

doi:10.6041/j.issn.1000-1298.2022.03.001

土地利用/覆被深度学习遥感分类研究综述

冯权泷^{1,2} 牛博文¹ 朱德海^{1,2} 陈泊安¹ 张超^{1,2} 杨建宇^{1,2}

(1. 中国农业大学土地科学与技术学院, 北京 100193; 2. 自然资源部农用地质量与监控重点实验室, 北京 100193)

摘要: 基于遥感分类实现高精度的土地利用和土地覆被制图是研究热点问题。近年来, 以卷积神经网络为代表的深度学习在计算机视觉领域取得了长足发展, 同时也被引入到土地利用/覆被遥感制图领域。相比于经典机器学习, 深度学习的优势表现为能够自适应提取与分类任务最相关的特征, 其缺陷表现为分类精度的提高依赖于海量标签样本。基于深度学习在土地利用/覆被分类中日益增多的研究成果, 本文从样本、模型、算法3个角度对其研究进展进行综述。在样本方面, 归纳总结了常用的土地利用/覆被样本集, 并分析了上述样本集的学术影响力; 在模型方面, 综述了土地利用/覆被分类中常用的深度学习模型, 包括卷积神经网络、循环神经网络、全卷积神经网络等的最新研究成果; 在算法方面, 综述了样本稀疏条件下的土地利用/覆被分类算法的最新研究进展, 具体包括主动学习、半监督学习、弱监督学习、自监督学习、迁移学习等。最后从样本、模型、算法3个角度对未来研究方向进行展望, 通过构建大规模遥感样本数据集、持续优化深度学习模型结构、提升样本稀疏条件下深度学习模型的时空泛化能力等研究, 可以进一步改善土地利用/覆被分类效果和精度。

关键词: 深度学习; 土地利用; 土地覆被; 遥感分类; 样本-模型-算法

中图分类号: TP79 文献标识码: A 文章编号: 1000-1298(2022)03-0001-17

OSID:



Review for Deep Learning in Land Use and Land Cover Remote Sensing Classification

FENG Quanlong^{1,2} NIU Bowen¹ ZHU Dehai^{1,2} CHEN Boan¹ ZHANG Chao^{1,2} YANG Jianyu^{1,2}

(1. College of Land Science and Technology, China Agricultural University, Beijing 100193, China)

2. Key Laboratory for Agricultural Land Quality Monitoring and Control, Ministry of Natural Resources, Beijing 100193, China)

Abstract: Accurate land use and land cover (LULC) mapping based on remote sensing image classification has been a hot topic nowadays. Recently, deep learning, especially convolutional neural network, has achieved promising results in computer vision tasks, which has also been introduced into the field of LULC mapping. Compared with classic machine learning methods, deep learning is capable of extracting the most representative features from remote sensing images, however, its performance is depended on massive labeled data. Considering deep learning has been widely used in LULC classification, the objective was to provide a comprehensive review of deep learning from the following perspectives as sample dataset, model structure and training strategy. Specifically, from the perspective of samples, the most commonly used LULC sample dataset was summarized and their academic influence was analyzed. From the perspective of models, the latest research of deep learning models were reviewed, including convolutional neural network, recurrent neural network, fully convolutional network. From the perspective of training strategies, various training methods that could tackle the data-hunger issue of deep learning were summarized, including active learning, semi-supervised learning, weakly-supervised learning, self-supervised learning, transfer learning. Finally, an outlook of deep learning in LULC mapping was provided, which was still from three perspectives of sample dataset, model structure and training strategy. Through the construction of large-scale LULC sample dataset, improvement of deep learning model structure and the increase of spatial-temporal generalization capability under limited samples, LULC remote sensing classification could yield a better performance and accuracy in future study.

Key words: deep learning; land use; land cover; remote sensing classification; sample - model - strategy

收稿日期: 2022-01-26 修回日期: 2022-02-14

基金项目: 国家重点研发计划项目(2021YFE0102300)和国家自然科学基金项目(42001367)

作者简介: 冯权泷(1988—),男,副教授,博士生导师,主要从事机器、深度学习及在农业遥感中的应用研究,E-mail: fengql@cau.edu.cn

通信作者: 朱德海(1962—),男,教授,博士生导师,主要从事3S技术在农业和国土资源管理中的应用研究,E-mail: zhudehai@cau.edu.cn

0 引言

土地利用/覆被 (Land use and land cover, LULC)专题图,是表达自然土地类型以及人类开发利用土地状况的专题要素地图,在资源调查、环境监测、生态保护、城市规划、农业生产等领域具有十分重要的作用。由于遥感具有大范围同步观测等优势,已经成为土地利用/覆被制图的主要数据来源,如何基于遥感影像实现土地利用/覆被的自动分类成为研究热点问题^[1-8]。

在深度学习技术^[9]兴起以前,土地利用/覆被遥感分类多依赖于人工设计特征与机器学习分类器^[10-11]。其中人工设计特征包括归一化植被指数等光谱指数、纹理特征、缨帽变换特征等^[12-13],而机器学习分类器多以决策树、随机森林和支持向量机为主^[14-17]。人工设计特征对专家知识的要求很高,同时其鲁棒性和泛化能力存在一定缺陷,导致更换研究区和数据后,已有的遥感分类模型往往不能取得较好的分类结果。

相比于经典机器学习算法,深度学习不需要人工设计特征的环节,而是能够根据损失函数自动提取与目标任务最相关的特征,具有鲁棒性强、模型易于迁移等优势,成为了遥感领域的一个研究热点,并已经应用在城市土地利用分类、滨海湿地土地覆被分类、作物精细分类、道路及建筑等专题要素制图等领域^[18-22]。鉴于深度学习的相关研究成果日益增多,本文拟从样本数据集、模型结构、算法策略方面对深度学习在土地利用/覆被遥感分类中的研究进展进行综述,为相关研究人员提供参考。

首先介绍人工智能与深度学习的相关知识,包括卷积神经网络、循环神经网络等常用网络模型;然后从样本角度出发,对现有的土地利用/覆被遥感分类样本集进行综述;其次从深度学习模型的角度出发,综述土地利用/覆被遥感分类中用到的各种深度神经网络模型;再次从模型泛化能力的角度出发,对稀疏样本下深度学习模型的学习策略进行综述;最后对未来研究方向进行展望。深度学习样本-模型-算法总体框架如图1所示。

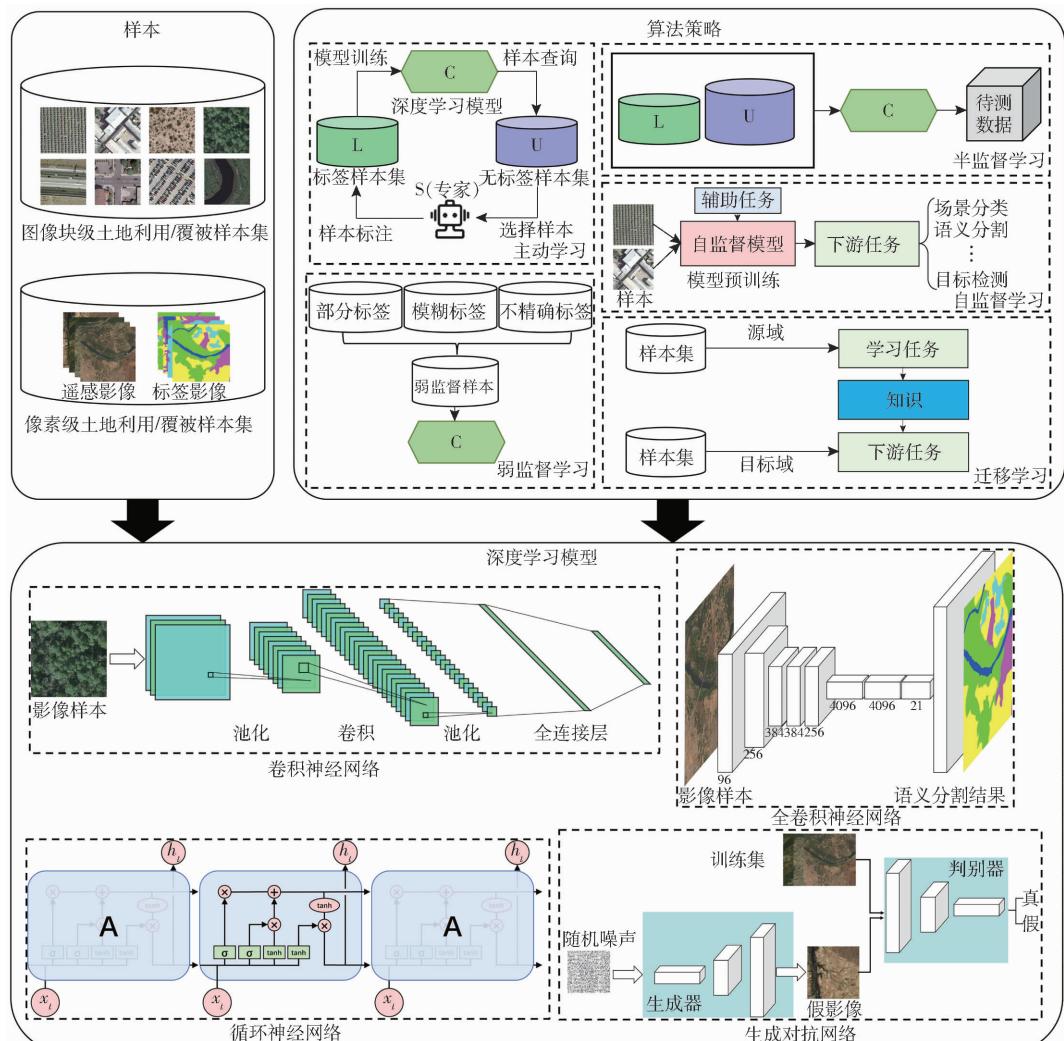


图1 深度学习样本-模型-算法框架图

Fig. 1 Flow chart of sample - model - strategy for deep learning

1 人工智能与深度学习技术概述

1.1 人工智能

人工智能是研究用于模拟、延伸和扩展人的智能的理论、方法、技术及应用系统的一门技术科学^[23]。随着大数据技术以及高性能计算的发展和成熟,以深度学习为代表的人工智能已经在语音识别、目标检测、机器翻译等领域取得了超过传统算法的性能,并逐渐受到遥感与地学领域专家的关注和重视。具体而言,人工智能包括许多研究分支,其中机器学习是实现人工智能的一种重要方法,而深度学习作为机器学习的一个分支,通过构建深度神经网络实现对人类大脑认知过程的模拟^[9]。

1.2 深度学习

深度学习可以看作经典人工神经网络的“深度”版本,通过增加隐含层数量,从而提高特征学习和表达能力。实际上,深度学习是深度神经网络的同义词,常用的深度学习模型包括卷积神经网络、循环神经网络、生成对抗网络,以及用于语义分割的全卷积神经网络等。

1.2.1 卷积神经网络

卷积神经网络(Convolutional neural network, CNN)主要用于计算机视觉(Computer vison, CV)领域^[24-27],通过卷积、池化等操作,对图像的高层语义特征进行提取。

一个典型的卷积神经网络为 VGG^[25], 主要包含卷积层、池化层、全连接层和分类层。其中,卷积层主要利用卷积算子实现特征向量的计算,并通过多层卷积堆叠,实现多层次的图像特征提取;池化层包括均值池化、最大值池化等,主要为了减小特征图的尺寸;全连接层中所有神经元以全连接的形式进行连接;分类层主要采用 softmax 分类器。

