

DOI: 10.13382/j.jemi.B2205923

# 基于改进 U-net 网络的液压管路分割方法<sup>\*</sup>

张 平<sup>1</sup> 佟昆宏<sup>1</sup> 王学珍<sup>2</sup>

(1. 西安建筑科技大学机电工程学院 西安 710055; 2. 上海宝冶集团有限公司 上海 201999)

**摘 要:**针对液压管路背景多变、管道弯折、管道重叠排布等复杂现象且现有图像分割方法对管路分割精度不高等问题,提出一种以 U-net 网络为基础,结合 Mobilenetv3 网络、SE 注意力机制模块、自校正卷积模块的液压管路分割方法。该方法以 Mobilenetv3-large 模型作为骨干网络,结合 LR-ASPP 网络处理特征图;在解码过程中,融入 SE 注意力模块和 SC 自校正模块,提升了特征提取能力;最后采用 Dice 函数和 BCE 函数的组合来作为网络的损失函数,有效地提升了网络的收敛能力。实验结果表明本文提出的方法在交并比、像素精度指标上的均值分别达到 90.8%、95.2%,且模型体积为 16.9 M,推理每张图像所耗时间 20 ms,可应用于需实时部署的场景,为液压管路渗漏的准确识别提供了基础。

**关键词:** 液压管路;图像分割;Mobilenetv3 网络;注意力机制;SC 自校正模块

**中图分类号:** TP391.4 ; TH137.8<sup>+</sup>6      **文献标识码:** A      **国家标准学科分类代码:** 520.2040

## Hydraulic pipeline segmentation method based on improved U-net network

Zhang Ping<sup>1</sup> Tong Kunhong<sup>1</sup> Wang Xuezheng<sup>2</sup>

(1. College of Mechanical & Electrical Engineering, Xi'an University of Architecture and Technology, Xi'an 710055, China;  
2. Shanghai Baoye Group Co., Ltd., Shanghai 201999, China)

**Abstract:** Aiming at the complex phenomena such as variable background, bending and overlapping arrangement of hydraulic pipeline and the low accuracy of pipeline segmentation by existing image segmentation methods, a hydraulic pipeline segmentation method based on U-net network, combined with Mobilenetv3 network, squeeze-and-excitation networks module and self-calibration convolutional module is proposed. The method selected Mobilenetv3-large model as the backbone network, and the feature maps are processed with Lraspp network. In the decoding process, the squeeze-and-excitation networks module and self-correction module are integrated to improve the feature extraction ability. Finally, the combination of Dice function and BCE function is used as the loss function of the network, which effectively improves the convergence ability of the network. Experimental results show that the mean values of the proposed method in the intersection over union and pixel accuracy are 90.8% and 95.2%, respectively. The model size is 16.9 M, and the reasoning time for each image is 20 ms, which can be applied to the scene requiring real-time deployment. It provides a basis for the accurate identification of hydraulic pipeline leakage.

**Keywords:** hydraulic line; image segmentation; Mobilenetv3 network; mechanism of attention; SC self-correcting module

## 0 引 言

液压油泄漏是液压系统在实际工作中经常发生的故障,研究表明及早发现泄漏区域能够减小液压泄漏造成的损失<sup>[1]</sup>。目前对液压管路泄漏方面尤其是液压管路渗

漏的准确定位和实时检测研究较少,且主要依靠人眼观察或通过荧光示踪剂进行观察<sup>[2]</sup>,但这些方法对操作人员的工作状态及专业素质要求较高、且难以达到实时检测的目的,容易对后续的生产活动造成重大的影响。

近年,随着数字图像处理和机器视觉技术的发展,其已用到管道渗漏检测。文献[3-6]通过对渗漏现象的运

动特征处理和分析来检测液压管路渗漏现象。然而液压管路具有小管径、规格多、类型多、管路结构复杂、图像背景复杂、多角度布置安装等特点,因此为实现液压管路渗漏的准确识别,首先需对管路图像进行精准分割。因此,液压管路的精准分割对液压管路检测和保障其安全运行具有十分重要的意义。

