

基于权重动态变形和双重网络自我验证的 遥感影像分类方法

张庆芳¹, 丛铭^{1*}, 韩玲¹, 席江波¹, 荆青青², 崔建军¹, 杨成生¹, 任超峰¹, 顾俊凯¹, 许妙忠³, 陶翊婷³

¹长安大学地质工程与测绘学院, 陕西 西安 710054;

²中国自然资源航空物探遥感中心, 北京 100083;

³武汉大学测绘遥感信息工程国家重点实验室, 湖北 武汉 430079

摘要 目前主流的神经网络在面对复杂多样的地物目标时难以精确区分,同时样本数量少、弱监督条件也容易为神经网络带来大量噪声与错误。为此,在分析遥感影像的地物特点后,提出一种基于权重动态变形的双重网络遥感影像分类方法,通过构架灵活、简易却有效的权重动态变形结构,构建经过改进的分类网络与目标识别网络,形成双网络对照的自我验证,从而提高学习性能、修复误差、增补遗漏、提高分类精度。实验结果表明,所提方法在容易实施的基础上,表现出更强的地物认知能力和更强的噪声抵抗能力,即其能够适应各种遥感影像的分类任务,具有较为广阔的应用潜力。

关键词 遥感影像分类; 神经网络; 权重动态变形; 双重神经网络; 自我验证

中图分类号 P237

文献标志码 A

DOI: 10.3788/LOP231381

Classification Method of Remote Sensing Image Based on Dynamic Weight Transform and Dual Network Self Verification

Zhang Qingfang¹, Cong Ming^{1*}, Han Ling¹, Xi Jiangbo¹, Jing Qingqing², Cui Jianjun¹,
Yang Chengsheng¹, Ren Chaofeng¹, Gu Junkai¹, Xu Miaozhong³, Tao Yiting³

¹College of Geology Engineering and Geomatics, Chang'an University, Xi'an 710054, Shaanxi, China;

²China Aero Geophysical Survey & Remote Sensing Center for Land and Resources, Beijing 100083, China;

³State Key Laboratory of Information Engineering in Surveying, Mapping and Remote Sensing, Wuhan University, Wuhan 430079, Hubei, China

Abstract Currently, popular neural networks not only struggle to accurately recognize various types of surface targets but also tend to introduce significant noise and errors when handling limited samples and weak supervision. Therefore, this study proposes a dual-network remote sensing image classification method based on dynamic weight deformation, after analyzing the features of remote sensing images. By constructing a flexible, simple, and effective weight dynamic deformation structure, we establish an improved classification network and target recognition network. This introduces the self-verification ability of dual network comparison, thereby enhancing learning performance, error correction, recognition efficiency, supplementing omissions, and improving classification accuracy. Experimental comparisons show that the proposed method is easy to implement and exhibits stronger cognitive ability and noise resistance. It confirms the adaptability of the proposed method to various remote sensing image classification tasks and its vast application potential.

Key words remote sensing image classification; neural network; dynamic weight deformation; dual neural network; self verification

1 引言

遥感影像作为大范围、动态、多通道的地表观测数

据,能够提供真实、详尽的地面信息,是当前科技发展
与工程实践不可或缺的重要数据^[1]。而遥感影像分
类,作为从每个像素中抽象出地物语义的信息挖掘技

收稿日期: 2023-05-26; 修回日期: 2023-07-04; 录用日期: 2023-07-24; 网络首发日期: 2023-08-15

基金项目: 国家级国家重点研发计划子课题(2021YFC3000404-01)、省部级地调项目独立课题(D20201180)、厅局级项目独立课题(SXJK2021-0225)

通信作者: *mingc@chd.edu.cn

术,能够从繁复、多样的地面场景中获取地表场景中的地物信息,从而为道路提取^[2]、农作物分析^[3]、舰船识别^[4]、建筑物认知^[5]、土地覆被解读与土地变化检测^[6-7]等应用提供地面参考,是当前遥感领域中受到广泛关注的研究热点。

当前常用的高分辨率遥感影像分类方法主要由统计学习分类与神经学习分类构成。其中,基于统计学习的分类方法主要有模糊聚类分类^[8]、基于支持向量机的分类^[5]、基于决策树的分类^[9],以及基于集成学习的分类^[10]等。模糊聚类方法通过建立样本间某种相似关系以达到使样本分类的目的;支持向量机基本模型是定义在特征空间上的间隔最大的线性分类器,它的学习策略就是间隔最大化;分类决策树模型实则是一种描述实例分类的树形结构,由节点和有向边组成。这些方法大多在人工构造特征的基础上,根据统计学建立特征与类别间的映射实施分类,在特征选择良好的情况下,能够直观、准确分类,但在面对包含噪声的高维数据时,特征难以选择且运算量巨大^[11]。

此外,基于神经学习的分类方法,主要包括基于卷积神经网络的分类^[11]、基于空洞卷积神经网络的分类^[12]、基于循环神经网络的分类^[13]、基于对抗神经网络的分类^[14]、基于注意力结构神经网络的分类^[15],以及基于神经结构搜索的分类^[16]等。程谿杰等^[17]提出一种基于深度可分离卷积的轻量化残差网络模型,在一定程度上缓解了利用高光谱图像进行特征提取和分类过程中参数量大导致训练时间长的问题。Zhu等^[18]提出一种用于高光谱影像分类的自监督对比高效非对称空洞网络(SC-EADNet),可以有效利用到影像中未被标记的像素。Tang等^[19]提出一种基于递归神经网络(DRRNN)的土地覆被分类深度再学习方法,先在局部窗口中提取类相关特征(CCF),然后应用再学习过程对遥感影像进行迭代分类,直到满足停止条件。Song等^[20]提出一种具有多尺度连接的双分支生成对抗网络(TBGAN)。Ge等^[21]提出一种具有极化全注意力机制的双分支卷积神经网络进行高光谱遥感影像分类,实现了可以分别有效提取频谱和空间特征的双分支卷积神经网络。郑宗生等^[22]针对水生植物提取研究中的绿色水生植物的光谱特征不明显问题,提出一种基于一阶导数法结合 AlexNet 的分类模型。这些方法通过构建神经元网络感知模型,利用过量参数按梯度下降逐步拟合分类函数,实现类别判断,其拟合精度与泛化能力都非常优秀,但严重依赖样本数据,应用难度较大^[23]。

其中,基于注意力结构神经网络的分类方法^[15]通过注意力结构评估不同特征对分类的影响力度,重点突出对分类有明显增益的特征,从而有效提高分类精度。王思泽等^[24]提出一种全局-局部注意力特征重用网络,引入局部注意力结构,聚焦重点空间信息且增强特异性光谱提取能力,并设计全局修正模块,提高网络

可靠性。这种方法在合理设置参数并提供可靠样本的情况下,地物分辨能力较强,但在解析高分辨率遥感影像时,容易陷入以下困境:1)当前注意力结构^[15]与自适应变形结构^[25]过于复杂,难以由非计算机行业人士进行构架与应用;2)在遥感影像少样本、弱监督的现实条件下,现有的注意力结构在增加运算成本的同时未必能够保证分类精度的显著提升;3)采用单一的神经网络,缺乏对分类结果进行自我核查的能力,难以修复误差与增补遗漏,制约了分类精度的提高。

