

脑机接口中脑电信号的特征提取和模式分类^①

潘家辉¹, 冯宝²

¹(华南师范大学 软件学院, 南海 528225)

²(桂林航天工业学院 自动化系, 桂林 541004)

摘要: 从智能处理与不确定性的角度, 探讨了脑机接口中的核心问题-EEG 模式特征的识别和分类. 针对 EEG 模式分类中所存在的不确定性问题, 从 EEG 的特征提取和分类模型构建两个方面进行了分析, 并提出了解决问题的方法和对策. 以 P300 成分为例, 从导联选择、滤波处理和时间窗处理三方面进行特征提取, 采用贝叶斯线性判别分析的方法进行模式分类. 最后以第三届脑机接口竞赛 P300 字符输入的数据为实验, 分别采用 3 种不同的方法进行数据分析, 通过分类准确率和不同重复次数下性能的比较, 实验结果表明了本文特征提取和模式分类方法的有效性.

关键词: 脑机接口; P300; 特征提取; 模式分类; 贝叶斯线性判别法

Feature Extraction and Pattern Classification for EEG in Brain-Computer Interface

PAN Jia-Hui¹, FENG Bao²

¹(School of Software, South China Normal University, Nanhai 528225, China)

²(Department of Automation, Guilin University of Aerospace Technology, Guilin 541004, China)

Abstract: The identification and classification of EEG pattern features in brain-computer interface (BCI) were proposed from the angle of the intelligent processing and the uncertainty. For the uncertainty problem of the existence of EEG, two aspects of EEG processing, feature extraction and classification, were analyzed. Furthermore, we put forward the methods to solve the problem. With P300 component as an example, the channel selection, filtering and time window selection were used for feature extraction. Then the Bayes linear discriminant analysis method was used for pattern classification. Finally, the P300 data sets of the BCI competition III were used for data analysis. By comparing the classification accuracy rate of three different methods, the results demonstrated the effectiveness of our method.

Key words: brain-computer interface; P300; feature extraction; pattern classification; bayes linear discriminant method

1 引言

脑机接口(brain-computer interface, BCI)是一种不依赖于大脑外周神经与肌肉正常输出通道的控制系统, 通过采集和分析人脑生物电信号, 在人脑与计算机或其他电子设备间建立起直接交流和控制的通道. 这样人就可以通过大脑来表达意愿或操纵设备, 而不需要语言或肢体的动作, 这可以有效增强身体严重残疾的患者与外界交流或控制外部环境的能力, 以提高患者的生活质量. 脑机接口的发展有赖于神经科学、工程学、心理学、计算机和康复学等各交叉学科专家

间的密切合作, 具有非常重要的科学意义、学术价值和广阔的应用前景, 是当今世界研究的热点^[1].

要想实现脑机接口, 有两个个必要条件: 第一, 必须有一种能够可靠反应大脑思维的信号; 第二, 这种信号能够被实时快速地收集. 目前可用于脑机接口的人脑信号有: EEG(脑电图)、EMG(脑磁图)和fMRI(功能性核磁共振图像)等. 目前大多数 BCI 研究机构采用的大脑信号是 EEG^[2]. 本文的研究不是探讨如何设计和实现 BCI 系统, 我们关注 BCI 中 EEG 信号的模式分类问题.

^① 基金项目:国家自然科学基金重大研究计划(91120305);国家高技术研究发展计划(863)(2012AA022305)

收稿时间:2014-12-26;收到修改稿时间:2015-02-02

2 脑机接口中的不确定性

“不确定性”在主、客观世界中都是普遍存在,例如人类关于世界的认识是不确定的,人类的认知过程也是不确定的.因此脑机接口中也存在着“不确定性”的问题.在文献[3]中说到不确定性,主要包含随机性、模糊性、不完备性、不稳定性和不一致性,其中随机性和模糊性是最重要的两种基本形式.在脑机接口中,不确定性问题主要包含下列两个方面:

1) EEG 模式具有不确定性

人脑系统在结构、功能、行为等方面以及它的输入-输出反应特性都极为复杂^[4].作为对大脑状态的外部反映,脑电活动也表现出得相当复杂.因此,所测得的 EEG 信号是非平稳的、带有强噪声的、具有不确定性的时间序列数据.

