

基于深度神经网络的渠道水毁智能检测方法研究

王泽鹏 李宏强

河南省濮阳市引黄工程管理处 河南 濮阳 457000

摘要: 由于渠道距离长、周边环境复杂等因素,渠道水毁检测在水利工程中是一个难点。针对这一问题,提出了一种基于深度神经网络的渠道水毁智能检测方法,主要解决河道管理中水毁问题的识别与分类。具体地,首先利用多旋翼无人机对渠道图像数据进行采集,并对数据进行扩充以增加训练数据数量和保持鲁棒性;然后对训练数据进行标注,利用改进的ResNet-18网络对标注数据进行训练;最后对测试数据进行分类测试。对渠道共采集了40000张图像数据,其中训练数据28000张,测试数据12000张。实验结果显示该方法能够对渠道管理中的水毁问题实现精准快速地识别和分类,能够为后续渠道治理提供准确位置和图像依据。

关键词: 河道管理;渠道水毁检测;智慧水利;图像处理;深度学习

0 引言

渠道水毁检查是水利工程中一项重要的任务,由于渠道长、周边环境复杂等原因,巡检人员无法实时监控渠道情况,衬砌裂缝、塌陷、损坏、雨淋沟等问题不能得到及时发现和治理,造成了很大的安全隐患。针对此类情况,研究人员提出了很多解决方案,取得了一定的成效。传统的渠道水毁检查方式都是基于人工巡检,在效率和频次上都受到了限制。尤其是周边环境复杂的河道,巡检人员无法达到现场查看水情,给工作带来了极大的不便。

近年来,无人机技术得到了突飞猛进的发展,小型化、轻量化和信息化的无人机也在农林业、城市交通、安防等领域得到了广泛应用。搭载了高清摄像头的无人机,能够代替人工到危险区域或人员不易到达的场所查看现场情况,为后续决策提供事实依据。无人机在渠道管理中的应用也很有发展前景。由于渠道长、交通不便等因素,巡检人员只能沿着河边或在桥上进行巡查、拍摄取证,无法到达现场查看详情,导致巡检效率低、危险系数大等问题。此时利用信息技术、航空技术和3S技术等的无人机系统就发挥了重要的作用,它操作简单、机动灵活的特点让其能够亲临现场详细查看衬砌、水闸现状以及水流情况,实现高效率的渠道巡检工作。基于无人机系统的渠道巡检方式突破了传统人工巡检方式的束缚,能够快速获取垃圾淤积、违建乱栽、游泳捕鱼、水面污染等水事违法行为的情况,大大提升了渠道巡检效率^[1]。

然而基于无人机获取的渠道图像数据仍需要人工排查才能发现河道管理中的问题。为了进一步提升巡检效率,本文引入深度学习对图像数据进行自动识别和

分类。深度学习是近年来新兴的技术,在图像处理中得到了广泛的应用,可以用其实现图像识别或分类的任务。深度学习不需要指定特定的特征,它在学习的过程中会自动选择最优特征,然后根据特征和标签进行图像的识别和分类。在渠道水毁检测任务中,我们事先设定无人机沿渠道的飞行路线,在其飞行过程中采集渠道的视频数据,然后将视频帧分为图像,使用深度学习即可完成图像识别任务。

1 整体方案设计

针对渠道水毁问题和现存检测方法的缺陷,本文提出了一种基于深度神经网络的渠道水毁智能检测方法。该方法首先将无人机采集的视频数据转换为图像,并对图像进行预处理。然后根据经验对图像进行标注。本文将图像分为正常图像和异常图像,其中异常图像分为衬砌裂缝、衬砌损毁、雨淋沟三种。最后,利用改进的ResNet-18网络对标注数据进行训练,并在测试集上进行测试。本文的检测方法能够快速识别无人机拍摄的视频数据是否存在渠道水毁问题,提高了河道管理效率。整体设计方案如图1所示,本文将正常图像和异常图像按比例融合后输入ResNet-18网络中提取特征,ResNet-18网络包含5个卷积块(res1至res5),一个全局池化层(GAP)和一个softmax层。

本文以引黄入冀补淀工程(河南段)为例,具体说明基于深度神经网络的渠道水毁智能检测方法。引黄入冀补淀工程是国务院确定的节水供水重大水利工程,工程于2017年建成通水,工程为沿线部分地区农业供水和向白洋淀实施生态补水,缓解沿线地区农业灌溉缺水及地下水超采状况,改善白洋淀生态环境,并可作为沿线地区抗旱应急备用水源。工程渠首设计引水流量为150立

