

基于YOLOv8可变形卷积的工人安全帽检测系统

孙叶美, 李淼, 段聪聪, 陈帅宇*

(天津城建大学计算机与信息工程学院, 天津 300384)

摘要: 建筑工地的复杂环境给工人安全帽佩戴检测带来了极大的挑战。为精准辨识复杂施工环境中作业人员安全帽佩戴情况, 有效降低安全事故发生率, 提出了一种基于可变形卷积的工人安全帽佩戴检测算法。该算法在YOLOv8骨干网络部分融合可变形卷积模块, 缓解了传统标准卷积层使用固定几何结构提取特征时限制模型建模能力的问题, 提升了对复杂施工环境的分析识别能力; 通过图像几何变换和像素级处理方法, 丰富训练样本数量以提升检测模型在不同工地场景中的泛化能力。将该算法部署到Jetson TX2, 编写目标检测软件, 实现了实际建筑工地场景的现场检测。实验表明: 该模型能在复杂施工环境下完成工人的安全帽佩戴检测, 在标准数据集上识别准确率为95.2%, 且具有一定鲁棒性, 可向各类施工现场进行推广。

关键词: YOLOv8; 工地现场; 不安全行为检测; 可变形卷积; 目标识别

中图分类号: TN391.4

文献标志码: A

doi: 10.11959/j.issn.2096-3750.XXXX.

Deformable convolution system for the detection of workers' safety helmets using YOLOv8

Sun Yemei, Li Miao, Duan Congcong, Chen Shuaiyu*

School of Computer and Information Engineering, Tianjin Chengjian University, Tianjin 300384, China

Abstract: The complex environment of construction sites presents a huge challenge for detecting unsafe behaviors among workers. In order to accurately identify the wear of helmets for workers in complex construction environments, and effectively reduce the incidence of safety accidents, a detection algorithm based on deformable convolution for the identification of safety helmets worn by workers is proposed. The algorithm fuses deformable convolutional modules in the YOLOv8 backbone network part, alleviating the limitations of traditional standard convolution layers, which rely on fixed geometric structures for feature extraction. This enhancement improves the model's ability to analyze and identify complex construction environments. By employing image geometric transformations and pixel-level processing, the algorithm enriches the number of training samples, thereby enhancing the generalization capability of the detection model across various site scenarios. The algorithm is deployed on the Jetson TX2, and the target detection software is developed to facilitate on-site detection of the actual construction site environment. The results indicate that the model can effectively detect unsafe behaviors among workers in complex construction environments, achieving a recognition accuracy of 95.2% on a standard dataset. Furthermore, the model demonstrates robustness and can be applied across various construction sites.

Key words: YOLOv8, construction site, unsafe behavior detection, deformable convolution, object recognition

收稿日期: 2025-XX-XX; 修回日期: 2025-XX-XX

通信作者: 陈帅宇, chenshuaiyu0906@163.com

基金项目: 天津市哲学社会科学规划项目“人工智能技术驱动天津市服务业升级路径研究”(TJGL19XSX-045)、国家级大学生创新创业训练计划项目(202410792012)

Foundation Items: Tianjin Philosophy and Social Science Planning Project “Research on the Upgrading Path of Tianjin Service Industry Driven by Artificial Intelligence Technology” (TJGL19XSX-045), National Innovation and Entrepreneurship Training Program for Undergraduates (202410792012)

0 引言

随着我国经济快速发展, 建筑业进入高速增长阶段, 作为国民经济的核心支柱, 其施工安全显得尤为关键。随着作业装置大型化、复杂化发展, 以及从业人员自我保护意识欠缺、管理制度实施不到位, 导致建筑事故频频发生, 给工人安全和企业财产带来了巨大威胁。而在施工现场发生的安全事故中, 造成施工人员伤亡的主要原因之一就是未按要求佩戴安全帽。目前, 我国在施工现场的安全监测主要依赖于现场安全人员的监督, 而由于施工现场占地广阔、工作场景多变以及工人流动性强等原因, 人工监管经常容易出现疏忽, 从而造成安全隐患, 无法满足施工安全的要求, 存在很大的局限性。因此, 自动监督的方法成为多数施工场地的选择。

近年来, 随着深度学习技术的快速进步, 目标检测算法也得到了显著的改进和完善, 许多学者将此技术应用于施工安全检测中, 从而有效增强施工现场的安全管理, 保障工人的生命安全, 减少潜在的安全事故。

