

doi:10.6041/j.issn.1000-1298.2023.05.016

基于 U-Net 网络的高标准农田道路识别方法

袁翠霞¹ 赵春江^{1,2} 任艳敏^{1,2} 刘玉^{1,2} 李淑华^{1,2} 李少帅³(1. 北京市农林科学院信息技术研究中心, 北京 100097; 2. 国家农业信息化工程技术研究中心, 北京 100097;
3. 自然资源部国土整治中心, 北京 100035)

摘要: 高标准农田是国家粮食安全的重要保障, 作为其中的重要工程, 田间道路的快速准确获取可为高标准农田建设质量评估和效果评价提供基础数据支撑。针对传统方法对细窄田间道路识别精度低、泛化能力不强的问题, 本文提出了基于 U-Net 网络的高标准农田道路识别方法。首先, 在分析田间道路基本特征的基础上, 选取 GF-2 影像作为试验数据, 采用面向对象方法对影像进行分割并根据对象特征进行分类, 剔除光谱特征与田间道路相似的建筑物等非道路要素, 减少道路识别干扰; 然后, 对影像进行裁剪、标签制作和数据增强等操作, 并使用 U-Net 网络挖掘影像的深浅层特征, 通过不断调整参数对网络进行训练, 实现田间道路的快速识别; 最后, 依据道路断点特征, 采用局部连接法对道路断点进行修复, 并以河北省定州市东亭镇为试验区进行方法测算与精度验证。结果表明: 通过挖掘 622 幅田间道路样本的影像特征, U-Net 网络可以有效识别各类场景下的高标准农田道路, 通过对道路断点进行修复后, 研究区田间道路识别精确率达 96%, 召回率和 F1 值分别为 62%、75%, 该识别精度能够满足高标准农田建设质量快速评估要求。相比传统识别方法, 结合面向对象和深度学习的方法可以在减少建筑物干扰的基础上快速地识别出田间道路, 能更好解决田间道路材质差异大、植被遮挡等造成识别结果噪声多、误识别问题, 该方法可为细窄地物的识别提供方法参考。

关键词: 田间道路; 识别; 深度学习; U-Net; 面向对象; 高标准农田

中图分类号: TP75 文献标识码: A 文章编号: 1000-1298(2023)05-0163-07

OSID:



Recognition Method of High-standard Farmland Road Based on U-Net

YUAN Cuixia¹ ZHAO Chunjiang^{1,2} REN Yanmin^{1,2} LIU Yu^{1,2} LI Shuhua^{1,2} LI Shaoshuai³(1. Research Center of Information Technology, Beijing Academy of Agriculture and Forestry Sciences, Beijing 100097, China
2. National Engineering Research Center for Information Technology in Agriculture, Beijing 100097, China
3. Land Consolidation and Rehabilitation Center, Ministry of Natural Resources, Beijing 100035, China)

Abstract: High-standard farmland construction is an important guarantee for national food security, and the quality assessment of high-standard farmland construction is beneficial to the implementation of farmland planning and government decision-making. As an important project of high-standard farmland construction, the rapid and accurate acquisition of field roads can provide basic data support for the quality assessment and effect evaluation of high-standard farmland construction. Thus, it is necessary to obtain accurate and effective field roads information. However, compared with high-grade roads, the narrow pavement width and easy occlusion by vegetation are the typical characteristics of field roads, which are the main factors leading to the low degree of automation in existing methods. Aiming at the problems of low accuracy and weak generalization ability of traditional recognition methods for narrow field roads, a high-standard farmland road recognition method was proposed based on U-Net network. Firstly, on the basis of analyzing the basic characteristics of the field roads, the GF-2 images were selected as the experimental data, and the object-oriented method was used to segment the image and classify it according to the characteristics of the object, so as to eliminate non-roads such as buildings with similar spectra elements to reduce interference; then, operations such as cropping, labeling, and

收稿日期: 2022-09-08 修回日期: 2022-10-11

基金项目: 北京市农林科学院青年基金项目(QNJJ202232)、北京市农林科学院农业农村部农业遥感机理与定量遥感重点实验室建设项目(PT2023-26)和自然资源部国土卫星遥感应用重点实验室开放基金项目(KLSMNR-202205)

作者简介: 袁翠霞(1997—), 女, 研究实习员, 主要从事农田信息识别研究, E-mail: 2301984508@qq.com

通信作者: 任艳敏(1984—), 女, 高级工程师, 博士, 主要从事耕地质量调查监测和评价规划研究, E-mail: renym@nercita.org.cn

data enhancement were performed on the image, the U-Net network was used to mine the deep and shallow features of the image, and the network was continuously trained by adjusting parameters to achieve accurate identification of field roads; finally, according to the characteristics of road breakpoints, the local connection method was used to repair the road breakpoints, and the accuracy verification were carried out in Dongting Town, Dingzhou City, Hebei Province as the experimental area. The results showed that by mining the image features of 622 field road samples, the U-Net network could effectively identify high-standard farmland roads in various scenarios. After repairing the road breakpoints, the field road identification precision in the study area reached 96%, and the recall and F1 score were 62% and 75%, respectively. The recognition accuracy could meet the requirements for rapid evaluation of high-standard farmland construction quality. Compared with traditional identification methods, the combination of object-oriented and deep learning methods could quickly identify field roads on the basis of reducing building interference, and could better solve the noise and misidentification issues caused by large differences in field road materials and vegetation occlusion. This method could provide a method reference for the identification of narrow objects in farmland.

