

一种超分辨SAR图像水域分割算法及其应用

陈嘉琪^{*①} 刘祥梅^① 李 宁^{②③} 张 燕^①

^①(河海大学计算机与信息学院 南京 211100)

^②(河南大学计算机与信息工程学院 开封 475004)

^③(河南省大数据分析处理重点实验室 开封 475004)

摘 要: 合成孔径雷达(SAR)图像水域分割在湖泊、河流等陆地水文监测领域有重要的研究意义。由于SAR图像分辨率不足所导致的陆地与水域边界模糊,会影响水域分割精度。该文以中国青藏高原地区的多庆错湖为研究对象,使用Sentinel-1A SAR图像数据,综合运用深度残差模型、通道注意力与亚像素卷积,提出一种基于亚像素卷积的增强型通道注意力深度残差超分辨网络,对滤波后的SAR图像进行重建、水域轮廓提取与精度分析。通过比较不同超分辨算法下的重建结果及水域轮廓提取精度,该文算法在重建效果与提取精度上都较传统方法有明显提升,并具有很好的鲁棒性。

关键词: 合成孔径雷达; 超分辨率重建; 水域分割

中图分类号: TN958

文献标识码: A

文章编号: 1009-5896(2021)03-0700-08

DOI: [10.11999/JEIT200366](https://doi.org/10.11999/JEIT200366)

A High-precision Water Segmentation Algorithm for SAR Image and its Application

CHEN Jiaqi^① LIU Xiangmei^① LI Ning^{②③} ZHANG Yan^①

^①(College of Computer and Information, Hohai University, Nanjing 211100, China)

^②(School of Computer and Information Engineering, Henan University, Kaifeng 475004, China)

^③(Henan Key Laboratory of Big Data Analysis and Processing, Henan University, Kaifeng 475004, China)

Abstract: Water segmentation of Synthetic Aperture Radar (SAR) is of great significance in land hydrological monitoring, such as lakes and rivers. Water segmentation accuracy is influenced by the blurring of the boundary between land and water region because of the insufficient resolution of SAR image. Sentinel-1A SAR image is used to study the Duoqing Co in the Tibetan Plateau of China. This paper integrates the enhanced deep residual block, channel attention mechanism and sub-pixel convolution, an enhanced channel attention deep residual network is proposed based on sub-pixel to reconstruct the filtered SAR image, extract the water contour and analyze the accuracy. By comparing the reconstruction results of different super-resolution algorithms and the accuracy of water contour extraction, this algorithm, with great robustness, is obviously better than the traditional method in both reconstruction effect and extraction accuracy.

Key words: Synthetic Aperture Radar (SAR); Super-resolution reconstruction; Water segmentation

收稿日期: 2020-05-08; 改回日期: 2020-12-05; 网络出版: 2020-12-17

*通信作者: 陈嘉琪 cjq19840130@163.com

基金项目: 国家自然科学基金(61771183, 61601437), 中央高校基础研究基金(2016B07114), 河南省科技攻关计划项目(192102210082), 河南省青年人才托举工程(2019HYTP006), 中国博士后科学基金(2013M541035)

Foundation Items: The National Natural Science Foundation of China (61771183, 61601437), The Fundamental Research Funds for the Central University (2016B07114), The Plan of Science and Technology of Henan Province (192102210082), The Youth Talent Lifting Project of Henan Province (2019HYTP006), China Postdoctoral Science Foundation (2013M541035)

1 引言

青藏高原是世界上湖泊最多的地区之一，截至2018年，有1424个湖泊面积达到1 km²以上，总面积约5×10⁴ km²，并且这些湖泊大多为内陆湖^[1]。因为海拔、气温等条件的限制，这些高原内陆湖受人类活动影响小，多处于自然状态，能真实地反映地质活动和气候变化。对这些湖泊的探测，在环境监测、灾难预警等领域都具有重要意义。光学探测器^[2]在该地区虽然应用广泛，但容易受到云雾、降雨等恶劣天气的影响。合成孔径雷达(Synthetic Aperture Radar, SAR)具有较好的穿透性，不受光照、云层等影响，能提供全天时、全天候的观测影像^[3]，是监测高原湖泊等内陆水体的理想设备。

