

机械臂抓取任务的脑电分类^①



吴恭朴, 王长元, 肖 锋

(西安工业大学 计算机科学与工程学院, 西安 710021)

通信作者: 王长元, E-mail: cyw901@163.com

摘 要: 针对大脑认知完好无损的患者, 却患有重度神经肌肉疾病导致肢体行动受限的问题, 为使患者重新获取障碍肢体的自主控制能力, 本文提出了一种机械臂抓取任务的脑电分类方法对患者进行障碍肢体运动康复训练. 首先使用非侵入式脑电技术对运动想象脑电信号进行采集, 通过预处理、特征提取以及多尺度特征融合卷积神经网络进行分类识别; 最后利用分类模型得到的标签解码成机械臂能够识别的指令, 控制机械臂完成特定任务. 实验结果表明: 实验选取的 15 名健康受试者运动想象实验采集的脑电数据具有可行性, 平均准确率达到 82% 以上; 为机械臂抓取任务的脑电分类提供了一种新思路.

关键词: 脑机接口; 运动想象脑电; 多尺度特征融合; 卷积神经网络; 机械臂

引用格式: 吴恭朴, 王长元, 肖锋. 机械臂抓取任务的脑电分类. 计算机系统应用, 2023, 32(5): 204-211. <http://www.c-s-a.org.cn/1003-3254/9083.html>

EEG Classification of Robotic Arm Grasping Task

WU Gong-Pu, WANG Chang-Yuan, XIAO Feng

(School of Computer Science and Engineering, Xi'an Technological University, Xi'an 710021, China)

Abstract: Aiming at the problem of limb movement limitation caused by severe neuromuscular disease in patients with intact brain cognition, this study tries to enable patients to autonomously control their impaired limbs again and thus proposes an electroencephalogram (EEG) classification method of robotic arm grasping task to carry out rehabilitation training for patients with impaired limb movement. Firstly, the motor imagery EEG signals are collected by a non-invasive EEG technology, and they are then classified and identified by preprocessing, feature extraction, and convolutional neural networks with multi-scale feature fusion. Finally, the label obtained by the classification model is decoded into instructions that can be recognized by the robotic arm, so as to control the arm to fulfill specific tasks. The experimental results show that the EEG data collected from experimentally selected 15 healthy subjects in the motor imagery experiments are feasible, and the average accuracy rate reaches more than 82%, which provides a new idea for EEG classification of robotic arm grasping task.

Key words: brain-computer interface (BCI); motor imagery electroencephalogram (EEG); multi-scale feature fusion; convolutional neural network (CNN); robotic arm

重度神经肌肉疾病或肌萎缩侧索硬化症、脊髓损伤等神经障碍疾病会使患者的肢体肌肉受限甚至可能丧失自主控制能力^[1,2]. 而此类患者的大脑认知却是完好无损的, 因此可通过脑机接口技术进行辅助治疗. 脑

机接口 (brain-computer interface, BCI) 是一种新型的人机交互技术, 可以不依赖于患者受损的外周神经及肌肉组织, 通过大脑和外部智能机械臂之间直接进行信息和指令的传输, 让患者控制外界设备对障碍肢体进

① 基金项目: 国家自然科学基金 (52072293); 基础加强计划技术领域基金 (2020-JCJQ-JJ-430)

收稿时间: 2022-10-27; 修改时间: 2022-11-29; 采用时间: 2022-12-11; csa 在线出版时间: 2023-03-24

CNKI 网络首发时间: 2023-03-27

行运动康复训练^[3,4], 以此来刺激脑的重塑, 使患者重新获取障碍肢体的自主控制能力. 陈小刚等人^[5]通过设计结合增强现实 (AR) 脑机接口和计算机视觉的高级控制体系结构, 控制机械臂执行拾取和放置任务. 吴浩镇等人^[6]采用基于稳态视觉刺激的 BCI 获取脑电信号, 通过对采集视觉刺激诱发的脑电信号进行降采样滤波, 利用 CCA 将数据进一步分析转化为机械臂的控制信号, 以此控制机械臂进行运动. Hayta 等人^[7]根据国际 10-10 系统, 从头皮上的 64 个位置记录脑电图 (EEG) 信号. 研究了基于 3 类电机图像的 BCI 的配置参数优化, 用于控制平面中的六自由度 (DOF) 机械臂.

