



# 基于改进共空间模式与深度信念网络的脑电信号识别算法研究

项伟, 吴迎年\*

北京信息科技大学自动化学院, 北京 100192

\* 通信作者. E-mail: wuyingnian@126.com

收稿日期: 2018-03-14; 接受日期: 2018-04-08; 网络出版日期: 2018-07-16

北京信息科技大学重点研究培育项目 (批准号: 5221823307)、研究生科技创新项目 (批准号: 5121723303)、大学生创业培育基金项目 (批准号: 5111710813) 资助

**摘要** 使用脑电信号控制智能轮椅是智能轮椅的一种新型控制方式, 其控制中最大的问题在于脑电信号的识别与分类, 尤其是对多种脑电信号的分类. 为了提高多种脑电信号识别与分类的准确度, 本文提出了将改进共空间模式与深度信念网络运用于脑电信号识别与分类中. 采用 Emotiv EPOC+ 脑电采集仪采集多种脑电信号, 改进共空间模式针对多种脑电信号进行特征信号提取, 深度信念网络对提取的特征信号进行识别与分类. 实验表明, 提出的改进共空间模式与深度信念网络的分类准确率高于传统脑电信号的分类方法, 在未来研究多种脑电信号的识别与分类上提供了一种研究思路.

**关键词** 脑-机接口, 脑电信号, 改进共空间模式, 深度信念网络

## 1 引言

2013年, 美国政府公布了“推进创新神经技术脑研究计划”, 脑科学的研究得到了充分的肯定和支持, 脑-机接口 (brain-computer interface, BCI) 作为脑科学的研究领域之一备受研究者的关注. 脑-机接口是一种人-机接口 (human-computer interface) 方式, 是人类大脑与外部环境直接建立的一种神经信号交流通道. 脑-机接口通过专用的脑电信号 (electroencephalogram, EEG) 采集设备采集和提取人类的脑电信号, 进而识别脑电信号中携带的人类的思维想象, 据此产生相应的控制信号, 实现人脑中中枢神经系统与外部设备的直接交互. 目前, 脑-机接口技术已经大量应用于运动感知、肢体康复、残疾人生活辅助等医学领域, 另外, 在教育、游戏、智能家居、航空等领域也具有很大的研究与应用价值.

目前, 我国正进入老龄化社会, 智能轮椅给予了老年人出行的极大方便, 但是, 智能轮椅普遍采用手柄控制, 其交互手段并不自然, 对于脑卒中病人或双手甚至四肢残疾人士尤其困难, 脑-机接口技

**引用格式:** 项伟, 吴迎年. 基于改进共空间模式与深度信念网络的脑电信号识别算法研究. 中国科学: 信息科学, 2018, 48: 919-931, doi: 10.1360/N112017-00297  
Xiang W, Wu Y N. Research on EEG recognition based on improved-common spatial patterns and deep-belief network algorithm (in Chinese). Sci Sin Inform, 2018, 48: 919-931, doi: 10.1360/N112017-00297

术运用到智能轮椅中,很好地解决了上述问题<sup>[1,2]</sup>.对于脑电信号控制智能轮椅,一般通过高性能的脑电信号传感器进行脑电信号采集,对采集完的脑电信号进行预处理,再对处理好的脑电信号进行特征提取,最后,通过对特征向量进行模式分类得到对应的控制信号,从而控制智能轮椅的运动.目前,脑-机接口的模式分类研究已经取得了很多成果,其中神经网络和支持向量机(support vector machine, SVM)对两类脑电信号分类效果较好;针对本文研究的脑电信号控制智能轮椅的四方位运动以及停止状态,希望对于多类高维的脑电信号具备更加优秀的分类效果.

通过实验探究,本文提出了改进共空间模式(improved-common spatial patterns, I-CSP)与深度信念网络(deep belief network, DBN)进行脑电信号识别与分类.利用改进共空间模式能有效提高脑电信号的信噪比,获取多类(平面四方位运动及静止状态)运动想象脑电特征信号,再利用深度信念网络对提取的脑电特征信号进行特征学习并进行分类(CSP-DBN).通过本文提出的方案与用粗糙数据结合深度信念网络的分类(DBN)和共空间模式特征数据结合支持向量机(CSP-SVM)的分类的对比表明,改进型共空间模式结合深度信念网络能够更好地学习有效特征,对多类脑电特征信号的分类更加准确.

## 2 脑-机接口研究现状

脑-机接口研究早在20世纪60年代开始就被科学家所重视,Delgado与Fetz几乎同时对脑-机接口进行了探索. Delgado开发出了一款可移植芯片,通过无线电刺激大脑达到控制目标自由移动的目的;Fetz则研究猴子的单个脑细胞从而控制仪表盘的指针,这些探索为脑-机接口的发展奠定了基础.

伴随着基础脑神经科学、信号采集技术、信号处理技术,以及机器学习的迅猛发展,脑-机接口技术得到了很好的发展.目前,美国、德国、日本、奥地利等都有相当成熟的脑-机接口研究小组,国内也有不少大学和研究机构从事脑-机接口技术研究.为了探究脑-机接口算法,多家世界著名脑-机接口研究中心多次联合举办“BCI competition”的脑-机接口分析竞赛,大大促进了脑-机接口的发展.

