

文章编号: 1672-6987(2022)04-0120-07; DOI: 10.16351/j.1672-6987.2022.04.016

# 基于深度卷积神经网络的海洋多目标涡旋检测方法

刘启明<sup>1</sup>, 杨树国<sup>1</sup>, 赵莉<sup>2\*</sup>

(1.青岛科技大学 数理学院, 山东 青岛 266061; 2.青岛市中医医院(市海慈医院), 山东 青岛 266033)

**摘要:** 提出了一种基于深度卷积神经网络的海洋多目标涡旋检测方法。首先利用改进的密集卷积精确提取海洋涡旋特征, 并使用跨层融合技术提高特征的利用率, 来充分捕捉边缘信息; 然后结合转置卷积和跳过连接构建上采样路径得到检测结果, 以获得更高的检测准确率; 最后在 CMEMS(哥白尼海洋环境监测服务中心)发布的公开数据集上对本工作提出的方法进行对比实验, 实验结果表明: 与 EddyNet、PET 等方法相比, 本工作的方法能够有效分离、检测出距离较近的涡旋, 具有更好的检测结果。

**关键词:** 海洋涡旋; 深度学习; 特征融合; 目标检测

**中图分类号:** S 513

**文献标志码:** A

**引用格式:** 刘启明, 杨树国, 赵莉. 基于深度卷积神经网络的海洋多目标涡旋检测方法[J]. 青岛科技大学学报(自然科学版), 2022, 43(4): 120-126.

LIU Qiming, YANG Shuguo, ZHAO Li. Ocean multi-eddy detection method based on deep convolution neural network[J]. Journal of Qingdao University of Science and Technology (Natural Science Edition), 2022, 43(4): 120-126.

## Ocean Multi-Eddy Detection Method Based on Deep Convolution Neural Network

LIU Qiming<sup>1</sup>, YANG Shuguo<sup>1</sup>, ZHAO Li<sup>2</sup>

(1.College of Mathematics and Physics, Qingdao University of Science and Technology, Qingdao 266061, China;

2.Qingdao Hospital of Traditional Chinese Medicine (Qingdao Hiser Hospital), Qingdao 266033, China)

**Abstract:** This paper proposes a deep convolutional neural network-based ocean multi-eddy detection method. Firstly, we use an improved dense convolution to accurately extract ocean eddy features, and use a cross-layer fusion technique to improve feature utilization, aiming to capture edge information fully. Secondly, we construct an upsampling path combining transposed convolutions and skip connections for higher detection accuracy. Finally, we compare the proposed method with other methods on a public dataset published by Copernicus Marine Environmental Monitoring Services (CMEMS). The experimental results show that compared with EddyNet and PET, this method can more effectively separate and detect eddy currents in close range, so this method has better detection effect.

**Key words:** ocean eddy; deep learning; feature fusion; object detection

收稿日期: 2021-08-26

基金项目: 国家自然科学基金山东省联合基金项目(U1906215).

作者简介: 刘启明(1997—), 男, 硕士研究生. \*通信联系人.

涡旋是世界海洋中普遍存在的一种中尺度海洋现象,是指尺度小于罗斯贝波的海水旋转运动的总称,其中半径为第一斜压罗斯贝半径量级(即10~100 km)的涡旋被称为中尺度涡旋;而半径小于第一斜压罗斯贝半径且大于边界层湍流尺度的涡旋被称为次中尺度涡旋(即0.1~10 km)。按照旋转方向可分为气旋涡和反气旋涡,北(南)半球气旋涡中,海水呈逆(顺)时针旋转。无论南北半球,由于地球自转诱导的科氏力,气旋涡(反气旋涡)的中心伴随着辐散(辐聚),所以产生上升流(下沉流)<sup>[1]</sup>。因此,这些涡旋一方面将海洋深层的冷水和营养盐输送到海洋上层,另一方面也会将海洋表面的暖水输送到海洋深层,通过对水体的混合和运输改变海洋的温盐场结构,进而对海洋动力过程、生态系统变迁及全球气候变化产生重要的影响<sup>[2]</sup>。因此,对于海洋涡旋检测的研究具有重要的科学意义和实际应用价值。

