



DOI:10.12404/j.issn.1671-1815.2403062

引用格式:周智伟,陶庆,苏娜,等.基于表面肌电信号的CNN-LSTM模型下肢动作识别[J].科学技术与工程,2025,25(7):2841-2848.

Zhou Zhiwei, Tao Qing, Su Na, et al. Lower limb motion recognition based on surface electromyography and a CNN-LSTM fusion model[J]. Science Technology and Engineering, 2025, 25(7): 2841-2848.

基于表面肌电信号的 CNN-LSTM 模型 下肢动作识别

周智伟¹, 陶庆^{1*}, 苏娜², 刘景轩¹, 李博文¹, 裴浩¹

(1. 新疆大学智能制造现代产业学院, 乌鲁木齐 830017; 2. 新疆医科大学第一附属医院, 医学检验中心, 乌鲁木齐 830054)

摘要 为了提高对下肢运动的分类准确度,提出了一种基于表面肌电信号(surface electromyography, sEMG)的卷积神经网络与长短期记忆网络融合识别模型(convolutional neural network and long short-term memory network, CNN-LSTM)。首先,采集了20名受试者进行上楼、下楼、行走和蹲起4种步态动作的sEMG;接着,对采集到的sEMG数据进行预处理,并提取了两种时域和频域特征,用作机器学习识别模型的特征输入;最后,基于预处理后肌电信号数据,构建了CNN-LSTM的下肢动作识别模型,并与CNN、LSTM和支持向量机(support vector machine, SVM)模型的性能进行对比。结果显示,CNN-LSTM模型在下肢动作识别准确率上分别比CNN、LSTM和SVM模型高出2.16%、8.34%和11.16%,证明了其优越的分类性能。研究结论为康复医疗器械与助力器械提供了一个有效的下肢运动功能改善方案。

关键词 表面肌电信号; 下肢动作识别; CNN-LSTM; 卷积神经网络; 长短期记忆网络

中图分类号 TP301; **文献标志码** A

Lower Limb Motion Recognition Based on Surface Electromyography and a CNN-LSTM Fusion Model

ZHOU Zhi-wei¹, TAO Qing^{1*}, SU Na², LIU Jing-xuan¹, LI Bo-wen¹, PEI Hao¹

(1. College of Intelligent Manufacturing Modern Industry, Xinjiang University, Urumqi 830017, China;

2. Medical Laboratory Center, The First Affiliated Hospital of Xinjiang Medical University, Urumqi 830054, China)

[Abstract] To enhance the classification accuracy of lower limb movements, this paper was introduced a hybrid recognition model based on surface electromyography (sEMG) that combines convolutional neural networks (CNN) with long short-term memory networks (LSTM). Initially, sEMG data were collected from 20 subjects performing four types of gait movements: ascending stairs, descending stairs, walking, and squatting. Subsequently, the collected sEMG data underwent preprocessing, and both time domain and frequency domain features were extracted to serve as inputs for the machine learning recognition model. The CNN-LSTM model was then constructed for lower limb action recognition and compared against the performances of CNN, LSTM, and SVM (support vector machine,) models. The results demonstrate that the CNN-LSTM model outperforms the CNN, LSTM, and SVM models by 2.16%, 8.34%, and 11.16% in accuracy, respectively, thereby proving its superior classification performance. This model provides an effective solution for enhancing lower limb motor functions, offering significant benefits for rehabilitation medical equipment and power assist devices.

[Keywords] surface electromyographic signals; lower limb motion recognition; CNN-LSTM; convolutional neural networks; long short-term memory networks

下肢运动的识别在众多领域中具有显著的应用价值。在康复治疗领域,下肢运动识别可以帮助医生客观地评估患者的身体状态,从而优化康复方案。此外,下肢运动识别使人体与可穿戴动力辅助外骨骼机器人有效结合,从而提高人体的负重能力和工作效率。据报道,识别下肢运动也有望改善老

年、体弱和运动障碍患者的日常生活质量。表面肌电信号(surface electromyography, sEMG)由多个运动单元产生的动作电位叠加而成,其中蕴含了与人类行为密切相关的生物学信息。相较于肌内肌电信号的采集,sEMG的采集过程具有安全性高、可靠性强和无创性等显著优势^[1]。表面肌电信号能够

收稿日期:2024-04-25 修订日期:2024-06-05

基金项目:国家自然科学基金(52365039);自治区天山英才项目(2023TSYCLJ0051)

