

基于节律调制的脑—机接口系统 ——从离线到在线的跨越

(申请清华大学工学博士学位论文)

培 养 单 位： 医 学 院

学 科： 生 物 医 学 工 程

研 究 生： 王 毅 军

指 导 教 师： 高 上 凯 教 授

二〇〇七年四月

基于节律调制的脑-机接口系统——从离线到在线的跨越

王毅军

**Brain-Computer Interfaces Based on
Modulation of Brain Rhythms: Progress
from Offline Analysis to Online
Application**

Dissertation Submitted to

Tsinghua University

in partial fulfillment of the requirement

for the degree of

Doctor of Engineering

by

Wang Yijun

(Biomedical Engineering)

Dissertation Supervisor: Professor Gao Shangkai

April, 2007

关于学位论文使用授权的说明

本人完全了解清华大学有关保留、使用学位论文的规定，即：

清华大学拥有在著作权法规定范围内学位论文的使用权，其中包括：（1）已获学位的研究生必须按学校规定提交学位论文，学校可以采用影印、缩印或其他复制手段保存研究生上交的学位论文；（2）为教学和科研目的，学校可以将公开的学位论文作为资料在图书馆、资料室等场所供校内师生阅读，或在校园网上供校内师生浏览部分内容；（3）根据《中华人民共和国学位条例暂行实施办法》，向国家图书馆报送可以公开的学位论文。

本人保证遵守上述规定。

（保密的论文在解密后遵守此规定）

作者签名： _____

导师签名： _____

日 期： _____

日 期： _____

摘 要

脑-机接口是不依赖于外周神经和肌肉的信息传输通道，它为瘫痪病人提供了一种与外界环境通讯的新途径。基于脑电信号的脑-机接口具有成本低、操作方便、对大脑无损伤等优点，是当前脑-机接口研究的主要方向。脑-机接口的研究有明确的临床应用背景，因此研究开发具备实时性以及脑-机交互学习功能的实用在线系统具有十分重要的意义。

本论文以基于脑电节律调制的在线脑-机接口系统为研究对象，对大脑感觉运动皮层的 μ 节律和视皮层的稳态视觉诱发电位进行了深入的研究。以脑电节律调制为生理背景，论文提出并实现了多种基于节律调制的脑-机接口系统。

脑电信号处理是在线脑-机接口系统的核心。本论文以节律调制的神经生理背景为基础提出了一种综合时-频-空域信息的特征提取方法，并采用多特征结合的方法，显著提高了对不同脑电模式分类的正确率。这一方法在 2003 年第二届国际脑-机接口竞赛的“单次手指运动脑电数据集”中获得了第一名。

机器学习算法是在线系统的另一个重要环节。基于统计学习理论，本论文提出了一系列适用于在线脑-机接口的机器学习算法，成功解决了在线系统的小样本学习和休息状态的自动检测等问题。这些方法应用在 2005 年第三届国际脑-机接口竞赛的“小样本想象运动脑电数据集”和“休息状态自动检测数据集”中均获得了第一名。

在算法研究的基础上，本论文进一步设计实现了基于想象运动、大脑同步化、稳态视觉诱发电位的三种在线脑-机接口系统。基于想象运动的在线系统实现了脑-机交互适应学习的训练模式，获得了稳定的性能；三分类系统被成功应用于机器人的运动控制。大脑同步化系统可用于进一步提高想象运动脑-机接口系统的性能。基于稳态视觉诱发电位的在线系统达到了 43bits/min 的平均信息传输速率，临床脊髓损伤病人试用结果表明系统的设计是非常成功的。

以单一模式的脑-机接口系统为基础，本论文还首次提出了多模式脑-机接口的设想，并通过实验研究验证了基于多模式注意的脑-机接口的可行性。

关键词：脑-机接口； μ 节律；稳态视觉诱发电位；在线机器学习；多模式注意

Abstract

Brain-computer interface (BCI) is a communication channel which does not depend on the brain's normal output pathways of peripheral nerves and muscles. It supplies the paralyzed patients with a totally new approach to communicate with the environment. The electroencephalogram (EEG) based method is the main interest of current BCI research due to its advantages of low cost, convenient operation and non-invasiveness. Design and implementation of an online system plays an important role in BCI research with the purpose of producing practical devices for real-life clinical application. Compared with offline data analysis, an online BCI has great difficulties in fulfilling real-time processing, system practicability and brain-machine co-adaptation.

The principle of an online BCI based on rhythmic modulation of EEG signals has been proposed in this dissertation. Two rhythmic EEG components corresponding to brain activities from sensory-motor cortex and visual cortex, i.e. mu rhythm and steady-state visual evoked potential (SSVEP), have been investigated and employed in constructing several different types of online BCI systems based on modulation of brain rhythms.

EEG Signal processing is the most important factor in the online BCI. Considering the neurophysiologic background of brain rhythms, we proposed a feature extraction algorithm based on parameter optimization in temporal, frequency, and spatial domains respectively. Besides, an approach integrating different EEG components was utilized to significantly improve the accuracy of classifying different brain states. With using this approach, we won the "self-paced key typing" dataset in BCI Competition 2003.

Machine learning algorithms also play important roles in the online BCI. A series of online machine learning approaches based on the statistic machine learning theory have been proposed and successfully applied to solve the problems in the online system, e.g. "small training set" and "automatic detection of the idle state".

The advantages of these novel approaches were validated through our winnings of the “small training set” dataset and the “idle state detection” dataset in BCI Competition 2005.

With using the aforementioned algorithms, we implemented three different online BCI systems based on rhythmic modulation of EEGs, i.e. a motor imagery based BCI, a synchrony based BCI, and an SSVEP based BCI. An adaptive method was integrated in the motor imagery based BCI to realize brain-machine co-adaptation during the online training procedure, contributing to a robust system performance. In particular, the three-class motor imagery BCI has been applied to control three directional movements of a robot. The synchrony based BCI provided a new way to further improve the performance of the motor imagery based BCI. The SSVEP based BCI achieved a high information transfer rate of 43bits/min in the lab and was proved a very successful system through clinical tests by the patients with spinal cord injury.

Moreover, different from the BCI using a single modal EEG component, a novel BCI prototype called multi-modal BCI has been first presented in this dissertation. A BCI platform based on multi-modal attention has been designed and proved promising through offline data analysis.

Key words: brain-computer interface; mu rhythm; steady-state visual evoked potential; online machine learning; multi-modal attention

目 录

第 1 章 引言	1
1.1 脑-机接口的定义	1
1.2 脑-机接口的研究现状	2
1.2.1 脑-机接口方法概述	2
1.2.2 基于脑电信号的脑-机接口系统	3
1.3 基于脑电节律调制的脑-机接口系统	5
1.4 脑-机接口系统存在的问题	7
1.4.1 数据传输率	7
1.4.2 系统的独立性	8
1.4.3 系统的临床应用	9
1.5 从离线分析到在线应用的挑战	9
1.5.1 系统的实时性	10
1.5.2 脑-机交互适应学习	11
1.5.3 大脑空闲状态的检测	11
1.5.4 系统的实用性	12
1.6 论文的结构和内容	13
第 2 章 节律调制脑-机接口的生理基础	14
2.1 脑电节律	14
2.2 mu 节律	14
2.3 事件相关去同步化和同步化	15
2.3.1 事件相关去同步化和同步化的定义	16
2.3.2 事件相关去同步化和同步化的生理基础	17
2.3.3 mu 和 beta 节律的事件相关去同步化和同步化	18
2.4 稳态视觉诱发电位	20
2.4.1 稳态视觉诱发电位的定义	20
2.4.2 稳态视觉诱发电位的特点	20
2.5 本章小结	21

第 3 章 脑电节律信号的特征提取方法	22
3.1 脑电节律信号的量化方法	23
3.1.1 基于能量特征的时域分析方法	24
3.1.2 基于能量特征的频域分析方法	27
3.2 脑电节律的空间增强算法	29
3.2.1 基于共空间模式的空间滤波算法	30
3.2.2 基于独立分量分析的空间滤波算法	34
3.2.3 多类问题的扩展	39
3.3 脑电节律的同步化分析	43
3.3.1 脑电同步化分析算法	43
3.3.2 想象运动脑电同步化分析	45
3.4 单次手指运动诱发脑电的特征提取	46
3.4.1 BCI Competition 2003 数据集 IV	47
3.4.2 手指运动诱发脑电的特征分析	47
3.4.3 特征提取和分类	49
3.4.4 讨论	52
3.5 本章小结	55
第 4 章 在线脑-机接口系统机器学习算法	57
4.1 脑-机交互适应系统	57
4.2 分类算法在脑-机接口中的应用	58
4.2.1 基于可分性判据的特征选择	60
4.2.2 分类器设计	61
4.2.3 特征结合方法	65
4.3 脑-机接口与小样本机器学习	67
4.4 基于小样本机器学习的想象运动脑电分类	69
4.4.1 BCI Competition III 数据集 IVa	69
4.4.2 想象运动脑电特征提取方法的选择	72
4.4.3 特征提取的参数优选方法	75
4.4.4 基于半监督学习的自适应分类算法	77
4.4.5 结果及讨论	81
4.5 无训练样本的休息状态脑电自动检测	84

4.5.1	BCI Competition III 数据集 IVc.....	84
4.5.2	特征提取和分类器设计.....	85
4.5.3	分类结果.....	87
4.6	本章小结.....	89
第 5 章	基于想象运动脑电的在线脑-机接口系统.....	91
5.1	想象运动脑-机接口的原理.....	91
5.2	想象运动在线脑-机接口设计.....	91
5.2.1	脑-机接口在线系统框图.....	91
5.2.2	想象运动在线实验设计.....	93
5.3	在线特征提取和模式分类.....	95
5.4	系统测试.....	98
5.5	对想象运动脑电分类中几个问题的讨论.....	100
5.5.1	离线与在线模式的比较.....	100
5.5.2	多分类想象运动的分类器设计.....	102
5.6	本章小结.....	104
第 6 章	基于运动皮层同步化的在线脑-机接口系统.....	106
6.1	大脑同步化研究背景.....	106
6.2	想象运动中的大脑同步化.....	107
6.2.1	想象运动中的脑电同步化.....	107
6.2.2	基于同步化特征的想象运动脑电分类.....	109
6.2.3	同步化算法的性能比较.....	111
6.2.4	相位同步化与事件相关去同步化的关系.....	112
6.3	基于同步化特征的在线脑-机接口系统设计.....	115
6.4	基于同步化的想象运动脑-机接口电极放置方法.....	116
6.5	本章小结.....	120
第 7 章	基于稳态视觉诱发电位的在线脑-机接口系统.....	121
7.1	基于稳态视觉诱发电位的脑-机接口系统设计.....	121
7.1.1	系统工作原理.....	121
7.1.2	系统构成.....	122
7.2	参数优选方法.....	123

7.2.1	电极位置选择	124
7.2.2	频率响应分析	129
7.2.3	自动调节时间窗	131
7.3	系统测试和应用	132
7.4	本章小结	134
第 8 章	多模式脑—机接口系统的设计	135
8.1	多模式脑—机接口的原理	135
8.2	基于视觉和触觉注意的脑—机接口系统	136
8.2.1	系统框图	137
8.2.2	特征提取和模式分类	139
8.2.3	分类结果	141
8.2.4	多模式注意过程中 μ 节律的 ERD/ERS	143
8.3	本章小结	144
第 9 章	总结和展望	145
9.1	论文的工作成果	145
9.2	论文的创新点	147
9.3	脑—机接口研究的展望	148
9.3.1	本论文进一步研究的展望	148
9.3.2	脑—机接口研究的展望	149
	参考文献	152
	致谢与声明	166
	个人简历、在学期间发表的学术论文与研究成果	167

第 1 章 引言

1.1 脑—机接口的定义

正常情况下，大脑和外部环境的通讯需要通过外周神经和肌肉通道来完成，但这一通道常因为一些疾病或损伤而被削弱或破坏，比如脊髓侧索硬化症（amyotrophic lateral sclerosis, ALS）、脊髓损伤（spinal cord injury, SCI）、脑瘫（cerebral palsy）、肌萎缩（muscular dystrophies）等。现代医学技术的发展使得这一类病人还能继续维持生命很长时间，因此如何提高他们的生活质量已成为被广泛关注的问题。

在无法修复这类损伤的情况下，脑—机接口(brain-computer interface, BCI)技术提供了一种非肌肉控制的通讯通道，使大脑可以直接和外部环境进行信息交互。脑—机接口将人脑的信号直接转换成对外部设备的控制命令，信息的传递不再需要经过外周神经和肌肉等传出通道^[1-6]。大量脑功能成像的研究证明^[7]：思维和大脑之间存在着紧密的联系，因此从大脑的活动中可以解读出人的意图。解读由外界刺激或思维活动引起的大脑活动变化是脑—机接口系统的基本原理，在现有的脑—机接口研究中使用了各种监测大脑活动的脑功能成像方法，如脑电图(electroencephalogram, EEG)^[8-14]、大脑皮层电位图(electrocorticogram, ECoG)^[15-17]、脑磁图(magnetoencephalogram, MEG)^[18,19]、正电子发射断层成像(positron emission tomography, PET)和功能磁共振成像(functional magnetic resonance imaging, fMRI)^[20,21]，近红外光谱成像(near-infrared spectroscopy, NIRS)^[22,23]，以及大脑神经元活动(neuronal activity)^[24]等。

如图 1.1 所示，一个典型的脑—机接口系统由数据采集、信号处理、设备控制三个部分组成。数据采集部分为系统的输入部分，负责大脑活动的信号采集；信号处理部分负责从采集到的信号中提取出大脑特定活动下的特征，然后将其翻译为对外部设备的控制命令；而系统输出部分的任务是根据控制命令来执行对外部设备的操作。在基于脑电信号的脑—机接口系统中，输入信号是在头皮记录到的 EEG 信号，信号处理部分从脑电信号中提取出诱发响应或者脑电节律的相应特征，然后将这些特征转换为预先设定的设备控制指令，再由设备控制模块完成对外部设备的控制。现有的大部分脑—机接口系统是实验室环境下的

演示系统，输出设备多为基于计算机软件的图形或文字目标选择，比如光标运动控制和字符输入等^[1-6]。




图 1.1 脑—机接口系统框图

1.2 脑—机接口的研究现状

1.2.1 脑—机接口方法概述

根据大脑活动记录方式的不同可以把脑—机接口分为有损（invasive）和无损（non-invasive）两大类^[1]：有损方式包括大脑皮层电位和神经元记录，无损方式以脑电信号为主，同时还包括了脑磁图、功能磁共振成像、近红外光谱成像等方法。在 BCI 研究的过程中，较早出现的是基于脑电信号的 BCI 和基于单个神经元记录的 BMI（brain-machine interface）系统^[6]。基于神经元记录的 BMI 直接记录到皮层神经元的放电活动，因此可以实现很高的信息传输速率^[24,25]，但由于手术和电极植入存在的风险、对大脑的损伤、植入电极的寿命受生物兼容性影响等问题，BMI 的研究对象通常是老鼠和猴子等动物^[25-28]。2006 年，Hochberg 等人首次将 BMI 系统应用在严重的 SCI 病人身上，在大脑的运动皮层植入电极阵列，帮助病人实现了计算机操作和假肢控制等功能^[24]。随着计算机技术和电生理信号记录技术的发展以及其它脑功能成像技术的出现，皮层电位、脑磁图、功能磁共振和近红外光谱成像方法也被应用到脑—机接口的研究中。大脑皮层电位 BCI 的研究通常是在需要手术的癫痫病人身上进行，和头皮脑电信号相比，皮层电位记录到的是大脑皮层表面的电活动，因此有较高的信噪比

和空间分辨率，皮层电位的另外一个优势是能够记录到较高频率的 γ 波 ($>30\text{Hz}$)，而在头皮脑电中 γ 节律由于传导过程中的低通效应而被大大削弱^[15]。脑磁图能够准确记录到由大脑皮层的活动引起的脑磁场变化，因而能够记录到比脑电响应更强并且分布更为集中的大脑活动^[18]。功能磁共振成像的优点在于高的空间分辨率，同时还能检测到大脑深部结构的活动^[20]。近红外光谱成像的原理是检测大脑活动时皮层的血氧变化，和功能磁共振方法相比，其优点是设备简单便携，因此有更高的实用性^[22]。脑电信号经过脑脊液、颅骨、头皮的传导后其空间分辨率大大降低^[29]，并且脑电记录过程中很容易引入肌电、眼电、以及其它由记录装置引起的伪迹，这些因素限制了脑电信号 BCI 的传输速率。但采集设备简单、操作方便、较少受使用环境限制、时间分辨率高、记录无损等优点使得基于脑电信号的 BCI 仍是当前 BCI 研究的主要方式，并且在 BCI 实际应用中，特别是对于完全瘫痪的病人，系统的传输速率可能不是使用者最关心的问题，在 Birbaumer 等人的研究中，17 名 ALS 病人中只有 1 人愿意使用颅内电极^[5]。本论文的工作仅讨论基于脑电信号的脑—机接口系统。

1.2.2 基于脑电信号的脑—机接口系统

基于脑电信号的 BCI 研究最早可以追溯到 20 世纪 70 年代，早期研究的目的是让受试者通过生物反馈训练学习如何自主地控制脑电节律。Nowis 等人的研究表明，受试者通过训练后能够自主调节脑电的 α 波^[30]；Sterman 等人得到类似的结论，他们研究的是人脑对感觉运动皮层 μ 节律的调节能力^[31]。这些开创性的工作为基于脑电信号的 BCI 研究打下了很好的基础。1973 年，Vidal 在有关脑—机通讯 (brain computer communication) 的论文里详细讨论了可能应用到 BCI 中的脑电信号^[32]，列举了脑电 α 波、诱发电位、 μ 节律等信号，这些信号都被应用到现有的 BCI 系统中。

在现有的脑电 BCI 系统中，最常用的有以下四种脑电信号：视觉诱发电位 (visual evoked potential, VEP)、 μ 和 β 节律、事件相关电位 (event-related potentials, ERP)、慢皮层电位 (slow cortical potential, SCP)。使用这些信号的脑—机接口系统通过检测大脑对视觉刺激、注视或注意的方向、运动意图、认知活动的响应来实现光标控制和字符输入等简单的通讯功能。

1.2.2.1 视觉诱发电位脑—机接口

视觉诱发电位是大脑对视觉刺激响应，属于外源性诱发响应，需要通过视觉刺激来诱发产生，诱发 VEP 的方式有闪光刺激，颜色交替及图形翻转等。根据视觉刺激的频率高低，VEP 又可以分为瞬态 VEP (transient VEP, TVEP) 和稳态 VEP (steady-state VEP, SSVEP)^[33]。瞬态 VEP 通常需要经过多次叠加平均才能提取到，分析的参数多为潜伏期和波幅；而对稳态 VEP 的分析常用的是功率谱分析的方法。1992 年，Sutter 等人实现了一种基于瞬态视觉诱发电位的 BRI (brain response interface) 系统^[8]。视觉刺激器使用的是电脑显示器上 8×8 的闪烁方块矩阵，刺激模式为红绿颜色交替，使用同一个伪随机序列作为每个目标的输入序列，但每个目标刺激序列起始时刻不同。视觉诱发电位有较固定的潜伏期，因此每个目标诱发出的瞬态 VEP 序列起始时刻不同。BRI 采用模板匹配的方法来寻找 VEP 序列的起始时刻，从而确定受试者注视的目标。一位植入硬脑膜外电极的 ALS 病人使用 BRI 可以达到每分钟输入 10-12 个单词的传输速率。另一类 VEP 脑-机接口使用 SSVEP 信号，最常用的方法是利用 SSVEP 携带的频率信息来判断使用者注视的方向，从而确定出受试者注视的目标刺激^[9,34-37]。刺激器同样采用电脑显示器上的闪烁方块，但每个方块采用不同的闪烁频率来编码。这一类型的 SSVEP 系统将在第七章详细介绍。Kelly 等人还实现了另外一种基于空间选择性注意的独立式 SSVEP 脑-机接口系统，视觉刺激为屏幕左右两个不同刺激频率的闪光块，通过选择性的空间注意 (selective spatial attention) 来调节两个不同频率 SSVEP 的幅度，从而实现左右两个目标的任意选择^[38,39]。

1.2.2.2 基于 mu 和 beta 节律的脑-机接口

mu 节律又称为中央前区 alpha 节律，产生于大脑的感觉运动皮层，频率范围为 8-12Hz。mu 节律和肢体的感觉运动有密切关系，可以被感觉刺激及肢体的主动或被动运动阻断。通常在 mu 节律出现的同时还伴随着 18-26Hz 的 beta 节律出现，肢体的真实运动或想象运动中伴随着由大脑运动皮层 mu/beta 节律的事件相关去同步化和同步化 (event-related desynchronization/synchronization, ERD/ERS) 引起的脑电能量变化^[40]。肢体运动或想象运动过程中，ERD 的空间分布特性符合大脑运动皮层的躯体对应分布：想象左右手运动时，最显著的 ERD 出现在对侧运动皮层的手对应区域；而想象脚动时 ERD 出现在脚对应区所在的中央区域^[41]。现有的基于 mu 和 beta 节律的 BCI 有两种模式：一种是采用机器

学习的算法根据 ERD 的空间分布特性来识别大脑的运动想象状态，比如区分想象左手、右手、脚、舌头等不同的状态^[10,42]；另一种是通过反馈训练让使用者能够实时调节 mu 和 beta 节律的幅度，从而控制一维或二维的光标运动^[11,43]。本文的第五章将详细介绍想象运动脑-机接口的设计和实现。

1.2.2.3 慢皮层电位脑-机接口

头皮脑电中的低频特征是皮层产生的缓慢的电压变化，这些电压的偏移可以发生在 0.5-10 秒的时间内，被称为慢皮层电位，负向的慢皮层电位与运动相关的皮层活动有关，而正向的慢皮层电位与皮层兴奋程度的下降有关^[44]。Birbaumer 等人的研究表明，经过训练受试者可以自主控制慢皮层电位的幅度升降，但这种训练往往需要持续很长的时间^[12,45]。基于慢皮层电位的 TTD (thought translation device) 系统已经在 ALS 病人中进行了临床应用的测试，并能实现基本的文字输入功能^[46,47]。

1.2.2.4 事件相关 P300 电位脑-机接口

事件相关电位是大脑对某种事件进行信息加工时诱发产生的一系列电活动。P300 是事件相关电位的一种，最早由 Sutton 等人使用 oddball 实验的方法记录到^[48]。P300 出现在新奇事件刺激后 250-450 毫秒内，是一种内源性诱发电位，没有外加刺激的新奇事件也能诱发出 P300。P300 电位通常采用相干平均的方法进行提取，需要进行多次平均才能得到 P300 波形。Donchin 等人设计了基于 P300 的虚拟打字机 P3Speller^[13]，一个 6×6 字符矩阵按行或列依次闪烁，行和列出现的次序是随机的，于是包含使用者想要输入字符的行或列的闪烁就是能够诱发出 P300 的靶刺激，通过检测 P300 所在的行和列就能确定使用者想要输入的字符。P300 脑-机接口的优点是使用者需要的训练很少，在 P300 脑-机接口的研究中，特征提取和分类算法是研究的热点，国际脑-机接口数据竞赛中多次出现有关 P300 分析的数据集^[49,50]。

1.3 基于脑电节律调制的脑-机接口系统

从信号分析的角度上看，在四种 BCI 系统常用的脑电成分中，事件相关电位、皮层慢电位以及瞬态视觉诱发电位属于相位锁定 (phase-locked) 的脑电低频响应，特征提取通常针对时域的波形特征来进行，相干平均的方法可用于提

高信号的信噪比；而稳态视觉诱发电位和 μ/β 节律属于频率较高的脑电节律性振荡，其特征体现为固定频带范围内的脑电能量变化，最常用的方法为频域分析方法，如功率谱分析^[40]。在由事件引起能量变化的脑电节律中， μ 和 β 节律为非相位锁定节律，时域波形平均的方法反而会削弱节律信号的特征，因此特征提取通常针对信号的能量变化进行；而稳态诱发电位同时具备相位锁定和能量变化两个特征，因此时域和频域的方法都可以使用。本文的第三章将具体介绍脑电节律信号的分析方法。

自主调节脑电节律的幅度是脑-机接口设计中常用的方法，如对 α 波和 μ/β 节律的幅度调节。本文提出了基于节律调制的脑-机接口的定义：通过调节与大脑活动有关的特定脑电节律来实现的脑-机接口。脑电信号由多个不同频率范围的节律成分组成，论文第二章将具体介绍脑电节律的生理背景。基于节律调制的脑-机接口系统可以使用较高频率的脑电节律，如 μ/β 节律和稳态视觉诱发电位，节律调制信号的特点可以概括为以下几方面：

1) 脑电节律信号的抗干扰能力强，通常脑电信号中的低频成分更容易受到由记录电极、眼动和肌电等其它生理信号引入的噪声干扰。例如眼动信号的主要分量为低频响应，因此在 ERP 的分析中去眼动干扰是一个重要环节，而在 μ 和 β 节律的分析中眼动干扰通常可以不予考虑。

2) 脑电节律调制通常是可持续过程，节律调制过程可以持续较长时间，而单次诱发响应通常只发生在刺激后几百毫秒时间内，因此相对于瞬态响应，节律调制信号有更高的信噪比，更容易实现单次任务的检测识别。在数据分析中，节律调制信号分析对系统时间精度的要求低于瞬态诱发脑电信号，采用时域平均的 ERP 分析方法需要保证每次实验的数据能够精确对准，而节律调制信号的分析允许较大的时间误差。

3) 脑电节律信号的分析有更丰富的信号处理方法，如在时域和频域都可以采用能量分析和同步化分析等算法。不同频率的脑电节律信号包含了大脑活动的大量信息，这些信息可能有助于大脑活动的特征提取，因此节律调制脑-机接口在算法研究和系统性能提高上有更大的潜力。

想象运动脑-机接口和稳态视觉诱发电位脑-机接口都属于节律调制的脑-机接口。由于 SSVEP 和 μ/β 节律有着较高的信噪比，因此这两类系统都有较好的性能，是实用化系统的可行性方案，也是当前脑-机接口研究的热点^[9-11,42,43,49,50]。SSVEP 系统的缺点是依赖于外部视觉刺激，在频率选择模式的系

统中目标的选择需要借助于眼动，因此不适用于完全瘫痪的病人，但它具有操作简单、速度快、可识别目标数多、训练少等优点；而想象运动脑-机接口则是独立的脑-机接口系统，但相对而言，其可识别任务数较少，需要更多的反馈训练，也需要更多的记录电极。尽管这两类系统存在上述差别，但它们都属于节律调制的脑-机接口，工作原理均为使用者对脑电节律的调制。SSVEP 系统的节律调制可以分为以下两种：第一种类型是频率选择性调制，通过注视不同频率的视觉刺激来改变 SSVEP 的频率特征^[9,34-37]；第二种是固定频率的幅度调制，通过空间选择性注意来自主调节 SSVEP 的幅度^[38]。想象运动系统的节律调制针对固定频率范围的运动相关脑电节律（mu 和 beta 节律），通过选择节律幅度调制的皮层空间位置来反映使用者的大脑想象运动状态^[42]。由于类似的节律调制机制，SSVEP 和 mu/beta 节律在信号分析方法上也有许多共同点，有关脑电节律信号分析的具体方法将在论文的第三章详细介绍。

由于脑电节律信号的以上特点，本文采用基于节律调制的脑-机接口系统来研究在线脑-机接口方法，采用 mu/beta 节律和 SSVEP 的节律调制为系统设计方案，研究了感觉运动皮层和视皮层的脑电节律调制现象（mu/beta 节律反映了大脑感觉运动皮层的活动状态，而 SSVEP 为视觉皮层对外界视觉刺激响应）；除此之外，本论文的工作还以基于视觉和触觉的多模式注意（multi-modal attention）脑-机接口方案为例，论证了使用多种不同感觉模式脑电节律的并行调制来实现脑-机接口系统的可行性。

1.4 脑-机接口系统存在的问题

1.4.1 数据传输率

脑-机接口系统的性能通常采用信息传输速率（information transfer rate, ITR）来评价，ITR 采用单位时间内传输的信息量来表示，单位为 bits/min。假定 BCI 系统可识别 N 种不同的任务，每种任务被选择的概率相同，如果选择的正确率是 P ，那么每次选择平均传输的信息量为^[1]：

$$B = \log_2 N + P \log_2 P + (1 - P) \log_2 [(1 - P)/(N - 1)] \quad (1-1)$$

在基于脑电信号的脑-机接口系统中，SSVEP 脑-机接口可识别目标数多，

正确率高，在实验室环境下测试的平均信息传输速率为 43bits/min^[36]。现有脑-机接口的通讯速率还远不能满足较复杂通讯的要求，如三维空间中的连续运动控制。数据传输率低是脑电信号脑-机接口的普遍问题，其原因可以归结于脑电信号较低的信噪比，提高系统的数据传输率可以从以下几个方面考虑：

- 1) 使用有效的信号处理算法来提高脑电信号的信噪比，例如信号的去噪、基于空间滤波的信号增强；
- 2) 设计适合脑电信号信息解码的新方法，从原始信号中挖掘出更多的有用信息来帮助提高脑电分类的正确率，如采用同步化分析的方法来得到大脑皮层不同区域相互协作的信息；
- 3) 采用基于分类器设计的机器学习算法来提高脑电分类的正确率；
- 4) 通过基于生物反馈的训练方法来提高系统使用的效率；
- 5) 增加系统可识别任务的种类，提高每次选择的信息量；
- 6) 增加脑电记录的通道数，使脑电数据中包含更多的有效信息。

在 BCI 系统中，可识别任务种类和识别的正确率有直接的联系，增加任务种类通常会直接导致正确率的下降，因此应根据数据传输率的大小来选择合适的任务数。另外，实用的 BCI 系统希望使用尽量少的记录电极，尽量短的系统训练时间，这种情况下要提高系统的数据传输率难度更大。

1.4.2 系统的独立性

根据是否需要肌肉控制的参与，可以把 BCI 系统分为独立型（independent BCI）和依赖型（dependent BCI）两种^[1]。依赖型 BCI 不适用于部分完全瘫痪的病人，例如基于多目标注视的 SSVEP 脑-机接口，系统的操作需要控制眼动的肌肉参与；独立型 BCI 的操作完全由使用者的大脑活动控制，甚至不需要任何的外界刺激，如基于想象运动的脑-机接口系统。通常依赖型 BCI 有更高的数据传输速率，能识别更多的任务种类，并且只需要少量的训练；而独立型 BCI 只能识别较少的任务种类，正确率较低，并且需要较长时间的训练。

BCI 系统的独立性还和工作模式有关。现有的 BCI 系统大部分以同步方式（synchronous mode）工作，系统的启动和关闭由手动操作完成，并且每次任务操作的开始和结束依赖于系统触发信号的提示；而异步方式（asynchronous mode）工作的 BCI 系统能自动检测大脑活动的状态，实现工作和空闲状态的自动切换，每次操作的时刻由使用者自由决定^[51]。使用异步的模式可以实现完全独立的 BCI

系统，其难点是要在保证系统操作正确的同时避免系统的假阳性（false positive）误操作。

1.4.3 系统的临床应用

BCI 研究的目的是要给运动障碍的残疾人提供与外界通讯的工具，而现有的 BCI 系统大部分都还处于实验室研究阶段，参加测试的通常是运动功能正常的志愿者，并且测试在干扰较少的脑电实验室环境中进行。要实现实用化的 BCI 产品，必须进行临床应用的测试。在完成实验室演示系统研究后，部分技术较成熟的 BCI 系统开始进行临床应用的尝试：德国 Tübingen 的 TTD 系统帮助部分 ALS 病人实现了简单的文字输入功能^[12]；美国 Wadsworth 中心将基于 mu 和 beta 节律调节的 BCI 应用到 SCI 病人，实现了较为复杂的二维平面光标运动控制^[43]；奥地利 Graz 的想象运动 BCI 系统帮助一名四肢瘫痪残疾人实现了假肢控制^[52]；本论文中的 SSVEP 系统被试用于帮助 SCI 病人操作家居环境控制器^[36]。

BCI 系统在临床上的应用可以概括为两种：第一种应用为帮助残疾人实现与外界环境的通讯，包括文字输入和光标移动等计算机操作、假肢和轮椅的运动控制、使用家居环境控制器来操作各种电器等；另一种为运动损伤的康复辅助，BCI 系统的使用可以帮助病人强化对相应的神经通路的刺激，例如使用大脑信号控制假肢的运动有助于恢复肢体的真实运动功能^[4]，BCI 和功能电刺激（functional electrical stimulation, FES）的结合能够通过刺激相应的肌肉而恢复部分肢体的运动功能^[53,54]。

1.5 从离线分析到在线应用的挑战

脑-机接口的研究有广阔的应用前景，正成为脑科学、康复工程、神经工程及人-机交互（human-computer interface, HCI）领域的一个热点。国内的脑-机接口研究起步较晚，开始于 20 世纪 90 年代末^[55]，最近几年有越来越多的实验室开始从事脑-机接口的研究，有文献报导的大部分研究成果为脑-机接口系统中的信号处理和模式分类算法^[56-62]，而关于在线脑-机接口系统以及临床应用的研究都还处于起步阶段，国内脑-机接口系统的实用化和产品化还有很长的路要走。

2006 年，Mason 等人在关于脑-机接口研究的调查中把现有的 BCI 系统分

为三种类型^[63]：信号转换系统（transducer）、演示系统（demonstration system）、辅助设备（assistive device）。在有文献报导的 79 个 BCI 研究组中，有 10 个实现了基于 BCI 的辅助设备（13%），26 个设计了 BCI 演示系统（33%），其余 43 个处在离线数据分析的阶段（54%）。不考虑 BCI 输出设备的实用性，可以把 BCI 系统的研究分为离线原型系统的设计和在线应用系统的实现两个步骤，演示系统和辅助设备都属于在线 BCI 系统。在线系统的实现以离线系统为基础，同时还需要解决系统的实时性和实用性等一系列问题。在 BCI 系统的研究中，离线系统通常采用数据分析来验证系统的可行性或评价算法的性能，而在线系统的研究更侧重于实用化系统的设计和应用，以及生物反馈训练等方面的研究。

1.5.1 系统的实时性

系统的实时性要求首先体现在数据采集上，脑电采集设备必须能够实现数据的实时获取。大部分产品化的脑电图机都提供了在线数据处理接口，有以下两种常见的实时数据获取方式：第一种是通过计算机和采集设备的接口实时获得在线数据，这种模式的实时性强，通常可以认为不存在延迟；第二种模式通过数据转移的方式来实现，例如可以通过网络通讯把实时数据发送到客户端的计算机，这种方式存在系统延迟，数据获取受到网络环境的影响，但通常情况下能够满足 BCI 在线系统的实时性要求。

系统的实时性还受到脑电信号在线处理的影响，在线处理环节包括了信号预处理、特征提取、模式分类和设备控制。在线分析与离线分析系统一个明显的差别是要求算法的因果性，在需要提供实时连续反馈的 BCI 系统中，信号处理和机器学习算法只能针对当前时刻之前的数据，这一约束对在线 BCI 系统中的机器学习提出了更大的挑战^[50]，提出了小训练样本（small training set）、组对组（session-to-session）、人对人（subject-to-subject）的分类器设计问题。在线系统需要考虑的另外一个问题是系统的运算速度，运算量过大的算法即使在离线分析中取得了很好的效果也无法应用到在线系统中。系统的运算速度主要取决于两方面因素：一方面由于脑电采集使用了较高的采样率，并且在研究中可能使用较多的通道数，所以在线处理的数据量较大；另一方面使用较复杂的信号处理和模式识别算法会导致很大的运算量，如独立分量分析（independent component analysis, ICA）、脑电逆问题（inverse problem）等。除了在因果性和运算量影响上的差别外，离线数据分析过程中允许人为干预，比如伪迹的去除、

样本的挑选、特征提取和分类器参数的选取；而在线系统不再允许有人工干预，所有的处理都需要由程序来自动完成，因此在线系统对算法的灵活性和稳定性提出了更高的要求。

1.5.2 脑-机交互适应学习

脑-机交互学习 (co-adaptive learning) 是当前脑-机接口研究的难点之一^[1,64]，脑-机交互适应包括了大脑学习 (brain learning) 和机器学习 (machine learning) 两个过程，其中大脑的学习过程需要借助基于在线系统的生物反馈训练 (biofeedback training) 来完成，而机器学习则是通过模式分类 (pattern recognition) 算法来实现。

生物反馈训练能提高使用者的 BCI 信息传输速率^[43,65]，由于大脑的可塑性 (brain plasticity)，在学习过程中神经通路被强化或者形成新的神经通路，从而导致大脑功能和结构发生变化，大脑学习通常需要较长的时间。机器学习过程由计算机完成，采用模式识别系统中的“训练-测试”模式，使用带类别标签的训练集数据进行特征提取和分类器设计，再对没有类别标签的测试集进行测试来判断测试样本的类别。现有脑-机接口系统的学习模式可以分为三种：独立的大脑学习、独立的机器学习、人脑和机器的协同学习。大脑学习型 BCI 系统通过生物反馈使训练者逐渐掌握自主调节脑电节律的技能^[11,12]；机器学习型 BCI 系统则通过模式分类的方法来识别受试者特定的思维状态^[66-69]；最近几年，能够在大脑学习过程中实时更新分类器参数的自适应机器学习算法开始出现在 BCI 系统中^[43]。以上三种方式中，脑-机协同训练方式有大脑学习和机器学习的同时参与，因此有更高的训练效率。

在线反馈系统和机器学习算法的结合使脑-机交互适应学习成为可能，有关脑-机交互适应学习的研究可以从以下几个方面进行：1) 在线特征提取参数优化和分类器参数的更新；2) 交互适应训练中训练模式的设计，如间隔式学习或同步式学习的模式；3) 对训练效果的评价，如比较训练过程中脑电信号特征和 BCI 系统性能的变化。

1.5.3 大脑空闲状态的检测

区分系统处于“空闲状态”或“工作状态”是在线脑-机接口系统需要解决的一个实际问题，检测系统的状态有助于实现完全独立的 BCI 系统。异步模

式的 BCI 系统具备系统状态实时监测的能力^[51]。大部分现有的 BCI 系统采用手动的方式来启动或关闭系统，系统工作过程中采用带触发信号的同步模式，在指定的时间范围内完成系统的操作。

与系统的“空闲状态”相对应的是大脑的“休息状态”，即使在休息状态下大脑仍然接收到来自外部环境的各种信息并产生相应的响应，因此休息状态下的大脑状态并不稳定，基于机器学习的休息状态检测方法并不能保证在线应用时的稳定性。大脑空闲状态的自动检测方法需要根据 BCI 系统的类型做相应的调整，在基于想象运动的脑-机接口系统中，感觉运动皮层 μ 和 β 节律的检测可以作为大脑空闲状态检测的基本依据，和视觉反馈有关的枕区 α 节律，受注意程度调控的前额区 θ 节律也能够提供用于检测大脑空闲状态的附加信息。在论文的第四章中将介绍一种系统“空闲状态”自动检测的方法，这种方法实现了在没有训练样本时大脑“休息状态”的自动检测。

1.5.4 系统的实用性

现有的脑-机接口系统大部分还处在实验室研究的阶段，而 BCI 研究的最终目标是要实现有实用价值的产品。考虑到用户群体的特殊性，脑-机接口系统从实验室演示系统阶段过渡到日常生活应用阶段还需要解决以下几个问题^[70]：

1) 系统使用的方便。系统的使用尽可能不需要技术协助，应使用可靠的记录电极以及友好的用户界面设计。采用机器学习方法能较大地提高系统的性能，但同时也提出了系统操作的新问题，例如系统的初始化设置、训练校准、在线学习等。解决 BCI 机器学习中的“小样本学习”和“组对组学习”等问题有助于提高系统使用的便捷性。

2) 系统能在噪声环境下稳定工作。与脑电实验室环境相比，日常家居环境中有较强的电磁干扰及其它环境噪声，在强干扰的环境下要确保脑电信号记录的质量，可以采用有源电极（active electrode）记录等方法。

3) 系统的便携性。系统中使用尽可能少的记录通道数，使用体积小的可携带式设备，采用无线通讯的数据传输方式，设计基于数字信号处理器（digital signal processor, DSP）的硬件平台，同时还需要保证系统的使用不影响使用者的其它日常活动。

1.6 论文的结构和内容

为了实现脑—机接口的实用化，本论文提出了基于脑电节律调制的在线脑—机接口方案，并对其进行了系统的研究。针对 BCI 系统存在的信息传输率低、使用过程繁琐、系统适应性差等问题，从脑电节律的信号处理以及机器学习算法入手，提出了一套适用于在线脑—机接口系统的特征提取和分类算法，并通过大量离线和在线实验的脑电数据分析验证了算法的有效性和实用性。在算法研究的基础上，采用 μ /beta 节律和 SSVEP 的节律调制方案设计并实现了想象运动在线脑—机接口、大脑同步化在线脑—机接口、稳态视觉诱发电位在线脑—机接口，并提出了基于多模式注意的脑—机接口系统原型。在临床应用中，SSVEP 脑—机接口被尝试用于帮助脊髓损伤病人控制家用电器^[36]。

论文第二章介绍了基于脑电节律调制的脑—机接口的生理基础，重点描述了运动相关脑电节律和稳态视觉诱发电位两种节律性脑电信号的生理背景，详细介绍了事件相关去同步化和同步化的机理。第三章从能量特征的量化、空间滤波增强算法、大脑同步化分析算法三个方面详细论述了节律性脑电信号的特征提取方法，最后介绍了算法在“手指运动诱发脑电分类”中的应用。第四章以机器学习理论为依据，提出了基于“小样本学习”的脑—机接口在线学习算法，从特征提取方法、参数选择方法、自适应分类算法三个方面提出了解决脑—机接口小样本学习过程中存在的“过学习 (overfitting)”问题的对策，最后介绍了这一系列方法在“小样本想象运动脑电分类”问题中的应用。第四章还提出了一种在无训练样本时“休息状态脑电自动检测”的方法。论文的第五章到第八章分别介绍了基于脑电节律调制的四种脑—机接口系统，对每一种脑—机接口系统的原理、平台、实验设计、数据分析和结果进行了具体的描述：第五章介绍了基于 μ 和 β 节律能量特征的想象运动在线脑—机接口的设计和实现；第六章研究了想象运动中大脑运动皮层的同步化现象并进一步实现了基于大脑同步化的在线脑—机接口系统；第七章介绍了 SSVEP 脑—机接口的实用化研究；第八章在单一模式脑—机接口系统的基础上提出了多模式脑—机接口系统的原型，并通过“多模式注意脑电数据分类”验证了多模式脑—机接口方案的可行性。论文最后是工作总结和对脑—机接口研究方向和应用前景的展望。

第 2 章 节律调制脑—机接口的生理基础

2.1 脑电节律

从 1929 年 Berger 首次记录到人脑 EEG 信号以来，有关脑电的研究和应用可以归纳为以下几个方向：EEG 信号的起源（神经生理和细胞学基础），EEG 在临床诊断和治疗中的应用，大脑神经认知功能的研究，脑—机接口的应用。

EEG 信号是由大量神经元放电活动中突触后电位（postsynaptic potential）引起的细胞外场电位（extra-cellular field potential）的总和，而 EEG 中波状节律的产生是群体神经元同步发放的结果^[71]。头皮脑电信号的频率范围为 0.1-100Hz，正常成人的脑电主要成分频率为 8-30Hz，根据产生的机制可以把脑电信号分为自发脑电（spontaneous EEG）和诱发电位（evoked potential），根据心理生理学的观点，通常把脑电信号按频率范围分成五种节律：0.1-3.5Hz 的 delta 节律，4-7.5Hz 的 theta 节律，8-13Hz 的 alpha 节律，14-30Hz 的 beta 节律和 30Hz 以上的 gamma 节律^[72]。尽管脑电的节律特性很早就被提出，但关于脑电节律机制的深入研究大都出现在 20 世纪 80 年代后，脑电节律的细胞学基础还处在研究过程中，现有的研究对脑电节律的认识还很有限。

