

基于YOLOv5算法的水位智能监测系统

白海洋, 林俊宪, 陈家合, 张柳, 周璇滢

河海大学农业科学与工程学院, 江苏 南京

收稿日期: 2023年5月15日; 录用日期: 2023年6月14日; 发布日期: 2023年6月26日

摘要

近年来, 图像识别技术快速发展, 为了实现水位数据前端处理, 本论文提出了将YOLOv5算法用于前端处理水位监测数据的方案。本方案与传统方案最大的不同之处在于数据处理方式, 本方案直接将YOLOv5算法嵌入集成单片机中, 在前端进行数据转换, 最后将结果显示在终端, 传统方案需要将数据传输回服务器中。论文实验数据的采集, 考虑了不同测量地点和光照角度等因素, 具有真实性。最后将YOLOv5算法的实验数据与YOLOv4、hog + svm和Faster RCNN算法进行对比, 并以F1作为比较标准。结果显示: 在验证集下, YOLOv5算法的mAP值和准确率等指标均表现优异, F1值高于Faster RCNN将近4%, 高于HOG + SVM将近12%, 在GPU和CPU环境下, 单张图片检测时间分别为15 ms、125 ms, 说明YOLOv5算法在各种复杂环境下的均能适应图像识别任务, 具有高识别率和鲁棒性。

关键词

YOLOv5算法, 水位智能监测系统, 图像前端处理, 单片机

Intelligent Water Level Monitoring System Based on YOLOv5 Algorithm

Haiyang Bai, Junxian Lin, Jiahe Chen, Liu Zhang, Xuanying Zhou

College of Agricultural Science and Engineering, Hohai University, Nanjing Jiangsu

Received: May 15th, 2023; accepted: Jun. 14th, 2023; published: Jun. 26th, 2023

Abstract

In recent years, image recognition technology has developed rapidly, in order to achieve front-end processing of water level data, this paper mainly proposes a scheme of using YOLOv5 algorithm for front-end processing of water level monitoring data. The biggest difference between this

scheme and traditional schemes lies in the data processing method. This scheme directly embeds the YOLOv5 algorithm into the integrated microcontroller, performs data conversion in the front-end, and finally displays the results in the terminal. Traditional schemes require data transmission back to the server. The collection of experimental data in the paper takes into account factors such as different measurement locations and lighting angles, and has authenticity. Finally, compare the experimental data of YOLOv5 algorithm with YOLOv4, hog + SVM, and Faster RCNN algorithms, and use F1 as the comparison standard. The results show that under the validation set, the YOLOv5 algorithm performs excellently in terms of mAP value and accuracy, with an F1 value nearly 4% higher than Faster RCNN and nearly 12% higher than HOG + SVM. In GPU and CPU environments, the single image detection time is 15 ms and 125 ms, respectively. This indicates that the YOLOv5 algorithm can adapt to image recognition tasks in various complex environments, with high recognition rate and robustness.

Keywords

YOLOv5 Algorithm, Intelligent Water Level Monitoring System, Image Front-End Processing, Single Chip

Copyright © 2023 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

图像识别技术广泛应用于水文、安防、医疗、交通等领域,孙英豪等[1]研究了基于图像识别的无标尺水位测量技术,为河道和水库的水位实时测量提供了技术支持,杨宇等[2]引入目标追踪算法,实现了对特定动态目标的准确识别与追踪的功能。在本论文中,主要研究图像识别技术运用在水位测量中的运用。水位测量对于农田灌区和河流河道十分重要,它既能辅助实现水资源集约化,又能为防汛抗旱、水利工程的管理提供水情信息。

市面上已经陆续出现了以图像识别为核心的监测技术,成功实现了水位的自动读数,其工作原理主要是利用前端摄像头拍摄水尺照片,再将图像数据传回数据中心,但是,这个过程极其消耗数据流量。如果水位数据提前在前端就处理完毕,直接得到水位结果,就能极大地提升工作效率。

本论文研究的基于 YOLOv5 算法的水位智能监测系统,能弥补当前水位测量的缺陷。并且,在水位监测领域中,利用机器学习辅助预报水位的运用,已经有了诸多成功案例,张帆等[3]提出一种结合移动激光和视频图像处理技术的方法,去避免在测量中由于杂物和水渍的干扰问题,取得了不错的效果。李涛等[4]研究了人工智能技术在水利工程中的运用,并详细分析了人工智能技术的具体细节。

傅启凡等[5]提出了基于语义分割的视频水位监测方法,相对于传统监测方法,效果更佳。

YOLO 算法是基于单阶段检测的目标检测算法之一,它把目标检测等价转换为一个回归问题。首先,将需要检测的图片调整为 448×448 大小,整体输送到 CNN 网络中,仅仅经过一个神经网络,该图片被划分成 7×7 的网格。它不同于 RCNN 模型,RCNN 网络模型也就是通过 SVM [6]来进行分类操作。RCNN 模型需要生成候选区域并对该区域进行分类,它直接将边界框所属类别和位置直接在输出层输出,输出结果是 $7 \times 7 \times 30$ 的张量(tensor),30 代表维度,从结果中可以知道对象的可能位置和置信度,最后采用 NMS 算法[7]选择出最可能的结果。基于以上原理,YOLO 算法检测速度比传统算法更快,准确率也更高。

