

基于卷积神经网络的 SAR 图像水体提取

陈 坤 郝 明 庄 龙 谢 聪

(南京电子技术研究所 南京 210039)

摘 要: 基于 SAR 图像的水体提取在洪涝监测等领域应用广泛。基于阈值分割的水体提取方法容易将山体阴影分类为水体进行错误提取,传统机器学习的分类方法需要人工提取有效的特征,低效耗时。提出了基于卷积神经网络的 SAR 图像水体提取方法,首先对 SAR 图像进行分块处理,通过基于图像块的多层卷积操作和池化操作自动学习 SAR 图像特征,最后利用 Sigmoid 分类器对所提取的特征进行水体和非水体的分类,实现水体的提取。通过基于 Sentinel-1A 获取的 SAR 数据的实验验证了所提方法的有效性,水体提取的召回率和精确率均可达到 99%,并且性能优于 OTSU 阈值方法和基于纹理特征的 SVM 方法。该方法克服了山体阴影对水体提取的影响,并且其自动学习特征的能力可以实现水体的高效提取。

关键词: SAR 图像;水体提取;卷积神经网络

中图分类号: TN959.3 **文献标识码:** A **国家标准学科分类代码:** 420.2099

A method for water body extraction in SAR image using CNN

Chen Kun Hao Ming Zhuang Long Xie Cong

(Nanjing Research Institute of Electronics Technology, Nanjing 210039, China)

Abstract: Water body extraction based on SAR images is widely used in flood monitoring and other fields. The water body extraction method based on threshold segmentation is easy to classify mountain shadows as water bodies for wrong extraction. Traditional machine learning classification methods require manual extraction of effective features, which is inefficient and time-consuming. This paper proposes a SAR image water extraction method based on convolutional neural network. First, the SAR image is divided into blocks, and the SAR image features are automatically learned through multi-layer convolution and pooling operations based on image blocks. Finally, the Sigmoid classifier is used to classify the pixels into water and non-water to realize the extraction of water body. Experiments based on SAR data obtained by Sentinel-1A verify the effectiveness of this method. The recall rate and accuracy rate of water extraction can reach 99%, and the performance is better than the OTSU threshold method and the SVM method based on texture features. This method overcomes the influence of mountain shadows on water body extraction, and its ability to automatically learn features can achieve efficient water body extraction.

Keywords: SAR image; water body extraction; CNN

0 引 言

地表水体是河流、湖泊、冰川、沼泽 4 种水体的总称,其分布和变化是当地生态环境的重要影响因素,基于遥感系统大范围提取水体信息在生态环境监测、水资源调查和洪涝灾害治理等领域具有重要意义^[1-3]。光学遥感系统是一种被动式成像系统,基于光学遥感成像的水体具有多种光谱特征,增加了水体提取和监测的难度。合成孔径雷达作为一种主动式成像系统,可以穿透云层生成地面信息,不受大气条件影响全天时大范围采集数据,弥补了光学遥感成

像的局限。除此之外,光滑水面雷达发射电磁波的后向散射能力较弱,在 SAR 图像中呈现为较暗区域,这一特性使水体很容易在 SAR 图像中识别出来。基于 SAR 图像的水体提取技术具有重要的研究和应用价值。

当前基于 SAR 图像的水体提取方法可以归类为基于阈值分割的方法^[4]、基于滤波的方法和基于机器学习的方法。由于光滑水面的后向散射系数较低,基于图像阈值分割的水体提取方法率先发展起来。其算法原理是统计 SAR 图像后向散射强度直方图,通过直方图获取水体阈值,根据阈值将 SAR 图像的像素分类为水体和非水体两种

类别,从而实现对水体的提取。阈值分割法原理简单,具有运算速度快、计算量小的优势。OTSU 算法^[5]和熵阈值算法是目前使用较多的基于阈值分割的方法。当对尺寸较大的图像进行处理时,这类方法的运算时间增大,精度较低,而且由于相干斑噪声的影响,较难获取准确的分割阈值。虽然发展出了阈值自动选择^[6]的算法,但是相干斑噪声的影响始终存在。为了抑制相干斑噪声的影响,研究者提出了滤波法^[7],这类方法基于小波变换、形态学滤波和 Gamma 滤波等,有效降低了 SAR 图像的相干斑噪声。但是这类基于滤波的方法存在水体边缘不够连续光滑的问题。机器学习方法利用 SAR 图像纹理等特征可以实现水体和非水体的较高精度分类。常用的机器学习方法包括支持向量机(support vector machine, SVM)^[8]和随机森林^[9]。结合基于灰度共生矩阵提取的纹理特征,使用 SVM 进行监督分类可以有效降低相干斑噪声的影响^[10]。相比于阈值分割方法,基于机器学习的方法可以更好的区分水体和其他类型地物,但是前期需要花费较大的精力提取有效的特征以得到较高的分类精度。

