

基于 BlazePose 和随机森林算法的 异常步态检测

黄灶荣¹, 王春宝^{1,2†}, 韦建军¹, 余学书¹, 谭啸海¹

(1. 广西科技大学, 广西 柳州 545616; 2. 广东铭凯医疗机器人有限公司, 广东 珠海 519075)

摘要:异常步态对行动能力产生严重影响,因此,及时、自动地检测异常步态具有至关重要的意义。本文提出了一种基于 BlazePose 和随机森林算法的人体异常步态检测方法。先利用 BlazePose 算法提取 RGB 视频中的人体骨骼关键点,然后通过数据处理获取 7 个关键的步态特征参数。最后采用随机森林算法作为步态分类器,用于区分正常步态与异常步态。利用 142 例异常步态数据和 257 例正常步态数据对分类器进行训练和测试评估,实验结果显示准确率和召回率分别达到 97.5% 和 90%,表明该方法在异常步态检测方面具备一定的可行性和实用价值。

关键词:BlazePose; 随机森林; 异常步态检测; 数据处理

中图分类号:TP391.4

文献标识码:A

Abnormal Gait Detection Based on BlazePose and Random Forest

HUANG Zaorong¹, WANG Chunbao^{1,2†}, WEI Jianjun¹, YU Xueshu¹, TAN Xiaohai¹

(1. Guangxi University of Science and Technology, Liuzhou, Guangxi 545616 China;

2. Guangdong Mingkai Medical Robot Co., Ltd., Zhuhai, Guangdong 519075, China)

Abstract: Abnormal gait significantly affects mobility, making timely and automatic detection of abnormal gait critically important. This study proposes a human abnormal gait detection method based on BlazePose and the random forest algorithm. Firstly, the BlazePose algorithm is utilized to extract skeletal keypoints of the human body from RGB videos. Next, seven key gait feature parameters are obtained through data processing. Finally, the random forest algorithm is employed as the gait classifier to differentiate between normal and abnormal gaits. The classifier is trained and evaluated using 142 cases of abnormal gait data and 257 cases of normal gait data. Experimental results show an accuracy of 97.5% and a recall rate of 90%, indicating that the proposed method exhibits certain feasibility and practical value in the field of abnormal gait detection.

Key words: BlazePose; random forest; abnormal gait detection; data processing

随着社会的不断发展,人们对健康和生活质量的关注度日益增加。然而,许多人由于年龄、疾病、受伤等原因可能出现异常步态,尤其是老年人。异常步态往往暗示着身体机能下降或存在某些病症,如步态速度降低可能是认知能力下降的前兆^[1],异

常步态与脑血管疾病严重程度相关^[2]等。因此,及时、自动地检测人体异常步态并进行进一步分析和诊断具有重要意义。

目前,步态检测根据检测设备主要分为接触式和非接触式两种。接触式方法利用可穿戴设备(如

惯性传感器 IMU、压力传感器、加速度计等)采集运动信号进行步态分析。例如,Vytautas 等人^[3]通过在鞋内安装压力传感器,分析足部压力以获取步速、步长、足部重量分布和步态阶段的时间等信息,从而检测异常步态,并实现了 94% 的准确率。然而,这种需要安装在鞋内的传感器方法在实际应用中存在不便。另外,东京工业大学的一项研究^[4]表明将 IMU 绑在小腿上进行步态估计可以准确反映多个空间步态参数,如步幅和步速等。但接触式方法需要将设备固定在测试者身上,这增加了医务人员的负担,也可能限制患者的行动能力。相比之下,利用摄像头等非接触式设备可以避免这些问题。摄像头主要分为带深度信息的 RGBD 摄像头、普通高清 RGB 摄像头和手机摄像头,这三类摄像头在异常步态检测研究中都有涉及。例如,Anthony 等人^[5]研究了 Kinect 摄像头在异常步态检测中的应用,结果显示识别成功率约为 87%,这个结果在临床环境中用于诊断与步态和姿势障碍相关的疾病是可接受的。Wang 等人^[6]通过在机器人上安装低成本的 RGB 摄像头,使用基于视觉的人体姿态估计方法设计了一种新型的无标记步态分析设备,主要步态参数包括内翻/外翻和背屈/趾屈。实验表明,与基于深度相机或多相机运动捕捉

