

doi: 10.6046/zrzyyg.2021135

引用格式: 伊尔潘·艾尼瓦尔,买买提·沙吾提,买合木提·巴拉提. 基于 GF-2 影像和 Unet 模型的棉花分布识别[J]. 自然资源遥感, 2022, 34(2): 242–250. (Erpan A, Mamat S, Maihemuti B. Recognition of cotton distribution based on GF-2 images and Unet model[J]. Remote Sensing for Natural Resources, 2022, 34(2): 242–250.)

基于 GF-2 影像和 Unet 模型的棉花分布识别

伊尔潘·艾尼瓦尔¹, 买买提·沙吾提^{1,2,3}, 买合木提·巴拉提^{1,2,3}

(1. 新疆大学地理与遥感科学学院, 乌鲁木齐 830046; 2. 新疆绿洲生态重点实验室, 乌鲁木齐 830046;
3. 智慧城市与环境建模自治区普通高校重点实验室, 乌鲁木齐 830046)

摘要: 为探讨深度学习方法在干旱区棉花分布识别中的适用性及优化流程, 以渭干河—库车河三角绿洲典型作物棉花为研究对象, 利用国产 GF-2 影像, 结合野外调查数据, 采用 Unet 深度学习方法, 借助 Unet 网络多重卷积运算的特点充分挖掘棉花在遥感影像上的深层次特征, 从而提高棉花的提取精度。结果表明, Unet 模型提取研究区棉花、玉米、辣椒的识别效果优于面向对象和传统机器学习算法分类结果, 总体精度为 84.22%, Kappa 系数为 0.804 7, 相比面向对象方法以及传统机器学习算法 SVM 和 RF 的总体精度分别提高了 7.94, 11.93 和 11.73 百分点, Kappa 系数提高了 10.13%, 14.72%, 14.60%。Unet 模型分类结果中, 棉花的制图精度和用户精度均高于其余 3 种方法, 分别为 94.95% 和 89.07%。利用 Unet 模型在 GF-2 高分辨率遥感影像上高精度提取干旱区棉花空间分布信息具有可行性和可靠性。

关键词: 深度学习; 棉花识别; Unet 模型; GF-2 影像

中图法分类号: TP 79 **文献标志码:** A **文章编号:** 2097-034X(2022)00-0242-09

0 引言

棉花作为我国重要的经济作物, 在我国新疆地区种植广泛。在遥感影像上高精度地识别棉花, 掌握棉花种植面积等年度波动状况, 为政府部门提供可靠的棉花农情信息, 对提高经济生产和我国农业安全都具有重要意义^[1]。

目前, 国内外利用遥感技术进行棉花识别研究多使用 MODIS 数据^[2-3]、Landsat 数据^[4-5]、哨兵数据^[6]等中低分辨率遥感影像, 采用支持向量机(support vector machine, SVM)^[7]、随机森林(random forest, RF)^[8]、最大似然法^[9]等传统机器学习算法进行棉花信息识别提取。虽然这些影像数据可以有效提高时间分辨率、减少成本, 但混合像元数量众多, 光谱识别度有限, 缺乏有效的棉花识别特征参量等^[10-12], 不能很好地满足复杂地貌条件下棉花高精度识别分类要求。另外, 仅采用有限的浅层特征和规则简单、结构单一的自动提取算法在复杂地物分

布情况下表现出极大的局限性。因此, 需要探索提高棉花提取精度的新方法。

近几年我国高分系列卫星的发射以及深度学习算法的发展, 为作物高精度识别研究带来了新的机遇^[13-15], 尤其是 GF-2 卫星具有亚米级空间分辨率^[16], 为较好实现复杂背景下的作物精准识别提供了重要数据源。同时, 以 Unet 模型为代表的目标识别方法不断完善, 在城市绿地提取^[16]、水稻病害识别^[17]、胡杨冠层提取^[18]等方面均有较多的应用, 这为今后利用 Unet 模型高精度识别农作物提供了技术参考, 使得 Unet 模型成为实现作物高精度监测技术突破的重要支点之一, 为作物识别精度提高, 智能化、自动化信息提取指明了方向, 必将成为新的研究热点。但是, 通过总结前人研究发现, 利用 Unet 模型进行棉花提取的研究较少, 相关应用鲜有报道。因此本文尝试将 Unet 模型应用到棉花识别研究中。