第一作者:周智伟(1999—),男,汉族,新疆奎屯人,硕士研究生。研究方向:下肢动作识别、深度学习。E-mail:912918131@qq.com。

*通信作者:陶庆(1978—),男,汉族,江苏常熟人,博士,教授。研究方向:先进设计与制造、虚拟现实技术。E-mail:xjtiao@qq.com。

投稿网址:www.stae.com.cn

直接反映肌肉的活动模式,在康复机器人、可穿戴外骨骼控制以及人机交互中得到了广泛的应用。

在表面肌电信号和动态脑电信号的预处理研究方面,主要集中在特征的提取方法与分类算法,旨在实现对多种人体肢体运动模式的高识别率。例如, Totty 等^[2]采用了 K -最近邻 (K -nearest neighbor, KNN) 算法结合肌肉激活数据和运动数据,对功能性手臂活动行为观察系统中的日常生活活动进行了有效分类。崔冰艳等^[3]结合时域与时频域特征的 sEMG 特征空间构造方法,提出了基于 sEMG 的支持向量机 (support vector machine, SVM) 分类器、人工鱼群优化算法 (artificial fish swarm algorithm, AFSA) 优化的 SVM 分类器和深度学习卷积神经网络 (convolutional neural network, CNN) 分类模型,对上肢手势动作进行了识别。史小华等^[4]提出了一种基于表面肌电信号的下肢康复训练模式,通过提取肌电信号特征,并利用反向传播神经网络 (back-propagation neural network, BPNN) 辨识运动意图,将结果作为康复机器人驱动信号,实现主动训练。黄圣等^[5]提出一种使用 sEMG 数据进行手部动作识别的改进的深度森林模型,利用 3 类分类器算法之间的互补性,提高深度森林模型的分类识别准确率,对 16 种常用手部动作的平均识别精度为 94%。Ai 等^[6]从表面肌电信号中提取时域特征和小波系数,并对加速度信号使用动态时间规划 (dynamic time warping, DTW) 距离进行特征提取,采用线性判别分析 (linear discriminant analysis, LDA) 和 SVM 对 5 种下肢动作进行分类。刘国平等^[7]通过改进的 ReliefF 算法对数据预处理后的时域特征向量进行最优选择,并使用基于平衡决策树的支持向量机对 5 种常见的哑铃动作进行分层识别,为个性化哑铃动作指导奠定了基础。赵世昊等^[8]采用数据增强后的 EFM (enhanced feature map) 作为输入样本,并在 CNN 架构中融入 ECA (efficient channel attention) 机制以赋予关键特征信息更高的权重,进一步通过模块化设计调整网络中深层特征提取模块的层数,有效地提高了手势识别的准确度。Xi 等^[9]应用小波变换处理表面肌电信号,并计算得到小波相干系数,使用 SVM 对 6 种日常活动进行分类。刘光达等^[10]提出了一种基于肌电信号的肌肉疲劳分类方法,将遗传算法的交叉变异和改进的果蝇优化算法混合,并与神经网络结合对肌肉疲劳进行识别,实现了肌肉疲劳的准确检测和分类。Sui 等^[11]通过运用小波包变换 (wavelet packet transform, WPT) 来分解表面肌电信号,以提取小波包系数,并从中计算得到的方差和能量作为输入,喂入改进的

SVM 分类器中,对六种上肢动作的识别实现了 90.66% 的准确率。刘声中等^[12]通过改进 sEMG 活动段检测技术,提高了手部运动意图分类的精确度。采用了双级判别自适应门限技术检测 sEMG 的活动段,并将运动意图对应的特征矩阵及其标签用作 LSTM 手部运动意图分类模型的输入与输出,使得 6 种运动意图平均分类精度提升至 91.7%。Gupta 等^[13]记录了 18 名受试者在 3 种下肢运动模式下的双通道肌电信号,并评估了窗口大小、特征向量类型及分类器类型对识别性能的影响,发现选用 256 ms 窗口大小、32 ms 重叠、LDA 分类器以及时间特征向量可获得优良性能。

根据文献[14-15]的研究发现,当前的运动识别技术主要依赖于肌电信号和脑电信号,其中使用表面肌电信号进行下肢动作识别能够在客观条件下实现满意的识别成果。但是,现有的研究下肢动作分类方法一般先提取 sEMG 的特征,然后使用机器学习或深度学习算法对所提取的特征进行识别分类,以实现对手部动作的识别。然而,这种手动提取特征方法只考虑了部分信息,不能完全反映输入数据的整体特性,无法提取出关键的特征,导致在特征提取过程中部分 sEMG 信息缺失,从而影响识别率。因此,为解决上述传统特征提取过程中的信息丢失的问题,本研究基于表面肌电信号提出了 CNN-LSTM 的下肢运动识别模型,该模型能够有效地捕捉肌电信号中的时空特征,提高了下肢动作的识别精度和鲁棒性,能够为下肢运动康复提供更为可靠和高效的解决方案。

