

doi: 10.6046/gtzyyg.2020090

引用格式: 仇一帆, 柴登峰. 无人工标注数据的 Landsat 影像云检测深度学习[J]. 国土资源遥感, 2021, 33(1): 102-107. (Qiu Y F, Chai D F. A deep learning method for Landsat image cloud detection without manually labeled data [J]. Remote Sensing for Land and Resources, 2021, 33(1): 102-107.)

# 无人工标注数据的 Landsat 影像云检测深度学习方法

仇一帆, 柴登峰

(浙江大学地球科学学院, 杭州 310027)

**摘要:** 云和云阴影检测是 Landsat 影像产品生产的重要环节。近年来,深度学习极大提升了 Landsat 影像云检测的精度,但是深度卷积神经网络模型的训练依赖庞大规模的标注图像,需要人工标注出大量图像上每个像素是否为云或云阴影。人工标注成本高、耗时长,不利于训练出具有实用价值的模型。受弱监督学习启发,文章提出一种新的云和云阴影检测模型深度学习方法。首先,采用常规云检测算法 CFMask 检测 Landsat8 影像云及其阴影;然后,将其替代人工标注图像用以训练深度卷积神经网络模型;最后,应用训练所得模型检测新图像中的云及其阴影。实验结果表明,所提方法的总体精度为 85.55%,与 CFMask 结果相比精度有所提升,说明利用非人工标注数据训练深度网络模型进而检测云和云阴影的思路是可行的。

**关键词:** 云和云阴影检测; Landsat8 影像; 卷积神经网络; 语义分割

**中图分类号:** TP 751.1 **文献标志码:** A **文章编号:** 1001-070X(2021)01-0102-06

## 0 引言

Landsat 系列卫星自 1972 年发射至今一直持续对地观测,提供了全球范围长时序连续陆地遥感记录,是目前应用最广泛的遥感数据集之一。然而, Landsat 系列卫星与其他光学传感器一样,容易受到云层及其阴影影响,研究表明,地球表面的年均云层覆盖率在中纬度地区大约为 35%,全球范围内约为 58%~66%<sup>[1-3]</sup>。遥感影像上,被云层遮挡的像素变亮,被云阴影遮挡的像素变暗,地表特征模糊<sup>[4-6]</sup>,干扰地物信息的提取,影响研究结果的准确性。因此,云和云阴影检测是 Landsat 影像产品生产的重要环节。

目前美国地质调查局(United States Geological Survey, USGS)官方使用 CFMask(C function of Mask)算法来检测影像上的云和云阴影,检测结果作为质量评估(quality assessment, QA)波段保存于 Landsat Collection 1 Level 1 产品中。CFMask 是 Fmask(Function of Mask)算法的 C 语言实现<sup>[1,6-7]</sup>,通过分析 Landsat 影像所有波段的大气层顶(top of atmosphere, TOA)表观反射率和亮度温度,基于云

和云阴影的物理属性建立阈值规则逐像素进行检测。这种基于阈值规则的方法在遥感影像云和云阴影检测领域应用广泛,但受到传感器类型、地理位置、大气条件等因素影响,阈值的选择通常难以把握;而且为了保证精度,往往会设定大量阈值规则,例如 FMask 就使用了超过 20 组阈值,增加了该方法的使用和迁移难度<sup>[6,8]</sup>。除此之外,常用的 Landsat 影像云和云阴影检测方法还包括多时相检测法和统计学方法。多时相检测法基于云和云阴影的动态性,通过比较恒定视角多时相影像的光谱差异构建云检测算法<sup>[5,9]</sup>。虽然研究结果表明多时相检测法能有效提高云检测精度,但在实际应用中诸如热带和亚热带等全年多云的地区很难获取无云观测作为参考,限制了现有多时相检测方法的应用。基于统计学思想利用空间特征和光谱特征来估计影像整体云覆盖率<sup>[10]</sup>或检测影像上的云层<sup>[11-12]</sup>也是云和云阴影检测的一种常见思路。

计算机性能的提升和深度学习的发展为云和云阴影检测带来了新思路<sup>[13-14]</sup>,如 Chai 等<sup>[15]</sup>利用 Seg-Net 模型将像素划分为云、薄云、云阴影或无云 4 个类别,实现了 Landsat 影像上的云和云阴影检测。深度学习通常依赖大规模标注数据来训练网络模型,

