

行简化的同时,保持部件的重要几何特性,实现点云的减小率达到 50%-90%,在保证数据处理效率的前提下,不降低形貌恢复的准确性。本项目拟以目标配准+特征配准相结合的方法,通过对目标点云优化,对 BIM 设计模型进行粗略配准,并对螺栓孔、节点、截面轮廓等特征点进行精确配准,使其达到  $\pm 0.5\text{mm}$  以内。在此基础上,通过对异型钢结构设计和施工规程的分析,确定各工序的误差限值,即:预制件表面曲率误差不超过  $\pm 0.5\text{mm}$ ,螺栓孔位中心偏差不超过  $\pm 0.5\text{mm}$ ,安装后的安装位置误差不超过  $\pm 5$  毫米,部件之间的连接间隙在 2 毫米以内,误差在  $\pm 2$  毫米以内,在进行模型对比时,必须严格依照这个阈值来判断是否符合要求,以防止由于阈值的不一致而引起的质量判断偏差。

#### 4.3 现场施工应用的工艺质量控制

现场施工应用环节的质量控制核心是实现三维扫描技术与现场装配施工的高效协同,保证了测量数据的准确快速引导施工过程中的纠偏工作。首先,组建三维控制测量团队,并配有专职的扫描操作员和数据处理员,使扫描、数据处理和施工说明无缝连接,在扫描数据处理完毕后,30 分钟之内向施工团队反馈偏差分析结果;其次,对点扫描点进行标准化,将控制点放置非受力部位,不易发生碰撞的部位,并对目标进行防护,以避免因目标移动或损伤而造成的点云连接偏差。在此基础上,将扫描检测融入到每一道工序的质量验收中,在工厂生产前,在现场构件吊装就位后,在拼接工序结束后,都要经过 3D 扫描,确认通过后,才能进行下一道工序,从而达到“扫描检测-合格验收-工序推进”的施工过程,防止因不合格工序而造成的偏差积累。

### 5 工程应用验证

以某城市 3.8 万  $\text{m}^2$  文化中心异型钢结构工程为验证对象,该工程主要由 216 个非标准异形结构组成,其中包括 216 个异形截面,节点间距  $\leq 10\text{mm}$ ,整体空间位置偏差  $\leq 5\text{mm}$ 。在使用过程中,对 36 个不符合要求的零件进行了预制件的二次扫描和修正,达到了 100% 的出厂合格率;在

吊装过程中对地基预埋件的误差进行复核和校正,借助三维跟踪测量仪对零件进行精确定位;在拼接过程中,对多个构件表面的法向偏差和焊接变形进行了校正;整个验收阶段的扫描比对结果表明,最大误差为 4.7 毫米,项目一次通过。本项目采用 3D 扫描技术,实现构件预制尺寸误差小于  $\pm 0.5\text{mm}$ ,大大减少单个构件废品率,提高施工效率,实现装配合格率 98.5%,返工率降低 90%,钢结构装配施工成本较预算降低 23%,工期缩短 22 天,充分验证了三维扫描技术在异型钢结构装配中的可行性和有效性,并论证所提出的应用工艺及质量控制要点的实用性。

### 6 结语

综上所述,本文以异型钢结构为研究对象,针对其装配造型复杂、精度要求高、传统测量手段受限等问题,通过对 3D 扫描与异型钢结构装配工艺的适应性研究,梳理其在工厂预制-现场吊装定位-构件拼接组装-整体验收全过程中的应用关键技术,建立涵盖点云采集-处理-模型比对-现场施工应用的全过程质量监控体系,并以文化中心异型钢结构为例进行应用验证。研究成果将揭示三维扫描技术对异型钢结构进行高精度数字化检测和可视化控制,提高其装配精度和建造效率,减少返工率和废品率,是促进异型钢结构装配建造数字化和精细化的核心技术。未来,结合 BIM、数字孪生、人工智能等技术对其进行深度优化,采用数字孪生技术,将点云数据和装配工艺进行实时关联,并采用人工智能算法对点云进行自动化分析,并对其进行误差预警,从而提高其技术应用的智能化程度。对推动建筑钢结构行业的数字化转型与高质量发展具有重要的现实意义。

#### 参考文献

- [1] 杨明珠. 基于三维激光扫描点云数据特征点提取及建筑物重建[D].昆明理工大学,2017.
- [2] 基于三维激光扫描的建筑物逆向建模实现方法及应用[J]. 工业建筑,2020,50(03):178-181+189.
- [3] 三维激光扫描技术在大跨度机库屋盖钢结构施工过程中的应用[J]. 建筑施工,2020,42(04):487-489.