2. 目标识别算法

2.1. 目标对象分析

水位识别需要较高的精确度，所以，在采集水位测量图片时，考虑了不同时间段、距离、角度、环境等因素，采集不同场景的图片，保证数据多样性、真实性和严谨性。

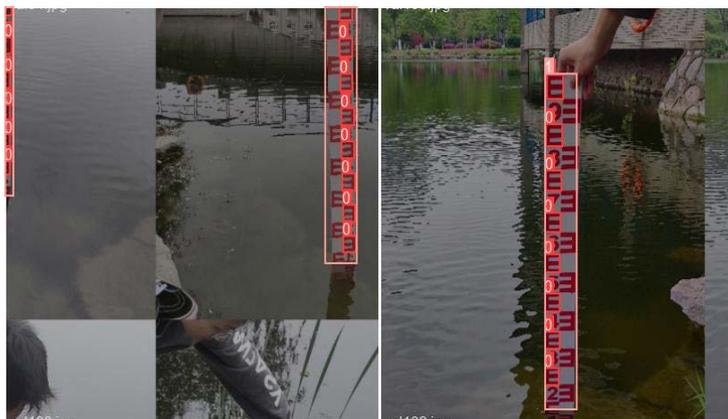


Figure 1. Real data acquisition and identification renderings

图 1. 实景采集数据和识别效果图

本论文本次采集图片 5000 余张，如图 1 即为实景采集部分图片，取样水域、取样距离、取样角度、取样时间和取样光线均不同，数据集庞大，本论文研究仅选取图部分代表性图片。

2.2. 算法简介

传统方法有 adaboost + harr、HOG + SVM 等，虽然性能稳定，但是检测准确率相对较低，传统机器学习算法 Two-stage，主要是 Faster R-CNN 和 Mask R-CNN [8]，它们对于小目标检测效果不佳，深度学习算法 one-stage，主要是 YOLO 算法，YOLO 算法从 YOLOv1 到 YOLOv5，不断克服以前算法的不足，检测速度和精度不断提升，YOLOv5 算法相对于 YOLOv4 算法，检测平均精度并没有提升，但是 YOLOv5 算法用户友好，均值权重文件更小，代码易读，模型训练和推理时间更快速。

2.3. 水位智能监测系统中 YOLOv5 算法的特点

2.3.1. 网络摄像头

网络摄像头连接树莓派单片机，树莓派单片机连接储能电池，储能电池连接太阳能电板，网络摄像头直接拍摄监测水尺。

2.3.2. 前端数据处理

利用单片机在前端集成将获取与处理数据合并，实现实时监测，确保了数据的真实性与可靠性。

2.3.3. 采用新型图像处理算法

采用 YOLO 识别算法，依靠大量素材进行机器学习与算法训练，以高效率得到准确的水位数据。

2.3.4. 信息转化

将图像信息转化为低数据量的文本，水位数据传输在水位监测技术中尤为重要，但传统的图像数据在通讯条件较差的农村地区有着巨大的局限性，项目将水位数据转变为低数据量的文本，具有更卓越的实际效果。

2.4. 水位智能监测系统介绍

如图 2 所示, 水位智能监测系统的各个部件从编号 1 到编号 9 开始, 编号 1 为风速风向测定仪, 它与单片机相连接, 用于实时风速监测拟合真实水位数据。编号 2 为太阳能电池板, 用于全套设备的发电。编号 3 为智能网络摄像头, 用于水位图像采集与网络传输。编号 4 为不锈钢杆件, 用于支撑整体结构, 固定并搭载太阳能电板、摄像头等设备, 其表面进行热镀锌处理, 防止受潮老化。编号 5 为树莓派单片机, 作为处理图像数据, 转化数据格式, 软件控制的信息终端。编号 6 为大容量电池, 储存太阳能, 维持设备 24 小时正常工作。编号 7 为高强度发光器, 用于夜间灯光照明。编号 8 为连通器挡板, 用于减小由于波浪影响导致的水位偏差, 保证水面稳定, 其表面布满渗水孔, 维持与外界水位一致。编号 9 为普通水尺, 是被观测对象, 其精度为 1 cm。其实景模型图如图 3 所示。

水位智能监测系统的工作模式分为拍摄阶段、数据处理阶段和维护阶段。

在拍摄阶段中, 智能网络摄像头 2 与集成单片机 5 相连, 终端控制系统利用无线传输模块远程打开设备电源, 智能网络摄像头 2 与集成单片机 5 开始工作, 集成单片机 5 控制智能网络摄像头 2 连续拍摄普通水尺 9 得到多张水位图像数据图片。

在处理阶段中, 集成单片机 5 利用嵌入的 YOLO 算法得到相应的图像模型, 而后利用数据转换算法得到对应水位数据, 并转化为文本数据封存。文本数据利用无线传输模块再次返回终端得到显示结果, 无线传输模块设置在集成单片机顶部, 且电脑终端与集成控制器之间通过无线传输模块利用中国移动传输。