传统的管道分割方法主要以监督方法分割和阈值分割为主,李大华等<sup>[7]</sup>基于细胞免疫机制提出了一种改进的 OTSU 算法,提取了高温蒸汽管道区域;彭道刚等<sup>[8]</sup>通过改进二维 OTSU 的联合密度计算公式将管道从复杂背景中提取出来;Shao 等<sup>[9]</sup>通过两次阈值分割得到高温管道区域;王乐等<sup>[10]</sup>利用 Canny 算子进行水下管道的边缘检测并进行分割处理;黄子明等<sup>[11]</sup>基于直方图概率密度函数的 OTSU 双阈值分割方法对管道区域分割。张艳博等<sup>[12]</sup>利用红外热成像方法提取管道区域并利用热像图的温差判断泄漏点。传统管道分割方法大多采取人工设计特征的方式,易受光照、噪声、目标特征变化等因素干扰,实际应用中存在分割效果差、识别速度慢等缺点,难以进行有效的管道区域提取。

近年来,基于卷积神经网络的深度学习方法已经用于管道图像分割处理。李伟等<sup>[13]</sup>结合 Mask-RCNN 与 CCTV 检测方法检测排水管道,获得了较高的准确率。罗东浩<sup>[14]</sup>在研究海底管道泄漏检测方法时,同时使用了 FCN 与 U-net 方法,证实了 U-net 网络具有更好的效果。Zhou 等<sup>[15]</sup>借鉴生物神经网络调控免疫系统的机理,设计一种基于神经免疫网络的复杂背景下红外管道目标的检测与提取算法,但是实时性较差且相应增加工业成本。Bharti 等<sup>[16]</sup>提出了一种新的自监督机制,用于以实时微

调预先训练的 U-Net 网络模型,对海底管道进行检测与分割。

尽管研究人员在管道语义分割任务上已经做了许多研究,但是大多数以水管和大型工业管道为主,此类管道具有管径大、管道排布整齐、背景相对单一等特点,这与前述液压管路特点不一致,因此上述方法无法得到准确的液压管路边缘信息且易出现液压管路图像信息缺失的情况,故满足不了液压管路的分割要求。针对此,本文提出了一种基于改进 U-Net 的液压管路分割方法,缩小了模型体积、提升了特征提取能力和收敛能力。

## 1 改进的 U-net 网络

### 1.1 网络结构

针对液压管路的识别特点,本文对 U-net 网络进行了改进,结构如图 1 所示,使用 Mobilenetv3 作为主干网络,右侧为特征融合网络。输入图像可以是任意大小的液压管道图像,在输入网络之前,首先对图像进行数据增强、归一化、减均值等预处理操作。预处理图像进入网络后,通过骨干网络对原始图像进行特征提取,得到 1/2, 1/4, 1/8, 1/16 这 4 种不同尺度的特征图。最小尺度的特征图会经过 LR-ASPP 模块做进一步处理。在解码过程中,本文引入了 SE 特征注意力模块和 SC 自校正卷积层作为解码层。在特征图自顶向下的传播过程中,每个解码层的输出会与对应的编码层得到的输出进行向量拼接,然后作为下一层的输入,最后经输出层,得到输入图像的掩模图。




图 1 改进的网络模型结构图

Fig. 1 Structure diagram of the improved model

## 1.2 编码器结构

在原始的 U-net 网络中,使用的是 5 层常规的卷积层来进行特征图的提取操作。但通过这种网络结构并不能高效充分地提取图像的信息,并且过多参数会使运算速度较慢和模型体积较大。为了充分提取图像信息,以及减少模型体积便于模型后期部署,引入 Mobilenetv3 网络来替换原有的特征提取结构。Mobilenetv3 是谷歌开源的一个轻量化网络结构,可用于模型在移动端的部署。在 v3 中采用了神经架构搜索方法 (neural architecture search, NAS),该方法可以找到最匹配当前网络结构的超参数<sup>[17]</sup>。在 Mobilenetv3 中,Block 模块是其最基本的模块,通过连续堆叠多个 Block 模块得到 Mobilenetv3 网络。并且在 Mobilenetv3 中存在 v3-small 和 v3-large 两个版本,根据实际需求,选择 v3-large 作为骨干网络。激活函数 h\_swish( $x$ ) 是在 ReLU6 激活函数的基础上进行改进,可减少参数量提升推理速度,如式 1 所示。并且本文在 Mobilenetv3 结构后添加了 LR-ASPP 模块,来进一步处理特征图,其作用在于增加特征图所包含尺度,并且不会引入过多的计算力,有利于分割任务<sup>[16]</sup>。

