

引用格式:栗之浩,潘明阳,李邵喜,等. 基于超分辨率 DEM 与实时水位交互的海图动态等深线生成方法[J].大连海事大学学报,2026,52(1):12-20.

## 基于超分辨率数字高程模型与实时水位交互的 海图动态等深线生成方法

栗之浩<sup>1</sup>,潘明阳<sup>\*1</sup>,李邵喜<sup>1</sup>,王沫<sup>2</sup>,胡景峰<sup>1</sup>,郝江凌<sup>1</sup>,张若澜<sup>1</sup>

(1.大连海事大学 航海学院,辽宁 大连 116026;2.天津航海仪器研究所,天津 300131)

**摘要:**针对 S-102 测深表面数据不完备导致电子海图(ENC)产品中稀疏水深数据精度不足,难以直接支撑高可靠性动态水深计算的制约,提出一种基于深度学习超分辨率技术的解决方案。该方案利用改进的 TSE-EDSR 模型,从海图稀疏水深点中重建高保真度海底数字高程模型(DEM),并结合实时水位数据生成动态等深线。实验结果表明,本文方法生成的数字高程模型及动态等深线在精度和形态真实性上均显著优于传统插值方法,可为 S-98 互操作应用提供技术支撑,对推动新一代电子海图的应用与发展具有重要的理论和实践价值。

**关键词:**电子海图(ENC);等深线;深度学习;超分辨率(SR);数字高程模型(DEM)

中图分类号:P285.3;P208 文献标志码:A

文章编号:1006-7736(2026)01-0012-09

doi:10.16411/j.cnki.issn1006-7736.2026.01.002

### Dynamic nautical chart depth contours generation based on super-resolution DEM and real-time water level interaction

LI Zhihao<sup>1</sup>, PAN Mingyang<sup>\*1</sup>, LI Shaoxi<sup>1</sup>, WANG Mo<sup>2</sup>,  
HU Jingfeng<sup>1</sup>, HAO Jiangling<sup>1</sup>, ZHANG Ruolan<sup>1</sup>

(1. Navigation College, Dalian Maritime University,  
Dalian 116026, China; 2. Tianjin Navigation Instruments  
Research Institute, Tianjin 300131, China)

**Abstract:** To address the limitation of sparse and insufficiently accurate bathymetric data in electronic navigational chart (ENC) products caused by incomplete S-102 bathymetric sur-

face data, which hinders reliable dynamic depth computation, this paper proposed a deep learning-based super-resolution solution. The approach employed an improved TSE-EDSR model to reconstruct high-fidelity seabed digital elevation models (DEMs) from sparse charted depth points, and integrated real-time water level data to generate dynamic depth contours. Experimental results show that the proposed method significantly outperforms traditional interpolation techniques in both accuracy and morphological realism of the generated DEMs and dynamic depth contours, providing technical support for S-98 interoperability applications and offering significant theoretical and practical value for the advancement of next-generation ENC systems.

**Key words:** electronic navigational chart (ENC); depth contours; deep learning; super-resolution (SR); digital elevation model (DEM)

## 0 引言

电子海图(ENC)中的等深线是保障航行安全的关键要素<sup>[1]</sup>。传统 ENC 提供的等深线是基于特定的深度基准面计算的,无法反映真实、动态的海洋环境。随着国际海道测量组织(IHO)S-100 框架和系列产品规范的推广,特别是 S-98 互操作性规范的提出,为实现动态等深线这一变革性应用提供了标准路径<sup>[2]</sup>。船载电子海图显示与信息系统或船舶交通服务系统等的应用可将 S-101 电子

收稿日期:2025-09-01;修回日期:2025-11-05

基金项目:国家重点研发计划课题(2024YFB4303603)

作者简介:栗之浩(2000—),男,硕士生;潘明阳<sup>\*</sup>(1975—),男,博士,教授,博士生导师,E-mail:panmingyang@dlmu.edu.cn

海图、S-102 测深表面与 S-104 水面航行水位动态数据层进行融合,从而生成可精确反映当前水深的动态等深线,提升导航或监管的精细度和安全性。

S-98 规范中定义的一种主要互操作形式是:将 S-104 数据叠加至 S-102 之上,生成动态安全等深线,并替代 S-101 中的水深数据,从而更精确地划分可航区域与不可航区域<sup>[3]</sup>。然而,由于高密度、高精度水深数据的测量成本高昂,且该类数据涉及主权安全的敏感地理信息,加之 S-102 产品规范尚未完善,导致目前可共享与流通的 S-102 产品极为稀缺。因此,其像电子海图产品那样实现大范围、大规模应用,仍需较长时间。因此,利用 S-101 海图中的水深数据与 S-104 水位数据进行互操作,可成为动态等深线生成的一种折中替代方案。这意味着,生成动态等深线所需的基础地形信息,只能来源于电子海图产品中经制图综合与抽稀处理的代表性水深点。由于原始数据点本质上具有稀疏性,若直接用于构建海底数字高程模型(DEM),其精度难以满足实际需求。基于该类粗糙 DEM 与实时水位融合生成的动态等深线,将出现位置偏差、不平滑甚至断裂等问题,无法满足安全航行与监管的精度要求。如何在仅依赖已发布的稀疏水深产品数据这一现实约束下,重建高精度的海底 DEM,并在此基础上实现动态等深线的智能、可靠生成,是必须解决的核心难题。

