

面向老年人跌倒检测的改进 YOLOv7 算法

易峥荣, 潘昊[†], 谢冰倩

(沈阳化工大学信息工程学院, 辽宁 沈阳 110000)

摘要:随着人口老龄化的问题日益凸显,室内跌倒事件的发生率也随之上升,老人跌倒成为家庭和社会关注的重点问题。针对目前的跌倒检测模型往往需要大量的计算资源和参数配置,且在复杂环境中这些跌倒检测算法的准确率仍然较低等问题,提出了一种改进型的 YOLO-GDDH 的跌倒检测算法。首先,借鉴 YOLOv9 提出的广义高效层聚合网络(GELAN),在原始骨干网络中加入 RepNCSPPELAN4 模块,保证网络轻量级的基础上提升网络推理速度和准确度。其次,引用一种先进的聚集和分布(GD)机制来改进原有的路径聚合网络(PANet),增强颈部网络的信息融合能力。最后,采用动态检测头进行检测结果输出,加快网络收敛速度。实验结果表明,改进算法在测试集上的均值平均精度 mAP@ 0.5 达到 97.8%,优于基线 YOLOv7-tiny;同时,模型仅有 6.4 M 的参数数量和 14.3 B 的计算量。相较于其他主流的轻量化目标检测模型, YOLO-GDDH 在保证模型轻量化的同时具有较高的检测精度,验证了本文所提方法的有效性。

关键词:跌倒检测; YOLOv7-tiny; 轻量化网络; 聚集和分布机制; 动态检测头

中图分类号: TP3

文献标识码: A

An Improved YOLOv7 Algorithm For Fall Detection in Elderly People

YI Zhengrong, PAN Hao[†], XIE Bingqian

(College of Information Engineering, Shenyang Chemical University, Shenyang, Liaoning 110000, China)

Abstract: Elderly falls have become a major issue for families and society as a result of the aging population's increasing prevalence and the rise in indoor fall incidents. This paper proposes an improved fall detection algorithm for YOLO-GDDH, aiming at the issues that current fall detection models often require a large number of computational resources and parameter configurations, the accuracy of these fall detection algorithms remains relatively low in complex environments. First, the RepNCSPPELAN4 module is added to the original backbone network, building on the generalized efficient layer aggregation network (GELAN) developed by YOLOv9, to enhance the network inference speed and accuracy while ensuring a lightweight network. Second, the original path aggregation network (PANet) is modified using a better gather-and-distribute mechanism (GD) mechanism. This improves the neck network's information fusion capability. Finally, the dynamic head is used to output detection results to accelerate the network convergence speed. The experimental results show that the improvement algorithm achieves 97.8% mean average precision mAP@ 0.5 on the test set, which is better than the baseline YOLOv7-tiny. meanwhile, the model has only 6.4 M parametric quantities and 14.3 B computational volume. in contrast to other popular lightweight target detection models, YOLO-GDDH has a high detection precision while maintaining the lightweight model, confirming the efficacy of the technique presented in this paper.

Key words: fall detection; YOLOv7-tiny; lightweight network; gather-and-distribute mechanism; DyHead

在全球范围内,人口老龄化的问题日益凸显,根据联合国的一份报告^[1],2020年全球65岁及以上的老年人口为7.27亿,预计到2050年将达到15亿(两倍多)。在这个人群中,室内跌倒事件的发生率异常高,据世界卫生组织(WHO)报告,每年有28%—35%的65岁以上老人至少跌倒一次,这一比例随着年龄的增长而上升,老人跌倒成为家庭和社会关注的重点问题。利用先进科学技术开发高效实用的跌倒检测系统为老年人提供安全保障,具有重要的社会实际意义。

近年来,国内外研究者们采用多种方法来提高跌倒检测的准确性和实用性,大多数跌倒检测方法主要分为三类:基于可穿戴传感器的方法、基于环境传感器的方法和基于计算机视觉的方法。基于可穿戴传感器的方法是一种利用加速度计、陀螺仪、气压计等传感器设备来计算各种参数^[2],根据这些参数识别到跌倒。但这种方法存在用户依从性差,且还需要考虑用户佩戴舒适度、电池寿命和数据隐私等问题^[3]。基于环境传感器的跌倒检测方法指的是使用环境中的设备(如传感器、摄像头、声音检测设备)来监测和识别跌倒事件^[4]。这类方法可能会受到光照条件和遮挡的影响,另外,该方法需要在环境中安装设备,涉及较高的初始成本和维护成本。基于计算机视觉的跌倒检测方法是一种非侵入性技术,这种技术通过图像或视频监控系统捕捉跌倒事件^[5]。由于现代人工智能和深度学习的发展,摄像头在机场、公交车站、火车站、道路、街道和家庭中的使用也越来越多,相较于前面两种方法,基于计算机视觉的方法为跌倒检测问题提供了更全面、更可靠的低成本解决方案。

目前,以计算机视觉为基础的目标检测算法主要分为两大类,一类是基于区域的目标检测算法(Region-based),如R-CNN(Regions with CNN features)^[6]、Fast-R-CNN^[7]、Faster-R-CNN^[8],这类算法首先生成一系列候选区域(即可能包含对象的区域),然后对每个区域进行分类,因为需要处理多个区域,通常速度较慢。另一类是基于回归或直接预测的目标检测算法,如YOLO(You Only Look Once)系列^[9-14]、SSD^[15]、RetinaNet^[16]等,这类算法通过直接预测图像中对象的边界框和类别来进行检测,简化了模型结构和训练过程,通常速度更快,适用于实时处理场景。因此,基于单阶段的YOLO及其衍生系列检测算法被广泛使用。