系统的方法相比,使用单个 RGB 相机的方法以较小的硬件成本实现了具有竞争力的性能。Aditya 等人^[7]通过智能手机摄像头创建了基于 OpenPose 的无标记步态分析系统(OMGait),使用 OMGait 测量了人体在不同照明和服装条件下的踝关节、膝关节和髌关节的屈伸角度。结果显示,该系统足以测量脚踝、膝盖和臀部的运动值,并且比 Kinect 系统表现更好。可见,随着技术的发展,普通摄像头甚至手机摄像头在异常步态检测方面具有良好的检测效果和成本优势。

本文采用普通摄像头的非接触式方法,提出了一种基于 BlazePose 的异常步态检测方法,在自然场景下实现实时监测,并进行了实验验证和分析。具体而言,本文利用 BlazePose 算法提取人体骨骼关键点,并提取步态参数,使用随机森林算法作为分类器,对 SAIL-TUG 数据集进行训练和验证,最终实现异常步态的检测和分类。本文旨在证明该方法的有效性和实用性,并探讨未来研究的方向和应用前景。

整个步态检测系统的框架如图 1 所示,包括三个主要步骤:(1)人体骨骼关键点提取;(2)步态特征参数提取;(3)步态分类。




图 1 步态检测系统框架

1 相关工作

1.1 人体姿态估计在步态识别中的应用

人体姿态估计是计算机视觉领域的一个重要研究方向,并得到了广泛应用,包括动作识别、运动捕捉、增强现实以及步态识别检测等。然而,在步态识别中,人体姿态估计面临着诸多挑战,如人体姿态变化、噪声干扰以及实时性等问题。因此,将人体姿态估计应用于步态识别仍然是一个具有挑战性的任务。

早期的步态检测主要使用预定义的模型和统

计学方法来描述人体步态,但这些方法往往无法达到理想的效果^[8]。随着深度学习技术的发展,各种算法相继被提出并得到应用发展,比如 DeepPose、CPM、SHN、OpenPose 等^[9]。这些方法都采用了相似的流程:首先通过多层卷积和池化操作提取输入图像的特征信息,然后通过一个或多个后续的回归器或分类器预测人体关键点的位置或姿态。然而,这些算法通常需要大量的计算资源,并对硬件有较高的要求。

在 2020 年,谷歌公司提出了一种名为 BlazePose 的人体姿态估计神经网络架构^[10],BlazePose 融合了热图技术和回归关键点技术,具有出色的性

能。该方法在中端手机 CPU 上的速度比 20 核电脑 CPU 上的 OpenPose 快 25~75 倍,同时提供了更多的关键点数量(达到 33 个)。尽管 BlazePose 在人体姿态估计领域取得了显著的进展,但目前在步态识别领域的应用研究很少。2022 年 Liu 等人^[11]提出了一种基于 BlazePose 和 LSTM(long short term memory)的船员跌倒检测方法。该方法通过 BlazePose 提取人体关键点信息,并使用 LSTM 对相关特征进行分析。实验证明,该算法检测海员跌倒行为的准确率达到了 100%,在 CPU 上的检测帧率可达 29 fps,满足实时检测需求。然而,与这项工作不同的是,我们研究的是异常步态检测问题,需要提取更多的关键点信息,并计算步态特征。基于此方法在硬件成本及识别精度与速度上的优势,本文选择使用 BlazePose 算法进行人体骨骼关键点提取工作。

1.2 基于摄像头的异常步态检测

基于摄像头的异常步态检测是一种非侵入式的方法,通过从视频中提取步态参数并使用分类器进行判断,可以识别异常步态。早在 2006 年,Stebbins 等人^[12]就开始研究利用摄像头系统(Vicon)进行异常步态的视觉识别,并使用软件进行自动评估异常情况。研究结果表明,这种方法在临床上有助于解释步态报告的一致性,并产生更一致的治疗建议。

