

DOI:10.16356/j.1005-2615.2020.05.005

基于深度卷积网络的海洋涡旋检测模型

张 盟, 杨玉婷, 孙 鑫, 董军宇, 梁 瑶

(中国海洋大学信息科学与工程学院, 青岛, 266100)

摘要:传统的利用遥感数据检测涡旋的方法通常是基于物理参数、几何特征、手工特征或专家知识。本文重点研究了基于深度学习技术从海表面高度图中识别海洋涡旋的方法。针对海洋卫星拍摄的海洋表面高度图中的涡旋检测问题,提出了一种基于卷积神经网络的多涡旋检测模型,该模型能够准确提取涡旋的特征信息,拟合语义信息与海面高度之间的关系。同时,在用于涡旋检测的最新公开数据集 SCSE-Eddy 上进行模型训练,以评估基于人工智能的涡旋检测方法性能,该数据集涵盖了 15 年来位于中国南海及其东部部分海域的每日卫星遥感海表面高度数据。实验结果表明,与现有的方法相比,本文模型取得了更好的检测结果,能够更好地区分相距较近的涡旋。

关键词:卫星遥感;涡旋检测;深度学习;海表面高度图像

中图分类号: TP3; TP7; P7 **文献标志码:** A **文章编号:** 1005-2615(2020)05-0708-06

Ocean Eddy Detection Model Based on Deep Convolution Neural Network

ZHANG Meng, YANG Yuting, SUN Xin, DONG Junyu, LIANG Yao

(Institute of Information Science and Engineering, Ocean University of China, Qingdao, 266100, China)

Abstract: The automatic detection of mesoscale ocean eddies is extremely essential to monitor their dynamic changes. Therefore, effective detection of ocean eddies is vital to improve understanding of ocean dynamics. The traditional methods of detecting eddies using remote sensing data are usually based on physical parameters, geometric features, manual features or expert knowledge. In recent years, the deep learning technology has been improved by many experts. In this paper, the deep learning method is used to detect the ocean eddies from the sea surface height (SSH) data. Firstly, a multi-eddy detection model based on deep convolution neural network is proposed aiming to resolve eddy detection challenge on SSH data photoed by satellite. The model can accurately extract the feature information of eddies and fit the relationship between semantic information and sea level anomaly. Secondly, a new dataset, i.e., SCSE-Eddy, is used to train the proposed model and evaluate the performance of eddy detection method based on artificial intelligence (AI). This dataset is composed of the daily satellite remote sensing SSH data covering the South China Sea and its eastern sea area over the past 15 years. Experimental results show that, compared with the existing methods, the model proposed in this paper achieves the best performance and distinguishes close eddies well.

Key words: satellite remote sensing; eddy detection; deep learning; sea surface height images

海水运动属于经典流体力学的范畴。首先,海水的运动在地球自转的旋转坐标系中;其次,海洋是分层流体。现场观测和卫星遥感图像均表明,海洋旋转分层流体中存在大量的旋涡。全球海洋的

基金项目: 国家自然科学基金(61971388, U1706218, 41576011, L1824025)资助项目;山东省重点研究开发计划(GG201703140154)资助项目。

收稿日期: 2020-06-07; **修订日期:** 2020-07-20

通信作者: 孙鑫,男,副教授, E-mail: sunxin@ouc.edu.cn。

引用格式: 张盟,杨玉婷,孙鑫,等. 基于深度卷积网络的海洋涡旋检测模型[J]. 南京航空航天大学学报, 2020, 52(5): 708-713. ZHANG Meng, YANG Yuting, SUN Xin, et al. Ocean eddy detection model based on deep convolution neural network[J]. Journal of Nanjing University of Aeronautics & Astronautics, 2020, 52(5): 708-713.