以自然图像分类为例,相比于经典的机器学习模型,卷积神经网络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代表性的图像特征,进而提高分类精度。

1.2.2 循环神经网络

循环神经网络(Recurrent neural network, RNN)的输入一般为序列数据(如文本、视频等),其隐含层之间是存在连接的, t 时刻隐含层的输入不仅来自输入层,同时来自 $t-1$ 时刻隐含层的输出。

循环神经网络的输入是一个序列数据 X_t , t 时刻隐含层的输出是 h_t , A 表示循环神经网络当前的状态^[31]。常用的循环神经网络包括长短时记忆网络(Long short term memory, LSTM)^[28]、门控循环单

元(Gated recurrent unit, GRU)^[29]、Transformer^[30]等。由于循环神经网络在处理序列数据方面具有天然的优势^[31],已经被应用在多时相遥感影像分析、高光谱图像分类中,用于建模多时相数据之间以及高光谱不同波段之间的相互依赖关系。

1.2.3 生成对抗网络

生成对抗网络(Generative adversarial network, GAN)^[32]包括:生成器(Generator, G) 和判别器(Discriminator, D)。其中生成器 G 主要用来学习真实图像的分布,从而使生成的图像更加接近于真实图像;而判别器 D 主要对生成的图像进行真假判断。生成对抗网络的训练过程是一个 min - max 的优化问题。

随着网络的迭代训练,生成器 G 与判别器 D 不断进行对抗,并最终达到一种动态平衡:生成器 G 生成的图像十分接近真实情况,判别器 D 无法判断出图像真假,对于给定图像预测为真的概率为 50%。在遥感领域,生成对抗网络主要用于模拟样本的生成和模型的对抗训练。

1.2.4 全卷积神经网络

全卷积神经网络(Fully convolutional network, FCN)是将卷积神经网络 CNN 中的全连接层替换为卷积层所形成的,被用于图像语义分割任务中,并在医学图像分割等领域^[33-36]得到应用。相比于基于中心像素所在图像块的分类方式,全卷积神经网络可以减少冗余计算、提高大范围土地利用/覆被制图的效率,受到了广泛关注^[37-38]。经典的全卷积神经网络包括 FCN^[39]、UNet^[40-42]、DeepLab^[43-46] 等模型。

2 土地利用/覆被遥感分类样本研究进展

从样本角度来综述土地利用/覆被遥感分类中样本数据集的研究进展。随着深度学习的快速发展,卷积神经网络^[47-49]、循环神经网络^[50-51]、全卷积神经网络^[52-53]等模型均被应用到土地利用/覆被遥感分类中。然而如何验证不同模型之间的可比性,从而进一步评价模型优劣,成为关键问题。因此,开源样本数据集的构建具有十分重要的意义。

近年来,各国学者、机构发布了一系列土地利用/覆被遥感分类样本数据集,涵盖了不同尺度、传感器类型、时间/空间/光谱分辨率等,为相关研究提供了基准数据支持。本文将其分为两个类型:图像块级样本和像素级样本。其中图像块级样本多来自于遥感场景识别数据集,用一个 $N \times N$ 大小图像块(image-patch)表示一种土地利用/覆被类型。而像素级样本多来自于遥感语义分割数据集,对不同土

地利用/覆被的边界进行像素级别的标注。

2.1 图像块级土地利用/覆被遥感分类样本集

基于图像块的土地利用/覆被样本集与遥感场景识别数据集类似,其标注过程表现为对一个 $N \times N$ 的图像块赋以特定的土地利用/覆被类别(图 2)。该样本集对应的深度学习模型多为基于 CNN 或 RNN 的图像分类模型,优势是标注过程简单,劣势是并不能获取特定地物的边界信息。

表 1 列举了广泛使用且具有影响力的图像块级样本数据集,并给出了相关元数据。

如表 1 所示,图像块级样本集多以航空影像(如 UC Merced^[54]、SAT-4/SAT-6^[58])和高分辨率的 Google Earth 卫星影像(如 WHU-RS19^[55]、AID^[60]等)为主,空间分辨率多在 0.3~2 m 之间,然而其光谱分辨率较低,多为 RGB 或 RGB-NIR 影



图 2 图像块级土地利用/覆被样本示例^[54]

Fig. 2 LULC sample based on image-patch^[54]

表 1 图像块级土地利用/覆被遥感分类样本集

Tab. 1 Commonly used LULC sample dataset based on image-patch

数据集名称	数据源	样本数量	样本尺寸/ (像素 × 像素)	空间分辨 率/m	波段数	土地利用/ 覆被类别数	发布年份	文献序号
UC Merced	航空影像	2 100	256 × 256	0.3	3	21	2010	[54]
WHU-RS19	Google Earth	1 005	600 × 600	0.5	3	19	2010	[55]
RSSCN7	Google Earth	2 800	400 × 400	0.25~2	3	7	2015	[56]
Brazilian coffee scenes	SPOT-5	50 004	64 × 64	10	3	3	2015	[57]
SAT-4/SAT-6	航空影像	500 000/405 000	28 × 28	1	4	4/6	2015	[58]
SIRI-WHU	Google Earth	2 400	200 × 200	2	3	12	2016	[59]
AID	Google Earth	10 000	600 × 600	2	3	30	2017	[60]
EuroSAT	Sentinel-2	27 000	64 × 64	10/20/60	13	10	2019	[61]

像。考虑到深度学习模型训练对于海量标签样本的需求,数据集整体呈现出样本数量不断增加的趋势,从几千发展到几十万不等。此外,少部分数据集以 Sentinel-2 等多光谱卫星影像作为数据源,其光谱分辨率有所提升,然而其空间分辨率相对较低。

上述样本集在土地利用/覆被类别数量的设定上存在两种分化。一方面,部分数据集只关心少数概要性的地物类别,如 SAT-4 数据集仅包含裸地、森林、草地和其它共 4 类土地覆被类型;另一方面,部分数据集则更关注土地利用/覆被的精细分类,如 UC Merced、WHU-RS19、AID 等包含几十种具有特定语义的土地利用/覆被类别。

2.2 像素级土地利用/覆被遥感分类样本集

基于像素的土地利用/覆被样本集与遥感语义分割数据集类似,其标注过程表现为对某一特定地物涵盖的所有像素进行标注(图 3)。该样本集对应的深度学习模型多为语义分割模型,优势是可以获取地物的准确边界,劣势是标注工作量较大。

由于逐像素的土地利用/覆被制图能够提供更

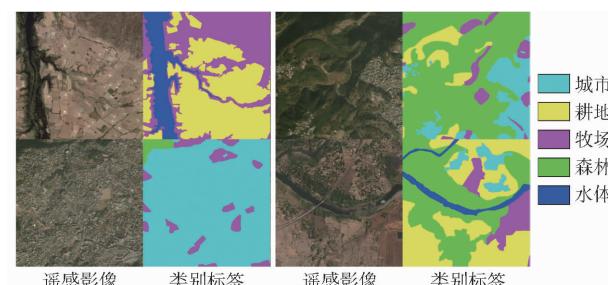


图 3 像素级土地利用/覆被样本集示例^[62]

Fig. 3 LULC sample based on pixel^[62]

为精细的地物分布情况,对气候、生态、水文等多领域的研究有着重要意义^[63],其样本数据集的发布也日益增加。

常用的像素级样本集如表 2 所示。可以看出,大部分样本集拥有更多的波段数,但在样本数量、类别等方面都存在局限性。同时,受到光谱分辨率的制约,这类数据集的空间分辨率较低。同时大部分数据集仅为指定研究区内的单幅影像与标注,只有一些最近发布的数据集(如 DeepGlobe、GID)其样本数量和空间分辨率较高,但仅为一般的 RGB 或 RGB-NIR 影像,光谱分辨率较低。

表2 像素级土地利用/覆被遥感分类样本集

Tab. 2 Commonly used LULC sample dataset based on pixel

数据集名称	数据源	样本数量	影像尺寸/(像素×像素)	空间分辨率/m	波段数量	土地利用/覆被类别数	发布年份	文献序号
Houston	ITRES	1	349×1 905	2.5	144	15/20	2014	[64]
Kennedy Space Center(KSC)	AVIRIS	1	614×512	18	224	13	2014	[65]
Botswana	EO-1	1	348×512	30	242	14	2015	[65]
Indian pines	AVIRIS	1	145×145	20	224	16	2015	[65–66]
Salinas	AVIRIS	1	521×217	3.7	224	16	2015	[65]
University of Pavia	ROSIS	1	610×610	1.3	103	9	2015	[65]
DeepGlobe	Mix	803	2 448×2 448	0.5	3	7	2018	[62]
GID	GF-2	150	6 800×7 200	1/4	4	15	2020	[67]
雄安新区航空高光谱遥感影像分类数据集	航空影像	1	3 750×1 580	0.5	250	19	2020	[68]

像素级样本集一般具有更为精细的土地利用/覆被类别设定,如 GIC 发布的 Indian pines 数据集供包含玉米、小麦等共 16 种土地覆被类别,GID 数据集则包含了工厂、居民区、灌丛等共 15 种土地利用/覆被类别。

总体而言,相比于图像块级样本集,像素级样本集仍缺乏标注质量高的大规模数据集,且现有的大部分数据集仅针对特定区域,普适性有待提升。

2.3 土地利用/覆被遥感分类样本集影响力分析

以 Google Scholar 中的论文引用次数作为影响力指标,对常用土地利用/覆被遥感分类样本集进行影响力分析(图4)。如图4所示,基于像素尺度的样本集影响力较大,以 GIC 发布的 Indian pines^[65–66] 和 University of Pavia^[65] 数据集为代表,且由该团队发布的 Salinas^[65] 和 KSC^[65] 数据集也具有较高的影响力。在图像块尺度的样本集中,经典数据集 UC Merced^[54] 具有最高影响力,国内学者提出的 AID^[60] 和 RSSCN7^[56] 数据集发布时间相对较晚,但由于其在样本数量、质量、尺寸等方面的优势,其近两年影响力逐渐提升。

同时,图4表明国内外学者更多关注基于多/高光谱影像的逐像素分类。一方面由于更多光谱信息的引入,可以有效提高地物的类间可分性,提升分类精度;另一方面,逐像素分类结果能够对土地利用/覆被情况进行更精细的刻画,也利于后续变化检测等任务。同时,图像块级分类受限于大范围制图时的“棋盘效应”,其在遥感场景分类中更受关注。

