J. Lake Sci.(湖泊科学),2027,39(2):000-000
DOI: 10.18307/2027.0234
©2027 by *Journal of Lake Sciences*

水库消落带优势草本群落自动提取的深度学习与传统机器学习方法对比*

江维薇[1,2,4]，祝瑞盛[1,3]，陈　实[1,3]，肖衡林[5**]
（1：湖北工业大学土木建筑与环境学院，武汉 430068）
（2：湖北工业大学，河湖健康智慧感知与生态修复教育部重点实验室，武汉 430068）
（3：湖北工业大学，环境岩土与河湖生态修复湖北省重点实验室，武汉 430068）
（4：湖北工业大学，生态环境岩土与河湖生态修复学科引智创新示范基地，武汉 430068）
（5：江汉大学，精细爆破全国重点实验室，武汉 430056）

摘　要：水库消落带植被优势种群的变化是河流生态系统演变的重要指示因子，也是湿地生态管理的核心依据。然而，目前尚缺乏快速、准确获取其优势草本群落信息的高效方法。为此，本研究以二滩水库消落带优势草本群落为研究对象，系统评估了 U-Net、PSPNet 与 DeepLabV3+三种主流深度学习模型，结合不同卷积神经网络骨干网络，在消落带典型草本群落类型自动识别中的性能，并与基于特征工程与堆叠集成机器学习方法进行对比。结果表明：（1）U-Net 与 ResNet50 组合的综合表现最优，总体精度达 0.918，F1 分数最高，在狗牙根（F1=0.941）、苘麻等优势草本群落识别中尤为突出。其编码—解码结构能够有效融合多层级语义与空间细节信息，增强模型在复杂植被场景下的识别稳定性。（2）PSPNet 与 DeepLabV3+在部分组合中验证损失波动较大，如 PSPNet-ResNet50 在训练早期损失波动显著，可能与其多尺度模块对网络深度敏感有关；但二者训练效率较高，推理时间较短，适用于大范围植被监测。（3）与传统方法相比，深度学习在优势草本群落识别方面表现相当，如堆叠集成模型总体精度为 0.931，U-Net+ResNet50 与之接近。然而，在样本较少的“其他草本群落”类别中，传统方法的 F1 分数整体高于深度学习模型，其最低值（0.672）仍高于深度学习的最高值（0.539）。尽管如此，深度学习具备自动特征提取能力，显著降低了对人工特征工程的依赖，展现出较强的跨区域迁移潜力。综上，深度学习模型在水库消落带草本群落分类中具有良好的应用前景，未来应进一步扩充样本规模、融合多源遥感数据，并结合迁移学习方法，构建“数据—模型—应用”协同优化的智能识别体系，以支撑湿地生态系统精细化监测与管理。
关键词：水库消落带；优势草本群落；无人机；深度学习；机器学习

Comparative study of deep learning and traditional machine learning methods for automated extraction of dominant herbaceous community in reservoir water-level-fluctuation zones*

Jiang Weiwei[1,2,4]，Zhu Ruisheng[1,3]，Chen Shi[1,3] & Xiao Henglin[5**]
(1：*School of Civil and Engineering，Architecture and Environment，Hubei University of Technology，Wuhan* 430068，*P. R. China*)
(2：*Key Laboratory of Intelligent Health Perception and Ecological Restoration of River and Lakes，Ministry of Education，Hubei University of Technology，Wuhan* 430068，*P.R.China*)
(3：*Hubei Key Laboratory of Environmental Geotechnology and Ecological Remediation for Lake&River，Hubei University of*

* 2026-02-23 收稿；2026-05-22 收修改稿；2026-05-25 录用。
国家自然科学基金项目（U22A20232，52578409，42101375）、湖北省科技厅创新群体项目（2025AFA020）和湖北省教育厅优秀中青年科技创新团队项目（T2024006）联合资助。
** 通讯作者；E-mail: xiao-henglin@163.com。

Technology，*Wuhan* 430068，*P.R.China*）
（4：*Innovation Demonstration Base of Ecological Environment*，*Geotechnical and Ecological Restoration of Rivers and Lakes*，*Hubei University of Technology*，*Wuhan* 430068，*P.R.China*）
（5：*State Key Laboratory of Precision Blasting*，*Jianghan University*，*Wuhan* 430056，*P.R.China*）

Abstract: Variations in dominant plant communities within reservoir water-level-fluctuation zones are important indicators of river ecosystem evolution and provide essential support for wetland ecological management. However, efficient approaches for rapid and accurate acquisition of dominant vegetation information are still lacking. This study focused on the dominant herbaceous communities in the water-level-fluctuation zone of Ertan Reservoir and systematically evaluated the applicability of three widely used deep learning models—U-Net, PSPNet, and DeepLabV3+—coupled with different convolutional neural network backbones for automatic identification of typical herbaceous community types. A comparative analysis was also conducted with a stacking ensemble machine learning method based on feature engineering. The results show that (1) the U-Net–ResNet50 model achieves the best overall performance, with an overall accuracy of 0.918 and the highest F1 score. This model performs particularly well in identifying typical dominant herbaceous communities, including the *Cynodon dactylon* community (F1 = 0.941) and the *Abutilon theophrasti* community. Its encoder–decoder structure effectively integrates multi-level semantic information and spatial details, thereby improving identification stability in complex vegetation environments. (2) Some combinations of PSPNet and DeepLabV3+ exhibit obvious fluctuations in validation loss. Specifically, the PSPNet–ResNet50 model shows notable loss fluctuations in the early training phase, which may be due to the high sensitivity of its multi-scale module to network depth. Nevertheless, both models have higher training efficiency and shorter inference time, making them suitable for large-scale vegetation monitoring. (3) Deep learning models achieve competitive performance in identifying dominant herbaceous communities compared with conventional methods. The stacking ensemble model yields an overall accuracy of 0.931, which is comparable to that of the U-Net–ResNet50 model. For the sparsely sampled category of other herbaceous communities, conventional methods generally obtain higher F1 scores than deep learning models, with the minimum F1 score of conventional methods (0.672) exceeding the maximum F1 score of deep learning models (0.539). Nonetheless, deep learning methods can automatically extract features, which greatly reduces reliance on manual feature engineering and shows strong potential for cross-regional model transfer. In summary, deep learning models have good application prospects for classifying herbaceous communities in reservoir water-level-fluctuation zones. Future research could expand sample datasets, integrate multi-source remote sensing data, and adopt transfer learning methods to construct an intelligent recognition framework that achieves synergistic optimization of data, models, and applications. The findings of this study can support refined monitoring and management of wetland ecosystems.

Keywords: Reservoir water-level-fluctuation zone; dominant herbaceous community; unmanned aerial vehicle (UAV); deep learning; machine learning

水库作为重要的人工水体，其生态系统健康对区域水资源安全、生物多样性与环境可持续发展具有关键意义[1]。水库消落带是水位周期性涨落形成的干湿交替区，是连接水生与陆生生态系统的关键过渡带，具有独特的生态环境功能[2]。消落带植被，作为这一敏感区域的“生态工程师”，通过其冠层与根系结构，能够有效缓冲风浪、固土护岸、拦截面源污染[3-4]，并调节水库周缘的微气候与生物地球化学循环[5]。因此，准确掌握消落带优势草本群落的时空分布格局[6]，对于评估水库生态系统健康状况、指导生态调度与管理至关重要[7]。

与自然河岸带类似，水库消落带植被群落也常由少数优势物种主导[8]。这些优势物种因其高生物量、强生态效应和对水位变动等环境胁迫的显著响应，通常被视为水库水文与生态环境变化的“哨兵”[9]。然而，消落带剧烈的干湿交替和频繁的人力干扰导致其植被群落动态多变，传统地面调查方法难以实现大范围、高效率的同步监测[10]。遥感技术，特别是具备高时空分辨率的无人机遥感，为破解这一难题提供了理想的技术路径[11]。

