

基于改进人工神经网络的人体姿态识别方法在人机交互医疗设备中的应用

代维利

(海军青岛特勤疗养中心, 山东 青岛 266071)

摘要: 为提升人机交互医疗设备对久坐不动、常年卧床等状态下人体的监测效果, 在利用无线体域网建立人体姿态识别系统的基础上, 设计了相应的改进人工神经网络与无线体域网系统进行融合, 并将其应用于人机交互医疗设备中; 结果表明, 在HiEve数据集中, 该方法于20次迭代时开始收敛, 损失函数值为0.0112; 在患者不同姿势的识别验证中, 该方法下的人机交互医疗设备识别准确率均显著高于90%, 并且耗时最短仅为23.16 s, 具有较高的识别准确率和效率, 为人体姿态识别及相关医疗设备的应用提供了更为可靠的技术参考。

关键词: 改进人工神经网络; CNN; 无线体域网; 人体姿态识别; 人机交互; 医疗设备

Application of Human Pose Recognition Method Based on Improved Artificial Neural Network in Human-machine Interactive Medical Devices

DAI Weili

(Navy Qingdao Special Service Convalescent Center, Qingdao 266071, China)

Abstract: In order to improve the monitoring effect of human-computer interactive medical equipment on human body under the conditions of being sedentary and bedridden all the year round, wireless body area network (WBAN) is used to establish a human body posture recognition system, based on this, an improved artificial neural network is designed to fuse with the WBAN system, which is applied to the human-computer interactive medical equipment. The results show that in the HiEve dataset, the method starts to converge at 20 iterations, and the Loss function value is 0.0112. In recognition verification on the different postures of patients, the human-machine interaction medical device recognition accuracy of this method is significantly higher than 90%, and the shortest time is only 23.16 s. It has high recognition accuracy and efficiency, providing a more reliable technical reference for the human posture recognition and related medical device applications.

Keywords: Improving artificial neural networks; CNN; wireless body area network; human pose recognition; human-computer interaction; medical equipment

0 引言

近年来, 人体姿态识别研究逐渐成熟, 在视频的智能分析、虚拟现实、人机交互、视频摘要、视频信息检索与运动分析方面都具有广阔的应用前景。姿态识别已经成为深度学习领域的研究热点之一, 深度学习算法的研究推动了姿态识别研究的进步^[1]。而信号采集与无线技术迎来了新的发展高峰。在人们日益关注自身健康的当下, 身体各项指标的准确监测成为医学领域的研究重点之一。在该背景下, 有学者提出无线体域网 (WBAN, wireless body area network)^[2]。WBAN属于短距离、小型的无线传感器网络, 汲取了无线通信与微机电系统的共同优势。该项技术主要应用在人体周围, 通过各类传感器信息的采集, 能够实现人体生命和姿态信息的监测, 已经在医疗领域取得了巨大

的成功^[3]。在WBAN技术中, 人体姿态识别能够对患者状态进行实时准确地监测, 对于医学诊断及辅助治疗具有重要意义^[4]。但在实际应用中, WBAN具有高动态特性, 当人体姿态出现改变时, 信号采集和传输同样也会发生变化, 这就要求二者无形之中必须具有较高的适应性。同时计算机视觉领域中人体姿态识别已然成为当今最具有挑战性的研究方向。随着各国科技公司推出深度学习传感设备后, 基于深度图像的人体姿态识别技术开始受到广泛学者的关注。但由于人体姿态与动作的复杂度较高, 利用深度图像特征与骨骼关键点提取的维度也较高, 无法对图像进行较为准确的预处理。此时人工神经网络 (ANN, artificial neural network) 与卷积神经网络 (CNN, convolutional neural networks) 应运而生, 并在相关领域得到了广泛的应用与关注^[4]。黄展原等学者为了对老人摔倒进行有效监测,

收稿日期: 2023-07-13; 修回日期: 2023-07-18。

作者简介: 代维利 (1984-), 男, 大学本科, 副主任技师。

引用格式: 代维利. 基于改进人工神经网络的人体姿态识别方法在人机交互医疗设备中的应用[J]. 计算机测量与控制, 2024, 32(1): 245-250.

