

DOI: 10.13382/j.jemi.B2508647

基于 StarNet 改进的轻量化连铸板坯检测算法

SGI-YOLOv7*

刘 乐 顾玲珑 李子洋 方一鸣

(燕山大学智能康复及神经调控河北省重点实验室 秦皇岛 066004)

摘要:针对当前通用检测算法存在的网络复杂度高、参数量大、难以适应连铸产线复杂环境与严苛实时要求等问题,提出一种基于 StarNet 改进的轻量化连铸板坯检测算法 SGI-YOLOv7 (YOLOv7 with StarNet, GSConv-based Slim-neck, and Inner-SIoU loss function)。首先,基于采集的连铸产线板坯图像构建用于板坯检测的专用数据集;其次,采用 StarNet 替换 YOLOv7 (you only look once version 7) 主干网络,利用星型操作实现高效特征映射,有效降低了模型参数规模和计算复杂度;再次,引入基于分组混洗卷积 (group shuffle convolution, GSConv) 的轻量化 Slim-neck 结构,实现跨层级特征的高效融合与压缩;同时,设计基于辅助边框的内部尺度感知交并比 (inner scale-aware intersection over union, Inner-SIoU) 损失函数,通过方向感知梯度优化与多尺度回归机制,提升模型在宽高比差异显著场景下的适应性及收敛速度。最后,在自制板坯数据集上的对比实验结果表明,所提 SGI-YOLOv7 算法在维持较高检测精度 (mAP@0.5 为 96.0%) 的同时,参数量较基准 YOLOv7 模型减少 35.6%、计算量降低 65.6%,推理速度达到 82 fps,显著减轻硬件部署负担,实现了工业场景下连铸板坯的高效、轻量化实时检测。

关键词: 连铸板坯检测; YOLOv7; 轻量化; StarNet; 损失函数

中图分类号: TN911.73

文献标识码: A

国家标准学科分类代码: 520

Improved lightweight continuous casting slab detection algorithm

SGI-YOLOv7 based on StarNet

Liu Le Gu Linglong Li Ziyang Fang Yiming

(Key Laboratory of Intelligent Rehabilitation and Neuroregulation of Hebei Province,
Yanshan University, Qinhuangdao 066004, China)

Abstract: Aiming at the problems of high network complexity, large parameter size, and difficulty in adapting to the complex environment and stringent real-time requirements of continuous casting production lines in current general detection algorithms, this paper proposes a lightweight continuous casting slab detection algorithm named SGI-YOLOv7 (YOLOv7 with StarNet, GSConv-based Slim-neck, and Inner-SIoU loss function). Firstly, a dedicated dataset for slab detection is constructed based on images collected from the continuous casting production line. Secondly, StarNet is adopted to replace the backbone network of YOLOv7 (you only look once version 7), utilizing star operations to achieve efficient feature mapping, which effectively reduces the model's parameter scale and computational complexity. Thirdly, a lightweight Slim-neck structure based on group shuffle convolution (GSConv) is introduced to achieve efficient fusion and compression of cross-level features. Simultaneously, an inner scale-aware intersection over union (Inner-SIoU) loss function is designed based on auxiliary bounding boxes, which enhances the model's adaptability and convergence speed in scenarios with significant aspect ratio variations through direction-aware gradient optimization and a multi-scale regression mechanism. Finally, comparative experimental results on the self-built slab dataset show that the proposed SGI-YOLOv7 algorithm maintains high detection accuracy (mAP@0.5 is 96.0%) while reducing parameters by 35.6% and computational cost by 65.6% compared to the baseline YOLOv7 model, with an inference speed reaching 82 frames per second. This significantly alleviates the hardware deployment burden and achieves efficient, lightweight, real-time detection of continuous casting slabs in industrial scenarios.

Keywords: continuous casting slab detection; YOLOv7; lightweight; StarNet; loss function

收稿日期: 2025-08-07

Received Date: 2025-08-07

* 基金项目: 国家自然科学基金 (62573375)、河北省自然科学基金 (F2024203038)、秦皇岛市科学技术研究与发展计划项目 (202302B048)、省级重点实验室绩效补助经费项目 (22567619H) 资助

0 引言

钢铁产业作为工业体系的核心支柱,其发展水平是国家综合实力与产业竞争力的重要体现^[1-2]。连铸板坯是炼钢与热轧的关键中间产品,在现代钢铁企业广泛推行的“热送热装”工艺中,高温板坯从结晶器拉出后需立即进行切割、调度与输送。在该高速连续的生产过程中,若板坯状态无法被实时、准确地感知与跟踪,可能引发以下问题:1)高温板坯在吊运、输送过程中若发生位置偏移、掉落或与设备碰撞,将引发严重安全事故,威胁人员与设备安全;2)一旦发生“混钢”(即不同钢种板坯混淆),不仅会导致整批次产品质量下降,还会造成材料与能源浪费,甚至导致生产中断。3)传统人工巡检难以实现全流程、高精度的板坯跟踪,致使制造执行系统中的物流信息无法闭环,影响生产效率与资源调度优化。因此,对板坯进行在线、实时的准确检测与跟踪,不仅是实现物流闭环、防止“混钢”事故、保障高温作业安全的前提,更是提升连铸产线自动化和智能化水平的必由要求。

目前,钢铁企业普遍采用基于可编程逻辑控制器(programmable logic controller, PLC)的红外射频板坯检测与跟踪系统。然而,该系统在实际应用中存在明显局限:红外传感器在传送轨道上间隔安装,只能获取连铸板坯经过特定位置的离散数据,难以实现连续的位置跟踪。另外,传感器长期暴露于连铸现场的高温辐射、强电磁干扰、高浓度水蒸气及导电粉尘等恶劣环境中,导致其内部电子/光学元件极易老化、性能衰退、维护成本较高,且存在检测信号不稳定、误报率高等问题,致使板坯实际位置(物理流)与信息系统中的跟踪数据(信息流)严重脱节,甚至出现跟踪丢失,严重影响生产调度的准确性与连续性。因此,采用非接触、高鲁棒性的机器视觉技术替代常规传感方式,已成为实现可靠、精准跟踪的迫切需求。