在传统的人工步态评估中,医生和治疗师通常综合考虑多种步态特征和标准,以确定是否存在异常步态。然而,由于缺乏统一的步态特征参数标准来衡量异常步态,使评估结果具有不一致性。步态特征参数分为动力学、运动学和时空参数三种^[13]。基于摄像头的步态检测主要使用运动学和时空参数。例如,Nguyen 等人^[14]提出了一种基于正常步态模型检测异常步态的方法,从骨骼信息中提取了 7 个步态运动学参数,如左髋角、右髋角、左膝角和右膝角等,总体准确率达到 90.12%。Ye 等人^[15]在完整的步态周期中提取了 12 个步态参数,包括足距比、膝角比等,并使用多种分类算法进行分类,发现 NARX-NN 算法效果最好。Wang 等人^[16]在步态参数提取器中定义了 9 个步态参数,包括站立时间、步长、速度、左髋屈曲等,使用 SVM 算法作为分类器,并发现仅使用其中 4 个参数的组合效果比使用全部 9 个参数更好。

异常步态分类算法分为基于机器学习和基于深度学习两类。基于机器学习的步态分类算法主要包括支持向量机(SVM)、随机森林(RF)和 K 最

近邻(KNN)等算法。而基于深度学习的步态算法主要涵盖卷积神经网络(CNN)、长短时记忆网络(LSTM)和循环神经网络(RNN)等算法。Khokhlova 等人^[17]采用骨骼关节方向数据计算步态运动学参数,并设计了一个 LSTM 集成模型来创建无监督的步态分类器,取得了良好的效果。Chen 等人^[18]使用不同的分类器(包括 SVM、KNN 和 RF)对提出的骨关节炎异常步态混合预测模型进行分类,发现 SVM 具有最佳的分类效果,准确率高达 98.77%。Luo 等人^[19]基于随机森林对正常步态与偏瘫步态进行分类,分析了步幅和步速等步态特征对偏瘫分类的重要性,并取得了 90.65% 的平均分类准确率。由于随机森林分类算法具有高准确率和抗过拟合,以及可以对特征进行重要性分析的特点^[20],分类任务将使用随机森林算法进行。

2 人体骨骼关键点提取和数据预处理

2.1 人体骨骼关键点提取

此任务将采用 BlazePose 网络来提取人体关键点信息。BlazePose 是一种轻量级卷积神经网络,推理过程中包含一个人体姿态检测器和一个姿态跟踪器(如图 2)。姿态跟踪器预测关键点坐标、当前帧上的人的存在,以及当前帧的感兴趣区域。当跟踪器指示没有人存在时,在下一帧上重新运行检测器网络。这样可以使网络在手机等设备上的运行更加轻量级。




图 2 BlazePose 推理过程

BlazePose 网络的训练过程主要包括关键点检测和关键点回归两个部分。在网络的训练过程中,采用了热图、偏移量和回归相结合的方法来训练整个网络。这一方法对应于图 3 中的热图(左)、偏移量(中)和回归(右)。

BlazePose 网络在训练过程中首先利用热图和偏移量进行训练。在回归训练阶段,网络截断了图 3(左)的输出分支。这种截断操作既有效地利用了热图来监督训练过程,又在不损失准确率的情况下

提高了整个网络的推理速度。相较于 COCO Pose 的 17 个人体关键点,BlazePose 人体关键点提取网络为每个人体预测了 33 个关键点(包括置信度)。这些关键点的拓扑结构和效果如图 4 所示。与 OpenPose 和 Kinect 的拓扑结构相比,BlazePose 仅利用面部、手和足部上最小数量的关键点来估计后续模型感兴趣区域的旋转、大小和位置。通过获取更丰富的语义特征,本研究确保了步态参数的选择多样性。




