

基于多模态数据融合的改进中尺度涡检测模型

李忠伟¹, 刘格格², 李永^{1*}, 徐斌², 宫凯旋¹

(1. 中国石油大学(华东) 海洋空间与信息学院, 山东 青岛 266400; 2. 中国石油大学(华东) 青岛软件学院、计算机科学与技术学院, 山东 青岛 266400)

摘要: 提出一种基于多模态数据融合的改进中尺度涡检测模型。该模型以海平面高度数据为基础,首次将融合表层海温数据扩展为融合多深度层海温数据;将海温数据的深度层作为通道,嵌入通道注意力机制,使得模型能够关注于海水温度数据中最具有区分度的深度层;模型在编码及解码过程中采用残差学习单元,在加深网络深度的同时,更好地拟合激活函数,缓解训练问题,以提高模型的检测准确率。以中国南海部分海域为例开展实验验证,结果表明该中尺度涡检测模型准确率达到93.62%,模型具备有效性和可靠性。

关键词: 中尺度涡;多模态数据;通道注意力;残差学习单元;深度学习

中图分类号: P731.2 **文献标识码:** A **文章编号:** 1003-0239(2024)02-0053-10

0 引言

中尺度涡是指直径为几十到几百千米、存在时间为几十天到半年以上的天气式海洋涡旋,是一种在各大洋中普遍存在的重要海洋现象^[1-2]。海洋中尺度涡的生成机制包括洋流的蛇形、海面风的作用、海面加热和冷却、地形作用等^[3],因此其附近海水在运动过程中携带着极大的动能,同时伴随着温度、盐度、叶绿素浓度的变化,对海洋中的物质运输、热量传递及海洋生物的分布产生很大影响^[4]。研究中尺度涡的分布对水文、气象、生态环境、海洋声学等领域均具有重要意义。

国内外学者已经开展了大量中尺度涡检测分析工作,其中基于物理特征的OW(Okubo-Weiss)算法^[5-6]、基于流场几何特征的WA(Winding-Angle)算法^[7]和VG(Vector Geometry)算法^[8]等传统方法,不仅需要人为干预设置合适的阈值,还存在显著的任务特异性和泛化能力差的限制,故不能很好地适应复杂多变的海洋环境^[9]。近年来不断崛起的人工智

能方法在各个领域都有令人惊艳的表现,这也给中尺度涡的检测研究提供了新的思路。XU等^[10]将能够满足语义和细节融合的金字塔场景解析网络(Pyramid Scene Parsing Network, PSPNet)作为涡旋检测方法的核心算法,并传统基于几何方法的VG算法结果进行比较,证明了人工智能算法的有效性。与此同时,也出现了许多基于人工智能算法并结合了中尺度涡所处环境附近海平面高度、海水温度、流场等海洋要素不同特征的中尺度涡智能检测模型。例如,基于海平面高度(Sea Surface Height, SSH)数据,董子意等^[11]引入卷积注意力机制和残差学习模块对U-Net网络进行改进,提升了涡旋检测效果;基于海水温度(Sea Surface Temperature, SST)数据, MOSCHOS等^[12]提供了一种通过测高检测来获取海温图像数据集的新方法,并训练了一个卷积神经网络(Convolutional Neural Network, CNN)分类器用于准确检测涡流特征,后又使用高分辨率海洋数值模型将涡旋的特征流线与其在SST上的特征联系起来,来分割SST的红外卫星图像^[13];

收稿日期: 2023-05-06。

基金项目: 国家自然科学基金重点项目(62231028)。

作者简介: 李忠伟(1978-),男,教授,博士,主要从事大数据处理与人工智能算法及其智慧应用方面研究。E-mail: li.zhongwei@vip.163.com

*通信作者: 李永(1979-),男,高级实验师,硕士,主要从事物联网和嵌入式方向、操作系统方向、人工智能方向等研究。E-mail: 20030019@upc.edu.cn

基于流速数据,BAI等^[14]创建了基于流场数据的涡旋图像数据集,并提出了一种用于高精度涡旋检测的深度学习方 法 SP-RCNN (Stream Path - Based Region - Based Convolutional Neural Networks)。上述方法均基于单模态数据对涡旋进行检测,可能会出现因数据噪声和采样误差而造成的涡旋漏检、误检等问题,因此,学者开始研究将多种模态数据进行融合的涡旋检测模型,如 LIU 等^[15]利用密集连接网络将海平面高度数据和海水温度数据进行融合,作为涡旋检测模型的输入;FAN 等^[16]提出了涡旋检测网络 (Eddy Detection Network, EDNet),即利用融合海面高度、海面温度和流速 3 种模态的卫星数据对涡旋进行分割。