1 相关工作

国内外学者围绕安全帽佩戴检测问题开展了大量研究, 主要分为传统机器学习和基于深度学习两大技术路线。传统的工人安全帽佩戴检测方法主要依赖传感器^[1]判断工人与设备位置, 再通过控制模块进行检测。然而, 此类方法成本高且定位精度有限。后来图像处理技术^[2-11]被广泛应用于安全帽检测, 这些方法通常采用背景减除法或选取检测窗口分离出动态目标, 然后采用方向梯度直方图 (Histogram of Oriented Gradient, HOG)、颜色直方图等对所分离目标或所选取窗口内的颜色、形状等特征进行描述, 进而使用训练好的分类器(如支持向量机、K最近邻法、正态贝叶斯、神经网络等)实现目标实体的识别与分类。然而, 传统的识别方法受限于一些特定施工场景, 且较为依赖特征的选择和提取, 导致识别准确率较低, 且定位精度、自动化和智能化程度不高, 在复杂施工环境下识别效果并不出色。

随着技术的不断进步, 基于深度学习的方法具有端到端的训练模式和强大的特征提取能力, 在识

别目标种类的丰富度和准确度上展现了巨大优势^[12-21]。目前, 目标检测算法主要分为二阶段和一阶段两类^[17]。二阶段目标检测方法先生成候选区域再分类识别, 常见的有 Fast R-CNN(Fast Region-based Convolutional Network, Fast R-CNN)系列等, 例如孙勇^[18]等利用 Faster R-CNN 算法构建了一个建筑工人不安全行为检测系统, 能够识别未佩戴安全帽等行为。一阶段目标检测是通过一个网络直接提取特征和分类, 相比二阶段检测检测速度更快, 常见模型有 YOLO (You Only Look Once, YOLO) 系列^[22-30]等。例如王贞^[15]等在 YOLOv8 颈部添加通道注意力机制, 增强算法对特征的提取能力, 实现施工环境中安全帽佩戴检测。王晨^[9]等使用 YOLOv4 对安全帽佩戴情况进行了识别。然而, 现实图像中需要识别的目标通常是不规则和复杂的, 而这些方法在空间维度上提取特征时, 受限于传统标准卷积操作中使用固定尺寸的卷积核提取特征, 导致提取的特征依赖于固定感受野中包含的局部信息, 阻碍了模型在复杂场景下识别的建模能力, 降低了识别准确率。

本文针对上述问题, 提出了一种基于可变形卷积的工人安全帽佩戴检测系统, 主要贡献包括: 第一, 在 YOLOv8 算法网络结构的骨干网络部分设计融合可变形卷积模块, 使模型的感受野自适应目标大小尺寸, 缓解传统标准卷积层使用固定几何结构提取特征时限制模型建模能力的问题, 提高模型的特征表达和复杂环境下建模能力。第二, 通过图像几何变换和像素级处理方法丰富训练样本数量, 解决训练样本少和实际采集图像质量差的问题, 提升检测模型在各类工地场景中的泛化能力。第三, 将该算法部署到 Jetson TX2, 开发目标检测软件, 实现建筑工地实际复杂环境下的实时监测, 进而建立建筑工地人员不安全行为预警机制, 旨在更有效地预防施工事故、提升施工安全管理水平。

2 方法

本文设计的模型包括三个主要部分: 骨干网络、颈部网络和预测输出端, 其结构如图 1 所示。对于输入的待检测图像, 首先经过骨干网络自适应获取目标尺寸的感受野和浅层次纹理特征, 随后颈部网络再对获得的高级特征进行语义编码, 最后预测输出端对编码特征进行边界框回归和筛选, 输出

检测结果。

2.1 可变形卷积模块

对于标准卷积操作，卷积核具有固定像素点的位置，对输入图像的每个位置应用相同的卷积核。而实际上，不同位置的图像可能具有不同的改变，标准卷积无法适应实际环境图像的不规则布局与非刚性形变，因此可能导致提取的目标特征不准确。

对于原YOLOv8结构的骨干网络，假设输入待检测图像为 X_{in} ，则骨干网络不同阶段的输出 Y_1, Y_2, Y_3 ，分别如式(1-3)所示：

$$Y_1 = C2f\left(CBS\left(C2f\left(CBS\left(CBS\left(X_{in}\right)\right)\right)\right)\right) \quad (1)$$

$$Y_2 = C2f\left(CBS\left(Y_1\right)\right) \quad (2)$$

$$Y_3 = SPPF\left(C2f\left(CBS\left(Y_2\right)\right)\right) \quad (3)$$

式中，CBS()表示卷积、归一化和激活函数等操作，C2f()表示对特征进行一系列CBS模块、残差连接等操作，SPPF()表示空间金字塔池化操作。假设 R 为感受野， $R=\{(-1,-1),(-1,0),\dots,(0,1),(1,1)\}$ ，则对于特征图 x 中任意位置 p_0 ，传统标准卷积操作的输出 $Y_{standConv}(p_0)$ 如式(4)所示：

