

基于改进的全卷积神经网络的资源三号遥感影像云检测

裴亮¹, 刘阳^{1,2*}, 谭海², 高琳¹

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 提出了基于改进的深度学习全卷积神经网络的资源三号遥感影像云检测方法。将预训练后的深层卷积神经网络全连接层改为全卷积层,采用反卷积方法对特征图进行上采样,优化改进网络结构,并采用 Adam 梯度下降法加速收敛。利用资源三号云区影像数据集对网络进行训练,将上采样后的影像特征输入 sigmoid 分类器进行分类。实验结果表明,该方法检测精度和速度均优于传统方法,准确率可达 90.11%,单张影像检测耗时可缩短至 0.46 s。

关键词 遥感; 资源三号影像; 深度学习; 全卷积网络; 云检测

中图分类号 P237

文献标识码 A

doi: 10.3788/LOP56.052801

Cloud Detection of ZY-3 Satellite Remote Sensing Images Based on Improved Fully Convolutional Neural Networks

Pei Liang¹, Liu Yang^{1,2*}, Tan Hai², Gao Lin¹

¹ School of Geomatics, Liaoning Technical University, Fuxin, Liaoning 123000, China;

² Satellite Surveying and Mapping Application Center, NASG, Beijing 100048, China

Abstract A method for cloud detection of ZY-3 satellite remote sensing images is proposed based on improved deep learning fully convolutional neural network. In pre-trained deep convolutional neural network, full convolution layer is used instead of full connection layer, and deconvolution method is used to up-sample feature map to optimize and improve network structure, then the Adam gradient descent method is adopted to accelerate convergence. The network is trained by using the resource image database of ZY-3 satellite, and the up-sampled image features are input into the Sigmoid classifier. Experimental results show that the proposed method performs better than the traditional methods in terms of detection accuracy and speed. The accuracy achieves 90.11%, and detection time can be reduced to 0.46 s.

Key words remote sensing; ZY-3 images; deep learning; fully convolutional networks; cloud detection

OCIS codes 280.4788; 100.2960; 100.2980; 100.3008

1 引言

在光学卫星影像中,云层是可见光和红外波段的主要污染源之一。由于传感器受大气密度和云层变化等影响较大,许多影像存在云层遮挡问题,因此影像局部模糊不清甚至存在“盲区”,极大地影响了对地观测和地标提取。在进行传感器校正产品的生产前,资源三号测绘卫星的数据需要剔除云量覆盖

过大的影像,以减轻生产负担,提高生产效率。

目前,遥感影像主要利用可见光或近红外光谱阈值法进行云检测,该方法利用云的高反射率和低温特性将云层与其他地物分离,计算简单,检测效率高,缺点是当地面覆盖了冰、雪、沙漠或云为薄卷云、层云和小积云时,云和地面难以区分,因为大部分光谱方法只适用于特定场景或识别不同的云^[1]。此外,一般国产高分卫星波段仅含有蓝、绿、红、近红外

收稿日期: 2018-07-19; 修回日期: 2018-09-10; 录用日期: 2018-09-12

基金项目: 辽宁省教育厅科学研究项目(L2015215)

* E-mail: 764039378@qq.com

4个波段,基于影像光谱特征的云区检测方法的劣势难以在资源三号卫星影像上体现^[2]。随着相关技术的发展,基于云纹理和空间特征的检测方法以及模式识别等技术在云区检测方向上得到了广泛应用,赵晓^[3]利用模糊C均值聚类方法通过最小化目标函数完成样本迭代聚类,利用支持向量机(SVM)聚类法进行类属判别,该方法在具备先验知识的条件下可以获得较好的分类结果,但人为干预极大地影响检测效率。

