

DOI:10.19651/j.cnki.emt.2108278

## 基于 ICNet 模型的人体步态识别研究\*

曾 维 何刚强 罗伟洋 郭翼凌  
(成都理工大学机电工程学院 成都 610059)

**摘要:** 步态作为一种行为特征,具有非侵犯性高、伪装性低和远距离识别等特点,具有广阔的应用前景。在实际应用时,步态识别易受环境因素干扰,识别率低。本文提出了一种在胶囊网络中引入空间注意机制,提升有效步态特征在胶囊的权重,又通过反馈权重矩阵的设计,更新输入图像,从而获得网络性能提升的方法。该方法在 CASIA-B 数据集进行了大量的实验。在正常行走、带包行走、大衣行走 3 种不同的行走条件下,平均识别率分别达到 93%、85%、67%。同时在 OU-MVLP 数据集上进行了多视角的步态识别实验,平均识别率达到了 85%。

**关键词:** 步态识别;行为特征;胶囊网络;复杂背景;ICNet

**中图分类号:** TP75 **文献标识码:** A **国家标准学科分类代码:** 520.2

## Research on gait recognition of human body based on ICNet model

Zeng Wei He Gangqiang Luo Weiyang Guo Yiling

(School of Mechanical and Electrical Engineering, Chengdu University of Technology, Chengdu 610059, China)

**Abstract:** Gait recognition refers to the technology of identity verification by identifying the walking posture of pedestrians. Different from the physiological characteristics such as fingerprints and palmprint that need close contact, gait, as a behavioral feature, has the characteristics of high non-invasive, low camouflage and long-distance recognition. Therefore, gait recognition has broad application prospects in various fields. This paper proposes a gait feature recognition method based on capsule network, and introduces spatial attention mechanism in the capsule network to improve the weight of effective gait features in the capsule, and updates the input image through the design of feedback weight matrix to improve the performance. The designed gait recognition model based on capsule network has been tested on CASIA-B dataset. The average recognition rate is 93%, 85% and 67% respectively under three different walking conditions: normal walking, walking with bags and walking with coats. At the same time, a multi view gait recognition experiment is carried out on the OU-MVLP data set, and the average recognition rate reaches 85%.

**Keywords:** gait recognition; behavior characteristics; capsule network; complex background; ICNet

## 0 引 言

步态识别最初是心理学方面的研究,通过分析个人的行为动作研究个体心理状态。随着生物特征识别技术的兴起,基于步态的身份识别技术逐渐引起关注<sup>[1]</sup>。其中,美国国防部高级研究计划署在 2000 年资助了远距离身份识别的科研项目 HumanID,该项目的目标是通过生物特征开发人类的检测和分类识别系统,以应对恐怖主义的袭击<sup>[2]</sup>。在该项目的倡导下,步态作为一种远距离可识别的生物特征被纳入研究,为接下来的步态识别研究做出了贡献。其中,国外比较著名的学校有日本大阪大学、美国马里兰大学、南佛罗里达大学、南安普顿大学等。国内研究机构包括

中国科学院自动化研究所、山东大学、复旦大学、深圳大学等。目前基于步态识别开发了多种应用,其中有包括智能人脸步态智能检测、步态识别的意图感知、室内行人导航等<sup>[3-5]</sup>。

Kovac 等<sup>[6]</sup>从步态剪影图提取人体骨骼模型,并通过分析骨骼模型获取步态信号和具体的运动参数进行步态识别。Wu 等<sup>[7]</sup>提出了基于 CNN 的步态识别,对于多视角的步态识别,通过深度学习网络获取人体骨骼信息识别率优于同时期其他方法。Ramakic 等<sup>[8]</sup>提出一种从视频流中识别别人的算法,该算法由两个模块组成,一个模块用于创建数据集,另一个模块用于识别步态。Khan 等<sup>[9]</sup>提出一个非线

收稿日期:2021-11-05

\* 基金项目:国家重点研发计划项目(2018YFC1505102)资助

性视图转换模型的跨视角步态识别,该方法将步态描述符从多视点转换为单一视点,然后从不同视角采集的视频中学习单一视角的模型,并通过一个共享的高级虚拟路径将它们投影到一个单一的规范视角。