同时降低相关设备的成本与制作问题,提出一种基于 2D 视频的摔倒监测算法。通过 3 个公共摔倒数据集测试显示,该算法是可行的并能够有效提高监测效率^[5]。孙月驰等人提出一种基于优化 CNN 的人体行为动作识别算法,以有效应对复杂图像中人体姿态识别不准的问题。过程中通过构嵌 Maxout 多层感知网络结构实现增强 CNN 的特征提取能力。结果表明,该方法对人体行为与动作识别有较高准确率^[6]。金玮等研究人员将 CNN 与高速通信技术相互融合并应用于人体姿态识别当中,以应对病人跌到能够及时获得救助。数据显示,该方法对人体姿态的识别准确率高达 99.75%,同时具有百分百的敏感度,能够准确对人体跌到进行检测^[7]。邓平与吴明辉将多信息融合的特征筛选方法与人体姿态修正相结合,以应对传统人体姿态识别算法识别精度不足等问题。结果表明,通过修正后该算法对人体姿态识别的精度高达 99.67%,同时能够以较少的特征数目获得更准确的姿态分类^[8]。从以上相关研究可知,对人工神经网络的改进集中在不同领域的方方面面,但仍无法满足医疗设备所需要的高效率与高准确性的要求,网络与智能算法相结合的技术更新亟待解决。鉴于此,研究在 WBAN 人体姿态识别系统的基础上,结合改进 ANN 自适应学习与高速寻优等特点,将其应用于人机交互医疗设备系统中,以期进一步提高医疗设备人体姿态识别的应用效果。

1 基于改进 ANN 的人体姿态识别系统在人机交互医疗设备中的研究

1.1 基于 WBAN 的人体姿态识别系统的构建

人体在地面时有静止与相对运动的两个状态。当一个人处于相对静止的状态时对应的坐标系为自然坐标系;而当一个人发生相对运动时对应的坐标系则为动态坐标系^[9]。在自然坐标系中,人体向上从头到脚的垂直站立方向被定义为 X 轴的正方向;而人体朝着水平方向左边则为 Y 轴的正方向;人体脸部朝前的方向则被看做是 Z 轴的负方向。于是,重力加速度 G 的方向与 X 轴的方向实际上是一致的。另一方面在动态坐标系中,不管任何时间任何地点以及任何方向,更不管人体处在何种状态,均选择人体从脚到头的方向向量作为 X 轴的正方向;Y 轴与 Z 轴的方向选取与自然坐标系相同。为了对人体的不同姿态特征进行提取,通常利用 4 种不同的特征参数向量对运动中的人体姿态进行目标检测与识别。通过系统计算与采集得到 3 个轴的加速度值,同时引入支持向量机(SVM, signal vector magnitude)对其进行平方计算操作后再取值。得到的数值对应表示人体正在进行的不同强度运动。随着运动的剧烈程度的增大其数值也逐渐增大,可以初步对人体运动是否剧烈进行判断。利用恰当的阈值对人类运动进行判断,并对人体运动状态进行分类。具体计算见式(1)。

$$SVM = \sqrt{a_x^2 + a_y^2 + a_z^2} \quad (1)$$

式(1)中, a_x, a_y, a_z 对应代表 Z、X 与 Y 轴的加速度。同时当人体围绕着 X 轴进行旋转时,向左转是正向角度参数,

此时 θ_x 作为航向角。当人体围绕 Y 轴旋转时, θ_y 作为俯仰角。当围绕 Z 轴进行旋转时,向后退则是正向角度参数, θ_z 表示横滚角。对不同的坐标轴角度的极差进行分析,并以此计算在同一个采样时间内人体运动姿态旋转过的最大角度(R_x, R_y, R_z)。以通过 WBAN 系统采集得到的角度数据为基础数据进行实验计算,能够对运动着的人体是否发生弯腰或跌倒情况做出合理的判断。具体计算见式(2)。

$$R_y = \theta_{y\max} - \theta_{y\min} \quad (2)$$

式(2)中, θ_{\min} 与 θ_{\max} 是指在对数据单位进行采集过程中对应得到的最小值与最大值。同时由于实验所采取的硬件系统能够对人体姿势进行实时的采集,将人体坐标系三轴的角加速度设置为 ω 。不同人所发生的姿态动作在相同的时间内是不尽相同的,因此围绕着人体旋转所产生的转动角度与速度也不相同,这就表示着对应的坐标系也不相同。日常生活中,当一个人身体发生十分剧烈的晃动时,那么很有可能是该患者罹患了中风或脑卒中而产生的身体抽搐。因此当面临这种情况时,及时地对患者进行监测能够有效帮助医生更为快速且准确地判断得到该病患的情况。在对患者进行实时检测时对应的极差 r 计算见式(3)。

$$\begin{cases} \omega = d\theta/dt \\ r = \omega_{\max} - \omega_{\min} \end{cases} \quad (3)$$