在人体跌倒检测工作中,针对YOLOv5s算法在检测老年人跌倒行为时存在的特征提取能力不

足、细节信息丢失等问题,Chen等^[17]通过增加非对称卷积块(ACB)和空间注意机制模块来增强YOLOv5s网络。这提高了模型的检测能力和准确性。Zi等^[18]提出了一种结合YOLOv7和DeepSORT的跟踪算法,使用双照明估计,可在处理前调整视频输入以增强可见性,该方法在减少误报和提高挑战性照明条件下跌倒检测的可靠性方面取得了显著改进。朱等^[19]结合了可变形卷积、标准卷积和通道空间混合注意机制开发了一个名为C2D的新型特征提取模块,这种结合不仅增强了模型捕捉复杂细节的能力,还改善了对目标变形的处理能力。卫王金^[20]采取数据重采样的方法,并在颈部网络嵌入坐标注意力模块,通过不同方向上的通道加权方式,使网络聚焦于待检测目标区域,以提取目标更多的细节信息,增强网络鲁棒性。黄万里^[21]通过借鉴注意力机制和膨胀卷积的思路,在YOLOv7的网络结构上依次设计3个模块嵌入网络模型中,从而提高老人跌倒检测算法的效率。上述跌倒检测的研究都取得了一定的成果,但仍存在一些问题。首先,尽管许多改进算法采用了特殊卷积模块以提高检测精度,但模型在复杂背景下的目标定位和识别精度仍有待提高。其次,一些模型通过添加注意力机制以提升精度,但多种注意力机制的有机结合使模型的计算成本和性能之间的平衡仍有不足。

针对上述问题,提出了一种基于YOLOv7-tiny的改进算法“YOLO-GDDH”,旨在实现模型轻量化与检测性能的优化,确保更准确地识别和定位目标。主要贡献如下:

- 1)在模型中采用RepNCSPeLan4模块对骨干网络进行改进,改进的骨干网络为模型提供了更完整的输入信息,提升了模型检测精度。
- 2)引入聚集和分发机制(GD)替换原有的路径聚合网络(PANet)结构,使模型的特征融合效率得到提升,改善误检漏检能力。
- 3)采用动态检测头DyHead替换原有检测头,增强模型多尺度特征融合能力,加快网络收敛速度。

1 YOLOv7-tiny 概述

YOLOv7是一种高效的目标检测模型,YOLOv7-tiny是YOLOv7的一个轻量级版本,设计上更为简化,参数数量显著减少,可以在CPU上较为有效地运行。YOLOv7-tiny整个网络架构分为三个主要部分:主干网络(Backbone)、颈部网络(Neck)

