

目 录

摘要.....	I
Abstract.....	III
第一章 绪论.....	1
1.1 课题研究背景和意义.....	1
1.2 国内外研究现状.....	2
1.2.1 信号采集方法研究现状.....	2
1.2.2 信号预处理方法研究现状.....	3
1.2.3 特征提取方法研究现状.....	4
1.2.4 分类器设计方法研究现状.....	5
1.3 研究内容与结构安排.....	6
第二章 脑电信号多分类框架理论.....	9
2.1 脑电信号特征描述.....	9
2.1.1 脑电信号的产生.....	9
2.1.2 脑电信号的频率成分.....	10
2.1.3 相关同步和去同步.....	10
2.2 基于巴特沃斯带通滤波器的频带划分.....	12
2.3 公共空间模式 (CSP).....	13
2.4 深度学习模型基础理论介绍.....	14
2.4.1 损失函数.....	14
2.4.2 激活函数.....	15
2.4.3 优化器.....	16
2.5 本章小结.....	17
第三章 脑电运动想象信号实验分析.....	19
3.1 实验数据.....	19
3.1.1 BCI Competition IV Dataset IIA 数据集.....	19

3.1.2 BCI Competition IV Dataset IIB 数据集.....	20
3.2 数据的预处理.....	23
3.3 信号的分频处理分析.....	25
3.4 卷积神经网络.....	27
3.4.1 网络结构.....	27
3.4.2 卷积神经网络的训练方法.....	29
3.5 长短期记忆递归神经网络.....	29
3.6 多尺度 CNN-LSTM 结构.....	30
3.7 训练环境设置.....	33
3.8 评价标准.....	33
3.9 本章小结.....	34
第四章 实验结果与分析.....	35
4.1 BCI Competition IV Dataset IIA 结果分析.....	35
4.2 BCI Competition IV Dataset IIB 结果分析.....	37
4.3 自建数据集结果分析.....	38
4.4 特征频带选择分析.....	38
4.5 消融实验.....	40
4.6 模型实时性与可移植性分析.....	41
4.7 本章小结.....	42
第五章 总结与展望.....	43
5.1 总结.....	43
5.2 展望.....	43
参考文献.....	45
致谢.....	55

摘要

脑机接口（Brain-Computer Interface, BCI）是一门涉及神经科学、工程学和计算机科学的交叉学科，它为活跃的大脑与其他外部设备的交互提供了一种不涉及正常神经或肌肉的控制和通信手段。BCI 技术具有深远的意义和广泛的应用前景，它不仅打破了传统的人机交互界限，为人类带来了更加便捷、高效和个性化的交互体验。同时，它在医疗、教育、娱乐和军事等领域的广泛应用以及推动相关学科的发展等方面也取得了显著的成就。在 BCI 系统中，运动想象（Motor Imagery, MI）被广泛应用于主动式 BCI 设计中，这种系统通过特定的信号采集设备实时采集个体进行 MI 时产生的脑电图（Electroencephalogram, EEG）。随后，利用 BCI 技术对采集到的信号进行预处理、特征提取和分类，以识别个体的运动意图。这些运动意图随后被转化为外部设备可以识别的控制命令，从而实现对外部设备的控制。BCI 技术中主要任务就是将采集到的脑电信号进行一系列的处理转化为外部设备能够识别的命令，但其在实际应用中仍面临一些挑战，如个体差异较大以及分类正确率有待提高等，不能满足实际应用的需求。

本文基于现有的 BCI 技术，对脑电信号的特点进行了分析，结合划分滤波器组的方法，提出了一种多尺度特征融合 CNN-LSTM 网络（MFFCL）。该架构可用于基于运动图像的多类脑电信号的特征提取和识别，与其他分类方法相比，具有较高的分类准确率和较快的处理速度。

在脑电信号的预处理使用中，大多数基于深度学习的 MI-EEG 算法不会对脑电信号进行划分或者划分为较宽的频带，而较宽的频带无法充分利用脑电信号中多个子频带的不同特征，导致脑电信号分类模型的性能较差。针对这一问题，本文参考了滤波器组公共空间模式(Filter Bank Common Spatial Pattern, FBCSP)对频带进行划分并分别处理的理论，提出了一种新的划分方式。实验的框架如下：

首先对输入的脑电信号进行独立成分分析以滤除其中多种伪迹信号和噪声干扰，然后对经过预处理的信号进行分频处理，频带的选择与滑动时间窗中的窗口滑动方式相似，最后获得数份带有不同信息的全新数据集。接下来，根据提出的框架设计出多尺度 CNN-LSTM 结构，网络中的全连接层融合所有特征信息，其多尺度主要体现在数据频率范

围的多尺度和不同尺度的级联结构上。本研究采用重叠滤波器组对脑电信号进行频带划分，并与级联的 CNN-LSTM 网络相结合，实现空间特征、时间特征和频率特征的融合。本文证明 MFCL 有效地分离了多频率分量中的判别特征，并准确地从 EEG 数据中提取了时间和空间特征。同时，该网络的小规模结构对小规模脑电数据具有很强的适应性，使其有可能应用于实时多类脑机接口系统。在脑电信号分类实验中，与其他网络结构相比，MFCL 在 IV-2a 和 IV-2b 上的平均准确率分别为 88.4% 和 88.7%，在自建数据集上的平均准确率为 82.2%，取得了最高的分类准确度。MFCL 是一种有效的端到端脑电解码模型，具有较高的分类精度，减少了参数使用和计算资源。这证明了它在 MI-BCI 研究中的特征提取和分类中的实用性。

关键词：脑机接口；运动想象；特征提取；深度学习

Abstract

Brain computer interface (BCI) is an interdisciplinary subject involving neuroscience, engineering and computer science. It provides a control and communication means that does not involve normal nerves or muscles for the interaction between the active brain and other external devices. BCI technology has far-reaching significance and broad application prospects. It not only breaks the traditional boundaries of human-computer interaction, but also brings more convenient, efficient and personalized interactive experience for human beings. At the same time, it has also made remarkable achievements in the wide application of medical treatment, education, entertainment, military and other fields and in promoting the development of related disciplines. In BCI system, motor imagery (MI) is widely used in the design of active BCI. This system uses specific signal acquisition equipment to collect the electroencephalogram (EEG) generated by individuals during MI in real time. Then, BCI technology is used to preprocess, extract features and classify the collected signals to identify the individual's motion intention. These motion intentions are then transformed into control commands that can be recognized by the external device, so as to realize the control of the external device. The main task of BCI technology is to convert the collected EEG signal into a series of commands that can be recognized by external devices, but it still faces some challenges in practical application, such as large individual differences and the accuracy of classification needs to be improved, which can not meet the needs of practical application.

Based on the existing BCI technology, this paper analyzes the characteristics of EEG signals, and proposes a multi-scale feature fusion CNN-LSTM network (MFFCL) combined with the method of dividing filter banks. This architecture can be used for feature extraction and recognition of multi class EEG signals based on moving images. Compared with other classification methods, it has higher classification accuracy and faster processing speed.

In the use of EEG preprocessing, most of the MI-EEG algorithms based on deep learning do not divide the EEG signal or divide it into wider frequency bands, and the wider frequency bands

can not make full use of the different characteristics of multiple sub-bands in the EEG signal, resulting in poor performance of the EEG classification model. To solve this problem, this paper refers to the theory that filter bank common spatial pattern (FBCSP) divides and processes the frequency bands separately, and proposes a new division method. The framework of the experiment is as follows:

Firstly, the input EEG signal is analyzed by independent component analysis to filter out a variety of artifact signals and noise interference, and then the preprocessed signal is processed by frequency division. The selection of frequency band is similar to the window sliding mode in sliding time window. Finally, several new data sets with different information are obtained. Next, a multi-scale CNN-LSTM structure is designed according to the proposed framework. The full connection layer in the network integrates all feature information. Its multi-scale is mainly reflected in the multi-scale of the data frequency range and the cascade structure of different scales. In this study, overlapping filter banks are used to divide the frequency band of EEG signals, and combined with cascaded CNN-LSTM network to realize the fusion of spatial characteristics, temporal characteristics and frequency characteristics. This paper proves that MFFCL can effectively separate the discriminant features in multi frequency components, and accurately extract the temporal and spatial features from EEG data. At the same time, the small-scale structure of the network has strong adaptability to small-scale EEG data, which makes it possible to be applied to real-time multi class brain computer interface system. In the EEG classification experiment, compared with other network structures, the average accuracy of MFFCL on IV-2a and IV-2b was 88.4% and 88.7%, respectively, and the average accuracy on self-built data set was 82.2%, which achieved the highest classification accuracy. MFFCL is an effective end-to-end brain electrolytic code model, which has high classification accuracy and reduces the use of parameters and computing resources. This proves its practicability in feature extraction and classification in MI-BCI research.

