

基于 LACNN 的 FMCW 雷达实时跌倒检测方法

罗彬¹ 常俊^{1,2} 孙江黎¹ 李栋¹

(1. 云南大学信息学院 昆明 650500; 2. 云南省高校物联网技术及应用重点实验室 昆明 650500)

摘要: 针对现有的雷达跌倒检测方法存在计算复杂度过高、参数量庞大的问题,本文提出了轻量级自适应卷积神经网络——LACNN。首先,从 FMCW 雷达采集到的人体活动回波信号中提取出微多普勒特征。其次,使用改进的轻量级 ShuffleNet 网络对特征进行初步提取。然后,使用轻量级通道-空间注意力模块与高效的不对称卷积核并行多尺度特征提取模块对特征进行精细化处理。为了提高模型的泛化能力,模型中嵌入了卷积批量归一化 AconC 模块。最后,融合的特征被送入全连接层进行检测。与其他网络模型的比较结果显示,所提出的模型 F1 分数达到了 99.33%,提高了 0.61%~4.10%,同时保持更低的计算成本,FLOPs 仅为 1.047 M,模型参数量仅为 69.09 M。

关键词: FMCW 雷达;实时跌倒检测;网络轻量化;LACNN 模型

中图分类号: TN959;TP391 **文献标识码:** A **国家标准学科分类代码:** 510.99

Real-time fall detection method for FMCW radar based on LACNN

Luo Bin¹ Chang Jun^{1,2} Sun Jiangli¹ Li Dong¹

(1. College of Information, Yunnan University, Kunming 650500, China;

2. University Key Laboratory of Internet of Things Technology and Application, Kunming 650500, China)

Abstract: Aiming at the problems of excessive computational complexity and large number of parameters in existing radar fall detection methods, this paper proposes a lightweight adaptive convolutional neural network, LACNN. Firstly, micro-Doppler features are extracted from the human activity echo signals acquired by the FMCW radar. Secondly, Initial extraction of features using an improved lightweight ShuffleNet network. Then, the features are refined using a lightweight channel-space attention module with an efficient asymmetric convolutional kernel parallel multi-scale feature extraction module. To improve the generalisation ability of the model, a convolutional batch normalization AconC module is embedded in the model. Finally, the fused features are fed into the fully connected layer for detection. Comparison results with other network models show that the proposed model achieves an F1 score of 99.33%, which is an improvement of 0.61%~4.10%, while maintaining a lower computational cost, with FLOPs of only 1.047 M and model parametric quantities of only 69.09 M.

Keywords: FMCW radar; real-time fall detection; network lightweight; LACNN model

0 引言

随着医疗保健进步,人类平均寿命增加导致老年人口上升,老年人跌倒风险随之增加,成为严重的健康问题^[1]。为此,开发高效可靠的跌倒检测系统已成为全球电子技术和智能化测量研究领域的重要课题^[2-3]。这一技术的发展,旨在为老年人提供更加安全的生活保障,降低跌倒带来的健康风险^[4-5]。

雷达技术能够在不接触用户身体和不受环境影响的情况下,捕获目标的距离和速度信息,且无需成像或记录声音,从而最大程度地保护用户隐私。因此,雷达技术在跌倒检测领域展现出独特的优势和应用潜力^[6]。研究者在开

发基于雷达的人体跌倒检测系统时,探讨了两种不同的方案:传统机器学习和深度学习。Tewari 等^[7]利用支持向量机(support vector machine, SVM)、随机森林(random forest, RF)等,设计了分级的跌倒检测系统。Hanifi 等^[8]利用巴氏距离(bhattacharyya distance, BD)等特征评估方法,并结合运用经典的 K 近邻算法(k-nearest neighbor, KNN)与线性判别分析(linear discriminant analysis, LDA)技术,构建了一套跌倒事件检测的分类模型。Shah 等^[9]使用了主成分分析(principal component analysis, PCA)技术提取核心特征信息,然后运用了 SVM 等算法对人类行为进行分类。然而,传统机器学习技术的性能在极大程度上

依赖于手工特征工程,这通常要求深厚的专业知识^[10]。相比之下,深度学习技术通过自动特征学习机制,能够有效缓解上述传统机器学习面临的挑战与限制^[11]。He 等^[12]提出了一种基于通道-空间注意力模块的二维卷积神经网络(2-dimensional convolutional neural network with channel and spatial attention module, 2DCNN-CBAM)的雷达多域表示跌倒检测方法。Yang 等^[13]利用双雷达数据融合策略以汇总两者的微多普勒特征并输入至卷积神经网络。郭夏迪等^[14]使用雷达和摄像头双模态数据,通过双模态门控特征融合网络(bi-modal gated feature fusion network, BMGFFN)进行跌倒检测。Niu 等^[15]结合迁移学习(transfer learning, TL)策略,利用改进的残差网络(residual network, ResNet)进行跌倒检测。元志安等^[16]构建了一种结合卷积神经网络与长短期记忆网络的混合架构,提取跌倒动作的时间序列特征并执行事件分类。

