

# 基于 SSVEP 的空间机械臂脑机交互方法

钱一润<sup>1,2</sup>, 王从庆<sup>1,2</sup>, 张闻锐<sup>1,2</sup>, 展文豪<sup>2</sup>, 张民<sup>1</sup>

(1. 南京航空航天大学 自动化学院, 南京 210016;

2. 中国航天员科研训练中心 人因工程国防科技重点实验室, 北京 100094)

**摘要:** 为实现航天员与空间机械臂的脑机交互, 针对稳态视觉诱发电位脑机接口 (SSVEP-BCI), 提出一种基于卷积神经网络的 SSVEP 信号分类方法; 该方法以 SSVEP 信号经过快速傅立叶变换的特征为输入, 经过三层卷积层、全连接等操作实现信号的分类识别; 采用清华大学 Benchmark 数据集对该方法进行测试, 在 1 秒的时间窗口下, 平均分类准确率为 99.07%, 平均信息传输率为 149.24 b/min, 均明显高于采用典型相关分析或滤波器组典型相关分析的方法; 实验对比分析表明, 该方法针对短时间窗口的 SSVEP 信号具有较好的目标分类效果; 最后, 使用分类后的信号作为控制信号, 对仿真环境下的空间机械臂进行操作, 实现人和空间机械臂的脑机交互。

**关键词:** 稳态视觉诱发电位; 脑机接口; 信号分类; 卷积神经网络; 空间机械臂

## A Brain Computer Interaction Method of Space Manipulators Based on SSVEP

QIAN Yirun<sup>1,2</sup>, WANG Congqing<sup>1,2</sup>, ZHANG Wenrui<sup>1,2</sup>, ZHAN Wenhao<sup>2</sup>, ZHANG Min<sup>1</sup>

(1. School of Automation, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China;

2. National Key Laboratory of Human Factors Engineering China Astronauts Research and Training Center, Beijing 100094, China)

**Abstract:** In order to realize the brain computer interaction between astronauts and space manipulators, aiming at the steady-state visual evoked potential brain-computer interface (SSVEP-BCI), the SSVEP signals classification method based on convolutional neural network is proposed. This method takes the characteristics of the SSVEP signals after fast Fourier transform as the input signal, and realizes the classification and recognition of the SSVEP signals through three-layer convolution and full connection. The benchmark data set of Tsinghua University is used to verify the method. Under the time window of 1 second, the accuracy of average classification is 99.07% and the rate of average information transmission is 149.24 b/min, which are significantly higher than that of using canonical correlation analysis or filter bank canonical correlation analysis. The comparison result shows that the proposed method has good target classification effect for the short-time SSVEP signals. Finally, the recognized signals are used as the control signals to operate the space manipulator in the simulation environment to realize the brain computer interaction between human and space manipulators.

**Keywords:** steady-state visual evoked potential; brain-computer interface; signal classification; convolutional neural network; space manipulator

## 0 引言

空间机械臂是空间站中用来完成目标搬运、在轨建设和辅助航天员出舱等任务的智能设备, 具有强大的应用能力和广阔的发展前景。空间机械臂可以由航天员遥控进行操作, 然而在失重的环境影响下, 航天员很难像在地面一样自如地操控空间机械臂。脑机接口 (BCI, brain-computer interface) 作为一种可以直接实现大脑与外界间信息传输的通道<sup>[1]</sup>, 可以通过脑机接口技术对大脑中的神经信号进行解码并传输给空间机械臂, 实现航天员与空间机械臂之

间的脑机交互控制。稳态视觉诱发电位 (SSVEP, steady-state visual evoked potential) 是一种受持续视觉刺激而产生的脑电信号<sup>[2]</sup>, 根据其原理而设计的 SSVEP 脑机接口凭借着频域特征明显、可选择的目标数多、信息传输速率快且受试者不需要经过训练等优势, 在对信息传输要求较高的场合已被广泛使用。

传统的 SSVEP 信号分析方法主要有功率谱密度分析<sup>[3]</sup> (PSDA, power spectral density analysis) 和典型相关分析 (CCA, canonical correlation analysis) 等。功率谱密度分析

收稿日期: 2021-12-02; 修回日期: 2021-12-28。

基金项目: 装备预研重点实验室基金项目 (6142222190310)。

作者简介: 钱一润 (1998-), 男, 江苏无锡人, 硕士, 主要从事模式识别与人工智能方向的研究。

王从庆 (1960-), 男, 江苏南京人, 教授, 博士生导师, 主要从事智能控制与人机交互方向的研究。

引用格式: 钱一润, 王从庆, 张闻锐, 等. 基于 SSVEP 的空间机械臂脑机交互方法[J]. 计算机测量与控制, 2022, 30(6): 197-202.

