EMAHA-DB1：用于日常生活活动分类的新型上肢表面肌电数据集

Naveen Kumar Karnam、Anish Chand Turlapaty，电气与电子工程师协会会员，Shiv Ram Dubey，电气与电子工程师协会高级会员 和 Balakrishna Gokaraju，电气与电子工程师协会会员

arXiv:2301.03325v1 [eess.SP] 9 Jan 2023

摘要—**本文介绍人体活动肌电分析数据库1（EMAHA-DB1），这是一个新型多通道表面肌电（sEMG）信号数据集，用于评估日常生活活动（ADL）。该数据集采集自25名健全受试者，他们完成了22项活动，这些活动依据功能性手臂活动行为系统（FAABOS）进行分类（3项——全手手势，6项——打开/关闭办公抽屉，8项——抓握并拿住小型办公物品，2项——手指屈曲和伸展，2项——书写，1项——休息）。表面肌电数据由一组五个 Noraxon Ultium 无线表面肌电传感器测量，传感器配有银/氯化银电极，放置于人手上。我们分析了该数据集在手部活动识别方面的分类性能。分类采用四种先进的机器学习分类器，包括随机森林（RF）、精细K近邻（KNN）、集成K近邻（sKNN）和支持向量机（SVM），并结合七种时域与频域特征集。使用能量特征与自回归特征集成，并采用三阶多项式核的SVM分类器，在五个FAABOS类别上取得了83.21%的先进分类准确率。使用相同的SVM分类器，并集成频域对数矩（LMF）特征、改进的LMF、时域统计（TDS）特征、频带功率（SBP）、通道互相关和局部二值模式（LBP），在22类手部活动上的分类准确率为75.39%。分析结果展示了该数据集所应对的技术挑战。所开发的数据集可用作各种分类方法的基准，也可用于与日常生活活动相对应的表面肌电信号分析，以及假肢和其他可穿戴机器人技术的开发。**

索引词—**机器学习、分类算法、表面肌电（sEMG）、日常生活活动（ADL）、特征、数据集和基准。**

I. 引言

PERFORMING 在进行日常生活活动（ADL）时能够毫无困难地完成手部动作，意味着拥有功能上的独立性和良好的生活质量 [2]。然而，受以下疾病影响的人群很难完成简单的手部动作：上肢残疾 [3], [4], 、与衰老相关的疾病 [5],、神经肌肉疾病 [6], 以及与中风相关的残疾 [7], [8], [9],[10]。人机界面和人机交互界面可以支持康复过程，帮助患者从上述疾病中恢复。例如，目前正在开发基于计算机视觉技术的基于手势的界面，用于识别和分类手势 [11]。此外，许多研究人员还探索了利用视觉手势进行机器人控制 [12], [13], [14]。然而，基于视觉的控制方法难以确定合适的驱动控制，以及动作过程中肌肉施加的力量大小。一种量化上肢活动的方法是使用可穿戴传感器，例如惯性运动传感器（IMUs），包括加速度计、陀螺仪和磁力计。这些传感器用于测量和监测肢体活动、量化肌肉运动功能缺陷[15], 以及对身体活动类型进行分类 [16], [17]。尽管可穿戴传感器能够识别人体活动，但在精确识别手势、细微的手指运动以及完成动作所用的肌肉力量方面仍存在不足 [18]。

此外，通过表面肌电（sEMG）信号进行手部动作分类和肢体控制 [19], [20] ，有助于假肢装置、外骨骼手臂、先进的逼真生物力学模型及康复治疗的设计 [21]。在这些应用中，多模态信号的使用也十分普遍。相关文献分析了融合 IMU 和表面肌电信号 [22], [23], [24]进行手部活动分类以及前臂连续方向估计的方法。脑电信号（EEG）与表面肌电信号也被融合，用于解码人体意图。与基于独立表面肌电信号的控制相比，这一融合过程能够生成更优的控制信号 [25], [26], [27]。为了获得更高的分类准确率，可以将表面肌电信号中的特征与基于视觉的图像分类网络中的特征进行融合 [28]。在实际应用中，多模态方法会增加硬件和软件系统的复杂性，因此难以适用于不同的实际应用。通过独立表面肌电信号进行手部动作分析与分类正日益受到关注 [29], [30], [31], [32], [33] ，这也是我们当前工作的重点。

本文介绍了人体活动肌电分析数据库 1（EMAHA-DB1），这是一个面向印度人群日常生活活动的新型表面肌电数据集。EMAHA-DB1 的主要特征如下：

- 目前已有多个表面肌电数据集，涵盖手势、手部动作、腕部运动和抓取物体等活动。这些数据集主要面向西方人群采集，而目前尚无

N.K. Karnam 和 A.C. Turlapaty 就职于印度信息技术学院斯里城校区（印度安得拉邦）的生物信号分析实验室（电子邮箱：anish.turlapaty@iiits.in）。S.R. Dubey 就职于印度信息技术学院阿拉哈巴德校区（印度北方邦普拉亚格拉吉 211015）的计算机视觉与生物识别实验室（电子邮箱：srdubey@iiita.ac.in）。B. Gokaraju 就职于可视化与计算高级研究中心（ViCAR）以及北卡罗来纳州立农业技术大学（美国北卡罗来纳州格林斯伯勒）的计算数据科学与工程系（电子邮箱：bgokaraju@ncat.edu）。

来自印度人群的日常生活活动数据集。EMAHA- DB1 填补了这一空白。

- 印度有收集人体测量数据的传统 [34], [35]。对于任何人群，人体测量学都会影响其运动学和动力学 [36]，[37]。EMAHA-DB1 将补充现有的人体测量学、运动学和动力学数据集 [30], [37]，有助于针对印度人群开展上肢康复治疗、生理学研究和临床研究。

- 通过依据功能性手臂活动行为观察系统（FAABOS [38]）对动作进行分组，分析日常生活活动的表现。Uswatte 等人 提出的功能分类体系根据行为意义对手部动作进行量化分组。
- 目前已有一些公开的日常生活活动数据集，例如 NinaPro [39]、、BioPatRec [40]、Ramikushaba [41] 和 UCI Gesture [42]，但它们未涵盖若干重要的日常生活活动类别。手部活动通常在实验环境中进行，每项活动的持续时间固定；然而，我们为不同活动设定了不同的持续时间，以近似相应的真实手部动作持续时间。

- 该数据集可用于为分类算法建立基准，或开展统计学研究。与其他任何公开的日常生活活动数据集相比，所开发的数据集包含更多受试者和更多活动重复次数。

本文的主要贡献如下：

1) 本研究测量了与日常生活活动相关的肌肉活动，并采集了来自印度人群的新型多通道表面肌电数据。

2) EMAHA-DB1 数据集按照定制的 FAABOS 功能类别进行组织，以便使用先进的机器学习分类器开展分析。具体而言，对表面肌电信号进行分析，将其分类为功能组以及单项活动。3) 我们还针对 FAABOS 功能类别开展了广泛的特征分析。

