

DOI: 10.13382/j.jemi.B2508406

融合 RT-DETR 及插值法的井口控制盘仪表参数识别*

张清正 张仕海 屈重年 郭晓赛

(天津职业技术师范大学机械工程学院 天津 300222)

摘要:针对海上平台井口控制盘仪表智能巡检系统,提出了一种基于轻量化 RT-DETR 模型与插值法的仪表参数识别方法。为实现模型轻量化及目标高精度提取,重构并优化了 RT-DETR 的主干与颈部网络,通过引入跨阶段局部光照增强模块(CSP-IEM)与快速增强混合聚合模块(FEMAM)提升光照鲁棒性和颈部网络效率,同时设计了匹配感知损失函数(MAL)保留了匹配质量信息。消融实验表明,相比于原始的 RT-DETR 算法,改进后的 RT-DETR 算法在海上平台井口控制盘仪表数据集上的 mAP@0.5 达到了 76.1%,参数量与计算量分别减少了 30.73%和 25.79%,帧率(FPS)达到了 216 fps。基于仪表关键目标识别及图象处理方法,提出采用样条插值法计算仪表读数的方法。现场采集图像仪表参数的读取实验表明,所提出的样条插值法相对于局部角度法的平均相对误差与平均全局误差分别相对降低了 45.5%与 48.3%。综合实验证明,所提出的仪表参数识别方法满足现场计算资源受限条件下的部署,检测精度及实时性等方面的需求。

关键词:海上平台;井口控制盘;RT-DETR 模型;样条插值;目标识别;参数识别

中图分类号: TH868 **文献标识码:** A **国家标准学科分类代码:** 520.20

Parameter identification for wellhead control panel instruments by integrating RT-DETR and interpolation method

Zhang Qingzheng Zhang Shihai Qu Chongnian Guo Xiaosai

(School of Mechanical Engineering, Tianjin University of Technology and Education, Tianjin 300222, China)

Abstract: A parameter identification method based on a lightweight RT-DETR model and a spline interpolation method is proposed for the instrument intelligent inspection system developed for the offshore platform wellhead control panel. To achieve lightweight model and high-precision targets extraction, the backbone and neck networks of RT-DETR are reconstructed and optimized. The cross-stage local illumination enhancement module (CSP-IEM) and the fast enhanced hybrid aggregation module (FEMAM) are introduced to improve illumination robustness and neck network detection efficiency. A matching-aware loss function (MAL) is designed to preserve matching quality information. The ablation experimental results show that the model achieves a mean average precision (mAP) of 76.1% at 0.5, reduces the number of parameters and computation by 30.73% and 25.79%, respectively, and achieves a frame rate of 216 fps. Based on the key targets recognition and image processing methods for instruments, a method using spline interpolation to calculate instrument readings is proposed. The experiment of reading instrument parameters from on-site collected images shows that the spline interpolation method reduces the mean relative error and mean global error by 45.5% and 48.3%, respectively compared to the local angle method. Comprehensive experiments have demonstrated that the proposed instrument parameter identification method meets the requirements for deployment under limited on-site computing resources, as well as the needs for detection accuracy and real-time performance.

Keywords: offshore platform; wellhead control panel; RT-DETR model; spline interpolation; target recognition; parameter identification

0 引言

海上平台井口控制盘汇集了压力、温度、流量等仪表及相关操作系统,用于对采油树的安全阀、套筒放气阀、电潜泵等运行参数的监测和控制,因此,井口控制盘对井口台的安全运行至关重要。目前,井口台多属于无人平台,控制盘所监控的参数主要是就地存储,集控室或远程管理平台为了获取相关参数,需要人工现场抄录或拷贝,由此形成了对控制盘人工定期巡检的管理模式。然而,目前人工巡检模式存在仪表参数获取不及时、工作量大、工作环境较恶劣、维护管理成本高等现实问题。因此,现场急需一种井口控制盘仪表自动巡检装置及参数自动识别系统,以代替人工巡检。

对于仪表参数的自动识别,由于井口控制盘上均为指针式仪表,目前主要采用基于深度学习的目标识别与读数方法。例如,Ninama 等^[1]提出了结合 DenseNet-169 特征提取与经典图像处理的混合框架,显著增强了复杂背景及不同光照下的指针定位与刻度识别精度。Feng 等^[2]开发了一种神经网络模型,能够在低质量图像中检测仪表及其一个或多个指针。Lin 等^[3]提出了一种遮挡

模拟方法,并通过优化生成对抗网络的方式,以生成更优的指针掩码。Leon-Alcázar 等^[4]利用合成数据生成多种表盘姿态与干扰场景,训练端到端模型实现表盘检测与指针角度回归,有效降低了真实数据标注需求并提升了鲁棒性。Salomon 等^[5]首次构建了多圆盘水表读数数据集(UFPR-ADMR),并基于 Faster R-CNN 与 YOLO 分别完成圆盘检测与指针识别。陶金等^[6]提出了一种基于深度学习的指针式仪表检测方法,通过对 YOLOv4-tiny 网络与 Hourglass 网络结构进行改进,达到精准识别指针式仪表读数的目的。以上方法从不同角度证实了基于深度学习的仪表参数识别方法的可行性及优越性。然而,井口控制盘上的指针式仪表具有其特殊性:一方面,仪表外的玻璃罩存在反光效应,会影响图像采集质量;另一方面,由于巡检区域及仪表位置固定,可通过建立仪表量程矩阵来省略量程识别环节。