3 基于深度学习的土地利用/覆被遥感分类模型研究进展

从模型角度,综述土地利用/覆被遥感分类中常用的深度学习模型,包括卷积神经网络(CNN)、循环神经网络(RNN)、全卷积神经网络(FCN)等。

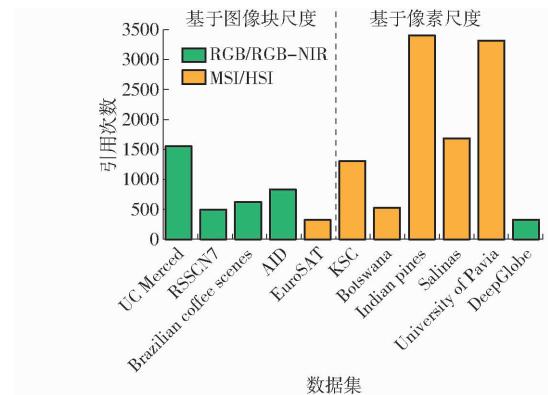


图4 常用土地利用/覆被遥感分类样本集影响力统计结果

Fig. 4 Impact statistics of commonly used LULC sample dataset

3.1 基于卷积神经网络的土地利用/覆被分类

卷积神经网络因其强大的图像特征提取能力,在土地利用/覆被分类中被广泛应用。在前期研究中,研究人员多倾向于直接使用计算机视觉领域内的经典模型(AlexNet、VGG、ResNet 等)或者自行搭建一个简单网络,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(sliding window)方式得到逐像素或逐图像块的预测结果。其中 REZAEI 等^[69]采用在 ImageNet 上预训练的 AlexNet 网络进行了湿地土地覆被制图的研究,并将其与随机森林等经典机器学习模型进行比较,结果表明卷积神经网络可以有效改善湿地土地覆被分类精度。类似的研究如文献[70–76]。

然而上述研究仅仅是借用 CV 经典模型,并没有考虑到遥感多谱段成像的特点。针对这一问题,研究人员转向了双路(或双分支)卷积神经网络的研究,用于同时学习遥感影像的空间特征和光谱特征。在一个典型的双路神经网络中,包含两个分支或子网络,即空间特征提取子网络和光谱特征提取子网络。其中 HUANG 等^[77]设计了一个双路卷积

神经网络模型用于城市土地利用制图,该模型的第一个分支是在 ImageNet 上预训练的 AlexNet 网络,用于提取空间特征,第 2 个分支是由几个卷积层级联形成的小卷积网络(small DCNN),用于提取光谱特征,最后采用特征堆叠的方法进行空间-光谱特征的融合,并基于 WorldView 高分辨率影像实现了香港和深圳的城市土地利用制图,取得了 91.25% 的分类精度。类似的研究如文献[78-80]。

笔者针对城市土地利用遥感分类问题,对双路卷积神经网络进行改进,构建了多尺度残差模块以增强空间特征的代表性和可分性,从而有效提高了

分类精度。同时针对滨海湿地土地覆被分类问题^[81],通过引入多源光学、雷达遥感影像,提出了一个多路卷积神经网络模型(图 5),该模型通过多尺度可变形卷积模块提高其对于地物尺寸和形状变异的鲁棒性,并设计了一个深度特征自适应融合模型,用于融合多传感器、多时相的光学和雷达数据,在黄河三角洲取得了 93.78% 的分类精度,并验证了多传感器数据的融合可以有效增加滨海湿地土地覆被类型之间的可分性。此外,笔者还针对农业塑料覆被^[82]、城中村^[83]等土地利用/覆被中的专题要素进行了提取。

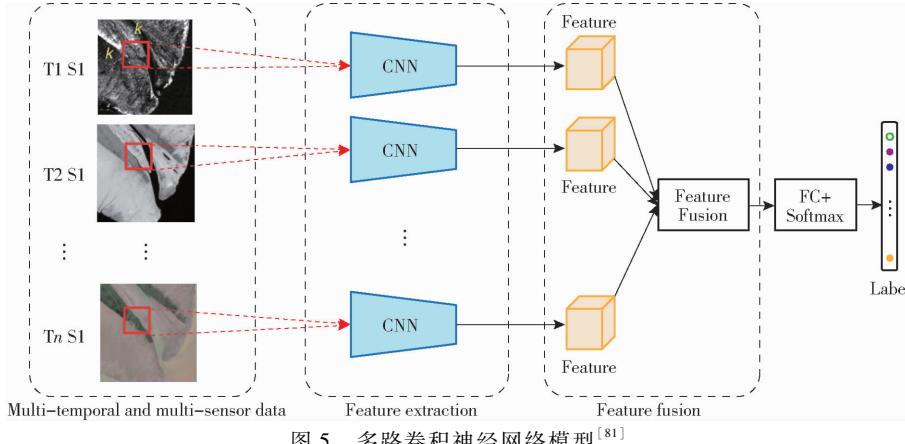


Fig. 5 Multi-path convolutional neural network model^[81]

3.2 基于循环神经网络的土地利用/覆被分类

循环神经网络的优势在于对序列信号进行建模,虽然不能像 CNN 那样对遥感影像的空间特征进行提取,但 RNN 对光谱特征和时序特征的学习能力要强于 CNN,同样被广泛应用于土地利用/覆被的遥感分类研究中^[84-92]。

在光谱特征提取方面,RNN 被用于多光谱和高光谱影像的分类中,用于建模不同波段之间的相互依赖关系。MOU 等^[85]针对高光谱影像的土地利用/覆被分类问题,较早使用 LSTM、GRU 等循环神经网络构建了分类模型。其中模型的输入为单个像素对应的光谱曲线,模型的输出则为对应的土地利用/覆被类别,并在 3 个航空高光谱数据集上验证了 RNN 模型的分类效果。后续研究则集中在如何继续优化 RNN 模型结构,从而提高光谱特征提取能力。文献[86]研究具有典型性,通过构建级联 RNN 模型进行高光谱分类,该模型由 2 个 RNN 级联而成,其中第 1 个 RNN 用于去除高光谱影像中的冗余波段,第 2 个 RNN 则利用剩余波段进行影像分类。通过上述级联的方式,可以进一步提高模型的分类精度。相关研究还包括文献[87]。

在时序特征提取方面,RNN 被用于多时相遥感影像的分类研究中,通过学习多时相影像之间的时

序依赖关系,从而提高不同地物的类间可分性以改善土地利用/覆被分类精度。其中, RUBWURM 等^[88]基于多时相 Sentinel - 2 号影像,分别采用 LSTM 和 GRU 构建了土地覆被分类模型,并在 17 种地物分类中取得了 90% 的精度,验证了 RNN 在时序特征提取中的有效性。类似研究有文献[89-91],均采用 RNN 对耕地中的农作物进行了精细分类。

3.3 基于卷积-循环神经网络的土地利用/覆被分类

考虑到 CNN 的优势在于遥感影像的空间特征提取,而 RNN 的优势在于光谱特征和时序特征提取,因此将 CNN 和 RNN 进行耦合可以实现空间、时序、光谱特征之间的有效融合,并进一步提高土地利用/覆被分类的精度。其中, MEI 等^[93]基于高光谱影像,分别构建了空间注意力卷积神经网络和光谱注意力循环神经网络模型,分别对高光谱的空间特征和光谱特征进行提取,并通过特征融合进一步提高分类精度。MOU 等^[94]构建了一个 CNN-RNN 耦合模型实现了光谱-空间-时序特征的有效提取,其中 CNN 用于提取遥感影像的光谱-空间特征,而 RNN 用于提取多时相影像的时序特征,通过级联 CNN 和 RNN 模型,实现了土地利用/覆被的变化检

测。类似的研究还包括文献[95–98]。

笔者针对小尺度的土地利用/覆被精细分类问题,构建了一种基于循环注意力网络的 CNN-RNN 耦合模型^[99],并应用在多时相无人机可见光影像的分类中(图 6)。具体而言,考虑到无人机影像具有丰富几何结构信息的特点,首先构建多尺度可变形卷积神经网络,对无人机影像进行空间特征提取,以提高模型对于地块形状和尺度变异的鲁棒性;同时构建融合注意力机制的循环神经网络,实现多时相无人机影像空间特征和时序特征的自适应融合;该模型取得了 92.80% 的分类精度,并验证了循环注意力融合模型在学习多时相特征依赖关系方面的有效性。

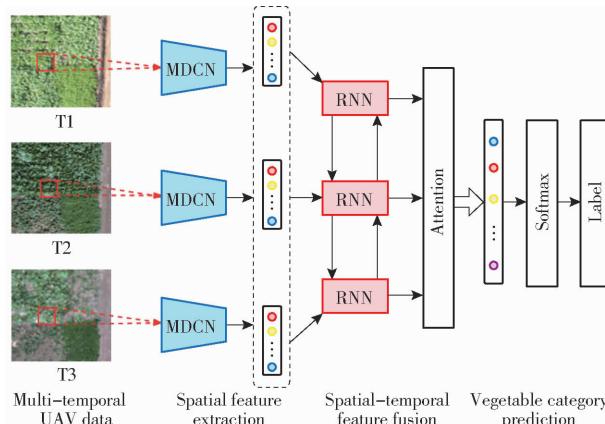


图 6 循环注意力网络模型^[99]

Fig. 6 Attention-based recurrent convolutional neural network^[99]

3.4 基于全卷积神经网络的土地利用/覆被分类

相比于 CNN、RNN 等模型以基于图像块的方式进行土地利用/覆被分类,全卷积神经网络可以实现像素级的地物分类,在大范围土地利用/覆被制图时其计算效率高的优势较为明显。其中 FCN 是计算机视觉领域最早提出的全卷积神经网络模型,被广泛应用于土地利用/覆被分类领域。其中张宏鸣等^[100]利用 FCN-8s 模型对灌区无人机影像进行了渠系提取,杨亚男等^[101]基于 FCN-8s 模型对无人机影像中的梯田进行了提取,都取得了较好分类结果。同时,研究人员在 FCN 的基础上进行了模型改进,如孙钰等^[102]针对无人机影像农业塑料覆被分类任务对 FCN 模型进行了改进,SHRESTHA 等^[103]提出了一种增强的 FCN 模型用于提高建筑物的分类精度。相关研究还包括文献[104–105]。

同时,UNet 以模型结构简洁、鲁棒性高等优势,受到了遥感领域研究人员的关注,其模型也被不断改进,并广泛应用于土地利用/覆被分类中。DIAKOGIANNIS 等^[106]提出了一种 UNet 的改进模型,将残差连接、空洞卷积、金字塔池化以及多任务

学习方法进行组合,同时改进 Dice 损失以解决样本不平衡问题,提高了土地利用/覆被的分类精度。YE 等^[107]将空间-光谱注意力机制应用于 UNet 模型,以提升不同卷积层之间的特征表达一致性,实现了建筑物的高精度提取。类似的研究还包括文献[106–113]。

DeepLab 系列模型也在土地利用/覆被分类中得到了广泛应用。其中 LIN 等^[114]利用通道注意力模块对 DeepLab 模型进行改进,以提升模型对光谱特征的敏感性,并将其应用于道路提取。吴永静等^[115]采用 ResNet-50 作为特征提取网络对 DeepLab 进行改进,并基于高分辨率遥感影像实现了光伏用地的高精度分类。相关研究还包括文献[72,115–119]。

4 样本稀疏条件下土地利用/覆被遥感分类算法研究进展

相比于计算机视觉领域,土地利用/覆被遥感分类中的样本标注对专家知识的要求更高,必要时还需要进行野外考察,从而造成了训练样本的稀疏性。如果仅使用有限的标签样本,将容易造成分类模型的过拟合,降低模型的时空泛化能力,因此如何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,就成为了一个关键技术问题。下面主要阐述样本稀疏条件下的土地利用/覆被遥感分类算法的研究进展,所涉及的算法包括主动学习、半监督学习、弱监督学习、自监督学习、迁移学习等。