针对现有注意与变形结构的缺陷以及单一网络的局限,本文提出一种基于权重动态变形的双重网络(DWTDN)遥感影像分类方法,通过普通卷积、Softmax 分类器及特征图点乘的方式构架灵活、简易却有效的权重动态变形结构,对神经网络自适应获取的特征图进行智能化权重度量,从而提高网络的学习性能,并在此基础上,构架相互独立的分类网络与目标识别网络,形成双网络布局进行误差修复与遗漏增补,进而更加深入地对分类结果进行优化,提高分类精度。

其中,构架的权重动态变形结构着眼于遥感影像少样本、弱监督的现实条件,通过自适应地度量特征图权重,能够有效帮助网络抑制少样本中的弱监督干扰,提升学习性能。并且其结构简单,容易实现,可轻松应用于已有的网络结构当中。同时,相互独立的分类网络与目标识别网络,能够在分别认知地面场景的基础上,通过相互比对进行自我核查,优化分类结果,切实有效地提高分类精度。

总体而言,本文在设计一种权重动态变形结构的基础上,提出并采用一种双重网络的地面场景分析思路,实现了分类结果的自我核查、误差修复及遗漏增补,能够获取高精度的地物分类结果。并且所提方法容易实现,易于实施,有望被广泛应用于道路提取、建筑物认知、土地覆被解读与土地变化检测等领域中^[26],具有较强的应用价值。

2 权重动态变形网络结构

2.1 权重动态变形的思路

神经网络在进行自适应的特征分析过程中,能够通过梯度下降自适应地获得卷积核参数,从而调整卷积以分析数据中的典型特征。然而,为了更加准确地理解地物,对于提取出的特征,应当探讨不同特征在识别地物中的重要性,并以权重参数的形式刻画不同通道特征的地物识别能力,从而帮助神经网络进一步提升学习能力。

为此,针对多通道的特征图,参考已有的注意力网络结构与变形网络结构^[15,25],以数字权重的方式对特征图的多通道信息进行考评,从而确定每个通道对认知地物的贡献程度。具体来说,假设有一个多通道特征 F , F_i 表示 F 中的第 i 个通道的特征值,那么参考 Softmax,该通道特征的权重 Q_i 为该通道特征的指数

与所有通道特征指数和的比值:

$$Q_i = \frac{\exp(F_i)}{\sum_j \exp(F_j)} \quad (1)$$

采用这种方式对神经网络提取的特征图进行权重划分,可以看到,所有通道的权重和等于 1,即 $\sum_i Q_i =$

1,能够方便神经网络通过后向传播与前向传播对各通道权重进行自动评价,从而突出对地物类别有重要影响的特征,进而提高神经网络的学习性能与分类能力。具体来说,借鉴卷积与非线性激活的拟合能力,在串联一定数量卷积、非线性激活的基础上,使用 Softmax 分类器,构架权重动态变形的基本结构,如图 1 所示:




图 1 权重动态变形的基本结构

Fig. 1 The basic structure of dynamic weight deformation

通过 Softmax 获取多通道权重后,将多通道权重与多通道特征图进行哈达马积点乘^[27],即可通过权重凸显多通道特征中的重要信息,约束多通道特征中的

无用干扰,并且可轻松用于已有神经网络中,改动难度小,应用潜力较大,如图 2 所示:

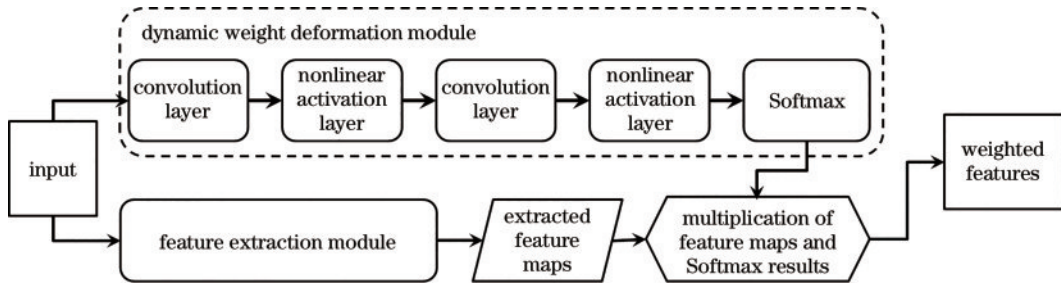


图 2 权重动态变形的点乘应用

Fig. 2 The application of point multiplication of dynamic weight deformation

2.2 基于残差连接的菱形特征提取结构

为了深入挖掘地面复杂场景中各种尺度的隐藏特征,提出一种基于残差连接的深度菱形结构,借助多次

卷积的特征提取能力,结合池化与转置卷积的尺度放大与缩小,配合残差连接压制梯度弥散与梯度爆炸,形成较强的特征挖掘能力。具体结构如图 3 所示:

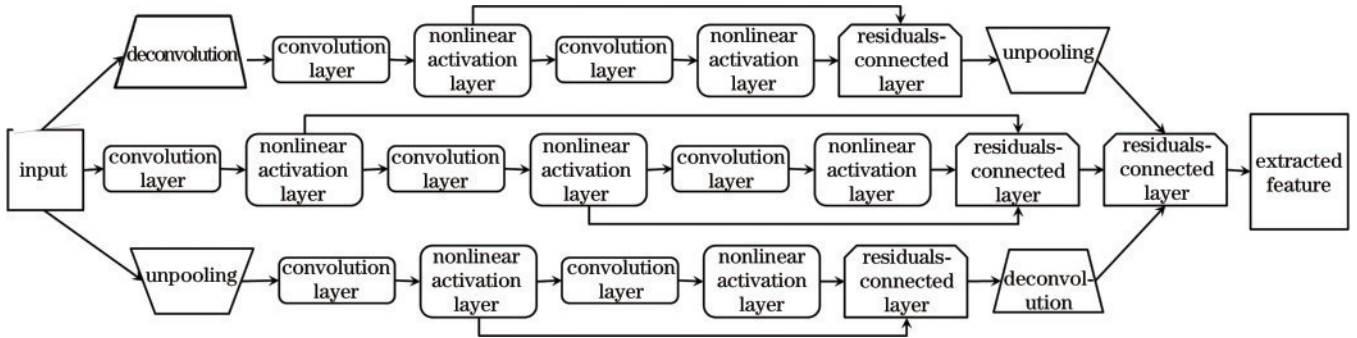


图 3 基于残差连接的菱形特征提取结构

Fig. 3 Diamond feature extraction structure based on residual connection

其中:池化后的多次卷积能够对大尺度特征进行认知与分析;直接进行的多次卷积能够对原始尺度特征进行解读;转置卷积后的多次卷积可以对小尺度特征进行解读与理解,从而尝试全面挖掘各尺度的隐藏特征。

2.3 多菱形权重动态变形的分类网络

在串联多个残差菱形结构全面分析地物特征的基础上,配合权重动态变形结构,能够形成全面深入挖掘

隐藏特征的特征分析结构,配合批处理归一化、卷积及非线性激活,使用 Softmax 分类器,即可构架端到端的逐像素分类网络,其网络结构如图 4 所示。

这种特征分析结构可以根据实际地物的复杂情况,酌情删减或添加菱形结构的数量,以适应地物解读的需要。需要注意的是,虽然权重动态变形结构可以被广泛应用于网络的各个特征分析环节,但由于特征权重描述的是不同通道特征信息对分类的共享程度,

