

CUI Yide, WANG Sheng, YU Yang, LIU Guihong, MA Wentao, HUANG Yan, YANG Tao, YANG Xiaofeng. Shallow-water Bathymetry Mapping from Satellite SAR Imagery Using Deep Learning with Multiple Feature Inputs (in Chinese). *Chinese Journal of Space Science*, 2025, **45**(2): 424–436. CSTR:32142.14.cjss.2024–0158. DOI:10.11728/cjss2025.02.2024–0158

基于多特征输入深度学习的浅海水下 地形 SAR 卫星遥感*

崔宜德^{1,2} 汪 胜¹ 于 暘¹ 刘桂红¹
马文韬¹ 黄 岩¹ 杨 涛^{1,2} 杨晓峰³

1(中国科学院空天信息创新研究院 遥感与数字地球全国重点实验室 北京 100101)

2(中国科学院大学 北京 100049)

3(南京大学空间地球科学研究院 苏州 215163)

摘 要 面向浅海地形高精度反演需求, 改善光学遥感手段普遍存在的水质依赖性强和测深范围有限的问题, 研究以 Sentinel-1 卫星合成孔径雷达 (SAR) 遥感影像为数据, 提出了一种多特征输入的深度学习浅海地形反演模型. 研究数据包括 2024 年中国海南岛东北部海域的 6 景 SAR 影像, 其中 4 景用于模型训练, 2 景用于模型测试, 参考真值为 ETOPO 的 Ice surface elevation geotiff 数据. 反演模型由 1 个卷积层、2 个 BottleNeck 模块和 1 个全连接层构成. 实验结果表明, 模型在训练集上的均方根误差和平均绝对百分比误差分别为 1.57 m 和 6.56%, 在测试集上为 1.95 m 和 11.55%, 水深最大探测范围为 49.05 m. 此外, 对于 2 景不同海况条件下的影像, 其水深反演结果接近, 表明本文模型具有较好的鲁棒性, 可为浅海水下地形遥感探测提供新技术支持.

关键词 合成孔径雷达, 浅海地形反演, 深度学习, 多特征输入

中图分类号 P71

Shallow-water Bathymetry Mapping from Satellite SAR Imagery Using Deep Learning with Multiple Feature Inputs

CUI Yide^{1,2} WANG Sheng¹ YU Yang¹ LIU Guihong¹
MA Wentao¹ HUANG Yan¹ YANG Tao^{1,2} YANG Xiaofeng³

1(State Key Laboratory of Remote Sensing and Digital Earth, Aerospace Information Research Institute,
Chinese Academy of Sciences, Beijing 100101)

2(University of Chinese Academy of Sciences, Beijing 100049)

* 国家重点研发计划项目资助 (2023YFB3907700)

2024-11-08 收到原稿, 2024-12-17 收到修定稿

©The Author(s) 2025. This is an open access article under the CC-BY 4.0 License
(<https://creativecommons.org/licenses/by/4.0/>)

3(Institute of Space Earth Science, Nanjing University, Suzhou 215163)

Abstract In response to the demand for high-precision shallow sea topography inversion and to improve the limitations of optical remote sensing, this study proposes a deep-learning model utilizing multiple feature inputs to inverse shallow sea topography from spaceborne Synthetic Aperture Radar (SAR) images. For the data acquisition and dataset construction, six high-resolution Sentinel-1 dual-polarization SAR images covering the waters northeast of Hainan Island of China in 2024 under different phases and sea conditions were collected, among which six images were used for model training, while the rest were used for testing. The reference depth was obtained from ETOPO. In dataset creation, SAR images are segmented into 8×8 sub-images. The model input is designed to consist of 8 feature variables, which involve the VV polarization backscattering coefficient σ_0^{VV} , radar incidence angle θ , geography information (latitude and longitude), and marine dynamic environmental parameters. The model output is reference depth from ETOPO with spatial consistency. The deep learning network comprises a convolutional layer, two BottleNeck modules from ResNet, and a fully connected layer. The final model performances in retrieving shallow water depth are shown as follows: For the training set, the model achieved a Root Mean Square Error (RMSE) of 1.57 m, and the average absolute percentage error is 6.56%, with the maximum detectable water depth reaching 49.05 m. The model presented with an RMSE of 1.95 m, and the average absolute percentage error is 11.55% for the testing dataset. Additionally, there is little difference between the two scenes with different temporal and sea conditions, indicating that the model is stable and robust. Thus, the proposed model was based on the brightness patterns observed in SAR imagery, which can detect shallow-water depths up to 50 m with high precision.

Key words Synthetic Aperture Radar (SAR), Shallow sea bathymetry, Deep learning, Multiple feature inputs

0 引言

浅海水下地形是近岸海域海洋经济开发、海洋资源利用以及海岸带军事活动等所需海洋信息的重要组成部分, 准确的浅海地形或水深信息对于沿海区域的发展和海洋相关应用至关重要, 是环境可持续性和区域经济繁荣发展不可或缺的重要参考资料^[1,2]. 早期的水深测量主要依赖于测深杆或测深锤, 虽然简单直接, 精度较高, 但因多以船载平台开展测量, 难以进入受潮汐影响的浅滩区和水下礁石密布的区域^[3,4]. 随着科学技术的发展, 尤其是遥感探测手段的精进, 以多光谱/高光谱为代表的被动光学手段和以激光雷达为代表的主动光学手段逐渐发展为重要的水下地形探测手段^[5]. 一方面, 被动光学遥感的观测范围较广, 因此其多用于大范围水下地形测绘. 但是其易受天气、云层、日照条件、时间等环境因素影响, 测量精度和可测量深度受限. 另一方面, 激光雷达通常具备较高的测量精度, 但是其观测的面积较小, 难以实现大面积海域空间连续的水下地形探测^[6,7]. 随着遥感载荷在

探测分辨率和穿透力上的不断发展, 合成孔径雷达因其高空间分辨率、全天时全天候观测和不易受天气条件影响的独特优势, 逐渐成为研究水下地形的主要数据源之一.