$$h\_swish(x) = x \cdot \frac{\text{ReLU6}(x + 3)}{6} \quad (1)$$

式中: $x$  为输入;ReLU6 为激活函数; $h\_swish(x)$  为改进后的激活函数。

## 1.3 压缩激活模块

在特征图中,不同位置上的像素重要性是不同的,抑制背景信息而突出目标特征信息也是提升模型分割精度的重要方法。在深度学习中,常使用注意力模块来增强有意义的目标特征。SE 模块主要分为两个部分:压缩和激励<sup>[18]</sup>,如图 2 所示。压缩使用全局平均池化的操作,降低信息的维度,如式 (2) 所示。激励则是为了获取不同通道的特征图的权重,具体操作是全连接层-ReLU-全连接层-sigmoid 函数,如式 (3) 所示。最后再加权到各个通道的特征上,如式 (4) 所示。

$$S_c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W U_c(i, j) \quad (2)$$

式中: $U_c(i, j)$  表示上个卷积核输出的多维矩阵向量中的第  $c$  维矩阵中的第  $i$  行第  $j$  列元素; $H$  和  $W$  则表示矩阵的高和宽; $S_c$  则是  $c$  维矩阵压缩后的结果。

$$E_c = \sigma[W_2 f(W_1 S_c)] \quad (3)$$

式中: $W_1$  与  $W_2$  分别是全连接层或者卷积层的降维权值与升维权值; $f$  则是 ReLU 激活函数; $\sigma$  则是 sigmoid 激活函数; $E_c$  则是  $c$  维通道的权重值。

$$\tilde{X}_c = E_c \cdot U_c \quad (4)$$

式中: $\tilde{X}_c$  表示  $c$  维的最终特征。




图 2 压缩激活模块流程

Fig. 2 The flow chart of the Squeeze Excitation module

## 1.4 自校正卷积模块

使用常规的卷积核通常难以获得较大的感受野,即使是添加注意力模块,也会受到这方面的限制。而自校正卷积具有更大的感受野,有助于捕获整个特征区域。SCConv 结构可以通过自校正操作适应地在每个空间位置周围建立远程空间和通道间依存关系,在不增加额外参数和复杂性的情况下提高模型的整体性能<sup>[19]</sup>。如图 3 所示,首先是拆分输入特征图,保持宽高不变,通道数为原来 1/2 的两个特征图,如式 (5) 所示;输入为  $C \times H \times W$  的特征图,输出通道也为  $C$  的卷积中,卷积核的维度为  $C \times C \times H \times W$ ,然后将卷积核拆分为 4 个部分  $K_1, K_2, K_3, K_4$ ,每个部分的维度为  $C/2 \times C/2 \times H \times W$ 。拆分卷积核的主要是为了有效地收集每个空间位置的上下文信息。然后对特征图  $X_1$  进行处理,其主要步骤为平均池化-上采样-sigmoid 激活-卷积操作,如式 (6) ~ (9) 所示。然后对另一条分支上的特征图  $X_2$  经过卷积核  $K_1$  提取得到特征  $Y_2$ ,最后再对  $Y_1$  和  $Y_2$  进行拼接操作,得到最终的输出特征。与传统卷积相比,自校正卷积有效地扩大了卷积层的感受野,并且不会引入更多的复杂度。

$$X_1, X_2 = S(X) \quad (5)$$

式中: $X$  表示输入特征图, $X_1$  和  $X_2$  为拆分后的两个特征图。

$$T_1 = \text{Avgpool}_r(X_1) \quad (6)$$

式中: $r$  为池化处理的下采样率和步长, $T_1$  为经过下采样得到的低维特征图,  $\text{Avgpool}_r$  进行  $r$  倍的下采样操作。

$$X'_1 = \text{Up}[F_2(T_1)] = \text{Up}(T_2 \times K_2) \quad (7)$$

式中: $\text{Up}$  是双线性上采样操作, $K_2$  为卷积特征变换, $F_2$  为以  $K_2$  为核的卷积过程; $X'_1$  为上采样后的特征图。




