Research on Fall Detection Algorithm for the Elderly Based on Structural Reparameterization*

SONG Wei, ZHOU Chen, PAN Julong*
(College of Information Engineering, China Jiliang University, Hangzhou Zhejiang 310018, China)

Abstract: Developing a reliable wearable fall detection device is essential for mitigating injuries among the elderly resulting from fall. Most of current deep learning models for elderly fall detection struggle to balance accuracy with computing cost effectively. A novel fall detection classification model utilizing structural reparameterization is studied and designed to solve the above problems. Initially, the moment of a is identified fall based on peak combined acceleration, which is used as the central point for data windowing. Two seconds data around this point are then captured as the model's input data. A multi-branch convolutional kernel, serving as the backbone for feature extraction, is developed. To enhance efficiency, the Ghost Module is integrated, streamlining the model and minimizing computational demands. Structural reparameterization differentiates the model's training from its testing, allowing for the extraction of acceleration, gyroscope, and Euler angle features via the multi-branch convolutional kernel during training. During testing, this multi-branch structure condenses into a single-branch framework, reducing computational load and improving inference speed while maintaining model performance. Results of experimental validation on both KFall and SisFall datasets demonstrate the model's excellence, achieving accuracy of 99.60% and 98.67%, specificity of 99.56% and 98.58%, sensitivity of 99.64% and 98.72%, respectively.

Key words: fall detection; lightweight model; structural reparameterization; wearable device; inertial data
EEACC: 7230 **doi**: 10.3969/j.issn.1004-1699.2025.10.009

基于结构重参数化的老人跌倒检测算法研究*

宋 炜, 周 辰, 潘巨龙*
(中国计量大学信息工程学院, 浙江 杭州 310018)

摘 要: 穿戴快速且精准的跌倒检测装置是减少老年人因跌倒后无法及时救助而受到伤害的有效方法。目前用于老人跌倒检测的深度学习模型仍未能兼顾精度与计算效率, 提出一种基于结构重参数化的跌倒检测分类模型用于解决上述问题。首先, 确定跌倒落地合加速度最大时刻作为数据窗口的中心点, 以此点向前和向后分别截取 1 s 的数据作为模型输入, 构建多分支不同大小的卷积核作为特征提取的核心骨干网络。其次, 引入 Ghost 模块减少计算量, 使模型更轻量化。最后, 使用结构重参数化, 使得模型的训练和测试有所区分, 在模型训练时通过多分支卷积提取加速度、陀螺仪和欧拉角的特征, 在测试时, 将多分支结构等价转换为单路结构后, 在几乎不损失模型性能前提下减少了模型的计算量并提高了推理速度。实验结果表明, 在 KFall 和 SisFall 两个跌倒公开数据集上, 改进后的模型分别获得 99.60%和 98.67%的准确率、99.56%和 98.58%的特异度、99.64%和 98.72%的敏感度。

关键词: 跌倒检测; 轻量化模型; 结构重参数化; 可穿戴设备; 惯性传感数据
中图分类号: TP181 **文献标识码**: A **文章编号**: 1004-1699(2025)10-1793-07

据联合国最新统计, 全球老龄人口总数已达 6.29 亿, 占世界总人口的 10%, 2020 年, 我国 60 岁以上的老年人因跌倒而死亡的人数占到了因伤害死亡人数的 39.34%[1]。对于老人而言, 跌倒所带来的损害比年轻人更大, 死亡率更高, 且跌倒带来的骨折、扭伤更难以恢复。据统计, 65 岁以上老人是因摔倒造成死亡的主要人群。即使跌倒不一定会造成身体伤害, 也会造成老人沮丧、抑郁、焦虑的心理, 老人会因害怕再次跌倒而降低行为能力, 导致行动受限。在这样的背景下, 如果不能及时反馈和解决跌倒引发的问题, 将会带给老人更大的身体和精神损伤, 所以积极应对因跌倒给老人带来的影响是实现健康老龄化的关键[2]。

目前, 有多种跌倒检测方法, 大致可以分为下面

项目来源: 浙江省基础公益研究计划项目(LGF21F020017)
收稿日期: 2024-04-18 **修改日期**: 2024-07-04

三类:基于可穿戴式传感器的方法[3]、基于环境信息的方法[4]和图像(视频)的方法[5]。

基于环境信息的跌倒检测在室内的多个位置安装设备记录老人的活动。通过整合红外线传感器、压力传感器和声音传感器等获得的信息,对跌倒行为进行检测。但是,该方法需要安装多个传感器,成本较高,而且易受房屋结构和外界环境的影响,导致准确率不高[6]。

