
YOLOv5 by
0.2 Confidence Threshold
0.4 IoU Threshold
1.00x
Download on the
App Store
Coming Soon on
Google Play

YOLO v5

一、 yolo v5解读

（一）、几种数据增强方法
（二）、backbone网络细节
（三）、边框预测细节
（四）、正样本采样细节
（五）、损失计算细节

二、 yolo v5训练

（一）、打标自己的数据
（二）、训练自己的yolov5
（三）、保存模型，导出onnx，yolov5-lite

三、 yolo v5复现

（一）、backbone网络复现
（二）、损失计算复现
（三）、训练自己的数据
（四）、扩展yolov5支持关键点检测
（五）、扩展yolov5支持实例分割

一、 yolo v5解读

（一）、几种数据增强方法

rectangular: 同个batch里做rectangle宽高等比变换，加快训练

hsv_h: 0.015 # image HSV-Hue augmentation (fraction)，色调
hsv_s: 0.7 # image HSV-Saturation augmentation (fraction)，饱和度
hsv_v: 0.4 # image HSV-Value augmentation (fraction)，曝光度
degrees: 0.0 # image rotation (+/- deg)，旋转
translate: 0.1 # image translation (+/- fraction)，平移
scale: 0.5 # image scale (+/- gain)，缩放
shear: 0.0 # image shear (+/- deg)，错切/非垂直投影
perspective: 0.0 # image perspective (+/- fraction), range 0-0.001，透视变换
flipud: 0.0 # image flip up-down (probability)，上下翻转
fliplr: 0.5 # image flip left-right (probability)，左右翻转
mosaic: 1.0 # image mosaic (probability)，4图拼接
mixup: 0.0 # image mixup (probability)，图像互相融合
copy_paste: 0.0 # segment copy-paste (probability)，分割填补

最后box坐标转换，segment坐标转换

一、 yolo v5解读

（一）、几种数据增强方法

rectangular: 同个batch里做rectangle宽高等比变换，加快训练

原图: (375 × 500)

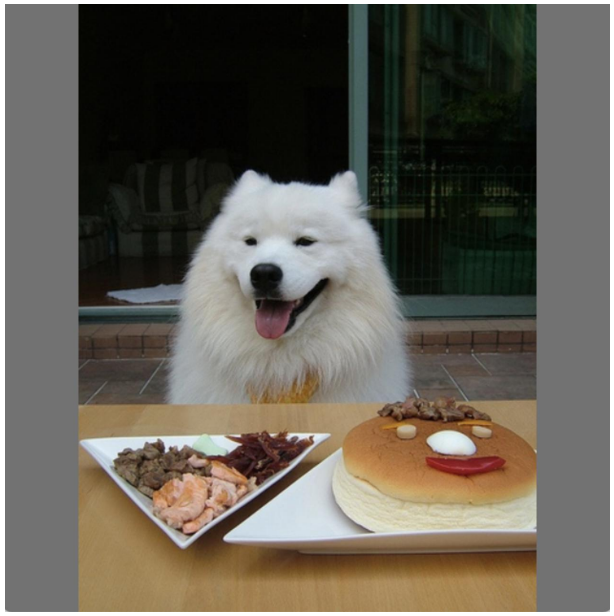

通常的resize: (640 × 640)

rectangular resize:
(520 × 640)

注意点：
yolov5里rect为True时，对每个batch都是单独一个input shape，
所以每个batch都会尽量的减少pad的黑边，减少计算量
参考：yolov5/utils/datasets.py/#L462-L484

一、 yolo v5解读

（一）、几种数据增强方法

rectangular: 同个batch里做rectangle宽高等比变换，加快训练

```
# Rectangular Training
if self.rect:
    # 所有训练图片的shape(w,h)
    s = self.shapes
    # 计算高宽比
    ar = s[:, 1] / s[:, 0]
    # 高宽比按小到大排序
    irect = ar.argsort()
    self.img_files = [self.img_files[i] for i in irect]
    self.label_files = [self.label_files[i] for i in irect]
    self.labels = [self.labels[i] for i in irect]
    self.shapes = s[irect]  # wh
    ar = ar[irect]

    # Set training image shapes
    shapes = [[1, 1]] * nb
    for i in range(nb):
        # 同个batch的图片拿出来
        ari = ar[bi == i]
        mini, maxi = ari.min(), ari.max()
        if maxi < 1:
            # 同个batch里最大的高宽比小于1，将batch里的所有图片处理成[640*maxi, 640*1]，注意这里是[h,w]格式
            shapes[i] = [maxi, 1]
        elif mini > 1:
            # 同个batch里最小的高宽比大于1，将batch里的所有图片处理成[640*1, 640*(1/mini)]，注意这里是[h,w]格式
            shapes[i] = [1, 1 / mini]
    self.batch_shapes = np.ceil(np.array(shapes) * img_size / stride + pad).astype(np.int) * stride
```

一、 yolo v5解读

（一）、几种数据增强方法

hsv_h: 0.015 # image HSV-Hue augmentation (fraction)，色调
hsv_s: 0.7 # image HSV-Saturation augmentation (fraction)，饱和度
hsv_v: 0.4 # image HSV-Value augmentation (fraction)，曝光度

原图

色调调整

饱和度调整

曝光调整

综合调整

yolov5 opencv, hsv变换：

```
r = np.random.uniform(-1, 1, 3) * [hgain, sgain, vgain] + 1
hue, sat, val = cv2.split(cv2.cvtColor(im, cv2.COLOR_BGR2HSV))
dtype = im.dtype
x = np.arange(0, 256, dtype=r.dtype)
lut_hue = ((x * r[0]) % 180).astype(dtype)
lut_sat = np.clip(x * r[1], 0, 255).astype(dtype)
lut_val = np.clip(x * r[2], 0, 255).astype(dtype)
im_hsv = cv2.merge((cv2.LUT(hue, lut_hue), cv2.LUT(sat, lut_sat), cv2.LUT(val, lut_val)))
cv2.cvtColor(im_hsv, cv2.COLOR_HSV2BGR, dst=im)
```

一、 yolo v5解读

（一）、几种数据增强方法

degrees: 0.0 # image rotation (+/- deg)，旋转
scale: 0.5 # image scale (+/- gain)，缩放

$$\times \begin{bmatrix} 0.99640066 & -0.31456676 & 0. \\ 0.31456676 & 0.99640066 & 0. \\ 0. & 0. & 1. \end{bmatrix} =$$

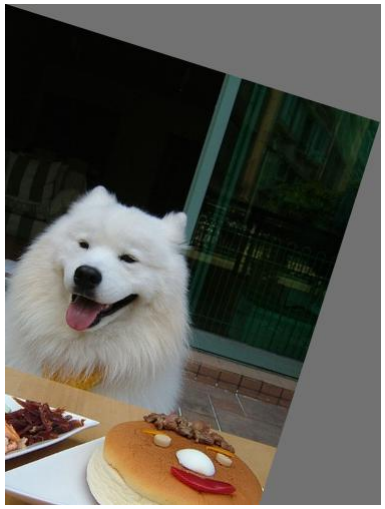

$$\texttt{dst}\left(\frac{M_{11}x + M_{12}y + M_{13}}{M_{31}x + M_{32}y + M_{33}}, \cdot \frac{M_{21}x + M_{22}y + M_{23}}{M_{31}x + M_{32}y + M_{33}}\right) = \texttt{src}(x, y)$$

注意点：
1. src为左边图片, dst为右边旋转缩放变换后的图片，xy为横纵坐标，M为旋转缩放矩阵
2. 旋转参数主要是M[0,1], M[1, 0]起作用, 且M[0,1], M[1, 0]互为相反数
3. 缩放参数主要是M[0,0], M[1,1]起作用
详见：yolov5/utils/argumentations.py/#L143-L149

一、 yolo v5解读

（一）、几种数据增强方法

degrees: 0.0 # image rotation (+/- deg)，旋转
scale: 0.5 # image scale (+/- gain)，缩放

```python
def rotate_scale(im, degrees, scale):
    """旋转缩放"""
    im_copy = im.copy()
    h,w,_ = im.shape
    # Rotation and Scale matrix
    RS = np.eye(3)
    angle = random.uniform(-degrees, degrees)
    random_scale = random.uniform(1 - scale, 1 + scale)
    RS[:2] = cv2.getRotationMatrix2D(angle=angle, center=(0, 0), scale=random_scale)
    new_im = cv2.warpPerspective(im_copy, RS, dsize=(w, h), borderValue=(114, 114, 114))
    return new_im
```

yolov5中OpenCV实现旋转缩放

一、 yolo v5解读

（一）、几种数据增强方法

translate: 0.1 # image translation (+/- fraction)， 平移

$$\times \begin{bmatrix} 1. & 0. & 95. \\ 0. & 1. & 127. \\ 0. & 0. & 1. \end{bmatrix} =$$

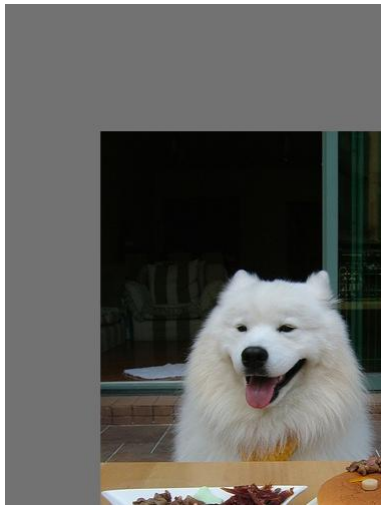

$$\texttt{dst}\left(\frac{M_{11}x + M_{12}y + M_{13}}{M_{31}x + M_{32}y + M_{33}}, \cdot \frac{M_{21}x + M_{22}y + M_{23}}{M_{31}x + M_{32}y + M_{33}}\right) = \texttt{src}(x, y)$$

注意点：

1. src为左边图片, dst为右边旋转缩放变换后的图片， xy为横纵坐标， M为平移矩阵
2. x轴平移参数主要是M[0,2]起作用
3. y轴平移参数主要是M[1,2]起作用

详见：yolov5/utils/argumentations.py/#L156-L159

一、 yolo v5解读

（一）、几种数据增强方法

translate: 0.1 # image translation (+/- fraction)， 平移

```python
def translate(im, t=0.1):
    """平移"""
    im_copy = im.copy()
    h, w, _ = im.shape
    T = np.eye(3)
    T[0, 2] = random.uniform(0.5 - t, 0.5 + t) * w * 0.5
    T[1, 2] = random.uniform(0.5 - t, 0.5 + t) * h * 0.5
    new_t = cv2.warpPerspective(im_copy, T, dsize=(w, h), borderValue=(114, 114, 114))
    return new_t
```

yolov5中OpenCV实现平移

一、 yolo v5解读

（一）、几种数据增强方法

shear: 0.0 # image shear (+/- deg)，错切/非垂直投影

$$\times \begin{bmatrix} 1. & 0.12266402 & 0. \\ -0.76603159 & 1. & 0. \\ 0. & 0. & 1. \end{bmatrix} =$$

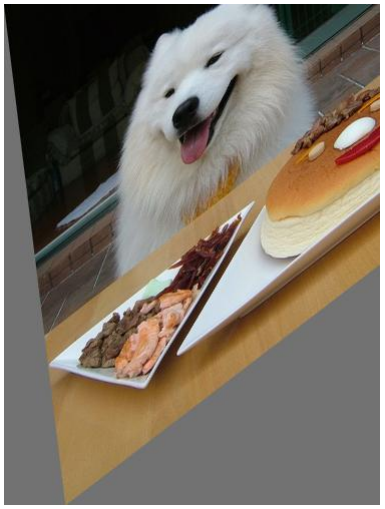

$$\texttt{dst}\left(\frac{M_{11}x + M_{12}y + M_{13}}{M_{31}x + M_{32}y + M_{33}}, \cdot \frac{M_{21}x + M_{22}y + M_{23}}{M_{31}x + M_{32}y + M_{33}}\right) = \texttt{src}(x, y)$$

注意点：

1. 错切的类似于固定图片一边，对另外平行一边施加一个推力形成的变形
2. src为左边图片, dst为右边错切变换后的图片，xy为横纵坐标，M为错切矩阵
3. 错切参数主要是M[0,1], M[1, 0]起作用

详见：yolov5/utils/argumentations.py/#L152-L154

一、 yolo v5解读

（一）、几种数据增强方法

shear: 0.0 # image shear (+/- deg)，错切/非垂直投影

```python
def shear(im, degree):
    """错切"""
    im_copy = im.copy()
    h, w, _ = im.shape
    S = np.eye(3)
    # 错切和旋转都是通过[0,1],[1,0]两个参数控制，不同的是旋转两个参数互为相反数，错切则不然
    S[0, 1] = math.tan(random.uniform(-degree, degree) * math.pi / 180)
    S[1, 0] = math.tan(random.uniform(-degree, degree) * math.pi / 180)
    print(S)
    new_im = cv2.warpPerspective(im_copy, S, dsize=(w, h), borderValue=(114, 114, 114))
    return new_im
```

yolov5 错切实现

一、 yolo v5解读

（一）、几种数据增强方法

perspective: 0.0 # image perspective (+/- fraction), range 0-0.001， 透视变换

$$\times \begin{bmatrix} 1. & 0. & 0. \\ 0. & 1. & 0. \\ 0.000752396836 & 0.0000695 & 1. \end{bmatrix} =$$

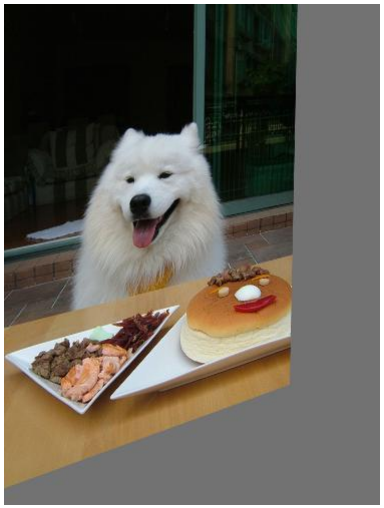

$$\texttt{dst}\left(\frac{M_{11}x + M_{12}y + M_{13}}{M_{31}x + M_{32}y + M_{33}}, \cdot \frac{M_{21}x + M_{22}y + M_{23}}{M_{31}x + M_{32}y + M_{33}}\right) = \texttt{src}(x, y)$$

注意点：

1. src为左边图片, dst为右边透视变换后的图片， xy为横纵坐标， M为变换矩阵
2. 变换参数主要是M[2,0], M[2,1]起作用

一、 yolo v5解读

（一）、几种数据增强方法

perspective: 0.0 # image perspective (+/- fraction), range 0-0.001， 透视变换

```python
def perspective(im, p=0.001):
    """透视变换"""
    h, w, c = im.shape
    im_copy = im.copy()
    P = np.eye(3)
    P[2, 0] = random.uniform(-p, p)
    P[2, 1] = random.uniform(-p, p)
    im_copy = cv2.warpPerspective(im_copy, P, dsize=(w, h), borderValue=(114, 114, 114))
    return im_copy
```

yolov5中OpenCV实现透视变换

```python
def perspective(im, p=0.001):
    """透视变换"""
    h, w, c = im.shape
    P = np.eye(3)
    P[2, 0] = random.uniform(-p, p)
    P[2, 1] = random.uniform(-p, p)
    new_im = np.zeros_like(im) + 114.
    for row in range(h):
        for col in range(w):
            col_new = (P[0, 0] * col + P[0, 1] * row + P[0, 2]) / (P[2, 0] * col + P[2, 1] * row + P[2, 2])
            row_new = (P[1, 0] * col + P[1, 1] * row + P[1, 2]) / (P[2, 0] * col + P[2, 1] * row + P[2, 2])
            new_im[int(row_new), int(col_new), :] = im[row, col, :]

    new_im = np.array(new_im, dtype=np.uint8)
    return new_im
```

根据变换公式实现透视变换

一、 yolo v5解读

（一）、几种数据增强方法

flipud: 0.0 # image flip up-down (probability)，上下翻转
fliplr: 0.5 # image flip left-right (probability)，左右翻转

原图

上下翻转

左右翻转

yolov5 翻转变换：

```
# 上下翻转
im_up = np.flipud(im)
# box坐标y翻转
labels[:, 2] = 1 - labels[:, 2]
```

```
# 左右翻转
im_right = np.fliplr(im)
# box坐标x翻转
labels[:, 1] = 1 - labels[:, 1]
```

一、 yolo v5解读

（一）、几种数据增强方法

mosaic: 1.0 # image mosaic (probability)， 4图拼接

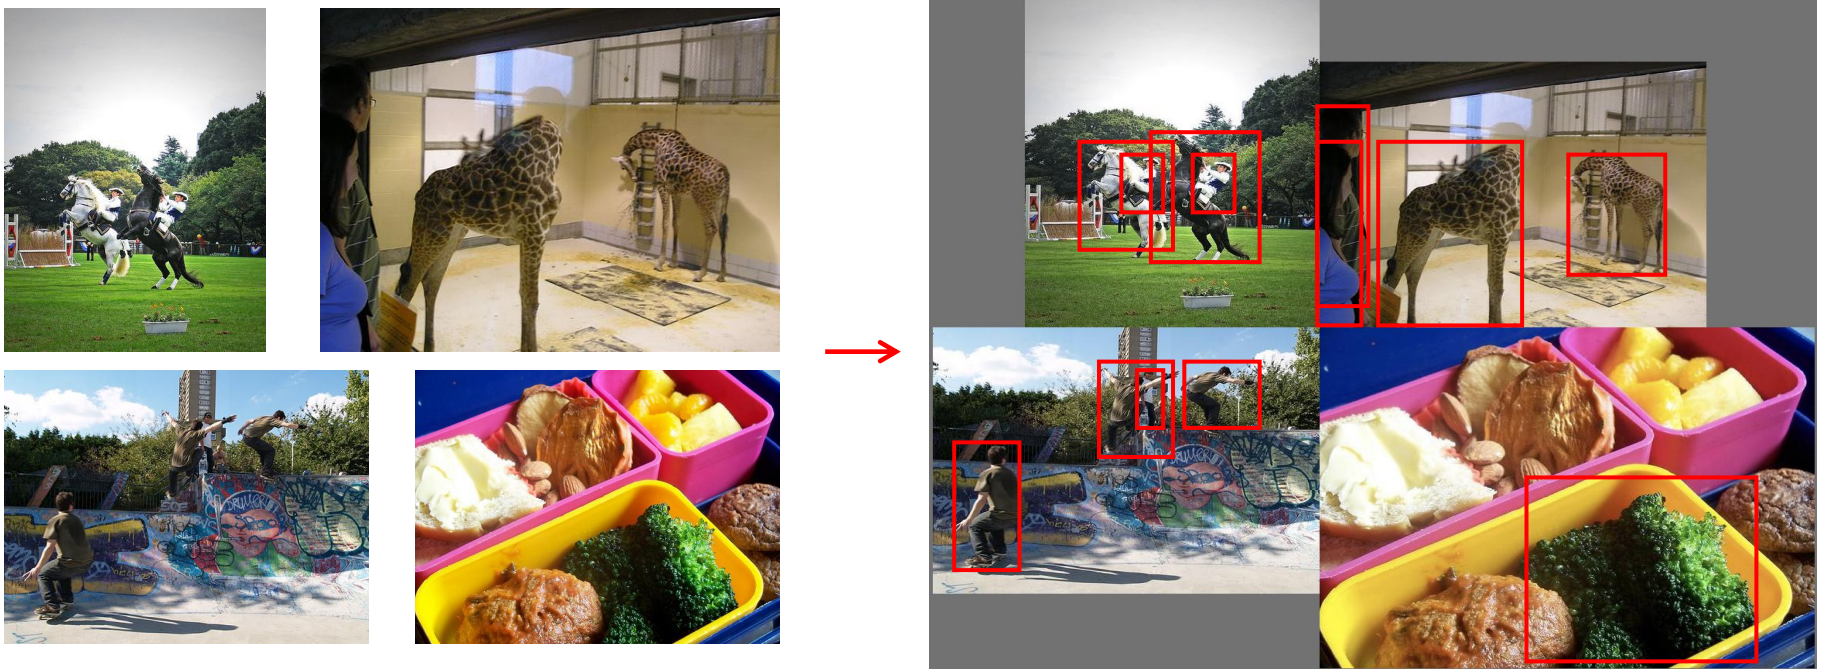

拼接流程:
1. 初始化整个背景图, 大小为(2*image_size, 2*image_size, 3)
2. 随机取一个中心点
3. 基于中心点分别将4个图放到左上,右上,左下,右下, 此部分可能会由于中心点小于4张图片的宽高, 所以拼接的时候可能会进行裁剪
4. 重新将打标边框的偏移量计算上