然而,这些采用深度学习算法设计的跌倒检测系统,普遍未充分考虑模型的大参数量和高计算复杂度对实时跌倒检测应用带来的严重阻碍。具体而言,雷达终端设备的内存和计算资源有限,导致具有大规模参数和计算需求的深度学习网络难以在这些设备上实现部署。此外,在实时跌倒检测场景中,系统需迅速分析传感器数据并作出准确判断,计算高需求的网络会阻碍数据的实时分析与决策,任何处理延迟都可能导致错过最佳救援时间,从而引发严重后果。同时,大参数量和高计算复杂度的模型在推理过程中将产生高能耗的问题,这不利于跌倒检测系统的高效设计。

为了解决上述问题,本研究创造性地设计了一个专用于实时跌倒检测的轻量级自适应卷积神经网络(lightweight adaptive convolutional neural network, LACNN),该模型具有高计算效率、低参数量的特点。模型的性能评估依托于格拉斯哥大学于 2019 年公布的权威人类活动数据集进行。

1 雷达信号处理

本文之前的工作^[15]清楚地说明了数据预处理的方式与微多普勒时间图(doppler-time-map, DTM),这里简单介绍一下。为了便于数据处理,首先从雷达采集到的原始回波数据集中提取出记录人体活动的的数据,并将其重排。接着对回波数据矩阵执行距离傅里叶变换(fast Fourier transform, FFT),得到时间与距离的关系。然后对数据应用动目标指示技术(moving target indication, MTI),以增强人体的动态特征,同时抑制静态杂波。由于被测目标与雷达之间的距离大致在 10~30 距离单位的范围内。因此,选择该距离范围内的样本值进行短时傅里叶变换(short time Fourier transform, STFT)以获得 DTM。该变换过程的表示如式(1)所示。

$$\mathbf{R}_{STFT}(\mathbf{f}, \mathbf{k}) = \left| \sum_{n=1}^L \omega_n \mathbf{R}_{FFT}(\mathbf{f}, \mathbf{n}) e^{-j2\pi k \frac{n}{L}} \right|^2 \quad (1)$$

式中: $\mathbf{R}_{STFT}(\mathbf{f}, \mathbf{k})$ 表示微多普勒谱图特征矩阵, ω_n 为海明

窗函数, L 为窗长。最终得到 6 类行为的 DTM,如图 1 所示。DTM 揭示了跌倒瞬间的人体姿态失衡与速度突变,其在跌倒检测应用中的潜力不言而喻。

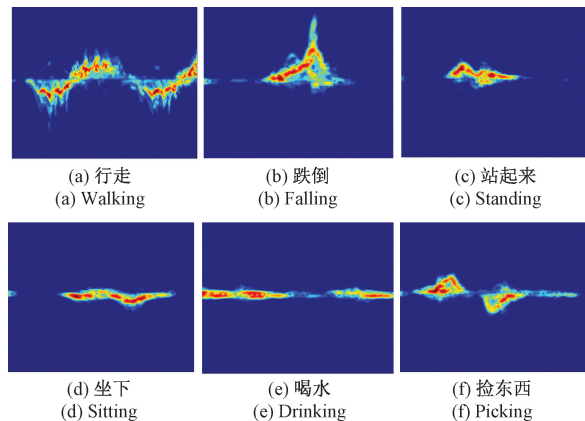


图 1 不同行为的 DTM 示意图

Fig. 1 Schematic diagram of DTM with different behaviors

2 提出的方法

2.1 整体架构

本文提出的 LACNN 网络模型集成了 3 个关键组件:特征提取层、特征优化层和决策层,如图 2 所示。在特征提取阶段,采用高效的网络架构 ShuffleNet 对 DTM 进行初步的特征提取。接着,特征优化层通过联合使用通道-空间注意力(channel-spatial attention, CSA)模块和不对称卷积核并行多尺度特征提取(asymmetric convolution kernel-parallel multiscale feature extraction, ACK-PMFE)模块,对初步提取的特征进行精细化处理。处理后的特征传递至决策层,其中全局平均池化(global average pooling, GAP)用于特征汇总,Flatten 操作将特征矩阵展平为一维特征向量。最终,全连接层将展平后的特征向量映射到长度为 2 的输出向量,每个维度对应一个类别的预测概率,从而实现了输入数据所属类别的精确判别。