在水下地形反演领域, 使用的数据源主要包括以激光雷达为代表的主动光学、以多光谱/高光谱为代表的被动光学和合成孔径雷达遥感, 基于不同的数据有研究开发了一系列反演模型. 在光学遥感领域, 沿海区域的光学浅海水下地形反演模型大致可分为三类: 光谱匹配模型、基于统计的模型和机器学习模型^[3,8-12], 且各种机器学习算法已经应用于水深探测和水下地形反演领域^[1,13]. 以上方法的前提必须有实测水深数据, 而在没有实测水深点的情况下, Liu 等^[14]提出可以利用多时相高分辨率的光学影像, 例如 Landsat-8, Sentinel-2, GF-2 等, 通过缩小比例的水深测绘方法完成大范围的浅海水深探测, 从清澈到浑浊水域都能得到较为准确的水深, 但是最大水深在 15 m 以内, 且对于超过特定深度的水体, 其水深估计可能会被低估^[14,15]. 尽管光学遥感测深技术在浅海水

深探测方面取得显著进展,但是其探测范围和精度受水体透明度、大气条件以及不同底质及生物光学特性等因素影响^[16].一般来说,被动式的多光谱/高光谱传感器的观测范围广,但水深探测范围有限且测量精度往往较低^[17];相比之下,主动式的激光雷达一般只能覆盖点和线的区域,但探测精度较高.因此,现有研究多采用主被动遥感结合的方式探测水下地形,这样既能实现大范围观测,又可以保证较高的探测精度.例如, Pacheco 等^[18]基于多波段对数线性模型和 Landsat-8 对岛礁周边海域浅海水域 (0~12 m) 进行水深反演,利用激光雷达测深数据对被动光学遥感水深反演算法进行优化,试验结果表明水深反演的平均误差为 0.2 m,中误差为 0.1 m. Legleiter 等^[19]结合 CASI 高光谱数据和机载激光雷达数据利用经验方法对两种不同水域类型进行水深反演研究,并对其反演深度和动态范围进行了评估,结果显示该方法在不同水域条件下具有良好的适应性和准确性. Xi 等^[20]使用 ICESat-2/ATLAS 数据对南海岛屿和礁石的浅水区域进行深度提取和精度评估. Hu 等^[21]提出了一种结合 ICESat-2 激光雷达数据和被动光学遥感图像的卫星测深技术,通过算法优化,有效提取海面和海底的光子点群,并基于改进的折射校正模型进行水深反演.

另外,利用 SAR 影像反演水下地形依赖于水下地形调制导致的海表面特征变化,然后基于规则条纹或明暗相间的条纹等图像特征间接反演水下地形^[22,23].当前基于 SAR 影像的水下地形探测方法主要分为三类:仿真反演模型、理论反演模型和涌浪反演模型^[24-27].其中,仿真反演模型和理论反演模型是根据雷达波、潮流和海底地形之间的相互作用来反演水深,但这两种模型都对复杂的物理过程进行了简化,探测精度较差^[28-31].而利用涌浪来反演水深的方法比较普遍,且精度相对较高.该方法利用水深与涌浪波长、方向和周期等参数之间的线性频散关系,通过单景 SAR、短时重复周期的 SAR 或多源融合的 SAR 数据来估计浅水深度^[32-35],但精度受波周期和参考水深的影响.为解决波周期不变对浅水深度探测影响的问题, Rong 等^[36]提出了一种基于 SAR 子孔径图像的浅海水下地形探测方法,利用子孔径图像引入的时间信息,得到波浪周期,再结合图像提供的波长信息探测水深,其反演得到的水深主要分布在 20 m 以下,与 GEBCO (General Bathymetric Chart

of the Oceans) 参考水深数据进行对比,水深反演的平均绝对误差 (Mean Absolute Error, MAE) 为 2.8 m,平均相对误差 (Mean Relative Error, MRE) 为 23.91%,均方根误差 (Root Mean Square Error, RMSE) 为 3.30 m.周期可变理论的引入,更好地改进了涌浪反演水深方法,然而最大探测水深依然在 30 m 以浅居多.基于涌浪方法来反演水深仅限于浅水区域,因此亟需一种新的探测方法可以实现 30 m 以深的水下地形探测.

深度学习作为当下流行的一种算法,广泛应用于海洋领域研究,成为监测中尺度海洋现象和反演海洋参量必不可少的工具.深度学习网络能够充分发挥 SAR 影像高空间分辨率的优势,提取其高维度特征信息,在台风、中尺度涡旋监测^[37]、海洋锋^[38]和海洋内波^[39]等典型海洋现象的监测与参数反演以及风场^[40]、流场、温度和盐度等基本海洋参量的反演^[41]中发挥着重要作用.因此,深度学习网络具备提取高分辨率 SAR 的细节信息与纹理特征的优势,能够通过构建高度复杂的模型来学习数据中的非线性关系,从而提供更为精确的预测和反演结果,为解决水深探测问题提供了可能^[3,42,43].近年来,深度学习模型应用在遥感图像反演水深的研究中且精度较高^[44,45],但大多都是基于光学影像,利用 SAR 图像的深度学习测深制图的方法较少.研究利用不同海况条件下的 Sentinel-1 SAR 数据,在考虑图像局部空间信息与相对位置关系前提下,提出一种基于多特征输入的深度学习水下地形探测方法,以子图作为输入,利用深度学习网络实现该区域 50 m 以浅水深的智能反演,建立了中国海南岛东北部海域浅海水下地形反演模型.

1 研究区域与数据

1.1 研究区域

如图 1 所示,研究选择中国海南岛东北部附近海域为研究区,区域包含罗伯半岛以及多个浅滩,经度范围为 110.542°E—110.997°E,纬度范围为 20.071°N—20.51°N,海域面积约为 2500 km².该海域的水深主要分布范围为 0~30 m,水深的整体变化较为平缓,但空间差异性较为显著.

