

# 基于功能性近红外光谱的脑机接口综述

李鸿云<sup>1,2,3</sup>, 伏云发<sup>1,2,3\*</sup>

<sup>1</sup>昆明理工大学信息工程与自动化学院, 云南 昆明 650500;

<sup>2</sup>昆明理工大学脑认知与脑机智能融合创新团队, 云南 昆明 650500;

<sup>3</sup>云南省计算机技术应用重点实验室, 云南 昆明 650500

**摘要** 脑机接口(BCI)技术通过解码分析大脑的神经活动来实现人脑与计算机等外部设备的直接交互,可作为信息交流和恢复运动功能的手段,已被应用于通信、智能机器人控制、生物医学和神经康复等诸多领域。功能性近红外光谱(fNIRS)是一种可用于探测大脑皮层血红蛋白浓度变化的光学成像技术,近些年被用于无创BCI的发展。本文系统、详细地综述了fNIRS-BCI的发展历程、组成原理、涉及的关键技术、未来的发展趋势以及局限性和待解决的问题,重点对特征分类算法进行了全面统计,并将结果与前人的部分统计数据进行对比分析,归纳出一些有价值的结论与观点。本文旨在让有兴趣探索fNIRS-BCI的研究人员对其有一个全面而具体的了解,甚至为他们提供一定的参考和指导。

**关键词** 光谱学; 功能性近红外光谱; 脑机接口; 信号降噪; 特征提取; 特征分类

中图分类号 O433

文献标志码 A

doi: 10.3788/LOP202158.1600006

## Functional Near-Infrared Spectroscopy-Based Brain-Computer Interface

Li Hongyun<sup>1,2,3</sup>, Fu Yunfa<sup>1,2,3\*</sup>

<sup>1</sup> School of Information Engineering and Automation, Kunming University of Science and Technology, Kunming, Yunnan 650500, China;

<sup>2</sup> Integration and Innovation Team of Brain Cognition and Brain Computer Intelligence, Kunming University of Science and Technology, Kunming, Yunnan 650500, China;

<sup>3</sup> Computer Technology Application Key Lab of Yunnan Province, Kunming, Yunnan 650500, China

**Abstract** The brain-computer interface (BCI) technology enables direct interaction between the human brain and computers or other external devices by analyzing and decoding neural activity. It can be used as a means of information exchange or the restoration of motor functions and has been applied in communications, intelligent robot control, biomedicine, and neurorehabilitation, etc. Functional near-infrared spectroscopy (fNIRS), an optical imaging technique that can be used to detect changes in hemoglobin concentration within the cerebral cortex, has been employed recently in the development of noninvasive BCI. The development history, composition principles, key technologies, future development trends, limitations, and problems of fNIRS-BCI are reviewed systematically and in detail. Particularly, the feature-classification algorithm was analyzed comprehensively, and the result was compared with statistical data from its predecessors to summarize several valuable conclusions and opinions. This review is designed to provide a comprehensive and specific understanding of fNIRS-BCI and references and guidance.

**Key words** spectroscopy; functional near-infrared spectroscopy; brain-computer interface; signal denoising; feature extraction; feature classification

**OCIS codes** 300.6340; 040.3060; 070.5010

收稿日期: 2020-09-08; 修回日期: 2020-10-12; 录用日期: 2020-10-21

基金项目: 国家自然科学基金(81771926, 61763022, 61463024, 81470084)

通信作者: \*fyf@ynu.edu.cn

## 1 引 言

包括人类在内的高等动物的中枢神经系统由大脑和脊髓组成,而周围神经系统由周围神经、神经节和感受器构成。中枢神经系统接收全身各处的传入信息并对其进行整合加工,之后,一部分信息(也可以是大脑自发的信息)成为协调的运动性输出。通常情况下,输出通道为周围神经和肌肉组织。脑机接口(BCI)是实现大脑信息直接与外部设备(可以是计算机、机械臂以及芯片等)进行交流或通信,而不依赖于正常的由周围神经和肌肉组成的输出通道的通信系统<sup>[1-2]</sup>。

由于神经元的活动,中枢神经系统(BCI中特指大脑区域)中无时无刻不在发生电生理、神经化学和代谢现象,如神经元动作电位、突触电位、神经递质的释放以及氧的消耗等。这些现象可以通过放置在头皮上、大脑皮层上或大脑灰质内的传感器监测的电位或磁场以及血红蛋白氧合参数等进行量化。BCI系统采集、记录这些量化的大脑信号,然后对这些信号进行预处理,并从中提取某些信号特征,把这些特征转换成作用于外部设备或身体本身的人工输出<sup>[3]</sup>。以上就是BCI的基本原理。

在大脑的生理活动中,众所周知的是电磁活动。脑电图(EEG)、脑磁图(MEG)、脑皮层电图(ECoG)或植入大脑组织的微电极(ME)可以基于动作电位等神经电现象,对大脑活动进行电测量。然而,这些探测方法存在诸多不足之处:EEG信号的空间分辨率低,且易受电噪声的影响。MEG探测的与脑电流相关的磁场相对于不受实验控制(如地磁场的波动)的周围环境中的磁场非常小,且易受电力线磁场的干扰。此外,EEG和MEG传感器的放置位置距离所探测的神经元较远,因此用其探测到的信号来识别大脑的活跃区域不够精准。直接放置在大脑皮层上或皮层内的电极虽然能相对精准地测量它周围的电活动,但其仅能覆盖到大脑区域非常有限的一部分<sup>[3-4]</sup>。植入大脑灰质的电极所能获取的神经信号的信噪比较高,但易引发免疫反应和愈伤组织(疤),进而导致信号质量衰退,甚至消失<sup>[5]</sup>;此外,这种完全侵入式的探测方法存在颅内感染的风险,且操作复杂,需要进行专业的外科手术。

目前,利用测量化学过程来研究大脑活动的方法主要是通过正电子发射断层成像(PET)技术<sup>[6-7]</sup>实现的,但将其应用于人类大脑活动的研究尚显粗略、不精细。除此之外,它需要使用昂贵的回旋加速

器以及注射特制的放射性标记化合物,而且时间分辨率较低<sup>[8]</sup>。

由于电方法和化学方法的局限性,通过测量代谢过程来探测大脑活动并应用于BCI的方法近些年逐渐成为研究热点。当大脑某个区域的神经元代谢活动增加时,区域内基本代谢“燃料”(葡萄糖与氧气)的需求量也会随之增多,这些代谢“燃料”通过血液的流动来运送,因而该区域血流量也会相应增加。大脑的血液动力学响应可作为神经元活动的一种标记。在BCI的发展中,目前应用最广泛的血液动力学响应信号检测方法是功能核磁共振成像(fMRI)和功能性近红外光谱(fNIRS)。fMRI具有较高的空间分辨率,然而设备昂贵、体积庞大,并且需要在封闭的环境中操作,这使得其不适合应用于发展实用性BCI。fNIRS通过跟踪不同形态血红蛋白的变化来测量血流<sup>[3,9]</sup>,具有无创、成本低廉、易使用、便携性好等优点,为BCI的发展提供了一种具有较大潜力的应用方案。

目前,国内外已发表关于BCI的综述多为基于脑电(EEG-BCI)的,而与fNIRS相关的综述论文粗泛冗杂,涵盖fNIRS技术在诸多领域的应用,鲜有单独侧重fNIRS应用于BCI的综述。2015年,Naseer等<sup>[10]</sup>概述了2004—2014年间fNIRS-BCI的研究情况,主要对激发脑信号的实验任务、降噪方法、特征提取和分类技术进行了简要的综述,得出如下结论:由于实验中没有头发遮挡引起的伪迹,心算、音乐想象和情感诱导等认知任务最受研究人员青睐;带通滤波法是最常用的降噪方法;据统计,均值和斜率是最常提取的特征,线性判别分析(LDA)的计算量低且分类效果良好,是使用频率最高的分类算法。然而,Naseer等在核心内容部分仅泛泛地引述了他人的研究,并未概述其研究过程、结果和意义等。此外,他们的文章没有系统地归纳fNIRS-BCI的发展历程以及目前存在的问题和局限性等,且缺乏个人的观点和建议。时隔数载,fNIRS-BCI领域的研究发生了巨大变化,尤其是近些年各种神经网络模型等新鲜血液的注入,使其焕发出了别样生机。本文旨在更加详细、全面、系统地介绍fNIRS-BCI技术,并将相关统计数据与Naseer等总结的数据进行对比,分析近些年fNIRS-BCI技术的发展变化,预测其未来的发展趋势,以供BCI爱好者和相关领域的研究人员参考。

## 2 fNIRS-BCI的发展概况

1977年,Jöbsis<sup>[11]</sup>首次提出了使用光学手段探

测动物(猫)大脑活动的技术,他用实验验证了利用能够穿透颅骨的辐射光谱检测大脑氧合水平和其他细胞标记物浓度变化的可行性,并将实验结论发表在 *Science* 期刊上。该论文一经发表便引起了生物医学领域研究人员的极大关注,之后越来越多的科研机构开始涉足近红外成像技术探测大脑的研究。

1988年, Delpy 等<sup>[12]</sup>在用 fNIRS 探测大脑活动过程中将近红外信号测量与大脑氧合联系起来,并考虑了近红外光在穿行过程中散射的影响,制定了改进的比尔-朗伯定律(MBLL),使大脑活动的检测精度得到了提高。此后,在该领域的研究中,人们基本上都利用这个定律将光信号转换为血红蛋白浓度信号。

由于近红外光在生物组织中的穿透能力有限,早期的 fNIRS 仅用来探测动物或婴儿大脑皮层内的血流活动<sup>[13-14]</sup>。1991年以后,随着光学理论和计算机技术的发展,出现了反射式扩散光学成像技术(RDOT);该技术是基于光散射理论模型的一种成像技术,能比较准确地描述出光子在生物组织中的基本运动规律。自此以后,研究人员开始使用 fNIRS 探测成年人脑皮层中的血流活动<sup>[15-16]</sup>。1993年, Villringer 等<sup>[9]</sup>首次使用 fNIRS 检测了成年人的脑功能,随后出现了较为轻便简捷的单通道 fNIRS 系统,该系统一出现便成为研究成人和婴儿脑认知功能的一种重要手段。

2004年, Coyle 等<sup>[17]</sup>在实验中让被试想象持续挤压和释放软球的运动,并用 fNIRS 探测被试大脑运动皮层的血流活动,检测到了皮层内氧合血红蛋白(oxy-Hb 或 HbO)和脱氧血红蛋白(deoxy-Hb、Hb 或 HbR)浓度变化信号(这些信号能用于控制 BCI 外设),首次验证了 fNIRS 可用于发展 BCI。

2006年, Sitaram 等<sup>[18]</sup>采用一个 20 通道的连续波近红外光谱系统测试被试左右手运动想象任务期间大脑运动皮层氧合血红蛋白和脱氧血红蛋白的浓度变化,并使用支持向量机(SVM)和隐马尔可夫模型(HMM)算法对不同模式下的血液动力学响应

信号进行离线分类,分别得到了 73%和 89%的平均分类精度。他们的研究结果进一步证明了在 BCI 开发中使用 fNIRS 技术的可行性。

2014年, Naseer 等<sup>[19]</sup>实现了 fNIRS-BCI 系统数据的完全在线分类,证实了开发具有较大实用价值的实时 fNIRS-BCI 系统的可行性。与此同时, Gallegos-Ayala 等<sup>[20]</sup>成功利用 fNIRS-BCI 系统实现了与处于完全锁定状态的肌萎缩侧索硬化症患者的大脑交流,拓展了这项技术的应用空间。