多模态数据融合方法对提升涡旋检测精度有很大贡献,尤其是将 SSH 和 SST 数据进行融合,二者均为中尺度涡较强有力的物理表征方式,其中 SSH 数据为单层海表面数据, SST 数据为多深度层数据,但现有方法大多停留在融合 SST 表层数据而忽略了深度层数据对涡旋检测的作用。LGUENSAT 等^[17]基于 U-Net 架构,提出了用于中尺度涡特征提取的 EddyNet 实例分割模型,该模型在满足拟合涡旋检测效果的基础上,大大提高了涡旋的检测速度,但仍然存在深层特征提取能力不强、网络精度提取不高的问题。本文提出了一种基于多模态数据融合的改进中尺度涡检测模型,该模型在以 SSH 数据为主的检测基础上,首次将融合 SST 数据扩展为融合多深度层海温 (Multi-depth Sea Temperature, MDST) 数据,并为 MDST 数据嵌入通道注意力 (Efficient Channel Attention, ECA) 机制^[18],同时在编解码过程中采用残差学习单元对模型特征提取网络进行改进。经过实验验证,模型在一定程度上提高了涡旋检测精度,为海洋中尺度涡的自动识别提供了新思路。

1 研究方法

1.1 基于多模态数据融合的改进中尺度涡检测模型

基于多模态数据融合的改进中尺度涡检测模型结构如图 1 所示。在数据融合部分,模型为 MDST 数据嵌入 ECA 机制,使得模型能够关注于 SST 数据中最具有区分度的深度层,然后将具有

ECA 的 MDST 数据进行 1×1 卷积降维后,与 SSH 数据进行融合,将融合数据输入到改进后的 EddyNet 模型中。

与 U-Net 架构^[19]类似, EddyNet 网络模型也是一个 U 型对称网络,其较 U-Net 参数数量少,因此内存消耗低,能够大大增加模型的训练速度,但其仍未解决模型提取深层特征能力差的问题。本文通过嵌入残差学习单元来对 EddyNet 进行改进,即引入残差映射后,模型将上一个残差块的特征信息加入下一个残差块中,在加深网络深度的同时,有效避免了网络过深引起的梯度消失和涡旋特征信息丢失问题。改进后的 EddyNet 依然沿用了原模型的 3 级全 32 滤波器架构,网络是典型的“编码器-解码器”架构。编码器路径具有 3 个阶段,每个阶段的残差单元模块主要包括两组批标准化层 (Batch Normalization, BN)、ReLU 激活函数层、Dropout 层和 3×3 卷积层 (Convolutional Layer),与输入特征图恒等捷径连接 (Shortcut) 以计算残差后,通过 2×2 最大池化层 (Max Pooling) 进行下采样,将输入特征图的分辨率减半,其中, 3×3 卷积层主要用于提取涡旋输入图的特征信息, Dropout 层可以忽略部分特征检测器以避免过拟合。解码器路径同样具有 3 个阶段,每个阶段首先利用拼接 (Concatenate) 将上采样 (Up Sampling) 特征图与对应层级的编码器卷积层进行拼接,以返回到图像原始分辨率,之后再进行相应的特征提取工作。与 U-Net 一样,本模型同样受益于从收缩路径到扩展路径的跳跃连接,以结合不同网络层中具有不同深度的语义抽象信息和不同细腻程度的位置信息,进一步提升正反气旋涡的语义分割精确度。

1.2 海面高度数据与多深度层海温数据融合

中尺度涡旋在北半球逆时针旋转为气旋涡,顺时针旋转则为反气旋涡^[15]。涡旋驱动局部海流,导致海平面高度异常和海水温度异常,气旋涡表现为负海平面高度异常,涡旋内部的水温比周围海水低,称为冷涡,反气旋涡表现为正海平面高度异常,涡旋内部水温较高,故也被称为暖涡。谢旭丹等^[20]对南海中尺度涡的温盐异常三维结构进行了构建分析,在平均状态下,南海海域最大位温异常 (即涡核) 出现在次表层约 80 m 深度处,反气旋涡结构维




图2 ECA通道注意力结构图

Fig.2 Efficient channel attention structure

深而引起的梯度消失和爆炸,我们在模型的编码及解码过程中均采用了残差学习单元(Residual Units)^[23]。HE等^[24]提出的原始残差学习模块主要包括两组卷积层、BN批标准化层和ReLU激活函数层(见图3a),通过直接将输入信息传到输出,保护