在维护阶段中, 主要是从电能储备、风向监控、光照保障、防止水波和设备固定等方面去处理。电能储备: 设备初始时蓄电池 6 已由太阳能电池板 2 发电充满, 且电能足以支持装置日常使用, 蓄电池 6 和集成单片机 5 设置在电子装置盒内, 蓄电池 6 为可充电电池, 太阳能电池板 2 设置在不锈钢杆件 4 左边且与蓄电池 6 连接。风向监控: 风速风向测定仪 1 装配于智能网络摄像头 2 顶部, 用以监测实时风速拟合真实水位数据。光照保障: 高强度发光器 7 集成于智能网络摄像头 2 中, 用于夜间或灯光照明不良时刻的水尺拍摄。防止水波: 普通水尺 9 在防浪板 8 中, 防止水面起伏导致测量数据出现严重偏差。设备固定: 智能网络摄像头 2 嵌套在不锈钢杆件 4 上, 并与集成单片机 5 相连, 实时拍摄普通水尺 9 水位高度并传输至集成单片机 5 中。

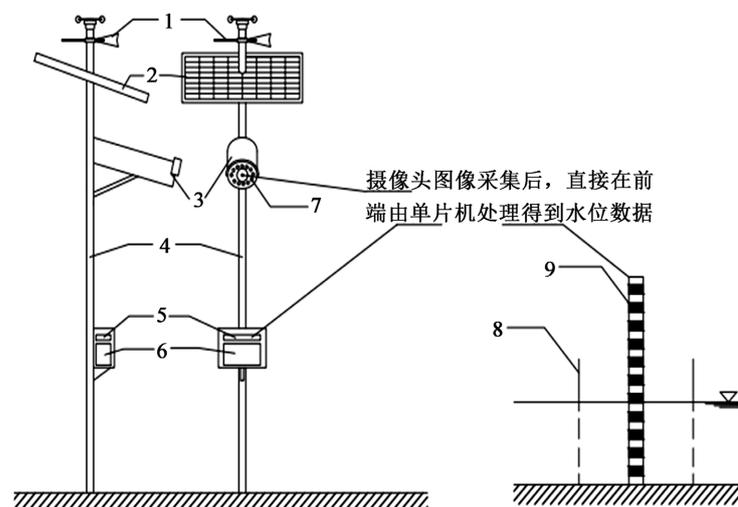


Figure 2. Reality structure diagram

图 2. 实景结构图



Figure 3. Real scene model
图 3. 实景模型图

2.5. YOLOv5 算法在水位智能监测系统中的应用步骤

2.4 小节已经对水位智能监测系统进行了流程化的描述，具体 YOLOv5 算法在该系统中的技术方案将在以下环节进行展开，本实施细仅为了说明细节，不是为了限制本论文的保护范围。研究步骤包括水尺图片采集、图像前端处理、水位测算、文本数据转换等。发明内容：提供基于 YOLO 算法的图像识别方法，通过对摄像头采集到的水尺图片进行图像处理。

2.5.1. 水尺图片采集

智能网络摄像头 2 与集成单片机 5 相连，终端控制系统利用无线传输模块远程打开设备电源，智能网络摄像头 2 与集成单片机 5 开始工作，集成单片机 5 控制智能网络摄像头 2 连续拍摄普通水尺 9 得到多张水位图像数据图片。

2.5.2. 图像前端处理

人工识别若干水尺单位刻度 $rect$ ，水尺与水面基线交界处 $rect-max$ 并进行图像标注。将图像标注的训练集与验证集导入 $yolov5s.yaml$ 进行机器学习，得到初始算法模型，然后，集成单片机 5 利用嵌入的 YOLO 算法得到相应的图像模型。

2.5.3. 水位测算

得到相应的图像模型之后，利用数据转换算法得到对应水位数据，并转化为文本数据封存。无线传输模块设置在集成单片机顶部，且电脑终端与集成控制器 13 之间通过无线传输模块利用中国移动传输，文本数据利用无线传输模块再次返回终端得到显示结果。

2.5.4. 文本数据转换

正常水尺识别分析。由摄像头距离水尺距离计算固定视距比例 J ，然后计算图上“E”的固定长度 L_0 ，由 $rect-max$ 长度计算水位数据 L 。

水尺结垢，遮挡条件下识别分析。由算法训练模型可得到水尺单个“E”图像长度 $L_i (i=1,2,3,4,\dots)$ ，“E”个数 n ，以及水尺露出水面图像长度 L_{all} ，舍去最大值与最小值，计算图像平均长度， $L_0 = \sum_{i=1}^n L_i / n$ ，计算图像长度与实际长度比例关系 $J: J = L_0 / 5$ ，据比例关系计算水尺露出水面实际长度 $L: L = (5L_{all} / L_0) + A + B + C$ 。A 为风速经验系数，B 为视距经验系数，C 为温度经验系数。