Key words: Brain computer interface; Motor imagery; Feature extraction; Deep learning

第一章 绪论

1.1 课题研究背景和意义

自 20 世纪 60 年代，研究人员已经开始探寻将脑电信号与其他外部设备进行通信的技术。如今，随着神经科学、工程学和计算机科学等学科领域的发展以及现代人类需求多样化的趋势，探寻人大脑高级认知综合研究的意向日趋增长，人们开始不断探索人脑在记忆、学习、思维等高级认知的理解，并与仿生、嵌入式等技术结合，构建了脑机接口（Brain-Computer Interface, BCI）^[1-3]。脑机接口是一门涉及神经科学、工程学和计算机科学的交叉学科，它为活跃的大脑与其他外部设备的交互提供了一种不涉及正常神经或肌肉的控制和通信手段^[4-7]。脑电图（Electroencephalogram, EEG）是脑机接口系统研究中常用的信号采集方法^[8]。其中，脑电图传感器能够记录使用者头皮下方神经元所释放的放电信号并传输到计算机上，然后，解码算法就可以将发电信号所携带的信息转换为计算机可以理解的指令，以驱动外部设备完成相关活动并实现自主控制。BCI 的应用前景十分广阔，在康复治疗领域中，BCI 可以促进患者神经重塑，即使在严重神经损伤后也是如此^[9]。在与一些外部辅助设备相辅助的前提下，BCI 在帮助中风、脊髓损伤和肌萎缩侧索硬化症（ALS）患者提高生活质量方面具有巨大潜力^[10]；在大众娱乐领域，BCI 可以与虚拟现实技术相结合，以实现实时准确的控制游戏中的角色来获得更加身临其境的游戏体验^[3, 11]；在军事领域中，BCI 可以帮助士兵更好地控制无人机、无人驾驶车辆、机器人等无人设备，来代替军队或特定职业的人执行各种危险任务^[12]。此外，它还能够提供士兵的实时反馈，有助于掌握战场状态并及时调整战略布局。在医疗领域中，针对 BCI 的研究有助于揭示认知过程和大脑活动之间的关联，促进了对神经系统功能和疾病的理解，为神经科学和认知科学等研究提供重要的方法和依据^[13]。尽管 BCI 的研究依旧处于早期阶段，但它在各个领域上具有广阔的潜力，并且能够推动我们对人类大脑的认知和理解。

运动想象(motor imagery, MI)作为脑机接口研究中经常使用的一种模式识别任务，此任务要求受试者想象自己正在进行某种特定的运动而无需外界条件刺激和明显的动作输出，这时大脑的感觉运动皮层就能产生特定的响应^[14]。这种技术不依赖于外部刺激，能够

直接根据人的运动意图进行控制，从而极大地提升了使用者的自主性。EEG 能够检测这些大脑产生的电信号在特定频带内的变化趋势，这些变化趋势周期性地与感觉、运动或认知任务相关，这构成了基于脑机接口中脑电信号分类的基础^[15]。MI-BCI 在康复医学领域具有显著意义。它可以通过激活部分休眠神经突触进行代偿，进而促进重建受损运动神经通路。结合想象任务的康复训练模式可以充分调动患者主动意图，有效改善康复治疗的效果。Lee 等人^[16]将 24 名患有慢性脑卒中的患者分为两组，两组均进行共 6 周的平板运动训练而运动想象训练组进行额外的运动想象训练，实验结果证明了运动想象训练提高了步态能力且适用于脑卒中患者。除此之外，MI-BCI 可以表达患者的自主运动意愿，通过想象运动激活大脑中负责产生实际运动的区域，进而促进受损神经的修复^[17]。这种基于脑机接口的神经反馈训练范式为这些患者提供了新的治疗途径^[18]。综上所述，本文的主要研究内容为探究 EEG 信号中的运动想象信号分类。

1.2 国内外研究现状

脑机接口是一种将大脑活动与外部设备进行直接通信的技术，旨在使个体能够通过大脑信号来操控计算机、外部设备或其他技术而不涉及传统的神经肌肉通路^[19]。在脑机接口系统的研究中，具体的方法主要包括信号采集、信号预处理、特征提取、分类器设计和控制接口等步骤，其结构图如图 1-1 所示。

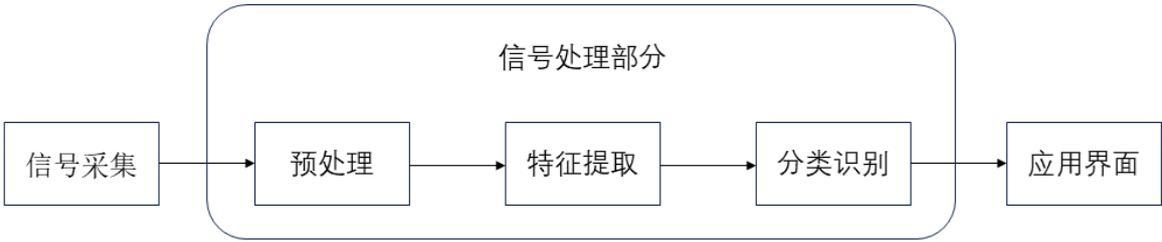


图 1-1 脑机接口系统完整框图

1.2.1 信号采集方法研究现状

信号采集部分是 BCI 系统的基础，它的主要作用是从大脑皮层采集脑电信号。这些脑电信号经过后续的处理和分析，可以转化为计算机能够识别的指令，从而实现对外部设备的控制。因此，信号采集的准确性和效率直接影响到 BCI 系统的性能和功能。常见的信号

采集方法包括脑电图。

脑电图的发展历程可以追溯到 19 世纪末，英国一位生理科学工作者首次在兔脑和猴脑上记录到了脑电活动，但这一发现当时并未引起广泛关注。随着生物学对神经冲动的生物电性质的发现，人们对大脑中电活动的理解逐渐加深。1912 年，乌克兰生理学家弗拉基米尔·弗拉基米罗维奇·普拉维奇内明斯基首次在狗身上检测到脑电波和诱发电位。诱发电位是一种通过给予神经系统某一部位适宜刺激，并在相应部位记录到的电位变化，这一技术的发现为脑电图学的研究提供了新的手段。随着技术的不断进步，脑电活动的研究得到了不断改进和发展。20 世纪 20 年代，德国神经科学家 Hans Berger^[20]带领团队发明了第一个真正意义上的脑电图仪器，这一仪器能够记录到更精细的脑电信号，极大地推动了脑电图学的发展。最初的脑电传感器是由金属电极制成的，用于接触头皮以捕捉大脑的电活动。随着时间的推移，这些传感器得到了改进，提高了舒适性和精确性。到了 20 世纪 30 年代，发展出了“国际 10-20 系统”，这是一种标准化的脑电电极布置方法，至今仍在广泛使用^[21]。这一方法使得脑电图记录更加标准化和可比较，推动了传感器布置和记录的标准化。

1.2.2 信号预处理方法研究现状

脑电信号本身非常微弱，并且容易受到肌体活动、电磁噪声、工频干扰以及眼电伪迹等的干扰。这些因素会显著降低脑电信号的质量，使得直接提取的特征信息不准确，从而影响后续的模式识别和分类任务。其次，预处理过程能够去除脑电信号中的非特征频段噪声干扰，改善脑电信号的质量，使得后续的特征提取和分类过程更加准确和可靠。

Jung 等人^[22]设计了一种独立分量分析（ICA）的方法，该方法可以有效地检测、分离和去除脑电图记录中各种人为来源的污染并且从脑电图中去除这些伪影，造成了广泛的影响。Ille 等人^[23]提出了一种基于空间滤波器的 EEG 伪迹去除方法，该方法利用伪迹和脑电信号的不同拓扑结构去除脑电信号中的干扰与伪影。Srinivasan 等人^[24]提出了一种将脑电信号以矩阵形式排列的有效预处理技术，该技术包括整数提升小波变换作为去相关器以及分层树中的集合划分作为源编码器，获得了更好的率失真性能编码延迟。An 等人^[25]设计了一种基于生成对抗性网络（GAN）的多通道脑电信号去噪方法，该模型多了一个鉴别器用于判断噪声是否被滤除，实现了去除噪声和干扰过程的自动化并显著缩短了所需时间。

Debnath 等人^[26]设计了一种能够在用户差异较大的情况下实现脑电数据兼容的自动预处理架构，取得了良好的效果。

1.2.3 特征提取方法研究现状

原始的脑电信号往往包含大量的数据点，直接处理这些数据不仅计算量大，而且可能导致过拟合等问题。通过特征提取，我们可以将原始信号转化为更简洁、更有代表性的特征向量，从而降低数据维度，提高计算效率。除此之外，脑电信号还是一种具有非线性、非平稳、信号幅值弱、信噪比低等特点的电信号，通过有效的特征提取可以提高脑电信号模式的识别准确率。脑电特征主要有三种类型：时域、频域和空域。