详见: yolov5/utils/datasets.py/#L681-L711

一、 yolo v5解读

（一）、几种数据增强方法

mosaic: 1.0 # image mosaic (probability)， 4图拼接

以下示例是 由于中心点(下图红点)随机选取不同， 可能会出现的裁剪情况

中心点左右上下
刚好大于任何图
片的宽高

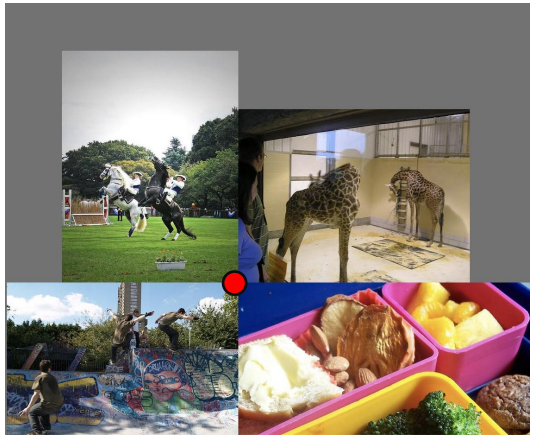

中心点下半部分
小于图片高
下边图片进行裁剪

中心点右半部分
小于图片宽
右边图片进行裁剪

中心点左半部分
小于图片宽
左边图片进行裁剪

一、 yolo v5解读

（一）、几种数据增强方法

mixup: 0.0 # image mixup (probability)，图像互相融合

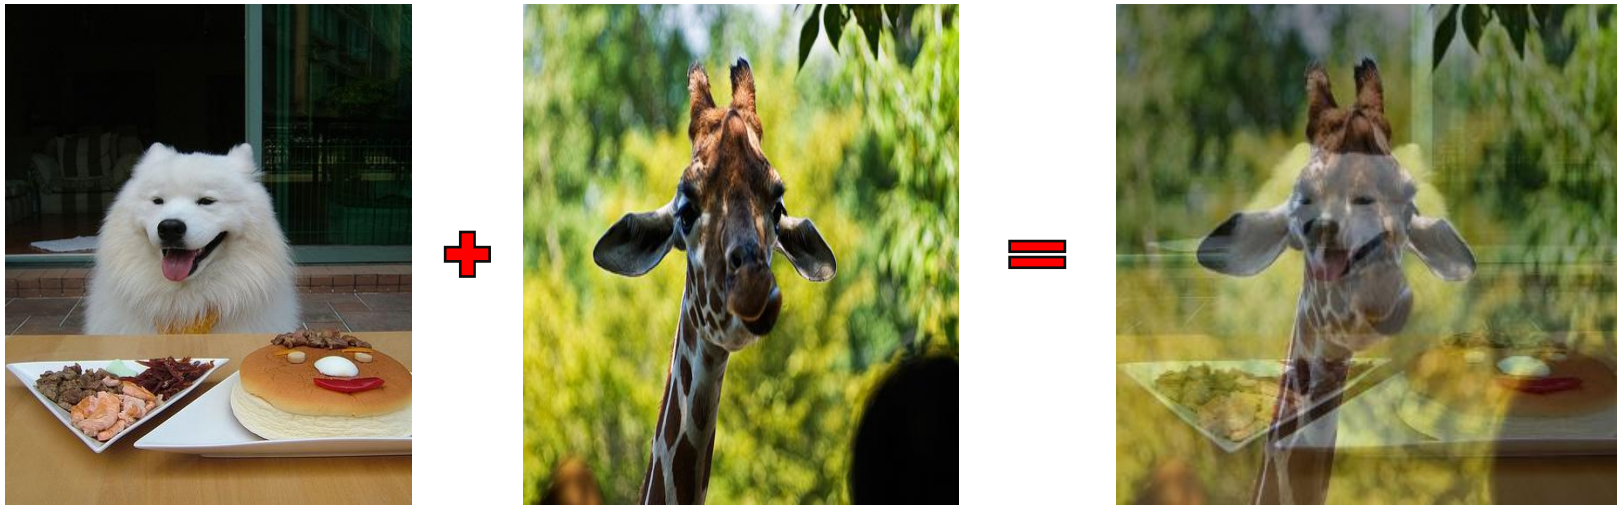

mixup的思想其实就是简单地将两张图叠加到一起，通过不同的透明度区分

下面是yolov5的实现代码：

```
def mixup(im, labels, im2, labels2):
    # Applies MixUp augmentation https://arxiv.org/pdf/1710.09412.pdf
    r = np.random.beta(32.0, 32.0)  # mixup ratio, alpha=beta=32.0
    im = (im * r + im2 * (1 - r)).astype(np.uint8)
    labels = np.concatenate((labels, labels2), 0)
    return im, labels
```

一、 yolo v5解读

（一）、几种数据增强方法

copy_paste: 0.0 # segment copy-paste (probability)，分割填补

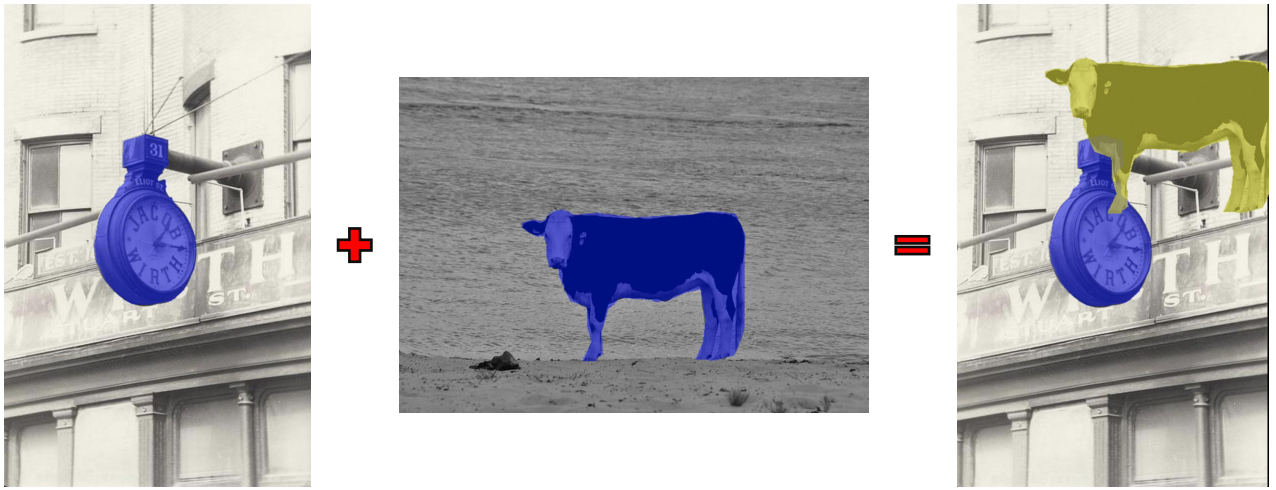

分割填补注意点：

1. 分割出图像的目标后，需要计算该目标边框与填补图片中的所有目标边框IOU<0.3(实现参数)
2. 详见yolov5/utils/argumentations.py/#L213-L234

一、 yolo v5解读

(一) 、几种数据增强方法

最后box坐标转换， segment坐标转换
这部分参考: yolov5/utils/argumentations.py/#L175-L208

1. 将所有变换矩阵连乘得到最终的变换矩阵: M = T @ S @ R @ P @ C

2. 将坐标点(x,y)处理成(x,y,1), 其中segment.shape=[n, 2], 表示物体轮廓各个坐标点:
   xy = np.ones((len(segment), 3))
   xy[:, :2] = segment
   如果是box坐标, 这里targets每行为[x1,y1,x2,y2],n为行数,表示目标边框个数:
   xy = np.ones((n * 4, 3))
   xy[:, :2] = targets[:, [1, 2, 3, 4, 1, 4, 3, 2]].reshape(n * 4, 2)

3. 应用旋转矩阵: xy = xy @ M.T

4. rescale操作, 这里如果透视变换参数perspective不为0， 就需要做rescale:
   xy = xy[:, :2] / xy[:, 2:3]
   透视变换参数为0, 则无需做rescale:
   xy = xy[:, :2]

   为什么perspective这里需要做rescale?

$$\texttt{dst}\left(\frac{M_{11}x+M_{12}y+M_{13}}{M_{31}x+M_{32}y+M_{33}},.\frac{M_{21}x+M_{22}y+M_{23}}{M_{31}x+M_{32}y+M_{33}}\right)=\texttt{src}(x,y)$$

   如果是perspective, rescale就跟图像变换一样, 还需要除以上述分母

5. 将坐标clip到[0, width],[0,height]区间内
6. 进一步过滤,留下那些w,h>2,宽高比<20,变换后面积比之前比>0.1的那些xy

一、 yolo v5解读

（二）、backbone网络 参数量/体积

Small	Medium	Large	XLarge
YOLOv5s	YOLOv5m	YOLOv5l	YOLOv5x
14 MB_{FP16} 2.0 ms_{V100} 37.2 mAP_{COCO}	41 MB_{FP16} 2.7 ms_{V100} 44.5 mAP_{COCO}	90 MB_{FP16} 3.8 ms_{V100} 48.2 mAP_{COCO}	168 MB_{FP16} 6.1 ms_{V100} 50.4 mAP_{COCO}

tf2.x复现参数量:

参数量: 7202491 float16: ≈ 13.5M	参数量: 21025275 float16: ≈ 40M	参数量: 46354491 float16: ≈ 88.4M	参数量: 86501755 float16: ≈ 165M

参数换算公式: 参数量 * 2 / 1024 /1024 （一个float16占2个字节，1024个字节为1k）

一、 yolo v5解读

（二） 、backbone网络

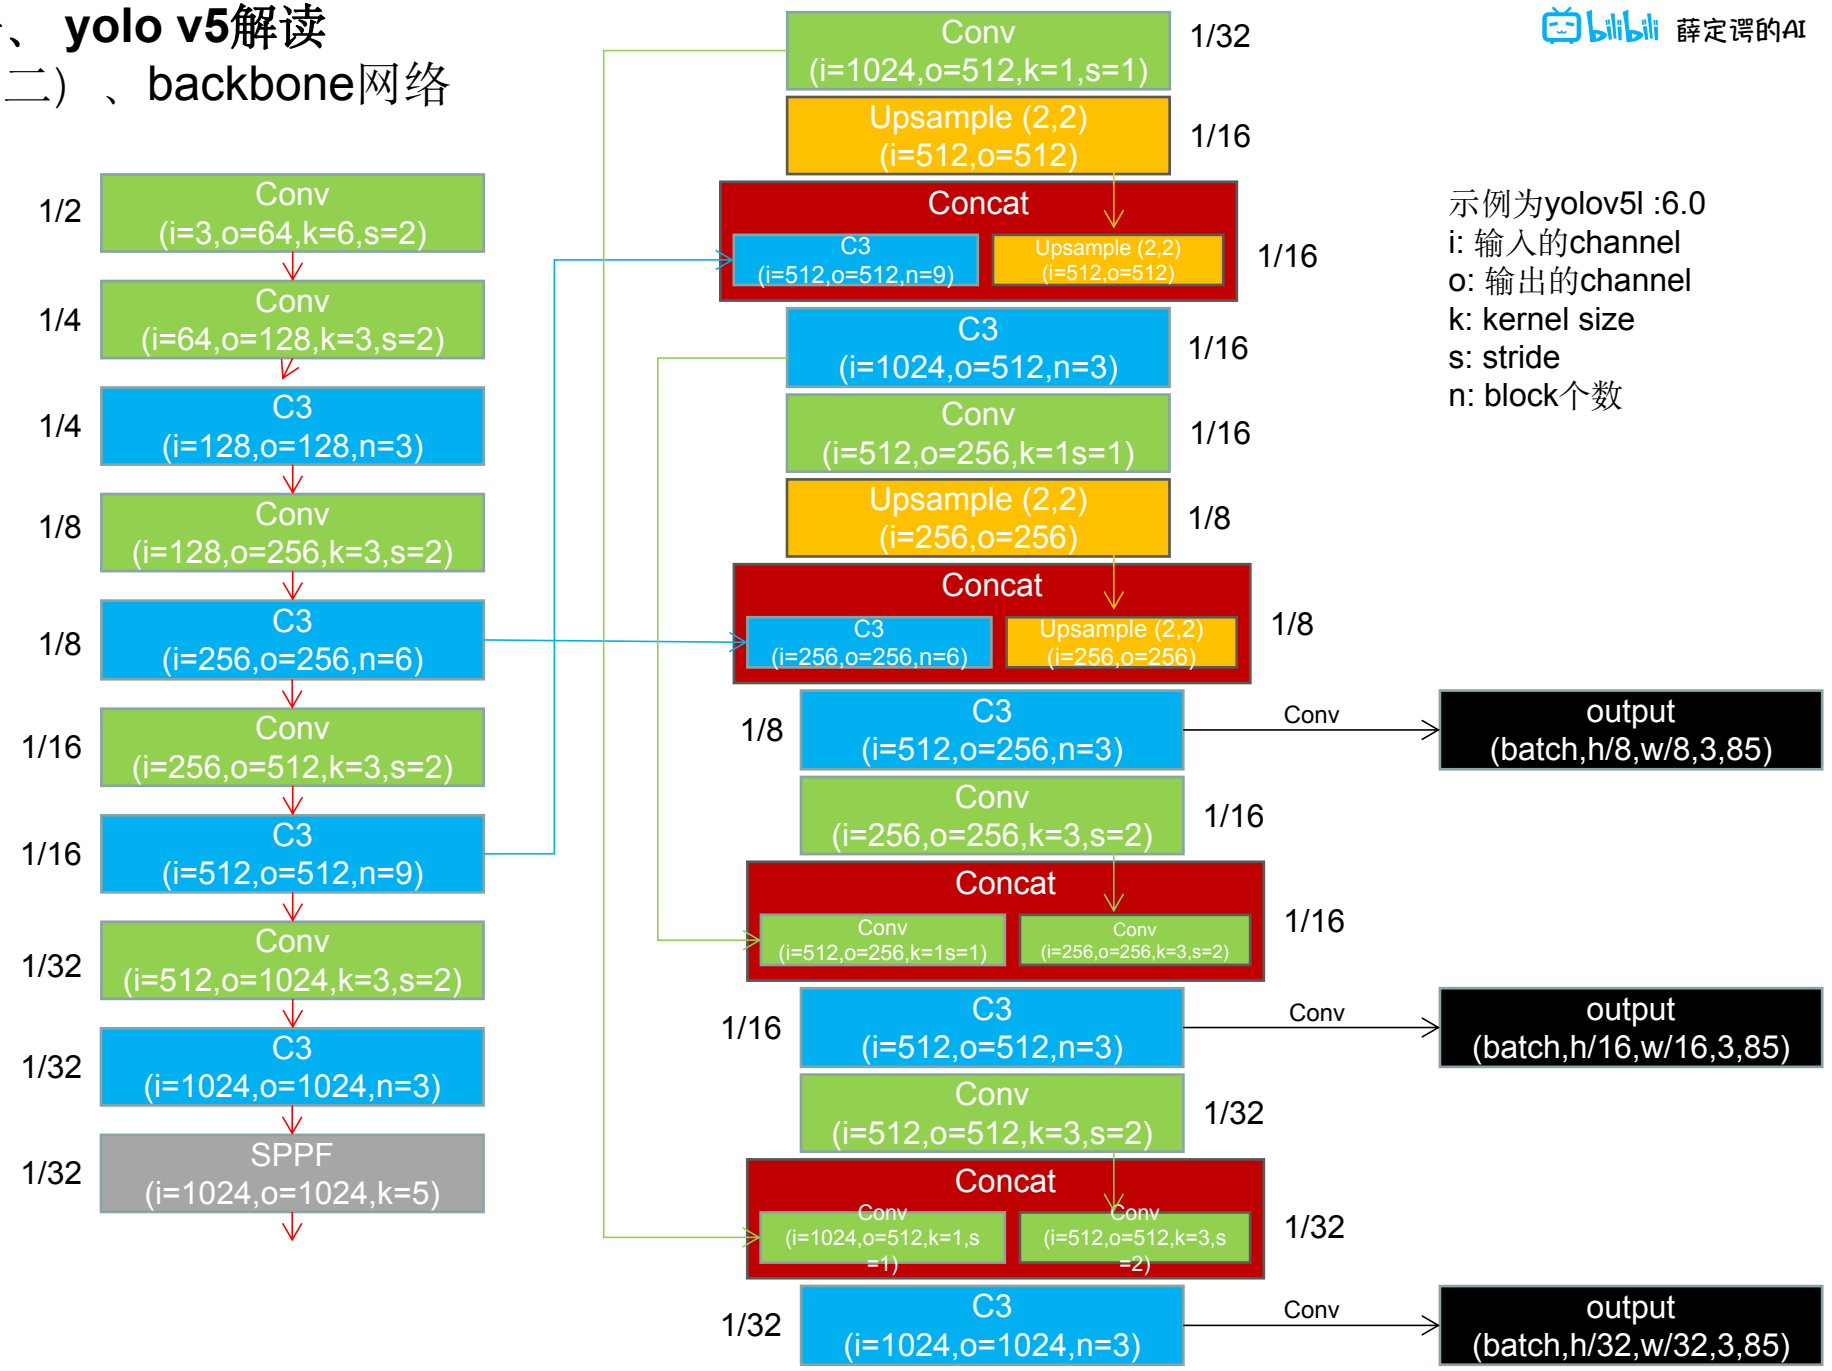

示例为yolov5l :6.0
i: 输入的channel
o: 输出的channel
k: kernel size
s: stride
n: block个数

一、 yolo v5解读

（二）、backbone网络: FPN+PAN

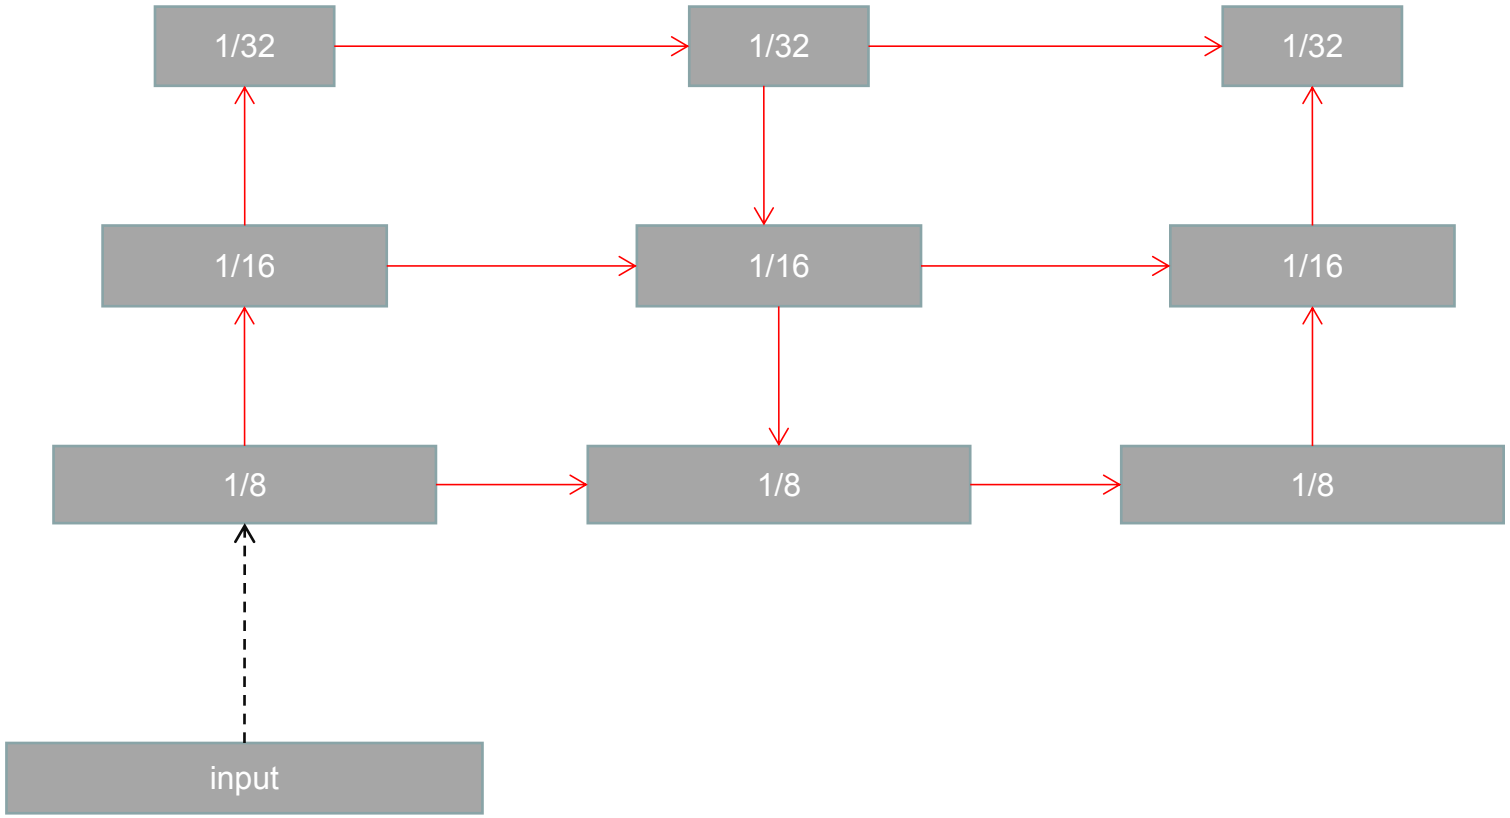

一、 yolo v5解读

（二） 、backbone网络 Conv层

```
class Conv(nn.Module):
    # Standard convolution
    def __init__(self, c1, c2, k=1, s=1, p=None, g=1, act=True):  # ch_in, ch_out, kernel, stride, padding, groups
        super().__init__()
        self.conv = nn.Conv2d(c1, c2, k, s, autopad(k, p), groups=g, bias=False)
        self.bn = nn.BatchNorm2d(c2)
        self.act = nn.SiLU() if act is True else (act if isinstance(act, nn.Module) else nn.Identity())

    def forward(self, x):
        return self.act(self.bn(self.conv(x)))

    def forward_fuse(self, x):
        return self.act(self.conv(x))
```