近年来,深度学习飞速发展,在图像处理领域有着深刻且广泛的研究和应用^[11-13]。在 SAR 图像语义分割领域,FCN^[14]、U-Net^[15]等深度学习模型相继被提出,在性能方面相比传统方法有所提升。SAR 图像水体提取本质上就是对 SAR 图像中水体部分和非水体部分进行分割。基于阈值分割的方法虽然运算简单,但只适合低噪小尺度 SAR 图像处理。而基于传统机器学习的方法需要花费较大精力预先处理 SAR 数据手动提取有效的数据特征。深度学习方法凭借其多层网络结构和强大的学习能力,可以不需要数据的先验知识和抽象特征,可以直接使用 SAR 图像作为输入数据,自动学习输入数据的高维特征用于分类,获取高精度的分类结果。本文引入卷积神经网络用于 SAR 图像水体提取,实现对 SAR 图像水体的精确提取。通过 Sentinel-1A SAR 数据的实验,验证了本文方法的有效性,并且相比传统 OTSU 阈值分割方法和 SVM 方法,在性能上有所改善。

1 卷积神经网络

传统全连接神经网络每一层的每一个神经元节点都和下一层的所有神经元节点连接,所以网络参数的数量会随着输入数据的增长而急速增加,这增加了模型的复杂度和训练难度。卷积神经网络(convolutional neural network, CNN)采用局部连接、权值共享和下采样的策略,避免图像结构信息丢失的同时,极大程度地减少了网络参数数量,降低了模型结构的复杂度,克服了全连接网络的缺点。CNN 的主要结构包括卷积层、池化层和激活层。

1.1 卷积层

卷积层的目的是提取输入的特征,实现特征从低维到高维的映射,得到有区分性的高维特征。卷积层使用卷积

核与图像做卷积操作,卷积核被输入图像的全局区域共享,通过不同的卷积核会得到不同的特征映射。这就是权值共享机制,其有效降低了模型复杂度。卷积层与上一层局部连接,即卷积层的每一个节点只和上一层的近邻区域节点相连,大大减少了网络参数数量和模型复杂度。卷积层的特征映射过程如图 1 所示,首先用卷积核通过滑窗的形式和输入做卷积运算,然后用非线性激活函数处理卷积结果。假设第 l 层的输出为 O_l ,卷积核权重矩阵为 W_l ,则:

$$O_l^{N \times N} = h(O_l^{M \times M} \otimes W_l^{K \times K} + b_l) \quad (1)$$

式中: b_l 表示第 l 层的偏置向量; $\otimes$ 表示卷积运算; $h(\cdot)$ 表示非线性激活函数。若卷积步长为 S ,边缘补充数为 P ,则输出尺寸 $N = \frac{M - K + 2P}{S} + 1$ 。




图 1 卷积操作

1.2 池化层

池化层中,通过下采样操作特征图进行降维。下采样操作也就是将输入映射为各个区域的统计值,作为网络的输出。池化层主要有如下优点。首先,通过池化层的下采样操作后,特征维数降低,这可以有效减少网络的参数数量,降低模型复杂度,从而降低网络的训练难度。其次,分类器要学习卷积层从输入数据中抽象出的高维特征难度较高,而且容易导致网络过拟合,池化层的降维操作可以有效减轻这一问题。最后,池化操作具有平移不变性,即特征通过池化操作后,虽然空间位置有所变化,但是特征的值保持不变。常用的池化方式包括最大值池化和平均池化,如图 2 所示。最大值池化就是将图像某一区域的最大值作为该区域的特征值输出;平均池化就是将图像某一区域的平均值作为该区域的特征值输出。




图 2 池化操作

1.3 激活层

激活函数为神经网络引入非线性元素,使神经网络可以逼近任意非线性函数,从而可以对非线性模型进行建模。卷积层操作和池化层操作都是线性映射,即使构建多层网络,该网络也只能进行线性建模。而激活函数引入非线性映射,增加了网络的非线性表达能力。本文模型卷积层采用 ReLU 激活函数,输出层选择 Sigmoid 函数。