时域特征提取方法通常能够突出显示信号中的局部特征例如突发事件或周期性变化，这使得它们在检测和分析特定事件或模式方面具有优势。Acharya 等人^[27]详细讨论了包括均值、标准差、方差、偏度、峰度等特征提取方法以及不同自动癫痫分期检测技术，这些统计量可以反映脑电信号的总体特性。介丹等人^[28]提出了一种名为移动方差化的方法，该方法使用移动方差化对脑电信号进行序列重构以提取出样本熵和方差熵。

EEG 信号特征提取的频域方法主要关注信号的频率成分，通过将 EEG 信号分解为不同频率的成分并对这些成分的幅度、功率、相位等属性来提取特征。Kim 等人^[29]提出了一种能反映时间、频率和空间特征的有效特征提取方法 WDPSD，该方法能够计算 PSD 权重矩阵并提取出鲁棒性和自适应性特征，具有良好的分类准确性，但该方法忽略了脑电信号的时域信息，无法保持其时变特征。Yang 等人^[30]通过将短时傅立叶变换（STFT）应用于 EEG 信号，将原始 EEG 信号转换为表示时频特性的频谱图以获得更加具有区别性的特征，获得了较为理想的效果，但 STFT 时间窗的选择受限且频率分辨率高的特点会导致信息丢失。Issa 等人^[31]利用连续小波变换（CWT）提取出能够在时域和频域上描述脑电激活的灰度图像特征取得了更高的精度，但 CWT 方法需要仔细选择合适的基函数和尺度参数，这需要大量的先验知识，不利于大规模的推广。

EEG 信号特征提取的空域方法主要关注不同脑区之间的空间关系和信息传递，通过分析电极之间的相互作用和拓扑结构来揭示大脑的功能连接和协同工作模式。通过空域方法，可以观察到大脑在不同任务或状态下的网络动态变化。公共空间模式(CSP)是一种利用矩阵分解技术识别最优空间滤波器以获得深度判别特征向量的特征提取方法。Lotte 等人^[32]

提出了一个理论框架 RCSP 来实现对 CSP 的规范化以解决 CSP 对噪声非常敏感并且容易过拟合的问题，取得了更高的分类准确率。

尽管脑电信号特征提取的方法愈加完善，但单一域中提取的特征信息会导致有效判别特征的浪费，混合域提取应运而生。混合域特征提取能够融合来自不同域（如时域、频域、空域等）的信息，这种融合有助于更全面、深入地理解 EEG 信号，因为大脑的活动往往涉及多个层面和维度的交互。通过结合多个域的特征，混合域特征提取可以提取出更丰富、更具代表性的特征，从而增强对 EEG 信号的描述能力，这有助于提高后续分类、识别等任务的准确性。Samavat 等人^[33]设计了一种深度学习网络架构用于提取时间、频率和空间特征并与脑电频带的差分熵合并，获得了较高的分类准确度。

1.2.4 分类器设计方法研究现状

分类器通过将输入的 EEG 特征映射到特定的类别标签对提取的 EEG 信号特征进行分类，从而识别用户的意图或状态进而控制外部设备或与系统进行交互。分类器的准确性和效率直接影响到 BCI 系统的性能，因此选择合适的分类器并进行优化对于提高整个系统的可靠性、响应速度和用户体验至关重要。

贝叶斯神经网络是一种在模型参数的建模和预测中引入了贝叶斯推断的框架，Chai 等人^[34]使用贝叶斯神经网络作为分类器获得了最高的受试者工作曲线下面积。线性判别分析是一种在降低维度的同时最大化类别之间的差异，从而使得不同类别的样本在降低维度后能够更好地区分开来的监督学习算法，Gaur 等人^[35]使用线性判别分析用于每个时间窗口的分类获得更可靠的性能。支持向量机是一种分开不同类别的数据点来使两个类别之间的间隔最大化的监督学习模型，Liu 等人^[36]训练支持向量机用于人类情感识别，在 DEAP 数据集上获得了较高的识别准确率。但是在传统的机器学习分类框架中，特征提取和分类识别是相互独立的，这可能会导致有效特征信息的丢失。因此，有必要同步实现特征提取和分类识别。

随着近年来深度学习技术的不断完善和发展，端到端卷积神经网络(CNN)在自然语言处理和计算机视觉分类中得到了广泛的应用^[37]。深度学习的显著特点包括从数据中自动提取特征和减少特征损失，一些研究者将深度学习理论引入到脑电分类中^[38]。Amin 等人^[39]使用基于多层次特征融合的 CNN 网络从不同层提取特征。Dai 等人^[40]设计了一种混合尺度

的 CNN 架构，采用数据增强方法来解决受试者之间最优卷积尺度变化的问题。然而，与混合神经网络相比，单个 CNN 网络更容易受到脑电信号的非平稳性和非线性的影响。混合神经网络卷积核的特殊结构使得网络可能只捕获固定序列长度内的特征，因此它可能无法捕获较长的时间相关性。因此，将 CNN 与不同结构结合组成混合神经网络在脑电信号分类中似乎具有更大的潜力。Tao 等人^[41]提出了一种带有注意机制的卷积递归神经网络，可以提取更高的判别特征，提高识别准确率。Roy 等人^[42]设计了一种多尺度特征融合 CNN，能够在不重叠的范数频带中捕获可区分的特征。虽然这些方法是富有成效的，但它们捕获信号中时间相关性的能力较弱，这对于时变信号来说是不令人满意的。长短期记忆(LSTM)具有处理长期依赖的独特能力。LSTM 与 CNN 相结合，形成新的混合神经网络。Ay 等人^[43]设计了一种基于 CNN-LSTM 的深度混合模型，其中 CNN 层提取时间特征，LSTM 层提取序列学习特征，实现了对脑电信号的准确、快速分类。Shoeibi 等人^[44]使用包含 z-score 和 L2 组合归一化的 1D-CNN-LSTM 网络获得了更好的分类效果。Shen 等人^[45]设计了一个卷积递归神经网络(CRNN)模型，该模型可以提取频率、空间信息和时间相关性进行数据学习，并在上海交通大学情绪脑电图数据集(SEED)和使用生理信号的情绪分析数据库(DEAP)数据集上展示了先进的性能。然而，在 CNN 提取空间特征的过程中，时间相关性被破坏，导致 LSTM 层提取时间特征不完整。还需要注意的是，很多成熟的网络如 VGGNet^[46]和 GoogleNet^[47]并不适合小训练集。然而，上述模型大多采用单支路输入的网络结构，并且使用较宽的频带，因此没有充分利用来自多个子带的判别信息。考虑到工作频带对 MI-CNN 模型的性能有显著影响，并且单个分支的输入不能充分利用有效的脑电信息，增加模型的深度和宽度是一种有效的方法。

1.3 研究内容与结构安排

为了解决这些问题，充分发挥深度学习模型在脑电信号中的优势，本文提出了一种用于脑电信号分类的多尺度特征融合 CNN-LSTM 网络 (MFFCL)。该方法能够自适应地提取多个频率分量的判别信息，具有较高的时效性和较低的内存消耗。具体来说，设计了一个滤波器组来分解 EEG 信号，以获得多个频率分量的表示。在此基础上，CNN 和 LSTM 分别提取每个频率分量的空间特征和时间特征。最后，将提取的特征收集到全连通层中，

确定分类的预测标签。以下是这项工作的主要贡献：

(1) 本文实现了一个较低复杂度的滤波器组多尺度深度网络模型，该模型可用于脑机接口中运动想象范式的多分类问题。该模型的实时性和低功耗特性为未来在应用中的实现提供了可能性。

(2) 该模型可以从不同频率分量的脑电信号中提取时间和空间特征，旨在增加提取特征类别之间的差异。

(3) 在不改变模型和超参数的情况下，该模型可以自适应地提取数据中的有效信息，并且对不同的多通道脑电图具有良好的分类性能和鲁棒性。

本文的章节安排组织如下：

第一章主要介绍了脑机接口技术分类的研究背景与意义，其次简要介绍了 BCI 系统的结构构成以及各部分结构的功能，再次对不同结构的国内外发展现状进行了详细的阐述并指出其存在的问题，最后指出本研究提出的多分类脑电信号框架的由来以及特点。

第二章主要描述了脑电信号多分类框架所使用结构的相关理论基础部分，首先介绍了脑电产生的生理基础和特点，其次介绍了滤波器频带划分的原理以及公共空间滤波器模式的简单介绍，再次对深度学习使用的一些函数进行了简单的介绍，最后简单介绍了一下对运动想象分类的研究。