1. 关于分组卷积，主要是减少参数减低计算量用.
2. 其计算逻辑大概为:
如右图，假设输入channel为12，输出channel为6，kernel_size=3，分组groups=3，bias=False

- 那么传统的卷积每个卷积核大小为3x3x12，总的参数量为6x3x3x12
- 分组后每个group的输入channel=12/3=4，每个group输出channel=6/3=2，每个group里面的卷积核大小=3x3x4，总的参数量为6x3x3x4

可以看出来分组后参数量为传统卷积的1/groups。

不过，在最新的yolov5 6.0代码里面不做这个分组。

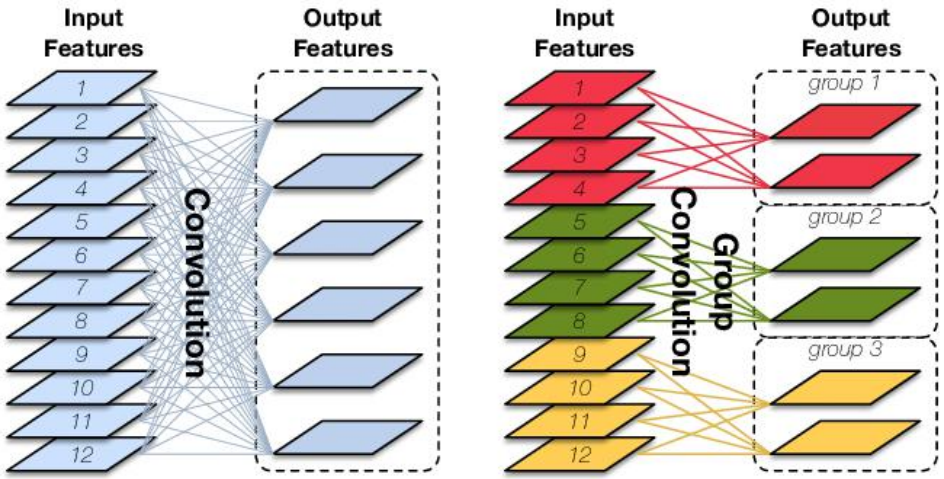

分组卷积
图片链接[1]

1. https://www.researchgate.net/figure/The-transformations-within-a-layer-in-DenseNets-left-and-CondenseNets-at-training-time_fig2_321325862

一、 yolo v5解读

(二) 、backbone网络 Conv层

```
class Conv(nn.Module):
    # Standard convolution
    def __init__(self, c1, c2, k=1, s=1, p=None, g=1, act=True):  # ch_in, ch_out, kernel, stride, padding, groups
        super().__init__()
        self.conv = nn.Conv2d(c1, c2, k, s, autopad(k, p), groups=g, bias=False)
        self.bn = nn.BatchNorm2d(c2)
        self.act = nn.SiLU() if act is True else (act if isinstance(act, nn.Module) else nn.Identity())

    def forward(self, x):
        return self.act(self.bn(self.conv(x)))

    def forward_fuse(self, x):
        return self.act(self.conv(x))
```

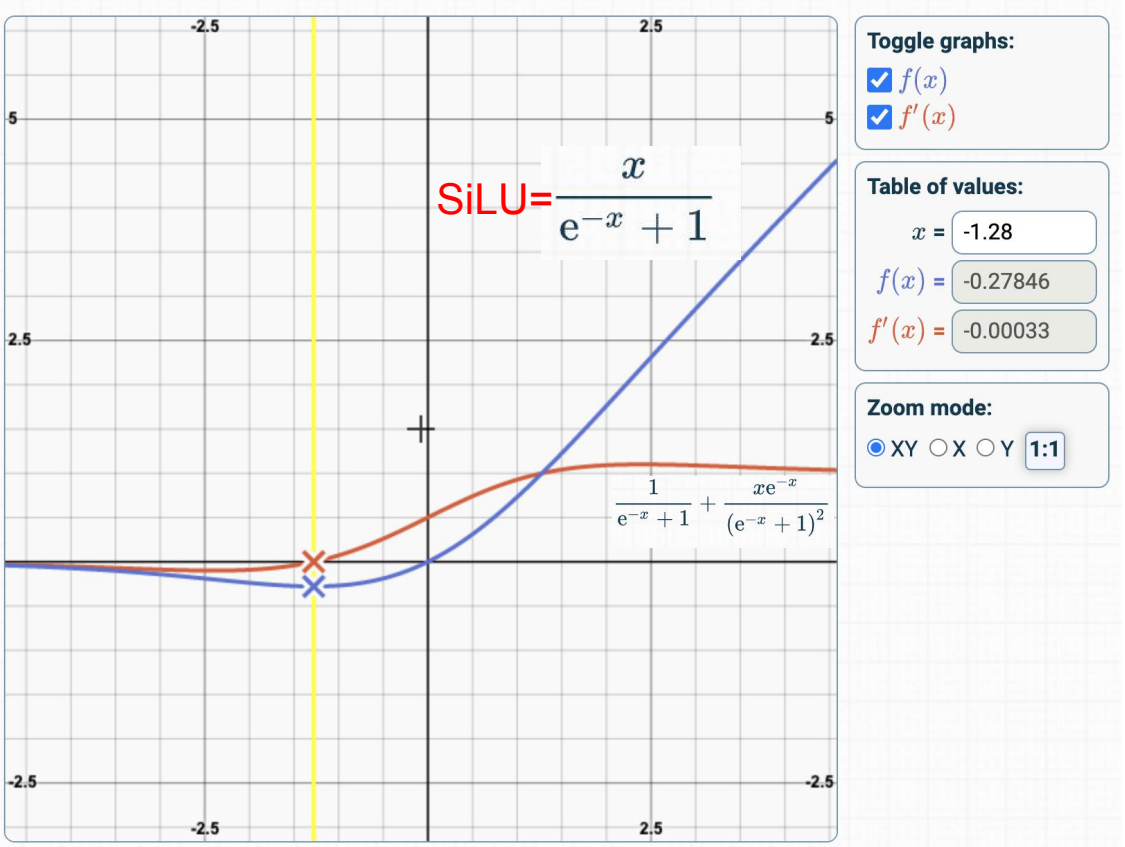

1. SiLU，其表达式以及表现形式如右图蓝线.
2. SiLU的函数形式跟ReLU十分相似，区别在于SiLU在<0处有负值，随着输入的绝对值越大，其跟ReLU就越相似，表现出ReLU非线性特点，以及避免梯度弥散消失，同时也具有一定的正则效果.
3. SiLU最早是这篇论文[1]里提出的用于强化学习的，作者提到SiLU具有自稳定定性，相关实验可以在这个论文[2]看到，同时SiLU非单调递增特征，在x=-1.28存在函数极小值，作者在其论文也解释到这种存在了一定的隐性正则效果.

最后为什么yolov5采用SiLU,其实更多还是实验的结果：这里[3]可以看到作者实验了11种.
如果你有新的act，也可以像这个issue[4]跟作者讨论.

1. https://arxiv.org/pdf/1702.03118.pdf
2. https://www.researchgate.net/publication/266205382_Expected_energy-based_restricted_Boltzmann_machine_for_classification
3. https://github.com/ultralytics/yolov5/blob/c9c95fb282322bc2928f44488f2467c5f4104f09/models/common.py#L34-L55
4. https://github.com/ultralytics/yolov5/issues/2891#issuecomment-826658992

一、 yolo v5解读

（二）、backbone网络 C3层

BottleneckCSP 与 C3

1. CSP结构是这篇论文[1]中提出的，如下图所示：

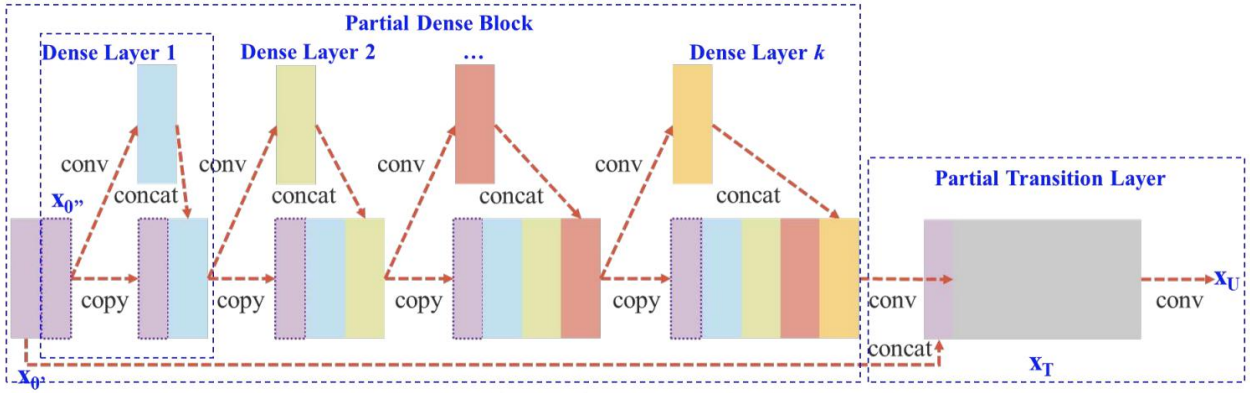

2. CSPNet论文中主要是对比denseNet的特征融合，目的是为了提高模型的速度，同时兼顾精度，denseNet的concat结构如下图：

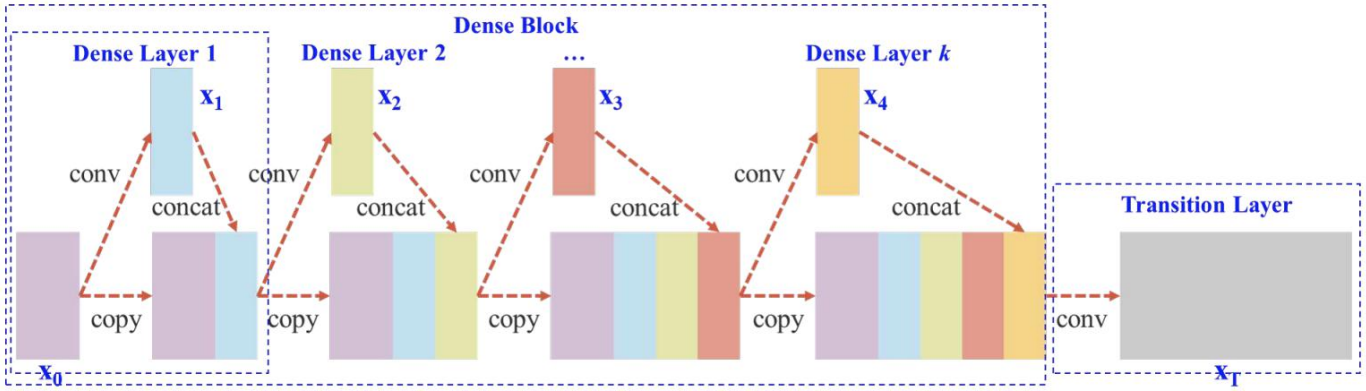

3. 可以看出CSP结构通过分离通道层，只对其中一部分特征做卷积，再concat，以此减少计算量，同时又能保证精度。

1.https://openaccess.thecvf.com/content_CVPRW_2020/papers/w28/Wang_CSPNet_A_New_Backbone_That_Can_Enhance_Learning_Capability_of_CVPRW_2020_paper.pdf

一、 yolo v5解读
（二） 、backbone网络 C3层

BottleneckCSP 与 C3

在最新的yolov5中(release-v6.0)，bottleneckCSP作者修改了原论文关于CSP的实现，不采用通道分离，而是直接全部参与卷积：

```
class BottleneckCSP(nn.Module):
    # CSP Bottleneck https://github.com/WongKinYiu/CrossStagePartialNetworks
    def __init__(self, c1, c2, n=1, shortcut=True, g=1, e=0.5):
        super().__init__()
        c_ = int(c2 * e)  # hidden channels
        self.cv1 = Conv(c1, c_, 1, 1)
        self.cv2 = nn.Conv2d(c1, c_, 1, 1, bias=False)
        self.cv3 = nn.Conv2d(c_, c_, 1, 1, bias=False)
        self.cv4 = Conv(2 * c_, c2, 1, 1)
        self.bn = nn.BatchNorm2d(2 * c_)  # applied to cat(cv2, cv3)
        self.act = nn.SiLU()
        self.m = nn.Sequential(*(Bottleneck(c_, c_, shortcut, g, e=1.0) for _ in range(n)))

    def forward(self, x):
        y1 = self.cv3(self.m(self.cv1(x)))
        y2 = self.cv2(x)
        return self.cv4(self.act(self.bn(torch.cat((y1, y2), dim=1))))
```

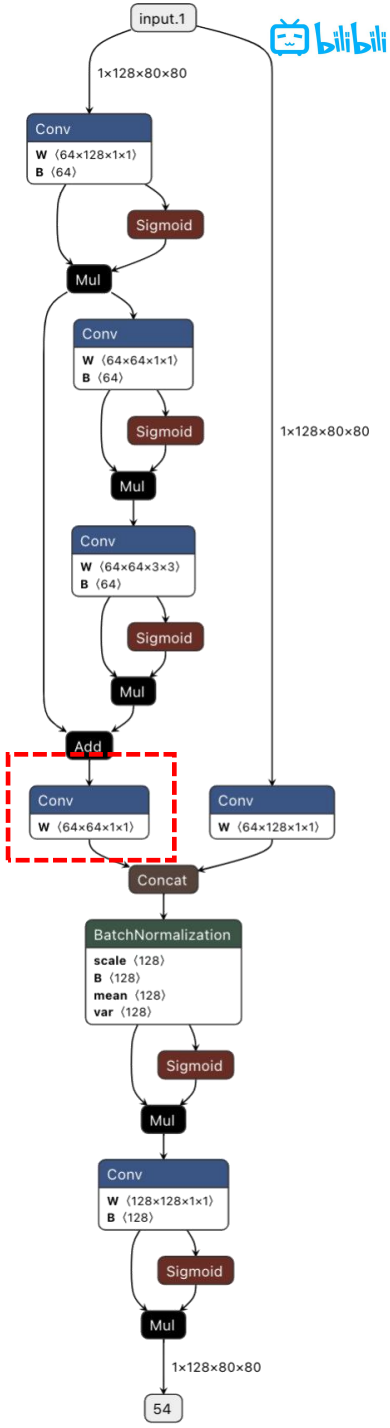

一、 yolo v5解读

（二） 、backbone网络 C3层

在最新的yolov5中(release-v6.0)，最终采用的C3的结构，而C3名称的由来，就是bottleneckCSP中4个conv卷积层，去掉了1层，剩下3层，所以称为C3，具体去掉的哪一层卷积， 位于上一P中CSP结构中画红圈部分.

```
class C3(nn.Module):
    # CSP Bottleneck with 3 convolutions
    def __init__(self, c1, c2, n=1, shortcut=True, g=1, e=0.5):
        super().__init__()
        c_ = int(c2 * e)  # hidden channels
        self.cv1 = Conv(c1, c_, 1, 1)
        self.cv2 = Conv(c1, c_, 1, 1)
        self.cv3 = Conv(2 * c_, c2, 1)  # act=FReLU(c2)
        self.m = nn.Sequential(*(Bottleneck(c_, c_, shortcut, g, e=1.0) for _ in range(n)))

    def forward(self, x):
        return self.cv3(torch.cat((self.m(self.cv1(x)), self.cv2(x)), dim=1))
```

所以最后采用C3这种结构，同样是实验的结果，bottleneckCSP和C3性能上的对比如下图(上面是bottleneckCSP，下面是C3),从前向计算，反向传播来说，C3都比bottleneckCSP快：

Params	GFLOPs	GPU_mem (GB)	forward (ms)	backward (ms)	input	output
7611392	0	2.166	48.01	87.05	(6, 1024, 64, 64)	(6, 1024, 64, 64)
7348224	0	2.020	30.66	58.69	(6, 1024, 64, 64)	(6, 1024, 64, 64)

实验代码：

```
csp = BottleneckCSP(1024,1024,2)
c3 = C3(1024,1024,2)
result = profile(input=torch.randn(6,1024,64,64), ops=[csp, c3],n=50)
```

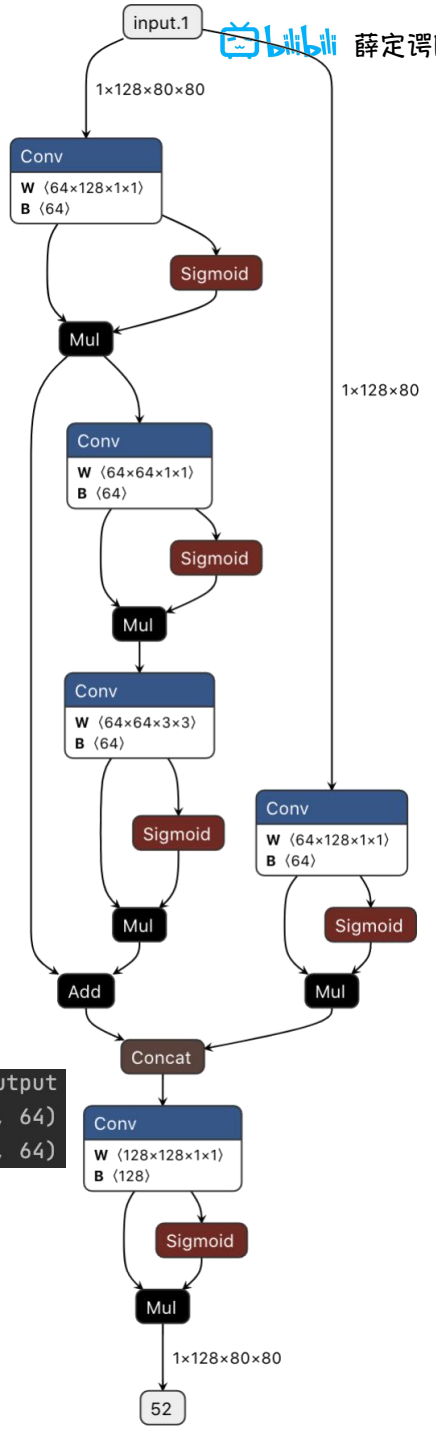

一、 yolo v5解读

(二) 、backbone网络 SPPF层

SPP与SPPF

1. SPP是15年何凯明在论文[1]中提出的一种空间金字塔池化结构，如下图：

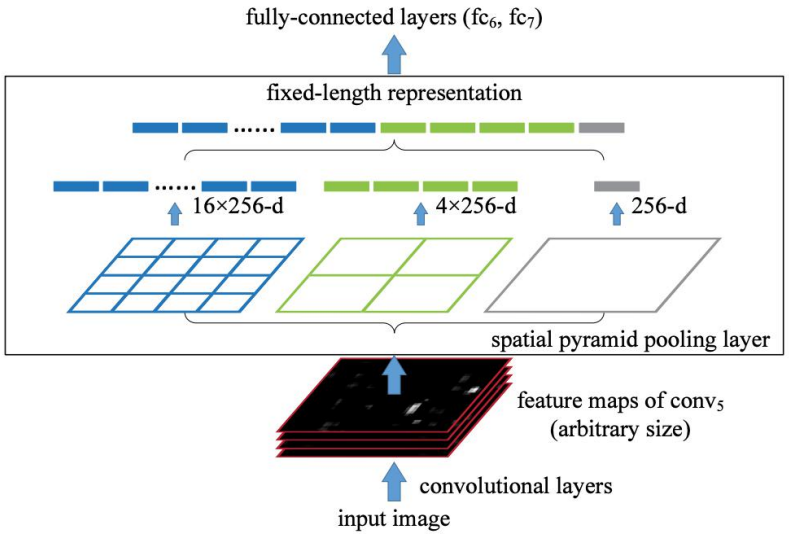

本意上是为了解决RCNN目标检测中不同proposal边框最后都能接上FC层，通过对卷积层施加自适应的大小3种池化操作，最后得到结果再做flatten到固定的大小，就可以统一接fc，就可以避免当时的ROIwrap层的裁剪+reisze丢失精度。

2. 右图早期的yolov5 spp实现，yolov5修改了spp中的池化padding,stride，使得所有三种不同尺度的池化通过不同kernel_size的池化后，都能输出统一的大小.

