

# 面向大规模地质统计甲烷监测的基于部件的目标检测

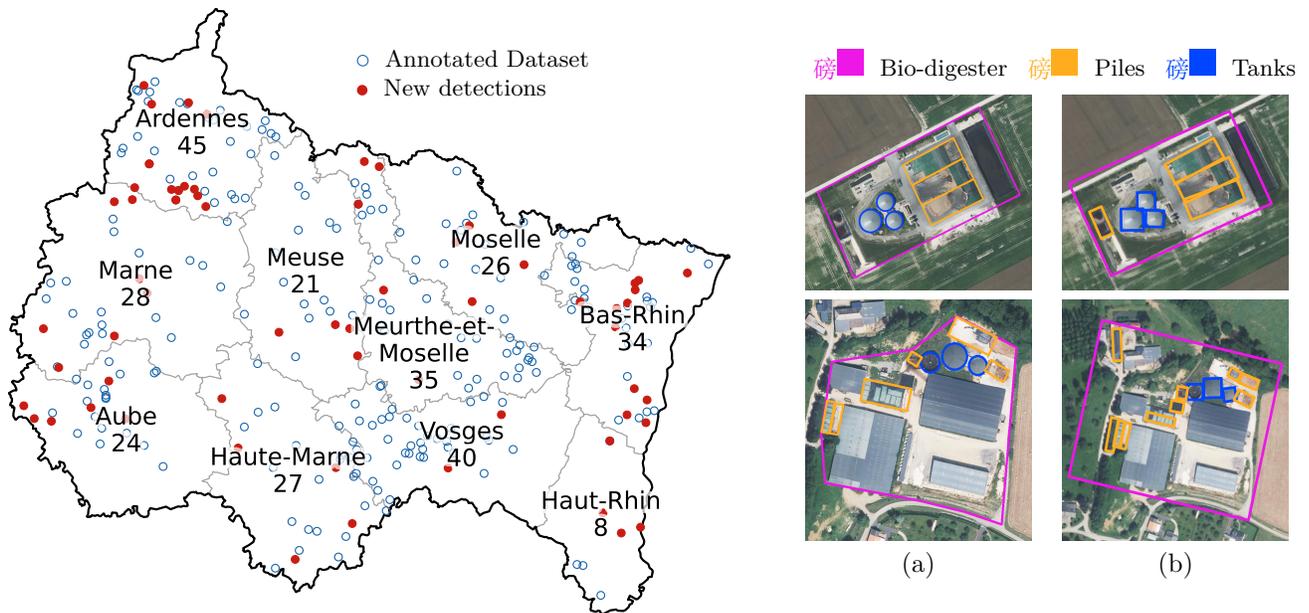
Adhemar de Senneville<sup>1\*</sup> Xavier Bou<sup>1\*</sup> Thibaud Ehret<sup>2</sup> Rafael Grompone<sup>1</sup>  
Jean-Louis Bonne<sup>3</sup> Nicolas Dumelie<sup>3</sup> Thomas Lauvaux<sup>3</sup> Gabriele Facciolo<sup>1</sup>

<sup>1</sup>Université Paris-Saclay, CNRS, ENS Paris-Saclay, Centre Borelli, France

<sup>2</sup>AMIAD, Pole Recherche, France

<sup>3</sup>Université de Reims Champagne-Ardenne, France

[adhemardesenneville.github.io/Large-Scale-Object-Detection/](https://adhemardesenneville.github.io/Large-Scale-Object-Detection/)



## Abstract

目标检测是计算机视觉在遥感影像中的主要应用之一。尽管其可用性不断增加，但遥感数据的巨大体量在大范围地理区域内检测稀有目标时构成了挑战。矛盾的是，这一普遍挑战对许多应用至关重要，例如大规模估算某些人类活动对环境的影响。在本文中，我们提出通过研究法国生物消化池的甲烷生成和排放来解决这个问题。我们首先介绍一个包含生物消化池的新数据集，其中有小规模的训练和验证集，以及一个在没有目标观测的情况下高度不平衡的大型测试集，因为这样的地点很少见。我们开发了一种基于部分的方法，该方法考虑了生物消化池的基本子元素以增强初始检测。为

\* These authors contributed equally

此，我们将我们的方法应用于新的、未见过的区域以建立生物消化池的清单。然后，我们计算某一地区在某一时间可归因于这些基础设施的甲烷产量的地统计估算。

## 1. 介绍

在 80 年期间，一分子甲烷 ( $CH_4$ ) 的全球变暖潜力大约是二氧化碳的 80 倍 [24]。由于其在大气中的寿命较短，并被估计为对近期全球气温上升的 30% 负有责任 [13]，减少  $CH_4$  的排放被认为是缓解近期气候变化的有效策略 [36]。

由于高光谱遥感数据的可用性不断提高，最近的努

力已经集中在检测和量化大型甲烷排放 [25–27]。这些方法已被证明对识别重大甲烷泄漏有效，使组织能够减轻其对气候变化的影响。然而，目前的大规模遥感仪器仅限于每小时数吨的大型排放者 [4, 7, 27, 40]，缺乏检测小型排放者的灵敏度。跟踪单个低排放者的贡献具有挑战性，但当汇总为区域估算时却有重要意义。这些排放者包括沼气厂、废水处理设施、小型社区垃圾填埋场以及油气井场。尽管大型甲烷生产设施的泄漏不可避免地会释放大量的甲烷  $CH_4$ ，但研究表明，小型地点相对于其生产而言往往有更高的甲烷损失 [22]。此外，最近的一项研究报告称，美国约有 70% 的油气甲烷排放来自低排放设施 [44]。小型来源的排放通常使用空中仪器进行测量。然而，空中活动代价高昂且范围有限，因此国家层面的汇总排放量是通过自下而上的方法和自我报告来推导，而不是直接测量。这些自下而上的甲烷清单通常不公开访问或不完整，这导致了偏差和少报。此外，它们缺乏捕捉排放演变所需的空间和时间分辨率。相反，遥感领域中的一些工作利用卫星图像的广泛覆盖来生成特定对象的大规模清单 [28, 33, 37]。这一过程称为对象清单化，它了解这些对象在大面积上的空间分布及其潜在的环境影响提供了宝贵的见解。受这一范式的启发，基于定位小型甲烷排放源的自下而上的方法，可以作为估算低排放者的大规模排放的可行替代方案。

基于这个想法，本文研究了农业沼气厂，这些厂通过厌氧消化有机废物（例如粪肥、农作物残留物和食物废弃物）将有机物转化为甲烷。随着每年沼气厂数量迅速增长，现有的生物甲烷生产库存很快变得不完整和过时。因此，这些设施累计产生的甲烷排放可能成为整体排放中的一个显著但监测不足的组成部分。

在此背景下，我们的工作开发了一种自下而上的方法，用于从有限且不完整的数据库中检测遥感图像中的小型沼气厂。然后，我们使用生成的大规模清单来估算总计的甲烷生产量，从中可以推断出潜在泄漏的比例。我们的方法引入了一种基于部件的概率后处理来控制大规模检测的精度，使我们能够迭代改进模型，并识别出法国更广泛、未注释区域的大量生物消化池。此外，我们探索了不同分辨率下的不同航空和卫星图像来源，并确定 SPOT 卫星数据在 1.5 米处作为性能和效率之间的最佳折衷。定性和定量实验证明了我们的模型在法国不同地区的泛化性。我们的贡献可以总结为：