由于行人的步态是一种个体的规律性行为,容易被多种因素干扰。传统的研究方法通过对不同的步态识别数据集设置不同的单一变量条件采集相应的步态。而在不同的大型数据集中,主流的变量还包括观测视角的变化、行人衣物对步态的遮蔽情况、包裹的携带情况。本文设计了一种新型的人体步态识别算法模型,该算法模型不强调设置某一个单一的具体特征,而是利用胶囊网络对周期化的步态剪影序列实现步态特征的识别,并对胶囊网络进行反馈权重设计和优化设计改进,来提升步态识别率。

### 1 人体步态识别整体方案架构

本文设计了一种基于改进胶囊网络的人体步态识别模型——ICNet 模型。该方法在胶囊网络中引入空间注意机制,提升有效步态特征在胶囊的权重,又通过反馈权重矩阵的设计,更新输入图像,获得性能提升。

基于 ICNet 模型的步态识别框架包括普通卷积层、初始胶囊层、数字胶囊层,以及空间注意机制,如图 1 所示。普通卷积层保留了卷积神经网络(CNN)的特征提取特性<sup>[10]</sup>,抽取底层特征,然后将底层特征输入初始胶囊层,初始胶囊层识别步态的低级特征,然后将初始胶囊层和数字胶囊层通过路由算法连接,并将数字胶囊层的输出向量使用空间注意机制加强,最后使用全连接层和 SoftMax 函数得到识别结果。

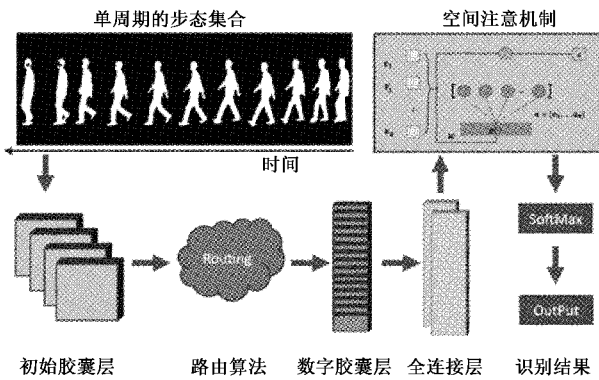


图 1 步态识别基本框架

## 2 改进胶囊网络模型——ICNet 模型

### 2.1 改进的空间注意机制

为了在胶囊网络的步态识别任务中,加强对重点步态特征区域的关注以及提高对步态特征信息的关注效率,在胶囊网络中添加空间注意机制。该方法可以增强局部的步态特征,提高胶囊网络对步态识别的跨视角识别能力和步态识别性能。采用的空间注意机制基本原理如图 2 所示。




图 2 空间注意机制

胶囊网络中  $\mathbf{V}$  中第  $j$  个元素的表达式如式(1)所示。

$$V_j = R^{1 \times E}, j = 1, 2, \dots, B \quad (1)$$

其中,  $\mathbf{V} = \{V_j\}_{j=1}^B$  是状态序列,并且  $\mathbf{V} \in R^{B \times E}$ , 通过将向量  $\mathbf{V}$  输入学习系统  $g(\cdot)$  得到注意力的中间权重,如式(2)所示。

$$e = g(\mathbf{V}) = \mathbf{VW} \quad (2)$$

其中,  $\mathbf{W} \in R^{E \times 1}$ , 利用注意力中间权重产生概率向量  $\mathbf{a} = [a_1, \dots, a_B]$ , 该向量维度是  $1 \times B$ 。该加权向量  $\mathbf{a}$  的第  $j$  个元素表达式如式(3)所示。