外界刺激或大脑的认知活动会对脑电的节律产生影响，例如中央额区的 theta 节律被认为与思维活动（如问题的思考 and 解决）有关，而枕区的 alpha 节律被认为是指示视皮层状态的节律^[72]。在闭眼时视皮层处于空闲的状态，在枕区能记录到显著的 alpha 节律，而睁眼时则发生 alpha 波阻断的现象，alpha 节律在视觉、听觉、触觉等感觉刺激或思维活动（如心算）时受抑制的程度不同。

2.2 mu 节律

在大脑没有处于感觉处理或运动控制时的清醒状态下，在感觉运动皮层的区域能够记录到频率为 8-12Hz 的 mu 节律，由于其频率和 alpha 波相似，因此也被称为中央区 alpha 节律。mu 节律在频率和幅度上和枕部 alpha 节律类似，但在空间分布和所反映的生理功能上存在很大的差别。Adrian 和 Matthews 描述了“空闲系统（idling system）”的概念^[73]，大脑在既不接收也不处理感觉信息时处于空

闲状态,皮层的空闲程度可以反映出皮层是否参与了感觉信息的处理。枕区 alpha 节律被认为是视皮层区域的空闲节律 (idling rhythm), 而 mu 节律则被认为是感觉运动皮层区域的空闲节律^[74]。

mu 节律在肢体运动时会发生被阻断的现象, 这些运动包括主动或被动的运动。mu 节律的阻断现象和运动的计划准备有关, 执行运动的想法或是动作的准备都能抑制 mu 节律, 截肢病人假想被截除肢体的运动同样也能阻断 mu 节律^[75]。Arroyo 等人使用硬膜下电极记录研究了 mu 节律的功能意义, 研究结果证明了皮层 mu 节律和感觉运动皮层的躯体特定分布 (somatotopic arrangement) 特征的联系^[76]。在皮层的感觉运动区, 这种抑制 mu 节律的效应通常在大脑两侧皮层都存在, 但运动肢体对侧皮层上 mu 节律被抑制的程度要大于同侧皮层。除了肢体运动外, 轻微的触觉刺激也能产生 mu 节律的抑制效应, 并且在刺激肢体的对侧皮层区域内更为显著^[72]。

在 mu 节律变化的同时通常还伴随着 beta 节律的变化, beta 节律包含了 mu 节律的二次谐波成分, 而另外一部分 beta 节律是和 mu 节律相互独立的成分, 可以根据时间或空间分布上的差异对它们进行分离^[77,78]。Salmelin 等人的 MEG 研究认为 mu 节律来自感觉皮层, 而 beta 节律来自于运动皮层^[79,80]。

2.3 事件相关去同步化和同步化

感觉刺激等事件会引起脑电的变化, 和事件时间锁定 (time locked) 的群体神经元活动的变化产生事件相关电位 (event-related potential, ERP), 如诱发电位 (evoked potential, EP)。在 ERP 的检测中通常采用时域的平均技术, 使用平均方法的前提是假定 ERP 信号对事件刺激的响应延迟是固定的, 并且信号之间是相位锁定 (phase locked) 的, 而自发脑电为随机的背景噪声, 因此通过叠加平均可以提高 ERP 的信噪比。实际上诱发电位被认为至少有一部分是自发脑电信号各频率分量发生相位重组的结果^[81-83], 因此采用时域平均的方法得到的结果只是对真实情况的某种近似。和事件相关的另一种脑电变化是基于能量的变化, 由于多次实验中脑电信号频率分量相位分布的不一致性, 采用时域平均的方法反而会削弱非相位锁定信号的特征, 因此通常采用能量分析的方法来检测事件相关的脑电能量变化。睁眼时发生的脑电 alpha 节律的阻断现象是典型的非相位锁定能量变化, 这一类事件相关的脑电变化被称为脑电的事件相关去同步

化和同步化 (event-related desynchronization/synchronization, ERD/ERS) [40]。

2.3.1 事件相关去同步化和同步化的定义

事件相关去同步化 (ERD) 表现为在指定频带范围内, 脑电中同特定的神经活动事件相关的脑电节律能量的衰减过程; 与之相反的是事件相关同步化 (ERS), 表现为能量的上升过程[40]。根据 ERD/ERS 的定义, 计算出事件相关脑电在特定频带内相对于事件发生前的能量比就可以确认是否存在 ERD/ERS。事件相关脑电的 ERD/ERS 是一个时间过程, 文献[40]给出了计算多次实验平均 ERD/ERS 的步骤, 图 2.1 说明了 ERD/ERS 的计算过程:




图 2.1 (a) ERD 的计算; (b) ERS 的计算。(摘自[40])

- 1) 对所有单次实验脑电数据做某个指定频率范围的带通滤波;
- 2) 计算滤波后的脑电信号每个采样点值的平方, 得到能量曲线;
- 3) 将多次实验的脑电能量曲线做平均, 得到平均后的能量曲线;
- 4) 对能量平均曲线采用滑动时间窗进行平滑处理;
- 5) 以事件前参考时间段内的能量为参考, 计算能量改变的百分比。

图 2.1 (a) 是计算 μ 节律 ERD 的过程, 而图 2.1 (b) 计算了 β 节律的 ERS。假设事件发生后, 某特定频带内的脑电能量是 A , 事件发生前参考时间段内该频带内的能量是 R 。图 2.1 中有阴影的时间段内的能量定义为参考能量 R , 那么 ERD 和 ERS 定义了能量相对增加或减少的百分比, 可以表示为:

$$ERD/ERS = \frac{A-R}{R} \times 100\% \quad (2-1)$$

2.3.2 事件相关去同步化和同步化的生理基础

ERP 被认为是特定刺激引起的锥体神经元的一系列瞬态突触后响应, 而 ERD/ERS 是由神经网络中控制振荡的一个或多个参数的变化产生的, 三个因素决定了这些振荡的特性^[40]: 1) 神经元固有的膜特性和突触处理中的动态变化; 2) 由反馈环路形成的神经网络各元素之间相互联系的强度和范围, 可辨识的反馈环路包括短距离或长距离的丘脑-皮层或皮层-皮层的反馈环路; 3) 来自整体或局部神经传导系统的调制影响。如图 2.2 所示 (图中箭头的大小表示了响应的强弱), ERP 和 ERD/ERS 的产生机理不同, ERP 是皮层神经元对传入活动变化产生的响应, 也就是说 ERP 产生的机制可以理解为一个稳态系统对外界刺激的响应, 即现有的大脑皮层神经网络响应的结果; 而 ERD/ERS 是皮层内功能连通性 (functional connectivity) 变化的结果, 是由控制脑电各频率成分的神经元和中间神经元局部交互作用引起的变化, ERD/ERS 通常只针对脑电信号中某个特定的频率范围^[84]。

丘脑皮层系统 (thalamocortical system) 细胞的兴奋性增强会产生较低幅度的去同步化脑电^[85], 因此 ERD 可以反映由感觉认知信息的处理和运动行为的产生引起的皮层区域兴奋。ERD 程度上的增强或分布范围的扩大表示有更大范围的神经网络或更多的神经元群体加入到信息处理中, 能增强 ERD 的因素包括更高的任务复杂性和更高的任务执行效率; 而 ERS 的情况正好相反, 脑电幅度的上升是大量神经元同步活动的结果, 大量神经元的一致性活动表示皮层神经元

在信息处理中处于较低的兴奋状态^[86]。




图 2.2 事件相关脑电的产生机理：(a) ERD/ERS；(b) ERP。图中 TCR 为丘脑中继神经元 (thalamic relay cells)，RE 表示丘脑网状核 (thalamic reticular nucleus)。(摘自[40])

ERD 和 ERS 不是孤立发生的，感觉运动皮层局部化的 ERD 通常伴随着出现在邻近皮层区域内和信息处理有关的 ERS，也就是说感觉运动皮层局部化的皮层兴奋会对邻近区域的皮层活动产生抑制作用。例如在手动时，运动皮层内代表手的区域出现 ERD，而在代表脚的区域可能出现 ERS；在脚动时 ERD/ERS 的分布情况正好相反^[86]。

2.3.3 mu和beta节律的事件相关去同步化和同步化

在各种感知、决策和记忆的任务中，alpha 波频段的脑电 ERD 有相对较广的分布，任务复杂性和要求注意程度的提高也会增大 ERD 的程度。alpha 节律的阻断现象是 ERD 过程，不仅可以表现为对各种特定刺激响应，也可以出现在对刺激的期望或预备过程中，例如在视觉反馈刺激的预备注意过程中，在枕区能记录到最大的 ERD，而在听觉反馈出现之前在颞区能记录到最显著的 ERD^[87]。

除感觉和认知处理外，肢体的运动会感觉运动皮层区域引起 mu 和 beta

节律的 ERD/ERS。ERD 首先出现在运动肢体对侧的皮层区域，随着动作的完成而转变为对称的两侧分布。另外，ERD 的对侧性还和是否利手（dominant hand）有关：当利手运动时，其对侧皮层的 ERD 明显强于同侧区域；而在非利手运动时，对侧强同侧弱的效应减弱^[86]。在 ERD 消失后接着出现 beta 节律的 ERS，可以认为是 beta 节律在 ERD 后的反弹过程。

除了运动准备外，运动想象也能产生类似的 ERD/ERS，这说明运动想象和运动准备是通过相同的大脑结构来完成的，例如想象左右手运动在感觉运动皮层手对应区域内引起 mu 和 beta 节律的 ERD，其对侧强同侧弱的空间分布特点和计划执行真实运动时的 ERD 非常相似。在想象运动中通过反馈训练，对侧分布的 ERD 显著性增强，并且在同侧区域可以引起 ERS。想象运动的 ERD/ERS 表明大脑运动皮层参与到假想的肢体运动中，真实运动前和想象运动的 ERD 反映了感觉运动皮层相同类型神经网络的准备或调整活动^[86]。

感觉运动皮层具有躯体特定区的分布（somatotopic distribution），如图 2.3，按从顶叶中央区域到两侧颞叶的顺序，运动皮层依次为代表脚、手、脸、舌头运动的功能区域。真实运动和想象运动的 ERD/ERS 反映了运动皮层在肢体运动时兴奋或抑制的状态，因此不同肢体运动的 ERD/ERS 在头皮上的空间分布符合躯体特定区域分布的特征，例如脚的 ERD 位于中央区域，而手的 ERD 分布在两侧区域。




图 2.3 大脑初级运动皮层的躯体特定分布（摘自[88]）

2.4 稳态视觉诱发电位

2.4.1 稳态视觉诱发电位的定义

视觉诱发电位 (visual evoked potential, VEP) 是大脑视皮层对视觉刺激产生的响应, 反映了整个视觉通路输出的特征。瞬态视觉诱发电位 (transient VEP, TVEP) 是由间歇式的视觉刺激引起的大脑活动的短暂变化, 如果施加的视觉刺激为周期性的持续刺激, 每次刺激引起的响应互相混叠从而形成稳态视觉诱发电位 (steady state VEP, SSVEP), 这时大脑被认为处于稳态的兴奋过程。有多种方式的视觉刺激能够诱发出 VEP, 比如闪光刺激、图形翻转、光栅等, 棋盘格翻转 (checkerboard reversal) 是诱发 VEP 最常用的刺激模式, 这种刺激方式诱发出的 VEP 有较大的幅度和较高的可重复性^[89]。

2.4.2 稳态视觉诱发电位的特点

SSVEP 具有明显的周期性特征, 其频谱包含有一系列与刺激频率成整数倍关系的频率成分, 其中以基频和二倍频成分最为显著 (如图 2.4), 这种频率跟随的现象被称为 SSVEP 的节律同化, 或者称为视皮层的光驱动响应 (photic driving response), 对于视觉通路正常的人, 节律同化现象普遍存在。




图 2.4 13Hz 刺激诱发的 SSVEP: (a) 时域波形; (b) 幅度谱。

SSVEP 的幅度、相位和潜伏期等特征受很多因素的影响, 包括刺激频率、对比度、调制深度、刺激野的大小以及颜色等视觉刺激参数^[89]。对于相同物理属性的视觉刺激, SSVEP 的强度还与受试者对视觉刺激空间位置的注视有关。视觉刺激越接近视野中央, 诱发出的 SSVEP 幅度就越大; 越往外围, 诱发出的 SSVEP 的幅度越小。这一现象可以从以下两个方面来解释: 首先是因为视网膜中央凹处的视细胞密度最大, 因此对中央区域的刺激最为敏感; 其次, 源自视网膜中央的纤维投射到枕叶皮层后部, 而周围的纤维投射到枕叶内侧面, 因此头皮记录到的 SSVEP 更多是由中央纤维的投射产生。

SSVEP 的幅度还受到注意的调制, Müller 等人关于 SSVEP 空间选择性注意 (selective spatial attention) 的研究结果表明^[90,91]: 1) 当空间注意执行以后, 由闪光刺激诱发的 SSVEP 的幅度将会上升; 2) SSVEP 的注意调制有显著的对侧优势的现象, 即与空间注意位置相对的对侧皮层的幅度增强程度远远高于同侧皮层。

2.5 本章小结

脑电信号由各种频率的节律成分组成, 按照产生机制的不同, 由事件引起的脑电变化又可以分为 EP 和 ERD/ERS 两类。EP 是大脑皮层对感觉输入的直接响应, 而 ERD/ERS 是皮层内神经元交互作用的结果。本章介绍了 EP 和 ERD/ERS 的神经生理机制, 具体描述了大脑感觉运动皮层 mu 和 beta 节律的 ERD/ERS, 以及反映视皮层对视觉刺激响应的 SSVEP 的原理和特点。真实运动和想象运动过程中都伴随着 mu 和 beta 节律的 ERD/ERS, 其空间分布符合躯体特定分布的特点。在基于节律调制的脑-机接口系统设计中, 我们采用检测 mu 和 beta 节律 ERD/ERS 的空间分布特性作为想象运动脑-机接口设计的基本原理。SSVEP 的频率跟随特性以及注意对 SSVEP 的幅度调制效应是基于 SSVEP 的脑-机接口设计的生理依据。

第3章 脑电节律信号的特征提取方法

信号处理算法是脑-机接口系统的核心部分，其任务是从脑电信号中提取出反映大脑思维状态的信息。经过从皮层到头皮的传导，脑电信号的空间分辨率大大降低^[29]，并且脑-机接口中使用的事件相关诱发脑电幅度较弱，通常淹没在自发背景脑电中，因此需要使用信号处理的方法来去除背景噪声，从而提高信号的信噪比。另一方面，由于脑-机接口的任务是要把维数很高的原始脑电信号转换为简单的控制命令，因此需要使用信号处理的方法来提取可用于事件相关脑电分类的低维特征。在线脑-机接口的研究中，特征提取方法的选择还需要同时考虑算法的因果性和实时性。

脑-机接口中常用的信号处理算法可以概括为以下几大类^[92]：时域-频域处理方法、空间增强算法、脑电逆问题（EEG inverse problem）方法。基于时域和频域处理的方法主要包括模板匹配（template matching）、带通滤波（bandpass filtering）、傅立叶变换（Fourier transform）、AR 模型（autoregressive model）、小波变换（wavelet transform）等；空间处理算法有 Laplacian 空间滤波器、主分量分析（principle component analysis, PCA）、独立分量分析（independent component analysis, ICA）、共空间模式（common spatial pattern, CSP）等；脑电逆问题方法中常用的有基于偶极子模型（dipole model）和分布式源模型（distributed model）的求解方法。

想象运动脑电是脑-机接口信号处理算法研究的热点^[93-108]。计算带通能量是最简单的特征提取方法，选择想象运动脑电变化最显著的 mu 和 beta 节律所在的频带做带通滤波，再计算平均的脑电带通能量作为特征，想象运动在线脑-机接口系统经常采用这种方法^[43,93,94]；AR 模型的方法最早被用在奥地利 Graz 的想象运动脑-机接口中，使用 AR 谱估计得到的 AR 系数被用作脑电分类的特征，在此基础上还发展出了自适应的 AR 模型方法^[95,96]；共空间模式（CSP）方法用于想象运动脑电分类获得了很好的效果^[97,98]，通过空间滤波的方式来提取任务相关的脑电成分，从而大大提高了事件相关脑电的信噪比；独立分量分析（ICA）的方法把原始脑电分解成多个独立的源活动，根据各个独立分量在时域、频域和空域分布的特点可以找到提取任务相关脑电的空间滤波器^[42,99,100]；使用

偶极子模型和分布式源模型来求解想象运动的源定位也被用于想象运动脑电的特征提取^[101-103]，脑内源活动的位置和强度被用于识别想象运动的状态；想象运动脑电特征提取方法还有基于时-频-空域模式的特征提取方法^[104,105]、基于大脑同步化分析的特征提取方法^[106,107]、基于线性描述符的特征提取方法^[108]等。

论文的第二章介绍了在节律调制脑-机接口中使用的两种脑电节律信号：想象运动脑电和稳态视觉诱发电位。本章将以信号处理过程更为复杂的想象运动诱发脑电为例，详细说明节律调制信号的特征提取方法，并介绍这些方法在第二届脑-机接口数据竞赛“单次手指运动诱发脑电分类数据集”中的应用。

3.1 脑电节律信号的量化方法

本节以想象运动脑电数据为例来介绍脑电节律信号量化常用的方法，使用的数据来自我们设计的想象运动在线脑-机接口实验。在有视觉反馈的在线实验中，三种想象任务分别为想象左手、右手和脚的运动。实验中共采集 32 导联脑电信号，采样率为 256Hz（在线实验的详细内容见第五章）。图 3.1 为想象左手运动时右侧运动皮层 C4 导联和附近电极的脑电带通信号，第 2 秒为想象任务提示出现的时刻，时域带通滤波为 10-13Hz，带通信号中包含了 mu 节律的 ERD 过程，想象左手运动过程中右侧运动皮层 mu 节律的能量显著下降。




图 3.1 左手想象运动时右侧运动皮层区域的 mu 节律

3.1.1 基于能量特征的时域分析方法

在论文的第二章中提到，想象运动引起的 mu 和 beta 节律的 ERD/ERS 是非相位锁定的事件相关诱发脑电响应^[40]，因此采用时域平均的方法无法提取能量变化的特征，特征提取需要通过能量分析来完成。计算带通能量的方法是最简单的时域特征分析方法，为了能更好地理解 ERD/ERS 的幅度和相位特性，我们采用 Hilbert 变换^[109]求信号包络的方法来计算时域的能量变化过程，图 3.2 为 Hilbert 变换求信号包络的计算过程。

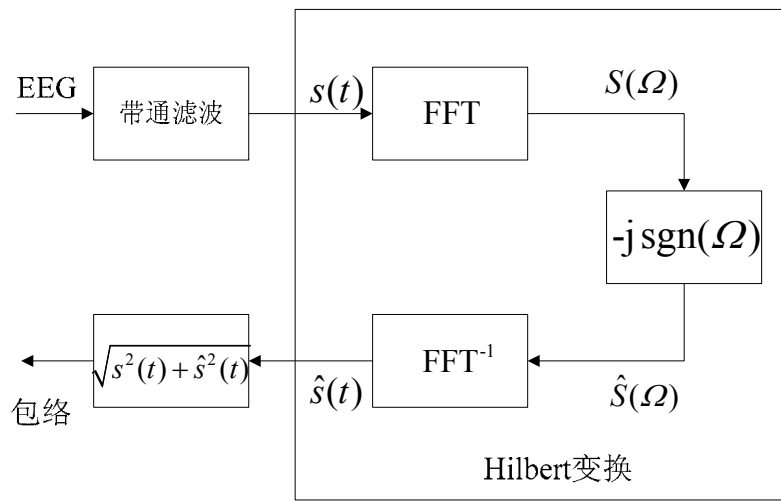


图 3.2 Hilbert 变换求信号包络示意图

假定经过带通滤波后原始脑电信号表示为 $s(t)$ ， $s(t)$ 的解析信号（analytic signal）定义为：

$$z(t) = s(t) + j\hat{s}(t) = A(t)e^{j\phi(t)} \quad (3-1)$$

解析信号的虚部为信号 $s(t)$ 的 Hilbert 变换，计算如下：

$$\hat{s}(t) = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{s(\tau)}{t - \tau} d\tau = s(t) * \frac{1}{\pi t} \quad (3-2)$$

Hilbert 变换器的频率响应为：

$$H(j\Omega) = -j \operatorname{sgn}(\Omega) \quad (3-3)$$

可以得到（3-2）式在频域的表达式：

$$\hat{S}(\Omega) = S(\Omega)H(\Omega) = S(\Omega)[-j\text{sgn}(\Omega)] \quad (3-4)$$

(3-1) 式中的 $A(t)$ 为解析信号的模，是原始信号 $s(t)$ 的包络 (envelop):

$$A(t) = \sqrt{s^2(t) + \hat{s}^2(t)} \quad (3-5)$$

(3-1) 式中的 $\Phi(t)$ 是信号的瞬时相位 (instantaneous phase):

$$\phi(t) = \arctan(\hat{s}(t) / s(t)) \quad (3-6)$$

可以采用信号包络来表示信号在时域的能量特征，图 3.3 显示了想象左右手运动两种任务在单次实验和多次实验时域平均两种情况下 μ 节律的波形和包络，用于平均的每类任务各有 120 次实验。对比单次实验和多次平均的信号包络，经过多次实验平均后两种想象任务的能量差别增强，C4 导联在想象左手运动过程中存在显著的 ERD (如图中箭头方向所示)，并且 ERD 的程度随着任务的执行逐渐增大；而想象右手过程中没有明显的 ERD，表现为能量的略微上升 (ERS)。对比单次任务和多次任务平均的时域信号波形，经过平均后两种想象任务的 μ 节律幅度都大大降低，远低于包络的平均结果，并且从平均的波形中无法区分两种想象运动状态。

根据 (3-6) 式来计算单次实验中 μ 节律的瞬时相位，假设相同想象任务下 μ 节律的包络 $A(t)$ 大致相同，对多次实验的时域波形平均可以近似表示为：

$$E(s(t)) = E(A(t) \cos(\phi(t))) = A(t)E(\cos(\phi(t))) \quad (3-7)$$

图 3.4 为想象左手运动状态下，C4 导联 μ 节律在 $t=3, 4, 5$ 秒三个不同时刻的瞬时相位分布，在 x 轴上 $[-\pi, \pi]$ 被分成等宽的五个区间。在三个不同时刻，瞬时相位的分布都接近于均匀分布，(3-7) 式中 $E(\cos(\Phi(t)))$ 接近于 0，因此时域波形平均将严重削弱 μ 节律。瞬时相位的概率分布证明了想象运动过程中 μ 节律的 ERD 是非相位锁定的。




图 3.3 想象运动脑电的波形和包络：（a）单次任务；（b）多次任务平均。




图 3.4 想象左手运动时 C4 导联脑电 mu 节律的瞬时相位概率分布

3.1.2 基于能量特征的频域分析方法

在频域常用的能量分析方法为功率谱估计的方法，谱估计的结果可用于特征提取参数的选择，如确定不同想象任务下差别最显著的脑电成分的频率。功率谱也可以直接作为能量特征用于分类。在想象运动脑电的特征提取中，最常用的功率谱估计方法是周期图法（periodogram）^[110]和 AR 模型谱估计（auto-regressive model）^[95,96]。

周期图可以用快速傅立叶变换（fast Fourier transform, FFT）计算，是较常用的谱估计方法，对信号 $x(n)$ 的 N 点观察数据，周期图的计算公式如下^[109]：

$$\hat{P}_{\text{PER}}(e^{j\omega}) = \frac{1}{N} \left| \sum_{n=0}^{N-1} x(n)e^{-j\omega n} \right|^2 \quad (3-8)$$

周期图法的谱分辨率较低，方差性能不好。图 3.5 是想象运动脑电在 C4 导联位置的周期图功率谱，想象左手运动对应了 mu 节律的 ERD 过程，能量远低于想象右手运动。单次实验数据周期图起伏较大，多次实验的平均周期图较为平滑，两种任务下 mu 节律能量的变化更为明显。根据多次任务平均的周期图可以确定想象左右手任务时 mu 节律变化最显著的频率范围为 10-13Hz，在想象运动单次任务分类时，可以选择周期图在 10-13Hz 范围内的功率谱密度值作为特征直接用于分类。




图 3.5 想象运动脑电周期图功率谱：（a）单次任务；（b）多次任务平均。

AR 谱估计是一种参数模型功率谱估计方法，假定所研究的过程 $x(n)$ 是由输入序列 $u(n)$ 激励一个线性系统 $H(z)$ 的输出，可以由已知的 $x(n)$ 来估计 $H(z)$ 的参数，再由 $H(z)$ 的参数来估计 $x(n)$ 的功率谱^[109]。在 AR 模型中，假定 $u(n)$ 是方差为 σ^2 的白噪序列， $u(n)$ 和 $x(n)$ 的输入输出关系表示为：

$$x(n) = -\sum_{k=1}^p a_k x(n-k) + u(n) \quad (3-9)$$

如果 $u(n)$ 的方差和模型的参数 a_1, \dots, a_p 已知，可以求得 $x(n)$ 的功率谱：

$$P(e^{j\omega}) = \frac{\sigma^2}{\left| 1 + \sum_{k=1}^p a_k e^{-j\omega k} \right|^2} \quad (3-10)$$

AR 系数的求解可参考[109]，如通过“自相关法”求解 Yule-Walker 方程得到。AR 模型是一个全极点的模型，更易于反映谱峰值。AR 谱估计的质量受到阶次 p 的影响， p 太小时谱过于平滑而反映不出谱峰，而 p 过大可能会产生虚假的峰值。脑电信号的 μ 节律在功率谱上表现为谱峰，因此 AR 模型适用于描述想象运动脑电的功率谱。图 3.6 是想象运动脑电带通信号（10-35Hz）在 C4 导联上的 AR 功率谱（阶次分别为 5 和 9）。以平均周期图作为参照，9 阶 AR 模型功率谱比 5 阶模型更为准确，更能准确地描述 μ 节律能量变化的特点。




图 3.6 C4 导联想象运动脑电多次实验平均 AR 功率谱：（a）5 阶模型；（b）9 阶模型。

3.2 脑电节律的空间增强算法

脑电信号处理中，空间滤波是常用的方法，通过多个导联数据的线性组合可以提高脑电信号的信噪比。在 μ 节律的分析中，常用的空间滤波器有两大类：一类是各导联权重固定的空间滤波器，如共平均参考 (common average reference, CAR) 和大小 Laplacian 方法 (large/small laplacian) [111]；另一类是基于数据统计分析的空间滤波方法，常用的有主分量分析 (PCA)、独立分量分析 (ICA) [99,100] 和共空间模式 (CSP) 方法 [97,98]。

共平均参考方法从原始信号中减去所有电极信号的均值，其计算方法如下：

$$V_i^{\text{CAR}} = V_i^{\text{ER}} - 1/n \sum_{j=1}^n V_j^{\text{ER}} \quad (3-11)$$

其中 n 是电极总数， V_i^{ER} 是电极上采集到的原始信号。通过 CAR 的计算，在大部分电极中共有的空间低频成分将被去除，因此 CAR 方法的作用为高通空间滤波 (high-pass spatial filtering)，可以突出在空间分布上高度集中的脑电成分。Laplacian 方法则从原始导联信号中减去电极附近的电极组的线性组合值，大小 Laplacian 分别选择次近邻 (next-nearest-neighbor electrodes) 和最近邻 (nearest-neighbor electrodes) 的电极组，Laplacian 的计算方法如下：

$$V_i^{\text{LAP}} = V_i^{\text{ER}} - \sum_{j \in S_i} g_{ij} V_j^{\text{ER}} \quad (3-12)$$

$$g_{ij} = (1/d_{ij}) / \sum_{k \in S_i} (1/d_{ik})$$

S_i 是由第 i 个电极周围的电极组成的集合， d_{ij} 是电极 i 与电极 j 的距离。Laplacian 方法强调了电极位置下方径向的源活动，同样起到空间高通滤波的作用，突出了在局部集中的源活动。

Wadsworth 实验室比较了 CAR 和两种 Laplacian 空间滤波器在 μ 节律调节脑电数据分析中的作用 [111]。在 64 导联脑电的分析中，对 C3 导联做空间滤波时使用的导联组合如图 3.7 所示，耳参考是一种双极导联 (bipolar lead) 的方式，记录到的是电极位置和耳参考处的电位差，Laplacian 方法使用了 C3 邻近的四个电极。由于 μ 节律的分布集中在感觉运动皮层区域，使用高通空间滤波的方法可以提高 μ 节律的信噪比。在图 3.7 的四种电极组合方式中，CAR 和大 Laplacian

获得了最好的效果；而小 Laplacian 由于过高的空间滤波频率，在去除了背景活动的同时也削弱了部分 mu 节律的活动，因此空间增强效果并不明显。




图 3.7 C3 导联使用空间滤波方法时使用的电极组合（摘自[111]）

3.2.1 基于共空间模式的空间滤波算法

共空域子空间分解（common spatial subspace decomposition, CSSD）方法最早用于提取多任务模式下多导联脑电中与某种特定任务相应的成分^[112]，这种方法用在 BCI 的单次手指运动脑电分类中取得了很好的效果^[65,66]。CSSD 方法可以采用源分解的模型来描述。假定 \mathbf{X}_A 和 \mathbf{X}_B 分别是两种不同任务模式诱发的脑电信号，除了任务外，两种模式其它的试验条件都相同，采用复合源的模型来描述事件相关脑电信号 \mathbf{X}_A 和 \mathbf{X}_B ：

$$\mathbf{X}_A = [\mathbf{C}_A \mathbf{C}_C] \begin{bmatrix} \mathbf{S}_A \\ \mathbf{S}_C \end{bmatrix} \quad \mathbf{X}_B = [\mathbf{C}_B \mathbf{C}_C] \begin{bmatrix} \mathbf{S}_B \\ \mathbf{S}_C \end{bmatrix} \quad (3-13)$$

其中 \mathbf{S}_A 和 \mathbf{S}_B 分别是代表任务 A 和 B 的源活动， \mathbf{C}_A 和 \mathbf{C}_B 由两种源活动相应的空间模式（spatial pattern）组成，空间模式为源活动在头皮各电极分布的权重向量； \mathbf{S}_C 是两种任务下共有的源活动， \mathbf{C}_C 由 \mathbf{S}_C 的空间模式组成。CSSD 方法的目的是提取出原始脑电信号中与任务 A 和 B 相关的特定成分 $\mathbf{C}_A \mathbf{S}_A$ 和 $\mathbf{C}_B \mathbf{S}_B$ 。将用 CSSD 算法设计出的空域滤波器表示为 \mathbf{F}_A （对应任务 A）和 \mathbf{F}_B （对应任务 B），设 \mathbf{X} 是原始多导联脑电信号，可以得到 \mathbf{X} 中任务相关的脑电成分为：

$$\mathbf{C}_A \mathbf{S}_A = \mathbf{F}_A \mathbf{X} \quad \mathbf{C}_B \mathbf{S}_B = \mathbf{F}_B \mathbf{X} \quad (3-14)$$

与任务 A 相关的成分 $C_A S_A$ 在 A 任务模式下的能量高于 B 任务模式，而与任务 B 相关的脑电成分 $C_B S_B$ 则在 B 任务模式下幅度更大。在脑电模式分类问题中，通常把任务转变为提取与任务相关的源活动，即提取 S_A 和 S_B ，这种方法也称为共空间模式（common spatial pattern, CSP）方法^[97,98]。

结合想象左右手运动脑电的分类来给出 CSP 算法的基本步骤，详细的证明可参考文献[112]。假定 X_L 和 X_R 分别是想象左右手运动两种任务下的多导联脑电信号， X_L 和 X_R 归一化的空间协方差阵 R_L 和 R_R 为：

$$R_L = \frac{X_L X_L^T}{\text{trace}(X_L X_L^T)} \quad R_R = \frac{X_R X_R^T}{\text{trace}(X_R X_R^T)} \quad (3-15)$$

X^T 是矩阵 X 的转置， $\text{trace}()$ 计算矩阵对角线元素之和。对同一任务模式下多次实验数据的协方差阵取平均值，得到平均的空间协方差矩阵 \overline{R}_L 和 \overline{R}_R 。对复合的空间协方差阵 R 做主分量分解：

$$R = \overline{R}_L + \overline{R}_R = U_0 \Sigma U_0^T \quad (3-16)$$

其中 U_0 是特征向量， Σ 是特征值的对角阵。定义预白化变换矩阵 P ：

$$P = \Sigma^{-1/2} U_0^T \quad (3-17)$$

利用预白化矩阵 P 对 \overline{R}_L 和 \overline{R}_R 进行如下变换得到 S_L 和 S_R ：

$$S_L = P \overline{R}_L P^T \quad S_R = P \overline{R}_R P^T \quad (3-18)$$

再对 S_L 和 S_R 分别做主分量分解：

$$S_L = U_L \Sigma_L U_L^T \quad S_R = U_R \Sigma_R U_R^T \quad (3-19)$$

可以证明 S_L 和 S_R 有相同的特征向量 U ，特征值对角阵之和为单位阵：

$$U_L = U_R = U \quad \Sigma_L + \Sigma_R = I \quad (3-20)$$

由式(3-20)可以假定 Σ_L 和 Σ_R 具有如下的形式：

$$\begin{aligned}\boldsymbol{\Sigma}_L &= \text{diag} \left[\overbrace{1 \cdots 1}^{m_L} \quad \overbrace{\sigma_1 \cdots \sigma_{m_C}}^{m_C} \quad \overbrace{0 \cdots 0}^{m_R} \right], \\ \boldsymbol{\Sigma}_R &= \text{diag} \left[\overbrace{0 \cdots 0}^{m_L} \quad \overbrace{\delta_1 \cdots \delta_{m_C}}^{m_C} \quad \overbrace{1 \cdots 1}^{m_R} \right],\end{aligned}\quad (3-21)$$

$\boldsymbol{\Sigma}_L$ 和 $\boldsymbol{\Sigma}_R$ 相应两个特征值之和为 1, 因此 \boldsymbol{S}_L 最大的特征值对应了 \boldsymbol{S}_R 中最小的特征值。取 $\boldsymbol{\Sigma}_L$ 中最大的 m_L 个特征值对应的特征向量组成 \boldsymbol{U}_l 来定义与左手运动相应的空间滤波矩阵 $\boldsymbol{S}\boldsymbol{F}_L$, 与右手运动相应的空域滤波阵 $\boldsymbol{S}\boldsymbol{F}_R$ 由 $\boldsymbol{\Sigma}_R$ 中最大的 m_R 个特征值对应的特征向量 \boldsymbol{U}_r 组成:

$$\boldsymbol{S}\boldsymbol{F}_L = \boldsymbol{U}_l^T \boldsymbol{P} \quad \boldsymbol{S}\boldsymbol{F}_R = \boldsymbol{U}_r^T \boldsymbol{P} \quad (3-22)$$

空间模式 $\boldsymbol{S}\boldsymbol{P}_L$ 和 $\boldsymbol{S}\boldsymbol{P}_R$ 为任务相关源活动在各电极分布的权重向量:

$$\boldsymbol{S}\boldsymbol{P}_L = \boldsymbol{W}\boldsymbol{U}_l \quad \boldsymbol{S}\boldsymbol{P}_R = \boldsymbol{W}\boldsymbol{U}_r \quad \text{其中 } \boldsymbol{W} = \boldsymbol{U}_0 \boldsymbol{\Sigma}^{1/2} \quad (3-23)$$

想象左右手运动的任务相关源活动 \boldsymbol{s}_L 和 \boldsymbol{s}_R 的计算如下:

$$\boldsymbol{s}_L = \boldsymbol{S}\boldsymbol{F}_L \cdot \boldsymbol{X} \quad \boldsymbol{s}_R = \boldsymbol{S}\boldsymbol{F}_R \cdot \boldsymbol{X} \quad (3-24)$$

根据 (3-19) 式主分量分解的过程可以得到如下结论:

$$\text{var}(\boldsymbol{S}\boldsymbol{F}_L \cdot \boldsymbol{X}_L) > \text{var}(\boldsymbol{S}\boldsymbol{F}_R \cdot \boldsymbol{X}_L) \quad \text{var}(\boldsymbol{S}\boldsymbol{F}_R \cdot \boldsymbol{X}_R) > \text{var}(\boldsymbol{S}\boldsymbol{F}_L \cdot \boldsymbol{X}_R) \quad (3-25)$$

对想象左右手运动脑电分类问题, \boldsymbol{s}_L 和 \boldsymbol{s}_R 的能量大小可以直接用于分类。图 3.8 为使用 CSP 算法分析想象左右手运动脑电数据得到的一组空间滤波器和空间模式, 两个空间滤波器中权重最大的分别为 C3 和 C4 导联, 对应了大脑感觉运动皮层的位置, 源分布的空间模式和空间滤波器一致。想象左手运动时, 右侧运动区有明显的 ERD 存在, 左侧皮层的能量高于右侧区域, 因此提取想象左手任务相关源活动的空间滤波器 $\boldsymbol{S}\boldsymbol{F}_L$ 更强调 C3 导联的活动, 而与右手任务相关的空间滤波器 $\boldsymbol{S}\boldsymbol{F}_R$ 则突出了 C4 位置代表的源活动。图 3.9 为 CAR 滤波后的 C3/C4 导联以及 CSP 滤波后得到的 $\boldsymbol{s}_L/\boldsymbol{s}_R$ 的 r^2 曲线 (r^2 用于描述特征的可分性^[1])。想象左右手两种任务下, 与 C3/C4 导联信号相比, 由 CSP 空间滤波得到的任务相关

源活动 s_L/s_R 的 r^2 值有明显的提高, r^2 的增大表明 CSP 滤波的方法能够提高任务相关脑电成分的信噪比。




图 3.8 想象左右手运动脑电 CSP 算法结果: (a) 提取左右手任务相关源活动的空间滤波器; (b) 任务相关源活动的空间模式。




图 3.9 CSP 滤波前后想象运动脑电的 r^2 曲线: (a) C3 导联和 s_L 的 r^2 曲线; (b) C4 导联和 s_R 的 r^2 曲线。

3.2.2 基于独立分量分析的空间滤波算法

独立分量分析 (independent component analysis, ICA) 是一种盲信源分离 (blind source separation, BSS) 的方法^[113]。如果 $\mathbf{x}(t) = [x_1(t), \dots, x_m(t)]^T$ 是多通道随机信号, 独立分量分析可以用图 3.10 所示的“混合-解混”模型来描述。假设观测信号 $\mathbf{x}(t)$ 是由一组相互独立的源信号 $\mathbf{s}(t) = [s_1(t), \dots, s_n(t)]^T$ 经过线性变换 \mathbf{A} 混合在一起, 表示为:

$$\mathbf{x}(t) = \mathbf{A}\mathbf{s}(t) \quad (3-26)$$

通常假定源信号的个数小于或等于观测信号的通道数。在模型中, 源信号 $\mathbf{s}(t)$ 和混合矩阵 \mathbf{A} 都是未知的, 只有混合后的 m 个时间过程可以观测到。独立分量分析就是要在混合阵 \mathbf{A} 及源信号 $\mathbf{s}(t)$ 未知的条件下求解混矩阵 \mathbf{W} , 使得解混后得到的信号 $\mathbf{u}(t) = [u_1(t), \dots, u_n(t)]^T$ 逼近源信号 $\mathbf{s}(t)$ 。 $\mathbf{u}(t)$, $\mathbf{s}(t)$ 和 $\mathbf{x}(t)$ 的关系表示为:

$$\mathbf{u}(t) = \mathbf{W}\mathbf{x}(t) = \mathbf{W}\mathbf{A}\mathbf{s}(t) \quad (3-27)$$

解混矩阵 \mathbf{W} 的逆矩阵 \mathbf{W}^{-1} 的第 j 列表示的是矩阵 \mathbf{u} 中第 j 行的独立分量在各个测量位置处的分布强度, 也就是独立分量的空间分布模式。在独立分量分析的结果中, 这个空间模式是固定不变的, 独立分量分析的结果是把观察信号 $\mathbf{x}(t)$ 分解成了统计独立、空间分布稳定的时间过程 $\mathbf{u}(t)$ 。

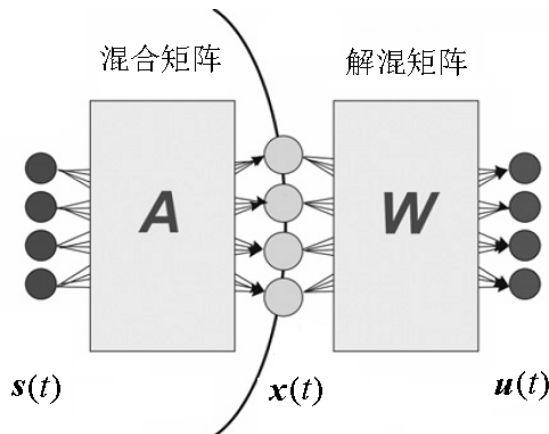


图 3.10 ICA 的“混合-解混模型”

独立分量分析是一个优化问题, 目标是在独立性判据最优的意义下寻找近似解, 使 $\mathbf{u}(t)$ 中的各分量尽可能相互独立^[114]。独立分量分析常用的方法有: 互信息极小法 (minimization of mutual information)^[113]、信息极大 (information

maximization, Infomax) 法^[115]、FastICA 法 (也叫固定点算法)^[116]、极大似然 (maximum likelihood) 法^[117]等。在信息论的框架下, 可以大致统一这些方法的独立性判据^[118]。非高斯程度可以作为提取独立分量时独立程度的判据, 当方差为常数时, 高斯分布具有最大熵, 最小化互信息等同于最大化各分量的非高斯性的总和, 从而保证各分量相互独立。Infomax 算法通过对引入的非线性环节输出的联合熵最大化来间接实现预测源信号的互信息最小化。互信息的最小化还可以表示为负熵 (negentropy) 的最大化, 而负熵可以通过近似化的方法来得到, 这是 FastICA 算法的原理。极大似然法和 Infomax 法在判据上基本一致。有关以上算法的具体内容可参考文献[114]。

在生物医学信号和图像处理中, 独立分量分析常用于以下领域: 脑电诱发电位的单次提取^[119,120], 脑电伪迹的去除^[121,122], 胎儿心电的提取^[123,124], 功能磁共振成像大脑兴奋区域的检测^[125,126]等。其中, 脑电信号处理是 ICA 最早被引入的研究领域, ICA 被广泛用于脑电的成分提取和分析理解^[42,64,83,99,100,127-130]。多导联脑电信号中往往包含了任务响应、背景脑电、检测过程中的噪声等各种成分。在独立分量分析中结合时域、频域和空域的先验知识, 能够挑选出与脑电中某个特定成分相应的一个或多个独立分量, 从而用于提取原始信号中与任务相关的特定成分。大脑状态的变化往往表现为与大脑皮层功能相应的特定频率成分在能量和空间分布上的差异, 因此对独立分量分析中的空间分布模式矩阵 W^{-1} 的分析尤其重要。在脑电模式分类的应用中, 使用源空间分布模式的先验知识进行约束, 可以找到一个或多个与特定任务模式相应的独立分量, 使用解混矩阵 W 相应的行向量作为空间滤波器可以提取出与特定任务相应的脑电源活动。独立分量代表的源活动在不同任务模式下存在的差异是 ICA 用于多模式脑电分类的基础, 使用 ICA 方法的目标是通过独立分量的挑选来得到用于提取任务相关源活动的空间滤波器。

图 3.11 为想象运动脑电独立分量的空间模式, 独立分量分析使用 EEGLAB^[131]工具箱。用于独立分量分析的数据为 32 导联想象运动脑电, 采样率为 256Hz, 记录时间为 379 秒, 包含了想象左右手运动任务各 20 次。数据矩阵的大小为 32×97024 , 得到 32 个独立分量。从图 3.11 中的空间模式可以找到几个典型的 EEG 独立分量, IC5 和 IC6 是主要反映眼动的独立分量, IC2 反映了枕区的 alpha 节律, IC3 为中央区的 alpha 节律, IC8 和 IC13 分别代表了左右运动区的 mu 节律, IC9 反映了前额区域的活动, IC21 则是反映肌电的独立分量。




