

DOI:10.3880/j.issn.1004-6933.2021.05.012

基于深度学习的道路积水智能监测方法

白岗岗¹, 侯精明¹, 韩 浩¹, 夏军强², 李丙尧¹, 张阳维¹, 卫志豪¹

(1. 西安理工大学省部共建西北旱区生态水利国家重点实验室, 陕西 西安 710048;

2. 武汉大学水资源与水电工程科学国家重点实验室, 湖北 武汉 430072)

摘要:针对目前城市区域内涝频发且传统内涝积水监测方法具有危险性大、成本较高及时效性较低等问题,提出了一种利用深度学习技术的城市道路积水快速监测方法,该方法基于卷积神经网络,可对输入积水图像数据集进行积水特征提取。选取西安理工大学校内积水情况进行验证,结果表明该方法对数据集的训练和验证的平均准确率分别为 96.1% 和 90.1%,能较准确实现图像积水面积自动提取,从而实现城市内涝监控图像中的积水区域自动识别和积水面积自动获取。

关键词:城市内涝;深度学习;卷积神经网络;积水监测;图像识别

中图分类号:TP399 **文献标志码:**A **文章编号:**1004-6933(2021)05-0075-06

Intelligent monitoring method for road inundation based on deep learning//BAI Ganggang¹, HOU Jingming¹, HAN Hao¹, XIA Junqiang², LI Bingyao¹, ZHANG Yangwei¹, WEI Zhihao¹ (1. State Key Laboratory of Eco-Hydraulics in Northwest Arid Region of China, Xi'an University of Technology, Xi'an 710048, China; 2. State Key Laboratory of Water Resources and Hydropower Engineering Science, Wuhan University, Wuhan 430072, China)

Abstract: To solve the problems including frequent urban inundation and unsafe, costly and inefficient traditional monitoring urban inundation method, a method of detecting urban road flood rapidly based on deep learning techniques is proposed. This method, based on convolutional neural network, can extract the features of puddles from the input accumulated water image data set. The water accumulation in Xi'an University of Technology is selected for verification. It is shown that the average recognition accuracy of the method for training and verification of the data set is 96.1% and 90.1% respectively, and automatic extraction of the puddle area in the image is realized accurately. So that the automatic identification of the inundation area and the automatic acquisition of the water area in the urban inundation monitoring image are realized.

Key words: urban inundation; deep learning; convolutional neural network; inundation monitoring; image identification

随着全球气候变化加剧,极端降雨频次不断增加,与此同时城镇化进程快速推进,极大地改变了下垫面条件,致使城市内涝积水问题日益突出^[1-5]。2012 年北京“7·21”特大暴雨引发了严重的城市内涝,造成严重的人员伤亡和经济损失。2018 年 8 月辽宁大连突降大到暴雨,路面积水使灯箱漏电,致一名蹚水行走的男子不幸触电身亡。可见高效、安全、精准地开展城市内涝积水监测对降低内涝成灾风险、减少内涝引起的城市交通及市民出行安全等隐患具有重要意义^[6]。

目前针对城市内涝积水信息监测的主要方法有人工观测法、仪器测量法等,其中人工观测法需要消

耗大量的人力物力,效率较低且存在严重的安全隐患;仪器测量法通过传感器进行量测,有着方便快捷且精度较高的优点,但缺点也较明显,如仪器成本高且受外界的干扰较大^[7]。因此,需寻找一种安全、效率高且成本低的监测方法来监测城市内涝积水。

近年来随着深度学习技术的不断提高,人工智能飞速发展,卷积神经网络(convolutional neural network, CNN)作为深度学习的代表算法,在图像识别领域中的应用取得了大量突破性成果。Hua 等^[8]针对大场景遥感影像中多个物体和微物体的实时检测,提出了一种将视觉感知和 CNN 相结合的遥感影

基金项目:水资源与水电工程科学国家重点实验室(武汉大学)开放研究基金(2016HLG01);陕西省国际科技合作交流计划(2017KW-014)