尽管遥感技术为消落带植被监测提供了新的技术路径，但在草本群落精细分类的实际应用中仍面临诸多挑战[12]。草本物种间光谱特征相似，且其关键辨识特征（如叶脉、绒毛）在遥感影像中极易损失[13]。以往研究多依赖于复杂的特征工程与机器学习方法[14-15]。例如，我们前期的研究提出了一种基于随机森林的优势度加权特征递归消除法，并结合堆叠模型，在河岸带草本群落提取中取得了良好效果[16]。然而，这类方法高度依赖遥感图像处理的专业知识来人工设计与筛选特征，构建过程繁杂，在生态学领域推广应用存在较高门槛[17]。

近年来，深度学习技术为上述瓶颈提供了新的解决方案[18]。与传统方法相比，深度学习能够通过深度神经网络自动学习和编码图像中的多层次抽象特征，从而减少对人工特征工程的依赖，并在图像识别和语义分割任务中表现出较强潜力[19]。然而，就水库消落带草本群落精细分类而言，相关研究仍相对有限。现有与消落带相关的遥感研究多集中于群落组成与空间分布调查、岸带面积变化监测或植被活力变化分析，例如三峡库区的相关工作主要侧重于植被时空变化特征刻画[20]；相比之下，面向优势草本群落细分类的深度学习系统对比研究仍较缺乏。尽管如此，相近的湿地及河岸带识别研究已为理解该类任务的技术难点提供了参考。已有研究表明，在高分辨率影像条件下，目标尺度差异大、背景复杂、植被分布破碎等因素，可能削弱深度学习模型对空间异质性和细碎边界的刻画能力[21]；德国河岸带多模态分类研究也表明，即使融合 RGB、NIR 和高程等多源信息，类别不平衡、样本有限、标注误差及水体干扰等因素仍可能削弱模型在水陆交错复杂场景中的分类精度[22]。二滩水库消落带受高程梯度、水位涨落和裸地背景共同影响，草本群落斑块小而破碎，不同物种之间呈明显镶嵌分布，进一步提高了优势草本群落精细识别难度。因此，有必要在该类复杂场景下系统比较深度学习与传统机器学习方法的适用性与性能差异，以明确现有模型的优势边界，并为水库消落带优势草本群落精细识别提供更具针对性的技术依据。

基于此，本文以二滩水库消落带的优势草本群落为研究对象，旨在系统对比深度学习与传统机器学习方法在优势草本群落分类中的性能。重点探讨：（1）深度学习模型在水库消落带复杂场景下的草本群落分类精度与鲁棒性；（2）相较于依赖人工特征工程的机器学习方法，深度学习在特征提取自动化与模型性能上的优势；（3）不同模型架构对分类结果的影响，为水库消落带草本群落遥感监测提供一套高效、低技术门槛的解决方案，进而推动遥感技术在湖泊与水库生态系统研究中的深入应用。

1 材料与方法

1.1 研究区概况与无人机数据采集

二滩水库位于中国雅砻江下游，四川省攀枝花市盐边县和米易县的交界处（26°34′18″~ 27°5′50″N、101°18′02″～101°57′59″E），是二十世纪建成投产的大型水电工程，最大坝高 240 米。消落带水位落差 45 米，高程介于水库死水位（海拔 1155 m）和正常蓄水位（海拔 1200 m）之间，地物类型主要包括裸土和植被，植被多以狗牙根、苘麻、酸模叶蓼等矮小草本类植物为主，土壤类型主要为铁铝土、雏形土、疏松岩性土。在二滩水库消落带选取典型样地，采用 DJ-P4 Multispectral 搭载包含 Red、Green、Blue、Red Edge、Near infrared 五波段相机进行航拍数据采集，拍摄于 2022 年 7 月 5 日进行，当日风力小于 4 级，天气晴朗。航拍前设置了 7~8 个地面控制点，利用千寻星耀 Xmini-GNSS，测量控制点经纬度和高程。拍摄时设置航高 25 m,飞行速度 2 m/s，航向重叠率为 80%，旁向重叠率为 70%，曝光方式为自动曝光，获取图像空间分辨率 0.95 cm，样地采集 150 - 200 张照片，每张影像大小 5518×3397 像素。采集完毕后，通过软件 pix4d 进行图像预处理，生成研究区域的完整数字正射影像（digital orthograph map）（图 1）。

1.2 基于 RF-Y-RFE 特征工程与堆叠机器学习的优势草本群落提取

在草本群落分类提取中，传统特征选择方法往往侧重于整体分类精度[23]，而忽略了优势草本群落识别这一关键管理目标。为此，我们在前期研究中提出了基于随机森林的优势度加权的特征递归消除法（Dominance - Weighted Random Forest Recursive Feature Elimination，RF-Y-RFE）[16]，该方法根据样方调查确定优势种及其对应的草本群落类型，并基于各物种的相对盖度、相对频度和相对密度计算其重要值，进而得到优势度（具体调查过程与计算方法见补充材料 Text S1）。在此基础上，按公式（1）构建优势草本群落优势度加权平均精度（YAA），替代总体精度作为目标函数，并通过随机森林模型迭代筛选

最优特征子集。这一改进使得 RF-Y-RFE 在河岸优势物种自动提取中，能够更有效地整合样方调查的生态信息与无人机多光谱遥感数据，提升模型在识别关键优势类群上的表现。

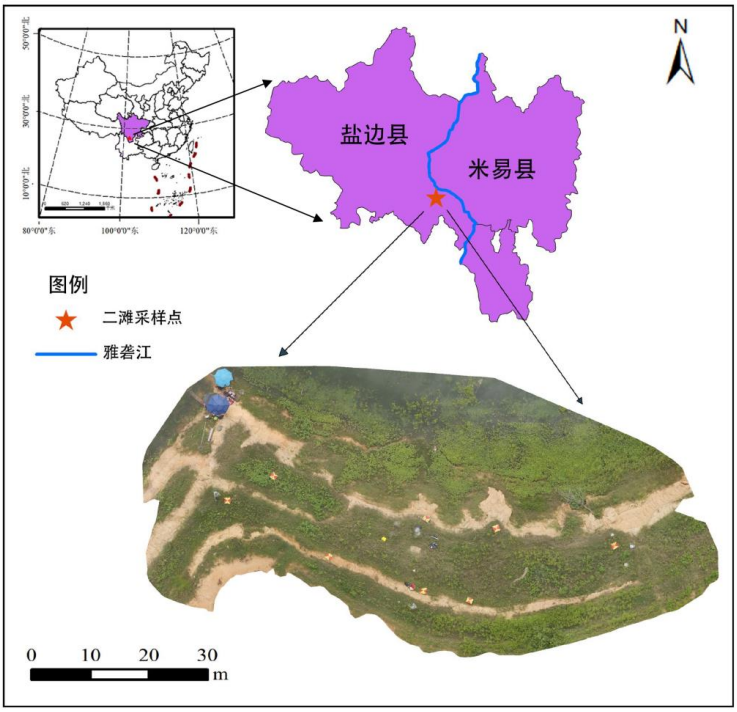

图 1 研究区位置及其无人机正射影像

Fig.1 Location of the study area and its UAV orthophoto

$$Y_{AA} = \sum_i^n (\bar{Y}_i * \frac{P_i + R_i}{2}) \tag{1}$$

$$\bar{Y}_i = \frac{Y_i}{\sum_i^n Y_i} \tag{2}$$

$$P_i = \frac{X_{ii}}{X_{i+}} \quad , \quad R_i = \frac{X_{ii}}{X_{+i}} \tag{3}$$

式中，n 为优势物种的类别数目，$\bar{Y}_i$ 为对应优势草本群落 i 的归一化优势度，Y_i 为对应草本群落的优势度，P_i 为对应草本群落 i 的精确度，R_i 为对应草本群落类 i 的召回率，X_{i+}、X_{+i} 为混淆矩阵各行、各列之和。

