

DOI:10. 19650/j. cnki. cjsi. J2412944

基于图像的道路裂缝分割及量化方法研究

于天河,徐博超,侯善冲,赵思诚,刘珂鑫

(哈尔滨理工大学测控技术与通信工程学院 哈尔滨 150006)

摘要:针对当前道路裂缝检测与量化领域中高成本与高精度之间的矛盾,本文提出了一种低成本高精度的道路裂缝自动分割量化系统。首先,该系统采用添加跳跃级往返多尺度融合模块与注意力门机制的卷积神经网络进行分割预测,并命名为 SW-Net。随后,通过结合 MCO、DFS 以及不同方向上像素统计曲线的变化趋势对裂缝进行分类。最后,为了克服裂缝量化的不连续性和传统形态学骨架量化算法的局限性,本文通过结合 A* 算法并对其进行扩展,以计算裂缝的最短长度和最大宽度。实验对比结果表明,该系统在 Crack500 数据集上取得了所有对比模型中最佳的准确率(93.68%)和 F1 分数(0.8965)。改进后分类算法的平均分类精度达到 99.29%,分类速度为 109 张/s。其量化最短长度和最大宽度的相对误差分别为 12.34% 和 15.85%,较传统骨架方法的平均量化误差降低了 5.16%。这些结果表明,该系统在裂缝的分割、分类和量化方面取得了显著进展。

关键词: 裂缝分割;裂缝分类;裂缝量化;A* 算法

中图分类号: TP391.41 TH711 文献标识码: A 国家标准学科分类代码: 510.40

Research on image-based segmentation and quantification of road cracks

Yu Tianhe, Xu Bochao, Hou Shanchong, Zhao Sicheng, Liu Kexin

(College of Measurement and Control Technology and Communication Engineering, Harbin University of Science and Technology, Harbin 150006, China)

Abstract: Aiming at the contradiction between high cost and high precision in the field of road crack detection and quantification, this paper proposes a low cost, high precision automatic segmentation and quantification system for road cracks. Firstly, the convolutional neural network with jump-stage round-trip multi-scale fusion module and attention gate mechanism is used for segmentation prediction, which is named SW-Net. Then, the cracks are classified by combining MCO, DFS and the trend of pixel statistical curves in different directions. Finally, in order to overcome the discontinuity of crack quantization and the limitation of traditional morphological skeleton quantization algorithm, this paper combined the A* algorithm and extended it to calculate the shortest length and maximum width of cracks. Experimental comparison results show that the system achieves the best accuracy (93.68%) and F1 score (0.8965) among all comparison models on the Crack500 dataset. The average classification accuracy of the improved classification algorithm is 99.29%, and the classification speed is 109 pieces/s. The relative errors of the shortest length and maximum width are 12.34% and 15.85% respectively, which is 5.16% lower than the average error of the traditional skeleton method. These results show that the system has made remarkable progress in the segmentation, classification and quantification of cracks.

Keywords: crack segmentation; crack classification; crack quantification; A* algorithm

0 引言

截至 2023 年末,我国的公路总里程已达到惊人的 543.68 万千米,其中高速公路的建设规模更是达到了

18.36 万千米^[1]。然而,庞大的公路网络随着运营年限的增加,不可避免地会出现裂缝等损坏情况。若不及时修复,这些裂缝必将会扩大并加深,这不仅影响公路的美观,还会减少公路的承重能力和使用寿命,甚至引发路面更为严重的病害。因此需要定期检查并快速评估路面损

坏情况,以科学合理地指导路面维护计划^[2]。

传统的路面裂缝的检测主要依赖于人工目视检查,这种方法要求专业人员对裂缝的类别、长度和宽度等关键指标进行精确评估。然而,这种方法不仅耗时耗力,而且其结果往往受到个人主观判断的影响^[3]。现如今裂缝有多种检测技术,主要包括:基于线扫描激光的立体成像系统,如文献[4]中所采用的数字化公路数据采集车,其原理是在数据采集车上集成线扫激光、3D工业相机等设备,利用这些设备以毫米级的精度快速检测裂缝和坑洞。但该方法由于其昂贵的部署成本导致目前并未普及。如在文献[5]中设计的基于平行激光的便携式非接触裂缝宽度视觉测量系统。该系统利用智能手机作为图像采集、处理和人机交互平台,用平行激光器作为测量基准对裂缝宽度进行测量。然而该方法仅能量化裂缝的宽度,无法量化裂缝的长度。

在钢铁工业裂缝检测领域中,电磁无损检测是一种通过电磁场与工件相互作用的非破坏性检测技术。如文献[6]中提出的基于双层排线探头的轧辊表面微裂纹检测技术,该技术具有响应速度快、灵敏度高、易实现自动化等诸多优势。此外,另一种检测方法是结合激光超声信号与变分模态分解技术,通过提取金属表面回波特征值,对金属裂纹的长度进行定量检测,进而计算出实际的裂缝长度^[7]。然而,这些技术仅适用于钢铁工件,并不适用于对电磁场无反应的道路裂缝检测。因此基于计算机视觉的道路裂缝检测与量化方法由于其低成本和高精度而备受关注。

对于道路裂缝检测任务,深度学习相较于传统图像算法展现出了更高的性能。早在2017年Cha等^[8]就提出了一种基于窗口与深度学习的道路混凝土裂缝检测架构,这代表着深度学习在裂缝检测领域的首次应用。除裂缝检测外,许多研究人员还致力于改进CNN(convolutional neural networks, CNN)架构以实现裂缝分割,例如U-Net^[9]、DeepLabv3+^[10]、DMA-Net^[11]、YOLOv8-seg^[12]。然而,这些方法仅能实现道路裂缝的基本检测与分割,其检测精度和分割效果尚需进一步提升。此外,这些方法无法提供裂缝的具体几何特征信息,如裂缝的最大宽度和最短长度。因此,实现低成本的道路裂缝自动化系统正逐渐成为道路养护的必然趋势。

裂缝自动分类在道路养护中也起着至关重要的作用。现阶段,裂缝分类技术主要有两种:图像处理与深度学习。利用图像处理进行裂缝分类,如文献[13]中的单背景连通区域分类算法,是通过线性裂缝和网状裂缝图像中背景连通区域数量的差异进行区分。然而,这种方法仅能判断裂缝是否为网裂或非网裂,对于非网裂的裂缝无法进行方向的细分,且该分类方法精度较低。相比之下,利用深度学习进行裂缝分类具有高精度且能细分

的优势。在文献[14]中,Chen等采用MobileNetV3-Large作为主干网,通过结合文献[15]中的CBAM(convolutional block attention module, CBAM)模块,构建了MobileNetV3-Large-CBAM模型,并利用开源的桥梁裂缝数据集对裂缝的分类与识别进行了研究。文中Chen等^[14]对比了多种主流CNN裂缝分类网络,并在仅有CPU的环境下进行实验。在所有对比模型中,其提出的MobileNetV3-Large-CBAM模型在综合精度和速度上表现最好。尽管该模型相较于图像处理方法在分类精度上有所提升,且能够进一步细分裂缝方向,但在计算资源有限的嵌入式系统中,由于其庞大的参数量,其分类推理速度并不如图像处理算法快。因此,本研究在图像处理算法的基础上进行进一步改进,旨在实现高准确度和细分裂缝的同时,提高裂缝分类的推理速度。

随着图像量化的技术日渐成熟,将深度学习与图像量化技术紧密融合,以实现道路裂缝自动量化,正逐渐成为道路裂缝检测领域的主流趋势。传统的裂缝图像量化主要利用裂缝中轴骨架细化法进行量化,如Li等^[16]利用ResNet152与矩阵网络相结合作为裂缝分割的骨干网络,通过角点检测技术精确定位裂缝区域,随后从生成的二值化图像中提取出裂缝的骨架,并利用裂缝的几何特征进行长度和宽度等参数的精确计算。类似地,在最近的其他研究^[17-20]中也采用了与Li等^[16]相似的形态学骨架算法进行裂缝量化。然而,这种骨架细化算法在处理细小裂缝时容易出现断点,并且在量化裂缝长度时对裂缝边界的敏感性非常高,尤其是在裂缝尖端只有几个像素宽的情况下。这导致在裂缝尖端提取出的裂缝骨架呈锯齿状,使得计算出的细裂缝长度通常比实际裂缝长度更长,从而增大了裂缝长度的量化误差。

为了解决上述道路裂缝检测、分类与量化的成本与精度问题,本研究设计了一种道路裂缝自动分割量化系统。首先,为了提高网络的分割效果,防止网络出现尺度相关性的问题,并能更有效地提取各种复杂裂缝的特征,本文通过结合跳跃级往返多尺度融合模块^[21]和注意力门机制^[22]改进了传统U-Net网络结构,提出了一种新颖的跳跃多尺度注意力网络,即SW-Net。接下来对生成的二值图像进行形态学闭操作(morphological closed operation, MCO),以连接不相交的裂缝区域,从而获得连续的裂缝,便于后续裂缝长度的准确量化。然后,通过确定裂缝连通区域数和分析不同方向上像素统计曲线的变化趋势来判断裂缝类型。最后,为了准确量化裂缝长度与宽度,防止出现裂缝尖端长度量化过长的问题,采用 A^* ^[23]量化算法来量化裂缝的最短长度,并扩展 A^* 量化算法以量化裂缝的最大宽度,进而根据不同类别的裂缝二值图像对实际裂缝的长度、宽度进行估算。

1 理论分析

1.1 裂缝自动分割量化系统

本研究设计了一种道路裂缝自动分割量化系统,其整体系统框图如图 1 所示。该系统包括 3 个主要研究部分:裂缝分割、分类和量化。其具体流程如下:

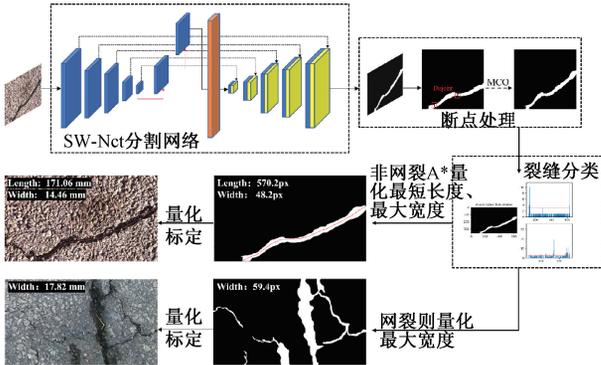


图 1 裂缝自动分割量化系统

Fig. 1 Block diagram of automatic crack segmentation quantization system

首先,传入图片到 SW-Net 分割网络进行分割预测,生成只有裂缝的二值图像。然后,通过 MCO 操作连接分割中断裂的裂缝,再通过深度优先搜索 (depth-first search algorithm, DFS) 算法^[24] 确定裂缝的连通区域数,同时确定该二值图像的直方图分布趋势,通过设置其判断条件就可以有效地区分线性裂缝与网状裂缝的多种情况。最后,鉴于不同类型的裂缝需要提取不同的参数,如果判断为线性裂缝则通过 A* 算法和本文的扩展 A* 算法量化其最短长度和最大宽度;如果为网裂,则利用扩展 A* 算法量化其最大宽度,根据相应的换算公式计算出预测的裂缝长度,并标定在原图中。

1.2 SW-Net 网络结构

为了更准确、高效地区分裂缝像素和背景像素,以便于后续更好地实现损伤严重程度的量化评估,本研究在 U-Net 基础上提出了一种 W 型的新网络结构,命名为 SW-Net (skip attention-W-Net),其网络结构如图 2 所示。SW-Net 包含 1 个编码器结构和 1 个解码器结构,不同于如图 3 所示的 U-Net 网络结构,SW-Net 的解码器采用转置卷积来代替基于插值的上采样方法,这使得网络能够自动学习上采样过程,从而更好地捕捉局部细小裂缝的特征和上下文信息。

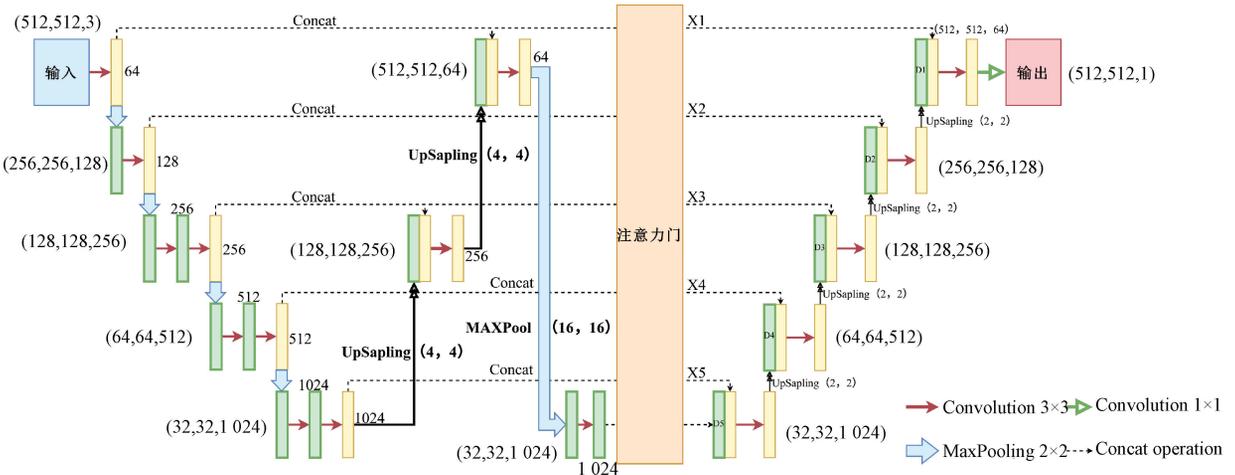


图 2 SW-Net 网络架构

Fig. 2 SW-Net network architecture

此外,传统的卷积网络 (如 U-Net) 通常在下采样和上采样时采用固定的感受野大小 (如 2×2 或 3×3),这种固定采样尺度的使用会导致网络在处理不同尺度的图像特征时出现尺度相关性的问题,特别在路面裂缝分割的任务中更为突出。结果可能导致完整的裂缝被识别成多段,或者在路面存在坑洞等情况下,网络更容易将孤立点错误地识别为裂缝。这些问题在一定程度上源于采样尺度的限制,导致网络主要关注小尺度的局部特征,但却失去了全局的感受野。

为了解决上述问题,SW-Net 引入了跳跃级往返多尺度融合 (skip-level feature fusion) 机制,以增强网络对不同感受野和尺度信息的感知能力。具体来说,本文将最后一次的下采样得到的特征图通过 4×4 的感受野进行上采样,随后通过跳跃连接将原始下采样中的特征图与上采样得到的特征图拼接起来。再通过两次上采样将特征图恢复到原始图像大小之后,将感受野扩大到 16×16 进行下采样,以获取最小尺寸的特征图集。这种多尺度池化跳跃拼接融合策略有助于扩大网络的感受野,提高其区

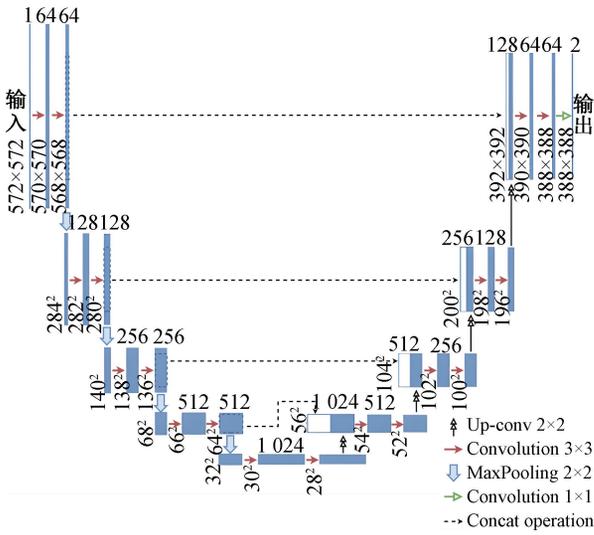


图3 U-Net 网络架构

Fig. 3 U-Net network architecture

分背景、干扰信息和分割裂缝的能力。最后,每个下采样层的输出都经过了注意力门的处理(详见 1.3 节),随后与相应的转置卷积层的输出进行拼接,并进行 4 倍(2×2)尺寸的上采样。每次上采样后,再与相同尺度的下采样特征图进行拼接,以突出裂缝特征并减少无关的背景噪声干扰。这一策略有效地融合了浅层和深层特征,实现了对裂缝信息的全面提取。

1.3 主要网络结构层

1) 卷积运算和跳跃式特征融合

如图 4 所示,每层的卷积运算都包括卷积层、BN (batch normalization, BN) 层和激活函数 (rectified linear unit, ReLU) 层,其中非线性激活函数是深度神经网络架构的主要部分之一,激活函数的选择会影响模型的速度、性能和收敛性。

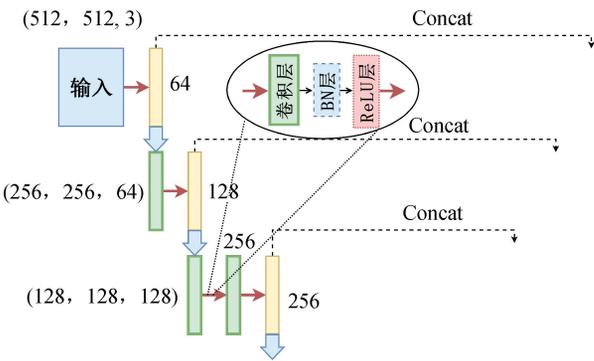


图4 卷积层运算

Fig. 4 Convolutional layer operation

本研究通过引用参考文献[25]中带有可调节参数的激活函数 NormLinComb 进行训练。NormLinComb 是

(ReLU、Sigmoid、Tanh、SoftSign) 函数集中线性组合的模拟,其定义如式(1)所示。

$$NormLinComb(x) = \frac{\sum_{i=0}^n w_i F_i(x)}{\|W\|} \quad (1)$$

其中, w_i 是可调节参数; F_i 是激活函数集中的不同激活函数; n 是线性组合中的项数。相较于传统的 ReLU 激活函数, NormLinComb 解决了 ReLU 从零均值单位偏移的问题。同时,它在不显著减慢模型训练速度的情况下,提供了更好的收敛结果。通过该文章的对比实验可知,采用 $w_0=0.75$ (ReLU)、 $w_1=0.15$ (Sigmoid)、 $w_2=0.07$ (Tanh)、 $w_3=0.03$ (SoftSign) 时收敛效果更好且模型的检测速度更快, NormLinComb 函数曲线如图 5 所示。