近年来,基于时间分辨的功能性近红外光谱扫描技术(TR-fNIRS)的 BCI,以其增强的深度敏感性使得来自脑外层的信号污染降低,从而受到了越来越多的关注。2020年, Abdalmalak 等<sup>[21]</sup>首次将基于 TR-fNIRS 的 BCI 用于健康参与者的“心理交流”,这表明 TR-fNIRS 可能适合发展面向脑损伤患者群体的 BCI。

本课题组总结了“超星发现”数据库历年收录 fNIRS-BCI 的文献数量,如图 1 所示。需要说明的是:1)Coyle 等于 2004 年首次将 fNIRS 技术应用于 BCI 的研究,故统计从 2004 年开始;统计截止到 2020 年 6 月,如无特别说明,下文中的图表数据均基于此条件。2)之所以选择“超星发现”数据库进行统计,是因为其收录的 fNIRS-BCI 领域的文献数量较其他数据库更丰富(如表 1 所示),更具代表性且更具参考价值。




图 1 “超星发现”数据库历年收录 fNIRS-BCI 的文献数量  
Fig. 1 Quantity of literatures related to fNIRS-BCI recorded in the Superstar Discovery database over the years

表 1 各数据库检索到的 fNIRS-BCI 文献数量一览

Table 1 A list of the quantity of literatures related to fNIRS-BCI recorded in several databases

Database	Superstar Discovery	Web of Science	Engineering Village	China National Knowledge Infrastructure
Quantity of entries	478	217	165	70

### 3 fNIRS-BCI 的原理及系统组成

#### 3.1 fNIRS 的基本原理

在大脑活动过程中,脑组织内的神经元为了供应能量而分解葡萄糖时需要消耗氧气,而氧气依靠血液内的血红蛋白运输,因此大脑活动会引起脑组织周围血管内血液成分的变化,比如 HbO 和 HbR 浓度的变化。fNIRS 技术可利用近红外光穿过大脑皮层组织时的衰减程度来间接测量这些变化。

大脑组织中吸收近红外光的成分主要有水、HbO 和 HbR,它们对近红外光的吸收性有一定差异,如图 2 所示。血红蛋白对吸收光谱中波长在 650 nm 以下的光波有较强的吸收作用,而水会大量吸收 950 nm 以上的光波,所以 fNIRS 通常使用波长为 650~950 nm 的近红外光。这一光学窗口内的近红外光能够很好地透过大脑组织<sup>[22-23]</sup>,并且光的吸收变化主要是由 HbO 和 HbR 主导的,可以用




图 2 HbO、HbR 和水在近红外波段的吸收系数  
Fig. 2 Absorption coefficient of HbO, HbR, and water in near-infrared band

来反映这两种生色团的浓度变化<sup>[24]</sup>。

#### 3.2 fNIRS-BCI 系统的组成

基于 fNIRS 的 BCI 系统通常由信号采集、信号预处理、模式识别和控制设备几个部分组成,有些系统还存在反馈装置,如图 3 所示。

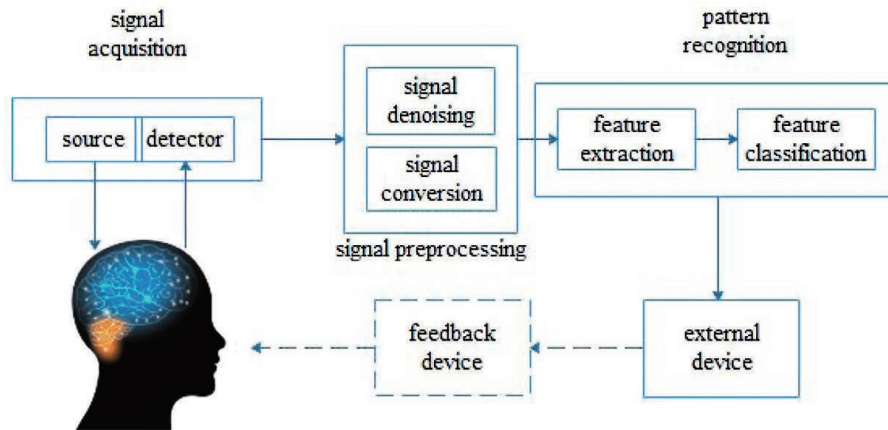


图 3 fNIRS-BCI 系统的组成

Fig. 3 Composition of fNIRS-BCI system

信号采集装置由放置于头部的光源-探测器对组成。发光二极管(光极)作为光源发射特定波长的近红外光,近红外光透过头皮和颅骨,进入几毫米厚的大脑皮层组织,之后又穿过颅骨和头皮返回到一个或多个到光源距离固定(一般认为最佳距离为 3 cm 左右<sup>[25-26]</sup>)的检测器。

信号预处理主要分为噪声伪迹剔除和信号转换两个部分。前者用于消除生理噪声(如呼吸振荡、心脏搏动和 Mayer 波等)以及探头移动或头动引起的噪声,后者将光信号转换为血红蛋白浓度信号,以便后续的信号处理。

模式识别包括信号的特征提取和分类。首先提取 HbO 或(和)HbR 浓度变化信号的特征,再使用

分类算法对其进行分类,得到不同的输出信号,用以控制外部设备。外部设备可以是计算机显示器、轮椅和机械臂等。

部分 fNIRS-BCI 系统增加了反馈装置,该装置可实时向用户反馈控制结果,以使用户对自身的大脑活动作出适当的调整,对外部设备进行更协调的控制操作。

### 4 fNIRS-BCI 信号采集

#### 4.1 采集区域

研究过程中采集 fNIRS 信号的大脑皮层区域的选取与设计的实验任务有关,例如:实验任务若涉及精神任务或工作记忆,则将光源-探测器对排布于

负责调控这些任务的前额叶皮层区域对应的额头部位;若实验任务与运动有关,便将其排布于初级运动皮层区域对应的头顶。这两个大脑皮层区域是 fNIRS-BCI 中获取脑信号最常见的部位,由于没有头发遮挡带来的信号伪迹,前额叶皮层成为研究人员最热衷于探测的区域<sup>[27-28]</sup>。

#### 4.2 光谱类型

用于 fNIRS 的光谱主要有连续波光谱(CW 光谱)、时间分辨光谱(TR 光谱)和频域光谱(FD 光谱)<sup>[23,29]</sup>。CW 光谱方法以其经济、简单灵活、设备便携、采样率高和信噪比高等优点而成为 fNIRS-BCI 研究中应用最为广泛的一种<sup>[3]</sup>。

在 CW-fNIRS 系统中,光源设备通常通过一个信号发生器以低频连续产生或调制两束不同波长的近红外光。两束光的波长值分别在等吸收点(大致在 805 nm 处,此时 HbO 和 HbR 的吸收系数相同)前后选取,分别用以探测 HbO 和 HbR 的浓度变化。在少量文献中,偶见使用一个波长或三个波长的研究<sup>[30-32]</sup>。

#### 4.3 通道数量

fNIRS-BCI 使用的设备通道数由一个到上百个不等。最近,英国伦敦大学学院生物医学光学研究实验室研发了一种可以提供 256 个通道的 fNIRS 系统,该系统灵活、适应性强,可用于成人、儿童或婴儿,且用户能按照自己的需求来布置光源-探测器对,从而可以实现任何被试上进行任意大脑皮层区域的研究<sup>[33]</sup>。这是目前所知通道数量最多的 fNIRS 系统。研究人员通常使用多通道系统采集脑信号,但在一些研究中有时也会采用仅有一个通道(单通道)的系统,而且也得到了不错的实验结果<sup>[34-36]</sup>。

无论是单通道还是多通道 fNIRS-BCI 系统,它们都有各自的优点:单通道系统可以设计得很小,便于开发便携式的应用设备,而多通道系统则能提供更多的大脑活动信息。

### 5 fNIRS-BCI 涉及的关键技术

#### 5.1 信号预处理

##### 5.1.1 噪声伪迹的剔除

采集到的脑信号中通常含有一些噪声和伪迹,需要在对信号进行分析前将其剔除,以提高信号数据的质量。常见的噪声伪迹以及消除方法如下:

##### 1) 高频噪声

探头未与头皮紧密接触导致的外部光线干扰以

及头发对近红外光的遮挡都会引起高频噪声。通常,在佩戴探测设备过程中,严密的操作(如将头发充分拨开)可以较为有效地减少这种噪声的产生。除此之外,使用只允许低频信号透过的低通滤波器( $<0.5$  Hz)可以将高频噪声过滤掉<sup>[37]</sup>。相比而言,这种噪声较为容易去除。

##### 2) 生理噪声

顾名思义,生理噪声来源于被试自身的生理活动,包括呼吸振荡、心脏搏动和 Mayer 波等。呼吸振荡是呼吸引起的波动,与被试呼吸频率有关,正常情况下的波动频率为 0.2~0.3 Hz;心脏搏动会使动脉产生脉冲振荡,进而引起整个大脑 fNIRS 信号的波动,波动频率与被试心率有关,通常为 0.8~1.5 Hz,这种伪迹对 fNIRS 信号的影响最为明显,应作为重点消除对象;Mayer 波是以低于呼吸频率发生的动脉血压的自发振荡,其波动频率约为 0.1 Hz<sup>[3,37]</sup>。

根据这些生理噪声的频率特征,利用特定频带范围(如 0.02~0.5 Hz)的带通滤波器可以将大部分噪声消除掉,而且这种方法适用于在线 BCI 系统,因而具有较广阔的应用前景。但由于呼吸振荡和 Mayer 波等低频振荡的频带与脑功能活动引起的血液动力学响应信号的频带存在明显的重叠,使用单纯的基于频率的滤波方法可能会导致血液动力学响应信号失真,因此带通滤波方法对其无能为力<sup>[38]</sup>。独立成分分析法(ICA)<sup>[39-41]</sup>和主成分分析法(PCA)<sup>[42-43]</sup>能够有效分离和去除包括呼吸振荡等在内的生理噪声。

脑功能活动激活的脑区是特定的,而生理噪声的干扰是全局的(在一些文献中,生理噪声也被称为“全局干扰”),存在于大脑的各个区域。因此,在利用 fNIRS 测量脑功能活动时,认为非激活区域的测量信号与生理干扰相关,将激活区域与非激活区域的测量信号相减便可以实现脑功能信号和干扰信号的分离<sup>[38]</sup>。这就是 ICA 和 PCA 用于去除 fNIRS 信号中生理噪声的理论基础。

此外,还可以使用最小均方(LMS)自适应滤波算法追踪生理噪声的变化,并对其进行自适应消除<sup>[44-45]</sup>;但它的缺点是收敛速度较慢,并且脑功能检测时间过长,容易使被试疲劳,反而会影响到采集信号的质量<sup>[38]</sup>。

##### 3) 基线漂移

有些实验任务诱发的血液动力学响应很难在放松阶段完全恢复到基线状态,下文提到的运动伪影

也会改变基线值,这些实验误差就是基线漂移。幸运的是,由于这类噪声变化的频率较慢,也比较容易消除<sup>[37]</sup>。除了控制好实验任务外,还可以使用二次项拟合、高通滤波、平滑器和去趋势算法来消除噪声<sup>[46-47]</sup>。Jang 等<sup>[48]</sup>提出了一种联合小波变换与最小描述长度准则的去趋势算法(Wavelet-MDL),即:先把小波变换应用于近红外时间序列,将其分解为不同尺度的全局趋势、血液动力学信号和噪声成分,然后利用最小描述长度准则为全局趋势的估测提供最优的模型顺序选择,最终成功地去除了 fNIRS 数据中的漂移信号。实验结果表明,这种新的去趋势算法优于传统的同类算法。

