

组 LASSO 罚多变量自回归模型脑电特征分工类^①

王金甲^② 党雪 杨倩 王凤嫔 孙梦然

(燕山大学信息科学与工程学院 秦皇岛 066004)

(河北省信息传输与信号处理重点实验室 秦皇岛 066004)

摘 要 自回归(AR)模型和多变量自回归(MVAR)模型是脑机接口(BCI)系统脑电信号(EEG)常用的特征提取方法。AR 模型没有考虑多通道间的相互关系,MVAR 模型虽然考虑了多通道间相互关系,但是会出现模型过参数化问题。为解决 MVAR 模型过参数问题,本文提出采用组 LASSO 罚 MVAR 模型对脑电信号进行特征提取,采用梯度下降和块坐标下降相结合的方法估计模型参数,然后采用线性支持向量机(SVM)对提取的特征进行分类。实验结果表明,组 LASSO 罚 MVAR 模型的分类正确率达 93%,高于 MVAR 模型、LASSO-MVAR 模型和 6 阶 AR 模型的识别正确率。

关键词 脑机接口(BCI);脑电信号(EEG);特征提取;多变量自回归(MVAR)模型;正则化;组 LASSO

0 引 言

脑机接口(brain-computer interface, BCI)是一种可以在人脑和外部电子设备之间建立直接交流通道的新型交互系统^[1],典型应用包括拼写程序、虚拟智能家居、控制外部设备和残疾人通用辅助技术等。BCI 研究热点是如何快速有效地提取脑电信号(electroencephalograph, EEG)信号的特征和提高识别准确率^[2]。常用的脑电特征有频域特征^[3]、时域特征^[4]和时频域特征(time-frequency analysis)、共空间模式(common spatial patterns, CSP)^[5]等。其中自回归(autoregressive, AR)模型因其时间序列建模和特征分类效果好^[6]得到了广泛应用。Atyabi 等人^[6]将 AR 模型系数用于单次 EEG 分类,重点研究了模型阶数。Vijayan 等人^[7]基于 AR 模型系数研究了 EEG 情感识别。Lawhern 等人^[8]利用 SVM 对 AR 参数特征进行 EEG 分类,达到了 94% 的正确

率。但是 AR 模型仅能处理单通道时间序列信号,多通道脑电信号特征提取方法更应该采用能建模多通道互信息的多变量自回归(multivariate vector autoregressive, MVAR)模型^[9]。Anderson 等人^[9]对 2 个意识任务、6 个通道 EEG 信号进行了单通道 AR 模型和多通道 MVAR 模型特征提取的对比研究,结果表明 MVAR 模型系数作为特征能够获得更好的识别率。Mattia 等人^[10]构造了多通道脑电信号时变 MVAR 模型研究 EEG 多通道交互特点。Dutta 等人^[11]利用多元经验模态分解的固有模态函数建立 MVAR 模型,脑电信号平均分类正确率为 94.43%。Shahabi 等人^[12]利用 MVAR 模型系数提取 EEG 连接模式。

MVAR 模型存在过参数化问题,即样本数量少和模型参数多之间的矛盾。结构稀疏正则化方法可以产生模型参数的稀疏性,为解决模型维数过高、过参数化、计算量大、变量选择和时滞选择等问题提供了方法。目前 EEG 特征提取很少采用稀疏 MVAR

① 国家自然科学基金(61473339),首批河北省青年拔尖人才支持计划([2013]17)和京津冀基础研究合作专项(F2019203583)资助项目。
② 男,1978 年生,博士,教授;研究方向:信号处理与模式识别;联系人,E-mail: wjj@ysu.edu.cn
(收稿日期:2018-12-20)

模型。套索(least absolute shrinkage and selection operator, LASSO)是一种可用于高维特征选择的正则化新方法^[13],组 LASSO^[14]是 LASSO 方法的推广。Wang^[15]基于 LASSO 和最小角回归算法研究不同年龄段脑电信号并得出结论,年龄对 EEG 信号的影响并不显著。王金甲和陈春^[16]采用分层 MVAR 模型用于 EEG 信号特征提取。

本文提出采用组稀疏 MVAR 模型用于 EEG 信号特征提取。将结构稀疏正则化方法与 MVAR 模型结合,给滞后系数矩阵施加组 LASSO 罚约束,同时侧重比较变量对自身的依赖关系与自身-其他变量的交叉依赖关系间的差别,并通过给对角线与非对角线系数施加不同的权重来判断变量自身影响和变量间交互影响的关系。本文创新点如下:(1)将组 LASSO 罚从回归模型和分类模型推广到高维时间序列自回归模型;(2)组 LASSO 罚解决了 MVAR 模型过参数化问题;(3)罚模型参数估计采用了块坐标下降算法。实验结果表明组 LASSO 罚 MVAR 模型参数作为 EEG 特征的分类正确率达到 93%,优于 AR 模型参数和 MVAR 模型参数的分类性能。