虽然脑电信号能够反应大脑的功能状态,包含一些有价值的信息,但不包含所有的信息,我们不能完全清楚地解释大脑皮层中神经元之间的相互作用,以及如何产生脑电.我们关于 EEG 的知识是有限的、不完备的.同时,人体中的神经元细胞所构成的网络系统是如此的巨大,它们之间的相互作用很难进行量化.而且,人脑是一个复杂巨系统,大脑的行为从宏观意义上可以说是带有强烈的随机性.

因此,我们关于大脑以及大脑功能活动的表征—EEG 的认识是模糊的、不完备的,只能定性地解释 EEG 的产生、以及行为特征,而不能做到对大脑以及脑电的完全量化认识.

2) 分类问题本身具有不确定性

所谓分类,就是根据确定的概念外延导出概念的内涵,即用模型或函数能够预测那些类标记尚未未知的对象,以区分新的概念外延^[5].这里导出的分类模型是基于对带有类标记的已知训练集的分析,因此,分类是一种有类标记指导的机器学习方法,是一个概念归纳的过程.

而对于 EEG 的分类,由于我们不能用精确定义的概念和严格证明的定理描述实现对不同类别的 EEG 进行完全区分,因此我们对于 EEG 特征不同这一概念的认识是模糊的.

而且作为一种有类标记指导的学习方法,分类问题具有不确定性,主要表现在:将新的待分类的对象划分给相应的类时,可能会出现与两个异类的类中心的距离都比较接近的情况;此外,根据少量类标记已

知的训练集导出分类模型,可能会过于适应训练集的数据分布,而不能有效地描述整体数据集的分类结构,因此,在划分更多的、类标记未知的新对象时,会出现很多的不确定性问题.

下面将从数据处理和数据分类两方面来研究如何有效解决 EEG 信号模式分类的不确定性问题.

3 EEG 的特征提取

一般来说,EEG 的特征提取是脑机接口中的预处理环节.其主要任务是根据脑机接口系统的要求,去除与特征脑电无关的其他特征信号,提高数据的信噪比,通过选取合适的特征提取方法提取所需要的各种特征参数,并以此组成表示 EEG 特征的特征向量. EEG 模式的特征提取是构建分类模型的前提.

由于 EEG 数据是非平稳的、带有很强背景噪声的、具有不确定性的时间序列数据,因此在特征的提取过程中,我们希望能够发现那些容易提取、对噪声不敏感,以及对区分不同类别的 EEG 模式很有效的特征集.因此,这需要将 EEG 相关的背景知识和对 EEG 样本数据的分析结合起来,以此发现有用的和有效的特征.

目前,在基于 EEG 的脑机接口研究中,常用的特征参数大部分是时域特征,如 P300 成分慢皮层电位等.常用的特征提取方法有:傅立叶变换、小波变换、自回归建模、空间和时间滤波器、头皮电极类型和定位等用来检测和测量特征的信号处理方法^[5].

我们以 P300 成分为例,P300 是 Sutton 等于 1965 年所发现的,是一种事件相关电位,即凡是外加一种特定的刺激作用于机体,在给予刺激或撤消刺激时,在神经系统任何部位引起的电位变化^[6].其中,P300 即为晚成分的第三个正波 P3.其中,P 是英文“正波”(positivity)的简写,300 则是潜伏期约为 300 毫秒.P300 字符输入系统是一种基于 P300 成分的典型脑机接口应用,已成功应用在虚拟键盘上,并帮助残疾人实现与电脑的交流.与其它大部分脑电信号一样,P300 是一种具有多通道的皮层信号.因此,在进行 P300 电位检测之前,特征选择是非常重要的.