$$Y_{standConv}(p_0) = \sum_{p_n \in R} w(p_n) * x(p_0 + p_n) \quad (4)$$

其中， p_n 代表感受野 R 中任意位置坐标， $x(p_0+p_n)$ 为输入特征图中的任意位置元素， $w(p_n)$ 代表卷积操作的

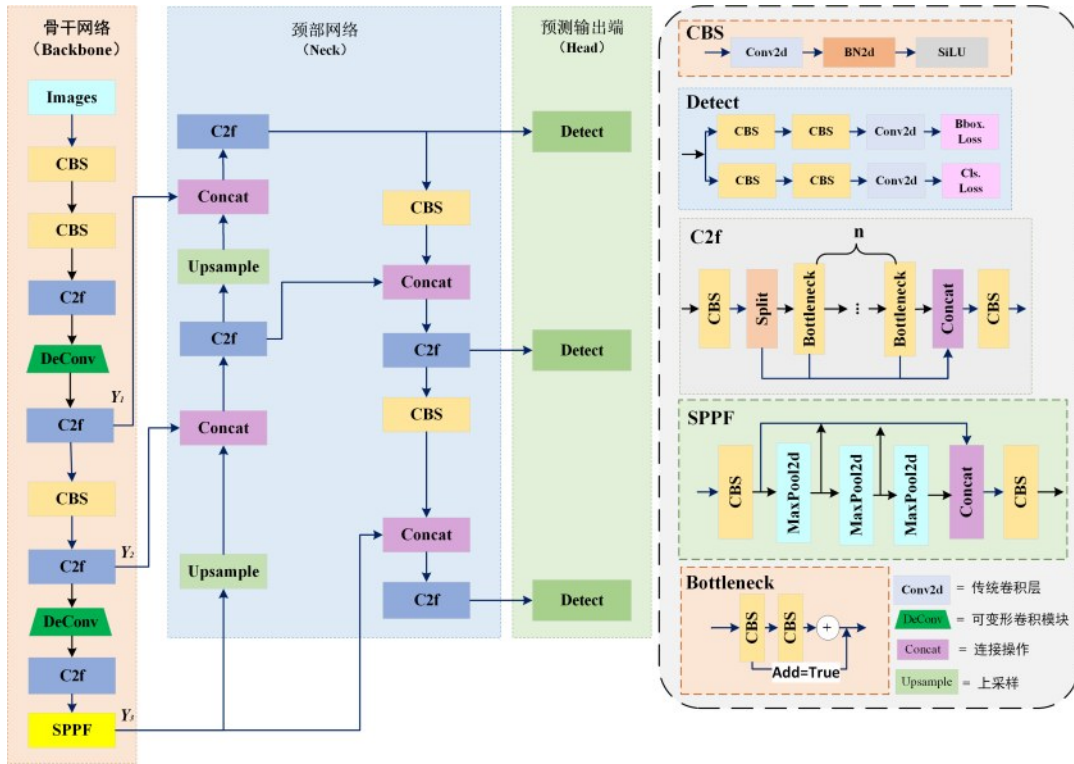


图1 基于可变形卷积的安全帽佩戴检测框架图

权重。使用标准卷积操作进行浅层特征的提取时，固定几何结构导致模型感受野受到局限，阻碍了模型建立像素特征之间的依赖关系。

而可变形卷积是对传统标准卷积的优化，可变形卷积模块示意图如图2所示，其主要包括两个步骤：(1)使用卷积层学习偏移量；(2)通过双线性插值方法确定采样点的数值。在执行可变形卷积操作时，对于给定的输入特征图 $x(b \times h \times w_c \times c)$ ，其中 b, h, w_c 和 c 分别为批大小、特征图高度、宽度和通道

数量。首先通过卷积层获得临时特征值 $x(b \times h \times w_c \times 2c)$ ，其中 $2c$ 表示 x 和 y 两个方向的偏移量通道。则对于特征图中任意位置 p_0 ，可变形卷积的输出 $Y_{deformConv}(p_0)$ 如式(5)所示：

$$Y_{deformConv}(p_0) = \sum_{p_n \in R} w(p_n) * x(p_0 + p_n + \Delta p_n) \quad (5)$$

其中， Δp_n 代表偏移量。然而 Δp_n 通常可能是小数，对于离散图像数据，不能采用非整数为坐标。所以，对于公式(5)先通过采用双线性插值计算采样

点的值，然后再进行模型的反向传播和端到端训练。

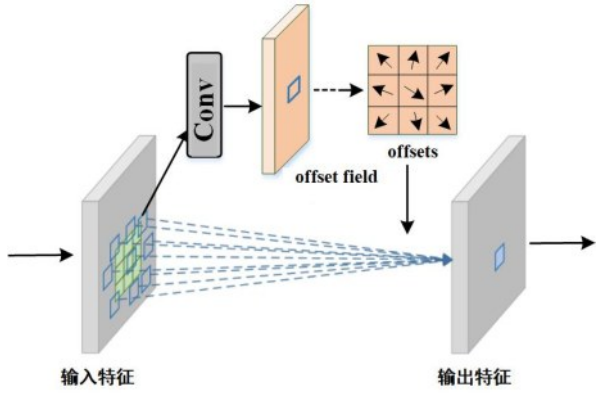


图2 可变形卷积模块示意图

则对于改进后的骨干网络不同阶段的输出 Y_{after_1} , Y_{after_2} , Y_{after_3} , 如式(6-8)所示:

$$Y_{after_1} = C2f\left(\text{DeConv}\left(C2f\left(\text{CBS}\left(\text{CBS}\left(X_m\right)\right)\right)\right)\right) \quad (6)$$

$$Y_{after_2} = C2f\left(\text{CBS}\left(Y_{after_1}\right)\right) \quad (7)$$

$$Y_{after_3} = \text{SPPF}\left(C2f\left(\text{DeConv}\left(Y_{after_2}\right)\right)\right) \quad (8)$$

式中, DeConv()为可变形卷积操作。通过可变形卷积操作,对输入特征映射的样本点进行偏移量调整,可以在卷积过程中改变模型感受野,增强模型对不规则目标识别的灵活性,提高模型复杂场景下目标识别的准确度。图3展示了两种卷积操作感受野的对比。由于提取特征中固定卷积核尺寸的限制,传统标准卷积的感受野和采样位置较为固定,见图3(a),而可变形卷积能够根据目标尺寸和形状自适应地调整其感受野和采样位置,见图3(b)。整个模型中,当多个可变形卷积模块叠加时,这种复合变形的效果将得到进一步增强。




图3 传统标准卷积感受野和可变形卷积感受野对比

(a)传统标准卷积感受野 (b)可变形卷积感受野

2.2 数据集构建

为丰富训练样本的多样性,本文结合筛选后的公共SHWD安全帽佩戴检测数据集和实际建筑工地项目施工现场采集的视频图片作为训练集进行实验,该数据集涵盖了两个类别的检测对象:安全帽和头部,共有7581张图像,按照检测模型需要将数据集进行随机划分,训练集、验证集和测试集的划分比例为7:1:2。为了准确标注实际施工现场采集的图像,本文采用Labelimage工具进行目标标记。图4展示了使用Labelimage进行目标标记的示例。此外,由于在实际应用中场景复杂,本文通过采用图像几何变换和像素级预处理策略扩充数据集,如图5所示,通过对图像进行灰度化、仿射变换、随机遮挡等处理,可增加不安全行为的训练样本数量和多样性,提高模型在复杂环境下目标识别

准确度。

3 实验

3.1 实验环境及评价指标

本文采用的硬件平台为Intel Xeon E5-2680 v4处理器(2.40GHz)和NVIDIA RTX 3090显卡(24GB)进行实验。软件平台为PyTorch深度学习框架和CUDA 11.3。训练时输入图像统一调整大小为640×640,训练批大小为16,交并比(Intersection over Union, IoU)阈值设置为0.7。使用精确率P(Precision, P)、召回率(Recall, R)和平均精度均值mAP(mean Average Precision, mAP)来评估模型的有效性。精确率、召回率和平均精度如式(9-12)所示:



图4 使用标注软件对是否佩戴安全帽进行画框标注




图5 训练集扩充

$$Precision = \frac{TP}{TP + FP} \quad (9)$$

$$Recall = \frac{TP}{TP + FN} \quad (10)$$

$$AP = \int_0^1 Precision(Recall)d(Recall) \quad (11)$$

$$mAP = \frac{\sum_{i=1}^c AP_i}{c} \quad (12)$$

其中 TP(True Positives)代表分类器正确预测正样本的实例数量, FP(False Positives)代表分类器预测为正样本但实际为负样本的错误预测数量, FN(False Negatives)代表错误识别为负样本的样本数量, c 代表数据集的类别数量。

3.2 算法消融实验分析

为了验证所提算法的有效性, 本文进行了一系

列消融实验并将实验结果汇总在表1中。Model_1为YOLOv8n网络; Model_2为在模型Backbone部分融合一个可变形卷积模块, Model_3为在模型Backbone部分融合两个可变形卷积模块(如图1所示); Model_4是在Neck融合可变形卷积模块并在扩增的数据集进行训练, Model_5是在Head融合可变形卷积模块并在扩增的数据集进行训练; Model_6为Model_3在扩增的数据集进行训练。所有消融实验均基于同一环境下进行训练测试。由表1可以看出, Model_3相较于原始模型Model_1在检测未戴安全帽(Head)和佩戴安全帽(Helmet)的精度值分别从85.3%和89.3%提高到91.9%和91.0%, 漏检率也从20.5%降低到13.0%, 说明引入可变形卷积可以明显的提高识别检测准确率并减少漏检率。特别是平均精度均值, 分别比Model_1和Model_2提