Key words: field roads; recognition; deep learning; U-Net; object oriented; high-standard farmland

0 引言

高标准农田建设是巩固和提高粮食生产能力、保障国家粮食安全的关键,得到高度重视^[1]。作为高标准农田建设的重要工程,田间道路的快速准确获取是高标准农田建设质量评价和成效评估的关键^[2]。高标准农田道路包含机耕路和生产路,其中机耕路宽度一般为3~6 m,生产路宽度不宜超过3 m^[3],在空间分辨率优于1 m的高分辨率影像中,高标准农田道路也仅表现为几个像元宽度;加上易受道路两侧作物或防护林遮挡,导致识别精度不高,且易出现断点。在全国大规模推进高标准农田建设的背景下,如何快速准确获取田间道路,为高标准农田建设质量评估提供基础数据支撑,具有较强的实用性和紧迫性^[4]。

目前,围绕道路识别研究已形成3大类方法:
①基于像元的方法,主要根据像元的光谱特征进行道路识别。该方法识别速度较快,且不受人为因素影响;但由于方法侧重关注像元本身的特征,导致无法感知影像的整体信息,且易与周围光谱相似的地物造成混分,出现“椒盐现象”^[5-6]。
②基于面向对象的方法,即在对象分割的基础上选取相关特征对道路进行识别,可在一定程度上减少“椒盐现象”,但识别出的道路易与周围地物粘连,导致边缘不够平滑^[7-8]。
③基于深度学习的方法,是近年来热门的影像信息识别方法^[9],能够从原始的像素特征到抽象的语义特征逐层提取信息,具有识别速度快、精度高的突出优点,已广泛应用在道路识别研究中^[10]。由于道路两侧植被遮挡以及建筑物阴影的影响,直接应用FCN^[11]、U-Net^[12]、SegNet^[13]、LinkNet^[14]、DeepLab^[15]等代表性网络难以识别被遮挡的道路。ZHOU等^[16]在LinkNet网络的基础上加

入膨胀卷积构建了D-LinkNet网络,可以减轻一般网络池化层下采样降低图像分辨率导致图像信息损失的问题。ZHU等^[17]提出了一种融合全局上下文感知模块的网络模型,解决图像卷积运算时集中关注局部信息导致忽略图像的全局特征以及像元间空间关系的问题。李朝奎等^[18]提出结合空洞卷积和ASPP结构的网络模型DC-Net用于提取农村道路,在精度、道路连结性等提取结果较好。除识别方法外,以往的研究对象主要集中在高级别城市道路^[17,19-20]、农村道路领域^[21-22],对于宽度较窄、易受植被遮挡、光谱特征不够明显的高标准农田道路的识别研究较少。

本文基于高分辨率遥感影像,充分利用面向对象和深度学习方法的优势,在剔除非田间道路要素的基础上,充分挖掘影像的深浅层特征,构建高标准农田道路快速识别方法,用于高标准农田建设质量评估和耕地质量评价,为细窄地物的识别提供方法参考。

1 研究思路与方法

1.1 研究思路

高标准农田区域包含农田、田间道路、沟渠、防护林等多种要素。为提高田间道路的识别精度,本文采用面向对象方法在剔除非田间道路要素的基础上,利用U-Net网络的深度学习方法挖掘影像的深浅层特征,开展高标准农田道路的快速识别。具体步骤包括:①选择适宜精度的高分辨率遥感影像,并对影像进行辐射校正、几何校正等处理,获取高标准农田项目区基础底图。②制作田间道路样本数据集,并利用面向对象方法去除光谱特征与田间道路相似的建筑物等地类。③构建U-Net的深度学习网络模型,并进行网络参数设置与模型训练,最后提

