DOI: 10.3901/JME.2019.11.131

复合肢体想象动作脑-机接口中黎曼核支持 向量机递归特征筛选方法*

陶学文 奕伟波 陈龙 何峰 綦宏志
(天津大学精密仪器与光电子工程学院 天津 300072)

摘要: 相对于传统的想象动作脑-机接口, 复合肢体想象动作脑-机接口有效提升了指令复杂度, 具有更好的中风后康复治疗潜力, 但当前较低的识别精度限制了其临床应用。为提升复合肢体想象动作相关脑电信号特征的特异性并降低不同通道间的信息混淆, 提出了一种基于脑电流形特征信息刻划的黎曼核支持向量机递归特征筛选方法(Riemann kernel support vector machine recursive feature elimination, RKSVM-RFE)。采集了 10 位被试在进行想象 7 种不同肢体部位动作时的脑电信号数据, 利用 RKSVM-RFE 方法进行特征优化和建模, 对脑电数据对应的运动意图进行识别。结果显示, 基于所提方法的平均识别正确率达到了 77%, 相比于经典的 CSP 方法提高了近 7%, 并且能够消减近 50% 的脑电信息采集通道, 可有效降低系统复杂性。研究结果为基于想象动作脑-机接口的康复技术发展提供了新的思路, 值得进一步发展。

关键词: 运动想象; 脑-机接口; 流形; 特征筛选; 支持向量机

中图分类号: R318

Riemann Kernel Support Vector Machine Recursive Feature Elimination in the Field of Compound Limb Motor Imagery BCI

TAO Xuewen YI Weibo CHEN Long HE Feng QI Hongzhi

(School of Precision Instruments and Optoelectronics Engineering, Tianjin University, Tianjin 300072)

Abstract: Compound limb motor imagery brain-computer interface (CLMI-BCI) has better rehabilitative potential after stroke than traditional motor imagery brain-computer interface (MI-BCI), because of its high complexity of instructions. However, its ability of using for clinical is limited due to the low recognition accuracy. To solve this problem, a new method named Riemann kernel support vector machine recursive feature elimination (RKSVM-RFE) is proposed based on the manifold information on electroencephalogram (EEG). The EEG data of 10 subjects are collected when they were imagining 7-class movements of different parts of the body. The data is modeled using RKSVM-RFE to recognize the motor intention corresponding to the EEG data. Results show that accuracy from our method is about 7% higher than the state-of-the-art method named CSP. And RKSVM-RFE can reduce complexity of system because it can decrease 50% EEG channels. The research provides a new idea about the development of rehabilitation technology based on MI-BCI, which is worthy of further development.

Key words: motor imagery; BCI; manifold; feature selection; SVM

0 前言

脑-机接口(Brain computer interface, BCI)是一种可以将脑电信号转化为智能输出的系统^[1]。在众多脑-机接口的范式中, 基于运动想象(Motor imagery, MI)的脑-机接口最能反映人的自主意识, 它由于可以直接利用主动思维意识驱动外设而被称为主动式

BCI。近期研究表明, 这种通过 BCI 系统使患者可以利用解码运动意识驱动受损运动系统重新工作的康复治疗方法, 能起到促进大脑可塑性和诱导神经重塑的作用, 从而帮助中风患者恢复运动功能。且相比于传统的由康复师或康复机械被动牵引而没有主动意识加入的被动式中风康复方法, 主动式的 MI-BCI 具有更优的治疗效果^[2-4]。

MI-BCI 的工作原理是通过解码由想象身体不同部位运动所引发的感觉运动皮层脑电信号特征, 然后转化为指令来控制外设^[5-6]。神经生理学研

* 国家自然科学基金资助项目(91648122)。20180917 收到初稿, 20181126 收到修改稿

$W = \sum \alpha_i y_i \mathbf{x}_i$ 。假设 $\mathbf{x}_i$ 含有 K 个特征, 每个特征对于分类的贡献则可以通过删除该特征造成的分类间隔的变动大小来衡量

$$dJ = |W(\mathbf{x}, y) - W(\mathbf{x}^{-j}, y^{-j})| \quad (2)$$

SVM-RFE 通过递归迭代的方式逐次删除分类贡献低的特征, 完成对于所有特征按照分类贡献度大小的排序。在脑电特征删选上, 则可以通过 SVM-RFE 对单个脑电特征, 或者脑电信号采集通道进行排序^[11]。