在早期的研究中,研究者重点关注的是 P300 正波本身,所提取的用于分类的参数也是与这个正波相关的特征量.通常是在一个较窄的时间窗(例如刺激后 200~400 ms 范围)内提取 P300 波形的幅度、面积等特

度量。目前,部分研究已表明采用长时间窗内的数据进行分类比单纯使用 P300 正波数据的效果更好^[7]。这类文献分析 P300 时所用的时间窗通常是手动选择的以包括 0-600 毫秒的时间段。但是, P300 的有效成分通常是与特定的使用者及刺激事件相关。在 0~600 ms 这样的长时间窗内除了 P300 波形外,还包含了其他有用的脑电成分。这些脑电成分对应的导联对不同的使用者也情况各异。此外,使用大的时间窗以包括具有窄小宽度的 P300 成分可能会降低 P300 与背景信号的可区分性。对于上述的不确定性问题,我们采用下面方法进行智能处理。

3.1 导联选择

增加了信息来源是一种有效的方法,然而导联选择范围过大,会出现高维特征向量出现过学习现象的风险。因此,除了在传统认为 P300 信号较强的大脑顶区布置电极外,我们还可以进行人工选择或者半自动选择的方法,通过观察采集的训练数据,画出目标与非目标的波形图,如图 1 所示,除了顶区外,枕区也有区分明显的情况,因此可以适当扩充区分明显的导联,使该选择更合理。

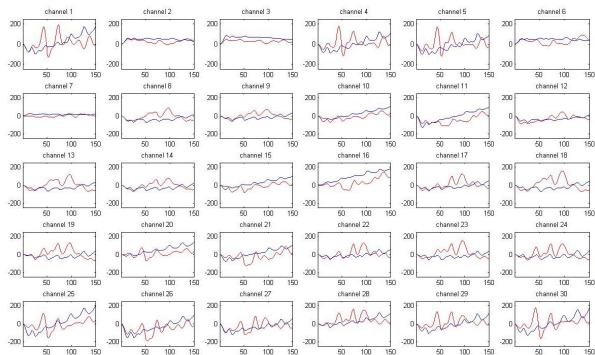


图 1 32 导联的波形图(红色为目标,蓝色为非目标)

3.2 滤波处理

在滤波环节,研究滤波器阶次和频带两个参数对结果的一个影响。使用 FIR 滤波器进行滤波,使用窗函数法设计滤波器,选择 Kaiser 窗。考虑到特征提取的过程中需要进行一次降采样,为了满足采样定律,所采集信号的频率范围不能超过采样率的一半,这是选择带通滤波器高端截止频率的原则。在不研究滤波对结果影响时,固定选择频带为 0.1-12Hz,阶次为 12 的 FIR 滤波器,然后数据通过降采样至 32Hz。

3.3 时间窗选择

每个个体的 P300 正波时间都一样,但基本的时间范围不会相差太远。我们可以在使用长时间窗方法中选取 0~600ms 作为数据段。理论上讲,这个时间窗内除了包含 P300 成分外,也应该包含刺激发生后较早的诱发响应成分。我们的实验结果表明特征窗越长,分类正确率也会越高。这分类器会自动挑选合适的特征,要做的只需要使窗口内包含全部重要的特征,然后让分类器自动搜索这些特征即可。

此外,我们可以对时间窗做这样的划分,其中开始部分的 0~100ms 作为基线校准使用,后面的 100~600ms 以 32 Hz 进行采样共包含 20 个数据点,这 20 个数据点就构成了一个 20 维的特征向量。上述的处理都是在相关背景知识下所做的优化操作,这样做无疑增加了信息来源,最终提高了 BCI 系统的识别正确率。

4 EEG分类模型的构建

在脑机接口中,构建分类模型的目的是获取与不同认知活动相关联的模式类别。模型分类能力的好坏取决于所提取的特征对不同类别的 EEG 模式的区分能力和所选择的分类方法。

常见的具有代表性的分类方法有支持向量机、人工神经网络、贝叶斯网络、遗传算法等。如果所提取的特征能够线性地划分特征空间,区分不同的 EEG 模式特征,那么分类模型的构建就非常简单,采用简单的线性分类方法就可很容易地将不同特征的 EEG 区分开来。

概率论是表示不确定性的唯一合理的方法,概率论对于机器学习或不确定情况下的推理是有用的。贝叶斯概率理论是数学概率论的一个分支,它通过将先验知识和观测事件结合起来而允许我们对于现实世界的不确定性建模并进行感兴趣的推理^[8]。因此,我们可以把各种机器学习问题统一在贝叶斯机器学习方法框架下,把机器学习和模式识别问题看作是一个贝叶斯推理问题。在本文,我们使用贝叶斯线性判别分析的方法来进行脑电信号 P300 成分的模式分类。