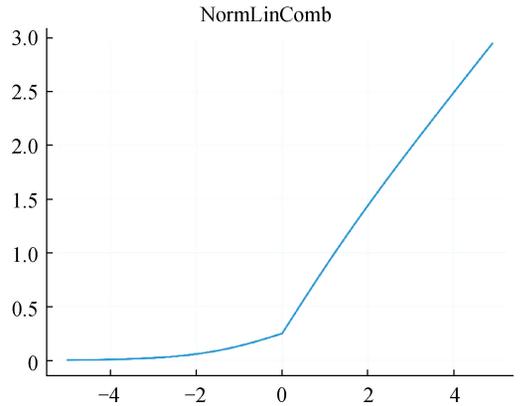


图5 NormLinComb 激活函数曲线

Fig. 5 NormLinComb activation function curve

为了增强网络对不同感受野和尺度信息的感知能力,以防止网络仅专注于裂缝的局部像素,从而减轻分割时容易出现细小裂缝断连的问题, SW-Net 引入了跳跃式特征融合及多尺度上下采样的机制。添加这一机制的另一主要原因在于强化网络对低级特征的记忆能力,在网络逐步提取特征的过程中,需要对裂缝的特征进行反复拟合和强调。但过度强调裂缝特征会使得网络对道路像素的微小变化非常敏感,从而导致积水、坑洼等非裂缝特征被视为裂缝处理,如图 6 所示。因此采用跳跃式特征融合操作,将低级特征与高维采样特征并行连接。这确保网络在下采样后仍能维持对全局特征的感知,避免过度聚焦于局部特征,同时也有助于帮助网络更好地区分图像中的背景和裂缝区域,从而提高了分割的准确性。

2) 注意力门

裂缝图像的分割是一项复杂且具有挑战性的工作,而传统的 CNN 结构通常难以直接处理各种复杂形状的裂缝区域。为了解决这个问题,本研究引入了 Kang 等^[22]使用的注意力门 (attention gate) 模块,以便帮助网络更好地提取各种复杂裂缝的特征,使其仅关注有裂缝的区域,



图 6 井盖误识别

Fig. 6 Manhole cover misidentification

从而提高分割裂缝的性能,其结构如图 7 所示。

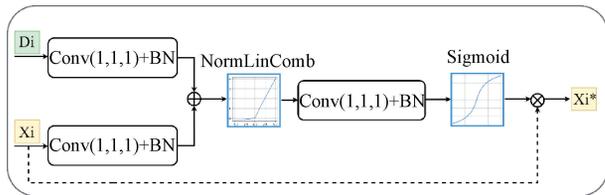


图 7 注意力门模块

Fig. 7 Attention gate module

图 7 中 X_i 表示第 i 层下采样过程的输出结果, D_i 表示第 $i+1$ 层上采样后的输入结果。 X_i 中的关键特征信息是由门控信号 D_i 所确定的, 这些门控信号包括了丰富的上下文信息, 允许模型对跳跃拼接相关的特征施加更多的权重, 并专注于输入 X_i 的特定部分, 而不是输入特征图中的每个特征。 然后, 通过 NormLinComb 激活函数增加模型的非线性, 并使用 $1 \times 1 \times 1$ 卷积层进行线性变换。 最后将 Sigmoid 函数作为注意力门的最后一个操作, 得到一个 0 到 1 的重要性分数, 通过将这个注意力图与输入 X_i 相乘, 即可将其分配给特征图的每个部分, 从而产生注意力块的最后输出 X_i^* 。 该注意力门模块的引入使得 SW-Net 在数据训练过程中能够集中于有用的显著特征, 同时抑制背景区域中的不相关部分, 从而有效提高模型的灵敏度和预测精度。

1.4 裂缝分类

鉴于不同类型的裂缝需要提取不同的参数, 如线性裂缝的量化包括最短长度和最大宽度, 而对于网状裂缝, 仅需要提取其最大的宽度。 因此, 在进行裂缝的量化分析之前, 必须首先对其类型进行区分。

1) 线性裂缝和网状裂缝的区分

传统的单背景连通区域分类算法, 正如文献[13]中所提出的, 是通过对线性裂缝和网状裂缝图像中背景连通区域数量的差异进行区分。 若背景连通区域数量小于或等于 2, 则可判定为线性裂缝; 反之, 若背景连通区域数量大于 2, 则可判定为网状裂缝。 图 8 展示了该方法对不同裂缝的背景连通区域的标记结果, 其中圆点表示已标记的背景连通区域。



(a) 网状裂缝及其背景连通区域标记

(a) Network crack and its background connected region markers



(b) 线性裂缝及其背景连通区域标记

(b) Linear cracks and their background connected region markers

图 8 不同裂缝的背景连通区域标记

Fig. 8 Background connectivity region markers for different cracks

然而, 上述单背景分类方法存在一个严重的缺陷, 即当图中的线性裂缝将背景分割成 3 个或更多背景连通区域时, 将会导致严重的误判, 如图 9 所示的情况。 在图 9 中, 背景连通区域的数量为 4, 但该分类方法会将其误识别为网状裂缝。 因此, 需要对该分类方法进行进一步的优化和改进, 以提高分类法对复杂场景的准确性。 为了解决这一问题并更准确地区分这两种类型的裂缝, 首先对二值图像执行 MCO^[26] 操作, 以连接裂缝断点。 随后, 采用深度优先搜索 (DFS) 算法对二值图像中裂缝的连通区域进行标记。 最后, 利用二值图像得到 mask 的骨架线并获取骨架的最小外接矩形, 这个矩形可以是任意旋转的, 而不仅仅是水平或垂直的。 对其进行 X, Y 两个方向的投影, 得到两个投影的直方图, 通过结合直方图投影与裂缝的连通区标记的情况即可判断其类型。

具体来说, 对于 1 个 $M \times N$ 大小的图像 $I(x, y)$, 其统计像素如式 (2) 和 (3) 所示。

$$X(i) = \sum_{x=1}^M I(x, y) \quad (2)$$

$$Y(j) = \sum_{y=1}^N I(x, y) \quad (3)$$

其中, $X(i)$ 是水平统计像素的总数, $Y(j)$ 是垂直统计像素的总数。 根据这些统计结果, 可以绘制出水平和垂直方向上的直方图, 如图 10 所示, 其中图 10(a) 为水

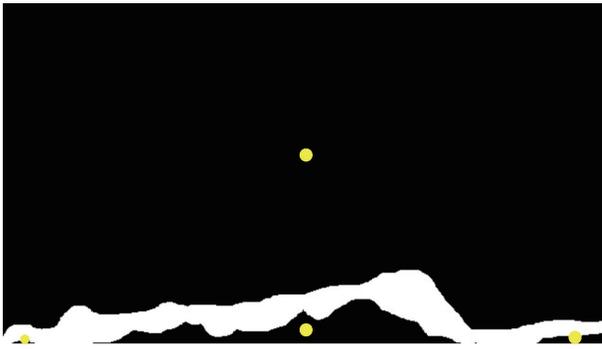


图9 单背景连通区域分类算法误识别

Fig. 9 Single background connected region classification algorithm misrecognizes

平方向的直方图,图 10(b)为垂直方向的直方图。通过设置裂缝连通区域数目和直方图分布趋势的判断条件,就可以有效地区分线性裂缝与网状裂缝的多种情况。具体包括:只有当裂缝连通区域数目小于 3 且水平直方图或垂直直方图均匀分布时,即可判断其为线性裂缝,反之则为网状裂缝。通过本文 3.2 节进行的对比实验结果表明,这种判断方法相较于单背景分类方法有很大的提升,具有极高的准确性。

2) 不同线性裂缝的区分

当通过上述方法判断为线性裂缝后,可通过如下方

裂缝类型:水平裂缝

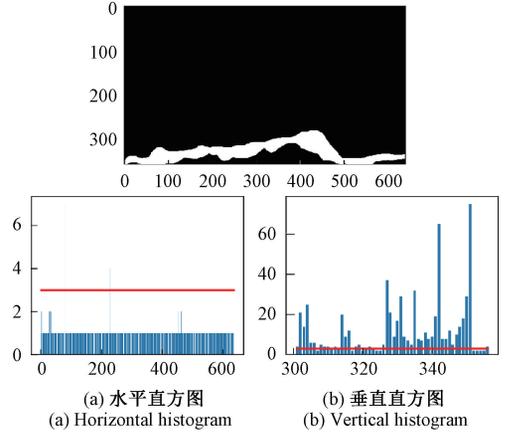
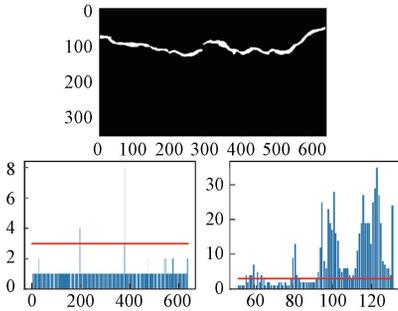


图10 水平裂缝的直方图

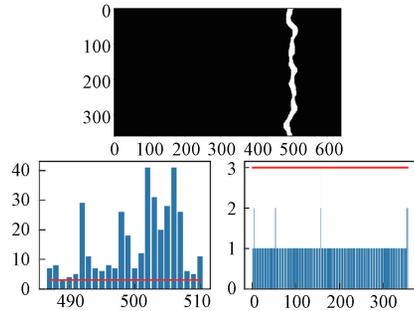
Fig. 10 Histogram of horizontal cracks

法对不同类型的线性裂缝进行细分。对于图 10 中的水平裂缝,其水平方向的直方图通常呈现出均匀的变化,不会超过预设的阈值。然而,其垂直方向的直方图开始趋于零,随后在中间迅速上升,最终呈线性上升并在某一点突然下降。因此,根据不同方向线性裂缝目标像素曲线变化的不同趋势,通过设定好相应的阈值规则,即可有效地区分出不同类型的线性裂缝。具体区分效果如图 11 所示,其中图 11(a)为水平裂缝的分类效果、图 11(b)为

