doi:10.3772/j.issn.1002-0470.2023.07.002

## 基于独立分量分析和普鲁克分析的运动想象迁移学习策略①

毛传波② 杨庆华 蔡世波 王志恒③

(浙江工业大学特种装备制造与先进加工技术教育部/浙江省重点实验室 杭州 310023)

摘要 针对传统上基于运动想象的脑机接口系统在应用之前需要进行枯燥冗长的校准 实验的问题,提出基于独立分量分析(ICA)和普鲁克分析的迁移学习算法。该算法采用 独立分量分析对脑电信号进行空间滤波,对比应用多种对齐变换方法,实现对样本数据的 平移和缩放。并提出欧氏空间下的旋转变换方法,以进一步匹配目标受试者与其他受试 者的样本分布,实现有效的跨受试者和跨数据集的迁移学习。所提算法相较基于黎曼普 鲁克分析的方法具有更好的分类性能以及计算效率,并在公共数据集 PhysionetMI 和 BCI-IV-2a 上较传统机器学习算法将平均 kappa 值提高了约 0.1 和 0.04。结果表明该方法能 有效提高小样本下的分类正确率,这有助于降低对校准数据量的需求,从而减少校准实验 的耗时。

关键词 运动想象;脑机接口;独立分量分析(ICA);普鲁克分析;迁移学习

## 0 引言

脑机接口是一项通过解码人类大脑皮层产生的脑电信号去识别人的意图,从而产生控制信号驱动外部设备的技术。运动想象是其主要范式之一,它是基于人在进行不同肢体运动的想象时,脑电信号会在特定频段产生不同的事件相关去同步(event-related desynchronization, ERD)和事件相关同步(event-related synchronization, ERS)现象<sup>[1-3]</sup>。通过对受试者进行一定时间的训练,采集其进行运动想象时的脑电数据,根据这些数据分析其 ERD/ERS模式,得到该受试者特定的分类模型,接着就可以依靠该模型对后续的运动想象事件进行分类识别<sup>[4]</sup>。

目前运动想象均是基于机器学习技术。传统的 机器学习模型一般是基于 2 个假设:(1)测试集和 训练集相互独立并且是同分布的;(2)有足量的已 标注数据。然而由于脑电信号微弱且变化大,每次 实验的环境、电极位置等因素也无法保证完全一致, 导致同一个受试者在不同时间的实验数据差异巨 大,这违反了假设(1),因此在传统机器学习框架下 受试者过去采集的数据不可用。为了收集足量可用 的标注数据,传统上在每次实验之前都需要先进行 约 30 min 的校准实验<sup>[5]</sup>,即使是经验丰富的受试者 也是如此。这个过程耗时又枯燥,无论对科研实验 还是应用推广都是不小的阻碍。

为了减少校准实验的耗时,迁移学习技术被引 入到运动想象当中,主要包括跨时间和跨受试者 2 种形式。目标受试者过去的数据以及其他受试者的 数据所分布的领域称为源域,目标受试者的测试数 据所分布的领域称为目标域。迁移学习的理念是尽 量减小目标域和源域数据的分布差异,使得跨域分 类识别成为可能,从而降低对校准数据的需求量,减 短甚至取消校准实验的耗时。

目前已有不少学者相继提出他们的迁移学习方法,其中较为成功的包括 Zanini 等人<sup>[6]</sup>提出的黎曼

① 国家重点研发计划(2018YFE0125600,2019YFB1311401)和浙江省公益项目(LGG19E050023)资助。

② 男,1997年生,硕士生;研究方向:智能装备,机器人;E-mail: 173210540@qq. com。

③ 通信作者, E-mail: wzh232@zjut.edu.cn。 (收稿日期:2021-12-31)

空间对齐(Riemannian-space alignment, RA)方法和 He 等人<sup>[7]</sup>提出的欧氏空间对齐(Euclidean-space alignment, EA)方法。RA 算法首先求得一个参考矩 阵,用此参考矩阵对每一个实验数据的协方差矩阵 进行对齐变换,使得变换后的协方差矩阵的黎曼均 值为单位矩阵,这意味着源域和目标域的数据中心 得到重合,再配合使用最小黎曼距离(minimum distance to Riemannian mean, MDRM)分类器进行跨域 迁移识别。EA 算法同样需要先获得一个参考矩 阵,不同之处在于它被直接用于欧氏空间实验数据 的对齐,经对齐变换后仍可以使用在欧氏空间中性 能突出的共空间模式(common spatial pattern, CSP)<sup>[89]</sup> 特征提取方法和线性判别分析(linear discriminant analysis, LDA) 分类器。另外, Wang 等人<sup>[10]</sup> 和 Wu 等人<sup>[11]</sup>还提出了基于独立分量分析(independent component analysis, ICA) 的零训练分类方法,该方 法不依赖任何源域的数据,直接依靠对 ERD/ERS 模式的先验知识对测试数据进行分类。值得一提的 是,ICA 作为一种盲源分离技术,具有不需要数据标 签就可以获得良好空间滤波器的优势。上述方法都 属于无监督算法。为了更进一步匹配源域和目标 域,Rodrigues 等人<sup>[12]</sup>提出了黎曼普鲁克分析(Riemannian Procrustes analysis, RPA)算法,该算法在 RA 的基础上,利用目标域少量有标签数据,对目标 域所有数据在黎曼空间进行旋转变换,使得目标域 和源域各类中心更相近。