基于以上分析,本文为满足井口控制盘仪表参数自动读取的需求,提出一种基于目标识别与样条插值相结合的仪表参数自动读取方法。并系统开展了 RT-DETR 模型优化、仪表关键目标识别以及参数读取实验等研究工作。整体研究思路如图 1 所示。

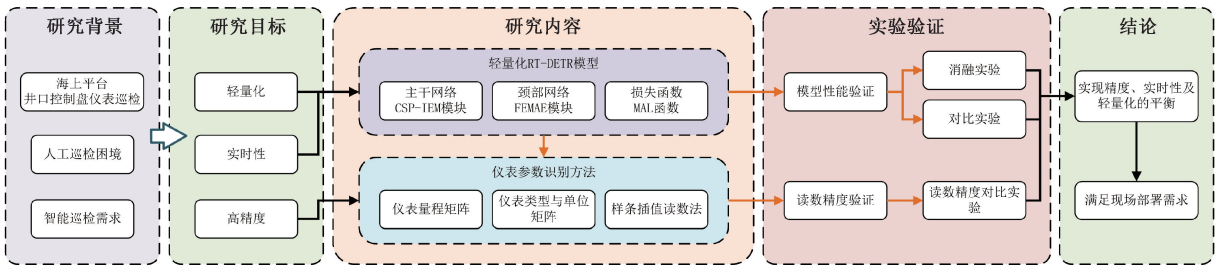


图 1 整体研究思路

Fig. 1 Overall research framework

1 海上平台井口控制盘仪表自动读数方法

基于深度学习目标识别模型的井口控制盘仪表自动读数过程包括:1)规划仪表巡检装置的图像采集点位,构建各点位仪表量程、类型、单位等信息矩阵;2)通过巡检装置获取井口控制盘某点位的仪表图像;3)采用目标识别模型提取图像中的仪表目标,并对多个仪表进行编号;4)采用目标识别模型提取仪表目标中的刻度线、指针、指针回转中心等关键信息,并采用图像处理法获取各个关键点坐标;5)利用样条插值法进行识别读数。

1.1 仪表信息矩阵的构建

由于井口控制盘上仪表相对位置固定,仪表巡检装置的巡检点位亦固定,为简化读数过程,减少因目标识别误差所带来的读数失败问题,可提前构建井口控制盘上

的仪表信息矩阵,并在后期读数过程中直接检索相应信息。所构建的仪表信息矩阵包括仪表量程矩阵 $\mathbf{R} \in \mathbf{R}^{I \times J \times N}$ 与仪表类型矩阵 $\mathbf{T} \in \mathbf{S}^{I \times J \times L}$,如图 2 所示,其中 I 表示巡检点位, J 表示仪表序号, N 表示量程信息点数, l 为类型索引。定义式如下:

$$\mathbf{R}_{i,j,k} = \mathbf{R}_{i,j}^{(k)}, k = 0, 1, \dots, N \quad (1)$$

$$\mathbf{T}_{i,j,l} = \mathbf{T}_{i,j}^{(l)}, l = 0, 1 \quad (2)$$

式中: $\mathbf{R}_{i,j}^{(0)}$ 为第 i 点位第 j 仪表的起始量程值; $\mathbf{R}_{i,j}^{(N)}$ 为终止量程值; $\mathbf{R}_{i,j}^{(1)}, \dots, \mathbf{R}_{i,j}^{(N-1)}$ 为中间量程值; $\mathbf{T}_{i,j,0}$ 代表第 i 点位第 j 仪表的类型; $\mathbf{T}_{i,j,1}$ 代表其单位。在实时读数过程中,可以通过索引的方法直接获取当前仪表的量程、类型与单位信息,提高了读数的准确性及实时性。

1.2 样条插值读数法

指针仪表读数常用的方法有角度法^[7]、局部角度

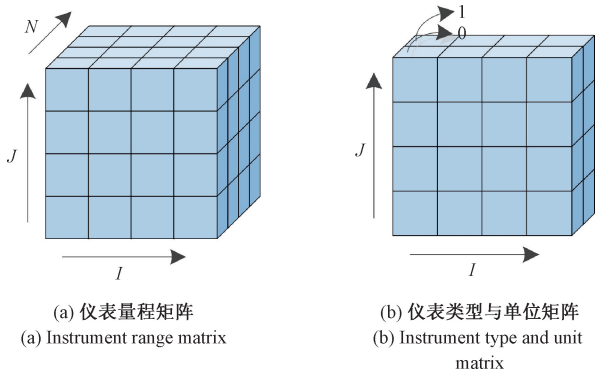


图2 仪表信息矩阵
Fig. 2 Instrument information matrix

法^[8]和加权角度法^[9]等。角度法通过指针端点与起始刻度、起始刻度与终止刻度间的角度比值,再结合量程映射为数值,该方法可能因为刻度、指针端点等识别定位误差而造成较大的读数误差;局部角度法只利用指针与附近两个标度间的角度范围读数,亦对局部目标识别定位偏差较敏感;加权角度法通过多个局部角度法区域结果加权融合用以提高精度,存在多个局部角度法计算过程繁琐,加权值难以确定等问题。

