

基于注意力机制的 CNN-LSTM 网络下肢膝关节角度预测

汤璐, 杨玺霖, 王祥瑞, 胡倩媛, 郑辉

(上海理工大学健康科学与工程学院, 上海 200093)

摘要: 解析膝关节运动意图是实现下肢外骨骼机器人穿戴舒适性的核心。神经系统疾病患者常伴有下肢运动障碍, 通过表面肌电信号对其进行运动评估。为实现上述患者在运动评估与关节角度预测的融合, 本文提出一种新型的基于注意力机制的 CNN-LSTM 网络模型, 通过 10 通道表面肌电信号实现水平行走、上坡和上楼梯时 3 种日常运动膝关节角度预测, 其预测误差指标均方根误差 (Root mean square error, RMSE)、平均绝对误差 (Mean absolute error, MAE) 和决定系数 (R^2) 均值分别为 2.74、2.50 和 0.97, 均优于传统网络模型。进一步, 通过消融实验, 显示上述 3 个预测指标分别平均下降了 20.47%、34.36% 和 6.59%。可见, 本文提出的基于注意力机制的 CNN-LSTM 模型端到端预测方法具有最高的预测精度, 为下肢外骨骼机器人系统的人机交互控制方案提供了参考。

关键词: 表面肌电信号; CNN-LSTM 模型; 注意力机制; 关节角度预测; 外骨骼机器人

中图分类号: TP249

文献标志码: A

An Attention Mechanism-Based CNN-LSTM Framework for Lower Limb Knee Joint Angle Prediction

TANG Lu, YANG Xilin, WANG Xiangrui, HU Qianyuan, ZHENG Hui

(School of Health Sciences and Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China)

Abstract: Decoding knee motion intention is crucial for the wearable comfort in lower extremity exoskeleton robots. Patients with neurological disorders are often accompanied with lower limb movement disorders assessed by surface electromyography (sEMG) signals. To integrate the motion assessment and joint angle prediction for these patients, a novel CNN-LSTM framework based on the attention mechanism is proposed to predict the knee joint angle for three daily motions, i.e., horizontal walking, going uphill, and going up stairs, through 10-channel sEMG signals. The prediction error indicators, i.e., the root mean squared error (RMSE), the mean absolute error (MAE), and the coefficient of determination (R^2) reach 2.74, 2.50, and 0.97, respectively, outperforming the traditional network. Furthermore, the ablation experiments show the three indicators have decreased by 20.47%, 34.36% and 6.59% on average, respectively. The proposed end-to-end prediction framework based on the attention mechanism can reach the highest prediction accuracy, providing a reference for the human-robot interaction scheme of the lower limb exoskeleton robot system.

Key words: surface electromyography (sEMG) signal; CNN-LSTM model; attention mechanism; joint angle prediction; exoskeleton robot

引言

人体运动意图识别技术是指利用计算机技术来预测人体运动模式的方法,将该技术应用于穿戴式下肢外骨骼机器人已经成为国内外研究热点^[1]。下肢外骨骼机器人控制器主要通过加速度信号、关节角度、关节角速度及肢体与地面的交互力等运动信息预测下肢运动模式,预定下肢运动轨迹,以辅助患者下肢运动。下肢运动离不开髋关节、膝关节及踝关节相互配合,其中膝关节主要负责关节弯曲与伸直,不仅承受着巨大的体重负荷,而且为双足行进提供稳定的流体机制进而进行精准的运动。因此,能准确、实时地解析膝关节运动意图是实现人机交互和下肢外骨骼机器人穿戴舒适性的核心。

目前,用于下肢膝关节角度预测的信号包括运动信号和表面肌电(Surface electromyography, sEMG)信号。sEMG信号是由肌肉兴奋或活动而形成的复杂生物电,携带丰富的神经肌肉控制信息和肌肉激活信息,能反映神经肌肉运动状态。相较于运动信号,sEMG信号超前肢体运动30~150 ms^[2],保证了通过sEMG信号预测的膝关节角度用于下肢外骨骼机器人的实时性。He等^[3]基于上肢各块肌肉的肌纤维长度、最大肌力系数和最大肌张力等生理参数构建出肌肉骨骼模型,实现了对手腕、拇指、食指和中指关节角度的预测,其评估的相关系数和归一化均方根误差分别为0.92和0.107,其角度预测的精度依赖于生理参数的选择与确定。随后,研究者将sEMG信号特征送入支持向量机(Support vector machine, SVM)^[4]、反向传播(Back propagation, BP)神经网络^[5]、随机森林^[6]和径向基核函数(Radial basis function, RBF)神经网络^[7]等分类器中,实现下肢髋关节、膝关节和踝关节角度的预测。

随着深度学习技术的发展,卷积神经网络(Convolutional neural network, CNN)已成功应用于时间序列预测,在连续关节角度估计中具有较高的准确性和更好的平滑性^[8]。CNN在sEMG信号的研究中具有平移不变的处理数据的优势,能够保持sEMG信号之间的原始二维空间特征^[9]。Ameri等^[10]首次通过sEMG信号验证了CNN回归技术预测手腕运动的可行性,相比于SVM具有更高的回归精度。Wang等^[11]基于sEMG建立CNN模型预测骑自行车和步行时下肢多关节角度,通过CNN模型预测髋关节、膝关节和踝关节角度的平方平均数误差分别是3.888 6、2.819 9和3.114 8。为了充分考虑步态sEMG信号的时空相关性,Zhu等^[12]在CNN网络的基础上融合了长短期记忆(Long short-term memory, LSTM)模块,基于主成分分析处理后的sEMG特征输入CNN-LSTM模型来预测膝关节角度,预测误差为 1.34 ± 0.25 ,表明CNN-LSTM模型能提升关节角度预测精度。Sun等^[13]构建CNN-BiLSTM下肢膝关节角度预测模型,将通过集成评分器量化的sEMG信号特征和惯性信号融合的高维时间序列作为模型输入,该模型在公共数据集验证的平均均方根误差为4.07。然而,上述研究都具有复杂的特征提取过程,并且sEMG信号特征值的选取和计算都会影响模型的鲁棒性和预测误差。

CNN网络逐层处理方式为主获取特征提供了新的视角^[14],实现了将特征提取隐藏在深度卷积神经网络逐层处理中,现已被广泛应用于分类和回归任务中。目前,在角度预测中还没有相关论文采用端对端的处理方法。同时,本文还注意到下肢运动中不同时刻膝关节角度对应的各块肌肉的激活强度不同,可以引入注意力机制来获取历史数据对当前数据点的不同贡献^[15]。因此,通过多通道sEMG信号预测膝关节角度中引入注意力机制,根据肌肉激活强度分配相应的注意力,以增强显著激活肌肉的影响。

基于此,本文提出一种新型的采用端对端方法的注意力机制CNN-LSTM模型,实现对膝关节角度的预测。采集3种下肢运动包括水平走、上坡和上楼梯过程多通道的sEMG信号,将其送入基于注意力机制的CNN-LSTM模型,实现对不同运动模式下膝关节角度的预测,并设计消融实验,与传统RBF网络进行结果对比分析,进一步验证本研究所提预测模型对下肢膝关节角度的预测性能。