和预测网络(Head)。其结构图如图 1 所示。

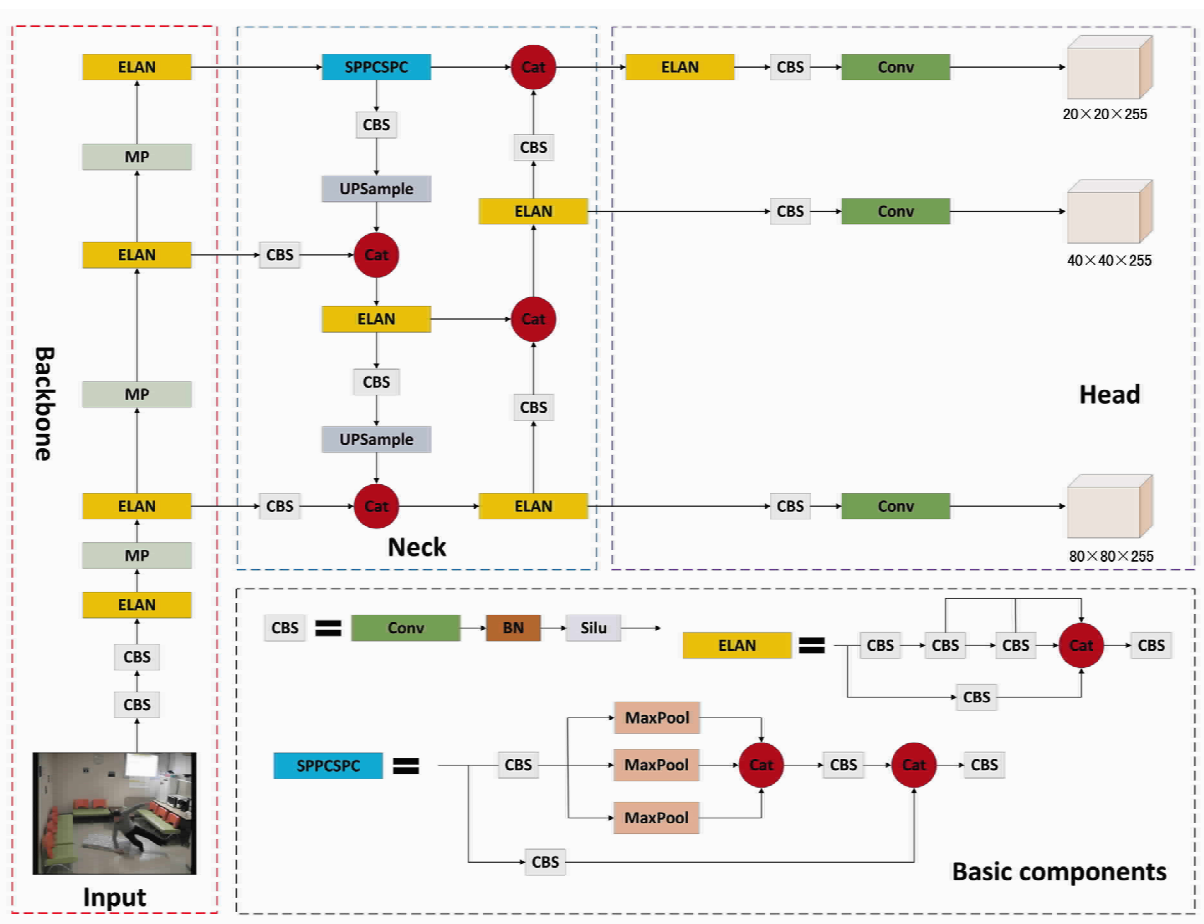


图 1 YOLOv7-tiny 网络结构

1.1 主干网络

主干网络是一个主要由卷积层组成的深度神经网络,包含 CBS 模块、ELAN 模块以及 MP 模块。CBS 模块由卷积层、BN 层和 SILU 激活函数组成。其中,ELAN 模块是一个高效的网络结构,通过控制最短和最长的梯度路径使网络学习更多特征,具有更强的鲁棒性。

1.2 颈部网络

颈部网络位于检测模型的主干和头部之间,也称为检测器的副本。颈部的主要功能是进行特征融合,它将不同尺度的特征图整合在一起,以便在多尺度上进行有效的目标检测。

1.3 预测网络

检测发生在头部,Head 也称为密集预测,YOLOv7 网络采用 I-Detect 检测头作为输出端,利用 RepConv 来调整通道数,并使用 1×1 卷积操作预测目标的位置、对象的类别以及置信度。

2 改进的 YOLO-GDDH 算法

使用 RepNCSPELAN4 模块、GD 机制和 DyHead 检测头对原始网络进行了三方面的改进,改进的网络结构图如图 2 所示。

2.1 改进的特征提取主干网络

RepNCSPELAN4 模块是 YOLOv9 中提出的一种先进架构,主要设计用于高效处理高维数据,使用较少的参数来维持或甚至提高模型的性能,专门用于在不同尺度上改进特征的处理和聚合。c1 为模块的输入 channel(上一模块的输出),c2 为模块的输出 channel,其整体结构如图 3 所示。

RepNCSPELAN4 模块主要由卷积层(Conv)和 RepNCSP 模块共同作用以处理和精炼特征。卷积层用以从输入图像中提取特征,保持空间尺寸的同时修改通道深度。除了核心架构细节外,RepNCSPELAN4 还包括来自通用高效层聚合网络(GELAN)的元素,GELAN 继承了 CSPNet 和 ELAN 的设计理念,侧重于高效的梯度路径规划和快速推理。本文使用该模块改进原有结构的主干网络,在保证网络轻量化的同时,增强模型计算效率和性能。

