引文格式：王月红, 孟凡效, 丁乐乐 . 基于深度学习的农业大棚检测[J]. 地理空间信息, 2023, 21(10): 85-87. doi:10. 3969/j.issn. 1672-4623.2023.10.021

基于深度学习的农业大棚检测

王月红[1]，孟凡效[2*]，丁乐乐[2]
（1. 天津市自然资源调查与登记中心，天津 300000；2. 天津市勘察设计院集团有限公司，天津 300000）

摘　要：农业大棚的即时空间分布信息能为相关农业部门提供农业管理和资源分配的依据，具有重要意义。针对这一需求，对比分析了深度学习模型FCN, UNet和HRNet在高分辨率遥感影像大棚检测任务上的性能，对FCN, UNet和HRNet模型在大棚检测方面的效果进行定量和定性分析。通过对比发现UNet等网络模型正确率均可达到90%以上，交并比IOU达到85%以上，其中HRNet的效果最好，正确率和IOU分别为92.79%和87.32%。实验表明基于深度学习的大棚检测方法可为快速精确获取大棚分布信息提供技术支撑，具有实用价值。

关键词：农业大棚；空间分布；高分遥感；深度学习
中图分类号：P208　　**文献标志码：**B　　**文章编号：**1672-4623（2023）10-0085-03

Agricultural Greenhouse Detection Method Based on Deep Learning

WANG Yuehong[1], MENG Fanxiao[2], DING Lele[2]
(1. Tianjin Survey and Registration Center of Natural Resources, Tianjin 300000, China;
2. Tianjin Survey Design Institute Group Co., Ltd., Tianjin 300000, China)

Abstract: It’s of great significance that real-time spatial distribution information of agricultural greenhouses can provide a basis for agricultural management and resource allocation for relevant agricultural departments. In view of this demand, we compared and analyzed the performance of various deep learning models FCN, UNet and HRNet in greenhouse detection task with high spatial resolution images, giving quantitative and qualitative analysis on the effects of various models in greenhouse detection. It is found that the accuracy of these models can reach more than 90% and the intersection ratio of IoU more than 85%, among which HRNet has the best result with 92.79% accuracy and 87.32% IoU. The experiment shows that the greenhouse detection method based on deep learning can provide technical support and practical value for quickly and accurately acquiring greenhouse distribution information.

Key words: agricultural greenhouse, spatial distribution, high-resolution remote sensing, deep learning

随着深度学习在计算机视觉领域的成熟应用，深度学习在遥感影像解译领域获得广泛关注[1-3]，并被应用于大棚检测[4-6]。针对大棚提取任务，本文对比分析了深度学习模型FCN[7]，UNet[8]和HRNet[9]在高分辨率遥感影像大棚检测任务上的性能，对多种模型在大棚检测方面的效果进行定量和定性分析。

1　基于深度学习的农业大棚检测

本文提出的方法主要包括3个部分，即高分影像预处理、深度特征提取和农业大棚识别3个部分，对于给定高分影像，首先对其进行归一化、数据增强等预处理，然后输入深度卷积神经网络进行深度特征提取，最后利用分类器对提取得到的特征进行识别。在训练阶段，根据真实标准值和识别的结果计算损失函数，计算参数的偏导数，更新网络参数。

1.1　数据预处理与深度特征提取

1.1.1　数据预处理

设输入影像为 $I \in R^{H\times W\times 3}$ 及其对应的标注影像 $Y \in R^{H\times W\times 2}$，其中 H，W 分别表示影像的行、列。考虑到训练过程中显存的限制，本文将 H，W 设置为512。即训练阶段将影像裁剪成规格为 512×512 的数据用于训练模型。为增加模型的鲁棒性和泛化能力，本文首先对数据进行随机旋转、拉伸、平移等预处理操作：

收稿日期：2022-04-18。
项目来源：天津市重点研发计划科技支撑重点项目（18YFZCSF00620）；天津市重点研发计划院市合作项目（18YFYSZC00120）。
第一作者简介：王月红（1986—），高级工程师，主要从事不动产登记，自然资源调查，不动产权籍调查，地籍测绘等相关工作，E-mail: wangyuehong68@126.com。
通信作者：孟凡效（1991—），硕士，主要从事测绘地理信息、精密工程测量等工作，E-mail: 739369615@qq.com。