作者简介:白岗岗(1994—),男,硕士研究生,研究方向为内涝监测与模拟。E-mail: ganggang_bai@163.com

通信作者:侯精明(1982—),男,教授,博士,主要从事城市水力学研究。E-mail: jingming.hou@xaut.edu.cn

像实时物体检测算法,该算法不仅能保证检测精度,且可大幅度提高目标检测的效率。Zang 等^[9]提出了一种基于深度学习和计算机视觉的自动车牌检测和识别方法,该方法对于车牌检测和识别的效果较好。Massoli 等^[10]基于深度学习对人脸进行识别,并采用超分辨率技术提升了对人脸识别的精度。陈利^[11]提出了一种基于深度学习技术的车牌识别方法,与传统方法相比识别和定位车牌的准确率更高。何西麟^[12]采用深度学习技术搭建了基于 CNN 模型的手写字符识别模型,手写体字符的识别率超过 90%。卢宏涛等^[13]将 CNN 应用于物体监测和人脸识别,与传统方法相比,CNN 模型的识别精度较高。刘胤等^[14]应用图像识别技术实现了实验室异常自动监测和人脸自动识别等功能,比传统人工监控方法具有更高的识别速度和精度。张雪芹等^[15]基于植物识别算法和 CNN 中的 AlexNet 网络模型对植物图像进行识别,该方法的泛化性和准确性较高,识别速度较快。

本文基于西安理工大学金花校区内的道路积水图像,采用基于 CNN 的目标检测算法识别道路积水区域并提取积水面积,与实测结果对比表明,该方法可以实现道路积水范围的提取且具有较高的精度,可为相关部门自动准确获取道路积水信息提供技术依据。

1 理论算法

1.1 CNN

CNN 是基于深度学习理论的一种前馈神经网络,在图像处理领域有着出色的表现^[16]。CNN 擅长发掘数据的局部特征,对数据的旋转、平移等具有较高的稳健性,通过输入原始数据,采取卷积、池化及激活函数映射等操作,最后按目标任务特征输出目标分类和定位^[17]。CNN 由输入层、卷积层、池化层、全连接层以及输出层组成,其中输入层用来接收样本数据,并将样本数据输送到 CNN 中进行特征提取;卷积层通过多个滤波器进行卷积操作进而提取输入数据的特征,每个卷积层包含若干个特征图,同一特征图的神经元共享同一卷积核的权值参数,可以减少各网络层间的连接及过拟合现象,由前一层的特征图与卷积核进行卷积运算并经过激活函数后输出得到这一层的特征图;池化层亦称为下采样层,通过求局部区域的最大值或平均值进行降采样,进而缩小矩阵尺寸,减小特征空间,即在减少数据量的同时保留可用信息。CNN 通常取若干个卷积层和池化层交替连接,而后连接若干个全连接层,全连接层用于将目标任务形式化为目标函数,实现最终

分类^[18]。

CNN 不需要任何输入和输出之间的精确表达式,只需通过大量学习就能得到输入与输出之间的映射关系^[19]。在训练 CNN 时,反向传播算法是性能最好且应用最为广泛的方法,通过计算预测值与真实值之间的误差(损失),并将误差由最后一层逐层向前反馈,同时更新每层参数,再进行前馈,如此往复,直到网络模型收敛,进而达到模型训练的目的^[20]。对于样本数量为 N 的训练集,使用交叉熵作为损失函数^[21],可表示为

$$J = -\frac{1}{N} \sum_{n=1}^N \ln(P(Y = y_n | \mathbf{x}_n, w, b)) \quad (1)$$

式中: J 为损失函数; y_n 为第 n 个样本所属的类别; $\mathbf{x}_n$ 为第 n 个样本的特征向量; w 为末层权参数; b 为相应偏置参数。

CNN 在测试时输入图像所属某一类别 y 的预测值 y_{pred} 为

$$y_{\text{pred}} = \underset{y}{\operatorname{argmax}} P(Y = y | \mathbf{x}, w, b) \quad (2)$$

