

Chernoff加权分类器框架在运动想象脑-机接口中的应用

谭平^① 刘利枚^① 郭璠^{*②} 周开军^①

^①(湖南工商大学新零售虚拟现实技术湖南省重点实验室 长沙 410205)

^②(中南大学自动化学院 长沙 410083)

摘要: 针对现有脑机接口(BCI)分类器与大脑认知过程结合不够紧密的问题, 该文提出一种基于Chernoff加权的分类器集成框架方法, 并用于同步运动想象脑机接口中。通过对训练数据进行统计分析, 获得各时刻脑电信号(EEG)的统计特性, 并建立基于大脑认知过程的高斯概率模型。然后利用Chernoff边界特性得到该概率模型的最小误差, 并以此确定该时刻分类器的权重, 通过对各时刻分类器的加权, 实现同步脑机接口的信号分类。以脑机接口竞赛数据作为测试, 并与线性判决分析、支持向量机和极限学习方法分别结合构成新的集成方法。由实验结果可知, 加权集成框架方法的分类性能比原独立分类方法有显著提高。

关键词: 脑机接口; 运动想象; 概率模型; Chernoff误差边界; 模式分类

中图分类号: R741.044; TP391

文献标识码: A

文章编号: 1009-5896(2020)02-0488-07

DOI: 10.11999/JEIT181132

Applying Chernoff Weighted Classification Frame Method to Motor Imagery Brain Computer Interface

TAN Ping^① LIU Limei^① GUO Fan^{*②} ZHOU Kaijun^①

^①(Key Laboratory of Hunan Province for New Retail Virtual Reality Technology, Hunan University of Technology and Business, Changsha 410205, China)

^②(School of Automation, Central South University, Changsha 410083, China)

Abstract: For the problem that the classifier is less considered to be combined with the brain's cognitive process in the Brain-Computer Interface (BCI) system, a Chernoff-weighted based classifier integrated frame method is proposed and used in synchronous motor imagery BCI. In the method, the statistic characteristics of ElectroEncephaloGraphy (EEG) are obtained by analyzing in each time point of synchronous BCI, and then the probability model is established to compute the Chernoff error bound, which is adopted as the weight of common classifier to take the discriminant process. The test experiments are based on the datasets from BCI competitions, and the proposed frame method is employed to compose with LDA, SVM, ELM respectively. The experimental results demonstrate that the proposed frame method shows competitive performance compared with other methods.

Key words: Brain Computer Interface (BCI); Motor imagery; Probabilistic model; Chernoff error bound; Pattern classification

收稿日期: 2018-12-07; 改回日期: 2019-07-20; 网络出版: 2019-09-11

*通信作者: 郭璠 guofancsu@163.com

基金项目: 国家自然科学基金(61502537), 国家社科基金(19BGL111), 湖南省教育厅科学研究优秀青年项目(18B338), 湖南省重点实验室开放研究基金项目(2017TP1026), 教育部人文社科基金(14YJCZH099)

Foundation Items: The National Natural Science Foundation of China (61502537), The National Social Science Foundation of China (19BGL111), The Scientific Research Project of the Education Department of Hunan Province (18B338), The Open Fund of Key Laboratory of Hunan Province (2017TP1026), The Foundation of Ministry of Education Humanities and Social Sciences (14YJCZH099)

1 引言

脑机接口(Brain Computer Interface, BCI)是一种新型人机交互系统,它不依赖神经系统和肌肉组织,直接利用大脑活动信号与外部环境交互信息^[1]。BCI是一个比较年轻的多学科研究领域,它涉及神经学、生理学、心理学、工程学、计算机学、康复保健等多种学科^[2]。脑电信号(ElectroEncephalography, EEG)是BCI研究中普遍采用的一种生物电信号,因为该信号具有非植入、便携、时间分辨率较高的特点^[3]。而运动想象是EEG脑机接口中常用的一种脑电控制方式。它通过采集大脑运动功能区的EEG信号来判别试验者的运动意图。运动想象的EEG信号主要集中在8~24 Hz,其解码出来的信号可以用于字符拼写、控制鼠标运动、驾驶轮椅或空间导航等^[4,5]。

运动想象脑机接口通常分为同步和异步两种方式,同步方式中有提示信号,试验者根据提示信号做出相应的运动想象;而异步方式没有提示信号,需要随时识别实验者运动想象意图。异步方式的脑机接口具有更好的实用性,但是研究难度很大,成功案例较少。为了便于研究和比较,本文仅研究同步运动想象脑机接口。