式(3)中, ω 与 θ 分别表示人体发生转动时的角加速度与转动的角度;而 t 是指间隔无限小的时间段; ω_{\min} 与 ω_{\max} 分别表示在对数据进行采集的过程中所对应的角速度的最小值与最大值。其中人体的不同姿态会根据不同加速度而产生不同的位置移动,医生可以根据该位移为病人的复检情况做出合理的判断,同时为该病患合理规划并建议运动方式与运动量。将三维空间内 3 个轴所产生位移的量看做计算姿态检测参量的重要参数,具体计算出见式(4)。

$$S = \iint a dt \quad (4)$$

式(4)中,a 表示人体在运动时任意一个数轴产生的加速度;S 表示人体姿态运动时数轴所产生的位移。综合得到人体运动时姿态多级分层的识别算法。该算法主要是服务于应用无线体域网时对人体不同姿势与动作的识别。具体的识别过程见图 1。

图 1 中可以发现整个人体姿态多级分层识别共分为三各阶段。在第一阶段,研究选择 SVM 值作为决策依据,并根据实验数据的数值设定合适的阈值 a。将得到的阈值作为基础依据,假设共有慢走(Walk)、蹲(Squat)、坐(Sit)、跑步(Run)和弯腰(Stoop)5 种姿态,将这 5 种姿态通过分类初步定义为非剧烈运动与剧烈运动。当人体发生运动时,若运动过程中的某一个姿态连续 30 毫秒内不间断并持续的出现 3 个波峰采样点的数值一直大于阈值时,则将该姿态判别为跑步,并定义为姿态 A1。若这一姿态的波峰采样点小于阈值时则将该姿态判别为坐、蹲、弯腰和走,并下定义为姿态 A2,进而有效识别出相应的跑步姿态。接着进入到第二阶段,在该阶段实验将 Y 轴方向姿态发生的角

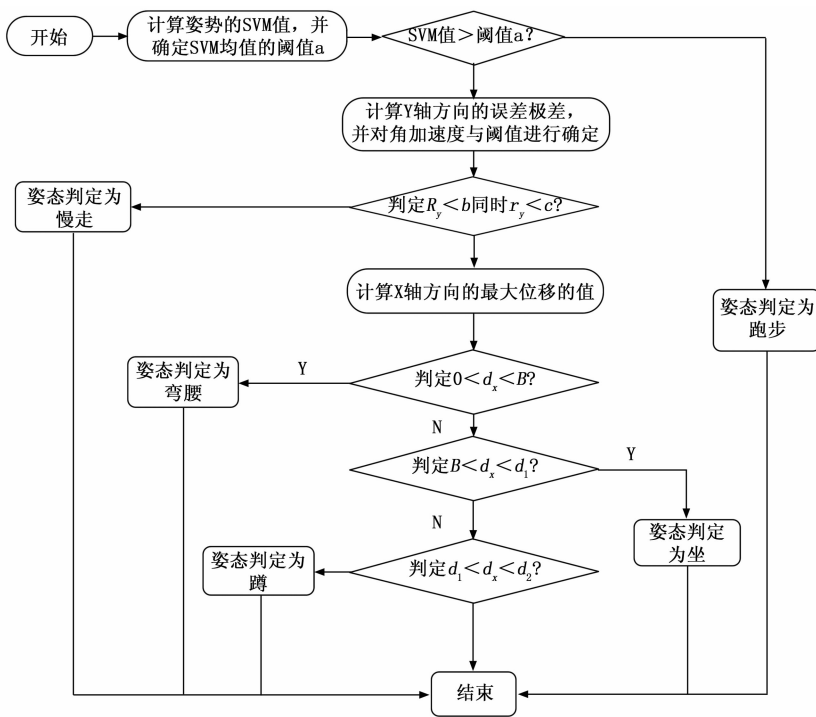


图 1 人体姿态多级分层识别算法流程

度的极差 R_y 与该纵轴方向上角加速度的极差 r_y 看作是判断依据。当人体进行运动时，会产生不同的姿态。这些不同的姿态所拥有的特征不尽相同。在姿态 A2 当中，当人体发生慢走运动时，3 个角度 $\theta_1, \theta_2, \theta_3$ 的值并不会发生较大的变化，甚至看作并没有任何变化发生。因此计算得到的 Y 轴方向的 R_y 与 r_y 的数值都会较小。相反，当人体姿态处于弯腰、蹲下以及坐下 3 个状态时，两个极差 R_y 与 r_y 的数值均会有较大的变动。因此将实验所设定的角加速度阈值 c 与角度对应的阈值 b 可知，当极差 R_y 大于角度阈值同时极差 r_y 大于角加速度阈值时，将对应的人体姿态判定为弯腰、蹲下以及坐下，并将其定义为姿态 B1。而其他的阈值比较情况则判定为人体处于慢走状态当中，并将其下定义为姿态 B2。当第二阶段的人体姿态识别结束即可识别出慢走状态。最后便是第三阶段。在该阶段中，研究人员将实验所得数据当中位于 X 轴方向上的加速度展开两次积分操作，进而得到人体在 X 轴方向上的位置移动的量 d_x 作为判断依据。人体处于弯腰姿态时，相对于腰部直立时的状态而言，腰部弯曲时的位移几乎不会因人为因素而变化。但当人体姿态由站立姿转变为坐姿时，其腰部发生的位移应当显著小于其大腿的长度 d_1 。当人体从站立的姿势转变为蹲坐姿势时，其腰部对应发生的位移应当大于其大腿的长度 d_1 但小于整个大腿腿部的长度 d_2 。根据上述所有特点可知，实验选取在 X 轴方向上的位置移动阈值可以对姿态进行有效区分，进而识别出不同的对应姿态。

