

罗子昂, 吴钦木. 基于 SAM-AlexNet 的跨视角步态周期分类算法研究[J]. 智能计算机与应用, 2025, 15(10): 181-187.  
DOI:10.20169/j.issn.2095-2163.251028

# 基于 SAM-AlexNet 的跨视角步态周期分类算法研究

罗子昂, 吴钦木

(贵州大学 电气工程学院, 贵阳 550025)

**摘要:** 步态识别技术随着生物特征识别技术的发展受到越来越多的关注,步态周期检测技术是步态识别系统中的一个重要环节。针对步态周期分类易出错、准确率低等问题,本文提出了一种基于 SAM-AlexNet 的跨视角步态周期分类模型。首先,使用双三次插值和非局部均值滤波对步态轮廓图像进行预处理;然后,使用 Sobel 算子提取人体边缘特征,并将其与原始图像进行融合,模型能够更好地捕捉到步态轮廓的关键信息。其次,引入了空间注意力模块(Spatial Attention Mechanism, SAM),使模型能够更加聚焦于对分类任务更为关键区域,进一步提升了模型的性能。实验结果表明,该优化模型在 CASIA-B 数据集的不同视角下行人步态周期三分类任务上取得了较好的性能,准确率达到 93%。与 AlexNet 基础模型相比提高近 5%。因此,本文所提出的模型能够有效地提高步态周期的分类能力。

**关键词:** 步态周期分类; AlexNet; 空间注意力模块(SAM); 步态识别

中图分类号: TP391

文献标志码: A

文章编号: 2095-2163(2025)10-0181-07

## Research on cross-perspective gait cycle classification algorithm based on SAM-AlexNet

LUO Zi'ang, WU Qinmu

(College of Electrical Engineering, Guizhou University, Guiyang 550025, China)

**Abstract:** With the development of biometric identification technology, gait recognition technology has attracted more and more attention, and gait cycle detection technology is an important link in the gait recognition system. In order to solve the problems of error-prone and low accuracy of gait cycle classification, this paper proposes a cross-perspective gait cycle classification model based on SAM-AlexNet, which firstly uses bicubic interpolation and non-local mean filtering to preprocess gait profile images. Then, the Sobel operator is used to extract the human edge features and fuse them with the original image, and the model can better capture the key information of the gait profile. Secondly, the Spatial Attention Mechanism (SAM) is introduced to enable the model to focus more on the regions that are more critical to the classification task, which further improves the performance of the model. Experimental results show that the optimized model achieves good performance in the gait cycle tri-classification task, with an accuracy of 93%. Compared to the AlexNet base model, the improvement is more than 5%. Therefore, the model proposed in this paper can effectively improve the classification ability of gait cycle.

**Key words:** gait cycle classification; AlexNet; Spatial Attention Module; gait recognition

## 0 引言

步态周期检测<sup>[1]</sup>是指通过分析步态图像或其他相关数据,识别和测量人体行走或运动中的步态周期。步态周期检测在医学<sup>[2]</sup>、运动科学<sup>[3]</sup>和生物力学<sup>[4]</sup>等领域具有重要的应用价值。步态周期检测是人体步态分析<sup>[5]</sup>的关键步骤之一,对于理解和

评估人体运动模式、诊断运动障碍<sup>[6]</sup>以及设计康复方案具有重要意义。步态周期<sup>[7]</sup>是指从一个足部接触地面开始到下一个足部接触地面结束的时间间隔。准确地检测和测量步态周期可以提供关于步态稳定性、步态对称性以及步态异常的信息。因此,步态周期检测在临床医学、康复工程和运动科学等领域展现出广阔的应用前景。

**基金项目:** 黔科合支撑[2021]一般442。

**作者简介:** 罗子昂(1999—),男,硕士研究生,主要研究方向:步态周期检测,外骨骼机器人。

**通信作者:** 吴钦木(1975—),男,博士,教授,博士生导师,主要研究方向:电机控制,深度学习。Email: qmwu@gzu.edu.cn。

收稿日期: 2024-01-15

许多步态识别算法依赖于步态周期的识别来准确提取特征,步态周期的精度对于步态分析和识别非常重要。跨视角步态周期检测是指在不同摄像机视角下对步态周期进行准确检测。由于不同视角下人体的外观和姿态变化,跨视角步态周期检测具有一定的难度。视角变化可能导致人体的形状、大小、姿态等特征发生变化,从而影响步态周期的检测精度。