针对稀疏数据点重建连续地理表面的问题,学界与业界已探索多种技术方法。传统方法主要依赖空间插值算法,如反距离加权法、克里金插值法及样条函数法等<sup>[4]</sup>。该类方法在数据点密集场景下表现尚可,但面对官方海图数据普遍存在的稀疏性时,其数学假设易引发生成表面过度平滑的问题,导致地形高频细节难以恢复,这正是前述等深线质量缺陷的直接成因。近年来,随着深度学习的发展,基于深度学习的超分辨率(SR)技术在图像恢复领域取得突破,为水深 DEM 重建提供了新思路。部分研究者已尝试将图像 SR 模型应用于 DEM 数据,并证实其相比传统插值方法具有显著优势。Chen 等<sup>[5]</sup>将超分辨率领域的第一个深度学习超分模型 SRCNN 首次应用在 DEM 的超分辨率上,取得了较插值方法更好的结果。Xu 等<sup>[6]</sup>提出基于梯度先验和迁移学习的 DEM 超分辨率方法。该方法在误差指标和地形细节恢复方

面显著优于传统插值及端到端深度学习模型。Li 等<sup>[7]</sup>提出了基于边缘特征变换器的 DEM 超分辨率网络,提高了 DEM 重建的质量。这些研究表明,基于深度学习的 DEM 超分辨率潜力巨大,为本研究提供了坚实的理论基础与明确的创新方向。本文将深度学习图像超分辨率技术与动态水文信息相结合,构建了完整的动态等深线生成方案。

本文的主要贡献在于:提出一个完整的端到端动态制图方案,首次系统性构建了从官方稀疏数据输入到动态等深线输出的全流程自动化框架,直接响应 S-100 标准对智能化、动态化海图服务的需求;设计了针对地形特征优化的 SR 模型 TSE-EDSR,通过引入更适宜地形重建的复合损失函数,显著提升了模型对水下地貌细节的恢复能力;验证了仅依赖生产数据生成高质量动态等深线的可行性,为解决当前海图服务的核心痛点提供了低成本且高效的解决方案。

## 1 动态等深线智能生成框架与方法

### 1.1 总体技术框架

本文设计的从稀疏生产数据到高精度动态等深线智能生成的自动化处理框架如图 1 所示。该框架旨在解决现有电子海图数据稀疏性与动态航行需求之间的矛盾。

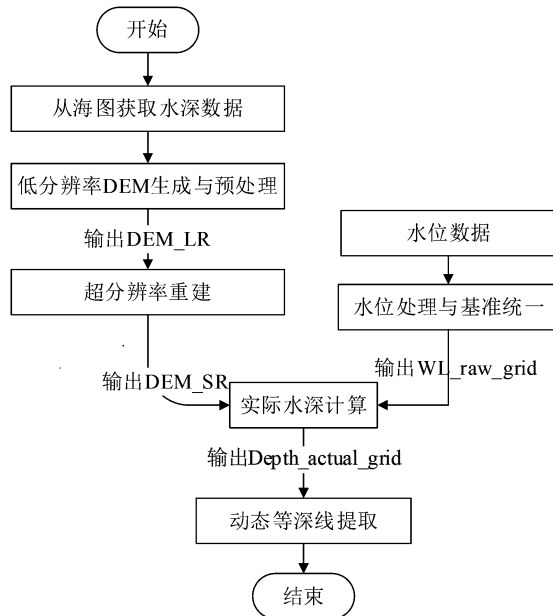


图 1 动态等深线智能生成框架

Fig.1 Intelligent generation framework for dynamic depth contours

流程始于海图产品中的稀疏水深点。首先,通过传统插值法将其初步网格化,生成低分辨率  $DEM_{LR}$ 。随后,将该  $DEM_{LR}$  输入核心超分辨率网络,重建高分辨率、高保真度的海底  $DEM_{SR}$ 。同时,框架实时获取水位数据,并进行水平与垂直基准的统一及空间配准。最后,通过融合  $DEM_{SR}$  与实时水位格网,计算出瞬时水深场  $DEM_{actual}$ ,并从中提取随水位实时变化的动态等深线。

## 1.2 面向地形优化的超分辨率网络

### 1.2.1 模型选择与适用性分析

该任务为单通道、连续数值场的超分辨率回归问题,目标是在提升峰值信噪比(PSNR)和降低均方根误差(RMSE)的同时,保持等深线的几何稳定性。EDSR 模型通过移除归一化(BatchNorm)层,采用残差卷积与残差缩放机制,使数值分布更加稳定<sup>[8]</sup>;其参数规模适中,在小样本数据与受限算力条件下更易实现收敛与部署,符合 DEM 的分段平滑先验。相比之下,基于生成对抗网络(GAN)或 Transformer 架构的超分模型,在任务场景适配性与数据需求方面存在局限,难以满足该任务的特定需求。