1.2 YOLOv2 网络结构

TensorFlow 是 Google 在 Dist Belief 的基础上采用数据流程图进行数值计算,对神经网络框架进一步优化得到的一种深度学习系统,可在 CPU 和 GPU 上运行,具有速度快、精度高、灵活性强、可用范围广等特点,被广泛应用于 CNN、递归神经网络(RNN)等各类机器学习算法^[18,22]。TensorFlow 是通过计算图的形式来表述计算的一种深度学习系统,目前已有多种经 COCO 数据库训练且基于 TensorFlow 的网络结构,如 Fast R-CNN、Faster R-CNN、YOLO、R-FCNN 及 YOLOv2 等,故仅需在这些基础网络结构上修改某些参数便可训练目标检测模型^[23]。与 Faster R-CNN、YOLO 相比,YOLOv2 提出了新的 Darknet-19 基础网络,共包含 19 层卷积层和 5 层池化层,使用大量的 3×3 和 1×1 卷积,通过将 1×1 的卷积置于 3×3 卷积之间对积水特征进行压缩,并采用了 Batch Normalization(批量归一化)处理及 K-means 聚类作为候选框选取规则,通过这一系列调优算法,在保证检测精度的基础上提升了检测速度。

本文选用基于 CNN 的 YOLOv2 目标检测模型,模型通过输入分辨率为 416 像素 $\times$ 416 像素的积水图像,采用 Darknet-19 基础结构对输入积水图像进行积水特征提取,输出 $13 \times 13 \times 1024$ 特征图,并取第 16 层的 $26 \times 26 \times 512$ 特征图重组成 $13 \times 13 \times 256$ 特征图,采用融合方法将二者相结合,生成 $13 \times 13 \times 1280$ 特征图,最终经过卷积操作,生成 $13 \times 13 \times 30$ 的特征图,具体网络结构如图 1 所示。




图1 YOLOv2 网络结构

Fig.1 Network structure of YOLOv2

2 研究数据

2.1 基础数据采集

采用高清数码摄像机和照相机设备采集西安理工大学金花校区道路地势低洼或易积水区积水图像。摄像机安装位置如图2所示,每隔10 min 获取一帧积水图像,得到的图像分辨率为2560像素×1440像素;照相机拍摄的积水图像分辨率为4272像素×2848像素。共筛选采集了积水图像1000幅,作为初始积水样本数据集,图3为数据集图像示例。




图2 图像采集设备安装位置

Fig.2 Installation location of image acquisition equipment



(a) 摄像机拍摄图像

(b) 照相机拍摄图像

图3 数据集图像示例

Fig.3 Examples of images in dataset

2.2 数据预处理

为避免在训练过程中由于训练样本过少而出现过拟合现象,需对数据集进行数据扩充。数据扩充方法有随机裁剪、角度变换及彩色转换等,为增加数据多样性,考虑不同方位和光照强度时的积水图像,采用彩色转换、角度变换将样本数据集扩充至3000幅,其中由700幅图像进行角度变换得到2000幅,另300幅图像进行彩色转换得到1000幅。因检测目标较大,而降低图像像素不会影响目标检测精度,但可大幅度提高模型训练速度,故将图像缩小至416像素×416像素,最后采用Labellmg标注工具对数据集进行标签制作。

基于OpenCV(open source computer vision library)计算机视觉开源库,编写代码对原积水样本图像进行角度变换(水平或垂直方向旋转),如图4所示;通过Matlab软件编写代码实现对数据集的彩色转换,如图5所示,分别在色彩原色R、G、B即红色、绿色和蓝色3个通道加不同的失真值。

积水目标检测是通过学习有标签的图像样本,然后对新的图像做出预测的过程,故需提前生成标签^[24]。用Labellmg标注工具可在图像中标注目标位置并生成表示目标标准框位置的xml文件,文件中包含图像名称、像素大小、所属图片位置及标注的积水范围等信息,极大地方便了数据集标签的制作,如图6所示。