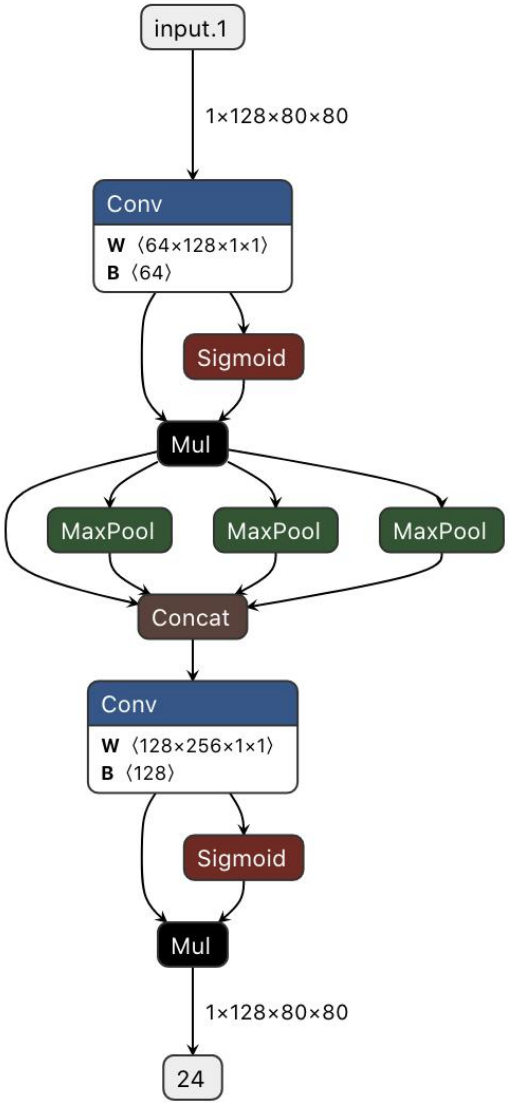

yolov5 spp层

1. https://arxiv.org/pdf/1406.4729.pdf

一、 yolo v5解读

（二）、backbone网络 SPPF层

在最新的yolov5中(release-v6.0)

1. 作者将早期的SPP替换为SPPF，可以在这个issue[1]看到，修改的地方是将3个并行的max_pool替换为串行，并且kernel_size全部都是一样，如右图所示。

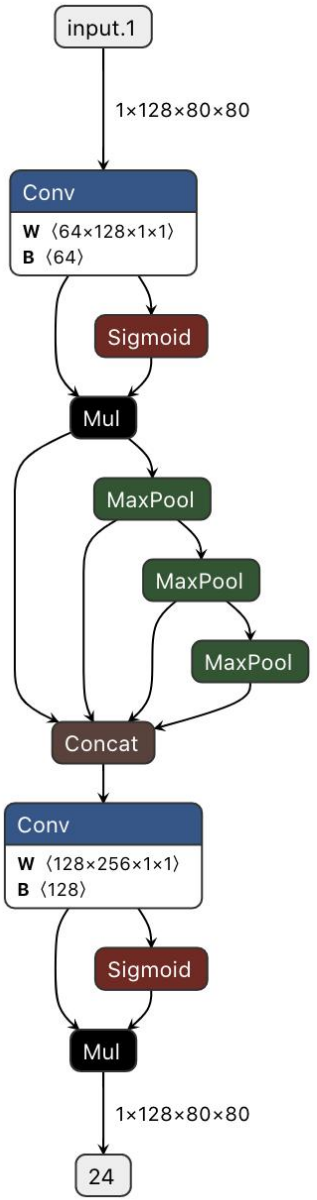

2. 这么修改的目的就只有一个，就是实践得到串行的max_pool同样能得到spp的结果，同时能带来更多的性能上的提升，包括前向计算，反向计算，对比结果可以看下面截图，上面是SPP的实验效果，下面是SPPF的实验效果：

```
from models.common import SPPF,SPP
from utils.torch_utils import profile
m1 = SPP(1024, 1024)
m2 = SPPF(1024, 1024)
results = profile(input=torch.randn(16, 1024, 64, 64), ops=[m1, m2], n=100)
```

Params	GFLOPs	GPU_mem (GB)	forward (ms)	backward (ms)	input	output
2624512	0	4.586	80.9	171.2	(16, 1024, 64, 64)	(16, 1024, 64, 64)
2624512	0	4.452	55.23	114.7	(16, 1024, 64, 64)	(16, 1024, 64, 64)

1. https://github.com/ultralytics/yolov5/pull/4420

一、 yolo v5解读

（三）、边框预测细节

$$
\begin{aligned}
b_x &= (2\sigma(t_x) - 0.5 + c_x) * stride \\
b_y &= (2\sigma(t_y) - 0.5 + c_y) * stride \\
b_w &= (2\sigma(t_w))^2 * anchor\_grid \\
b_h &= (2\sigma(t_h))^2 * anchor\_grid
\end{aligned}
$$

几个注意点：

1. 其中tx, ty, tw, th为模型预测输出，
   bx,by,bw,bh为最终预测目标边框中心点，宽高

2. cx, cy为当前预测的Tensor对应的grid坐标，值域为[0, grid_size), stride为[8, 16, 32], 举例加入输入[416, 416, 3], 预测输出的tensor是[batch, 52, 52, 3, 5+num_class], 则cx是在[0, 52)区间, stride为8

3. anchor_grid同理, 值域为[0, image_size], 具体实现是anchor * stride, 其中anchor会被处理到[0, grid_size)区间, 再通过 * stride放大到原图输入大小[0, image_size)

一、 yolo v5解读

（三）、边框预测细节

$$x\_offset = \sigma(t_x)$$
$$y\_offset = \sigma(t_y)$$

yolov3 中心点xy偏移量预测
（未加上对应grid坐标）

$$x\_offset = 2\sigma(t_x) - 0.5$$
$$y\_offset = 2\sigma(t_y) - 0.5$$

yolov5 中心点xy偏移量预测
（未加上对应grid坐标）

公式改动点：

1. yolov5 相比 v3, 偏移量在经过sigmoid函数归一化到[0,1]后, 乘以了2再减0.5，最后值域空间为[-0.5, 1.5]

2. 偏移量值域空间从[0,1]转成[-0.5, 1.5], 主要是v5正采样逻辑, **每个ground true grid cell 上下左右4个位置都参与到采样空间, 往右和往上最多需要减0.5，往左和往下最多需要加1.5**，具体采样细节看第(4)部分

一、 yolo v5解读

（三）、边框预测细节

$$w = e^{t_w}$$
$$h = e^{t_h}$$

yolov3 边框宽高w,h预测
（未乘上对应anchor宽高）

$$w = (2\sigma(t_w))^2$$
$$h = (2\sigma(t_h))^2$$

yolov5 边框宽高w,h预测
（未乘上对应anchor宽高）

公式改动点：

1. yolov5 相比 v3, 偏移量在经过sigmoid函数归一化到[0,1]后, 乘以了2再做平方，最后值域空间为[0, 4]，v3用e做指数得到最终w,h

2. 宽高预测值域空间转成[0, 4], 主要是v5边框筛选逻辑, **每个ground true 目标边框宽高与当前尺度下的anchor宽高计算比值，只要那些比值在[0.25, 4]之间**，具体筛选细节看v5源码 utils/loss.py/ComputeLoss/build_targets/ r跟j两个变量

一、 yolo v5解读

（四）、正样本采样细节

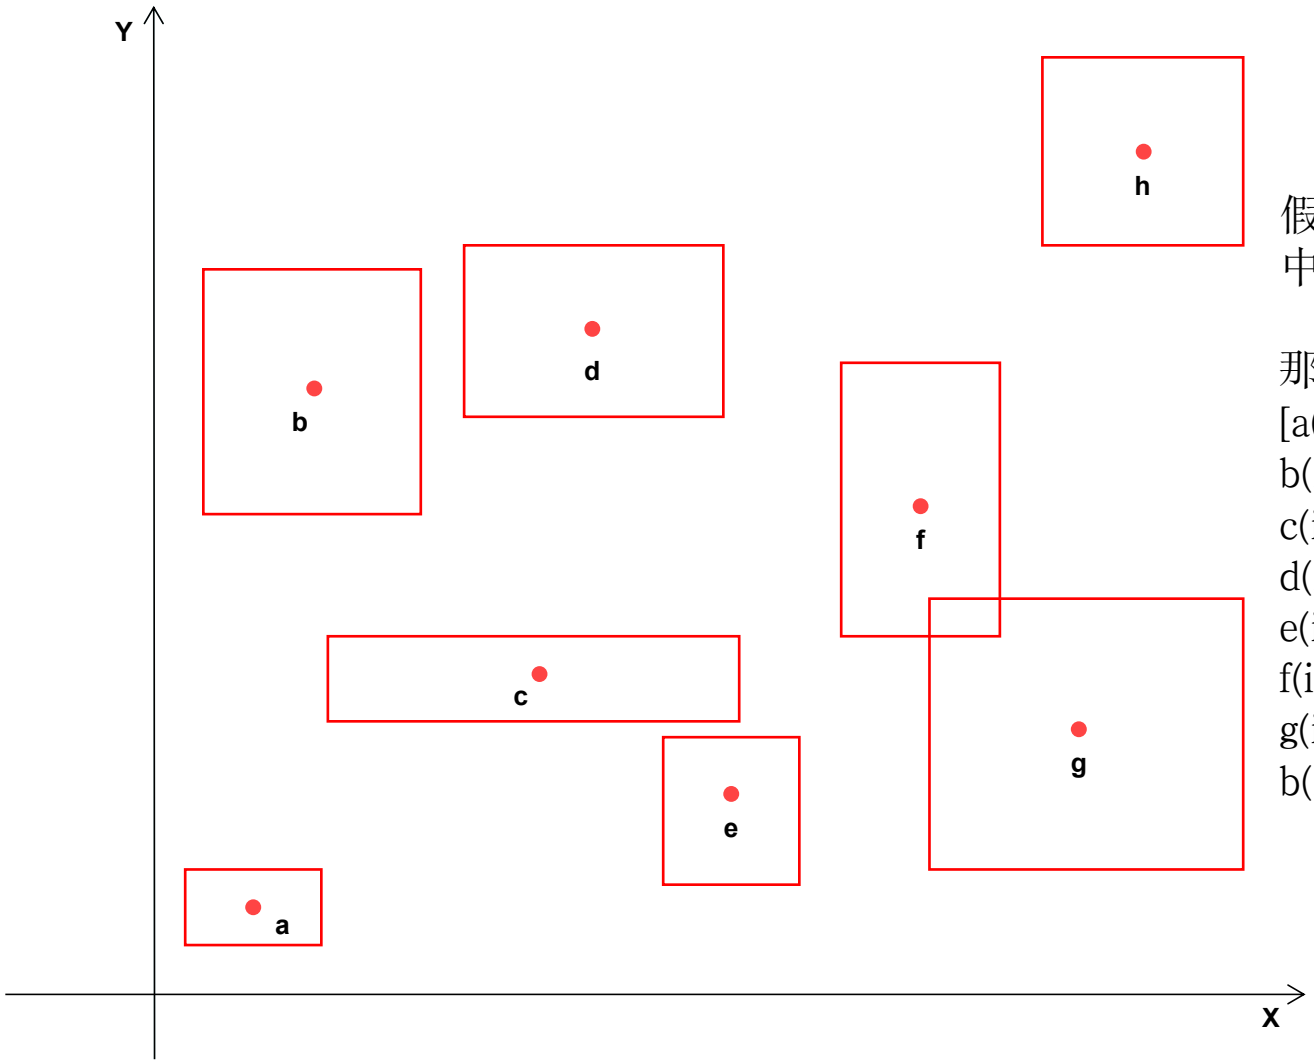

假设a-h总共8个目标边框，其中红点为边框中心点，如左图：

那么输入的target数据为：
[a(image_id, class_id, x, y, w, h),
b(image_id, class_id, x, y, w, h),
c(image_id, class_id, x, y, w, h),
d(image_id, class_id, x, y, w, h),
e(image_id, class_id, x, y, w, h),
f(image_id, class_id, x, y, w, h),
g(image_id, class_id, x, y, w, h),
b(image_id, class_id, x, y, w, h)]

一、 yolo v5解读

（四）、正样本采样细节

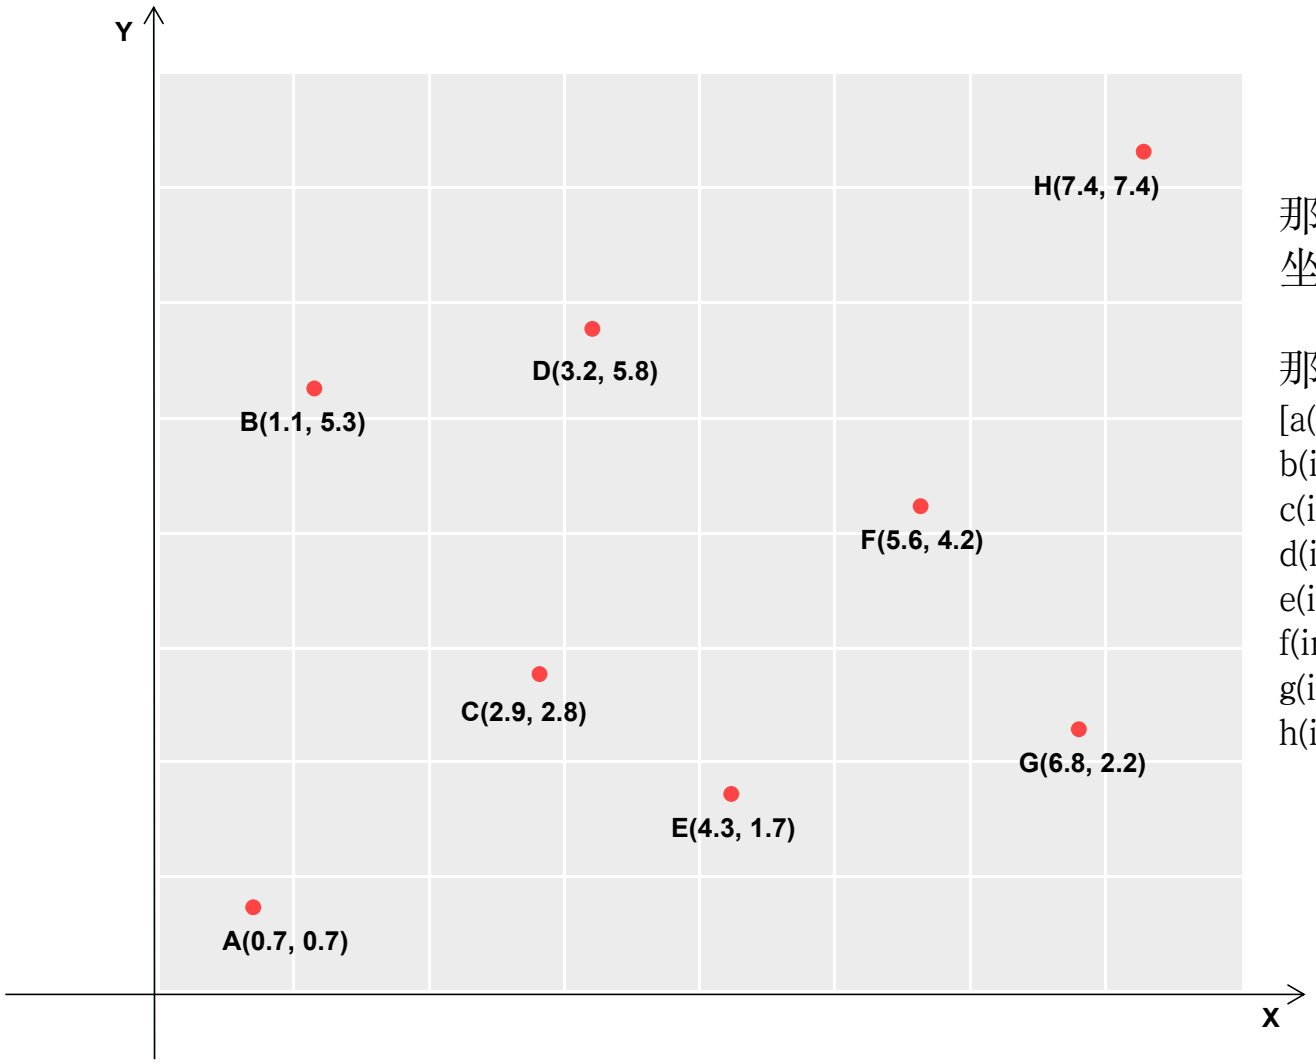

那么a-h 8个边框对应的中心点坐标A-H如图：

那么输入的target数据为：
[a(image_id, class_id, 0.7, 0.7, w, h),
b(image_id, class_id, 1.1, 5.3, w, h),
c(image_id, class_id, 2.9, 2.8, w, h),
d(image_id, class_id, 3.2, 5.8, w, h),
e(image_id, class_id, 4.3, 1.7, w, h),
f(image_id, class_id, 5.6, 4.2, w, h),
g(image_id, class_id, 6.8, 2.2, w, h),
h(image_id, class_id, 7.4, 7.4, w, h)]

