

DOI: 10.13382/j.jemi.B2306690

复杂恶劣环境下水位智能检测方法研究*

王宇^{1,2} 魏宇^{1,2} 孙传猛^{1,2} 武志博^{1,2} 李勇³

(1. 中北大学省部共建动态测试技术国家重点实验室 太原 030051; 2. 中北大学电气与控制工程学院 太原 030051;
3. 重庆大学煤矿灾害动力学与控制国家重点实验室 重庆 400044)

摘要:实现智能化水务管控和洪涝灾害预警,需要实时、准确感知水位信息变化情况。针对现有技术不能满足夜晚、雾天、雨天、漂浮物遮挡、灯光阴影等复杂恶劣环境下的水尺水位的影像水位反演(小目标特征)识别需求,提出一种融合改进YOLOv5与RankSE的水位智能检测方法。首先,采用强化小尺度特征的多层级特征融合方法来改进YOLOv5算法,以强化对小目标的捕捉能力;其次,融入RankSE模块进一步提升对小目标的感知能力;最后,提出一种全新的水位高程解算方案,仅需利用部分水尺锚框信息即可获得准确的水位高程信息,极大提升了检测方法的鲁棒性。研究表明,本文所述方法水位检测相对准确度达98.5%,较原算法提高了8.4%;在复杂恶劣环境下可以自动、准确识别出水位高程,最大误差仅为0.11 m。研究结果有效提升了复杂恶劣环境下水位检测的准确性。

关键词: 复杂恶劣环境;水位智能检测;YOLOv5;水尺

中图分类号: TP391 **文献标识码:** A **国家标准学科分类代码:** 520.6

Research on intelligent detection method of water level in complex and harsh environment

Wang Yu^{1,2} Wei Yu^{1,2} Sun Chuanmeng^{1,2} Wu Zhibo^{1,2} Li Yong³

(1. State Key Laboratory of Dynamic Measurement Technology, North University of China, Taiyuan 030051, China;

2. School of Electrical and Control Engineering, North University of China, Taiyuan 030051, China;

3. State Key Laboratory of Coal Mine Disaster Dynamics and Control, Chongqing University, Chongqing 4 00044, China)

Abstract:To realize intelligent water management and control and flood disaster early warning, it is necessary to accurately sense the change of water level information in real time. Because the prior technology cannot meet the requirements of water level identification in complex and harsh environments such as night, fog, rainy day, floating object occlusion, light shadows, etc., an intelligent water level detection method based on improved YOLOv5 and RankSE was proposed. Firstly, the YOLOv5 algorithm was improved by the multi-level feature fusion method which strengthens small-scale features, to strengthen the ability of capturing small targets. Secondly, integrating the RankSE module further enhances the perception of small targets. Finally, a new solution of water level elevation was proposed, which can obtain accurate water level elevation information only by using part of water gauge anchor frame information, which greatly improved the robustness of the detection method. The research results show that the accuracy of water level detection in this paper reached 98.5%, which was 8.4% higher than the original algorithm. The water level elevation could be automatically and accurately identified in complex and harsh environments. The maximum error was only 0.11 m. The research results effectively improve the accuracy of water level detection in complex and harsh environments.

Keywords: complex and harsh environment; intelligent detection of water level; YOLOv5; water gauge

收稿日期: 2023-07-03 Received Date: 2023-07-03

* 基金项目: 国家重点研发计划青年科学家项目(2022YFC2905700)、山西省基础研究计划项目(202203021212129, 202203021221106)、山西省科技成果转化引导专项(202104021301061)资助

0 引言

近年来,我国因强降雨而引发的城市内涝时有发生,严重影响人民生活,危害人民生命财产安全。可见,水文资料与人类社会生活、生态环境关系密切,水位监测在水利工程、防汛预警等领域发挥着重要作用,实现精细化水务管控和洪涝灾害预警,需要实时、准确感知水位信息变化情况^[1-3]。

随着信息化进程的不断推进,图像处理技术迅猛发展,以图像手段进行水位检测的方法得到广泛关注,目前主要分为基于传统计算机视觉(非深度学习)的水位检测技术和基于深度学习的水位检测技术。早期,在基于传统计算机视觉的水位检测技术中,Yan 等^[4]提出了一种基于单摄像机图像的水位自动检测方法,该方法采用数字图像处理技术实时检测水位,但该算法对雨天、雾霾、雪天、阴影遮挡、光影变换等干扰敏感。Iwahashi 等^[5]提出水平检测算子检测水位线,但是对不规则水位线检测效果差。Bao 等^[6]通过边缘提取与 Harr 特征分段计算提取水位线,但同样在光照强烈、光影变幻的情况下容易产生误检。孙维亚等^[7]对拍摄到的水位图像进行预处理,并利用改进 Canny 算子对水尺关键字部分进行分割,进而获取当前水位值,但当水尺存在遮挡或图像不清晰将导致检测算子产生误检。刘铭辉等^[8]提出一种复杂光照条件下不定长水尺图像水位测量方法,提高了不定长水尺图像水位检测的可靠性。曹文卓等^[9]提出一种基于语义分割和由粗到精策略的水位线检测方法,提升了水位检测精度。基于传统计算机视觉(非深度学习)水位检测技术虽然不依赖大量数据,且初步实现了无人化识别,但是其鲁棒性有限不适用于雨天、雾霾、雪天等复杂恶劣场景。

随着人工智能技术的迅速发展,国内外很多学者将深度学习应用到水位检测技术中。程淑红等^[10]提出利用 U-net 图像分割技术识别水位线,U-net 水位自动分割可以精确地标记出水位线,同时解决了在水位测量过程中图像背景所带来的影响。肖卓等^[11]利用 SSD 目标检测算法开展了视频水位检测算法研究,该方法能准确定位水尺目标并提取水位值。廖赞等^[12]设计了一种卷积神经网络结构进行水位线检测,可以对河道湖泊等开放水域实现全天候非接触式水位连续监控。王磊等^[13]提出一种由 YOLO-v3 对象检测和 ResNet 刻度识别模型构成的实时水位识别算法,方法水位识别精度将继续提高,并具备向检测断面现场环境识别拓展的应用空间。夏平等^[14]针对水尺污渍和倾斜造成观读数据误差问题,提出基于改进超像素与图割算法的智能视觉水位识别算法。傅启凡等^[15]采用改进的 DeepLabv3+算法并结合空间注

意力机制、通道注意力机制和边缘细化模块对水位标尺图像进行分割,以实现对水位的智能识别。徐志康等^[16]采用图像处理技术处理采集的水尺图像实现水尺定位及分割,然后基于模糊 C 聚类方法分割水尺字符并输入到训练好的卷积神经网络中进行识别。李欣宇等^[17]构建一种融合 Transformer 与残差通道注意力机制的 Unet 模型(TRCAM-Unet),进而提出基于 TRCAM-Unet 的恶劣场景水位智能检测方法。Sakaino 等^[18]提出了一种基于相机视觉的水位估计方法,该方法在检测效率、鲁棒性和准确性方面都有了很大提升。Vitry 等^[19]结合深度卷积神经网络,利用现有的监控摄像机系统来提供定性的洪水水位趋势信息。房爱印等^[20]提出了一种高精度的水尺水位检测网络:DetSegNet,在网路结构、损失函数等方面对 YOLOv4 和 DeepLabv3+算法进行了创新,有效提升的水位检测精度。张荣星等^[21]针对复杂环境下水尺识别及水位线检测存在准确率较低的问题,提出了一种小区域引导下的水尺水位检测方法,有效提升水位检测精度。基于深度学习的水位检测技术比起传统计算机视觉(非深度学习)的水位检测技术检测精度提升很大,但水尺刻度在检测图像中属于“小目标”对象,在复杂恶劣环境下,现有目标检测技术对小目标的检测能力依然存在严峻挑战。因此,有效实现恶劣场景下的水位精准检测成为亟待解决的难题。

