

通道扩维与 FastICA 算法相融合用于 BCI 运动想象脑电信号识别

翟克文¹, 刘建平¹, 司昕路²

(1 武警工程大学 信息工程系, 陕西 西安 710086;

2 西安机电信息技术研究所, 陕西 西安 710065)

摘 要: FastICA 是独立成分分析法(ICA)中的一种快速算法, 因其收敛速度快而备受关注. 本文将基于负熵判据的 FastICA 算法应用于运动想象脑电信号的识别中, 并根据 ICA 算法的特点设计了数据处理的实验流程. 针对 2003 年国际 BCI 竞赛 data set III 中通道数较少的问题, 提出一种通道扩维算法, 在不增加采集电极数的情况下, 可成倍地增加相似通道的数量, 提供更丰富的脑电信息. 将通道扩维与 FastICA 算法相融合应用于国际 BCI 竞赛数据的处理中, 实验结果表明通道扩维算法提升了 FastICA 算法的分类准确率, 同时 FastICA 算法处理信息速度较快的特点也弥补了通道扩维算法耗时较多的缺陷.

关键词: 独立成分分析; 负熵; 通道扩维; 脑机接口

中图分类号: TP391

文献标识码: A

文章编号: 1000-7180(2015)11-0180-05

Combination of the Channel Dimension Expansion and FastICA for the Recognition of BCI Motor Imagery EEG

ZHAI Ke-wen¹, LIU Jian-ping¹, SI Xin-lu³

(1 Department of Information, Engineering University of CAPF, Xi'an 710086, China;

2 Xi'an Institute of Electromechanical Information Technology, Xi'an 710065, China)

Abstract: As a fast algorithm of independent analysis (ICA), FastICA is drawing attention due to its rapid convergence speed. Based on the application of FastICA algorithm with the criterion of neg-entropy to the recognition of motor imagery electroencephalogram (EEG), and the characteristics of ICA, this paper designs the experimental process for data treatment. Concerning the problem of few channels in the data set III in the BCI Competition 2003, a channel dimension expansion algorithm is put forward in this paper, which can exponentially increase the number of similar channels and provide more brain electricity information without increasing the number of electrodeplates to be collected. In this paper, the channel dimension expansion is combined with the algorithm of FastICA to be applied to the data treatment of BCI Competition. The experiment results suggest that the channel dimension expansion algorithm can improve the classification accuracy of FastICA, and that the fast information treatment of FastICA can make up for the time-consuming side of the channel dimension expansion algorithm.

Key words: independent component analysis (ICA); neg-entropy; channel dimension expansion; brain-computer interface (BCI)

1 引言

BCI 技术绕开了外周神经和肌肉等正常的脑与外界交流的途径, 通过分析脑信号、提取信息、控制

外部设备的方式实现了大脑直接与外部环境进行通讯; 其实质是通过脑电信号识别人的意图, 从而实现人机交流^[1-2]. BCI 技术在医疗、军事、娱乐等很多领域有着广泛的应用前景, 正受到全世界范围内专家

学者的关注与研究^[3].

人想象肢体运动时,大脑相应的感觉运动区中的 α 和 β 节律能量会发生变化,我们可以通过检测 α 和 β 节律的变化来实现对不同想象任务的识别.能否准确快速地识别出与运动想象相关的脑电模式,是 BCI 系统的主要评价指标.由于脑电信号具有非平稳、时变、微弱等特点,选取有效的特征提取方法,是 BCI 技术的关键^[4-5].本文提出一种通道扩维与 FastICA 算法相融合的特征提取方法,该方法能够有效地解决由于脑电采集电极过少而造成的准确率不高的问题,同时比传统的时频分析法更快速,适合于在线分析.本文应用计算机技术,将真实的脑电实验数据进行相应的格式转化,导入到 Matlab 工具中进行实验.通过两种扩维实验结果的对比,验证了融合算法的优越性,发现了该算法的一般规律及存在的主要问题,为下一步将算法应用于脑电数据的在线分析提供了一定依据.

2 快速独立成分分析(FastICA)算法

2.1 ICA 算法原理

独立成分分析法^[6-7]可以看作是主成分分析法(PCA)的一种扩展,它将数据变换到相互独立的方向上,使经变换所得的各个分量之间同时满足正交性和相互独立性.从数学的角度考虑就是为多维数据寻找一种变换,使得数据的特征尽可能相互独立.ICA 的基本模型如图 1 所示.




