



(12)发明专利申请

(10)申请公布号 CN 110472636 A

(43)申请公布日 2019. 11. 19

(21)申请号 201910681936.8

(22)申请日 2019.07.26

(71)申请人 四创科技有限公司

地址 350012 福建省福州市晋安区新店镇秀山路245号4号楼6层608单元

(72)发明人 单森华 陈佳佳 吴闽帆 戴诗琪 林永清

(74)专利代理机构 福州元创专利商标代理有限公司 35100

代理人 陈明鑫 蔡学俊

(51) Int. Cl.

G06K 9/46(2006.01)

G06K 9/62(2006.01)

G06N 3/04(2006.01)

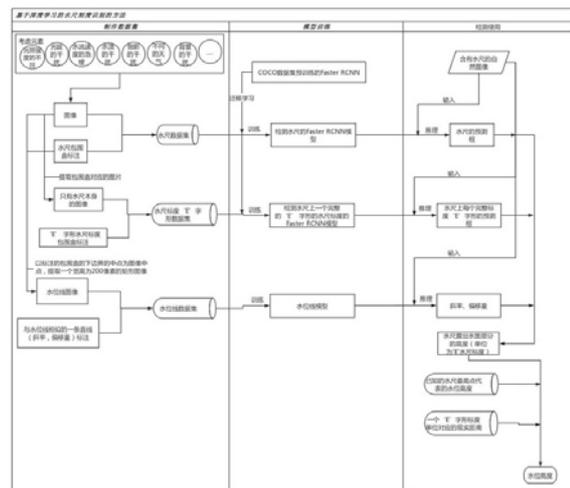
权利要求书2页 说明书5页 附图4页

(54)发明名称

基于深度学习的水尺E字形刻度识别方法

(57)摘要

本发明涉及一种基于深度学习的水尺E字形刻度识别方法,包括以下步骤:步骤S1:采集水尺图片,并进行标注处理,得到水尺数据集;步骤S2:提取水尺标度E字形数据集;步骤S3:提取水位线数据集;步骤S4:构建以ResNe101为特征提取器的Faster RCNN,并预训练;步骤S5:根据水尺数据集和水尺标度E字形数据集分别训练预训练后的Faster RCNN;步骤S6:构建水位线神经网络模型,并使用水位线数据集进行训练;步骤S7:将待测水尺图片依次输入第一Faster RCNN和第二Faster RCNN,得到水尺上每个完整标度E字形的预测框数据;步骤S8:将得到的水尺上每个完整标度E字形的预测框数据输入训练后的水位线神经网络模型,计算得到水位高度。



CN 110472636 A

1. 一种基于深度学习的水尺E字形刻度识别方法,其特征在于,包括以下步骤:

步骤S1:采集水尺图片,并进行标注处理,得到水尺数据集;

步骤S2:根据得到的水尺数据集,提取水尺标度E字形数据集;

步骤S3:根据得到的水尺数据集,提取水位线数据集;

步骤S4:构建以ResNe101为特征提取器的Faster RCNN,并预训练,得到预训练后的Faster RCNN;

步骤S5:根据水尺数据集和水尺标度E字形数据集分别训练预训练后的Faster RCNN,得到训练后的第一Faster RCNN和第二Faster RCNN;

步骤S6:构建水位线神经网络模型,并使用水位线数据集进行训练,得到训练后的水位线神经网络模型;

步骤S7:将待测水尺图片依次输入第一Faster RCNN和第二Faster RCNN,得到得到水尺上每个完整标度E字形的预测框数据;

步骤S8:根据得到的水尺上每个完整标度E字形的预测框数据和训练后的水位线神经网络模型,计算得到水位高度。

2. 根据权利要求1所述的基于深度学习的水尺E字形刻度识别方法,其特征在于:所述水尺图片标注的内容为包围整个水尺的包围盒。

3. 根据权利要求2所述的基于深度学习的水尺E字形刻度识别方法,其特征在于,所述步骤S2具体为:基于水尺数据集,利用水尺数据集标注的包围盒,将只包含水尺的图片提取出来,作为水尺标度E字形数据集。

4. 根据权利要求2所述的基于深度学习的水尺E字形刻度识别方法,其特征在于,所述步骤S3具体为:以水尺数据集为基础,利用水尺数据集标注的包围盒,以标注的包围盒的下边界的中点为图像中点,每张图片提取一个宽高为200像素的水位线图像,作为水位线数据集。