图 3 BlazePose 的网络架构




图 4 BlazePose 的拓扑结构和效果

2.2 数据预处理

在进行姿态估计任务时,从摄像头或传感器获取的原始数据通常会受到多种干扰因素的影响,例如噪声和抖动。这些因素会降低数据的准确率和精度。为了解决这个问题,采用了一种常用的非线性数字信号处理方法,即中值滤波(median filter),用于去除图像和信号中的异常值。中值滤波的原理是对信号的每个采样点周围的一段区域(例如一个平滑窗口)内的所有数值进行排序,并将其中位数作为该点的新值。中值滤波能有效地消除不同类型的噪声,如椒盐噪声和高斯噪声,而不会破坏信号中的边缘和细节。在实验中观察到关键点的 x 坐标和 y 坐标的值变化幅度不同,因此不宜采用

相同的平滑窗口大小。基于经验,为不同的关键点的 x 坐标和 y 坐标选择了不同的平滑窗口大小。以 RAnkle_x(右脚踝的 x 坐标)和 RAnkle_y(右脚踝的 y 坐标)为例,图 5 展示了中值滤波的效果,其中 RAnkle_x(y)曲线代表 BlazePose 识别出的右脚踝关键点的 x (y)坐标,其余两条曲线表示滤波后的数据。RAnkle_x_smooth 平滑窗口为 15, RAnkle_y_smooth 平滑窗口为 3。请注意,在此图中,曲线的数据点每 15 个显示一个,并在滤波后曲线上做了一个小的负垂直偏移,以便清楚地显示和比较。




图 5 中值滤波的效果

3 步态参数提取

3.1 参数选择与数据处理

根据先前的研究,结合异常步态形态提出了 7 个步态特征参数作为人体步态状态的指标。这些参数包括左步幅与左腿长之比、右步幅与右腿长之比、左髋屈曲角度、右髋屈曲角度、左膝屈曲角度、右膝屈曲角度和步数。将这些参数编号为 G1~G7,并在表 1 中进行详细的描述。

在步态临床研究中,由于需要正式许可和特殊实验室设置,以及难以接触临床环境,导致可用的异常步态评估数据集非常有限。然而,Wang 等人^[16]在临床环境中收集了 404 名受试者进行 TUG(timed up-and-go)测试的视频,我们将该视频数据作为异常步态检测的数据来源,并验证步态检测方法的可靠性。

该数据集的受试者需要完成 TUG 测试,其中包括从坐到站起、3 米步行、转身、3 米步行向后、再次坐下这五个动作。由于提出的步态参数只需

关注步行过程,因此,在使用 BlazePose 识别人体关键点并进行数据处理后,需要识别出开始步行、结束步行、开始步行向后、结束步行向后这四个时间点。为了准确分割步态阶段,选择了具有明显数据变化的踝关节关键点的数据作为分割依据。

表 1 步态特征参数

编号	参数名	描述	观察
G1	左步幅与左腿长之比	左脚足跟着地到该侧足跟再次着地所进行的距离与左腿长度的比值	左脚运动能力
G2	右步幅与右腿长之比	右脚足跟着地到该侧足跟再次着地所进行的距离与右腿长度的比值	右脚运动能力
G3	左髋屈曲角度/(°)	在行走时左髋关节的屈曲角度	身体稳定性
G4	右髋屈曲角度/(°)	在行走时右髋关节的屈曲角度	身体稳定性
G5	左膝屈曲角度/(°)	在行走时左膝关节的屈曲角度	身体支撑能力
G6	右膝屈曲角度/(°)	在行走时右膝关节的屈曲角度	身体支撑能力
G7	步数	在固定距离内行走步数	身体运动能力

由于摄像头从侧面拍摄受试者,在行走过程中,远离摄像头的脚的部分会被另一只脚遮挡,导致脚相关关键点的识别精度较低。为提高数据准确率,在计算步态参数时,只考虑相对于摄像头较近脚的数据。例如,计算右步幅时只考虑受试者从左向右行走时右脚关键点的数据。根据数据预处理的结果,对踝关节关键点的数据进行进一步处理。以右踝关节点为例,首先由式(1)得到数据曲线的斜率。