收稿日期: 2020-04-01; 修订日期: 2020-06-02

基金项目: 国家重点研发计划项目“长江中下游地区水稻主要气象灾害监测技术方法研究”(编号: 2017YFD0300402-3)和国家自然科学基金项目“多时相遥感影像目标提取的时空模型与方法研究”(编号: 41571335)共同资助。

第一作者: 仇一帆(1995-),女,硕士研究生,主要研究方向为遥感图像处理算法研究。Email: rs\_qyf@zju.edu.cn。

通信作者: 柴登峰(1974-),男,副教授,研究方向为遥感图像分析。Email: chaidf@zju.edu.cn。

而这些数据往往是通过人工标注的方式来获取的,成本高、耗时长、具有主观性,不利于训练出具有实用价值的模型。为了解决这个问题,有学者提出了弱监督学习概念,使用不充足或不准确的监督信息来训练模型,减少了人工标注数据的使用,目前这个方法在计算机视觉领域已经有了一定的突破<sup>[16-17]</sup>,但具体到云和云阴影检测研究上还没有进展。

针对上述遥感影像云和云阴影检测方法存在的问题,本文受弱监督学习思想启发,利用 CFMask 产生的云和云阴影检测结果作为弱监督学习样本训练 SegNet 深度神经网络,整个训练过程不使用人工标注的先验数据。模型训练完成后,对新图像进行检测并验证检测精度,量化描述研究结果。旨在探讨脱离人工标注数据训练深度神经网络模型进行 Landsat 影像云和云阴影检测的可行性,为后续实现更加完善的云和云阴影检测奠定基础。

## 1 研究数据

### 1.1 数据描述

实验数据来自 Landsat Collection 1 Level 1 产品和 Landsat8 云覆盖评估 (cloud cover assessment, CCA) 验证数据集<sup>[18]</sup>。

Level 1 产品包含 10 个 30 m 空间分辨率波段,1 个 60 m 空间分辨率的全色波段,以及 QA 波段。QA 波段中包含的云和云阴影信息依据 CFMask 算法生成,根据表 1 列出的 QA 波段 bit 位描述或文献 [19] 提供的 59 类 QA 波段值解释规则可以解译出影像上的云和云阴影信息。

表 1 Landsat8 Collection 1 Level 1 QA 波段 bit 位描述

Tab. 1 Landsat8 Collection 1 Level 1 quality band bit designations

位信息	含义	位信息	含义
0	填充	8	云阴影置信度
1	地形遮蔽	9	雪/冰置信度
2	辐射饱和	10	雪/冰置信度
3	辐射饱和	11	卷云置信度
4	云	12	卷云置信度
5	云置信度	13	—
6	云置信度	14	—
7	云阴影置信度	15	—

如表 1 所示,QA 值二进制形式第 4 位是云像素标识,第 7 位和第 8 位存储云阴影置信度信息。对于单个 bit 位存储信息的情况,以第 4 位为例,若值为 0 表示该像素并非云像素,若值为 1 则为云像素;对于用双 bit 位表示的信息,以第 7 位和第 8 位为例,若从高位到低位分别为:“00”表示不存在云阴影;“01”表示云阴影存在的置信度很低(0 ~

33%);“10”表示中等置信度(34% ~ 66%);“11”表示置信度很高(67% ~ 100%)<sup>[19]</sup>。QA 波段能提供较高精度的云和云阴影掩模,但仍存在一定的误差,其数据标签并不是完全准确的。本实验将 30 m 空间分辨率波段组合成的 10 通道多波段影像对应 TOA 表观反射率和亮度温度作为输入数据,将 QA 波段派生为标注数据来训练 SegNet 模型。

Landsat8 CCA 验证数据由 USGS 地球资源观测与科学中心创建,通过人工方式标注出了影像上的云、薄云、云阴影和无云像素。验证数据共 96 个场景,均匀分布于全球各大洲,覆盖荒地、森林、灌木地、草地/农田、雪/冰、城市、湿地以及水域 8 个不同的生物群落区<sup>[1,18]</sup>。需要注意的是,Landsat8 CCA 验证数据只用于评估检测结果精度,不参与模型的训练过程。