本文其余部分安排如下：第二节详细介绍所提出的 EMAHA-DB1 数据集；第三节介绍机器学习框架中的实验；第四节展示实验结果；第五节总结全文并展望未来研究方向。

II. EMAHA-DB1：提出的表面肌电数据集

A. 数据采集

1) 研究参与者：印度信息技术学院斯里城校区机构伦理委员会（编号：IIITS/EC/2022/01）批准了拟议的数据采集方案。该方案总体遵循《赫尔辛基宣言》，并具体遵循印度《涉及人类参与者的生物医学与健康研究国家伦理指南》。二十五名无上肢病变病史的健康受试者参与了表面肌电数据采集，其中包括22名男性和3名女性。其平均年龄为 28±6 岁。在首次活动环节开始前，每位参与者均签署了书面知情同意书，且整个数据采集过程完全无创。

表 I：手部活动列表

活动编号	活动描述
A0	手部静止（坐姿）
A1	抛硬币（坐姿）
A2	打响指（坐姿）
A3	拉动空抽屉 - 后视图（坐姿）
A4	拉动负重抽屉（2kg）- 后视图（坐姿）
A5	拉动空抽屉 - 前视图（坐姿）
A6	拉动负重抽屉（2kg）- 前视图（坐姿）
A7	推空抽屉——后视图（坐姿）
A8	推有重量（2kg）的抽屉——后视图（坐姿）
A9	双手交握（坐姿）
A10	拍手（坐姿）
A11	抓握并拿住1升水瓶（坐姿）
A12	抓握并持握小锤子（坐姿）
A13	（坐姿）抓握并持握小锯子
A14	用钢笔在纸张上写下“生物信号实验室”——侧向抓握（坐姿）
A15	用记号笔在板上写下“生物信号实验室” - 侧向抓握（站姿）
A16	（站姿）提起装有 4 升水的小桶
A17	使用键盘输入“生物信号实验室” 单指（坐姿）
A18	用侧向抓握的方式从杯中饮用茶水/水（坐姿）
A19	拿起手机，放到耳朵旁，然后挂断把手机放在桌上（坐姿）
A20	抓握并拿住一本书（坐姿）
A21	抓握并拿住网球（坐姿）

表二：手部肌肉上的传感器放置

通道编号	传感器编号	手部肌肉名称
1	21621	肱桡肌（BR）
2	21623	桡侧腕屈肌（FCR）
3	21624	尺侧腕屈肌（FCU）
4	21625	肱二头肌（BB）
5	21626	拇短展肌（APB）

2）实验设置和采集方案：每位受试者执行的 22 项活动列于表 I 中。每项手部肌肉活动均使用如图1所示的 5 通道 Noraxon Ultium 无线表面肌电传感器系统进行记录 [43] 。如图1所示，将五个自粘式 Ag/AgCl双电极放置在右臂最具代表性的五个肌肉部位中央。指导每位受试者舒适地坐好，一侧肘部置于桌面，手臂弯曲， 90° 与前臂呈一定角度。肌肉位置根据第 17 [44] 章中的图谱选定，并列于表二中。每次实验开始时，使用含酒精湿巾清洁参与者的双手。

每次实验开始前，受试者都会熟悉实验方案，其中包括拟进行活动的视频演示。根据受试者的适应情况，每位受试者每次实验的总持续时间最长为一小时。每项活动的持续时间最长为10秒，并重复10次。每次重复之间休息5秒，不同活动的实验环节之间间隔30秒。每项活动包含两个阶段：（1）动作阶段和（2）休息阶段。不过，有些活动还包括一个额外的放松阶段。在动作阶段，受试者进行相应的活动；在放松阶段，受试者从动作状态过渡到休息状态；在休息阶段，受试者完全放松自己的

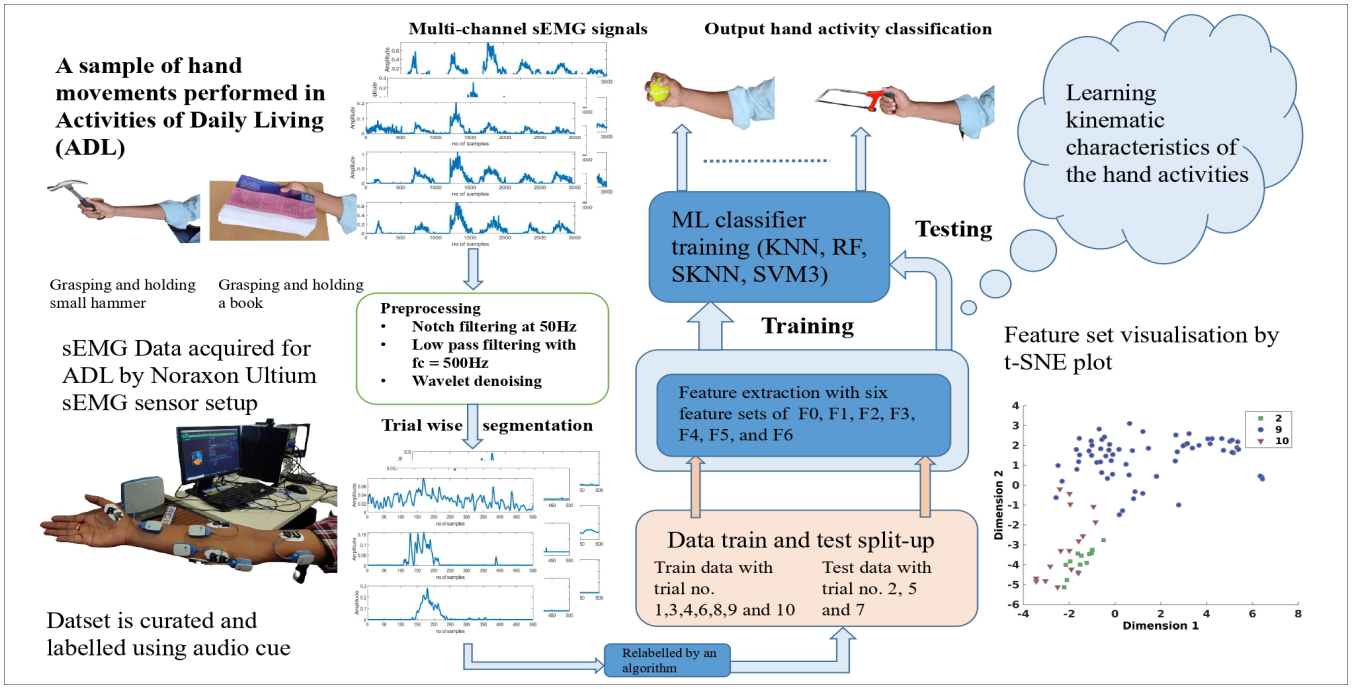

图1：学　习流程：从表面肌电数据集采集到手部　　活动

表III：各项活动的各阶段时长。

编号	T_X	T_A	T_R	T_T	编号	T_X	T_A	T_R	T_T	编号	T_X	T_A	T_R	T_T
A1	3	5	0	8	A8	3	5	0	8	A15	3	15	2	20
A2	3	5	0	8	A9	3	5	0	8	A16	5	5	3	13
A3	3	5	0	8	A10	3	5	0	8	A17	3	10	2	15
A4	3	5	0	8	A11	3	5	3	11	A18	5	5	3	13
A5	3	5	0	8	A12	3	5	3	11	A19	5	5	3	13
A6	3	5	0	8	A13	3	5	3	11	A20	5	5	3	13
A7	3	5	0	8	A14	3	10	2	15	A21	5	5	3	13

