

基于 SobelUnet 的海洋流速场超分辨率重建研究

杜俊坤¹, 王明清², 黄占鳌¹, 李孝杰¹

(1. 成都信息工程大学 计算机学院, 四川 成都 610225;

2. 无锡九方科技有限公司, 江苏 无锡 214072)

摘要: 高分辨率的海洋流速场对提高数值模拟和预测精度具有重要意义。以海洋环流模型 HYCOM 的 $1/12^\circ$ 分辨率模拟海洋流速场为基础, 重建超分辨率海洋流速场。但是, 直接以 HYCOM 结果重建高分辨率海洋流速场存在困难, 同时传统插值难以准确恢复复杂海洋流速场的细节。为解决这一难题, 提出一种基于 SobelUnet 的超分辨率重建方法。该模型包含初始态模块、多语义融合模块和残差 Sobel 注意力模块 3 部分。其中, 初始态模块通过分析多年海洋流速场数据成功捕捉了关键海陆细节, 多语义融合模块合成不同语义级别的特征来弥补信息损失, 残差 Sobel 注意力模块利用 Sobel 卷积和注意力机制增强了海洋流速场边缘。实验结果表明, 相比其他参考模型, 该方法在 PSNR、SSIM、MSE 和 MAE 等多个指标上有所提高。SobelUnet 模型能够高效地重建海洋流速场数据, 并恢复更丰富的细节信息。

关键词: HYCOM; 海洋流速场; 超分辨率重建; 传统插值; SobelUnet

DOI: 10.11907/rjdk.241170

开放科学(资源服务)标识码(OSID):

中图分类号: TP391.41

文献标识码: A

文章编号: 1672-7800(2025)007-0185-09



Study on Super-Resolution Reconstruction of Ocean Current Velocity Field Based on SobelUnet

DU Junkun¹, WANG Mingqing², HUANG Zhan'ao¹, LI Xiaojie¹

(1. School of Computer Science, Chengdu University of Information Technology, Chengdu 610225, China;

2. Ninecosmos Science and Technology Ltd., Wuxi 214072, China)

Abstract: High-resolution ocean current velocity fields are significant for improving the accuracy of numerical simulation and prediction. In this study, the ocean current velocity fields simulated by the Hybrid Coordinate Ocean Model (HYCOM) with a resolution of $1/12^\circ$ are utilized to construct a super-resolution field. However, directly reconstructing high-resolution ocean currents from HYCOM results is challenging, and conventional interpolation methods fail to accurately recover complex flow details. To address this problem, a super-resolution reconstruction method based on SobelUnet is proposed. This model consists of three modules: the initial state module, the multi-semantic fusion module, and the residual Sobel attention module. Specifically, the initial state module successfully captures critical land-sea details by analyzing multi-year ocean current data; the multi-semantic fusion module synthesizes features at different semantic levels to compensate for information loss; the residual Sobel attention module enhances ocean current edges by employing Sobel convolutions and attention mechanisms. Experimental results demonstrate that compared with other reference models, the proposed method improves PSNR, SSIM, MSE and MAE. It illustrates that the SobelUnet model can efficiently reconstruct ocean current data and recover richer detail information.

Key Words: HYCOM; ocean current velocity field; super resolution reconstruction; traditional interpolation; SobelUnet

收稿日期: 2024-02-27

扫描二维码阅读全文:



基金项目: 成都信息工程大学科技创新能力提升计划项目(KYTD202330)

作者简介: 杜俊坤(1996-), 男, 成都信息工程大学计算机学院硕士研究生, 研究方向为图像处理、深度学习、气象应用; 王明清(1989-), 男, 无锡九方科技有限公司博士研究生, 研究方向为大气海洋领域人工智能创新应用; 黄占鳌(1993-), 男, 博士, 成都信息工程大学计算机学院讲师, 研究方向为神经网络理论与应用、不平衡数据学习、智慧气象应用; 李孝杰(1981-), 女, 博士, 成都信息工程大学计算机学院教授、硕士生导师, 研究方向为机器学习、图像处理。本文通讯作者: 李孝杰。

0 引言

海洋流速场数据的高分辨率重建对于深入理解海洋动力学过程、维持生态平衡以及提高气候预测精度具有重要意义^[1-4]。然而,以海洋环流模拟的低分辨率流场结果重建高分辨率海洋流速场存在困难,而传统插值方法无法准确恢复复杂海洋流速场的细节信息,这为重建工作带来了挑战。传统的双线性插值^[5]、双三次插值和样条插值算法在处理全局一致性方面具有优势,但难以恢复数据中的细微变化^[6]。相比之下,深度学习方法凭借其强大的非线性建模能力,在高度复杂的问题处理上表现卓越^[7]。但是,现有的深度学习超分辨率模型应用于海洋流速场数据时,仍难以有效重建复杂的海洋流速场边缘纹理,需要进行更深入的研究。