上世纪以来,国内外众多海洋学者对海洋涡旋的检测问题进行了大量研究,取得了一系列研究进展,提出了诸多检测算法。目前,传统的检测算法主要有基于物理特征、流场几何特征、手工标注特征及混合算法等方法。其中,基于物理特征的 Okubo-Weiss(OW)参数法<sup>[3-4]</sup>深受学者青睐,多应用于地中海海域、秘鲁海域<sup>[5-6]</sup>,它可以较好地提取涡旋特征,但参数的选取过分依赖于专家经验,并且直接影响检测的精度,因此该方法的检测准确度较低。基于流场几何特征的 Winding Angle(WA)缠绕角方法<sup>[7]</sup>,通过计算并筛选流场瞬时闭合曲线的方式对涡旋进行识别,但由于涡旋在形成及消亡过程中往往不具备流场闭合曲线的特征,因此该方法的漏检率较高;类似地, NENCIOLI也提出了一种纯粹基于几何特征的方法(vector geometry, VG)方法<sup>[8]</sup>;这些基于流场几何特征检测方法都存在共同的缺点,即需要对数据进行逐点检测,再利用流场几何特征进行判断,为了保证涡旋识别的准确率往往致使计算量过大、效率过低。基于手工标注特征的方法一般涉及到的特征比较低级,无法表现出涡旋的高动态性。另外也有一些学者将上述的传统算法加以融合而发展出混合算法,例如 YI等提出的基于海表面异常高度和物理特征(OW)参数法的涡旋检测方法<sup>[9]</sup>、MCWILLIAMS提出的将流场几何特征和相对涡度结合起来的海洋涡旋检测方法<sup>[10]</sup>。虽然混合算法具有其融合的各个子算法的优点,但是对历史数据的质量要求较高,

并强烈依赖于专家经验,因此检测涡旋的效率依旧较低。

近年来,随着深度学习的蓬勃发展,人工智能技术在各领域得到高效应用,学者们开始将传统的方法与深度学习进行结合,取得了卓越成就<sup>[11]</sup>。例如深度学习通过创建多层神经网络,对训练样本进行拟合,已经被广泛应用于语音、图像的识别和检测等方面<sup>[12-13]</sup>。同时,伴随着超分辨率遥感卫星技术的快速发展,越来越多的高时空分辨率的海洋表面高度遥感图像数据可以供研究人员使用,已有学者针对海洋涡旋检测的特点,把海洋表面高度数据视为二维图像,结合机器学习和深度学习的方法对海洋涡旋进行检测识别。如 ASHKEZARI等<sup>[14]</sup>通过构建涡旋相位角特征矩阵,利用支持向量机(SVM)进行分类训练,再通过使用滑动窗格进行涡旋检测。LGUENSAT等<sup>[15]</sup>在经典的语义分割框架中,利用编码器-解码器网络(U-Net)对气旋和反气旋进行了识别,但没有对语义信息和特征进行充分的利用,缺乏对检测到的涡旋大小等特征进行定量分析。

本工作基于深度学习方法,结合先进的语义分割理论,提出了一个海洋多目标涡旋检测的深度模型,该模型能够有效提取并利用涡旋的语义信息和特征,充分捕捉边缘信息,有效地实现多目标涡旋检测,最后,将本文提出的方法与传统方法进行了对比实验,实验结果表明,本工作的方法性能更优。