本文首先介绍 MVAR 模型,其次给出组 LASSO 罚 MVAR 模型和参数估计的块坐标下降算法,包括时滞组 LASSO 罚模型、自身-其他时滞组 LASSO 罚模型,再次是实验结果和分析,最后是结论。

1 MVAR 模型

假设高维时间序列 y_t 满足 MVAR 模型:

$$y_t = v + \sum_{l=1}^p B^{(l)} y_{t-l} + u_t, t = 1, \dots, T \quad (1)$$

其中 $v \in \mathbb{R}^k$ 是截距向量; $\{B^{(l)} \in \mathbb{R}^{k \times k}\}_{l=1}^p$ 是时滞为 l 的模型系数矩阵; $l = 1, \dots, p$; $\{u_t \in \mathbb{R}^k\}_{t=1}^T$ 是独立同分布的高斯白噪声。

系数矩阵 B 、截距 v 的最小二乘估计式为

$$\begin{aligned} \{\hat{v}, \hat{B}\} &= \operatorname{argmin}_{v, B} \frac{1}{2} \sum_{t=1}^T \|y_t - v - \sum_{l=1}^p B^{(l)} y_{t-l}\|_F^2 \\ &= \operatorname{argmin}_{v, B} \frac{1}{2} \|Y - v \mathbf{1}^T - BZ\|_F^2 \end{aligned} \quad (2)$$

其中 $Y = [y_1, \dots, y_T]$, $Z_t = [y_t^T, \dots, y_{t-p}^T]^T$, $Z = [Z_2, \dots, Z_{T-1}]$, $B = [B^{(1)}, B^{(2)}, \dots, B^{(p)}]$, $U = [u_1,$

$\dots, u_T]$ 。

LASSO 罚 MVAR 模型^[17]系数估计为

$$\{\hat{v}, \hat{B}\} = \operatorname{argmin}_{v, B} \frac{1}{2} \|Y - v \mathbf{1}^T - BZ\|_F^2 + \lambda \|B\|_1 \quad (3)$$

其中 λ 为超参数。LASSO-MVAR 模型参数求解可以采用坐标下降法。令 $R_t = Y_t - \sum_{l \neq t} B_{jl} Z_{lt}$ 代表部分残差,利用软阈值函数 $S(x, \phi) = \operatorname{sgn}(x)(|x| - \phi)_+$, $(|x| - \phi)_+ = \max(|x| - \phi, 0)$, 矩阵 B 每个元素更新的软阈值形式为

$$B_{jr} = \frac{S(\sum_t R_t Z_{rt}, \lambda)}{\sum_t Z_{rt}^2} \quad (4)$$

2 组 LASSO 罚多变量自回归模型

2.1 结构稀疏多变量自回归模型

高维小样本数据的变量选择尤为重要。LASSO 模型利用 L_1 范数实现变量选择。当变量之间具有相关性时,组 LASSO 罚模型利用 L_2 范数通过组稀疏实现变量组选择能力。这类结构稀疏多变量自回归模型为

$$\min_{v, B} \sum_{t=1}^T \|y_t - v - \sum_{l=1}^p B^{(l)} y_{t-l}\|_F^2 + \lambda P_y(B) \quad (5)$$

其中 $P_y(B)$ 为带有结构稀疏的罚函数, λ 为超参数。模型参数估计可以采用块坐标下降法的凸优化法求解。

令 $P_y(B) = \sqrt{k^2} \sum_{l=1}^p \|B^{(l)}\|_F$, 模型称为时滞组 LASSO 罚多变量自回归模型(GLASSO-MVAR)。

$$\begin{aligned} \min_{v, B} \{ & \sum_{t=1}^T \|y_t - v - \sum_{l=1}^p B^{(l)} y_{t-l}\|_F^2 \\ & + \lambda \sqrt{k^2} \sum_{l=1}^p \|B^{(l)}\|_F \} \end{aligned} \quad (6)$$

该模型考虑时滞组结构,示意图如图 1 所示。组内变量要么被同时选择黑色部分,要么被同时舍弃白色部分。




图1 时滞为4的时滞组 LASSO 罚滞后结构示意图

令 $P_y(B) = \sqrt{k} \sum_{l=1}^p \|B_{on}^{(l)}\|_F + \sqrt{k(k-1)} \sum_{l=1}^p \|B_{off}^{(l)}\|_F$, 模型称为自身-其他时滞组 LASSO 罚多变量自回归模型(OOGLASSO-MVAR), 描述如式(7)所示:

$$\min_{v, B} \left\{ \sum_{l=1}^T \|y_l - v - \sum_{l=1}^p B^{(l)} y_{l-l}\|_F^2 + \lambda \left(\sqrt{k} \sum_{l=1}^p \|B_{on}^{(l)}\|_F + \sqrt{k(k-1)} \sum_{l=1}^p \|B_{off}^{(l)}\|_F \right) \right\} \quad (7)$$