$$k_i = (y_{i+1} - y_{i-1}) / (x_{i+1} - x_{i-1}) \tag{1}$$

式中, k_i 为该点的斜率; i 为该点的索引; x 和 y 分别为数据点的横纵坐标。

然后由式(2)对斜率进行阈值处理以消除异常数据的影响。根据经验选择阈值为 0.5。

$$t_i = \begin{cases} 0, & k_i < 0.5 \\ 1, & k_i \geq 0.5 \end{cases} \tag{2}$$

式中, t_i 为该点进行阈值处理后的值。

对于左脚踝关节点,则取阈值为-0.5。如图 6 所示,阈值处理后的曲线中有 5 个大于阈值的波段,但其中有 2 个明显不属于步行过程,需要去除。通过波段宽度的大小来进行判断,根据实验结果选择宽度阈值为 5,由式(3)得到 P_i 。

$$P_i = \begin{cases} 0, & n \leq 5 \\ t_i, & n > 5 \end{cases} \tag{3}$$

式中, P_i 为该点信号判断处理后的值; n 表示波段宽度大小。

左踝关节点的处理方式相同。通过这些处理步骤可以确定 TUG 测试的 5 个阶段中步行阶段的开始和结束。当数据值从 0 变为 1 时,表示开始迈步;当数据值从 1 变为 0 时,表示迈步结束。右步幅的数量可以由波段的数量表示。例如在图 6 (在此图中,曲线的数据点每 15 个显示一个,并在阈值处理 1 和阈值处理 2 曲线上做了一个小的负垂直偏移,以便更清楚地显示和比较)的阈值处理 2 曲线上,有 3 个波段,因此可以得到 3 个右步幅参数。这个信号检测过程在后续步态参数计算中非常重要。




图 6 R_Ankle 数据经过处理得到步幅参数

在得到步行阶段之后,使用以下方法在其中提取 G1~G7 共 7 个参数。图 7 直观显示了一个右步幅阶段的相关参数。其中 L_{R1} 、 $L_{R(H-K)}$ 、 $L_{R(K-A)}$ 、 $L_{R(H-S)}$ 分别表示右步幅长度、大腿长度、小腿长度、肩部到髋关节的长度。 θ_{RH} 、 θ_{RK} 分别表示右髋屈曲角度、右膝屈曲角度。请注意,在此图中,相机位于拍摄对象的右侧。因此,提取右脚相关关键点。




图 7 一个右步幅阶段的相关步态参数示意图

3.2 参数计算

3.2.1 G1 和 G2

G1 是在受试者从右向左行走时由式(4)求得, G2 是在受试者从左向右行走时由式(5)求得。腿长由两段长度(髌关节到膝关节、膝关节到踝关节的长度)相加得到,为减小误差,这两个数据在单个步幅阶段中每帧计算得到后通过取众数的方法求得。而单个步幅由一个步幅阶段中的迈步起始点与迈步结束点两点之间的欧式距离求得,以右步幅为例,可由式(6)求得。

$$G1 = \frac{L_{\text{左步幅}}}{L_{\text{左腿长}}} = \frac{(L_{L1} + L_{L2} + \dots + L_{Ln})/n_{\text{左}}}{L_{L(H-K)} + L_{L(K-A)}} \quad (4)$$

$$G2 = \frac{L_{\text{右步幅}}}{L_{\text{右腿长}}} = \frac{(L_{R1} + L_{R2} + \dots + L_{Rn})/n_{\text{右}}}{L_{R(H-K)} + L_{R(K-A)}} \quad (5)$$

式中, L_{Ln} (L_{Rn}) 表示第 n 个左(右)步幅数据; $L_{L(H-K)}$ ($L_{R(H-K)}$) 表示左(右)脚髌关节与膝关节的长度; $L_{L(K-A)}$ ($L_{R(K-A)}$) 表示左(右)脚膝关节与踝关节的长度。

$$L_{Ri} = \sqrt{(R_A x_i - R_A x_{i-1})^2 + (R_A y_i - R_A y_{i-1})^2} \quad (6)$$