近年来,深度学习算法在自然语言处理、降维、运动建模、人工智能,以及图像分类等领域取得了诸多成果^[4-11]。从初始的卷积神经网络 LeNet^[12]到后来的 AlexNet^[13]深度神经网络模型,卷积神经网络(CNN)在图像分类和图像检测等方面已取得巨大成就和广泛应用。CNN本质上是一个多层感知机,其受生物学知识启发并结合了人工神经网络的特点^[14],采用局部连接和权值共享的方式使得网络易于优化,卷积层数越深,感受域范围越大,越能学习到更抽象的影像特征。通常,CNN网络在卷积层之后会连接若干全连接层,将卷积层产生的特征图映射成一个固定长度的特征向量。经典CNN结构适合于图像级分类和回归任务,最后得到关于整个输入影像的数值描述(概率),如 AlexNet 的 ImageNet 模型输出的一个 1000 维向量用于表示输入图像属于每一类的概率;陈洋等^[15]利用 CNN 进行遥感影像云检测,有效解决了波段少和光谱范围受限而导致的阈值法检测效果不佳的问题,但该方法只能获得云检概率图,不能实现像素级影像输出;2015年,Long等^[16]提出了全卷积神经网络(FCNN),并将其用于图像语义分割,与经典的 CNN 在卷积层之后使用全连接层得到固定长度的特征向量进行分类不同,FCNN 可以接受任意尺寸的输入图像,对影像进行像素级分类。

针对资源三号遥感影像可用波段少、光谱信息受限,且传统云区检测方法效率难以满足实际影像生产等问题,本文提出基于改进的 FCNN 算法,并将其应用于资源三号卫星的遥感影像云区检测,对三次上采样后的全卷积神经网络(FCN-8s)进行再优化(8s代表输出图像扩大8倍),实验结果表明,该方法可以明显提高云区检测精度。

2 原理与方法

2.1 数据集预处理

为了提高实验精度和速度,进行神经网络训练

和测试前,必须对样本数据集进行归一化处理。本文采用特征标准化法,首先计算云区影像数据各维度数据的均值并减去,除以该维度数据的标准差,使得云区影像数据的每一个维度都具有零均值和单位方差。

2.2 CNN 基本原理

CNN的作用在于其多层结构能够自主学习输入影像特征。作为一种多层的监督学习神经网络,隐含层的卷积层和池化层是实现 CNN 特征提取功能的核心模块。

卷积,即对输入影像和滤波矩阵做内积。在 CNN 中,卷积层的每一个卷积滤波器重复作用于整个感受野中,对输入图像的卷积结果构成了输入图像的特征图,可用于提取图像的局部特征。CNN 的突出特点在于其局部连接和权值共享的方式,一方面减少了权值数量,使得网络易于优化;另一方面降低了过拟合风险,在卷积结果后加偏置项并经激活函数完成函数映射。利用公式可以将卷积表示为

$$X_j^l = f\left(\sum X_i^{l-1} \cdot k_{ij}^l + b_j^l\right), \quad (1)$$

式中 i 代表卷积行数, j 代表卷积列数, l 代表对应卷积层的层数, k 为该层卷积核, b 为该层的偏置项, $f(\cdot)$ 为对应的激活函数,其作用是对上层卷积层提取的简单低维特征进行非线性映射,并组合出更复杂的高维特征^[17]。权重和偏置项为卷积过程的中间参数,为输入影像信息通过卷积层向前传递的值。由于卷积是一种线性运算,而对于样本集,其不一定为线性运算,为此利用非线性激活函数,可以将训练得到的云区特征保留并映射,增强神经网络的表达能力。常见的激活函数包括 Sigmoid、tanh、ReLU。本文采用 ReLU 激活函数,该函数具有收敛速度快、泛化性能好和运算量小等特点。