### 1.2 数据预处理与样本集构建

由于 Landsat 影像图幅较大,直接输入神经网络占用内存高,图形处理器 (graphics processing unit, GPU) 很难负担,因此将各场景切割为互不重叠的 512 像素 × 512 像素大小子景并存储为 png 格式。影像上有一些不反映地物信息的填充像素,为了简化信息提取过程,在构建样本集时剔除了这些包含填充像素的切割图像。最后,每个场景约有 120 个 512 像素 × 512 像素大小子景用于样本集的构建,每个子景对应 10 个多光谱波段和 1 个 QA 波段。

本文共构建了 3 个样本集,分别是:用于训练 SegNet 网络的训练样本集,用于优化网络参数的验证样本集,以及用于客观评价网络性能的测试样本集。本研究以 Landsat8 CCA 验证数据集的 96 个场景为研究对象,这些场景均匀分布于全球范围,包含所有生物群落区类型,具有代表性。96 个场景中,有 64 个场景未标注出云阴影,不能用于精度验证,将这 64 个场景每个场景切割后的子景按 80% 和 20% 的比例随机分配为训练样本和验证样本;其余 32 个场景标注完整,用于构建测试样本集。训练、验证、测试样本集中子景数量和切割图像数量如表 2 所示。

表 2 样本集子景数量和切割图像数量

Tab. 2 The number of subscenes and images in sample set

样本集	训练样本集	验证样本集	测试样本集
子景总量	6 396	1 575	3 966
切割图像总量	70 356	17 325	43 626
按生物群落子景数量统计			
荒地	996	244	242
森林	610	150	749
灌木地	509	125	871
草地/农田	799	198	485
雪/冰	680	168	618
城市	898	221	378
湿地	803	196	499
水域	1 101	273	124

