

基于深度学习的资源三号卫星遥感影像云检测方法

陈洋¹, 范荣双², 王竞雪¹, 陆婉芸³, 朱红⁴, 楚清源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 国家测绘工程技术研究中心, 北京 100039;

³ 南京大学地理与海洋科学学院, 江苏 南京 210023;

⁴ 国家测绘地理信息局卫星测绘应用中心, 北京 100048

摘要 针对资源三号卫星影像波段少、光谱范围受限的特点, 提出了基于深度学习的资源三号卫星遥感影像的云检测方法。首先, 采用主成分分析非监督预训练网络结构, 获得了待测遥感影像特征; 其次, 为减少在池化过程中影像特征信息的丢失, 提出自适应池化模型, 该模型能很好地挖掘影像特征信息; 最后, 将影像特征输入支持向量机分类器进行分类, 获得了云检测结果。选取典型区域进行云检测实验, 并与传统 Otsu 方法进行对比。结果表明: 所提方法的检测精度高, 且不受光谱范围的限制, 可用于资源三号卫星多光谱影像和全色影像的云检测。

关键词 遥感; 云检测; 深度学习算法; 主成分变换; 资源三号卫星影像

中图分类号 P237

文献标识码 A

doi: 10.3788/AOS201838.0128005

Cloud Detection of ZY-3 Satellite Remote Sensing Images Based on Deep Learning

Chen Yang¹, Fan Rongshuang², Wang Jingxue¹, Lu Wanyun³,
Zhu Hong⁴, Chu Qingyuan²

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

² National Engineering Research Center of Surveying and Mapping, Beijing 100039, China;

³ Geographic and Oceanographic Sciences, Nanjing University, Nanjing, Jiangsu 210023, China;

⁴ Satellite Surveying and Mapping Application Center, National Administration of Surveying, Mapping and Geoinformation, Beijing 100048, China

Abstract The cloud detection method of ZY-3 satellite remote sensing images based on deep learning is proposed to solve the problem of the images with few image bands and limited spectral range. Firstly, we obtain the feature of remote sensing images measured with the unsupervised pre-training network structure of principal component analysis. Secondly, we put forward the adaptive pooling model, which can well mine images in order to reduce the loss of image feature information in the pooling process. Finally, the image features are input into the support vector machine classifier to obtain the cloud detection results. The typical regions are selected for cloud detection experiments, and the detection results are compared with that of the traditional Otsu method. The results show that the proposed method has high detection precision and is not limited by the spectral range, and it can be used for the multi-spectral and panchromatic images cloud detection of ZY-3 satellite.

Key words remote sensing; cloud detection; deep learning; principal component analysis; ZY-3 satellite image

OCIS codes 280.4788; 100.2960; 100.2980; 100.3008

收稿日期: 2017-08-15; 收到修改稿日期: 2017-09-24

基金项目: 国家重点研发计划项目(2016YFC0803100)、国家自然科学基金(41101452)、高等学校博士学科点专项科研基金(20112121120003)

作者简介: 陈洋(1991—), 男, 硕士研究生, 主要从事影像分割、地物信息智能提取和深度学习方面的研究。

E-mail: 874153187@qq.com

导师简介: 范荣双(1975—), 男, 博士, 研究员, 主要从事遥感与地理信息技术应用等方面的研究。

E-mail: fanrsh@casm.ac.cn

1 引 言

地球上空大约有 50% 以上的区域被云覆盖,导致星载卫星获取的影像含有云层,云层不仅覆盖了地表信息,还给影像的配准、融合等处理造成了诸多影响,因此对遥感影像进行云检测是非常有必要的^[1-2]。此外,云检测精度会影响后续云及地表等相关定量参数的反演精度,因而提高云检测精度能极大地促进遥感影像的实际应用^[3]。