鉴于此,本文结合恶劣场景下水位图像特点,提出一种融合改进 YOLOv5 与 RankSE(基于秩的压缩激活网络)的水位智能检测方法,该方法具有准确性高、泛化能力强的特点。具体研究内容为:1)以深度学习目标检测算法对水岸分界线(水位线)进行目标检测,这区别于常规方法对水面的识别;2)采用强化小尺度特征的多层级特征融合方法来改进原 YOLOv5 算法;3)利用求秩运算代替原 SENet 的全局平均池化操作,提出 RankSENet 模块;4)提出了一种鲁棒性强的水位高程换算方案,在无需检测出所有待检对象的情况下,能够将水尺锚框信息解算为准确的实际水位高程信息。

1 复杂恶劣环境下的水位特征分析

1.1 复杂恶劣环境检测目标特征

白天、黑夜、灯光阴影等环境下检测目标特征如图 1 所示,复杂恶劣环境下,现有的水位检测算法不能准确的定位水尺或者水面,易在图像部分区域发生漏检和误检,严重影响检测算法的性能。

1.2 “水岸分界线”特征

图 1 所列的复杂恶劣环境会模糊水尺或者水面特征,影响深度学习算法性能。相比定位水尺或者水面,水

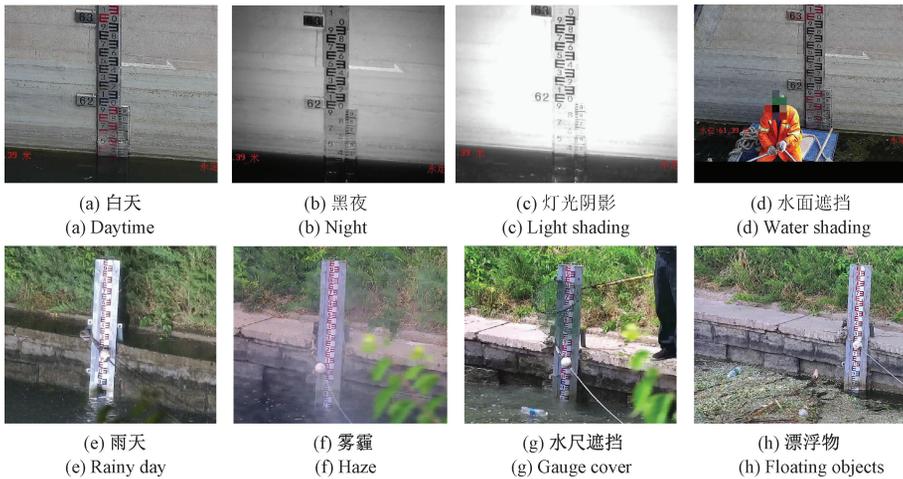


图 1 不同环境下采样实例图

Fig. 1 Sampling examples in different environments

岸分界线有更加清晰明确的特征。常规水面特征与水岸分界线特征对比图如图 2 所示。由图可知,水岸分界线特征是十分明确和稳定的,其一边为水面,另一边为岸堤,二者差异明显,且堤岸特征通常十分稳定。因此,利用深度学习学习方法学习“水位线”的效果会比水尺或者水面更好,为效解决复杂恶劣环境下的水位检测难题提供了新的手段。

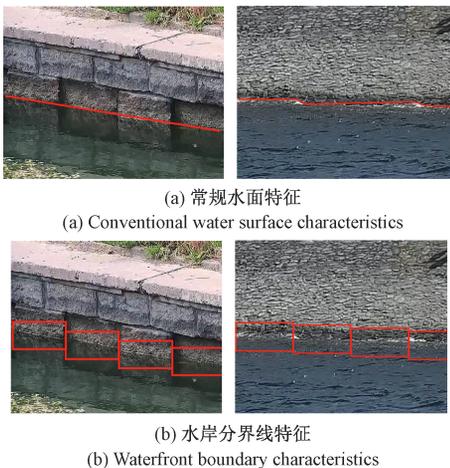


图 2 常规水面特征与水岸分界线特征对比
Fig. 2 Comparison between conventional water surface features and waterfront boundary features

1.3 水尺刻度的“小目标”特征

在深度学习中,小目标检测一直是技术难点。同一类别中所有目标实例的相对面积,即边界框面积与图像面积之比的中位数在 0.08%~0.58%之间。根据图 3 可知,在水尺图像中,水尺刻度与图像的相对比例是极小的,具有鲜明的“小目标”特征;同时,该“小目标”特征更

易受复杂恶劣环境干扰。可见,基于水尺的水位检测技术受制于“小目标检测”难题和复杂恶劣环境干扰,极易出现较大误差甚至直接失效。



图 3 水尺图像示意图

Fig. 3 Schematic diagram of water gauge image

2 水位智能检测机理

2.1 水位检测原理

现有目标检测算法仅输出水尺锚框坐标、类别、置信度等信息,而非实际的水位高程值。如图 4 所示,常规的含有“E”字水尺图像中,有明显的高程刻度值且搭配对应的正“E”、反“E”两种高程标志,并且每个“E”类标志在垂直方向的实际高程是确定的,这对于利用深度学习目标检测技术获取水位高程值提供了实现依据:首先,结合“E”类标志在图像纵方向的像素距离与实际高度,可获得像素在垂直方向与实际高度的比率 K (单位: $m/pixel$);然后,获得水位线(黄线)距离最顶部“E”类标志的实际距离 L (单位: m),如式(1)所示;最后,计算最顶部“E”类标志实际刻度与 L 的差值,即可获得水位高程

值 H , 如式(2)所示。

$$L = K \times (y_{\text{water}} - y_{\text{Etop}}) \quad (1)$$

$$H = \text{最顶部 } E \text{ 实际刻度} - L \quad (2)$$

式中: y_{water} 为水位检测像素坐标, y_{Etop} 为最顶部“E”类标志的像素坐标。

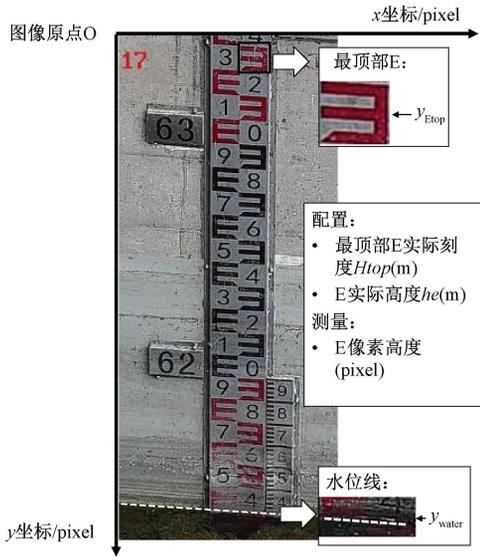


图 4 “E”字水尺图像示意图

Fig. 4 “E” water gauge image schematic diagram

2.2 逼近真实水位线的方法

将目标检测算法预测的水位线锚框中心坐标采样, 并进行最小二乘法拟合, 即可获得水位线的表达式:

$$y = ax + b \quad (3)$$

其中:

$$a = \frac{n \sum_{i=1}^n x_i y_i - \sum_{i=1}^n x_i \sum_{i=1}^n y_i}{n \sum_{i=1}^n x_i^2 - \left(\sum_{i=1}^n x_i \right)^2} \quad (4)$$

$$b = \bar{y} - a\bar{x} \quad (5)$$

式中: x_i, y_i 是预测框中点坐标; a 是拟合直线的斜率; b 是拟合直线的截距; n 是预测框数量; \bar{x}, \bar{y} 是预测框中点坐标均值。

