

陈汪洋. 基于深度残差神经网络的道路积水深度提取方法[J]. 净水技术, 2025, 44(6): 157-163.

CHEN W Y. Extraction method of road waterlogging depth based on deep residual neural network [J]. Water Purification Technology, 2025, 44(6): 157-163.

## 基于深度残差神经网络的道路积水深度提取方法

陈汪洋\*

(中国水务投资有限公司,北京 100053)

**摘要** 【目的】针对现有道路积水深度传感器安装维护成本高的问题,【方法】文章提出了一种基于深度残差神经网络的道路积水深度提取方法,从“全球眼系统”“网络平台”“洪涝应急抢险照片”多渠道收集数据集。【结果】解决了积水图像数据集数量、质量不高的问题;并以积水严重程度作为标签分级,解决了现有研究无法识别积水深度的问题,在原始测试集上可以达到96.5%的准确率。【结论】实例分析结论表明,采用深度残差神经网络从积水图像中提取积水深度信息的方法确实可行,并且在实际应用中能够满足积水监测的精度要求。

**关键词** 排水系统 道路积水 残差神经网络 积水深度提取 内涝防控

中图分类号: TU992 文献标志码: A 文章编号: 1009-0177(2025)06-0157-07

DOI: 10.15890/j.cnki.jsjs.2025.06.019

## Extraction Method of Road Waterlogging Depth Based on Deep Residual Neural Network

CHEN Wangyang\*

(China Water Investment Corporation Co., Ltd., Beijing 100053, China)

**Abstract** [Objective] In response to the high installation and maintenance costs of existing road waterlogging depth sensors, this paper proposed a road waterlogging depth extraction method based on deep residual neural network. [Methods] The method collected data from multiple channels such as the “global eye system” “network platform” and “flood emergency rescue photos”, [Results] to address the issues of insufficient quantity and low quality of the waterlogging image dataset. By labeling the dataset based on the severity of waterlogging, the method solved the problem of inability to identify waterlogging depth in previous research, achieving an accuracy of 96.5% on the original test set. [Conclusion] Conclusion from case analysis demonstrate the feasibility of using deep residual neural network to extract waterlogging depth information from waterlogging images, meeting the accuracy requirements for waterlogging monitoring in practical applications.

**Keywords** drainage system road waterlogging residual neural network waterlogging depth extraction waterlogging control

随着气候变化和城市化进程加快,城市道路积水问题日益严重。积水带来居民危险、车辆行驶困难、交通事故增加、交通拥堵加剧等城市管理难题。因此,研究城市道路积水识别可及时监测和预警,保障道路交通安全顺畅十分必要。分析积水数据同时也可城市规划 and 基础设施提供参考,用以改善排水系统,优化道路设计,提高防洪能力。

随着计算机技术进步,图像传感器监测道路积水引起学者关注<sup>[1]</sup>。但一般的图像积水监测方法

均需要在项目现场安装大量摄像传感器,不符合低成本需求<sup>[2]</sup>。相比之下,利用计算机视觉深度学习方法从监控视频数据中识别积水深度的研究前景更为明朗。为了训练精准的机器视觉模型,需要大量高质量的训练数据<sup>[3]</sup>。为解决数据量不足问题,FloodX项目创建了全面的城市洪水数据集<sup>[4]</sup>,并通过传统传感器和监控摄像机监测洪水场景。然而,数据集仅限于试验基地,导致图像差异性不足,可能出现局部过拟合风险<sup>[5]</sup>。此外,即使获取大量洪涝

[收稿日期] 2023-05-30

[通信作者] 陈汪洋(1976—),男,高级工程师,主要从事供水排水及环境工程的规划、技术管理及研究等工作,E-mail:chenwangyang@vip.sina.com。