肌肉。表III列出了每项活动的持续时间，其中 T_X、 T_A、 T_R和 T_T 分别表示休息、动作、放松和总持续时间。

3) 与现有数据集的比较：表 IV 对比了 EMAHA-DB1 数据与现有表面肌电手部活动数据集的特征。除了引言中提到的显著特征外，EMAHA-DB1 还具有以下一些额外且独特的特征：1) 实验设计为手部活动包含三个阶段：动作（肌肉收缩/放松）、释放（动作回撤）和休息（肌肉放松）；2) 测量仅使用少量传感器，因此与现有数据集相比，所需的计算资源更少。

B. 数据准备

1）活动分段：对于 EMAHA-DB1 中的表面肌电信号，依据表III所示的各动作阶段持续时间，对动作起始点和结束点进行初步标注。为提高活动标签的质量，基于[46],开发的流程，采用了改进的信号分段过程（如下所列）：

1）首先，对每位受试者执行的每项活动的每个试次，均对多通道信号进行整流。2）对于每个试次，确定最大值和最小值，以计算范围 R。3）将 $R/\sqrt{2}$ 处的信号强度（3 dB 振幅）视为两侧的阈值。4）针对每个通道，找出初步起始点之后第一个越过 3 dB 阈值的信号强度。五个通道中越过阈值的位置里最靠前的一处，视为动作起始点。5）从动作结束处开始对试次数据反向解析。针对每个通道，找出从末端起的第一个点，即最后一个越过 3 dB 阈值的位置。将这些通道中越过阈值的位置里最靠右的一处标记为动作结束点。6）最后，将起始点与结束点之间的信号样本标注为动作，并分配相应的活动编号，其余信号则视为休息状态。

上述流程针对一次日常生活活动试次示于图 2。可以观察到，信号分段改进了活动与休息的标注过程，进而提高了分类过程的可靠性。

*2) FAABOS*类别：EMAHA-DB1根据功能性手臂活动行为观察系统（FAABOS） [38], [29]进行映射。具体而言，EMAHA-DB1中的动作被重新划分为以下五个主要组别：1）无物体动作，2）持物，3）物体抓握，4）手指屈伸，以及5）书写。映射到这些组别中的动作类别列于表 V中。

表 IV：与基准数据集的基本数据特征比较

数据集 Name	动作类别	传感器	No. of 受试者 (S)	No. of 活动 (N_A)（包括休息）	No. of 通道 (N_c)	采样频率 (N_s)（样本每秒）	Rest 时长-tion (T_X)(秒)	动作时长-tion (T_A)(秒)	发布持续时tion (T_R)（秒）	次数重复次数 (N_R)	总计 no. of pat-型 (N)
NinaPro DB1 [39]	手势，腕关节移动-物品，and 抓握物体	Otto Bock	27	53	10	100	3	5	-	10	14310
NinaPro DB2 [39]	手势、腕关节运动，抓握 Ob-物体以及手指按压动作	Delsys Trigno 无线	40	50	12	2000	3	5	-	6	12000
NinaPro DB4 [45]	手势，腕关节动作-以及抓握物体	Cometa Mini-Wave	10	53	12	2000	3	5	-	6	3180
BioPatRec DB2 [40]	手势，and 腕关节和手部动作	Thalmic 肌电臂带	17	27	8	2000	3	3	-	3	1377
UCI 手势-势 [42]	腕关节和手部动-部	Myo Thalmic 臂环	36	7	8	1000	3	3	-	4	1008
Rami-kushaba DB6 [41]	手部动作	Delsys DE 2.x 系列肌电传感器	11	40	7	4000	3-5	5	-	6	2640
EMAHA-DB1 (Our 数据集)	**日常活动 - 抓握并拿住、书写和绘画、打开/关闭**	**Noraxon Ultium 表面肌电传感器**	**25**	**22**	**5**	**2000**	**3-5**	**5-15**	**3-5**	**10**	**5500**

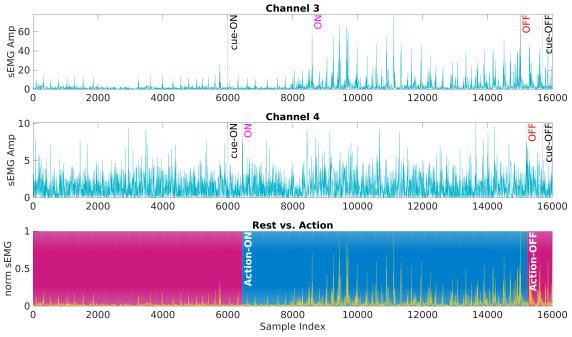

图 2：日常生活活动试次的表面肌电信号人工分割示意图

表 V：FAABOS活动组。

组标签	组名	活动编号
0	Rest	A0
1	无物体动作	A2、A9 和 A10
2	持物	A3、A4、A5、A6、A7 和 A8
3	物体抓握	A11，A12，A13，A16，A18，A19，A20 和 A21
4	手指屈曲与伸手指的屈伸	A1 和 A17
5	书写	A14 和 A15

III. 方法

A. 问题陈述

EMAHA-DB1中的表面肌电模式总数为 $N = S \times N_A \times N_R$，其中 S 为受试者总数，N_A 为不同活动的数量，N_R对应每位受试者每个动作的重复次数。所提出的表面肌电数据集可表示为：

$$\mathbf{x} = \{\mathbf{x}_n\}_{n=1}^{N} \tag{1}$$

其中，每个观测数组 $\mathbf{x}_n$ 由多个通道组成，如下所示：

$$\mathbf{x}_n = \{\mathbf{x}_{n,m}\}_{m=1}^{N_C}, \quad n = 1, \cdots, N \tag{2}$$

表 VI：提取特征汇总

特征 Set	特征	特征长度
F_0 [47]	平均绝对值 (MAV)，时域特征-总能量（TSE）和频带能量（SBE）	$1 \times N_C$, $4 \times N_C$, 以及 $4 \times N_C$
F_1 [48]	平均绝对值、过零次数（ZC）、斜率变化（SC）和波形长度（WL）	$1 \times N_C$、$1 \times N_C$, $1 \times N_C$，以及 $1 \times N_C$
F_2 [49]	F1 和自回归系数 (ARC)	$9 \times N_C$和 $2 \times N_C$
F_3 [50]	F1、肌电脉冲率 (MPR)、Willison 振幅（WAMP），以及基数	$9 \times N_C$, $1 \times N_C$, $1 \times N_C$，以及 $1 \times N_C$
F_4 [51]	频域对数矩（LMF）	$5 \times N_C$
F_5 [52]	F4，改进的LMF，时域统计量（TDS）、频带功率（SBP）、Max 通道互相关和局部二值模式（LBP）	$5 \times N_C$, $10 \times N_C$, $4 \times N_C$, $4 \times N_C$, $2 \times N_C$, 以及 $2 \times N_C$
F_6 [53]	均方根（RMS）、时变功率谱描述符（TD-PSD） [51]，差分绝对标准差值（DASDV）以及差分绝对均值值（DAMV）	$1 \times N_C$、$6 \times N_C$、$1 \times N_C$和 $1 \times N_C$