这样, 通过采样加拟合的方式, 获得逼近真实的水位线。该方法无须检测所有水位线区域, 解决了水面存在异物遮挡导致部分区域水位线预测无效的问题, 且更具鲁棒性。

2.3 水位检测方案

利用深度学习目标检测技术获取水位需要事先对数据集进行标注, 各标注示例图如图 5 所示, 表 1 对各类标注形式作了归纳。其中, 各类标注类型具有不同的功能: E 类, 分为正 E0、反 E1, 根据配置 E 的高程信息, 获得垂向上每个像素与实际高程的粗略比率 K' ; 数字类, 根据

图 4 配置最顶部完整数字对应 E 的刻度信息, 联系像素坐标与世界坐标; 水位类, 获得水位线和水位线在垂直方向的图像坐标, 进而换算出实际高程; 水尺类, 判断 E 类、数字类对象是否合法 (即校验目标是否处于合法区域)。

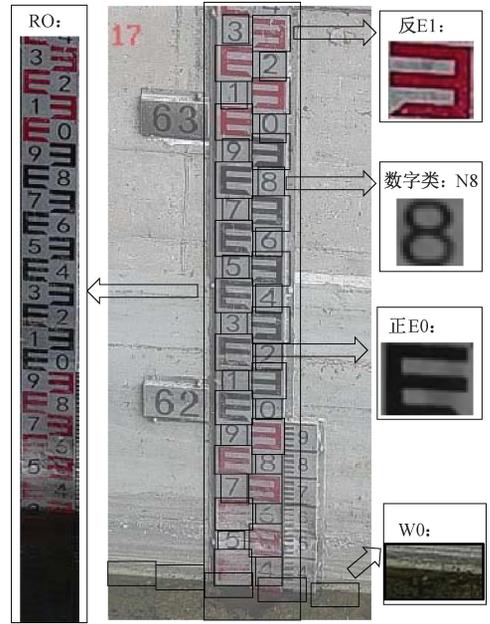


图 5 水尺图像标注示意图

Fig. 5 Schematic diagram of water gauge image annotation

表 1 各类标注形式

Table 1 Various forms of annotation

标注类型	标注形式和标签
E 类	正 E, 记为 E0; 反 E, 记为 E1
数字类	数字 0~9, 分别记为 N0~N9
水位类	标注框中心贴合水位线, 标注框之间保持连续, 记为 W0
水尺类	水平向正好包含水尺, 垂向全包括, 记为 R0

能仅依靠深度学习目标检测算法只能获得若干个含有目标坐标、种类信息的矩形锚框, 并不能获得准确的水位高程值, 而且由于算法自身性缺陷, 或者受拍摄场景影响, 导致算法不能识别出所有待检目标, 为了将输出的水尺图像信息转化为准确的实际水位高程信息, 同时增强算法适用性, 本文提出了一种全新水位高程换算方案, 解决恶劣场景下水位识别难题, 并在此基础上形成水位检测方案:

1) 在实际应用中, 首先进行参数配置, 获得水尺中每个 E 类标志的实际高程 he 和最顶端完整搭配数字的 E 类标志的实际刻度 H_{top} , 以及所对应的数字, 记为 $X3$ 。

2) 检测水尺类 (R0) 目标, 得到水尺的水平横坐标 R_{xmin} 和 R_{xmax} , 以便判断除水位类 (W0) 以外的其它检测对象是否合法, 即判断目标水平横坐标是否存在于 (R_{xmin}, R_{xmax}) 之间, 在此区域内为合法对象, 否则为非

法对象,非法对象不进行计算。如果没有检测到 R0 目标,系统继承上一次 R0 对象坐标信息。

3) 检测水位类(W0)目标,并利用线性回归拟合水位线;同时检测数字类(N类)目标是否存在,存在便进行下一步骤,如未检测到N类目标或W0类目标,系统继承上一次水位实际高程值H,操作结束。

4) 检测E类(正E、反E)目标,利用单个E实际高程和E的像素高程得到实际高程与像素高程之间的粗略映射关系,即粗略比率 K' ,如式(6)所示。如未检测到E类目标,系统利用单个N类目标实际高程与其像素高程进行计算。

$$K' = \frac{E \text{ 实际高度}}{E \text{ 像素高度}} \quad (6)$$

5) 检测并判断数字(N类)对象数量,如果数量大于1个,则计算顶端与底端N类对象之间实际长度与像素长度的比值,即精确比率 K 。

6) 获得拟合水位线的基准计算坐标,取相邻两个合法正E、反E目标之间的中心横坐标 x_{water} ,并将此横坐标代入水位线表达式(3),求得当前水位线纵坐标 y_{water} 。

7) 如图6所示,利用X1信息和配置顶端E实际刻度 H_{top} ,获得X1中心实际高程 H_{top} ,进而获得水位实际高程H。水位高程值H计算公式为:

$$H = H_{\text{top}} - (y_{x1} - y_{\text{water}}) \times K \quad (7)$$

其中, y_{x1} 为X1对应纵坐标; K 为精确比率, H_{top} 为X1中心实际高程。

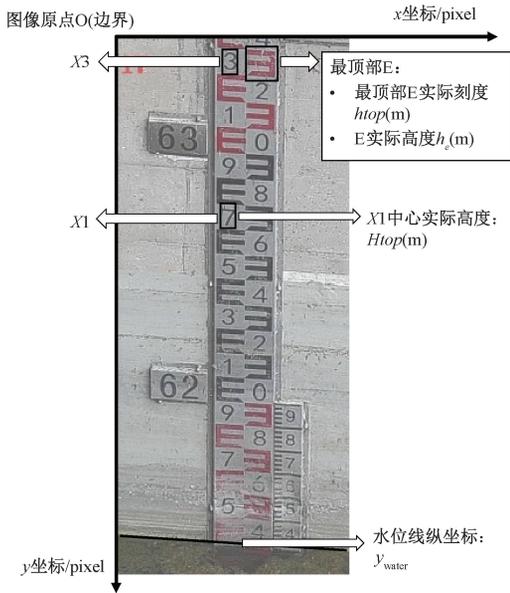


图 6 X1、X3 配置示意图

Fig. 6 Configuration diagram of X1 and X3

整体方案流程图如图7所示。

2.4 改进 RankSE 模块

传统卷积网络通过感知输出各特征通道信息,实现对目标的分类及定位,压缩激活网络(squeeze-and-excitation networks, SENet)通过重新分配各个特征通道权重,提升含目标信息特征通道的表征能力,通过集成 SENet 至 YOLOv5 网络,可有效提升模型的准确率。

SENet 网络结构如图8所示,对于输入特征图(通道数为 C),网络经过压缩、激活、特征重标定3个操作对其重新标定,通过学习各个通道之间的关联性,自动获得每个特征通道的重要程度,然后按照此重要程度提升对当前任务作用成效高的特征,并抑制成效低的特征,从而提升模型的准确率。其中,压缩操作指 SENet 通过对特征图的空间维度进行特征压缩,将每一个二维的特征通道经过全局平均池化操作压缩为一个实数,这个实数反应了该通道特征的潜在重要程度,压缩后的输出维度与输入特征通道 C 一致。压缩操作公示为:

$$f(X) = \frac{\sum_{i=1}^h \sum_{j=1}^w X(i, j)}{h \times w} \quad (8)$$

式中: $X(i, j)$ 为输入特征图, h, w 分别为特征图的高、宽, $f(X)$ 为压缩实数。

然而,在实际的水尺刻度检测任务中,水尺刻度目标可能比较细微,相对整个水位图像而言,其所占面积较小,导致检测算法通过卷积提取到的特征图中包含的水尺刻度特征信息较少。这些特征经 SENet 压缩(全局平均池化)操作后,极易消弭水尺刻度信息对压缩实数的影响,使所得实数不能准确反应该通道的潜在重要程度。