目前,脑-机接口研究<sup>[3,4]</sup>内容主要包括脑电信号采集、预处理<sup>[5]</sup>、特征提取、模式识别与分类、工程控制等方面,其中,预处理、特征提取和模式识别是脑-机接口研究的核心内容<sup>[6~8]</sup>.脑电信号的预处理一般是去除脑电信号中的伪迹,主要包括肌肉运动或眼动产生的伪迹以及电力工频噪声等.获取脑电信号数据就是去除或抑制这些伪迹,使得脑电信号的设备获取的信息仅来自于大脑,对这些脑电信号进行特征提取,才能得到有效的脑电特征数据.对脑电信号预处理一般采用阈值法或者带阻滤波等方法,阈值法预处理时,生物信号的非平稳性可能会保留部分含伪迹的数据,带阻滤波预处理时可能会将部分高频有用信号分量除去,因此,预处理过程容易造成有效信息被去除.深度信念网络对粗糙的脑电数据具备强大的特征学习能力,能直接从粗糙脑电数据中学习有效脑电特征<sup>[9]</sup>,这样就能简化脑电识别流程,有效进行脑电信号分类.

对运动想象脑电信号进行特征提取能有效提高识别与分类的能力.目前,提取脑电特征信号的方法主要有时域分析法、频域分析法、时频分析法、空域滤波法等.自回归(AR)模型就属于时域分析法,通过自然信号在时间上的相关联系,利用之前的一些测量值预测下一个测量值.快速Fourier变换(FFT)、频谱分析都属于频域分析法,其主要是研究脑电信号在频域中各个节律( $\mu$ 节律、 $\beta$ 节律、 $\gamma$ 节律等)的幅值与功率的变化.小波变换<sup>[10]</sup>属于时频分析法,具有变焦距特性,能突显类别中的差异,具有很好的频域滤波效果.上述方法主要是研究单一通道的脑电信号,本文采用的脑电采集设备具备




图 1 Emotiv EPOC+ 脑电信号通道分布图

Figure 1 Emotiv EPOC+ channel distribution of EEG

采集多通道脑电信号的能力,多通道脑电信号之间的联系也是特征提取研究的内容,共空间模式作为空域滤波<sup>[11]</sup>的一种,主要研究多导联的脑电信号,具备有效提高信噪比的能力。

利用特性信号进行模式识别和分类是研究脑-机接口的最终目的。目前,脑电特征信号的分类算法<sup>[12~14]</sup>主要包括神经网络、支持向量机(SVM)、Bayes 分类器、线性回归等。其中,支持向量机和神经网络应用最为广泛,其分类效果比较突出。深度信念网络作为新型脑电信号分类方式具备强大的学习能力,尤其是对粗糙脑电信号的处理能力,让该方法在脑电信号分类上具备一定优势。

### 3 脑电信号采集系统

脑-机接口研究工作是基于对脑电信号的分析,因此,对脑电信号的采集是研究脑-机接口的首要环节。脑电信号一般使用国际电极 10~20 安放标准的电极帽或采集仪进行采集,主要采集与运动想象脑电相关通道的数据信号。本文使用的脑电信号采集仪是美国 Emotiv System 公司开发的 Emotiv EPOC+ 脑电采集仪,其电极安放是采用国际电极 10~20 安放标准,一共安放了 14 个电极以及两个参考电极,各个电极分别是 AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4, 以及参考电极 CMS 和 DRL,如图 1 所示。

为了保证实验数据的可靠性,本文设计了相应的脑电信号采集规则。实验要求采集环境必须避开电动设备、高频辐射等容易产生电磁干扰的地方,保证光线适中、简单安静、通风顺畅、温度适中,不会影响受试者情绪。实验选择了 6 位男性受试者和 2 位女性受试者进行脑电信号数据采集,要求受试者实验前 24 小时内未食用可能导致神经系统过度紧张兴奋或者抑制的药品和食品,并保证精神充沛,头部干燥无油;试验时尽量做到肌肉放松,避免大范围的肌肉运动。

本次实验根据智能轮椅的运动方式对每位受试者进行了 3 种不同程度的脑电信号采集,第 1 种只采集运动想象前进和运动想象停止两个动作;第 2 种采集运动想象前进、后退,以及运动想象停止 3 个动作;第 3 种采集运动想象前进、后退、左转、右转,以及运动想象停止 5 个动作。