环流在地球的大洋流中容易产生特征性的涡旋,特别是中尺度的海洋涡旋。事实上,海洋涡旋具有不同模式的旋转相干结构,其直径从几百米到几千米不等。中尺度涡旋的半径在10~100 km之间,对营养盐和浮游植物的分布、能量和盐的输送以及海洋生产具有重要的作用。

遥感技术在1960年被提出,可以定义为“以摄影方式或非摄影方式获得被探测目标的影像或数据的技术”。近年来,卫星遥感技术得到了快速发展,研究人员能够获取更多的高清晰度和高质量的遥感图像,随之而来的热点问题是对于这些遥感图像的处理和分析。然而,涡旋检测仍然是具有挑战性的问题,特别是对于存在多个涡旋的大型海洋区域。传统算法主要基于经验物理参数、阈值和科学计算(如小波分解^[1]和卷绕角^[2])。比较经典的涡旋检测算法^[3-5]对叶绿素分布、速度场变形和空间变异性等因素比较敏感。此外,专家的专业知识对于提供进行涡旋检测的物理参数的经验阈值必不可少。而人工智能技术(特别是深度学习模型)越来越多地应用于遥感领域^[6-7],被认为是在海洋应用领域取得突破性创新的潜在候选技术。

国内外专业人士已经提出了诸多检测海洋物理过程的算法,例如海洋涡旋^[8]和海洋锋^[6,9-10]。传统算法可具体分为4类:基于几何的^[5,11]、基于物理参数的^[12-13]、基于手工标注特征的^[14-15]以及混合方法^[16-17]。基于几何的方法的不足是如果没有清晰的几何特征,就无法从数据中检测出涡旋细节。基于物理参数的方法需要针对特定的兴趣区域设置一组合适的阈值,因此它们是特定于任务的,并且泛化能力有限。基于手工标注特征的方法通常设计低级特征,这些特征无法表示海洋涡旋的高动态性。尽管混合方法具有上述方法的优点,但仍然需要专家知识和无噪声历史数据才能正确执行检测。

Lguensat等^[8]提出了一种用于特征提取的U-net编码器-解码器结构,然而它不能充分利用语义信息和特征来区分边缘。Franz等^[18]使用编码器-解码器和传统算法^[19]来检测涡旋。将多尺度特征融合应用于合成孔径雷达(Synthetic aperture radar, SAR)图像的海洋涡旋检测。巧合的是,Xu等^[20]使用PSPNet^[21]来融合不同层中的多尺度特征。尽管在最后一个特征图的编码中包含了丰富的语义信息,但由于网络模型中的跨行操作的汇集,使得涡旋边界细节信息丢失严重。

现有基于深度学习的涡旋检测模型忽略了其空间分辨率的恢复,其主要原因是大多数的深层神经网络结构都是为了适应自然图像的纹理特征提取而设计的。因此,为利用卫星遥感海面高度图像

进行涡旋检测提供一种针对性的深度学习模型至关重要。事实上,涡旋的空间分辨率在最初卫星拍摄的时候已经确定,可以清晰地显示涡旋大小及位置,而空间信息恢复性差的卷积神经网络模型进行自动检测时会破坏掉其原始的空间分辨率,就会导致涡旋在采样海域图片上的定位变得不准确,可视化效果变得很差。

深度学习模型的成功训练依赖高质量数据集。EddyNet方法训练时使用的数据集是由一种经典涡旋检测(Py-eddy-tracker, PET)算法^[22]采样1998年至2011年海面高度(Sea surface height, SSH)图像所创建,该遥感数据采集自Copernicus Marine Environment Monitoring Service(CMEMS)。Franz等使用围绕澳大利亚和南赤道洋流的高分辨率海面异常(Sea level anomaly, SLA)图,这是欧洲航空局气候变化倡议(ESA climate change initiative, ESACCI)的预处理数据。数据集涵盖1993年1月至2014年12月的每日数据,空间分辨率为0.25°。然而,数据集依赖于传统的基于参数的算法,即Okubo-Weiss^[23-24]方法,它容易受到数据噪声的影响,并且过于主观,阈值的定义异常困难。Xu等也采用了CMEMS公布的数据,生成训练数据时使用的算法是VG算法^[5],此算法性能逊色于PET^[22]。目前,大多数适合训练深度学习模型的数据集并不公开,导致研究人员在尝试将人工智能技术应用于海洋遥感领域时困难重重。

本文所使用的数据集SCSE-Eddy源自CMEMS最新发布的卫星遥感数据,用来评估基于人工智能的涡旋检测方法的性能和有效性,其训练深度学习模型的标签由PET方法生成并由海洋学家针对不准确的地方进行订正。本文基于深度学习技术,提出了一个适用于多涡旋检测的特定深度模型。该模型能够提取涡旋的深层特征、融合空间信息、拟合语义信息与海面高度之间的关系。本文在SCSE-Eddy数据集上进行了和其他方法的对比实验,实验结果表明本文提出的模型达到了更先进的性能。