基于 RF-Y-RFE 构建的最优特征空间，构建堆叠机器学习模型进行优势草本群落提取并与其中各基模型进行对比。根据经验和试错，堆叠模型以 RF-1、RF-2、Catboost、XGBoost、Decision Tree 机器学习方法为基模型，元模型则选择了结构简单、稳定性良好的逻辑回归算法。通过在基础层的训练集上进行 K 折交叉验证，训练多个独立的基模型，将其输出作为第二层的输入，用于元学习器的训练。各基模型及元学习器的具体参数设置见补充材料 Text S2。

为评估优势草本群落提取精度，采用独立随机采集的测试样本构建混淆矩阵，计算总体精度（OA）、生产者精度（PA）、用户精度（UA）、平均精度（AA）和 F1 得分等指标作为精度评价标准。独立测试样本依据实地调查结果与无人机正射影像目视解译结果，在各类别地物斑块内随机选取对

象样本，用于构建混淆矩阵并评价模型分类性能。根据样方调查与无人机影像解译结果，研究区草本植被划分为狗牙根、酸模叶蓼、苘麻、其他草本群落和枯萎草本群落等类别，其中“其他草本群落”由藜、小蓬草、鬼针草、合萌和猩猩草等少量伴生种或过渡类群组成。本研究共构建对象级训练样本 898 个和独立测试样本 970 个，各类别样本数量见表 1。同时，利用麦克尼马尔检验定量评估不同分类器之间分类结果差异的统计显著性。

表 1 模型训练样本与独立测试样本统计

Tab.1 Statistics of model training samples and independent test samples

类别	训练样本数	测试样本数	总数	占总样本比/%
牙根	210	208	418	22.38
酸模叶蓼	107	108	215	11.51
苘麻	221	262	483	25.86
其他草本群落	58	79	137	7.33
裸地	130	136	266	14.24
水体	53	52	105	5.62
其他地物	86	90	176	9.42
枯萎草本群落	33	35	68	3.64
总计	898	970	1868	100

1.3 基于多种深度特征自编码器与语义分割模型的优势草本群落提取对比

深度特征自编码器无需繁琐的特征工程，能够从原始输入数据中提取有用的特征，这些特征是后续模型进行分类的基础[24]。本文主要选择了 VGGNet[25]、ResNet[26]和 DenseNet[27]三种表现优异的骨架网络进行深度特征自编码，并分别结合 U-Net、DeeplabV3+和 PSPNet 三种语义分割模型进行消落带优势草本群落提取对比实验，组合实验方案如表 2、表 3 所示，所有模型的其余详细超参数（包括学习率范围、学习率策略、L2 正则化系数等）均列于补充材料 Text S3。

表 2 同种骨架网络不同模型对比试验

Tab. 2 Comparison experiment of different models with the same backbone network

模型类型	迭代次数	批次大小	损失函数	验证比例	优化算法	骨架网络
U-Net	25	8	softmax	0.1	Adam	ResNet-50 ResNet-101
PSPNet						ResNet-50 ResNet-101
DeeplabV3+						ResNet-50 ResNet-101

表 3 不同骨架网络的性能对比试验

Tab. 3 Performance comparison experiment of different backbone networks

模型类型	迭代次数	批次大小	损失函数	验证比例	优化算法	骨架网络
DeeplabV3+	25	8	softmax	0.1	Adam	VGGNet-16/19 DenseNet-169/201
PSPNet	25	8	softmax	0.1	Adam	VGGNet-16/19 DenseNet-169/201

为提高深度学习模型的泛化能力，本文对样本进行了扩充与增强处理。首先，导入 1.2 节生成的机器学习训练样本矢量文件，并将原始图像裁剪为 512×512 像素的切片；裁剪时设置 256 像素步长，使相邻图像片段保持充分重叠，以增加有效样本数量；同时，对每幅图像施加 30°顺时针旋转处理，以增强模型对不同空间方向目标的适应能力。基于遥感影像中的地物类型对样本进行标注，样本训练集和验证集的比例设置为 9：1，其中验证集仅用于训练过程中的模型监控与参数调优，不参与最终分类精度评价。最终用于构建混淆矩阵和评估模型性能的测试样本为独立随机采集样本，未参与任何模型训练与调参。考虑到本文属于小样本条件下的草本群落细分类任务，且最终精度评价基于独立测试样本完成，因此采用 9：1 划分以尽可能保留有效训练信息，同时满足训练过程中的评估需求。本试验训练、验证和测试过程

所使用的运行环境见补充材料 Text S4。

2 结果与分析

2.1 基于同构骨架网络深度特征编码器的分类精度综合评价

从图 2 所示的训练损失函数曲线可知，不同算法与骨架网络的组合存在明显差异。U-Net 与 ResNet 的配置整体表现出更平滑的优化轨迹；其中，U-Net-ResNet50 在训练早期即实现由 1.4 向 0.2 的迅速收敛，验证损失亦同步下降到 0.2，表明该组合在优化过程的稳定性与跨样本表现的一致性方面更为突出。ResNet101 则相对复杂，其训练损失的下降节奏相对缓慢，但验证损失长期维持在较低区间，提示该组合该模型在训练能力及泛化能力上较强。相较而言，PSPNet 与 DeepLabV3+在训练阶段的损失曲线起伏更为明显。以 PSPNet-ResNet50 为例，验证损失在前 0~1000 个 batch 内频繁出现较大幅度的上下摆动，说明其金字塔池化模块[28]对局部细节特征的学习稳定性仍有待提升。PSPNet 更强调全局信息整合，这对于大尺度、结构相对完整的目标有利，但对于消落带中边界模糊、纹理复杂、空间异质性较强的草本群落，过强的全局聚合可能削弱局部差异，从而影响模型稳定性。而在 DeepLabV3+以 ResNet50 为骨架的试验中，验证损失整体处于较低水平；但在 ResNet101 中验证损失波动较大。可能在于，其多尺度空洞卷积结构[29]对骨架网络深度较为依赖。

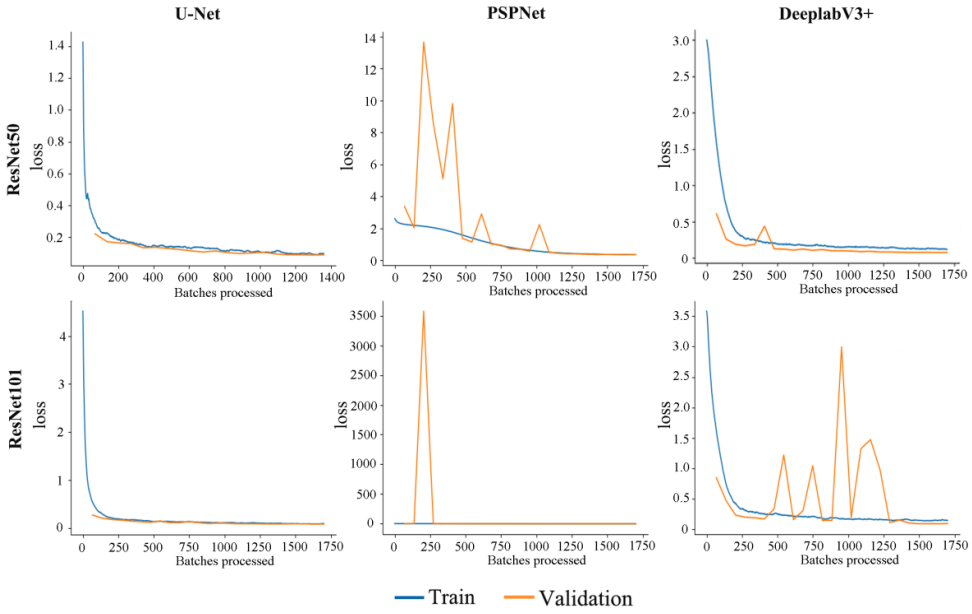

图 2 ResNet 骨架下的损失函数曲线

Fig.2 Loss function curves with ResNet backbone

ResNet 的对比试验表明(图 3)，U−Net 结合 ResNet50 的效果最优，不仅总体精度最高达到 0. 918，而且各优势物种的提取精度也显著高于其他组合。就单个物种而言，U+R50 在狗牙根、芎麻等物种的识别上均取得较高的 F1 得分，其中狗牙根与芎麻的表现更为突出。相较之下，PSPNet 和 DeeplabV3+在酸模叶蓼的识别结果波动较大，尤其是 P+R50 与 P+R101 在该物种上的精度差异达到 0. 322。