1.2 基于 CNN 与无线体域网的人机交互医疗设备人体姿态识别模型的设计

现实生活中 WBAN 被广泛应用于人体可穿戴设备，这

一举措便要求人体姿态识别算法在设计的过程中能够尽量地降低人为干预所带来的影响，即在训练后能够自动地产生相应的拓扑结构。该方法不需要人工选取并设置门限，即可对人体新姿态进行识别。但 WBAN 在实际运行的过程中存在有大量的人为工作，识别率较高但应用价值较低。CNN 隶属于 ANN 的一种，是在 ANN 算法的基础上改进得到的。CNN 拥有深层神经网络的前馈神经网络，具有较强的容错、自适应学习及并行计算能力。近年来 CNN 广泛应用于处理分类和识别问题，特别是人脸识别、辅助医疗诊断、自动驾驶系统等领域，极大程度上促进了深度学习快速发展和推广应用。鉴于此，研究提出利用改进卷积神经网络模型对 WBAN 算法进行改进，并进行人体姿态识别算法，并期待有效减少人为设定算法的拓扑结构，最终实现算法可靠性^[10]。CNN 网络的构建与训练是分步骤进行的，CNN 网络构建的流程如下。第一层为网络输入层，即 input 层。由于 CNN 网络能够进行自我学习，当输入图像为深度图像，便可以将其作为网络的输入。

接着将卷积层定义为 C_x ，该卷积层通过 $n \times n$ 的滤波器大小（即卷积核或窗口大小）与偏置值相加再进行卷积操作，便能够得到特征图 N 个。卷积网络的下采样层则被定义为 S_x 。在不同的邻域区域内对图像上的 4 个像素进行求和，并加入卷积核元素进行加权操作，另外加上偏置值，并通过激活函数 sigmoid，以得到一个大小约缩小 4 倍的特征映射图 S_{x+1} 。对应得到的一层卷积层与下采样层的过程实现见图 2。




图 2 一层卷积层与下采样层的过程

实验所设计的改进卷积神经网络模型是设计一共可以分为 4 个步骤。首先对卷积网络层数进行选取。CNN 特征提取实际上是一个从低级到高级的抽取过程。当前面的卷积层所提取的是研究图像中层次较低的特征，那么后面的卷积层再增加时，特征的提取便会开始变得越来越抽象化。从这个角度来看，如果网络层级过少，可能会引入大量的干扰信息，而无法准确反映图像的关键特征。然而，如果网络层级过多，虽然能够获得图像的高级抽象特征，但随着层级的增加，有效信息的损失也会逐渐增多，这可能会导致无法获取最优的特征信息。但由于所选取的深度图像所包含的信息较为单一，那么特征的提取便会逐渐明显。