目前,遥感影像的云检测方法很多,且主要是利用遥感影像光谱特征对云进行检测。这些方法主要根据云在红外波段的反射率或亮温值与其他地物不同而将云层与其他地物进行分离^[4-5],具有计算简单、检测效率高等优点,但是要求影像有足够多的波段范围。一般国产高分卫星波段仅含有蓝、绿、红、近红外 4 个波段,波段范围为 0.43~0.90 μm ^[6]。基于影像光谱特征的检测方法在资源三号(ZY-3)卫星影像上没有明显优势。许多学者将基于聚类分割的图像分析方法应用到遥感影像云检测中,但阈值选择的人为主观因素较强。例如,高贤君等^[7]将最大类间自适应阈值(Otsu)应用到遥感影像云检测中,获得了较好的检测结果,但是检测阈值需要人为干预。Aghdam 等^[8]提出了基于大型深层卷积神经网络(CNN)的自然图像分类算法,在 Image Net 数据集上取得了很高的分类精度。卷积神经网络是一种典型的深度学习算法,可通过梯度下降方法训练网络获得模型参数,经过训练的卷积神经网络能充分挖掘影像的特征,最终完成遥感影像的分类^[9]。

针对资源三号高分辨率卫星影像波段少、光谱范围受限的特点,传统的云检测方法难以满足现实生产检测的精度需求,本文将卷积神经网络算法应用于国产资源三号卫星遥感影像云检测中。首先,采用主成分分析(PCA)非监督预训练网络结构,在主成分分析小化重构误差原则下,获取待检测影像的特征,通过学习得到含有训练样本统计特性的滤波器;其次,为减少采样过程中影像特征的缺失,在最大池化模型和平均模型的基础上,根据插值原理提出自适应池化模型(APM);最后,将影像特征输入支持向量机(SVM)分类器进行分类,获得云检测结果。

2 原理与方法

2.1 主成分分析预训练卷积神经网络

影像库标签的训练数据少,需要采用非监督方

式初始化网络滤波器。采用主成分分析非监督预训练,设输入卷积神经网络的影像有 M 景,其大小为 $m \times n$,卷积滤波器大小为 $g_1 \times g_2$,在训练影像的第 i 景中取出全部大小为 $g_1 \times g_2$ 的影像块,将其表示为向量形式 $\mathbf{X}_i = \{x_{i,1}, x_{i,2}, x_{i,3}, \dots, x_{i,mm}\}$,对 \mathbf{X}_i 取均值得到影像 \mathbf{X}_i 的影像块为 $\bar{\mathbf{X}}_i = \{\bar{x}_{i,1}, \bar{x}_{i,2}, \bar{x}_{i,3}, \dots, \bar{x}_{i,mm}\}$ 。所以训练数据的影像块为

$$\mathbf{X} = \{\bar{\mathbf{x}}_1, \bar{\mathbf{x}}_2, \bar{\mathbf{x}}_3, \dots, \bar{\mathbf{x}}_n\} \in \mathbf{R}^{g_1 g_2 \times M_{mm}}. \quad (1)$$

采用主成分变换方法最小化重构误差求解特征向量^[10]:

$$\begin{cases} \min_{\mathbf{V} \in \mathbf{R}^{g_1 g_2 \times H}} \|\mathbf{X} - \mathbf{V}\mathbf{V}^T \mathbf{X}\|^2 \\ \text{s.t. } \mathbf{V}^T \mathbf{V} = \mathbf{I}_H \end{cases}, \quad (2)$$

式中 \mathbf{I}_H 为 $H \times H$ 单位矩阵; \mathbf{V} 为协方差矩阵 $\mathbf{X}\mathbf{X}^T$ 的前 H 个特征向量,表示输入影像块的主要特征。主成分变换初始化卷积神经网络的滤波器组 \mathbf{W}_h 可表示为

$$\mathbf{W}_h = \mathbf{m}_{g_1 g_2}(\mathbf{V}_h), h = 1, 2, 3, \dots, H, \quad (3)$$

式中 $\mathbf{m}_{g_1 g_2}(\mathbf{V}_h)$ 表示将向量 \mathbf{V} 映射到矩阵 \mathbf{W}_h , \mathbf{V}_h 为影像的第 h 个主要特征。采用主成分分析的非监督训练能获取局部影像的主要特征,所以主成分分析初始化滤波器可认为是一种简单的自动编码器。