为了进一步提升迁移学习的分类正确率,本文 提出一种基于独立分量分析和普鲁克分析的方法。 首先,对每个受试者的脑电数据进行 ICA 空间滤 波,以提高信噪比。其次,依据普鲁克分析的思想, 对比应用多种对齐变换方法,实现对样本数据的平 移和缩放。并提出欧氏空间下的旋转变换方法,以 进一步匹配源域和目标域的数据分布。最后,将所 提算法与多种算法进行跨受试者和跨数据集的测试 对比,验证方法的有效性。

## 1 材料与方法

#### 1.1 数据集

为了有效对比验证各种算法的性能,采用具有 丰富受试者和多种运动想象类型的 PhysionetMI<sup>[13]</sup> 数据集和 BCI-IV-2a<sup>[14]</sup>数据集。其中 PhysionetMI 采用全部4 类想象动作的数据,而 BCI-IV-2a 仅采 用想象左手、右手和双脚3 类数据,以便于后续在该 数据集上进行跨数据集的对比测试。两数据集的具 体信息如表1 所示。

表1 数据集的详细信息

数据集	想象动作	受试者数量	通道数量	每类样本数量	采样频率/Hz	每个样本时长/s
PhysionetMI	左手/右手/双手/双脚	109	64	18 ~ 28	160	4
BCI-IV-2a	左手/右手/双脚	9	22	144	250	4

#### 1.2 独立分量分析

独立分量分析是一种盲源信号分离技术<sup>[15]</sup>,对 于*n*导脑电信号 $\mathbf{x} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n]^T$ ,可以看成由 *n*个独立源信号 $\mathbf{s} = [\mathbf{s}_1, \mathbf{s}_2, \dots, \mathbf{s}_n]^T$ 线性混叠而 成,即:

$$\boldsymbol{x} = \boldsymbol{A}\boldsymbol{s} \tag{1}$$

其中A为混合矩阵,对应的解混模型为

$$y = Wx \tag{2}$$

式中,  $y = [y_1, y_2, \dots, y_n]^T$ 为源信号 *s*的估计, *W* 为  $n \times n$ 的解混矩阵。*W*同时还可以看作空间滤波 矩阵,每一个行向量是一个空间滤波器,其元素值是 - 684 — 原始脑电信号 x 各通道信号的权重, y 则为经空间 滤波的信号,相比于原始脑电信号其各通道信号的 信噪比得到了提高。

解混矩阵 W 的估计算法主要有 Infomax、Jade、 Sobi和 Fastica,研究表明<sup>[16-17]</sup>在脑电信号处理领域 Infomax 算法效果最佳。但经 Infomax 算法解混得到 的源估计信号的顺序是不确定的,需要依赖人工去 筛选运动相关成分,同时计算成本高昂。Wu 等 人<sup>[11]</sup>提出的简化 Infomax 算法很好地解决了这些问 题。首先该算法的计算量小,推荐的迭代次数为 300次;更为重要的是,经测试由该算法得到的滤波 矩阵 W 的对角线元素的绝对值总是所在行最大的。 例如在第*i*行的所有元素中,第*i*个元素的绝对值是 最大的,这意味着  $x_i$  对  $y_i$  的贡献是最大的,因此可 以认为  $y_i$  是对应 *i* 通道的滤波信号,也就是说经该 算法得到的滤波信号的顺序与原信号是保持一致 的。

在应用简化的 Infomax 算法之前,首先对原始脑电数据进行 8~30 Hz 的 5 阶巴特沃斯带通滤波预处理,以去除肌电、基线漂移等干扰,仅保留感兴趣的 mu 频段<sup>[18]</sup>和 beta 频段<sup>[19]</sup>。然后将 k 个 n×l 的脑电数据首尾拼接成 n×k·l 的二维信号,其中 k 代表数据个数,n 代表通道数,l 代表每通道的信号 点数。利用拼接后数据应用简化的 Infomax 算法得 到滤波矩阵后,参数采用推荐的 0.02 步长和 300 迭 代次数,根据式(2)对原始脑电信号进行空间滤波。

