引文格式：韩维涛,任东宇,高燕军,等. 人工河网双重决策智能化选取方法[J]. 地理空间信息, 2026, 24(6):41-45. doi:10. 3969/j.issn. 1672-4623.2026.06.007

人工河网双重决策智能化选取方法

韩维涛[1,2]，任东宇[3,4*]，高燕军[5]，周何帆[3,4]，罗　浩[3,4]，向净云[3,4]

（1. 中国地质大学（武汉），湖北 武汉 430074；2. 河北省制图院，河北 石家庄 050031；
3. 自然资源部第三地理信息制图院，四川 成都 610100；4. 自然资源部数字制图与国土信息应用重点实验室，湖北 武汉 430072；
5. 山东省地图院，山东 济南 250014）

摘　要：提出一种面向人工河网的智能化选取方法，基于深度学习模型和人机协同的双重决策，首先基于Half Edge模型生成平面有向图，构建Stroke模型，并使用图神经网络进行筛选，形成初始河网骨架；再根据专家经验通过人机协同方式进行微调，达到应用标准。实验表明，该方法实现了不同数据源、地理环境及制图用途下的自适应选取，兼顾语义信息与空间分布，显著提升数据缩编效率和数据库质量，具有良好的跨场景泛用性，可广泛支撑地图制作、地理信息服务等工作。

关键词：人工河网选取；双重决策；深度学习；人机协同；Half Edge

中图分类号：P283　　**文献标志码：**B　　**文章编号：**1672-4623（2026）06-0041-05

Artificial River Network Intelligent Selection Method Based on Dual Decision-making Framework

HAN Weitao[1,2], REN Dongyu[3,4], GAO Yanjun[5], ZHOU Hefan[3,4], LUO Hao[3,4], XIANG Jingyun[3,4]

(1. China University of Geosciences, Wuhan 430074, China;
2. Hebei Provincial Institute of Cartography, Shijiazhuang 050031, China;
3. The Third Geoinformation Mapping Institute of Ministry of Natural Resource, Chengdu 610100, China;
4. Key Laboratory of Digital Mapping and Land Information Application, Ministry of Natural Resources, Wuhan 430072, China;
5. The Map Institute of Shandong Province, Jinan 250014, China)

Abstract: In this paper, we proposed an intelligent selection method for artificial river networks based on a dual decision-making framework integrating deep learning models and human-computer collaboration. Firstly, we used the Half Edge model to construct a planar directed graph, and established a stroke model. Then, we employed a graph neural network for initial screening and decision-making to form a preliminary river network skeleton. Finally, expert knowledge was incorporated through human-computer collaborative decision-making to fine-tune and perform batch deletion on the output, ensuring compliance with production standards. Experimental results demonstrate that the proposed method achieves adaptive selection across diverse data sources, geographical environments, and mapping purposes, effectively balances semantic information with spatial distribution, significantly improves the efficiency of data reduction and the quality of databases, and exhibits strong cross-scenario generalization capability. This approach can robustly support map production and geographical information services.

Key words: artificial river network selection, dual decision-making, deep learning, human-computer collaboration, Half Edge

河网作为自然地理环境的核心要素与人类活动的重要空间载体，是地形图、专题地图及各类地理空间数据库的关键组成部分。在地图制图领域，受地图承载力限制，随着比例尺缩小，须对河网进行取舍与概括，这一过程称为河网选取[1-3]。其目标是在保持河网整体结构、密度对比及水文地理特征的前提下，筛选出最重要的河流，以达成地图表达的清晰性与地理真实性的平衡。

河网又分为自然河网和人工河网，两种河网的特点存在较大差异[1]，主要体现在以下两个方面：①整体图形特征方面，人工河网呈网格状分布，河渠间往往呈直角相交，而自然河网中的河流大多呈锐角相交。自然河网的主支流关系明显，人工河网则多呈格状分布，无明显主支流关系。②个体特征方面，人工河渠比较平直，弯曲较少，而自然河流由于受到地形的影响，弯曲较多。这就导致自然河网的选取方法不能直接用于人工河网的选取，因此，研究人工河网选取方法具有重要理论价值和应用价值。