1.2 Sentinel-1 A 数据

选择欧空局提供的高空间分辨率 Sentinel-




图 1 研究区域位置信息. (a) 区域概况, (b) 2024 年 6 月 8 日拍摄的研究区的一景 Sentinel-1 SAR 影像

Fig. 1 Location of the study area. (a) Optical image of the area, (b) Sentinel-1 SAR image of the study area taken on 8 June 2024

1 SAR 数据作为研究数据. 根据研究区域范围, 在 ASF Data Search^{*}上获取了 2024 年的 6 景 C 波段 IW 模式 VV/VH 极化 Sentinel-1 A GRDH 的 SAR 影像, 其空间分辨率约为 10 m, 观测幅宽为 250 km. 研究中, 将其中 4 景影像用于训练模型, 其余 2 景用于模型测试. 在雷达波长、入射角和各种海洋参数相同的条件下, VV 极化产生的回波信号一般要强于 HH 极化产生的回波信号, 水下地形调制产生的海面“明暗条纹”特征更加显著, 因此研究选择 VV 极化下的后向散射系数作为实验数据源^[24]. 通过对原始数据进行辐射定标、热噪声去除、地形校正、裁剪等预处理, 得到不同时相下的后向散射系数以及入射角信息. 此外, 不同时间和海况条件下的 SAR 图像的特征具有明显差异, 主要体现在是否存在明暗对比的条纹. 因此, 对 6 景 SAR 图像按照统一的最大值和最小值进行归一化处理, 将所有图像的灰度值调整至 0~1, 将 6 景 SAR 图像被拍摄的世界标准时间与该景图像绘制如图 2 所示.

1.3 风和流数据

一般情况下, 海面风速和海表流速会对海洋水动力产生影响, 海表面粗糙度发生变化, 进而导致 SAR 观测水下地形的回波信号存在差异. 研究表明, 流速越大, 水下地形越易被 SAR 观察到, 而海面风速

不能过高, 当其超过 $10 \text{ m}\cdot\text{s}^{-1}$ 时, 由风场引起的海面粗糙度过强, 则会掩盖由地形引起的雷达波异常^[22,24]. 因此, 研究在输入数据中引入了流场和风场来描述不同海况, 即分别选择 ERA5(ECMWF Reanalysis v5) 提供的 10 m 高度风和 HYCOM(Hybrid Coordinate Ocean Model) 提供的海面流场作为反演模型的辅助输入资料. 其中, 海表面风场由风速水平分量 (U) 和垂直分量 (V) 组成, 空间分辨率为 $0.25^\circ \times 0.25^\circ$, 时间分辨率为 1 h. 海表流场数据包含东西向流速和南北向流速数据, 其经度方向空间分辨率为 0.08° , 纬度方向空间分辨率为 0.04° , 时间分辨率为 1 h. 实验中选择对应 SAR 图像成像时间临近时刻 (11:00 UTC) 的数据代表其风场数据和流场数据, 并将获取的海表风场和流场数据按照试验区域进行裁剪, 得到对应的水平和垂直风分量以及东西向和南北向流速. 图 3 给出了研究区 2024 年 6 月 8 日的风场和流场资料, 白色箭头表示风向和流向.

1.4 水深参考真值

研究采用 ETOPO 全球数字高程模型 (DEM) 数据作为研究的水深参考真值, 该数据的空间分辨率为 15 弧秒, 约为 450 m. 图 4 给出了根据研究区域范围裁剪得到的参考水深数据, 可以看出该区域水深主要分布在 0~30 m. 对于整个区域而言, 水深分布呈

^{*} <https://search.asf.alaska.edu/>




图2 不同时间和海况条件下的 SAR 影像

Fig. 2 SAR images at different times and sea state conditions




图3 研究区域 2024 年 6 月 8 日的风场 (a) 和流场 (b) 数据 (白色箭头表示风向或流向)

Fig. 3 Wind field (a) and current field (b) information of the study area on 8 June 2024 (white arrows representing wind direction or current direction information)

现出四周浅中间深, 最大水深约为 80 m, 而且区域存在明显的水深变化, 从非常浅的水域到较深的水域都有分布. 研究中水深数据主要有两方面作用: 一是作为参考水深数据用于模型构建; 二是作为实测真值对浅海水深探测结果进行评估验证.

2 水深探测模型

2.1 数据集构建

在数据集构建过程中, 需要对数据进行筛选, 以

保证数据集质量. 数据筛选原则包含三点. ① 剔除了参考真值中水深值大于 0 的陆地区域, 确保模型专注于水深探测反演. ② 研究实验区域内的水深参考真值的统计结果表明, 该区域内大于 50 m 的水深数据样本极少, 无法通过简单的数据增强改变其在整个数据集中的占比, 因此研究剔除水深值大于 50 m 的区域, 专注于 50 m 以浅的水下地形反演. ③ 对于风场或流场数据缺失的样本进行了剔除, 以确保数据集的完整性和可靠性.




图 4 水深参考真值. (a) 试验区 ETOPO 水深插值结果, (b) 对应的水深分布直方图统计结果

Fig. 4 Reference water depth. (a) Interpolation result of ETOPO water depth in the test area, (b) the statistical result of the corresponding water depth distribution histogram

为了描述不同区域位置水深与后向散射系数 (σ_0^{VV}) 的非线性关系, 实验中对输入特征进行位置编码 (Position Encoding, PE), 用于描述切割之后的各子图之间的相对位置关系. 对于一张 512×512 的 σ_0^{VV} 特征图, 首先将其按行列切割成 4×4 的子图, 保证子图之间不重叠; 然后将每一张子图转化为 16×1 的向量, 将转换后的所有样本连接为一个序列, 得到序列大小为 $[16384, 1, 16]$; 随后进行位置编码计算, 先将每个向量视为位置编码输入的一个词 (Token), 因此序列长度为 16384, 继而按照

$$E_{p,2i} = \sin\left(\frac{p}{10000 \frac{2i}{d_{\text{model}}}}\right), \quad (1)$$

$$E_{p,2i+1} = \cos\left(\frac{p}{10000 \frac{2i}{d_{\text{model}}}}\right) \quad (2)$$

计算位置编码矢量 $\mathbf{E}$, 最后按照

$$\mathbf{F}_{\text{PE}} = \mathbf{F} + \mathbf{E} \quad (3)$$

将特征矢量 $\mathbf{F}$ 与位置编码矢量 $\mathbf{E}$ 相加, 得到编码之后的特征图矢量, 记为 $\mathbf{F}_{\text{PE}}$. 式中, p 表示 Token 在序列中的位置, $p=0,1,2,\dots,16$; $\mathbf{E}$ 为 Token 的位置矢量, $E_{p,2i}$ 表示这个位置向量中的第 i 个元素, i 表示奇数维度, $2i$ 表示偶数维度; d_{model} 表示 Token 的维度, 此处 d_{model} 为 16.