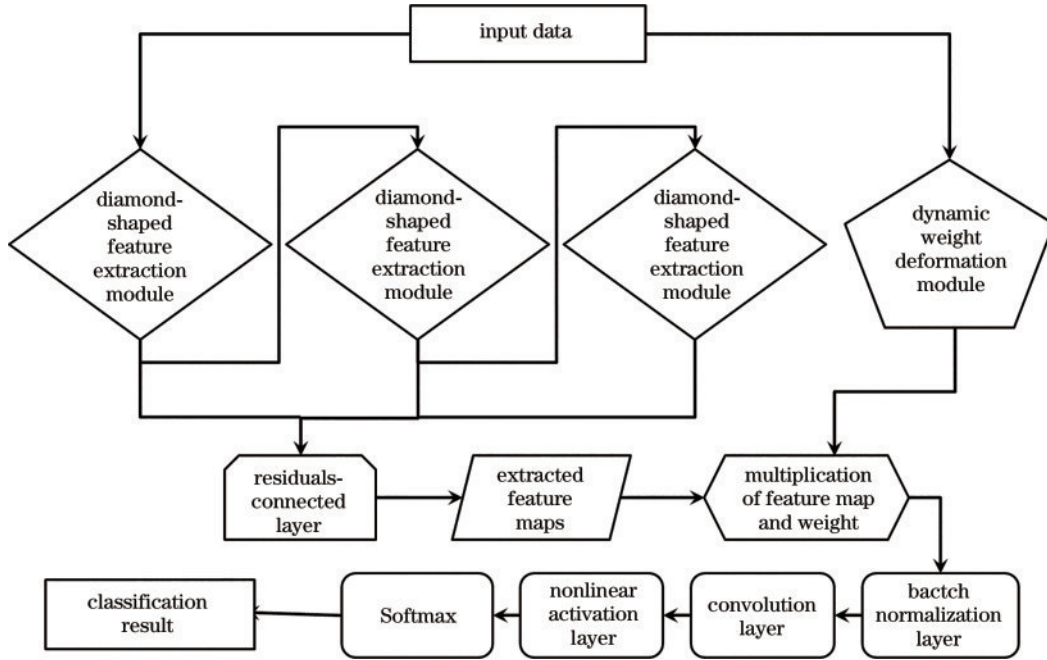


图 4 多菱形权重动态变形的分类网络结构

Fig. 4 Classification network structure with dynamic deformation of multi-diamond weights

因此,特征图的通道数越多,权重动态变形结构带来的学习性能提升也越明显。结合重复实验与测试结果,可在残差汇总特征使特征图达到最大通道数后,使用权重动态变形结构分析特征通道权重,提升网络的认知能力,以期获得更加优秀的分类结果。

2.4 结合权重动态变形的目标识别网络结构

为了进行目标识别,选择当下广泛流行、易于施展并且不断进化的 YOLO 目标识别网络。首先通过卷积、非线性激活、残差连接等神经网络元构架提取特征的主干特征提取部分(backbone 部分),然后采用上下采样^[28]、路径聚合^[29]等方法构建解析特征的关键环节(neck 部分),最后使用卷积、逻辑回归等手段建立能够进行回归框预测的识别框架^[30]。

由于所提权重动态变形结构具备分析特征权重的能力,同时该结构又可以通过相乘的形式与现有特征提取算法结合,因此可根据需要对 YOLO 系列的特征分析主干网络进行修改。具体改进思路如下:在主干网络实施特征挖掘后,通过权重动态变形结构度量特征的重要程度,随后向后续特征分析的关键环节提供带有权重的特征信息,并进行最终的预测识别,网络结构示意图如图 5 所示。

采用这种无需添加繁复结构与各种连接的改进方式,旨在以最小的改进成本换取最大的改进效果,可将权重动态变形用于各种已有神经网络当中,从而形成通用、普适、高效、低成本的特征权重分析思路,帮助现有深度网络进一步提升其学习性能。

