

基于 UNet 深度学习算法的东海大型漂浮藻类遥感监测

李潇凡¹, 王胜强^{1*}, 翁轩¹, 孙德勇¹, 张海龙¹, 焦红波⁴, 梁涵玮^{2,3}¹南京信息工程大学海洋科学学院, 江苏 南京 210044;²自然资源部海岸带开发与保护重点实验室, 江苏 南京 210024;³南京信息工程大学地理科学学院, 江苏 南京 210044;⁴国家海洋信息中心, 天津 300171

摘要 基于语义分割神经网络 UNet, 利用 GOCI(Geostationary Ocean Color Imager) 卫星传感器数据, 构建出能够有效提取大型漂浮藻类的深度学习模型, 实现了对大型漂浮藻类信息端到端、像素到像素的分割识别。验证结果表明: 所提出的深度学习模型对验证集中大型漂浮藻类的平均识别精度达到 88.54%; 通过与传统的归一化植被指数法和替代型漂浮藻类指数法进行对比, 发现基于 UNet 构建的大型漂浮藻类监测模型具有更高的准确率且受云的影响较小。利用 UNet 大型漂浮藻类提取模型的识别结果对 2017 年东海藻类暴发过程进行了分析, 模型显示出很好的实用性。

关键词 海洋光学; 大型漂浮藻类; 遥感监测; 深度学习; 语义分割; UNet

中图分类号 O436

文献标志码 A

doi: 10.3788/AOS202141.0201002

Remote Sensing of Floating Macroalgae Blooms in the East China Sea Based on UNet Deep Learning Model

Li Xiaofan¹, Wang Shengqiang^{1*}, Weng Xuan¹, Sun Deyong¹,Zhang Hailong¹, Jiao Hongbo⁴, Liang Hanwei^{2,3}¹ School of Marine Sciences, Nanjing University of Information Science & Technology, Nanjing, Jiangsu 210044, China;² Key Laboratory of Coastal Zone Exploitation and Protection, Ministry of Natural Resources, Nanjing, Jiangsu 210024, China;³ School of Geographic Sciences, Nanjing University of Information Science & Technology, Nanjing, Jiangsu 210044, China;⁴ National Marine Data and Information Service, Tianjin 300171, China

Abstract This paper proposed a deep learning model based on a semantic segmentation neural network (UNet) for extracting floating macroalgae blooms effectively from the data of Geostationary Ocean Color Imager (GOCI) satellite sensors, achieving the end-to-end and pixel-to-pixel segmentation and recognition of the information of floating macroalgae blooms. The validation results show that the average recognition accuracy of the deep learning model for floating macroalgae blooms in the validation set can reach 88.54%. Compared with existing methods for detecting floating macroalgae blooms, including normalized difference vegetation index (NDVI) and alternative floating algae index (FAI), the constructed model based on the UNet for monitoring floating macroalgae blooms has high accuracy and is less affected by clouds. Consequently, the recognition results of the UNet based model for floating mac-

收稿日期: 2020-07-20; 修回日期: 2020-08-11; 录用日期: 2020-08-28

基金项目: 国家自然科学基金(41876203, 41506200)、国家对地观测科学数据中心开放基金项目(NODAOP2020009)、自然资源部海岸带开发与保护重点实验室开放基金(2019CZEPK07)、南京市留学人员科技创新项目(R2019LZ05)、江苏省研究生科研创新计划(KYCX20_0959)

* E-mail: shengqiang.wang@nuist.edu.cn

roalgae blooms are successfully applied to analyzing the outbreak process of floating macroalgae blooms in the East China Sea in 2017. The proposed model indicates a good applicability.

Key words oceanic optics; floating macroalgae blooms; remote sensing monitoring; deep learning; semantic segmentation; UNet

OCIS codes 010.0280; 010.4450; 100.2000

1 引言

大型漂浮藻类大规模暴发事件频发,给沿海地区的生态环境、水产养殖和渔业带来了严重损失^[1-4]。影响我国近海的大型漂浮藻类主要为浒苔和马尾藻。其中,浒苔的影响区域主要是黄海海域^[5],而马尾藻暴发则主要发生在东海海域,自 2017 年以来马尾藻的暴发成为了备受关注的新灾害。例如,2017 年江苏省受马尾藻影响的紫菜养殖区面积高达 $2.27 \times 10^8 \text{ m}^2$,大部分养殖区面临产量损失,造成的直接经济损失超过 5 亿元人民币^[6]。因此及时、准确地获取大型漂浮藻类的时空分布信息对保护我国近海海洋生态环境、养殖业经济等有着重要意义。

大型漂浮藻类暴发时漂移路径多变,传统的浮标观测、船舶观测耗时费力,并且很难全面准确地掌握受灾区域的暴发时间、分布范围和漂移路径等信息。相比之下,卫星遥感技术具有大尺度、高时空覆盖率等优势,成为监测大型漂浮藻类分布的主要手段。例如,卫星遥感可以及时、经济地获取大型漂浮藻类的暴发时间、地点、范围和漂移路径等信息,这将有助于对大型漂浮藻类灾害进行预防和治理^[6]。目前用于监测大型漂浮藻类的卫星传感器主要包含搭载在极轨卫星的 MODIS (Moderate-Resolution Imaging Spectroradiometer)、MERIS (Medium Resolution Imaging Spectrometer Instrument)、LandSat、高分传感器等,以及搭载在静止轨道卫星 COMS (Communication, Ocean, and Meteorological Satellite) 上的 GOCI (Geostationary Ocean Color Imager) 传感器。大型漂浮藻类的短时漂移特点,使得利用较低时间分辨率的极轨卫星对大型漂浮藻类进行实时监测较为困难,而 GOCI 传感器每天可提供 8 景观测数据,时间分辨率为 1 h,空间分辨率为 500 m,其高时空分辨率的特点为大型漂浮藻类监测提供了重要的数据保障。

