引文格式：李旭,万继康,雍斌. 利用轻量化卷积神经网络提取东部平原湖泊[J]. 地理空间信息, 2025, 23(1): 75-79. doi:10. 3969/j.issn. 1672-4623.2025.01.016

利用轻量化卷积神经网络提取东部平原湖泊

李　旭[1,2]，万继康[1,3]，雍　斌[1,2*]
（1. 河海大学 水文水资源与水利工程科学国家重点实验室，江苏 南京 210098；
2. 河海大学 水文水资源学院，江苏 南京 210098；3. 江苏大学 计算机通讯与工程学院，江苏 镇江 212013）

摘　要：湖泊水体与非水体光谱的空间特征易混淆，传统水体提取方法难以满足快速、高精度的水体遥感制图需求。鉴于此，首先利用轻量化卷积神经网络图像分类模型和语义分割模型构建了水体自动化提取模型（AWEM）；再利用河流、湿地数据库和形态学后处理方法剔除河流、湿地等信息；最后提取并分析了我国东部平原湖区的湖泊。将AWEM在3个高度异构的场景中进行测试，结果表明AWEM的精度达到了95.28%以上，且拥有较高的效率，适用于复杂区域地表水的高精度提取。研究结果可为中高空间分辨率湖区的湖泊测绘提供参考。

关键词：遥感影像；深度学习；轻量化卷积神经网络；水体提取；湖泊制图
中图分类号：P237　　**文献标志码：**B　　**文章编号：**1672-4623（2025）01-0075-05

Research on the Eastern Plain Lake Extraction Based on Lightweight Convolutional Neural Network

LI Xu[1,2], WAN Jikang[1,3], YONG Bin[1,2]
(1. State Key Laboratory of Hydrology and Water Resources and Hydraulic Engineering Science, Hohai University, Nanjing 210098, China;
2. College of Hydrology and Water Resources, Hohai University, Nanjing 210098, China;
3. School of Computer Communication and Engineering, Jiangsu University, Zhenjiang 212013, China)

Abstract: The spatial characteristics of lake water bodies and non-water body spectra are easily confused, and traditional water body extraction methods are difficult to meet the needs of rapid and high-precision water body remote sensing mapping. To address this issue, we used lightweight convolutional neural network image classification model and semantic segmentation model to construct a water automatic extraction model (AWEM) at first. Then, we used river and wetland databases and morphological post-processing method to remove information such as rivers and wetlands. Finally, we extracted and analyzed the lakes in the plain lake area of eastern China. We tested AWEM in three highly heterogeneous scenarios. The results show that the accuracy of AWEM achieves over 95.28%. The model has high efficiency and can be used for high-precision extraction of surface water in complex areas. The study can provide reference for lake surveying and mapping in lake areas with medium and high spatial resolution.

Key words: remote sensing image, deep learning, lightweight convolutional neural network, water body extraction, lake mapping

湖泊具有调节河川径流、储存饮用水源、记录区域环境变化、维持区域生态系统平衡等多种特殊功能[1-2]。据统计，我国拥有面积大于等于1 km^2的天然湖泊2 800多个[3]，其中53%的湖泊分布在青藏高原地区（海拔高于4 000 m），受人为活动影响较小[4]。我国东部地区湖泊较少，但由于人口大量聚集、城镇化进程和工业化发展的加速，东部湖泊水质安全面临挑战，因此利用遥感数据的时空信息对东部湖泊水体进行连续监测是当前研究的热点。目前针对光学图像常用的水体提取方法包括谱间关系法、机器学习和深度学习等。谱间关系法主要利用遥感图像中不同波段之间的光谱反射率关系来提取水体。常用的水体提取指数包括归一化水体指数（NDWI）、归一化差异水体指数[5]（MNDWI）、自动化水体提取指数[6]（AWEI）等。这些指数通过计算图像中像元之间的谱间关系，提供了水体与非水体的区别特征，具有简单直观、计算速度快等优势，但易受山区阴影和城市内部高大建筑物阴影的影响，在地表水提取的适用性和精度上存在一定局限性。机器学习算法以各种能反映水体和非水体的遥感影像特征为输入，基于选定的分类器（支持向量机、随机森林等）进行水体提取。随着机器学习技术的不断发展，基于深度学习提取水体的算法逐

