引 用 格 式:YANG Jing,ZHAO Hui,LUO Yaohua,*et al*.A review of wetland classification with high-resolution remote sensing image based on Deep Learning[J].Remote Sensing Technology and Application,2025,40(4):923-935.
[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[J].遥感技术与应用,2025,40(4):923-935.]
DOI:10.11873/j.issn.1004-0323.2025.4.0923

基于深度学习的高分影像湿地分类研究综述

杨 静[1,2],赵 慧[1],罗耀华[2,3],王俊迪[1,2]
(1.中国科学院、水利部成都山地灾害与环境研究所,四川 成都 610299;
2.成都理工大学 计算机与网络安全学院(牛津布鲁克斯学院),四川 成都 610059;
3.成都理工大学 地球勘探与信息技术教育部重点实验室,四川 成都 610059)

摘要:高分影像地物分类是遥感分类研究热点之一。传统的卫星影像湿地分类采用人工提取特征解译方式,费时费力且精度低,高分影像下湿地植被特征复杂,湿地水文边界季节性波动,实现自动、高效地高分影像湿地分类是亟待解决的问题。为促进高分影像在湿地分类中的应用,研究阐明了深度学习在高分影像湿地分类中的优势,总结了在高分影像中常用的深度学习分类模型,分析了深度神经网络、卷积神经网络、生成对抗网络在湿地分类中的最新研究成果。最后从样本、模型两个方面对深度学习在高分影像湿地分类中存在的问题以及后续的研究趋势进行了展望。

关 键 词:高分影像;湿地分类;深度学习;样本—模型
中图分类号:TP75 **文献标志码**:A **文章编号**:1004-0323(2025)04-0923-13

1 引 言

湿地是位于陆生生态系统和水生生态系统之间的过渡性地带,兼具两种生态系统的特征,和海洋、森林并称为地球三大生态系统。湿地在水源涵养、净化水质、蓄洪抗旱、调节气候和维护生物多样性等方面发挥着重要作用,是重要的自然生态系统,也是自然生态空间的重要组成部分[1-5]。由于全球人类活动和气候变化等多种因素,世界湿地正在加速丧失和退化[6]。在中国,随着社会经济的快速发展,湿地保护与利用的矛盾日益凸显,湿地被非法侵占、围垦和污染等现象时有发生,湿地生态系统保护工作面临巨大的挑战。湿地分类是湿地研究的地理基础,是湿地科学理论的核心问题之一,也是湿地科学发展水平的标志。对湿地进行科学分类并完成空间制图是湿地资源调查、评价和保护管理十分重要的前提[7-10]。

湿地边界的季节性动态化、数据收集的成本和质量都给湿地分类研究带来了很多问题。遥感技术范围大以及周期短的特点为大规模湿地的时间和空间分类提供了机遇[11-12],遥感技术在湿地测绘和监测方面有着诸多优势,如经济高效、多时相、多平台、实地考察要求低,覆盖范围广等,可以有效地用于监测湿地随时间变化的过程[13]。随着传感器技术的不断提升,目前湿地测绘常见的遥感数据包括航空摄影和摄像、高光谱图像、雷达和激光雷达数据以及中分辨率和高分辨率多光谱卫星影像。高分卫星遥感解译技术基于遥感技术的连续时空的数据获取能力,逐渐成为湿地监测分类的重要方法。本研究主要围绕空间分辨率在0.5~5 m或者亚米级的遥感卫星影像(高分影像)展开研究综述分析。这类数据通过利用更高的空间分辨率来解决低分辨率图像在单个像素中捕获多个栖息地时引起的光谱混合,进而导致地面覆盖物的分类不太精确的问题[14]。同时,这类数据可以提取更精细的

收稿日期:2024-08-20;**修订日期**:2024-12-17
基金项目:科技部重大专项"额尔齐斯河谷湿地生态系统格局与功能调查"(2021xjkk070202)。
作者简介:杨 静,硕士研究生,主要从事人工智能与遥感信息挖掘方向的研究。E-mail: yangj@stu.cdut.edu.cn
通信作者:赵 慧,副研究员,主要从事生态遥感与湿地格局方向的研究。E-mail: zhaohui@imde.ac.cn

地物纹理特征和地物空间位置关系,实现在小空间尺度上对高度分散的景观和植物类型的区分[15-17]。然而,随着监测手段的多样性以及传感器研制技术的提升,数据传输和存储技术的迅速发展,高分影像的数据量呈现爆炸性的增长趋势。海量的高分影像数据给数据信息的挖掘提出了更严苛的要求。当影像分析或者信息提取的速度与数据获取的速度无法匹敌,高分影像也难以发挥其优势与价值[18]。

高分影像湿地分类成功的关键之一在于对有效地物特征的提取。早期的湿地分类手段主要采用人机交互的目视解译方式,分类精度高,但费时费力,无法满足大范围实时获取湿地覆被信息的需求[19]。随后出现基于像元和面向对象的分类方法,以提取影像的低层特征(如:像素、形状、上下文关系和空间结构等特征)。这些传统的特征提取手段无法灵活利用高分影像数据丰富的地物细节、纹理信息,会造成数据丰富但信息匮乏的问题[20]。此外,这些人工特征提取的过程需要各种复杂的数字计算和理论推导,需要大量人工参与确定最优参数,主观性较强,存在误差[21]。随着机器学习的兴起,一些浅层分类模型,开始应用于湿地遥感影像分类中,如最大似然法、支持向量机等。而这些浅层模型无法挖掘出深层的上下文语义信息,对于具有复杂、非线性特征的湿地分类问题就会受到极大限制。深度学习从大数据中自动提取与目标任务最相关的特征,具有鲁棒性强、模型易于迁移等优点。此外,深度学习一定程度上解决了目前大量的计算机工作需要人类提供预定义的规则或指导的问题,能够有效减少人为参与[22],因此,对高分影像湿地进行分类可以充分利用影像的空间结构信息。这不仅在一定程度上提高了高分影像湿地分类的处理精度,还满足了高分影像湿地分类进行少量人工干预的自动化快速分析的需求。目前,研究学者基于深度学习在高分影像湿地分类已进行了大量研究,但缺乏一个比较全面、系统的综述,在结合深度学习的高分影像湿地分类上仍存在许多问题有待研究。例如深度学习依赖大量的标记样本进行网络的训练[23],但由于湿地的复杂性和异质性,高分影像获取昂贵,缺乏公开可以利用的数据库,造成深度学习在高分影像湿地领域可以利用的标记样本数据量的缺乏[24]。因此,为了探究如何利用深度学习更好地进行高分影像湿地分类,本文针对深度学习在高分影像湿地分类领域中的应用展开探讨,提出了深度学习技术应用在此领域的一些挑战,最后,展望了深度学习在高分影像湿地分类中的发展方向。

2 高分影像湿地分类的研究现状

2.1 高分影像的优势与挑战

随着卫星技术的发展,具有高空间分辨率的影像正逐步普及和可用。这些影像大多来源于RapidEye、WorldView-2、WorldView-3、吉林一号卫星、高分一号(GF-1)、高分二号(GF-2)、QuickBird、SPOT 6等卫星(表1)。更精细的空间分辨率和更频繁的时间数据可以显著提高分类和识别的准确性[25],实现湿地植物群落尺度的分类制图,以及捕捉湿地的动态变化。Gonzalez等[26]使用WorldView-2图像绘制并描述了桑博龙邦湾南部沼泽湿地中主要植物群落的分布格局,实现能够在景观尺度上区分高度细节植物群落。Dechka等[27]利用IKONOS-2卫星影像进行湿地监测,绘制了加拿大草本湿地植被群落的分布制图。Adam等[28]使用WorldView-2影像绘制了在南非北开普省半干旱地区腺扁豆入侵和共存的本地物种的分布制图。McCarthy等[29]发现WorldView-2比Landsat 8在沿海湿地制图方面有更高的识别精度。