传统的SAR水域分割算法主要有阈值分割、机器学习、主动轮廓模型(Active Contour Model, ACM)等。阈值分割法通过设置多个阈值，实现对图像区域的划分，操作简单，缺点是难以选择最优阈值且受相干斑噪声影响大^[4]。机器学习在SAR图像处理中逐步成为热点^[5]。通过训练样本，建立网络模型，实现水域分割。本文方法不易受相干斑影响，但需要事先制作大量训练样本。ACM算法将图像分割问题转化为求解能量泛函数最小值问题^[6,7]，可以获取连续、平滑的轮廓曲线，但对初始轮廓依赖性大^[8]。星载SAR受最小天线孔径积的制约，其宽幅模式的空间分辨率通常在10 m数量级，往往无法满足实际应用需求^[9,10]。同时，在水域和陆地的边界地区，回波信号区分度相对较小，使得水陆边界难以确定，进一步限制了水域提取的精度。

针对以上问题，为了提升湖泊轮廓提取精度，可以在进行水域分割之前，对图像进行超分辨(Super Resolution, SR)重建。SR是一种通过单张或多张低分辨率(Low Resolution, LR)原始图像得到细节丰富的高分辨率(High Resolution, HR)图像或序列的图像增强方法^[10]。当前SR重建算法主要分为3类：插值型、重构型和学习型。插值型算法利用待插值空间相邻点计算得到待插入点像素，是最早的SR算法^[11]。该方法优点是计算复杂度低，处理速度快，但缺点是HR图像会出现边缘模糊现象。重构型算法是结合图像的退化模型与LR图像的重建条件，对成像过程建立模型，再将同一场景不同信息融入模型中，得到HR图像的方法^[12]。这类算法以时间消耗换取空间分辨率的提高，复杂程度高且无法保证分辨率的提高程度。学习型算法克服了重构中的障碍，在LR与HR样本库之间，通过学习建立二者的映射关系，进而指导完成图像的超分辨重建。近年来随着机器学习的蓬勃发展，基于神经网络的SR算法日益受到关注。

本文提出一种基于深度残差超分辨的SAR图像水域分割算法，在传统ACM水域分割算法中，融入改进的增强型深度超分辨率网络(Improved Enhanced Deep Super Resolution network, IEDSR)。该网络在增强型深度残差网络的基础上，在每个残差块上引入通道注意力块，训练时更加专注于影像的高频信息部分，减少模型复杂度^[13]。为进一步缩短运行时间，本文将亚像素卷积层添加到网络末端，用于上采样操作。由此构成一种基于亚像素卷积的增强型通道注意力深度残差超分辨率网络。本文对获取的SAR影像，运用Lee滤波器进行相干斑抑制。将滤波后的影像进行超分辨处理，图像的行列像素值扩大为初始图像的2倍。在提高图像中边界的清晰度后，通过ACM提取水域面积。为了验证该模型的精度和在此基础上水域分割的准确性，本文以青藏高原的多庆错湖为例进行实验。该湖泊在2016年发生过突然的干涸和复原现象^[14]，其图像更具有代表性。实验表明，本文算法相比于传统的超分辨率网络，重建效果更佳，湖泊轮廓提取精度明显提升。

2 基于混合对数正态分布的ACM模型

经典的ACM模型有C-V和GAC模型等。这些模型在同质性较好的图像中有很好的效果，但对于图像的噪声较为敏感。对于SAR图像而言，其统计分布多呈现非高斯分布，容易受到乘性相干斑噪声影响。本文引用一种基于混合对数正态分布的ACM算法(improved ACM based on Mixed Log-normal Distribution, MLD-ACM)^[15]，应用混合对数正态分布对SAR影像进行拟合，通过期望最大化算法对参数进行估计。同时，引入区域可变系数，使水平集在演化过程中能准确停在目标边界。模型的能量函数概括为

$$\begin{aligned}
 E(\phi(v)) &= \omega E_{\text{lg NMM}}(\phi(v)) + E_b(\phi(v)) \\
 &= \omega \int_{\Omega_1} \lg p_1 H(\phi) dy \\
 &\quad - \omega \int_{\Omega_2} \lg p_2 (1 - H(\phi)) dy \\
 &\quad + \mu \int_{\Omega} \frac{1}{4} (|\nabla \phi|^2 - 1) dv \\
 &\quad + \eta \int_{\Omega} g(v) \delta_{\varepsilon}(\phi(v)) |\nabla \phi(v)| dv \\
 &\quad + \rho(v) \int_{\Omega} g(v) H_{\varepsilon}(-\phi(v)) dv \quad (1)
 \end{aligned}$$