早期的双三次插值等传统的插值算法主要基于像素间关系进行推测,难以捕捉图像的复杂细节,也难以恢复高频信息,自适应性和准确性有限^[8-9]。如图1所示,BI-CUBIC(Bicubic Interpolation)生成的海洋流速场图像过于平滑,许多纹理细节丢失,与GT(Ground Truth)图有一些距离。为解决该问题,研究者开始探索基于深度学习的神经网络超分辨率方法。早期的SRCNN(Super-Resolution Convolutional Neural Network)^[10]、FSRCNN(Fast Super-Resolution Convolutional Neural Network)^[11]等模型采用卷积神经网络(Convolutional Neural Network, CNN)进行重建,但随着网络加深,训练难度增大,出现了模型退化问题。残差网络结构的提出改善了这一问题。基于残差学习的VDSR(Very Deep Convolutional Networks)^[12]、EDSR(Enhanced Deep Residual Networks for SR)^[13]、DBPN(Deep Back-Projection Networks)^[14]、RCAN(Residual Channel Attention Networks)^[15]等模型相继出现,通过扩展网络宽度和深度提升流场的细节还原能力与重建精度。但过深、过宽的网络参数量巨大,面临过拟合风险。后续的IMDN(Information Multi-Distillation Network)^[16]、RFDN(Residual Feature Distillation Network)^[17]等模型采用轻量网络和残差学习方式,在控制参数量的同时维持关键特征提取能力,但是这类模型生成的图像往往过于平滑,高频纹理丢失。基于生成对抗网络的SRGAN(SuperResolution Generative Adversarial Network)等采用对抗生成和感知损失方式,能够产生更逼真的视觉效果^[18]。随着任务难度提升,网络深处的信息传递出现衰减。TTSR(Texture Transformer Network for SR)^[19]、SwinIR(Image Restoration Using Swintransformer)^[20]、ESRT(Efficient Sub-pixel Residual Transformer)^[21]和HNCT(Hybrid Network of CNN and Transformer)^[22]等模型广泛采用Transformer^[23]架构,并通过注意力机制建模图像中的全局关联和长程依赖关系^[24]。尽管相比计算效率更高的卷积网络结构,这类全注意力机制存在计算复杂

度更高的缺点,且需要大规模标注数据进行预训练,但其生成图像质量取得了较大提升^[25]。然而,由于海洋流速场数据具有陆地区域广阔、海洋流速场范围窄小等特点,其边缘信息较为复杂。由图1可见,现有算法模型在处理此类数据集时,常难以充分恢复海洋流速场的纹理细节和边缘信息,关键特征未得到充分保留。




Fig. 1 Comparison of different methods for generating ocean velocity field images

图1 不同方法生成海洋流速场图像比较

为解决上述问题,本文构建一种面向海洋流速场数据的超分辨率深度网络SobelUnet。该模型包含初始状态模块、多尺度特征融合模块和残差Sobel注意力模块。初始状态模块通过分析多年来的海洋流速场数据,有效提取海陆边界等关键信息。多尺度特征融合模块合成了不同语义层面的特征,弥补了信息损失。残差Sobel注意力模块增强了海洋流速场的边缘细节。SobelUnet的精细设计使其可以全面获取场数据的结构和边缘特征,避免了深度网络中的特征退化,实现了更准确的纹理重建,因此在海洋流速场数据超分辨率任务中具有较好表现。本文的主要贡献如下:

(1)在模型设计方面,SobelUnet采用多尺度特征提取与融合的策略,有机结合了Sobel算子卷积和注意力机制,并进行了多级语义特征的融合。该设计可以全方位获取海洋流速场数据的空间结构和关键边缘纹理信息,避免了深度网络中的特征退化和过拟合问题,从而实现更准确的纹理重建。

(2)在网络模块设计上,SobelUnet创新性地构建了初始态模块(Initial State Module, ISM)、多尺度特征融合模块(Multi-Semantic Fusion Module, MSFM)和残差Sobel注意力模块(Residual Sobel Attention Module, RSAM)。其中,初始状态模块通过分析多年平均最小值成功提取了海陆分布的关键信息,多尺度特征融合模块有效利用了不同语义粒度的特征,残差Sobel注意力模块增强了海洋流速场

数据的边缘和纹理。

实验结果证明,SobelUnet 模型相比传统算法和当前主流的深度学习模型,在多项性能指标上都获得了提升,为气象学、海洋学以及相关气候变化研究提供了强有力的技术支持,从而推动该领域的发展。

1 相关工作

海洋流速场数据的获取为研究海洋动力学过程和改进气候预测提供了可能,但是直接获取的海洋流速场数据分辨率较低,无法满足对流场细节的还原需求。研究者尝试了各种补间方法,如双线性插值和样条插值,但这些方法主要依靠邻域像素信息进行预测,难以准确重建复杂流场的细节^[6]。如图 1 所示,在插值重建的图像中,海洋流速场的边缘恢复完全不准确,复杂的高频区域过于平滑,效果太差。