其中 $B_{on}^{(l)}$ 和 $B_{off}^{(l)}$ 分别代表系数矩阵 $B^{(l)}$ 的对角线和非对角线元素。

该模型考虑了时滞组结构,并将系数矩阵 $B(l)$ 对角线上的系数与非对角线上的系数加以区分,示意图如图2所示。对角线上的系数代表序列自己的滞后,非对角线上的系数代表其他序列的滞后。组内变量可以被同时选择黑色部分,可以被同时舍弃白色部分,还可以对角线被选择而非对角线不被选择。




图2 时滞为4的自身-其他滞后结构示意图

2.2 罚模型参数求解算法

时滞组 LASSO 罚模型参数估计方法主要利用块坐标下降法将问题转化成许多子问题,这些子问题可以通过单变量凸优化方法来解决^[18]。

定义 $R_q = B^{(q)} Z_q - Y \in \mathbb{R}^{k \times T}$ 代表部分残差,部分系数矩阵 $B^{(q)}$ 的优化如式(8)所示。

$$\min_{B^{(q)}} \frac{1}{2} \|R_{-q} - B^{(q)} Z_q\|_F^2 + \lambda \|B^{(q)}\|_F \quad (8)$$

$$\frac{1}{2} \|R_{-q} - B^{(q)} Z_q\|_F^2 \text{ 对 } B^{(q)} \text{ 求导为 } \nabla_{B^{(q)}}$$

$\frac{1}{2} \|R_{-q} - B^{(q)} Z_q\|_F^2 = B^{(q)} Z_q Z_q^T - R_{-q} Z_q^T$, 因此上式对 $B^{(q)}$ 求得:

$$B^{(q)} Z_q Z_q^T - R_{-q} Z_q^T + \lambda \omega(B^{(q)}) \quad (9)$$

其中定义 $\omega(B^{(q)}) = \begin{cases} \frac{B^{(q)}}{\|B^{(q)}\|_F} & B^{(q)} \neq 0 \\ \{U: \|U\|_F \leq 1\} & B^{(q)} = 0 \end{cases}$

当 $B^{(q)} = 0$ 时, $\frac{B^{(q)} Z_q Z_q^T - R_{-q} Z_q^T}{\lambda} \in \{U: \|U\|_F \leq 1\}$, 可以得到结论 $B^{(q)} = 0 \Leftrightarrow \|R_{-q} Z_q^T\|_F \leq \lambda$ 。当假定 $B^{(q)} \neq 0$ 时, $B^{(q)} Z_q Z_q^T - R_{-q} Z_q^T + \lambda \left(\frac{B^{(q)}}{\|B^{(q)}\|_F} \right) = 0$, 进一步有 $B^{(q)} (Z_q Z_q^T + \frac{\lambda}{\|B^{(q)}\|_F} I_k) = R_{-q} Z_q^T$, 由于 $Z_q Z_q^T$ 是正定的且 $\lambda > 0$, 所以 $Z_q Z_q^T + I_k \cdot \frac{\lambda}{\|B^{(q)}\|_F}$ 正定, 因此可以建立置信区间的子问题,

将 $R_{-q} Z_q^T \notin \mathbb{R}^{k \times k}$ 转化为标量, 定义 $r_q = \text{vec}(R_{-q} Z_q^T)$, $G_q = Z_q Z_q^T \otimes I_k$, $B_q = \text{vec}(B^{(q)})$ 。

整理得到 $B_q^T (G_q + \frac{\lambda}{\|B_q\|_F} I_{k^2}) = r_q$, 因此将式(9)写成置信区间子问题:

$$\min \frac{1}{2} B_q^T G_q G_q^T B_q + r_q^T B_q, \text{ s. t. } \|B_q\|_F \leq \Delta \quad (10)$$

$\Delta > 0$ 代表置信区间残差, 在 KKT 条件下 $\|B_q^*\|_F = \Delta$, 得到 $B_{qq}^* = -(G_q + \frac{\lambda}{\Delta} I_k^2)^{-1} r_q$ 。根据文献[19]等式 $B_q^* = \Delta y_q(\Delta)$, 得到 $y_q(\Delta) = -(\Delta G_q + \lambda I_{k^2})^{-1} r_q$ 。通过 G_q 特征值分解得 $y_q(\Delta) = -W(\Delta V + \lambda I_{k^2})^{-1} W_{r_q}$ 。令 $\Psi = (\Delta V + \lambda I_{k^2})^{-1}$, 得到 $\|y_q(\Delta)\|_F^2 = \sum_i \frac{(w_i^T r_q)^2}{(v_i \Delta + \lambda)^2}$, 其中 w_i 代表 W 的第 i 列, v_i 代表 V 的第 i 列。最后可以得到 Δ 的最优解 $1 - \frac{1}{\|y_q(\Delta)\|_F}$, 因此就得到了 B_q^* 的估计值。