另外, 随着近几年新疆环塔里木林果业的发展, 果棉间作的种植模式迅速扩大, 使作物种植环境更加复杂, 导致现有遥感监测方法无法满足复杂地理

收稿日期: 2021-04-25; 修订日期: 2021-09-13

基金项目: 新疆自然科学基金(自然科学基金)联合基金项目“基于深度学习和无人机遥感的病害核桃树木识别与定位”(编号: 2021D01C055)和国家自然科学基金地区基金项目“渭干河流域水文过程与非点源溶质运移耦合模拟及水资源利用安全范式”(编号: 41762019)共同资助。

第一作者: 伊尔潘·艾尼瓦尔(1995-), 男, 硕士研究生, 主要从事遥感图像智能解译方面的研究。Email: erpan_edu@163.com。

通信作者: 买买提·沙吾提(1976-), 男, 博士, 副教授, 主要从事干旱区资源环境及农业遥感应用方面的研究。Email: korxat@xju.edu.cn。

环境条件下及时、准确的作物识别要求。因此,本文针对地块破碎、种植结构复杂以及传统机器学习算法存在的高分辨率影像信息利用不足、大数量样本运算能力有限等问题,以渭干河—库车河绿洲为研究区,通过获取 GF-2 遥感数据,将 Unet 模型应用到棉花识别研究中,探讨 Unet 模型在干旱区作物精细分类中的适用性及优化流程,以期为干旱区作物精细分类提供新的思路。

1 研究区概况及数据源

1.1 研究区概况

研究区位于塔里木盆地北部的渭干河—库车河

三角绿洲(简称“渭库绿洲”)是典型的冲积扇平原,地理坐标为 $E80^{\circ}37' \sim 83^{\circ}59'$, $N41^{\circ}06' \sim 41^{\circ}40'$,年降水量为 50.0 ~ 66.5 mm,年均蒸发量为 2 000 ~ 2 092 mm,气候类型为暖温带大陆性干旱气候。研究区以种植业为主导产业,作物类型主要包括棉花、玉米、小麦等,是新疆重要的粮棉基地之一。从 1994 年起,新疆成为我国最大产棉区和最大的商品棉基地^[19]。2011 年统计数据显示,“渭库绿洲”棉花面积分别占新疆棉花总面积及阿克苏地区棉花总面积的 8.56% 及 38.2%,产量分别占 8.41% 及 40.34%,是新疆主要的棉花生产区域之一^[20]。研究区地理位置及分类目标具体如图 1 所示。




图1 研究区地理位置、解译点、样方分布及目标类别示意图

Fig. 1 Schematic diagram of the geographic location, interpretation points, sample distribution and target categories of the study area

1.2 数据源及其预处理

本文采用的数据是 2018 年 9 月 17 日的 GF-2 影像,GF-2 数据包含 4 个多光谱波段(空间分辨率 4 m)和 1 个全色波段(空间分辨率 1 m),幅宽可达 43.5 km,是我国空间分辨率最高的民用陆地观测卫星。首先对原始影像进行大气校正、正射校正等预处理后将多光谱波段与全色波段数据融合得到空间分辨率为 1 m 的影像。然后,利用野外辅助调查数据在影像中选取棉花、玉米等作物样本,借助样本标注工具 Labelme 对选取出的图像进行精细标注获得样本标签。由于深度学习需要大量数据进行训

练^[21],因此本文采用加噪、对称变换、旋转、改变亮度等数据增强方法对有限的样本数据进行扩充,最终获得 8 000 张图像大小为 25 像素×25 像素的数据集,并按照 9:1 的比例分为训练集与验证集,为作物分类做准备。

为了制作影像分类所需要的样本数据,以及了解不同作物的分布特征,于 2018 年 7 月 3—12 日、2019 年 2 月 5—9 日分别进行了 2 次野外实地调查,共获取各类地物样点 478 个、样方 20 个,并利用差分 GPS 获取各点经纬度信息,测算样方内地物面积等。根据野外调查样点和样方数据最终选取

4 km × 4 km 范围作为实验区域,所选区域包含套种田地、套种园林等较为复杂的种植环境。

2 研究方法

2.1 Unet 语义分割模型

Unet 模型在深度学习遥感影像分类领域应用较为广泛,其结构是一种典型的编码-解码框架(图2),主要过程一般为图像输入、编码操作、解码操作、图像输出4个部分^[22]。本文首先将 GF-2 遥感图像输入该网络中;其次,对输入图像进行编码

操作,编码过程通过2个3×3卷积计算后可以获得64个通道的特征图像,再利用2×2的卷积进行最大池化,将图像的大小缩小为原图一半,通过重复4次上述过程图像的特征通道逐渐增加,从而获取图像的深层次特征;然后,在进行解码操作时,利用2×2的反卷积恢复图像大小,每完成一次反卷积运算,将获得的图像与上一层提取到的特征图进行融合,并再次进行2次3×3卷积运算,来还原物体细节特征,使边缘特征更加精细;最后,完成解码操作,利用 Softmax 激活函数和1×1的卷积将各像素归类并输出分类结果图。