该能量函数考虑了相干斑影响，具有良好的抗噪声性能。轮廓曲线 C 将SAR影像 Ω 划分为 Ω_1 与 Ω_2 两部

分, p_1 与 p_2 为对应的概率密度函数。 v 为图像中的像素点, 引入水平集函数 $\phi(v)$, 使 $\Omega_1 = \{\phi > 0\}$ 与 $\Omega_2 = \{\phi < 0\}$, 轮廓线 $C = \{\phi = 0\}$ 。引入Heaviside函数 H 以及Dirac函数 δ ; ω , μ 和 η 为待定参数; E_{lgNMM} 与 E_b 为基于区域的能量函数和边缘信息的能量函数。 $g(v)$ 与 $\rho(v)$ 为边缘停止函数和区域可变系数。其表达式为

$$g(v) = \frac{1}{1 + f/(\sigma_{\text{in}}^2(v) + \sigma_{\text{out}}^2(v) + 1)} \quad (2)$$

$$\rho(v) = \alpha e^{-\beta|u_{\text{in}}(v) - u_{\text{out}}(v)|} + c \quad (3)$$

式(2)中 f 为图像的梯度信息, $\sigma_{\text{in}}^2(v)$ 与 $\sigma_{\text{out}}^2(v)$ 分别为轮廓内外的模拟方差, 为了提高边缘停止函数特性, 将局部区域方差引入该函数。式(3)中 α , β 和 c 为待定参数, u_{in} 与 u_{out} 为轮廓内外区域均值。依据变分法原理, 最小化式(1), 得到对应的水平集函数。

3 IEDSR重建模型

图1(a)所示, 对原始图像卷积, 提取特征。然后将通道注意力块融入残差网络, 构成增强型通道注意力深度残差块(Enhanced Channel Attention Resblock, ECAR), 多个ECAR级联实现非线性映射(图1(b))。最后通过亚像素卷积进行上采样, 使特征提取与非线性映射能在低分辨率空间实现, 从而降低计算复杂度。

3.1 残差网络

超分辨率卷积神经网络(Super Resolution Convolutional Neural Network, SRCNN)^[16]被提出以来, 基于卷积神经网络(Convolutional Neural Network, CNN)的模型在超分辨率重建领域取得了显著进步^[17], 但网络结构往往越来越复杂, 模型深度不断增加。在CNN训练过程中, 前一层网络的参数变化将引起后一层网络的连锁变化。随着网络深度增加, 这一影响会不断放大, 导致网络训练难度大、降质、梯度弥散等问题。

深度残差学习理念很好地解决了上述问题。基本思想是使用一个“卷积-ReLU-卷积”模块学习输入到残差的映射, 而不是直接学习输入到输出之间的映射(图1(c))。网络期望叠加层学习到的映射函数可以表示为 $Y(x) = H_x - x$, 可用 $Y(x) + x$ 表示期望学习到的原始映射函数 H_x 。其中, 用 x 表示该结构的输入, H_x 表示期望学习到的隐藏映射函数即该结构输出, ReLU为激活函数。卷积-ReLU-卷积模块称为残差模块。

残差模块的另一个优点是可以解决梯度弥散的问题。基础残差模块有着下面的函数关系

$$y_l = H_{x_l} + F(x_l, \omega_l) \quad (4)$$

$$x_{l+1} = f(y_l) \quad (5)$$

当满足 $H_{x_l} = x_l$, $x_{l+1} = y_l$ 的条件时, 对式(4)和式(5)递推计算可以得到

$$x_L = x_l + \sum_{i=l}^{L-1} F(x_i, \omega_i) \quad (6)$$

由式(6)发现, 对某一浅层残差单元的输入和中间层全部的复杂映射求和便可得到第 L 个残差单元的输入。对损失函数求偏导, 发现即使网络的深度很深, 梯度也仍然存在, 梯度弥散的问题由此解决。

本文增强型深度残差网络中的残差模块, 在每个残差块中的最后一个卷积层后, 设置一个残差缩放因子 s 。通过扩大模型的尺寸来提升重建结果的质量。当特征图的数量增加至一定程度时, 网络在训练过程中可能会产生数值不稳定的情况^[18]。故而引入残差缩放因子 s 来解决这一问题。

3.2 通道注意力机制

图像超分辨率重建算法将原始的低分辨率图像输入网络进行特征提取。而低分辨率图像含有大量低频信息, 这些信息本可以直接传播到输出。倘若平等对待、处理所有通道, 会造成神经网络学习能




图1 算法整体流程图

力下降。本文在神经网络中引入通道注意力机制，增大具有高频信息的通道权值，减小其余含有众多低频信息的权值。以此增加通道之间的差异性，加速网络收敛，并进一步提升网络的学习性能^[19]。示意图如图2所示。