式中, L_{Ri} 表示右步幅长度; $R_A x$ 和 $R_A y$ 分别表示右脚踝关节点 x 和 y 的位置。

3.2.2 G3 和 G4

与前两个参数一样, G3 是受试者从右向左行走时提取的, G4 是受试者从左向右行走时提取的。并直接取序列的最大差值,如式(7)和式(8)所示。而具体的角度计算根据余弦定理求得,以右脚髌关节屈曲角度为例,由式(9)求得。

$$G3 = \theta_{LH\max} - \theta_{LH\min} \quad (7)$$

$$G4 = \theta_{RH\max} - \theta_{RH\min} \quad (8)$$

式中, $\theta_{LH\max}$ 和 $\theta_{LH\min}$ 分别表示左脚髌关节屈曲最大和最小角度; $\theta_{RH\max}$ 和 $\theta_{RH\min}$ 分别表示右脚髌关节屈曲最大和最小角度。

$$\theta_{RH} = \arccos\left(\frac{L_{R(H-K)}^2 + L_{R(H-S)}^2 - L_{R(S-K)}^2}{2 \times L_{R(H-K)} \times L_{R(H-S)}}\right) \quad (9)$$

式中, $L_{R(H-K)}$ 、 $L_{R(H-S)}$ 和 $L_{R(S-K)}$ 分别表示右脚髌关节到膝关节的距离;髌关节到肩关节的距离和肩关节到膝关节的距离。

3.2.3 G5 和 G6

计算方法与 G3 和 G4 类似,如式(10)~式(12)所示。

$$G5 = \theta_{LK\max} - \theta_{LK\min} \quad (10)$$

$$G6 = \theta_{RK\max} - \theta_{RK\min} \quad (11)$$

式中, $\theta_{LK\max}$ 和 $\theta_{LK\min}$ 分别表示左脚膝关节屈曲最大和最小角度; $\theta_{RK\max}$ 和 $\theta_{RK\min}$ 表示右脚膝关节屈曲最大和最小角度。

$$\theta_{RK} = \arccos\left(\frac{L_{R(H-K)}^2 + L_{R(K-A)}^2 - L_{R(H-A)}^2}{2 \times L_{R(H-K)} \times L_{R(K-A)}}\right) \quad (12)$$

式中, $L_{R(H-K)}$ 、 $L_{R(K-A)}$ 和 $L_{R(H-A)}$ 分别表示右脚髌关节到膝关节的距离、膝关节到踝关节的距离和髌关节到踝关节的距离。

3.2.4 G7

一个步幅表示走了两步,所以步数可由左步幅和右步幅得到,如式(13)。

$$G7 = 2 \times (G1 + G2) \quad (13)$$

4 步态分类

首先对数据集中的 404 个视频样本进行详细分析,剔除 5 个灯光闪烁或测试者未按规定路径行走的样本,得到 399 个符合要求的视频样本,其中异常与正常步态的数量分别为 142 和 257。通过对样本进行步态特征参数的提取工作,得到一个包含 399 组步态特征参数的集合,记为 $P = \{P_1, P_2, \dots, P_k\}$; $P_k = (G1, G2, G3, G4, G5, G6, G7, n)$, 其中 $k \in [1, 399]$, $n = 0$ 或 1。这对应于异常和正常两个类别。

随机森林是一种集成学习算法^[21]。它通过构建多个决策树进行预测,并通过投票来集成它们的预测结果。该算法会对训练数据进行随机采样,同时随机选择特征,从而降低过拟合的风险,提高预测的准确率和稳定性。

为了解各个参数对分类结果的贡献程度,使用随机森林算法对特征参数集合 P 进行特征权重计算,结果如图 8 所示。参数 G7 对分类的贡献率最高,达到了 31.7%,而参数 G3 的贡献率仅为 5.3%。这说明步数(由参数 G7 表示)在分类任务中起到了重要作用,也间接验证了在固定距离内行走的步数可以作为判断步态异常的重要指标。

分类评估指标包括准确率(accuracy)、召回率(recall)和 AUROC(area under the receiver operating characteristic curve)。准确率是指模型正确分类的样本数占总样本数的比例[如式(14)]。召回率是指在所有实际为正例的样本中,被模型正确预测为正例的样本所占的比例[如式(15)]。召回