2.6. YOLO 损失函数

$$\begin{aligned} \text{LossFunction} = & \lambda_{coord} \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{obj} \left[(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2 \right] \\ & + \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{obj} \left[(\sqrt{w_i} - \sqrt{\hat{w}_i})^2 + (\sqrt{h_i} - \sqrt{\hat{h}_i})^2 \right] \\ & + \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{obj} \left[(C_i - \hat{C}_i)^2 \right] \\ & + \lambda_{coord} \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{obj} (C_i - \hat{C}_i)^2 \\ & + \sum_{i=0}^{S^2} 1_i^{obj} \sum_{C \in \text{classes}} (p_i(C) - \hat{p}_i(C))^2 \end{aligned}$$

x_i, y_i 在公式中代表的含义是：预测对象的 x 轴与 y 轴的直角坐标内的数值；

\hat{x}_i, \hat{y}_i 在公式中代表的含义是： x, y 在直角坐标系中的实际坐标数值；

w_i, h_i 在公式中代表的含义是：预测对象的宽度值和高度值；

\hat{w}_i, \hat{h}_i 在公式中代表的含义是：实际对象的宽度值和高度值；

C_i 为预测对象的类别， \hat{C}_i 为实际对象的类别；

公式第四、五排分别预测项目背景置信度和对象类别。

$P_i(C)$ 为预测对象的置信度， $\hat{P}_i(C)$ 为实际对象的置信度；

λ_{coord} 和 λ_{noobj} 是权值系数，目的是平衡各项的 Loss 比重。取值分别为 5 和 0.5。

B 和 S 分别表示单个矩形边界框和单个网格单元， obj 和 $noobj$ 分别代表存在和不存在目标对象。

2.7. 模型的训练和调整

数据集内有 520 张水位图像，5112 种测量实况。其中 380 张用来训练和验证模型的数量分别为 380, 140, 约为 3:1。

2.7.1. 试验运行平台

本文中所有测试和训练都在微型电脑树莓派上进行，8 GB 内存，配置 linux 系统，同时安装配置了 anaconda [9] 环境。训练好的算法模型加载进入树莓派，项目所有程序由 python 语言编写，Pytorch [10] 框架，使用树莓派定时控制摄像头拍照，然后识别图像数据直接得到水位文本数据，最后通过无线网络模块传回数据终端。

在 CPU 和 GPU [11] 上都需要进行模型的测试，训练时权值每更新一轮，就将 BN 进行正则化 [12]，每一层都加入丢弃层，丢弃比值 1:2，动量 0.95，权值衰减为 0.0005，起始学习率为 0.1%，迭代 5 千次后，衰减为原来的 0.1，并且在一开始设置 burn_in 参数，保证模型稳定性，其值为 1 000，实际计算如下：

$$\text{学习率} = \text{学习率} \times (\text{迭代次数} / \text{burn_in})^4。$$

2.7.2. 数据集预处理

用矩形框对图像进行人工标注之后，然后用目标对象的实际数据分别比上图像的宽度值、高度值，得出一组 0~1 范围分布的结果，方便更快更好地读取不同类型的图像，这组数据为：类别序列 index，目标中心坐标 x 和 y ，宽度高度 w, h ，边框右下角坐标 x_1, y_1 ，左上角坐标 x_2, y_2 。

$$x = \frac{x_1 + x_2}{2w}, y = \frac{y_1 + y_2}{2h}$$

$$w = \frac{x_1 - x_2}{w}, h = \frac{y_1 - y_2}{h}$$

在训练前，需要数据增强，微调色调、曝光和色量的变化范围，最终生成 61,200 张图片对象供训练使用。还需计算出锚点的预训练数值。

2.7.3. 模型的测试与评估

最终模型训练训练图像 61,200 张，耗时 4 h，Loss 变化图如图 4 所示。可以看出，随着迭代次数的增加，box_loss 和 obj_loss 的值无限趋于 0.02，cls_loss 无限趋于 0，准确率在不断提高。