第一作者简介：李旭（1998—），硕士研究生，研究方向为水文遥感，E-mail：1143248014@qq.com。
通信作者：雍斌（1975—），博士研究生，教授，主要研究方向为降水与水文模拟预报，E-mail： 20080006@hhu.edu.cn。

步出现，能够应对复杂多变的环境和处理大规模遥感数据，如Isikdogan F等[7-8]提出了全卷积神经网络Deep WaterMap和DeepWaterMap+，这种新的结构化模型可将地表水与陆地、雪、冰、云和阴影区分开。然而，深度学习方法需要大量带标签的数据和丰富的计算资源，阻碍了其应用范围。此外，以往的地表水制图通常在局部尺度上进行，所提方法在相应的研究区域表现良好，但运用到其他区域时，准确性往往会降低，因此需要开发一种适用于高度异质背景下的自动化高效水体提取模型。鉴于此，本文利用轻量化卷积神经网络图像分类模型和语义分割模型构建了一种水体自动化提取模型，并结合湖泊、湿地数据库和形态学后处理提取了东部平原湖区的湖泊。研究结果可为中高空间分辨率湖泊测绘提供方法参考。

1 研究区概况和数据来源

东部平原湖区是我国第二大湖区，包括长江、淮河中下游区域，黄河、海河下游区域以及大运河附近区域的大小湖泊[9]，是我国湖泊最密集的地区之一。我国五大淡水湖（鄱阳湖、洞庭湖、太湖、洪泽湖和巢湖）都属于东部平原湖区湖泊[10]。研究区靠近海洋，具有优越的水热条件、发达的水系、丰富的水源补给，气候具有温暖湿润的特点；降水分配不均匀、变化大，导致丰水期和枯水期的湖泊面积波动较大。河流和湖泊关系密切，在调蓄江河方面湖泊发挥了不可估量的作用。随着经济的迅速发展，区域人类活动的干扰越来越严重，湖泊水体富营养化程度高、水质污染严重。本文采用的数据为2014-01-01—2022-01-01覆盖东部平原湖区的6 950景Landsat8影像和492景Sentinel-1A遥感影像。Sentinel-1A的GRD数据集（该数据与后向散射系数有关）是经Sentinel-1工具箱正射校正的产品，包括地面范围探测场景，每个场景包括3种分辨率（10 m、25 m、40 m）和4个波段组合（对应场景极化），数据每天更新，发布后2 d内可在GEE中检索到。

2 研究方法与技术路线

2.1 水体自动化提取模型构建

定义输入特征图中 (i,j) 位置的数据向量为 $\boldsymbol{x}_{ij}$，编码器层和解码器层的数学表示为：

$$y_{ij}=f_k(\boldsymbol{x}_{i+\theta i,\,j+\theta j}) \tag{1}$$

$$x_k^{'}=g_k^{'}(y_{i+\theta i,\,j+\theta j}) \tag{2}$$

式中，y_{ij} 为卷积计算后的特征值；f_k 为卷积函数；θ 为步长；$x_k^{'}$ 为反卷积计算后的特征值；$g_k^{'}$ 为反卷积函数。

考虑到水提取效率和精度，本文以EfficientNetV2神经网络中带有按比例激活机制的Fused-MBConv模块和MBConv模块为编码层，DeepLabv3+的空间空洞卷积为解码层。由于在浅层网络中使用Depthwise（DW）卷积的速度很慢，不能充分利用现有加速器，因此只在深层网络中使用含有DW卷积的MBCov模块，并引入按比例激活注意力机制的压缩模块来简化网络。解码器层参考DeepLabv3+模型[11]，充分利用底层特征的边界信息和高层特征的图像语义。利用空间空洞金字塔池化模块，将隐含水体边界的低层特征与隐含语义的高层特征相结合获取多尺度特征；再重新构建模型中的通道数，以6波段卫星图像作为输入。水体自动化提取模型（AWEM）的解码层先对高层特征进行4倍的双线性上采样，再将其与相应的低层特征连接起来进行后续解码。中间特征被双线性上采样两次，并连接到低层特征进行后续解码。该操作可将具有丰富边界信息的低层特征与具有高级语义的高层特征结合起来。