不同的想象意图会产生不同的脑电信号,因此脑机接口可以看成是一个模式识别系统,通过对不同模式下的特征进行分类,从而识别大脑的意图。脑机接口中的常用分类算法包括线性判决分析^[6](Linear Discriminant Analysis, LDA)、支持向量机^[7](Support Vector Machine, SVM)、K-最近邻域^[8](K-Nearest Neighbor, K-NN)、贝叶斯统计分类器^[9]、人工神经网络^[10]等。另外人工神经网络的一些改进版本如极限学习机(Extreme Learning Machine, ELM)、深度学习^[11]也开始被用到BCI系统中。

这些分类算法大多是通用型算法,各有优缺点,但是它们都没有利用人类大脑认知过程的特性,没有与大脑的认知过程相结合。在第II届脑机接口竞赛中,Lemm等人^[12]提出了一种基于加权概率模型的方法,该方法假设大脑认知过程是一个概率模型,并计算试验者在同步脑机接口中各个时刻的认知概率,利用Chernoff误差边界对概率模型累积加权,从而有效提高分类性能,并在第II, III届脑机接口竞赛中连续获得运动想象数据组的第1名。

从原理上来说,Lemm算法是将同步运动想象脑机接口的每次试验建模成一个独立时序序列。在这个时序序列的起始时刻对齐的情况下,各个时刻的特征分布可以用统计概率来估计。考虑到相邻时刻信号相关性较强,可以通过加权累积方式,利用前

一时刻的信息提高当前时刻的分类性能。但是该方法只考虑了特征的概率分布,而没有充分利用分类器本身的分类优势。而如何将分类器的优势和Lemm算法的思想有机结合,是本文研究的主要出发点。

基于以上考虑,本文结合了Lemm所采用的方法,提出了基于Chernoff加权分类器框架分类方法。该方法通过Softmax函数将独立分类器的分类结果映射到 $[0, 1]$,然后利用累计加权方式进行再次分类判别。由于权值来源于每次试验各个时刻的统计分析,因此累积加权利用了各时刻的先验知识,提高了判别能力。通过对脑机接口竞赛数据集进行测试,结果表明该方法有效提高了独立分类器的性能。

2 Chernoff加权分类器框架

2.1 Chernoff误差边界与分类权重

在同步运动想象脑机接口实验中,每一次试验都是在信号提示下进行,且每次试验是独立的,因此可以对在 t 时刻的特征进行概率建模。假设BCI系统进行二分类试验,即左、右手运动想象判别试验。那么分别对左、右手运动想象试验进行统计,并建立左、右手运动想象特征的高斯分布,如式(1)所示

$$p(\mathbf{v}(t)|d) = \frac{|\sigma_t^y|^{-0.5}}{\sqrt{2\pi}} e^{(-\frac{1}{2}(\mathbf{v}(t)-\mu_t^y)(\sigma_t^y)^{-1}(\mathbf{v}(t)-\mu_t^y))} \quad (1)$$

其中, $\mathbf{v}(t)$ 是 t 时刻的特征向量, μ 和 σ 是左右两个类别 $d \in \{L, R\}$ 的均值和标准方差,这里的 L, R 分布表示左、右方向。由于假设的模型是高斯模型,因此可以通过Chernoff误差边界^[13]来得到该时刻的分类精度。假设

$$P(\text{er}|\mathbf{v}) = \begin{cases} P(L|\mathbf{v}), & \text{想象是右} \\ P(R|\mathbf{v}), & \text{想象是左} \end{cases} \quad (2)$$

则

$$P(\text{er}|\mathbf{v}) = \min[P(L|\mathbf{v}), P(R|\mathbf{v})] \quad (3)$$

由于概率 $p \in [0, 1]$,可以利用式(4)进行计算

$$\min[a, b] \leq a^\lambda b^{1-\lambda} \quad (4)$$

这里 $0 \leq a, b \leq 1$ 且 $0 \leq \lambda \leq 1$ 。假设 $a \geq b$,那么 $a/b \geq 1$,则 $\min[a, b] = b \leq (a/b)^\lambda b = a^\lambda b^{1-\lambda}$ 。