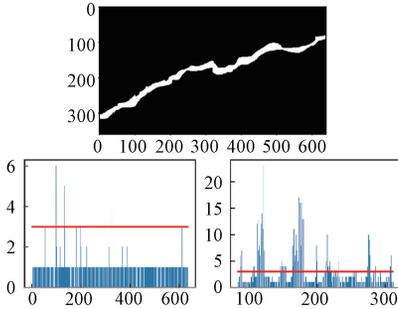
裂缝类型:水平裂缝



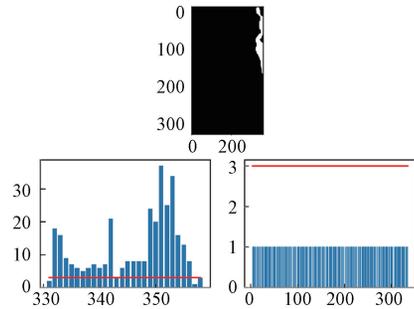
裂缝类型:垂直裂缝



裂缝类型:水平裂缝



裂缝类型:垂直裂缝



(a) 水平裂缝
(a) Horizontal cracks

(b) 垂直裂缝
(b) Horizontal cracks

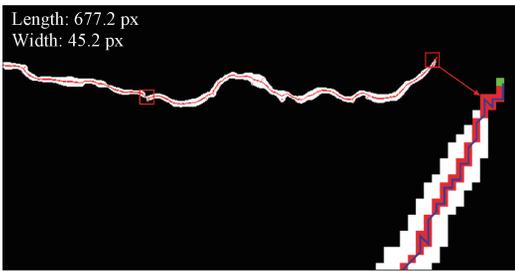
图11 不同线性裂缝的区分

Fig. 11 The distinction of different linear cracks

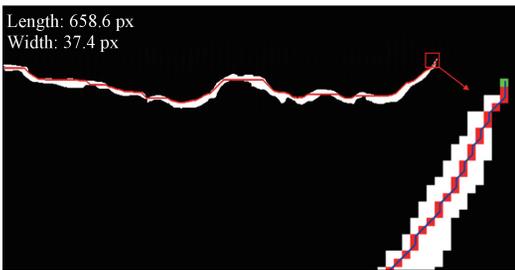
垂直裂缝的分类效果。可以看到本文的分类算法在图中的水平与垂直裂缝 4 种情况中均判断正确。

1.5 A* 算法寻找裂缝最短长度

大多数裂缝量化方法均采用形态学骨架化算法^[27]或细化算法^[28]来提取分割后的二值图像中的裂缝骨架,并利用该骨架的坐标信息来计算裂缝的长度。然而,这些方法对裂缝图像的边界非常敏感,尤其是在裂缝尖端处,如图 12(a)中所示的情况。在裂缝的骨架提取过程中,骨架法计算出的像素可能存在相同的列坐标,但这并不一定代表它们在正确的连接顺序上,根据其提取的骨架来计算裂缝的长度可能会偏长。因此,为了准确地量化裂缝的长度,需要引入额外的步骤来调整原始中轴算法创建的连接顺序。本研究采用了 A* 算法对裂缝进行精确量化,其改进后的正确连接效果如图 12(b)所示。



(a) 中轴骨架算法量化
(a) Axis skeleton algorithm quantization



(b) A*算法量化
(b) A* algorithm quantization

图 12 不同量化算法效果对比

Fig. 12 Comparison of the effect of different quantization algorithms

A* (A-Star)算法是一种用于寻找给定起点和给定目标点之间最短路径的方法,也是一种在静态路网中求解最短路径最有效的直接搜索方法。该算法融合了 Yu 等^[29-30]所使用的 Dijkstra^[29]算法和 Greedy Best First Search^[30]算法的优点,其搜索过程中的距离估算值与实际值越接近,最终搜索速度越快。图 13 中的示例清楚地演示了 A* 算法如何寻找最短路径(图中用“O”框框选的像素块表示)的过程。

A* 算法的整体流程通过 $F(I)$ 函数实现,其定义如式(4)所示。

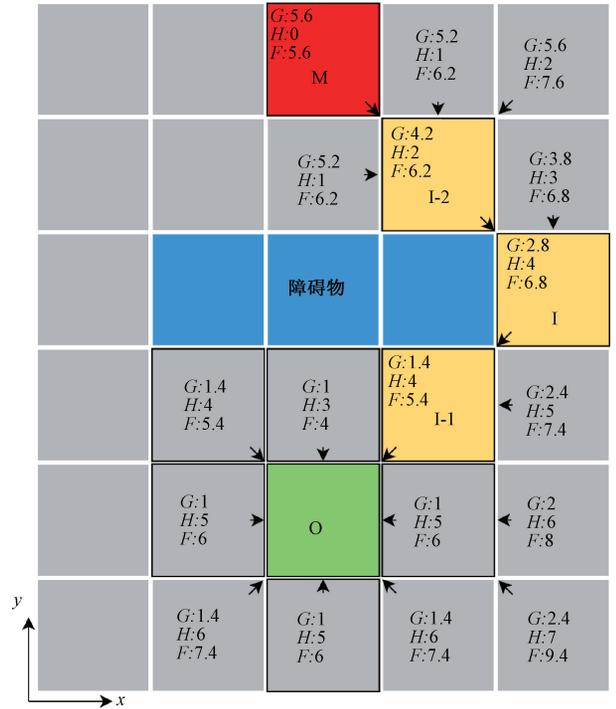


图 13 A* 算法查找最短路径的示意图

Fig. 13 Diagram of A* algorithm finding the shortest path

$$F(I) = G(I) + H(I) \tag{4}$$

其中, $G(I)$ 代表从起点 O 移动到给定点 I-1 的实际移动成本,而 $H(I)$ 则表示从给定点 I-1 移动到目标点 M 的估计移动成本。 $G(I)$ 和 $H(I)$ 的计算如式(5)、(6)所示。

$$G(I) = \sqrt{(x_1 - x_{I-1})^2 + (y_1 - y_{I-1})^2} + G(I - 1) \tag{5}$$

$$H(I) = |x_M - x_1| + |y_M - y_1| \tag{6}$$

其中, $x_M, y_M, x_{I-1}, y_{I-1}, x_1, y_1$ 是指点 M, I 和 I-1 的坐标。本研究采用对角距离的计算方式进行估算,以考虑斜角方向的移动。具体来说, A* 算法优先计算周围具有最小 F 值的点(图中用 M 框框选的像素表示),然后将它们添加到开放列表(open list)中,通过计算当前点(例如 I-1)周围相邻点的 F 值,并选择 F 值最低的点作为下一节点(例如 I)。随后使用这些点的坐标,就可以获得最短路径的长度(最终的 G 值)。有关算法如何搜索下一个最优点的更多细节,可以在 Foead^[31]中查询。

1.6 扩展 A* 算法量化宽度

针对网状裂缝宽度难以量化的问题,本研究通过进一步扩展 A* 算法,实现了对裂缝最大宽度的精确量化。传统的裂缝宽度量化方法,如 Li 等^[16]所述,是通过计算裂缝骨架像素与裂缝长度的比值间接推断出裂缝的宽度信息。然而,这种方法过于依赖通过中轴骨架定理获得

的裂缝骨架,从而导致在骨架提取不精确时产生较大的量化误差。因此,为了减少宽度量化误差,本研究对 A^* 算法进行了创新性的扩展,利用其得到的精确最短路径来计算裂缝的宽度,具体的量化细节如图 14 所示。

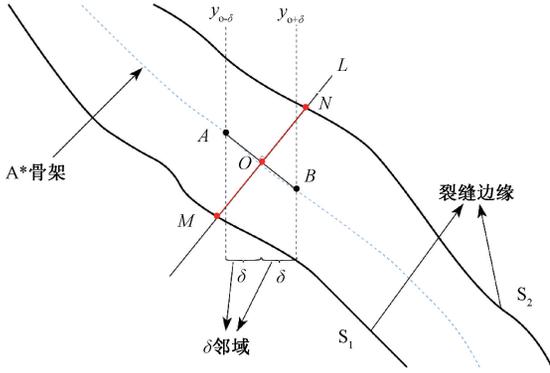


图 14 扩展 A^* 算法量化宽度

Fig. 14 Expand the quantization width of the A^* algorithm

在图 14 中, S_1 和 S_2 表示裂缝的边缘,对于最短路径上的任一像素点 O ,预先定义其附近的邻域值 δ ,则点 O 处裂缝的宽度可以通过以下方式进行计算:

1) 从 O 点处开始,确定该点的邻域,在该邻域内画出垂直于水平轴的直线,即图中 $y_{O-\delta}$ 和 $y_{O+\delta}$ 。这些直线与最短路径相交,形成交点 A 和 B 。

2) 将交点 A 和 B 连接,得到线段 AB ,通过点 O 画一条垂直于 AB 的直线 L ,得到该直线与裂缝两边的交点 M 和 N 。

3) 计算从点 M 到点 N 的距离,这个距离即代表裂缝在点 O 处的量化宽度。

对比中轴骨架细化算法量化宽度得到的骨架路径,利用 A^* 算法可以得到更为精确的最短路径,从而进一步提高裂缝宽度量化的精度。借助预先定义的邻域值和垂直线的交点,即可以找到该最短路径上所有裂缝点的最大宽度。通过本文 3.3 节的对比试验可以看出,该扩展 A^* 量化方法显著提升了裂缝宽度量化的准确性。

