砂质基底海岛地形遥感动态监测研究

李静，肖懿哲，陈皓

（江苏省测绘工程院 南京 210019）

摘要：砂质基底海岛地形受潮流水动力影响显著，地形演变迅速，及时掌握其周边地形动态变化规律对海岛保护与管理具有重要意义。文章以某砂质基底海岛周边海域为研究区，基于 2013 年环境减灾卫星（HJ-1B）遥感数据，构建了 4 种能够削弱悬浮泥沙影响的水深遥感反演模型（支持向量机、随机森林、全连接神经网络和卷积神经网络）。通过系统对比各模型精度，发现卷积神经网络（CNN）模型表现最优，其反演结果与实测水深的决定系数（R^2）达 0.98，均方根误差（RMSE）为 0.74 m，平均相对误差（MRE）为 5.97%。为进一步验证模型适用性并揭示地形演变规律，将 CNN 模型迁移应用于 2017 年环境卫星影像，实现了 2013—2017 年间地形变化的定量分析。结果表明：CNN 模型在迁移应用中仍保持良好性能，能够准确重构区域地形宏观格局与微地貌细节；2013—2017 年，研究区整体地形以淤积为主，淤积区面积占比 62.93%，平均淤积厚度为 2.66 m（年均约 0.53 m），冲刷区面积占比 37.07%，平均冲刷厚度为 1.16 m（年均约 0.23 m），整体呈现向东淤积趋势，需重点关注海岛北侧约 1 km 处出现的局部冲刷现象。文章构建的高精度反演模型与多时相动态监测方法，可为砂质基底海岛的地形稳定性评估与海岸带管理提供可靠技术支撑。

关键词：砂质基底海岛；水深反演；HJ-1B 环境卫星；卷积神经网络；动态监测；冲淤演变

中图分类号：P737.1；TP79 **文献标志码：**A **文章编号：**1005-9857（2026）03-0108-10

Satellite-Based Dynamic Monitoring of Topographic Changes in Sandy Substrate Islands

LI Jing，XIAO Yizhe，CHEN Hao

（Jiangsu province surveying & mapping engineering institute，Nanjing 210019，China）

Abstract：Sandy substrate islands，significantly influenced by tidal hydrodynamics，experience rapid geomorphological changes，making it crucial to monitor the dynamic evolution of their surrounding topography for effective island conservation and management. This study focuses on the coastal waters surrounding a sandy substrate island. Utilizing 2013 HJ-1B satellite imagery，four water depth inversion models-Support Vector Machine（SVM），Random Forest（RF），Fully Connected Neural Network（FNN），and Convolutional Neural Network（CNN）-were developed to mitigate the impact of suspended sediments. A systematic comparison revealed that the CNN model

收稿日期：2025-10-28；**修订日期：**2026-02-20

基金项目：2021 年江苏省自然资源科技项目（2021040）；2021 年江苏省海洋科技创新项目（JSZRHYKJ202101）.

作者简介：李静，高级工程师，硕士，研究方向为近海水下地形遥感反演

achieved optimal performance，with a coefficient of determination（R^2）of 0.98，a Root Mean Square Error（RMSE）of 0.74 m，and a Mean Relative Error（MRE）of 5.97% against measured water depth data．To further validate the model's applicability and investigate topographic evolution，the CNN model was transferred and applied to 2017 HJ-1A/B imagery，enabling quantitative analysis of topographic changes between 2013 and 2017．Results indicate that the CNN model maintained robust performance in the transfer applications，accurately reconstructing both the macroscale terrain and microscale topographic details．During 2013—2017，the study area was dominated by siltation，with accretion zones accounting for approximately 62.93% of the total area and an average siltation thickness of 2.66 m（approximately 0.53 m annually）．Erosion zones covered about 37.07% of the area，with an average erosion depth of 1.16 m（approximately 0.23 m annually）．An overall eastward siltation trend was observed，while localized scour near approximately 1 km north of the island requires particular attention．The high-precision inversion model and multi-temporal dynamic monitoring methodology developed in this study provide a reliable technical framework for assessing topographic stability and supporting coastal zone management of sandy substrate islands．

Keywords：Sandy substrate islands；Bathymetry inversion；HJ-1B satellite；Convolutional neural network（CNN）；Dynamic monitoring；Erosion and deposition evolution

0　引言

海岛地形动态监测是海岸带管理与生态保护的重要基础，尤其是具有特殊意义的海岛[1-2]。砂质基底海岛，因其基质松散，在潮汐和波浪等水动力作用下，地形冲淤演变更为剧烈，对其周边地形进行快速、持续的监测尤为迫切。传统船载测深技术虽可提供高精度数据，但受限于成本与作业效率，难以实现大范围和高频次的重复观测，无法满足动态监测的现实需求[3-6]。

光学遥感技术因其高效和低成本的优势，被认为是传统水深测量的有效补充。随着遥感技术的发展，水深反演方法已从早期的线性模型发展到多种非线性机器学习模型[7-9]。然而，该方法在实际应用中仍面临两大挑战：一方面，在悬浮泥沙浓度高的浑浊水域（如江苏沿海的辐射沙脊群海域），复杂的水体光学特性严重影响光信号传输，导致模型反演精度显著降低[10-13]；另一方面，现有研究大多局限于单时相的模型构建与验证，缺乏对模型时序迁移与应用能力的系统评估[14]。