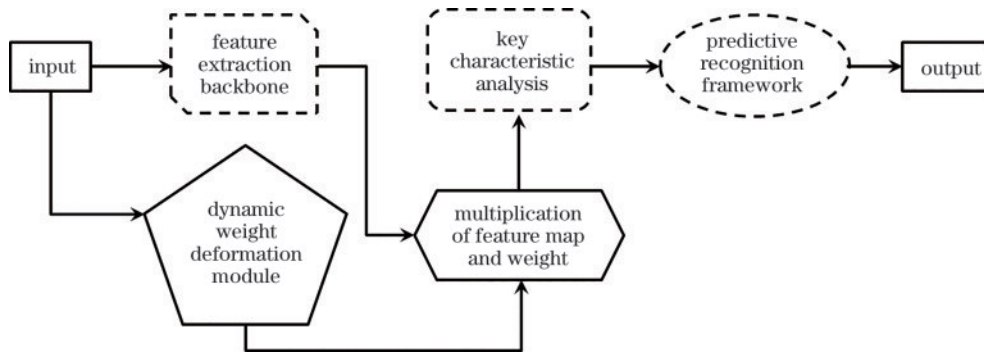


图 5 通过权重动态变形改进的 YOLO 网络示意图

Fig. 5 Schematic diagram of YOLO network improved by weight dynamic deformation

3 基于权重动态变形的双重网络结构

3.1 单一网络缺少自我验证的局限

现有的深度网络已能够对遥感影像进行较好的解

读,然而,单一的分类网络仍欠缺客观、独立的结果验证手段,导致分类结果中的过拟合误差与欠拟合错误难以被准确发现,进而限制了了解译遥感影像中丰富地面信息的能力。

针对这一缺陷,提出一种客观、独立、稳健可信的双网络分类思路,如图 6 所示。采用与分类网络完全独立的目标识别网络,找出各类地物可能存在的位置

与范围,并以此为依据,对分类结果进行第三方客观验证,修复过分类噪声与欠分类错误,提高精度与可信度。

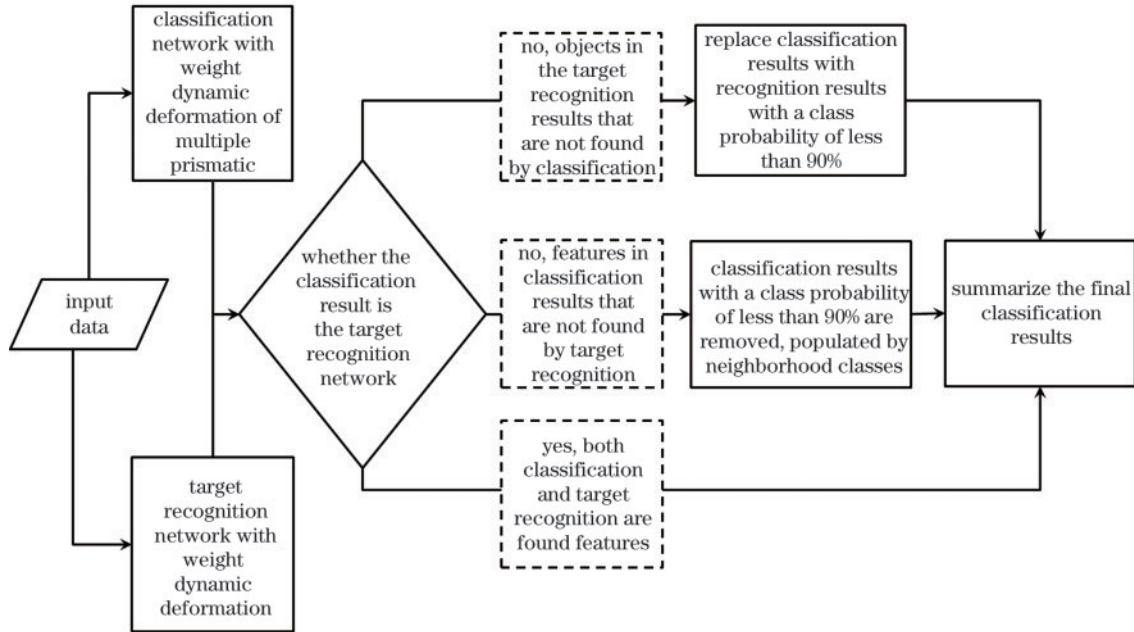


图 6 双重网络的构建布局

Fig. 6 Schematic diagram of the dual model network structure

3.2 基于概率可信的双重网络结果验证

为了充分发挥分类网络与目标识别网络各自的优势,在分类与目标识别完成后,提出一种基于概率可信的双重网络结果验证方法,主要参考分类结果的类别概率,结合目标识别网络的认知结果,对分类结果进行修正,得到更加准确的分类结果。具体来说,针对分类结果与目标识别结果间的差异,按以下两种情况分别进行结果验证:

1) 分类结果中存在目标识别未找到的地物

对于分类已找到但目标识别未找出的地物,参考分类结果中的类别概率:若类别概率大于 90%,认为分类结果稳定,保留该地物;若类别概率小于 90%,则认为分类结果不稳定,将其去除,由周围邻域进行地物类别填充,修正类别概率较小的过拟合误差。

2) 目标识别结果中存在分类未找到的地物

对于目标识别判断出的地物,若分类未找到,则在目标识别判断出的位置,用目标识别判断的地物类别替换分类结果中类别概率小于 90% 的区域,从而修复类别概率较小的欠拟合错误。

最后,汇总各类地物的双重网络认知结果,即可得到经过验证和修复的分类结果,能够更加全面、准确地表征地面场景,具体布局如下:

- 1) 分别构建分类网络和目标识别网络,以实施分类和目标识别任务;
- 2) 修正分类结果与目标识别结果中的差异;
- 3) 结合分类结果与目标识别结果都找到的地物,

得到稳健、可信,准确性较高的最终分类结果。

4 实验与讨论

4.1 实验设计

4.1.1 实验数据

在数据使用方面,采用少样本、弱监督的典型遥感卫星影像数据,主要以中国资源 3 号卫星、Rapid-eye 卫星、SPOT5 卫星影像数据为主,其空间分辨率为 5~10 m。共计准备 40 张 500×500 大小的影像,并且为了验证分类网络在少样本、弱监督条件下的分类性能,计划以 10 张影像为样本,对其余 30 张影像进行分类测试。

4.1.2 实验方法

为了验证所提多菱形权重动态变形的双重网络的有效性,设置了去除目标识别网络仅采用多菱形权重动态变形的分类网络(DWTCN)。同时,选用全卷积神经网络(FCN)、具有注意力结构的 Attention-Unet 和广受好评的 MASK-RCNN 进行对比分析。

FCN 是深度学习在语义分割领域的开创性工作之一,它将全连接层替换成卷积层,使得网络可以得到相同大小的分割结果,实现了像素级别的预测。Attention-Unet 在经典多尺度 Unet 的基础上,加入注意力判断筛选机制,以期在分析特征过程中自适应地提取、挖掘和利用对分类贡献强的特征,从而获得较好的分类结果^[31]。此外, MASK-RCNN 则在经典 FASTER-RCNN 目标识别网络^[25]中加入基于 MASK

的注意力机制,从而在网络分析目标时,能够在确定目标位置的基础上,通过MASK注意力机制找出目标的轮廓与边界,最终完成高精度细粒度的分类,受到广泛好评^[32]。

每种网络的层数大致都在 120,且每种网络的未知数个数约为 50 万,从而保持近似的层数与未知数个数,以进行客观、公正的对比。

4.1.3 精度评定

在分类结果评价方面,需要手动标记获取地物分布的地面真值(GT),根据地物的分布,主要标记 7 类地物,分别为别墅、大棚、普通建筑物、植被、水体、道路以及裸地。参考地面真值,可以从主观定性观察与客观定量评估两个方面对分类结果的表现进行综合、全面的评价。

具体来说,主观定性观察将从感官上评价分类结

果与地面真值间的相似程度、噪声的分布状况以及误分类的主要表现。而客观定量评估参考地面真值,主要以总体分类精度(OA)计算分类结果的定量分类精度^[33],并以 Kappa 系数定量描述分类结果与地面真值的相似程度^[33],完成分类结果的科学评价。通过分类后得到的混淆矩阵可以计算 OA 和 Kappa 系数,总体的混淆矩阵是从影像全要素分类的结果中获取的,单个目标类别的混淆矩阵则是将全要素分类结果转化为二分类结果(目标类别与非目标类别)后获取的。

4.2 实验结果

4.2.1 实验结果 1

实验 1 的影像中主要包含别墅、普通建筑、植被、道路、水体与裸地,主要比较分类结果中“别墅”的精度。其原始影像与分类结果在图 7 中展示。根据地面真值,分类结果的客观精度如表 1 所示。