1 信号采集及预处理

1.1 sEMG 信号和角度数据采集方案

本实验共招募6名健康大学生(3男3女,平均年龄为 23.0 ± 2.0 岁)作为受试者。受试者具体信息如表1所示。

选取人体下肢膝关节运动过程中主要涉及的10块肌肉,即胫骨前肌、腓骨长肌、内侧腓肠肌、外侧腓肠肌、比目鱼肌、股外侧肌、股直肌、股二头肌、半腱肌和股内侧肌。表面肌电电极放置前,用酒精清洁肌肉表面皮肤,具体安放细则参考 SENIAM 准则^[16]。同时,在右腿膝关节与髌关节中间点,及膝关节与踝关节中点各放置1个姿态传感器,以实时获取受试者膝关节角度。姿态传感器方向分别是: x 轴为受试者水平向前方向, y 轴为受试者垂直向上方向, z 轴为受试者水平向左方向。表面肌电电极和姿态传感器放置右腿位置如图1所示。

实验设置水平走、上坡和上楼梯3种日常的下肢运动模式。实验过程中,受试者被要求在固定测试地点按照自身舒适的速度完成3种运动,以保证信号更加贴切真实日常运动,且每个

运动持续时间至少2 min。本研究应用场景是辅助下肢运动障碍患者进行康复,鉴于患者下肢运动速度低于正常人^[17-18],实验方案除设定舒适速度外,对慢速运动下3种运动模式的信号也进行了采集,即保证同一受试者步幅度不变时,采集低于舒适速度的信号(下文称慢速),以验证不同运动速度对预测模型的稳定性影响。信号采集设备为实验室自行研发的多通道表面肌电采集系统,可同步采集10通道sEMG信号及姿态角。表面肌电电极为Ag-AgCl差分表面电极,放大倍数为1 000,采样率为1 000 Hz;传感器为BWT901CL姿态传感器,能够在动态环境下准确返回当前姿态角,采样频率为200 Hz,角度测量精度为 0.05° 。

1.2 膝关节角度解算

首先,将3种运动模式下的膝关节角度通过IBM Spss Statistics 23软件进行统计学分析,结果显示水平走、上坡和上楼梯3种运动模式下的膝关节角度存在显著性差异($p < 0.05$);随后,通过2个姿态传感器所采集的姿态数据,运用基于双姿态传感器对关节角度的测量原理,建立欧拉角法相应的数学模型^[19]。

定义惯性坐标系为东北天坐标系 O ,在运动的初始位置(设为位置1)定义连杆坐标系 A 固连于姿态传感器I,连杆坐标系 B 固连于姿态传感器II。经过运动后(设为位置2),在位置2定义连杆坐标系 A' 固连于姿态传感器I,连杆坐标系 B' 固连于姿态传感器II。规定连杆坐标系与惯性坐标系原点重合,用欧拉角描述连杆坐标系与惯性坐标系之间的转换关系。绕 x 轴旋转的方向角为滚转角,绕 y 轴旋转的方向角为俯仰角,绕 z 轴旋转的方向角为航向角,其欧拉角表示姿态时的坐标转换顺序定义为 $z \rightarrow y \rightarrow x$ 。角度解算的具体过程如下:

表1 受试者信息表

Table 1 Subject information table

序号	性别	年龄/ 岁	身高/ cm	体重/ kg	步频/(步·min ⁻¹)	
					舒适速度	慢速
1	女	23	158	55.0	96	67
2	男	25	173	62.5	107	64
3	男	22	175	65.0	104	56
4	女	23	163	53.6	113	77
5	男	21	177	67.5	110	72
6	女	24	169	60.0	97	71

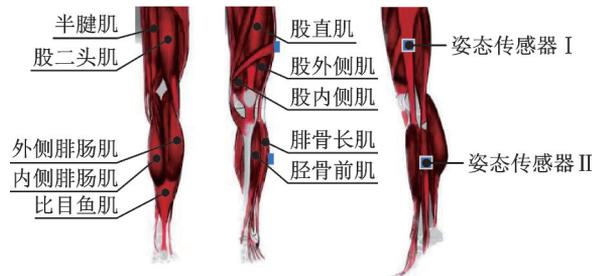


图1 传感器位置分布

Fig.1 Sensor location distribution

设膝关节位置1角度为 θ_1 ,此时传感器I对应的滚转角、俯仰角和航向角分别为 α_{11} 、 β_{11} 和 γ_{11} ;传感器II对应的滚转角、俯仰角和航向角分别为 α_{12} 、 β_{12} 和 γ_{12} 。由传感器I、II分别计算连杆坐标系A相当于与惯性坐标系的变换矩阵 ${}^O_A R_1$,和连杆坐标系B相当于与惯性坐标系的变换矩阵 ${}^O_B R_1$ 。则连杆坐标系B相当于与连杆坐标系A的变换矩阵 ${}^A_B R_1$ 为

$${}^A_B R_1 = ({}^O_A R_1)^{-1} {}^O_B R_1 \quad (1)$$

将运动后膝关节位置2角度记为 θ_2 ,此时传感器I采集滚转角、俯仰角和航向角分别为 α_{12} 、 β_{12} 和 γ_{12} ,传感器II采集滚转角、俯仰角和航向角分别为 α_{22} 、 β_{22} 和 γ_{22} 。由传感器I、II采集值分别计算连杆坐标系A相当于与惯性坐标系的变换矩阵 ${}^O_A R_2$,和连杆坐标系B相当于与惯性坐标系的变换矩阵 ${}^O_B R_2$ 。则连杆坐标系B相当于与连杆坐标系A的变换矩阵 ${}^A_B R_2$ 为

$${}^A_B R_2 = ({}^O_A R_2)^{-1} {}^O_B R_2 \quad (2)$$

在位置2中定义辅助坐标系Q为连杆坐标系B随连杆坐标系A作相同或变换后形成的连杆坐标系。坐标系变换过程如图2所示。

设连杆坐标系Q与辅助坐标系B'之间的变换矩阵为 R' ;设存在点C在连杆坐标系B'中的坐标为 $P_{C'}$,在辅助坐标系Q中的坐标为 P_C 。在连杆坐标系A'中对C点的描述如下

$$P_C = ({}^A_B R_1)^{-1} {}^A_B R_2 P_{C'} \quad (3)$$

由式(1,2,3)可知

$$R' = (({}^O_A R_1)^{-1} {}^O_B R_1)^{-1} ({}^O_A R_2)^{-1} {}^O_B R_2 \quad (4)$$

变换矩阵 R' 应有下列格式

$$R' = \begin{bmatrix} n_x & o_x & a_x \\ n_y & o_y & a_y \\ n_z & o_z & a_z \end{bmatrix} \quad (5)$$