基于 GAN 的超分算法(如 ESRGAN)在目标

函数中引入对抗项,虽可提升自然图像的主观锐度,但为增强视觉锐度,往往牺牲像素级误差并引入纹理幻觉。针对单通道连续数值场任务,伪高频特征会导致等深线位置或形态偏移,破坏几何稳定性,与安全等深线需求相悖。同时,鉴别器学习的是自然纹理统计特性,而 DEM 的纹理特征表现为低纹理、强空间相关性,与 GAN 的纹理先验不匹配。此外,对抗训练对初始化和数据分布敏感,训练过程复杂,不利于海图生产系统的可追溯性与审计需求。因此,本文模型改进基于 EDSR 架构,优先保障数值精度与几何一致性。

基于 Transformer 的超分模型(如 SwinIR 和 HAT)虽具备强全局建模能力,但通常需依赖大规模预训练数据才能实现泛化。在本文数据规模有限的条件下,该类模型易出现过拟合现象,且对噪声干扰较为敏感。此外,Transformer 类模型因参数规模更大,计算开销显著增加,导致推理速度相对较低<sup>[9]</sup>。

### 1.2.2 网络架构

本文采用的 TSE-EDSR 网络架构由浅层特征提取、深度特征提取、上采样和重建四部分组成,具体结构如图 2 所示。

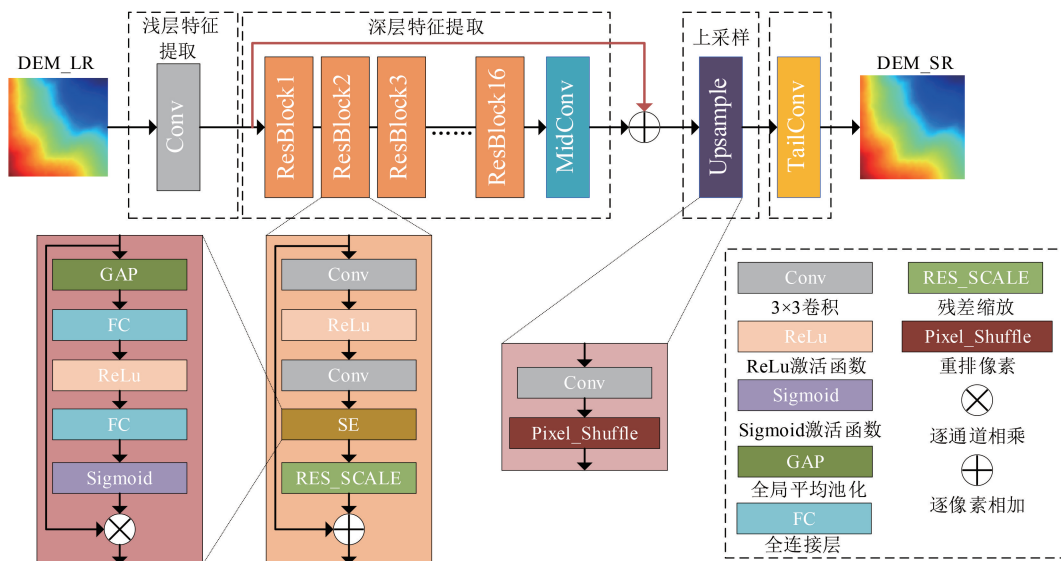


图 2 TSE-EDSR 网络架构

Fig.2 TSE-EDSR network architecture

首先,  $DEM_{LR}$  数据作为模型输入,通过初始卷积层进行浅层特征提取,将其从原始像素空间映射至 96 维特征空间,并输出浅层特征图。

其次,浅层特征图被送入 16 个级联的优化

ResBlocks 残差块及一个中间卷积层,输出包含深度上下文信息的特征图<sup>[11]</sup>。其中,每个残差块集成卷积变换与 SE 注意力机制调控,SE 模块通过学习通道权重来增强关键特征响应<sup>[12]</sup>。

随后,经过中间卷积层处理的深层特征图与初始浅层特征图通过主干残差连接进行融合,生成融合特征并输入至上采样模块。该模块采用 PixelShuffle 像素重组技术,将特征图的空间分辨率提升 4 倍,输出高分辨率的多通道特征图<sup>[13]</sup>。

最后,模型尾部卷积层将高分辨率特征图回归为单通道的高程值,最终输出重建的高分辨率 DEM。

### 1.2.3 地形优化复合损失函数

为确保重建的 DEM 不仅在数值上精确,而且在地理形态上更真实、合理,从而生成平滑、连续的等深线,本文采用复合损失函数,将像素级保真度约束与地形表面平滑度约束有机结合。

首先,采用平均绝对误差损失  $L_1$  作为主要的重建损失项<sup>[15]</sup>,计算模型输出  $DEM_{SR}$  与真实高分辨率水深  $DEM_{HR\_truth}$  之间的平均绝对差值。 $L_1$  损失对异常值具有良好的鲁棒性,有助于生成边缘清晰的重建结果。 $L_1$  的表达式为:

$$L_1 = \frac{1}{N} \sum_{i=1}^N \left( |DEM_{SR}^{(i)} - DEM_{HR\_truth}^{(i)}| \right) \quad (1)$$