首先,与中低分辨率影像相比,高分影像具有丰富的光谱和空间数据信息,其优势在于高空间细节地物的边界、斑块的几何形状和纹理。然而,这也导致它的复杂性随着观测尺度的细化和对象的细节变得丰富而迅速增加,使得阴影和地物的类内可变性增加,类间可分离性减小,由此给高分影像湿地分类带来了更多的挑战。其次,不同类型的湿地在光学卫星数据中可能具有相似的光谱特征,即存在“同谱异物”和“同物异谱”的现象[30]。第三,这些具有高分辨率的卫星是商业的,影像获取成本昂贵且对外开放的可用数据有限。最后,湿地植被类型具有光谱相似性,湿地植被的生命形态和物种组成存在随时间变化的特点[31],此外,湿地水位呈季节性变化使得湿地边界可能呈现季节性的变化规律[32],而这些时间性特征往往难以捕捉。上述原因导致湿地的标注数据获取非常耗时、成本昂贵,给湿地分类,特别是物种级分类带来了更多的挑战[33-34]。

2.2 基于传统方法的高分影像湿地分类研究进展

高分影像地物分类意在为每一个像素赋予一个地物类别,其难点通常在于有效的影像特征提取

表 1　常用于深度学习的高分影像卫星参数

Table 1　Commonly used high-resolution image satellite parameters in deep learning

卫星名称	发射年份	空间分辨率/m	轨道高度/km	卫星国别	应用案例
GF-1	2013年	全色影像:2 多光谱影像:8	645	中国	沼泽湿地植被分类[35]
GF-2	2014年	全色影像:0.81 多光谱影像:3.24	631	中国	滨海湿地植被分类[19]
GF-6	2018年	全色影像:2 多光谱影像:8	645	中国	红树林湿地制图[36]
GF-7	2019年	全色影像:0.5 多光谱影像:2	506	中国	红树林湿地制图[37]
北京二号	2015年	全色影像:0.8 多光谱影像:3.2	651	中国	红树林湿地制图[37]
北京三号	2021年	全色影像:0.5 多光谱影像:2	600	中国	红树林湿地制图[37]
高景一号	2016年	全色影像:0.5 多光谱影像:2	530	中国	红树林湿地制图[37]
资源三号01星	2012年	全色影像:2 多光谱影像:8	506	中国	红树林湿地制图[36]
资源三号02星	2016年	全色影像:2 多光谱影像:8	505	中国	湿地植物物种分类[38]
吉林一号	2015年	全色影像:0.72 多光谱影像:2.88	650	中国	海珠湖湿地植被分类[33]
IKONOS	1999年	全色影像:1 多光谱影像:4	681	美国	草本湿地植被分类[27]
QuickBird	2001年	全色影像:0.61 多光谱影像:2.44	482	美国	淡水湖泊湿地植被分类[39]
WorldView-2	2009年	全色影像:0.46 多光谱影像:1.84	770	美国	沼泽湿地植被分类[26]
WorldView-3	2014年	全色影像:0.31 多光谱影像:1.24	617	美国	森林湿地洪泛区制图[40]
RapidEye	2008年	多光谱影像:5	630	德国	湿地分类制图[41]
SPOT-6	2012年	全色影像:1.5 多光谱影像:6	694	法国	人工湿地浮游植物监测[42]

与基于特征的分类[43]。因此,如何提取有辨识度的地物特征,并将像素按照其所属类别正确归类是实现高分影像地物分类的关键。

基于传统方法的高分影像湿地分类研究中,许多研究者提出了各类基于图像的提取方法,主要集中在各种监督或非监督机器学习分类算法[44-45]。按照不同的分类标准可分为基于像元和基于对象的图像分析方法。两种方法的区别在于所依赖的是几何特征还是光谱特征,前者以湿地影像作为整体进行建模,对每个像素进行分类,而不考虑相邻像素。后者将影像分割后的对象或者区域作为最小分析单元,利用光谱和背景图像特征进行分类和识别。与基于像素的方法不同,基于对象方法将对象形状和上下文信息加入到光谱和纹理信息中,可在一定程度上消除单个像素分类产生的“椒盐”现象[46]。

传统机器学习分类包括特征提取和分类两个方面。特征提取是将空间、光谱和时间卫星数据转换为特征向量,利用这些衍生特征在分类器阶段训练和执行机器学习模型[47-49]。传统的分类器有随机森林(Random Forest,RF)、支持向量机(Support Vector Machine,SVM)、最大似然等。根据目标和研究区影像的复杂性和维度选择分类器,可以对湿地进行准确的分类。最大似然无法对多维遥感数据进行充分分类,但对于有着特殊的映射应用,参数化最大似然分类器比非参数化分类器具有更高的精度。Carle等[50]发现最大似然比SVM分类器在

绘制淡水沼泽植被分布图时精度更高，总体准确率达75%。RF和SVM等非参数方法，在高维数据的分类方面表现出更好的性能。RF因其简单且鲁棒性强，也被广泛应用于湿地分类[51-52]。SVM是另一种常用于复杂湿地分类的分类器[53]，在解决小样本、非线性等问题中表现出优异的性能[54]。该算法的目标是找到一个分类超平面，使得训练样本中的两类样本都能够被分开，并且距离该平面尽可能地远[55]。Deval等[56]发现在绘制印度半干旱森林湿地地物时，SVM更适合识别光谱特征相似高的物种，分类准确率达到了85.12%。

以上都是常见的高分影像湿地的底层特征提取与分类方法，这些特征提取的方法都能取得不错的分类结果，但是，这种人工设计的底层图像特征被用于高分影像湿地分类时，存在以下问题：①这种涉及经验和主观的人工特征工程需要具备该领域大量的先验基础知识[57]；②设计和挑选的特征需要是目标相关的[19]；③人工设计的底层特征和高级语义之间存在语义鸿沟[58]。这些都使得利用底层特征进行高分影像湿地提取时难以做到针对不同场景、不同数据的自适应学习，泛化能力差，导致更换研究区域和数据后，已有的湿地分类模型往往不能取得较好的分类结果[59]。

3 基于深度学习的高分影像湿地分类模型研究进展

3.1 深度学习在高分影像湿地分类中的优势

如前所述，高分影像湿地的分类任务关键在于对影像中目标地物的理解和特征提取。然而构建复杂的特征描述规则具有一定的难度，多数情况下无法清楚地知道待分类的湿地影像需要提取哪些特征以进行地物的分类与识别。同时，湿地水陆交接边界条件的变化增大了湿地边界提取的不确定性，如季节和气候的变化，地表水分的变迁，以及光照强度、拍摄角度的变化等，都会使所提取的特征不足以表征计算机所面临的待分类的地物，为高分影像湿地的分类造成更大困难。随着人工智能的发展，深度学习为湿地影像分类提供了一种新的思路。

深度学习通过强大的特征学习能力，适应多模态数据和复杂场景的能力，以及高度自动化的流程，为高分影像湿地分类提供了更加精准、高效和灵活的技术手段。在多层感知机的设计下，深度学习能够从海量的原始数据中自主的进行特征层次学习，构建低—中—高层特征的学习模式，用于提取具有鲁棒性、稳定性与不变性的特征[60]。通过逐层特征学习获得更抽象的、具有区别度的、含有语义信息的深层特征，并利用层次化的端对端构建方式，跨越语义鸿沟，将特征提取与湿地影像的分类结合为一体进行训练，从而最终提升分类或预测的准确性。首先，深度学习优势在于能够学习湿地植被、泥滩等多种地物的光谱、空间和纹理特征，更好地处理混合像素问题；其次，支持迁移学习，可以通过预训练模型和半监督学习在小样本条件下提升湿地分类性能；第三，结合时间序列和空间特征，可以实时分析湿地植被的时空变化；最后，高效的自动化和扩展性，可以满足湿地大规模遥感数据的自动分类。