连杆坐标系B'相对于辅助坐标系Q以膝关节回转轴为等效轴,以膝关节相对运动度为等效角度。根据其变换矩阵可以求得等效转角,即膝关节运动角度 ϕ 为

$$\phi = \arccos\left(\frac{n_x + o_y + a_z - 1}{2}\right) \quad (6)$$

膝关节实际角度为

$$\theta_2 = \theta_1 + \phi \quad (7)$$

根据上述解算公式,可获得3种运动模式下膝关节角度解算结果,如图3所示。

1.3 sEMG 信号预处理

送入预测模型前,每通道sEMG信号依次经过带通滤波、陷波滤波、去均值、整流和低通滤波处理环节。由于sEMG信号主要能量分布在50~250 Hz,而运动伪迹噪声的频谱一般集中在0~20 Hz。可通过低截止频率为20 Hz、高截止频率为500 Hz的巴特沃斯6阶带通滤波器滤除部分噪声。此外,由于中国的工频干扰为50 Hz,采用50 Hz的陷波滤波器消除工频干扰。最后,每通道的sEMG信号通过截止频率为5 Hz,阶数为1的低通滤波器获得sEMG包络信号。以内侧腓肠肌为例,展示了sEMG信号预

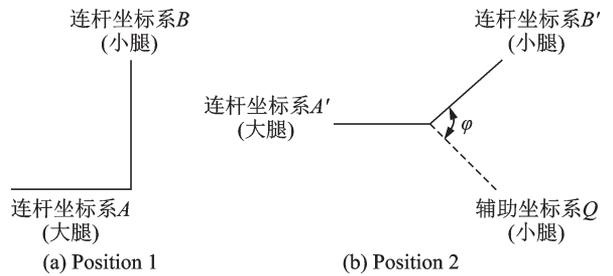


图2 坐标系变换过程

Fig.2 Coordinate system transformation process

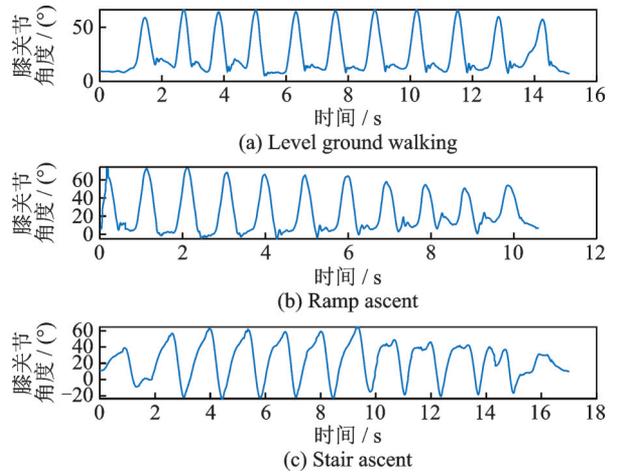


图3 3种运动模式下膝关节角度

Fig.3 Knee angle in three sports modes

处理全过程,如图4所示。膝关节角度的采样频率为200 Hz,而sEMG信号采集频率为1 000 Hz。因此,需要对sEMG信号进行次级采样,确保sEMG信号的和膝关节角度信号长度的一致性。为降低不同受试者及不同通道sEMG信号在幅值上的差异,对每通道sEMG信号采用最大最小值进行归一化处理,结果如图4(f)所示。

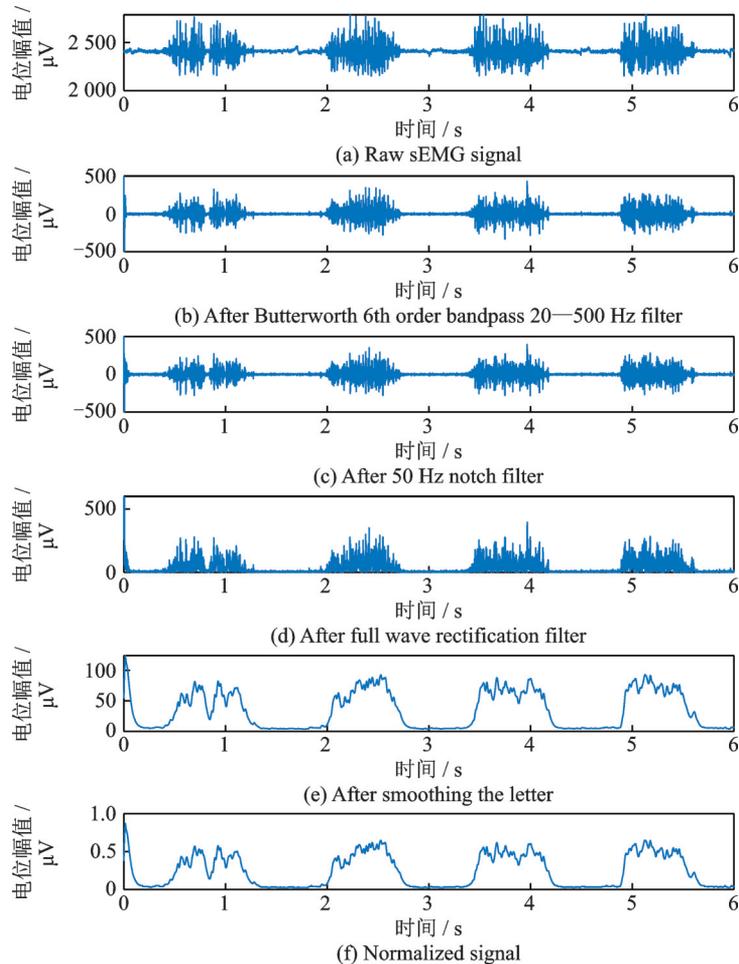


图4 内侧腓肠肌肌电信号的预处理全过程

Fig.4 Entire preprocessing process of EMG signals of medial gastrocnemius muscle

2 基于注意力机制的CNN-LSTM模型

基于注意力机制的CNN-LSTM模型的整体架构如图5所示。预测模型主要由3个模块组成: CNN、基于注意力机制LSTM和全连接层模块。首先,将10通道sEMG信号和膝关节角度信号拼接成一个多元时间序列,作为模型的输入;其次,通过CNN网络来提取输入数据的空间特征,去除时间序列中的噪声和不稳定成分;接着,通过LSTM层学习CNN单元输出之间的长期非线性关系,突出时间序列的有效的时间特征;最后,将数据集输入模型预测连续膝关节角度。CNN网络由2个卷积层和2个池化层组成,卷积层分别有64和128个卷积核;LSTM模型包含2个隐藏层,分别有128和64个神经元;模型的底层是两个完全连接层,分别有5 760和2 880个神经元,通过ReLU激活函数输出预测结果。