图 3.11 想象运动脑电独立分量的空间模式

完成 ICA 后需要对独立分量进行优选，对独立分量的理解可以结合时域、频域和空域的信息。例如眼动干扰的独立分量在时域波形上有明显的眼动信号的特征，在频域内能量集中在低频部分，而在空间分布上位于前额区域内。图 3.12 显示了从图 3.11 的 32 个独立分量中选择的 4 个典型的独立分量。图 3.12 (a) 和 (b) 的独立分量代表了想象任务相关的运动皮层 mu 节律：从空间分布上看，位于两侧感觉运动皮层；从功率谱看，位于 mu 节律的频带范围内；对比左右手

想象两种任务下的谱分布,两个独立分量分别与左右运动皮层的 ERD 分布一致。图 3.12 (c) 和 (d) 中的独立分量分别代表了眼动信号和枕区 alpha 节律的源活动,在左右手想象两种任务下,这两个独立分量的功率谱没有明显差别;另外,枕区 alpha 节律在频域内和 mu 节律混叠,但在空间分布上两者有显著差别。因此,在想象运动脑电的分析中,可以使用 mu 节律独立分量对应的空间滤波器来提取想象左右手运动任务相关的 mu 节律,同时去除原始信号中混入的枕区 alpha 波等背景脑电。




图 3.12 独立分量选择: (a) 运动皮层右侧 mu 节律; (b) 运动皮层左侧 mu 节律; (c) 眼动信号; (d) 枕区 alpha 波。

假定 X 是原始多导联脑电信号,左右运动皮层 mu 节律相应的空间滤波器为 W_L 和 W_R , 想象左右手运动的任务相关独立分量 u_L 和 u_R 的计算如下:

$$u_L = W_L \cdot X \quad u_R = W_R \cdot X \quad (3-28)$$

图 3.13 为使用 CAR 滤波后的 C3/C4 导联以及经 ICA 空间滤波得到的 u_L/u_R 的归一化功率谱和 r^2 曲线。在想象左右手运动两种任务下,与 C3/C4 导联信号相比,由 ICA 空间滤波器得到的独立分量 u_L/u_R 的 r^2 值有明显的提高。基于 ICA 的空间滤波方法也能提高想象运动脑电 mu 节律的信噪比,其效果与 CSP 方法大致相同(参见图 3.9)。




图 3.13 ICA 滤波前后想象运动脑电 r^2 曲线：(a) C3 导联和 u_L 的 r^2 ；(b) C4 导联和 u_R 的 r^2 。

基于 CSP 和 ICA 两种不同方法的空间滤波器设计在想象运动脑电模式分类应用中有各自的特点：1) 从空间增强的效果上看，两种空域滤波的方法能得到类似的结果，即通过数据集的统计分析后设计出的空间滤波器都能提取出与特定任务相应的源成分，从而提高了任务诱发脑电的信噪比；2) 从想象运动的生理背景看，两种方法得到的空间滤波器在空间模式上具有相似性，都能反映出想象运动过程中 μ 节律 ERD 分布的躯体特定区域性，真实反映了大脑运动皮层的源活动；3) 从空间滤波器的设计过程看，CSP 方法的性能依赖于预处理过程的参数选取，时间窗和频率窗的选择对空间滤波器的性能尤其重要，而 ICA 方法关键在于独立分量的选择；4) CSP 方法的使用更为方便，不需要过多的人工干预，适合于在线系统的使用，而独立分量分析及优选过程的计算量要远大于 CSP 方法，独立分量需要结合较多的先验知识进行人工选择，带约束条件的 ICA (constrained ICA, cICA) ^[132,133] 方法是解决独立分量自动选择问题的可行方法；5) CSP 的设计过程依赖于数据的任务标签，而 ICA 可以使用无监督的模式，因此数据的准备和选择更为方便；6) 从源分解模型上看，ICA 方法更为灵活，可以求得多个独立的信号源，有可能得到更为细致的源活动，从而更准确地描述大脑的真实源活动，而 CSP 方法的出发点是要寻找能最大化两类样本能量差别的空间投影方向，提取出的成分反映的是不同任务模式下的脑电能量差别，可能并不能准确地描述真实的大脑源活动。

3.2.3 多类问题的扩展

前面介绍了基于 CSP 和 ICA 的空间滤波方法在两种任务脑电模式分类中的应用，Dornhege 等人将两类 CSP 算法扩展到多分类的应用中^[134]，多分类 CSP 算法有以下三种不同的形式：

1) 将多分类问题转化为多个两分类问题，对每个两分类问题分别使用两类 CSP 算法，最后的分类结果由组合分类器来决定。这样一来， N 类问题被转化为 $N \times (N-1)/2$ 个两分类问题，图 3.14 描述了三分类情况下这一算法的流程（假定三类任务分别为任务 A，任务 B 和任务 C）。




图 3.14 基于两类任务 CSP 的三分类算法框图

2) 把 N 类问题转化为 N 个新的两分类问题（两类分别为一类样本及所有剩余样本，one-versus-rest）^[134,135]，简称为 OVR 方法。这样相应的空域滤波器设计可以得到 N 组结果，使用 N 组空间滤波器分别处理每类样本，每个样本都将得到 N 组滤波结果作为特征，然后采用多分类器进行分类。与方法 1 相比，OVR 算法选择的空域模式更少，得到的特征维数更低，因此更有利于分类器的设计。图 3.15 为三分类问题的 OVR 算法流程。




图 3.15 CSP 三分类 OVR 算法框图

3) 多类协方差矩阵的同步联合对角化方法。这一方法的思路与两分类 CSP 算法类似，通过矩阵联合对角化设计出 N 组用于提取 N 种任务相关成分的空间滤波器，图 3.16 为采用三类联合对角化 CSP 算法的分类算法框图。




图 3.16 CSP 三分类联合对角化算法框图

假定 \mathbf{X}_L , \mathbf{X}_R 和 \mathbf{X}_F 分别是想象左右手运动和想象脚动三种任务下的多导联脑电信号，归一化的空间协方差阵可以写作：

$$\mathbf{R}_L = \frac{\mathbf{X}_L \mathbf{X}_L^T}{\text{trace}(\mathbf{X}_L \mathbf{X}_L^T)} \quad \mathbf{R}_R = \frac{\mathbf{X}_R \mathbf{X}_R^T}{\text{trace}(\mathbf{X}_R \mathbf{X}_R^T)} \quad \mathbf{R}_F = \frac{\mathbf{X}_F \mathbf{X}_F^T}{\text{trace}(\mathbf{X}_F \mathbf{X}_F^T)} \quad (3-29)$$

对复合的空间协方差阵 \mathbf{R} 做主分量分解：

$$\mathbf{R} = \overline{\mathbf{R}}_L + \overline{\mathbf{R}}_R + \overline{\mathbf{R}}_F = \mathbf{U}_0 \boldsymbol{\Sigma} \mathbf{U}_0^T \quad (3-30)$$

其中 \mathbf{U}_0 是特征向量， $\boldsymbol{\Sigma}$ 是特征值的对角阵。预白化变换矩阵 \mathbf{P} 为：

$$\mathbf{P} = \boldsymbol{\Sigma}^{-1/2} \mathbf{U}_0^T \quad (3-31)$$

利用 \mathbf{P} 对 $\overline{\mathbf{R}}_L$ ， $\overline{\mathbf{R}}_R$ 和 $\overline{\mathbf{R}}_F$ 进行如下变换后得到 \mathbf{S}_L ， \mathbf{S}_R 和 \mathbf{S}_F ：

$$\mathbf{S}_L = \mathbf{P} \overline{\mathbf{R}}_L \mathbf{P}^T \quad \mathbf{S}_R = \mathbf{P} \overline{\mathbf{R}}_R \mathbf{P}^T \quad \mathbf{S}_F = \mathbf{P} \overline{\mathbf{R}}_F \mathbf{P}^T \quad (3-32)$$

通过近似联合对角化^[136]，可以找到正交矩阵 \mathbf{U} 和近似对角阵 $\boldsymbol{\Sigma}_L$ ， $\boldsymbol{\Sigma}_R$ 和 $\boldsymbol{\Sigma}_F$ ，满足如下关系：

$$\mathbf{U} \mathbf{S}_L \mathbf{U}^T = \boldsymbol{\Sigma}_L \quad \mathbf{U} \mathbf{S}_R \mathbf{U}^T = \boldsymbol{\Sigma}_R \quad \mathbf{U} \mathbf{S}_F \mathbf{U}^T = \boldsymbol{\Sigma}_F \quad (3-33)$$

根据 (3-30) 式， $\boldsymbol{\Sigma}_L$ ， $\boldsymbol{\Sigma}_R$ 和 $\boldsymbol{\Sigma}_F$ 具有如下关系：

$$\boldsymbol{\Sigma}_L + \boldsymbol{\Sigma}_R + \boldsymbol{\Sigma}_F = \mathbf{I} \quad (3-34)$$

空间滤波器设计时特征值的选择基于以下假设^[134]： N 类问题中，如果同一类中的两个特征值 (λ_1 和 λ_2) 和其它各类特征值的均值比 ($(1-\lambda_1)/(N-1)$ 和 $(1-\lambda_2)/(N-1)$) 的乘积为 1，那么这两个特征值对空间滤波器的选择同等重要。因此空间滤波器设计时 $\boldsymbol{\Sigma}_L$ ， $\boldsymbol{\Sigma}_R$ 和 $\boldsymbol{\Sigma}_F$ 中特征值的选择根据下式进行：

$$\text{score}(\lambda) = \max(\lambda, (1-\lambda)/(1-\lambda+(N-1)^2\lambda)) \quad (3-35)$$

分别取得分最高的特征值对应的 \mathbf{U}_L ， \mathbf{U}_R 和 \mathbf{U}_F 来得到空间滤波器：

$$\mathbf{S}\mathbf{F}_L = \mathbf{U}_L^T \mathbf{P} \quad \mathbf{S}\mathbf{F}_R = \mathbf{U}_R^T \mathbf{P} \quad \mathbf{S}\mathbf{F}_F = \mathbf{U}_F^T \mathbf{P} \quad (3-36)$$

空间模式 $\mathbf{S}\mathbf{P}_L$ ， $\mathbf{S}\mathbf{P}_R$ 和 $\mathbf{S}\mathbf{P}_F$ 为任务相关源活动在各电极分布的权重向量，

$$\mathbf{S}\mathbf{P}_L = \mathbf{W}\mathbf{U}_L \quad \mathbf{S}\mathbf{P}_R = \mathbf{W}\mathbf{U}_R \quad \mathbf{S}\mathbf{P}_F = \mathbf{W}\mathbf{U}_F \quad \text{其中 } \mathbf{W} = \mathbf{U}_0 \boldsymbol{\Sigma}^{1/2} \quad (3-37)$$

三种想象任务相关的源活动 s_L , s_R 和 s_F 的计算如下:

$$s_L = SF_L \cdot X \quad s_R = SF_R \cdot X \quad s_F = SF_F \cdot X \quad (3-38)$$

图 3.17 为使用三类联合对角化 CSP 算法分析三种任务想象运动脑电数据得到的一组空间滤波器和空间模式, 源分布的空间模式对应了大脑感觉运动皮层 ERD 的三个主要区域: 想象左右手运动时, ERD 的分布主要位于运动皮层的对侧区域; 想象脚动时 ERD 分布在中央区域。使用这组空间滤波器能够提高三种想象运动状态下 mu 节律的信噪比。




图 3.17 使用 CSP 三类联合对角化算法分析想象运动脑电得到的空间滤波器和空间模式: (a) 空间滤波器; (b) 空间模式。

基于 ICA 的空间滤波方法在多分类问题中的应用方法和图 3.16 中的 CSP 方法相似。拼接多类任务的脑电数据做一次独立分量分析, 然后根据先验知识和带标签的训练数据集来选取与特定任务相关的独立分量, 从而得到多个空间滤波器, 最后采用多分类器进行分类。与两分类问题相比, 独立分量的挑选过程更为复杂, 在实际应用中, 通常使用带类别标签的数据集来检验使用空间滤波器进行特征提取和分类的效果。

3.3 脑电节律的同步化分析

脑电的同步化现象被认为是不同脑区功能协作和整合的重要表现，是脑科学研究中的热点^[137,138]。神经科学的研究表明：不论是在单个神经元对，或者大范围的神经元群体间；还是在大脑皮层的某一区域，或者是不同的区域之间，同步化现象都广泛存在。认知行为必须依靠广泛分布在大脑中的不同功能分区自身的整合及相互间的持续协作来完成。同步化活动有可能是大脑把特定的皮层及皮层下区域整合为一个整体，从而完成行为及认知功能的主要机制。大脑的同步化研究可以采用微观和宏观的方法，基于微电极记录的动物实验通常研究单一感觉模式内小范围区域内的同步现象；多个脑区之间的大范围同步多采用宏观电极记录方式来研究，例如脑电图、脑磁图和皮层电位图等。

在基于节律调制的脑-机接口中，计算大脑不同区域间脑电信号的同步化可以作为一种特征提取方法。在大脑不同的思维状态下，同步化在不同脑区的空间分布特征可以作为特征提取的依据。例如，在想象运动过程中，不同的肢体运动想象状态对应了运动皮层不同区域的同步化特征，因此 μ 和 β 节律的同步化可以用于想象运动的分类。同步化特征与想象运动脑电分类常用的能量特征因为在生理机理上的差异而有一定的独立性，可以进一步通过特征结合的算法来提高想象运动脑-机接口的性能。

3.3.1 脑电同步化分析算法

Quiroga 等人比较了脑电信号同步化分析常用的算法，包括互相关、相干函数、非线性依赖、互信息、相位同步化等方法^[139]。计算互信息方法需要较多的数据来预测联合概率密度，因此性能不如其它算法稳健；其它各种算法能得到类似的结果，都适用于量化分析脑电信号的同步化特征。下面介绍脑电同步化分析中常用的互相关，相干函数和相位同步化方法。

1) 互相关 (cross-correlation function)

对两个同时测量的时间序列 $x_n, y_n, n = 1, \dots, N$ ，互相关函数定义如下：

$$c_{xy}(\tau) = \left\langle \left(\frac{x_i - \bar{x}}{\sigma_x} \right) \left(\frac{y_{i+\tau} - \bar{y}}{\sigma_y} \right) \right\rangle_i = \frac{1}{N-\tau} \sum_{i=1}^{N-\tau} \left(\frac{x_i - \bar{x}}{\sigma_x} \right) \left(\frac{y_{i+\tau} - \bar{y}}{\sigma_y} \right) \quad (3-39)$$

\bar{x}, σ_x 分别表示 x 的均值和标准差， τ 表示时移，互相关函数给出了 x 和 y 间线性同步的一种度量，互相关函数的取值范围为 $[0, 1]$ ，0 表示 x 和 y 之间不存在同步

化，而 1 表示了最大的同步化程度。

2) 相干函数 (coherence function)

相干函数定义为 x 和 y 归一化的互功率谱幅度：

$$\Gamma_{xy}(\omega) = \frac{|\langle C_{xy}(\omega) \rangle|}{\sqrt{\langle C_{xx}(\omega) \rangle} \sqrt{\langle C_{yy}(\omega) \rangle}} \quad (3-40)$$

其中 $C_{xx}(\omega)$ 为 x 的自功率谱， $C_{xy}(\omega)$ 为 x 和 y 的互功率谱：

$$C_{xx}(\omega) = X(\omega)X^*(\omega) \quad C_{xy}(\omega) = X(\omega)Y^*(\omega) \quad (3-41)$$

$X(\omega), Y(\omega)$ 分别表示 x 和 y 的傅立叶变换。 $C_{xy}(\omega)$ 为 x, y 互相关函数的傅立叶变换，相干函数与互相关函数包含了同样的信息。相干函数表示了在频率 ω 处， x 和 y 相应频率成分的同步化程度。相干函数的取值范围也为 $[0, 1]$ ，0 表示 x 和 y 在频率 ω 处不存在同步，1 表示频率 ω 处两信号分量的完全同步化。

3) 相位同步 (phase synchronization)

相位同步现象广泛存在于两个振荡信号之间，相位同步的分析方法包括瞬时相位的求解和锁相值的量化两个步骤。根据 (3-6) 式，由信号 $x(t)$ 的解析信号可以求得信号在时刻 t 的瞬时相位 $\Phi(t)$ 。两个信号 $x(t)$ 与 $y(t)$ 的瞬时相位差为：

$$\phi_{xy}(t) = \phi_x(t) - \phi_y(t) \quad (3-42)$$

相位锁定值 (phase locking value, PLV) 定义为^[140]：

$$PLV = \left| \left\langle e^{j\phi_{xy}(t)} \right\rangle_t \right| \quad (3-43)$$

$\langle \rangle_t$ 表示在某个时间段内求均值。PLV 的取值范围为 $[0, 1]$ ， $x(t)$ 与 $y(t)$ 完全不同步时，瞬时相位差服从均匀分布，PLV 值为 0；当 $x(t)$ 与 $y(t)$ 完全同步化时，瞬时相位差为常数，PLV 值为 1。

互相关函数和相干函数包含了相同的信息。相干函数是频率的函数，而 EEG 中的同步现象往往仅限于有限的带宽范围内，因此相干函数被普遍应用于神经科学的研究。与相位同步相比，相干分析的局限性可以概括为以下两个方面：首先，相干分析在很大程度上依赖于被测信号的平稳性，而大脑的活动是非平稳的；另外一方面，相干分析计算谱的相关性，因而不能分离出信号间幅度和

相位的相互作用，无法清楚地描述相位或幅度同步的相对重要性。在大脑的整合中，相位锁定被认为是直接相关的生理机制，而相干的方法则是一种间接的同步测量方法。相位同步方法的优点是直接把给定频带范围内的信号相位信息从幅度信息中分离出来，并不要求信号是平稳的。对宽带信号来说，瞬时相位在神经生理学上很难解释，相位同步的方法通常只用于分析脑电信号中某些特定的窄带成分，如想象运动中的 μ 节律。

3.3.2 想象运动脑电同步化分析

在想象运动过程中，大脑运动皮层的不同区域间存在着同步化的关系，主要体现为辅助运动区 (supplementary motor area, SMA) 和初级运动皮层 (primary motor cortex, M1) 区域的大范围同步化^[141]。图 3.18 为有典型同步化特征的想象左右手运动单次实验脑电波形 (想象过程中的 2 秒数据)，带通信号为 10-15Hz 的 μ 节律。选择代表 SMA 和左右 M1 区域的 FCz, C3 和 C4 导联来计算运动皮层不同区域间的同步化。从信号波形上看，想象左手运动时，C4 和 FCz 导联有明显的同步化特征；而在想象右手运动时，C3 和 FCz 导联上波形的相关程度更高。




图 3.18 (a) 想象左手运动单次实验脑电；(b) 想象右手运动单次实验脑电。

表 3.1 为采用互相关 (时移为零)，相干函数 (频率为 12Hz) 以及相位同步化算法来分析图 3.18 中两次实验数据得到的同步化结果，包括了三种电极组合

方式：C3-C4，C3-FCz 和 C4-FCz，分别代表两侧 M1 区域，左侧 M1 和 SMA，以及右侧 M1 和 SMA 的组合。在想象左右手运动过程中，对侧 M1 区域与 SMA 的同步化程度高于同侧区域，而两侧 M1 之间的同步化程度最低。数据分析结果表明，三种同步化算法都适用于想象运动脑电的同步化特征提取，论文的 6.2.3 节将会给出以上三种方法用于想象运动脑电分类的结果。

表3.1 想象左右手运动任务下运动皮层的脑电同步化分析

任务		C3-C4	C3-FCz	C4-FCz
想象左手	互相关	0.10	0.28	0.81
	相干函数	0.16	0.28	0.80
	相位同步	0.17	0.24	0.83
想象右手	互相关	0.22	0.80	0.27
	相干函数	0.33	0.85	0.37
	相位同步	0.10	0.80	0.30

3.4 单次手指运动诱发脑电的特征提取

本节将介绍我们提出的一种针对“单次手指运动诱发脑电分类”的特征提取方法，此算法应用在第二届国际脑-机接口数据竞赛（BCI Competition 2003）的手指运动脑电实验数据集中获得了小组第一名^[49]。

在脑-机接口的研究中，手指运动诱发脑电分类有实验方法简单、抗干扰能力强、分类正确率较高、响应速度快、且无需训练等优点。但因为下面几方面的原因，要实现高正确率的单次任务检测仍有不少困难：1) 诱发脑电信号很微弱，淹没在幅值很高的背景脑电中，因此信噪比很低；2) 叠加平均技术是诱发电位提取中常用的方法，能大大提高诱发脑电的信噪比，但同时也降低了系统的响应速度，因此不适用于以高传输速率为目标的单次提取；3) 当手指运动速度较快时，多次诱发脑电响应之间出现混叠现象，从而加大了提取的难度。

在单次手指运动诱发脑电分类过程中，结合生理机制，使用有效的信号处理算法来进行特征提取是关键。使用前面介绍的脑电节律信号的分析方法，我们综合考虑了真实手指运动前诱发脑电中的运动准备电位（readiness potential，

RP) 和 mu/beta 节律的事件相关去同步化 (ERD) 这两个生理特征, 有效地使用了共空间模式 (CSP) 空域滤波算法对多导联事件相关脑电进行预处理, 在时域、频域、空域全面分析研究了单次手指运动诱发脑电的特征分布, 最终提取出三个相对独立并且有效的特征用于分类。

3.4.1 BCI Competition 2003 数据集 IV

第二届脑-机接口数据竞赛数据集 IV (<self-paced 1s>) 是在受试者随意敲击电脑键盘时采集的脑电数据。实验方法如图 3.19 所示, 受试者坐在舒适的椅子上, 两手做模拟打字动作, 按键的速度大约是每秒一次, 按键的左右手次序由受试者自由决定。数据长度从按键前 620 毫秒到 130 毫秒共 500 毫秒, 采样率为 1000Hz, 通带为 0.05-200Hz。电极导联采用 28 导国际标准 10/20 导联系统 (参见图 3.23)。数据集中包括了 316 个样本的训练集和 100 个样本的测试集, 已知标签的训练集用于特征提取方法和分类器的设计, 测试集用来检测算法的性能。数据分析的任务是通过对训练集的分析学习, 设计出分类器对测试集进行分类, 最终提交的结果是对 100 个测试样本对应的运动模式的预测值 (左手或右手), 由预测结果的正确率来确定比赛的名次。



图 3.19 手指运动诱发脑电采集示意图

3.4.2 手指运动诱发脑电的特征分析

3.4.2.1 运动准备电位

运动相关皮层电位 (movement-related cortical potentials, MRCPs) 是自主运

动前在头皮上记录到的幅值缓慢下降的电位，运动准备电位 (readiness potential, RP; 也称为 Bereitschaftspotential, BP) 是 MRCPs 的主要成分之一，它显著分布在大脑皮层的顶部区域^[142,143]。

运动准备电位具有对侧占优的特点，在运动肢体对侧皮层的分布要明显强于同侧。图 3.20 是对所有训练集样本平均后的左右手运动诱发脑电各导联的波形，以及运动前 320 毫秒和运动前 140 毫秒两个时刻的脑电幅度地形图，运动前 620 毫秒时刻的脑电幅值指定为 0。图中大部分导联在手指运动前都表现出负向波的特征，在左手运动模式下，大脑右侧运动皮层 RP 的特征最为明显；而右手运动前，左侧运动皮层区域的 RP 更强。另外，越接近手指真实运动的时刻，运动准备电位负向波的特征越明显。手指运动前运动准备电位在头皮上空间分布的不同可以作为手指运动诱发脑电分类的一个依据。




图 3.20 运动前 320 毫秒和 140 毫秒时刻的运动准备电位地形图及各导联的时域波形：(a) 左手手指运动；(b) 右手手指运动。

3.4.2.2 事件相关去同步化

单次真实手指运动用运动前的诱发脑电来判断随后的手指运动模式，因此数据集中存在运动前 μ 和 β 节律的 ERD^[40]。图 3.21 显示的是位于运动皮层区域的 C3 和 C4 导联分别在左右手运动前脑电信号能量分布的情况，用 8-35Hz 的带通滤波器滤除信号中的低频和高频成分。在 μ 和 β 频带内，左右手指运动诱发脑电能量分布存在着较大的差异。根据 ERD 分布的特点，C3 导联在右手运动前应出现明显的 ERD 特征，能量应低于左手运动；而 C4 导联则在左手运动

前出现 ERD，能量分布应低于右手运动。图 3.21 中实际数据分析的结果与 ERD 的生理特征一致。手指运动前的 μ 和 β 节律的 ERD 在头皮空间分布上的差异可以作为手指运动诱发脑电分类的另一个根据。




图 3.21 手指运动前的脑电功率谱：(a) C3 导联功率谱；(b) C4 导联功率谱。

3.4.3 特征提取和分类

手指运动诱发脑电的特征提取根据 RP 和 ERD 两个生理特征来进行，因为 RP 和 ERD 间存在独立性，所以考虑分别从中提取单个特征，最后结合多个特征来进行分类器的设计。在特征提取中使用了 Fisher 线性判别分析 (Fisher discriminant analysis, FDA)^[144]，对于左右手指运动诱发脑电分类问题，它将从信号中提取出的高维特征降到一维空间中，用其在一维空间的投影值作为新的特征来表示单次实验脑电与左右手两类运动模式的贴近度。这种方法容易实现，需要的计算量小。图 3.22 描述了整个分类算法流程：结合 CSP 空间滤波算法和 FDA 从单次手指运动诱发脑电中提取出三个特征，然后用单层感知机神经网络对这三个特征进行分类来预测单次手指运动的模式。计算中使用采样率为 100Hz 的数据，因为本算法中仅用到 0-33Hz 的脑电成分，100Hz 以上的高频成分并不影响其生理特征的表现。另外，使用采样率为 100Hz 的数据能大大降低运算量，从而提高分类速度，更适合于脑-机接口的在线分析。在 100Hz 采样率下，时间长度为 500 毫秒的数据长度为 50 点。为了方便算法中的描述，下文中用数据

点序号（1 到 50）来对应-620 毫秒到-130 毫秒时间段上的 50 个数据点。

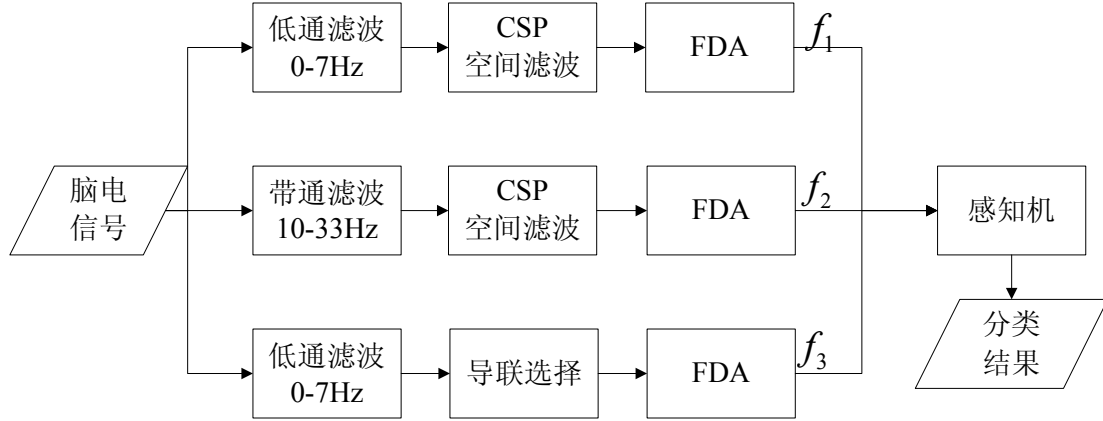


图 3.22 分类算法流程图

3.4.3.1 特征提取

特征 f_1 的生理背景是运动准备电位，具体体现为感觉运动皮层区域的负向波，它在大脑运动感觉皮层对侧的响应要强于同侧。RP 属于低频成分，因此提取这个特征时采用 0-7Hz 的低通滤波，对实际数据的观察发现 RP 在时间窗 44-47 内最为明显，因此采用宽度为 4 个数据点的 28 导联脑电做 CSP 处理，设计仅包含一个空间模式向量的空域滤波器 SF_L 和 SF_R 。用 SF_L (1×28) 和 SF_R (1×28) 对预处理后的脑电数据 X (28×4) 做空间滤波，定义 8×1 维的特征向量 $x_1 = [s_L \ s_R]^T$ ，其中 $s_L = SF_L X$ ， $s_R = SF_R X$ 。最后通过 FDA 把 x_1 投影到一维空间得到特征 f_1 。

特征 f_2 提取方法和特征 f_1 相似，但因为 RP 和 ERD 不同的生理背景，处理过程中参数的选择也不同，这些参数包括预处理过程中滤波器通带、时域时间窗、CSP 过程中特征值的选取、特征的定义等。特征 f_2 的生理背景是 mu 和 beta 节律的 ERD，手指运动前 ERD 主要分布在运动皮层的对侧区域。提取 ERD 的特征时用 10-33Hz 的带通滤波，时间窗为 19-50，数据段共包括 32 个数据点。CSP 空间滤波器设计时取三个最大的特征值，经过空间滤波后得到 s_{Li} 和 s_{Ri} ($i=1-3$)，维数均为 1×32 。把它们交替串接组成长度为 192 的特征向量 x_2 ，特征向量的绝对值能反映 ERD 能量变化的特点。在样本有限的情况下，特征向量维数过高会影响分类器的推广能力，所以对绝对值向量每 8 点求均值来降低特征向量的维数，得到长度为 24 的特征向量 x_2 ，再对 x_2 进行 FDA 得到特征 f_2 。

特征 f_3 的生理背景同 f_1 ，综合考虑各导联 RP 在时域内负向波的特征，从数

据初段和末段定义两个特征来反映 RP 时域波形变化中的下降趋势。预处理过程同特征 f_1 ，同样采用 0-7Hz 的低通滤波。通过时域平均波形的比较来观察同一导联 RP 在左右手两种运动模式下的幅度差异。图 3.23 (b) 显示了在左右手运动两种模式下时域各导联波形均值之差。两种模式下，RP 特征的差异在 F3, F1, F4, FC5, FC3, C5, C3, CP5, CP3 这 9 个导联较小，实际分类中使用这些导联对分类结果没有明显作用。使用其它 19 导数据，从每导数据的前段 (1-8) 和末段 (41-50) 提取出 2 个特征 k_1 和 k_2 (波形幅度的均值) 来表现与 RP 相关的脑电幅值下降过程，这两个特征能较好地表现出时域中 RP 为负向波的特征。图 3.23 (a) 显示了左手运动时 C4 导联在两个单次实验中的波形及相应的特征 k_1 和 k_2 。由 19 导联数据共得到 38 个特征，定义向量 $\mathbf{x}_3=[k_{11} k_{12} \dots k_{i1} k_{i2}]^T$ ($i=19$)，对 \mathbf{x}_3 进行 FDA 得到特征 f_3 。




图 3.23 (a) C4 导联在左手运动时诱发脑电的平均值波形和两个单次实验波形， k_1 和 k_2 为用于描述 RP 的两个特征；(b) 28 导联波形均值在左右手运动两种任务下的幅度差。

3.4.3.2 分类和结果

在得到以上三个特征后，用单层感知机神经网络来训练用于判断单次手指运动模式的分类器。感知机的优点在于学习过程收敛很快，并且与初始值无关。对于左右手运动这个两类问题，定义输入的特征向量 $\mathbf{p}=[f_1 f_2 f_3]^T$ ，左手运动时输

出为 0，右手运动则输出为 1，分类器表示为：

$$a = \text{hardlim}(\mathbf{w}^T \mathbf{p} + b) \quad (3-44)$$

函数 $\text{hardlim}(x)$ 为硬限函数，返回值为 0 或 1，权重 \mathbf{w} 和偏移值 b 由感知机通过已知类别标签的训练集数据学习得到。

316 个样本的训练集采用留一法 (leave-one-out) 训练的结果如下：使用三个特征时，分类正确率为 $93.0 \pm 2.50\%$ ；三个特征单独用于分类时也得到了较高的正确率，其中分类效果最好的是基于 ERD 的特征 f_2 ，正确率为 $89.1 \pm 2.97\%$ ，特征 f_1 和 f_3 的正确率分别为 $81.6 \pm 3.78\%$ 和 $84.0 \pm 3.70\%$ 。最后对测试集的 100 个样本进行测试，正确率为 84%。与训练集相比，测试集正确率下降的原因可以归结为数量较少的训练样本导致了分类器的推广能力较差（有关分类推广能力的讨论见 4.3 节）。以上分类结果表明，本文提出的以运动准备电位和事件相关去同步化两个生理现象为基础，采用 CSP 空域滤波与 FDA 相结合的方法来分析手指运动诱发脑电的算法是合理有效的。我们提交的结果在所有 15 个参赛小组中列第一位，表 3.2 为部分提交结果^[145]。

表3.2 BCI Competition 2003 数据集IV结果

排名	提交人	错误率 (%)	研究机构
1	Zhiguang Zhang	16	Tsinghua University
2	Radford Neal	19	University of Toronto
3	Ulrich Hoffmann	23	—
4	Tzu-Kuo Huang	25	National Taiwan University, Taipei
4	Brett Mensh	25	Massachussets Institute of Technology
6	Dominik Brugger	27	University of Tübingen
6	Kai-Min Chung	27	National Taiwan University, Taipei
8	Michael Schröder	29	University of Tübingen

3.4.4 讨论

3.4.4.1 时间窗和频率窗

预处理过程中滤波器频率窗的选择和 CSP 处理中时间窗的选择对分类效果的影响很大。根据先验知识可以初步估计各个参数值,如 RP 为低频成分, ERD 分布在 μ 和 β 频带内。在实际的计算过程中,采用滑动窗的方法来选择参数。在信号预处理的滤波中,对不同带宽的滤波器选择不同的截止频率,分别计算单个特征的分类正确率,选择出对 RP 最有效的频带为 0-7Hz,而 ERD 最集中在 10-33Hz。对 CSP 算法时间窗的选择采用类似的方法,对不同宽度的时间窗分别选择不同的起始点计算分类正确率,通过计算可以发现 RP 集中在 44-47 时段,而 ERD 集中在 19-50 时段内,这些时段内左右手运动诱发脑电特征最为显著。图 3.24 显示了与 ERD 相应的特征 f_2 提取中 CSP 时间窗参数的选择对分类正确率的影响。可以看到,当时间窗以 50 为终点时,最高的分类正确率对应的起点不是真实运动时刻的近端或远端,对于特征 f_2 的提取,选择起点为 19 时能获得最高的分类正确率。




图 3.24 特征 f_2 提取中时间窗和分类正确率的关系

3.4.4.2 空间滤波器设计

在 CSP 空域滤波器设计过程中,特征值的选取很重要(见(3-21)式)。原则上是选取与左右手运动模式相对应的最大的几个特征值,实际应用中可以采用对分类结果进行比较的方法来选择特征值。依次选取单个特征值进行 CSP 滤

波器设计，对空域滤波的结果进行分类，得到与单个特征值对应的分类正确率，然后根据所有正确率的高低，从中选择出最有效的几个特征值来设计空间滤波器。表 3.3 中列出了五个特征值 e_1 到 e_5 （按从大到小降序排列）相应的分类正确率。在特征 f_1 的提取中，只有最大的特征值得到较高的正确率 82%，其余四个特征值对应的分类正确率都低于 60%，所以仅选取 e_1 来设计空域滤波器。而在特征 f_2 的提取过程中，前五个特征值相应的分类正确率从 84%到 59%，越大的特征值越集中表现了两种运动模式的差异，对应的分类正确率越高。前三个特征值对应的正确率大于 70%，远高于 e_4 和 e_5 ，最终确定选择前三个特征值来设计空域滤波器。

表3.3 使用单个特征值设计空域滤波器时的分类正确率（%）

特征	特征值				
	e_1	e_2	e_3	e_4	e_5
f_1	82	51	53	55	52
f_2	84	77	70	61	59

3.4.4.3 数据传输率

把测试集的 100 个样本加入到训练集中，得到样本数为 416 的数据集，用留一法训练得到的分类正确率为 91.33%。用同样的方法来处理第一届脑-机接口数据竞赛的手指运动诱发脑电数据集<self-paced 2s>^[146]，调整相应的参数来设计分类器。与<self-paced 1s>相比，<self-paced 2s>中的 RP 特征显著增强，因此特征 f_1 和特征 f_3 的分类正确率都大大提高。同样用留一法训练，得到的分类正确率为 98.23%。从图 3.25 (a) 中可以看出，虽然<self-paced 1s>的分类正确率下降了大约 7 个百分点，但每次判断的时间从 2s 减少到 1s，最终得到的数据传输率为 34.48bits/min，与<self-paced 2s>的 24.91bits/min 相比仍有较大的提高。

可以考虑从下面几个方面来提高系统的数据传输率。如图 3.25 (b)，在相同的正确率下，如果按键速度加快，则比特率将大大提高，当每秒运动 2 次时，如果能得到高于 85%的正确率，那么信息传输率将高于 46bits/min。但手指运动的速度和分类正确率往往是互相矛盾的，一般来说，提高速度以降低分类正确率为代价，选择适当的速度才能获得最高的数据传输率。另一方面，训练样本

集的大小影响到分类器的推广能力，采集尽可能多的训练样本也能降低预测误差，但同时也需要花费更多的训练时间。除上述方法外，增大可识别任务的种类（如采用左右手和脚动三种模式），使用更有效的特征提取和分类算法也能提高系统的数据传输率。




图 3.25 (a) 不同手指运动速率下的信息传输率，速度为 2 次/秒时，假定分类正确率为 85%；(b) 信息传输率和手指运动速率及分类正确率的关系曲线。

3.5 本章小结

针对想象运动脑电数据处理，本章详细说明了在时域和频域基于能量的节律信号特征量化方法，并介绍了脑电同步化算法及其在想象运动脑电分析中的应用。在多导联脑电分析中，我们将基于数据统计分析的 CSP 和 ICA 两种空间滤波方法用于分析想象运动脑电数据， μ 节律的信噪比获得了显著的提高。

在脑电节律信号特征分析的实际应用中，我们提出的基于 CSP 空间滤波的特征提取方法在第二届国际脑-机接口数据竞赛中获得了“手指运动诱发脑电分类”数据集的第一名，对测试集的分类正确率为 84%。与其它参赛小组的算法相比^[145]，我们算法的优势主要体现在以下几个方面：

1) 综合时域-频域-空域的参数选择方法，详细分析了 μ 节律 ERD 和运动准备电位的时间过程、能量分布、空间分布，从而提取出稳定的特征；

- 2) 基于大脑活动源分解模型的 CSP 空间滤波算法的应用, 通过提取任务相关的源活动去除了背景自发脑电的影响, 从而提高了运动相关脑电的信噪比;
- 3) 基于神经生理背景的特征结合方法, 手指运动前 mu 节律的 ERD/ERS 和运动准备电位由于不同的生理机制而存在较强的独立性, 通过两者的特征结合提高了分类正确率。

本章介绍的脑电节律信号特征提取方法将被用于实现我们设计的在线脑-机接口系统, 具体内容参见论文的第 5-7 章。

第4章 在线脑-机接口系统机器学习算法

脑-机接口实现的基本原理是把大脑的不同思维状态翻译成相应的控制命令。早期的 BCI 系统更注重用户训练的方法，基于大脑对生物反馈信号的适应性，受试者在长期的适应学习后能够自主控制几种机器可以识别的大脑状态^[11,45]。BCI 系统还可以采用分类算法（classification algorithm）来实现，使用分类算法自动检测大脑状态的优点是训练的时间短并且识别率高，现有的脑-机接口很多都采用了基于模式识别（pattern recognition）的机器学习算法^[146,147]。在线脑-机接口系统使用的机器学习算法必须满足因果性和实时性的需要。

4.1 脑-机交互适应系统

脑-机接口系统中在线机器学习算法的发展使得脑-机交互适应系统的实现成为可能。最近几年，具有交互适应功能的脑-机接口的研究开始被广泛关注^[43,148-153]。Wolpaw 等人在 mu 节律控制二维光标运动的用户训练过程中采用自适应的方法，根据不断更新的训练样本集来更新两个线性投影函数的参数^[43]。Sheony 等人分析了想象运动脑-机接口的自适应分类方法，提出了结合离线数据和在线数据的自适应分类方法，利用在线数据对离线数据分析设计的分类器做少量调整的方法获得了较高的性能^[148]。Vidaurre 等人还设计了不需要针对不同受试者做离线分析的自适应想象运动脑-机接口，系统的初始化使用由多个数据集离线分析得到的统一参数，使用自适应 AR 模型和二次判别分析（quadratic discriminant analysis, QDA）进行特征提取和分类，受试者根据系统提供的反馈信息进行适应，在脑-机交互适应过程中系统的性能得到了逐步提高^[149]。

如图 4.1 (a)，一个脑-机交互适应系统包括了基于大脑学习的生物智能系统和基于机器学习的人工智能系统两个组成部分。大脑学习通过反馈训练来完成，受试者根据反馈信息来寻找到最适合 BCI 系统操作的大脑状态，并通过反复的强化训练得到巩固和提高；机器学习通过自适应的在线学习算法来实现，更新的内容包括了训练集样本、特征提取参数和分类器。提示或反馈信息同时也作用于机器学习过程，可提供样本的标签信息或者根据反馈信息来进行样本的挑选。由于大脑学习和机器学习的同时参与，脑-机交互学习比单一模式的

大脑学习或机器学习有更高的效率。图 4.1 (b) 提出了一种交互学习的模式，第一步使用离线数据分析来初始化机器学习的参数；接着开始训练样本逐渐增加的交互学习过程，采用分段学习的模式，大脑适应和机器适应交替进行；最后是使用固定大小的训练样本集的学习过程，考虑到学习过程中大脑状态的逐渐改变，对训练集也不断进行更新，当前的训练集中去除了较早的部分样本，仅包含最新的训练样本，更适合当前状态的大脑检测。

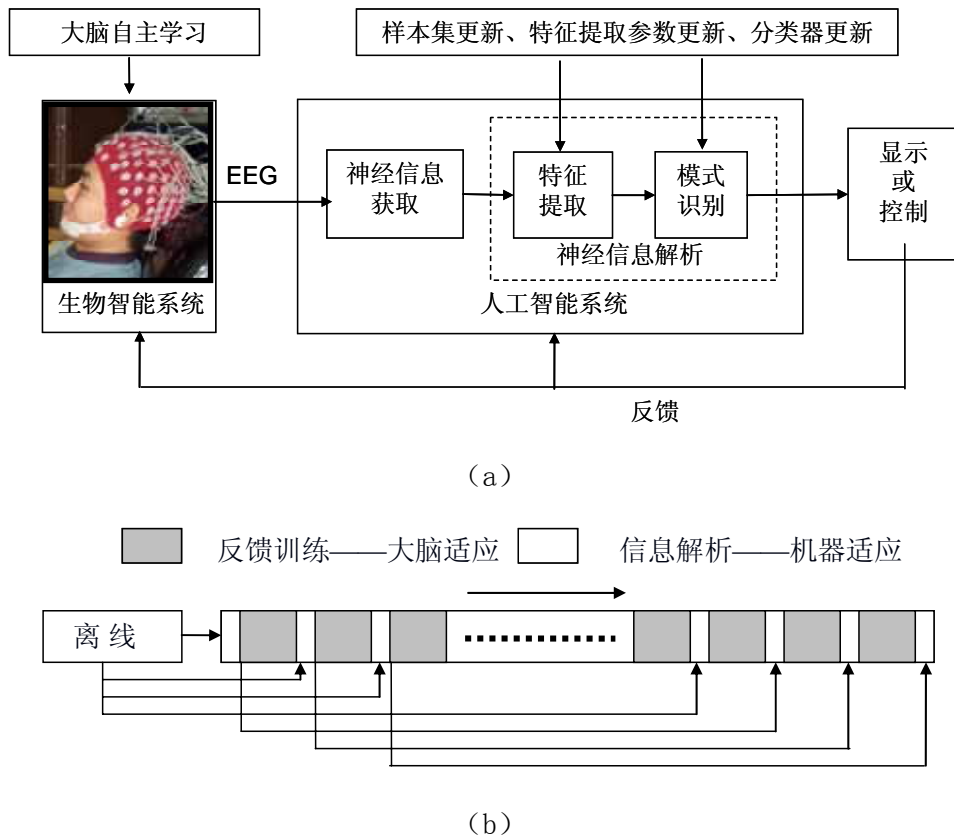


图 4.1 (a) 脑-机交互适应系统框图；(b) 脑-机交互学习过程。

4.2 分类算法在脑-机接口中的应用

图 4.2 为模式识别系统的基本构成框图，包括了输入信息的获取、信号的预处理、特征提取、分类器设计、以及分类决策的输出。预处理的目的是去除噪声，突出有用的信息；特征提取通过变换把维数较高的测量空间中表示的模式转变为在维数较低的特征空间中表示的模式，来自同一类别的不同样本的特征非常接近，而来自不同类别的样本的特征有较大的差异；分类决策要在低维的