基于图像(视觉)的方法不用用户携带设备,一般是将摄像头安装在室内,记录老人活动行为,经过图像处理和分析进行跌倒检测算法设计,从而判断人体是否发生跌倒。但是这种方法由于摄像头的盲区、光线不足、人体部分被遮挡等原因,不能有效判断老人跌倒的情况,并且严重侵犯了个人隐私。

相较于以上两种跌倒检测方法,基于可穿戴式传感器的方法具有检测设备成本低,不易受环境影响,检测范围广和跌倒漏报率低等优势。因此,基于可穿戴式设备的跌倒检测研究已逐渐成为学者关注的焦点[7]。该方法主要是把一个或多个传感器与微控制器组合的系统穿戴在老人身上,包括加速度计、陀螺仪和磁力计等[8],通过人体活动产生传感器信号,再经过数据预处理和分析,运用跌倒检测算法判断人体是否发生跌倒。刘鹏达等[9]针对在可穿戴式跌倒检测终端中部署机器学习模型存在计算力弱、内存受限和传统机器学习算法选取特征不完善等问题,提出了基于惯性传感器的轻量化卷积神经网络跌倒检测算法,达到了 98.20%的跌倒检测准确率。Waheed 等[10]研究了双向长短期记忆模型(BiLSTM)在数据集 SisFall 和 UP-Fall Detection 上的表现,该模型在两个数据集上的准确率分别为 97.21%和 97.41%。

分析上述研究可知,当前部署在可穿戴跌倒检测终端中的深度学习模型仍然存在一些问题,通常难以兼顾检测精度和计算速度。若使用经典轻量化模型加快推理速度,则提取的特征表达能力有限;若使用复杂的模型结构提高跌倒准确率,又会导致模型参数量和内存开销增大。

本文针对上述问题提出了一种基于结构重参数化的轻量化跌倒检测模型(Reparameterized Fall Detection Network,RFDNet)。本研究主要贡献为以下三点:①设计了多分支异构卷积核以提升模型对特征的表达能力,并引入了结构重参数化思想,对模型的训练和测试进行了解耦,在模型训练完成后,将多分支结构等价转换为单支路结构,在几乎不牺牲精度的同时,使得模型在轻量化和推理时间两个指标上得以改进。②引入 Ghost 模块[11],使得模型以较少代价获取丰富的跌倒数据特征,从而达到模型轻量化、减少模型计算量的目的。③本模型在 KFall 数据集上以 2 342 个参数量取得了 99.60%的准确率、99.56%的特异度和 99.64%的敏感度;在 SisFall 数据集上以 3 110 个参数量取得了 98.67%的准确率、98.58%的特异度和 98.72%的敏感度,在 PC 上使用本文模型对两个数据集的单个样本进行运算,模型推理时间分别为 1.57 ms 和 1.82 ms。本模型的轻量化和实时性保证了模型可部署至可穿戴跌倒检测装置中。

1 相关背景知识

1.1 相关数据集

本文采用数据集 KFall[12]和 SisFall[13]作为实验数据。

2021 年 Yu 等发布了公开数据集 KFall,该数据集由 32 位年轻采集者通过固定在下背部的九轴惯性传感器(LPMS-B2,LP-RESEARCH)采集获得,包括 15 种跌倒姿势和 21 种日常生活活动。数据集一共包含了 5 075 个样本,其中有 2 729 个日常活动样本,2 346 个跌倒样本。该数据集共有九轴数据,前三个为加速度数据,由三轴加速度计(±16 g)获取,中间三个为角速度数据,由三轴陀螺仪(±2 000 °/s)获取,后三个为欧拉角(横滚角、俯仰角和偏航角)数据,其通过对角速度进行集成,再结合加速度计和磁力计的信息,使用扩展的卡尔曼滤波算法进行修改计算得到。所有传感器均以 100 Hz 的采样频率采集数据。

2017 年 Sucerquia 等发布了公开数据集 SisFall,该数据集由 38 位志愿者在腰部佩带专用的嵌入式设备,以 200 Hz 的采样频率采集了加速度和角速度数据,一共包含 1 798 次跌倒样本和 2702 次日常活动样本,其中包括 23 名年轻人进行的 19 种日常生活活动(Activities of Daily Living,ADL)和 15 种跌倒类型,14 名 62 岁以上的健康独立参与者进行的 15 种 ADL 类型,以及一名 60 岁参与者进行所有 ADL 和跌倒的数据。本文使用四元数法对加速度数据和角速度数据进行姿态解算以求欧拉角,算法步骤为:单位化加速度向量、计算误差、积分误差、补偿角速度、四元数更新、四元数归一化和欧拉角计算。