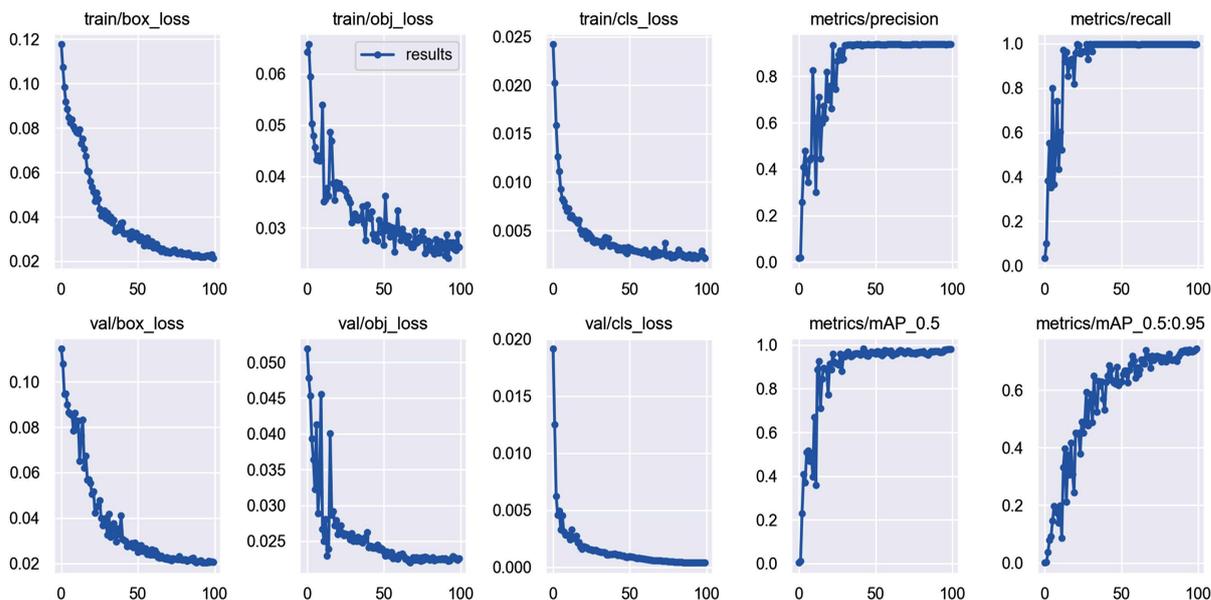


Figure 4. Diagram of the results file

图 4. Results 文件图表

在本论文中使用召回率 recall [9]，准确率 precision [13]，IOU 和 mAP [14]来评估训练好的模型。

$$\text{Precision} = \frac{TP}{TP + FP}$$

$$\text{Rcall} = \frac{TP}{TP + FN}$$

$$\text{mAP} = \frac{1}{C} \sum_{k=i}^N P(k)R(k)$$

- TP: 真正样本量;
- FP: 假正样本量;
- FN: 假负样本量;
- C: 类别数量;
- N: 引用阈值的量;
- K: 阈值;

$P(k)$: 准确率;

$R(k)$: 召回率。

通过 mAP 值找出性能最优的模型。然后调整阈值、召回率、准确率和 IOU 等值, 使之满足监测需求。

3. 模型试验结果分析

用 mAP 值去评估训练好的模型整体性能, 在 mAP 值最大的模型中, 比较不同阈值下召回率、准确率和 IOU [15]的改变量, 确定最优阈值, 然后对不同环境下的水位进行检测, 并与其他算法进行横向对比。

3.1. 最优模型的寻找

从众多模型中找出 mAP 最大的模型, 由图 4 可知, 稳定后的 metrics/mAP_0.5 高达 0.96, metrics/mAP_0.5: 0.95。如图 5 所示, PR_curve [16]曲线很稳定, 波动幅度很小, 进一步说明此次训练的效果很好。

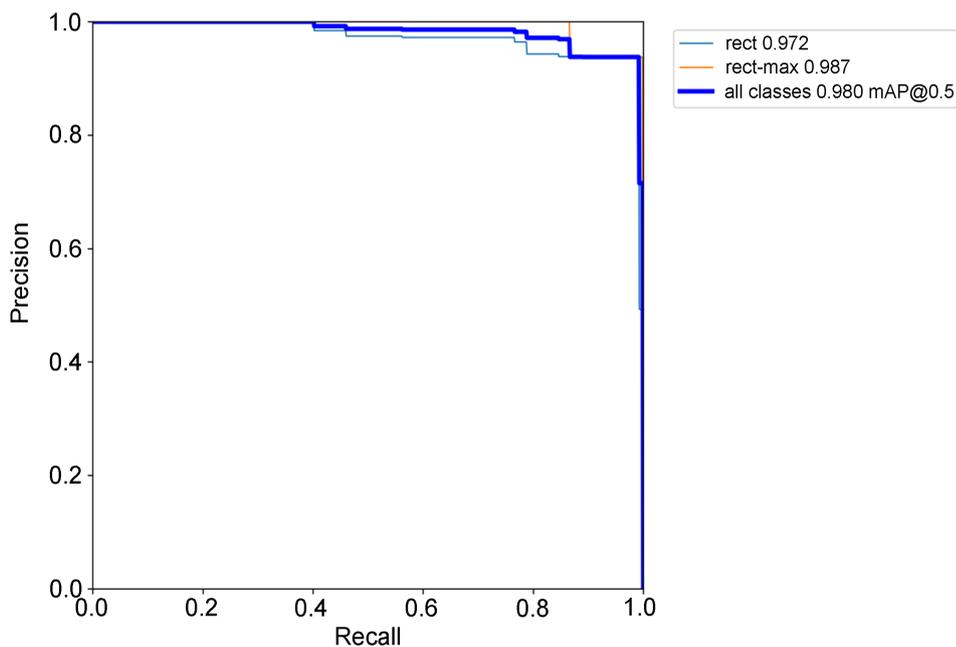


Figure 5. PR_curve

图 5. PR_curve

3.2. 类别阈值的选择

阈值取 0.5, 结合准确率、召回率、IOU 和 F1 指标。

$$F1 = \frac{2 \times \text{precision} \cdot \text{Recall}}{\text{precision} + \text{Recall}}$$