同时 P+R50 在其他草本群落识别中 F1 得分也仅有 0. 002。在训练与推理耗时上，U−Net+ResNet50 整体用时通常高于 PSPNet 与 DeepLabV3+。这可能与后两者采用空洞卷积、金字塔池化等更利于并行的结构有关，从而提升计算效率、缩短训练时间[30]；而 U−Net 尽管结构相对直观，但层级较深、卷积操作累积较多，因此导致其训练时间偏长。

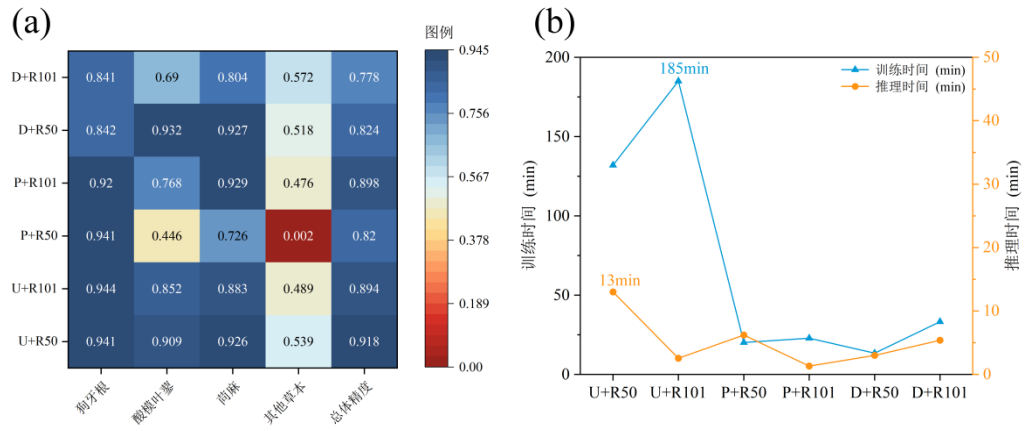

图 3 ResNet 骨架下不同模型的分类精度与计算效率对比

（计算效率包括训练总时长和整幅测试影像推理总时长。用于效率统计的测试影像共 1 幅，影像尺寸为 3397 × 5518 像素，总像素量为 18, 744, 646 像素）

Fig. 3 Comparison of classification accuracy and computational efficiency of different models with ResNet backbones

2.2 基于异构骨架网络深度特征编码器的分类精度综合评价

图 4 给出了 PSPNet 与 DeepLabV3+在 DenseNet169/201 及 VGG16/19 骨架下的训练与验证损失变化。各模型训练损失均随 batch 增加持续下降，验证损失整体收敛但呈现架构依赖性差异。PSPNet 在 VGG 骨架下过拟合更突出，且在训练早期与 VGG、DenseNet 组合均出现较明显的周期性波动，提示其金字塔池化与浅层或密集连接骨架的匹配度有限。相比之下，DeepLabV3+的验证损失更平稳，约在 300 个 batch 后趋于稳定，整体泛化稳定性更好。

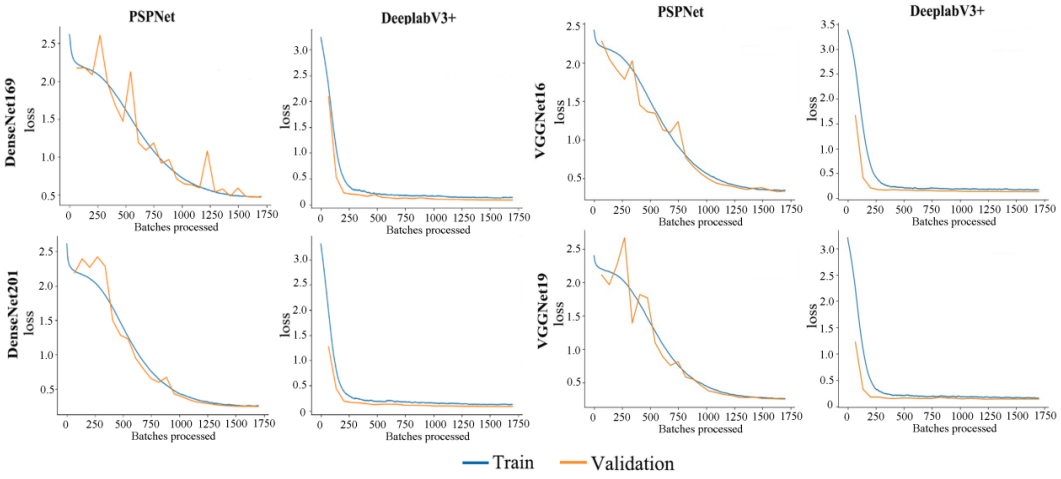

图 4 两种不同骨架网络训练损失曲线图

Fig. 4 Training loss curves of two different backbone networks

基于 VGGNet 与 DenseNet 骨架的结果表明，网络结构差异会同时影响分类精度与计算效率。图 5 汇总了不同组合在四类草本群落上的 F1 得分、总体精度以及训练与推理时间。其中，D+D169 综合表现最佳：总体精度达 0.896，且推理时间最短（1 min 18 s）。在各类地物提取精度方面，狗牙根与苘麻整体更易识别，而酸模叶蓼相对困难。狗牙根中 P+D201 的 F1 最高（0.925），D+D169 次之（0.918）；酸模叶

蓼以 D+D201 表现最好（0.790），而 P+D169 仅为 0.558。苘麻与其他草本群落的最佳组合均为 D+D169，说明 DenseNet 骨架在复杂背景下更具稳定优势。

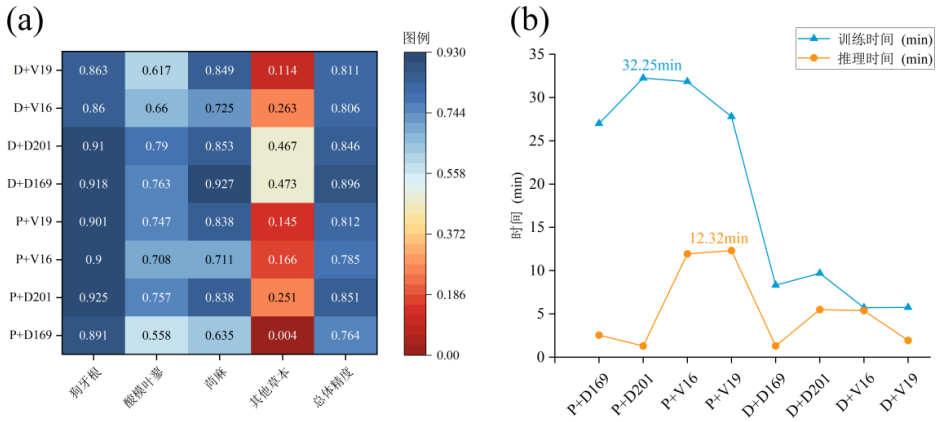

图 5 PSPNet 和 DeepLabV3+不同骨架组合的分类精度与计算效率对比

(计算效率包括训练总时长和整幅测试影像推理总时长，统计口径同图 3）

Fig. 5 Comparison of classification accuracy and computational efficiency of PSPNet and DeepLabV3+ using different backbone combinations

在训练耗时上，DeepLabV3+整体短于 PSPNet，可能与 PSPNet 的空间金字塔池化模块引入了额外的计算有关。综合精度与效率来看，DeepLabV3+搭配 DenseNet 的表现更优，更适用于多类别、精细化的草本群落分类，相比其与 ResNet 的组合更具优势。