2.2 改进的 ShuffleNet

雷达系统在计算能力和存储空间方面的局限性,实现实时跌倒检测需要依赖于一个轻量级的网络模型。由于 DTM 在同一维度内具有显著的相关性,传统的卷积与池化操作在提取局部特征时,会导致高度相关的特征分散到不同的通道中,而这种通道间的信息隔离会影响到跌倒检测的准确性。

为了解决上述问题,本文构建了两种瓶颈结构——基本单元(basic unit, BU)和空间下采样单元(spatial down sampling unit, SDSU),分别如图 3(a)和(b)所示。通道分割(channel split)方法用于优化通道数量和网络结构,减少了模型的计算负担;通道重组(channel shuffle)方法用于重新排列不同组的通道,促进了不同通道组之间的信息交互。最终,本文改进的 ShuffleNet^[17]模型




图 2 LACNN 网络模型

Fig. 2 LACNN network model




图 3 瓶颈结构示意图

Fig. 3 Schematic diagram of bottleneck structure

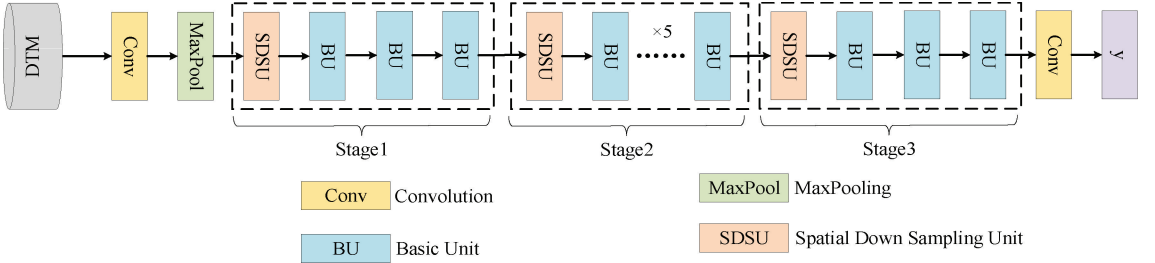


图 4 改进的 ShuffleNet 模型结构图

Fig. 4 Structure of the improved ShuffleNet model

因此, AconC 凭借动态自适应机制, 能够针对样本的特性进行灵活调整, 从而提升了模型在多样性跌倒场景下的泛化能力。此外, 该机制通过稳定梯度流, 减少了训练时间和计算成本, 为雷达驱动的实时跌倒检测提供了一种实用的方法。

2.4 CSA 注意力模块

在跌倒检测的应用场景下, 关键挑战在于精准捕捉跌倒瞬间的加速度剧变与姿势失衡特征。针对此类任务, 空间与时间的捕获缺一不可^[18]。因此, 本研究在模型架构中

如图 4 所示, 通过该模型促进具有相关性的特征在不同通道间进行交互, 并维持模型的轻量化。

2.3 卷积批量归一化 AconC 模块

在跌倒检测领域, 环境多样性与个体体型差异显著增加了 DTM 图像的变异性。传统 ReLU 激活函数在处理此类高度异质性数据时暴露出局限性, 易导致梯度消失, 限制了模型对多样化特征的有效学习。鉴于此, 本文提出具备自适应特性的 AconC 激活函数, 并设计了 CBA 模块(如图 5(b) 所示), 作为对现有 CBR (convolutional batch normalization relu) 模块(如图 5(a) 所示)的升级方案。AconC 的计算如式(2)所示。

$$f_{AconC}(x) = (p_1 - p_2)x \cdot \sigma[\beta(p_1 - p_2)x] + p_2x \quad (2)$$

式中: β, p_1, p_2 是通用的参数, 决定着 Acon 开关的激活状态。这是因为关键的开关因子 β 直接影响着这一过程的非线性特征, 如式(3)所示。

$$\begin{aligned} \beta \rightarrow \infty, f_{AconC}(x) &\rightarrow \max[p_1x, p_2x] \\ \beta \rightarrow 0, f_{AconC}(x) &\rightarrow \text{mean}[p_1x, p_2x] \end{aligned} \quad (3)$$

融合了通道-空间注意力模块, 旨在动态增强与跌倒直接关联的时空特征, 优化模型对关键信息的关注度。本文设计的通道注意力(channel attention, CA)模块与空间注意力(spatial attention, SA)分别如图 6、7 所示。