图像,构建合理的识别算法仍然是一个难题<sup>[6]</sup>,因为人眼难以准确判断积水深度。

目前的计算机视觉研究多从侧面入手,直接判断积水深度存在困难。Vitry 等<sup>[7]</sup>提出了基于迁移学习的积水深度提取方法,利用参照物照片和迁移学习模型来判断区域的积水深度。Jiang 等<sup>[8]</sup>则提出了利用现有监视摄像头系统提供定性洪水趋势信息的方法,使用深度卷积神经网络(DCNN)监测洪水,并引入定性洪水指数(SOFI)替代水位波动的观测。研究人员从互联网收集了洪水图像进行神经网络训练,并将其应用于监视视频。通过语义分割方法提取参照物和水面数据,并对比参照物淹没的深度来计算积水深度。这些方法能够在不同角度的照片中提取积水信息,并进行深度估计。

尽管深度神经网络模型在视觉领域逐渐成熟,但将其应用于积水识别仍面临一些问题。首先,现有积水识别算法的精度较低,由于道路积水图像的模糊性,准确辨认具体水深困难。目前的研究多采用参照物的淹没高度来推断积水深度,但这种方法依赖于参照物,难以处理没有参照物的情况。其次,缺乏可用的图像积水数据集,深度学习模型需要大量高质量的数据进行训练,但目前可用的数据集有限,采集困难且数量有限,导致过拟合问题。最后,环境因素对积水识别产生影响,不同拍摄角度、光照和车流等因素会导致积水图像的差异性,使现有算法在实际应用中遇到困难。

针对上述问题,本研究在浙江某市排水公司积水图像数据进行识别的基础上,提出以积水严重程度作为数据集的标签分级,并使用深度残差神经网络(residual network, ResNet)实现对输入图像的积水深度信息提取。

## 1 基于标签分级图像的 ResNet 算法

图像识别在日常生活安全中已经得到广泛应用,例如人脸识别和机动车违章行为鉴别等领域。它也是目标行为理解和视频内容检索等高级计算机视觉问题的基础。然而,在积水图像识别领域中,同一类积水的实例可能存在较大差异,而不同类积水可能非常相似。即使使用严重程度标注的方法对积水图像进行分类,要实现高精度的积水识别仍然具有挑战性。

考虑到积水图像的复杂背景和高难度的特征提

取,本研究在广泛收集数据集的基础上,采用了基于标签分级的 ResNet 作为训练模型的架构。该模型使用了残差块结构,可以在增加网络深度的同时不降低模型的准确率,有效地学习数据集的特征。迁移学习是一种将在某个领域上学习到的特征应用到相关领域的方法。考虑到道路积水图像多发生于城市环境,许多与积水相关的背景已经存在于 ImageNet 数据集中。使用迁移学习方法(即对经过 ImageNet 数据集预训练的神经网络结构进行微调),可以缓解数据集背景不足的问题,提高模型的泛化能力。

ResNet 是一种深度学习算法<sup>[9]</sup>,旨在解决深层神经网络训练中的梯度消失和梯度爆炸问题,并提高网络的准确性和泛化能力。它的核心思想是引入残差连接,允许网络学习输入与输出之间的残差,从而更容易地优化网络参数。ResNet 的基本结构由残差块(residual block)组成,如图 1 所示。每个残差块内部由多个卷积层和批量归一化层构成,并包含了跳跃连接(shortcut connection)。残差块的输入为  $x$ ,经过 2 个卷积层和批量归一化层的处理后,得到残差特征输出  $F(x)$ 。然后将输入  $x$  与残差特征输出  $F(x)$  相加,得到残差块的输出,即  $F(x) + x$ 。这里的加法操作就是残差连接,使得网络能够学习输入与输出之间的残差。ResNet 如式(1)。