2.2 卷积神经网络结构

卷积神经网络是受生物神经学知识启发并参考其结构原理结合人工神经网络而产生的开创性研究成果之一^[11]。与浅层机器学习算法相比,卷积神经网络具有强适用性、分类并行处理、权值共享等优点,极大地减少了全局优化的训练参数,目前已经成为深度学习领域的研究热点^[12]。卷积神经网络结构由输入层、卷积层、池化层和全连接层组成,其网络结构如图 1 所示。图中的 C1 和 C2 分别为第一个和第二个积层;S1 和 S2 分别为第一个和第二个池化层。

输入影像在卷积层和滤波层之间进行卷积运算,卷积层和滤波层一般通过激活函数连接^[13]。采用 \mathbf{G}_i 表示卷积神经网络第 i 层的特征图,其卷积过程可以描述为

$$\mathbf{G}_i = f(\mathbf{G}_{i-1} \otimes \mathbf{W}_i + \mathbf{b}_i), \quad (4)$$

式中 \mathbf{W}_i 为第 i 层卷积核的权值特征向量, \otimes 为卷积操作, \mathbf{b}_i 为偏移向量。通过线性激活函数 $f(\cdot)$ 得到第 i 层的特征图 \mathbf{G}_i 。

激活函数主要可以分为线性激活函数和非线性激活函数。常用的非线性激活函数有 3 种,分别是双曲线函数、Sigmoid 函数和 Softplus 函数。双曲线函数是 Sigmoid 函数的一种变体,双曲线函数的

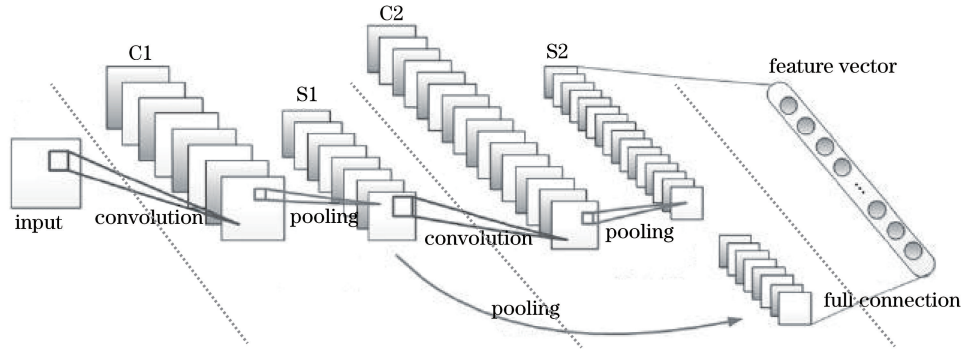


图 1 卷积神经网络结构图

Fig. 1 Schematic of convolution neural network structure

取值范围为 $[-1, 1]$, Sigmoid 函数的取值范围为 $[0, 1]$ 。线性激活函数与生物神经元受刺激后的激活状态比较接近,因此,该函数在一定程度上具有稀疏性以及收敛速度快等优点,已被许多国内外学者作为卷积神经网络的激活函数^[14]。将 Sigmoid 函数的线性修正函数 $f(x) = \max(x)$ 作为卷积神经网络的激活函数。

卷积层和池化层依次相连,并通过激活函数连接。常见的池化层模型主要有最大池化模型和平均池化模型 2 种。

设由卷积层得到的特征图矩阵为 G_{ij} , 池化区域大小为 $c \times c$, b_1 为偏移量,池化步长为 c , 则最大池化模型可以表示为

$$F_{ij} = \max(G_{ij}) + b_1, \quad i = 1, 2, \dots, c, \quad j = 1, 2, \dots, c, \quad (5)$$

式中 $\max_{i=1, j=1}^c (G_{ij})$ 表示从特征图矩阵 G 中大小为 $c \times c$ 的池化区域内取最大元素。

平均池化模型可以表达为

$$F_{ij} = \frac{1}{c^2} \left(\sum_{i=1}^c \sum_{j=1}^c G_{ij} \right) + b_1. \quad (6)$$