另外,在国家积极推进钢铁工业“数字化转型”与“智能制造”的背景下,基于视觉的连铸板坯检测系统可有效替代人工巡检和基于 PLC 的红外射频检测方式,能够为智能调度、质量预警、工艺优化提供实时数据支撑,进一步提升连铸产线信息化水平,符合行业高质量发展方向。近年来,随着计算机性能的持续提升,尤其是卷积神经网络(convolutional neural network, CNN)的提出与发展,基于机器视觉与深度学习的目标检测算法已在众多领域得到广泛应用,并表现出卓越性能^[3-5]。基于卷积神经网络的工作原理,目标检测算法主要分为两类,两阶段算法和单阶段算法,其核心区别在于特征提取前是否包含候选区域生成步骤。两阶段检测算法流程相对复杂,

以区域卷积神经网络(region-based convolutional neural network, R-CNN)系列算法为代表。2014年, Girshick 等^[6]开创性地提出了 R-CNN 算法,该算法利用选择性搜索方法生成候选区域,有效克服了传统方法在特征表示上的局限。然而,该算法特征提取过程复杂且耗时,尤其在复杂背景下尤其难以高效生成有效候选框。随后, Ren 等^[7]提出了 Faster R-CNN 网络,引入区域建议网络以取代选择性搜索方法,实现候选区域的自动生成,并结合边界框回归进一步提升检测框定位精度,最终实现了真正的端到端检测。尽管如此,两阶段算法虽然通常具备较高的检测精度,但其固有的多阶段流程导致计算冗余显著增加,计算开销也随之上升。

相比之下,单阶段算法通过精简模型结构,在保持检测性能的同时显著提升了模型紧凑性、减少了参数量,并大幅优化了检测速度。典型代表包括 YOLO(you only look once)系列和 SSD(single-shot multi-box detector)系列算法。2015年, Redmon 等^[8]提出了首个单阶段检测算法 YOLO,该算法采用单一神经网络对整幅图像进行统一处理,实现了端到端的高效检测。随后相继推出的 YOLOv2^[9]、YOLOv3^[10]、YOLOv4^[11]等改进版本,在保持高速推理的同时显著提升了检测精度。2016年,文献[12]提出的 SSD 算法通过数据增强技术和多尺度特征映射,有效提升了模型对不同尺度目标的检测泛化能力。然而,尽管 YOLO 系列和 SSD 系列算法在检测速度上能够满足实时性要求,但其检测精度与 R-CNN 系列为代表的两阶段方法相比仍存在差距。2020年, Lin 等^[13]指出单阶段检测算法精度受限的主要原因在于训练过程中海量的背景样本,导致模型过度关注背景而忽视前景目标,并提出 RetinaNet 架构,通过引入焦点损失函数对不同难度的样本进行加权,使模型更关注难以检测的目标。然而,文献[13]基于锚框的目标检测架构本身存在超参数数量庞大、生成冗余检测框等固有局限性。为克服这些问题并简化模型设计流程,文献[14]受关键点检测启发,提出的 CornerNet 完全摒弃锚框机制,通过检测目标边界框的左上角与右下角两个关键点来实现定位。2023年,文献[15]提出 YOLOv7 架构,通过结合模型结构重参数化、动态标签分配策略以及辅助损失函数,有效平衡了计算复杂度与检测性能。

然而,通用检测算法直接部署于连铸生产现场,仍面临严峻的“工业场景多维约束”挑战,这主要源于连铸现场复杂的视觉环境与严苛的工业部署要求。1)成像环境复杂,目标特征提取困难。连铸现场持续存在高温红外辐射、冷却工序带来的高浓度水雾以及弥漫的导电粉尘,导致采集图像常出现过曝、模糊或对比度不足的现象,为目标特征的稳定提取带来困难。2)遮挡频繁与尺度变化剧烈。在实际生产中,吊运板坯的天车及其他设备极易

对板坯造成局部或完全遮挡。同时,由于摄像头安装位置固定,板坯在辊道运输及天车吊运过程中与摄像头的距离会发生大幅变化,引起板坯目标在图像中的尺度变化剧烈,因而对检测网络的感受野设计及多尺度适应能力提出了较高要求。3)实时性要求严苛。为匹配连铸机高速拉坯节奏与天车调度速度,视觉检测算法需与生产节拍严格同步。在工业边缘设备算力有限条件下,检测算法的推理速度需稳定在 15 fps 以上才能保证视频流处理的连贯性。4)检测精度与可靠性要求高。连铸生产对板坯漏检与误检具有极低容忍度,要求检测算法在复杂干扰下仍保持较高的检测精度(通常要求 $mAP@0.5 > 95\%$),以确保每块板坯均被准确跟踪。5)工业边缘设备算力受限。现有通用检测算法(如原版 YOLOv7)虽在精度上满足要求,但其参数量大、计算复杂度高,难以在算力受限的工业边缘设备上实现实时推理;常规的轻量化模型(如简单剪枝或浅层网络)在面对上述复杂现场环境、遮挡频繁与尺度变化剧烈时,往往因特征提取能力不足,难以同时满足高精度与高效率的工业检测标准。

为解决上述矛盾,文献[16]采用 Fire 模块压缩传统卷积神经网络的参数量,并结合模型压缩技术实现在 ImageNet 数据集上保持较高精度的同时,具有更少的参数量和更快的推理速度,然而该方法过度压缩参数导致深层特征提取能力不足。文献[17]利用深度可分离卷积(depth-wise separable convolution, DWConv)替代传统卷积操作,从而能更有效地利用模型参数,然而该方法在移动端部署时存在内存访问瓶颈。文献[18]通过设置宽度乘法器和分辨率乘法器两个全局超参数,实现了准确率和推理速度的平衡,然而该方法的超参数需人工预设,缺乏对不同场景的自适应能力。文献[19]提出的 MobileNetv3 通过引入 Hard Sigmoid 激活函数与压缩-激励(squeeze-and-excitation, SE)注意力机制,在参数增量可控的前提下显著提升了目标检测任务的准确率,然而 SE 模块的静态权重分配策略难以适应动态变化的工业场景。可以看出,这些方法虽在推进模型压缩方面取得进展,但在精度、推理效率与环境适应性等方面仍存在不同局限,不能完全满足连铸板坯检测所要求的高精度、高实时性与强鲁棒性并重的需求。