随着深度学习技术的发展,研究者开始利用卷积神经网络(CNN)进行图像超分辨率重建,并取得了显著进展^[26-30]。2014 年,Dong 等^[10-11]提出 SRCNN 和 FSRCNN 模型,开始利用 CNN 进行超分辨率重建,但随着网络加深,训练困难加大。2015 年,He 等^[31]提出 ResNet 模型,解决了训练问题。2016 年,Kim 等^[12]提出更深层的网络 VDSR,通过堆叠 20 层残差网络提高了重建图像质量。2017 年,Lim 等^[13]提出更宽的网络 EDSR,将 ResNet^[31] 模块扩展到 256 个通道,大大加深和加宽了网络结构,进一步提升了超分辨率重建效果。2018 年,Zhang 等^[15]提出 RCAN 模型,创新性地采用深度残差结构提取全局特征,并配合通道注意力机制优化网络,显著提高了重建细节的清晰度。同年,Haris 等^[14]提出 DBPN 模型,通过反投影机制和深度残差结构提高重建效果。但这些模型参数量大,数据不足时会出现过拟合。2019 年,Hui 等^[16]提出 IMDN 模型,创新性地构建金字塔残差网络提取图像的多尺度信息。2020 年,考虑到模型复杂度,Liu 等^[17]提出 RFDN 模型,使用反复堆叠残差区块的轻量级网络结构,在降低参数量的同时保持重建

效果。但这些方法在海洋流速场数据边缘恢复方面仍有不足。2020 年,Yang 等^[19]提出基于 Transformer 的 TTSR 算法,首次将 Transformer 引入图像超分领域,极大地提高了重建质量。2021 年,Liang 等^[20]提出 SwinIR,采用 Swin Transformer^[32] 捕捉图像全局上下文信息,显著提升了重建效果,但是计算量很大。2022 年,ESRT^[21] 模型和 HNCT^[22] 模型被提出,其有机结合了 CNN 和 Transformer,并充分发挥两者的优势,在减少计算量的同时提高了重建效果。但在处理海洋流速场数据时,现有方法难以准确重建复杂的边缘细节。

2 SobelUnet 模型构建

针对以上问题,本文提出一种基于深度学习的超分辨率网络 SobelUnet,以期生成更准确和高质量的海洋流速场数据。如图 2 所示,横向虚线(cat)代表特征图的通道连接。其中,Ini 表示洋流速度的初始状态特征,LR_{up} 表示低分辨率洋流速度图像的 4 倍上采样结果。将 Ini 和 LR_{up} 输入预训练的 VGG(vgg16) 模型,以提取 3 个尺度的语义特征,包括 Ini_{x4}、Ini_{x2}、Ini_{x1} 和 LR_{upx4}、LR_{upx2}、LR_{upx1}。IR 表示通过 VGG 从 Ini 和 LR_{up} 提取的多尺度特征,F_{in} 表示 F_{mr1}、F_{mr2}、F_{mr3} 和 F_{mr4} 中的一个特征,MSFM、RSAM 分别表示多尺寸多语义融合模块和残差 Sobel 卷积注意力模块。MR 模块包含 MSFM 和 RSAM 模块。SobelUnet 网络由多尺度特征提取模块(MR)和初始态模块(左下角,VGG 加上 Ini)构成。其中,MR 模块包含多语义特征融合模块和残差 Sobel 卷积注意力模块。下面首先介绍 SobelUnet 的关键模块,然后描述损失函数构成。

2.1 网络结构

2.1.1 初始态模块

为提供充足的语义信息和多尺度纹理特征,本文在 SobelUnet 模型的初始态模块中设计了一种方法,通过分析多年海洋流速场数据的时序矩阵计算统计最小值,获得反映海陆分布基础纹理的海洋流速场矩阵表达,从而提取海




Fig. 2 Structure of SobelUnet model

图 2 SobelUnet 模型结构

海洋流速场数据中的海陆边界等关键细节信息。由于许多海陆边界等关键特征是相对稳定的,可以较大程度上提供有利于重建的纹理信息。另外,本文将初始态纹理特征输入预训练的卷积神经网络 VGG 中,以获得不同语义粒度的多尺度特征表达。该方式进一步丰富了模型中的纹理表示,使其可以适应不同尺度下的特征变化,从而提高了重建结果的鲁棒性和准确度。如图 3 所示,初始态特征中包含了丰富的海陆边界等重要纹理信息。

与其他输入的海洋流速场低分辨率图不同的是,初始态海洋流速场图 Ini 会比 BICUBI 图更加平滑,很多内部小细节被消除,但大块边缘细节得到保留,从而为后续重建提供了充分的细节信息。初始态特征经过预训练的 VGG 可提取出多个尺度的语义特征,具体过程为:

$$Ini_{x1}, Ini_{x2}, Ini_{x4} = VGG(Ini) \quad (1)$$

其中, $VGG()$ 函数代表预训练的 VGG, 其中 Ini_{x1} 、 Ini_{x2} 、 Ini_{x4} 是 Ini 经 VGG 三层 $relu3_1$ 、 $relu2_1$ 、 $relu1_1$ 提取出的 3 种尺度语义特征。综上所述,尽管初始态特征与真实数据存在一定差异,但初始态特征为重建提供了丰富的信息,有利于海洋流速场图重建。