其中，N_C 是通道数（来自不同的电极），每个通道均由一个数组组成，如下所示：

$$\mathbf{x}_{n,m} = \{x_{n,m}(i)\}_{i=1}^{N_T} \tag{3}$$

其中，$N_T = N_s \times T_T$ 是持续时间为 T_T 的一次试次中的数值数量，N_s 是采样率（样本/秒）。对于给定的试次，为了进行特征提取，信号被划分为 N_{seg} 个分段。每个分段 s_g 由一个数组组成，如下所示：

$$\mathbf{s}_g^j = \{x_{n,m}(i)\}_{i=1}^{N_g} \quad j = 1, \cdots N_{seg} \tag{4}$$

其中，N_g 是一个分段中的样本数，且$N_T = N_{seg} \times N_g$。

本研究旨在将分段后的表面肌电信号映射到相应的活动标签（即$\mathbf{t}_g$ - 目标），

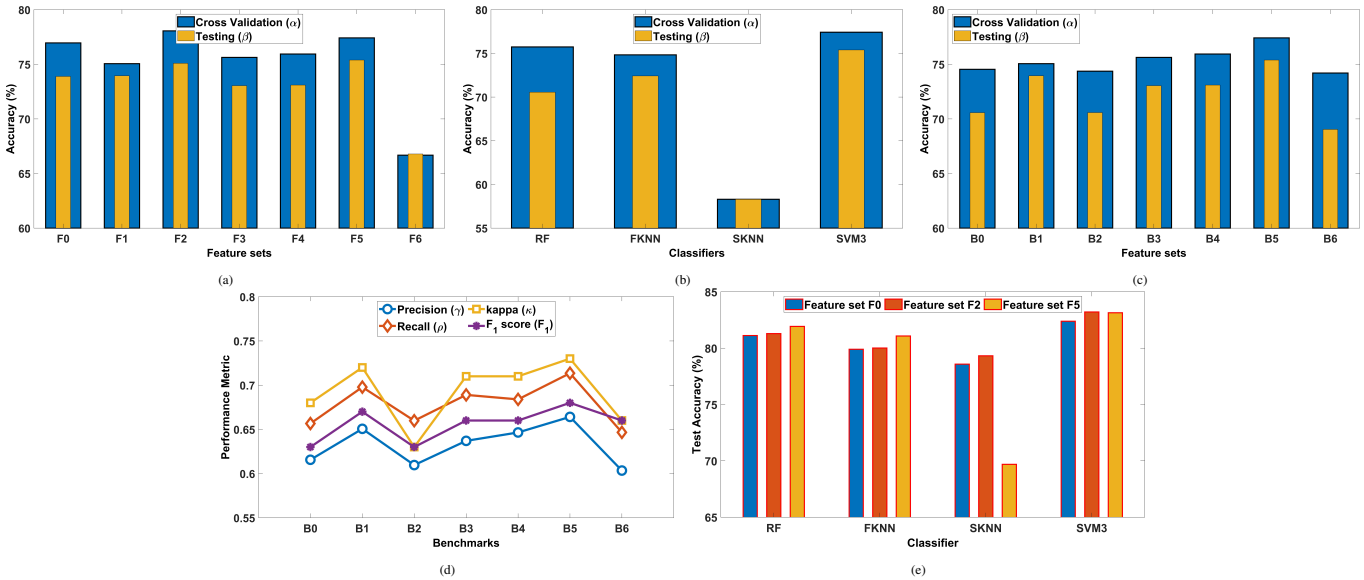

图3：性能比较：(a) 使用三次支持向量机（3阶多项式支持向量机）比较不同特征集成，(b) 使用不同分类器比较基准特征集成 F_5，(c) 与基准框架比较，(d) 按各种指标与基准框架比较，以及 (e) 与 FAABOS 类别框架比较。

表VII：分类器的数值设置。

分类器	模型设置
精细K近邻	近邻数量 = 5，距离度量 =城市街区距离，距-距离权重 = 平方逆
集成KNN	学习周期数 = 30，学习器 =K近邻、子空间维度 = 25
三次支持向量机	多项式核，阶数 = 3，盒约束 = 1，多重-类别方法 =一对一
随机森林 自助法袋数	= 300

表 VIII：特征集成与基准分类器设置对比。

特征提取	特征学习	BF	分类器	特征提取	特征学习	BF	分类器
F_0	$9 \times N_C$	B_0 [47]	精细K近邻	F_4	$5 \times N_C$	B_4 [54]	SVM3
F_1	$4 \times N_C$	B_1 [48]	SVM3	F_5	$27 \times N_C$	B_5 [52]	SVM3
F_2	$11 \times N_C$	B_2 [49]	精细K近邻	F_6	$9 \times N_C$	B_6 [39]	随机森林
F_3	$12 \times N_C$	B_3 [50]	SVM3				

这可以表述为：

$$f\{\mathbf{s}_g\} \rightarrow \mathbf{t}_g \tag{5}$$

其中，$\mathbf{t}_g$ 表示表 V 中指定的目标（组标签），或表 I 中指定的个体活动标签。式 (5) 中的映射函数由监督分类器实现。对于该映射函数，需要采用适当的特征来表征表面肌电信号与相应活动之间潜在的逆运动学关系。

B. 特征提取

本文采用了以下特征集，这些特征集改编自[47]：F_0、F_1、F_2、F_3和 F_4，以及 F_5，并额外加入一个特征集 F_6，该特征集由均方根（RMS）、时变功率谱描述符（TD-PSD）、差分绝对标准差值（DASDV）和差分绝对均值（DAMV）组成。请注意，每个分段均计算这些特征，并将其串联以构建完整的特征向量。提取的特征集总结见表 VI。

C. 监督分类器

本文针对表面肌电信号分类任务，考察了四种算法：随机森林（RF）、精细K近邻（FKNN）、集成K近邻（sKNN）和三次支持向量机（SVM3）。这些分类器经过训练，并使用按受试者划分的数据进行测试，并报告平均性能。本文所用不同机器学习算法的超参数设置汇总于表VII。使用标准指标评估分类器的性能，包括交叉验证准确率（α）、测试准确率（β）、卡帕系数（κ）、精确率（γ）、召回率（ρ）和 F1 分数（F_1）。