提出的 YOLO-GDDH 的跌倒检测算法通过

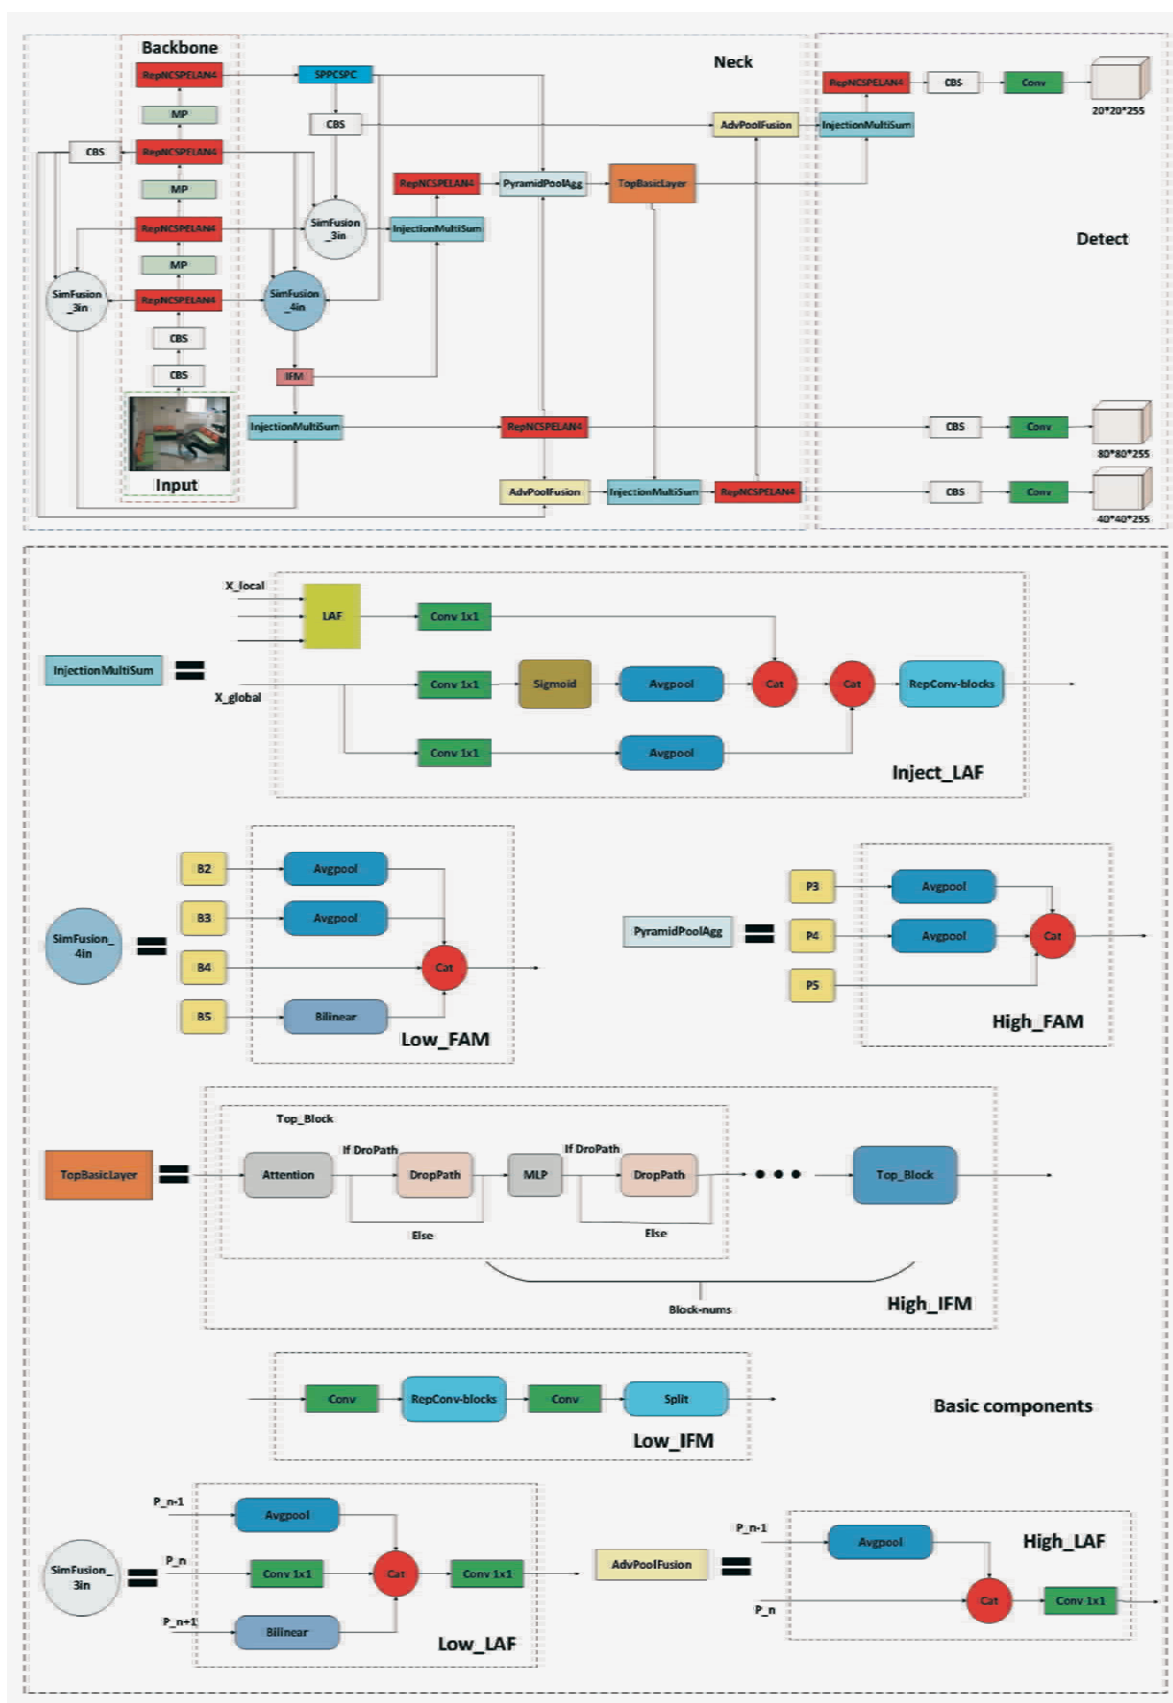


图2 YOLO-GDDH 网络结构图

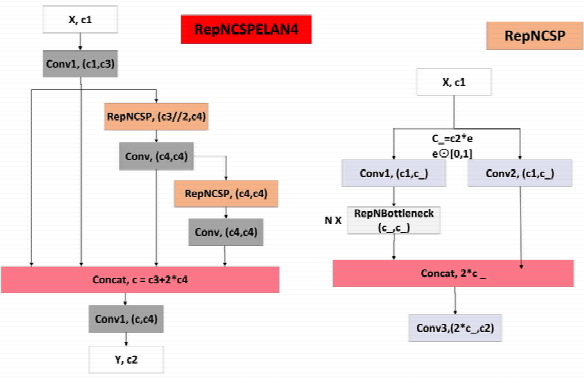


图 3 RepNCSPELAN4 模块结构图

2.2 融合 GD 机制的颈部网络

YOLOv7 的颈部采用了路径聚合网络 (PANet) 来融合多层特征, PANet 通过自上而下和自下而上的路径增强了特征层之间的连接和信息流动,从而使模型在不同尺度上捕捉到更丰富的特征信息。但在 YOLOv7 中,仍存在信息损失问题,故本文通过在 YOLOv7-tiny 网络的 Neck 部分引入聚集和分发机制 (GD),使用统一的模块来聚集和融合所有层级的信息,在不显著增加网络计算量的情况下,增强多尺度特征融合能力。

GD (Gather-and-Distribute) 机制^[22]是一个信息融合结构,它通过全局融合多层特征并将全局信息注入更高的层中,显著增强了颈部的信息融合能力。GD 机制包括两个分支:低阶聚集和分配 (Low-GD) 分支及高阶聚集和分配 (High-GD) 分支,分别通过基于卷积的块和基于注意力的块提取和融合特征信息,其网络架构如图 4 所示。