项目来源：地图图融合更新和产品派生关键技术研究与应用（2026YFHZ0112）。

第一作者简介：韩维涛（1987—），在读博士研究生，高级工程师、注册测绘师，主要研究方向为测绘地理信息工程、国土空间用途管制，E-mail：576344881@qq.com。

通信作者：任东宇（1989—），硕士，高级工程师，主要研究方向为地图制图与地理信息工程应用，E-mail： 360079316@qq.com。

1 人工河网选取方法

目前，针对人工河网的选取研究成果较少，主要是依靠人工规则驱动搭配简单优化算法进行决策，属于半智能化选取。本文提出了一种“深度学习+人机协同”的双重决策方法，实现端到端的全智能化选取。

1.1 传统选取

在人工河网半智能化选取方法中，具有代表性的是武芳等[1]提出的基于“知识决策”的人工河网选取方法，车一鸣[2]提出的相关方法，还有翟仁健[3]提出的基于遗传多目标优化的人工河网自动选取。

尽管传统半自动化选取方法目前在实践中得到了广泛应用，相较于纯人工选取，选取效率和效果有明显提升。但面对不同场景，不同数据源，都需要重新设计选取规则，泛用性较差，智能化层级较低。

1.2 “深度学习+人机协同”双重决策选取

随着人工智能技术的发展，机器学习和深度学习模型强大的数据分析能力和自主学习能力，让其在地理信息领域得到广泛应用，并且展现出了广阔的潜力。例如在遥感影像解译方面，图像分割模型展现出了强大的性能，如DeepLabV3+[4]，UNet[5]和SAM[6]等；在遥感影像超分辨率重建方面，GAN网络[7-8]有其得天独厚的优势；在道路自动选取领域[9-11]，图神经网络大放异彩。而在天然河流自动选取研究中，机器学习模型被广泛应用，如BP神经网络[12-13]，SVM支持向量机[14-15]。

但此前在天然河网和道路网的选取研究中，为了最大化实现智能化和自动化，未充分考虑实际生产中的应用效果。

针对上述问题，本文创新性地提出一种“深度学习+人机协同”双重决策的人工河网选取方法，第一重决策是深度学习决策，由深度学习模型主导的骨架构建，筛选出人工河网的整体框架；第二重决策是人机协同决策，基于专家经验，通过人机协同对人工河网骨架进行微调优化，最终达到符合应用标准的人工河网选取效果。具体创新点如下：

1）引入了深度学习模型用于人工河网的骨架搭建。相较于人工预设规则和优化算法进行骨架搭建的方式，深度学习模型的自主学习能力和应对不同场景的泛用性更强。

2）提出了一种双重决策方法用于人工河网的选取，相较于利用深度学习或机器学习模型的单重决策，加入了基于专家经验的人机协同微调进行辅助决策。双重决策在保证选取效率和智能化程度的基础上，优化了整体选取效果，更加符合应用要求。

2 研究方法

本文研究内容主要为2个决策模块：一是深度学习决策，深度学习模型主导的骨架构建过程；二是人机协同决策，基于专家经验，通过人机协同进行微调优化。

2.1 人工河网数据源

本研究数据源为江苏省宿迁市人工河网地理实体数据，具备平原地区典型的渠网化特征，丘陵、山地等地貌区域的人工河网数据尚在收集中。

在实验中，为了验证本方法的泛用性，从地理实体数据库中选取了3块具备典型特点的区域用于实验，分别包含1 258条、775条、1 330条人工河流。其分布情况如图1所示。



图1 选取的3个区域数据示例

3个区域的河网结构呈现出显著差异。区域A的河网分布均匀，拓扑连通性高，形成的网格结构清晰完整。区域B的河网则呈不规则分布，整体连通性中等，网格结构模糊且较为破碎。区域C在结构上具有混合特征：其部分区域存在与区域A类似的大片清晰网格，同时也分布着与区域B相似的细碎模糊网格，但整体河网的连通性在三者中最弱。

研究时，也充分考虑了水系面对人工河网的影响，如图2所示，选取了包含水系面的3个区域数据，从中可以看出，选取的3个区域水系面数据较少，这是由于人工河网多为沟渠，通常修建在田地中，与相连通的天然湖泊、天然池塘等相隔较远，因此，在本次研究中，受研究区域影响，并未将与湖泊、水库、水塘等面状水系的连通性作为人工河网选取的特征参考。