1 数据及关键技术原理

1.1 海洋涡旋数据集

为了满足对深度模型训练的需求,本文采用了一个全新并且公开的多涡旋检测数据集——SCSE-Eddy。它覆盖了整个中国南海及其东部海域,如图1所示。整个区域的经度是从105.5°E到150°E,纬度是从4°N到30°N,黄色代表陆地或岛屿。

根据CMEMS发布的最新SSH数据,SCSE-Eddy包含了从2003年9月23日到2018年9月23




图1 数据集采样海域

Fig.1 Sampled sea area of dataset

日共15年的数据,生成了以天为单位的5480张带有多目标标签的涡旋检测海高图像。

在建立训练和验证参考数据时采用了经典并且非常有效的PET方法来得出训练所需的涡旋图像数据。SCSE-Eddy数据集分为训练集和验证集。训练集由前13年的数据(即4750张海表面高度图像)构成,而验证集使用的是2017—2018两年的数据(即730张海表面高度图像)。每一条数据都表示为一个单通道图像,空间分辨率为 0.25° ,大小为 $302\text{像素}\times 184\text{像素}$ 。

1.2 关键技术原理

对包含目标特征的特征图进行下采样时,主要是通过卷积操作,其原理为

$$y(i) = \sum_k x(i+k)w(k) \quad (1)$$

式中: i 对应输出特征图 y 上的位置; $w(k)$ 为卷积核; k 为长度; x 为输入特征图。

待检测目标的特征图进行充分提取之后,需要




图2 多涡旋检测模型网络结构

Fig.2 Structure of multi-eddy detection model

2.1 编码模块

海洋多涡旋检测模型的编码模块是一个基于卷积网络的特征提取器,该提取器提取输入SSH图像的主要特征,包括改进的稠密块结构和下采样操作。稠密块结构可以看作是ResNets^[25]的拓展,它对之前的特征图进行迭代求和。具体地,首先将输入的特征图和经过第1次卷积操作之后的特征图进行级联;随后将级联之后的结果与第2次卷积操作的结果进行第2次级联;最后1次级联操作是针对前面两次的级联结果。稠密块结构中使用的卷积核大小是 3×3 ,激活函数是ReLU,该结构的

对特征图进行尺寸的恢复,尺寸恢复的大小就是原本图片输入的大小。在进行恢复的过程中,最主要的方式就是使用上采样。式(2)用于计算当前位置 (x,y) 上采样后的特征值。其中, $f(A_{11}), f(A_{21}), f(A_{12})$ 和 $f(A_{22})$ 是位置 (x,y) 四周最邻近给定的特征,其中, $A_{ij}=(x_i,y_j), i,j\in\{1,2\}$, r 为上采样率因子。上采样到原图的大小再送入模型中的分割层,保证空间信息的完整性。

$$f(x,y) \approx r^* \left(\frac{f(A_{11})}{(x_2-x_1)(y_2-y_1)} (x_2-x)(y_2-y) + \frac{f(A_{21})}{(x_2-x_1)(y_2-y_1)} (x-x_1)(y_2-y) + \frac{f(A_{12})}{(x_2-x_1)(y_2-y_1)} (x_2-x)(y-y_1) + \frac{f(A_{22})}{(x_2-x_1)(y_2-y_1)} (x-x_1)(y-y_1) \right) \quad (2)$$

2 多涡旋检测模型

本文提出了一种新的多涡旋检测模型,该模型能够很好地检测出两种不同类型的涡旋(气旋涡和反气旋涡),在恢复涡旋图像空间分辨率上体现出了巨大优势。图2给出了模型具体结构,该模型由两部分组成:编码模块和解码模块。编码模块包括从图像输入进行卷积操作开始,到下采样结束的全过程,通过卷积汇聚丰富的涡旋特征语义信息;解码模块包括从上采样操作开始,到检测出涡旋的全过程,可以对海洋涡旋进行准确的空间分辨率恢复。