目前，在高分影像湿地分类中应用成功的深度学习模型可大致分为判别模型和生成模型两类，前者通过学习特征与类型的条件概率来判断输入数据的类别，后者通过学习特征与类型的联合概率来揭示数据生成机制，从而求得条件概率分布。其中，基于判别模型的深度学习模型包括深度神经网络（Deep Neural Network，DNN）和卷积神经网络（Convolutional Neural Network，CNN）。基于生成模型的最具代表性的是生成对抗网络（Generative Adversarial Network，GAN）。

3.2 基于深度神经网络的高分影像湿地分类

DNN按照不同层的位置划分，内部的神经网络可分为输入层、隐藏层和输出层。DNN可以理解为有很多隐藏层的神经网络，有强大的非线性拟合能力、特征提取能力和容错能力，在面对海量、高维度的数据时，表现优于机器学习[61]。

一些研究学者尝试将高分影像与DNN结合，用于1.2 m分辨率的高精度湿地测绘中。Martins等利用主成分分析（Principal Component Analysis，PCA）的特征选择方法识别来自光探测和测距（LiDAR）数据的相关输入变量，并集成一组多光谱数据和输入变量来训练一个深度神经网络架构[62]（图1），同时探讨了各种输入变量（光谱、纹理和地形等）的选择对DNN模型精度的影响，并与传统的机器学习方法进行比较后发现，该模型在高分影像湿地类型分类的精度达到93.3%，其准确率与其他传统方法相当。由于DNN模型是以向量形式输入特征，不考虑影像的结构信息，虽然在每一层都会进行一个全局的特征提取，但这个过程并非递进，

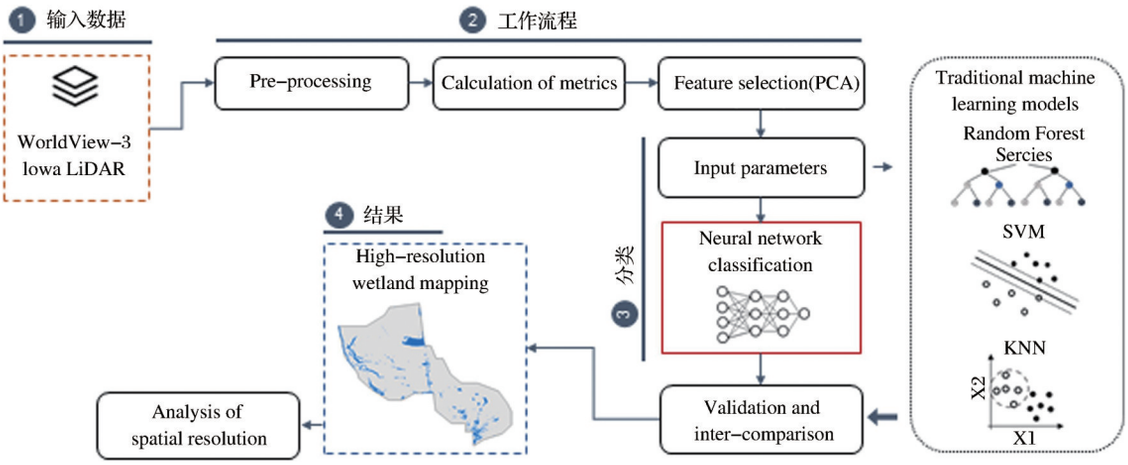

图 1　基于 DNN 模型湿地测绘[62]

Fig.1　Wetland mapping based on DNN model

导致最终的特征质量提高不大。DNN 模型虽可以用于高分影像湿地分类提取中,其优势与传统方法相比,并不明显[62]。

3.3　基于卷积神经网络的高分影像湿地分类

CNN 主要用于计算机视觉领域(Computer Vison,CV),由输入层、卷积层、池化层、全连接层和输出层组成[63],如图 2 所示。通过堆叠多层卷积层和池化层,可以得到更深的网络结构,对图像的高层语义特征进行提取,如 VGG、Xception 等,其后的全连接层也可以是多层的。CNN 的优势是将图像特征提取与分类任务集成到一个模型中,通过端到端训练,可以使模型自动学习到最具有代表性的图像特征,进而提高分类精度。

CNN 具有超强的图像特征提取能力[64],近年来被广泛应用于高分影像湿地分类领域的研究。在前期研究中,研究学者倾向于自行搭建一个简单的 CNN 或直接使用计算机视觉领域的经典模型(AlexNet、VGG、Xception、ResNet 等),通过训练基于图像块的分类模型,然后在整个研究区的影像上以滑窗方式得到逐像素或逐图像块的预测结果。Rezaee 等[41]使用在 ImageNet 上预训练的 AlexNet 网络对湿地进行分类,结果显示,相比于 RF 分类器,在土地覆盖类型识别中,CNN 的总体精度达到了 94.82%,提高了约 16%,在湿地分类方面,平均提高了约 30%。

研究发现相比随机森林等经典机器学习模型,具有高级空间特征的 CNN,可以减少光谱相似引起的湿地类别之间的混淆,从而有效改善湿地分类精度。游佩佩等[19]使用 VGG16 进行湿地典型植被解译,总体分类精度达到了 98.71%,Kappa 系数为 0.99,比 SVM、BP 神经网络分别提高了 2.83% 和 7.84%。

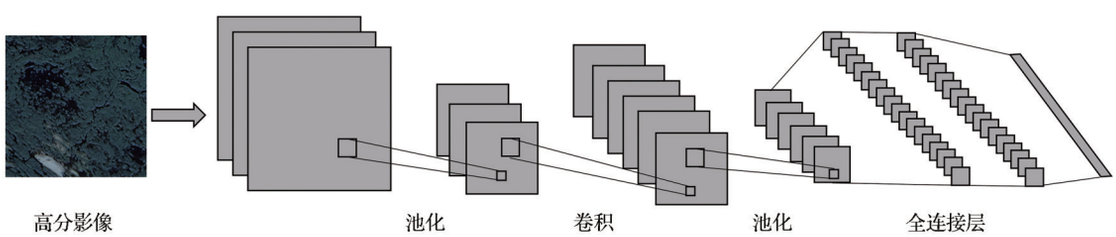

图 2　卷积神经网络

Fig.2　Convolutional Neural Network

考虑到高分辨率影像具有多波段的特点,研究人员使用更深层架构的 CNN 来同时学习高分影像的空间特征和光谱特征。Mahdianpari 等[65]对比了 7 种深度卷积神经网络模型湿地分类的性能,其中 Inception 和 ResNet 的集成网络 InceptionResNetV2 实现了最高的分类精度,达到了 96.17%,尤其在处理特别复杂的湿地分类问题方面表现突出。研究表明,不同网络对于特征提取是互补的,利用更多的光谱信息对于光谱相似的湿地类别进行分类非常重要。

此外,一些研究人员将集成学习与深度学习相结合来解决复杂的湿地分类。Jamali 等[66]提出了一

个集成模型(图3),先分别对比了8种深度卷积神经网络模型在3个研究区域的精度,之后利用RF、袋装树(Bagged Tree,BTree)、贝叶斯优化树(Bayesian Optimized Tree,BOT)3个监督分类器和一个无监督多数投票分类器融合每个研究区域内3个最佳网络的结果。此外,该研究将融合后的分类器结果与单个深度卷积神经网络比较发现,融合后的4个分类器在3个研究区的结果都得到了提高,尤其BTree模型对各种湿地类型分类效果更好,集成的CNN模型的平均精度相比单个最优CNN模型提高了9.63%~19.04%。研究还表明微调参数较少的CNN网络在识别湿地方面的准确率更高,并且研究区域的已有训练数据数量不同,也会造成不同的分类效果。

CNN不仅可以提取影像特征,还可以被用于图像分辨率重建之中,如超分辨率卷积神经网络(Super-Resolution Convolutional Neural Network,SRCNN)和快速超分辨率卷积神经网络(Fast Super-Resolution Convolutional Neural Network,FSRCNN),这些网络也可以被用于高分影像湿地植被监测,进行物种识别。Chen等[67]提出一种基于对象的图像分类框架,用于黄河三角洲湿地进行早期外来入侵植物的监测。