IV. 分类实验、结果与分析

按照下文所述，采用最先进的分类和特征提取方法对所开发的 EMAHA-DB1 表面肌电数据集进行分析。

A. 预处理和数据划分

根据 [55], 中描述的流程，记录的表面肌电数据按如下方式进行预处理。首先，对表面肌电数据进行滤波，以去除 50Hz 的电源线噪声。然后，采用截止频率为 500Hz 的一阶巴特沃斯低通滤波器。最后，使用对称小波作为母小波，进行 8 阶小波去噪。每位受试者的数据按照 [55] 中的划分方法，按试次划分为 70% 的训练数据和 30% 的测试数据。采用长度为 $N_g = 200$ 个采样点、持续时间为 $T_{seg} = 100ms$ 的非重叠移动窗口片段。每个分段提取的特征数量 s_g 汇总于表 VIII。

表 IX：肌肉与动作的对应关系。

肌肉	肌肉的主要功能 cle
肱二头肌（BB）	屈曲肘关节，使前臂旋后并使手在桡尺关节处旋后
肱桡肌（BR）	屈曲肘关节
桡侧腕屈肌（FCR）	屈曲腕关节并使手外展
尺侧腕屈肌（FCU）	屈曲并内收腕关节
拇短展肌（APB）外展拇指关节	

B. 实验

如前所述，本文开展了以下两项案例研究：1）对表 I 所列的各个动作类别进行分类。在这项案例研究中，分析其在特征集成、分类器、基准分类框架以及特征可视化方面的表现；2）对表 V 所列的 FAABOS类别进行分类。在第二项案例研究中，分析其在特征集成方面的表现，并进一步分析与肌肉部位相关性最高的特征。

C. 案例研究*1*：结果与分析

1) 与特征集成的比较：本比较研究分析了特征集F_0-F_6 。每个特征集均用作SVM3的输入，并评估其性能指标 α 和 β 。如图3a所示，特征集 F_5 （$\alpha = 77.42$ 和 $\beta = 75.39$）表现最佳。其次是特征集成 F_2 ，其在 $\alpha = 78.06$ 和 $\beta = 75.09$上的表现落后0.3%。特征集成 F_6 的分类性能最低（$\alpha = 66.68$和 $\beta = 66.79$）。

2) 与分类器的比较：本实验分析了标准机器学习算法（如随机森林、FKNN、sKNN和SVM3）使用 F_5 特征集时的分类性能。如图3b所示，SVM3分类器（$\alpha = 77.42$和 $\beta = 75.39$）表现最佳，其次是FKNN（$\alpha = 74.83$ 和$\beta = 72.42$）。SKNN分类器的表现最差（$\alpha = 58.4$ 和 $\beta = 58.3$）。因此，从该实验可以看出，对于特征集 F_5 ，SVM3分类器优于其他基准分类器。

3）与基准算法的比较：通过与现有表面肌电基准分类方法进行比较，确定最适合 EMAHA-DB1 的分类框架。这些方法由特征集成与分类框架的不同组合构成，如表 VIII 所示。基准 B_i 表示采用特征集 F_i 的分类框架，适用于 $i = 0, 1, \cdots, 6$。数值分析中所用不同分类器的参数设置也列于表VII。根据交叉验证准确率（α）和测试准确率（β）分析这些分类器的性能，相应结果见图3c。基准 B_5 的性能达到最先进水平，其 $\alpha = 77.42$ 和 $\beta = 75.39$ 均表现出色。在所比较的基准中， B_6 的性能最低，其 $\alpha = 74.2$ 和 $\beta = 69.04$ 表现较差。基准框架的其他性能指标（即 κ、γ、 ρ 和 F_1）见图3d。基准框架 F_5 在各项指标上均取得最高值每项性能指标的具体数值分别为 $\kappa = 0.73$、 γ=0.66、ρ=0.71 和 $F_1 = 0.68$。排名第二的是 B_6 框架，其指标值分别为 $\kappa = 0.66$、γ= 0.60、 ρ= 0.64 和 $F_1 = 0.66$。

4) 使用 *t-SNE* 进行特征可视化：以下分析针对22种单独的动作类别，但按 FAABOS组进行。对于特征集 F_0 至 F_6，观察发现 F_5 是表现最佳的特征集，因此用于序贯特征选择分析（SFS）。通过 SFS，确定了每组手部活动中最相关的特征，并进一步使用 t分布随机邻域嵌入（t-SNE）[56]进行分析。本研究使用排名前6的特征列：84、85、96，97、101和105。排名较高的列为84和85，分别对应均值和方差特征（来自TDS特征集）；96，97，101，和105则对应 SBP特征集 [47]中的频带 [0 (N_s/8)] 和[(N_s/8) (N_s/4)] 。肘部屈伸和腕部屈伸主要由肌群 BB、BR、FCR 和 FCU [57]支持，如表 IX 所示。第2组和第3组的动作类别涉及相同的肌肉运动，包括肘部屈伸、腕部屈伸以及旋前与旋后，如表 X 所示。因此，从图4b和图4c可以看出，由于不同动作涉及相似的肌群并具有相同的基本肌肉运动，部分动作的聚类存在重叠。第1组、第4组和第5组中的动作则可以清晰区分，分别见图4a、图4d和图4e。

D. 案例研究 *2*：结果与分析

*1) FAABOS*类别与特征集成的比较：根据表 V 中规定的 FAABOS类别，对 EMAHA-DB1 的表面肌电信号进行分类。使用排名前三的特征集（如 F_0、 F_2 和 F_5 ）对表面肌电信号的六种 FAABOS类别进行训练和测试，相应结果绘制于图3e中。SVM3分类器（α = 86.54 和 β = 83.21）搭配特征集 F_2 时性能最佳。其次是同一SVM3分类器（α =85.85 和 β = 83.14）搭配特征集 F_5 ，其性能略低 0.07%。使用特征集 F_0 和 SKNN分类器（α = 85.66 和 β =82.39）时性能最差。

2）*FAABOS*组的*t-SNE*特征可视化：本分析针对6个FAABOS类别展开。在特征集 F_0、 F_2和 F_5中，观察发现 F_2 是表现最佳的特征集，因此用于SFS分析。通过SFS分析，本研究选取排名前6的特征列：1、3、4、5、19和23。排名较高的特征列为1、3、4和5，对应平均绝对值（MAV）；第19列对应波形长度；第23列对应自回归系数。根据排名较高的特征列生成t-SNE图，如图5所示。观察发现，动作和静息簇可以清晰区分，但动作组内的簇彼此重叠，这是由于肌群参与相似所致。根据近期一篇关于肌群及其功能的表面肌电研究综述 [58], ，这些肌肉