使用可以带来4个方面的优势:(1)融合更多的空间信息,捕捉涡旋细节;(2)隐式的深度监督,此优势得益于块中的路径较短;(3)特征重用,所有卷积层都可以轻松获取其前面的卷积层信息,从而很容易重用先前计算的特征图中的特征;(4)参数的使用效率更高。图3给出了本文所使用的稠密块的具体结构,为了更好地拟合多涡旋检测模型的功能,本文将级联的结果在最后输出时再次级联,而不是只级联每个卷积层的输出。这也是本文对稠密块进行改进的地方,保证浅层特征图的空间信息可以充分融合到经过卷积操作处理会损失部分空

间信息的特征图中,加强对先前特征图的重用,使深层特征图和浅层特征图共同发挥各自的优势,保证接下来精准恢复涡旋细节与空间分辨率。

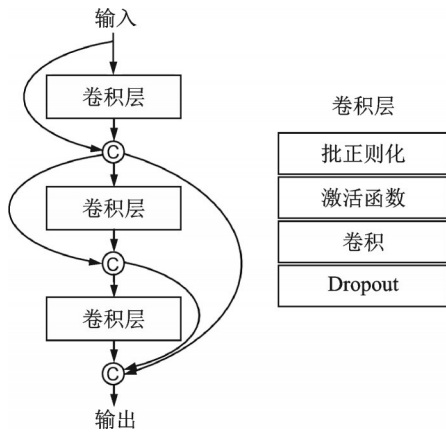


图 3 稠密块简图

Fig.3 Diagram of dense block

2.2 解码模块

解码模块的设计用来得出海洋涡旋的检测结果,并保持精确的空间信息。编码模块进行特征提取之后,将上采样层(原理如 1.2 节所述)添加到标准 CNNs 中以恢复输出层输入的空间分辨率,因此可以处理任意大小的输入特征。下采样和上采样的具体操作如图 4 所示。为了弥补由池化层引起的分辨率损失,本文在模型的下采样和上采样路径




图 4 下采样和上采样

Fig.4 Downsampling and upsampling

之间引入了跳跃连接。

跳跃连接有助于上采样操作从下采样卷积层中恢复细粒度信息。卷积之后的特征图有 3 个维度:宽、高和通道,此处的级联和跳跃连接均是在通道维度进行,保持原本存储在宽和高维度中的深层和浅层信息。

3 实验结果与分析

3.1 实验条件及参数设计

在本文采用的数据集 SCSE-Eddy 中,训练集包括的训练样本有 4 750 张图片,验证集包括的验证样本有 730 张图片。由于数据样本量充足并且排除参数设置的影响,本文模型以及对比模型的参数设置完全相同,训练批次 epoch 设置为 300,并且将学习率设置为 0.001。在模型训练阶段,本文在 NVIDIA RTX2080Ti 显卡上进行训练,训练的 batch_size 为 4。深度模型在训练过程中,难免会出现模型过拟合的状态,为了避免这一现象的产生,本文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 13 h 左右,在训练和验证阶段相对于其他模型都表现出最好的性能。

3.2 实验结果

为了验证本文提出模型的有效性,本文分别与 PET 方法^[22]、EddyNet 方法^[8]以及基于 PSPNet 方法^[20]进行了多次实验对比,图 5(a)是 4 种方法检测的相同海域的海表面高度图,图 5(b—e)分别对应 4 种方法,图 5(f)是海域中的部分地转流图。可以看到 EddyNet 检测到的涡旋要比 PET 方法多,但是由于其网络结构太简单,涡旋检测的数量不如 PSPNet 和本文的方法。基于 PSPNet 的方法可以识别出很多数量的涡旋,因为 PSPNet 可以充分利