将式(4)和贝叶斯公式代入式(3),可以得到Chernoff误差边界

$$\begin{aligned} P(\text{er}) &= \int P(\text{er}|\mathbf{v})p(\mathbf{v})d\mathbf{v} \\ &\leq \int P^\lambda(L|\mathbf{v})P^{1-\lambda}(R|\mathbf{v})p^\lambda(\mathbf{v})p^{1-\lambda}(\mathbf{v})d\mathbf{v} \\ &= \int P^\lambda(L)p^\lambda(\mathbf{v}|L)P^{1-\lambda}(R)p^{1-\lambda}(\mathbf{v}|R)d\mathbf{v} \\ &= P^\lambda(L)P^{1-\lambda}(R) \int p^\lambda(\mathbf{v}|L)p^{1-\lambda}(\mathbf{v}|R)d\mathbf{v} \quad (5) \end{aligned}$$

如果条件概率满足正态分布,那么

$$\int p^\lambda(\mathbf{v}|L)p^{1-\lambda}(\mathbf{v}|R)d\mathbf{v} = e^{-k(\lambda)} \quad (6)$$

其中

$$e^{-k(\lambda)} = \frac{\lambda(1-\lambda)}{2} (\boldsymbol{\mu}_L - \boldsymbol{\mu}_R)^T [\lambda\sigma_L + (1-\lambda)\sigma_R]^{-1} \cdot (\boldsymbol{\mu}_L - \boldsymbol{\mu}_R) + \frac{1}{2} \ln \frac{|\lambda\sigma_L + (1-\lambda)\sigma_R|}{|\sigma_L|^\lambda |\sigma_R|^{1-\lambda}} \quad (7)$$

由于Chernoff误差边界可得到分类误差,又因为误差和精度相加为常数1,故容易得到分类精度,并用该精度作为分类权值,即精度高的权值大。假定左右概率 $P(L)=P(R)=0.5$,可以定义权重值 ω_t

$$\omega_t = 0.5 - P(\text{er}) = 0.5 - 0.5 \times \min_{0 \leq \lambda \leq 1} e^{-k(\lambda)} \quad (8)$$

这里 ω_t 可以通过数值方法求得。

当在 t_0 时刻判断分类结果时,由于每次试验有起始时刻,且试验时间长度是固定的,因此可以利用 $t \leq t_0$ 时刻的经验数据,提高分类性能。这里采用加权累积的方式,将 $t \leq t_0$ 的经验信息组合,提高分类的期望值。公式如式(9)

$$p(d|\mathbf{v}(0), \dots, \mathbf{v}(t_0)) = \left| \frac{\sum_{t \leq t_0} \omega_t p(d|\mathbf{v}(t))}{\sum_{t \leq t_0} \omega_t} \right| \quad (9)$$

将 $p(d|\mathbf{v}(0), \dots, \mathbf{v}(t_0))$ 的值转换到 $[-1, 1]$ 。可利用式(10)

$$d_{\text{out}} = 1 - 2 \times p(L|\mathbf{v}(0), \dots, \mathbf{v}(t_0)) \quad (10)$$

这里 $d_{\text{out}} > 0$ 判定为右, $d_{\text{out}} < 0$ 判定为左,相应的绝对值大小表明该判定的置信度。

2.2 Softmax回归函数

分类器对特征数据进行分类会得到一个分类距离值,该距离值是一个无量纲的距离实数,其大小可能超出 $[0,1]$ 的范围。为此,可以通过softmax函数^[4]将分类器的输出变换到 $[0,1]$ 。假设分类器的输出是 E_L 和 E_R ,可以定义如式(11),式(12)的变换公式

$$P_L(x) = \frac{\exp(\theta_L E_L)}{\exp(\theta_L E_L) + \exp(\theta_R E_R)} \quad (11)$$

$$P_R(x) = \frac{\exp(\theta_R E_R)}{\exp(\theta_L E_L) + \exp(\theta_R E_R)} \quad (12)$$

其中 θ_L 和 θ_R 是softmax的参数, P_L 和 P_R 分别是判断为左和右的概率。由式(11)和式(12)可知,分母部分是左右判断概率的累加值,实现概率的归一化。通过softmax可以将独立分类器的输出变换到概率空间,满足Chernoff误差边界的条件,从而可以通过式(9)利用先验知识提高分类性能。