#### 1.3 普鲁克分析

普鲁克分析是一种用来分析形状分布的统计方法,常用于人脸对齐<sup>[20-21]</sup>。普鲁克分析的工作原理 是首先从2个不同的形状分布中各选取一些特征 点,然后通过一些几何变换使得两边对应的特征点 尽可能靠近,从而达到让2个形状分布对齐的效果。

假设目标域和源域选取的特征点集分别为

$$\boldsymbol{M} = \{ \boldsymbol{m}_i \in \mathbb{R}^n \}_{i=1}^c \; \boldsymbol{\mathcal{M}} \; \boldsymbol{\tilde{M}} = \{ \boldsymbol{\tilde{m}}_i \in \mathbb{R}^n \}_{i=1}^c$$
(3)

并假设存在一个线性变换关系,使得 c 对的特征点 集都具有以下等式关系:

$$\boldsymbol{m}_i = \frac{1}{s} \boldsymbol{Q}(\tilde{\boldsymbol{m}}_i - \boldsymbol{a}) \tag{4}$$

其中, $a \in \mathbb{R}^n$ 代表对源域数据点的平移变换; $s \in \mathbb{R}$ 代表对源域数据点的缩放变换; $Q \in \mathbb{R}^{n \times n}$ 是一个正 交矩阵,代表对源域数据点的旋转变换。经过以上 变换后源域的特征点就和目标域的特征点重合,普 鲁克分析的目标就是求解a、s和Q。

依照普鲁克分析的思想,可以对运动想象脑电 数据做一定的平移、缩放和旋转变换,使得源域和目 标域数据的分布尽量接近,进而实现迁移分类识别。 根据需要标签与否将变换处理分为对齐变换和旋转 变换2个过程。对齐变换不需要样本的标签,本文 测试对比了通道归一化(channel normalization, CN)、欧氏空间对齐和黎曼空间对齐3种方法。旋转变换需要利用样本的标签,将源域每个受试者的数据向目标域旋转。

#### 1.4 对齐变换

1.4.1 通道归一化

对于平移和缩放变换最直观的做法就是归一化 处理,首先是对第*i*个数据的第*j*个通道提取方差的 对数作为特征:

$$f_{ij} = \log(\operatorname{var}(\boldsymbol{y}_{ij}))$$
(5)

其中 y<sub>ij</sub> 代表 ICA 滤波后第 *i* 个数据的第 *j* 个通道的脑电信号,接着对每一维特征零均值化:

$$f_{ij}^{(\text{zero})} = f_{ij} - \frac{1}{k} \sum_{i=1}^{k} f_{ij}$$
(6)

最后对每一维特征做归一化:

$$f_{ij}^{(CN)} = \frac{f_{ij}^{(zero)}}{\sqrt{\frac{1}{k} \sum_{i=1}^{k} (f_{ij}^{(zero)})^2}}$$
(7)

经过通道归一化处理后,每个受试者数据的每 一维特征都分布在零点附近,且与零点的平均距离 为1,这样源域和目标域就得到了对齐。

1.4.2 欧氏空间对齐

相对于通道归一化对每一维特征分别做平移和 缩放,欧氏空间对齐<sup>[7]</sup>方法则是直接对整个数据 *n* ×*l*个数据点做对齐变换。

首先计算样本数据的协方差矩阵:

$$\boldsymbol{R}_{i} = \frac{1}{l} \boldsymbol{y}_{i} \boldsymbol{y}_{i}^{\mathrm{T}}$$
(8)

其中 y<sub>i</sub> 代表 ICA 滤波后第 i 个数据点,T 代表矩阵转置。

然后求得平均协方差矩阵:

$$\boldsymbol{R} = \frac{1}{k} \sum_{i=1}^{k} \boldsymbol{R}_{i}$$
(9)

接着是对每个样本点做对齐变换:

$$\tilde{\mathbf{y}}_i = \overline{\mathbf{R}}^{-1/2} \mathbf{y}_i \tag{10}$$

经过欧式空间对齐变换后,所有数据点的平均 协方差矩阵为

$$\frac{1}{k} \sum_{i=1}^{k} \tilde{\boldsymbol{y}}_{i} \tilde{\boldsymbol{y}}_{i}^{\mathrm{T}} = \frac{1}{k} \sum_{i=1}^{k} \overline{\boldsymbol{R}}^{-1/2} \boldsymbol{y}_{i} \boldsymbol{y}_{i}^{\mathrm{T}} \overline{\boldsymbol{R}}^{-1/2}$$
$$= \overline{\boldsymbol{R}}^{-1/2} \left( \frac{1}{k} \sum_{i=1}^{k} \boldsymbol{y}_{i} \boldsymbol{y}_{i}^{\mathrm{T}} \right) \overline{\boldsymbol{R}}^{-1/2}$$
$$= \overline{\boldsymbol{R}}^{-1/2} \overline{\boldsymbol{R}} \overline{\boldsymbol{R}}^{-1/2} = \mathbf{I}$$
(11)
$$- 685 - \mathbf{I}$$