实验中需要对经纬度之外的 6 个特征进行编码, 位置编码的每个位置都有一个唯一的编码, 两个位置之间的关系可以通过其位置间的仿射变换来建模. 通过加入经纬度信息表征子图的绝对位置, 而加入位置

信息后的 $\mathbf{F}_{\text{PE}}$ 能够更好地表示子图之间的相对位置. 将子图进行编码后, 按照切割顺序拼接, 得到位置编码之后的特征图像.

为保证不同特征之间的一致性, 需要进行空间匹配, 研究中所有的输入数据均重采样至 100 m 的空间分辨率. 此外, 由于试验区的各类水深的样本数量分布不均, 尤其是 30 m 以深的样本数量极少, 为了平衡数据集中不同水深样本的分布, 研究对 30 m 以深的样本子图进行旋转以达到增强样本数量的目的. 最终, 研究构建了一个空间分辨率为 100 m, 包含 20764 组多通道 8×8 子图的数据集, 该数据集包含多种特征输入, 例如 SAR 的 VV 极化后向散射系数、SAR 雷达入射角、地理经纬度、风场和流场等特征.

2.2 浅海水下地形反演模型

图 5 给出了基于多特征输入和残差结构构建的浅海水下地形反演模型 (Multiple-features and Residual-blocks Based Water Depth Inversion Model, MR-WDI) 的网络框架. 模型的输入是后向散射系数、雷达入射角、经度、纬度、风速风向以及流速和流向特征图, 经过一系列卷积操作后输入最后的全连接层, 输出为对应子图像的实际水深值, 实验中使用的水深真值定义为子图水深的均值.

从图 5 可知, MR-WDI 模型的初始阶段采用 3×3 卷积核对于子图进行卷积操作, 以初步提取图像的空间特征并捕获其层次结构. 随后, 引入两个残差块, 其中每个残差块包含三个卷积层, 对于初步提取的特征先经过 1×1 的卷积, 然后再进行 3×3 的卷积, 最后




图 5 MR-WDI 模型结构

Fig. 5 MR-WDI model structure

再加一层 1×1 的卷积, 特征图深度加深, 通过引入跳跃连接来解决深层网络训练中的退化问题, 有助于梯度的流动并促进网络的训练. 这些层不仅调整了特征的维度, 增强了特征表示能力, 还可能引入非线性变换, 增强模型对复杂特征的学习能力.

通过这种设计, 特征图的深度被扩展至 512, 模型能够进行更深层次的特征学习. 为了控制模型的复杂性并防止过拟合, 特征图的深度随后被减少至 128. 在特征提取的最后阶段, 模型采用了平均池化层, 该层在降低特征图空间维度的同时, 有效保留了关键信息, 输出特征深度为 512, 最后通过一个全连接层, 完成变量之间的非线性映射. 这种网络设计不仅平衡了深度学习模型的复杂性和计算效率, 还有助于提高模型的泛化能力.

研究将数据集按 7:1:2 比例随机划分为训练集、测试集和验证集, 参考水深为对应子图水深均值, 用均方根误差计算损失, 使用随机梯度下降 (SGD) 作为优化器, 学习率设置为 0.00005, 动量为 0.9, 训练集的 batch_size 设置为 100, 测试集的 batch_size 设置为 50, 迭代 100 个 epoch 生成水深探测模型.

在这项研究中, 使用平均绝对误差 E_{ma} (MAE)、均方根误差 E_{rms} (RMSE)、平均绝对百分比误差 E_{map} (Mean Absolute Percentage Error, MAPE) 和决定系数 (R^2) 四个评价指标来综合评估水深探测误

差^[1,3,30,31], 即

$$E_{ma} = \frac{1}{n} \sum_{i=1}^n |d_i - r_i|, \quad (4)$$

$$E_{map} = \frac{100}{n} \sum_{i=1}^n \left(\left| \frac{r_i - d_i}{r_i} \right| \right), \quad (5)$$

$$E_{rms} = \sqrt{\frac{1}{n} \sum_{i=1}^n (d_i - r_i)^2}, \quad (6)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (d_i - r_i)^2}{\sum_{i=1}^n (\bar{r} - r_i)^2}. \quad (7)$$

式中, d_i 和 r_i 分别表示预测水深与参考水深, $\bar{r}$ 为参考水深的均值. 其中, MAE 提供了模型预测水深与真实水深之间误差的一个度量, 但不考虑误差的方向. MAE 越小, 表示模型预测精度越高; MAPE 提供了一个标准化的误差度量, 使得不同水深范围的反演误差可以进行比较; RMSE 不仅考虑了误差的大小, 还考虑了误差的方向, 并且对较大的误差给予了更大的权重. RMSE 越小, 表示模型预测精度越高; R^2 是衡量模型预测值与真实水深值之间线性关系强度的一个指标, 其越接近 1, 表示模型解释能力越强.

3 模型结果分析与验证

研究采用 MR-WDI 模型对 4 景不同时相和海况条件下的 SAR 数据进行 8×8 切图后训练, 得到的水

深反演结果 MAE 为 1.08 m, RMSE 为 1.57 m, MAPE 为 6.56%, 最大探测水深范围达到 49.05 m. 由于所得到的水深数据是通过切图求均值后插值计算得出的, 因此探测到整体区域的最大水深小于 49.95 m, 且由于大于 50 m 的水深点较少, 因此在计算误差时进行了剔除. 图 6 给出了在测试集上, 2 景测试数据结果为: 2024 年 7 月 2 日的一景 RMSE 为 1.95 m, MAPE 为 11.55%, 而 2024 年 6 月 8 日一景 RMSE 为 1.98 m, MAPE 为 11.86%, 2 景数据的水深反演误差接近, 说明模型鲁棒性好. 与 Bian 等^[27]提出的基于波浪波长、波浪方向、波浪周期等参数与水深的线性色散关系估算水深方法相比, 研究提出的 MR-WDI 模型不仅在水深探测范围上有所提升, 最大探测水深可达 49.05 m, 而且通过多时相数据的融合, 增强了模型对水深变化的捕捉能力, 在 2 景测试数据上显示出更好的鲁棒性, 且水深反演的 MAE 与 RMSE 优于 Rong 等基于 SAR 子孔径图像波浪的水深反演误差^[36]. 以上结果表明, MR-WDI 模型能够以高精度实现中国海南岛东北部 50 m 以浅水区域的水深反演.