因此在总体上，CNN 网络并不需要太多的层次便可以实现对图像中的关键特征信息的提取。有学者研究发现，当 CNN 网络层数为 5，而其他条件不变的情况下，此时模型中的网络便可以实现快速地拟合与收敛，同时拥有较高的识别速度与准确性。接着是对滤波器个数进行选取。鉴于输入图像为深度图像时，所包含的数据信息会较为准确，因此实验采用简单的线性滤波器便能够有效提取图像中的关键特征^[11]。滤波器的个数选取会影响分类的效果和效率。若滤波器个数较少，产生的特征图就会减少，可能导致特征提取不全面；反之，滤波器个数过多，需要处理的特征图数量也会相应增加，既会降低处理速度，又可能引入许多无用的特征。因此，在权衡速度与准确性的考虑且大量实验数据表明，在以准确性为首要考量的情况下，当滤波器的个数选取为 6 个时，CNN 网络可以达到较高的效率。然后选择合适的滤波器大小。实际上，滤波器是一种可以处理信号以改善其性质或提取有用信息的电子设备或软件工具。在电子和通信工程中，滤波器主要用于消除某些不需要的频率或保留某些所需频率。其运作原理基于对频率的选择性，即对某些频率响应强烈，对其他频率则响应弱或无响应。综合考虑各方面因素后，实验滤波器大小（即卷积核尺寸）选取为 5×5，它在提取特征方面效果良好，并能保持较快的特征提取速度。最后选取 tanh 函数作为激活函数。一般的激活函数输出数据时并没有稀疏性，这会导致过程中生成大量的稀疏数据。因此需要在实验过程中设定一些惩罚因子以避免这种情况的产生。通过进行无监督训练，筛选排除掉一大堆接近于 0 的冗余数据，避免由于梯度消失问题而影响收敛速度。然而 ReLU 函数是一种线性修正函数，其根本作用在于若计算得到的数值比 0 小，便将其设置为 0，否则设置为原始数值。经过实践验证，训练后得到的改进 CNN 网络具备有适当的稀疏性，能够满足要求。同时，训练后的 CNN 网络可视化效果与传统方法训练得到的效果十分相似，这表示所选取 tanh 函数在进行适当计算的同时还能够有效提升收敛速度。最终综合上述原理，实验选取 3D-CNN 与 WBAN 相互结合，共同优化人体姿态识别系统。姿态识别的整体过程见图 3。

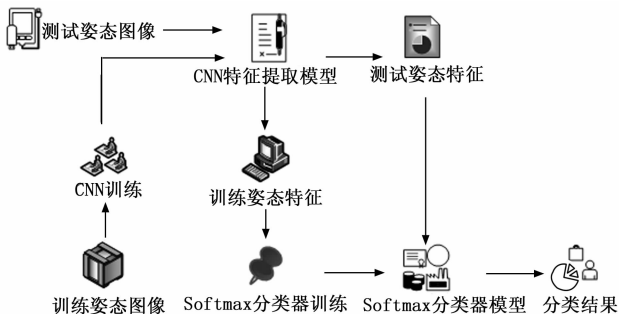


图 3 姿态识别的整体过程

图 3 中整个姿态识别流程包括以下几个步骤。首先，采集样本图片并对应做好标记，接着，对每种类型的姿态训练样本进行分类，并输入到 CNN 以进行模型训练，适时

调整网络以实现收敛。然后，将输出层更改为 softmax 分类器，并将测试图像作为输入。最后，对识别结果的准确性进行验证和评估。其中 3D-CNN 在对时空两个维度上的特性进行计算的同时，还能够运用 3D 卷积核对多幅图片与多个视频进行处理。因此，卷积层中的特征图均会与上一层连续多帧的图像相互关联。具体计算见式（5）。

$$v_{ij}^{xyz} = \tanh \left(b_{ij} + \sum_{p=1}^{P_i} \sum_{q=1}^{Q_i} \sum_{r=1}^{R_i} \omega_{ijm}^{pqr} v_{(i-1)m}^{(x+p)(y+q)(z+r)} \right) \quad (5)$$

式（5）中，tanh 表示激活函数； b_{ij} 代表卷积层上特征图所产生的偏移量； P_i, Q_i 代表卷积层上卷积核的空间维度对应尺寸； R_i 代表卷积核上时间维度的尺寸； ω_{ijm}^{pqr} 代表当下时刻卷积核在时刻特征图上位置 p, q, r 与上一层卷积核的第 m 个特征图相互连接所对应的权重。为了减少三维卷积在运行过程中的计算量，将传统的二维池化拓展至三维池化，不仅能够有效降低网络的计算量，同时还能够提升网络在时间维度上的鲁棒性^[12]。假设卷积区域为 $S_1 \times S_2 \times S_3$ ，那么采用最大值池化方式的三维池化计算见式（6）。

$$y_{ml} = \max_{\substack{0 \leq i \leq S_1, 0 \leq j \leq S_2, 0 \leq k \leq S_3}} (x_{m \times s + i, n \times i + j, i \times r + k}) \quad (6)$$

式（6）中， x 代表三维空间上的输入向量； y 代表三维池化层对应的输出结果； s, t, r 表示三维池化操作在 3 个维度上所产生的步长。通过计算可知，经过 3D 维度池化操作后，可以有效地降低网络的时空尺寸，进而极大地降低网络的计算复杂度，同时池化操作融合后的网络在时空维度上的鲁棒性均有显著提升。研究所设计的 3D 卷积网络的第一层为输入层，该层采用的图像帧的参数设置为 7 帧分辨率 60×40 ，第二层网络则为硬线层，他的主要功能在于能够从图像中提取出灰度与水平方向上的光流等。具体结构见图 4。