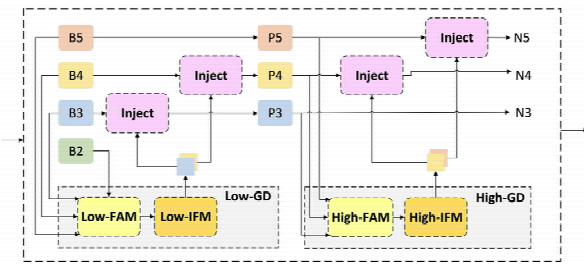


图 4 DG 网络结构图

低阶分支主要处理高分辨率特征,以保留小目标的信息,此分支主要包括低阶特征对齐模块 (Low-FAM)、低阶信息融合模块 (Low-IFM) 以及信息注入模块 (Inject),其细节结构图如图 3 所示。

低阶特征对齐模块使用平均池化 (AvgPool) 操作来下采样输入特征,实现特征尺寸的统一,同时减少后续处理步骤的计算复杂性。低阶信息融合模块采用多层重参数化卷积块 (RepBlock) 和分割操作。RepBlock 将对齐后的特征 F_{align} 作为输入,并输出融合后的特征 F_{fuse} ,这些特征随后在通道维度上被分割为 F_{ini_P3} 和 F_{ini_P4} ,并与不同层级的特征融合。其公式如下所示:

$$F_{align} = \text{LOW_FAM}([B2, B3, B4, B5]) \tag{1}$$

$$F_{fuse} = \text{RepBlock}(F_{align}) \tag{2}$$

$$F_{ini_P3}, F_{ini_P4} = \text{split}(F_{fuse}) \tag{3}$$

最后信息注入模块 (Inject) 将得到融合后的全局信息分发到每个层级,并通过注意力操作注入,以此增强模型对特定层级特征的处理能力。

高阶分支则聚焦于处理低分辨率特征,优化对大尺寸目标的检测,强化了模型的多尺度处理能力。此分支的关键模块包括高阶特征对齐模块 (High-FAM)、高阶信息融合模块 (High-IFM) 和信息注入模块 (Inject)。高阶特征对齐模块与低阶模块类似,使用平均池化 (Avgpool) 减少输入特征的维度至统一大小,为后续的高级信息处理减轻负担。高阶信息融合模块采用变压器块 (Transformer Block) 和分割操作处理对齐后的特征。其公式如下:

$$F_{align} = \text{High_FAM}([P3, P4, P5]) \tag{4}$$

$$F_{fuse} = \text{Transformer}(F_{align}) \tag{5}$$

$$F_{ini_N4}, F_{ini_N5} = \text{Split}(\text{Conv } 1 \times 1(F_{fuse})) \tag{6}$$

在高阶分支中,信息注入模块与低阶分支中完全相同。此外,为了促进信息流动,GD 还引入了轻量级相邻层 (LAF) 融合模块,该模块在局部尺度上组合来自邻近层的特征,采用 LAF 模块与信息注入模块的结合来平衡模型的准确性和速度之间的关系。

2.3 改进的动态检测头

YOLOv7 的检测头由多个卷积层构成,这些卷积层负责从特征图中预测对象的类别和位置。针对在处理高度动态和复杂场景时传统检测头存在灵活性和适应性不足等问题,本文采用动态检测头 DyHead (Dynamic Head)^[23] 替换原有检测头,通过在目标检测头中整合多种注意力机制来处理特征的不同维度 (尺度、空间位置和通道),以适应不同的任务和场景,从而提升目标检测的性能,动态检测头结构如图 5 所示。

给定特征张量 $F \in R$, DyHead 动态检测头应用自注意的一般模拟为 $W(F) = \pi(F) \cdot F$, 将注意力功能转换为三个连续的注意, 每个注意只关注一个角度:

$$W(F) = \pi_C(\pi_S(\pi_L(F) \cdot F) \cdot F) \cdot F \quad (7)$$

式中, $\pi_L(\cdot)$ 、 $\pi_S(\cdot)$ 、 $\pi_C(\cdot)$ 分别是作用于尺度 L、空间位置 S 和通道 C 上的三个不同的注意函数。

(1) 尺度感知注意力 (Scale-aware Attention) π_L : 根据对象的尺寸动态地调整特征的重要性, 以便于对不同尺寸的对象进行有效检测。

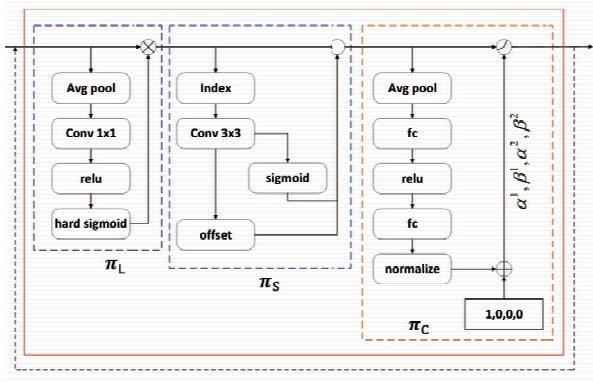


图 5 DyHead 结构

$$\pi_L(F) \cdot F = \sigma\left(f\left(\frac{1}{s_c} \sum_{s,c} F\right)\right) \cdot F \quad (8)$$

式中, $f(\cdot)$ 是 1×1 卷积层近似的线性函数;

$\sigma(x) = \max\left(0, \min\left(1, \frac{x+1}{2}\right)\right)$ 是 hard-sigmoid 激活函数。