以上仪表读数方法主要适用于刻度均匀分布的仪表,对于因结构及变形等因素导致的刻度非均匀分布情况,其读数误差较大。本文基于所构建的井口控制盘仪表量程矩阵,提出了一种样条插值读数法,即将仪表刻度盘的角度与数值关系视为分段非线性函数关系,使用标定时拟合的多个角度与刻度值对作为锚点,对指针当前角度值进行分段插值及拟合预测,实现更精准、更结构化的读数方式。

设仪表刻度盘上存在 $n+1$ 对已知量程刻度点,其对应角度以旋转中心 o 垂直向下的向量为初始方向,规定顺时针角度 θ 为正,那么共存在 $n+1$ 对角度 θ_i 与数值 v_i 的映射关系 $(\theta_0, v_0), (\theta_1, v_1), \dots, (\theta_n, v_n)$, 在每段区间上构造三次多项式 $S_i(\theta)$:

$$S_i(\theta) = a_i + b_i(\theta - \theta_i) + c_i(\theta - \theta_i)^2 + d_i(\theta - \theta_i)^3 \quad (3)$$

使得插值函数 $S(\theta)$ 满足插值约束条件:

$$S_i(\theta_i) = v_i, S_i(\theta_{i+1}) = v_{i+1} \quad (4)$$

$$S'_i(\theta_{i+1}) = S''_{i+1}(\theta_{i+1}) \quad (5)$$

$$S''_i(\theta_{i+1}) = S''_{i+1}(\theta_{i+1}) \quad (6)$$

$$S''_0(\theta_0) = 0, S''_{n-1}(\theta_n) = 0 \quad (7)$$

其中,式(4)为插值条件,式(5)为一阶导连续性条件,式(6)为二阶导连续性条件,式(7)为边界条件。通过这些约束可构造三对角线性方程组,唯一确定每个区间的三次插值多项式系数,最终得出全区间的平滑插值函数 $S(\theta)$ 。

$$S(\theta) = \begin{cases} S_0(\theta), & \theta \in [\theta_0, \theta_1] \\ S_1(\theta), & \theta \in [\theta_1, \theta_2] \\ \vdots \\ S_{n-1}(\theta), & \theta \in [\theta_{n-1}, \theta_n] \end{cases} \quad (8)$$

对于任意检测出的指针角度 θ_{ptr} ,通过函数计算对应读数。

$$v_{ptr} = S(\theta_{ptr}) \quad (9)$$

2 RT-DETR 模型优化及仪表关键目标识别

基于现场巡检装置采集的井口控制盘仪表图像,并综合考虑到巡检任务对于实时性的要求,本文选择 RT-DETR 模型对仪表、仪表上刻度、指针等关键目标进行识别。基于关键目标识别结果,采用图像处理法提取刻度线内端点、指针端点及回转中心等目标的坐标。基于指针端点与回转中心连线、刻度线内端点与回转中心连线之间的夹角,采用样条插值的方法计算当前仪表实时参数。

2.1 RT-DETR 模型结构

RT-DETR^[10]利用 Transformer 的自注意力机制来处理图像数据,不依赖于非极大值抑制(non-maximum suppression, NMS)后处理的耗时操作,没有 anchor 等先验知识和约束。它省略了后处理步骤,推理速度无延迟且保持稳定,通过解耦尺度内交互和跨尺度融合有效处理多尺度特征,从而大幅降低 DETR 的计算成本,并在目标的实时检测上优于 YOLO(you only look once) 系列模型^[11]。

如图3所示,RT-DETR 模型由主干网络、混合编码器和带有辅助预测头的解码器组成。首先,利用 Backbone 的最后3个输出特征(S3、S4、S5)作为编码器的输入,减少特征层的处理。其次,混合编码器由 AIFI(attention-based intra-scale feature interaction)模块和 CCFM(CNN-based cross-scale feature-fusion module)模块组成,AIFI 仅对 S5 这一特征层进行处理,在保证模型性能的同时减少了计算量,CCFM 模块通过自底向上和自顶向下两条路径的特征融合,将多尺度特征转换为一系列图像特征;最后,采用 IoU-aware 查询选择机制来选择固定数量的图像特征作为初始对象查询,以优化解码器,再通过迭代优化查询对象来生成预测框和置信度分数。

2.2 基于 RT-DETR 改进的算法模型

在 RT-DETR 目标检测模型中,官方提供了以 ResNet 和 HGNet 等为主干的数 10 个不同模型^[12]。考虑到模型轻量化及检测实时性的需求,选择了网络深度与检测精度较为平衡的 RT-DETR-R18 作为基础模型,并对模型进行改进以更好地适用于海上平台井口盘上仪表表盘、表