2.3 完整的分类器框架

图1是本文所提方法的结构框图,在该框图中主要包括特征输入、初次分类器、Softmax转换、加权累积和判别输出5个部分。这个结构可以看成是一个分类框架(Classification Frame, CF),其中初次分类器可以采用任何一种独立分类器,只要该分类器的输出判断是一个判别实数,例如LDA, SVM, ELM等。在独立分类器完成分类后,通过Softmax函数将独立分类输出映射到 $[0, 1]$ 之间,然后利用Chernoff进行加权处理。

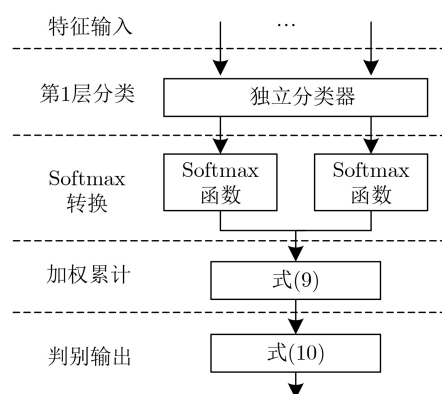


图1 Chernoff加权框架方法的结构框图

实际分类应用中包括训练和测试两个过程。表1和表2所示的算法1和算法2分别是该方法的训练和测试步骤。通过训练过程,可以得到高斯概率模型以及Chernoff误差边界,从而可以获得相应时刻 t 的权值 w ,同时也可得到独立分离器的各个参数。

在测试过程中,独立分类器用来处理测试数

表1 算法1 Chernoff框架方法的训练过程

输入: EEG训练数据
输出: 独立分类器模型参数和概率权重 w
步骤1 对EEG数据进行预处理,提取特征向量;
步骤2 利用独立分类器训练得到模型参数;
步骤3 利用式(1)得到特征向量的均值和方差;
步骤4: 利用式(8)得到权重 w 。

表2 算法2 Chernoff框架方法的测试过程

输入: t 时刻的测试EEG数据,独立分类器参数和权重 w
输出: 分类结果和判定值 $d_{\text{out}}(t)$
步骤1 对EEG数据进行预处理,提取特征向量;
步骤2 通过独立分类器的训练模型得到 $y_c(t)$;
步骤3 利用式(11)和式(12)将 y_c 转化到 $p(t) \in [0, 1]$;
步骤4 利用式(9)计算 $p_{\text{out}}(t)$;
步骤5 利用式(10)将 $p_{\text{out}}(t)$ 变换到 $d_{\text{out}}(t) \in [-1, 1]$;
步骤6 通过 $d_{\text{out}}(t)$ 的符号获得分类结果。

据, 其输出结果将通过softmax函数转换成 $P(t) \in [0, 1]$ 。相应的权重 w 可以用于计算 $p(d|\mathbf{v}(0), \dots, \mathbf{v}(t_0))$ 。

3 实验数据及方法

实验数据来自第II届脑机接口竞赛数据第3个数据集dataset III, 该数据集包括训练和测试数据。数据分为两个类别, 分别为左手运动想象和右手运动想象, 由C3和C4两个导联电极采集得到。为了保证同步脑机接口的准确实现, 需要根据提示信号进行多次试验。试验开始前2 s是休息调整期, 然后在 $t = 2$ s时, 系统发出“哔”的声音, 提示即将开始, 同时屏幕上显示一个十字叉; 在 $t = 3$ s时, 随机显示向左(或者向右)的箭头, 此刻, 试验者想象左手(或者右手)的动作, 如图2所示。




图2 每次试验的时序示意图

该数据集中训练和测试数据分别都包括140次试验, 该试验的时序与图2一致。由于竞赛中采用的是互信息作为评价标准, 互信息越高, 则性能越好。本实验同样采用互信息作为分类方法的性能评价指标。另外为了验证本实验方法的有效性, 实验中还选择了其他数据集作为验证, 这些数据分布来自第III、第IV届脑机接口竞赛数据集。这些数据集同样采集于C3和C4, 其中第2个数据集选自第III届脑机接口竞赛数据集dataset IIIb, 而第3、第4个数据集选自第IV届脑机接口竞赛数据集dataset IIb。如表3所示。

实验中采用Bandpower作为特征提取方法, 由于运动想象包括的频率主要在 $8 \sim 12$ Hz和 $16 \sim 24$ Hz, 因此设计2个4阶巴特沃斯带通滤波器。然后将滤波后的数据进行平方, 得到能量特征。为了减少误差的影响以及满足高斯分布, 对前面处理的数据进行平滑和对数操作。由于实验数据共有2个