1 数据的采集与处理

1.1 数据采集

采集 20 名的健康受试者的 sEMG,其各项身体基本参数如表 1 所示。

在实验开始前,所有受试者均没有遭受骨折、扭伤、肌肉拉伤或其他可能影响运动功能的伤害。且在实验前一周无任何剧烈运动,有效避免了肌肉酸痛或不适。实验设备选用 PLUX 无线肌电采集设备,选择 1 000 Hz 的采样频率。此外,选用氯化银 (AgCl) 材质的肌电电极片和 75% 酒精棉。

如图 1 所示,受试者分别进行了 4 种下肢运动:上楼、蹲起、行走和下楼。其中,每名受试者在进行上楼和下楼这两种下肢运动模式时,每个动作进行

表 1 受试者基本信息

Table 1 Basic information of the subject

年龄/岁	身高/cm	体重/kg
22 ~ 28	160 ~ 189	60 ~ 85



图1 实验场景图

Fig. 1 Diagram of the experimental scene

8组,每组需进行5次,每次运动周期为2s;进行蹲起运动时需进行3组,每组进行20次,每次运动周期为3s;进行行走运动需进行5组,每组运动周期为60s,可得到30组数据,组间休息3~5min,并且在不同的动作之间需要休息10~15min,以避免肌肉疲劳影响结果。

1.2 数据预处理

在sEMG采集过程中,易受环境噪声和其他生物电信号(如心电信号)干扰的特性,故需要进行降噪处理。sEMG中包含有用信息的频率范围主要集中在5~200Hz。因此,本研究采用了30~300Hz的四阶巴特沃斯带通滤波器与50Hz的陷波滤波器来对原始sEMG进行滤波。此外,利用db2小波基进行4层小波分解,并通过小波阈值技术进一步实现降噪。随后,根据各动作周期的初始点将处理后的数据进行分段,其中行走、上楼梯和下楼梯的动作周期定为2s,而蹲起动作的周期设定为3s。采用重叠窗技术对每个动作周期内的sEMG数据段进行进一步的分割。这里选用了1024ms的滑动窗口配合512ms的步进长度,以此将各通道的sEMG细分成序列化的数据窗口。图2为使用滑动窗口技术对单个通道的肌电信号进行分割的过程。




图2 滑动窗口分割图

Fig. 2 Sliding window segmentation diagram

1.3 特征提取

为了从处理后的肌电数据中提取有效信息,供机器学习模型作为特征输入,本研究从采集的肌电信号中同时提取了时域和频域特征,并对这些特征进行了归一化处理。在时域分析中,关键指标包括

肌电信号时间序列 x_i 的绝对平均值(mean absolute value, MAV)和均方根值(root mean square, RMS)。在频域分析中,通过分析肌电信号的功率谱密度函数 $P(f)$,进一步提取平均功率频率(mean power frequency, MPF)和中值频率(median frequency, MF)作为重要的频域特征,计算公式如表2所示。

表2 特征计算公式

Table 2 Feature calculation formula

特征	计算公式
时域	MAV $T_{MAV} = 1/N \sum_{i=1}^N x_i $
	RMS $T_{RMS} = \sqrt{1/N \sum_{i=1}^N x_i^2}$
频域	MPF $F_{MPF} = \int_0^{+\infty} fP(f) df / \int_0^{+\infty} P(f) df$
	MF $\int_0^{F_{MF}} P(f) df = \frac{1}{2} \int_0^{+\infty} P(f) df$

2 CNN-LSTM 模型构建

2.1 CNN

sEMG被认为是一种混合信号,其源于多个肌肉活动的时间和空间上的叠加,这导致了其较高的复杂性^[16]。传统的卷积神经网络多用于图像的处理,难以有效地捕捉一维时间序列数据中的特征。相比之下,一维卷积神经网络(1DCNN)可以更直接地处理时序数据,使模型的参数量更少,并且能够从这些时序顺序中学习特征。因此,本文中选择了1DCNN作为处理sEMG的模型,为动作识别提供有力支持。模型结构如图3所示。