通过脑机接口技术来控制机械臂辅助肢体障碍患者完成日常简单的任务, 将会提高他们的神经康复训练效果. 运动想象 (motor imagery, MI) 是一类重要的脑机接口范式, 在肢体运动功能障碍的康复训练中具有潜在的应用价值^[8], 目前已经有研究人员成功将患者的运动想象意图解码用于机械臂的控制. 但是由于脑电信号比较微弱, 并且在采集过程中易产生大量的干扰信号, 如果患者想要使用脑电信号精准控制机械臂, 这将变得十分困难. 邓欣等人^[9]针对脑机接口系统信号的复杂性和输出控制指令较少的问题, 提出了融合运动想象脑电与眼电信号方法扩充控制指令的轻量级机械臂控制系统. 将双眨眼作为任务开关, 单次眨眼控制阶段切换, 通过运动想象生成多种控制指令, 以此控制机械臂运动. 曲思霖等人^[10]针对运动想象脑电信号实现任务少、识别准确率低等问题, 提出了基于小波分解的共空间模式脑电信号特征提取方法. 通过识别的脑电信号作为解码控制信号, 控制机械臂抓取空间中目标物体. 尹悦等人^[11]设计想象左、右手两指令的运动想象脑机接口范式, 控制外骨骼运动, 实验结果识别正确率为 70%. 验证了设计的外骨骼控制系统的有效性. Ak 等人^[12]提出了一种用于 BCI 的运动想象脑电图信号分类的新方法, 通过频谱图方法后进行深度学习, 来控制机械臂的运动. Xu 等人^[13]研究提出了一种基于触觉反馈的基于运动图像脑电的连续遥控机器人控制系统, 实验结果表明, 利用无线便携式设备获取的脑电图实现连续遥控机器人控制系统完成伸展和抓取任务的可行性.

本文为降低干扰和提高识别率, 对传统实验范式进行改进, 采用非侵入式脑机接口技术和操作相关图

片视觉引导方式进行运动想象实验, 结合特定任务, 采集被试者脑电信号. 通过陷滤波和带通滤波对脑电信号进行处理, 并设计了一种基于多尺度特征并行融合的卷积神经网络方法^[14]进行脑电意图分类识别. 将识别的标签转换成供机械臂识别的指令, 完成对机械臂特定任务操作的控制.

1 信号采集与预处理

1.1 脑电实验设计

本文使用北京津发科技股份有限公司提供的 ErgoLAB 人机环境同步平台脑电测量系统进行脑电实验的设计和脑电信号的实时采集. 脑电实验设计采用操作相关图片视觉引导方式进行运动想象实验, 并设计了机械臂的 6 个操作动作, 图 1 依次是“下降”“抓取”“上升”“左转”“放置”“放置”和“右转”, 进行信号采集.




图 1 脑电实验设计动作

1.2 脑电信号采集

1.2.1 采集设备

脑电信号领域目前已经被广泛使用的非侵入式采集方法有多通道电极 EEG 方法、脑电图、磁共振成像、近红外光谱和磁脑电图等^[15,16]. 目前, 临床实验中是以美国临床神经生理学会制定的 10-20 标准导联、10-10 标准导联和 10-5 标准导联最为常见^[17].

因此本文将引用 10-20 标准导联系统建议的电极位置为基准展开实验, 同时表 1 是选用 Desai^[18]的标准将脑电信号依据其频率分为 5 个不同波段. 采用半干式电极设备, 图 2 是集精度与便携一体的 32 导水电极设备. 相比于干电极而言, 它采用少量的液体电解质, 就可以达到相对较低的阻抗并获得高质量的脑电信号. 这种测量方式, 可以保证采集较高的脑电信号质量. 其采样频率高达 256 Hz, 分辨率为 24 bit, 支持信号可编程放大. 并使用无线蓝牙模块, 进行无线数据传输.