在局部范围内,水尺表面、水尺背景(如墙面)颜色是一致的,与“刻度标志”在视觉属性上区别明显。显然,利用卷积神经网络提取目标的高维特征时,特征图的背景信息应可能会出现差异不大的情况,这意味着输出的特征图矩阵近似是一种低秩矩阵。为方便说明与理解,假设局部图像背景颜色一致,则卷积网络输出特征图信息也一致。当这个局部区域包含水尺目标时,相当于给输出特征图加入了不规则的新信息,增加了特征图矩阵的复杂程度。如图9所示,椭圆圈为水尺图像信息,由于水尺刻度图像特征较少,SENet 采用全局平均池化操作得到的实数并不能很好的反应出加入水尺刻度后特征图的变化程度;然而,由于水尺刻度信息的加入,使原来的低秩矩阵变为高秩矩阵,即特征图的秩相较于平均池化得到得实数,更能反应每个特征通道得变化程度。

然而,当检测目标为水位线时,水位线贯穿整个图片,导致求秩运算后得到的特征图依然是低秩特征图,无法很好的体现其特征通道的重要程度,但在此情况下,水位线的特征信息往往分布较多。为了解决上述问题,如图10所示,将求秩运算与原 SENet 的全局平均池化操作

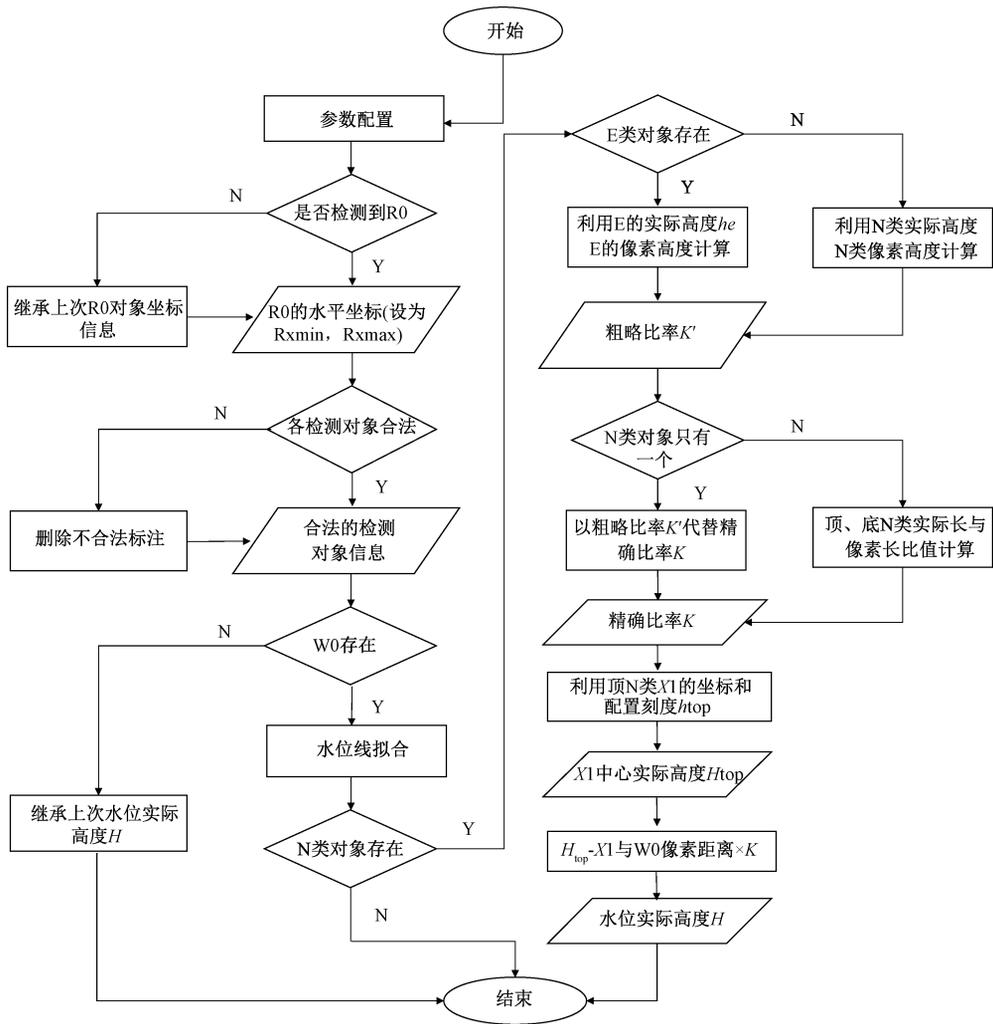


图 7 水位检测方案流程

Fig. 7 Flow chart of water level detection scheme

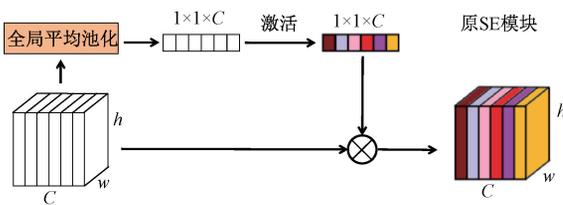


图 8 SENet 网络结构

Fig. 8 SENet network structure diagram

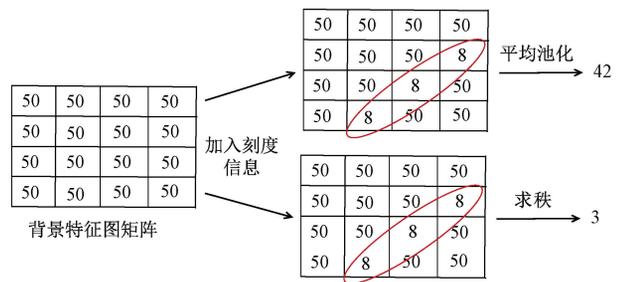


图 9 “秩”表征特征通道重要性原理示意图

Fig. 9 Schematic diagram of the importance principle of “rank” to represent feature channels

相结合,代替原先仅对特征图进行的平均池化操作,在检测对象特征分布较多、或较少的情况下,均能有效提升压缩实数的变化程度,本文将新的 SENet 命名为 RankSENet。

2.5 原 YOLOv5 网络结构

YOLOv5 网络模型主要分为输入层、基准网络层、颈部特征融合网络层、检测头 4 个部分。网络结构如图 11

所示,其中,输入层负责图像预处理,包含图像自适应缩放、Mosaic 数据增强、自适应锚框计算等操作;基准网络层采用 CSPDarknet53 结构作为基准,同时引入 Focus 结构对图像进行切片,然后在通道方向拼接,减少原始信息的丢失,同时,减少网络计算量;颈部特征融合网络层使

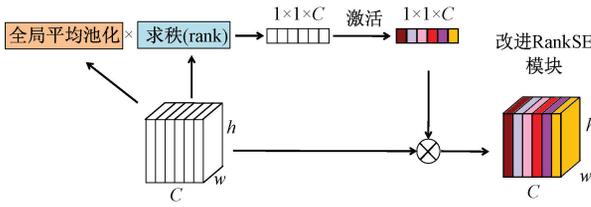


图 10 RankSENet 网络结构

Fig. 10 RankSENet network structure

用 SPP 模块,解决了将图像裁剪到固定尺寸时引起图片失去部分重要信息的问题;使用 FPN 加 PAN 特征融合模块,通过上采样将高层特征信息与底层特征进行融合,再通过自下而上的融合方式,提高了特征映射的多样性和鲁棒性,最后将融合后大、中、小 3 种不同尺度的特征映射送入检测头进行预测;检测头主体部分是 3 个检测器,每个检测器利用网格中设定的先验框在不同尺度的特征映射上进行目标检测,最终将 3 个检测器中概率评分最高的先验框选定为最终预测框。