浅海水下地形成像主要经过三个物理过程: 潮流场与水下地形的相互作用、潮流场与海表面波的相互作用、雷达波与海表面波的相互作用^[24,46]. 三个物理过程中的非线性相互作用影响了 SAR 海面后向散射, 最终反映在雷达影像上则是明暗对比的条纹. 因此,

雷达图像上的条纹特征信息对于深度学习网络的挖掘有很大影响. 此外, 子图大小选择影响着输入图像的特征多少, 也影响预测水深分辨率. 从模型输入图大小和条纹特征两个方面对模型性能进行分析.

3.1 模型输入对性能的影响

为研究模型输入对性能的影响, 针对 4 景中国海南岛东北部的训练数据, 分别切割成 4×4 , 8×8 , 16×16 大小的子图, 并将其输入模型中, 使用 2 景数据作为测试集, 并通过 4 个评价指标进行精度评估. 实验结果表明, 将图像作为输入考虑了周围图像信息, 且子图切割得越大, 包含的地形信息越丰富, 反演精度也越高.

表 1 和表 2 分别给出了 2024 年 6 月 8 日和 2024 年 7 月 2 日两景 SAR 数据在不同子图大小训练的模型的预测结果, 相比之下, 随着子图增加, 测试结果表现更好, 但两者之间的差异并不显著, 精度提升不大. 子图大小直接决定初始图像所包含的纹理特征信息, 对于 4×4 的一张子图, 其包含的信息较少, 通过卷积提取的特征信息有限, 随着子图增大, 相同卷积核大小会更好考虑图像的局部空间信息, 所以 4×4 子图的平均绝对百分比误差相对会较大, 但是对应的水深分辨率为 400 m, 相比于 8×8 和 16×16 大小的子图而言是有优势的, 所以测试结果差异不明显.

在样本数据集之外, 选取 2024 年 8 月 19 日的一景 SAR 数据, 在具备地形条纹特征情况下, 使用




图 6 MR-WDI 模型的测试结果. (a) 2024 年 7 月 2 日 SAR 的水深探测结果, (b) 2024 年 6 月 8 日 SAR 的水深探测结果

Fig. 6 Test results of the MR-WDI model, the color represents the depth point density. Depth detection results of the SAR on 2 July 2024 (a) and on 8 June 2024 (b)

4×4, 8×8, 16×16 子图训练的模型分别进行水深反演. 表 3 给出了不同子图大小模型水深预测结果, 三种模型预测能力相差不大, 子图越大, 精度有所提升但不显著. 然而考虑到水深预测分辨率问题和实际地形分布情况, 图 7 给出了三种模型的三维地形预测结果. 结果表明, 随着子图变大, 预测分辨率会降低, 即使和实际地形拥有一样的起伏变化趋势, 但是还原三维地形的细节也会有所损失. 针对本实验而言, 考虑预测精度以及实际地形分辨率问题, 最终选择 8×8 子图训练模型进行浅海地形探测.

因此, 相比于其他两种, 在研究中 8×8 子图可以达到更好的实验结果, 既能挖掘到 SAR 图像上的信息, 又可以保证分辨率. 与传统的点对点式模型预测水深相比, 以图作为输入考虑了像元点周围图像的纹理信息, 且切割子图越大, 包含地形信息越丰富, 反演精度越高, 但受影像与水深分辨率影响, 以及研究区域的不同, 最优子图大小选择不同.

3.2 SAR 图像特征对模型性能的影响

对原始数据进行 8×8 切图, 并用于模型训练, 在数据集之外选取了具有不同条纹特征的 2 景 SAR 数

据: 2024 年 3 月 28 日和 2024 年 8 月 19 日的各一景, 进行了浅海水深预测, 图 8 给出了两景数据的归一化雷达后向散射截面 (Normalized Radar Cross Section, NRCS), 并进行了最大最小值归一化. 由于海况影响, 3 月 28 日 SAR 图像中的地形特征被风浪等噪声干扰, 尽管如此, 图像中仍然可以观察到一些明暗对比的条纹. 相比之下, 8 月 19 日的 SAR 图像显示出更为明显的条纹特征. 根据图 4 的水深插值图, 8 月 19 日的一景 SAR 图像与水深分布基本一致, 在水深较浅或者水深变化较大的区域呈现出亮条纹特征, 水深较深的区域在图像上基本没有特征显示, 所以在 30 m 以上的深水区预测水深偏低, 误差较大 (见图 9); 而对于受海况条件影响比较大的 SAR 图像, 其条纹信息被掩盖, 导致图像上出现大面积比较暗的特征, 这些特征在模型中可能被误认为是噪声, 从而影响水深预测的准确性, 所以在水深预测结果上误差较大, 水深预测值在浅水区和深水区都偏低.