## 1 数据

大量高质量数据是深度学习模型成功训练的重要基础,尽管有学者已经创建了海洋涡旋数据集,但是其中的大多数没有公开发布,相关研究人员无法直接使用,在一定程度上限制了该领域的发展。因此,本研究工作使用哥白尼海洋环境监测服务中心(CMEMS)最新发布的海表面高度卫星遥感数据产品,该产品由 Data Unification and Altimeter Combination System(DUACS)多任务融合高度计数据处理系统处理发布,将 Jason-3、Sentinel-3A、HY-2A等运行中的卫星探测的海表面高度(sea surface height, SSH)数据加以集成,再使用最优插值方法计算获得,来自多卫星高度计的融合数据具有很高的时间和空间分辨率,可以为海洋涡旋检测任务提供近实时的卫星遥感数据。

本研究海域为热带西北太平洋海域( $0^{\circ}\sim 32^{\circ}\text{N}$ 、 $109^{\circ}\text{E}\sim 141^{\circ}\text{E}$ ),包括中国南海及其东部海域(如图1所示)。本研究使用了从2000年1月1日至2021年

3月5日的7 735张每日海表面高度图像。




图 1 本文研究海域

Fig.1 Sea area studied in this paper

本工作所设计的深度学习算法除了需要给定海表面高度图像外,还需要给定对应的标签图像,然而数据集没有直接给出,因此本工作采用经典的涡旋检测(Py-eddy-tracker, PET)算法<sup>[16]</sup>来创建标签图像数据,该数据与海表面高度图像共同构成本工作

的数据集:其中训练集由前 20 年的数据构成,共包含 7 306 张海洋表面高度图像及标签图像;测试集包含 2020 年 1 月 1 日至 2021 年 3 月 5 日的 429 张海洋表面高度图像及标签图像。图像的空间分辨率为 $0.25^{\circ} \times 0.25^{\circ}$ ,大小为 128 像素 $\times$ 128 像素,每张图像均为单通道图像。在形成数据集时,为了减少异常数据对结果的影响,对标签图像数据进行了预处理:对于陆地及岛屿区域,将其对应的像素值替换为类别像素值 0,对于气旋区域,将其标准像素值替换为类别像素值 1,对于反气旋区域,将其标准像素值替换为类别像素值 2。由于海洋涡旋是缓慢动态移动的,单个涡旋可以存活几周至几个月<sup>[17-18]</sup>,因此不需要进行数据增强(如向训练集中添加裁剪、旋转后的数据图像)。

## 2 基于深度卷积神经网络的多目标海洋涡旋检测模型

为了更好地提取多个涡旋的特征,以及更高效地融合不同尺度的特征,从而获得更好的涡旋检测效果,本工作基于深度学习方法建立了一个基于深度卷积神经网络的多目标海洋涡旋检测模型。模型的具体结构如图 2 所示。




图 2 多目标海洋涡旋检测模型网络结构

Fig.2 Structure of multi-objective ocean eddies detection model

该模型由编码和解码两个部分组成<sup>[19]</sup>,其中编码部分主要进行涡旋特征的提取及融合,包含改进后的密集卷积块,以及跨层融合到下采样操作的整个过程;解码部分使用转置卷积进行上采样操作,直到最终检测出涡旋。

### 2.1 编码部分

本工作所提出的海洋涡旋检测模型的编码部分,是基于改进的密集卷积模块的特征提取器。提取输入的海表面高度图像的涡旋特征后,再通过跨层融合将全部特征融合起来。通过以上操作,不仅

