

DOI: 10.19650/j.cnki.cjsi.J2312041

基于 sEMG 的下肢连续运动切换态实时识别方法*

石欣¹, 敖钰民¹, 范智瑞¹, 余可祺¹, 秦鹏杰²

(1. 重庆大学自动化学院 重庆 400044; 2. 中国科学院深圳先进技术研究院 深圳 518055)

摘要: 在外骨骼与人进行自然人机交互(HRI)过程中,准确快速地识别下肢连续运动中的切换态至关重要。切换态 sEMG 信号即包含切换前后运动信息,又包含切换的瞬态信息,难以直接用于识别。为了快速准确地识别切换态,本文提出了 FMICMD-LACNN 的实时识别方法。提出了自适应多分量瞬时频率估计方法来提高多元本征线性调频模式分解(MICMD)计算效率,提出了分量能量惩罚因子提高 MICMD 分解精度,从而形成了快速多元本征调频模式分解(FMICMD)算法。针对 FMICMD 分解后 sEMG 信号,构建了 LACNN 识别模型,实现了快速且准确的切换态识别。本研究采集了 10 名受试者 8 种常见下肢连续运动切换态下的 sEMG 信号进行实验验证。结果表明,对于这 8 种切换态,该方法平均识别准确率为 98.35%,平均识别时间仅约 8 ms,均优于 CNN-LSTM、E2CNN 以及 CNN-BiLSTM 方法。该方法具有较高的准确率和实时性,能够满足外骨骼与人体快速自然交互的需求。

关键词: 运动意图识别;表面肌电信号;MICMD;CNN

中图分类号: TH70 文献标识码: A 国家标准学科分类代码: 510.40

Real-time recognition method of switching states of continuous lower limb movements based on sEMG

Shi Xin¹, Ao Yumin¹, Fan Zhirui¹, Yu Keqi¹, Qin Pengjie²

(1. School of Automation, Chongqing University, Chongqing 400044, China; 2. Shenzhen Institute of Advanced Technology, Chinese Academy of Sciences, Shenzhen 518055, China)

Abstract: Accurately and rapidly identifying the switching states in continuous lower limb movements is crucial for natural human-robot interaction (HRI) with exoskeletons. The switching state sEMG signals contain both pre-and post-switching movement information, as well as transient information related to the switching, making them difficult to directly use for recognition. In order to quickly and accurately identify the switching states, this paper proposes a real-time recognition method called FMICMD-LACNN. An adaptive multi-component instantaneous frequency estimation method is proposed to improve the computational efficiency of the multivariate intrinsic chirp mode decomposition (MICMD), and a component energy penalty factor is proposed to enhance the decomposition accuracy of MICMD, thus forming the fast multivariate intrinsic chirp mode decomposition (FMICMD) algorithm. For the sEMG signals decomposed by FMICMD, a LACNN recognition model was established to achieve fast and accurate switching states identification. This study collected sEMG signals from 10 subjects in 8 common lower limb continuous motion switching states for experimental verification. The results show that for these 8 switching states, the average recognition accuracy of this method is 98.35%, and the average recognition time is only about 8 ms, which is better than the CNN-LSTM, E2CNN and CNN-BiLSTM methods. This method has high accuracy and real-time performance, and can meet the needs of fast and natural interaction between the exoskeleton and the human body.

Keywords: movement intention recognition; sEMG; MICMD; CNN

0 引言

机器人技术目前在各行各业中应用广泛。在爬升、救援、军事等特殊工作场景中,外骨骼机器人因其可以减轻人体负荷,提高工作效率,已经成为近年来研究的热点^[1]。

目前,外骨骼研究的一个难点在于如何解决人机自然交互问题。如果不能准确获得人体运动意图,外骨骼就可能造成人机不协调甚至人体伤害的后果。特别是当行走的环境发生转换时,外骨骼的驱动模式也要自然过渡,以匹配人体运动。因此,快速准确获取人体运动状态切换意图是实现外骨骼与人体自然协同的关键。

在下肢连续运动切换态识别研究方面,Grimmer等^[2]采集平地行走(level walking, LW)和楼梯行走(stair walking, SW)之间4种切换态的动作捕捉数据并解析其中的动力学和预动作数据,然后使用方差多元分析来检测切换态的开始和结束时刻。Chen等^[3]使用惯性测量单元(inertial measurement unit, IMU)收集运动信息,然后使用LSTM-CNN模型对步行、上楼梯(stair ascending, SA)、下楼梯(stair descending, SD)、坐着-站立(stand up, S-U)、站着-坐下(sit down, S-D)5种状态进行识别,分类精度达到97.78%。Sheng等^[4]采集平地行走、上坡(ramp ascending, RA)、下坡(ramp descending, RD)、上楼梯、下楼梯5种稳态运动状态间8种切换态的IMU数据,然后使用双复数小波变换提取特征并使用支持向量机进行识别,精度达到了98.92%。

总的来说,目前切换态识别方法在识别精度上已经较高,但由于运动学和动力学以及IMU数据滞后于动作产生的特性^[5],再加上外骨骼控制也需要一定时间,这些基于运动学数据的方法难以用于外骨骼运动模式柔顺切换。而表面肌电(surface electromyographic, sEMG)信号

因为其提前于人体动作30~150 ms产生^[6],包含丰富运动信息^[7]以及非侵入的采集和低时延的特性^[8],成为理解人体运动意图的重要方式^[9-14]。

sEMG信号是一种微弱的生理信号,具有混沌性、非平稳性和动态时变性。使用切换态sEMG信号快速准确识别连续运动中的切换态具有一定困难。为解决这些问题,本文提出了FMICMD-LACNN下肢连续运动模态切换识别方法。具体而言,先提出了快速多元本征调频模态分解(fast multivariate intrinsic chirp mode decomposition, FMICMD)对多通道sEMG信号进行分解以扩充特征信息,然后使用基于局部注意力机制的卷积神经网络(convolutional neural network based on local attention, LACNN)识别日常生活中常见的8种下肢连续运动切换态^[15]。通过实验证明,本文所提方法有较高的准确率,达到了98.35%,在实时性上表现也较好,平均识别时间仅约8 ms。