图2 通道注意力机制示意图

图2中，输入特征图和输出特征图的维度都是 $H \times W \times C$ ， H_{GP} 表示全局平均池化操作， W_D 和 W_U 分别表示降维、升维操作， $F_{Sigmoid}$ 表示Sigmoid激活函数， $\otimes$ 表示Hadamard乘积。将维度为 $H \times W \times C$ 的特征图作为输入，经过全局平均池化得到的逐通道统计量可看作一系列用于描述各个通道的描述符，将其记作 $\hat{z} \in R^C$ ，那么， $\hat{z}$ 的第 k 个元素可以表示为

$$\hat{z}_k = H_{GP}(x_k) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W x_k(i, j) \quad (7)$$

其中， $H_{GP}(\cdot)$ 表示全局平均池化处理， x_k 表示输入特征图的第 k 个通道分量， $x_k(i, j)$ 表示第 k 个通道中坐标位置是 (i, j) 的图像像素值。逐通道统计量 $\hat{z}$ 在经过两次卷积及激活作用，获得缩放后的描述量

$$s_k = F(W_U \delta(W_D \hat{z}_k)) \quad (8)$$

其中， $\delta(\cdot)$ 表示ReLU激活操作， $F(\cdot)$ 表示Sigmoid激活函数。将原输入与式(8)计算得到的描述量 s_k 做Hadamard乘法计算，得到最终的通道注意力特征表示

$$\hat{x}_k = s_k \otimes x_k \quad (9)$$

3.3 增强型通道注意力深度残差模块

本文提出将通道注意力机制引入增强型深度残差块，构成ECAR，使构建的重建网络可以专注于更有用的高频信息通道，提高神经网络的学习能力。具体而言，先对输入的特征图进行卷积，从而获得更为深层的特征表示，然后经过通道注意力块的处理，再输出到级联的下一个基本单元提取更深层次的图像特征。ECAR的网络基本单元如图1(b)所示，由2个级联的卷积层、ReLU激活函数和1个通道注意力模块构成，并增加局部跳连结构。通道注意力块中的降维和升维均利用 1×1 的卷积实现，降维卷积层使用ReLU激活函数，升维卷积层使用Sigmoid激活函数， $\otimes$ 表示Hadamard乘法， $\oplus$ 表示逐像素加法运算。

3.4 亚像素卷积

现有的SRCNN算法对原始低分辨率图像作双

3次插值来得到1张与目标重建结果尺寸相同的低分辨率图像，再将其作为重建算法的输入图像，这样大大降低了算法的整体训练速度。本文去掉用双3次插值的上采样预处理操作，在网络的末端添加亚像素卷积，实现上采样操作。亚像素卷积可分解为两步：(1)对低分辨率特征图作卷积，将它的特征通道数转化为 r^2 ，其中的 r 表示上采样倍数，本文为2；(2)对卷积后得到的低分辨率特征图做周期性的移动，通过重新排列获得高分辨率图像作为最终的输出图像。

亚像素卷积操作可以用式(10)的数学形式表示

$$I^{HR} = f^l(I^{LR}) = PS(W_l * f^{l-1}(I^{LR}) + b_l) \quad (10)$$

W_l 对应第 l 层网络的卷积核，PS对应一个周期性移动操作。式(10)中的PS操作可以用式(11)表示

$$PS(T)_{x,y,c} = T_{\lfloor x/r \rfloor, \lfloor y/r \rfloor, c \cdot r \cdot \text{mod}(y,r) + c \cdot \text{mod}(x,r)} \quad (11)$$

其中， x 和 y 表示高分辨率空间中的输出像素坐标， C 为图像的通道数量， $\lfloor \cdot \rfloor$ 和 $\text{mod}(\cdot)$ 分别表示向下取整和取余操作。经过第1步卷积后，得到 r^2 个 $H \times W$ 的特征图像。这些图像中，每个像素对应 r^2 通道。对于每个像素，将这些通道重新排列成 $r \times r$ 的区域子块。则原本的 $r^2 \times H \times W$ 的图像重新排列成一张 $rH \times rW$ 的高分辨率图像。亚像素卷积层相比于反卷积操作，在保持分辨率的同时，提高了网络的训练效率。