跨视角步态周期检测的意义在于提高步态分析和识别的鲁棒性和实用性。在现实应用中,摄像机的位置和角度可能会发生变化,因此能够准确地在不同视角下检测步态周期,可以使步态分析和识别系统更加稳健和可靠。Rogez 等学者<sup>[8]</sup>使用低维流形对 3 维姿势和相机视角进行建模并学习轮廓的生成模型,通过在场景的水平面和姿势视角流形上联合使用递归贝叶斯采样,进行具有高透视效果的视角不变 3 维步态跟踪。然而,这种跟踪必须在人为设置的环境中进行。张云佐等学者<sup>[9]</sup>利用 BlazePose 模型对行人视频数据集进行步态周期检测,但该方法依赖于特定的外观和形状特征来进行识别。在 18°和 36°视角下,人体的外观和形状可能会发生较大的变化,导致算法难以准确地识别步态周期。徐怡博<sup>[10]</sup>利用分类和回归两种方法对于步态轮廓图数据集进行步态周期检测,尽管回归方法可以提供更精细的时间信息,但在实际应用中需要权衡标注工作的复杂性和数据集的要求。分类方法相对而言更简单和易于实施,因此在某些情况下可能更为实用。

因此,本文基于 Sam-AlexNet 网络模型提出了

基于分类的步态周期检测,相比过往方法优化图像预处理流程,将人体边缘特征与原始图像相结合作为输入,在 AlexNet 基础模型中加入空间注意力模块,采用改进的网络模型进行步态周期特征提取,完成最终的步态周期检测。与已有的方法相比,该方法减低了周期特征提取的难度和计算量,并可在跨视角条件下进行步态周期检测。

1 模型设计

1.1 AlexNet 网络模型

在 AlexNet 模型出现之前,传统的机器学习方法在图像分类任务上表现不佳。在 2012 年, Krizhevsky 等学者提出了 AlexNet,通过引入深度卷积神经网络<sup>[11]</sup>的概念,成功地将图像分类的准确率提升到了一个新的高度。这一成果不仅开创性地提供了使用深度神经网络来解决图像问题的有效途径,同时也引发了产业界对神经网络的兴趣,随后在这一领域的优秀成果也不断涌现。VGGNet、GoogleNet 和 ResNet 等网络即是基于 AlexNet 网络的演进发展,在网络的层数和深度上皆有增加,因此能够更好地处理更复杂的图像识别<sup>[12]</sup>任务。

AlexNet 的具体结构如图 1 所示,AlexNet 模型的权重层包括 5 个卷积层和 3 个全连接层,AlexNet 采用了深度卷积神经网络结构,通过多层卷积层和池化层的堆叠,有效提取图像特征。使用 ReLU 作为激活函数,解决梯度消失问题,也进一步提升了计算速度。引入 LRN 操作增强模型泛化能力和鲁棒性。在卷积层后使用 Dropout 操作防止过拟合,减少神经元间依赖关系。




图 1 AlexNet 结构图

Fig. 1 Structure of AlexNet

本文选择 AlexNet 作为基础模型的原因是相比于 VGGNet、GoogleNet 或 ResNet 等更深、更复杂的网络结构来说, AlexNet 具有相对简单的网络结构和较低的计算复杂度。由于步态轮廓图是二值图像, 当与彩色图像或具有丰富语义信息<sup>[12-13]</sup>的图像相比后可知, 步态轮廓图的信息相对较少。使用较深的网络结构可能会导致过拟合或计算资源的浪费。而 AlexNet 作为最早成功应用于大规模图像分类任务的深度卷积神经网络, 具有适度的深度和复杂度, 能够提取足够的特征信息, 同时具有较快的训练速度和较低的计算资源需求。因此, 选择 AlexNet 作为本文的基础模型是合理的选择。AlexNet 不仅具有适度的复杂度、较低的计算资源需求, 并且能够提取足够的特征信息进行后续的步态识别。尽管步态轮廓图可能缺乏丰富的语义信息, 但 AlexNet 仍然可以通过学习轮廓的形状和纹理等特征来进行有效的分类和识别。