基于上述分析,为实现板坯从连铸区到热轧区全时段、全方位、全流程的在线实时检测,并在有限算力与高精度检测之间寻求平衡,本文提出一种基于 StarNet 改进的轻量化目标检测算法 SGI-YOLOv7 (YOLOv7 with StarNet, GSConv-based Slim-neck, and Inner-SIoU loss function)。主要创新工作如下:1)主干网络轻量化设计:引入 StarNet^[20]作为主干网络,通过星型操作在低维空间中实现高维非线性特征的高效映射,显著降低了模型的

参数量与计算复杂度,并保持对板坯细微特征的提取能力。2)高效特征融合结构:使用分组混洗卷积(group shuffle convolution, GSConv)替代传统卷积构建轻量化 Slim-neck 结构^[21],实现跨层级特征的高效融合与信息交互,进一步压缩网络总参数量,增强模型在多尺度目标下的特征表达能力。3)边界框回归优化机制:设计基于辅助边框的内部尺度感知交并比(inner scale-aware intersection over union, Inner-SIoU)损失函数^[22-23],通过引入方向感知梯度优化与多尺度辅助回归机制,显著加速模型收敛,提升模型在宽高比差异较大目标(如板坯与天车)上的定位鲁棒性与适应能力。最后,在自制板坯数据集上的实验结果表明,所提 SGI-YOLOv7 算法在实现对连铸板坯有效检测的同时能显著减少参数量和计算量,有效解决了高性能算法在算力受限工业边缘设备上实时部署的难题,满足连铸生产现场对高精度、高实时性在线检测的严苛要求。

1 连铸板坯检测数据集构建

由于目前尚无公开的连铸板坯检测数据集供本文使用,故本文在某钢厂连铸产线上安装了 6 台相同型号的高分辨率摄像机(4 000 000 pixel)对连铸板坯整个运输过程进行全面监测,如图 1 所示,每帧图像的分辨率均为 1 920×1 080 pixels。



图 1 板坯数据集部分展示

Fig. 1 Partial display of the slab dataset

数据集的标签使用 LabelImg 工具生成,这些标签被分为 3 类,板坯(slab)、天车(crane)和夹取板坯的天车(craneandslab)。其中,板坯是本文重点检测目标,而在数据集中加入“天车”和“夹取板坯的天车”这两类目

标是基于工业现场特性的必要考量:1)天车与板坯在视觉上均属于大型金属结构且空间关联密切(常相邻或重叠),显式标注“天车”可利用监督信号引导模型依据形态与上下文学习更精细的特征区分,从而降低对相似背景目标的误检率;2)板坯在吊运过程中常被天车部分或完全遮挡,显式标注“夹取板坯的天车”有助于模型学习特定遮挡下的语义特征,增强在遮挡场景下的板坯识别能力;3)该标注方式有助于调度系统识别板坯的“静止/运输/吊运”等逻辑状态,为板坯生产调度与跟踪提供更丰富的语义信息,符合工业现场对全流程感知的需求。

为增加训练图像的多样性,增强模型在连铸复杂现场中的泛化能力,本文将 6 个摄像机拍摄的含不同背景的图片进行混合,形成统一的数据集。另外,本数据集在构建时充分考虑了影响视觉检测的多维因素:1)季节多样性:涵盖春、夏、秋、冬不同季节采集的图像,以包含温差、湿度、雾气、设备表面状态(如:冷凝水、霜冻)对成像质量的影响;2)板坯成型时间与温度状态差异:数据集中包含刚切割的高温板坯(亮红黄色、边缘热浪畸变)、冷却中的中温板坯(暗红色至灰色)、以及已冷却的常温板坯(灰黑色、氧化铁皮完整),覆盖板坯从产出到入库的全温度状态谱;3)环境与目标交互变化:包括光照变化、天车遮挡、板坯表面氧化与污染、设备运动模糊等真实工况。通过采集真实多状态数据,可促使视觉模型学习更具鲁棒性的特征表示,从而在实际部署中适应全时段、全方位、全流程的连续检测任务。最终,该数据集由 3 000 张具有不同背景的照片组成,随后以 6 : 2 : 2 的比例划分为训练集、验证集和测试集。具体如表 1 所示。

表 1 板坯数据集中图片和标签数量

Table 1 The number of images and labels in the slab dataset

数据集	图片数量	标签数量		
		slab	crane	craneandslab
训练集	1 800	3 457	1 298	986
验证集	600	1 129	431	339
测试集	600	2 154	849	587
总计	3 000	6 740	2 578	1 912

2 改进的轻量化目标检测算法 SGI-YOLOv7

2.1 基于 StarNet 的主干网络

主干网络的选取对检测模型的整体性能和计算复杂度具有显著影响。当前常用的轻量级主干网络(如 GhostNet、ShuffleNetv2 和 FasterNet 等)通过特征重用与特征重组策略,在保持低参数量与计算量的同时,增强了网络对高维非线性特征的表征能力。然而,研究者为了强

化特征提取能力而引入的基于点积相乘的注意力机制虽能提升特征判别性,却导致计算复杂度激增,显著降低运行效率。而星型操作因其在自然语言处理、计算机视觉等多个领域的卓越性能,常被引入到轻量化网络设计中。其中,基于星型操作构建的 StarNet 模型^[20],通过将低维输入特征非线性映射至高维特征空间,实现了对复杂高维特征的准确捕获。该模型借助特征空间升维机制,显著提升了复杂场景下目标聚焦能力与特征提取效能,并兼具高实时性与检测精度。本文采用 StarNet 替代 YOLOv7 模型中原有的主干网络,通过减少计算量和参数量来实现轻量化,同时利用特征重用和特征重组增强对高维非线性特征的表征能力,从而提升网络效率。StarNet 结构示意图如图 2 所示。