4 实验结果与分析

本文实验所用计算机CPU为Intel(R) Core (TM) i7-9750H，GPU为NVIDIA GeForce GTX 1650。在tensorflow_gpu-1.13.1学习环境下，使用Python3.6.5进行处理。将滤除相干斑噪声的SAR影像降采样，构建训练样本。为了增加样本数，对图像进行水平与垂直翻折，由120张影像构成训练集。实验内容分两部分：(1)本文算法与插值型算法(Bicubic)、融合卷积神经网络的学习型算法(SRCNN)进行超分辨率重建比较；(2)基于上述3种算法与原始图像，应用MLD-ACM算法进行水域轮廓提取，并进行定量分析。

4.1 参数指标与模型训练

本文使用峰值信噪比(Peak Signal to Noise Ratio, PSNR)与结构相似性指数(Structural Similarity index, SSIM)来衡量算法间重建效果。PSNR和SSIM分别用于衡量参考与目标图像的灰度相似性和结构相似性，这里的参考图像指原始高分辨率图像，目标图像指重建输出的图像。两者的数学表达式为

$$PSNR = 10 \lg \frac{L^2}{MSE} \quad (12)$$

$$SSIM = \frac{(2\mu_f\mu_{\hat{f}} + c_1)(\sigma_{f_{\hat{f}}} + c_2)}{(\mu_f^2 + \mu_{\hat{f}}^2 + c_1)(\sigma_f^2 + \sigma_{\hat{f}}^2 + c_2)} \quad (13)$$

式(12)中, L 为对图像进行量化的灰度级别, MSE 为图像均方误差。式(13)中 c_1 与 c_2 为常数, μ_f 与 $\mu_{\hat{f}}$ 分别为参考图像与目标图像的平均灰度, σ_f 与 $\sigma_{\hat{f}}$ 为两者的方差。 $\sigma_{f_{\hat{f}}}$ 则是参考图像与目标图像的协方差。

水域提取精度则通过漏检率(OM)、虚警率(COM)和轮廓平均偏移距离(Dis)来衡量。取 A_R 为湖泊实测面积, A_E 为算法提取到的湖泊面积, A_{RE} 为湖泊实际与提取到的湖泊面积的重合部分, 数学公式为

$$OM = \frac{A_R - A_{RE}}{A_R} \quad (14)$$

$$COM = \frac{A_E - A_{RE}}{A_E} \quad (15)$$

$$Dis = \sqrt{\left(\sum_{i=1}^N d_i^2\right)/N} \quad (16)$$

其中, d_i 为提取的水域与真实边界对应点距离, N 为水体的边界长度, i 为边界像素点个数。

实验中将特征图通道数量设为256。对于图1结构, 特征提取部分由256个通道数 3×3 卷积层实现。非线性映射部分则通过32个级联的增强型通道注意力深度残差模块来实现。在深度残差模块构建中引入的残差缩放因子 s 设置为0.01。结合PSNR和SSIM评价指标, 本文选用L1范数作为网络的损失函数。该函数以最小化估计值和目标值之间的绝对值为目标, 其定义为

$$Loss_1(\Theta) = \frac{1}{n} \sum_{i=1}^n |F(i) - X_i| \quad (17)$$

其中, n 表示数据集中样本数量, $F(i)$ 与 X_i 分别为第 i 个样本估计值和样本目标值。

使用自适应矩阵估计法作为神经网络训练的优化算法。该算法是随机梯度下降算法的扩展值, 通过梯度的1阶、2阶矩估计为网络中各个不同参数设计自适应学习率。图3为训练过程整体趋势变化图, 经过 2×10^5 次迭代得到模型。当训练次数达到约 2×10^4 次后, 损失值下降趋势放缓, 后续损失值曲线呈微小的上下波动。

4.2 超分辨重建比较

该实验对Sentinel-1A卫星影像, 采用Bicubic, SRCNN与本文算法进行超分辨重建。图4为对2016年8月23日VV通道影像处理结果。原始图像 $558 \text{像素} \times 510 \text{像素}$, 算法重建后得到的图像为 $1116 \text{像素} \times 1020 \text{像素}$, 前后图像水平与垂直方向分辨率为72 dpi。可以明显分辨出, SRCNN与本文算法, 相比于原图, 其水域与陆地对比有所增强, 并且本文算法效果更为明显。而Bicubic处理后图像变化却不明显, 与原图相似。

对其余7组处理, 其中2016年4月17日与6月12日为湖泊接近干涸的影像, 定量结果如表1所示。在这8景影像中, SRCNN在3景图像中PSNR数值




图3 IEDSR网络损失值变化曲线




图4 3种超分辨算法对多庆湖影像处理结果对比

表 1 8组多庆错湖影像重建质量评估(PSNR(dB)/SSIM)