目前国内外研究者主要采用指数阈值法进行大型漂浮藻类监测,指数阈值法主要包括归一化植被指数 (NDVI) 法、增强型植被指数 (EVI) 法、漂浮藻类指数 (FAI) 法、替代型漂浮藻类指数 (AFAI) 法等^[7-15]。NDVI 的值用 N_{DVI} 表示,AFAI 的值用

A_{FAI} 表示。例如, Qi 等^[10] 基于多源卫星传感器数据,利用 AFAI 法对 2017 年大型漂浮藻类的暴发进行了监测。然而,需要指出的是:虽然指数阈值法应用广泛,但其容易受到大气条件和海面环境的影响,进而导致监测结果存在较大的不确定性。

随着深度学习技术的发展,卷积神经网络在目标检测、目标提取、图像分类等领域表现出很大的潜力,其强大的图像特征提取能力为遥感图像提取提供了新的思路,卷积神经网络已逐步应用于遥感相关研究中^[16-17]。UNet 是典型的卷积神经网络模型之一,具有提取准确率高、迁移性好等特点,在遥感监测上有明显优势。

因此,本文基于 GOCI 卫星遥感数据,利用 UNet 深度学习网络构建出能够有效提取大型漂浮藻类信息的深度学习模型,实现对我国近海大型漂浮藻类灾害的遥感监测,进而为大型漂浮藻类灾害的防控治理提供科学技术支持。

2 研究区域与数据

2.1 研究区概述

本文研究区域为大型漂浮藻类常发区域,经纬度范围为: $27^\circ\text{N} \sim 34^\circ\text{N}$, $119^\circ\text{E} \sim 128^\circ\text{E}$,研究区域主要包括东海区域。东海的面积约为 $7.7 \times 10^5 \text{ km}^2$,平均水深为 349 m,最大水深为 2719 m,有着复杂的海底地形,年平均水温为 $20 \sim 24^\circ\text{C}$,水文特征比较稳定。

2.2 GOCI 卫星数据与预处理

本文采用 GOCI 遥感数据,GOCI 是由韩国在 2010 年发射的静止轨道水色卫星 COMS 上所搭载的传感器,可检测 8 个波段,中心波段分别为 412, 443, 490, 555, 660, 680, 745, 865 nm,观测区域范围为: $111^\circ\text{E} \sim 149^\circ\text{E}$, $21^\circ\text{N} \sim 47^\circ\text{N}$ 。GOCI 每天可提供 8 景数据,时间间隔为 1 h^[18]。本文从 GOCI 数据官网 (<http://kosc.kiost.ac.kr/eng/>) 筛选了 10 景 2015—2017 年大型漂浮藻类暴发期间海域少云图像,下载了 L1B (Level-1B) 数据,用 GDPS (GOCI Data Processing System, Version 2.0) 对其进行裁剪和大气校正处理得到 L2C (Level-2C) 数据。L2C 数据包含消除瑞利散射的遥感反射率 (R_{rc}) 数据与

地物掩模信息^[19], 本文使用瑞利校正后的遥感反射率进行相关研究。

3 大型漂浮藻类提取模型及精度评价方法

3.1 UNet 深度学习网络

本研究采用 UNet 深度学习网络对大型漂浮藻类分布进行遥感提取。UNet 深度学习网络是一种语义分割神经网络, 广泛应用于遥感影像的解译^[20-22]。UNet 深度学习网络结构由编码端、解码端及跳跃连接组成, 利用向前卷积、编码端池化下采样、解码端上采样等过程获取图像特征信息。

用于大型漂浮藻类提取的深度学习模型的建立分为 3 个步骤: 1) 数据预处理; 2) 模型训练; 3) 模型

验证。具体流程如图 1 所示。首先, 筛选 2015—2017 年大型漂浮藻类暴发期间 10 景少云的遥感影像数据, 利用 GDPS 对 10 景 GOCI 的 R_{rc} 数据进行裁剪, 并通过 GDPS 中的 Flag Viewer 针对陆地的掩模生成假彩色合成影像。在此基础上, 对图像进行目视解译, 将其标记为大型漂浮藻类、清洁海水、浑浊海水、云和陆地共 5 类。其次, 对每景训练集图像进行随机分割, 将其分割成 4000 个子矩阵以增加样本, 按 6:4 的比例将样本随机分为训练集和验证集, 并在 MATLAB 编译环境下利用训练集数据对 UNet 深度学习网络进行训练学习, 构建出用于提取大型漂浮藻类分布信息的深度学习模型。最后, 利用验证集数据对基于 UNet 的深度学习模型提取的大型漂浮藻类分布信息进行精度验证评价。