4.1 基于主动学习的土地利用/覆被遥感分类

主动学习最早见于机器学习领域,是目前解决标签样本稀疏的常用学习策略之一。其核心思想为:首先使用少量标签样本训练分类模型,再利用该模型从无标签样本集中选择最具代表性或最易错分的样本,由专家对其进行标注,再加入到标签样本集中,并迭代训练模型,从而使模型具有更高的精度和泛化能力^[120–122]。

主动学习的核心问题在于如何选取无标签样本。其选择策略种类较多,主要划分为 3 类:基于无标签样本的不确定性,如委员会查询^[123];基于无标签样本对模型的影响程度,如 Fisher 信息比^[124];基于无标签样本的分布情况,如流形学习^[125]、KL 散度^[126]等。

主动学习备受遥感领域研究人员的关注^[127–135],并被应用到土地利用/覆被遥感分类中。HAUT 等^[131]设计了一种主动学习策略,用于贝叶斯卷积神经网络的训练,通过构建多维贝叶斯卷积神经网络以适应多种高光谱影像,在 Indian Pines、

Salinas 等公开数据集上实现了较好的分类结果。杨承文等^[132]将深度贝叶斯网络与主动学习策略相结合,先基于有限的标签样本对模型进行预训练,再筛选出不确定性高的样本对模型进行进一步训练,从而增强了模型在样本稀疏条件下的泛化性。相关研究还包括文献[130,133–134]。

上述方法均采用预先设计好的策略或准则对无标签样本进行选取,然而这些策略或准则的泛化性仍难以得到保证。为了解决这些问题,部分学者将度量学习与主动学习相结合,通过优化损失函数的设计以提高无标签样本选择的合理性。其中 ZHANG 等^[135]提出了一种结合主动学习的多度量学习方法,通过多个度量指标的分配,以学习并优化损失函数,在 Houston 和 Indian Pines 数据上验证了该方法的有效性。

4.2 基于半监督学习的土地利用/覆被遥感分类

与主动学习类似,半监督学习旨在利用少量标签样本和大量无标签样本对模型进行训练。不同的是,半监督学习更强调训练过程的自动化,而不是主动学习中大量的人工干预^[136–137]。半监督学习主要包括两大类:基于伪标签的方法和基于一致性正则化的方法。前者主要利用为无标签样本赋予伪标签的思想,利用当前模型给予无标签样本最有可能被

预测的类别作为其伪标签,之后将伪标签加入标签数据集对模型进行继续训练^[138];后者主要依赖对干扰不变性的假设,即对同一样本进行数据增强,而增强后的样本之间,其预测标签应当保持一致^[139]。

由于土地利用/覆被分类往往难以获得海量、高质量的标签样本,因此半监督学习受到了广大研究人员的关注。其中,在基于伪标签的半监督学习方面,CENGGORO 等^[140]采用了一种变分半监督学习框架,同时利用标签样本和无标签样本对深度学习模型进行优化,以解决土地利用/覆被分类中的样本不平衡问题。相关研究还包括文献[141]。

笔者在伪标签法方面开展了半监督深度学习的相关研究。针对半干旱区的土地覆被分类问题,提出了一种多门控机制的半监督深度学习框架^[142],通过概率门、不确定性门和抗噪性门的联合使用,以筛选并生成高质量的伪标签样本(图 7),并通过消融实验证实了不同门控机制的有效性。同时,针对城市防尘绿网的遥感分类问题,构建了一种 two-step 的半监督深度学习算法^[143],首先筛选高概率的无标签样本,然后将其与标签样本进行特征相似度计算,若 top-k 的标签样本具有相同的类别,则将该类别赋给当前无标签样本。

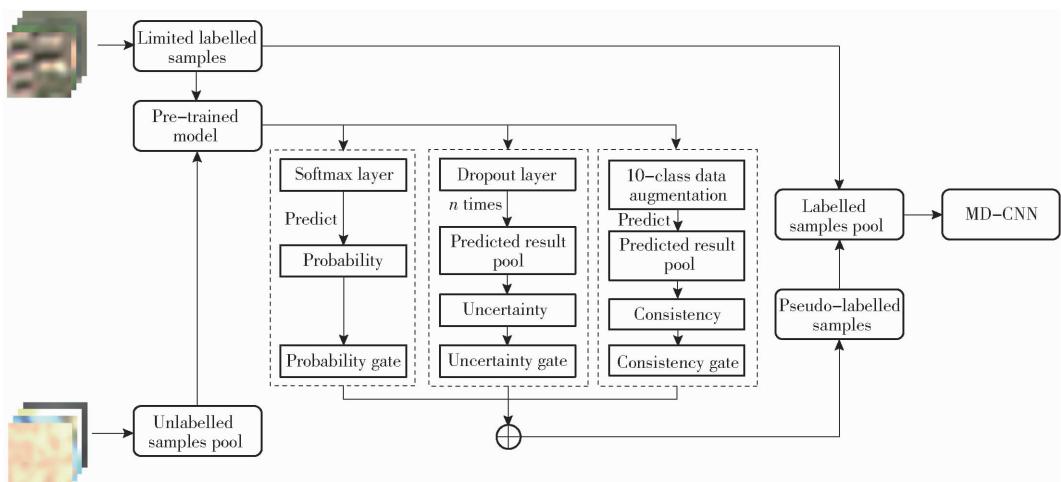


图 7 多门控机制的半监督深度学习框架^[142]

Fig. 7 Multi-gate semi-supervised learning method^[142]

除了上述伪标签样本方法外,一致性正则化方法也得到了研究。其中 ZHANG 等^[144]提出了一种基于半监督学习的语义分割网络(S4Net),在对标签样本进行特征提取的同时,对无标签样本施加随机变换或扰动,并利用组合的损失函数训练模型,在 DeepGlobe 数据集上取得了具有竞争力的结果。文献[145]进行了类似研究。

4.3 基于弱监督学习的土地利用/覆被遥感分类

本文所指的弱监督学习主要针对不确切监督

(Inexact supervision) 问题^[146],即基于粗粒度的上游标签实现细粒度的下游任务。在土地利用/覆被遥感分类中,常见的弱监督学习表述如下:如何在只有图像块级别或低分辨率的土地利用/覆被标注的情况下,去实现像素级别或高分辨率的土地利用/覆被遥感分类任务。

弱监督学习可以一定程度上实现粗粒度标注样本的复用,对于样本稀疏引起的模型过拟合具有一定的缓解作用,在近期受到了遥感研究人员的关

注^[147-151]。其中, SCHMITT 等^[147]探索了如何使用低分辨率的土地覆被样本去生成高分辨率的土地覆被分类图,首先采用 MODIS 的 500 m 分辨率的全球土地覆被数据集作为低分辨率样本集,然后利用 DeepLab v3+ 和 UNet 语义分割模型在高分辨率 Sentinel 影像数据集 SEN12MS 上进行训练,并在 DFC2020 数据集的验证集上进行精度评估。虽然作者指出上述方法的精度并不能令人满意,但是其技术路线可以给人以启发,因为低分辨率的土地利用/覆被样本比较容易获得,相似的研究还包括文献[148]。相比于 SCHMITT 等^[147]直接使用低分辨率的样本对模型进行训练,WANG 等^[149]则利用图像块级的标签样本和类激活图 (Class activation maps, CAMs) 的方法获取像素级的伪标签,并将伪标签加入标签样本集,对 UNet 语义分割模型进行重新训练,证明了上述弱监督方法在土地覆被分类中的有效性。针对跨领域的土地利用/覆被分类问题,LI 等^[150]提出了一个基于弱监督约束的语义分割模型,通过弱监督迁移不变性约束、弱监督伪标签约束以及弱监督旋转一致性约束,改善了模型的分类效果。

4.4 基于自监督学习的土地利用/覆被遥感分类

自监督学习属于无监督学习的一种^[152],可在没有明确人工监督信息的情况下(如标签),从数据本身出发构建学习算法^[153]。主要通过设计辅助任务(如灰度图像上色^[154]、拼图游戏^[155]、图像修复^[156]等)来对模型进行预训练,从而更好完成下游任务(如目标检测、语义分割等)。近年来,随着各种辅助任务的提出,自监督策略的训练效果越来越接近全监督学习,引起了越来越多国内外研究者的关注。

目前将自监督学习应用到土地利用/覆被遥感分类中的研究较少,国内外相关研究均处于起步阶段。其中 AYUSH 等^[157]提出了地理感知自监督对比学习策略,该方法通过时序正样本对在空间上对齐的方式,并结合影像拍摄地点的知识,在 Map of the World 数据集上较 MoCo-v2 模型提升了 8% 的精度。REN 等^[158]提出一种基于相互信息的自监督模型,并首次将自监督学习应用于 PolSAR 土地覆被分类任务中,通过辅助任务的设计,提高了土地覆被制图的性能。文献[159-160]进行了类似研究。

4.5 基于迁移学习的土地利用/覆被遥感分类

迁移学习主要解决不同域(源域和目标域)之间的模型对齐问题^[161]。考虑到遥感影像具有天然的多域性,即在时间、空间、光谱等维度上存在天然差异,因此如何将源域学习到的知识迁移至目标域,

并利用有限的目标域样本提升遥感分类模型的性能,就依赖于迁移学习的深入研究。

迁移学习主要包括基于模型参数的迁移、基于域适应的迁移、基于对抗学习的迁移等。其中基于模型参数的迁移属于早期被广泛应用的方法,深度学习网络的微调法(fine tune)即属于此类方法。其中 WURM 等^[162]利用在 QuickBird 上训练好的模型迁移至具有不同光谱波段的 Sentinel-2 和 TerraSAR-X 中,并对贫民窟这一独特的土地利用类型进行分类,结果表明基于模型参数的迁移对异源传感器(QuickBird 与 SAR)之间的学习效果较差,而对于同源传感器(QuickBird 与 Sentinel-2)之间的分类结果具有提升作用。

在基于域适应的迁移方面,QIN 等^[163]提出了一种基于张量对齐的域适应(Domain adaptation, DA)方法。首先将源域和目标域的遥感影像分割成超像素,然后通过对齐矩阵实现源域和目标域之间的子空间对齐,并通过投影矩阵完成特征重映射,从而提高了目标域内土地利用/覆被分类的精度。文献[164-165]进行了类似研究。

在基于对抗学习的迁移方面,XU 等^[166]采用对抗学习策略提出了一种可转移注意力的对齐方法,以增加细粒度特征,并在语义分割模型中使用域适应方法,以缓解类间不平衡问题。文献[167-168]进行了类似研究。

5 研究展望

5.1 大规模遥感样本数据集构建

深度学习本质上属于数据驱动模型,其在土地利用/覆被遥感分类中的性能很大程度上取决于样本数据的规模、标注质量、地物类别的多样性与完备性等。虽然研究人员相继发布了一些土地利用/覆被分类遥感样本数据集,然而大部分样本仅采样自某一地区和某一时期,这将导致训练出的深度学习分类模型的时空泛化能力较差,如果直接将上述分类模型用于其他地区或时期,分类精度往往难以得到保证。

为了解决土地利用/覆被遥感分类中深度学习模型的时空泛化问题,一个最直接有效的办法是构建大规模遥感样本数据集,并进行公开发布,从而有助于广大研究人员利用其进行深度学习模型构建与训练。实际上,在计算机视觉领域,正是由于 ImageNet 等大规模开源样本数据集的发布,才有效促进了深度学习在自然图像分类、目标检测等领域的的发展和落地应用。