表1 不同波段的脑电信号

波段名	Delta	Theta	Alpha	Beta	Gamma
频率范围 (Hz)	<4	4-8	8-14	14-30	>30
带宽	4	4	6	16	—




图2 脑电信号采集通道

1.2.2 信号采集

15名无任何病史且身体健康的受试者, 签署知情同意书. 舒适地坐在安静的环境中, 依靠大脑想象支配肢体完成运动, 在图片视觉引导想象实验的过程中, 肢体保持静止, 不做出实际运动. 图3是受试者在进行特定任务运动想象, 此过程会产生活跃的脑电信号, 通过脑电帽采集脑电信号的同时使用软件对脑电数据进行记录.



图3 受试者进行特定任务运动想象

1.3 脑电信号通道选择

本文选择的是医用级32导联水电极脑电帽, 通过在不同的电极位置放置湿润海绵条, 使电极充分与头皮进行接触, 采集脑电信号. 为了避免设备中湿润海绵条

在使用过程中由于水分蒸发导致信号传输质量下降的情况, 本文设计了多组预实验来考察海绵条水分蒸发情况, 预实验的实验数据不会纳入样本中^[19]. 预实验结果表明, 完成设备穿戴后大约2h会出现电极与海绵接触不良的情况, 设备传输脑电信号下降, 预实验结束. 根据上述预实验结果以及被试者反馈, 实验在穿戴好设备之后1h内效果最好, 因此本文确定了实验的时长是1h.

在预实验中发现, 由于个体颅骨形状差异导致部分电极位置上无法充分和被试者头皮进行接触. 因此, 为了系统稳定性通过预实验确定了实验时长最长为1h, 同时排除部分接触不良的电极, 分别为: F7、F8、T7、T8、P7、P8、O1、Oz和O2, 图4中F7、F8、T7、T8、P7、P8、O1、Oz和O2表示被排除的电极, A1和A2表示参考电位电极. 其中脑电信号的零势点是一个夹在耳垂部分的额外电极, 是脑电采集设备的电势校准点, 仅用于采集系统内部计算头皮上32导电位的相对电势差, 后续不会在处理中使用到这两个电极通道^[19].




图4 排除电极与参考电位平面坐标

1.4 脑电信号预处理

脑电信号是一种不稳定的5-100 Hz低频生物电信号, 易受到其他生物信号和伪迹噪声的干扰, 并且在使用脑电仪、电脑等电子设备进行数据采集时, 不可避免会产生工频干扰. 没有经过任何处理的EEG数据会受到很多伪迹的干扰, 这些干扰信号无疑会使EEG信号分析更加复杂, 也不能更好地反映大脑的思维活动, 为了避免增加工作量, 在提取之前需要将其

剥离^[20]. 干净的 EEG 数据预处理是分析结果准确的必要前提, 数据预处理的好坏会影响后续的分析结果. 目前大多数预处理方法为公共空间模式 (CSP)、主成分分析 (PCA)、公共平均参考 (CAR)、表面拉普拉斯 (SL)、自适应滤波^[15]、独立成分分析 (ICA) 和数字滤波器等.

为了更容易地识别出大脑活动诱发的脑电信号, 需要使用合适的滤波器去除噪声干扰. 滤波器是根据设置的要求让需要的频段的信号通过, 抑制不需要的频段的信号. 带通滤波器只让指定的范围频段内的信号通过, 其他频率的信号都抑制掉; 而带阻滤波器 (也称为带阻滤波器) 则是抑制特定频段的信号, 其他频率

的信号都通过的滤波器.

因此, 本文首先采用 1–40 Hz 的带通滤波和会替代高通滤波的陷滤波对 50 Hz 市电干扰进行过滤^[21], 对原始脑电信号数据进行滤波处理, 同时去均值光滑处理. 图 5 展示了被试者在 2 s 间进行特定任务抓取的滤波处理后的脑电信号图. 在休息阶段被试者脑电信号波形图会处于较平缓状态, 由图 5 中 00:06:18.000 之前的波形图可以看出. 00:06:18.000 之后开始缓慢产生波动, 00:06:19.000–00:06:21.000 期间产生剧烈波动. 通过波形图可以得出被试者正在进行运动想象脑电实验所产生的脑电信号波动. 经过滤波处理后的部分通道波形图效果较光滑, 达到预期目标.