图 9 给出了 SAR 估计水深与参考水深之间的关系. 每个点代表一个数据样本, 颜色表示密度, 颜色越深表示数据点越密集. 结果给出了两幅 SAR 影像的

表 1 不同子图大小对 2024 年 6 月 8 日 SAR 数据的预测结果
Table 1 Predictions of different subimage sizes for SAR data on 8 June 2024

子图大小	MAE/m	MAPE/(%)	RMSE/m	R^2
4×4	1.42	12.31	2.26	0.96
8×8	1.31	11.86	1.98	0.97
16×16	1.26	10.97	2.05	0.98

表 2 不同子图大小对 2024 年 7 月 2 日 SAR 数据的预测结果
Table 2 Predictions of different subimage sizes for SAR data on 2 July 2024

子图大小	MAE/m	MAPE/(%)	RMSE/m	R^2
4×4	1.41	11.81	2.12	0.96
8×8	1.29	11.55	1.95	0.97
16×16	1.25	10.84	1.97	0.97

表 3 不同子图大小对 2024 年 8 月 19 日 SAR 数据的预测结果
Table 3 Predictions of different subimage sizes for SAR data on 19 August 2024

子图大小	MAE/m	MAPE/(%)	RMSE/m	R^2
4×4	1.39	12.42	2.32	0.96
8×8	1.29	11.70	1.96	0.97
16×16	1.24	11.02	2.07	0.97




图 7 研究区的三维水下地形分布. (a) 4×4 预测结果, (b) 8×8 预测结果, (c) 16×16 预测结果, (d) 参考水深数据
Fig. 7 Three-dimensional topography of the study area. (a) 4×4 prediction, (b) 8×8 prediction, (c) 16×16 prediction, (d) reference water depth data




图 8 不同海况下的 SAR 图像
Fig. 8 SAR images under different sea conditions

预测精度, 3月28日的 SAR 数据预测结果表现出较大的误差, 其中平均绝对误差为 2.19 m, 均方根误差为 2.61 m, 平均绝对百分比误差为 21.33%。如图 8(a) 所示, 该景 SAR 图像在浅水区和深水区, 因为 SAR 图像在这些区域的特征不够明显, 导致模型难以准确捕捉水深信息, 所以预测水深普遍偏低。对于 8月19日的 SAR 数据, 预测结果表现为: 平均绝对误差为 1.29 m, 均方根误差为 1.96 m, 平均绝对百分比误差为 11.70%, 该景 SAR 影像显示了较小的误差, 尤其是在浅水区和中等水深区域。对比可得, 具有明

显条纹且成像较好的 SAR 图像, 水深反演精度高, 对应的水深值也接近参考水深, 且反演水深精度较高的水深段位于 10~30 m, 在深水区预测结果均偏低, 与该区域实际水深分布有关。

4 结论与发展趋势

基于雷达海面后向散射强度与水深变化之间的相关性, 提出了一种基于多特征输入的深度学习水下地形探测模型 (MR-WDI 模型)。研究获取了 2024 年




图9 水深反演误差散点图

Fig. 9 Scatterplot of water depth inversion errors

不同海况条件下覆盖中国海南岛东北部海域的6景 Sentinel-1 卫星 SAR 影像, 其中4景数据被用于构建训练集, 其余2景数据则用于模型的测试. 实验数据集共包含8种特征参量, 分别是 VV 极化后向散射系数 (σ_0^{VV})、雷达入射角 (θ)、地理经纬度以及描述海况的海面风场 (风速和风向)、流场 (流速和流向), 使用与其空间匹配一致的 ETOPO 水下地形产品作为参考真值, 以子图作为输入, 搭建 MR-WDI 模型. 在训练集上, 水深反演的 MAE 为 1.08 m, RMSE 为 1.57 m, MAPE 为 6.56%, 最大探测水深范围达 49.05 m. 在测试集上, 2景测试数据的 RMSE 为 1.95 m, MAPE 为 11.55%, 2景数据测试结果接近, 说明 MR-WDI 模型对于该区域水深探测比较稳定且鲁棒性较好. 与基于波浪波长、波浪方向、波浪周期等参数与水深的线性色散关系估算水深方法相比, 研究提出的 MR-WDI 模型不仅在水深探测范围上有所提升, 而且通过多时相数据融合, 增强了模型对水深变化的敏感性, 在2景测试数据上显示出较好的精度.

此外, 还分析了模型输入和 SAR 条纹特征对水深反演模型性能的影响. 一方面, 模型以子图作为输入, 考虑了周围图像信息, 随着切割子图增大, 包含地形信息越丰富, 相同大小的卷积核能提取的局部空间信息越多, 反演精度越高, 但受图像与水深分辨率影响, 以及研究区域的不同, 最优子图大小选择不同, 研究最终选择 8×8 子图构建模型. 另一方面, MR-WDI 模型的性能受 SAR 条纹特征的影响, 对于受海况条件影响大的 SAR 图像, 模型难以准确捕捉水深信息,

所以水深预测结果在浅水区与深水区均低于参考水深, 误差较大; 而存在明暗 SAR 条纹特征的图像, 水深探测结果更接近参考水深, 但由于该区域水深分布差异影响, 在 30 m 以上的水深预测结果低于参考水深.

尽管 MR-WDI 模型在图像条纹特征和区域上存在一定限制, 但深度学习在 SAR 浅海水深探测研究中展现出巨大的潜力, 后续将根据不同区域的水深分布不同来进行多个区域的水深探测实验. 未来, 可以利用更多的 SAR 数据, 结合 SAR 探测地形理论与深度学习技术, 研究开发新的算法, 以提高浅海地形探测的精度和深度以及扩大模型的适用范围.

参考文献

- [1] SHEN W, CHEN M Y, WU Z Q, *et al.* Shallow-water bathymetry retrieval based on an improved deep learning method using GF-6 multispectral imagery in Nanshan Port waters[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2023, **16**: 8550-8562
- [2] PURKIS S J, GLEASON A C R, PURKIS C R, *et al.* High-resolution habitat and bathymetry maps for 65, 000 sq. km of Earth's remotest coral reefs[J]. *Coral Reefs*, 2019, **38**(3): 467-488
- [3] AI B, WEN Z, WANG Z H, *et al.* Convolutional neural network to retrieve water depth in marine shallow water area from remote sensing images[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2020, **13**: 2888-2898
- [4] CUI Ziwei, XU Wenxue, LIU Yanxiong, *et al.* Current status of the acquisition and processing of airborne laser