图2 Unet 模型结构示意图

Fig. 2 Unet model structure diagram

Unet 模型作为深层网络参数众多,其中批次大小、学习率、迭代次数、优化器是较为重要的几类参数,需要多次实验进行调节^[23]。通过多次实验,本文中将批次大小设置为4,学习率为0.001,迭代次数设置为100次。本文尝试了 Adam, Adagrad, Rmsprop, SGD 等4类常用的优化器,绘制了不同优化器在训练集上损失函数值的变化曲线,如图3所示。优化器对深度学习模型最终的分类效果影响较

大^[23],它通过更新和计算影响模型训练和模型输出的网络参数,使其逐渐接近最优值,从而得到较低的损失函数值。从图3可知,Adam 优化器相比于其他3类优化器最先达到最低损失函数值并提前进入稳定状态。因此,本文选择了 Adam 优化器^[24]来提升训练效果,进而为获取高精度的作物分类结果打下基础。

2.2 精度评价指标

本文利用混淆矩阵计算 Kappa 系数、总体精度 (overall accuracy, OA)、制图精度 (product accuracy, PA)、用户精度 (user accuracy, UA)、交并比 (intersection over union, IOU) 等评价指标分析影像分类结果^[25-26]。其中, Kappa 系数表示预测结果与真实值之间的匹配程度,数值范围在0~1之间; OA 能够直观地体现预测结果与真实类别之间的正确匹配情况; PA 为某一类验证样本被正确分类的概率,代表分类方法的好坏; UA 则为某一类别预测结果正确代表实际真值的概率,反映分类结果的可信度; IOU 为标签上所有类别的真实值和模型所产




图3 不同优化器的训练损失函数值随迭代次数变化曲线

Fig. 3 Training loss function value of different optimizers varies with the number of iterations

生的预测值的交集和并集的比值。各指标公式分别为：

$$Kappa = \frac{N \sum_i^r X_{ii} - \sum_i^r (X_{i+} X_{+i})}{N^2 - \sum_i^r (X_{i+} X_{+i})} \quad , \quad (1)$$

$$OA = \sum_i^r X_{ii} / N \quad , \quad (2)$$

$$UA = X_{ii} / X_{i+} \quad , \quad (3)$$

$$PA = X_{ii} / X_{+i} \quad , \quad (4)$$

$$IOU = \sum_{i=0}^k \frac{p_{ii}}{\sum_{j=0}^k p_{ij} + \sum_{j=0}^k p_{ji} - p_{ii}} \quad , \quad (5)$$

式中： N 为总像素数； X_{ii} 为某类别正确分类数； X_{i+} 为该类别分类总数； X_{+i} 为该类别验证样本数； p_{ii} 为原为 i 预测为 i 的数量； p_{ij} 为原为 i 预测为 j 的数量； p_{ji} 为原为 j 预测为 i 的数量。

3 结果与分析

3.1 Unet 模型训练

为了检验模型训练是否过拟合绘制了训练过程中损失函数值变化曲线,为了获知模型训练是否收敛绘制了训练过程中精度随迭代次数的变化曲线,如图 4 所示。从图 4(a)中可知,训练集和验证集的损失函数值随着迭代次数的增加均大致体现为下降趋势,其中,训练集的曲线在大约进行 25 次迭代之后不再变化。虽然验证集的损失函数值出现了小幅度的波动现象,但是模型整体并没有过拟合。图 4(b)中无论是训练集还是验证集,其精度随迭代次数增加平稳上升,同样大约于 25 次迭代之后不再变化,表明模型已经收敛,再增加迭代次数精度也不会出现较大改变,表明对于本次实验,迭代 25 次之后便可结束训练。




图 4 模型训练过程损失函数和精度变化曲线

3.2 Unet 分类结果

不同分类方法的精度评价结果如表 1 所示,从表 1 中可知,Unet 模型的总体分类精度为 84.22%,相比于面向对象、SVM 和 RF 算法分别提高了 7.94, 11.93 和 11.73 百分点,其 Kappa 系数为 0.804 7,相对面向对象、SVM 和 RF 提高了 10.13%,14.72% 和 14.60%,Unet 模型分类效果较好。从各地物分类结果来看,Unet 模型分类结果中,棉花、玉米和辣椒的制图精度与用户精度均维持在较高的水平,尤其