高了 4.7% 和 4.5%。而且，使用扩增的数据集进行训练获得的 Model_6，也能提高违章行为的识别精度，进一步说明该扩增训练样本的方式可以增加样本的多样性，提高模型在复杂环境下目标识别准确度。并且，对比结果显示，在 Backbone 部分融入可变形卷积的 Model_6，其 mAP 相较于在 Neck 部分融入的 Model_4 提升了 2.4%，相较于在 Head 部分融入的 Model_5 模型提升了 2.3%。这表明，在本实验的数据集和实验设置下，将可变形卷积模块融入 Backbone 部分能带来相对更优的性能提升。此外，Model_6 的 F1 Score 从 Model_1 的 84.5 提升到了 91.6，充分说明了模型在精确率和召回率之间取得了较好的平衡。

图 6 展示了改进后的 YOLOv8 模型在检测安全帽相关目标（“head”和“helmet”）时的 Preci-

表 1 不同改进模型在 SHWD 数据集上的检测结果

Model	AP/%		mAP			Miss Rate/%	F1 Score
	Head	Helmet	@	P/%	R/%		
			0.5/%				
Model_1	85.3	89.3	87.3	90.1	79.5	20.5	84.5
Model_2	85.7	89.4	87.5	89.7	79.8	20.2	84.5
Model_3	91.9	91.0	92.0	91.7	87.0	13.0	89.3
Model_4	92.0	93.6	92.8	92.6	87.3	12.7	89.9
Model_5	92.0	93.9	92.9	92.1	86.7	13.3	89.3
Model_6	95.2	95.2	95.2	93.3	89.9	10.1	91.6

sion - Recall 曲线。横坐标为召回率 (Recall)，纵坐标为精确率 (Precision)，右上角标注了不同类别及整体的平均精度值，其中“head”类别 AP 为 0.952，“helmet”类别 AP 为 0.952，所有类别综合的 mAP@0.5 为 0.952。通俗意义上讲，P-R 曲线与坐标轴围成的面积越大，证明模型的性能越好。

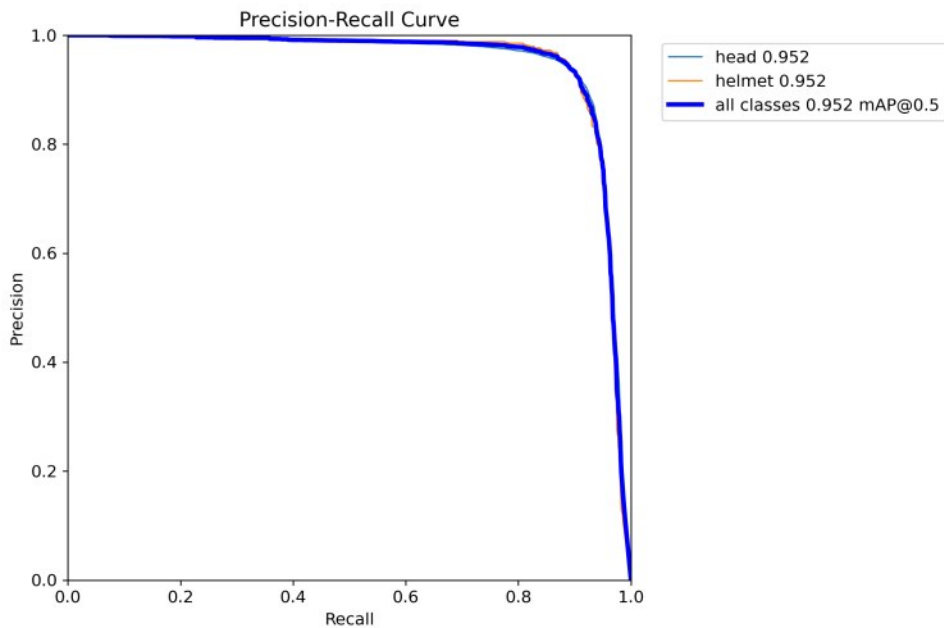


图 6 本文模型的精确率-召回率曲线图

3.3 文中方法与经典方法对比分析

为了进一步验证本文算法的优势，本文在 SHWD 数据集上与 Faster-RCNN^[16]、RFBNet^[14]、YOLOv5、YOLOv8n^[20]所提算法、TA-YOLOv8n^[2]、YOLOv11^[25]进行了实验对比，各算法的平均精度均值见表 2，检测结果图像见图 7。由表 2 可知，本文算法与 Faster-RCNN 相比，在 mAP 上提高了 16.8%，而且在参数量和计算量上也有了较大的降低，并且检测速度也大大地提高。与 RFBNet 相比，

无论是在参数量还是计算量上都低于 RFBNet 方法，同时 FPS 提高了 22 帧。而与其他 YOLO 系列方法比较也可以分析出，本文方法在 mAP 值上比 YOLOv5 方法高 9.5%、比 YOLOv8n 方法高 7.9%、比 TA-YOLOv8n 方法高 3%。虽然在参数量和计算量上本文方法与 YOLOv5 和 YOLOv11 相比有部分提高，但也能满足安全帽检测任务的实时性要求。