## 2 云和云阴影检测算法

本文方法实验流程如图 1 所示。

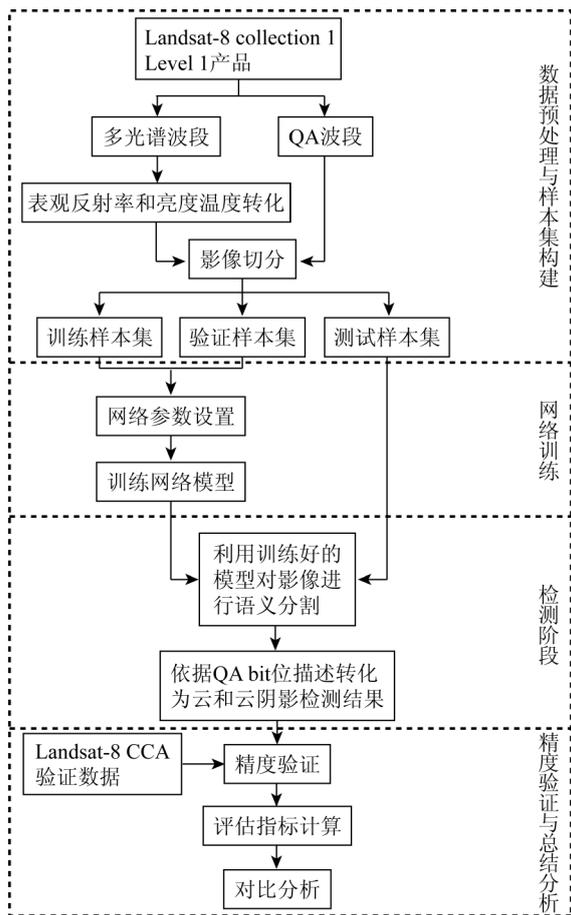


图 1 实验方案技术流程

Fig. 1 Technical flowchart of experimental scheme

本方法将云和云阴影检测视为语义分割问题，

利用整幅影像的空间信息和所有波段的光谱特征对图像进行分割,最后依据表 1 的 QA 波段位描述将语义分割结果标记为云、无云或云阴影,完成遥感影像云和云阴影检测。

### 2.1 SegNet 模型

本文参考文献[20]构建了 SegNet 语义分割模型,其网络结构如图 2 所示,从左向右依次经过编码器 (Encoder)、解码器 (Decoder) 和 Softmax 分类器,最后到达输出层,完成端到端的像素级分割任务。SegNet 可以接受任意尺寸的输入图像,其原型结构的输入为 3 通道图像,本文为了更好地学习和利用 Landsat 影像特征,设置模型的输入图像通道数为 10,本文中输入图像尺寸为 512 像素 × 512 像素。编码器基于 VGG 网络,包括卷积层、批归一化层、ReLU 激活层和池化层,卷积层均采用 3 像素 × 3 像素大小卷积核,第一层卷积层中卷积核个数设置为 96,池化层采用最大池化操作,并记录池化索引,图像经过编码器各隐含层,实现对影像特征信息的低维提取;解码器包含上采样层以及与卷积层一一对应的反卷积层,利用编码阶段保存的最大池化索引还原图像尺寸和边界信息,重构高维特征。编码器-解码器结构大大减少了模型的训练参数,提高了网络效率,并对边界的描述起到优化作用。解码器输出的高维特征向量输入 Softmax 分器,用于预测图像上各像素所属类别的概率并生成一个  $k$  通道的类置信图 ( $k$  为类别个数),尺寸与输入图像相同。最后,具有最大概率的类别输出为语义分割结果。

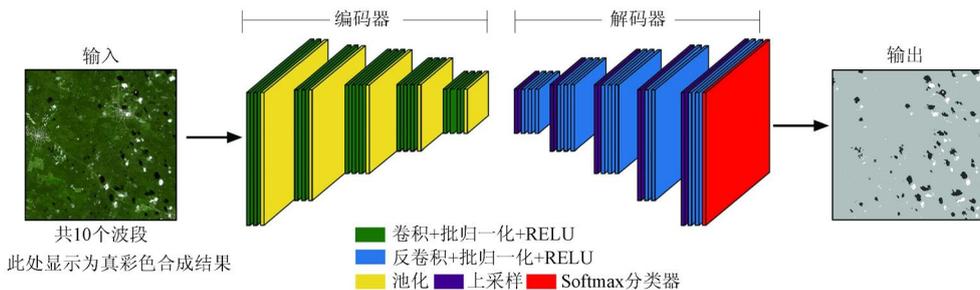


图 2 基于 SegNet 的网络结构

Fig. 2 Network structure based on SegNet

### 2.2 参数设置与网络训练

SegNet 语义分割模型的训练以交叉熵损失函数最小化为目标,使模型对训练样本的预测结果尽可能地与所给标注数据标签相匹配。模型采用反向传播 (back propagation, BP) 算法,计算网络中所有权重损失函数的梯度,反馈给优化器 (Optimizer) 以更新网络参数,实现交叉熵最小化。本文选择自适应

矩估计 (adaptive moment estimation, Adam) 算法作为优化器,Adam 是一种自适应学习速率的求解方法,实验证明它能较好地解决损失函数的最优化问题,与其他优化器算法相比综合性能表现更佳<sup>[21-22]</sup>,Adam 的一阶矩估计衰减速率设定为 0.9,二阶矩估计衰减速率为 0.999;学习速率初始值设定为  $1E-4$ ,在每一轮参数更新过程中更新学习速

率。为了防止出现过拟合,模型在对每个卷积层进行 RELU 函数激活后,添加了一个 dropout 层,以一定的概率激活网络上的神经元,本文将激活概率设置为 0.5。

### 2.3 精度评价

为了定量评价 Landsat8 影像云和云阴影检测的精度,本文采用总体精度(overall accuracy, OA)和 F1 分数作为评价指标。总体精度表示为检测结果中分类正确的像素数量占测试样本集全部像素数量的比值,F1 分数是对精确率和召回率的调和平均。2 个评价指标的计算公式分别为:

$$OA = \frac{\sum_i N_{ii}}{\sum_{ij} N_{ij}}, \quad (1)$$

$$F1_i = \frac{2p_i r_i}{p_i + r_i}, \quad (2)$$

式中:  $i, j$  为类别标识;  $F1_i$  为类别  $i$  的 F1 分数;  $N_{ij}$  为本属于类别  $j$  的像元预测为类别  $i$  的数量;  $p_i$  和  $r_i$  分别为类别  $i$  的精确率和召回率,计算公式如下:

$$r_i = N_{ii} / \sum_j N_{ij}, \quad (3)$$

$$p_i = N_{ii} / \sum_j N_{ji}. \quad (4)$$

## 3 实验结果分析

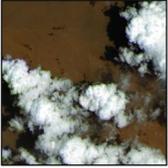
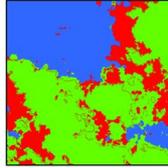
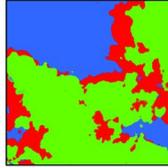
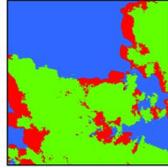
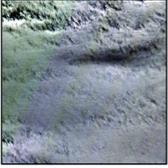
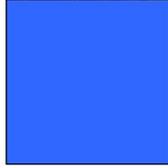
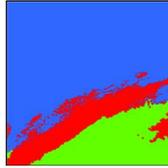
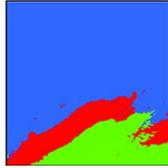
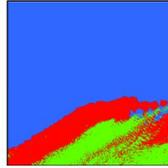
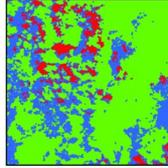
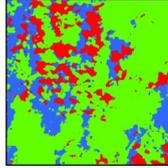
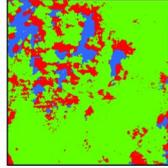
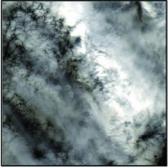
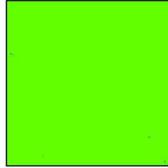
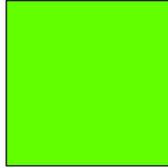
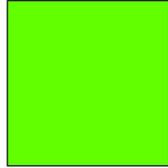
为了评估本文方法的有效性和可行性,对测试样本集进行云和云阴影检测,并与 CFMask 算法结果进行对比分析。CFMask 是 Landsat 官方云检测方法,可以对全球范围 Landsat 影像进行无偏检测,综合性能较好,具有权威性<sup>[1]</sup>。

### 3.1 定性分析

从实验结果中选取了 5 个典型场景进行视觉评价,如表 3 所示,影像 1—5 所示场景分别位于不同的生物群落区中,其下垫面分别为荒地、冰雪、植被(灌木)、水域和湿地;从左至右依次是输入图像、地面真值、本文方法检测结果以及 CFMask 检测结果。输入图像以 B4(R), B3(G), B2(B) 合成显示,真值为 Landsat8 CCA 验证数据中经人工方式标注的云和云阴影掩模,检测结果及真值中的云阴影、云和无云像元分别用红色、绿色和蓝色标示。由于 Landsat8 CCA 验证数据提供的云和云阴影掩模在标注时区分了云类别与薄云类别,而本文方法和 CFMask 算法在进行云和云阴影检测时均不区分云的厚薄,因此合并 Landsat8 CCA 验证数据中的云和薄云 2

表 3 云和云阴影检测结果

Tab. 3 Cloud and cloud shadow detection results

影像序号	真彩色影像	真值	本文方法	CFMask
1				
2				
3				
4				
5				

个类别,统一作为云类别来进行标示,在后续对实验结果进行定量分析时,也作相同合并处理以验证计算结果的精度。对于 Landsat 数据的实际应用而言,通常认为云像元和薄云像元都是无效的,因此将云与薄云类别合并并不会影响对本方法有效性的判断。由表 3 可知,总体而言,本文方法在不同生态环境、云属种类或云层分布条件下均能较好地判定出云和云阴影位置,识别出云和云阴影的大致边界。相比 CFMask 结果,本文方法检测出的云和云阴影更准确,与真值的匹配度明显更优,如本文方法识别出了 CFMask 没有识别出的表 3 中 1 号影像右侧较薄的云层,对 3 号影像的卷云也有更好的识别效果,4 号影像中 CFMask 方法结果过多估计了影像上的云层和云阴影,而本文方法改善了这一问题。