自身-其他时滞组 LASSO 罚模型参数估计方法也是利用块坐标下降法将问题转化成许多子问题。为了将变量自身的滞后系数矩阵与其他变量的滞后系数矩阵分到不同的组内, 作如下定义 $r_{-qq} =$

$vec(\mathbf{R}_{-qq}), \mathbf{B}_{qq} = vec(\mathbf{B}_{on}^{(q)}), \mathbf{M}_{qq} = (\mathbf{Z}^T \otimes \mathbf{I}_k)_{qq}$ 。每一个变量自身的滞后系数矩阵的子问题就可以描述为

$$\begin{aligned} \min_{\mathbf{B}_{qq}} & \left\{ \frac{1}{2} \|\mathbf{M}_{qq} \mathbf{B}_{qq} + \mathbf{r}_{-qq}\|_F^2 + \lambda \|\mathbf{B}_{qq}\|_F \right\} \\ & = \min_{\mathbf{B}_{qq}} \left\{ \frac{1}{2} \mathbf{B}_{qq}^T \mathbf{M}_{qq}^T \mathbf{M}_{qq} \mathbf{B}_{qq} + \mathbf{r}_{-qq}^T \mathbf{M}_{qq} \mathbf{B}_{qq} + \lambda \|\mathbf{B}_{qq}\|_F \right\} \end{aligned} \tag{11}$$

目标函数的子梯度如下：

$$\frac{\partial}{\partial \mathbf{B}_{qq}} = \mathbf{M}_{qq}^T \mathbf{M}_{qq} \mathbf{B}_{qq} + \mathbf{M}_{qq}^T \mathbf{r} + \lambda \omega(\mathbf{B}_{qq}) \tag{12}$$

其中 ω 定义为 $\omega(s) \in \begin{cases} \frac{s}{\|s\|_F} & s \neq 0 \\ \{u: \|u\|_F \leq 1\} & s = 0 \end{cases}$ 。当

$\mathbf{B}_{qq} = 0$ 时, $\frac{\mathbf{M}_{qq}^T \mathbf{M}_{qq} \mathbf{B}_{qq} + \mathbf{M}_{qq}^T \mathbf{r}}{\lambda} \in \{u: \|u\|_F \leq 1\}$,

可以得到结论 $\mathbf{B}_{qq} = 0 \Leftrightarrow \|\mathbf{M}_{qq}^T \mathbf{r}\|_F \leq \lambda$ 。当 $\mathbf{B}_{qq} \neq 0$

时, $\mathbf{M}_{qq}^T \mathbf{M}_{qq} \mathbf{B}_{qq} + \mathbf{M}_{qq}^T \mathbf{r} + \lambda (\frac{\mathbf{B}_{qq}}{\|\mathbf{B}_{qq}\|_F}) = 0$, 经整理得

$\mathbf{B}_{qq} (\mathbf{M}_{qq}^T \mathbf{M}_{qq} + (\frac{\lambda}{\|\mathbf{B}_{qq}\|_F})) = -\mathbf{M}_{qq}^T \mathbf{r}$ 。将上式转化为

置信区间子问题。先定义 $\mathbf{m}_q = -\mathbf{M}_{qq}^T \mathbf{r}, \mathbf{F}_q = \mathbf{M}_{qq}^T \mathbf{M}_{qq} \otimes \mathbf{I}_k, \mathbf{B}_{qq} = vec(\mathbf{B}_{qq})$, 带入上式得到 $\mathbf{B}_{qq}^* = -$

$(\mathbf{F}_q + \frac{\lambda}{\Delta_1} \mathbf{I}_k^2)^{-1} \mathbf{m}_q$ 。下面的求解过程与时滞组求解过程相类似, 这里仅做简要推导。上式也可以写作

$\mathbf{y}_{1q}(\Delta_1) = -(\Delta_1 \mathbf{F}_q + \lambda \mathbf{I}_{k^2})^{-1} \mathbf{m}_q$ 。将 $\mathbf{F}_q$ 进行奇异值分解, $\mathbf{W}_1, \mathbf{V}_1$ 为 $\mathbf{F}_q$ 奇异值分解的结果, $\mathbf{w}_{1i}, \mathbf{v}_{1i}$ 分别为 $\mathbf{W}_1$ 和 $\mathbf{V}_1$ 的第 i 列。推导得到 $\mathbf{y}_{1q}(\Delta_1) = -\mathbf{W}_1$

