimeter Waves*, 2010, 29(4): 288-292.
刘健. FY-2 云检测中动态阈值提取技术改进方法研究 [J]. *红外与毫米波学报*, 2010, 29(4): 288-292.
- [9] Shan N, Zheng T Y, Wang Z S. High-speed and high-accuracy algorithm for cloud detection and its application [J]. *Journal of Remote Sensing*, 2009, 13(6): 1138-1155.
单娜, 郑天垚, 王贞松. 快速高准确度云检测算法及其应用 [J]. *遥感学报*, 2009, 13(6): 1138-1155.
- [10] Harb M, Gamba P, Dellacqua F. Automatic delineation of clouds and their shadows in Landsat and CBERS (HRCC) data [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2016, 9(4): 1532-1542.
- [11] Braaten J D, Cohen W B, Yang Z. Automated cloud and cloud shadow identification in Landsat MSS imagery for temperate ecosystems [J]. *Remote Sensing of Environment*, 2015, 169: 128-138.
- [12] Cheng Q, Shen H F, Zhang L P, *et al.* Cloud removal for remotely sensed images by similar pixel replacement guided with a spatio-temporal MRF model [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2014, 92: 54-68.
- [13] Ozkan S, Efendioglu M, Demirpolat C. Cloud detection from RGB color remote sensing images with deep pyramid networks [J/OL]. *Computer Science*, 2018. [2018-08-08]. <https://arxiv.org/pdf/1801.08706.pdf>.
- [14] Scaramuzza P L, Bouchard M A, Dwyer J L. Development of the Landsat data continuity mission cloud-cover assessment algorithms [J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2012, 50(4): 1140-1154.
- [15] Murtagh F, Barreto D, Marcello J. Decision boundaries using bayes factors: the case of cloud masks [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2003, 41(12): 2952-2958.
- [16] Chen L C, Papandreou G, Kokkinos I, *et al.* DeepLab: semantic image segmentation with deep convolutional

- nets, atrous convolution, and fully connected CRFs[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2016, 40(4): 834-848.
- [17] Lu Y S, Li Y X, Liu B, *et al.* Hyperspectral data haze monitoring based on deep residual network [J]. Acta Optica Sinica, 2017, 37(11): 1128001.
陆永帅, 李元祥, 刘波, 等. 基于深度残差网络的高光谱遥感数据霾监测 [J]. 光学学报, 2017, 37(11): 1128001.
- [18] Badrinarayanan V, Kendall A, Cipolla R. SegNet: a deep convolutional encoder-decoder architecture for image segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(12): 2481-2495.
- [19] Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation[C]//International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham: Springer, 2015: 234-241.
- [20] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6): 84-90.
- [21] LeCun Y, Bengio Y, Hinton G. Deep learning [J]. Nature, 2015, 521(7553): 436-444.
- [22] Hamaguchi R, Fujita A, Nemoto K, *et al.* Effective use of dilated convolutions for segmenting small object instances in remote sensing imagery [C]. IEEE Winter Conference on Applications of Computer Vision, 2018: 1442-1450.
- [23] Hinton G E. Learning multiple layers of representation [J]. Trends in Cognitive Sciences, 2007, 11(10): 428-434.
- [24] Kingma D, Ba J. Adam: a method for stochastic optimization[J/OL]. Computer Science, 2014. [2018-08-08]. <https://arxiv.org/pdf/1412.6980.pdf>.
- [25] Luo W, Li Y, Urtasun R, *et al.* Understanding the effective receptive field in deep convolutional neural networks[J/OL]. Computer Science, 2017. [2018-08-08]. <https://arxiv.org/pdf/1701.04128.pdf>.
- [26] Shelhamer E, Long J, Darrell T. Fully convolutional networks for semantic segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(4): 640-651.
- [27] Gao X J, Wang Y C, Zheng S Y, *et al.* Real-time automatic cloud detection during the process of taking aerial photographs [J]. Spectroscopy and Spectral Analysis, 2014, 34(7): 1909-1913.
高贤君, 万幼川, 郑顺义, 等. 航空摄影过程中云的实时自动检测 [J]. 光谱学与光谱分析, 2014, 34(7): 1909-1913.