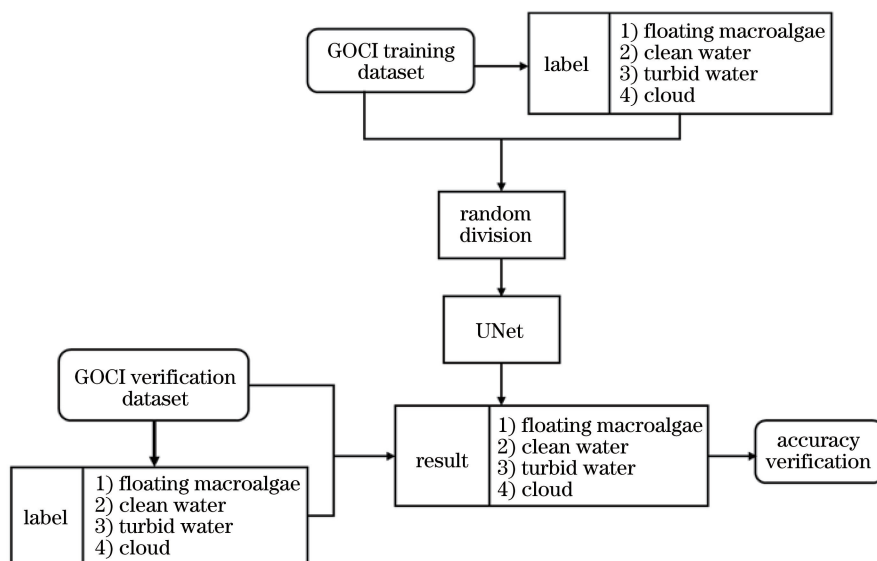


图 1 建立用于提取大型漂浮藻类的深度学习模型的具体流程

Fig. 1 Specific process of establishing deep learning model for floating macroalgae bloom extraction

3.2 NDVI 法与 AFAI 法

本文对比分析了基于 UNet 的深度学习模型、基于 NDVI 法和基于 AFAI 法的大型漂浮藻类提取效果。其中 NDVI 法最初是根据植被在红光波段与近红外波段的不同光谱特征建立植被信息提取指数。由于大型漂浮藻类光谱和植被光谱具有相似性, NDVI 法也常被用于大型漂浮藻类的提取, N_{DVI} 的计算公式为

$$N_{DVI} = \frac{R_{NIR} - R_{RED}}{R_{NIR} + R_{RED}}, \quad (1)$$

式中: R_{NIR} 和 R_{RED} 分别表示近红外波段(860 nm 波段)和红光波段(660 nm 波段)的反射率。

AFAI 法也主要利用了大型漂浮藻类在红光波段的强吸收和近红外波段的高反射特征, A_{FAI} 的计算公式为

$$A_{FAI} = R_{rc, NIR} - [R_{rc, RED} + (R_{rc, LNIR} - R_{rc, RED})(\lambda_{NIR} - \lambda_{RED}) / (\lambda_{LNIR} - \lambda_{NIR})], \quad (2)$$

式中: $R_{rc, RED}$ 、 $R_{rc, NIR}$ 、 $R_{rc, LNIR}$ 分别为红光波段(660 nm 波段)、近红外波段(745 nm 波段)和长波近红外波段(865 nm 波段)的反射率。

3.3 精度评价

本研究主要关注的是提取大型漂浮藻类分布信息的准确度, 在诸多精度评价指标中, F_1 分数能够更加确切地表征单类目标提取的准确度, 因此本文采用 F_1 分数对大型漂浮藻类的提取结果进行精度评价, F_1 分数的计算公式为

$$F_1 = 2 \frac{PR}{P + R}, \quad (3)$$

式中: P 和 R 分别表示精确率和召回率。精确率 P

是指真正例占深度学习网络估测值为正例的比例,可表示为

$$P = N_{TP} / (N_{TP} + N_{FP}), \quad (4)$$

召回率 R 是指真正例占真实值为正例的比例,可表示为

$$R = N_{TP} / (N_{TP} + N_{FN}), \quad (5)$$

式中: N_{TP} 表示真实值为正例且被算法分类为正例的数量; N_{FP} 表示真实值为反例而被算法分类为正例的数量; N_{FN} 表示真实值为正例而被算法分类为反例的数量。 N_{TN} 表示真实值为反例且被算法分类为反例的数量, N_{TP} 、 N_{FP} 、 N_{FN} 、 N_{TN} 构成的混淆矩阵如表 1 所示。

表 1 混淆矩阵

Table 1 Confusion matrix

| Predicted value | True value | |
|-----------------|------------|----------|
| | True | False |
| Positive value | N_{TP} | N_{FP} |
| Negative value | N_{FN} | N_{TN} |

由以上分析可以看出: F_1 分数是精确率和召回率的加权调和平均数。相比其他评价指标, F_1 分数的优势在于它可以惩罚极端情况, 因其赋予精确度和召回率相同的权重, 所以在两者之一为 0 的情况

下 F_1 分数也为 0。 F_1 分数的取值范围为 0~1, 其值越高表明提取精度越高, 反之亦然。

4 结 果

4.1 深度学习模型对大型漂浮藻类分布的提取

通过对 6 景 GOCI 数据共 24000 个随机样本的不断训练, 网络达到了收敛状态, 最后 10 次迭代的平均准确度为 92.43% (每次迭代的准确度取区间最大值), 对于训练样本, 全局提取结果的 F_1 分数为 90.48%。在此基础上, 利用建立的基于 UNet 的深度学习模型对 2017 年 4 月 3 日大型漂浮藻类分布信息进行了提取。结果如图 2 所示: 图 2(a) 为 2017 年 4 月 3 日 GOCI 假彩色合成影像, 图 2(b) 为利用基于 UNet 的深度学习模型提取的大型漂浮藻类的信息。利用目视解译方法并根据大型漂浮藻类的光谱特性及分布特性, 可得: 大型漂浮藻类在假彩色合成图像中呈现为红色的细条带状 [图 2(a)]。如图 2(b) 所示, 基于目视解译图像的提取结果为: 白色像元为厚云, 棕色像元为浑浊水体, 浅蓝色像元为清澈水体, 红色条带状像元为大型漂浮藻类。对比目视解译结果可知: 基于 UNet 的深度学习模型