高分辨率影像地物复杂,导致传统池化模型不能很好地挖掘影像特征。在池化层中取 2 种不同的池化区域,如图 2 所示,空白处表示像元值为 0,阴影处由不同像元值组成,A 表示最大值区域。图 2(a)所示的整个特征图的特征主要集中在 A 处,如果采用平均池化模型进行池化,则整个特征图的特征会产生弱化。图 2(b)所示的特征图的特征主要分布在 A、B、C 处,在这三者关系未知的情况下,采用最大池化模型进行池化,整个特征图的特征会产生一定弱化,最终影响遥感影像的云检测精度。

为了减少池化过程中丢失的影像特征,在最大池化模型和平均模型的基础上,根据插值原理提出




图 2 不同池化区域。(a)一种特征图;(b)另一种特征图

Fig. 2 Different pooling areas. (a) A feature mapping; (b) other feature mapping

自适应池化模型。在复杂的池化区域内,该模型能自适应通过池化因子 u 来调节池化过程,表达式为

$$F_{ij} = \frac{u}{c^2} \left(\sum_{i=1}^c \sum_{j=1}^c G_{ij} \right) + (1-u) \max_{i=1, j=1}^c (G_{ij}) + b_1. \quad (7)$$

池化因子 u 的作用是根据不同池化区域来动态优化传统池化模型,其表达式为

$$u = \frac{a(b_{\max} - a)}{b_{\max}^2}, \quad (8)$$

式中 a 为池化区域内除了最大元素之外的所有元素的平均值, b_{\max} 为池化区域最大元素。 u 取值范围为 $(0, 1)$, 该模型兼顾了最大池化模型和平均模型的特点,能根据不同池化区域特点自适应优化模型,尽可能挖掘特征图的特征,提高了资源三号卫星云检测精度。

2.3 向量机分类器

SVM 分类器是建立在统计学习理论的 VC 维理论和结构风险最小原理基础上的,根据有限的样本信息在模型的复杂性(即对特定训练样本的学习精度)和学习能力(即无错误地识别任意样本的能力)之间寻求最佳折衷,以获得最好的推广能力^[15-16]。研究表明,SVM 分类算法的优势是在训练样本很少的情况下具有快速的学习能力和较高的分类精度。本实验选取 LIBSVM 开源软件包。

基于深度学习的资源三号卫星遥感影像云检测方法主要步骤有:1)影像预处理和云标签数据制作以及网络构建;2)采用主成分变换初始化网络结构;3)将特征图合并成为一个列特征向量,并输入全连接层,通过反向传播算法更新网络滤波器权值;4)将最终获取的特征向量输入到 SVM 分类器,最后得到云检测结果,其流程图如图 3 所示。

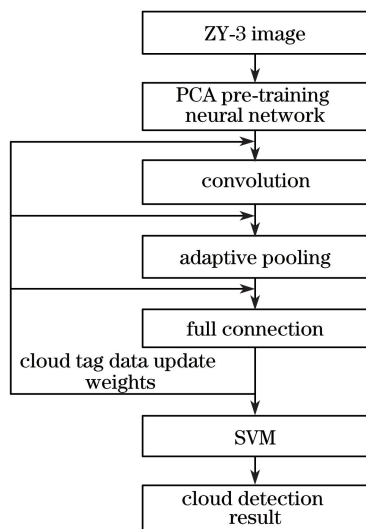


图 3 云检测方法流程图

Fig. 3 Flowchart of the proposed cloud detection method

3 实验与分析

为验证基于深度学习的资源三号卫星遥感影像云检测方法的有效性,选取资源三号卫星遥感影像 1、2 作为实验对象,并与文献[7]提出 Otsu 云检测方法进行对比。其中,影像 1 是多光谱影像,如图 4(a)所示,空间分辨率为 5.8 m,大小为 8856 pixel × 8976 pixel,云的类型主要为薄云和厚云,地物类型主要是山地。影像 2 为全色影像,如图 4(b)所示,无云覆盖,地物主要为城镇,空间分辨率为 2.1 m,大小为 8856 pixel × 8976 pixel。