近年来，研究呈现出多源数据融合与多时相分析的反演发展趋势。机器学习，尤其是深度学习，在捕捉复杂非线性关系方面展现出强大的潜力[15]。钟静等[16]利用 ICESat-2 激光测高数据与 Sentinel-2 影像相结合，通过机器学习模型实现了高精度水深反演。谢丛霜等[17]提出，结合物理辐射传输信息和卷积神经网络的模型，充分利用机器学习能力，将主被动遥感手段结合以提高反演精度。然而，这些方法主要基于国外卫星数据源，针对的水体环境与江苏近海高悬沙海况存在显著差异，并且其模型在时序应用方面的研究仍显不足。

因此，面对江苏海域高悬沙浓度的特殊挑战与模型时序应用研究匮乏的现状，本文基于国产卫星数据，通过构建能够有效适应高悬沙水体并具备时序迁移应用能力的水深反演模型，以实现砂质基底海岛地形的动态监测，为自然资源管理提供重要决策支撑。

1　悬沙影响下的水深遥感反演模型构建

1.1　研究区

本文选取砂质基底海岛周边海域，结合实测水下地形测量范围，划定长约 4 100 m，宽约 2 450 m，总面积约 10 km^2 的海域作为水深反演研究区。研究区内水深在 5 ～ 20 m 之间，地形差异大，适宜光学遥感反演研究。区域潮汐属半日潮性质，有明显的旋转流特点，悬浮泥沙以粉砂为主，悬沙浓度高。

1.2 数据与分析

1.2.1 实测数据

实测水深数据测量比例尺均为 1 ∶ 5 000，测量时间是 2013 年 6 月 19—27 日。采用 HY1600 单波束测深仪进行测量，测深精度中误差为 ±0.11 m。实测数据显示海岛周边地形整体呈现西高东低、西北高于东南的分布特征，砂质基底东侧有陡坎，高差在 2 m 左右。

实测悬浮泥沙数据采用定点观测方式获取，观测站点位于海岛西南方向。每隔 1 h 采集一组水样，共获得 25 组表层悬浮泥沙样品。悬浮泥沙样品分析采用烘干称重法进行。结果显示，在连续观测期间，表层悬浮泥沙浓度变化区间为［23，120］mg/L，平均悬浮泥沙含量达 60.19 mg/L，水体较为浑浊，含沙量高，为典型的二类水体。

在连续观测站点采集悬浮泥沙水样的同时，同步获取光谱数据。实测光谱使用美国 ASD 公司的手持式地物光谱仪（FieldSpec® HandHeld2）测量，采用水面之上法获取。本次共获得 10 组有效实测光谱反射率数据（因设备故障部分数据无效），水体光谱在 400 ～ 550 nm 波段范围内，光谱反射率很快达到饱和，而在 550 ～ 690 nm 范围内，光谱反射率则出现较大的变化。光谱整体上呈现双峰分布特征，第一反射峰在 550 ～ 600 nm，第二反射峰则在 810 nm 附近，是典型的二类水体光谱特征。10 组有效光谱曲线特征如图 1 所示。

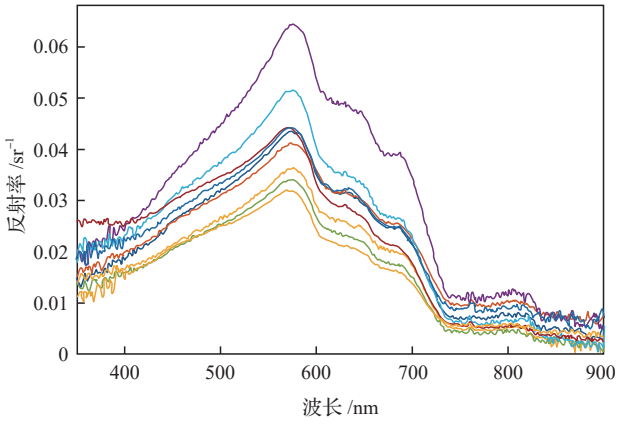

图 1 实测光谱特征曲线

Fig.1 Measured spectral characteristic curve

1.2.2 影像数据

本文采用环境减灾卫星 HJ-1B 的 CCD1 传感器影像，空间分辨率为 30 m，包含 4 个波段，光谱范围为 0.43 ～ 0.90 μm，幅宽达 360 km，重访周期 4 d。该数据不仅包含了穿透水体能力最强的蓝绿波段，而且覆盖范围广、重复周期短，具备遥感动态监测的条件。为实现大范围的反演并保障反演精度与应用效果，选择整体云量小于 10% 且研究区域上方清晰无云的影像；同时，在确保数据时间准同步的前提下，为避免悬浮物和叶绿素等水色要素季节特征对地形反演的干扰，最终选定 2013 年 7 月 11 日和 2017 年 8 月 28 日的两景影像。其中，2013 年 7 月 11 日的影像用于反演模型的构建与分析；2017 年 8 月 28 日的影像用于模型的应用研究。

1.2.3 数据预处理

数据预处理主要包括大气校正和潮位改正。

影像数据经辐射定标后，采用 ENVI 软件中的 FLAASH 模块进行大气校正。校正过程中，结合影像的光谱响应函数完成了等效中心波长的转换。

卫星影像反演得到的是成像时刻的瞬时水深，与实测水下地形数据的基准不统一。由于水深反演模型是基于瞬时潮位构建的，因此，必须将实测地形数据统一至瞬时潮位。利用收集到的研究区内实测数据基准与卫星成像时刻瞬时水深之间的转换关系，对实测数据进行了潮位改正，转换为瞬时水深。