式中: $N$  为像素总数。

为进一步提升后续等深线的质量,本文引入地形平滑损失项。该损失项并非直接比较模型输出与目标梯度的差异,而是通过惩罚模型输出自身内部过大的梯度变化来实现平滑损失。具体地,通过二维卷积操作,利用预设的差分卷积核作用于模型输出,分别计算其在  $x$  方向的一阶差分  $\nabla_x DEM_{SR}^{(i)}$  和  $y$  方向的一阶差分  $\nabla_y DEM_{SR}^{(i)}$ 。 $x$  方向的差分卷积核为  $[[[0,0,0],[0,-1,1],[0,0,0]]]$ , $y$  方向的差分卷积核为  $[[[0,0,0],[0,-1,0],[0,1,0]]]$ 。地形平滑损失  $L_{smooth}$  定义为一阶差分绝对值之和在所有像素点上的平均值,其数学表达式为:

$$L_{smooth} = \frac{1}{N} \sum_{i=1}^N \left( |\nabla_x DEM_{SR}^{(i)}| + |\nabla_y DEM_{SR}^{(i)}| \right) \quad (2)$$

式中: $\nabla_x$ 和 $\nabla_y$ 分别为通过一阶有限差分卷积核计算的水平和垂直梯度。

最终,模型的总损失函数由上述两者加权求和得到,即

$$L_{total} = (1 - \lambda_{smooth}) L_1 + \lambda_{smooth} L_{smooth} \quad (3)$$

式中: $\lambda_{smooth}$  为超参数,用于调节数据保真度与表

面平滑度之间的平衡。通过最小化该复合损失,模型被引导寻找一个既能准确拟合观测数据、又符合地形平滑先验的最优解,从而显著提升生成等深线质量。

### 1.3 实时水位融合与动态等深线生成

在 S-98 互操作框架下,可将经超分重建的海底高程  $DEM_{SR}$  与 S-104 水位数据进行时空一致化融合以生成动态等深线。

根据官方文档描述,S-104 数据支持 HDF5 编码的栅格数据存储格式,因此,水位与水深在本质上均为栅格场数据<sup>[17]</sup>。在 S-98 互操作框架下进行时空一致化融合时,首先对  $DEM_{SR}$  与水位数据  $W$  进行坐标与基准统一,即在同一水平坐标系与统一的垂直基准下进行融合计算。在时间轴上,选取目标时刻  $t$  的水位切片,随后,将  $W$  重采样到  $DEM_{SR}$  网格,使两者像元中心一一对应。针对水位场空间变化平缓的特性,采用双线性插值进行重采样,以兼顾数值精度与计算效率。在统一网络上计算瞬时动态水深:

$$Depth_{actual}(u,v,t) = W(u,v,t) - DEM_{SR}(u,v) \quad (4)$$

式(4)为随时间变化的完整水深表面。基于该动态水深场,即可采用等值线追踪算法,提取任意指定深度值的动态等深线,为自定义安全等深线查询、航行风险评估等高级应用提供了核心数据支撑。

## 2 实验与结果分析

### 2.1 核心超分辨率模型训练与验证

本节旨在通过定量与定性相结合的对比分析,独立评估本文提出的地形优化超分辨率网络相较于基线方法的性能表现。实验的核心目标是验证模型从低分辨率  $DEM_{LR}$  中恢复高分辨率  $DEM_{SR}$  的能力。

#### 2.1.1 数据集构建

模型训练数据采用 NOAA 公开发布的 10 m 分辨率沿海 DEM 产品。将原始数据切割为  $300 \times 300$  像素的图像块(patch)作为高分辨率真实样本  $DEM_{HR}$ 。为使模型专注于学习复杂地形,引入了基于地形复杂度(以高程标准差衡量)的均衡采样策略,提升了中、高复杂度地形样本在数据集中的比例。为模拟真实世界的低分辨率数据,采

用一套高级随机降质流程(随机高斯模糊、随机高斯噪声及随机下采样插值)生成  $75 \times 75$  像素的低分辨率样本。最终,构建了一个包含 2240 对训练样本、480 对验证样本和 480 对测试样本的高

质量数据集。数据覆盖区域如图 3 所示。其中,阴影部分为训练数据覆盖的海域。从左至右,从上至下依次为:夏威夷、关岛、美属萨摩亚、波多黎各、北马里亚纳群岛联邦、美属维尔京群岛。



图 3 数据覆盖区域(阴影部分)

Fig.3 Data-covered sea area (shaded)

### 2.1.2 对比方法与评价指标

为全面评估本文提出的地形优化超分辨率网络 TSE-EDSR 的性能,将 TSE-EDSR 分别与三种插值方法(Bicubic、Nearest、Lanczos)、EDSR(与 TSE-EDSR 共享相同骨干网络,仅用于消融研究以验证模型改进有效性)以及 SwinIR 和 HAT 模型进行对比。实验的评价指标采用图像重建公认的定量标准。本文采用峰值信噪比(PSNR)和均方根误差(RMSE)。

峰值信噪比(PSNR):

$$E_{\text{PSNR}} = 10 \lg \left( \frac{\text{Max}I^2}{E_{\text{MSE}}} \right) \quad (5)$$