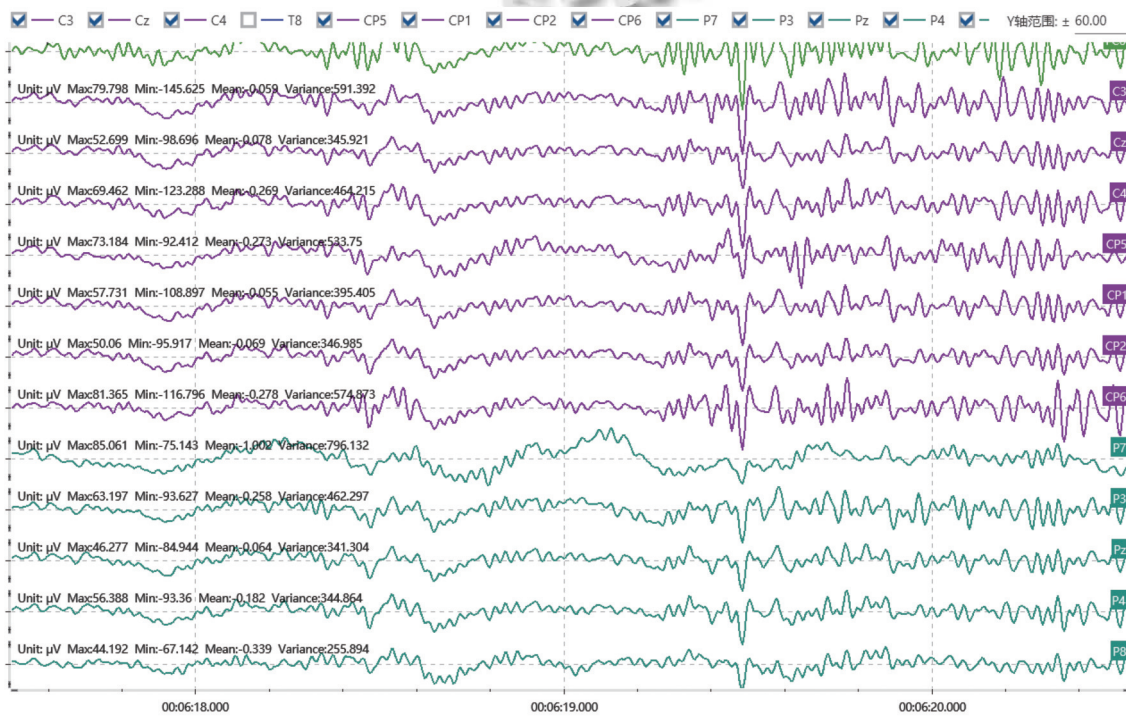


图 5 不同通道的脑电信号图

1.5 特征提取

经过滤波处理后的脑电数据就可以进行特征提取, 特征能够代表一个信号的固有模式, 是信号处理及分析任务中的常规手段. 脑电信号是一种非平稳的随机信号, 一般来说, 随机信号的持续时间和总能量是无限的, 但是它的平均功率是有限的, 因此, 在脑电信号特征应用方面要对随机信号的频域进行分析, 由此看来, 功率谱的研究是必不可少的, 功率谱密度目前常被研究者作为脑电研究中的一种重要特征^[22,23].

本文采用 Welch 法估计功率谱, 该方法首先将长度 N 的数据 $x(n)$ 分成 L 段, 每段有 M 个数据, 第 i 段数据表示为:

$$x_i(n) = x(n + iM - M)d[n + (i - 1)M], \quad 0 \leq n \leq M, 1 \leq i \leq L \quad (1)$$

其中, $d[]$ 表示矩形窗. 然后, 将窗函数 $w(n)$ 加到每一个数据段上, 求出每一段的周期图, 第 i 段的周期图如式 (2) 所示, 其中 U 为归一化因子, 可通过式 (3) 求得. 假设每段周期图互不相关, 故最后的功率谱估计如式 (4) 所

示. 相关研究表明, Welch 法为渐进无偏估计, 其方差与 M 有关, 估计方差为周期图方差的 $1/L$.