特征空间中把识别对象归为某一类别，基本的做法是在样本训练集的基础上确定出识别错误率最小的决策规则。脑-机接口包括了一个用于识别大脑思维状态的完整的模式识别系统：系统的输入为头皮上采集到的高维脑电信号，预处理包括信号在时域、频域和空间的选择以及信号的去噪，特征提取采用信号处理的方法将预处理后的高维信号转换为低维的特征向量，分类决策过程中使用由训练样本设计的分类器对输入的特征向量进行类别判定，决策结果作为系统的输出被用于外部设备的控制。




图 4.2 模式识别系统的构成框图

脑-机接口中的分类问题主要集中在以下两个方面^[154]：

1) 维数灾难 (curse of dimensionality)。随着特征维数的增加，设计性能稳定的分类器需要的训练样本数呈指数增长^[155]。当样本的特征维数很大时，一方面带来数据处理的麻烦，处理时间的消耗很大；另一方面是训练样本采集的困难，采集足够的样本需要很大的花费。维数灾难问题是脑-机接口设计需要重点考虑的问题，脑电信号由于较高的时间分辨率和导联数量往往具有很高的特征维数，而由于大脑信号的时变性，以及较显著的个体差异，能获得的训练样本数量十分有限，特别是在脑-机接口在线系统的使用过程中，考虑到系统使用的方便性和使用者的疲劳等因素，能获取的训练样本集更小。通常使用特征选择和特征提取的方法来降低脑电信号的特征维数。

2) 预测误差。假定样本 x 的类别标签为 y ，根据大小相同的训练集 T 得到的分类器函数集为 f ，而未知的最优分类器函数为 f^* ，那么预测误差为：

$$E_T[y - f(x)]^2 = E_T[y - f^*(x)]^2 + E_T[f^*(x) - f(x)]^2 \quad (4-1)$$

上式右边第一项为无法削减的理想分类器预测误差，第二项为分类器与理想分

类器的偏差，可以进一步分解为两部分：

$$E_T[f^*(x) - f(x)]^2 = [f^*(x) - E_T f(x)]^2 + E_T[f(x) - E_T f(x)]^2 \quad (4-2)$$

(4-2) 式右边第一项为分类器函数集的输出均值与理想最优分类器的偏差 (bias)，第二项为分类器函数集输出的方差 (variance)，偏差取决于分类器函数集 f ，而方差则对训练集 T 敏感，预测误差由偏差和方差两者共同决定。(4-1) 和 (4-2) 式的推导参见文献[156]。通常稳定的分类器有大的偏差和小的方差，而不稳定的分类器则有小的偏差和较大的方差，因此实际应用中需要对偏差和方差作折衷选择。由于大脑状态的时变特性，数据集通常可能导致较大的方差，因此使用稳定的分类器更能保证脑-机接口数据分类的性能。

4.2.1 基于可分性判据的特征选择

为减轻维数灾难问题对脑-机接口系统的影响，在进行分类器设计之前需要进行特征的选择，降低脑电信号原始特征空间的维数。特征选择主要针对脑电信号预处理过程中的三个参数：时间窗、频率窗、电极位置。单个特征选择的任务是要给出在不同参数情况下，单个特征对于分类结果的重要性。基于可分性判据的特征选择是根据指定的判据计算方法来评定单个特征对于分类能起的作用，在 BCI 的研究中最常用的可分性判据是计算 r^2 的方法^[1]。

r^2 表示了特征和任务的相关性，反映了任务种类即可预测的特征信息。在两类任务的情况下，任务向量 Y 取值为 +1 和 -1，特征向量为 X ， X 由 X_{+1} 和 X_{-1} 组成，假设两类样本数量相同， r^2 的计算过程如下：

$$\begin{aligned} r^2(X) &= \left[\frac{\text{Cov}(X, Y)}{\sigma_X \sigma_Y} \right]^2 = \left[\frac{E(XY) - EXEY}{\sigma_X \sigma_Y} \right]^2 = \left[\frac{E(XY)}{\sigma_X} \right]^2 \\ &= \left[\frac{E(X_{+1} - X_{-1})}{2\sigma_X} \right]^2 = \frac{(EX_{+1} - EX_{-1})^2}{4\sigma_X^2} \end{aligned} \quad (4-3)$$

当 X_{+1} 和 X_{-1} 的均值相等时， r^2 为 0，特征不包含对分类有效的信息；当 X_{+1} 和 X_{-1} 为不相等的常数时， r^2 为 1，知道任务的种类即可得到特征的准确值，特征对应的分类正确率为 100%。 r^2 反映了特征的重要性， r^2 越大的特征对分类的贡献也越大。 r^2 可用于选择频率、时间、导联参数，图 4.3 为使用 r^2 的时-频分布和空间分布来选择想象运动脑电分类中的特征提取参数的示例。图 4.3 (a) 用于选择信号预处理的时间窗和频带，采用短时傅里叶变换 (short-time Fourier

transform, STFT)^[109]计算两种任务下各自的脑电时-频能量分布(time-frequency distribution), 计算出时-频平面上每一点的 r^2 , 得到时-频 r^2 分布。选择 r^2 显著的时频区域作为用于分类的特征, 图中 r^2 最显著的区域对应了想象运动的执行过程中 mu 和 beta 节律变化最显著的区域。图 4.3 (b) 为固定时-频参数后计算得到的电极空间 r^2 分布图。从图中可以挑选出用于分类的电极组合, 如图中的前额区和左右中央区域的 r^2 值较大, 这些区域分别对应了运动皮层的辅助运动区和初级运动区。

除 r^2 外, 特征可分性判据的计算还可以采用 (4-4) 式的 Fisher 判据 (Fisher criterion) 或其它假设检验的方法, 如 t 检验等。

$$F_{\text{score}}(\mathbf{X}) = \frac{(\mathbf{E}\mathbf{X}_{+1} - \mathbf{E}\mathbf{X}_{-1})^2}{\sigma_{\mathbf{X}_{+1}}^2 + \sigma_{\mathbf{X}_{-1}}^2} \quad (4-4)$$




图 4.3 (a) r^2 时-频分布图; (b) r^2 空间分布图。

4.2.2 分类器设计

在脑-机接口的研究中, 分类算法的性能直接影响到系统的信息传输速率, 使用推广能力好, 计算速度快的分类器是设计在线脑-机接口系统的重要环节。文献[154]把现有脑-机接口常用的分类算法归为五类: 1) 线性分类器 (linear classifiers), 2) 神经网络 (neural networks), 3) 非线性贝叶斯分类器 (nonlinear Bayesian classifiers), 4) 近邻分类器 (nearest neighbor classifiers), 5) 分类器结

合 (combinations of classifiers)。表 4.1 为第三届脑-机接口数据竞赛获胜算法中使用的分类器^[50]，在所有七个数据集中，五个采用了 Fisher 线性分类器 (Fisher discriminant analysis, FDA) 或者支持向量机 (support vector machine, SVM) 的分类算法，有四个数据集运用了分类器结合的算法。在脑-机接口的脑电数据分类问题中，线性分类器由于算法的推广能力好，执行速度快，是在线脑-机接口最常用的分类方法。下面将介绍现有脑-机接口中常用的两种分类器：Fisher 线性分类器和支持向量机。

表4.1 第三届脑-机接口数据竞赛获胜分类算法

数据集	数据类型	分类算法	分类器结合
I	Motor imagery	FDA	Linear SVM
II	P300	Linear SVM	Mixture(Summing)
IIIa	Motor imagery	SVM	——
IIIb	Motor imagery	Probabilistic model	Accumulative classifier
IVa	Motor imagery	FDA	Bagging
IVc	Motor imagery	FDA	——
V	Mental tasks	Distance based discriminator	——

4.2.2.1 Fisher 线性判别

线性分类器把 d 维空间的样本投影到一条直线上形成一维空间，Fisher 线性判别方法要解决的问题是要寻找最易于分类的投影线，使得各类样本的投影能分开得最好。如图 4.4 (a)，两类样本在方向为 \mathbf{w}_1 的直线上的投影完全分开，而在图 4.4 (b) 中方向为 \mathbf{w}_2 的直线上的投影两类样本混在一起而无法识别。




图 4.4 Fisher 线性判别的基本原理：（a）易于分类的投影方向；（b）难于分类的投影方向。（摘自[157]）

假设有 N 个 d 维样本 $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N$ ，其中的 N_1 个属于 ω_1 类，记为 \mathbf{X}_1 ，其它的 N_2 个属于 ω_2 类，记为 \mathbf{X}_2 。对 \mathbf{x}_n 的各个分量作线性组合

$$y_n = \mathbf{w}^T \mathbf{x}_n, n=1,2,\dots,N. \quad (4-5)$$

就得到 N 个一维样本 y_n 的集合 \mathbf{Y} ，根据样本类别可分为两个子集 \mathbf{Y}_1 和 \mathbf{Y}_2 。在投影后的一维样本空间，两类样本的均值表示为：

$$\tilde{m}_i = \frac{1}{N_i} \sum_{y \in \mathbf{Y}_i} y, i=1,2. \quad (4-6)$$

两类样本的类内离散度和总类内离散度表示为：

$$\tilde{S}_i^2 = \sum_{y \in \mathbf{Y}_i} (y - \tilde{m}_i)^2, i=1,2. \quad (4-7a)$$

$$\tilde{S}_w = \tilde{S}_1^2 + \tilde{S}_2^2 \quad (4-7b)$$

要使一维空间的样本易于分类，两类样本的均值之差应尽可能大，同时样本内部尽量密集，即类内离散度尽量小。Fisher 准则函数定义为：

$$J_F(\mathbf{w}) = \frac{(\tilde{m}_1 - \tilde{m}_2)^2}{\tilde{S}_1^2 + \tilde{S}_2^2} \quad (4-8)$$

Fisher 方法的目标是要寻找 $J_F(\mathbf{w})$ 取极大值时的 \mathbf{w}^* ，有关 \mathbf{w}^* 的求解过程可以参考 [157,158]。求得 \mathbf{w}^* 后可以利用训练集的先验知识来确定两类样本分类的阈值 y_0 ，得到如下的决策规则：

$$y = \text{sgn}(\mathbf{w}^T \mathbf{x} - y_0), \begin{cases} y > 0, \mathbf{x} \in \omega_1 \\ y < 0, \mathbf{x} \in \omega_2 \end{cases} \quad (4-9)$$

4.2.2.2 支持向量机

支持向量机 (support vector machine, SVM) 的方法是从线性可分情况下的最优分类面提出的^[157]。图 4.5 为最优分类面的示意图，图中的点和圈分别表示两类样本，H 是能把两类样本准确分开的分类线， H_1 和 H_2 为经过离分类线最近的样本点且平行于分类线的直线。 H_1 和 H_2 之间的距离叫做两类样本的分类间隔 (margin)， H_1 和 H_2 上的训练样本叫做支持向量 (support vectors)。最优分类线要求两类样本的分类间隔最大，并且两类样本能够被最好地分开。




图 4.5 最优分类面示意图

设 n 个样本组成的样本集为 $(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_n, y_n) \in \mathbb{R}^d \times \{+1, -1\}$ 。线性判别函数的一般形式为：

$$g(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b \quad (4-10)$$

对判别函数进行归一化,使两类样本都满足 $|g(\mathbf{x})| \geq 1$,可以求得分类间隔为 $2/\|\mathbf{w}\|$,使间隔最大等价于使 $\|\mathbf{w}\|^2$ 最小。在线性不可分的情况下,引入松弛项 $\xi_i \geq 0$,最优分类面的求解可以表示为约束优化问题:

$$\begin{aligned} \min \phi(\mathbf{w}) &= \frac{1}{2} \|\mathbf{w}\|^2 + C \left(\sum_{i=1}^n \xi_i \right) \\ \text{subject to } & y_i [(\mathbf{w}^T \mathbf{x}_i + b)] - 1 + \xi_i \geq 0, i = 1, 2, \dots, n. \end{aligned} \quad (4-11)$$

上式的求解可以参考[157],最后得到的最优分类函数是:

$$f(\mathbf{x}) = \text{sgn} \left\{ \sum_{i=1}^n \alpha_i y_i (\mathbf{x}_i \cdot \mathbf{x}) + b \right\} \quad (4-12)$$

非支持向量对应的 α_i 均为零,因此上式的求和只对支持向量进行, b 是分类的域值,可由任意一个支持向量求得。如果用内积 $K(\mathbf{x}_i, \mathbf{x})$ 代替上式中的点积,相当于把原特征空间变换到了另一个新的特征空间,相应的判别函数为:

$$f(\mathbf{x}) = \text{sgn} \left\{ \sum_{i=1}^n \alpha_i y_i K(\mathbf{x}_i, \mathbf{x}) + b \right\} \quad (4-13)$$

支持向量机通过内积变换将输入空间变换到一个高维空间,然后在新空间中求取最优线性分类面。只要能够适当选择一种内积定义,构造一个支持向量数量相对较少的最优分类面,就可以得到较好的推广性^[157]。

4.2.3 特征结合方法

在3.4节“手指运动诱发脑电分类”中提到了特征结合的分类算法,结合事件相关去同步化(ERD)和运动准备电位(RP)的特征提高了手指运动脑电的分类正确率。特征结合是BCI研究中经常使用的方法,常见的方法可以归纳为以下两类:

1) 基于不同脑电信号的特征结合。Mensch等人结合了脑电gamma频段的能量特征^[159],提高了皮层慢电位分类的正确率;在真实手指运动脑电分类中,ERD和RP的结合被广泛采用^[57,160,161],这一方法同样被用于想象运动脑电和皮层电位的

分类^[162,163]；Gerwin 等人使用错误电位（error potential）来修正 mu 节律调节中的误操作^[164]，从而降低了分类错误率；在多模式注意脑电分类中，由视觉刺激引起的 SSVEP 和触觉刺激引起的 mu 节律的 ERD/ERS 被同时用于特征提取和分类^[165]。

2) 基于不同信号处理方法的特征结合。在 ERD/ERS 的特征提取中，CSP 方法提取的特征是 mu 和 beta 节律能量的大小，而 AR 模型的方法提取的是功率谱分布的特性，两者相结合能提高运动脑电分类的正确率^[162]；在想象运动脑电分类中结合能量和同步化特征，结合幅度同步化和相位同步化特征，结合局部同步化和大范围同步化特征的方法都有助于提高分类性能^[141,166]。

由于不同脑电信号以及不同特征提取方法之间存在的独立性，特征结合的方法能够提供更多对分类有帮助的信息。在脑-机接口中不同脑电信号间的独立性主要体现在信号的频域和空域分布，如想象运动过程中的 RP 和 ERD 在频域独立，而多模式注意脑电分类中 SSVEP 和 mu 节律在频域和空间分布上都相互独立。文献[162]证明了在特征相互独立的情况下，特征结合能减小预测误差。两类情况下，假定样本集由 N 个独立的特征集 $\mathbf{X}_1, \dots, \mathbf{X}_N$ 构成，样本的类别标签为 y ，假定存在风险最小化的分类器函数 $f_j: \mathbb{R}^{d_j} \rightarrow \{-1, +1\}, j=1 \dots N$ ，使得

$$P(f_j(\mathbf{X}_j) | y = \pm 1) \square N(\mu_{j,\pm 1}, \sigma_{j,\pm 1}^2) \quad (4-14)$$

对上式作进一步简化，假定 $\sigma_j^2 = \sigma_{j,\pm 1}^2$ ， $\mu_j = \pm \mu_{j,\pm 1}$ ，根据（4-14）式可以计算特征向量集 \mathbf{X}_j 的预测误差 c_j ：

$$c_j = g(\mu_j / \sigma_j), \quad g(z) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^0 \exp(-\frac{1}{2}(x-z)^2) dx \quad (4-15)$$

定义特征结合分类器的输出为方差归一化后的 N 个分类器输出的和：

$$f(x) = \sum_{j=1}^N f_j(x_j) / \sigma_j \quad (4-16)$$

特征结合分类器输出仍为正态分布，其均值和方差可表示为 μ 和 σ ，由于 $f_j(x_j)$ 相互独立，因此特征结合后的预测总误差可以表示为：

$$c = g(\mu/\sigma) = g\left(\frac{\sum_{j=1}^N \mu_j / \sigma_j}{\sqrt{N}}\right) = g\left(\frac{\sum_{j=1}^N g^{-1}(c_j)}{\sqrt{N}}\right) \quad (4-17)$$

假定 c_j 相等，由于函数 g 为递减函数，可以得到特征结合前后预测误差的关系：

$$c = g(\sqrt{N}g^{-1}(\hat{c})) < \hat{c} \quad (c_j = \hat{c}, j = 1, \dots, N) \quad (4-18)$$

上式表明，在特征独立的情况下，特征结合算法能够减小预测误差。

4.3 脑-机接口与小样本机器学习

机器学习的目的是根据已知的训练样本寻找系统输入和输出之间关系的估计，使得系统能够对将来未知的输入做出准确的输出预测。以两类情况为例，系统的输入 \mathbf{x} 和输出 y 之间存在未知的概率分布 $P(\mathbf{x}, y)$ ，机器学习就是要根据已知的 k 个独立同分布的观测样本 $(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_k, y_k) \in \square^d \times \{+1, -1\}$ ，在函数集 \mathbf{F} 中寻找一个最优的函数 $f: \square^d \rightarrow \{+1, -1\}$ 来最小化输出预测的期望风险：

$$R(f) = \int l(f(\mathbf{x}), y) dP(\mathbf{x}, y) \quad (4-19)$$

l 是损失函数，常用的损失函数为均方损失：

$$l(f(\mathbf{x}), y) = (y - f(\mathbf{x}))^2 \quad (4-20)$$

由于 $P(\mathbf{x}, y)$ 未知，因此最小化期望风险无法通过计算来直接实现，在实际应用中通常采用经验风险的最小化来逼近。经验风险根据训练样本来计算：

$$R_{\text{emp}}(f) = \frac{1}{k} \sum_{i=1}^k l(f(\mathbf{x}_i), y_i) \quad (4-21)$$

用求经验风险最小值代替求期望风险最小值的方法被称为“经验风险最小化原则”。当样本数趋于无穷时，经验风险收敛到期望风险，但在样本有限的情况下，经验风险最小并不一定意味着期望风险最小。学习机器对未来输出进行正确预测的能力被称作推广能力（generalization ability）。在某些情况下，经验风险过小反而会导致推广能力的下降，这一现象被称为“过学习（overfitting）”^[157]。

根据统计学习理论，期望风险和经验风险与训练样本数的关系如图 4.6，期

望风险高于经验风险，而且训练样本数越小，两者的偏差越大，当训练样本数接近无穷大时，期望风险和经验风险相同。期望风险和经验风险的关系表示为：

$$R[f] \leq R_{\text{emp}}[f] + \Phi(n/h) \quad (4-22)$$

Φ 为置信范围， n 为训练样本数， h 为分类器函数的 VC 维（VC 维指示了函数的复杂性^[157]）。置信范围是关于 n/h 的递减函数，当 n/h 较大时，置信范围就会很小，当 n/h 过小时置信范围变大，易发生“过学习”的现象。“过学习”问题中，分类器对训练样本的识别能获得很高的性能，但对新样本的识别能力却很差，即期望风险大大高于经验风险。传统机器学习方法普遍采用“经验风险最小化原则”，但当样本数目有限时，需要同时考虑最小化经验风险和置信范围才能得到好的推广能力。过学习的发生和训练样本数以及分类器的复杂性有关，过少的训练样本和过高的分类器复杂性都会引起过学习。在训练样本数量固定的情况下，为减小置信范围的取值，分类器设计中应使用尽量简单的模型，但过于简单的模型也可能不足以描述训练集数据的差异，从而引起经验风险的增加，因此折衷调整模型的复杂程度是解决过学习问题的关键。选择经验风险与置信范围之和最小的分类器，就可以达到期望风险的最小（如图 4.7），这种思想被称为“结构风险最小化原则”^[157]。




图 4.6 期望风险和经验风险与样本数的关系曲线




图 4.7 结构风险最小化示意图

使用机器学习算法后，在线脑-机接口系统需要考虑训练集样本的获取问题。为了保证分类算法有好的推广能力，需要有足够的训练样本用于分类器设计，因此需要花费大量的时间来获取训练数据。而在 BCI 系统的实际应用中，使用者通常希望尽可能避免或缩短训练的时间，解决好“小样本学习”问题对脑-机接口系统的实用化有重要意义。针对在线脑-机接口的特点，可以从以下几个方面避免小样本引起的“过学习”问题：1) 从分类函数的复杂性考虑，应选择 VC 维小的分类器，如线性分类器等；2) 从特征提取的方法考虑，应选择生成特征维数低的特征提取方法，如采用空间滤波的方法对原始的多导联脑电信号进行降维；3) 从训练样本数量考虑，可以采用在线自适应学习的方法，将新样本逐步添加到原有的训练集中，在训练中实时更新分类器。

4.4 基于小样本机器学习的想象运动脑电分类

4.4.1 BCI Competition III 数据集 IVa

“小样本学习想象运动脑电数据集”是第三届国际脑-机接口数据竞赛(BCI Competition III) [50]的数据集 IVa，由德国柏林的 BCI 研究组提供，这一数据集的难点在于如何避免想象运动脑电小样本学习中存在的“过学习”问题。图 4.8 为想象运动单次实验过程：受试者坐在舒适的椅子上，电脑显示器上出现的图片或符号作为想象任务开始和结束的提示，任务提示出现后，受试者开始执行想象左右手动或脚动的任务，想象持续的时间为 3.5 秒，想象任务之后是时间不固定的休息(1.75-2.25 秒)。竞赛中用于分类的是想象右手和想象脚动两类样本。

数据集共包含了五位受试者（AL, AA, AV, AW, AY）的想象运动数据，每位受试者共采集了四组数据，每组共 70 个样本（每类 35 个），共有 280 个样本（每类 140 个）。数据集中的一部分带有类别标签，作为训练集，用于特征提取和分类器训练；剩余的无标签部分作为测试集，用于算法性能的评价。每位受试者训练集的大小不同，分别为总样本数的 80%，60%，30%，20%，和 10%。数据竞赛要求提供所有测试集样本的标签，按所有受试者的总分类正确率进行评价（五位受试者所有测试样本的分类正确率），因此训练集越小的受试者对竞赛结果影响的权重越大，分析处理这一数据集的关键是要保证小样本训练集（特别是受试者 AW 和 AY）能有较高的分类正确率。实验中的脑电信号采集使用 118 导联 BrainAmp 脑电图机，导联位置为扩展后的 10/20 导联系统（如图 4.9）。原始数据采样率为 1000Hz，想象运动脑电通常只分析 beta 节律以下的频段，因此在数据处理过程中将数据降采样到 100Hz。




图 4.8 单次想象运动实验过程

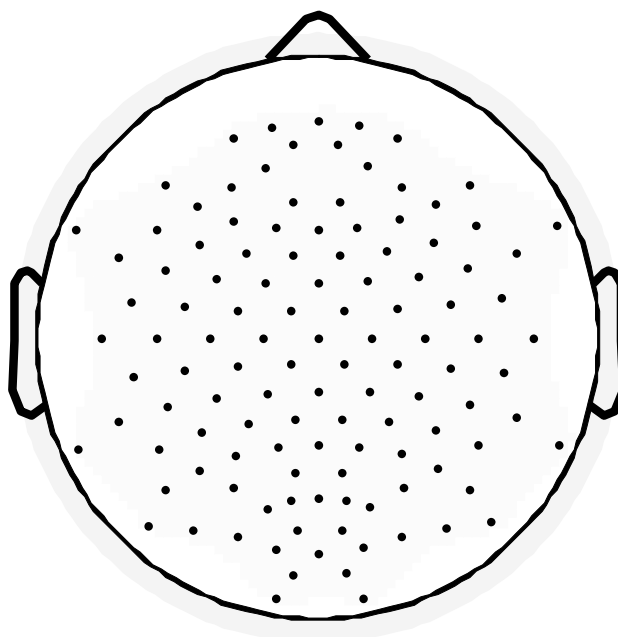


图 4.9 想象运动 118 导联电极位置图

想象运动脑电分类的生理依据是 μ/β 节律和运动准备电位。图 4.10 是受试者 AL 在想象右手和想象脚动时 μ 节律的 ERD/ERS 和运动准备电位在头皮上的空间分布。ERD/ERS 的分布符合躯体特定区分布的特征，想象右手动时，ERD 分布在运动皮层的两侧区域，并且有对侧强同侧稍弱的特征；而想象脚动时，ERD 分布在运动皮层的中央区域，并且在两侧手的区域上还同时存在 ERS。根据 ERD/ERS 的空间分布特征可以判断出受试者运动想象的状态。想象手动和想象脚动时运动准备电位的空间分布也存在差异，想象手动时运动准备电位的分布更广，并且对侧区域上的分布强于同侧；而想象脚动时运动准备电位的分布更为集中，并且在沿中轴线的位置上稍微偏后。运动准备电位的幅度和空间位置也能够提供用于区分大脑想象手动和脚动状态的有用信息。




图 4.10 想象右手/右脚运动时脑电变化的空间分布：(a) μ 节律的 ERD/ERS；(b) 运动准备电位。

4.4.2 想象运动脑电特征提取方法的选择

想象运动脑电的特征提取中使用了三种常用的方法：CSP 空间滤波方法，AR 谱估计方法，以及对侧占优的运动准备电位（lateralized readiness potential, LRP）波形特征的提取。CSP 和 AR 算法提取的是想象运动过程中 mu/beta 节律的 ERD/ERS 特征。在特征结合的方法中，由于 mu/beta 节律和 RP 的独立性，以及不同算法描述的信号特征不同，结合 CSP，AR 和 LRP 三种方法能提高分类的性能。使用特征结合方法的缺点是增加了特征的维数，特征维数的增加会导致分类器推广能力的下降，因此在小样本数据集的处理中有必要选择一种合理的特征提取方法。

CSP 方法的目的是设计能够提取出任务相关脑电的空间滤波器，通过去除不同任务间共有的脑电分量来起到提高信噪比的作用。CSP 方法通过空间滤波把高维脑电数据投影到低维的特征空间，空间滤波器由所有导联位置的权重向量组成，这一线性投影使得两类任务脑电数据的能量差别最大。分析想象手动和想象脚动脑电数据时，使用 CSP 算法设计出两个空间滤波器 \mathbf{S}_H 和 \mathbf{S}_F ，用于从原始脑电信号 \mathbf{X} 提取出和任务相关的源活动 \mathbf{s}_H 和 \mathbf{s}_F ：

$$\mathbf{s}_H = \mathbf{S}_H \cdot \mathbf{X} \quad \mathbf{s}_F = \mathbf{S}_F \cdot \mathbf{X} \quad (4-23)$$

经过 CSP 空间滤波处理后，想象手动时得到的 \mathbf{s}_H 要强于 \mathbf{s}_F ，而在想象脚动时 \mathbf{s}_F 较强，通过比较两种任务相关成分的能量大小可以识别出想象任务的种类，用于分类的特征向量定义为：

$$f = [\text{var}(\mathbf{s}_H) \quad \text{var}(\mathbf{s}_F)] \quad (4-24)$$

在实际应用中，空间滤波器的个数通常取 1 到 3 个，过多的空间滤波器对提高分类正确率的帮助不大，同时还会增大特征的维数。

AR 模型用于估计信号的功率谱，是想象运动脑电分类中常用的方法，它描述了想象运动过程中脑电信号的功率谱特性，将高维的时域原始脑电信号用低维空间的 AR 系数来表示。AR 模型表示如下：

$$x(n) = -\sum_{k=1}^p a_k x(n-k) + u(n) \quad (4-25)$$

$u(n)$ 是方差为 σ^2 的白噪，AR 谱估计的输出是 p 阶的 AR 系数和方差 σ^2 ，对一个导联的脑电信号进行 AR 谱估计，得到的特征向量定义如下：

$$f = [a_1 a_2 \dots a_p \sigma^2] \quad (4-26)$$

在想象运动脑电分类的实际应用中，根据 ERD/ERS 分布的特点，可以在运动皮层代表手动和脚动的区域选择出 N 个不同的导联位置，经过拼接后得到用于分类的特征向量（维数为 $N \times (p+1)$ ）：

$$f = [a_{11} a_{12} \dots a_{1p} \sigma_1^2 \dots a_{N1} a_{N2} \dots a_{Np} \sigma_N^2] \quad (4-27)$$

运动准备电位的分析针对其时域波形的幅度大小，RP 表现为负向慢波，想象任务不同时 RP 的空间分布也不同，LRP 方法用多个导联上的信号平均幅度来表示运动准备电位在空间分布上的特征。每一导联位置的特征定义为 $[t_1 t_M]$ 时间窗内的信号平均幅度， N 个导联的特征经过拼接后构成特征向量：

$$f = [f_1 f_2 \dots f_N], f_i = \frac{1}{M} \left(\sum_{k=t_1}^{t_M} x_i(k) \right) \quad (4-28)$$

对以上三种方法提取出的特征分别采用 Fisher 线性分类器进行分类：

$$y = \varphi(\mathbf{x}) = \text{sign}(\mathbf{w}^T \mathbf{x} + b) \quad (4-29)$$

线性分类器有较低的 VC 维，因此有较好的推广能力^[157]。根据（4-22）式，在训练样本数量固定的情况下，分类器设计的目标是要在保证低经验风险的情况下，使输入特征的维数尽可能低。对比以上三种方法，CSP 方法的特征维数为两类空间滤波器的个数，并且经空间滤波提取出的任务相关脑内源活动包含了多导联信号的信息。AR 方法的特征维数 ($N \times (p+1)$) 和 AR 模型阶次的选择有关，较高的阶次能够更精确地表示谱的特点，但同时也生成更高维的特征；AR 方法的特征维数还取决于使用的导联数目，要保证较低的特征维数只能使用较少的导联，导联选择在减小了特征维数的同时也丢失了有利于分类的大量信息。LRP 方法的特征维数同样取决于所选择导联的数量。

图 4.11 对比了上述三种方法在使用不同大小训练集时的交叉检验分类结果（AR-1ch, AR-2ch 表示使用 1 个和 2 个导联信号的 AR 方法；LRP-5ch 和

LRP-15ch 表示使用的导联数分别为 5 和 15 时的 LRP 方法)。使用受试者 AL 的数据进行分析, 分别采用所有样本的 10%-90% 作为训练集, 特征提取的参数见表 4.2, 表中的参数根据所有样本进行优选得到。以上三种方法中, CSP 方法有最高的分类正确率, 并且不受训练集大小的影响; 而 AR 和 LRP 方法分类正确率较低, 并且随着训练样本的减少而降低, 在训练集大小为 10% 时出现显著的下降。AR 方法由于丢失了部分导联的信息, 性能低于 CSP 方法, 当训练样本足够多时, AR-2ch 方法的性能高于 AR-1ch; 当训练集大小为 20% 时, 两者的性能接近; 而当训练样本数降到 10% 时, 由于具有较好的推广性能, AR-1ch 的正确率反而高于 AR-2ch。使用 LRP 方法时的结果和 AR 方法类似。由以上的分析比较可见, 在小样本训练中, 使用 AR 和 LRP 方法需要根据经验风险和置信范围对特征维数做出折衷选择; 而 CSP 方法在使用优选参数的情况下, 算法的性能基本不受样本训练集大小的影响, 因此更适用于小样本想象运动脑电的特征提取。




图 4.11 CSP, AR 和 LRP 方法在使用不同大小训练集时的分类正确率

表4.2 受试者AL特征提取使用的参数

方法	频带 (Hz)	时间窗 (秒)	导联数	特征维数
CSP	12-14	0.7-4.3	37	2
AR(2/1)	8-35	0.5-4.5	2/1	16/8
LRP(15/5)	0.05-1.5	0.5-1.5	15/5	15/5

4.4.3 特征提取的参数优选方法

通过特征提取方法的比较，我们选择 CSP 算法来分析小样本想象运动数据，由前面的分析可以知道，在选择优化参数的前提下，CSP 算法具有很好的推广能力。在上一节中，比较三种特征提取方法的性能时使用的优化参数是由所有样本通过交叉检验得到的；而在实际的在线分类过程中，需要根据数量有限的训练样本来确定特征提取参数。参数选择根据以下两条准则来进行：

1) 分类器输出结果的分布符合两类样本的概率分布。数据集中，想象右手和想象脚动的样本个数相同，因此分类器的输出应符合以下关系：

$$P(y = -1) = \int_{-\infty}^0 pdf(x)dx, P(y = 1) = \int_0^{+\infty} pdf(x)dx, P(y = -1) = P(y = 1) = 0.5 \quad (4-30)$$

其中 $y = \pm 1$ 表示样本标签（1 表示脚动，-1 为手动）， x 为线性分类器取符号函数之前的输出， $pdf(x)$ 为 x 的概率密度函数（probability density function, pdf）。使用这一准则的前提是实验中各类样本的概率确定或可预测。在实际应用中训练集数据中样本的概率已知，而在 BCI 在线使用过程中也可以根据应用的类型来预测不同种类样本的概率。

2) 在较短的时间内，假定大脑的状态基本稳定，可以认为训练集和测试集的样本服从同样的特征分布，因此可以认为训练集和测试集有相似的 $pdf(x)$ 。可以通过计算相关系数（correlation coefficient）来判断训练集和测试集的相似性。在由训练集得到的经验风险基本不变的情况下，参数选择的目标函数定义为最大化训练集和测试集 $pdf(x)$ 的相关系数（TR 和 TE 分别表示训练集和测试集）：

$$\max \rho(pdf(x^{TR}), pdf(x^{TE})) = \frac{\text{cov}(pdf(x^{TR}), pdf(x^{TE}))}{\sigma_{pdf(x^{TR})} \sigma_{pdf(x^{TE})}} \quad (4-31)$$

根据以上两条准则，对所有两类样本构成的数据集，理想的 $pdf(x)$ 应符合双峰分布，并且两个峰互相对称；而对某一类样本的数据，其 $pdf(x)$ 为单峰分布。图 4.12 为对受试者 AL 采用两种不同特征提取参数得到的 $pdf(x)$ 曲线。 x 的取值范围在横轴被分成等间隔的 40 份，纵轴的值表示每一份中样本的概率。三种曲线分别表示了脚动样本，手动样本和所有样本的概率分布， x 的值由多次交叉检验得到。图 4.12 (a) 和图 4.12 (b) 中训练集和测试集 $pdf(x)$ 的相关系数分别为 0.04 和 0.81，相应的分类正确率分别为 92.4% 和 99.0%，图 4.12 (a) 中只有训练集的样本分布符合对称双峰分布，测试集中样本分布发生了较显著的变化，四组测试数据之间也存在明显的差异，这种情况下特征选择参数还需要做进一步的调整；而图 4.12 (b) 中训练集和测试集两类样本总和的概率分布均符合对称且互相分离的双峰分布特征，测试集获得了很高的分类正确率。




图 4.12 (a) 参数优选前的 $pdf(x)$ ； (b) 参数优选后的 $pdf(x)$ 。

参数选择的方法联合特征提取和分类进行，除上述两条准则外，同时还以最小化经验风险为目标，对不同的特征提取参数进行搜索，需要选择的参数包括电极位置、时间窗、信号频带。可以根据生理背景进行这些参数的初始化，例如导联位置选择运动皮层所在的区域，而信号的频带选择 μ 和 β 节律所在的频率范围。表 4.3 是五位受试者使用 CSP 算法进行特征提取时使用的优选参数，可以看到想象运动过程中 ERD/ERS 特征提取的参数存在较大的个体差异。

表4.3 五位受试者CSP方法特征提取的个性化参数

受试者	频带 (Hz)	时间窗 (秒)	导联数
AL	12-14	0.7-4.3	37
AA	11-16	0.7-3.5	38
AV	9.5-11.5	1.0-3.5	8
AW	10-15	0.8-4.0	56
AY	9-24	0.7-2.0	20

4.4.4 基于半监督学习的自适应分类算法

4.4.4.1 半监督学习

根据 (4-22) 式，在特征提取和分类方法确定的情况下，进一步提高分类器推广能力的方法是增加训练样本的数量。使用半监督学习^[167] (semi-supervised learning) 的方法可以把分类后的测试样本作为额外的训练样本加入到原有的训练集中。随着测试的不断进行，训练集的样本数将逐渐加大，置信范围逐渐减小。如果能保证经验风险稳定，那么分类器的推广能力将随着测试的进行而逐步提高。只有当测试样本包含对分类有效的信息时，半监督学习的方法才能起作用^[167]。在想象运动脑电数据分类中，已知所有数据采集在较短的时间内完成，也就是说受试者的状态可以认为基本稳定，因此测试集的样本同样包含了对分类有效的信息；另外，在小样本训练集内的交叉检验结果也保证了测试集有较高的分类正确率，在这种情况下使用半监督学习的方法是合理的。

4.4.4.2 Bagging 算法

在参数自适应调整的半监督学习过程中，我们采用了 Bagging (bootstrap aggregation) 的方法来设计分类器。Bagging 方法得到的是一个组合分类器 (ensemble classifier)，其中的分量分类器 (component classifier) 为 (4-29) 式的 Fisher 线性分类器：

$$y_B = \varphi_B(\mathbf{x}) = E_L[\varphi(\mathbf{x}, D_L^{(B)})] \quad (4-32)$$

其中 D_L 为训练集， $D_L^{(B)}$ 为自助数据集 (从原始训练集中随机选择的部分样本组成的新训练集)， E_L 表示在整个训练集上的期望。Bagging 算法的计算过程如下^[158]：从原始数据集中分别独立随机地抽取部分样本构成自助数据集，每一个自助数据集都被用于训练一个分量分类器并对测试样本进行分类，最终的分类结果根据所有分量分类器的输出决策进行投票来决定。

Bagging 算法最早由 Breiman 提出，其作用是在保证分类性能不变的情况下减小分类性能的方差^[168]。Bagging 方法通过自助数据集的投票来确定最终的分类结果。在多个数据集的投票过程中，由数据集中小部分不稳定因素造成的错误判决最终将被忽略，而由大部分稳定因素给出的判决结果将被保留。训练数据较小的变化就会导致分类器和分类正确率较大变化被称为不稳定分类。在不稳定分类的情况下，Bagging 算法能够提高分类器的性能。公式 (4-33) 到 (4-36) 证明了 Bagging 算法在分类器不稳定情况下得到的预测误差小于分量分类器的平均预测误差。

假定 (\mathbf{x}, y) 为 D_L 中的独立的样本， \mathbf{x} 为样本的特征向量， y 为类别标签，服从分布 P ，使用 Bagging 分类器对 \mathbf{x} 进行预测，得到的输出为：

$$\varphi_B(\mathbf{x}, P) = E_L[\varphi(\mathbf{x}, D_L^{(B)})] \quad (4-33)$$

预测误差定义为对所有样本预测均方误差的期望：

$$e_B(\mathbf{x}, P) = E_{y,\mathbf{x}}(y - \varphi_B(\mathbf{x}, P))^2 \quad (4-34)$$

而分量分类器的平均预测误差为：

$$e(\mathbf{x}, P) = E_L E_{y,\mathbf{x}}(y - \varphi(\mathbf{x}, D_L^{(B)}))^2 \quad (4-35)$$

根据 $E(x^2) \geq (Ex)^2$ ，可以证明 Bagging 的预测误差低于分量分类器平均误差：

$$\begin{aligned}
e^2 &= Ey^2 - 2Ey\varphi_B + E_{y,x}E_L\varphi^2(\mathbf{x}, D_L^{(B)}) \\
&\geq Ey^2 - 2Ey\varphi_B + E_{y,x}(E_L\varphi(\mathbf{x}, D_L^{(B)}))^2 \\
&= Ey^2 - 2Ey\varphi_B + E_{y,x}(\varphi_B(\mathbf{x}, P))^2 \\
&= e_B^2
\end{aligned} \tag{4-36}$$

Bagging 方法的性能改善程度取决于 $E_L\varphi^2(\mathbf{x}, D_L^{(B)})$ 和 $(E_L\varphi(\mathbf{x}, D_L^{(B)}))^2$ 间的差别，当分量分类器都很稳定时，两者的差别很小；而当分量分类器不稳定时，Bagging 的改进效果明显^[168]。

在半监督学习过程中，Bagging 方法起着重要的作用。在学习过程中，少数的错分样本也被同时加入到原有的训练集中，从而引入了部分不稳定因素，可能引起后续样本分类时的不稳定性。使用 Bagging 方法能够削弱少数错分样本对分类器性能的影响，使得新增部分的训练样本可以近似认为是正确标签的样本，从而起到提高分类器推广能力的作用。我们对竞赛数据集的受试者 AL 的数据进行了仿真测试。将前两组数据作为训练集，后两组数据作为测试集，随机选择训练集中 30% 的样本作为错分样本（手动更改类别标签），自助数据集的大小为训练集的 50%，分量分类器的个数为 50。使用包含错分样本的训练集后，分量分类器的平均分类正确率从 99.1% 下降到 83.4%，但 Bagging 分类器的分类结果保持在 95.7%，大大高于分量分类器的平均分类正确率。仿真结果说明，Bagging 方法在半监督学习的过程中能够去除错分样本带来的不稳定性，从而保证新分类器有更好的推广能力。

4.4.4.3 自适应分类

将带有标签的训练集表示为 $D_L = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_L, y_L)\}$ ，其中 \mathbf{x} 是样本的特征向量，而 y 是类别标签。测试集可以表示为 $D_U = \{(\mathbf{x}_{L+1}, y_{L+1}), \dots, (\mathbf{x}_{L+U}, y_{L+U})\}$ ，训练集中的 y 已知，分类的任务是要给出测试集的类别标签。小样本想象运动脑电数据集中，训练集的大小为 L ，测试样本数为 U ，每位受试者的数据集包含了四组数据。在小样本学习的情况下，假定训练集仅为第一组的部分数据，则测试集由四部分组成，分别是第一组的剩余测试样本和其它三组数据的全部样本（表示为 $D_{U1}-D_{U4}$ ）。图 4.13 表示了基于半监督学习方法的自适应分类过程，具体描述为以下几个步骤：

- 1) 根据初始的训练集 D_L 采用有监督的学习模式来识别第一组数据中的测试样本 D_{U1} ，使用联合特征提取和分类的参数优选方法来确定特征提取的参数，使用 CSP 算法进行特征提取，采用 LDA 作为分量分类器，最终的判决结果 $[y_{L+1}, \dots, y_{L+U1}]$ 由 Bagging 分类器投票给出；
- 2) 使用半监督学习的模式进行分类，更新训练样本集，将 D_{U1} 加入到原训练集 D_L 中构成新的训练集，使用更新后的训练集识别第二组数据，为了从新训练样本中获得更多的信息，对新训练集重新进行特征提取参数的选择，特征提取和分类的方法不变；
- 3) 继续更新训练样本集，将已标签的测试样本加入到现有训练集中，采用与步骤 2 相同的方法分别对第三和第四组数据进行分类。




图 4.13 自适应分类算法框图

随着自适应学习和分类的进行，训练集将包括越来越多的可靠样本。由小样本学习引起的过学习问题由于训练样本数的增加而被逐渐削弱，因此分类器的推广能力得到改善。自适应分类的方法可以直接应用到在线 BCI 系统中，从而缩短系统参数初始化的训练过程。