由图 7 可以看出，本文算法在安全帽佩戴检测准确率和置信度方面均优于 YOLOv8 和 YOLOv11。

表2 不同算法在SHWD数据集上的检测结果对比

Model	mAP@0.5/%	Param/M	GFLOPs	FPS(·s ⁻¹)
Faster-RCNN	78.4	39.78	205.25	56
RFBNet	80.6	38.46	164.56	64
YOLOv5	85.7	6.54	16.5	122
YOLOv8n	87.3	11.12	28.4	77
TA-YOLOv8n	92.2	12.18	31.7	—
YOLOv11	93.1	9.86	6.3	59
Ours	95.2	11.62	28.9	86

图7(a)原图显示有3名工人佩戴安全帽，YOLOv8



图7 在公共数据集上的检测结果图

4 系统实现

4.1 系统设计

本检测系统基于 Jetson TX2 平台搭建，包括主机、Jetson TX2 开发板、显示器和摄像头等硬件设备。系统的软件设计流程图如图8所示。首先，利用服务器对算法模型进行训练，并遴选最优目标检测算法。随后，使用 TorchScript 将训练所得模型转换为可部署格式。将转换后的模型部署至 Jetson TX2 开发板中。最后，利用 Qt Creator 开发上位机目标检测软件，用于结果展示。实际应用中，Jetson TX2 实时读取摄像头视频数据，利用部署的模型进行目标检测，并将结果回传至上位机显示，上位机软件实时显示监控视频和检测结果，确保系统正常工作。

本文开发的系统目标检测软件界面如图9所示。界面功能主要包括：模型配置、输入数据类型选择功能。为了适应不同场景下的速度和精度要求，软件的模型配置有本文 Best 模型、YOLOv8s、

方法检测到4个安全帽，存在错检；而本文算法和YOLOv11方法均检测到所有安全帽，但本文算法具有更高的置信度。由图7(b)中，原图有4位工人未戴安全帽和15位佩戴安全帽的工人，YOLOv8方法检测出来5位未戴安全帽和12位佩戴安全帽的工人，存在1个错检和3个漏检；YOLOv11方法检测出4位未佩戴安全帽和12位佩戴安全帽的工人，检测存在3个漏检；而本文算法检测出来了4位未佩戴安全帽和14位佩戴安全帽的工人，仅存在一个漏检。这些对比结果充分证明了本文算法在安全帽佩戴识别任务中的更高准确性。

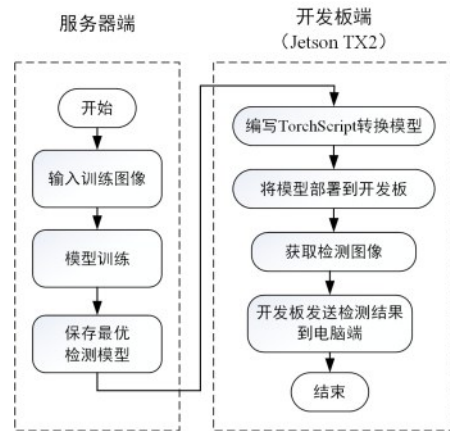


图8 基于嵌入式开发板的目标检测系统流程图

YOLOv8n、YOLOv8m 和 YOLOv8l 选项。软件输入数据类型包括图片、视频和实时摄像头接入，可以增加对模型不同场景下检测需求。模型配置好后，选择待检测的监测数据类型，点击“开始”按钮，检测进度条会显示检测的进度，界面会显示监控图像和目标检测标注后的结果，并在“检测结果”输出检测记录信息。此外，在界面的左下角添

加了报警功能，若检测到未佩戴安全帽的不安全行为，界面上的报警灯会亮起并发出警报声，有效减少了施工安全事故的发生。图 10 为建筑工地现场实际检测结果，特别是图 10(b)中，在目标较小的情况下，本文模型依然可以识别未戴安全帽的人员，充分说明本文设计引入的可变形卷积和数据扩充的有效性。图 11 展示模型在 Jetson TX2 上的嵌入式部署性能，该实验结果来自一段大小为 3.6MB，时长为 20s，尺寸为 1280*720 的视频。在模型配置中选择本文 Best 模型，在软件输入数据类型中选择视频文件。截取平均性能指标来说明嵌入式部署指标，在当前视频中平均 FPS 为 6.69，推理的平均延迟时间为 150.65ms，平均内存占用为 289.2MB，GPU 的平均功耗为 9.29W。

网络部分设计引入了可变形卷积模块，有效缓解了标准卷积层因使用固定几何结构提取特征而导致的模型建模能力受限问题。此外，本文通过图像进行几何变换和像素级处理方法扩充了训练样本数量，增强了检测模型在各种复杂工地场景中的泛化能力。最后，将该算法部署到 Jetson TX2，编写目标检测软件，实现了实际复杂建筑工地现场安全帽佩戴的检测。虽然本文改进的模型能够有效提升检测精度，且具有较高的实用性和可靠性，但该模型仍存在改进空间，下一步将继续优化模型结构，在提高检测精度的同时加快目标检测速度，并且加强模型在复杂环境中的适应性。