## 1.2 空间注意力模块

空间注意力模块(Spatial Attention Module)是一种允许卷积神经网络关注输入图像中信息最丰富的部分的模块。使用空间注意力模块的主要优点是能够选择性地放大相关特征并抑制不相关特征。这使得卷积神经网络能够专注于输入步态轮廓图像中信息最丰富的部分, 从而获得更好的任务性能。此外, 空间注意力模块的计算效率很高, 因为空间注意力模块只使用 2 个池化操作和 1 个卷积层, 空间注意力模块的结构如图 2 所示。由图 2 可知, 第 1 个池化操作是平均池化操作, 用于计算通道上每个特征的平均值。第 2 个池化操作是最大池化操作, 用于计算通道上每个特征的最大值。然后将这 2 个池化特征图连接起来并输入到具有  $7 \times 7$  滤波器大小的标准卷积层中, 从而生成 2D 空间注意力图。

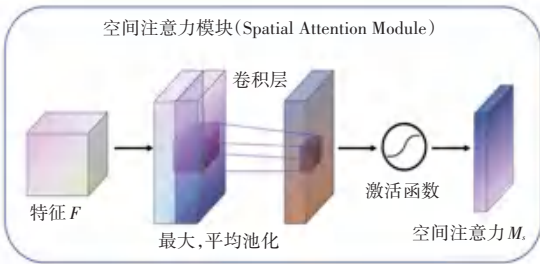


图 2 SAM 模型结构图

Fig. 2 Structure of the SAM model

空间注意力图的计算公式为:

$$M_s(F) = \sigma(f^{7 \times 7}([\text{AvgPool}(F); \text{MaxPool}(F)])) \quad (1)$$

其中,  $M_s$  表示空间注意力图;  $F$  表示输入特征图;  $\sigma$  表示 Sigmoid 函数;  $f^{7 \times 7}$  表示滤波器尺寸为  $7 \times 7$  的卷积操作; AvgPool 和 MaxPool 分别表示平均池化和最大池化操作; “[ ]” 表示串联。

## 1.3 整体模型结构

基础的 AlexNet 模型是在彩色图像数据集上进行训练和设计的, 而步态轮廓图是二值图像, 信息量较少。这就使得传统的 AlexNet 无法充分利用步态轮廓图中的特征信息, 从而可能导致分类性能下降。同时, 传统的 AlexNet 在训练时使用了大量的参数, 而步态轮廓图数据集相对较小, 这可能导致过拟合的风险。为了克服这些不足, 本文对 AlexNet 基础模型进行了改进。

首先, 在第 1、3、5 卷积层后引入了批归一化操作。批归一化可以对每个批次的输入进行归一化处理, 减少内部协变量转移的影响, 使得网络更容易训练和优化, 加速了训练过程, 并解决了梯度消失和梯度爆炸的问题。

其次, 由于在深层网络中, 特征的抽象程度逐渐增加, 网络更加关注全局信息, 因此在较深的层次上引入这些层可能会带来较小的收益。此外, 引入这些层也会增加模型的复杂性和计算成本。通过实验后本文选择在第 1、3、5 卷积层后加入 SAM 空间注意力模块, 以更好地提取步态轮廓图中的边缘信息。空间注意力模块通过选择性地放大与步态轮廓边缘相关的特征并抑制其他不相关的特征, 提高模型对步态轮廓边缘信息的敏感性。

这些改进使得本文模型能够更好地适应步态轮廓图的特点, 充分利用其特征信息, 并显著提高了步态轮廓图的分类准确率。SAM-AlexNet 模型设计如图 3 所示。

## 1.4 损失函数和优化算法的选择

(1) 损失函数。交叉熵损失函数在深度学习中用于衡量预测分布与真实分布之间的差异, 可以作为优化目标函数来指导模型的训练方向。在步态识别任务中, 选择交叉熵损失函数作为优化目标函数, 可以评估模型对于不同步态类别的预测准确性, 并指导模型在训练过程中逐渐优化预测分布与真实分布之间的差异。交叉熵函数的数学定义公式具体如下:

$$L = - \sum_{i=1}^N y_i \log(x_i) \quad (2)$$

其中,  $N$  表示样本的数量;  $y_i$  表示真实标签的概率分布;  $x_i$  表示模型的预测结果的概率分布。



(2) 优化算法。随机梯度下降 ( Stochastic Gradient Descent,SGD)算法通过随机采样少量训练样本来计算梯度,具有计算速度快、硬件要求低的优势。然而,却也存在收敛不稳定的问题。为了解决