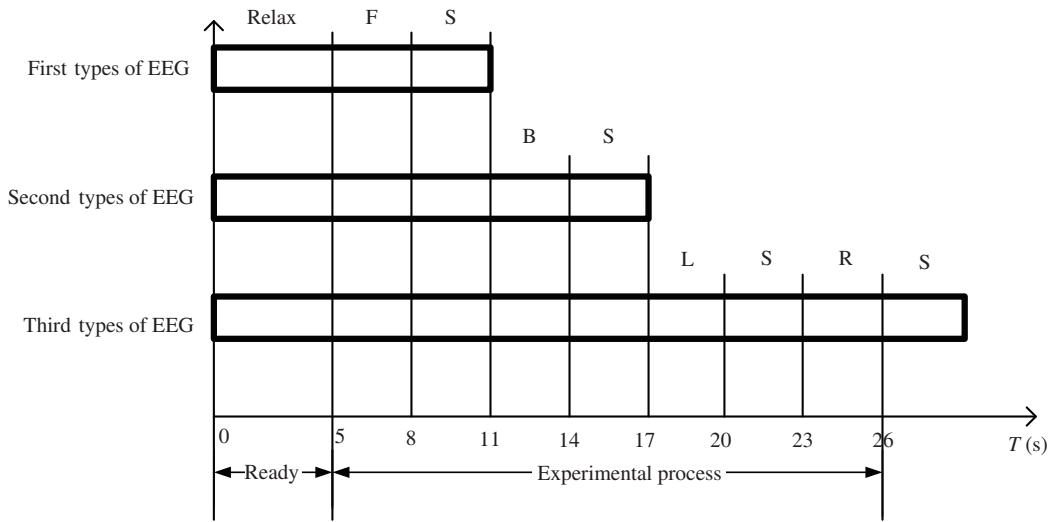


图 2 3 种采集实验单次采集过程  
 Figure 2 An experimental process about three types of EEG

具体单次采集过程 (如图 2 所示) 如下: 第 1 种采集在实验开始阶段 ( $t = 0$  s), 受试者保持放松状态, 大脑尽量处于放空状态;  $t = 5$  s 时, 受试者会听到运动想象前进的提示音, 开始进行物体向前的运动想象;  $t = 8$  s 时, 受试者会听到运动想象停止的提示音, 想象物体静止状态;  $t = 11$  s, 实验停止提示音想起之后, 受试者停止实验任务, 进行休息, 等待下次实验. 第 2 与 3 种采集过程类似于第 1 种采集, 只是第 2 种采集在  $t = 11$  s 时会响起运动想象后退的提示音, 受试者进行物体向后运动想象; 在  $t = 14$  s 时才会有实验停止的提示音, 停止实验任务. 第 3 种采集在第 2 种的基础上,  $t = 14$  s 时, 受试者会听到运动想象停止提示音, 想象物体静止状态;  $t = 17$  s 时会响起运动想象左转的提示音, 受试者进行物体向左运动想象;  $t = 20$  s 时会响起运动想象停止提示音, 想象物体停止状态;  $t = 23$  s 时会响起运动想象右转提示音, 受试者进行物体向右运动想象;  $t = 26$  s 时会有实验停止的提示音, 停止实验任务, 受试者进行休息.

通过以上的实验, 对受试者 3 种不同程度的脑电信号数据进行了采集, 本文对每一种数据进行了初步处理. 对于第 1 种数据, 选取了  $t = 6 \sim 7$  s 和  $t = 9 \sim 10$  s 之间的数据作为实验样本; 对于第 2 种数据, 选取了  $t = 6 \sim 7$  s,  $t = 9 \sim 10$  s,  $t = 12 \sim 13$  s 之间的数据作为实验样本; 对于第 3 种数据, 选取了  $t = 6 \sim 7$  s,  $t = 9 \sim 10$  s,  $t = 12 \sim 13$  s,  $t = 18 \sim 19$  s,  $t = 24 \sim 25$  s 之间的数据作为实验样本.

由于 Emotiv EPOC+ 脑电采集仪的采样频率为 128 Hz, 每个实验样本为  $14 \times 128$  维数据矩阵, 为了实验分类效果的准确性, 就第 3 种程度数据采集了 80 组, 每组数据 5 个数据样本, 每个样本为  $14 \times 128$  维数据矩阵. 如图 3 所示是某位受试者某组运动想象前进和静止状态的单一通道脑电信号波形图. 根据脑电信号的数据样本, 本文按一定比例分成了两个部分, 一部分作为训练样本, 另一部分作为测试样本.

#### 4 改进共空间模式提取脑电特征信号

共空间模式 (CSP) 算法<sup>[15,16]</sup> 是一种监督方法, 对于训练样本, 每组数据的类别是已知的, 共空间模式算法将会通过各类训练数据的协方差矩阵同时对角化, 构建出空间滤波器, 通过空间滤波器的




图 3 (网络版彩图) 通道 FC5 采集的 (a) 运动和 (b) 静止脑电信号波形图  
Figure 3 (Color online) Motion (a) and standstill (b) EEG waveform of FC5 channel

测试数据能实现在能量上的协方差最大化, 即与其中一类方差达到最大, 而与另一类方差达到最小, 从而, 得到的特征向量增强了两类数据之间的差别.

共空间模式适用于二分类的问题, 本文设计的第 1 种程度脑电信号数据只有两种状态, 即运动想象前进和运动想象静止, 采用共空间模式能够很好地得到特征向量. 对于第 2 和 3 类脑电信号数据, 其分类种类多于两类, 因此, 本文提出了一对多的改进共空间模式 (I-CSP) 算法. 通过第 1 次算法得到想象运动状态和想象静止状态的特征向量, 之后再多次利用共空间模式算法提取想象运动状态的各类特征向量. 多种分类问题, 需要构建多个共空间模式滤波器.