#### 4) 运动伪影

运动伪影来源于被试的眨眼、皱眉、讲话和头部快速移动等身体活动。例如,头部的快速移动可能会导致光源或探测器探头与头皮发生相对位移,从而导致光纤和皮肤之间的光耦合发生变化。运动伪影在 fNIRS 信号中的影响表现为使信号出现高频尖峰、增加幅值和改变基线值<sup>[49-50]</sup>。

Virtanen 等<sup>[51]</sup>在实验中使用加速计估测了基线运动伪影,并通过缩放 fNIRS 信号的振幅对这些伪影进行了校正。最近,Siddiquee 等<sup>[52]</sup>研发了一种可穿戴的无线近红外光谱仪网络传感器,它能够通过放置在近红外光学传感器附近的多感官结合惯性测量单元(IMU),更加准确地记录运动的相关信号。然后,他们将 IMU 中单个传感器的数值与运动融合信号相结合,进行伪影校正,结果发现信噪比显著提高。该研究表明,运动融合算法可以更准确地估测和去除运动伪影。

Robertson 等<sup>[49]</sup>比较了从信号中去除运动伪影的五种方法:双输入递归最小二乘(RLS)自适应滤波、小波滤波、ICA、双通道回归和多通道回归。他们发现,在大多数数据集中,使用 ICA 或多通道回归可使所有通道的信噪比中值变化最大。因此他们认为,从提高信噪比这一方面来看,多通道回归和 ICA 是减少 fNIRS 信号中运动伪影的最有效方法。Cooper 等<sup>[50]</sup>利用模拟血液动力学响应函数(HRF)比较了主成分分析、卡尔曼滤波、小波滤波和样条插值四种运动伪影校正方法的性能,结果发现样条插值和小波滤波方法表现较好。最近,Rayyan 等<sup>[53]</sup>比较分析了高斯滤波、巴特沃斯滤波、卡尔曼滤波、血液动力学响应滤波、维纳滤波和有限脉冲响应滤波六种滤波技术对 fNIRS-BCI 分类精度的影响,发现血液动力学响应滤波效果较好,表明其能有效去

除 fNIRS 数据中的噪声。

不难发现,一些去噪方法是可以同时消除多种噪声伪迹的,比如各种频带的滤波方法,可在一定程度上消除绝大多数类型的噪声伪迹。此外,滤波器方法具有简单、计算成本低和能实现在线操作的优点,因此滤波方法成为 fNIRS-BCI 数据预处理中最常用的降噪方法。

鉴于不同方法对不同伪迹噪声的消除能力各异,可以有针对性地结合使用两种或多种方法,虽然这样会增加算法开销,但能达到更佳的降噪效果。Verdière 等<sup>[54]</sup>联合使用 0.01~0.5 Hz 的带通滤波器与小波插值法来去除伪迹噪声,获得了较高质量的信号数据。

此外,在多通道的信号采集系统中,如果出现伪迹污染较严重的通道,可以考虑将其直接剔除,以免后续影响整体数据的分类精度。

#### 5.1.2 信号转换

在 fNIRS 数据的预处理过程中,通常会使用改进的比尔-朗伯定律<sup>[12,55]</sup>将近红外光强度变化信号转换为 HbO 和 HbR 浓度变化信号,以便得到更高的数据分类精度。

比尔-朗伯定律指出,光强度的衰减与非吸收介质中吸收生色团的浓度和光子的穿行路径长度成正比,即

$$A = \lg \frac{I_0}{I_1} = c\epsilon l, \quad \epsilon = \frac{4\pi k}{\lambda}, \quad (1)$$

式中: $A$  为光强衰减量; $I_0$  为入射光强度; $I_1$  为出射光强度; $c$  为吸收生色团的浓度; $\epsilon$  为吸收系数(为吸收生色团的特性); $l$  为光子穿行路径长度; $k$  为消光系数; $\lambda$  为光的波长。

(1)式适用于吸光物质为均匀非散射体系的情况。而头部是一个复杂的非均匀介质光路,且需要考虑光在穿行过程中发生的散射,因此在 fNIRS 的实际应用中,比尔-朗伯定律会被改进成

$$A = \lg \frac{I_0}{I_1} = c\epsilon l F_{DP} + G, \quad (2)$$

式中: $F_{DP}$  为差分路径长度因子,是一个用来解释由于散射而增加的路径长度的尺度项; $G$  为包含散射损失量的附加标量项。

## 5.2 特征提取

### 5.2.1 信号指标类型

fNIRS-BCI 中用于分类的血液动力学信号指标主要有四种:HbO、HbR、HbT 和 HbD。需要注意的是,目前 fNIRS-BCI 中应用得最多的连续波光谱

并不能测量 HbO 与 HbR 浓度的绝对值,只能获得它们相对于基线值的浓度变化值。HbO 和 HbR 浓度变化信号是基础的血液动力学响应信号,其中 HbO 因具有响应灵敏以及重测可靠性和稳定性高的优点而在研究中采用得最多<sup>[56-57]</sup>。当然,为了获得更多的信息,很多研究会同时采集和分析这两种血红蛋白浓度信号。甚至有研究表明,在某些实验中使用 HbO 和 HbR 信号的组合特征比使用单独的特征可以获得更高的分类精度<sup>[58]</sup>。HbT (the total of HbO and HbR)是氧合血红蛋白与脱氧血红蛋白浓度变化值之和;HbD (the difference of HbO and HbR)为两者浓度变化值之差,是较为新颖的信号指标,近些年才被提出和使用<sup>[59-61]</sup>。

### 5.2.2 特征选择

在选择好血红蛋白浓度信号指标后,需要进一步提取这些信号中有用的数据特征,以便后续基于此进行分类。基本的统计特征包括信号均值、峰值、幅值、方差、斜率、偏度、峰度和曲线下面积等,不同信号的这些特征往往存在差异,通过分类器可以将其进行识别分类。其中,最常用的特征是均值和斜率。据统计,将近一半的 fNIRS-BCI 研究中使用的特征集包含了血红蛋白浓度信号的均值或斜率值<sup>[10]</sup>。

除了上述常见的统计特征外,其他类型的特征在一些文献中也有所提及,如: Tai 等<sup>[62]</sup>在研究情绪诱导任务的血液动力学响应时使用的遗传算法的搜索空间中包含了零交叉点(ZC,信号越过基线的次数)和均方根(RMS)等不常用的特征。Abibullaev 等<sup>[63]</sup>采集了被试额叶皮质活动激活的脑血液动力学响应信号,并用去噪后的小波系数作为分类器的输入特征,获得了良好的分类性能,并且发现分类性能与小波分解的母小波的类型有关;他们还发现,将特征与分类器进行特定的组合,能得到最佳的分类结果。Verdière 等<sup>[64]</sup>基于收缩线性判别分析法(sLDA)来区分 12 名飞行员自动与手动着陆方式,对采集的 HbO 与 HbR 信号数据的传统氧合特征(均值、峰值、方差、偏度、峰度、曲线下面积和斜率)和连接特征(协方差、Pearson 相关、Spearman 相关、频谱相干和小波相干)的性能进行了测试。经过分层交叉验证(单独使用每个特征和结合多个特征)后发现,连接特征的整体效果要比传统的氧合特征好,尤其是小波相干的分类精度最高。此外,将曲线下面积与小波相干组合可以获得最优的分类效果。

Qureshi 等<sup>[64]</sup>使用一般线性模型(GLM)对滤波降噪后的 fNIRS 信号进行建模,再利用最小二乘法对模型的系数进行自适应估计,然后将估计系数的多个特征进行组合并用于分类。实验发现,与使用传统血液动力学响应数据获得的最佳分类结果相比,该方法得到的平均分类精度显著提高。GLM 可以同时使用干扰回归因子过滤伪迹信号和提取血液动力学响应函数特征。最近, von Lümann 等<sup>[65]</sup>从传统方法预处理的信号以及经 GLM 和生理干扰回归因子预处理的信号中分别提取了常用的 fNIRS 特征,并比较了它们的质量。结果表明,基于 GLM 的方法能够对大脑活动提供更好的单次实验评估,同时,它还能增加一种新的特征类型——个体和通道特异性血液动力学响应函数回归因子的权重,该特征能显著提高二分类任务的分类精度。该研究同时分别验证了 fNIRS 信号预处理和特征提取中的一个备选方案。

通常,上述特征都是人工选择的,为了快速选择出用于分类的最佳特征(或特征集),有时研究者会使用一些启发式方法(HM)进行搜索,比如遗传算法<sup>[62,66-67]</sup>和多元模式分类技术<sup>[68-70]</sup>等。遗传算法(GA)是一种通过模拟自然进化过程搜索最优解的方法,将其运用于信号处理,用于从一个包含多种特征的集合中选择最有效特征。多元模式分类(MVPC)技术通过训练一个分类器来识别状态间区别最大的数据特征,能有效识别信号的哪些方面携带有相关参数的最多信息。

此外,为了增加某些特征的可分性,可以使用共空间模式(CSP)算法进行空间滤波。CSP 算法在脑电信号处理中应用广泛,近些年 Zhang 等<sup>[71]</sup>将其引入到 fNIRS 领域,并证实了它的有效性。之后, Jiang 等<sup>[72]</sup>对其进行改进,提出了一种针对 fNIRS 独特特征的改进的共空间模式(MCSP)算法。它将近红外光谱信号从原始信号空间投影到一个信号子空间中,以提取高度可分的特征。最近,他们又将算法的应用范围从二分类扩展到多分类问题<sup>[73]</sup>,进一步证明了 MCSP 在处理更多数据的复杂分类问题上的有效性。他们的研究在一定程度上推进了 fNIRS 信号处理算法的发展。

### 5.3 特征分类

提取血液动力学响应信号特定的特征后,需要使用分类器(基于分类算法训练得到)对它们进行分类,以产生不同类型的输出信号来控制外部设备。fNIRS-BCI 研究中常用的分类算法主要有支持向量

机、线性判别分析、人工神经网络、深度神经网络、卷积神经网络和隐马尔可夫模型等。

### 5.3.1 支持向量机(SVM)

SVM 根据结构风险最小原理构造目标函数,以寻找一个满足要求的分割超平面,使训练集中的点距离分割超平面尽可能远<sup>[74]</sup>。当样本数据线性不可分时,可以利用核函数实现非线性变换,将数据映射到一个高维空间中,使其线性可分。SVM 在小样本、非线性及高维模式识别中表现出了许多特有的优势<sup>[75]</sup>,因此在 fNIRS-BCI 研究中使用的频率最高,如图 4 所示。




图 4 2004—2020 年 fNIRS-BCI 中使用的 主要特征分类算法的占比

Fig. 4 Proportion of main feature classification algorithms used in fNIRS-BCI from 2004 to 2020

Batula 等<sup>[76]</sup>使用 SVM 对执行 4 种运动想象任务(右手、左手、右脚和左脚叩击)时运动皮层的 fNIRS 数据进行模式识别,获得了不错的准确率,这表明 SVM 适用于多分类任务识别。Dadgostar 等<sup>[77]</sup>为利用 fNIRS 技术诊断精神分裂症,基于 SVM 对采集的 16 个精神分裂症患者和 10 个健康被试的 Stroop 任务的 fNIRS 信号进行分类,结果发现使用 6 个通道数据的分类精度高达 87.31%,体现了 SVM 的良好性能。