取出区域内所有田间道路。④对识别结果中的道路断点进行修复,直到结果精度达到预期。技术路线如图1所示。

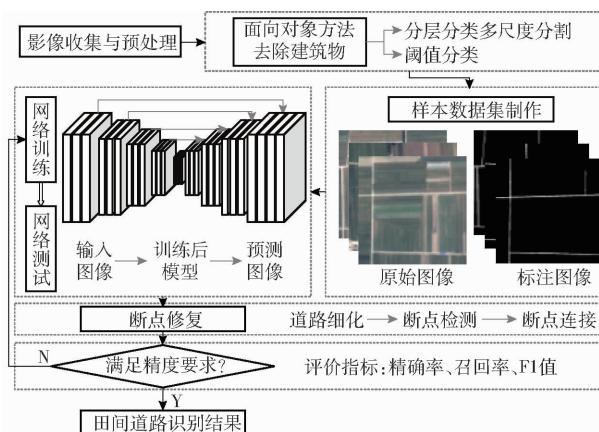


图1 技术路线图

Fig. 1 Technological roadmap

1.2 面向对象方法

采用面向对象方法剔除高标准农田项目区的建筑物等非田间道路要素,主要包括影像分割、特征计算和对象分类等步骤^[23]:①影像分割。影像分割是对象分类的基础,本文采用多尺度分割方法,通过像元与像元间的相似性逐一合并相邻像元,并根据地物大小进行不同尺度分割,实现分割后对象内部的异质性最小^[24]。②特征计算。影像特征包括光谱特征、几何特征、纹理特征等,本文主要利用光谱反射率、归一化差异植被指数(Normalized difference vegetation index, NDVI)和形状指数等影像特征,区分出区域建筑物、道路等要素。③对象分类。在特

征计算的基础上,结合阈值分类和决策树分类方法构建不同要素分类规则,去除建筑物等非道路要素。

1.3 U-Net网络

U-Net网络是对FCN(全卷积网络)的改进^[12],最早用于生物和医学图像的分割,可以充分利用图像深浅层特征,基于少量样本数据实现目标的准确快速提取^[25]。U-Net网络由输入层、卷积层、池化层、激活函数和输出层组成,是一种对称的U形网络结构,适用于语义简单、边界不清晰的图像分割任务^[26]。网络左侧为编码层,用于对图像进行下采样提取图像特征;右侧为解码层,用于图像上采样还原图像尺寸,通过上下连接识别出不同尺度图像要素。

1.3.1 编码层

U-Net编码层包含5个模块,每个模块由2个卷积层、1个最大池化层、1个批规范化层(Batch normalization, BN)^[27]和1个ReLU激活函数构成(表1)。其中,卷积层采用相同填充,使得卷积后图像尺寸保持不变;每2个卷积层后接1个池化层,用于减小网络参数的数量规模,缓解过拟合现象;批规范化层是对数据进行归一化处理,以加快网络收敛速度,解决梯度消失问题,提高网络泛化能力;ReLU激活函数是将神经元的输入映射到输出端,便于深层神经网络的构建,增强神经网络的学习能力,表达式为

$$\text{ReLU}(x) = \max(0, x) \quad (1)$$

式中 x ——图像特征输入值

表1 编码层结构信息

Tab. 1 Information of encoding layer structure

编码层	输入	输出	类型	核大小	步长	Padding	结构数量
Encoder1	512×512×3	512×512×64	Conv	3×3	1	1	2
	512×512×64	256×256×64	Maxpooling	2×2	1	0	1
Encoder2	256×256×64	256×256×128	Conv	3×3	1	1	2
	256×256×128	128×128×128	Maxpooling	2×2	1	0	1
Encoder3	128×128×128	128×128×256	Conv	3×3	1	1	2
	128×128×256	64×64×256	Maxpooling	2×2	1	0	1
Encoder4	64×64×256	64×64×512	Conv	3×3	1	1	2
	64×64×512	32×32×512	Maxpooling	2×2	1	0	1
Encoder5	32×32×512	32×32×1024	Conv	3×3	1	1	2

1.3.2 解码层

解码层包含5个不同尺度的模块,每个模块包含1个反卷积和2个卷积,用于恢复图像原始尺寸,每个模块结构信息如表2所示。为弥补经过编码层分辨率下降后丢失了的部分浅层特征,解码层通过跳跃连接与下采样5个尺度特征进行融合,提取图像中的深层语义特征。为得到田间道路和背景值的

二值图像,采用1×1卷积输出1个通道图像。由于田间道路分割属于二分类任务,因此使用Sigmoid激活函数作为分类器将神经网络训练结果转换为像元点所属类别的概率图,最终设置阈值为0.5,实现道路二值图像输出。Sigmoid激活函数表达式为

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

表 2 解码层结构信息

Tab. 2 Information of decoding layer structure

解码层	输入	输出	类型	核大小	步长	Padding	结构数量
Decoder1	$32 \times 32 \times 1024$	$64 \times 64 \times 1024$	Trans-Conv	3×3	1	1	1
	$64 \times 64 \times 1024$	$64 \times 64 \times 512$	Conv	3×3	1	1	2
Decoder2	$64 \times 64 \times 512$	$128 \times 128 \times 512$	Trans-Conv	3×3	1	1	1
	$128 \times 128 \times 512$	$128 \times 128 \times 256$	Conv	3×3	1	1	2
Decoder3	$128 \times 128 \times 256$	$256 \times 256 \times 256$	Trans-Conv	3×3	1	1	1
	$256 \times 256 \times 256$	$256 \times 256 \times 128$	Conv	3×3	1	1	2
Decoder4	$256 \times 256 \times 128$	$512 \times 512 \times 128$	Trans-Conv	3×3	1	1	1
	$512 \times 512 \times 128$	$512 \times 512 \times 64$	Conv	3×3	1	1	2
Decoder5	$512 \times 512 \times 64$	$512 \times 512 \times 2$	Conv	3×3	1	1	1
	$512 \times 512 \times 2$	$512 \times 512 \times 1$	Conv	1×1	1	0	1