$$I_i(\omega) = \frac{1}{MU} \left| \sum_{n=0}^{M-1} x_i(n) w(n) e^{-j\omega n} \right|^2, 1 \leq i \leq M-1 \quad (2)$$

$$U = \frac{1}{M} \sum_{n=0}^{M-1} w^2(n) \quad (3)$$

$$P_{xx}(e^{j\omega}) = \frac{1}{L} \sum_{i=1}^M I_i(\omega) \quad (4)$$

本文基于 Welch 法计算滤波后脑电信号以及 δ , θ , α , β 和 γ 频段的功率谱密度, 在计算不同频段的功率时, 可通过式 (5) 所示, 计算该频段功率密度的和, 即相应功率密度曲线对应频段内的面积, 其中, $psd(f)$ 表示功率谱密度函数, f 表示信号的频率.

$$\begin{cases} P_\delta = \int_1^4 psd(f)df \\ P_\theta = \int_4^8 psd(f)df \\ P_\alpha = \int_8^{13} psd(f)df \\ P_\beta = \int_{13}^{30} psd(f)df \\ P_\gamma = \int_{30}^{40} psd(f)df \end{cases} \quad (5)$$

本文选取被试者在想象抓取任务和休息时的 C4 通道进行 PSD 分析, 抓取任务和休息的总功率图分别如图 6、图 7 所示, PSD 功率谱图分别如图 8、图 9 所示.




图 6 休息时 δ , θ , α , β 和 γ 频段的总功率图




图 7 抓取时 δ , θ , α , β 和 γ 频段的总功率图




图 8 休息时 PSD 功率谱密度图




图 9 抓取时 PSD 功率谱密度图

图 6 和图 8 显示的是被试者在休息时, θ , α , β 和 γ 频段的功率偏低, 而 δ 频段的功率有些偏高, 可能是被试者在休息时眨眼造成的. 但整体呈现平静状态, 说明被试者没有进行运动想象实验. 与此同时, 图 7 和图 9 显示的是 δ , θ , α , β 和 γ 频段的功率整体偏高, 被试者的脑区呈现活跃状态, 活跃状态由蓝色到红色程度由低到高, 说明被试者正在进行运动想象实验.

2 多尺度特征融合卷积神经网络

目前用于识别脑电信号的分类器主要划分为结合机器学习的经典分类器和结合深度学习技术的神经网络分类模型. 相比于传统的机器学习分类器, 基于深度学习网络的分类模型则对数据分类更为高效. 典型的基于深度学习的分类网络为卷积神经网络. CNN 的结构类似于视觉神经系统结构, 是一个多层的神经网络结构. 其中输入层用于接收数据, 卷积层、池化层和全连接层共同构成 CNN 的隐含层, 也就是 CNN 的核心层, 用于数据的计算和分析. 最后的输出层输出数据分析和判定的结果.

通过对传统机器学习分类模型和神经网络分类模型的分析可知, 现有的传统机器学习分类模型虽然对数据样本直接分类较强, 但其学习能力有限, 泛化不高. 因此, 为获取较为丰富的脑电特征信息, 本文使用基于多尺度特征并行融合的卷积神经网络方法进行分类^[14], 以获取图像各层级不同尺度特征加强网络分类效果. 模型主要由特征提取、多尺度特征融合以及模式识别 3 个单元组成, 图 10 是整体结果模型图.

2.1 特征提取单元

特征提取单元将脑电数据作为输入, 输入特征大小为 $(n, 512, 23)$, 其中 n 为样本量, 512 为提取 2 s 的脑电数据, 23 是选取的通道数. 采用不同尺度卷积核并行提取信号不同分辨率的空间信息. 本文分别对输入特征图使用 3、5 不同尺度卷积核进行提取, 第 1 个卷积层的卷积核大小为 5×5 , 步长为 2; 第 2 个卷积层的卷积核大小为 5×5 , 步长为 1; 第 3 个卷积层的卷积核大

小为 3×3 , 步长为 1.

通常情况下, 在同一时间大约有 1%–4% 的神经元是处于活跃状态的, 为了提高神经元的活跃状态. 因此, 本文在每个卷积层之后加入激活函数层 ReLU, 使用修

正线性单元 (即线性整流) 的神经网络中大概有 50% 的神经元可以处于激活状态. 与此同时, 本文还选择最大池化层降低数据维度并保留主要特征信息以及使用归一化层, 防止训练过程中出现过拟合现象.