在选取训练数据时,综合考虑研究区域的云分布情况和种类,选取 578 个有标签云数据,并且选取 3027 个无标签数据,主要用于非监督训练。本实验采取 Linux 下的 caffe 机器学习框架,硬件环境为 CPU Intel (R) Xeon (R) E5-2630, GPU Nvidia Tesla M40 16 G 内存。构建网络结构模型如图 1 所示,一共包括 5 层,分别是 2 个卷积层,2 个自适应池化模型,1 个全连接层。第 1 层卷积滤波器设置为 300 个,第 2 层卷积滤波器设置为 230 个,其滤波器大小均设置 5 × 5;将采样间隔设置为 1,卷积神经网络激活函数采用 Sigmoid 函数的线性修正函




图 4 资源三号卫星的原始遥感影像。

(a)多光谱影像;(b)全色影像

Fig. 4 ZY-3 original remote sensing images.

(a) Multi-spectral image; (b) panchromatic image

数,最后将卷积神经网络学习的云特征输入 SVM 分类器进行云检测。所提方法的云检测结果如图 5(a)和图 5(c)所示。文献[7]的 Otsu 阈值云检测结果如图 5(b)和图 5(d)所示。




图 5 所提方法与 Otsu 方法的云检测效果对比。

(a)所提方法,多光谱影像;(b) Otsu 方法,多光谱影像;

(c)所提方法,全色影像;(d) Otsu 方法,全色影像

Fig. 5 Comparison of cloud detection results between proposed method and Otsu method.

(a) Proposed method, multi-spectral image;

(b) Otsu method, multi-spectral image;

(c) proposed method, panchromatic image;

(d) Otsu method, panchromatic image

从图 5(a)和图 5(b)可以看出:在所提云检测方法的多光谱影像云检测结果中,云边界清晰,能识别薄云和厚云;Otsu 方法的云检测结果中存在误检现象,将高反射率的地物(如裸地)误检为云。从图 5(c)和图 5(d)可以看出:所提云检测方法对无云

全色影像基本不存在误检的情况;在 Otsu 方法的全色影像云检测结果中存在较严重的误检情况,该方法将反射率较高的地物(如建筑物、道路、雪等)误检为云。目视所提评价方法可知,云检测结果漏检和误检现象较少,且不受影像光谱范围的限制,可用于资源三号卫星多光谱和全色影像的云检测。

表 1 不同云检测方法的评价参数

Table 1 Parameters of different cloud detection methods

Detection method	OA		Kappa coefficient	
	Multi-spectral image	Panchromatic image	Multi-spectral image	Panchromatic image
Proposed method	0.988451	0.990123	0.934512	—
Otsu method	0.934619	0.904121	0.731812	—

由表 1 可知:与 Otsu 方法相比,所提云检测方法的精度更高,其中多光谱影像云检测的总体精度为 0.988451,比 Otsu 方法的总体精度高 5.3832%;全色影像检测的总体精度为 0.990123,比 Otsu 方法的总体精度高 8.6002%。在 2 幅资源三号卫星遥感影像的检测结果中,所提云检测方法的总体精度大于 95%,Kappa 系数大于 90%。通过定量评价验证了将深层卷积神经网络算法应用于资源三号卫星遥感影像云检测的精度。

通过上述目视评价和定量评价方式的比较可知,所提方法的云检测结果较好,这主要是由于卷积神经网络模型复杂的多层非线性变换使其具有更强的表达与建模能力,对国产高分辨率影像中的复杂云特征有很好的表达,从而能获得较好的检测结果。

4 结 论

将卷积神经网络算法应用到国产资源三号卫星的遥感影像云检测中,在一定程度上弥补了传统 Otsu 方法的不足,该方法可用于国产卫星影像的质量控制、云区域的提取等。传统 Otsu 云检测方法的主要不足表现为很容易对高反射率地物(如建筑物、裸地、雪)产生误判。与传统 Otsu 方法相比,所提方法的优势主要包括云检测精度高、误判较少,适用于有云、无云的影像,不受影像光谱范围的限制,可用于资源三号卫星多光谱和全色影像的云检测。