2.1.2 多尺寸多语义融合模块

为获取海洋流速场数据更丰富的多尺度特征,本文在 SobelUnet 模型中设计了多语义特征融合模块 (MSFM)。




Fig. 4 Structure of MSFM module

图 4 MSFM 模块结构

与普通卷积层相比,MSFM 模块的创新之处在于其采用多分支结构和跨层特征融合的设计,以获取海洋流速场数据更丰富的多尺度特征表达。每个分支中的卷积操作和激活函数均经过精心设计,以充分提取给定尺度下的海洋流速场特征信息。此外,通过 $concat$ 操作融合不同网络层的特征图,MSFM 模块增强了对多粒度语义信息的聚合与学习。该设计可较大程度地保留海洋流速场的关键纹理细节。其数学表示如下:

$$F_1 = ConR(C(F_{in}, IR)) \quad (2)$$

$$F_2 = ConR(C(F_{in}, F_1)) \quad (3)$$

$$F_{out} = C(F_{in}, F_2) \quad (4)$$

其中, $ConR()$ 函数代表卷积和 ReLU 激活函数, $C()$ 函数代表 $concat$ 特征融合, F_{in} 和 IR 是输入特征矩阵, IR 是不同尺寸的初始态或低分辨率特征图, Ini 和 LR_{up} 通过预训练的 VGG 模型分别提取 3 种尺度的语义特征。中间特征 F_1 和 F_2 在过程中被计算出来, F_{out} 是输出特征。这种多分支和跨层设计增强了模型对海洋流速场多尺度特征的表示与利用,提升了对关键纹理细节的保留能力。




Fig. 3 Effect image of the ISM module

图 3 ISM 模块效果图

如图 4 所示, C 代表特征拼接, $ConR$ 代表卷积和激活操作。其中,MSFM 模块包含多个卷积操作、跨层特征拼接及激活函数。首先,串联的多组卷积可扩大感受野,提取不同尺度的特征信息。其次,通过跨层级拼接初始态和低分辨率特征图,网络可以同时学习各种语义粒度下的海洋流速场特征表达。最后,激活函数的引入增强了非线性拟合能力,提高了模块的鲁棒性。

2.1.3 残差 Sobel 卷积注意力模块

为了增强生成海洋流速场数据图像的边缘信息与纹理细节,该模型引入 Sobel 算子注意力模块。该模块在图像处理中扮演着重要角色。如图 5 所示, XY 代表水平和垂直梯度变量, M 代表相应元素的乘法运算, S 代表累加和求和函数, Q 代表开根式函数, A 代表加法运算。其中, Sobel 卷积操作包括两个卷积层,首先进行乘法、累加操作,然后使用平方根和 Sigmoid 激活函数等,这一系列操作有助于提升海洋流速场图像生成任务中边缘检测的精度与纹理细节的保留能力。Sobel 卷积运算是一种高效的边缘检测机制,可以从海洋流速场图像中提取关键的高频边缘信息,这对于准确获取海洋流速场边界至关重要。Sobel 算子注意力模块不仅可以强化边缘,而且可以通过乘法操作 M 进行区域加权,基于 Sobel 卷积结果选择性地增强海洋流速场边缘。同时,加法连接 A 将增强边缘特征与原始特征图的融合,得到更丰富的特征表达。

相较于传统卷积注意力机制, Sobel 算子模块能够通过梯度约束机制实现更精细的控制。其中,过程函数可表




Fig. 5 Structure of RSAM module

图 5 RSAM 模块结构

示为:

$$F_{R1} = \text{ConR}(F_R) \quad (5)$$

$$F_{sobel} = \text{SobelCon}(F_R) \quad (6)$$

$$F_S = \text{sigmoid}(F_{sobel}) \quad (7)$$

$$F_{out} = M(F_{R1}, F_S) + F_R \quad (8)$$

其中, $\text{SobelCon}()$ 代表卷积化的 Sobel 算子, M 函数代表乘法操作, $\text{sigmoid}()$ 代表激活函数, 将特征的数值范围重新映射到 0~1 之间。 F_R 是输入矩阵, F_{out} 是输出矩阵, F_{sobel} 是经过 Sobel 算子卷积后得到的特征矩阵, F_{R1} 和 F_S 是中间矩阵。 F_S 是权重系数矩阵, F_{R1} 是注意力机制中的 V , 构成了注意力机制。该模块充分发挥了 Sobel 卷积在边缘检测方面的优势, 结合元素运算和残差连接, 实现了对海洋流速场关键边缘和纹理的有效强化。其中, 过程函数可以表示为:

$$XY = \text{ConR}(F_R) \quad (9)$$

$$F_{sobel} = \text{ConR}(Q(S(M(XY, XY)))) \quad (10)$$

其中, S 代表 SUM 操作, Q 代表 sqrt 开平方根操作, XY 代表 Sobel 算子横竖方向的梯度矩阵。从图 6 可以看出, 相较于 BICUBIC 插值结果, 残差卷积模块 (ResNet) 虽能部分恢复边缘纹理, 但整体效果仍不理想, 与原始边缘存在明显偏差, 而残差 Sobel 注意力模块 (RSAM) 生成的结果总体边缘效果更佳。