式中:  $\text{Max}I$  为图像最大像素值;  $E_{\text{MSE}}$  为预测图像与真值图像之间的均方误差。该指标通过计算均方误差来衡量重建图像与真值图像在像素值上的保真度。 $E_{\text{PSNR}}$  值越高,表明重建结果失真越小,数值精度越高。

均方根误差(RMSE):

$$E_{\text{RMSE}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (6)$$

式中:  $y_i$  和  $\hat{y}_i$  分别为真值和模型预测值的高程值;  $N$  为像素总数。式(6)反映了预测值与真实值之间的平均误差,其值越低,表明模型的预测精度越高。

### 2.1.3 实施细节

训练基于 PyTorch 框架实现,所有实验均在配备 NVIDIA GeForce RTX 3070 GPU 的 PC 上完成。训练采用 Adam 优化器,初始学习率设置为  $1 \times 10^{-4}$ ,并应用余弦退火策略动态调整<sup>[18]</sup>。BatchSize 为 4,共完成 200 个训练轮次(Epochs),每个 Epoch 在验证集上进行一次验证,并保存最优模型参数。

在正式训练前,通过小规模实验(50Epochs,批次大小提升为 8)验证了超参数对结果的影响。本文重点考察与任务最相关的两类超参数:  $\lambda_{\text{smooth}}$  与通道数  $C$ ,结果分别如图 4、图 5 所示。




图 4  $\lambda_{\text{smooth}}$  对 PSNR 的影响

Fig.4 The influence of  $\lambda_{\text{smooth}}$  on PSNR

由图 4 可知,PSNR 在  $\lambda_{\text{smooth}} = 0.05$  时,取得峰值;当  $\lambda_{\text{smooth}} > 0.05$  时,过强平滑带来的细节损

失使 PSNR 下降。因此,本文  $\lambda_{smooth}$  取值为 0.05。




图 5 通道数  $C$  对 PSNR 的影响

Fig.5 The impact of channel count  $C$  on PSNR

由图 5 可知,PSNR 随通道数  $C$  的增加而上升,但其边际收益随着  $C$  的增加逐渐递减。综合考虑参数量与时延,本文  $C$  取值为 96。

训练与验证的总损失函数收敛曲线及训练过程中验证集的 PSNR 曲线分别如图 6、图 7 所示。




图 6 训练与验证集损失曲线

Fig.6 Training and validation loss curves

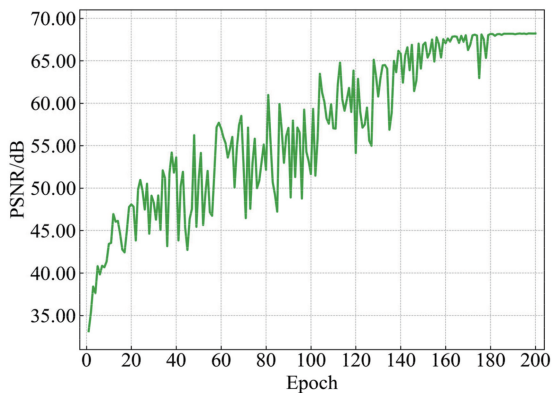


图 7 验证集 PSNR 曲线

Fig.7 Validation PSNR curve

#### 2.1.4 模型性能评估

为定量评估模型从低分辨率 DEM 中恢复高精度 DEM 的能力,本文在测试集上采用 TSE-ED-

SR、几种代表插值方法<sup>[19]</sup>及几种代表深度学习方法,对精度指标、计算效率指标 Flops(每秒浮点运算次数)与推理速度指标 FPS(每秒处理图像数)进行对比。对比模型 HAT 与 SwinIR 通道数均设为 96,窗口大小设置为 5,层数设置为 6,通过控制参量使得 Flops 与 TSE-EDSR 相当,其他超参数、优化器、批次及训练方法均保持一致。表 1 为不同超分辨率模型在测试集上的定量性能对比结果。

表 1 不同超分辨率模型在测试集上定量性能对比结果

Tab.1 Quantitative performance comparison of different super-resolution models on the test set

模型	RMSE/m	PSNR/dB	Flops/G	FPS
Lanczos	3.61	62.24	N/A	N/A
Nearest	4.91	58.89	N/A	N/A
Bicubic	3.32	62.88	N/A	N/A
EDSR	2.21	66.33	45.89	169.77
SwinIR-S	1.89	67.19	43.89	39.24
HAT-S	1.97	66.84	42.96	38.05
TSE-EDSR	1.69	68.18	45.91	117.62

由表 1 可知,本文提出的 TSE-EDSR 在精度上表现最优。在计算复杂度方面,TSE-EDSR 的 FLOPs (G)与 EDSR 基本一致,吞吐效率也保持较高水平;相较于 HAT-S/SwinIR-S,其 FPS (GPU)明显更高。上述结果表明,所引入的 SE 注意力机制与地形平滑损失在几乎不增加计算开销的前提下,显著提升了重建精度,同时兼顾推理效率,更适合实际应用场景的部署需求。