2 实验配置

2.1 训练配置

本研究采用 PyTorch 框架构建了 SW-Net 网络模型,并利用 CUDA 12.2 和 CUDNN 进行加速训练。训练过程在一台搭载 Intel i5-13600KF 处理器、64 GB 内存以及 NVIDIA GeForce RTX 3090 GPU (24 GB RAM) 的工作站上进行。

学习率作为决定学习过程是否收敛和收敛速度的关键超参数,对训练过程有着重要的影响,本研究采用余弦退火方法作为学习率衰减方法^[32],如式(7)所示。

$$\eta_t = \eta_{\min} + \frac{1}{2}(\eta_{\max} - \eta_{\min}) \left(1 + \cos\left(\frac{T_{\text{cur}}}{T} \pi\right) \right) \quad (7)$$

其中, η_{\max} 和 η_{\min} 分别代表学习率的最大值和最小值来定义其变化范围, T_{cur} 和 T 分别代表当前的 epoch 数和总 epoch 数。

在 SW-Net 的训练过程中,采用了自动水平翻转技术对训练图像进行数据增强。同时,为了不断调整权重参数,本研究采用了自适应优化器 Adam (adaptive moment estimation, Adam)^[33],该优化器在计算更新步幅方面具有显著的优势,例如计算效率高,不受梯度扩展和转换的影响。最后将学习率的初始值设置为 0.001,指数衰减率设置为 $\beta_1 = 0.9$ 和 $\beta_2 = 0.999$ 。在 SW-Net 的最后一层使用了单个卷积核,并采用了 Sigmoid 作为最后的激活函数,这有助于加快网络的收敛速度。

2.2 数据集配置与评估指标

为全面验证分割网络改进的效果,本研究精心选取了 U-Net、DeepLabv3+、YOLOv8-seg 等主流裂缝分割网络进行对比研究,对比方法中涉及的所有超参数都经过了很好的调整。同时,为确保实验的公正性和准确性,所有对比网络均使用了 Crack500 公开数据集^[34]进行训练和性能测试。该数据集是由 Github 上的一个项目发布 (<https://github.com/fyangneil/pavement-crack-detection>) 的开源裂缝数据集,总共包含 3 368 张图像,其中训练集 1 896 张,测试集 1 124 张,验证集 348 张。

为了全面且客观地评估模型性能,本研究采用了多样化的评估指标,包括精度 (precision, Pr)、召回率 (recall, Re)、F1 分数 (F1)、平均像素准确率 (mean pixel accuracy, mPA) 和平均并集交集 (mean intersection over union, $mIoU$),这些指标的计算公式如表 1 所示。

表 1 评价指标

Table 1 Evaluation index

评估指标	公式定义
Pr	$Pr = \frac{TP}{TP + FP}$
Re	$Re = \frac{TP}{TP + FN}$
$F1$	$F1 = \frac{2 \times Pr \times Re}{Pr + Re}$
mPA	$mPA = \frac{TP + FN}{TP + TN + FP + FN}$
$mIoU$	$mIoU = \frac{ X \cap Y }{ X \cup Y }$

其中, TP 、 TN 、 FP 和 FN 分别代表真阳性、真阴性、假阳性和假阴性的数量, X 代表模型预测的裂缝在图像中

的预测区域像素数目, Y 代表裂缝在真实标签 (ground truth) 中的像素数目。

3 实验结果

3.1 裂缝分割性能对比

在模型训练过程中, 4 种评价指标随 epoch 数的变化曲线如图 15 所示, 最终经过 300 个 epoch 后, 各个模型的指标如表 2 所示。结果表明, 本文提出的 SW-Net 具有优

异的性能, 该网络的准确率分别比其他 4 种网络提高了 9.65%、10.01%、9.47% 和 6.77%; F1 提高了 9.05%、13.68%、8.32% 和 6.66%。此外, SW-Net 在 mIoU 和 mPA 值方面也明显优于其他 4 种网络。与 U-Net 相比, SW-Net 引入的注意力门和跳跃式特征融合机制为其带来了显著的优势。这些改进不仅显著提升了 mPA、F1 分数和 mIoU 等关键性能指标, 而且增强了 SW-Net 在图像分割任务中的鲁棒性, 使其在面对多样且复杂的裂缝场景时, 依然能够实现出色的分割效果。

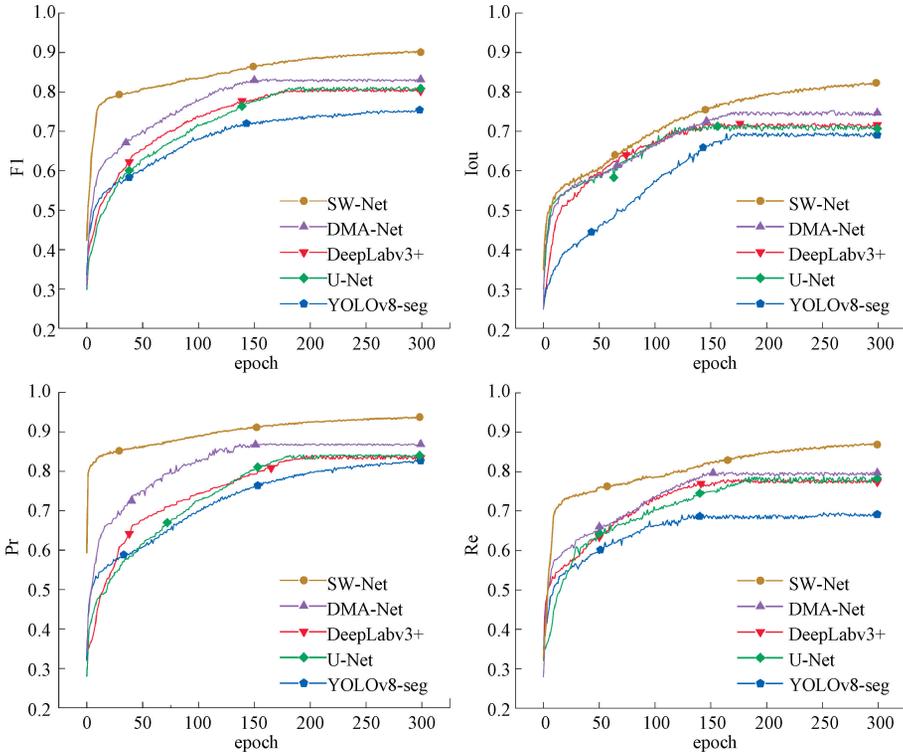


图 15 4 种评价指标训练过程比较

Fig. 15 Comparison of training process of four evaluation indexes

表 2 5 种网络检测指标的比较

Table 2 Comparison of five kinds of network detection indexes

网络模型	Pr	Re	F1	mPA	mIoU
U-Net	0.840 3	0.774 4	0.806 0	0.946 8	0.712 1
YOLOv8-seg	0.836 7	0.695 8	0.759 7	0.864 9	0.696 4
DeepLabv3+	0.842 1	0.786 5	0.813 3	0.922 3	0.702 1
DMA-Net	0.869 1	0.794 3	0.829 9	0.954 7	0.742 2
SW-Net	0.936 8	0.859 7	0.896 5	0.977 1	0.819 1

相比之下, DMA-Net 虽然在 DeepLabv3+ 的基础上添加了注意力门机制, 但从表 2 中的对比结果可以看出, DMA-Net 的提升效果并没有 SW-Net 相对于 U-Net 的改

进明显。因此, 这表明在保持分割网络框架的底层特征提取机制不变的情况下, 仅仅通过增加某些模块往往难以大幅度提升分割的性能。表 2 中的其他指标值还表明, 尽管 YOLOv8 在目标检测与分类领域表现出色, 但在处理小数据集分割任务时, 其性能并不理想, 甚至不及结构相对简单的 U-Net。这说明在利用深度学习进行图像处理时, 必须根据具体的任务需求仔细调整和优化网络架构, 以确保达到最佳的性能表现。

5 种网络对测试集图像的预测结果及相应的真实标签如图 16 所示, 对于图 16(a) 中的单侧粗裂缝的分割, YOLOv8-seg 无法完整的预测出裂缝形状, 而 U-Net 的预测结果则出现断裂的情况, 相比之下, 其他 3 种网络均展现出了较好的预测效果。对于图 16(b) 中细裂缝的分