1.2 欧拉角

欧拉角也称为姿态角,包含偏航角、俯仰角、横滚角。从人的正面看过去,x 轴正方向即为左手所指方向,y 轴正方向则为人体正面的朝向,z 轴正方

向则为人体正上方。绕 x 轴方向旋转的角度则为俯仰角,绕 y 轴方向旋转的角度为横滚角,绕 z 轴方向旋转的角度为偏航角(如图 1 所示)。

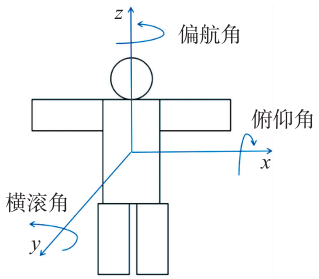

图 1　人体对应直角坐标系及欧拉角示意图

当人跌倒时姿态会随之发生变化,身体会发生一定程度的旋转,使得欧拉角产生变化,引入欧拉角的作用可以使模型有效判断人体当前姿态,确定人体当前是否为平躺状态,加入欧拉角还可以帮助模型判断跌倒方向,有助医护人员提前知晓受伤部位。当向前或向后跌倒时,俯仰角会发生显著变化,当人侧向跌倒时,则横滚角会发生显著变化。因此人体姿态角可以作为一个很好的特征给予模型学习,以求训练得到一个高精度的跌倒检测模型。

1.3　数据窗口选择

当人发生跌倒时,通常会经过以下三种阶段:跌倒前阶段、跌倒发生时失衡下落阶段和跌倒发生后与地面撞击及躺在地上的阶段。训练一个准确的跌倒检测模型,需要同时将这三个阶段的数据进行学习,因此给予模型的输入数据应同时包含这三阶段。在此三个阶段中,最具有显著特征的是跌倒发生时失衡下落阶段,该阶段人体会有剧烈的跌倒趋向。在此引入一个跌倒特征——信号幅度矢量 **SMV**(Signal Magnitude Vector),**SMV** 意为人体三轴加速度矢量平方和的平方根,其实质为人体发生跌倒动作的各向加速度变化的总体描述,在失衡下落阶段,**SMV** 将会逐渐增加,并在撞击地面前达到最大值,假设 $\boldsymbol{x}(t)$、$\boldsymbol{y}(t)$、$\boldsymbol{z}(t)$ 分别代表在 t 时刻 x 轴、y 轴和 z 轴方向上的加速度,则 **SMV** 定义式如式(1)所示:

$$\mathbf{SMV}=\sqrt{\boldsymbol{x}(t)^2+\boldsymbol{y}(t)^2+\boldsymbol{z}(t)^2} \tag{1}$$

数据窗口的长度和位置会影响模型检测跌倒的性能,本文设计将 **SMV** 达到峰值时刻作为数据窗口的中心位置,以此为中心向前和向后截取一段时间的数据作为数据窗口,以便于模型可以同时训练包含上述三个阶段的跌倒数据。跌倒发生的失衡下落阶段一般只有 0.8 s 左右,因此数据窗口的总体长度应至少 1.5 s 以上,这样可以保证模型较好地学习跌倒前阶段和跌倒后阶段传感器数据之间的差异。但数据窗口也不能过长,过长则会导致模型推理时间增加,提取的特征不显著,不利于模型训练。本文在 1 s、2 s 和 3 s 三种不同数据窗口长度的情况下对跌倒检测模型的准确率、敏感度和特异度进行了比较,本次实验在 SisFall 数据集上进行,实验结果如图 2 所示。

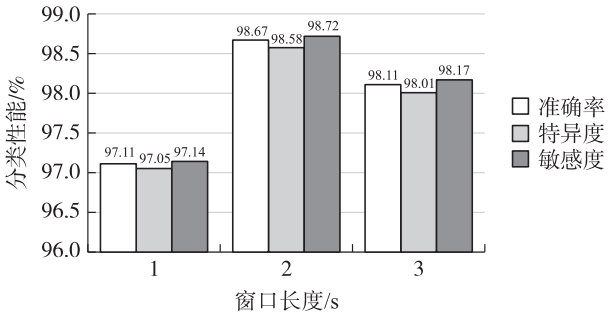

图 2　数据窗口长度对模型检测性能的影响

实验结果表明当数据窗口长度为 2 s 时,模型跌倒检测性能都比其他两种情况更好。特异度是误判跌倒的可视化体现,特异度越高误判越少。敏感度是漏判跌倒的可视化体现,敏感度越高漏判越少。

1.4　模型评价指标

本文旨在研究老人跌倒检测,该任务分类为跌倒和非跌倒(日常行为),二分类任务通常由四个统计参数评估,在本文中它们分别是:真正例(True Positive,TP)意为模型对样本预测为跌倒,而真实类别为跌倒。真负例(True Negative,TN)意为模型对样本预测为日常行为类(非跌倒),而真实类别为日常行为类。假负例(False Negative,FN)意为模型对样本预测为日常行为类,而真实类别为跌倒,即为漏判。假正例(False Positive,FP)意为模型对样本预测为跌倒,而真实类别为日常行为类,即为误判。