$$a_j = \frac{\exp(e_j)}{\sum_{k=1}^B \exp(e_k)} \quad (3)$$

输出的合成向量  $\mathbf{C}$ , 其中合成向量  $\mathbf{C}$  是空间注意机制处理后的加权特征的计算公式如式(4)所示。

$$\mathbf{C} = \sum_{j=1}^B a_j V_j \quad (4)$$

### 2.2 反馈权重的设计

为获得更高的性能,对胶囊网络进行反馈权重的设计。如图 3 所示为胶囊网络的向量神经元。




图 3 向量神经元

如图 4 所示,对输入向量  $\mathbf{u}$  进行仿射变换并得到新向量  $\mathbf{U}$ 。其中  $\mathbf{U}_i$  是特征  $i$  的位置向量,  $j$  是图像的一个实例,  $\mathbf{U}_{j|i}$  是从实例  $j$  中导出的特征  $i$  的位置向量。 $\mathbf{W}$  是实现这过程的仿射。因为指向同一个实例的特征不同,因此向量  $\mathbf{U}_{j|i}$  需要乘以权重  $\mathbf{C}$ , 然后形成加权求和向量。




图 4 胶囊网络反馈权重设计

胶囊网络反馈权重设计如图 4 所示,反馈权重矩阵更新输入图像部分,来提高步态识别的识别能力,提高系统模型鲁棒性。首先输入步态图像,然后从步态特征图像生成特征向量,并根据特征向量训练权重矩阵。将特征向量转换为权重矩阵的表达式用线性函数表示如式(5)所示。

$$f = \mathbf{W}^T v + b \quad (5)$$

其中,  $\mathbf{W}$  为线性矩阵,  $b$  是偏差,  $f$  和  $\mathbf{W}$  都可微,在不断迭代中,  $\mathbf{W}$  和  $b$  呈线性变化。从特征图像提取的特征向量表达式如式(6)所示。

$$\mathbf{v} = [\mathbf{v} = [v_1, v_2, \dots, v_N]] \quad (6)$$

对应的感受野公式如式(7)所示。

$$\mathbf{v} = [\mathbf{R} = [\mathbf{R}_1, \mathbf{R}_2, \dots, \mathbf{R}_N]] \quad (7)$$

其中,  $N$  是特征图像的像素个数,根据每个特征向量得到权重矩阵,输入层的最终权值矩阵是所有权值矩阵的和。其中卷积部分在一定程度上尝试提取步态特征,如图 4 所示,设置 3 个卷积层,卷积层提取细粒度的步态特征,并将这些特征进行了一定程度的综合。所有卷积核的大小是  $7 \times 7$ ,步长是 1,池化核大小是  $2 \times 2$ ,步长是 2,通过 ReLU 非线性函数激活和批标准化。改进后的胶囊网络将卷积后的数据重塑为向量神经元,并通过动态路由将实体特征更好地表示。

### 2.3 路由算法和损失函数的优化

如图 5 所示,是胶囊网络间的路由迭代过程。主要分为两部分,第 1 部分是胶囊  $u_i$  到预测向量  $u_{ji}$  的线性组合,第 2 部分是预测向量  $u_{ji}$  到胶囊  $j$  的总输入  $s_j$  的动态路由。

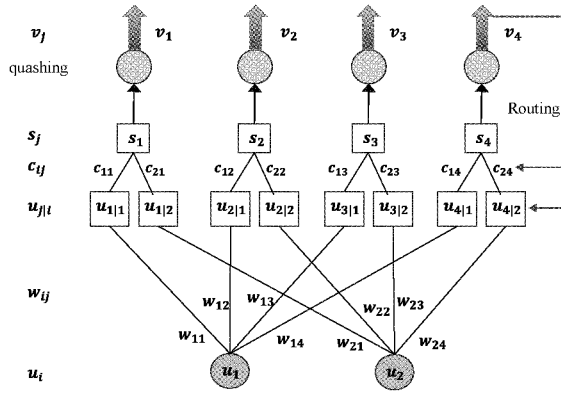


图 5 胶囊网络多的层间路由迭代

图 5 中,  $u_1$  和  $u_2$  作为输入向量,分别和权重矩阵  $\mathbf{W}_{ij}$  运算得到不同的预测向量  $u_{ji}$ ,即  $u_{11}$  和  $u_{12}$ 。然后对应的预测向量和耦合系数  $c_{ij}$  计算得到胶囊  $j$  的总输入  $s_j$ 。然后将  $s_j$  经过非线性压缩函数得到下一层胶囊的输出,至此路由算法完成。