1.4 单试次脑电信号在黎曼空间内的表示与距离

假设单试次脑电数据表示为 $\mathbf{V} \in \mathbf{R}^{l \times t}$, l 为导联个数, t 为采样点数, 则可定义单试次数据的样本互协方差矩阵(Sample covariance matrix, SCM)为

$$\mathbf{C}_i = \frac{\mathbf{V}_i \mathbf{V}_i^T}{\text{trace}(\mathbf{V}_i \mathbf{V}_i^T)} \quad (3)$$

易得式(3)中 $\mathbf{C}_i$ 为对称正定矩阵(Symmetric and positive definite, SPD)。由此, 单试次脑电数据就可以用一个 SPD 作为表征。

图 2 为黎曼空间的一些基本组成元素。在黎曼空间中, M 是一个曲面, 称之为流形, 在欧式空间中, 一个点的表示采用矢量的形式, 而在流形中, 一个点采用一个 SPD 来表示。所以单试次运动想象信号的互协方差矩阵可以对应为流形 M 上的一个点。 $\mathbf{C}$ 和 $\mathbf{C}_i$ 的黎曼距离定义为两者在 M 上的曲线距离, 也称测地线距离。图 2 中的 TcM 为以点 $\mathbf{C}$ 为基准的切空间, 黎曼空间上的所有点都可以映射到该切空间, 映射过程如图 2 中的 $\mathbf{C}_i$ 和 $\mathbf{S}_i$, 映射公式为

$$\mathbf{S}_i = \text{Log}_{\mathbf{C}}(\mathbf{C}_i) = \mathbf{C}^{1/2} \log(\mathbf{C}^{-1/2} \mathbf{C}_i \mathbf{C}^{-1/2}) \mathbf{C}^{1/2} \quad (4)$$

式中, $\log(\bullet)$ 计算过程: 若矩阵 $\mathbf{A} = \mathbf{V} \mathbf{D} \mathbf{V}^{-1}$, 则 $\log(\mathbf{A}) = \mathbf{V} \mathbf{D}' \mathbf{V}^{-1}$, 其中 $\mathbf{D}$ 为对角矩阵, $\mathbf{D}' = \lg(\mathbf{D})$ (即对 $\mathbf{D}$ 中对角线上的非零元素求对数)^[20], $\text{Log}_{\mathbf{C}}(\mathbf{C}_i)$ 表示 $\mathbf{C}_i$ 到 $\mathbf{C}$ 的映射。黎曼空间的切空间为欧式空间, 此时两点的欧式距离就包含了原始黎曼空间的矩阵之间的黎曼距离的信息。

图 2 黎曼空间

因此由式(4)与内积的知识可定义黎曼切空间中的矢量内积为

$$\langle \mathbf{S}_1, \mathbf{S}_2 \rangle_{\mathbf{C}} = \text{trace}(\mathbf{S}_1 \mathbf{C}^{-1} \mathbf{S}_2 \mathbf{C}^{-1}) \quad (5)$$

这样, 我们可以用互协方差矩阵来表示单试次脑电信号, 并定义出两个单试次脑电信号在黎曼空间中的内积。

1.5 黎曼核支持向量机及 RKSVM-RFE

在切空间内, 从原始黎曼空间映射过来的点都能保留对称正定矩阵之间黎曼距离的信息, 而对称正定矩阵又与原始的单次脑电数据的互协方差矩阵一一对应。于是可以利用第 1.3 节中 SVM 核函数的形式将原始空间的脑电数据映射到黎曼流形的切空间中, 相当于间接提取了脑电数据的流形特征, 可以称之为黎曼核支持向量机算法(Riemann kernel SVM, RKSVM)。核函数的具体表征如下。

结合式(5)中的映射关系和式(2)可得

$$K_R(\mathbf{C}_i, \mathbf{C}_j; \mathbf{C}_{ref}) = \langle \varphi(\mathbf{C}_i), \varphi(\mathbf{C}_j) \rangle =$$

$$\langle \text{Log}_{\mathbf{C}_{ref}}(\mathbf{C}_i), \text{Log}_{\mathbf{C}_{ref}}(\mathbf{C}_j) \rangle_{\mathbf{C}_{ref}} =$$

$$\text{trace}[\log(\mathbf{C}_{ref}^{-1/2} \mathbf{C}_i \mathbf{C}_{ref}^{-1/2}) \log(\mathbf{C}_{ref}^{-1/2} \mathbf{C}_j \mathbf{C}_{ref}^{-1/2})] \quad (6)$$