能提取到丰富的涡旋特征,还能将不同层次的语义特征和边界细节特征融合起来,捕获到图像更多的全局和局部信息。

具体地,将海表面高度图像输入后,首先进行涡旋特征提取,主要通过基于卷积操作的密集模块完成,具体操作如图 3 所示。

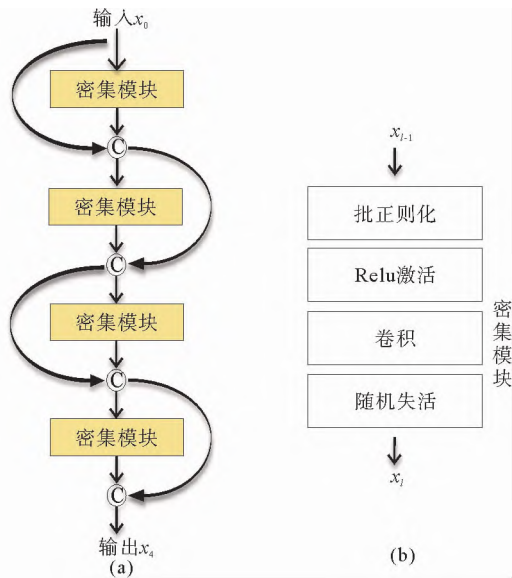


图 3 密集模块简图

Fig.3 Sketch of the dense module

每个密集模块包含如图 3(b)所示的四个层,用来提取输入图像的特征,其原理如下:

$$x_l = H(x_{l-1}). \quad (1)$$

其中,  $H$  为批正则化、激活、卷积、随机失活等非线性操作,  $x_l$  为第  $l$  层的输出特征图。从输入图像开始,通过第  $l$  层密集模块的操作  $H(\cdot)$  生成含有  $k$  层的输出特征图  $x_l$ 。

密集模块的非线性操作  $H$  中,最重要的是卷积操作,其原理如下:

$$y(i) = \sum_t x(i+t) \cdot \omega(t). \quad (2)$$

其中,  $y(i)$  为输出特征图第  $i$  个像素点位置的特征值,  $\omega(t)$  为卷积核,  $t$  为卷积核的长度,  $x(\cdot)$  为输入特征图相应区域的特征值。

利用上述过程,对输入图像进行特征提取并生成特征图,之后引入跨层融合来减少卷积过程中的信息丢失,如图 3(a)所示。

在下采样中,对密集模块的输入特征图  $x_{l-1}$  和输出特征图  $x_l$  进行级联操作,级联后再进行最大池化操作,使得每个区域内的最大特征得以保留,参数

减少,其原理为:

$$h_j = \max_{(m,n) \in N_j} \alpha_{mn}. \quad (3)$$

其中,  $\alpha_{mn}$  为特征图上的特征值,  $N_j$  为池化操作的滑动窗口,  $h_j$  为经过最大池化操作后的特征值。

经过最大池化操作后,特征图的大小会发生变化,长和宽都会相应减少,而通道数不会发生变化。池化后的特征图大小变化如下:

$$\begin{aligned} W_{out} &= (W_{in} - K) / S + 1, \\ H_{out} &= (H_{in} - K) / S + 1, \\ C_{out} &= C_{in}, \end{aligned} \quad (4)$$

其中,  $W_{in}$ ,  $W_{out}$  分别表示特征图宽度的输入值和输出值;  $H_{in}$ ,  $H_{out}$  分别表示特征图高度的输入和输出值;  $C_{in}$ ,  $C_{out}$  分别表示通道数的输入值和输出值;  $S$  为步长,  $K$  为卷积核的大小。

经过上述特征提取、特征融合及下采样操作,得到的特征图中含有丰富的语义信息,特别是在特征融合过程中,每一层都将之前所有层的输入进行融合,再传递给之后的所有层,这样的跨层融合结构具有众多的优势,尤其是提高了特征的重用,每一层都可以得到前面各层的特征信息,参数的重用率更高,各层的有效特征全部进行了融合,可以充分利用涡旋的细节特征以及空间特征。

本工作输入 SSH 图像大小为  $128 \times 128$ ,采用  $2 \times 2$  最大池化,选取  $k = 12$ ,输入图像经过特征提取、特征图融合及下采样操作后,模型的编码工作全部完成,得到了充分提取、高度融合的海洋涡旋特征图,为解码工作提供了丰富的特征信息,有助于获得更加精准的涡旋检测结果。