$(\Delta_1 \mathbf{V}_1 + \lambda \mathbf{I}_{k^2})^{-1} \mathbf{W}_{1rq}$ 。令 $\mathbf{Y} = (\Delta_1 \mathbf{V}_1 + \lambda \mathbf{I}_{k^2})^{-1}$, 则

$\|\mathbf{y}_{1q}(\Delta_1)\|_F^2 = \sum_i \frac{(\mathbf{w}_{1i}^T \mathbf{m}_q)^2}{(\mathbf{v}_{1i}^T \Delta_1 + \lambda)^2}$ 。 Δ_1 的最优解为 $1 - \frac{1}{\|\mathbf{y}_{1q}(\Delta_1)\|_F}$, 因此就得到了 $\mathbf{B}_{qq}^*$ 的估计值。

3 实验结果与分析

EEG 分类数据来自文献[16,20]。本实验采用受试者 1、3、5、7 的所有样本作为实验数据。特征提取方法采用 MVAR、LASSO-MVAR、GLASSO-MVAR、OOGLOSSO-MVAR 模型参数, 分类器采用线性 SVM, 将 10 次实验的均值作为最终的分类结果。实验共有 10 种任务, 400 个样本随机抽取 200 个作为训练集, 剩下的 200 个作为测试集。

实验 1 给出了不同时滞下 4 种模型参数的分类正确率。以受试者 7 为例, 表 1 ~ 表 4 给出了在时滞 $p=1 \sim 7$ 时, 10 种任务组合方式下的 10 次实验的平均分类正确率(表中加黑数字代表每种任务组合的正确率最大值)。

从表 1 到表 4 可知, 对于受试者 7 来说, OOGLOSSO-MVAR 取得了最高的分类正确率为 93%。在 10 种任务组合中, 第 1 种(基准、乘法计算)和第 7 种(乘法计算、视觉计算)的分类正确率较高。此外不同任务组合方式对应的最大时滞不同, 不同方法所对应的最大时滞也是不同的。LASSO-MVAR、OOGLOSSO-MVAR 对应的最大时滞均为 $p=1$, MVAR、GLASSO-MVAR 的最大时滞为 $p=2$ (这里所说的最大时滞指至少有 5 种任务组合方式取得了

表 1 MVAR 模型不同时滞的平均正确率

任务组合	1	2	3	4	5	6	7	8	9	10
时滞										
1	0.83	0.59	0.78	0.73	0.75	0.78	0.84	0.76	0.74	0.80
2	0.85	0.64	0.85	0.81	0.82	0.80	0.84	0.76	0.78	0.85
3	0.80	0.65	0.84	0.78	0.79	0.79	0.84	0.76	0.74	0.85
4	0.78	0.63	0.83	0.73	0.76	0.76	0.84	0.76	0.71	0.84
5	0.76	0.60	0.81	0.69	0.73	0.72	0.84	0.76	0.68	0.81
6	0.72	0.59	0.83	0.70	0.69	0.71	0.84	0.76	0.67	0.79
7	0.70	0.58	0.77	0.70	0.69	0.71	0.84	0.76	0.66	0.80

表 2 LASSO-MVAR 模型不同时滞的平均正确率

任务组合 时滞	1	2	3	4	5	6	7	8	9	10
1	0.84	0.60	0.77	0.74	0.78	0.75	0.90	0.74	0.73	0.79
2	0.79	0.61	0.79	0.73	0.75	0.74	0.86	0.74	0.72	0.77
3	0.76	0.58	0.77	0.72	0.76	0.78	0.87	0.74	0.70	0.75
4	0.79	0.57	0.77	0.72	0.77	0.72	0.87	0.73	0.70	0.76
5	0.78	0.57	0.77	0.71	0.76	0.74	0.85	0.75	0.70	0.74
6	0.77	0.55	0.78	0.69	0.74	0.73	0.84	0.75	0.69	0.73
7	0.76	0.54	0.78	0.69	0.72	0.72	0.84	0.74	0.64	0.74

表 3 GLASSO-MVAR 模型不同时滞的平均正确率

任务组合 时滞	1	2	3	4	5	6	7	8	9	10
1	0.86	0.59	0.82	0.75	0.78	0.79	0.92	0.79	0.73	0.81
2	0.83	0.60	0.84	0.77	0.81	0.79	0.88	0.79	0.74	0.80
3	0.83	0.58	0.82	0.75	0.79	0.78	0.89	0.77	0.74	0.77
4	0.85	0.62	0.81	0.75	0.82	0.77	0.90	0.78	0.72	0.77
5	0.82	0.57	0.84	0.74	0.82	0.77	0.89	0.79	0.71	0.77
6	0.82	0.56	0.84	0.73	0.78	0.77	0.88	0.80	0.68	0.77
7	0.83	0.58	0.84	0.71	0.80	0.77	0.88	0.80	0.70	0.76