第三章主要描述了本文研究的基于运动想象的多类脑电信号的分类框架，首先是本文运用到竞赛数据库和自采数据库的详细介绍，其次是对脑电信号预处理部分的介绍，再次阐述的对脑电信号分频的原理与方法以及对卷积神经网络和长短期记忆网络的详细介绍，再者详细介绍了所提模型的结构以及超参数的设置，最后简单介绍了实验的训练环境以及做出评价的评价标准。

第四章是在第三章的实验框架上对实验结果和数据进行了分析来阐述该算法的可行性，并于其他几种脑电分类方法进行对比以体现本文提出算法的优越性，最后，设置消融实验验证所提出部分结构的重要性与合理性，从多个维度出发证明所提结构的可靠性。

第五章是总结与展望，本章总结了本文的工作内容，分析总结当前研究的优势与有待完善之处并对脑机接口技术未来的研究工作进行展望。

第二章 脑电信号多分类框架理论

2.1 脑电信号特征描述

2.1.1 脑电信号的产生

大脑皮层是大脑表面的一层由神经元细胞体所构成灰质，主导机体内一切活动过程并调节机体与周围环境的平衡^[48]。按照脑沟、脑裂及脑裂的延长线可以将大脑皮层分为额叶、顶叶、颞叶、枕叶四个大区，具体划分如表 2-1 所示。

表 2-1 大脑皮层的不同区域及中枢神经系统的主要功能

大脑皮层区域	主要功能
额叶	与精神、语言和随意运动有关
顶叶	负责处理触觉、压力、温度、疼痛等感觉，同时也是与视觉相关的神经冲动传导的重要中继站
颞叶	与听觉、语言理解、记忆及精神活动有关
枕叶	是视觉信息的主要中枢

此外，大脑皮层中还存在负责接收和处理来自身体各部位的感觉信息和运动指令以及将不同区域的信息进行整合和协调以实现更高级别的认知和行为功能的初级感觉区和初级运动区。当该区域的神经元兴奋时，会产生电位差以形成神经冲动。这个电位差导致离子在神经元膜上运动，产生电流。当大量神经元在相同的时间内放电，并且它们的放电是同步的，就会在头皮上形成强烈的电场。这种同步放电导致脑电信号的出现。这是脑电信号产生的原因。

脑电信号是一种较为复杂的生物电信号，它的幅度通常十分微弱，一般在几微伏到几百微伏之间。这种特性使得在脑电信号采集和分析的过程中非常容易受到例如思维、情感、环境等外部噪声和干扰的影响^[49]。除此之外，脑电信号还是一种非平稳和非线性的电信号，其统计特性随时间而发生变化，产生机制涉及神经元的脉冲放电等多种因素的相互作用，这对人们分析脑电信号的机制和信息处理产生了严峻的挑战。因此，脑电信号的分析和处理需要采用相应的方法，适应其非平稳、非线性的特性，以更好地捕捉和理解脑电信号中的动态特性和复杂关联，揭示大脑活动的动态机制和信息处理过程^[50]。

2.1.2 脑电信号的频率成分

脑电信号中运动想象的频率特性通常涉及特定的频率范围，这些范围与大脑在处理运动想象时的神经活动模式有关^[51]。根据频率的不同，脑电信号可以分为不同的频段，每个频段都具有不同的特性和意义^[52]。以下是常见的脑电信号频段及其特性，其各频段波形图如图 2-1 所示。

δ 波的频率范围为 1-4Hz，通常出现在深层次的放松和恢复性睡眠状态下，与人无意识的认知活动和保持意识的问题息息相关。

θ 波的频率范围为 4-8Hz，在成年人中通常只在精神恍惚或者是催眠状态时出现，但在儿童和青少年中却较为活跃，与创造力、整体性和直觉性思维有关。

α 波的频率范围为 8-14Hz，通常 在人清醒、闭上眼睛休息和进行轻松活动时出现。 α 波的机理与人内部注意力和视觉想象有关和大脑的信息处理和整合有关，在休息状态下较为突出，但在运动执行或认知任务时会减少。因此， α 波 a 的抑制被认为是大脑准备进行运动的指示之一，通常被视为运动想象的开始的先兆。

β 波的频率范围为 14-32Hz，与大脑的兴奋状态有关，通常出现在认知推理、计算、阅读、沟通以及思考时，也与焦虑、紧张和压力等负面情绪有关。 β 波与大脑皮层的激活状态相关，因此在运动想象时，大脑可能会显示出更多的 β 波活动，频段中也包含更多的与运动想象相关的有效特征。

γ 波的频率范围为 32-100Hz，通常出现在学习、记忆和处理等认知活动中，与大脑的信息处理和神经网络的同步化有关。此外，冥想和 γ 波之间有很强的联系。

2.1.3 相关同步和去同步

事件相关去同步（Event-Related Desynchronization, ERD）和事件相关同步（Event-Related Synchronization, ERS）是指在处理特定任务或者事件时，大脑不同区域的神经活动发生特定的节律性变化的现象^[52]。事件相关去同步通常发生在大脑处理某种任务或接收某种刺激时，表现为特定脑区的信号能量降低，而事件相关同步表现得与事件相关去同步相反。具体而言，当个体想象执行某个动作，如想象抬起右手时，观察到左侧运动皮层区域（与右手控制相关）可能出现 α 和 β 频段的事件相关去同步现象，这是因为想象

运动与实际运动在神经层面上有很多相似之处，都会导致相应脑区的神经元活动增强。与 ERD 相反，ERS 现象通常出现在想象运动结束后或任务间歇期，具体表现为 ERS 可能表示大脑在准备下一次想象运动或回到静息状态的过程中，相关脑区的神经元活动减少或同步性降低。大脑皮层区域的节律性变化，反映了大脑在处理运动想象时的神经活动模式，有助于我们理解大脑如何处理运动信息，并可能用于开发基于脑电信号的运动想象脑机接口（BMI）技术^[53]。ERD/ERS 量化的具体计算方法为：

$$C_{ERD/ERS} = \frac{A-R}{R} \times 100\% \tag{2-1}$$

在式中，A 为执行任务后的功率谱，R 为执行任务前的功率谱。

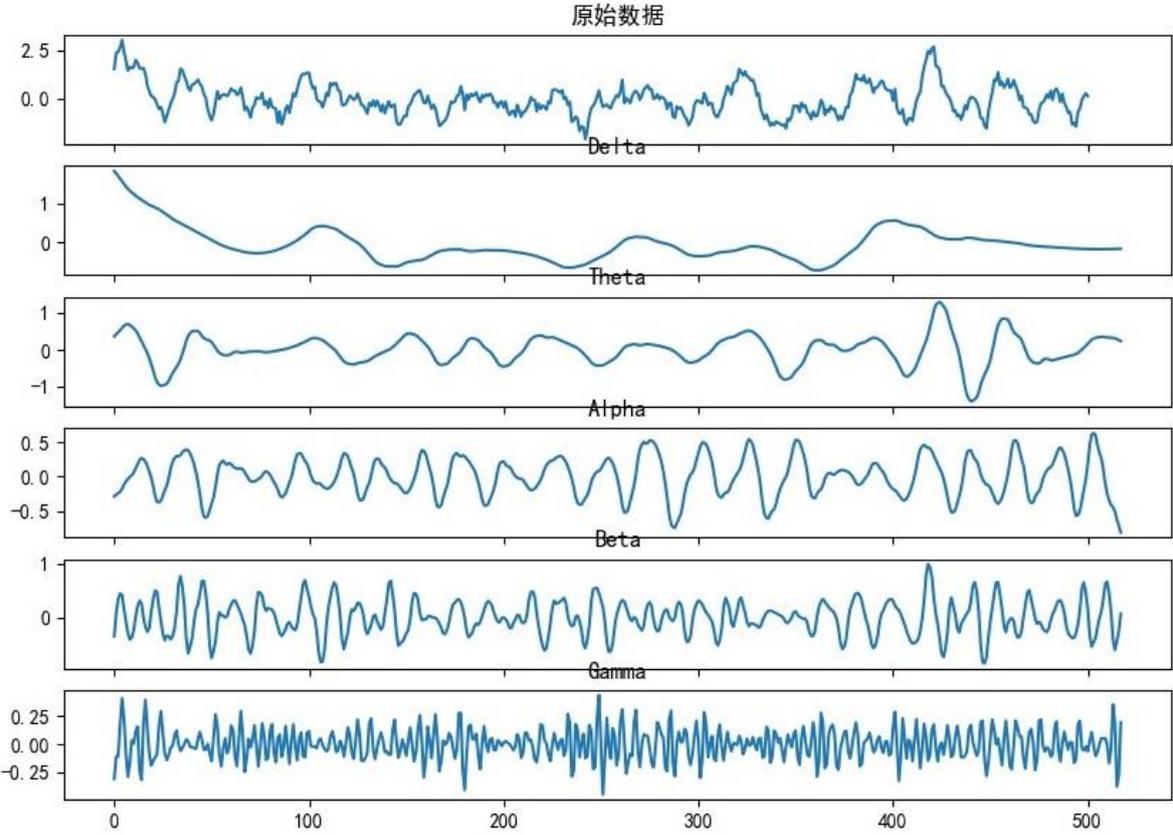


图 2-1 脑电信号各频段波形图

在基于运动想象的脑电信号分类中，C3、C4 和 Cz 电极是常用的电极位置，它们位于大脑的中部，覆盖中央沟附近的区域，与运动控制紧密相关^[54]。表 2-2 是对四类常见运动想象(如想象右手、左手、脚部和舌头运动)在 C3、C4 和 Cz 电极附近可能观察到的 ERD/ERS 现象的概述。