图 4 3D-CNN 网络结构图

图 4 中可以看出在硬线层后是一个 3D 卷积层。在此基础上，实验将对每一条不同的信道进行 3D 卷积运算，并通过运算操作获得对应的特征图。由于时域卷积核的大小为 3，因此在经过卷积运算后，得到的 5 条信道的特征图时间维度分别为 5, 5, 5, 4, 4。接着是一个二维卷积层，其卷积核的大小均为 2×2 ，这一操作使得经过卷积运算后的特征图的对应数目不会发生改变，而特征图的尺寸却从 54×34 变为 27×17 。在结构池化层 S3 后紧接着一个 3D 卷积层。经过 C2 层的处理后可以得到两组特征图；而经过 C4 层的处理后可以得到特征图 78 张，共 6 组。在 S3 层后的卷积层为 2D 池化层，将其命名为 C4，卷积核大小约为 3×3 ，因此在经过池化操作后，每组特征图的大小均为 7×4 ，且

数目保持不变。最后一层则为 C6，其中具有 128 个神经元，该层的输入是通过 S5 层卷积操作后输出的，其中 S5 的卷积核大小为 7×4 ；C6 将 S5 层输出的 78 个特征图进行全连接，最后得到 128 维度的特征向量。整个 CNN 运行过程中，选用的双曲正切函数为 $\tanh(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$ 。

2 医疗设备中人体姿态识别系统的性能测试与应用效果分析

为了验证研究所构建方法能够对人体姿态进行识别，并准确地应用于人机交互医疗系统设备中，研究对所构建平台的实际性能与应用效果进行分析，期待能够为医疗行业的发展提供一定的支持。开展实验所使用的服务器平台配置如下：实验硬件环境为 Intel i5 处理器，16 G 内存，1T 硬盘，编程环境基于 Python；操作系统为 Windows 10；中央处理器为 Intel Corei7-4590；数据储存系统为 MySQL data bank；GPU 型号为 GTX1080Ti 11Gx4；CPU 型号为 Intel Xeon E5-2665x2。实验选取 HiEve 与 Human3.6 M 两个公开的人体姿势数据集进行人体姿势识别的仿真实验。所有实验环节均在相同的设备环境中进行。研究将改进 SVM 模型、RCNN 模型与 CNN-Apriori 模型与研究模型进行不同性能指标的比较。首先对比不同算法的收敛速度，具体结果见图 5。




图 5 不同算法收敛速度对比

图 5 (a) 是在 HiEve 数据集上的测试结果。曲线变化显示，当迭代次数为 20 次左右，研究方法开始趋于平稳，同时对应 0.011 2 的损失函数值；与此同时其他两种算法的损失函数值均显著高于 0.03。当迭代次数进行到第 40 次时，RCNN 模型与 CNN-Apriori 模型开始出现有最小损失值，数值分别为 0.025 8 与 0.026 7。图 5 (b) 是在 Human3.6 M 数据集上的测试结果。可以发现当迭代次数在第 30 次附近时，研究方法便有最小损失值函数值，此时其余算法在迭代进行到第 50 次左右才能够有最小值。对比以上结果可知，在相同的时间长度内研究方法能够更为快速达到最小收敛度，具有更为快速的收敛速度。这也表示研究方法对数据的分析与计算过程效率会更高，并且有着较为广泛的普适性。接着对 4 种模型的 AUC 值进行对比，具体见图 6。

图 6 中可以看出，与其他方法相比，研究方法的 ROC 曲线下面积显著较大。研究方法、RCNN 模型、文献 [13]

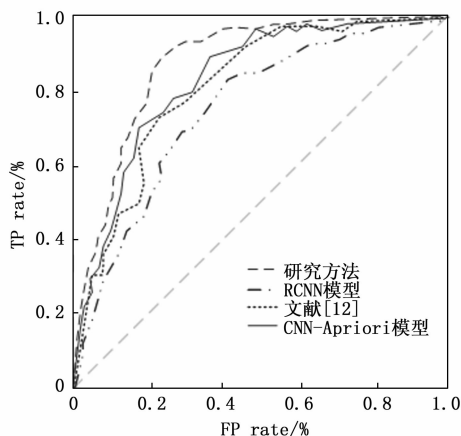


图 6 4 种模型的 ROC 曲线

与 CNN-Apriori 模型对应的 ROC 曲线占据面积为 0.897、0.856、0.789 与 0.754。以显著性原理为基础可知，研究方法的 AUC 值最大，在对人体姿势进行识别的过程中得到的识别效果较好，具有较高的真实性。为了丰富研究方法的实际效果，研究对不同算法的准确率进行分析，具体见图 7。