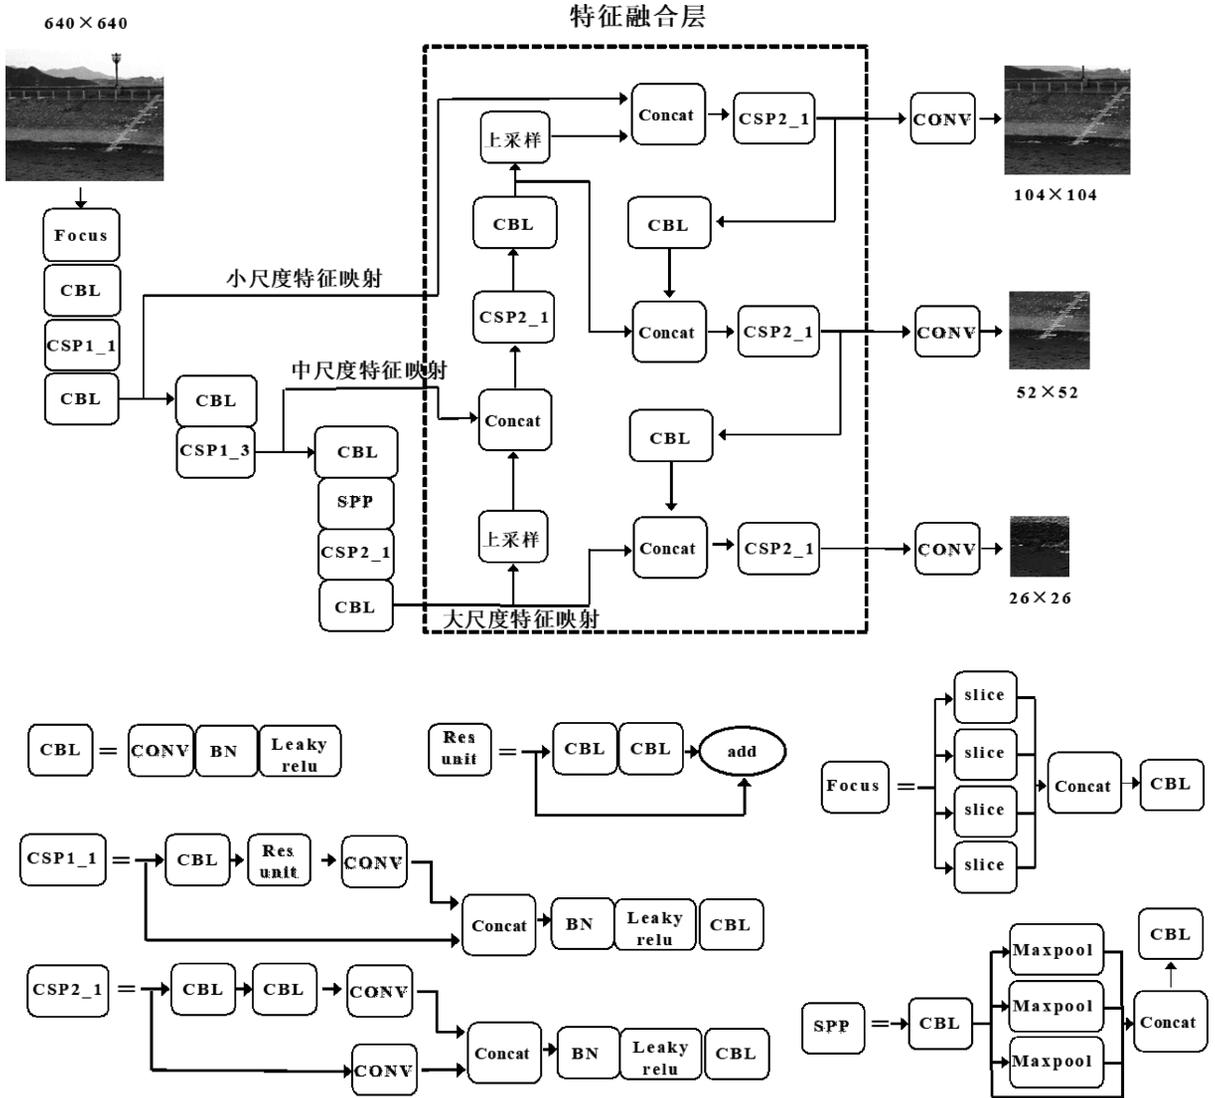


图 11 YOLOv5 网络结构

Fig. 11 YOLOv5 network structure

目标检测算法主要分为单阶段和双阶段两大类,其中,单阶段目标检测算法代表有 YOLOv3、SSD 等;双阶段目标检测算法代表有 Faster-RCNN。YOLOv5 属于单阶段目标检测算法,该算法融合了 YOLO 先前版本的优点,在公开 COCO 数据集上对 Faster-RCNN、SSD、YOLOv3、

YOLOv4、YOLOv5 进行测试(如表 2 所示)表明,YOLOv5 在 mAP(准确性)和 FPS(实时性)性能指标上都表现最优。因此,YOLOv5 算法能够学习到水位图像的语义特征,并满足水位检测的实时性、准确性等要求。

表 2 不同目标检测算法在 COCO 数据集上的测试结果

Table 2 Test results of different target detection algorithms on COCO dataset

性能指标	F-RCNN	SSD	YOLOv3	YOLOv4	YOLOv5
mAP/%	59.1	48.5	55.3	65.7	69.6
帧率/fps	-	22	35	33	40

2.6 改进 YOLOv5 网络结构

根据卷积理论可知,浅层特征映射包含更多的图像空间信息和细节信息,有利于目标定位,深层特征映射包

含更多的图像语义信息,有利于目标分类。根据感受野不同,YOLOv5 通过小尺度映射检测小目标,由于水尺刻度对象属于小目标,因此,需要提升 YOLOv5 对小尺度映射的识别与定位能力。

综上所述,对 YOLOv5 网络颈部特征融合网络层做如下改进:将 YOLOv5 中尺度特征映射和大尺度特征映射两个传递节点汇入到小尺度特征映射通道,对小尺度特征映射进行紧密、充分融合,提高小尺度特征映射传递空间信息、细节信息和语义信息的能力。改进后 YOLOv5 网络结构如图 12 所示。