使用三种评价指标来评估跌倒检测模型性能:准确率(Accuracy,Acc)、特异度(Specificity,Sp)、敏感度(Sensitivity,Se)。其中准确率作为评估分类正确的样本占总样本个数的比例,特异度作为评估正确检测正常活动的样本占全部日常活动样本的比例,敏感度作为评估正确预测为跌倒的样本占全部跌倒样本的比例,定义式如下:

$$\mathrm{Acc}=\frac{\mathrm{TP}+\mathrm{TN}}{\mathrm{TP}+\mathrm{TN}+\mathrm{FP}+\mathrm{FN}} \tag{2}$$

$$\mathrm{Sp}=\frac{\mathrm{TN}}{\mathrm{TN}+\mathrm{FP}} \tag{3}$$

$$\mathrm{Se}=\frac{\mathrm{TP}}{\mathrm{TP}+\mathrm{FN}} \tag{4}$$

2 跌倒检测模型

跌倒检测任务具有实时性,同时跌倒检测模型需要准确的跌倒识别能力,并做到轻量化和高效化以部署在嵌入式跌倒检测终端。鉴于此,本文设计了多分支不同卷积核(Multi-branch Convolution Kernel,MCK)的结构以保证充分提取跌倒数据特征。引入 Ghost 模块构成 Ghost-MCK 模块,降低模型参数量和计算量,采用结构重参数化(Structural Reparameterization,Rep),使得多分支结构等价转换为单路结构以实现快速的推理。本文提出的 RFDNet 模型兼顾了准确率、实时性和轻量化要求,在跌倒精度和轻量化上具有良好平衡。

2.1 RFDNet 总体架构

RFDNet 是包含了 5 个阶段的卷积神经网络(如图 3(a)所示)。

本模型总体结构为倒残差结构,主要服务于计算资源受限的移动设备,倒残差结构的主要特点为首先逐点卷积扩充通道维度,然后将升维后的特征张量作为特征提取模块的输入,最后再进行逐点卷积降维作为下一模块的输入。

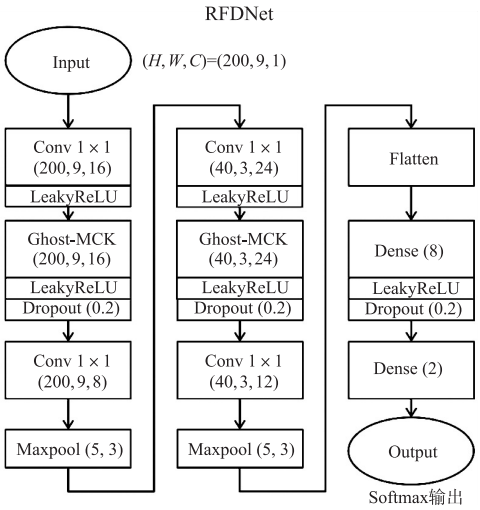

(a) RDFNet

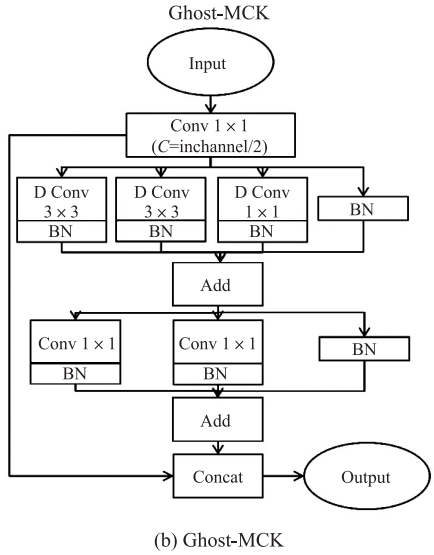

(b) Ghost-MCK

图 3 RDFNet 模型结构和 Ghost-MCK 结构

第一个阶段为模型输入阶段,使用一个逐点卷积扩充通道维度。

第二和第四阶段为主要的特征提取阶段,均由 Ghost-MCK 模块组成(如图 3(b)所示)。Ghost-MCK 模块首先将上一阶段的输入使用常规点卷积获取必要的特征,再通过 MCK 模块获取相似的特征图,然后将两者拼接,再进行非线性操作。Ghost-MCK 模块由两部分串联。第一部分由两个 3×3、一个 1×1 深度卷积层和一个恒等连接分支并联组成,第二部分则是由两个 1×1 卷积核和一个恒等连接分支并联组成,并且在每一层后都有 BN(Batch Normalization)层。不同尺寸的卷积核具备不同的感受野,能够提升模型提取特征的能力,使得获取的特征更加丰富。