是棉花的制图精度与用户精度均高于其他方法的结果,说明利用 Unet 模型在 GF-2 遥感影像上较高精度地提取棉花具有一定可靠性。面向对象分类结果相比于 SVM 和 RF 具有较好的表现,从各地物情况来看,面向对象方法对玉米和林地有较好的提取效果。对于果园而言,4 类方法总体表现较为一般,其中 Unet 模型与面向对象方法相比 SVM 和 RF 算法,在提取果园方面精度都有一定的提升。不同方法分类结果如图 5 所示。

表 1 分类结果精度评价
Tab. 1 Classification result accuracy evaluation

地类	Unet		面向对象		SVM		RF	
	PA/%	UA/%	PA/%	UA/%	PA/%	UA/%	PA/%	UA/%
棉花	94.95	89.07	69.31	79.86	64.36	79.08	69.48	72.86
玉米	94.81	91.38	88.88	94.81	68.75	65.90	68.92	67.00
辣椒	81.69	91.55	47.06	57.54	69.69	59.16	58.30	45.44
果园	68.30	79.70	74.05	56.51	59.50	64.24	57.33	67.33
林地	61.25	68.30	63.82	87.39	62.21	63.01	64.91	72.24
其他	82.36	72.06	98.23	77.43	97.76	88.45	98.73	88.46
总体精度/%	84.22		76.28		72.29		72.49	
Kappa 系数	0.804 7		0.703 4		0.657 5		0.658 7	




图 5 研究区分类结果

Fig. 5 Classification results in the study area

从图 5 可以看出,Unet 模型结果中识别棉花的视觉效果相比于面向对象、SVM 和 RF 结果要好,面向对象结果中将一些棉地错分为辣椒,SVM 和 RF 结果中有一些属于棉花区域的像素被错分为林地,Unet 模型识别棉花地块边界较为平滑、斑点较少,在一些样方、样点所在的区域被错分的像素较其他 3 类方法结果而言相对减少。

为了更好地说明各地物目标的分类效果,利用野外调查样点和样方数据选取了 4 个局部区域,这些区域包含棉花、玉米、辣椒 3 类作物以及套种区域等复杂的种植环境,通过计算 IOU 分析分类结果中各类目标物的预测值与真实值的重合情况,如表 2 所示。由表 2 可知,Unet 模型分类结果的 IOU 平均值为 0.730 1 分别高出面向对象、SVM 和 RF 结果 28.36%、28.01% 和 26.95%,说明 Unet 模型分类结果中目标的预测值与真实值更为接近。其中,从 Unet 模型结果各类别 IOU 来看,棉花、玉米和辣椒的 IOU 均高于 0.8,说明该模型对这 3 类作物的识别效果较好。其果园和林地虽均低于 0.8,但是

相比于面向对象、SVM 和 RF 算法得到了较好的提升,而面向对象、SVM 和 RF 的分类结果的 IOU 平均值基本在同一水平,差距较小。

表 2 局部区域各地物 IOU 统计

Tab. 2 IOU statistic of local areas and objects

















作物	Unet	面向对象	SVM	RF
棉花	0.895 7	0.547 8	0.717 2	0.675 5
玉米	0.847 9	0.819 5	0.561 0	0.577 0
辣椒	0.826 9	0.502 0	0.359 9	0.409 1
果园	0.744 1	0.414 3	0.511 0	0.504 1
林地	0.545 8	0.194 7	0.280 8	0.303 8
其他	0.520 1	0.200 7	0.270 2	0.294 1
平均值	0.730 1	0.446 5	0.450 0	0.460 6

局部区域分类结果如表 3 所示,Ⅰ号区域中作物类型为棉花和辣椒,Unet 模型分类结果中棉花和辣椒的边界较为平滑,错分的像素也相比面向对象、SVM 和 RF 的分类结果明显减少。Ⅱ号区域包括玉米、果园、林地和其他 4 个类别,其中面向对象结果中存在将玉米错分为林地的像素,SVM 和 RF 结果中将玉米错分为果园的像素居多,Unet 模型则较好

地识别出了玉米,错分像素大大减少。Ⅲ号区域中,果园里局部区域果树种植稀疏,SVM 和 RF 算法将稀疏部分多数像素错分到其他类别中,Unet 模型结果则有了一定的提升。Ⅳ号区域为棉花和辣椒套种区域,从面向对象分类算法识别效果看,没能将辣椒

区域和周围的棉花区分,均被识别为了辣椒,而 SVM 和 RF 则是将套种的辣椒错分为了林地。Unet 模型结果虽然也存在识别错误的像素,但识别出了大部分套种在棉花中辣椒。