### 3.2 定量分析

为进一步验证所提方法的有效性可行性,本文利用 Landsat8 CCA 验证数据对检测结果进行精度验证,采用总体精度和 F1 分数 2 个指标进行定量评价,结果如表 4 所示。实验结果的总体精度为 85.55%,云、云阴影和无云类别的 F1 分数分别为 78.14%,43.86%和 90.62%,均高于 CFMask 结果。值得一提的是,与云检测相比,精确的云阴影检测难度更高,往往会大量漏检和误检情况,而本文方法云阴影检测结果的 F1 分数较 CFMask 有所提高,且精确率从 35.5% 提高到 44.5%,标示着本方法一定程度上能够改善云阴影检测的精确程度,优化云阴影检测结果。

表 4 测试样本集检测结果评价

Tab. 4 Evaluation of detection results (%)

指标	类别	本文方法	CFMask
F1 分数	云	78.14	77.39
	云阴影	43.86	41.84
	无云	90.62	89.87
总体精度		85.55	84.27

对 8 个生物群落区进行单独统计,大部分群落区的检测精度优于相同场景下的 CFMask 结果,其中,荒地、草地/农田、城市、灌木地和水域 5 个生物群落区的检测精度均超过 90%,城市场景的云和云阴影检测精度为 91.49%,较 CFMask 结果提高了超过 10.6%,检测性能提升显著。但是,本文所提方法对雪/冰区域的检测结果精度较差,这一点在表 3 的 2 号影像中也有所体现,经过分析,认为可能是由于训练样本标注数据在这个区域的准确率过低(低于 60%),导致错误标签信息对训练过程造成的干扰难以忽视,模型无法正确地提取特征,因而出现分割结果误差较大的问题,在后续研究中拟加入其他辅助条件做进一步筛选以提高检测的精确程度。

## 4 结论

1) 本文利用 CFMask 云检测结果替代人工标注数据训练 SegNet 语义分割模型,检测 Landsat 影像上的云和云阴影。结果表明,本文方法能够实现 Landsat 影像上的云和云阴影检测,总体精度达到 85.55%,与 CFMask 结果相比有一定改善,证明了采用非人工标注数据训练深度网络模型进行云和云阴影检测的思路是可行的。

2) 本文方法改进了利用深度学习进行云和云阴影检测时依赖大规模像素级云和云阴影人工标注数据的问题,降低了训练数据的获取成本,为后续研究奠定基础。

3) 本方法在检测精度上仍有进一步提升的空间,下一步的研究工作拟通过结合其他筛选条件,对标注数据中的显著错误,如冰雪与云的混淆错误,进行初步纠正后再用于网络模型训练来进一步提高 Landsat 影像云和云阴影检测精度。

### 参考文献 (References):

- [1] Foga S, Scaramuzza P L, Guo S, et al. Cloud detection algorithm comparison and validation for operational Landsat data products [J]. Remote Sensing of Environment, 2017, 194: 379 - 390.
- [2] Ju J, Roy D P. The availability of cloud - free Landsat ETM + data over the conterminous United States and globally [J]. Remote Sensing of Environment. 2008, 112(3): 1196 - 1211.
- [3] Rossow W B, Schiffer R A. Advances in understanding clouds from ISCCP [J]. Bulletin of the American Meteorological Society, 1999, 80(11): 2261 - 2287.
- [4] Fisher A. Cloud and cloud - shadow detection in SPOT5 HRG imagery with automated morphological feature extraction [J]. Remote Sensing, 2014, 6(1): 776 - 800.
- [5] Zhu Z, Woodcock C E. Automated cloud, cloud shadow, and snow detection in multitemporal Landsat data: An algorithm designed specifically for monitoring land cover change [J]. Remote Sensing of Environment, 2014, 152: 217 - 234.
- [6] Zhu Z, Woodcock C E. Object - based cloud and cloud shadow detection in Landsat imagery [J]. Remote Sensing of Environment, 2012, 118: 83 - 94.
- [7] Zhu Z, Wang S, Woodcock C E. Improvement and expansion of the Fmask algorithm: Cloud, cloud shadow, and snow detection for Landsats 4, 7, 8, and Sentinel 2 images [J]. Remote Sensing of Environment, 2015, 159: 269 - 277.
- [8] Irish R R, Barker J L, Goward S N, et al. Characterization of the Landsat - 7 ETM + automated cloud - cover assessment (ACCA) algorithm [J]. Photogrammetric Engineering and Remote Sensing, 2006, 72(10): 1179 - 1188.
- [9] Hagolle O, Huc M, Pascual D V, et al. A multi - temporal method for cloud detection, applied to FORMOSAT - 2, VENμS, Landsat and Sentinel - 2 images [J]. Remote Sensing of Environment, 2010, 114(8): 1747 - 1755.

