

油气设施智能识别与矢量点标注研究

刘松¹ 钱宇雯^(通讯作者) 申晋利¹ 胡钰乾² 陈玉华²

1. 中石油勘探开发研究院 北京 100083; 2. 中国矿业大学资源与地球科学学院 江苏徐州 221008

摘 要: 随着全球能源需求的增长, 油气设施的高效检测与管理成为资源开发的重要课题。传统的人工检测方法效率低且成本高昂, 难以满足大规模油气田的监控需求。近年来, 遥感技术与深度学习的结合为目标检测提供了新的解决方案。本研究基于高分辨率遥感影像与深度学习技术, 提出了一种改进的 YOLOv5 模型, 用于油气设施的智能识别与标注。通过融合 Focal Loss 损失函数, 解决了类别不均衡问题, 优化了模型对井场、场站及疑似油气设施的检测性能。实验结果表明, 模型在测试集上的平均精度 (AP) 分别为井场 0.872、场站 0.9、疑似油气设施 0.808, 综合识别准确率达 90% 以上。塔里木盆地研究区构建的 21 万张影像切片影像集及 3850 个地理矢量点成果, 为油气设施管理提供了高精度、低成本的解决方案, 显著提升了监测效率。

关键词: 遥感技术; 高分辨率; 深度学习; YOLOv5; 目标检测

0 引言

油气设施的监测和管理不仅关乎资源的开发效率, 还直接影响到油气田的安全性和环境保护。然而, 现有的油气设施检测方法主要基于人工识别和地面调查, 这些手段在应对大规模、长期监控任务时, 通常存在效率不高、费用较大以及精确度不足的挑战。鉴于此, 探索一套自动化、高效率、成本较低的监控策略, 已成为油气田管理领域亟待解决的问题。

然而, 油气设施的目标检测任务仍然面临一些挑战, 尤其是类别不均衡问题。油气设施中, 不同类别的设施 (如井场、场站、疑似油气设施等) 在影像中的分布往往不均, 某些类别的样本数远大于其他类别, 这使得模型在训练过程中容易产生偏倚。为了解决这一问题, Focal Loss 损失函数被引入到 YOLOv5 模型

中^[9], 该方法能够有效地缓解类别不均衡对模型训练的影响, 从而提高目标检测的精度和召回率。


本研究运用了一个改进的 YOLOv5 模型, 并融合了 Focal Loss 损失函数进行优化, 目的是提升油气设施智能识别与标注的准确性。通过实验验证, 本研究的方法在井场、场站及疑似油气设施的检测中, 均取得了良好的结果。

数据集

1.1 数据获取与预处理

本研究所用的遥感影像数据来源于北京二号、北京三号以及高分二号卫星, 如图 1 所示。遥感数据的分辨率分别为 0.8 米、0.5 米和 0.8 米, 可以提供清晰的地表影像, 适用于油气设施的检测任务。表 1 列出了不同卫星的参数对比。研究区域位于塔里木盆地,

影像覆盖面积超 51000 平方公里。



(a) 北京二号 (b) 北京三号 (c) 北京二号

图 1 三类影像分布图

表 1 卫星影像参数对比

卫星	全色分辨率	多光谱分辨率	重访周期	
北京二号	0.8 m	3.2 m	3-5 天	
北京三号	0.5 m	2.0 m	2-3 天	
高分二号	0.8 m	3.2 m	4-5 天	

这些卫星的遥感影像数据为油气设施的自动化识别提供了可靠的来源。原始影像数据经过压缩处理（从 16 位转为 8 位）^[10]，并通过无重叠裁剪的方式将影像切割为多个小块，每个小块的尺寸为 1024×768 像素，以便进行后续的训练和测试。同时，将影像格式从 TIF 转换为 JPG，以减少存储空间并提高读取效率。在数据预处理阶段，保留了每张影像的 WGS1984 地理坐标信息，确保了数据的空间精度，为后续的地理定位和矢量点生成奠定基础。

2.2 数据集构建

经过数据预处理后，从 21 万张影像切片中筛选出 1210 张高质量的影像，这些影像包含了井场、场站、疑似油气设施等目标类别，每个类别的数量如表 2 所示。通过使用 LabelImg 工具进行标注，所有目标都被框定在边界框中，并为其分配了类别标签。将数据集按照 6:2:2 的比例划分为训练集、验证集和测试集。为了提高模型的泛化能力，采用了数据增强技术，包

括图像翻转、旋转、噪声加入和 HSV 空间变换等方式^[11-13]，扩充了训练集中的样本量。数据集中的目标类别包括三类。井场（类别 0），是油气开采的主要设施，通常占据较大的区域。场站（类别 1），油气处理与储存的设施，规模根据类型不同有大有小且常见。疑似油气设施（类别 3），一些标志性不明显的可能的油气设施区域（如计量站等），尚未被确认。