5. 根据权利要求1所述的基于深度学习的水尺E字形刻度识别方法,其特征在于:所述预训练采用COCO数据集对Faster RCNN进行预训练。

6. 根据权利要求1所述的基于深度学习的水尺E字形刻度识别方法,其特征在于,所述步骤S7具体为:

步骤S71:将待测水尺图片输入第一FasterRCNN,得到水尺的预测框 B_{sg} , $[x_{sg}, y_{sg}, w_{sg}, h_{sg}]$,其中 x_{sg} 、 y_{sg} 分别为预测框 B_{sg} 左上角在图像上的横、纵坐标, w_{sg} 、 h_{sg} 为水尺预测框的宽、高;

步骤S72:将到的水尺预测框 B_{sg} 对应的图片 g_1 单独提取出来,并输入第二Faster RCNN,得到水尺上每个完整标度E字形的预测框;检测到 k 个'E'字形预测框,在竖直方向上,最下面的'E'字形预测框为 B_{be} , $[x_{be}, y_{be}, w_{be}, h_{be}]$,其中 x_{be} 、 y_{be} 分别为预测框 B_{be} 左上角在图像上的横、纵坐标, w_{be} 、 h_{be} 为预测框的宽、高。

7. 根据权利要求6所述的基于深度学习的水尺E字形刻度识别方法,其特征在于:所述水位线神经网络模型以ResNet34为基础,其特征提取部分由5个卷积过程组成。

8. 根据权利要求7所述的基于深度学习的水尺E字形刻度识别方法,其特征在于,所述步骤S8具体为:

步骤S81: 在图像上, 以 $[x_{sg} + \frac{1}{2}w_{sg}, y_{sg} + h_{sg}]$ 为框的中心点, 取一个宽高为200像素的图像 g_2 , 输入至水位线网络中, 通过ResNet34特征提取器提取特征, 后将特征输入至全连接神经网络, 拟合斜率 a_{g2} 和相对于图像左下角的偏移量 b_{g2} , 从而得到输出一条水位线;

步骤S82: 根据水位线与水尺的预测框 B_{sg} , 得到该水位线在图 g_2 上的中点 p_{g2} , $(x_{sg} + \frac{1}{2}w_{sg}, y_{sg} + h_{sg} - 100 + 100 * a_{g2} + b_{g2})$;

步骤S83: 计算 p_{g2} 与预测框 B_{be} 下边界的中点 $(x_{be} + \frac{1}{2}w_{be}, y_{be} + h_{be})$ 的距离 $d = \sqrt{[(x_{sg} + \frac{1}{2}w_{sg}) - (x_{be} + \frac{1}{2}w_{be})]^2 + [(y_{be} + h_{be}) - (y_{sg} + h_{sg} - 100 + 100 * a_{g2} + b_{g2})]^2}$, 得到被水淹没部分的'E'字形标度, 露出水面的高度为 $\frac{d}{h_{be}}$ 个标度单位;

步骤S84: 基于预设水尺最高点代表的水位高度 H_{db} 、一个E字形标度单位对应的现实距离 d_{unit} , 得到实际水位高度为 $H_{db} - (k + \frac{d}{h_{be}}) * d_{unit}$ 。

基于深度学习的水尺E字形刻度识别方法

技术领域

[0001] 本发明涉及一种基于深度学习的水尺E字形刻度识别方法。

背景技术

[0002] 水位是反映水体水情最直观的因素,它的变化主要由于水体水量的增减变化引起的。水位是指自由水面相对于某一基面的高程,水面离河底的距离称水深。水位高于某个特定的高度时,便会有水涝、决堤等灾害。也就是说,这个高度是江河、湖泊、海洋、水库等水体水面高度的安全线,常被称作水位警戒线,不同江河、湖泊、海洋、水库的水位警戒线高度不一。精准、系统地感知水位变化,才能在应对水位变化的过程中趋利避害,采取有效措施调控水位。

[0003] 水尺是测量水位变化的重要工具,通过摄像头对水尺进行实时监测是现有监测水位的主要方法之一。现已存在的水尺刻度识别方法是通过传统的图像处理手段,与人工设计的图像特征进行比较,从而识别水尺刻度。此传统的水尺刻度识别方法在应用上具有一定的缺点:因是人工设计的图像特征,无法有效地适应自然环境的多样变化,如:水尺倒影过强,水尺上有泥垢等等。针对此方面存在的突出问题,提高水尺刻度识别的精准性,准确地感知水位的变化,是水利管理工作的必然要求。