方米每秒，引水线路全长482公里，其中河南境内84公里。工程自通水以来，至2023年2月底，渠首闸共引黄河

水约39.6亿立方米，其中河北用水25.6亿立方米，濮阳市14亿立方米，工程效益得到了充分发挥。

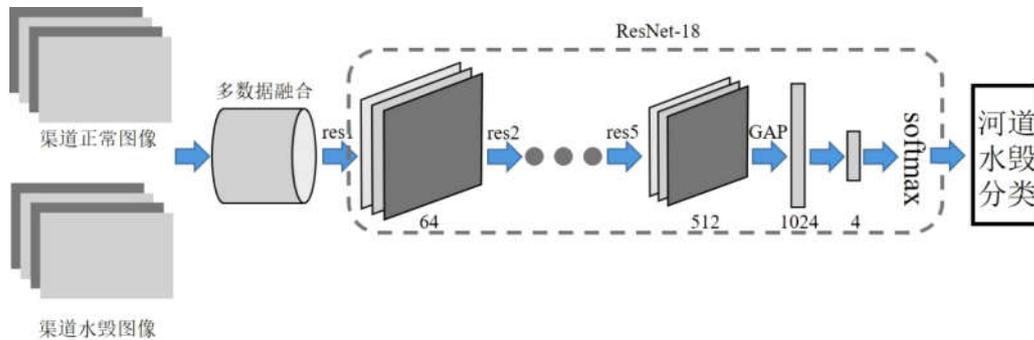


图1 本文的整体设计方案

2 算法模型

渠道水毁检测可以考虑为一个多分类任务，即分为正常图像和各类异常图像。我们认为一个近乎完美的分类方法可以在识别异常图像的同时，保持很高的正常图像识别率。为了实现这一目的，我们采用了一个经典的分类网络模型——ResNet-18^[2]。

2.1 图像预处理

无人机采集的渠道数据中，通常异常数据较少。异常数据如图2所示。本文采用随机翻转、裁剪、颜色变化、加入随机噪声等方法对图像数据进行扩充，以增强训练数据、提升模型鲁棒性。随后对图像进行标注，并将图像分为训练集和测试集。



图2 渠道水毁图像示例

2.2 多数据融合

本文采集的图像数据包含多种标签，由于不同标签数据的特征和数量不同，因此将数据直接随机结合在一起训练不是一个好的方法。为了充分利用不同数据的特征，本文采用一种多数据融合的方法，该方法能够调整输入数据的比例，使得训练的权重不会偏颇。输入数

据包含四类标签，分别为正常图像、衬砌裂缝、衬砌损坏、雨淋沟，多数据融合方法每批次按比例选择不同类型的图像并把它们送入网络进行训练。经过5个卷积块后，提取出输入图像的深度特征，全局平均池化层（GAP）将降低深度特征的维度，再经过两个全连接层后，利用softmax loss损失函数将输入图像分为两类——正常图像和各类异常图像。

2.3 损失函数及图像分类

损失函数是用来评价模型的预测值与真实值之间的相似程度，损失函数越小，则模型越好。通过损失函数来做反向传播不断更新模型参数，达到最优预测值的目的。深度神经网络提取的特征在输入全连接层之前，会将特征矩阵压缩为一个N1的向量X。全连接层的任务就是训练一个T行N列的权值矩阵W，以达到最优的图像分类效果，这里的数值T指的是图像类别。

经过全连接层后得到一个T1的向量L，由于向量中的每个数值都没有限制，因此采用softmax将每个值都控制在0~1之间，即转化为了属于某一类的概率。公示如下：

$$S_j = e^{a_j} / \sum_{k=1}^T e^{a_k} \quad (1)$$

Softmax loss公示如下：

$$L = - \sum_{j=1}^T y_i \log S_j \quad (2)$$

其中 S_j 表示softmax输出向量的第j个值， y_i 表示第i张图像的真实标签值，T表示图像类别数，在本文中 $T=4$ ，也即正常图像、衬砌裂缝、衬砌损坏、雨淋沟四类。

3 测试结果与分析

3.1 数据集采集

所有的数据都来采集于无人机。无人机操作员采用一台搭载35mm定焦镜头相机的轴距为1100mm的六旋翼无人机，以20m的高度，1.5m/s的速度沿着引黄入冀补淀总干渠桩号3+000~8+000段进行数据采集。经过对原始视

频数据的处理，最终得到40000张的数据，每张图像像素为480×640。数据集中包含有正常图像以及衬砌裂缝、衬砌损坏、雨淋沟三类渠道水毁图像。在训练过程中，按照7：3的比例将数据分为训练集和测试集。

3.2 硬件平台和训练方法

本文采用Caffe框架来训练模型。在训练过程中，每批次随机选取256张图像训练10个周期，每批次中正常图像和异常图像的比例为1：1。本文设置初始学习率为0.01，在10000次迭代后，学习率将变为0.005。本文将权重衰减和动量分别设置为0.0002和0.9。该模型在一台装备有8块 NVIDIA 1080ti GPU的设备上使用随机梯度下降（Stochastic Gradient Descent, SGD）算法进行训练，整个训练过程约8min。