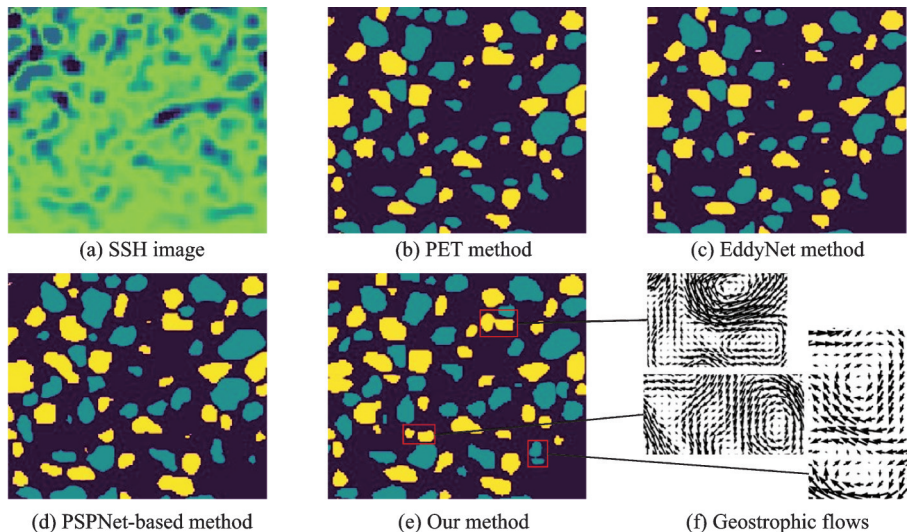


图 5 4 种方法结果对比

Fig.5 Comparison of detection results using four methods

用更多的上下文信息来捕获涡旋细节。本文方法的优点是可以精确恢复涡旋图像的空间分辨率,也就是可以捕捉到更细节的涡旋信息,特别是对于半径较小的和相距较近的涡旋(包括其位置和轮廓)。从图5(f)地转流图上也可以看出,当涡旋距离比较近时,其他方法很难区分。本文的方法进行了准确的空间信息恢复之后,在高空间分辨率的可视化结果中可以看出该海域存在多个涡旋。

Chelton等^[1]证明海洋中存在大量的涡旋,传统检测算法容易受到噪声影响而产生漏检现象。本文统计了4种不同的方法在5次检测实验中分别检测到两种不同类型的涡旋数量的平均值,如表1所示。

表1 涡旋检测数量对比

Table 1 Comparison of detection number of eddies

方法	气旋涡数域	反气旋涡数域	总数
PET	4 473	3 737	8 210
EddyNet	4 502	3 794	8 296
PSPNet	4 614	3 906	8 520
本文	4 648	3 925	8 573
数据集	4 645	3 931	8 576

人工智能的方法可以比传统的算法检测到数量更多的涡旋^[20],主要原因是这些方法具有检测半径较小的涡旋的能力。具体来说,由于EddyNet的网络结构比较简单,其检测涡旋的能力不如PSPNet,数量上气旋涡和反气旋涡的总数相差了将近300,本文的方法进一步恢复高空间分辨率来分离相距较近的涡旋。

半径是涡旋的一个重要物理性质,由涡旋半径可以得知涡旋覆盖的海域面积以及涡旋轮廓,因此可以作为衡量检测结果的一种非常有价值的标准。由于本文的方法可以恢复更高的空间分辨率,所以对涡旋半径检测也更准确。表2是4种方法对涡旋半径进行5次检测求平均的结果,并与数据集中的数据进行对比。

表2 涡旋检测半径对比

Table 2 Comparison of detection radius of eddie km

方法	PIT	EddyNet	PSPNet	本文	数据集
平均	84.75	87.29	90.63	92.61	92.74
最大半径	298.38	298.81	297.57	299.04	300.07

4 结 论

本文提出了一种可以在卫星遥感海表面高度图上进行多涡旋自动检测的模型,该模型基于深度学习中的卷积神经网络,采用编码和解码框架以及改进稠密块的结构来融合丰富的空间信息,实现对

遥感图像的精确空间分辨率恢复。为了满足人工智能领域和遥感领域相结合的需求,本文采用了一个完全公开的由CMEMS发布的最新数据构成的数据集SCSE-Eddy,用来评估涡旋自动检测模型的性能,该数据集可以公开供任何研究人员使用。同时将本文提出的模型和现阶段最好的涡旋检测模型进行比较,实验结果表明,4种方法中本文的方法取得了最好的涡旋检测效果。

参考文献:

- [1] TURIEL A, ISERN-FONTANET J, GARCÍA-LADONA E. Wavelet filtering to extract coherent vortices from altimetric data[J]. *Journal of Atmospheric & Oceanic Technology*, 2007, 24(12): 2103-2119.
- [2] KE Q, JIANG T, MA S. A tabu search method for geometric primitive extraction[J]. *Pattern Recognition Letters*, 1997, 18(14): 1443-1451.
- [3] GAUBE P, MCGILLICUDDY D J, CHELTON D B, et al. Regional variations in the influence of meso-scale eddies on near-surface chlorophyll[J]. *Journal of Geophysical Research Oceans*, 2015, 119(12): 8195-8220.
- [4] MITHAL V, KHANDELWAL A, NAYAK G, et al. A spatio-temporal data mining approach to global scale burned area monitoring[C]//*Proceedings of AGU Fall Meeting Abstracts*. USA: American Geophysical Union, 2014.
- [5] 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 & Oceanic Technology*, 2010, 27(3): 564-579.
- [6] YANG Y, DONG J, SUN X, et al. Ocean front detection from instant remote sensing SST images[J]. *IEEE Geoscience and Remote Sensing Letters*, 2016, 99: 1-5.
- [7] ZHANG L, DU B. Deep learning for remote sensing data: A technical tutorial on the state of the art[J]. *IEEE Geoscience & Remote Sensing Magazine*, 2016, 4(2): 22-40.
- [8] 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.
- [9] LIMA E, XIN S, YANG Y, et al. Application of deep convolutional neural networks for ocean front recognition[J]. *Journal of Applied Remote Sensing*, 2017, 11(4): 1.
- [10] SUN X, WANG C. A multiscale deep framework for

- ocean fronts detection and fine-grained location[J]. IEEE Geoscience & Remote Sensing Letters, 2019, 2(1): 1-5.
- [11] CHELTON D B, SCHLAX M G, SAMELSON R M. Global observations of nonlinear mesoscale eddies[J]. Journal of Physical Oceanography, 2011, 91(2): 167-216.
- [12] ALPERS W, BRANDT P, LAZAR A, et al. A small-scale oceanic eddy off the coast of West Africa studied by multi-sensor satellite and surface drifter data[J]. Remote Sensing of Environment, 2013, 129: 132-143.
- [13] FAGHMOUS J H, CHAMBER Y, BORIAH S, et al. A novel and scalable spatio-temporal technique for ocean eddy monitoring[C]//Proceeding of Twenty-Sixth AAAI Conference on Artificial Intelligence. Toronto, Ontario, Canada: AAAI Press, 2012.
- [14] ASHKEZARI M D, HILL C N, FOLLETT C N, et al. Oceanic eddy detection and lifetime forecast using machine learning methods[J]. Geophysical Research Letters, 2016, 91(2): 217-225.
- [15] KARIMOVA S. Spiral eddies in the baltic, black and caspian seas as seen by satellite radar data[J]. Advances in Space Research, 2012, 50(8): 1107-1124.
- [16] ISERN-FONTANET J, GARCÍA-LADONA E, FONT J. Identification of marine eddies from altimetric maps[J]. Journal of Atmospheric & Oceanic Technology, 2003, 20(5): 772-778.
- [17] 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 Discussions, 2014, 10(2): 825-851.
- [18] FRANZ K, ROSCHER R, MILIOTO A, et al. Ocean eddy identification and tracking using neural networks[C]//Proceedings of IEEE International Geoscience and Remote Sensing Symposium. Providence, Rhode Island: IEEE Computer Society Press, 2018: 6887-6890.
- [19] LUCAS B, KANADE T. An iterative image registration technique with an application to stereo vision[C]//Proceedings of the 7th International Joint Conference on Artificial Intelligence. Vancouver, BC, Canada: Morgan Kaufmann Publishers, 1997.
- [20] XU G, CHENG C, YANG W, et al. Oceanic eddy identification using an AI scheme[J]. Remote Sensing, 2019, 11(11): 1349-1361.
- [21] ZHAO H, SHI J, QI X, et al. Pyramid scene parsing network[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Providence, Rhode Island: IEEE Computer Society Press, 2017: 2881-2890.
- [22] MASON E, PASCUAL A, MCWILLIAMS J C. A new sea surface height-based code for oceanic mesoscale eddy tracking[J]. Journal of Atmospheric & Oceanic Technology, 2014, 31(5): 1181-1188.
- [23] WEISS J. The dynamics of enstrophy transfer in two-dimensional hydrodynamics[J]. Physica D: Nonlinear Phenomena, 1991, 48: 273-294.
- [24] 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.
- [25] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//Proceedings of IEEE Conference on Computer Vision & Pattern Recognition. Providence, Rhode Island: IEEE Computer Society Press, 2016: 770-778.

(编辑:刘彦东)