第三阶段则是对第二阶段的输出进行逐点卷积降维操作,并经过池化层,再对其进行逐点卷积升维,作为第四阶段的输入。

第五阶段首先对第四阶段的输入进行降维操作并经过池化层,再采用全连接层、Dropout 层和 Softmax 函数输出跌倒检测的结果。

2.2 结构重参数化

模型训练时,以多分支卷积对数据提取多尺度特征,增强模型对特征的表示能力。然而多分支卷积的代价则是增加了模型的复杂度和参数量,严重影响了模型的推理速度。基于此原因,RFDNet 使用了结构重参数化的思想[14],使得模型训练完成后,将多分支卷积等价替换成单支路结构,这种方式在保证模型保留训练时获得的强大特征表示能力同时,又能降低模型复杂度和参数量,增加模型的推理速度。本文模型的重参数化包括对不同尺寸卷积核的合并和卷积层对 BN 层的吸收。

2.2.1 卷积吸收 BN 层

由于卷积计算和 BN 均为线性运算,具备可加性,因此可以使得卷积吸收 BN 层。卷积操作与 BN 的计算公式如下:

$$y_{\text{conv}}=wx+b_{\text{conv}} \tag{5}$$

$$y_{\text{BN}}=\gamma\frac{x-\mu}{\sigma}+b_{\text{BN}}=\frac{\gamma}{\sigma}x+\left(b_{\text{BN}}-\frac{\gamma\mu}{\sigma}\right) \tag{6}$$

式(5)、式(6)中:y_{conv} 和 y_{BN} 分别为卷积运算和 BN 层的输出,其中 x 代表输入,w 和 b_{conv} 分别为卷积的权重和偏移量。γ、μ、σ、b_{BN} 分别为 BN 层的缩放变

量、均值、方差和偏移量。虽然在训练周期时,以上参数会随着模型学习而更新,而在推理周期时,上述参数均为固定值,可以使得卷积层吸收 BN 层,联合式(5)和式(6)则可以得到吸收 BN 层后的卷积表达式,如下所示:

$$y_{\mathrm{conv(BN)}}=\left(\frac{\gamma\omega}{\sigma}\right)\times x+\left[\frac{\gamma}{\sigma}\times(b-\mu)+b_{\mathrm{BN}}\right]=\omega_{\mathrm{conv(BN)}}\times x+b_{\mathrm{conv(BN)}} \tag{7}$$

式中:$y_{\mathrm{conv(BN)}}$ 为新卷积的输出,x 为输入,$\omega_{\mathrm{conv(BN)}}$ 和 $b_{\mathrm{conv(BN)}}$ 为新卷积层的权重和偏置。

2.2.2　MCK 模块重参数化

MCK 模块的重参数化由两部分构成,第一部分为将两个 3×3、一个 1×1 深度卷积层和一个恒等连接分支结构重参数化,形成一个 3×3 深度卷积。第二部分则是将两个 1×1 点卷积层和一个恒等连接分支结构重参数化,形成一个 1×1 点卷积。

$$y_{\mathrm{conv(new)}}=(w_1x+b_1)+(w_2x+b_2)=(w_1+w_2)x+(b_1+b_2) \tag{8}$$

根据式(8)所示,若输入 x 的特征图尺寸大小相同,卷积之间具有可加性[15]。因此第一部分的卷积核分别补零扩充至 3×3 尺寸即可相加,而对于恒等连接分支,引入 Identity 的概念,对于某个运算符,若任一操作数与 I 通过运算符后仍为原来的数,那么 I 就是该运算符的 Identity,对于卷积操作同样有其 Identity,由于深度卷积可以看做分组卷积,只要将输入特征图与 i 组 1×1 卷积核进行分组卷积,i 等于输入通道数,每组卷积的输出通道数与输入通道数相同,并将第 n 组的第 n 个卷积权重赋值 1 即可使得输入特征图等于输出特征图,然后将 i 组 1×1 卷积核补零扩充成 i 组 3×3 卷积核,故可与其他 3×3 卷积核相加。根据卷积的可加性,将它们的权重和偏置进行相加,形成一个单路结构的 3×3 卷积层。对于第二部分的卷积进行相似操作,不同的是普通卷积不用分组卷积,因此恒等连接分支只需要一组点卷积。卷积相加操作如图 4 所示。