是一种单通道分析方法, 通过将脑电信号从时域转换到频域<sup>[4]</sup>, 比较信号的频率成分和相对强弱来对受试者关注的视觉刺激进行分类。作为目前主流的 SSVEP 分类方法, 典型相关分析及其改进方法被广泛应用, CCA 方法可以计算出两组多维变量之间的相关性<sup>[5]</sup>。Lin 等人<sup>[6]</sup>提出的 CCA 方法通过分析脑电信号与模板信号之间的相关关系来对 SSVEP 信号进行分类。作为一种多通道方法, CCA 具有高效性和鲁棒性, 已成为一种 SSVEP 信号分类的经典方法。陈小刚等人<sup>[7]</sup>在 CCA 的基础上有效地利用了信号中的谐波成分, 提出了改进方法滤波器组典型相关分析 (FBCCA, filterbank canonical correlation analysis), 进一步提高了信号的分类准确率。近年来, 深度学习已经在很多领域成为了一种热门方法。引入深度学习来对 SSVEP 信号进行分类, 相比于传统方法, 深度学习在学习数据特征方面有着天然的优势, 卷积神经网络<sup>[8]</sup> (CNN, convolutional neural network) 是最常使用的算法之一。杜光景等人<sup>[9]</sup>使用了一个 7 层的 CNN 网络对原始的多通道 SSVEP 信号进行分类, 在针对短时间的 SSVEP 信号时, 有效地提高了信号的分类准确率和鲁棒性。A. Ravi 等人<sup>[10]</sup>先将 SSVEP 信号转换到频域提取特征, 再输入到 CNN 网络, 可以有效地降低模型的计算复杂度。

在空间机械臂脑机交互系统中, 为保证实际应用中的信息传输效率, 有必要在短时间内实现对 SSVEP 信号的正确分类, 因此本文针对 1 s 时间窗口的 6 类信号分类问题, 提出了一种基于卷积神经网络的 SSVEP 分类方法, 并与传统的 CCA 和 FBCCA 方法进行比较, 本文方法的平均识别准确率最高。采用本文方法解码 6 类 SSVEP 信号, 并控制仿真环境下的空间机械臂进行操作。

## 1 SSVEP 信号处理与分类

### 1.1 SSVEP 信号原理

SSVEP 信号由视觉刺激产生<sup>[11]</sup>, 当人眼受到外界一个持续性的闪烁刺激时 (刺激频率一般高于 6 Hz), 大脑枕叶区的视觉皮层会产生相应的信号, 该信号的频率与闪烁刺激的频率及其谐波频率相同。SSVEP 脑机接口正是根据这个原理设计的。如图 1 所示, 当受试者注视一个频率为 10 Hz 的周期性持续刺激时, 从 SSVEP 信号的频谱图上可明显看出在 10 Hz、20 Hz 和 30 Hz 处出现波峰, 波峰的幅值随着频率的增大呈递减趋势。

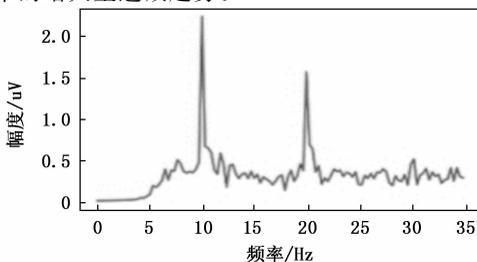


图 1 10 Hz 频率诱发的 SSVEP 频谱图

### 1.2 数据集介绍及预处理

本文所使用的数据来自清华大学的 Benchmark 数据集<sup>[12]</sup>, 该数据集共采集了 35 名健康的受试者 (记为 S01-S35), 其中女性有 17 名, 男性有 18 名。在所有受试者中, 受试者 S01-S08 有过 SSVEP 数据的采集经验, 受试者 S09-S35 则没有。该数据集使用 64 通道的脑电仪对 40 个目标进行了 6 次实验, 每次实验采集到的有效时间为 5 s。经处理后, SSVEP 信号的采样频率为 250 Hz, 并且通过 50 Hz 的陷波滤波器去除工频干扰。选择 8 Hz, 9 Hz, 10 Hz, 11 Hz, 12 Hz 和 13 Hz 这 6 个频率作为 6 分类的刺激频率。基于经验知识, 选择该数据集中位于大脑枕叶区的 Pz, PO5, PO3, POz, PO4, PO6, O1, Oz 和 O2 这 9 个通道的数据。并使用巴特沃斯带通滤波器对选用的 SSVEP 信号进行滤波。