## 2.2 解码部分

当全部特征提取及融合完成后,解码部分负责将融合后的特征图还原到输入分辨率大小,逐步还原后经交叉熵损失 SoftMax 分类,得出海洋涡旋检测的具体结果。首先进行特征图尺寸的恢复,也就是将编码部分得到的特征图经解码操作变成输入图像原始尺寸大小。然后进行编码解码操作,编码部分通过构建下采样路径来获得特征图,解码部分则是一个相反的过程,通过构建一个上采样路径来使提取到的特征图逐步恢复空间分辨率,主要由上采样操作(转置卷积或反卷积操作)和跳过连接组成。下采样和上采样的主要操作如图 4 所示。

当编码部分完成特征提取后,上采样操作开始工作,并且和对应的跳过连接进行通道上的融合,以此增强特征图的空间分辨率,形成新的输入。由于下采样过程中的池化操作会在一定程度上损失有效

特征信息,引入跳过连接则能保留原来大量的信息,可改善特征提取到上采样操作过程中的信息丢失,这对于海洋涡旋检测任务来说十分必要。

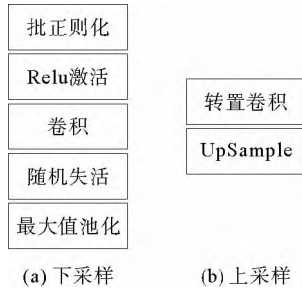


图 4 下采样和上采样过程

Fig.4 Downsampling and upsampling process

特征图还原完成后,最后一步就是使用 SoftMax 分类得到海洋气旋(类别 1)、反气旋(类别 2)和背景(类别 0)3 类的概率,即每个类别的最终结果。

本工作所用的训练样本为  $\{(x^{(i)}, y^{(i)})\}, i=1, \dots, n$ , 类标签为  $y^{(i)} \in \{0, 1, 2\}$ , 使用 SoftMax 函数计算样本属于每个类别的概率:

$$p(y_i = k | x_i, w) = \frac{\exp(w_k^T x_i)}{\sum_{j=1}^k \exp(w_j^T x_i)}, k=0, 1, 2. \quad (5)$$

定义代价函数:

$$J(y, \tilde{y}) = -\frac{1}{n} \sum_{i=1}^n \sum_{j=1}^k \sigma(y^{(i)}) \lg \tilde{y}_j^{(i)}. \quad (6)$$

其中,  $\tilde{y} = p(y | x, w)$ ,  $w_j \in \mathbf{R}^{m+1}$ , 示性函数  $\sigma(\cdot) = \begin{cases} 1, & y = i, \\ 0, & y \neq i. \end{cases}$

通过梯度下降法求得损失函数极小化后的权重系数  $w$ , 最大概率  $\tilde{y}$  对应的类别即  $x$  的分类类别, 即得到每个像素所对应的涡旋类别。

解码部分以编码部分的输出特征图  $x_{16}$  作为输入, 经过上述 3 次上采样操作及通道融合后, 特征图大小变为输入海表面高度图像大小  $128 \times 128$ , 再经过 SoftMax 分类后, 输出海洋涡旋检测的结果, 即得到分割图像。至此, 解码工作全部完成, 也获得整个海洋涡旋检测结果。

### 3 模型训练设置

#### 3.1 模型损失函数与优化

深度学习多分类任务通常采用交叉熵函数作为损失函数进行训练, 针对海洋涡旋检测任务的正负样本不均衡的特点, 本工作使用改进的加权骰子系

数作为损失函数, 加速网络的训练。

骰子系数通常用来度量两个样本之间的相似度, 一般定义为

$$Dice = \frac{2|X \cap Y|}{|X| + |Y|}. \quad (7)$$

其中,  $X$  表示标签区域,  $Y$  表示预测区域,  $|X \cap Y|$  表示二者区域内元素之和的交集,  $|X|$ ,  $|Y|$  表示每个区域元素之和。Dice 系数的计算公式相当于计算真实值和预测值的交并比, 一般用于评判分割的效果, 取值在  $0 \sim 1$  之间, 越接近 1 证明拟合的越好。它将一个类别的所有像素作为一个整体, 构造 Dice 系数差异函数, 即损失函数:

$$DiceLoss = 1 - \frac{2|X \cap Y|}{|X| + |Y|}. \quad (8)$$

Dice Loss 直接将分割效果的评估指标作为损失函数来监督网络, 计算系数时, 还忽略了大量的背景因素, 有效地提高了收敛速度。

本工作在此基础上进行了改进, 由于本工作共有 3 个类别: 气旋、反气旋和背景, 因此首先对 3 个类别分别计算骰子系数, 然后进行加权平均, 作为总体的 Dice 系数, 最后计算得到加权损失函数:

$$DiceLoss = 1 - (w_1 \times Dice_1 + w_2 \times Dice_2 + w_3 \times Dice_3). \quad (9)$$

其中,  $Dice_i (i=1, 2, 3)$  分别表示气旋、反气旋和背景的系数,  $w_i (i=1, 2, 3)$  则分别表示三者对应的权重。

#### 3.2 模型超参数设置

在本工作采用的数据集中, 训练集包括的训练样本有 7 306 张图片, 验证集包括的验证样本有 471 张图片。由于数据样本量充足并且排除参数设置的影响, 本文模型以及其他对比模型的参数设置完全相同, 采用 Adam 优化器, 训练批次 epoch 设置为 50, 学习率设置为 0.001, 训练的批数 batch size 设置为 6。为了避免过拟合现象的产生, 采用了归一化层和神经元保留比例为 80% 的 Dropout 层。模型的整个训练过程需要 7 h 左右, 同样实验条件下, 本工作模型训练集的精度达到 94%, 比 EddyNet 算法精度提高了 4 个百分点, 在验证阶段相对于其他模型也表现出更好的性能。

### 4 实验结果

为了检验本工作提出方法的涡旋检测效果, 在上述数据集上, 对不同的方法 EddyNet、PET 和本工作的方法进行了对比性实验, 检测结果如图 5 所示(图中红绿色块分别代表反气旋涡和气旋涡):




图 5 不同检测方法结果对比

Fig.5 Comparison of the results of different testing methods

从图 5 可以看出,本工作方法的结果与 PET 方法更为相似,因为本工作的模型是由其结果训练的,但是与 EddyNet 方法相比,本工作的方法检测到了更多的涡旋,尤其是对于边缘区域小而模糊的涡旋,也能精确地捕捉到这些信息和特征。

由于受专家经验及筛选条件严格的限制,传统方法的漏检率较高,而人工智能的方法由于能够检测到更小的涡旋,因此比传统方法检测到的涡旋数量更多。图 6 为 2020 年 1 月 1 日至 2021 年 3 月 5 日南海及其附近海域这两种方法检测到的海洋涡旋

数量比较。在此期间,EddyNet 算法共检测到 49 752 个海洋涡旋,本算法共检测到 68 726 个海洋涡旋,并且本算法检测到的气旋和反气旋的数量均比 EddyNet 算法检测到的多(见表 1),两个结果之间的单日最大差为 64。

表 1 不同方法检测到的海洋涡旋数量统计

Table 1 Statistics on the number of ocean eddies detected by different methods

参数	PET	EddyNet	本研究
气旋数量	23 713	25 468	35 326
反气旋数量	19 403	24 284	33 400
总数量	43 116	49 752	68 726

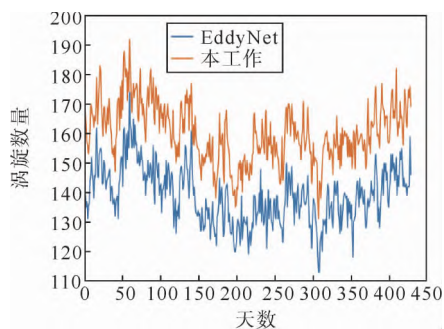


图 6 两种方法检测出的 2020 年 1 月 1 日至 2021 年 3 月 5 日的海洋涡旋数量对比

Fig.6 Comparison of the number of ocean eddies detections by the two methods during Jan 1<sup>st</sup>, 2020 and Mar 5<sup>th</sup>, 2021