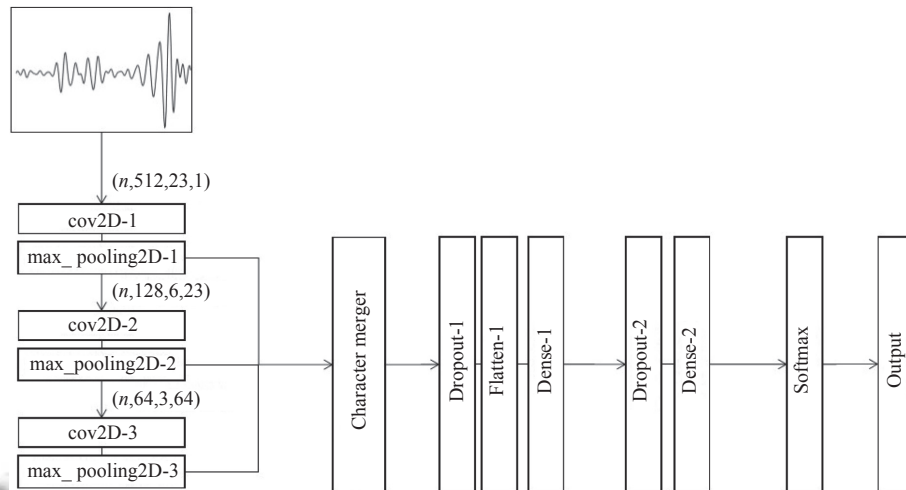


图 10 网络分类模型

2.2 多尺度特征融合单元

多尺度特征融合单元保证网络同步提取细节和全局特征, 该部分将特征提取单元的输出作为输入, 在保证特征多样化表达的同时进行融合, 设计池化层来参与融合特征向量的维度^[14], 第 1 层池化核大小为 3×3 , 步长为 2; 第 2 层池化核大小为 2×2 , 步长为 2; 第 3 层池化核大小为 2×2 , 步长为 1, 输入到融合层中进行特征融合.

2.3 模式识别单元

模式识别单元是在多尺度特征融合单元之后, 把融合后的特征输入进行识别, 而 N 分类的识别准确率是在全连接层与 Softmax 分类器进行输出^[14], 表达式为:

$$A_j(z) = \frac{e^{z_j}}{\sum_N e^{z_N}} \quad (6)$$

其中, z_j 为第 j 个类别的线性概率; z_N 为 N 个类别的线性概率之和; $A_j(z)$ 为类别归一结果.

全连接层一般位于多个卷积层和池化层之后, 输出层之前. 主要就是连接所有输入特征, 生成特征列向量. 此外, CNN 的最后一个全连接层还可以对特征向量进行降维, 得到与分类类别相对应的特征向量. 在全

连接层中对输入特征的操作同常规神经网络类似, 先进行矩阵乘法, 再加上偏置的运算, 最后通过激活函数的非线性变换来得到其列向量. 最后一个全连接层来说只进行线性计算, 之后在输出层使用分类函数进行非线性变换, 因此最后一个全连接层和分类函数可合称输出层. 对于全连接层来说, 其神经元数量越多, 网络的拟合能力就越强, 由于参数冗余带来的过拟合风险也越大, 因此, 一般会在全连接层后会进行正则化或 Dropout 的操作来避免过拟合的发生.

3 机械臂控制及结果分析

3.1 数据集设置

本文采用 15 名被试者总共做了 1800 次实验, 每次实验的总时长是 36 s, 其中休息准备阶段 3 s, 机械臂动作想象时长分别为 3 s. 实验中, 设备采集数据的采样频率为 256 Hz, 采样方法选取任务动作的 0.5–2.5 s 范围的数据, 即每个事件的数据窗口设置为 2 s, 每个序列数据样本为 512 行. 根据脑电信号通道选择, 排除部分干扰通道. 最终确定数据集大小为 $(n, 512, 23)$, 其中 n 为样本量, 512 为提取 2 s 的脑电数据, 23 是选取的通道数. 标签设置根据 6 组不同的特定任务, 将前 3 组归为抓取任务标签, 后 3 组归为释放任务标签.