### 1.3 构建卷积神经网络

#### 1.3.1 特征提取

特征提取是从原始信号中提取出对分类最有效可靠的特征, 进行特征提取可以有效降低数据的维度, 并且能够在后续处理使用时简化卷积神经网络的计算复杂度。对于脑电信号, 通常采用傅里叶变换、小波变换法等方法提取信号的频域或时频域特征<sup>[13]</sup>。

在本文中, 选择先对 SSVEP 信号进行特征提取, 再把提取的特征输入到 CNN 进行分类。SSVEP 信号频域特征明显, 快速傅里叶变换 (FFT, fast Fourier transform) 可以将信号转换到频域<sup>[14]</sup>。对原始的 SSVEP 信号使用快速傅里叶变换可以得到一组复数序列, 其中实部代表信号的幅度信息, 虚部代表信号的相位信息。研究表明, 信号的相位信息在解码 SSVEP 时提供重要信息<sup>[15]</sup>, 因此将快速傅里叶变换的实部和虚部结合起来作为 CNN 的输入。对每个通道使用分辨率为 0.293 0 Hz 的标准快速傅里叶变换, 选择 4~40 Hz 之间的频率分量, 把计算出的 FFT 实部和虚部组合成一个新的特征。

再将这些特征按通道顺序进行堆叠, 得到最终的特征矩阵。

#### 1.3.2 卷积神经网络

卷积神经网络的研究开始于 20 世纪 80 至 90 年代, 经过多年的完善发展, 目前已经是深度学习领域中最常用的神经网络之一, 在图像处理<sup>[16]</sup>、信号分类<sup>[17]</sup>和目标检测<sup>[18]</sup>等方面都发挥了重要的作用。一个常见的 CNN 架构包括输入层、隐藏层和输出层这几部分。在隐藏层中, 又有卷积层、全连接层等常见的架构。利用 CNN 进行信号分类时, 网络的输入通常是原始时域信号或信号的特征矩阵, 通过卷积层对输入的数据加以学习, 并由输出层输出分类标签。

在本文中, 设计了一个 5 层的 CNN 网络, 分别是一个输入层, 3 个卷积层和一个全连接的输出层。总体的网络结构如图 3 所示, 每一层的网络具体如下:

1) 输入层  $I_1$ 。第一层为整个网络的输入层, 将前一步

特征提取中得到的特征矩阵作为整个网络的输入在特征提取中, 我们对每一个通道都提取了特征, 整个特征矩阵的维度即为通道数 $\times$ 特征数量。在图 2 中, 输入的特征矩阵大小为  $9 \times 248$ , 表示一共有 9 个通道的输入数据, 每个通道中有 248 个特征数量。

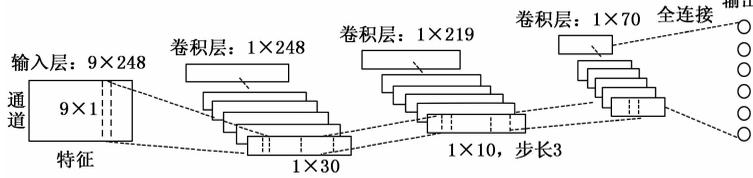


图 2 卷积神经网络总体结构图

2) 卷积层  $l_2$ 。卷积层  $l_2$  层执行整个网络中的第一次卷积操作, 为学习每个通道的不同作用, 参考空域滤波器的设计, 在这一层中, 利用步长为 1, 维度为  $9 \times 1$  的一维卷积核对输入数据进行卷积。  $l_2$  层一共输出 18 个大小为  $1 \times 248$  的一维特征图。

3) 卷积层  $l_3$ 。第三层是对每张特征图中的频谱特征进行学习, 利用步长为 1, 维度为  $1 \times 30$  的卷积核进行卷积。在这一层中只进行有效的卷积, 即不对边界数据进行处理, 最后输出的特征图数量不变, 大小则变为  $1 \times 219$ 。