表 2-2 左右手、舌头和脚的运动想象在 C3、C4 和 Cz 电极表现的 ERD/ERS 现象

运动想象类别	C3	C4	CZ
左手	ERS	ERD	-
右手	ERD	ERS	-
脚部	ERS	ERS	ERD
舌头	ERS	ERS	ERS

2.2 基于巴特沃斯带通滤波器的频带划分

巴特沃斯滤波器是一种最大平坦型的电子滤波器，其在通频带内的频率响应曲线最大限度平坦，而在阻频带中频率响应曲线逐渐下降为零，这意味着其在截止频率下的平滑处理效果而不会导致信号截断或失真^[55]。除此之外，无论巴特沃斯滤波器的阶数设定为多少，其幅度对角频率（即频率响应的幅度随频率的变化）曲线都保持同样的形状，其形状都保持相同。但是，滤波器的阶数越高，在阻带内的振幅衰减速度越快，其效果如图 2-2 所示。巴特沃斯滤波器的传递函数通常表示为：

$$|H(\omega)|^2 = \frac{1}{1 + \left(\frac{\omega}{\omega_c}\right)^{2n}} = \frac{1}{1 + \varepsilon^2 \left(\frac{\omega}{\omega_p}\right)^{2n}} \quad (2-2)$$

其中 $H(\omega)$ 表示巴特沃斯滤波器的传递函数， ω 是一个复变量，表示频域中的复频率， n 表示滤波器的阶数， ω_c 表示为截止频率， ω_p 表示通频带边缘频率。

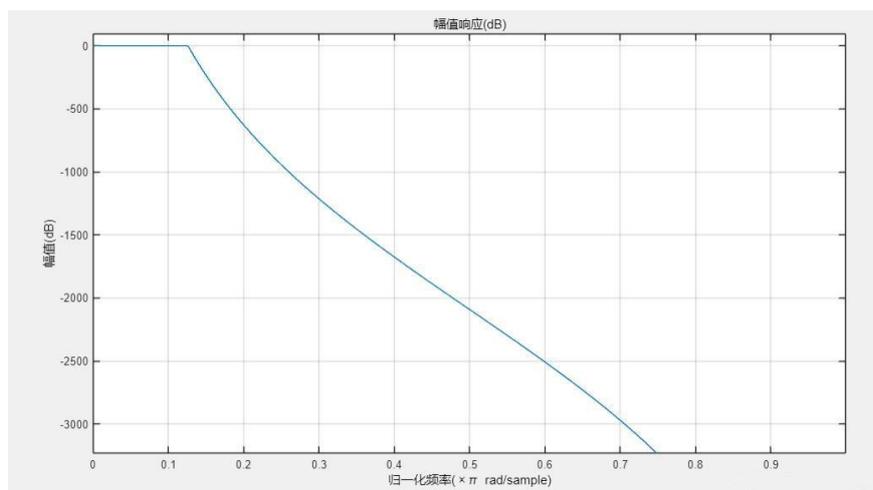


图 2-2 巴特沃斯滤波器振幅衰减随阶数变化示意图

2.3 公共空间模式（CSP）

共同空间模式（Common Spatial Patterns, CSP）是一种常用于脑电信号处理，特别是在脑机接口技术中，用于分类运动想象等任务的空间滤波方法^[56]。其基本思想是通过最大化或最小化两个不同类别（两种不同的运动状态）之间的差异来优化空间滤波器，以便最终将脑信号分类为特定的类别。这些空间滤波器通过投影脑电信号到一个新的空间中，使得在该空间中不同类别的数据分布最大程度上分离。CSP 算法的核心步骤包括计算各类别信号的协方差矩阵，解决这些协方差矩阵的广义特征值问题，并利用得到的特征向量构造空间滤波器。这些滤波器能够将原始的多通道脑电信号投影到一个低维空间，从而提取出与特定任务相关的特征，其计算过程如图 2-3 所示：

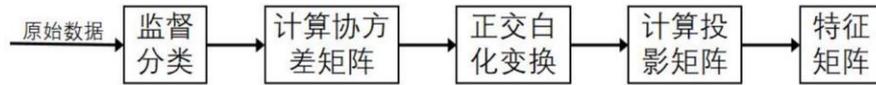


图 2-3 公共空间模式算法的计算过程

在实现 CSP 的过程中，首先需要计算每一类信号的协方差矩阵，协方差矩阵的计算公式为：

$$C_i = \frac{X_i \cdot X_i^T}{\text{trace}(X_i \cdot X_i^T)} \quad (i=1, 2) \quad (2-3)$$

其中， X_1 和 X_2 分别为运动想象任务下两种相互线性独立的时空信号矩阵， C_c 表示两类数据的空间协方差矩阵之和。

接着进行白化变换以消除不同通道之间的相关性并通过对两类协方差矩阵的同时对角化，找到一组最优的空间滤波器。白化变换的公式由奇值分解定理得：

$$C_c = U_c \Lambda_c U_c^T \quad (2-4)$$

其中 U_c 为特征向量矩阵， Λ_c 表示特征值的对角阵，且特征值是降序排列的。

白化转换 U_c 得：

$$P = \frac{1}{\sqrt{\Lambda_c}} \cdot U_c^T \quad (2-5)$$

其中 P 白化特征值矩阵，将 P 作用于 C_1 、 C_2 可得：

$$S_i = P C_i P^T \quad (i=1, 2) \quad (2-6)$$

S_i 具有公共特征向量，而且存在两个对角矩阵和特征向量矩阵 B ，满足如下条件：

$$S_i = B\Lambda_i B^T \quad (i=1, 2) \quad (2-7)$$

然后，这些滤波器能够将原始信号投影到新的空间中，使得两类信号的方差差异最大化，其公式为：

$$W = (Q^T P)^T \quad (2-8)$$

最后，提取出投影后的特征向量，用于后续的分类任务。然而，需要注意的是，CSP算法假设不同类别的脑电信号在空间上是线性可分的，这可能在某些情况下不成立。

2.4 深度学习模型基础理论介绍

深度学习模型使用损失函数、激活函数和优化器是训练过程中至关重要的组成部分，它们共同确保了模型能够有效地从数据中学习并优化其参数。

2.4.1 损失函数

损失函数用于衡量模型预测结果与实际标签之间的差异，能够直接影响到模型的训练效果。不同的损失函数适用于不同的任务类型，选择合适的损失函数至关重要^[57]。交叉熵损失函数基于信息论中的交叉熵概念，通常用于衡量分类问题中两个概率分布的相似度，特别适用于神经网络的输出是概率分布时的情形。在分类问题中，真实标签通常被视为一个概率分布，其中正确类别的概率为 1，其他类别的概率为 0。

对于二分类问题，假设 N 个样本，则交叉熵损失函数可以定义为：

$$L = \frac{1}{N} \sum_i L_i = \frac{1}{N} \sum_i -[y_i \cdot \log(p_i) + (1 - y_i) \cdot \log(1 - p_i)] \quad (2-9)$$

其中 y_i 表示是实际标签（0 或 1）， p_i 表示模型预测的概率值， \log 是自然对数函数。

对于多分类问题，假设 N 个样本，则交叉熵损失函数可以定义为：

$$L = \frac{1}{N} \sum_i L_i = -\frac{1}{N} \sum_i \sum_{c=1}^M y_{ic} \log(p_{ic}) \quad (2-10)$$

交叉熵损失使用了对数函数，这使得模型对于错误分类的惩罚更加严格。通过最小化交叉熵损失，模型可以更好地学习对正确类别的预测，并使得预测的概率分布更接近于实际标签的分布。在训练过程中，通常使用梯度下降等优化算法来最小化交叉熵损失函数，从而更新模型的参数以提高预测的准确性。

2.4.2 激活函数

激活函数通过引入非线性因素作用在神经网络的隐藏层或输出层，使得神经网络能够对神经元的输出进行非线性变换。激活函数的引入使得神经网络可以学习和表示更加复杂的函数关系，从而增加了其拟合各种数据模式的能力^[58]。激活函数通常连续并可导，并且导函数值域的区间要符合实际的需求。常见的激活函数有以下几种：