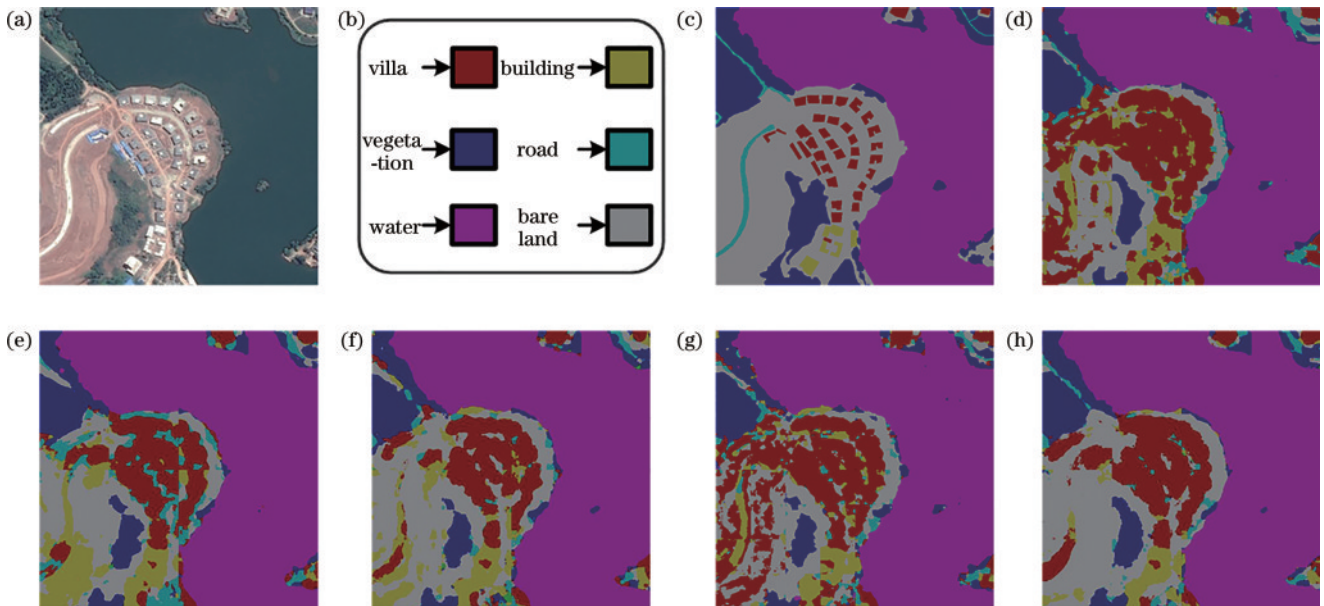


图 7 实验 1。(a)原始影像;(b)地物类别组成;(c)地面真值;(d) FCN 的分类结果;(e) Attention-Unet 的分类结果;(f) MASK-RCNN 的分类结果;(g)DWTCN 的分类结果;(h)DWTDN 的分类结果

Fig. 7 Experiment 1. (a) Original remote sensing image; (b) feature category composition; (c) GT; (d) results of FCN; (e) results of Attention-Unet; (f) results of MASK-RCNN; (g) results of DWTCN; (h) results of DWTDN

表 1 实验 1 的分类精度

Table 1 Classification accuracy of experiment 1

Classification accuracy of different networks	FCN		Attention-Unet		MASK-RCNN		DWTCN		DWTDN	
	OA	Kappa	OA	Kappa	OA	Kappa	OA	Kappa	OA	Kappa
villa	0.84	0.27	0.88	0.36	0.91	0.43	0.84	0.28	0.90	0.42
building	0.74	0.18	0.86	0.35	0.83	0.32	0.89	0.25	0.87	0.35
vegetation	0.84	0.70	0.94	0.69	0.94	0.71	0.83	0.67	0.95	0.75
road	0.76	0.16	0.57	0.22	0.57	0.25	0.88	0.18	0.67	0.32
water	0.88	0.97	0.98	0.96	0.98	0.97	0.98	0.96	0.99	0.98
bare land	0.77	0.35	0.67	0.40	0.66	0.40	0.77	0.36	0.67	0.41
overall	0.72	0.60	0.70	0.57	0.79	0.69	0.73	0.61	0.82	0.72

从图 7 和表 1 可以看出:FCN、Attention-Unet 和 DWTCN 在分析道路时容易引入误差/错误,OA 与

kappa 系数较低;而 MASK-RCNN 在分析道路时也引入了一些误差/错误,但 OA 与 kappa 系数有一定提升;

DWTDN 通过自我验证压制误差/错误,能够较好地辨识微小道路,表现出最好的 OA 与 Kappa 系数。

4.2.2 实验结果 2

实验 2 的影像中主要包含普通建筑、植被、大棚与裸地,主要比较分类结果中“大棚”的精度。其原始影像与分类结果在图 8 中展示。根据地面真值,分类结果的客观精度如表 2 所示。

从图 8 和表 2 可以看出:FCN、Attention-Unet 和 DWTCN 在解读细微建筑等地物时,容易引入误差/错误,OA 与 Kappa 系数较低;而 MASK-RCNN 能够更加准确地理解细小特征,OA 与 Kappa 系数有所提升;DWTDN 通过特征权重分析与自我验证机制,进一步抑制了误差/错误,能够最佳地辨识各类地物,表现出最好的 OA 与 kappa 系数。

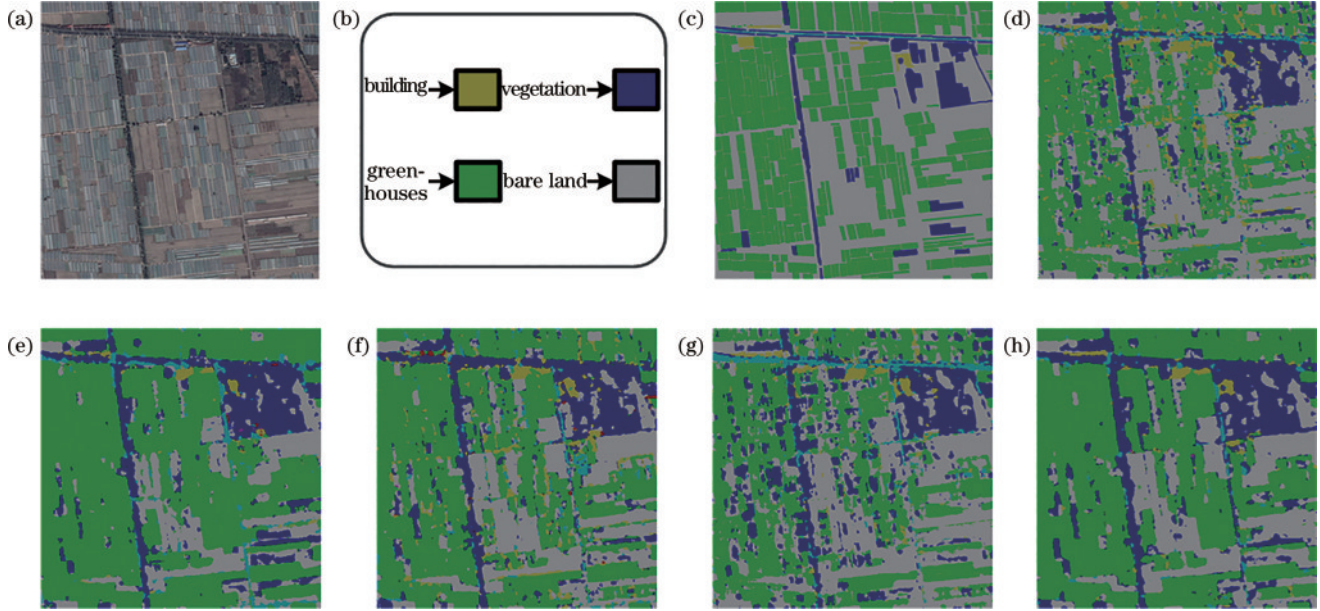


图 8 实验 2。(a)原始影像;(b)地物类别组成;(c)地面真值;(d) FCN 的分类结果;(e) Attention-Unet 的分类结果;(f) MASK-RCNN 的分类结果;(g)DWTCN 的分类结果;(h)DWTDN 的分类结果

Fig. 8 Experiment 2. (a) Original remote sensing image; (b) feature category composition; (c) GT; (d) results of FCN; (e) results of Attention-Unet; (f) results of MASK-RCNN; (g) results of DWTCN; (h) results of DWTDN