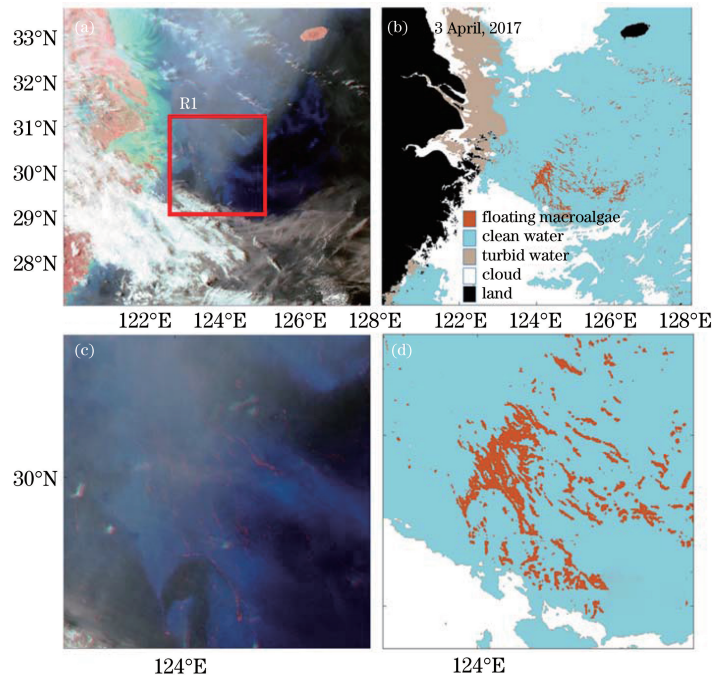


图 2 不同区域的 GOCI 假彩色合成影像和基于 UNet 的深度学习模型对大型漂浮藻类的提取结果。(a)(c)不同区域的 GOCI 假彩色合成影像; (b)(d)基于 UNet 的深度学习模型对大型漂浮藻类的提取结果

Fig. 2 GOCI pseudo-color synthetic images for different regions, and extracted results of floating macroalgae blooms using UNet based deep learning model. (a)(c) GOCI pseudo-color synthetic images for different regions; (b)(d) extracted results of floating macroalgae blooms using UNet based deep learning model

能够很好地利用图像的光谱、形状等特征信息,有效提取出厚云、清澈水体、浑浊水体和大型漂浮藻类信息,且提取结果与目视解译结果大体一致,能够清楚地反映出大型漂浮藻类在东海的总体空间分布特征。而对于大型漂浮藻类密集分布区 R1[图 2(a)中方框所示区域],通过对比基于 UNet 的深度学习模型[图 2(d)]与大型漂浮藻类实际分布[图 2(c)]可以看出,基于 UNet 的深度学习模型能够很好地提取出大型漂浮藻类分布的轮廓。

4.2 深度学习模型和其他指数法的对比

分别采用基于 UNet 的深度学习模型、NDVI 法和 AFAI 法,并利用 2015 年 4 月 22 日的 GOCI

影像对大型漂浮藻类分布信息进行了提取。图 3 展示了 GOCI 假彩色合成影像与 3 种大型漂浮藻类信息提取算法的提取结果。可以看出:利用基于 UNet 的深度学习模型提取的大型漂浮藻类整体分布情况[图 3(b)]与大型漂浮藻类的实际分布[图 3(a)]保持高度一致,能够很好地表现出大型漂浮藻类的区域分布特征和覆盖面积。而 NDVI 法[图 3(c)]的准确度较低,存在较明显的误判情况。AFAI 法[图 3(d)]能较好地表现出大型漂浮藻类的分布情况,提取得到的大型漂浮藻类轮廓特征与大型漂浮藻类实际分布比较相近,但对大型漂浮藻类覆盖面积存在一定程度的低估(表 2)。