为便于直观比较不同深度学习模型组合在分类精度与计算效率上的差异，本文进一步将图 3 和图 5 中的核心结果汇总为表 4。表 4 表明，各模型在精度与效率之间存在一定权衡：U-Net+ResNet50 在总体精度和优势草本群落识别方面表现突出，而 DeepLabV3+结合部分骨架网络在计算效率上更具优势。

表 4 不同深度学习模型组合的分类精度与计算效率对比

Tab. 4 Classification accuracy and computational efficiency of different deep learning model combinations

模型组合	狗牙根	酸模叶蓼	苘麻	其他草本群落	总体精度	训练时间	推理时间
U+R50	0.941	0.909	0.926	0.539	0.918	2h12min	13min
U+R101	0.944	0.852	0.883	0.489	0.894	3h5min	2min33s
P+R50	0.941	0.446	0.726	0.002	0.82	20min8s	6min12s
P+R101	0.92	0.768	0.929	0.476	0.898	22min50s	1min19s
D+R50	0.842	0.932	0.927	0.518	0.824	13min24s	3min
D+R101	0.841	0.69	0.804	0.572	0.778	33min15s	5min23s
P+D169	0.891	0.558	0.635	0.004	0.764	27min	2min33s
P+D201	0.925	0.757	0.838	0.251	0.851	32min15s	1min18s
P+V16	0.9	0.708	0.711	0.166	0.785	31min51s	11min56s
P+V19	0.901	0.747	0.838	0.145	0.812	27min48s	12min19s
D+D169	0.918	0.763	0.927	0.473	0.896	8min19s	1min18s
D+D201	0.91	0.79	0.853	0.467	0.846	9min42s	5min30s
D+V16	0.86	0.66	0.725	0.263	0.806	5min43s	5min23s
D+V19	0.863	0.617	0.849	0.114	0.811	5min45s	1min56s

2.3 深度学习与基于 RF-Y-RFE 和堆叠机器学习的精度比较

为进一步筛选消落带优势草本群落提取的最优方案，本节对深度学习与传统机器学习方法中分类精度最高的试验结果进行对比。图 6 汇总了各模型在不同地物上的分类表现：狗牙根与苘麻的识别整体较为稳定，这可能与二者作为研究区优势草本群落、分布相对连续且群落覆盖较集中有关；但对酸模叶蓼及其他草本群落这类分布较零散、易与其他地物混杂的类别，模型间差异更为明显。就机器学习模型而言，各方法在狗牙根、苘麻、裸地、枯萎草本群落等类别上的效果相近，主要差别集中在“其他草本群落”和酸模叶蓼。深度学习模型中，U+R50 整体表现最佳，其次为 D+D169，P+R101 相对最弱。具体来看，P+R101 在细节刻画上不足，尤其在裸地以及零星酸模叶蓼与其他草本群落的识别中误分较多，说明其对边界模糊、斑块细碎类别的局部差异捕捉能力相对有限。这表明，虽然 P+R101 在独立测试集上取得了较高精度，但在处理未参与训练、验证和独立测试的样本时表现相对较弱，说明其泛化性能有限，可能与当前样本规模有限及数据分布不平衡有关[31]。

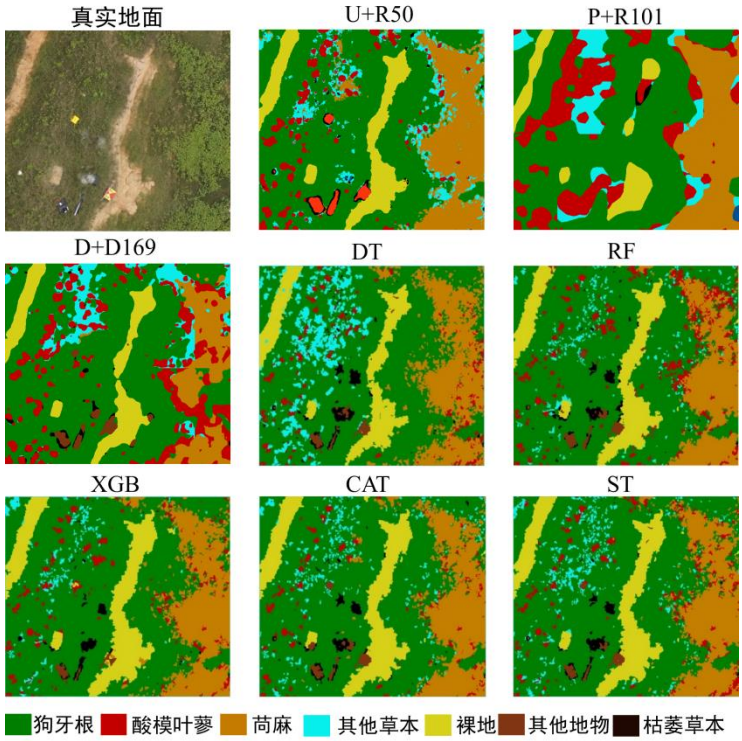

图 6 不同分类模型提取结果

Fig. 6 Extraction results of different classification models

为进一步量化不同方法的分类性能差异，本研究统计了各模型在不同地物类别上的 F1 得分与总体分类精度。由图 7 可知，堆叠集成模型（ST）在总体精度上表现最优（0.931），其次为 U+R50 与 CAT。在狗牙根、酸模叶蓼、苘麻等优势草本群落类别上，机器学习与深度学习的提取能力整体相当，例如狗牙根中 ST 与 U+R50 的 F1 得分均为 0.941，苘麻多数模型 F1 得分高于 0.92，酸模叶蓼亦保持较高水平。

然而，在样本较少的“其他草本群落”类别中，传统方法的 F1 分数整体高于深度学习模型，其最低值（0.672）仍高于深度学习的最高值（0.539）。由于该类别由少量伴生种或过渡类群合并而成，样本数量有限、空间分布零散，且常与裸地或其他草本混生，因而呈现出明显的空间破碎化和镶嵌分布特征。对于这类样本量不足且生境复杂的草本群落类别，深度学习模型往往难以获得足够的信息来充分学习其复杂多变的光谱与空间特征，从而导致识别能力受限[32]。这可能与该类植被与优势草本群落及裸地之间的光谱分异相对较弱，同时其斑块尺度较小、边界过渡不清且局部纹理连续性较差有关，从而增加了深

度学习模型在小样本条件下学习稳定判别特征的难度。相较之下，基于 RF-Y-RFE 的机器学习方法能够更有针对性地保留指数、纹理和地理等对复杂类别更敏感的特征，其中指数特征有助于放大不同种群生理状态和覆盖差异，纹理特征能够刻画其零散、细碎的斑块结构，地理特征则可反映其沿高程和水分梯度的分布偏好，因此在“其他草本群落”这类小样本、高异质性类别上表现出更强稳定性。值得注意的是，堆叠模型在总体精度上的优势主要来源于对该类样本数量较少类别的识别提升，而在水库消落带更受关注的优势草本群落提取上，深度学习模型与传统优秀方法（如 RF-Y-RFE 和堆叠学习）表现相当。

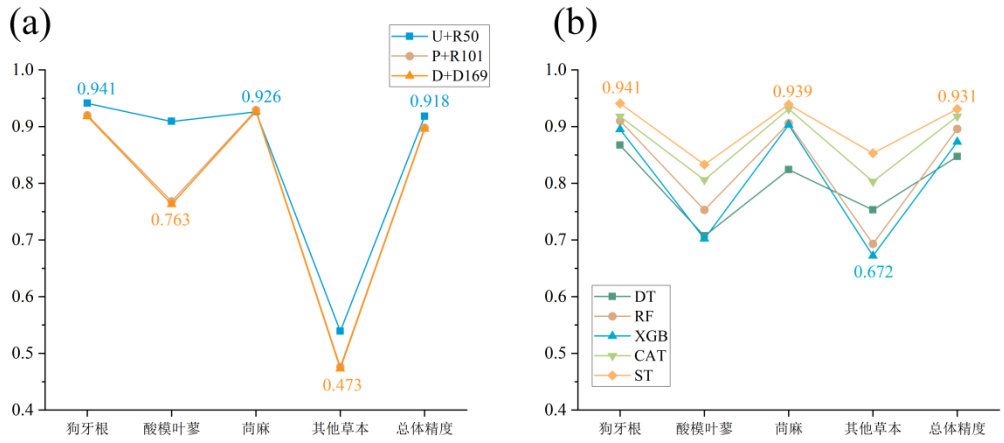

图 7 不同分类模型在各草本群落类别及总体精度上的 F1 得分对比：

(a) 深度学习模型 F1 得分 (b) 传统机器学习 F1 得分

Fig.7 Comparison of F1 scores of different classification models for each herbaceous community category and overall accuracy: (a) F1 scores of deep learning models (b) F1 scores of traditional machine learning