这个问题,本文引入自适应学习率 ( Adaptive Learning Rate),以减缓不稳定的收敛状态。此外,优化算法中还使用了权值衰减和神经元失活等技术来防止过拟合,提高模型的泛化能力。

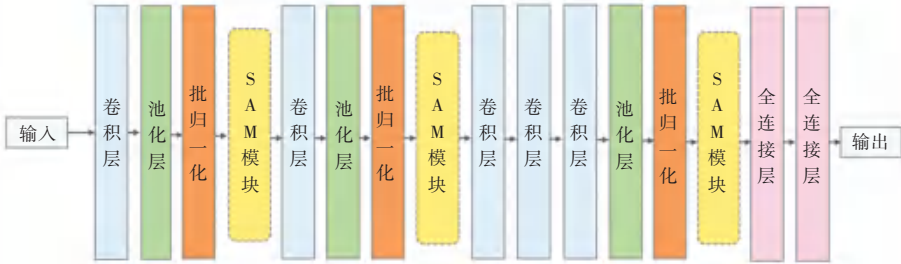


图 3 SAM-AlexNet 模型设计  
Fig. 3 SAM-AlexNet model design

1.5 整体流程

SAM-AlexNet 模型实现步态轮廓图像分类整体流程如图 4 所示。首先,将 CASIA-B 数据集中的步态轮廓图按照 0°,18°⋯,180°这 11 个不同视角进行分类,然后通过人工方式对每个视角下的数据集进行分类,对分类后的步态轮廓图像进行预处理,使用 Sobel 算子提取人体边缘特征并将其与原始图像进行融合<sup>[14]</sup>,以突出人体的轮廓,从而有利于提升模型的分类性能,接下来再将数据集按照 6 : 2 : 2 的比例划分为训练集、验证集和测试集。其中,训练集用于模型的训练,验证集用于调整模型的超参数和进行模型选择,测试集用于评估模型的性能。最后将步态轮廓图作为输入数据,输入至 SAM - AlexNet 网络模型中进行训练和测试。并对分类结果进行性能评估。

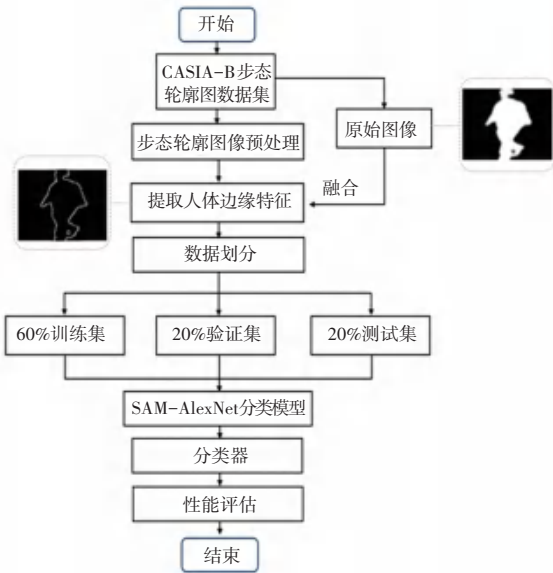


图 4 步态图像分类流程

Fig. 4 Flowchart of gait image classification

2 实验结果分析

本实验平台为一块 GPU 显卡,GPU 型号为 NVIDIA GeForce RTX 3060,该 GPU 显存为 11.75 GB,显卡频率 1.35 GHz。实验基于深度学习框架为 Keras2.6.0 和 TensorFlow2.6.0,使用 Python3.9 语言编程。

2.1 数据集描述和预处理

(1)数据集的选取和分类。本文采用 CASIA-B 数据集进行步态周期的分类。CASIA-B 是中国科学院自动化研究所提供的一个大规模、多视角的步态数据集。该数据集采集于 2005 年 1 月,旨在用于步态识别和人体行为分析等研究领域。CASIA-B 数据集包含了 124 例采集者的原始视频数据和轮廓图像,每个人在 11 个不同视角下进行采集。这些视角从 0°~180°、以 18°为间隔,涵盖了行人行走时的不同方向。