了信息的完整性,过程中只需要学习输入与输出之间有差别的部分,简化了学习的目标和难度。之后,HE等^[23]又对残差学习模块进行了优化(见图3b),将批标准化层BN和激活函数ReLU视为权重卷积层的“预激活”,这种新的残差学习单元结构相对于传统“后激活”的方法更容易训练和泛化,误差更小。本模型也采用了“预激活”结构的残差学习单元,并在捷径连接中对输入特征进行1×1卷积(见图3c),1×1卷积捷径连接可以通过调整特征图通道数、增加非线性变换和融合信息等方式,提高模型的训练效率和泛化性能,比恒等捷径连接具有更强的表征能力,可以更好地对涡旋检测模型进行优化。

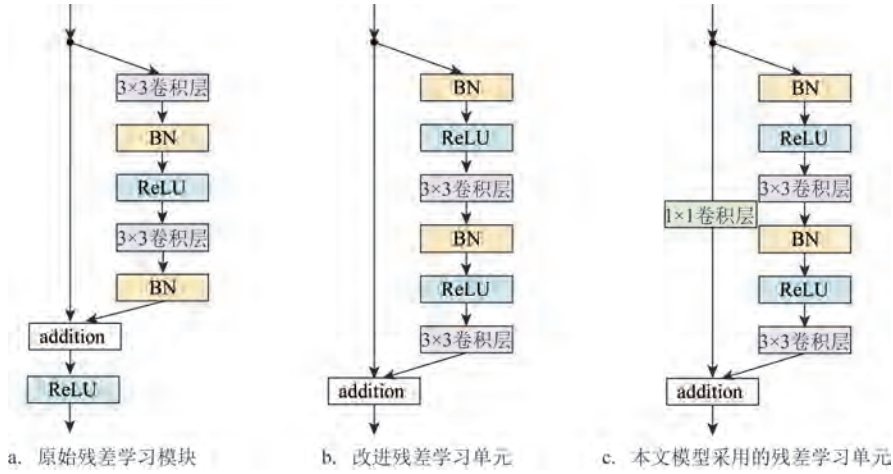


图3 残差学习结构对比

Fig.3 Comparison of residual learning structures

1.4 损失函数

模型使用基于Dice系数(Dice Coefficient)实现的Dice Loss^[25]作为损失函数。Dice系数是一种集合相似度量函数,通常用于计算两个样本的相似度,取值范围为[0,1],即图像分割效果好则倾向于1,分割效果差则倾向于0。Dice系数计算公式为:

$$dice(P, G) = \frac{2|P \cap G|}{|P| + |G|} \quad (1)$$

式中:|P|为预测区域,G为真实区域,|P|+|G|表示两个区域中元素的总和;Dice系数值dice为P与G区域交集与区域总和之比的两倍。

由于中尺度涡图像分割模型为多分类问题,主

要分类为气旋涡区域、反气旋涡区域及背景区域,各数据集存在样本不均衡的问题,于是本模型在计算总体Dice系数时,并非单纯地采用每类Dice系数取平均值的方式。我们首先尝试计算3类样本的权重,根据每类样本的占比倒数对其Dice系数进行加权,以此来最大化网络的性能。加权Dice系数(Weighted Dice Coefficient)与损失函数计算公式分别为:

$$dice_{weighted} = \alpha \times dice_{cyc} + \beta \times dice_{anti} + \gamma \times dice_{bg} \quad (2)$$

$$loss = 1 - dice_{weighted} \quad (3)$$

式中: $dice_{cyc}$ 、 $dice_{anti}$ 、 $dice_{bg}$ 分别为气旋涡区域、反气旋涡区域、背景区域的Dice系数; α 、 β 、 γ 分别为三者的权重; $dice_{weighted}$ 为数据总体加权Dice系数;loss为模型计算得出的损失函数值。

2 实验与分析

2.1 数据集制作

实验数据来自哥白尼海洋环境检测中心(Copernicus Marine Environment Monitoring Service, CMEMS)提供的全球海洋物理再分析数据(Global Ocean Physics Reanalysis),该数据地理范围覆盖全球,空间分辨率为 0.083° (即 $1/12^\circ$)。本实验选择2010年1月1日—2020年12月31日共11年的日平均数据,范围为中国南海部分海域($4^\circ\sim 21^\circ\text{N}$, $105^\circ\sim 118^\circ\text{E}$,见图4)。

数据集标签制作主要包括以下两个步骤:

①采用经典的涡流识别和跟踪(Py-Eddy-Tracker, PET)^[26]方法,根据SSH和流场UV数据识别涡旋。图5a为SSH数据可视化图,图5b为不同容错率所呈现的涡旋轮廓,经过实验验证,我们设置涡旋轮廓容错为55,以达到更好的检测效果,图5c为检测得到的涡旋图。利用PET分别生成气旋涡和反气旋涡的有效涡旋轮廓信息,主要包括有效轮廓经纬度(Effective Contour Latitudes / Longitudes)、有效半径(Effective Radius)等,以及涡旋速度等值线轮廓信息,主要包括速度等值线经纬度(Speed Contour Latitudes/Longitudes)、速度半径(Speed Radius)等。我们考虑采用速度等值线轮廓进行标签制作,它对应于具有最高平均地转流的闭合等值线,且速度等值线可以看作是涡旋能量最大