图 1 ICA 模型

$s_i(t), i = 1, 2, \dots, N$ 为 N 个源信号,构成列向量 $S(t) = [s_1(t), \dots, s_N(t)]^T$, $x_i(t), i = 1, 2, \dots, M$ 为 M 个观测信号(混合信号),构成列向量 $X(t) = [x_1(t), \dots, x_M(t)]^T$,满足 $X(t) = AS(t)$,其中 $A(M \times N)$ 为混合矩阵($N \leq M$).从观测信号 $X(t)$ 中提取源信号 $S(t)$ 的解决思路是寻找一个 $N \times M$ 维解混矩阵 W ,使 $X(t)$ 经过 W 变换后得到 N 维近似源信号 $Y(t) = [y_1(t), \dots, y_N(t)]^T$,即有

$$Y(t) = WX(t) = WAS(t) \quad (1)$$

为了确保 ICA 基本模型是可解的,必须作出如下假设和约束:

- (1)独立成分是统计独立的;
- (2)独立成分具有非高斯分布;

(3)独立成分数小于或等于混合信号数;

独立成分分析是以将观测的随机信号分解为统计独立的分量为目标.独立性的要求对 ICA 非常重要,而 ICA 的思路也主要源于两种独立性度量思想——非线性不相关原理、非高斯性极大原理^[8].

本文所用的基于负熵的 FastICA 算法就是根据非高斯性极大原理提出的.

2.2 基于负熵的 FastICA 算法

FastICA 算法由信号的预处理和独立成分的提取两部分组成.预处理包括信号的中心化和白化两步,基于负熵的 FastICA 算法的输入数据必须要经过白化处理.

为了对预处理后的信号进行独立成分的提取.要首先寻找一种独立性的判断依据来度量分离信号的独立性.根据非高斯性极大原理,本文采用负熵作为信号独立性的判据.

假设随机向量 $y = [y_1, y_2, \dots, y_3]^T$ 的联合概率密度为 $p(y)$,其微分熵定义为

$$H(y) = - \int p(y) \log p(y) dy \quad (2)$$

负熵定义为

$$J(y) = H(y_{\text{gauss}}) - H(y) \quad (3)$$

式中, y_{gauss} 是具有和 y 相同协方差矩阵的高斯变量.

由信息论可知,高斯变量在所有相同方差的随机变量中熵是最大的.所以,式(3)中求 $J(y)$ 的最大值就是最大化随机变量 y 的非高斯性.但是,式(3)中负熵的计算涉及到对随机变量概率密度的估计,估计的有效性依赖于对估计参数的选择,计算量大,因此在实际应用中要选取负熵计算的近似方法.本文选取非线性函数对负熵进行估计.

$$J(y) \approx [E\{g(y)\} - E\{G(y_{\text{gauss}})\}]^2 \quad (4)$$

G 是对比函数,是一种非二次、非线性函数, G 函数的选取关系到算法的计算速度、结果的稳定性,本文经过多次实验验证,选取适合处理 BCI 信号的 G 函数为 $G(u) = \frac{1}{4}u^4$.

依据负熵的判断依据,当 $J(y)$ 最大时,独立成分得以分离,此时可求出相应的分离矩阵 W .由式(4)可知, $J(y)$ 最大即 $E\{G(y)\}$ 最大,也就是对 $E\{G(y)\} = E\{G(w^T x)\}$ 求极大值.令 $E'\{G(w^T x)\} = E\{xg(w^T x)\} = 0$,其中 w 是分离矩阵 W 中的某一行的转置,是一个 N 维向量, g 函数是对比函数 G 的导数.

由牛顿迭代公式:

$$x_{n+1} = x_n - [f(x_n)/f'(x_n)], n = 0, 1, 2, \dots \quad (5)$$

可得

$$w^a = w - \frac{E\{xg(w^T x)\} - \beta w}{E\{g'(w^T x)\} - \beta} \quad (6)$$

式中, $\beta = E\{w^T xg(w^T x)\}$, w^a 为某一次牛顿迭代的结果. 由于观测信号已经经过白化预处理, 为了简便算法, 可将式(6)进行简化处理, 并在每次迭代后, 对 w^a 进行归一化处理, 从而可得 FastICA 的算法公式如下:

$$w^a = E\{xg(w^T x)\} - E\{g'(w^T x)\}w \quad (7)$$

$$w^* = w^a / \|w^a\| \quad (8)$$

FastICA 算法就是通过对式(7)、式(8)的迭代, 估计出分离矩阵 W , 进而估计独立源的.