即所有受试者数据的平均协方差矩阵都是单位矩阵,源域和目标域得到了对齐。

同样地,提取对齐后数据方差的对数作为特征:

$$f_{ij}^{(\text{EA})} = \log(\operatorname{var}(\tilde{\mathbf{y}}_{ij}))$$
(12)

1.4.3 黎曼空间对齐

黎曼空间对齐<sup>[6]</sup>与欧氏空间对齐的区别在于 平均协方差矩阵的求解,EA 计算的是算术平均值, 而 RA 计算的是几何平均值。首先是协方差矩阵之 间黎曼距离的定义:

$$\delta(\mathbf{R}_{1},\mathbf{R}_{2}) = \| \log(R_{1}^{-1}R_{2}) \|_{F} = \left[ \sum_{r=1}^{n} \log^{2}\lambda_{r} \right]^{\frac{1}{2}}$$
(13)

其中,F 代表 Frobenius 范数,  $\lambda_r$ ( $r = 1, 2, \dots, n$ ) 是  $R_1^{-1}R_2$  的实特征值。则所有数据点的平均协方差矩 阵为

$$\overline{\boldsymbol{R}} = \arg\min_{\boldsymbol{R}} \sum_{i=1}^{k} \delta^{2}(\boldsymbol{R}, \boldsymbol{R}_{i})$$
(14)

式(14)的含义是寻找一个参考矩阵,它到所有数据

点的平均黎曼距离最小,这里采用 Matlab 的 covariance toolbox 进行计算求解。

得到参考矩阵后同样依照式(10)对数据点做 对齐变换,变换后所有协方差矩阵样本的黎曼均值 为单位矩阵,源域和目标域在黎曼空间得到了对齐。

最后提取特征:

$$f_{ij}^{(RA)} = \log(\operatorname{var}(\tilde{y}_{ij}))$$
(15)  
1.4.4 分组对齐

需要注意的是,不仅不同受试者之间数据分布 存在差异,同一个受试者不同组次之间的数据分布 也可能存在一定差异。例如 PhysionetMI 数据集的 受试者 S040,其样本数据经过通道归一化后,采用 t-SNE 降至二维,结果如图1(a)所示,同一组次的数 据具有明显的聚集性,不同组次间数据分布差异显 著。而如果以组次为单位分别做通道归一化,结果 如图1(b)所示,数据的分布将会均匀许多,本文将 这种处理方式称为分组对齐。



图 1 受试者 S040 整体对齐和分组对齐下数据分布

#### 1.5 旋转变换

经过上述对齐变换和特征提取,每个受试者数 据集合可以表示为

 $D = \{f_i \in \mathbb{R}^n | i = 1, \dots, k\}$ (16) 其中 $f_i$ 表示一个数据特征向量(包括 $f_i^{(CN)} \, \mathbf{x} f_i^{(EA)}$ 和  $f_i^{(RA)} 3$ 种对齐方法得到的特征向量)。假设第t个 受试者为目标受试者,用:

$$\boldsymbol{T} = \boldsymbol{D}_{t} \, \boldsymbol{\Re} \, \boldsymbol{S} = \bigcup_{h} \, \boldsymbol{D}_{h} \tag{17}$$

分别表示目标域和源域的样本集合。并假设目标域 部分样本的标签和源域所有样本的标签是已知的, 用 **T**<sub>1</sub> 表示目标域有标签的样本集合, **T**<sub>u</sub> 代表目标 - 686 -- 域没有标签的样本集合,那么 $T = T_1 \cup T_u$ 。分别对  $S 和 T_1$ 求得不同类别的类中心:

$$\widetilde{\boldsymbol{M}} = \{ \widetilde{\boldsymbol{m}}_i \in \mathbb{R}^n \}_{i=1}^c \; \boldsymbol{\mathcal{H}} \; \boldsymbol{M} = \{ \boldsymbol{m}_i \in \mathbb{R}^n \}_{i=1}^c$$
(18)

其中 $\tilde{M}$ 、 $M \in \mathbb{R}^{e^{xn}}$ 即是做普鲁克旋转变换所选取的特征点集。旋转变换的目标是求得一个正交矩阵Q,使得 $\tilde{M}$ 和M尽量接近,即,