$$y = F(x, w) + x \quad (1)$$

其中: $x$ ——输入;  
 $y$ ——输出;  
 $F(x, w)$ ——残差特征输出;  
 $w$ ——网络参数。

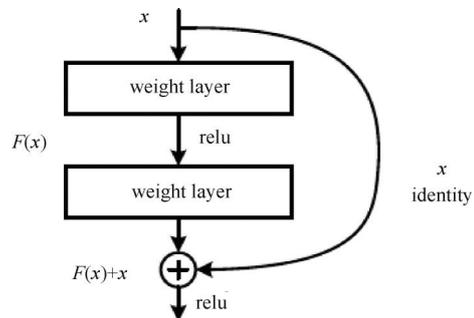


图 1 残差神经网络 block 结构<sup>[10]</sup>

Fig. 1 Block Structure of Residual Neural Network<sup>[10]</sup>

通过引入残差连接,ResNet 可以更容易地训练深层网络,在线性转换和非线性转换之间寻求到了

一个平衡,可以使得模型深度达到数百层依然能达到良好的效果<sup>[11]</sup>。

## 2 研究过程

### 2.1 积水图像数据集来源与收集方法

本研究利用“全球眼”道路监控、网络图像平台以及浙江省某市排水公司的排涝记录作为积水样本数据集,该数据集包含多种场景,并具有高质量。通

过使用这样的数据集,本研究能够有效提高 ResNet 的识别精度和泛化能力。

#### 2.1.1 “全球眼”道路监控

与本研究建立合作的研究单位共有 3 000 余处全球眼监控点,这些监控数据主要由排水调度中心使用,通过工作人员的人工识别来确定积水点,并根据积水的严重程度进行应急车辆的调度,如图 2 所示。

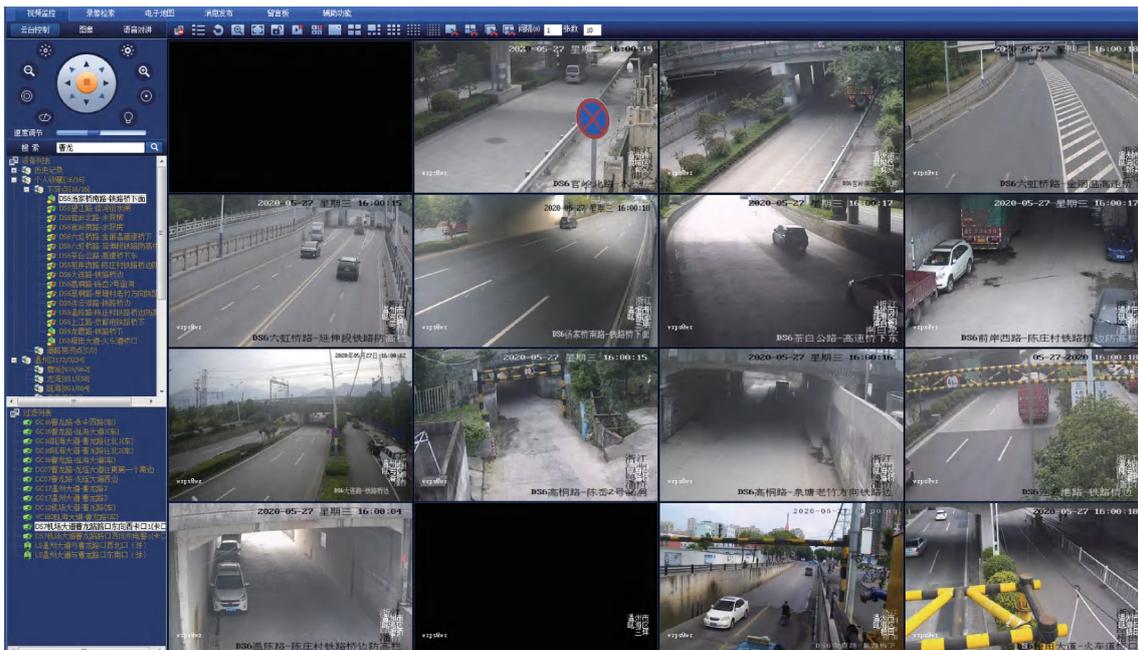


图 2 全球眼系统界面

Fig. 2 Interface of Global Eye System

为了保护道路监控数据的敏感性,全球眼通讯系统采用了端到端加密。由于监控视频流具有大量数据、高传输比特率和强实时性的特点,无法直接从数据流中解析出视频信息。本研究与全球眼系统使用方某市排水公司签署了保密协议,明确约定视频数据仅用于与排水公司业务直接相关的道路积水识别研究,以此获取了使用全球眼系统的权限。