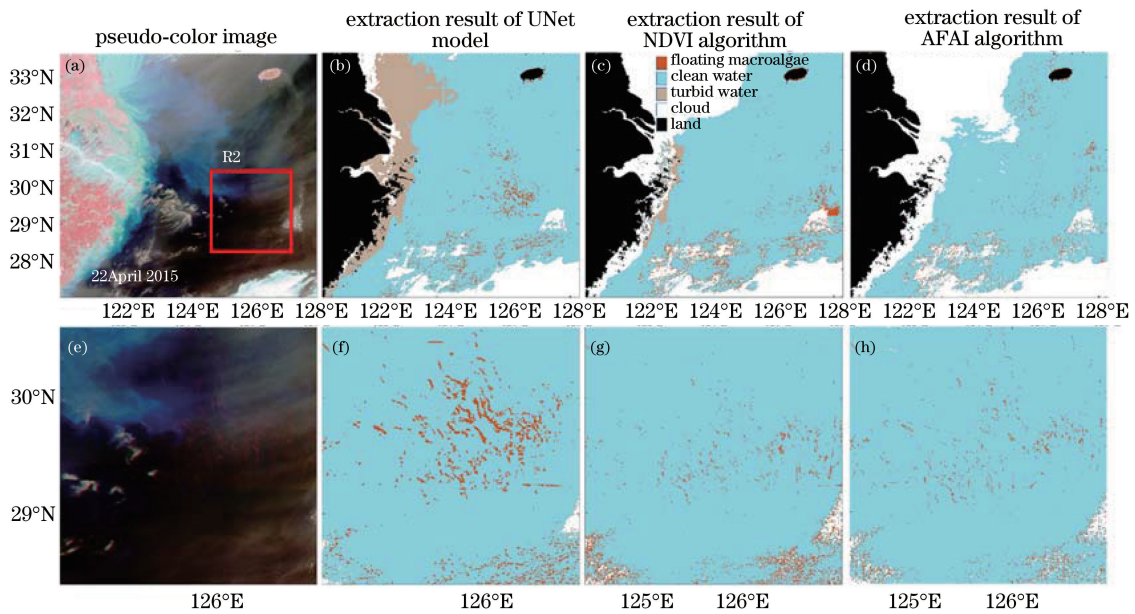


图 3 不同区域的 GOCI 假彩色合成影像以及采用基于 UNet 的深度学习模型、NDVI 法和 AFAI 法得到的大型漂浮藻类分布图。(a)(e)不同区域的 GOCI 假彩色合成影像;(b)(f)采用基于 UNet 的深度学习模型得到的大型漂浮藻类分布;(c)(g)采用 NDVI 法得到的大型漂浮藻类分布;(d)(h)采用 AFAI 法得到的大型漂浮藻类分布

Fig. 3 GOCI pseudo-color synthetic images for different regions, and distributions of floating macroalgae blooms obtained by UNet based deep learning model, NDVI method, and AFAI method. (a)(e) GOCI pseudo-color synthetic images for different regions; (b)(f) distributions of floating macroalgae blooms obtained by UNet based deep learning model; (c)(g) distributions of floating macroalgae blooms obtained by NDVI method; (d)(h) distributions of floating macroalgae blooms obtained by AFAI method

表 2 采用基于 UNet 的深度学习模型、NDVI 法、AFAI 法得到的大型漂浮藻类分布结果

Table 2 Distribution results of floating macroalgae blooms obtained by UNet based deep learning model, NDVI method, and AFAI method

| Method | Pixel number of floating macroalgae blooms | A_{sar}/km^2 | Pixel number of floating macroalgae blooms in R1 | A_{sar} in R1 / km^2 | $F_1/\%$ |
|--------------------------------|--|-----------------------|--|---------------------------------|----------|
| UNet based deep learning model | 19898 | 4974.50 | 5460 | 1365.00 | 86.09 |
| NDVI | 16526 | 4131.50 | 5224 | 1306.00 | 79.38 |
| AFAI | 15463 | 3865.75 | 4901 | 1225.25 | 79.78 |

Note: A_{sar} represents distribution area of floating macroalgae blooms.

对于大型漂浮藻类密集分布区 R2[图 3(a) 中方框所示区域], 基于 UNet 的深度学习模型能够很好地提取出大型漂浮藻类分布轮廓, 其提取结果[图 3(f)]与大型漂浮藻类实际分布[图 3(e)]依然存在很好的对应关系。相比之下, NDVI 法[图 3(g)]和 AFAI 法[图 3(h)]虽然能够描绘出大型漂浮藻类分布规律, 但对大型漂浮藻类覆盖面积存在一定的低估。

表 2 展示了基于 UNet 的深度学习模型、NDVI 法、AFAI 法提取的大型漂浮藻类的像元个数与 F_1 分数。利用基于 UNet 的深度学习模型得到的大型漂浮藻类像元个数为 19898, 总面积为 4974.50 km^2 , F_1 分数为 86.09%, 而利用 NDVI 法和 AFAI 法得到的大型漂浮藻类像元个数分别为 16526 和 15463, F_1 分数分别为 79.38% 和 79.78%。由表 2 可以看出: 采用基于 UNet 的深度学习模型得到的大型漂浮藻类的 F_1 分数(86.09%)明显比 NDVI 法(79.38%)、AFAI 法(79.78%)高, 这说明基于 UNet 的深度学习模型对大型漂浮藻类的提取准确度更高, 具有更高的可信度; 此外, 基于 UN-

et 的深度学习模型提取的像元数更多, 而 NDVI 法与 AFAI 法提取的像元个数相对较少, 这表明基于 UNet 的深度学习模型提取的大型漂浮藻类分布面积(A_{sar})更加接近大型漂浮藻类实际分布面积, 而 NDVI 法和 AFAI 法确实存在低估现象。

4.3 深度学习模型在特殊情况下对大型漂浮藻类的提取结果

基于 2015 年 3 月 24 日的 GOCI 影像, 分别采用基于 UNet 的深度学习模型、NDVI 法和 AFAI 法对大型漂浮藻类分布信息进行了提取, 提取结果如图 4 所示。图 4(a) 展示了一景复杂环境下的假彩色合成影像, 图中大范围区域受云的影响; 图 4(b) 为基于 UNet 的深度学习模型在这种复杂环境下的提取结果, 可以看出在薄云情况下, 基于 UNet 的深度学习模型仍取得不错的效果, 几乎不受云的影响。而 NDVI 法[图 4(c)]和 AFAI 法[图 4(d)]均在不同程度上受到了云的影响, 具体表现为: NDVI 法[图 4(c)]存在大面积的误判情况, AFAI 法[图 4(d)]同样存在误判情况, 但较 NDVI 法的误判程度低。