(1) ELU 函数：

ELU 函数没有当出现异常输入时反向传播中产生大的梯度导致神经元死亡和梯度消失的问题，拥有更短的训练时间和更高的准确度。ELU 函数如下：

$$\begin{cases} ELU(x) = e^x - 1 & x < 0 \\ ELU(x) = x & x \geq 0 \end{cases} \quad (2-11)$$

(2) Softmax 函数：

Softmax 函数通常用于多分类问题的输出层，它将神经元的输出转换为概率分布，确保较小的值具有较小的概率，并且不会直接丢弃。Softmax 函数将每个输出值映射到(0,1)之间，并且所有输出值的和为 1，其作用效果如图 2-4 所示。Softmax 函数如下：

$$S_i = \frac{e^i}{\sum_j e^j} \quad (2-12)$$

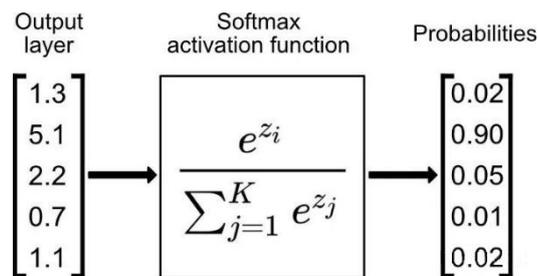


图 2-4 Softmax 函数作用效果

(3) Tanh 函数：

Tanh 函数将输入压缩到-1 到 1 的区间之间，它解决了 Sigmoid 函数输出不是以 0 为中心的问题。Tanh 函数如下：

$$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} = \frac{2}{1 + e^{-2x}} - 1 \quad (2-13)$$

2.4.3 优化器

优化器用于调整模型参数以最小化损失函数。它通过计算损失函数的梯度来更新模型参数^[59]。常见的优化器包括以下几种

1 随机梯度下降（Stochastic Gradient Descent, SGD）：

随机梯度下降是梯度下降算法的一种变体，其核心思想是通过不断迭代来更新模型参数，以最小化损失函数。与传统的梯度下降不同，随机梯度下降的每次迭代中随机选择一个小批量的样本来计算梯度，这极大的降低了迭代的计算开销，并且可以更频繁地更新模型参数，从而更快地收敛到局部最优解。随机梯度下降公式为：

$$\nabla_{\theta} f(\theta; x_i, y_i) + \nabla_{\theta} \phi(\theta) \quad (2-14)$$

2 Adam：

Adam 算法结合了自适应学习率和动量的特性，通过考虑梯度的一阶矩估计和二阶矩估计来加速模型的收敛过程。这有助于在梯度更新中考虑先前的梯度信息，减少参数更新的方差，从而提高稳定性。Adam 算法对于参数的初始化相对不太敏感，并且可以根据其梯度的历史信息来调整学习率，从而更好地适应不同特征和数据。具体公式如下：

$$\begin{aligned} v_{dW^{[L]}} &= \beta_1 v_{dW^{[L]}} + (1 - \beta_1) \frac{\partial \tau}{\partial W^{[L]}} \\ v_{dW^{[L]}}^{correct} &= \frac{v_{dW^{[L]}}}{(1 - \beta_1)^t} \\ s_{dW^{[L]}} &= \beta_2 s_{dW^{[L]}} + (1 - \beta_2) \left(\frac{\partial \tau}{\partial W^{[L]}} \right)^2 \\ s_{dW^{[L]}}^{correct} &= \frac{s_{dW^{[L]}}}{(1 - \beta_2)^t} \\ W^{[L]} &= W^{[L]} - l \frac{v_{dW^{[L]}}^{correct}}{\sqrt{s_{dW^{[L]}}^{correct} + \epsilon}} \end{aligned} \quad (2-15)$$

在方程中， t 表示每层进行算法优化的次数， L 则是层的总数。 β_1 和 β_2 为调控两个加权平均值的超参数， l 代表优化算法的学习率，而 ϵ 是一个极小的数值，用于避免“除零操作”的发生。

2.5 本章小结

运动想象分类研究，主要利用脑电信号来解析和识别个体在想象进行特定运动时的大脑活动模式。在运动想象分类的研究中，研究者通常采用脑电图等电生理学手段来捕捉大脑的电活动。通过对这些电信号进行深入的分析和处理，可以提取出与运动想象紧密相关的特征。这些特征随后被用于训练机器学习算法，从而实现运动想象的精准分类^[60]。

本章从脑电信号的起源、发展历程以及当前的研究现状等多个方面进行了介绍，使读者能够比较全面的了解其信号处理方法的作用及效果。其次，我们还对这些方法在脑电信号处理领域中的适用性和重要性进行了阐述，为后续的研究奠定了理论基础。通过对比分析，我们揭示了这些理论之间的内在联系和差异点，为读者提供了一个更为清晰的理论框架。同时，我们还讨论了这些理论在解决特定问题时的优势和局限性，以便读者能够根据实际情况选择合适的理论工具。此外，我们还对这些理论在实际研究中的应用进行了举例说明，使读者能够更好地理解这些理论的实践价值。

然而，运动想象分类研究仍面临一些挑战和限制，个体差异、信号质量、噪声干扰等因素都可能对分类效果产生影响。此外，由于脑电信号的非平稳性和非线性特性，如何提取出有效的特征并设计出高效的分类算法仍是当前研究的热点和难点。综上所述，运动想象分类研究是一个充满挑战和机遇的领域^[61]。下一章将会针对上述问题改进实验框架以期取得良好的效果。

第三章 脑电运动想象信号实验分析

3.1 实验数据

3.1.1 BCI Competition IV Dataset IIA 数据集

BCI Competition IV Dataset IIA 数据集包含来自四个 MI 任务（左手和右手、脚和舌头）的九名参与者的脑电图数据^[62]。将总共 25 个电极（22 个用于 EEG，3 个用于 EOG）放在每个参与者的头上用于数据采集，电极的排放格式按照国际标准 10-20 放置，图 3-1 为其排放方式示意。采样频率为 250Hz，带通在 0.5Hz 和 100Hz 之间。此外，采用 50Hz 的陷波滤波器来抑制噪声。采集到的数据按照采集时间被分为训练集和测试集，每个数据集包含 288 次运动想象的记录。实验范式如图 3-2 所示。每次试验的持续时间设定为 7.5 秒，包括视觉提示、MI 和休息时间。在 $t=0s$ 时，黑屏上出现一个持续时间为 2s 的注视十字，同时发出快速警告音的语音提醒，提示受试者。随后，屏幕上出现一个指向上、下、左或右的箭头，指示四项任务中的一项。这提醒受试者执行所需的 MI 任务。每个受试者被要求执行 MI 任务，直到屏幕上的十字消失 ($t=6s$)。之后，从 6 秒到 7.5 秒进行了短暂的休息。