$$I=\mathrm{RandomRot}(I) \tag{1}$$

$$I=\mathrm{RandomScale}(I) \tag{2}$$

$$I=\mathrm{RandomShift}(I) \tag{3}$$

式中，RandomRot(·)、RandomScale(·)、RandomShift(·)分别为随机旋转、拉伸和平移操作。

在经过预处理操作后，将得到的数据输入深度网络中进行深度特征提取。在本文中，分别利用FCN，UNet，和HRNet等3个网络进行深度特征提取。

1.1.2 深度特征提取

FCN和UNet是典型的语义分割网络，其通过对输入数据进行编码和解码得到深度特征，其中在编码的过程中，FCN和UNet逐步降低输入数据的分辨率，然后在解码中通过反卷积等上采样算子恢复特征的分辨率，而且为利用多尺度特征，FCN和UNet将编码层和解码层特征进行融和。虽然UNet和FCN网络通过编码—解码这一结构来提取特征和保持分辨率，然而这一结构在特征编码时仍将丧失图像细节信息，针对这一问题，HRNet网络设计为4分支网络，并令第一分支网络空间分辨率不变，在提取的过程中4分支网络交互传递信息。

FCN：FCN为用于影像语义分割的经典网络，在本文中，使用ResNet-50[12]作为FCN的backbone用于特征提取。在ResNet-50中，基本逻辑构成单位为Basic Block，Basic Block含有跨层连接，便于信息的直接流通和梯度传递，若干个Basic Block堆叠形成Stage Block。4个Stage Block构成ResNet-50深度网络。本文中选用第4个Stage Block的输出特征同于大棚检测。由于在进行深度特征的提取过程中，影像空间分辨率会下降，因此本文采用线性差值将提取得到的特征图拉伸到和原图像一样大小，则特征图上每一个位置（x，y）的通道被作为该处像元的特征向量。

UNet：为弥补深度特征提取过程中空间分辨降低，细节信息丢失的问题，UNet将低层的高分辨特征和高层的低分辨率特征进行叠加融合，在本文中，同样使用ResNet-50作为UNet的backbone。

HRNet：为在提取特征的过程中保持空间细节信息，HRNet采用4个网络分支用于提取不同尺度的特征，不同尺度的分支之间相互传递信息，进行多尺度融合。

在本文中将深度特征提取过程用函数Net(·)，则深度特征提取表示为：

$$x=\mathrm{Net}(I) \tag{4}$$

式中，Net(·)可取值为FCN，UNet以及HRNet，$x\in R^{H\times W\times C}$为提取得到特征图，$C$为提取的特征图通道数。

1.2 农业大棚识别

对于得到的深度特征图x，将其输入分类器SoftMax获得识别结果：

$$p(I_j)=\begin{bmatrix}p(1|I_j)\\ \cdot\\ p(n|I_j)\end{bmatrix}=\begin{bmatrix}\dfrac{e^{w_1\cdot x_j}}{\sum_{\mathrm{cls}=1}^{\mathrm{n}}e^{w_{cls}\cdot x_j}}\\ \cdot\\ \dfrac{e^{w_n\cdot x_j}}{\sum_{\mathrm{cls}=1}^{\mathrm{n}}e^{w_{\mathrm{cls}}\cdot x_j}}\end{bmatrix} \tag{5}$$

式中，$p(t|I_j)$为像素I_j属于类别t的概率；n为总的类别个数，在本文中取值为2，即分类为农业大棚和非农业大棚两类；x_j为像素I_j的深度特征向量；w_{cls}为分类器SoftMax中的参数矩阵$w\in R^{n\times n}$的第cls行。

在训练阶段，根据最大似然估计方法，计算交叉熵损失函数，使得样本被正确分类的概率最大：

$$J=\frac{-1}{H\times W}\sum_{j=1}^{H\times W}Y_j*\lg p(I_j) \tag{6}$$

式中，$Y_j\in R^2$为像素I_j的one-hot类别编码；$*$为向量内积运算。根据链式法则计算网络损失函数J对参数的偏导数并更新参数：

$$\nabla\mathrm{par}=\frac{\partial J}{\partial\mathrm{par}} \tag{7}$$

$$\mathrm{par}=\mathrm{par}-lr\cdot\nabla\mathrm{par} \tag{8}$$

式中，par为网络参数；lr为学习率。

2 实验结果分析

本文实验数据包括800张高分影像，单张影像大小2 000×2 000，图像分辨率为0.5 m，其中随机抽取400张影像用于训练，剩余400张影像用于测试。训练学习率为0.000 03，训练迭代次数为15 000。本文使用正确率Acc以及交并比IOU作为评价指标：