发明内容

[0004] 有鉴于此,本发明的目的在于提供一种基于深度学习的水尺E字形刻度识别方法,以很好的克服传统积水检测方式的缺点,在多变的自然环境(光照、遮挡、扭曲等)下,对水尺刻度的识别依然具有较强的鲁棒性。

[0005] 为实现上述目的,本发明采用如下技术方案:

[0006] 一种基于深度学习的水尺E字形刻度识别方法,包括以下步骤:

[0007] 步骤S1:采集水尺图片,并进行标注处理,得到水尺数据集;

[0008] 步骤S2:根据得到的水尺数据集,提取水尺标度E字形数据集;

[0009] 步骤S3:根据得到的水尺数据集,提取水位线数据集;

[0010] 步骤S4:构建以ResNe101为特征提取器的Faster RCNN,并预训练,得到预训练后的Faster RCNN;

[0011] 步骤S5:根据水尺数据集和水尺标度E字形数据集分别训练预训练后的Faster RCNN,得到训练后的第一Faster RCNN和第二Faster RCNN;

[0012] 步骤S6:构建水位线神经网络模型,并使用水位线数据集进行训练,得到训练后的水位线神经网络模型;

[0013] 步骤S7:将待测水尺图片依次输入第一Faster RCNN和第二Faster RCNN,得到

[0014] 得到水尺上每个完整标度E字形的预测框数据;

[0015] 步骤S8:根据得到的水尺上每个完整标度E字形的预测框数据和训练后的水位线神经网络模型,计算得到水位高度。

[0016] 进一步的,所述水尺图片标注的内容为包围整个水尺的包围盒。

[0017] 进一步的,所述步骤S2具体为:基于水尺数据集,利用水尺数据集标注的包围盒,将只包含水尺的图片提取出来,作为水尺标度E 字形数据集。

[0018] 进一步的,所述步骤S3具体为:以水尺数据集为基础,利用水尺数据集标注的包围盒,以标注的包围盒的下边界的中点为图像中点,每张图片提取一个宽高为200像素的水位线图像,作为水位线数据集。

[0019] 进一步的,所述预训练采用COCO数据集对Faster RCNN进行预训练。

[0020] 进一步的,所述步骤S7具体为:

[0021] 步骤S71:将待测水尺图片输入第一Faster RCNN,得到水尺的预测框 B_{sg} , $[x_{sg}, y_{sg}, w_{sg}, h_{sg}]$,其中 x_{sg} 、 y_{sg} 分别为预测框 B_{sg} 左上角在图像上的横、纵坐标, w_{sg} 、 h_{sg} 为水尺预测框的宽、高;

[0022] 步骤S72:将到的水尺预测框 B_{sg} 对应的图片 g_1 单独提取出来,并输入第二Faster RCNN,得到水尺上每个完整标度E字形的预测框;检测到 k 个‘E’字形预测框,在竖直方向上,最下面的‘E’字形预测框为 B_{be} , $[x_{be}, y_{be}, w_{be}, h_{be}]$,其中 x_{be} 、 y_{be} 分别为预测框 B_{be} 左上角在图像上的横、纵坐标, w_{be} 、 h_{be} 为预测框的宽、高。

[0023] 进一步的,所述水位线神经网络模型以ResNet34为基础,其特征提取部分由5个卷积过程组成。

[0024] 进一步的,所述步骤S8具体为:

[0025] 步骤S81:在图像上,以 $[x_{sg} + \frac{1}{2}w_{sg}, y_{sg} + h_{sg}]$ 为框的中心点,取一个宽高为200像素的图像 g_2 ,输入至水位线网络中,通过ResNet34特征提取器提取特征,后将特征输入至全连接神经网络,拟合斜率 a_{g2} 和相对于图像左下角的偏移量 b_{g2} ,从而得到输出一条水位线;

[0026] 步骤S82:根据水位线与水尺的预测框 B_{sg} ,得到该水位线在图 g_2 上的中点 p_{g2} , $(x_{sg} + \frac{1}{2}w_{sg}, y_{sg} + h_{sg} - 100 + 100 * a_{g2} + b_{g2})$;