# The Identification of Marine Substrate Types Based on Side-Scan Sonar Images

Jinlong Wang<sup>1,2</sup>

1. Shanghai Institute of Geological Exploration Technology, Shanghai, 200072, China

2. Shanghai Engineering Research Center for Ground Subsidence Control, Shanghai, 200072, China

## Abstract

In order to improve the image blurring problem and the phenomenon of excessive reliance on manual discrimination and high cost in identifying marine sediment types, a marine sediment type recognition model based on improved DeepLabV3+side scan sonar images is proposed. This model combines coordinate attention mechanism with DeepLabV3+algorithm for local detail preservation, and uses graph neural network and boundary loss perception algorithm for global spatial structure modeling to enhance the overall substrate type recognition performance of the model. The experimental results showed that the recognition F1 score of the research model reached a maximum of 93.56%, the Kappa coefficient and average intersection to union ratio reached 0.942 and 0.896, respectively, the average task processing time was 34.11ms, and the overall classification accuracy reached 94.58%. In summary, the model proposed by the research institute has high-precision recognition performance and can effectively balance the contradiction between accuracy and efficiency, achieving robust recognition of different types of marine sediments and providing reliable data support for marine material surveying in society.

## Keywords

Side scan sonar; Marine sediment identification; DeepLabV3+; GCN; CA; Boundary loss awareness

## 基于侧扫声呐图像的海洋底质类型识别研究

王金龙<sup>1,2</sup>

1. 上海市地质勘查技术研究院, 中国·上海 200072

2. 上海地面沉降控制工程技术研究中心, 中国·上海 200072

## 摘要

为了改善在识别海洋底质类型出现的图像模糊问题及过度依赖人工判别、成本高昂的现象, 研究提出了一种基于改进DeepLabV3+侧扫声呐图像的海洋底质类型识别模型。该模型通过结合坐标注意力机制与DeepLabV3+算法进行局部细节保留, 图神经网络与边界损失感知算法进行全局空间结构建模, 增强模型整体的底质类型识别性能。实验结果表明, 研究模型的识别F1分数最高达到93.56%, Kappa系数与平均交并比分别达到0.942与0.896, 平均任务处理耗时为34.11ms, 整体的分类准确率达到94.58%。综上所述, 研究所提模型具备高精度的识别性能, 且能够有效平衡精度与效率之间的矛盾, 做到稳健识别不同类型的海洋底质, 为社会进行海洋物质勘测提供了可靠的数据支撑。

## 关键词

侧扫声呐; 海洋底质识别; DeepLabV3+; GCN; CA; 边界损失感知

## 1 引言

伴随着人口增长与陆地资源的逐渐减少, 海洋勘测已成为当今社会的重点拓展领域, 不少学者基于海底的工程力学性质, 进行海底光缆的铺设、海上风电工程建设等研究<sup>[1]</sup>。海洋底质作为维护海洋权益的核心依据, 其决定了海洋生态环境保护与修复的基础参数, 同时也直接影响着污染物的迁移与吸附<sup>[2]</sup>。进行海洋底质类型的识别, 有助于提升海底工程建设的承载力及稳固力, 也可提升声呐扫描的参数优化与精确度提升<sup>[3]</sup>。

由于海洋环境的特殊性, 直接的采样点相比于陆地环境大幅度减少, 底质空间变化剧烈, 附加天气与海况的影响, 进行底质识别的难度充满了不确定性, 也增加了获取实物样本的成本与时间<sup>[4]</sup>。目前, 社会进行海洋底物识别的方法有直接采样、声学遥感分类、机器学习等, 但因为取样过程的干扰、物理机制的限制及训练数据的过度依赖, 导致底质类型的识别精度受到严重影响、分析结果失真化<sup>[5-6]</sup>。而DeepLabV3+作为语义分割的模型, 通过空洞卷积与空间金字塔的结构可有效处理地物尺度不一的问题, 并且控制图像识别的细节丢失现象<sup>[7]</sup>。坐标注意力机制(Coordinate Attention, CA)则是通过位置嵌入的方式提升处理位置信息的性能, 捕获长程依赖性<sup>[8]</sup>。因此, 研究采用DeepLabV3+与CA进行图像声呐侧扫, 并提