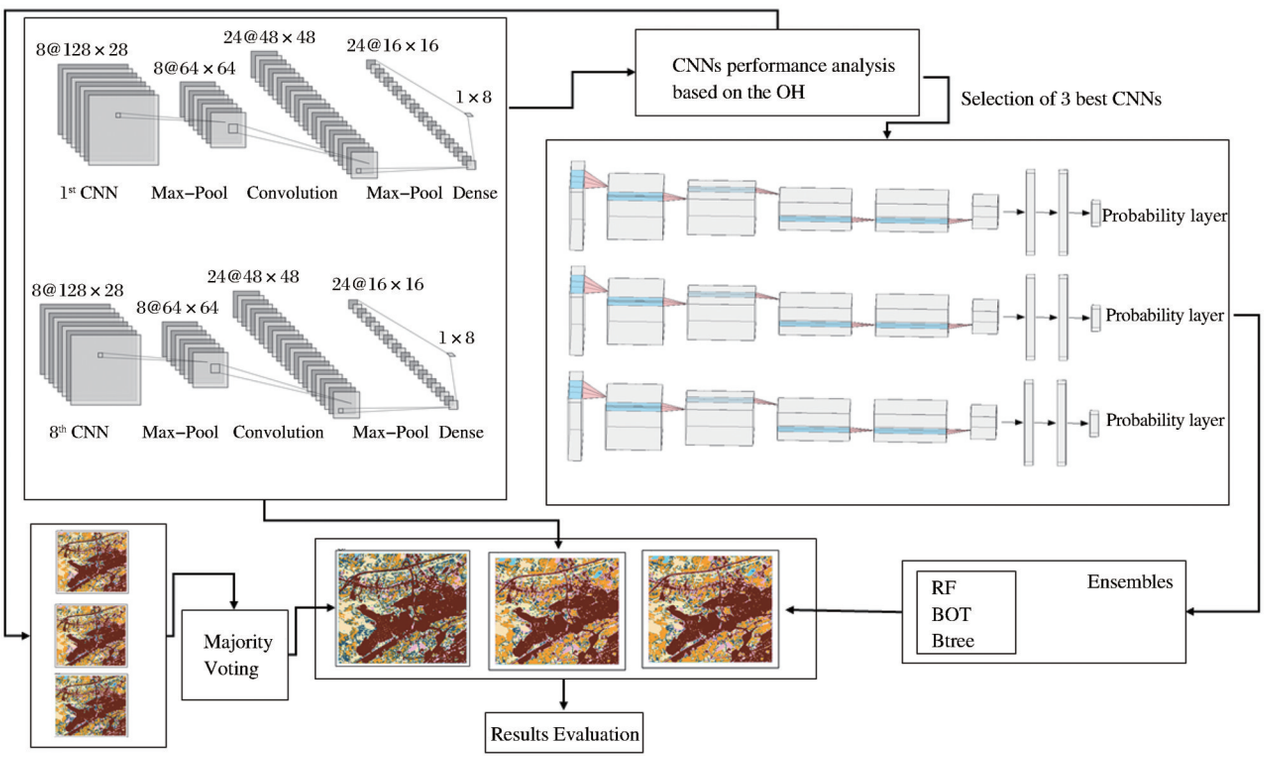

图3 集成深度学习模型框架[66]

Fig.3 Integrated deep learning model framework[66]

相比传统CNN以基于图像块的方式进行湿地分类,全卷积神经网络则可以实现像素级的地物分类,在大范围湿地制图时其计算效率高的优势较为明显。其中U-Net是较早使用全卷积网络进行语义分割的算法之一,具有结构简洁、鲁棒性高的特点,其中的编码器(下采样)—解码器(上采样)和跳跃连接经典结构被许多新的卷积神经网络所借鉴,并广泛应用于图像分割领域。Du等[40]使用了一种基于U-Net改进的模型,将WorldView-3多光谱数据与精细空间分辨率LiDAR、数字高程模型(DEM)和地形湿度指数(TWI)相结合对德尔马瓦半岛地区森林湿地进行洪水淹没制图。该网络以U-Net为主干,加入改进的卷积层残差块,即由残差连接、空洞卷积、金字塔池化模块和多任务学习组成,扩大了感受野,以提取全局和不同尺度下语义关系。加入混合的Dice和Focal损失函数,以缓解正负样本数量不平衡的问题,促进模型的训练。该模型集成了输入图像的空间和光谱信息,利用高分辨率影像在森林湿地洪泛区识别的准确率达到了95%,具有较高的精度和较少的"椒盐"效应。考虑到湿地具有季节性或者周期性变化,湿地边界难以确定。Sun等[36]采用多源数据,集成空间、时间和模型,提出了一种基于红树林生境、低潮和语义分割的时空优化方法模型(hybrid U-Net)。该方法利用

红树林退潮期，减少了周围植被对红树林湿地边界区分的干扰，满足了小样本、高精度、高效绘制大尺度红树林需求。

DeepLab系列通过多尺度空洞卷积方法解决了图像分割中的多尺度问题，也被广泛应用于高分影像湿地分类中。Liu等[35]选取高空间分辨率卫星高分1号、高分2号等不同的遥感数据作为数据源，基于DeepLabV3+深度学习模型，构建了12个植被分类模型，探讨不同空间分辨率和光谱范围的遥感影像对滨海湿地地物分类的影响。其中利用空间分辨率为0.8和多种光谱指数的影像数据源实现了最高的整体分类精度，达到了92.8%。研究发现，结合影像光谱波段和光谱指数（植被指数、土壤指数和水分指数等）可以提高沼泽植被分类的精度。此外，影像的空间分辨率越高，由于光照影响，较高的植被更加容易受到阴影的干扰，因此更精细的空间信息在一定程度上也会造成干扰。Chen等[38]采用多源数据与光谱指数结合，将基于对象分析方法（OBIA）和CNN相结合构建了MRS_DeepLabV3+模型，实现了湿地植物物种分类。

采用先进的语义分割模型，也可以提高湿地的分类精度。Cheng等[68]利用坐标注意力机制对RegNet模型进行改进，得到CA-RegNet模型，引入的空间信息，可以增强模型对影像空间结构的理解，用于滨海湿地分类，成功区分人工湿地与滨海湿地；同时也将ConvNeXt、EfficientNet B7、Inception-RegNet和SE-RegNet模型首次应用于高分影像湿地分类任务中，并表现出优越的分割性能。同时，研究人员也将CNN引入先进的语义分割模型。Zhang等[37]将CNN引入先进的半监督语义分割模型（Segment Anything Model，SAM），利用CNN能够提取多尺度局部空间结构和纹理特征作为辅助分支，与SAM用于捕捉全局语义信息的主干（Vision Transformer，ViT）形成互补与融合关系，得到一种增强的MW-SAM模型。该方法在针对湿地复杂的边界和内部的异质性问题上，还引入了提示生成策略生成特定湿地的特征，在红树林湿地分类中展示了显著的效果。但该模型的计算复杂度较高，需要大量的计算资源。

3.4　基于生成对抗网络的高分影像湿地分类

GAN包括：生成器（Generator，G）和判别器（Discriminator，D）两部分，如图4所示[69]。G根据要求不断从随机噪声中生成与实际标签数据相近的伪样本，并传递给D；然后D推断图像是来自G所产生的还是真实的[70]。在博弈中，由G和D在对抗训练的过程中进行迭代优化，不断优化各自网络的参数，最后达到纳什平衡状态[71]。