2.3 模型训练

在经数据预处理后得到的3000幅积水数据集中,选取2500幅图像作为训练集,其中1665幅图像是由原始图像经过彩色转换、角度变换得到的,



图4 角度变换

Fig.4 Angle transformation





图 5 彩色转换

Fig.5 Color conversion



(a) 制作标签界面



(b) 生成的 xml 文件

图 6 图像集标签制作

Fig.6 Label making of image data

500 幅图像作为测试集(摄像机图像 145 幅,照相机图像 355 幅)。采用中央处理器为 Intel i7-8700、

GPU 为 RTX2070 的硬件配置,运行环境为 Windows 10.0、CUDA 10.0 以及 TensorFlow 深度学习系统,实现基于 YOLOv2 算法的模型训练。经多次训练和参数调整,设置的模型网络参数如下:初始学习率为 0.001,批尺寸为 32,迭代次数为 50 次,并采用正则化方法来防止模型过拟合,最终训练产生了用于预测积水的模型权重,其保存了模型的结构、权重以及训练参数配置等。图 7 为模型对积水数据集的训练与验证准确率,平均值分别为 96.1%和 90.1%。





图 7 模型训练和验证结果

Fig.7 The result of model training and validation


3 识别结果与分析

利用训练好的模型权重,可实现积水图像自动识别及积水面积自动提取。图 8 为部分测试集里的图像对模型准确率进行测试的效果。摄像机拍摄机位、角度不变,拍摄画面单一,而照相机拍摄场地、角度都是随机的,故模型对摄像机图像识别效果较照相机要好。


为实现对图像中积水面积的提取,分别用照相机垂直拍摄的图像(图 9(a)(b))和摄像机拍摄的、经过曲面矫正和透视变换技术矫正的图像(图 9(c))进行识别,并可自动提取识别类别、识别率及检测框坐标 $x_{\max}$ 、 $x_{\min}$ 、 $y_{\max}$ 、 $y_{\min}$ 等信息,表 1 为积水图像检测框信息。



(a) IMG_1



(b) IMG_2



(c) IMG_3

图 8 积水图像自动识别结果

Fig.8 The result of automatic image recognition for puddles




图9 积水面积提取示例

Fig.9 Example of the puddle area extraction

表1 积水图像检测框信息

Table 1 The information of object boxes in inundation images

图像名称	$x_{\max}$	$x_{\min}$	$y_{\max}$	$y_{\min}$	$S_o/\text{像素}$
IMG_4	405.65	4.15	416.00	195.02	88 723.47
IMG_5	366.19	118.02	348.55	94.17	63 129.48
	3.91	153.64	49.00	251.75	4 423.78
	264.77	2.39	323.94	98.69	5 698.07
	1.67	0	121.36	156.12	18 686.00
IMG_6	271.93	119.84	416	266.44	21 120.66

注: S_o 为检测框像素;IMG_6 包含 4 个检测框。

所有图像尺寸均为 416 像素 $\times$ 416 像素,即图像大小 $S_a = 173\,056$ 像素,以图像 IMG_4 为例,整个图像的真实尺寸为 55 cm $\times$ 55 cm,即图像实际面积 $A = 3\,025\text{ cm}^2$,利用摄影测量原理,即式(3)可计算出积水识别面积 $A_{\text{识}} = 1\,551\text{ cm}^2$,与积水实测面积 $A_{\text{实}} = 1\,434\text{ cm}^2$ 相比,误差约为 8%。同理可计算出图像 IMG_5 和 IMG_6 的积水面积,结果如表 2 所示。

$$A_{\text{识}} = \frac{S_o}{S_a} A \quad (3)$$

表2 积水识别面积与实测面积对比

Table 2 Comparison of the identified and measured area of the puddles

图像名称	$S_o/\text{像素}$	$S_a/\text{像素}$	A/cm^2	$A_{\text{识}}/\text{cm}^2$	$A_{\text{实}}/\text{cm}^2$	误差/%
IMG_4	88 723	173 056	3 025	1 551	1 434	8.15
IMG_5	63 129	173 056	12 100	4 414	3 850	14.60
IMG_6	49 929	173 056	309 000	89 100	83 400	6.90

由表 2 可知,利用本文方法计算得到的积水识别面积与实测面积误差均在允许范围($\pm 20\%$)内,验证了基于深度学习技术的城市道路积水范围识别和提取方法的合理性和可行性。

4 结 语

于西安理工大学金花校区采集 1 000 幅道路积水图像数据,经数据扩充得积水样本集 3 000 幅图像,其中 2 500 幅作为训练集,500 幅作为测试集,采

用 TensorFlow 深度学习系统,基于 CNN 的 YOLOv2 模型对积水区域进行了智能识别,实现了对积水图像信息的智能获取,训练和验证的平均准确率分别为 96.1% 和 90.1%,自动提取的积水面积误差也均在允许的范围内,验证了方法的合理性和可行性,可为城市内涝积水监测与管理提供参考。