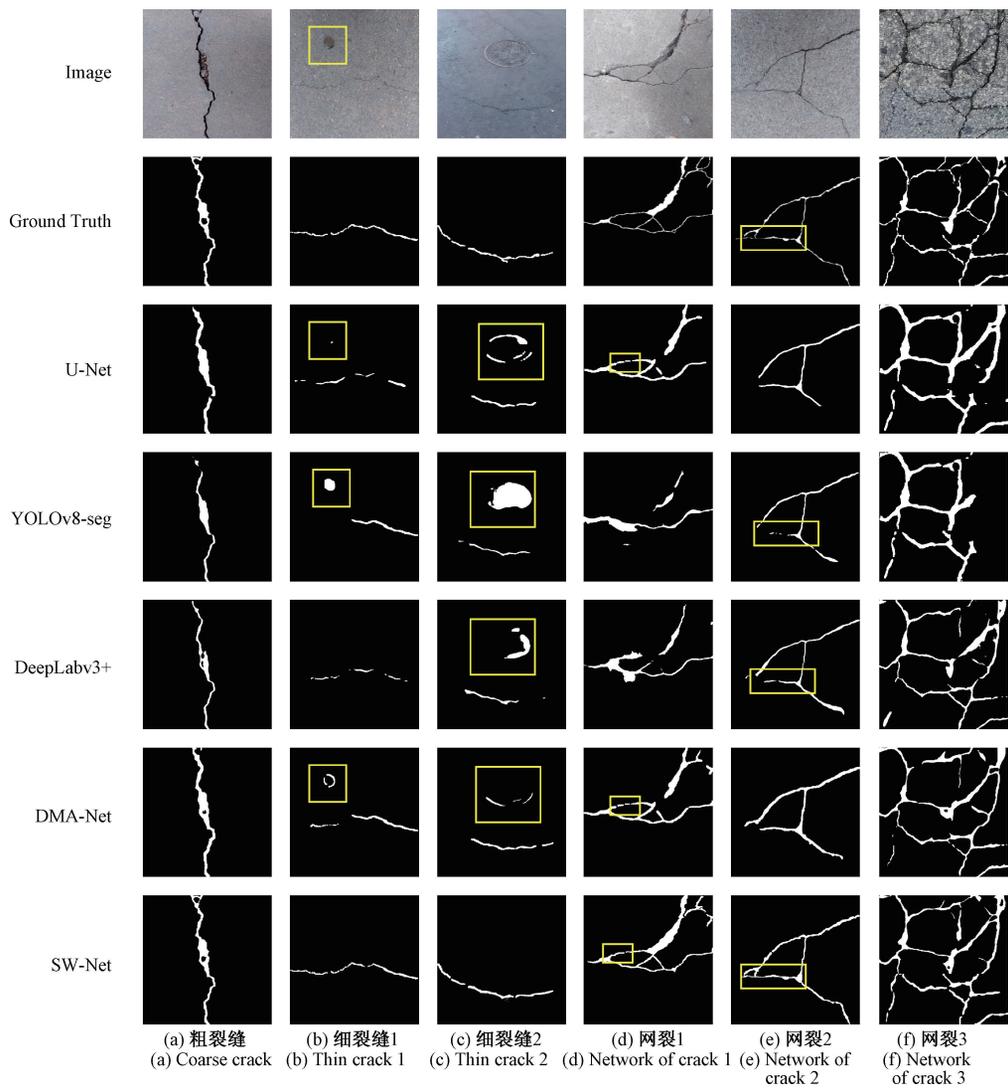


图 16 5 种网络分割预测结果的比较

Fig. 16 Comparison of prediction results of five kinds of network segmentation

割,与其他网络相比,SW-Net 预测的裂缝更加连续且完整,这得益于其引入的注意力门机制,该机制显著提高了网络对细小裂缝特征的灵敏度和预测精度。对于含有井盖的复杂背景图 16(c),其他 4 种网络均将井盖的边缘误识别为裂缝,只有 SW-Net 在准确预测裂缝的同时,避免了将井盖误判为裂缝,这证明添加了跳跃式特征融合机制在提高分割准确性的同时,抑制了背景区域中的不相关部分。对于不同方向的网状裂缝,可以看出在图 16(d)~(f)中所有的网络预测效果均有不同程度的断裂,但相比之下,SW-Net 的断裂最少,展现出了其对复杂裂缝结构更高的捕捉能力和鲁棒性。

为了确保后续裂缝分类与量化的骨架完整,对于分割断裂的裂缝可以通过 MCO 将断裂部分连接,其连接对比效果如图 17 所示。从图 17(a)可以看出,对于距离较近的断裂裂缝来说,MCO 操作可以完美的连接断裂处。

然而,对于图 17(b)中相距较远且不相交的裂缝,MCO 并不能用较小的卷积核有效地连接这些断裂区域,因为形态学闭运算主要依赖于结构元素的尺寸,较小的卷积核在这种情况下难以覆盖大范围的裂缝,从而导致闭运算难以同时连接这些远距离的不相交裂缝。解决这一问题的方式之一是使用更大尺寸的卷积核,以更好地处理这种不同裂缝之间距离较远的情况。

3.2 裂缝分类效果对比

在 1.4 节中,详细阐述了改进的裂缝分类方法,鉴于不同类型的裂缝需要提取不同的参数,本文的分类方法专注于将裂缝分为线性裂缝和网状裂缝两大类。为了验证这一分类方法的准确性、适用性与分类推理速度,本研究选取了多种不同形态和复杂度的线网裂缝图片进行测试,与传统的单背景连通区域分类算法的对比效果如图 18 所示。由于单背景连通区域分类算法是将背景连

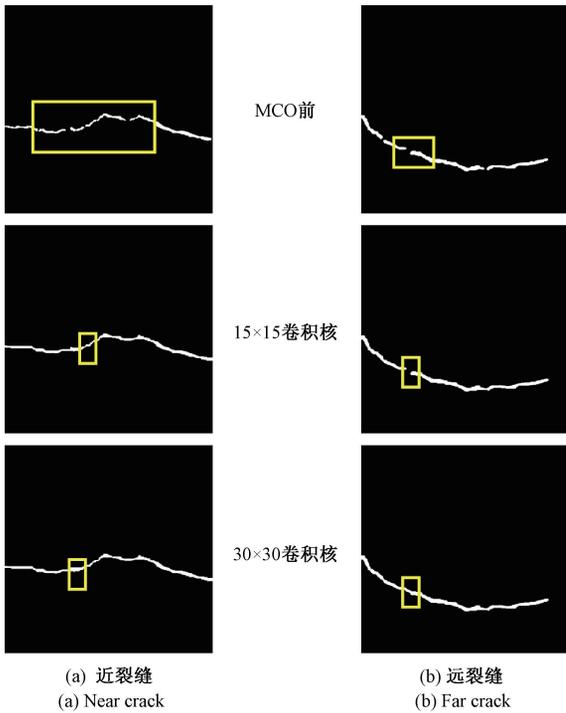


图 17 形态学闭运算效果对比

Fig. 17 Comparison of the effect of morphology closed operation

通区域数大于 2 的情况判断为网裂,小于等于 2 的情况判断为线性裂缝,这导致其将 (2) ~ (4) 这 3 种情况均判断错误,而本文提出的分类方法在这 4 种情境下均能准确地判断裂缝的类别。

鉴于裂缝在实际场景中的多样性和复杂性,本研究进一步扩大了测试范围,对 Crack500 的所有测试集图片 (共 1 124 张) 进行分类测试,并与深度学习领域的 MobileNetV3-Large-CBAM^[14] 裂缝分类算法进行比较,其分类测试结果如表 3 所示。从表 3 可以看出,本文分类方法的平均分类准确率高达 99.29%,相较单背景连通区

	背景连通区域数	裂缝连通区域数	单背景连通区域分类法	本文分类法
(1)	3	1	网裂	网裂
(2)	4	1	网裂	线性
(3)	2	1	线性	网裂
(4)	5	1	网裂	线性

图 18 2 种分类方法对比

Fig. 18 Comparison of two classification methods

域分类算法 (89.04%) 与 MobileNetV3-Large-CBAM (97.09%),分别提高了 10.25%、2.2%,特别是在细分垂直裂缝时,准确率高达 99.63%。在仅使用 CPU 进行的分类推理速度对比实验中,本文的分类算法比 MobileNetV3-Large-CBAM 提升了 64 张/s,尽管本文的分类算法在推理速度上略慢于单背景连通区域分类算法,但综合考虑 3 种裂缝分类方法的精度与速度,这进一步验证了本文分类方法的高准确性与高适用性。

表 3 3 种分类方法在 Crack500 测试集上的分类结果

Table 3 Classification results of three classification methods on the Crack500 test set

算法	单背景连通区域分类算法			MobileNetV3-Large-CBAM			本文改进分类算法		
	水平裂缝	垂直裂缝	网裂	水平裂缝	垂直裂缝	网裂	水平裂缝	垂直裂缝	网裂
分类推理速度/(张/s)	117			45			109		
实际裂缝类别数/张	784	340		511	273	340	511	273	340
各算法分类结果/张	836	288		504	265	355	508	272	344
准确率/%	93.36	84.71		98.63	97.07	95.59	99.41	99.63	98.82

3.3 裂缝量化性能对比

为了测试本文量化算法的适用性与准确性,本研究在校园内通过使用智能移动平台 (如图 19 所示) 拍摄水泥路面构建量化测试集。

在拍摄过程中,相机被固定在距离地面 $z=0.1\text{ m}$ 的高度上,以确保裂缝图像的清晰度和一致性。因此,从图像中的像素尺寸转换为实际的路面裂缝尺寸的转换系数 k 可以通过式 (8) 计算。