$$\mathrm{Acc}_i=\frac{TP_i}{TP_i+FN_i}=\frac{TP_i}{\mathrm{Num}_i} \tag{9}$$

$$\mathrm{IOU}_i=\frac{TP_i}{TP_i+FN_i+FP_i} \tag{10}$$

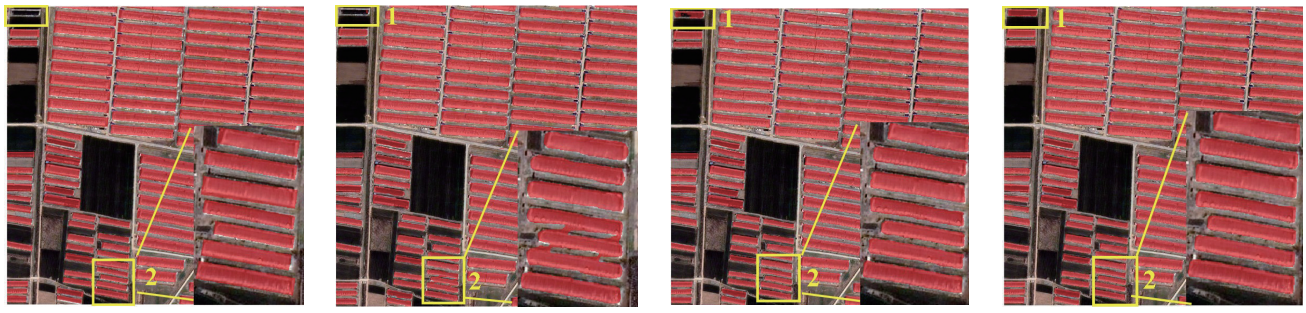
式中，Acc_i和IOU_i为类i的正确率和IOU；TP_i为i样本被正确分类的样本数、FN_i为i样本被错误分类的样本数；Num_i为类i样本的总个数；FP_i为被错误分为类i的样本数。

表1给出了FCN，UNet和HRNet在测试数据集上的识别精度。从表1可以看出，FCN，UNet和HRNet 3个网络对大棚的识别正确率都可以达到91%以上，IOU精度高于86%。相比于UNet，FCN对于农业大棚的识别正确率和IOU略高，分别有0.4%和0.39%的提升。在3个网络中，由于HRNet在细节信息保持方面更具优势，因此在测试数据集上取得最优的提取精度。

图1给出了3个网络模型在其中一张测试数据上的识别结果图。从图1可以看出，FCN，UNet和HRNet 3个网络的提取结果从视觉上来看与人工标注的结果并无太大差异。其中图中区域1为人工遗漏标记的大棚，FCN没有正确将其检测出来，UNet识别出部分区域，而HRNet将其成功的提取出来。对于区域2，虽然3个网络都能将其范围内的大棚正确识别，然而，FCN网络由于丢失细节信息较UNet和HRNet较为严重，因此在大棚之间的区域，在FCN中也被错误地识别为大棚，而UNet和HRNet都可以将这些间隔区域正确识别。

表1　FCN，UNet和HRNet在测试数据集上的识别精度

模型	Acc		IOU	
	大棚	非大棚	大棚	非大棚
FCN	92.06	99.04	87.09	97.74
UNet	91.66	99.04	86.70	97.67
HRNet	92.79	98.95	87.32	97.77



a GT　　b FCN　　c UNet　　d HRNet

图1　深度学习模型大棚提取结果

3　结　语

作为重要的农业基础设施，及时获得大棚的空间分布信息为相关农业部门提供农业管理和资源分配的依据，具有重要意义。针对这一任务，本文分析对比了深度学习模型FCN, UNet和HRNet在大棚检测上的精度。在所用数据中，3个网络都可达到90%以上的正确率，IOU可达到85%以上，其中HRNet由于其网络可以更好地保留空间细节信息，识别精度最高，正确率和IOU分别达到92.79%和87.32%。实验表明，基于深度学习的大棚检测方法可为快速精确获取大棚分布信息提供技术支撑，具有实用价值。

参考文献

[1] 夏乐,李长安,江涛,等. 基于深度卷积神经网络的遥感图像船只识别[J]. 地理空间信息,2021,19(9):7-9

[2] 郑磊,何直蒙,丁海勇. 基于ENVINet5的高分辨率遥感影像稀疏塑料大棚提取研究[J]. 遥感技术与应用,2021,36(4):908-915

[3] Zhang X, Cheng B, Chen J, et al. High-resolution Boundary Refined Convolutional Neural Network for Automatic Agricultural Greenhouses Extraction from GaoFen-2 Satellite Imageries[J]. Remote Sensing, 2021, 13(21): 4 237

[4] Ma A, Chen D, Zhong Y, et al. National-scale Greenhouse Mapping for High Spatial Resolution Remote Sensing Imagery Using a Dense Object Dual-task Deep Learning Framework: A case Study of China[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2021, 181: 279-294

[5] 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: 3 431-3 440

[6] 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

[7] Sun K, Xiao B, Liu D, et al. Deep High-resolution Representation Learning for Human Pose Estimation[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition,2019: 5 693-5 703

[8] 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