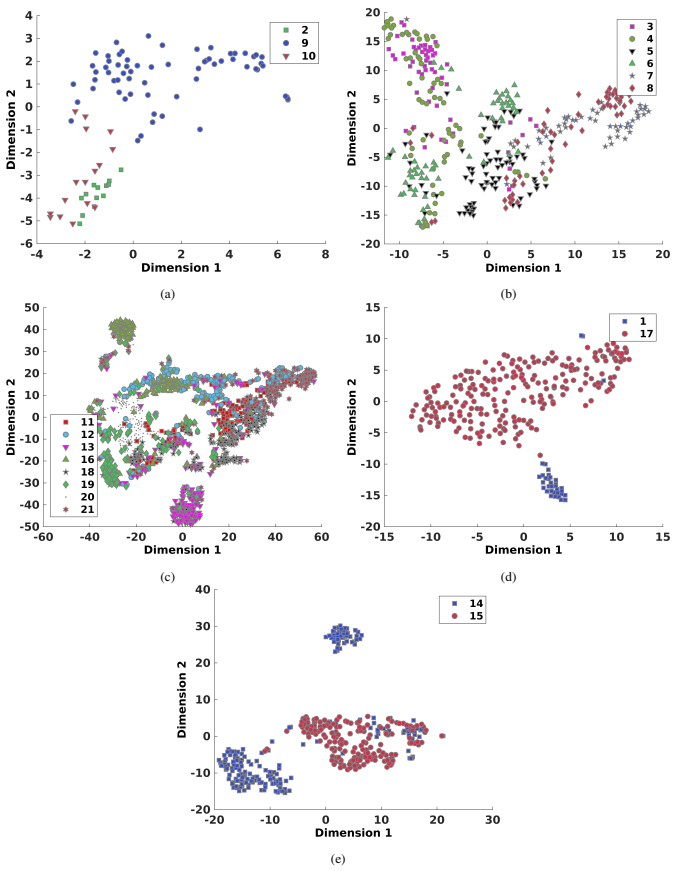

图4：第1组（a）、第2组（b）、第3组（c）、第4组（d）和第5组（e）的特征集t-SNE图。

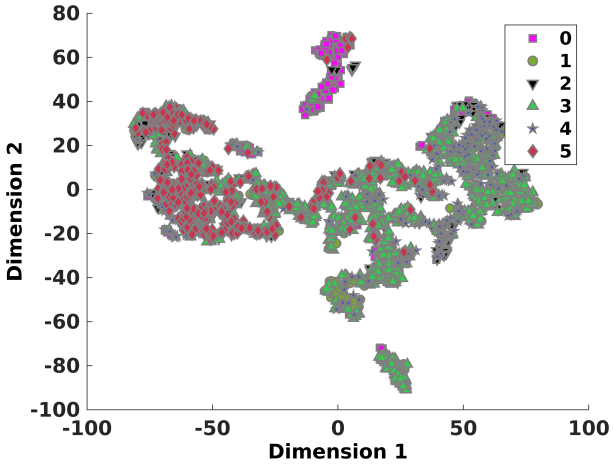

图5：六个FAABOS组的特征集t-SNE图

在本研究中，桡侧腕屈肌、尺侧腕屈肌、肱桡肌和肱二头肌与FAABOS各类别所涉及的主要功能相对应，详见表X。

E. 讨论

在 FAABOS类别（类别数 = 5）的情况下，SVM3方法的分类性能最佳。这可能是因为类别数量相对较少，而且特征集成 F_5 能够更好地捕捉功能类别层面的表征。机器学习框架的性能

表X：FAABOS组与动作及肌肉映射。

组	涉及的主要动作	肌肉
无物体动作（1）	腕屈曲与伸展及手指操作	桡侧腕屈肌、尺侧腕屈肌、BR
Hold 物体（2）	肘屈曲与伸展、腕屈曲与伸展，以及前臂旋前与旋后	BB、BR、桡侧腕屈肌、尺侧腕屈肌
物体抓握（3）	肘屈曲与伸展、腕屈曲与伸展、前臂旋前与旋后，以及手指操作	桡侧腕屈肌、尺侧腕屈肌、肱桡肌、肱二头肌
屈曲 and 手指伸展手指（4）	腕屈曲与伸展及手指操控操控	BB、BR、桡侧腕屈肌、尺侧腕屈肌
书写（5）	肘屈曲与伸展、腕屈曲与伸展，以及手指操作	FCR、BB、尺侧腕屈肌、拇短展肌

可能还需要进一步提升。这种表现可能是因为活动数量相对较多，且类内相关性较高。使用 t-SNE进行的特征可视化显示，FAABOS组内各项活动的可分性较好。在各个FAABOS组的 t-SNE图中，休息与动作之间也呈现出明显的区分。

V. 结论与未来展望

本文收集了一个包含来自印度人群的22项日常生活活动的新型表面肌电数据集（EMAHA-DB1）。EMAHA-DB1包含了一些现有数据集中未涉及的活动。本文将表面肌电EMAHA-DB1数据集与公开可用的现有表面肌电数据集进行了比较。我们从不同角度对该数据集进行了分析，包括时域和频域中的特征集分析、个体动作分类、FAABOS类别分类，以及使用t-SNE进行的特征可视化。在上述分析中，由改进的LMF、时域统计（TDS）特征、频带功率（SBP）、通道互相关和局部二值模式（LBP）组成的集成特征集（F_5）结合三次支持向量机分类器，获得了 β = 75.39%的最高测试准确率。此外，在FAABOS组分类中，最佳性能同样由三次支持向量机分类器（$\beta = 83.21$）取得，其特征集由能量特征和自回归系数组成（F_2）。最后，使用t-SNE图进行的可视化分析表明，所提取的特征集能够清晰地区分同一组内的日常生活活动。所得结果表明，EMAHA-DB1可成功用作开发手势识别系统、生理分析以及日常生活活动表面肌电临床研究的基准。

关于未来的工作，该框架可能需要在特征方面进一步创新，以提升分类性能；EMAHA-DB1 目前仅使用机器学习分类器进行分析，深度学习方面仍有改进空间；也可以使用小波或经验模态分解（EMD）技术分解时间序列，以分析该数据集；最后，还可以分析 EMAHA-DB1 数据集，以学习其统计分布。