3 FastICA 算法在 BCI 运动想象脑电信号识别中的应用

本文的实验数据源自 2003 年国际 BCI 竞赛 data set III(左右手运动想象)^[4]. 实验选取 140 组试验采集的脑电数据作为研究对象, 每组试验的真实分类均已知(左右手各 70 次), 便于计算分类准确率. 每组试验包含 C3、C4、Cz 三通道数据, 时间长度为 9 s, 采样频率为 128 Hz. 试验中运动想象开始于 $t=3$ s, 因此, 有效时间为第 3 s 至第 9 s, 有效数据为 896 个数据点.

本文对脑电数据进行识别的思路是, 先把 140 组数据随机分为训练集与测试集(训练集 20 组、测试集 120), 把 20 组训练集数据中想象左手运动的挑出, 并根据需要进行选择时间段, 最后把选择好的数据进行首尾相连. 按照 FastICA 算法的步骤对连接好的数据进行独立分量提取就可以得到一个分离矩阵 W_L, W_R . 用同样的方法可以构造出右手滤波器 W_R .

通过上面的步骤, 我们得到了各类任务的滤波器 W , 接下来的任务就是定义特征向量. 把采集到的脑电数据 W 分别送入到两种滤波器 W_L, W_R 中可得到两种源信号:

$$\begin{cases} Z_L = W_L X \\ Z_R = W_R X \end{cases} \quad (9)$$

根据想象左右手运动脑电信号的 ERD/ERS 现象^[4], 本文采用如下方法定义特征量.

$$\begin{cases} f_1 = \log\left(\frac{\text{var}(Z_L)}{\text{var}(Z_L) + \text{var}(Z_R)}\right) \\ f_2 = \log\left(\frac{\text{var}(Z_R)}{\text{var}(Z_L) + \text{var}(Z_R)}\right) \\ f = (f_1, f_2) \end{cases} \quad (10)$$

f 就是得到的特征向量, 将 f 送入到分类器中进行处理就可得到最终的分类结果. 本文采用基于径向基核函数的 SVM 分类器对特征向量进行分类^[12], 对测试集的 120 组数据采用 Hold-out 交叉验证法计算分类准确率, 即将 120 组数据集平均划分为两个子集, 一组作为训练集, 另一组作为测试集. 进行两次分类, 相互调换子集, 取两次结果的平均作为最终结果.

本文具体的实验流程如图 2 所示.




图 2 FastICA 实验流程

4 通道扩维

在 2003 年国际 BCI 竞赛 data set III 中, 只有 C3、C4、Cz 三通道数据可供选择, 通道数过少. 针对这个问题, 本文采用对原始数据进行短时延迟的方法, 人为地增加通道数量, 从而达到通道扩维的目的.

竞赛数据中, 原始的脑电信号为

$x(t) = \{x_{c3}(t), x_{c4}(t), x_{cz}(t)\}^T$. 对 $x(t)$ 进行 Δt 秒的延时得到一组“新”信号为

$x(t - \Delta t) = \{x_{c3}(t - \Delta t), x_{c4}(t - \Delta t), x_{cz}(t - \Delta t)\}^T$, 将延时后的信号与原信号在空域上进行组合, 得到扩维后的信号如下:

$$\tilde{x}(t) = \{x(t)^T, x(t - \Delta t)^T\}^T \quad (11)$$

新的脑电数据 $\tilde{x}(t)$ 在通道数上较原数据 $x(t)$ 多了一倍.

通道扩维算法包括单次扩维和多次扩维两种. 单次扩维中, 每次实验只进行一次 Δt 的扩维, 通过调整 Δt 的值来获取最优的扩维效果. 多次扩维中, 通过多次延时不同的 Δt 以达到扩维的目的, 得到的新信号如下:

$$\tilde{x}(t) = \{x(t)^T, x(t - \Delta t_1)^T, x(t - \Delta t_2)^T, \dots,$$

$$x(t - \Delta t_n)^T \}^T \quad (12)$$

式中, $\Delta t(i=1,2,\dots,n)$ 为第 i 次的延拓时间. 实验中, 我们通过调整扩维次数及延拓时间获得最佳的扩维效果. 在通道数较少的运动想象 BCI 实验中, 通道扩维算法可以在不增加采集电极数的情况下, 成倍增加脑电信号的通道数量, 提供更多的脑电信息.