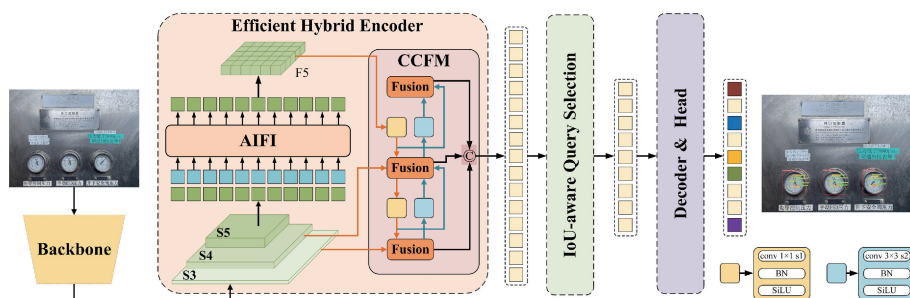


图 3 RT-DETR 网络模型结构
Fig. 3 RT-DETR network model structure

盘指针、指针回转中心、标度等目标的检测任务。

1) CSP-IEM 的构建与主干网络优化

在原 RT-DETR-r18 主干网络中,特征提取模块主要由一系列堆叠的 Basic-Block(内含多个卷积操作)组成,能够有效捕获全局语义信息^[13]。然而,随着网络深度和通道维度的增加,这些卷积层所需的参数量和计算量快速上升,使得模型在嵌入式或实时推理场景中面临存储受限与运算瓶颈等问题^[14]。为此,本文引入 CIDNet 中的 IEL(intensity enhance layer)模块,其定义如式(10)所示。IEL 首先将输入特征 \tilde{Y}_l 分解为“亮度分量” Y_l 与“反射分量” Y_R ,随后分别经由深度卷积 W_s 与 \tanh 激活进行非线性增强,再以逐元素乘积 \odot 融合两个分量,最后通过深度卷积 W_o 输出特征图。该结构在保持极低参数量的同时,通过分支式的非线性交叉增强,实现了暗区细节放

大与过曝抑制功能,并兼具噪声抑制功能。

$$\tilde{Y}_l = W_o([\tanh(W_s Y_l) + Y_l] \odot [\tanh(W_s Y_R) + Y_R]) \quad (10)$$

为了利用 IEL 的优势实现 RT-DETR 主干网络的优化,参考 CSP(cross-stage partial)思想^[15],提出一种跨阶段局部光照增强模块(cross-stage partial intensity enhancement module, CSP-IEM)。如图 4 所示,CSP-IEM 既保留了 CSP 的直通通路,又用 IEL 取代了重量级卷积单元,构建出更轻量的特征处理单元。最终,将 RT-DETR 主干网络的所有 Basic-Block 替换为 CSP-IEM,并对单元模块顺序作适当调整,以降低模型的参数量与计算量,并通过 IEL 的光照-反射联合增强机制,确保目标检测精度。预期可在维持模型检测精度前提下,实现更快的推理速度与更低的计算资源占用。




图 4 CSP-IEM 结构
Fig. 4 CSP-IEM structure

2) FEMAM 的构建与颈部网络优化

在原 RT-DETR-r18 颈部网络中,为了实现多尺度特征的深度融合,采用了 4 个 RepC3 模块^[16]。这些模块通过并行的多分支卷积,在训练阶段构建复杂的多路径信息流,并在推理时汇聚为单一路径,从而提升了模型语义表达能力。然而,RepC3 的多分支设计不可避免地带来了参数量和计算量的显著增加^[17]。为进一步对模型进行轻量化,引入混合聚合网络(mixed aggregation network, MANet)^[18]以替代传统的单路径卷积模块,在保持丰富特征表达的同时提升检测效率。MANet 并行融合了 3 种卷积变体:用于通道重标定的 1×1 卷积;用于高效空间特

征提取的深度可分离卷积(DSConv);用于增强层级融合能力的 ConvNeck。其中,ConvNeck 模块虽然增强了层级融合能力,但也增加了较多的参数开销。为此,考虑将 ConvNeck 模块替换为结构更为轻量的 FasterNet block^[19],构建一种快速增强混合聚合模块(faster enhanced mixed aggregation module, FEMAM)。FasterNet block 不仅保留了原有的感受野,还以更少的卷积核组合完成同等功能。FEMAM 模块结构如图 5 所示。

基于以上分析,将 RT-DETR 颈部网络的 4 个 RepC3 全部替换为 FEMAM,形成了轻量化且具备高效特征融合能力的新型颈部网络。这不仅在单阶段检测任务上带来