1 数据预处理

1.1 sEMG信号采集

本文搭建的实验环境示意图如图1所示,从左到右分别是平地、楼梯、平地、坡道、平地场景。本文采用的sEMG传感器是英国Biometrics公司生产的无线sEMG传感器,足底压力传感器型号为FS-INS-3Z-V2。10个采样率为1 000 Hz的sEMG传感器分别放置在左右腿的股直肌、股内侧肌、股二头肌、胫骨前肌和内侧腓肠肌,两个足底压力传感器被放置在鞋中。sEMG传感器的电极放置方式遵循SENIAM^[16]的建议。受试者在实验场景中从左至右运动可以采集到LW-RA, RA-LW, LW-SD, SD-LW 4种运动模态切换时的信号,反之可以采集到LW-SA, SA-LW, LW-RD, RD-LW 4种信号。

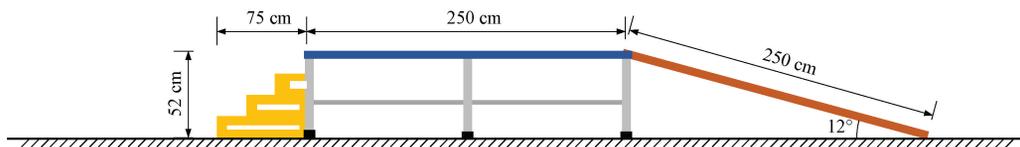


图1 实验场地示意图

Fig. 1 Experimental site

本次实验共招募10名健康受试者,受试者均为男性,年龄20~31岁,身高1.68~1.82 m,体重60.3~81.6 kg。所有受试者在实验开始前均被告知实验内容,并签署知情同意书。每位受试者在开始采集sEMG信号前均会使用酒精棉片擦拭皮肤,以防止皮肤杂质干扰。

1.2 数据预处理

为清楚的标定当前受试者运动模态,以脚完全离地

作为切换态的起始点,再次接触到地面作为结束点。当脚离地后处于摆动态时,足底压力接近为0,而当脚再次接触地面时,足底压力会快速上升。因此,当足底压力低于阈值 th 时为切换态起始点,大于阈值 th 为结束点。经过实验测试和比较,本文设定 $th = 1.5$ 。sEMG信号高度敏感,容易受到外界干扰,从而影响模型的分类结果^[17-19]。为了降低噪声对信号的影响,所有的sEMG信

号均经过低频截止频率为 20 Hz 高频截止频率为 250 Hz 的巴特沃斯 4 阶带通滤波以及 50 Hz 的陷波滤波。随后将每种切换态的数据按照窗长为 100 ms 无重叠划窗的方式划分为多个数据片段。每个类别的样本量在 958 ~ 1 499 之间。为了保持类别的平衡,仅使用每个类别的前 958 个数据片段。

2 FMICMD-LACNN 识别方法

切换态的 sEMG 信号相较于稳态信号更加复杂,一方面其包含切换前后稳态的运动信息,另一方面又包含一些瞬态信息。

在过去,以往研究所使用的时域、频域、和时频域特征^[20-22]存在参数选取是经验性的,特征表达能力有限,特征鲁棒性和区分性不够等问题。为了解决这些问题,可以先将切换态 sEMG 信号分解以扩展特征信息,然后使用可以自动学习深度语义信息的深度学习模型进行进一步的特征抽取和分类识别。

基于对实时性和分解精度要求的考虑,本文对多元本征调频模态分解 (multivariate intrinsic chirp mode decomposition, MICMD)^[23]进行了改进提出了 FMICMD,然后设计了一个基于局部注意力^[24]的深度卷积神经网络 LACNN 模型对分解后的特征张量进行进一步的特征提取、特征强化以及冗余消除,最后实现快速准确的识别目标。

2.1 快速多元本征调频模态分解 FMICMD

1) 多元本征调频模态分解

相较于使用较多的多元经验模态分解 (multivariate empirical mode decomposition, MEMD)^[25]和多元变分模态分解 (multivariate empirical mode decomposition, MVMD)^[26],Chen 等^[23]提出的 MICMD 在多通道非平稳信号快速分解任务上有很大的潜力。

MICMD 假设多通道信号 $\mathbf{X}(t)$ 的不同通道对应分量的瞬时频率 (instantaneous frequency, IF) 相同,通过调频调频的方式重构:

$$\mathbf{X}(t) = \sum_{k=1}^K \begin{bmatrix} \alpha_{k,1}(t) \\ \alpha_{k,2}(t) \\ \vdots \\ \alpha_{k,v}(t) \end{bmatrix} \cos\left(2\pi \int_0^t f_k(\tau) d\tau\right) + \begin{bmatrix} \beta_{k,1}(t) \\ \beta_{k,2}(t) \\ \vdots \\ \beta_{k,v}(t) \end{bmatrix} \sin\left(2\pi \int_0^t f_k(\tau) d\tau\right) + \eta(t) \quad (1)$$

其中, K 代表分量数, V 表示信号通道数, $\alpha_{k,v} = a_{k,v} \cos(\phi_k)$, $\beta_{k,v} = -a_{k,v} \sin(\phi_{k,v})$, $f_k(\tau)$ 表示第 k 个分量

的 IF, $\eta(t)$ 为噪声和分解误差。利用冗余傅里叶级数对瞬时振幅 $a_{k,v}$ 与瞬时频率 $f_k(t)$ 进行拟合:

$$\alpha_{k,v}(t) = \alpha_{k,v}^0 + \sum_{p=1}^{P_A} \left(\alpha_{k,v}^p \cos(2\pi p F_B t) + \bar{\alpha}_{k,v}^p \sin(2\pi p F_B t) \right)$$

$$\beta_{k,v}(t) = \beta_{k,v}^0 + \sum_{p=1}^{P_A} \left(\beta_{k,v}^p \cos(2\pi p F_B t) + \bar{\beta}_{k,v}^p \sin(2\pi p F_B t) \right) \quad (2)$$

$$f_k(t) = f_k^0 + \sum_{p=1}^{P_F} \left(f_k^p \cos(2\pi p F_B t) + \bar{f}_k^p \sin(2\pi p F_B t) \right)$$