1.4 道路断点修复

为提高田间道路识别精度,需要对识别结果中的道路断点进行修复。由于断点与所在田间道路的走向在相近角度内,因此首先采用八邻域算法识别出道路断点,然后采用局部连接法对断点进行修复。八邻域算法采用 3×3 的矩形对影像像元点进行遍历,根据矩阵中心点与其相邻像元点的相对位置进行断点判别^[28],具体判别标准如图2所示^[25],其中1代表道路,0代表背景。局部连接方法是以断点为中心点,向其所在直线方向进行延伸,对满足一定距离和方向的断点进行连接,形成连续的道路网。

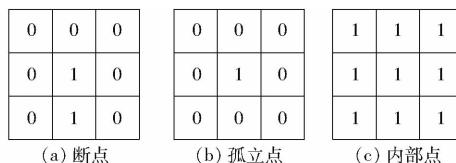


图 2 断点判别示意图

Fig. 2 Schematics of breakpoint discrimination

2 数据来源与模型训练

2.1 数据来源与预处理

田间道路在南北方的不同地貌类型区分布特征差异较大,本文选取北方平原区的河北省定州市附近高标准农田集中分布区域开展数据采集,并在东亭镇进行方法实证分析(图3)。东亭镇地处华北平原,属冲积平原,地面平坦开阔;区域土地总面积为 49.17 km^2 ,大部分耕地已实施高标准农田建设,田块多呈南北走向,道路纵横分布,密度合理,耕作便利;农业生产以小麦、玉米为主,一年两熟,5月底、6月初为小麦收获期。为减少两侧植被对田间道路的遮挡,影像选取日期定在6—7月。

高分二号(GF-2)卫星是我国自主研制的首颗空间分辨率优于1 m的民用光学遥感卫星,搭载有2台高分辨率1 m全色、4 m多光谱相机,具有亚米级空间分辨率、高定位精度和快速姿态机动能力等

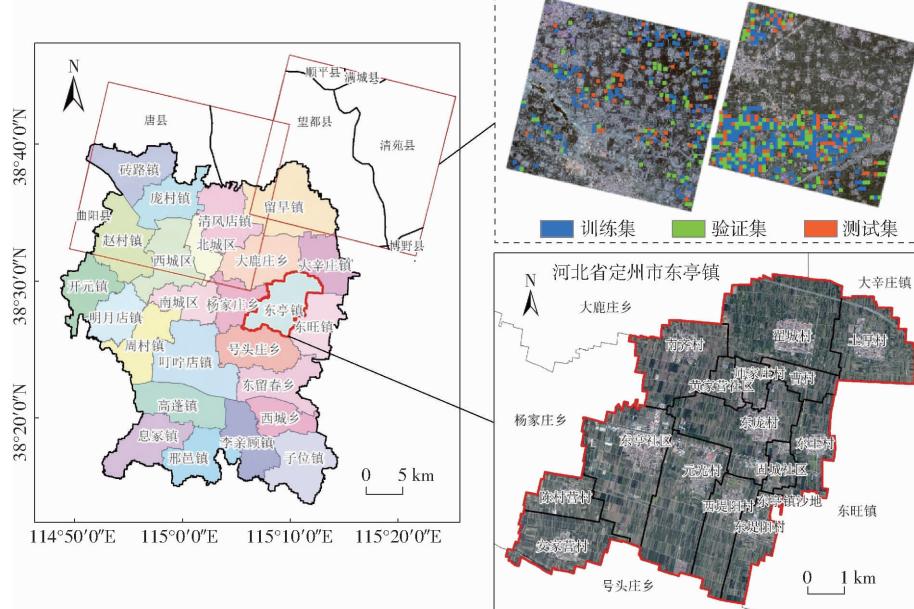


图 3 河北省定州市东亭镇位置与样本分布示意图

Fig. 3 Schematic of sample distribution and location of Dongting Town, Dingzhou City, Hebei Province

特点。本文选用高分二号影像作为基础数据来源,日期为 2020 年 6 月。影像预处理包括几何校正和辐射校正,配准后的影像均方根误差为 0.37 个像元,融合后的影像分辨率为 1 m,有红、绿、蓝、近红外 4 个波段。

2.2 样本标注与增强

田间道路样本标注通过 ArcGIS 软件操作实现,其中田间道路像素值设置为 255,背景值设置为 0。为满足 U-Net 网络输入要求,将影像和标注图分别裁剪成 512 像素 \times 512 像素,经过初步筛选最终获得 622 幅原始影像和对应的标注图(图 4)。以数量比例 5:3:2 划分样本数据,其中训练集 310 幅、验证集 186 幅、测试集 126 幅。影像中包含了建筑物、田块、裸地、大棚、田间道路等地物。其中,田间道路在影像中仅占据 3~6 个像元宽度,且部分道路被树木遮挡,为道路的准确提取带来困难。为避免网络训练过程中出现过拟合现象,在训练过程中使用旋转、缩放、镜像、添加高斯噪声等操作对训练数据和验证数据进行在线随机变换实现数据增强。