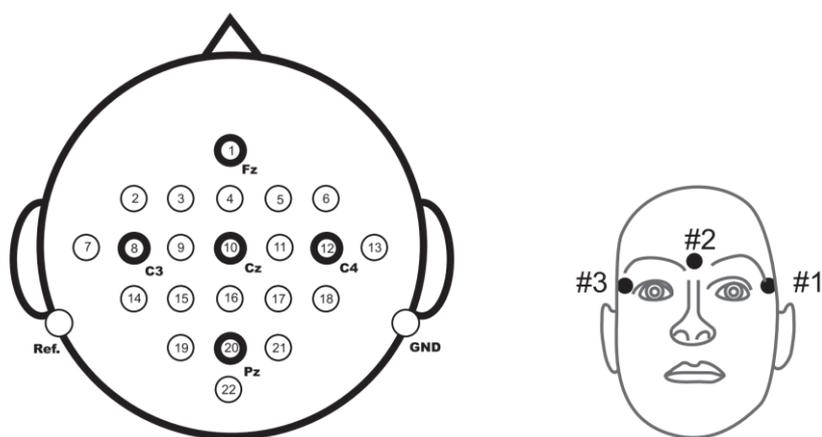


图 3-1 左图为用于采集脑电信号的电极位置，右图用于采集眼电信号的电极位置

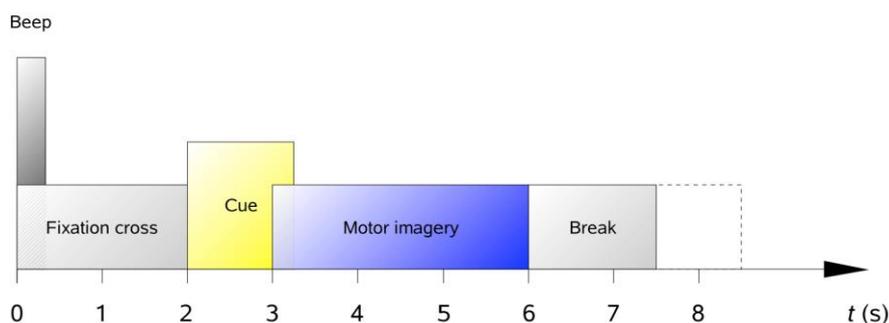


图 3-2 BCI Competition IV Dataset IIA 实验范式

3.1.2 BCI Competition IV Dataset IIB 数据集

BCI Competition IV Dataset IIB 数据集包含来自两个 MI 任务（左手和右手）的 9 名参与者的脑电图数据^[62]。在数据采集过程中，这 9 名受试者坐在距离电脑显示屏大约 1 米的座椅上，头戴脑电采集装置。脑电信号数据主要来自于 C3、CZ、C4 这三个电极，它们记录了受试者的运动想象。此外，为了评估眼电信号(EOG)在大脑进行运动想象时对于脑电信号的影响，还采集了眼电信号以排除其的干扰。每个受试者的脑电图数据集包含五个会话。前两个会话是没有视觉反馈的脑电图图像数据，每个会话包含 120 个试验。最后三个会话是具有视觉反馈的脑电图图像数据，每个会话包含 160 个试验。在每次进行运动想象测试之初，屏幕上会展现一个十字形的标记。当听到一段 70 毫秒的简短声音提示后的大约 1 秒钟，这个十字标记会根据既定的运动想象任务（无论是想象左手还是右手的动作）转变为一个指向左或右的箭头标记。该图案会持续显现大约 1.25 秒的时间，为实验者提供一个明确的信号，在随后的 3 至 7 秒内展开运动想象，进而收集到相关的脑电数据。随后，会有一段超过 1.5 秒的休息时间供实验者放松。

3.1.3 自建数据集

脑电信号的采集方式主要有两种：侵入式和非侵入式。以皮层脑电图和深度电极为代表的侵入式采集需要将电极植入大脑皮层之内，皮层脑电图方法具有更好的空间分辨率，能够准确检测脑电图电极不可见的高频脑活动；而深度电极则是通过手术或其他形式穿透生物组织将电极植入大脑的更深层，记录来自一小群神经元的活动。这两种方法都提供了大脑活动的深入图景，但需要具有不定程度的风险的神经外科手术植入电极，且测试对象

往往不能接受，并不适用于日常应用。而非侵入式采集方法通常使用脑电图来记录大脑的电活动，是 BCI 研究中最常见的神经影像学方法。EEG 通过电极记录大脑的电活动，电极通常嵌入电极帽中，安装在用户身上并调节电极以获得良好的信号，这种方法相对便宜且便携^[63]。

EEG 信号的采集设备如图 3-3 所示，该设备由电源和控制器、信号放大器、模拟数字转换器和电极帽四部分组成。自发脑电信号通常比较微弱，信号放大器负责将电极捕捉到的微弱信号进行放大和滤波，以便后续的数据处理和分析。模拟数字转换器将放大器输出的模拟信号转换为数字信号，以便计算机可以处理和存储这些数据。电极帽是一种头戴式装置，其电极的布置通常遵循国际 10-20 国际导联的 64 导电极图，以确保一致性和可比性。电极的排列方式如图 3-4 所示。在实验过程中，佩戴电极帽会使氯化银合金电极与头皮直接接触。另外，我们还会在电极的空腔内注入特定的导电膏来使电极与头皮之间的电阻达到实验要求。最终采集到的数据是由特定信道数量乘以由对应采样点的电压幅值组成，样本数量由设置的采样率以及实验范式的设计决定。组实验包含的任务数量和类型与 BCI Competition IV Dataset IIA 相同，但实验进行的指示本文做了些许的优化。在最开始时，屏幕显示“单击鼠标左键开始实验”这一段文字提示，点击鼠标左键后，屏幕显示柔色的空白屏幕以提示受试者专注，4s 后出现一个提示语提示受试者想象特定的任务，4s 后重新显示空白屏幕并循环往复。



(a) 电源和控制器



(b) 电极帽和转接盒

图 3-3 脑电信号采集设备

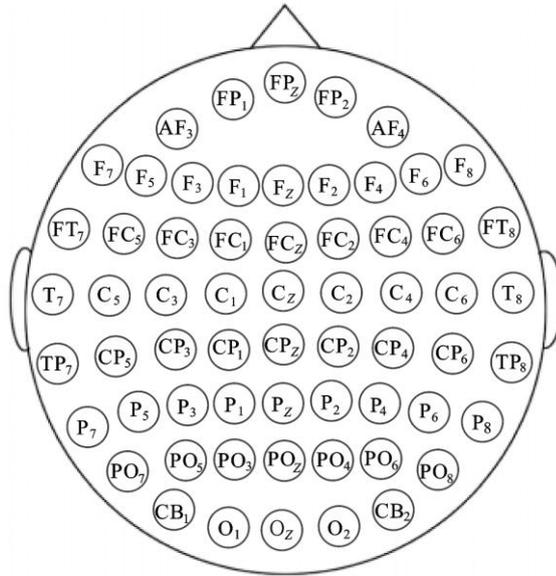


图 3-4 国际 10-20 国际导联的 64 导电极图

7 名年龄在 22 岁到 27 岁之间的志愿者参与了本次脑电信号的采集，其中所有受试者都是健康的，有正常或矫正的视力和右利手。在实验开始前告知了实验的注意事项并获得了所有受试者的知情同意，所有的受试者都在实验前洗发以减小外界干扰因素的影响。每个参与者分别进行两次不同的运动想象脑电数据采集实验，两者间隔均为一天。每次实验包括 6 节共 288 次任务，每两节实验之间有一个短暂的休息供受试者恢复精力。为了减少环境中电磁场和环境噪声的干扰，信号采集均在特定的电磁屏蔽室中，电磁屏蔽室如图 3-5 所示。



图 3-5 电磁屏蔽室环境

除此之外，被试者被安排在一个舒适的椅子上，整个实验流程中没有其他人参与并且实验室中保持足够安静以尽量消除对被试的干扰。最后，利用 0.5-100Hz 的带通滤波器对

采集到的脑电数据滤波来消除噪声的干扰，这一部分是由采集设备自动完成。采集到的脑电信号可视化如图 3-6 所示。

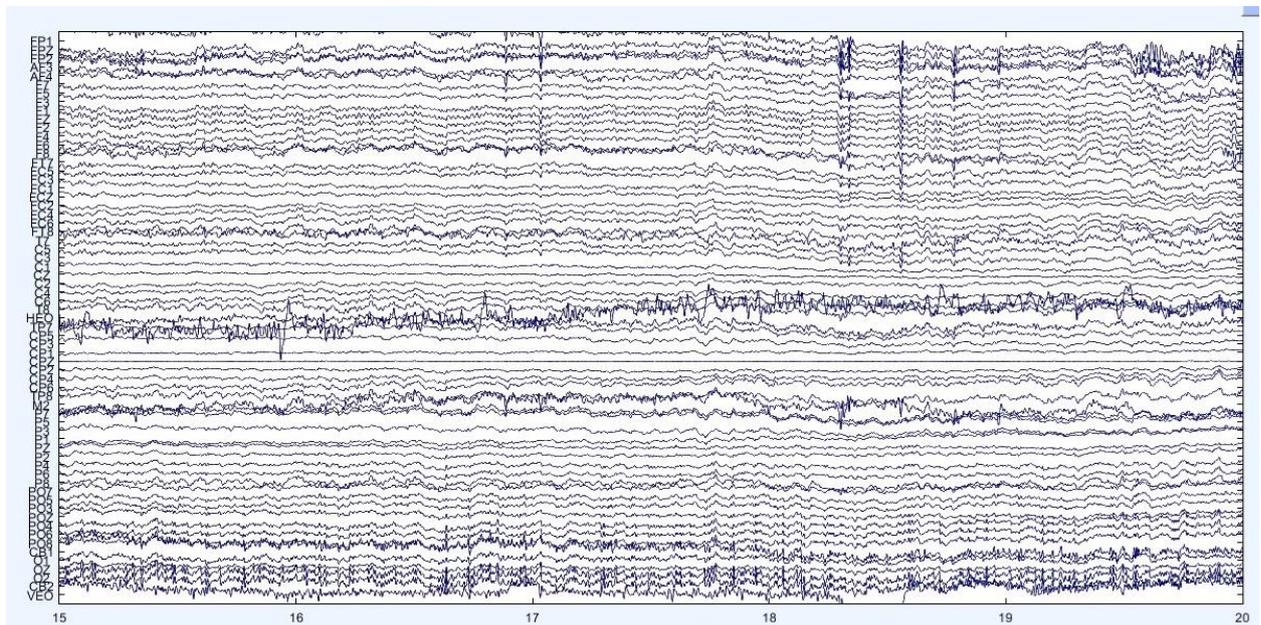


图 3-6 自建数据集可视化分析

3.2 数据的预处理

竞赛数据集给定的数据格式为 GDF 格式，而自建数据集的数据格式为 CNT 格式。为了保证实验的可靠性，需要将数据的 CNT 格式转换为 GDF 格式并检验了每次试验的试验类型，起始位置，通道，持续时间，采样频率等信息与转换前是否一致。GDF 格式数据的读取不同于一般格式的数据，虽然 MATLAB 中的 EEGLAB 数据包^[64]可以很方便的读取并处理脑电信号，但深度学习模型在 MATLAB 中的可操作性不足，无法满足实验的需求。因此本实验采用的数据读取工具是基于 Python 的 MNE 工具包^[65]，在读取过程中提取数据头信息封装与数据主体并去除，最终提取出通道数*时间轴的数据格式。竞赛数据集为 22 个信道而采集到的数据为 64 信道，为与竞赛集数据格式保持一致，本文按照竞赛数据集的格式去除自建数据集中的多余电极。