式中, $\mathbf{C}_{ref}$ 称为参考矩阵, 表示此时的切空间是以该点作为基准(图 2 中的 $\mathbf{C}$ 点)。本文一共采用了 3 种参考矩阵, 分别是单位矩阵 $\mathbf{I}$, 样本互协方差矩阵的欧式平均 $\mathbf{C}_m$, 样本互协方差矩阵的黎曼几何平均 $\mathbf{C}_{rm}$ 。后两者定义如下

$$\mathbf{C}_m = \frac{1}{N} \sum_{i=1}^N \mathbf{C}_i$$

$$\mathbf{C}_{rm} = \argmin_{\mathbf{C}} \sum_{i=1}^N \delta_R^2(\mathbf{C}, \mathbf{C}_i) \quad (7)$$

式中, $\delta_R(\mathbf{C}, \mathbf{C}_i)$ 表示黎曼空间中两点的黎曼距离, 根据信息几何中的定义^[13], 黎曼距离为

$$\delta_R(\mathbf{C}_1, \mathbf{C}_2) = \|\text{Log}(\mathbf{C}_1^{-1} \mathbf{C}_2)\|_F = \left[\sum_{i=1}^E \lg^2 \lambda_i \right]^{1/2} \quad (8)$$

式中, λ_i 为 $\mathbf{C}_1^{-1} \mathbf{C}_2$ 特征分解后的实特征值, $\text{Log}(\bullet)$ 为一种矩阵运算^[13]。为了在黎曼核这种非线性核且多分类情况下将 RFE 用于导联筛选, 需要对第 1.3 节中的基本 RFE 算法进行扩展。本文中使用导联的移除对已训练的 RKSVM 的代价函数值的影响进行导联重要程度的排序。首先, 由支持向量机的优化过程^[19], 可表示 RKSVM 的代价函数为

$$L = \frac{1}{2} \bar{\alpha}^T \mathbf{H} \bar{\alpha} - \sum_i \alpha_i \quad (9)$$

式中, $\mathbf{H} = y_i y_j K(\mathbf{C}_i, \mathbf{C}_j; \mathbf{C}_{ref})$, K 为(6)式中的黎曼

核函数, α 为拉格朗日系数。衡量某个导联移除之后对代价函数的变化时, 可保持拉格朗日系数不变, 重新计算移除该导联之后的 H , 即需要重新计算核函数 $K(C_i(-n), C_j(-n); C_{ref})$ 和 $H(-n)$, $(-n)$ 表示移除第 n 个导联。由此, 可定义导联的序贯指数(重要性程度)为

$$J_i = \frac{1}{2} \bar{\alpha}^T H \bar{\alpha} - \frac{1}{2} \bar{\alpha}^T H(-i) \bar{\alpha} \quad (10)$$

对于多分类情况, 需要训练出 m (类别个数)个一对多(One vs rest, OVR)的 RKSVM 分类器, 计算结果如下。

假设训练样本集和类别标识为 $X=[x_1, x_2, \dots, x_k]^T$ $Y=[y_1, y_2, \dots, y_k]^T$ 初始导联序号列表为 $s=[1, 2, \dots, n]$, 特征序贯列表 $r=[]$, 对训练样本的导联数 $X=X(:, s)$; 训练 7 个一对多 RKSVM 分类器 $\alpha_i = \text{SVM-Train}(X, Y)$ ($i=1, 2, \dots, 7$)。

计算 7 种类别序贯指数并求平方和

$$U_i = \sum (1/2 \bar{\alpha}_i H \bar{\alpha}_i - 1/2 \bar{\alpha}_i H(-i) \bar{\alpha}_i)^2 \quad (11)$$

寻找最小的 U_i 对应的导联 $f = \text{argmin}(U_i)$ 更新列表 $r = [s(f), r]$, 在导联序号中去掉最小序贯指数的维度; 最后循环直至遍历所有导联。