表 3 局部区域分类结果
Tab.3 Schematic diagram of local area classification results

区域	假彩色影像	Unet 结果	面向对象结果	SVM 结果	RF 结果
I					
II					
III					
IV					
棉花 玉米 辣椒 果园 林地 其他					

4 讨论

本文基于 GF-2 影像数据,利用 Unet 模型识别了棉花和玉米等作物,并取得了较为理想的识别效果。国内外虽然在作物精细分类方面做了大量研究并取得了一定的成果^[27-29],但基于 GF-2 数据和 Unet 模型的干旱区棉花识别的研究相对较少。“渭库绿洲”在干旱区遥感应用研究领域具有一定代表性且为新疆重要的产棉区,本研究可为干旱区棉花信息提取提供新的思路。

从研究结果看,Unet 模型提取棉花的精度较高,这与马永建^[30]的研究结果一致,说明国产高分卫星和 Unet 模型方法在干旱区遥感棉花识别研究中效果较好。另外,本文利用的是 9 月中旬的 GF-2 影像,9 月中下旬为棉花识别最佳时期^[31],因此棉花得到了较好地识别效果。对于玉米 Unet 模型同样表现出了较高的识别精度,这是由于玉米属于高冠层密度作物^[32],与其他作物相比有更为细致的纹理特征,因此模型提取精度较高。对于辣椒 SVM 和 RF 的分类精度较低,与之相比 Unet 模型的精度则得到了一定的提高,这是由于辣椒与棉花、玉米光谱

特征相似,利用传统机器学习算法基于像元光谱特征识别辣椒,只能获取浅层特征从而影响识别精度。而 Unet 模型通过卷积运算可以充分利用 GF-2 影像高空间分辨率的优势,自主学习辣椒的深层次图像特征,因此其结果有了较高的提升。果树和林地的识别结果 4 种方法均表现较差,分析误差存在的原因,可能是研究区内林地与果树影像的纹理特征相似,进而影响了两者的提取精度。

另外,本文在 Unet 模型参数的调整需要进行多次的实验,本文中 choice Adam 算法优化器时,模型在训练集上的损失函数值下降最快并达到稳定状态,这与赵阳^[23]的研究结果一致,Adam 算法作为一种自适应算法,具有较快的收敛速度^[24]。深度学习模型的网络结构复杂、参数较多,其调试过程依赖操作经验和数次反复试验,这也在一定程度上降低了工作效率。本文 Unet 模型训练过程中验证集损失函数值曲线出现小幅度波动,原因可能是训练集和验证集比例为 9:1,验证集数量分配较少所引起。因此,不同比例的数据分配对模型训练的影响也是今后值得研究的内容。本研究中 Unet 模型对作物的提取结果虽然优于 SVM 和 RF 算法,但是只利用了 GF-2 影像 3 个波段的光谱特征,缺少对其他光谱

特征(如植被指数)的应用,可在以后的研究中构建多类植被指数^[33],以求获得更高精度的识别效果。

通过研究表明,深度学习方法应用于遥感影像作物识别具有较大的潜力,但作为一门新兴技术手段,需要进一步完善和提高。今后的研究中可以尝试多种深度学习模型提取作物信息,如 Deeplab V3^[32]和 Pspnet^[34]等。还可以尝试 CRF^[35-36]后处理方法优化分类结果以及引入集成学习^[37]的思想,将多种方法提取结果进行集成,从而提高作物分类的精度。

5 结论

1) Unet 模型对作物的分类精度较高,总体精度为 84.22%,相比面向对象、SVM 和 RF 算法提高了 7.94、11.93 和 11.73 百分点,Kappa 系数为 0.804 7,提高了 10.13%、14.72% 和 14.60%。

2) 从单个作物类别来看,Unet 模型对棉花的分类效果优于其他作物的识别效果。对于部分套种区域,Unet 模型能够挖掘作物图像的深层次特征,从而提升分类的准确性,较好识别套种作物,获取更精准的作物空间分布信息。

3) GF-2 影像高空间分辨率的优势配合 Unet 深度学习方法在干旱区作物遥感影像高精度识别研究中具有可行性和可靠性。

参考文献 (References):

