

申请上海交通大学硕士学位论文

基于前额眼电信号的警觉度估计模型研究

学 校： 上海交通大学

院 系： 电子信息与电气工程学院

班 级： B0903393

学 号： 1090339060

硕 士 生： 蔡浩宇

专 业： 计算机应用技术

导 师： 吕宝粮（教授）

上海交通大学电子信息与电气工程学院

2012 年 11 月

**A Dissertation Submitted to Shanghai Jiao Tong University for the
Degree of Master**

**Research of Vigilance Estimation Model Based on
Forehead Electrooculogram**

Author: Cai Haoyu

Specialty: Computer Science & Engineering

Advisor: Prof. Lu Baoliang

School of Electronics and Electric Engineering

Shanghai Jiao Tong University

Shanghai, P.R.China

November 29, 2012

附件四

上海交通大学 学位论文原创性声明

本人郑重声明：所呈交的学位论文，是本人在导师的指导下，独立进行研究工作所取得的成果。除文中已经注明引用的内容外，本论文不包含任何其他个人或集体已经发表或撰写过的作品成果。对本文的研究做出重要贡献的个人和集体，均已在文中以明确方式标明。本人完全意识到本声明的法律结果由本人承担。

学位论文作者签名：蔡诺宇

日期：2013 年 1 月 7 日

附件五

上海交通大学 学位论文版权使用授权书

本学位论文作者完全了解学校有关保留、使用学位论文的规定，同意学校保留并向国家有关部门或机构送交论文的复印件和电子版，允许论文被查阅和借阅。本人授权上海交通大学可以将本学位论文的全部或部分内容编入有关数据库进行检索，可以采用影印、缩印或扫描等复制手段保存和汇编本学位论文。

保密 ，在 ___ 年解密后适用本授权书。

本学位论文属于

不保密 。

(请在以上方框内打“√”)

学位论文作者签名: 蔡浩宇

日期: 2013年1月7日

指导教师签名: 吕宝根

日期: 2013年1月7日

基于前额眼电信号的警觉度估计模型研究

摘要

警觉度通常被定义为操作者在执行某项任务时，对外界刺激长时间保持注意与警惕的灵敏程度。警觉度是一项与人的疲劳与清醒状态紧密相关的生理指标。通过观测人长时间进行操作任务时对外界变化的反应时间，以及应对方式的准确性，可以用来评估人的警觉程度。

当人感到疲劳或者困倦时，警觉度会明显下降。这对于汽车或者高铁司机都是极其危险的，会使车祸的发生概率大大上升。这种性质的事故都被归结为疲劳驾驶，疲劳驾驶作为交通事故的一个重要诱因，正受到广泛的关注。

传统基于生理电信号的警觉度分析方法，一般会用到脑电、眼电等生理特征。将电极直接接触人体可以获得较之视频信号更可靠的生理信号，但同时也会因为采集装置的部署在实际应用中产生诸多不便与妨碍。

本研究正是针对传统基于眼电的警觉度分析的不足之处，提出将采集电极放置于人的前额处，利用前额的生理电信号，代替传统眼电信号进行警觉度分析。本研究提出的主要思想是，使用独立成分分析的方法，从前额信号中分离出独立的眼电分量，利用眨眼检测算法以及基于 SVM 的肌电、眼电分类方法，从独立信号中抽取出独立水平眼电与独立垂直眼电信号。最后将独立的水平与垂直眼电信号作为输入，使用基于眼电的警觉度分析方法，进行警觉度的估计。

本研究的主要创新有两点：一是提出并证明了从前额眼电信号中可

以抽取出水平与垂直眼电信号这一假设。二是给出了一整套从前额眼电信号分离水平眼电和垂直眼电信号的完整方法，包括如何选择电极摆放策略，如何进行信号的独立成分分析、特征提取与分类。

本研究的得到的结论是，在前额电信号中，完全可以分离出独立的水平与垂直眼电信号，并可以将之用于警觉度的估计。基于本研究的成果，可以大大提升基于眼电的警觉度估计系统的实用性与便携性，使之真正成为可以提供给汽车、高铁司机等实际使用的警觉度检测解决方案。

关键词：眼电，前额，警觉度，信号处理

Research of Vigilance Estimation Model Based on Forehead Electrooculogram

ABSTRACT

Vigilance is usually defined as the sensitivity or ability of people to maintain attention and alertness to external stimuli, when they perform some tasks during a long time. Vigilance is a physiological indicator closely related to the waking or fatigue state. People's reaction time to external changes or responding accuracy for a long period can be used in evaluation of the degree of people's alertness levels.

When people feel fatigue or sleepiness, vigilance decreased significantly. For car and high-speed railway drivers, decreasing vigilance is extremely dangerous and would make increasing the probability of occurrence of traffic accident greatly. Incidents caused by lower vigilance are considered as one kind of fatigue driving. Drivers' fatigue as an important incentive for traffic accidents has received widespread attention.

Traditional vigilance analysis methods based on physiological signals usually use EEG and EOG physiological characteristics. The electrodes contacted with the human body directly can offer more reliable signals compared to video signals. On the other hand, however, the electrodes for acquiring EEG and EOG signals may lead inconvenience and hinder the users in practical applications.

In this study, to overcome the shortcomings of traditional electrode

placement for acquiring EOG signal, we place the electrodes on the forehead and use forehead EOG signals to analyze vigilance, instead of the traditional EOG signals. The main idea of this study is to use independent component analysis to separate independent EOG components from forehead EOG signals. Blink detection algorithms and SVM-based classification method for removing EMG and EOG artifacts are used for select independent HEO and VEO signals from extracted independent signals. In the end, independent horizontal and vertical EOG signals are used as input signals for our vigilance estimation system based on EOG signals.

This thesis has two main contributions to EOG-based vigilance estimation. The first one is that we put forward and prove the assumption that the horizontal and vertical EOG signals can be extracted from the forehead EOG signals. The second one is that we propose a methodology for using forehead EOG signals for vigilance estimation, including how to select the electrode placement strategies, how to separate independent component analysis, and how to perform feature extraction and classification.

The conclusion of this study is that independent HEO and VEO signals can be definitely separated from the forehead EOG signals, and can be used for vigilance estimation. Based on the results of this study, it is possible to greatly enhance the practicality of EOG based vigilance estimation system, and make it truly become part of the vigilance detection solutions used by the drivers of cars and high-speed railway.

Keywords: EOG, Forehead EOG, vigilance, vigilance estimation, independent component analysis.

目 录

基于前额眼电信号的警觉度估计模型研究	1
基于前额眼电信号的警觉度估计模型研究	I
摘 要	I
ABSTRACT	III
第一章 绪论	8
1.1 研究背景及意义	8
1.2 国内外研究现状	9
1.2.1 基于眼部特征的疲劳检测	9
1.2.2 基于视频技术的眼部特征检测	11
1.2.3 疲劳与 EOG 的研究现状	11
1.3 基于生理信号的警觉度分析概述	14
1.3.1 脑电信号与警觉度	14
1.3.2 眼电信号与警觉度	16
1.4 研究意义	20
1.4.1 研究的创新性	20
1.4.2 研究的应用价值	21
1.5 主要研究内容	24
1.6 毕业论文结构	25
1.7 本章小结	25
第二章 基于眼电信号的警觉度分析	27
2.1 基于 EOG 警觉度分析一般过程	27
2.2 眼电信号的特征提取	28
2.2.1 慢速眼动特征提取	28
2.2.2 快速眼动特征提取	29
2.2.3 眨眼特征提取	30
2.3 基于线性动力系统的降噪	32
2.4 特征整合	32
2.5 本章小结	33
第三章 基于前额信号分离眼电信号的可行性分析与实验设计	34

3.1 利用前额电信号的相关研究	34
3.2 前额电信号的生理特性	36
3.3 基于前额电信号分离眼电信号的假设	36
3.4 分离眼电信号的实验设计目的	37
3.5 实验设置及流程	38
3.5.1 实验设备	38
3.5.2 实验流程	45
3.6 前额电极摆放策略	46
3.7 本章小结	49
第四章 基于前额电信号的眼电信号分离	50
4.1 基于 ICA 的前额电信号分离	50
4.1.1 盲信号分离	50
4.1.2 独立成分分析的原理	50
4.1.3 ICA 算法选择	52
4.1.4 基于 FastICA 分离前额电信号	53
4.2 验证前额电信号中存在独立眼电信号	56
4.3 从前额电信号中分离眼电信号的一般过程	59
4.4 区分 HEO 与 VEO 信号	59
4.5 SVM 选择 HEO 与 VEO 信号	61
4.5.1 Welch 算法计算功率谱密度	62
4.5.2 AR 模型计算自相关系数	63
4.5.3 SVM 分类 EMG 与 EOG	65
4.6 EOG 抽取算法性能评估	66
4.7 本章小结	67
第五章 基于前额眼电信号的警觉度实验系统及优化	68
5.1 图片实验	68
5.2 实时跟踪实验	69
5.3 本章小结	71
第六章 全文总结	72
6.1 本论文的主要结论与创新点	72
6.2 未来工作展望	73
参 考 文 献	74
致 谢	79
攻读硕士学位期间已发表或录用的论文	81

第一章 绪论

1.1 研究背景及意义

警觉度(vigilance)通常被定义为操作者在执行某种任务时,对外界刺激长时间保持注意与警惕的灵敏程度。警觉度是一项与人的疲劳与清醒状态紧密相关的生理指标。通过观测人长时间进行操作任务时对外界变化的反应时间,以及应对方式的准确性,可以用来评估人的警觉程度。

人们对警觉度的研究起始于 20 世纪 50 年代,最初的研究是从睡眠问题入手,主要研究人在清醒和睡眠两个不同状态下的区别。之后的研究表明,人从清醒到睡眠的过程是由若干个阶段构成的,研究的重点就变为研究分析这些阶段分别有哪些特征。随后随着研究范围的扩展,人们把传统的从清醒到入睡之间的状态进一步细分,从而明确地提出了警觉度的概念^[57]。

许多人机交互系统都需要操作人员保持一定的警觉度。对于一些特殊的工作,如高速铁路的机车司机,高速公路上的长途客车驾驶员,以及进行各种精密操作的工作人员,更要求保持很高的警觉度。当人感到疲劳或者困倦时,警觉度会明显地下降,特别对于高铁司机而言,这是非常危险的。此时人的反应速度变慢,对瞬时变化的路况以及指挥信号无法做出及时的应对,使得事故的发生概率大大上升。这种性质的事故都被归结为疲劳驾驶,疲劳驾驶作为交通事故的一个重要诱因,正受到广泛的关注。

就机动车驾驶而言,据不完全统计,全世界每年死于交通事故的人数约为 60 万,因车祸受伤的人数平均每年约有 1000 万^[1]。在美国的恶性汽车事故中,57%的事故与驾驶员疲劳有关,疲劳驾驶已成为事故发生的主要原因;英国交通研究实验室认为:疲劳驾驶导致的道路交通事故占全部交通事故的 10%^[2];法国国家事故报告表明,因疲劳驾驶而发生车祸的占人身伤亡事故 14.9%,占死亡事故的 20.6%^[3]。1999 年我国发生道路交通事故 412860 起,致伤 286080 人,死亡 83529 人,造成直接经济损失 21.24 亿元^[4]。

在铁路交通中,疲劳驾驶问题同样是重大安全隐患问题。我国铁路 1978 年 12 月至 1980 年 10 月间,机车乘务员因瞌睡造成的行车重大事故占总事故的 42%,共有

34 起。根据郑州铁路局对全路 1991-2000 年间发生的 69 件因机车乘务员责任而造成事故的统计中,因疲倦瞌睡造成的事故前五年有 29%,而后五年提升到 57%。2007 年,我国铁路相继发生的太原局“7.4”和兰州局“7.23”列车重大事故,其主要原因都是与机车司机在值乘过程中精神不振、瞌睡打盹有关。最新研究表明,高速列车驾驶员长时间作业后,脑力疲劳、心理疲劳较眼疲劳及体力疲劳更为明显^[5],即使驾驶员的疲劳从外表不易被观察到。因此,及时检测与发现高铁驾驶员疲劳状态对于保障高速铁路安全运行、保护乘客生命财产安全至关重要。鉴于此,在当前我国高速铁路迅速发展的阶段,如何对人的警觉度进行估计和预测是辅助安全驾驶领域的一个重要课题^[6]。

疲劳状态的研究在很大程度上就是要分析出哪些因素与人的疲劳程度有关,哪些因素直接反映了人的疲劳程度,从而根据这些相关因素来判断人的疲劳状态。在疲劳研究中,眨眼频率、皮肤阻抗、体温以及血压等生理信号都曾被用来估计警觉度^{[7][8]}。对比各种基于视频、红外、脑电 (EEG) 以及各种生理体征的警觉度检测算法,眼电 (EOG) 具有鲁棒性高,受干扰性小等特点。但是传统的眼电信号采集方法,将电极放置于人的眼睛周围,部署繁琐同时会对使用者的视野带来不利的干扰。基于前额眼电信号的警觉度分析方法,将眼电信号从前额的信号中分离出用于警觉度分析,将为基于眼电的警觉度分析带来易于部署,不干扰使用者视线等有点,更好的提升了基于眼电的警觉度分析系统的实用性与可行性。

1.2 国内外研究现状

1.2.1 基于眼部特征的疲劳检测

多方研究表明,人体在进入疲劳状态时,眼部的行为模式会出现一定程度的改变,这种变化可以作为判断疲劳状态的依据。目前国际上已有一些商业化的疲劳驾驶检测和预警装置,主要采用基于 PERCLOS 方法的红外线瞳孔定位,或者基于更加复杂的视频采集技术。它们都是借助计算机视觉的手段,通过测量驾驶员眼睑的运动特征,来发现驾驶员是否处于疲劳状态的。

PERCLOS 方法最早是于 1998 年由卡耐基梅隆 (Carnegie Mellon) 大学的驾驶研究中心研发提出的^[9],其核心思想是测定眼睛闭合时间占特定时间的百分比。他们采用的系统通过两个摄像头,利用视网膜对不同波长红外光的反射能力差异来定位视网膜,并以此分析眼睛的大小和位置,来判断眼睛的睁闭,由此可计算眼睛闭合度超过

80%的时间与眨眼总时间的比率。2001年，美国纽约 Rensselaer Polytechnic 学院的 Qiang Ji 对上述系统进行了改进，仅用一个摄像机对眼睛进行定位^[10]。同年，卡耐基梅隆大学的机器人研究所也开发出了名为 Copilot 的车载疲劳检测系统^[11]，在利用 PERCLOS 方法判断疲劳的同时，克服了驾驶员佩戴眼镜时的反光问题。目前，PERCLOS 方法已经被美国联邦公路管理局被认定是一种可靠有效的疲劳检测法，并在车载实时疲劳检测系统中成功得到了商业运用^[12]。由于该方法有效且容易实现，目前国际上自行研发并商业化的疲劳驾驶检测装置，也大量采用 PERCLOS 这一方法来判断疲劳状态，如美国 Attention Technologies 公司推出的 Driver Fatigue Monitor (DD850)，以及中国南京远驱科技有限公司推出的 gogo850 疲劳驾驶预警系统。

2003年，澳大利亚国立大学与沃尔沃公司合作的 Seeing Machines 公司研发了一套 FaceLAB 系统^[13]。该系统采用的不是传统的瞳孔红外线反射技术，而是用一对立体摄像机来测量数据。所以能够检测到使用者面部的各种特征，包括驾驶员头部姿势、眼睑运动、视线方向、瞳孔直径等，也可作为单独的眼动仪来使用。该系统不仅支持 PERCLOS 方法来检测疲劳，还可以分析其他眼睑运动特征，以作为疲劳检测标准。它适用于各种脸型，眼睛和多数眼镜，并可以在阳光下或暗房中工作，受试者可以距离摄像机几十公分到几米远。目前这套系统已发展至第五代，已经成为一套成熟的商业化产品（如图 1-1）。



图 1-1 第五代 FaceLAB 系统

2004年,欧盟启动了 AWAKE 计划^[14],旨在开发和制定一套驾驶员疲劳检测和预警系统的标准。它结合了对驾驶员状态和驾驶表现的测量,包括驾驶员眼睑的运动、对方向盘的握力、对车道的把握、以及对刹车和油门的控制。这些参数都将输入至驾驶预警系统中以确定是否需要向驾驶员发出警报。AWAKE 计划对疲劳驾驶预警系统的综合设计提供了比较全面的指导性意见。

1.2.2 基于视频技术的眼部特征检测

目前,国际上提出的对于疲劳驾驶的检测方法中,包括 PERCLOS 在内,通过视频技术采集眼睑运动特征的占了比较大比重。此类方法最大的优点在于对使用者来说,无需接触人体,没有使用上的麻烦,容易推广使用。而对于基于脑电、眼电等生理参数的方法,虽然存在一定数量的研究,但是基本上没有像 PERCLOS 方法一样形成实用性的系统。这有两个原因,第一,以脑电、眼电为代表的生理信号虽然能够准确地反应人体警觉度,但是实际提取存在着较大的局限性。第二,其他生理参数,如心电、血压、脉搏等,虽然提取方便,但是与警觉度的关系却不如脑电一般直接,甚至还不如使用眼部特征的方法效果稳定。

但是另一方面,基于计算机视觉的面部特征提取方法,以及道路特征提取方法,都会受到外界因素的限制而影响其效果,虽然前述的各种研究正在不断地提高算法的鲁棒性,但是亮度、角度以及其他的一些不可控因素仍然在一定程度上限制着算法的性能;另外,基于计算机视觉的面部特征提取方法非常容易接受人为的伪造信号,并且被其所欺骗;而道路特征方法则对非标准型道路无能为力。

另一方面,从根本上来说,基于视频技术的眼部特征检测,与基于眼电的眼部特征检测相比,其目的是一致的。但是,通过眼电可以方便地检测到许多视频技术无法或者很难检测到的特征信息,如眼睑的速度,及眼球的运动等。要用视频技术来检测这些特征,必须使用昂贵的眼动仪级别的设备(一部眼动仪的价格为数万至数十万)。而使用的特征越是单一,疲劳检测的结果也越是不可靠,这不仅是欧盟 AWAKE 计划中所提出的指导性建议,也是大部分研究者的共识。因此,发展基于以脑电和眼电为代表的生理信号特征的警觉度估计方法是现在以及将来非常重要的一个课题。

1.2.3 疲劳与 EOG 的研究现状

目前,基于视频技术的疲劳检测研究的主要目的在于提升对眼球定位的准确性,

以及提高在不同照度、不同角度状态下,算法的鲁棒程度。而对于基于 EOG 研究来说,一方面,我们要提升对于 EOG 特征提取的准确性和鲁棒性,另一方面,我们要找出与疲劳度关系最为密切的 EOG 特征。下面列举一些关于 EOG 特征提取,以及 EOG 特征与疲劳度关系的国内外现存研究。

(1) 哈佛医学院的 Mercedes Atienza 等人于 2004 年进行了关于眼睑运动与慢速眼动关系的研究,发现了眼睑运动的急剧减少与睡眠状态的开始有密切联系^[15]。当眼睑运动减少时,慢速眼动随之增加,标志着睡眠第一阶段的开始。此研究表明眼睑运动的频度与慢速眼动存在着较大联系,根据眼睑运动的频度,可以比较准确地检测 2.5s 的时间段中是否有慢速眼动出现。眼睑运动的频度也可以作为疲劳检测的检测标准之一。

(2) 日本国家职业安全与健康研究所的 Kosuke Kaida 等人于 2007 年进行了一项疲劳检测相关研究,对 Karolinska 睡眠量表(KSS)、长眨眼、EEG 的 alpha 波、以及心率标准差(SDNN)这几个特征,以 4 分钟的时间窗,与任务实验的错误率进行了关系比较,结果表示长眨眼次数与疲劳度关系不大,而脑电 alpha 波功率密度、SDNN、以及 KSS 主观判断与疲劳度的关系比较大^[16]。

(3) 英国 QinetiQ 公司人类科学研究中心的 Nicola Wright 等人于 2004 年进行了一项关于飞行员疲劳度的研究^[17]。实验记录了飞行员在飞行过程中的 EEG、EOG、以及手腕活动变化。研究的目的是使用实用性更强的手腕活动来代替 EEG 和 EOG 检测疲劳度。研究指出 EEG 和 EOG 能够精确地对疲劳度变化产生反应。

此外,研究还指出在清醒状态下,EOG 会出现眼球跳动,而当警觉度下降时,眼球跳动会减少,而慢速眼动会增加,且随着疲劳度的下降眼球运动的低频成分会越来越增加。

(4) 韩国首尔国立大学的 Youn Sung Kim 等人于 2009 年进行了基于生体信号的疲劳度检测系统的研究^[18]。该系统被设计成头盔的模式,面向军队使用,它同时检测 EEG 的 alpha 波、EOG 的眨眼特征(6 种不同特征),以及 ECG 的心率变异度。他们的研究表明,EEG 的 alpha 波的效果并不好,而眨眼特征中的眼睑速度峰值效果较好,另外心电图中的低频/高频比(LF/HF)效果也较好。

虽然此研究是面向实际使用,但是仍然没有解决数据实时处理和头发影响电极检测的问题。

(5) 马来西亚 Kebangsaan 大学的 Thum Chia Chieh 等人进行的研究,使用了快速眼动来对疲劳度进行分类^[19]。该方法将水平眼电和垂直眼电分量相加,目的是得到速度的矢量和,并与设定的速度阈值相比较,以判断快速眼动。在整个信号上采取时