表 2 实验 2 的分类精度

Table 2 Classification accuracy of experiment 2

Classification accuracy of different networks	FCN		Attention-Unet		MASK-RCNN		DWTCN		DWTDN	
	OA	Kappa	OA	Kappa	OA	Kappa	OA	Kappa	OA	Kappa
building	0.67	0.20	0.54	0.15	0.62	0.28	0.64	0.10	0.70	0.31
vegetation	0.82	0.27	0.86	0.41	0.88	0.45	0.89	0.41	0.90	0.48
greenhouses	0.73	0.45	0.82	0.65	0.80	0.60	0.78	0.57	0.83	0.67
bare land	0.70	0.39	0.72	0.34	0.71	0.33	0.74	0.47	0.72	0.34
overall	0.60	0.38	0.69	0.51	0.66	0.47	0.66	0.48	0.71	0.52

4.2.3 实验结果 3

实验 3 的影像中主要包含普通建筑、植被、大棚、水体与裸地。其原始影像与分类结果在图 9 中展示。根据地面真值,分类结果的客观精度如表 3 所示。

从图 9 和表 3 可以看出:Attention-Unet 分析小面积水体的能力较弱,OA 与 Kappa 系数较低;FCN、DWTCN 对水体的提取能力差,无法提取有效的水体范围;而 MASK-RCNN 能够稳健认知水体等地物,提升了 OA 与 Kappa 系数;DWTDN 能够很好认知水体等各类地物,表现出最好的 OA 与 Kappa 系数。

4.2.4 实验结果 4

实验 4 的影像中主要包含普通建筑、植被、道路与

裸地,主要比较分类结果中“普通建筑”的精度。其原始影像与分类结果在图 10 中展示。根据地面真值,分类结果的客观精度如表 4 所示。

从图 10 和表 4 可以看出:Attention-Unet、DWTCN 分析细小道路时引入了噪声与错误,OA 与 Kappa 系数较低;FCN 对道路的识别能力差,Kappa 系数低;而 MASK-RCNN 的稳健性能有所提升,OA 与 Kappa 系数有所提高;DWTDN 能够以最佳的噪声抵抗力认知各类地物,OA 与 Kappa 系数最好。

4.3 分析与讨论

4 种分类方法在 4 次实验中的表现如表 5 所示,在遥感影像弱监督、稀少样本的条件下,4 种遥感影像分

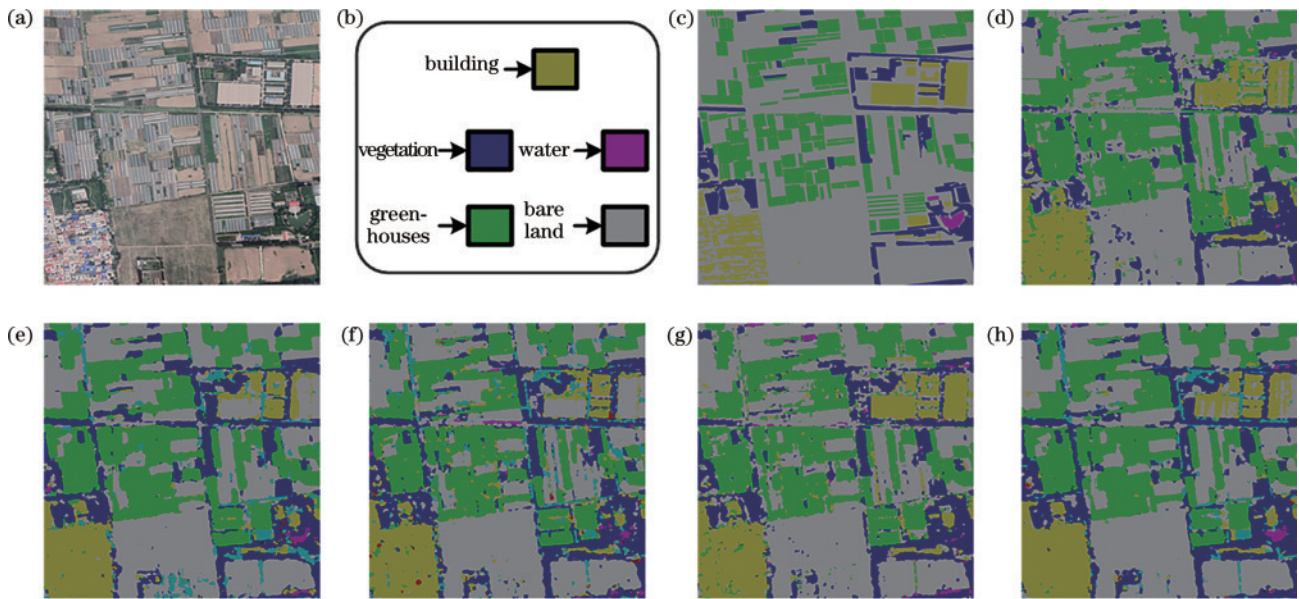


图 9 实验 3。(a)原始影像;(b)地物类别组成;(c)地面真值;(d) FCN 的分类结果;(e) Attention-Unet 的分类结果;
(f) MASK-RCNN 的分类结果;(g)DWTCN 的分类结果;(h)DWTDN 的分类结果

Fig. 9 Experiment 3. (a) Original remote sensing image; (b) feature category composition; (c) GT; (d) results of FCN; (e) results of Attention-Unet; (f) results of MASK-RCNN; (g) results of DWTCN; (h) results of DWTDN

表 3 实验 3 的分类精度

Table 3 Classification accuracy of experiment 3

Classification accuracy of different networks	FCN		Attention-Unet		MASK-RCNN		DWTCN		DWTDN	
	OA	Kappa	OA	Kappa	OA	Kappa	OA	Kappa	OA	Kappa
building	0.93	0.59	0.90	0.43	0.91	0.54	0.92	0.61	0.93	0.60
vegetation	0.88	0.53	0.89	0.52	0.89	0.52	0.88	0.55	0.89	0.54
water	0.49	0.14	0.61	0.24	0.67	0.26	0.48	0.06	0.69	0.28
greenhouses	0.85	0.64	0.89	0.73	0.90	0.75	0.89	0.71	0.91	0.76
bare land	0.72	0.48	0.70	0.56	0.74	0.57	0.75	0.52	0.75	0.57
overall	0.71	0.55	0.66	0.51	0.68	0.53	0.71	0.56	0.72	0.56