1.3 模型构建与精度验证

为削弱研究区内悬浮泥沙浓度对水体反射率的影响，并充分发挥非线性统计学方法的数理能力，本文构建了 4 种基于非线性统计学的机器学习模型：支持向量机（SVM）模型、随机森林（RF）模型、全连接神经网络（FNN）模型及卷积神经网络（CNN）模型。

（1）特征因子选取。水深反演因子：通过分析水深与光谱反射率的相关系数（r），选取了与水深相关性高（决定系数 $R^2 > 0.85$）的 6 个光谱特征作为输入参数，即 B3、B1+B3、B2+B3、B3+B4、B2 × B3、B3 × B4。

悬沙影响因子：通过分析悬浮泥沙浓度与光谱反射率的相关系数（r），选取了与悬沙浓度相

关性高（决定系数 $R^2 > 0.80$）的 5 个光谱特征作为输入参数，即 B2、B1+B2、B1−B2、B1 × B2、（B1+B2）/（B1/B2）。

（2）样本划分。本文共获取 4 952 个有效数据对。采用随机抽样方法，将约 80%（3 962 个）的数据对作为训练样本用于构建和训练模型；剩余约 20%（990 个）的数据对作为独立的测试样本，用于模型精度验证。

（3）模型训练与验证。为消除随机抽样差异的影响，4 种机器学习模型均使用完全相同的训练样本集建立与训练，并统一使用相同的测试样本集进行精度评价。精度评价采用平均绝对误差（MAE）、平均相对误差（MRE）和均方根误差（RMSE）3 种指标进行评价。

1.3.1　模型构建

（1）支持向量机模型和随机森林模型。本文程序的实现基于 Python 3.10 环境与 Scikit-learn 机器学习库。支持向量机采用径向基函数，随机森林采用 Scikit-learn 中的 RandomForestRegressor 框架，算法中的回归树个数设置为 100，其余参数均使用默认值。

（2）全连接神经网络模型。本文程序的实现基于 Python 3.10 环境和 Keras 与 TensorFlow 深度学习框架，隐藏层和输出层权重初始化方法为随机高斯分布，加入正则化惩罚项，激活函数选择修正线性单元（ReLu）；遥感反演水深属于回归问题，所以选用的损失函数为均方误差（MSE），优化器使用梯度下降法自适应矩估计（Adam）。全连接神经网络的网络结构为 11—16—32—1。模型训练进行双层循环，内层循环设置批次大小（batch size）为 32；外层循环设置迭代次数（epochs）为 300。

（3）卷积神经网络模型。本文程序的实现基于 Python 3.10 环境和 Keras 深度学习框架。特征值在输入前需进行格式化处理，重构成二维数据。搭建多个卷积层、最大池化层、展平层（flatten）、全连接层的多层复杂网络结构，激活函数选择 Relu；整体模型采用 Adam 优化算法，损失函数设定 MSE；根据数据集的特征设置适当的核数及尺寸、最大池化层的尺寸、步长、卷积核卷积方式、池化层池化方式参数。训练方式与全连接神经网络一致，进行双层循环，内层循环设置 batch size 为 32；外层循环设置 epochs 为 300。

1.3.2　精度分析

（1）精度统计。4 种模型反演精度普遍较高，其中，随机森林和卷积神经网络模型显著优于支持向量机和全连接神经网络模型（表 1）。

表 1　模型精度情况

Table 1　Model accuracy status

反演模型	验证数据精度			
	R^2	MAE/m	RMSE/m	MRE/%
支持向量机	0.95	0.81	1.12	10.72
全连接神经网络	0.95	0.75	1.03	9.45
随机森林	0.98	0.46	0.74	5.28
卷积神经网络	0.98	0.51	0.74	5.97

（2）反演能力分析。为进一步评估 4 种模型的反演能力，本文对验证数据集中的实测值与预测值进行了分析，绘制了 1∶1 线（图 2）、2 m 误差线（图 2）及残差分布的误差图（图 3）。图中，图例色带表示验证点密度。

1∶1 线分析表明，4 种反演模型整体拟合效果良好，预测值基本围绕 1∶1 线分布。在 5 ～ 20 m 水深范围内，模型预测能力由弱至强排序依次为：支持向量机模型、全连接神经网络模型、随机森林模型和卷积神经网络模型。

2 m 误差线分析表明，随机森林模型和卷积神经网络模型的反演精度优于支持向量机模型和全连接神经网络模型，预测误差基本控制在 2 m 范围内，并且误差分布更为集中。其中，卷积神经网络模型的反演精度最优。

残差分布分析显示，支持向量机模型和全连接神经网络模型的残差分布相对分散，表明其预测能力稍弱。相比之下，随机森林模型和卷积神经网络模型的残差在零值附近高度集中，主要分布在 −2.5 ～ 2.5 m 的窄幅区间内，反映出更优的拟合效果。值得注意的是，在 4 ～ 15 m 水深区间，随机森林模型的拟合效果更佳；而在 15 m 以深水域，卷积神经网络模型的反演效果则更为突出。