### 5.3.2 线性判别分析(LDA)

LDA 最早由 Fisher 在 1936 年提出,故亦称之为 Fisher 线性判别。LDA 的基本思想为:设法将训练集中的样例投影到一条直线或一个超平面上,使同类样例的投影点尽可能接近,异类样例的投影点尽可能远离<sup>[78]</sup>。由于该方法具有简单、计算成本低、执行速度快和分类精度较高等诸多优点,因此成为 fNIRS-BCI 领域最常用的分类算法之一。

Luu 等<sup>[79]</sup>通过 fNIRS 探测前额叶皮层在任务期间的血液动力学响应,评估了 9 名被试对两种不同饮料的主观偏好(任务期间在心里作选择),使用 LDA 对单次试验的平均信号振幅进行分类,获得了

80% 的平均准确率,体现了该算法的高效性。为了提高 LDA 的性能,有时研究人员会对其进行适当改进。比如:上文提及的 Verdière 等<sup>[54]</sup>在 2018 年的研究中运用了收缩线性判别分析法(SLDA)。2019 年, Sereshkeh 等<sup>[57]</sup>设计了一个在线三分类(想象回答“是”或“不是”,以及休息状态) fNIRS-BCI 实验,用各通道 HbO 浓度变化的均值训练了一个正则化线性判别分析(RLDA)分类器;结果显示,12 名被试中有 9 人的三分类精度达到了 83.8%,证明了语音想象可以作为发展 fNIRS-BCI 的激活任务。

### 5.3.3 人工神经网络(ANN)

ANN 是通过人工模拟大脑神经网络处理信息的方式构建的运算模型,习惯将其直接简称为“神经网络”(NN)。ANN 由大量的节点(即“神经元”)相互连接构成,每两个节点之间按一定的权重相连,每个节点含有一种特定的输出函数(激活函数),当节点接收到的来自多个其他节点的总输入值(其他节点的输入加权求和)超过了该节点的激活阈值时,该节点被激活并产生输出。ANN 是一种非参数模型,不需要基于统计背景进行模型的构建<sup>[80]</sup>。此外,它还具有很强的鲁棒性、非线性映射能力和自学习能力,因此成为模式识别中的热门算法,近些年也被引入到 fNIRS-BCI 研究中。

Truong 等<sup>[81]</sup>提出了一种利用小波分析消除 fNIRS 信号噪声的方法,并从计算出的滤波系数中提取信息特征作为 ANN 分类的输入,得到了高达 99.9% 的离线分类精度,这一结果确定了小波分析作为信号预处理方法和 ANN 作为分类模型的优势。Naseer 等<sup>[82]</sup>利用 fNIRS 信号分析和比较了六种不同分类器——SVM、LDA、ANN、二次判别分析(QDA)、K-最近邻(KNN)和朴素贝叶斯分类器(NBC)——对心算和休息两类心理任务的分类准确率。从 7 个被试的 HbO 信号中提取出 6 种特征分别进行二维和三维组合,结果表明,这两种情况下 ANN 的平均分类准确率均最高,分别为 91.4% 和 96.3%,证明了 ANN 在某些情况下的表现远优于传统的机器学习算法。

### 5.3.4 深度神经网络(DNN)

DNN 是在 ANN 的基础上发展起来的,属于深度学习算法的一种。它拥有更多的网络层次结构,因而对事物的建模或抽象能力更强,能模拟更复杂的模型。DNN 可以直接对原始大脑信号进行处理,通过逆传播来学习可区分的信息,而不需要人工选



择特征。它通过深层结构捕获有代表性的高级特征和潜在的依赖关系,通常能获得高于传统算法的分类精度。DNN 的缺点是网络层数(与其学习能力相关)越多,时间复杂度越高,即模型复杂度与训练效率成反比。此外,训练时需要大量的数据,以降低过拟合风险和获得较好的分类效果。

Huve 等<sup>[83]</sup>使用 DNN 对精神任务(心算和单词生成)与休息状态下大脑活动的 fNIRS 信号进行分类,尽管在线分类效果欠佳,但离线状态下获得了 82% 的分类准确率。该研究表明,改变每层神经元的数量对分类精度没有太大的负面影响,而在训练中采用随机失活(Dropout)方法能提高 DNN 的分类精度。Nagasawa 等<sup>[84]</sup>为提升分类准确率,提出了一种使用生成对抗网络(GANs)增强近红外光谱数据的方法;同时,他们对使用 fNIRS 模拟数据训练的 DNN 进行了性能评估,评估结果显示:训练数据增加后,DNN 的分类精度提高了一倍。最近,他们又进一步使用 Wasserstein GANs 增强 fNIRS 数据,并将生成的数据扩充为训练数据,在不考虑分类器影响的情况下提高了四种不同类型任务的分类准确率<sup>[85]</sup>。这些研究表明,深度学习方法不仅可以用作分类,也可以作为数据增强的一种有效手段。

### 5.3.5 卷积神经网络(CNN)

CNN 也属于深度学习算法的一种,相较于普通的神经网络,它包含了一个由卷积层和子采样层构成的特征提取器,不仅可以自动提取适当的特征,还可以捕捉不同层次和范围的特征。另外,它可以通过给一组神经元赋予相同的连接权(即“权共享”)来节省训练开销,同时这样做又降低了过拟合的风险<sup>[86]</sup>。CNN 在多分类任务中表现较好,但值得一提的是,用于训练分类器的样本数量会直接影响它的分类精度,特别是在复杂的分类器中。随着样本数量的增加,复杂分类器能够达到比简单分类器更高的准确率。然而,前者的时间复杂度要比后者大很多。

Trakoolwilaiwan 等<sup>[87]</sup>以 CNN 作为自动特征提取器和分类器,对 8 个被试的左右手在运动执行任务和休息期间的血液动力学信号进行分类,并将分类结果与使用均值、峰值、斜率、方差、峰度和偏度等特征分类的 SVM 和 ANN 结果进行对比,结果发现,CNN 的分类精度较后两者分别提高了 6.49% 和 3.33%。他们的研究表明 CNN 中卷积滤波器提取的特征比传统方法选取的更具鉴别性。Yang

等<sup>[88]</sup>通过分析执行不同的精神任务时大脑前额叶皮层产生的血液动力学信号,对 15 名轻度认知障碍(MCI)患者和 9 名健康对照组进行了研究,以实现 MCI 的诊断;结果显示:使用 LDA 区分两类人群的最高准确率为执行 n-back 和 Stroop 任务时的 76.67%,而通过脑激活地图和通道关联地图特征训练的 CNN 在区分 n-back 任务时具有较高的分类准确率,分别为 90.62% 和 85.58%。该研究表明,结合使用 CNN 与图像生物标志(特征)可以为 MCI 患者的诊断提供可靠的临床工具。

### 5.3.6 隐马尔可夫模型(HMM)

HMM 的基本原理为:由一个隐藏的马尔可夫链随机生成不可观测的状态随机序列,再由各个状态生成一个观测,从而产生观测随机序列,每个观测向量都由一个具有相应概率密度分布的状态序列产生<sup>[89]</sup>。HMM 是一种非线性概率分类器,它提供了观察一组主要适用于时间序列分类的特征的概率,因而存在一定的局限性。

Sitaram 等<sup>[18]</sup>同时采用 SVM 和 HMM 两种模式识别算法对左右手运动想象任务的血液动力学响应信号数据进行离线分类,结果发现前者的平均准确率为 73%,而后者的平均准确率高达 89%,突出证明了 HMM 应用于 fNIRS-BCI 的可行性。此后,Falk 等<sup>[90]</sup>与 Seo 等<sup>[91]</sup>分别在他们的研究中应用了 HMM 算法,并获得了较高的分类精度,分别为 83% 和 85.7%,进一步证明了它良好的分类性能。

除了上述几种常见的分类算法,一些研究中偶尔也会采用梯度提升树(GBDT)、随机森林(RF)、逻辑回归(LR)、偏最小二乘判别分析(PLSDA)<sup>[91-92]</sup>,以及上文提及的 QDA、KNN 和 NBC 等分类算法。

### 5.3.7 分类算法统计

本课题组基于“超星发现”数据库统计了 2004 年以来,12 种特征分类算法在以往研究中的使用情况。通常情况下,研究中使用的分类算法会在文献摘要中提及,但也有部分文献仅在正文(一般为背景介绍或数据分析环节)中阐述。因此,为使统计数据更加精准,本课题组在检索主题为 BCI 与 fNIRS 的情况下,分别并含(“与”)检索了各种分类算法英文全称和简称分别作为检索主题、摘要以及全部字段(全文)时的文献数量,然后基于此计算出各分类算法出现的文献的平均数量(为精确起见,结果保留了两位小数),如表 2 所示。

表 2 2004—2020 年 fNIRS-BCI 特征分类算法检索情况(基于“超星发现”数据库;截止到 2020 年 6 月)

Table 2 Retrieval results of feature classification algorithm used in fNIRS-BCI from 2004 to 2020  
(Based on Superstar Discovery database; the statistical period is until June 2020)

Retrieval content	Subject	Abstract	All the fields	Average
SVM/Support Vector Machine	67/96	61/89	67/97	79.50
LDA/Linear Discriminant Analysis	40/70	38/68	40/70	54.33
ANN/Artificial Neural Network	10/19	9/15	10/22	14.17
DNN/Deep Neural Network	7/19	7/19	7/19	13.00
CNN/Convolutional Neural Network	3/8	3/7	3/8	5.33
HMM/Hidden Markov Model	3/4	3/4	3/4	3.50
LR/Logistic Regression	3/4	3/4	3/4	3.50
QDA/Quadratic Discriminant Analysis	3/3	3/3	3/3	3.00
GBDT/Gradient Boosting Decision Tree	3/3	3/3	3/3	3.00
NB/Naive Bayes	4/2	4/2	4/2	3.00
RF/Random Forest	2/2	2/2	2/2	2.00
KNN/K-Nearest Neighbor	1/1	1/1	1/1	1.00

根据表 2 的数据,本课题计算并绘制了 2004—2020 年 fNIRS-BCI 中主要特征分类算法占比饼图,如图 4 所示。Naseer 等<sup>[10]</sup>统计的 2004—2014 年 fNIRS-BCI 中主要特征分类算法占比饼图如图 5 所示。




图 5 2004—2014 年 fNIRS-BCI 中使用的主要特征分类算法的占比(数据来源于文献[10])

Fig. 5 Proportion of main feature classification algorithm used in fNIRS-BCI from 2004 to 2014 (data come from Ref. [10])

对比图 4、5 可以得到以下结论:

在 2014 年以前,LDA 是 fNIRS-BCI 中最为常用的分类算法,其次是 SVM;而时至今日,再次纵观文献却发现 SVM 成为了使用频率最高的分类算法。由此可以推断,SVM 在近几年的 fNIRS-BCI 研究中热度有所增长,甚至超过了 LDA。为了进一步验证这个结论,本课题组又使用与上述类似的方法,分别统计了三个主要数据库在

2015—2020 年间收录的涉及 SVM 与 LDA 的文献数量(取平均值,并四舍五入取整数),并计算平均收录数量,如表 3 所示。不出所料,近 5 年来,使用 SVM 的研究文献总量比使用 LDA 的文献总量平均高出 60.9%。除此之外,为排除数据库检索误差造成的影响,本课题组在另一个数据库(Web of Science)中,对根据相关主题条件检索到的文献进行了逐篇核查,结果发现 2015—2020 年间,确切使用 SVM 的文献数量比使用 LDA 的多出 34.6%。