最后，实验以1∶100 000、1∶250 000、1∶500 000三种比例尺的人工河网选取为研究对象。

2.2 深度学习决策

深度学习决策模块包含构建平面有向图、构建人工河网Stroke、搭建深度学习实验模型三部分内容。

第一，构建平面有向图，将组成人工河网实体的每条边看作方向相反的两条半边Half Edge，基于Half Edge模型构建平面有向图$G(V,E)$，其中，G为非连通图，V为顶点集合，E为半边集合，设集合中的每

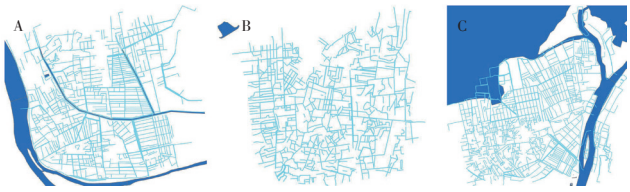


图2　包含水系面的3个区域数据示例

条半边 $e=u\to v$，u 为半边起点，v 为半边终点。基于构建的平面图 $G(V,E)$ 作初始化选取，舍弃不足长度指标的孤立和悬挂人工河段，构建过程如图3。

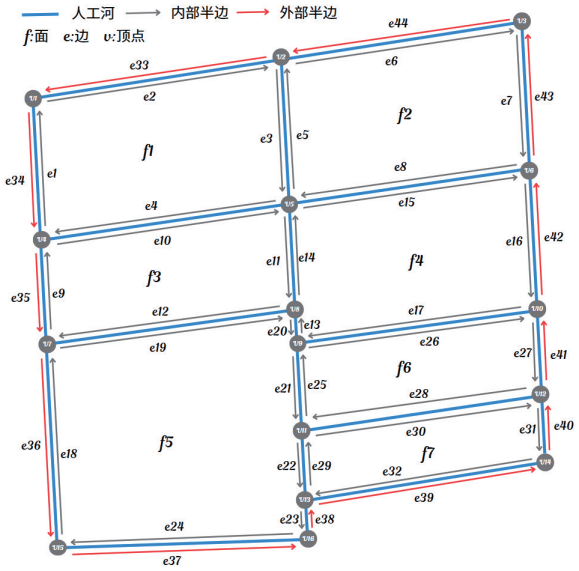


图3　人工河网构建平面有向图

计算平面图 $G(V,E)$ 的面片集合 Faces={ f_1，f_2，f_3,…}，计算得到每个Face关联的HalfEdge信息（$f1=\{e_1,e_2,e_3,e_4,\cdots\}$），设组成每个Face的几何点集 $V(f_i)=\{v1(x_1,y_1),v2(x_2,y_2),v3(x_3,y_3),\cdots\}$，计算每个Face的面积，公式如下：

$$S(f_i)=\frac{1}{2}\left|\sum_{i=1}^{n}x_iy_{i+1}-x_{i+1}y_i\right| \tag{1}$$

再使用深度优先搜索（DFS）遍历整个有向图 $G(V,E)$，以找到每个节点 v 所属的连通分量（最大连通子图）。遍历每个Face，根据组成当前Face的每条Half Edge长度占比计算所有Half Edge的瓜分面积，公式如下：

$$S(E_i)=\frac{\mathrm{Len}(E_i)}{\mathrm{Len}}S(f_{E_i}) \tag{2}$$

式中，$\mathrm{Len}(E_i)$ 为某半边 E_i 的长度；Len 为 E_i 所在Face(f_i)的所有半边长度总和；$S(f_{E_i})$ 为半边 E_i 所在Face的面积。

第二，构建人工河网Stroke，基于平面图 $G(V,E)$ 构建Stroke模型 $\mathrm{Stro}(E)$，依次遍历每一条Half Edge，根据语义信息和弧段夹角将首尾相接的相邻HalfEdge划入同一Stroke。