CA 与 CS 模块的构建结合了平均池化与最大池化两种策略, 以实现特征的互补, 其计算如式(4)所示。

$$\begin{aligned} M_c(F) &= \sigma(W_2(W_1(F_{Avg}^c)) + W_2(W_1(F_{Max}^c))) \\ M_s(F) &= \sigma(f^{7 \times 7}[F_{Avg}^s; F_{Max}^s]) \end{aligned} \quad (4)$$

式中: σ 代表 Sigmoid 激活函数, $f^{7 \times 7}$ 代表 7×7 的卷积操




图 5 CBR 模块与 CBA 模块的网络结构图

Fig. 5 Network structure diagram of CBR module and CBA module




图 6 CA 模块的网络结构图

Fig. 6 Network structure diagram of CA module




图 7 CS 模块的网络结构图

Fig. 7 Network structure diagram of CS modul

作, $W_1 \in \mathbb{R}^{c \times c}$, $W_2 \in \mathbb{R}^{c \times \frac{c}{r}}$, $r = 16$ 。

给定空间特征矩阵图 $F \in \mathbb{R}^{C \times H \times W}$ 作为输入, CSA 模块依次推断出 1D 通道注意力 $M_c \in \mathbb{R}^{C \times 1 \times 1}$ 和 2D 空间注意力 $M_s \in \mathbb{R}^{1 \times H \times W}$, 整体注意力过程的概况如式(5)所示, 其网络结构如图 8 所示。

$$\begin{aligned} F' &= M_c(F) \otimes F \\ F'' &= M_s(F') \otimes F \end{aligned} \quad (5)$$

式中: \otimes 表示逐元素乘法, F'' 是最终的精化输出。




图 8 CSA 模块的网络结构图

Fig. 8 Network structure diagram of CSA module

2.5 ACK-PMFE 模块

为了让模型能够同步驾驭行为特征的空间细节异质性与时间动态性,本研究创新性地设计了不对称卷积核并行多尺度特征提取模块,如图 9 所示。该模块通过运用多种尺寸的非对称卷积核,能够高效捕获动态行为的姿态演

进及速度变化趋势。并行多尺度特征提取的机制,则赋能模型跨层级整合信息,助力模型同步捕获全局与局部特征细节。这一设计紧密贴合 DTM 行为特征的高度相关特性。




图 9 ACK-PMFE 的网络结构图

Fig. 9 Network structure diagram of ACK-PMFE

ACK-PMFE 模块由 3 个并行分支组成,每个分支的初始层均采用 1×1 卷积核,与第 1 个分支相比,第 2 个分支增加了两个额外的 1×3 和 3×1 卷积核,而第 3 个分支则增加了 1×5 和 5×1 卷积核。最终,这 3 个分支的特征在通道维度上被拼接在一起,并通过一个 3×3 卷积层生成一个更为全面的特征图。ACK-PMFE 模块的数学描述如式(6)所示。

$$y = \text{Conv}_{3 \times 3}(\text{Cat}(f_1, f_2, f_3)) \quad (6)$$

式中: f_i 表示第 i 个分支提取到的特征, $\text{Cat}(\cdot)$ 表示拼接操作, $\text{Conv}_{3 \times 3}$ 表示卷积核大小为 3×3 的卷积操作, y 是经 ACK-PMFE 模块提取到的特征。

2.6 损失函数

在处理类别不平衡的数据集时,传统的交叉熵损失函数往往导致模型偏向于数量较多的负样本,而忽略了数量较少但更重要的正样本。针对这一问题,本文提出使用 Focal Loss 损失函数来训练网络,其在交叉熵损失的基础上引入两个关键参数: α (正负样本平衡系数)和 γ (聚焦参数)。其中 α 用于调整正负样本的相对重要性,它能够降低负样本的权重,从而使模型更加关注正样本的学习; γ 则用于减少易分类样本的损失贡献,它能够降低模型对易分类样本的关注程度,使模型更加关注难分类的样本。Focal

Loss 表达式如式(7)所示。

$$FL(p,y,\alpha,\gamma)=\begin{cases}-\alpha(1-p)^\gamma\ln(p),y=1\\-(1-\alpha)p^\gamma\ln(1-p),y=0\end{cases}\quad(7)$$