深度学习在国产资源三号影像的云检测领域具有较大潜力,所提云检测方法还存在许多不足,比如没有判断卷积神经网络的层次结构和参数设置是否最优。下一步工作将借鉴已有网络模型进行研究,

为了定量评价所提云检测方法,采用人工目视解译方式勾取的云区域作为真值。勾绘准则为:云边界模糊区域勾绘精度小于 3 pixel,云边界清晰区域勾绘精度小于 1 pixel。利用混淆矩阵计算 2 幅影像云检测结果的总体精度(OA),用 OA 和 Kappa 系数定量评价云检测结果,评价指标如表 1 所示。

期待能进一步提高云检测的精度。

参 考 文 献

- [1] Zhu Z, Woodcock C E. Object-based cloud and cloud shadow detection in Landsat imagery[J]. Remote Sensing of Environment, 2012, 118: 83-94.
- [2] 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.
- [3] Hughes M J, Hayes D J. Automated detection of cloud and cloud shadow in single-date Landsat imagery using neural networks and spatial post-processing[J]. Remote Sensing, 2014, 6(6): 4907-4926.
- [4] Liu D W, Han L, Han X Y. High spatial resolution remote sensing image classification based on deep learning[J]. Acta Optica Sinica, 2016, 36(4): 0428001.
刘大伟, 韩玲, 韩晓勇. 基于深度学习的高分辨率遥感影像分类研究[J]. 光学学报, 2016, 36(4): 0428001.
- [5] Chen Y, Fan R S, Wang J X, *et al.* Segmentation of high-resolution remote sensing image combining phase consistency with watershed transformation[J]. Laser & Optoelectronics Progress, 2017, 54(9): 092803.
陈洋, 范荣双, 王竞雪, 等. 结合相位一致和分水岭变换的高分辨率遥感影像分割方法[J]. 激光与光电子学进展, 2017, 54(9): 092803.
- [6] Chen Z W, Zhang G, Ning J S, *et al.* An automatic cloud detection method for ZY-3 satellite[J]. Acta Geodaetica et Cartographica Sinica, 2015, 44(3): 292-300.
陈振伟, 张过, 宁津生, 等. 资源三号测绘卫星自动云检测[J]. 测绘学报, 2015, 44(3): 292-300.
- [7] Gao X J, Wan 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.
- [8] Aghdam H H, Heravi E J. Convolutional neural networks[M]. Heidelberg: Springer International Publishing, 2017: 85-130.
- [9] Yu Q, Gong P, Clinton N, *et al.* Object-based detailed vegetation classification with airborne high spatial resolution remote sensing imagery[J]. *Photogrammetric Engineering & Remote Sensing*, 2006, 72(7): 799-811.
- [10] Deng W, Hu J, Lu J, *et al.* Transform-invariant PCA: A unified approach to fully automatic face alignment, representation, and recognition[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2014, 36(6): 1275-1284.
- [11] Chen Y, Fan R S, Wang J X, *et al.* High resolution image classification method combining with minimum noise fraction rotation transform 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影像分类方法[J]. *激光与光电子学进展*, 2017, 54(10): 102801.
- [12] Du Y, Bourlai T, Dawson J. Automated classification of mislabeled near-infrared left and right iris images using convolutional neural networks[C]. 8th International Conference on Biometrics Theory, Applications and Systems, 2016: 1-6.
- [13] Lee C Y, Gallagher P W, Tu Z. Generalizing pooling functions in convolutional neural networks: Mixed, gated, and tree[C]. *Artificial Intelligence and Statistics*, 2016: 464-472.
- [14] Maggiori E, Tarabalka Y, Charpiat G, *et al.* Convolutional neural networks for large-scale remote-sensing image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(2): 645-657.
- [15] Vapnik V N. *Statistical learning theory*[M]. New York: Wiley, 1998.
- [16] Foody G M, Mathur A. The use of small training sets containing mixed pixels for accurate hard image classification: Training on mixed spectral responses for classification by a SVM[J]. *Remote Sensing of Environment*, 2006, 103(2): 179-189.