## 2.2 动态等深线生成框架端到端评估

### 2.2.1 框架端到端效果可视化

在进行端到端评估之前,首先对超分辨率重建效果进行可视化评估。鉴于已发布的电子海图(ENC)产品中,测深点并非原始测试点的逐点完整展示,而是依据 IHO S-4 编绘规则进行选择性的呈现;在小比例尺海图上,测深点间距应保持明显不均匀,以暴露数据间隙。为此,本文采用坡度自适应下采样技术从  $DEM_{LR}$  抽取稀疏点,模拟复杂地形区采样密度更高、平坦区采样密度更低的数据分布特征,并以  $DEM_{HR}$  为统一基准进行精度评估。图 8 为三个测试集样本从稀疏点到  $DEM_{SR}$  的可视化及与真实  $DEM_{HR}$  对比的超分辨率效果。由图 8 可知,仅依靠稀疏采样点,框架可逐步还原 DEM 的细节纹理,这为后续潮位叠加与等深线精

化奠定了基础。

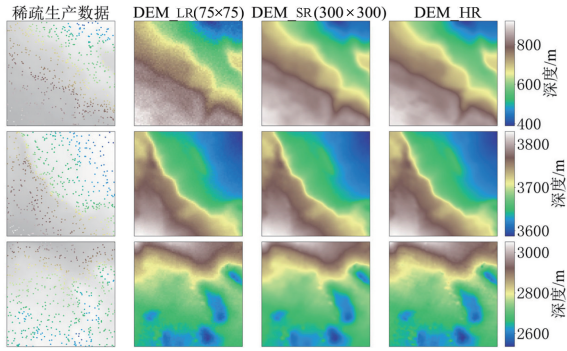


图 8 超分辨率效果图

Fig.8 Super-resolution effect diagram

选取图号为 C1313100 的 ENC 海图数据进行框架的测试应用。首先提取出海图的水深点要素,将点投影到平面,并通过 Bicubic 插值生成  $DEM_{LR}$ ,再经超分处理后叠加潮位提取等深线。图 9 为等深线修正效果图。由图 9 可知,潮位的引入显著改变了等深线的空间分布,可为电子海图的使用者提供随水位变化的动态等深线分布,为可航区判断等决策提供依据。

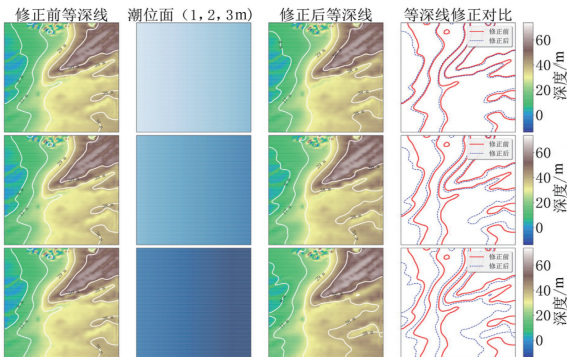


图 9 等深线修正效果图

Fig.9 Contour correction effect diagram

### 2.2.2 动态等深线几何精度评价

为验证所提出框架在潮位改正后生成动态等深线的几何精度,本节采用可视化定性分析与定量评估指标相结合的方法,对等深线几何误差进行系统性评估。首先,采用本文方法和传统插值方法分别得到修正后的等深线。接着,将其与以  $DEM_{HR}$  为基准叠加相同水位后计算的真值等深线进行配准比较(等深线的提取方法一致),提取级别设定为自适应 6 级。定量分析评价指标包括平均垂向距离、平均 Hausdorff 距离及等深线长度误差三类。

(1) 平均垂向距离 (APD)。设在第  $k$  级等深

线上,预测曲线上任一点  $p_i$  到真值曲线的最小欧氏距离为:

$$d_i^{(k)} = \min_{q \in C_{gt}^{(k)}} \theta \| p_i - q \|_2 \quad (7)$$

则该级别的平均垂向距离定义为:

$$L_{APD}^{(k)} = \frac{1}{|C_{pred}^{(k)}|} \sum_i d_i^{(k)} \quad (8)$$

全局误差取各级的平均值,即

$$E_{APD} = \frac{1}{N} \sum_{k=1}^N L_{APD}^{(k)} \quad (9)$$

(2) 平均 Hausdorff 距离 (HD)。HD 可反映最坏情况时的误差,即

$$E_{HD}^{(k)} = \max \left\{ \max_{p \in C_{pred}^{(k)}} \min_{q \in C_{gt}^{(k)}} \| p - q \|_2, \max_{q \in C_{gt}^{(k)}} \min_{p \in C_{pred}^{(k)}} \| p - q \|_2 \right\} \quad (10)$$

同样,求跨级平均,得到整体 HD。

(3) 等深线长度误差 (LE)

等深线长度误差可表示为:

$$E_{LE}^{(k)} = \frac{\left| \ln \left( C_{pred}^{(k)} \right) - \ln \left( C_{gt}^{(k)} \right) \right|}{\ln \left( C_{gt}^{(k)} \right)} \times 100\% \quad (11)$$

分别采用本文方法与传统插值方法对 480 份测试样本进行处理,得到经本框架修正后的等深线。随后计算 APD、HD、LE 三项评价指标并取算术平均值,整体结果如表 2 所示。