图4 实验选择区域

Fig.4 Experiment area

的部分,通常小于有效半径。

②利用Shapely包的点线函数关系判断实验所选区域是否包含步骤①中PET生成的涡旋速度等值线经纬度包围区域,将其检测到的气旋涡标注为“2”,反气旋涡标注为“1”,其余背景部分及陆地标注为“0”,通过人工订正后,最终得到数据集标签。

实验标注2010—2020年共计4 018张SSH数据图,其中将2010—2019年共计3 652张数据图作为

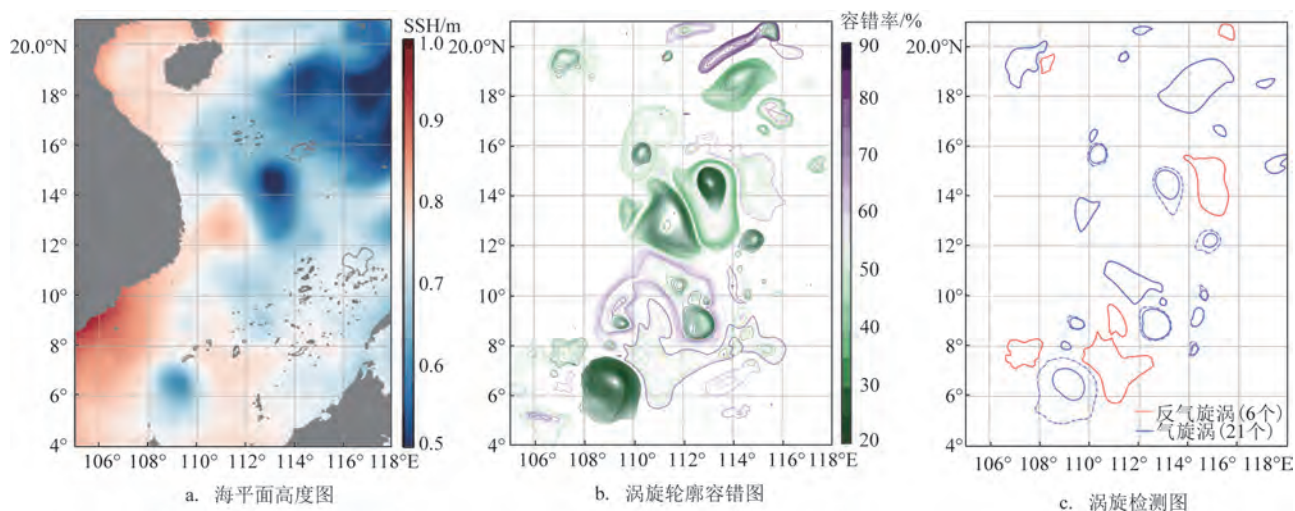


图5 PET涡旋检测方法图

Fig.5 PET eddy detection method map

训练集,将2020年共计366张数据图作为测试集。

2.2 实验参数及评价指标

实验环境基于Python 3.7搭建, GPU为NVIDIA GeForce RTX 3060, CUDA版本为11.1, Keras版本为2.10.0, Tensorflow-gpu版本为2.10.1。实验选择Dice Loss作为损失函数,采用计算高效、善于处理非平稳模型的Adam优化器来优化模型。实验训练时按照8:2划分训练集和验证集,为避免过拟合问题,实验设置早停机制, patience设置为100 epoch, 监听参数fitness设置为评估损失val_loss。

本实验的中尺度涡检测任务实则为气旋涡、反气旋涡及背景区域的多分类任务,故实验选择分类准确率(Categorical Accuracy)、平均Dice系数(Mean Dice Coefficient)和加权Dice系数3种评价指标为模型进行评估。

2.3 结果分析

为了验证本文改进模型的可靠性和有效性,在2010—2019年涡旋训练集上进行了多次对比实验,并在2020年涡旋测试集上进行测试,同时将U-net和董子意等^[10]提出的涡旋检测模型作为辅助对比,通过分类准确率、平均Dice系数和加权Dice系数将模型的涡旋检测性能进行对比分析,结果如表1。

我们SSH数据、SST数据、MDST数据、SSH与MDST融合数据分别在EddyNet模型中进行实验。从表1的结果可以看出,在涡旋检测中,SSH与MDST融合数据相对于任一单模态数据均表现出了