贝叶斯线性判别分析(BLDA)利用正则化来防止与高维且可能为噪声的数据的过拟合^[9]。通过 Bayes 分析,可以自动而快速从训练数据估计出正则化的阶数,并且不需要耗费时间去交叉验证。

当将类 1 的回归目标设为 $\frac{N}{M_1}$, 对于类-1 的回归目

标设为 $-\frac{N}{N_2}$ 时, 这里 N 为训练例数总和, N_1 为类 1 的样本数, N_2 为类 -1 的样本数. 贝叶斯线性判别分析的方法是在 Bayes 框架下的回归分析, 并设定如上目标值.

假定 Bayes 回归中的目标值 t 和特征向量 x 与叠加的高斯白噪声线性相关:

$$t = w^T x + n \tag{1}$$

在这个假定下, 可以得到用于回归中计算权值 w 的似然函数:

$$p(D/\beta, w) = \left(\frac{\beta}{2\pi}\right)^{\frac{N}{2}} \exp\left(-\frac{\beta}{2} \|X^T w - t\|^2\right) \tag{2}$$

这里 t 表示回归目标值, X 表示从用于训练的特征向量的水平堆栈获得的矩阵. D 表示一对 $\{x, t\}$, β 表示噪声方差的逆, N 表示训练集中的样本数.

为了在 Bayes 背景下描述推导, 需要为隐含变量设定先验分布, 例如权向量 w . 权值的先验分布为一个零均值的高斯分布. w 的估计值向初始值收敛, 从而降低了过拟合的危险.

给定似然函数和先验分布, 后验分布可以由 Bayes 公式计算如下:

$$p(w/\beta, \alpha, D) = \frac{p(D/\beta, w)p(w/\alpha)}{\int p(D/\beta, w)p(w/\alpha)dw} \tag{3}$$

既然先验和似然函数都是高斯分布的, 后验概率也应该是高斯分布并且它的参数可以由似然函数和先验概率通过方阵计算得到.

通过将代入了新的输入向量 x 的似然函数(公式 2)与后验分布(3)相乘, 并对 w 积分, 从而获得了预分布, 即在输入向量条件下的回归目标值的概率分布.

$$p(\hat{t}/\beta, \alpha, \bar{x}, D) = \int p(\hat{t}/\beta, \bar{x}, w)p(w/\beta, \alpha, D)dw \tag{4}$$

预分布同样也是高斯型分布, 可以由均值和方差来表示.

仅使用预分布的均值即可完成分类决策来参与决定, 对重复试验的每次均值进行累加, 累加均值最大值所对应的目标即可作为 BLDA 算法得出的分类结果.

5 实验与结果

为了验证本文提出的方法, 我们分析第 III 届脑机接口竞赛关于 P300 字符输入的数据集^[10], 并与其它比较好的算法比较其分类性能. 对该数据集简单描述如下: 每个使用者使用的字符输入界面为 6x6 的字符矩阵, 如图 2 所示. 在使用过程中, 要求使用者注视其中

一个字符键. 所采集到的脑电信号为 64 通道的, 采样率为 240Hz. 使用者分别是为被试 Subject A 和被试 Subject B. 这里的界面刺激闪烁采用行闪列闪的方式. 因此行列交替闪烁一轮(round)有 12 次闪烁, 这样的闪烁在输入每个字符时需重复 15 次(repeat). 对每个使用者采集总计 185 个字符.



图 2 第三届脑机接口竞赛的 P300 字符输入系统界面

为了测试本文分类方法的性能, 我们分别比较了常规的方法、本文的方法、以及与在本次竞赛第一名的获得者 Rakoto 与 Guigue 所取得的结果^[11]进行比较. 对于常规的方法, 一般在每一行或列开始闪烁时, 对每个通道的信号都抽取其 0-600ms 的信号, 并对其进行 0.1-20Hz 的带通滤波及进行 10 倍的下采样, 然后采用标准支持向量机分类算法对同样的数据集进行数据分析并计算同样的性能指标(分类准确率). 对于 Rakoto 方法^[11], 他们在训练集上进行递归消除通道和迭代选取时空特征的方法.