【作者简介】王金龙(1988-), 中国江苏盐城人, 硕士, 工程师, 从事海洋测量、卫星导航与定位研究。

出海洋底质类型识别模型，旨在提高空间感知精度，强化底物特征的提取性能，构建更具判别性的特征表示。研究的创新性在于构建了一种基于 CA 引导的 DeepLabV3+ 海洋底质识别模型，在技术上融合 CA 机制与语义分割网络，强化复杂海底环境下的特征建模能力，在应用上将该模型用于海洋底质类型识别，为工程地质分区提供了更精细、更可靠的底质类型识别方案。

## 2 基于 CA-DeepLabV3+ 算法的海洋底质识别模型构建

### 2.1 结合 DeepLabV3+ 与 CA 的声呐扫描算法设计

当前获取海洋底物的方式主要是通过船只、箱式等方式取样，钻探样本的费用较高且耗时偏长<sup>[9]</sup>。常用的声学探测，例如多波束、侧扫声呐获取的多偏向于间接数据测量，可能产生异物同谱的现象，影响勘测图像的清晰度与准确性<sup>[10]</sup>。而 DeepLabV3+ 的多尺度特征捕获优势，可有效识别大小尺度不同的底物类型<sup>[11]</sup>。CA 机制有助于建立地理空间规律，进行更高效的位置感知<sup>[12]</sup>。因此，研究将 CA 机制与 DeepLabV3+ 结合，构成 CA-DeepLabV3+ 侧扫声呐图像算法，旨在提升空间定位精度，缓解异物同谱现象。CA-DeepLabV3+ 算法进行侧扫声呐图像采集的过程如图 1 所示。

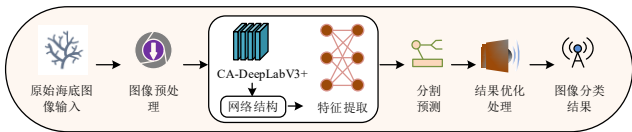


图 1 CA-DeepLabV3+ 进行侧扫声呐图像采集的过程 (图像来源: <https://icon.suca999.com/>)

如图 1 所示，CA-DeepLabV3+ 算法将原始的侧扫声呐图像进行标准化处理，通过降噪处理与数据增强等操作降低图像畸变的可能性。处理后的图像输入至 CA-DeepLabV3+ 网络中，通过骨干网络特征进行多阶段特征提取，利用空洞空间金字塔的池化进行多个并行且扩张率不同的空洞卷积，逐步生成不同分辨率的特征图，有效捕捉多个尺度感受野的上下文信息。CA-DeepLabV3+ 算法进行空洞卷积映射海洋底物特征向量的过程如表达式 (1)。

$$y[i, j] = \sum_{i=1}^H \sum_{j=1}^W x[i + d \cdot L, j + d \cdot L] k[L, L] \quad (1)$$

式 (1) 中， $y[i, j]$  表示海洋底物特征图的坐标像素值， $x$  表示输入的原始海洋特征图， $d$  和  $L$  分别表示空洞率与滤波器尺寸， $k[L, L]$  表示卷积权重参数， $H$  表示输入特征向量的高度， $W$  表示输入特征向量的宽度， $L$  表示卷积和原始尺寸。随后，CA 机制将位置信息嵌入通道注意力中，沿水平和垂直方向分别编码长程依赖关系，生成不同特征所对应的注意力权重，提升算法进行目标阴影与真实回波区分的准确性，并聚焦于细长线性结构的描绘。CA-DeepLabV3+ 算法增大声呐扫描感受野的过程如表达式 (2)。

$$rf = L + (L - 1) \times (d - 1) \quad (2)$$

式 (2) 中， $rf$  表示声呐扫描感受野的分辨率。最后，经过多层级特征融合与逐像素分割，将深层分类语义信息与浅层空间细节结合，输出一个与输入图像大小相同的概率图，保持目标边缘的完整性，并提升图像连续性与识别准确率。CA-DeepLabV3+ 算法嵌入海洋底物信息模块的过程如表达式 (3)。

$$\begin{cases} z_c^w(w) = \frac{1}{H} \sum_{0 \leq j \leq H} x_c(j, w) \\ z_c^h(h) = \frac{1}{W} \sum_{0 \leq i \leq W} x_c(h, i) \end{cases} \quad (3)$$