使用包含3个卷积层、池化层、批量标准化层(batch normalization, BN)、3个全连接层以及一个Dropout层的1DCNN模型。在卷积层中,输入信号会经过一维卷积处理,计算公式为

$$h_j^l = \sum_{i=1}^n x_i^l \otimes k_{ij}^l + b_j^l \quad (1)$$

式(1)中: l 为层数; j 为元素序号; n 为输入特征向量的长度; h 为输出特征向量; x 为输入特征向量; k 为卷积核; b 为偏置向量; \otimes 为卷积操作。

为了增强模型的训练效率与稳定性,在每个卷积层后使用BN归一化,计算过程如下。

首先,沿Batch的维度计算相同通道的均值与方差,计算公式为

$$\mu_B = \frac{1}{n} \sum_{i=1}^n x_i \quad (2)$$




图3 1DCNN 模型结构
Fig.3 1DCNN model structure

$$\sigma_B^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \mu_B)^2 \quad (3)$$

然后,对相同 Batch 维度上的均值和方差做归一化,计算公式为

$$\hat{x}_i = \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \varepsilon}} \quad (4)$$

式(4)中: ε 为一个较小的正数,通常用于确保数值稳定性,避免分母出现零值的情况。

其次,通过学习两个参数 γ (缩放因子) 和 β (平移因子) 来恢复特征值可能需要的任何缩放和平移,计算公式为

$$y_i = \gamma \hat{x}_i + \beta \quad (5)$$

最后,在经过每个 BN 后采用 ReLU 激活函数,计算公式为

$$\text{ReLU}(x) = \max(0, x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (6)$$

为了提高模型训练速度,本研究采用最大池化进行降采样。在训练阶段,为了评估模型输出的概率分布与真实标签的概率分布之间的偏差,本文中选用交叉熵损失函数,计算公式为

$$L(\theta) = -\frac{1}{n} \left[\sum_{i=1}^n \sum_{k=1}^K I\{y_i = k\} \lg \frac{\exp(\theta_k^T x)}{\sum_{j=1}^K \exp(\theta_j^T x)} \right] \quad (7)$$

式(7)中: $I\{y_i = k\}$ 为一个指示函数,表示当样本 i 的真实类别 y_i 等于类别 k 时,取值为 1,否则取值为 0; K 表示类别数; θ 为模型的参数。

此外,为了优化学习过程并最小化损失函数,本研究采用 Adadelta 优化器来自动调整学习率。在 3 个全连接层中间插入两个 Dropout 层,以增强模型的泛化能力并避免过拟合。如表 3 所示为网络模型配置。

表3 1DCNN 模型参数配置

Table 3 1DCNN model parameter configuration

网络层	卷积核数目	卷积核尺寸	步长	输出维度
卷积层 1	64	3 × 1	5	64 × 1 020
BN1 + ReLU	—	64	—	64 × 1 020
池化层 1	64	2 × 2	—	64 × 510
卷积层 2	32	3 × 1	3	32 × 508
BN2 + ReLU	—	32	—	32 × 508
池化层 2	32	2 × 2	—	32 × 254
卷积层 3	10	3 × 1	3	10 × 252
BN3 + ReLU	—	10	—	10 × 252
池化层 3	10	2 × 2	—	10 × 126
全连接层 1	1	1 260	—	1 260 × 1
全连接层 2	1	600	—	600 × 1
全连接层 3	1	100	—	100 × 1

2.2 LSTM

长短时记忆网络 (long short-term memory, LSTM) 是一种特殊的循环神经网络,通过引入门控单元来控制数据流,从而有效解决传统循环神经网络在处理长序列数据时遭遇的梯度消失和梯度爆炸问题^[17]。肌电信号通常包含复杂的时间动态,这些动态可能在较长的时间尺度上展现出相关性,而 LSTM 的特有结构使其能够学习这些长期依赖关系。LSTM 网络的结构如图 4 所示。

LSTM 的工作机制包括:当前输入 x_t 和先前时间步的隐藏状态 h_{t-1} 通过 sigmoid 函数处理生成遗忘门输出 f_t ,该输出在 0 ~ 1 之间变化。输出值为 0 时表示“完全遗忘”,为 1 时表示“完全保留”。计算公式为