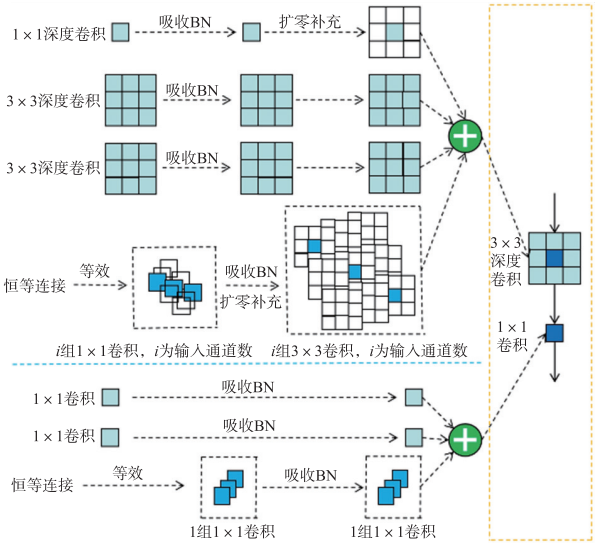

图 4　MCK 模块的重参数化

2.3　Ghost-MCK 模块

GhostNet[11] 网络在模型轻量化上的做法具有一定优势,其本质为将传统的单层卷积网络拆分为两种卷积方式,一种为普通卷积,另一种为简易线性计算,即首先使用普通卷积生成一半特征图,再通过简易线性变换生成一半特征图,最后将它们进行拼接生成最终输出特征图,以实现模型的轻量化。该模块以损失 0.16% 的模型准确率为代价,使模型推理时间降低 0.58 ms 和参数量减少 34.9%,轻量化后的模型更适合部署至可穿戴跌倒检测终端中。

针对本文的 MCK 模块,由于卷积核为 1×1 的深度卷积作用有限,因此,将其改为普通卷积,聚合通道信息,而将 3×3 卷积作为深度卷积,在该模块中无非线性层。重参数化后的 Ghost-MCK 模块如图 5 所示。

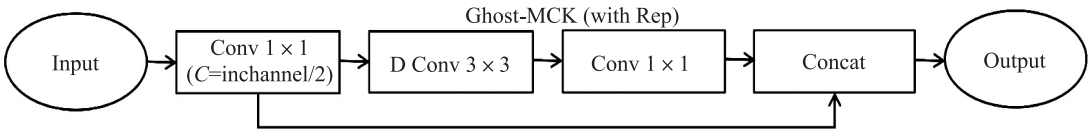

图 5　重参数化后的 Ghost-MCK 模块

3　实验结果与分析

为证明本文提出的 RFDNet 模型的准确性和优越性,并且加入欧拉角协助跌倒检测有助于提高其准确率和减少误判率,本文设置了重参数化后的 RFDNet 模型与传统模型之间在数据集 KFall 和 SisFall 上的对比实验以及欧拉角作为模型输入和结构重参数化对模型性能的影响的消融实验,模型输入均为加速度、角速度和欧拉角。目前使用数据集 KFall 和 SisFall 的 70% 数据用于模型训练、10% 数据用于模型验证和 20% 数据用于模型测试,未来计划部署至嵌入式跌倒终端中进行模型在线测试。

3.1　轻量化模型对比实验

由于可穿戴装置内存受限,因此模型对比方面,将本文模型与轻量化卷积模型 LW-CNN[9]、MobileNetV2[16]、SqueezeNet[17]、ShuffleNet[18] 和 CNN-LSTM[19]

进行对比。由于上述传统轻量化模型和本文模型比较过于庞大,其计算量和参数量较多,无法部署至可穿戴跌倒检测终端中并与本文模型进行对比,因此对这些模型进行了调整,便于本文模型与它们进行对比。主要的改动为降低这些模型的模块数,并加入和本文模型同样层数的池化层。总体来说,与本文模型进行对比的模型均是轻量化网络模型。其结果如表 1 和表 2 所示。

表 1 KFall 数据集上的模型性能对比

模型	Acc/%	Sp/%	Se/%	推理时间/ms	参数量/个
LW-CNN[9]	98.42	98.35	98.48	**1.02**	4 762
MobileNet V2[16]	99.16	99.14	99.21	1.53	5 342
SqueezeNet[17]	99.01	98.76	99.24	1.97	6 626
ShuffleNet[18]	98.60	98.27	98.90	1.76	8 514
CNN-LSTM[19]	98.61	99.36	97.98	2.06	4 834
RFDNet(本文)	**99.60**	**99.56**	**99.64**	1.57	**2 342**

从表 1 可以看出在 KFall 数据集上本文模型具有最高的准确率、特异度和敏感度,并且模型参数量在所有模型中最少,但推理速度并非最快,其中 LW-CNN 模型 1.02 ms 的推理时间为最短,其完全单路模型的结构,并且卷积层较少的原因导致其虽然推理速度快,模型性能却因此降低。而 RFDNet 并非完全的单路模型结构,因此其模型复杂度相较于完全单路结构模型高,导致推理时间相对增加,但在众多轻量化模型中仍有良好表现。