4.4.5 结果及讨论

我们使用两个不同的数据集对上述“小样本学习想象运动脑电分类”的算法进行了测试。数据集 1 为第三届国际脑-机接口竞赛数据集 IVa，数据集 2 是我们自己设计的在线脑-机接口实验中采集的想象运动脑电。数据集 2 的实验任务为通过想象运动来控制光标的一维运动（想象左手运动控制屏幕上的光标向上运动，想象右手运动控制光标下降），在想象过程中光标的实时运动作为反馈信号，有关实验的具体说明将在第五章介绍。数据集 2 也包括了五位受试者（FL，MY，SJH，WW，ZD）。实验中每位受试者都采集了四组数据，每组数据包含 60 个样本，第一组数据用作训练集，后三组用作测试集（训练样本和测试样本的数量分别为 60 和 180）。

在数据集 1 的处理中，对使用 CSP 算法性能较低的受试者 AA 和 AV 还采用了特征结合的方法，加入了 AR 和 LRP 方法的特征；而对其它三位受试者仅使用了 CSP 算法，一方面因为 CSP 方法在训练集获得了很高的分类正确率，另一方面也为了保证受试者 AW 和 AY 由小样本训练集得到的分类器能有较好的推广能力；对训练样本很少的受试者 AW 和 AY 还采用了基于半监督学习的自适应分类算法。表 4.4 是第三届脑-机接口数据竞赛公布的部分结果^[169]，我们提交的结果在所有 14 个参赛小组中排在第一位，五位受试的平均分类正确率为 94.17%，远远高于第二名的 85.12%。其中受试者 AW 和 AY 的分类正确率分别为 100%和 97.6%，可以认为没有发生过学习问题；受试者 AA 和 AV 的结果也好于其它小组，证明了特征结合方法的有效性。表 4.5 是两个数据集训练集和测试集的分类正确率，对所有 10 名受试者训练集和测试集的平均分类正确率分别为 95.1%和 95.4%，大部分受试者（8/10）的测试集分类结果略高于训练集，证明了基于半监督学习的自适应算法对分类器性能的改善作用。

表4.4 BCI Competition III 数据集IVa部分提交结果的正确率 (%)

排名	提交人	正确率	AA	AL	AV	AW	AY
1	Yijun Wang	94.17	95.5	100.0	80.6	100.0	97.6
2	Yuanqing Li	85.12	89.3	98.2	76.5	92.4	80.6
3	Liu Yang	83.45	82.1	94.6	70.4	87.5	88.1
4	Zhou Zongtan	72.62	83.9	100.0	63.3	50.9	88.1
5	Michael Bensch	69.17	73.2	96.4	70.4	79.9	50.8
6	Cedric Simon	68.57	83.0	91.1	50.0	87.9	54.4
7	Elly Gysels	67.86	69.6	96.4	64.3	69.6	61.9
8	Carmen Viduarre	64.05	66.1	92.9	67.3	68.3	50.4

表4.5 小样本想象运动数据集分类结果

受试者	训练样本 /测试样本	正确率±标准差 (%)		
		训练集	测试集	
1	AL	224/56	99.4±0.21	100
	AA	168/112	95.1±0.45	95.5
	AV	84/196	91.3±1.13	80.6
	AW	56/224	98.1±1.93	100
	AY	28/252	98.2±1.69	97.6
2	FL	60/180	83.7±6.01	86.1
	MY	60/180	98.2±1.81	100
	SJH	60/180	95.3±2.62	99.4
	WW	60/180	98.5±1.80	100
	ZD	60/180	93.4±3.12	95
平均值	——		95.1	95.4

从表 4.5 中可以看到竞赛数据集的受试者 AV 还存在过学习的问题，训练集

上交叉检验得到的分类正确率为 91.3%，而在测试集中下降为 80.6%。与其他受试者相比，受试者 AV 想象运动脑电信号的特征较弱，使用 CSP 方法的分类正确率较低，在采用了特征结合的算法后，训练集的正确率和仅使用一种特征提取方法相比有了较大的提高（CSP：84.3%，AR：82.6%，LRP：82.3%），但在经验风险减小的同时也增大了特征维数，造成了分类器推广能力的下降，因此在测试集中没有取得预期的分类结果。特征结合方法在受试者 AA 的数据集上获得了较好的效果，特征结合后训练集的分类正确率为 95.1%（CSP：93.4%，AR：92.2%，LRP：90.3%），而测试集的正确率为 95.5%，这在一定程度上和受试者 AA 的训练样本数较大有关。另一方面，由于受试者 AV 从训练集得到的分类正确率较低，为防止过多错分样本对后续分类结果的影响，在 AV 数据的分析中没有采用自适应分类的方法。

基于半监督学习的自适应分类算法在离线数据分析中取得了较好的结果，大部分受试者获得了高于小样本训练集的分类性能，但要实现在线系统的自适应分类，需要注意以下几个问题：首先是参数更新的自动完成，在离线分析中的参数更新往往加入了较多的人工干预，而在线系统需要确定参数优化的准则以便程序能自动完成参数更新；另一方面是要满足自适应分类中计算的实时性要求，基于特征提取和分类的参数优选需要重复进行多个参数的搜索和分类结果的计算，使用 Bagging 算法也进一步加大了计算量，减少自适应分类的计算量可以考虑设计合理的参数更新模式（如缩小参数搜索的范围，分段更新分类器参数等）以及使用在线优化算法。

解决脑-机接口小样本学习问题的另一类方法是设计“组对组”或“人对人”的分类器。“组对组”的方法可以使用受试者以前的样本集来设计分类器，而不需要重新采集样本；而“人对人”的分类器更进一步可以使用其他人的样本集来设计。在对现有数据集的分析中，“人对人”分类器的设计由于个体差异的显著性而无法取得令人满意的结果；“组对组”分类器的难点是要解决脑电信号的时变性（包括大脑状态的改变，以及可能由采集设备引入的变化，如电极位置的偏差等），根据想象运动 ERD/ERS 空间模式设计的“组对组”分类器有一定的可行性，已被尝试用于想象运动脑电和皮层电位的分析中^[163]。在当前的脑-机接口研究中，结合“小样本学习”和“组对组”分类器的方法能够更进一步地提高想象运动脑-机接口的实用性。

4.5 无训练样本的休息状态脑电自动检测

4.5.1 BCI Competition III数据集IVc

在论文的第一章中我们强调了“休息状态自动检测”在脑-机接口应用中的重要性：一方面 BCI 系统的独立性要求对系统的工作状态进行实时检测，另一方面无训练样本的自动检测能够大大减少训练时间，大脑休息状态的不稳定性需要大量的样本才能保证机器学习算法的稳定性。第三届脑-机接口数据竞赛的数据集 IVc 提出了“休息状态脑电无训练样本的自动检测”的问题^[50]。数据集 IVc 的实验过程和数据集 IVa 的“小样本想象运动脑电分类”基本相同，IVc 的训练集包括两类样本，分别是想象左手运动和想象右脚运动，而测试集中有三类样本，除两类想象任务外还包括休息状态。测试集中每次任务持续时间仅为 1 秒，数据分析的难点在于如何仅用两类想象运动训练样本来完成休息状态样本的识别，同时还要保证想象运动任务的正确分类。本节的工作由本实验室的张丹合作完成。

图 4.14 是想象左手、想象右脚和休息时 μ 节律 ERD 在头皮上的分布，休息状态根据竞赛公布的结果由测试集中的休息样本计算得到。想象手动时的 ERD 分布在左右两侧运动皮质区域，而想象脚动时的 ERD 位于中央区域内。把想象手动和想象脚动时 ERD 分布的区域定义为 A1 和 A2，两个区域在空间位置上相互独立。在休息状态下，运动皮质处于空闲状态，在 A1 和 A2 区域内都没有明显的 ERD 特征。




图 4.14 ERD 空间分布：(a) 想象手动；(b) 想象脚动；(c) 休息状态。

表 4.6 总结了三种状态下 ERD 空间分布的特点，提出了使用想象手动和脚动两类样本自动检测休息状态的方法：根据 A1 区域内 ERD 的有无可以把三类

样本分成想象手动 (-1) 和想象脚动/休息 (+1) 两类；根据 A2 区域内 ERD 的有无可以区分想象脚动 (+1) 和想象手动/休息 (-1)；对两种类别的标签分别求均值得到三类样本标签 (想象手动: -1, 想象脚动: +1, 休息: 0)。根据上述方法, 分类器设计的任务是从想象左手和想象脚动两类训练样本中设计出检测 A1 和 A2 区域内 ERD 的分类器。由于 A1 和 A2 区域在空间分布上相互独立, 因此使用想象手动和脚动的训练样本可以设计出所需要的两个分类器。

表4.6 手动、脚动和休息三种状态的理想分类结果

任务	A1 类别标签	A2 类别标签	A1+A2 类别标签
想象手动	-1	-1	-1
想象脚动	+1	+1	+1
休息	+1	-1	0

4.5.2 特征提取和分类器设计

ERD 特征的提取仍然采用 CSP 算法, 使用训练集的样本可以设计出用于提取两类想象任务相关源活动的一组空间滤波器 \mathbf{SF}_H 和 \mathbf{SF}_F , 空间滤波后得到的三类样本的源活动 \mathbf{s}_H 和 \mathbf{s}_F 有如下关系:

$$\mathbf{s}_H = \mathbf{SF}_H \mathbf{X} : \mathbf{SF}_H \mathbf{X}_R \approx \mathbf{SF}_H \mathbf{X}_H > \mathbf{SF}_H \mathbf{X}_F \quad (4-37a)$$

$$\mathbf{s}_F = \mathbf{SF}_F \mathbf{X} : \mathbf{SF}_F \mathbf{X}_R \approx \mathbf{SF}_F \mathbf{X}_F > \mathbf{SF}_F \mathbf{X}_H \quad (4-37b)$$

其中 \mathbf{X}_R , \mathbf{X}_F , \mathbf{X}_H 分别为休息, 想象脚动和想象手动时的多导联脑电数据矩阵, \mathbf{SF}_H 用于提取想象手动时能量较高的源活动, 即 A2 区域的 ERD 特征; \mathbf{SF}_F 用于提取想象脚动时能量较高的源活动, 即 A1 区域的 ERD 特征; 休息状态 A1 和 A2 区域都没有 ERD, 因此能量都处于较高的状态。

三种任务的识别分为以下两个步骤进行:

1) 区分休息和非休息状态。测试集中想象任务持续时间仅为 1 秒, 但每个任务之间还有 1.75 到 2.25 秒的休息时间, 因此休息状态的样本持续时间可以定为 2.75 秒。图 4.15 为检测休息状态的流程图, 信号预处理取 0.7-2.75 秒的时间窗, 针

对 μ 节律做 12-14Hz 的带通滤波，根据单个 CSP 空间滤波器设计的分类器采用 Bagging 算法对测试样本进行分类，再对两组分类器的输出结果求均值得到 y_1 。根据表 4.6，休息状态检测的结果如下：

$$z = \begin{cases} 0 & k_1 < y_1 < k_2 \\ y_1 & y_1 < k_1 \text{ 或 } y_1 > k_2 \end{cases} \quad (4-38)$$

k_1 和 k_2 为手工指定的阈值，阈值范围内的测试样本被认为是休息状态，而其它样本则为想象运动状态，等待下一步的处理。




图 4.15 休息状态检测流程图

2) 区分想象左手和想象脚动状态。图 4.16 为想象手动和想象脚动分类的流程图，分类过程基本不变，因为想象任务持续时间为 1 秒，信号预处理时采用的时间窗为 0.6-1.2 秒，带通滤波为 11-27Hz。在训练集数据的分析中，采用较宽的信号频带（同时包括 μ 和 β 节律）能够提高两类想象运动分类的正确率。竞赛采用预测的均方误差作为评价标准，为减小均方误差，想象运动状态的最终分类结果按以下方法做归一化处理：

$$z = \begin{cases} -1, & \text{if } y_2 < k_3 \\ -\frac{y_2}{k_3}, & \text{if } k_3 \leq y_2 \leq 0 \\ \frac{y_2}{k_4}, & \text{if } 0 \leq y_2 \leq k_4 \\ 1, & \text{if } y_2 > k_4 \end{cases} \quad (4-39)$$

k_3 和 k_4 为手工指定的阈值，-1 表示想象手动状态，1 为想象脚动状态，剩余部分样本的输出结果归一化到 -1 和 1 之间。




图 4.16 想象手动和想象脚动分类流程图

4.5.3 分类结果

在测试集中一共有 420 个样本（每类样本各 140 个），数据竞赛中提交的结果用均方误差来评价：

$$MSE = \frac{1}{420} \sum_{i=1}^{420} (y_i - z_i)^2 \quad (4-40)$$

z_i 为预测结果， y_i 为样本标签。如果指定所有的样本分类结果均为 0，相应的均方误差为 0.667。表 4.7 为脑-机接口数据竞赛公布的比赛结果^[169]，我们提交的结果在 7 个小组中排第一位，均方误差为 0.30，与其它小组相比有明显的优势^[50]。

表4.7 BCI Competition III 数据集IVc结果

排名	提交人	均方误差	合作人
1	Dan Zhang	0.30	Yijun Wang
2	Liu Yang	0.59	Hu Dewen, Zhou Zongtan, Zang Guohua
3	Zhou Zongtan	0.60	Hu Dewen, Liu Yang
4	Bo Hong	0.67	Soumyadipta Acharya, Nitish V. Thakor
5	Kiyoung Yang	0.74	Hyunjin Yoon, Cyrus Shahabi
6	Cyrus Shahabi	0.88	Kiyoung Yang, Hyunjin Yoon
7	Hyunjin Yoon	1.33	Kiyoung Yang, Cyrus Shahabi

图 4.17 为提交结果中前两名的三类样本分类结果，可以看到第二名的结果

在区分两类想象运动状态时取得了很好的效果，但大部分休息状态的样本被误分为两类想象状态；我们算法的优势在于能够较好地检测出休息状态，并且在想象运动的分类中也获得了较高的正确率。以上数据分析结果表明，休息状态时大脑的感觉运动皮层没有明显的 ERD 发生，始终存在比较稳定的 μ 节律，因此 μ 节律的特征适合用于想象运动 BCI 系统的空闲状态检测。




图 4.17 第三届脑-机接口数据竞赛数据集 IVc 三种任务脑电分类结果：(a) 第一名；(b) 第二名。（来自[169]）

在同步方式工作的多分类想象运动脑-机接口系统中，可以采用类似的方法，用想象左右手两类训练样本来实现想象脚动状态的自动检测，这一方法在实际应用中能够起到缩短训练时间的作用。图 4.18 为三类想象运动状态下 C3/C4 导联 μ/β 节律的能量分布，想象左右手运动时，ERD 的分布具有明显的对侧显著的特点，而想象脚动时的 C3/C4 上的能量都较高。如果设计一个线性分类器对想象左右手两类任务进行分类，如图 4.18 中的实线所示，左右手两类样本能很好地区分，但想象脚动的样本则混在左右手样本中而无法识别。如果分别

用 C3 和 C4 导联的能量特征来设计两个用于检测两侧皮层的 ERD 的分类器，想象左右手两类样本的两条分类线如图中虚线和点画线所示，可以看到绝大部分想象脚动的样本落在表示 C3/C4 均无 ERD 的右上角区域内。使用上述方法，即使在无训练样本的情况下，想象脚动的状态也可以被准确地识别。




图 4.18 三分类想象运动脑电 C3/C4 导联能量特征分布

4.6 本章小结

本章以“脑-机交互适应学习”方法在脑-机接口中的应用为背景介绍了在脑-机接口中常用的特征选择和分类算法。在有自适应学习功能的在线脑-机接口系统中，需要解决训练样本的获取和自适应分类器参数更新等问题，使用合理的特征提取、特征选择和分类器设计方法能大大提高在线系统的性能。本章的工作为在线脑-机接口系统的设计和实现奠定了基础。

在对“小样本想象运动脑电数据分类”的分析过程中，基于统计学习理论，我们根据想象运动脑电分类的特点，提出了解决“过学习”问题的三条对策：1) 选择特征提取方法，2) 联合特征提取和分类的参数优选方法，3) 半监督学习

的自适应分类算法。这一系列方法在第三届脑-机接口数据竞赛的数据集 IVa 获得了小组第一名，在我们自己采集的想象运动数据集上也取得了满意的结果，测试数据和训练数据的分类性能基本相同，部分测试数据的分类正确率还高于小样本训练集的正确率。

在线脑-机接口系统机器学习的另外一个难点是大脑的“空闲状态检测”，我们根据想象运动过程中 ERD 空间分布的特点，由想象手动和想象脚动两类训练样本设计出了能自动区分“休息状态”的分类器，实现了“休息状态脑电的自动检测”。这一方法在第三届脑-机接口数据竞赛的数据集 IVc 获得了小组第一名。这一方法还被尝试于三类任务想象运动的分类，仅使用想象左右手两类训练样本实现了想象脚动状态的自动检测，这一应用有助于进一步缩短想象运动在线脑-机接口的训练时间。

第 5 章 基于想象运动脑电的在线脑—机接口系统

脑—机接口技术 (BCI) 的出现使人脑与外界环境的直接通讯成为可能^[1]。基于想象运动的脑—机接口是当前 BCI 研究的热点^[1,4,5,49,50], 从 BCI 应用的角度看, 想象运动脑电分类具有较高的正确率, 并且能够实现多任务模式; 从脑功能研究的角度看, 它能够作为运动控制 (motor control) 和运动意图 (motor intention) 研究的平台。基于脑电 mu 节律调制的生理背景, 本章的工作设计并实现了想象运动在线脑—机接口系统。

5.1 想象运动脑—机接口的原理

现有的想象运动 BCI 有两种模式: 一种是采用机器学习的算法来识别大脑的运动想象状态, 比如区分左手、右手、脚、舌头等不同躯体部位的运动想象状态^[10,93,94,170]; 另一种是通过反馈训练来让使用者能够借助想象运动来实时调节运动相关的 mu 和 beta 节律的幅度, 从而控制一维或二维的光标运动^[11,43,171-173]。

在想象运动脑—机接口中, 数据分析主要针对的是大脑运动皮层相应区域的 mu 和 beta 节律的事件相关去同步化和同步化 (ERD/ERS) 现象。ERD/ERS 表现为一定频带范围内脑电信号能量的下降或上升, 想象运动引起的 ERD/ERS 通常出现在 mu 和 beta 节律所在的 8-12Hz 和 18-26Hz 的范围内, 在空间分布上符合大脑感觉运动皮层的躯体特定区域分布^[40]。想象左右手运动时, 最显著的 ERD 出现在对侧运动皮层的手对应区, 而想象脚动时 ERD 出现在脚对应的中央区域。除 ERD 外, 想象运动还可能同时伴随着 ERS 现象, 例如想象脚动时, 在中央区域出现 ERD, 而在两侧的手对应区内可能出现 ERS^[86]。从运动想象脑电中提取出 ERD/ERS 在空间分布上的特点是实现想象运动脑—机接口的关键。

5.2 想象运动在线脑—机接口设计

5.2.1 脑—机接口在线系统框图

第一章提出了在线脑—机接口设计的几个难点: 系统的实时性、系统的实用性、脑—机交互学习。在线系统的实现首先要解决的是数据处理的实时性,

包括脑电数据的实时获取以及特征提取和模式分类的实时计算。本文设计的在线系统以荷兰 BioSemi 公司的 128 导 ActiveTwo 脑电图机^[174]为数据采集平台，采用基于 TCP/IP 协议的服务器-客户端数据通讯方式来实时获取脑电数据。BioSemi 脑电图机实时采集的数据量为每秒 1.5 兆字节，为保证数据采集的稳定，由一台 PC 专门负责脑电数据采集，并作为实时数据传输的服务器。数据通讯的客户端为另外一台 PC，脑电数据的在线处理和实时反馈的呈现均由客户端完成。服务器根据客户端的需要实时发送脑电数据，客户端在接收到数据后由程序执行预处理、特征提取、模式分类等数据分析步骤，并给使用者提供实时的视觉反馈信息。系统的软件平台基于美国 NI 公司的 LabVIEW^[175]环境开发，服务器端使用的数据采集程序由 BioSemi 公司提供，客户端的在线脑电数据分析由我们自己设计完成。客户端程序采用在 LabVIEW 中嵌入 Matlab 脚本的编程模式，LabVIEW 的优点在于其图形化编程方式，图形界面的编写十分方便，并且还提供了丰富的信号处理函数库；在线数据由 Matlab 在后台完成，使用 Matlab 脚本便于算法的修改和测试。经过大量在线实验的测试，上述方案能满足脑-机接口在线系统实时性的要求。

图 5.1 是想象运动脑-机接口在线演示系统框图，系统包括三个主要组成部分：BioSemi 脑电图机，负责数据采集和发送的服务器 PC，数据在线处理及提供任务提示和视觉反馈的客户端 PC。

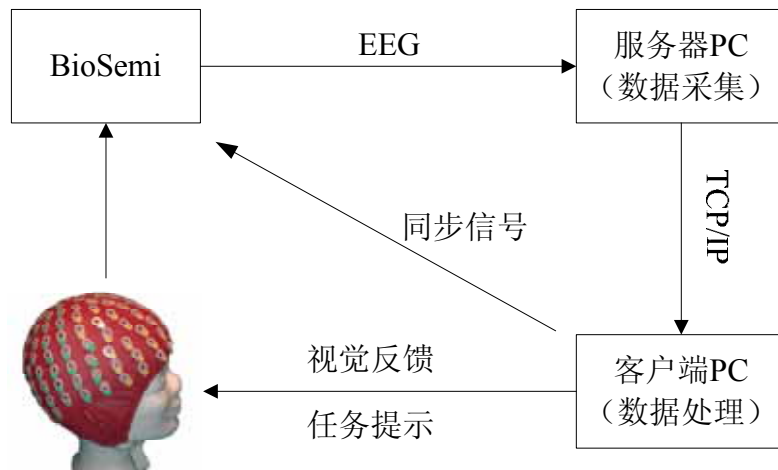


图 5.1 想象运动脑-机接口在线演示系统框图

在线系统的使用包括以下几个环节：

- 1) 脑电数据采集：安装好电极后，根据客户端程序的要求选择需要发送的数据格式（包括采样率和导联数）。启动服务器 PC 上的数据采集程序进入 TCP/IP 监听的状态，等待客户端建立连接。同时采集程序开始本地的实时数据存储，将原始脑电数据保存好用于离线分析。
- 2) 在线数据处理：启动客户端程序，建立和数据服务器的连接并接收来自数据采集 PC 的实时数据，系统开始在线实验。客户端程序除完成在线数据分析和提供视觉反馈两个主要功能外，还需要将在线实验的任务触发信号（trigger signal）以并口通讯的方式发送到 BioSemi 脑电图机，由数据采集 PC 完成触发信号与脑电数据的同步保存以便离线分析。另外，客户端程序可以同时保存所有接收到的脑电数据以及在线处理的结果。
- 3) 离线数据分析：在线实验过程中，可能需要对数据做进一步的分析，这时可以使用离线分析的方法。离线分析可以采用较复杂的信号处理算法，根据离线分析的结果对在线数据处理的参数进行相应的调整，如滤波频带和导联位置等。

5.2.2 想象运动在线实验设计

图 5.2 是想象运动脑-机接口在线实验的框图，每次想象任务的总时间为 8 秒。开始 2 秒为休息时间，受试者处于完全放松的状态，休息状态的后半段要求受试者集中注意力等待想象任务提示的出现；第 3 秒开始时刻，屏幕出现由不同方向的箭头表示的想象运动任务，受试者开始执行持续时间为 6 秒的运动想象；从第 4 秒开始屏幕上出现实时的视觉反馈信息，反馈持续的时间为 5 秒；任务结束时，根据在线反馈给出任务完成的结果（正确或错误）。任务结束后，受试者开始进入下一次实验的休息状态，等待新的任务。

在线实验设计了两种模式，第一种为左右手运动想象控制屏幕光标的一维运动，第二种为左右手和脚的运动想象控制二维平面上三个不同方向进度条的增长。图 5.2 (a) 为两分类实验示意图，任务由屏幕右侧不同方向的箭头提示给出，方向朝上的提示代表想象左手运动，向下的方向指示想象右手运动。通过对大脑运动皮层区域 C3 和 C4 导联的能量特征进行模式分类来识别想象状态，从而控制光标的一维运动，想象左手状态控制光标的上升，而想象右手运动则控制光标的下降。视觉反馈由被控制的光标给出，光标从屏幕左侧的中央位置出现，在水平方向匀速向右运动，垂直方向的运动方向由实时的分类结果决定，光标每秒运动 8 次，以光标出现的位置为原点，屏幕垂直方向的最大最小值为

±40，水平方向最大值为 40。如果在持续 5 秒的视觉反馈过程中，光标在竖直方向上始终向同一个方向运动，任务结束时光标将到达屏幕的右上角或右下角。每次任务的最后结果由光标的位置来决定，如果光标位于屏幕的上半区域则认为受试者在想象左手运动，位于屏幕的下半区域则对应了右手运动想象。图 5.2 (b) 是三分类实验示意图，任务分别为想象左右手动和想象脚动。三任务想象运动分别对应了二维平面上不同的运动方向，想象左右手动分别控制往左和往右两个方向的运动，想象脚动用于控制往前的运动方向，这一模式可以用于控制机器人行走。视觉反馈为三个不同方向的进度条，每次任务开始前，进度条的值被清零，与两类任务类似，进度条每秒更新 8 次，当前显示的是第 4 秒反馈开始出现后分类结果的累积值，进度条的最大值为 40，如果视觉反馈持续的 5 秒内分类器输出结果相同，相应的进度条将增长到最大值。每次任务的正确与否根据三个进度条中的最大值代表的想象运动状态来确定。

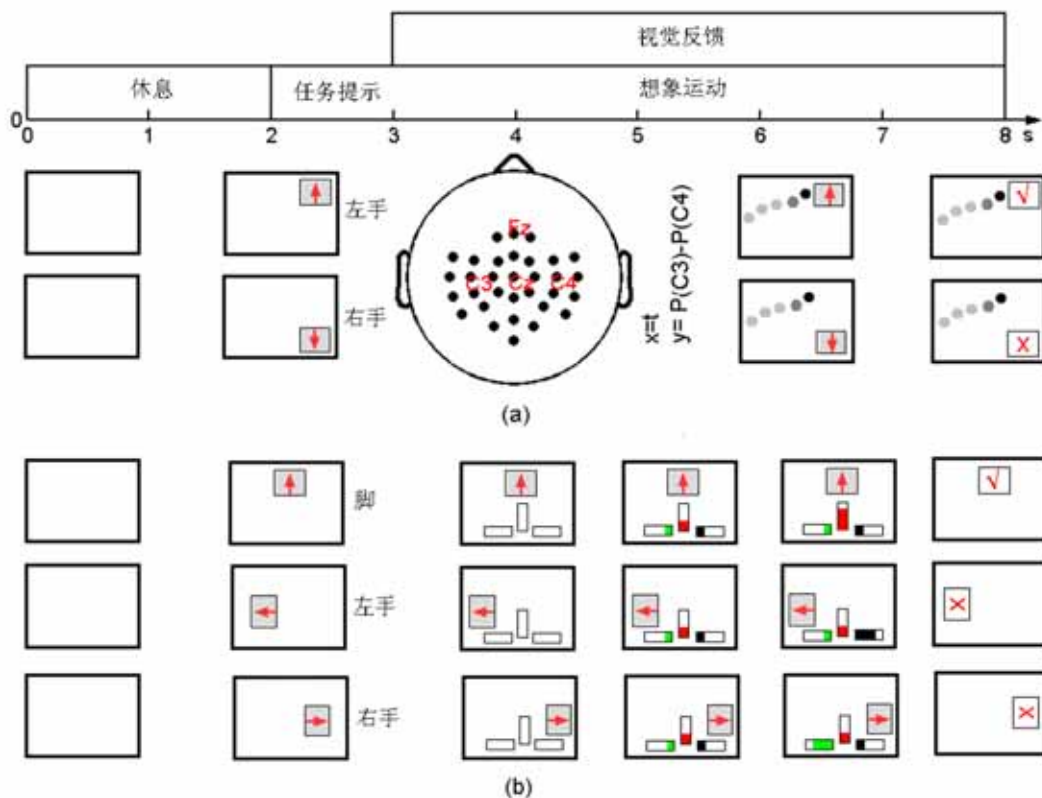


图 5.2 想象运动脑-机接口在线实验示意图：(a) 想象左右手运动两类任务模式；(b) 想象左右手和想象脚动三种任务模式，三行分别为想象脚、左手、右手运动三种任务单次实验过程的示意图。

除屏幕光标控制的演示模式外，我们还将想象运动脑-机接口在线系统应用到真正的外部设备控制中。图 5.3 (a) 为基于在线两分类想象运动的辅助康复训练系统。训练过程中，康复器械的动作由相应肢体的想象运动来触发，这种主动训练 (active training) 模式有助于神经通路的强化和肢体运动功能的恢复^[4]。图 5.3 (b) 为基于三分类想象运动的机器人运动控制系统，通过想象左右手和想象脚动三种状态来控制机器人的二维运动。两名使用者通过这一系统可以控制机器狗进行足球比赛，这一方案还可用于帮助瘫痪病人操作轮椅。



图 5.3 想象运动脑-机接口系统的应用：(a) 康复训练辅助系统；(b) 机器人运动控制系统。

5.3 在线特征提取和模式分类

图 5.4 为采用“训练-控制”两步模式的在线系统特征提取和模式分类算法。训练模式的任務包括以下三个方面：1) 特征提取参数的优化，2) CSP 空间滤波器的设计^[97,98]，3) LDA 分类器的训练^[157]。参数优化采用 4.4 节的方法，选择带通滤波的频率窗和 CSP 预处理的时间窗；CSP 空间滤波器由训练数据获得，同时用于训练和控制模式下脑电数据的空间滤波增强；LDA 分类器的训练使用 CSP 滤波后得到的维数较低的特征向量。在控制模式下，使用由训练数据得到的优化参数，CSP 滤波器和 LDA 分类器来实时检测想象运动的状态。使用 CSP 空间滤波的方法可以提高想象运动脑电的信噪比。训练模式的数据处理有较大的运算量，为了保证控制模式下系统性能的稳定，对训练模式的数据处理使用离线分析的方法。




图 5.4 特征提取和模式分类算法流程图

考虑到系统的实时性和实用性，在线反馈训练过程采用更为简单的计算带通能量的方法，以 C3 和 C4 导联的带通能量为特征进行 LDA 分类器的设计。在线学习中采用了自适应的学习方法，LDA 分类器随着训练过程中样本集的增大而自动更新，两分类光标控制的在线学习可以表示为：

$$y(t) = \text{sgn}(\mathbf{w}(t)^T [P_{C_3}(t) \ P_{C_4}(t)]^T + b(t)) \quad (5-1)$$

\mathbf{w} 和 b 是 LDA 的参数，由 t 时刻之前的样本集训练得到， y 是光标运动的方向（±1）， $P_{C_3}(t)$ 和 $P_{C_4}(t)$ 表示 C3 和 C4 导联的脑电能量（ t 时刻前 1 秒内脑电的平均能量）。实验结果表明，三类想象运动中 C3/C4 导联的能量特征表现为两两线性可分，因此在线学习中的三分类任务被转化为三个两分类问题：

$$y_i(t) = \text{sgn}(\mathbf{w}_i(t)^T [P_{C_3}(t) \ P_{C_4}(t)]^T + b_i(t)), i = 1, 2, 3. \quad (5-2)$$

分类结果由三个 LDA 分类器的输出决定，判决规则见表 5.1。图 5.5 (a) 为一名受试者通过想象左右手运动控制的光标运动轨迹，分别由两类任务的 120 次样本平均得到，想象左手运动时，光标向上运动，想象右手运动光标向下运动。图 5.5 (b) 为一名受试者三类想象运动中视觉反馈的平均概率（每类样本各 120 个），向左向右和向前三种进度条反馈的最大值分别对应了想象左手、想象右手和想象脚动的任务。

表5.1 想象运动三分类判决规则

LDA 1 (左手 / 右手)	LDA 2 (左手 / 脚)	LDA 3 (右手 / 脚)	分类结果
+1	+1	-1	左手
+1	+1	+1	左手
-1	+1	+1	右手
-1	-1	+1	右手
+1	-1	-1	脚
-1	-1	-1	脚
+1	-1	+1	——
-1	+1	-1	——




图 5.5 (a) 屏幕光标一维运动轨迹；(b) 三类想象任务中的视觉反馈进度条。

基于带通能量分类的在线自适应学习的具体步骤如下：

- 1) 预处理参数的初始化：对于新的受试者，采用较常用的参数设置（如 C3/C4 导联，10-15Hz 带通滤波），有足够多的训练样本后再进行离线分析，对预处理参数进行更新；对于参加过多次实验的受试者，使用上次实验优选的参数。
- 2) 分类器参数的初始化：以想象左右手运动分类为例，LDA 分类器的初始值指定为 $\mathbf{w}^T(0)=[+1 \ -1]$ ， $b(0)=0$ 。在想象左右手运动过程中，运动皮层同侧区域 μ 节律的能量高于对侧区域，因此采用计算 C3/C4 的能量差作为初始分类器。
- 3) 训练阶段一：受试者根据由初始化分类器输出的视觉反馈进行基于“大脑学

习”的适应，这一过程持续的时间较短，设置为每类任务 5 次实验。

4) 训练阶段二：训练样本数达到设定值后，开始进入“脑-机交互适应”的学习过程。随着训练的进行，训练样本数量逐渐增加，LDA 分类器进行实时的更新；根据实时的视觉反馈，大脑的学习适应也同时进行。

5) 训练阶段三：样本数量足够大时，分类器开始进行固定样本数量的更新方式，保留最新的样本，去除最初的样本，使分类器最适合于检测当前的大脑状态。

5.4 系统测试

在线想象运动脑-机接口实验在无屏蔽的室内环境中进行，受试者坐在有扶手的椅子上，全身放松，眼睛注视计算机屏幕上的视觉反馈，执行想象任务的过程中要求受试者避免肢体的真实动作。脑电采集使用 BioSemi 公司的 ActiveTwo 脑电图机，共记录 32 导联信号（电极位置见图 5.2 (a)，覆盖了运动皮层相应的大脑区域），采样率为 256Hz。共有 10 名肢体运动功能正常的志愿者（7 名男性，3 名女性，年龄在 22-27 岁之间，均为实验室学生，对脑-机接口的研究均有一定程度的了解）参加了两分类想象运动实验，其中的 5 人还尝试了三分类在线实验。根据受试者状态的不同，用于离线分析的实验数据共保存了 2-5 组，每组实验中每类任务各 30 个样本，各类样本随机出现，每个样本对应的单次实验时间为 8 秒，每组实验中间为 3-5 分钟的休息。

表 5.2 为想象左右手运动两分类实验的结果。在线分析的正确率为“脑-机交互适应”过程的结果，每组数据的前 10 个样本用作在线分类器初始化训练，剩余的 50 个样本用于在线测试。离线分析的正确率由所有样本采用 10×10 交叉检验的方法得到。离线分析对时间窗进行了选择，并且使用了基于 CSP 的空间滤波增强算法，因此分类性能优于在线分析。10 名受试者离线数据分析的平均正确率为 94.92%（83.57%-99.60%），在线分析的平均正确率为 92.86%（79.6%-98.8%）。表 5.3 为三分类实验数据分析的结果，使用参数优化和 CSP 方法的离线三分类结果比在线结果提高了 5.52%（分别为 85.00%和 79.48%）。在三种想象运动任务的两两组合中，分类正确率最高的是想象左右手运动（97.77%），另外两种区分想象手动和想象脚动的结果无明显差别（分别为 88.15%和 88.99%）。5 名受试者中有两人三种想象任务的识别率都很高，其他三人由于想象脚动的识别率较低，三类任务的总正确率低于想象左右手运动。参

加三分类实验的受试者都经过想象左右手运动两类任务的训练，因此想象左右手动的识别率较高；对想象脚动状态的适应可能需要更多的训练，来寻找和强化更为稳定的想象脚动状态。

以上数据分析的结果表明，我们设计的在线想象运动脑-机接口获得了较高的系统性能，多分类系统的实现更有助于想象运动脑-机接口的实用化。系统的特点可以概括为以下几点：1) 系统稳定性高，提取运动皮层区域的 μ 节律能量作为特征；2) 使用电极数少，在线分析算法仅使用 C3/C4 两个导联，因此得到的 LDA 分类器有很好的推广能力；3) 实时的反馈模式，受试者可以在单次实验内得到连续的反馈信息，有利于大脑状态的及时调整；4) “脑-机交互适应”的在线学习模式，大脑学习和机器学习的同时参与进一步提高了在线训练的效率。

表5.2 想象运动两分类实验结果

受试者	样本数	滤波频带 (Hz)	在线正确率 (%)	离线分析	
				时间窗 (秒)	正确率±标准差 (%)
WW	240	12-15	97.5	2.5-7.5	99.60±0.52
MY	240	10-15	97.5	2.5-6	99.28±0.18
CSH	300	11-15	96.4	2.5-8	98.95±0.21
SJH	300	9-14	98.8	2.5-7	98.68±0.29
ZYJ	240	10-15	97	2.5-6	98.42±1.33
HLW	300	13-16	94.4	2.5-8	95.13±0.47
ZD	300	9-16	92	2.5-6.5	94.73±1.71
KYX	300	10-15	88.4	3-8	93.90±0.14
JCH	240	10-15	87	2.5-8	86.97±1.84
FL	300	10-15	79.6	3-8	83.57±0.24
均值	——	——	92.86	——	94.92

表5.3 想象运动三分类实验结果

受试者	样本数	离线分析正确率±标准差 (%)				在线正确率 (%)
		左/右	左/脚	右/脚	三分类	
SJH	360	99.33±0.44	99.61±0.27	97.94±0.59	98.11±0.70	94.00
WW	360	99.83±0.35	96.92±0.97	98.92±0.40	97.56±1.23	94.67
ZYJ	180	98.20±2.57	82.40±4.88	90.60±5.17	80.13±4.68	74.71
FL	180	96.33±1.72	83.67±2.92	85.67±2.63	77.00±2.82	68.00
ZD	180	95.17±1.83	78.17±5.06	71.83±8.66	72.22±4.32	66.00
均值	—	97.77	88.15	88.99	85.00	79.48

5.5 对想象运动脑电分类中几个问题的讨论

5.5.1 离线与在线模式的比较

无反馈的脑-机接口实验数据通常用于研究离线分类算法，在脑-机接口在线系统中也可以用于系统参数的初始化。在基于“大脑学习”的系统中，反馈信息是大脑状态调整的依据，大脑的学习完全依赖于在线反馈^[11,12]。为了研究想象运动的执行对视觉反馈的依赖程度，我们对比了在有反馈和无反馈两种模式下的想象运动脑电能量分布。实验任务为想象右手和想象脚动，在线实验为一维光标运动控制模式。在有反馈和无反馈两种模式下，每类任务各采集30个样本，每次实验的流程与图5.2中的两分类实验相同。

图5.6为两种模式下，想象右手运动和想象脚动时左侧运动皮层C3导联的脑电功率谱。两种模式下C3导联脑电功率谱有明显的差别，在无反馈的模式下两种想象任务中均包含了明显的alpha波谱峰；而在有实时视觉反馈的模式下，视觉皮层处于兴奋状态，枕区alpha节律被明显抑制，从而更突出了mu节律的特征。选择10-15Hz的频率范围计算两种任务带通能量的 r^2 值，分别为0.67和0.28，在无反馈模式下，背景alpha节律的引入降低了mu节律的信噪比；选择13-15Hz的频带避开部分alpha波成分， r^2 值分别为0.77和0.55。由于alpha节律和mu节律在频带上的混叠，使用简单的滤波方法无法完全避免alpha节律的影响。在使用多导联数据的情况下，可以考虑用独立分量分析的方法来提取mu

节律，去除背景 alpha 节律。




图 5.6 想象右手和想象脚动时 C3 导联的功率谱：（a）在线反馈模式；（b）无反馈模式。

图 5.7 比较了两种模式下 r^2 值的空间分布情况，在运动皮层区域内，在线反馈模式的 r^2 值高于无反馈模式，所有导联中 r^2 最大的 6 个导联的均值分别为 0.59 和 0.37。在线反馈模式下，ERD 在运动皮层分布的区域更广，两种模式下 r^2 值大于 0.2 的导联数量分别为 12 导和 6 导。由图 5.7 (c) 两种模式下 r^2 差别的空间分布可以看到，反馈模式下 ERD 更显著的区域位于左侧运动皮层和辅助运动皮层区域。根据这一结果可以进一步提出以下假设：在有反馈模式下参与到想象运动中的运动皮层范围更广。




图 5.7 想象右手和想象脚动时 r^2 的空间分布图：（a）在线反馈模式；（b）无反馈模式；（c）两种模式的差别。

5.5.2 多分类想象运动的分类器设计

为保证系统的稳定性，三分类在线想象运动脑-机接口采用推广性能较好的 LDA 分类器。在线反馈信息来自于 C3 和 C4 导联的带通能量特征，可以把三分类问题转化为三个两分类问题，线性分类器的设计有两种模式：“一对一”的模式以及“一对多”的模式^[157]。一对一的模式的判决规则见表 5.1，三个分类器分别用于区分三类任务的两两组合，最终的判决通过投票得到。“一对多”的模式中两类任务分别是三种任务中的一种以及另外两种任务的组合。

图 5.8 是一名受试者（右利手）三分类想象运动脑电的功率谱。想象左右手动时，C3/C4 导联的 ERD 分布具有对侧占优的特点；而想象脚动时，C3/C4 导联都有较高的带通能量。图 5.9 是 C3/C4 导联带通能量（10-35Hz）的特征分布及两种分类器设计模式下的三条分类线。从 C3/C4 带通能量的特征分布上看，三类任务符合两两线性可分的特点，因此使用“一对一”的分类器更为合理；使用“一对多”的分类器将想象运动任务的识别率，在有部分样本被误判的同时，还将造成较多数量样本的据判（当某个样本被同时识别为两类样本时，分类器无法做出决策）。图 5.10 为想象运动在线三分类系统使用的特征提取和分类算法框图，单次实验的结果由三个“一对一”模式的 LDA 分类器的累积投票结果来决定。




图 5.8 三分类想象运动的脑电功率谱：（a）C3 导联；（b）C4 导联。




图 5.9 三分类想象运动任务下 C3/C4 导联的能量特征分布和分类线：(a) “一对一”的两分类模式；(b) “一对多”的两分类模式。




图 5.10 想象运动脑-机接口在线特征提取和分类算法框图

从图 5.8 中可以看到，在想象运动过程中，大脑两侧运动皮层在 C3/C4 导联的谱分布有较大的差别，左右脑运动区的能量分布具有不对称性。C3 导联还保留了部分 alpha 节律的谱峰，其频率略低于 mu 节律；C4 导联没有明显的 alpha 节律，在想象左手运动时，mu 节律存在显著的 ERD 特征。C3 导联上三种想象任务的 mu 和 beta 节律能量都有较大差异，其中想象脚动的能量最高，而 C4 导联上想象右手和想象脚动能量相同，这一现象与文献[176]中关于真实手指运动前的 ERD 分析结果一致。可以这样解释运动皮层的这种不对称性：想象右手运动时 ERD 有更强的对侧分布特点，仅存在于对侧的 C3 导联；而想象左手运动时，ERD 在 C3/C4 都存在，对侧强于同侧。在图 5.9 (a) 中，区分想象左右手运动的分类线代表的投影方向大致对应了计算 C3/C4 导联的能量差，如果仅使用 C3/C4 导联其中的一个特征来区分想象左右手任务，识别率将大大降低。这一现象表明，在想象左右手运动过程中，大脑的两侧运动皮层都参与了对运动肢体的编码，同时两者之间还存在着较强的独立性，肢体的想象运动过程中包含了两侧运动皮层的相互协作。

5.6 本章小结

本章介绍了基于想象运动的在线脑-机接口系统的设计和实现，详细说明了在线系统的实验框图以及特征提取和分类算法。基于想象左右手运动的一维光

标控制的演示系统可用于实现基于脑-机接口的运动康复训练。基于想象左右手和脚动的三分类系统被成功用于机器人左移、右移和前行的运动控制。运动方向和运动肢体的巧妙对应有助于受试者更好地理解系统的原理，并在训练过程中能正确地执行相应的想象任务。