间窗的形式,对每个窗口计算快速眼动出现的次数,并且据此来判断测试者是否处于瞌睡状态。该方法使用的算法非常简单,但确实完成了整套系统的实物构造,其分类精度宣称可达到 90%。

(6) 法国 Toulouse 大学的 Bruno Jammes 等人进行的关于从眼电信号中侦测眨眼成分的研究^[20]。使用了两个阈值:眼睑闭合速度阈值与睁开速度阈值,来定位眨眼波形的位置,并根据波形的形态特征,计算此波形中各个眨眼特征参数,其眨眼侦测的准确率宣称可达到 96%。该研究虽然提到了检测出来的眨眼特征可用于疲劳度计算,但是并未有对此进行详细的研究。

本研究也基于此方法并稍作修改,用以在 EOG 中提取眨眼特征。

(7) 意大利 Bologna 大学的 Elisa Magosso 等人于 2006 年发表的研究,其中详细地介绍了一种基于离散小波变换,从 EOG 中侦测慢速眼动的方法^[21]。其目的是实现睡眠阶段的自动分类。虽然此研究并不是用来检测疲劳度的,但是其很好地证明了所提出的方法可以准确地识别慢速眼动,以及慢速眼动在睡眠分类上的重要价值。作者于此后所发布的一系列文章,也皆围绕着这一方法,展开到不同的临床运用上^[22-24]。

本研究也将此方法作为侦测慢速眼动特征的方法之一。

(8) 日本学者 Kazushi Hyoki 等人早于 1998 年进行了关于 EOG 与 EEG 作为疲劳度特征的研究^[25]。该研究分析了 EOG 的快速眼动特征与 EEG 的 alpha 波、beta 波的关系,指出在疲劳实验中,快速眼动的出现与 EEG 的 alpha 波、beta 波有正相关的关系。该研究同时提出了以 15 度/s 作为快速眼动的速度阈值,并以此在 EOG 中提取快速眼动。

(9) 澳大利亚的 S. Hanke 等人于 2009 年发表了 EOG 与疲劳度相关研究^[26]。该研究对 EOG 的速度、幅值、低频/高频比(LF/HF)这三个特征进行了测试,其结果显示速度和幅值与警觉度的关系并不明显,相对而言,LF/HF 是一个最能反映警觉度的特征。该研究并没有将 EOG 特征归类为慢速眼动、快速眼动、眨眼等,但实际上 LF/HF 是一个用来表现慢速眼动所占比例的特征。

在本研究中,同样对 LF/HF 这个特征进行了测试,结果表明它是一个能够反映警觉度的有用特征。

(10) 日本大阪理工学院的 Mieko Ohsuga 等人于 2007 年发表了关于眨眼与驾驶员疲劳度关系的研究^[27]。该研究同样以两个阈值侦测眨眼,分别是高电压幅值与低电压幅值,前者用以侦测可能的眨眼候选,后者用以确定眨眼的起始和终止位置,在所有的眨眼候选中,持续时间过长的将被剔除。之后,该研究采用了 K-means 方法对眨眼特征参数进行聚类,并指出其中时间段、幅值大的眨眼属于清醒状态,而时间

长、幅值低的眨眼属于疲劳状态。以此可判断驾驶员处于何种状态。

该研究的缺陷在于对每个驾驶员的数据采取了单独的聚类,因此无法解决不同个体中存在的比较大的个体差异问题。

(11) 中国北京航空航天大学胡淑燕与清华大学的郑钢铁于 2008 年发表了与欧盟的 SENSATION 计划的合作研究成果。该研究利用 EOG 中提取出的 11 种眼睑特征来作为 SVM 分类器的输入,以此将驾驶员的疲劳度分为三种不同状态。研究指出他们的分类精度可达 80% 以上,并且在重度疲劳时,分类精度可达 100%。该研究的缺点是数据统计量不足,并且没有使用支持在线化的分析手段。

1.3 基于生理信号的警觉度分析概述

1.3.1 脑电信号与警觉度

脑电图 (EEG) 记录的是脑中大量神经元进行同步放电时,在头表皮上所反映出的微弱的电位差。由于大脑皮层有序的多层结构中锥体细胞的轴突径向排列,树突在外层呈切向分布,这样有序的点偶极子放电能够克服颅骨的屏蔽,可在头皮上记录到 0.5~40 Hz 较大幅度 ($1\sim 100\mu\text{V}$) 的 EEG 信号。




图 1-2 脑电信号产生原理以及波形示意图

脑细胞无时无刻不在进行自发性、节律性、综合性的电活动，将这种电活动的电位作为纵轴，时间特征作为横轴，记录下来的电位与时间相互关系的平面图即为脑电图。通常将这种大脑皮层内部持续的节律性电位变化称为自发脑电（Spontaneous EEG）。

此外，脑电还可以描述为脑地形图的形式，其反映的是一个特定时刻或时间内脑电或脑电能量在整个头皮上的分布情况。图 1-3 为反映脑电能量分布的脑地形图。




图 1-3 反映脑电能量分布的脑地形图

脑电信号的频率（或周期）、波幅、相位构成脑电信号的基本特征^[28]。基于这些特征的强度与相对变化，可以反映出大脑所处的状态，比如缺血、缺氧等。医学、神经科学和认知科学的研究结果表明，人们对环境的警觉度涉及很多大脑的活动，因此使用 EEG 来估计人的疲劳、睡眠、清醒、注意力等警觉度状态是非常合适的。

脑电信号的分析，一般用到从 EEG 中提取出的三个分量，分别是时域、频域和空间分布。

其中时域信息通常是由一些事件相关电位(event related potential, ERP)组成的。但是由于脑电信号极其微弱，受环境影响明显，通常含有大量的背景噪声，因此时域信息通常很难直接使用。与之相比，频域信息作为一种更为宏观的表现，使用功率谱分析的方法，更容易反映出不同频率、频带与特定脑活动的关联。在基于 EEG 的警觉度研究中,最常用的有 5 个频带,分别是 δ (0.5~4 Hz)、 θ (4~8 Hz)、 α (8~13 Hz)、 β (13~25 Hz) 和 γ (> 25 Hz)。空间信息所表现的是 EEG 信号在头皮表面的空间分布情况，可以反映出不同脑区的活动状态。

在睡眠试验中，被试从清醒状态到睡眠状态的脑能量密度分布图，如图 1-4 所示。

将被试的警觉度，划分为，清醒、轻度疲劳、瞌睡和睡眠 4 种状态，可以看出其中 δ 、 α 以及 γ 节律能量密度分布在不同状态下，有明显的差异。

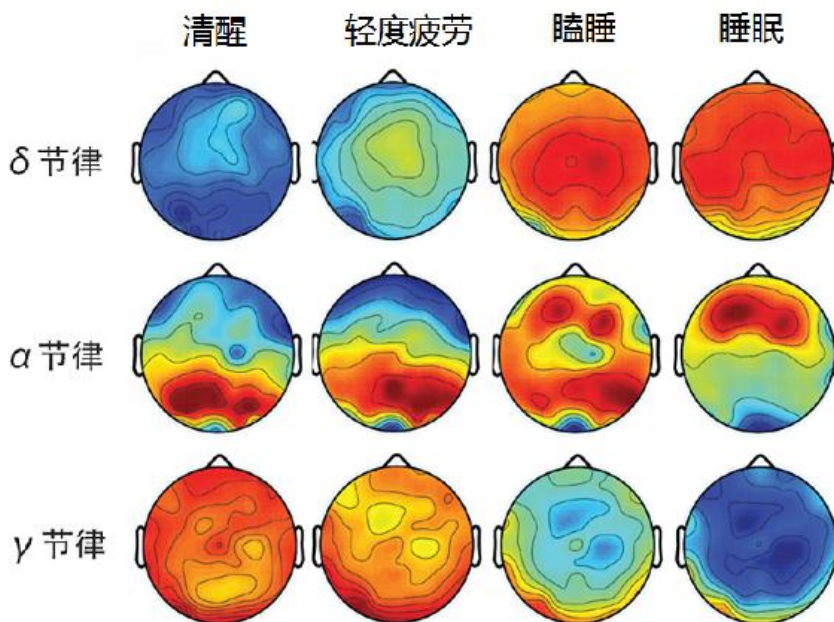


图 1-4 δ 、 α 、 γ 节律在清醒-睡眠转换过程中能量密度的区域分布^[29]

随着被试从清醒转入睡眠状态， δ 节律的能量不断增强， γ 节律的能量则逐渐减弱，并且空间分布上向后脑转移，而 α 节律的能量则在空间分布上，从后脑向前脑转移。目前有许多研究表明，伴随着警觉度的下降，脑电信号中的低频区域能量会增加，而高频段能量会减弱，并且当警觉度很高时，一些节律，比如 α 节律的成分也会削弱。基于目前的研究情况，可以肯定，EEG 与警觉度之间是有着密切的关联的。

1.3.2 眼电信号与警觉度

眼电图 (EOG) 通常记录的是视网膜色素上皮和光感受器细胞之间存在的视网膜静电位。根据在明、暗适应条件下视网膜静止电位的变化，可反映光感受器细胞的光化学反应和视网膜外层的功能状况。EOG 也可用于测定眼球位置及眼球运动的生理变化，即记录的是眼动肌所产生的生理电位变化。为了检测眼球的水平运动，把一对电极分别置于眼内角和眼外角，检测垂直运动时则置于眼睑上下，记录两者的电位差。

眼球向着前方时无电位差，但旋转时角膜侧电极则比另一电极偏正。把这一电位差放大，即可作为反应眼球运动的重要指标。

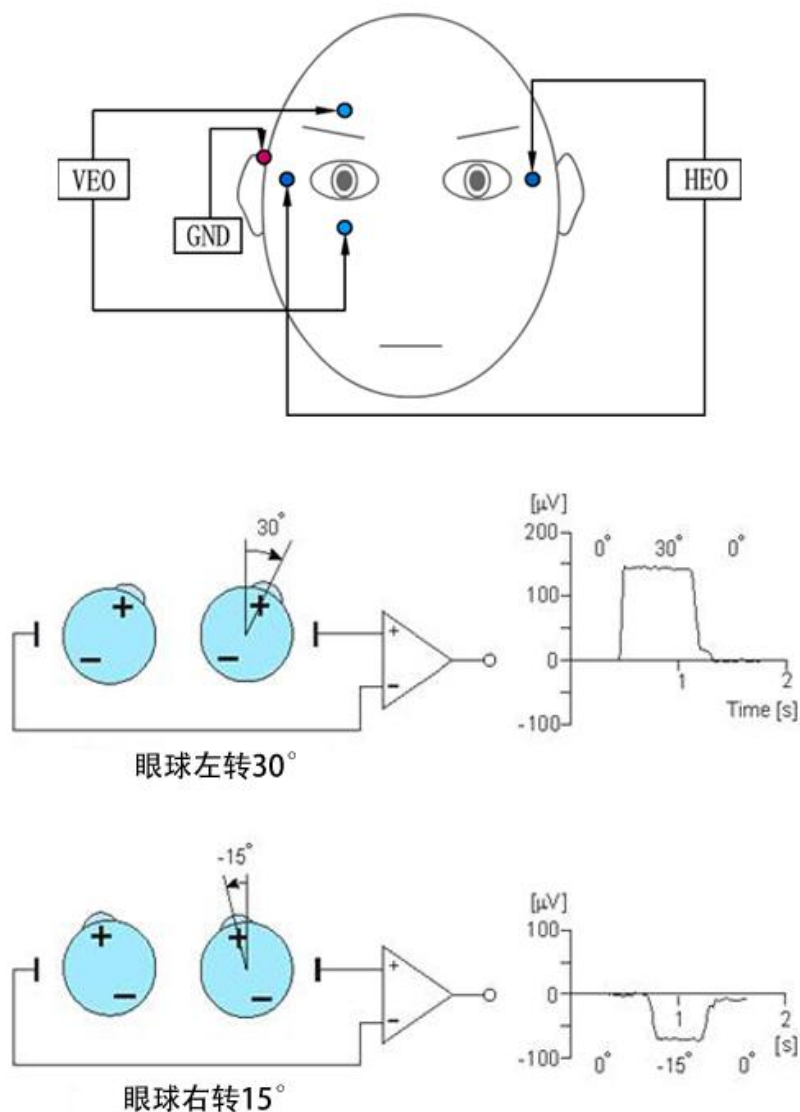


图 1-5 眼电信号产生原理以及波形示意图

前文中提到了在睡眠实验中，EEG 可以用来反应被试从清醒到睡眠的状态。同样，EOG 也是划分睡眠阶段的重要指标^[30]。

在哺乳动物和鸟类中，睡眠分为两大类：快速眼动睡眠（REM）和非快速眼动睡眠（NREM），每一种类型都有一组不同的相关生理、神经和心理特征。美国睡眠

睡眠的阶段最早是由 Alfred Lee Loomis 与其合作者在 1937 年定义, Loomis 将睡眠中不同的 EEG 分成五个不同的等级, 从 A 到 E, 分别表示清醒状态到深度睡眠状态。在 1953 年, 快速眼动睡眠 (REM Sleep) 被发现, 成为睡眠中的一个显著特征, 因此 William Dement 和 Nathaniel Kleitman 将睡眠重新划分成了四个非 REM 睡眠阶段, 和一个 REM 睡眠阶段。而详细的睡眠阶段划分准则, 则于 1968 年, 由 Allan Rechtschaffen 和 Anthony Kales 发布在“R&K 睡眠评分手册”上, 这也成为了之后一直沿用至现在的 RK 准则。在 RK 准则中, 非 REM 睡眠被细分成四个阶段, 其中阶段 3 和 4 属于俗称的“慢波睡眠”阶段(因为频率低的 δ 节律在 EEG 中占了主导), 在阶段 3 中, δ 节律在 EEG 中占的比率少于 50%, 而在阶段 4 中则高于 50%。REM 睡眠阶段则被归于阶段 5。

睡眠阶段的划分, 以及其他的睡眠研究通常在专门的睡眠研究室中以多导睡眠图 (Polysomnography) 的方式记录和评价。评估措施包括 EEG, EOG, 和肌电图 (EMG)。人类的第一个平均睡眠周期是 90 分钟, 第二到四个周期是 100 到 120 分钟^[32]。

眼动以及警觉度在不同睡眠周期中的具体表现如下:

(1) 非 REM 睡眠

根据 2007 年发布的 AASM 标准, 非 REM 睡眠包含了三个阶段。在非 REM 睡眠中较少出现做梦。

阶段 1 包括了大脑从 α 节律 (8~13Hz) 主导转变成由 θ 节律 (4~8Hz) 主导的过程。此阶段通常被描述成瞌睡阶段。短暂抽搐、入睡抽动、肌肉阵挛等现象出现在此阶段, 一些人还会经历入睡幻觉 (处于睡眠与清醒之间的一种不清晰状态)。在阶段 1 中, 人体会失去部分的肌肉张力, 以及大部分的警觉度。本研究以及大部分针对疲劳驾驶的研究必须防止测试者进入阶段 1 睡眠。

阶段 2 的标志性特征是脑波中出现 12~16Hz 的睡眠纺锤波 (sleep spindles), 以及 K 复合波 (K-complex)。在此阶段中, 人体的肌肉活动会大大降低, 并且会失去所有对外界环境的警觉能力。此阶段占成年人所有睡眠时间的 45%~55%。

阶段 3 被称为深度睡眠或慢波睡眠, 其特征是 0.5~4Hz 的 δ 节律成为脑波的主导。在此阶段中, 可能会出现各种睡眠异状, 如夜游、梦呓、尿床、夜惊等。

(2) REM 睡眠

快速眼动睡眠, 或称 REM 睡眠, 在成年人中占了 20~25% 的睡眠时间。REM 睡眠的判断依据包括快速眼动的出现, 以及快速的低电压 EEG。大多数在清醒后仍然记得的梦都是出现在此阶段的。在哺乳动物中, 已确定在此阶段会出现肌肉松弛的现象, 此种现象被认为是一种保护机制, 用来防止肌肉因为梦境的影响而产生剧烈运动

并损伤自身组织。

在警觉度分析中，EOG 与 EEG 往往会同时出现，这是因为 EOG 作为肌肉运动电位强度远大于 EEG，所以一般做 EEG 分析时，都会将 EOG 作为噪声滤除。但是，眼动作为一向与警觉度有关的重要生理指标，通过 EOG 所反映出的眼电信号与警觉度也是有着极高的相关性的。

在睡眠试验中，从 EOG 中侦测出的快速眼动与慢速眼动与人的清晰-睡眠状态紧密相关，与警觉度也有着深刻的关系。同样，在前文所述的 PERCLOS 系统中，眨眼这一生理信号，也被证明是检测警觉度的一个重要手段。

1.4 研究意义

1.4.1 研究的创新性

本研究在基于 EOG 进行警觉度分析的基础上，探索将前额电信号用于警觉度分析的可行性与实用性。针对这一目标，本文首先进行了具体的实验，尝试从前额电信号中分离出独立的 EOG，证明了 EOG 信号完全可以基于前额电信号抽取。然后，基于 EOG 警觉度分析的技术和原理，将从前额信号中抽取出的 EOG 信号用于警觉度的估计，并通过实验评估其效果。

相比基于 EEG 的警觉度分析方法，基于 EOG 的警觉度估计，在实用性方面有很大的提升。这主要体现在：

(1) EEG 是由大脑神经元集体同步放电所产生的信号，在穿越骨骼、大脑皮层与毛发传递到检测电极之后，仅有微伏级别的电位，对于放大器的要求相当高。而 EOG 作为由眼球运动引发的肌肉放电信号，可达毫伏级水平，借助放大倍数较低的放大器即可将监测信号用于分析，极大降低了实现难度与成本，同时提高了便携性。

(3) EEG 信号微弱，环境噪声的强度远远大于有效信号（噪声一般是肌肉电信号，强度远大于脑电信号），同时噪声源很多。为了过滤出有效 EEG 信号，不仅需要复杂的降噪算法，还必须有足够多的监测电极提供侦测通道（独立成分分析方法要求侦测通道的数量必须大于等于信号源成分的数量）。复杂的降噪算法使得运算能力有限的便携处理器难以负荷，而数量众多的监测电极，通常需要十几乃至几十个，更是为实际应用的装配带来相当大的困难。而 EOG 恰恰相反，其信号强度大，有效信号强度一般大于噪声强度，同时 EOG 噪声干扰少，所需检测电极少，仅需 4-6 个，这就大大降低了对降噪算法的要求，同时也为佩戴带来了极大的方便。

传统的 EOG 信号采集方法,需要将监测电极安置于眼睛四周。对于实验室实验,或者被试处于静止状态下的情境来说并无不便。但是,考虑到警觉度监测系统的实际适用环境,比如,正在驾车的司机,在户外执行任务的士兵等,放置于眼睛上下以及两侧的电极,将会影响他们的视线,长时间佩戴还会带来面部的不适感,对他们正在进行的工作任务带来极大的干扰。为此,本为提出了全新的 EOG 采集方式——基于前额采集电信号的 EOG 信号分离(如图 1-7)。

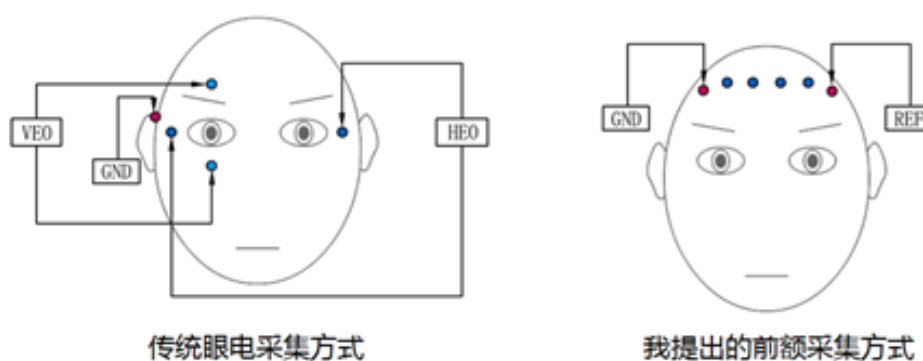


图 1-7 传统眼电采集方式与创新方式对比图

在这种全新的眼电采集方式下,监测电极将全部被安置在前额附近,可利用头带或帽子固定,再通过信号处理技术从前额电极中分离出垂直眼电(VEO)和水平眼电(HEO)成分。这样可极大简化眼电信号的采集。此后,基于本文所提出的一系列针对前额电信号的分离,分类筛选与降噪方法,经处理后得到的 EOG 信号可以有效的使用基于 EOG 的警觉度分析方法与技术,进行警觉度的估计。

1.4.2 研究的应用价值

本研究的基本出发点,就是如何提供一种在真实环境下,方便实用的警觉度估计方法。正是基于这种需求与考量,提出了基于前额信号进行警觉度估计的方法。除了前文中提及的针对疲劳驾驶的警觉度预警系统外,本研究在许多军用、民用领域都有巨大的潜在应用价值。

(1) 疲劳驾驶检测

这是本研究最重要的原始动机,由于每年疲劳驾驶造成的生命和财产损失实属巨大,将本研究的成果实用化将是一项十分迫切的需求。特别是近年来我国高速铁路迅

猛发展，高速铁路上发生意外事故所带来的灾难性，远超于一般公路交通。在一般公路交通事故中，超载酒驾等因素都是造成的事故主要原因，但是高速铁路中，驾驶员的疲劳驾驶问题则更为突出。