徐怡博<sup>[10]</sup>在步态周期三分类时根据周期的帧数特征,将一个周期固定划分为 24 帧,并将每个类别的帧数固定为 4 帧,如图 5 所示。3 个类别依次是后腿支撑、双腿支撑和前腿支撑。




图 5 固定帧数步态三分类

Fig. 5 Fixed frame number gait triple classification

然而,这种分类方法在数据集中引入了一定的误差,由于不同个体的步态特征和行走速度等因素的差异,并非所有人的每个步态类别下都是固定的 4 帧。实际上,数据集中的样本每个步态类别所占帧数<sup>[15]</sup>分布在 2~4 帧之间。尽管与实际情况相比,这种差异并不显著,但仍然存在一定的误差。为了减小这种误差,本研究采用了人工标注的方法对数据集进行了更加精确的分类。通过这种方式,确保了每个步态周期类别中包含由 2、3、4 帧组成的样本。在双腿支撑的分类情况下,具体如图 6 所示。图 6 中清晰展示了每个类别中包含的不同帧数组成的双腿支撑类别。




图 6 非固定帧数双腿支撑

Fig. 6 Non-fixed frame number double leg support

(2)数据集的预处理。CASIA-B 步态轮廓图原始图像存在一些不足之处。首先,原始图像的尺寸可能不一致,这会导致图像在输入模型之前需要进行统一的尺寸调整。其次,原始图像中可能存在噪声和细节信息,这可能会干扰模型对步态特征的准确提取。为了提高模型对步态轮廓图像的分类准确率,本文采用了双三次插值和非局部均值滤波的处理方式。双三次插值调整图像大小,消除了尺寸差异对模型的影响,而非局部均值滤波处理则平滑了图像,减少了噪声和细节信息,突出了步态轮廓的形状和结构,处理前后的对比如图 7 所示。这种预处理方式提高了图像质量和一致性,为模型提供了更准确、更清晰的输入。通过这样的处理,模型能够更好地理解和提取步态特征,从而显著提升了对步态轮廓图像的分类准确率。最终将预处理后的图像进行手动标记并放入对应的类别中,所有视角完成标记的数量为 60 000 张左右,再将处理后的 11 个视角的数据集按照 6 : 2 : 2 的比例划分为训练集、验证集、测试集。3 种数据集的种类和数量见表 1。




图 7 处理前后对比图

Fig. 7 Comparison before and after processing

表 1 数据集种类和数量

Table 1 Type and number of data sets

数据集	步态类别		
	前腿支撑	双腿支撑	后腿支撑
训练集	12 000	12 000	12 000
验证集	4 000	4 000	4 000
测试集	4 000	4 000	4 000

2.2 边缘特征提取

本文将 Sobel 算子<sup>[16]</sup>应用于步态轮廓图像的边缘特征提取,通过计算梯度幅值和方向突出步态轮廓的形状和结构。与直接输入原始图像相比,将原始图像与边缘特征融合后进行分类可以强化边缘信息来提供更具区分度的特征。这种综合的预处理方式提供了更准确、更鲁棒的特征表示,有助于提高步态图像分类的性能和可靠性。

2.3 实验结果与分析

本文进行训练采用超参数为:批处理大小为每批 32 张图片,基础 AlexNet 模型训练轮数为 150 轮, SAM-AlexNet 模型训练轮数为 100 轮,学习率为 0.000 1。模型训练结果如图 8 所示,基础 AlexNet 模型的准确率起初较低,在迭代 60 轮后才趋于平稳,波动幅度稍大,准确率达到 88. 72%; SAM-AlexNet 模型则在迭代 20 轮后趋于平稳,且验证集的 loss 值比基础 AlexNet 模型更小,波动相对较小,最终准确率达到 93. 03%。由此可见,改进后的 SAM-AlexNet 模型相比基础 AlexNet 模型表现出更快的训练速度和更高的分类准确率,并且在训练过程中的波动幅度较小。这表明改进后的模型具有更好的收敛性和稳定性。