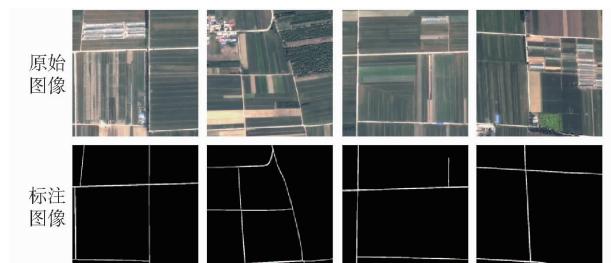


图 4 部分原始图像与对应的标注图像

Fig. 4 Some original images and corresponding labeled images

2.3 参数设置与网络训练

实验在 Windows 10 操作系统中进行,开发语言环境为 Anaconda 3 和 Python 3.8,CPU 和 GPU 配置分别为 Intel(R) Xeon(R) W-2150B 和 NVIDIA GeForce RTX 3070,深度学习框架为 PyTorch。网络训练将初始学习率设置为 1×10^{-5} ,将训练集样本每 2 幅影像作为一个批次(batch)输入网络中进行训练,训练一共进行 100 个周期迭代循环。在训练过程中,设置损失值为监测值,当连续 10 个周期损失值没有降低便将学习率下降 1/10,以便收敛到目标函数最优值。

为了解决影像中道路与背景类别占比不平衡问题,在使用二值交叉熵(Binary cross entropy, BCE)函数的基础上引入 Dice Loss 损失函数作为本文损失函数 Loss,计算公式为

$$Loss = B_{Loss} + D_{Loss} \quad (3)$$

其中

$$B_{Loss} = -\frac{1}{N} [y_i \lg \hat{y}_i + (1 - y_i) \lg (1 - \hat{y}_i)] \quad (4)$$

$$D_{Loss} = 1 - \frac{2|X \cap Y|}{|X| + |Y|} \quad (5)$$

式中 N ——像元个数

y_i ——像元 i 的真实像素值

\hat{y}_i ——像元 i 的预测像素值

X ——预测值像元点集

Y ——真实值像元点集

B_{Loss} ——BCE 损失函数

D_{Loss} ——Dice Loss 损失函数

损失值越低,表明预测结果与实际结果越接近,识别精度越高。由于自适应矩估计优化算法(Adaptive moment estimation, Adam)^[29]是通过计算梯度的一阶和二阶矩估计自适应调整每个参数的学习率,具有实现简单、计算效率高、内存需求小等优点,本文采用 Adam 优化算法对网络参数进行训练和优化。

利用 U-Net 网络对田间道路数据进行训练,训练损失值及验证精度变化如图 5 所示。随着迭代次数的增加,网络损失不断下降,同时精度也在不断提升;在经过 100 个周期后,训练损失值稳定在 0.035 左右,验证精度稳定在 86.6% 左右。

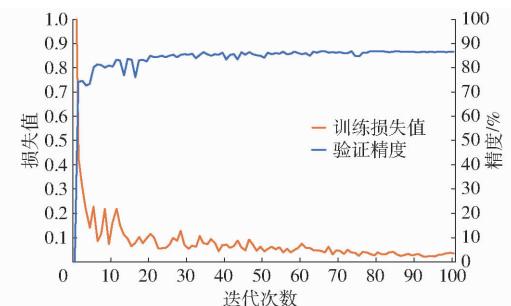


图 5 训练损失值及验证精度变化曲线

Fig. 5 Training loss and validation accuracy change

3 结果分析与精度验证

3.1 非田间道路剔除结果

为剔除光谱特征与田间道路相似的研究区建筑物,在影像预处理的基础上,采用面向对象方法的多尺度分割工具对影像进行分割,并分别采集建筑和非建筑对象样本,分析不同类型样本的光谱均值、形状指数、长宽比等参数,基于对象样本特征的分析构建分类规则集,最终实现建筑物非田间道路的去除。研究区土地总面积为 49.17 km²,剔除的建筑物面积约 7.16 km²,占研究区土地总面积的 14.56%;剩余待检测区为 42.01 km²,占研究区土地总面积的 85.44%。

3.2 田间道路识别结果

利用构建的 U-Net 网络对待监测区域的田间道路进行识别运算, 结果如图 6 所示。利用 U-Net 网络提取的田间道路边缘平滑, 噪声较少; 通过与标注结果比对发现, 道路走势与实际道路接近, 整体精度较高。从空间分布看, 东亭社区中部、东堤阳村的道路基本被识别, 且识别的道路连通性较好, 而元光村南部、翟城村西部等地识别出的田间道路断点较多, 几乎形不成道路网。通过分析区域影像可知, 被