本研究使用 Windows 截屏应用程序编程 (API) 接口来采集研究区域的全球眼数据。数据收集时间为 2020 年 6 月—2020 年 9 月,共计 110 d,数据采集过程如图 3 所示。在该时间段内,研究区域发生了 46 次降雨事件,其中包括 5 次强降雨事件,导致多处道路积水。然而,该数据集中存在大量晴天数据,导致样本不均衡。因此,需要对采集到的无降雨条件下的数据集进行欠采样处理。经过初步筛选后,将被命名为“全球眼数据集”的监控平台图像数据

加入到整个数据集中。

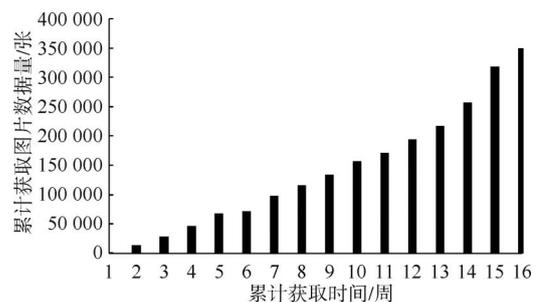


图 3 全球眼数据集构建过程

Fig. 3 Annotation Process of Global Eye Dataset

#### 2.1.2 网络图像平台爬虫

尽管全球眼数据集具有大量的数据,但其场景数量有限(即监控摄像头的视角)。为了提高模型的泛化能力,需要增加数据集的多样性。因此,本研究从百度图片、Google Image 等网络平台上爬取了

1 731 张不同程度积水的图像,并将其命名为“网络平台数据集”,并将其添加到整个数据集中。

### 2.1.3 排水公司排涝记录

通过与某市排水公司合作,获得了排涝过程中拍摄的应急抢险图像记录数据。通过对这些数据进行筛选,将其命名为“应急抢险数据集”,并将其加入到整个数据集中。该数据集涵盖了实际工作中的各种状况,对于图像积水识别算法的实际应用具有重要意义。不同渠道数据集描述如表 1 所示。

表 1 不同数据集描述

Tab. 1 Description of Different Datasets

数据集名称	数据集总数/张	场景数/个	积水图像数/张	非积水图像数/张
全球眼数据集	350 000	268	160 000	190 000
网络平台数据集	1 731	1 731	1 329	402
应急抢险数据集	1 321	462	912	409

## 2.2 数据集预处理

### 2.2.1 积水图像数据集标注方法

在进行模型训练之前,需要对数据集进行积水深度标注。然而,由于积水图像的模糊性和复杂性,即使是人眼也很难准确识别积水的真实深度。在实际应用中,防洪监测人员更多地关注积水的深度区间,而不是准确的深度数值,以此来判断积水的严重程度并制定相应的洪水应急调度方法。因此,为了应对这种情况,本研究提出了一种将连续特征处理为离散特征的方法。本文依据现场安装的电子水尺等传感器历史数据,定义了 5 个积水深度:0、0~5、5~10、10~20 cm 和  $\geq 20$  cm,并将它们对应为 5 个积水严重程度标签:无积水、湿润、浅积水、深积水和严重积水。这 5 个区间标签代表了积水可能造成的不同程度的危害,如图 4 所示。