两位被试的离线数据分析结果如表 1 所示. 从表 1 中看出, 两位被试使用本文的特征提取和分类方法比常规方法的准确率要高, 但比 Rakoto 方法要低. 图 2 显示了三种方法在不同的重复次数(round 的个数)下的平均准确率. 每个重复次数对应一个准确率, 例如 5 表示的是从 round1 到 round 5 采集的脑电数据. 在本次竞赛数据中, 这个重复次数的范围从 1 到 15. 从图 2 中可以看出, 对于不同的重复次数, 本文方法都能获得比常规方法更高的准确率, 而在重复次数较低(<5)的情况下, 本文的方法与 Rakoto 方法的准确率接近.

表 1 3 种方法的字符预测准确率

	Subject A(%)	Subject B(%)
常规方法	88	92
本文方法	91	96
Rakoto 方法	96	100




图3 不同重复次数的平均准确率. 圆圈线、星号线和点划线分别表示常规方法、本文方法和 Rakoto 方法的平均准确率

6 总结

本文从智能处理与不确定性的角度,探讨了脑机接口中的核心问题-EEG模式特征的识别和分类.针对EEG模式分类中所存在的不确定性问题,从EEG的特征提取和分类模型构建两个方面进行了分析,并提出了解决问题的方法和对策.

脑机接口的研究还处于初级的探索阶段,我们对于大脑、EEG时间序列数据的认识和理解都是模糊的、不精确的,无法量化的,同时EEG的分类也是模糊的、带有很强的随机性,因此在EEG模式的识别和分类中存在着许多不确定性问题,传统的信号处理方法很难提取到能够反映与认知活动相关的特征,这就要求我们采用定性的数据处理方法和推理方法,结合EEG和认知活动的相关的专业背景知识,提取到与认知活动相匹配的定性特征,这是本人今后研究的方向,也是今后BCI研究发展的一个重要方向.

参考文献

- 1 王新光,邹凌,段锁林,周仁来.脑机接口技术的研究与进展.中国组织工程研究与临床康复,2008,12(39):7722-7724.
- 2 杨帮华,颜国正,丁国清,于莲芝.脑机接口关键技术研究.北京生物医学工程,2005,24(4):308-310.
- 3 李德毅,刘常昱,杜鹃,韩旭.不确定性人工智能.软件学报,2004,15(11):1583-1594.
- 4 钱学森,于景元,戴汝为.一个科学新领域-开放的复杂巨系统及其方法论.自然杂志,1990,12(5):1-8.
- 5 李少宾.面向脑机接口的不确定性 EEG 分类研究[硕士学位论文].合肥:中国科学技术大学,2008.
- 6 Farwell LA, Donchin E. Talking of the top of your head: Toward a mental prosthesis utilizing event-related brain potentials. *Electroenceph Clin Neurophysiol*, 1988, 70: 510-523.
- 7 Krusienski DJ, Sellers EW, McFarland DJ. Toward enhanced 17300 speller performances. *Journal of Neuroscience Methods*, 2008, 167(1): 15-21.
- 8 王向阳.面向不确定性推理和数据模式的模式识别方法研究[博士学位论文].上海:上海交通大学,2007.
- 9 Kindermans PJ, Verstraeten D, Schrauwen B. A Bayesian model for exploiting application constraints to enable unsupervised training of a P300-based BCI. *PloS One*, 2012, 7(4): e33758.
- 10 Kaper M, Meinicke P, Grossekhoefer U, Lingner T, Ritter H. BCI competition 2003-data set IIB: support vector machines for the P300 speller paradigm. *IEEE Trans. on Biomedical Engineering*, 2004, 51(6): 1073-1076.
- 11 Rakotomamonjy A, Guigue V. BCI competition III: dataset II-ensemble of SVMs for BCI P300 speller. *IEEE Transactions on Biomedical Engineering*, 2008, 55(3): 1147-1154.