日期	Bicubic	SRCNN	本文IEDSR
20150902	27.41/0.76	28.46/0.82	28.22/0.85
20151016	24.64/0.68	25.38/0.75	26.39/0.85
20151125	27.05/0.78	28.21/0.84	28.28/0.86
20160401	25.86/0.78	26.90/0.84	27.43/0.89
20160417	27.09/0.83	28.46/0.88	27.93/0.89
20160612	24.12/0.76	24.99/0.83	24.90/0.86
20160730	27.71/0.79	28.94/0.85	29.04/0.88
20160823	28.61/0.81	29.55/0.86	29.88/0.88
平均值	26.56/0.77	27.61/0.83	27.76/0.87

比本文算法大，但就平均值而言，本文算法有更好的重建效果。本文算法的SSIM指标始终优于其他算法，表明重建后图像与原图结构性差异性更小。SRCNN与本文算法都是学习型超分辨率算法，作为插值型的Bicubic效果则明显弱于两者，其两项指标都小于上述学习型算法。

4.3 基于超分辨率的轮廓提取

本文对原始图像和应用上述3种重建算法处理后的图像进行水域轮廓提取。以2016年6月12日湖泊干涸时期影像为例(图5)，红线为真实轮廓情况，紫线为本文算法提取结果，蓝线、绿线与黄线为原图、Bicubic和SRCNN处理结果。如图5(a)中所示，蓝线与红线偏差较大，紫线则与红线更为接近。经过超分辨率处理后，在该实验中，轮廓提取结果更为精准，并且本文算法获得了最高的提取精度。

表2为实验的8组数据在以上4种情形下的精度评估。对原图应用Bicubic，SRCNN与IEDSR，得到分辨率为原图的2倍，同一清晰度的超分辨率影像。其中2016年6月12日，未经重建的影像，其3项指标都高于处理后影像，表明重建后提高了轮廓提取精度。综合8景影像结果，IEDSR提取精度依旧比另外3种高。在上述情形下，提取精度比较结果依次是：IEDSR, RSCNN, Bicubic和未经处理的提取




图 5 多庆错湖轮廓提取结果

表 2 不同时期轮廓提取精度比较(OM(%)/COM(%)/Dis像素)

日期	原图	Bicubic	SRCNN	本文IEDSR
20150902	0.39/0.29/0.73	0.26/0.13/0.44	0.22/0.11/0.35	0.14/0.13/0.29
20151016	0.26/1.14/1.03	0.22/0.56/0.61	0.18/0.64/0.60	0.05/0.78/0.60
20151125	0.12/2.83/2.32	0.17/1.14/1.03	0.08/1.24/1.01	0.02/1.24/0.97
20160401	0.12/2.74/2.25	0.19/0.88/0.83	0.08/0.93/0.77	0.01/0.64/0.51
20160417	0.28/10.57/2.96	0.50/3.84/1.80	0.43/3.24/1.50	0.02/2.44/0.99
20160612	0.62/12.93/2.70	0.61/4.41/0.89	0.48/4.43/0.86	0.04/3.15/0.55
20160730	0.23/0.54/0.77	0.13/0.28/0.41	0.05/0.51/0.57	0.01/0.28/0.30
20160823	0.16/0.30/0.52	0.01/0.11/0.22	0.09/0.05/0.15	0.05/0.08/0.10

结果。Bicubic和SRCNN在8景图像中平均运行时间分别为0.0018 s和12.46 s。IEDSR的平均时间为5.13 s。运行时间从快到慢依次为, Bicubic, IEDSR和SRCNN。Bicubic虽然超分辨率效果较差, 但计算快。IEDSR则在计算时间和重建效果在本文应用背景下, 都优于SRCNN。IEDSR提取多庆错湖轮廓,

得到2015年9月到2016年8月的时序结果(图6)。结合表2与图6, 在湖水充盈时, 这4种情况下提取精度都相对较高。但在出现干涸现象时, 以上4种情形精度普遍下降。但本文算法在不同时期, 其指标较其他3种情形都较低, 表明本文算法具备较好的鲁棒性。




图6 2015年9月至2016年8月应用IEDSR水域提取结果

对于图6得到的水域轮廓, 本文进行相应比例放大, 计算出湖泊实际面积。结果表明该湖泊从2016年4月起不断萎缩, 并出现干涸现象, 并在7月份恢复至正常水位。有研究表明, 该地区降水、气温条件稳定, 未出现气候的异常^[14], 其变化的原因未来可以做进一步探究。