表 3 2015—2020 年各数据库收录涉及 SVM 与 LDA 的 fNIRS-BCI 文献数量

Table 3 Quantity of fNIRS-BCI literatures related to SVM and LDA included in several database from 2015 to 2020

Classification algorithm	Superstar Discovery	Web of Science	Engineering Village	Average
SVM	54	34	22	37
LDA	31	23	14	23

此外还可以发现,2004—2020 年 fNIRS-BCI 研究中 HMM 的应用占比较 2014 年以前下降了不少。显然,HMM 逐渐淡出了 fNIRS-BCI 中主流分类算法的行列,取而代之的是近些年来热度日益增长的各种神经网络模型。表 4 给出了 2015—2020 年国内外对 fNIRS-BCI 的主要研究情况。

表 4 2015—2020 年 fNIRS-BCI 主要研究情况汇总

Table 4 Summary of major fNIRS-BCI studies from 2015 to 2020

Reference	Task	Feature	Classification algorithm	Number of classification	Classification accuracy
Ref. [93], 2015	MA and other 11 mental tasks	Slope of HbO, HbR and HbT, etc.	LDA	2	77% (personalized tasks); 73% (prescribed tasks)
Ref. [94], 2015	MA and mental counting	Mean of HbO and HbR	SVM	2	82.4% (the best)
Ref. [95], 2015	MA, word generation, mental rotation, and rest	Slope of HbO and HbR	DNN, LDA, and SLDA	2	DNN: 63.2%; LDA: 64.3%; SLDA: 65.7%
Ref. [96], 2015	Active and passive movements of fingers of the right hand	Average level of HbO and spatial patterns	SVM	2	71.82%
Ref. [97], 2017	MI and ME(hand extension and finger tapping)	Mean, slope, quadratic coefficient, and approximate entropy of HbO	SVM	4	87.65% (hand extension); 87.58% (finger tapping)
Ref. [82], 2016	MA and rest	Mean, peak, slope, variance, kurtosis, and skewness of HbO	LDA, QDA, KNN, NBC, SVM, and ANN	2	71.6%, 90.0%, 69.7%, 89.8%, 89.5%, and 91.4% (2D features); 79.6%, 95.2%, 64.5%, 94.8%, 95.2%, and 96.3% (3D features)
Ref. [98], 2017	ME of left and right hand(hand grasping)	Approximation coefficients of EEG and mean of HbO and HbR	SVM	2	91.02%
Ref. [99], 2017	Visual task of primary RGB colors	Mean, peak, slope, skewness, and kurtosis of HbO	LDA	3	55.29%
Ref. [71], 2017	MI of left and right hand	Mean, slope, and variance of HbO and HbR	LDA	2	75.3% (HbO); 72.3% (HbR)
Ref. [100], 2017	Handshake, ball grasp, poking, and cold temperature stimulation	Mean, peak, and skewness of HbO	LDA	2 and 4	Binary: 78.12%, 75.94%; quaternary: 50.31%
Ref. [87], 2017	ME of left and right hand and rest	Mean, peak, slope, variance, kurtosis, and skewness of HbO and HbR	SVM, ANN, and CNN	3	SVM: 86.19%; ANN: 89.35%; CNN: 92.68%
Ref. [101], 2018	ME of finger tapping	Mean and slope of HbO and HbR	LDA and GLM	2	LDA: 78.7%; GLM: 65.76% (HbO), 70.3% (HbR)

续表

Reference	Task	Feature	Classification algorithm	Number of classification	Classification accuracy
Ref. [72], 2018	MA and rest	Mean and variance of HbO and HbR	LDA	2	77.2%(HbO); 72.9%(HbR)
Ref. [77], 2018	Stroop task	Wavelet energy of HbO	SVM	2	87.31%(6 channels); 74.31%(16 channels)
Ref. [57], 2019	Speech imagery	Mean of HbO	RLDA	3	64.1%
Ref. [102], 2019	Drowsy and alert states of driving a car simulator	Automatically extracted from different channels and time windows	DNN and CNN	2	DNN: 97.2%(the best); CNN: 99.3%
Ref. [60], 2020	MI, word generation, n-back and discrimination/selection response task	Automatically extracted from EEG, HbO, HbR, and HbD	DNN and SVM	2 and 4	MI task:91%(DNN), 85%(SVM); n-back task: 87%(DNN), 82%(SVM)
Ref. [103], 2020	Emotional task	Average level of HbO and HbR	LDA	2	64.50%, 67.75%, 71.00%
Ref. [92], 2020	Self-paced walking	TKE and AUC of HbO, HbR, and HbT	GBDT, RF, LR, and LDA	2	AUC:94.4%, 93.6%, 82.6%, and 81.9%; TKE(GBDT): 98.75%(offline), 100%(pseudo-online)
Ref. [104], 2020	MI of left and right hand, MA and rest	Mean, slope, peak, skewness, and kurtosis of HbO and HbR	LDA, KNN, and SVM	2	LDA: 87.87%; KNN: 79.59%; SVM: 89.54%(the best)

Notes: MA means mental arithmetic; MI means motor imagery; ME means motor execution; GLM means general linear model; TKE means Teager-Kaiser energy; AUC means area under the curve.

## 6 发展趋势

### 6.1 多模态融合

多模态 BCI 就是将 fNIRS、EEG、fMRI 和 MEG 等多种不同模态的技术融合起来而开发的混合的 BCI 系统<sup>[30-31,105-106]</sup>。由于 fNIRS 和 EEG 模态

都具有信号易获取以及便携性、可在开放环境下使用等优点,因此研究人员更热衷于这两种模态的融合研究。已有不少研究证明,fNIRS-EEG 混合 BCI 的性能优于单独的 fNIRS 或 EEG 系统<sup>[59,107-108]</sup>。混合 BCI 能获得更好的性能与其可以实现不同模态技术的优势互补密切相关。表 5 对几种常见模态

表 5 各种模态 BCI 的比较

Table 5 Comparison of various models of BCI

BCI mode	Spatial resolution	Temporal resolution	Resistance to motion disturbance	Resistance to electromagnetic interference	Portability	Equipment cost	Novelty
EEG	*	* * *	*	*	* * *	*	*
PET	* * *	*	*	NA	*	* * *	*
fMRI	* * *	*	*	NA	*	* * *	*
fNIRS	* *	* *	* *	* * *	* * *	* *	* * *

的脑机接口技术进行了优缺点对比(星号越多,表示该项指标得分越高;NA 表示“无”)。混合系统不仅能够通过结合不同类型信号数据的特征来提高分类精度,还可以同时从相同或不同的大脑区域获取大脑信号,增加 BCI 控制命令的数量,从而使系统的功能更加多样和强大。可以预见,多模态融合将是 BCI 发展的一种趋势。

多模态融合的策略主要体现在两个方面:在硬件系统的设计上,可将 fNIRS 的光极-探测器对和 EEG 电极按最佳的排布方式集成在一个头盔上,以实现同时采集相同脑区不同类型的大脑活动信息<sup>[109]</sup>;在信号处理环节,可联合提取两种或多种信号的特征并将其输入分类器,从而获得更高的精度。

## 6.2 便携式

一套具有实用性的 fNIRS-BCI 系统应能在开放环境下使用,而不是局限于实验室。而这样的设备必然是简洁、轻便可携带(或穿戴)的,因此未来生产的设备系统应尽可能缩小体积,即便是与 fNIRS 结合的各种混合系统,也应开发成完全集成和无线式的<sup>[110]</sup>。

为方便开发便携式设备,系统的通道不宜过多,因此需最大限度地利用少通道中蕴含的信息,这在一定程度上也依赖于信号处理算法的性能,未来的研究中也应重视相关算法的优化。此外,在硬件优化方面,使用无线方式传输采集的信号是最佳的选择。

## 6.3 范式自然

为了获得更好的分类效果,许多与精神(心理)任务有关的 fNIRS-BCI 研究中使用的实验范式是非直接、非自然的。例如,通过让被试执行心算或心理歌唱等心理任务来传递信息或回答简单的“是”或“不是”问题<sup>[67]</sup>。这些较为复杂的心理任务通常与实际意图没有直接联系,且会涉及额外的大脑思维转换,这使得参与者很难完成这些任务,而且容易产生大脑疲劳。近些年,一些研究人员开始致力于与自然意图直接关联的实验范式的研究<sup>[20,57]</sup>。这类符合实际应用的范式更适用于开发对用户友好的产品,也将成为 fNIRS-BCI 心理任务的研究趋势。

目前,通过左右手(想象)运动来操控外部设备的左右运动是最基础和最易实现的自然任务范式。然而,一些相对复杂的自然任务范式(如通过想象说话使外设输出相应的语音<sup>[111]</sup>等)产生的大脑信号不易精确获取或解码较为困难,在 fNIRS 等无创模

式的 BCI 中难以成功应用,需要生物医学、神经科学和信号处理等领域的科研人员共同努力,以精确锁定任务激活的脑区并有效采集和解码可分信号,只有这样才有可能在未来解决这些难题。

## 6.4 异步

异步 BCI 系统仅在用户有控制意图的时候才被激活,且能连续监控脑信号,并对其进行实时、在线分析<sup>[112-113]</sup>。显然,异步 BCI 系统更加自然、实用,并适合于控制。未来,fNIRS-BCI 系统要走出实验室,投入实际应用,而基于异步的在线系统必将占据主导地位。

所设计的此类 BCI 的实验范式中通常会包含一个无任务的空闲状态,该空闲状态是控制 BCI 的开关。准确识别大脑从无控制(空闲)状态切换到意图控制(任务)状态至关重要,它决定了系统的可靠性和安全性<sup>[114]</sup>。一种检测策略是:首先利用训练好的机器学习算法模型预测任务激活样本的概率值,然后使用一个平滑窗(可通过网格搜索法选择窗口的长度和阈值)对其进行平滑,当平滑后的概率值大于阈值时,就认定为任务状态开始<sup>[92]</sup>。此外,由于需要实时采集和解码 fNIRS 信号,异步 BCI 对信号处理算法的性能要求较高。带通滤波法适用于在线系统,是信号降噪的首选方法。为了获得较好的实时响应性能,Li 等<sup>[92]</sup>提出了基于每个采样点的特征提取与识别方法,分别使用快速的 Teager-Kaiser 能量算子和梯度提升决策树来提取特征和建立实时检测模型,该模型的识别延时仅为  $(0.39 \pm 1.06)$  s, AUC 值高达 0.944。

## 7 目前存在的问题和局限性

### 7.1 血液动力学响应的延迟问题

fNIRS-BCI 的一个主要限制因素是与脑血液动力学响应相关的延迟,目前的文献并没有明确定义大脑接受特定刺激以后,血红蛋白氧合状态是何时开始有明显变化的。而且,这种自然延迟的时间存在较大的个体差异<sup>[115-117]</sup>。

为了提高 fNIRS 的响应速度,Cui 等<sup>[70]</sup>提出了一个称为“初始倾度”(initial dip)的参数,采用该参数对 HbO 和 HbR 信号进行趋势分析,以寻找刺激后血液动力学响应的初始倾向。他们使用这个参数并结合从信号中提取的其他特征进行分析,结果发现解码行为状态变化的延迟可以减小 50%。然而,要完全消除这种延迟的影响,目前尚无法实现。这种延迟严重影响了实时 fNIRS-BCI 应用系统的开发。