在未来研究中,可以优先考虑以下两种类型的

遥感样本数据集:图像块级样本数据集;像素级样本数据集。其中图像块级样本数据集的构建方法与UC Merced、AID等场景识别数据集类似,用一个遥感图像块来表示某一种特定的土地利用/覆盖类型,样本标注的过程较为简单,标注人员直接对该遥感图像块的类别进行赋值即可。然而这种样本并不能提供精确的地物边界信息,导致大区域制图结果出现明显的边缘锯齿效应;此外一个遥感图像块中往往同时存在多种地物类型,这种场景复杂性也将增加分类难度。相比于图像块级样本数据集,像素级样本数据集可以提供每一种土地利用/覆盖类型的边界信息,然而标注工作量较高,较为费时费力。同时,在构建上述两类样本数据集时,还需要考虑遥感影像的多源性,尽可能覆盖多尺度、多传感器、多时相、多区域的遥感影像,进而提高样本数据集的完备性和可用性。

5.2 深度学习模型结构优化

在当前土地利用/覆盖遥感分类研究中,研究人员或直接采用计算机视觉领域较为成熟的深度学习模型、或在经典模型上进行结构改进,在各自数据集上取得了较好的分类精度。虽然也有相关研究人员针对遥感影像的特点进行模型结构优化,但其适用范围往往需要进一步验证。

在未来的研究中,一方面可以继续借鉴计算机视觉领域的最新研究成果,但更重要的是需要分析遥感影像自身特点,有针对性地对深度学习的网络结构进行改进。相比于计算机视觉领域关注的自然图像,遥感影像具有天然的多源、多传感器、多谱段、多尺度、多时相等特征。在设计分类网络时,多光谱影像、高光谱影像、雷达影像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,厘米级的无人机影像、亚米级的高分辨率卫星影像以及中低分辨率卫星影像,其特征提取网络有何不同,多时相影像、多传感器影像之间如何进行特征融合,从而进一步提高分类的精度和可靠性,同时,相比于自然图像,遥感影像更多揭示的是宏观地学现象,因此在设计深度学习模型结构时,如何考虑增加地学的先验知识,从而提高模型结构的合理性,也是一个需要思考的问题。

此外,还可以研究深度神经网络结构的自动寻优方法,即网络结构也是从样本数据集中学习得到

的。需要注意的是,网络结构的自动寻优需要海量的训练样本,如果样本集的规模较小,其学到的网络结构仅是局部最优解,其时空泛化能力仍存在缺陷。

5.3 稀疏样本下深度学习模型泛化性能提升

通过构建大规模遥感样本数据集,可以一定程度上解决深度学习模型的时空泛化能力问题。然而大规模样本集的构建费时费力,同时在实际的土地利用/覆盖遥感分类中,可用的样本数量总是较少的,因此稀疏样本是遥感领域研究者需要面对的一个重要议题。稀疏样本可以从时间和空间两方面去理解,即已有的样本数据集往往是基于某一特定时间、特定空间的影像进行标注的,那么在这一时空范围以外的遥感影像,如果不进行大规模重新标注,那么其样本必然是稀疏的。此外,对历史影像而言,如果没有对应时间段的野外采样记录,其样本类别只能通过遥感影像目视解译的方法进行判读,其不确定性较高。

为了解决稀疏样本问题,在未来的研究中,可以重点考虑无监督学习、半监督学习和迁移学习等算法。其中无监督学习对标签样本的依赖度最低,其通过海量无标签样本的训练,从而将原始影像数据转换到一个类间可分性高的特征空间。而自监督学习属于无监督学习中的一个热门方向,其相关思想也可以被遥感领域研究人员所借鉴。这是因为遥感影像作为天然的无标签样本库,可为无监督学习提供海量无标签训练样本。同时,半监督学习由于同时考虑了有限的标签样本和海量的无标签样本,也可以缓解因稀疏样本造成的遥感分类模型的过拟合问题。迁移学习则重点考虑不同光谱、空间、时间分辨率遥感影像之间的样本复用问题,可以采用域适应的方法实现遥感分类模型的时空谱迁移,提高模型泛化能力。

综上,随着深度学习技术的不断发展,土地利用/覆盖样本集的种类和数量将持续上升,为模型训练和精度对比提供数据支撑;深度学习模型的结构也将得到进一步优化,并更能适应遥感影像的特点;各种学习策略的不断改进,将会提高模型在样本稀疏条件下的时空泛化能力。上述样本-模型-算法的改进将持续推动深度学习在土地利用/覆盖制图中的广泛应用。

参 考 文 献

- [1] 周珂,杨永清,张娅娜,等.光学遥感影像土地利用分类方法综述[J].科学技术与工程,2021,21(32):13603–13613.
ZHOU Ke, YANG Yongqing, ZHANG Yanna, et al. Review of land use classification methods based on optical remote sensing images[J]. Science Technology and Engineering, 2021, 21(32): 13603 – 13613. (in Chinese)

- [2] 骆剑承, 胡晓东, 吴田军, 等. 高分遥感驱动的精准土地利用与土地覆盖变化信息智能计算模型与方法研究[J]. 遥感学报, 2021, 25(7): 1351–1373.
LUO Jiancheng, HU Xiaodong, WU Tianjun, et al. Research on intelligent calculation model and method of precision land use/cover change information driven by high-resolution remote sensing[J]. Journal of Remote Sensing, 2021, 25(7): 1351–1373. (in Chinese)
- [3] 刘哲, 刘帝佑, 朱德海, 等. 作物遥感精细识别与自动制图研究进展与展望[J]. 农业机械学报, 2018, 49(12): 1–12.
LIU Zhe, LIU Diyou, ZHU Dehai, et al. Review on crop type fine identification and automatic mapping using remote sensing [J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(12): 1–12. (in Chinese)
- [4] 张磊, 吴炳方. 关于土地覆被遥感监测的几点思考[J]. 国土资源遥感, 2011(1): 15–20.
ZHANG Lei, WU Bingfang. A discussion on land cover mapping[J]. Remote Sensing for Land & Resources, 2011(1): 15–20. (in Chinese)
- [5] 陈永慧, 李小娟, 胡德勇. 遥感图像土地覆被专题信息提取方法综述[J]. 首都师范大学学报(自然科学版), 2009, 30(1): 59–64.
CHEN Yonghui, LI Xiaojuan, HU Deyong. Review on the methods for extracting land cover thematic information from remote sensing image[J]. Journal of Capital Normal University(Natural Sciences Edition), 2009, 30(1): 59–64. (in Chinese)
- [6] 赵春江. 农业遥感研究与应用进展[J]. 农业机械学报, 2014, 45(12): 277–293.
ZHAO Chunjiang. Advances of research and application in remote sensing for agriculture [J]. Transactions of the Chinese Society for Agricultural Machinery, 2014, 45(12): 277–293. (in Chinese)
- [7] GONG P, LIU H, ZHANG M, et al. Stable classification with limited sample: transferring a 30-m resolution sample set collected in 2015 to mapping 10-m resolution global land cover in 2017[J]. Science Bulletin, 2019, 64: 370–373.
- [8] SCHMITT M, HUGHES L H, QIU C, et al. SEN12MS—a curated dataset of georeferenced multi-spectral sentinel-1/2 imagery for deep learning and data fusion[J]. arXiv preprint, arXiv:1906.07789, 2019.
- [9] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521: 436–444.
- [10] ADAM E, MUTANGA O, ODINDI J, et al. Land-use/cover classification in a heterogeneous coastal landscape using RapidEye imagery: evaluating the performance of random forest and support vector machines classifiers[J]. International Journal of Remote Sensing, 2014, 35: 3440–3458.
- [11] 朱德海, 刘逸铭, 冯权泷, 等. 基于 GEE 的山东省近 30 年农业大棚时空动态变化研究[J]. 农业机械学报, 2020, 51(1): 168–175.
ZHU Dehai, LIU Yiming, FENG Quanlong, et al. Spatial-temporal dynamic changes of agricultural greenhouses in Shandong Province in recent 30 years based on Google Earth Engine[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(1): 168–175. (in Chinese)
- [12] 黄健熙, 侯裔焯, 武洪峰, 等. 基于时间序列 MODIS 的农作物类型空间制图方法[J]. 农业机械学报, 2017, 48(10): 142–147.
HUANG Jianxi, HOU Yuzhuo, WU Hongfeng, et al. Crop type mapping method based on time-series MODIS data in Heilongjiang Province[J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(10): 142–147. (in Chinese)
- [13] 张荣群, 王盛安, 高万林, 等. 基于时序植被指数的县域作物遥感分类方法研究[J]. 农业机械学报, 2015, 46(增刊): 246–252.
ZHANG Rongqun, WANG Sheng'an, GAO Wanlin, et al. Remote-sensing classification method of county-level agriculture crops using time-series[J]. Transactions of the Chinese Society for Agricultural Machinery, 2015, 46(Supp.): 246–252. (in Chinese)
- [14] FENG Q, LIU J, GONG J. UAV remote sensing for urban vegetation mapping using random forest and texture analysis[J]. Remote Sensing, 2015, 7: 1074–1094.
- [15] FENG Q, LIU J, GONG J. Urban flood mapping based on unmanned aerial vehicle remote sensing and random forest classifier—a case of Yuyao, China[J]. Water, 2015, 7(4): 1437–1455.
- [16] BREIMAN L. Random forests[J]. Machine Learning, 2001, 45(1): 5–32.
- [17] CHAPELLE O, VAPNIK V, BOUSQUET O, et al. Choosing multiple parameters for support vector machines[J]. Machine Learning, 2002, 46(1): 131–159.
- [18] ZHANG L, ZHANG L, DU B. Deep learning for remote sensing data: a technical tutorial on the state of the art[J]. IEEE Geoscience and Remote Sensing Magazine, 2016, 4(2): 22–40.
- [19] ZHU X, TUI A D, MOU L, 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.
- [20] KAMILARIS A, PRENAFETA F X. Deep learning in agriculture: a survey[J]. Computers and Electronics in Agriculture, 2018, 147: 70–90.
- [21] 李德仁, 张良培, 夏桂松. 遥感大数据自动分析与数据挖掘[J]. 测绘学报, 2014, 43(12): 1211–1216.
LI Deren, ZHANG Liangpei, XIA Guisong. Automatic analysis and mining of remote sensing big data[J]. Acta Geodaetica et Cartographica Sinica, 2014, 43(12): 1211–1216. (in Chinese)
- [22] 陈前, 郑利娟, 李小娟, 等. 基于深度学习的高分遥感影像水体提取模型研究[J]. 地理与地理信息科学, 2019, 35(4): 43–49.
CHEN Qian, ZHENG Lijuan, LI Xiaojuan, et al. Water body extraction from high-resolution satellite remote sensing images based on deep learning[J]. Geography and Geo-Information Science, 2019, 35(4): 43–49. (in Chinese)
- [23] 涂序彦. 何谓“人工智能”？概念、对象、内容及方法[J]. 软件世界, 1999(1): 34–36.
TU Xuyan. What is “artificial intelligence”? conception, object, content and method[J]. Software World, 1999(1): 34–