具体划分过程中,前期与浙江省某市排水公司

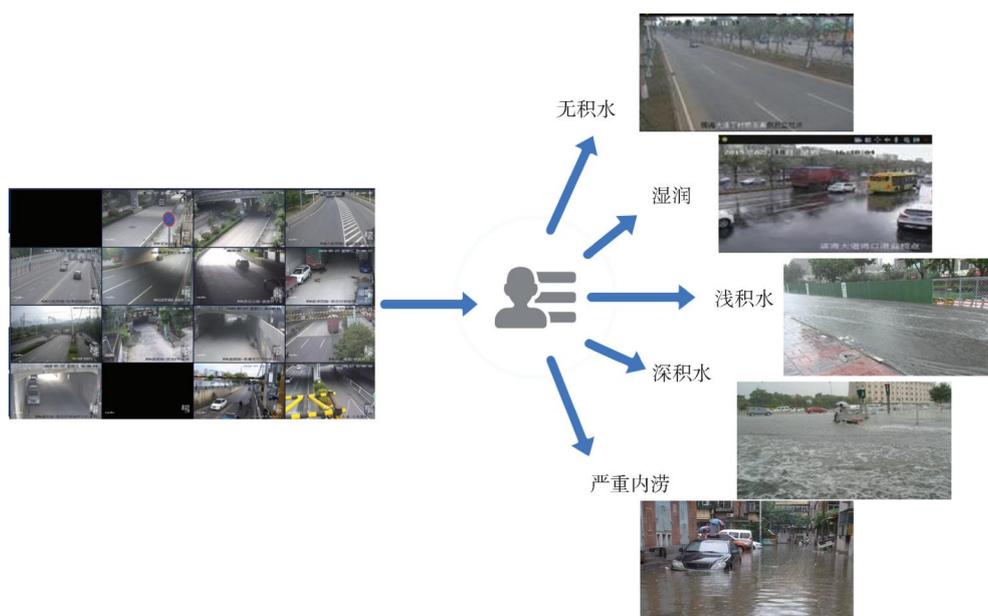


图 4 数据集标注方法

Fig. 4 Annotation Method for Dataset

调度中心的工作人员进行了交流,了解他们在判断道路积水严重程度时的思路。在此基础上,确定了不同场景图像中道路积水深度的辨别方法,全部采用人工分类方式(历经 35 d),对整个积水图像数据集进行了特征划分(表 2)。

### 2.2.2 图像尺寸与格式处理

为了适应 ResNet 的训练,本研究收集的数据集中的图片大小并不完全相同。为了统一输入图像的

表 2 不同严重程度积水图像描述

Tab. 2 Descriptions of Different Severity Levels of Waterlogging Images

严重程度	无积水	湿润	浅积水	深积水	严重积水
数量/张	81 641	88 923	71 254	63 937	47 297

像素尺寸,将其调整为 214×214。同时,为增强积水识别算法的鲁棒性,对输入图像进行了一系列的处理操作,包括随机裁剪、随机反转、曝光度亮度调整、

灰度切片等。最后,将处理后的图像转换为 PyTorch 机器学习库可处理的 tensor 变量,以便进行后续的模型训练和处理。

### 2.3 基于标签分级的数据场景预训练的迁移学习方法

虽然本研究使用了较大规模的训练数据集,但由于场景数量相对较少,存在过拟合的风险。为了缓解这种场景数量不足的问题,采用了“迁移学习策略”,用于提升系统性能。“迁移学习策略”是指将已经在大量数据上训练过的深度学习模型架构再次应用于类似的任务中,并微调已学到的特征参数,然后将其重新应用于新任务,以提高模型的泛化能

力。如果预训练模型已经学习到足够多的特征,迁移后的模型只需要很少的训练样本就能取得良好效果。此外,迁移学习不仅仅针对特定任务,预训练模型在学习了训练数据集后具有一些通用的特征能力。例如,在本研究中,为了得到积水识别模型,在预训练模型已经能够识别道路、车辆、灯杆等标识物的基础上,只需要进一步学习积水与这些标识物交叉的信息。

本研究采用了 ResNet50 神经网络架构作为预训练模型。ResNet 架构如图 5 所示。在使用道路积水训练集对模型进行训练之前,已经使用 ImageNet 数据集对模型进行了预训练。

网络层名称	输出层大小	18-层	34-层	50-层	101-层	152-层
conv1	112×112	7×7, 64, 步幅2				
		3×3最大池, 步幅2				
conv2_x	56×56	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
conv3_x	28×28	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 8$
conv4_x	14×14	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 36$
conv5_x	7×7	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
	1×1	平均池化, 1 000维全连接层, softmax池化函数				
FLOPs		1.8×10 <sup>9</sup>	3.6×10 <sup>9</sup>	3.8×10 <sup>9</sup>	7.6×10 <sup>9</sup>	11.3×10 <sup>9</sup>