率衡量了模型对正例样本的覆盖能力。AUROC 是 ROC 曲线下的面积,其取值范围在 0 到 1 之间。它是评估二分类模型性能的指标之一,用于衡量模型在不同阈值下分类的整体性能。

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \times 100\%$$

(14)

$$Recall = \frac{TP}{TP + FN} \times 100\%$$

(15)

为了评估不同步态特征参数对分类效果的贡献,对这些参数进行组合处理,并使用随机森林分类器进行评估。总共有 7 个参数,因此可以得到 $2^7=128$ 种不同的参数组合。得到的评估结果如图 9 所示(按照准确率从高到低排列,每 2 个参数组合数据只显示 1 个,以便清楚地显示)。准确率范围在 0.575 至 0.975 之间,召回率范围在 0.2 至 0.9 之间。这表明不同的参数组合对分类效果有着显著影响,合理的步态参数组合可以得到较好的分类结果。




图 8 G1~G7 各个参数对随机森林分类的重要程度




图 9 各种步态特征参数组合的结果

本文在采用随机森林算法的同时,添加决策树(DT)^[22]、K 最近邻(KNN)^[23]、逻辑回归(LR)^[24]、朴素贝叶斯(NB)^[25]、随机梯度下降(SGD)^[26]、支持向量机(SVM)^[27]等先进分类算法对步态进行分类识别。在每次训练过程中将训练数据和测试数据按照 8 : 2 的比例进行随机拆分。实验结果显示在表 2 中,可以观察到,随机森林算法展现出最佳的分类效果,其准确率达到 97.5%,召回率为 90%,AUROC 为 0.92。这表明随机森林分类器在该问题上具有较好的分类性能。

表 2 各种分类算法的结果比较

分类算法	准确率/%	召回率/%	AUROC
RF	97.5	90	0.92
DT	85	72	0.81
KNN	89	76	0.87
LR	95	80	0.90
NB	88	84	0.91
SGD	86	80	0.88
SVM	95	80	0.91

5 结 论

本文提出了一种基于 BlazePose 和随机森林算法的异常步态检测方法,利用 BlazePose 算法进行人体骨骼关键点提取。提取了 7 个步态特征参数并进行计算。利用随机森林算法对 SAIL-TUG 数据集进行分类实验,实验结果表明,本文的方法能够有效地检测出正常与异常步态,并具有较高的准确率、召回率和 AUROC 值。这验证了该方法在步态识别检测中的可行性。

通过与多种分类算法进行比较,发现随机森林算法在本方法中表现最佳。这为进一步改进和优化步态异常检测模型提供了有益的参考。此外也对不同步态特征参数的组合进行了评估,发现不同的参数组合对分类效果产生较大影响。特别是步数这一参数在分类任务中起到了重要作用,可以作为判断步态异常的重要指标之一。

未来的研究可以探索优化算法和模型,对步态参数进行更深入的分析,以进一步提升步态异常检测的性能和精确度。此外,可以将异常步态检测应用于更广泛的领域,如医疗和运动康复等,以促进健康管理和康复治疗的发展。