ReLU 函数图像如图 3 所示。ReLU 函数作为分段函数,把所有负值变为 0,而保持正值不变,这种单侧抑制机制时神经网络中的神经元具有了稀疏激活性,可以更好地拟合数据。而且 ReLU 函数在非负区间地导数为常数,有效地解决了梯度消失地问题。ReLU 函数公式如下:

$$f(x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (2)$$

$$f'(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (3)$$




图 3 ReLU 函数

Sigmoid 函数图像如图 4 所示。Sigmoid 函数输出映射在(0,1)之间,可以表示分类的概率,因而多用于输出层完成二分类任务。Sigmoid 函数公式如下:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (4)$$

$$f'(x) = f(x)(1 - f(x)) \quad (5)$$

2 用于 SAR 图像水体提取的 CNN 模型

本文针对 SAR 图像水体提取问题提出一种包含 3 个卷积层结构的深度卷积神经网络。网络结构模型如图 5 所示,包括输入、特征提取和分类 3 个部分。特征提取部分通过 3 次卷积池化操作从低维数据中抽象出高维特征。每个卷积层之后都接有一个批量归一化层,对输入特征作标准化处理,使得每一个特征在所有输入样本上都服从相同的分布,从而加快模型训练速度。卷积层采用 ReLU 函数作为线性激活函数。最大池化能够减小卷积层参数误差造成的估计均值的偏移,从而更多的保留纹理信息,适用于对水




图 4 Sigmoid 函数

体目标和非水体目标差异性特征的提取,所以模型中采用最大池化。经过多层卷积和池化操作抽象出的高维特征通过两层全连接层映射为分类器可理解的特征向量作为输出层的输入。由于二分类问题,选择 Sigmoid 函数作为输出层的激活函数。网络各层具体参数设置如表 1 所示。

表 1 CNN 网络参数设置

层结构	核结构
卷积层 1	16@3×3,步长 1
池化层 2	2×2,步长 2
卷积层 3	32@3×3,步长 1
池化层 4	2×2,步长 2
卷积层 5	64@3×3,步长 1
池化层 6	2×2,步长 2
全连接层 7	30
全连接层 8	2




图 5 SAR 图像水体提取 CNN 模型

2.1 网络优化

本文通过使用动量的随机梯度下降算法(stochastic gradient descent with momentum, SGDM)优化网络参数,该方法一定程度上可以避免损失函数在优化过程中陷入局部最小,并且可以加快网络学习速度。算法步骤如下:

1) 设定初始学习率 ϵ , 动量参数 α , 待更新参数 θ , 待更新学习速度 v ;

2) 更新迭代次数 $i = i + 1$;

3) 从训练集中采集包含 m 个样本的小批量, 计算损失函数 $l^{(k)}(\theta)$;

4) 估计第 i 次迭代的损失函数的梯度:

$$g_i = \frac{1}{m} \nabla_{\theta} \sum_k l^{(k)}(\theta) \quad (6)$$

5) 更新学习速度: $v_i = \alpha v_{i-1} - \epsilon g_i$;

6) 更新参数 $\theta_i = \theta_{i-1} + v_i$, 重复步骤 2)~6) 直到模型收敛。

3 实 验

3.1 性能指标

为了评估所提出方法的性能, 本文采用准确率 (accuracy)、精确率 (precision)、召回率 (recall) 和 $F1$ 参数 ($F1$ measure) 作为衡量算法性能的指标。为了清楚地说明上述指标的含义, 首先作如表 2 所示的定义。

表 2 名称定义

名称	含义
TP	真实水体样本被判定为水体的样本数量
FP	真实非水体样本被判定为水体的样本数量
FN	真实水体样本被判定为非水体的样本数量
TN	真实非水体样本被判定为非水体样本数量

性能指标定义如表 3 所示。准确率是所有样本中分类正确的样本所占的比例, 精确率是被判定为水体的样本中真实水体样本所占的比例, 召回率是真实水体样本中被正确分类的样本所占的比例, $F1$ 参数是精确率和召回率的调和平均值。

表 3 性能指标

指标	定义
准确率	$\frac{TP + TN}{TP + FP + FN + TN}$
精确率	$\frac{TP}{TP + FP}$
召回率	$\frac{TP}{TP + FN}$
$F1$ 参数	$\frac{2 \times \text{精确率} \times \text{召回率}}{\text{精确率} + \text{召回率}}$

3.2 实验数据

本文数据选择 2020 年 6 月获取的长江流域下游地区的 Sentinel-1A 数据, 为 C 波段宽幅 (IW) 模式下获取的 SAR 图像, 大小为 $25\,685 \times 16\,720$, 通过 Lee 滤波、幅度校正和几何校正后的 16 bit 深度图如图 6 所示。为了便于实验验证, 截取数据中 4 个含有水体的区域作为实验数据, 分别是平原湖泊 (湖泊 1)、山区湖泊 (湖泊 2)、宽河道 (河流