图 3 自校正卷积流程

Fig. 3 Self-correcting convolution flow chart

$$Y'_1 = F_3(X_1) \cdot \sigma(X_1 + X'_1) \quad (8)$$

式中:  $\sigma$  是 sigmoid 函数,  $F_3$  为以  $K_3$  为核的卷积过程,  $Y'_1$  为经过  $F_3$  卷积与 sigmoid 函数的注意力特征图相融合的输出结果。

$$Y_1 = F_4(Y'_1) = Y'_1 \times K_4 \quad (9)$$

式中:  $Y_1$  自校正部分的输出特征,  $K_4$  为卷积特征变换。

### 1.5 混合损失函数

直接使用交叉熵函数容易造成很多细节信息丢失。因此, 本文采用了混合损失函数来解决输入部分图片中管道边缘细节丢失和正负样本点不均衡的问题。Dice Loss<sup>[20]</sup>是在 Dice 系数的基础上取得的, Dice 系数是一种集合相似度度量函数, 通常用于计算两个样本点的相似度, 取值范围为  $[0, 1]$ , 如式 (10) 所示。BCE Loss<sup>[21]</sup>的具体形式如式 (11) 所示。本文损失函数由 Dice Loss 和 BCE Loss 组成, 可有效提升网络收敛的稳定性。混合损失函数如式 (12) 所示。

$$L_{DL} = 1 - \frac{2|X \cap Y|}{|X| + |Y|} \quad (10)$$

式中:  $X$  为网络预测的管道像素区间,  $Y$  为真实标注的管道像素区间,  $|X \cap Y|$  为两个区间求交集,  $|X|$  和  $|Y|$  分别代表  $X$  和  $Y$  的元素个数,  $L_{DL}$  为 Dice 损失函数。

$$L_{BCE}(p, y) = \begin{cases} -\log_2 p, & y = 1 \\ -\log_2(1 - p), & y = 0 \end{cases} \quad (11)$$

式中:  $p$  表示该像素点的预测概率值,  $y$  表示该像素点的类别,  $L_{BCE}$  为 BCE 损失函数。

$$L = L_{BCE}(p, y) + L_{DL} \quad (12)$$

式中:  $L$  为混合损失函数。

## 2 实验

### 2.1 数据集

本文所使用的数据集均来自于工厂实地拍摄, 且为了保证图像多样性, 通过改变拍摄角度、设置不同的背景布等方法来模拟不同环境中的液压管道, 共收集了 1 450 张图片, 并且按照 8 : 1 : 1 的比例划分训练集、验证集和测试集。

### 2.2 数据预处理及增强

在深度学习中, 为了减小模型的计算量以及提升模型收敛的稳定性, 通常会对图像进行预处理, 包括图像尺寸处理、归一化、灰度化等。本文方法所参与计算的参数量较少, 因此使用彩色图像进行模型训练。此外, 使用图像归一化和减去均值的方法将图像像素调整到  $256 \times 256$ 。

在数据预处理之后, 在每批次图像上采用仿射变换、图像翻转、图像裁剪、颜色扰动方法进行图像增强, 以增加数据的多样性, 提升模型的鲁棒性。

### 2.3 实验条件

实验的所用显卡为 NVIDIA GeForce RTX 2070, 显存 16 G; CPU 为 Intel (R) Core (TM) i5-9400F。训练集 1 160 张图像, 验证集 145 张图像, 测试集 145 张图像。最佳超参数如表 1 所示, 其中 Epoch 表示模型的迭代次数, 以完成所有训练集图像为一个 epoch; BatchSize 表示每次输入网络的图片数量; 优化器表示网络反向传播所用方法;  $L_r$  表示学习率。

表 1 本文算法最佳超参数

Table 1 The best hyperparameter of the proposed algorithm

| 迭代次数/Number | 批大小/Number | 优化器  | 学习率     |
|-------------|------------|------|---------|
| 100         | 16         | Adam | 0.000 1 |