2.2 损失函数

SobelUnet 模型采用 L1 损失函数, 因为其对异常值的鲁棒性较好, 可帮助网络更好地适应局部特征的变化。需要注意的是, L1 损失函数的梯度较大, 可能导致模型容易忽略部分局部最小值。相比之下, L2 损失函数对异常值敏感, 梯度收敛较慢。

经过综合考虑, L1 损失函数更适合 SobelUnet 图像重建任务。其表达式为:

$$F_{rec} = \|I_{SR} - I_{HR}\|_1 \quad (11)$$

其中, I_{SR} 、 I_{HR} 分别代表网络生成的矩阵和相应的真实矩阵。

3 实验条件

3.1 数据集

海洋流速场数据集来源于海洋环流预报模型 HYCOM




Fig. 6 Comparison of normal residual convolution module with RSAM module

图 6 普通残差卷积模块与 RSAM 模块对比

的模拟结果, HYCOM 是由美国海洋预报中心开发的混合坐标全球海洋环流模型^[33]。HYCOM 可以提供丰富的三维海洋物理变量信息, 如海水温度、盐度、密度、流速、混合层深度、海面高度、温跃层深度、上升流速以及海冰密集度等。本文选取 HYCOM 中代表 0 m 水深层面的海洋流速场数据集, 时间范围为 2017 年 1 月 1 日—2019 年 12 月 31 日, 每日一个时次。空间坐标系为经纬度, 覆盖经度 $0^\circ \sim 360^\circ$ 、纬度 $90^\circ \text{S} \sim 90^\circ \text{N}$, 采用 $1/12^\circ \times 1/12^\circ$ 的均匀经纬网格分辨率。流速的数值范围为 $-3.963 \sim 4.119 \text{ m/s}$ 。数据集整体呈矩阵形式, 尺寸为 $4\,500 \times 3\,251$, 其中 4 500 为经度方向网格点数, 3 251 为纬度方向有效网格点数。将数据集随机采样后划分为训练集、验证集和测试集, 采样比例为 10:1:3。训练集选取 2017—2019 年前 30 个月的数据, 验证集和测试集分别采用 1 个月和最后 3 个月的数据, 测试集共包含 90 张图像。此外, 从 HYCOM 中随机抽取 100 张海水温度图像和 100 张海面高度图像, 并在其他物理变量上对模型进行扩展测试。为提取初始态特征, 通过分析多年海洋数据最小值得到代表海陆边界纹理的初始特征矩阵。

3.2 实验细节

本文在 NVIDIA GeForce RTX3090 GPU 基于 PyTorch 实现 SobelUnet 模型, 使用双三次插值生成低分辨率输入,

并采用随机数据增强策略。为了增强训练数据,本文对高分辨率和低分辨率图像进行了随机翻转、旋转和裁剪操作。采用随机抽样的方式构建训练集,其中 batch-size 设置为 6,总共进行 300 000 次迭代训练,每经过 2 000 次迭代后进行一次指标测试。使用 Adam 优化器,并将学习率设置为 $1e-4$,重建损失使用 L1 损失。为了评估超分辨率输出的性能,使用 MAE、MSE、PSNR 和 SSIM 等指标对真实数据矩阵进行评估。输出和输入都是两个通道的图像。在进行各种模型对比实验时,保持相同的优化器、学习率、输入通道和尺寸等条件,以确保实验的公平性。表 1 给出了残差 Sobel 注意力模块(RSAM)的网络结构细节,其中输入输出通道数、卷积核大小、步幅和填充方式分别用字母(i, o, k, s, p)表示,与图 5 中的 RSAM 模型结构相对应。

Table 1 Network structure parameters of the RSAM
表 1 RSAM 网络结构参数

层名	参数设置	输入特征	输出特征
ConR_0	$i=64, o=64, k=3, s=1, p=1$	F_R	XY
ConR_1	$i=1, o=64, k=3, s=1, p=1$	$Q(S(M(XY, XY)))$	F_{sobel}
Sigmoid		F_{sobel}	F_S
ConR_2	$i=64, o=64, k=3, s=1, p=1$	F_R	F_{R1}
Output		$M(F_S, F_{R1}) + F_{R1}$	F_{out}

4 实验结果与分析

4.1 评价指标

在海洋流速场数据降尺度中,本文使用以下指标进行模型性能的评估。

(1) MAE (Mean Absolute Error) 考虑了每个像素的误差,可以较好地评估整体图像的重建质量,而不是只关注部分区域。其表达式为:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (12)$$

其中, MAE 度量了模型预测值 y_i 与真实值 $\hat{y}_i$ 之间的平均绝对误差。该值越小,表示模型的预测越准确。

(2) MSE (Mean Squared Error) 可以衡量图像的整体重建误差。其表达式为:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (13)$$

其中, MSE 度量了模型预测值与真实值之间的平均平方误差。与 MAE 类似,该值越小越好。

(3) PSNR (Peak Signal-to-Noise Ratio) 主要关注图像的失真程度,适用于需要精确度和灵敏度的场景。其表达式为:

$$PSNR = 10 \cdot \log_{10} \left(\frac{\max pixel value^2}{MSE} \right) \quad (14)$$