[0027] 步骤S83:计算 p_{g2} 与预测框 B_{be} 下边界的中点 $(x_{be} + \frac{1}{2}w_{be}, y_{be} + h_{be})$ 的距离

$d = \sqrt{[(x_{sg} + \frac{1}{2}w_{sg}) - (x_{be} + \frac{1}{2}w_{be})]^2 + [(y_{be} + h_{be}) - (y_{sg} + h_{sg} - 100 + 100 * a_{g2} + b_{g2})]^2}$,得到被水淹没

部分的‘E’字形标度,露出水面的高度为 $\frac{d}{h_{be}}$ 个标度单位;

[0028] 步骤S84:基于预设水尺最高点代表的水位高度 H_{db} 、一个E字形标度单位对应的现实距离 d_{unit} ,得到实际水位高度为 $H_{db} - (k + \frac{d}{h_{be}}) * d_{unit}$ 。

[0029] 本发明与现有技术相比具有以下有益效果:

[0030] 本发明可以很好的克服传统积水检测方式的缺点,在多变的自然环境(光照、遮挡、扭曲等)下,对水尺刻度的识别依然具有较强的鲁棒性。

附图说明

- [0031] 图1是本发明流程原理图；
[0032] 图2是本发明一实施例中的水尺数据图像；
[0033] 图3是本发明一实施例中的水尺图像提取的水尺预测框；
[0034] 图4是本发明一实施例中提取的E字形预测框；
[0035] 图5是本发明一实施例中得到的水位线图像；
[0036] 图6是本发明一实施例中一个深度残差方法块。

具体实施方式

- [0037] 下面结合附图及实施例对本发明做进一步说明。
- [0038] 请参照图1,本发明提供一种基于深度学习的水尺E字形刻度识别方法,包括以下步骤:
- [0039] 步骤S1:采集水尺图片,并进行标注处理,得到水尺数据集;
- [0040] 步骤S2:根据得到的水尺数据集,提取水尺标度E字形数据集;
- [0041] 步骤S3:根据得到的水尺数据集,提取水位线数据集;
- [0042] 步骤S4:构建以ResNe101为特征提取器的Faster RCNN,并采用 COCO数据集对Faster RCNN进行预训练,得到预训练后的Faster RCNN;
- [0043] 步骤S5:根据水尺数据集和水尺标度E字形数据集分别训练预训练后的Faster RCNN,得到训练后的第一Faster RCNN和第二Faster RCNN;
- [0044] 步骤S6:构建水位线神经网络模型,并使用水位线数据集进行训练,得到训练后的水位线神经网络模型;
- [0045] 步骤S7:将待测水尺图片依次输入第一Faster RCNN和第二Faster RCNN,得到
- [0046] 得到水尺上每个完整标度E字形的预测框数据;
- [0047] 步骤S8:将得到的水尺上每个完整标度E字形的预测框数据输入训练后的水位线神经网络模型,计算得到水位高度。
- [0048] 在本实施例中,所述水尺图片标注的内容为包围整个水尺的包围盒。数据集中的图片在收集过程中考虑了以下元素:①光斑的干扰;②光照强度不同的干扰;③水花的干扰;④背景的干扰;⑤水渍的干扰⑥倒影的干扰⑦不同天气条件的干扰等条件。
- [0049] 在本实施例中,所基于水尺数据集,利用水尺数据集标注的包围盒,将只包含水尺的图片提取出来,作为水尺标度E字形数据集。对数据集中的图片进行标注。标注的内容为:包围每个'E'字形水尺标度的包围盒。包围盒有且只有一个完整的'E'字形的水尺标度。
- [0050] 在本实施例中,所述步骤S3具体为:以水尺数据集为基础,利用水尺数据集标注的包围盒,以标注的包围盒的下边界的中点为图像中点,每张图片提取一个宽高为200像素的水位线图像,作为水位线数据集。对数据集中的图片进行标注。标注的内容为:与水位线相似的一条直线(斜率,偏移量)。
- [0051] 在本实施例中,所述步骤S7具体为:
- [0052] 步骤S71:将待测水尺图片输入第一Faster RCNN,得到水尺的预测框 B_{sg} , $[x_{sg}, y_{sg}, w_{sg}, h_{sg}]$,其中 x_{sg} 、 y_{sg} 分别为预测框 B_{sg} 左上角在图像上的横、纵坐标, w_{sg} 、 h_{sg} 为水尺预测框的宽、高;