其中, P_A 以及 P_F 分别代表瞬时幅值 (instantaneous amplitude, IA) 和 IF 的傅里叶阶数。 P_A 用于调节每个时刻 IA 的震荡程度。 P_F 用来控制 IF 误差。 $F_B = f_s / LN$ 为基频。根据文献^[27]的建议,本文取 $l = 2$ 。式(2)中需要求解的参数为:

$$\theta_{k,v}^\alpha = [\alpha_{k,v}^0, \alpha_{k,v}^1, \dots, \alpha_{k,v}^{P_A}, \bar{\alpha}_{k,v}^1, \dots, \bar{\alpha}_{k,v}^{P_A}]^T$$

$$\theta_{k,v}^\beta = [\beta_{k,v}^0, \beta_{k,v}^1, \dots, \beta_{k,v}^{P_A}, \bar{\beta}_{k,v}^1, \dots, \bar{\beta}_{k,v}^{P_A}]^T$$

$$\theta_k^f = [f_k^0, f_k^1, \dots, f_k^{P_F}, \bar{f}_k^1, \dots, \bar{f}_k^{P_F}]^T$$

此外,由式(2)可以看出,幅值与频率的参数呈线性关系,如果 IF 参数已知,则可以通过求解一组线性方程来计算相应的 IA 的参数。

MICMD 将多通道信号累加后,采用如式(3)所示广义参数化时频变换 (general parameterized time-frequency transform, GPTFT)^[28]来获取其时频图。

$$TF(t, f, \mathbf{X}; \sigma) = \int_{-\infty}^{+\infty} \bar{\mathbf{m}}_A(\tau) \omega_\sigma(\tau - t) e^{-j2\pi f \tau} d\tau \quad (3)$$

变换后,通过多次迭代拟合时频脊线^[29]即可得出所有分量 IF。

MICMD 使用最小二乘模型求解 IA 参数。为了更好地解释 MICMD 方法,将 $\mathbf{X}(t)$ 重写为下式:

$$\mathbf{X} = \Phi \Theta + \eta \quad (4)$$

式中: $\mathbf{X} = [x_1, x_2, \dots, x_v]$, \mathbf{X} 的形状为 $N \times V$, V 代表通道数, N 代表信号长度, η 表示噪声和分解误差,核矩阵 $\Phi = [\Phi_1, \Phi_2, \dots, \Phi_K]$ 包含着模型信息。

$$\text{其中: } \Phi_k = [C_k \Psi \quad S_k \Psi]$$

$$C_k = \text{diag}[\cos(\theta_k(t_0)) \cdots \cos(\theta_k(t_{N-1}))]$$

$$S_k = \text{diag}[\sin(\theta_k(t_0)) \cdots \sin(\theta_k(t_{N-1}))]$$

$$\theta_k(t_i) = 2\pi \int_0^{t_i} f_k(\tau) d\tau$$

Ψ 是一个 $N \times (2P_A + 1)$ 的矩阵, Ψ 中的元素为:

$$\Psi_{n,p} = \begin{cases} \cos(2\pi(p-1)F_B t_{n-1}), & (1 \leq p \leq P_A + 1) \\ \sin(2\pi(p-P_A-1)F_B t_{n-1}), & (P_A + 2 \leq p \leq 2P_A + 1) \end{cases}$$

Θ 为待求瞬时幅值冗余傅里叶模型系数矩阵:

$$\Theta = \begin{bmatrix} \theta_{1,1}^\alpha & \theta_{1,2}^\alpha & \cdots & \theta_{1,v}^\alpha \\ \theta_{1,1}^\beta & \theta_{1,2}^\beta & & \theta_{1,v}^\beta \\ \theta_{2,1}^\alpha & \theta_{2,2}^\alpha & & \theta_{2,v}^\alpha \\ \theta_{2,1}^\beta & \theta_{2,2}^\beta & \ddots & \theta_{2,v}^\beta \\ \vdots & \vdots & & \vdots \\ \theta_{K,1}^\alpha & \theta_{K,2}^\alpha & & \theta_{K,v}^\alpha \\ \theta_{K,1}^\beta & \theta_{K,1}^\beta & \cdots & \theta_{K,v}^\beta \end{bmatrix}$$

通过计算参数矩阵 Θ 可以恢复所需的模态。假设得到的参数使分解误差最小,为了避免矩阵伪逆引起的不适定问题,在解中引入了正则化项 λ , 如下:

$$\min_{\Theta} \|\mathbf{X} - \Phi\Theta\|_F^2 + \lambda \|\Theta\|_F^2 \quad (5)$$

其中, $\|\cdot\|^2$ 为 Frobenius 范数的平方, λ 可以调节数据保真度和扰动灵敏度之间的权衡。可以写出上式的解析解为:

$$\tilde{\Theta} = (\Phi^T\Phi + \lambda I)^{-1}\Phi^T\mathbf{X} \quad (6)$$

其中, I 是一个与 $\Phi^T\Phi$ 大小相同的单位矩阵, $\tilde{\cdot}$ 符号来表示估计值。由此可用式(7)估计出 IA:

$$\tilde{a}_{k,v}(t) = \sqrt{(\Psi\tilde{\theta}_{k,v}^\alpha)^2 + (\Psi\tilde{\theta}_{k,v}^\beta)^2} \quad (7)$$

由于 $\tilde{\theta}_{k,v} = [\tilde{\theta}_{k,v}^\alpha \quad \tilde{\theta}_{k,v}^\beta]^T$, 因此,第 v 通道信号的第 k 个分量可以重构为:

$$\tilde{m}_{k,v}(t) = \Phi_k\tilde{\theta}_{k,v} \quad (8)$$

总的来说, MICMD 分解多通道信号步骤如下:

- (1) 将多通道信号累加;
- (2) 使用 GPTFT 方法将其变换到时频域;
- (3) 在时频域拟合时频脊线以估计分量的 IF, 然后基于冗余傅里叶级数估计该分量 IA;
- (4) 使用累加后信号减去 IA 得到残差, 当残差足够小或者分解数量达到预期后进入步骤(5), 否则重复进行步骤(2)~(4)的操作;
- (5) 根据所有分量 IF, 重构出所有通道的所有分量, 完成分解。

MICMD 的计算效率上虽然比 MEMD、MVMD 等多元分解方法快很多,但其计算效率仍然不满足本研究要求,这一点可以在下文实验部分得到验证。这主要是 MICMD 在估计 IF 的时候采用迭代拟合的方式估计,占据了大部分算法时间。除此之外,分解结果每个分量幅值范围比较均匀,剩余的残差也较高。也就是说, MICMD 仍存在计算效率和分解精度较低问题。

因此,本文提出 FMICMD 方法从以下两个方面对 MICMD 进行改进:(1)在 IF 估计时,为了一次性估计所有分量的 IF,提出了自适应多分量瞬时频率估计方法以