1)、窄河道 (河流 2) 四种水体类型, 如图 7 和 8 所示。




图 6 长江流域下游地区 SAR 图像




图 7 湖泊区域




图 8 河流区域

3.3 模型训练

模型训练数据集从获取的 SAR 数据中人工提取并标注, 不包含上述 4 个区域的数据。其中训练样本个数为 50 万左右, 交叉验证样本个数为 20 万左右, 测试样本个数为 20 万左右。

本文方法在 Windows10 环境下基于 MATLAB R2019a 编程实现。本文通过大量实验选择最佳参数设置, 初始学习率 $\epsilon = 0.01$, 动量参数 $\alpha = 0.9$ 。

3.4 实验结果

为验证本文方法的有效性, 将基于 CNN 的实验结果与基于 OTSU 阈值分割法^[2]和 SVM 方法^[7]的实验结果进行比较。

图 9 所示为平原湖泊和山区湖泊两类湖泊区域的水体提取结果, 黑色像素为水体, 白色像素为非水体部分。表 4 和 5 所示为 OTSU 方法、SVM 方法和 CNN 方法针对这两

类湖泊区域进行水体提取的性能参数结果。虽然 OTSU 方法将能够将湖泊水体部分完整提取出来,但是由于平原地区道路和部分农田与水体类似的灰度特征,以及山区的山体阴影与水体类似的灰度特征,OTSU 方法往往将道路、部分农田和山体阴影错误分类为水体,从而造成全局分类精度的下降。CNN 方法很好地克服了 OTSU 方法的缺点,将水体和非水体部分有效区分,实现了对水体的精确提取。SVM 方法结合基于灰度共生矩阵提取的纹理特征,有效降低了对非水体部分的物分类,但是水体提取的边缘性较差,比如湖泊 2 的水体边缘部分就没有很好的提取出来。而 CNN 方法对水体边缘细节部分可以实现有效提取,如图 9(f)所示。




图 9 湖泊区域水体提取

表 4 湖泊 1 提取结果 %

方法	OTSU	SVM	CNN
准确率	27.77	98.09	100.00
精确率	27.77	98.02	100.00
召回率	100.00	94.74	99.98
F1 参数	43.47	96.35	99.99

表 5 湖泊 2 提取结果 %

方法	OTSU	SVM	CNN
准确率	7.23	99.31	99.98
精确率	7.23	97.79	100.00
召回率	100.00	92.81	99.72
F1 参数	13.49	95.24	99.98

图 10 所示为宽河道和窄河道两类河流区域的水体提取结果,黑色像素为水体,白色像素为非水体部分。表 6

和 7 所示为 OTSU 方法、SVM 方法和 CNN 方法针对这两类河流区域进行水体提取的性能参数结果。针对河流 1 这类宽河道,相较于 OTSU 方法和 SVM 方法,CNN 方法可以完整提取河道水体部分,并且保持水体边缘较清晰平滑。对于河流 2 这类窄河道,河道窄细处的像素点只有几行或几列,基于纹理特征的 SVM 方法对此学习到的特征往往并不具有较高的区分性,所以只能提取零星的水体像素点,而不能完整提取整个河道,并且所提取的水体边缘粗糙。而 CNN 方法由于其强大的特征学习能力,可以获得有效的窄河道部分像素点的特征表示,相较于 SVM 方法所提取的窄河道水体像素点数目有所改善,能够较为完整的提取窄河道水体,如图 10(e)、(f)所示。除此之外,在全局分类精度即准确率上,CNN 方法也优于 OTSU 方法和 SVM 方法。




图 10 河流区域水体提取

表 6 河流 1 提取结果 %

方法	OTSU	SVM	CNN
准确率	8.04	98.96	100.00
精确率	8.04	96.54	100.00
召回率	100.00	91.13	99.97
F1 参数	14.88	93.76	99.99

表 7 河流 2 提取结果 %

方法	OTSU	SVM	CNN
准确率	9.45	97.40	99.72
精确率	9.45	87.34	99.97
召回率	100.00	78.00	96.48
F1 参数	17.27	82.41	98.19

4 应用实例——洪涝灾害监测

洪涝灾害监测是基于 SAR 图像水体提取的重要应用

领域。每年 6~7 月,长江流域正值梅雨季节,这段时间由于降水量的暴涨,长江主干道及其支流水位变化剧烈。以 2020 年 6~7 月对长江下游地区主干道水位变化的监测为例,验证本文提出方法的有效性。