本方法加强了对特征的重用,提高了特征的利用效率,因而能够获取涡旋的更多细节特征,尤其是对于检测区域边缘特征的利用更加高效,因此能够准确区分开相隔较近的两个涡旋,如图 7 所示,Eddy-Net 算法和本方法在对气旋检测结果的对比中,本方法检测效果更加接近真实情况,如图 7(c)地转流图所示,尤其是对于相隔较近的两个涡旋的检测,本方法能够更好地将其分离和检测出来。衡量海洋涡旋检测性能的另一指标就是半径大小,因此本工作对比了所检测海域的涡旋半径大小,如表 2 所示,这是两

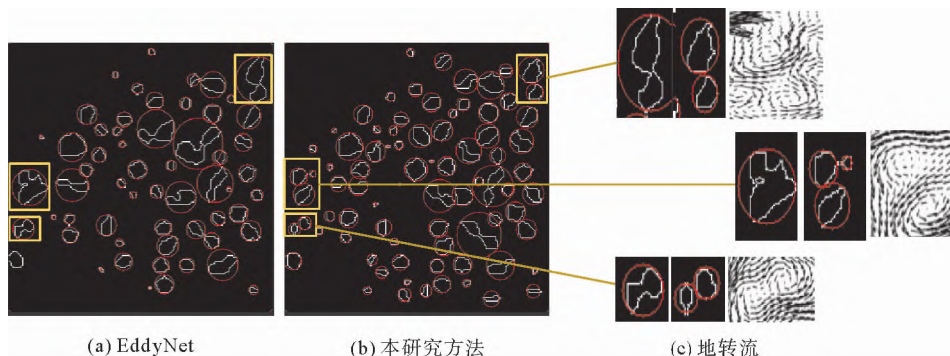


图 7 不同检测方法结果对比

Fig.7 Comparison of the results of different testing methods

种方法对涡旋半径进行了 5 次计算并求得平均值的结果,本工作所提出的方法检测到的涡旋平均半径和最大半径都更大,而最小半径更小,这同样也验证了本工作方法具备检测到更小涡旋的能力。

表 2 不同方法检测到的海洋涡旋半径统计

Table 2 Statistics on the radius of ocean eddies detected by different methods

参数	EddyNet	本研究
平均半径/km	76.79	84.82
最大半径/km	457.17	461.55
最小半径/km	9.81	8.67

## 5 结 语

本工作所提出的海洋多目标涡旋检测算法能够捕捉到多涡旋的丰富细节特征,融合了深层次的语义信息,适合海洋多涡旋检测任务。同时,本工作利用 2000 年至 2020 年的海表面高度图像数据和 PET 算法提取的涡旋信息标签作为训练数据,2020 年 1 月 1 日至 2021 年 3 月 5 日的 429 张海表面高度图像作为测试数据,对本方法与传统算法 PET 以及 EddyNet 算法进行了比较,结果表明,本算法能够检测到更多的海洋涡旋,特别是对于小尺度边缘涡旋的捕捉,效果更优。因此,本工作所提出的方法更适合海洋多目标涡旋检测。