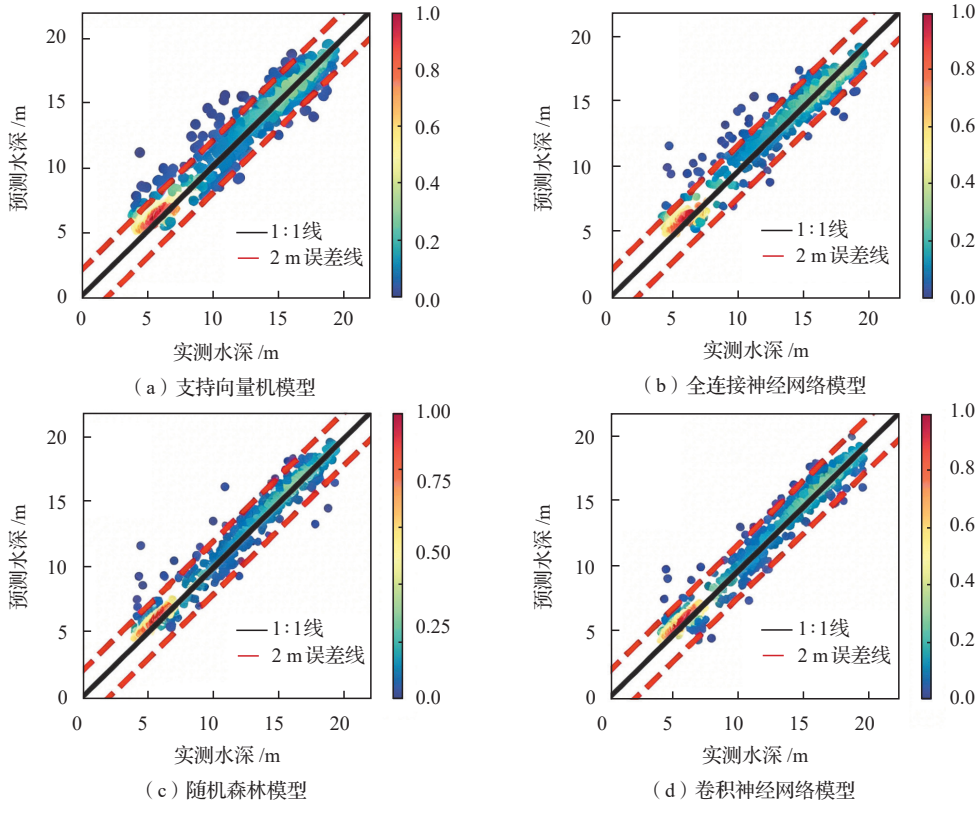

图 2　模型反演精度对比

Fig.2　Comparison of model inversion accuracy

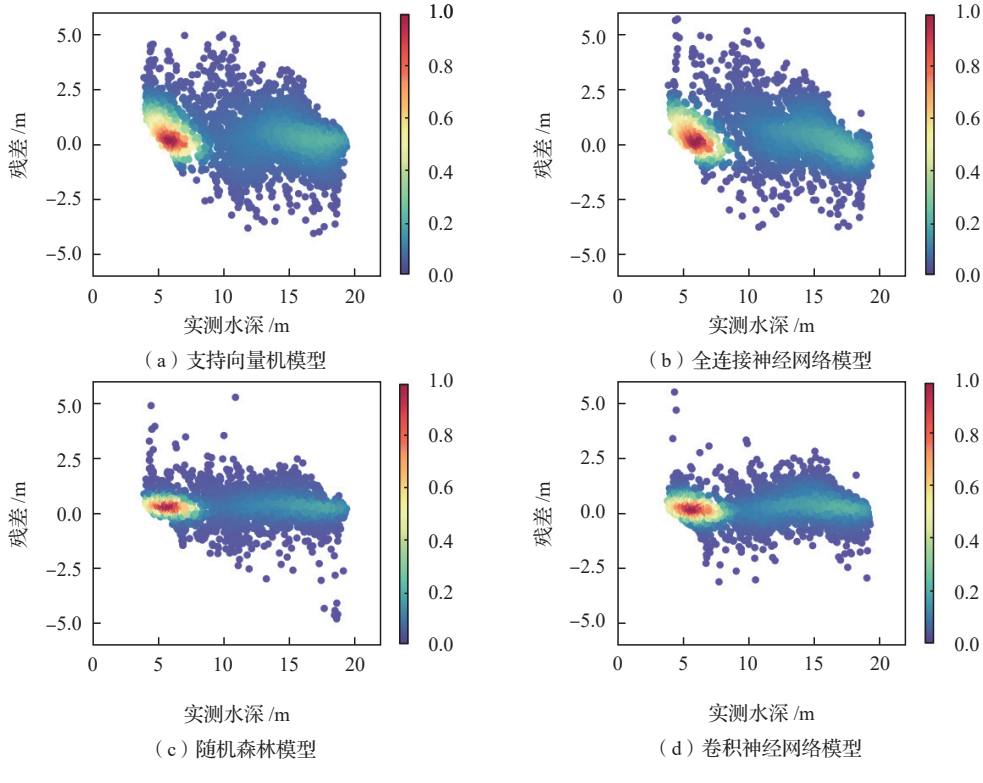

图 3　模型残差分布

Fig.3　Residual distribution of the model

2　反演模型应用与演变分析

2.1　模型迁移应用可行性分析

经评估 4 种反演模型的预测性能，结果表明，随机森林模型和卷积神经网络模型的地形反演精度最优。为推进模型的实际应用，本文将上述两种模型应用于 2013 年的影像数据，进行地形反演。通过系统比较模型反演值与实测地形数据的差异，深入分析了两种模型的反演效果。

2.1.1　整体精度分析

反演结果整体显示（图 4），两种模型的反演地形在宏观趋势上与实测地形高度一致，验证了模型反演结果的可靠性。尽管在局部区域存在一定的偏差，表现为地形高程的局部高估现象或低估现象，但这并不影响整体地形的准确性。