F1 是衡量指标, 可以看到 all classes 0.97 at 0.707, 也就是说, 所有类别的判断精度大约在 0.97 左右。rect 的性能略优于 rect-max, 但是两者结果无限逼近, rect 代表人工识别若干水尺单位刻度, rect-max 代表水尺与水面基线交界处。

图 6 即为 F1 结果图, 此时准确率和召回率均大于 0.97, F1 值也表现优异, 模型检验结果良好。

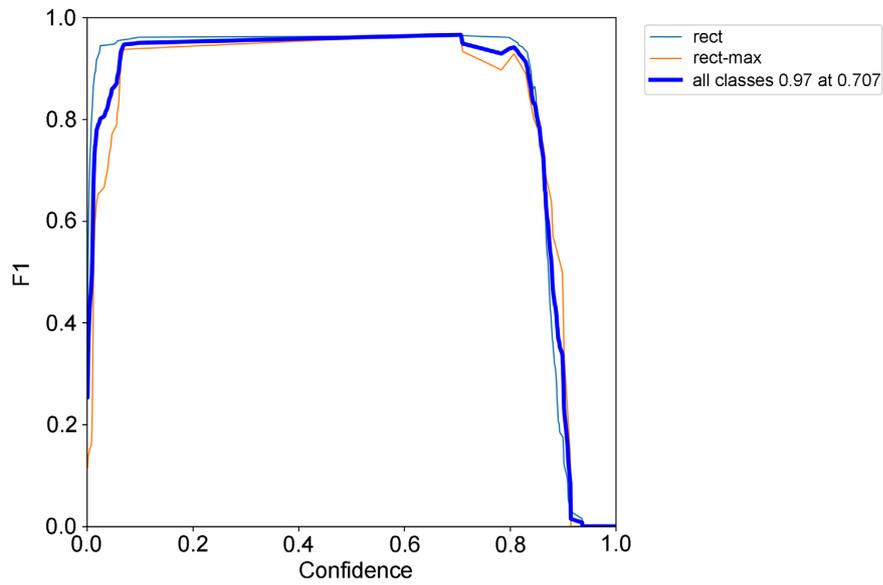


Figure 6. F1 result plot
图 6. F1 结果图

3.3. 实际效果的检验

3.3.1. 不同测量地点的对比试验

Table 1. Experimental results of four algorithms at different measurement sites

表 1. 四种算法对不同测量地点的实验结果

测量地点	算法	F1/%			
		第一次观测	第二次观测	第三次观测	均值
相对静止湖面	YOLOv4	99.12	99.01	98.58	98.90
	YOLOv5	98.72	98.98	97.99	98.56
	HOG + SVM	89.88	88.92	84.56	87.79
	Faster RCNN	96.02	95.89	95.24	95.72
缓慢流动水域	YOLOv4	99.01	98.06	98.15	98.41
	YOLOv5	98.04	98.02	97.12	97.73
	HOG + SVM	86.88	85.45	82.37	84.90
	Faster RCNN	94.08	93.88	94.98	94.31
中等流速水域	YOLOv4	99.01	98.06	98.15	98.41
	YOLOv5	98.04	98.02	97.12	97.73
	HOG + SVM	80.14	75.99	79.32	78.48
	Faster RCNN	92.01	91.89	93.91	92.60
平均值	YOLOv4	99.05	98.38	98.29	98.57
	YOLOv5	98.27	98.34	97.41	98.01
	HOG + SVM	85.63	83.45	82.08	83.72
	Faster RCNN	94.04	93.89	94.71	94.21

3.3.2. 不同光照角度的对比试验

Table 2. Experimental results of the four algorithms under different lighting conditions

表 2. 四种算法对不同光照条件下的实验结果

光照条件	算法	F1/%			
		第一次观测	第二次观测	第三次观测	均值
光照充足	YOLOv4	99.66	99.03	98.87	99.19
	YOLOv5	98.22	98.16	97.63	98.00
	HOG + SVM	87.72	88.12	86.23	87.36
	Faster RCNN	96.41	95.96	96.22	96.20
光照一般	YOLOv4	98.78	98.87	97.66	98.44
	YOLOv5	98.15	98.07	97.42	97.88
	HOG + SVM	84.88	87.33	87.85	86.69
	Faster RCNN	94.35	95.17	95.45	94.99
光照欠佳	YOLOv4	98.07	97.09	97.11	97.42
	YOLOv5	97.99	97.14	97.04	97.39
	HOG + SVM	76.18	73.97	78.07	76.07
	Faster RCNN	90.77	90.19	92.14	91.03
平均值	YOLOv4	98.84	98.33	97.88	98.35
	YOLOv5	98.12	97.79	97.36	97.76
	HOG + SVM	82.93	83.14	84.05	83.37
	Faster RCNN	93.84	93.77	94.60	94.07

3.3.3. 不同测量时间的对比试验

Table 3. Experimental results of four algorithms for different measurement times

表 3. 四种算法对不同测量时间的实验结果

测量时间	算法	F1/%			
		第一次观测	第二次观测	第三次观测	均值
北京时间 8 点	YOLOv4	99.42	99.41	98.99	99.27
	YOLOv5	98.14	98.08	97.99	98.07
	HOG + SVM	89.78	87.88	86.77	88.14
	Faster RCNN	96.44	95.99	96.74	96.39
北京时间 12 点	YOLOv4	99.49	99.52	98.97	99.33
	YOLOv5	98.47	98.48	98.97	98.64
	HOG + SVM	89.82	87.89	87.74	88.48
	Faster RCNN	96.47	96.97	96.71	96.72