4) 卷积层  $l_4$ 。卷积层  $l_4$  是在卷积层  $l_3$  的基础上对频谱特征再做一次卷积, 采用步长为 3, 维度为  $1 \times 10$  的卷积核进行卷积, 同样不对边界数据进行处理, 共输出 18 个特征图, 每个特征图的大小减小为  $1 \times 70$ 。为方便将这一层得到的数据传递给输出层, 在卷积结束后对所有数据进行扁平化处理。

5) 输出层  $l_5$ 。输出层由 6 个节点组成, 代表原始 SSVEP 数据中的 6 个刺激频率。将卷积层  $l_4$  和输出层  $l_5$  进行全连接, 选择使用 softmax 函数作为输出层的激活函数。

在卷积神经网络的每一层卷积后, 选择线性整流函数 (ReLU) 作为卷积层的激活函数, 并且不设置偏置值。研究表明, 批归一化可以使特征服从均值为 0, 方差为 1 的分布, 从而使得网络中的数据分布相对稳定, 可以简化调参过程, 并起到了一定的正则化效果。为了提高网络的泛化能力, 加快模型的学习训练速度<sup>[19]</sup>, 对卷积层  $l_2$ ,  $l_3$  和  $l_4$  层的输出均使用批归一化处理。同时, 使用权值衰减和随机删除部分神经元的方法可以有效防止训练过程中出现过拟合现象, 因此在每一层卷积中引入了 L2 正则化和 dropout 方法<sup>[20]</sup>。

CNN 训练时, 使用误差反向传播法训练网络。以均值为 0, 标准差为 1 的高斯分布作为 CNN 的权重初始值。训练过程中, 利用小批量训练进行学习, 每次输入 32 个数据段, 总共迭代 50 次。损失函数选择使用交叉熵损失函数, 采用 SGDM 算法进行权值优化, 设置学习率为 0.001, 动量为 0.9。为防止过拟合, 设置正则化项 L2 为 0.000 1,

dropout 比率为 0.2。

### 1.4 典型相关分析

CCA 方法可以计算出两组数据之间的相关程度。其基本原理是分别从两组数据中提取一对综合变量, 计算这组变量对之间的相关关系, 我们可以得到一个数值, 即为这两组变量对之间的相关系数。显然, 在这两组数据中我们可以提取出很多对综合变量。其中, 相关系数最大的一组变量对被称为这两组数据的一对典型变量, 相关系数越大, 代表这组变量对之间的相关关系就越强, 说明两组数据之间的关联性也越强。因此, 在分析两组数据之间的整体关系时, 可以根据这两个指标来判断。

使用 CCA 方法进行 SSVEP 分类时, 我们通常只关注 SSVEP 信号与模板信号之间最大的相关系数, 因此通过计算两者之间的典型相关系数就可以确定刺激频率。研究表明, CCA 在区分 SSVEP 信号时具有优异的性能<sup>[21]</sup>。定义两组变量  $X$  和  $Y_i$ ,  $X$  为采集到的 SSVEP 信号, 表示为:

$$X = (X_1, X_2, \dots, X_n) \quad (1)$$

式中,  $n$  表示采集的 SSVEP 信号通道数。  $Y_i$  为根据视觉刺激频率创建的模板信号。表示为:

$$Y_i = \begin{pmatrix} \sin(2\pi f_i t) \\ \cos(2\pi f_i t) \\ \vdots \\ \sin(2\pi k f_i t) \\ \cos(2\pi k f_i t) \end{pmatrix}, t = \frac{1}{F_s}, \frac{2}{F_s}, \dots, \frac{N_s}{F_s} \quad (2)$$

式中,  $i$  表示某类视觉刺激目标,  $f_i$  表示该类刺激的频率,  $k$  表示模板信号中的谐波个数,  $N_s$  表示 SSVEP 信号中的采样点个数。对于变量  $X$  和  $Y_i$ , 可以表示成  $x = X^T u$ ,  $y_i = Y_i^T v$ , 其中,  $u$  和  $v$  分别表示  $X$  和  $Y_i$  的系数矩阵, 可计算新变量  $x$  和  $y_i$  的皮尔森相关系数:

$$\rho(x, y_i) = \frac{\epsilon(x^T y_i)}{\sqrt{\epsilon(x^T x) \epsilon(y_i^T y_i)}} \quad (3)$$