通过对脑电数据的初步处理, 其脑电数据可以表示为矩阵  $A_i$ , 且  $A_i \in R^{N \times T}$ , 其中,  $N, T$  分别表示电极的数目和采样点的数目. 对脑电信号矩阵进行标准化运算处理得到其协方差矩阵, 如下所示:

$$C_i = \frac{(A_i A_i^T)}{\text{trace}(A_i A_i^T)}, \quad (1)$$

其中,  $\text{trace}(\cdot)$  表示矩阵  $A_i$  对角线元素之和. 对于第 3 种程度的脑电信号, 其数据分为 5 组, 即向前、向后、左转、右转和静止, 可以用  $G_1, G_2, G_3, G_4$  和  $S$  来分别表示, 为了获取更好的空间滤波效果, 先将 5 组数据分为两大组, 分别表示运动和静止, 得到平均标准化的空间协方差矩阵  $\overline{C_G}$  和  $\overline{C_S}$ :

$$\overline{C_G} = \frac{1}{K_{G_j}} \sum_{i=G_j} C_i \quad (j = 1, 2, 3, 4), \quad (2)$$

$$\overline{C_S} = \frac{1}{K_S} \sum_{i=S} C_i, \quad (3)$$

其中,  $K_{G_j}$  和  $K_S$  分别表示两大组脑电数据的样本数. 对两大组数据的平均标准化空间协方差求和, 得到了两组数据的混合空间协方差矩阵  $C_C$ :

$$C_C = \overline{C_G} + \overline{C_S}, \quad (4)$$

再对  $C_C$  做矩阵的对角化分解:

$$C_C = U_C \lambda_C U_C, \quad (5)$$




图 4 (网络版彩图) CSP 特征提取 (a) 运动和 (b) 静止的脑电信号波形图

Figure 4 (Color online) Motion (a) and standstill (b) EEG waveform feature extraction by CSP

那么  $\lambda_C$  就是  $C_C$  的特征值构成的对角矩阵, 其对应的特征矩阵为  $U_C$ , 对特征值对角矩阵进行降序处理, 再按下式进行白化转换:

$$P = \sqrt{\lambda_C^{-1}} U_C^T. \quad (6)$$

经过白化转换后, 使得  $PC_C P^T$  对应的特征值为 1, 对各组的平均标准化空间协方差做如下变化:

$$S_G = P \overline{C_G} P^T, \quad (7)$$

$$S_S = P \overline{C_S} P^T, \quad (8)$$

此时的  $S_G$  和  $S_S$  具有相同的特征向量, 若  $S_G = B \lambda_G B^T$ , 则  $S_S = B \lambda_S B^T$ ,  $\lambda_G + \lambda_S = I$ ,  $I$  为单位矩阵. 因此, 如果  $S_G$  有最大的特征值, 则对应  $S_S$  有最小的特征值, 则两组脑电信号具备了区分的特征. 利用特征向量矩阵  $B$ , 求得投影矩阵:

$$W = (B^T P)^T, \quad (9)$$

根据投影矩阵  $W$ , 对每组实验数据矩阵  $A_i$  进行分解, 提取脑电信号的特征:

$$Z = W A_i, \quad (10)$$

最后将分解的想象运动的脑电信号特征  $Z$  再次通过共空间模式滤波器, 得到各种模式下的特征数据, 这些特征数据作为深度信念网络的输入数据, 等待深度信念网络训练. 图 4 为经过共空间模式后单一通道的运动想象前进和静止的脑电特征波形图.

## 5 深度信念网络模型

深度信念网络 (DBN) [17, 18] 是由多层受限 Boltzman 机 (restricted Boltzman machine, RBM) 堆叠而成的, 是一种概率生成模型. 深度信念网络的训练就是对各层受限 Boltzman 机的训练, 可以通过无监督贪婪逐层训练的方法进行训练. 对于单层受限 Boltzman 机的训练方法, 一般是使用对比散度 (contrastive divergence, CD) 算法.




图 5 (网络版彩图) 受限 Boltzmann 机

Figure 5 (Color online) Restricted Boltzmann machine

### 5.1 受限 Boltzmann 机

受限 Boltzmann 机是一类随机神经网络模型<sup>[19]</sup>, 具有两层神经元结构, 分别叫做可视层和隐藏层. 可视层主要用于输入训练数据, 隐藏层主要作为特征检测器. 每层内部没有连接, 但是两层之间全部连接, 结构图如图 5 所示.