Continued

北京时间 17 点	YOLOv4	98.11	99.02	98.46	98.53
	YOLOv5	98.02	98.72	98.77	98.50
	HOG + SVM	84.89	87.11	84.78	85.59
	Faster RCNN	95.42	94.99	96.22	95.54
北京时间 20 点	YOLOv4	97.19	98.77	97.42	97.79
	YOLOv5	97.01	98.02	97.79	97.61
	HOG + SVM	81.11	77.88	74.82	77.94
	Faster RCNN	91.49	90.91	93.42	91.94
平均值	YOLOv4	98.55	99.18	98.46	98.73
	YOLOv5	97.91	98.33	98.38	98.21
	HOG + SVM	86.40	85.19	83.53	85.04
	Faster RCNN	94.96	94.72	95.77	95.15

3.3.4. 不同天气状况的对比试验

Table 4. Experimental results of four algorithms on different weather conditions

表 4. 四种算法对不同天气状况的实验结果

天气状况	算法	F1/%			
		第一次观测	第二次观测	第三次观测	均值
晴	YOLOv4	99.48	99.49	98.92	99.30
	YOLOv5	98.87	98.74	97.85	98.49
	HOG + SVM	89.44	87.32	86.88	87.88
	Faster RCNN	96.48	95.94	96.79	96.40
阴	YOLOv4	98.49	99.01	98.97	98.82
	YOLOv5	98.19	98.03	98.92	98.38
	HOG + SVM	89.11	83.81	86.72	86.55
	Faster RCNN	94.47	95.97	96.78	95.74
小雨	YOLOv4	98.12	97.09	98.99	98.07
	YOLOv5	98.01	97.03	98.22	97.75
	HOG + SVM	85.17	83.12	81.47	83.25
	Faster RCNN	94.47	95.97	96.78	95.74
雾	YOLOv4	98.01	97.04	96.98	97.34
	YOLOv5	97.08	96.97	96.28	96.78
	HOG + SVM	75.17	73.14	71.48	73.26
	Faster RCNN	90.44	87.91	88.72	89.02

Continued

	YOLOv4	98.53	98.16	98.47	98.38
平均值	YOLOv5	98.04	97.69	97.82	97.85
	HOG + SVM	84.72	81.85	81.64	82.74
	Faster RCNN	93.97	93.95	94.77	94.23

表 1~4, 分别展示了 YOLOv4 [17]、YOLOv5 [18]、hog + svm [19]和 Faster RCNN [20]算法在不同工况下的表现, 数据显示, 在所有工况条件下, YOLOv5 算法和 YOLOv4 算法效果甚好, Faster RCNN 算法整体表现名列前茅, HOG + SVM 算法准确率最低, YOLOv5 算法平均精度略低于 YOLOv4, 但是 YOLOv5 算法推理时间更短, YOLOv5 算法检测 100 幅图像, 模型在 GPU 和 CPU 下分别花费了 1.5 s 和 12.5 s, 平均每幅图像检测时间为 15.00 ms 和 125.00 ms。由于水位在一定时间内, 处于稳定的高度, 变化频率不大, 所以能够满足实际要求。

4. 总结

当前水位图像识别技术, 利用前端摄像头拍摄照片, 再传回数据中心进行处理, 这个过程比较费时间和流量, 本文论述了基于 YOLOv5 算法的水位智能监测系统, 提供了在前端识别处理水位数据, 并将水位数据转化为文本进行传输, 极大的降低了传输成本。

本论文使用了 YOLOv5 算法, 其依靠大量素材进行机器学习与算法训练之后才得到, 除此之外, 还创造性地升级了实验设备。网络摄像头连接树莓派单片机, 就可以直接拍摄监测水尺。单片机的特点是, 体型小巧, 功能强大, 数据处理能力强。单片机将获取与处理数据进行合并, 确保了数据的真实性。在信息转化方面, 将图像信息转化为低数据量的文本, 降低了传输成本, 具有更卓越的实际效果。

为了证明 YOLOv5 算法在水位测量中的准确性, 在实验环节, 分别使用了 YOLOv4、hog + svm 和 Faster RCNN 三种算法进行结果对比, YOLOv5 算法的 mAP 值和准确率等指标均表现优异, F1 值高于 Faster RCNN 将近 4%, 高于 HOG + SVM 将近 12%, 在 GPU 和 CPU 环境下, 单张图片检测时间分别为 15 ms、125 ms。