导联电极和2个带通滤波器, 因此 t 时刻的数据样本包含4个特征。

本文采用了LDA, SVM, ELM 3种分类器, 并分别与所提出的Chernoff加权分类框架结合, 构成LDA-CF, SVM-CF, ELM-CF 3种方法。其中SVM利用了LibSVM工具包, 采用线性核, 其参数为默认值。而ELM设置了32个隐含节点, 激活函数是Sigmoid函数。考虑到深度学习在机器学习与模式分类领域的巨大成功以及EEG信号的时序特性, 本文利用了基于深度信息的序列学习模型LSTM (Long-Short Term Memory)方法, 该方法采用3层LSTM网络, 每层采用32个节点, 使用Softmax作为激活函数。实验分为训练过程和测试过程, 通过训练可以得到分类器参数以及Chernoff权重, 然后通过测试数据测试分类器性能。这里需要说明, LSTM本身是针对时序信号的分类方法, 且它带有记忆和遗忘机制, 无法直接与Chernoff框架结合, 因此本文实验中针对LSTM没有采用Chernoff框架。

BCI系统实现了人的大脑到外部设备的通信, 可以用通信理论来量化其信息传输率。文献[15]提出了脑机接口中连续输出的互信息计算方法, 并且作为脑机接口竞赛的评判标准。互信息表示从一个带噪声信道的输出中获得输入的信息量, 公式为

$$I = \frac{1}{2} \log_2 \left(\frac{\sigma_s^2 + \sigma_n^2}{\sigma_n^2} \right) = \frac{1}{2} \log_2 (1 + \eta_{\text{SNR}}) \quad (13)$$

其中, σ_s^2 和 σ_n^2 分别是信号和噪声的方差, η_{SNR} 是信噪比。

由于每一次试验都是时域上的连续分类, 这意味着在任何一个时间点上的EEG数据, 必须要实时分析并获得分类结果。实验过程中本文采用了Biosig工具箱, 它是BCI竞赛中官方建议的辅助评估工具。Biosig工具箱中带有互信息指标的性能评估函数, 可以直接使用。

4 结果与讨论

实验程序在Matlab 2010b上运行, 计算机的CPU为双核2.5 GHz, 4 GB RAM。本小节包括训练数据特征的概率统计分析、各分类方法的结果比较和实验结果讨论3部分。

表3 实验中的数据集

序号	数据集来源	训练集个数(试验次数)	测试集个数(试验次数)	类别
1	BCI II (III)	1 (140)	1 (140)	2
2	BCI III (IIIb)	1 (320)	1 (320)	2
3	BCI IV (IIb)	3 (400)	2 (320)	2
4	BCI IV (IIb)	3 (400)	2 (320)	2

4.1 特征向量的概率统计分析

为了验证所提取的特征向量是否满足高斯概率分布,对各个时刻的特征值进行概率统计分析。可以通过统计频数直方图方式得到概率分布图。图3是数据集1中想象右手运动的特征统计图。其中 x 轴是Bandpower特征值, y 轴表示时间, z 轴是特征的统计概率。从图中可以看出第1 s的时候,特征分布的左边有一点拖尾,这是起始时刻滤波引起的拖尾效应。在随后的时刻里,虽然各个时刻处的概率有点小尖峰,但是特征分布基本上具有高斯分布的特性,即中间概率大,两端概率较少。因此用高斯分布进行概率估计是可行的。




图3 各个时刻的特征统计概率分布图

4.2 各分类方法的结果对比

实验过程总共对7个方法进行测试。由于ELM是多层感知器(Multi-Layer Perception, MLP)的一个特例,而且它的权值矩阵是随机产生的,计算的结果会在一定范围内随机变化,为了验证其性能,所以针对ELM和ELM-CF两个算法,每个数据集运行50次的平均值和方差作为它们性能指标。图4—图7是第1—第4个测试数据集中互信息的结果图。其中 x 轴是时间, y 轴是对应的互信息。图中互信息越大,意味着传输的信息率越高,分类性能越好。

在图4中,LDA,SVM,ELM,LSTM在 $t = 5$ s时达到最大互信息,然后开始递减,显然ELM在这4个算法中是最好的。而LDA-CF,SVM-CF和ELM-CF的互信息在 $t = 5$ s之前,比其他3个方法