一、 yolo v5解读

（四）、正样本采样细节

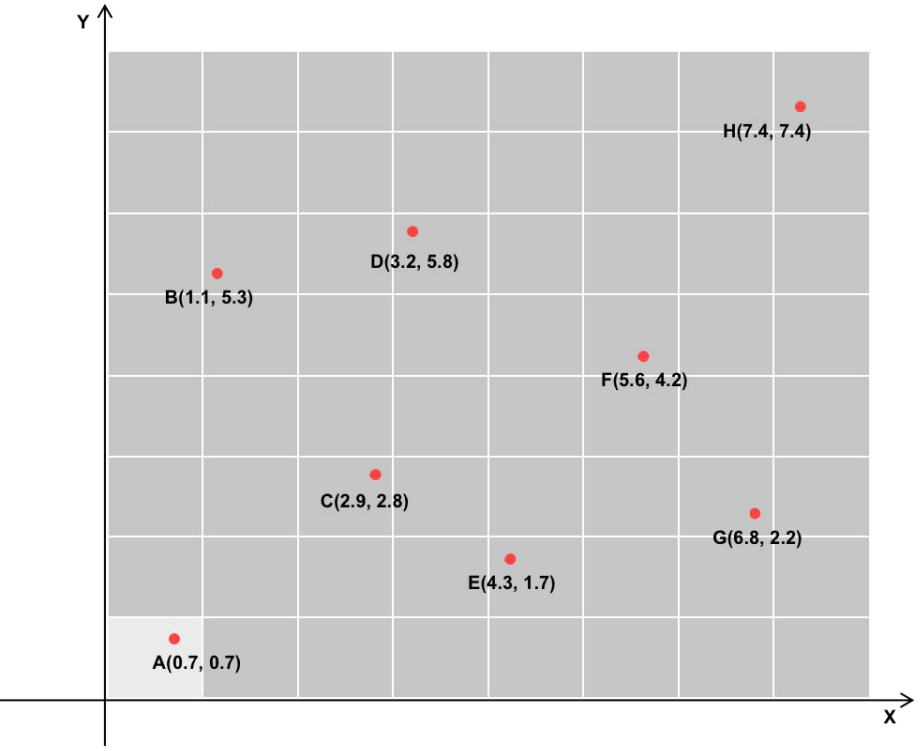

(gxy > 1)