## 7.2 数据训练问题

研究表明,适当增加 fNIRS-BCI 系统的训练数据可以提高数据的分类精度,然而增加训练会给被试带来不适,甚至引起被试的反感,反而会影响采集数据的质量。另外,提供多少训练数据才能获得最佳分类效果目前尚无定论。因此,研究人员需要权衡分类精度和对被试(或用户)的友好性,这也是一项挑战。

此外,未来的 BCI 必定是朝着实时(在线)系统发展,这类系统仅能要求用户进行少量的训练甚至无需训练,因此要获得较好的分类效果异常困难。

## 7.3 没有统一的评定标准

世界各地有很多研究团队正在从事 fNIRS-BCI 研究,与使用其他技术手段的 BCI 一样,各个团队使用的研究方法、协议和设备等不尽相同。虽然研究人员的目标是最大限度地开发该技术,使其高效、满意地检测和翻译大脑活动,但是目前并没有完全一致的评定标准用于评价这类系统的优劣,因为评价 BCI 系统需要综合考虑实用程度、分类类别数(控制命令数)、分类效果和数据传输速度等诸多性能指标。缺乏统一的评定标准在一定程度上是不利于 fNIRS-BCI 发展的。

## 7.4 探测范围极其有限

fNIRS 仅能探测大脑皮层表面几毫米的大脑活动,尽管一些多通道设备可以覆盖大脑皮层的几乎所有区域,然而相对于整个大脑而言,其所探测的区域仍是相当有限的。许多大脑活动都涉及 fNIRS 探测不到的区域,这也是影响 fNIRS-BCI 发展的一大局限因素。

## 7.5 双向 BCI 开发难度大

在有创 BCI 领域,双向 BCI(亦称“闭环 BCI”)近年来成为了许多研究人员的研究重点。双向 BCI 是一种能将反馈信号直接作用于脑区的 BCI 系统,例如在基于脑皮层电图(ECoG)的系统中,被试控制的机械臂在触碰到物体后,通过电信号刺激大脑的体感皮层,让被试感觉到自己触碰到了物体,而不是使用传统的反馈方法——让被试通过视觉来了解控制结果<sup>[118]</sup>。一些无创 BCI 的研究者也想开发这种对用户更加方便友好的双向系统,但从双向 BCI 的原理来看,开发包括 fNIRS 技术在内的无创方法,难度不言而喻。

## 8 结束语

从 2004 年 fNIRS 首次被验证可用于发展 BCI

以来,fNIRS-BCI 的研究探索历经了 16 个春秋。尽管相比其他模式的 BCI,其历时不算长,但近些年来取得了不少令人瞩目的研究成果,从事该领域的科研人员也与日俱增。

从前额叶皮层区和初级运动皮层区采集的 fNIRS 信号具有较好的可分性,因此研究人员通常探测这两个区域。连续波光谱技术具有经济、简单灵活、采样率和信噪比高等特点,在 fNIRS-BCI 研究中使用得最多。单通道系统的体积小,便于开发便携式应用设备,而多通道系统能提供更多的大脑活动信息。

针对不同的噪声伪迹,本文探讨了相应的降噪方法。滤波器方法能在一定程度上消除大多数类型的噪声伪迹,而且其设计简单、计算成本低并适合在线操作,因此在数据去噪过程中最常用。鉴于不同方法对不同噪声伪迹的消除能力各异,有针对性地结合使用两种或多种方法,能达到更佳的降噪效果,尽管计算成本会相应增加。

fNIRS 信号中使用频率最高的特征是信号均值和斜率。用于将特征分类的算法主要包括 SVM、LDA、ANN、DNN、CNN 和 HMM 等。本课题组的统计结果显示:SVM 在近几年 fNIRS-BCI 研究中的使用占比有所增加,甚至超过了 LDA;而 HMM 这一主流分类算法逐渐被各种神经网络模型取代。DNN 和 CNN 等深度学习算法可以从 fNIRS 信号中自动提取出合适的特征,不需要人工选择特征,这是这些分类算法在 fNIRS-BCI 研究中热度上升的重要原因。不过它们的分类精度受训练样本数量的影响较大,对于少量样本的情况,其分类精度不见得会比传统的分类算法高。但是,随着样本数量增加,其优势便会逐渐显现出来,尽管训练所需的时间要比后者长得多。

纵观文献可以发现,实际上不存在绝对最优的特征或分类方法,因为各种分类器对各种特征有不同的“亲和力”。此外,不同的被试在执行同样的任务时,他们的大脑激活程度可能不同,从而导致大脑血液动力学信号存在差异。为提高总体分类精度,一种较为有效的策略是:对每个被试,基于特定的分类器,使用启发式方法,搜索和选择出对该分类器最具区分性的特征集;或者使用启发式方法搜索出最佳的特征和分类器组合。

未来的 fNIRS-BCI 系统会朝着多模态、便携式、范式自然和异步方向发展,但其仍存在一些待解决的问题或固有的局限性,比如血液动力学响应的

延迟问题、数据训练问题、没有统一的评定标准、探测范围极其有限以及双向 BCI 开发难度大等。

## 参 考 文 献

- [1] Wolpaw J R, Birbaumer N, McFarland D J, et al. Brain-computer interfaces for communication and control[J]. *Clinical Neurophysiology*, 2002, 113(6): 767-791.
- [2] Liu M C. Research on pattern recognition algorithms for motor-imagery-based brain-computer interface [D]. Guangzhou: South China University of Technology, 2009.  
刘美春. 基于运动想象的脑-机接口系统模式识别算法研究[D]. 广州: 华南理工大学, 2009.
- [3] Wolpaw J R, Wolpaw E W. Brain-computer interfaces principles and practice[M]. Fu Y F, Yang Q H, Xu B L, et al, Transl. Beijing: National Defense Industry Press, 2017:1-561.  
乔纳森·R·沃尔帕乌, 伊丽莎白·温特·沃尔帕乌. 脑-机接口原理与实践[M]. 伏云发, 杨秋红, 徐保磊, 等, 译. 北京: 国防工业出版社, 2017: 1-561.
- [4] Edelman B J, Johnson N, Sohrabpour A, et al. Systems neuroengineering: understanding and interacting with the brain[J]. *Engineering*, 2015, 1 (3): 292-308.
- [5] Shi S J. EEG based brain-computer interface on hearing [D]. Shanghai: Shanghai Jiaotong University, 2010.  
施少杰. 基于 EEG 的听觉脑-计算机接口研究[D]. 上海: 上海交通大学, 2010.
- [6] Liu Y, Yang Y, Sun M, et al. Highly specific noninvasive photoacoustic and positron emission tomography of brain plaque with functionalized croconium dye labeled by a radiotracer[J]. *Chemical Science*, 2017, 8(4): 2710-2716.
- [7] Liu Y, Liu H, Yan H, et al. Aggregation-induced absorption enhancement for deep near-infrared II photoacoustic imaging of brain gliomas *in vivo* [J]. *Advanced Science*, 2019, 6(8): 1801615.
- [8] Wang R F, Liu H J, Zhang C L. Prospect of study and application on PET receptor imaging[J]. *Chinese Journal of Medical Imaging Technology*, 2006, 22 (10): 1599-1603.  
王荣福, 刘红洁, 张春丽. PET 受体显像的研究应用进展[J]. *中国医学影像技术*, 2006, 22(10): 1599-1603.
- [9] Villringer A, Planck J, Hock C, et al. Near infrared spectroscopy (NIRS): a new tool to study hemodynamic changes during activation of brain function in human adults[J]. *Neuroscience Letters*, 1993, 154(1/2): 101-104.
- [10] Naseer N, Hong K S. fNIRS-based brain-computer interfaces: a review [J]. *Frontiers in Human Neuroscience*, 2015, 9: 3.
- [11] Jöbsis F F. Noninvasive, infrared monitoring of cerebral and myocardial oxygen sufficiency and circulatory parameters [J]. *Science*, 1977, 198 (4323): 1264-1267.
- [12] Delpy D T, Cope M, van der Zee P, et al. Estimation of optical pathlength through tissue from direct time of flight measurement [J]. *Physics in Medicine and Biology*, 1988, 33(12): 1433-1442.
- [13] Cope M, Delpy D T. System for long-term measurement of cerebral blood and tissue oxygenation on newborn infants by near infra-red transillumination [J]. *Medical and Biological Engineering and Computing*, 1988, 26(3): 289-294.
- [14] Fantini S, Franceschini M A, Gratton E, et al. Non-invasive optical mapping of the piglet brain in real time[J]. *Optics Express*, 1999, 4(8): 308-314.
- [15] McCormick P W, Stewart M, Lewis G, et al. Intracerebral penetration of infrared light: technical note[J]. *Journal of Neurosurgery*, 1992, 76 (2): 315-318.
- [16] Hu H B. Development and application of near-infrared spectroscopy [D]. Hefei: University of Science and Technology of China, 2010.  
胡汉彬. 功能近红外光谱成像研究及应用[D]. 合肥: 中国科学技术大学, 2010.
- [17] Coyle S, Ward T, Markham C, et al. On the suitability of near-infrared (NIR) systems for next-generation brain-computer interfaces [J]. *Physiological Measurement*, 2004, 25(4): 815-822.
- [18] Sitaram R, Zhang H H, Guan C T, et al. Temporal classification of multichannel near-infrared spectroscopy signals of motor imagery for developing a brain-computer interface [J]. *NeuroImage*, 2007, 34(4): 1416-1427.
- [19] Naseer N, Hong M J, Hong K S. Online binary decision decoding using functional near-infrared spectroscopy for the development of brain-computer interface [J]. *Experimental Brain Research*, 2014, 232(2): 555-564.
- [20] Gallegos-Ayala G, Furdea A, Takano K, et al. Brain communication in a completely locked-in patient using bedside near-infrared spectroscopy [J]. *Neurology*, 2014, 82(21): 1930-1932.
- [21] Abdalmalak A, Milej D, Yip L C M, et al. Assessing time-resolved fNIRS for brain-computer interface applications of mental communication [J]. *Frontiers in Neuroscience*, 2020, 14: 105.