图 5 ResNet 网络架构<sup>[10]</sup>

Fig. 5 Framework of ResNet Network<sup>[10]</sup>

在实际训练过程中,首先使用“全球眼数据集”训练神经网络所有层,接着冻结除最后一层外所有层,使用“网络平台数据集”“应急抢险数据集”训练最后一层,以使得神经网络尽可能学习不同场景下积水特征,提高模型的泛化能力。

## 3 研究结果与分析

### 3.1 模型评估标准

目前国内外研究主要使用图像识别准确率作为计算机视觉性能评估的标准,以计算量作为运算效率评估的标准。其中,图像识别准确率即不同严重程度积水识别准确占比计算如式(2)~式(3)。

$$acc(f;D) = \frac{1}{m} \sum_{i=0}^m \prod [f(x_i) = y_i] \quad (2)$$

$$D = \{(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)\} \quad (3)$$

其中: $D$ ——给定测试集;

$m$ ——测试集样本数量;

$f(x_i)$ ——模型输出;

$acc(f;D)$ ——图像识别准确率;

$\prod (\cdot)$ ——为指示函数,在 $\cdot$ 为真时取 1,否则取 0。

计算量一般用每秒浮点型计算次数表示,卷积层每秒浮点型计算次数计算方法如式(4)。

$$C_{CCF} = (2 \times C_i K^2 - 1) \times HWC_0 \quad (4)$$

其中: $C_{CCF}$ ——卷积层每秒浮点型计算次数;

$C_i$ ——输入通道数量;

$K$ ——卷积核尺寸;

$H$ ——输出特征数量;

$W$ ——图像尺寸;

$C_0$ ——输出通道。

全连接层每秒浮点型计算次数计算方法如式(5)。

$$F_{\text{FCLF}} = (2 \times I - 1) \times O \quad (5)$$

其中:  $F_{\text{FCLF}}$ ——全连接层每秒浮点型计算次数;

$I$ ——输入神经元数量;

$O$ ——输出神经元数量。

### 3.2 不同神经网络算法性能评估

本文使用 ResNet34、ResNet50、VGG 和 AlexNet 等网络对原始积水数据集进行训练,并比较它们的性能。表 3 展示了 4 种网络在原始积水数据集上的试验结果。每个神经网络都经过学习率和批量大小的优化,以确保训练参数的最佳设置。同时,监控训练集误差和验证集误差,并设置早停机制,以避免模型过拟合。ResNet 的效果明显优于传统算法如 VGG 和 AlexNet。正如前文所述,由于本研究采用了较大规模的训练集,更深的 ResNet50 可以取得更好的训练效果。因此,本研究选择了 ResNet50 作为神经网络训练架构。

表 3 4 种神经网络在积水数据集的识别准确率对比  
Tab. 3 Comparison of Recognition Accuracy of Four Neural Networks on Waterlogging Dataset

模型	预训练	最高识别精度	每秒浮点型计算次数
ResNet34	True	96.1%	3.58G
ResNet50	True	96.5%	6.31G
VGG16	True	93.7%	14.94G
AlexNet	True	94.1%	0.71G

文献<sup>[5-6]</sup>显示,现有图像积水识别的研究集中在积水范围的识别,此类研究对积水范围的识别精度在 75%~85%,相比之下本研究不仅能实现积水深度的识别,且能达到更高精度(表 3),表明本研究所提出积水图像识别算法的效果较佳。

图 6 为 4 种神经网络训练样本大小与道路积水识别准确率的对比,针对不同的训练样本数量,每个标签的样本数量遵循表 3 中各类别之间的比例关系。由图 6 可知,4 种神经网络模型识别准确率随着训练样本数量的增加而不断提升,其中,ResNet50 模型表现出最佳的性能,在实际城市道路积水深度识别应用中具备更高的识别精度和鲁棒性能。