[0053] 步骤S72:将到的水尺预测框 B_{sg} 对应的图片 g_1 单独提取出来,并输入第二Faster RCNN,得到水尺上每个完整标度E字形的预测框;检测到 k 个‘E’字形预测框,在竖直方向上,最下面的‘E’字形预测框为 B_{be} , $[x_{be}, y_{be}, w_{be}, h_{be}]$,其中 x_{be} 、 y_{be} 分别为预测框 B_{be} 左上角在图像上的横、纵坐标, w_{be} 、 h_{be} 为预测框的宽、高。

[0054] 在本实施例中的,所述水位线神经网络模型以ResNet34为基础,其特征提取部分由5个卷积过程组成。水位线神经网络模型如下:

[0055] 表1

| 网络层名 | 水位线网络结构 | |
|---------|---|-------------------------|
| Conv1 | 7×7, 64, stride 2 | |
| Conv2_x | 3×3 max pool, stride 2 | |
| | $\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 3$ | |
| Conv3_x | $\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 4$ | |
| Conv4_x | $\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 6$ | |
| Conv5_x | $\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 3$ | |
| FC | average pool, 1-d fc | average pool, 1-d fc |

[0057] 表格1中块的构造如图6所示,块后面的数字为块的堆栈数量。下采样由Conv3_1、Conv4_1和Conv5_1执行,步幅为2。

[0058] 如表1所示,水位线神经网络模型以ResNet34为基础,该网络的特征提取部分由5个卷积过程组成。

[0059] 其中所有卷积操作、池化操作的步长都为2。Conv_1中,以大小为7×7、通道数为64的卷积核进行卷积操作。Conv2_x中,首先进行3×3最大池化操作,后接上含有3个堆栈的 $\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix}$ 残差方法块进行卷积操作。残差方法块详情如图6所示:输入I依次进行大小为 3×3、通道数为64的卷积操作,relu非线性激活操作,大小为3×3、通道数为64的卷积操作得到M。再将I和M的指按通道对应相加后接上relu激活,得到输出的特征映射。Conv3_x、Conv4_x、Conv5_x 的实现和上面所述一致,只有残差方法块的参数和残差方法块的个数不

一样,这个可参照表格1。另,在Conv3_1、Conv4_1和Conv5_1 后有执行下采样操作,其步长为2。Conv3_1代表的是Conv3_x的第一个残差方法块。经过Conv1-Conv5_x特征提取步骤后,将得到图像的高级特征映射。

[0060] 在进行卷积操作之后,将得到的特征映射分别输入到2个分支。2个分支在结构、设计上一致:首先将输入的特征映射进行步长为2 的平均池化,后接上一个1维的全连接层,得到输出值。损失函数为网络输出与标注值的MSE(均方误差)。进行训练,2个分支最终将分别拟合输出偏移量与斜率。

[0061] 在本实施例中,所述步骤S8具体为:

[0062] 步骤S81:在图像上,以 $[x_{sg} + \frac{1}{2}w_{sg}, y_{sg} + h_{sg}]$ 为框的中心点,取一个宽高为200像素的图像 g_2 ,输入至水位线网络中,通过ResNet34特征提取器提取特征,后将特征输入至全连接神经网络,拟合斜率 a_{g2} 和相对于图像左下角的偏移量 b_{g2} ,从而得到输出一条水位线;

[0063] 步骤S82:根据水位线与水尺的预测框 B_{sg} ,得到该水位线在图 g_2 上的中点 p_{g2} ,

$$(x_{sg} + \frac{1}{2}w_{sg}, y_{sg} + h_{sg} - 100 + 100 * a_{g2} + b_{g2});$$

[0064] 步骤S73:计算 p_{g2} 与预测框 B_{be} 下边界的中点 $(x_{be} + \frac{1}{2}w_{be}, y_{be} + h_{be})$ 的距离

$$d = \sqrt{[(x_{sg} + \frac{1}{2}w_{sg}) - (x_{be} + \frac{1}{2}w_{be})]^2 + [(y_{be} + h_{be}) - (y_{sg} + h_{sg} - 100 + 100 * a_{g2} + b_{g2})]^2},$$

得到被水淹没部分的‘E’字形标度,露出水面的高度为 $\frac{d}{h_{be}}$ 个标度单位;