胶囊网络的总损失采用边际损失函数进行优化,边际损失公式如式(8)所示。

$$L_k = T_k \max(0, m^+ - \|V_k\|)^2 + \lambda(1 - T_k) \max(0, \|V_k\| - m^-)^2 \quad (8)$$

其中,  $L_k$  代表第  $k$  类的边际损失,如果预测正确,并且  $m^+ = 0.9, m^- = 0.1$  那么  $T_k$  的值是 1,  $\lambda$  表示损失的降权,本文遵循胶囊网络的基础设置,  $\lambda$  为 0.5。

### 2.4 ICNet 模型优化策略

为了加快模型的收敛,模型在胶囊网络的卷积层采用批标准化,并采用了 Adam 优化算法。

#### 1) 批标准化

批标准化在机器学习中被证明是极其重要的理论。Ioffe 等<sup>[11]</sup>在 2015 年提出了批标准化的技术(BN),该技术解决了梯度消失和爆炸问题。这个技术是在模型每层的激活函数之前或之后增加一个操作,将每一个输入归零并归一化,并且每一层都使用两个参数向量对结果进行缩放和移动。

使用批标准化会降低模型的训练速度,但是批标准化可以加快模型的收敛速度,总体上时间消耗并没有显著增加。并且批标准化将神经元的输入调整为标准的正态分布,使得损失函数更加敏感,加大了梯度,同时加快了训练速度为了输入数据标准化,批标准化需要计算当前批次的平均值和标准差,评估每个输入数据的平均值和标准差,如式(9)~(12)所示。

$$\mu_B = \frac{1}{mB} \sum_{i=1}^{mB} x_i \quad (9)$$

$$\sigma_B^2 = \frac{1}{mB} \sum_{i=1}^{mB} (x_i - \mu_B)^2 \quad (10)$$

$$\tilde{x}_i = \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}} \quad (11)$$

$$z_i = \gamma \otimes \tilde{x}_i + \beta = BN_{\gamma, \beta}(x_i) \quad (12)$$

其中,  $\mu_B$  输入的平均向量,通过计算整个批次  $B$  得到,  $\mu_B$  是输入的标准差向量;  $mB$  是该批次中的实例数量;  $x_i$  是实例  $i$  以零点居中并标准化的输入向量;  $\gamma$  是神经网络层的缩放参数;  $\otimes$  表示每个输入和对应的输出缩放相乘;  $\beta$  是神经层的偏移参数;  $\epsilon$  是平滑项;  $z_i$  是批标准化后的输出,将输入缩放和移动的结果。

#### 2) Adam 算法

Adam(adaptive moment estimation)优化算法对于深度学习任务至关重要<sup>[12]</sup>。Adam 算法使用自适应学习率加快收敛速度,并且该算法结合了 Adagrad 和 RMSProp 两种算法的优点,具有实现简单,超参数可解释性以及初始学习率可限制等特点。Adam 算法使用的两种均值公式如式(13)、(14)所示。

$$m_i = \beta_1 m_{i-1} + (1 - \beta_1) \nabla J_{w_{i-1}} \quad (13)$$

$$v_i = \beta_2 v_{i-1} + (1 - \beta_2) \nabla J_{w_{i-1}} \odot \nabla J_{w_{i-1}} \quad (14)$$

$$\nabla J_{w_{i-1}} = -e_i u_i^T \quad (15)$$

其中,  $\beta_1$  和  $\beta_2$  是固定的常数,  $\beta_1 = 0.99, \beta_2 = 0.999$ ;  $\nabla J_{w_{i-1}} = -c_j u_i^T$  表示代价函数  $J$  对  $w_{i-1}$  求导;  $\odot$  表示向量的元素相乘;  $m_i$  是梯度的一阶矩,  $v_i$  是梯度的二阶矩估计,算法中,修正估计误差公式如式(16)、(17)所示。

$$\hat{m} = \frac{m_i}{1 - \beta_1^i} \quad (16)$$

$$\hat{v}_{i,j} = \frac{mv_i}{1 - \beta_2^i} \quad (17)$$

通过公式, Adam 算法的权重更新表达式如式(18)所示。

$$w_{i,j} = w_{i-1,j} - \frac{\mu}{\sqrt{\hat{v}_{i,j+\epsilon}}} \hat{m}_{i,j} \quad (18)$$