- 我们提出了一种方法学，该方法学从具有稀疏空间分布的最小数据集入手，生成能够在全国范围内稳健检测生物消化器的模型。
- 据我们所知，我们发布了首个大型的生物消化器卫星数据集，其中包括设施和部件的标注。
- 我们证明了我们的方法和数据集可以用来识别以前未知的生物消化器站点，更新不完整的清单或生成新的清单。我们评估了我们方法在空间分辨率方面的限制，并提供了新发现的、未注释站点的可视化。最后，我们利用生物消化器的视觉特征来预测布列塔尼地区生物消化器的甲烷总产量。

## 2. 相关工作

**目标检测。**物体检测通过预测其周围的包围框来定位物体，通常由中心  $(x, y)$  坐标、宽度和高度定义 [57]。物体检测器还预测每个检测的类别标签和置信度分数。深度学习的最新进展已经在物体检测方面取得了重大改进 [47]。像 Faster R-CNN 这样的两阶段检测器首先提出物体区域，然后对其进行分类 [10, 12, 31]，通常在牺牲速度的情况下提供更高的准确性。相比之下，一阶段检测器在一个步骤中执行定位和分类，使得大规模图像推断更快 [6, 18, 41, 55]，YOLO 系列是其中最突出的 [17, 29, 30, 42, 43]。在遥感中，经常使用定向边界框 (OBB) 来更准确地封闭物体 [38, 46, 51]。OBB 通过添加一个角度参数来扩展传统的边界框，该参数指定它们的旋转以更好地与物体方向对齐。因此，许多作品已经适应物体检测架构以结合方向回归。Oriented R-CNN [48] 通过引入对角度敏感的区域建议网络和专门的边界框回归来扩展 Faster RCNN 的两阶段检测器，以准确定位任意方向的目标。最近，LSKNet [20] 采用了大选择核机制并增强了多尺度特征提取，提升了航拍图像物体检测性能。Ding 等 [5] 适配了用于定向物体检测的变换器架构，还有一系列其他研究从架构角度提出改进定向物体检测 [11, 41, 49, 52]，或缓解角度回归任务带来的边界问题 [2, 23, 50, 53, 54, 56]。随着遥感影像的日益普及，大量未标记的数据已为其使用做好准备。然而，标记数据既昂贵又耗时。幸运的是，已经提出了许多遥感数据集，推动了在目标检测问题上的重大研究努力。众所周知的大量数据集，如 DOTA 或 DIOR，包含了广泛的类别，例如汽车、网球场或直升机。这些数据集通常用于在微调较小的遥感数据集之前对模型进行预训练，从而引入航拍视角信息。然而，由于卫星图像的特性，这些基准测试包含臭名昭著的类别不平衡，我们经常在所有数据集中看到相同的类别。为了解决这个问题，其他研究提出了专注于不常见或细粒度目标类别的数据集。SIMD 数据集包含不同类型的飞机和车辆，例如螺旋桨飞机、巴士或教练机。Sun 等人引入了一个污水处理厂数据集，包含一个类别：污水处理。这些形状各异，但更重要的是它们由特定的辨别元素构成。宁波铁塔数据集在大量复杂背景中引入了稀疏分布的铁塔观察。这很接近于在现实生产环境中搜索自然实例的模型。部分基于对象检测模型将对象表示为多尺度可变形部分模型的混合体，其中每个部分捕捉局部外观特征，它们的空间关系通过约束进行建模。这种方法允许在姿势和遮挡变化下对对象进行鲁棒检测。尽管如今深度学习方法已经超越了传统的部分基模型，但其核心理念已被集成到最近的深度学习模型中。DPM-CNN 将可变形部分基模型与卷积神经网络相结合，用学习的 CNN 特征提取器取代了 DPM 中使用的标准图像特征。Part R-CNN 通过结合显式部分基推理来扩展基于区域的 CNN，细化定位并实现精细识别。PBNet 将部分基检测概念扩展到深度学习，以处理遥感中的复杂对象，这些对象具有多样的形状和大小。这种方法在检测由较小可检测

部分组成的对象时显得尤为重要。**物品清单** 一些研究旨在通过航拍或卫星影像建立特定物体的大规模清单以进行环境监测。例如, [39] 通过使用 OpenStreetMap 进行大规模众包创建数据集, 解决了对小型太阳能阵列的文档记录不足问题。另一方面, 深度学习方法使得对广阔地理区域的高效分析成为可能。Robinson 等人 [33] 提出了一种基于深度学习的方法, 从航拍图像中检测家禽舍, 生成了一个开源的国家级家禽数据集。他们证明了该模型在大规模环境监测中的潜力。同样, Ramachandran 等人 [28] 在高分辨率卫星图像上提出了一种两阶段深度学习流程, 以检测油气井台和储罐。他们识别了超过 70,000 个未映射的井台和超过 169,000 个储罐, 并展示了用于改进甲烷排放监测的自动化、国家级基础设施映射的潜力。更近期, Robinson 等人 [34] 使用类似技术和 OpenStreetMap 作为标签, 构建了一全球商业太阳能光伏农场和陆上风力涡轮机的时空数据集。据我们所知, 目前尚未尝试过对小规模甲烷生产地点如生物反应器进行清单整理。在这一方向的工作可帮助大规模的甲烷排放监测, 通过对小型排放源的空间和时间跟踪支持可持续性努力。

X This work strives for generalizable bio-digester detection from a limited set of annotations. To this end, we construct an initial small-scale dataset based on a few previously identified sites in France's Grand Est region. 我们从 DB ORTHO [14] 中提取图像, 这是一个由法国国家地理和森林信息研究所 (IGN) 获取的 RGB 正射影像集, 每像素分辨率为 20 厘米。我们将图像重采样至 50 厘米/像素, 并生成  $1024 \times 1024$  的切片。在我们的空间分辨率实验中, 我们考虑了另外两个图像来源, 即商业卫星 RGB 产品 SPOT6/7 [15], 分辨率为每像素 1.5 米, 以及提供每像素 10 米图像的低分辨率平台 Sentinel-2。真实标签以地理定位的分割注释形式提供。对于每个生物反应器, 我们注释了三种不同的类别: 整个生物反应器装置、(厌氧) 消化罐和生物质堆 (原料存放区域)。后两者是生物反应器站点内较小的结构, 对于确认站点的存在至关重要。图 2 展示了一个示例站点及其注释, 适用于 BD ORTHO (航空)、SPOT 和 Sentinel-2 数据源。

我们生成了包含 163 个和 40 个样本的训练集和验证集。我们还引入了 400 张背景图像, 即没有生物消化池的图像, 这些图像是随机选择并手动验证的, 以确保它们包含的建筑物不是生物消化池。稀释参数  $\alpha$  代表图像集中非背景瓦片的比例。通过用背景图像稀释注释的验证样本, 我们可以获得更现实的有关检测器产生的误报数量的概念, 尤其是因为我们没有用大量样本进行训练。此步骤对于更好地控制我们模型的性能和我们消融研究的相关性是至关重要的。