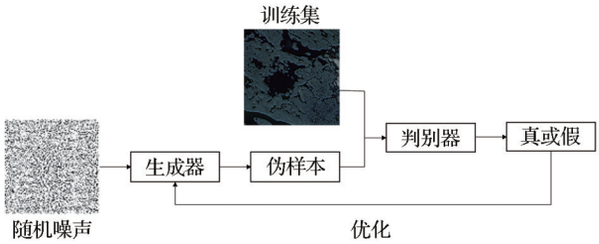

图4　生成对抗网络

Fig.4　Generative Adversarial Network

DNN和CNN尽管具有适用性和成功案例，但都需要大量的标记样本来提高模型的性能。以GAN为代表的生成网络则可以部分解决深度学习样本不足的问题[72-74]，为湿地的样本稀缺问题提供了解决思路。以地物分类为例，通过将需要处理的高分影像裁剪为指定大小的训练样本以代替随机变量，进而训练生成器以直接生成地物的形式来代替分类模型中的识别过程，可以有效减少识别过程中所需要的环节数。同时，通过选择合适的对抗训练方法和损失函数以保证模型优化的合理性和有效性，进而在自动化训练过程中保证较高的精准度。相较于卷积神经网络，基于GAN网络的方法通过对抗训练优化模型性能，在不增加网络复杂度的情况下，可以有效增强像素预测结果的一致性。

如果标签样本数量不足，容易造成分类模型的过拟合，降低模型的时空泛化能力。为了综合利用有限的标签样本和海量无标签样本进行模型训练，He等[33]提出一种基于对象的半监督湿地分类方法，即ShuffleGAN，该模型将ShuffleNet加入GAN网络之中，以减少计算量，获得速度和精度之间的平衡，同时将训练集分成标记和未标记样本放入模型进行训练，以解决湿地分类中的标记样本缺乏的问题。该方法总体准确率（Overall Accuracy，OA）达到了83.55%，在视觉质量和湿地分类精度方面都表现出优异的效果，实现了物种级分类。

从表2对比分析中可知，当样本数据量足够大、分类复杂且数据来源较多时，卷积神经网络算法最为合适；当数据规模较小时，应选择生成对抗网络等半监督模型。但是各种分类方法都有自身的局限性。

表2 深度学习高分影像湿地分类方法特点

Table 2 Characteristics of wetland classification methods in deep learning high-resolution images

	神经网络	代表性分类算法	优点	缺点
判别模型	深度神经网络	DNN	相比传统方法优势并不明显	以向量形式输入特征,不考虑影像结构,样本需求量大
	卷积神经网络	CNN	可以减少光谱相似引起的湿地类别之间的混淆,分类精度较高	样本需求量大
		AlexNet、VGG、Xception、ResNet、Inception	网络层数深,处理复杂的湿地分类表现优异	样本需求量大,分类精度依赖于神经网络的层数
		SRCNN、FSRCNN	提高图像分辨率,恢复图像的光谱和空间细节	分类精度依赖于所构建的斑块的大小
		UNet、DeepLab	实现像素级分割、适用于大范围湿地制图,具有较少的“椒盐”效应	样本需求量大
		RegNet	处理复杂影像效果显著	样本需求量大
生成模型	生成对抗网络	GAN	样本需求量少	模型不好收敛

4 深度学习在高分影像湿地分类应用中的挑战与展望

湿地植被等土地覆被的类型和空间分布随环境因素发生快速而频繁的变化,包括季节和气候变化、地形、海平面上升、水温、洪水和盐碱化等,利用高分影像进行高精度湿地分类是具有挑战性的。湿地景观的动态监测较复杂,需要季节性多次采集数据,并且之后需要通过具有快速且自动化算法、较少人为干预的监测系统,来分析具有高空间、时间和光谱分辨率的影像。特别是对于这种连续或几乎实时的土地覆盖监测系统,如果使用专业知识来设计和提取湿地不同类别的最有效和区分性特征,会更加困难,并且分类的精度依赖于这些特征挑选的质量。深度学习的自动提取特征,可以快速得到精度更高、更准确的分类结果,为解决这些问题提供了新的方向。目前深度学习在高分影像湿地分类应用中仍存在以下3点不足。

4.1 标准湿地遥感样本数据集构建的问题

深度学习属于数据驱动模型,基于深度学习的高分影像湿地分类性能很大程度取决于样本数据的规模大小和标注质量,以及湿地结构的复杂性和类别的多样性。在数据集构建技术上,一方面,湿地数据采集困难,需要野外实地观测,样本数据标注费时费力;另一方面,大多数研究人员难以获得高分辨率商业数据。这就导致样本数据集不仅在数量上有限,在种类上也缺乏,并且大多数可用的高分影像样本数据集,因其样本仅采集于特定的时间和地点,且需要考虑湿地的季节性变化、光照效应和不同区域的类内变化等因素,形成一个综合数据集难度很大。

4.2 深度学习网络的泛化性问题

由于湿地遥感数据的时、空特殊性,在特定区域构建好的深度学习网络模型通常是针对该区域特定生态系统训练的,而不是一个通用的混合生态系统模型。在新的区域应用时,仍然需要大量的实测标记样本,才能使模型的精度更高。如何提高深度学习网络的泛化性是急需解决的问题。

4.3 深度学习模型结构优化的策略问题

在高分影像湿地分类研究中,大部分研究学者直接使用计算机视觉领域中较为成熟的深度学习模型,或者对模型进行了改进,虽然也有研究学者针对高分影像的特点进行了模型优化,但其适用范围还需进一步验证。一方面针对数据源,研究人员多采用多源、多时相、多分辨率获得湿地的动态变化和特征,在模型上采用四通道或者多通道结构;尽管多通道模型能够融合多源数据,取得显著成果,但多源数据的特征提取网络是否需要单独设计,不同波段之间的特征是否需要融合,如何进行特征融合,还有待思考;此外,如何充分利用数据中蕴含的地貌知识或者其他植被知识图谱,也是一个需要思考的问题。最后,模型的输入数据源需要切片,这一过程可能会导致每个切片之间存在地物边界,而这些切片通常彼此不重叠,在切片边界处的信息可能不完整,导致模型在地物边界处的分类不太准确。另一方面针对模型结构,深度学习模型对输入的高分影像湿地进行自动学习提取特征,具有一定程度上的“黑盒”特性和不可解释性。同时,深度学习训练模型的参数优化,即批量大小、学习率等,也是一个尚待解决的挑战。目前还没有确切的

方法来实现超参数的最佳组合。

5　未来的探索方向

结合当前深度学习在湿地植被遥感研究的现状及不足,建议未来应加强以下几个方面的研究。

5.1　样本数据集构建研究

构建大规模公开样本数据集平台,整合不同来源的数据集,从而帮助研究者进行深度学习模型构建和训练。建议采用两种方式进行数据集构建。一种是图像块级标注(一个图像块一个类别)。这种标签对细节不太敏感,优点是比较容易制作,缺点是无法提供精确的地物边界信息,可能会导致大区域制图结果出现明显的边缘锯齿效应;并且一个图像块中可能会同时存在多种地物类型,增加模型分类难度。另一种像素级标注,需要由该领域的专家对影像像素进行分类并生成分割地图,相比图像块级样本可以提供精确的地物边界信息,但是比较耗时。

5.2　深度学习网络模型研究

(1)稀疏样本下深度学习模型构建。除了扩大数据集规模外,还可以尝试构建需要少量样本的网络,比如无监督、半监督学习和迁移学习。无监督学习对样本的需求最低。半监督方法可以同时利用有限的标记样本和大量未标记的样本来训练分类器,减少了一部分标记样本需求。迁移学习方法使用一个预先训练的分类器来提取新数据集的特征,例如使用标记多模态数据集上的预训练模型来标记单模态数据集。也可以在模型训练之前采用数据增强方法增加样本数量,采用图像变换(如翻转、平移、旋转)在原始数据的基础上生成额外的、更多样化的数据样本。

(2)深度学习模型结构优化。结合高分影像的自身特点,有针对性地改进深度学习网络,不断探索计算机视觉领域的技术在高分遥感湿地分类中的结合。首先,针对湿地影像与其他遥感影像不同,呈现季节性动态变化,且没有明确边界的问题。如季节性变化会导致植被分类时光谱可分离性降低,网络在模型训练期间学习具有相似特征的植被类型时会产生混乱。在构建模型数据集时,一方面,可以考虑输入多源、多时、多分辨率影像,从“时空”、“空谱”、“时空谱”一体化融合特征等方面考虑,可以全面捕捉湿地的动态变化,提高分类准确性;另一方面,为了减弱深度学习的“黑盒”特性和可解释性。可以加入一些辅助信息(如光谱指数、(Digital Elevation Model, DEM)和植被指数序列等),进而更好地利用湿地的先验知识,从而提高模型结构的合理性。而对于数据切片带来的问题,可以使用滑动窗口或者添加重叠区域,来解决切片边界的问题,提高边界处的分类精度。