图9 系统目标检测软件界面

5 结论

本文提出了一种基于 YOLOv8 可变形卷积的工人安全帽佩戴检测算法。该算法在 YOLOv8 的骨干



图 10 建筑工地现场实际检测结果

[INFO] 平均性能指标：	
平均 FPS	: 6.69
平均延迟 (ms)	: 150.65
平均内存占用	: 289.2MB
平均 GPU 功耗(W)	: 9.29
平均 GPU 温度(C)	: 65.76

图11 嵌入式开发板检测结果

参考文献：

- [1] 王林,孙礼涛,翁鸿飞,等. 一种建筑施工现场不安全行为识别系统[P]. 四川省: CN202021009212.3, 2021-01-05.
Wang L, Sun LT, Weng HF, et al. A kind of unsafe behavior recognition system for building construction site [P]. Sichuan: CN202021009212.3, 2021-01-05.
- [2] Memarzadeh M, Golparvar-Fard M, Niebles J C. Automated 2D detection of construction equipment and workers from site video streams using histograms of oriented gradients and colors[J]. Automation in Construction, 2013, 32: 24-37.
- [3] Zhu Z, Ren X, Chen Z. Integrated detection and tracking of workforce and equipment from construction jobsite videos[J]. Automation in Construction, 2017, 81: 161-171.
- [4] Du S, Shehata M, Badawy W. Hard hat detection in video sequences based on face features, motion and color information[C]//2011 3rd international conference on computer research and development. IEEE, 2011, 4: 25-29.
- [5] Shrestha K, Shrestha P P, Bajracharya D, et al. Hard-hat detection for construction safety visualization[J]. Journal of Construction Engineering, 2015, 2015(1): 721380.
- [6] Rubaiyat A H M, Toma T T, Kalantari-Khandani M, et al. Automatic detection of helmet uses for construction safety[C]//2016 IEEE/WIC/ACM International Conference on Web Intelligence Workshops (WIW). IEEE, 2016: 135-142.
- [7] 刘云波,黄华. 施工现场安全帽佩戴情况监控技术研究[J]. 电子科技, 2015, 28(04): 69-72.
Liu Y B, Huang H. Research on monitoring technology of helmet wearing situation in construction site[J]. Electronic Science and Technology, 2015, 28(04): 69-72.
- [8] Mneymneh B E, Abbas M, Khoury H. Automated hardhat detection for construction safety applications[J]. Procedia engineering, 2017, 196: 895-902.
- [9] 卢颖,吕希凡,郭良杰,等. 基于 Kinect 的地铁乘客不安全行为识别方法与实验[J]. 中国安全生产科学技术, 2021, 17(12): 162-168.
Lu Y, Lu X F, Guo L J, et al. Kinect-based subway passenger unsafe behavior recognition method and experiment[J]. China Safety Production Science and Technology, 2021, 17(12): 162-168.
- [10] 杨赛烽. 基于 Kinect 的罐笼内矿工不安全行为识别方法研究[D]. 江苏: 中国矿业大学(江苏), 2019.
Yang S F. Research on the identification method of miners' unsafe behavior in cage based on Kinect [D]. Jiangsu: China University of Mining and Technology (Jiangsu), 2019.
- [11] 赵江平,王焱. 基于图像识别技术的不安全行为识别[J]. 安全与环境工程, 2020, 27(01): 158-165.
Zhao J P, Wang Y. Unsafe behavior recognition based on image recognition technology[J]. Safety and Environmental Engineering, 2020, 27(01): 158-165.
- [12] 常捷,张国维,陈文江,等. 基于 YOLO-V3 算法的加油站不安全行为检测[J]. 中国安全科学学报, 2023, 33(02): 31-37.
CHANG J, ZHANG G W, CHEN W J, et al. Detection of unsafe behavior at gas stations based on YOLO-V3 algorithm[J]. Chinese Journal of Safety Science, 2023, 33(02): 31-37.
- [13] 纪执安,周云奕,张玉媛,等. 基于改进 YOLOv5 的工业现场不安全行为检测[J]. 中国安全科学学报, 2024, 34(07): 38-43.
JI Z A, ZHOU Y Y, ZHANG Y Y, et al. Detection of unsafe behaviors at industrial sites based on improved YOLOv5[J]. Chinese Journal of Safety Science, 2024, 34(07): 38-43.
- [14] Liu S, Huang D. Receptive field block net for accurate and fast object detection[C]//Proceedings of the European conference on computer vision (ECCV). 2018: 385-400.
- [15] 王贞,邱杭,吴斌,等. 基于 CCG-YOLOv8 的施工场景下安全帽佩戴检测[J]. 武汉理工大学学报, 2024, 46(6): 73-80.
WANG Z, QIU H, WU B, et al. Detection of helmet wearing in construction scenarios based on CCG-YOLOv8[J]. Journal of Wuhan University of Technology, 2024, 46(6): 73-80.
- [16] Ren S, He K, 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, 2016, 39(6): 1137-1149.
- [17] 张艳,孙晶雪,孙叶美,等. 基于分割注意力与线性变换的轻量化目标检测[J]. 浙江大学学报(工学版), 2023, 57(06): 1195-1204.
Zhang Y, Sun X J, Sun Y M, et al. Lightweight target detection based on segmented attention and linear transformation[J]. Journal of Zhejiang University (Engineering Edition), 2023, 57(06): 1195-1204.
- [18] 孙勇. 建筑工人不安全行为智能检测系统研究与设计实现[D]. 深圳: 深圳大学, 2020.
Sun Y. Research and design implementation of intelligent detection system for construction workers' unsafe behavior [D]. Shenzhen: Shenzhen University, 2020.
- [19] 王晨. 面向作业安防的智能检测技术研究与实现[D]. 西安: 西安工业大学, 2022.
Wang C. Research and Implementation of Intelligent Detection Technology for Job Security [D]. Xi'an: Xi'an University of Technology, 2022.
- [20] Varghese R, Sambath M. YOLOv8: A Novel Object Detection Algorithm with Enhanced Performance and Robustness[C]//2024 International Conference on Advances in Data Engineering and Intelligent Computing Systems (ADICS). IEEE, 2024: 1-6.
- [21] 张田楷. 基于改进 YOLOv8 的安全帽佩戴检测方法的研究[D].