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (8)$$

式(8)中: w_f 为权重; σ 为 sigmoid 激活函数; b_f 为偏置。

输入门在单元状态更新的过程中扮演者关键角

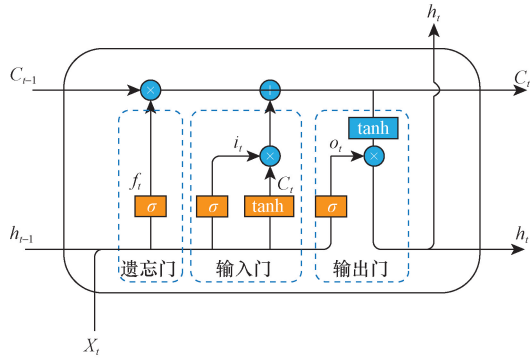


图4 LSTM 模型结构

Fig. 4 LSTM model structure

色。首先,通过 sigmoid 确定需要更新的信息部分,生成输入门的输出 i_t 。其次,通过 tanh 层生成一个新的候选值 \tilde{C}_t ,该向量表示可能被添加到状态中的新信息。最终,将遗忘门的输出 f_t 与前一单元状态 C_{t-1} 相乘,以舍弃无用信息,并将输入门的输出 i_t 与候选值 \tilde{C}_t 相乘,以此来更新新的单元状态 C_t 。计算公式为

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (9)$$

$$\tilde{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (10)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (11)$$

式中: \tilde{C}_t 表示候选值; $f_t * C_{t-1}$ 表示选择性忘记不相关信息; $i_t * \tilde{C}_t$ 表示保留有用信息。

在 LSTM 中,输出门经过 sigmoid 层决定应被输出的单元状态,将单元状态通过 tanh 层调整后与 sigmoid 层的输出相乘,以产生最终的输出 h_t 。计算公式为

$$O_t = (W_o[h_{t-1}, x_t] + b_o) \quad (12)$$

$$h_t = O_t * \tanh(C_t) \quad (13)$$

式中: O_t 表示输出门的激活函数。

在本研究中 LSTM 网络参数配置如表 4 所示。

表 4 LSTM 模型参数配置

Table 4 LSTM model parameters configuration

参数名称	符号或数值
损失函数	Cross Entropy
优化器	Adadelta
层数	3
LSTM 单元	100
批量大小	40
学习率	0.001

2.3 CNN-LSTM 模型

在上述分析的基础上,本研究构建了一个基于 sEMG 的 CNN-LSTM 下肢运动识别模型,其整体框架结构如图 5 所示。首先,将预处理过的 sEMG 输入至 CNN 层进行特征提取;随后经过两个全连接层,然后进入 LSTM 层;最终,再通过全连接层来生成最终的分类决策。针对多通道 EMG 信号, CNN 能够解析不同肌肉之间的相互作用及其空间布局;而 LSTM 则优秀地处理了时间序列数据,记忆了信息的长期依赖。通过并联这两种模型,能够对 sEMG 进行高效且精确的识别。