式 (3) 中， $z_c^w(w)$  和  $z_c^h(h)$  分别表示宽度为  $w$  的第  $c$  个通道水平方向的特征图和高度  $h$  的第  $c$  个通道垂直方向的特征图， $x_c$  表示第  $c$  个通道的输入特征图， $H$  表示输入特征图的高， $W$  表示输入特征图的宽。

### 2.2 引入 GCN-BAL 算法的底质识别模型优化

研究采用 CA-DeepLabV3+ 算法进行侧扫声呐，旨在实现对海底目标的精准分割与地物分类，但由于 CA-DeepLabV3+ 算法主要通过卷积神经网络的架构进行感受野的扩大，对于全局结构关系的建模能力较弱，对非线性空间数据的适应性也有待提高。而结合图卷积网络 (Graph Neural Network, GCN) 与边界感知损失 (Boundary-Aware Loss, BAL) 的 GCN-BAL 算法具有强大的全局关系建模能力，擅长处理非结构化与非线性数据<sup>[13-14]</sup>。因此，研究引入 GCN-BAL 算法优化 CA-DeepLabV3+ 算法，构成最终的 GCN-BAL-CA-DeepLabV3+ 海洋底质识别模型，简称 GBCD 模型，旨在提升图像全局拓扑的一致性，防止过度卷积造成边界模糊。GBCD 模型识别海洋底质的过程如图 2 所示。




图 2 GBCD 模型识别海洋底质的过程

如图 2 所示，GBCD 模型将侧扫声呐采集的原始图像经过预处理后，消除声波衰减和姿态变化带来的畸变影响，为后续模型提供高质量的输入。处理后的数据输入 GCN 模块进行全局关系的建模，模型通过将图像像素构建为图节点，利用邻接样本图节点进行关系建模，推理出不同底质类型之间的语义关联与空间共现规律，使模型学习不同底质类型之间的共现关系，纠正像素级分类的错误。GBCD 模型进行海洋底质特征建模节点传递的过程如表达式 (4)。

$$X_i^{(k)} = \gamma^{(k)}(X_i^{(k-1)}, \bigoplus_{j \in N(i)} \phi^{(k)}(X_i^{(k-1)}, X_j^{(k-1)}, e_{ij})) \quad (4)$$

式 (4) 中， $X_i^{(k)}$  为海洋底质特征节点  $i$  在第  $k$  层的特征， $e_{ij}$  为海洋底质特征节点  $i$  到节点  $j$  的边上特征。海洋底

质特征节点利用附近信息生成融合底质特征信息阶段如表表达式 (5)。

$$\gamma^{(k)}(X_i^{(k-1)}, NeighborMessage) \quad (5)$$

式 (5) 中,  $\gamma^{(k)}$  和  $NeighborMessage$  分别表示聚合邻域信息后生成的底质特征信息与聚合邻居节点信息。在 DeepLabV3+ 模块中, 模型进行局部特征精细化, 保留低级空间细节特征, 并融合边界、阴影轮廓等特征。随后, CA 机制强化关键信息, 抑制背景、噪声等冗余信息。BAL 再进行通过强化边缘区域的损失权重, 使图像边缘清晰化, 引导模型关注边界处的分类准确性, 解决类别不平衡问题, 防止模型为了追求高度准确率而将所有区域都预测为占主导地位的泥底。最后, 融合特征通过 softmax 层, 并分配对应像素的底质类别标签, 输出编码图, 展示出不同海洋底质的分布边界和范围。GBCD 模型优化获得真实分割海洋底质标签和预测海洋底质分割结果的过程如表达式 (6)。

$$\begin{cases} B_{gt} = DetectBoundary(S_{gt}) \\ B_{pred} = DetectBoundary(S_{pred}) \end{cases} \quad (6)$$

式 (6) 中,  $S_{gt}$  表示真实分割海洋底质标签,  $S_{pred}$  表示预测分割海洋底质结果,  $B_{gt}$  表示  $S_{gt}$  的边界,  $B_{pred}$  表示  $S_{pred}$  的边界。