此外, 我们生成了一个测试集, 以解决在大规模区域中寻找新样本的能力。为此, 我们收集了覆盖整个马恩省的 5096 张图像, 这个省是法国的 101 个省之一。我们知道, 马恩省最初有 21 个生物反应器。图 3 展示了训练集和验证集的地理空间分布, 而表 1 则提供了本研究中使用的数据集划分的概要。

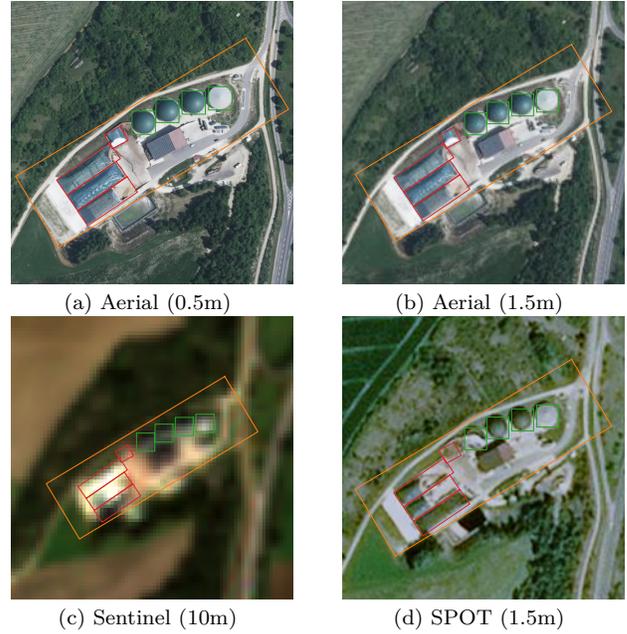


Figure 2. 航空和卫星数据集的示例及其标注。(a) 和 (b) 分别对应于重新取样为每像素 0.5 米和 1.5 米的 BD ORTHO 图像。Sentinel-2 (c) 和 SPOT (d) 图像显示在底部。

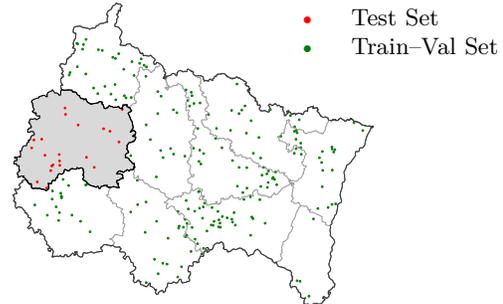


Figure 3. 法国大东部大区地图。测试集的位置以红色标出, 仅出现在马恩省。训练-验证集的位置以绿色标出, 位于大东部大区的其他地方。

Dataset	Number of Images	Annotated vs Background Tiles	$\alpha$
Training	326	163 vs 163	50 %
Validation	440	40 vs 400	9.1 %
Test - Marne	5096	27 vs 5069	0.53 %

Table 1. 研究中使用的拟议生物消化池数据集的总结以及不同集中标注瓦片  $\alpha$  的比例。请注意, 在测试环境中, 27 个瓦片包含 21 个生物消化池 (由于瓦片重叠, 一些地点出现在多个瓦片中)。

**大规模数据集。** 在这项工作中, 我们迭代检测并手动验证以前未标记区域中的生物沼气池站点, 识别出现有

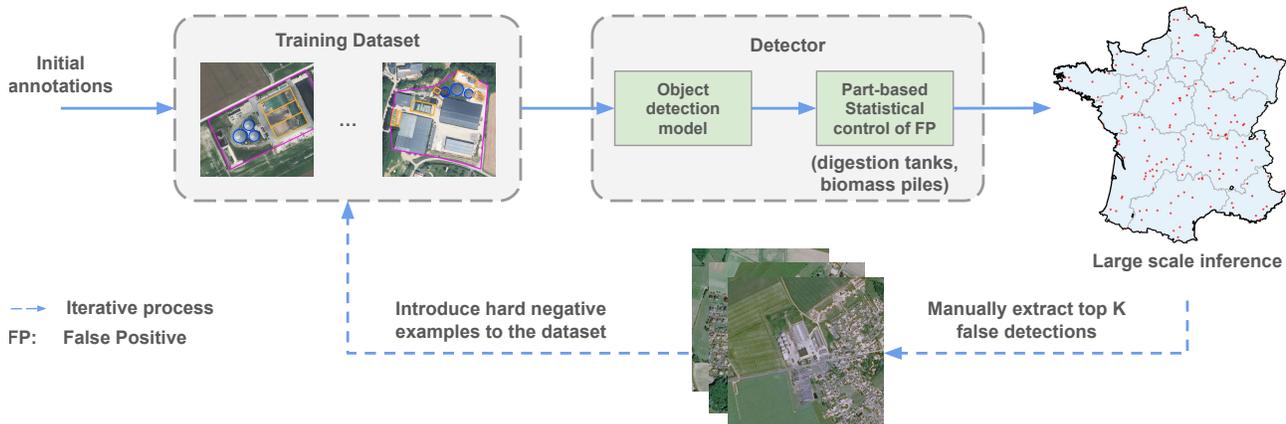


Figure 4. 所提出方法的一般图示。首先用最初标注的数据集训练传统的目标检测网络。然后，我们应用基于部分的统计方法来原因提高检测性能，使大规模检测变得可以承受。随后，进行一个迭代过程，其中 1) 将训练好的检测器应用于较大、不同区域，2) 手动验证和加入数据集的前  $K$  个检测。然后对得到的较大数据集进行相同的过程。

数据库中缺失的新建站点。此外，作为迭代优化的一部分，我们引入了硬负例，即倾向于错误检测的例子，以便网络学会忽略它们。结果，我们构建了据我们所知第一个大规模的生物沼气池检测数据集。我们坚信这可以推动该领域的发展，并支持未来关于低排放源甲烷估算的研究。生成的数据集包括未在大东和布列塔尼地区标记的新检测，以及 200 个硬负例样本。更多关于最终数据库及其过程的信息在第 4 节中提供。

### 3. 方法

我们旨在从有限的注释集中训练一个模型，该模型能够在不同的区域之间进行泛化。为此，我们的方法首先在可用的注释集上训练一个传统的目标检测器。然后，我们利用已注释的部分来区分真阳性和假阳性，并减少错误检测的数量。最后，我们在大型未注释区域上迭代应用检测器，并手动将最有信心的假阳性加入到数据集中以提高鲁棒性，并反复进行训练过程。图 4 说明了这一过程，每个步骤将在接下来的段落中详细介绍。

我们首先在第 ?? 节中描述的初始标注数据集上训练一个物体检测器。为此，我们在包含大量卫星图像的 DOTA [46] 上对网络进行预训练。然后，我们微调模型以预测在生物消化器数据集上标注的三种不同类别——现场本身、消化罐和生物质堆。我们考虑了几种架构，并在第 4 节中对它们进行了比较，即 YOLOv8 [16]、Faster R-CNN [31]、Oriented R-CNN [48] 和 LSKNet [19]。我们将这种简单的监督模型设置为检测基线，在对大区域进行推理后，我们提取所有满足预定义置信度阈值的生物消化器检测结果。自然地，在这种低数据情况下，低阈值会导致高召回率和低精度，而高阈值会导致良好的精度和低召回率。尽管检测器在验证集上表现相对较好，但在大区域中，由于背景图像的数量和未见过的物体的存在，误报数量