参考文献

- [1] COHEN A J, VERGHESE J, ZWERLING L J. Cognition and gait in older people[J]. *Maturitas*, 2016, 93: 73–77.
- [2] SHARMA B, WANG Meng, MCCREARY C R, et al. Gait and falls in cerebral small vessel disease: a systematic review and meta-analysis[J]. *Age and ageing*, 2023, 52(3): 1–12.
- [3] VYTAUTAS B, ANDRIUS D, JUSTE R, et al. Wearable feet pressure sensor for human gait and falling diagnosis[J]. *Sensors*, 2021, 21(15): 5240–5252.
- [4] MAO Yufeng, TAIKI O, HIROKI O, et al. Estimation of stride-by-stride spatial gait parameters using inertial measurement unit attached to the shank with inverted pendulum model[J]. *Scientific Reports*, 2021, 11(1): 1–10.
- [5] ANTHONY B, KONSTANTINOS B, MAYSAM A. A review on the use of microsoft kinect for gait abnormality and postural disorder assessment[J]. *Journal of health-care engineering*, 2021, 2021: 1–19.
- [6] WANG Ziyang, FANI D, IRINA V, et al. A single R-GB camera based gait analysis with a mobile tele-robot for healthcare[J]. *Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 2021, 2021: 6933–6936.
- [7] ADITYA V, VENKATESWARAN R, TATHAGATA R, et al. Development of a robust, simple, and affordable human gait analysis system using bottom-up pose estimation with a smartphone camera[J]. *Frontiers in Physiology*, 2022, 12: 784–865.
- [8] TAFAZZOLI F, SAFABAKHS R. Model-based human gait recognition using leg and arm movements[J]. *Engineering Applications of Artificial Intelligence*, 2010, 23(8): 1237–1246.
- [9] 曹晓瑜, 夏端峰. 基于深度学习的人体姿态估计方法综述[J]. *现代信息科技*, 2022, 6(23): 1–6.
- [10] BAZAREVSKY V, GRISHCHENKO I, RAVEENDRAN K, et al. BlazePose: on-device real-time body pose tracking[J]. 2020. DOI:10.48550/arXiv.2006.10204.
- [11] LIU Wei, LIU Xu, HU Yuan, et al. Fall detection for shipboard seafarers based on optimized BlazePose and LSTM[J]. *Sensors*, 2022, 22(14): 5449–5467.
- [12] STEBBIN J, PITT T, THEOLOGIS T. Objective identification of gait abnormalities[J]. *Gait & Posture*, 2006, 24: 47–49.
- [13] 田皓宇, 马昕, 李贻斌. 基于骨架信息的异常步态识别方法[J]. *吉林大学学报(工学版)*, 2022, 52(4): 725–737.
- [14] NGUYEN T N, HUYNH H H, MEUNIER J, et al. Skeleton-based abnormal gait detection[J]. *Sensors*, 2016, 16(11): 1792–1805.
- [15] YE Minxiang, YANG Cheng, VLADIMIR S, et al. D-istinct feature extraction for video-based gait phase classification[J]. *IEEE Transactions on Multimedia*, 2019, 22(5): 1113–1125.
- [16] WANG Yanhong, ZOU Qiaosha, TANG Yanmin, et al. Sail: a deep-learning-based system for automatic gait assessment from TUG videos[J]. *IEEE Transactions on Human-Machine Systems*, 2022, 52(1): 110–122.
- [17] KHOKHLOVA M, MIGNIOT C, MOROZOV A, et al. Normal and pathological gait classification LSTM model[J]. *Artif Intell Med*, 2019, 94: 54–66.
- [18] CHEN Fang, CUI Xiwen, ZHAO Zhe, et al. Gait Acquisition and analysis system for osteoarthritis based on hybrid Prediction Model[J]. *Computerized Medical Imaging and Graphics*, 2020, 85: 1–11.
- [19] LUO Guoliang, ZHU Yean, WANG Rui, et al. Random forest based classification and analysis of hemiplegic gait using low-cost depth cameras[J]. *Medical & Biological Engineering & Computing*, 2020, 58(2): 373–382.
- [20] 吕红燕, 冯倩. 随机森林算法研究综述[J]. *河北省科学院学报*, 2019, 36(3): 37–41.
- [21] HO T K. Random decision forests[J]. *IEEE Computer Society*, 1995(1): 278–282.
- [22] QUINLAN J R. Induction of decision trees[J]. *Machine Learning*, 1986, 1(1): 81–106.
- [23] ALTMAN N S. An introduction to kernel and nearest neighbor nonparametric regression[J]. *The American Statistician*, 1992, 46(3): 175–185.
- [24] WALKER S H, DUNCAN D B. Estimation of the probability of an event as a function of several independent variables[J]. *Biometrika*, 1967, 54(1–2): 167–179.
- [25] MARON M E. Automatic indexing: an experimental inquiry[J]. *Journal of the Acm*, 1961, 8(3): 404–417.
- [26] MONRO R S. A stochastic approximation method[J]. *Annals of Mathematical Statistics*, 1951, 22(3): 400–407.
- [27] CORTES C, VAPNIK V. Support-vector networks[J]. *Machine Learning*, 1995, 20(3): 273–297.