表 4 OOGLOSSO-MVAR 模型不同时滞的平均正确率

任务组合 时滞	1	2	3	4	5	6	7	8	9	10
1	0.86	0.59	0.80	0.77	0.81	0.81	0.93	0.76	0.74	0.81
2	0.84	0.59	0.81	0.77	0.81	0.79	0.91	0.78	0.74	0.79
3	0.81	0.59	0.80	0.79	0.79	0.77	0.90	0.77	0.75	0.76
4	0.82	0.62	0.78	0.73	0.80	0.77	0.90	0.77	0.74	0.75
5	0.80	0.58	0.81	0.74	0.78	0.76	0.88	0.77	0.74	0.74
6	0.80	0.58	0.84	0.71	0.78	0.75	0.87	0.79	0.70	0.74
7	0.81	0.57	0.82	0.69	0.78	0.76	0.86	0.78	0.69	0.74

最高的分类正确率)。对其他 3 位受试者进行同样分析,结果表明此结论同样成立。

实验 2 给出了每种模型在各自最大时滞下的分类正确率,如图 3 所示。将 4 位受试者的分类正确率做成折线图,4 种模型使用各自对应的最大时滞。横坐标是 10 种任务组合,纵坐标是分类正确率。

从图 3 可知:(1) 对于不同的受试者,最佳的任

务组合方式不同。这说明每个人的思维方式不同。

从图上看,前 2 个受试者的最佳组合方式为第 9 种(字母组合、视觉计算),受试者 5 为第 10 种(图形旋转、视觉计算),受试者 7 为第 7 种(基准、视觉计算)。(2) 对于不同的受试者,最佳的特征提取方式不同。这说明通用的特征提取方法是很困难的。但从总体来看,对于所有的受试者,采用 MVAR 进行特征提取至少在 5 种组合方式下达到了最高的分类正确率。这说明 MVAR 作为 EEG 特征提取方法

是合适的,尽管其参数多训练时间长。(3) 在组稀疏罚模型的基础上,优先考虑自身的滞后可提高分类正确率。例如受试者 1、3、7 的第 7 种任务组合方

式所对应的最佳特征提取方法均为 OOGGLASSO-MVAR 模型。




图 3 4 个受试者的分类结果

表 5 给出了 4 种模型特征提取方法在各自最大时滞下的平均值、最大值、最佳任务组合方式,并对比 MVAR、LASSO-MVAR 模型和 AR 模型^[20]。从表 5 可知:(1)从均值来看,采用 2 阶 MVAR 的分类效果要优于 6 阶 AR。这是因为 AR 模型只适合用于单通道信号,会忽略多通道间相互作用,而多变量自回归模型则可以挖掘多个通道之间的互信息,因此分类正确率高。(2) 1 阶的 OOGGLASSO-MVAR 与 6 阶 AR 分类效果相当,稍差于 2 阶 MVAR。OOGGLASSO-MVAR 只用了最低阶数就得到比较高的分类正确率,体现了自身-其他时滞组罚结构的优越性。(3) 从平均正确率上看,采用 LASSO-MVAR 进行特征提取得到的平均正确率最低。这说明在参数空间较小时,在多变量自回归模型的基础上施加

LASSO 罚的效果并不显著。(4) 对于受试者 1、3,对应任务组合方式均为第 9 种(视觉计算、字母组合),最佳特征提取方法均为 MVAR 模型,最高分类正确率分别为 82%、84%;对于受试者 5,对应任务组合方式为第 10 种(图形旋转、视觉计算),最佳特征提取方法为 MVAR 模型,最高分类正确率为 83%;对于受试者 7,对应的任务组合方式为第 7 种(视觉计算、乘法计算),最佳特征提取方法为 OOGGLASSO-MVAR 模型,最高分类正确率为 93%。

实验 3 讨论时滞较高即参数空间较大时不同模型特征提取方法的分类效果。以 $p=7$ 为例,图 4 给出了 4 位受试者不同模型特征提取方法下的分类正确率箱线图。横坐标是 4 种特征提取方法,纵坐标是分类正确率。