近年来，为了抑制国内不断上升的恶性重大交通事故数量和死亡率，公安部加大了对超载、超速、超员、醉酒驾驶和疲劳驾驶的管理及惩罚力度，在一定程度上改善了国内的交通安全状况。但是，在上述管理措施中，唯有对疲劳驾驶没有定量和科学的衡量标准和检测手段。因为与超载、超速、超员和醉酒驾驶不同，疲劳驾驶是一个过程，需要一个在线的监测手段。因此，对于驾驶疲劳检测不但具有极高的理论价值，同时具有重要的现实意义。

目前已有越来越多的基于标签，视频等信息的疲劳检测系统陆续出现，但是此类基于视频的系统受环境、光照等影响极其明显，且可以受到人为伪造的误导。因此，基于从前额电信号中分离出 EOG 的疲劳检测系统，凭借其便于装备，受环境影响小，且难以伪造误导等优势，具有突出的应用价值。

(2) 军用设备

本研究的另一应用领域是军用设备，战场状态瞬息万变，需要士兵临场做出各种快速且正确的反应。虽然据报道，美国加州 QUASAR 公司已于 2008 年为美国国防部研制出无线可穿戴脑电头盔，并在美国空军特种部队的反恐演习中用于精神负荷的分析^[33]，以便后勤部门采取措施进行控制，如图 1-8 所示。但考虑到检测的鲁棒性与便携性，基于前额电极的检测设备如果被开发出来，将更轻量级，更方便佩戴使用，而且对于士兵的正常战术动作毫无妨碍。



图 1-8 QUASAR 公司开发的军用无线脑电头盔

(3) 民用推广

基于前额电信号的检测技术，最重要的贡献是，提供了一种简单轻量级的佩戴检测方式。这使得基于 EEG、EOG 的各种技术，可以方便的被投入到各个应用领域。

由美国 Neurosky 公司所研发的穿戴式 EEG, EOG 检测系统，已经被应用于多个商用民用领域。比如，其研发的产品被用于美国射箭队^[34]以帮助提升运动员的射击精度。而其另一款产品，Necomimi 则更是在数字消费娱乐领域大放异彩，通过分析处理前额收集的电信号，将佩戴者的感情反应于电动猫耳上。此外，其相关产品在教育领域，特别是帮助青少年集中精力方面，也有所推广（如图 1-9）。



图 1-9 Neurosky 公司开发民用脑电设备

总结上述应用领域可见，利用基于前额电信号采集的技术可以大力推进各种 EOG、EEG 相关研究成果的实用化，商业化，在未来的应用市场领域，还将体现出更多的实际应用价值。

1.5 主要研究内容

本论文的主要目的是,提出一种可以在前额采集电信号并将其用于警觉度估计的方法。主要工作包括了两方面:一是基于前额信号的眼电信号分离,其中主要采用了独立成分分析的方法,结合眨眼检测的相关算法,在前额信号中将独立的垂直与水平眼电分离出来;二是将分离出的眼电信号用于警觉度的估计,对其降噪去除伪迹,从中提取出与警觉度相关的特征,然后采用基于 EOG 的警觉度分析方法进行警觉度估计。此外还包括如何设计更好的实验系统,以获得警觉度的参考。

具体如下:

(1) 基于前额电信号的眼电信号分离

为了提高基于 EOG 的警觉度预警系统的实用性与便携性,EOG 的采集设备被安置于人的前额处,但是这样带来的问题是,在前额处并不能直接采集到 EOG,更无法直接采集到独立的 HEO 与 VEO。

所以必须解决如下问题:

- (a) 在抛弃了传统的 EOG 采集电极摆放方式后,如何设计一种既方便实用又能保证可以从前额侦测信号通道中得到优质有效独立 HEO 与 VEO 信号的电极摆放方式。
- (b) 验证前额信号中,存在独立 HEO 与 VEO 信号这一假设。
- (c) 如何将基于 EOG 警觉度分析技术所需的独立 HEO 与 VEO 分量,基于独立成分分析的方法,结合眨眼检测算法,从前额的侦测信号通道中分离出来。
- (d) 基于 SVM 去除肌电噪声的方法,对分离出的 HEO 与 VEO 进行分类筛选,将最可能接近实测 HEO 与 VEO 保留,用作警觉度的估计。

(2) 基于前额信号中分离出的 EOG 的警觉度估计

基于前额中分离出的水平与垂直眼电信号,找出它们与警觉度的关联。然后采用基于 EOG 的警觉度估计方法,利用前额信号中分离出的 EOG 进行警觉度估计实验。

(3) 警觉度实验系统改进尝试

目前实验中采用的实验系统,是基于图片刺激序列的,被试被要求当出现某一图片时,及时准确的做出相应的反应。这一过程中的反应时间和准确度,会被整合作为警觉度的参考。这种系统的最大缺陷就是,被试的警觉度参考是一系列离散的数值,不便于某些理论分析。

实验系统的改进,希望能够通过设计实验,更为实时的获得被试的警觉度状态变化。主要设计思想是让被试控制某一光标,去持续的跟踪一个受一定随机干扰运动的目标点,通过实时的分析被试的反应,动作的准确,光标与目标点之间的紧密程度,作为警觉度的参考。

1.6 毕业论文结构

本论文正文由以下七个章节组成:

第一章:总体介绍警觉度监测的研究背景和意义,国内外研究进展,脑电眼电信号与警觉度的关系,并阐明本文的研究意义与主要研究内容。

第二章:重点介绍基于 EOG 进行警觉度估计的一般过程,包括如何做特征提取,如何进行 LDS 去噪,以及如何如何进行特征整合。

第三章:主要分析基于前额电信号进行警觉度估计的可行性,重点在于分析前额信号中分离出 EOG 的可行性。利用前额电信号进行警觉度研究,在国内外尚属罕见,所以本章特别分析前额信号与眼电的关系,并提出前额信号可以分离出眼电信号这一假设。

第四章:重点介绍如何设计实验来验证前额信号中可以分离出 EOG 的假设,并且为今后从前额信号中抽取 EOG 提供可行的前额电极摆放策略。

第五章:是本文的核心,首先验证了前额信号中可以分离出 EOG 这一假设。然后,提供了一整套从前额信号中提取出独立 HEO 与 VEO 的方法,包括,使用 ICA 的盲信号分离,基于眨眼检测区分 HEO 与 VEO 的方法,以及基于 SVM 去除肌电伪迹的思路挑选 HEO 与 VEO 的方法。

第六章:介绍基于前额电信号的警觉度实验流程,并对于传统图片实验的方式,提出优化设计方案。

第七章:对全文的工作进行总结,并对今后基于前额信号的警觉度监测系统进行了展望。

1.7 本章小结

本章首先介绍了警觉度的相关定义,以及警觉度研究的背景与意义。随后,对国内外警觉度的研究现状,特别是基于 EOG 的警觉度研究现状做了详细的列举;然后,简单介绍了 EEG 和 EOG 与警觉度的关系,阐述了为什么这两个生理信号可以被用来

估计警觉度；接下来，对本研究的研究创新性以及实际的应用价值进行了阐述；最后，简要列举了本论文的工作内容，以及论文的整体结构。

第二章 基于眼电信号的警觉度分析

2.1 基于 EOG 警觉度分析一般过程

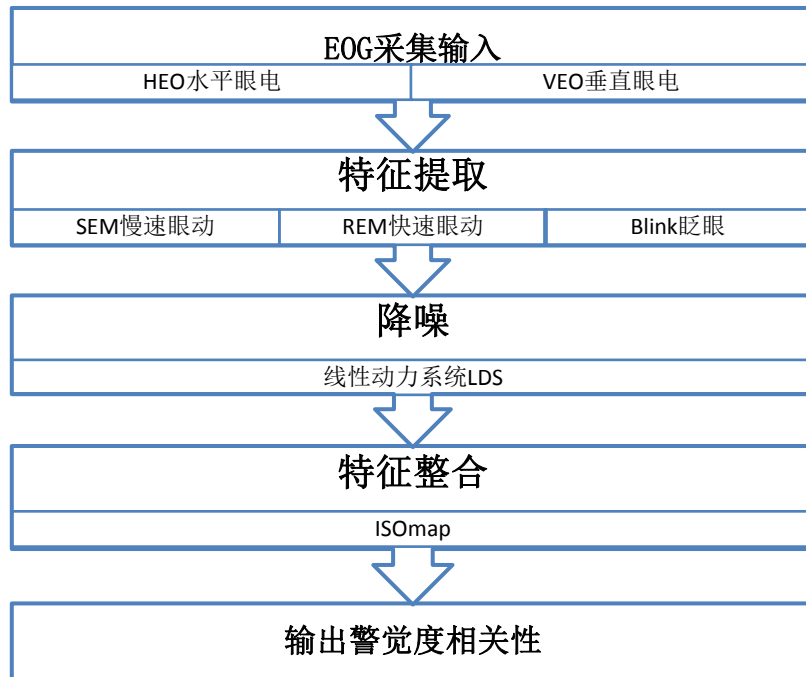


图 2-1 EOG 警觉度分析的一般流程

图 2-1 给出的是基于 EOG 进行警觉度分析的完整方法流程。整个过程的输入是 EOG 信号，分为水平眼电 HEO 与垂直眼电 VEO。随后，使用特征提取的算法，会从 HEO 与 VEO 中提取出，慢速眼动 SEM，快速眼动 REM 以及眨眼特征。然后，对提取出的特征信号，采用线性动力系统 LDS 进行降噪处理，滤除变化剧烈且无规律的成分，最后使用 ISomap 与流形学习方法进行特征整合，降为至 1 维，输出一条可以反映警觉度状态的曲线。

2.2 眼电信号的特征提取

基于前文所述的眼电信号的生理特性,在进行警觉度分析的时候,需要先将眼电信号中的慢速眼动、快速眼动以及眨眼信息抽取出来,独立分析他们各自与警觉度的关联性。

2.2.1 慢速眼动特征提取

提取慢速眼电 SEM 特征的方式主要由两种。一是基于离散小波变换的方法,另一种是基于短时傅里叶变换的方法。

基于离散小波变换的方法,主要参照了 E.Magosso 等人于 2006 年提出的方法^[21-24]。该方法将 HEO 作为输入,首先进行小波分解,将输入信号分成不同频带的子成分,然后进行能量计算,得出每个子成分在某一给定时间长度内的能量强度,再然后,引入一个判定函数,针对每一个子成分,评判其中慢速眼动部分占整体的比重,最后,将这一比重与一个阈值做比较,判别出各个子成分是否可用来作为 SEM 特征。该方法不论在频域还是时域上都能保证完整的信号特征,但是由于做小波变换需要的计算能力更高,且在本研究中,并不需要对慢速眼动进行准确的定位分析,主要还是根据 SEM 的出现频率来判断被试的警觉度状态,所以基于便携与应用性考量,后续实验基本都采用基于短时傅里叶变换的方法。

短时傅立叶变换(Short Time Fourier Transfrom, STFT)的作用与小波变换类似,也是将信号从时域转化到频域,用以分析信号在频域上的特征。与小波变换相比,短时傅立叶变换在时域上的分辨率非常低,而慢速眼动的持续时间,在零点几秒到数秒直接都有可能。因此,STFT 的时间窗设置格外关键,如果设置的太小则有可能会忽略长时间的慢速眼动,如果将时间窗设置的太长则又无法定位出短时眼动。不过本研究中主要用到在给定时间内,慢速眼动出现比例这一信息,而 EOG 研究使用的分辨率不高,一般在 8-10s,所以 STFT 完全可以满足这一要求,最终将低频部分能量与高频部分能量的比值,作为慢速眼动的特征。

具体操作流程如图 2-2:

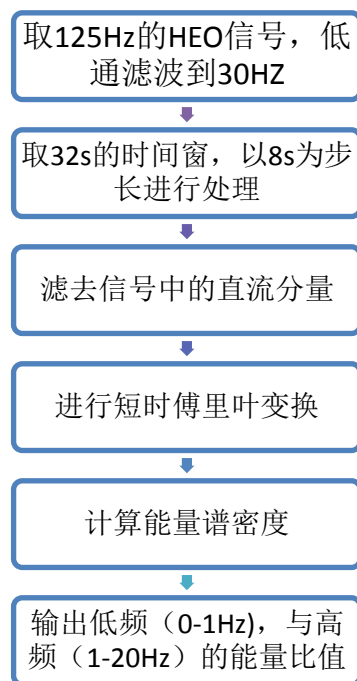


图 2-2 慢速眼动提取流程

2.2.2 快速眼动特征提取

快速眼动的特征提取主要基于 K. Hyoki 等人所提出的算法^[25]。其核心思想是根据眼球的运动速度，来界定是否出现快速眼动。其论文中提到，慢速眼动的速度阈值是 15deg/s，所以只要检测到眼动速度超过这一阈值就可以认为出现了快速眼动。基于这一方法，最终将给定时间段（8s）内的 HEO 带通滤波后进行差分，将这段时间内大于阈值的离散点的个数，作为最终提取出的快速眼动特征。

具体操作流程如图 2-3:

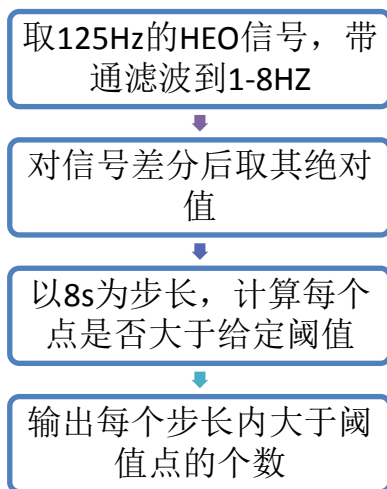


图 2-3 快速眼动提取流程

2.2.3 眨眼特征提取

对于眨眼特征的提取,本实验室的马家昕在参考 Bruno Jammes 等人的方法后^[20],提出了进一步的优化改进方法^[36-37]。原方法的核心思想是给定两个速度阈值,一个是眼睑闭合的速度阈值,一个是眼睑打开的速度阈值。在 EOG 的时域波形中,可以借助着两个阈值来定位一次眨眼行为。

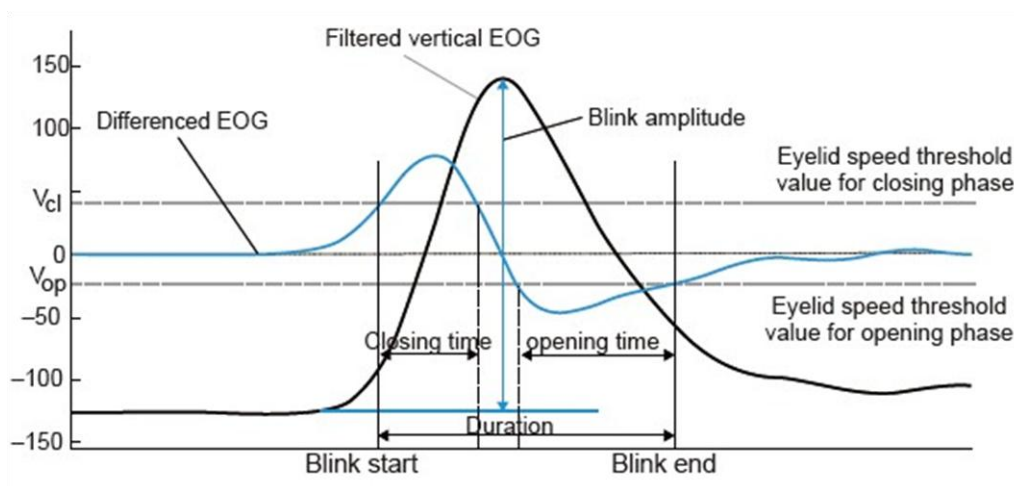


图 2-4 眨眼信号的波形特征

如图 2-4 所示，黑色的曲线是眨眼时刻的 VEO 波形，可以看出眨眼时会出现一次明显的波峰。蓝色曲线是对 VEO 进行差分后得到的波形，所表示的是眼睛闭合或睁开的速度。可以看到，当黑色曲线达到峰值时，蓝色曲线的值为 0，也就是说当眼睑完全闭合时，其速度等于 0，这与真实的眨眼情况相符合。因为采用了差分后的 VEO，所以该方法不容易受到电压漂移等因素的影响，对于肌电或其他干扰所造成的电位漂移有很好的抗干扰效果。

图 2-4 中， V_{cl} 和 V_{op} 表示两个阈值，前者用来判断眼睑闭合，后者用来判断眼睑睁开，都是作用在差分后的波形上的。以 EOG 原信号的峰值点，也就是差分信号的 0 点为界，可将眨眼信号分成闭眼部分和开眼部分两个部分。闭眼部分可以通过差分信号是否超过 V_{cl} 来定位，而开眼部分则可以通过差分信号是否低于 V_{op} 来定位。 V_{cl} 和 V_{op} 的大小可先通过经验设定一个初始值，然后通过采集一段时间的信号来进行调整。基于闭眼与睁眼的定位，就可以定位一次眨眼行为。

该方法对于被试闭眼非常缓慢的情况存在漏检，作者在原文中提到，此时被试已经处于极度疲劳的状态，警觉度的预警应该在此前就早已被触发，所以并未针对这一现象做出处理。本实验室的马家昕针对这一问题，以及一些其他的不足之处，做出了改良，最终形成了本文中所使用的眨眼检测方法。

在改进方法中，一次眨眼时间将由 4 个点来定位，分别是两个超过 V_{cl} 的点，和两个低于 V_{op} 的点，这样设定使得侦测到的眨眼长度、睁眼时长、以及闭眼时长，都更接近实际的眨眼。此外，改进方法中还专门针对两次相邻很近，甚至在波形上重合的眨眼事件进行了特别的处理。最后针对缓慢闭眼的问题，同样针对缓慢闭眼的电位波形做出了特别优化。

最终眨眼特征被分为了 8 类，如下：

眨眼时长(duration)：从眼睑开始闭合到完全睁开的时间。

闭眼时长(closing time)：从眼睑开始闭合到开始睁开的时间。

睁眼时长(opening time)：从眼睑开始睁开到完全睁开的时间。

闭眼速度(closing velocity)：眼睑闭合的最高速度。

睁眼速度(opening velocity)：眼睑睁开的最高速度。

眨眼间隔(interval)：两次眨眼之间的间隔。

闭眼/眨眼时间比 (PERCLOS)：这是用于模仿 PERCLOS 系统的特征，定义为闭眼与眨眼总持续时间的比例。

LF/HF：低频部分能量与高频部分能量的比值。

在实际操作中，将计算每个眨眼的特征参数，包括眨眼时长、闭眼时长、睁眼时

长、闭眼速度、睁眼速度、眨眼间隔、闭眼/眨眼时间比、LF/HF。每隔 8s 输出一次平均值。

2.3 基于线性动力系统的降噪

用 LDS 进行 EEG 特征的去噪是本实验室的一项主要研究成果^[38]，后来将其用于 EOG 的降噪，同样得到了很好的效果。基于警觉度的生理特性，认为警觉度的变化是一种缓慢且有规律的变化过程。而实际得到的信号中，存在着大量无序且剧烈变化的成分，将其视为噪声。因此，采用线性动力系统可以有效的过滤掉 EOG 信号中与警觉度无关的成分，并达到平滑信号的效果。

LDS 的效果如图 2-5 所示，变化剧烈的非警觉度成分被过滤掉。虽然对特征信号进行低通滤波也可以达到类似的效果，但是 LDS 引入了状态空间的概念，比常用的移动平均方法，具有更高的估计精度^[37]。




图 2-5 LDS 效果图，蓝线为 LDS 处理之前，红线为经 LDS 处理之后的结果

2.4 特征整合

本研究的最终意义是进行警觉度的估计，所以最终需要输出一条可以反映警觉程度的曲线。特征融合，就是将已得到的多个特征，融合成一个特征。因为不管实际检测到了多少特征，比如快速眼动、慢速眼动、眨眼等，但是最后实际输出的警觉度曲线只能有一条，该输出就是经过多个特征的融合得到的。最简单的特征融合方法就是直接求和，也就是先将各个特征的归一化（包括取值范围、正负相关性都需进行归一），

之后将它们直接叠加。这么做的好处是明显的：若这些特征确实主要反映着警觉度的变化，则它们之中与警觉度相关的成分因为规律相同，所以将会通过叠加而被进一步扩大，而与警觉度无关的成分则因为规律各异，所以将会通过叠加而被抵消，这样就达到了特征融合的目的。本研究采用流形学习，或称等距映射方法（ISOMap）进行特征整合，将多维特征降至一维。

在选取特征进行降维方面，本文所采用的是经测试后与警觉度的平均相关度大于 0.6 的特征，包括：慢速眼动特征（DWT， LF/HF），眨眼特征（closing time, closing velocity, opening velocity, LF/HF）这些特征。

2.5 本章小结

本章简要介绍了基于 EOG 的警觉度分析技术。基于 EOG 的警觉度估计，首先从 HEO 与 VEO 中抽取 SEM, REM 以及眨眼等特征，然后基于 LDS 进行降噪处理，最后使用 ISOMap 进行特征整合。因为本文后面将要提出的基于前额电信号的警觉度检测，核心思想就是从前额中分离出 EOG，然后用基于 EOG 的警觉度分析方法来进行警觉度的估计，所以基于 EOG 进行警觉度分析的技术基础十分重要。

第三章 基于前额信号分离眼电信号的可行性分析与实验设计

3.1 利用前额电信号的相关研究

目前国内外直接利用前额电信号抽取 EOG 信号的研究尚属罕见。

L.Weil 等人在 2008 年曾做了利用前额生物信号控制轮椅的研究^[39]。研究中，他们定义了抬一下额头、抬两下额头、闭左眼、闭右眼以及咬合等 5 中面部运动，将这 5 种脸部运动的状态对应到一个有穷状态机上，最终用于对轮椅移动的控制。