会增加。因此，我们利用生物消化器站点的重要部分，并借鉴基于部分的模型 [8]，提出去除误报。在本节中，我们使用部件检测器以提升最终检测器的性能。尽管每个检测器独立地产生大量的误报，但将这些类似的弱检测器结合在一起形成一个统一的强分类器，如在 boosting [9, 35] 中，可以改善检测性能。人类自然地通过首先发现潜在候选物，然后通过检查特征部分（如图 1 中的罐和堆）来确认，从而识别出细粒度的物体，如生物消化器。遵循这一直觉，我们基于在检测到的生物消化器中是否存在这些部分来定义检测信心。具体来说，

设  $\mathbf{p} = (p_1, p_2, \dots, p_{N_{max}})$  为某个对象类别的所有检测概率的向量，其中  $N_{max}$  是给定生物消化槽地点内提取的该类别检测总数。设  $\mathbf{p}_t$  和  $\mathbf{p}_p$  分别为储罐和堆的检测概率向量， $N_t$  和  $N_p$  分别表示检测到的储罐和堆的数量。从中我们可以计算出在生物消化槽地点内存在  $N_{object}$  的概率—其中对象是储罐或堆—如下

$$p(N_{object} = N | \mathbf{p}_{object}) = \sum_{\substack{I \subseteq \{1, \dots, N_{max}\} \\ |I| = N}} \prod_{i \in I} p_i \prod_{j \notin I} (1 - p_j). \quad (1)$$

在方程 (1) 中，我们假设每一个检测被建模为成功概率为  $p_i$  的独立伯努利试验。因此，给定检测概率向量  $\mathbf{p}_{object}$  情况下观测到恰好  $N$  个真实检测的概率，可以通过对所有成功（概率为  $p_i$ ）和失败（概率为  $1 - p_i$ ）组合进行求和来计算。

然后，我们估计生物消化器内坦克和堆积物数量的先验分布。图 5 显示了训练数据中每个地点坦克和堆积物的直方图。数据集中的所有生物消化器至少包含一个坦克，其中三辆坦克最为常见。我们近似估计给定检测到的坦克数量  $N_t$  和堆积物数量  $N_p$  时，某个地点是生物消化器的概率  $p(D | N_t, N_p)$ 。为此，我们考虑两种方法：(a) 使用双变量泊松分布进行建模，以及 (b) 在假设独立性（因为这两个变量表现出低相关性）

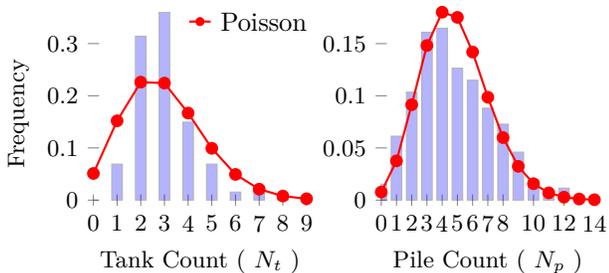


Figure 5. 训练集每个站点上的消化池和生物质堆数量的直方图。

的情况下使用经验直方图。

给定一个检测和一定数量的罐体和堆积物，我们现在可以估计该检测是一个生物消化池的概率，其中  $p_b$  是生物消化池检测的置信度。根据全概率定理，检测得分  $p(D|\mathbf{p}_t, \mathbf{p}_p, p_b)$  计算为

$$p(D|\mathbf{p}_t, \mathbf{p}_p, p_b) = p_b \sum_{N_t, N_p \geq 0} p(N_t | \mathbf{p}_t) \cdot p(N_p | \mathbf{p}_p) \cdot p(D | N_t, N_p), \quad (2)$$

，对应于在观察到的生物消化池、罐体和堆积物得分的情况下，检测的总体概率。请注意，可以在应用检测阈值后统计罐体和堆积物的数量；然而，这会为我们的检测流程增加一个难以调节的参数。

**迭代改进。**生物消化器地点在视觉上与其他结构（如工业区、石油储存区域或农场）相似。这导致了较高的假阳性率，降低了检测的可靠性。尽管起始标注有限，大量未标记的地区可以用来获取新样本。因此，我们使用预训练模型和基于部分的统计假警报检测器，通过假阳性检测来改进检测器。借鉴 [34] 的灵感，我们通过人工检查置信度最高的  $K$  个检测，识别出大面积土地上的高置信度假阳性检测。这些难例在每次迭代时作为新的背景加入训练集，而无需任何标注。同样地，在每次迭代时也建立一个新的更困难的验证集，以评估与这些挑战性例子的对抗。引入这些自信的假阳性（也称为难负例）应该使检测器对挑战性观察更加健壮，并提供更现实的方法性能评估。

此外，我们考虑了增加野外检测的正确实例以增加训练场所的数量。然而，早期实验表明，由于大多数生物降解器场所的视觉特征相似，添加已经符合学习分布的新正例所提供的益处有限。相反，教导网络识别哪些不是生物降解器被证明是一种更具影响力和成本效益的替代方法。

我们总共进行 3 次迭代，包括第一次初始训练。每次我们检查测试集中所有未标记的检测，并将最有信心的  $K = 100$  个误报引入训练集。

## 4. 实验

**实现细节。**鉴于生物质堆的延伸和紧密排列的特性，我们除了传统的目标检测器外，还考虑使用定向目标检

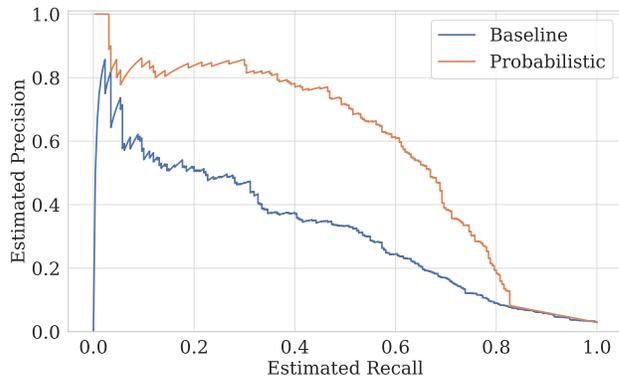


Figure 6. 不同检测方法在整个大东部地区的精确率-召回率曲线。基线方法（蓝色）表现最差，而概率部件方法（橙色）显著提高了性能。

测器。这样，对于对角线安排的重叠检测，非极大值抑制的问题就变得不那么麻烦。我们在 100 个周期上训练我们的模型，使用批量大小为 2 的 Adam 优化器 ( $\beta_1 = 0.9$ ,  $\beta_2 = 0.999$ ,  $\epsilon = 1e-8$ )，权重正则化为 0.0001。我们应用的数据增强包括水平、垂直和对角线翻转。对于每个模型，我们使用学习率调度程序和原始实现中的损失配置。基于我们的实验，我们选择 LSKNet 作为我们的最终目标检测器。所有实验均在单个 NVIDIA P5000 GPU 上进行。