提高多通道 sEMG 信号分解效率;(2)在估计 IA 时,提出了分量能量惩罚因子来平衡分量能量对分量幅值的影响从而提高分解的精度。

2) 自适应多分量瞬时频率估计方法

自适应多分量瞬时频率估计方法如算法 1 所示。相较于 MICMD,该算法省去了迭代求 IF 的过程,更快估计出所有分量 IF。

算法 1: 自适应多分量瞬时频率估计

- 1: 初始化 $\alpha \leftarrow \{0, \dots, 0\}$, ε, σ, K 等参数
- 2: 所有通道信号累加并使用 GPTFT 时频变换方法得到时频图: $Spec(t, f) = TF(t, f, \alpha, \sigma)$
- 3: 将时频图 $Spec(t, f)$ 沿时间轴累加得到 $Acc(f)$
- 4: 找到大于 ε 倍 $Acc(f)$ 平均值的最右边频率索引 f_r
- 5: 将频率区间 $[0, f_r]$ 均匀划分为 K 组, 其中第 i 组的频率范围为 $[f_l^i, f_r^i]$, 其中 $f_l^i = \frac{i-1}{n}f_r, f_r^i = \frac{i}{n}f_r$
- 6: 计算第 i 组频率区间的加权平均频率: $f_i = \frac{\sum_{f_l^i}^{f_r^i} f \cdot Acc(f)}{\sum_{f_l^i}^{f_r^i} Acc(f)}$
- 7: 以这 K 个加权平均频率 f_i 为中心, 将时频图 $Spec(t, f)$ 在频率轴上划分 K 个子图, 第 i 部分的频率范围为 $\left[\frac{f_{i-1} + f_i}{2}, \frac{f_i + f_{i+1}}{2}\right]$
- 8: 直接拟合每个子图的时频脊线以估计每个分量 IF 得到 $\overline{IF}_1, \overline{IF}_2, \dots, \overline{IF}_K$

3) 分量能量惩罚因子

估计出每个分量的 IF 之后,可以通过式(6)得到参数矩阵 $\tilde{\Theta}$ 以计算每个分量的 IA。为平衡分量能量对 IA 的影响,在该解析式中引入分量能量惩罚因子 P :

$$\tilde{\Theta} = (\Phi^T\Phi + \lambda IP)^{-1}\Phi^T\mathbf{X} \quad (9)$$

P 定义为包含不同分量平均能量信息的因子构成的向量:

$$P = [p_1, p_2, \dots, p_i, \dots, p_K]$$

其中, p_i 计算方式如下:

$$p_i = \frac{\sum_{t=1}^N \sum_{f=f_l^i}^{f_r^i} Spec(t, f)}{N \times \Delta f_i} \quad (10)$$

其中, N 为信号长度,本文为 100 ms, f_l^i 和 f_r^i 分别表示第 i 个分量对应频带的频率下界和上界。

为保证和 MICMD 具有相同尺度,将 P 归一化到 $[0, 1]$ 范围:

$$P = \min(P)/P \quad (11)$$

引入分量能量惩罚因子 P 之后,可以有效避免能量低的分量和能量高的分量具有相似的幅值进而导致 MICMD 分解精度降低的问题。

2.2 局部注意力卷积神经网络 LACNN

本文设计的 LACNN 方法主要由卷积、批量归一化、最大池化、局部注意力和全连接输出构成,可以分为 3 层。具体结构如图 2 所示。

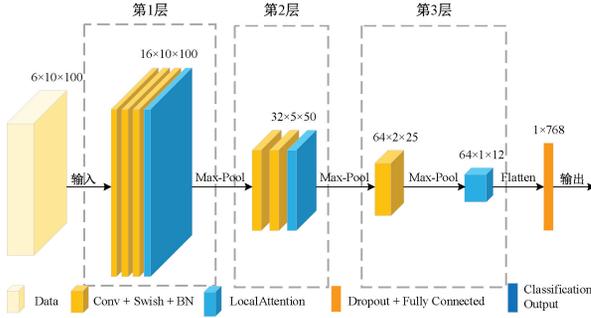


图 2 LACNN 模型结构图

Fig. 2 LACNN model structure

在 LACNN 模型中,所有的卷积层使用 3×3 大小的卷积核,池化层核大小为 2×2 。为了避免 ReLU 激活函数的神经元死亡问题,本文使用 Swish 激活函数^[30]进行非线性激活。批量归一化处理用于加速收敛和降低过拟合。Swish 由式(12)计算,其中 σ 表示 Sigmoid 函数, β 是平滑系数。本文取 $\beta = 1$ 以减少计算。

$$\text{Swish}(x) = x \cdot \sigma(\beta x) \quad (12)$$

2.3 评价指标

在这项工作中,我们使用准确率、召回率、精确率和 F1-Score 来评估下肢运动模式切换态识别方法的分类性能,使用平均耗时来评估信号分解算法和分类算法的实时性能。相应的计算方式如下:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (13)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (14)$$

$$\text{Precision} = \frac{TP}{TP + FP} \quad (15)$$

$$F_1 - \text{Score} = \frac{2(\text{Precision} \times \text{Recall})}{\text{Precision} + \text{Recall}} \quad (16)$$

$$\text{Timecost} = \frac{1}{n} \sum_{i=1}^n t_i \quad (17)$$

其中, TP 表示被正确识别的正样本数, TN 表示被正确识别的负样本数, FP 表示被错分为正样本的负样本数, FN 为被错分为负样本的正样本数, t_i 为第 i 个数据窗的处理时间。

3 实验验证

本文使用硬件环境 CPU 为 Intel i7-11800H @ 2.3 GHz, GPU 为 Nvidia RTX 3060 Laptop 的 PC, 软件环境为带有 Pytorch1.13.1+cu117 的 Python3.7.1。在训练时使用 5 折交叉验证的训练策略,考虑到部署到嵌入式设备的可能性,本文所有模型的训练在 GPU 上完成,而测试则在 CPU 上完成。在训练模型时候使用相同的目标函数、优化器以及超参数。目标函数是交叉熵损失函数,优化器是自适应矩估计算法^[31],模型的初始学习率为 0.001,使用分步学习率衰减策略每 20 个 epoch 学习率衰减为原来的 0.4。