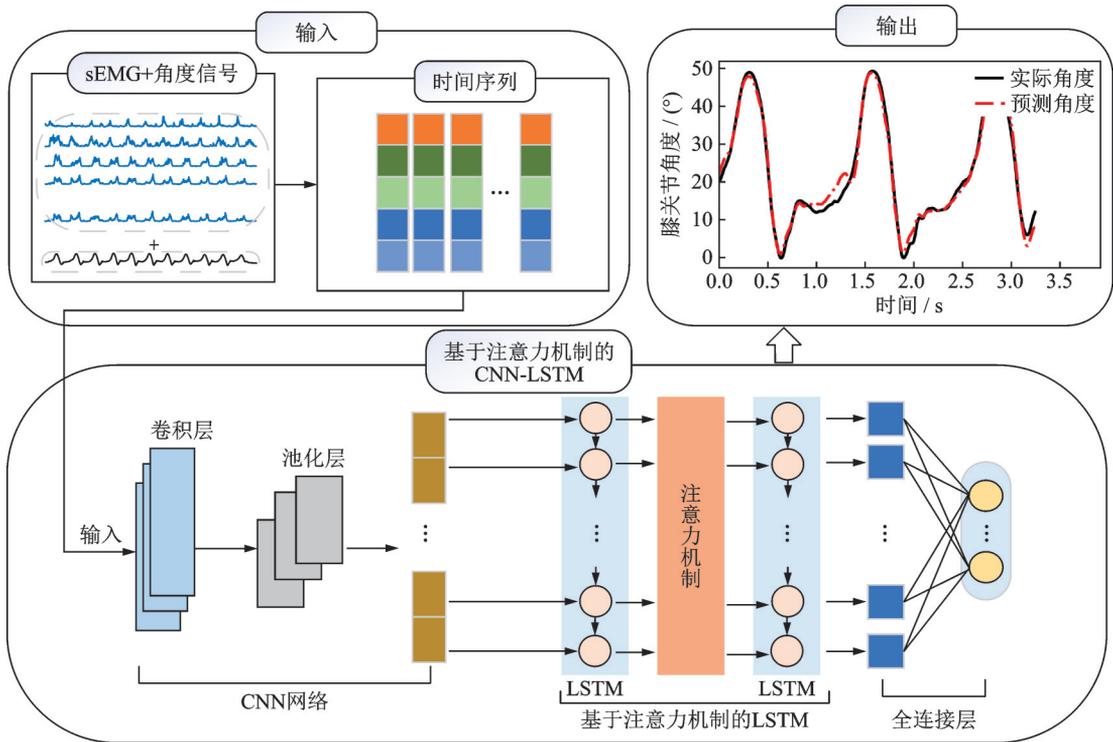


图5 基于注意力的CNN-LSTM混合模型的整体架构

Fig.5 Overall architecture of the attention-based CNN-LSTM hybrid model

2.1 1D-CNN作为多变量特征提取模块

CNN是一种前馈神经网络,具有卷积运算和深度结构,常用于图像处理^[20]和自然语言处理^[21]。每个CNN都由1个卷积层和1个池化层组成,本文的一维CNN(One-dimensional CNN, 1D-CNN)包含2个卷积层和2个池化层。1D-CNN可以接受多变量时间序列作为输入,并通过卷积层、ReLU层和池化层提取时间特征。本文1D-CNN处理多元时间序列的过程如图6所示。

1D-CNN使用矩形滤波器来提取多变量时间序列特征。设矩形滤波器的高度和宽度分别为 h 和 w , h 为每个滤波器中处理的sEMG信号输入向量的数量, w 为输入序列的通道数,卷积层生成的卷积特征数量分别为64和128。当多元时间序列输入到1D-CNN时,网络的卷积层和池化层通过滑动窗口来处理输入。用 $\{x_{i,j}\}$ 表示多通道sEMG信号输入向量集合, $i=1,2,\dots,n$; $j=1,2,\dots,l$ 。 $x_{i,j}$ 表示第 i 个采样点的第 j 个变量值。 n 为训练样本的数量; k 为卷积核的数量(本文第一层为64); S_m^1 为第一层卷积层处理多变量时间序列的结果; w_j^m 和 b_j^m 分别为第 m 个矩形滤波器的第 j 个特征权重和偏置。

卷积运算可表示为

$$S_m^1 = (X_{ij}^1, X_{ij}^2, \dots, X_{ij}^m)^{-1} = \begin{bmatrix} \text{Re LU} \left(b_j^1 + \sum_{j=1}^k w_j^1 \times x_{i,j} \right) \\ \text{Re LU} \left(b_j^2 + \sum_{j=1}^k w_j^2 \times x_{i,j} \right) \\ \vdots \\ \text{Re LU} \left(b_j^m + \sum_{j=1}^k w_j^m \times x_{i,j} \right) \end{bmatrix} \quad (8)$$

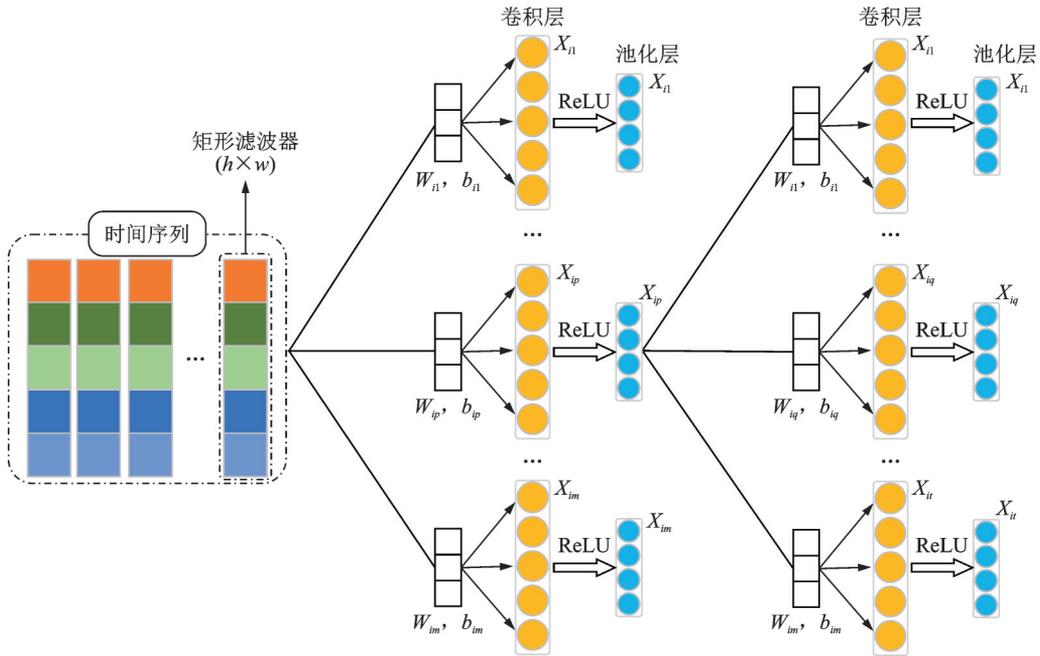


图6 1D-CNN处理多变量时间序列过程

Fig.6 Process of 1D-CNN processing of multivariate time series

为增加CNN的非线性特征,使用ReLU激活函数,可以增强网络的表达能力^[22]。ReLU函数定义为

$$\text{ReLU}(x) = \begin{cases} 0 & x \leq 0 \\ x & x > 0 \end{cases} \quad (9)$$