参考文献:

- [1] 黄绵松,杨少雄,齐文超,等. 固原海绵城市内涝削减效果数值模拟[J]. 水资源保护,2019,35(5):13-18. (HUANG Miansong, YANG Shaoxiong, QI Wenchao, et al. Numerical simulation of urban waterlogging reduction effect in Guyuan sponge city[J]. Water Resources Protection,2019,35(5):13-18. (in Chinese))
- [2] 陆海明,邹鹰,孙金华,等. 基于 SWMM 的铁心桥实验基地内涝防治效果模拟[J]. 水资源保护,2020,36(1):58-65. (LU Haiming, ZOU Ying, SUN Jinhua, et al. Simulation of waterlogging control effect in Tiexinqiao experimental base based on SWMM[J]. Water Resources Protection,2020,36(1):58-65. (in Chinese))
- [3] 吴海春,黄国如. 基于 PCSWMM 模型的城市内涝风险评估[J]. 水资源保护,2016,32(5):11-16. (WU Haichun, HUANG Guoru. Risk assessment of urban waterlogging based on PCSWMM model[J]. Water Resources Protection,2016,32(5):11-16. (in Chinese))
- [4] 宋耘,李琼芳,牛铭媛,等. 基于 SWMM 模型的南京典型易涝区暴雨内涝模拟[J]. 水利水电科技进展,2019,39(6):56-61. (SONG Yun, LI Qiongfang, NIU Mingyuan, et al. Rainstorm and waterlogging simulation in typical inundated districts of Nanjing based on SWMM[J]. Advances in Science and Technology of Water Resources, 2019, 39(6): 56-61. (in Chinese))
- [5] 侯精明,李东来,王小军,等. 建筑小区尺度下 LID 措施前期条件对径流调控效果影响模拟[J]. 水科学进展,2019,30(1):45-55. (HOU Jingming, LI Donglai, WANG Xiaojun, et al. Effects of initial conditions of LID measures on runoff control at residential community scale[J].