1.6 多类共空间模式方法

本文将目前多指令 MI-BCI 识别效果最佳的多类共空间模式方法(Multi class common spatial pattern, MCCSP)^[8]作为 RKSVM-RFE 算法的对比, 以验证本文方法的有效性。CSP 主要的设计思路是找到一组最优的空间滤波器使得滤波之后的两类数据方差差距最大, 所以原始的 CSP 算法是一个二分类算法, MCCSP 一般采用一对多的策略扩展至多分类, 具体过程如下。

由前可得所有类别的互协方差矩阵之和 $C = C_1 + C_{1r}$, 对 C 做特征值分解并对特征矢量矩阵做白化可得 $P = A^{-1/2} U_0^T$, U_0^T 为特征矢量矩阵, A 为特征值的对角矩阵。接着对 C_1 、 C_{1r} 进行白化得 S_1 、 S_{1r} 再将其特征分解得到特征矢量矩阵 B , 可得最终的滤波器为 $W_{1r} = B^T P$ 。

7 种类别则需要计算得到 7 个一对多滤波器, 最后的特征矢量 f 可表示为

$$f = (f_1, f_2, f_3, f_4, f_5, f_6, f_7) \\ f_i = \ln \left(\frac{\text{var}(W_{ir} X)}{\sum_{i=1}^7 \text{var}(W_{ir} X)} \right) \quad (12)$$

参照文献[8], 本文采用线性 SVM 对特征矢量 f 进行识别, 识别率的评估采用十折交叉验证。

2 结果与分析

本文先后共采用了 MCCSP 与三种参考矩阵的 RKSVM 总共四种算法, 表 1 是四种方法分别对应的 10 位被试 7 种想象动作的识别正确率。

表 1 复合运动想象识别正确率(%)

被试	MCCSP	RSR(I)	RSR(C_m)	RSR(C_{rm})
S1	70.82	78.59	80.40	80.03
S2	81.97	83.39	85.53	76.61
S3	63.14	72.32	76.43	76.61
S4	64.28	68.21	68.75	68.93
S5	67.85	63.21	66.78	66.25
S6	74.11	78.57	79.63	80.36
S7	71.61	82.14	83.57	83.93
S8	68.93	71.07	75.89	75.53
S9	71.96	75.54	80.36	80.18
S10	66.25	71.78	73.21	73.57
平均	70.07	74.48	77.06	76.20
标准差	5.40	6.35	6.09	5.45
p 值	—	0.005	0.0002	0.004

为了便于比较, RKSVM-RFE 算法的识别率评估也都采用 10 折交叉验证的方法。表 2 最后一行给出了配对 t 检验下 MCCSP 识别率和 RKSVM-RFE 算法的识别率的对比结果。可以看出, 采用三种 RKSVM-RFE 的方法结果都要显著优于传统 MCCSP, 其中采用样本互协方差矩阵的欧式平均作为参考矩阵达到了几种方法的最高正确率 77.06%, 比 MCCSP 方法的 70.07% 高将近 7%。且在 MCCSP 的结果中, 识别正确率超过 80% 的被试仅有一位, 而在 RKSVM-RFE 中, 以 C_m 与 C_{rm} 作为 C_{ref} 的方法都有 4 位被试达到了 80% 以上。这样的准确率已经接近很多研究中左右手二分类的情况, 所以这一结果也为复合动作的 MI-BCI 走向实际应用增加了可能性。RSR 为 RKSVM-RFE 的缩写。

图 3 给出了以样本互协方差矩阵的欧式平均 (C_m) 作为参考矩阵的 RKSVM-RFE 方法的识别率混淆矩阵, 从图中可以看出该方法对于有无动作的分类, 也即对于静息态的识别准确率较高, 几乎不会有误触发的情况; 从相似动作如左手右脚与左手、双手的识别情况来看, 只有少数样本的识别结果会混淆, 平均水平下只有 7% 的左手右脚样本被错误识别为左手, 5% 被错误识别为双手, 这是一个可以接受的错误率, 说明了此方法在对处理相似动作任务的信息混叠方面具有较好的效果。