图4 数据集1的互信息图




图5 数据集2的互信息图

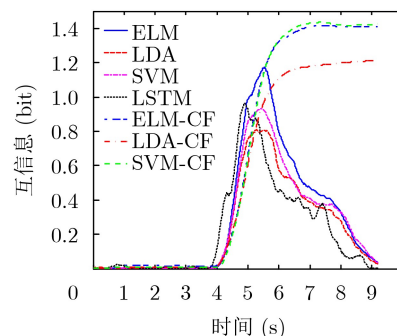


图6 数据集3的互信息图




图7 数据集4的互信息图

的低。但是随着时间的增加,这3个方法的互信息保持增长,其中LDA-CF在 $t = 8.6$ s时得到最大互信息0.631,SVM-CF在 $t = 0.84$ s达到最大值0.662,而ELM-CF在 $t = 0.85$ s时互信息达到最大值0.6806。从图中可看出,引入Chernoff加权框架的3个分类方法的性能得到了较大提高。

由于数据集1来自第II届BCI竞赛,表4列出了本文中所采用方法得到的最大互信息以及第II届脑机接口竞赛结果,其中ELM和ELM-CF方法分别列出了重复50次的均值和方差。从表4中可以看出,引入了Chernoff加权框架的算法,其互信息相对原来算法而言,都得到了较大提高,并且均高于脑机接口竞赛第1名的0.61 bit,其中ELM-CF算法具有最佳性能,差不多高出第1名10%。

图5、图6、图7分别描述了数据集2、数据集3和数据集4在各算法下获得的互信息变化图。从图

中同样可以看出, 在开始阶段, LDA-CF, SVM-CF和ELM-CF 3个框架集成方法的互信息比独立分类器算法的低, 但随着时间的变化, 它们的增速比独立分类器快。并且在独立分类器递减的时候, 它们依然保持增长, 最终高于独立分类器方法。LDA-CF, SVM-CF和ELM-CF 3个方法相互比较可知, 在图5中, LDA-CF的值略高于SVM-CF和ELM-CF, 在图6、图7中, SVM-CF高于LDA-CF和ELM-CF。从4个数据集的结果来看, LDA-CF, SVM-CF和ELM-CF分别有表现最佳的情况。但是整体而言, 它们都比独立分类方法有较大性能提高。

图8是各算法的分类精度的柱状图。图中的小短线表示分别是ELM和ELM-CF的方差。从图8中可以看出, 不同的数据集分类准确性各有不同, 但是总体而言基于框架的分类方法的分类精度要高于独立分类器方法。

为了进一步查看框架分类方法分类的变化过程, 这里以LDA-CF分类器为例, 对式(10)中 d_{out} 输出结果进行统计分析。图9是LDA-CF方法对数据集1输出结果 d_{out} 的时间统计图, 其中 x 轴是时间轴, 纵轴是 d_{out} 输出值的统计量。粗虚线是判断为右手运动的均值, 其方差由浅黄色区域表示。粗实线是判断为左手运动的均值, 其方差由深绿色表示。在开始4 s, 左右判断的方差和均值基本重叠在一




图9 d_{out} 的统计均值和方差变化图

起, 因为此刻还没有做出判别。随着时间变化, 均值逐渐分开, 大概从第6 s开始, 左右判别的方差已经完全分开, 这说明本方法的分类具有较高的置信度。

4.3 实验结果讨论

本文所采用的Chernoff加权框架方法借鉴了序列采样模型建模方法。序列采样模型^[16]是认知过程模型中一种经典方法, 在人们做决策时, 该方法假设决策信息来源于时间采样样本信息, 随着这些信息的积累, 逐渐超过决策边界, 从而做出判别。而基于Chernoff加权框架分类方法将独立分类器与该过程有机结合, 充分利用的 t 时刻之前的信息, 提高了分类器的性能。

另外, 基于Chernoff加权框架方法利用的是 t 时刻之前的概率统计信息, 与直接利用 t 时刻之前的特征向量不同。直接利用 t 时刻之前的特征向量, 可以简化为 t 时刻之前的特征向量与 t 时刻的特征向量的权重是相同的, 而分类框架利用 t 时刻之前的特征向量的权重是不同的, 该权重依赖于所计算的 w 值。如果仅仅从采用更多数据上说, 分类框架是利用了更多数据, 但是不是简单利用更多数据, 而是基于先验概率统计的数据信息。