池化层用于进行非线性降采样,当卷积获得输入影像的特征后,利用特征对影像数据进行分类,但该过程计算量较大,因此需要在两个相邻的卷积层之间插入池化层对卷积特征进行降维,常用的池化操作有最大池化和平均池化,本文采用最大池化方法。该方法将卷积特征划分为 n^2 个不相交区域,这些区域中的最大特征表示降维后的卷积特征,这样就减小了隐藏层的计算复杂度,增强了对输入影像平移缩放等操作的稳健性。池化层可利用公式表示为

$$X_{i,j}^l = \max_{m>0, s>n} \{X_{i+s+m, j, s+n}^{l-1}\}, \quad (2)$$

式中 s 表示池化的模板尺寸, m 和 n 表示相应方向的步长。

可以将实验过程视为一个二分类过程,而二分类的云区检测问题可以看作是逻辑斯谛回归任务,当信号传递至最后一层时,利用参数优化算法不断最小化损失函数(损失函数通过对比目标矢量标签和预测矢量标签进行量化误差)。本文网络结构的最后一层卷积层连接 sigmoid 正则项和二进制交叉熵损失函数 C ,可以表示为

$$C = -\frac{1}{n} \sum_x [y \cdot \ln a - (1 - y) \cdot \ln(1 - a)], \quad (3)$$

影像中每一个像素对应的标签值均 $\in [0, 1]$, a 为分类输出正确类的结果, y 为对应正确类的标签, x 表示样本, n 表示样本总数。当 a 接近于 1 时,对应正确类的标签为 1,即 $y = 1$, C 中第一项接近于 0 时,第二项等于 0。对于非正确类, a 接近于 0 时, $y = 0$ 。故最终 C 接近于 0,当分类输出正确类的结果与 1 差距越大, C 值越大。

传统 CNN 参数优化算法多采用随机梯度下降 (SGD),该方法适合于小批量网络训练,下降速度慢且存在非最优点持续振荡等问题。SGD 为最初算法,加入了一阶动量后得到 SGDM 算法,AdaGrad 和 RMSProp 是在其基础上加入了二阶动量,本文采用的 Adam 算法为自适应+动量算法,是在 SGD 基础上加入了一、二阶动量,利用梯度一阶和二阶矩

估计动态调整每个参数学习率,经过偏置校正后,每一次迭代学习率都有确定范围,参数比较平稳,收敛速度加快。

2.3 FCNN 基本原理

FCNN 基于深度卷积神经网络 (VGG-16)^[18],在 2014 年 ILVRC (Image NeLarge-Scale Visual Recognition Challenge 2014) 定位与分类竞赛中,分别获得了第一名和第二名。VGG-net 所有卷积层均使用 3×3 的卷积核,前 4 层为一层卷积加一层池化交替结构,第 5 层到第 13 层为两层卷积加一层池化交替结构,第 14 层到第 16 层为全连接层,其中,卷积层提取局部特征,全连接层描述图像全局特征,最后连接一层 Softmax 分类层。该网络适用于图像级分类和回归任务,将卷积层产生的特征图映射为固定长度的特征向量,得到关于输出结果的概率值。

实验中云区对应位置检测为像素级分类结果,相当于对每个像素进行一次二分类,目的是将图像分割为两个区域,使语义相同的像素分割在同一区域内。CNN 的后三层均为一维向量,计算方式不再采用卷积,因此二维信息丢失,采用 FCNN 将这三层全部转化为 1×1 的卷积核所对应的等同向量长度多通道卷积层,后三层全连接层全部转化为卷积计算,如图 1 所示。