更强的准确性和鲁棒性,同时证明了MDST数据相较于SST数据具备更好的涡旋检测效果。将SSH数据和融合数据在加入残差单元的EddyNet中进行实验验证,表1中的数据也表明,残差学习单元为模型带来了一定程度的性能提升。经过训练,基于多模态数据融合的改进中尺度涡检测模型在测试集中取得了93.62%的分类准确率,相比于EddyNet模型基于单模态SSH数据的分类准确率高2.17%,平均Dice系数提高3.15%,加权Dice系数提高4.63%,展现出了不错的涡旋检测性能。

图6为本模型与PET模型的涡旋检测效果对比图,其中图6a为2020年第144天的涡旋检测图,图6b为2020年第285天的涡旋检测图。从图中标注的红色框线可以看出,本模型检测出了部分PET模型未检测出的涡旋,在与SSH等值线图高度符合的同时,涡旋边缘也更加拟合。

2.4 涡旋统计与分析


利用基于多模态数据融合的改进中尺度涡检测模型,我们对2020年全年共366 d的中尺度涡进行检测,共检测到气旋涡5 554个,反气旋涡3 738个,对结果进行统计与分析。

根据涡旋轮廓的坐标数据计算涡旋中心的经纬度位置,并将其进一步细分到 $1^{\circ} \times 1^{\circ}$ 经纬度网格内,图7a—c分别为涡旋总体分布图(不分极性)、气旋涡分布图与反气旋涡分布图。从图7a中可以看出,涡旋总体主要沿南海海盆东北—西南线和海南岛西部海域分布,与郑全安等^[27]对南海中尺度涡空

表1 模型涡旋检测性能对比

Tab.1 Comparison of model eddy detection performance

模型	分类准确率	平均Dice系数	加权Dice系数
U-net	0.886 5	0.628 8	0.493 6
U-net+残差块+CBAM ^[10]	0.930 4	0.788 3	0.710 6
EddyNet+SST	0.899 1	0.641 2	0.500 4
EddyNet+MDST	0.904 2	0.658 1	0.519 6
EddyNet+SSH	0.914 5	0.763 4	0.673 6
EddyNet+融合数据	0.922 1	0.773 0	0.688 1
EddyNet+残差单元+SSH	0.926 8	0.776 9	0.697 4
EddyNet+残差单元+融合数据	0.936 2	0.794 9	0.719 9



注:黄色区域为气旋涡、绿色区域为反气旋涡,从左到右分别为SSH等值线图、PET模型涡旋检测图和本文模型检测图

图6 本文模型与PET模型涡旋检测对比图

Fig.6 Comparison of our model and PET

间分布的统计分析相对一致;对比图7b和7c,由于南海暖流的影响,海南岛西部海域主要分布着反气旋涡,而距离南北部海岸越近,越容易形成气旋涡,如北部湾冷涡。此外,反气旋涡主要分布在南海海盆中部、南海东北部,气旋涡主要分布在西沙群岛海域、吕宋岛西部海域。

南海中尺度涡的季节分布受季节性气候变化、海洋环流等多种因素综合影响,图8a为气旋涡、反气旋涡在不同月份的数量分布。统计表明,南海海域气旋涡总体上多于反气旋涡,气旋涡在冬、春两季数量较多,其中2月最多,为569个,夏、秋两季数量较少,其中6月最少,为377个;与之相反,反气旋

涡在冬、春两季数量较少,其中4月最少,为260个,而夏、秋两季数量较多,其中5月最多,为391个,两种气旋涡的季节数量分布与王萌等^[28]阐述的中尺度涡季节变化规律较为符合。图8b为涡旋最大圆周月平均转速折线图,涡旋转速主要在20~35 cm/s之间,反气旋涡年平均转速约为27.18 cm/s,气旋涡约为25.30 cm/s,说明反气旋涡的动力特征普遍强于气旋涡^[28]。涡旋速度半径统计见图8c,气旋涡平均半径为50.73 km,反气旋涡为60.49 km,大部分涡旋半径为25~50 km,气旋涡和反气旋涡分别约有36.9%和34.2%处于该区间;在涡旋半径超过50 km后,涡旋数量依半径增大呈递减状态,模型暂未检测到半径