式中: y 表示预测的样本类别, p 表示预测正样本的概率。在本文中, $\alpha=0.25,\gamma=2$ 。

3 实 验

3.1 数据集与实验环境

本研究的实验环境如表 1 所示。用于实验的数据集由 7 个子数据集构成,这些子数据集在不同时间点、8 种不同环境下采集^[19]。参与数据采集的志愿者共 72 名,年龄分布在 21~98 岁,涵盖不同的身高和体重,以确保数据集的泛化能力。数据集内的非跌倒活动为图 1 所示的行走、站起来、坐下、喝水和捡东西。为了提高评价结果的置信度,本研究采用了数据增强技术对数据集进行了一定扩充,具体包括图像翻转、图像平移方法,最终得到 2 952 张图像。以图 1 展示的 DTM 为例,其扩充后的示例如图 10

所示。同时,为了保证跌倒事件在时间维度上的稀疏性,数据集中跌倒与非跌倒活动的数量比例约为 1:7。本文将整个数据集按照 7:3 的比例划分为训练集和测试集,以便进行后续模型训练与评估。

表 1 实验环境参数表

Table 1 Parameters of the experimental environment	
环境与参数	具体信息
GPU	NVIDIA GeForce RTX 2080Ti
OS	Linux
Python	3.9.6
Pytorch	2.1.0
Learning rate	0.001
Epoch	100
Batch size	64
Optimizer	Adam
Input image pixels	224×224

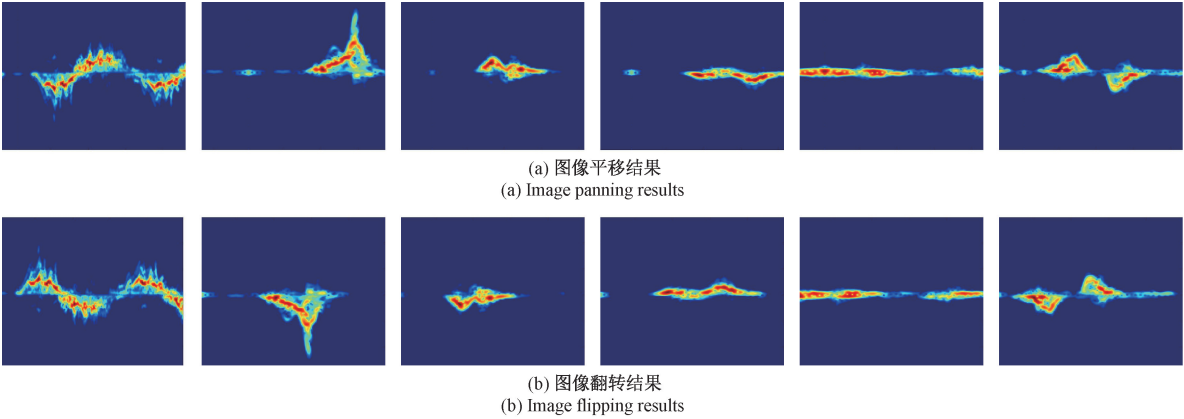


图 10 扩充的 DTM 示意图

Fig. 10 Schematic diagram of the expanded DTM

3.2 性能指标

本研究采用多个性能指标,包括准确率(Accuracy、A)、精确率(precision、P)、F1 分数(F1 score、F1)以及召回率(recall、R),以对所提出网络模型的跌倒检测能力进行全面且深入的评估。这些度量标准的计算方法如式(8)所示。此外,为了衡量网络模型的轻量化程度,本文采纳了两个重要指标:浮点运算次数(floating point of operations, FLOPs)和模型参数量(parameters)。

$$\begin{aligned}A&=\frac{TP+TN}{TP+TN+FP+FN}\\P&=\frac{TP}{TP+FP}\\R&=\frac{TP}{TP+FN}\\F1&=\frac{2\times P\times R}{P+R}\end{aligned}\quad(8)$$

式中:TP(true positive)表示成功检测到的跌倒行为;FP(false positive)表示错误检测到的非跌倒行为;TN(true negative)表示成功检测到的非跌倒行为;FN(false negative)表示错误检测到的跌倒行为。

3.3 模型评估

如图 11 所示,模型在训练过程中损失值随训练轮次增加而逐渐下降,这表明随着模型的训练深入,其性能得到了提升,并变的更加稳定。如图 12 所示,在训练过程中,模型的准确率(每 10 个 epoch 计算一次)尽管存在轻微波动,但整体保持在较高水平。

可视化的检测结果如图 13 所示,可知该模型能够较好地检测出跌倒与非跌倒行为。

同时,绘制的混淆矩阵如图 14 所示。其中,第 2 行第 1 列的数据表明模型的虚警率为 0.64%,而第 1 行第 2 列的数据则表明模型的漏警率为 1.87%。因此,该模型具备较高的准确率、较低的误报率。