图 2 StarNet 结构示意图

Fig. 2 StarNet structure diagram

图 2 中,StarNet 采用 4 级分层设计结构,每级使用卷积层进行下采样,并采用 Star Block 进行特征提取。该结构对应 YOLOv7 主干网络的前 5 层,共完成 5 次下采样操作。StarNet 首先使用 1 个 3×3 的卷积层来降低输入分辨率,随后通过由 4 个 3×3 的卷积和 Star Block 组成的功能模块进行特征提取。每个 Star Block 的深度(迭代次数)可独立设置,在提升网络灵活性的同时增强了特征提取能力。此外,Star Block 模块采用 7×7 的 DWConv 提取输入特征。与传统卷积相比,DWConv 对输入数据的每个通道单独进行卷积,再将结果逐元素相加,有效减少了参数量和计算量,加速了训练与推理过程。其次,对输出特征进行高效标准化处理:使用 2 路通道扩展因子为 4 的 1×1 卷积核进行特征升维,生成 2 个通道数分别扩大

4 倍的特征图,并选取其中一路通过 ReLU6 激活函数进行非线性映射。再次,对 2 路输出执行逐元素乘法,实现跨通道信息交互并显著提升特征维度。最后,将结果输入至第 2 个 DWConv 模块以提取更深层次特征,得到最终的输出特征图。

在单层神经网络中,StarNet 将权重矩阵和偏差与输入矩阵 X 合并,再与输入特征执行逐元素乘法后输出,具体如式(1)所示^[20]。

$$\begin{cases} Y = (W_1^T X_1) \cdot (W_2^T X_1) \\ W_1 = [W \ B_1]^T, W_2 = [W \ B_2]^T \end{cases} \quad (1)$$

式中: Y 为执行逐元素乘法操作后的输出特征; W 为线性层的权重矩阵; B_1, B_2 为偏置向量; $X_1 = [X, a]^T$ 为输入增广矩阵(包含常数项 a); $*$ 表示星型操作。

定义 $w_1, w_2, x \in R^{(c+1) \times 1}$, c 为输入特征通道数,则该星型操作可表述为式(2)所示^[20]。

$$\begin{aligned} w_1^T x * w_2^T x = & \left(\sum_{i=1}^{c+1} w_1^i x^i \right) * \left(\sum_{j=1}^{c+1} w_2^j x^j \right) = \sum_{i=1}^{c+1} \sum_{j=1}^{c+1} w_1^i w_2^j x^i x^j = \\ & \underbrace{\alpha_{(1,1)} x^1 x^1 + \dots + \alpha_{(4,5)} x^4 x^5 + \dots + \alpha_{(c+1,c+1)} x^{c+1} x^{c+1}}_{\frac{(c+2)(c+1)}{2}} \end{aligned} \quad (2)$$

式中: i, j 为通道下标; α 为各项系数,其表达式如式(3)所示^[20]。

$$\alpha(i, j) = \begin{cases} w_1^i w_2^j, & i = j \\ w_1^i w_2^j + w_1^j w_2^i, & i \neq j \end{cases} \quad (3)$$

由式(3)可知,高效的星型操作可将 c 维输入空间展开得到维度为 $\frac{(c+1)(c+2)}{2} \approx \left(\frac{c}{\sqrt{2}}\right)^2$ 的复杂隐式高维特征,显著提升了特征维度,且单层内不会引入额外的计算开销。

相较于传统神经网络通过增加网络宽度和深度以提升性能的范式,星型运算可视为一种在特征通道间执行

成对乘法的核映射机制,具备多项式核函数的扩展特性。当该运算被嵌入神经网络架构并形成多层堆叠结构时,每层网络都会引发隐式维度复杂度呈指数级递增。通过如式(4)所示的多层星型操作堆叠,可以递归地将隐式维度扩展至接近无限^[20]。

$$\begin{aligned} Y_1 &= \sum_{i=1}^{c+1} \sum_{j=1}^{c+1} w_{(1,1)}^i w_{(1,2)}^j x^i x^j, \in R^{\left(\frac{c}{\sqrt{2}}\right)^2} \\ Y_2 &= W_{2,1}^T Y_1 \cdot W_{2,2}^T Y_1, \in R^{\left(\frac{c}{\sqrt{2}}\right)^2} \\ Y_3 &= W_{3,1}^T Y_2 \cdot W_{3,2}^T Y_2, \in R^{\left(\frac{c}{\sqrt{2}}\right)^3} \\ &\vdots \\ Y_n &= W_{n,1}^T Y_{n-1} \cdot W_{n,2}^T Y_{n-1}, \in R^{\left(\frac{c}{\sqrt{2}}\right)^{2^n}} \end{aligned} \quad (4)$$

式中: Y_n 表示第 n 次星型操作的输出。

因此,通过 n 层堆叠,星型操作能在紧凑的特征空间

内实现维度以 $R^{\left(\frac{c}{\sqrt{2}}\right)^{2^n}}$ 指数级扩展。这种在紧凑特征空间内进行高效计算的能力,同时受益于隐含的高维度特性,使得网络结构精简且运算高效,显著减少了信息冗余和计算成本。

2.2 基于 GSConv 的轻量化颈部网络

为优化模型参数规模与计算效率,可采用深度可分离卷积直接替代传统卷积,然而此类方法常导致目标检测精度显著下降。为此,本文引入了基于 GSConv 的轻量化 Slim-neck 结构^[21],通过构建融合传统卷积与深度可分离卷积的混合卷积层,在保持模型精度的同时实现结构轻量化。该模块包含标准卷积层、深度可分离卷积层及通道混洗操作,其核心在于通过通道混洗融合两类卷积的输出特征,将标准卷积提取的全局特征注入深度可分离卷积的输出通道,以促进局部特征的跨通道交互。GSConv 结构如图 3 所示。




图 3 GSConv 结构

Fig. 3 GSConv structure diagram

图3中,以 C_1 通道的特征图为输入信号传入GSConv模块,最终输出 C_2 通道的特征图。GSConv模块首先对输入特征应用标准卷积进行通道信息融合,产生具有 $C_2/2$ 输出通道的特征。随后,通过深度可分离卷积处理该特征,生成通道数减半的特征图。最后,通过拼接(Concat)操作融合深度可分离卷积与标准卷积的输出特征。该方法将深度可分离卷积与标准卷积结合,在保留标准卷积特征提取能力的同时,通过分离通道内/间运算显著降低计算开销,增强模块的非线性表征能力。