其次,在网络的选择和设计上可以结合湿地的具体问题,选择合适的分类器或者综合不同类型网络的优势,来更有效地解决湿地分类中的问题。具体而言,高空间分辨率影像的空间信息更丰富、更精细,在一定程度上减少了像元混叠,提高了模型的可操作性,但对于一些复杂土地覆盖类型,噪声干扰则更加严重(如阴影、云、雾等),加剧了目标提取的困难。为了解决噪声干扰问题,则可以选取去噪模型。其次,CNN类能够多尺度提取局部特征的网络的分类效果表现优异,因此对于物种级分类可以考虑在模型中引入CNN;而能够实现像素级分类的语义分割模型,对于湿地复杂边界的提取效果更加显著,因此对于大尺度湿地制图可以选择先进的语义分割模型。

最后,不同的遥感影像具有不同的优缺点,如多尺度、多传感器、多时相、多谱段等特征。因此,在设计网络时,可以考虑引入多模态神经网络,将不同类型的遥感影像(如光学遥感、合成孔径雷达影像、LiDAR和高光谱数据等)进行多模态数据融合,还可以引入注意力机制和提示生成策略,帮助网络聚焦于湿地影像中的关键区域(植被、边界)从而提高分类的准确度和可靠性。此外,在网络参数优化方面,可以尝试自适应地确定最佳网络参数。

参考文献(References):

[1] MAHDAVI S, SALEHI B, GRANGER J, *et al*. Remote sensing for wetland classification: A comprehensive review[J]. GIScience & Remote Sensing, 2018, 55(5): 623-658. DOI: 10.1080/15481603.2017.1419602

[2] TINER R W. Wetland indicators: A guide to wetland formation, identification, delineation, classification, and mapping[M]. Boca Raton: CRC press, 2016.

[3] MAO D H, WANG Z M, DU B J, *et al*. National wetland mapping in China: A new product resulting from object-based and hierarchical classification of Landsat 8 OLI images[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2020, 164: 11-25. DOI: 10.1016/j.isprsjprs.2020.03.020

[4] YANG Yongxing. Main characteristics, progress and prospect of international wetland science research[J]. Progress in Geography, 2002, 21(2): 111-120.[杨永兴. 国际湿地科学研究

的主要特点、进展与展望[J]. 地理科学进展, 2002, 21(2): 111-120.]

[5] MITSCH W J, BERNAL B, HERNANDEZ M E. Ecosystem services of wetlands[J]. International Journal of Biodiversity Science, Ecosystem Services & Management, 2015, 11(1): 1-4. DOI: 10.1080/21513732.2015.1006250

[6] MOHAMMADIMANESH F, SALEHI B, MAHDIANPARI M, *et al*. Wetland water level monitoring using Interferometric Synthetic Aperture Radar (InSAR): A review[J]. Canadian Journal of Remote Sensing, 2018, 44(4): 247-262. DOI: 10.1080/07038992.2018.1477680

[7] WERNER B A, JOHNSON W C, GUNTENSPERGEN G R. Evidence for 20th century climate warming and wetland drying in the North American Prairie Pothole Region[J]. Ecology and Evolution, 2013, 3(10): 3471-3482. DOI: 10.1002/ece3.731

[8] DAVIDSON N C.Ramsar convention on wetlands: Scope and implementation[M]. The Wetland Book. Dordrecht: Springer Netherlands, 2018: 451-458. DOI: 10.1007/978-90-481-9659-3_113

[9] MAHDIANPARI M, SALEHI B, MOHAMMADIMANESH F, *et al*. The first wetland inventory map of Newfoundland at a spatial resolution of 10 m using Sentinel-1 and Sentinel-2 data on the Google Earth Engine cloud computing platform[J]. Remote Sensing, 2019, 11(1): 43. DOI: 10.3390/rs11010043

[10] FOURNIER R A, GRENIER M, LAVOIE A, *et al*. Towards a strategy to implement the Canadian wetland Inventory using satellite remote sensing[J]. Canadian Journal of Remote Sensing, 2007, 33(Sup1): S1-S16. DOI: 10.5589/m07-051

[11] LAROCQUE A, PHIRI C, LEBLON B, *et al*. Wetland mapping with Landsat 8 OLI, Sentinel-1, ALOS-1 PALSAR, and LiDAR data in Southern New Brunswick, Canada[J]. Remote Sensing, 2020, 12(13): 2095. DOI: 10.3390/rs12132095

[12] MOHAMMADIMANESH F, SALEHI B, MAHDIANPARI M, *et al*. Full and simulated compact polarimetry SAR responses to Canadian wetlands: Separability analysis and classification[J]. Remote Sensing, 2019, 11(5): 516. DOI: 10.3390/rs11050516

[13] AMANI M, BRISCO B, MAHDAVI S, *et al*. Evaluation of the Landsat-based Canadian wetland inventory map using multiple sources: Challenges of large-scale wetland classification using remote sensing[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2020, 14: 32-52.

[14] MCCARTHY M J, RADABAUGH K R, MOYER R P, *et al*. Enabling efficient, large-scale high-spatial resolution wetland mapping using satellites[J]. Remote Sensing of Environment, 2018, 208: 189-201. DOI: 10.1016/j.rse.2018.02.021

[15] ADAM E, MUTANGA O, RUGEGE D. Multispectral and hyperspectral remote sensing for identification and mapping of wetland vegetation: A review[J]. Wetlands Ecology and Management, 2010, 18(3): 281-296. DOI: 10.1007/s11273-009-9169-z

[16] MCCARTHY M J, MERTON E J, MULLER-KARGER F E. Improved coastal wetland mapping using very-high 2-meter spatial resolution imagery[J]. International Journal of Applied Earth Observation and Geoinformation, 2015, 40: 11-18. DOI: 10.1016/j.jag.2015.03.011

[17] LANE C R, ANENKHONOV O, LIU H X, *et al*. Classification and inventory of freshwater wetlands and aquatic habitats in the Selenga River Delta of Lake Baikal, Russia, using high-resolution satellite imagery[J]. Wetlands Ecology and Management, 2015, 23(2): 195-214. DOI: 10.1007/s11273-014-9369-z

[18] ZIKOPOULOS P, EATON C. Understanding big data: Analytics for enterprise class Hadoop and streaming data[M]. New York: McGraw-Hill Osborne Media, 2011.

[19] YOU Peipei, LIU Zhenbo, XIE Jiawei, *et al*. Research on deep learning algorithm remote sensing classification of Jiangsu coastal wetlands based on GF-2 image[J]. Resources and Environment in the Yangtze Basin, 2021, 30(7): 1659-1669.[游佩佩, 刘振波, 谢嘉伟, 等. 基于GF-2的江苏滨海湿地遥感深度学习分类算法研究[J]. 长江流域资源与环境, 2021, 30(7): 1659-1669.]

[20] TANG Yuqi. Research on object-oriented detection of multi-feature changes in cities with high resolution images[D]. Wuhan: Wuhan University, 2013.[汤玉奇. 面向对象的高分辨率影像城市多特征变化检测研究[D]. 武汉: 武汉大学, 2013.]

[21] ZHU Hongchun, CAI Lijie, LIU Haiying, *et al*. Optimal segmentation scale calculation for high-resolution remote sensing image[J]. Science of Surveying and Mapping, 2015, 40(3): 71-75.[朱红春, 蔡丽杰, 刘海英, 等. 高分辨率影像分类的最优分割尺度计算[J]. 测绘科学, 2015, 40(3): 71-75.]