表 2 等深线精度定量评估结果

Tab.2 Quantitative evaluation results of contour line accuracy

模型	APD/px	HD/px	LE/%
Lanczos	3.06	18.01	76.81
Nearest	2.92	17.89	74.01
Bicubic	2.83	17.11	65.86
SwinIR	1.52	11.28	10.45
HAT	1.62	11.93	12.14
TSE-EDSR	1.23	9.67	6.31

由表 2 可知,本文方法在等深级别上的 APD 为 1.23 px, HD 为 9.67 px, LE 为 6.31 %,均优于其他方法,表明本文的深度超分辨率与潮位改正的联合框架能够有效保持等深线的几何形态与位置精度。但仅通过表 2 中的数值难以全面反映整体误差分布特征。为此,如图 10 所示,本文展示了 480 个样本在不同方法下的误差分布,从而更

直观地证明本文方法的优越性。

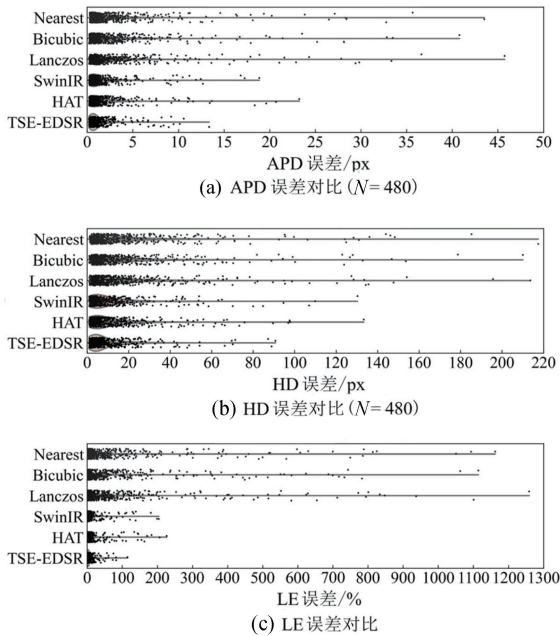


图 10 不同超分辨率方法等深线精度误差分布

Fig.10 Error distribution of contour line accuracy obtained by different super-resolution methods

由图 10 可知,本文方法的等深线精度误差显著低于其他对比方法,验证了深度学习超分辨率技术在该任务中的有效性与显著优势。为进一步定性评估,将预测等深线  $C_{pred}$  与真实的修正后等深线  $C_{gt}$  进行套叠比较,并截取对比区域绘制如图 11 所示的视图。其中,红色实线表示  $C_{gt}$ , 蓝色虚线表示  $C_{pred}$ 。

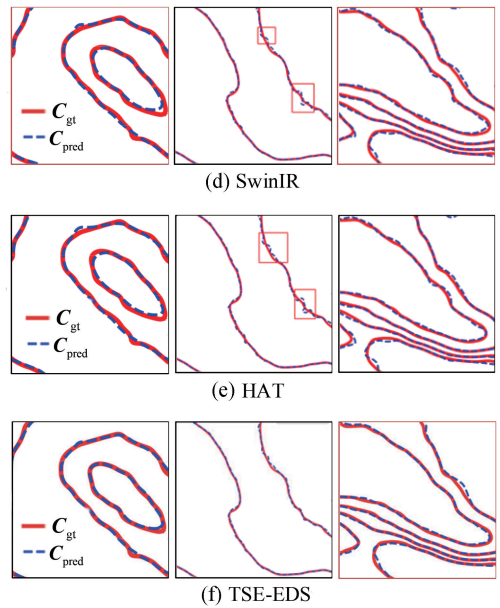
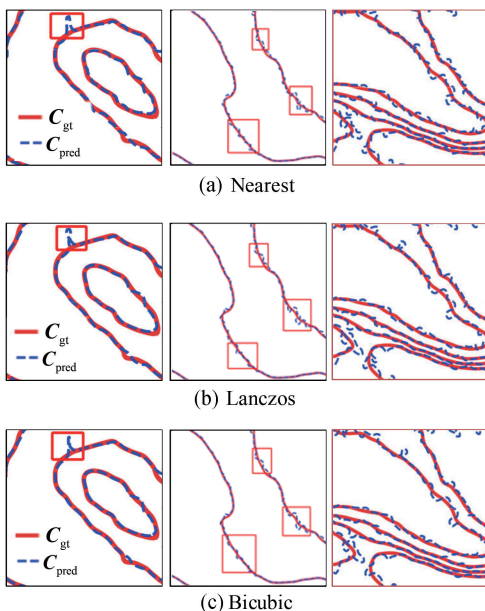


图 11  $C_{pred}$  与  $C_{gt}$  的可视化叠加比较

Fig.11 Visualization overlay comparison between

$C_{pred}$  and  $C_{gt}$

由图 11 可知,在截取的观测窗口内,采用传统方法进行超分辨率重建等深线时,第一个样本出现畸形,第二个样本出现锯齿,第三个样本(地形较为复杂)出现杂乱线条。这是由于传统方法在超分辨率重建阶段未能很好地重建水深分布,导致叠加水位后等深线提取失效。深度学习方法 SwinIR 与 HAT 在图 2 也出现轻微的锯齿。本文方法生成的等深线在主干走向上,两者几乎完全重合,仅在个别陡坡处存在亚像素级偏移;等深线局部的转折与环状封闭结构均能被准确重建,与上文定量评估方法所得的优秀指标高度吻合。