尽管GSConv能有效降低计算复杂度,但为充分发挥其性能优势,仍需与其他模型架构结合,以实现推理速度与检测精度之间的平衡。为进一步提升颈部网络的特征复用效率与推理速度,本文采用VoVGSCSP(cross-stage partial network integrating VoVNet and GSConv)结构替换YOLOv7颈部网络中原有的高效层级聚合网络结构,并保持输入与输出维度不变。如图4所示,VogVSCSP是一种复合型轻量化结构,其设计融合了3类关键思想:首先,引入了VoVNet的“一次性聚合”机制,通过并行化特征提取路径与终端统一融合,显著提升了特征复用效率,避免了传统链式聚合中反复拼接所带来的内存与计算开销;其次,通过残差连接将标准卷积与GSConv模块进行有机整合,在确保检测器精度的前提下,实现推理时间与模型参数量的双重优化;最后,通过吸收跨阶段局部网络的特征融合机制,将输入特征分为两部分进行处理,一部分直接短接到输出,另一部分经过轻量化特征提取路径,从而在增强梯度流多样性的同时,进一步抑制了计算冗余。

2.3 基于辅助边框的 Inner-SIoU 损失函数

在目标检测算法的构建与优化过程中,作为评估模型预测结果与真实标签间差异程度的关键指标,损失函数指导着模型的训练与优化方向。通常,损失函数值越高表明模型预测与实际情况偏差越大,模型性能不足;反之则表明预测与真实情况吻合度高,模型性能较优。

传统目标检测损失函数(完全交并比(complete intersection over union, CIoU)损失函数)在边界框回归中依赖交并比(intersection over union, IoU)的计算来衡量预测框与真实框的匹配程度。然而,此类方法在优化过程中缺乏明确的收敛方向,导致预测框收敛速度慢且效率低。特别地,当预测框与真实框具有相同长宽比,但宽度和高度值完全不同的情况下,CIoU损失函数难以进行有效优化,为此本文引入了尺度感知交并比(scale-aware intersection over union, SIoU)损失函数^[22]。SIoU综合考虑了重叠面积、形状、中心点距离和角度等多个因素,通过最小化与距离相关的变量个数,可实现更快速、更精准的目标检测优化。SIoU示意图如图5所示,其中B表示预测框, B^{gt} 表示真实框。




图4 VoVGSCSP结构

Fig. 4 VoVGSCSP structure diagram




图5 SIoU示意图

Fig. 5 SIoU schematic diagram

SIoU充分考虑了角度损失,其定义如式(5)所示^[22]。

$$\Lambda = 1 - 2\sin^2\left(\arcsin(z) - \frac{\pi}{4}\right) \quad (5)$$

式中: $z = \frac{C_h}{\delta} = \sin(\alpha)$; $\delta = \sqrt{(b_{c_x}^{gt} - b_{c_x})^2 + (b_{c_y}^{gt} - b_{c_y})^2}$, $C_h = \max(b_{c_y}^{gt}, b_{c_y}) - \min(b_{c_y}^{gt}, b_{c_y})$ 。其中, $b_{c_x}^{gt}$ 和 $b_{c_y}^{gt}$ 分别表示真实框中心点的x轴和y轴坐标; b_{c_x} 和 b_{c_y} 分别表示预测框中心点的x轴和y轴坐标; C_w 和 C_h 分别表示真实框和预测框中心点在x轴和y轴方向的距离; δ 表示真实框和预测框中心点之间的欧氏距离; z 表示角度相关的正弦比值; Λ 表示角度损失值。

真实框和预测框之间的距离损失定义如式(6)所示^[22]。

$$\Delta = (\rho_x + \rho_y)^\gamma \quad (6)$$

式中: $\rho_x = \left(\frac{b_{c_x}^{gt} - b_{c_x}}{A_w} \right)^2$; $\rho_y = \left(\frac{b_{c_y}^{gt} - b_{c_y}}{A_h} \right)^2$; $\gamma = 2 - \Delta$ 。其中,

A_w 和 A_h 分别表示真实框和预测框最小外接矩形的宽度和高度。

真实框和预测框之间的形状损失定义如式(7)所示^[22]。

$$\Omega = (1 - e^{-\bar{\omega}_w})^\theta + (1 - e^{-\bar{\omega}_h})^\theta \quad (7)$$

式中: $\bar{\omega}_w = \frac{|w - w^{gt}|}{\max(w, w^{gt})}$, $\bar{\omega}_h = \frac{|h - h^{gt}|}{\max(h, h^{gt})}$ 。其中, w^{gt} 和 h^{gt} 分别表示真实框的宽度和高度; w 和 h 分别表示预测框的宽度和高度; θ 表示控制形状损失敏感度的权重参数。

最后,基于式(6)和(7)得到如式(8)所示的 SIoU 损失函数。

$$L_{\text{SIoU}} = 1 - \text{IoU} + \frac{\Delta + \Omega}{2} \quad (8)$$

式中: L_{SIoU} 表示 SIoU 损失函数; IoU 表示预测框与真实框的交并比。

在边界框回归过程中,通过区分不同类型的回归样本,并利用不同尺度的辅助边框计算损失,能有效加快回归速度^[23]。对于高 IoU 样本,采用较小的辅助边框计算损失能加速收敛(图 6(a));对于低 IoU 样本,则更适合使用较大的辅助边框加速预测框收敛(图 6(b))。因此,采用尺寸合适的辅助边框计算 IoU 损失,可提升模型的快速收敛性能。 (x_c^{pre}, y_c^{pre}) 和 (x_c^{gt}, y_c^{gt}) 分别表示预测框和真实框的中心点, (w^{pre}, h^{pre}) 和 $(w^{pre}_{inner}, h^{pre}_{inner})$ 分别

表示预测框和辅助预测框的宽度与高度, (w^{gt}, h^{gt}) 和 $(w^{gt}_{inner}, h^{gt}_{inner})$ 分别表示真实框和辅助真实框的宽度与高度。根据具体数据集和检测器,通过比例因子 α (通常设为 0.5 ~ 1.5) 调节辅助边框的尺度,进而计算损失。