对于一个受限 Boltzmann 机, 若可视层单元为  $V$ , 节点数为  $m$ ; 对应的隐藏层单元为  $H$ , 节点数为  $n$ ; 那么, 可视层和隐藏层组成的系统具备能量, 其能量可表示为

$$E(v, h) = - \sum_{i=1}^m \sum_{j=1}^n V_i \omega_{ij} H_j - \sum_{i=1}^m a_i V_i - \sum_{j=1}^n b_j H_j, \quad (11)$$

其中, 可视层单元和隐藏层单元都是二进制状态,  $\omega_{ij}$  为可视单位  $i$  与隐藏单位  $j$  之间的连接权值,  $a_i$  和  $b_j$  则表示可视单位  $i$  与隐藏单位  $j$  对应的偏置. 通过上述能量公式, 可视层和隐藏层之间是相互独立的, 所以在给定可视层单元或者隐藏层单元的值时, 另外一层的取值和给定层没有关系, 其条件概率为

$$P(H|V) = \prod_{j=1}^n P(H_j|V), \quad (12)$$

$$P(V|H) = \prod_{i=1}^m P(V_i|H), \quad (13)$$

对于这个受限 Boltzmann 机, 其可视层单元和隐藏层单元取值的联合概率分布为

$$P(V, H) = \frac{1}{Z} \exp(-E(V, H)), \quad (14)$$

其中,  $Z$  是联合概率分布的归一化常数, 表示所有可视层单元和隐藏层单元对之和为

$$Z = \sum_V \sum_H \exp(-E(V, H)), \quad (15)$$

该受限 Boltzmann 机分配给可视层单元的概率为

$$P(V) = \frac{1}{Z} \sum_H \exp(-E(V, H)). \quad (16)$$

由于可视层和隐藏层之间没有联系, 所以, 在给定可视层的情况下, 隐藏层单元的值被设置为 1 的概率为

$$P(H_j = 1|V) = \sigma \left( b_j + \sum_{i=1}^m V_i \omega_{ij} \right). \quad (17)$$

若给定隐藏层单元, 则可视层单元的值被设置为 1 的概率为

$$P(V_i = 1|H) = \sigma \left( a_i + \sum_{j=1}^n \omega_{ij} H_j \right), \quad (18)$$

其中,  $\sigma(x)$  为 S 型激活函数,  $\sigma(x) = \frac{1}{(1+\exp(-x))}$ .

## 5.2 对比散度 (CD) 训练方法

对受限 Boltzman 机的训练就是对其可视层和隐藏层连接权值的更新. Gibbs 采样在训练受限 Boltzman 机时, 能都得到未知参数梯度的近似, 但是对于高维数据来说, 其采样步数一般要求较大, 使得训练效率太低, 所以, 一般采用对比散度算法训练受限 Boltzman 机.

对比散度算法与 Gibbs 采样不同, 能很好地提高训练速度. 当训练数据输入后, 其作为初始数据通过 Gibbs 采样, 只需要经过少数几次 (一般只需要一次) 就能达到很好的近似效果, 来进行权值估算. 根据式 (19), 可视层单元对权值的对数梯度为

$$\frac{\partial \log p(V)}{\partial \omega_{ij}} = \langle V_i H_j \rangle_{\text{data}} - \langle V_i H_j \rangle_{\text{model}}, \quad (19)$$

其中,  $\langle V_i H_j \rangle_{\text{data}}$ ,  $\langle V_i H_j \rangle_{\text{model}}$  表示数据、模型对可视层与隐藏层分布的期望. 通过这个梯度, 可以得到模型期望权值和实际权值的偏差:

$$\Delta \omega_{ij} = \varepsilon \frac{\partial \log p(V)}{\partial \omega_{ij}} = \varepsilon (\langle V_i H_j \rangle_{\text{data}} - \langle V_i H_j \rangle_{\text{model}}), \quad (20)$$

其中,  $\varepsilon$  表示的是模型的学习率. 根据这个权值的偏差, 模型进行权值的更新, 偏置量  $a_i$  和  $b_j$  也同时更新:

$$\Delta \omega_{ij} = \varepsilon (V \cdot P(H|V)_{\text{data}} - V \cdot P(H|V)_{\text{model}}), \quad (21)$$

$$\Delta a_i = \varepsilon (P(V|H)_{\text{data}} - P(V|H)_{\text{model}}), \quad (22)$$

$$\Delta b_j = \varepsilon (P(H|V)_{\text{data}} - P(H|V)_{\text{model}}). \quad (23)$$

## 5.3 改进共空间模式与深度信念网络

根据深度信念网络的网络结构, 以及改进共空间模式产生的特征数据, 本文设计了改进共空间模式与深度信念网络对脑电信号进行识别与分类. 图 6 为改进共空间模式与深度信念网络结构图.

在脑电信号采集仪采集到脑电信号之后, 根据采集规则, 对脑电数据进行了数据预处理, 得到了各组的待识别的脑电数据. 根据改进共空间模式算法提取了各种脑电数据特征信号. 脑电数据特征信号作为深度信念网络的输入原始信号<sup>[20, 21]</sup>, 对深度信念网络进行了预训练和微调. 预训练主要是对每一层的受限 Boltzman 机进行无监督训练, 对于最底层的受限 Boltzman 机, 脑电特征信号作为输入, 通过对比散度算法来训练第 1 层受限 Boltzman 机的权值和偏置量, 然后将第 1 层的输出作为第 2 层受限 Boltzman 机的输入量, 继续通过上述方法训练参数, 直到最后一个参数训练完成. 在每一层的受限 Boltzman 机获得了相应的权值之后, 产生相应的输出特征向量, 最上一层的 BP 层接收这一输出特征向量, 有监督地训练分类器, BP 层的输出结果与实际结果相比对, 得到的误差结果就反向传播到输入端. 由于每一层的受限 Boltzman 机只能确保自身层内的权值对该层的特征向量映射达到最优, 所以反向传播会将误差信息下传到每一层的受限 Boltzman 机中, 对整个网络进行微调, 使得深度信念网络得到充分地训练.