按上述步骤计算待检测的 SSVEP 信号与各模板信号之间的皮尔森相关系数, 确定目标频率:

$$f_i = \max \rho(x, y_i), i = 1, 2, \dots, M \quad (4)$$

式中,  $M$  为视觉刺激的个数。

### 1.5 滤波器组典型相关分析

FBCCA 是对 CCA 方法的一种改进<sup>[22]</sup>, 相比于 CCA, FBCCA 方法有效地利用了信号中的谐波成分。根据 CCA 的原理, 在进行 SSVEP 信号分类时, 更关注 SSVEP 信号与模板信号之间的相关关系, 而忽略了 SSVEP 内部的谐波信息。从 SSVEP 的频谱图中可以很清楚地看出, 信号中的谐波成分, 尤其是二次谐波成分非常明显, 因此可以通过这些谐波成分为 SSVEP 分类提供重要的参考信息。

在进行分类前, 先使用滤波器组将 SSVEP 信号分成多个子带, 对每个子带和模板信号进行 CCA 处理, 计算出对

应的相关系数。最后，将每个子带得到的相关系数进行加权平方和后求得最终的相关系数：

$$p_i = \sum_{j=1}^l \omega(j) p_j^2, i = 1, 2, \dots, M \quad (5)$$

式中， $i$  表示某类视觉刺激目标， $j$  表示子带的索引， $l$  为子带总个数， $M$  为视觉刺激的个数， $\omega(j)$  为子带分量对应的权重因子，可以表示为：

$$\omega(j) = j^{-a} + b, j \in [1, j] \quad (6)$$

式中， $a$  和  $b$  为常数参数，根据经验，通常设置参数  $a$  为 1.25，参数  $b$  为 0.25。最终确定目标频率为：

$$f_i = \max(p_i), i = 1, 2, \dots, M \quad (7)$$

## 2 实验分析

将卷积神经网络方法在数据集上的进行测试，由于卷积神经网络需要比较大的数据量，而数据集中的 SSVEP 信号较少，因此采用数据分割的方式增加数据量<sup>[23]</sup>。将每个 5 秒的数据用宽度为 1 s，步长为 200 ms 的滑动窗口进行分割，这样单次试验将能获得 21 个分段数据，每人每个频率目标一共有 126 个分段数据，可满足卷积神经网络的数据需求。

使用卷积神经网络方法进行训练时，将单个受试者的数据按比例划分为训练集和测试集。为得到较好的效果，对每个受试者的数据进行 10 倍交叉验证，即将数据划分为 10 份，分别选择其中 9 份数据作为训练数据，剩余的 1 份数据作为测试数据。每次试验都会得到一个分类准确率，将 10 次试验得到的准确率的平均值作为最终的分分类准确率。同时使用 CCA 和 FBCCA 的方法在该数据集上进行测试，将 3 种方法得到的分类准确率进行比较，对比的结果如表 1 所示。

实验表明，对 35 名受试者使用本文提出的卷积神经网络方法，平均分类准确率为 99.07%，明显高于 CCA 方法 (41.67%) 和 FBCCA 方法 (85.79%)。其中最高的分类准确率为 100% (S3, S5, S10, S12, S13, S14, S22, S25, S26, S31, S32)，共 11 人，占总数的 31.43%；最低分类准确率为 94.18% (S33)。考虑到数据集中受试者 S1-S8 有过采集 SSVEP 数据的经验，而受试者 S09-S35 则没有，因此对其分别进行讨论。对于有过经验的受试者 S1-S8，他们的分类准确率都在 99% 以上，平均分类准确率达到 99.64%，说明对于有经验的受试者，本文给出的方法可以出色的完成短时间窗口下的 SSVEP 信号分类问题，且具有较高的鲁棒性。受试者 S09-S35 没有采集经验，他们的平均分类准确率为 98.90%。在的 27 名受试者中，共有 5 人的分类准确率低于 98% (S11, S18, S19, S29, S33)，占没有采集经验人数的 18.52%，只有两人的分类准确率没有达到 95% (S19: 94.71%，S33: 94.18%)，且相差并不大，说明即使是没有经验的受试者，采用本文方法依然可以保持较高的分类准确率。

除了识别准确率，还可以通过信息传输率 (ITR, in-

formation translate rate) 来评价 SSVEP 脑机接口的性能<sup>[24]</sup>，ITR 表示在一分钟内所能够传输的信息量大小，ITR 越大，说明该方法下信息传输率越快。在 SSVEP 脑机接口中有 3 个重要的参数指标，分别是待分类的刺激频率数、信号的分类准确率和单次刺激所持续的时间。信息传输率将这 3 个指标结合起来：