在本次实验中，本文选取了从执行任务阶段开始后 4 秒的数据为每个运动成像任务的脑电图数据，这意味着代表每个动作的单个信道中包含采样频率*4 个采样点。具体来说，对于 Competition IV Dataset IIA 数据集，截取每次测试 2~6s 的数据作为该方法的输入样本。对于 Competition IV Dataset IIB 数据集，本文使用前两个会话从 3 秒到 7 秒的截断数据作

为样本，最后三个会话从 3.5 秒到 7.5 秒的截断的数据作为样本。对于自建数据集，截取每次测试 2~6s 的数据被作为该方法的输入样本。

为了获得更准确的 EEG 数据并减少误解，通常需要在数据预处理阶段去除眼电图（EOG）、心电图（ECG）和肌电图（EMG）等噪声的干扰。在 EEG 处理中，PCA 可以通过正交变换将原始特征空间中的线性相关变量转换为线性无关的主成分去除噪声和伪迹，同时保留信号中的主要成分^[66]。但 PCA 假设数据中的主要变化是由少数几个主成分引起且对异常值和缺失数据敏感，不能完全分离脑电信号中的潜在噪声。在 EEG 处理中，独立成分分析（ICA）从多变量统计数据中找到隐藏的因子或成分来分离出不同的信号源，如脑电活动、眼动、肌电活动等^[22]。除此之外，ICA 不需要对干扰信号进行先验假设，因此具有更广泛的适用性。在本实验中，使用 ICA 降低 EEG 信号中的噪声干扰为后续工作创造有利的条件。识别到的部分成分如图 3-7 所示。去除前后脑电信号变化如图 3-8 所示，其中红色为剔除之后的效果，可以看到经过 ICA 处理后的信号更加稳定和平滑。

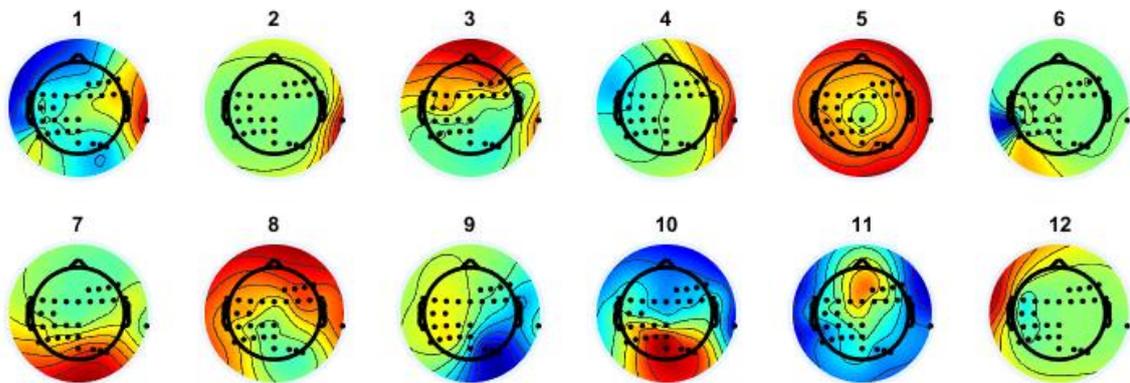


图 3-7 部分独立成分分布效果图

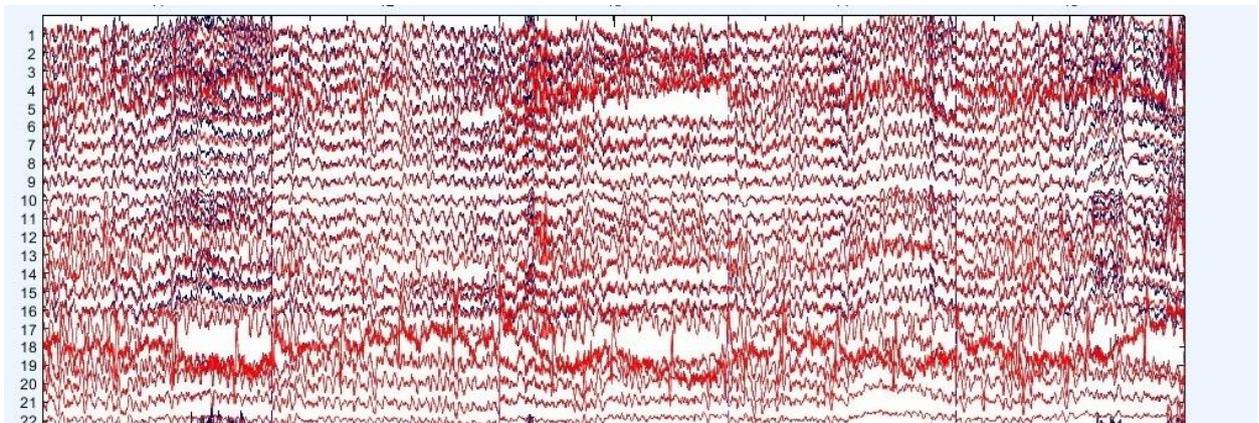


图 3-8 预处理后效果图

3.3 信号的分频处理分析

滤波器组公共空间模式 (FBCSP) 是由德国柏林工业大学的 Angelika Gräser 等人^[67]提出的一种专门用于运动想象分类等的研究方法, 该方法结合滤波器组和共同空间模式的特征提取技术, 通过一系列带通滤波器进行分解形成多个频段的子信号以找到能够最大化两类信号差异的空间滤波器。首先, 将原始脑电信号通过一组带通滤波器进行分解, 通常覆盖多个频段 (如 alpha、beta 等)。每个频段内的信号都被视为一个独立的信号通道。其次, 在每个频段上, 应用 CSP 算法来找到能够最大化两类信号差异的空间滤波器。CSP 通过计算两类信号的协方差矩阵, 并求解广义特征值问题, 得到一组空间滤波器。最后, 将原始信号通过每个频段上的 CSP 滤波器进行投影, 得到降维后的特征向量。这些特征向量包含了原始信号中与运动想象最相关的信息。

FBCSP 能够同时分析多个频段的脑电信号, 从而捕捉到与运动想象相关的不同频段的信息。这有助于提高分类性能, 尤其是当相关信息分布在不同频段时。同时, 通过滤波器组分解, FBCSP 能够在一定程度上减少噪声和伪迹对构架特征提取的影响。这是因为噪声和伪迹通常分布在特定的频段, 而 FBCSP 可以在这些频段上应用更严格的滤波或排除。

滤波器组公共空间模式 (FBCSP) 的成功应用证明, 利用多频带的判别特征是提高 MI 分类性能的可行方法。在 FBCSP 算法中, 首先采用非重叠带通滤波器组将脑电信号分解成多个频段以提取不同频段的判别信息。不同运动想象动作判别信息的最活跃点分布在不同的频率范围内, 例如 μ 节律 (8-14 Hz) 和 β 节律 (14-30 Hz) 就是两个与运动图像密切相关重要的频率范围。具体来说, 在运动执行过程中会发生事件相关去同步现象; 运动结束后会发生事件相关去同步现象。因此, 通过分频处理可以选择性地强调或抑制某些频率成分, 从而更准确地捕捉和分析这些特定频段的信号特征。通过对 FBCSP 方法的分析表明, 将多个弱分类器(不同频段提取的判别特征)组合(分类器训练)构建成一个强分类器是着实有效的方法。除此之外, 全频带的脑电信号包含大量的数据和信息, 直接处理可能会导致计算量大、耗时长。通过分频处理, 可以将全频带的信号分解为多个子频带, 从而降低每个子频带的计算量和信号复杂度。然而, CSP 算法仅仅能将两类样本的均值差异最大化, 而完全忽略了类内的离散度信息。由于运动脑电信号是典型的非平稳信号, 类内方差可能会很大, 这会影响后续特征分类的效果。

以上内容仅为本文档的试下载部分，为可阅读页数的一半内容。如要下载或阅读全文，请访问：<https://d.book118.com/237163122162010012>