 $min_{Q} \| M - \tilde{M}Q \|_{F}^{2}, s. t. QQ^{T} = I
 (19)
 这是一个正交普鲁克问题<sup>[20]</sup>,存在解析解,根据奇
 异值分解定理,可以得到:$ 

$$\boldsymbol{U}\boldsymbol{S}\boldsymbol{V}^{\mathrm{T}} = \boldsymbol{M}^{\mathrm{T}}\widetilde{\boldsymbol{M}}$$
(20)

那么所求旋转矩阵的解为

$$\boldsymbol{Q} = \boldsymbol{V}\boldsymbol{U}^{\mathrm{T}} \tag{21}$$

利用得到的旋转矩阵对集合 *S* 的数据点做旋转变换:

 $f_i^{(\text{PA})} = f_i Q, f_i \in S$ (22)

1.6 分类算法

根据对齐变换的算法选择不同,提出以下 3 种 迁移学习策略。

(1)算法1对ICA空间滤波后数据采用CN算法分组对齐,对源域每个受试者的数据做旋转变换,
 *T*<sub>1</sub>和*S*作为训练集,*T*<sub>u</sub>作为测试集,采用LDA分类器做迁移学习分类。

 (2)算法2对ICA空间滤波后数据采用EA算法分组对齐,对源域每个受试者的数据做旋转变换, *T*<sub>1</sub>和*S*作为训练集,*T*<sub>u</sub>作为测试集,采用LDA分类器做迁移学习分类。

 (3)算法3对ICA空间滤波后数据采用RA算法分组对齐,对源域每个受试者的数据做旋转变换, *T*<sub>1</sub>和*S*作为训练集,*T*<sub>u</sub>作为测试集,采用LDA分类器做迁移学习分类。

为了对比验证所提算法的有效性,对以下4种 算法的分类性能进行测试。

(1)基准算法1对ICA空间滤波后数据提取特征,T<sub>1</sub>作为训练集,T<sub>u</sub>作为测试集,采用最小距离分类器(训练集样本数量较少时采用LDA分类将产生奇异值)做传统机器学习分类。

(2)基准算法2对带通滤波后数据提取协方差 矩阵,*T*<sub>1</sub>作为训练集,T<sub>u</sub>作为测试集,采用 MDRM 分类器做传统机器学习分类。

(3) RA-MDRM 对带通滤波后数据提取协方差 矩阵,采用 RA 算法进行对齐,*S* 作为训练集,*T*<sub>u</sub> 作 为测试集,采用 MDRM 分类器做无监督迁移学习分 类。

(4) RPA-MDRM 对带通滤波后数据提取协方 差矩阵,采用 RPA 算法进行对齐变换, *T*<sub>1</sub>和 *S*作为 训练集, *T*<sub>u</sub>作为测试集,采用 MDRM 分类器做半监 督迁移学习分类。

#### 1.7 性能指标

针对多分类问题,采用 kappa 值作为性能指标:

$$k = \frac{p_0 - p_e}{1 - p_e} \tag{23}$$

其中, po 代表分类正确率, pe 代表随机概率。

## 2 结果与讨论

#### 2.1 跨受试者迁移学习

为了验证算法的有效性,采用留一法,对每个受 试者重复10次随机划分数据集,每类取N个样本 作为训练集,剩余样本作为测试集,所有其他受试者 的样本同样用作训练集。对于PhysionetMI数据集, 选取运动区FC5、FC3、FC1、FC2、FC2、FC4、FC6、C5、 C3、C1、Cz、C2、C4、C6、CP5、CP3、CP1、CPz、CP2、CP4 和CP6这21个通道对应的特征用于分类。需要注 意的是,该数据集在ICA空间滤波和普鲁克对齐变 换阶段都是使用全部64通道的数据。对于BCI-IV-2a数据集,使用全部22通道的特征用于分类。

在 PhysionetMI 上各种算法的平均 kappa 值结 果如表 2 所示,两两算法之间的 t 检验结果如图 2 所示。图中黑色方块代表所在行的算法显著优于所 在列的算法,白色方块代表无显著差异,显著性水平 为 0.05。可以看到,在已知样本量较小(N < 15)的 情况下,传统机器学习算法的分类性能较差,甚至劣 于无监督算法。所提出的 3 种算法在所有的 N 取 值下均显著优于其他 4 种算法,3 种算法之间的表 现差异不大,仅在 N = 5 时算法 3 相比算法 2 具有显 著性优势。从平均结果上看,算法 3 是最优的,在 N = 5、10 和 15 时,相比基准算法 1 提升了 0.09、0.11 和 0.11,相比 RA-MDRM 提升了 0.04、0.08 和0.09, 相比 RPA-MDRM 提升了 0.08、0.09 和 0.08。