- [10] Molnar G, Coakley J A. Retrieval of cloud cover from satellite imagery data – a statistical approach[J]. *Journal of Geophysical Research – Atmospheres*, 1985, 90(D7): 2960 – 2970.
- [11] Ricciardelli E, Romano F, Cuomo V. Physical and statistical approaches for cloud identification using meteorological second generation – spinning enhanced visible and infrared imager data[J]. *Remote Sensing of Environment*, 2008, 112(6): 2741 – 2760.
- [12] Amato U, Antoniadis A, Cuomo V, et al. Statistical cloud detection from SEVIRI multispectral images[J]. *Remote Sensing of Environment*, 2008, 112(3): 750 – 766.
- [13] Zi Y, Xie F, Jiang Z. A cloud detection method for Landsat8 images based on PCANet[J]. *Remote Sensing*, 2018, 10(6): 877.
- [14] Xie F, Shi M, Shi Z, et al. Multilevel cloud detection in remote sensing images based on deep learning[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2017, 10(8): 3631 – 3640.
- [15] Chai D, Newsam S, Zhang H K, et al. Cloud and cloud shadow detection in Landsat imagery based on deep convolutional neural networks[J]. *Remote Sensing of Environment*, 2019, 225: 307 – 316.
- [16] Zhou Z. A brief introduction to weakly supervised learning[J]. *National Science Review*, 2018, 5(1): 44 – 53.
- [17] Deselaers T, Alexe B, Ferrari V. Weakly supervised localization and learning with generic knowledge[J]. *International Journal of Computer Vision*, 2012, 100(3): 275 – 293.
- [18] U. S. Geological Survey. L8 biome cloud validation masks [DB/OL]. [2020 - 04 - 01]. <http://dx.doi.org/10.5066/F79Z930Q>.
- [19] U. S. Geological Survey. Landsat collection 1 level - 1 quality assessment band [EB/OL]. [2020 - 04 - 01]. <https://www.usgs.gov/land-resources/nli/landsat/landsat-collection-1-level-1-quality-assessment-band>.
- [20] 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.
- [21] Ruder S. An overview of gradient descent optimization algorithms [EB/OL]. (2017 - 06 - 15) [2020 - 04 - 01]. <https://arxiv.org/abs/1609.04747>.
- [22] Kingma D P, Ba J. Adam: A method for stochastic optimization [EB/OL]. (2017 - 01 - 30) [2020 - 04 - 01]. <https://arxiv.org/abs/1412.6980>.

## A deep learning method for Landsat image cloud detection without manually labeled data

QIU Yifan, CHAI Dengfeng

(School of Earth Sciences, Zhejiang University, Hangzhou 310027, China)

**Abstract:** Cloud and cloud shadow detection is an important part in the production of Landsat images. In recent years, deep learning has greatly improved the accuracy of cloud detection in Landsat images. However, deep convolutional neural network model training relies on a large scale of labeled images, and it is necessary to manually label each pixel as clearness, cloud or cloud shadow. Manually labeling is rather costly and time-consuming, which is not conducive to train practical models. Inspired by weakly supervised learning, this paper proposes a new deep learning method for cloud and cloud shadow detection. Firstly, conventional cloud detection algorithm CFMask is used to detect cloud and cloud shadow in Landsat images. Then, the results are used to replace the manually labeled images to train the deep convolutional neural network model for cloud detection. Finally, the model is used to detect the cloud and its shadow in new images. Experimental results show that the overall accuracy of the proposed method is 85.55%, which is better than that of CFMask and indicates that it is feasible to train the deep network model to detect cloud and cloud shadow without manually labeled data.

**Keywords:** cloud and cloud shadow detection; Landsat8 image; convolutional neural network; semantic segmentation

(责任编辑: 张 仙)