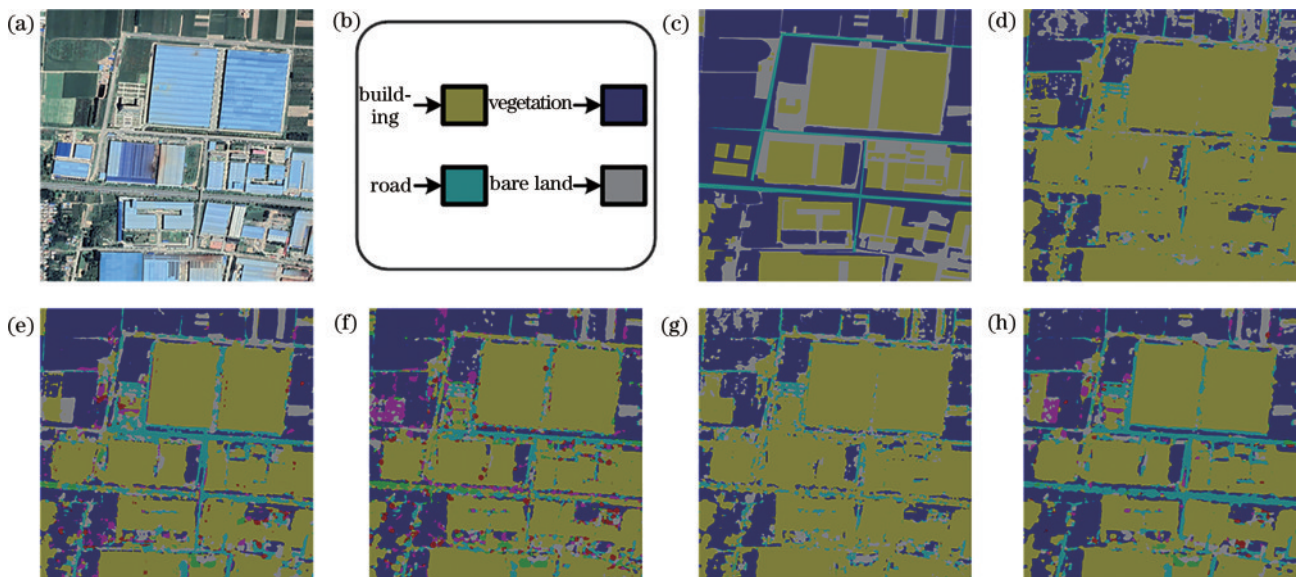


图 10 实验 4。(a)原始影像;(b)地物类别组成;(c)地面真值 GT;(d) FCN 的分类结果;(e) Attention-Unet 的分类结果;
(f) MASK-RCNN 的分类结果;(g)DWTCN 的分类结果;(h)DWTDN 的分类结果

Fig. 10 Experiment 4. (a) Original remote sensing image; (b) feature category composition; (c) GT; (d) results of FCN; (e) results of Attention-Unet; (f) results of MASK-RCNN; (g) results of DWTCN; (h) results of DWTDN

表 4 实验 4 的分类精度
Table 4 Classification accuracy of experiment 4

Classification accuracy of different networks	FCN		Attention-Unet		MASK-RCNN		DWTCN		DWTDN	
	OA	Kappa	OA	Kappa	OA	Kappa	OA	Kappa	OA	Kappa
building	0.69	0.43	0.81	0.63	0.83	0.67	0.72	0.49	0.84	0.68
vegetation	0.80	0.56	0.83	0.64	0.84	0.65	0.81	0.57	0.85	0.68
road	0.52	0.05	0.59	0.25	0.61	0.29	0.62	0.18	0.66	0.32
bare land	0.76	0.01	0.77	0.43	0.77	0.43	0.76	0.01	0.77	0.43
overall	0.59	0.37	0.63	0.48	0.65	0.49	0.62	0.42	0.70	0.53

类方法均能对大部分地物进行合理辨识。其中：MASK-RCNN 的稳健性和准确性更好；FCN 在不同场景下精度波动较大，易受地物类别分布的干扰；Attention-Unet 分类结果的 OA 与 Kappa 平均值为 0.67 与 0.52，分类结果准确性和稳定性都较高。但 MASK-RCNN、FCN 和 Attention-Unet 容易受到地物边缘、地物细节等脏信息的干扰，形成大量的斑点噪声、条纹噪声与错误分类。

根据 DWTDN 在表 5 及 4 次实验中的表现，针对遥感影像中样本稀少且包含弱监督错误的分类困境，所

提 DWTDN 在特征权重分析与自我验证的学习过程中，能够抵抗各种地物阴影、地物边缘、光照差异等脏信息的干扰，对地物进行稳健、准确的解读，总体上获取了最佳的分类结果，OA 与 Kappa 平均值达到 0.74 与 0.58。综合 DWTCN 在 4 次实验中的表现可知，去除目标识别网络之后，网络的分类结果的 OA 和 Kappa 系数都有大幅下降。即双重网络结构能有效地改善分类效果，提高分类精度，DWTDN 能够更好适应遥感影像样本稀少且包含弱监督脏信息的数据特点，准确抽象出地面场景中的地物语义信息。

表 5 所有实验的分类精度对比
Table 5 Classification accuracy of all experiments

Classification accuracy of different networks	FCN		Attention-Unet		MASK-RCNN		DWTCN		DWTDN	
	OA	Kappa	OA	Kappa	OA	Kappa	OA	Kappa	OA	Kappa
Exp. 1	0.72	0.60	0.70	0.57	0.79	0.69	0.73	0.61	0.82	0.72
Exp. 2	0.60	0.38	0.69	0.51	0.66	0.47	0.66	0.48	0.71	0.52
Exp. 3	0.71	0.55	0.66	0.51	0.68	0.53	0.71	0.56	0.72	0.56
Exp. 4	0.59	0.37	0.63	0.48	0.65	0.49	0.62	0.42	0.70	0.53

5 结 论

所提 DWTDN 分类网络，能够通过简单、方便、有效的权重动态变形结构，评价特征对分类的重要性，并将重要的特征凸显出来，结合神经网络的后向传播进行学习。此外，双重网络相互印证的自我验证思路，弥补了神经网络自我验证能力的缺陷，能够帮助网络在分类过程中进一步压制各类噪声与错误，从而提供更加准确、更加可靠的分类结果，增强了网络认知遥感影像的能力。

相比于现有的 Attention-Unet 和 MASK-RCNN，在真实遥感影像分类实验中，所提网络的分类结果表现出最佳的区域一致性与最优秀的细节认知，并始终保持稳健、可靠的分类精度。面对高分辨率遥感影像的复杂地表场景以及稀少且包含干扰信息的训练样本，所提分类网络通过加强特征学习能力和提高自我验证能力，增强了网络的学习性能与抗干扰性能，从而能够提供稳健可信的地物类别信息，具有很强的应用潜力。

参 考 文 献

[1] 赵英时. 遥感应用分析原理与方法[M]. 北京: 科学出版

社, 2003.

Zhao Y S. Principles and methods of remote sensing application analysis[M]. Beijing: Science Press, 2003.

[2] 沈川, 贾渊, 杨珂珂. 基于高分遥感影像的断裂道路连接方法[J]. 计算机测量与控制, 2020, 28(2): 246-249.

Shen C, Jia Y, Yang K K. Fracture road connection method based on high-resolution remote sensing image [J]. Computer Measurement & Control, 2020, 28(2): 246-249.

[3] 吕雅慧, 张超, 鄢文聚, 等. 高分辨率遥感影像农田林网自动识别[J]. 农业机械学报, 2018, 49(1): 157-163.

Lü Y H, Zhang C, Yun W J, et al. Automatic recognition of farmland shelterbelts in high spatial resolution remote sensing data[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(1): 157-163.

[4] Zhang X H, Lü Y F, Yao L B, et al. A new benchmark and an attribute-guided multilevel feature representation network for fine-grained ship classification in optical remote sensing images[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2020, 13: 1271-1285.