池化层通过减少来自卷积层的传入数据大小来降低参数的数量和网络计算成本,它保留了来自前一层中的每一个神经元的最大值,有利于调整过拟合。最后,dropout层通过从神经网络中随机丢弃神经元来防止神经元之间的过度协同适应,增强模型的泛化能力。

2.2 LSTM作为时间特征提取块

LSTM通过反馈循环对时间序列的上下文信息进行编码,通过引入记忆单元来解决传统的循环神经网络梯度消失和梯度爆炸的问题,在连续运动量预测方面取得良好结果^[23-24]。LSTM的记忆单元由1个单元状态和3个门组成,包括输入门、遗忘门和输出门,这些门通过使用sigmoid作为激活函数来确定每个存储单元的状态,从而使信息选择性的传输。将CNN层输出序列 $[x_1, x_2, \dots, x_T]$,输入LSTM中的展开链结构,如图7所示。在每个时刻 t ,记忆单元接收到来自前一个时刻 $(t-1)$ 输入门、遗忘门和输出门的信号,根据这些信号和前一时刻的输入 x_t 来更新单元状态 c_t 。这样的结构特点让历史信息可以在LSTM的整个循环中递归传递。

LSTM的第一步是遗忘门,决定当前状态中要丢弃的信息。遗忘门读取前一时刻的隐藏状态 h_{t-1} 和 x_t ,经过一个sigmoid层输出 f_t 在0到1之间的值。1表示“完全保留”,0表示“完全丢弃”。遗忘门的计算公式为

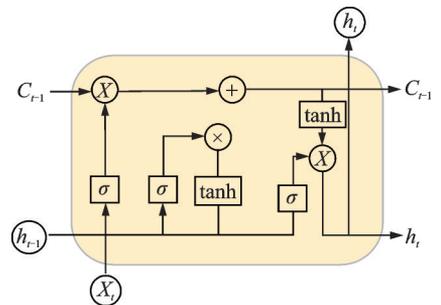


图7 LSTM内部链式结构

Fig.7 Internal chain structure of LSTM

$$f_t = \sigma(W_f[h_{t-1} \ x_t] + b_f) \quad (10)$$

式中: W_f 和 b_f 为可训练的参数; $[h_{t-1} \ x_t]$ 表示将当前时刻的隐藏状态和当前时刻的输入拼接在一起; σ 表示 sigmoid 函数。

输入门决定哪些新信息可以添加到单元的状态中。 i_t 表示输入门的输出,是一个介于0到1之间的数值,表示要保留的信息量,其计算公式为

$$i_t = \sigma(W_i[h_{t-1} \ x_t] + b_i) \quad (11)$$

$$\tilde{C}_t = \tanh(W_c[h_{t-1} \ x_t] + b_c) \quad (12)$$

式中: W_i 、 W_c 表示权重矩阵; b_i 、 b_c 表示对应的偏置; \tanh 为双曲线正切函数; \tilde{C}_t 表示新的候选单元状态,它的每个元素都在-1到1之间。 C_t 更新的公式为

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \quad (13)$$

输出门将记忆单元中存储的信息与当前时间步的输入进行加权,以生成输出。输出门的计算方式与输入门相似,先是通过一个 sigmoid 函数决定门的开放程度,再通过一个 \tanh 函数来生成输出向量。计算公式为

$$O_t = \sigma(W_o[h_{t-1} \ x_t] + b_o) \quad (14)$$

$$h_t = O_t \times \tanh(C_t) \quad (15)$$

式中: W_o 表示权重矩阵; b_o 表示对应的偏置; O_t 表示输出门的输出。最后得到当前时刻的隐藏状态 h_t 。

2.3 基于注意力的 Encoder-Decoder 网络

Encoder-Decoder 网络广泛用于自然语言处理领域,包括编码器(Encoder)和解码器(Decoder)。Encoder由递归神经网络构成,可以学习输入序列的特征并输出一个中间状态向量 C 。 C 可以理解为模型的输入通过 Encoder 变成一个维度固定的信息序列向量,是对输入信息的概括和提取。紧接着 Decoder 将 C 作为输入,得到目标输出。

传统的 Encoder-Decoder 网络模型中状态向量 C 被认为是等价的,易出现权重分配不均匀的问题,尤其是针对长序列数据预测,Decoder 对于不同时刻的输出,其输入都是同一个状态向量 C ,忽略了长序列数据前后依赖关系,会导致输出的预测精度下降。综上,本文在 Encoder-Decoder 网络中引入注意力机制,注意力机制通过计算中间状态向量 C 的相关注意力权重。注意力机制计算过程即是中间状态向量 C 的计算过程,注意力机制将 Encoder 端所有隐藏状态与 Decoder 端的当前状态进行相关性计算,并为隐藏状态分配权重,以便在 Decoder 端进行加权求和,使得 Decoder 端能够更好地捕捉输入序列中的重要信息,提高模型的准确性和鲁棒性。在时间序列预测任务中,通常将一个或多个时间序列转换为一个输出时间序列。为考虑过去和未来的数据信息,选择双向长短期记忆(Bi-directional LSTM, Bi-LSTM)网络作为 Encoder-Decoder 网络的结构模块来处理数据,基于注意力机制的深度 LSTM 模型的架构如图8所示。

注意力机制是一种学习输入数据重要性的算法,提高集中区域信息的接受灵敏度和处理速度。注意力机制的核心是根据信息的重要性来分配相应的注意力权重,注意力会计算每个输出与输入数据之间的相似度,得到不同输入对应的权重,在根据该权重对全部输入加权求和^[25]。对于引入注意力机制的 Encoder-Decoder 网络,输入序列 $[x_1, x_2, \dots, x_T]$ 经过编码器 LSTM 生成信息序列 $[h_1, h_2, \dots, h_T]$,注意力机制计算注意力得分 e_t ,由 h_t 和 d_{t-1} 之间的相关性决定,再计算其注意力权重 α_t 和加权中间状态向量 C_t ,解码器 LSTM 将 C_t 和 d_{t-1} 作为输入,输出 Y_t ,即 t 时刻的预测膝关节角度值。注意力值的计算过程可表示为