### 3 GBCD 模型的海洋底质类型识别性能验证

#### 3.1 实验环境与数据集说明

研究实验环境参数设置如下, 操作系统为 Windows 10, GPU 为 NVIDIA GeForce RTX 2080 Ti 11G, 内存大小为 16.0GB, CPU 为 Intel(R) Core(TM) i7-10700K 4800MHz, 深度学习框架为 PyTorch, 学习率为 0.01, 开发语言为 Python 3.8, 迭代次数 100 次。实验数据集采用声呐图像自动分类数据集 (Automatic Classification of SONar images, ACSON) 数据集和海底沉积物实地验证数据集 (Ground-truth Seafloor Sediment, GSS) 数据集。ACSON 数据集主要用于沉船、飞机残骸等目标检测和底质分类, 其中标注了不同底质类型和人为目标, 例如沙波、岩石、海草等, 适用于验证海洋底质类型的识别。GSS 数据集来源于美国地质调查局, 提供了多个沿海地区的底质采样点以及底质类型, 适合验证模型对底质类别的识别精度。

#### 3.2 GBCD 模型底质类型识别性能的评估

研究采用海洋通用分割模型 (Marine Segment Anything Model, SeaSAM)、海洋神经隐含表面 (Neural Implicit Surfaces for Ocean, NeuS-Ocean)、知识图谱增强的图神经网络海底底质分类模型 (Knowledge Graph Enhanced GNN for Seabed, KG-GNN) 三种海洋底质识别模型与 GBCD 模型在 ACSON 数据集上进行比较。为了验证 GBCD 模型的识别准确优势, 研究将上述四种模型的测试结果通过识别精确率、召回率及 F1 分数三项指标衡量, 其测试结果如表 1 所示。

表 1 模型指标测试结果

数据集类型	模型	精确率 (%)	召回率 (%)	F1 (%)
ACSON	GBCD	94.27	92.86	93.56
	SeaSAM	86.92	85.47	86.19
	NeuS-Ocean	88.63	87.94	88.28
	KG-GNN	91.45	90.12	90.78
GSS	GBCD	92.58	91.23	91.90
	SeaSAM	84.95	83.78	84.36
	NeuS-Ocean	87.36	86.52	86.94
	KG-GNN	89.74	88.61	89.17

如表 1 所示, GBCD 模型在两个数据集上的 F1 分数分别达到 93.56% 与 91.90%。综合表现可以看出, 三种对比模型中 KG-GNN 模型的结果最佳, 但在两个数据集上的精确率相较于研究所提模型仍然降低了 2.82% 与 2.84%。由以上结果可知, GBCD 具有优秀的底质类型识别性能, 通过 DeepLabV3+ 架构中引入 GCN 算法及 CA 机制的深度耦合, 能够有效捕捉海洋底质样本非线性数据关系, 解决建模长距离依赖性上不足的问题, 提升模型进行定位与底质类别强相关的特征区域识别的精准聚焦性能, 从而使得模型在提高识别精确率的同时, 确保整体的分割精度。为了进一步验证 GBCD 模型的优势, 研究将四种海洋底质类型识别模型在 ACSON 数据集上测试, 采用 Kappa 系数与平均交并比 (Mean Intersection over Union, MIoU) 两项指标衡量模型预测的底质类别与实测样本的一致性。若 Kappa 系数越高, 证明分类效果越佳, 是评估分类图可靠性的关键指标, 而 MIoU 可直观反映模型对每一类底质覆盖范围的预测准确度。其测试结果如图 3 所示。




图 3 模型指标测试结果图

从图 3(a) 可以得知, GBCD 模型迭代 100 次后的 Kappa 系数为 0.942, 均高于三种对比模型。在图 3(b) 中, GBCD 模型的 MIoU 结果为 0.896, 同样优于三种对比模型。四种模型结果最低的是 SeaSAM 模型, 与研究所提模型相比, 两项指标分别降低了 0.063 与 0.087。由以上结果可知, Kappa 系数反映出 GBCD 模型在不同底质类型识别的过程中具有清晰决策边界, 可有效避免类别识别混淆的情况发生, MIoU 系数证明 GBCD 模型像素级分割任务上的卓越性能, 与真实标注区域重合度较高。这得益于 GBCD 模型的 BAL 结构与 DeepLabV3+ 模块, 清晰化局部细节, 输出更真实、更高精度的底质区域分布范围图。为了证明 GBCD 模型具备更多的识别优势, 研究将上述四种模型在 ACSON