图 3 所有被试平均与两位典型被试的 7 种动作识别正确率的混淆矩阵

图 4 给出了三种不同参考矩阵的 RKSVM-RFE 导联筛选结果图，图中曲线上的点代表采用重要性前 n 的导联进行 RKSVM 识别时的识别率。图中可见，随着用于识别的导联数量的增加，识别率呈现出先上升后下降的趋势。如采用所有导联进行识别，识别率较最高识别率有明显的降低，因此，可以按照 RFE 算法取拐点处导联组合获得最优识别率，此时平均只需要 54.7%(35/64)的导联数量。这意味着采用 RKSVM-RFE 方法不但可以获取更好的识

别效果，还可以消减一半左右的脑电采集通道，这对于简化系统，提高系统的稳定性，甚至发展便携式 MI-BCI 都具有重要的意义。由图 4 中可以看出，当采用 C_m 与 C_{rm} 作为参考矩阵时，识别率随着导联组合的变化几乎相同，且都优于以单位矩阵作为参考的情况。我们分析这里的主要原因是这两种矩阵都在黎曼空间中充分利用了训练样本分布的信息，而单位矩阵没有包含任何与样本分布有关的信息。

图 4 所有被试平均和两位典型被试的导联筛选结果图(三条曲线分别代表不同参考矩阵的 RKSVM-RFE 算法)

表 2 中列出了通过 RKSVM-RFE 筛选出来两名典型被试和所有被试平均的重要性程度排名靠前的 10 个脑电导联的名称，并将靠近感觉运动皮层的导联用加粗的形式做了标记。可以看出在筛选过后的排序表中，运动区附近的导联占比都很高，在所有

被试平均情况下，仅有两个导联不在感觉运动区的位置上。图 5 给出了所有被试平均的导联对分类重要程度的脑地形图，图中数值越大代表重要性程度高的导联区域，反之，数值越小代表重要性程度越低的区域。从中也可以看出，重要的导联主要分布在头部中央部位，在生理上这个位置对应于大脑感觉运动区，主要负责人类肢体感觉和运动。这个结果表明 RKSVM-RFE 对复合肢体想象动作脑电识别所筛选出的特征导联，是具有一定的神经生理学对应意义的。

表 2 导联排序表			
顺序	S1	S2	平均
1	C1	FC6	O2
2	CP3	CPZ	C3
3	FCZ	C4	CPZ
4	CZ	FC2	C1
5	P1	O2	CZ
6	C3	C3	C5
7	PO5	P5	P5
8	FC4	C5	CP1
9	O2	C2	C2
10	FPZ	PO5	C4

图 5 平均重要程度脑地形图

3 结论

本文将黎曼核 SVM 算法引入复合肢体动作脑电识别中,并结合 SVM-RFE 的框架,发展出了一种新型的复合想象动作脑电识别的 RKSVM-RFE 算法。该算法可以优化脑电信息通道的特异性,进而提高了对于复合肢体想象动作脑电识别的正确率,并能够大量减少脑电通道数目,有助于系统简化和稳定,对基于脑电识别的 MI-BCI 神经康复机器人技术的发展具有一定的价值。本文研究也表明基于信息几何框架的黎曼核方法对基于脑电识别的大脑功能状态检测技术具有很好的潜力,值得进一步深入研究。