- 大连: 大连交通大学, 2024.
- Zhang T K, Research on helmet wearing detection method based on improved YOLOv8 [D]. Dalian: Dalian Jiaotong University, 2024.
- [22] 房鑫,陈兵旗,彭书博,等. 基于改进YOLOv4的前方车辆检测方法[J]. 传感器与微系统,2024,43(10):155-159.
- FANG X, CHEN B Q, PENG S B, et al. A forward vehicle detection method based on improved YOLOv4[J]. Sensors and Microsystems,2024,43(10):155-159.
- [23] 温王鹏,罗文婷,李林,等. 基于YOLOv7和图像分块的车道线破损检测算法[J]. 传感器与微系统,2024,43(09):131-134+139.
- WEN W P, LUO W T, Li L, et al. Lane line breakage detection algorithm based on YOLOv7 and image chunking[J]. Sensors and Microsystems,2024,43(09):131-134+139.
- [24] 胡海宁,黄雷阳,杨洪刚,等. 改进YOLOv8n的轻量型蜂窝陶瓷缺陷检测算法[J]. 激光与光电子学进展, 2024, 61(22): 160-169.
- Hu H N, Huang L Y, Yang H G, et al. Improved YOLOv8n defect detection algorithm for lightweight honeycomb ceramics[J]. Advances in Lasers and Optoelectronics, 2024, 61(22): 160-169.
- [25] Khanam R, Hussain M. Yolov11: An overview of the key architectural enhancements. arxiv 2024[J]. arxiv preprint arxiv: 2410.17725.
- [26] 罗臻,蒋瑜,李维诚. 基于改进YOLO11n的道路缺陷检测模型[J/OL]. 微电子学与计算机,1-13[2025-02-28].
- Luo Z, Jiang Y, Li W C. Road defect detection model based on improved YOLO11n[J/OL]. Microelectronics and Computers, 1-13 [2025-02-28].
- [27] 阮庭海,樊卫华. 基于YOLOv8的自动驾驶车道检测改进算法[J]. 计算机测量与控制,2025,33(02):31-36.
- Ruan T H, Fan W H. Improved algorithm for automatic driving lane detection based on YOLOv8[J]. Computerized Measurement and Control,2025,33(02):31-36.
- [28] 庞国涛,邓晓平,于海洋,等. 基于改进YOLOv5s的预制叠合板生产质量视觉检测研究[J]. 土木工程信息技术,2025,17(01): 37-42.
- PANG G T, DANG X P, YU H Y, et al. Research on visual inspection of prefabricated laminated panel production quality based on improved YOLOv5s[J]. Information Technology for Civil Engineering and Construction,2025,17(01):37-42.
- [29] 李希,潘誉. 基于改进YOLOv8的探地雷达管线目标检测方法[J]. 计算机与现代化,2025,(01):94-99.
- LI X, PAN Y. Ground-penetrating radar pipeline target detection method based on improved YOLOv8[J]. Computer and Modernization,2025,(01):94-99.
- [30] Lei F.; Tang F.; Li S. Underwater Target Detection Algorithm Based on Improved YOLOv5. J. Mar. Sci. Eng. 2022, 10, 310.