- [22] Li C Q. Near infrared spectroscopy and brain monitoring[J]. Foreign Medical Sciences Section on Neurology & Neurosurgery, 1995, 22(2): 70-72.  
李长清. 近红外光谱技术与脑监测[J]. 国外医学神经病学神经外科学分册, 1995, 22(2): 70-72.
- [23] Strangman G, Boas D A, Sutton J P. Non-invasive neuroimaging using near-infrared light[J]. Biological Psychiatry, 2002, 52(7): 679-693.
- [24] Xu W T. Brain blood-oxygen detection based on near-infrared spectroscopy[D]. Chengdu: University of Electronic Science and Technology of China, 2014.  
徐文廷. 基于近红外光谱技术的脑血氧检测[D]. 成都: 电子科技大学, 2014.
- [25] Gagnon L, Cooper R J, Yücel M A, et al. Short separation channel location impacts the performance of short channel regression in NIRS [J]. NeuroImage, 2012, 59(3): 2518-2528.
- [26] Yamamoto T, Maki A, Kadoya T, et al. Arranging optical fibres for the spatial resolution improvement of topographical images[J]. Physics in Medicine and Biology, 2002, 47(18): 3429-3440.
- [27] Derosière G, Mandrick K, Dray G, et al. NIRS-measured prefrontal cortex activity in neuroergonomics: strengths and weaknesses [J]. Frontiers in Human Neuroscience, 2013, 7: 583.
- [28] Jiang J, Jiao X J, Pan J J, et al. Emotional state recognition based on functional near-infrared spectroscopy[J]. Acta Optica Sinica, 2016, 36(3): 0317002.  
姜劲, 焦学军, 潘津津, 等. 基于功能性近红外光谱技术识别情绪状态[J]. 光学学报, 2016, 36(3): 0317002.
- [29] Torricelli A, de Contini D, Pifferi A, et al. Time domain functional NIRS imaging for human brain mapping[J]. NeuroImage, 2014, 85: 28-50.
- [30] Shin J, Kwon J, Im C H. A ternary hybrid EEG-NIRS brain-computer interface for the classification of brain activation patterns during mental arithmetic, motor imagery, and idle state [J]. Frontiers in Neuroinformatics, 2018, 12: 5.
- [31] Shin J, von Lümann A, Blankertz B, et al. Open access repository for hybrid EEG-NIRS data [C] // 2018 6th International Conference on Brain-Computer Interface (BCI), January 15-17, 2018, Gangwon, Korea (South). New York: IEEE Press, 2018: 1-4.
- [32] Ding X M, Wang B Y, Liu D Y, et al. Multi-channel brain functional imaging system based on lock-in photon counting [J]. Chinese Journal of Lasers, 2019, 46(1): 0107001.  
丁雪梅, 王兵元, 刘东远, 等. 基于锁相光子计数的多通道脑功能成像系统[J]. 中国激光, 2019, 46(1): 0107001.
- [33] Aicaigou.UK UCL near-infrared functional brain imaging system [EB/OL]. [2020-06-20]. <https://b2b.baidu.com/land?id=9765b316417aa3e19d6d1b18fa5f081810>.  
爱采购. 英国 UCL 近红外脑功能成像系统 [EB/OL]. [2020-06-20]. <https://b2b.baidu.com/land?id=9765b316417aa3e19d6d1b18fa5f081810>.
- [34] Yang Q, Ge S. Classification of a single channels fNIRS signal for a brain computer interface[C] // 2014 7th International Conference on Biomedical Engineering and Informatics, October 14-16, 2014, Dalian, China. New York: IEEE Press, 2014: 46-50.
- [35] Xu G, Li X L, Liu X M. A simple design of functional near-infrared spectroscopy system [J]. Spectroscopy and Spectral Analysis, 2015, 35(2): 552-556  
徐刚, 李小隼, 刘晓民. 简易脑功能近红外光谱系统设计[J]. 光谱学与光谱分析, 2015, 35(2): 552-556
- [36] Yin X X, Shi G, Wang Z D, et al. Development of one-channel fNIRS system and physiological noise reduction in brain hemodynamic responses[C] // 2015 IEEE International Conference on Robotics and Biomimetics (ROBIO), December 6-9, 2015, Zhuhai, China. New York: IEEE Press, 2015: 763-768.
- [37] Zhang Y Y, Li Z. Review of noise sources and denoising methods based on functional near-infrared spectroscopy for brain imaging [J]. Infrared, 2019, 40(7): 35-46.  
张阳阳, 李征. 功能性近红外光谱脑成像噪声源及去噪方法综述[J]. 红外, 2019, 40(7): 35-46.
- [38] Zhang Y. Study of signal extraction method in brain activity measurement by near infrared spectroscopy [D]. Harbin: Harbin Institute of Technology, 2011.  
张岩. 基于近红外光谱技术的脑功能活动信号提取方法研究[D]. 哈尔滨: 哈尔滨工业大学, 2011.
- [39] Kohno S, Miyai I, Seiyama A, et al. Removal of the skin blood flow artifact in functional near-infrared spectroscopic imaging data through independent component analysis [J]. Journal of Biomedical Optics, 2007, 12(6): 062111.
- [40] Virtanen J, Noponen T E J, Meriläinen P. Comparison of principal and independent component analysis in removing extracerebral interference from near-infrared spectroscopy signals [J]. Journal of Biomedical Optics, 2009, 14: 054032.
- [41] Hsu S H, Pion-Tonachini L, Palmer J, et al. Modeling brain dynamic state changes with adaptive mixture independent component analysis[J].



- NeuroImage, 2018, 183: 47-61.
- [42] Zhang Y H, Brooks D H, Franceschini M A, et al. Eigenvector-based spatial filtering for reduction of physiological interference in diffuse optical imaging [J]. *Journal of Biomedical Optics*, 2005, 10(1): 011014.
- [43] Franceschini M A, Joseph D K, Huppert T J, et al. Diffuse optical imaging of the whole head[J]. *Journal of Biomedical Optics*, 2006, 11(5): 054007.
- [44] Zhang Q, Brown E N, Strangman G E. Adaptive filtering to reduce global interference in evoked brain activity detection: a human subject case study [J]. *Journal of Biomedical Optics*, 2007, 12(6): 064009.
- [45] Zhang Y, Liu X, Liu D, et al. Evoked hemodynamic response estimation to auditory stimulus using recursive least squares adaptive filtering with multidistance measurement of near-infrared spectroscopy[J]. *Journal of Healthcare Engineering*, 2018, 2018: 7609713.
- [46] Pinti P L, Merla A, Aichelburg C, et al. A novel GLM-based method for the Automatic IDentification of functional Events (AIDE) in fNIRS data recorded in naturalistic environments[J]. *NeuroImage*, 2017, 155: 291-304.
- [47] Santosa H, Hong M J, Kim S P, et al. Noise reduction in functional near-infrared spectroscopy signals by independent component analysis [J]. *The Review of Scientific Instruments*, 2013, 84(7): 073106.
- [48] Jang K E, Tak S, Jung J, et al. Wavelet minimum description length detrending for near-infrared spectroscopy [J]. *Journal of Biomedical Optics*, 2009, 14(3): 034004.
- [49] Robertson F C, Douglas T S, Meintjes E M. Motion artifact removal for functional near infrared spectroscopy: a comparison of methods [J]. *IEEE Transactions on Biomedical Engineering*, 2010, 57(6): 1377-1387.
- [50] Cooper R J, Selb J, Gagnon L, et al. A systematic comparison of motion artifact correction techniques for functional near-infrared spectroscopy[J]. *Frontiers in Neuroscience*, 2012, 6: 147.
- [51] Virtanen J, Kotilahti K M, Ilmoniemi R, et al. Accelerometer-based method for correcting signal baseline changes caused by motion artifacts in medical near-infrared spectroscopy[J]. *Journal of Biomedical Optics*, 2011, 16(8): 087005.
- [52] Siddiquee M R, Xue T, Marquez J S, et al. Sensor fusion in human cyber sensor system for motion artifact removal from NIRS signal [C] // 2019 12th International Conference on Human System Interaction (HSI), June 25-27, 2019, Richmond, USA. New York: IEEE, 2019: 192-196.
- [53] Rayyan A K, Noman N, Sajid S, et al. Cortical tasks-based optimal filter selection: an fNIRS study [J]. *Journal of Healthcare Engineering*, 2020, 2020: 9152369.
- [54] Verdière K J, Roy R N, Dehais F. Detecting pilot's engagement using fNIRS connectivity features in an automated vs. manual landing scenario[J]. *Frontiers in Human Neuroscience*, 2018, 12: 6.
- [55] Matthews F, Pearlmutter B A, Wards T E, et al. Hemodynamics for brain-computer interfaces [J]. *IEEE Signal Processing Magazine*, 2008, 25(1): 87-94.
- [56] Holper L, Biallas M, Wolf M. Task complexity relates to activation of cortical motor areas during uni- and bimanual performance: a functional NIRS study[J]. *NeuroImage*, 2009, 46(4): 1105-1113.
- [57] Sereshkeh A R, Yousefi R, Wong A T, et al. Online classification of imagined speech using functional near-infrared spectroscopy signals [J]. *Journal of Neural Engineering*, 2019, 16(1): 016005.
- [58] Shin J, Müller K R, Hwang H J. Near-infrared spectroscopy (NIRS)-based eyes-closed brain-computer interface (BCI) using prefrontal cortex activation due to mental arithmetic [J]. *Scientific Reports*, 2016, 6(1): 36203.
- [59] Yin X X, Xu B L, Jiang C H, et al. A hybrid BCI based on EEG and fNIRS signals improves the performance of decoding motor imagery of both force and speed of hand clenching [J]. *Journal of Neural Engineering*, 2015, 12(3): 036004.
- [60] Saadati M, Nelson J, Ayaz H. Multimodal fNIRS-EEG classification using deep learning algorithms for brain-computer interfaces purposes [M] // Ayaz H. *Advances in neuroergonomics and cognitive engineering*. Cham: Springer, 2020, 953: 209-220.
- [61] Borgheai S B, McLinden J, Zisk A H, et al. Enhancing communication for people in late-stage ALS using an fNIRS-based BCI system [J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2020, 28(5): 1198-1207.
- [62] Tai K, Chau T. Single-trial classification of NIRS signals during emotional induction tasks: towards a corporeal machine interface[J]. *Journal of Neuroengineering and Rehabilitation*, 2009, 6: 39.
- [63] Abibullaev B, An J. Classification of frontal cortex haemodynamic responses during cognitive tasks using wavelet transforms and machine learning algorithms [J]. *Medical Engineering & Physics*, 2012, 34(10): 1394-1410.