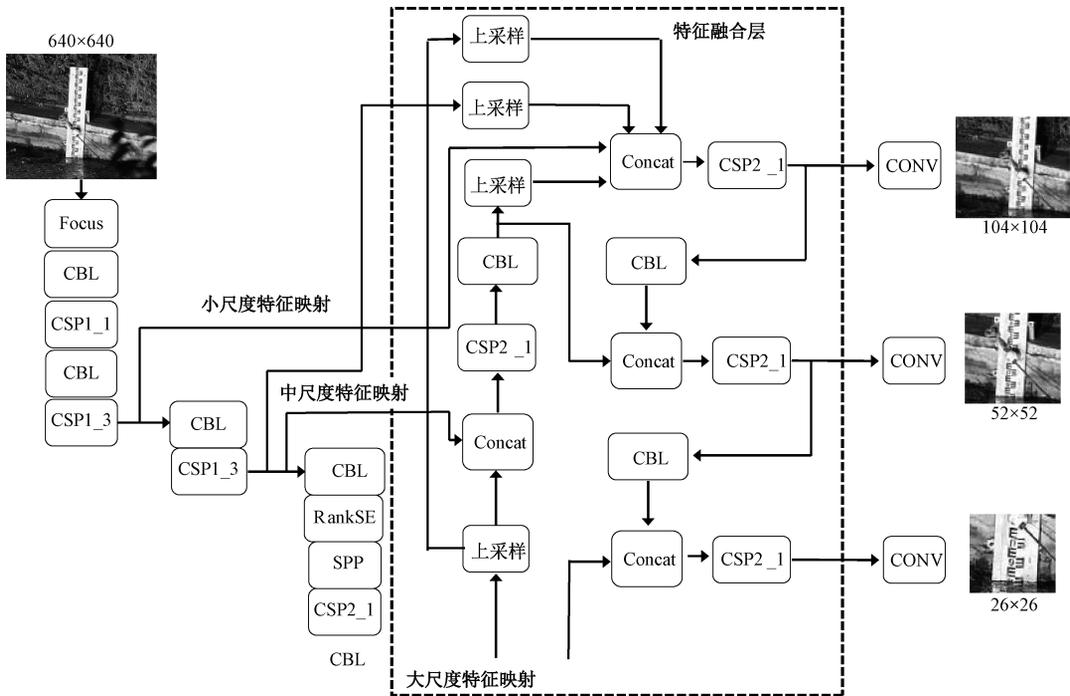


图 12 改进 YOLOv5 网络结构

Fig. 12 Improved YOLOv5 network structure

改进 YOLOv5 在水尺识别中更具优势:增加了小尺度特征映射的汇入节点,实现更加充分、更紧密的融合,丰富了小尺度映射特征图信息,提高了小尺度特征映射识别水尺刻度的能力。

3 水位智能检测实验研究

3.1 实验方案

首先,制作数据集,通过实地隔时采集某两处场景(场景 A、场景 B)中各类水位图像总共 4 175 张。其中,场景 A 为某郊外河道,通过灯光直接照射弥补夜间光线不足;场景 B 为某水库,夜间通过红外功能采集水尺图像。观察图像可知,场景 A 图片清晰度较高,但由于灯光直射导致图像中阴影较多,水尺部分区域存在异物遮挡,

郊外场景也较为复杂,给目标检测带来一定挑战;场景 B 水尺部分完整,但是由于夜间采用红外采集,导致夜晚图像的清晰度不高,并且红外过曝等因素严重影响了图片成像。综上所述,两处场景特点不同,所需解决的问题也不同,同时满足了数据集样本多样性。

其次,根据 2.3 节所述方案对水位线进行标注,将标注图像按比例分为训练集(3 675 张)和测试集(500 张)。为防止过拟合,训练集经数据集增强扩容至 13 875 张。

然后,本文选用改进 RankSE-YOLOv5 算法作为深度学习主干网络,利用测试集测试训练算法的性能。

最后,为验证融合 RankSE 与改进 YOLOv5 网络模型的优越性能,设计了相关对比实验。对比模型分别为 YOLOv5、改进 YOLOv5、SE-YOLOv5+(集成 SENet 与改进 YOLOv5)、RankSE-YOLOv5+(集成 RankSENet 与改进 YOLOv5)。

实验过程中,超参数取值一致:Batch Size 设置为 32,初始学习率为 0.01,采用余弦退火算法对学习率进行更新学习率,最大迭代次数均为 500。实验硬件场景: Intel Xeon Gold 5218R CPU, 256 G 内存, Nvidia Quadro RTX6000 24GB GPU。软件场景: 64 位 Windows10, Python3.8+Pytorch1.7.1。

3.2 评价指标

通常,目标检测算法模型主要通过平均精度(average precision, AP)、平均精度均值(mean AP, mAP)、准确率和召回率等评估目标检测算法的性能。然而,水位线(W0 对象)在延伸方向无限大、法线方向无限小,其特征不随图像尺度发生变化,导致上述评价指标失效。并且,考虑到所选目标检测算法可能自身性能局限,导致识别准确率低、漏检率高等问题,因此本文提出了一种全新的水位高程解算方案,可以在原目标检测算法检测准确率低下的条件下,实现准确的水位识别。

本文所提水位智能检测方法输出结果为实际水位高程,为了检验本文所提水位高程解算方案的可行性,本文以预测水位高程与真实水位高程的相对准确度 P_a 作为评价指标:

$$P_a = \left(1 - \frac{|H_{real} - H|}{H_{real}} \right) \times 100\% \quad (9)$$

式中: H 为算法预测水位高程; H_{real} 为真实水位高程; 真实水位高程值为人工提取的标签值。

3.3 实验结果分析

测试集总计 500 张水位图像,包含了各类复杂场景,各模型部分检测热力图如图 13 所示。由热力图效果可知:1)SENet 与强化小尺度特征的多层级特征融合方法的热力图已聚焦于“水尺刻度”上,这是原 YOLOv5 所不能的。显然,SE-YOLOv5+提升了对小目标(水尺刻度)的捕捉能力。2) RankSE-YOLOv5+的检测热力图,相比 SE-YOLOv5+对小目标(水尺刻度)聚焦得更精准, RankSE-YOLOv5+对小目标的检测能力更强。这从检测目标对象的类别概率可以看出:在图 13 中,某对象“E1”在原 YOLOv5、SE-YOLOv5+、RankSE-YOLOv5+的检测概率分别为 0.49、0.75、0.84。可见,融入 RankSE 模块后的 YOLOv5 特征提取能力更强,目标识别准确率更高,对水尺刻度特征表达更加显著,而背景等无关信息得到了极大的削弱。因此,融合 RankSE 模块可以显著加强对水尺刻度此类小目标的特征信息提取能力。

各模型水位实际高程预测如图 14、15 所示,由图可知,本文水位监测方法在各类复杂恶劣场景下能有效识别出当前水位实际高程值。而且,在目标检测算法(YOLOv5)由于自身性能问题、复杂恶劣场景影响导致算法存在漏检的情况下,依然能准确推算出实际水位高

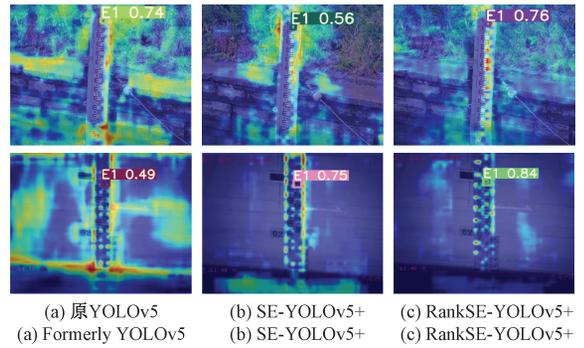


图 13 各模型检测热力图示例图

Fig. 13 Example of heat maps for each model detection

程值,证明了本文所提水位高程解算方案能极大稀释算法自身性能不佳或者各类复杂恶劣场景所带来的影响,使本方案无需检测出所有目标,其适用性更高,鲁棒性更强。并且,对比图 14、15 可知,相较于原 YOLOv5 算法,本文提出的 RankSE-改进 YOLOv5 算法输出锚框数量更多,说明本文所述方法在复杂恶劣场景下对水尺刻度识别能力更强,泛化性能更高。由此可见,本文所述水位检测方法可以准确、有效的完成在复杂恶劣场景下的水位监测任务。