表 2 SisFall 数据集上的模型性能对比

模型	Acc/%	Sp/%	Se/%	推理时间/ms	参数量/个
LW-CNN[9]	97.11	95.55	98.26	**1.12**	8 858
MobileNet V2[16]	98.01	97.20	98.53	1.77	8 158
SqueezeNet[17]	97.78	97.30	98.10	2.24	9 442
ShuffleNet[18]	98.00	97.50	98.33	1.87	10 562
CNN-LSTM[19]	97.99	98.08	97.94	2.12	4 834
RFDNet(本文)	**98.67**	**98.58**	**98.72**	1.82	**3 110**

从表 2 可以看出轻量化模型在九轴 SisFall 数据集上表现整体不如 KFall 数据集,由于 SisFall 数据集中欧拉角的计算方式与 KFall 数据集中的欧拉角不同,因为 SisFall 数据集无磁力计数据,无法通过使用磁力计传感器采集到的数据对偏航角进行补偿,因此导致整体检测指标有所下降,但本文模型仍然在 SisFall 数据集上具有最好的综合性能。

3.2 欧拉角对模型的影响

在跌倒检测模型中,欧拉角作为输入特征有助于提供人体姿势和运动的关键信息。通过对欧拉角的变化进行特征提取,可以检测到人体发生突然的旋转,导致人体产生异常的姿势,进而表示发生了失衡或者跌倒。此外,欧拉角数据还可用于确定跌倒的类型(如向前跌倒、侧向跌倒或向后跌倒)。因此模型对欧拉角数据进行特征提取,可以获取人体的姿态信息,使得模型学习到人体正常行为状态的姿态变化信息和人体发生跌倒的姿态变化信息,使得模型相较于未加入欧拉角作为特征时更为灵敏和准确,降低误判和漏判的可能。

以本文模型为基础在 KFall 数据集上进行了欧拉角作为输入特征的消融实验,结果如图 6 所示。

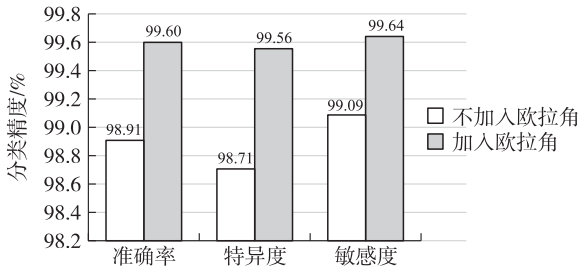

图 6 欧拉角作为输入特征的指标对比

从图 6 实验结果可以看出,加入欧拉角使模型的准确率从 98.91%增至 99.60%,特异度从 98.71%增至 99.56%,以及敏感度从 99.09%增至 99.64%。所以,加入欧拉角可提高模型跌倒的正确识别率和日常行为活动的正确识别率,使模型整体的准确率得到提高。实验证明了欧拉角作为特征输入可有效提升模型检测的能力,有助于及时发现跌倒事件。

3.3 结构重参数化对模型的影响

为验证结构重参数化对模型性能的影响,本文在 KFall 数据集上进行了针对结构重参数化策略的消融实验,实验结果如表 3 所示。从实验结果可以看到,在几乎不损失准确率的前提下,模型的参数量得到了 28.38%的减少,推理时间减少了 0.91 ms。模型尺寸从 1667 kB 减小至 1176 kB,减小了 29.45%。重参数化后的直铺单路结构使得模型推理速度提升,模型尺寸更小,更适合模型部署于可穿戴设备,更重要的是模型性能近乎不变。

表 3 重参数化对模型性能的影响

模型	Acc/%	Sp/%	Se/%	推理时间/ms	参数量/个
RFDNet(without Rep)	**99.61**	**99.78**	99.44	2.48	3 270
RFDNet(with Rep)	99.60	99.56	**99.64**	**1.57**	**2 342**

4 结语

本文针对老人跌倒检测模型,提出了一种基于结构重参数化的跌倒检测模型,兼顾精度、速度和轻量化的要求,使其能够部署于可穿戴嵌入式设备。首先,确定跌倒合加速度最大时作为中心点分别向前和

向后截取 1 s 的数据作为模型的输入数据。然后,构建多分支不同卷积核结构作为特征提取的核心骨干网络。其次,引入 Ghost 模块,使得模型轻量化程度更高。最后,使用结构重参数化,将模型的训练和测试区分开,在模型训练时通过多分支卷积核提取加速度、角速度和欧拉角的特征,在测试时,将多分支卷积结构等价转换为单路结构,在几乎不损失模型性能的前提下减少模型的计算量并提高推理速度。同时消融实验结果表明了结构重参数化策略和加入欧拉角作为模型输入对实现模型轻量化的有效性。