该项研究中，三个电极被摆放在前额以抽取生理信号，随后，经过滤波，数据处理，特征抽取，分类等一系列处理，分类得出控制轮椅的 5 个状态。由于前额信号中会同时混杂 EOG, EMG, EEG 等三种信号，该项研究便同时使用了三种信号分别抽取特征，随后利用反向传播神经网络 (BPANN) 进行分类，得出不同的状态。但是在对前额取得的原始信号的处理阶段，这项研究并没有深入区分 EOG, EMG 与 EEG。他们根据三种信号的不同生理特性，将频率在 0.5-45Hz 之间的信号定义为 EEG，0.2-3.0Hz 之间的信号定义为 EOG，70-10000Hz 之间的高频信号定义为 EMG。虽然从结果看来，综合使用这样处理过的 EOG, EMG 与 EEG 是可以区分出 5 种面部运动的，但是这样的处理方法，却无法基于 EOG 进行警觉度检测的要求。

另一项研究来自 Antti T. Vehkaoja 于 2005 年发表论文^[40]，文中指出，他们研发了一种头戴式无线 EOG 与面部 EMG 检测设备。如图 3-1 所示，5 个电极被摆放与前额，其中两个作为 EMG 的信道，而另外两对作为 EOG 的信道。该项研究重点在于阐述如何实现整套无线采集硬件系统的，对于 EOG 与 EMG 的信号处理，给出的方法也较为简单。




图 3-1 LDS 一种头戴式无线 EOG 与面部 EMG 检测设备

研究者根据生理信号特性，针对 EOG 信号给予 40 的较低增益，而针对 EMG 则给予了 1000 的增益。EMG 的滤波采用了 10-400Hz 的带通滤波，而 EOG 则是 400Hz 以下的低通滤波。该研究虽然可以大致区分 EOG 与 EMG，但也没有针对 HEO 与 VEO 做单独的抽取处理。

由上述研究案例可以看出，目前的研究主要还集中在利用前额电信号直接控制轮椅，或者单纯的采集硬件设备研究方面，尚无直接利用前额电信号进行警觉度估计的研究。

更为遗憾的是，虽然在前额采集到的信号中，明显混杂了 EEG，EOG 与 EMG 等各种信号源，但是因为研究目的不同，目前所有基于前额电信号的研究，都没有对三种信号进行深入的抽取与分离。基本是简单的按照信号频率以及幅度对采集到的信号进行了粗略的划分，比如直接将高频视为 EMG，将低频视为 EOG，而没有更加深入的抽取。这样得到的 EOG 或者 EMG 信号，虽然在一定程度上可以表现出一些生理特性，比如眨眼动作这种明显的眼肌运动仍旧可以被抽取出，但是更为细微精准的眼部运动，就会被来自其他信号源的信息或者噪声所淹没。而如前文所述，在我们基于 EOG 进行警觉度分析的研究中，除却眨眼这种特征，慢速与快速眼动等都是极其重要的特征信息，仅仅依靠基于频段筛选这种粗略的信号处理方式，会将水平眼动信息中包含的重要生理信号丢失掉，这样简单处理后得到的 EOG 信号是无法直接用于后续警觉度分析的。同样，这样的信号处理方法，亦无从区分水平眼动 HEO 与垂直眼动 VEO，而独立的 HEO 与 VEO 恰恰是本研究中提供给后续警觉度分析系统的直接输入信号源。

3.2 前额电信号的生理特性

人的前额是一个各种生理电信号交错集中的区域，除了我们分析所需要的 EOG 之外，由面部肌肉运动所产生的 EMG 信号也会很容易被采集到，此外 EEG 信号虽然微弱，但是也可以在前额被检测到。

通常所说的眼电图，一种是测量在视网膜色素上皮和光感受器细胞之间存在的视网膜静电位，另一种则是我们在研究中会用到的眼动所产生的电位。在实际应用中，这种 EOG 又会被分为水平眼动 HEO，也就是由眼球水平运动所产生的信号，和垂直眼动 VEO 也就是由眼球垂直运动所产生的信号。在我们研究中会用到的三个主要特征，SEM，REM 与眨眼，在 HEO 与 VEO 中会有所体现。以眨眼为例，因为眨眼需要眼睑打开闭合，会产生很强的电位变化，这一点不仅在 VEO 中，在 HEO 中也会有所体现。不过，一般来说，SEM 与 REM 主要与眼球的水平运动有关，而眨眼则更多的通过垂直眼动来体现。

面部表情运动所带来的肌电 EMG 信号，在前额上的表现也是相当明显的。因为与眼动一样都是由面部肌肉所引发的电位变化，所以 EMG 成分可以很清晰的反应在前额采集的眼电信号中。在实验实测过程中，诸如皱眉头，咬牙等之类的面部肌肉运动，会对前额信号产生巨大的影响。

研究中所用的眼电信号是于眼球运动，主要是眼球运动所产生的肌电信号，通过对已有的实验数据的观察可知，眼电信号相比于噪声信号的幅度很大，并且眼部动作如眨眼等产生的信号十分明显，虽然面部运动产生的 EMG 信号同样很强，但是起与 EOG 的在模式上游很大差异，所以从前额中分离出眼电信号，理论上是可行的。基于盲信号分离的思想，通过各种信号分析技术可以有效地对眼电信号进行自动分析，提取出相应的眼部活动状态。另一方面前额眼电信号是人的生理信号，与视频图像相比有更好的准确性，并且测量错误率小，难以伪装。因此以前额眼电信号作为疲劳程度的评估方法有较好的应用前景。

3.3 基于前额电信号分离眼电信号的假设

根据前文的分析，本论文提出这样一个假设：

在前额采集的电信号中混杂有多个观察信号源，包括脑电 EEG，肌电 EMG，水平眼电 HEO、垂直眼电 VEO，以及各种噪声。其中眼电信号、肌电、脑电与其它信

号源，彼此之间在统计上相互独立。同时，水平眼电与垂直眼电也是统计独立的。所以，可以通过 ICA 的方法，将水平眼电与垂直眼电，从多个前额信号（观察信号）中分离出来。

这一假设，是可以基于前额眼电信号进行警觉度估计的基础，只有确认在前额信号中可以分离出独立的 HEO 与 VEO 信号，才可以采用基于 EOG 的警觉度分析技术，进行警觉度的估计。

在后面的篇章中，将详细介绍，我是如何设计实验验证这一假设，并且设计方法将独立 HEO 与 VEO 从前额信号中分离提取出来的。

3.4 分离眼电信号的实验设计目的

作为一项探索性的尝试实验，基于前额电信号的眼电信号分离实验，有着如下几重目标：

(1) 验证“可以从前额采集的多个信号源中，分离构造出水平与垂直眼电信号”这一猜想。

为了达成这一目标，实验中会同时使用传统眼电采集法与前额眼电采集法同步采集信号，然后，要求被试尝试做出各种常见或者极端的面部动作，最后对比基于传统方法采集到的眼电信号，与基于前额眼电采集法采集并分离出的眼电信号的相关性，从而确定基于前额采集信号分离出独立分量中，是否包含 HEO 与 VEO 信号。

(2) 寻找可重构出眼电信号的最佳电极摆放策略，包括：使用几个电极，放置在何种位置，Ref 参考电极放置在何处，Gnd 接地电极放置在何处。

为了实现这个目标，实验中同样要求使用传统眼电采集法与前额眼电采集法同步采集信号，并控制在实验环境不变的情况下，针对同一被试，同一组刺激，尝试各种不同电极摆放策略，随后针对每一组电极摆放策略，计算出抽取后 EOG 与实测 EOG 的相关度，最后综合考量抽取后 EOG 与实测 EOG 的相关程度以及摆放方式的实用性，决定选出一种最优的电极摆放策略。

(3) 研究重构眼电信号的方法，比较重构出的眼电信号与直接采集的眼电信号的相关度。尝试分析差异原因，并尝试找出可以提高相关度的方法。

这一目标与前两者不同，前两项目标，均是考虑到在已知实测 EOG 的前提下，对比实测 EOG 与抽取后的 EOG，而后做出各种分析。而这一目标，则是考虑在实际应用环境中，系统并无先验的实测 EOG 信息，在此情况下，如何基于盲信号分离的思想，抽取并挑选出最接近实测 HEO 与 VEO 的独立分量。

为了完成这一目标,实验中同样同时基于传统眼电采集法与前额眼电采集法同步采集信号。基于传统眼电采集法可以直接得到实测 HEO 与 VEO,于是将实测 HEO 与 VEO 保留作为对比参照。此后,基于 EOG 的生理特性设计方法,在无先验实测 HEO 与 VEO 的前提下,基于盲信号分离的思想,抽取并挑选出最接近 HEO 与 VEO 的两组信号,基于它们与实测 HEO 和 VEO 的相关度,来评判 EOG 的抽取效果,并分析研究提升抽取 EOG 与实测 EOG 相关度的方法。

3.5 实验设置及流程

3.5.1 实验设备

实验系统包括两大部分,如图 3-2 所示。

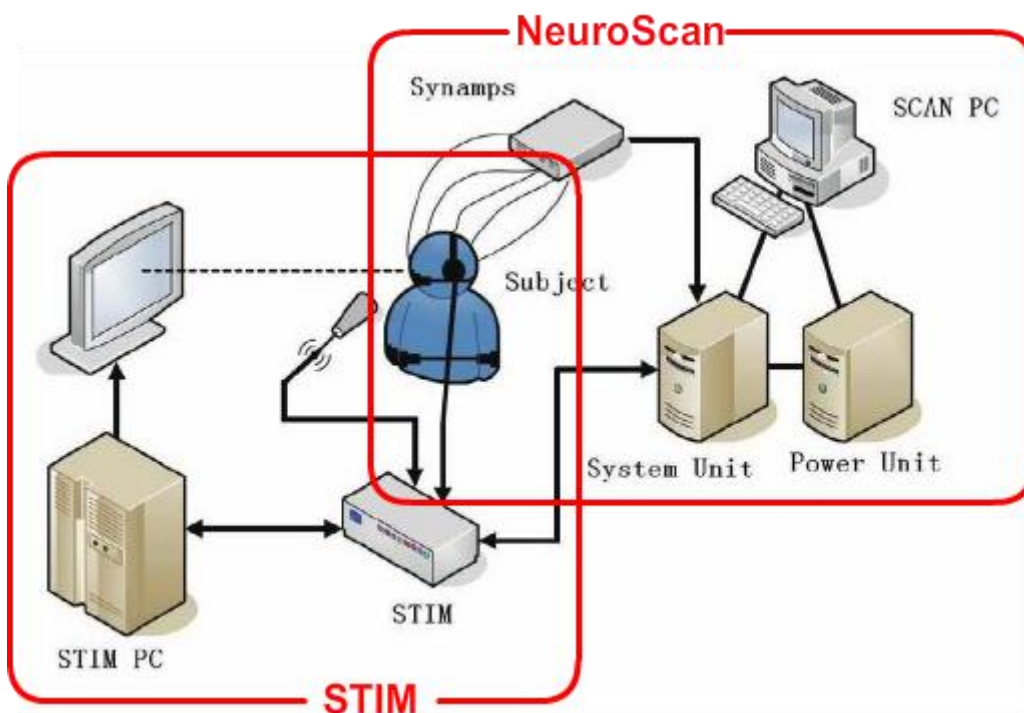


图 3-2 实验设备示意图

第一部分是 NeuroScan 采集系统,负责采集被试的眼电与额电信号,经过采集、放大、滤波后,将每个采集电极的时序电位信号保存,以供后续处理。

第二部分是 Stim 系统,负责生成刺激序列,同时收集被试对于刺激所作出的主

动反馈。包括一个刺激展示系统，与一个反馈收集系统。

经过整合，基于 NeuroScan 系统采集的电信号，与基于 Stim 系统采集到的被试主动反馈可以被整合到同一组时序序列中，这样极大的方便了电极信号与被试反馈在时间尺度上的对应。

NeuroScan 系统

本实验采用的信号采集设备是 Neuroscan ESI-128 系统，主要包括湿电极脑电帽、信号放大器和 Scan 软件三部分。该套系统是针对脑电采集专门设计的数据收集系统，不过做简单的电极映射之后，同样可以被直接用于前额以及眼电信号的采集。

湿电极帽是脑电采集的直接采集部分，通过为接近头皮的各电极中注入液态导电介质来降低高阻抗的干扰，从而提取出微弱的脑电信号，并将脑电信号发送到放大系统中。本实验中所使用的 Neuroscan 脑电帽最多可以支持 64 导电电极，但是本实验中并不需要按照脑电实验的电极使用方式来处理，而是做了特别的映射。

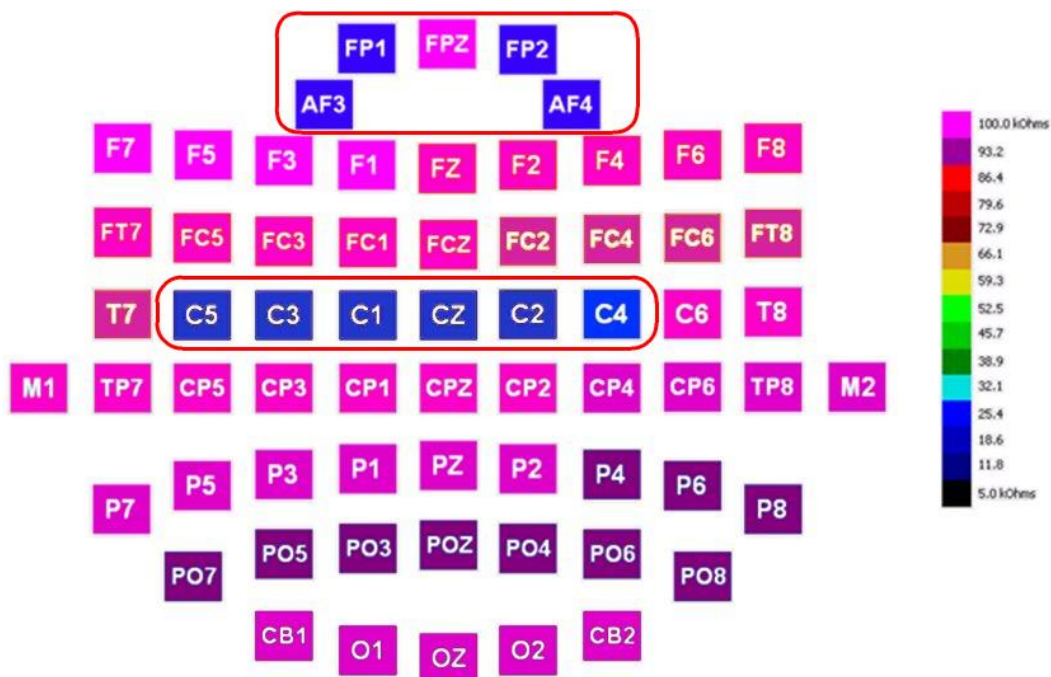


图 3-3 阻抗显示示意图，颜色越深代表阻抗越小，右边是阻抗的标尺

如图 3-3 所示，深蓝色（被圈释）部分的电极，表示阻抗很低，是实验中会被使用的电极，所以注入了导电膏，接触被试人体。而其它电极，虽然也是脑电帽上的电极，但是却没有被使用，所以出于人体绝缘状态，接入阻抗相当大。

通常在脑电实验中，FPZ, FZ, CZ, PZ 和 OZ 是从鼻根到枕外隆凸起的连线，其它电极则分别对应佩戴者整个脑壳的其他位置。而在本实验中，因为仅仅是借助脑电帽作为信号采集设备，而并非用其采集脑电，所以稍加改造，单独使用 AF3, FP1, FP2, AF4 作为使用传统方法采集眼电信号的电极，而 C1-C5，也同样用引线单独引出，则分布于额头，作为额头采集电信号的监听电极，CZ 作为参考电极 REF，此外还有接地电极 GND 也是传统采集法与前额采集法共用的电极。实验要求的阻抗大小约为 $5k\Omega$ 左右。电极帽另一端与放大器相连，放大器将采集到的信号进行放大和滤波处理，最后整合成固定格式的的数据并传输到软件端。

Scan Software 是用来观察与记录采集信号的软件系统，图 4-2 所示的阻抗分布图，就是 Scan Software 所提供的在实验开始前检查每个电极是否处于正常工作的功能。此外各种采样参数，比如采样频率，带通滤波等都可以经由 Scan Software 设置处理。在本实验中，因为主要关注的是 EOG 信号，所以采样频率为 500Hz，并对采样原始输入数据进行了 0.1-100Hz 的滤波处理。

Stim 系统

Stim 系统用于为被试提供任务环境，包括刺激诱发部分与刺激反馈收集部分。诱发部分通常用于播放图片、音乐等刺激材料，实验设计人员可以通过程序的设定决定刺激材料的播放顺序和播放时间等，在实验过程中被试可以通过按取刺激反馈部分的特定按钮设备，将对每个刺激材料的反应结果反馈给 Scan 系统。在警觉度实验中具体是通过不同的图片序列对被试进行视觉上的刺激，然后接收并记录被试的按键响应。系统会自动记录下从刺激产生到测试者按键所花的时间，以及测试者按键的正确率。这些行为特征对我们的实验结果有着重要的参考意义和辅助作用。

在本实验中，并没有用到 Stim 系统进行被试反馈的收集，而仅使用其作为刺激的诱发。实际实验中，Stim 系统配套的软件部分被用来编辑表情刺激序列的种类、产生方法、持续时间等各种参数，从而方便地定制整个测试任务。当编辑好的任务被运行后，屏幕上就会显示一系列图片，每幅图持续一段很短的时间，图片之间会有黑屏间隔。而测试者的则需要针对图片的提示做出各种面部动作反馈。

除了 NeuroScan 和 Stim 系统之外，还配有一个摄像头，用于观测测试者的实验

状况，防止测试者出现异常行为。实验环境为封闭的，无噪声，无刺激光线干扰的环境。另外还有一点特别注意的是，实验使用的 LED 屏幕，为 22 寸，距离被试约 50cm。这样可以保证被试每次转动眼睛时视线移动范围基本一致，同时也确保有一定的眼球可转动范围。实验场景如图 3-4 所示。



图 3-4 警觉度实验场景

本实验的基本模式是，要求被试在整个实验中，根据刺激的提示，模仿做出各种各样的脸部动作，在这一过程中，不断的采集实测眼电与前额电信号。最终用于评估是否在任何状态下，前额电信号中都可以抽取出眼电信号。

为了达到这一目的，实验中设计了 14 种刺激动作，基本涵盖了各种常见的、夸张的面部运动。并将这些动作一一拍照，制成动作序列图片，配之以文字说明，可以直观简单的提示被试按照图片与文字所反映的内容，模仿做出各种面部动作。一个典型的刺激动作如图 3-5 所示。



图 3-5 一个典型的刺激动作图片

这 14 种刺激动作分别如图 3-6，图 3-7 所示：



图 3-6 实验中的刺激动作序列

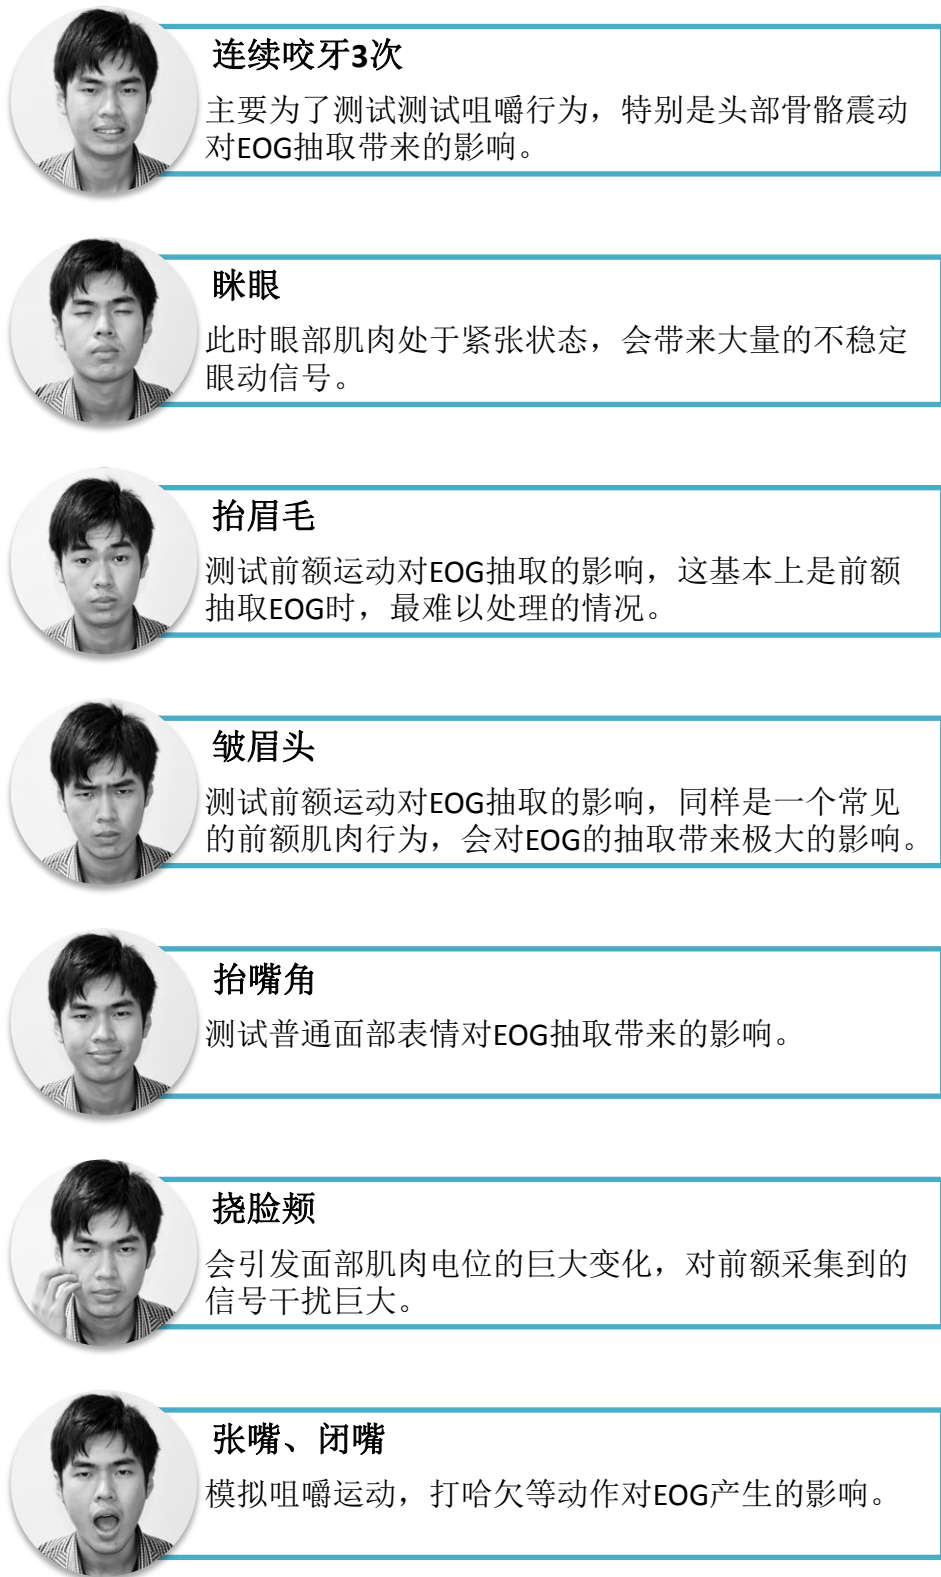


图 3-7 实验中的刺激动作序列 (续)