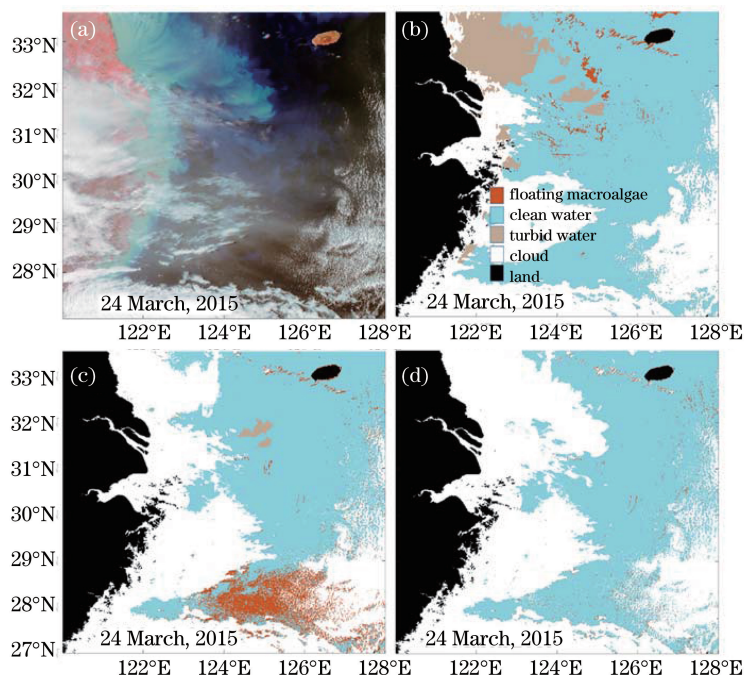


图 4 2015 年 3 月 24 日 GOCI 假彩色合成影像, 以及采用基于 UNet 的深度学习模型、NDVI 法和 AFAI 法得到的大型漂浮藻类分布。(a) 2015 年 3 月 24 日 GOCI 假彩色合成影像; (b) 采用基于 UNet 的深度学习模型得到的大型漂浮藻类分布; (c) 采用 NDVI 法得到的大型漂浮藻类分布; (d) 采用 AFAI 法得到的大型漂浮藻类分布

Fig. 4 GOCI pseudo-color synthetic image on 24 March, 2015 and distributions of floating macroalgae blooms obtained by UNet based deep learning model, NDVI method, and AFAI method. (a) GOCI pseudo-color synthetic image on 24 March, 2015; (b) distribution of floating macroalgae blooms obtained by UNet based deep learning model; (c) distribution of floating macroalgae blooms obtained by NDVI method; (d) distribution of floating macroalgae blooms obtained by AFAI method

4.4 2017 年大型漂浮藻类暴发过程分析

利用基于 UNet 的深度学习模型,对 2017 年大型漂浮藻类的暴发过程进行了分析,结果如图 5 所示。由图 5(a)可以看出,利用基于 UNet 的深度学习模型在 2017 年 4 月 3 日浙江外海以东海域监测到了大型漂浮藻类暴发初期现象,经统计可得,大型漂浮藻类覆盖面积约为 6962.25 km^2 。经过一段时间的发展,大型漂浮藻类向北转移,且覆盖面积有所增加,约为 9567.5 km^2 [2017 年 4 月 19 日,

图 5(b)]。随着时间的推移,大型漂浮藻类继续向北转移,转移过程中得到了充分且迅速的生长,暴发规模进一步增大,覆盖面积高达 16410 km^2 ,且出现了明显的聚集现象[2017 年 5 月 18 日,图 5(c)]。2017 年 5 月 28 日,大型漂浮藻类逐渐消散,影响范围明显大幅度减小,覆盖面积为 1917 km^2 。大型漂浮藻类暴发过程可能与海洋温度异常升高、良好的光照利用率以及海藻养殖业带来的营养富集等因素有关^[9,23-24],对于其具体的暴发机制还需进行进一步的深入研究。

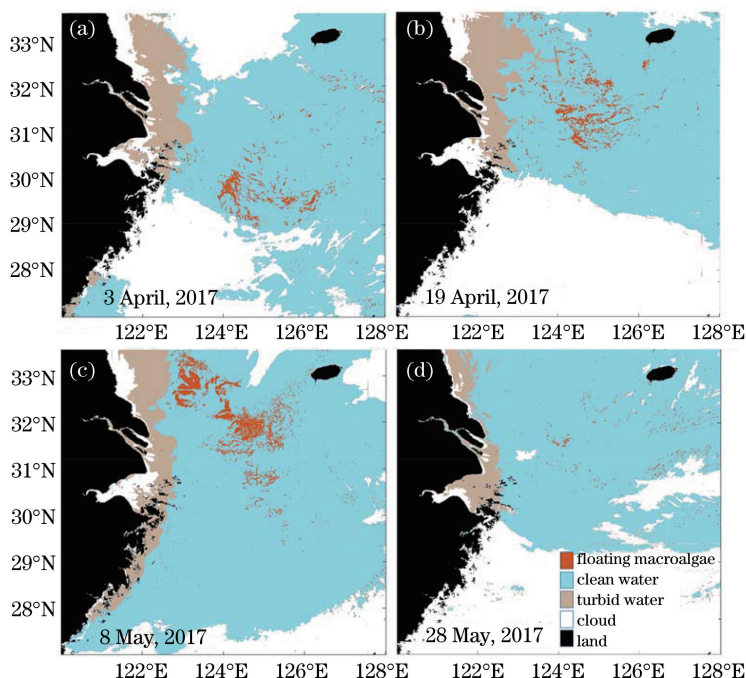


图 5 利用基于 UNet 的深度学习模型提取的中国近海大型漂浮藻类分布情况。(a) 2017 年 4 月 3 日;
(b) 2017 年 4 月 19 日;(c) 2017 年 5 月 18 日;(d) 2017 年 5 月 28 日