为检验不同模型分类结果差异是否具有统计学显著性，本文对代表性模型开展了 McNemar 检验。结果表明，在机器学习模型内部，ST 与 CAT、RF 和 XGB 的分类结果差异均达到显著水平（P<0.05）；在深度学习模型内部，U+R50 相较于 D+D169 和 U+R101 也均表现出显著优势（P<0.05）。跨方法比较结果显示，ST 与 U+R50 的分类结果差异未达到显著水平（P=0.0718），说明两者总体分类表现相近。

表 5 代表性模型之间的 McNemar 检验结果

Tab.5 McNemar test results between representative models.

基准模型	对比模型	χ^2	P 值	显著性
ST	CAT	5.04	0.0248	*
ST	RF	14.69	1.27×10^{-4}	***
ST	XGB	48.79	2.85×10^{-12}	***
U+R50	D+D169	4.1215	0.0423	*
U+R50	U+R101	11.2667	7.89×10^{-4}	***
U+R50	ST	3.24	0.0718	ns

* 表示 $P<0.05$，** 表示 $P<0.01$，*** 表示 $P<0.001$，ns 表示差异不显著（$P\geq0.05$）。

因此，针对优势草本群落的提取，深度学习具备替代传统优秀机器学习方法的潜力。尤其考虑到其特征自动编码能力，能够有效降低对专业特征工程的依赖，削弱专业知识壁垒，从而在水库消落带及同类湿地草本群落自动化提取中具有更广泛的推广价值[33-34]。

3 讨论

本研究系统评估了多种深度学习模型及其骨干网络在水库消落带优势草本群落分类中的性能。结果表明，U-Net 与 ResNet50 的组合在总体精度与 F1 分数上表现最优，尤其对狗牙根、苘麻等典型优势草本群落识别效果较好，验证了深度学习在消落带草本群落自动提取中的潜力[35-36]。该优势既得益于 U-Net 的编码—解码结构与跳跃连接，也与二滩水库消落带的生境特征密切相关。受高程梯度、水位涨落和裸地背景共同影响，研究区草本群落斑块细碎、分布破碎，物种镶嵌明显，且边界模糊、纹理复杂、空间异质性较强。在此场景下，U-Net 通过融合浅层细节与深层特征，更适合处理小斑块、弱边界的草本目标；而 ResNet50 在特征表达能力与模型复杂度之间取得良好平衡，因此在当前样本规模下表现更优，这与已有关于特征融合提升语义分割性能的结论一致[37-38]。相对而言，PSPNet 与 DeepLabV3+在部分组合中验证损失波动较大，其优势未能充分体现。PSPNet 擅长整合全局上下文，对尺度较大、结构完整的地物有利，但面对边界模糊、纹理复杂的草本群落，过强的全局聚合反而削弱局部差异判别，影响稳定性。DeepLabV3+依赖多尺度空洞卷积扩大感受野，理论上能够增强语义表达，但在小样本、类别混杂且类间边界较弱的条件下，这种优势并未充分转化为稳定的边界判别能力。由此可见，消落带草本群落分类效果并不单纯取决于模型结构是否更复杂，而更取决于模型特征提取方式与斑块尺度、边界清晰度及生境复杂性的匹配程度。在计算效率上，PSPNet 与 DeepLabV3+因引入空洞卷积与金字塔池化，训练耗时较短，适用于大范围植被调查及近实时监测[39-40]；U-Net 虽训练时间较长，但在高精度物种识别上不可替代，更适合生态保护重点区域的精细制图[41]。

以三峡库区为代表的大型水库消落带研究中，相关工作多侧重于植被覆盖变化、恢复格局或中低分辨率下的类型判读[42]。这类研究在区域监测与宏观管理层面具有重要价值，但识别对象多为消落带范围、土地覆被或植被类型单元，尚难直接支撑优势草本群落物种层面的精细识别。相比之下，本文聚焦于二滩水库消落带这一高程梯度明显、水位涨落频繁且草本群落斑块细碎镶嵌的复杂场景，进一步针对狗牙根、苘麻、酸模叶蓼等优势草本群落开展细分类，识别任务更细，分类难度也更高。尤其是在斑块尺度小、边界模糊和物种镶嵌明显的条件下，模型对局部细节、空间异质性和细碎边界的刻画能力更容易成为制约分类效果的关键因素。与此同时，本文在同一数据集上比较了 U-Net、PSPNet、DeepLabV3+及其不同骨干网络的性能，并与基于优势度加权特征递归消除和堆叠集成学习的机器学习框架进行了对比，从而较为系统地呈现了不同方法在复杂消落带场景中的适配差异。因此，本文结果有助于加深对优势草本群落细分类方法适用性的认识，并为高精度制图、复杂场景细分类和快速区域监测中的方法选择提供参考。

值得注意的是，尽管结合优秀特征工程与堆叠机器学习的方法在消落带草本群落分类总体精度上优于深度学习模型，但这种优势仅集中体现在数量较少的其他草本群落类别上，而在本研究与生态管理中更关注的优势草本群落提取上，二者表现相当。相较于传统方法，深度学习更突出的优势在于其自动特征提取能力[43]，能够显著降低对人工特征设计和筛选的依赖，减少技术门槛，因此在跨区域、跨场景的生态遥感应用中具有更大的推广潜力。

未来，针对水库消落带等典型生境中的主要优势草本群落，进一步扩充大规模样本可有效提升模型的泛化能力与实用性。对于“其他草本群落”等样本量较少、组成复杂且空间分布零散的类别，尽管本文已通过旋转等方式进行了基础数据增强，但后续仍可结合更有针对性的增强策略，并引入半监督学习或少样本学习方法，进一步挖掘有限标注样本与未标注数据中的潜在信息，从而缓解深度学习对大样本的依赖。需要指出的是，不同水库消落带在群落组成、地形条件和水文扰动方式上存在明显差异，优势种类型并不完全一致，因此跨区域模型应用应充分考虑区域差异性。在此基础上，可结合迁移学习方法，围绕不同优势物种和不同消落带场景构建更具针对性的识别模型，并在更多区域开展验证。随着研究区域和应用案例的持续增加，模型将在不断积累样本与经验的过程中增强对复杂生态场景的适应能力。

4 结论

本文以二滩水库消落带优势草本群落为研究对象，系统比较了多种深度学习模型及其骨干网络与传统机器学习方法在优势草本群落自动提取中的表现。主要结论如下：

1）在不同深度学习模型组合中，U-Net 与 ResNet50 的组合综合表现最优，总体精度达到 0.918，在狗牙根、苘麻等优势草本群落类别上的识别效果尤为突出，说明编码—解码结构结合适中的骨干网络深度更适合二滩水库消落带复杂场景下的小斑块、弱边界草本群落识别。

2）PSPNet 与 DeepLabV3+在部分组合中虽未取得最高分类精度，但训练与推理效率相对较高，更适合大范围植被调查与快速监测。结果表明，消落带草本群落分类效果并不单纯取决于模型结构复杂程度，而与模型特征提取方式同研究区斑块尺度、边界清晰度及生境复杂性的匹配程度密切相关。

3）与基于 RF-Y-RFE 和堆叠集成的传统机器学习方法相比，深度学习在优势草本群落提取这一核心任务上已具备相近的分类能力，并在降低人工特征工程依赖、提升识别自动化水平方面展现出明显优势；但在“其他草本群落”等小样本、高异质性类别上仍存在不足，后续仍需结合样本扩充、多源数据融合及迁移学习等手段进一步提升模型泛化能力。

5 参考文献

[1] Liang ST, Wang F, Wu D *et al*. Ecological health assessment of reservoirs based on macrobenthic index of biotic integrity in Haihe Basin. *Ecology and Environmental Sciences*, 2023, **32**(8): 1457-1464. DOI: 10.16258/j.cnki.1674-5906.2023.08.011. [梁舒汀, 王菲, 吴丹等. 基于大型底栖动物完整性指数的海河流域典型水库水生态健康评价. 生态环境学报, 2023, **32**(8): 1457-1464.]