以 \bar{P}_a 作为评价指标, \bar{P}_a 为前述水位检测准确性评价指标的均值,其中,结果如表 3 所示。由表 3 可知:1)原 YOLOv5、改进 YOLOv5、SE-YOLOv5+、RankSE-YOLOv5+(本文模型)的检测水位高程与真实水位高程的相对准确度 P_a 平均值分别为 90.1%、94.0%、96.1%、98.5%,融合的各方法均对水位检测识别的提高有明显的贡献;2)本文提出的算法模型在 \bar{P}_a 评价指标中获得 98.5% 的评分,较原 YOLOv5 提升为 8.4%,其准确程度可以满足实际工程应用,说明本文方法可以很好的完成在恶劣场景下的水位检测任务。

表 3 水位线检测数据统计

Table 3 Water level line detection data statistics A

(%)

场景	YOLOv5	改进 YOLOv5	SE-YOLOv5+	RankSE-YOLOv5+
	\bar{P}_a	\bar{P}_a	\bar{P}_a	\bar{P}_a
白天	93.2	97.1	97.9	99.5
黑夜	92.5	96.2	97.1	98.8
雨天	91.6	94.8	95.0	98.3
雾天	89.8	92.2	93.5	98.7
遮挡	90.5	92.6	96.5	97.6
漂浮物	87.2	91.9	96.4	98.1
灯光	85.9	93.2	96.3	98.4
平均值	90.1	94.0	96.1	98.5



图 14 YOLOv5 水位识别实例图

Fig. 14 YOLOv5 water level identification example diagram

4 恶劣场景下的水位检测实践

选取某水库为实践点。为便于分析本文方法准确性,水位图像采集点布置在某水尺区域。利用本文水位检测技术对该处 2022 年 7 月 22 日~7 月 30 日的水位进行监测。监测时每隔 0.5 h 取图一次,总共抓取图像 384 张。检测结果如图 16 所示,在整个监测期间没有出现错误识别结果,且检测水位高程值与人工观测值的最大误差仅为 0.11 m。这充分说明,本文所述的无水尺水位智

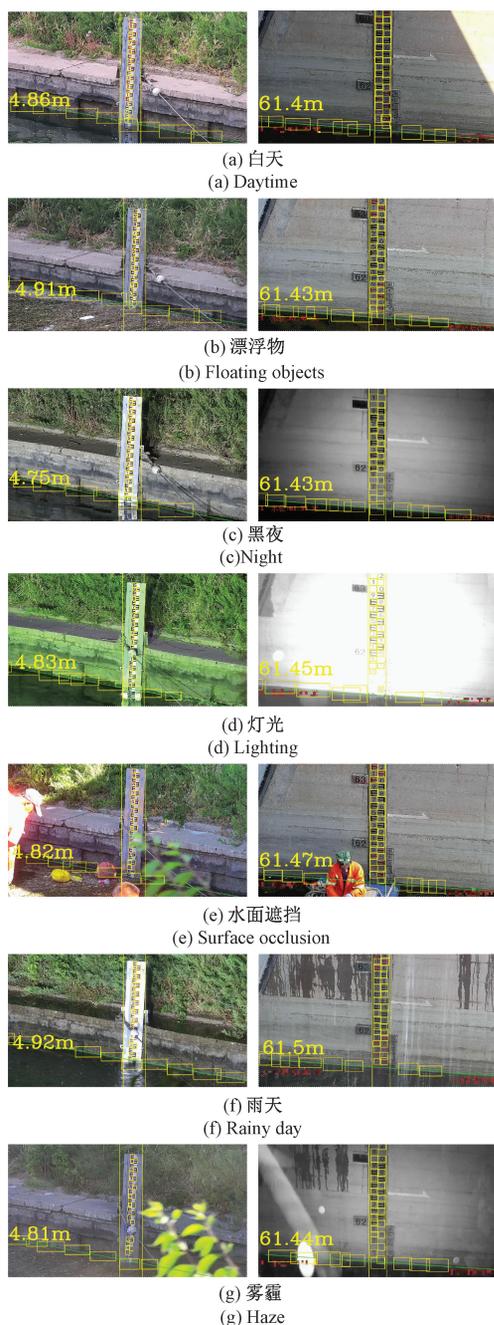


图 15 改进 YOLOv5 水位识别实例图

Fig. 15 Example diagram of improved YOLOv5 water level recognition

5 结 论

为解决复杂恶劣环境下的水位检测难题,提出一种融合改进 YOLOv5 与 RankSE 的无水尺水位智能检测

能检测方法在夜晚、雾霾、雨天、漂浮物遮挡、灯光等复杂恶劣环境下可以自动、准确识别出水位高程。

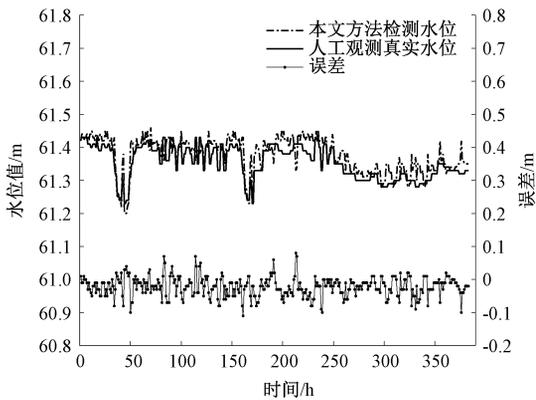


图 16 某水库水位整体监测结果

Fig. 16 Overall monitoring results of water level of a reservoir

方法。

对水尺刻度属于小目标,提出强化小尺度特征的多层级特征融合方法来改进 YOLOv5 算法,强化对小目标的捕捉能力;利用求秩运算代替原 SENet 的全局平均池化操作,提出 RankSENet 模块进一步提升对小目标的感知能力;利用改进 YOLOv5 算法捕捉特定尺寸的水位线锚框,通过拟合锚框中心点逼近真实的水位线;提出一种全新的水位高程解算方案,仅需利用部分水尺锚框信息即可获得准确的水位高程信息。

相关试验表明,本技术有效提升了复杂恶劣环境下水位检测的准确性:水位高程检测相对准确度为 98.3%,较原算法提高了 8.4%;本技术能在夜晚、雾霾、雨天、漂浮物遮挡、灯光阴影等复杂恶劣环境下自动、准确地检测出水位高程,且最大误差仅为 0.11 m。

参考文献

[1] DU W Y, CHEN N C, YUAN S. Flood events process detection and near real-time service based on sensor web[J]. Acta Geodaetica et Cartographica Sinica, 2020, 49(2): 191-201.

[2] 陈敏,胡春杰,阮聪,等. 基于 NB-IoT 的水雨情实时监测系统与设计[J]. 电子测量技术, 2020, 43(2): 133-138.

CHEN M, HU CH J, RUAN C, et al. Real-time monitoring system and design of rainwater condition based on NB-IoT [J]. Electronic Measurement Technology, 2020, 43(2): 133-138.

[3] 张衍,王剑平,张果,等. 图像法水位检测研究进展[J]. 电子测量技术, 2021, 44(13): 104-113.

ZHANG K, WANG J P, ZHANG G, et al. Research progress of water level detection by image method[J]. Electronic Measurement Technology, 2021, 44(13): 104-113.

[4] YAN T L, YI Ch L, JEN Y H. Automatic water-level detection using single-camera images with varied poses[J]. Measurement, 2018, 127: 167-174.

[5] IWAHAHI M, UDOMSIRI S. Water level detection from video with FIR filtering[C]. 2007 Proceedings of 16th International Conference on Computer Communications and Networks, IEEE, 2007: 826-831.

[6] BAO J, TAO Q CH, ZHANG P. An algorithm of water level detection based on image processing [J]. Water Resources and Power, 2015, 33(4): 96-99.