[0065] 步骤S74:基于预设水尺最高点代表的水位高度 H_{db} 、一个‘E’字形标度单位对应的现实距离 d_{unit} ,得到实际水位高度为 $H_{db} - (k + \frac{d}{h_{be}}) * d_{unit}$ 。

[0066] 以上所述仅为本发明的较佳实施例,凡依本发明申请专利范围所做的均等变化与修饰,皆应属本发明的涵盖范围。

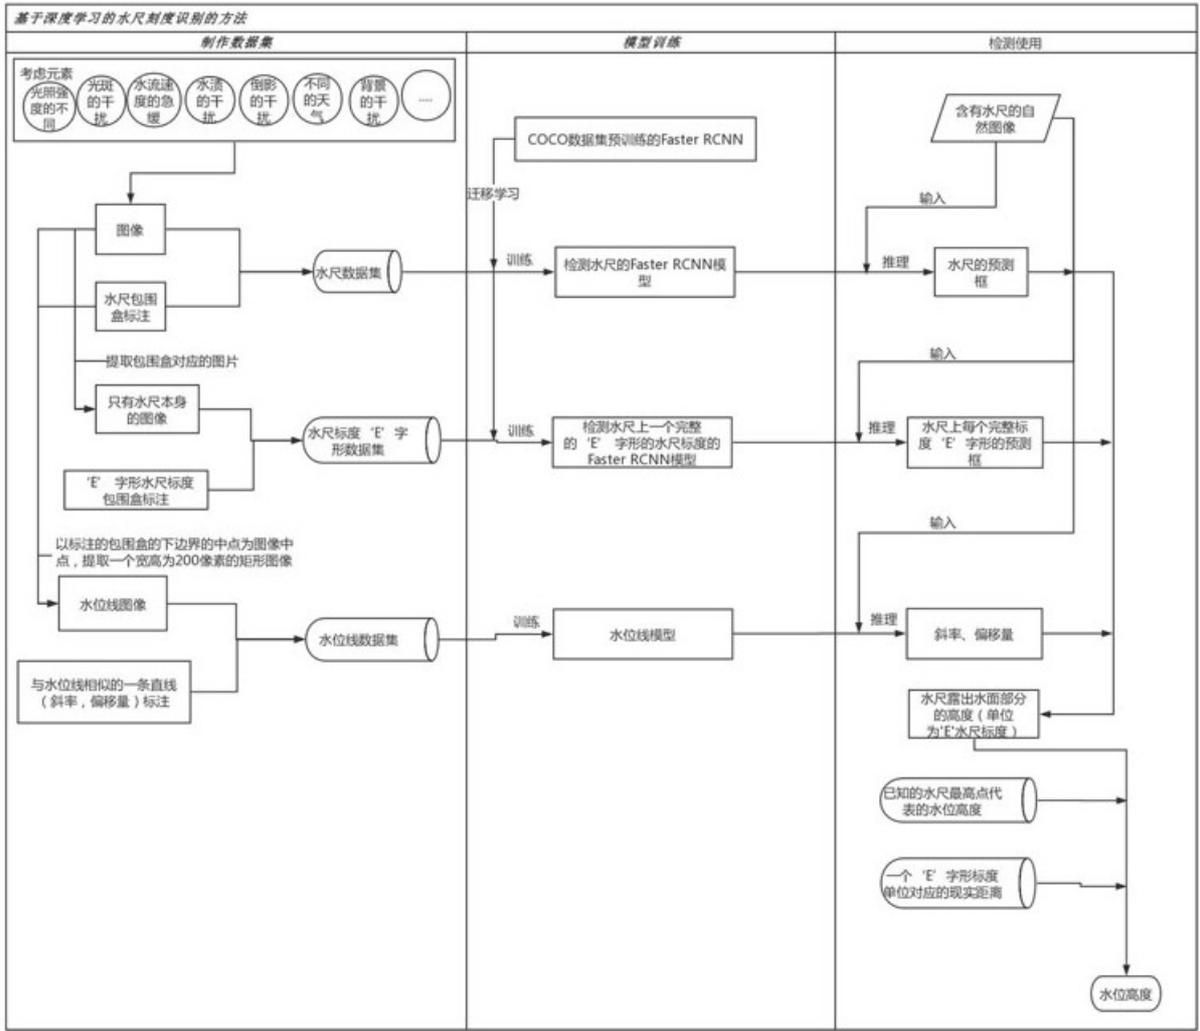


图1

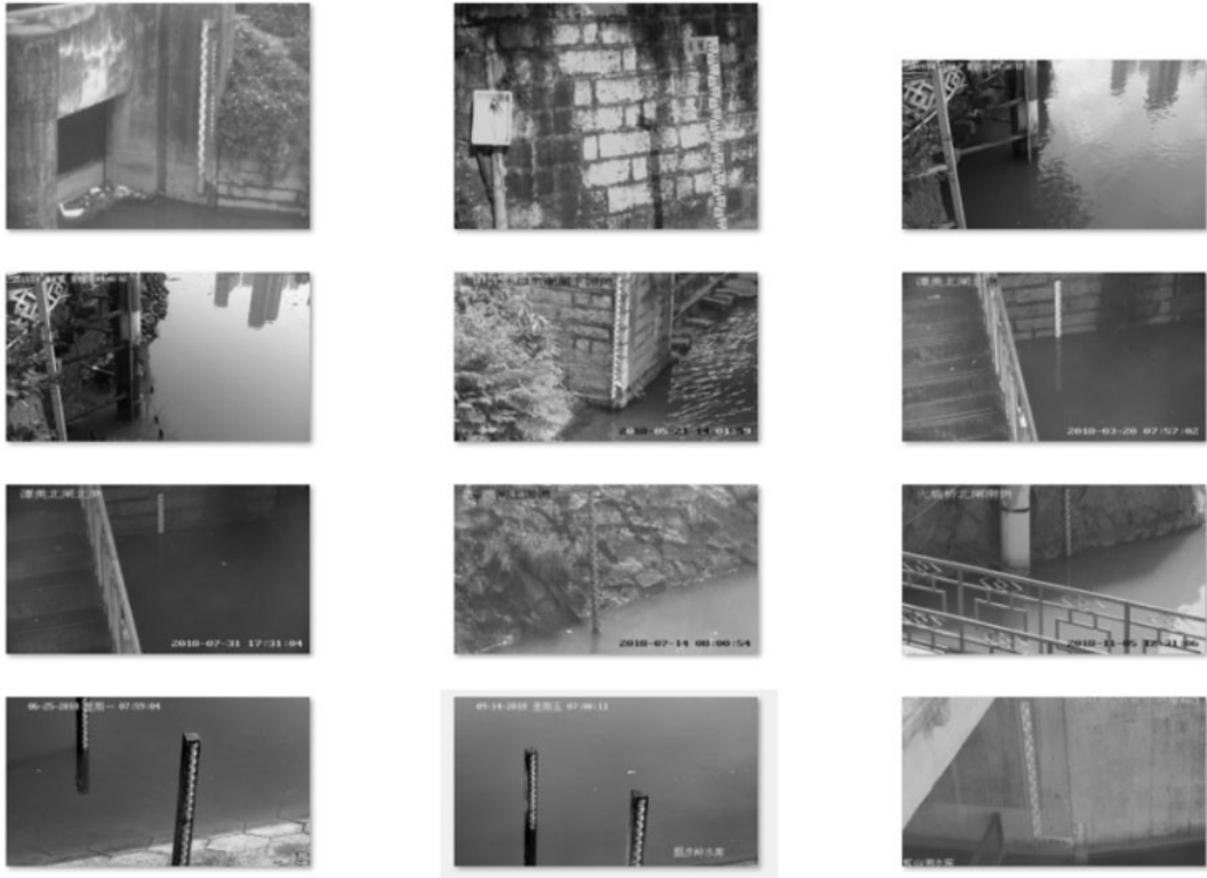


图2

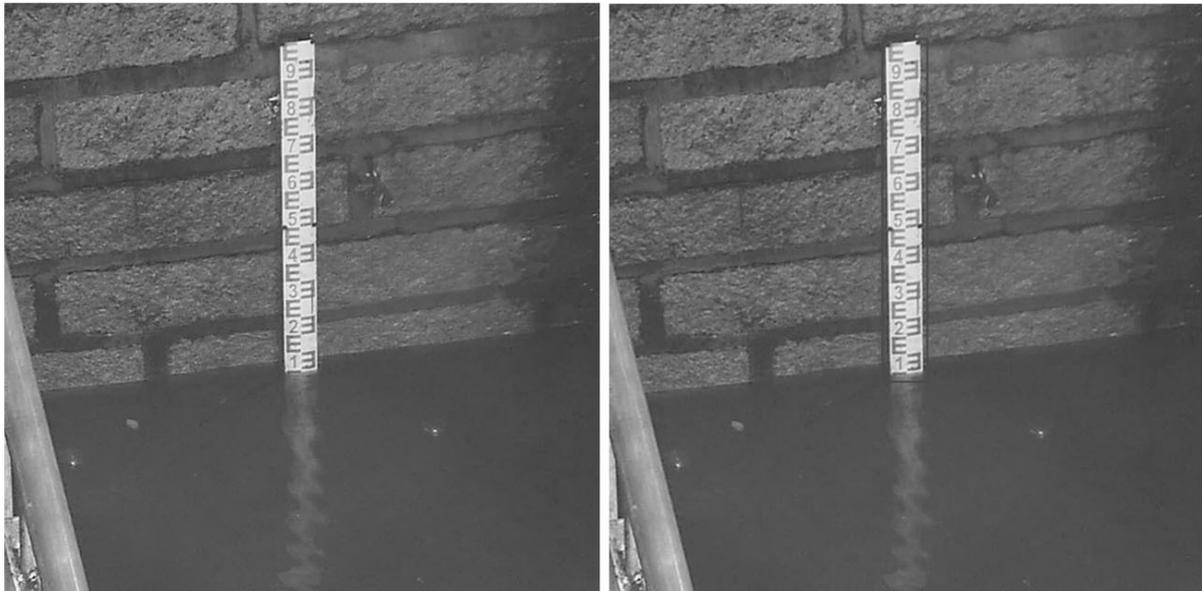