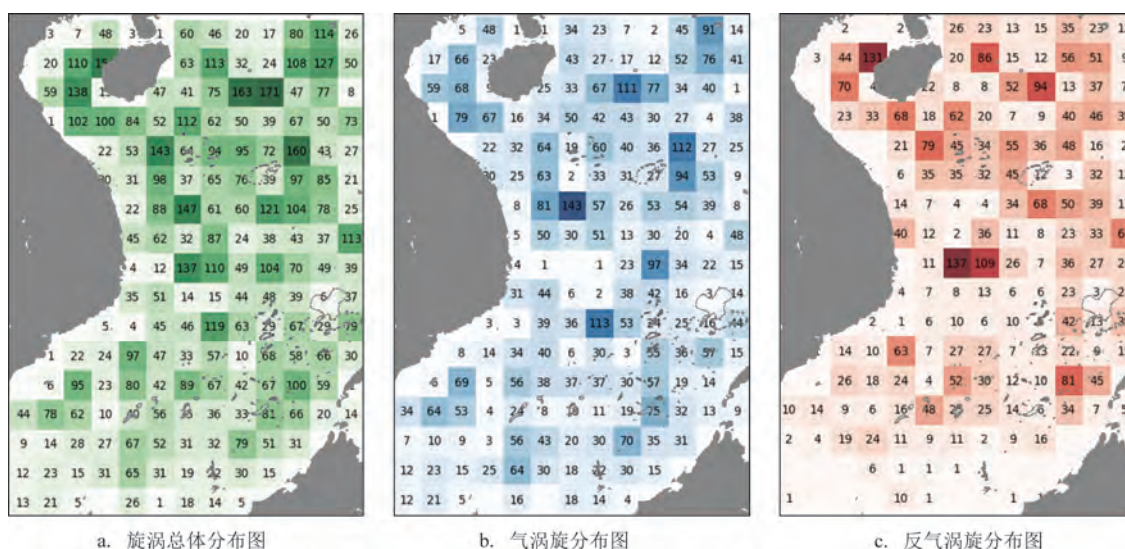


图7 涡旋分布图

Fig.7 Eddies distribution map

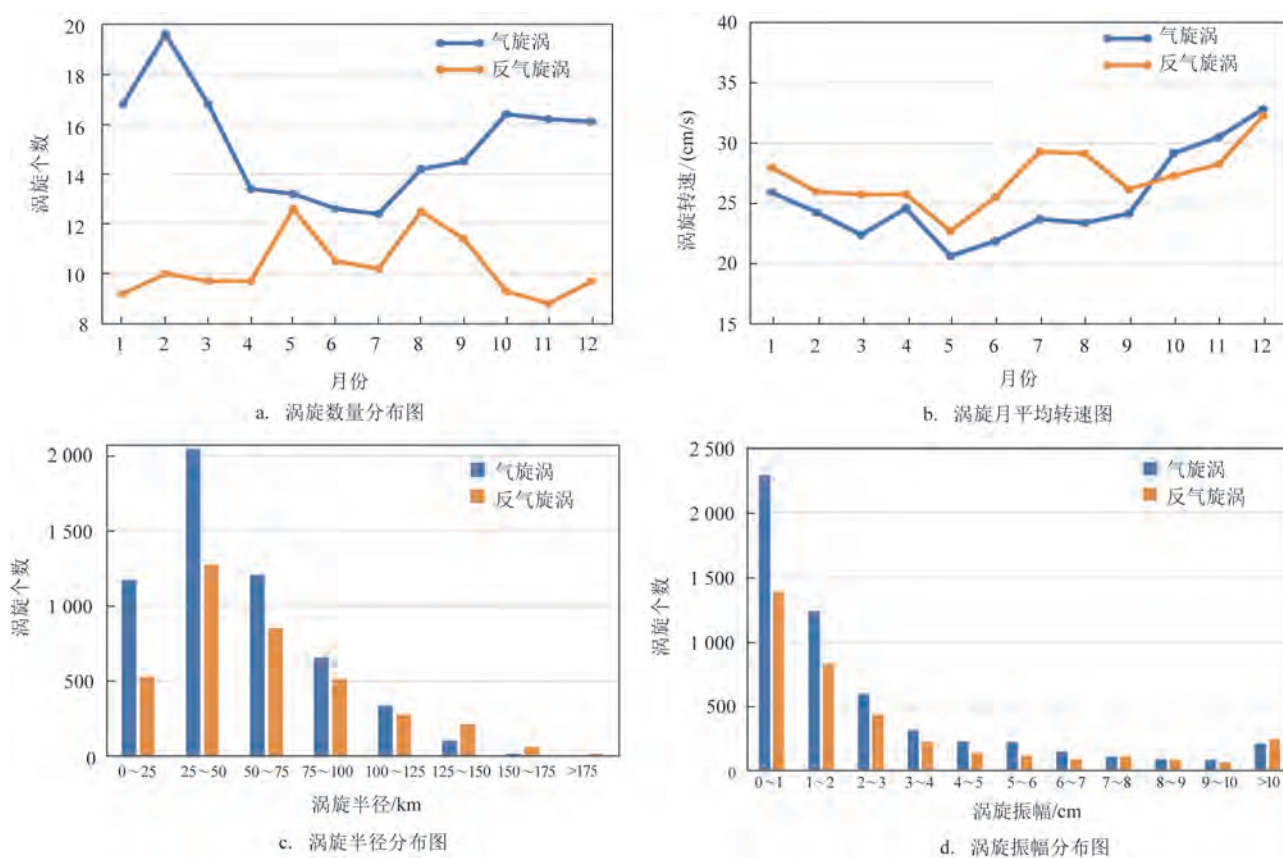


图8 涡旋特征属性统计图

Fig.8 Eddies feature charts

超过 175 km 的气旋涡,也仅有约 0.13% 的反气旋涡半径大于 175 km。图 8d 反映出涡旋的振幅分布情

况,绝大部分涡旋内部海面高度极值与涡旋轮廓边缘海面高度之差为 0~1 cm,反气旋涡的平均振幅

约为3.01 cm,气旋涡约为2.56 cm。

3 结论

本文首先将海面高度数据与表层海温数据与多深度层海温数据进行融合,在减少单模态数据容易出现涡旋误检、漏检问题的同时,增强了海水温度数据的可利用性;其次,模型利用ECA通道注意力,为海水温度数据的不同深度层赋予权重,使得模型关注其最有贡献度的深度层;最后,在模型的编码及解码过程中采用残差学习单元来缓解训练问题,并改善了网络退化。本文实验结果表明,基于多模态数据融合的改进中尺度涡检测模型能够准确提取涡旋特征,很好地达到涡旋检测效果,融合多深度层海水温度数据的方式也为涡旋检测研究提供了新思路。本文实验主要针对南海部分海域,对于其他涡旋数量繁多且更为活跃的海域,将进一步改进模型以提高其适用性和可迁移性;除此之外,还将引入更多的相关海洋要素数据进行涡旋检测以提升模型整体性能。

参考文献:

- [1] D'ALIMONTE D. Detection of mesoscale eddy-related structures through Iso-SST patterns[J]. IEEE Geoscience and Remote Sensing Letters, 2009, 6(2): 189-193.
- [2] CHEN G, EZRATY R. Non-tidal aliasing in seasonal sea-level variability and annual Rossby waves as observed by satellite altimetry[J]. Annales Geophysicae, 1997, 15(11): 1478-1488.
- [3] 白志鹏, 韩君, 郭贤鹏, 等. 基于CORA2再分析数据的南海中尺度涡时空分布特征初步研究[J]. 海洋预报, 2020, 37(2): 73-83.
BAI Z P, HAN J, GUO X P, et al. Spatial and temporal distribution characteristics of mesoscale eddies in the South China Sea based on the CORA2 reanalysis data[J]. Marine Forecasts, 2020, 37(2): 73-83.
- [4] WYRTKI K, MAGAARD L, HAGER J. Eddy energy in the oceans [J]. Journal of Geophysical Research, 1976, 81(15): 2641-2646.
- [5] 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.
- [6] WEISS J. The dynamics of enstrophy transfer in two-dimensional hydrodynamics[J]. Physica D: Nonlinear Phenomena, 1991, 48(2-3): 273-294.
- [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 M, 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] 杜艳玲, 刘倩倩, 王丽丽, 等. 融合多尺度旋转锚机制的海洋中尺度涡自动检测[J]. 中国图象图形学报, 2022, 27(10): 3092-3101.
DU Y L, LIU Q Q, WANG L L, et al. Multi-scale rotating anchor mechanism based automatic detection of ocean mesoscale eddy[J]. Journal of Image and Graphics, 2022, 27(10): 3092-3101.