2.1.2　断面精度分析

为更细致地刻画模型反演误差的空间分布特征，进一步选取研究区南部（S1）、中部（S2）和北部（S3）3 个典型断面进行精度验证分析（图 5）。断面分析结果表明，两种模型在所选断面均表现出较高的反演精度，其反演的地形起伏趋势与实测地形吻合良好。具体而言，随机森林模型在深水区域的反演结果波动性相对较大，而卷积神经网络模型则展现出更强的细节捕捉能力。

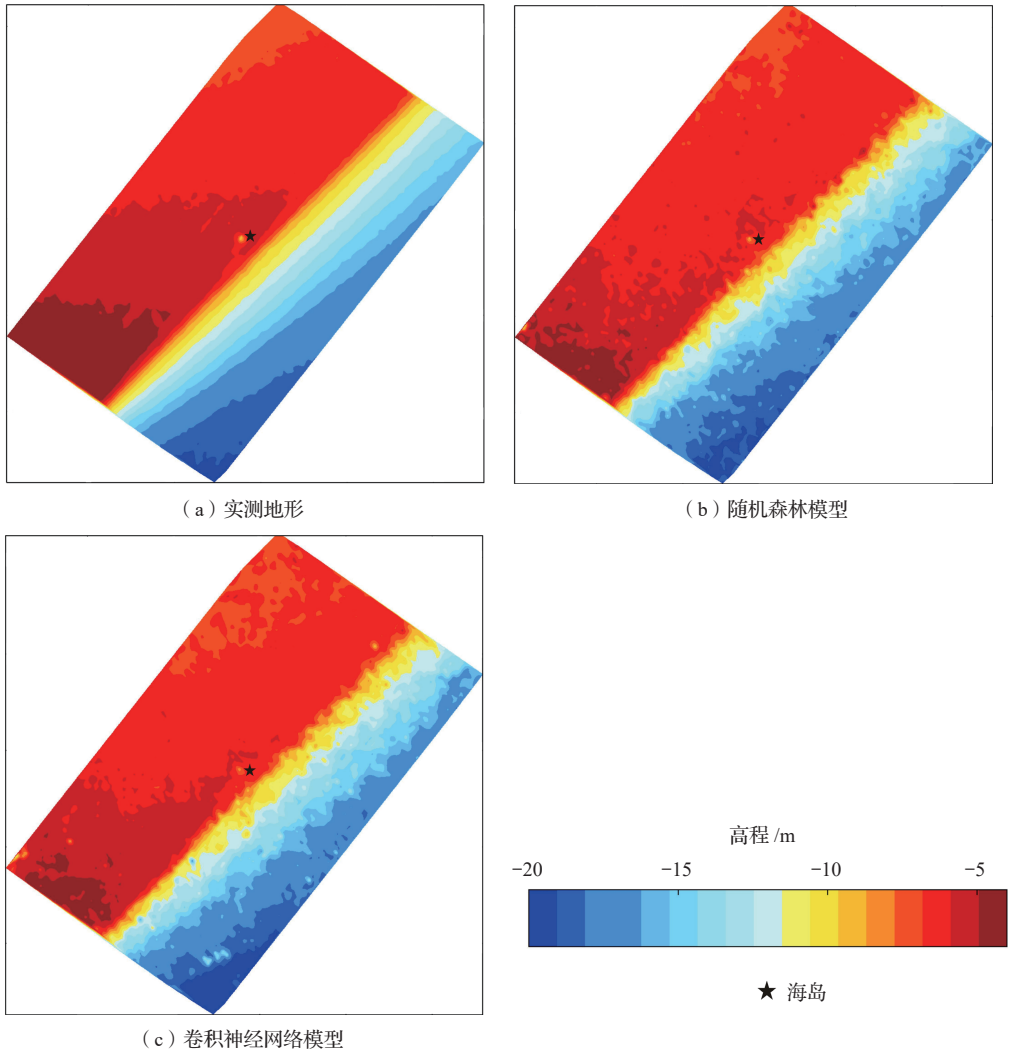

（a）实测地形　（b）随机森林模型　（c）卷积神经网络模型

图 4　RF 模型和 CNN 模型地形反演结果

Fig.4　Terrain inversion results of RF and CNN models

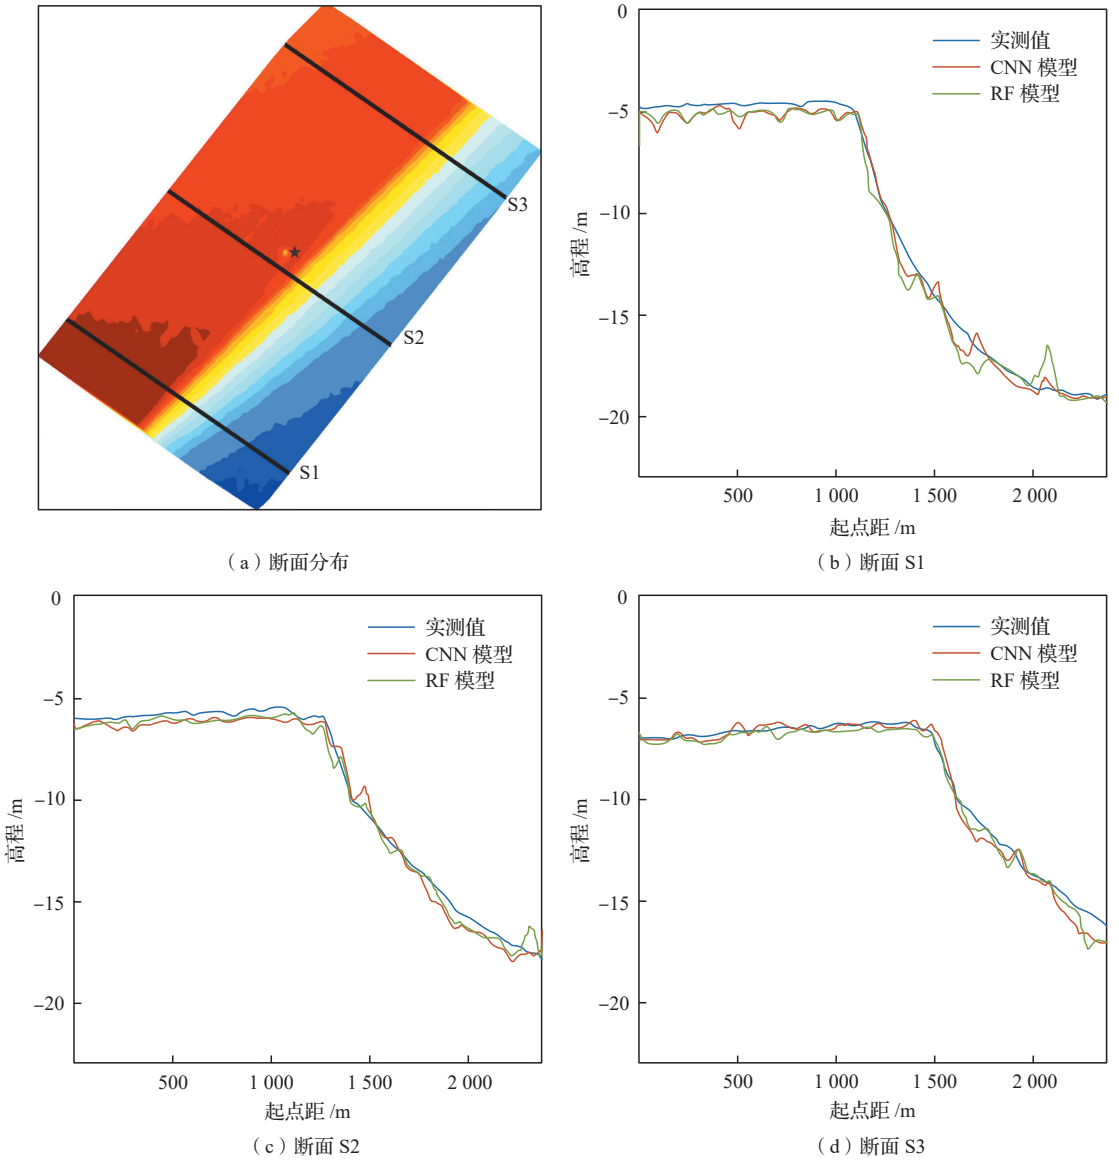

（a）断面分布　（b）断面 S1

（c）断面 S2　（d）断面 S3

图 5　断面精度分析

Fig.5　Section accuracy analysis

整体精度和断面精度分析结果表明，两种模型均表现出较高的地形反演精度；随机森林模型在深水区域的反演结果波动性较大，而卷积神经网络模型则展现出更优的细节捕捉能力。

2.2　基于 CNN 模型的地形反演与冲淤演变分析

综合考量模型反演精度与效果，本文选取性能更优的 CNN 模型应用于 2017 年遥感影像进行地形反演，并基于此开展 2013—2017 年水下地形的冲淤演变分析。