在 BCI-IV-2a 上各种算法的平均 kappa 值结果 如表 3 所示。结果表明,算法 1 的表现较差,甚至低 于基准算法 1,算法 2 和算法 3 的分类结果相近,相 比其他算法具有明显提升。在已知样本量极少的情 况下( $N \leq 5$ ),无监督算法仍具有优势。RPA-MDRM 相比基准算法 2 也有一定程度的提升,证明基于黎 曼普鲁克分析的半监督算法确实能在小样本量下提 高分类性能。整体来看仍是算法 3 最优,在 N = 5、 10、15 和 20 时,相比基准算法 1 提升了 0.03、0.02、

		-						
N	基准算法1	基准算法 2	RA-MDRM	RPA-MDRM	算法1	算法2	算法 3	
5	0.17	0.19		0.18	0.25	0.25	0.26	
10	0.19	0.21	0.22	0.21	0.28	0.29	0.30	
15	0.20	0.22		0.23	0.31	0.31	0.31	

表 2 PhysionetMI 上各种算法跨受试者平均 kappa 值



图 2 PhysionetMI 上各种算法之间的 t 检验结果

表 3 BCI-IV-2a 上各种算法跨受试者平均 kappa 值

N	基准算法1	基准算法 2	RA-MDRM	RPA-MDRM	算法1	算法2	算法 3
5	0.36	0.31		0.37	0.33	0.38	0.39
10	0.41	0.37	0.29	0.41	0.38	0.44	0.43
15	0.43	0.39	0.38	0.42	0.40	0.46	0.47
20	0.44	0.42		0.43	0.42	0.47	0.48

0.04和0.04,相比 RA-MDRM 提升了0.01、0.05、
0.09和0.1,相比 RPA-MDRM 提升了 0.02、0.02、
0.05和0.05。

#### 2.2 跨数据集迁移学习

2.1 节结果证明了所提算法在跨受试者迁移学 习的有效性,但其应用前提条件是已有一定数量其 他受试者的样本数据,如能够利用其他数据集实施 迁移学习,将有效规避这个问题。为了测试各种算 法跨数据集迁移学习的表现,以具有大量受试者的 PhysionetMI 为训练集,BCI-IV-2a 为测试集。为了适 配 BCI-IV-2a,对 PhysionetMI 提取左手、右手和双脚 3 类样本数据,通道数也降至对应的 22 通道。结果 如表 4 所示,RA-MDRM 和所提出的 3 种算法与跨 受试者的结果相当,算法 3 整体上有略微的提升,证 明了所提算法跨数据集迁移学习的可行性。值得注 意的是,RPA-MDRM 算法在跨数据集的测试中具有 明显的提升,相比跨受试者的平均 kappa 值,在 *N* = 5、10、15 和 20 时分别提升了 0.04、0.06、0.07 和 — 688 — 0.08,整体上比算法3提升了0.02。

表4 BCI-IV-2a 上各种算法跨数据集平均 kappa 值

N	RA-MDRM	RPA-MDRM	算法1	算法2	算法3
5		0.41	0.33	0.38	0.40
10	0.27	0.47	0.38	0.44	0.45
15	0.57	0.49	0.42	0.45	0.47
20		0.51	0.44	0.46	0.49

图 3 给出了 N = 20 时各受试者的 kappa 值,可 以明显看到,各种算法的测试结果均与基准算法呈 正相关,说明每个受试者数据质量本身决定了可区 分性的上限,不同算法分类性能的优劣更多在于针 对不同受试者的泛化能力。例如无监督算法 RA-MDRM,其测试结果的随机性最高,对受试者 S5 具 有最好的表现,对受试者 S2 的结果却小于 0(分类 正确率低于随机值)。原因在于每个个体存在特殊 性,与所有个体的平均表现存在差异,无监督算法无 法应对这种差异。RPA-MDRM 与 RA-MDRM 的区 别在于多了一步旋转变换操作,它考虑了每个个体的特殊性,利用其少量有标签数据将该个体与其他 个体数据分布进一步旋转对齐,扩充了训练集,从而 得到较基准算法2更高的分类精度。算法3对每个 受试者的测试结果均优于基准算法1,展示出了良 好的泛化能力。