**指标。**生物降解反应器地点通常缺乏精确的空间边界，使得传统的 IoU 阈值不适合评估。标准的基于 IoU 的指标经常错误分类正确的检测，特别是当外围结构如建筑物在检测边界框内被可变地包含或排除时。我们改用基于距离的规则：如果检测的中心位于任何标注地点的 200 米以内，则视为真正的正例。这个阈值对应于在我们的数据中观察到的正例的最大偏移量。如果在非极大值抑制之后一个地点被多次检测到，我们视其为一次检测。

$AP_{dist}$  然后是指使用基于距离的匹配标准而不是标准 IoU 阈值计算的平均精度。为了评估给定类别的检测器，我们报告标准的基于 IoU 的指标  $AP_{50}$ ，即在 IoU 阈值为 0.5 时的平均精度。我们选择 0.5 的阈值，因为与检测该对象相比，精确定位给定对象对我们的分析并不是至关重要的。另外， $mAP_{50}$  是所有类别的平均精度的均值。我们提取了整个 Grand Est 地区的 BD ORTHO 航空数据，将其重采样至 1.5 米，并使用我们的模型进行推断——在大约 5 小时内处理了超过 36000 张图像。平均精度曲线如图 6 所示。如图所见，基于部分的统计方法显著提高了性能。我们观察到在低召回率时精度存在差异。在检查误报情况时，我们发现大约 63 个生物消化器站点未在我们的数据库中记录，这占到了我们检测的 25%。新发现的生物消化器的地理空间分布在图 1 中以红色显示，蓝色代表先前已知的位置。

为了评估我们方法的泛化能力，我们选择了法国的

Region	In-Database			Overall		
	TP	GT	Recall	Correct	Total	Precision
Grand Est	188	224	83.9 %	251	311	80.7 %
Marne	18	21	85.7 %	28	36	77.8 %
Bretagne	96	179	53.6 %	131	185	70.8 %

Table 2. 在马恩省、大东部大区 and 布列塔尼次区域的检测结果。结果被分为数据库内（现有的真实数据）和总体检测结果，包括新的发现。精度和召回率是通过确认的匹配来计算的；总体计数包括参考数据库之外的检测。

Method	Probability Law	$AP_{dist}$	Max Recall at 100 % Precision
Baseline		0.949	62.5 %
Part-based	Poisson	0.917	62.5 %
Part-based	Histogram	0.969	95.0 %

Table 3. 对降低误报率的拟议方法进行消融研究。我们根据平均精度 ( $AP_{dist}$ ) 和在 100 个 % 精度下的最大召回率来报告它们的影响。

两个在训练中未使用的区域：马恩和布列塔尼。马恩区域包括 21 个已知的生物反应器，其中 18 个被正确识别，3 个被遗漏。此外，检测到了 10 个在参考数据库中不存在的新地点，这表明模型具备超越已知数据的泛化能力。此外，布列塔尼以其丰富的生物消化站点而闻名，并且有一个公开的数据库可用 [1]。我们观察到召回率的性能有所下降；然而，结果仍然具有相关性，精度为 70%，并且在该区域有 35 个数据库外的正确检测。这些结果在表 2 中总结，显示了从大东部训练区域到法国其他两个区域的泛化能力。

**基于部件的检测。**我们对所提出的基线和基于部件的方法进行消融，以尽量减少错误检测数量。为此，我们在表 3 中提供了验证集每种情况的结果。尽管泊松分布考虑了变量之间的相关性，但使用经验直方图来近似概率分布可以获得更好的结果。利用经验分布的基于部件的方法显著提升了不依赖于罐和堆部件检测器的基线检测效果。因此，我们在大规模实验中使用了该方法。

我们对不同空间分辨率的多个遥感源的检测可行性进行了研究。为此，我们分别使用 0.5 米和 1.5 米的航空 BD ORTHO 影像、SPOT (1.5 米) 以及 Sentinel-2 (10 米) 来训练我们的模型。结果如表 4 所示，由于分辨率和域转移的问题，与 0.5 米的航空数据相比，SPOT 的性能显著下降。首先，较低的分辨率降低了小目标（如坦克和堆积物）在显而易见的大小。其次，从 IGN 数据转移过来的标注会引入时间不一致的问题，未标记的结构会出现，而其他的则消失。然而，SPOT 的结果与 1.5 米/像素的 BD ORTHO 相差不远。由于 SPOT 卫星数据更易获取且更易处理，它在性能与效率之间提供了一个合理的折中。然而，对于许多对象，使用

	$mAP_{50}$	Site	Pile	Tank	$AP_{dist}$	Recall	Precision
Aerial (0.5m)	0.75	0.68	0.58	0.98	0.97	97.5 %	97.5 %
Aerial (1.5m)	0.61	0.76	0.17	0.89	0.93	95.0 %	95.0 %
SPOT (1.5m)	0.58	0.76	0.13	0.85	0.92	90.0 %	97.3 %
Sentinel (10m)	0.10	0.30	0.00	0.00	0.49	42.5 %	85.0 %

Table 4. 不同图像来源中最佳目标检测模型的性能。召回率和精度在使用基于距离的匹配计算的最佳 F1 分数下计算。

Iteration	Known Database Size	New Detection	Hard Negatives
0	203	-	0
1	203	149	100
2	352	205	200

Table 5. 数据集在迭代中的演变。已审查的 top-N 检测的总结，显示每次迭代中已知实例、新检测和难负样本的数量。

Iteration	$mAP_{50}$	Site	Pile	Tank	# Background	$\alpha$
0	0.26	0.52	0.11	0.14	163	50 %
1	0.29	0.66	0.06	0.16	263	38 %
2	0.59	0.76	0.14	0.86	363	31 %

Table 6. 难例挖掘验证性能。

Sentinel-2 的检测完全失败，因为它们被显示得相当小和/或模糊，与其他来源相比表现逊色许多。

我们评估迭代过程对我们方法的性能以及对数据集的影响。在三次迭代过程中，我们发现 1) 最初未标记的正确检测项和 2) 容易成为错误正例的具有挑战性的样本。表格 5 描述了这些元素在每次迭代中的引入。为此，我们收集了一组在数据集迭代期间未包含的错误正例样本，并将它们包括在验证集中，以便在更具挑战的条件下评估模型。这些困难样本的一些示例显示在图 ?? 中。然后我们在每次迭代中评估我们的模型，如表 6 所示。性能随着每次迭代而提高， $mAP_{50}$  从 0.26 提高到 0.59。油罐检测的提升最大， $AP_{50}$  从 0.16 提高到 0.86，这暗示模型更好地学习到了将生物消化槽与类似的油罐结构区分开来。

估计大面积的发电量可以提供有关潜在甲烷泄漏及其对大气影响的有价值信息。因此，我们利用布列塔尼生成的生物厌氧反应器清单来估算其以千瓦 (kW) 为单位的总生产量，对于这个我们有实际数据 [1]。我们建立了一个线性回归模型，如图 7 所示，该模型根据站点内检测到的总体储罐面积（一个与设施规模相关的特征）来预测发电量。虽然模型的预测误差较大，这是意料之中的，但它能够对大量观测数据提供合理的汇总估计。总体而言，发电量估计模型预测了 33 % 的发电可变性。

在这项工作中，我们提出了一种方法，从有限和不完整的标注中检测生物反应器位置，结合基于部分的检测和强负样本挖掘，以应对经典检测器在大规模下产生的大量误检。我们展示了我们的检测器如何能够在培训区域（大东部）内稳健地检测生物反应器位置，