36. (in Chinese)
- [24] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks [J]. Advances in Neural Information Processing Systems, 2012, 25: 1097–1105.
- [25] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [J]. arXiv preprint, arXiv: 1409.1556, 2014.
- [26] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770–778.
- [27] HUANG G, LIU Z, VAN D M L, et al. Densely connected convolutional networks [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 4700–4708.
- [28] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural Computation, 1997, 9(8): 1735–1780.
- [29] CHO K, MERRIENBOER B, BAHdanau D, et al. On the properties of neural machine translation: encoder-decoder approaches [J]. arXiv preprint, arXiv: 1409.1259, 2014.
- [30] VASWANI A, SHAZER N, PARMAR N, et al. Attention is all you need [C] // Advances in Neural Information Processing Systems, 2017: 5998–6008.
- [31] COLA H. Understanding LSTM Networks [EB/OL]. [2022-01-25]. <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>.
- [32] GOODFELLOW I, POUGET J, MIRZA M, et al. Generative adversarial networks [J]. Communications of the ACM, 2020, 63(11): 139–144.
- [33] CHEN J, LU Y, YU Q, et al. Transunet: transformers make strong encoders for medical image segmentation [J]. arXiv preprint, arXiv:2102.04306, 2021.
- [34] CAO H, WANG Y, CHEN J, et al. Swin – Unet: Unet-like pure transformer for medical image segmentation [J]. arXiv preprint, arXiv:2105.05537, 2021.
- [35] 熊俊涛, 刘柏林, 钟灼, 等. 基于深度语义分割网络的荔枝花叶分割与识别 [J]. 农业机械学报, 2021, 52(6): 252–258.
XIONG Juntao, LIU Bolin, ZHONG Zhuo, et al. Litchi flower and leaf segmentation and recognition based on deep semantic segmentation [J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(6): 252–258. (in Chinese)
- [36] 李旭青, 张秦雪, 安志远, 等. 基于可变形全卷积神经网络的冬小麦自动解译研究 [J]. 农业机械学报, 2020, 51(9): 144–151.
LI Xuqing, ZHANG Qinxue, AN Zhiyuan, et al. Automatic interpretation of winter wheat based on deformable full convolution neural network [J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(9): 144–151. (in Chinese)
- [37] 杨蜀秦, 宋志双, 尹瀚平, 等. 基于深度语义分割的无人机多光谱遥感作物分类方法 [J]. 农业机械学报, 2021, 52(3): 185–192.
YANG Shuqin, SONG Zhishuang, YIN Hanping, et al. Crop classification method of UAV multispectral remote sensing based on deep semantic segmentation [J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(3): 185–192. (in Chinese)
- [38] WANG Y, ZENG X, LIAO X, et al. B – FGC – Net: a building extraction network from high resolution remote sensing imagery [J]. Remote Sensing, 2022, 14(2): 144.
- [39] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015: 3431–3440.
- [40] 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, Springer, Cham, 2015: 234–241.
- [41] ZHOU Z, SIDDIQUEE M M R, TAJBAKHSH N, et al. A nested U – Net architecture for medical image segmentation [J]. arXiv preprint, arXiv:1807.10165, 2018.
- [42] QIN X, ZHANG Z, HUANG C, et al. U^2 – Net: going deeper with nested U-structure for salient object detection [J]. Pattern Recognition, 2020, 106: 107404.
- [43] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. Semantic image segmentation with deep convolutional nets and fully connected CRFs [J]. arXiv preprint, arXiv:1412.7062, 2014.
- [44] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. Deeplab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 40(4): 834–848.
- [45] CHEN L C, PAPANDREOU G, SCHROFF F, et al. Rethinking atrous convolution for semantic image segmentation [J]. arXiv preprint, arXiv:1706.05587, 2017.
- [46] CHEN L C, ZHU Y, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation [C] // Proceedings of the European Conference on Computer Vision (ECCV), 2018: 801–818.
- [47] 季顺平, 田思琦, 张驰. 利用全空洞卷积神经元网络进行城市土地覆盖分类与变化检测 [J]. 武汉大学学报(信息科学版), 2020, 45(2): 233–241.
JI Shunping, TIAN Siqi, ZHANG Chi. Urban land cover classification and change detection using fully atrous convolutional neural network [J]. Geomatics and Information Science of Wuhan University, 2020, 45(2): 233–241. (in Chinese)
- [48] 宁纪锋, 倪静, 何宜家, 等. 基于卷积注意力的无人机多光谱遥感影像地膜农田识别 [J]. 农业机械学报, 2021, 52(9): 213–220.
NING Jifeng, NI Jing, HE Yijia, et al. Convolutional attention based plastic mulching farmland identification via UAV multispectral remote sensing image [J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(9): 213–220. (in Chinese)
- [49] 郭交, 李仪邦, 董思意, 等. 融合栈式自编码与 CNN 的高光谱影像作物分类方法 [J]. 农业机械学报, 2021, 52(12):

- 225–232.
- GUO Jiao, LI Yibang, DONG Siyi, et al. Innovative method of crop classification for hyperspectral images combining stacked autoencoder and CNN[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(12): 225–232. (in Chinese)
- [50] WU H, PRASAD S. Convolutional recurrent neural networks for hyperspectral data classification[J]. Remote Sensing, 2017, 9(3): 298.
- [51] 林蕾. 基于循环神经网络模型的遥感影像时间序列分类及变化检测方法研究[D]. 北京:中国科学院大学, 2018.
- LIN Lei. Satellite image time series classification and change detection based on recurrent neural network model[D]. Beijing: University of Chinese Academy of Sciences, 2018. (in Chinese)
- [52] 刘文萍, 赵磊, 周焱, 等. 基于深度学习的无人机土地覆盖图像分割方法[J]. 农业机械学报, 2020, 51(2): 221–229.
- LIU Wenping, ZHAO Lei, ZHOU Yan, et al. Deep learning based unmanned aerial vehicle landcover image segmentation method[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(2): 221–229. (in Chinese)
- [53] MAGGIORI E, TARABALKA Y, CHARPIAT G, et al. Fully convolutional neural networks for remote sensing image classification[C]//2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), 2016: 5071–5074.
- [54] YANG Y, NEWSAM S. Bag-of-visual-words and spatial extensions for land-use classification[C]//Proceedings of the 18th SIGSPATIAL International Conference on Advances in Geographic Information Systems. New York, 2010: 270–279.
- [55] DAI D, YANG W. Satellite image classification via two-layer sparse coding with biased image representation[J]. IEEE Geoscience and Remote Sensing Letters, 2011, 8(1): 173–176.
- [56] ZOU Q, NI L, ZHANG T, et al. Deep learning based feature selection for remote sensing scene classification[J]. IEEE Geoscience and Remote Sensing Letters, 2015, 12(11): 2321–2325.
- [57] PENATTI O A B, NOGOGUEIRA K, DOS S J A. Do deep features generalize from everyday objects to remote sensing and aerial scenes domains? [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops, 2015: 44–51.
- [58] BASU S, GANGULY S, MUKHOPADHYAY S, et al. Deepsat: a learning framework for satellite imagery[C]//Proceedings of the 23rd Sigspatial International Conference on Advances in Geographic Information Systems, 2015: 1–10.
- [59] ZHAO B, ZHONG Y, XIA G S, et al. Dirichlet-derived multiple topic scene classification model for high spatial resolution remote sensing imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2015, 54(4): 2108–2123.
- [60] XIA G S, HU J, HU F, et al. AID: a benchmark data set for performance evaluation of aerial scene classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(7): 3965–3981.
- [61] HELBER P, BISCHKE B, DENGEL A, et al. Eurosat: a novel dataset and deep learning benchmark for land use and land cover classification[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2019, 12(7): 2217–2226.
- [62] DEMIR I, KOPERSKI K, LINDENBAUM D, et al. Deepglobe 2018: a challenge to parse the earth through satellite images[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops, 2018: 172–181.
- [63] GONG P, WANG J, YU L, et al. Finer resolution observation and monitoring of global land cover: first mapping results with Landsat TM and ETM + data[J]. International Journal of Remote Sensing, 2013, 34(7): 2607–2654.
- [64] DEBES C, MERENTITIES A, HERENMANS R, et al. Hyperspectral and LiDAR data fusion: outcome of the 2013 GRSS data fusion contest[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2014, 7(6): 2405–2418.
- [65] GIC. Hyperspectral remote sensing scenes [EB/OL]. [2022-01-25]. http://www.ehu.eus/ccwintco/index.php/Hyperspectral_Remote_Sensing_Scenes.
- [66] BAUMGARDNER M F, BIEHL L L, LANDGREBE D A. 220 band aviris hyperspectral image data set: June 12, 1992 Indian pine test site 3[EB/OL]. [2022-01-25]. <https://purr.pardue.edu/publications/1947/about?v=1>.
- [67] TONG X Y, XIA G S, LU Q, et al. Land-cover classification with high-resolution remote sensing images using transferable deep models[J]. Remote Sensing of Environment, 2020, 237: 111322.
- [68] 岑奕, 张立福, 张霞, 等. 雄安新区马蹄湾村航空高光谱遥感影像分类数据集[J]. 遥感学报, 2020, 24(11): 1299–1306.
- CEN Yi, ZHANG Lifu, ZHANG Xia, et al. Aerial hyperspectral remote sensing classification dataset of Xiongan New Area (Matiwan Village)[J]. Journal of Remote Sensing, 2020, 24(11): 1299–1306. (in Chinese)
- [69] 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.
- [70] KUSSL N, LAVRENIUK M, SKAKUN S, et al. Deep learning classification of land cover and crop types using remote sensing data[J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(5): 778–782.
- [71] ALSHEHHI R, MARPU P R, WOON W L, et al. Simultaneous extraction of roads and buildings in remote sensing imagery with convolutional neural networks[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2017, 130: 139–149.
- [72] NIU Z, LIU W, ZHAO J, et al. DeepLab-based spatial feature extraction for hyperspectral image classification[J]. IEEE Geoscience and Remote Sensing Letters, 2018, 16(2): 251–255.
- [73] 陈敏, 潘佳威, 李江杰, 等. 结合 VGGNet 与 Mask R-CNN 的高分辨率遥感影像建设用地检测[J]. 遥感技术与应用, 2021, 36(2): 256–264.
- CHEN Min, PAN Jiawei, LI Jiangjie, et al. High resolution remote sensing image construction land detection combined with VGGNet and Mask R-CNN[J]. Remote Sensing Technology and Application, 2021, 36(2): 256–264. (in Chinese)
- [74] 吴海平, 黄世存. 基于深度学习的新增建设用地信息提取试验研究—全国土地利用遥感监测工程创新探索[J]. 国土