5 结论

本文提出一种改进的增强型深度超分辨率网络, 结合MLD-ACM边缘提取算法。该方法将通道注意力块融入增强型残差网络, 使模型训练过程更集中于图像高频成分, 减少模型复杂度。在网络末端进行亚像素卷积, 缩短运行时间, 同时更加专注图像细节部分。以多庆错湖为例, 对超分辨率重建和水域提取情况进行比较分析。实验结果表明, 该网络有更好的重建效果, 可以提取更加准确的轮廓信息。本文算法具有很好的鲁棒性, 可以完成对高原湖泊的监测。另外, 多庆错湖在2016年4月—8月的异常现象, 也值得进一步研究。

参考文献

[1] 朱立平, 张国庆, 杨瑞敏, 等. 青藏高原最近40年湖泊变化的主要表现与发展趋势[J]. 中国科学院院刊, 2019, 34(11):

1254–1263. doi: [10.16418/j.issn.1000-3045.2019.11.008](https://doi.org/10.16418/j.issn.1000-3045.2019.11.008).

ZHU Liping, ZHANG Guoqing, YANG Ruimin, *et al.* Lake variations on Tibetan plateau of recent 40 years and future changing tendency[J]. *Bulletin of Chinese Academy of Sciences*, 2019, 34(11): 1254–1263. doi: [10.16418/j.issn.1000-3045.2019.11.008](https://doi.org/10.16418/j.issn.1000-3045.2019.11.008).

[2] SONG Kaishan, LIU Ge, WANG Qiang, *et al.* Quantification of lake clarity in China using Landsat OLI imagery data[J]. *Remote Sensing of Environment*, 2020, 243: 111800. doi: [10.1016/j.rse.2020.111800](https://doi.org/10.1016/j.rse.2020.111800).

[3] 李春升, 王伟杰, 王鹏波, 等. 星载SAR技术的现状与发展趋势[J]. 电子与信息学报, 2016, 38(1): 229–240. doi: [10.11999/JEIT151116](https://doi.org/10.11999/JEIT151116).

LI Chunsheng, WANG Weijie, WANG Pengbo, *et al.* Current situation and development trends of spaceborne SAR technology[J]. *Journal of Electronics & Information Technology*, 2016, 38(1): 229–240. doi: [10.11999/JEIT151116](https://doi.org/10.11999/JEIT151116).

[4] GUO Yaru and ZHANG Jixian. A new 2D Otsu for water extraction from SAR image[J]. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2017, XLII-2/W7: 733–736. doi: [10.5194/isprs-archives-XLII-2-W7-733-2017](https://doi.org/10.5194/isprs-archives-XLII-2-W7-733-2017).

[5] 杜兰, 魏迪, 李璐, 等. 基于半监督学习的SAR目标检测网络[J].