通过四种算法在该项目中的量化表现, 可以得出, YOLOv5 算法在水位智能监测系统中的准确性能满足实际需求, 且运算速度最优, 具有高识别率和鲁棒性。

参考文献

- [1] 孙英豪, 丁勇, 李登华, 谢东辉. 基于图像识别的无标尺水位测量技术研究[J/OL]. 水利水运工程学报: 1-9. <http://kns.cnki.net/kcms/detail/32.1613.TV.20230227.1329.004.html>, 2023-02-28.
- [2] 杨宇, 刘宇红, 彭燕, 孙雨琛, 张荣芬. 基于机器视觉的目标识别追踪算法及系统设计[J]. 传感器与微系统, 2020, 39(4): 92-95+98.
- [3] 张帆, 靳晓妍. 基于视频图像的嵌入式水位监测方法[J]. 中国测试, 2022, 48(12): 140-145.
- [4] 李涛, 徐高, 梁思涵, 李英睿, 王敏, 李冰. 人工智能图像识别在水利行业的应用进展[J]. 人民黄河, 2022, 44(11): 163-168.
- [5] 傅启凡, 路茗, 张质懿, 纪立, 丁华泽. 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.
- [6] 周婷, 汪炎, 邹俊, 李辰, 崔玉环, 王笑宇, 谢传流, 夏萍. 基于 PCA 和 SVM 的遥感影像水体提取方法及验证[J]. 水资源保护, 2023, 39(2): 180-189.
- [7] 杨有为, 周刚. 面向自然场景文本检测的改进 NMS 算法[J]. 计算机工程与应用, 2022, 58(1): 204-208.
- [8] Bharati, P. and Pramanik, A. (2020) Deep Learning Techniques—R-CNN to Mask R-CNN: A Survey. In: Das, A., Nayak, J., Naik, B., Pati, S. and Pelusi, D., Eds., *Computational Intelligence in Pattern Recognition. Advances in Intelligent Systems and Computing*, Vol. 999, Springer, Singapore, 657-668. https://doi.org/10.1007/978-981-13-9042-5_56

- [9] Mikkelsen, L., Moesgaard, K., Hegnauer, M. and Lopez, A.D. (2020). ANACONDA: A New Tool to Improve Mortality and Cause of Death Data. *BMC Medicine*, **18**, Article No. 61. <https://doi.org/10.1186/s12916-020-01521-0>
- [10] Men, Q. and Shum, H.P.H. (2022) PyTorch-Based Implementation of Label-Aware Graph Representation for Multi-Class Trajectory Prediction. *Software Impacts*, **11**, Article ID: 100201. <https://doi.org/10.1016/j.simpa.2021.100201>
- [11] Li, F., Wang, Y., Jiang, J., *et al.* (2023) Heterogeneous Acceleration Algorithms for Shallow Cumulus Convection Scheme over GPU Clusters. *Future Generation Computer Systems*, **146**, 166-177. <https://doi.org/10.1016/j.future.2023.04.021>
- [12] 江铃焱, 郑艺峰, 陈澈, 李国和, 张文杰. 有监督深度学习的优化方法研究综述[J]. 中国图象图形学报, 2023, 28(4): 963-983.
- [13] 刘昱, 于坤霞, 李鹏, 李占斌, 张晓明. 黄河中游典型流域水文统计模型精度集合评价[J]. 人民黄河, 2023, 45(4): 20-27.
- [14] 周熙然, 李德仁, 薛勇, 汪云甲, 邵振峰. 地图图像智能识别与理解: 特征、方法与展望[J]. 武汉大学学报(信息科学版), 2022, 47(5): 641-650.
- [15] Wu, S., Yang, J., Wang, X. and Li, X. (2022) IoU-Balanced Loss Functions for Single-Stage Object Detection. *Pattern Recognition Letters*, **156**, 96-103. <https://doi.org/10.1016/j.patrec.2022.01.021>
- [16] Cao, Y., Chen, Z., Wen, T., *et al.* (2022) Rail Fastener Detection of Heavy Railway Based on Deep Learning. *High-Speed Railway*, **1**, 63-69. <https://doi.org/10.1016/j.hspr.2022.11.001>
- [17] Ouf, N.S. (2023) Leguminous Seeds Detection Based on Convolutional Neural Networks: Comparison of Faster R-CNN and YOLOv4 on a Small Custom Dataset. *Artificial Intelligence in Agriculture*, **8**, 30-45. <https://doi.org/10.1016/j.aiia.2023.03.002>
- [18] Yuan, J., Zheng, X., Peng, L., *et al.* (2023) Identification Method of Typical Defects in Transmission Lines Based on YOLOv5 Object Detection Algorithm. *Energy Reports*, **9**, 323-332. <https://doi.org/10.1016/j.egy.2023.04.078>
- [19] Sharma, A.K., Nandal, A., Dhaka, A., *et al.* (2023) HOG Transformation Based Feature Extraction Framework in Modified Resnet50 Model for Brain Tumor Detection. *Biomedical Signal Processing and Control*, **84**, Article ID: 104737. <https://doi.org/10.1016/j.bspc.2023.104737>
- [20] Bandong, S., Nazaruddin, Y.Y. and Joelianto, E. (2023) Faster RCNN Mixed-Integer Optimization with Weighted Cost Function for Container Detection in Port Automation. *Heliyon*, **9**, E13213. <https://doi.org/10.1016/j.heliyon.2023.e13213>