每个构建出的Stroke，在后续模型训练过程中，会作为图节点训练样本，因此，还需要选取并计算相应的Stroke属性作为图节点特征。在本实验中，选择了2种维度的Stroke属性。其一，物理属性，由构建出的Stroke计算所得，选取了3种：Stroke总长度、Stroke的总瓜分面积、Stroke连通性，物理属性能表征人工河网的物理形态；其二语义属性，由人工河系天然自带，采用离散型选取了3种：是否为重点实体（0代表否、1代表是）、是否有名称（0代表否、1代表是）、等级（干渠：2、支渠：1、其他或无值：0）、是否关联天然河湖（0代表否，1代表是），语义属性能表征人工河网的语义形态。每条Stroke的总长度，计算公式如下：

$$\mathrm{Len}\left(\mathrm{Stro}\left(E^{'}\right)\right)=\sum_{i=1}^{n}\mathrm{Len}(E_i) \tag{3}$$

式中，$\mathrm{Stro}\left(E^{'}\right)$ 为半边集合 $E^{'}$ 构成的Stroke，每条Stroke的总瓜分面积，计算公式如下：

$$S\left(\mathrm{Stro}\left(E^{'}\right)\right)=\sum_{i=1}^{n}S(E_i) \tag{4}$$

每条Stroke的连通性，为同时与多少个其他Stroke相连的数量，通过ArcGIS工具进行计算并统计。其余语义属性则在地理实体数据库中直接读取对应字段，在进行人工河流的收集整理中已完毕[16]。

第三，搭建深度学习实验模型，在模型的选择上，综合大量的实验效果并借鉴了天然河网和道路选取的研究后，选择了图卷积网络模型，

最终模型的框架图如图4所示，主要模块为用于特征推理的两层图卷积层，首层图卷积将节点自身特征与其一阶邻居特征相融合，生成初步的中间表征；第二层图卷积则进一步融合这些中间表征，捕获更广泛的图结构依赖。

在进行模型训练和推理决策之前，$\mathrm{Stro}(E)$ 需要被处理为图结构，才能传入模型进行训练和测试。将每一个Stroke都作为一个图节点，构建为对偶图，方法采用了此前道路自动选取研究中，将Stroke数据转化为图结构的方法，图节点之间的关联性也同样采用了欧氏距离作为关联信息，其计算过程分为两步，第一步计算Stroke几何中心，计算公式如下：

$$C_j=\left(\frac{1}{n_j}\sum_{i=1}^{n_j}x_i,\frac{1}{n_j}\sum_{i=1}^{n_j}y_i\right) \tag{5}$$

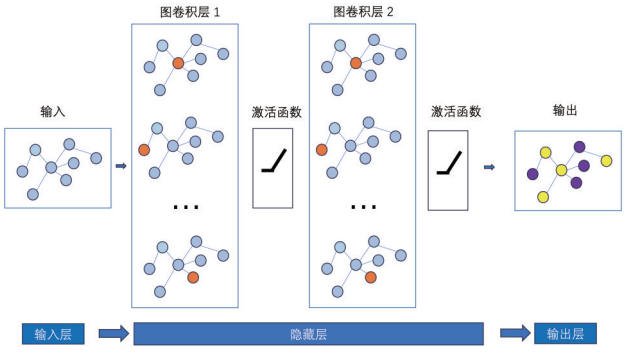


图4 图卷积网络模型图

式中，C_j 为第 j 个stroke的几何中心，第二步计算欧氏距离，计算公式如下:

$$d_{jk}=\sqrt{\left(x_c^j-x_c^k\right)^2+\left(y_c^j-y_c^k\right)^2} \tag{6}$$

式中，2个stroke的中心坐标分别 (x_c^j,y_c^j) 和 (x_c^k,y_c^k)；d_{jk} 为第 j 个stroke和第 k 个stroke之间的欧氏距离。

经过深度学习模型决策后，会为每个比例尺生成一个初步的人工河网骨架SkeletonStrokes。未被模型选取的原始河网段并不会被直接删除，而是被保留并附加特定标签，留待后续通过人机协同交互流程进行进一步的校验与调整。

2.3 模型训练策略

深度学习决策模块搭建完毕后，并不能直接进行使用，其核心的图卷积网络模型，需要传入样本进行训练。

模型训练所用平台为NVIDIA Geforce RTX 3090 GPU，在训练配置上，采用Adam优化器，初始学习率为0.002。学习率调度器选用StepLR，其衰减率设置为0.95，每30个epoch衰减一次。训练的总epoch上限为20 000。损失函数采用交叉熵。此外，训练过程辅以早停机制进行调控：以训练损失为监控指标，并设置耐心值为300。这意味着当损失值连续300个epoch未下降时，训练将自动停止，并保存此刻的性能最优模型。