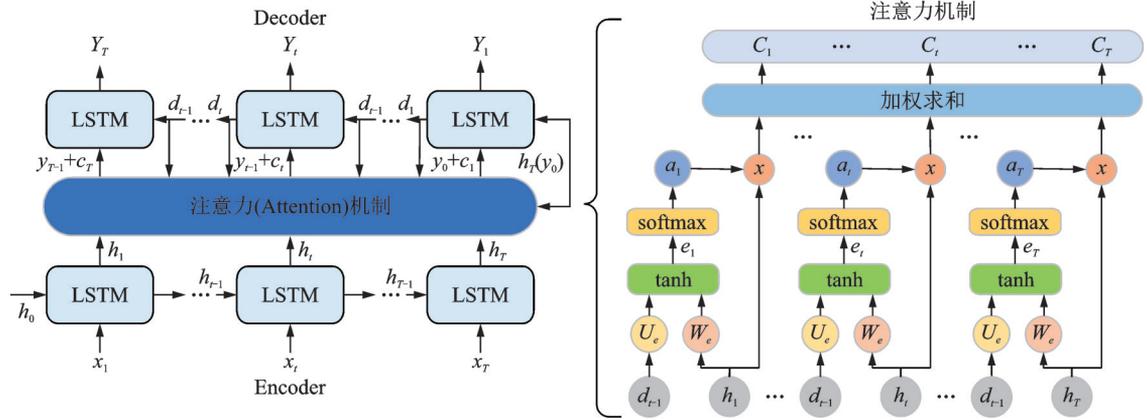


图8 基于注意力机制的LSTM模型架构

Fig.8 LSTM model architecture based on attention mechanism

$$e_t = v^t \times \tanh(W_e \times h_t + u_e \times d_{t-1} + b) \quad (16)$$

$$\alpha_t = \frac{\exp e_t}{\sum_{t=1}^T \exp e_t} \quad (17)$$

$$C_t = \sum_{t=1}^T \alpha_t \times h_t \quad (18)$$

式中: W_e 和 u_e 为可学习的参数矩阵; v^t 为参数向量; b 为解码器 LSTM 的偏置向量。

3 下肢膝关节角度预测结果与分析

本文在 Python3.7 中的 Tensorflow 深度学习框架平台搭建基于注意力机制的 CNN-LSTM 网络进行膝关节角度预测。其中 Epoch=100, batch_size = 128, 选择 Adam 作为优化器, 训练集和测试集的比例为 4:1。将预处理后的 sEMG 信号作为基于注意力机制的 CNN-LSTM 模型输入, 模型输出角度作为预测角度值, 实现 3 种运动模式的膝关节角度端到端预测。同时, 为了验证本文预测模型对下肢膝关节角度的预测性能, 研究不同运动速度对预测结果的影响, 同时对比本文提出的模型与无注意力机制 CNN-LSTM 网络模型及传统 RBF 网络模型预测效果。

3.1 评价指标

为了评估本文预测模型性能, 通过 3 个评价指标, 即均方根误差 (Root mean square error, RMSE)、平均绝对误差 (Mean absolute error, MAE) 和决定系数 (R^2) 进行评估。RMSE 和 MAE 表征实际膝关节角度与预测膝关节角度之间的误差, 其值越小误差越小; R^2 表示实际膝关节角度和预测膝关节角度之间的相似性, 其取值范围在 0~1 之间, 越接近 1, 模型的拟合度越好。评价指标的计算公式分别为

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (\theta_{p,i} - \theta_{a,i})^2}{n}} \quad (19)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |\theta_{p,i} - \theta_{a,i}| \quad (20)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (\theta_{p,i} - \bar{\theta}_p)^2}{\sum_{i=1}^n (\theta_{a,i} - \bar{\theta}_a)^2} \quad (21)$$

式中: n 为信号采集点数; $\theta_{p,i}$ 为预测值; $\bar{\theta}_p$ 为预测值的平均值; $\theta_{a,i}$ 为实际值; $\bar{\theta}_a$ 为实际平均值。

3.2 不同运动速度验证模型性能

为验证不同速度对基于注意力机制的CNN-LSTM模型预测性能的影响,将3种运动模式下慢速和舒适速度的sEMG信号分别送入基于注意力机制的CNN-LSTM模型预测膝关节角度,计算两种速度下6名受试者3种运动模式在预测模型中的评价指标RMSE、MAE和 R^2 均值,结果如表2所示。

表2 两种速度下3种运动模式实验结果对比

Table 2 Comparison of experimental results of three motion modes at two speeds

速度	动作模式	RMSE	MAE	R^2
慢速	水平走	2.40±0.12	2.11±0.09	0.97±0.01
	上坡	2.67±0.31	2.17±0.07	0.96±0.01
	上楼梯	2.80±0.20	2.92±0.09	0.96±0.01
舒适速度	水平走	2.70±0.43	2.42±0.33	0.96±0.02
	上坡	2.72±0.71	2.17±0.58	0.98±0.02
	上楼梯	2.81±0.13	2.92±0.32	0.96±0.02

由表2可知,水平走在慢速时膝关节角度预测误差RMSE(2.40±0.12)和MAE(2.11±0.09),小于舒适速度时的RMSE(2.70±0.43)和MAE(2.42±0.33)。上坡及上楼梯2种运动模式膝关节角度预测结果也有相同规律。慢速的RMSE预测精度相比于舒适速度提高了0.36%~11.11%。将同一运动模式下两种不同速度的3个评价指标结果分别进行独立样本 T 检验,结果显示3种运动模式慢速和舒适速度3个评价指标上均不存在显著差异($p>0.05$)。结果表明,本文提出的基于注意力机制的CNN-LSTM模型可以实现患者以舒适速度及慢速运动时对膝关节角度的预测。

3.3 不同运动模式验证模型性能

下肢运动复杂多样,相应的下肢运动意图识别模型应能在多种运动模式下正常预测。为了探究本文所提出的预测模型在不同运动模式下预测膝关节角度的稳定性,本实验将6名受试者水平走、上坡和上楼梯3种运动模式预处理后的信号送入基于注意力机制的CNN-LSTM模型预测膝关节角度。膝关节角度预测波形结果如图9红线所示,其中,图9(a)水平走和图9(b)上坡中膝关节实际角度(黑线)变化较为平滑,图9(c)上楼梯运动膝关节实际角度存在抖动峰值,基于注意力机制的CNN-LSTM预测模型的跟踪效果表现较好。

此外,通过消融实验展示本文预测模型中注意力机制对膝关节角度预测结果的影响,即将预处理后的信号送入无注意力机制CNN-LSTM模型。同时,通过对比传统RBF神经网络模型预测结果,进一步验证本文提出预测模型的优越性。基于上述两种模型预测膝关节角度波形如图9所示,由膝关节角度预测波形结果可知,3种运动模式下,通过CNN-LSTM及RBF神经网络模型预测的膝关节角度与实际角度跟踪效果差,而基于注意力机制的CNN-LSTM预测模型的跟踪效果表现较好。

为进一步对预测模型进行性能分析,根据式(19~21)计算模型预测膝关节角度与实际角度间误差RMSE、MAE和 R^2 。表3显示了6名受试者在3种运动模式下RMSE、MAE和 R^2 平均误差指标。