致谢

本研究由印度政府 SERB 通过项目资助编号 CRG/2019/003801 资助。

参考文献

[1] T.-H.-C. Nguyen、J.-C. Nebel 和 F. Florez-Revuelta，《基于自我中心视觉的日常生活活动识别：综述》，Sensors，第16卷，第1期，第72页，2016年。[2] F. Monjazebi、A. Dalvandi、A. Ebadi、H. R. Khankeh、M. Rahgozar 和 J. Richter，《基于执行日常生活活动能力的慢性阻塞性肺疾病功能状态评估：纸笔测量工具的系统综述》，Global Journal of Health Science，第8卷，210，2016年3，第 p. .[3] W. H. Organization 等，《简明残疾调查：印度、老挝人民民主共和国和塔吉克斯坦2019年结果》，2021年。[4] I. Narang、B. Mathur、P. Singh 和 V. Jape，《印度上肢截肢者临床调查》，Orthot Prosthet，第40卷，37，1986年第2期，第29页。[5] E. J. Overdorp、R. P. Kessels、J. A. Claassen 和 J. M. Oosterman，《神经心理学和神经病理学缺陷对老年人工具性日常生活活动的综合影响：系统综述》，Neuropsychology Review，第26卷，第1期，第92–106页，2016年。[6] J. C. Deenen、C. G. Horlings、J. J. Verschuuren、A. L. Verbeek 和 B. G. van Engelen，《神经肌肉疾病流行病学：文献全面综述》，Journal of Neuromuscular Diseases，第2卷，第1期，第73–85页，2015年。[7] R. Chieffo、G. Comi 和 L. Leocani，《卒中后步态障碍的非侵入性神经调控：理论依据、可行性与最新进展》，Neurorehabilitation and Neural Repair，第30卷，第1期，第71–82页，2016年。[8] C. L. Kenmuir、M. Hammer、T. Jovin、V. Reddy、L. Wechsler 和 A. Jadhav，《急性缺血性卒中且轻型卒中量表评分较低患者的预后预测因素》，Journal of Stroke and Cerebrovascular Diseases，第24卷，第7期，第1685–1689页，2015年。[9] J. D. Pandian 和 P. Sudhan，《印度的卒中流行病学与卒中护理服务》，Journal of Stroke，第15卷，第3期，第128页，2013年。[10] C. Wang、M. Sivan、D. Wang、Z.-Q. Zhang、G.-Q. Li、T. Bao 和 S. Q. Xie，《基于最大随意收缩的肌肉激活估计进行定量肘部痉挛测量》，IEEE Transactions on Instrumentation and Measurement，第71卷，11，2022年第1页。[11] S. Mitra 和 T. Acharya，《手势识别：综述》，IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)，第37卷，第3期，第311–324页，2007年。[12] S. Waldherr、R. Romero 和 S. Thrun，《用于人机交互的基于手势的界面》，Autonomous Robots，第9卷，第2期，第151–173页，2000年。[13] H.-D. Yang、A.-Y. Park 和 S.-W. Lee，《用于人机交互的手势检测与识别》，IEEE Transactions on Robotics，第23卷，第2期，第256–270页，2007年。[14] B. Burger、I. Ferran´e、F. Lerasle 和 G. Infantes，《双手手势识别及与语音融合以控制机器人》，Autonomous Robots，第32卷，第2期，第129–147页，2012年。[15] N. Makaram、P. A. Karthick 和 R. Swaminathan，《疲劳性肌肉收缩过程中肌电信号变化动态的转移网络方法分析》，IEEE Transactions on Instrumentation and Measurement，第70卷，第1–8页，2021年。[16] D. M. Karantonis、M. R. Narayanan、M. Mathie、N. H. Lovell 和 B. G. Celler，《利用三轴加速度计实现用于动态监测的实时人体运动分类器》，IEEE Transactions on Information Technology in Biomedicine，第10卷，167，2006年第1期，第156页。[17] J.-Y. Yang、J.-S. Wang 和 Y.-P. Chen，《利用加速度测量进行活动识别：一种用于构建神经分类器的有效学习算法》，Pattern Recognition Letters，第29卷，第16期，第2213–2220页，2008年。[18] W. Qi、H. Su 和 A. Aliverti，《基于智能手机的人类活动自适应识别与实时监测系统》，IEEE Trans Hum Mach Syst，第50卷，第5期，第414–423页，2020年。[19] C. J. Bell、P. Shenoy、R. Chalodhorn 和 R. P. Rao，《利用非侵入式脑机接口控制人形机器人》，Journal of NeuroEngineering and Rehabilitation，第5卷，第2期，第214页，2008年6月，doi: 10.1088/1741-2560/5/2/012。[20] D. Farina、N. Jiang、H. Rehbaum、A. Holobar、B. Graimann、H. Dietl 和 O. C. Aszmann，《从表面肌电中提取神经信息以控制上肢假肢：新兴途径与挑战》，IEEE Transactions on Neural Systems and Rehabilitation Engineering，第22卷，第4期，第797–809页，2014年。[21] R. Wen、W. Tay、B. P. Nguyen、C.-B. Chng 和 C.-K. Chui，《基于直接增强现实的手势引导机器人辅助手术界面》，"Comput Methods Programs Biomed，第116卷，第2期，pp. 68–80, 2014. [22] M. T. Wolf, C. Assad, M. T. Vernacchia, J. Fromm, and H. L. Jethani，"基于手势的机器人控制及其来自 JPL BioSleeve 的可变自主性"，载于《2013 IEEE 国际机器人与自动化会议》。IEEE，2013 年，第 1160–1165 页。[23] Z. Lu, X. Chen, Q. Li, X. Zhang, and P. Zhou，"一种手势识别框架及面向移动设备的可穿戴手势交互原型"，IEEE Transactions on Human-Machine Systems，第 44 卷，第 2 期，第 293–299 页，2014 年。[24] S. Jiang, B. Lv, W. Guo, C. Zhang, H. Wang, X. Sheng, and P. B. Shull，"通过表面肌电和 IMU 传感实现腕戴式实时手部及表面手势识别的可行性"，IEEE Transactions on Industrial Informatics，第 14 卷，第 8 期，第 3376–3385 页，2017 年。[25] J. A. Mucarquer, P. Prado, M.-J. Escobar, W. El-Deredy, and M. Za˜nartu，"利用肌电阵列改进脑电图肌肉伪迹去除"，IEEE Transactions on Instrumentation and Measurement，第 69 卷，第 3 期，第 815–824 页，2020 年。[26] J.-H. Jeong, J.-H. Cho, K.-H. Shim, B.-H. Kwon, B.-H. Lee, D.-Y. Lee, D.-H. Lee, and S.-W. Lee，"在多次记录会话中采集的单侧上肢 11 项直观运动任务多模态信号数据集"，GigaScience，第 9 卷，第 10 期，文章号 giaa098，2020 年。[27] J. Tryon and A. L. Trejos，"评估卷积神经网络作为脑电图–肌电信号融合方法的效果"，Frontiers in Neurorobotics，第 15 卷，文章号 692183，2021 年。[28] M. Zandigohar, M. Han, M. Sharif, S. Y. Gunay, M. P. Furmanek, M. Yarossi, P. Bonato, C. Onal, T. Padir, D. Erdogmus 等，"融合肌电信号与视觉信息，以推断假手控制中的人类抓握意图"，arXiv 预印本 arXiv:2104.03893，2021 年。[29] M. S. Totty and E. Wade，"用于日常生活活动非侵入式分类的肌肉激活与惯性运动数据"，IEEE 生物医学工程汇刊，第 65 卷，第 1076 页，2018 年第 5 期，第 1069 页。[30] N. J. Jarque-Bou, M. Vergara, J. L. Sancho-Bru, V. Gracia-Ib´a˜nez, and A. Roda-Sales，"日常生活活动期间前臂和手部运动学及肌电图的校准数据库"，Scientific Data，第 6 卷，第 1 期，第 1–11 页，2019 年。[31] X. Song, S. S. Van De Ven, L. Liu, F. J. Wouda, H. Wang, and P. B. Shull，"基于日常生活活动的康复系统，用于中风后手臂和手部运动功能再训练"，IEEE Transactions on Neural Systems and Rehabilitation Engineering，第 30 卷，第 621–631 页，2022 年。[32] A. Vijayvargiya, P. Singh, R. Kumar, and N. Dey，"利用可解释人工智能实现下肢表面肌电测量与活动识别分析的硬件实现"，IEEE Transactions on Instrumentation and Measurement，第 71 卷，第 1–9 页，2022 年。[33] Q. Li, Z. Luo, and J. Zheng，"一种基于深度异常检测的新方法：使用手势多通道表面肌电信号进行用户身份验证"，IEEE Transactions on Instrumentation and Measurement，第 71 卷，第 1–11 页，2022 年。[34] D. N. Majumdar，"关于统计方法在人类测量学中应用的讨论"，Sankhy˘a: The Indian Journal of Statistics (1933-1960)，第 4 卷，第 4 期，第 591–598 页，1940 年。 [在线]。网址：http://www.jstor.org/stable/40383967 [35] P. P. Majumder，"人体测量学、马哈拉诺比斯与人类遗传学"，Sankhya B，第 80 卷，第 1 期，第 224–236 页，2018 年。[36] P. Liang, W. H. Kwong, A. Sidarta, C. K. Yap, W. K. Tan, L. S. Lim, P. Y. Chan, C. W. K. Kuah, S. K. Wee, K. Chua 等，"以亚洲人为中心、记录日常生活活动的人体运动数据库"，Scientific Data，第 7 卷，第 1 期，第 1–13 页，2020 年。[37] J. Wojtusch and O. von Stryk，"Humod——用于研究、建模和仿真人体运动驱动层动力学的多功能开放数据库"，载于《2015 IEEE-RAS 第 15 届人形机器人国际会议（Humanoids）》，2015 年，第 74–79 页。[38] G. Uswatte and L. Hobbs Qadri，"一种用于量化中风后日常生活中手臂活动的行为观察系统。"Rehabilitation Psychology，第 54 卷，第 4 期，第 398 页，2009 年。[39] M. Atzori, A. Gijsberts, C. Castellini, B. Caputo, A.-G. M. Hager, S. Elsig, G. Giatsidis, F. Bassetto, and H. M¨uller，"用于非侵入式自然控制机器人假手的肌电图数据"，Sci. Data，第 1 卷，第 1 期，文章号 140053，2014 年 12 月。[40] M. Ortiz-Catalan, R. Br˚anemark, and B. H˚akansson，"BioPatRec：一种基于模式识别算法的人工肢体控制模块化研究平台"，Source Code Biol Med，第 8 卷，第 1 期，文章号 11，2013 年 4 月。[41] R. N. Khushaba, M. Takruri, J. V. Miro, and S. Kodagoda，"利用时变频谱特征实现与肢体位置无关的肌电模式识别"