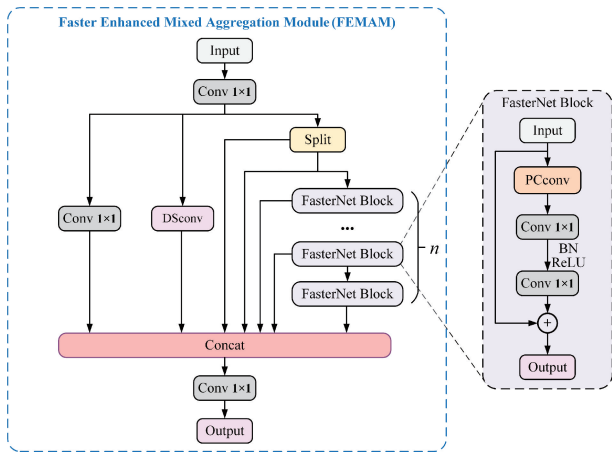


图5 FEMAM 模块结构

Fig. 5 FEMAM module structure

了更丰富的特征交互,还通过多条梯度路径的并行设计,使网络在轻量化条件下保持了对语义和空间信息的捕捉能力。

3) MAL 损失函数的构建

RT-DETR 采用的 VFL (varifocal loss)^[20] 损失函数如式(11)所示。VFL 主要针对目标检测中正负样本不平衡问题,通过同时兼顾分类精度与定位精度来提升检测性能^[21]。其核心思想在于引入动态加权机制,根据样本

特性对背景类别样本赋予较低权重,从而在训练过程中有效降低负样本对总损失的影响,同时提高模型对正样本的敏感性与响应能力。

$$VFL(p, q, y) = \begin{cases} -q \log(p) + (1 - q) \log(1 - p), & q > 0 \\ -\alpha p^\gamma \log(1 - p), & q = 0 \end{cases} \quad (11)$$

式中: p 是经 sigmoid 后的预测概率; q 是真实评分(如 IoU 分数); α 和 γ 为超参数。

然而, VFL 在 q 较小时,其乘子与标签值同时趋近于 0,导致模型几乎忽略了这部分低质量正样本。为增强模型对低质量匹配样本的关注并加速收敛,引入匹配感知损失 MAL (matchability-aware loss) 函数,如式(12)所示,其核心思想是在损失权重与监督标签中同时保留匹配质量信息。

$$MAL(p, q, y) = \begin{cases} -q^\gamma \log(p) + (1 - q^\gamma) \log(1 - p), & y = 1 \\ -p^\gamma \log(1 - p), & y = 0 \end{cases} \quad (12)$$

与 VFL 损失函数相比, MAL 直接以 q^γ 作为监督标签,简化了正和负样本的损耗权重,它对高质量匹配样本的处理与 VFL 类似,但增强了对低质量匹配的关注,从而提高了训练期间有限正样本的利用率。

整合 CSP-IEM、FEMAM 与 MAL 优化方法,优化后的 RT-DETR 模型如图 6 所示。

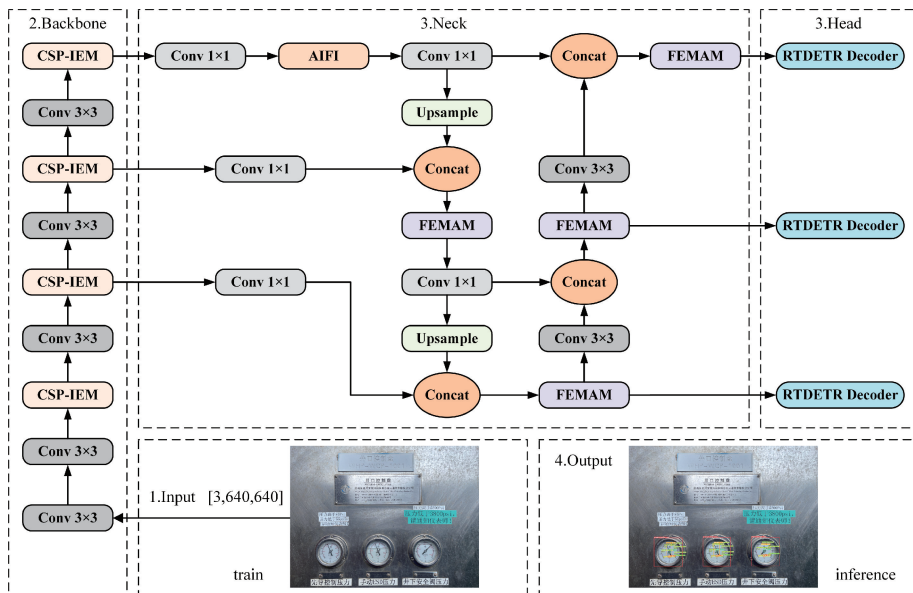


图6 优化后的 RT-DETR 模型结构

Fig. 6 Optimized RT-DETR model structure

3 实验分析

3.1 基于优化 RT-DETR 模型的目标检测实验

1) 实验条件

本文模型训练的实验环境配置为操作系统 Ubuntu

20. 04. 6 LTS、机带 RAM 32. 0 GB、CPU 为 13th Gen Intel (R) Core (TM) i7-13700KF、GPU 为 NVIDIA GeForce RTX 3090、算法框架为 PyTorch 2. 4. 1、编程语言为 Python 3. 8. 16、GPU 加速库为 CUDA 12. 1、cudnn 9. 1. 0。