3.2 模型训练

本文使用的设备配置为 32 GB 内存, Titan V GPU 和 i7 处理器. 随机选取数据集的 70% 为训练集对多尺度特征融合模型进行训练学习, 30% 为测试集. 设计的学习率为 0.01, 迭代次数为 200 次, 并加入 L2 正则化提高泛化能力, 防止网络过拟合, L2 正则化设置为 0.0001. 通过设置对应任务标签进行模型训练.

3.3 机械臂系统调试

本文选择以树莓派作为系统的主控芯片, 来控制机械臂运行. 为了避免机械臂系统的问题导致机械臂不能完成特定任务抓取和释放, 因此, 本文在使用脑机接口控制机械臂之前对机械臂系统进行测试, 图 11 是对机械臂系统的测试图. 测试结果显示, 机械臂的各个动作都能正常执行, 达到预定要求, 可以进行脑电测试实验.




图 11 机械臂动作测试

3.4 机械臂运行

本文通过完成特定任务的脑电测试数据作为动作意图输入, 输入到训练好的模型中, 依次得出分类结果, 根据不同的分类结果, 将其解码成控制机械臂的指令, 完成机械臂的抓取和放置操作, 图 12 展示了机械臂完成抓取和释放的动作过程, 通过脑电测试, 机械臂能识别出脑电信号并完成抓取任务的一系列操作.




图 12 机械臂运行

3.5 识别率分析

根据机械臂动作识别结果我们可以判断出机械臂的识别率, 并且计算出不同动作所训练出来的平均识别率见表 2. 结果分析可知, 机械臂的平均识别率能达到 82% 以上, 基本达到了预期效果.

表 2 机械臂识别率 (%)

机械臂动作	识别率	平均识别率
下降/抓取/上升	82.5	82.7
左转/放置/右转	82.9	

4 结论

本文通过 32 导脑电帽采集脑电信号, 使用带通滤波、陷滤波进行信号预处理以及利用频谱图提取特征, 结合多尺度特征融合的卷积神经网络进行训练学习. 最后, 利用特定任务的脑电数据对模型进行测试, 测试的机械臂识别率达到预期效果.

机械臂抓取任务的脑电分类方法研究意义重大, 然而要实现这一系统还需要解决一系列技术难题, 其中最关键的技术就是设计自然的运动想象任务模式并进行有效的解码. 本文针对这一关键技术, 开展面向机械臂控制的运动想象脑电识别研究, 为机械臂抓取任务的脑电分类提供了一种新思路.

参考文献

- 1 Ganzer PD, Colachis IV SC, Schwemmer MA, *et al.* Restoring the sense of touch using a sensorimotor demultiplexing neural interface. *Cell*, 2020, 181(4): 763–773. e12. [doi: 10.1016/j.cell.2020.03.054]
- 2 Pels EGM, Aarnoutse EJ, Leinders S, *et al.* Stability of a chronic implanted brain-computer interface in late-stage amyotrophic lateral sclerosis. *Clinical Neurophysiology*, 2019, 130(10): 1798–1803. [doi: 10.1016/j.clinph.2019.07.020]
- 3 Chaudhary U, Birbaumer N, Ramos-Murguialday A. Brain-computer interfaces for communication and rehabilitation. *Nature Reviews Neurology*, 2016, 12(9): 513–525. [doi: 10.1038/nrneurol.2016.113]
- 4 Aggarwal S, Chugh N. Review of machine learning techniques for EEG based brain computer interface. *Archives of Computational Methods in Engineering*, 2022, 29(5): 3001–3020. [doi: 10.1007/s11831-021-09684-6]
- 5 陈小刚, 李坤. 基于增强现实脑机接口和计算机视觉的机械臂控制系统. *生物医学工程学杂志*, 2021, 38(3): 483–