在系统的应用中，我们提出了分段进行的在线脑-机接口训练和控制方案：1) 基于“脑-机交互适应学习”的在线自适应反馈训练，2) 基于参数优选和 CSP 算法的离线训练，3) 使用优化参数和 CSP 空间滤波方法的在线控制。在基于三分类想象运动系统的机器人运动控制应用中，系统获得了较高的性能。

共 10 名受试者参加了两分类系统的性能测试，在线和离线分析的平均分类正确率为 92.86%和 94.92%；5 名受试者参加了三分类系统的测试，在线和离线分析的平均正确率分别为 79.48%和 85.00%。测试结果表明，基于运动皮层脑电节律调制的方法有较高的稳定性，适用于实用化脑-机接口系统的设计。在线系统的实现为想象运动脑-机接口的实用化研究提供了一个很好的平台，同时也使得更深入地进行想象运动过程中脑-机交互学习的研究成为可能。

第 6 章 基于运动皮层同步化的在线脑-机接口系统

本文的 3.3 节介绍了脑电节律的同步化分析方法，在基于节律调制的脑-机接口中，计算大脑不同区域间脑电信号的同步化可以作为一种特征提取方法。由于同步化特征与脑电模式分类中常用的幅度或能量特征在生理机理上的差异，两种特征有较强的独立性，因此可以通过特征结合的方法来提高脑-机接口系统的性能。本章将深入研究想象运动中大脑运动皮层的同步化现象，并对多种脑电同步化特征提取的方法进行对比分析，选择适用于在线系统的特征提取算法，进一步实现基于脑电节律同步化的在线脑-机接口系统。

6.1 大脑同步化研究背景

对大脑组织各种水平的同步化现象的研究是当前神经科学研究的热点之一。不论是在单个神经元对，或者大范围的神经元群体间；还是在在大脑皮层的某一区域，或者是不同的区域之间，同步化现象都广泛地存在。认知行为必须依靠广泛分布在大脑中大量功能分区自身的瞬时整合及相互间的持续协作来完成。对于大脑的整合和同步 (brain integration and synchrony)，普遍认为存在两种不同空间范围的整合^[138]：一种是局部的整合 (local-scale integration)，表示同一大脑分区内神经元之间的影响，发生在毫米量级的范围内，例如在初级视皮层，2-7 毫米范围内的神经元活动具有相同的特性从而呈现同步化现象，局部的同步化强度往往和记录电极间的距离成反比关系；另一种是大范围的整合 (large-scale integration)，表示了不同脑区之间的相互影响，通常发生在厘米量级的范围内，例如枕区和额叶之间，或者是大脑半球之间的神经元活动的整合。尽管大范围整合的神经生理机理还不是很清楚，大范围的整合被认为平衡了解剖结构和功能结构上分散分布的大脑活动，从而实现了有一致性的行为和认知活动。大脑的动态连接可能是由多个不同频段范围内的大脑活动的同步化来实现的，同步化可能是大脑把特定的皮层及皮层下区域整合为一个整体，从而完成行为及认知功能的主要机制。不同频率的大脑活动可能对应了整合的不同功能和空间尺度，脑电的低频部分，特别是 *theta* 频段被认为在远距离脑区的耦合中起作用，而高频部分在局部范围的大脑整合中更为重要。

对大脑同步化现象的研究主要有微电极（micro-electrode）和宏观电极（macro-electrode）两种方式。基于微电极记录的动物实验通常研究单一感觉模式内小范围区域内的同步现象，通过单电极记录方式也发现了远距离隔离的脑区之间的大范围同步现象。单电极的记录方式通过宏观电极记录（EEG，MEG，ECoG）的方法得到了补充，宏观电极的记录方式也能观察到大范围同步现象。

6.2 想象运动中的大脑同步化

在脑-机接口系统中，同步化方法可以作为一种特征提取方法直接用于大脑状态的检测^[107,141,177]。在大脑不同的状态下，同步化在不同脑区的空间分布，以及同步化的程度都可以作为特征提取的依据。例如，在想象运动脑-机接口系统中，想象手动和想象脚动的同步化特征在运动皮层的初级运动区（primary motor cortex, M1），运动前区（premotor area, PMA）和辅助运动区（supplementary motor area, SMA）的空间分布上存在显著的差异，因此 mu 和 beta 节律在大脑运动皮层不同区域的同步化程度可以直接用于想象运动的分类。同步化特征与想象运动脑电分类常用的能量特征有一定的独立性，可以通过特征结合算法来进一步提高想象运动脑-机接口系统的性能^[106,141]。另外，同步化特征在头皮上的空间分布特性还能用于脑-机接口系统初始化中的电极选择^[141,178]，以及辅助判断皮层的兴奋区域。

除用于脑-机接口的特征提取外，同步化方法还能应用于肢体运动的生理学研究。大在运动系统的神经生理学研究中，基于脑电同步化方法的研究可从以下几个方面进行：1) 观察肢体运动中的局部同步化和大范围同步化现象，比较不同运动模式在同步化空间分布上的差异；2) 采用具有高时间分辨率的同步化分析算法来观察肢体运动过程中神经活动传导的动态过程，对比运动前的运动准备过程、运动过程、以及运动后的恢复过程中同步化在空间位置及强度上的变化；3) 比较不同频带范围内同步化特征的相互联系。

6.2.1 想象运动中的脑电同步化

大脑神经功能成像的研究表明：在大脑的真实运动控制中，运动皮层的辅助运动区域和运动前区对运动计划和运动意图起重要作用；而初级运动皮层在运动的执行过程中起主要作用^[88,179-181]。基于脑电分析的同步化研究发现，在真实

运动或想象运动过程中，大脑运动皮层的不同区域之间存在着同步化 [141,160,178,182-185]，大范围的同步现象发生在中央区域和前额区域之间。为了研究想象左右手运动过程中的脑电同步化现象，采用了图 6.1 所示的电极组合方式。在大范围同步化的研究中，使用了代表 M1 和 SMA 区域活动的 C3/C4 和 FCz 三个导联^[186]；在局部同步化的研究中，使用以 C3/C4 和 FCz 为中心的电极组合，包括中心电极和邻近的四个电极。同步化的计算采用相位同步化的方法（见 3.3.1 节），两种不同尺度同步化的相位锁定值（PLV）的计算如下：

$$PLV_{\text{Large-scale}} = \left| \left\langle e^{j\Delta\phi(t)} \right\rangle_t \right| \quad (6-1a)$$

$$PLV_{\text{Local-scale}} = \frac{1}{10} \sum_{k=1}^{10} \left| \left\langle e^{j\Delta\phi(t,k)} \right\rangle_t \right| \quad (6-1b)$$

$\Phi(t)$ 表示两导联信号的瞬时相位差。大范围相位同步化计算的是 C3/C4 和 FCz 导联两两组合的相位锁定值，局部同步化计算的是每组内五个电极两两组合（共 10 种组合方式）的 PLV 均值。




图 6.1 脑电同步化研究电极放置方法：（a）大范围同步化；（b）局部同步化。

在本文的研究中，相位同步化分析使用的数据为在线想象运动脑-机接口两分类数据集，在线实验的方法见 5.2 节。数据集中包括了 6 名右利手的受试者（5 名男性，1 名女性，年龄在 23-26 岁之间），每人采集 4 组数据，每组共 60 个样

本, 每名受试者共有 240 个样本 (每类 120 个)。用于计算 PLV 值的带通信号为 μ 节律, 不同受试者的频带范围略有差别 (位于 8-15Hz 范围内), 参考电极选择远离 M1 和 SMA 区域的 POz 导联。图 6.2 为 6 名受试者相位同步化分析的结果。大范围同步化的 PLV 值范围为 0.35-0.67, 而局部同步化的 PLV 值为 0.77-0.87, 局部同步化 PLV 值除反映了局部同步化活动外同时还可能包括了由容积传导引起的假同步化效应。两种尺度的同步化计算结果均表现出对侧强同侧弱的特点。以想象左手运动为例, 在大范围尺度下, C4 和 FCz 导联的同步化程度高; 在局部尺度下, 右侧 M1 区域的同步化程度高。在大范围同步化分析中, 代表左右侧 M1 区域的 C3 和 C4 导联的 PLV 值分别为 0.37 和 0.35, 说明在想象左右手运动的过程中, 两侧运动皮层不存在明显的同步化现象, 这一结果与文献[187]一致。在局部同步化的分析结果中, FCz 为代表的 SMA 区域在两种想象运动的状态下 PLV 值分别为 0.85 和 0.87, 两者没有明显的差别。在两种想象运动任务下, SMA 区域的大脑活动相似。





图 6.2 想象运动脑电的相位锁定值: (a) 大范围同步化, C3/C4 和 FCz 间的三种两两组合; (b) 局部同步化, 分别以 C3/C4 和 FCz 为中心的电极组合。

6.2.2 基于同步化特征的想象运动脑电分类


相位同步化的特征可直接用于想象运动脑电的分类, 大范围同步化中的 C3-C4 以及局部同步化中的 SMA 区域的特征在两种想象任务下没有显著差别, 因此定义如下三种特征向量:

$$\begin{aligned}
 \mathbf{x}_1 &= [\text{PLV}_{\text{Large-scale}}(\text{C3-FCz}) \text{PLV}_{\text{Large-scale}}(\text{C4-FCz})] \\
 \mathbf{x}_2 &= [\text{PLV}_{\text{Local-scale}}(\text{C3}) \text{PLV}_{\text{Local-scale}}(\text{C4})] \\
 \mathbf{x}_3 &= [\mathbf{x}_1 \ \mathbf{x}_2]
 \end{aligned} \tag{6-2}$$

\mathbf{x}_1 和 \mathbf{x}_2 分别用于计算大范围同步化和局部同步化的分类结果，而 \mathbf{x}_3 用于计算两种同步化特征相结合的分类结果。图 6.3 显示了一名受试者在想象左右手运动时两种不同尺度下 PLV 的分布，尽管局部同步化的 PLV 值很高，但在两种同步化测量尺度下两类任务都能被准确区分。



(a)



(b)

图 6.3 想象运动脑电 PLV 的分布：(a) 大范围同步化，C3-FCz 和 C4-FCz 的组合；(b) 局部同步化，左侧运动皮层 C3 电极组和右侧运动皮层 C4 电极组。

表 6.1 为基于同步化特征的想象运动脑电分类结果，分类器采用 LDA。大范围同步化的分类正确率高于局部同步化，两种同步化尺度下，6 名受试者平均正确率分别为 84.70%和 77.08%。其中两名受试者（KYX 和 ZD）局部同步化的分类正确率仅为 61.03%和 61.33%，但大范围同步化的结果为 87.02%和 80.77%，真实的局部同步化特征可能被淹没在由容积传导引起的假同步中。结合两种同步化特征进行分类，平均正确率为 87.02%，所有 6 名受试者的分类结果都得到了不同程度的提高。分类结果表明，两种尺度的同步化特征都能用于在线脑-机接口系统。从两者的性能上看，大范围同步化的结果更为稳定，而局部同步化特征不适用于部分受试者。从两者的计算过程看，大范围同步化仅使用了 C3/C4 和 FCz 三个导联，而局部同步化使用了三组电极，计算量更大。与文献 [106,107]的遍历式同步化特征选择方法相比，基于 M1 和 SMA 区域大范围同步化的特征定义方法有维数低、计算量小、性能稳定的优点，更适用于在线脑-机接口系统。

表 6.1 基于同步化特征的想象运动脑电分类正确率（±标准差，%）

受试者	大范围同步化	局部同步化	特征结合	提高
CSH	93.21±0.48	93.70±0.55	96.61±0.28	2.91
WW	91.93±0.80	92.50±0.60	94.19±0.54	1.69
KYX	87.02±0.51	61.03±1.14	87.05±0.47	0.03
FL	86.76±1.72	82.52±1.65	90.97±1.28	4.21
ZD	80.77±0.75	61.33±0.89	81.28±0.96	0.51
JCH	70.37±0.68	71.41±1.19	72.03±1.15	0.62
均值	84.70	77.08	87.02	1.66

6.2.3 同步化算法的性能比较

论文的 3.3 节介绍了三种脑电信号同步化分析算法，分别是互相关函数、相干函数和相位同步化算法。本文采用一名受试者的想象运动脑电数据（想象左右手运动，每类 60 个样本）对三种算法进行了比较，带通信号的频带为 10-15Hz，互相关函数的时移为零，相干函数取值为频率 12Hz 处（对应了 mu 节律的峰值

频率)。表 6.2 列出了三种算法的 r^2 值、分类结果和相应的计算时间。互相关的算法有最高的分类正确率和最少的计算时间；而相干函数计算时间最长，正确率最低；相位同步化的方法分类结果和相干函数的方法接近，但计算时间小于相干函数。在想象运动脑电分类中，互相关的方法（见 (3-39) 式）包括了幅度同步化的信息，并且还包含了相位差的信息，可以检测出 0 相移和 180 度相移的差别；而相位同步化的方法丢失了幅度同步化特征，并且在计算过程中也丢失了相位差的信息（见 (3-43) 式）。相干函数也没有保留相位差，同时由于相干函数是频率的函数，在计算过程中频率的选择将影响分类性能，过宽的频带将引入背景噪声的影响，而过窄的频带则会造成部分有效信息的丢失。另外相干函数由于需要进行功率谱估计的计算，因此有较大的运算量。当使用多导联数据分析时，计算量将影响到在线脑-机接口系统的实时性。三种同步化算法中互相关的方法最适合用于实现在线系统，同步化在线脑-机接口将采用计算互相关的方法来实现。

表 6.2 想象运动脑电同步化算法性能分析

算法	$r^2(\text{C3-FCz})$	$r^2(\text{C4-FCz})$	正确率±标准差 (%)	计算时间 (秒)
互相关	0.41	0.55	92.33±3.16	0.3130
相干函数	0.34	0.41	89.00±3.62	1.7500
相位同步化	0.29	0.48	90.17±2.66	0.6100

6.2.4 相位同步化与事件相关去同步化的关系

想象运动过程中伴随着 μ 和 β 节律的 ERD/ERS 现象，表现为事件相关脑电能量的上升或下降^[40]。ERD 的程度反映了运动皮层兴奋的程度，想象运动过程中的 ERD 分布具有对侧占优的特点。同步化的空间分布和 ERD 分布具有一致性，在两种不同尺度的脑电同步化测量中均表现出对侧强同侧弱的特点。图 6.4-6.6 说明了想象左右手运动过程中基于能量变化的 ERD/ERS 和两种不同尺度同步化测量的时间变化过程。计算时采用长度为 1 秒的滑动时间窗，由一名受试者所有样本平均得到（每类 120 个样本），第 2 秒为想象任务提示出现的时刻。如图 6.4 所示，想象手动时，在运动皮层的对侧区域出现 ERD，而在同侧区域出现 ERS，ERD 在想象开始 2 秒左右达到最大值，而 ERS 持续增大到任务

结束。在图 6.5 和图 6.6 中，大范围同步化和局部同步化的时间过程都表现为同侧下降和对侧增强，两种同步化现象在时间过程上还存在着差异。




图 6.4 想象左右手运动时 ERD/ERS 的时间过程：(a) C3 导联；(b) C4 导联。




图 6.5 想象左右手运动时脑电大范围同步化的时间过程：(a) 左侧 M1 和 SMA 的同步化；(b) 右侧 M1 和 SMA 的同步化。




图 6.6 想象左右手运动时脑电局部同步化的时间过程：(a) 左侧 M1 区域内的同步化；(b) 右侧 M1 区域内的同步化。

为进一步解释运动皮层同步化和脑电 μ 节律 ERD/ERS 的关系，本文采用独立分量分析 (ICA) 的方法来分析想象运动脑电的 α 频段成分。通过独立分量分析，原始脑电中的 α 频带信号可以分解为 μ 节律，枕区和中央区的 α 节律（背景 α 波），以及其它独立分量中的 α 频带分量：

$$\begin{aligned} \mathbf{X} &= \mathbf{X}^{\alpha} + \mathbf{X}^{\mu} + \mathbf{X}^{\text{others}} = \mathbf{W}^{-1} \left[\mathbf{S}^{\alpha} \quad \mathbf{S}^{\mu} \quad \mathbf{S}^{\text{others}} \right]^T \\ &= \mathbf{W}^{-1} \left[\mathbf{S}^{\alpha} \quad 0 \quad 0 \right]^T + \mathbf{W}^{-1} \left[0 \quad \mathbf{S}^{\mu} \quad 0 \right]^T + \mathbf{W}^{-1} \left[0 \quad 0 \quad \mathbf{S}^{\text{others}} \right]^T \end{aligned} \quad (6-3)$$

其中 \mathbf{W} 为解混矩阵， \mathbf{S} 为独立分量。独立分量的选择结合功率谱和空间模式的特征进行，选择 α 节律能量最大的几个独立分量作为代表背景 α 波和 μ 节律的独立分量（独立分量的选择参考 3.2.2 节的方法）。表 6.3 列出了一名受试者的原始脑电，背景 α 波和 μ 节律三种成分的大范围同步化分析结果（每类想象任务 60 个样本的平均结果）， μ 节律包括了左右运动区的两个独立分量；背景 α 节律包含了枕区和中央区的四个独立分量（6 个独立分量 α 频带的总能量占原始脑电的 75%）。由表 6.3 的分析结果可以得到以下几点结论：1) μ 节律成分在大范围同步化中表现出同侧强对侧弱的特点，与能量分布一致；2) α 节律在大范围同步化中 PLV 值很高，想象左右手运动两种任务下没有显著差别；3) 原始脑电的大范围同步化表现为对侧强同侧弱，与 μ 节律成分同步化结果相反。根据以上数据分析结果，对想象运动过程中的脑电同步化

现象提出如下假设：FCz 导联的 mu 节律能量远低于 C3/C4 导联，其主要成分为背景 alpha 节律，因此大范围同步化的对侧优势可以解释为运动皮层对侧区域和 SMA 区域 alpha 节律成分的同步化。想象运动过程中的 ERD 现象使对侧区域 mu 节律能量降低，从而更突出了背景 alpha 节律成分，使对侧区域的脑电成分与 FCz 导联更为相近。

表 6.3 基于独立分量分析的脑电同步化分析结果

信号	脑电能量(μV^2)			PLV		
	C3	C4	FCz	C3-FCz	C4-FCz	
原始脑电	左手	8.87	9.61	8.47	0.49	0.69
	右手	7.44	12.02	8.42	0.70	0.37
Mu 节律	左手	5.39	4.59	2.03	0.71	0.39
	右手	2.99	8.08	1.26	0.44	0.74
Alpha 节律	左手	4.73	5.65	4.90	0.87	0.80
	右手	4.52	5.40	4.58	0.92	0.70

6.3 基于同步化特征的在线脑-机接口系统设计

采用与图 5.2 (a) 的两分类想象运动相同的模式来实现基于大脑同步化的在线脑-机接口系统。在线系统采用互相关算法，计算 C3-FCz 和 C4-FCz 的同步化作为分类特征。图 6.7 是在线算法框图，主要处理为互相关函数的计算和 LDA 分类。同步化在线系统与基于带通能量特征的脑-机接口的主要区别在于采用了基于互相关函数的同步化特征提取方法。




图 6.7 同步化脑-机接口在线算法框图

4 名受试者（两名男性，两名女性，年龄在 24-27 岁之间）参加了在线同步

化脑-机接口实验，借助想象运动来调节大脑运动皮层的脑电同步化特征，从而实现屏幕一维光标的运动控制。单次实验的过程与基于带通能量的两分类想象运动实验相同（见图 5.2（a））。每名受试者采集三组数据，每组数据 40 个样本（每类 20 个），共得到 120 个样本。

表 6.4 为同步化实验离线数据分析的结果，使用的参考电极为耳电极。同步化特征为 C3-FCz 和 C4-FCz 的大范围同步化，采用与同步在线系统相同的互相关方法计算，能量特征为 C3 和 C4 导联的带通能量，采用 LDA 分类器对特征进行分类。同步化特征和能量特征的平均分类正确率没有明显差别，分别为 82.86% 和 83.28%；结合两种特征后，分类正确率有明显的提高，平均正确率为 91.25%；与同步化或能量特征方法相比，特征结合方法的分类正确率平均提高了 6.27%。这一结果表明，想象运动过程中的能量变化特征和同步化特征存在较强的独立性，通过特征结合的方法能获得更高的系统性能。两种方法都使用了很少的电极，能量特征仅使用了 C3/C4 两个电极，同步化特征的计算使用了 C3/C4 和 FCz 三个电极。使用 C3/C4 和 FCz 三个电极，并采用能量特征和同步化特征结合的方法能实现性能稳定的想象运动在线脑-机接口系统。

表 6.4 同步化脑-机接口脑电数据分类正确率(±标准差, %)

受试者	同步化特征	能量特征	特征结合	提高
ZYJ	91.32±0.94	91.50±1.05	96.44±0.47	5.12
FL	79.37±0.99	87.87±1.25	93.93±0.68	6.06
ZD	85.72±0.66	82.87±1.02	93.48±0.61	7.76
PF	75.01±0.89	70.89±1.19	81.16±1.37	6.15
均值	82.86	83.28	91.25	6.27

6.4 基于同步化的想象运动脑-机接口电极放置方法

使用少的导联和性能稳健的特征提取和分类算法是设计可实用化脑-机接口的有效方法。根据上述想象运动脑电分类的算法，采用带通能量或同步化测量的方法，使用图 6.8（a）所示的电极放置方法（C3，C4，FCz）可以实现性能稳定的在线想象运动脑-机接口，结合能量和同步化的特征还能进一步提高分

类的正确率。图 6.8 (b) 显示了想象左右手运动中的运动皮层大范围同步化的 PLV 值，左右运动区与 SMA 区域的同步化有对侧强同侧弱的特点。从脑电双极导联信号分析的角度考虑，FCz 位于前额中央区域，在两种想象运动过程中，FCz 分别与单侧 M1 区域同步化，而与另一侧区域的同步化程度很低，如果采用以 FCz 为参考电极的双极导联方法，将导致由同步化引起的左右 M1 区域的能量差。这一能量差别同样具有对侧分布的特点，与 ERD 引起的左右 M1 区域的能量差在分布上具有一致性，因此使用 FCz 参考的方法可以进一步增强想象左右手运动时左右 M1 区域的能量差，从而起到与提高 mu 节律信噪比相同的效果。




图 6.8 (a) 在线想象运动脑-机接口电极位置；(b) 想象左右手运动中的运动皮层大范围同步化。

图 6.9 显示了一名受试者在想象左右手运动两种任务下的单次实验脑电波形，包括了以耳电极为参考的原始信号和以 FCz 为参考的双极导联信号，信号长度为 1 秒，滤波频带为 10-15Hz。在图 6.9 (a) 中的想象左手数据中，C4 和 FCz 同步化 (PLV 值为 0.92)，C3 和 FCz 不同步 (PLV 为 0.17)；而图 6.9 (b) 的想象右手数据中，C3 和 FCz 同步 (PLV 为 0.95)，C4 和 FCz 不同步 (PLV 为 0.18)。对这名受试者的整个数据集进行 PLV 计算中的相位差 (见 (3-42) 式) 统计，单侧 M1 与 SMA 区域同步化时的相位差为 0.008 ± 0.250 弧度，因此可以认为 M1 与 SMA 区域的同步化为零相移的同步化。在耳参考脑电波形中，三个导联的能量没有明显差别；以 FCz 为参考时，C3 和 C4 导联的信号发生显著变

化。经过双极导联处理，与 SMA 同步化的一侧 M1 区域的脑电幅度大大降低，而与 SMA 不同步的一侧 M1 区域的脑电幅度没有明显的改变。以想象左手运动为例，上述双极导联的结果可以描述为如下的不等式：

$$\left\langle |S_{C4}(t) - S_{FCz}(t)|^2 \right\rangle_t < \left\langle |S_{C4}(t)|^2 \right\rangle_t < \left\langle |S_{C3}(t)|^2 \right\rangle_t \approx \left\langle |S_{C3}(t) - S_{FCz}(t)|^2 \right\rangle_t \quad (6-4)$$

S_{C3} ， S_{C4} ， S_{FCz} 分别为以耳电极为参考时 C3/C4 和 FCz 三个电极上的脑电信号。FCz 作为参考，使得 C4 导联的能量减小，而 C3 导联的能量基本保持不变，C4 和 C3 导联原始数据的能量差别是由想象左手运动时对侧占优的 ERD 引起的。FCz 电极包含了运动皮层大范围同步化的信息，以 FCz 为参考的带通能量方法同时综合了 ERD 能量变化和运动皮层大范围同步化两种特征，因此系统性能明显高于耳电极参考模式（见图 6.10）。




图 6.9 想象左右手运动时 C3/C4 和 FCz 的脑电信号波形，图中上下两部分波形分别对应耳参考和 FCz 参考：（a）想象左手运动；（b）想象右手运动。




图 6.10 想象左右手运动时 C3/C4 导联的能量以及两个导联的能量差，分别为耳参考和 FCz 参考两种模式：（a）想象左手运动；（b）想象右手运动。

表 6.5 采用不同参考的想象运动脑电带通能量分类正确率（±标准差，%）和 r^2 值

受试者	耳参考	CAR 参考	FCz 参考
ZYJ	91.50±1.05 (0.66)	99.76±0.13 (0.80)	97.28±0.53 (0.74)
FL	87.87±1.25 (0.60)	91.07±1.03 (0.68)	90.48±0.76 (0.64)
ZD	82.87±1.02 (0.46)	86.02±0.96 (0.56)	91.60±0.64 (0.64)
PF	70.89±1.19 (0.24)	76.85±0.82 (0.33)	75.97±1.03 (0.33)
均值	83.28	88.42	88.83

采用耳电极参考、共平均参考（CAR）和 FCz 参考三种不同的参考电极设置方法，对同步化在线脑-机接口实验的四个受试者的数据进行了对比分析。表 6.5 列出了三种方法的分类结果和相应的 r^2 值。CAR 方法的作用是空间的高通滤波器，可以提高 μ 节律的信噪比^[111]。FCz 参考的方式获得了和 CAR 类似的性能，平均分类正确率分别为 88.83%和 88.42%；在耳电极参考的模式下，分类正确率为 83.28%，比 FCz 参考的模式下降了 5.55%。由于 CAR 方法使用了所有 32 导联信号，而 FCz 参考的方法仅使用了 C3/C4 和 FCz 三个电极，因此 FCz 参考的方法在脑-机接口系统有更高的应用价值。同步化特征也可以直接用于分类，进一步采用能量和同步化特征结合的方法平均正确率为 91.25%（见表

6.4), 高于 FCz 参考的方法。与能量和同步化特征结合的方法相比, 以 FCz 为参考的带通能量方法的优点在于计算更为简单, 特征的维数更低, 因此分类器有更好的推广性能, 更适合用于在线脑-机接口系统的实现。

6.5 本章小结

现有的想象运动脑-机接口仅使用初级感觉运动皮层 (M1) 的脑电能量变化信息, 而忽略了辅助运动区 (SMA) 在想象运动过程中所起的作用。由于 SMA 在不同的想象运动状态下的能量特征没有显著差别, 因此简单地计算 SMA 区域的能量特征对想象运动脑电的分类没有帮助。使用同步化的方法来提取 SMA 的信息可以提高基于能量特征的想象运动脑-机接口的性能。

本章深入研究了大范围同步化和局部同步化两种尺度下想象左右手运动过程中大脑运动皮层的同步化现象, 并采用独立分量分析的方法解释了同步化和反映能量变化的 ERD 之间的关系。通过离线分析对互相关、相干函数和相位同步化三种同步化分析算法的性能进行了比较, 选择互相关的算法实现了在线同步化脑-机接口系统。

在想象运动脑电数据分析中对比了同步化分析方法, 带通能量方法, 以及特征结合的方法, 并进一步提出了一种能包含同步化信息的带通能量特征提取方法 (以 FCz 为参考电极的带通能量方法)。使用这一方法的三导联系统 (仅使用 C3/C4 和 FCz 三个电极) 与基于 CAR 空间滤波的 32 导联系统性能相当, 为想象运动脑-机接口的便携化奠定了基础。

第 7 章 基于稳态视觉诱发电位的在线脑-机接口系统

7.1 基于稳态视觉诱发电位的脑-机接口系统设计

与其它脑-机接口系统相比, 基于稳态视觉诱发电位 (SSVEP) 的脑-机接口有较高的数据传输率。对于大部分视觉通路正常的用户, 使用 SSVEP 系统只需要短时间的训练适应。第一章中介绍了各种基于 VEP 的脑-机接口系统, 目前已有报导的 VEP 脑-机接口系统有以下四种: 1) 基于瞬态视觉诱发电位的 BRI 系统^[8]; 2) 基于多目标选择的 SSVEP 系统^[34-37]; 3) 自主调节 SSVEP 幅度的系统^[9]; 4) 基于空间注意性选择的系统^[38,39]。这四种系统有各自的特点: BRI 有很高的数据传输率, 每次正确的操作能发送 6 比特的信息, 但系统采用的是有损的植入电极方式, 同时使用专门的硬件系统, 这不利于系统的改进和升级; 基于 SSVEP 的多目标选择系统也有较高的数据传输率, 采用头皮脑电信号, 但存在视觉刺激易造成视疲劳的问题; 自主调节 VEP 幅度的系统通过训练能够提高使用效率, 但数据传输率低; 基于空间注意性选择的系统是一个独立型的 BCI 系统, 不需要依赖于眼部肌肉控制的眼动, 能适用于完全瘫痪的病人, 但数据传输率更低。我们设计的 SSVEP 脑-机接口系统采用通过频率检测来确定注视方向的多目标选择模式, 其优势在于系统有较高的信息传输速率。

7.1.1 系统工作原理

有关视觉皮层的电生理研究表明^[89], SSVEP 的强度与受试者对视觉刺激空间位置的注视有关, 视觉刺激越接近视野中央, 诱发出的 SSVEP 幅度就大; 越往外围, SSVEP 的幅度越小。因为视皮层对中央视野的放大功能更为显著, 所以通过注视不同位置的视觉刺激, 可以实现从视野中多个不同的刺激中选择一个目标刺激, 这是基于 SSVEP 的脑-机接口系统的基本原理。

图 7.1 是系统的原理框图, 和其它脑-机接口系统类似, SSVEP 脑-机接口包括数据采集、特征提取、设备控制三个部分。视觉刺激器采用的是由 CRT 显示器上多个闪烁方块组成的虚拟键盘, 对外部设备的控制通过使用者注视方向的切换来实现。实际使用过程中, 由频率标记的虚拟键盘的所有方块同时闪烁, 操作者集中注意力注视目标刺激, 同时尽可能地忽略其它闪烁。这时目标

刺激将位于视野的中央区域内，引起刺激相应频率处 SSVEP 幅度的显著增加。使用信号处理方法可以检测出由目标刺激诱发出的 SSVEP 的频率，从而确定目标刺激的位置，并转换为相应的控制指令。

系统中信号处理模块的任务包括检测 SSVEP 的有无，以及在有 SSVEP 的情况下对其频率的检测。当目标刺激位于视野中央时，将在视皮层诱发出频率跟随特性的 SSVEP 信号，因此在枕区记录到的脑电信号的功率谱将在刺激频率处出现明显的谱峰。频率检测的方法是在指定的频带范围内寻找谱峰，并确定其频率；另外为了避免由自发脑电引起的假阳性响应，频谱峰值位置的脑电归一化幅度必须超过预先设定的阈值。当上述两个条件都满足时，系统将确认 SSVEP 的成功检测，并发出预先设定好的外设控制指令。

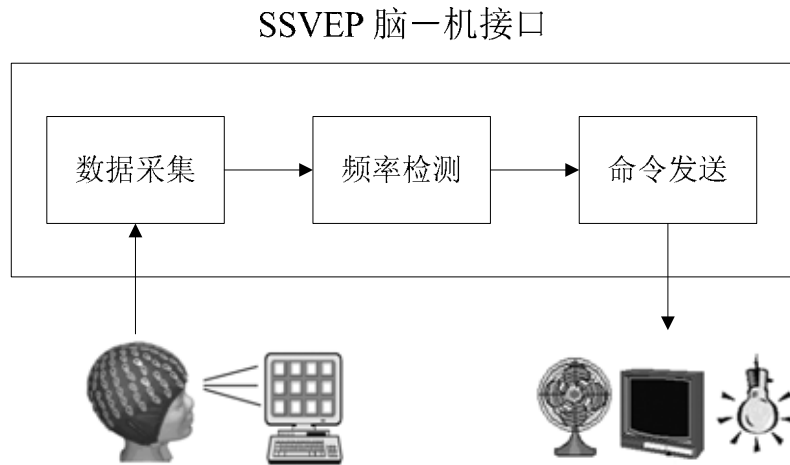


图 7.1 SSVEP 脑-机接口系统原理框图

7.1.2 系统构成

在本论文的研究中，系统搭建的硬件平台是 BioSemi 公司的 ActiveTwo 脑电图机，在预备实验中，采集 32 通道脑电信号用于导联位置和刺激频率等参数的优选；在脑-机接口在线实验中，仅使用一个双极导联。系统常用的视觉刺激器有两种，一种是计算机显示器实现的虚拟键盘^[34]，另一种用发光二极管来实现^[35]。因为受到 CRT 显示器刷新率的限制，虚拟键的闪烁频率往往只能达到十几赫兹，更高频率的刺激可以通过由可编程逻辑器件控制的发光二极管来实现，同时这一形式也便于实现便携化的系统。系统的输出设备有家居环境控制器、康复机械手、模拟电话拨号等多种形式，在系统性能测试中常用的是电话拨号

和家居环境控制器这两种模式^[34-36]。

系统的软件平台基于 LabVIEW 环境编写，包括脑电采集程序和在线数据分析算法。在线数据分析算法采用功能模块的方式添加到 BioSemi 公司的脑电采集程序 AcitveView 中。在线分析和数据采集由同一台 PC 来完成，PC 通过串口和外设进行通讯，发出命令后的反馈信号也由 PC 通过串口发送到刺激器。在线分析模块中特征提取和识别算法的任务是要完成 SSVEP 的频率检测，首先通过谱分析在频域中检测出 SSVEP 谱峰，然后判断峰值是否达到预设的阈值。实时数据处理只使用一个双极导联，有关导联位置的选择方法将在下一节中详细介绍。图 7.2 为 11Hz 和 13Hz 两种刺激频率诱发的 SSVEP 时域波形和幅度谱，图中的 SSVEP 有很高的信噪比，在这种情况下使用 4 秒长的脑电数据进行检测可以准确地得到 11Hz 和 13Hz 的峰值频率。




图 7.2 SSVEP 时域波形及幅度谱：（a）11Hz 视觉刺激；（b）13Hz 视觉刺激。

7.2 参数优选方法

原有的 SSVEP 脑-机接口在部分受试者中获得了很高的性能，其中三个受试者的数据传输率约为 50bits/min，但系统对于部分受试者却完全不适用，有两名受试者的平均数据传输率只有 3bits/min^[34]。系统的通用性不强是当前脑-机接口研究中的一个普遍问题，对不同的受试者，SSVEP 在频率-幅度响应、电极位置、背景自发脑电的影响等各个方面都存在较为显著的个体差异，从而直接影响到 SSVEP 的特征提取。针对这一问题，每一位受试者在使用在线系统之前都进行了一组 SSVEP 预实验，通过实验数据的离线分析，对导联位置和刺激

频率等系统参数进行优选。

预实验中使用 ActiveTwo 系统记录 32 导联脑电信号, 其中的 13 个电极位于 Pz 和 Oz 之间用于记录有较高空间分辨率的 SSVEP (见图 7.3)。采用方波调制的 LED 作为视觉刺激, 刺激频率为 9-17Hz 范围内的整数频率值。每个频率刺激的时间为 60 秒, 脑电信号的采样率为 256Hz。




图 7.3 SSVEP 预实验电极位置图

7.2.1 电极位置选择

考虑到系统的实用化, SSVEP 在线系统中只使用一个双极导联信号作为系统的输入, 由于在线系统中无法使用基于多导联信号的空间增强算法, 因此电极位置的选择起着很重要的作用, 决定了部分受试者能否使用本系统。针对这个问题, 我们提出了适用于 SSVEP 频率特征提取的“最优电极”选择的方法, 结合多导联脑电信号和独立分量分析来确定电极放置的位置。SSVEP 的背景噪声主要是自发脑电中的 alpha 波成份, 导联选择的目标是挑选出 SSVEP 信噪比最高的一个电极对 (信号电极-参考电极) 用于提取 SSVEP 的频率特征。

在头皮上不同位置记录到的 SSVEP 幅度不同, 初级视皮层的位置决定了枕部区域的 SSVEP 具有最大的幅度。首先, 通过能量分布图可以从枕部挑选出 SSVEP 最强的导联作为信号导联。选出了信号导联之后, 进行参考导联的挑选。

参考导联的选择要考虑以下两个因素：1) SSVEP 幅度；2) 与信号导联的距离。选择参考导联的目的是在双极导联信号中尽可能地保留 SSVEP 信号，同时去除背景噪声。理想的结果是：参考导联中 SSVEP 的幅度尽可能小，并且与信号导联距离也很小。距离近能保证两导联有尽可能相同的背景脑电成分，这样从信号导联中减去参考导联，既消除了相关的背景噪声，又保留了大部分 SSVEP 成分，因此可以获得较高的信噪比。但实际情况中这两个因素往往是互相矛盾的，通常情况是：参考导联离信号导联越近，则在相减后 SSVEP 的损失也越大；反之，则对背景噪声的消除越不明显。最优导联的确定需要综合两方面因素来折衷选择。

我们采用独立分量分析 (ICA) 的方法来比较不同导联间 SSVEP 信号和背景噪声的分布情况，以刺激频率为 13Hz 的 SSVEP 为例进行分析。从分解后的信号与噪声成分的能量分布能够直观地反映各导联间信号与噪声的相关性，从而寻找出信号相关性弱而背景噪声相关性强的双极导联作为优化导联。数据分析的具体步骤如下^[188]：

- 1) 选取 Pz 和 Oz 间的 13 导联脑电数据 \mathbf{X} (包含有 13Hz 的 SSVEP 成分) 作为 ICA 分析的输入。经过独立分量分析，得到 13 个独立分量作为源信号 $\mathbf{S}=\mathbf{W}\mathbf{X}$ ，其中 \mathbf{W} 是解混矩阵。
- 2) 观察比较所有独立分量的功率谱。在刺激频率 13Hz 处具有最大峰值的 4 个独立分量被认为是 SSVEP 的信号源分量，其它的独立分量则被认为是背景脑电噪声的源活动。分别用 $\mathbf{S}^{\text{Signal}}$ 和 $\mathbf{S}^{\text{Noise}}$ 来表示信号源和噪声源， \mathbf{S} 包含了全部的信号源和噪声源。
- 3) 将脑电信号 \mathbf{X} 分解成信号成分和噪声成分，分别用 $\mathbf{X}^{\text{Signal}}$ 和 $\mathbf{X}^{\text{Noise}}$ 来表示：

$$\mathbf{X} = \mathbf{X}^{\text{Signal}} + \mathbf{X}^{\text{Noise}} = \mathbf{W}^{-1} \begin{bmatrix} \mathbf{S}^{\text{Signal}} \\ \mathbf{S}^{\text{Noise}} \end{bmatrix} = \mathbf{W}^{-1} \begin{bmatrix} \mathbf{S}^{\text{Signal}} \\ \mathbf{0} \end{bmatrix} + \mathbf{W}^{-1} \begin{bmatrix} \mathbf{0} \\ \mathbf{S}^{\text{Noise}} \end{bmatrix} \quad (7-1)$$

- 4) 对 \mathbf{X} ， $\mathbf{X}^{\text{Signal}}$ 和 $\mathbf{X}^{\text{Noise}}$ 做功率谱分析，分别选择信号导联和参考导联，挑选出背景脑电相关性强，而 VEP 成分相关性弱的导联对。

下面用实际数据来说明整个处理过程。我们对一名受试者 (受试者 A) 13Hz 的 SSVEP 头皮脑电数据 \mathbf{X} 进行独立分量分析，得到源信号 \mathbf{S} 。从 \mathbf{S} 中各个独立分量的时域波形中很难直接得到有用信息，由于 SSVEP 成分的频率已知，所以可以根据这一先验条件分析各独立分量的频率成分，含有显著刺激频率成分的

独立分量作为 SSVEP 相关的信号源，其它刺激频率成分较弱的独立分量作为噪声分量。其中 4 个 13Hz 成分显著的独立分量被选为 SSVEP 源成分，而其它 9 个分量作为背景自发脑电分量。通过计算信号和噪声两种成分不同导联间的相关性可以选择出 SSVEP 信噪比高的导联对。更直观地，我们可以通过观察比较所有导联的 X ， X^{Signal} 和 X^{Noise} 的功率谱来确定最优导联的位置。具体的做法如下：根据 ICA 分析结果，计算出所有导联的 X ， X^{Signal} 和 X^{Noise} 的功率谱，然后将它们映射到相应的头皮位置上（共 13 组，如图 7.4 和 7.5 所示）。在每一导联位置上， X ， X^{Signal} 和 X^{Noise} 的功率谱分别位于正下方，右上方和左上方的位置。这样可以很清楚地选择出 SSVEP 强的信号导联，并观察比较各导联间的信号及噪声的相关信息，根据前面提到的两个基本因素（SSVEP 的幅度，电极间的距离）来确定出最优导联。




图 7.4 受试者 A 的 X ， X^{Signal} 和 X^{Noise} 的幅度谱




图 7.5 受试者 B 的 X , X^{Signal} 和 X^{Noise} 的幅度谱

通过两个例子来说明电极位置的确定，图 7.4 和图 7.5 是两个受试者原始脑电信号及分解后的 SSVEP 源信号和背景噪声的功率谱分布情况。如图 7.4 所示，受试者 A 的 SSVEP 幅度很强，而背景脑电相对较弱。SSVEP 幅度最大的是 PO2 导联，并且 SSVEP 在头皮上的分布比较均匀，从 PO2 开始向外围缓慢递减。确定 PO2 为信号导联后，如果选择位置离 PO2 较近的导联作为参考导联，双极导联将损失较多的 SSVEP 成分。因此对 A 类型的受试者，导联的选择以 SSVEP 的幅度为主要指标。计算结果表明，对于受试者 A，选择 SSVEP 幅度低并且离 PO2 较近的导联作为参考导联都能获得满意的结果，如 PO2-Pz 和 PO2-P4。受试者 B 的情况如图 7.5，信号导联同样选择 PO2 导联，受试者 B 的 SSVEP 幅度较弱，但背景自发脑电很强，SSVEP 几乎完全淹没在自发脑电中，如根据 SSVEP

幅度来选取参考导联将导致很低的信噪比。同时可以看到，受试者 B 的 SSVEP 幅度在各电极位置上的变化较为显著，在这种情况下，参考导联与信号导联的距离起到决定性的作用。在 PO2 左侧最近的几个导联 SSVEP 幅度都有明显的下降，而背景噪声的变化较小，因此选择这些导联作为参考导联有利于提高 SSVEP 的信噪比，如采用图 7.5 中箭头所示的 PO2-POz 导联对。

定义 SSVEP 峰值检测中的信噪比来衡量所选取双极导联的效率。指定 FFT 计算的点数为 1024（对应的数据长度为 4 秒），得到的频率分辨率为 0.25Hz，幅度谱 $y=|FFT(x)|$ 。如果检测正确， y 的最大值对应的频率即为刺激频率 f 。定义信噪比 SNR 为 y 在频率 f 处的值与邻近 4Hz 范围内的背景信号幅度均值的比值，SNR 的计算如下：

$$SNR = \frac{16 \times y(f)}{\sum_{k=1}^8 [y(f + 0.25 \times k) + y(f - 0.25 \times k)]} \quad (7-2)$$