2.4 评价指标

在分割算法中常用交并比(intersection over union, IoU)和像素准确率(pixel accuracy, PA)来评判模型。IoU 是指模型预测的目标像素区间占真实标签中的像素区间的比例,如式(13)所示。PA 是指模型预测正确的像素点个数占图片总像素点个数的比例,如式(14)所示。

$$\text{IoU} = \frac{|X \cap Y|}{|X \cup Y|} \tag{13}$$

式中: $X$  表示预测的目标像素区间, $Y$  表示真实的目标像素区间, $|X \cap Y|$  为  $X$  和  $Y$  重合部分的区间, $|X \cup Y|$  为  $X$  和  $Y$  的区间总和。

$$\text{PA} = \frac{\sum_{i=0}^K p_{ii}}{\sum_{i=0}^K \sum_{j=0}^K p_{ij}} \tag{14}$$

式中: $K$  表示目标前景的类别数量, $p_{ii}$  表示预测正确的像素数量, $p_{ij}$  表示所有像素的数量。

2.5 实验结果与对比分析

本文方法与其他常用网络处理的对照实验结果如表 2 所示。表 2 中  $T$  为处理测试图像的平均耗时。由表 2 可知,本文方法的像素准确率 PA 值达到 95.2%,交并比 IoU 值达到 90.8%均高于其他网络,相较于原始 U-net 网络,改进的 U-net 网络在像素准确率和交并比上分别提高了 3.8%、5.3%,在单张推理时间上减少了 8.7 ms,模型体积减少了 56.9 MB,验证了本文方法的优异性。

表 2 各模型对比实验

Table 2 Various model comparison experiments

| 网络模型       | 准确率/% | 交并比/% | 时间/ms | 模型大小/MB |
|------------|-------|-------|-------|---------|
| PSPNet     | 78.7  | 72.5  | 14    | 95.3    |
| DeepLabv3  | 87.5  | 82.5  | 43    | 155.2   |
| U-net      | 91.6  | 85.3  | 28.7  | 73.6    |
| Our method | 95.2  | 90.8  | 20    | 16.9    |

为验证各模块对 U-net 网络的性能提升,使用相同的数据分别进行模型训练,通过测试得到表 3 所示的各模块分割指标。

由表 3 可知,将 Mobilenetv3-large 模型代替原有的编码器卷积模块之后,单张推理时间减少了 13.9 ms,这证明了轻量化网络模型的有效性,在 U-net 结构中添加 SE

注意力机制和 SC 自校正卷积之后,PA 和 IoU 值分别提升了 2.1%、5%,这验证了在特征图中突出目标特征信息和增大感受野对于管道区域提取是有效的,将 U-net 原始损失函数替换为混合损失函数之后,PA 和 IoU 值也有相应的提升。对比结果表明了本文方法的有效性。

表 3 各模块消融实验

Table 3 Ablation experiments by module

| 模块方法                                  | 准确率/% | 交并比/% | 时间/ms |
|---------------------------------------|-------|-------|-------|
| U-net                                 | 91.6  | 85.3  | 28.7  |
| U-net+ Mobilenetv3                    | 91.5  | 84.5  | 14.8  |
| U-net+Mobilenetv3+SE                  | 92.7  | 87.6  | 17.8  |
| U-net+Mobilenetv3+SE+SC               | 93.6  | 89.5  | 19.3  |
| U-net+Mobilenetv3+SE+SC+Loss function | 95.2  | 90.8  | 20    |

为了更清晰地说明本方法在管路分割上的优势,选取了 5 个样本用不同算法进行分割,结果如图 4 所示。针对图片 1,其他算法均存在管道信息丢失的现象,本文方法则是完全检测出了管道结构,与标签图基本一致。针对图片 2,通过本文方法得到的推理图与标签更接近,其他方法检测出了管路大致结构但管道的轮廓曲线不平滑。针对图片 3,本文方法分割出了图片右边管道,而其他方法则丢失了这部分管道信息。对于多管路场景,见图片 4 和图片 5,本文方法可将各管路部分区分明显且边缘轮廓平滑。综合来看,本文方法相较于其他模型有更好的分割精度。