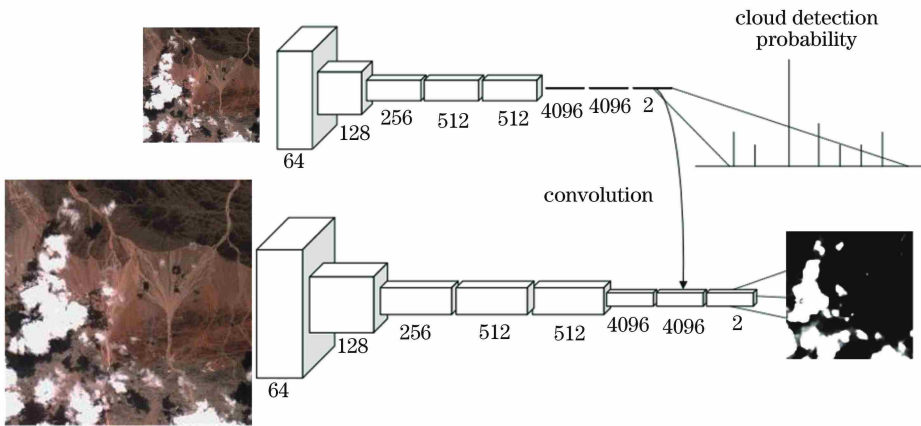


图 1 FCNN 示意图

Fig. 1 Schematic of FCNN

FCNN 经过多次卷积和池化后得到的图像越来越小,5 次卷积池化之后图像的分辨率依次缩小 2,4,6,8,16,32 倍,为了输出和原始图像同等大小的检测结果,需要对最后一层输出图像进行 32 倍上采样。

图 2 中 $n \times$ 表示对应的特征图上采样 n 倍(即

变大 n 倍), $32 \times$ upsampld 表示·图像变大 32 倍, $2 \times$ conv7 表示 conv7 的特征图变大 2 倍,图中其他含义类似。conv 表示卷积层,conv1 表示第一层卷积操作。第一行为 FCNN,输出层为卷积层,整个网络中包含 5 个池化层,输出结果中单个像素对应输入影像中的 $32 \text{ pixel} \times 32 \text{ pixel}$,尺寸大小为输入原

图的 1/32。为了得到与输入影像尺寸统一的输出影像,对 FCNN 进行上采样,在输出影像的像素点之间引入二次线性插值算法,在网络结构中以反卷积层形式实现。但是以上操作仅能还原输出结果的尺寸大小,不能精细化还原云区边缘位置,因此,在 FCN 的基础上改进网络结构以提高影像分辨率。如第二行中 FCN-16s 所示,池化层 pool4 的输出分辨率为 16 pixel 的影像结果,首先对图 2 的池化层 pool5 进行 2 倍上采样,再与 pool4 层特征融合获取反卷积结果,这样既可保留池化层 pool4 中的细节信息,又

能达到 16 pixel×16 pixel 的分类精度。第三行 FCN-8s 的网络原理是将 FCN-16s 网络中的特征融合结果再进行 2 倍上采样,并与输出分辨率为 8 pixel 的 pool3 层特征融合获得 8 pixel×8 pixel 的分类精度。其中 FCN-32s 表示一次上采样后的全卷积神经网络,32s 表示输出图像扩大 32 倍,FCN-16s 代表二次上采样后的全卷积神经网络,16s 表示输出图像扩大 16 倍,FCN-8s 代表三次上采样后的全卷积神经网络,8s 表示输出图像扩大 8 倍。实验结果如表 1 所示,其中 mean IU 表示识别准确度的平均值。




图 2 FCNN 原理示意图

Fig. 2 Schematic of principles of FCNN

表 1 不同网络结构准确率对比

Table 1 Accuracy comparison of different network structures

| Types of network | Overall accuracy | Mean accuracy | Mean IU |
|------------------|------------------|---------------|---------|
| FCN-8s | 0.8988 | 0.8010 | 0.7396 |
| FCN-16s | 0.8965 | 0.7963 | 0.7339 |
| FCN-32s | 0.8891 | 0.7867 | 0.7185 |

FCN-8s 网络训练是在 FCN-32s 与 FCN-16s 的基础上进一步移植训练而来,首先对 FCN-32s 网络结构进行训练,通过 FCN-32s 的训练模型训练 FCN-16s,再通过 FCN-16s 的训练模型训练 FCN-8s,整个 FCN-8s 网络模型需要经过三次训练。由表 1 结果可知,FCN-32s、FCN-16s、FCN-8s 网络结构的各项准确率均提高,证明多次反卷积操作可以提高算法准确率。

2.4 改进的 FCNN

为了获得更准确的实验结果,在 FCN-8s 的网络结构基础上进行改进优化,所得结果如图 3 所示。首先,对 FCN-8s 网络结构所得结果再次上采样,与

分辨率为 4 pixel 的 pool2 层特征进行融合,获得 4 pixel×4 pixel 的分类精度;然后,将输出结果与分辨率为 2 pixel 的 pool1 层再次进行特征融合,至此所得结果既保留了 pool1 层的细节信息,又达到了 2 pixel×2 pixel 分类精度。