- [1] 王文静. 基于多时相 Landsat8 数据的综合多特征棉田提取研究[D]. 徐州:中国矿业大学,2016.
Wang W J. Research on cottonfield extraction method of integrated multi-features based on multi-temporal Landsat8 image[D]. Xuzhou:China University of Mining and Technology,2016.
- [2] 王 玉. 基于时序光谱库的棉花种植面积信息提取研究[D]. 北京:中国地质大学(北京),2013.
Wang Y. Research on cotton planting areas extraction based on MODIS-EVI time-series data base[D]. Beijing:China University of Geosciences(Beijing),2013.
- [3] 张明伟. 基于 MODIS 数据的作物物候期监测及作物类型识别模式研究[D]. 武汉:华中农业大学,2006.
Zhang M W. Study on the method of crop phenology detection on and crop types discrimination based on MODIS data[D]. Wuhan:Huazhong Agricultural University,2006.
- [4] 张佳琪. 基于多源卫星遥感的昌吉市棉花种植面积信息提取研究[D]. 乌鲁木齐:新疆农业大学,2017.
Zhang J Q. Research on cotton planting areas extraction of Changji City based on multi-source satellite remote sensing image[D]. Urumqi:Xinjiang Agricultural University,2017.
- [5] 郝鹏宇. 基于多时相遥感数据的农作物分类研究[D]. 北京:中国科学院大学(中国科学院遥感与数字地球研究所),2017.
Hao P Y. Crop classification using time series remote sensing data[D]. Beijing:Institute of Remote Sensing and Digital Earth,Chinese Academy of Sciences,2017.
- [6] 马春玥. 基于遥感的新疆棉花种植面积时空变化及驱动力研究[D]. 乌鲁木齐:新疆大学,2020.
Ma C Y. Spatial-temporal changes and driving forces of cotton planting area in Xinjiang based on remote sensing[D]. Urumqi:Xinjiang University,2020.
- [7] 古丽努尔·依沙克,买买提·沙吾提,马春玥. 基于多时相双极化 SAR 数据的作物种植面积提取[J]. 作物学报,2020,46(7):1099-1111.
Gulnur I, Mamat S, Ma C Y. Extraction of crop acreage based on multi-temporal and dual-polarization SAR data[J]. Acta Agronomica Sinica,2020,46(7):1099-1111.
- [8] Mathur A, Foody G M. Crop classification by support vector machine with intelligently selected training data for an operational application[J]. International Journal of Remote Sensing,2008,29(7-8):2227-2240.
- [9] 贾 坤,李强子,田亦陈,等. 微波后向散射数据改进农作物光谱分类精度研究[J]. 光谱学与光谱分析,2011,31(2):483-487.
Jia K, Li Q Z, Tian Y C, et al. Accuracy improvement of spectral classification of crop using microwave backscatter data[J]. Spectroscopy and Spectral Analysis,2011,31(2):483-487.
- [10] 顾晓鹤,潘耀忠,何 馨,等. 以地块分类为核心的冬小麦种植面积遥感估算[J]. 遥感学报,2010,14(4):789-805.
Gu X H, Pan Y Z, He X, et al. Measurement of sown area of winter wheat based on per-field classification and remote sensing imagery[J]. Journal of Remote Sensing,2010,14(4):789-805.
- [11] 张雨果,王 飞,孙文义,等. 基于面向对象的 SPOT 卫星影像梯田信息提取研究[J]. 水土保持研究,2016,23(6):345-351.
Zhang Y G, Wang F, Sun W Y, et al. Terrace information extraction from SPOT remote sensing image based on object-oriented classification method[J]. Research of Soil and Water Conservation,2016,23(6):345-351.
- [12] Smith G M, Fuller R M. An integrated approach to land cover classification: An example in the island of Jersey[J]. International Journal of Remote Sensing,2001,22(16):3123-3142.
- [13] 黄健熙,侯裔焯,苏 伟,等. 基于 GF-1 WFV 数据的玉米与大豆种植面积提取方法[J]. 农业工程学报,2017,33(7):164-170.
Huang J X, Hou Y Z, Su W, et al. Mapping corn and soybean cropped area with GF-1 WFV data[J]. Transactions of the Chinese Society of Agricultural Engineering,2017,33(7):164-170.
- [14] 王霄煜,雷 钧. 基于高分一号卫星数据的新疆棉花种植面积信息提取研究[J]. 新疆农业科技,2021(1):23-26.
Wang X Y, Lei J. Research on the extraction of Xinjiang cotton planting area information based on Gaofen-1 satellite data[J]. Xinjiang Agricultural Science and Technology,2021(1):23-26.
- [15] 段春华,张 汛,尹 凡. 基于国产高分卫星影像的水稻种植区提取——以江苏苏中地区为例[J]. 卫星应用,2021(2):59-