图 11 模型训练的 loss 曲线
Fig. 11 Loss curves for model training




图 12 模型的准确率变化曲线
Fig. 12 Accuracy variation curve of the model




图 13 检测结果示意图
Fig. 13 Schematic diagram of test results




图 14 混淆矩阵
Fig. 14 Confusion matrix

为了进一步验证本文所提出模型的优越性,将其与残差网络 ResNet18^[20]、ResNet34^[20], 轻量级网络 MobileNetV3_small^[21]、MobileNetV3_large^[21]、其他跌倒检测网络(LWCNN^[22]、RNCK-SENet^[15])进行了对比,对比结果如表 2 所示。研究结果表明,本文提出的模型在多数评价指标上相较于其他模型展现了更优的性能。具体来说,尽管在 FLOPs 方面,本文模型较 MobileNetV3_small 增加了 0.006 G,但在检测精度上,平均提升了 4.655%。同样地,尽管在 Parameters 方面,本文模型比 LWCNN 多出了 0.833 M,但在检测精度上,平均增加了 3.53%。这些数据表明,本文模型在维持较高计算效率的同时,实现了更佳的分类型性能,从而在效率和准确性之间达到了更优的平衡。

表 2 不同网络模型对比结果表

Table 2 Comparison results of different network models

模型	A	P	R	F1	FLOPs/G	Para/M
ResNet18	0.959 0	0.963 4	0.986 4	0.974 7	1.824	11.178
ResNet34	0.976 9	0.978 4	0.996 7	0.987 2	3.678	21.286
MobileNetV3_small	0.917 3	0.916 5	0.995 9	0.952 3	0.063	1.520
MobileNetV3_large	0.926 6	0.923 4	0.999 2	0.957 8	0.233	4.205
LWCNN	0.940 8	0.959 0	0.965 3	0.961 9	0.220	0.214
RNCK-SENet	0.956 5	0.967 2	0.986 8	0.976 1	1.854	12.083
本文	0.988 2	0.989 7	0.997 0	0.993 3	0.069	1.047

3.4 评估 CBA 模块的对照实验

为系统性探究 CBA 模块在优化模型性能上的潜在贡献,

本文设置了 CBA 与 CBR 模块的对比实验,结果如表 3 所示。研究结果表明,CBA 模块的应用在维持模型 Parameters 与

表 3 CBA 模块与 CBR 模块对比结果表

Table 3 Comparison of results between CBA and CBR

模型	A	P	R	F1	FLOPs/M	Para/M
LACNN-CBR	0.978 5	0.991 3	0.980 7	0.986 0	69.09	1.047
LACNN-CBA	0.988 2	0.989 7	0.997 0	0.993 3	69.09	1.047

FLOPs 不变的情况下,显著提升了模型的各项评价指标,具体来说,A、R、F1 值分别提高了 0.97%、1.63%、0.73%。这一结果强有力地支持了 AconC 自适应激活机制在跌倒检测任务中的有效性论断。鉴于此,后续研究内容均基于 CBA 模块的框架设定展开。

3.5 消融研究

为了验证所提出模块的有效性,本文以改进的 ShuffleNet 作为基准网络(记为模型 A),设计了一系列消

融实验,结果如表 4 所示。

本文将 CSA 模块集成至基准网络中以构建模型 B。结果显示,模型 B 的 A、P、R 以及 F1 值均优于模型 A,这充分证明了 CSA 模块在提升模型性能方面的有效性。

本文将 ACK-PMFE 模块集成至基准网络中以构建模型 C。结果显示,模型 C 的 A、P、R 以及 F1 值均优于模型 A,这表明 ACK-PMFE 模块对于提升模型性能同样具有显著效果。

表 4 消融研究结果表

Table 4 Ablation study results

模型	Base Line	CSA	ACK-PMFE	A	P	R	F1
A	✓			0.929 7	0.966 6	0.959 0	0.959 0
B	✓	✓		0.980 3	0.986 0	0.997 4	0.988 9
C	✓		✓	0.981 0	0.985 5	0.993 0	0.988 9
D	✓	✓	✓	0.988 2	0.989 7	0.997 0	0.993 3

本文将 CSA 和 ACK-PMFE 两个模块同时添加到基准网络中以构建模型 D。结果显示,模型 D 的 A、P 以及 F1 值均优于其他模型,这充分证明了本文所提出的模块组合在提升模型性能方面的优势。