图 6 (网络版彩图) 改进共空间模式与深度信念网络

Figure 6 (Color online) Improved-common spatial patterns and deep belief network

## 6 实验与分析

本文实验采集了 3 种不同程度的脑电信号数据, 第 1 种采集了 120 组, 第 2, 3 种各采集了 80 组. 在第 1 种数据中, 实验随机选取了 60 组作为训练数据, 剩下的 60 组作为测试样本. 对于第 2, 3 种数据, 随机选取了 60 组作为训练数据, 剩下的 20 组作为测试样本.

为了验证共空间模式特征数据的特征提取效果, 实验选择了经过去噪处理的脑电数据和特征数据进行比对; 为了验证深度信念网络的分类效果, 选择了支持向量机 (SVM) 的分类方法进行比对. 因此, 实验设计了 4 种方案进行识别, 分别是去噪数据和深度信念网络组合 (DBN)、去噪数据和支持向量机组合 (SVM)、特征数据和支持向量机组合 (CSP+SVM), 以及特征数据和深度信念网络组合 (CSP+DBN).

深度信念网络在进行脑电信号分类时, 需要进行参数的合理设置, 参数的合理设置能有效地建立高效的深度信念网络, 主要设置包括: 各层受限 Boltzmann 机的节点数、学习率、权值衰减.

深度信念网络每一层的节点数选择比较关键, 节点数过多固然可以提高网络的逼近能力, 使之能

表 1 不同受试者在不同分类方法下对于第 1 种脑电信号的正确识别率

Table 1 The correct recognition rate about first type EEG under different subjects in different classification methods

	DBN (%)	SVM (%)	(CSP+SVM) (%)	(CSP+DBN) (%)
Experimenter 1	88.33	78.33	85.83	93.33
Experimenter 2	85.83	76.67	82.50	91.67
Experimenter 3	86.67	82.50	83.33	94.17
Experimenter 4	82.50	78.33	80.83	90.83
Experimenter 5	91.67	84.17	87.50	96.67
Experimenter 6	83.33	79.17	81.67	92.50
Experimenter 7	81.67	75.83	80.83	89.17
Experimenter 8	83.33	75.00	79.17	90.00

更加清晰地表达原始信息, 但是网络的泛化能力却下降; 节点数过少则可能会大量丢失重要信息. 目前, 对于深度学习各层以及各层节点数设置并没有一套调节参数的理论方案, 选取参数时更多凭借经验和反复实验比对, 本文通过反复实验确定 3 层隐藏层保证网络既具备泛化能力, 又不至于丢失信息, 各层的节点数安排为 500, 250, 30, 能使网络识别率最好, 因此, 本文选择了上述设置完成对脑电特征信号的识别.

深度信念网络的学习率和权值的变化紧密联系, 学习率太大会导致权值过大, 网络会因为权值改变过大而出现不稳定的情况. 因此, 在设计中权值的更新速度尽量慢一些, 保证网络缓慢收敛, 本次实验设计的学习率为 0.1.

深度信念网络中权值改变后通常需要对较大的参数添加惩罚因子, 避免陷入过拟合状态, 这就是权值衰减的原因. 最后权值的改变为

$$\Delta\omega_{ij} = \varepsilon \left( \frac{\partial \log p(V)}{\partial \omega_{ij}} + \frac{\lambda}{2} \omega \omega^T \right), \quad (24)$$

其中,  $\omega \omega^T \cdot \frac{\lambda}{2}$  是最简单的惩罚因子,  $\lambda$  为正则化系数, 本实验中设置为 0.001.

支持向量机 (SVM) 是目前对脑电信号分类中使用最广泛的方法之一, 分类效果也十分可观, 因此, 本文选择该分类方法作为比较. 本文选择的支持向量机的核函数为 RBF (radial basis function) 核函数.

对于第 1 种运动想象脑电信号, 只需要分类运动想象前进和静止, 8 位受试者在不同方案下的正确识别率如表 1 所示.

对于第 2, 3 种运动想象脑电信号, 脑电信号种类较多, 特征提取采用了改进共空间模式的空间滤波器, 8 位受试者在不同方案下的正确率如表 2 和 3 所示.

通过表 1 可以看出, 不同的受试者在同一程度脑电信号的识别分类中, 其脑电信号的识别正确率略有不同. 根据每个人采集脑电信号时的状态不同, 以及个人之间的差异, 存在一些误差属于合理情况. 通过对同一种脑电信号识别正确率的情况可以看出, 使用共空间模式和深度信念网络组合产生的分类效果较好. 以受试者 1 为例, 在第 1 类脑电信号的识别中, 相比传统的去噪的脑电信号和支持向量机组合识别率高出了 15%, 比共空间模式提取的特征信号与支持向量机组合的识别率也高出了 7.5%.