64.
Duan C H, Zhang X, Yin F. Extraction of rice planting areas based on domestic high-resolution satellite images: A case study of Suzhong region[J]. *Satellite Application*, 2021(2): 59-64.
- [16] 徐知宇, 周艺, 王世新, 等. 面向 GF-2 遥感影像的 U-Net 城市绿地分类[J]. *中国图象图形学报*, 2021, 26(3): 700-713.
Xu Z Y, Zhou Y, Wang S X, et al. U-Net for urban green space classification in Gaofen-2 remote sensing images[J]. *Journal of Image and Graphics*, 2021, 26(3): 700-713.
- [17] 戴子兵. 基于语义分割的水稻病害检测技术[D]. 成都: 西华大学, 2020.
Dai Z B. Rice disease detection technology based on semantic segmentation[D]. Chengdu: Xihua University, 2020.
- [18] 李越帅, 郑宏伟, 罗格平, 等. 集成 U-Net 方法的无人机影像胡杨树树冠提取和计数[J]. *遥感技术与应用*, 2019, 34(5): 939-949.
Li Y S, Zheng H W, Luo G P, et al. Extraction and counting of populus euphratica crown using UAV images integrated with U-Net method[J]. *Remote Sensing Technology and Application*, 2019, 34(5): 939-949.
- [19] 刘玫岑. 基于遥感和 GIS 的棉花面积提取和产量估测研究[D]. 乌鲁木齐: 新疆农业大学, 2006.
Liu M C. The study on the extracting area and yield estimate of cotton based on RS and GIS[D]. Urumqi: Xinjiang Agricultural University, 2006.
- [20] 玉苏甫·买买提, 吐尔逊·艾山, 买合皮热提·吾拉木. 新疆渭一库绿洲棉花种植面积遥感监测研究[J]. *农业现代化研究*, 2014, 35(2): 240-243.
Yusup M, Tursun H, Magpirat G. Remote sensing of cotton plantation areas monitoring in delta oasis of Ugan-Kucha River, Xinjiang[J]. *Research of Agricultural Modernization*, 2014, 35(2): 240-243.
- [21] 樊湘鹏, 周建平, 许燕, 等. 基于优化 Faster R-CNN 的棉花苗期杂草识别与定位[J]. *农业机械学报*, 2021, 52(5): 26-34.
Fan X P, Zhou J P, Xu Y, et al. Identification and localization of weeds based on optimized Faster R-CNN in cotton seedling stage under natural conditions[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2021, 52(5): 26-34.
- [22] 闫帅. 基于深度学习的冰川提取方法研究[D]. 北京: 中国地质大学(北京), 2020.
Yan S. Research on glacier extraction algorithms based on data-driven deep learning[D]. Beijing: China University of Geosciences (Beijing), 2020.
- [23] 赵阳. 基于深度学习的遥感图像道路提取[D]. 西安: 西安电子科技大学, 2019.
Zhao Y. Remote sensing image road extraction based on deep learning[D]. Xi'an: Xidian University, 2019.
- [24] 单磊. 深度学习算法并行优化技术及应用研究[D]. 长沙: 国防科技大学, 2019.
Shan L. Research on parallel optimization for deep learning algorithms and applications[D]. Changsha: National University of Defense Technology, 2019.
- [25] 李哲. 基于高分二号遥感影像的树种分类研究[D]. 北京: 北京林业大学, 2020.
Li Z. Research on classification of tree species based on GF-2 [D]. Beijing: Beijing Forestry University, 2020.
- [26] 王俊强, 李建胜, 丁波, 等. 深度学习语义分割方法在遥感影像分割中的性能分析[J]. *计算机测量与控制*, 2019, 27(7): 231-235.
Wang J Q, Li J S, Ding B, et al. Performance analysis of semantic segmentation method based on deep learning in remote sensing image segmentation[J]. *Computer Measurement and Control*, 2019, 27(7): 231-235.
- [27] 何昭欣, 张森, 吴炳方, 等. Google Earth Engine 支持下的江苏省夏收作物遥感提取[J]. *地球信息科学学报*, 2019, 21(5): 752-766.
He Z X, Zhang M, Wu B F, et al. Extraction of summer crop in Jiangsu based on Google Earth Engine[J]. *Journal of Geo-information Science*, 2019, 21(5): 752-766.
- [28] Wei M F, Qiao B J, Zhao J H, et al. The area extraction of winter wheat in mixed planting area based on Sentinel-2 a remote sensing satellite images[J]. *International Journal of Parallel, Emergent and Distributed Systems*, 2020, 35(3): 297-308.
- [29] 张鹏, 胡守庚. 地块尺度的复杂种植区作物遥感精细分类[J]. *农业工程学报*, 2019, 35(20): 125-134.
Zhang P, Hu S G. Fine crop classification by remote sensing in complex planting areas based on field parcel[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2019, 35(20): 125-134.
- [30] 马永建. 基于 CNN 的高分辨率遥感影像典型农作物分类方法研究[D]. 石河子: 石河子大学, 2020.
Ma Y J. Study on typical crops classification with high-resolution remote sensing images based on CNN[D]. Shihezi: Shihezi University, 2020.
- [31] 曹卫彬, 杨邦杰, 宋金鹏. TM 影像中基于光谱特征的棉花识别模型[J]. *农业工程学报*, 2004(4): 112-116.
Cao W B, Yang B J, Song J P. Spectral information based model for cotton identification on Landsat TM image[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2004(4): 112-116.
- [32] 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 S Q, Song Z S, Yin H P, et al. Crop classification method of UVA multispectral remote sensing based on deep semantic segmentation[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2021, 52(3): 185-192.
- [33] 梁继, 郑镇炜, 夏诗婷, 等. 高分六号红边特征的农作物识别与评估[J]. *遥感学报*, 2020, 24(10): 1168-1179.
Liang J, Zheng Z W, Xia S T, et al. Crop recognition and evaluation using red edge features of GF-6 satellite[J]. *Journal of Remote Sensing*, 2020, 24(10): 1168-1179.
- [34] 刘钊, 廖斐凡, 赵桐. 基于 PSPNet 的遥感影像城市建成区提取及其优化方法[J]. *国土资源遥感*, 2020, 32(4): 84-89. doi:10.6046/gtzyyg. 2020. 04. 12.
Liu Z, Liao F F, Zhao T. Remote sensing image urban built-up area extraction and optimization method based on PSPNet[J]. *Re-*