3 结果分析

3.1 评价指标

在对分类任务的性能进行评估中,本论文采用了四项核心统计度量以作为衡量分类模型的评价标

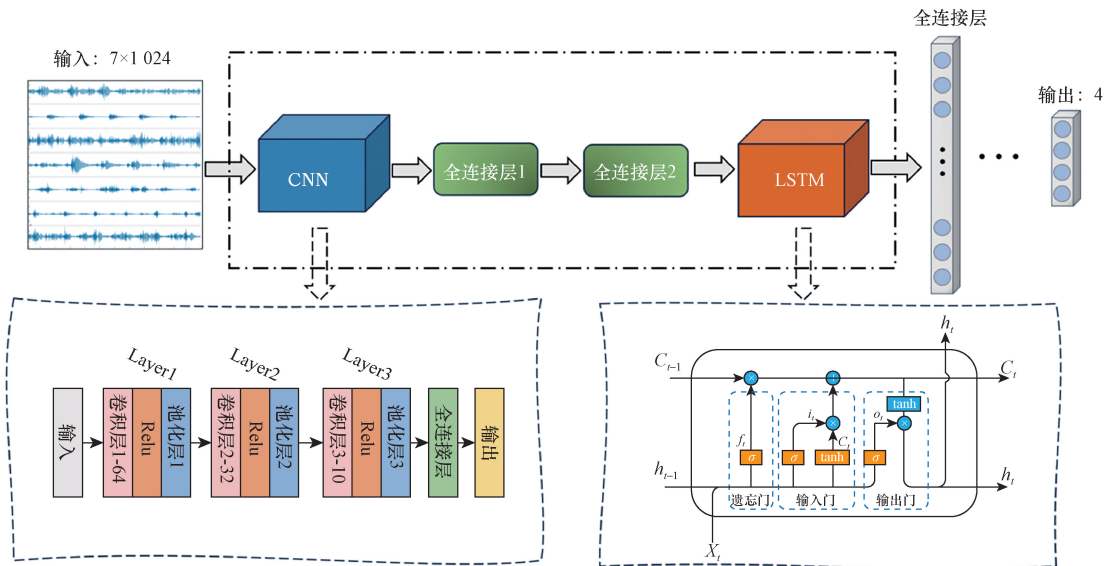


图5 CNN-LSTM 总体架构

Fig. 5 CNN-LSTM overall architecture

准,具体为准确率 A (accuracy)、精确率 P (precision)、召回率 R (recall) 及 F_1 (F_1 -score)。这一组指标综合反映了分类模型性能的多个维度,为模型表现的全面评价提供了依据。计算公式为

$$A = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (14)$$

$$P = \frac{TP}{TP + FP} \times 100\% \quad (15)$$

$$R = \frac{TP}{TP + FN} \times 100\% \quad (16)$$

$$F_1 = 2 \frac{RP}{R + P} \times 100\% \quad (17)$$

式中:TN 代表正确识别为负类的负样本数;TP 表示被准确划分为正类的正样本数;FN 表示指正样本错误地被归类为负类的情况数;FP 表示负样本被误判为正类的实例数量。

3.2 实验结果分析

在对 CNN-LSTM 模型进行了 300 轮的训练过程中,追踪了模型损失值的变化,并通过分析训练与测试损失的曲线变化来评估模型的拟合质量,如图 6 所示。训练结果表明,模型的损失值降至 2.1%,同时,模型的识别精度达到了 92.37%,这进一步证实了 CNN-LSTM 模型展现出的优良收敛性。

如图 7 所示为提出的 4 种分类模型识别方案的结果对比。根据图表数据,CNN-LSTM 模型在各项性能指标上表现出了显著成绩。具体而言,模型的准确率达到 92.37%、精确率为 91.10%、召回率为 92.23%,以及 F_1 为 91.66%。相比之下,CNN-LSTM 模型的准确率比 CNN 模型高 2.16%,比 LSTM 模型提升了 8.34%,且较 SVM 模型增加了 11.16%。在精确率、召回率和 F_1 3 个指标上,与 CNN 模型相比,CNN-LSTM 模型分别提高了 2.16%、5.27%、3.72%;与 LSTM 模型相比,分别提升了 4.46%、9.86%、7.21%;与 SVM 模型相比,增幅分




图 6 CNN-LSTM 模型损失曲线

Fig. 6 The loss curve of the CNN-LSTM model

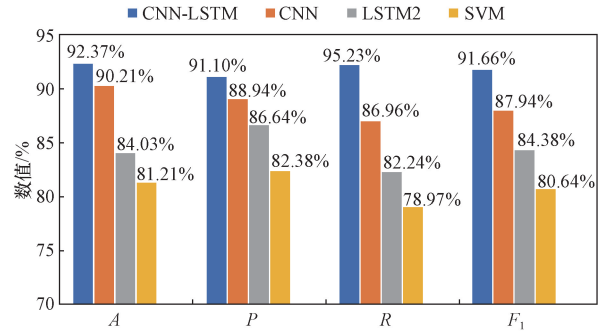


图 7 4 种分类模型性能对比

Fig. 7 Comparison of the performance of the 4 classification models

别为 8.72%、13.26%、11.02%。这些对比结果表明,CNN-LSTM 模型在下肢动作识别方面比 CNN、LSTM 以及 SVM 模型具有更高的适应性和优越性。

为了比较不同的下肢动作识别模型的性能,将 CNN、LSTM、CNN-LSTM、SVM 等模型使用相同测试数据进行测试。在处理不同的下肢动作时,首先计算了测试样本被分类为特定类别的概率,随后基于这些概率,对各个阈值条件下的假正率与真正率进行了计算,并据此绘制了相应的 ROC 曲线。针对每种下肢动作,在各个测试集中分别生成了对应的 ROC 曲线。通过对每种动作识别模型产生的 ROC 曲线进行平均处理,获得了每种模型针对下肢动作识别任务的综合 ROC 曲线,如图 8 所示。

如图 9 所示为通过 4 种不同模型的混淆矩阵,展示了对下肢动作进行四分类的结果,明显展现出所提出的 CNN-LSTM 模型能够从下肢 7 通道的表面肌电图信号中,准确地识别出各类下肢动作。在混淆矩阵中,对角线元素代表每个动作正确分类的样本数,而非对角线元素揭示了分类错误的样本数。动作分类包括:0 表示行走,1 表示上楼梯,2 表示下楼梯,以及 3 表示蹲起动作。