设 a, b, c, d 分别表示左、右、上、下的边界,将辅助真实框和辅助预测框的边界坐标分别定义如下^[23]:

$$b_{inner-a}^{gt} = x_c^{gt} - \frac{w^{gt}\alpha}{2}, \quad b_{inner-b}^{gt} = x_c^{gt} + \frac{w^{gt}\alpha}{2} \quad (9)$$

$$b_{inner-d}^{gt} = y_c^{gt} - \frac{h^{gt}\alpha}{2}, \quad b_{inner-c}^{gt} = y_c^{gt} + \frac{h^{gt}\alpha}{2} \quad (10)$$

$$b_{inner-a}^{pre} = x_c^{pre} - \frac{w^{pre}\alpha}{2}, \quad b_{inner-b}^{pre} = x_c^{pre} + \frac{w^{pre}\alpha}{2} \quad (11)$$

$$b_{inner-d}^{pre} = y_c^{pre} - \frac{h^{pre}\alpha}{2}, \quad b_{inner-c}^{pre} = y_c^{pre} + \frac{h^{pre}\alpha}{2} \quad (12)$$

另外,将辅助框的交集面积 Inter_{inner} 和并集面积 Union_{inner} 分别计算如下^[23]:

$$\begin{aligned} \text{Inter}_{inner} &= (\min(b_{inner-b}^{gt}, b_{inner-b}^{pre}) - \max(b_{inner-a}^{gt}, b_{inner-a}^{pre})) \times (\min(b_{inner-c}^{gt}, b_{inner-c}^{pre}) - \max(b_{inner-d}^{gt}, b_{inner-d}^{pre})) \end{aligned} \quad (13)$$

$$\text{Union}_{inner} = w^{gt}h^{gt}\alpha^2 + w^{pre}h^{pre}\alpha^2 - \text{Inter}_{inner} \quad (14)$$

由此得到基于辅助边框的内部交并比 (inner intersection over union, Inner-IoU) 损失函数:

$$L_{\text{Inner-IoU}} = \frac{\text{Inter}_{inner}}{\text{Union}_{inner}} \quad (15)$$

将式(8)与(15)结合,得到如式(16)所示的 Inner-SIoU 损失函数,该损失函数能有效加快检测模型的收敛速度,提升检测性能。

$$L_{\text{Inner-SIoU}} = 1 - L_{\text{Inner-IoU}} + \frac{\Delta + \Omega}{2} \quad (16)$$




图6 Inner-IoU 示意图

Fig. 6 Inner-IoU schematic diagram

3 实验结果及对比分析

本文改进轻量化目标检测算法 SGI-YOLOv7 的评测环境如下: 操作系统 Ubuntu 18.04.5 LTS, 编程语言 Python 3.8.13, 运行平台 Linux (Ubuntu 18.04), CPU 型号 Intel(R) Xeon(R) Gold 6248R, CPU 主频 3.00 GHz, 内存 128 GB DDR4, 显卡型号 NVIDIA GeForce RTX 3090, 显存 24 GB。

目标检测算法常用的评价指标包括参数量(parameters, Paras)、计算量(giga-floating point operations, GFLOPs)、平均精度(average precision, AP)、全类平均精度(mean average precision, mAP)以及检测速度(frames per second, FPS), 其计算公式如式(17)~(21)所示。

$$\text{Paras} = C_{out}(K_w \times K_h \times C_{in} + b)$$
 (17)

$$\text{GFLOPs} = C_{out}(2 \times C_{in} \times K_w \times K_h - b) \times W \times H$$
 (18)

式中: $K_w \times K_h$ 表示卷积核的大小; C_{in} 和 C_{out} 分别表示输入和输出通道数; b 为偏置; W 和 H 分别表示输出特征图的宽度和高度。

$$\text{AP} = \sum_{k=1}^N p(k) \Delta r(k)$$
 (19)

$$\text{mAP} = \frac{\sum_{i=1}^n \text{AP}_i}{n}$$
 (20)

式中: N 表示训练集中图像数量; $p(k)$ 表示第 k 张图像被识别时的精度值; $\Delta r(k)$ 表示识别图像数量从 1 变为 N 时召回率的变化; n 表示检测类别的数量。

$$\text{FPS} = \frac{N}{t_N}$$
 (21)

式中: t_N 表示模型检测所有图像所花费的时间。

3.1 轻量化目标检测算法 SGI-YOLOv7 对比实验

检测模型训练参数配置如下: 初始学习率 0.01, 学习率衰减系数 0.01, 批量大小 16, 并行计算线程数 8, 训练总轮数 300, 优化器随机梯度下降。其中, 初始学习率用于控制参数的步长更新, 降低模型陷入局部最优的风险; 批量大小和并行计算线程数分别对应单次迭代处理的图像样本数量和并行任务数量。

首先, 基于自制的板坯数据集, 在 YOLOv7 模型上比较了本文改进的损失函数 Inner-SIoU 与 CIoU、加权交并比(weighted intersection over union, WIoU)、最小点距离交并比(minimum point distance intersection over union, MPDIoU)、SIoU 等损失函数的效果(如表 2 所示)。其中, 基准损失函数 CIoU 的 mAP@0.5 为 96.6%; WIoU、MPDIoU、SIoU 的检测精度均有所提升, 分别达到

96.9%、97.1%、97.2%, 较 CIoU 分别提升了 0.3%、0.5% 和 0.6%。而本文改进的 Inner-SIoU 效果更为显著, 其 mAP@0.5 达到 97.4%, 较 CIoU 提升了 0.8%, 表明损失函数改进对模型检测精度提升效果显著。

表 2 不同损失函数的检测精度对比
Table 2 Comparison of detection accuracy of different loss functions

损失函数	AP@0.5/%			mAP@0.5/%
	板坯	天车	夹取板坯的天车	
CIoU	98.3	95.1	96.5	96.6
WIoU	98.8	94.9	97.1	96.9
MPDIoU	98.8	95.2	97.2	97.1
SIoU	98.9	95.3	97.3	97.2
Inner-SIoU	98.7	95.7	97.7	97.4

其次, 将本文所提轻量化目标检测算法 SGI-YOLOv7 与基准 YOLOv7 模型进行了对比实验(表 3)。实验结果表明, SGI-YOLOv7 算法的参数量减少 35.7%, 计算量降低 65.5%, 模型大小减小 34.4%。这些显著的轻量化优化结果能有效提升 YOLOv7 模型的检测效率。

表 3 SGI-YOLOv7 与 YOLOv7 的性能对比
Table 3 Performance comparison between SGI-YOLOv7 and YOLOv7