- [64] Qureshi N K, Naseer N, Noori F M, et al. Enhancing classification performance of functional near-infrared spectroscopy- brain-computer interface using adaptive estimation of general linear model coefficients[J]. *Frontiers in Neurorobotics*, 2017, 11: 00033.
- [65] von Lüthmann A, Ortega-Martinez A, Boas D A, et al. Using the general linear model to improve performance in fNIRS single trial analysis and classification: a perspective[J]. *Frontiers in Human Neuroscience*, 2020, 14: 00030.
- [66] Noori F M, Naseer N, Qureshi N K, et al. Optimal feature selection from fNIRS signals using genetic algorithms for BCI[J]. *Neuroscience Letters*, 2017, 647: 61-66.
- [67] Power S D, Kushki A, Chau T. Automatic single-trial discrimination of mental arithmetic, mental singing and the no-control state from prefrontal activity: toward a three-state NIRS-BCI[J]. *BMC Research Notes*, 2012, 5(1): 1-10.
- [68] Musallam S. Cognitive control signals for neural prosthetics[J]. *Science*, 2004, 305(5681): 258-262.
- [69] Yoo S S, Fairney T, Chen N K, et al. Brain-computer interface using fMRI: spatial navigation by thoughts[J]. *Neuroreport*, 2004, 15(10): 1591-1595.
- [70] Cui X, Bray S, Reiss A L. Speeded near infrared spectroscopy (NIRS) response detection[J]. *PLoS One*, 2010, 5(11): e15474.
- [71] Zhang S, Zheng Y C, Wang D F, et al. Application of a common spatial pattern-based algorithm for an fNIRS-based motor imagery brain-computer interface[J]. *Neuroscience Letters*, 2017, 655: 35-40.
- [72] Jiang X Y, Gu X, Mei Z N, et al. A modified common spatial pattern algorithm customized for feature dimensionality reduction in fNIRS-based BCIs[C]//2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), July 18-21, 2018, Honolulu, HI, USA. New York: IEEE Press, 2018: 5073-5076.
- [73] Jiang X Y, Gu X, Xu K, et al. Independent decision path fusion for bimodal asynchronous brain-computer interface to discriminate multiclass mental states[J]. *IEEE Access*, 2019, 7: 165303-165317.
- [74] Zhang J, Zhao H D, Li Y H, et al. Classifier for recognition of fine-grained vehicle models under complex background[J]. *Laser & Optoelectronics Progress*, 2019, 56(4): 041501.  
张洁, 赵红东, 李宇海, 等. 复杂背景下车型识别分类器[J]. *激光与光电子学进展*, 2019, 56(4): 041501.
- [75] Sun Z H. Study on support vector machine and its application in control[D]. Hangzhou: Zhejiang University, 2003.  
孙宗海. 支持向量机及其在控制中的应用研究[D]. 杭州: 浙江大学, 2003.
- [76] Batula A M, Ayaz H, Kim Y E. Evaluating a four-class motor-imagery-based optical brain-computer interface[C]//2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, August 26-30, 2014, Chicago, IL, USA. New York: IEEE Press, 2014: 2000-2003.
- [77] Dadgostar M, Setarehdan S K, Shahzadi S, et al. Classification of schizophrenia using SVM via fNIRS[J]. *Biomedical Engineering: Applications, Basis and Communications*, 2018, 30(2): 1850008.
- [78] Zhao X X, Liu G, Li W X, et al. Infrared spectroscopy combined with LDA and BPNN based on wavelet transform to detect citrus osbeck anthracnose[J]. *Chinese Journal of Lasers*, 2014, 41(s1): 115003.  
赵兴祥, 刘刚, 李伟星, 等. 红外光谱结合基于小波变换的 LDA 和 BPNN 研究甜橙炭疽病[J]. *中国激光*, 2014, 41(s1): 115003.
- [79] Luu S, Chau T. Decoding subjective preference from single-trial near-infrared spectroscopy signals[J]. *Journal of Neural Engineering*, 2009, 6(1): 016003.
- [80] Wang X B, Ma X, Wang X C. Infrared spectral pattern recognition of watercolor pen ink based on artificial neural network[J]. *Laser & Optoelectronics Progress*, 2020, 57(15): 153005.  
王晓宾, 马泉, 王新承. 基于人工神经网络的水彩笔油墨红外光谱模式识别[J]. *激光与光电子学进展*, 2020, 57(15): 153005.
- [81] Truong Q D K, Masahiro N. Functional near infrared spectroscopy for cognition brain tasks by wavelets analysis and neural networks[J]. *International Journal of Biological and Life Sciences*, 2008, 4: 28-33.
- [82] Naseer N, Qureshi N K, Noori F M, et al. Analysis of different classification techniques for two-class functional near-infrared spectroscopy-based brain-computer interface[J]. *Computational Intelligence and Neuroscience*, 2016, 2016: 5480760.
- [83] Huve G, Takahashi K, Hashimoto M. Online recognition of the mental states of drivers with an fNIRS-based brain-computer interface using deep neural network[C]//2019 IEEE International Conference on Mechatronics (ICM), March 18-20, 2019, Ilmenau, Germany. New York: IEEE Press, 2019: 238-242.
- [84] Nagasawa T, Sato T, Nambu I, et al. Improving fNIRS-BCI accuracy using GAN-based data

- augmentation [C] // 2019 9th International IEEE/EMBS Conference on Neural Engineering (NER), March 20-23, 2019, San Francisco, CA, USA. New York: IEEE Press, 2019: 1208-1211.
- [85] Nagasawa T, Sato T, Nambu I, et al. fNIRS-GANs: data augmentation using generative adversarial networks for classifying motor tasks from functional near-infrared spectroscopy[J]. *Journal of Neural Engineering*, 2020, 17(1): 016068.
- [86] Zhou Z H. Machine learning[M]. Beijing: Tsinghua University Press, 2016: 113-114.  
周志华. 机器学习[M]. 北京: 清华大学出版社, 2016: 113-114.
- [87] Trakoolwilaiwan T, Behboodi B, Lee J, et al. Convolutional neural network for high-accuracy functional near-infrared spectroscopy in a brain-computer interface: three-class classification of rest, right-, and left-hand motor execution[J]. *Neurophotonics*, 2017, 5(1): 011008.
- [88] Yang D, Hong K S, Yoo S H, et al. Evaluation of neural degeneration biomarkers in the prefrontal cortex for early identification of patients with mild cognitive impairment: an fNIRS study[J]. *Frontiers in Human Neuroscience*, 2019, 13: 317.
- [89] Li H. Statistical learning method [M]. Beijing: Tsinghua University Press, 2012: 1-235.  
李航. 统计学习方法[M]. 北京: 清华大学出版社, 2012: 1-235.
- [90] Falk T H, Guirgis M, Power S, et al. Taking NIRS-BCIs outside the lab: towards achieving robustness against environment noise[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2011, 19(2): 136-146.
- [91] Seo Y W, Lee S D, Koh D K, et al. Partial least squares-discriminant analysis for the prediction of hemodynamic changes using near infrared spectroscopy[J]. *Journal of the Optical Society of Korea*, 2012, 16(1): 57-62.
- [92] Li C G, Xu J C, Zhu Y F, et al. Detecting self-paced walking intention based on fNIRS technology for the development of BCI [J]. *Medical & Biological Engineering & Computing*, 2020, 58(5): 933-941.
- [93] Weyand S, Schudlo L, Takehara-Nishiuchi K, et al. Usability and performance-informed selection of personalized mental tasks for an online near-infrared spectroscopy brain-computer interface[J]. *Neurophotonics*, 2015, 2(2): 025001.
- [94] Naseer N, Hong K S, Khan M J, et al. Analysis of classification performance of fNIRS signals from prefrontal cortex using various temporal windows [C]//2015 10th Asian Control Conference (ASCC), May 31 - June 3, 2015, Kota Kinabalu, Malaysia. New York: IEEE Press, 2015: 1-5.
- [95] Hennrich J, Herff C, Heger D, et al. Investigating deep learning for fNIRS based BCI [C]//2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), August 25-29, 2015, Milan, Italy. New York: IEEE Press, 2015: 2844-2847.
- [96] Jin S H, Lee S H, Jang G, et al. An application of common spatial pattern algorithm for accuracy improvement in classification of cortical activation pattern according to finger movement [C]//2015 54th Annual Conference of the Society of Instrument and Control Engineers of Japan (SICE), July 28-30, 2015, Hangzhou, China. New York: IEEE Press, 2015: 1260-1264.
- [97] Zhang Z, Jiao X J, Xu F G, et al. The investigation of brain-computer interface for motor imagery and execution using functional near-infrared spectroscopy [J]. *Proceedings of the SPIE*, 2017, 10245: 102450I.
- [98] Li R H, Potter T, Huang W T, et al. Enhancing performance of a hybrid EEG-fNIRS system using channel selection and early temporal features [J]. *Frontiers in Human Neuroscience*, 2017, 11: 462.
- [99] Liu X L, Hong K S. Detection of primary RGB colors projected on a screen using fNIRS[J]. *Journal of Innovative Optical Health Sciences*, 2017, 10(3): 1750006.
- [100] Hong K S, Bhutta M R, Liu X L, et al. Classification of somatosensory cortex activities using fNIRS[J]. *Behavioural Brain Research*, 2017, 333: 225-234.
- [101] Gemignani J, Middell E, Barbour R L, et al. Improving the analysis of near-infrared spectroscopy data with multivariate classification of hemodynamic patterns: a theoretical formulation and validation[J]. *Journal of Neural Engineering*, 2018, 15(4): 045001.
- [102] Tanveer M A, Khan M J, Qureshi M J, et al. Enhanced drowsiness detection using deep learning: an fNIRS study[J]. *IEEE Access*, 2019, 7: 137920-137929.
- [103] Lucas R T, Juliana T, André M C, et al. Subject-independent decoding of affective states using functional near-infrared spectroscopy [EB/OL]. (2020-09-05) [2021-01-07]. DOI: 10.1371/journal.pone.0244840.
- [104] Aydin E A. Subject-specific feature selection for near infrared spectroscopy based brain-computer interfaces [J]. *Computer Methods and Programs in*

- Biomedicine, 2020, 195: 105535.
- [105] Mehagnoul-Schipper D J, van der Kallen B F W, Colier W N J M, et al. Simultaneous measurements of cerebral oxygenation changes during brain activation by near-infrared spectroscopy and functional magnetic resonance imaging in healthy young and elderly subjects [J]. *Human Brain Mapping*, 2002, 16(1): 14-23.
- [106] Sun J M. Research on artifact real-time removal method of EEG signal in EEG-fMRI hybrid brain-computer interface [D]. Guangzhou: South China University of Technology, 2018.  
孙佳敏. EEG-fMRI 混合脑机接口系统中 EEG 信号的在线去伪迹研究 [D]. 广州: 华南理工大学, 2018.
- [107] Fazli S, Mehnert J, Steinbrink J, et al. Enhanced performance by a hybrid NIRS-EEG brain computer interface [J]. *NeuroImage*, 2012, 59(1): 519-529.
- [108] Morioka H, Kanemura A, Morimoto S, et al. Decoding spatial attention by using cortical currents estimated from electroencephalography with near-infrared spectroscopy prior information [J]. *NeuroImage*, 2014, 90: 128-139.
- [109] Xiong X, Fu Y F, Zhang X B, et al. Design and experiment of a multi-modal electroencephalogram-near infrared spectroscopy helmet for simultaneously acquiring at the same brain area [J]. *Journal of Biomedical Engineering*, 2018, 35(2): 290-296.  
熊馨, 伏云发, 张夏冰, 等. 一种多模态脑电和近红外光谱联合采集头盔设计及实验研究 [J]. *生物医学工程学杂志*, 2018, 35(2): 290-296.
- [110] Safaie J, Grebe R, Abrishami M H, et al. Toward a fully integrated wireless wearable EEG-NIRS bimodal acquisition system [J]. *Journal of Neural Engineering*, 2013, 10(5): 056001.
- [111] Anumanchipalli G K, Chartier J, Chang E F. Speech synthesis from neural decoding of spoken sentences [J]. *Nature*, 2019, 568(7753): 493-498.
- [112] Touradj E, Jean-Marc V, Gary G. Brain-computer interface in multimedia communication [J]. *IEEE Signal Processing Magazine*, 2003, 20(1): 14-24.
- [113] Qi H T. Research of brain-computer interface based on motor imagery EEG [D]. Shenyang: Northeastern University, 2012.  
漆海涛. 基于运动想象脑电的脑-机接口技术的研究 [D]. 沈阳: 东北大学, 2012.
- [114] Hasan B A S, Gan J Q. Unsupervised movement onset detection from EEG recorded during self-paced real hand movement [J]. *Medical & Biological Engineering & Computing*, 2010, 48(3): 245-253.
- [115] Hwang H J, Choi H, Kim J Y, et al. Toward more intuitive brain-computer interfacing: classification of binary covert intentions using functional near-infrared spectroscopy [J]. *Journal of Biomedical Optics*, 2016, 21(9): 091303.
- [116] Naseer N, Hong K S. Classification of functional near-infrared spectroscopy signals corresponding to the right- and left-wrist motor imagery for development of a brain-computer interface [J]. *Neuroscience Letters*, 2013, 553: 84-89.
- [117] Schudlo L C, Chau T. Development of a ternary near-infrared spectroscopy brain-computer interface: online classification of verbal fluency task, stroop task and rest [J]. *International Journal of Neural Systems*, 2018, 28(4): 1750052.
- [118] Li C Y, Zhao W J. Decrypting the brain-computer interface: an interview with He Bin, dean of the Department of Biomedical Engineering, CMU [EB/OL]. [2020-04-18]. <http://www.zhishifenzi.com/depth/depth/8785.html>.  
李澄宇, 赵维杰. 解密脑机接口: 专访 CMU 生物医学工程系主任贺斌 [EB/OL]. [2020-04-18]. <http://www.zhishifenzi.com/depth/depth/8785.html>.