- 资源遥感, 2019, 31(4): 159–166.
- WU Haiping, HUANG Shicun. Research on new construction land information extraction based on deep learning: innovation exploration of the national project of land use monitoring via remote sensing[J]. Remote Sensing for Land & Resources, 2019, 31(4): 159–166. (in Chinese)
- [75] 田琳静, 宋文龙, 卢奕竹, 等. 基于深度学习的农业区土地利用无人机监测分类[J]. 中国水利水电科学研究院学报, 2019, 17(4): 312–320.
- TIAN Linjing, SONG Wenlong, LU Yizhu, et al. Rapid monitoring and classification of land use in agricultural areas by UAV based on deep learning method[J]. Journal of China Institute of Water Resources and Hydropower Research, 2019, 17(4): 312–320. (in Chinese)
- [76] 汪传建, 赵庆展, 马永建, 等. 基于卷积神经网络的无人机遥感农作物分类[J]. 农业机械学报, 2019, 50(11): 161–168.
- WANG Chuanjian, ZHAO Qingzhan, MA Yongjian, et al. Crop identification of drone remote sensing based on convolutional neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(11): 161–168. (in Chinese)
- [77] HUANG B, ZHAO B, SONG Y. Urban land-use mapping using a deep convolutional neural network with high spatial resolution multispectral remote sensing imagery[J]. Remote Sensing of Environment, 2018, 214: 73–86.
- [78] XU X, LI W, RAN Q, et al. Multisource remote sensing data classification based on convolutional neural network[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 56(2): 937–949.
- [79] 刘帅, 张旭含, 李笑迎, 等. 基于双分支卷积网络的高光谱与多光谱图像协同土地利用分类[J]. 农业工程学报, 2020, 36(14): 252–262.
- LIU Shuai, ZHANG Xuhan, LI Xiaoying, et al. Cooperative land use classification of hyperspectral and multispectral imagery based on dual branch convolutional neural network[J]. Transactions of the CSAE, 2020, 36(14): 252–262. (in Chinese)
- [80] FENG Q, ZHU D, YANG J, et al. Multisource hyperspectral and LiDAR data fusion for urban land-use mapping based on a modified two-branch convolutional neural network[J]. ISPRS International Journal of Geo-Information, 2019, 8(1): 28.
- [81] FENG Q, YANG J, ZHU D, et al. Integrating multitemporal Sentinel-1/2 data for coastal land cover classification using a multibranch convolutional neural network: a case of the Yellow River Delta[J]. Remote Sensing, 2019, 11(9): 1006.
- [82] 冯权泷, 牛博文, 朱德海, 等. 基于多核主动学习和多源数据融合的农田塑料覆被分类[J]. 农业机械学报, 2022, 53(2): 177–185.
- FENG Quanlong, NIU Bowen, ZHU Dehai, et al. Classification of agricultural plastic cover based on multi-kernel active learning and multi-source data fusion[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(2): 177–185. (in Chinese)
- [83] 冯权泷, 陈泊安, 牛博文, 等. 基于多尺度扩张卷积神经网络的城中村遥感识别[J]. 农业机械学报, 2021, 52(11): 181–189.
- FENG Quanlong, CHEN Boan, NIU Bowen, et al. Identification of urban villages from remote sensing image based on multi-scale dilated convolutional neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(11): 181–189. (in Chinese)
- [84] 张立福, 王帆, 刘华亮, 等. 从光谱到时谱—遥感时间序列变化检测研究进展[J]. 武汉大学学报(信息科学版), 2021, 46(4): 451–468.
- ZHANG Lifu, WANG Sa, LIU Hualiang, et al. From spectrum to spectrotemporal: research on time series change detection of remote sensing[J]. Geomatics and Information Science of Wuhan University, 2021, 46(4): 451–468. (in Chinese)
- [85] MOU L, GHAMISI P, ZHU X X. Deep recurrent neural networks for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(7): 3639–3655.
- [86] HANG R, LIU Q, HONG D, et al. Cascaded recurrent neural networks for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57(8): 5384–5394.
- [87] MA A, FILIPPI A M, WANG Z, et al. Hyperspectral image classification using similarity measurements-based deep recurrent neural networks[J]. Remote Sensing, 2019, 11(2): 194.
- [88] RUBWURM M, KÖRNER M. Multi-temporal land cover classification with sequential recurrent encoders [J]. ISPRS International Journal of Geo-Information, 2018, 7(4): 129.
- [89] NDIKUMANA E, HO T, BAGHDADI N, et al. Deep recurrent neural network for agricultural classification using multitemporal SAR Sentinel-1 for Camargue, France[J]. Remote Sensing, 2018, 10(8): 1217.
- [90] ZHONG L, HU L, ZHOU H. Deep learning based multi-temporal crop classification[J]. Remote Sensing of Environment, 2019, 221: 430–443.
- [91] 解毅, 张永清, 范兰, 等. 基于多源遥感数据融合和LSTM算法的作物分类研究[J]. 农业工程学报, 2019, 35(15): 129–137.
- XIE Yi, ZHANG Yongqing, XUN Lan, et al. Crop classification based on multi-source remote sensing data fusion and LSTM algorithm[J]. Transactions of the CSAE, 2019, 35(15): 129–137. (in Chinese)
- [92] 赵红伟, 陈仲新, 刘佳. 深度学习方法在作物遥感分类中的应用和挑战[J]. 中国农业资源与区划, 2020, 41(2): 35–49.
- ZHAO Hongwei, CHEN Zhongxin, LIU Jia. Deep learning for crop classification of remote sensing data: applications and challenges[J]. Chinese Journal of Agricultural Resources and Regional Planning, 2020, 41(2): 35–49. (in Chinese)
- [93] MEI X, PAN E, MA Y, et al. Spectral-spatial attention networks for hyperspectral image classification[J]. Remote Sensing, 2019, 11(8): 963.
- [94] MOU L, BRUZZONE L, ZHU X X. Learning spectral-spatial-temporal features via a recurrent convolutional neural network for change detection in multispectral imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57: 924–935.
- [95] LIU Q, ZHOU F, HANG R, et al. Bidirectional-convolutional LSTM based spectral-spatial feature learning for hyperspectral

- image classification [J]. *Remote Sensing*, 2017, 9(12): 1330.
- [96] WU H, PRASAD S. Convolutional recurrent neural networks for hyperspectral data classification [J]. *Remote Sensing*, 2017, 9(3): 298.
- [97] 张鹏强, 刘冰, 左溪冰, 等. 利用深度卷积循环神经网络的高光谱影像空谱特征分类方法 [J]. *测绘科学技术学报*, 2021, 38(4): 368–373.
- ZHANG Pengqiang, LIU Bing, ZUO Xibing, et al. Spatial spectral feature classification of hyperspectral images using deep convolution recurrent neural network [J]. *Journal of Geomatics Science and Technology*, 2021, 38(4): 368–373. (in Chinese)
- [98] 马欣悦, 王梨名, 祁昆仑, 等. 基于多尺度循环注意力网络的遥感影像场景分类方法 [J]. *地球科学*, 2021, 46(10): 3740–3752.
- MA Xinyue, WANG Liming, QI Kunlun, et al. Remote sensing image scene classification method based on multi-scale cyclic attention network [J]. *Earth Science*, 2021, 46(10): 3740–3752. (in Chinese)
- [99] FENG Q, YANG J, LIU Y, et al. Multi-temporal unmanned aerial vehicle remote sensing for vegetable mapping using an attention-based recurrent convolutional neural network [J]. *Remote Sensing*, 2020, 12(10): 1668.
- [100] 张宏鸣, 王斌, 韩文霆, 等. 基于全卷积神经网络的灌区无人机正射影像渠系提取 [J]. *农业机械学报*, 2019, 50(6): 241–248.
- ZHANG Hongming, WANG Bin, HAN Wenting, et al. Extraction of irrigation networks in irrigation area of UAV orthophotos based on fully convolutional networks [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2019, 50(6): 241–248. (in Chinese)
- [101] 杨亚男, 张宏鸣, 李杭昊, 等. 结合 FCN 和 DenseCRF 模型的无人机梯田识别方法研究 [J]. *计算机工程与应用*, 2021, 57(3): 222–230.
- YANG Ya'nan, ZHANG Hongming, LI Hanghao, et al. Research on UAV terrace recognition method based on FCN and DenseCRF model [J]. *Computer Engineering and Applications*, 2021, 57(3): 222–230. (in Chinese)
- [102] 孙钰, 韩京治, 陈志泊, 等. 基于深度学习的大棚及地膜农田无人机航拍监测方法 [J]. *农业机械学报*, 2018, 49(2): 133–140.
- SUN Yu, HAN Jingye, CHEN Zhibo, et al. Monitoring method for UAV image of greenhouse and plastic-mulched landcover based on deep learning [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2018, 49(2): 133–140. (in Chinese)
- [103] SHRESTHA S, VANNESCHI L. Improved fully convolutional network with conditional random fields for building extraction [J]. *Remote Sensing*, 2018, 10(7): 1135.
- [104] MARMANIS D, SCHINDLER K, WEGNER J D, et al. Classification with an edge: improving semantic image segmentation with boundary detection [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2018, 135: 158–172.
- [105] MOHAMMADIMANESH F, SALEHI B, MAHDIANPARI M, et al. A new fully convolutional neural network for semantic segmentation of polarimetric SAR imagery in complex land cover ecosystem [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2019, 151: 223–236.
- [106] DIAKOGIANNIS F I, WALDNER F, CACCIETTA P, et al. ResUNet – a: a deep learning framework for semantic segmentation of remotely sensed data [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2020, 162: 94–114.
- [107] YE Z, FU Y, GAN M, et al. Building extraction from very high resolution aerial imagery using joint attention deep neural network [J]. *Remote Sensing*, 2019, 11(24): 2970.
- [108] 何直蒙, 丁海勇, 安炳琪. 高分辨率遥感影像建筑物提取的空洞卷积 E – Unet 算法 [J/OL]. *测绘学报* [2022–01–22]. <https://kns.cnki.net/kcms/detail/11.2089.P.20211215.1136.012.html>. HE Zhimeng, DING Haiyong, AN Bingqi. E – Unet: atrous convolution-based neural network for building extraction from high-resolution remote sensing images [J/OL]. *Acta Geodaetica et Cartographica Sinica* [2022–01–22]. <https://kns.cnki.net/kcms/detail/11.2089.P.20211215.1136.012.html>. (in Chinese)
- [109] CAO K, ZHANG X. An improved res-unet model for tree species classification using airborne high-resolution images [J]. *Remote Sensing*, 2020, 12(7): 1128.
- [110] 李星华, 白学辰, 李正军, 等. 面向高分影像建筑物提取的多层次特征融合网 [J/OL]. *武汉大学学报(信息科学版)* [2022–01–21]. <https://kns.cnki.net/kcms/detail/42.1676.TN.20220114.1321.001.html>. LI Xinghua, BAI Xuechen, LI Zhengjun, et al. High-resolution image building extraction based on multi-level feature fusion network [J/OL]. *Geomatics and Information Science of Wuhan University* [2022–01–21]. <https://kns.cnki.net/kcms/detail/42.1676.TN.20220114.1321.001.html>. (in Chinese)
- [111] ZHANG P, KE Y, ZHANG Z, et al. Urban land use and land cover classification using novel deep learning models based on high spatial resolution satellite imagery [J]. *Sensors*, 2018, 18(11): 3717.
- [112] YAN S, XU L, YU G, et al. Glacier classification from Sentinel – 2 imagery using spatial-spectral attention convolutional model [J]. *International Journal of Applied Earth Observation and Geoinformation*, 2021, 102: 102445.
- [113] ZHENG Z, WAN Y, ZHANG Y, et al. CLNet: cross-layer convolutional neural network for change detection in optical remote sensing imagery [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2021, 175: 247–267.
- [114] LIN Y, XU D, WANG N, et al. Road extraction from very-high-resolution remote sensing images via a nested SE – Deeplab model [J]. *Remote Sensing*, 2020, 12(18): 2985.
- [115] 吴永静, 吴锦超, 林超, 等. 基于深度学习的高分辨率遥感影像光伏用地提取 [J]. *测绘通报*, 2021(5): 96–101.
- WU Yongjing, WU Jinchao, LIN Chao, et al. Photovoltaic land extraction from high-resolution remote sensing images based on deep learning method [J]. *Bulletin of Surveying and Mapping*, 2021(5): 96–101. (in Chinese)
- [116] 侯博文, 国冬梅, 郝伟, 等. 改进卷积网络的高分遥感图像城镇建成区提取 [J]. *中国图象图形学报*, 2020, 25(12):