方法	参数量/($\times 10^6$)	计算量/GFLOPs	模型大小/MB
YOLOv7	36.5	103.2	74.8
SGI-YOLOv7	23.6	35.6	49.1

再次, 为对比本文所提轻量化目标检测算法 SGI-YOLOv7 与其他经典轻量级增强算法及轻量级网络的检测性能, 在自制的板坯数据集上进行了对比实验, 实验结果如表 4 所示。可以看出, 在参数量方面: SGI-YOLOv7 算法的参数量最少(为 23.6 M), 与作为 YOLOv7 主干的 MobileNetv4、StarNet、FasterNet、HGNetv2 相比, 分别减少了 2.0、1.0、0.7 和 1.2 M; 在计算量方面: SGI-YOLOv7 算法的计算量最少(为 35.6 GFLOPs), 比 SSD 算法减少约 74%; 在检测速度方面: SGI-YOLOv7 算法达到 82.0 fps, 满足工业现场连铸板坯实时检测需求(≥ 15 fps); 在检测精度方面: SGI-YOLOv7 算法在实现轻量化的同时, 保持了较高的检测精度(mAP@0.5 为 96%)。综合上述可知, 本文所提轻量化目标检测算法 SGI-YOLOv7 在显著降低模型复杂度和资源消耗的同时, 保持了具有竞争力的检测精度。

最后, 为直观展现本文所提轻量化目标检测算法 SGI-YOLOv7 与基准 YOLOv7 算法在检测性能上的差异, 取部分板坯图片进行检测对比, 实验结果如图 7 所示。

表 4 SGI-YOLOv7 与其他算法的检测性能对比
Table 4 Comparison of detection performance between SGI-YOLOv7 and other algorithms

检测算法	mAP@ 50/ %	参数量/ ($\times 10^6$)	计算量/ GFLOPs	检测速度/ fps
MobileNetv4-YOLOv7	96.0	25.6	52.2	88.5
StarNet-YOLOv7	96.8	24.6	41.8	81.3
FasterNet-YOLOv7	96.5	24.3	40.6	50.0
HGNetv2-YOLOv7	96.9	24.8	41.5	43.8
SSD	78.2	23.9	137.0	64.5
YOLOv7	96.6	36.5	103.2	94.3
SGI-YOLOv7	96.0	23.6	35.6	82.0

可以看出,第 1 幅图中“夹取板坯的天车 (craneandslab)”目标,两种算法检测置信度均为 97%;第 2 幅图左侧边缘

处的“板坯 (slab)”目标,YOLOv7 算法未检测出来,而 SGI-YOLOv7 算法对图中所有的目标(板坯、天车、夹取板坯的天车)均进行了有效检测;第 3 幅图中存在 2 个“板坯 (slab)”目标,YOLOv7 算法的检测置信度分别为 83% 和 97%,SGI-YOLOv7 算法的检测置信度分别为 85% 和 96%;第 4 幅图中存在 1 个“板坯 (slab)”目标和 2 个“夹取板坯的天车 (craneandslab)”目标,YOLOv7 算法的检测置信度分别为 96%、97% 和 98%,SGI-YOLOv7 算法的检测置信度分别为 96%、96% 和 94%。综上所述,SGI-YOLOv7 算法的检测置信度与基准 YOLOv7 模型相差不大,能有效检测出连铸现场中的各类目标,表明本文所提 SGI-YOLOv7 算法在显著降低参数量与计算量的同时,仍然保持了较高的检测精度。



(a) 基准 YOLOv7 算法检测效果
(a) The detection effects of the benchmark YOLOv7 algorithm



(b) 所提轻量化 SGI-YOLOv7 算法检测效果
(b) The detection effects of the proposed lightweight SGI-YOLOv7 algorithm

图 7 连铸板坯检测结果对比

Fig. 7 Comparison of inspection results of continuous casting slabs

3.2 消融实验

为验证本文所提轻量化目标检测算法 SGI-YOLOv7 中各改进组件的有效性,本节使用相同的数据集和训练参数设置,通过逐步替换特定改进模块进行了消融实验,实验结果如表 5 所示。可以看出,Strategy 1(替换损失函数):使用 Inner-SIoU 替代原始的 CIoU 损失函数。与基准 YOLOv7 模型相比,在计算量和参数量保持不变的情况下,mAP@0.5 提升了 0.8 个百分点,为后续模型压缩提供了优化空间。Strategy 2(替换主干网络):在 Strategy 1 基础上,使用 StarNet 替换 YOLOv7 的主干网络。该策

略显著降低了模型复杂度,计算量和参数量分别显著降低 59.5%和 32.3%,而 mAP@0.5 性能指标保持不变。Strategy 3(引入轻量颈部):在 Strategy 2 基础上,将 Slim-neck 引入特征融合网络。该策略进一步减少了网络的计算量和参数量,分别为 65.6%和 35.6%(相较于基准 YOLOv7 模型),而 mAP@0.5 性能指标仅小幅下降 0.8%。综上可见,本文所提轻量化目标检测算法 SGI-YOLOv7 中各改进组件在模型轻量化方面效果显著,能够为资源受限场景下的算法部署提供高效、高精度的解决方案。

表 5 消融实验结果
Table 5 Ablation experiment results

Model	Inner-SIoU	StarNet	Slim-Neck	mAP@0.5/%	参数量/($\times 10^6$)	计算量/GFLOPs	检测速度/fps
YOLOv7	—	—	—	96.6	36.5	103.2	94.3
Strategy 1	✓	—	—	97.4	36.5	103.2	94.3
Strategy 2	✓	✓	—	96.6	24.7	41.8	84.7
Strategy 3	✓	✓	✓	96.0	23.5	35.5	82.0

4 结 论

针对当前通用检测算法在工业现场部署中存在的参数量大、计算复杂度高等问题,本文提出一种轻量化连铸板坯检测算法 SGI-YOLOv7。通过采用 StarNet 替换主干网络、引入基于 GSConv 的 Slim-neck 结构实现高效特征融合,并结合基于辅助边框的 Inner-SIoU 损失函数优化边界框回归,在自制的板坯数据集上实现了显著的轻量化效果:参数量减少 35.6% (23.6×10^6)、计算量降低 65.6% (35.6 GFLOPs),同时保持检测精度 mAP@0.5 为 96.0%,推理速度达 82 fps。所提算法满足了连铸现场对实时性与精度的要求,有效降低了硬件部署负担。在下一步工作中,将结合知识蒸馏技术进一步压缩模型规模,并探索自适应辅助边框缩放机制,以提升算法在复杂工况下的鲁棒性。