2.2 AWEM的训练和验证

借助GEE平台，选择Landsat8大气校正后的数据构建地表水样本库（SWKB）。SWKB包括训练集和验证集（真值）两个部分。首先在东部平原湖区选择29张Landsat8数据制作训练集，包括不同季节、不同场景（水体、植被、建筑、山区、道路、土壤和冰雪覆盖区），不同地形（高原、平原、山区、丘陵、盆地、峡谷）和不同天气因素（无云、多云、薄云或雾）；再基于Landsat8影像，参考0.5 m分辨率的Google Earth辅助图像，通过屏幕手动数字化获取地表水场景中的水体真值边界。模型训练采用自动挖掘样本数据特征的方式学习样本语义，通过分析训练和应用中的效果有针对性地调整参数、不断迭代优化，进而获得最优模型[12]。本文采用二元交叉熵函数来测量模型损失，即

$$L(y,\hat{y})=-\frac{1}{N}\sum_{i=0}^{N}\left(y\log\widehat{y_i}\right)+(1-y)\log(1-\widehat{y_i}) \tag{3}$$

式中，y、$\widehat{y_i}$分别为真实值和预测值，取值范围为0~1；N 为预测次数。

训练过程中通过随机图像翻转和角度旋转对模型进行增强，以获得较好的鲁棒性。输入图像的大小为

512像素×512像素。经多次测试后，批量大小和初始学习率分别设置为4和0.002，所有计算均在Google Colab中完成。采用Softmax分类器对提取的水体特征进行分类，提取层为全连接层，假设 $\boldsymbol{T}_i$ 是一个 K 维向量，表示位置 i 的非标准化得分，利用Softmax分类器对每个 $\boldsymbol{T}_i$ 元素构建一个向量，即

$$\boldsymbol{P}\left(f_i=j|\boldsymbol{T}_i\right)=\frac{\exp\left(\boldsymbol{T}_i\right)}{\sum_{i=1}^{K}\exp(\boldsymbol{T}_i)} \tag{4}$$

本文以平均交并比（MIoU）作为评估提取精度的指标之一。MIoU为实际水体区域与预测水体区域交集与并集的比值。MIoU的最大值为1，此时实际水体区域与预测区域完全重合；最小值为0，此时实际水体区域与预测区域没有重叠部分；通常其值大于0.5，就认为得到了理想的预测结果。另外，本文通过生产者精度（*PA*）、用户精度（*UA*）和整体精度（*OA*）对水体边界提取进行评估。

本文将AWEM提取结果与其他经典方法（MNDWI、AWEMsh、SVM、DeepLabv3+、DeepWaterMapV2、WatNet）进行比较，其中MNDWI和AWEMsh方法需要以人工方式确定阈值，通过10次测试选取水体提取精度最高时对应的阈值作为最佳阈值，分别为0.25、−0.18；SVM的惩罚函数选择正则化参数，核函数选择RBF径向基函数。测试集包含山区、云覆盖区和城市区。

$$\mathrm{AWEIsh}=B+2.5G-1.5(\mathrm{NIR}+\mathrm{SWIR1})-0.25\mathrm{SWIR2} \tag{5}$$

式中，B、G、NIR、SWIR1和SWIR2分别为水体在蓝光、绿光、近红外和短波红外波段的反射率。

2.3　AWEM在东部平原湖泊提取中的应用

东部平原湖泊分布比较破碎，受地形起伏变化、温度季节性变化、地表径流等因素的影响较大，因此湖泊的矢量边界是动态变化的，在遥感影像上反映为混合像元的动态变化。相较于固定的湖泊边界数据库，基于遥感图像提取的水体边界提取更能有效地实现水体掩膜，以避免陆地临近效应，且只有实现自动化提取才能满足大区域水质研究的需求。