- 电子与信息学报, 2020, 42(1): 154–163. doi: [10.11999/JEIT190783](https://doi.org/10.11999/JEIT190783).
- DU Lan, WEI Di, LI Lu, *et al.* SAR target detection network via semi-supervised learning[J]. *Journal of Electronics & Information Technology*, 2020, 42(1): 154–163. doi: [10.11999/JEIT190783](https://doi.org/10.11999/JEIT190783).
- [6] 冷英, 刘忠玲, 张衡, 等. 一种改进的ACM算法及其在鄱阳湖水域监测中的应用[J]. 电子与信息学报, 2017, 39(5): 1064–1070. doi: [10.11999/JEIT160870](https://doi.org/10.11999/JEIT160870).
- LENG Ying, LIU Zhongling, ZHANG Heng, *et al.* Improved ACM algorithm for Poyang lake monitoring[J]. *Journal of Electronics & Information Technology*, 2017, 39(5): 1064–1070. doi: [10.11999/JEIT160870](https://doi.org/10.11999/JEIT160870).
- [7] KASS M, WITKIN A, and TERZOPOULOS D. Snakes: Active contour models[J]. *International Journal of Computer Vision*, 1988, 1(1): 321–332. doi: [10.1007/BF00133570](https://doi.org/10.1007/BF00133570).
- [8] LI Ning, WANG R, DENG Yunkai, *et al.* Waterline mapping and change detection of Tangjiashan dammed lake after Wenchuan earthquake from multitemporal high-resolution airborne SAR imagery[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, 7(8): 3200–3209. doi: [10.1109/JSTARS.2014.2345417](https://doi.org/10.1109/JSTARS.2014.2345417).
- [9] 李宁, 牛世林. 基于局部超分辨率重建的高精度SAR图像水域分割方法[J]. 雷达学报, 2020, 9(1): 174–184. doi: [10.12000/JR19096](https://doi.org/10.12000/JR19096).
- LI Ning and NIU Shilin. High-precision water segmentation from synthetic aperture radar images based on local super-resolution restoration technology[J]. *Journal of Radars*, 2020, 9(1): 174–184. doi: [10.12000/JR19096](https://doi.org/10.12000/JR19096).
- [10] 王钢, 周若飞, 邹映琨. 基于压缩感知理论的图像优化技术[J]. 电子与信息学报, 2020, 42(1): 222–233. doi: [10.11999/JEIT190669](https://doi.org/10.11999/JEIT190669).
- WANG Gang, ZHOU Ruofei, and ZOU Yikun. Research on image optimization technology based on compressed sensing[J]. *Journal of Electronics & Information Technology*, 2020, 42(1): 222–233. doi: [10.11999/JEIT190669](https://doi.org/10.11999/JEIT190669).
- [11] TSAI R Y and HUANG T S. Multiframe image restoration and registration[J]. *Advances in Computer Vision and Image Processing*, 1984, 1(2): 317–339.
- [12] HARDIE R C, BARNARD K J, and ARMSTRONG E E. Joint MAP registration and high-resolution image estimation using a sequence of undersampled images[J]. *IEEE Transactions on Image Processing*, 1997, 6(12): 1621–1633. doi: [10.1109/83.650116](https://doi.org/10.1109/83.650116).
- [13] KIM J, LEE J K, and LEE K M. Accurate image super-resolution using very deep convolutional networks[C]. 2016 IEEE on Computer Vision and Pattern Recognition, Las Vegas, USA, 2016: 1646–1654. doi: [10.1109/CVPR.2016.182](https://doi.org/10.1109/CVPR.2016.182).
- [14] 吴中海, 哈广浩, 赵根模, 等. 西藏亚东-谷露裂谷南段多庆错2016年4月异常干涸的构造成因[J]. 地球科学, 2018, 43(S2): 243–255. doi: [10.3799/dqkx.2018.204](https://doi.org/10.3799/dqkx.2018.204).
- WU Zhonghai, HA Guanghao, ZHAO Genmo, *et al.* Tectonic analysis on abnormal dried up of Duoqing co lake of southern section of Yadong-Gulu rift in South Tibet during April, 2016[J]. *Earth Science*, 2018, 43(S2): 243–255. doi: [10.3799/dqkx.2018.204](https://doi.org/10.3799/dqkx.2018.204).
- [15] CHEN Jiaqi, WANG Qingwei, WANG Jian, *et al.* Change detection of water index in Danjiangkou reservoir using mixed log-normal distribution based active contour model[J]. *IEEE Access*, 2019, 7: 95430–95442. doi: [10.1109/ACCESS.2019.2929178](https://doi.org/10.1109/ACCESS.2019.2929178).
- [16] DONG Chao, LOY C C, HE Kaiming, *et al.* Image super-resolution using deep convolutional networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016, 38(2): 295–307. doi: [10.1109/TPAMI.2015.2439281](https://doi.org/10.1109/TPAMI.2015.2439281).
- [17] 张金松, 邢孟道, 孙光才. 一种基于密集深度分离卷积的SAR图像水域分割算法[J]. 雷达学报, 2019, 8(3): 400–412. doi: [10.12000/JR19008](https://doi.org/10.12000/JR19008).
- ZHANG Jinsong, XING Mengdao, and SUN Guangcai. A water segmentation algorithm for SAR image based on dense depthwise separable convolution[J]. *Journal of Radars*, 2019, 8(3): 400–412. doi: [10.12000/JR19008](https://doi.org/10.12000/JR19008).
- [18] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, *et al.* Deep residual learning for image recognition[C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, USA, 2016: 770–778. doi: [10.1109/CVPR.2016.90](https://doi.org/10.1109/CVPR.2016.90).
- [19] SZEGEDY C, IOFFE S, VANHOUCKE V, *et al.* Inception-v4, inception-ResNet and the impact of residual connections on learning[C]. Proceedings of the 31st AAAI Conference on Artificial Intelligence, 2016.
- 陈嘉琪: 男, 1984年生, 副教授, 硕士生导师, 研究方向为雷达信号处理及应用, 计算电磁学。
- 刘祥梅: 男, 1997年生, 硕士生, 研究方向为SAR图像处理。
- 李 宁: 男, 1987年生, 教授, 博士生导师, 研究方向为SAR信号与图像处理。
- 张 燕: 女, 1994年生, 硕士生, 研究方向为遥感图像超分辨率重建。

责任编辑: 余 蓉