参考文献

[1] 刘乐, 张晓松, 黄锋, 等. 基于改进 DBNet 和 SVTR 算法的连铸板坯号检测与识别[J]. 电子测量与仪器学报, 2024, 38(2): 67-75.
LIU L, ZHANG X S, HUANG F, et al. Detection and recognition of continuous casting slab numbers based on improved DBNet and SVTR algorithms [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(2): 67-75.
[2] YANG H L, FANG Y M, LIU L, et al. Improved YOLOv5

based on feature fusion and attention mechanism and its application in continuous casting slab detection [J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 1-16.
[3] 李大华, 徐傲, 王笋, 等. 基于改进 YOLOv5 的印刷电路板缺陷检测[J]. 电子测量技术, 2023, 46(23): 112-119.
LI D H, XU A, WANG S, et al. Defect detection of printed circuit boards based on improved YOLOv5 [J]. Electronic Measurement Technology, 2023, 46(23): 112-119.
[4] 吴兴辉, 何赞泽, 周辉, 等. 改进 YOLOv7 算法下的监控水域环境人员识别研究[J]. 电子测量与仪器学报, 2023, 37(5): 20-27.
WU X H, HE Y Z, ZHOU H, et al. Research on personnel recognition in monitored water environments based on improved YOLOv7 algorithm [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(5): 20-27.
[5] 朱宏禹, 韩建宁, 徐勇. 基于改进型 YOLOv5s 的印刷线路板瑕疵检测[J]. 国外电子测量技术, 2023, 42(3): 152-159.
ZHU H Y, HAN J N, XU Y. Defect detection of printed circuit boards based on improved YOLOv5s [J]. Foreign Electronic Measurement Technology, 2023, 42(3): 152-159.

- [6] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2014: 580-587.
- [7] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.
- [8] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection [C]. 29th IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779-788.
- [9] REDMON J, FARHADI A. YOLO9000: Better, faster, stronger [C]. 30th IEEE Conference on Computer Vision and Pattern Recognition, 2017: 6517-6525.
- [10] REDMON J, FARHADI A. YOLOv3: An incremental improvement [J]. ArXiv preprint arXiv: 1804.02767, 2018.
- [11] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: Optimal speed and accuracy of object detection [EB/OL]. (2024-05-24).
- [12] LIU W, ANGELOV D, ERHAN D, et al. SSD: Single shot multibox detector [C]. Proceedings of the 2016 European Conference on Computer Vision, 2016: 21-37.
- [13] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(2): 318-327.
- [14] LAW H, DENG J. CornerNet: Detecting objects as paired keypoints [J]. International Journal of Computer Vision, 2020, 128(3): 642-656.
- [15] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 7464-7475.
- [16] LANDOLA F N, HAN S, MOSKEWICZ M W, et al. SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size [J]. ArXiv: 1602.07360, 2017.
- [17] CHOLLET F. Xception: Deep learning with depthwise separable convolutions [C]. 30th IEEE Conference on Computer Vision and Pattern Recognition, 2017: 1800-1807.
- [18] HOUWARD A G, ZHU M L, CHEN B, et al. MobileNets: Efficient convolutional neural networks for mobile vision applications [J]. ArXiv: 1704.04861, 2017.
- [19] HOWARD A, SANDLER M, CHU G, et al. Searching for MobileNetV3 [C]. Proceedings of the IEEE International Conference on Computer Vision, 2019: 1314-1324.
- [20] MA X, DAI X Y, BAI Y, et al. Rewrite the stars [C]. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2024: 5694-5703.
- [21] LI H L, LI J, WEI H B, et al. Slim-neck by GSConv: A lightweight-design for real-time detector architectures [J]. Journal of Real-Time Image Processing, 2024, 21(3): 62.
- [22] GEVORGYAN Z. SIoU loss: More powerful learning for bounding box regression [J]. ArXiv: 2205.12740, 2022.
- [23] ZHANG H, XU C, ZHANG S J. Inner-IoU: More effective intersection over union loss with auxiliary bounding box [J]. ArXiv:2311.02877, 2023.

作者简介



E-mail: leliu@ysu.edu.cn

刘乐(通信作者), 2015年于燕山大学获得博士学位, 现为燕山大学自动化系副教授, 主要研究方向为复杂非线性系统智能优化控制、基于深度学习的图像识别算法及在流程工业中应用研究。

Liu Le (Corresponding author) received his Ph. D. degree from Yanshan University in 2015. Now he is an associate professor at the Department of Automation, Yanshan University. His research interests include intelligent optimization control of complex nonlinear systems, image recognition algorithm based on deep learning and its application in process industry.



顾玲珑, 2022年于燕山大学获得学士学位, 现为燕山大学硕士研究生, 主要研究方向为复杂工业背景下目标检测与跟踪、场景文本检测与识别。

E-mail: llgu1@stumail.ysu.edu.cn

Gu Linglong received her B. Sc. degree from Yanshan University in 2022. Now she is a M. Sc. candidate at Yanshan

University. Her main research interests include object detection and tracking in complex industrial backgrounds, and scene text detection and recognition.



李子洋,2024 年于西安科技大学获得学士学位,现为燕山大学硕士研究生,主要研究方向为工业场景下目标检测与识别。

E-mail:lzy0708092025@163.com

Li Ziyang received his B. Sc. degree from Xi'an University of Science and Technology in 2024. Now he is a M. Sc. candidate at Yanshan University. His main research interests include object detection and recognition in industrial scenarios.



方一鸣,2003 年于燕山大学获得博士学位,现为燕山大学自动化系教授,主要研究方向为连铸轧钢自动化智能化技术及应用,图像识别、智能优化算法及在流程工业中应用。

E-mail:fymingysu@163.com

Fang Yiming received his Ph. D. degree from Yanshan University in 2003. Now he is a professor at the Department of Automation, Yanshan University. His research interests include intelligent technology and application of continuous casting and rolling steel automation, image recognition, intelligent optimization algorithm and application in process industry.