2.2.1　冲淤演变特征分析

2013—2017 年（图 6）冲淤结果表明，研究区整体表现为淤积为主，局部冲刷。淤积面积达 6.01 km^2（占总面积的 62.93%），淤积量为 0.016 km^3，区域平均淤积厚度为 2.66 m（年均 0.53 m）。淤积中心主要位于海岛东侧，尤以中等水深区域最为显著。冲刷区域面积约 3.54 km^2（占比 37.07%），冲刷量为 0.004 km^3，区域平均冲刷厚度为 1.16 m（年均 0.23 m），冲刷区主要发生在海岛基底西北侧。该时段研究区

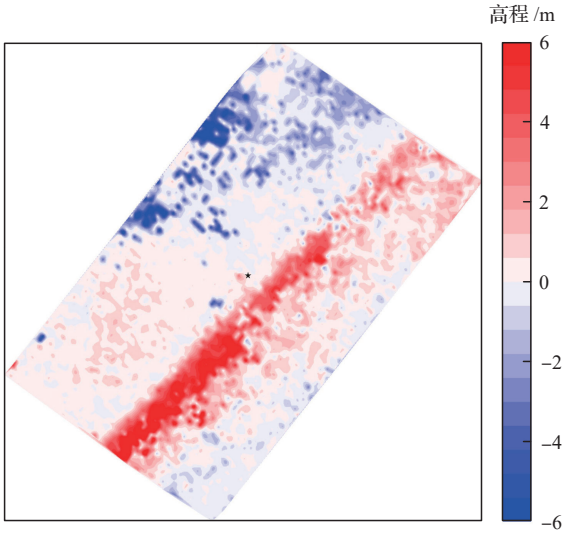

图 6　2013—2017 年冲淤演变分析

Fig.6　Analysis of sedimentation and erosion evolution from 2013 to 2017

平均地形变化深度为 0.91 m，整体呈现向东侧偏移的趋势。海岛周边地形变化幅度较小（约 0 ～ 1 m），北部以微弱冲刷为主，南部则呈现微弱淤积态势。

综合分析表明，相较于 2009—2013 年，2013—2017 年间研究区冲淤格局发生明显转变：①海岛东北部冲刷范围扩大；②海岛南部条带状淤积区淤积程度加剧；③海岛本体区域保持高度稳定，其周边表现为微弱冲刷。