5 实验结果

5.1 单次扩维实验

根据相关研究^[13], 本文对国际竞赛数据进行预处理, 选取 4~6 s 时间段, 8~30 Hz 频率段的脑电数据进行研究. 本文把 140 次试验数据平均分成 7 组, 每组 20 次试验数据分别当训练集, 其余 120 次当测试集, 共进行 7 组分类实验, 7 组实验的标号分别为 A1, A2, A3, A4, A5, A6, A7. 实验的采样频率为 128 Hz(即 1 s 有 128 个数据点), 每组实验进行 10 次延时, 分别延时 10 个、20 个、30 个直到 100 个数据点, 应用 FastICA 算法(假设独立源数与通道数相同)和 SVM 算法计算分类准确率.

从表 1 中可以看出, 在单次扩维实验中, 扩维后分类准确率较扩维前有较大的提升, 平均分类准确率至少提高了 3.4%(84.4%~87.8%). 同时, 对比扩维后的准确率发现, 延时不同的数据点数对分类准确率影响不大, 最大平均分类准确率与最小平均分类准确率相差只有 0.9%(87.8%~88.7%), 并且没有规律性. 扩维后完成分类的时间较扩维前增加了约 25%, 但考虑到 FastICA 算法较传统的时频分析法已经节省了大量的时间, 因此本实验中时耗的因素可以适当忽略.

表 1 单次扩维后的分类准确率 %

实验 标号	延时的数据点数										
	0	10	20	30	40	50	60	70	80	90	100
A1	84.3	88.4	86.7	85.5	90.3	86.4	88.6	84.9	86.5	87.6	87.7
A2	85.8	87.9	88.7	91.6	88.2	87.7	86.8	89.4	88.6	87.8	89.5
A3	87.5	88.7	91.3	90.7	89.9	89.6	93.7	88.8	91.7	92.1	89.5
A4	79.4	82.0	83.9	83.5	84.3	82.6	82.0	81.7	83.7	81.5	82.9
A5	88.9	91.3	93.7	91.9	90.9	92.4	94.4	92.5	93.1	94.1	92.3
A6	82.4	85.3	85.5	88.4	86.4	84.1	86.4	86.3	85.7	87.5	85.1
A7	83.7	86.9	85.5	85.7	88.6	87.7	87.3	84.7	89.5	85.3	86.5
均值	84.4	87.8	88.2	88.4	88.2	87.9	88.7	87.8	88.3	88.0	87.9
时间	2.2	2.7	3.1	3.0	2.7	2.9	2.7	2.8	2.9	2.6	3.0

5.2 多次扩维实验

与单次扩维实验相同, 仍然选取 4~6 s 时间段, 8~30 Hz 频率段的脑电数据, 进行 7 组分类实验, 实验标号不变. 每组实验分别进行 10 次扩维, 分别扩维 1 次、2 次、3 次一直到 10 次, 1 到 10 次扩维的延时点数分别为 10 个、20 个、30 个一直到 100 个. 应用 FastICA 算法和 SVM 算法计算分类准确率, 由于多次扩维后通道数较多, 设定独立源数为 4 不变.

表 2 所示为 7 组多次扩维实验的分类结果, 从分类结果可以看出, 在多次扩维实验中, 扩维后的分类准确率均有一定程度的提高. 为了更直观地展现出 7 组实验的分类结果及变化情况, 将实验所得的分类准确率制成分类结果变化图, 见图 3.

表 2 多次扩维后的分类准确率 %

实验 标号	扩维的次数										
	0	1	2	3	4	5	6	7	8	9	10
A1	84.3	88.4	88.7	87.5	90.3	89.8	89.8	87.9	86.5	85.6	85.7
A2	85.8	87.9	88.3	89.6	91.5	90.7	90.3	89.4	87.6	86.8	86.5
A3	87.5	88.7	90.3	89.7	92.9	91.9	91.2	88.8	89.7	88.5	87.5
A4	79.4	82.0	82.9	83.5	85.7	84.9	84.0	83.7	82.7	82.5	81.9
A5	88.9	91.3	91.7	91.3	94.4	94.4	93.1	92.5	93.1	91.7	92.3
A6	82.4	85.3	86.5	88.4	88.4	87.8	86.4	86.3	85.7	84.5	84.5
A7	83.7	86.9	86.5	86.9	88.6	89.5	87.3	86.7	86.5	86.3	86.7
均值	84.4	87.8	88.3	88.5	90.2	89.9	89.1	88.8	88.3	87.5	86.8
时间	2.2	2.7	3.3	3.9	4.2	4.7	4.6	4.9	5.2	5.7	6.6