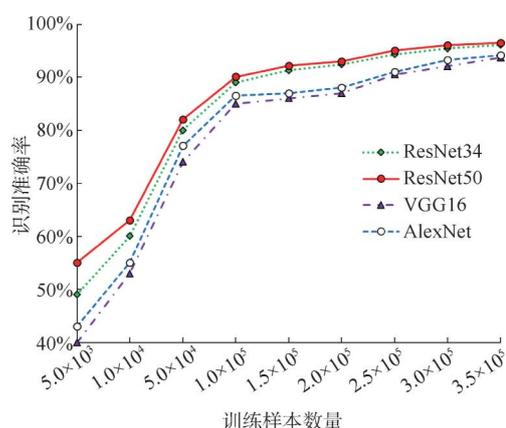


图 6 训练样本尺寸与识别准确率对比

Fig. 6 Comparison of Training Sample Size and Recognition Accuracy

## 4 结论

本文提出一种使用基于标签分级的 ResNet 从图像中提取积水信息的算法,具体步骤为:积水图像数据搜集、积水图像数据处理、积水图像特征分级、积水图像数据预训练和基于分级目标的积水程度图像识别

从“全球眼系统”“网络平台”“洪涝应急抢险照片”多渠道收集数据集,解决了积水图像数据集数量不多、质量不高的问题;以积水严重程度作为标签分级,解决了现有研究无法识别积水深度的问题,在原始测试集上可以达到 96.5% 的准确率。实例分析结果表明,采用 ResNet 从积水图像中提取积水深度信息的方法确实可行,并且在实际应用中能够满足积水监测的精度要求。

基于 ResNet 的道路积水深度提取方法具有广泛的应用前景,不仅可以为城市规划部门提供积水信息,帮助规划防洪设施、改善城市排水系统等,还可以应用于交通管理部门进行道路积水监测和预警,此外还可以应用于自动驾驶系统中,帮助车辆正确判断和应对道路积水情况,提高行车安全性。

## 参考文献

- [1] 吴俊毅, 秦华鹏. 基于一二维耦合内涝模型的城市道路积水来源量化分析[J]. 北京大学学报(自然科学版), 2021, 57(4): 716-722.
- WU J Y, QIN H P. Quantitative source analysis of waterlogging on urban roads based on a 1D and 2D coupling waterlogging model [J]. Acta Scientiarum Naturalium Universitatis Pekinensis, 2021, 57(4): 716-722.

- [ 2 ] 李振. 城市道路积水监控系统设计与实现[D]. 成都: 电子科技大学, 2013.  
LI Z. Design and implementation of water monitoring information system of city road [D]. Chengdu: University of Electronic Science and Technology of China, 2013.
- [ 3 ] CHANDLER J, ASHMORE P, PAOLA C, et al. Monitoring river-channel change using terrestrial oblique digital imagery and automated digital photogrammetry[J]. *Annals of the Association of American Geographers*, 2002, 92(4): 631-644.
- [ 4 ] ANDREAS H, FEUERSTEIN U, LUKAS R, et al. Methodological advances, challenges and perspectives in field phenotyping and its application to forage crops[J]. *Grassland Science in Europe*, 2019, 24: 295-305. DOI: 10.3929/ethz-b-000353856.
- [ 5 ] PILOTTI M, MENDUNI G, CASTELLI E. Monitoring the inception of sediment transport by image processing techniques [J]. *Experiments in Fluids*, 1997, 23(3): 202-208.
- [ 6 ] GHORBANIDEHNO H, LEE J, FARTHING M, et al. Deep learning technique for fast inference of large-scale riverine bathymetry [J]. *Advances in Water Resources*, 2021, 147: 103715. DOI: 10.1016/j.advwatres.2020.103715.
- [ 7 ] VITRY M M, KRAMER S, WEGNER J D, et al. Scalable flood level trend monitoring with surveillance cameras using a deep convolutional neural network [J]. *Hydrology and Earth System Sciences*, 2019, 23(11): 4621-4634.
- [ 8 ] JIANG J C, LIU J Z, QIN C Z, et al. Extraction of urban waterlogging depth from video images using transfer learning [J]. *Water (Switzerland)*, 2018, 10(10): 1485.
- [ 9 ] WU Z F, SHEN C H, HENGEL A V D. Wider or deeper: Revisiting the resnet model for visual recognition [J]. *Pattern Recognition*, 2019, 90: 119-133. DOI: 10.1016/j.patcog.2019.01.006.
- [ 10 ] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [C]. Las Vegas: 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016.
- [ 11 ] 王飞, 张莹, 邵豪, 等. 多尺度残差网络模型的研究及其应用 [J]. *电子测量与仪器学报*, 2019, 33(4): 19-28.  
WANG F, ZHANG Y, SHAO H, et al. Research and application of the multi-scale residual networks model [J]. *Journal of Electronic Measurement and Instrumentation*, 2019, 33(4): 19-28.