目前,采用离线方式在 PC 机上进行训练和测试跌倒检测模型,模型仍未能做到真正的单路结构,因此后续工作为找到更加适合单路结构的模型压缩方式,以及使用 TinyML 微型机器学习技术部署本模型于可穿戴跌倒检测终端中,并在终端中进一步测试模型性能。

致谢

感谢杭州唯灵医疗科技有限公司提供数据采集装置并提供部分跌倒实验数据。

参考文献:

[1] 张聪颖,耳玉亮,叶鹏鹏等. 2020 年中国老年人伤害死亡特征分析[J]. 中国健康教育,2022,38(11):968-972.

[2] 陶帅,常蒙月,汪祖民等. 基于可穿戴设备的跌倒检测方法研究进展[J]. 中国老年保健医学,2021,19(4):119-125.

[3] González Cañete F J,Casilari E. A Feasibility Study of the Use of Smartwatches in Wearable Fall Detection Systems [J]. Sensors,2021,21(6):2254.

[4] Yang Y, Yang H, Liu Z, et al. Fall Detection System Based on Infrared Array Sensor and Multi-Dimensional Feature Fusion[J]. Measurement,2022,192:110870.

[5] 杨海清,石珏. 基于姿态估计的静态图像跌倒检测方法[J]. 传感器与微系统,2020,39(10):132-134.

[6] 蔡敏雅,秦会斌. 老年人跌倒检测系统及其检测方法的研究进展[J]. 传感器与微系统,2024,43(2):7-11,16.

[7] 郭天宏,万蓬勃,石玉娇. 基于可穿戴压力传感器的跌倒检测研究综述[J]. 软件工程,2023,26(9):1-7.

[8] Chaccour K,Darazi R,Hassani A H E,et al. From Fall Detection to Fall Prevention:A Generic Classification of Fall-Related Systems[J]. IEEE Sensors Journal,2017,17(3):812-822.

[9] 刘鹏达,潘巨龙,左正魏,等. 基于惯性传感器的轻量化卷积神经网络跌倒检测算法[J]. 传感技术学报,2023,36(2):259-266.

[10] Waheed M,Afzal H,Mehmood K. NT-FDS:A Noise Tolerant Fall Detection System Using Deep Learning on Wearable Devices[J]. Sensors,2021,21(6):2006.

[11] Han K,Wang Y H,Tian Q,et al. GhostNet:More Features from Cheap Operations[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR),Seattle,WA,USA,IEEE,2020:1577-1586.

[12] Yu X Q,Jang J,Xiong S P. A Large-Scale Open Motion Dataset(KFall) and Benchmark Algorithms for Detecting Pre-impact Fall of the Elderly Using Wearable Inertial Sensors[J]. Frontiers in Aging Neuroscience,2021,13:692865.

[13] Sucerquia A,López J D,Vargas-Bonilla J F. SisFall:A Fall and Movement Dataset[J]. Sensors,2017,17(1):198.

[14] Ding X H,Zhang X Y,Ma N N,et al. RepVGG:Making VGG-style ConvNets Great Again[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR),Nashville,TN,USA,IEEE,2021:13733-13742.

[15] Liu S,Liu L,Tang J,et al. Edge Computing for Autonomous Driving:Opportunities and Challenges[J]. Proceedings of the IEEE,2019,107(8):1697-1716.

[16] Sanddler M,Howard A,Zhu M L,et al. MobileNetV2:Inverted Residuals and Linear Bottlenecks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition,Salt Lake City,UT,USA,IEEE,2018:4510-4520.

[17] Vaiyapuri T,Lydia E L,Sikkandar M Y,et al. Internet of Things and Deep Learning Enabled Elderly Fall Detection Model for Smart Homecare[J]. IEEE Access,2021,9:113879-113888.

[18] Chen G,Duan X H. Vision-Based Elderly Fall Detection Algorithm for Mobile Robot[C]//2021 IEEE 4th International Conference on Electronics Technology (ICET),Chengdu,China,IEEE,2021:1197-1202.

[19] García E,Villar M,Fáñez M,et al. Towards Effective Detection of Elderly Falls with CNN-LSTM Neural Networks [J]. Neurocomputing,2022,500:231-240.

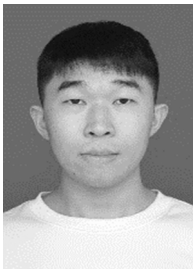

宋　炜(2000—),男,硕士研究生,研究方向为深度学习、跌倒检测,1013582184@qq.com;

潘巨龙(1965—),男,博士,教授,研究方向为物联网、智能计算和机器学习,pjl@cjlu.edu.cn。