通过 Sentinel-1A 遥感平台获取 2020 年 6 月和 2020 年 7 月长江下游江心洲地区 SAR 图像。监测结果如图 11 和 12 所示,蓝色部分表示 6 月长江水域面积,红色部分表示 7 月份长江水域增加的面积。可以看出江心洲和外滩所处区域已经被洪水淹没,两个面积较小的江心洲几近消失。




图 11 长江江心洲区域水体提取




图 12 长江江心洲区域 6~7 月水域面积变化

5 结 论

本文引入 CNN 实现基于 SAR 图像的水体提取。所提出的方法基于图像块对 SAR 图像进行处理,考虑了相邻像素信息,获得了更好的区域一致性,所提取的水体边缘更为光滑。同时通过多层卷积操作和池化操作获得更具代表性和鲁棒性的特征,有效克服了山体阴影对水体提取的影响。通过对平原湖泊、山区湖泊、窄河道和宽河道 4 类不同地形下的水体 SAR 数据的实验,验证了本文方法的有效性,并

且性能优于传统 OTSU 阈值分割法和基于纹理特征的 SVM 分类方法。以长江下游江心洲区域水域洪涝监测作为实例应用,进一步证明了本文方法的适用性。但是从实验中可以看出,所提出的 CNN 方法对细窄形状水体的提取效果不佳,这是由于所处理的图像块尺度与水体宽度接近的缘故,后续研究将考虑对这类水体的边缘和内部进行不同尺度的处理。

参考文献

- [1] LI M K, LI M, ZHANG P, et al. SAR image change detection using PCANet guided by saliency detection[J]. IEEE Geoscience and Remote Sensing Letters, 2019, 16(3): 402-406.
- [2] VALDIVIEZO-NAVARRO J C, SALAZAR-GARIBAY A, TÉLLEZ-QUINONES A, et al. Inland water body extraction in complex reliefs from Sentinel-1 satellite data[J]. Journal of Applied Remote Sensing, 2019, 13(1): 1-16.
- [3] MENG Q, WEN X, YUAN L, et al. Factorization-based active contour for water-land SAR image segmentation via the fusion of features [J]. IEEE Access, 2019, 7: 40347-40358.
- [4] WANG Z, ZHANG R, ZHANG Q, et al. An automatic thresholding method for water body detection from SAR image [C]. 2019 IEEE International Conference on Signal, Information and Data Processing(ICSIDP), 2019: 1-4.
- [5] OTSU N. A threshold selection method from gray-level histograms[J]. IEEE Transactions on Systems, Man, and Cybernetics, 1979, 9(1): 62-66.
- [6] 李景刚,黄诗峰,李纪人. ENVISAT 卫星先进合成孔径雷达数据水体提取研究:改进的最大类间方差阈值法[J]. 自然灾害学报,2010, 19(3): 139-145.
- [7] 庞英,刘畅. 一种改进的基于超像素的 SAR 图像海陆分割方法[J]. 国外电子测量技术,2019,38(8):12-18.
- [8] XIE L, ZHANG H, WANG C, et al. Water-body types identification in urban areas from radarsat-2 fully polarimetric SAR data [J]. International Journal of Applied Earth Observation and Geoinformation, 2016, 50: 10-25.
- [9] HUANG W L, DEVRIES B, HUANG C Q, et al. Automated extraction of surface water extent from Sentinel-1 data[J]. Remote Sensing,2018,10(5):797.
- [10] LV W T, YU Q Z, YU W X. Water extraction in SAR images using GLCM and support vector machine[C]. IEEE 10th International Conference on Signal Processing Proceedings, 2010: 740-743.
- [11] 张笑,刘文波. 基于卷积神经网络的 SAR 图像目标识别算法研究[J]. 电子测量技术, 2018, 41(14): 92-96.

- [12] PAI M M M, VAIBHAV M, UJJWAL V, et al. Improved semantic segmentation of water bodies and land in SAR images using generative adversarial networks [J]. International Journal of Semantic Computing, 2020, 14(1): 55.
- [13] HUA W, XIE W, JIN X. Three-channel convolutional neural network for polarimetric SAR images classification[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2020, 13: 4895-4907.
- [14] HENRY C, AZIMI S M, MERKLE N. Road segmentation in sar satellite images with deep fully convolutional neural networks[J]. IEEE Geoscience and Remote Sensing Letters, 2018, 15(12): 1867-1871.
- [15] PAI M M M, MEHROTRA V, AIYAR S, et al. Automatic segmentation of river and land in SAR images: a deep learning approach[C]. IEEE Second Int. Conf. Artificial Intelligence and Knowledge Engineering, 2019: 15-20.

作者简介

陈坤, 研究生, 主要研究方向为 SAR 图像地物分类算法。

E-mail: chenkun_bc@163.com