表 5 给出了 N = 20 时 RPA-MDRM 和算法 3 为 每个受试者训练模型及分类的平均耗时,测试环境 为 Matlab R2021a,硬件配置为 Intel(R) Core(TM) i7-11800H@2.30 GHz,2.30 GHz,16 GB RAM。从跨 受试者到跨数据集,随着训练集的扩大 2 种算法的 平均耗时均明显增大,而所提算法 3 的计算效率分 别是 RPA-MDRM 的 194 倍和 153 倍。究其原因,算 法 3 无论是旋转矩阵的求解或是 LDA 分类模型的 训练,其内部的数学过程都存在解析解,计算效率 高。相比之下基于黎曼框架的 RPA-MDRM 无论是 旋转矩阵的求解还是黎曼均值的计算都依赖于数值 计算方法,需要大量的迭代运算,计算成本高昂。



表 5 N = 20 时 RPA-MDRM 和算法 3 平均运算耗时

	跨受试者		跨数据集		
	RPA-MDRM	算法3	RPA-MDRM	算法3	
耗时/s	2.331	0.012	3.525	0.023	

对比所提的3种方法,它们的差别仅在于数据 的对齐变换环节,在计算成本上相差无几,而在分类 性能上算法1最差,算法3略优于算法2。也就是 说RA算法最优,EA算法次之,CN算法最差,这与 现有文献[22]的测试结果相符。分析其中的原因, CN算法将单个样本的数据按照不同的通道割裂开 来,每个通道提取频带能量作为特征单独考虑,忽视 了各通道信号之间的联系。虽然信号事先经过了 ICA空间滤波,但所采用的算法是简化的 Infomax 算 法,并不保证滤波后各通道信号之间完全的独立性, 仅仅是提高了信号的信噪比。而 EA 与 RA 算法是 对样本数据的协方差矩阵进行整体操作的, EA 保 证了对齐后所有数据的协方差矩阵算术平均值为单 位矩阵, RA 保证了对齐后所有数据的协方差矩阵 几何平均值为单位矩阵。对比发现, 3 种方法不是 对样本数据本身做对齐变换, 都是做了一定的降维 处理, 前者提取频带能量, 后者提取协方差矩阵。协 方差矩阵相比频带能量蕴含更丰富的信息, 其对角 线上元素是各个通道信号的方差, 这就相当于频带 能量, 而其他元素是不同通道信号之间的协方差, 这 蕴含了空间信息<sup>[23]</sup>, 也是 CN 算法所忽视的部分。 EA 和 RA 的作用原理是相似的, 只是前者是在欧氏 空间, 后者是在黎曼空间, 协方差矩阵作为对称正定 矩阵属于黎曼光滑流形<sup>[6]</sup>, 在黎曼空间上进行处理 更有优势。

— 689 —

## 3 结论

本文提出基于独立分量分析和普鲁克分析的运 动想象迁移学习策略,对运动想象信号应用独立分 量分析和对齐变换算法,得到经过初步对齐的特征 向量,将欧氏空间下的普鲁克分析引入脑电信号处 理领域,针对性设计了旋转变换策略以进一步匹配 源域和目标域,从而实现有效的迁移学习。所提出 的算法无论是在计算效率还是在分类性能上均优于 基于黎曼框架的迁移学习算法,在目标域已知标签 样本量较少的情况下相比传统机器学习具有显著提 高,这有助于降低对校准数据量的需求,从而有效减 少校准实验的耗时。并且在跨数据集的测试中保持 着良好的表现,显示其不对已有数据的依赖,这有利 于算法的推广应用。未来将继续探索将所提方法应 用于在线分类识别的可能。

#### 参考文献

- [ 1] PFURTSCHELLER G, NEUPER C, FLOTZINGER D, et al. EEG-based discrimination between imagination of right and left hand movement[J]. Electroencephalography and Clinical Neurophysiology, 1997,103(6):642-651.
- [2] PFURTSCHELLER G, LOPES F H. Event-related EEG/ MEG synchronization and desynchronization: basic principles [J]. Clinical Neurophysiology, 1999, 110 (11): 1842-1857.
- [3] PFURTSCHELLER G, STANCAK A, NEUPER C. Event-related synchronization (ERS) in the alpha band—an electrophysiological correlate of cortical idling: a review
   [J]. International Journal of Psychophysiology, 1996,24 (1-2):39-46.
- [4] 邹晓红,张轶勃,孙延贞.基于局部均值分解和多尺 度熵的运动想象脑电信号特征提取方法[J].高技术 通讯,2018,28(1):22-28.
- [5] BLANKERTZ B, SANNELLI C, HAIDER S, et al. Neurophysiological predictor of SMR-based BCI performance
   [J]. Neuroimage, 2010,51(4):1303-1309.
- [6] ZANINI P, CONGEDO M, JUTTEN C, et al. Transfer learning: a riemannian geometry framework with applications to brain-computer interfaces [J]. IEEE Transactions
   — 690 —

on Biomedical Engineering, 2018,65(5):1107-1116.