参 考 文 献

- [1] 陈树耿,贾杰. 脑机接口在脑卒中手功能康复中的应用进展[J]. 中国康复理论与实践, 2017, 23(1): 23-26.
- CHEN Shugeng, JIA Jie. Application of brain-computer interface in rehabilitation of hand function after stroke (review)[J]. Chinese Journal of Rehabilitation Theory and Practice, 2017, 23(1): 23-26.
- [2] DALY J J, WOLPAW J R. Brain-computer interfaces in neurological rehabilitation[J]. Lancet Neurol, 2008, 7(11): 1032-1043.
- [3] KIM S P, SIMERAL J D, HOCHBERG L R, et al. Neural control of computer cursor velocity by decoding motor cortical spiking activity in humans with tetraplegia[J]. J. Neural Eng., 2008, 5(4): 455-476.
- [4] BIRBAUMER N, WEBER C, NEUPER C, et al. Physiological regulation of thinking: Brain-computer interface (BCI) research[J]. Prog. Brain Res., 2006, 159: 369-391.
- [5] JOHNSON S H. Imagining the impossible: Intact motor representations in hemiplegics[J]. Neuroreport, 2000, 11(4): 729-732.
- [6] JOHNSON S H, SPREHN G, SAYKIN A J. Intact motor imagery in chronic upper limb hemiplegics: Evidence for activity-independent action representations[J]. J. Cogn. Neurosci., 2002, 14(6): 841-852.
- [7] ANG K K, CHUA K S, PHUA K S, et al. A randomized controlled trial of EEG-based motor imagery brain-computer interface robotic rehabilitation for stroke[J]. Clin. EEG Neurosci., 2015, 46(4): 310-320.
- [8] 奕伟波. 复合运动想象诱发下的脑电响应机制与解码技术研究[D]. 天津: 天津大学, 2017.
- YI Weibo. Research on response mechanism and decoding technology of EEG induced by compound motor imagery[D]. Tianjin: Tianjin University, 2017.
- [9] CHATTERJEE R, BANDYOPADHYAY T. EEG based motor imagery classification using SVM and MLP[C]// International Conference on Computational Intelligence and Networks. 23-25 Dec. 2016. THDC Institute of Hydropower Engg and Technology, Bhagirathipuram, Tehri, India. IEEE, 2016: 84-89.
- [10] LI D, ZHANG H, KHAN M S, et al. Recognition of motor imagery tasks for BCI using CSP and chaotic PSO twin SVM[J]. The Journal of China Universities of Posts and Telecommunications, 2017, 24(3): 83-90.
- [11] ARVANEH M, GUAN C, ANG K K, et al. Optimizing the channel selection and classification accuracy in EEG-based BCI[J]. IEEE Trans. Biomed. Eng., 2011, 58(6): 1865-1873.
- [12] ALOTAIBY T, EL-SAMIE F E A, ALSHEBEILI S A, et al. A review of channel selection algorithms for EEG signal processing[J]. Eurasip Journal on Advances in Signal Processing, 2015(1): 1-21.
- [13] ALEXANDRE B, STÉPHANE B, MARCO C, et al. Multiclass brain-computer interface classification by riemannian geometry[J]. IEEE Transactions on Biomedical Engineering, 2012, 59(4): 920-928.
- [14] BARACHANT A, BONNET S, CONGEDO M, et al. Classification of covariance matrices using a Riemannian-based kernel for BCI applications[J]. Neurocomputing, 2013, 112(10): 172-178.
- [15] CONGEDO M, BARACHANT A, KOOPAEI E K. Fixed point algorithms for estimating power means of positive definite matrices[J]. IEEE Transactions on Signal Processing, 2017, 65(9): 2211-2220.
- [16] RAMOSER H, MULLER-GERKING J, PFURTSCHER G. Optimal spatial filtering of single trial EEG during imagined hand movement[J]. IEEE Trans. Rehabil. Eng., 2000, 8(4): 441-446.
- [17] MA Y, DING X, SHE Q, et al. Classification of motor imagery EEG signals with support vector machines and particle swarm optimization[J]. Computational and Mathematical Methods in Medicine, 2016, 1(10): 1-8.
- [18] GUYON I, WESTON J, BARNHILL S, et al. Gene selection for cancer classification using support vector machines[J]. Machine Learning, 2002, 46(1-3): 389-422.
- [19] LAL T N, SCHRODER M, HINTERBERGER T, et al. Support vector channel selection in BCI[J]. IEEE Trans. Biomed. Eng., 2004, 51(6): 1003-1010.
- [20] GIBLIN P. A panoramic view of riemannian geometry by marcel berger[J]. Mathematical Intelligencer, 2006, 28(2): 73-74.

作者简介：陶学文，男，1995 年出生。主要研究方向为脑-机接口与模式识别。

E-mail: taoxuewen@tju.edu.cn

奕伟波，男，1987 年出生，工程师。主要研究方向为脑-机接口、运动想象、脑力负荷等。

E-mail: yiweibo1987@163.com

陈龙，男，1988 年出生，博士研究生。主要研究方向为神经康复与脑-

机接口。

E-mail: cagor@tju.edu.cn

何峰，男，1971 年出生，博士，副教授。主要研究方向为生物医学信号检测与处理、嵌入式医学仪器开发。

E-mail: heaven@tju.edu.cn

綦宏志(通信作者)，男，1975 年出生，博士，副教授。主要研究方向为生物医学信号处理、模式识别与脑-机接口。

E-mail: qhz@tju.edu.cn