图3

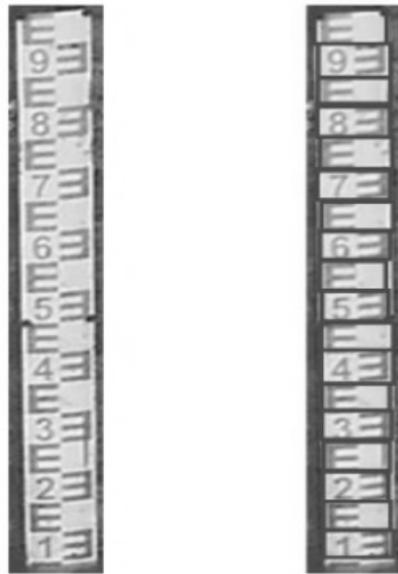


图4

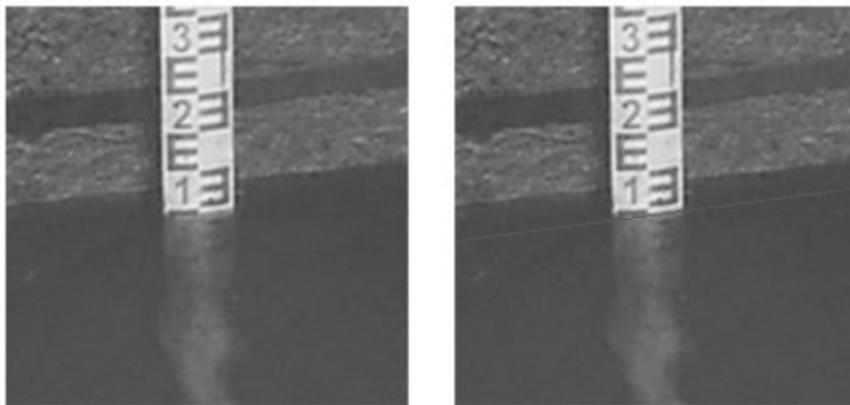


图5

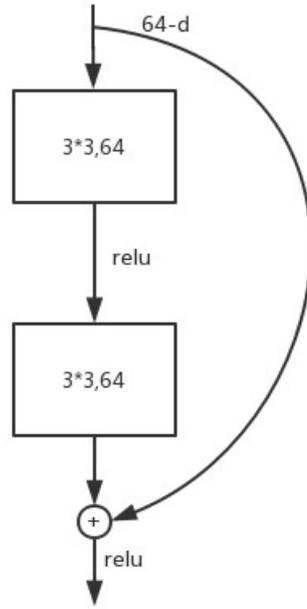


图6