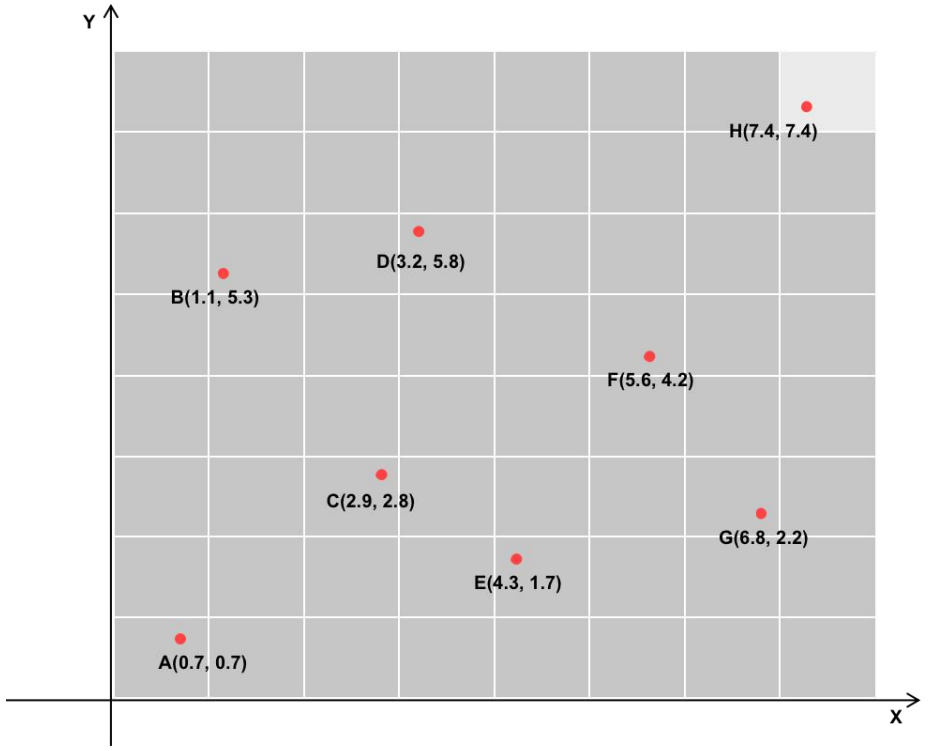

(gxi > 1), 其中gxi = (w,h) - gxy = (8,8) - gxy

一、 yolo v5解读

（四）、正样本采样细节

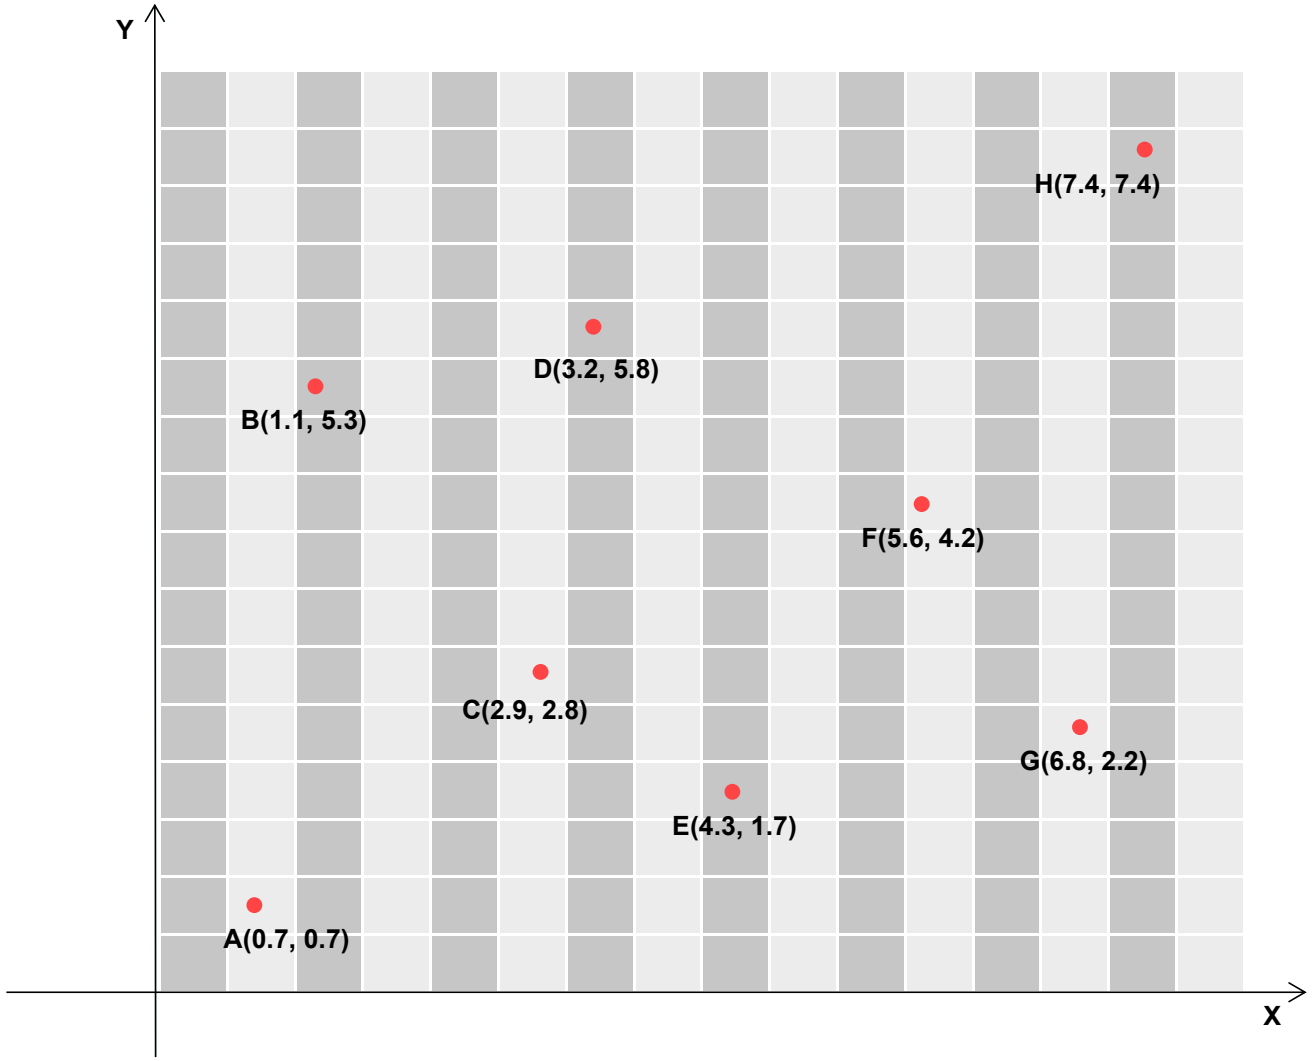

gxy_x % 1 < 0.5

一、 yolo v5解读

（四）、正样本采样细节

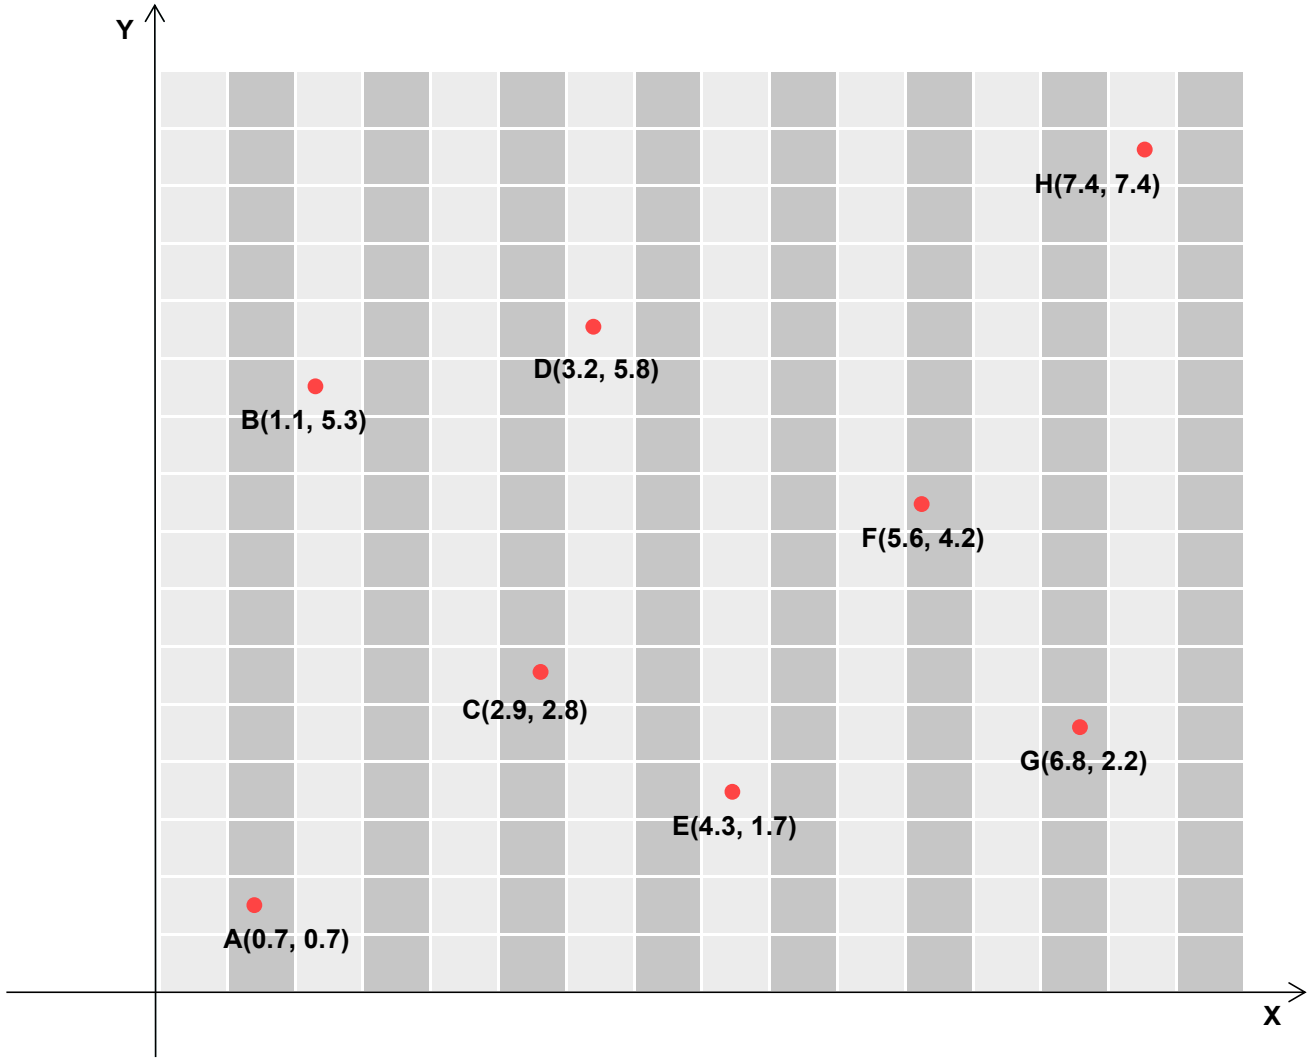

gxi_x % 1 < 0.5

一、 yolo v5解读

（四）、正样本采样细节

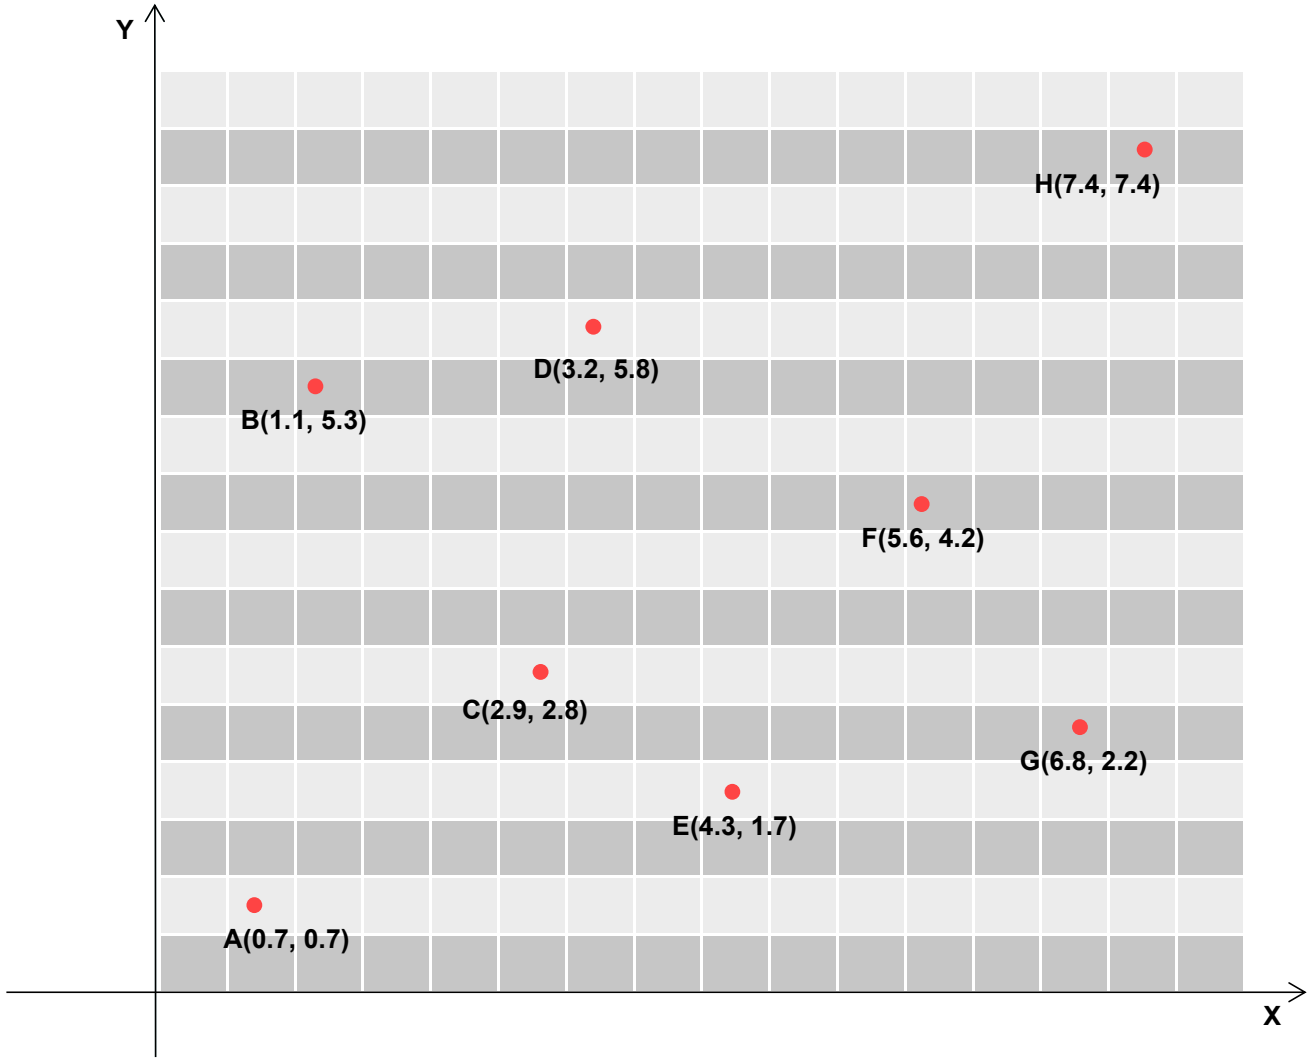

gxy_y % 1 < 0.5

一、 yolo v5解读

（四）、正样本采样细节

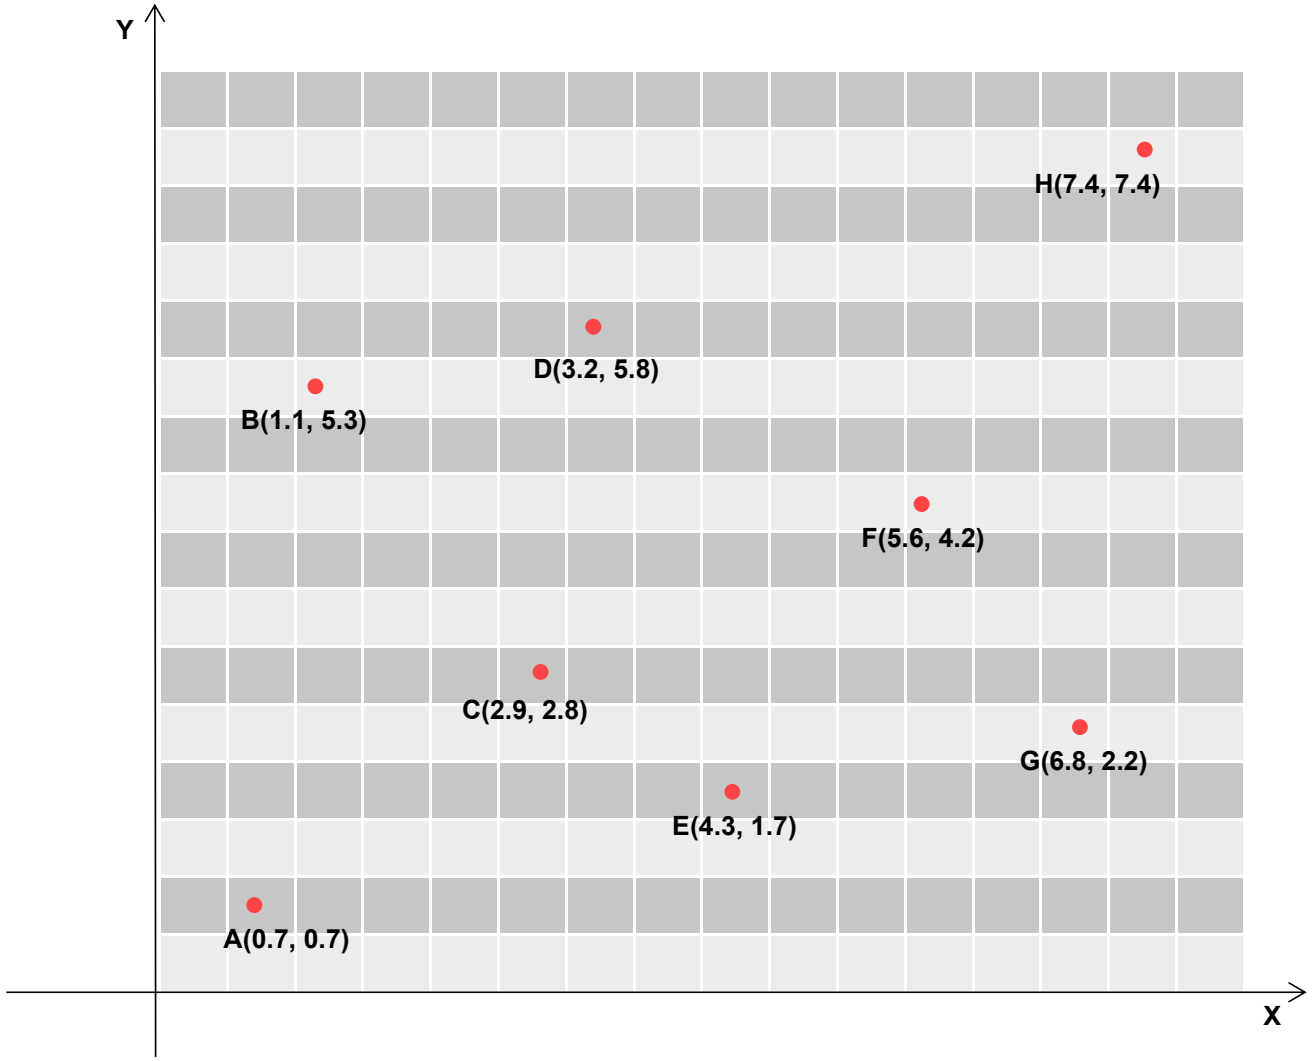

gxi_y % 1 < 0.5

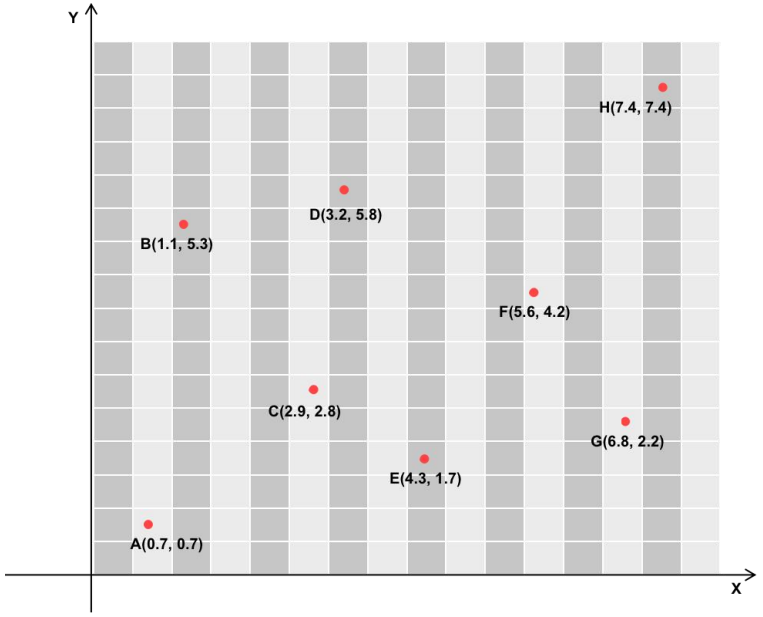

gxy_x % 1 < 0.5

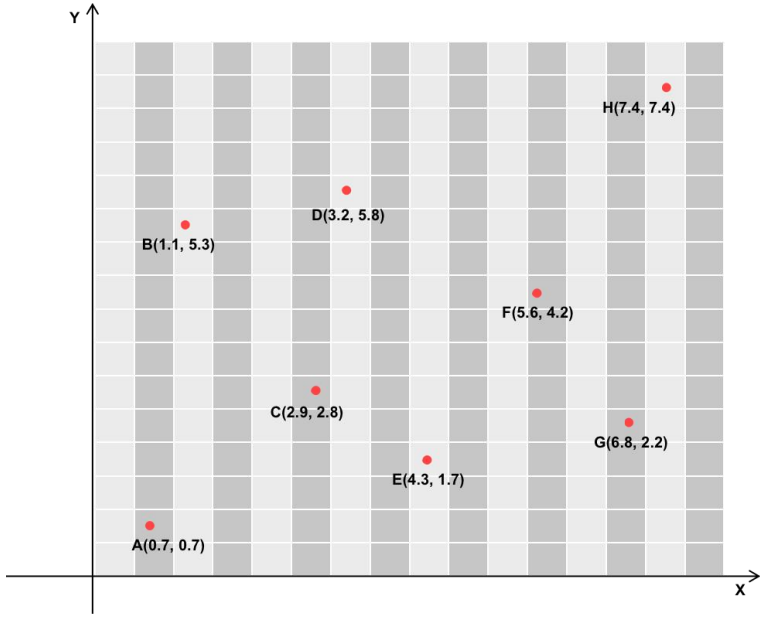

gxi_x % 1 < 0.5

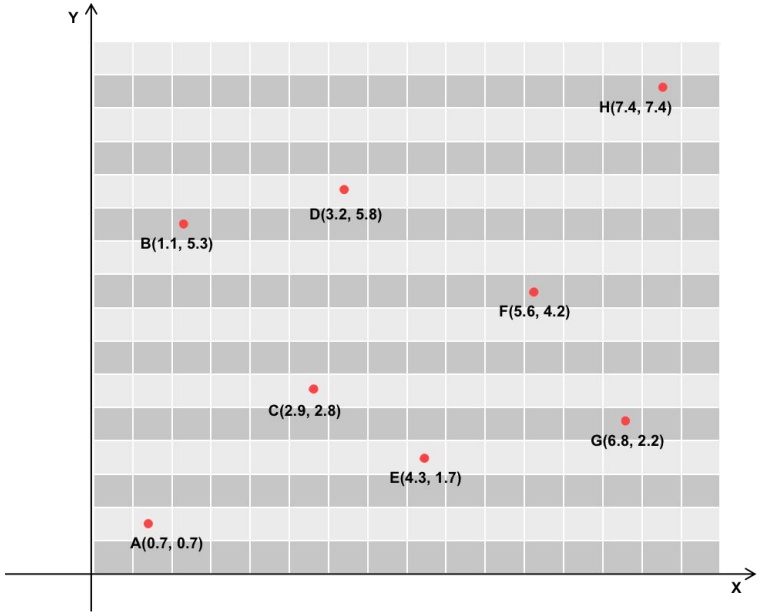

gxy_y % 1 < 0.5

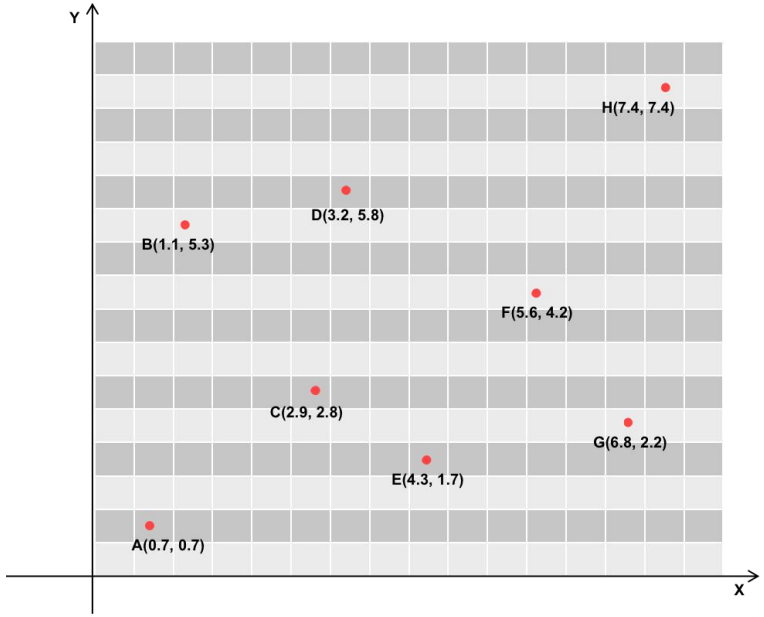

gxi_y % 1 < 0.5

一、 yolo v5解读

（四）、正样本采样细节

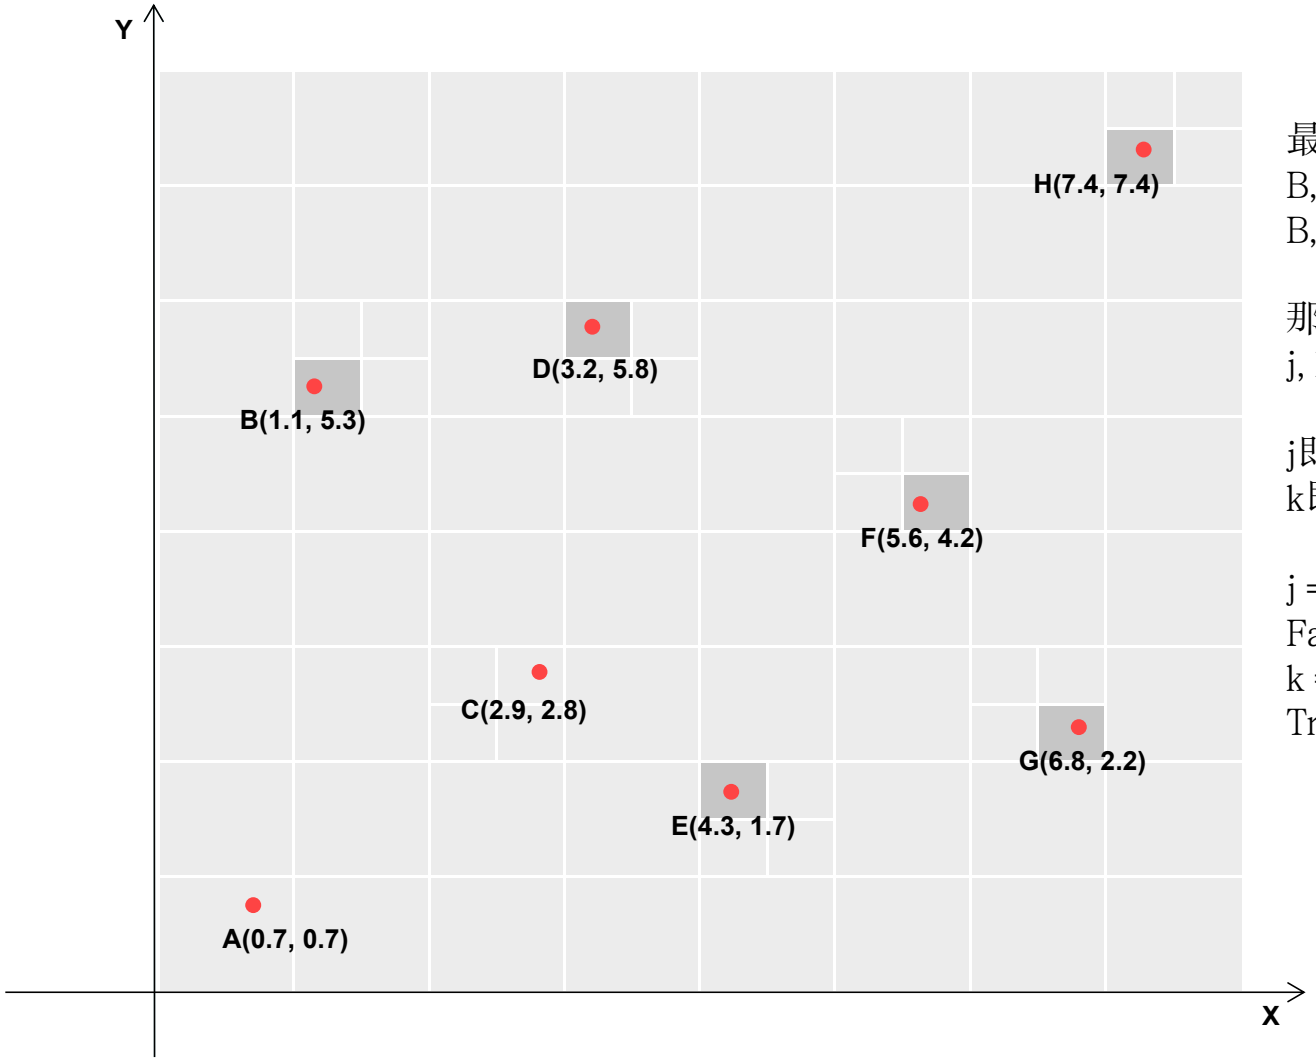

最终筛选得到，其中：
B, D, E, H 为 x % 1 < 0.5, 且x>1
B, F, G, H 为 y % 1 < 0.5, 且y>1

那么：
j, k =(gxy % 1 < 0.5)& (gxy > 1)

j即x % 1 < 0.5, 且x>1
k即y % 1 < 0.5, 且y>1

j = [False, True, False, True, True, False, False, True]
k = [False, True, False, False, False, True, True, True]

(gxy > 1) & (gxy % 1 < 0.5)

一、 yolo v5解读

（四）、正样本采样细节

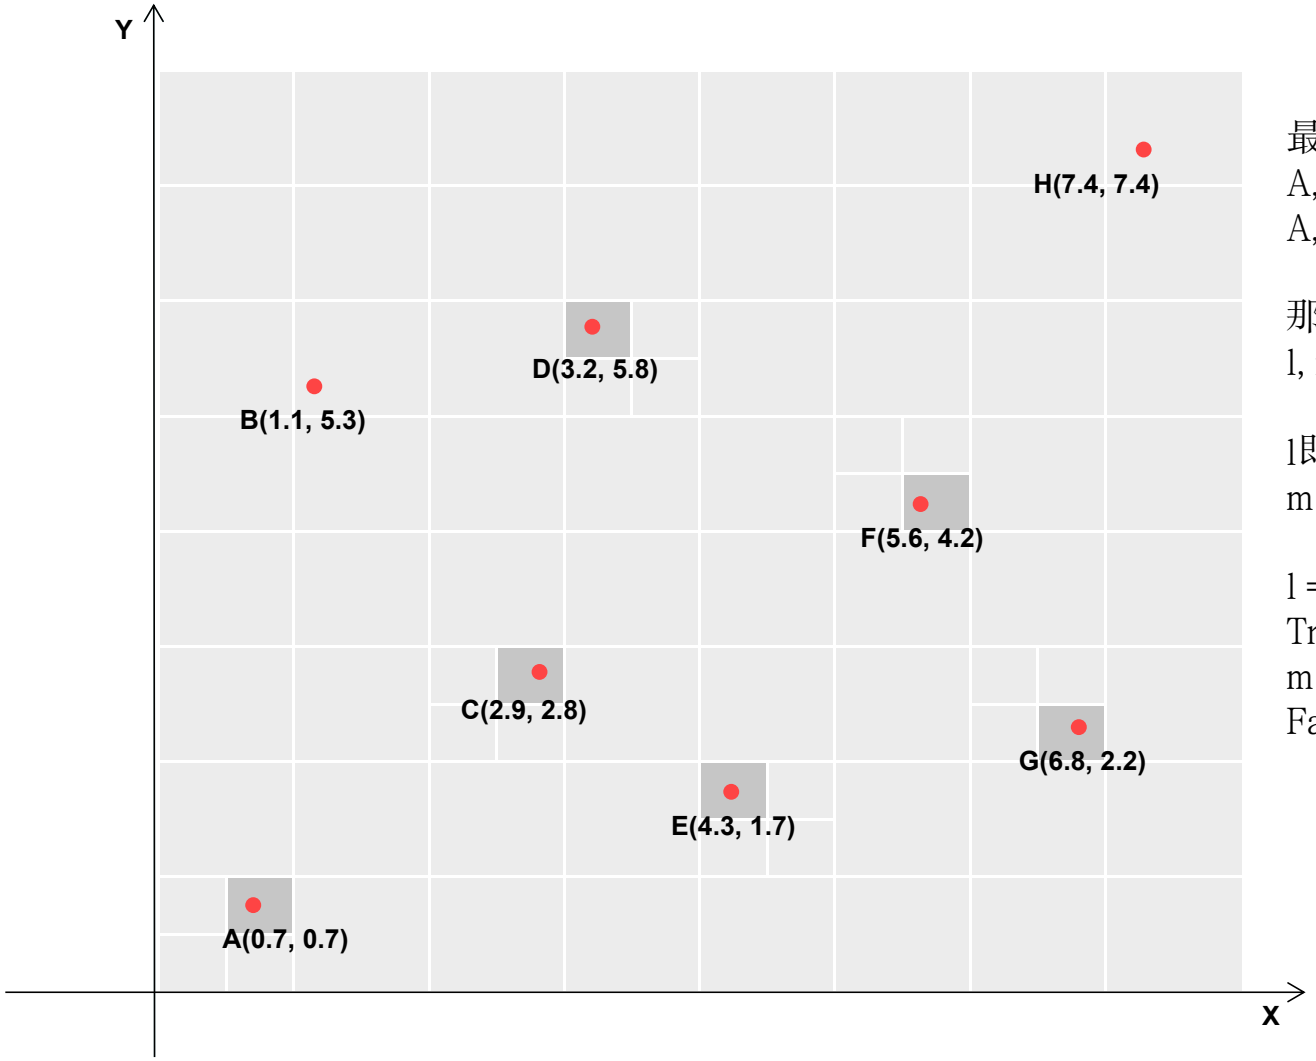

最终筛选得到，其中：
A, C, F, G 为 x % 1 < 0.5, 且x>1
A, C, D, E 为 y % 1 < 0.5, 且y>1

那么：
l, m =(gxi % 1 < 0.5)& (gxi > 1)

l即x % 1 < 0.5, 且x>1
m即y % 1 < 0.5, 且y>1

l = [True, False, True, False, False, True, True, False]
m = [True, False, True, True, True, False, False, False]

(gxi > 1) & (gxi % 1 < 0.5)

一、 yolo v5解读

（四）、正样本采样细节

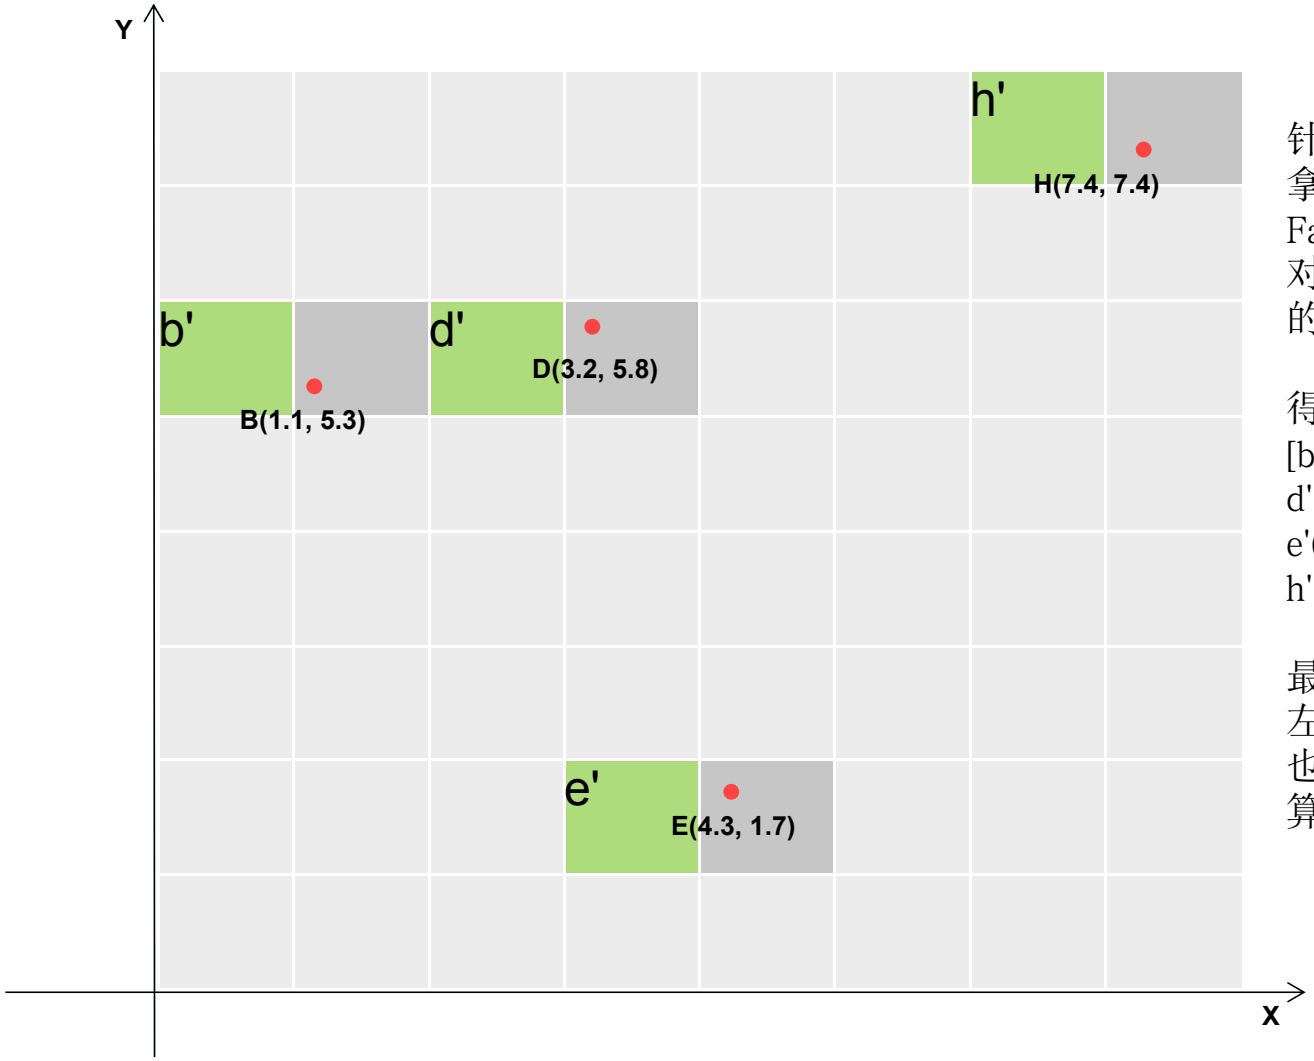

针对j做offset处理：
拿 j = [False, True, False, True, True, False, False, True]
对应的点， B, D, E, H ， 减去对应的offset[0.5, 0]

得到：
[b'(image_id, class_id, 0.6, 5.3, w, h),
d'(image_id, class_id, 2.7, 5.8, w, h),
e'(image_id, class_id, 3.8, 1.7, w, h),
h'(image_id, class_id, 6.9, 7.4, w, h)]

最终 b' d' e' h' 对应回原图位置如左边绿色部分， 也就是该些位置，也会作为ground truth数据用于计算损失.