3.6 卷积核对称性对比研究

为了全面评估本文提出的 ACK-PMFE 模块在模型性能提升、参数经济性以及计算效率方面的优势,本研究设计了一个对称性卷积核并行多尺度特征提取(symmetric convolution kernel-parallel multi-Scale feature extraction, SCK-PMFE)模块作为对照实验,如图 15 所示。




图 15 SCK-PMFE 的网络结构图

Fig. 15 Network structure diagram of SCK-PMFE

对比结果如表 5 所示,总体来看,ACK-PMFE 在提升模型性能方面的效果更为显著。同时,较 SCK-PMFE,

表 5 卷积核对称性对比结果表

Table 5 Comparison results of symmetry

模型	A	P	R	F1	FLOPs/M	Para/M
A	0.9297	0.966 6	0.959 0	0.959 0	38.63	0.243
A+SCK-PMFE	0.970 6	0.989 6	0.976 9	0.983 2	93.05	2.983
A+ACK-PMFE	0.988 2	0.989 7	0.997 0	0.993 3	68.98	1.014

ACK-PMFE 的 Parameters 和 FLOPs 分别减少了 1.969 M 和 24.07 M。这一结果充分证实了非对称卷积核设计在降低模型复杂度、计算成本以及提升网络性能方面的有效性和优越性。

4 结 论

本研究针对老年人跌倒检测问题,提出了轻量级自适

应卷积神经网络(LACNN)模型,取得了显著成果。LACNN 在轻量级 ShuffleNet 基础上,创新性地融合了通道-空间注意力模块、非对称卷积核并行多尺度特征提取模块以及卷积批量归一化 AconC 模块,实现了在保证模型轻量化的同时,显著提升跌倒检测性能。实验结果表明,LACNN 在准确率、精确度、召回率、F1 分数等指标上均优于 ResNet、MobileNetV3 等经典网络以及 LWCNN、

RNCK-SENet 等跌倒检测专用网络, FLOPs 和模型参数量也保持在较低水平, 展现出在实时跌倒检测领域的巨大潜力。非对称卷积核设计、AconC 激活函数以及模块组合的有效性均得到了验证, 证明了这些创新点对提升模型性能的重要性。然而, 本文的不足之处在于数据集无法涵盖日常生活中变化复杂的跌倒动作, 模型的泛化能力有待进一步提升。未来研究将重点探索以下方向: 扩充数据集规模 and 多样性, 提高模型的泛化能力; 优化模型架构, 进一步降低计算复杂度和参数量。