模型训练的关键参数设置 epoch 设置为 300, batch

size 设置为 8,采用 SGD 优化器,初始学习率为 0.01,学习率动量为 0.937,权重衰减系数设置为 0.0005,模型输入图像大小为 640×640。

基于本课题组前期研制的海上平台井口控制盘仪表巡检系统(图 7),测试所用仪表图像均来自于现场实验。




图 7 海上平台井口控制盘仪表巡检系统
Fig. 7 Offshore platform wellhead control panel instrument inspection system

2) 数据集与评价标准

基于海上平台场景实拍,本文自建了相关数据集。通过数据增强处理,将数据集扩充至 3 294 张,数据集中包含了全部井口控制盘仪表图像,以及为增强模型泛化能力而采集的相似类型其他场景仪表图像。数据集按照 7 : 2 : 1 比例随机划分训练集、验证集和测试集。

为评价模型轻量化改进方法的有效性,选用的评价指标包括:参数量——模型中需要学习的参数数量;4 亿次浮点运算数(giga floating point operations per second, GFLOPs)——运行一次网络模型需要进行浮点运算的次数;模型权重大小——网络中所有可学习参数(权重和偏置)的总大小;平均精度均值(mean average precision, mAP)——所有类别检测的平均正确率(AP)的综合加权平均,受 IoU 阈值影响,后续使用 mAP @ 0.5;帧率(frames per second, FPS)——每秒检测图片的帧数。

3) 消融实验

为确定各改进方法的贡献度,共设计 5 组对照实验,如表 1 所示。其中 M0 为原 RT-DETR 模型,M1 为 CSP-IEM 模块,M2 为 FEMAM 模块,M3 为 MAL 损失函数。

表 1 消融实验结果

Table 1 Results of ablation experiment

模型	参数量/ ($\times 10^6$)	浮点运算数/ GFLOPs	权重 大小	mAP@0.5/ %	帧率/ fps
M0	19.882	57	40.5	0.754	197.2
M0+M1	13.825	46.9	28.4	0.751	215.8
M0+M2	19.829	52.4	40	0.759	207.2
M0+M3	19.882	57	40.5	0.762	201.9
M0+M1+M2+M3	13.772	42.3	27.9	0.761	216.0

根据表 1 的消融实验结果,可以得出以下结论:

(1)在原模型主干网络中引入 CSP-IEM 模块后,模型参数量、计算量及模型权重大小均显著减少,实现了模型轻量化,提高了模型检测速度,同时 mAP@0.5 指标与原模型差异不大;

(2)将原模型 RepC3 替换为 FEMAM,模型参数量、计算量、模型权重大小均有所降低,同时 mAP@0.5 指标得到一定提升;

(3)替换原模型损失函数为优化 MAL 损失函数,在模型参数量、计算量、模型权重大小和 FPS 指标方面无明显变化,但 mAP@0.5 指标得到一定的提升;

(4)综合采用上述优化措施,在保证模型检测精度的同时,显著降低了模型参数量、计算量及模型权重大小,并有效提升了模型检测速度。

4) 同类模型对比实验

为进一步验证优化后 RT-DETR 模型的优势,在综合考虑参数量和计算量的情况下,选取了 3 种主流 YOLO 模型(YOLOv8m、YOLOv9m、YOLOv11 m)进行对比实验,所用数据集和实验环境均相同,实验结果如表 2 所示。

表 2 模型性能对比

Table 2 Comparison of model performance

模型	参数量/ ($\times 10^6$)	浮点运算数/ GFLOPs	权重 大小	mAP@0.5/ %	帧率/ fps
YOLOv8m	25.844	78.7	52.1	0.753	193.8
YOLOv9m	20.019	76.5	40.9	0.758	158.5
YOLOv11m	20.036	67.7	40.5	0.758	209.8
优化 RT-DETR	13.772	42.3	27.9	0.761	216.0

由表 2 可知,所优化的模型在参数量、计算量、模型权重、模型的 mAP@0.5 值等方面均表现最优。说明所优化的模型在精度、实时性和计算资源消耗方面实现了较好的平衡。以上对比模型对海上平台井口仪表及盘面关键目标的检测效果如图 8 所示。

由图 8 可知,相比于对照模型,优化后的 EM-DETR 模型能够全部检测出预期的目标,无漏检,且所检测出目标的整体置信度较高,进一步证实了优化模型的有效性和优越性。

3.2 井口控制盘仪表自动读数实验

1) 评价指标

为了评估读数方法的准确性,引入了平均相对误差(mean relative error, MRE)和平均全局误差(mean global error, MGE)两个评价指标,其定义分别如式(13)和(14)所示。

$$MRE = \frac{1}{N} \sum_{i=1}^N \frac{|Y_i - Y_{m,i}|}{Y_{m,i}} \times 100\% \quad (13)$$

$$MGE = \frac{1}{N} \sum_{i=1}^N \frac{|Y_i - Y_{m,i}|}{X_{max} - X_{min}} \times 100\% \quad (14)$$