表 2 标注样本数量

类别	0（井场）	1（场站）	2（疑似油气设施）	总计
样本数量（个）	887	141	282	1310
改进 YOLOv5 模型				

YOLOv5 的网络架构由三个核心组件：骨干网络（Backbone）、特征融合层（Neck）和检测头（Head）。其中，Backbone 负责从输入图像中提取特征，Neck 则通过特征融合模块整合来自不同尺度的特征，而 Head 负责最终的目标分类与定位。

本研究采用了 CSPDarknet53 网络作为 YOLOv5 的骨干网络 [14]，CSPDarknet53 是基于 ResNet 的改进模型，具有更强的特征提取能力。它通过使用 Cross-Stage Partial Networks（CSP）技术，减轻了网络训练过程中的梯度消失问题，并能够提高训练效率。CSPDarknet53 不仅能够提取底层特征，还能够有效地捕捉复杂的高层语义信息。

YOLOv5 引入了 FPN（Feature Pyramid Networks）与 PANet（Path Aggregation Networks）结合的特征融合模块，尤其是 PANet 的引入，有助于跨尺度信息的有效传递，从而提升了小目标的检测精度。PANet 通过自适应的路径加权，强化了不同层次的特征信息，使得模型对于尺度变化有更强的鲁棒性。

YOLOv5 采用了三层卷积的检测头，用于输出目标的类别、位置以及置信度。在类别不均衡问题上，Focal Loss 被引入到损失函数中，以帮助模型专注于难易样本的区分，从而提升对少数类的检测精度。

在本研究中，使用了 YOLOv5 目标检测框架，并对其进行了优化。该框架的骨干网络是 CSPDarknet53，这一网络因其卓越的特征提取性能，在处理多种尺寸目标的检测任务时表现突出。同时，模型的结构还结合了 PANet (Path Aggregation Network)，增强了不同尺度特征的融合能力^[15]，使得模型能够更好地处理复杂场景中的目标。

针对类别不平衡的问题，本研究在 YOLOv5 模型中嵌入了 Focal Loss 损失函数。Focal Loss 的主要原理是通过改变不同难度样本的权重分配，使模型更加关注那些难以识别的样本，进而提升模型对少数类别的识别能力。其公式 (1) 所示：

其中 y 是样本的标签值， p 是模型预测样本为正样本的概率，而 γ 为可以动态调整的超参数。

在模型训练阶段，Focal Loss 有效地降低了简单样本对总损失的贡献，同时增强了难以分类样本的损失比重，这样模型就能更有效地学习那些难以区分的样本。

模型使用 PyTorch 框架进行训练，硬件环境为 NVIDIA RTX 4080 Ti GPU。训练过程中，采用了标准的随机梯度下降 (SGD) 优化器，学习率动态调整，采用了数据增强和正则化技术，以防止过拟合。鉴于训练数据集中类别分布的不均匀性，对各类别的样本权重进行了优化，以保障模型能够均衡地掌握不同类

别的特性。

结果与讨论

4.1 模型性能评估

依据精确度、召回率以及平均精度等评价指标，模型在测试集上的表现如表 3 所示。

表 3 测试集评价指标

	0 (井场)	1 (场站)	2 (疑似油气设施)
Precision	0.872	0.9	0.808
Recall	0.90	0.88	0.87
AP	0.872	0.9	0.808

综合 AP 值为 0.86，模型在整体检测任务中表现良好，尤其在井场和场站类别上，取得了较高的检测精度。测试集上的模型表现揭示了其在实际应用场景中的可能性和重要性。随着不断的改进和细化，模型有望在众多业务环境中扮演更关键的角色。

此外，本项目在评估过程中采取随机抽样的方法，在 155 景影像中随机抽取 1 张影像，计算其识别精确率、召回率，如表 4 所示。通过分析该表可得，对于类别 0 (井场)，可以看到精确率和召回率都相对较高，这表明模型在识别井场方面表现良好。类别 1 (场站) 的精确率略低于类别 0，这可能意味着模型在识别场站时，虽然能够识别出更多的场站，但同时也可能将一些非场站的影像误判为场站。类别 2 (疑似油气设施) 的精确率和召回率都相对较高，这表明模型在这一类别上的表现较为均衡。