表 1 1 s 时间窗口下分类准确率对比

被试者	分类准确率/ %		
	CNN	CCA	FBCCA
S1	99.74	36.11	88.89
S2	99.61	30.56	86.11
S3	100	69.44	100
S4	99.34	55.56	94.44
S5	100	50.00	97.22
S6	99.87	55.56	94.44
S7	99.47	30.56	69.44
S8	99.07	25.00	61.11
S9	99.07	50.00	80.56
S10	100	36.11	94.44
S11	95.37	16.67	55.56
S12	100	66.67	100
S13	100	30.56	97.22
S14	100	47.22	94.44
S15	99.87	44.44	97.22
S16	98.81	25.00	72.22
S17	99.74	38.89	63.89
S18	95.76	22.22	80.56
S19	94.71	25.00	38.89
S20	98.82	25.00	91.67
S21	99.87	33.33	75.00
S22	100	55.56	100
S23	98.41	47.22	89.89
S24	99.87	38.89	97.22
S25	100	50.00	100
S26	100	47.22	100
S27	99.87	61.11	88.89
S28	99.73	41.67	88.89
S29	97.89	27.78	77.78
S30	99.34	47.22	86.11
S31	100	50.00	100
S32	100	58.33	94.44
S33	94.18	22.22	69.44
S34	99.74	55.56	100
S35	99.21	41.67	77.78
平均值	99.07	41.67	85.79

$$B = \left[ \log_2 N + P \log_2 p + (1 - P) \log_2 \frac{1 - P}{N - 1} \right] \quad (8)$$

$$ITR = \frac{60}{T} \times B \quad (9)$$

式中， $B$  表示一次刺激所传输的信息量， $T$  表示进行一次刺激所持续的时间， $N$  表示所要分类的刺激频率数量， $P$

表示分类准确率。在本文中, 共有 6 个待分类的刺激频率, 选用 35 名受试者的平均识别率作为信号的分类准确率, 设定单次刺激所持续的时间为理论时间 1 秒。通过上述公式, 计算出采用卷积神经网络方法时的信息传输率为 149.24 b/min, 已经达到了一个很高的传输速率。相比于 CCA 方法 (15.04 b/min) 和 FBCCA 方法 (99.92 b/min), 采用 CNN 方法下的信息传输率得到了巨大的提升。总体而言, 在针对短时间窗口的 SSVEP 信号时, 本文提出的方法比传统 CCA 和 FBCCA 方法在分类准确率和信息传输率上都有了很大的提升, 可以有效提高 SSVEP 脑机接口的分类性能。

### 3 空间机械臂的脑机交互控制

本文所使用的仿真实空间机械臂在 VS2017 平台上进行运行。首先在 3D Studio MAX 中绘制空间机械臂的模型, 然后使用 OpenGL 在 VS2017 平台上对空间机械臂进行重构。6 类 SSVEP 信号的分类识别在 Jupyter Notebook 中完成, 与空间机械臂仿真环境之间采用 TCP/IP 协议进行信息传输。将使用卷积神经网络方法分类后的结果作为控制信号, 控制仿真环境下的空间机械臂运动, 仿真实验方案如图 3 所示。