图8 各对照模型目标检测效果

Fig. 8 Target detection effect diagrams of each control model




图9 控制盘仪表图像

Fig. 9 Control panel instrument image

式中: Y_i 表示第 i 次读数的数值; $Y_{m,i}$ 表示第 i 次读数中, 人工方法的读数; X_{\max} 表示仪表刻度中的最大值; X_{\min} 表示仪表刻度中的最小值; N 为读数的总次数。

2) 自动读数实验

为验证本文读数方法的通用性与有效性, 在测试集中随机选取控制盘上4个点位的仪表图像进行自动读数实验, 如图9所示。某仪表的样条插值拟合曲线如图10所示。局部角度法与样条插值法对比读数结果如表3所示 ($N=3$)。

由表3可知, 本文所提出的基于 RT-DETR 模型与样条插值的读数方法, 实现了对井口控制盘仪表参数的自动读取。相较于传统的局部角度法, 样条插值法获得了更高的读数精度。该算法已应用于某海上平台, 并取得了稳定的应用效果。




图10 某仪表样条插值拟合曲线

Fig. 10 Spline interpolation fitting curve of a certain instrument

表3 控制盘仪表图像自动读数结果

Table 3 Automatic reading results of control panel instrument images

序号	Y_m /kPa	Y /kPa	$X_{\max} - X_{\min}$ /kPa	MRE/%		MGE/%	
				局部角度法	样条插值法	局部角度法	样条插值法
1	460	462.75	1 200	1.19	0.60	0.46	0.23
2	460	461.98	1 200	0.91	0.43	0.35	0.17
3	27 900	27 906.78	40 000	0.28	0.02	0.19	0.02
4	32 800	32 806.70	40 000	0.13	0.02	0.10	0.02
5	16 000	15 993.83	40 000	0.33	0.04	0.13	0.02
6	27 100	27 146.32	40 000	0.41	0.17	0.27	0.12
7	17 600	17 709.70	40 000	0.63	0.62	0.28	0.27
8	34 100	34 246.39	40 000	0.88	0.43	0.75	0.37
9	16 900	16 992.91	40 000	0.58	0.55	0.24	0.23
10	17 900	17 914.22	40 000	0.19	0.08	0.09	0.04

4 结 论

基于海上平台井口控制盘仪表参数自动读取的现实需求,提出一种基于深度学习目标识别与样条插值的参数读取方法。首先,针对传统局部角度法仪表参数读取误差大(尤其是针对具有一定变形的仪表)问题,提出了一种基于 3 次样条插值的仪表参数读取方法,有效地提高了参数读取精度。其次,为实现模型轻量化及仪表关键目标的高精度提取,从主干网络重构、颈部网络轻量化及损失函数 3 个方面对 RT-DETR 模型进行改进。相关实验表明,改进后的模型兼顾了精度与效率,并在参数量、计算量、模型权重、模型的 mAP@0.5 值等关键指标上均表现最优。最后,通过对海上平台井口控制盘仪表巡检图像的读数实验证明,本文提出的基于 RT-DETR 与样条插值的读数方法具有较高的读数精度。相较于传统的局部角度法,本文提出的样条插值法的 MRE 和 MGE 均显著降低。然而,在前期仪表信息矩阵的构建过程中依赖于人工操作,需要耗费较多的时间,且若原始仪表信息参数输入错误也会严重影响后期读数精度。今后,考虑将 OCR 技术与目标检测模型相融合,辅助前期仪表信息矩阵的构建过程,减少前期准备时间并提升工作效率。