- sounding data[J]. *Remote Sensing for Natural Resources*, 2023, **35**(3): 1-9 (崔子伟, 徐文学, 刘焱雄, 等. 机载激光测深数据获取及处理技术现状 [J]. 自然资源遥感, 2023, **35**(3): 1-9)
- [5] LI Yujia, ZHOU Xiaoqing, LI Guoyuan, *et al.* Progress and prospect of space-borne photon-counting lidar shallow water bathymetry technology[J]. *Infrared and Laser Engineering*, 2022, **51**(10): 20220003 (李雨佳, 周晓青, 李国元, 等. 星载单光子激光雷达浅水测深技术研究进展和展望 [J]. 红外与激光工程, 2022, **51**(10): 20220003)
 - [6] SCHWARZ R, MANDLBURGER G, PFENNIGBAUER M, *et al.* Design and evaluation of a full-wave surface and bottom-detection algorithm for LiDAR bathymetry of very shallow waters[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2019, **150**: 1-10
 - [7] WESTFELD P, MAAS H G, RICHTER K, *et al.* Analysis and correction of ocean wave pattern induced systematic coordinate errors in airborne LiDAR bathymetry[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2017, **128**: 314-325
 - [8] HEDLEY J, ROELFSEMA C, PHINN S R. Efficient radiative transfer model inversion for remote sensing applications[J]. *Remote Sensing of Environment*, 2009, **113**(11): 2527-2532
 - [9] LIU Y M, TANG S L, DENG R R, *et al.* Mapping ultrahigh-spatial-resolution bathymetry for a wide range of coastal optically shallow waters without in situ bathymetric data[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, **61**: 4207716
 - [10] CAO B, DENG R R, ZHU S L. Universal algorithm for water depth refraction correction in through-water stereo remote sensing[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2020, **91**: 102108
 - [11] LYZENG D R. Passive remote sensing techniques for mapping water depth and bottom features[J]. *Applied Optics*, 1978, **17**(3): 379-383
 - [12] CAO Bin. A Study of Shallow Seafloor Relief Measurement Using Optical Satellite Images[D]. Shanghai: Shanghai Ocean University, 2018 (曹斌. 光学卫星影像浅海海底地形测量方法研究 [D]. 上海: 上海海洋大学, 2018)
 - [13] LAI W D, LEE Z, WANG J W, *et al.* A portable algorithm to retrieve bottom depth of optically shallow waters from top-of-atmosphere measurements[J]. *Journal of Remote Sensing*, 2022, **2022**: 9831947
 - [14] LIU Y M, ZHAO J, DENG R R, *et al.* A downscaled bathymetric mapping approach combining multitemporal Landsat-8 and high spatial resolution imagery: demonstrations from clear to turbid waters[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2021, **180**: 65-81
 - [15] CHEN B Q, YANG Y M, XU D W, *et al.* A dual band algorithm for shallow water depth retrieval from high spatial resolution imagery with no ground truth[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2019, **151**: 1-13
 - [16] XU Y, CAO B, DENG R R, *et al.* Bathymetry over broad geographic areas using optical high-spatial-resolution satellite remote sensing without in-situ data[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2023, **119**: 103308
 - [17] MA S, TAO Z, YANG X F, *et al.* Bathymetry Retrieval From Hyperspectral Remote Sensing Data in Optical-Shallow Water[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, **52**(2): 1205-1212
 - [18] PACHECO A, HORTA J, LOUREIRO C, *et al.* Retrieval of nearshore bathymetry from Landsat 8 images: a tool for coastal monitoring in shallow waters[J]. *Remote Sensing of Environment*, 2015, **159**: 102-116
 - [19] LEGLEITER C J, OVERSTREET B T, GLENNIE C L, *et al.* Evaluating the capabilities of the CASI hyperspectral imaging system and Aquarius bathymetric LiDAR for measuring channel morphology in two distinct river environments[J]. *Earth Surface Processes and Landforms*, 2016, **41**(3): 344-363
 - [20] XI Xiaohuan, WANG Zijia, WANG Cheng. Bathymetric extraction method of nearshore based on ICESat-2/ATLAS data[J]. *Journal of Tongji University (Natural Science)*, 2022, **50**(7): 940-946 (习晓环, 王子家, 王成. 基于 ICESat-2/ATLAS 数据的近海岸水深提取 [J]. 同济大学学报 (自然科学版), 2022, **50**(7): 940-946)
 - [21] HU Qixin, CHENG Liang, CHU Sensen, *et al.* Water depth extraction of ICESat-2 and application to bathymetric inversion[J]. *Chinese Journal of Geophysics*, 2024, **67**(3): 997-1012 (胡琪鑫, 程亮, 楚森森, 等. ICESat-2 水深提取方法及其反演应用 [J]. 地球物理学报, 2024, **67**(3): 997-1012)
 - [22] FAN Kaiguo, HUANG Weigen, FU Bin, *et al.* SAR shallow water bathymetry surveys: a case study in Taiwan Shoal[J]. *Chinese Journal of Geophysics*, 2012, **55**(1): 310-316 (范开国, 黄韦良, 傅斌, 等. 台湾浅滩浅海水深 SAR 遥感探测实例研究 [J]. 地球物理学报, 2012, **55**(1): 310-316)
 - [23] BRUSCH S, HELD P, LEHNER S, *et al.* Underwater bottom topography in coastal areas from TerraSAR-X data[J]. *International Journal of Remote Sensing*, 2011, **32**(16): 4527-4543
 - [24] WANG Xiaozhen. Research on SAR Remote Sensing Imaging Mechanism and Inversion of Typical Shallow Water Topography[D]. Hangzhou: Zhejiang University, 2018 (王小珍. 浅海典型水下地形 SAR 遥感成像机理和反演研究 [D]. 杭州: 浙江大学, 2018)
 - [25] YU Xiangzhen, CHONG Jinsong, HONG Wen. Shallow sea topography imaging model by along-track interferometric SAR and its optimal radar parameters analysis[J]. *Journal of Electronics & Information Technology*, 2010, **32**(10): 2377-2382 (于祥祯, 种劲松, 洪文. 顺轨干涉 SAR 浅海地形成像建模及其最优雷达观测参数分析 [J]. 电子与信息学报, 2010, **32**(10): 2377-2382)
 - [26] ALPERS W, HENNINGS I. A theory of the imaging mechanism of underwater bottom topography by real and synthetic aperture radar[J]. *Journal of Geophysical Research: Oceans*, 1984, **89**(C6): 10529-10546
 - [27] BIAN X L, SHAO Y, WANG S A, *et al.* Shallow water