- Remote Sensing for Land and Resources, 2020, 32(4): 84–89. doi: 10.6046/gtzyyg. 2020. 04. 12.
- [35] 师超, 姜琦刚, 段富治, 等. 基于 Unet + CRF 的 GF-2 土地利用分类[J]. 世界地质, 2021, 40(1): 146–153.
- Shi C, Jiang Q G, Duan F Z, et al. GF-2 landuse classification based on Unet + CRF[J]. Global Geology, 2021, 40(1): 146–153.
- [36] Zhong Y F, Hu X, Luo C, et al. WHU-Hi; UAV-borne hyperspectral with high spatial resolution (H2) benchmark datasets and classifier for precise crop identification based on deep convolutional neural network with CRF[J]. Remote Sensing of Environment, 2020, 250: 112012.
- [37] 张新长, 江鑫. 多深度神经网络集成的道路提取[J]. 地理信息世界, 2020, 27(6): 87–92.
- Zhang X C, Jiang X. Road extraction based on integration of multiple deep neural networks[J]. Geomatics World, 2020, 27(6): 87–92.

Recognition of cotton distribution based on GF-2 images and Unet model

ERPAN Anwar¹, MAMAT Sawut^{1,2,3}, MAIHEMUTI Balati^{1,2,3}

(1. College of Geography and Remote Sensing Sciences, Xinjiang University, Urumqi 830046, China; 2. Xinjiang Key Laboratory of Oasis Ecology, Xinjiang University, Urumqi 830046, China; 3. Key Laboratory for Smart City and Environment Modelling of Higher Education Institute, Xinjiang University, Urumqi 830046, China)

Abstract: The typical crop cotton in the Ugan-Kuqa River Delta Oasis was used as the research object to study the applicability and optimization process of the deep learning method in the identification of cotton distribution in arid areas. Based on the domestic GF-2 images and the field survey data, the Unet deep learning method was adopted, in which the characteristics of the Unet network's multiple convolution operations were fully utilized to explore the deep-level characteristics of cotton in remote sensing images, thereby improving the precision of cotton extraction. The results show that the recognition effect of the Unet model to extract cotton, corn, and peppers in the study area is better than the classification results of the object-oriented method and the traditional machine learning algorithms. The overall precision is 84.22%, and the Kappa coefficient is 0.8047. Compared with the object-oriented method and the traditional machine learning algorithms SVM and RF, the overall precision has increased by 7.94 percentage points, 11.93 percentage points, and 11.73 percentage points, respectively, and the Kappa coefficient has increased by 10.13%, 14.72%, and 14.60%, respectively. In the classification results of the Unet model, both the mapping precision and the user precision of cotton are higher than those of the other three methods, which are 94.95% and 89.07%, respectively. Therefore, it is feasible and reliable to use the Unet model to extract high-precision cotton spatial distribution information of arid areas on GF-2 high-resolution remote sensing images.

Keywords: deep learning; cotton recognition; Unet model; GF-2 images

(责任编辑: 陈理)