(2) 空间感知注意力 (Spatial-aware Attention) π_S : 针对特征图的空间位置, 识别并强化那些对分类和定位最为关键的区域。

$$\pi_S(F) \cdot F = \frac{1}{L} \sum_{l=1}^L \sum_{k=1}^K \omega_{l,k} \cdot F(l; p_k + \Delta p_k; c) \cdot \Delta m_k \quad (9)$$

式中, K 为稀疏采样位置的个数; $p_k + \Delta p_k$ 为自学习空间偏移量 Δp_k 移位的位置, 以聚焦于判别区域; Δm_k 为位置 p_k 处的自学习重要标量。两者都是从 F 的中位数水平的输入特征中学习到的。

(3) 任务感知注意力 (Task-aware Attention) π_C : 根据不同任务 (如分类、框回归) 的需要, 动态调整特征通道的激活, 以优化各种任务的性能。

$$\pi_C(F) \cdot F = \max(\alpha^1(F) \cdot F_c + \beta^2$$

$$\beta^1(F), \alpha^2(F) \cdot F_c + \beta^2) \quad (10)$$

式中, F_c 是指第 c 个通道的特征片; $[\alpha^1, \alpha^2, \beta^1, \beta^2]^T = \theta(\cdot)$ 是一个学习控制激活阈值的超函数。

3 实验结果与分析

3.1 实验数据集及实验环境

为解决目前跌倒检测领域数据集规模有限、无法涵盖各种情况和变化等问题, 本实验数据集综合选取 UR Fall Detection Dataset、Fall detection Dataset、Le2i Fall Detection Dataset 三个数据集中的各部分组合而成。针对性地收集不同光照条件、生活场景的数据, 最终整理了 5735 张图片, 按照 6:2:2 划分训练集、验证集和测试集。

本研究基于 Pytorch 深度学习框架, 操作系统为 Windows 11, 实验环境为 python3.8、pytorch1.11 和 cuda11.3, 全部的模型在 RTX 3090 (24GB) 上运行在相同的超参数下进行训练、验证和测试, 均使用 SGD 优化器, 具体实验参数如表 1 所示。

表 1 实验参数

参数名称	参数信息
训练轮数	300
批次大小	8
图像大小	640×640
初始学习率	0.001
学习率动量	0.937
权重衰减系数	0.0005
预热 Epoch	3
预热学习率	0.1
预热学习率动量	0.8

3.2 评价指标

跌倒检测问题可以被认为是一个二元问题。对于跌倒检测, T 表示发生跌倒, F 表示没有跌倒。本文选取准确率 (Precision)、召回率 (Recall)、平均精度 (Average Precision, AP)、平均精度均值 (mean Average Precision, mAP) 作为模型性能评价指标, 其中 mAP 是评估模型整体性能的关键指标, 具体分为 mAP@0.5 和 mAP@0.5-0.95。mAP@0.5 表示 IoU 设为 0.5 时, 计算每一类的所有图片的 AP 值, 然后所有类别求平均; mAP@0.5-0.95 表示在不同 IoU 阈值 (从 0.5 到 0.95, 步长 0.05) 上的平均 mAP。其值越高, 表明该目标检测

模型的检测效果越好。准确率、召回率、平均精度和平均精度均值都可以根据 TP(真阳性)、TN(真阴性)、FP(假阳性)和 FN(假阴性)来定义,其公式如下式(11)~式(14)所示。

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (11)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (12)$$

$$\text{AP} = \int_0^1 p(R) dR \quad (13)$$

$$\text{mAP} = \frac{1}{n} \sum_{i=0}^n \text{AP}_i \quad (14)$$

式中,TP 表示正确检测跌倒;TN 表示正确检测到未跌倒;FP 的意思是错误地将正常活动检测为跌倒;FN 表示错误地将跌倒活动检测为未跌倒;准确率代表评估捕获的成果中跌倒所占得比例;召回率是指一项实验能正确地将实际跌倒检测为跌倒的程度。

3.3 实验结果

3.3.1 消融实验

为验证本文新增的模块是否起到作用,设置了消融实验。为了保证实验的公平性,所有实验结果均不采用预训练模型,所有超参数均一致,实验结果如表 2 所示。其中“√”号表示本组实验已使用该模块。

比较实验 A、实验 B 可知,将主干网络替换为 RepNCSPELAN4 模块后,模型具有高效的梯度路径规划和快速推理能力,相较于 YOLOv7-tiny 的所有指标均有上升,显示出该模块可以有效提升模型的检测精度。由实验 D 和实验 F 可知,各模块对 YOLOv7-tiny 模型的性能均有提升作用,而模块的组合使用可以进一步放大这些效果,特别是在各功能模块的配合下,最终的改进型 YOLO-GD-

DH 相较于 YOLOv7-tiny 而言准确率提升 2.4%,召回率提升 2%,mAp@0.5 提升 1.6%,mAp@0.5-0.95 提升 2.2%。

图 6 为在训练过程中比较 YOLOv7-Tiny 和改进型 YOLO-GDDH 的结果对比图。通过实验结果图可以观察到,改进型的 YOLO-GDDH 在各方面都优于 YOLOv7-tiny,准确率大幅提升,召回率、mAp@0.5 也增长显著,Training loss 收敛更快,模型的精度和准确率都得到了明显提升,验证了本文所提方法的有效性。