由 2.3 节可知,FCN-8s 的训练过程需要移植 FCN-32s 和 FCN-16s 的训练结果,共经历三次训练过程,训练耗时超过 40 h。针对全卷积神经网络训练过程复杂且训练时间长等问题,本文改进了全卷积神经网络结构并命名为 FCN-2s,如图 4 所示,此结构避免了繁杂的移植过程,对此结构进行单次训练即可直接获取训练结果,耗时不到 10 h,大幅缩减了网络训练时间,简化了网络训练过程,其中 ReLU、sigmoid 代表激活函数类型, pooling 为池化层, dropout 为模型平均层。

3 实验与分析

3.1 数据集准备

为了验证所提方法的准确性和时效性,将所提方法与传统云检方法模糊 C 均值聚类加 SVM 方法




图 3 改进的 FCNN 原理示意图

Fig. 3 Schematic of principle of improved FCNN

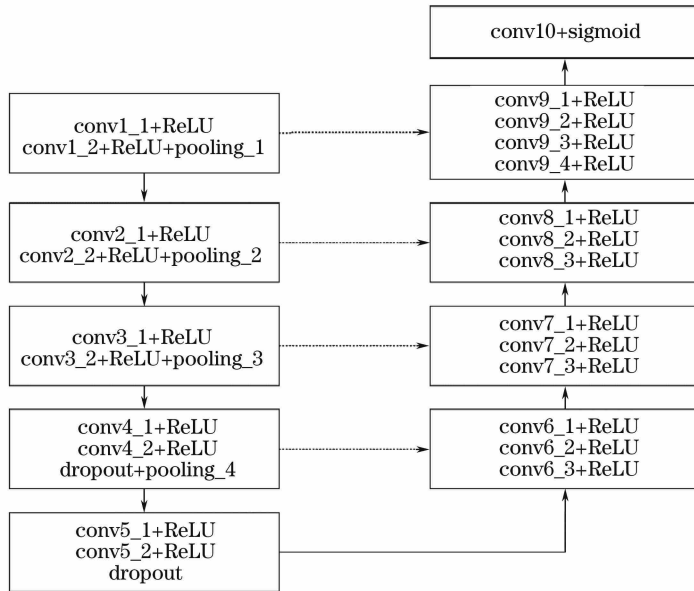


图 4 改进的 FCNN 结构示意图

Fig. 4 Structure diagram of improved FCNN

进行比较。为适应 FCNN 模型的输入,从数十米级分辨率的湖南省资源三号遥感影像上截取数千个 $256 \text{ pixel} \times 256 \text{ pixel}$ 的数据样本,通过目视解译从中挑选 200 个样本,制作训练集和测试集,使用 Photoshop 软件对样本中云区进行提取,得到黑白标签图片,如图 5 所示。训练数据集样本越多,实验精度越高,对样本和对应标签进行旋转、裁剪等操作,将样本集扩充为 1000 幅,并进行模型训练,其中 800 幅样本图像用于训练网络模型,200 幅样本图像

用于验证测试。

3.2 训练网络

实验使用主频为 3.40 GHz 的英特尔 i7 处理器和英伟达 GTX1080T 通用计算图形处理器,基于第三方开源的深度学习框架 Keras,使用 Python 接口进行深度学习模型搭建。为了防止过拟合并提高实验精度,对训练集和验证集进行正则化,将 FCN-2s 的学习率依次设置为 10^{-4} (学习率 base_lr 决定权值更新速率)。




图5 输入影像与标签图片。(a)输入影像1;(b)标签图片1;(c)输入影像2;(d)标签图片2

Fig. 5 Input images and label pictures. (a) Input image 1; (b) label picture 1; (c) input image 2; (d) label picture 2