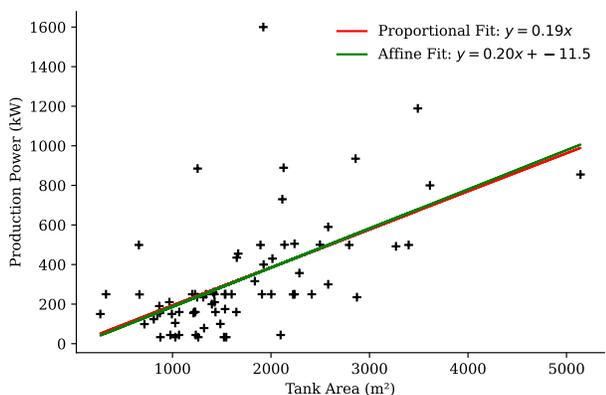


Figure 7. 布列塔尼地区 ( $r^2 = 0.332$ ) 的功率生产 (kW) 与水箱面积 ( $m^2$ ) 的对比。

并能够推广到其他地区 (布列塔尼)。所提出的迭代过程使我们能够找到新的、未标注的位置和对误检敏感的观察结果, 所有这些都用于补充数据库并构建一个大规模数据集。此外, 我们提供了对我们的方法及其组件的若干消融实验和评估, 以及对于理想分辨率的研究, 以在性能和大规模效率之间进行最佳权衡。最后, 我们建立了一个回归模型, 可以为整个区域的电力生产提供合理的估计。我们发布了代码、数据和检测到的位置, 以支持未来的研究。

本文介绍了通过自下而上的清单编制方法监测小型排放体甲烷贡献的理念。虽然它证明是有效的, 但未来的工作可以在几个方向上扩展。首先, 本研究为将类似程序应用于国家层面地区打开了可能性, 以计算整个法国或任何其他国家的潜在泄漏。此外, SPOT 卫星的可行性使得能够进行生物反应器建设的时间分析, 从而分析甲烷产量的年度增长。我们相信, 这项工作为更广泛的小型排放体甲烷测绘和更强大探测器的开发奠定了基础, 从而支持地球观测界。

## References

- [1] Association AILE. Carte & chiffres clés - la filière méthanisation en Bretagne et Pays de la Loire. <https://aile.asso.fr/biogaz/la-filiere/carte-chiffres-cles-methanisation/>, 2025. Accessed: June 12, 2025.
- [2] Xavier Bou, Gabriele Facciolo, Rafael Grompone von Gioi, Jean-Michel Morel, and Thibaud Ehret. Structure tensor representation for robust oriented object detection, 2024.
- [3] MMYOLO Contributors. MMYOLO: OpenMMLab YOLO series toolbox and benchmark. <https://github.com/open-mmlab/mmyolo>, 2022.
- [4] Daniel H. Cusworth, Andrew K. Thorpe, Alana K. Ayasse, David Stepp, Joseph Heckler, Gregory P. Asner, Charles E. Miller, Vineet Yadav, John W. Chapman, Michael L. Eastwood, et al. Strong methane point sources contribute a disproportionate fraction of total emissions across multiple basins in the United States. *Proceedings of the National Academy of Sciences*, 119(38):e2202338119, 2022.
- [5] Jian Ding, Nan Xue, Yang Long, Gui-Song Xia, and Qikai Lu. Learning roi transformer for oriented object detection in aerial images. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, pages 2849–2858, 2019.
- [6] Kaiwen Duan, Song Bai, Lingxi Xie, Honggang Qi, Qingming Huang, and Qi Tian. Centernet: Keypoint triplets for object detection. In *2019 IEEE/CVF International Conference on Computer Vision (ICCV)*, pages 6568–6577, 2019.
- [7] Thibaud Ehret, Aurélien De Truchis, Matthieu Mazzolini, Jean-Michel Morel, Alexandre D’Aspremont, Thomas Lauvaux, Riley Duren, Daniel Cusworth, and Gabriele Facciolo. Global tracking and quantification of oil and gas methane emissions from recurrent sentinel-2 imagery. *Environmental science & technology*, 56(14):10517–10529, 2022.
- [8] Pedro F. Felzenszwalb, Ross B. Girshick, David McAllester, and Deva Ramanan. Object detection with discriminatively trained part-based models. *IEEE transactions on pattern analysis and machine intelligence*, 32(9):1627–1645, 2009.
- [9] Yoav Freund and Robert E Schapire. A decision-theoretic generalization of on-line learning and an application to boosting. *Journal of Computer and System Sciences*, 55(1):119–139, 1997.
- [10] Ross Girshick, Jeff Donahue, Trevor Darrell, and Jitendra Malik. Rich feature hierarchies for accurate object detection and semantic segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 580–587, 2014.
- [11] Jiaming Han, Jian Ding, Nan Xue, and Gui-Song Xia. Redet: A rotation-equivariant detector for aerial object detection. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, pages 2786–2795, 2021.
- [12] Kaiming He, Georgia Gkioxari, Piotr Dollár, and Ross Girshick. Mask r-cnn. In *Proceedings of the IEEE international conference on computer vision*, pages 2961–2969, 2017.
- [13] IEA. Methane and climate change – global methane tracker 2022 – analysis. <https://www.iea.org/reports/global-methane-tracker-2022/methane-and-climate-change>, 2022.
- [14] IGN - Institut national de l’information géographique et forestière. BD ORTHO@: L’image géographique du territoire national, la France vue du ciel. <https://geoservices.ign.fr/bdortho>, 2024. Accessed: February 3, 2025.
- [15] Info Spot 6-7. Accès à l’Open Data Couvertures Spot 6-7 France. <https://www.geoportail.gouv.fr/actualites/observer-l-evolution-des-territoires-avec-spot>, 2023. Accessed: June 10, 2025.
- [16] Glenn Jocher, Jing Qiu, and Ayush Chaurasia. Ultralytics YOLO, 2023.