,"神经网络，第55卷，第42–58页，2014。

[42] S. Lobov、N. Krilova、I. Kastalskiy、V. Kazantsev 和 V. A. Makarov，“限制表面肌电接口性能的潜在因素”，*Sensors*，第18卷，第4期，第1122页，2018年。[43] “Noraxon Ultium 肌电系统”，网址：https://www.noraxon.com/ our-products/ultium-emg/，2022年。[44] E. Criswell，*Cram 表面肌电学导论*。伯灵顿：Jones & Bartlett 出版社，2010年。[45] S. Pizzolato、L. Tagliapietra、M. Cognolato、M. Reggiani、H. M¨uller 和 M. Atzori，“六种肌电采集配置在手部动作分类任务中的比较”，*PLoS One*，第12卷，第10期，第1–17页，2017年10月。[46] N. Male˘sevi´c、A. Olsson、P. Sager、E. Andersson、C. Cipriani、M. Controzzi、A. Bj¨orkman 和 C. Antfolk，“一个包含65种等长手势的高密度表面肌电信号数据库”，*Scientific Data*，第8卷，第1期，第1–10页，2021年。[47] N. K. Karnam、A. C. Turlapaty、S. R. Dubey 和 B. Gokaraju，“基于能量特征的手势表面肌电信号分类”，生物医学信号处理与控制，第70卷，第102948页，2021年。[48] A. J. Young、L. H. Smith、E. J. Rouse 和 L. J. Hargrove，“使用表面肌电模式识别对同步动作进行分类”，*IEEE Trans Biomed Eng*，第60卷，第5期，第1250–1258页，2012年5月，doi：10.1109/TBME.2012.2232293。[49] P. Geethanjali 和 K. Ray，“用于基于肌电模式识别的假手的低成本实时研究平台”，*IEEE/ASME Transactions on Mechatronics*，第20卷，第4期，第1948–1955页，2014年8月，doi：10.1109/TMECH.2014.2360119。[50] A. Waris、I. K. Niazi、M. Jamil、K. Englehart、W. Jensen 和 E. N. Kamavuako，“肌电手部动作分类技术的多日评估”，*IEEE 生物医学与健康信息学期刊*，第23卷，第4期，第1526–1534页，2018年7月，doi：10.1109/ JBHI.2018.2864335。[51] A. H. Al-Timemy、R. N. Khushaba、G. Bugmann 和 J. Escudero，“提高经桡骨截肢者肌电控制多功能上肢假肢在力变化情况下的性能”，*IEEE Transactions on Neural Systems and Rehabilitation Engineering*，第24卷，第6期，第650–661页，2015年6月，doi：10.1109/TNSRE.2015.2445634。[52] A. C. Turlapaty 和 B. Gokaraju，“利用表面肌电数据对身体动作进行分类的特征分析”，*IEEE 传感器期刊*，第19卷，第24期，第12 196–12 204页，2019年12月，doi：10.1109/JSEN.2019. 2937979。[53] E. Campbell、A. Phinyomark 和 E. Scheme，“肌电控制的当前趋势与混杂因素：肢体位置和收缩强度”，*Sensors*，第20卷，第6期，第1613页，2020年。[54] A. H. Al-Timemy、G. Bugmann、J. Escudero 和 N. Outram，“利用表面肌电图对灵巧假手控制中的手指运动进行分类”，*IEEE JBiomed Health Inform*，第17卷，第3期，第608–618页，2013年5月，doi：10.1109/JBHI.2013.2249590。[55] N. K. Karnam、S. R. Dubey、A. C. Turlapaty 和 B. Gokaraju，“EMGHandNet：一种利用表面肌电信号进行手部活动分类的卷积神经网络与双向长短期记忆网络混合架构”，生物控制论与生物医学工程，第42卷，第1期，第325–340页，2022年。[56] L. Van der Maaten 和 G. Hinton，“使用 t-SNE 可视化数据。”机器学习研究期刊，第9卷，第11期，2008年。[57] K. M. K. M. Van De Graaff，人体解剖学 / *Kent M. Van De Graaff*。第6版。美国马萨诸塞州波士顿：WCB/McGraw-Hill，1998年。[58] N. J. Jarque-Bou、J. L. Sancho-Bru 和 M. Vergara，“日常生活活动中前臂和手部肌肉活动表征的肌电应用系统综述：研究结果、挑战与未决问题”，*Sensors*，第21卷，第9期，2021年。