此前的道路自动选取研究发现，做跨比例尺选取任务时，选取效果会受到正负样本不平衡的影响，因此，本实验也设置了缓解样本不平衡的机制，简而言之，通过重新设定正类的判定阈值(初始默认为0.5)，最终比例尺由大到小的阈值设定分别为[0.3, 0.5, 0.6]。

2.4 人机协同决策模块

为了保证选取效果更加贴合应用需要，本研究采用了人机协同的方式，来校正深度学习决策构建出的人工河网骨架。

首先，将未被选取的Stroke，根据其划分总面积进行排序。并基于开放根定律确定总选取数量 $n'=n\sqrt{(m/m')^x}$，其中 n' 为原人工河stroke数量，n 为选取后的stroke数量，m 为原图比例尺分母，m' 为选取后的目标比例尺分母，x 为选取等级，则舍掉的stroke数量 $\text{num}=n-n'$，再统计SkeletonStrokes中已经确定的数量进行调整。然后，从划分面积值最小的Stroke着手，判断该Stroke是否为锁定状态或者含有边界半边，若是则跳过该Stroke，若不是则将该Stroke标记舍弃状态，标记舍弃Stroke的同时将其每条HalfEdge的相邻Face进行合并，同时更新平面图拓扑结构，并将合并后的Face所关联的Stroke加入SkeletonStrokes，标记为锁定状态。一直重复遍历判断，直至满足选取数量要求，若遍历完所有Stroke仍然不够选取要求，则恢复到初始锁定的SkeletonStrokes状态，再重复。最后，将全部标记舍弃的Stroke在地图窗口高亮显示，人工对选取不合理的地方进行微调。微调方式为：机器根据不同的操作命令获取手动选择的应舍而未舍的人工河段数据输入，以及被算法错误舍弃的人工河段数据输入，机器根据上述2种情况分别进行标记舍弃或者取消舍弃操作，得到微调后的人工河段所在的整条Stroke选取结果输出，通过快捷键对所有标记为舍弃的人工河段执行批量删除操作，并将执行过程记入程序日志和回撤集合，用于撤销回退。

3 实验结果

本实验以专家人工选取的结果作为标准参照，采用以下2个指标对模型性能进行量化评估：$F1$ 值以及选取一致率。其中，$F1$ 值以单个河段（Stroke）为基本计算单元，P 为精确率（Presion），R 为召回率（Recall），而选取一致率则以单条河流为计算对象，能够更为直观地反映整体选取效果。

$$F1=(2\times P\times R)/(P+R) \tag{3}$$

选取一致率=(正确选取应选取+正确不选取不应选取)/2 (4)

3.1 整体选取效果

本研究选取的江苏省宿迁市3个区域的选取效果，实验完成了1∶100 000、1∶250 000、1∶500 000三个比例尺中人工河网的选取。从实际选取效果来看分布均匀，网眼清晰的区域A效果最好，而特征最为复杂的区域C效果最差。尽管本方法在区域C上的选取效果不如区域A和区域B，但委托专家和生产人员评

估，选取效果符合应用需要。从不同比例尺的选取效果来看，随着比例尺的缩小，选取效果越来越好，这主要得益于，小比例尺下，需要呈现的要素量就越少，并且需要被选取的人工河流中，特征更为明显的大干渠占很大比重，更容易被模型所识别。