其中,  $\epsilon$  是一个较小的常数, 避免分式无意义, 本文取值设置为  $10^{-8}$ ,  $w_{i,j}$  表示  $i$  时刻的  $w_i$  的第  $j$  个分量。随着参数  $\hat{m}_i$  和  $\hat{v}_i$  的更新, Adam 算法自适应地对权重分量自适应调整。

### 3 实验结果与分析

#### 3.1 数据集

步态识别模型训练选用由中科院自动化所提供的 CASIA-B 步态数据集<sup>[13]</sup>, 总共包含 124 个行人(编号 001~124),

3 种行走状态, 包括正常(NM), 每个行人 6 个序列; 带包行走(BG), 每个行人两个序列; 穿外套(CL), 每个行人 2 个序列, 每个行人的每个序列都有 11 种观测角度, 角度范围( $0^\circ, 18^\circ, 36^\circ, \dots, 180^\circ$ ), 以  $18^\circ$  为一个刻度。因此每个行人包含序列总数为  $110(6+2+2) \times 11$  个序列。

步态识别模型实验选用日本大阪大学创立的多视角大型行人数据集——OU-MVLP 数据集<sup>[14-15]</sup>, 该数据集包含 10 307 个行人, 其中男性 5 114 人, 女性 5 193 人, 分布于不同的年龄段, 与 CASIA-B 数据集相比, 该数据集总共包含 14 个视角, 视角间隔  $15^\circ$ , 尽管人数更多, 视角更多, 但是该数据集却没有行人衣物、包裹携带等变量, 因此只适合于从视角因素对本文模型识别效果测试。

#### 3.2 实验配置

在 CASIA-B 数据集中, 按照训练集和测试集的大小不同, 设置 3 种实验模式, 分别是小样本模式 (small-sample model, SM); 中样本模式 (medium-sample model, MM), 大样本模式 (large-sample model, LM)。具体行人数据集分配比例如表 1 所示。

表 1 不同实验模式数据集分配比例

实验模式	训练集		测试集		
	行人 ID	行走条件	行人 ID	Gallery	Probe
—	—	—	—	Gallery	Probe
SM	001-024	NM01-NM06	025-124	—	NM05-NM06
MM	001-062	BG01-BG02	063-124	NM01-NM04	BG01-BG02
LM	001-074	CL01-CL02	075-124	—	CL01-CL02

本文使用 NVIDIA GPU 训练模型, 编程语言为 Python3.6, 实际训练时, 选择 Adam 优化器, 批处理大小为 30, 学习速率为  $1 \times 10^{-4}$ 。对于不同训练模式, 设置不同的迭代次数。

#### 3.3 不同行走状态步态识别测试

在现实生活中, 同一个人的步态序列很有可能是在不

同的行走条件下。为模拟这种情况, 本文在同一个视角, 不同行走条件的两个步态剪影序列里选择步态图作为特征输入。实验室环境测试步态如图 6 所示。

#### 3.4 ICNet 模型性能测试

##### 1) CASIA-B 数据集实验分析

设置不同迭代次数, 进行不同训练时期的步态识别准




图 6 不同行走状态下的步态识别测试

确率对比, 实验结果如图 7 所示。在到达 350 个训练时期后, 不同行走条件下的步态识别率趋于平滑。识别率从高到底分别是  $NM > BG > CL$ , 识别率分别是 93%、85%、67%。

按照表 1 所述的 3 种实验模式进行实验, 模型在 CASIA-B 数据集的 Rank-1 准确率如表 2 所示。表 2 中 Probe 准确率是排除相同 Gallery 视角的平均值。例如 Probe54° 的准确率是排除了 Gallery54° 视角的准确率的平