3.1 FMICMD 分解效果

MICMD 和 FMICMD 可调节的参数主要有 3 个,即 P_A, P_F, λ 。为保证一致性, MICMD 和 FMICMD 均使用相同的参数 ($P_A = 15, P_F = 5, \lambda = 0.1$)。在实验中,少部分信号完全分解为 5 个分量,而大部分信号需要分解为 6 个分量才能完全分解。为了保持一致性,将所有信号都分解为 6 个分量,分解结果示例如图 3 所示。

图 3(a) 和 (b) 分别展示了 MICMD 和 FMICMD 对 10 通道 sEMG 信号分解后的左腿股直肌上的示例结果。可以观察到, FMICMD 算法残差更小,精度更高。此外, MICMD 方法分解后的 6 个分量幅值范围分布较为均匀,而 FMICMD 的分量在低频和中频部分有较大的幅值,而在高频幅值较小,这和 sEMG 信号能量集中在低频和中频的能量分布相符合。这说明所提出的分量能量惩罚因子可以有效平衡不同分量能量对幅值的影响。

为验证本文所改进的 FMICMD 算法的有效性,同时评估不同分解方法之间的优劣,进行了消融和对比实验,结果如表 1 所示。

表 1 不同分解方法在本文数据集上分解效果

Table 1 Decomposition effects of different decomposition methods on the data set of this article

分解方法	分解误差/ μV	分解耗时/ms
MICMD	0.061 7±0.067 5	72.84±9.18
FMICMD(无分量能量惩罚因子)	0.055 5±0.056 0	5.88±1.00
FMICMD	0.015 0±0.019 5	5.93±2.13
MVMD($\alpha = 50$)	0.041 8±0.025 8	252.91±21.20
MVMD($\alpha = 10$)	0.008 5±0.005 1	264.36±23.60

由表 1 知,在分解效率上, FMICMD 方法表现最优,约为 MICMD 的 12 倍, MVMD 的 39 倍,能够很好地保证运算的实时性。在分解精度上,即使不使用分量能量

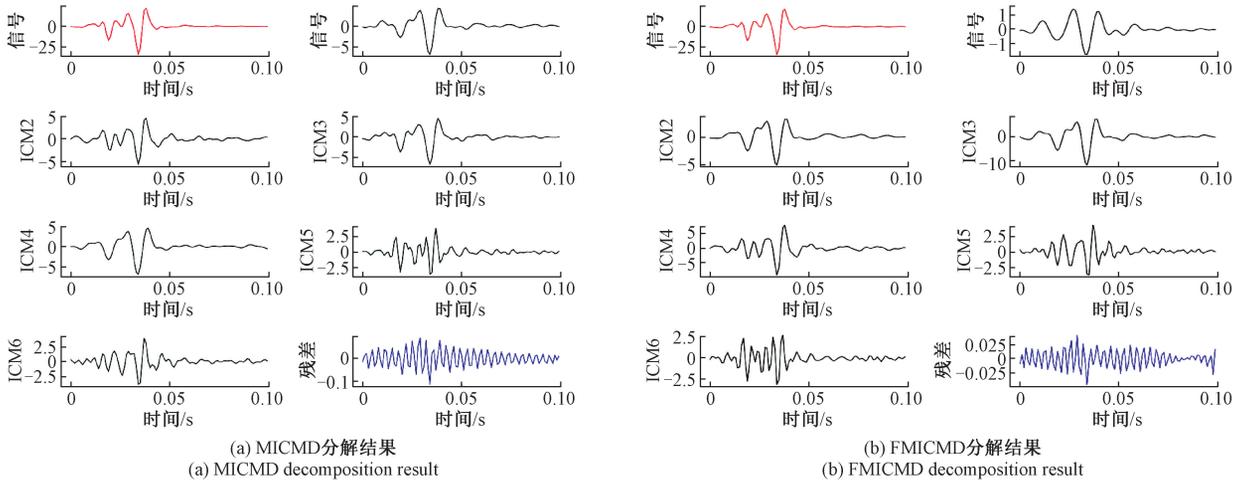


图3 sEMG信号分解示例

Fig. 3 sEMG signal decomposition example

惩罚因子, FMICMD的分解精度也显著高于($p = 0.025 < 0.05$) MICMD。这可能是因为 MICMD 方法在估计 IF 的时候, 仅提取能量高的时频脊线, 而 sEMG 信号能量最集中的频段为 20~150 Hz^[32] 之间, 因此 MICMD 对于 sEMG 的高频部分关注较少, 因而损失细节信息, 而 FMICMD 则对各个频段关注相对更加均匀。这一点也可以从下图 4 中 MIMCD 和 FMICMD 脊线提取对比可以看出。除此之外, 在加入分量能量惩罚因子后, FMICMD 的分解精度进一步提高并且分解效率并没有下降多少。MVMD 虽然可以通过降低惩罚参数 α 以提升分解精度, 但由于其处理时间大于数据窗时间(100 ms), 完全不满足实时性要求, 因此综合看来, FMICMD 无疑是较好的选择。

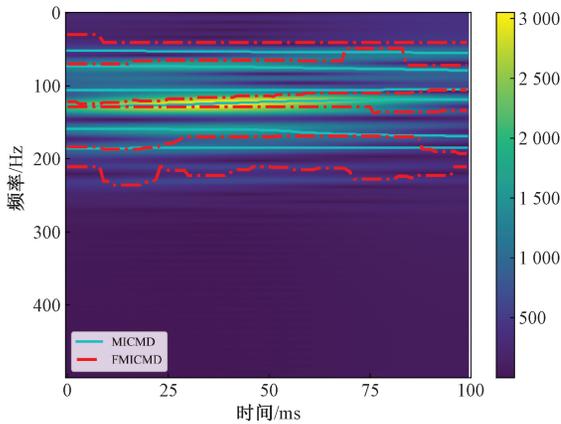


图4 MIMCD和FMICMD脊线提取对比

Fig. 4 Ridge extraction using MIMCD and FMICMD

3.2 FMICMD-LACNN 分类性能评估

为验证本文所设计的 LACNN 模型在特征提取上的有效性, 将测试集数据输入到 LACNN 模型中, 然后分别

截取第 1, 2, 3 层的特征图并展平为特征向量, 接着使用均匀流形近似投影 (uniform manifold approximation and projection, UMAP) 方法将特征向量降维到 2 维后进行可视化, 结果如图 5 所示散点图, 图中 8 种颜色的点对应 8 种切换态的样本点。