其中, PSNR 通常用于图像质量评估,表示图像信号的峰值信噪比。PSNR 值越高,图像质量越好。

(4) SSIM (Structural Similarity) 关注图像的结构相似性,适用于需要保留图像细节和结构的场景。其表达

式为:

$$SSIM = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (15)$$

其中, μ_x, μ_y 分别为两幅图像的均值, σ_x, σ_y 为标准差, σ_{xy} 为协方差。

为验证 SobelUnet 的有效性,针对海洋流速场数据集,采用定量和定性指标将本文方法与多种方法的检验结果进行比较,包括基于 CNN 的 SRCNN^[10]、EDSR^[13]、IMDN^[16] 模型,以及基于 Transformer 的 HNCT^[22]、ESRT^[21] 模型。为了保证公平性,本文使用这些方法发布的官方代码,在相同的框架、学习率、优化器等设置下重新进行训练测试。

4.2 定量比较

与其他超分任务一样,本文采用 MSE、MAE、PSNR 和 SSIM 作为评价指标。表 2 显示了 SobelUnet 和其他多个方法在海洋流速场测试集上的定量结果,最佳结果以粗体显示。从评价指标数值可以看出, SobelUnet 在测试集上表现最佳,具有最小的 MSE、MAE 和最大的 PSNR、SSIM,意味着其输出结果在像素级误差和结构相似性上最接近真值。综上,可以得出结论, SobelUnet 在测试集上取得了较好的重建效果,相较于 BICUBIC、SRCNN、EDSR、RFDN、IMDN、HNCT 和 ESRT 等方法, SobelUnet 在海洋流速场数据重建上具有明显优势。这主要源自 SobelUnet 独特的网络结构设计,融合了 Unet、多尺度、初始态、Sobel 算子以更准确地捕捉海洋流速场数据的细节和纹理信息。该设计使 SobelUnet 可以高效、准确地重建地表特征,评测结果验证了 SobelUnet 在实际中的应用价值。

Table 2 Comparison of quantitative experimental results

表 2 实验定量结果比较

方法	MSE	MAE	PSNR	SSIM
Bicubic	6.097 4e-4	1.100 2e-2	50.293	0.989 57
SRCNN ^[10]	9.502 2e-4	2.371 6e-2	48.322	0.959 14
EDSR ^[13]	3.458 7e-4	8.988 3e-3	52.626	0.993 37
RFDN ^[17]	5.139 4e-4	1.299 8e-2	50.995	0.988 92
IMDN ^[16]	3.938 9e-4	9.514 3e-3	52.167	0.992 73
HNCT ^[22]	3.658 6e-4	8.838 7e-3	52.483	0.993 25
ESRT ^[21]	4.074 0e-4	9.212 6e-3	52.396	0.992 54
SobelUnet(Ours)	3.133 0e-4	8.244 7e-3	53.171	0.994 13

图 7 比较了 SobelUnet 与 SRCNN、EDSR、IMDN、RFDN、HNCT 和 ESRT 等方法在海洋流速场数据集上的 PSNR 和 SSIM 指标趋势。结果显示,各模型都能快速收敛,但 CNN 基础模型(SRCNN、EDSR、RFDN 等)存在较大波动。而 SobelUnet 不仅收敛速度快,指标波动也最小,整体表现最优。图 7(c)、(d) 多分辨率下的指标验证实验进一步证实了 SobelUnet 的指标始终优于其他模型,充分验证了 SobelUnet 在该数据集上的应用优势。

4.3 定性评估

在对海洋流速场测试数据集的评估中,将 SobelUnet 方法与 BICUBI、SRCNN、EDSR、IMDN、RFDN、HNCT 等方法进行比较,并展示了可视化结果。为评估不同方法在复




Fig. 7 Performance comparison of different methods

图7 不同方法性能比较

杂海洋流速场景中的恢复能力,本文选取多个具有代表性的局部图像样本进行定性分析,并采用更直观的灰度图进行结果展示。如图8所示,与GT(Ground Truth)相比,双三次插值法(Bicubic)生成的图像过于平滑,边界和纹理细节损失严重;SRCNN和RFDN模型在边缘和纹理恢复上也较为不足;EDSR对复杂边界的重建能力有限;HNCT模型虽保持了较好的全局结构,在局部细节生成上仍有一定缺陷。然而,SobelUnet生成图像的视觉保真度有所改善,特别是在海陆交界等复杂高频区域,SobelUnet的恢复效果更佳。这主要归因于SobelUnet中的初始态模块提供了可靠的纹理先验,残差Sobel注意力模块强化了关键的边缘信息,以及多语义特征融合模块综合了不同尺度的空间信息。这些模块的协同设计使SobelUnet可以更准确地恢复海洋流速场数据的细节和结构。综上所述,SobelUnet在海洋流速场测试数据集上的表现不仅在视觉上保真度高,而且能更好地保留结构和纹理细节。这些优势使得本文方法在处理海洋流速场数据时具有更好的适应性。