图 7 在不同训练时期下, 在不同行走条件下的识别率

均值。表中 Gallery 视角不做区分,统计不同 Probe 视角时的步态识别准确率。

表 2 模型在 CASIA-B 数据集的 Rank-1 准确率

Probe		%										
实验模式	Probe	0°	18°	36°	54°	72°	90°	108°	126°	144°	162°	180°
SM	NM	64.6	83.3	90.4	86.5	80.2	75.5	80.3	86.0	87.1	81.4	59.6
	BG	55.8	70.5	76.9	75.5	69.7	63.4	68.0	75.8	76.2	70.7	52.5
	CL	29.4	43.1	49.5	48.7	42.3	40.3	44.9	47.4	43.0	35.7	25.6
MM	NM	86.8	95.2	98.0	94.5	91.5	89.1	91.1	95.0	97.4	93.7	80.2
	BG	79.9	89.8	91.2	86.7	81.6	76.7	81.0	88.2	90.3	88.5	73.0
	CL	52.0	66.0	72.8	69.3	63.1	61.2	63.5	66.5	67.5	60.0	45.9
LM	NM	90.8	97.9	99.4	96.9	93.6	91.7	95.0	97.8	98.9	96.8	85.8
	BG	83.8	91.2	91.8	88.8	83.3	81.0	84.1	90.0	92.2	94.4	79.0
	CL	61.4	75.4	80.7	77.3	72.1	70.1	71.5	73.5	73.5	68.4	50.0

2) OU-MVLP 数据集实验分析

由于 OU-MVLP 数据集只具备视角协变量,因此在该数据集只进行多视角的测试。OU-MVLP 数据集视角示意图如图 8 所示。

模型在 OU-MVLP 数据集的 Rank-1 准确率如表 3 所示。

3) 模型性能对比

为了更直观地对比步态识别模型的性能,将本文模型和 MGAN 模型以及 Gait-Net 进行对比,考虑不同模型在不同行走条件下的识别率,计算不同视角下的平均识别率,结果如图 9 所示。在 NM 条件下,MGAN 和 Gait-Net 和本文的模型识别率差异不大,并且 MGAN 方法平均识别率最低,但是 3 个模型在 NM 的识别率差别不大。在




图 8 OU-MVLP 数据集视角示意图

表 3 模型在 OU-MVLP 数据集的 Rank-1 准确率

视角		%				
Probe	全部视角	0°	0° + 30°	0° + 60°	0° + 60° + 90°	0° + 30° + 60° + 90°
0°	77.5	69.8	69.5	71.3	73.5	75.1
15°	85.9	65.8	77.5	78.8	79.5	84.1
30°	87.8	60.2	80.7	70.5	75.6	83.7
45°	88.5	61.3	62.3	68.7	72.6	86.7
60°	86.4	63.2	65.4	77.5	78.9	82.1
75°	86.6	59.9	60.1	62.1	70.2	85.3
90°	85.5	65.1	66.6	71.1	79.8	81.4
180°	79.3	67.5	68.1	74.3	75.6	78.1
195°	84.6	62.5	71.3	73.2	77.6	80.1
210°	87.1	59.9	78.8	78.1	80.9	85.4
225°	87.2	60.4	61.2	66.8	73.8	84.5
240°	84.4	62.8	65.2	78.0	79.0	82.8
255°	84.6	57.8	60.2	61.8	71.5	83.2
270°	85.2	67.4	64.8	70.4	83.0	83.0

BG 行走条件下, MGAN 模型识别率低于本文和 Gait-Net, 在影响最大的 CL 条件下, 本文模型的识别率优于其他两种模型。平均识别率可达到 50% 以上。




图 9 不同模型综合识别率对比

图 9 体现了相较于 MGAN 和 Gait-Net, 本文模型在步态特征的识别上具有优异性。

## 4 结 论

步态识别作为一种远距离的身份识别方式, 由于自身的识别特点, 可以应用于大多数场合。本文提出了一种基于 ICNet 网络模型的步态识别模型。在传统胶囊网络中引入空间注意机制, 提升有效步态特征在胶囊的权重, 并且对反馈权重矩阵进行设计, 更新输入图像, 获得性能提升。在 CASIA-B 数据集中, 在正常行走(NM)、带包行走(BG)、大衣行走(CL)3 种条件下, 不同 Probe 视角的平均识别率分别是 93%、85%、67%。在模型性能对比中, 本文模型实现了较高的识别精度, 并在干扰条件下识别率最高, 其中在 CL 条件下, 平均识别率也可达到 67%, 明显优于 MGAN 和 Gait-Net 两种模型。并且在 OU-MVLP 数据集中, 全部视角的平均识别率可达到 85%。步态识别的应用场景是身份认证领域, 步态识别作为一种身份识别手段, 接下来的工作可以研究步态反映的医疗信息, 或者在医疗康复领域的研究。例如对病患的步态分析, 分析病患身体情况, 研究后续的医疗康复服务。