对比表 1~3 表明, 当脑电信号识别的种类变多时, 其对于任何的分类方法, 识别率都有明显下降. 识别的种类越多, 其准确率越低, 有不少数据被误识别为其他类型数据, 说明数据本身之间差异较小. 另外, 本文使用的脑电信号采集仪为消费级采集仪, 其采集的数据效果不及实验级采集仪采集的效果,

表2 不同受试者在不同分类方法下对于第2类脑电信号的正确识别率

Table 2 The correct recognition rate about second type EEG under different subjects in different classification methods

	DBN (%)	SVM (%)	(CSP+SVM) (%)	(CSP+DBN) (%)
Experimenter 1	65.00	48.33	63.33	76.67
Experimenter 2	61.67	43.33	58.33	73.33
Experimenter 3	68.33	51.67	61.67	78.33
Experimenter 4	68.33	48.33	58.33	75.00
Experimenter 5	71.67	53.33	66.67	81.67
Experimenter 6	63.33	45.00	55.00	71.67
Experimenter 7	66.67	48.33	56.67	73.33
Experimenter 8	63.33	51.67	60.00	76.67

表3 不同受试者在不同分类方法下对于第3类脑电信号的正确识别率

Table 3 The correct recognition rate about third type EEG under different subjects in different classification methods

	DBN (%)	SVM (%)	(CSP+SVM) (%)	(CSP+DBN) (%)
Experimenter 1	40	25	35	47
Experimenter 2	45	22	36	49
Experimenter 3	47	28	40	51
Experimenter 4	46	30	41	53
Experimenter 5	49	27	41	52
Experimenter 6	40	29	30	43
Experimenter 7	43	31	36	48
Experimenter 8	45	33	39	52

这也是造成多类脑电信号识别率普遍偏低的原因之一。通过数据对比,本文提出的改进型共空间模式与深度信念网络的分类方式效果还是比较可观。

随着脑电数据种类的增多,所有特征提取以及分类算法的计算时间都大大增加,本文提出的改进型共空间模式与深度信念网络的分类方式的计算时间也大大增加,其中,主要时间花费在共空间模式提取脑电特征信号上,因此,可以通过设计并行计算来缩短共空间模式的计算时间。

## 7 结束语

本文通过研究脑电信号对智能轮椅的控制,提出了改进共空间模式结合深度信念网络对脑电信号进行特征提取与分类。改进共空间模式提取脑电特征信号,深度信念网络对多类脑电信号进行分类。该方法对比一般的脑电信号分类方法具备优秀的识别分类效果,尤其在多类脑电信号的分类中,有效地改进了脑电信号对智能轮椅控制效果。

在实验过程中,仍有一些问题需要进一步地探索。改进共空间模式和深度信念网络在计算高维数据时计算时间过长,特别在改进共空间模式提取脑电特征信号上,不利于智能轮椅的实时运动,准备尝试通过并行计算的方式提高计算速度;另外,还需要进一步探索深度信念网络的参数,使系统网络在保证系统最优的情况下训练速度和识别准确度均得到提升;最后,原始数据采集过程也需要进一步优化,尽量避免外界干扰影响脑电数据。