将AWEM训练后的权重上传至Google Cloud（https://console.cloud.google.com/）中，可在GEE中直接调用AWEM权重提取水体。为有效降低云和阴影的干扰，CLOUD_COVER参数设置小于20%。虽然AWEM在对抗云覆盖和阴影部分有显著效果，但牺牲了部分*PA*换来*UA*。某些区域由于长时间厚云层覆盖，而无法使用光学数据进行地表地物监测，因此很多研究采用SAR影像替代[13]。基于主动遥感的SAR影像不受云层干扰，可弥补光学数据的缺失。本文采用Sentinel−1全极化SAR数据进行极化分解和灰度共生矩阵的纹理特征提取[14]，得到地物多维特征，并通过可分性指数对多维特征进行冗余处理，有效解决了水体与非水体的误分现象，提高了水体提取精度。采用全极化法进行水体提取后，空间分辨率重采样至30 m，以匹配Landsat8数据的空间分辨率。

对光学影像和SAR影像进行水体提取后，结果中包含所有水体（湖泊、河流、沼泽、湿地和短暂性河流）。本文根据2004年世界自然基金会发布的全球湖泊和湿地数据库剔除河流、沼泽、湿地和短暂性河流。另外，在水体和陆地连接处存在水体的混合像元，本文通过多个湖泊边界的人工比对，在确保整体水体提取精度的前提下采用形态学方法向内腐蚀两个像元单位，得到水体的完整湖泊轮廓。

积水频率（*WF*）是指一段时间内像元位置识别为水体的次数与像元观测总次数的比值[13]。根据*WF*，将水体分为永久性水体（$WF>75\%$）、季节性水体（$25\%\leqslant WF\leqslant 75\%$）和临时性水体（$WF>25\%$），本文只考虑季节性水体和永久性水体。获取季节性水体和永久性水体后，采用像元区域生长法获取独立水体的轮廓并矢量化；并在ArcGIS10.6中统计湖泊水体的面积。本文只考虑面积大于1 km^2的湖泊水体。

3　研究结果分析

3.1　AWEM精度验证结果分析

在多光谱图像中，山区的光谱阴影、城市建筑阴影和云阴影是影响水体提取精度的因素。本文选取3个大气校正后的场景作为测试图像，分别代表山阴影、建筑阴影和云阴影；采用MIoU统计方法对每幅测试图像的提取结果进行统计，在每张图像上随机选取10个10像素×10像素的切片，比较提取结果和人工数字化结果；在每幅图像中采集500个水体边界像素，对比水体边界的整体精度。轻量化卷积神经网络通常对通道较少的图像处理效果较好，还需结合遥感图像的多特征波段以及水体在不同波段上的光谱响应。在数据输入端不仅考虑了数据自身的质量（波段选择、噪声污染等），而且考虑了数据输入网络中的高度、宽度和深度。本文中的网络深度设置为固定值，主要

探讨不同输入图像的高度和宽度对整体网络效率和精度的影响。输入高度、宽度较大的图像会增加场景信息量，可在一定程度上增加模型对水体特征的理解，但也增加了计算量。本文将输入图像设置为常用7种大小，对模型的精度和效率进行实验，每组图片大小分别训练20次，统计了MIoU中值和图像分类耗时（图1），可以看出，图片大小由515×512减至320×320时，提取精度变化不大，均值在96.71%以上，耗时则由51.2 s增至105 s；随着图片的减小，提取精度迅速降低，图片大小为128×128时精度最低，耗时则呈指数增加。该结果符合计算机的计算效率，随着图片的减小，计算机获取的场景信息量减少，MIoU精度降低，同时计算输入批量增加，需要消耗更多的内存，导致计算效率下降。