参考文献

- [1] NINAMA H, RAIKWAL J, RAVURI A, et al. Computer vision and deep transfer learning for automatic gauge reading detection[J]. *Scientific Reports*, 2024, 14(1): 23019.
- [2] FENG J, LUO H, MING R. Pointer meters recognition method in the wild based on innovative deep learning techniques[J]. *Scientific Reports*, 2025, 15(1): 845.
- [3] LIN Y, XU Z, CHEN D, et al. Occluded meter reading with pointer mask generation based on generative adversarial network [J]. *IEEE Transactions on Instrumentation and Measurement*, 2025, 74: 1-13.
- [4] LEON-ALCAZAR J, ALNUMAY Y, ZHENG C, et al. Learning to read analog gauges from synthetic data[C]. *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision (WACV)*, 2024: 8616-8625.
- [5] SALOMON G, LAROCA R, MENOTTI D. Deep learning for image-based automatic dial meter reading: Dataset and baselines [C]. *2020 International Joint Conference on Neural Networks (IJCNN)*. IEEE, 2020: 1-8.
- [6] 陶金,林文伟,曾亮,等.基于 YOLOv4-tiny 和 Hourglass 的指针式仪表读数识别[J]. *电子测量与仪器学报*, 2023,37(5): 1-10.
TAO J, LIN W W, ZENG L, et al. Pointer gauge reading recognition based on YOLOv4-tiny and Hourglass [J]. *Journal of Electronic Measurement and Instrumentation*, 2023, 37(5): 1-10.
- [7] MA Y, JIANG Q, WANG J, et al. An automatic reading method of pointer instruments [C]. *2017 Chinese Automation Congress (CAC)*. IEEE, 2017: 1448-1453.
- [8] HUANG Z, WANG Y, ZHANG Y, ZHANG C. A robust pointer meter reading method for inspection robots in real industrial scenarios [J]. *Neural Computing and Applications*, 2025, 37(7): 5369-5379.
- [9] PANG J, LIU B, HAN Z, et al. Improvement of the reading algorithm for pointer instruments based on deep learning [J]. *Engineering Research Express*, 2025, 7(1): 015271.
- [10] ZHAO Y, LV W, XU S, et al. Detsr beat YOLOs on real-time object detection[C]. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2024: 16965-16974.
- [11] 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 (CVPR)*, 2016: 779-788.
- [12] FEI S, ZHANG H. Visual detection of moving stacked objects based on efficient multi-scale grouping and improved multi-head self-attention [J]. *Measurement Science and Technology*, 2025, 36(3): 036208.
- [13] YU C, CHEN X. Railway rutting defects detection based on improved RT-DETR[J]. *Journal of Real-Time Image Processing*, 2024, 21(4): 146.
- [14] 钱承山,沈有为,孙宁,等.基于 Transformer 改进 YOLOv5 的山火检测方法研究[J]. *电子测量技术*, 2023,46(16): 46-56.
QIAN CH SH, SHEN Y W, SUN N, et al. Wildfire detection based on transformer-enhanced YOLOv5 [J]. *Electronic Measurement Technology*, 2023, 46(16): 46-56.
- [15] WANG C Y, LIAO H Y M, WU Y H, et al. CSPNet: A new backbone that can enhance learning capability of CNN[C]. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, 2020: 390-391.
- [16] ZHOU C, HE H, ZHOU H, et al. MSRT-DETR: A novel RT-DETR model with multi-scale feature sequence for cell detection[J]. *Biomedical Signal Processing and Control*, 2025, 103: 107378.
- [17] 张君轶,陈仁文,刘飞,等.基于嵌入式视觉的无人机目标定位系统[J]. *国外电子测量技术*, 2023, 42(2): 171-176.

ZHANG J Y, CHEN R W, LIU F, et al. UAV target localization system based on embedded vision [J]. Foreign Electronic Measurement Technology, 2023, 42(2): 171-176.

- [18] FENG Y, HUANG J, DU S, et al. Hyper-YOLO: When visual object detection meets hypergraph computation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2024, 47(4): 2388-2401.
- [19] CHEN J, KAO S H, HE H, et al. Run, don't walk: Chasing higher FLOPS for faster neural networks [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2023: 12021-12031.
- [20] ZHANG H, WANG Y, DAYOUB F, et al. VarifocalNet: An IoU-aware dense object detector [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2021: 8514-8523.
- [21] 冷冰,冷敏,常智敏,等. 基于 Transformer 结构的深度学习模型用于外周血白细胞检测 [J]. 仪器仪表学报, 2023, 44(5): 113-120.
- LENG B, LENG M, CHANG ZH M, et al. Deep-learning model based on transformer for peripheral blood leukocyte detection [J]. Chinese Journal of Scientific Instrument, 2023, 44(5): 113-120.

作者简介



张清正, 2023 年于山东理工大学获得学士学位, 现就读于天津职业技术师范大学, 主要研究方向为智能检测及应用。

E-mail: 0322231098@tute.edu.cn

Zhang Qingzheng received his B. Sc. degree from Shandong University of Technology

in 2023. Now he is studying at Tianjin University of Technology and Education. His main research interests include intelligent detection and its applications.



张仕海 (通信作者), 2012 年于北京工业大学获得博士学位, 现为天津职业技术师范大学教授, 主要研究方向为现代信号处理、机器视觉与人工智能技术。

E-mail: zshky77@163.com

Zhang Shihai (Corresponding author)

received his Ph. D. degree from Beijing University of Technology in 2012. Now he is a professor in Tianjin University of Technology and Education. His main research interests include modern signal processing, machine vision, and artificial intelligence technology.



屈重年, 2001 年于集美大学获得学士学位, 2009 年于天津理工大学获得硕士学位, 2013 年于北京工业大学获得博士学位, 现为天津职业技术师范大学副教授, 主要研究方向为智能制造、精密与超精密技术及其自动化装备。

E-mail: qchnian@126.com

Qu Chongnian received his B. Sc. degree from Jimei University in 2001, M. Sc. degree from Tianjin University of Technology in 2009 and Ph. D. degree from Beijing University of Technology in 2013, respectively. Now he is an associate professor in Tianjin University of Technology and Education. His main research interests include intelligent manufacturing, precision and ultra-precision technologies, and their automated equipment.



郭晓赛, 2023 年于黄淮学院获得学士学位, 现就读于天津职业技术师范大学, 主要研究方向为深度学习与图像处理。

E-mail: 0321231023@tute.edu.cn

Guo Xiaosai received her B. Sc. degree from HuangHuai University in 2023. Now she

is studying at Tianjin University of Technology and Education. Her main research interests include deep learning and image processing.