一、 yolo v5解读

（四）、正样本采样细节

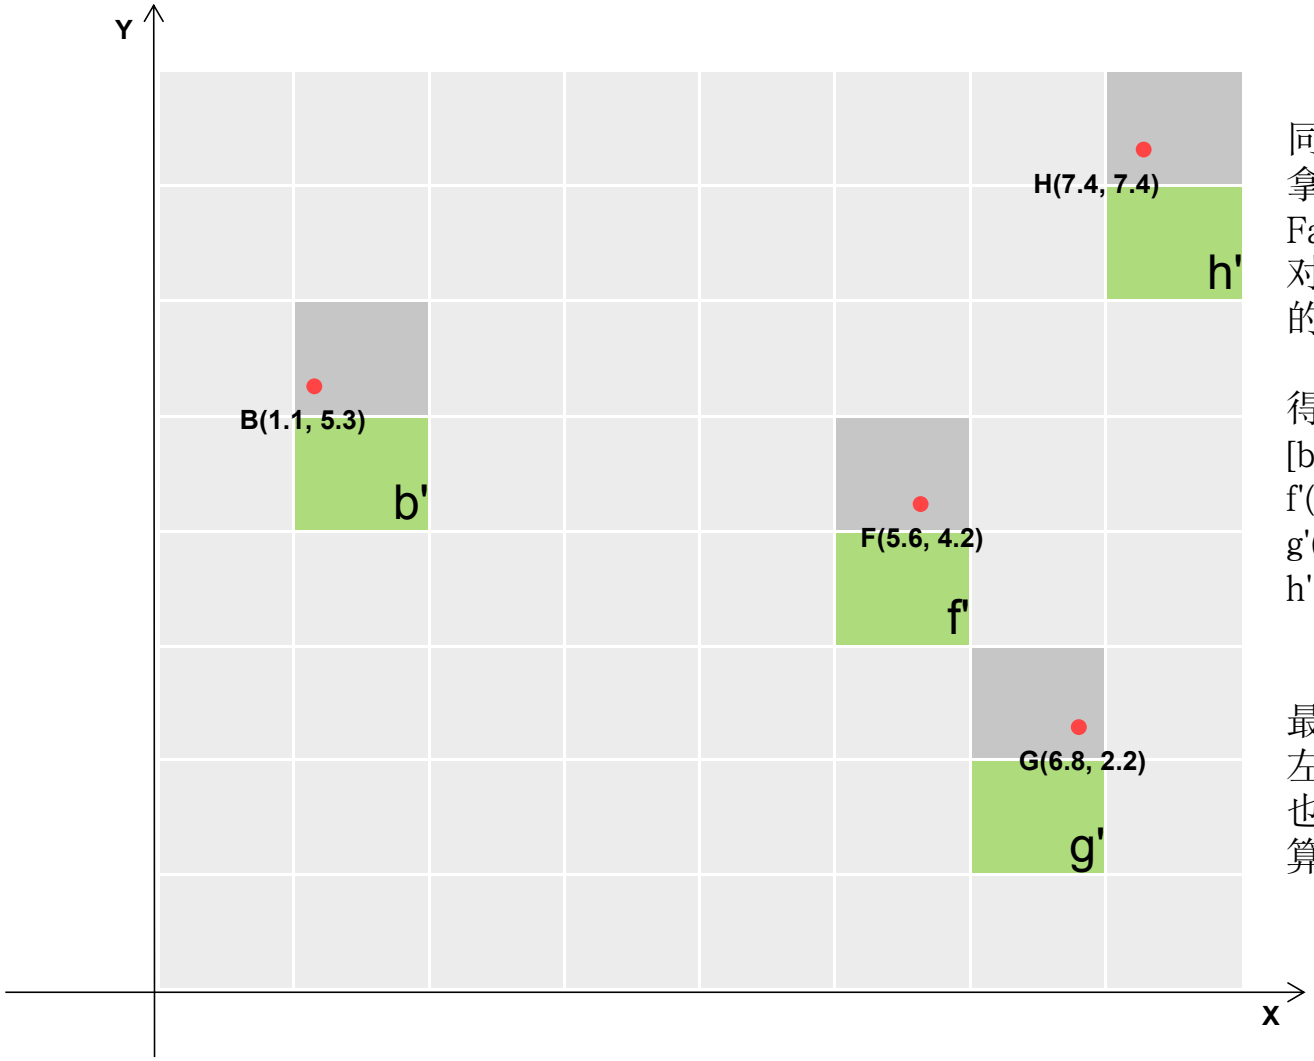

同理k做offset处理：
拿 k= [False, True, False, False, False, True, True, True]
对应的点， B, F, G, H ， 减去对应的offset[0, 0.5]

得到：
[b'(image_id, class_id, 1.1, 4.8, w, h), f'(image_id, class_id, 5.6, 3.7, w, h), g'(image_id, class_id, 6.8, 1.7, w, h), h'(image_id, class_id, 7.4, 6.9, w, h)]

最终 b' d' e' h' 对应回原图位置如左边绿色部分， 也就是该些位置，也会作为ground truth数据用于计算损失.

一、 yolo v5解读

（四）、正样本采样细节

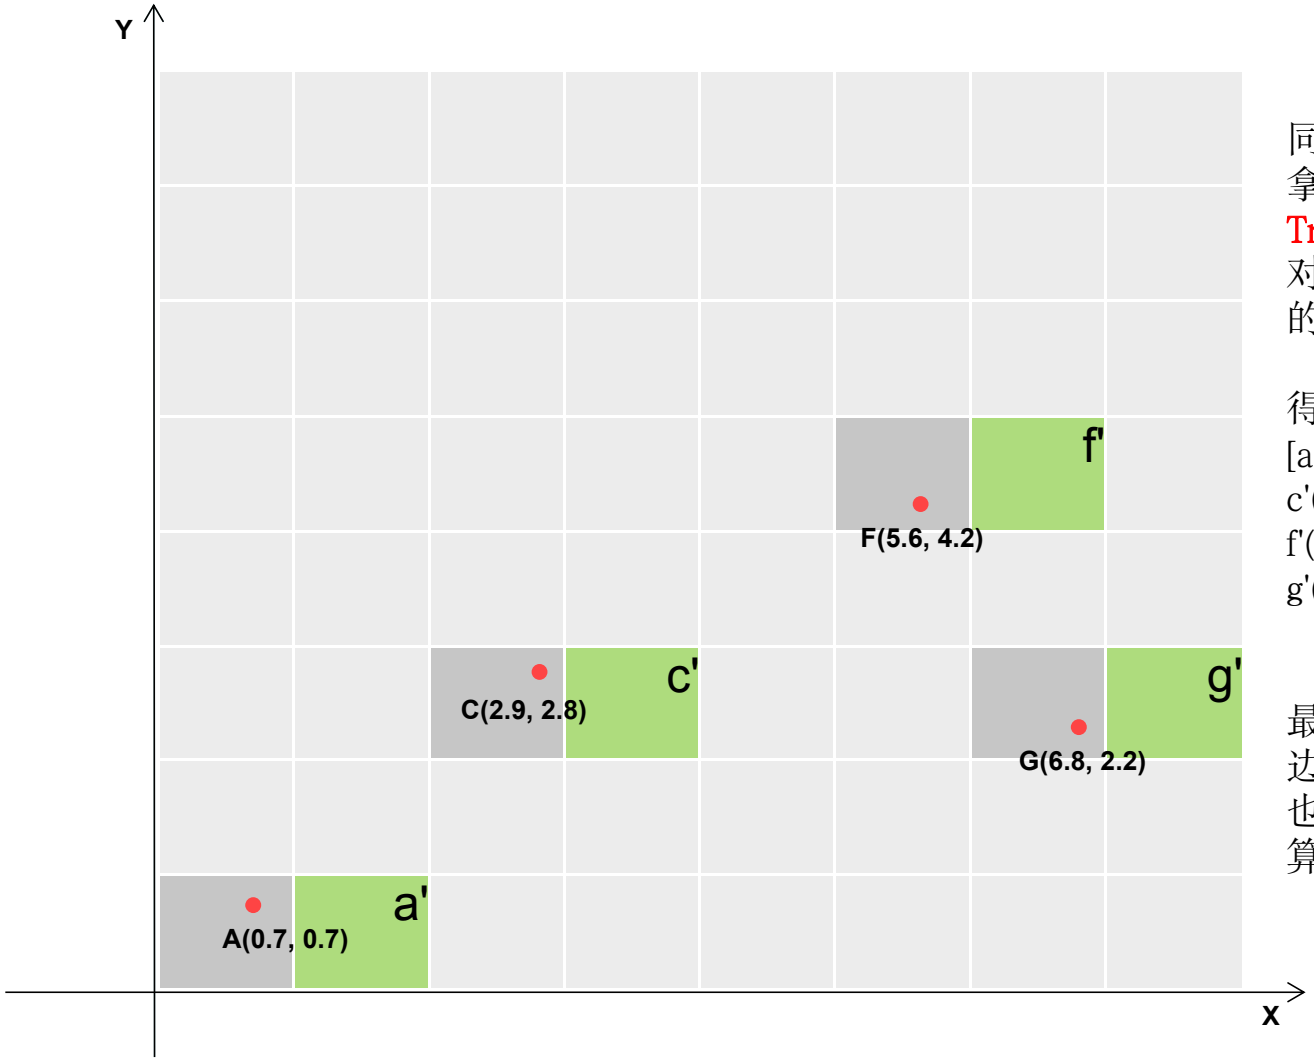

同理l做offset处理：
拿 l= [True, False, True, False, False, True, True, False]
对应的点， A, C, F, G ， 加上对应的offset[0.5, 0]

得到：
[a'(image_id, class_id, 1.2, 0.7, w, h),
c'(image_id, class_id, 3.4, 2.8, w, h),
f'(image_id, class_id, 6.1, 4.2, w, h),
g'(image_id, class_id, 7.3, 2.2, w, h)]

最终 a' c' f' g' 对应回原图位置如左边绿色部分， 也就是该些位置，也会作为ground truth数据用于计算损失.

一、 yolo v5解读

（四）、正样本采样细节

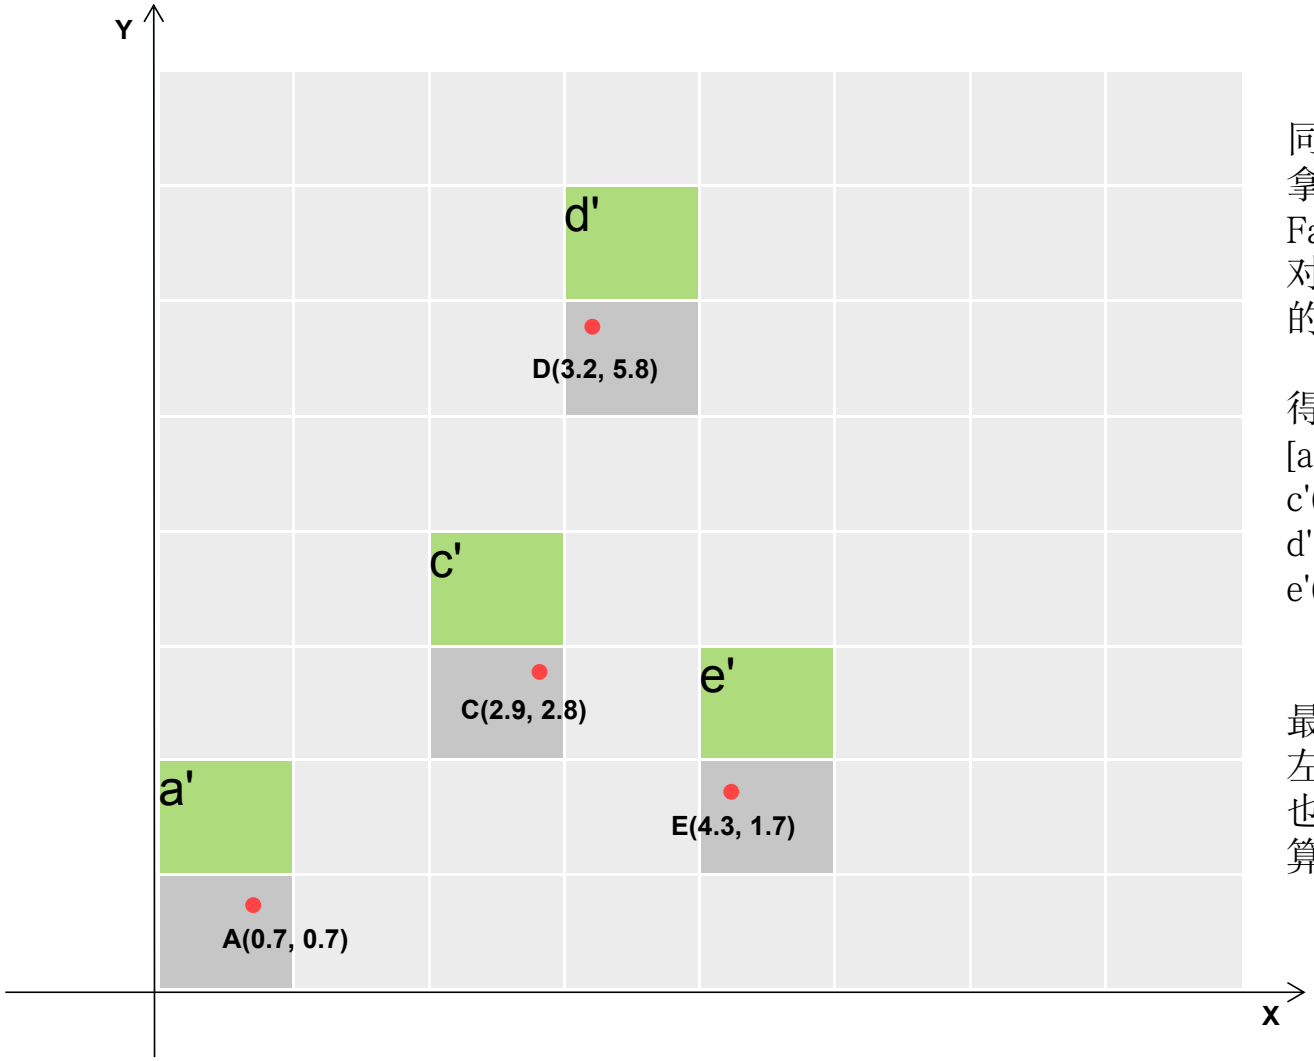

同理m做offset处理：
拿 m= [True, False, True, True, True, False, False, False]
对应的点， A, C, D, E ， 加上对应的offset[0, 0.5]

得到：
[a'(image_id, class_id, 0.7, 1.2, w, h),
c'(image_id, class_id, 2.9, 3.3, w, h),
d'(image_id, class_id, 3.2, 6.3, w, h),
e'(image_id, class_id, 4.3, 2.2, w, h)]

最终 a' c' d' e' 对应回原图位置如左边绿色部分， 也就是该些位置，也会作为ground truth数据用于计算损失.

一、 yolo v5解读

（四）、正样本采样细节

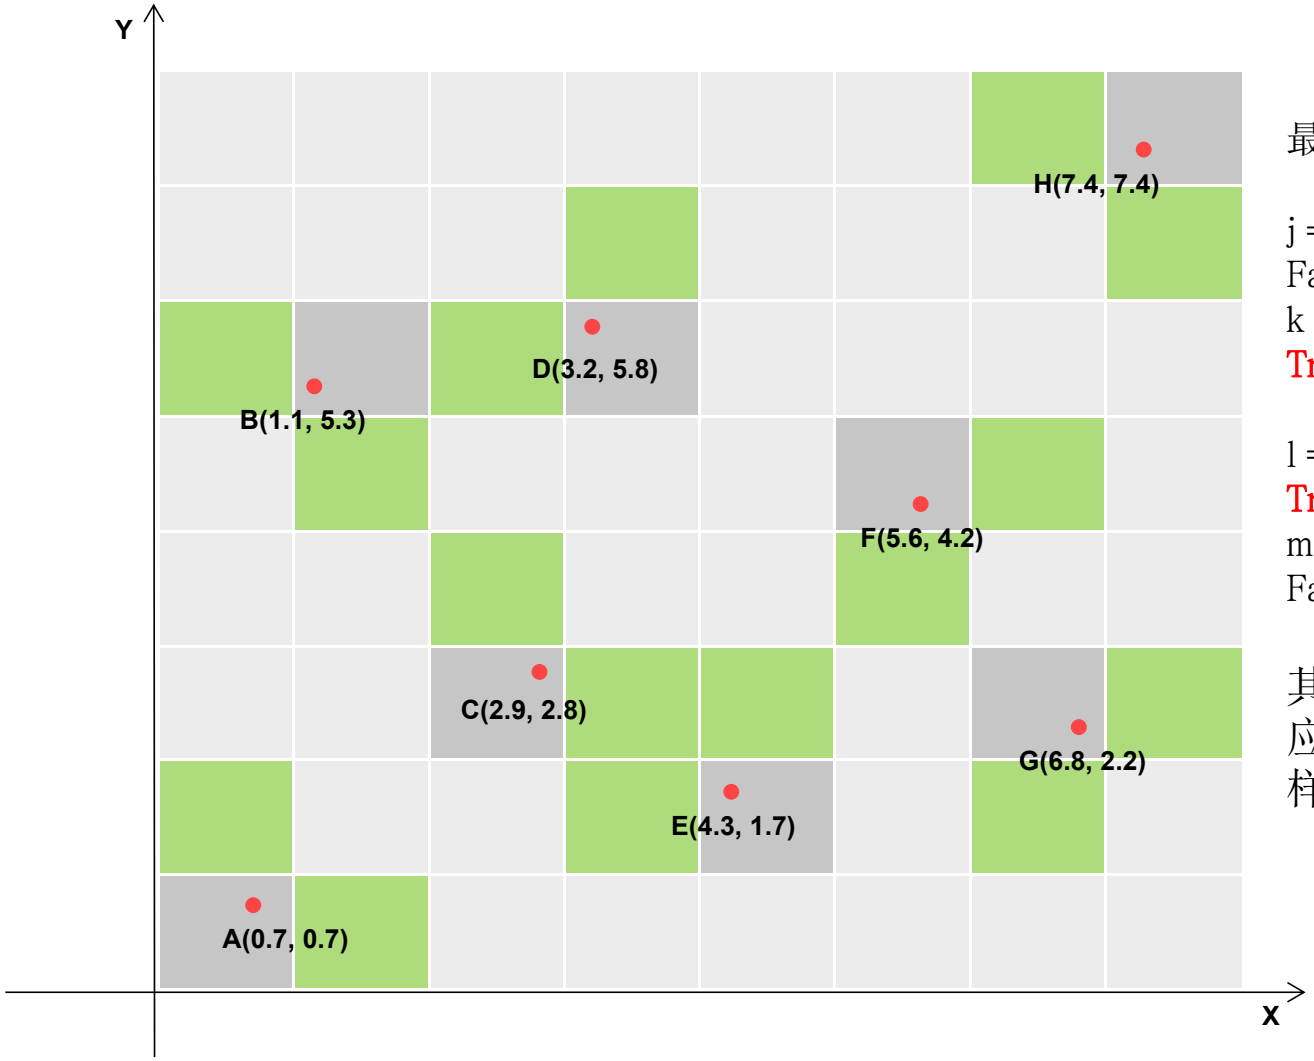

最终合并j, k, l, m:

j = [False, True, False, True, True, False, False, True]
k = [False, True, False, False, False, True, True, True]

l = [True, False, True, False, False, True, True, False]
m = [True, False, True, True, True, False, False, False]