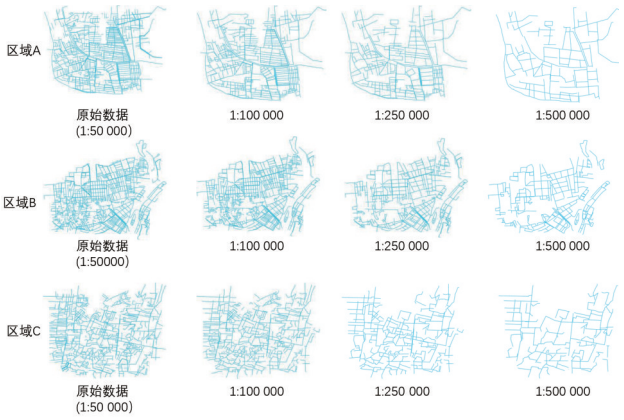


图5　不同比例尺下成都市道路网选取效果

3.2　深度学习单重决策

本实验还验证了去除人机协同决策模块仅使用深度学习模块进行单重决策的效果，结果如表1所示，从表中可以看出，当没有人机协同决策模块进行辅助微调时，3个区域所有比例尺的选取效果都出现了显著下降，特别是人工河网更为复杂的区域C，深度学习单重决策的作用，已经不足以支撑应用需要。

表1　深度学习单重决策效果

区域	指标/%	比例尺		
		1∶100 000	1∶250 000	1∶500 000
区域A	*F*1	90.16	91.11	94.35
	选取一致率	82.98	85.31	87.20
区域B	*F*1	83.32	84.13	85.24
	选取一致率	76.12	79.30	81.27
区域C	*F*1	75.32	76.14	78.16
	选取一致率	67.14	71.19	72.72

4　结　语

本文创新性地构建了一种融合深度学习与专家经验的人工河网智能化选取方法，显著提升了人工河网在地图制图综合中的选取表现。实验结果表明，相较于单一的深度学习决策，引入人机协同的双重决策机制所得到的选取结果更贴合实际生产需求。该研究为制图综合领域中人工河网自动化选取技术的应用，提供了新的研究思路与发展方向，具有重要的理论价值和实践意义。

参考文献

[1] 武芳,谭笑,王辉连,等. 顾及网络特征的复杂人工河网的自动选取[J]. 中国图象图形学报,2007,12(6):1103-1109

[2] 车一鸣,邓维熙,冯飞军,等. 耦合机器学习与连通性修正的河流选取模型[J]. 地理空间信息,2025,23(9):22-26

[3] 翟仁健,武芳,邓红艳,等. 基于遗传多目标优化的人工河网自动选取模型[J]. 测绘学报,2008,52(1):108-113

[4] Chen L C, Papandreou G, Schroff F, et al. Rethinking Atrous Convolution for Semantic Image Segmentation[J]. arXiv Preprint arXiv:1706. 05587,2017

[5] Ronneberger O, Fischer P, Brox T. U-Net:Convolutional Networks for Biomedical Image Segmentation[C]//International Conference on Medical Image Computing and Computer-assisted Intervention. Cham:Springer International Publishing,2015:234-241

[6] Kirillov J A, Mintun E, Ravi N, et al. Segment Anything[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision,2023:4015-4026

[7] Goodfellow I, Pouget-abadie J, Mirza M, et al. Generative Adversarial Networks[J]. Communications of the ACM, 2020,63(11):139-144

[8] Creswell A, White T, Dumoulin V, et al. Generative Adversarial Networks:An Overview[J]. IEEE Signal Processing Magazine,2018,35(1):53-65

[9] 马超,熊顺,蒋丹妮. 图卷积神经网络在道路网选取中的应用[J]. 测绘科学,2022,47(12):200-205

[10] 朱余德,杨敏,晏雄锋. 利用图卷积神经网络的道路网选取方法[J]. 北京测绘,2022,36(11):1455-1459

[11] 罗浩,廖顺华,周何帆,等. 城市全域道路多级自动选取方法[J]. 地理空间信息,2025,23(6):121-125

[12] Schmidhuber J. Deep learning In Neural Networks:An Overview[J]. Neural Networks,2015,61:85-117

[13] Rumelhart D E, Hinton G E, Williams R J. Learning Representations By Back-propagating Errors[J]. Nature, 1986, 323(6088):533-536

[14] Cortes C, Vapnik V. Support-vector Networks[J]. Machine Learning,1995,20(3):273-297

[15] Boser B E, Guyon I M, Vapnik V N. A Training Algorithm for Optimal Margin Classifiers[C]//Proceedings of the Fifth Annual Workshop on Computational Learning Theory,1992:144-152

[16] 罗浩,任东宇,周启,等. 层次化表达模型辅助的导航与制图道路网匹配方法[J]. 测绘科学,2023,48(10):225-236