表 4 真实影像评价指标

	0 (井场)	1 (场站)	2 (疑似油气设施)
Precision	0.93	0.80	0.92
Recall	0.88	0.85	0.87

本项目的目标检测模型在井场、场站和疑似油气设施的识别任务中表现出了较高的精度和鲁棒性，如图 2 所示。通过对模型输出结果的综合分析，结合精

确度、召回率、AP 评价指标, 可以确认模型能够较为准确地完成任务, 适应不同场景下的目标检测需求。然而, 仍然存在一些挑战和改进空间, 未来可通过进一步优化模型结构、增强训练数据集和提升算法性能来提升模型的整体识别效果和应用性能。




图 2 模型识别结果示例图

4.2 矢量点生成与修正

通过训练好的目标检测模型, 在遥感影像上进行目标检测, 生成了共 4474 个矢量点。这些点代表了模型检测到的油气设施位置。在初步评估中, 发现这些矢量点虽然能够识别出大部分油气设施, 但仍存在冗余点 (例如同一设施被检测多次) 和定位偏差 (例如检测点与实际设施位置存在误差)。

为了提高结果的精度和可用性, 采用去重处理和空间校正这两个后处理步骤。利用 ArcGIS 软件对检测结果进行去重。通过设置一个合理的空间阈值, 将空间距离小于该阈值的多个检测点合并为一个, 能够有效地消除由于目标检测模型中的误差或重复检测所产生的冗余点, 减少误检和漏检。通过将检测结果与已知的地理坐标数据进行比对, 校正检测点的位置偏差。通过地理信息系统 (GIS) 技术, 基于遥感影像对生成的矢量点进行坐标调整^[16], 使得每个点的位置更加准确地对应到实际设施的地理位置。效果如图 3 所示。




图 3 矢量点修正对比图

最终, 生成的修正后的矢量点不仅数量合理, 且与真实的油气设施地理分布高度吻合。从空间精度上来看, 经过修正后的矢量点位置与实际设施的偏差非常小, 达到了较高的定位精度。通过与实际数据的对比, 发现经修正后, 精度和鲁棒性得到了大幅度提升, 如图 4 所示。



图 4 部分矢量点示例图

经过去重和空间校正处理后, 最终保留了 3850 个有效点, 这些点代表了经过修正后的油气设施位置。通过这一过程, 矢量点的位置精度显著提高, 且与实际油气设施的分布高度一致。这一过程为遥感图像中的目标检测提供了一个较为完整的解决方案, 尤其是在处理小物体目标和复杂场景时。这些矢量点的地理位置经过修正后, 与油气田实际设施的分布高度一致, 具有较高的定位精度, 如图 5 所示。

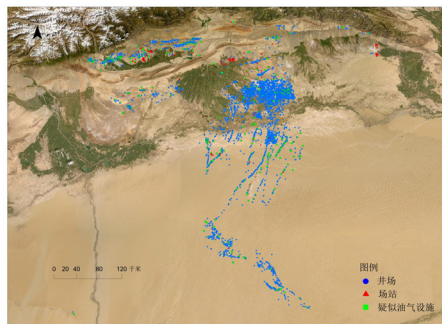


图 5 塔里木矢量点分布图

结论

本研究提出的基于改进 YOLOv5 模型的油气设施智能识别与标注方法,有效解决了塔里木盆地油气设施监测中的精度和效率问题。采用 Focal Loss 损失函数后,模型在处理类别不平衡问题上表现突出,有效提升了检测的准确性和召回率。实验结果显示,改进模型在井场、场站和疑似油气设施的检测中,表现优异。

此外,经过去重和空间校正处理后,生成的 3850 个矢量点与实际设施的地理分布高度一致,定位精度显著提升。本研究为油气设施的智能化监测提供了高效且精准的技术支持,并为未来的油气设施管理和环境监测奠定了基础。

参考文献

[1]Redmon J, Divvala S, Girshick R, et al. You Only Look Once: Unified, real-time object detection[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2016: 779-788.

[2] 张永梅, 季艳, 马礼, 等. 遥感图像建筑物识别及变化检测方法 [J]. 电子学报, 2014, 42(04): 653-657.

[3]Lin T Y, Dollar P, Girshick R, et al. Feature Pyramid Networks for Object Detection[C]// 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE Computer Society, 2017.

[4]Liu W, Ma L, Chen H. Arbitrary-Oriented Ship Detection Framework in Optical Remote Sensing Images[J]. IEEE Geoenvironment and Remote Sensing Letters, 2018:1-5.

[5]Yang J, Zhu Y, Jiang B, et al. Aircraft detection in remote sensing images based on a deep residual network and Super-Vector coding[J]. Remote Sensing Letters, 2018, 9(3):229-237.

作者简介: 刘松 (1972-), 男, 汉, 北京, 学士, 高级工程师, 研究方向: 环境遥感。

课题名称及编号: 油气田甲烷排放卫星遥感检测评估技术研究与应用, 编号: 2022D-5008-01。

cumt.edu.cn