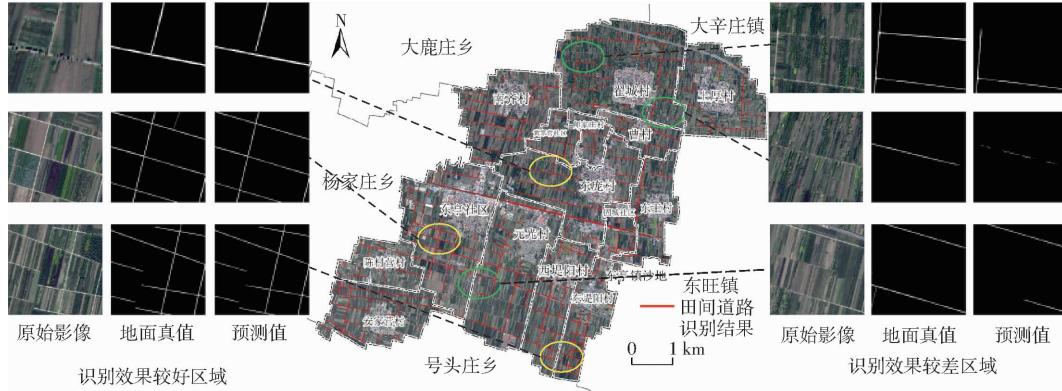


图 6 高标准农田道路识别结果

Fig. 6 Result of high-standard farmland road recognition

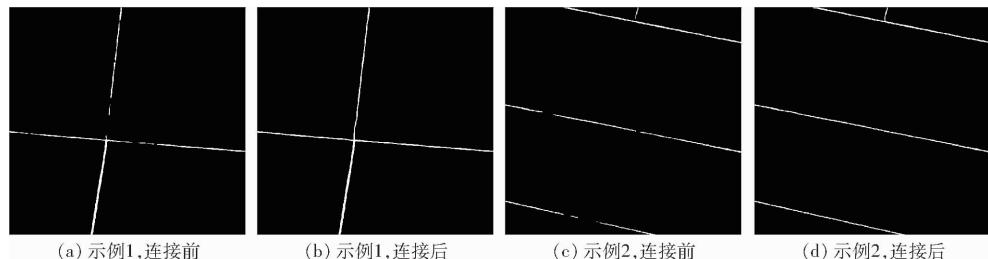


图 7 高标准农田道路断点连接效果对比

Fig. 7 Example diagrams of high-standard farmland road breakpoint connection effect comparison

3.3 识别结果精度验证

为全面有效地评价识别结果, 采用精确率 (Precision)、召回率 (Recall)、F1 值 (F1 score) 3 个指标^[30]对识别精度进行验证。其中, 精确率指正确识别的道路像元数占所有被识别为道路像元数的比率, 反映道路识别的精确程度; 召回率指正确识别的道路像元数占实际道路像元数的比率, 反映道路识别的完整性; F1 值为同时考虑精确率和召回率的综合指标, 当精确率和召回率同时都很高时, F1 值才会取得很高的分数。

研究区内田间道路总像元数为 103 809 024, 其中正确识别的道路像元数为 473 587, 错误识别的道路像元数为 18 335, 漏识别的道路像元数为 295 887。采用以上 3 个评价指标进行计算, 最终得到精确率为 96%, 召回率、F1 值分别为 62%、75%, 该结果精度可以满足高标准农田建设质量快速评估要求。

正确识别的田间道路多位于居民点周边或位于耕地集中连片区, 该区域的道路一般较为宽阔、硬化程度高且无植被遮挡, 因此误识别的像元数较少, 精度较高; 相反, 位于耕地分布零散区的田间道路, 本身多属于硬化程度不高的生产路, 区域背景复杂, 易受两侧植被遮挡, 路面光谱特征不明显, 导致识别的道路完整性较差、断点较多。因此, 本文借助八邻域算法在识别断点的基础上, 采用局部连接法对断点进行修复, 提高道路连通性, 从整体上提升道路识别精度(图 7)。

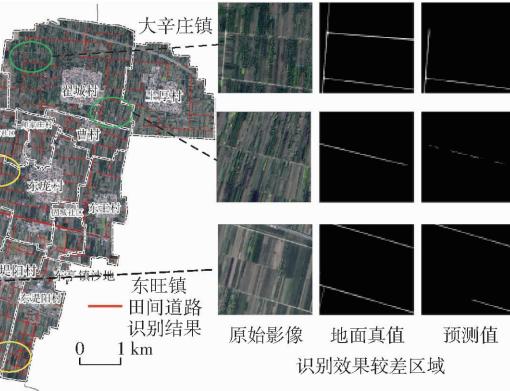


图 6 高标准农田道路识别结果

Fig. 6 Result of high-standard farmland road recognition

3.4 讨论

本文提出的基于面向对象和深度学习的高标准农田道路识别方法虽然在一定程度上能满足高标准农田建设质量效果评估需要, 但因受限于影像空间分辨率, 宽度较小、硬化程度不高的生产路识别结果精度还不理想, 未来需要寻求更高分辨率的影像实现高标准农田道路的全要素精确识别。另外, U-Net 网络虽在道路识别方面发挥一定优势, 但由于网络参数量较多, 模型训练时间较长, 后续将探讨轻量级神经网络在田间道路识别中的应用, 在保证识别精度的同时提高识别效率。