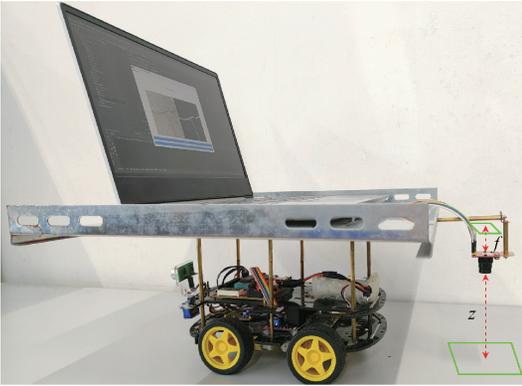


图19 智能移动平台

Fig. 19 Intelligent mobile platform

$$k = \frac{f}{z} \quad (8)$$

其中, f 表示相机焦距, z 表示相机镜头与地面之间的垂直距离。在本研究中, 通过计算地面真实裂缝的最大宽度和最短长度来准确测定其实际尺寸, 并将这些尺寸与基于式(9)计算出的预测尺寸 V_s 进行了比较。

$$V_s = I_p \times k \quad (9)$$

其中, I_p 表示二值图像中裂缝的最大宽度像素或最短路径像素的数目, 在量化最大宽度时, 其邻域值 δ 设置为 2 个 pixels。量化误差 E_r 通过式(10)进行计算。

$$E_r = \frac{|V_s - T_s|}{T_s} \times 100\% \quad (10)$$

其中, T_s 为裂缝的实际尺寸(裂缝的实际最大宽度和实际最短长度), V_s 为式(9)中的预测尺寸。根据式(8)中这些参数的实际值, 本研究确定转换系数 k 为 0.3, 即每个像素代表 0.000 3 m 的实际长度。将本文算法估计的量化结果与手动测量的真实值进行对比后, 图 20 展示了 4 个具有代表性的量化结果。所有图像的分辨率均为 640×640 , 每幅图像的最大宽度与最短长度均为裂缝实际参数, 并标定在原图中。通过式(10)可以得出本文的量化算法在 4 幅裂缝图像的最短长度和最大宽度上的最大误差分别为 11.21% 和 13.39%, 其中最小的宽度误差为图 20(b) 中的 7.50%, 最小的长度误差为图 20(d) 中的 9.01%。这些误差均在可接受的范围内, 同时这些结果不仅验证了本文量化算法的准确性, 也表明该方法能够精准地量化工程实践中的关键裂缝特征, 能为后续的裂缝损伤评估等工作提供了可靠的依据。

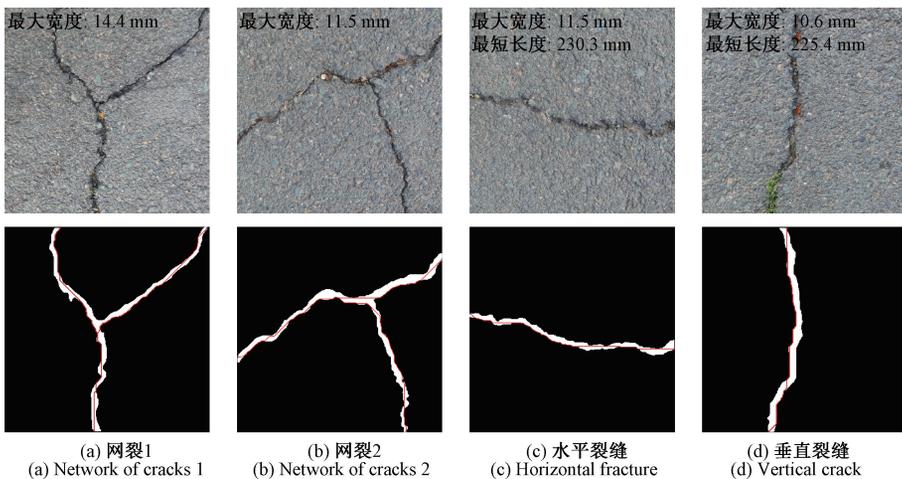


图 20 A* 算法量化最短长度与最大宽度

Fig. 20 The A* algorithm quantifies the minimum length and maximum width

为了进一步验证所提出的量化算法的优异性能, 本研究在 50 张非网裂的测试图像上对比了中轴骨架细化法和 A* 量化算法在最短长度和最大宽度上的表现, 并将统计结果绘制在图 21 中。若预测尺寸与实际尺寸相等, 则代表预测尺寸的圆点或三角形标记会落在基准线 $y=x$ 上。从图 21(a) 中可以看出, 三角形标记普遍位于基准线之上, 这表明中轴骨架细化算法在量化裂缝的最短长度时, 其预测值通常会比实际裂缝长度长。然而图中的圆点大多集中于基准线 $y=x$ 附近, 这表明 A* 算法其预

测值与实际值高度吻合, 能够很好地量化出裂缝的最短长度。

在针对网状裂缝的量化评估中, 本研究也选取了 50 张含有网裂特征的测试图像, 对两种量化最大宽度的算法进行了对比, 并将统计结果绘制于图 22 中。本文的扩展 A* 量化宽度算法通过对网状裂缝预量化出每个裂缝连通区域的最短路径, 进而量化出每条裂缝的最大宽度, 并最终选取其中的最大值作为整个网状裂缝的最大宽度。由于扩展中轴骨架细化算法通常高度依赖于裂

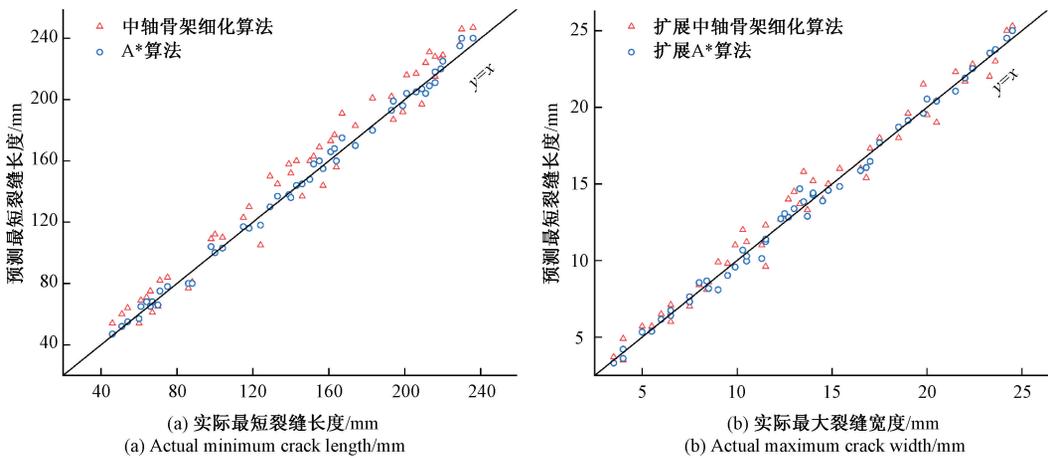


图 21 两种算法量化非网裂长度、宽度对比

Fig. 21 The two algorithms quantify the non-mesh crack length and width comparison

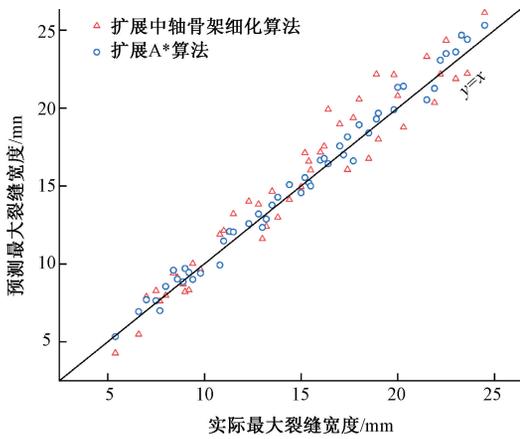


图 22 两种算法量化网裂最大宽度对比

Fig. 22 The two algorithms quantified the maximum width of mesh cracks

缝骨架的准确性,这导致图 22 中三角形标记的分布明显偏离基准线 $y=x$ 。然而,本研究引入的扩展 A* 量化宽度算法展现了出色的性能,得益于 A* 量化出的精确的最短路径,使得图 22 中圆点分布更加集中于基准线附近,体现出本文量化算法的高度准确性。

2 种方法最终的量化误差统计结果如表 4 所示,A* 算法的最短长度和最大宽度的量化误差分别为 12.34%、

15.85%,相较于中轴骨架算法,最短长度和最大宽度的量化误差分别降低了 6.91%、3.41%。进一步证明了本文的量化算法在路面裂缝损坏分级评估中的适用性和有效性,为实际工程应用中的裂缝检测与评估工作提供了有力的技术支持。

4 结 论

针对传统裂缝检测和量化成本高、精度低等问题,本研究提出了一种道路裂缝自动分割量化系统,通过结合 SW-Net 和本文的量化算法,实现了对裂缝的自动分割、分类和量化。通过一系列实验证明了该系统各功能的有效性,经测试该系统在 Crack500 数据集上准确率达到 93.68%、F1 分数为 0.8965。同时,在对已分割的裂缝图像进行分类时,通过结合 MCO、DFS 与不同方向上像素统计曲线的变化趋势对裂缝进行分类,使该系统平均分类准确率达到 99.29%,分类速度达到 109 张/s。最后,相较中轴骨架细化算法,该系统的平均量化误差降低了 5.16%,量化最短长度和最大宽度的相对误差分别为 12.34%、15.85%。这些结果均明确表明,该自动分割量化系统在分割、分类和量化方面取得了显著的突破。

总体而言,该系统中的 SW-Net 网络和扩展 A* 量化算法在道路裂缝分割、分类与量化任务中均表现出卓越的性能,是道路工程应用中裂缝分割和量化低成本、高精度的理想替代方法。然而,本研究所采用的 MCO 算法在特定情境下存在一定的局限性,特别是在连接距离较远的不相交裂缝时。在卷积核较小的情况下,MCO 方法无法有效连接这些裂缝,表现不尽如人意。为解决这一问题,建议后续的研究应探索并应用其他先进的图像处理方法,以优化裂缝的连接与分类过程。最后,为了进一步

表 4 本文算法与中轴骨架细化算法的量化误差对比
Table 4 Comparison of quantization error between the proposed algorithm and the central axis skeleton thinning algorithm

算法	非网裂		网裂
	最短长度	最大宽度	最大宽度
中轴骨架算法及扩展算法/%	19.25	17.87	20.65
A* 算法及扩展量化算法/%	12.34	14.98	16.73