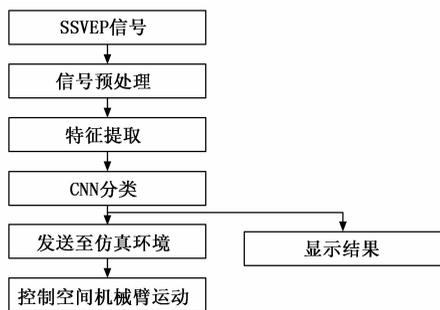


图 3 仿真实验方案流程图

仿真环境中的空间机械臂安装在空间站上, 由基座、大臂、中臂、小臂和末端手爪等部分组成, 其初始示意图见图 4。

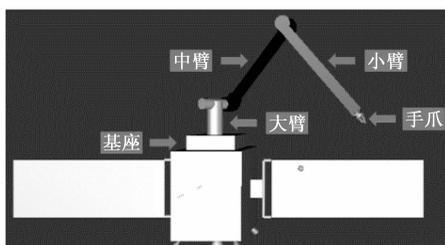


图 4 空间机械臂初始示意

操作者利用 SSVEP 信号解码指令控制空间机械臂, 各刺激频率与控制指令和空间机械臂动作的对应关系如表 2 所示。

进行仿真实验时, 空间机械臂转动示意图见图 5。

实验过程中, 当检测到受试者注视的刺激频率为 8 Hz

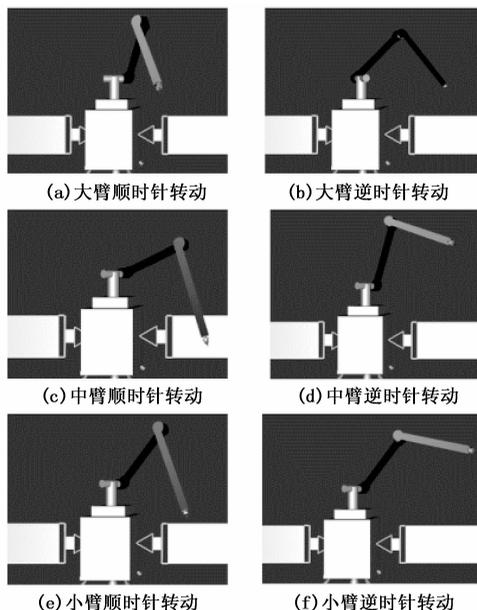


图 5 空间机械臂转动示意图

表 2 刺激目标对应控制指令及机械臂动作

刺激频率/Hz	控制指令	空间机械臂动作
8	000 001	大臂顺时针转动
9	000 010	大臂逆时针转动
10	000 100	中臂顺时针转动
11	001 000	中臂逆时针转动
12	010 000	小臂顺时针转动
13	100 000	小臂逆时针转动

时, 控制空间机械臂大臂顺时针转动; 检测到注视的刺激频率为 9 Hz 时, 控制空间机械臂大臂逆时针转动; 检测到注视的刺激频率为 10 Hz 时, 控制空间机械臂中臂顺时针转动; 检测到注视的刺激频率为 11 Hz 时, 控制空间机械臂中臂逆时针转动; 检测到注视的刺激频率为 12 Hz 时, 控制空间机械臂小臂顺时针转动; 检测到注视的刺激频率为 13 Hz 时, 控制空间机械臂小臂逆时针转动。

### 4 结束语

根据实际脑机交互场景中高信息传输率的要求, 本文针对短时间窗口下的 SSVEP 信号分类问题, 提出了一种基于卷积神经网络的方法。该方法通过快速傅里叶变换提取各通道的频谱特征并组成特征矩阵, 使用卷积神经网络对其进行分类。由于在应用卷积神经网络之前进行了特征提取, 本文提出的深度学习网络架构相比于直接对原始 SSVEP 信号进行深度学习要简单很多。在清华大学的 Benchmark 数据集上将本文方法与典型相关分析方法和滤波器组典型相关分析方法进行比较, 对比结果表明, 该方法的目标识别准确率和信息传输率要明显高于另外两种方法。在 1 秒的时间窗口下, 平均识别准确率达到了 99.07%, 平均信息传输率为 149.24 b/min。即使对于没有 SSVEP 信号采集

经验的受试者,应用本文方法的平均识别准确率也达到了 98.90%,表示该方法可以有效地对短时间窗口的信号进行分类。最后,采用分类后的 SSVEP 信号作为控制信号,控制仿真环境中空间机械臂的大、中、小臂运动,验证了本方法是一种可靠的脑机交互方法。

和其他脑电信号相同,SSVEP 信号也存在个体差异性、识别准确率会随着分类目标的增多而下降等缺点,如何使用迁移学习的方法提高模型在不同受试者之间的泛化能力;同时当面对目标更多的分类问题时,保证识别准确率是我们后续研究的重点。

#### 参考文献:

[1] VIDAL J J. Toward direct brain-computer communication [J]. Annual Review of Biophysics and Bioengineering, 1973, 2 (1): 157-180.

[2] 刘亚东,周宗潭,胡德文. 脑机交互系统技术 [M]. 北京: 科学出版社, 2007.

[3] 程佩清. 数字信号处理第三版 [M]. 北京: 清华大学出版社, 2019.

[4] CASTILLO J, MULLER S, CAICEDO E, et al. Feature extraction techniques based on power spectrum for a SSVEP-BCI [C] //IEEE International Symposium on Industrial Electronics, 2014: 284-288.