参考文献

- [1] 仲济磊, 黄震宇, 陈珍萍, 等. 多场景下的人体跌倒检测方法及应用[J]. 电子测量技术, 2022, 45(20): 21-28.
ZHONG J L, HUANG ZH Y, CHEN ZH P, et al. Detection method and application of human fall in multiple scenarios [J]. Electronic Measurement Technology, 2022, 45(20): 21-28.
- [2] 王新, 杨秀梅. 基于 YOLOv5s 和改进质心跟踪的人员跌倒检测[J]. 电子测量技术, 2023, 46(24): 172-178.
WANG X, YANG X M. Personnel fall detection based on YOLOv5s and improved centroid tracking[J]. Electronic Measurement Technology, 2023, 46(24): 172-178.
- [3] 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.
CAI M Y, QIN H B. Research progress of elderly fall detection systems and its detection methods [J]. Transducer Microsystem Technologies, 2024, 43(2): 7-11.
- [4] 杜群贵, 钟威. 轻量级 CNN 实时跌倒预测及嵌入式系统实现[J]. 电子测量技术, 2022, 45(11): 10-15.
DU Q G, ZHONG W. Lightweight CNN real-time fall prediction and embedded system implementation[J]. Electronic Measurement Technology, 2023, 45(11): 10-15.
- [5] 方震, 陈贤祥, 简璞, 等. 基于 FMCW 雷达的非接触式医疗健康监测技术综述[J]. 雷达学报, 2022, 11(3): 499-516.
FANG ZH, CHEN X X, JIAN P, et al. Review of noncontact medical and health monitoring technologies based on FMCW radar[J]. Journal of Radars, 2022, 11(3): 499-516.
- [6] 周杨, 李剑鹏, 王知雨, 等. 基于 4D 点云和航迹信息的人员跌倒检测方法[J]. 电子技术应用, 2024, 50(1): 120-124.
ZHOU Y, LI J P, WANG ZH Y, et al. Human fall detection method based on 4D point cloud and track information[J]. Application of Electronic Technique, 2024, 50(1): 120-124.
- [7] TEWARI R C, SHARMA S, ROURAY A, et al. Effective fall detection and post-fall breath rate tracking using a low-cost CW Doppler radar sensor [J]. Computers in Biology and Medicine, 2023, 164: 107315.
- [8] HANIFI K, KARSLIGIL M E. Elderly fall detection with vital signs monitoring using CW Doppler radar[J]. IEEE Sensors Journal, 2021, 21(15): 16969-16978.
- [9] SHAH S A, AHMAD J, MASOOD F, et al. Privacy-preserving wandering behaviour sensing in dementia patients using modified logistic and dynamic Newton Leipsnik maps [J]. IEEE Sensors Journal, 2021, 21(3): 3669-3679.
- [10] KIM Y, MOON T. Human detection and activity classification based on micro-Doppler signatures using deep convolutional neural networks [J]. IEEE Geoscience & Remote Sensing Letters, 2016, 13(1): 8-12.
- [11] LUO F, POSLAD S, BODANESE E. Human activity detection and coarse localization outdoors using micro-Doppler signatures[J]. IEEE Sensors Journal, 2019, 19(18): 8079-8094.
- [12] HE J, REN ZH T, ZHANG W Q, et al. Fall detection based on parallel 2DCNN-CBAM with radar multidomain representations [J]. IEEE Sensors Journal, 2023, 23(6): 6085-6098.
- [13] YANG T, MENG F, XU Q, et al. Fall feature enhancement and fusion using the stockwell transform with dual mmWave radars[J]. IEEE Sensors Journal, 2023, 23(2): 1368-1376.
- [14] 郭夏迪, 曹炳尧. 基于双模态门控特征融合的跌倒检测方法[J]. 计算机测量与控制, 2024, 32(10): 69-76.
GUO X D, CAO B Y. Falling detection method based on bi-modal gated feature fusion [J]. Computer Measurement & Control, 2024, 32(10): 69-76.
- [15] NIU J H, CHANG J, WANG Y H, et al. FMCW radar fall detection based on parallel multi-scale feature extraction[C]. 2023 9th International Conference on Computer and Communications (ICCC), 2023.
- [16] 元志安, 周笑宇, 刘心溥, 等. 基于 RDSNet 的毫米波雷达人体跌倒检测方法[J]. 雷达学报, 2021, 10(4): 656-664.
YUAN ZH AN, ZHOU X Y, LIU X P, et al. Human fall detection method using millimeter-wave radar based on RDSNet[J]. Journal of Radars, 2021, 10(4): 656-664.
- [17] MA N N, ZHANG X Y, ZHENG H T, et al. ShuffleNet V2: Practical guidelines for efficient CNN architecture design[C]. 2018 European Conference on

- Computer Vision(ECCV), 2018.
- [18] 周璇,易剑平. 基于优化 CBAM 改进 ResNet50 的异常行为识别方法[J]. 国外电子测量技术, 2024, 43(5): 36-41.
- ZHOU X, YI J P. Improved abnormal behavior recognition method of ResNet50 based on optimized CBAM [J]. Foreign Electronic Measurement Technology, 2024, 43(5): 36-41.
- [19] VICTORIA H A, MARAGATHAM G. Activity recognition of FMCW radar human signatures using tower convolutional neural networks [J]. Wireless Networks, 2021, DOI:10.1007/s11276-021-02670-7.
- [20] HE K M, ZHANG X Y, REN SH Q, et al. Deep residual learning for image recognition[C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition(CVPR), 2016.
- [21] HOWARD A, SANDLER M, CHEN B, et al. Searching for MobileNetV3 [C]. 2019 IEEE/CVF International Conference on Computer Vision(ICCV), 2019.
- [22] ZHENG P F, ZHANG AN X, CHEN J ZH, et al. Real-time fall recognition using a lightweight convolution neural network based on millimeter-wave radar [J]. IEEE Sensors Journal, 2024, 24(5): 7185-7195.

作者简介

罗彬, 本科生, 主要研究方向为雷达信号处理与跌倒检测。

E-mail: 1251992517@qq.com

常俊(通信作者), 副教授, 主要研究方向为无线通信信号处理与软件无线电、智能无线定位与感知等。

E-mail: changjun@ynu.edu.cn

孙江黎, 本科生, 主要研究方向为雷达信号处理与跌倒检测。

E-mail: sunjiangli@stu.ynu.edu.cn

李栋, 硕士研究生, 主要研究方向为毫米波雷达步态识别。

E-mail: lidong_op5t@stu.ynu.edu.cn