本文所提加权框架方法可以理解为两步分类方法, 第1步是独立分类器分类, 第2步是通过概率模型分类, 这两步通过softmax函数连接, 即将第1步的分类结果变换到概率空间, 满足第2步分类的条件。同时本方法结合了同步脑机接口实验的特征, 通过引入Chernoff误差累积加权过程, 在 t 时刻分类时利用 t 时刻之前的先验知识, 使得 t 时刻的分类性能高于 t 时刻之前的性能。从图4-图7也可看出独立分类是一个递增然后递减的过程, 而框架分类的互信息基本上是递增的, 这进一步说明本文的结果与序列采样模型具有一致性。

5 结束语

本文提出了基于Chernoff加权的分类器框架方法, 该方法利用softmax函数结合独立分类器和

表4 数据集1的最大互信息(bit)

分类方法	最大互信息
ELM	0.524/0.051
LDA	0.414
SVM	0.471
LSTM	0.511
ELM-CF	0.680/0.020
LDA-CF	0.631
SVM-CF	0.662
第II届BCI竞赛的第1名	0.61

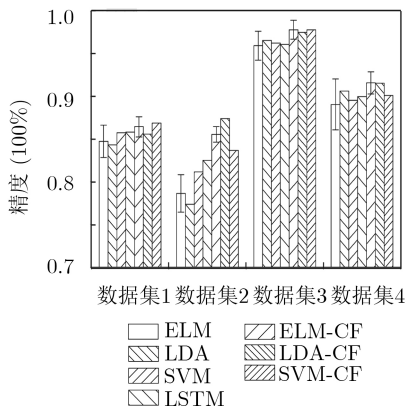


图8 各算法分类精度结果图

Chernoff误差边界加权两者优势,前者具有良好的分类性能,后者在分类过程中有效利用先验知识。具体实现过程中通过训练样本数据获得试验各个时刻的加权值,然后采用加权累积方式,利用 t 时刻之前的经验数据,提高分类性能。实验比较了LDA, SVM, ELM, LSTM, LDA-CF, SVM-CF, ELM-CF 7种方法,通过在历届脑机接口竞赛数据集的测试可知,结合Chernoff加权框架分类方法的互信息基本保持递增,且均高于原来单个分类器的性能。由于所利用的数据集都是二分类问题,下一步将重点研究如何将本方法应用到脑机接口的多分类问题中。