综上,本文方法通过融合稀疏水深数据与水位数据,实现了精确且随水位实时变化的动态等深线生成,显著提升了电子海图与水位产品的互操作准确性。

### 3 结 语

本文聚焦 S-98 互操作趋势下的核心技术挑战,设计并实现了一套根据官方稀疏 ENC 数据生成高精度动态等深线的自动化流程。通过引入深度学习超分辨率模型,有效解决了传统方法在处理稀疏数据时地形细节丢失、精度不足的问题。实验证明,利用本文框架生成的动态等深线在几何精度与形态保真度上均具有显著优势。

本文研究的价值在于直接响应了 S-98 标准的技术实现需求。S-98 Level 1 互操作的核心机制之一,便是利用高精度网格水深等动态数据层替换或交错 ENC 中的静态地表特征。本文方法生成的高分辨率 DEM,正是实现了这一机制所必需的高精度网格水深数据层,从而为动态安全等深线等高级导航功能的实现提供了坚实的底层数据基础,尤其是在 S-102 产品稀缺与不完备的情况下具有重要的应用价值。但本文研究也存在不足,当地形较为复杂且原始数据点过于稀疏时,深度学习模型将不能较好地重建原始地形,会出现较大误差。

总之,本文研究不仅为电子海图从静态向动态服务转型提供了一个可行的技术方案,也为 S-100 标准体系的落地应用扫清了一个关键的数据障碍,对推动下一代智能化电子海图系统的发展具有明确的实践意义。

#### 参考文献(References):

- [1] 惠大涛,王如政,白亭颖,等.一种面向海图生产的等深线及深度区生成方法研究[J].测绘与空间地理信息,2025,48(5):163-166.  
HUI D T, WANG R Z, BAI T Y, et al. Research on a generation method of isobaths and depth areas for nautical chart production[J]. Geomatics and Spatial Information Technology, 2025, 48(5):163-166. (in Chinese)
- [2] 缪锦根,白亭颖,姜悦,等.数字化浪潮下的海图转型:从纸质到电子的演变[J].中国海事,2025(2):21-26.  
MIAO J G, BAI T Y, JIANG Y, et al. Transformation of nautical charts in the digital wave: evolution from paper to electronic[J]. China Maritime, 2025(2):21-26. (in Chinese)
- [3] International Hydrographic Organization. S-98: Data Product Interoperability in S-100 Navigation Systems. Edition 1.0.0[S], 2021.
- [4] ZHANG Y F, YU W H. Comparison of DEM super-resolution methods based on interpolation and neural networks[J]. Sensors, 2022, 22(3): 745.
- [5] CHEN Z X, WANG X W, XU Z K, et al. Convolutional neural network based DEM super resolution[J]. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2016, 41: 247-250.
- [6] XU Z K, CHEN Z X, YI W W, et al. Deep gradient prior network for DEM super-resolution: Transfer learning from image to DEM[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2019, 150: 80-90.
- [7] LI Z J, MI D Y, LI C H, et al. EF-TSR: edge feature transformer-based DEM super-resolution network[J]. Remote Sensing Letters, 2025, 16(4): 389-399.
- [8] 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.
- [9] LIANG J Y, CAO J Z, SUN G L, et al. Swinir: image restoration using swin transformer[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021: 1833-1844.
- [10] CHEN X Y, WANG X T, ZHANG W L, et al. Hat: hybrid attention transformer for image restoration[J]. arXiv preprint, 2023, arXiv:2309.05239.
- [11] JIAO D L, WANG D J, LV H Y, et al. Super-resolution reconstruction of a digital elevation model based on a deep residual network[J]. Open Geosciences, 2020, 12(1): 1369-1382.
- [12] HU J, LI S, SUN G. Squeeze-and-excitation networks[C]//Proceedings of the IEEE conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.
- [13] ZHANG Y J, ZHENG Z, LUO Y M, et al. A CNN-based subpixel level DSM generation approach via single image super-resolution[J]. Photogrammetric Engineering & Remote Sensing, 2019, 85(10): 765-775.
- [14] HANIN B. Universal function approximation by deep neural nets with bounded width and ReLU activations[J]. Mathematics, 2019, 7(10): 992.
- [15] WU Z, MA P F. ESRGAN-based DEM super-resolution for enhanced slope deformation monitoring in Lantau island of Hong Kong[J]. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2020, 43: 351-356.
- [16] ZHAO H, GALLO O, FROSIO I, et al. Loss functions for image restoration with neural networks[J]. IEEE Transactions on Computational Imaging, 2016, 3(1): 47-57.
- [17] International Hydrographic Organization. S-104: Water Level Information for Surface Navigation. Edition 1.0.0[S], 2021.
- [18] LOSHCHILOV I, HUTTER F. SGDR: stochastic gradient descent with warm restarts[J]. arXiv preprint, 2016, arXiv:1608.03983.
- [19] REUTER H, NELSON A, JARVIS A. An evaluation of void-filling interpolation methods for SRTM data[J]. International Journal of Geographical Information Science, 2007, 21(9): 983-1008.