由图 5 可知, 经过 LACNN 模型第 1 层处理后, 8 种类别的样本分布还比较聚集; 而经过第 2 层计算后, 各个类别之间已经有了区分开的趋势; 当经过第 3 层之后, 即使不使用全连接层进行分类, 各个类别的样本已经能够较好地地区分开。这说明本文所设计的 LACNN 模型可以有效针对 FMICMD 分解后的切换态 sEMG 信号进行更深层次的特征提取。

使用前 80% 的数据训练, 后 20% 的数据测试, FMICMD-LACNN 模型在测试集上识别结果如图 6 所示混淆矩阵。

由图 6 可知, 所有类别的识别准确率均在 96% 以上, 对 RD-LW 切换态的识别达到了 100% 的准确率, 可见本文所提方法能够较为准确地识别 8 种切换态。LW-SA 切换态最容易和 LW-RA 混淆, 可能是因为从 LW-SA 和 LW-RA 在开始阶段肌肉发力情况比较相似。LW-RA 和 RA-LW 比较容易混淆, 可能是由于本研究场景中坡地的坡度较小, 使得平地行走和坡地行走之间肌肉发力差异较小, 再加上卷积神经网络对于旋转和翻转具有一定的不变性, 导致这两种切换态难以区分开。

3.3 消融和对比实验

为了进一步验证本文提出的 FMICMD-LACNN 切换态识别方法的优势, 还进行了消融和对比实验。

基于梅尔频谱图的双流卷积神经网络 E2CNN^[33]、卷积与长短期记忆网络相结合的 CNN-LSTM^[34] 以及卷积与双向长短期记忆网络相结合的 CNN-BiLSTM^[35] 算法是

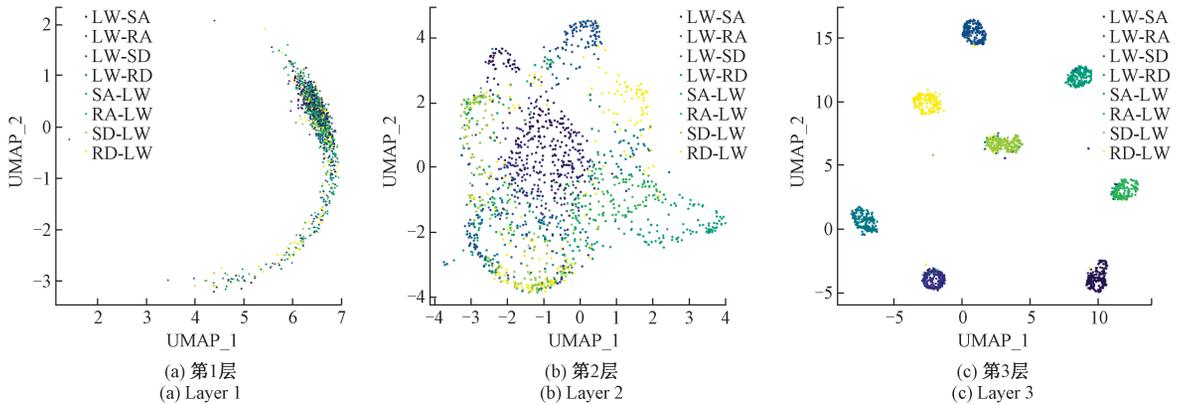


图 5 LACNN 不同层特征图 UMAP 降维可视化结果

Fig. 5 UMAP dimensionality reduction visualization results of different layer feature maps of LACNN

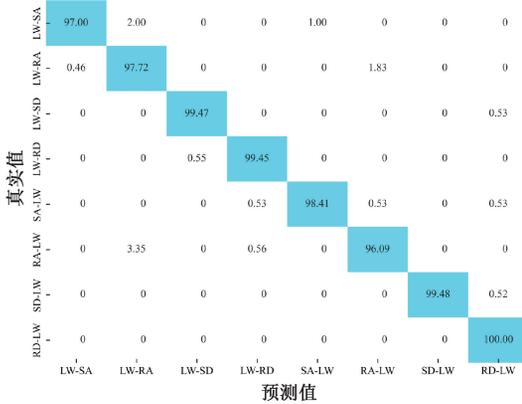


图 6 FMICMD-LACNN 切换态识别混淆矩阵

Fig. 6 Confusion matrix of switching state recognition with FMICMD-LACNN

近 2 年来在人体运动意图识别方面的优秀方法。本文将这些方法应用于本文数据集进行了对比,整体结果如表 2 所示,每个类别的识别准确率结果如表 3 所示。

由表 2 可以看出,相较于 MICMD 或 MVMD 和 LACNN 模型的组合,FMICMD 和 LACNN 组合无论是在识别精度还是识别速度都是最优的。对于 FMICMD 分解后数据,使用局部注意力的 LACNN 模型相较于不使用的 CNN 模型识别准确率有显著提升 ($p = 8.08 \times 10^{-6} < 0.05$),而平均识别时间却没有显著提升 ($p = 0.37 > 0.05$)。这说明局部注意力机制不仅能够有效完成对特征的强化和筛选,并且计算消耗并不高。另外,与 E2CNN、CNN-LSTM 以及 CNN-BiLSTM 相比,FMICMD-LACNN 方法在识别准确率和计算效率均方面均表现最好。

表 2 不同识别方法的分类性能评估

Table 2 Classification performance evaluation of different recognition methods

识别方法	Accuracy/%	Precision/%	Recall/%	F1-Score/%	Timecost/ms
CNN-BiLSTM	95.33±0.65	95.40±0.63	95.33±0.65	95.33±0.64	30.33±5.45
CNN-LSTM	92.98±0.24	93.10±0.20	92.97±0.24	92.99±0.23	23.75±3.28
E2CNN	94.40±0.67	94.57±0.63	94.40±0.68	94.41±0.68	18.89±2.73
FMICMD-CNN	96.45±0.33	96.50±0.32	96.45±0.33	96.46±0.33	8.09±1.67
FMICMD-LACNN	98.35±0.17	98.32±0.18	98.32±0.17	98.32±0.18	8.14±2.52
MICMD-LACNN	95.30±0.44	95.42±0.40	95.30±0.44	95.30±0.44	75.22±9.30
MVMD-LACNN	96.95±0.27	96.98±0.26	96.95±0.27	96.95±0.27	235.28±16.27