3.5.2 实验流程

每次完整的实验由 2 或 4 个同样的实验阶段组成。每个实验阶段中，14 组脸部动作刺激会随机出现各一次，没有任何可以预判的规律，每次持续 20s 时间，被试会被要求在这 20s 中不断模仿给定刺激的面部行为。

实验开始前，主试人员会向被试介绍实验的目的、流程和需要注意的事项。每个实验阶段的实验流程包括三个部分：开始提示、刺激模仿和休息。具体流程如图 3-8 所示：

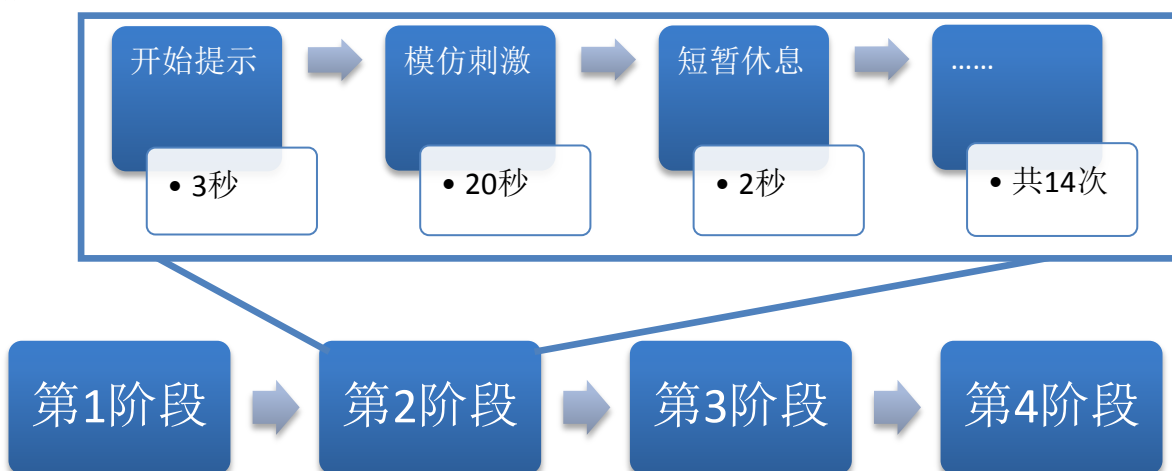


图 4-7 实验流程

开始提示是为了提醒被试集中精力，将注意力集中到实验中来，预示着刺激序列即将开始，该过程需要 3 秒钟；刺激模仿是实验的主要部分，通过给予被试图片和文字的说明，要求被试立刻模仿相应的动作，并持续 20s 的时间，直到出现短暂休息的提示。每一段模仿刺激之间，会有 2s 的短暂休息时间。每一个完整的实验阶段，大概持续 12 分钟，每两段实验阶段之间，会给予被试 5 分钟的休息时间。对于 2 段实验，大概总持续时间在 30 分钟，而 4 段实验大概持续 1 个小时。

本项实验共进行过两轮，每次有 6 位被试进行了实验，4 名男生、2 名女生。平均年龄 21 岁左右，身体健康、所有被试均为上海交通大学的本科生或研究生。被试在实验的前一天睡眠充足，睡眠质量良好。在实验前被试已被告知实验的目的，并被要求在实验过程中的不要做刺激动作没有提示到的多余动作，以避免无谓的信号干扰。

3.6 前额电极摆放策略

本研究其中有一项重要的研究目标是提出一种具有实用性的前额采集电极摆放策略。

传统的眼电采集方法，将一对电极分别摆放于一只眼睛的眼眶上下，把它们采集到的信号作为垂直眼电 VEO；再将一对电极摆放在两眼的外侧眼角，将它们采集到的信号作为水平眼电 HEO，再将参考电极 Ref 放置于耳廓，最后将接地电极 Gnd 也放置于耳朵，或者后脑处。

这样的电极摆放策略，可以最直接的获得垂直眼电 VEO 与水平眼电 HEO，并且有着较少的噪声干扰，被广泛应用与各种实验，甚至临床医学中。但是，当将这样的电极摆放策略应用与日常生活或者工作的复杂环境中时，会碰到诸多的问题。比如，在过于靠近眼睛的位置铺设电极以及导线会相当干扰使用者的视线；这样摆放会导致检测电极过于分散，配置起来较为麻烦；如果被试穿戴帽子或者眼镜等面部饰品就会干扰到电极的正常摆放，从而导致无法使用。在我们之前的警觉度分析实验中，就出现了佩戴眼镜的被试因为要检测眼电必须拖下眼镜，从而导致难以看清屏幕，不方便进行实验的现实矛盾。

因此，为了解决传统眼电采集方式，由于电极摆放原因而导致实际应用中的诸多限制，本文为新的前额点击摆放策略，提出了如下准则：

电极的摆放（如果是有线电极，还需考虑引线的排布），不可以对使用者的任何日常活动，特别是视线造成干扰。

电极应该可以被方便的穿戴，而无需复杂冗余的配置。应该可以与帽子，头带等设施方便结合，如果制成干电极，则应该可以瞬间穿戴完成。

基于这一的电极摆放来抽取 EOG 信号，必须有足够的鲁棒性。经过处理应该可以屏蔽掉明显的肌电干扰、伪迹以及被试的无意行为所造成的影响。

考虑到上述准则，本研究决定将检测电极全部排布与被试的额头。这是因为，第一，在所有的脸部肌肉运动中，前额是肌肉活动的复杂程度以及强度都相对较小的一个区域；第二，各种相关研究都已经指出，前额的皮层结构较为简单、无毛发干扰，传导性好，适合进行信号的采集；第三，前额是脸部上极其靠近眼睛的一个区域，可以很敏感的捕获到眼动信息。当然，还有一点原因就是，结合本实验室的其他项目研究来考虑，如果使用头戴式干电极采集设备，只须一根头带束与额头，就可以包含所需的检测电极。最终，我们在实验中共尝试了 4 种不同的前额点击摆放策略，如图

3-9 所示:

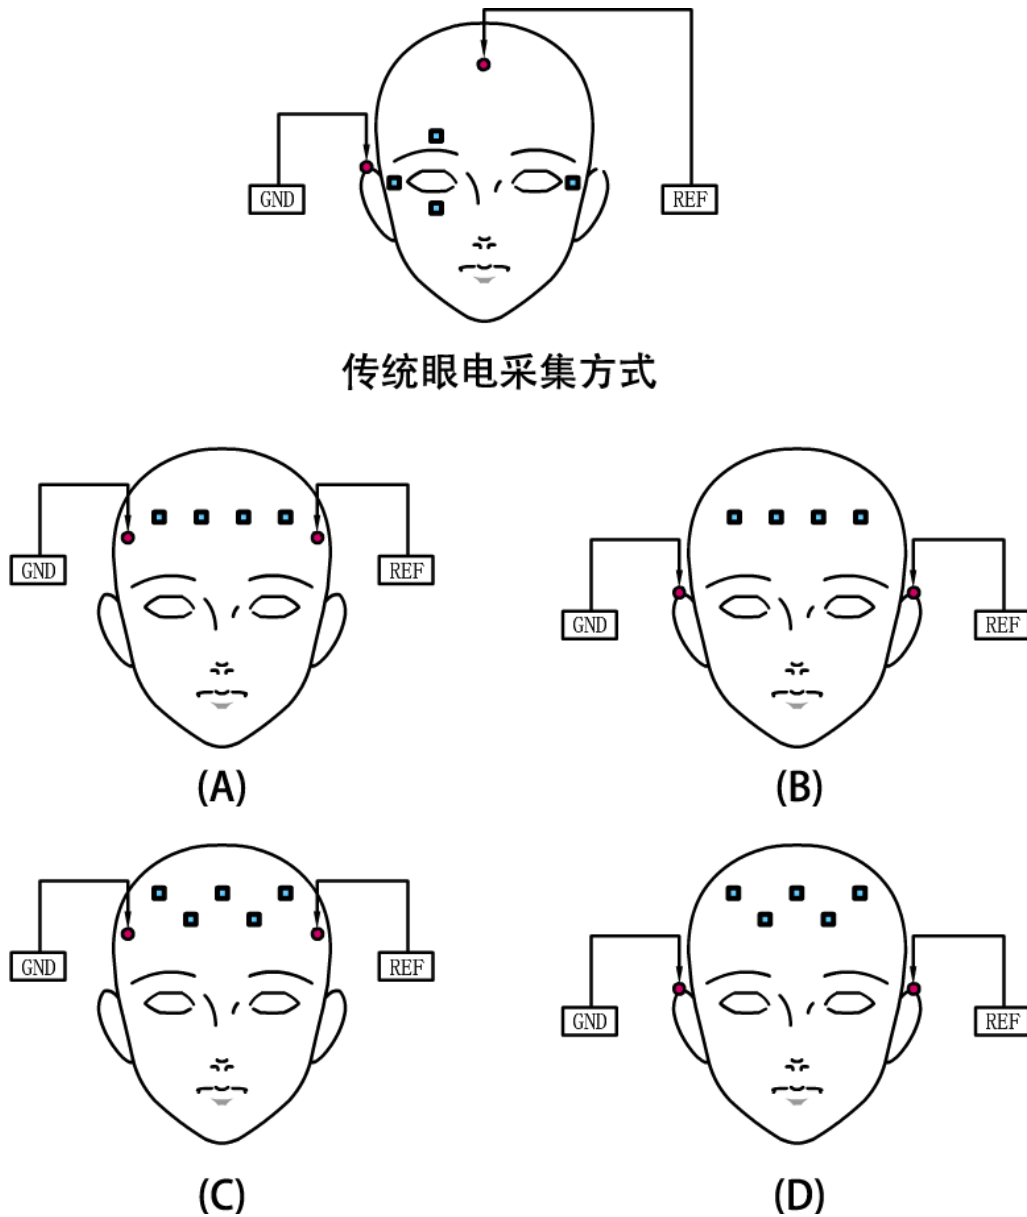


图 3-9 各种电极摆放策略，蓝色方块为眼电采集电极

以上 4 种电极摆放策略，可以归纳为两类。

第一类是 A 和 B，以 A 为代表，它们都使用了 6 个电极来采集前额电信号，其中 4 个电极作为额电检测电极，被水平排成一列位于额头。在 A 中，参考电极 Ref

与接地电极 Gnd，被放在了额头接近太阳穴的地方，而 B 中，Ref 与 Gnd 则分别被安置与耳廓。

第二类是 C 和 D，以 C 为代表，它们都使用了 7 个电极来采集前额电信号，其中 5 个电极作为额电检测电极，被交错放置于前额，构成一个 W 形状，下方两个，上方三个。下方的两个电极更接近上眼眶，这样的摆放是为了更敏感的检测到 VEO，特别是眨眼信息，并且放大 VEO 与 HEO 的差异。与第一类摆放模式详细，在 C 中，Ref 与 Gnd 被放置于额头接近太阳穴的地方，而 D 中则安置与眼眶。

在本研究的实验中，分别针对 4 种电极摆放方式做了对比试验。针对同一个被试，对他分别尝试了 4 种不同的采集方式。在实验时，额电采集法与传统眼电采集法同时使用，同步采集眼电信号。随后，以传统方式采集到的 HEO 与 VEO 做参照，将 4 种方式下抽取出的 HEO 与 VEO 与实测 HEO 与 VEO 进行了相关度计算。

对于前额采集到的电信号，A、B 方式，分别有 4 个信号通道，而 C、D 方式有 5 个信号通道。分别用独立主成分分离 ICA 的方法，对它们进行抽取，把得到的 4 或 5 个独立成分分别与实测 HEO 和 VEO 做相关度计算，得到表 3-1 的结果。

相关度	摆放方式 A	摆放方式 B	摆放方式 C	摆放方式 D
成分 1 与 HEO	0.903208	0.738512	0.431523	0.548274
成分 1 与 VEO	0.651832	0.658693	0.851649	0.845234
成分 2 与 HEO	0.832714	0.521875	0.638492	0.547803
成分 2 与 VEO	0.741515	0.880914	0.598675	0.789945
成分 3 与 HEO	0.531034	0.651234	0.772304	0.723494
成分 3 与 VEO	0.667283	0.801536	0.429840	0.524832
成分 4 与 HEO	0.685624	0.913452	0.889798	0.895034
成分 4 与 VEO	0.763817	0.782852	0.449284	0.393942
成分 5 与 HEO	——	——	0.752034	0.452356
成分 5 与 VEO	——	——	0.387494	0.582934

表 3-1 各种电极摆放策略下各独立成分与 HEO 和 VEO 的相关度

红色标出部分为具有最高相关度的独立成分

基于与 HEO 和 VEO 的相关度数据来对比 4 种电极摆放策略。不难看出，第二类电极摆放策略（C 和 D）在针对 VEO 的敏感程度上略优于第一类（A 和 B），在对于 HEO 的敏感程度上，两种检测方法没有太大差异。另外，实验前我所预期的 Ref 与 Gnd 的不同摆放位置会对噪音干扰产生的影响，在实际实验结果中，并没有明显体现，不论是 A、B 之间，还是 C、D 之间，都没有因为 Ref 与 Gnd 电极的位置改变，而对抽取 EOG 信号带来明显的差异。

因此，基于对上述实验结果的分析，为了更加方便实用，我选择了 A 和 C 两种电极摆放方式。而对比 A、C，A 的便携性与佩戴性还要优于 C，只不过 C 种方式对于 VEO 的检测效果还是要略好于 A。前文提到过，我们在使用 EOG 进行警觉度分析的方法中，从 HEO 中抽取了慢速眼动 SEM 与快速眼动 REM 作为特征，而在 VEO 中则主要抽取了眨眼作为特征。眨眼，是一个极其明显的肌电信号，即便 A 类方式抽取出的 VEO 与实测 VEO 的相关度只有 0.76，但是也足以被用来抽取眨眼信息。

最终，综合衡量实用性与抽取准确性，本研究决定采用 A 类方式作为最佳电极摆放策略。将 Gnd 与 Ref 电极分别放置于前额两侧接近太阳穴附近，而将 4 个前额信号检测电极水平排成一线，放置于前额处。

3.7 本章小结

本章首先明确了基于前额电信号分离眼电信号实验的多重目的，随后，详细介绍了整个实验的配置，包括实验使用到的软硬件设备。然后列出了实验所使用到的素材，特别是刺激序列，这是验证抽取算法是否足够健壮的一个关键设计。再然后，讲解了实验的具体流程与实际规模。在本章的最后，着重阐述了前额电极摆放策略的选择，最终给定的电极摆放策略，被应用于此后的所有眼电抽取与警觉度估计的实验中，并可以在此后的项目中配合干电极采集设备，真正发挥在实际应用中的功效。

第四章 基于前额电信号的眼电信号分离

4.1 基于 ICA 的前额电信号分离

4.1.1 盲信号分离

盲信号分离 BSS (Blind Signal Separation), 也被称作盲源分离 (Blind Source Separation), 是在源信号和传输通道参数未知的情况下, 根据输入源信号的统计特性, 仅由观测信号恢复出源信号的过程。所谓的“盲”是指源信号的特性及传输通道的特性都是未知的。例如公式 4-1:

$$\mathbf{x} = \begin{bmatrix} x_1(t) \\ x_2(t) \\ \dots \\ x_n(t) \end{bmatrix} = \mathbf{A} \cdot \mathbf{s} = \mathbf{A} \begin{bmatrix} s_1(t) \\ s_2(t) \\ \dots \\ s_n(t) \end{bmatrix} \quad (4-1)$$

其中 \mathbf{x} 是一个 n 维的观测值, \mathbf{s} 是想要求得的信号源, 共有 m 维。 \mathbf{A} 是一个 $m \times n$ 维的矩阵, 被称为混合矩阵, 所表现的是源信号的线性混合的方式。BSS 的目的即是要在 \mathbf{s} 和 \mathbf{A} 都未知的情况下, 求得源信号 \mathbf{s} 的各个分量。

盲信号分离基于源信号彼此之间毫无相关性这一假设, 比如, 信号彼此之间在统计上是独立的或者不相关的。因此, 盲信号分离可以将一组信号, 分离成另一组其他信号, 比如, 每个单独的信号的正规性被最大化, 而信号之间的正规性被最小化, 即统计独立性被最大化。盲信号分离有许多不同的方法, 比如: 主成分分析, 独立成分分析, 奇异值分解, 相关成分分析, 非负矩阵银子分解, 固定子空间分析等。

本研究中使用到的盲信号分离方法, 是独立成分分析 ICA。

4.1.2 独立成分分析的原理

在统计学中, 独立成分分析或独立分量分析 (Independent components analysis,

缩写：ICA) 是一种利用统计原理进行计算的方法。它是一个线性变换。这个变换把数据或信号分离成统计独立的非高斯的信号源的线性组合。独立成分分析是盲信号分离 (Blind source separation) 的一种特例^[42]。

独立成分分析的最重要的假设就是信号源统计独立。这个假设在大多数盲信号分离的情况中符合实际情况。即使当该假设不满足时，仍然可以用独立成分分析来把观察信号统计独立化，从而进一步分析数据的特性。独立成分分析的经典问题是“鸡尾酒会问题” (cocktail party problem)。该问题描述的是给定混合信号，如何分离出鸡尾酒会中同时说话的每个人的独立信号。

如图 4-1 所示，在一个鸡尾酒会上，有 N 个信号源记为 $s_1 \sim s_n$ (比如 N 个人正在交谈)，通常假设观察信号也有 N 个记为 $x_1 \sim x_n$ (比如有 N 个麦克风或者录音机)。无论哪个麦克风，记录下的声音都是 $s_1 \sim s_n$ 的混合信号，现在的问题是，只通过 x_1 和 x_n 记录下来的数据，如何能够分离出 s_1 和 s_n 的独立声音信号。

这即是一个已知 x ，对 $x=As$ 求 s 的问题。要解这个问题，ICA 利用了源信号具有统计独立性这一容易满足的先验条件，其目标是寻找某种变换，使得 s 的各个分量之间尽可能相互独立。




图 4-1 鸡尾酒会问题示意图

$x^{(i)}$ 的每个分量都由 $s^{(i)}$ 的分量线性表示。 A 和 s 都是未知的， x 是已知的，我们要想办法根据 x 来推出 s 。这个过程也称之为盲信号分离。

令 $W=A^{-1}$ ，那么 $s^{(i)}=A^{-1}x^{(i)}=Wx^{(i)}$

将 W 表示成，公式 4-2。

$$W = \begin{bmatrix} -w_1^T & - \\ \vdots & \\ -w_n^T & - \end{bmatrix} \quad (4-2)$$

其中 $w_i \in R^n$ ，其实就是将 w_i 写成行向量形式。那么得到：

$$s_j^{(i)} = w_j^T x^{(i)} \quad (4-3)$$

由于 w 和 s 都不确定，那么在没有先验知识的情况下，无法同时确定这两个相关参数。比如上面的公式 $s=wx$ 。当 w 扩大两倍时， s 只需要同时扩大两倍即可，等式仍然满足，因此无法得到唯一的 s 。同时如果将人的编号打乱，变成另外一个顺序，那么只需要调换 A 的列向量顺序即可，因此也无法单独确定 s 。这两种情况称为原信号不确定。