- [10] XU G J, CHENG C, YANG W X, et al. Oceanic eddy identification using an AI scheme[J]. Remote Sensing, 2019, 11(11): 1349.
- [11] 董子意, 杜震洪, 吴森森, 等. 基于改进U-Net网络的海洋中尺度涡自动检测模型[J]. 海洋学报, 2022, 44(2): 123-131.
DONG Z Y, DU Z H, WU S S, et al. An automatic marine mesoscale eddy detection model based on improved U-Net network[J]. Haiyang Xuebao, 2022, 44(2): 123-131.
- [12] MOSCHOS E, SCHWANDER O, STEGNER A, et al. Deep-SST-eddies: a deep learning framework to detect oceanic eddies in sea surface temperature images[C]//Proceedings of 2020 IEEE International Conference on Acoustics, Speech and Signal Processing. Barcelona, Spain: IEEE, 2020.
- [13] MOSCHOS E, KUGUSHEVA A, COSTE P, et al. Computer vision for ocean eddy detection in infrared imagery[C]//Proceedings of 2023 IEEE / CVF Winter Conference on Applications of Computer Vision (WACV). Waikoloa, HI, USA: IEEE, 2023: 6384-6393.
- [14] BAI X, WANG C B, LI C H. A streampath-based RCNN approach to ocean eddy detection[J]. IEEE Access, 2019, 7: 106336-106345.
- [15] LIU Y J, ZHENG Q A, LI X F. Detection and analysis of mesoscale eddies based on deep learning[M]//LI X F, WANG F. Artificial Intelligence Oceanography. Singapore: Springer, 2023.
- [16] FAN Z L, ZHONG G Q, WEI H X, et al. EDNet: a mesoscale eddy detection network with multi-modal data[C]//Proceedings of 2020 International Joint Conference on Neural Networks (IJCNN). Glasgow, UK: IEEE, 2020.
- [17] LGUENSAT R, SUN M, FABLET R, et al. EddyNet: a deep neural network for pixel-wise classification of oceanic eddies[C]//IGARSS 2018 - 2018 IEEE International Geoscience and Remote Sensing Symposium. Valencia, Spain: IEEE, 2018.
- [18] WANG Q L, WU B G, ZHU P F, et al. ECA-Net: efficient channel attention for deep convolutional neural networks[C]//2020 IEEE / CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, WA, USA: IEEE, 2020.
- [19] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation[C]//Proceedings of the 18th Medical Image Computing and Computer-Assisted Intervention. Munich, Germany: Springer, 2015.