[22] TAO Yiting. Research on classification method of high spatial resolution remote sensing images based on deep learning[D]. Wuhan: Wuhan University, 2019.[陶翊婷. 基于深度学习的高空间分辨率遥感影像分类方法研究[D]. 武汉: 武汉大学, 2019.]

[23] GOODFELLOW I, BENGIO Y, COURVILLE A. Deep learning[M]. Cambridge, MA: MIT Press, 2016.

[24] VALI A, COMAI S, MATTEUCCI M. Deep learning for land use and land cover classification based on hyperspectral and multispectral earth observation data: A review[J]. Remote Sensing, 2020, 12(15): 2495. DOI: 10.3390/rs12152495

[25] ROGAN J, CHEN D M. Remote sensing technology for mapping and monitoring land-cover and land-use change[J]. Progress in Planning, 2004, 61(4): 301-325. DOI: 10.1016/S0305-9006(03)00066-7

[26] GONZALEZ E, GONZÁLEZ TRILLA G, SAN MARTIN L, *et al*. Vegetation patterns in a South American coastal wet-

land using high-resolution imagery[J].Journal of Maps,2019,15(2):642-650. DOI:10.1080/17445647.2019.1644545

[27] DECHKA J A, FRANKLIN S E, WATMOUGH M D, *et al*. Classification of wetland habitat and vegetation communities using multi-temporal Ikonos imagery in southern Saskatchewan[J]. Canadian Journal of Remote Sensing, 2002, 28(5): 679-685. DOI: 10.5589/m02-064

[28] ADAM E,MURERIWA N, NEWETE S. Mapping Prosopis Glandulosa (mesquite) in the semi-arid environment of South Africa using high-resolution WorldView-2 imagery and machine learning classifiers[J]. Journal of Arid Environments, 2017, 145: 43-51. DOI: 10.1016/j.jaridenv.2017.05.001

[29] MCCARTHY M J, MERTON E J, MULLER-KARGER F E. Improved coastal wetland mapping using very-high 2-meter spatial resolution imagery[J]. International Journal of Applied Earth Observation and Geoinformation, 2015, 40: 11-18. DOI: 10.1016/j.jag.2015.03.011

[30] AMANI M, SALEHI B, MAHDAVI S, *et al*. Wetland classification using multi-source and multi-temporal optical remote sensing data in Newfoundland and Labrador, Canada[J]. Canadian Journal of Remote Sensing, 2017, 43(4): 360-373. DOI: 10.1080/07038992.2017.1346468

[31] MITSCH W J, GOSSELINK J G. Wetlands[M]. Hoboken, NJ: John Wiley & Sons, 2015.

[32] SOUTH R. Biogeography and Ecology of the Island of Newfoundland[M]. Cham: Springer Netherlands, 1983.

[33] HE Z, HE D, MEI X Q, *et al*. Wetland classification based on a new efficient generative adversarial network and Jilin-1 satellite image[J].Remote Sensing,2019,11(20):2455. DOI: 10.3390/rs11202455

[34] JAMALI A, MAHDIANPARI M, MOHAMMADIMANESH F, *et al*. A synergic use of Sentinel-1 and Sentinel-2 imagery for complex wetland classification using Generative Adversarial Network (GAN) scheme[J]. Water, 2021, 13(24): 3601. DOI: 10.3390/w13243601

[35] LIU M, FU B L, XIE S Y, *et al*. Comparison of multi-source satellite images for classifying marsh vegetation using DeepLabV3 Plus deep learning algorithm[J]. Ecological Indicators, 2021, 125: 107562. DOI: 10.1016/j. ecolind. 2021. 107562

[36] SUN Z Y, JIANG W G, LING Z Y, *et al*. Using multi-source high-resolution remote sensing data (2 m) with a habitat-tide-semantic segmentation approach for mangrove mapping[J].Remote Sensing,2023,15(22):5271. DOI:10.3390/rs15225271

[37] ZHANG Y, WANG X, CAI J Y, *et al*. MW-SAM: Mangrove wetland remote sensing image segmentation network based on segment anything model[J]. IET Image Processing, 2024, 18(14): 4503-4513. DOI: 10.1049/ipr2.13263

[38] CHEN Z Z, CHEN J J, YUE Y M, *et al*. Tradeoffs among multi-source remote sensing images, spatial resolution, and accuracy for the classification of wetland plant species and surface objects based on the MRS_DeepLabV^{3+} model[J].Ecological Informatics, 2024, 81: 102594. DOI: 10.1016/j.ecoinf.-2024.102594

[39] EVERITT J H, YANG C, FLETCHER R S, *et al*. Using aerial color-infrared photography and QuickBird satellite imagery for mapping wetland vegetation[J]. Geocarto International, 2004, 19(4): 15-22. DOI: 10.1080/10106040408542323

[40] DU L, MCCARTY G W, ZHANG X, *et al*. Mapping forested wetland inundation in the Delmarva Peninsula, USA using deep convolutional neural networks[J]. Remote Sensing, 2020, 12(4): 644. DOI: 10.3390/rs12040644

[41] REZAEE M, MAHDIANPARI M, ZHANG Y, *et al*. Deep convolutional neural network for complex wetland classification using optical remote sensing imagery[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2018, 11(9): 3030-3039. DOI: 10.1109/JSTARS.2018.2846178

[42] SONG Y M, ZHANG J. Monitoring and simulating the distribution of phytoplankton in constructed wetlands based on SPOT 6 images[J]. Open Geosciences, 2021, 13(1): 454-468. DOI: 10.1515/geo-2020-0243

[43] DARLING E M, RAUDSEPS J G. Non-parametric unsupervised learning with applications to image classification[J]. Pattern Recognition, 1970, 2(4): 313-335. DOI: 10.1016/0031-3203(70)90021-X

[44] BLANZIERI E, MELGANI F. Nearest neighbor classification of remote sensing images with the maximal margin principle[J]. IEEE Transactions on Geoscience and Remote Sensing, 2008, 46(6): 1804-1811. DOI: 10.1109/TGRS. 2008. 916090

[45] GONÇALVES M L, NETTO M L A, COSTA J A F, *et al*. An unsupervised method of classifying remotely sensed images using Kohonen self-organizing maps and agglomerative hierarchical clustering methods[J]. International Journal of Remote Sensing, 2008, 29(11): 3171-3207. DOI: 10.1080/01431160701442146

[46] DRONOVA I, GONG P, WANG L. Object-based analysis and change detection of major wetland cover types and their classification uncertainty during the low water period at Poyang Lake, China[J]. Remote Sensing of Environment, 2011, 115(12): 3220-3236. DOI: 10.1016/j.rse.2011.07.006

[47] BERHANE T M, LANE C R, WU Q S, *et al*. Decision-tree, rule-based, and random forest classification of high-resolution multispectral imagery for wetland mapping and inventory[J]. Remote Sensing, 2018, 10(4): 580. DOI: 10.3390/rs10040580

[48] SALEHI HIKOUEI I, KIM S S, MISHRA D R. Machine-learning classification of soil bulk density in salt marsh environments[J]. Sensors, 2021, 21(13): 4408. DOI: 10.3390/s21134408

[49] MOAYEDI H, JAMALI A, GIBRIL M B A, *et al*. Evaluation of tree-base data mining algorithms in land used/land cov-

er mapping in a semi-arid environment through Landsat-8 OLI image; Shiraz, Iran[J]. Geomatics, Natural Hazards and Risk, 2020, 11(1): 724-741. DOI: 10.1080/19475705. 2020. 1745902

[50] CARLE M V, WANG L, SASSER C E. Mapping freshwater marsh species distributions using WorldView-2 high-resolution multispectral satellite imagery[J]. International Journal of Remote Sensing, 2014, 35(13): 4698-4716. DOI: 10.1080/01431161.2014.919685

[51] MARTÍNEZ PRENTICE R, VILLOSLADA PECIÑA M, WARD R D, *et al*. Machine learning classification and accuracy assessment from high-resolution images of coastal wetlands [J]. Remote Sensing, 2021, 13(18): 3669. DOI: 10.3390/rs13183669

[52] WANG X X, GAO X W, ZHANG Y Z, *et al*. Land-cover classification of coastal wetlands using the RF algorithm for Worldview-2 and Landsat 8 images[J]. Remote Sensing, 2019, 11(16): 1927. DOI: 10.3390/rs11161927

[53] HAN X S, PAN J Y, DEVLIN A T. Remote sensing study of wetlands in the Pearl River Delta during 1995～2015 with the support vector machine method[J]. Frontiers of Earth Science, 2018, 12(3): 521-531. DOI: 10.1007/s11707-017-0672-x

[54] WANG Liguo, ZHAO Liang, LIU Danfeng. A review on the application of SVM in hyperspectral image processing[J]. Journal of Harbin Engineering University, 2018, 39(6): 973-983.[王立国, 赵亮, 刘丹凤. SVM在高光谱图像处理中的应用综述[J]. 哈尔滨工程大学学报, 2018, 39(6): 973-983.]