还有一种 ICA 不适用的情况，那就是信号不能是高斯分布的。假设只有两个人发出的声音信号符合多值正态分布， $s \sim N(0,1)$ ， I 是 2×2 的单位矩阵， s 的概率密度函数是以均值 0 为中心，投影面是椭圆的山峰状，如多值高斯分布。因为 $x=As$ ，因此， x 也是高斯分布的，均值为 0，协方差为 $E[xx^T] = E[Ass^T A^T] = AA^T$ 。

令 R 是正交阵 ($RR^T=R^T R=I$)， $A'=AR$ 。如果将 A 替换成 A' 。那么 $x'=A's$ 。 s 分布没变，因此 x' 仍然是均值为 0，协方差 $E[x'(x')^T] = E[A'ss^T(A')^T] = E[ARss^T(AR)^T] = ARR^T A^T = AA^T$ 。

因此，不管混合矩阵是 A 还是 A' ， x 的分布情况是一样的，那么就无法确定混合矩阵，也就无法确定原信号。

4.1.3 ICA 算法选择

使用 ICA 分离前额电信号所要解决的第一个问题是选择一种合适的 ICA 算法进行信号分离。这件事情意义重大，因为一个不合适的 BSS 算法可能会导致分离出的 EOG 中混杂了无意义的噪声和伪迹，同样也会混淆 HEO 与 VEO。

在本研究中，我们尝试了两种不同的算法，FastICA，EEGLab 工具包提供^[43]，和 Amuse，ICALab 工具包提供^[44]。这两种算法的主要不同在于，FastICA 是基于各个分量在统计上完全独立的前提，而 Amuse 只要求信号彼此之间不相关。

FastICA 与 Amuse 的输入信号都是一个数据矩阵，由 4 个观察信道采集的信号作为输入。两种算法的输出，是四个被分离后的独立信号。而这四个输出信道中，就包含了两个分别代表 HEO 与 VEO 的信道。

为了决定哪种 ICA 算法的效果更好，我将他们各自输出的 4 个独立成分分别与实测 HEO 和 VEO 做对比，计算相关度。取其中与 HEO 最相关的那个成分，作为分离后 HEO 的代表，取与 VEO 最相关的那个成分，作为分离后 VEO 的代表。然后，

评估哪种算法的分离 HEO、VEO 与实测 HEO、VEO 的相关度高，就选择哪种 ICA 算法用于后续研究实验。

在具体操作的时候，进行了两轮不同的评估。

第一轮，将完整的实验源数据（共约 12 分钟），整体作为输入，进行 ICA，然后评估相关度。

第二轮，将完整的实验源数据，按照 14 种刺激，分段成 14 个长度在 20 秒的数据，然后对这 14 段信号，分别进行 ICA，再分别对比他们与实测 HEO、VEO 的相关度。这样做是为了更为深入的分析，在各种不同干扰情况下，两种 ICA 算法的优劣。

实验的结果极其明显，基本上在所有情况下，FastICA 的表现，都优于 Amuse，所以此处就不对此做过多赘述了。综合结果看来，在第一轮对完整长度的信号样本 ICA 后，FastICA 分离出的 HEO、VEO 平均相关度与实测 HEO、VEO 是 0.87，而 Amuse 只有 0.79。在第二轮针对每一种不同刺激的详细分析中，在某些主要由眼动构成的刺激序列下，FastICA 分离出的 HEO 可以与实测 HEO 达到 0.99 的相关度，而对于干扰明显的情况下（比如皱眉头），最差也有 0.67 的相关度。各方面表现都要优于 Amuse，所以，本研究在后续，一直使用 FastICA 作为 ICA 的算法。

4.1.4 基于 FastICA 分离前额电信号

固定点算法（FastICA）是由 Aapo Hyvärinen 提出的一种 ICA 算法^[45]，以其收敛速度快、分离效果好被广泛应用于信号处理领域。该算法能很好地从观测信号中估计出相互统计独立的、被未知因素混合的原始信号。

该算法是基于定点递推算法得到的，是一种快速寻优迭代算法，用流程图的形式表现算法的流程如图 4-2。

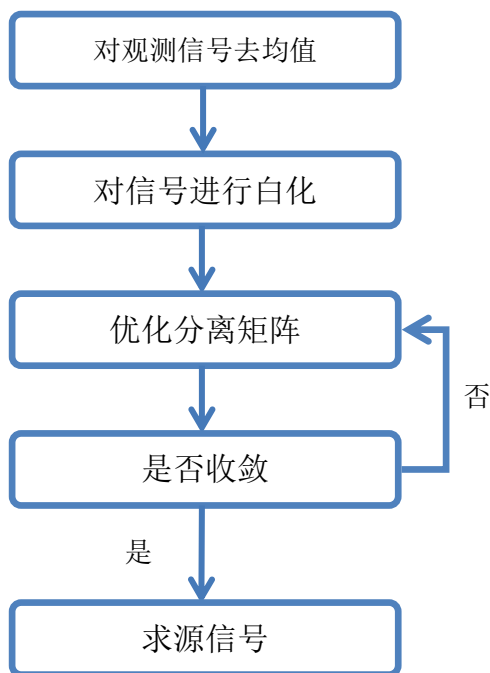


图 4-2 FastICA 算法流程图

较普通的 ICA 算法，它具有以下优点：

1、收敛速度快。在 ICA 数据模型的假设下，FastICA 收敛速度是 3 次的（或至少是 2 次的），而普通的 ICA 算法收敛速度仅仅是线性的。

2、和基于梯度的算法相比，快速定点算法不需要选择步长参数，说明该算法更加易于使用。

3、能通过使用一个非线性函数 g 便能直接找出任何非高斯分布的独立分量。而对于其他的算法来说，它们首先必须进行概率密度分布函数的估计，然后才相应地进行非线性的选择，因而必须选择非线性。

4、FastICA 算法的性能能够通过选择一个适当的非线性函数 g 而使其达到最佳化。特别是能得到最小方差的算法。

5、独立分量可被逐个估计出来，在探索性数据分析里是非常有用的，这类似于做投影追踪，这在仅需要估计几个（不是全部）独立分量的情况下，能极大地减小计算量。

在实际使用中， X 是一个 4 列的矩阵，每一列是一个采集电极输入的数据。

首先, 会对 X 进行去均值。也就是对 X 的每一个分量, 减去它的平均值, 使得观测信号 X 成为零均值变量, 这一步预处理是为了简化 ICA 算法, 并不意味着均值不能被估计出来。

$$x \leftarrow x - E\{x\} \quad (4-4)$$

然后, 对信号进行白化处理, 一般情况下所获得的数据都具有相关性, 通常都要求对数据进行初步的白化或球化处理, 因为白化处理可去除各观测信号之间的相关性, 从而简化后续独立分量的提取过程。通常情况下, 数据进行白化处理与不对数据进行白化处理相比, 算法的收敛性较好, 有更好的稳定性。

$$E\{\tilde{x}\tilde{x}^T\} = I \quad (4-5)$$

$$E\{xx^T\} = EDE^T \quad (4-6)$$

$$x \leftarrow ED^{-1/2}E^T x \quad (4-7)$$

随后, 对多个独立分量的估计, 需要将最大非高斯性的方法加以扩展。对应于不同独立分量的向量在白化空间中应是正交的, 算法第 6 步用压缩正交化保证分离出来的是不同的信号, 但是该方法的缺点是第 1 个向量的估计误差会累计到随后向量的估计上。

迭代算法找到一个使得数据 x 投影 $w^T x$ 的非高斯最大化的权重向量 w 作为方向。函数 $g(\cdot)$ 是一个非二次非线性函数 $f(\cdot)$ 的衍生。Hyvärinen 列举了两个不错的函数选择:

$$f(u) = \log \cosh(u); \quad g(u) = \tanh(u); \quad g'(u) = 1 - \tanh^2(u) \quad (4-8)$$

$$f(u) = -e^{-u^2/2}; \quad g(u) = ue^{-u^2/2}; \quad g'(u) = (1 - u^2)e^{-u^2/2} \quad (4-9)$$

实际分析中, 选择了第二个函数, 因为他具有更高的鲁棒性。

在每一次迭代中, 首先给一个随机初始化的权重向量 w 。

然后, 迭代计算:

$$w^+ \leftarrow E\{xg(w^T x)\} - E\{g'(w^T x)\}w \quad (4-10)$$

$$w \leftarrow w^+ / \|w^+\| \quad (4-11)$$

如果 w 没有收敛, 则继续迭代。

否则, 求出源信号。

$$s_j = w_j^T x \quad (4-12)$$

则 S 就是分离后的独立成分, 其中会有独立的 HEO 与 VEO 分量。

4.2 验证前额电信号中存在独立眼电信号

为了验证前额电信号中，可以分离出独立的眼电信号，首先将输入数据，按照每一种不同的刺激，分成 14 组，每一组长 20 秒，代表了在一种给定刺激下，所收集到的前额信号。然后，针对每一种刺激，单独分析抽取后信号与实测 HEO 与 VEO 的相关性，如果相关性足够高，则认为在该刺激动作下，前额信号是足以被抽取可替代实测 HEO 与 VEO 的眼电分量的。具体流程如图 4-3 所示：

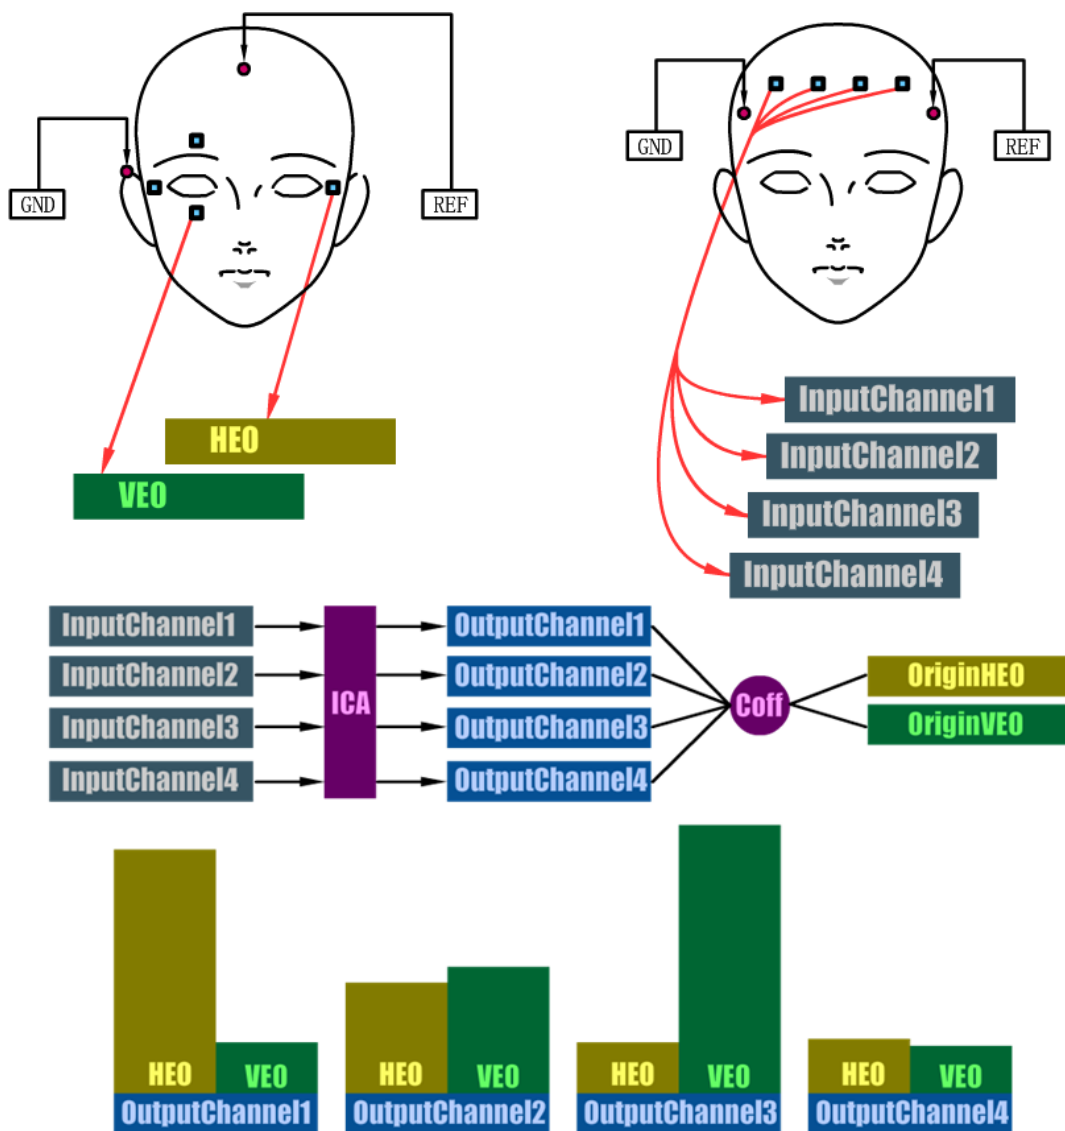


图 4-3 前额信号中抽取 EOG 的流程示意图

如图 4-3 所示输入数据有 4 个信号通道，分别代表前额的 4 个采集电极的输入，这四个信道在经过 ICA 之后，被分离为 4 个独立分量，将他们分别与实测 OriginHEO 和 OriginVEO 做相关度计算，则得到每一种刺激下，抽取出的 EOG 的效果。

图 4-4，是在某一给定刺激下，实测 EOG，原始输入信号，与 ICA 分离后的各个分量的对比图。

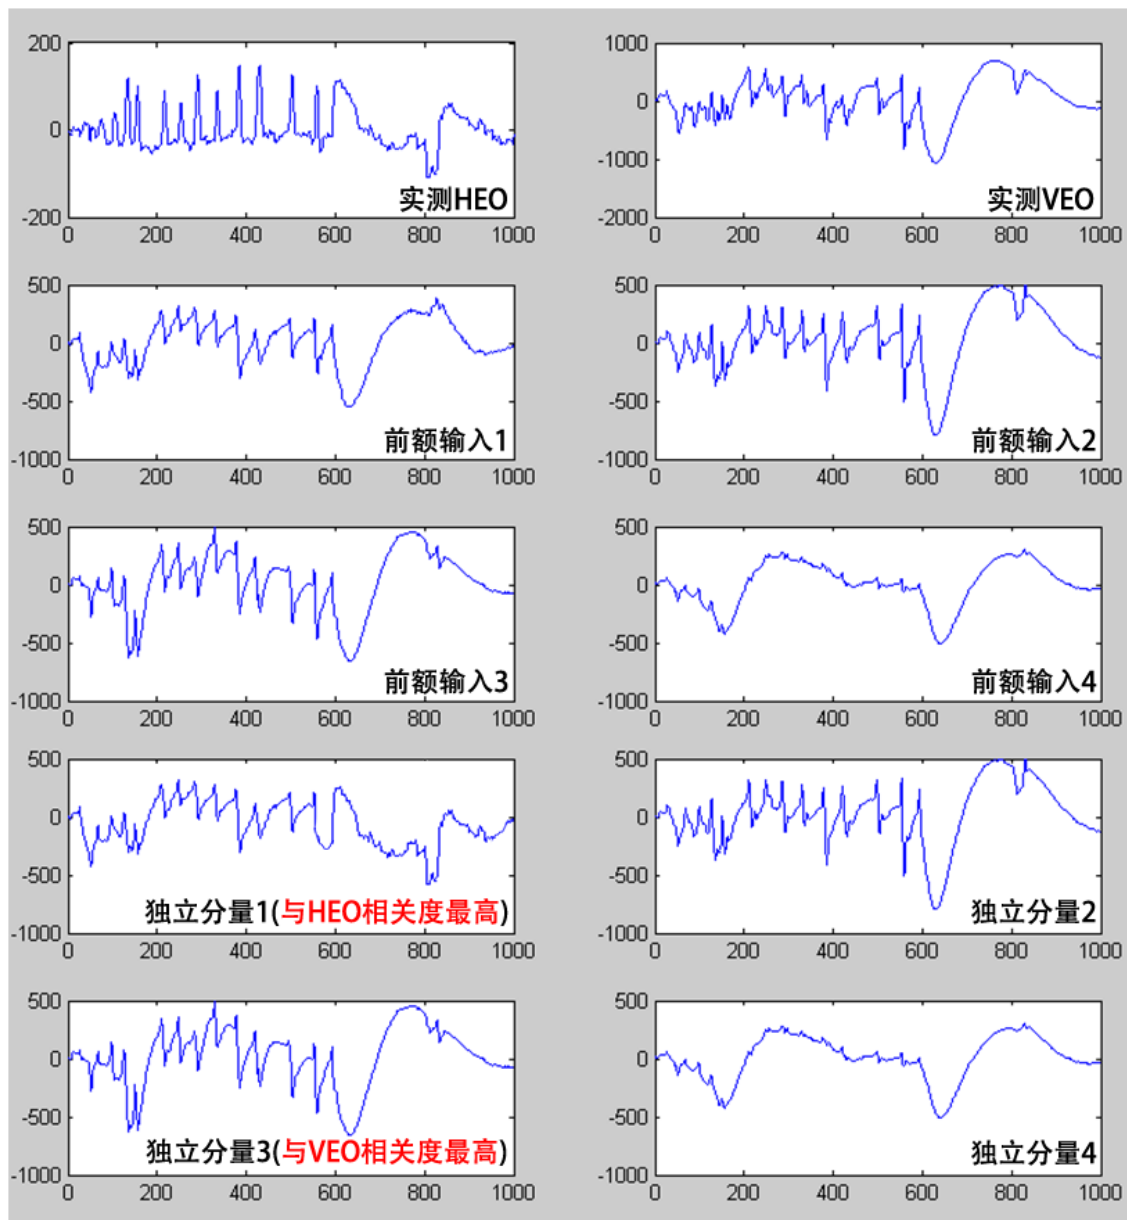


图 4-4 前额输入信号，分离信号与实测 HEO、VEO 信号的对比图

最终针对 14 种不同的脸部动作，将 ICA 分离出的眼电信号与实测 HEO 与 VEO 计算相关度，所得数据如图 4-5 所示。数据显示，对于混有脸部肌电干扰的信号，ICA 可以很好的从中分离出 HEO 与 VEO，平均相关度达到 0.82。所有 14 种刺激下抽取 HEO 与实测 HEO 的平均相关度是 0.9036，抽取 VEO 与实测 VEO 的平均相关度是 0.7862。在一些基本仅含有眼动的刺激动作下，如左右看这一动作，HEO 的相关度高达 0.99，而在一些面部肌肉干扰极其强烈的动作下，如抬眉头，HEO 的相关度有 0.51。考虑到在正常的警觉度估计应用场景与实验中，诸如抬眉头这种强肌电干扰动作，出现的频率很低，持续时间很短，并且此时肌电不仅干扰了前额信号，同样干扰了实测眼电信号，而在被试面部动作基本正常的条件下，经 ICA 分离抽取的 EOG 与实测 EOG 的相关度是很高的，能达到 0.9 以上，所以，完全可以认为在前额采集的电信号中，存在可以被独立抽取处理的 HEO 与 VEO 眼电信号。




图 4-5 每一种刺激下分离最接近 HEO 与 VEO 的独立成分与 HEO、VEO 的相关度

结果如图 4-5 所示。纵轴为与 HEO 和 VEO 的相关度，横轴是 14 种不同的动作刺激，依次为，抬头低头、摇头、咬牙、闭眼睁眼、转动眼球、左右看、上下看、咽口水、眯眼、抬眉毛、皱眉头、抬嘴角、挠脸颊、张嘴闭嘴。

4.3 从前额电信号中分离眼电信号的一般过程

在验证了前额眼电中存在独立 HEO 与 VEO 这一假设后,本研究提出一种方法,在无任何先验数据的情况下,可以抽取出足以代表实测 HEO 与 VEO 的信号,并经过判定算法,从其中选出两个分别代表 HEO 与 VEO 的分量,最后提供给基于 EOG 的警觉度估计系统使用。

整套方法的简要流程如图 4-6 所示:



图 4-6 从前额信号中抽取 HEO 与 VEO 的一般流程图

该方法主要由如下三部分构成:

- (1) 基于 ICA 独立成分分析,将输入的 4 个采集信道,分离独立分量。这一步,采用的 ICA 算法是 FastICA。
- (2) 基于眨眼检测的算法,根据眨眼这一显著特征在独立分离中的出现情况,区分出独立分量中哪些可以代表 HEO,哪些是 VEO。
- (3) 基于 SVM 去除肌电伪迹的算法,评判独立分量中肌电比重,从而分别在候选 HEO 与 VEO 代表中,挑选出肌电比重最少的那一个分量,作为最终选择的 HEO 或 VEO。

4.4 区分 HEO 与 VEO 信号

眨眼是正常人一个极其常见的生理行为,Monster AW 早在 1978 年就做了一项长期监测正常人眨眼行为的研究^[46]。在对正常人的眨眼行为进行了长时间(14 小时以上)的监控之后,研究指出,正常人的眨眼行为,存在一些周期性的趋势。正常人眨眼频率的平均值,在以 10 分钟到 2.5 小时的时间范围之内,会在每分钟 2 次,到每分钟 50 次之间变化。主要可以将观测到的眨眼频率归为以下三组:(1) 6 次以下每分钟,(2) 8-15 次每分钟,(3) 20-30 次每分钟。这些不同的分组,多多少少与一些个体不同的行为状态有关系。但是,不论在何种状态下,正常人的平均眨眼行为间隔,在 4-8 秒,平均一分钟 8 次。