[5] MUIRHEAD R J, ANDERSON T W. An introduction to multivariate statistical analysis [M]. New York: Wiley, 1986.

[6] LIN Z, ZHANG C, WU W, et al. Frequency recognition based on canonical correlation analysis for SSVEP-Based BCIs [J]. IEEE Transactions on Biomedical Engineering, 2006, 53 (12): 2610-2614.

[7] CHEN X, WANG Y, GAO S, et al. Filter bank canonical correlation analysis for implementing a high-speed SSVEP-based brain-computer interface [J]. Journal of Neural Engineering, 2015, 12 (4): 046008.1-046008.14.

[8] 周飞燕,金林鹏,董军. 卷积神经网络研究综述 [J]. 计算机学报, 2017, 40 (6): 1229-1251.

[9] 杜光景,谢俊,张玉彬. 用于稳态视觉诱发电位脑机接口目标识别的深度学习的方法 [J]. 西安交通大学学报, 2019, 53 (11): 42-48.

[10] RAVI A, BENI N H, MANUEL J, et al. Comparing user-dependent and user-independent training of CNN for SSVEP BCI [J]. Journal of Neural Engineering, 2020, 17 (2): 026028.1-026028.13.

[11] XU W, XU Y, CHANG T, et al. Co-scale conv-attentional image transformers [C] //IEEE International Conference on Computer Vision (ICCV), 2021: 1537-1548.

[12] BELLO I. Lambda networks: modeling long-range interactions without attention [C] //International Conference on Learning Representations (ICLR), 2021: 1-31.

[13] DAI Z, LIU H X, LE Q, et al. CoAtNet: marrying convolu-

[11] BEVERINA F, PALMAS G, SILVONI S, et al. User adaptive BCIs: SSVEP and P300 based interfaces [J]. Psychology Journal, 2003, 1 (4): 331-354.

[12] WANG Y, CHEN X, GAO X, et al. A benchmark dataset for SSVEP-based brain-computer interfaces [J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2017, 10 (25): 1746-1752.

[13] 雍颖琼,张宏江,程奇峰,等. 混合脑机接口及其研究进展 [J]. 计算机测量与控制, 2020, 28 (9): 9-13, 28.

[14] 赵丽,邢潇,刘泽华. 基于 DSP 和 ARM 的便携式脑电信号处理系统的实现 [J]. 计算机测量与控制, 2014, 22 (9): 2981-2982, 2986.

[15] PAN J, GAO X, DUAN F, et al. Enhancing the classification accuracy of steady-state visual evoked potential-based brain-computer interfaces using phase constrained canonical correlation analysis [J]. Journal of Neural Engineering, 2011, 8 (3): 036027.

[16] 杨真真,匡楠,范露,等. 基于卷积神经网络的图像分类算法综述 [J]. 信号处理, 2018, 34 (12): 1474-1489.

[17] 方成,薛质. 基于全双谱和卷积神经网络的信号分类方法 [J]. 计算机应用研究, 2018, 35 (12): 3766-3769.

[18] 范丽丽,赵宏伟,赵浩宇,等. 基于深度卷积神经网络的目标检测研究综述 [J]. 光学精密工程, 2020, 28 (5): 1152-1164.

[19] ZHANG X, et al. A convolutional neural network for the detection of asynchronous steady state motion visual evoked potential [J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2019, 6 (27): 1303-1311.

[20] SRIVASTAVA N, HINTON G, KRIZHEVSKY A, et al. Dropout: a simple way to prevent neural networks from overfitting [J]. Journal of Machine Learning Research, 2014, 15 (1): 1929-1958.

[21] BIN G, GAO X, ZHENG Y, et al. An online multi-channel SSVEP-based brain-computer interface using a canonical correlation analysis method [J]. Journal of Neural Engineering, 2009, 6 (4): 046002.

[22] 陈小刚. 高稳态视觉诱发电位脑-机接口的关键技术研究 [D]. 北京: 清华大学, 2015.

[23] 汪旭震. 基于 CNN 的稳态视觉诱发脑电信号身份识别研究 [D]. 西安: 西安电子科技大学, 2020.

[24] 印二威. 诱发式脑-机接口的设计与优化 [D]. 长沙: 国防科学技术大学, 2015.

[25] ZHAO H, GALLO O, FROSIO I, et al. Loss functions for image restoration with neural networks [J]. IEEE Transactions on Computational Imaging, 2017, 3 (1): 47-57.

(上接第 196 页)