3.3 实验结果及分析

3.3.1 数据融合方法的比较

本文分别采用随机数据融合的方法和多数据融合方法进行分类识别准确率的测试，训练过程如图3所示。

根据实验结果，在30000轮训练后，采用多数据融合的训练方法，其测试集识别准确率达96%左右，高于采用随机数据融合方法的90%。此外，采用多数据融合的方法也比采用随机数据融合的方法能更快的收敛，约经过20000轮训练后，采用多数据融合方法的分类准确率就能达到96%。

3.3.2 不同分类方法的比较

本小节采用不同的分类方法对水毁图像进行分类。通过深度神经网络提取出图像的特征后，采用K-Means聚类、高斯混合模型GMM来进行分类。对于K-Means聚类，本文选取K = 4，即将图像聚为4类，每一类都为同一类型的水毁类别。对于GMM，本文将高斯混合模型的组分设置为4，代表4种不同的类别。实验结果如表1所示，由实验结果可以看出，本文提出的方法有最好的分类效果。

表1 不同分类方法准确率比较

分类方法	K-Means	GMM	本文方法
准确率	82.37%	85.18%	96.05%

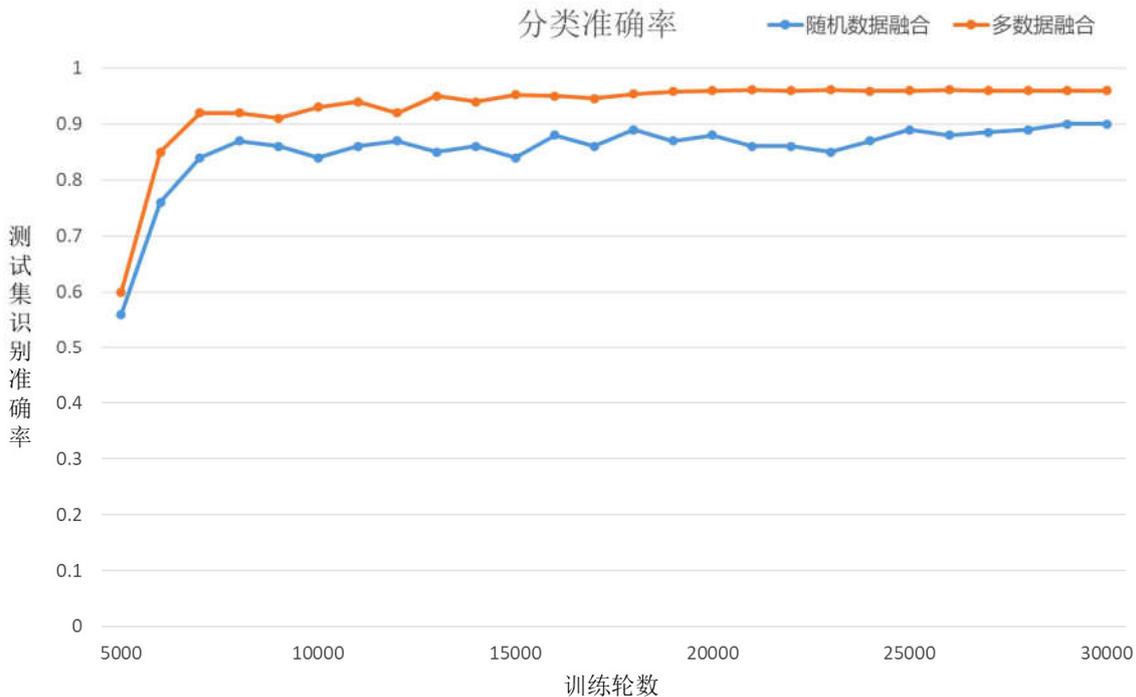


图3 两种不同数据融合方法的比较

4 结论

本文针对水利工程中渠道水毁检测问题，提出了采用深度神经网络和多数据融合的方法进行渠道水毁分类，并在测试集上取得了较高的识别率。实验结果表明，本文提出的方法能适用于水利工程中的渠道水毁检测，较好的识别衬砌裂缝、衬砌损毁、雨淋沟等水毁现象，提高了巡检效率，具有较高的工程应用价值。

参考文献

[1]陈波,张华,王姮,等.基于迁移学习的坝面表面缺陷智能检测方法研究[J].水利水电技术,2020,51(4):106-112.
 [2]K.He, X. Zhang, S. Ren, and J. Sun., Deep residual learning for image recognition, In CVPR, pages 770-778, 2016.