[7] 孙维亚,王达,许帅,等. 基于计算机视觉的水位检测算法[J]. 应用科学学报, 2022, 40(3): 434-447.

SUN W Y, WANG D, XU SH, et al. Water level detection algorithm based on computer vision[J]. Journal of Applied Sciences, 2022, 40(3): 434-447.

[8] 刘铭辉,车国霖,张衍,等. 一种不定长水尺图像水位测量方法[J]. 仪器仪表学报, 2021, 42(7): 250-258.

LIU M H, CHE G L, ZHANG K, et al. A water level measurement method for indefinite water gauge image[J]. Chinese Journal of Scientific Instrument, 2021, 42(7): 250-258.

[9] 曹文卓,王太固,徐兵,等. 基于语义分割的船闸水位检测方法研究[J]. 仪器仪表学报, 2023, 44(2): 238-247.

CAO W ZH, WANG T G, XU B, et al. Research on water level detection of ship lock based on semantic segmentation [J]. Chinese Journal of Scientific Instrument, 2023, 44(2): 238-247.

[10] 程淑红,赵小鹏,张仕军,等. 基于 U-net 的水位线检测[J]. 计量学报, 2019, 40(3): 361-366.

CHENG SH H, ZHAO K P, ZHANG SH J, et al. Water level detection based on U-net [J]. Acta Metrologica Sinica, 2019, 40(3): 361-366.

[11] 肖卓,陶青川,沈建军. 基于 SSD 目标检测的视频水位检测算法[J]. 现代计算机(专业版), 2019(9): 60-64.

XIAO ZH, TAO Q CH, SHEN J J. A video water-level recognition based on SSD object detect network [J]. Modern Computer (Professional Edition), 2019(9): 60-64.

[12] 廖赞,段清,刘俊晖,等. 基于深度学习的水位线检测算法[J]. 计算机应用, 2020, 40(S1): 274-278.

LIAO Y, DUAN Q, LIU J H, et al. Water line detection algorithm based on deep learning [J]. Journal of Computer Applications, 2020, 40(S1): 274-278.

[13] 王磊,陈明恩,孟凯凯,等. 基于深度学习算法的水位识别方法研究[J]. 水利信息化, 2020(3): 39-43, 56.

- WANG L, CHEN M EN, MENG K K, et al. Research on water level recognition method based on deep learning algorithm [J]. Water Conservancy Information Technology, 2020(3): 39-43, 56.
- [14] 夏平, 王峰, 雷帮军, 等. 基于超像素和图割算法的智能视觉水位识别[J]. 计算机仿真, 2021, 38(3): 430-436, 441.
- XIA P, WANG F, LEI B J, et al. Intelligent visual water level recognition algorithm based on super-pixel and graph cut segmentation[J]. Computer Simulation, 2021, 38(3): 430-436, 441.
- [15] 傅启凡, 路茗, 张质懿, 等. 基于语义分割的水位监测方法研究[J]. 激光与光电子学进展, 2022, 59(4): 89-100.
- FU Q F, LU M, ZHANG ZH Y, et al. Water level monitoring method based on semantic segmentation[J]. Laser Optoelectronics Progress, 2022, 59(4): 89-100.
- [16] 徐志康, 冯径, 张之正, 等. 一种结合卷积神经网络的水深自动测量方法[J]. 小型微型计算机系统, 2019, 40(4): 793-797.
- XU ZH K, FENG J, ZHANG ZH ZH, et al. Water level estimation combined with convolutional neural network[J]. Journal of Chinese Computer Systems, 2019, 40(4): 793-797.
- [17] 李欣宇, 孙传猛, 魏宇, 等. 融合 Transformer 与残差通道注意力的恶劣场景水位智能检测方法[J]. 电子测量与仪器学报, 2023, 37(1): 59-69.
- LI X Y, SUN CH M, WEI Y, et al. Water level intelligent detection method based on fuse Transformer residual channel attention mechanism in harsh environments[J]. Journal of Electronic Measurement and Instrumentation, 2019, 37(1): 59-69.
- [18] SAKAINO H. Camera-Vision-based water level estimation[J]. IEEE Sensors Journal, 2016, 16(21): 7564-7565.
- [19] VITRY M M D, 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.
- [20] 房爱印, 王永贤, 尹曦萌, 等. DetSegNet: 一种基于检测和分割的高精度水尺水位检测网络[J/OL]. 河海大学学报(自然科学版), 1-11 [2023-12-05].
- FANG AI Y, WANG Y X, YIN X M, et al. DetSegNet: A high-precision water ruler water level detection network based on detection and segmentation[J/OL] Journal of Hohai University (Natural Sciences), 1-11 [2023-12-

05].

- [21] 张荣星, 张果, 谢智峰, 等. 小区域引导下的水尺水位检测方法研究[J]. 云南大学学报(自然科学版), 2023, 45(3): 598-610.
- ZHANG R X, ZHANG G, XIE ZH F, et al. Research on water gauge water level detection method under small area guidance[J]. Journal of Yunnan University (Natural Science Edition), 2023, 45(3): 598-610.

作者简介



王宇, 2015 年于内蒙古科技大学获得学士学位, 2020 年于中北大学获得博士学位, 现为中北大学讲师, 主要研究方向为深度学习、机器视觉以及高压、高冲击、高温、高速、强电磁干扰等恶劣环境下各种瞬态过程的信息获取。

E-mail: 18235193412@163.com

Wang Yu received his B. Sc. degree from Inner Mongolia University of Science and Technology in 2015 and his doctorate degree from North University of China in 2020. Now he is a lecturer in North University of China. His main research interests include deep learning, computer vision, and information acquisition of various transient processes in harsh environments such as high voltage, high shock, high temperature, high speed, and strong electromagnetic interference.



魏宇, 2019 年获得佳木斯大学学士学位, 2023 年于中北大学获得硕士学位, 主要研究方向为深度学习与图像处理。

E-mail: 3069690@qq.com

Wei Yu received his B. Sc. degree from Jiamusi University in 2019, and M. Sc from North University of China in 2023. His main research interests include deep learning and image processing.



孙传猛(通信作者), 2010 年于重庆大学获得学士学位, 2015 年于重庆大学获得博士学位, 现为中北大学副教授, 主要研究方向为深度学习、机器视觉, 以及高压、高冲击、高温、高速、强电磁干扰等恶劣环境下各种瞬态过程的信息获取。

E-mail: sun_c_m@163.com

Sun Chuanmeng (Corresponding author) received his B. Sc. degree from Chongqing University in 2010 and Ph. D. degree from Chongqing University in 2015, respectively. Now he is an associate professor in North University of China. His main research interests include deep learning, computer vision, and information acquisition of various transient processes in harsh environments such as high voltage, high shock, high temperature, high speed, and strong electromagnetic interference.



武志博, 2011 年于中北大学获得学士学位, 2020 年于中北大学获得博士学位, 现为中北大学讲师, 主要研究方向为动态测试与智能仪器。

E-mail: wuzhibo@nuc.edu.cn

Wu Zhibo received his B. Sc. degree from North University of China in 2011 and Ph. D. degree from North University of China in 2020, respectively. Now he is a lecturer in North University of China. His main research interests include dynamic test and intelligent instrument.



李勇, 2007 年于重庆大学获得学士学位, 2013 年于博洛尼亚大学获得博士学位, 现为重庆大学副教授, 主要研究方向为结构工程与水力学。

E-mail: yong.li@cqu.edu.cn

Li Yong received his B. Sc. degree from Chongqing University in 2007 and Ph. D. degree from University of Bologna in 2013, respectively. Now he is an associate professor in Chongqing University. His main research interests include structural engineering and hydraulics.