提高量化算法的准确性和分割模型鲁棒性,建议后续的研究可以增加裂缝图像样本的数量和多样性。

参考文献

- [1] 交通运输部. 2023年交通运输行业发展统计公报[N]. 中国交通报, 2024.
Ministry of Transport. Statistical bulletin on development of transport industry in 2023[N]. China Communications News, 2024.
- [2] ZOU Z, ZHAO P, ZHAO X F. Automatic segmentation, inpainting, and classification of defective patterns on ancient architecture using multiple deep learning algorithms[J]. Structural Control and Health Monitoring, 2021, 28(7):27-42.
- [3] SERIGOS P, VISINTINE B A, SIMPSON A L, et al. Quality management program for pavement condition data collected on the national highway system [J]. Transportation Research Record, 2018, 2672(40):155-165.
- [4] MOKALLED S, LOCKE W, ABUODEH O, et al. Drive-by health monitoring of highway bridges using Bayesian estimation technique for damage classification [J]. Structural Control and Health Monitoring, 2022, 29(6):e2944.
- [5] 刘伟,周建行,杨延西. 基于平行激光的便携式视觉裂缝测量系统[J]. 仪器仪表学报, 2020, 41(11):235-243.
LIU W, ZHOU J X, YANG Y X. Portable vision crack measurement system based on parallel laser[J]. Chinese Journal of Scientific Instrument, 2020, 41(11):235-243.
- [6] 姜春,汪圣涵,唐健,等. 基于双层排线探头的轧辊表面微裂纹检测方法[J]. 仪器仪表学报, 2023, 44(6):188-196.
JIANG CH, WANG SH H, TANG J, et al. Micro-crack detection method on roll surface based on double-layer parallel cables probe[J]. Chinese Journal of Scientific Instrument, 2023, 44(6):188-196.
- [7] 颜江涛,赵纪元,訾艳阳,等. 激光超声信号变分模式分解与裂纹定量检测[J]. 仪器仪表学报, 2023, 44(1):223-230.
YAN J T, ZHAO J Y, ZI Y Y, et al. Variational mode decomposition of laser ultrasonic signal and crack quantitative detection[J]. Chinese Journal of Scientific Instrument, 2023, 44(1):223-230.
- [8] CHA Y J, CHOI W, BÜYÜKÖZTÜRK O. Deep learning-based crack damage detection using convolutional neural networks[J]. Computer-Aided Civil and Infrastructure Engineering, 2017, 32(5):361-378.
- [9] RONNEBERGER O, FISCHER P, BROX T. U-net; Convolutional networks for biomedical image segmentation[C]. Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015: Part III, 2015:234-241.
- [10] 周迅,李永龙,周颖玥,等. 基于改进 DeepLabV3+网络的坝面裂缝检测方法[J]. 清华大学学报(自然科学版), 2023, 63(7):1153-1163.
ZHOU X, LI Y L, ZHOU Y Y, et al. Dam surface crack detection method based on improved DeepLabV3 + network[J]. Journal of Tsinghua University (Science and Technology), 2023, 63(7):1153-1163.
- [11] SUN X Z, XIE Y CH, JIANG L M, et al. DMA-Net: DeepLab with multi-scale attention for pavement crack segmentation [J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(10):18392-18403.
- [12] 耿焕同,刘振宇,蒋骏,等. 基于改进 YOLOv8 的嵌入式道路裂缝检测算法[J]. 计算机应用, 2024, 44(5):1613-1618.
GENG H T, LIU ZH Y, JIANG J, et al. Embedded road crack detection algorithm based on improved YOLOv8[J]. Journal of Computer Applications, 2024, 44(5):1613-1618.
- [13] LIU J H, GU J X, LUO SH. Research on road crack detection based on machine vision[C]. 2022 IEEE 6th Advanced Information Technology, Electronic and Automation Control Conference, 2022:543-547.
- [14] CHEN L J, YAO H D, FU J Y, et al. The classification and localization of crack using lightweight convolutional neural network with CBAM[J]. Engineering Structures, 2023, 275:115291.
- [15] WOO S, PARK J, LEE J Y, et al. Cbam: Convolutional block attention module[C]. Proceedings of the European Conference on Computer Vision (ECCV), 2018:3-19.
- [16] LI G, CHEN Y Q, ZHOU J, et al. Road crack detection and quantification based on segmentation network using architecture of matrix [J]. Engineering Computations, 2022, 39(2):693-721.
- [17] FAN ZH, LIN H B, LI CH, et al. Use of parallel ResNet for high-performance pavement crack detection and measurement[J]. Sustainability, 2022, 14(3):1825.
- [18] SHAO CH Y, FENG X ZH, LI J B. Crack detection and measurement using PTZ camera-based image processing method on expressways [J]. Journal of Transportation Engineering, 2022, 148(3):04022043.
- [19] SU H F, WANG X, HAN T, et al. Research on a U-Net bridge crack identification and feature-calculation methods based on a CBAM attention mechanism [J]. Buildings, 2022, 12(10):12101561.
- [20] TENG SH, CHEN G F. Deep convolution neural

- network-based crack feature extraction, detection and quantification [J]. *Journal of Failure Analysis and Prevention*, 2022, 22(3):1308-1321.
- [21] TANG Z M, JIANG W M, ZHANG ZH, et al. DenseNet with Up-Sampling block for recognizing texts in images[J]. *Neural Computing and Applications*, 2020, 32:7553-7561.
- [22] KANG D H, CHA Y J. Efficient attention-based deep encoder and decoder for automatic crack segmentation[J]. *Structural Health Monitoring*, 2022, 21(5):2190-2205.
- [23] 孙岩霆,王荣杰,蒋德松. 融合 A* 与 DWA 算法的水面船艇动态路径规划 [J]. *仪器仪表学报*, 2024, 45(1):301-310.
SUN Y T, WANG R J, JIANG D S. Dynamic path planning of surface ship by combining A* and dynamic window algorithm [J]. *Chinese Journal of Scientific Instrument*, 2024, 45(1):301-310.
- [24] 侯艳丽,马震. 基于深度优先搜索的分层网络最短路径算法[J]. *无线电通信技术*, 2023, 49(4):684-688.
HOU Y L, MA ZH. Shortest path algorithm for layered networks based on depth-first search [J]. *Radiocommunication Technology*, 2023, 49(4):684-688.
- [25] AZAM B, VERMA B, KUTTICHIRA D P, et al. A novel graph-based framework for explainable image classification: Features that matter [C]. 2023 International Conference on Digital Image Computing: Techniques and Applications (DICTA), 2023:145-151.
- [26] 李帅,侯德华,高杰,等. 基于数学形态学的路面裂缝图像处理技术[J]. *公路工程*, 2018, 43(2):270-274.
LI SH, HOU D H, GAO J, et al. Pavement crack image processing technology based on mathematical morphology[J]. *Highway Engineering*, 2018, 43(2):270-274.
- [27] YANG X C, LI H, YU Y T, et al. Automatic pixel-level crack detection and measurement using fully convolutional network [J]. *Computer-Aided Civil and Infrastructure Engineering*, 2018, 33(12):1090-1109.
- [28] ZHANG T Y, SUEN C Y. A fast parallel algorithm for thinning digital patterns [J]. *Communications of the ACM*, 1984, 27(3):236-239.
- [29] YU S N, JANG J H, HAN CH S. Auto inspection system using a mobile robot for detecting concrete cracks in a tunnel[J]. *Automation in Construction*, 2007, 16(3):255-261.
- [30] HEUSNER M, KELLER T, Helmert M. Best-case and worst-case behavior of greedy best-first search[C]. 2017 International Joint Conferences on Artificial Intelligence and 23rd European Conference on Artificial Intelligence, 2018: 1463-1470.
- [31] FOEAD D, GHIFARI A, KUSUMA M B, et al. A systematic literature review of A* pathfinding [J]. *Procedia Computer Science*, 2021, 179:507-514.
- [32] HE T, ZHANG ZH, ZHANG H, et al. Bag of tricks for image classification with convolutional neural Networks[C]. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019:558-567.
- [33] KINGMA D P, BA J. Adam: A method for stochastic optimization[J]. *Computer Science*, 2014.
- [34] YANG F, ZHANG L, YU S J, et al. Feature pyramid and hierarchical boosting network for pavement crack detection [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2019, 21(4):1525-1535.

作者简介



于天河(通信作者),1997年和2003年于哈尔滨科技大学获得学士和硕士学位。2009年于哈尔滨工业大学获得博士学位。现任哈尔滨理工大学测控技术与通信工程学院教授。主要研究方向为图像处理与识别、信息处理、自动检测与智能仪器、人工智能。

E-mail:ythaa@163.com

Yu Tianhe (Corresponding author) received his Bachelor and Master degrees from Harbin University of Science and Technology in 1997 and 2003. He received his Ph. D from Harbin Institute of Technology in 2009. He is currently a professor at the School of Measurement and Control Technology and Communication Engineering of Harbin University of Science and Technology. His research interests include image processing and recognition, information processing, automatic detection and intelligent instruments, and artificial intelligence.



徐博超,2022年于哈尔滨理工大学获得学士学位,现为哈尔滨理工大学硕士研究生,主要研究方向为深度学习和图像分割。

E-mail:458763429@qq.com

Xu Bochao received his B. Sc. degree from Harbin University of Science and Technology in 2022. Now he is a master's candidate at Harbin University of Science and Technology. His research interests are deep learning and image segmentation.



侯善冲,2023年于山东理工大学获得学士学位,现为哈尔滨理工大学硕士研究生,主要研究方向为深度学习和图像处理。

E-mail:houshanchong@163.com

Hou Shanchong received his B. Sc. degree from Shandong University of Technology in 2023 and he is currently a master's student at Harbin University of Science and Technology, with his main research interests in deep learning and image processing.