## 参 考 文 献

- [1] 董昌明.海洋涡旋探测与分析[M].北京:科学出版社:2015:61-65.  
DONG Changming. Oceanic Eddy Detection and Analysis[M]. Beijing: Science Press: 2015: 61-65.
- [2] 崔凤娟.南海中尺度涡的识别及统计特征分析[D].青岛:中国海洋大学, 2015.  
CUI Fengjuan. Identification and Statistical Characterization of Mesoscale Eddies in the South China Sea[D]. Qingdao: Ocean University of China, 2015.
- [3] OKUBO A. Horizontal dispersion of floatable particles in the vicinity of velocity singularities such as convergences[J]. Deep Sea Research and Oceanographic Abstracts, 1970, 17(3): 445-454.
- [4] WESIS J. The dynamics of enstrophy transfer in two-dimensional hydrodynamics[J]. Physica D: Nonlinear Phenomena, 1991, 48(2/3): 273-294.
- [5] ISERN-FONTANET J, GARCIA-LADONA E, FONT J. Identification of marine eddies from altimetric maps[J]. J. Atmos. Oceanic Technol., 2003, 20(5): 772-778.
- [6] PENVEN P, ECHEVIN V, PASAPERA J, et al. Average circulation, seasonal cycle, and mesoscale dynamics of the Peru Current System: A modeling approach[J]. Journal of Geophysical Research Oceans, 2005, 110: C10021.
- [7] SADARJOEN I A, POST F H. Detection, quantification, and tracking of vortices using streamline geometry[J]. Computers & Graphics, 2000, 24(3): 333-341.
- [8] NENCIOLI F, DONG C, DICKEY T, et al. A vector geometry-based eddy detection algorithm and its application to a high-resolution numerical model product and high-frequency radar surface velocities in the southern California bight[J]. Journal of atmospheric and oceanic technology, 2010, 27(3): 564-579.
- [9] YI J, DU Y, HE Z, et al. Enhancing the accuracy of automatic eddy detection and the capability of recognizing the multi-core structures from maps of sea level anomaly[J]. Ocean Science, 2014, 10(1): 39-48.
- [10] MCWILLIAMS J C. The vortices of two-dimensional turbulence[J]. Journal of Fluid Mechanics, 1990, 219(-1): 361-385.
- [11] MONTI F, BOSCAINI D, MASCI J, et al. Geometric deep learning on graphs and manifolds using mixture model CNNs [C]// IEEE Conference on Computer Vision and Pattern Recognition, 2017: 5425-5434.
- [12] DAI J, LI Y, HE K, et al. R-FCN: Object detection via region-based fully convolutional networks[J]. Proceeding of the 30th International Conference on Neural Information Processing Systems, 2016: 379-387.
- [13] CHEN J, LEI B, SONG Q, et al. A hierarchical graph network for 3D object detection on point clouds [C]// Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2020: 392-401.
- [14] MD ASHKEZARI, HILL C N, FOLLETT C N, et al. Oceanic eddy detection and lifetime forecast using machine learning methods[J]. Geophysical Research Letters, 2016; 43 (23): 12234-12241.
- [15] LGUENSAT R, SUN M, FABLET R, et al. EddyNet: A deep neural network for pixel-wise classification of oceanic eddies[J]. IGARSS, 2018, 5(3): 1764-1767.
- [16] MASON E, PASCUAL A, MCWILLIAMS J C. A new sea surface height-based code for oceanic mesoscale eddy tracking [J]. Journal of Atmospheric and Oceanic Technology, 2014, 31(5): 1181-1188.
- [17] CHELTON D B, SCHLAX M G, SAMELSON R M. Global observations of nonlinear mesoscale eddies[J]. Progress in Oceanography, 2011, 91(2): 167-216.
- [18] 孙博雯. 中尺度涡旋三维结构与经向热输送研究[D]. 青岛: 中国科学院大学(中国科学院海洋研究所), 2019.  
SUN Bowen. Research on Three-Dimensional Structure and Meridional Heat Transport of Mesoscale Eddies[D]. Qingdao: University of Chinese Academy of Sciences(Institute of Oceanology, Chinese Academy of Sciences), 2019.
- [19] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation [C]// Springer International Publishing, Medical Image Computing and Computer-Assisted Intervention, 2015: 234-241.

(责任编辑 姜丰辉)