由表 3 可知,除了在识别 LW-RA 切换态方面 MVMD-LACNN 方法略高于本文所提算法,在其余 7 种模式下,本文算法平均准确率均为最高。然而考虑到在其他模式下本文

算法的表现,我们可以合理地推测这一微小差距可能是由于不同模式之间的数据特点造成的。综合分析,本文所提方法能够满足快速准确识别下肢连续运动切换态的目标。

表3 不同识别方法在8种切换态上的识别准确率

Table 3 Recognition accuracy of different recognition methods on 8 switching states

识别方法	LW-SA	LW-RA	LW-SD	LW-RD	SA-LW	RA-LW	SD-LW	RD-LW
CNN-BiLSTM	96.78±0.19	96.92±0.52	95.81±1.50	95.42±1.09	95.89±1.57	92.89±1.02	93.00±0.39	95.44±1.71
CNN-LSTM	94.53±1.19	89.50±2.29	96.76±0.47	94.36±1.66	93.63±1.06	93.49±0.98	90.52±0.79	91.36±1.10
E2CNN	93.49±1.64	92.77±1.09	97.93±1.31	97.01±1.10	96.57±1.34	92.45±1.48	96.72±0.43	88.80±3.07
FMICMD-CNN	95.71±0.94	94.71±0.35	97.44±0.75	97.31±0.79	98.02±0.67	95.93±1.28	97.10±0.68	95.68±1.44
FMICMD-LACNN	97.00±0.38	97.53±1.05	99.01±0.03	99.55±0.55	98.06±0.52	96.21±1.03	99.57±0.53	100.0±0.00
MICMD-LACNN	91.33±1.97	95.35±0.91	96.75±0.97	97.82±1.56	94.08±1.25	90.54±1.15	99.39±0.50	97.23±1.49
MVMD-LACNN	96.52±1.45	98.40±0.68	96.03±0.77	96.83±1.92	97.11±1.05	95.39±1.47	98.42±0.71	96.63±1.14

4 结 论

为了解决人体下肢运动模式切换态快速准确识别问题,本文提出一种基于 FMICMD 和 LACNN 相结合的方法。首先采用 FMICMD 算法对信号进行快速分解,降低信号复杂度,然后构建局部注意力卷积神经网络模型 LACNN 对分解后的信号进行特征强化和分类识别。

为了提高 MICMD 的计算效率,对其瞬时频率估计和瞬时幅值计算进行了改进。实验结果表明, FMICMD 方法与 MICMD 相比,具有更高的分解精度,分解速度提高约 12 倍。由于自适应多分量瞬时频率估计方法通过划分子图完成,因此无法分解频带较宽的信号,也无法处理分量频率剧烈变化的信号以及长时信号,适合用于短时瞬态信号。

为了从 FMICMD 分解后 sEMG 信号中充分提取有用特征同时抑制冗余特征,本文设计了由卷积、Swish 激活函数、批量归一化、局部注意力、池化以及全连接层构成的多层深度网络结构。实验结果证明了该模型的有效性。

本文所提出的 FMICMD-LACNN 方法在 8 种典型的下肢连续运动切换态识别任务上取得 98.35% 的平均分类准确率,且平均识别时间仅需 8.14 ms,综合来看,所提方法在准确率和计算效率上明显优于 CNN-LSTM、CNN-BiLSTM 和 E2CNN 等对比方法。未来还需考虑模块化集成方案,开发便携式系统原型,使方法更易于推广应用。

参考文献

[1] 孟琳,董洪涛,侯捷,等.面向下肢康复的柔性外骨骼机器人进展研究[J].仪器仪表学报,2021,42(4):206-217.
MENG L, DONG H T, HOU J, et al. Soft exoskeleton robot facing to lower-limb rehabilitation: A narrative review [J]. Chinese Journal of Scientific Instrument,

2021,42(4):206-217.

[2] GRIMMER M, ZEISS J, WEIGAND F, et al. Lower limb joint biomechanics-based identification of gait switchings in between level walking and stair ambulation[J]. Plos One, 2020, 15(9): e0239148.
[3] CHEN C F, DU Z J, HE L, et al. A novel gait pattern recognition method based on LSTM-CNN for lower limb exoskeleton[J]. Journal of Bionic Engineering, 2021, 18: 1059-1072.
[4] SHENG M, WANG W J, TONG T T, et al. Motion intent recognition in intelligent lower limb prosthesis using one-dimensional dual-tree complex wavelet transforms[J]. Computational Intelligence and Neuroscience, 2021, DOI:org/10.1155/2021/5631730.
[5] 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): 612-127.
[6] LI X, LIANG S, YAN S, et al. Adaptive detection of Ahead-sEMG based on short-time energy of local-detail difference and recognition in advance of upper-limb movements [J]. Biomedical Signal Processing and Control, 2023, 84: 104752.
[7] 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.
[8] FATIMAH B, SINGH P, SINGHAL A, et al. Hand movement recognition from sEMG signals using Fourier decomposition method [J]. Biocybernetics and Biomedical Engineering, 2021, 41(2): 690-703.
[9] 刘强,李玉榕,杜国川,等.基于 sEMG 信号的关节力矩