SNR 越大越有利于频率检测。图 7.6 (a) 中显示的是实际数据长度从 1 秒变化到 4 秒时 SSVEP 的 SNR（受试者 A 和 B），数据长度不足 4 秒则通过补零至 4 秒。图 7.6 (b) 是相应的峰值频率检测的正确率。受试者 A 在优选导联位置后，参考导联的改变对 SNR 影响较小，均获得很高的信噪比和正确率。而受试者 B 在两种选择下的结果变化显著。受试者 B 如采用与受试者 A 相同的导联方式（PO2-Pz），则其 SSVEP 完全淹没在背景脑电中，无法从中检测出 SSVEP 成分。然而，如果采用与信号导联最近的导联作为参考导联（PO2-POz），则在很大程度地去除了背景噪声，同时也保留了足够的 SSVEP 信息，因此提高了 SSVEP 的信噪比，使准确的峰值检测成为可能。可见对 B 类型的受试者，能否使用 SSVEP 脑-机接口的关键因素就是导联位置。




图 7.6 (a) VEP 的信噪比和数据长度关系曲线；(b) 峰值检测正确率和数据长度关系曲线。

7.2.2 频率响应分析

视觉刺激的频率是 SSVEP 脑-机接口系统的另外一个重要参数，为了实现系统的实用化，有两个与刺激频率有关的问题需要解决。首先是假阳性 (false positive) 误判的问题，如果刺激频率落在背景 alpha 波的频带范围内，自发脑电的功率谱有可能满足峰值检测的条件，从而发生误操作。对于异步的脑-机接口系统，必须解决假阳性问题。另外一个问题与峰值检测算法的执行效率有关，峰值检测算法要求 SSVEP 的幅度超过预先指定的阈值，对大部分受试者，在视觉刺激诱发出幅度较高的 SSVEP 的同时，背景 alpha 波的能量受到抑制；但对个别受试者，背景 alpha 节律仍然是 alpha 频段脑电的主要成分。图 7.7 为一名受试者的归一化脑电功率谱，其计算方法如下：

$$P = |\text{FFT}(\mathbf{x})| / \sum |\text{FFT}(\mathbf{x})| \quad (7-3)$$

这名受试者 12Hz 以下的自发脑电很强, 为避免由背景 alpha 节律引起的误操作, 视觉刺激应选择高于 12Hz 的频率。另外, 由于背景 alpha 波的总能量远高于 SSVEP 的能量, 尽管在刺激频率处 (13, 15 和 17Hz) SSVEP 有明显的峰值, 但峰值检测由于无法达到指定阈值而不能完成。对这名受试者, 采用截止频率为 12Hz 的高通滤波器, 将背景 alpha 节律排除在外, 峰值检测的效率将大大提高, 假阳性问题也得到解决。




图 7.7 在线脑-机接口系统视觉刺激频率的选择

提高 SSVEP 系统性能的另外一种方法是增加可识别目标的数量, 在频率分辨率不变的情况下, 设置更多的目标需要更大的频率带宽。有关视觉神经电生理的研究表明, SSVEP 幅度随频率变化的响应曲线大致可以根据出现的峰值划分为三个区域, 称为视觉通路的子系统^[89]: 低频区域 (6-15Hz), 中频区域 (15-30Hz), 高频区域(30-60Hz)。视觉子系统的 SSVEP 幅度受到很多因素的影响, 比如电极位置、环境亮度、刺激的调制深度等^[89,189,190]。由于受显示器刷新率的限制, 在线脑-机接口系统使用的是低频的 SSVEP (<15Hz), 这一频段的 SSVEP 有信噪比高、容易诱发、在头皮上有较广的空间分布等优点, 但也有以下局限性: 1) 低频的闪烁刺激容易使受试者产生视觉疲劳, 因此无法保证长时

间使用时系统的舒适性，同时视觉疲劳可能会降低 SSVEP 的幅度，使系统的性能下降；2) 低频 SSVEP 的频带和自发脑电 alpha 波的频带有很大的重叠，由此可能引起假阳性误操作，受试者在无视觉刺激的情况下，系统也可能从自发脑电中检测到与闪烁频率对应的峰值，从而影响到系统的实用性；3) 临床实验表明，低频闪光刺激还可能会诱发出癫痫。高频 SSVEP 可以避免这些不足，高频刺激会产生闪烁融合（flicker fusion）^[191]效应，因此能缓解视觉疲劳。由于高频 SSVEP 的幅度相对较低，在头皮上的空间分布也有限，可能引起系统性能的下。图 7.8 为一名受试者的 SSVEP 视觉子系统的幅度-频率响应和相应的信噪比曲线^[192]。视觉刺激频率为 5-45Hz，实验过程中每 2Hz 采集一次数据。低频，中频和高频区域的中心位置分别为 15Hz，31Hz 和 41Hz。随着刺激频率的增加，SSVEP 的幅度逐步下降，但由于背景噪声的能量也同时下降，因此在三个区域内 SSVEP 信噪比维持在相同的水平上。对这名受试者，31-35Hz 的中频区域以及 39-45Hz 的高频区域可以提供大约 10Hz 的频率范围，同时使用三个子系统可以实现更多目标的脑-机接口系统。




图 7.8 (a) SSVEP 三个视觉子系统的幅度-刺激频率响应曲线；(b) 视觉子系统相应的信噪比-刺激频率响应曲线。

7.2.3 自动调节时间窗

使用自动调节时间窗的方法可以提高脑-机接口系统的数据传输率

[36,38,193]。由于个体差异,不同受试者的 SSVEP 信噪比有较大的差异;对相同的受试者,由于脑电信号的时变性,每次系统操作需要的时间也可能不同。图 7.9 显示了两名受试者的归一化脑电功率谱,SSVEP 的刺激频率为 17Hz (LED 闪光刺激),计算功率谱的数据长度为 8 秒,不足 8 秒时补零。如果指定峰值检测的阈值为 0.02,两名受试者需要的数据长度分别为 2 秒和 4 秒。对大部分受试者,数据长度为 8 秒时,SSVEP 的信噪比可以满足峰值检测的需要。在系统中使用了自动调节时间窗的算法,预先设定长度为 8 秒的数据缓冲区,脑电数据实时对缓冲区进行填充,如果数据填满,对所有数据进行平移,即保留最新的 8 秒数据而丢去最早填入的数据。峰值检测持续进行,间隔为 300 毫秒,达到判决阈值后,清空数据缓冲区,开始下一次操作。这种工作模式保证了系统有更高的效率。




图 7.9 两名受试者频率为 17Hz 的 SSVEP 归一化功率谱(10-20Hz 总能量为 1):
(a) 受试者 A; (b) 受试者 B。

7.3 系统测试和应用

通过 SSVEP 预实验可以得到每个受试者的优选参数,在线系统中只使用了一个双极导联来进行 SSVEP 的峰值检测。系统测试中使用的视觉刺激器是 CRT 显示器上 13 个虚拟按键组成的数字键盘^[34],视觉刺激的分辨率为 0.25Hz,需要

的刺激频带为 3.25Hz，可以避开背景 alpha 波的范围来选择刺激频率。受试者被要求连续完成 12 个字符的输入，目标刺激由程序自动随机生成，任务提示信息为目标虚拟键外的矩形边框，字符正确输入后，边框将自动消失，接着出现下一个任务；如果输入错误，错误的目标位置将出现框形框，提示受试者清除错误的输入。

16 名视觉功能正常的志愿者（10 名男性，6 名女性，年龄在 22-42 岁之间）参加了系统的实验室测试。受试者坐在有扶手的椅子上，实验在无屏蔽的室内环境进行。为测试系统在不同环境下的性能，在中国康复中心对基于 SSVEP 脑-机接口的家居环境控制器^[35]进行了测试，11 名脊髓损伤病人（9 名男性，2 名女性，年龄在 22-53 岁之间，C4-C7 不同程度的脊髓损伤）参加了使用 SSVEP 脑-机接口系统控制电视的测试，测试环境为医生的办公室。

在实验室测试中，所有受试者都完成了 12 个字符的输入，平均信息传输速率为 43bits/min（范围为 29-63bits/min）。表 7.1 为其中三名受试者的详细测试结果，代表了所有受试者中的三种不同水平。其中两人完全正确地完成了所有任务，一人出现了一次误操作。临床测试中，有 10 名受试者可以使用本系统，平均信息传输速率为 21bits/min（范围为 8-36bits/min）。临床测试结果比实验室测试结果有较大的下降，可能有以下几方面的原因：1）受试者均为初次受试者，对闪烁刺激不太适应，较易产生视觉疲劳，而实验室测试者中大部分受试者都参加过多次实验；2）实验室环境光线较弱，有利于 SSVEP 的诱发，而临床环境光照较强，并且受到较多电磁干扰；3）受坐姿和环境干扰的影响，部分病人注意力不能集中，影响到 SSVEP 信号的诱发。

表 7.1 在线 SSVEP 脑-机接口实验室测试结果（确认键：✓，退格键：←）

受试者	刺激频率 (Hz)	字符输入结果	操作时间（秒） (最大值/最小值/均值)	信息传输速率 (bits/min)
QK	13-16	5917667775 ✓ ✓	3.77/3.21/3.40	63.10
GL	11-14	24527951 ← 411	5.96/4.70/4.87	44.17
MJ	11-14	363 ← 4119 ← (✓ ✓ ←) 885	10.46/4.98/5.68	31.35

基于稳态视觉诱发电位的脑-机接口系统有较高的数据传输率，可识别较多的目标种类，并且适用于大部分使用者。系统已被用于实现计算机操作、康复器械控制、电话拨号系统、机器人控制、家居环境控制器^[189]，图 7.10 为基于 SSVEP 脑-机接口的电话拨号演示系统^[194]，这一系统由本实验室的贾川和胥红来等人设计完成。



图 7.10 SSVEP 脑-机接口电话拨号演示系统

7.4 本章小结

基于稳态视觉诱发电位的脑-机接口由于其具有高信息传输率等方面的优势，在近年来倍受关注^[34-37]。然而由于 SSVEP 在频率、幅度、以及空间分布上的个体差异，SSVEP 在线脑-机接口在具体的实现过程中仍然存在许多问题需要解决。

本章提出的方法巧妙地解决了基于稳态视觉诱发电位的在线脑-机接口系统中的三个关键问题，即电极位置优化，刺激频率优选及时间窗的自动调节。使改进后的数据信息传输率（43bits/min）明显优于旧系统（27bits/min），适用的人群也得到了极大的扩展。在实验室和临床测试的所有受试者中（共 27 人），仅有一人不能完成系统操作，其他受试者都能完成简单的家电控制或更复杂的数字拨号。

本章的研究成果为开发实用的基于稳态视觉诱发电位的脑-机接口装置奠定了坚实的基础。

第 8 章 多模式脑-机接口系统的设计

现有的脑-机接口设计大都只采用来自一种感觉模式的脑电信号，对应了大脑皮层的单个功能分区的活动。想象运动脑-机接口检测 μ 和 β 节律的变化，对应了大脑感觉运动皮层的活动；基于视觉诱发电位的脑-机接口检测视觉皮层对外界刺激响应，通过波形或频率的识别来判断注视的方向或注意的程度。以想象运动脑-机接口和视觉诱发电位脑-机接口为基础，本章提出了多模式脑-机接口的原理，并设计了基于视觉和触觉注意的多模式脑-机接口。

8.1 多模式脑-机接口的原理

感觉和认知活动由大脑的不同功能分区相互协作和整合共同完成。图 8.1 为大脑皮层的功能分区图，主要分为运动皮层区域（motor areas）、感觉皮层区域（sensory areas）和联合区域（association areas）^[88]。感觉皮层区域主要包括了视觉皮层（visual cortex）、听觉皮层（auditory cortex）、体感皮层（somatosensory cortex）等区域。不同感觉模式在大脑皮层的空间分布上相互独立，在大脑对运动和感觉信息的处理过程中，多种模式的感觉系统并行工作。




图 8.1 大脑皮层功能分区（摘自[88]）

从脑-机接口应用的角度出发,可以利用多模式感觉系统工作的并行性来提高脑-机接口系统的性能。在大脑的工作过程中,每种感觉模式都能独立工作,因此有可能结合多种感觉模式来设计脑-机接口系统。以运动皮层和视觉皮层两种模式为例,多模式脑-机接口的设计可以考虑以下两种方案:1)任务一致型,使用多模式脑电信号完成相同的任务,例如结合想象运动和视觉诱发电位控制一维光标的运动,光标位置由 μ 节律和 SSVEP 的幅度同时决定,这种方案在分类过程中可以使用特征结合算法,由于两种信号存在较强的独立性,特征结合可以显著提高系统的性能;2)任务独立型,使用不同模式的脑电信号完成独立的任务,例如使用 μ 节律控制光标水平方向运动,同时使用 SSVEP 来控制光标垂直方向的运动,从而实现二维的运动控制,这种模式相当于增加了系统的可识别任务数,因此同样可以提高系统的性能。以上两种方案中,任务独立型多模式脑-机接口方案的难度更大,可能需要受试者较长时间的训练和适应。本章的工作仅针对任务一致型多模式脑-机接口。本章的工作由本实验室的张丹共同合作完成。

8.2 基于视觉和触觉注意的脑-机接口系统

提取感觉运动皮层和视觉皮层的大脑活动特征是脑-机接口设计常采用的方法,脑电中反映感觉运动皮层活动的成分是 μ 节律,而与视觉皮层活动相应的是视觉诱发电位。本文采用视觉和触觉两种感觉模式来设计独立型的多模式脑-机接口,系统原理为注意 (attention) 对脑电节律信号的幅度调制。基于 SSVEP 的独立型脑-机接口有两种模式,第一种为受试者通过反馈训练来自动调节单一频率 SSVEP 的幅度^[9],另外一种为通过空间注意性选择来改变两个不同频率的 SSVEP 成分的幅度^[38,39]。触觉系统的电生理研究表明,触觉刺激诱发的稳态体感诱发电位 (steady state somatosensory evoked potential, SSSEP) 的幅度同样受到注意的调制^[195,196],另一方面触觉刺激还能引起感觉运动皮层 μ 节律的 ERD/ERS^[72]。当注意在不同模式的感觉系统间切换时,大脑相应功能分区的皮层活动也发生相应的变化^[197-199],通过检测这些变化可以确定使用者的注意模式,从而实现多模式注意的脑-机接口。基于视觉和触觉多模式注意的脑-机接口是独立型的系统,工作原理为使用者对注意模式的自主选择,系统设计主要研究以下四个问题:1)注意对 SSVEP 的调制,2)注意对 μ 节律的调制,

3) 注意对 SSSEP 的调制, 4) 触觉空间选择性注意对 SSSEP 的调制。

8.2.1 系统框图

多模式注意脑电实验过程中设计了三种任务模式, 分别是视觉注意、左手触觉刺激注意、右手触觉刺激注意。实验中三种任务随机出现, 任务种类由单次实验开始前计算机屏幕中央的字符提示给出 (Visual 为视觉注意, Left 和 Right 分别代表左右触觉注意)。图 8.2 为视觉和触觉注意的多模式脑-机接口的系统示意图和数据采集示意图。

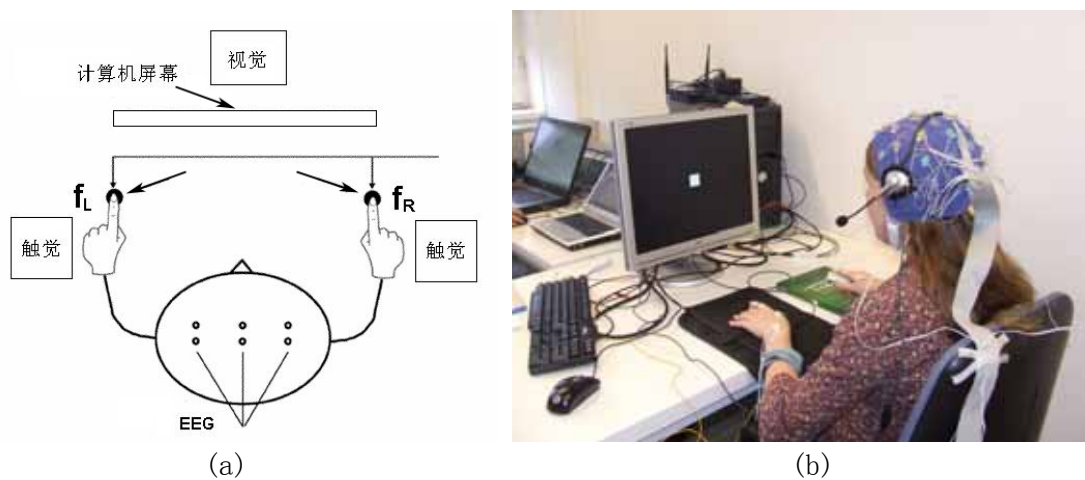


图 8.2 (a) 多模式注意脑-机接口系统示意图; (b) 脑电采集实验示意图。

单次实验的总时间为 10 秒, 前 5 秒为注意任务, 后 5 秒为休息。视觉刺激为计算机屏幕中央的黑白闪烁字符 (视角为 2.4 度), 要求受试者在任务过程中始终注视闪烁字符, 为方便受试者集中注意力, 随机出现五种字符 (从 A-E, 出现的次数可能为 1-7 次), 每次视觉注意任务开始时, 给出要求受试者注意的目标字符, 受试者计算目标字符在单次实验中出现的次数, 在任务结束后报告计数结果。视觉刺激的频率为 4.3Hz, 可以诱发出相同频率的 SSVEP。触觉刺激采用德国 QuaeroSys 公司的触觉刺激器, 刺激器为可用于生成盲文 (Braille) 的 8 根直径为 1 毫米的刺激点组成的阵列 (排成两列, 大小为 3×8 毫米), 刺激位置为两手食指的末端位置。为保证刺激位置不变, 用医用胶带将刺激器粘在食指下方。刺激器的 8 个刺激点采用相同的信号来控制, 刺激的幅度可变范围为 0-1.5 毫米。每次任务的最后阶段触觉刺激的幅度可能发生跳变 (幅度下降), 持续的时间为 100 毫秒, 触觉注意的任务是检测刺激过程中是否发生了幅度跳变。为

保证在触觉刺激过程中受试者能集中注意力，幅度跳变的大小通过准备实验来设定，使用对幅度变化检出率约为 80%时的跳变幅度。左右手的触觉刺激采用两个不同的频率标定，刺激频率通过预实验来确定，选择 20-40Hz 范围内体感诱发电位幅度较大的频率。另外，为避免由刺激器噪声引起的听觉干扰，在视觉和触觉刺激的同时给受试者播放白噪声，声强为受试者无法听见刺激器噪声时的最低声强。

共有 8 名视觉和触觉功能正常的志愿者（5 名男性，3 名女性，年龄在 20-30 岁之间）参加了多模式注意的实验，脑电采集使用 BioSemi 公司的 ActiveTwo 脑电图机，共采集 32 导联脑电（电极位置采用 10-20 导联系统，见图 8.3），另外在左右手各使用一个双极导联记录肌电（EMG）信号，肌电电极的放置以能准确记录到手指运动的肌电信号为标准，信号的采样率为 1024Hz。每名受试者采集 5 组数，每组数据包含 60 个样本（每类样本各 20 个），每名受试者一共得到每类各 100 个样本用于离线分析。




图 8.3 多模式注意实验电极位置图

8.2.2 特征提取和模式分类

在多模式脑-机接口中，采用基于脑电节律调制信号能量分析的方法进行特征提取，使用快速傅立叶变换（FFT）计算脑电信号的幅度谱。在视皮层区域检测 SSVEP 幅度的变化，而在感觉运动皮层区域检测 SSSEP 和 mu 节律的幅度变化。图 8.4 为三种任务状态下两名受试者枕区 Oz 位置处的 SSVEP 幅度谱，SSVEP 在基频和倍频处有明显的谱峰（4.3Hz 和 8.6Hz 处）。在视觉注意任务下，SSVEP 的基频幅度高于触觉注意而在倍频处三种任务没有明显差别，同时 alpha 节律受到抑制，能量低于触觉注意模式；而在左右触觉两种任务下，SSVEP 和 alpha 波的幅度都没有明显差别。图 8.5 为一名受试者感觉运动皮层 C3/C4 导联位置的 mu 节律幅度谱。触觉注意模式下，mu 节律几乎完全被抑制，能量远低于视觉注意任务，但在两种触觉任务下 mu 节律没有显著差别。图中 18Hz 和 20Hz 的两个谱峰值分别对应了由右手和左手触觉刺激诱发的 SSSEP，其空间分布具有对侧强同侧弱的特点。图 8.6 为一名受试者 C3/P4 位置的 SSSEP 幅度谱，右手 SSSEP 的刺激频率为 27Hz，左手刺激频率为 20Hz。在 C3 导联上，注意右手刺激时 SSSEP 的幅度受到抑制，注意左手和视觉注意两种任务下 SSSEP 的幅度接近；而在 P4 导联上，注意左手刺激时 SSSEP 幅度降低，注意右手和视觉注意两种模式下 SSSEP 的幅度相同。根据两个不同频率标记的 SSSEP 信号的幅度大小可以实现三种任务的识别。




图 8.4 三种注意任务下两名受试者 Oz 位置的 SSVEP 幅度谱：（a）受试者 A；（b）受试者 B。




图 8.5 一名受试者的 mu 节律幅度谱：(a) C3 导联；(b) C4 导联。




图 8.6 一名受试者的 SSSEP 幅度谱：(a) C3 导联；(b) P4 导联。

系统的特征提取和分类算法框图见图 8.7。数据处理的具体流程可以描述为以下三个步骤：

1) 信号预处理。采用共平均参考 (common average reference, CAR) 对 32 导原始信号进行空间滤波, CAR 可以降低背景噪声的影响, 从而提高信号的信噪比。对每次实验任务, 仅分析注意任务提示开始后的 5 秒数据。

2) 特征提取。采用 FFT 分别计算 32 导联信号的幅度谱, 由于视觉刺激频率为 4.3Hz, 需要 0.1Hz 的频率分辨率, 因此计算过程中对实际的 5 秒脑电数据通

过补零到长度为 10 秒。根据 SSVEP, mu 节律, 和 SSSEP 的频率从幅度谱中挑选三类特征; 进一步根据视觉皮层和体感皮层的空间位置特征进行电极的挑选, SSVEP 采用枕区位置的电极, mu 节律采用顶区位置的电极, 而 SSSEP 使用额区和顶区较大范围的电极。电极的选择可以根据先验知识来大致确定, 也可以采用计算 r^2 空间分布的方法来完成。经过选择得到三个特征向量 f_1 , f_2 , 和 f_3 , 分别代表了 SSVEP, mu 节律, 和 SSSEP 在不同注意任务模式下的幅度特征。这些特征可以反映注意对大脑视觉皮层和体感皮层活动的幅度调制。

3) 模式分类。SSVEP, mu 节律和 SSSEP 有各自的生理机制, 综合这三类信号的特征可以提高多模式注意分类的性能。将三个特征向量 f_1 , f_2 , 和 f_3 拼接成包含了三类信号特征的一个特征向量 $f=[f_1 f_2 f_3]$ 。由于特征向量有较高的维数, 使用推广性能较好的支持向量机 (SVM) 作为分类器, 对视觉注意和左右触觉注意三种任务进行分类, SVM 分类器使用径向基核函数^[157]。




图 8.7 特征提取和分类算法框图

8.2.3 分类结果

表 8.1 列出了 8 名受试者的分类结果, 采用 10×10 交叉检验方法得到。特征提取中, 除 SSVEP 采用相同的频率外, mu 节律选择峰值处的频率作为特征 (所有受试者的峰值频率范围为 9-12.5Hz), SSSEP 的频率根据刺激频率而定。左右触觉刺激注意的平均分类正确率为 63% (48.8%-78.5%), 只有一名受试者高于 75%。这一结果说明触觉空间选择性注意对 SSSEP 的调制作用并不显著。对视觉和触觉注意进行分类, 平均正确率为 83.2% (70.6%-90.7%), 不同感觉模式间的注意切换对三种脑电节律信号有调制作用, 其中 SSVEP 和 mu 节律更为显著。

三种任务的总分类正确率为 61.7%，与左右触觉注意的两分类结果相当。以上结果说明，空间选择性注意的实现困难较大，在线反馈训练可能有助于实现空间注意对 SSSEP 的幅度调制；而视觉和触觉的注意切换分类结果比较稳定，适合用于设计两种任务模式的在线脑-机接口系统。

数据分析结果表明，SSVEP 和 mu 节律的幅度明显受到注意的调制，而对于大部分受试者，SSSEP 的幅度没有显著变化。为研究多模式脑-机接口系统中不同模式脑电信号的作用，选择三种任务中的右手触觉注意和视觉注意两种任务进行分类，仅使用 SSVEP 和 mu 节律两种特征，得到的分类结果见表 8.2。同步记录的肌电信号的 r^2 分析结果说明视觉和触觉注意的可分性不是由肢体的真实动作引起的，所有受试者的 r^2 均值为 0.0071，使用肌电信号无法区分两类注意任务。单独使用 SSVEP 和 mu 节律的特征，两类任务的分类正确率分别为 81.4% 和 79.2%，结合两种特征后平均正确率为 87.6%，特征结合方法比使用单个特征提高了 4.4%。SSVEP 和 mu 节律分别反映了视皮层和体感皮层的活动，因此两者有较强的独立性，在任务一致型的多模式脑-机接口中，通过多感觉模式脑电信号的特征结合能够显著地提高脑-机接口的性能。

表 8.1 三任务分类使用的脑电分量的频率 (Hz) 和分类正确率 (±标准差, %)

受试者	SSVEP	Mu 节律	SSSEP (左 / 右)	左 / 右	触觉 / 视觉	三分类
CL	4.3	12	24/20	55.8±4.1	90.7±1.8	63.9±3.2
IN	4.3	11	20/18	63.8±4.2	81.7±4.0	56.9±3.2
NI	4.3	12	22/20	63.1±3.5	89.2±2.3	61.8±3.7
ZH	4.3	12.5	27/31	69.4±2.1	83.2±4.7	65.9±0.9
WA	4.3	12	20/27	78.5±3.7	90.2±3.1	80.1±2.4
CO	4.3	11	22/24	48.8±2.1	76.2±3.3	46.1±3.7
AL	4.3	9	20/27	64.3±1.8	83.5±2.9	61.9±3.2
TI	4.3	11	24/20	60.4±3.3	70.6±4.6	57.3±3.2
均值	——	——	——	63.0	83.2	61.7

表 8.2 右手触觉和视觉注意两任务脑电分类的正确率 (%) 和肌电的 r^2 值

受试者	r^2 (肌电)	Mu 节律	SSVEP	特征结合	提高
CL	0.0003	94.0	88.0	99.0	5.0
IN	0.0002	89.5	88.5	93.5	4.0
NI	0.0001	83.5	81.0	90.0	6.5
ZH	0.0426	82.0	76.0	88.0	6.0
WA	0.0018	77.5	80.5	87.5	7.0
CO	0.0003	71.0	80.5	83.0	2.5
AL	0.0114	68.0	78.5	81.0	2.5
TI	0.0001	68.0	78.0	80.0	2.0
均值	0.0071	79.2	81.4	87.6	4.4

8.2.4 多模式注意过程中 mu 节律的 ERD/ERS

视觉注意和触觉注意两种模式下, 感觉运动皮层的 mu 节律有显著差别。对 mu 节律做进一步分析, 计算其能量的 r^2 空间分布以及 mu 节律变化的时间过程。图 8.8 为一名受试者视觉注意和右手触觉注意两种任务下 mu 节律的对比分析。从图 8.8 (a) 看 C3 导联 mu 节律变化的时间过程, 主要体现为视觉注意过程中显著的能量上升, 表现为 ERS; 而在触觉注意状态下 mu 节律的幅度下降, 表现为 ERD 过程。随着注意任务的结束, mu 节律恢复到休息状态。图 8.8 (b) 为 mu 节律能量的 r^2 空间分布图。视觉注意任务下, mu 节律的 ERS 有较大的区域分布, 包括了左右感觉运动皮层以及前额区域。在触觉刺激过程中, 感觉运动皮层的状态受注意模式的调制, 在触觉注意模式下, 感觉运动皮层处于兴奋的状态, mu 节律受到抑制出现 ERD; 而在视觉注意模式下, 感觉运动皮层处于空闲状态, 从而出现 mu 节律的 ERS。




图 8.8 (a) mu 节律 ERD/ERS 时间过程，2 秒为任务开始时刻；(b) mu 节律 r^2 的空间分布图。

8.3 本章小结

现有的脑-机接口系统局限于单一的感觉模式，而大脑对信息的处理是由多模式感觉系统的相互协作共同完成的。基于多模式感觉系统并行工作的原理，本章提出了一种全新的多模式脑-机接口方案，并设计了基于视觉和触觉注意切换的多模式注意脑-机接口。

多模式注意脑-机接口系统采用 SSVEP、SSSEP 和 mu 节律的幅度调制为系统方案。以 SSVEP 和 mu 节律为特征的视觉和触觉注意任务分类获得了较高的性能，与单一模式特征的分类结果相比多模式系统的性能有显著的提高。数据分析结果表明，SSVEP 和 mu 节律的幅度受注意模式的调制，在视觉注意的状态下，视觉皮层兴奋增强，SSVEP 的幅度增加，而感觉运动皮层的活动被抑制，mu 节律的能量大幅上升；在触觉注意的状态下情况相反。

基于多模式注意的脑-机接口是完全独立的脑-机接口系统，并且有较高的分类正确率，可用于实现两种任务模式的在线脑-机接口系统。另外，多模式脑-机接口的设计思路还可直接用于提高现有脑-机接口系统的性能。

第 9 章 总结和展望

脑-机接口是当前神经工程领域研究的热点，经过最近十几年的快速发展，基于脑电信号的脑-机接口系统已经开始进入临床应用的研究阶段^[12,36,43,52]。设计性能稳定、操作方便、并且具有“脑-机交互学习”功能的在线系统是脑-机接口系统实用化的关键。使用特征稳定的脑电信号，应用有效的信号处理和机器学习算法是提高系统数据传输速率的常用方法。本论文的工作提出了基于脑电节律调制的脑-机接口系统框架，将感觉运动皮层的 μ/β 节律和视皮层的 SSVEP 应用到在线脑-机接口系统的设计中，成功实现了想象运动在线系统、同步化在线系统、SSVEP 在线系统，并提出了一种多模式脑-机接口的系统原型。针对脑电节律信号的特点，本论文提出了一套有效的脑电节律信号特征提取算法；并将基于统计学习理论的机器学习算法应用到在线脑-机接口系统中，实现了“脑-机交互学习”的功能。本论文的工作为基于节律调制的脑-机接口系统的实用化打下了良好的基础。

9.1 论文的工作成果

论文的主要工作成果可以概括为以下三部分：

1) 信号处理算法在节律调制脑-机接口中的应用：

论文对大脑运动皮层的运动相关脑电进行了较为深入的分析，从时域、频率、空域研究了想象运动过程中运动相关的 μ/β 节律的事件相关去同步化和同步化（ERD/ERS）和运动准备电位（readiness potential）的特点。从能量特征提取、空间滤波增强、同步化分析三个方面研究了脑电节律信号的分析方法。这些算法被成功用于实现在线脑-机接口系统。

2) 机器学习算法在脑-机接口在线系统中的应用：

论文中提出了一套基于统计学习理论的脑-机交互适应方法，实现了性能稳定的在线脑-机接口系统，并成功解决了在线机器学习中的“小样本学习”和“休息状态检测”问题。针对多导联脑电信号在线小样本学习中可能出现的过学习问题（overfitting），提出了包括特征提取方法的选择、参数优选方法、自适应机器学习等一系列方法。结合半监督学习（semi-supervised learning）和

Bagging (bootstrap aggregation) 组合分类器的分类算法被成功应用到想象运动脑—机接口的离线数据分析和在线实验中。基于 μ 节律生理特征提出的“休息状态检测”方法成功实现了在没有训练样本时休息状态的自动检测。

3) 基于节律调制的在线脑—机接口系统的设计和实现:

(1) 设计并实现了基于想象运动的在线脑—机接口系统。以 BioSemi 脑电图机为硬件平台, 实现了基于两分类想象运动的一维光标控制 (想象左手动和右手动控制光标的上升和下降, 共 10 名受试者参加测试) 和基于三分类想象运动的多方向运动控制 (想象左右手动和脚动对应往左、往右和往前三个方向的运动, 共 5 名受试者参加测试)。参加两分类实验的受试者经过少量训练后平均正确率为 95%, 两分类实验效果最好的受试者参加了三分类实验, 平均分类正确率为 85%。

(2) 采用互相关的同步化计算方法, 实现了基于同步化的在线脑—机接口系统。以同步化脑—机接口系统为平台, 研究了想象运动过程中大脑运动皮层脑电的多尺度同步化现象 (multi-scale brain synchronization)。详细分析了想象运动过程中大脑运动皮层的辅助运动区 (SMA)、运动前区 (PMA)、左右初级运动皮层 (M1) 在 μ 节律频带范围的大范围 (large-scale synchrony) 和局部范围同步化 (local-scale synchrony)。以幅度和相位特征的独立性为依据, 提出了相位特征和能量特征结合的特征提取方法, 进一步提高了想象运动脑—机接口的性能。以 SMA 和 M1 区域同步化现象为依据, 提出了在 SMA 位置安放参考电极的电极放置方法 (仅使用 Fz 和 C3/C4 三个电极), 可用于实现较高性能的便携式想象运动脑—机接口。

(3) 搭建了基于 BioSemi 脑电图机的在线 SSVEP 脑—机接口系统, 提出了个性化参数设置的方法, 对电极位置、视觉刺激频率、系统判断速度进行优选, 进一步提高了 SSVEP 脑—机接口的性能。采用优选后的一个双极导联可以明显提高 SSVEP 的信噪比, 并且具有操作方便, 计算速度快等优点。改进后的系统在实验室对 16 名受试者进行了测试, 平均信息传输率为 43bits/min (29-63bits/min), 与旧系统 (27bits/min) 相比有较大的提高。在中国康复中心对 11 名脊髓损伤病人在普通生活环境下进行了基于新系统的环境控制器测试 (控制电视), 平均信息传输率为 21bits/min。在系统的视觉刺激频率选择环节进一步讨论了高频 SSVEP 应用到脑—机接口系统中的可能性。虽然高频 SSVEP 幅度较低, 但在脑电高频范围内有足够高的信噪比, 并且还有减缓视觉疲劳的

优点，因此可以用于实现 SSVEP 系统。此外结合多频段 SSVEP 可以增加系统的可识别目标数，从而进一步提高 SSVEP 脑-机接口系统的实用性。

(4) 以视觉皮层的 SSVEP 和感觉运动皮层的 μ 节律为研究对象，进行了多模式脑-机接口的可行性研究，并实现了基于多模式注意（视觉刺激和触觉刺激的注意切换）的离线系统。对 8 名受试者的离线数据分析结果表明：当包含任务信息的视觉刺激和触觉刺激同时存在时，SSVEP 和 μ 节律的幅度受到注意模式的调制，以触觉注意状态为基线，视觉注意不但增强了 SSVEP 的幅度，而且同时增强了 μ 节律的幅度。来自不同感觉系统的脑电相关成分可以被并行地应用到脑-机接口系统中，为实现脑-机接口的多自由度控制提供了一种可行性方案。

9.2 论文的创新点

论文的主要创新点体现在以下两个方面：

1) 脑-机接口数据分析算法研究中的创新：

(1) 以脑电成分在生理机制上的独立性以及特征提取方法的独立性为依据，将特征结合算法应用到脑电数据分类中获得了较高的性能。在真实手指运动和想象运动脑电的分类中，结合了 μ/β 节律的 ERD/ERS 和运动准备电位；对 μ/β 节律的分析中，结合了 CSP 和 AR 模型算法进行特征提取。特征结合的方法在第二届国际脑-机接口数据竞赛中获得了“单次手指运动脑电分类数据集”的第一名。

(2) 将统计学习理论中的小样本学习方法成功地应用到在线脑-机接口系统中，针对想象运动脑电分类提出了一套脑-机交互适应的方法：以 CSP 空间滤波方法进行特征提取，以半监督学习和 Bagging 分类器进行在线学习和分类。这一方法获得了第三届国际脑-机接口竞赛“小样本想象运动脑电分类数据集”的第一名。

(3) 提出了想象运动分类中空闲状态 (idle state) 的自动检测方法。根据 μ 节律在大脑运动皮层空间分布上的特点，在仅有想象手动和想象脚动状态两类训练样本的情况下设计出能够准确地区分出空闲状态的分类器（三分类分类器）。这一方法能够减少训练时间，并且较好地解决了空闲状态时大脑状态不确定的问题，获得了第三届国际脑-机接口竞赛“休息状态自动检测”数据集的

第一名。

2) 在线脑-机接口系统开发中的创新:

(1) 设计了基于三类任务想象运动的机器人运动控制系统, 实现了肢体想象和运动方向的直接对应(想象左右手对应向机器人左向右运动, 想象脚动对应机器人向前运动), 采用基于视觉反馈和机器学习的脑-机交互适应方法进行在线训练和操作, 在线机器人控制系统在普通实验室环境中获得了较稳健的系统性能。

(2) 以大脑运动皮层各区域脑电节律的同步化活动为基础提出了适用于想象运动脑电分类的多尺度同步化(multi-scale brain synchrony)分析方法。在同步化特征的计算中提出了基于时域波形互相关分析的方法, 以此为基础, 实现了基于同步化特征的在线脑-机接口系统。

(3) 提出了基于电极位置优选的脑-机接口便携化和实用化方法。研究了 SSVEP 脑-机接口中 SSVEP 空间分布的特点, 在想象运动脑-机接口中研究了 mu 节律在运动皮层的区域同步化。采用双极导联(bipolar lead)的方式来提高特征提取方法的性能: 在 SSVEP 系统中消除了共有的背景脑电而保留 SSVEP 成分, 从而提高了 SSVEP 的信噪比; 而在想象运动系统中通过削弱同步化的成分, 从而进一步增强了由 mu 节律的 ERD 引起的大脑左右运动皮层的能量差异。在使用少量电极的在线脑-机接口系统中, 电极优选的方法显著提高了系统的性能。

(4) 设计了基于多模式注意(multi-modal attention)的脑-机接口系统, 以此为基础进一步提出了基于多模式脑电信号的脑-机接口系统的设计方案。与单一模式的系统相比, 多模式系统的性能得到了显著提高。多模式脑-机接口系统也可以作为多感觉交叉模式整合(multi-sensory cross-modal integration)^[200]研究的平台。

9.3 脑-机接口研究的展望

9.3.1 本论文进一步研究的展望

本论文的工作以节律调制在线脑-机接口系统的设计和实现为目标, 并通过较多样本的测试评价了系统的性能。有关节律调制脑-机接口的进一步研究可以从以下几个方面展开:

1) “脑—机交互适应学习”的深入研究。在大脑学习方面,可以研究大脑皮层在短时间训练(short-term training)和长时间训练(long-term training)过程中活动区域和活动强度的变化,同时评价生物反馈对大脑训练的作用;在机器学习方面,可以研究分类器的初始化方法,对“组对组”、“人对人”、“小样本学习”等各种方法进行比较。另外,对“脑—机交互适应学习”效果的评价需要设计严格的对照实验来进行。

2) 想象运动脑—机接口的临床测试。本论文中参加想象运动脑—机接口系统测试的都是运动功能正常的志愿者,对长期丧失肢体运动功能的病人,大脑运动皮层在功能上可能发生了变化,因此需要通过进一步的临床测试来对系统进行调整。在康复训练的应用中,肢体的被动运动同时会引起运动皮层脑电节律的变化,这些脑电变化可能对控制脑—机接口系统的脑电节律产生影响,如何保证脑—机接口系统在肢体运动过程中正常工作是想象运动脑—机接口在康复系统应用中需要解决的主要问题。

3) 高频 SSVEP 在线系统的实现。本论文采用离线分析的方式论证了高频 SSVEP 用于实现脑—机接口的可行性,其优点是有助于缓解视觉疲劳,并且能够增加可识别目标数。由于高频 SSVEP 的幅度很低,可能导致较差的抗干扰能力,环境光照、注意程度都可能对系统的性能产生较大的影响。高频 SSVEP 的实用性需要通过在线系统的测试来做进一步的验证。

4) 多模式脑—机接口在线系统的实现。论文提出了多模式注意的脑—机接口系统原型,离线分析在区分视觉注意和触觉注意两种任务时获得了较高的正确率,但在触觉空间选择性注意模式的脑电分类中没有得到一致的结果。与离线分析相比,在线系统的设计和实现更有利于多模式脑—机接口的深入研究。通过在线反馈系统的实现,在系统中加入大脑适应的过程,能进一步提高触觉和视觉注意两分类系统的性能,并且可能有助于寻找到触觉空间选择性注意更有效的执行方法。论文只对任务一致型多模式系统进行了研究,更为复杂的任务独立型多模式脑—机接口还有待进一步的研究。

9.3.2 脑—机接口研究的展望

脑—机接口实用化的研究以提高在线系统的性能为目标,包括了系统原理的设计,特征提取和分类算法的改进,大脑学习和机器算法的交互适应等多个方面。脑—机接口系统除了用于实用化方法研究之外,还能作为大脑神经科学

研究的平台，多模式脑功能成像（multi-modal neuroimaging）和多感觉交叉模式整合（multi-sensory cross-modal integration）是今后脑-机接口研究可能的方向。

1) 基于多模式脑功能成像的脑-机接口系统：

脑电图(EEG)通过测量大脑活动时产生的电信号来研究脑功能的动态过程，可以达到毫秒级的时间分辨率，因此可以对脑的活动做实时的记录，但由于传导过程中的模糊化效应，EEG 方法的空间分辨率较低；功能磁共振成像（fMRI）通过测量大脑活动时脑内各处血流含氧量的变化来反映神经细胞活动的变化，fMRI 可以达到 1-2 毫米的空间分辨率。因为 EEG 和 fMRI 在时间和空间分辨率上的优势互补关系，EEG 和 fMRI 的融合分析方法是脑功能成像研究的热点，EEG 和 fMRI 的同步记录能够保证两种数据出自相同的脑活动，但同步记录方法还存在着很多技术困难需要解决^[201,202]。EEG 和 fMRI 的同步记录使得基于多模式脑功能成像的脑-机接口系统的实现成为可能，高时间分辨率的 EEG 信号可以给受试者提供实时的反馈信号，并用于研究大脑变化的时间过程；而由 fMRI 可以得到空间分辨率很高的大脑活动状态，还可以观察到脑电信号难以检测的脑内深部结构的活动。EEG 和 fMRI 的结合可以更深入地研究脑-机接口训练过程中大脑发生的变化，研究在线脑-机接口使用中大脑不同功能分区之间的协作和整合。

2) 多感觉交叉模式脑-机接口系统：

大脑中存在着能对多种感觉模式的刺激发生响应的神经元，这些神经元实现了多感觉模式的整合。当多种不同模式的感觉在时间或空间上相近时，神经元的发放大大增加（高于多个单模式响应的直接求和）；相反地，如果多模式信息完全不匹配，神经元的发放将会受到显著的抑制。对感觉系统交叉模式处理（cross-modal processing）的研究可以归纳为以下三个方面：交叉模式的匹配（cross-modal matching），内容和空间信息的交叉模式整合（cross-modal integration），交叉模式的学习（cross-modal learning）^[200]。现有的交叉模式整合的研究主要集中在通过多个单一模式与整合模式的对照研究来确定交叉整合过程所包含的大脑功能区域。

研究大脑交叉模式集成的基本方法是对比多个单一模式和交叉模式情况下大脑皮层的不同状态，而对多种大脑状态的分类检测是设计实现脑-机接口常用的方法，因此交叉模式集成可以应用到脑-机接口系统的方案设计中。讨论几种可能用于实现脑-机接口的多模式集成方法：1) 通过交叉模式匹配来诱发

事件相关电位 (ERP), 交叉模式匹配具体表现为多种感觉刺激同时存在时通过多模式匹配来诱发 ERP, 与单一模式刺激诱发的 ERP 相比, 多模式诱发响应有更大的幅度, 因此能提高现有的基于单模式 ERP 的脑-机接口系统的性能; 2) 想象 (imagery) 在交叉模式整合中的应用^[203], 想象对交叉模式的作用和交叉模式学习有关。经过学习配对, 在单一模式刺激下可以通过想象来得到与交叉模式整合相同的结果, 因为想象可由大脑自由支配, 因此可用于实现独立的脑-机接口系统。以简单的两分类任务为例, 一种模式下受试者仅接受字符的声音刺激, 另一种模式为在声音刺激的同时受试者做相应的字形想象, 大脑在这两种模式下的状态分别为单一模式和交叉模式。同样, 对其它感觉模式也可以进行想象活动, 从而产生多种与不同感觉模式相应的大脑状态。

参考文献

- [1] Wolpaw J R, Birbaumer N, McFarland D J, et al. Brain-computer interfaces for communication and control. *Clin Neurophysiol*, 2002, 113:767-791.
- [2] Wolpaw J R, Birbaumer N, Heetderks W J, et al. Brain-computer interface technology: A review of the first international meeting. *IEEE Trans Rehabil Eng*, 2000, 8:164-173.
- [3] Vaughan T M, Heetderks W J, Trejo L J, et al. Brain-computer interface technology: A review of the second international meeting. *IEEE Trans Rehabil Eng*, 2003, 11:94-109.
- [4] Birbaumer N. Breaking the silence: Brain-computer interfaces (BCI) for communication and motor control. *Psychophysiology*, 2006, 43:517-532.
- [5] Birbaumer N. Brain-computer-interface research: Coming of age. *Clin Neurophysiol*, 2006, 117:479-483.
- [6] Lebedev M A, Nicolelis M A L. Brain-machine interfaces: past, present and future. *Trends Neurosci*, 2006, 29:536-546.
- [7] Haynes J D, Rees G. Decoding mental states from brain activity in humans. *Nat Rev Neurosci*, 2006, 7:523-534.
- [8] Sutter E E. The brain response interface: communication through visually-induced electrical brain response. *J Microcomput Appl*, 1992, 15:31-45.
- [9] Middendorf M, McMillan G, Calhoun G, et al. Brain-computer interfaces based on the steady-state visual-evoked response. *IEEE Trans Rehabil Eng*, 2000, 8:211-214.
- [10] Pfurtscheller G, Neuper C. Motor imagery and direct brain-computer communication. *Proc IEEE*, 2001, 89:1123-1134.
- [11] Wolpaw J R, McFarland D J, Vaughan T M. Brain-computer interface research at the Wadsworth Center. *IEEE Trans Rehabil Eng*, 2000, 8:222-226.
- [12] Hinterberger T, Schmidt S, Neumann N, et al. Brain-computer communication and slow cortical potentials. *IEEE Trans Biomed Eng*, 2004, 51:1011-1018.
- [13] Donchin E, Spencer K M, Wijesinghe R. The mental prosthesis: Assessing the speed of a P300-based brain-computer interface. *IEEE Trans Rehabil Eng*, 2000, 8:174-179.
- [14] Blankertz B, Dornhege G, Schafer C, et al. Boosting bit rates and error detection for the classification of fast-paced motor commands based on single-trial EEG analysis. *IEEE Trans Neural Syst Rehabil Eng*, 2003, 11:127-131.
- [15] Levine S P, Huggins J E, BeMent S L, et al. Identification of electrocorticogram patterns as the basis for a direct brain interface. *J Clin Neurophysiol*, 1999, 16:439-447.