- Advances in Water Science, 2019, 30 (1): 45-55. (in Chinese))
- [6] 侯精明. 深度学习技术在城市内涝监测中的应用[J]. 中国防汛抗旱, 2019, 29 (8): 8. (HOU Jingming. Application of deep learning technology in urban waterlogging monitoring [J]. China Flood & Drought Management, 2019, 29 (8): 8. (in Chinese))
- [7] 陈金水. 基于视频图像识别的水位数据获取方法[J]. 水利信息化, 2013 (1): 48-51. (CHEN Jinshui. Method of water level data capturing based on video image recognition [J]. Water Resources Informatization, 2013 (1): 48-51. (in Chinese))
- [8] HUA Xia, WANG Xinqing, RUI Ting, et al. A fast self-attention cascaded network for object detection in large scene remote sensing images[J]. Applied Soft Computing, 2020, 94: 106495.
- [9] ZANG Di, CHAI Zhenliang, ZHANG Junqi, et al. Vehicle license plate recognition using visual attention model and deep learning[J]. Journal of Electronic Imaging, 2015, 24 (3): 033001.
- [10] MASSOLI F V, AMATO G, FALICHI F. Cross-resolution learning for face recognition [J]. Image and Vision Computing, 2020, 99: 103927.
- [11] 陈利. 基于深度学习的车牌识别系统设计[J]. 计算机技术与发展, 2018, 28 (6): 85-89. (CHEN Li. Design of license plate recognition system based on deep learning [J]. Computer Technology and Development, 2018, 28 (6): 85-89. (in Chinese))
- [12] 何西麟. 基于深度学习的手写体字符识别研究与实现[D]. 广州: 中山大学, 2015.
- [13] 卢宏涛, 张秦川. 深度卷积神经网络在计算机视觉中的应用研究综述[J]. 数据采集与处理, 2016, 31 (1): 1-17. (LU Hongtao, ZHANG Qinchuan. Applications of deep convolutional neural network in computer vision [J]. Journal of Data Acquisition and Processing, 2016, 31 (1): 1-17. (in Chinese))
- [14] 刘胤, 冯军焕, 尹帮旭. 图像识别技术在实验室监控中的应用[J]. 实验室研究与探索, 2013, 32 (10): 210-213. (LIU Yin, FENG Junhuan, YIN Bangxu. Application of image recognition in laboratory monitoring[J]. Research and Exploration in Laboratory, 2013, 32 (10): 210-213. (in Chinese))
- [15] 张雪芹, 陈嘉豪, 诸葛晶晶, 等. 基于深度学习的快速植物图像识别[J]. 华东理工大学学报(自然科学版), 2018, 44 (6): 887-895. (ZHANG Xueqin, CHEN Jiahao, ZHUGE Jingjing, et al. Deep learning based fast plant image recognition[J]. Journal of East China University of Science and Technology, 2018, 44 (6): 887-895. (in Chinese))
- [16] ULLAH I, HUSSAIN M, QAZI E U H, et al. An automated system for epilepsy detection using EEG brain signals based on deep learning approach[J]. Expert Systems with Applications, 2018, 107: 61-71.
- [17] 苏赋, 吕沁, 罗仁泽. 基于深度学习的图像分类研究综述[J]. 电信科学, 2019, 35 (11): 58-74. (SU Fu, LYU Qin, LUO Renze. Review of image classification based on deep learning [J]. Telecommunications Science, 2019, 35 (11): 58-74. (in Chinese))
- [18] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述[J]. 计算机学报, 2017, 40 (6): 1229-1251. (ZHOU Feiyan, JIN Linpeng, DONG Jun. Review of convolutional neural network[J]. Chinese Journal of Computers, 2017, 40 (6): 1229-1251. (in Chinese))
- [19] 刘建伟, 刘媛, 罗雄麟. 深度学习研究进展[J]. 计算机应用研究, 2014, 31 (7): 1921-1930. (LIU Jianwei, LIU Yuan, LUO Xionglin. Research and development on deep learning[J]. Application Research of Computers, 2014, 31 (7): 1921-1930. (in Chinese))
- [20] 尹宝才, 王文通, 王立春. 深度学习研究综述[J]. 北京工业大学学报, 2015, 41 (1): 48-59. (YIN Baocai, WANG Wentong, WANG Lichun. Review of deep learning [J]. Journal of Beijing University of Technology, 2015, 41 (1): 48-59. (in Chinese))
- [21] 张顺, 龚怡宏, 王进军. 深度卷积神经网络的发展及其在计算机视觉领域的应用[J]. 计算机学报, 2019, 42 (3): 453-482. (ZHANG Shun, GONG Yihong, WANG Jinjun. The development of deep convolution neural network and its applications on computer vision [J]. Chinese Journal of Computers, 2019, 42 (3): 453-482. (in Chinese))
- [22] 尹宏鹏, 陈波, 柴毅, 等. 基于视觉的目标检测与跟踪综述[J]. 自动化学报, 2016, 42 (10): 1466-1489. (YIN Hongpeng, CHEN Bo, CHAI Yi, et al. Vision-based object detection and tracking: a review [J]. Acta Automatica Sinica, 2016, 42 (10): 1466-1489. (in Chinese))
- [23] 徐乐先, 陈西江, 班亚, 等. 基于深度学习的车位智能检测方法[J]. 中国激光, 2019, 46 (4): 230-241. (XU Lexian, CHEN Xijiang, BAN Ya, et al. Method for intelligent detection of parking spaces based on deep learning[J]. Chinese Journal of Lasers, 2019, 46 (4): 230-241. (in Chinese))
- [24] 邵娜, 李晓坤, 刘磊, 等. 基于深度学习的语音识别方法研究[J]. 智能计算机与应用, 2019, 9 (2): 135-142. (SHAO Na, LI Xiaokun, LIU Lei, et al. Research on speech recognition based on depth learning[J]. Intelligent Computer and Applications, 2019, 9 (2): 135-142. (in Chinese))

(收稿日期: 2020-05-14 编辑: 熊水斌)