(上接第 137 页)

- [ 24 ] SONG W, GAO B Y, WANG H L, et al. The rapid adsorption-microbial reduction of perchlorate from aqueous solution by novel amine-crosslinked magnetic biopolymer resin [J]. *Bioresource Technology*, 2017, 240: 68-76. DOI: 10.1016/j.biortech.2017.03.064.
- [ 25 ] MINALE M, GU Z L, GUADIE A, et al. Hydrous manganese dioxide modified poly(sodium acrylate) hydrogel composite as a novel adsorbent for enhanced removal of tetracycline and lead from water [J]. *Chemosphere*, 2021, 272: 129902. DOI: 10.1016/j.chemosphere.2021.129902.
- [ 26 ] LÜ L, HE J, WEI M, et al. Treatment of high fluoride concentration water by MgAl-CO<sub>3</sub> layered double hydroxides: Kinetic and equilibrium studies [J]. *Water Research*, 2007, 41(7): 1534-1542.
- [ 27 ] CHINOUNE K, BENTALEB K, BOUBERKA Z, et al. Adsorption of reactive dyes from aqueous solution by dirty bentonite [J]. *Applied Clay Science*, 2016, 123: 64-75. DOI: 10.1016/j.clay.2016.01.006.
- [ 28 ] ZOHRA B, AICHA K, FATIMA S, et al. Adsorption of Direct Red 2 on bentonite modified by cetyltrimethylammonium bromide [J]. *Chemical Engineering Journal*, 2008, 136(2/3): 295-305. DOI: 10.1016/j.cej.2007.03.086.
- [ 29 ] 陈瑶. 废白土炭基材料制备及其对水中有机污染物的去除研究 [D]. 郑州: 河南工业大学, 2021.  
CHEN Y. Study on the preparation of spent bleaching earth carbon-based materials and the removal of organic pollutants from aqueous solution [D]. Zhengzhou: Henan University of Technology, 2021.
- [ 30 ] WAN D J, WU L R, LIU Y D, et al. Adsorption of low concentration perchlorate from aqueous solution onto modified cow dung biochar: Effective utilization of cow dung, an agricultural waste [J]. *Science of the Total Environment*, 2018, 636: 1396-1407. DOI: 10.1016/j.scitotenv.2018.04.431.
- [ 31 ] ZHU X D, LIU Y C, QIAN F, et al. Preparation of magnetic porous carbon from waste hydrochar by simultaneous activation and magnetization for tetracycline removal [J]. *Bioresource Technology*, 2014, 154: 209-214. DOI: 10.1016/j.biortech.2013.12.019.
- [ 32 ] WAN D J, CHENG X F, SHI Y H, et al. Insights into lead removal in water using a novel carbonized material derived from the by-product of oil refining: Action mechanism and performance optimization [J]. *Journal of Chemical Technology and Biotechnology*, 2021, 96(11): 3224-3236.
- [ 33 ] 陈忻, 孙恢礼, 潘嘉慧. 壳聚糖及其衍生物对染料废水的脱色研究 [J]. *环境科学与技术*, 2007, 30(9): 86-88.  
CHEN X, SUN H L, PAN J H. Decolorization of dyeing wastewater using chitosan materials [J]. *Environmental Science and Technology*, 2007, 30(9): 86-88.