## 参考文献

- [1] STEVENAGE S V, NIXON M S, VINCE K. Visual analysis of gait as a cue to identity [J]. *Applied Cognitive Psychology*, 1999, 13(6): 513-526.
- [2] PHILLIPS P J. Human identification technical challenges [C]. In: *Proceedings of the 2002 International Conference on ImageProcessing*, New York, USA: IEEE, 2002, 49-52.
- [3] 高经纬, 马超, 姚杰, 等. 基于机器学习的人体步态检测智能识别算法研究[J]. *电子测量与仪器学报*, 2021, 243(3): 49-55.
- [4] 贾晓辉, 王涛, 刘今越, 等. 基于人体模型映射的步态识别及意图感知方法[J]. *仪器仪表学报*, 2020, 41(12): 236-244.
- [5] 胡叶, 张爱军. 基于 K-means 的室内行人导航步态识别方法[J]. *国外电子测量技术*, 2021, 316(3): 32-36.
- [6] KOVAC J, PEER P. Human skeleton model based

dynamic features for walking speed invariant gait recognition[J]. *Mathematical Problems in Engineering*, 2014(6): 15, DOI:10.1155/2014/484320.

- [7] WU Z, HUANG Y, WANG L, et al. A comprehensive study on cross-view gait based human identification with deep CNNs [J]. *Feb*, 39(2): 209-226.
- [8] RAMAKIĆ A, BUNDALO Z, BUNDALO D. A method for human gait recognition from video streams using silhouette, height and step length[J]. *Journal of Circuits, Systems & Computers*, 2020, 29(7): 316-322.
- [9] KHAN M H, FARID M S, GRZEGORZEK M. A non-linear view transformations model for cross-view gait recognition [J]. *Neurocomputing*, 2020, 402(1): 100.
- [10] AJIT A, ACHARYA K, SAMANTA A. A review of convolutional neural networks[J]. *2020 International Conference on Emerging Trends in Information Technology and Engineering (ic-ETITE)*, 2020: 1-5.
- [11] IOFFE S, SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[J]. *Proceedings of the 32nd International Conference on Machine Learning*, PMLR, 2015: 448-456.
- [12] SINGARIMBUN R N, NABABAN E B, SITOMPUL O S. Adaptive moment estimation to minimize square error in backpropagation algorithm[J]. *2019 International Conference of Computer Science and Information Technology (ICoSNIKOM)*, 2019: 1-7, DOI:10.1109/ICoSNIKOM48755.2019.9111563.
- [13] SHIQI Y, DAOLIANG T, TIENIU T. A framework for evaluating the effect of view angle, clothing and carrying condition on gait recognition[J]. *International Conference on Pattern Recognition*, IEEE, 2006: 441-444.
- [14] TAKEMURA N, MAKIHARA Y, MURAMATSU D, et al. On input/output architectures for convolutional neural network-based cross-view gait recognition[C]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2019, 29(9): 2708-2719.
- [15] IWAMA H, OKUMURA M, MAKIHARA Y, et al. The OU-ISIR gait database comprising the large population dataset and performance evaluation of gait recognition[J]. *IEEE Transactions on Information Forensics and Security, Information Forensics and Security*, IEEE Transactions on, IEEE Trans. Inform. Forensic Secur., 2012, 7(5): 1511-1521.

## 作者简介

曾维, 工学硕士, 副教授, 主要研究方向为计算机视觉目标检测、边缘服务器和人工智能技术应用等领域研究。

E-mail: zw@cdu.edu.cn

何刚强, 硕士研究生, 主要研究方向为智能硬件平台和图像处理等领域研究。

E-mail: hegangqiang@stu.cdu.edu.cn

罗伟洋, 硕士研究生, 主要研究方向为图像处理和嵌入式等领域研究。

E-mail: 917300514@qq.com