- [7] HE H, WU D. Transfer Learning for Brain-Computer Interfaces: an Euclidean space data alignment approach
   [J]. IEEE Transactions on Biomedical Engineering, 2020,67(2):399-410.
- [8] RAMOSER H, MULLER-GERKING J, PFURTSCHELLER G. Optimal spatial filtering of single trial EEG during imagined hand movement [J]. IEEE Transactions on Rehabilitation Engineering, 2000,8(4):441-446.
- [9] BLANKERTZ B, TOMIOKA R, LEMM S, et al. Optimizing spatial filters for robust EEG single-trial analysis[J].
   IEEE Signal Processing Magazine, 2008,25(1):41-56.
- [10] WANG Y, WANG Y-T, JUNG T-P. Translation of EEG spatial filters from resting to motor imagery using independent component analysis[J]. PLoS One, 2012,7(5): 1-12.
- [11] WU X, ZHOU B, LV Z, et al. To explore the potentials of independent component analysis in brain-computer interface of motor imagery[J]. IEEE Journal of Biomedical and Health Informatics, 2020, 24(3):775-787.
- [12] RODRIGUES P L C, JUTTEN C, CONGEDO M. Riemannian Procrustes analysis: transfer learning for braincomputer interfaces[J]. IEEE Transactions on Biomedical Engineering, 2019,66(8):2390-2401.
- [13] SCHALK G, MCFARLAND D J, HINTERBERGER T, et al. BCI2000: a general-purpose brain-computer interface(BCI) system[J]. IEEE Transactions on Biomedical Engineering, 2004,51(6):1034-1043.
- [14] TANGERMANN M, MULLER K R, AERTSEN A, et al. Review of the BCI competition IV[J]. Frontiers in Neuroscience, 2012, 6:1-31.
- [15] 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.
- [16] NAEEM M, BRUNNER C, LEEB R, et al. Seperability of four-class motor imagery data using independent components analysis[J]. Journal of Neural Engineering, 2006, 3(3):208-216.
- [17] BRUNNER C, NAEEM M, LEEB R, et al. Spatial filtering and selection of optimized components in four class motor imagery EEG data using independent components analysis[J]. Pattern Recognition Letters, 2007,28(8): 957-964.

- [18] PFURTSCHELLER G, BRUNNER C, SCHLOGL A, et al. Mu rhythm (de) synchronization and EEG single-trial classification of different motor imagery tasks [J]. Neuroimage, 2006,31(1):153-159.
- [19] 庄平. 脑电事件相关去同步化和同步化活动与运动相 关性作业[J]. 中国临床康复, 2004,(1):152-154.
- [20] 张娟. 稀疏正交普鲁克回归处理跨姿态人脸识别问题 [J]. 计算机科学, 2017,44(2):302-305.
- [21] 邰颖. 基于表示学习及回归模型的稳健人脸识别方法

研究[D]. 南京: 南京理工大学, 2017:67-81.

- [22] XU L C, XU M P, MA Z, et al. Enhancing transfer performance across datasets for brain-computer interfaces using a combination of alignment strategies and adaptive batch normalization [J]. Journal of Neural Engineering, 2021,18(4):1-19.
- [23] 何赫. 脑机接口中的迁移学习方法研究[D]. 武汉: 华中科技大学, 2020:16-16.

# Transfer learning strategy for motor imagery based on independent component analysis and Procrustes analysis

MAO Chuanbo, YANG Qinghua, CAI Shibo, WANG Zhiheng

(Key Laboratory of Special Purpose Equipment and Advanced Manufacturing Technology, Ministry of Education & Zhejiang Province, Zhejiang University of Technology, Hangzhou 310023)

#### Abstract

Aiming at the problem that the traditional brain-computer interface system based on motor imagery needs to perform a boring and lengthy calibration session before being used, a transfer learning algorithm based on independent component analysis (ICA) and Procrustes analysis is proposed. First, the electroencephalogram (EEG) signal is spatially filtered by independent component analysis, then a variety of alignment methods are used and compared with translate and scale the samples. And a rotation transformation method in Euclidean space is proposed to further match the data distribution of the target subject and other subjects, which helped to achieve effective transfer learning cross-subject and cross-dataset. The proposed method has better classification performance and computational efficiency than the method based on Riemannian Procrustes analysis, increasing the average kappa by 0.1 and 0.04 on the public dataset PhysionetMI and BCI-IV-2a compared with traditional machine learning algorithms. The results show that the method can effectively improve the classification accuracy under a small number of samples, which helps to reduce the demand for calibration data, thereby reducing the time required for the calibration session.

Key words: motor imagery, brain-computer interface, independent component analysis (ICA), Procrustes analysis, transfer learning