对比图 3 中多组实验的分类结果变化情况发现, 随着通道扩维次数的增加, 分类准确率会有一定的提高, 当达到一定次数后, 准确率不再提高, 再继续扩维, 大多数的实验准确率均会降低. 不同组实验中分类准确率最好的情况所对应的扩维次数不相同, 但大多数情况下, 扩维 4 次或 5 次时准确率达到最高. 多次扩维后的平均最高分类准确率较未扩维前提高了 5.8%(84.4%~90.2%), 完成分类所用的时间一般会随着扩维次数的增高而增加.

6 结束语

本文采用通道扩维算法与 FastICA 算法相融合的方法进行运动想象脑电信号的识别. 通过实验可知, 通道扩维算法在增加了一定量耗时的情




图3 多次扩维分类结果变化图

况下,提高了分类准确率.在扩维次数适当的情况下,多次扩维算法的分类效果比单次扩维更好,但所耗时间也更长.考虑到 FastICA 算法较传统的时频分析法已经节省了大量的时间,通道扩维算法对时耗的影响可以适当忽略.在采集电极数较少的情况下,通道扩维算法可以提供更多的通道,提高分类的准确率,将其与信息处理速度较快的 FastICA 算法相结合,可以弥补两种算法在实用性方面的缺陷.

参考文献:

- [1] Emily B J Coffey, Anne-Marie Brouwer, Ellen S Wilschut, et al. Brain-machine interfaces in space: Using spontaneous rather than intentionally generated brain signal [J]. *Acta Astronautica*, 2010, 67(1-2):1-11.
- [2] Wolpaw J R, Birbaumer N, Cfarland D J, et al. Brain-computer interfaces for communication and control [J]. *Clinical Neurophysiology*, 2002, 113(6):767-791.
- [3] Lotte F, Guan C. Regularizing common spatial patterns to improve BCI designs: unified theory and new algorithms[J]. *IEEE Trans Biomed Eng*, 2011, 58(2):355-362
- [4] 王月茹,李昕,李红红,等.基于时-频-空间域的运动想象脑电信号特征提取方法研究[J].*生物医学工程学杂志*,2014,31(5):955-961.

- [5] Rao R, Scherer R. Brain-computer interfacing[J]. *International Journal of Electronics and Computer Science Engineering*, 2010, 27(4):692-702.
- [6] Makeig S, Kothe C, Mullen TK. Evolving signal processing for brain-computer interfaces[J]. *Evolving Signal Processing for Brain-Computer Interfaces*, 2012(100):1567-1583
- [7] 吴延海,梁文莉.基于 Gabor 小波变换的 ICA 人脸识别算法研究[J].*微电子学与计算机*, 2013, 30(7):141-144.
- [8] 杨福生,洪波.独立分量分析的原理与应用[M].北京:清华大学出版社,2006.
- [9] Chuang CH, Lin YP, Ko LW. Automatic design for independent component analysis based brain-computer interfacing[C]// *Proceedings of the 35th Annual International Conference of the IEEE EMBS Osaka, Japan; IEEE*, 2013:2180-2183
- [10] Delorme A, Palmer J, Onton J. Independent EEG sources are dipolar [J]. *PLoS One*, 2012, 7(2):30-135
- [11] 吴小培,周蚌艳,张磊,等.运动想象脑-机接口中的 ICA 滤波器设计[J].*生物物理学报*, 2014, 30(7):540-554.
- [12] 曾勃炜,徐知海,吴键.基于粒子群优化和支持向量机的电力负荷预测[J].*微电子学与计算机*, 2011, 28(1):147-149.
- [13] 刘冲,赵海滨,李春胜,等.脑电信号频带能量特征的提取方法及分类研究[J].*系统仿真学报*, 2012, 24(12):2496-2499.

作者简介:

翟克文 男,(1990-),研究生.专业军事通信学.研究方向为武警通信. E-mail:3063911235@qq.com

刘建平 男,(1967-),博士,教授,博士研究生导师.研究方向为信号处理、脑机接口等.

司昕路 女,(1981-),工程师.研究方向为机电工程及自动化.