-
- [16] Graitmann B, Huggins J E, Levine S P, et al. Toward a direct brain interface based on human subdural recordings and wavelet-packet analysis. *IEEE Trans Biomed Eng*, 2004, 51:954-962.
- [17] Hill N J, Lal T N, Schroder M, et al. Classifying EEG and ECoG signals without subject training for fast BCI implementation: Comparison of nonparalyzed and completely paralyzed subjects. *IEEE Trans Neural Syst Rehabil Eng*, 2006, 14:183-186.
- [18] Kauhanen L, Nykopp T, Sams M. Classification of single MEG trials related to left and right index finger movements. *Clin Neurophysiol*, 2006, 117:430-439.
- [19] Kauhanen L, Nykopp T, Lehtonen J, et al. EEG and MEG brain-computer interface for tetraplegic patients. *IEEE Trans Neural Syst Rehabil Eng*, 2006, 14:190-193.
- [20] Hinterberger T, Weiskopf N, Veit R, et al. An EEG-driven brain-computer interface combined with functional magnetic resonance imaging (fMRI). *IEEE Trans Biomed Eng*, 2004, 51:971-974.
- [21] Yoo S S, Fairney T, Chen N K, et al. Brain-computer interface using fMRI: spatial navigation by thoughts. *Neuroreport*, 2004, 15:1591-1595.
- [22] Coyle S, Ward T, Markham C, et al. On the suitability of near-infrared (NIR) systems for next-generation brain-computer interfaces. *Physiol Meas*, 2004, 25:815-822.
- [23] Miyoshi T, Fujibayashi Y, Yonekura Y, et al. The construction of a brain-computer interface using the brain activity measured by near infrared spectroscopy. *Neurosci Res*, 2006, 55:S262-S262.
- [24] Hochberg L R, Serruya M D, Friehs G M, et al. Neuronal ensemble control of prosthetic devices by a human with tetraplegia. *Nature*, 2006, 442:164-171.
- [25] Santhanam G, Ryu S I, Yu B M, et al. A high-performance brain-computer interface. *Nature*, 2006, 442:195-198.
- [26] Serruya M D, Hatsopoulos N G, Paninski L, et al. Instant neural control of a movement signal. *Nature*, 2002, 416:141-142.
- [27] Chapin J K, Moxon K A, Markowitz R S, et al. Real-time control of a robot arm using simultaneously recorded neurons in the motor cortex. *Nat Neurosci*, 1999, 2:664-670.
- [28] Taylor D M, Tillery S I H, Schwartz A B. Direct cortical control of 3D neuroprosthetic devices. *Science*, 2002, 296:1829-1832.
- [29] Clark J W. The origin of biopotentials // Webster J G. *Medical Instrumentation: Application and Design*. 3rd ed. New York: John Wiley & Sons, 1998:121-182.
- [30] Nowlis D P, Kamiya J. The control of electroencephalographic alpha rhythms through auditory feedback and the associated mental activity. *Psychophysiology*, 1970, 6:476-484.
- [31] Sterman M B, Macdonald L R, Stone R K. Biofeedback training of the sensorimotor electroencephalogram rhythm in man: effects on epilepsy. *Epilepsia*, 1974, 15:395-416.

-
- [32] Vidal J J. Towards direct brain-computer communication. *Annu Rev Biophys Bioeng*, 1973, 2:157-180.
- [33] Celesia G G, Peachey N S. Visual evoked potentials and electroretinograms // Niedermeyer E, Lopes da Silva FH. *Electroencephalography: basic principles, clinical applications and related fields*. Baltimore: Williams and Wilkins, 1999:1017-1043.
- [34] Cheng M, Gao X R, Gao S G, et al. Design and implementation of a brain-computer interface with high transfer rates. *IEEE Trans Biomed Eng*, 2002, 49:1181-1186.
- [35] Gao X R, Xu D F, Cheng M, et al. A BCI-based environmental controller for the motion-disabled. *IEEE Trans Neural Syst Rehabil Eng*, 2003, 11:137-140.
- [36] Wang Y J, Wang R P, Gao X R, et al. A practical VEP-based brain-computer interface. *IEEE Trans Neural Syst Rehabil Eng*, 2006, 14:234-239.
- [37] Muller-Putz G R, Scherer R, Brauneis C, et al. Steady-state visual evoked potential (SSVEP)-based communication: impact of harmonic frequency components. *J Neural Eng*, 2005, 2:123-130.
- [38] Kelly S P, Lalor E C, Finucane C, et al. Visual spatial attention control in an independent brain-computer interface. *IEEE Trans Biomed Eng*, 2005, 52:1588-1596.
- [39] Kelly S P, Lalor E C, Reilly R B, et al. Visual spatial attention tracking using high-density SSVEP data for independent brain-computer communication. *IEEE Trans Neural Syst Rehabil Eng*, 2005, 13:172-178.
- [40] Pfurtscheller G, Lopes da Silva F H. Event-related EEG/MEG synchronization and desynchronization: basic principles. *Clin Neurophysiol*, 1999, 110:1842-1857.
- [41] Pfurtscheller G, Brunner C, Schlogl A, et al. Mu rhythm (de)synchronization and EEG single-trial classification of different motor imagery tasks. *Neuroimage*, 2006, 31:153-159.
- [42] Naeem M, Brunner C, Leeb R, et al. Separability of four-class motor imagery data using independent components analysis. *J Neural Eng*, 2006, 3:208-216.
- [43] Wolpaw J R, McFarland D J. Control of a two-dimensional movement signal by a noninvasive brain-computer interface in humans. *Proc Natl Acad Sci USA*, 2004, 101:17849-17854.
- [44] Rockstroh B, Elbert T, Canavan A, et al. *Slow cortical potentials and behavior*. 2nd ed. Baltimore: Urban and Schwarzenberg, 1989.
- [45] Birbaumer N, Ghanayim N, Hinterberger T, et al. A spelling device for the paralysed. *Nature*, 1999, 398:297-298.
- [46] Hinterberger T, Wilhelm B, Mellinger J, et al. A device for the detection of cognitive brain functions in completely paralyzed or unresponsive patients. *IEEE Trans Biomed Eng*, 2005, 52:211-220.

-
- [47] Hinterberger T, Kubler A, Kaiser J, et al. A brain-computer interface (BCI) for the locked-in: comparison of different EEG classifications for the thought translation device. *Clin Neurophysiol*, 2003, 114:416-425.
- [48] Sutton S, Braren M, Zubin J, et al. Evoked correlates of stimulus uncertainty. *Science*, 1965, 150:443-446.
- [49] Blankertz B, Muller K R, Curio G, et al. The BCI competition 2003: Progress and perspectives in detection and discrimination of EEG single trials. *IEEE Trans Biomed Eng*, 2004, 51:1044-1051.
- [50] Blankertz B, Muller K R, Krusienski D J, et al. The BCI competition III: Validating alternative approaches to actual BCI problems. *IEEE Trans Neural Syst Rehabil Eng*, 2006, 14:153-159.
- [51] Mason S G, Birch G E. A brain-controlled switch for asynchronous control applications. *IEEE Trans Biomed Eng*, 2000, 47:1297-1307.
- [52] Pfurtscheller G, Guger C, Muller G, et al. Brain oscillations control hand orthosis in a tetraplegic. *Neurosci Lett*, 2000, 292:211-214.
- [53] Boord P, Barriskill A, Craig A, et al. Brain-computer interface-FES integration: Towards a hands-free neuroprosthesis command system. *Neuromodulation*, 2004, 7:267-276.
- [54] Pfurtscheller G, Muller G R, Pfurtscheller J, et al. 'Thought' - control of functional electrical stimulation to restore hand grasp in a patient with tetraplegia. *Neurosci Lett*, 2003, 351:33-36.
- [55] Cheng M, Gao S K. An EEG-based cursor control system. *Proc 1st Conf IEEE BMES/EMBS Serving Humanity and Advancing Technology*, Atlanta, 1999:669.
- [56] Xu N, Gao X R, Hong B, et al. BCI competition 2003 - Data set IIb: Enhancing P300 wave detection using ICA-based subspace projections for BCI applications. *IEEE Trans Biomed Eng*, 2004, 51:1067-1072.
- [57] Wang Y J, Zhang Z G, Li Y, et al. BCI competition 2003 - Data set IV: An algorithm based on CSSD and FDA for classifying single-trial EEG. *IEEE Trans Biomed Eng*, 2004, 51:1081-1086.
- [58] Cheng M, Jia W Y, Gao X R, et al. mu rhythm-based cursor control: an offline analysis. *Clin Neurophysiol*, 2004, 115:745-751.
- [59] Pei X M, Zheng C X, Xu J, et al. Multi-channel linear descriptors for event-related EEG collected in brain computer interface. *J Neural Eng*, 2006, 3:52-58.
- [60] Guan J A. VEP estimation with feature enhancement by whiten filter for brain computer interface. *Lect Notes Contr Inf*, 2006, 345:1101-1106.

-
- [61] Liu Q B, Zhou Z T, Liu Y, et al. Feature extraction and pattern classification on mining electroencephalography data for brain-computer interface. *Lect Notes Contr Inf*, 2006, 345:864-869.
- [62] Sun S L, Zhang C S, Lu N J. On the on-line learning algorithms for EEG signal classification in Brain Computer Interfaces. *Lect Notes Comput Sc*, 2005, 3614:638-647.
- [63] Mason S G, Bashashati A, Fatourechhi M, et al. A comprehensive survey of brain interface technology designs. *Ann Biomed Eng*, 2007, 35:137-169.
- [64] Kostov A, Polak M. Parallel man-machine training in development of EEG-based cursor control. *IEEE Trans Rehabil Eng*, 2000, 8:203-205.
- [65] Pineda J A, Silverman D S, Vankov A, et al. Learning to control brain rhythms: Making a brain-computer interface possible. *IEEE Trans Neural Syst Rehabil Eng*, 2003, 11:181-184.
- [66] Kaper M, Meinicke P, Grossekaethofer U, et al. BCI competition 2003 - Data set IIb: Support vector machines for the P300 speller paradigm. *IEEE Trans Biomed Eng*, 2004, 51:1073-1076.
- [67] Sajda P, Gerson A, Muller K R, et al. A data analysis competition to evaluate machine learning algorithms for use in brain-computer interfaces. *IEEE Trans Neural Syst Rehabil Eng*, 2003, 11:184-185.
- [68] Blankertz B, Dornhege G, Krauledat M, et al. The Berlin brain-computer interface: EEG-based communication without subject training. *IEEE Trans Neural Syst Rehabil Eng*, 2006, 14:147-152.
- [69] Rezaei S, Tavakolian K, Nasrabadi A M, et al. Different classification techniques considering brain computer interface applications. *J Neural Eng*, 2006, 3:139-144.
- [70] Kubler A, Mushahwar V K, Hochberg L R, et al. BCI Meeting 2005 - Workshop on clinical issues and applications. *IEEE Trans Neural Syst Rehabil Eng*, 2006, 14:131-134.
- [71] Speckmann E J, Elger C E. Introduction to the neurophysiological basis of the EEG and DC Potentials // Niedermeyer E, Lopes da Silva FH. *Electroencephalography: basic principles, clinical applications and related fields*. Baltimore: Williams and Wilkins, 1999:17-29.
- [72] Niedermeyer E. The normal EEG of the waking adult // Niedermeyer E, Lopes da Silva FH. *Electroencephalography: basic principles, clinical applications and related fields*. Baltimore: Williams and Wilkins, 1999:167-192.
- [73] Adrian E D, Matthews B H. The Berger rhythm: potential changes from the occipital lobes in man. *Brain*, 1934, 57:355-385.
- [74] Kuhlman W N. Functional topography of the human mu rhythm. *Electroencephalogr Clin Neurophysiol*, 1978, 44:83-93.

-
- [75] Gastaut H, Naquet R, Gastaut Y. A study of the mu rhythm in subjects lacking one or more limbs. *Electroencephalogr Clin Neurophysiol*, 1965, 18:720-721.
- [76] Arroyo S, Lesser R P, Gordon B, et al. Functional significance of the mu rhythm of human cortex: an electrophysiologic study with subdural electrodes. *Electroencephalogr Clin Neurophysiol*, 1993, 87:76-87.
- [77] Pfurtscheller G, Berghold A. Patterns of cortical activation during planning of voluntary movement. *Electroencephalogr Clin Neurophysiol*, 1989, 72:250-258.
- [78] McFarland D J, Miner L A, Vaughan T M, Wolpaw J R. Mu and beta rhythm topographies during motor imagery and actual movement. *Brain Topogr*, 2000, 3:177-186.
- [79] Salmelin R, Hari R. Spatiotemporal characteristics of sensorimotor neuromagnetic rhythms related to thumb movement. *Neuroscience*, 1994, 60:537-550.
- [80] Salmelin R, Hari R. Characterization of spontaneous MEG rhythms in healthy adults. *Electroencephalogr Clin Neurophysiol*, 1994, 91:237-248.
- [81] Sayers P, Beagley H A, Hanshall W R. The mechanisms of auditory evoked EEG responses. *Nature*, 1974, 247:481-483.
- [82] Basar E. EEG-Brain dynamics: relation between EEG and brain evoked potentials. Amsterdam: Elsevier, 1980.
- [83] Makeig S, Westerfield M, Jung T P, et al. Dynamic brain sources of visual evoked responses. *Science*, 2002, 295:690-694.
- [84] Lopes da Silva FH, Pfurtscheller G. Basic concepts on EEG synchronization and desynchronization. Event-related desynchronization // Lopes da Silva FH, Pfurtscheller G. *Handbook of electroencephalography and clinical neurophysiology*, vol.6. Amsterdam: Elsevier, 1999:3-11.
- [85] Steriade M, Llinas R. The functional states of the thalamus and the associated neuronal interplay. *Phys Rev*, 1988, 68:649-742.
- [86] Pfurtscheller G, Lopes da Silva FH. EEG event-related desynchronization (ERD) and event-related synchronization (ERS) // Niedermeyer E, Lopes da Silva FH. *Electroencephalography: basic principles, clinical applications and related fields*. Baltimore: Williams and Wilkins, 1999:17-29.
- [87] Bastiaansen M C M, Bocker K B E, Brunia C H M, et al. Event-related desynchronization during anticipatory attention for an upcoming stimulus: a comparative EEG/MEG study. *Clin Neurophysiol*, 2001, 112:393-403.
- [88] Bear M F, Connors B W, Paradiso M A. *Neuroscience: exploring the brain*. 2nd ed. Baltimore: Williams and Wilkins, 2001.
- [89] Regan D. *Human brain electrophysiology: evoked potentials and evoked magnetic fields in science and medicine*. New York: Elsevier, 1989.

-
- [90] Muller M M, Picton T W, Valdes-Sosa P, et al. Effects of spatial selective attention on the steady-state visual evoked potential in the 20-28 Hz range. *Cogn Brain Res*, 1998, 6:249-261.
- [91] Morgan S T, Hansen J C, Hillyard S A. Selective attention to stimulus location modulates the steady-state visual evoked potential. *Proc Nat Acad Sci USA*, 1996, 93:4770-4774.
- [92] McFarland D J, Anderson C W, Muller K R, et al. BCI Meeting 2005 - Workshop on BCI signal processing: Feature extraction and translation. *IEEE Trans Neural Syst Rehabil Eng*, 2006, 14:135-138.
- [93] Pfurtscheller G, Neuper C, Flotzinger D, et al. EEGbased discrimination between imagination of right and left hand movement. *Electroenceph Clin Neurophysiol*, 1997, 103:642 - 651.
- [94] Scherer R, Muller G R, Neuper C, et al. Anasynchronously controlled EEG-based virtual keyboard: Improvement of the spelling rate. *IEEE Trans Biomed Eng*, 2004, 51:979-984.
- [95] Schlögl A, Flotzinger D, Pfurtscheller G. Adaptive autoregressive modeling used for single-trial EEG classification. *Biomed Tech*, 1997, 42:162-167.
- [96] Pfurtscheller G, Neuper C, Schlogl A, et al. Separability of EEG signals recorded during right and left motor imagery using adaptive autoregressive parameters. *IEEE Trans Rehabil Eng*, 1998, 6(3):316-325.
- [97] Muller-Gerking J, Pfurtscheller G, Flyvbjerg H. Designing optimal spatial filters for single-trial EEG classification in a movement task. *Clin Neurophysiol*, 1999, 110:787-798.
- [98] Ramoser H, Gerking J M, Pfurtscheller G. Optimal spatial filtering of single trial EEG during imagined hand movement. *IEEE Trans Rehabil Eng*, 2000, 8(4):441-446.
- [99] Delorme A, Makeig S. EEG changes accompanying learned regulation of 12-Hz EEG activity. *IEEE Trans Neural Syst Rehabil Eng*, 2003, 11:133-137.
- [100] Hung C I, Lee P L, Wu Y T, et al. Recognition of motor imagery electroencephalography using independent component analysis and machine classifiers. *Ann Biomed Eng*, 2005, 33:1053-1070.
- [101] Qin L, Ding L, He B. Motor imagery classification by means of source analysis for brain computer interface applications. *J Neural Eng*, 2004, 1:135-141.
- [102] Kamousi B, Liu Z M, He B. Classification of motor imagery tasks for brain-computer interface applications by means of two equivalent dipoles analysis. *IEEE Trans Neural Syst Rehabil Eng*, 2005, 13:166-171.
- [103] Liu H S, Gao X R, Yang F S. A three-dimensional spatio-temporal EEG pattern analyzing system. *Prog Nat Sci*, 2003, 13:590-595.
- [104] Wang T, Deng H, He B. Classifying EEG-based motor imagery tasks by means of time-frequency synthesized spatial patterns. *Clin Neurophysiol*, 2004, 115:2744-2753.

- [105] Yamawaki N, Wilke C, Liu Z M, et al. An enhanced time-frequency-spatial approach for motor imagery classification. *IEEE Trans Neural Syst Rehabil Eng*, 2006, 14:250-254.
- [106] Gysels E, Celka P. Phase synchronization for the recognition of mental tasks in a brain-computer interface. *IEEE Trans Neural Syst Rehabil Eng*, 2004, 12:406-415.
- [107] Brunner C, Scherer R, Graimann B, et al. Online control of a brain-computer interface using phase synchronization. *IEEE Trans Biomed Eng*, 2006, 53:2501-2506.
- [108] Pei X M, Zheng C X, Xu J, et al. Multi-channel linear descriptors for event-related EEG collected in brain computer interface. *J Neural Eng*, 2006, 3:52-58.
- [109] 胡广书. 数字信号处理—理论、算法与实现. 北京: 清华大学出版社, 1997.
- [110] Millón J del R, Renkens F, Mourino J, et al. Brain actuated interaction. *Artif Intel*, 2004, 159:241-259.
- [111] McFarland D J, McCane L M, David S V, et al. Spatial filter selection for EEG-based communication. *Electroenceph Clin Neurophysiol*, 1997, 103:386-394.
- [112] Wang Y H, Berg P, Scherg M. Common spatial subspace decomposition applied to analysis of brain responses under multiple task conditions: a simulation study. *Clin Neurophysiol*, 1999, 110:604-614.
- [113] Hyvarinen A, Karhunen J, Oja E. *Independent Component Analysis*, New York: Wiley, 2001.
- [114] 杨福生, 洪波. 独立分量分析的原理与应用. 北京: 清华大学出版社, 2006.
- [115] Bell A J, Sejnowski T J. An information-maximization approach to blind separation and blind deconvolution. *Neural Comput*, 1995, 7:1129-1159.
- [116] Hyvarinen A, Oja E. A fast fixed-point algorithm for independent component analysis. *Neural Comput*, 1997, 9:1483-1492.
- [117] J. F. Cardoso, Infomax and maximum likelihood for blind source separation, *IEEE Signal Proc Let*, 1997, 4:109-111.
- [118] Lee T W, Girolami M, Bell A J, et al. A unifying information-theoretic framework for independent component analysis. *Comput Math Appl*, 2000, 39:1-21.
- [119] Hong B, Yang F S, Pan Y F, et al. Single-trial estimation and analysis of PVEP based on independent component analysis. *Tsinghua Science and Technology*, 2001, 6(5):503-508.
- [120] 洪波. 基于独立分量分析和自组织聚类的脑电时空模式研究[博士学位论文]. 北京: 清华大学电机系, 2001.
- [121] Jung T P, Makeig S, Westerfield M, et al. Removal of eye activity artifacts from visual event-related potentials in normal and clinical subjects. *Clin Neurophysiol*, 2000, 111:1745-1758.

-
- [122] Joyce C A, Gorodnitsky I F, Kutas M. Automatic removal of eye movement and blink artifacts from EEG data using blind component separation. *Psychophysiology*, 2004, 41:313-325.
- [123] Zarzoso V, Nandi A K. Noninvasive fetal electrocardiogram extraction: Blind separation versus adaptive noise cancellation. *IEEE Trans Biomed Eng*, 2001, 48:12-18.
- [124] Lee J, Park K L, Lee K J. Temporally constrained ICA-based foetal ECG separation. *Electron Lett*, 2005, 41:1158-1160.
- [125] McKeown M J, Makeig S, Brown G G, et al. Analysis of fMRI data by blind separation into independent spatial components. *Hum Brain Mapp*, 1998, 6:160-188.
- [126] Anemuller J, Duann J R, Sejnowski T J, et al. Spatio-temporal dynamics in fMRI recordings revealed with complex independent component analysis. *Neurocomputing*, 2006, 69:1502-1512.
- [127] Vigario R, Sarela J, Jousmaki V, et al. Independent component approach to the analysis of EEG and MEG recordings. *IEEE Trans Biomed Eng*, 2000, 47:589-593.
- [128] Jung T P, Makeig S, McKeown M J, et al. Imaging brain dynamics using independent component analysis. *Proc IEEE*, 2001, 89:1107-1122.
- [129] James C J, Hesse C W. Independent component analysis for biomedical signals. *Physiol Meas*, 2005, 26:R15-R39.
- [130] Tsai A C, Liou M, Jung T P, et al. Mapping single-trial EEG records on the cortical surface through a spatiotemporal modality. *Neuroimage*, 2006, 32:195-207.
- [131] Delorme A, Makeig S. EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis. *J Neurosci Meth*, 2004, 134:9-21.
- [132] Hesse C W, James C J. The FastICA algorithm with spatial constraints. *IEEE Signal Proc Let*, 2005, 12:792-795.
- [133] James C J, Gibson O J. Temporally constrained ICA: An application to artifact rejection in electromagnetic brain signal analysis. *IEEE Trans Biomed Eng*, 2003, 50:1108-1116.
- [134] Dornhege G, Blankertz B, Curio G, et al. Increase information transfer rates in BCI by CSP extension to multi-class // Thrun S, Saul L, Schölkopf B. *Advances in Neural Inf Proc Systems (NIPS03)*, vol.16. Cambridge: MIT Press, 2004.
- [135] Wu W, Gao X R, Gao S K. One-versus-the-rest (OVR) algorithm: an extension of common spatial patterns (CSP) algorithm to multi-class case. in *Proc 27th Int IEEE EMBS Conf*, 2005, 2387-2390.
- [136] Cardoso J F, Souloumiac A. Jacobi angles for simultaneous diagonalization. *SIAM J Mat Anal Appl*. 1996, 17(1):161-164.
- [137] Singer W. Neuronal synchrony: A versatile code for the definition of relations? *Neuron*, 1999, 24:49-65.

-
- [138] Varela F, Lachaux J P, Rodriguez E, et al. The brainweb: Phase synchronization and large-scale integration. *Nat Rev Neurosci*, 2001, 2:229-239.
- [139] Quiroga R Q, Kraskov A, Kreuz T, et al. Performance of different synchronization measures in real data: A case study on electroencephalographic signals. *Phys Rev E*, 2002, 65:041903.
- [140] Lachaux J P, Rodriguez E, Martinerie J, et al. Measuring phase synchrony in brain signals. *Hum Brain Mapp*, 1999, 8:194-208.
- [141] Wang Y J, Hong B, Gao X, et al. Phase synchrony measurement in motor cortex for classifying single-trial EEG during motor imagery. in *Proc 28th Int IEEE EMBS Conf*, 2006, 75-78.
- [142] Kukleta M, Lamarche M. Steep early negative slopes can be demonstrated in pre-movement Bereitschaftspotential. *Clin Neurophysiol*, 2001, 112:1642-1649.
- [143] Jahanshahi M, Hallett M. *The Bereitschaftspotential: movement-related cortical potentials*. New York: Kluwer Academic/Plenum Press, 2002.
- [144] Blankertz B, Curio G, Muller K R. Classifying single trial EEG: toward brain computer interfacing // Diettrich T G, Becker S, Ghahraman Z. *Advances in Neural Inf Proc Systems (NIPS01)*, vol.14. Cambridge: MIT Press, 2002.
- [145] http://ida.first.fraunhofer.de/projects/bci/competition_ii/
- [146] Sajda P, Gerson A, Muller K R, et al. A data analysis competition to evaluate machine learning algorithms for use in brain-computer interfaces. *IEEE Trans Neural Syst Rehabil Eng*, 2003, 11:184-185.
- [147] Müller K R, Krauledat M, Dornhege G, et al. Machine learning techniques for brain-computer interfaces. *Biomed Tech*, 2004, 49(1):11-22.
- [148] Shenoy P, Krauledat M, Blankertz B, et al. Towards adaptive classification for BCI. *J Neural Eng*, 2006, 3:R13-R23.
- [149] Vidaurre C, Schloogl A, Cabeza R, et al. A fully on-line adaptive BCI. *IEEE Trans Biomed Eng*, 2006, 53:1214-1219.
- [150] Vidaurre C, Schloogl A, Cabeza R, et al. Adaptive on-line classification for EEG-based brain computer interfaces with AAR parameters and band power estimates. *Biomed Tech*, 2005, 50:350-354.
- [151] Sun S L, Zhang C S. Adaptive feature extraction for EEG signal classification. *Med Biol Eng Comput*, 2006, 44:931-935.
- [152] Yang B H, Yan G Z, Yan R G, et al. Adaptive subject-based feature extraction in brain-computer interfaces using wavelet packet best basis decomposition. *Med Eng Phys*, 2007, 29:48-53.

-
- [153] Buttfeld A, Ferrez P W, Millan J D. Towards a robust BCI: Error potentials and online learning. *IEEE Trans Neural Syst Rehabil Eng*, 2006, 14:164-168.
- [154] Lotte F, Congedo M, Lecuyer A, et al. A review of classification algorithms for EEG-based brain-computer interfaces. *J Neural Eng*, 2007, 4:R1-13.
- [155] Jain A K, Duin R P W, Mao J. Statistical pattern recognition: a review. *IEEE Trans Pattern Anal Mach Intell*, 2000, 22:4-37.
- [156] Friedman J H K. On bias, variance, 0/1-loss, and the curse-of-dimensionality. *Data Min Knowl Discov*, 1997, 1:55-77.
- [157] 边肇祺, 张学工, 等. 模式识别. 北京: 清华大学出版社, 2000.
- [158] Duda R O, Hart P E. *Pattern Classification*. 2nd ed. New York: John Wiley & Sons, 2000.
- [159] Mensh B D, Werfel J, Seung H S. BCI competition 2003 - Data set Ia: Combining gamma-band power with slow cortical potentials to improve single-trial classification of electroencephalographic signals. *IEEE Trans Biomed Eng*, 2004, 51:1052-1056.
- [160] Pineda J A, Allison B Z, Vankov A. The effects of self-movement, observation, and imagination on mu rhythms and readiness potentials (RP's): Toward a brain-computer interface (BCI). *IEEE Trans Neural Syst Rehabil Eng*, 2000, 8:219-222.
- [161] Li Y, Gao X R, Liu H H, et al. Classification of single-trial electroencephalogram during finger movement. *IEEE Trans Biomed Eng*, 2004, 51:1019-1025.
- [162] Dornhege G, Blankertz B, Curio G, et al. Boosting bit rates in noninvasive EEG single-trial classifications by feature combination and multiclass paradigms. *IEEE Trans Biomed Eng*, 2004, 51:993-1002.
- [163] Wei Q G, Meng F, Wang Y J, et al. Feature combination for classifying single-trial ECoG during motor imagery of different sessions. *Prog Nat Sci*, accepted.
- [164] Schalk G, Wolpaw J R, McFarland D J, et al. EEG-based communication: presence of an error potential. *Clin Neurophysiol*, 2000, 111:2138-2144.
- [165] Zhang D, Wang Y, Maye A, et al. A brain-computer interface based on multimodal attention. *3rd Int IEEE EMBS Conf Neural Eng*, 2007, 414-417.
- [166] Wei Q G, Wang Y J, Gao X R, et al. Amplitude and phase coupling measures for feature extraction in an EEG-based brain-computer interface. *J Neural Eng*, 2007, 4:120-129.
- [167] Chapelle O, Schölkopf B, Zien A. *Semi-supervised Learning*. Cambridge: MIT Press, 2006.
- [168] Breiman L. Bagging Predictors. *Machine Learning*, 1996, 24(2):123-140.
- [169] http://ida.first.fraunhofer.de/projects/bci/competition_iii/results/
- [170] Millan J D, Renkens F, Mourino J, et al. Noninvasive brain-actuated control of a mobile robot by human EEG. *IEEE Trans Biomed Eng*, 2004, 51:1026-1033.

-
- [171] Wolpaw J R, McFarland D J. Multichannel EEG-based brain-computer communication. *Electroenceph Clin Neurophysiol*, 1994, 90:444-449.
- [172] Wolpaw J R, McFarland D J, Vaughan T M, et al. The Wadsworth Center brain-computer interface (BCI) research and development program. *IEEE Neural Syst Rehabil Eng*, 2003, 11:204-207.
- [173] Vaughan T M, McFarland D J, Schalk G, et al. The wdsworth BCI research and development program: At home with BCI. *IEEE Trans Neural Syst Rehabil Eng*, 2006, 14:229-233.
- [174] <http://www.biosemi.com/products.htm>
- [175] LabVIEW user manual. National Instruments Corporation. 2003.
- [176] Bai O, Mari Z, Vorbach S, et al. Asymmetric spatiotemporal patterns of event-related desynchronization preceding voluntary sequential finger movements: a high-resolution EEG study. *Clin Neurophysiol*, 2005, 116:1213-1221.
- [177] Gysels E, Renevey P, Celka P. SVM-based recursive feature elimination to compare phase synchronization computed from broadband and narrowband EEG signals in Brain-Computer Interfaces. *Signal Process*, 2005, 85:2178-2189.
- [178] Wang Y J, Hong B, Gao X R, et al. Design of electrode layout for the motor imagery based brain-computer interface. *Electron Lett*, 2007, 43(10):557-558.
- [179] Dechent P, Merboldt K D, Frahm J. Is the human primary motor cortex involved in motor imagery? *Cognitive Brain Res*, 2004, 19:138-144.
- [180] Roland P E, Larsen B, Lassen N A, et al. Supplementary motor area and other cortical areas in organization of voluntary movements in man. *J Neurophysiol*, 1980, 43:118-136.
- [181] Deiber M P, Ibanez V, Honda M, et al. Cerebral Processes Related to Visuomotor Imagery and Generation of Simple Finger Movements Studied with Positron Emission Tomography. *NeuroImage*, 1998, 7:73-85.
- [182] Feige B, Aertsen A, Kristeva-Feige R. Dynamic synchronization between multiple cortical motor areas and muscle activity in phasic voluntary movements. *J Neurophysiol*, 2000, 84:2622-2629.
- [183] Brunner C, Graimann B, Huggins J E, et al. Phase relationships between different subdural electrode recordings in man. *Neurosci Lett*, 2005, 375:69-74.
- [184] Spiegler A, Graimann B, Pfurtscheller G. Phase coupling between different motor areas during tongue-movement imagery. *Neurosci Lett*, 2004, 369:50-54.
- [185] Leocani L, Toro C, Manganotti P, et al. Event-related coherence and event-related desynchronization/synchronization in the 10 Hz and 20 Hz EEG during self-paced movements. *Electroenceph Clin Neurophysiol*, 1997, 104:199-206.

- [186] Steinmetz H, Furst G, Meyer BU. Craniocerebral topography within the international 10-20 system. *Electroenceph Clin Neurophysiol*, 1989, 72:499-506.
- [187] Van Leeuwen W S, Wieneke G, Spoelstra P, et al. Lack of bilateral coherence of mu rhythm. *Electroenceph Clin Neurophysiol*, 1978, 44:140-146.
- [188] Wang Y J, Zhang Z G, Gao X R, et al. Lead selection for SSVEP based brain-computer interface. in *Proc 26th Int IEEE EMBS Conf*, 2004, 4507-4510.
- [189] 程明. 基于脑电信号的脑-计算机接口研究[博士学位论文]. 北京: 清华大学生物医学工程系, 2004.
- [190] Herrmann C S. Human EEG responses to 1-100 Hz flicker: resonance phenomena in visual cortex and their potential correlation to cognitive phenomena. *Exp Brain Res*, 2001, 137:346-353.
- [191] Cornsweet T N. *Visual perception*. New York: Academic Press, 1970.
- [192] Wang Y J, Wang R P, Gao X R, et al. Brain-computer interface based on the high frequency SSVEP. in *Proc 1st Int NIC Conf*, 2005, 37-39.
- [193] Bayliss J D. A flexible brain-computer interface. Ph.D. dissertation. Univ Rochester, Rochester, NY, 2001.
- [194] Jia C, Xu H L, Hong B, et al. A human computer interface using SSVEP-based BCI technology. *12th Int Conf HCI*, 2007, accepted.
- [195] Giabbiconi C M, Dancer C, Zopf R, et al. Selective spatial attention to left or right hand flutter sensation modulates the steady-state somatosensory evoked potential. *Cognitive Brain Res*, 2004, 20:58-66.
- [196] Muller-Putz G R, Scherer R, Neuper C, et al. Steady-state somatosensory evoked potentials: Suitable brain signals for brain-computer interfaces? *IEEE Trans Neural Syst Rehabil Eng*, 2006, 14:30-37.
- [197] Spence C, Pavani F, Driver J. Crossmodal links between vision and touch in covert endogenous spatial attention. *J Exp Psychol Human*, 2000, 26:1298-1319.
- [198] Eimer M, van Velzen J, Driver J. Cross-modal interactions between audition, touch, and vision in endogenous spatial attention: ERP evidence on preparatory states and sensory modulations. *J Cognitive Neurosci*, 2002, 14:254-271.
- [199] Shomstein S, Yantis S. Control of attention shifts between vision and audition in human cortex. *J Neurosci*, 2004, 24:10702-10706.
- [200] Calvert G A. Crossmodal processing in the human brain: Insights from functional neuroimaging studies. *Cereb Cortex*, 2001, 11:1110-1123.
- [201] Salek-Haddadi A, Friston K J, Lemieux L, et al. Studying spontaneous EEG activity with fMRI. *Brain Res Rev*, 2003, 43:110-133.

参考文献

- [202] Horwitz B, Poeppel D. How can EEG/MEG and fMRI/PET data be combined? *Hum Brain Mapp*, 2002, 17:1-3.
- [203] Raij T. Patterns of brain activity during visual imagery of letters. *J Cognitive Neurosci*, 1999, 11:282-299.

致 谢

本论文是在导师高上凯教授的悉心指导下完成的。衷心感谢高上凯教授对本人的精心指导，她的言传身教将使我终生受益。

感谢高小榕教授、洪波副教授、张志广副教授和杨福生教授对论文工作的精心指导与支持。

感谢张丹、魏庆国、吴畏和实验室其他同学的热情帮助与支持。

本论文承蒙中国国家自然科学基金项目（#60318001，#30630022）、北京市自然科学基金重点项目（#30510001）和中德博士生合作研究项目（CINACS）的资助，特此致谢。

声 明

本人郑重声明：所呈交的学位论文，是本人在导师指导下，独立进行研究工作所取得的成果。尽我所知，除文中已经注明引用的内容外，本学位论文的研究成果不包含任何他人享有著作权的内容。对本论文所涉及的研究工作做出贡献的其他个人和集体，均已在文中以明确方式标明。

签 名：_____日 期：_____

个人简历、在学期间发表的学术论文与研究成果

个人简历

1979年7月9日出生于福建省长汀县，1997年9月考入清华大学电机系生物医学工程专业，2001年7月本科毕业并获得工学学士学位，同年9月免试进入清华大学生物医学工程系攻读工学硕士学位，2004年9月免试进入清华大学生物医学工程系攻读工学博士学位（提前攻博）至今。

发表的学术论文

- [1] Wang Y J, Zhang Z G, Li Y, et al. BCI Competition 2003 Dataset IV: an algorithm based on CSSD and FDA for classifying single-trial EEG. *IEEE Trans Biomed Eng*, 2004, 51(6):1081-1086. (SCI 收录, 检索号: 822YX) (EI 收录, 检索号: 04238198015)
- [2] Wang Y J, Wang R P, Hong B, et al. A practical VEP-based brain-computer interface. *IEEE Trans Neural Syst Rehabil Eng*, 2006, 14(2):234-239. (SCI 收录, 检索号: 054QW) (EI 收录, 检索号: 063210048048)
- [3] Wang Y J, Hong B, Gao X R, Gao S K. Design of electrode layout for the motor imagery based brain-computer interface. *Electron Lett*, 2007, 43(10): 557-558. (SCI 源刊)
- [4] Wang Y J, Zhang Z G, Li Y, Gao X R. An algorithm for classifying single-trial EEG during self-paced finger movement. in *Proc CBME Conf*, 2003, 489-490. (获 2003 年中国生物医学电子学年会青年论文竞赛 一等奖)
- [5] Wang Y J, Zhang Z G, Gao X R, Gao S K, Lead selection for SSVEP based brain-computer interface. in *Proc 26th Int IEEE EMBS Conf*, 2004, 4507-4510. (EI 收录, 检索号: 05028779694)
- [6] Wang Y J, Wang R P, Gao X R, Gao S K. Brain-computer interface based on the high frequency SSVEP. in *Proc 1st Int NIC Conf*, 2005, 37-39. (EI 收录, 检索号: 06269961748)

- [7] Wang Y J, Gao X R, Gao S K, Common spatial pattern method for channel selection in motor imagery based brain-computer interface. in Proc 27th Int IEEE EMBS Conf, 2005, 5392-5395. (EI 收录, 检索号: 070710425518)
- [8] Wang Y J, Hong B, Gao X R, Gao S K. Phase synchrony measurement in motor cortex for classifying single-trial EEG during motor imagery. in Proc 28th Int IEEE EMBS Conf, 2006, 75-78. (EI 收录, 检索号: 071510533881)
- [9] Wang Y J, Hong B, Gao X R, Gao S K. Integrating power and phase features for multi-class motor imagery based brain-computer interface. in Proc CBME Conf, 2007, 1522-1525.
- [10] Wang Y J, Hong B, Gao X R, Gao S K. Implementation of a brain-computer interface based on three states of motor imagery. 29th Int IEEE EMBS Conf, 2007, (已录用, EI 收录)
- [11] Wei Q G, Wang Y J, Gao X R, Gao S K. Amplitude and phase coupling measures for feature extraction in an EEG-based brain-computer interface. J Neural Eng, 2007, 4:120-129. (SCI 收录)(EI 收录, 检索号: 071710566757)
- [12] Wei Q G, Meng F, Wang Y J, et al. Feature combination for classifying single-trial ECoG during motor imagery of different sessions. Prog Nat Sci, (已录用, SCI 源刊)
- [13] Zhang D, Wang Y J, Gao X R, Hong B, Gao S K. An algorithm for idle state detection in motor imagery based brain-computer interface. Computational Intelligence and Neuroscience, (已录用)
- [14] 马赞, 王毅军, 高小榕, 高上凯. 基于脑-机接口技术的虚拟现实康复训练平台. 中国生物医学工程学报, (已录用, EI 源刊)
- [15] 魏庆国, 高小榕, 王毅军, 高上凯. 基于多通道线性描述符的脑-计算机接口分类算法的研究. 中国生物医学工程学报, (已录用, EI 源刊)
- [16] Choi S H, Lee M, Wang Y J, Hong B. Estimation of optimal location of EEG reference electrode for motor imagery based BCI using fMRI. in Proc 28th Int IEEE EMBS Conf, 2006, 1193-1196.(EI 收录, 检索号: 071510534163)

- [17] Zhang D, Wang Y J, Maye A, et al. A brain-computer interface based on multimodal attention. in Proc 3rd Int IEEE EMBS Conf Neural Eng, 2007, 414-417. (EI 收录)

研究成果

- [1] 第二届国际脑-机接口竞赛 (BCI Competition 2003) 数据集 IV 第一名 (第一完成人)
- [2] 第三届国际脑-机接口竞赛 (BCI Competition III) 数据集 I 第一名 (第三完成人)
- [3] 第三届国际脑-机接口竞赛 (BCI Competition III) 数据集 IVa 第一名 (第一完成人)
- [4] 第三届国际脑-机接口竞赛 (BCI Competition III) 数据集 IVc 第一名 (第二完成人)
- [5] 2003 年中国生物医学电子学学术年会青年论文竞赛 一等奖
- [6] 清华大学第 23 届“挑战杯”科技竞赛 二等奖
- [7] 清华大学医学院第三届博士生论坛 优秀报告论文