4 结论

(1) 由于 CNN 模型对于较长序列的肌电信号的全局信息捕捉能力较差,结合 LSTM,提出了 CNN-LSTM 模型。该模型能够捕捉全局信息和序列关系,解决了 CNN 模型局部特征信息缺失的问题。

(2) 本研究构建并评估了 4 种不同的动作识别模型,旨在识别下肢康复训练中的 4 种动作。从 20 位参与者收集的 sEMG 中,提取了 MAV、RMS、MPF 和 MDF4 个关键特征值,应用于机器学习模型的输入。将预处理后的 sEMG 数据应用于 CNN、LSTM、SVM 模型的学习与训练,本研究比较了各模型在下肢动作识别任务上的效果。实验结果显示,CNN-LSTM 模型在测试数




图 8 4 种分类模型 ROC 曲线

Fig. 8 ROC curves for 4 classification models

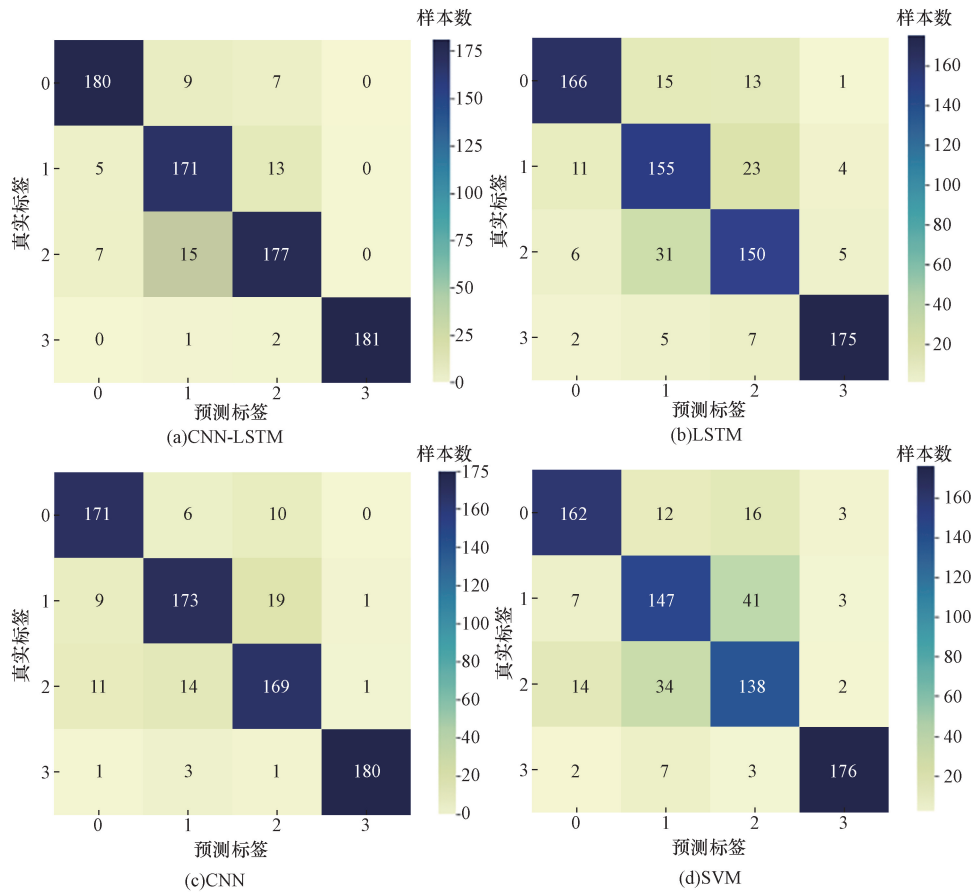


图 9 4 种模型的混淆矩阵

Fig. 9 Confusion matrices for 4 models

据上的平均准确率达到 92.37%。

因此,本研究提出的 CNN-LSTM 模型相较于其他模型展现出显著的优势,验证了其在下肢动作识别领域的卓越性能。在未来工作中,本研究计划将参与者群体从健康人群扩展到下肢功能受损的患者,并进一步规范肌电信号的采集流程,以此提高基于 sEMG 的下肢康复机器人在不同患者群体中的动作识别准确率。此外,还将探索和改进不同的训练模型,以优化动作识别的性能。