为了验证本文提出的模型在不同视角步态周期分类的鲁棒性,将一个待测步态轮廓序列按照顺序输入训练完成的卷积网络中,完成一个分类循环时,即得到一个周期的步态轮廓图像。具体的周期检测见表 2。本文通过 C 值来评价步态周期检测精度,可由下式计算求出:




图 8 周期检测分类验证结果

Fig. 8 Cycle detection classification validation results

$$C = \frac{|T - T_s|}{T} \tag{3}$$

其中,  $T$  表示实际周期中的帧数,  $T_s$  表示检测到的数目。  $C$  值越小, 误差越小, 方法得到的精度越高。相反,  $C$  值越大, 性能越差。表 2 的结果显示其中 SAM-AlexNet 网络模型的平均误差最小, 取得了最好的识别结果, 这也与验证集上得到的分类结果一致。除了  $0^\circ$ 、 $90^\circ$  和  $180^\circ$  视角外, 其它视角的  $C$  值

均小于 0.1, 平均误差只有 1~2 帧, 在可接受的范围内。由于步态轮廓图在  $0^\circ$ 、 $90^\circ$ 、 $180^\circ$  视角下, 摄像机中轴线与人体呈垂直关系, 人体的轮廓相对镜头左右对称, 从图像中所能提取到的人体运动特征信息没有其它视角那么丰富, 所以在这 3 个视角周期检测的误差相对较大, 不过本文提出的 SAM-AlexNet 模型相对其他模型在跨视角步态周期检测精度方面具有整体性的提升。

表 2 基于分类的步态周期检测方法性能

Table 2 Performance of classification-based gait cycle detection methods

内容	网络结构				
	LeNet	AlexNet	GoogLeNet	本文 AlexNet	SAM-AlexNet
$0^\circ$	0.04	0.30	0.17	0.16	0.12
$18^\circ$	0.25	0.33	0.33	0.14	0.05
$36^\circ$	0.38	0.04	0	0.09	0.03
$54^\circ$	0.50	0.13	0.17	0.13	0.06
$72^\circ$	0.36	0.13	0.17	0.10	0.08
$90^\circ$	0.16	0.12	0.16	0.15	0.10
$108^\circ$	0.28	0.12	0.12	0.13	0.09
$126^\circ$	0.32	0.16	0.24	0.12	0.04
$144^\circ$	0.24	0.12	0.28	0.08	0.03
$162^\circ$	0.46	0.23	0.15	0.09	0.04
$180^\circ$	0.40	0.40	0.12	0.20	0.13
Mean	0.31	0.18	0.17	0.13	0.07

3 结束语

本文首先采用非固定帧数的方法对每个步态周期类别进行更加精确的分类, 减小了数据集部分的误差, 同时采用双三次插值和非局部均值滤波<sup>[17]</sup>对原始图像进行预处理操作, 平滑原始图像的边缘和纹理以及减少图像中的噪声和伪影, 使得步态轮廓图更加清晰和准确, 分类结果也更加稳定和可靠。

再将原始图像与人体边缘特征图像按权重融合, 通过融合人体边缘特征, 可以增加模型对图像的语义理解能力, 增强模型对边缘信息的保持度。本文提出的 SAM-AlexNet 模型相比基础 AlexNet 模型增加了多个批归一化层, 提升了模型的收敛速度, 减少了网络对输入数据中的噪声和扰动的敏感度, 从而提高了网络的鲁棒性, 再根据步态轮廓图二值图像的特性引入空间注意力模块, 强化关键区域的特征表

示以及提高模型对局部细节的感知能力。通过多个基础模型的实验对比结果得知,AlexNet 基础模型相比其他基础模型具有更高的分类准确率,所以本文选取 AlexNet 作为基础模型,本文提出的 SAM - AlexNet 模型相比基础 AlexNet 模型提高了 5% 的准确率,且收敛速度更快、波动也较小。深度学习在步态周期检测中已经取得了一定的成果,但传统的信号处理和模型建模<sup>[18]</sup>方法仍然具有一定的优势。未来的研究<sup>[19]</sup>可以探索将深度学习与传统方法<sup>[20]</sup>相结合,充分利用两者的优势,进一步提高步态周期检测的性能。

参考文献

[1] MA Yuchao, ESNA A Z, PEDRAM M, et al. CyclePro: A robust framework for domain-agnostic gait cycle detection[J]. IEEE Sensors Journal, 2019, 19 (10): 3751-3762.