- 2677 – 2689.
- HOU Bowen, YAN Dongmei, HAO Wei, et al. Urban built-up area extraction using high-resolution remote sensing images with an improved convolutional neural network [J]. Journal of Image and Graphics, 2020, 25(12): 2677 – 2689. (in Chinese)
- [117] WANG Y, GAO L, HONG D, et al. Mask DeepLab: end-to-end image segmentation for change detection in high-resolution remote sensing images[J]. International Journal of Applied Earth Observation and Geoinformation, 2021, 104: 102582.
- [118] FU H, FU B, SHI P. An improved segmentation method for automatic mapping of cone karst from remote sensing data based on DeepLab V3 + model[J]. Remote Sensing, 2021, 13(3): 441.
- [119] SI Y, GONG D, GUO Y, et al. An advanced spectral-spatial classification framework for hyperspectral imagery based on DeepLab v3 + [J]. Applied Sciences, 2021, 11(12): 5703.
- [120] MACKAY D J C. Information-based objective functions for active data selection[J]. Neural Computation, 1992, 4(4): 590 – 604.
- [121] SETTLES B. Active learning literature survey[R]. University of Wisconsin-Madison, Department of Computer Sciences, 2009.
- [122] 刘康, 钱旭, 王自强. 主动学习算法综述[J]. 计算机工程与应用, 2012, 48(34): 1 – 4.
LIU Kang, QIAN Xu, WANG Ziqiang. Survey on active learning algorithms[J]. Computer Engineering and Applications, 2012, 48(34): 1 – 4. (in Chinese)
- [123] SEUNG H S, OPPER M, SOMPOLINSKY H. Query by committee [C] // Proceedings of the Fifth Annual Workshop on Computational Learning Theory, 1992: 287 – 294.
- [124] RAJAN S, GHOSH J, CRAWFORD M M. An active learning approach to hyperspectral data classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2008, 46(4): 1231 – 1242.
- [125] ZHANG L, CHEN C, BU J, et al. Active learning based on locally linear reconstruction[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33(10): 2026 – 2038.
- [126] MCCALLUMZY A K, NIGAMY K. Employing EM and pool-based active learning for text classification [C] // Proc. International Conference on Machine Learning (ICML). Citeseer, 1998: 359 – 367.
- [127] 王成军, 毛政元, 徐伟铭, 等. 超像素与主动学习相结合的遥感影像变化检测方法[J]. 地球信息科学学报, 2018, 20(2): 235 – 245.
WANG Chengjun, MAO Zhengyuan, XU Weiming, et al. Change detection approach for high resolution remotely sensed images based on superpixel and active learning[J]. Journal of Geo-Information Science, 2018, 20(2): 235 – 245. (in Chinese)
- [128] 邓鸿儒, 徐佳, 单文龙, 等. 利用主动深度学习提取极化 SAR 影像建筑区[J]. 测绘科学技术学报, 2018, 35(3): 278 – 284.
DENG Hongru, XU Jia, SHAN Wenlong, et al. Polarized SAR image building area extraction using active deep learning[J]. Journal of Geomatics Science and Technology, 2018, 35(3): 278 – 284. (in Chinese)
- [129] REN S, HE K, GIRSHICK R, et al. Faster R – CNN: towards real-time object detection with region proposal networks[J]. Advances in Neural Information Processing Systems, 2015, 28: 91 – 99.
- [130] LIU P, ZHANG H, EOM K B. Active deep learning for classification of hyperspectral images[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2016, 10(2): 712 – 724.
- [131] HAUT J M, PAOLETTI M E, PLAZA J, et al. Active learning with convolutional neural networks for hyperspectral image classification using a new bayesian approach[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(11): 6440 – 6461.
- [132] 杨承文, 李吉明, 杨东勇. 基于深度贝叶斯主动学习的高光谱图像分类[J]. 计算机工程与应用, 2019, 55(18): 166 – 172.
YANG Chengwen, LI Jiming, YANG Dongyong. Active learning for hyperspectral image classification with deep Bayesian [J]. Computer Engineering and Applications, 2019, 55(18): 166 – 172. (in Chinese)
- [133] 徐佳, 袁春琦, 程圆娥, 等. 基于主动深度学习的极化 SAR 图像分类[J]. 国土资源遥感, 2018, 30(1): 72 – 77.
XU Jia, YUAN Chunqi, CHENG Yuane, et al. Active deep learning based polarimetric SAR image classification [J]. Remote Sensing for Land & Resources, 2018, 30(1): 72 – 77. (in Chinese)
- [134] DENG C, XUE Y, LIU X, et al. Active transfer learning network: a unified deep joint spectral-spatial feature learning model for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 57(3): 1741 – 1754.
- [135] ZHANG Z, PASOLLI E, YANG H L, et al. Multimetric active learning for classification of remote sensing data[J]. IEEE Geoscience and Remote Sensing Letters, 2016, 13(7): 1007 – 1011.
- [136] ZHU X, GOLDBERG A B. Introduction to semi-supervised learning[M]. California: Morgan & Claypool, 2009: 60 – 100.
- [137] CHAPELLE O, SCHOLKOPF B, ZIEN A. Semi-supervised learning[M]. London: The MIT Press, 2006: 16 – 70.
- [138] LEE D H. Pseudo-label: the simple and efficient semi-supervised learning method for deep neural networks[C] // Workshop on Challenges in Representation Learning, ICML, 2013: 896.
- [139] TARVAINEN A, VALPOLA H. Mean teachers are better role models: weight-averaged consistency targets improve semi-supervised deep learning results[J]. arXiv preprint, arXiv: 1703.01780, 2017.
- [140] CENGGORO T W, ISA S M, KUSUMA G P, et al. Classification of imbalanced land-use/land-cover data using variational semi-supervised learning[C] // 2017 International Conference on Innovative and Creative Information Technology (ICITech), IEEE, 2017: 1 – 6.
- [141] WU H, PRASAD S. Semi-supervised deep learning using pseudo labels for hyperspectral image classification[J]. IEEE Transactions on Image Processing, 2017, 27(3): 1259 – 1270.
- [142] CHEN B, FENG Q, NIU B, et al. Mapping of land cover in semi-arid regions based on a multi-gate semi-supervised learning

- method—a case study of Zhangbei, China[J]. *Remote Sensing Letters*, 2022, 13(2): 207–217.
- [143] LIU J, FDENG Q, WANG Y, et al. Urban green plastic cover mapping based on VHR remote sensing images and a deep semi-supervised learning framework[J]. *ISPRS International Journal of Geo-Information*, 2020, 9(9): 527.
- [144] ZHANG B, ZHANG Y, LI Y, et al. Semi-supervised semantic segmentation network via learning consistency for remote sensing land-cover classification[J]. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2020, 2: 609–615.
- [145] CHEN J, YANG M, LING J. Attention-based label consistency for semi-supervised deep learning based image classification [J]. *Neurocomputing*, 2021, 453: 731–741.
- [146] ZHOU Z H. A brief introduction to weakly supervised learning[J]. *National Science Review*, 2018, 5(1): 44–53.
- [147] SCHMITT M, PREXL J, EBEL P, et al. Weakly supervised semantic segmentation of satellite images for land cover mapping—challenges and opportunities[J]. arXiv preprint, arXiv: 2002.08254, 2020.
- [148] YU Q, LIU W, GONCALVES W N, et al. Resolution enhancement for large-scale land cover mapping via weakly supervised deep learning[J]. *Photogrammetric Engineering & Remote Sensing*, 2021, 87(6): 405–412.
- [149] WANG S, CHEN W, XIE S M, et al. Weakly supervised deep learning for segmentation of remote sensing imagery [J]. *Remote Sensing*, 2020, 12(2): 207.
- [150] LI Y, SHI T, ZHANG Y, et al. Learning deep semantic segmentation network under multiple weakly-supervised constraints for cross-domain remote sensing image semantic segmentation[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2021, 175: 20–33.
- [151] ZHANG W, TANG P, CORPETTI T, et al. WTS: a weakly towards strongly supervised learning framework for remote sensing land cover classification using segmentation models[J]. *Remote Sensing*, 2021, 13(3): 394.
- [152] JAISWAL A, BABU A R, ZADEH M Z, et al. A survey on contrastive self-supervised learning[J]. *Technologies*, 2021, 9(1): 2.
- [153] GOYAL P, MAHAJAN D, GUPTA A, et al. Scaling and benchmarking self-supervised visual representation learning[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 6391–6400.
- [154] ZHANG R, ISPLA P, EFROS A A. Colorful image colorization[C]// European Conference on Computer Vision. Springer, Cham, 2016: 649–666.
- [155] NOROOZI M, FAVARO P. Unsupervised learning of visual representations by solving jigsaw puzzles [C]// European Conference on Computer Vision. Springer, Cham, 2016: 69–84.
- [156] HE K, CHEN X, XIE S, et al. Masked autoencoders are scalable vision learners[J]. arXiv preprint, arXiv:2111.06377, 2021.
- [157] AYUSH K, UZKENT B, MENG C, et al. Geography-aware self-supervised learning[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021: 10181–10190.
- [158] REN B, ZHAO Y, HOU B, et al. A mutual information-based self-supervised learning model for PolSAR land cover classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(11): 9224–9237.
- [159] ZHAO Z, LUO Z, LI J, et al. When self-supervised learning meets scene classification: remote sensing scene classification based on a multitask learning framework[J]. *Remote Sensing*, 2020, 12(20): 3276.
- [160] 李海峰, 黄浩哲, 彭剑, 等. 有限标注样本条件下基于自监督特征学习的遥感影像分类方法[C]//第七届高分辨率对地观测学术年会论文集, 2020: 80–93.
- [161] TZENG E, HOFFMAN J, ZHANG N, et al. Deep domain confusion: maximizing for domain invariance[J]. arXiv preprint, arXiv:1412.3474, 2014.
- [162] WURM M, STARK T, ZHU X X, et al. Semantic segmentation of slums in satellite images using transfer learning on fully convolutional neural networks[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2019, 150: 59–69.
- [163] QIN Y, BRUZZONE L, LI B. Tensor alignment based domain adaptation for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(11): 9290–9307.
- [164] ELSHAMLI A, TAYLOR G W, AREIBI S. Multisource domain adaptation for remote sensing using deep neural networks [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 58(5): 3328–3340.
- [165] JI S, WANG D, LUO M. Generative adversarial network-based full-space domain adaptation for land cover classification from multiple-source remote sensing images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 59(5): 3816–3828.
- [166] XU Q, YUAN X, OUYANG C. Class-aware domain adaptation for semantic segmentation of remote sensing images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 60: 1–17.
- [167] FAN Y, DING X, WU J, et al. High spatial-resolution classification of urban surfaces using a deep learning method [J]. *Building and Environment*, 2021, 200: 107949.
- [168] 沈瑜, 苑玉彬, 彭静, 等. 基于深度学习的寒旱区遥感影像河流提取[J]. *农业机械学报*, 2020, 51(7): 192–201.
SHEN Yu, YUAN Yubin, PENG Jing, et al. River extraction from remote sensing images in cold and arid regions based on deep learning[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2020, 51(7): 192–201. (in Chinese)