参考文献

- [1] TIWARI N, EDLA D R, DODIA S, *et al.* Brain computer interface: A comprehensive survey[J]. *Biologically Inspired Cognitive Architectures*, 2018, 26: 118–129. doi: [10.1016/j.bica.2018.10.005](https://doi.org/10.1016/j.bica.2018.10.005).
 - [2] 杨帮华, 李博. 基于脑机接口的康复训练系统[J]. *系统仿真学报*, 2019, 31(2): 174–180. doi: [10.16182/j.issn1004731x.joss.18-0791](https://doi.org/10.16182/j.issn1004731x.joss.18-0791).
YANG Banghua and LI Bo. Rehabilitation training system based on brain computer interface[J]. *Journal of System Simulation*, 2019, 31(2): 174–180. doi: [10.16182/j.issn1004731x.joss.18-0791](https://doi.org/10.16182/j.issn1004731x.joss.18-0791).
 - [3] ALAZRAI R, ALWANNI H, BASLAN Y, *et al.* EEG-based brain-computer interface for decoding motor imagery tasks within the same hand using Choi-Williams time-frequency distribution[J]. *Sensors*, 2017, 17(9): 1937. doi: [10.3390/s17091937](https://doi.org/10.3390/s17091937).
 - [4] LEEB R, LEE F, KEINRATH C, *et al.* Brain-computer communication: Motivation, aim, and impact of exploring a virtual apartment[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2007, 15(4): 473–482. doi: [10.1109/TNSRE.2007.906956](https://doi.org/10.1109/TNSRE.2007.906956).
 - [5] GUY V, SORIANI M H, BRUNO M, *et al.* Brain computer interface with the P300 speller: Usability for disabled people with amyotrophic lateral sclerosis[J]. *Annals of Physical and Rehabilitation Medicine*, 2018, 61(1): 5–11. doi: [10.1016/j.rehab.2017.09.004](https://doi.org/10.1016/j.rehab.2017.09.004).
 - [6] HASAN M R, IBRAHIMY M I, MOTAKABBER S M A, *et al.* Classification of multichannel EEG signal by linear discriminant analysis[C]. The 23rd International Conference on Systems Engineering, 2015: 279–282. doi: [10.1007/978-3-319-08422-0_42](https://doi.org/10.1007/978-3-319-08422-0_42).
 - [7] SELIM S, TANTAWI M M, SHEDEED H A, *et al.* A CSP\AM-BA-SVM approach for motor imagery BCI system[J]. *IEEE Access*, 2018, 6: 49192–49208. doi: [10.1109/access.2018.2868178](https://doi.org/10.1109/access.2018.2868178).
 - [8] BHADURI S, KHASNOBISH A, BOSE R, *et al.* Classification of lower limb motor imagery using K nearest neighbor and naïve-bayesian classifier[C]. The 3rd IEEE International Conference on Recent Advances in Information Technology (RAIT), Dhanbad, India, 2016: 1–6. doi: [10.1109/RAIT.2016.7507952](https://doi.org/10.1109/RAIT.2016.7507952).
 - [9] ZHANG Yu, WANG Yu, JIN Jing, *et al.* Sparse Bayesian learning for obtaining sparsity of EEG frequency bands based feature vectors in motor imagery classification[J]. *International Journal of Neural Systems*, 2017, 27(2): 1650032. doi: [10.1142/S0129065716500325](https://doi.org/10.1142/S0129065716500325).
 - [10] HAZRATI M K and ERFANIAN A. An online EEG-based brain-computer interface for controlling hand grasp using an adaptive probabilistic neural network[J]. *Medical Engineering & Physics*, 2010, 32(7): 730–739. doi: [10.1016/j.medengphy.2010.04.016](https://doi.org/10.1016/j.medengphy.2010.04.016).
 - [11] 程时伟, 周桃春, 唐智川, 等. 卷积神经网络实现的运动想象脑电分类及人-机器人交互应用[J]. *软件学报*, 2019, 30(10): 1–14. doi: [10.13328/j.cnki.jos.005782](https://doi.org/10.13328/j.cnki.jos.005782).
CHENG Shiwei, ZHOU Taoqun, TANG Zhichuan, *et al.* Motor imagery EEG classification based on convolutional neural network and its application in human-robot interaction[J]. *Journal of Software*, 2019, 30(10): 1–14. doi: [10.13328/j.cnki.jos.005782](https://doi.org/10.13328/j.cnki.jos.005782).
 - [12] LEMM S, SCHAFFER C, and CURIO G. BCI competition 2003-data set III: Probabilistic modeling of sensorimotor-rhythms for classification of imaginary hand movements[J]. *IEEE Transactions on Biomedical Engineering*, 2004, 51(6): 1077–1080. doi: [10.1109/TBME.2004.827076](https://doi.org/10.1109/TBME.2004.827076).
 - [13] TAN Ping, TAN Guanzheng, CAI Zixing, *et al.* Using ELM-based weighted probabilistic model in the classification of synchronous EEG BCI[J]. *Medical & Biological Engineering & Computing*, 2017, 55(1): 33–43. doi: [10.1007/s11517-016-1493-x](https://doi.org/10.1007/s11517-016-1493-x).
 - [14] MATSUI H. Variable and boundary selection for functional data via multiclass logistic regression modeling[J]. *Computational Statistics & Data Analysis*, 2014, 78: 176–185. doi: [10.1016/j.csda.2014.04.015](https://doi.org/10.1016/j.csda.2014.04.015).
 - [15] SCHLOGL A, KEINRATH C, SCHERER R, *et al.* Information transfer of an EEG-based brain computer interface[C]. The 1st International IEEE EMBS Conference on Neural Engineering, Capri Island, Italy, 2003: 641–644. doi: [10.1109/CNE.2003.1196910](https://doi.org/10.1109/CNE.2003.1196910).
 - [16] FORSTMANN B U, RATCLIFF R, and WAGENMAKERS E J. Sequential sampling models in cognitive neuroscience: Advantages, applications, and extensions[J]. *Annual Review of Psychology*, 2016, 67: 641–666. doi: [10.1146/annurev-psych-122414-033645](https://doi.org/10.1146/annurev-psych-122414-033645).
- 谭平: 男, 1981年生, 讲师, 主要研究方向为脑电信号处理、计算智能、模式识别。
刘利枚: 女, 1975年生, 教授, 主要研究方向为人工智能、机器人。
郭璠: 女, 1982年生, 副教授, 主要研究方向为图像增强、机器视觉、模式识别。
周开军: 男, 1978年生, 副教授, 主要研究方向为机器视觉、模式识别。