表 5 不同特征提取方法对照表

		AR	MVAR	LASSO-MVAR	GLASSO-MVAR	OOGGLASSO-MVAR
受试者 1	平均值	0.78	0.72	0.68	0.68	0.71
	最大值	0.86	0.82	0.76	0.75	0.78
	最佳任务组合方式	乘法计算 字母组合	视觉计算 字母组合	视觉计算 字母组合	乘法计算 图形旋转	乘法计算 字母组合
受试者 3	平均值	0.71	0.72	0.68	0.68	0.71
	最大值	0.80	0.84	0.75	0.74	0.78
	最佳任务组合方式	字母组合 视觉计算	字母组合 视觉计算	字母组合 视觉计算	字母组合 基准计算	字母组合 视觉计算
受试者 5	平均值	0.71	0.72	0.69	0.70	0.70
	最大值	0.83	0.83	0.82	0.80	0.83
	最佳任务组合方式	图形旋转 视觉计算	图形旋转 视觉计算	图形旋转 视觉计算	图形旋转 字母计算	图形旋转 视觉计算
受试者 7	平均值	0.79	0.80	0.77	0.78	0.79
	最大值	0.92	0.85	0.91	0.92	0.93
	最佳任务组合方式	乘法计算 视觉计算	乘法计算 基准计算	乘法计算 视觉计算	乘法计算 视觉计算	乘法计算 视觉计算




图 4 时滞为 7 时不同模型的分​​类正确率箱线图

从图 4 可知,当参数空间增大时,与实验 2 对比来看,4 种模型特征提取的分类正确率发生了变化。首先,在 10 种任务组合方式下,组稀疏罚模型的分​​类正确率较高,值分布也比较均匀,说明组稀疏结构

在模型待估参数过多时可以剔除无关变量,有效地进行特征提取。其次,LASSO-MVAR 模型的分​​类正确率也得到了改善,高于 MVAR 模型,这表明 LASSO-MVAR 模型的 L_1 范数在时滞较大时才呈现出一

定的优势,在压缩参数空间的同时进行了变量选择;而未施加任何约束的 MVAR 模型分类正确率最低。尤其对于受试者 7, MVAR 模型不如组稀疏罚模型稳定。对于受试者 1、3 来说, OOGLOSSO-MVAR 的分类正确率高于 GLASSO-MVAR, 这说明在多通道信号处理中, 不同通道间的相互作用不同, 且信号自身的相互影响大于信号间的交互影响。

本研究工作是在过去研究^[16]基础上进行的, 二者区别如下: (1) 本文工作基于组 LASSO 罚模型, 而不是分层罚模型; (2) 模型参数求解方法不同; (3) 实验结果不同。

目前深度学习方法在图像语音领域取得了巨大成功, 重要原因包括海量标注样本数据、极大运算量和运算时间、极高的网络模型复杂度^[22]。BCI 领域缺乏公认的海量标注样本, 导致深度网络模型训练不充分产生欠拟合问题, 分类正确率较低。MVAR 模型训练时间远低于深度网络的训练时间。更重要的是, 深度网络模型是黑箱的, 没有多变量自回归模型明显的物理意义, 不能展示多通道 EEG 信号间的相互依赖关系。因此一旦出现海量标注 EEG 样本, 深度学习方法就能展示强大的能力。

4 结 论

有效的特征提取是提高 EEG 信号分类正确率的关键。本文提出采用基于结构化稀疏的组 LASSO 罚 MVAR 模型系数作为脑电特征, 并用线性支持向量机对特征进行分类。采用结构化稀疏罚函数, 使得多变量自回归模型系数稀疏, 压缩了模型系数空间, 加速模型求解的成功率和收敛率。本研究创新在于将组 LASSO 罚从回归模型和分类模型推广到高维时间序列自回归模型, 运用组 LASSO 罚和块坐标下降算法解决了 MVAR 模型过参数化问题, 这为生物医学领域多通道信号特征提取提供了有益借鉴。脑电信号验证的结果表明, 利用 1 阶自身-其他时滞组罚 MVAR 模型就能得到与 6 阶 AR 模型近似的正确率, 在同一时滞下结构化稀疏罚 MVAR 模型的特征分类性能远超于 MVAR、LASSO-MVAR 等模型。进一步研究将包括带外变量的结构化稀疏罚