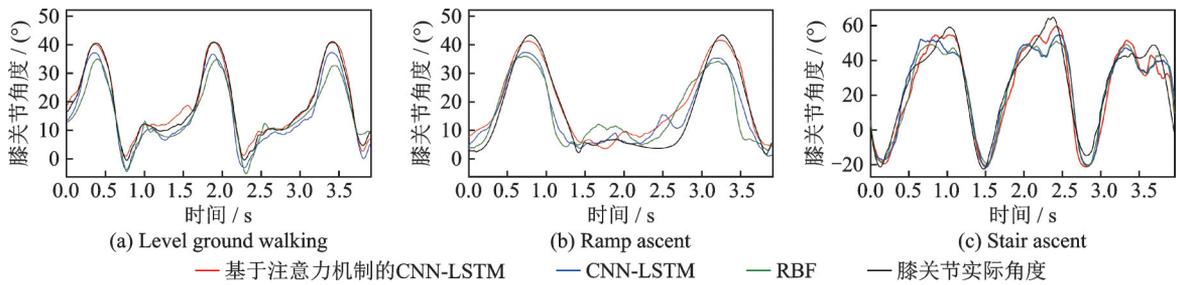


图9 3种运动模式下的膝关节角度的预测结果

Fig.9 Prediction results of knee joint angle in three sport modes

表3 3种运动模式下预测模型实验结果对比

Table 3 Comparison of experimental results of prediction models in three sport modes

预测模型	运动模式	RMSE	RMSE 均值	MAE	MAE 均值	R^2	R^2 均值
基于注意力机制的 CNN-LSTM	水平走	2.70 ± 0.43		2.42 ± 0.33		0.96 ± 0.02	
	上坡	2.72 ± 0.71	2.74 ± 0.42	2.17 ± 0.58	2.50 ± 0.41	0.98 ± 0.02	0.97 ± 0.02
	上楼梯	2.81 ± 0.13		2.92 ± 0.32		0.96 ± 0.02	
CNN-LSTM	水平走	3.75 ± 0.84		4.04 ± 1.49		0.90 ± 0.01	
	上坡	3.60 ± 0.82	3.64 ± 0.73	3.00 ± 0.70	3.36 ± 0.82	0.91 ± 0.01	0.91 ± 0.02
	上楼梯	3.56 ± 0.52		3.04 ± 0.28		0.92 ± 0.02	
RBF	水平走	4.43 ± 0.94		4.36 ± 0.37		0.88 ± 0.02	
	上坡	3.60 ± 0.45	4.05 ± 0.69	3.89 ± 0.53	4.06 ± 0.63	0.94 ± 0.01	0.91 ± 0.01
	上楼梯	4.11 ± 0.69		3.94 ± 1.00		0.91 ± 0.01	

由表3结果可知,在水平走模式下,基于注意力机制的CNN-LSTM模型的评价指标RMSE(2.70 ± 0.43)和MAE(2.42 ± 0.33)的值相对于另外两个预测模型最小,表示预测角度与实际角度之间的误差最小; R^2 值为 0.96 ± 0.02 ,最接近1,表明预测角度与实际角度之间相关性最大,与图9膝关节角度拟合曲线呈现结果一致。此外,上坡和上楼梯运动模式下的3个评价指标与水平走评价结果呈现相同规律。为进一步综合评估基于注意力机制的CNN-LSTM模型在下肢不同运动模式下的预测稳定性,计算3种预测模型的评价指标均值,基于注意力机制的CNN-LSTM预测模型评估指标RMSE、MAE和 R^2 均值分别为 2.74 ± 0.42 、 2.50 ± 0.41 和 0.97 ± 0.02 。相较于CNN-LSTM和RBF模型,基于注意力机制的CNN-LSTM模型RMSE预测精度提高了21.07%~39.05%,而基于注意力机制的CNN-LSTM预测模型相较于无注意力机制的CNN-LSTM模型,预测精度提高了21.07%~28.13%,其预测结果更为准确和稳定。无注意力机制的Encoder-Decoder之间只有一个固定的包含输入信息的中间状态向量 C ,该向量信息的重要性没有特别区分,重要信息容易被忽略,即无注意力机制的CNN-LSTM模型在权重分配上存在不足。由于本文引入注意力机制,可根据输入信息的重要性分配输入权重,加强了激活强度高、对输出角度贡献大的肌电特征数据的重要性,减少某些不重要信息对预测结果的影响,选择性对输入进行加权求出中间状态向量,使Encoder能够更好地捕捉输入序列中的重要信息,从而提高模型预测膝关节角度的准确性和鲁棒性。值得注意的是,3种运动模式下的预测结果的均方根误差(2.70 ± 0.43 、 2.72 ± 0.71 、 2.81 ± 0.13)接近,表明在不同的运动模式下,基于注意力机制的CNN-LSTM预测模型均能稳定预测膝关节角度。不同的运动模式下,人体各块肌肉的激活强度不同,高激活强度肌肉的肌电信号对运动意图识别贡献度大,基于表面肌电信号的运动意图识别中引入注意力机制,使Encoder根据输入序列重要性进行注意力权重的分配,将增强高激活强度的表面肌电信号的重要性,对运动意图识别精度提升具有一定的借鉴意义。传统的RBF模型需要预设参数初始值,对于非线性问题需要大量神经

元提高准确性,计算成本高、预测时间长。

传统的RBF模型平均预测时间为 562.23 ± 0.59 ms,本文提出的算法模型平均预测时间为 157.87 ± 0.43 ms,收敛速度提高了71.92%。综上所述,基于注意力机制的CNN-LSTM预测模型能更加准确和实时地预测膝关节角度,为实际场景预测膝关节角度提供了更为准确的预测参考。

4 结束语

为进一步提高膝关节角度预测的准确性,本文提出了一种新型的采用端对端方法的注意力机制CNN-LSTM模型,实现对膝关节角度的预测。将预处理的10通道sEMG信号作为网络模型的输入,通过CNN网络学习sEMG信号通道之间的相关性,LSTM网络获取信号的时间特征,并引入注意力机制,以增强显著激活肌肉对角度预测的贡献。新的混合框架不仅考虑了多通道之间的相关性,而且忽略了不相关的数据点,有助于提高多通道sEMG信号对膝关节角度的预测精度。通过实验验证,在3种不同日常运动模式下,本文提出的网络模型预测平均误差指标均优于RBF模型的预测结果。进一步,将注意力机制从模型中去除,膝关节角度预测结果平均RMSE、MAE和 R^2 分别下降了20.47%、34.36%和6.59%。由此可见,本文所提出的基于注意力机制的CNN-LSTM模型的端到端预测方法具有更高预测精度和稳定性。因此,该模型在实际的场景预测上能提供更为准确的预测,为下肢外骨骼机器人系统的人机交互控制方案提供参考。下一步工作将针对下肢外骨骼机器人系统进行人机运动交互控制方案研究,考虑将本文算法应用于控制器,以提升人机交互的柔顺性和舒适性。

参考文献:

- [1] XIA Y, LI J, YANG D, et al. Gait phase classification of lower limb exoskeleton based on a compound network model[J]. *Symmetry*, 2023, 15(1): 163.
- [2] 史小华,卢浩,廖梓宇,等.基于表面肌电信号的下肢康复主动训练[J]. *科学技术与工程*, 2018, 18(17): 61-66.
SHI Xiaohua, LU Hao, LIAO Ziyu, et al. Active training of lower limb rehabilitation robot based on sEMG[J]. *Science Technology and Engineering*, 2018, 18(17): 61-66.
- [3] HE Z, QIN Z, KOIKE Y. Continuous estimation of finger and wrist joint angles using a muscle synergy based musculoskeletal model[J]. *Applied Sciences*, 2022, 12(8): 3772.
- [4] YOSHIKAWA M, MIKAWA M, TANAKA K. Hand pose estimation using EMG signals[C]//*Proceedings of the 29th Annual International Conference on IEEE Engineering in Medicine and Biology Society*. [S.l.]: IEEE, 2007: 4830-4833.
- [5] ZHANG F, LI P, HOU Z G, et al. sEMG-based continuous estimation of joint angles of human legs by using BP neural network[J]. *Neurocomputing*, 2012, 78(1): 139-148.
- [6] LI Z, GUAN X, ZOU K, et al. Estimation of knee movement from surface EMG using random forest with principal component analysis[J]. *Electronics*, 2019, 9(1): 43.
- [7] WANG G, LIU Y, SHI T, et al. A novel estimation approach of sEMG-based joint movements via RBF neural network[C]//*Proceedings of 2019 Chinese Automation Congress (CAC)*. [S.l.]: IEEE, 2019: 1783-1788.
- [8] MA C, LIN C, SAMUEL O W, et al. Continuous estimation of upper limb joint angle from sEMG signals based on SCA-LSTM deep learning approach[J]. *Biomedical Signal Processing and Control*, 2020, 61: 102024.
- [9] PARK K H, LEE S W. Movement intention decoding based on deep learning for multiuser myoelectric interfaces[C]//*Proceedings of the 4th International Winter Conference on Brain-Computer Interface (BCI)*. [S.l.]: IEEE, 2016.
- [10] AMERI A, AKHAEI M A, SCHEME E, et al. Regression convolutional neural network for improved simultaneous EMG control[J]. *Journal of Neural Engineering*, 2019, 16(3): 036015.
- [11] WANG G, LIU Y, SHEN Y, et al. sEMG-based multi-joints motion estimation of lower limb utilizing deep convolutional neural network[C]//*Proceedings of 2022 IEEE International Conference on Real-time Computing and Robotics (RCAR)*. [S.l.]: IEEE, 2022: 13-18.
- [12] ZHU M, GUAN X, LI Z, et al. sEMG-based lower limb motion prediction using CNN-LSTM with improved PCA optimization algorithm[J]. *Journal of Bionic Engineering*, 2023, 20(2): 612-627.

- [13] SUN N, CAO M, CHEN Y, et al. Continuous estimation of human knee joint angles by fusing kinematic and myoelectric signals[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2022, 30: 2446-2455.
- [14] ZHAO Y, LI H, WAN S, et al. Knowledge-aided convolutional neural network for small organ segmentation[J]. *IEEE Journal of Biomedical and Health Informatics*, 2019, 23(4): 1363-1373.
- [15] XIAO Y, YIN H, ZHANG Y, et al. A dual-stage attention-based Conv-LSTM network for spatio-temporal correlation and multivariate time series prediction[J]. *International Journal of Intelligent Systems*, 2021, 36(5): 2036-2057.
- [16] HERMENS H J, FRERIKS B, DISSELHORST-KLUG C, et al. Development of recommendations for sEMG sensors and sensor placement procedures[J]. *Journal of Electromyography and Kinesiology*, 2000, 10(5): 361-374.
- [17] 励建安, 孟殿怀. 步态分析的临床应用[J]. *中华物理医学与康复杂志*, 2006(7): 500-503.
LI Jian'an, MENG Dianhuai. Clinical application of gait analysis[J]. *Chinese Journal of Physical Medicine and Rehabilitation*, 2006(7): 500-503.
- [18] 赵军, 张通, 芦海涛, 等. 脑卒中偏瘫步态分析的临床应用[J]. *中国康复理论与实践*, 2013, 19(7): 655-657.
ZHAO Jun, ZHANG Tong, LU Haitao, et al. Application of gait analysis for stroke patients with hemiparesis[J]. *Chinese Journal of Rehabilitation Theory and Practice*, 2013, 19(7): 655-657.
- [19] 卢涛, 王勇, 肖飞云. 基于双姿态传感器的关节运动角度测量方法[J]. *合肥工业大学学报(自然科学版)*, 2021, 44(6): 738-742, 747.
LU Tao, WANG Yong, XIAO Feiyun. A method for measuring joint motion angle based on dual-attitude sensor[J]. *Journal of Hefei University of Technology (Natural Science)*, 2021, 44(6): 738-742, 747.
- [20] 徐光柱, 朱泽群, 尹思璐, 等. 基于轻量级深层卷积神经网络的花卉图像分类系统[J]. *数据采集与处理*, 2021, 36(4): 756-768.
XU Guangzhu, ZHU Zequn, YIN Silu, et al. Flower image classification system based on lightweight DCNN[J]. *Journal of Data Acquisition and Processing*, 2021, 36(4): 756-768.
- [21] 孙林慧, 赵敏, 王舜. 基于深度域适应 CNN 决策树的跨语料库情感识别[J]. *数据采集与处理*, 2023, 38(3): 704-716.
SUN Linhui, ZHAO Min, WANG Shun. Cross-corpus emotion recognition based on deep domain adaptation and CNN decision tree[J]. *Journal of Data Acquisition and Processing*, 2023, 38(3): 704-716.
- [22] LI Y, ZOU L, JIANG L, et al. Fault diagnosis of rotating machinery based on combination of deep belief network and one-dimensional convolutional neural network[J]. *IEEE Access*, 2019, 7: 165710-165723.
- [23] OLSSON A, MALEŠEVIĆ N, BJÖRKMAN A, et al. Exploiting the intertemporal structure of the upper-limb sEMG: Comparisons between an LSTM network and cross-sectional myoelectric pattern recognition methods[C]//*Proceedings of the 41st Annual International Conference on IEEE Engineering in Medicine and Biology Society (EMBC)*. [S.l.]: IEEE, 2019: 6611-6615.
- [24] WANG C, GUO W, ZHANG H, et al. sEMG-based continuous estimation of grasp movements by long-short term memory network[J]. *Biomedical Signal Processing and Control*, 2020, 59: 101774.
- [25] DING Y, ZHU Y, FENG J, et al. Interpretable spatio-temporal attention LSTM model for flood forecasting[J]. *Neurocomputing*, 2020, 403: 348-359.

作者简介:



汤璐(1989-), 通信作者, 女, 博士, 讲师, 研究方向: 生理电信号处理、神经肌肉控制、运动障碍评估, E-mail: tanglu@usst.edu.cn。



杨玺霖(1999-), 女, 硕士研究生, 研究方向: 生物电信号处理及运动意图识别, E-mail: leahyang00@163.com。



王祥瑞(1999-), 男, 硕士研究生, 研究方向: 运动意图识别, E-mail: yepraywong@foxmail.com。



胡倩媛(1999-), 女, 硕士研究生, 研究方向: 运动意图识别, E-mail: 223332515@st.usst.edu.cn。



郑辉(2000-), 男, 硕士研究生, 研究方向: 运动意图识别, E-mail: applehui2020@163.com。