4.4 消融实验

SobelUnet在海洋流速场验证集上进行消融实验,以量化验证SobelUnet不同模块的效果,结果如表3所示。当移除残差Sobel卷积注意力模块,使用普通残差卷积时,PSNR指标下降了0.46,SSIM下降了0.002 54,MSE增加了0.781 4e-4,MAE增加了1.625 2e-3,说明Sobel注意力机制可以更好地捕捉场景关键的边缘信息,提升恢复质量。当

移除初始态模块时,PSNR下降了0.61,SSIM下降了0.002 59,MSE增加了0.737 8e-4,MAE增加了1.621 3e-3,验证了引入初始态特征模块可获得稳定纹理先验的效果。用普通卷积组替换多语义融合模块后,PSNR下降了0.44,SSIM下降了0.002 49,MSE增加了0.754 4e-4,MAE增加了1.623 4e-3,证明了多语义特征聚合可以更好地恢复场景细节。

4.5 扩展实验

海洋模型HYCOM数据集中的主要物理属性,如海水温度和海面高度等,在海陆边缘细节上表现出类似的特征。为评估SobelUnet模型对异构海洋物理量的迁移学习能力,使用HYCOM提供的海水温度和海面高度两个测试集对模型进行测试,以下将展示测试输出效果图。图9、图10对海面高度和海水温度两个物理量进行重构,本文模型在还原边缘细节和内部纹理方面效果较好,近似于原始数据,说明SobelUnet模型具有较强的泛化学习能力,不仅可以处理HYCOM数据集中单一的物理属性,而且可以扩展到处理HYCOM其他主要的物理属性。

5 结语

本文提出一种基于深度学习的SobelUnet模型,致力于海洋流速场数据的超分辨率重建任务。SobelUnet通过结合初始态模块、多语义特征融合模块以及残差Sobel注




Fig. 8 Qualitative comparison of different methods

图8 不同方法定性比较

Table 3 Ablation experiments

表3 消融实验

方法	MSE	MAE	PSNR(dB)	SSIM
RSAM(w/ResNet)	3.880 7e-4	8.608 1e-3	52.93	0.993 10
ISM(w/)	3.838 1e-04	8.604 2e-03	52.78	0.993 05
MSFM(w/)	3.853 7e-4	8.606 3e-3	52.95	0.993 15
SobelUnet(Ours)	3.099 3e-4	6.982 9e-3	53.39	0.995 64




Fig. 9 Local rendering of sea surface height

图9 海面高度局部效果图

意力模块,成功捕捉并重建了海洋流速场数据中的关键海陆边缘细节信息,提高了数据从低分辨率转换到高分辨率时的信息恢复精度和结构完整性。实验结果显示,相比BICUBIC插值和其他主流的深度学习模型,SobelUnet在MSE、MAE、PSNR和SSIM指标上均表现出优势,能够更准确、细致地重建海洋流速场图像。此外,对海面高度和海水温度等其他数据集的扩展测试也验证了SobelUnet在不




Fig. 10 Local rendering of seawater temperature

图10 海水温度局部效果图

同物理属性数据上具有较好的泛化能力。综上,SobelUnet为海洋动力学和气候研究领域提供了一种高效的超分辨率重建方法,具有较高的应用价值。

参考文献:

- [1] DU Y, LIN Z Q, ZHUANG S J, et al. Spatial downscaling of GPM satellite precipitation products in the Yangtze River Basin, China[J]. Remote Sensing Technology and Application, 2023, 38(3): 697-707.
杜懿,林泽群,庄胜杰,等. GPM 卫星降水产品在长江流域的空间降尺度研究[J]. 遥感技术与应用, 2023, 38(3): 697-707.
- [2] XU Y, GUO Z D, PAN Y C, et al. Interpolation method of satellite-ground collaborative precipitation and its applicability[J]. Chinese Journal of Agrometeorology, 2023, 44(8): 721-734.
徐勇,郭振东,盘钰春,等. 基于星地协同的降水数据插值方法及其