[55] MOUNTRAKIS G, IM J, OGOLE C. Support vector machines in remote sensing: A review[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2011, 66(3): 247-259. DOI: 10.1016/j.isprsjprs.2010.11.001

[56] DEVAL K, JOSHI P K. Vegetation type and land cover mapping in a semi-arid heterogeneous forested wetland of India: Comparing image classification algorithms[J]. Environment, Development and Sustainability, 2022, 24(3): 3947-3966. DOI: 10.1007/s10668-021-01596-6

[57] ZHAO W Z, DU S H. Spectral - spatial feature extraction for hyperspectral image classification: A dimension reduction and deep learning approach[J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(8): 4544-4554. DOI: 10.1109/TGRS.2016.2543748

[58] SUN Xian, FU Kun, WANG Hongqi. Spatial semantic objects-based hybrid learning method for automatic complicated scene classification[J]. Journal of Electronics & Information Technology, 2011, 33(2): 347-354.[孙显, 付琨, 王宏琦. 基于空间语义对象混合学习的复杂图像场景自动分类方法研究[J]. 电子与信息学报, 2011, 33(2): 347-354.]

[59] ZHAO W Z, DU S H. Learning multiscale and deep representations for classifying remotely sensed imagery[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2016, 113: 155-165. DOI: 10.1016/j.isprsjprs.2016.01.004

[60] FARABET C, COUPRIE C, NAJMAN L, *et al*. Learning hierarchical features for scene labeling[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(8): 1915-1929. DOI: 10.1109/TPAMI.2012.231

[61] HE K M, ZHANG X Y, REN S Q, *et al*. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2016: 770-778. DOI: 10.1109/CVPR. 2016.90

[62] MARTINS V S, KALEITA A L, GELDER B K, *et al*. Deep neural network for complex open-water wetland mapping using high-resolution WorldView-3 and Airborne LiDAR data[J]. International Journal of Applied Earth Observation and Geoinformation, 2020, 93: 102215. DOI: 10.1016/j.jag.2020.102215

[63] ZHU X X, TUIA D, MOU L C, *et al*. Deep learning in remote sensing: A comprehensive review and list of resources [J]. IEEE Geoscience and Remote Sensing Magazine, 2017, 5(4): 8-36. DOI: 10.1109/MGRS.2017.2762307

[64] CHENG G, XIE X X, HAN J W, *et al*. Remote sensing image scene classification meets deep learning: Challenges, methods, benchmarks, and opportunities[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2020, 13: 3735-3756.

[65] MAHDIANPARI M, SALEHI B, REZAEE M, *et al*. Very deep convolutional neural networks for complex land cover mapping using multispectral remote sensing imagery[J]. Remote Sensing, 2018, 10(7): 1119. DOI: 10.3390/rs10071119

[66] JAMALI A, MAHDIANPARI M, BRISCO B, *et al*. Comparing solo versus ensemble convolutional neural networks for wetland classification using multi-spectral satellite imagery [J]. Remote Sensing, 2021, 13(11): 2046. DOI: 10.3390/rs13112046

[67] CHEN M M, KE Y H, BAI J H, *et al*. Monitoring early stage invasion of exotic Spartina alterniflora using deep-learning super-resolution techniques based on multisource high-resolution satellite imagery: A case study in the Yellow River Delta, China[J]. International Journal of Applied Earth Observation and Geoinformation, 2020, 92: 102180. DOI: 10.1016/j.jag.2020.102180

[68] LI C, CUI H W, TIAN X L. A novel CA-RegNet model for Macau wetlands auto segmentation based on GF-2 remote sensing images[J]. Applied Sciences, 2023, 13(22): 12178. DOI: 10.3390/app132212178

[69] CAO Yangjie, JIA Lili, CHEN Yongxia, *et al*. Review of computer vision based on generative adversarial networks[J]. Journal of Image and Graphics, 2018, 23(10): 1433-1449.[曹仰杰, 贾丽丽, 陈永霞, 等. 生成式对抗网络及其计算机视觉应用研究综述[J]. 中国图象图形学报, 2018, 23(10): 1433-1449.]

[70] SONG T A, CHOWDHURY S R, YANG F, *et al*. PET image super-resolution using generative adversarial networks[J]. Neural Networks, 2020, 125: 83-91. DOI: 10.1016/j. neunet.2020.01.029

[71] YE Chen, GUAN Wei. A review of application of generative

adversarial networks[J]. Journal of Tongji University(Natural Science Edition), 2020,48(4):591-601.[叶晨,关玮.生成式对抗网络的应用综述[J].同济大学学报(自然科学版),2020,48(4):591-601.]

[72] HAN W, FENG R Y, WANG L Z, *et al*. A semi-supervised generative framework with deep learning features for high-resolution remote sensing image scene classification[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2018, 145: 23-43. DOI: 10.1016/j.isprsjprs.2017.11.004

[73] SUH S, LEE H, LUKOWICZ P, *et al*. CEGAN: Classification enhancement generative adversarial networks for unraveling data imbalance problems[J]. Neural Networks, 2021, 133: 69-86. DOI: 10.1016/j.neunet.2020.10.004

[74] ZHANG H Y, SONG Y Y, HAN C, *et al*. Remote sensing image spatiotemporal fusion using a generative adversarial network[J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 59(5): 4273-4286. DOI: 10.1109/TGRS. 2020. 3010530

A Review of Wetland Classification with High-resolution Remote Sensing Image based on Deep Learning

YANG Jing[1,2], ZHAO Hui[1], LUO Yaohua[2,3], WANG Jundi[1,2]

(1.*Institute of Mountain Hazards and Environment*, *Chinese Academy of Sciences*, *Chengdu* 610299, *China*;
2.*College of Computer Science and Cyber Security*(*Oxford Brookes College*), *Chengdu University of Technology*, *Chengdu* 610059, *China*;
3.*Key Lab of Earth Exploration & Infomation Techniques of Ministry Education*, *Chengdu University of Technology*, *Chengdu* 610059, *China*)

Abstract: The classification of wetlands with high-resolution images is one of the research hotspots of remote sensing classification. Aiming at the complex mottling of high-resolution image wetlands and wetland hydrological boundaries fluctuate seasonally, the traditional classification of high-resolution image wetlands adopts the manual extraction feature interpretation method, which is time-consuming, laborious and has low accuracy. Therefore, how to achieve automatic and efficient interpretation of wetlands is an urgent problem to be solved. In recent years, with the rapid development of artificial intelligence technology, the use of deep learning to achieve high-resolution image wetland classification has become a new research direction. In order to promote the development of high-resolution image wetland classification technology, the latest research results of deep learning models commonly used in high-resolution image wetland classification, including deep neural networks, convolutional neural networks, and generative adversarial networks, are summarized, and the application and innovation of various deep learning models in high-resolution image wetland classification were analyzed and discussed, such as the application of ensemble learning and the construction of semi-supervised models. Finally, from the aspects of samples and models, the problems of deep learning in the classification of wetlands with high-resolution images and the possible research trends in the future are prospected.

Key words: High resolution image; Wetland classification; Deep learning; Sample-Model