- NARX 预测模型[J]. 仪器仪表学报, 2022, 43(11): 123-131.
- LIU Q, LI Y R, DU G CH, et al. NARX prediction model of joint torque based on sEMG signal[J]. Chinese Journal of Scientific Instrument, 2022, 43(11): 123-131.
- [10] BAUD R, MANZOORI A R, IJSPEERT A, et al. Review of control strategies for lower-limb exoskeletons to assist gait [J]. Journal of Neuro Engineering and Rehabilitation, 2021, 18(1): 1-34.
- [11] 盛敏, 刘双庆, 王婕, 等. 基于 GMM-HMM 模型的下肢假肢运动意图识别[J]. 仪器仪表学报, 2019, 40(5): 169-178.
- SHENG M, LIU SH Q, WANG J, et al. Motion intent recognition of intelligent lower limb prosthesis based on GMM-HMM [J]. Chinese Journal of Scientific Instrument, 2019, 40(5): 169-178.
- [12] SHI X, QIN P, ZHU J, et al. Feature extraction and classification of lower limb motion based on sEMG signals[J]. IEEE Access, 2020, 8: 132882-132592.
- [13] PARK S, LEE D, CHUNG W K, et al. Hierarchical motion segmentation through sEMG for continuous lower limb motions [J]. IEEE Robotics and Automation Letters, 2019, 4(4): 4402-4409.
- [14] 李向新, 田岚, 郑悦, 等. 一种下肢运动意图识别算法性能实时测评系统[J]. 仪器仪表学报, 2020, 41(5): 99-107.
- LI X X, TIAN L, ZHENG Y, et al. Real time performance test evaluation system for lower limb motion intention recognition algorithm [J]. Chinese Journal of Scientific Instrument, 2020, 41(5): 99-107.
- [15] MARCOS MAZON D, GROEFSEMA M, SCHOMAKER L R, et al. IMU-based classification of locomotion modes, switchings, and gait phases with convolutional recurrent neural networks[J]. Sensors, 2022, 22(22): 8871.
- [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] SHEN C, PEI Z, CHEN W, et al. Lower limb activity recognition based on sEMG using stacked weighted random forest[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2023, 32: 166-177.
- [18] KOPPULU P K, CHEMMANGAT K. Automatic selection of IMFs to denoise the sEMG signals using EMD[J]. Journal of Electromyography and Kinesiology, 2023, 73: 102834.
- [19] LI C, DENG H, YIN S, et al. sEMG signal filtering study using synchrosqueezing wavelet transform with differential evolution optimized threshold[J]. Results in Engineering, 2023, 18: 101150.
- [20] PAN T Y, TSAI W L, CHANG C Y, et al. A hierarchical hand gesture recognition framework for sports referee training-based EMG and accelerometer sensors[J]. IEEE Transactions on Cybernetics, 2020, 52(5): 3172-3183.
- [21] KARHEILY S, MOUKADEM A, COURBOT J B, et al. sEMG time-frequency features for hand movements classification [J]. Expert Systems with Applications, 2022, 210: 118282.
- [22] OZDEMIR M A, KISA D H, GUREN O, et al. Hand gesture classification using time-frequency images and transfer learning based on CNN [J]. Biomedical Signal Processing and Control, 2022, 77: 103787.
- [23] CHEN Q, LANG X, XIE L, et al. Multivariate intrinsic chirp mode decomposition[J]. Signal Processing, 2021, 183: 108009.
- [24] LUONG M T, PHAM H, MANNING C D. Effective approaches to attention-based neural machine translation[J]. ArXiv Preprint, 2015, ArXiv:150804025.
- [25] REHMAN N, MANDIC D P. Multivariate empirical mode decomposition [J]. Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences, 2010, 466(2117): 1291-1302.
- [26] UR REHMAN N, AFTAB H. Multivariate variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2019, 67(23): 6039-6052.
- [27] CHEN S, PENG Z, YANG Y, et al. Intrinsic chirp component decomposition by using Fourier series representation[J]. Signal Processing, 2017, 137: 319-327.
- [28] YANG Y, PENG Z, DONG X, et al. General parameterized time-frequency transform [J]. IEEE Transactions on Signal Processing, 2014, 62(11): 2751-2764.
- [29] DJUROVIC I, STANKOVIC L. An algorithm for the Wigner distribution based instantaneous frequency

- estimation in a high noise environment [J]. *Signal Processing*, 2004, 84(3): 631-643.
- [30] RAMACHANDRAN P, ZOPH B, LE Q V. Swish: a self-gated activation function[J]. *ArXiv Preprint*, 2017, ArXiv:171005941.
- [31] KINGMA D P, BA J. Adam: A method for stochastic optimization (2014)[J]. *ArXiv Preprint*, 2017, ArXiv:14126980.
- [32] 李效,张明,张倩,等. 基于 CEEMD-VMD-SIST 算法的 sEMG 信号降噪方法[J/OL]. *计算机测量与控制*, 1-9 [2024-03-21]. <http://kns.cnki.net/kcms/detail/11.4762.TP.20231228.1642.004.html>.
LI X, ZHANG M, ZHANG Q, et al. Denoising method for sEMG signal based on CEEMD-VMD-SIST algorithm [J/OL] *Computer Measurement & Control*, 1-9[2024-03-21]. <http://kns.cnki.net/kcms/detail/11.4762.TP.20231228.1642.004.html>.
- [33] QURESHI M F, MUSHTAQ Z, REHMAN M Z U, et al. E2CNN: An efficient concatenated CNN for classification of surface EMG extracted from upper limb[J]. *IEEE Sensors Journal*, 2023, 23(8): 8989-8996.
- [34] BAI D, LIU T, HAN X, et al. Multi-channel sEMG signal gesture recognition based on improved CNN-LSTM hybrid models [C]. *Proceedings of the 2021 IEEE International Conference on Intelligence and Safety for Robotics (ISR)*, IEEE, 2021.
- [35] KARNAM N K, DUBEY S R, TURLAPATY A C, et al. EMGHandNet: A hybrid CNN and Bi-LSTM architecture for hand activity classification using surface EMG signals[J]. *Biocybernetics and Biomedical Engineering*, 2022, 42(1): 325-40.

作者简介



石欣(通信作者),2003年和2010年于重庆大学分别获得硕士学位和博士学位。现为重庆大学教授、博士生导师,主要研究方向为智能控制、无线传感网络。

E-mail: meetshixin@gmail.com

Shi Xin (Corresponding author) received his M. Sc. degree and Ph. D. degree both from Chongqing University in 2003 and 2010, respectively. He is currently a professor and a Ph. D. advisor at Chongqing University. His main research interests include intelligent control and wireless sensor network.



敖钰民,2021年于重庆大学获得学士学位。现于重庆大学攻读硕士学位,主要研究方向为无线传感网络、数字信号处理和深度学习。

E-mail: yuminao@foxmail.com

Ao Yumin received his B. Sc. degree from Chongqing University in 2021. Currently studying for a M. Sc. degree at Chongqing University, his main research directions are wireless sensor networks, digital signal processing and deep learning.



秦鹏杰,2015年于重庆科技大学获得学士学位。2023年于重庆大学获得博士学位。现为中国科学院深圳先进技术研究院助理研究员,主要研究方向为模式识别与智能系统。

E-mail: pj.qin@siat.ac.cn

Qin Pengjie received his bachelor's degree from Chongqing University of Science and Technology in 2015. Obtained a Ph. D degree from Chongqing University in 2023. Currently, he is an assistant researcher at Shenzhen Institute of Advanced Technology, Chinese Academy of Sciences. His main research direction is pattern recognition and intelligent systems.