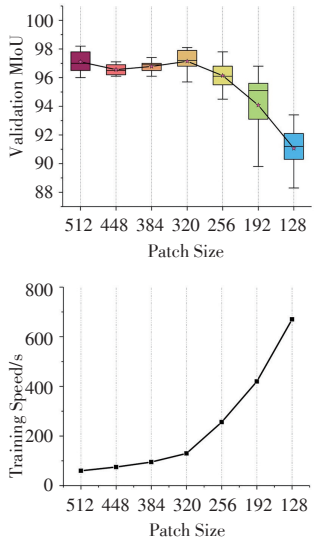


图1 不同输入图片大小的验证精度和计算效率

本文将AWEM与DeepLabv3+、DeepWaterMap、WatNet等进行比较；将所有模型的输入通道改为6通道，以适应本文数据集；将数据集2/3的数据用于训练，1/3的数据用于验证；将所有模型迭代计算200次。其损失函数和MIoU精度统计见图2，其中背景虚线代表每次迭代获得的函数值，由于每次迭代的值变化剧烈不具有代表性，因此利用中值滤波法对迭代函数进行平滑（图中实线标记值），所有模型在迭代75次后迅速收敛，AWEM的收敛速度最快，DeepWaterMapV2模型次之；AWEM的提取精度最高（98.32%），DeepWaterMapV2模型次之；AWEM的模型结构与WatNet类似，但其在低层卷积中去掉了DW卷积，引入了注意力激活机制，因此模型的收敛速度和效率都得到了一定的提升。

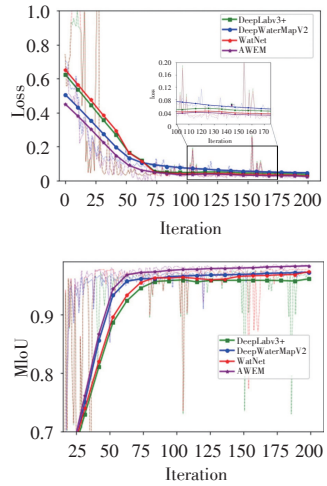


图2 不同模型的损失值和提取精度

7种模型在不同测试区域的准确率见表1，可以看出，AWEM的*OA*在所有测试区域中最高；所有模型中手动调整阈值指数法的精度最低，这并不是阈值选择不恰当，而是已将阈值调到最佳，但整体精度依然没有其他模型高，其主要原因在于该方法只应用了遥感图像的2~3个波段，其余波段信息无法参与计算。

3.2 东部平原湖泊时空变化分析

根据提取的湖泊数据，本文统计了2015—2021年东部平原湖区湖泊的面积和个数变化情况，结果表明，2015—2021年东部平原湖泊总数由510个减至476个，总面积由16 683.256 km^2增至18 494.772 km^2。2015—2018年的湖泊数量减少但湖泊面积却增加，其

表1 不同模型的精度统计/%

验证区域	指标	MNDWI	AWEMsh	SVM	DeepLabv3+	DeepWaterMapV2	WatNet	AWEM
城市区域	*PA*	75.73	87.89	77.12	91.60	93.19	96.82	98.02
	UA	73.89	82.11	79.11	95.91	97.82	92.89	96.31
	OA	74.36	83.18	78.56	92.21	95.60	94.68	97.01
山区	*PA*	80.37	89.72	76.32	90.77	91.21	90.29	92.89
	UA	76.10	83.97	72.99	94.15	97.39	95.55	97.59
	OA	81.98	86.15	73.18	93.17	94.48	92.98	95.67
云覆盖区域	*PA*	77.86	88.74	81.42	90.86	92.07	91.27	93.90
	UA	87.74	84.63	78.89	94.09	96.31	96.88	96.01
	OA	84.88	85.77	80.71	91.22	94.66	93.46	95.28

中面积为1~5 km²的湖泊减少了40个，面积50 km²以上的湖泊数量只增加了2个但面积却增加了1 895.556 km²，说明东部平原湖泊的面积变化主要受大面积湖泊的正向影响，小面积湖泊有一定的负向影响，但程度较弱。2015—2021年湖泊的面积和数量均呈先减后增的趋势，其中2015—2018年数量减少较剧烈、面积减少较缓慢，2018—2021年数量增加较缓慢、面积增加较剧烈。该变化除受降水因素影响外，还与近年来全球气候变暖、流域气候变化和人类活动等因素有关，东部平原湖区人口密集、城市化发展水平高，对湖泊变化具有巨大影响。