FCN-2s 网络模型训练中迭代次数达到 30 次时,损失曲线和验证集准确率曲线均已趋于收敛,如图 6 所示,随着迭代次数的增加两者快速收敛,第 30 次迭代时,训练集和验证集的损失值分别为 0.0904 和 0.0986;训练集和验证集的准确率分别为 0.9833 和 0.9794。为了验证 Adam 算法相较于传统神经网络训练所采用 SGD 算法的优越性,应用

SGD 算法进行训练,实验结果如图 7 所示,训练集和验证集的损失值均缓慢收敛,以训练集损失值为例,第 1 次和第 30 次迭代损失值分别为 0.7088 和 0.6608,收敛速度慢且损失值远大于 Adam 算法;准确率相较于 Adam 算法亦收敛较慢,且低于 Adam 算法准确率。


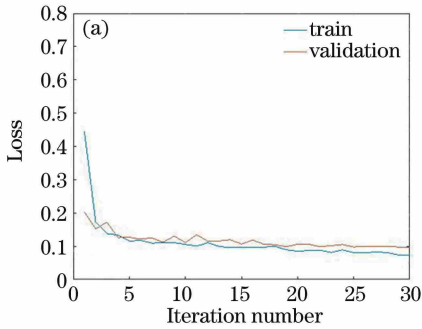


图6 Adam 算法的收敛曲线。(a)损失;(b)准确率

Fig. 6 Convergence curves of Adam algorithm. (a) Loss; (b) accuracy

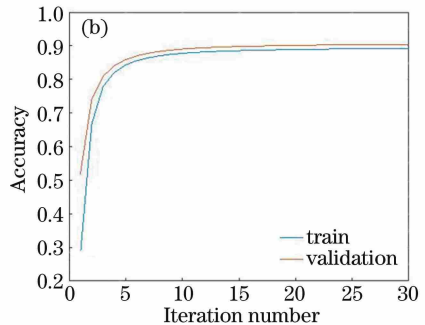
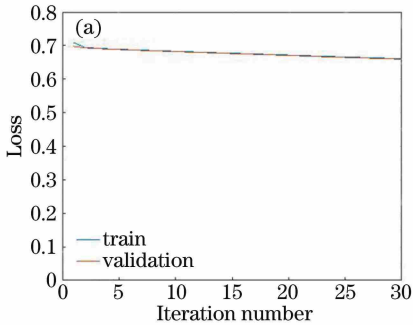


图7 SGD 算法收敛曲线。(a)损失;(b)准确率

Fig. 7 Convergence curves of SGD algorithm. (a) Loss; (b) accuracy

与传统云区检测方法中效果较好的模糊 C 均值聚类+SVM 法作对比,该方法将模糊 C 均值方法通过最小化目标函数完成样本迭代聚类,利用 SVM 聚类法进行类属判别,利用先验知识进行判别,分类准确性较高。图 8 为本文提出的基于全卷积神经网络 FCN-32s、FCN-16s、FCN-8s 以及本文改进算法 FCN-2s 的云区检测结果和对比实验的检

测结果。

从图 8 可以看出:FCN-32s 算法的云区检测结果最粗糙,只能检测出云区的大致范围,对于小范围云区特征无法检测;FCN-8s 算法的检测结果较 FCN-16s 和 FCN-32s 有明显提高;FCN-2s 算法的检测结果最细致,能够准确提取小范围云区特征,基本能够覆盖真实云区范围;而传统云区检测方

法——FCM+SVM 算法可以检测厚云及团云,无法准确检测出薄云范围,且此方法需要人为手动选

点,因此只能进行单张影像处理,不能实现批量检测任务,无法应用于影像质检任务。




图 8 不同方法的检测结果对比。(a)原始图像;(b)标签图像;(c) FCN-2s;(d) FCN-8s;(e) FCN-16s;(f) FCN-32s;(g) FCM+SVM

Fig. 8 Comparison of detection results of different methods. (a) Original images; (b) label picture; (c) FCN-2s; (d) FCN-8s; (e) FCN-16s; (f) FCN-32s; (g) FCM+SVM