- [17] Rahima Khanam and Muhammad Hussain. Yolov11: An overview of the key architectural enhancements, 2024.
- [18] Hei Law and Jia Deng. Cornernet: Detecting objects as paired keypoints. In Proceedings of the European conference on computer vision, pages 734–750, 2018.
- [19] Yuxuan Li, Qibin Hou, Zhaohui Zheng, Ming-Ming Cheng, Jian Yang, and Xiang Li. Large selective kernel network for remote sensing object detection, 2023.
- [20] Yuxuan Li, Xiang Li, Yimian Dai, Qibin Hou, Li Liu, Yongxiang Liu, Ming-Ming Cheng, and Jian Yang. Lsknet: A foundation lightweight backbone for remote sensing, 2024.
- [21] Tsung-Yi Lin, Michael Maire, Serge J. Belongie, Lubomir D. Bourdev, Ross B. Girshick, James Hays, Pietro Perona, Deva Ramanan, Piotr Dollár, and C. Lawrence Zitnick. Microsoft COCO: common objects in context. CoRR, abs/1405.0312, 2014.
- [22] Anders Michael Fredenslund, Einar Gudmundsson, Julie Maria Falk, and Charlotte Scheutz. The danish national effort to minimise methane emissions from biogas plants. Waste Management, 157:321–329, 2023.
- [23] Jeffri Murrugarra-Llerena, Jose Henrique Lima Marques, and Claudio R. Jung. Gaucho: Gaussian distributions with cholesky decomposition for oriented object detection, 2025.
- [24] Intergovernmental Panel on Climate Change (IPCC). Technical Summary, page 35–144. Cambridge University Press, 2023.
- [25] Elyes Ouerghi, Thibaud Ehret, Carlo de Franchis, Gabriele Facciolo, Thomas Lauvaux, Enric Meinhardt, and Jean-Michel Morel. Automatic methane plumes detection in time series of sentinel-5p 11b images. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 53:147–154, 2022.
- [26] Elyes Ouerghi, Thibaud Ehret, Gabriele Facciolo, Enric Meinhardt, Jean-Michel Morel, Carlo De Franchis, and Thomas Lauvaux. Methane plumes detection on prisma 1l images with the adjusted spectral matched filter and wind data. In IGARSS 2023-2023 IEEE International Geoscience and Remote Sensing Symposium, pages 7598–7601. IEEE, 2023.
- [27] Sudhanshu Pandey, Ritesh Gautam, Sander Houweling, Hugo Denier Van Der Gon, Pankaj Sadavarte, Tobias Borsdorff, Otto Hasekamp, Jochen Landgraf, Paul Tol, Tim Van Kempen, et al. Satellite observations reveal extreme methane leakage from a natural gas well blowout. Proceedings of the National Academy of Sciences, 116(52):26376–26381, 2019.
- [28] Neel Ramachandran, Jeremy Irvin, Mark Omara, Ritesh Gautam, Kelsey Meisenhelder, Erfan Rostami, Hao Sheng, Andrew Y. Ng, and Robert B. Jackson. Deep learning for detecting and characterizing oil and gas well pads in satellite imagery. Nature Communications, 15(1):7036, 2024.
- [29] Joseph Redmon and Ali Farhadi. Yolov3: An incremental improvement. CoRR, abs/1804.02767, 2018.
- [30] Joseph Redmon, Santosh Kumar Divvala, Ross B. Girshick, and Ali Farhadi. You only look once: Unified, real-time object detection. CoRR, abs/1506.02640, 2015.
- [31] Shaoqing Ren, Kaiming He, Ross Girshick, and Jian Sun. Faster r-cnn: Towards real-time object detection with region proposal networks. Advances in neural information processing systems, 28, 2015.
- [32] Shaoqing Ren, Kaiming He, Ross Girshick, and Jian Sun. Faster r-cnn: Towards real-time object detection with region proposal networks, 2016.
- [33] Caleb Robinson, Ben Chugg, Brandon R. Anderson, Juan M. Lavista Ferres, and Daniel E. Ho. Mapping industrial poultry operations at scale with deep learning and aerial imagery. CoRR, abs/2112.10988, 2021.
- [34] Caleb Robinson, Anthony Ortiz, Allen Kim, Rahul Dodhia, Andrew Zolli, Shivaprakash K Nagaraju, James Oakleaf, Joe Kiesecker, and Juan M. Lavista Ferres. Global renewables watch: A temporal dataset of solar and wind energy derived from satellite imagery. 2025.
- [35] Robert E. Schapire. The boosting approach to machine learning: An overview. Nonlinear estimation and classification, pages 149–171, 2003.
- [36] Drew Shindell, Johan C. I. Kuylenstierna, Elisabetta Vignati, Rita van Dingenen, Markus Amann, Zbigniew Klimont, Susan C. Anenberg, Nicholas Muller, Greet Janssens-Maenhout, Frank Raes, Joel Schwartz, Greg Faluvegi, Luca Pozzoli, Kaarle Kupiainen, Lena Höglund-Isaksson, Lisa Emberson, David Streets, V. Ramanathan, Kevin Hicks, N. T. Kim Oanh, George Milly, Martin Williams, Volodymyr Demkine, and David Fowler. Simultaneously mitigating near-term climate change and improving human health and food security. Science, 335(6065):183–189, 2012.
- [37] Dan Stowell, Jack Kelly, Damien Tanner, Jamie Taylor, Ethan Jones, James Geddes, and Ed Chalstrey. A harmonised, high-coverage, open dataset of solar photovoltaic installations in the uk. Scientific Data, 7(1):394, 2020.
- [38] Xian Sun, Peijin Wang, Zhiyuan Yan, Feng Xu, Ruiping Wang, Wenhui Diao, Jin Chen, Jihao Li, Yingchao Feng, Tao Xu, et al. Fair1m: A benchmark dataset for fine-grained object recognition in high-resolution remote sensing imagery. ISPRS Journal of Photogrammetry and Remote Sensing, 184:116–130, 2022.
- [39] Scientific Data Curation Team. A harmonised, high-coverage, open dataset of solar photovoltaic installations in the UK. Nature, 2020.
- [40] Andrew K. Thorpe, Robert O. Green, David R. Thompson, Philip G. Brodrick, John W. Chapman, Clayton D. Elder, Itziar Irakulis-Loitxate, Daniel H. Cusworth, Alana K. Ayasse, Riley M. Duren, et al. Attribution of individual methane and carbon dioxide emission sources using emit observations from space. Science advances, 9(46):eadh2391, 2023.
- [41] Zhi Tian, Chunhua Shen, Hao Chen, and Tong He. Fcos: Fully convolutional one-stage object detection.