在我们实验的实际现象中，一次眨眼行为，主要由眼睑的闭合张开构成，属于垂直眼动，会在 VEO 信号中看到明显的波形变化，但在 HEO 信号中却反映微弱。而之前基于 EOG 的警觉度检测算法中，也是基于 VEO 进行眨眼特征的提取的。

基于以上生理特征，本研究将眨眼特征作为区分潜在 HEO 与 VEO 的判定方法，针对 4 个 ICA 输出的独立成分，分别使用眨眼特征抽取算法，统计眨眼次数，并将眨眼次数出现频率最高的两个独立成分作为候选的 VEO 信号，出现频率最低的则是候选 HEO 信号。

具体做法在 2.3.3 中提及的眨眼特征提取算法基础上，专门针对眨眼次数的提取，做出改进。

(1) 在一个眨眼波形上，首先对齐进行差分，定义两个阈值 V_{cl} 和 V_{op} ，前者用来判断眼睑闭合，后者用来判断眼睑睁开，都是作用在差分后的波形上的。算法侦测到的一个眨眼事件由四个点来定位，分别是两个超过 V_{cl} 的点，和两个低于 V_{op} 的点，为了方便分别记这四个点为 x_1, x_2, x_3, x_4 。由于原算法中将 x_1 作为眨眼和闭眼的起始点， x_2 作为闭眼结束点， x_3 作为睁眼起始点， x_4 作为眨眼和睁眼的结束点，这样设定使得侦测到的眨眼长度、睁眼时长、以及闭眼时长，都比实际的眨眼要短。为了使实际侦测到的这些参数与实际相符，本研究采用的方法中对这四个点进行了扩展。在找到这四个点以后，我们将 x_1, x_2 由 V_{cl} 的位置扩展到 E_{cl} 的位置，将 x_3, x_4 由 V_{op} 的位置扩展到 E_{op} 的位置， E_{cl}, E_{op} 是比 V_{cl} 和 V_{op} 更接近 0 的两个值。

(2) 算法中虽然使用了参数 A_{min} 来区别眨眼和眼动，但 A_{min} 这个值是与 EOG 的电压幅值来比较的。因为对数据进行差分这一步骤消除了 EOG 电压幅值漂移的影响，但是这里重新引入了与电压幅值的比较，就等于再次加入了这一影响。因此，我们将 A_{min} 的比较对象改成以下规则：

$$\begin{aligned} V_1 &= |data(x_1) - data(x_2)| \\ V_2 &= |data(x_3) - data(x_4)| \end{aligned} \quad (4-13)$$

对 $(V_1+V_2)/2$ 和 A_{min} 比较大小。

其中 $data(x_k)$ 是点 x_k 处的电压幅值，因为这引入了差值计算，所以通过这种手段，即使电压往负向漂移，产生的眨眼信号仍然不会漏检。

如图 4-7，图中红线表示眨眼开始、绿线表示眨眼结束，上图是原始信号，下图是差分信号。红线与绿线之间的便是被检测的一次眨眼行为。




图 4-7 眨眼波形分析图

在本方法中,我们需要选择一些参数,其中最重要的参数是 V_{cl} 和 V_{op} 这两个阈值,其他还有 A_{min} 、 pu 、 E_{cl} 、 E_{op} 、 $combTH$ 。对于 V_{cl} 和 V_{op} 这两个参数,如果选的大小不一样,则会对最后的结果产生很大的影响。理论上最好的选择方法是让系统进行自适应的选择,即先对测试者采取一段数据,针对这段数据中眨眼的情况,对这两个参数进行适当的调整,对于 A_{min} 也是如此。但是为了方便,本研究中未进行这一步骤,而是对所有的测试者都采用同一个平均实验结果较好的参数,同时考虑到抽取眨眼特征的目的是为了区分 VEO 与 HEO,刻意提升了 V_{cl} 与 V_{op} 的阈值,以此提升了一次眨眼行为被检测到的门槛。我们使用的参数如下:

$$V_{cl} = 15, V_{op} = -15, A_{min} = 100, pu = 1.5, E_{cl} = 3, E_{op} = -3, combTH = 0$$

4.5 SVM 选择 HEO 与 VEO 信号

使用 SVM 选择 HEO 与 VEO 信号的思想,来自于基于 SVM 去除肌电 EMG 与眼电 EOG 伪迹的研究。本实验室的 George 曾使用这一方法,滤除脑电 EEG 信号中的

肌电 EMG 与眼电 EOG 伪迹^[47]，此处将借鉴这一方法，对 EOG 与 EMG 信号抽取特征进行分类，将分类为 EOG 的信号作为抽取出的 HEO 与 VEO 使用。

SVM 用于分类的特征有两个，一个是频域上的功率谱密度，使用 Welch 算法计算，一个是时域上的 AR 模型自相关系数。之后，一个 RBF 内核的 SVM 会被用来分类 EOG 与 EMG。

4.5.1 Welch 算法计算功率谱密度

Peter D. Welch 与 1967 年提出了一个得到广泛应用的非常有效的，基于傅里叶变换 (FFT) 来计算数字信号功率谱密度 (PSD) 的方法。功率谱密度 PSD 是一个被用来描述给定信号的功率在不同频率范围内分布的数量，单位是 V^2/Hz 。

算法本身的工作原理如下：输入信号是一个长度为 N 的向量 $x, x[j], j = 0, \dots, N-1$ ，将它分为长度是 L 的 K 段，允许每一段之间，有一个长度为 D 的重合区域。图 4-8 展示了输入信号是如何被划分的。




图 4-8 输入信号的划分示意图

随后对于每一段信号，乘以一个对应的长度为 L 的时窗 $w[j]$ ，在对这个积使用离散傅里叶变换，这样就得到他们的样本周期图。离散傅里叶变换的形式定义如下^[49]：

$$X[k] = \sum_{n=0}^{N-1} x[n] e^{-i(2\pi/N)kn} \quad (4-14)$$

将它用于给定时间窗的乘积，得到：

$$A_k[n] = \sum_{j=0}^{L-1} x_k[j]w[j] e^{-i(2\pi/L)nj} \quad (4-15)$$

使用这些傅里叶系数，得到一个 K 修改后的时窗：

$$I_k[f_n] = \frac{1}{U} |A_k(n)|^2 \quad (4-16)$$

其中：

$$f_n = \frac{n}{L} \quad n = 0, \dots, L/2 \quad (4-17)$$

$$U = \frac{1}{L} \sum_{j=0}^{L-1} w^2(j) \quad (4-18)$$

最后，功率谱密度被估计为所有这些样本周期图的平均。

$$P(f_n) = \frac{1}{K} \sum_{k=1}^K I_k(f_n) \quad (4-19)$$

估计使用 Welch 算法计算 PSD 的时间复杂度十分简单。计算每一 $I_k(f_n)$ 大约需要 $\theta(L \cdot \log(L))$ ，这就是快速傅里叶变换的复杂度。最后考虑到总共有 K 个这样不同的模式，所以，最终时间复杂度是：

$$\theta(Welch) = \theta(L \cdot \log(L) \cdot K) \quad (4-20)$$

4.5.2 AR 模型计算自相关系数

自回归 (AR) 模型，采用了一个参数化的数学模型，来对采样到的时序信号进行建模。应用领域极其广泛，涉及到频谱分析、数据压缩和模式分类的特征提取。在 EEG 分析中，AR 模型被用于做模式分类的特征提取，作为一种特征抽取的技术^[50]。基于运动想象的控制室 AR 模型在这方面的一个很好的成功案例，模型的相关系数被

证明对于区分左手或右手运动的想象极其有用^[51]。

AR 模型需要一个合理的传递函数的形式，所有的自由参数都在它的分母上，比如一个无限脉冲响应。如果这些参数的值随着每一次采样更新，就被成为一个自适应滤波器。如果这些参数针对整个采样时间来说，是被事先指定好的，则是非自适应的。由于非自适应的 AR 模型相对自适应的灵活度远远不够，并且无法适应短期变化或者存在异常的信号，所以他们要求信号要是稳定的。研究证明对于短时 EEG 信号片段来说，这一要求是完全可以被满足的，所以非自适应的 AR 模型被用于对 EEG 采用信号的建模处理^[52]。

下面将详细介绍 AR 模型在这方面的具体应用。一个可以使用 AR 模型的基本思想是，一个当前的时序采样 s_n 可以被表示为一系列前 p 个时序采样的线性组合。如公式 4-21 所示：

$$\tilde{s}_n = - \sum_{i=1}^p a_{pi} s_{n-1} \quad (4-21)$$

最大的挑战是如何为模型估计出正确的参数 a_{p1}, \dots, a_{pn} ，如果模型对于给定的信号采样可以有很好的拟合，那么它也完全可以被用于预测未来的采样 s_n ，以及它的后继。实际 s_n 的值与其预测值 \tilde{s}_n 之间的差异，被叫做前向预测误差， e_{pn} 。

$$e_{pn} = s_n - \tilde{s}_n = s_n + \sum_{i=1}^p a_{pi} s_{n-1} \quad (4-22)$$

预测误差的能量 E ，基于整个数据序列 s_1, \dots, s_n 的预测误差的平方，被定义为：

$$E = \frac{1}{N} \sum_{n=1}^N e_{pn}^2 \quad (4-23)$$

这个公式可以被用来寻找模型参数的估计。基于最小二乘误差准则，可以找到一系列参数 a_{p1}, \dots, a_{pn} 使得 E 最小。

$$\frac{\partial E}{\partial a_{pi}} = 0, \quad 1 \leq i \leq p \quad (4-24)$$

这样得出的最小预测误差 E_p 是。

$$E_p = \left(\frac{1}{N} \sum_{n=1}^N s_n^2 \right) + \sum_{i=1}^p \left(\frac{1}{N} \sum_{n=1}^N s_n s_{n-i} \right) a_{pi} \quad (4-25)$$

这可以最终被用来解尤利-沃克方程，从而得到 AR 模型的参数。具体如下：

$$\begin{bmatrix} \tilde{R}_0 & \tilde{R}_1 & \tilde{R}_2 & \cdots & \tilde{R}_p \\ \tilde{R}_1 & \tilde{R}_0 & \tilde{R}_1 & \cdots & \tilde{R}_{p-1} \\ \tilde{R}_2 & \tilde{R}_1 & \tilde{R}_0 & \cdots & \tilde{R}_{p-2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \tilde{R}_p & \tilde{R}_{p-1} & \tilde{R}_{p-2} & \cdots & \tilde{R}_0 \end{bmatrix} \begin{bmatrix} \tilde{R}_0 & \tilde{R}_1 & \tilde{R}_2 & \cdots & \tilde{R}_p \\ \tilde{R}_1 & \tilde{R}_0 & \tilde{R}_1 & \cdots & \tilde{R}_{p-1} \\ \tilde{R}_2 & \tilde{R}_1 & \tilde{R}_0 & \cdots & \tilde{R}_{p-2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \tilde{R}_p & \tilde{R}_{p-1} & \tilde{R}_{p-2} & \cdots & \tilde{R}_0 \end{bmatrix} \begin{bmatrix} 1 \\ a_{p1} \\ a_{p2} \\ \vdots \\ a_{pp} \end{bmatrix} = \begin{bmatrix} E_p \\ 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix} \quad (4-26)$$

其中对于一组有限数据序列 s_1, s_2, \dots, s_N , \tilde{R}_i 就是：

$$\tilde{R}_{|i-j|} = \frac{1}{N} \sum_{n=1}^N s_{n-i} s_{n-j} \quad 0 \leq i \leq p \text{ and } 1 \leq j \leq p \quad (4-27)$$

尤拉-沃克方程组定义的线性系统方程式，可以使用例如高斯消去法的方法解决。还有其他的递归算法专门解决这组方程，比如 Levinson-Durbinso 算法^[53]，比起普通的高斯消元法，它更有效率一些。不过，为了分析在最坏情况下计算 AR 相关系数的复杂度，还是假定使用了高斯消元法。这样最终得出计算 AR 相关系数的时间复杂度是：

$$\theta(AR) = \theta(Modelsize^3) + \theta(Modelsize \cdot datapoints) \quad (4-27)$$

4.5.3 SVM 分类 EMG 与 EOG

本研究最终使用了 RBF 内核的支持向量机（使用了 libSVM 工具包的实现^[54]）来进行分类，将候选 HEO 或 VEO 分为 EMG 与 EOG，之所以这样选择有如下几个理由。

第一，SVM 非常有聚合性，是不太容易产生噪声与异常点的，这一点对于我们的项目是非常重要的。因为，实验中被试是不断被要求作出各种面部动作干扰的，所采集到的信号必然受到很多噪声与异常的干扰。SVM 是一个正则分类器，这就意味

着,可以控制学习分类器的复杂性,避免过度学习。还有在受到干扰比较强烈的数据时,SVM可以保持很好的泛化性能。第二,SVM在高维特征向量的处理上,有很好的鲁棒性,而我们实验中说使用的特征向量,位数都比较高。

因此选择一个能满足这些需求的分类器极其重要。我们使用的实验数据时很不稳定的,为了验证在各种情况下对于EOG的抽取情况,实验特别要求被试做出了各种会含有强烈机电干扰的动作。

在对于SVM内核的选择上,基本基于Matlab SVM工具箱的相关说明^[55],其中对于如何选择线性内核,以及如何使用一个非线性的RBF给出了详细的讨论。讨论中指出,当训练数据的数量超过特征数据时,需要使用RBF内核,并且将数据映射到一个更高的维度空间,是没有任何实际意义的,也不会带来更好的结果。因此,本文最终采用了RBF内核。

对SVM的训练数据一部分来自本次试验所采集的前额信号,另一部分来自之前实验室所做的去除机电伪迹的实验数据,共计2000组随机选择的信号段,一半主要是EOG,另一半是EMG。SVM的相关参数设置,也参照了之前进行的去除机电伪迹的相关经验。结果表明,SVM对于EOG和EMG的分类精度,可以达到90%以上。

4.6 EOG 抽取算法性能评估

为了评估整套EOG抽取算法的实际性能,设计了如下方式进行评估。

(1) 在有实测HEO与VEO作为先验数据的情况下,将ICA分离出的各个分量,与实测HEO和VEO进行对比,针对每一种刺激,挑选出与HEO和VEO相关度最高的分量,作为HEO_1与VEO_1的独立分量。

(2) 在没有实测HEO与VEO作为先验数据的情况下,按照章节4.3中所阐述的流程抽取出HEO_2与VEO_2。

(3) 将HEO_2、VEO_2与实测HEO和VEO计算分别相关度。

(4) 因为在EOG抽取算法中,输入信号有4个通道,ICA分离出的独立成分也是4个,这4个中有一个被最终挑选为HEO另一个挑选为VEO。第一步骤中,因为有先验的实测EOG数据作为参照,所以挑选出的HEO_1,VEO_1对应的信道是最优的,将这一最优序列,与第二步骤中抽取出的HEO_2,VEO_2对应的信道编号进行对比,就可以知道第二步骤中抽取出的EOG,是不是可以选择的最优情况。

实际数据表明,抽取后HEO_2与实测HEO的平均相关度,可达0.8457,VEO_2与实测VEO的平均相关度有0.7697。抽取后的HEO_2、VEO_2所选择的信道与

HEO₁、VEO₁ 的重合度，有 90%。

一组实际数据如图 4-9 所示：




图 4-9 抽取 HEO、VEO 与实测 HEO、VEO 的相关度

红色框表示所选择的独立分量并不是最优的 HEO 或 VEO 代表

4.7 本章小结

本章首先详细介绍了基于 ICA 的额电信号分离，然后将 ICA 分离出的信号与实测 EOG 进行对比，验证了额电中存在独立 HEO 与 VEO 分量这一假设。随后，提出了一整套从前额电信号中抽取 HEO 与 VEO 的方法，经过 ICA，基于眨眼的 HEO 与 VEO 划分，以及基于 SVM 的 EOG 与 EMG 分类，最终从 EOG 中抽取出独立的 HEO 与 VEO 分量，可以提供给基于 EOG 的警觉度分析方法，进行警觉度的研究。

第五章 基于前额眼电信号的警觉度实验系统及优化

5.1 图片实验

基于图片的警觉度实验，是一个单调的基于视觉任务的警觉度实验。实验环境与第四章中所介绍的眼电实验类似，在一间隔音房间中进行，室内照明亮度正常，通风良好，温度 27 摄氏度左右，相对湿度 60% 左右。目的在于给被试创造一个舒适的环境，更易困倦，从而可观测到不同状态下的警觉度。

实验过程中，被试被要求坐在显示器前，根据屏幕上出现的交通标志的颜色，按动手中控制器上相同颜色的按钮。实验素材由 640 个交通图标构成刺激图片序列，一共 4 种颜色，每个颜色有 160 个图标。实验中，每一次会随机出现一个图标，持续 500ms，每次刺激持续 5-7 秒，其余时刻是黑屏。这样设计是为了要求被试必须快速做出反应，当被试精神涣散的时候，很容易测出延迟反应，或者错误的按键。这些都会作为警觉度标定的参照。实验过程中的刺激序列如图 5-1 所示，部分交通标志刺激图片如图 5-2 所示。

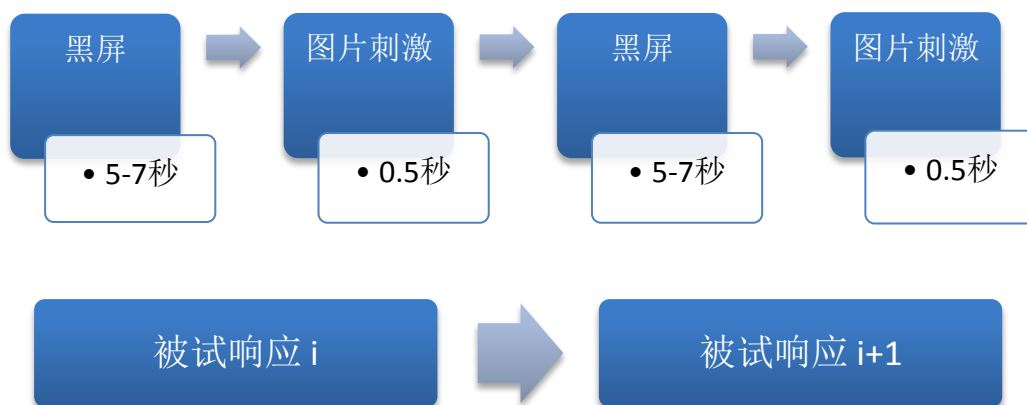


图 5-1 实验刺激序列



图 5-2 交通标志刺激图片

实验一般在午饭后 13:00-15:00 进行，因为这一时间最容易诱发被试精力疲劳。每次实验持续 40-60 分钟，被试在经过简单的适应过程后，每人在不同天内至少参与两次实验。被试在实验前一天的睡眠时间不能超过 8 小时，并且不能饮用含咖啡因，酒精等会影响大脑正常工作的饮料。每次实验过程中，所有的图片刺激序列以及被试响应序列，通过 STIM 系统记录。

如果评估基于眼电数据的警觉度监测算法的性能，就需要知道被试在不同时刻的真实警觉度状况。在本实验中，警觉度的标定，基于被试的按键相应速度，以及在年检的准确度，由于已有的研究表明，人的警觉度变化平均周期大于 4 分钟^[56]，因此可以基于一段时间内的被试平均响应错误率来标注警觉度状态。在本实验中，被试当前的警觉度通过当前时刻以及周围 2 分钟内的局部平均响应错误率来标注，且每隔 2 秒标注一次，错误率越高则警觉度越低。

5.2 实时跟踪实验

基于图片的警觉度实验，可以清晰的反映出被试的警觉度变化状态，并且易于采用被试的反馈数据进行警觉度的标定，并且，由于一般人的警觉度变化周期为 4 分钟，所以，虽然图片序列是离散的，大概没十几秒刷新一次，但是也足以反映 4 分钟区间内的基本警觉度状态。