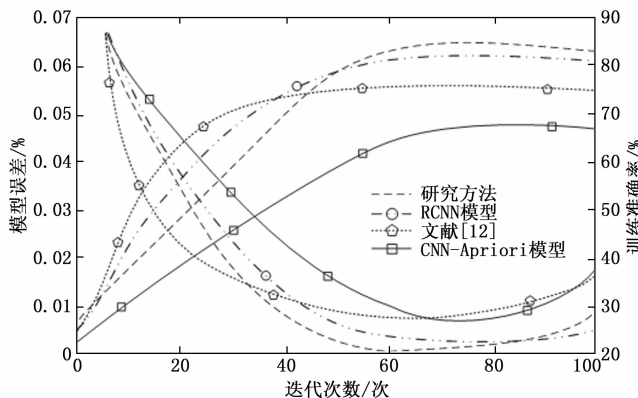


图 7 模型精度及损失率变化图

根据图 7 可知，模型在误差的变化上呈现出急剧减小后又缓慢增加的趋势，迭代次数为 60 时为拐点，准确率也同样在迭代次数为 60 次附近时开始趋向收敛，此时其训练准确率接近于 84.32%，显著高于其余 3 种算法。其次当迭代到达 60 次附近时，研究方法的误差无限接近于 0.00%，而此时 RCNN 模型、文献 [13] 与 CNN-Apriori 模型对应的误差分别为 0.005 21%、0.009 87% 与 0.012 54%。以上结果说明研究方法在具有较高准确率的同时，模型所产生的误差也相对较低，能够被人体姿态识别系统中。最后将 4 种不同的算法应用于人机交互医疗设备系统的患者不同姿势存储系统中，进行实际效果的验证，具体结果见图 8。

图 8 (a) 为 4 种方法对患者不同姿势的识别准确率，图 8 (b) 则为识别时间对比。图 8 (a) 中可知，在对患者的腰痛姿势、腿痛姿势以及腹痛姿势的基本动作识别中，研究方法的识别准确率均显著高于 90%，均高于其他算法的识别准确率。而 RCNN 模型的是被准确率均低于 85%，

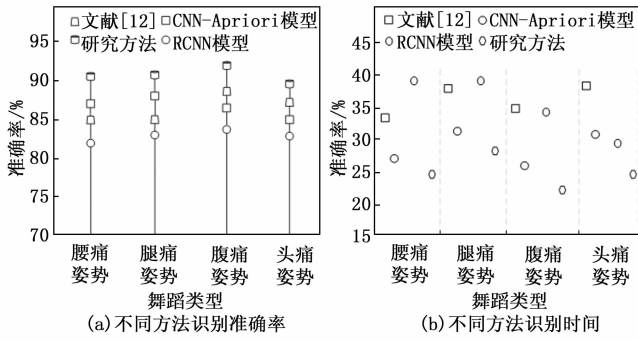


图 8 不同方法运行下的患者姿势识别效果

是 4 种方法中最低的。由图 8 (b) 中, 在对患者的腰痛姿势与腿痛姿势进行识别时间中, RCNN 模型的识别耗时最长, 据接近于 40.0 s。在腹痛姿势与头痛姿势的识别中, CNN-Apriori 模型的识别耗时最长, 分别为 35.21 s 与 38.47%。而研究方法的所需时间均为最少, 对应不同姿势的耗时分别为 25.14%、27.45%、23.16% 与 25.61%。对比以上结果可知, 研究方法能够对患者的不同姿势进行较为准确的识别, 同时耗时较少。

3 结束语

利用人机交互医疗设备对人体健康状态进行监测是当前医疗行业重点发展的项目之一。为了能够更加全面地实现人体姿态识别在人机交互医疗设备中的应用, 研究根据 WBAN 能够实现不同层次间信号传输的特点, 构建了相应的人体姿态识别系统。过程中, 分别对网络结构、网路层数、滤波器个数与尺寸进行了选择, 并选取了最为合适的激活函数, 使得改进 CNN 能够有效地提取图像特征并识别姿态。同时, 针对 WBAN 识别效率较低的缺陷, 提出通过 3D 卷积网络对其进行改进。结果显示, 在 HiEve 数据集上, 当迭代次数为 20 次左右, 研究方法开始趋于平稳, 同时对应应有 0.011 2 的损失函数值; 在 Human3.6 M 数据集中, 该模型于 30 次迭代左右出现最小损失值函数值。ROC 曲线对比中, 研究方法、RCNN 模型、文献 [13] 与 CNN-Apriori 模型对应的 ROC 曲线占据面积为 0.897、0.856、0.789 与 0.754, 研究方法的性能更优。不同算法的准确率方面, 该模型于 60 次迭代附近时, 误差无限接近于 0.00%; 同时准确率也同样在迭代次数为 60 次附近时开始趋向收敛, 此时其训练准确率接近于 84.32%, 显著高于其

(上接第 244 页)

[13] YANG K, WANG Y, TANG H. A subarray design method for low sidelobe levels [J]. Progress In Electromagnetics Research Letters, 2020, 89: 45-51.