VAR 模型的特征提取等。

参考文献

- [1] McFarland D J, Wolpaw J R. EEG-based brain-computer interfaces[J]. *Current Opinion in Biomedical Engineering*, 2017, 4(1):194-200
- [2] 胡春海, 李涛, 刘永红, 等. 基于改进差分进化算法的运动想象脑机接口频段选择[J]. *计量学报*, 2018, 39(11):276-279
- [3] Gökse H. BCI oriented EEG analysis using log energy entropy of wavelet packets[J]. *Biomedical Signal Processing and Control*, 2018, 44(7): 101-109
- [4] Luo J, Feng Z R, Lu N. Spatio-temporal discrepancy feature for classification of motor imageries[J]. *Biomedical Signal Processing and Control*, 2019, 47(1):137-144
- [5] Sethi S, Upadhyay R, Singh H S. Stockwell-common spatial pattern technique for motor imagery-based brain computer interface design[J]. *Computers and Electrical Engineering*, 2018, 71(10): 492-504
- [6] Atyabi A, Shie F, Naples A. Mixture of autoregressive modeling orders and its implication on single trial EEG classification [J]. *Expert Systems with Applications*, 2016, 65(15):164-180
- [7] Vijayan A E, Sen D, Sudheer A P. Sudheer EEG-based emotion recognition using statistical measures and autoregressive modeling[C]//2015 IEEE International Conference on Computational Intelligence and Communication Technology (CICIT), Ghaziabad, India, 2015: 587-591
- [8] Lawhern V, Hairston W D, McDowell K, et al. Detection and classification of subject-generated artifacts in EEG signals using autoregressive models[J]. *Journal of Neuroscience Methods*, 2012, 208(2):181-189
- [9] Anderson W, Stolz E A, Shamsunder S. Multivariate autoregressive models for classification of spontaneous electroencephalographic signals during mental tasks [J]. *IEEE Transaction on Biomedical Engineering*, 1998, 45(3):277-286
- [10] Pagnotta M F, Plomp G. Time-varying MVAR algorithms for directed connectivity analysis: critical comparison in simulations and benchmark EEG data[J]. *PLoS One*, 2018, 13(6): e0198846
- [11] Dutta S, Singh M, Kumar A. Automated classification of non-motor mental task in electroencephalogram based brain-computer interface using multivariate autoregressive model in the intrinsic mode function domain[J]. *Biomedical Signal Processing and Control*, 2018, 43(5): 174-

- [12] Shahabi H, Moghimi S. Toward automatic detection of brain responses to emotional music through analysis of EEG effective connectivity[J]. *Computers in Human Behavior*, 2016, 58 (1):231-239
- [13] Tibshirani R. Regression shrinkage and subset selection via the LASSO[J]. *Journal of the Royal Statistical Society*, 1996, 58(1):267-288
- [14] Yuan M, Lin Y. Model selection and estimation in regression with grouped variables[J]. *Journal of the Royal Statistical Society*, 2006, 68(1):49-67
- [15] Wang Y, Chung M K, Bachhuber D R W, et al. LARS network filtration in the study of EEG brain connectivity [C]// 2015 IEEE 12th International Symposium on Biomedical Imaging (ISBI), New York, USA, 2015:30-33
- [16] 王金甲, 陈春. 分层向量自回归的多通道脑电信号的特征提取研究[J]. *自动化学报*, 2016, 42(8):1215-1226
- [17] Hsu N J, Hung H L, Chang Y M. Subset selection for vector autoregressive processes using Lasso[J]. *Computational Statistics and Data Analysis*, 2008, 52 (7):3645-3657
- [18] Nicholson W B, Matteson D S, Bien J. VARX-L: structured regularization for large vector autoregressions with exogenous variables[J]. *International Journal of Forecasting*, 2017, 33(3):627-651
- [19] Qin Z, Scheinberg K, Goldfarb D. Efficient block-coordinate descent algorithms for the group LASSO[J]. *Mathematical Programming Computation*, 2013, 5 (2):143-169
- [20] Zhang Y, Ji X, Liu B, et al. Combined feature extraction method for classification of EEG signals[J]. *Neural Computing and Applications*, 2016, 3 (10):1-9
- [21] Huan N J, Palaniappan R. Neural network classification of autoregressive features from electroencephalogram signals for brain-computer interface design[J]. *Journal of Neural Engineering*, 2004, 1(3):142-150
- [22] Yann L C, Bengio Y, Hinton G. Deep learning[J]. *Nature*, 2015, 521(7553):436-444

EEG feature classification based on group LASSO penalized multivariate autoregressive model

Wang Jinjia, Dang Xue, Yang Qian, Wang Fengpin, Sun Mengran

(School of Information Science and Engineering, Qinhuangdao 066004)

(Hebei Key Laboratory of Information Transmission and Signal Processing, Yanshan University, Qinhuangdao 066004)

Abstract

Autoregressive (AR) model and multivariate vector autoregressive (MVAR) model are general feature extraction methods of electroencephalograph (EEG) signal in brain-computer interface (BCI). AR model does not consider the relationship between multi-channels. MVAR model considers the relationship between multi-channels, but it will lead to over-parameterization. In order to solve the over-parameter problem of MVAR model, a novel feature extraction of EEG signals based on the group LASSO penalized MVAR model is proposed. The gradient descent method and block coordinate descent method are used to estimate model parameters. The extracted features are classified by the linear support vector machine (SVM). The new method not only overcomes the limitations of AR used for single channel signals, but also effectively avoids the problem of over parameterization in MVAR model. The experimental results show that the classification accuracy reaches 93%, which is higher than the MVAR model, LASSO-MVAR model and 6 order AR model.

Key words: brain computer interface (BCI), electroencephalograph (EEG), feature extraction, multivariate autoregressive(MVAR) model, regularization, group LASSO