2.2.2　断面水深变化分析

鉴于研究区海域广阔且离岸较远，平均水深变化难以反映局部区域特征。为更精细地刻画水下地形的空间异质性，本文沿用了南部（S1）、中部（S2）和北部（S3）3 条代表性断面（图 5），提取 2013 年与 2017 年反演水深数据，通过对比分析断面地形形态变化，揭示冲淤动态（图 7）。

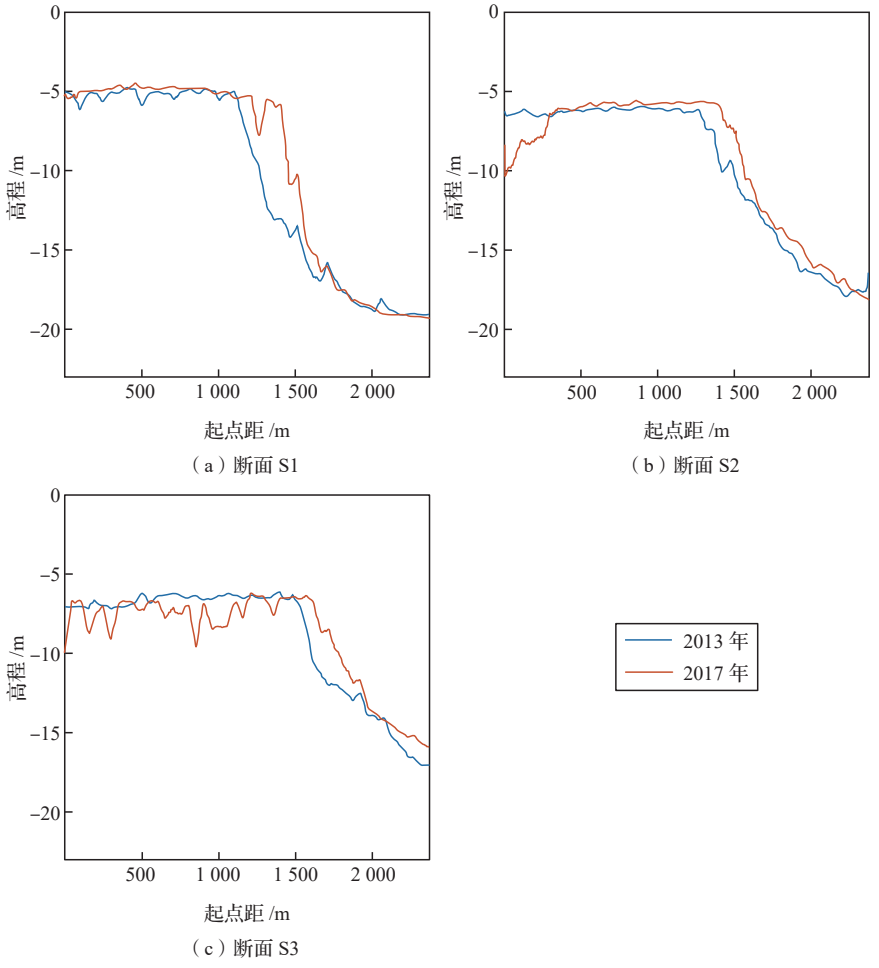

（a）断面 S1　（b）断面 S2

（c）断面 S3

图 7　2013 年与 2017 年研究区断面水深变化情况

Fig.7　Changes in water depth at cross-sections in the study area between 2013 and 2017

断面 S1（南部）：2013—2017 年，该断面地形发生显著变化。主要表现为断面中部水深明显变浅，表明强烈淤积；而断面两端（最浅处和最深处）地形则相对稳定。整体上，该断面平均水深减小约 1 m。

断面 S2（中部）：除靠近岸线一侧呈现轻微冲刷（水深加深）外，断面其余部分均表现为淤积（水深变浅）。

断面 S3（北部）：该断面呈现东西差异，西侧水深加深（冲刷），东侧水深变浅（淤积）。整体平均水深变化甚微。

断面综合分析结论：2013—2017 年，研究区海底地形整体呈淤积趋势，并伴随向海方向的推移。淤积强度及变化幅度表现出空间差异，其中，南部区域（断面 S1）最为显著，中部（断面 S2）次之，北部（断面 S3）相对较弱。

3 结论

（1）基于环境减灾卫星 HJ-1B 的 CCD1 构建的 4 种削弱悬沙影响的水深反演模型均表现出良好的性能，平均相对误差优于 10%。其中，CNN 模型精度显著领先，其 RMSE ＜ 0.8 m，平均相对误差＜ 6%。

（2）基于 RF 模型和 CNN 模型在反演精度上的优势，对模型拟合预测能力和反演精度进行综合评价分析。结果表明，CNN 模型预测反演能力最具优势。

（3）基于最优的 CNN 模型构建的水深反演模型开展了 2017 年遥感影像地形反演应用实践，并研究了 2013—2017 年海岛地形冲淤分析。结果表明：2013—2017 年的地形整体以淤积为主，研究区水深居中区域淤积幅度最大；海岛基底地形整体较为稳定，其北部区域存在少量冲刷，需要特别关注。

（4）针对遥感反演模型应用研究较少的现状，开展了反演模型应用实践。通过开展不同时期的地形冲淤演变研究，证实了模型应用的效果，可为动态监测地形变化提供决策支持。

（5）研究的高精度反演模型能获取传统船测难以覆盖的数据，掌握水下地形变化，减少监测盲区。同时，能够了解冲淤变化情况，实现定量化、空间化的分析，为重大工程实施或者特殊海岛权益维护提供依据。

参考文献（Reference）：

[1] 唐世林，黄宇业，刘永明，等. 海岛海岸带浅水地形卫星遥感反演技术[J]. 中国科学院院刊，2026，41(1)：96-106.
TANG Shilin，HUANG Yuye，LIU Yongming，et al. Satellite-derived bathymetry in island coastal zones：Technology[J]. Bulletin of Chinese Academy of Sciences，2026，41(1)：96-106.