Fig. 5 Distributions of floating macroalgae blooms near the East China Sea obtained by UNet based deep learning model.

(a) 3 April, 2017; (b) 19 April, 2017; (c) 18 May, 2017; (d) 28 May, 2017

5 结 论

基于 GOCI 卫星传感器数据资料并利用 UNet 深度学习网络构建出了能够有效提取中国近海海域大型漂浮藻类的深度学习模型。该模型可在比较复杂的大气海洋环境中实现对大型漂浮藻类、清洁海水、浑浊海水和云的分布信息的自动提取,提取大型漂浮藻类时得到的 F_1 分数平均可达 88.54%。相比于常用的 NDVI 法、AFAI 法,所提出的深度学习模型具有更高的大型漂浮藻类提取准确度,并且受云的影响较小;利用所提出的深度学习模型的提取结果,对 2017 年大型漂浮藻类暴发过程进行了分析,分析结果表明所提出的深度学习模型具有很好的实用性。这些结果为大型漂浮藻类灾害的科学监

测防控提供了重要的技术支撑。然而,所提出的深度学习模型可能存在小部分错检或漏检情况,这可能与网络训练数据量不够大、训练不完全有关。今后的研究中将进一步通过增加不同情况下的训练样本来提高对大型漂浮藻类的监测精度。此外,基于高空间分辨率卫星数据的 UNet 深度学习识别模型有待进一步的研究。

尽管对 2017 年东海大型漂浮藻类暴发过程进行了分析,但是在大型漂浮藻类暴发初期,其斑块往往很小,仅有 500 m 空间分辨率的 GOCI 传感器很难对其进行有效监测。对于早期大型漂浮藻类爆发现象的探测,需要依靠更高空间分辨率的卫星遥感数据(如 Landsat、高分等)^[6]。需要指出的是,所提出的基于 UNet 的深度学习模型在基于高空间分辨

率的卫星遥感数据的大型漂浮藻类的探测方面具有很大的应用潜力,这将是后续研究的方向之一。另外,本文研究区为东海,虽然东海海域的大型漂浮藻类主要为马尾藻,但有些情况下也有可能是浒苔,甚至会有马尾藻和浒苔的混生现象,如何客观准确地确认所探测的大型漂浮藻类是马尾藻还是浒苔,还需要根据浒苔和马尾藻的具体光谱特征差异^[25]提出相应的区分模型,这些都是下一步的研究方向。