[2] YU Liang, YAN Li, CHEN Mengjie, et al. Cyclostationary modeling of surface electromyography signal during gait cycles and its application for cerebral palsy diagnosis [J]. Journal of Shanghai Jiaotong University ( Science ), 2018, 23 ( S1 ): 56-61.

[3] HINKEL-LIPSKER J W, HAHN M E. Coordinative structuring of gait kinematics during adaptation to variable and asymmetric split - belt treadmill walking - A principal component analysis approach[J]. Human Movement Science,2018,59:178-192.

[4] ROZHIN M, ALI F, HAMED A, et al. Artificial intelligence approach in biomechanics of gait and sport: A systematic literature review[J]. Journal of Biomedical Physics & Engineering, 2023, 13 (5): 383-402.

[5] JEAN-PIERRE D E P M D, HENK C W P D, JOHN A P M O M D. Readers' evaluation of effect of peer review and editing on quality of articles in the Netherlands Tijdschrift voor Geneeskunde [J]. The Lancet,1996,348(9040): 1480-1483.

[6] CAVORZIN P L, CARRAULT G, CHAGNEAU F, et al. On the interest of computer modelling in the validation of ambulatory measurement of movement disorders in man[C]// Proceedings of 2005 IEEE Engineering in Medicine and Biology 27<sup>th</sup> Annual Conference. Piscataway,NJ:IEEE,2005: 5443-5444.

[7] JAMAL I H, IZHAR C A A, FAUZILAN A S, et al. Systematic literature review: Human gait cycle model using image-temporal feature[C]//Proceedings of the IEEE International Conference on Recent Advances and Innovations in Engineering. Piscataway,NJ: IEEE,2021:1-6.

[8] ROGEZ G, JONATHAN R, GUERRERO J J, et al. Monocular 3-D gait tracking in surveillance scenes[J]. IEEE Transactions on Cybernetics,2014,44(6):894-909.

[9] 张云佐, 董旭, 蔡昭权. 拟合下肢几何特征的多视角步态周期检测[J]. 吉林大学学报(工学版), 2023, 53 (9): 2611-2619.

[10]徐怡博. 步态周期检测方法研究[D]. 哈尔滨:哈尔滨工程大学, 2018.

[11]SZEGEDY C, LIU Wei, JIA Yangqing,et al. Going deeper with convolutions[J]. arXiv preprint arXiv,1409.4842,2014.

[12]SHAFIQ M, GU Zhaoquan. Deep residual learning for image recognition; A survey[J]. Applied Sciences, 2022, 12 (18): 8972-8972.

[13]ZHANG Ruijun, HE Zixuan, ZHU Jian, et al. Collaborative multi-feature extraction and scale-aware semantic information mining for medical image segmentation[J]. Physics in Medicine and Biology, 2022,67:20.

[14]LIU Songlin, ZHANG Shouming, DIAO Zijian,et al. Pedestrian re-identification based on attention mechanism and multi-scale feature fusion [J]. Mathematical Biosciences and Engineering: MBE, 2023, 20 (9): 16913-16938.

[15]唐云祁,薛傲,丁建伟,等. 基于帧差时空特征的步态周期检测方法[J]. 数据采集与处理,2017,32(3):533-539.

[16]RAKESH R, VINAY A. Edge detection using guided Sobel image filtering [J]. Wireless Personal Communications, 2023, 132 (1): 651-677.

[17]刘建宾, 刘保中. 一种基于深度学习的非局部均值图像降噪方法[J]. 计算机仿真, 2020, 37 (8): 228-234.

[18]赵潇衡. 基于时空注意力机制的图卷积病理步态辅助诊断算法研究[D]. 沈阳:辽宁大学, 2023.

[19]许文正, 黄天欢, 贾晔烨, 等. 跨视角步态识别综述[J]. 中国图象图形学报, 2023, 28 (5): 1265-1286.

[20]PARK M H, KWAK K Y, KIM D W. Developing a portable gait cycle detection system using an inertial sensor and evaluating the accuracy of the gait cycle detection [J]. Technology and Health Care, 2015, 24 (S1):69-76.