东部平原湖泊分布很不均匀，呈现两头少、中间多的分布格局，主要分布在江苏、安徽两省，其次是江西、湖南和湖北，这些地区的湖泊总面积占东部平原湖泊总面积的一半以上；江淮中下游更是水网密集、大小湖泊集中分布。2015—2021年湖泊数量和面积的地理异质性变化不明显，湖泊分布格局较稳定。

4　结　语

本文提出了AWEM，并在3个高度异构的场景下测试并验证了模型精度；设计了湖泊自动化提取方案，分析了东部平原湖泊的时空演变特征。

1）AWEM采用的模型架构兼顾了低层水体特征和高层语义特征，在所有选定的测试区域中*OA*最高，达到95.28%以上；在提取效率和精度上均优于传统指数法和机器学习方法。

2）AWEM具有很好的鲁棒性。在东部平原湖区选取的训练数据集包括不同时间、不同场景的信息，以增强计算机对水体信息的理解。AWEM可兼容多种遥感类型数据，不局限于Landsat8数据。

3）东部平原湖泊空间分布异质性明显，呈现两头少、中间多的空间分布格局。2015—2021年湖泊个数整体减少，但面积呈增加趋势；其面积变化主要受到大面积湖泊的正向影响，小面积湖泊有一定的负向影响，但程度较弱。

本文提出的AWEM样本数据集的制作过程较复杂，水体真值数据的制作需要人工交互选择，模型对真值的依赖程度非常高。在模型训练阶段，需根据模型在准确性和效率两方面的性能进行分析，需要多次调参和训练。由于水体受地形、岛礁、季节性等因素影响，湖泊水体边界呈现动态变化，若要获取高精度的湖泊矢量边界，目前仅依靠机器是无法满足要求的，仍需人工交互解译。

参考文献

[1] Allan J,McIntyre P,Smith S,et al. Joint Analysis of Stressors and Ecosystem Services to Enhance Restoration Effectiveness[J]. Proceedings of the National Academy of Sciences,2013,110(1):372-377

[2] Allen M, Ingram W. Constraints on Future Changes in Climate and the Hydrologic Cycle[J]. Nature, 2002, 419(6 903):224-232

[3] Verpoorter C,Kutser T,Seekell D,et al. A Global Inventory of Lakes Based on High-resolution Satellite Imagery[J]. Geophysical Research Letters,2014,41(18):6 396-6 402

[4] Ma R H,Yang G S,Duan H T,et al. China's Lakes at Present: Number,Area and Spatial Distribution[J]. Science China(Earth Sciences),2011,54(2):283-289

[5] Xu H. Modification of Normalised Difference Water Index (NDWI) to Enhance Open Water Features in Remotely Sensed Imagery[J]. International Journal of Remote Sensing,2006,27(14):3 025-3 033

[6] Feyisa G L,Meilby H,Fensholt R,et al. Automated Water Extraction Index: A New Technique for Surface Water Mapping Using Landsat Imagery[J]. Remote Sensing of Environment,2014(140):23-35

[7] Isikdogan F, Bovik A C, Passalacqua P. Surface Water Mapping by Deep Learning[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2017,10(11):4 909-4 918

[8] Isikdogan F,Bovik A C,Passalacqua P. Seeing Through the Clouds with Deep WaterMap[J]. IEEE Geoscience and Remote Sensing Letters,2019(11):1-5

[9] 翟天恩,张靖天,华飞,等. 东部平原湖区沉积物中溶解性有机氮分布特征[J]. 环境工程学报,2016,10(9):5 001-5 008

[10] 王洪道. 我国东部平原湖泊水资源分析[J]. 自然资源, 1986,8(2):77-83

[11] Chen Y, Fan R, Yang X, et al. Extraction of Urban Water Bodies from High-resolution Remote Sensing Imagery Using Deep Learning[J]. Water,2018,10(5):585

[12] 林晓萍. 基于深度学习的耕地新增建房监测研究[J]. 地理空间信息,2021,19(11):88-91

[13] 刘宇晨,高永年. Sentinel时序影像的长江流域地表水体提取[J]. 遥感学报,2022,26(2):358-372

[14] Zhu M. Water Extraction from Fully Polarized SAR Based on Combined Polarization and Texture Features[J]. Water, 2021,13(23): 3 332