- [20] 谢旭丹, 王静, 储小青, 等. 南海中尺度涡温盐异常三维结构[J]. 海洋学报, 2018, 40(4): 1-14.
XIE X D, WANG J, CHU X Q, et al. Three-dimensional thermohaline anomaly structures of mesoscale eddies in the South China Sea[J]. Haiyang Xuebao, 2018, 40(4): 1-14.
- [21] 赵福, 张蕴斐, 朱学明, 等. 冬季台湾西南海域一对冷、暖中尺度涡的同化模拟研究[J]. 海洋预报, 2017, 34(5): 1-15.
ZHAO F, ZHANG Y F, ZHU X M, et al. An assimilative numerical study of the paired cold and warm mesoscale eddies during winter in the Southwest of Taiwan[J]. Marine Forecasts, 2017, 34(5): 1-15.
- [22] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-excitation networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(8): 2011-2023.
- [23] HE K M, ZHANG X Y, REN S Q, et al. Identity mappings in deep residual networks[C]//Proceedings of the 14th European Conference on Computer Vision - ECCV 2016. Amsterdam, The Netherlands: Springer, 2016.
- [24] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA: IEEE, 2016.
- [25] MILLETARI F, NAVAB N, AHMADI S A. V-Net: fully convolutional neural networks for volumetric medical image segmentation[C]//Proceedings of the 4th International Conference on 3D Vision. Stanford, CA, USA: IEEE, 2016.
- [26] 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.
- [27] 郑全安, 谢玲玲, 郑志文, 等. 南海中尺度涡研究进展[J]. 海洋科学进展, 2017, 35(2): 131-158.
ZHENG Q A, XIE L L, ZHENG Z W, et al. Progress in research of mesoscale eddies in the South China Sea[J]. Advances in Marine Science, 2017, 35(2): 131-158.
- [28] 王萌, 张艳伟, 刘志飞, 等. 南海北部中尺度涡的时空分布特征: 基于卫星高度计资料的统计分析[J]. 地球科学进展, 2019, 34(10): 1069-1080.
WANG M, ZHANG Y W, LIU Z F, et al. Temporal and spatial characteristics of mesoscale eddies in the northern South China Sea: statistics analysis based on altimeter data[J]. Advances in Earth Science, 2019, 34(10): 1069-1080.

An improved mesoscale eddy detection model based on multimodal data fusion

LI Zhongwei¹, LIU Gege², LI Yong^{1*}, XU Bin², GONG Kaixuan¹

(1. College of Oceanography and Space Informatics, China University of Petroleum, Qingdao 266400, China; 2. Qingdao Institute of Software, College of Computer Science and Technology, China University of Petroleum, Qingdao 266400, China)

Abstract: In this paper, an improved mesoscale eddy detection model based on multimodal data fusion is proposed. On the basis of sea level height data, the model extends the sea surface temperature fusion method into multi-depth ocean temperature fusion method for the first time. Taking the depth layer of ocean temperature data as a channel with channel attention mechanism, the model can focus on the depth layer with the most distinguishing degree in ocean temperature data. Residual learning unit is used in the encoding and decoding processes to improve the detection accuracy of the model, which not only deepen the depth of the network, but also better fit the activation function and alleviate the training problem. Utilizing the model in the South China Sea mesoscale eddy detection shows that the accuracy rate of the mesoscale eddy detection reaches 93.62%. The effective and reliable results suggest that the model can provide a new and reasonable idea for the research of mesoscale eddy detection.

Key words: mesoscale eddy; multimodal data; efficient channel attention; residual learning unit; deep learning