3 结 论

针对液压管路图像中管路背景多变、管道弯折、管路重叠排布等因素导致图像分割精度低的问题,提出一种基于改进 U-net 网络的液压管路图像分割方法,通过使用 Mobilenetv3-large 网络、采用 LR-ASPP 结构、融入 SE 注意力模块和 SC 自校正卷积、引入 Dice 函数和 BCE 函数,减少了网络体积、提升了特征提取能力和网络收敛能力。实验结果表明,所提出的方法对液压管路分割的 IoU 可达 90.8%、PA 可达 95.2%,推理时间为 20 ms/张,模型体积大小为 16.9 m,可应用于实时场景。但本文算法同样也存在一些不足之处,如分割边缘不够精细、丢失部分管道信息等。因此,本文仍需对数据的平衡性以及模型参数等进行进一步优化。

参考文献

[1] 张希鹏. 机械液压传动系统泄露分析及有效控制[J]. 化工管理, 2018(15): 186-187.

ZHANG X P. Leakage analysis and effective control of mechanical hydraulic transmission system [J]. Chemical




图 4 对比实验效果  
Fig. 4 Comparative experimental results

Industry Management, 2018(15): 186-187.

[ 2 ] 杨正强, 杜随更. 现代机械设备液压系统状态评估及故障诊断综述 [ J ]. 西安航空学院学报, 2015, 33(5): 47-53.

YANG ZH Q, DU S G. State evaluation and fault diagnosis of hydraulic system of modern mechanical equipment [ J ]. Journal of Xi' an Aeronautical University, 2015, 33(5): 47-53.

[ 3 ] FAHIMIPIREHGALIN M, TRUNZER E, ODENWELLER M, et al. Automatic visual leakage detection and localization from pipelines in chemical process plants using machine vision techniques [ J ]. Engineering, 2021, 7(6): 758-776.

[ 4 ] 张涛, 刘文华, 赵谊平. 基于孪生网络和长短时记忆网络的输油管道泄漏检测方法 [ J ]. 计算机应用, 2019, 39(S1): 241-244.

ZHANG T, LIU W H, ZHAO Y P. Oil pipeline leak detection method based on twin network and long term memory network [ J ]. Journal of Computer Applications, 2019, 39(S1): 241-244.

[ 5 ] LYU C, LIU Y, WANG X, et al. Visual early leakage detection for industrial surveillance environments [ J ]. IEEE Transactions on Industrial Informatics, 2021, 18(6): 3670-3680.

[ 6 ] 孙小凯. 基于机器视觉的液压元件渗漏检测系统研究 [ D ]. 南京: 南京航空航天大学, 2018.

SUN X K. Research on hydraulic component leakage detection system based on machine vision [ D ]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2018.

[ 7 ] 李大华, 王宇, 高强, 等. 基于细胞免疫的红外图像分割算法及 FPGA 实现 [ J ]. 红外, 2020, 41(4): 27-35.

LI D H, WANG Y, GAO Q, et al. Infrared image segmentation algorithm and FPGA implementation based on cell immunity [ J ]. Infrared, 2020, 41(4): 27-35.

[ 8 ] 彭道刚, 尹磊, 威尔江, 等. 基于 OTSU 和区域生长的电厂管道缺陷检测与分割 [ J ]. 红外技术, 2021, 43(5): 502-509.

PENG D G, YIN L, QI ER J, et al. Detection and segmentation of power plant pipeline defects based on OTSU and region growing [ J ]. Infrared Technology, 2021, 43(5): 502-509.

[ 9 ] SHAO L, ZHANG Y M, LI J, et al. High temperature region segmentation based on improved two-dimensional Otsu pipeline infrared image [ J ]. Spectroscopy and Spectral Analysis, 2019, 39(5): 1637-1642.


[ 10 ] 王乐, 纪竟, 邓彦松. 基于图像分割的水下管道检测机器人设计 [ J ]. 机器人技术与应用, 2017(4): 37-40.