4 结论

(1) 采用面向对象方法, 可以有效去除建筑物、农田等非田间道路要素信息, 减少其对道路识别的影响。

(2)采用U-Net网络的深度学习方法,能充分利用影像的深浅层特征,基于有限样本(622幅图像)实现田间道路的快速识别。

(3)针对识别出的道路断点问题,局部连接法可有效进行连接修复,最终识别结果精确率达到96%,召回率、F1值分别为62%、75%。

参 考 文 献

- [1] 王珂,李玲,黎鹏. 基于生态安全和粮食安全的高标准农田建设研究[J]. 生态与农村环境学报, 2021,37(6): 706–713.
WANG Ke, LI Ling, LI Peng. Study on high-standard farmland construction based on ecological security and food security [J]. Journal of Ecology and Rural Environment, 2021,37(6): 706–713. (in Chinese)
- [2] 马雪莹,邵景安,曹飞. 重庆山区县域高标准基本农田建设综合成效评估——以重庆市垫江县为例[J]. 自然资源学报, 2018,33(12): 2183–2199.
MA Xueying, SHAO Jing'an, CAO Fei. Comprehensive performance evaluation of high standard farmland construction in mountainous counties—a case study in Dianjiang, Chongqing [J]. Journal of Natural Resources, 2018,33(12): 2183–2199. (in Chinese)
- [3] 国家市场监督管理总局,国家标准化管理委员会. 高标准农田建设通则:GB/T 30600—2022[S]. 北京: 中国标准出版社, 2022.
- [4] 戴激光,王晓桐,智新宇,等. 动态权重约束下的农村机耕路提取方法[J]. 地球信息科学学报, 2021,23(5): 773–784.
DAI Jiguang, WANG Xiaotong, ZHI Xinyu, et al. An extraction method of rural mechanically cultivated road under dynamic weight constraint [J]. Journal of Geo-information Science, 2021,23(5): 773–784. (in Chinese)
- [5] 黄巍,黄辉先,徐建闽,等. 基于Canny边缘检测思想的改进遥感影像道路提取方法[J]. 国土资源遥感, 2019,31(1): 65–70.
HUANG Wei, HUANG Huixian, XU Jianmin, et al. An improved road extraction method for remote sensing images based on Canny edge detection [J]. Remote Sensing for Land and Resources, 2019,31(1): 65–70. (in Chinese)
- [6] DAI J, ZHU T, ZHANG Y, et al. Lane-level road extraction from high-resolution optical satellite images[J]. Remote Sensing, 2019,11(22): 2672.
- [7] 金静,党建武,王阳萍,等. 面向对象的高分辨率遥感影像道路提取算法[J]. 兰州交通大学学报, 2017,36(1): 57–61.
JIN Jing, DANG Jianwu, WANG Yangping, et al. Research on object oriented algorithm for road extraction in high-resolution remote sensing image [J]. Journal of Lanzhou Jiaotong University, 2017,36(1): 57–61. (in Chinese)
- [8] MIAO Z, SHI W, ZHANG H, et al. Road centerline extraction from high-resolution imagery based on shape features and multivariate adaptive regression splines[J]. IEEE Geoscience and Remote Sensing Letters, 2013,10(3): 583–587.
- [9] 张永宏,何静,阚希,等. 遥感图像道路提取方法综述[J]. 计算机工程与应用, 2018,54(13): 1–10.
ZHANG Yonghong, HE Jing, KAN Xi, et al. Summary of road extraction methods for remote sensing images [J]. Computer Engineering and Applications, 2018,54(13): 1–10. (in Chinese)
- [10] 陈振,陈芸芝,吴婷,等. 面向高分遥感影像道路提取的轻量级双注意力和特征补偿残差网络模型[J]. 地球信息科学学报, 2022,24(5): 949–961.
CHEN Zhen, CHEN Yunzhi, WU Ting, et al. A lightweight dual attention and feature compensated residual network model for road extraction from high-resolution remote sensing images [J]. Journal of Geo-information Science, 2022,24(5): 949–961. (in Chinese)
- [11] 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.
- [12] 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, 2015.
- [13] BADRINARAYANAN V, KENDALL A, CIPOLLA R. SegNet: a deep convolutional encoder-decoder architecture for image segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017,39(12): 2481–2495.
- [14] CHAURASIA A, CULURCIELLO E. LinkNet: exploiting encoder representations for efficient semantic segmentation [C] // 2017 IEEE Visual Communications and Image Processing, 2017.
- [15] CHEN L, 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, 2018, 40(4): 834–848.
- [16] ZHOU L, ZHANG C, WU M. D-LinkNet: LinkNet with pretrained encoder and dilated convolution for high resolution satellite imagery road extraction [C] // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), 2018.
- [17] ZHU Q, ZHANG Y, WANG L, et al. A global context-aware and batch-independent network for road extraction from VHR satellite imagery [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2021,175: 353–365.
- [18] 李朝奎,曾强国,方军,等. 改进全卷积网络方法的高分二号影像农村道路提取[J]. 遥感学报, 2021,25(9): 1978–1988.
LI Chaokui, ZENG Qiangguo, FANG Jun, et al. Road extraction in rural areas from high resolution remote sensing image using a improved full convolution network [J]. National Remote Sensing Bulletin, 2021,25(9): 1978–1988. (in Chinese)