- depth retrieval from multitemporal sentinel-1 SAR data[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2018, **11**(9): 2991-3000
- [28] YUAN Y L, HUA F, PAN Z D, *et al.* LAGFD-WAM numerical wave model—I. basic physical model[J]. *Acta Oceanologica Sinica*, 1991, **10**(4): 483-488
- [29] ZHANG S S, LIU B, LI X F, *et al.* Automatic extraction of internal wave signature from multiple satellite sensors based on deep convolutional neural networks[C]//IGARSS 2020 - 2020 IEEE International Geoscience and Remote Sensing Symposium. Waikoloa: IEEE, 2020: 5717-5720
- [30] WANG J, ZHANG H G, YANG J S, *et al.* A new mapping method of underwater bottom topography in the shallow sea by using SAR images[C]//Remote Sensing of the Ocean, Sea Ice, Coastal Waters, and Large Water Regions 2016. Edinburgh: SPIE Remote Sensing, 2016
- [31] FAN Kaiguo. Shallow water bathymetry surveys by SAR based on M4S for simulations of microwave imaging oceanic surface[D]. Qingdao: Ocean University of China, 2009 (范开国. 基于海面微波成像仿真 M4S 软件的 SAR 浅海地形遥感探测 [D]. 青岛: 中国海洋大学, 2009)
- [32] LI D F, ZHAO Z Q. Facet-based hybrid method for electromagnetic scattering from shallow water waves modulated by submarine topography[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, **60**: 2004314
- [33] HUANG L Y, MENG J M, FAN C Q, *et al.* Shallow sea topography detection from multi-source SAR satellites: a case study of Dazhou Island in China[J]. *Remote Sensing*, 2022, **14**(20): 5184
- [34] BIAN X L, SHAO Y, TIAN W, *et al.* Underwater topography detection in coastal areas using fully polarimetric SAR data[J]. *Remote Sensing*, 2017, **9**(6): 560
- [35] PEREIRA P, BAPTISTA P, CUNHA T, *et al.* Estimation of the nearshore bathymetry from high temporal resolution Sentinel-1A C-band SAR data - a case study[J]. *Remote Sensing of Environment*, 2019, **223**: 166-178
- [36] RONG Feicheng, MENG Junmin, JI Yonggang. Shallow sea underwater topography detection based on SAR subaperture image[J]. *Journal of Telemetry, Tracking and Command*, 2024, **45**(1): 106-115 (荣飞成, 孟俊敏, 纪永刚. 基于 SAR 子孔径图像的浅海水下地形探测 [J]. 遥测遥控, 2024, **45**(1): 106-115)
- [37] FANG Chao, WANG Sheng, LIU Guihong, *et al.* Spatio-temporal distribution characteristics of arctic ice eddies based on SAR satellite observations[J]. *Chinese Journal of Space Science*, 2023, **43**(6): 1125-1134 (房超, 汪胜, 刘桂红, 等. 基于 SAR 卫星观测的北极冰涡时空分布特征 [J]. 空间科学学报, 2023, **43**(6): 1125-1134)
- [38] REN Shihe, HAN Yanhong, LI Jingshi, *et al.* Oceanic front detection model based on U-Net network[J]. *Chinese Journal of Space Science*, 2023, **43**(6): 1091-1099 (任诗鹤, 韩焱红, 李竞时, 等. 基于 U-Net 的海洋锋智能检测模型 [J]. 空间科学学报, 2023, **43**(6): 1091-1099)
- [39] LEE S, KIM D J, LI C L, *et al.* A new model for high-accuracy monitoring of water level changes via enhanced water boundary detection and reliability-based weighting averaging[J]. *Remote Sensing of Environment*, 2024, **313**: 114360
- [40] YANG H Y, FANG C, WANG S, *et al.* On the ambiguity removal of wind direction derived from space-borne SAR imagery using deep learning[J]. *Remote Sensing of Environment*, 2024, **308**: 114202
- [41] YUROVSKY Y Y, KUDRYAVTSEV V N, YUROVSKAYA M V, *et al.* Tropical cyclone signatures in SAR ocean radial Doppler Velocity[J]. *Remote Sensing of Environment*, 2024, **311**: 114251
- [42] ZHAO X N, WANG D Q, XU H L, *et al.* Water deep mapping from HJ-1B satellite data by a deep network model in the sea area of Pearl River Estuary, China[J]. *Open Geosciences*, 2021, **13**(1): 782-795
- [43] WU Z Q, MAO Z H, SHEN W, *et al.* Satellite-derived bathymetry based on machine learning models and an updated quasi-analytical algorithm approach[J]. *Optics Express*, 2022, **30**(10): 16773-16793
- [44] KALOOP M R, EL-DIASTY M, HU J W, *et al.* Hybrid artificial neural networks for modeling shallow-water bathymetry via satellite imagery[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, **60**: 5403811
- [45] ZHONG J, SUN J, LAI Z L, *et al.* Nearshore bathymetry from ICESat-2 LiDAR and Sentinel-2 imagery datasets using deep learning approach[J]. *Remote Sensing*, 2022, **14**(17): 4229
- [46] LI X F, YANG X F, ZHENG Q N, *et al.* Deep-water bathymetric features imaged by spaceborne SAR in the Gulf Stream region[J]. *Geophysical Research Letters*, 2010, **37**: L19603

作者简介



崔宜德 男, 2001 年 12 月出生于山东省德州市, 现为中国科学院空天信息创新研究院在读博士研究生, 主要研究方向为基于 SAR 观测的浅海水下地形研究。
E-mail: cuiyide23@mailsucas.ac.cn



于 阳 (通信作者) 女, 1982 年 12 月出生于上海市, 现为中国科学院空天信息创新研究院遥感与数字地球重点实验室助理研究员, 主要研究方向为海洋动力环境遥感反演、海洋中尺度现象遥感检测与反演等。
E-mail: yuyang@aircas.ac.cn