## 参考文献

- 1 Zhang R. A study on brain computer interface (BCI) — based functional assistance for the seriously disabled. Dissertation for Ph.D. Degree. Guangzhou: South China University of Technology, 2016 [张瑞. 面向重度残疾人的脑机接口功能辅助研究. 博士学位论文. 广州: 华南理工大学, 2016]
- 2 Hoffmann U, Vesin J M, Ebrahimi T, et al. An efficient P300-based brain-computer interface for disabled subjects. *J Neurosci Method*, 2008, 167: 115–125
- 3 Li X. Study and implementation of online motor imagery based brain-computer interface system. Dissertation for Master Degree. Beijing: Tsinghua University, 2012 [李翔. 基于运动想象的在线脑 – 机接口系统的研究与实现. 硕士学位论文. 北京: 清华大学, 2012]
- 4 Wang S F, Lee Y H, Shiah Y J, et al. Time-frequency analysis of EEGs recorded during meditation. In: Proceedings of the 1st International Conference on Robot, Vision and Signal Processing (RVSP), Kaohsiung, 2011. 73–76
- 5 Wang K, Ye C, Shen Y Q, et al. Automatic removal algorithm of ocular artifact in electroencephalogram signal. *Comput Eng*, 2011, 37: 257–260 [王魁, 叶闯, 沈益青, 等. 脑电信号中眼电伪迹的自动去除算法. *计算机工程*, 2011, 37: 257–260]
- 6 Rajesh P N Rao. Brain-computer Interfacing an Introduction. Beijing: China Machine Press, 2016 [Rajesh P N Rao. 脑机接口导论. 北京: 机械工业出版社, 2016]
- 7 Gao S K. Comments on recent progress and challenges in the study of brain-computer interface. *Chinese J Biomedical Eng*, 2007, 26: 801–803 [高上凯. 浅谈脑 – 机接口的发展现状与挑战. *中国生物医学工程学报*, 2007, 26: 801–803]
- 8 Dornhege G. Toward Brain-Computer Interfacing. Cambridge: MIT Press, 2007
- 9 Tang X L, Zhou J L, Zhang N, et al. Recognition of motor imagery EEG based on deep belief network. *Inf Control*, 2015, 44: 717–721 [唐贤伦, 周家林, 张娜, 等. 基于深度信念网络的运动想象脑电信号识别. *信息与控制*, 2015, 44: 717–721]
- 10 Ma M Z, Guo L B, Su K F. Classification method of motor imagery EEG signals based on wavelet and common spatial pattern. *China Sci Technol Inf*, 2017, 08: 83–85 [马满振, 郭理彬, 苏奎峰. 基于小波包和共空间模式的运动想象脑电信号分类方法. *中国科技信息*, 2017, 08: 83–85]
- 11 Li L T. Classification method of four-class motor imagery EEG data based on common spatial pattern. *Instrumentation*, 2016, 05: 12–14 [李立亭. 基于共空间模式的四类运动想象脑电信号分类方法. *仪器仪表用户*, 2016, 05: 12–14]
- 12 Jia X W, Li K, Li X Y, et al. A novel semi-supervised deep learning framework for affective state recognition on EEG signals. In: Proceedings of the 14th International Conference on Bioinformatics and Bioengineering, Boca Raton, 2014
- 13 Li X Y, Jia X W, Xun G X, et al. Improving EEG feature learning via synchronized facial video. In: Proceedings of International Conference on Big Data, Santa Clara, 2015. 843–848
- 14 Wang J W. Preprocessing methods and applications based on EEG. Dissertation for Master Degree. Beijing: Beijing University of Posts and Telecommunications, 2015 [王佳威. 脑电波信号的处理方法与应用. 硕士学位论文. 北京: 北京邮电大学, 2015]
- 15 Liang J K. EEG Analysis and BCI Research based on Motor Imagery under Driving Behavior. Beijing: National Defense Industry Press, 2015 [梁静坤. 基于想象驾驶行为的脑机接口控制. 北京: 国防工业出版社, 2015]
- 16 Zhang S H. Analysis of motor imagery EEG. Dissertation for Master Degree. Shanghai: Shanghai Jiao Tong University, 2015 [张异欢. 运动想象脑电信号的分析研究. 硕士学位论文. 上海: 上海交通大学, 2015]
- 17 Wang T. SMS classification methods based on deep learning. Dissertation for Master Degree. Xi'an: Chang'an University, 2016 [王婷. 基于深度学习的短信分类技术研究. 硕士学位论文. 西安: 长安大学, 2016]
- 18 Yang D P. Product image classification based on deep learning. Dissertation for Master Degree. Dalian: Dalian Jiaotong University, 2015 [杨东坡. 基于深度学习的商品图像分类. 硕士学位论文. 大连: 大连交通大学, 2015]
- 19 Dai R M. The motor imagery EEG classification based on deep learning. Dissertation for Master Degree. Beijing: Beijing Institute of Technology, 2015 [戴若梦. 基于深度学习的运动想象脑电分类. 硕士学位论文. 北京: 北京理工大学, 2015]
- 20 Gao Y B, Lee H J, Mehmood R M, et al. Deep learning of EEG signals for emotion recognition. In: Proceedings of IEEE International Conference on Multimedia & Expo Workshops (ICMEW), Turin, 2016
- 21 Liu J W, Cheng Y, Zhang W D, et al. Deep learning EEG response representation for brain computer interface. In: Proceedings of the 34th Chinese Control Conference (CCC), Hangzhou, 2015. 3518–3523

# Research on EEG recognition based on improved-common spatial patterns and deep-belief network algorithm

Wei XIANG & Yingnian WU\*

*School of Automation, Beijing Information Science and Technology University, Beijing 100192, China*

\* Corresponding author. E-mail: wuyingnian@126.com

**Abstract** Using electroencephalogram (EEG) signals to control intelligent wheelchairs is one of the new control methods for controlling intelligent wheelchairs. The most serious problem in the control process is recognition and classification of EEG signals, especially a variety of EEG signals. To improve the accuracy of EEG classification, improved-common spatial patterns and a deep-belief network algorithm are proposed and used for recognition and classification of EEG signals. A variety of different EEG signals were collected by an Emotiv EPOC+ EEG collector, and the characteristic signals were extracted by improved-common spatial patterns and identified and classified by a deep-belief network algorithm. Simulation results show that the classification accuracy of improved-common spatial patterns and the deep-belief network algorithm is higher than that of the traditional classification method, and a research perspective is provided for the classification of various EEG signals in the future.

**Keywords** brain-computer interface, EEG signals, improved-common spatial patterns, deep-belief network



**Wei XIANG** was born in 1990. He is pursuing an M.S. degree from the Beijing Information Science and Technology University, Beijing. His research interests include natural human-computer interaction, Internet of things, and robot control.



**Yingnian WU** was born in 1976. He received a Ph.D degree in control science and engineering from Beihang University, Beijing, in 2015. Currently, he is a senior professor at the Beijing Information Science and Technology University. His research interests include natural human-computer interaction and control, high-performance simulation, Internet of things, and robot control.