为了客观定量评价改进的 FCNN 算法的优越性,采用准确率、精确度、召回率和 F_1 -综合评价指标(F_1 -measure)对比分析实验结果。云区检测识别结果可以分为正确云区检测范围(T_P)、正确非云区检测范围(T_N)、错误云区检测范围(F_N)和错误非云区检测范围(F_P)。4 个评价指标分别为

$$R_{\text{accuracy}} =$$

$$(T_P + Y_N)/(T_P + F_P + F_N + T_N), \quad (4)$$

$$R_{\text{precision}} = T_P/(T_P + F_P), \quad (5)$$

$$R_{\text{recall}} = T_P/(T_P + F_N), \quad (6)$$

$$R_{F_1\text{-measure}} =$$

$$2R_{\text{precision}} \cdot R_{\text{recall}}/(R_{\text{precision}} + R_{\text{recall}}), \quad (7)$$

式中综合指标 $R_{F_1\text{-measure}}$ 综合了精确度和召回率的结果,其值越高说明实验方法越有效。

表 2 不同云区检测结果的平均精度与速度

Table 2 Average accuracy and speed of detection results in different cloud areas

| Types of network | Accuracy /% | Precision /% | Recall /% | F_1 -measure /% | Detection time /s |
|------------------|-------------|--------------|-----------|-------------------|-------------------|
| FCN-2s | 90.11 | 96.92 | 90.36 | 93.53 | 0.46 |
| FCN-8s | 83.96 | 94.15 | 85.35 | 89.53 | 2.24 |
| FCN-16s | 80.36 | 92.48 | 81.94 | 86.89 | 2.30 |
| FCN-32s | 76.52 | 88.29 | 79.67 | 83.76 | 2.36 |
| FCM+SVM | 83.72 | 84.89 | 84.61 | 84.75 | >60.00 |

由表 2 可以看出,FCNN 算法比传统云检算法精确度更高,单张图像检测时间更短,本文提出的改进的 FCNN 算法无论是在准确度、精确度、召回率、 F_1 -综合评价指标还是单张图检测时间等方面都具有明显优势,准确率达到 90.11%,精确度达到 96.92%,召回率达到 90.36%, F_1 综合评价指标达到 93.53%,说明本文算法对检测结果具有优化作用。实验效率方面,FCNN 算法可实现批量云区检测工作,单张图像检测时间平均为 0.46 s,远低于平均检测时间为 2.3 s 的基础全卷积神经网络。FCM+SVM 方法无法批量处理影像,需要手动选点,单张影像平均检测时间超过 60 s,检测时间长且

工作量巨大。因此,本文方法在日常影像云区检测任务中可大幅提高工作效率。

4 结 论

基于改进的 FCNN 的云区检测算法弥补了传统算法的不足,将云区检测定位准确率提高至 90.11%,基本还原了输入影像的细节信息。该算法可处理任意尺寸的输入影像,实现端到端的像素级检测能力。针对 FCNN 训练过程繁琐、收敛效果较差、训练时间长且云检测结果精度较低等问题,所提算法均进行了优化改进,解决了传统云检算法难以识别薄云区域、实验过程需要人工选点和无法批量