3.3.2 轻量化对比试验

为体现改进后的模型 YOLO-GDDH 在保持优异性能的同时兼顾实时性和网络的计算量,我们设置了轻量化对比实验,额外增加用来衡量模型内存占用的参数量(Params)和计算量的浮点运算次数(Floating Point Operations Per Second, FLOPs)作为模型性能的评价指标之一,FLOPs 数越高,意味着该模型需要更多的计算资源来运行。实验结果如表 3 所示。通过将 YOLO-GDDH 与其他检测模型对比可知,YOLOX、YOLOv6 模型参数量大,计算量也很大;RCS-YOLO、YOLOv5s 与 YOLOv7-tiny 模型各项性能指标不相上下,但其参数量和计算量都偏大;YOLOv9 模型作为 YOLO 系列最新版本,具有较高的准确性优势,但在模型轻量化方面,改进后的 YOLO-GDDH 模型具有较低的计算复杂度和参数数量,明显优于 YOLOv9 模型,且模型较于原始 YOLOv7-Tiny 仅增加 0.4M 的参数量,但检测精度和准确率都有显著提升,相较于目前主流的轻量化目标检测模型更优。

表 2 消融实验比较

实验编号	YOLO v7-tiny	RepNCSPELAN4	GD	DyHead	Precision	Recall	mAP @0.5	mAP @0.5-0.95
A	√				92.5	91.7	96.2	65.7
B	√	√			93.1	92.2	95.9	65.8
C	√		√		92.8	92.5	96.5	66.2
D	√	√	√		93.7	93.2	96.7	67.6
E	√			√	92.9	92.6	96.1	66.6
F	√	√	√	√	94.9	93.7	97.8	67.9

表3 不同轻量化模型对比

模型	Precision	Recall	mAP@0.5	mAP@0.5-0.95	Params /M	FLOPs /B
YOLOX	91.5	90.1	95.3	64.4	8.9	26.8
RCS-YOLO	93.3	92.6	96.7	66.6	7.8	21.8
YOLOv5s	92.3	91.5	96.1	65.2	7.0	16.0
YOLOv6	92.2	90.8	95.9	65.1	18.5	45.3
YOLOv7-tiny	92.5	91.7	96.2	65.7	6.0	13.2
YOLOv9	96.3	95.5	98.8	69.1	9.7	39.6
YOLO-GDDH	94.9	93.7	97.8	67.9	6.4	14.3