[5] 周建伟, 吴一全. MRELBP 特征、Franklin 矩和 SVM 相结合的遥感图像建筑物识别方法[J]. 测绘学报, 2020,

- 49(3): 355-364.
Zhou J W, Wu Y Q. Building area recognition method of remote sensing image based on MRELB feature, Franklin moment and SVM[J]. Acta Geodaetica et Cartographica Sinica, 2020, 49(3): 355-364.
- [6] Al-Najjar H A H, Kalantar B, Pradhan B, et al. Land cover classification from fused DSM and UAV images using convolutional neural networks[J]. Remote Sensing, 2019, 11(12): 1461.
- [7] El Jazouli A, Barakat A, Khellouk R, et al. Remote sensing and GIS techniques for prediction of land use land cover change effects on soil erosion in the high basin of the Oum Er Rbia River (Morocco)[J]. Remote Sensing Applications: Society and Environment, 2019, 13: 361-374.
- [8] 王春艳, 刘佳新, 徐爱功, 等. 一种新的高分辨率遥感影像模糊监督分类方法[J]. 武汉大学学报(信息科学版), 2018, 43(6): 922-929.
Wang C Y, Liu J X, Xu A G, et al. A new method of fuzzy supervised classification of high resolution remote sensing image[J]. Geomatics and Information Science of Wuhan University, 2018, 43(6): 922-929.
- [9] Zhang C, Pan X, Zhang S Q, et al. A rough set decision tree based MLP-CNN for very high resolution remotely sensed image classification[J]. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2017, XLII-2/W7: 1451-1454.
- [10] Dou P, Chen Y B, Yue H Y. Remote-sensing imagery classification using multiple classification algorithm-based Ada boost[J]. International Journal of Remote Sensing, 2018, 39(3): 619-639.
- [11] Tao Y T, Xu M Z, Zhang F, et al. Unsupervised-restricted deconvolutional neural network for very high resolution remote-sensing image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(12): 6805-6823.
- [12] 乔文凡, 慎利, 戴延帅, 等. 联合膨胀卷积残差网络和金字塔池化表达的高分影像建筑物自动识别[J]. 地理与地理信息科学, 2018, 34(5): 56-62.
Qiao W F, Shen L, Dai Y S, et al. Building extraction from high resolution remote sensing images by combining dilated convolutional residual networks and pyramid pooling representation[J]. Geography and Geo-Information Science, 2018, 34(5): 56-62.
- [13] Wang Q, Liu S T, Chanussot J, et al. Scene classification with recurrent attention of VHR remote sensing images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57(2): 1155-1167.
- [14] Ma D, Tang P, Zhao L J. SiftingGAN: generating and sifting labeled samples to improve the remote sensing image scene classification baseline *in vitro*[J]. IEEE Geoscience and Remote Sensing Letters, 2019, 16(7): 1046-1050.
- [15] Tong W, Chen W T, Han W, et al. Channel-attention-based DenseNet network for remote sensing image scene classification[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2020, 13: 4121-4132.
- [16] Bui D T, Tran T D, Nguyen T T, et al. Aerial image semantic segmentation using neural search network architecture[M]//Kaenampornpan M, Malaka R, Nguyen D D, et al. Multi-disciplinary trends in artificial intelligence. Lecture notes in computer science. Cham: Springer, 2018, 11248: 113-124.
- [17] 程镛杰, 杨耘, 李龙威, 等. 基于深度可分离卷积的轻量化残差网络高光谱影像分类[J]. 光学学报, 2023, 43(12): 1228010.
Cheng R J, Yang Y, Li L W, et al. Lightweight residual network based on depthwise separable convolution for hyperspectral image classification[J]. Acta Optica Sinica, 2023, 43(12): 1228010.
- [18] Zhu M Z, Fan J Y, Yang Q H, et al. SC-EADNet: a self-supervised contrastive efficient asymmetric dilated network for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 5519517.
- [19] Tang Y W, Qiu F, Wang B J, et al. A deep relearning method based on the recurrent neural network for land cover classification[J]. GIScience & Remote Sensing, 2022, 59(1): 1344-1366.
- [20] Song D M, Tang Y H, Wang B, et al. Two-branch generative adversarial network with multiscale connections for hyperspectral image classification[J]. IEEE Access, 2022, 11: 7336-7347.
- [21] Ge H M, Wang L G, Liu M Q, et al. Two-branch convolutional neural network with polarized full attention for hyperspectral image classification[J]. Remote Sensing, 2023, 15(3): 848.
- [22] 郑宗生, 刘贝, 卢鹏, 等. 基于 AlexNet 的近岸水生植物光谱分类及特征光谱分析[J]. 中国激光, 2023, 50(2): 0211001.
Zheng Z S, Liu B, Lu P, et al. Spectral classification and characteristic spectral analysis of nearshore aquatic plants based on AlexNet[J]. Chinese Journal of Lasers, 2023, 50(2): 0211001.
- [23] 龚健雅, 季顺平. 从摄影测量到计算机视觉[J]. 武汉大学学报(信息科学版), 2017, 42(11): 1518-1522, 1615.
Gong J Y, Ji S P. From photogrammetry to computer vision[J]. Geomatics and Information Science of Wuhan University, 2017, 42(11): 1518-1522, 1615.
- [24] 王思泽, 关欣, 李镛. 全局-局部注意力特征重用高光谱图像超分辨率网络[J]. 光学学报, 2023, 43(21): 2115001.
Wang S Z, Guan X, Li Q. Hyperspectral image super-resolution network of local-global attention feature reuse [J]. Acta Optica Sinica, 2023, 43(21): 2115001.
- [25] Chen Y, Chen H S, Liu G Q. Remote sensing image registration based on spatial transform network and phase correlation method[C]//2019 International Conference on Intelligent Informatics and Biomedical Sciences (ICIIBMS), November 21-24, 2019, Shanghai, China. New York: IEEE Press, 2020: 125-128.
- [26] 关泽群, 刘继琳. 遥感图像解译[M]. 武汉: 武汉大学出版社, 2007.
Guan Z Q, Liu J L. Remote sensing image interpretation [M]. Wuhan: Wuhan University Press, 2007.

- [27] 张贤达. 矩阵分析与应用[M]. 2 版. 北京: 清华大学出版社, 2013.
Zhang X D. Matrix analysis and applications[M]. 2nd ed. Beijing: Tsinghua University Press, 2013.
- [28] Zhou P, Ni B B, Geng C, et al. Scale-transferrable object detection[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 528-537.
- [29] Tan M X, Pang R M, Le Q V. EfficientDet: scalable and efficient object detection[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 10778-10787.
- [30] Yang G H, Feng W, Jin J T, et al. Face mask recognition system with YOLOV5 based on image recognition[C]//2020 IEEE 6th International Conference on Computer and Communications (ICCC), December 11-14, 2020, Chengdu, China. New York: IEEE Press, 2021: 1398-1404.
- [31] Wu C Y, Zhang F, Xia J S, et al. Building damage detection using U-net with attention mechanism from pre- and post-disaster remote sensing datasets[J]. Remote Sensing, 2021, 13(5): 905.
- [32] Mahmoud A, Mohamed S, El-Khoribi R, et al. Object detection using adaptive mask RCNN in optical remote sensing images[J]. International Journal of Intelligent Engineering and Systems, 2020, 13(1): 65-76.
- [33] Song K S. Globally convergent algorithms for estimating generalized gamma distributions in fast signal and image processing[J]. IEEE Transactions on Image Processing, 2008, 17(8): 1233-1250.