生产等问题,将单张影像检测时间缩短至 0.46 s,计算机自动化处理避免了人为干预,极大地节省了卫星影像质量检查与数据分发时间,提高了工作效率。

然而,所提出的云区检测算法还存在很多不足,下一步将致力于解决薄雾的识别率较低,以及具有相同光谱和纹理特性的雪覆盖区域无法区分等问题。

参 考 文 献

- [1] Hou S W, Sun W F, Zheng X S. Overview of cloud detection methods in remote sensing images [J]. *Space Electronic Technology*, 2014, 11(3): 68-76, 86.
侯舒维, 孙文方, 郑小松. 遥感图像云检测方法综述 [J]. *空间电子技术*, 2014, 11(3): 68-76, 86.
- [2] Yang L, Pan Z Q, Fu Q Y, *et al.* Atmospheric correction of multi spectral data of ZY-3 [J]. *Spectroscopy and Spectral Analysis*, 2013, 33(7): 1903-1906.
杨磊, 潘志强, 傅俏燕, 等. 资源三号卫星多光谱数据的大气校正研究 [J]. *光谱学与光谱分析*, 2013, 33(7): 1903-1906.
- [3] Zhao X. Research on cloud detection method for high resolution satellite remote sensing images [D]. Harbin: Harbin Institute of Technology, 2013: 40-47.
赵晓. 高分辨率卫星遥感图像云检测方法研究 [D]. 哈尔滨: 哈尔滨工业大学, 2013: 40-47.
- [4] Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks [J]. *Science*, 2006, 313(5786): 504-507.
- [5] Collobert R, Weston J. A unified architecture for natural language processing: deep neural networks with multitask learning [C] // *International Conference on Machine Learning*, 2008: 5089-5096.
- [6] Bengio Y. Learning deep architectures for AI [J]. *Foundations and Trends in Machine Learning*, 2009, 2(1): 1-127.
- [7] Mohamed A R, Sainath T N, Dahl G, *et al.* Deep belief networks using discriminative features for phone recognition [C] // *IEEE International Conference on Acoustics, Speech and Signal Processing*, 2011: 5060-5063.
- [8] Chan T H, Jia K, Gao S H, *et al.* PCANet: a simple deep learning baseline for image classification [J]. *IEEE Transactions on Image Processing*, 2015, 24(12): 5017-5032.
- [9] Kavukcuoglu K, Ranzato M, Lecun Y. Fast inference in sparse coding algorithms with applications to object recognition [EB/OL]. (2010-10-18) [2018-02-11]. <https://arxiv.org/abs/1010.3467>
- [10] Silver D, Huang A, Maddison C J, *et al.* Mastering the game of go with deep neural networks and tree search [J]. *Nature*, 2016, 529(7587): 484-489.
- [11] Li Z Q, Zhu R F, Gao F, *et al.* Hyperspectral remote sensing image classification based on 3D-convolution neural network combined with conditional random field optimization [J]. *Acta Optica Sinica*, 2018, 38(8): 0828001.
李竺强, 朱瑞飞, 高放, 等. 3D-CNN 联合条件随机场优化的高光谱遥感影像分类 [J]. *光学学报*, 2018, 38(8): 0828001.
- [12] LeCun Y, Bottou L, Bengio Y, *et al.* Gradient-based learning applied to document recognition [J]. *Proceedings of the IEEE*, 1998, 86(11): 2278-2324.
- [13] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks [J]. *Communications of the ACM*, 2017, 60(6): 84-90.
- [14] Chen Y, Fan R S, Wang J X, *et al.* High resolution image classification method combining with minimum noise fraction rotation and convolution neural network [J]. *Laser & Optoelectronics Progress*, 2017, 54(10): 102801.
陈洋, 范荣双, 王竞雪, 等. 结合最小噪声分离变换和卷积神经网络的高分辨率影像分类方法 [J]. *激光与光电子学进展*, 2017, 54(10): 102801.
- [15] Chen Y, Fan R S, Wang J X, *et al.* Deep learning based on cloud detection for ZY-3 remote sensing image [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遥感影像云检测方法 [J]. *光学学报*, 2018, 38(1): 0128005.
- [16] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation [C] // *IEEE Conference on Computer Vision and Pattern Recognition*, 2015: 3431-3440.
- [17] Liu X, Wang G H, Yang H C, *et al.* Road extraction from remote sensing image based on fully convolutional networks [J]. *Remote Sensing Information*, 2018, 33(1): 69-75.
刘笑, 王光辉, 杨化超, 等. 全卷积神经网络遥感影像道路提取方法 [J]. *遥感信息*, 2018, 33(1): 69-75.
- [18] Simonyan K, Zisse R, Man A. Very deep convolutional networks for large-scale image recognition [EB/OL]. (2015-04-10) [2018-01-25]. <https://arxiv.org/abs/1409.1556v6>.