[2] LIU Yongming，TANG Shilin，HUANG Yuye，et al. Mapping the bathymetry of coral islands with the Landsat series：quantitative evaluation of the consistency and temporal change detection[J]. International Journal of Applied Earth Observation and Geoinformation，2025，142：104721.

[3] CHEN Benqing，YANG Yanming，XU Dewei，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(5)：1-13.

[4] ZHOU Yu，LU Lejun，LI Linlin，et al. A generic method to derive coastal bathymetry from satellite photogrammetry for tsunami hazard assessment[J]. Geophysical Research Letters，2021，48(21)：e2021GL095142.

[5] XU Xichen，FU Dongjie，SU Fenzhen，et al. Global distribution and decline of mangrove coastal protection extends far beyond area loss [J]. Nature Communications，2024，15(1)：10267.

[6] HUANG Yuye，YANG Hongqiang，TANG Shilin，et al. An appraisal of atmospheric correction and inversion algorithms for mapping highresolution bathymetry over coral reef waters[J]. IEEE Transactions on Geoscience and Remote Sensing，2023，61：1-11.

[7] 马毅，张杰，张靖宇，等. 浅海水深光学遥感研究进展[J]. 海洋科学进展，2018，36(3)：331-351.
MA Yi，ZHANG Jie，ZHANG Jingyu. et al. Progress in shallow water depth mapping from optical remote sensing[J]. Advances in Marine Science，2018，36(3)：331-351.

[8] 汪万智，邹欣庆，李海宇. 南海珊瑚礁光学浅水海域多光谱遥感水深反演[J]. 高校地质学报，2022，28(5)：758-767.

WANG Wanzhi，ZOU Xinqing，LI Haiyu．Water depth inversion from multispectral imagery over optically shallow waters of coral reefs in South China Sea[J]．Geological Journal of China Universities，28(5)：758-767.

[9] 孟鑫垚，刘焱雄，陈义兰，等．基于空间特征的机器学习模型浅海水深反演[J]．海洋科学进展，2023，41(3)：498-509.
MENG Xinyao，LIU Yanxiong，CHEN Yilan，et al．Spatial feature-based machine learning model for shallow water depth retrieva[J]．Advances in Marine Science，2023，41(3)：498-509

[10] 梁志诚，黄文骞，杨杨，等．基于神经网络技术的多因子遥感水深反演模型[J]．测绘工程，2012，21(4)：17-21.
LIANG Zhicheng，HUANG Wenqian，YANG Yang，et al．Study of the water depth retrieval based on artificial neural network[J]．Engineering of Surveying and Mapping，2012，21(4)：17-21.

[11] XU Xueli，PAN Qiqi，WANG Zaifeng，et al．Research on improving the accuracy of remote sensing-based bathymetry on muddy coasts[J]．Estuarine，Coastal and Shelf Science，2025，313：109126.

[12] ASHPHAQ M，SRIVASTAVA P K，MITRA D．Preliminary examination of influence of Chlorophyll，Total Suspended Material，and Turbidity on Satellite Derived-Bathymetry estimation in coastal turbid water[J]．Regional Studies in Marine Science，2023，65：103084.

[13] 张鹰，张芸，张东，等．南黄海辐射沙脊群海域的水深遥感[J]．海洋学报，2009，31(3)：39-45.
ZHANG Ying，ZHANG Yun，ZHANG Dong，et al．An underwater bathymetry reversion in the radial sand ridge group region of the southern Huanghai Sea using the remote sensing technology[J]．Haiyang Xuebao，2009，31(3)：39-45.

[14] ISLER T，MONTEYS X，CASAL G，et al．Assessment of a generalized linear model for satellite-derived bathymetry in turbid waters using Sentinel-2 multi-temporal images[C]//EGU General Assembly 2025，2025.

[15] MISRA A，VOJINOVIC Z，RAMAKRISHNAN B，et al．Shallow water bathymetry mapping using Support Vector Machine (SVM) technique and multispectral imagery[J]．International Journal of Remote Sensing，2018，39(15-16)：5111-5136.

[16] 钟静，孙杰，赖祖龙，等．ICFSal-2 与 Sentinel2 数据融合的深度学习浅滩水深测量[J]．测绘通报，2023(7)：39-43.
ZHONG Jing，SUN Jie，LAI Zulong，et al．A deep learning method for nearshore bathymetry with ICESat-2 andSentinel-2 datasets[J]．Bulletin of Surveying and Mapping，2023(7)：39-43.

[17] 谢丛霜，陈鹏，潘德炉．主被动遥感融合辐射传输卷积神经网络水深反演方法[J]．光子学报，2024，53(8)：46-58.
XIE Congshuang，CHEN Peng，PAN Delu．Bathymetric inversion method for active-passive remote sensing fused radiative transfer information convolutional neural networks[J]．Acta Photonica Sinica，2024，53(8)：46-58.