其中深灰色即原ground truth对应边框数据，绿色为补充正样本边框数据。

一、 yolo v5解读

（四）、正样本采样细节

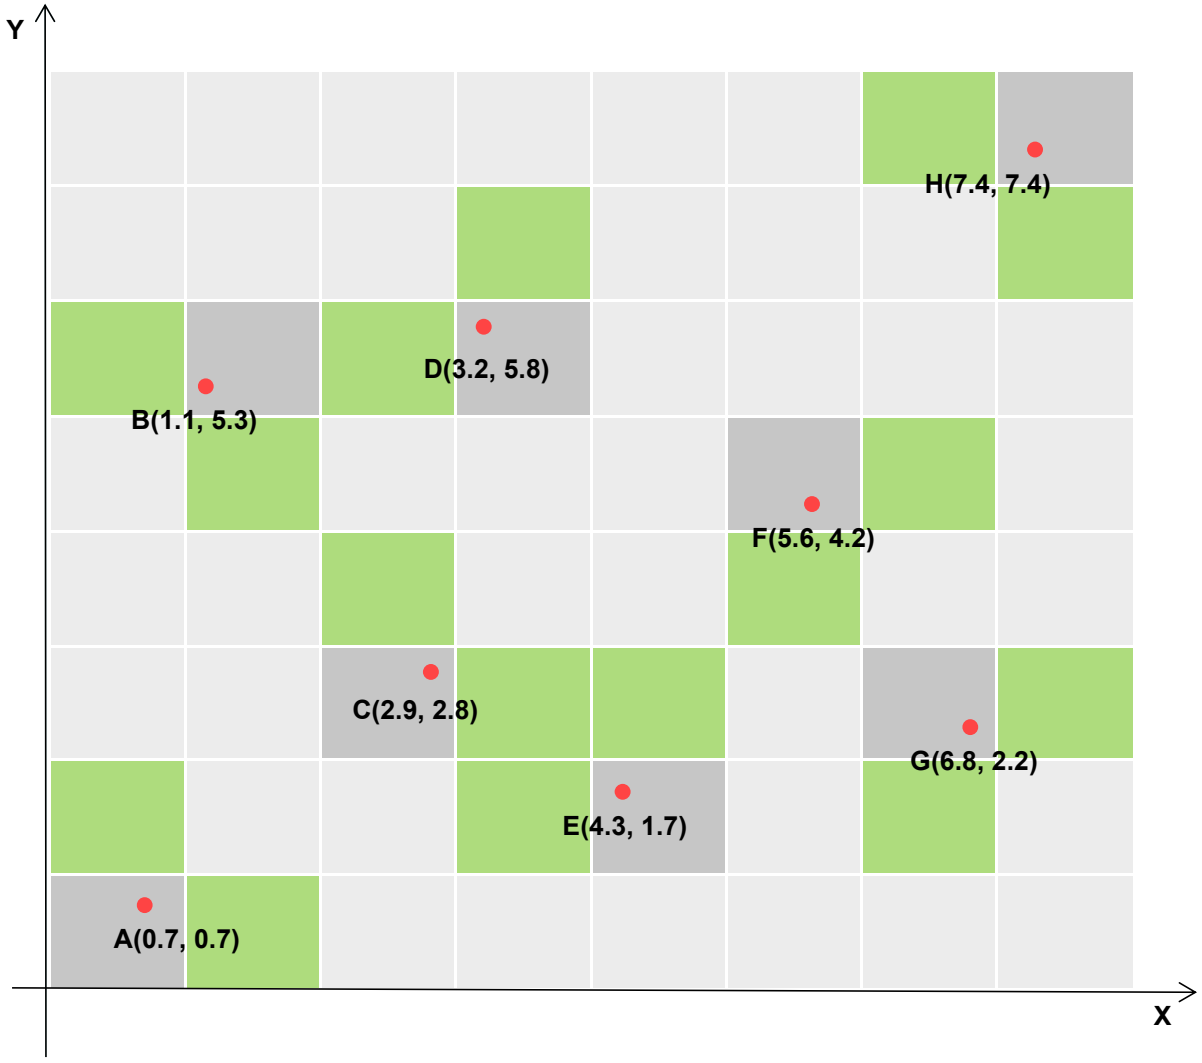

最后得到：

点 => 取整得到grid坐标 => 相减得到该grid的边框xy偏移量

A => grid(0,0) => (0.7,0.7) - (0,0) = (0.7, 0.7)
A^{up} => grid(0,1) => (0.7, 0.7) - (0,1) = (0.7, -0.3)
A^{right} => grid(1,0) => (0.7, 0.7) - (1,0) = (-0.3, 0.7)

B => grid(1,5) => (1.1, 5.3) - (1,5) = (0.1, 0.3)
B^{left} => grid(0, 5) => (1.1, 5.3) - (0, 5) = (1.1, 0.3)
B^{down} => gird(1, 4) => (1.1, 5.3) - (1, 4) = (0.1, 1.3)

C => grid(2,2) => (2.9,2.8) - (2,2) = (0.9,0.8)
C^{up} => grid(2,3) => (2.9,2.8) - (2,3) = (0.9,-0.2)
C^{right} => grid(3,2) => (2.9,2.8) - (3,2) = (-0.1,0.8)

D => grid(3,5) => (3.2, 5.8) - (3,5) = (0.2,0.8)
D^{up} => grid(3,6) => (3.2, 5.8) - (3,6) = (0.2,-0.2)
D^{left} => grid(2,5) => (3.2, 5.8) - (2,5) = (1.2,0.8)

E => grid(4,1) => (4.3, 1.7) - (4,1) = (0.3,0.7)
E^{up} => grid(4,2) => (4.3, 1.7) - (4,2) = (0.3,-0.3)
E^{left} => grid(3,1) => (4.3, 1.7) - (3,1) = (1.3,0.7)

F => grid(5,4) => (5.6, 4.2) - (5,4) = (0.6,0.2)
E^{right} => grid(6,4) => (5.6, 4.2) - (6,4) = (-0.4,0.2)
E^{down} => grid(5,3) => (5.6, 4.2) - (5,3) = (0.6,1.2)

G => grid(6,2) => (6.8, 2.2) - (6,2) = (0.8,0.2)
G^{right} => grid(7,2) => (6.8, 2.2) - (7,2) = (-0.2,0.2)
G^{down} => grid(6,1) => (6.8, 2.2) - (6,1) = (0.8,1.2)

H => grid(7,7) => (7.4, 7.4) - (7,7) = (0.4,0.4)
H^{left} => grid(6,7) => (7.4, 7.4) - (6,7) = (1.4,0.4)
H^{down} => grid(7,6) => (7.4, 7.4) - (7,6) = (0.4,1.4)

一、 yolo v5解读

（五）、损失计算细节 box loss

GIoU：《Generalized Intersection over Union: A Metric and A Loss for Bounding Box Regression》

$$\lambda_{coord}\sum_{i}^{S^2}\sum_{j}^{anchors}1_{ij}^{obj}\sum_{l\in[x,y,w,h]}(l_{ij}^{true}-l_{ij}^{pred})^2$$

$$IoU=\frac{|A\cap B|}{|A\cup B|}$$

$$\mathcal{L}_{IoU}=1-IoU$$

$$GIoU=IoU-\frac{|C\backslash(A\cup B)|}{|C|}$$

$$\mathcal{L}_{GIoU}=1-GIoU$$

左边是yolov3里用的L2损失，中间是传统的IoU及其边框损失表达式，右边是GIoU及其边框损失表达式

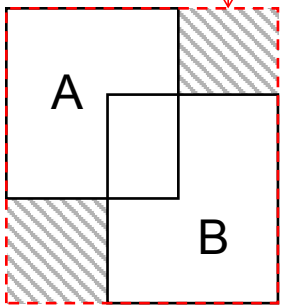

图1

1. GIoU在IoU的基础上考虑多了非交叉面积比例，如右图1红色虚线框就是A,B边框的最小包围框，灰色斜线面积占整个红色边框面积就是非交叉面积占比

2. 对比L2损失，IoU和GIoU具有尺度不变性，意味着当目标边框等比放大时，损失能依旧保持同样的量级，无需针对大小不同边框分别处理。

3. 对比IoU损失，L2和GIoU具有偏离趋势度量能力，如下图2，传统IoU=0时，边框距离的远近已经对最终损失都是一样，但是GIoU随着两个边框距离越远，表现得越接近-1，换算成损失就是越大，同样GIoU会驱使模型预测边框分布于真实边框的上下左右方向，对斜方向预测结果施加更大损失，如下图3.

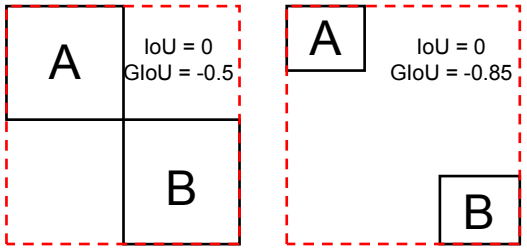

图2

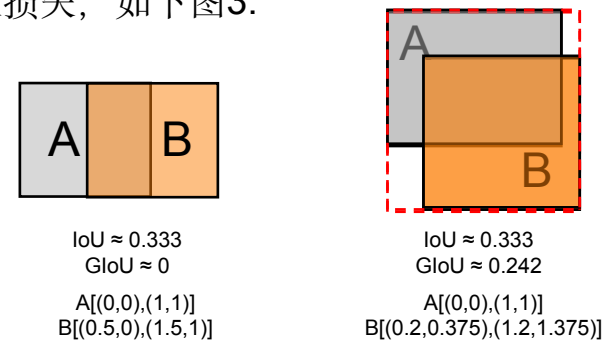

图3

一、 yolo v5解读

（五）、损失计算细节 box loss

DIoU：《Distance-IoU Loss: Faster and Better Learning for Bounding Box Regression》

$$\mathcal{L}_{DIoU} = 1 - IoU + \frac{\rho^2(\mathbf{b}, \mathbf{b}^{gt})}{c^2}$$

DIoU损失在1-IoU的基础上，增加了中心点距离占比惩罚项，其中惩罚项分子是预测边框中心点与真实边框中心点的距离，分母是预测边框与真实边框的最小包围框对角线长，如下图d和c：

1. 对比GIoU损失，DIoU能更好度量预测边框和真实边框的中心点距离和方向，表现如下图所示，绿色真实边框，红色预测边框，当预测边框与真实边框互相包含，或者互相垂直交叉，水平交叉，GIoU会退化成为IoU，从而失去非交叉占比的惩罚项，而DIoU依旧能为模型提供更好的梯度方向：

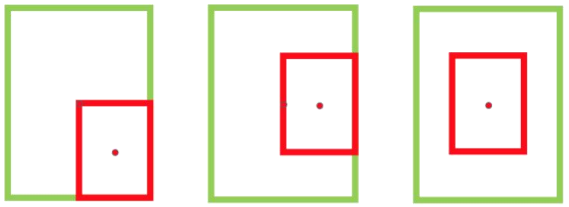

2. 与GIoU损失一样，DIoU也具有尺度不变性，意味着当目标边框等比放大时，损失能依旧保持同样的量级，无需针对大小不同边框分别处理。
3. 与GIoU损失一样，DIoU损失值域空间为[0,2]，当完美拟合损失0，当距离无限远且不交叉时，损失是2。

一、 yolo v5解读

（五）、损失计算细节 box loss

CIoU：《Distance-IoU Loss: Faster and Better Learning for Bounding Box Regression》《Enhancing Geometric Factors in Model Learning and Inference for Object Detection and Instance Segmentation》

$$\mathcal{L}_{CIoU} = 1 - IoU + \frac{\rho^2(\boldsymbol{p}, \boldsymbol{p}^{gt})}{c^2} + \alpha V$$

$$v = \frac{4}{\pi^2}(arctan\frac{w^{gt}}{h^{gt}} - arctan\frac{w}{h})^2$$

$$\alpha = \frac{v}{(1 - IoU) + v}$$

CIoU损失在DIoU的基础上，增加了宽高比惩罚项，其中v为真实边框与预测边框的宽高比损失，a为宽高比损失系数：

1. 对比DIoU损失，当预测边框和真实边框的中心点重合，CIoU具有更好的宽高拟合效果，如下图所示，预测边框与真实边框中心点重合，DIoU损失中的中心点距离惩罚项=0，DIoU损失退化成IoU损失，但是此时CIoU仍有宽高比损失惩罚，能进一步调整宽高比例：

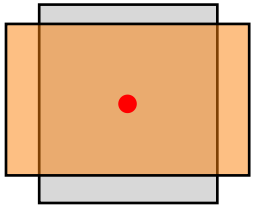

2. CIoU综合了IoU的交叉面积占比损失，DIoU的中心点偏移损失，以及自身宽高比损失3种度量优点。

一、 yolo v5解读

（五）、损失计算细节 box loss

CIoU：《Distance-IoU Loss: Faster and Better Learning for Bounding Box Regression》《Enhancing Geometric Factors in Model Learning and Inference for Object Detection and Instance Segmentation》

$$\mathcal{L}_{CIoU} = 1 - IoU + \frac{\rho^2(\boldsymbol{p}, \boldsymbol{p}^{gt})}{c^2} + \alpha V$$

$$v = \frac{4}{\pi^2}(arctan\frac{w^{gt}}{h^{gt}} - arctan\frac{w}{h})^2$$

$$\alpha = \frac{v}{(1 - IoU) + v}$$

原论文CIoU损失在实现上做了一点小调整，在求导时a作为常数项不参与梯度更新，只针对v里的w和h分别求导，会得到如下：

$$\frac{\partial v}{\partial w} = \frac{8}{\pi^2}(arctan\frac{w^{gt}}{h^{gt}} - arctan\frac{w}{h}) \times \frac{h}{w^2 + h^2},$$

$$\frac{\partial v}{\partial h} = -\frac{8}{\pi^2}(arctan\frac{w^{gt}}{h^{gt}} - arctan\frac{w}{h}) \times \frac{w}{w^2 + h^2}.$$

1. 其中w^2+h^2通常会由于w或者h太小而造成反向传播的时候梯度爆炸，所以原作者最初版本[1]的实现如下：

```
with torch.no_grad():
    arctan = torch.atan(w2 / h2) - torch.atan(w1 / h1)
    v = (4 / (math.pi ** 2)) * torch.pow((torch.atan(w2 / h2) - torch.atan(w1 / h1)), 2)
    S = 1 - iou
    alpha = v / (S + v)
    w_temp = 2 * w1
ar = (8 / (math.pi ** 2)) * arctan * ((w1 - w_temp) * h1)
cious = iou - (u + alpha * ar)
```

其中alpha和v均不参与梯度更新，只有ar处直接写成了求导形式，最后对w,h求导只会剩下h,-w,没有w^2+h^2

1.https://github.com/Zzh-tju/DIoU-SSD-pytorch/commit/36bb49bda7b7e818f7208e1fa918bd204531d0dd

一、 yolo v5解读

（五）、损失计算细节 box loss

CIoU：《Distance-IoU Loss: Faster and Better Learning for Bounding Box Regression》《Enhancing Geometric Factors in Model Learning and Inference for Object Detection and Instance Segmentation》

$$\mathcal{L}_{CIoU} = 1 - IoU + \frac{\rho^2(\boldsymbol{p}, \boldsymbol{p}^{gt})}{c^2} + \alpha V$$

$$v = \frac{4}{\pi^2}(arctan\frac{w^{gt}}{h^{gt}} - arctan\frac{w}{h})^2$$

$$\alpha = \frac{v}{(1 - IoU) + v}$$

在最新的CIoU[1]，实现上改为如下：

```
v = (4 / (math.pi ** 2)) * torch.pow((torch.atan(w2 / h2) - torch.atan(w1 / h1)), 2)
with torch.no_grad():
    S = 1 - iou
    alpha = v / (S + v)
cious = iou - (u + alpha * v)
cious = torch.clamp(cious,min=-1.0,max = 1.0)
```

其中同样的alpha不参与参数的梯度更新，只是作为一个常数，但是v的修改已经默认了不对w^2+h^2问题做额外处理，早期的版本虽然兼顾了w^2+h^2对最终梯度问题的影响，反向传播形式没变，但是正向表达式中的v变了，yolov5由于对wh有做进一步筛选，所以避免了w^2+h^2过小对梯度的影响。

1. https://github.com/Zzh-tju/DIoU-SSD-pytorch/blob/master/utils/box/box_utils.py#L85-L90

一、 yolo v5解读

（五）、损失计算细节 object loss

yolov5的object loss默认用的01二分类交叉熵：

```
# 这里直接拿CIoU作为预测的目标
score_iou = iou.detach().clamp(0).type(tobj.dtype)

# 这里其实self.gr最开始作者的设想是综合yolov2 v3 v4的做法，在目标概率1和CIoU之间做一个加权平均
# 后面就全部用CIoU了
tobj[b, a, gj, gi] = (1.0 - self.gr) + self.gr * score_iou

# self.BCEobj是nn.BCEWithLogitsLoss
obji = self.BCEobj(pi[..., 4], tobj)

# 由于yolov5最终预测3层，每层的object损失系数分别为:[4.0, 1.0, 0.4]
lobj += obji * self.balance[i]
```

假如object loss参数fl_gamma>0,会在object loss的基础上加一层focal loss，用于平衡正负样本损失差异

```
pred_prob = torch.sigmoid(pred)
p_t = true * pred_prob + (1 - true) * (1 - pred_prob)

# 这里alpha=0.25,gamma=1.25, 对于未正确分类的样本，会给予更高的权重
alpha_factor = true * self.alpha + (1 - true) * (1 - self.alpha)
modulating_factor = (1.0 - p_t) ** self.gamma
loss *= alpha_factor * modulating_factor
```

一、 yolo v5解读

（五）、损失计算细节 class loss

yolov5的class loss默认用的01二分类交叉熵：

```
# 这里的cn=0.05, cp=0.95是作者参考这篇论文做的类别平滑处理,
# 如果是多分类， cp = 1.0 - label_smoothing, cn = label_smoothing / num_classes
# 如果是01二分类，cp = (1.0 - label_smoothing), cn = 0.5 * label_smoothing
# 论文是直接处理成0/1二分类交叉熵，所以是下者
t = torch.full_like(ps[:, 5:], self.cn, device=device)
t[range(n), tcls[i]] = self.cp
lcls += self.BCEcls(ps[:, 5:], t)
```

```
# 假如object loss参数fl_gamma>0,会在object loss的基础上加一层focal loss，用于平衡正负样本损失差异
pred_prob = torch.sigmoid(pred)
p_t = true * pred_prob + (1 - true) * (1 - pred_prob)

# 这里alpha=0.25,gamma=1.25, 对于未正确分类的样本，会给予更高的权重
alpha_factor = true * self.alpha + (1 - true) * (1 - self.alpha)
modulating_factor = (1.0 - p_t) ** self.gamma
loss *= alpha_factor * modulating_factor
```

完结

欢迎关注b站：薛定谔的AI