参 考 文 献

- [1] Yang C, Xi X G, Chen S J, et al. sEMG-based multifeatures and predictive model for knee-joint-angle estimation[J]. AIP Advances, 2019, 9(9): 095042.
- [2] Totty M S, Wade E. Muscle activation and inertial motion data for noninvasive classification of activities of daily living[J]. IEEE Transactions on Biomedical Engineering, 2018, 65: 1069-1076.
- [3] 崔冰艳, 邓嘉, 张祥. 基于表面肌电信号的手势识别方法[J]. 科学技术与工程, 2023, 23(35): 15133-15141.
Cui Bingyan, Deng Jia, Zhang Xiang. Hand gesture recognition based on surface electromyography[J]. Science Technology and Engineering, 2023, 23(35): 15133-15141.
- [4] 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 based on surface electromyography signal[J]. Science Technology and Engineering, 2018, 18(17): 61-66.
- [5] 黄圣, 茅健. 基于改进深度森林的表面肌电手势识别方法[J]. 上海工程技术大学学报, 2023, 37(2): 190-197.
Huang Sheng, Mao Jian. Recognition method of sEMG gesture based on improved deep forest[J]. Journal of Shanghai University of Engineering Science, 2023, 37(2): 190-197.
- [6] Ai Q. Research on lower limb motion recognition based on fusion of sEMG and accelerometer signals[J]. Symmetry, 2017, 9(8): 147.
- [7] 刘国平, 王南星, 周毅, 等. 基于改进 ReliefF 算法的哑铃动作识别[J]. 科学技术与工程, 2019, 19(32): 219-224.
Liu Guoping, Wang Nanxing, Zhou Yi, et al. Recognition of dumbbell movements based on an improved reliefF algorithm[J]. Science Technology and Engineering, 2019, 19(32): 219-224.
- [8] 赵世昊, 周建华, 伏云发. 注意力机制 CNN 结合肌电特征矩阵的手势识别研究[J]. 电子测量与仪器学报, 2023, 37(6): 59-67.
Zhao Shihao, Zhou Jianhua, Fu Yunfa. Investigation of gesture recognition using attention mechanism CNN combined electromyography feature matrix[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(6): 59-67.
- [9] Xi X G, Yang C, Shi J H, et al. Surface electromyography-based daily activity recognition using wavelet coherence coefficient and support vector machine[J]. Neural Processing Letters, 2019, 50(3): 2265-2280.
- [10] 刘光达, 许蓝予, 肖若兰, 等. 基于 FGNN 算法的 sEMG 肌肉疲劳分类方法[J]. 科学技术与工程, 2022, 22(19): 8370-8377.
Liu Guangda, Xu Lanyu, Xiao Ruolan, et al. Muscle fatigue classification method of sEMG signal based on FGNN algorithm[J]. Science Technology and Engineering, 2022, 22(19): 8370-8377.
- [11] Sui X W, Wan K X, Zhang Y. Pattern recognition of sEMG based on wavelet packet transform and improved SVM[J]. Optik, 2019, 176: 228-235.
- [12] 刘声中, 许德章. 一种基于改进 sEMG 活动段检测的手部运动意图识别新方法[J]. 嘉兴学院学报, 2022, 34(6): 105-112.
Liu Shengzhong, Xu Dezhong. A new method for hand motion intent recognition based on improved sEMG signal active segment detection[J]. Journal of Jiaxing University, 2022, 34(6): 105-112.
- [13] Gupta R, Agarwal R. Electromyographic signal-driven continuous locomotion mode identification module design for lower limb prosthesis control[J]. Arabian Journal for Science and Engineering, 2018, 43(12): 7817-7835.
- [14] Reaz M, Hussain M, Mohd-Yasin F. Techniques of EMG signal analysis: detection, processing, classification and applications (Correction)[J]. Biological Procedures Online, 2006, 8(1): 11-35.
- [15] Xu H, Xiong A. Advances and disturbances in sEMG-based intentions and movements recognition: a review[J]. IEEE Sensors Journal, 2021, 21(12): 13019-13028.
- [16] Chiang J, Wang Z J, & McKeown M. A hidden Markov, multivariate autoregressive (HMM-mAR) network framework for analysis of surface EMG (sEMG) data[J]. IEEE Transactions on Signal Processing, 2008, 56(8): 4069-4081.
- [17] 王睿, 杨建荣. 基于长短时记忆神经网络易损性分析的适用性研究[J]. 四川建筑科学研究, 2024, 50(2): 9-15.
Wang Rui, Yang Jianrong. Study on the applicability of vulnerability analysis based on long short-term memory neural network[J]. Sichuan Building Science, 2024, 50(2): 9-15.