但是，每基于 10s 左右的一次刺激，难以在更加精细的时间颗粒度上表现出被试

的警觉度变化，所以，本为对此提出了一种改进方法，并将其实现。这就是，实时跟踪警觉度实验。

这一实验的基本环境与基于图片的警觉度实验基本相同，但是对于被试所采用的刺激任务完全不一样。如图 5-3 所示，是实时跟踪警觉度系统的软件截图。

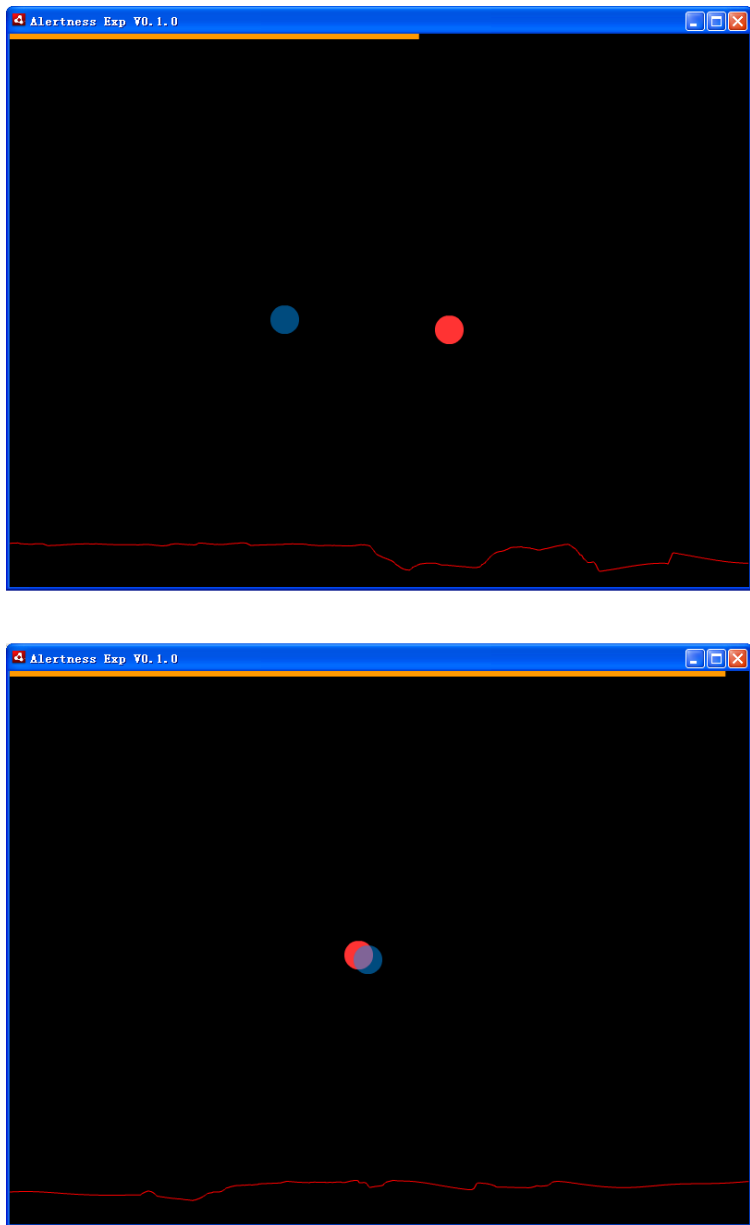


图 5-3 实时跟踪警觉度系统的软件截图

在警觉度实验过程中，屏幕上会出现红色与蓝色两个亮斑，其中，红色的亮斑由

算法控制，基于多次正弦叠加与随机扰动，在一个距离屏幕中心一定约束半径内，随机漂移。与此同时，被试被要求控制蓝色光斑实时跟踪红色斑点，并尽量与之重合。而被试的警觉度，则会基于红色与蓝色光斑的中心距离做出标定。

实验所采用的刺激输出设备是 LED 屏幕，为 22 寸，距离被试约 50cm。这样可以保证被试每次转动眼睛时视线移动范围基本一致，同时也确保有一定的眼球可转动范围。

被试的反馈，采用轨迹球进行输入，被试需要滚动轨迹球来控制蓝色光斑在屏幕上的位置，为了使被试可以熟悉轨迹球的操作，在实验开始前会预留一定时间给被试上手熟悉。为了保证系统所给出的警觉度的实时性，采样频率最高可达 100Hz。

实时跟踪系统，被简单实现并用于警觉度实验。基于实验数据与被试的主动反馈分析，实时跟踪系统在时间层面上，确实可以更为细致的标定出被试的警觉度变化，但是仍旧存在如下几个问题：

(1) 实时系统要求被试高度集中精力，而实际实验中发现，被试一般难以长久的保持控制轨迹球的高度注意力，所以，这种实验，难以在一个较长时间区域内进行测试，一般被试在 20 分钟以上，就会出现明显疲劳。

(2) 一般人警觉度变化平均周期大于 4 分钟，是一个较为平缓的过程，而实时跟踪系统，在提供了较小时间颗粒度精度的同时，也更容易受到被试某些干扰动作的影响，所以如何采用一种较好的策略，来使用实时系统提供的警觉度数据进行警觉度的标定，仍值得进一步研究。

此后，将会在以上问题的基础上，对实时采集实验进行进一步的完善。

5.3 本章小结

本章主要对比了两种警觉度实验方法，一种是基于图片刺激的警觉度实验方式，另一种是实时跟踪的警觉度实验方式。二者在刺激任务的设计与警觉度的标定方法方面，有着很大的差异，因此也带来了满足了不同的实验需求与效果，最终本章对比了两种实验方式的利弊，并提出了今后改进的方向。

第六章 全文总结

本章将对全文进行总结，归纳本研究在基于眼电的警觉度分析领域所做的只要工作和创新点，然后对今后的工作进行展望，给出基于前额眼电警觉度分析的进一步研究方向。

6.1 本论文的主要结论与创新点

本论文主要针对基于前额信号抽取的警觉度估计的关键技术问题进行了分析研究，侧重研究如何从前额采集到的电信号中分离出独立的 HEO 与 VEO 信号并给出了具体的解决方案。主要结论与创新点如下：

(1) 本文提出了在前额电信号中存在独立 HEO 与 VEO 这一假设。并通过实验证明了，针对前额电信号进行 ICA 处理后，可以从中得到 HEO 与 VEO 独立分量，从而验证了这一假设。

(2) 基于前额信号进行警觉度分析的一大核心目标是，提高整套系统的实用性，因此，必须对传统眼电采集方法的电极摆放进行改进。本文针对实际应用的需求，设计了各种前额电极摆放策略，并经过实际试验，给出了各种策略的性能评估，最终得出了一种平衡实用性与鲁棒性的最优前额电极摆放策略。

(3) 本论文提出一套完整的方法，经过前额电信号的采集，基于 ICA 的独立成分分析，基于眨眼检测算法的 HEO 与 VEO 分类，基于 SVM 肌电去伪迹的 EOG 与 EMG 分类，最终将独立 HEO 与 VEO 成分，从前额信号中提取出来，以供后续基于眼电的警觉度估计算法使用。

(4) 本论文尝试提出一种实时跟踪的警觉度实验模式。目前实验中采用的实验系统，是基于图片刺激序列的，被试被要求当出现某一图片时，及时准确的做出相应的反应。改进系统，要求被试使用轨迹球不断跟踪屏幕上随机漂移的亮斑，在警觉度标定的实时性方面大大提升。

6.2 未来工作展望

2012年3月交通运输部、公安部、国家安全生产监督管理总局联合召开“道路客运安全年”活动动员部署电视电话会议，贯彻中央、国务院关于加强道路交通安全工作的决策部署。2012-2013年全国仍具有十几条新建高铁项目开工，这些都为疲劳检测系统，提供了巨大的应用平台与空间。

在算法层面上，本研究后续的一个主要努力方向是，设计一套基于前额采集电信号的在线警觉度分析算法。整合前额眼电抽取技术与基于眼电的警觉度估计技术，设计一个算法，可以实时的进行警觉度估计。这样，将进一步推进警觉度监测系统在实际中的应用。此后，还可以在此基础上，进一步进行研究，提出基于警觉度模型的预测算法，进一步增强警觉度估计的实用价值。

在应用层面上，随着干电极采集技术的日趋完善，配合干电极头带，结合前额电信号采集技术，将采集分析算法移植入嵌入式系统中，可以真正做到简便实用的警觉度预测。

在系统层面上，将努力实现一整套完善的，多模态警觉度估计系统。整合眼电、脑电、情感等多种特征，结合视频监控、干电极采集等多种技术，将每种方法的优劣进行互补，最终实现一套集各种技术于大成的警觉度监测预测系统。

最后，除却警觉度分析，基于前额信号的眼电信号提取技术，同样可以被用于各种商用、民用领域，比如，基于前额信号帮助分析运动员的注意力状态等等。这一便捷的信号采集抽取技术，必将在未来发挥出更多的实际应用意义。

参 考 文 献

- [1] 过秀成, 道路安全学. 南京: 东南大学出版社. 2001, pp.31-32.
- [2] D. Dawson, N. Lamond, K. Donkin, Quantitative similarity between the cognitive psychomotor performance decrement associated with sustained wakefulness and alcohol intoxication[C]. Proceedings of the Third International Conference on Fatigue and Transportation, Fremantle, Western Australia. 1998: 44-45.
- [3] 陈伟, 疲劳驾驶: 法国人的防范之策. 决策咨询. 2000, 10:43-44.
- [4] 苗泽青, 谷志杰, 交通安全法规及管理. 北京: 人民交通出版社, 2002: 100-101.
- [5] 于洪生, 高速铁路司机作业前后疲劳状况调查分析, 疾病检测与控制杂志, 2010, vol.4 ,No.7.
- [6] S. Makeig and M. Inlow, Lapses in Alertness: Coherence of Fluctuations in Performance and EEG Spectrum[J]. Electroencephalography and Clinical Neurophysiology. 1993, 86(1): 23-35.
- [7] R. R. Knippling, J. S. Wang, J. N. Kaniathra, Current NHTSA Drowsy Driver R&D. Proceedings of the Fifteenth International Technical Conference on the Enhanced Safety of Vehicles, Melbourne, Australia, 1996.
- [8] D. F. Dinges, M. M. Mallis, G. J. W. Maislin. Final Report: Evaluation of Techniques for Ocular Measurement as an Index of Fatigue and as the Basis for Alertness Management, National Highway Traffic Safety Administration, Report No DOT HS 808 762.
- [9] R. Grace, V. E. Byrne, J. M. Legrand, et al., "A machine vision based drowsy driver detection system for heavy.
- [10] Q. Ji and X. Yang, "Real-Time Eye, Gaze, and Face Pose Tracking for Monitoring Driver Vigilance", Real-Time Imaging, 2002, 8, pp.357-377.
- [11] Pilot Test of Fatigue Management Technologies - Final Report. <http://www.fmcsa.dot.gov/facts-research/research-technology/publications/pilot-test/fmt-selected-for-study.htm>.
- [12] D. F. Dinges, M. M. Mallis, G. Maislin et al., "Final Report: Evaluation of Techniques for Ocular Measurement as an Index of Fatigue and as the Basis for Alertness Management," National Highway Traffic Safety Administration. USA., 1998, Report No. HS 808762.
- [13] faceLABv5. <http://www.seeingmachines.com/product/faceLAB/>.

- [14] S. Boveris, "Driver fatigue monitoring technologies and future ideas," Proceedings of AWAKE Road Safety Workshop, 2004.
- [15] M. Atienza, J. L. Cantero, R. Stickgold 2004. Posttraining sleep enhances automaticity in perceptual discrimination. *J. Cogn. Neurosci.* 16:53–64B.
- [16] K. Kaida, T. Akerstedt, G. Kecklund, J. P. Nilsson, J. Axelsson, Use of subjective and physiological indicators of sleepiness to predict performance during a vigilance task. *Ind Health.* 2007;45(4):520–526.
- [17] N. A. Wright, A. S. McGown. Involuntary sleep during civil air operations: wrist activity and the prevention of sleep. *Aviat Space Environ Med* 2004; 75:37– 45.
- [18] Y. Kim, H. Baek, J. Kim, H. Lee, J. Choi and K. Park Helmet-based physiological signal monitoring system *Eur. J. Appl. Physiol.*, vol. 105, pp. 365-372, 2009
- [19] T. C. Chieh, M. M. Marzuki, H. Aini, H. S. Farshad, M. B. Yeop, Development of vehicle driver drowsiness detection system using electrooculogram (EOG), *Computer, Communications, & Signal Processing with Special Track on Biomedical Engineering*, 2005, pp-165-168.
- [20] B. Jammes, H. Sharabty and D. Esteve, "Automatic EOG analysis: A first step toward automatic drowsiness scoring during wake-sleep transitions," *Somnologie.* 2008, 12(3): 227-232.
- [21] E. Magosso, F. Provini, P. Montagna, M. Ursino a wavelet based method for automatic detection of slow eye movements *Med. Eng. Phys.*, 28 (2006), pp. 860–875.
- [22] E. Magosso, M. Ursino, A. Zaniboni, F. Provini, P. Montagna Visual and computer-based detection of slow eye movements in overnight and 24-h EOG recordings *Clin. Neurophysiol.*, 118 (2007), pp. 1122–1133.
- [23] E. Magosso, M. Ursino, F. Provini, P. Montagna
Wavelet analysis of electroencephalographic and electro-oculographic changes during the sleep onset period *Conf Proc IEEE Eng Med Biol Soc*, 2007 (2007), pp. 4006–4010.
- [24] E. Magosso, M. Ursino, A. Zaniboni, E. Gardella, A wavelet-based energetic approach for the analysis of biomedical signals: application to the electroencephalogram and electro-oculogram *Comput Appl Math*, 207 (2009), pp. 42–62
- [25] K. Hyoki, M. Shigeta, N. Tsuno, Y. Kawamuro, T. Kinoshita, Quantitative electro-oculography and electroencephalography of alertness *Electroenceph Clin Neurophysiol*, 106 (1998), pp. 213–219.
- [26] S. Hanke, J. Zeitlhofer, G. Wiest et al., "Automated Vigilance Classification based on EOG signals: Preliminary Results," *World Congress on Medical Physics and Biomedical Engineering, Munich, Germany, IFMBE Proceedings*, vol. 25/9, pp. 428-431, 2009.
- [27] M. Ohsuga, Y. Kamakura, Y. Inoue, Y. Noguchi, R. Nopsuwanchai (2007) Classification of blink

waveforms toward the assessment of driver's arousal levels—an EOG approach and the correlation with physiological measures. *Eng Psychol Cogn Ergon* 4562:787–795.

[28] 赵仑. ERP 实验教程[M]. 天津: 天津社会科学院出版社, 2004:11–12.

[29] 孙琿, 基于状态空间模型的警觉度估计与预测算法研究[学士论文]. 上海交通大学. 2010.

[30] Sleep. <http://en.wikipedia.org/wiki/Sleep>.

[31] M. H. Silber, S. Ancoli-Israel, M. H. Bonnet, S. Chokroverty, M. M. Grigg-Damberger, M. Hirshkowitz, S. Kapen, S. A. Keenan, et al. (March 2007). "The visual scoring of sleep in adults". *Journal of Clinical Sleep Medicine* 3 (2): 121–31. PMID 17557422.

[32] C. Guilleminault, M. L. Kreutzer (2003-09-30). "Chapter 1 – Normal Sleep". In Michael Billiard (in English). *Sleep: Physiology, Investigations, and Medicine* (Google eBook). Springer. p. 5. ISBN 978-0-306-47406-4. Retrieved 2012-04-07.

[33] R. Mattews, P. J. Turner, N. J. McDonald, et al. Real Time Workload Classification from an Ambulatory Wireless EEG System Using Hybrid EEG Electrodes[C]. Proceedings of 30th International Conference of the IEEE Engineering in Medicine and Biology Society, Vancouver, British Columbia, Canada, 2008.

[34] Neurosky Helps USA Olympic Archers

<http://forsytharchery.com/club/2010/02/neurosky-helps-usa-olympic-archers/>

[35] K. Hyoki, M. Shigeta, N. Tsunob, et al. Quantitative electro-oculography and electroencephalography as indices of alertness[J], *Electroencephalography and clinical Neurophysiology*, 1998, 106(3): 213-219.

[36] J. X. Ma, L. C. Shi, B. L. Lu, Vigilance Estimation by Using Electrooculographic Features[C]. Proceedings of 32nd International Conference of the IEEE Engineering in Medicine and Biology Society, pp.6591-6594, Buenos Aires, Argentina, 2010.

[37] 马家昕, 石立臣, 吕宝粮. 基于脑电和眼电的警觉度在线估计. 视听觉信息的认知计算学术交流会. 北京. 2010.

[38] L. C. Shi, B. L. Lu, Off-Line and On-Line Vigilance Estimation Based on Linear Dynamical System and Manifold Learning[C]. Proceedings of 32nd International Conference of the IEEE Engineering in Medicine and Biology Society, Buenos Aires, Argentina, 2010: 6587-6590.

[39] L. Wei and H. Hu, "Use of Forehead Bio-signals for Controlling an Intelligent Wheelchair," Proceedings of IEEE Int. Conf. on Robotics and Biomimetics, Bangkok, Thailand, 14-17 December 2008, pp. 108-113.

[40] A. T. Vehkaoja, J. A. Verho, M. M. Puurtinen, N. M. Nojd, J. O. Lekkala, and J. A. Hyttinen.

Wireless Head Cap for EOG and Facial EMG Measurements. In Proc. of the 27th Annual International Conference of the Engineering in Medicine and Biology Society.

[41] Blind Signal Separation http://en.wikipedia.org/wiki/Blind_signal_separation.

[42] Independent Component Analysis http://en.wikipedia.org/wiki/Independent_component_analysis.

[43] A. Delorme and S. Makeig, "EEGLab: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis", *Journal of Neuro science Methods*, vol.134, pp.9-21, 2004.

[44] A. Cichocki, S. Amari, K. Siwek, T. Tanaka, A. Phan, et al., "ICALAB toolboxes", <http://www.bsp.brain.riken.jp/ICALAB>.

[45] A. Hyvarinen, E. Oja, Independent component analysis: algorithms and applications. *Neural Netw.*, 2000; 13: 411-30.

[46] A. W. Monster, H. C. Chan, D. O'Connor, Long-term trends in human eye blink rate. *Biotelemetry Patient Monit.* 1978;5:206-222.

[47] G. Bartels, L. C. Shi, B. L. Lu, "Automatic Artifact Removal from EEG - a Mixed Approach Based on Double Blind Source Separation and Support Vector Machine", *Proceedings of the 32nd International Conference of the IEEE Engineering in Medicine and Biology Society, Buenos Aires, Argentina, Sep., 2010.* pp.5383-5386.

[48] D. Peter, Welch. The Use of Fast Fourier Transform for the Estimation of Power Spectra: A Method Based on Time Averaging Over Short, Modified Periodograms. *IEEE Transactions on Audio and Electroacoustics*, AU-15:70-73, 1967.

[49] A. V. Oppenheim, R. W. Schaffer, and J. R. Buck. *Discrete-time Signal Processing*, second edition. Prentice-Hall, 1999.

[50] T. K. Ning and J. D. Bronzino. Autoregressive and bispectral analysis techniques: EEG applications. *IEEE Engineering in Medicine and Biology Magazine*,9:47-50, 1990.

[51] G. Pfurtscheller, C. Neuper, A. Schlogl and K. Lugger. Separability of EEG signals recorded during right and left motor imagery using adaptive autoregressive parameters. *IEEE Transactions on Rehabilitation Engineering*, 6: 316-325, 1998.

[52] J. Pardey, S. Roberts, and L. Tarassenko. A review of parametric modelling techniques for EEG analysis. *Medical Engineering & Physics*, 1:2-11, 1996.

[53] J. Makhoul. Linear prediction: A tutorial review. *Proceedings of the IEEE*, 63:561-580, 1975.

[54] C. C. Chang and C. J. Lin. LIBSVM: a library for support vector machines, 2001. Software available at <http://www.csie.ntu.edu.tw/~cjlin/libsvm>.

- [55] C. W. Hsu, C. C. Chang, and C. J. Lin. A Practical Guide to Support Vector Classification. National Taiwan University, Taipei, 2008. URL <http://www.csie.ntu.edu.tw/~cjlin>.
- [56] S. Makeig, M. Inlow. Lapses in alertness: coherence of fluctuations in performance and EEG spectrum [J]. *Electroencephalography and Clinical Neurophysiology*, 1993, 86(1):23–35.
- [57] 傅佳伟,石立臣,吕宝粮基于 EEG 的警觉度分析与估计研究综述[期刊论文]-中国生物医学工程学报 2009(04)

致 谢

犹记论文开篇之时，我还身着短袖嘲笑魔都的秋天怎得如此扭捏不前，而今收官，却只得躲在空调下犹豫着不肯多伸出哪怕一根手指。细数过这些日子，动笔前夸口我堂堂网络写手日更万字的豪情早已灰飞烟灭，不禁感叹编故事可以书生意气挥斥方遒，而耕论文却必要格物致知诚意正心。行文至此，尚有几分感慨，不知何以言说，想我转念间在交大已是七年有余，定要在此感谢母校多年的培养，感谢纳税人提供的教育科研经费。

我自知不是个好学生，至少在经典概念中不是，但我却很幸运，因为遇到了吕老师这位好老师，不仅是经典概念中好老师，同样是超然概念中的好老师。作为我的导师，吕老师在科研学术上为我规划指出了明确的方向与道路，在我的每一点成果中都凝结着吕老师的远见与智慧。实验室工作上，吕老师悉心安排，亲历亲为，与吕老师一同通宵工作的经历，至今激励着我要为自己的事业努力奋斗。如此种种，都是经典概念中的好，却不足以体现吕老师在超然概念中的好。这超然概念中的伟大在于，吕老师作为导师给予了我人生的塑造。回首我从小学至今十九年的学校生活，能对我人生轨迹有如此大影响的老师，唯有两人。一人是我小学六年级的数学老师，

他用自身的言行教会了我，要有自己独立的思想与人格，要用自己的思想去怀疑世上的一切规则与现象。而吕老师，则在我执拗的坚持着自己的选择时，用他的智慧与宽容，给予了我无限的空间，这不是对我行为的容忍，而是对我思想的包容。在此，我要深深的感谢我的导师，吕宝粮老师。如果不是吕老师，可能我无法做到今日的一切，更无从谈及未来，能在这样一些岁月中遇到您，乃我此生之幸。

还要感谢实验室的各位前辈同学，特别是，石立臣学长，马家昕学长，王晓韡学长，对我的研究给出了相当大的指导与帮助。

最后，感谢我的父母，在长达一年的时间中孜孜不倦的叮嘱我，儿啊要写论文了。可见有我这种非主流的种，也不是件容易事。

2012年11月27日清晨

攻读硕士学位期间已发表或录用的论文

- [1] H. Cai, J. Ma, L. Shi, and B. Lu, "A novel method for eog features extraction from the forehead," in Proceedings of 30th International Conference of the IEEE Engineering in Medicine and Biology Society, EMBC, 2011 Annual International Conference of the IEEE. IEEE, 2011, pp. 3075–3078.