[2] Chai PH, Dai YR, Liang W *et al*. Advances of ecological restoration of lakeside zone. *Strategic Study of CAE*, 2010, **12**(6): 32-35. DOI: 10.3969/j.issn.1009-1742.2010.06.006. [柴培宏, 代嫣然, 梁威等. 湖滨带生态修复研究进展. 中国工程科学, 2010, **12**(6): 32-35.]

[3] He XB, Bao YH. Research advances on soil erosion and ecological restoration in the riparian zone of the Three Gorges Reservoir. *Science of Soil and Water Conservation*, 2019, **17**(4): 160-168. DOI: 10.16843/j.sswc.2019.04.019. [贺秀斌, 鲍玉海. 三峡水库消落带土壤侵蚀与生态重建研究进展. 中国水土保持科学, 2019, **17**(4): 160-168.]

[4] Hu HB, Deng WB, Wang X. Research progress on ecological function and construction technology of riparian vegetation buffer strips in the Yangtze River Basin. *Journal of Zhejiang A & F University*, 2022, **39**(1): 214-222. DOI: 10.11833/j.issn.2095-0756.20210201. [胡海波, 邓文斌, 王霞. 长江流域河岸植被缓冲带生态功能及构建技术研究进展. 浙江农林大学学报, 2022, **39**(1): 214-222.]

[5] Zeng LX, Huang ZL, Xiao WF *et al*. Function, design and management of riparian vegetation buffer strips. *Scientia Silvae Sinicae*, 2010, **46**(2): 128-133. [曾立雄, 黄志霖, 肖文发等. 河岸植被缓冲带的功能及其设计与管理. 林业科学, 2010, **46**(2): 128-133.]

[6] Cho H, Kang H, Kim J. Vertical and longitudinal variations in plant communities of reservoir drawdown zones in South Korea. *Journal of Ecology and Environment*, 2019, **43**: 23. DOI: 10.1186/s41610-019-0123-6.

[7] Wang Q, Yuan XZ, Liu H *et al*. Effect of initial impoundment on the vegetation and species diversity in water-level fluctuation zone of the Three Gorges Reservoir. *Journal of Natural Resources*, 2011, **26**(10): 1680-1693. [王强, 袁兴中, 刘红等. 三峡水库初期蓄水对消落带植被及物种多样性的影响. 自然资源学报, 2011, **26**(10): 1680-1693.]

[8] Jiang WW, Li WT, Xiao HL. Species composition, spatial distribution characteristics and topographic attribution of vegetation in the water-level-fluctuating zone of the Nuozhadu Reservoir in the Lancang River Basin. *J Lake Sci*, 2022, **34**(6): 2025-2039. DOI: 10.18307/2022.0618. [江维薇, 李文涛, 肖衡林. 澜沧江流域糯扎渡水库消落带植被的物种组成、空间分布特征及地形解释. 湖泊科学, 2022, **34**(6): 2025-2039.]

[9] Zhang AY, Fan DY, Ma L *et al*. Intra-annual variations in leaf traits of *Cynodon dactylon*(L.) Pers. During exposure period in riparian zone of Three Gorges Reservoir Area. *Plant Science Journal*, 2022, **40**(4): 453-461. DOI: 10.11913/PSJ.2095-0837.2022.40453. [张爱英, 樊大勇, 马良等. 三峡消落带优势植物狗牙根在水库落干期的叶性状变化. 植物科学学报, 2022, **40**(4): 453-461.]

[10] Zhang Y, Sun JY, Li W. Temporal and spatial trends in NDVI of vegetation in water level fluctuation zone and drivers along an altitude gradient in the Yarlung Zangbo River Basin. *Biodiversity Science*, 2024, **32**(5): 84-98. DOI: 10.17520/biods.2023432. [张瑶, 孙君瑶, 李伟. 雅鲁藏布江流域不同海拔梯度下消落区植被 NDVI 的时空变化趋势及驱动因素. 生物多样性, 2024, **32**(5): 84-98.]

[11] Sun ZY, Wang XN, Wang ZH *et al*. UAVs as remote sensing platforms in plant ecology: Review of applications and challenges. *Journal of Plant Ecology*, 2021, **14**(6): 1003-1023. DOI: 10.1093/jpe/rtab089.

[12] Kong JX, Zhang ZC, Zhang J. Classification and identification of plant species based on multi-source remote sensing data: Research progress and prospect. *Biodiversity Science*, 2019, **27**(7): 796-812. DOI: 10.17520/biods.2019197. [孔嘉鑫, 张昭臣, 张健. 基于多源遥感数据的植物物种分类与识别: 研究进展与展望. 生物多样性, 2019, **27**(7): 796-812.]

[13] Wan FM, Wan HW, Gao JX *et al*. Applications and prospects of hyperspectral remote sensing for monitoring plant species diversity. *Research of Environmental Sciences*, 2025, **38**(1): 166-180. DOI: 10.13198/j.issn.1001-6929.2024.10.16. [万凤鸣, 万华伟, 高吉喜等. 高光谱遥感在植物物种多样性监测中的应用与展望. 环境科学研究, 2025, **38**(1): 166-180.]

[14] Rusnák M, Goga T, Michaleje L *et al*. Remote sensing of riparian ecosystems. *Remote Sensing*, 2022, **14**(11): 2645. DOI: 10.3390/rs14112645.

[15] Belcore E, Latella M, Piras M *et al*. Enhancing precision in coastal dunes vegetation mapping: Ultra-high resolution hierarchical classification at the individual plant level. *International Journal of Remote Sensing*, 2024, **45**(13): 4527-4552. DOI: 10.1080/01431161.2024.2354135.

[16] Jiang WW, Zhu RS, Zhou YP *et al*. Integrating UAV remote sensing and field ecology for fine-scale mapping of riparian herbaceous vegetation. *Remote Sensing Applications*: *Society and Environment*, 2026, **41**: 101925. DOI: 10.1016/j.rsase.2026.101925.

[17] Belgiu M, Drăguţ L. Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2016, **114**: 24-31. DOI: 10.1016/j.isprsjprs.2016.01.011.

[18] Zhu XX, Tuia D, Mou LC *et al*. Deep learning in remote sensing: A comprehensive review and list of resources. *IEEE Geoscience and Remote Sensing Magazine*, 2017, **5**(4): 8-36. DOI: 10.1109/MGRS.2017.2762307.

[19] Shelhamer E, Long J, Darrell T. Fully convolutional networks for semantic segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, **39**(4): 640-651. DOI: 10.1109/TPAMI.2016.2572683.

[20] Guan DJ, Qu SJ, Yang SS *et al*. Spatio-temporal evolution process of vegetation coverage of hydro-fluctuation belt in Three Gorges Reservoir based on GIS-RS. *Journal of Chongqing Jiaotong University*: *Natural Sciences*, 2018, **37**(6): 56-62. [官冬杰, 瞿思佳, 杨姗姗等. 基于 GIS-RS 的三峡库区消落带植被覆盖时空演变过程. 重庆交通大学学报: 自然科学版, 2018, **37**(6): 56-62.]