WANG L, JI J, DENG Y S. Design of underwater pipeline inspection robot based on image segmentation [ J ]. Robot

- Technology and Application, 2017(4): 37-40.
- [11] 黄子明, 贺继林. 面向水下管网的视觉检测系统研究[J]. 电子测量与仪器学报, 2021, 35(6): 79-87.  
HUANG Z M, HE J L. Research on visual inspection System for underwater pipe network [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(6): 79-87.
- [12] 张艳博, 任瑞峰, 梁鹏, 等. 基于热成像的埋地热力管道缺陷检测试验研究[J]. 仪器仪表学报, 2020, 41(6): 161-170.  
ZHANG Y B, REN R F, LIANG P, et al. Experimental study on defect detection of buried thermal pipelines based on thermal imaging [J]. Chinese Journal of Scientific Instrument, 2020, 41(6): 161-170.
- [13] 李伟, 刘桂雄, 曾成刚. 基于实例分割+CCTV 排水管道缺陷检测方法研究[J]. 电子测量技术, 2022, 45(3): 153-157.  
LI W, LIU G X, ZENG CH G. Research on drainage pipe defect detection method based on case segmentation and CCTV [J]. Electronic Measurement Technique, 2022, 45(3): 153-157.
- [14] 罗东浩. 基于深度学习的海底管道泄漏检测方法[D]. 哈尔滨: 哈尔滨工程大学, 2019.  
LUO D H. Subsea pipeline leakage detection method based on deep learning [D]. Harbin: Harbin Engineering University, 2019.
- [15] ZHOU Z J, ZHANG B F, YU X. Infrared spectral image segmentation algorithm based on neural immune growth immune domain network [J]. Spectroscopy and Spectral Analysis, 2021, 41(5): 1652-1660.
- [16] BHARTI V, LANE D, WANG S. Learning to detect subsea pipelines with deep segmentation network and self-supervision [C]. Global Oceans 2020: Singapore-US Gulf Coast, 2020: 1-7.
- [17] HOWARD A, SANDLER M, CHU G, et al. Searching for mobilenet3 [C]. Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 1314-1324.
- [18] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.
- [19] LIU J J, HOU Q, CHENG M M, et al. Improving convolutional networks with self-calibrated convolutions [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 10096-10105.

- [20] MILLETARI F, NAVAB N, AHMADI S A. V-net: Fully convolutional neural networks for volumetric medical image segmentation [C]. 2016 fourth International Conference on 3D Vision (3DV), 2016: 565-571.
- [21] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [C]. Proceedings of the IEEE International Conference on Computer Vision, 2017: 2980-2988.


## 作者简介



张平, 2002 年于长安大学获得学士学位, 2005 年于长安大学获得硕士学位, 2013 年于西安交通大学获得博士学位, 现为西安建筑科技大学副教授, 主要研究方向为流体传动与控制、光纤检测技术、机器视觉技术及应用等。

E-mail: pzhang@xauat.edu.cn

**Zhang Ping** received his B. Sc. degree in 2002 from Chang'an University, received his M. Sc. degree in 2005 from Chang'an University, received his Ph. D. degree in 2013 from Xi'an Jiaotong University. Now he is an associate professor and M. Sc. supervisor in Xi'an University of Architecture and Technology. His main research interests include fluid transmission and control, optical fiber detection technology, machine vision technology and application.



佟昆宏 (通信作者), 2019 年于西安建筑科技大学获得学士学位, 现为西安建筑科技大学硕士研究生, 主要研究方向为计算机视觉。

E-mail: 971009695@qq.com

**Tong Kunhong** (Corresponding author) received his B. Sc. degree in 2019 from Xi'an University of Architecture and Technology. Now he is a M. Sc. candidate of Xi'an University of Architecture and Technology. His main research interests include intelligent information processing and application.



王学珍, 2001 年于安徽工业大学获得学士学位, 2016 年于同济大学获得工程硕士学位, 现为上海宝冶集团有限公司正高级工程师, 主要研究方向为流体传动及控制、工业工程。

E-mail: 575913597@qq.com

**Wang Xuezheng** received her B. Sc. degree in 2001 from Anhui University of Technology, received her M. Sc. degree in 2016 from Tongji University. Now she is a senior engineer of Shanghai Baoye Group Co., Ltd. Her main research interests include fluid transmission and control, industrial engineering.