[14] 胡尚坤, 孙雨泽, 杨小鹏, 等. 一种基于粒子群算法的多目标子阵划分优化方法 [J]. 信号处理, 2017, 33 (8): 1132-1137.

[15] 杨海清, 芦 斌. 基于改进蚁群算法的水下无人机路径规划研究 [J]. 计算机测量与控制, 2020, 28 (10): 216-220.

[16] 段海滨, 马冠军, 王道波, 等. 一种求解连续空间优化问题的改进蚁群算法 [J]. 系统仿真学报, 2007 (5): 974-977.

余 3 种算法。将该模型应用于人机交互医疗设备进行患者不同姿势的检测中, 对应的耗时分别为 25.14 s、27.45 s、23.16 s 与 25.61 s, 具有更高的效率, 验证了该方法的有效性。总的来说, 研究所提出方法为医疗设备提供了一个有力的工具, 能够有助于提升医疗服务质量和效率。但研究主要从软件方面进行姿态识别的改进, 未来需要通过蓝牙等硬件设施的技术更新来实现更优的效果。

参考文献:

[1] 王苾蓉, 吴静静. 基于关键姿态的快递场景人一物交互行为识别方法 [J]. 计算机测量与控制, 2022, 30 (6): 182-189.

[2] 李俊侠, 张 秦, 郑桂妹. 超宽带雷达人体姿态识别方法研究 [J]. 现代电子技术, 2021, 44 (19): 1-7.

[3] 金 玮, 孟 君, 黄宇飞, 等. 基于 CNN 和高速通信技术的医用人体姿态识别方法 [J]. 微型电脑应用, 2022, 38 (7): 20-26.

[4] 周 帅, 张飞云, 郑永权. 基于 Kinect 采集的武术动作识别匹配研究 [J]. 自动化技术与应用, 2020, 39 (3): 94-97.

[5] 黄展原, 李 兵, 李庚浩. 基于视频和人体姿态估计的老年人摔倒监测研究 [J]. 计算机工程与科学, 2021, 43 (5): 883-890.

[6] 孙月驰, 平 伟, 徐明磊. 基于优化卷积神经网络结构的人体行为识别 [J]. 计算机应用与软件, 2021, 38 (2): 198-269.

[7] 金 玮, 孟 君, 黄宇飞, 等. 基于 CNN 和高速通信技术的医用人体姿态识别方法 [J]. 微型电脑应用, 2022, 38 (7): 20-26.

[8] 邓 平, 吴明辉. 基于机器学习的人体运动姿态识别方法 [J]. 中国惯性技术学报, 2022, 30 (1): 37-43.

[9] 徐浙君, 陈善雄. 基于深度学习的弱纹理图像关键目标点识别定位方法 [J]. 计算机测量与控制, 2022, 30 (2): 186-200.

[10] 胡佳玲, 施一萍, 谢思雅, 等. 基于轻量级卷积神经网络人脸识别算法的研究与应用 [J]. 传感器与微系统, 2022, 41 (1): 153-156.

[11] 王 彪, 戴 毓. 基于深度学习网络的异步电动机故障识别 [J]. 微型电脑应用, 2022, 38 (12): 25-27, 31.

[12] 孙冬颖, 侯建鹏, 周丽丽, 等. 羽毛球动作训练步态识别分析系统设计 [J]. 自动化技术与应用, 2021, 40 (12): 177-180.

[13] 张 冰, 唐和礼, 黄冬梅, 等. 神经网络及智能算法在膜污染研究中的应用 [J]. 膜科学与技术, 2021, 56 (1): 160-169.

[14] 张忠民, 李蔚然. 基于蚁群算法的子阵级自适应多波束形成 [J]. 应用科技, 2022, 49 (1): 83-89.

[15] 陈希信, 尹成斌, 王 峰. 一种降维空时自适应处理子阵划分方法 [J]. 雷达科学与技术, 2014, 12 (5): 456-469.

[16] 熊子源. 阵列雷达最优子阵划分与处理研究 [D]. 长沙: 国防科学技术大学, 2015.

[17] 陈 适. 自适应波束形成算法的研究与实现 [D]. 西安: 西安电子科技大学, 2019.

[18] OLIVERI G, POLI L. Optimal sub-arraying of compromise planar arrays through an innovative ACO-weighted procedure [J]. Technical Report, 2011, 109: 279-299.