[21] Yang J, Zhao H, Luo YH *et al*. A review of wetland classification with high-resolution remote sensing image based on deep learning. *Remote Sensing Technology and Application*, 2025, **40**(4): 923-935. DOI: 10.11873/j.issn.1004-0323.2025.4.0923. [杨静, 赵慧, 罗耀华等. 基于深度学习的高分影像湿地分类研究综述.遥感技术与应用, 2025, **40**(4): 923-935.]

[22] Reinhardt M, Rommel E, Heuner M *et al*. Applying deep learning methods for a large-scale riparian vegetation classification from high-resolution multimodal aerial remote sensing data. *Remote Sensing*, 2025, **17**(14): 2373. DOI: 10.3390/rs17142373.

[23] Fan DD, Li QZ, Wang HY *et al*. Improvement in recognition accuracy of minority crops by resampling of imbalanced training datasets of remote sensing. *National Remote Sensing Bulletin*, 2019, **23**(4): 730-742. [樊东东, 李强子, 王红岩等. 通过训练样本采样处理改善小宗作物遥感识别精度. 遥感学报, 2019, **23**(4): 730-742.]

[24] Chu F, Fu YL, Zhao X *et al*. Operating performance assessment method and application for complex industrial process based on ISDAE model. *Acta Automatica Sinica*, 2021, **47**(4): 849-863. DOI: 10.16383/j.aas.c200475. [褚菲, 傅逸灵, 赵旭等. 基于 ISDAE 模型的复杂工业过程运行状态评价方法及应用. 自动化学报, 2021, **47**(4): 849-863.]

[25] Ma LX, Dou CF, Song CC *et al*. Insulator nondestructive testing based on VGGNet algorithm. *Opto-Electronic Engineering*, 2021, **48**(1): 38-45. DOI: 10.12086/oee.2021.200072. [马立新, 豆晨飞, 宋晨灿等. 基于 VGGNet 算法的绝缘子无损检测. 光电工程, 2021, **48**(1): 38-45.]

[26] Zhou HM, Chen JG, Dai ZG *et al*. Lightweight residual networks for diagnosis of apple leaf diseases. *Fujian Journal of Agricultural Sciences*, 2024, **39**(1): 83-92. DOI: 10.19303/j.issn.1008-0384.2024.01.011. [周罕觅, 陈佳庚, 代智光等. 基于轻量级残差网络的苹果叶病识别. 福建农业学报, 2024, **39**(1): 83-92.]

[27] Wu RB, Zhao T, Qu JY. Flight delay prediction model based on deep SE-DenseNet. *Journal of Electronics & Information Technology*, 2019, **41**(6): 1510-1517. DOI: 10.11999/JEIT180644. [吴仁彪, 赵婷, 屈景怡. 基于深度 SE-DenseNet 的航班延误预测模型. 电子与信息学报, 2019, **41**(6): 1510-1517.]

[28] Fan YH, Dong ZY, Yang XZ. The integrated contextual encoding and feature fusion SAR images segmentation method. *Journal of Image and Graphics*, 2022, **27**(8): 2527-2536. [范艺华, 董张玉, 杨学志. 结合上下文编码与特征融合的 SAR 图像分割. 中国图象图形学报, 2022, **27**(8): 2527-2536.]

[29] Liu WX, Shu YZ, Tang XM *et al*. Remote sensing image segmentation using dual attention mechanism Deeplabv3+Algorithm. *Tropical Geography*, 2020, **40**(2): 303-313. [刘文祥, 舒远仲, 唐小敏等. 采用双注意力机制 Deeplabv3+算法的遥感影像语义分割. 热带地理, 2020, **40**(2): 303-313.]

[30] Shao P, Gao ZA. Hybrid spatial pyramid pooling network to change detection for high resolution remote sensing images. *National Remote Sensing Bulletin*, 2025, **29**(1): 279-289. [邵攀, 高梓昂. 面向高分辨率遥感影像变化检测的混合空间金字塔池化网络. 遥感学报, 2025, **29**(1): 279-289.]

[31] Ling ZF, Liu T, Du P *et al*. Pattern recognition of regular buildings with unbalanced sample size. *Journal of Geo-Information Science*, 2022, **24**(1): 63-73. [令振飞, 刘涛, 杜萍等. 样本数量不平衡下的建筑群模式识别方法研究.地球信息科学学报, 2022, **24**(1): 63-73.]

[32] Jamali A, Mahdianpari M, Mohammadimanesh F *et al*. A deep learning framework based on generative adversarial networks and vision transformer for complex wetland classification using limited training samples. *International Journal of Applied Earth Observation and Geoinformation*, 2022, **115**: 103095. DOI: 10.1016/j.jag.2022.103095.

[33] Ma L, Liu Y, Zhang XL *et al*. Deep learning in remote sensing applications: A meta-analysis and review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2019, **152**: 166-177. DOI: 10.1016/j.isprsjprs.2019.04.015.

[34] Nuradili P, Zhou J, Zhou GY *et al*. Deep learning method for wetland segmentation in unmanned aerial vehicle multispectral imagery. *Remote Sensing*, 2024, **16**(24): 4777. DOI: 10.3390/rs16244777.

[35] Gao HY, Li RR, Shen Q *et al*. Deep-learning-based automatic extraction of aquatic vegetation from sentinel-2 images—a case study of Lake Honghu. *Remote Sensing*, 2024, **16**(5): 867. DOI: 10.3390/rs16050867.

[36] Lin N, Quan HL, He J *et al*. Urban vegetation extraction from high-resolution remote sensing imagery on SD-UNet and vegetation spectral features. *Remote Sensing*, 2023, **15**(18): 4488. DOI: 10.3390/rs15184488.

[37] He KM, Zhang XY, Ren SQ *et al*. Deep residual learning for image recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. June 27-30, 2016, Las Vegas, NV, USA. IEEE, 2016: 770-778. DOI: 10.1109/CVPR.2016.90.

[38] Chen LC, Zhu YK, Papandreou G *et al*. Encoder-decoder with atrous separable convolution for semantic image segmentation. *Computer Vision – ECCV 2018*. Cham: Springer International Publishing, 2018: 833-851. DOI: 10.1007/978-3-030-01234-2_49.

[39] Agduma AR, Altarez RDD. Multi-model convolutional neural network architectures for coastal forest extent and aboveground biomass estimation. *Remote Sensing Applications*: *Society and Environment*, 2025, **39**: 101647. DOI: 10.1016/j.rsase.2025.101647.

[40] Chen LC, Papandreou G, Kokkinos I *et al*. DeepLab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2018, **40**(4): 834-848. DOI: 10.1109/TPAMI.2017.2699184.

[41] Chen LW, Zhou XC, Li CX *et al*. Classification of tree species based on UNet-ResNet14* semi-supervised learning using UAV images. *Transactions of the Chinese Society of Agricultural Engineering*, 2024, **40**(1): 217-226. [陈龙伟, 周小成, 李传昕等. 基于 UNet-ResNet14*半监督学习的无人机影像森林树种分类. 农业工程学报, 2024, **40**(1): 217-226.]

[42] Li WP, Zeng Y, Wu BF *et al*. Research and monitoring of vegetation recovery based on remote sensing in the drawdown area of the Three Gorges basin. *Resources and Environment in the Yangtze Basin*, 2011, **20**(3): 332-338. [李伟萍, 曾源, 吴炳方等. 三峡水库 156 米蓄水位消落区植被恢复遥感动态监测研究.长江流域资源与环境, 2011, **20**(3): 332-338.]

[43] Zhang H, Wang KF, Wang FY. Advances and perspectives on applications of deep learning in visual object detection. *Acta Automatica Sinica*, 2017, **43**(8): 1289-1305. DOI: 10.16383/j.aas.2017.c160822. [张慧, 王坤峰, 王飞跃. 深度学习在目标视觉检测中的应用进展与展望. 自动化学报, 2017, **43**(8): 1289-1305.]