- [17] RUSSELL B C, TORRALBA A, MUROHY K P, et al. LabelMe: a database and web-based tool for image annotation [J]. International Journal of Computer Vision, 2008, 77(1–3): 157–173.
- [18] RONNEBERGER O, FISCHER P, BROX T. U–Net: convolutional networks for biomedical image segmentation [C] // Medical Image Computing and Computer-Assisted Intervention (MICCAI), 2015: 234–241.
- [19] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [C] // Advances in Neural Information Processing Systems, 2017: 5998–6008.
- [20] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module [C] // European Conference on Computer Vision (ECCV), 2018: 3–19.
- [21] WANG X, IRSICK R, GUPTA A, et al. Non-local neural networks [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7794–7803.
- [22] FU J, LIU J, TIAN H, et al. Dual attention network for scene segmentation [C] // IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2020: 3141–3149.
- [23] JIE H, LI S, GANG S, et al. Squeeze-and-excitation networks [C] // IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2018: 7132–7141.
- [24] FFARAHNNK-GHAZANI F, BAGHSHAH M S. Multi-label classification with feature-aware implicit encoding and generalized cross-entropy loss [C] // 24th Iranian Conference on Electrical Engineering (ICEE), 2016: 1574–1579.
- [25] HEIDLER K, MOU L C, BAUMHOER C, et al. HED–UNet: a multi-scale framework for simultaneous segmentation and edge detection [C] // International Geoscience and Remote Sensing Symposium (IGARSS), 2021: 3033–3040.
- [26] HE K, ZHANG X, REN S, et al. Delving deep into rectifiers: surpassing human-level performance on imagenet classification [C] // IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2015: 1026–1034.

(上接第 169 页)

- [19] BATRA A, SINGH S, PANG G, et al. Improved road connectivity by joint learning of orientation and segmentation [C] // 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2019.
- [20] ZHANG X, HAN X, LI C, et al. Aerial image road extraction based on an improved generative adversarial network [J]. Remote Sensing, 2019, 11(8): 930.
- [21] DAI J, MA R, AI H. Semi-automatic extraction of rural roads from high-resolution remote sensing images based on a multifeature combination [J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 1–5.
- [22] TAN H, SHEN Z, DAI J. Semi-automatic extraction of rural roads under the constraint of combined geometric and texture features [J]. ISPRS International Journal of Geo-Information, 2021, 10(11): 754.
- [23] 韩文霆, 张立元, 张海鑫, 等. 基于无人机遥感与面向对象法的田间渠系分布信息提取 [J]. 农业机械学报, 2017, 48(3): 205–214.
HAN Wenting, ZHANG Liyuan, ZHANG Haixin, et al. Extraction method of sublateral canal distribution information based on UAV remote sensing [J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(3): 205–214. (in Chinese)
- [24] 李前景, 刘珺, 米晓飞, 等. 面向对象与卷积神经网络模型的 GF–6 WFV 影像作物分类 [J]. 遥感学报, 2021, 25(2): 549–558.
LI Qianjing, LIU Jun, MI Xiaofei, et al. Object-oriented crop classification for GF–6 WFV remote sensing images based on convolutional neural network [J]. National Remote Sensing Bulletin, 2021, 25(2): 549–558. (in Chinese)
- [25] 王斌, 陈占龙, 吴亮, 等. 兼顾连通性的 U–Net 网络高分辨率遥感影像道路提取 [J]. 遥感学报, 2020, 24(12): 1488–1499.
WANG Bin, CHEN Zhanlong, WU Liang, et al. Road extraction of high-resolution satellite remote sensing images in U–Net network with consideration of connectivity [J]. Journal of Remote Sensing, 2020, 24(12): 1488–1499. (in Chinese)
- [26] 韩振浩, 李佳, 苑严伟, 等. 基于 U–Net 网络的果园视觉导航路径识别方法 [J]. 农业机械学报, 2021, 52(1): 30–39.
HAN Zhenhao, LI Jia, YUAN Yanwei, et al. Path recognition of orchard visual navigation based on U–Net [J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(1): 30–39. (in Chinese)
- [27] IOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift [J]. arXiv:1502.03167, 2015.
- [28] SOBEL I. Neighborhood coding of binary images for fast contour following and general binary array processing [J]. Computer Graphics and Image Processing, 1978, 8(1): 127–135.
- [29] KINGMA D P, BA J. Adam: a method for stochastic optimization [C] // International Conference on Learning Representations (ICLR), 2015.
- [30] HEIPKE C, MAYER H, WIEDEMANN C. Evaluation of automatic road extraction [J]. International Archives of Photogrammetry and Remote Sensing, 1997, 32(3): 151–160.