- 适用性[J]. 中国农业气象, 2023, 44(8): 721-734.
- [3] JIANG X W, HE X Q, LIN M S, et al. Advances in marine satellite remote sensing technology in China[J]. Marine Sciences, 2019, 41(10): 113-124.
- 蒋兴伟, 何贤强, 林明森, 等. 中国海洋卫星遥感应用进展[J]. 海洋学报, 2019, 41(10): 113-124.
- [4] WUNSCH C, STAMMER D. Satellite altimetry, the marine geoid, and the oceanic general circulation[J]. Annual Review of Earth and Planetary Sciences, 1998, 26(1): 219-253.
- [5] SHEPARD D. A two-dimensional interpolation function for irregularly-spaced data[C]//Proceedings of the 1968 23rd ACM National Conference, 1968: 517-524.
- [6] FRANKE R. Scattered data interpolation: tests of some methods[J]. Mathematics of Computation, 1982, 38: 181-200.
- [7] BAHRAMI M, FOROUZANFAR M. Sleep apnea detection from single-lead ECG: a comprehensive analysis of machine learning and deep learning algorithms[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-11.
- [8] BAI H, MING X S, LIU Q H, et al. Downscaling study of GPM satellite precipitation data in the Yellow River Basin based on the MGWR model[J]. Arid Land Geography, 2023, 46(7): 1052-1062.
- 柏荷, 明义森, 刘启航, 等. 基于MGWR模型的黄河流域GPM卫星降水数据降尺度研究[J]. 干旱区地理, 2023, 46(7): 1052-1062.
- [9] LEPCHA D C, GOYAL B, DOGRA A, et al. Image super-resolution: a comprehensive review, recent trends, challenges and applications[J]. Information Fusion, 2023, 91: 230-260.
- [10] DONG C, LOY C C, HE K, et al. Learning a deep convolutional network for image super-resolution[C]//Zurich: IEEE International Conference on Computer Vision Workshop, 2014.
- [11] DONG C, LOY C C, TANG X. Accelerating the super-resolution convolutional neural network[C]// Amsterdam: European Conference on Computer Vision, 2016.
- [12] KIM J, LEE J K, LEE K M. Accurate image super-resolution using very deep convolutional networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 1646-1654.
- [13] LIM B, SON S, KIM H, et al. Enhanced deep residual networks for single image super-resolution[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops, 2017: 136-144.
- [14] HARIS M, SHAKHNAROVICH G, UKITA N. Deep back-projection networks for super-resolution[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 1664-1673.
- [15] ZHANG Y L, LI K P, LI K, et al. Image super-resolution using very deep residual channel attention networks[C]//Proceedings of the European Conference on Computer Vision, 2018: 286-301.
- [16] HUI Z, GAO X, YANG Y, et al. Lightweight image super-resolution with information multi-distillation network[C]//Proceedings of the 27th ACM International Conference on Multimedia, 2019: 2024-2032.
- [17] LIU J, TANG J, WU G. Residual feature distillation network for lightweight image super-resolution[C]//Glasgow: European Conference on Computer Vision, 2020.
- [18] LEDIG C, THEIS L, HUSZÁR F, et al. Photo-realistic single image super-resolution using a generative adversarial network[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 4681-4690.
- [19] YANG F, YANG H, FU J, et al. Learning texture transformer network for image super-resolution[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 5791-5800.
- [20] LIANG J, CAO J, SUN G, et al. Swinir: image restoration using swin transformer[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021: 1833-1844.
- [21] LU Z, LI J, LIU H, et al. Transformer for single image super-resolution[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 457-466.
- [22] FANG J, LIN H, CHEN X, et al. A hybrid network of CNN and transformer for lightweight image super-resolution[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 1103-1112.
- [23] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems, 2017: 6000-6010.
- [24] LIN T Y, WANG Y X, LIU X Y, et al. A survey of transformers[J]. AI Open, 2022, 3: 111-132.
- [25] FOURNIER Q, CARON G M, ALOISE D. A practical survey on faster and lighter transformers[J]. ACM Computing Surveys, 2023, 55: 1-40.
- [26] CAI J, ZENG S Q. Lightweight image super-resolution reconstruction using multi-scale upsampling method[J]. Software Guide, 2023, 22(4): 168-174.
- 蔡靖, 曾胜强. 多尺度上采样方法的轻量级图像超分辨率重建[J]. 软件导刊, 2023, 22(4): 168-174.
- [27] WANG W, XU J W. Research on image super-resolution method based on GAN[J]. Software Guide, 2019, 18(6): 181-183.
- 王旺, 徐俊武. 基于GAN的图像超分辨率方法研究[J]. 软件导刊, 2019, 18(6): 181-183.
- [28] PAN Z H, ZHU J, CHI X Y, et al. An image super-resolution model based on feature fusion and attention mechanism[J]. Application Research of Computers, 2022, 39(3): 884-888.
- 盘展鸿, 朱鉴, 迟小羽, 等. 基于特征融合和注意力机制的图像超分辨率模型[J]. 计算机应用研究, 2022, 39(3): 884-888.
- [29] CHEN J L, PENG Y B, LI N. Single image super-resolution reconstruction network based on dual learning strategy[J]. Application Research of Computers, 2021, 38(7): 2235-2240.
- 陈金玲, 彭艳兵, 李念. 基于对偶学习策略的单图像超分辨率重建网络[J]. 计算机应用研究, 2021, 38(7): 2235-2240.
- [30] HU G P, CHEN Z Y, WANG X M, et al. Image super-resolution based on deep residual U-Net with attention mechanism[J]. Application Research of Computers, 2021, 38(4): 1271-1276.
- 胡高鹏, 陈子鑒, 王晓明, 等. 基于深度残差反投影注意力网络的图像超分辨率[J]. 计算机应用研究, 2021, 38(4): 1271-1276.
- [31] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [32] LIU Z, LIN Y, CAO Y, et al. Swin transformer: hierarchical vision transformer using shifted windows[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021: 10012-10022.
- [33] CHASSIGNET E P, HURLBURT H E, SMEDSTAD O M, et al. The HYCOM (hybrid coordinate ocean model) data assimilative system[J]. Journal of Marine Systems, 2007, 65: 60-83.

(责任编辑:黄健)