参 考 文 献

- [1] Yang H, Li Z B, Li Y Y, et al. Species identification and nutritional composition analysis of *enteromorpha* in Xiamen coastal waters[J]. China Fishery Quality and Standards, 2013, 3(4): 70-75.
杨欢, 黎中宝, 李元跃, 等. 厦门海域浒苔种类鉴定及其营养成分分析[J]. 中国渔业质量与标准, 2013, 3(4): 70-75.
- [2] Zhao S F, Liu L S, Sun H Q, et al. Morphological and microstructural characteristics of *enteromorpha* algae from Zhanjiang sea area[J]. Journal of Guangdong Ocean University, 2013, 33(6): 1-8.
赵素芬, 刘丽丝, 孙会强, 等. 湛江海域浒苔属 *Enteromorpha* 种类的形态与显微结构[J]. 广东海洋大学学报, 2013, 33(6): 1-8.
- [3] Wang H, Wang H W. Investigation and study on *enteromorpha* in Liaoning Province[J]. Journal of Anhui Agricultural Sciences, 2009, 37(6): 2676-2678, 2710.
王晗, 王宏伟. 辽宁沿海浒苔属的调查研究[J]. 安徽农业科学, 2009, 37(6): 2676-2678, 2710.
- [4] Xing Q G, Hu C M. Mapping macroalgal blooms in the Yellow Sea and East China Sea using HJ-1 and Landsat data: application of a virtual baseline reflectance height technique[J]. Remote Sensing of Environment, 2016, 178: 113-126.
- [5] Cui T W, Zhang J, Sun L, et al. Satellite monitoring of massive green macroalgae bloom (GMB): imaging ability comparison of multi-source data and drifting velocity estimation[J]. International Journal of Remote Sensing, 2012, 33(17): 5513-5527.
- [6] Xing Q G, Guo R H, Wu L L, et al. High-resolution satellite observations of a new hazard of golden tides caused by floating *sargassum* in winter in the Yellow Sea[J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(10): 1815-1819.
- [7] Hu C M, He M X. Origin and offshore extent of floating algae in Olympic sailing area [J]. Eos, Transactions American Geophysical Union, 2008, 89(33): 302-303.
- [8] Huete A, Justice C, van Leeuwen W. MODIS vegetation index (MOD13) [EB/OL]. [2020-07-20]. <https://www.mendeley.com/catalogue/edc791aa-0330-381b-8400-6a70c358af12/>.
- [9] Hu C M. A novel ocean color index to detect floating algae in the global oceans[J]. Remote Sensing of Environment, 2009, 113(10): 2118-2129.
- [10] Qi L, Hu C M, Wang M Q, et al. Floating algae blooms in the East China sea [J]. Geophysical Research Letters, 2017, 44(22): 11501-11509.
- [11] Yu J, Huang H H, Shu L M, et al. *Sargassum* extraction using remote sensing technology[J]. Remote Sensing Information, 2013, 28(2): 93-100, 105.
于杰, 黄洪辉, 舒黎明, 等. 马尾藻遥感信息提取[J]. 遥感信息, 2013, 28(2): 93-100, 105.
- [12] Gower J, Hu C M, Borstad G, et al. Ocean color satellites show extensive lines of floating *sargassum* in the gulf of Mexico[J]. IEEE Transactions on Geoscience and Remote Sensing, 2006, 44(12): 3619-3625.
- [13] Gower J F R, King S A. Distribution of floating *sargassum* in the Gulf of Mexico and the Atlantic Ocean mapped using MERIS [J]. International Journal of Remote Sensing, 2011, 32(7): 1917-1929.
- [14] Zhang H L, Sun D Y, Li J S, et al. Remote sensing algorithm for detecting green tide in China coastal waters based on GF1-WFV and HJ-CCD data [J]. Acta Optica Sinica, 2016, 36(6): 0601004.
张海龙, 孙德勇, 李俊生, 等. 基于 GF1-WFV 和 HJ-CCD 数据的我国近海绿潮遥感监测算法研究[J]. 光学学报, 2016, 36(6): 0601004.
- [15] Chen Y, Sun D Y, Zhang H L, et al. Remote-sensing monitoring of green tide and its drifting trajectories in Yellow Sea based on observation data of geostationary ocean color imager[J]. Acta Optica Sinica, 2020, 40(3): 0301001.
陈莹, 孙德勇, 张海龙, 等. 结合 GOCI 数据的黄海绿潮遥感监测及漂移轨迹研究[J]. 光学学报, 2020, 40(3): 0301001.
- [16] Su J M, Yang L X, Jing W P. U-net based semantic segmentation method for high resolution remote sensing image [J]. Computer Engineering and Applications, 2019, 55(7): 207-213.
苏健民, 杨岚心, 景维鹏. 基于 U-Net 的高分辨率遥感图像语义分割方法[J]. 计算机工程与应用, 2019, 55(7): 207-213.
- [17] Wu G M, Chen Q, Ryosuke S, et al. High precision building detection from aerial imagery using a U-net like convolutional architecture[J]. Acta Geodaetica et Cartographica Sinica, 2018, 47(6): 864-872.
伍广明, 陈奇, Ryosuke Shibasaki, 等. 基于 U 型卷

- 积神经网络的航空影像建筑物检测[J]. 测绘学报, 2018, 47(6): 864-872.
- [18] Ryu J H, Han H J, Cho S, et al. Overview of geostationary ocean color imager (GOCI) and GOCI data processing system (GDPS)[J]. Ocean Science Journal, 2012, 47(3): 223-233.
- [19] Ahn J H, Park Y J, Ryu J H, et al. Development of atmospheric correction algorithm for Geostationary Ocean Color Imager (GOCI)[J]. Ocean Science Journal, 2012, 47(3): 247-259.
- [20] Ghosh A, Ehrlich M, Shah S, et al. Stacked U-nets for ground material segmentation in remote sensing imagery[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), June 18-22, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 18347270.
- [21] Xia W, Zhang Y Z, Liu J, et al. Road extraction from high resolution image with deep convolution network: a case study of GF-2 image[J]. Proceedings, 2018, 2(7): 325.
- [22] Iglovikov V, Shvets A. TernaNet: U-Net with VGG11 encoder pre-trained on ImageNet for image segmentation[EB/OL]. (2018-02-17)[2020-07-20]. <https://arxiv.org/abs/1801.05746>.
- [23] Ding M J, Qiu Z F, Zhang H L, et al. Inversion algorithm for turbidity of bohai and Yellow Seas based on NPP-VIIRS satellite data[J]. Acta Optica Sinica, 2019, 39(6): 0601002.
丁梦娇, 丘仲锋, 张海龙, 等. 基于 NPP-VIIRS 卫星数据的渤海黄海水体反演算法研究[J]. 光学学报, 2019, 39(6): 0601002.
- [24] Su X P, Sun D Y, Wang S Q, et al. Remote sensing to estimate sea-surface density of yellow and bohai seas off the east Coast of China[J]. Laser & Optoelectronics Progress, 2019, 56(11): 110101.
苏校平, 孙德勇, 王胜强, 等. 黄渤海海表密度的遥感反演[J]. 激光与光电子学进展, 2019, 56(11): 110101.
- [25] An D Y, Xing Q G, Wei Z N, et al. Spectral features and analysis of typical floating macroalgae in the Yellow Sea [J]. Oceanologia et Limnologia Sinica, 2018, 49(5): 1054-1060.
安德玉, 邢前国, 魏振宁, 等. 黄海典型漂浮大型藻类光谱特征分析[J]. 海洋与湖沼, 2018, 49(5): 1054-1060.