- In 2019 IEEE/CVF International Conference on Computer Vision (ICCV), pages 9626–9635, 2019.
- [42] Chien-Yao Wang, Alexey Bochkovskiy, and Hong-Yuan Mark Liao. Yolov7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors, 2022.
- [43] Chien-Yao Wang, I-Hau Yeh, and Hong-Yuan Mark Liao. Yolov9: Learning what you want to learn using programmable gradient information, 2024.
- [44] James P. Williams, Mark Omara, Anthony Himmelberger, Daniel Zavala-Araiza, Katlyn MacKay, Joshua Benmergui, Maryann Sargent, Steven C. Wofsy, Steven P. Hamburg, and Ritesh Gautam. Small emission sources in aggregate disproportionately account for a large majority of total methane emissions from the us oil and gas sector. *Atmospheric Chemistry and Physics*, 25(3):1513–1532, 2025.
- [45] Yuxin Wu, Alexander Kirillov, Francisco Massa, Wan-Yen Lo, and Ross Girshick. Detectron2. <https://github.com/facebookresearch/detectron2>, 2019.
- [46] Gui-Song Xia, Xiang Bai, Jian Ding, Zhen Zhu, Serge Belongie, Jiebo Luo, Mihai Datcu, Marcello Pelillo, and Liangpei Zhang. Dota: A large-scale dataset for object detection in aerial images. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 3974–3983, 2018.
- [47] Youzi Xiao, Zhiqiang Tian, Jiachen Yu, Yinshu Zhang, Shuai Liu, Shaoyi Du, and Xuguang Lan. A review of object detection based on deep learning. *Multimedia Tools and Applications*, 79:23729–23791, 2020.
- [48] Xingxing Xie, Gong Cheng, Jiabao Wang, Xiwen Yao, and Junwei Han. Oriented R-CNN for object detection. *CoRR*, abs/2108.05699, 2021.
- [49] Yongchao Xu, Mingtao Fu, Qimeng Wang, Yukang Wang, Kai Chen, Gui-Song Xia, and Xiang Bai. Gliding vertex on the horizontal bounding box for multi-oriented object detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 43(4):1452–1459, 2021.
- [50] Xue Yang and Junchi Yan. Arbitrary-oriented object detection with circular smooth label. In *Computer Vision–ECCV 2020: 16th European Conference, Glasgow, UK, August 23–28, 2020, Proceedings, Part VIII 16*, pages 677–694. Springer, 2020.
- [51] Xue Yang and Junchi Yan. On the arbitrary-oriented object detection: Classification based approaches revisited. *International Journal of Computer Vision*, 130(5):1340–1365, 2022.
- [52] Xue Yang, Junchi Yan, Ziming Feng, and Tao He. R3det: Refined single-stage detector with feature refinement for rotating object. In *Proceedings of the AAAI conference on artificial intelligence*, pages 3163–3171, 2021.
- [53] Xue Yang, Junchi Yan, Qi Ming, Wentao Wang, Xiaopeng Zhang, and Qi Tian. Rethinking rotated object detection with gaussian wasserstein distance loss. In *International conference on machine learning*, pages 11830–11841. PMLR, 2021.
- [54] Xue Yang, Xiaojiang Yang, Jirui Yang, Qi Ming, Wentao Wang, Qi Tian, and Junchi Yan. Learning high-precision bounding box for rotated object detection via kullback-leibler divergence. *Advances in Neural Information Processing Systems*, 34:18381–18394, 2021.
- [55] Ze Yang, Shaohui Liu, Han Hu, Liwei Wang, and Stephen Lin. Reppoints: Point set representation for object detection. In *2019 IEEE/CVF International Conference on Computer Vision (ICCV)*, pages 9656–9665, 2019.
- [56] Yi Yu and Feipeng Da. Phase-shifting coder: Predicting accurate orientation in oriented object detection. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pages 13354–13363, 2023.
- [57] Zhong-Qiu Zhao, Peng Zheng, Shou-tao Xu, and Xindong Wu. Object detection with deep learning: A review. *IEEE transactions on neural networks and learning systems*, 30(11):3212–3232, 2019.
- [58] Yue Zhou, Xue Yang, Gefan Zhang, Jiabao Wang, Yanyi Liu, Liping Hou, Xue Jiang, Xingzhao Liu, Junchi Yan, Chengqi Lyu, Wenwei Zhang, and Kai Chen. Mmrotate: A rotated object detection benchmark using pytorch. In *Proceedings of the 30th ACM International Conference on Multimedia*, 2022.

# 面向大规模地质统计甲烷监测的基于部件的目标检测

## Supplementary Material

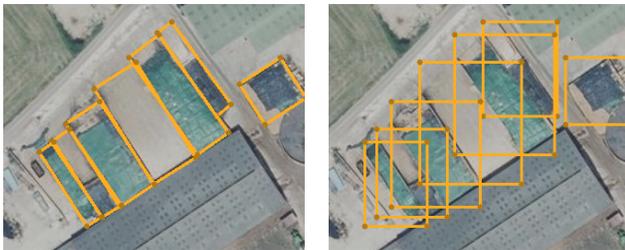
Model	Overall	Bio-digester	Tank	Pile
Yolov8 (COCO) [16]	0.386	0.383	0.601	0.173
Yolov8 (DOTA) [16]	0.672	0.736	0.901	0.378
Faster RCNN [32]	0.687	0.854	0.909	0.299
LSK [19]	0.724	0.846	0.741	0.584
Oriented RCNN [48]	0.701	0.824	0.746	0.533

Table 7. 不同目标检测器的比较。对于不同的模型和参数，总体和每类的 AP50 分数被报告。YOLOv8 (COCO) 和 YOLOv8 (DOTA) 分别对应于在 COCO 和 DOTA 上预训练的 YOLO 模型。

我们使用带注释的验证数据比较并证明我们选择的目标检测架构的合理性。我们评估了几种目标检测架构，以确定最适合我们的任务。我们考虑了 YOLOv8 [16] 的效率，Faster R-CNN [31] 作为轻量级的两阶段检测器，以及两个定向目标检测器：Oriented R-CNN [48] 和 LSKNet [19]。表 7 总结了使用分辨率为每像素 1 米的 BD ORTHO 影像时，所有模型的总体和每类 AP50 得分。

我们首先通过比较在 DOTA [46] 和 COCO [21] 上预训练的 YOLOv8 模型的微调性能来评估预训练的影响。结果证实，使用 DOTA 进行特定领域的预训练可将 YOLOv8 性能提高 74 %。定向物体检测器不仅增强了堆料检测，还改进了总体厌氧消化器的识别。然而，对于油罐检测，传统物体检测器的表现更好。这并不令人意外，因为圆形物体缺乏明显的方向性，这是定向物体检测中已知的问题 [2]。基于这一点以及上述结果，我们选择 LSKNet 作为我们的最终物体检测器。图 1 (b) 展示了验证集的定性示例。

### 4.1. 定向边界框



(a) 无重叠的有向边界框 (b) 边界框高度重叠失败情况

Figure 8. 桩体标注方法的可视化

图 8 展示了一个案例，其中定向包围盒提供了一种更合适的标注格式。树桩通常较细长，并且不与水平或垂直轴对齐，使得轴对齐包围盒由于过度重叠而产生人为偏高的交并比 (IoU) 得分。

### 4.2. 训练实现细节

使用 Detectron [45] 实现。训练时使用 Smooth L1 损失进行边界框回归，使用 Focal 损失进行分类 ( $\alpha = 0.25, \gamma = 2.0$ )。正则化包含权重衰减 0.0001，而批量归一化被冻结。未应用 dropout。

YOLOv8 使用 mmyolo [3] 实现。训练时分类损失权重为 0.5，边界框回归损失权重为 7.5，分布焦点损失权重为 0.375。基础学习率设置为 0.01，并使用线性预热计划和学习率衰减。使用动量为 0.03 的批量归一化。模型应用 L2 正则化，权重衰减为 0.0001。批量归一化保持冻结。未应用 dropout。

定向 RCNN 和 LSKNet 使用 mmrotate [58] 实现。RPN 使用一个基于 sigmoid 的交叉熵损失 (权重 = 1.0) 进行目标分类，并使用一个平滑 L1 损失 ( $\beta = 0.111$ ) 进行边框回归进行训练。RoI 头针对多类分类应用一个基于 softmax 的交叉熵损失 (权重 = 1.0)，以及一个平滑 L1 损失 ( $\beta = 1.0$ , 权重 = 1.0) 进行最终边框优化。初始学习率设置为 0.01，并经过线性热启动阶段，从 0.001 开始，在 500 次迭代中逐步增加。在热启动之后，应用 MultiStepLR 调度器，在第 7 个 epoch 时将学习率降低 0.1 倍。训练过程总共进行 8 个 epoch。模型结合了权重衰减为 0.0001 的 L2 正则化。训练过程中批归一化层被冻结。不使用 dropout。

Hard Negative Examples



Figure 9. 在三次训练迭代中难以处理的负样本。在迭代 0 中，从 Grand-Est 地区随机抽取样本。