491. [doi: [10.7507/1001-5515.202011039](https://doi.org/10.7507/1001-5515.202011039)]
- 6 吴浩镇, 徐家骏, 曹芳淇, 等. 基于稳态视觉刺激的脑控机械臂系统设计. 智能城市, 2022, 8(9): 8–10.
- 7 Hayta Ü, Irimia DC, Guger C, *et al.* Optimizing motor imagery parameters for robotic arm control by brain-computer interface. *Brain Sciences*, 2022, 12(7): 833. [doi: [10.3390/brainsci12070833](https://doi.org/10.3390/brainsci12070833)]
- 8 Allison BZ, Dunne S, Leeb R, *et al.* *Towards Practical Brain-computer Interfaces: Bridging the Gap from Research to Real-world Applications*. New York: Springer, 2012.
- 9 邓欣, 肖立峰, 杨鹏飞, 等. 融合运动想象脑电与眼电信号的机械臂控制系统开发. 智能系统学报, 2022: 1–11. [doi: [10.11992/tis.202107042](https://doi.org/10.11992/tis.202107042)]
- 10 曲思霖, 王从庆, 李建亮, 等. 基于小波变换共空间模式的脑电信号解码. 郑州大学学报(工学版), 2022, 43(3): 31–36. [doi: [10.13705/j.issn.1671-6833.2021.06.003](https://doi.org/10.13705/j.issn.1671-6833.2021.06.003)]
- 11 尹锐, 曹勇, 姜劲, 等. 基于运动想象脑机接口的外骨骼控制系统研究. 航天医学与医学工程, 2020, 33(3): 208–213. [doi: [10.16289/j.cnki.1002-0837.2020.03.004](https://doi.org/10.16289/j.cnki.1002-0837.2020.03.004)]
- 12 Ak A, Topuz V, Midi I. Motor imagery EEG signal classification using image processing technique over GoogLeNet deep learning algorithm for controlling the robot manipulator. *Biomedical Signal Processing and Control*, 2022, 72: 103295. [doi: [10.1016/j.bspc.2021.103295](https://doi.org/10.1016/j.bspc.2021.103295)]
- 13 Xu BG, Li WL, He XH, *et al.* Motor imagery based continuous teleoperation robot control with tactile feedback. *Electronics*, 2020, 9(1): 174. [doi: [10.3390/electronics9010174](https://doi.org/10.3390/electronics9010174)]
- 14 胡勤伟, 陶庆, 王妮妮, 等. 用于稳态视觉诱发电位目标识别的多尺度特征融合卷积神经网络方法. 西安交通大学学报, 2022, 56(4): 185–193, 202. [doi: [10.7652/xjtuxb202204020](https://doi.org/10.7652/xjtuxb202204020)]
- 15 Lakshmi MR, Prasad TV, Prakash VC. Survey on EEG signal processing methods. *International Journal of Advanced Research in Computer Science Software Engineering*, 2014, 4(1): 84–91.
- 16 Sanei S, Chambers JA. *EEG Signal Processing*. Chichester: John Wiley, 2007.
- 17 王萌亚, 王仲朋, 陈龙, 等. 卒中后运动神经反馈康复训练研究进展与前景. 中国生物医学工程学报, 2019, 38(6): 742–752. [doi: [10.3969/j.issn.0258-8021.2019.06.013](https://doi.org/10.3969/j.issn.0258-8021.2019.06.013)]
- 18 Desai J. *Electroencephalography (EEG) data collection and processing through machine learning* [Master's Thesis]. Fayetteville: University of Arkansas, 2014.
- 19 周高豪. 操作员多通道生理数据融合疲劳建模与分析 [硕士学位论文]. 西安: 西安工业大学, 2022.
- 20 Xie Y, Oniga S. A review of processing methods and classification algorithm for EEG signal. *Carpathian Journal of Electronic and Computer Engineering*, 2020, 13(1): 23–29. [doi: [10.2478/cjece-2020-0004](https://doi.org/10.2478/cjece-2020-0004)]
- 21 Altaheri H, Muhammad G, Alsulaiman M, *et al.* Deep learning techniques for classification of electroencephalogram (EEG) motor imagery (MI) signals: A review. *Neural Computing and Applications*, 2021: 1–42.
- 22 Ko W, Jeon E, Jeong S, *et al.* Multi-scale neural network for EEG representation learning in BCI. *IEEE Computational Intelligence Magazine*, 2021, 16(2): 31–45. [doi: [10.1109/MCI.2021.3061875](https://doi.org/10.1109/MCI.2021.3061875)]
- 23 Wang H, Zhu XS, Chen PY, *et al.* A gradient-based automatic optimization CNN framework for EEG state recognition. *Journal of Neural Engineering*, 2022, 19(1): 016009. [doi: [10.1088/1741-2552/ac41ac](https://doi.org/10.1088/1741-2552/ac41ac)]

(校对责编: 牛欣悦)