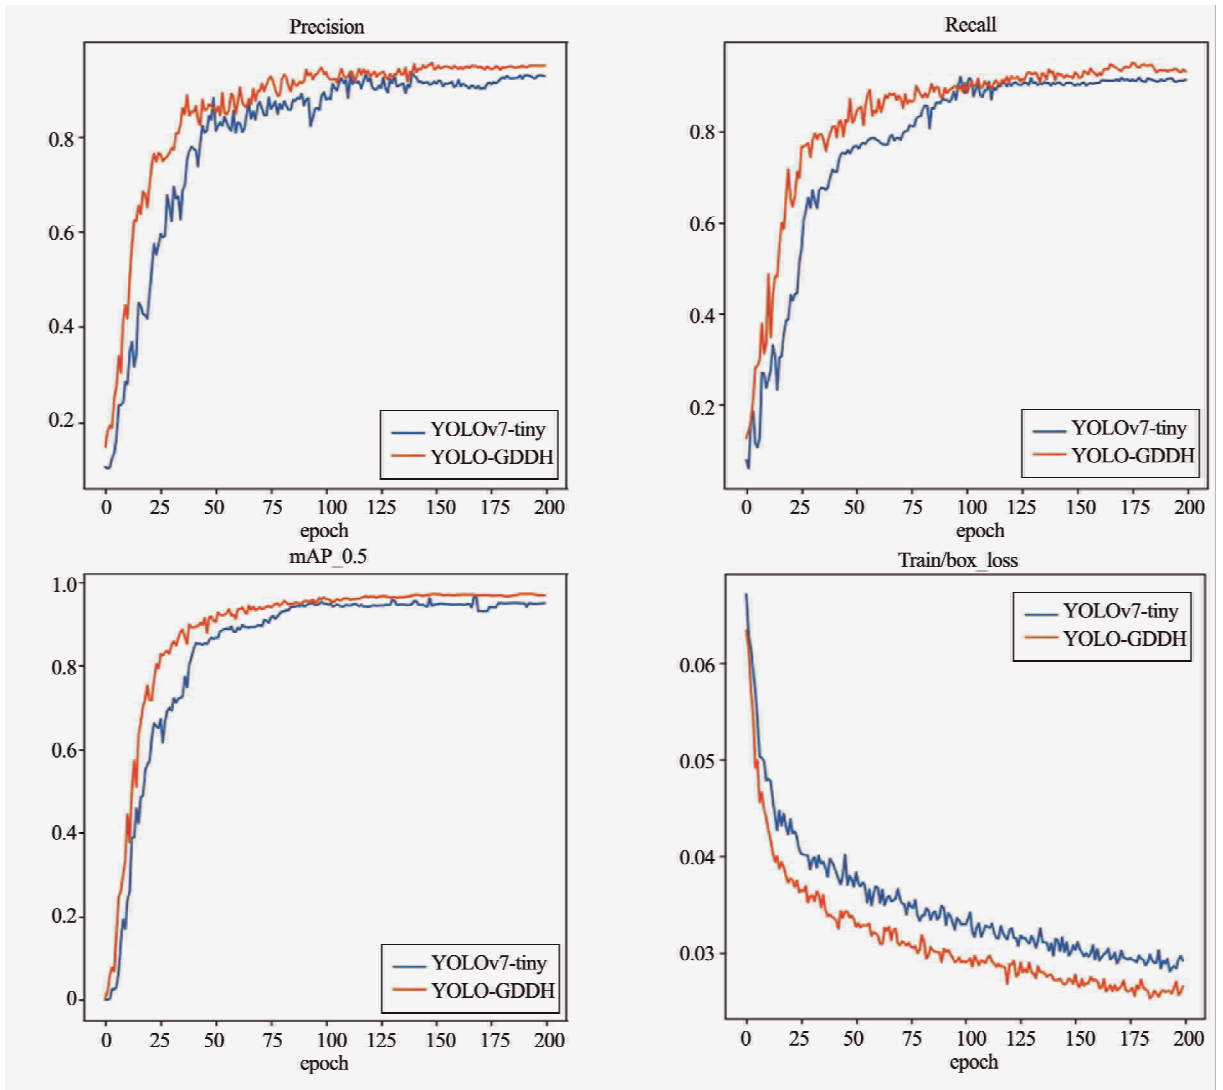


图6 改进型 YOLO-GDDH 和 YOLOv7-tiny 训练情况对比

4 结论

针对目前的跌倒检测模型往往需要大量的计算资源和参数配置,且在复杂环境中,如物体遮挡和光照不足的场景下,这些跌倒检测算法的准确率

仍然较低等问题,提出了一种基于 YOLOv7-tiny 改进的人体室内跌倒检测算法:YOLO-GDDH。改进后的模型相比 YOLOv7-tiny 模型,其参数量和计算量小幅增加,准确率、召回率及精度均有所提升,在保证模型轻量化的同时具有较高的检测精度,满足实际应用场景下跌倒检测的需求。未来,

我们将采用剪枝、量化等模型压缩方法来减少模型参数数量,兼顾检测速度和精度的同时,更好地部署到边缘设备上。

参考文献

- [1] United Nations, Department of Economic and Social Affairs, Population Division. World Population Ageing 2020 Highlights: Living arrangements of older persons[R]. New York: United Nations, 2020: 1—2.
- [2] KANGAS M, KONTTILA A, WINBLAD I, et al. Determination of simple thresholds for accelerometry-based parameters for fall detection[C]//2007 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 2007: 1367—1370.
- [3] YUSIF S, SOAR J, HAFEEZ-BAIG A. Older people, assistive technologies, and the barriers to adoption: a systematic review[J]. International Journal of Medical Informatics, 2016, 94: 112—116.
- [4] YANG L, REN Y, ZHANG W. 3D depth image analysis for indoor fall detection of elderly people[J]. Digital Communications and Networks, 2016, 2(1): 24—34.
- [5] ROUGIER C, MEUNIER J, ST-ARNAUD A, et al. Robust video surveillance for fall detection based on human shape deformation[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2011, 21(5): 611—622.
- [6] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[A]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Columbus, OH, USA: IEEE, 2014: 580—587.
- [7] GIRSHICK R. Fast R-CNN[A]//Proceedings of the IEEE International Conference on Computer Vision (ICCV). Santiago, Chile: IEEE, 2015: 1440—1448.
- [8] 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, 2017, 39(6): 1137—1149.
- [9] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[A]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA: IEEE, 2016: 779—788.
- [10] LI C, LI L, JIANG H, et al. YOLOv6: a single-stage object detection framework for industrial applications[J]. arXiv, 2022.
- [11] GE Z, LIU S, WANG F, et al. YOLOX: exceeding YOLO series in 2021[J]. arXiv, 2021.
- [12] 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[J]. arXiv, 2022.
- [13] WANG C Y, YE H I, LIAO H Y M. YOLOv9: learning what you want to learn using programmable gradient information[J]. arXiv, 2024.
- [14] KANG M, TING C M, TING F F, et al. RCS-YOLO: a fast and high-accuracy object detector for brain tumor detection[A]. In: GREENSPAN H, MADABHUSHI A, MOUSAVI P, et al. Medical Image Computing and Computer Assisted Intervention - MICCAI 2023[M]. Cham: Springer Nature Switzerland, 2023, 14223: 600—610.
- [15] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector[A]. In: LEIBE B, MATAS J, SEBE N, et al. Computer Vision-ECCV 2016[C]. Cham: Springer International Publishing, 2016: 21—37.
- [16] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[A]// Proceedings of the IEEE International Conference on Computer Vision (ICCV). Venice, Italy: IEEE, 2017: 2980—2988.
- [17] CHEN T, DING Z, LI B. Elderly fall detection based on improved YOLOv5s network[J]. IEEE Access, 2022, 10: 91273—91282.
- [18] ZI X, CHATURVEDI K, BRAYTEE A, et al. Detecting human falls in poor lighting: object detection and tracking approach for indoor safety[J]. Electronics, 2023, 12(5): 1259.
- [19] 朱胜豪, 钱承山, 阙希. 改进 YOLOv5 的高精度跌倒检测算法[J]. 计算机工程与应用, 2022, 58(20): 1—11.
- [20] 卫金金. 基于单目摄像头的室内老人跌倒识别研究[D]. 南京: 南京邮电大学, 2022.
- [21] 黄万里. 基于改进 YOLOv7 的跌倒检测算法研究[D]. 武汉: 江汉大学, 2024.
- [22] WANG C, HE W, NIE Y, et al. Gold-YOLO: efficient object detector via gather-and-distribute mechanism[J]. Advances in Neural Information Processing Systems, 2023, 36: 51094—51112.
- [23] DAI X, CHEN Y, XIAO B, et al. Dynamic head: unifying object detection Heads with attentions[J]. arXiv, 2021. World Population Ageing 2020 Highlights .