

节律自适应的运动想象脑电空域特征提取方法

吴叶兰, 张跃, 曹璞刚, 廉小亲, 于重重
北京工商大学人工智能学院, 北京 100048

【摘要】目的:针对运动想象脑电(MI-EEG)信号个体差异性大,特征质量依赖频带的选择,导致多类MI-EEG信号识别效果差的问题,提出节律自适应的空域特征提取方法。**方法:**用滤波器组共空间模式(FBCSP)提取多个频带的空域特征,结合免疫粒子群优化算法,对特征提取过程中的频、空参数寻优,实现节律、空域特征提取参数的自适应调整,获取最优节律下的FBCSP空域特征,提升多类MI-EEG信号的识别准确率。**结果:**本文方法在BCI-IV Dataset 2a、BCI-III Dataset 3a数据集上取得85.49%的平均准确率,较原始FBCSP方法提升10.84%。**结论:**本文方法更好地获取了脑电空域特征,能有效提高分类正确率,为MI-EEG分类提供了新的解决思路。

【关键词】运动想象脑电信号;特征提取;滤波器组共空间模式;免疫粒子群优化

【中图分类号】R318

【文献标志码】A

【文章编号】1005-202X(2023)10-1270-08

Rhythm adaption method for extracting spatial features of MI-EEG

WU Yelan, ZHANG Yue, CAO Pugang, LIAN Xiaoqin, YU Chongchong

School of Artificial Intelligence, Beijing Technology and Business University, Beijing 100048, China

Abstract: Objective To propose a method for spatial feature extraction based on rhythm adaption for addressing the problem of poor recognition of multi-class motor imagery electroencephalogram (MI-EEG) caused by the individual differences in MI-EEG and the dependence of feature quality on frequency band selection. **Methods** The spatial features under different frequency bands were extracted with filter bank common spatial pattern (FBCSP). The immune particle swarm optimization algorithm was used to optimize the frequency band and spatial feature extraction parameters in feature extraction for realizing the adaptive adjustment of the rhythm and spatial parameters and obtaining the FBCSP spatial features under the optimal rhythm, thereby improving the recognition accuracy of multi-class MI-EEG. **Results** The proposed method had an average accuracy of 85.49% on BCI-IV Dataset 2a and BCI-III Dataset 3a, which was 10.84% higher than the original FBCSP method. **Conclusion** The proposed method is advantageous in EEG feature extraction and can effectively improve classification accuracy, providing a new solution for MI-EEG classification.

Keywords: motor imagery electroencephalogram; feature extraction; filter bank common spatial pattern; immune particle swarm optimization

前言

脑-机接口(Brain-Computer Interface, BCI)通过测量中枢神经系统的电活动,检测人脑意图,实现脑和外部设备的信息交互^[1]。根据采集范式的不同,脑电信号分为运动想象、情绪、稳态视觉诱发等类型。其中,运动想象脑电(Motor Imagery Electroencephalogram, MI-EEG)信号是内源性自发

脑电,在医疗康复、军事科学、生活娱乐等领域具有较高的应用价值^[2]。如何准确、有效地对脑电信号进行特征提取和分类,是BCI技术的研究热点。

脑电图(EEG)信号特征提取可以从时域、频域、时频域和空域等不同维度进行^[3],常用的方法有自回归模型(Auto Regressive, RA)^[4]、快速傅里叶变换(Fast Fourier Transform, FFT)^[5]、希尔伯特-黄变换(Hilbert Huang Transform, HHT)^[6]、共空间模式(Common Spatial Pattern, CSP)^[7]等。其中,CSP方法提取的EEG空域特征具有较高区分度^[8],在EEG信号分类中应用广泛^[9-12]。但由于MI-EEG具有被试特异性和强节律的特点^[13],不同个体的最佳频-时-空参数受自身内外因素的影响,差异性较大,因此,要获

【收稿日期】2023-06-05

【基金项目】国家重点研发计划(2018YFC0807903)。

【作者简介】吴叶兰,硕士,副教授,主要研究方向:机器人视觉、高光谱检测, E-mail: wuyel@th.btbu.edu.cn

得好的空域特征需针对被试特异性并结合频域信息。耿雪青等^[14]提出人工蜂群优化的EEG信号分类方法,针对不同被试,对空域特征提取参数和分类器超参数进行优化。汲继跃等^[15]提出最优区域的CSP方法,根据方差比筛选出适用于被试者的电极区域。Qi等^[16]提出基于时空滤波的通道选择方法,挑选出适用于不同个体的最佳通道集。上述研究从空域角度进行自适应调整,但忽略了节律的重要性。

本文针对MI-EEG信号个体差异性大,对MI-EEG节律特性利用不充分等问题,提出一种节律自适应的空域特征提取方法:利用免疫粒子群优化(Immune Particle Swarm Optimization, IPSO)算法,对滤波器组共空间模式(Filter Bank Common Spatial Pattern, FBCSP)中的频带和空域特征提取参数同时进行优化,自适应搜索适用于被试者的最佳频带和空域特征提取参数,实现对不同被试的有效特征表征,用支持向量机(SVM)完成分类,最后与其它算法进行比较,验证本文方法的有效性。

1 数据集与预处理

实验数据为BCI-IV Dataset 2a和BCI-III Dataset 3a 4分类(左手、右手、双脚、舌头)运动想象数据集。

BCI-IV Dataset 2a 包含 9 名受试者(编号 A01~A09),每名被试共进行 576 次运动想象任务,每次任务持续 8 s,第 2~0 s 为任务预警时间,第 0~4 s 为运动想象时间,第 4~6 s 为被试休息时间(图 1)。共采集 22 个通道的 EEG 信号,采样频率为 250 Hz,采集后进行 0.5~100 Hz 带通滤波和 50 Hz 陷滤波。




图1 BCI-IV Dataset 2a 实验范式

Figure 1 BCI-IV Dataset 2a experimental paradigm

BCI-III Dataset 3a 包含 3 名受试者(编号 K3b、K6b、L1b),K3b 包含 360 组样本,其余被试包含 240 组样本。每次任务想象时长持续 4 s,采样频率为 250 Hz,共采集 60 个通道的 EEG 信号。为与 BCI-IV Dataset 2a 数据集通道数量一致,选用靠近头皮中部的 22 个电极(图 2)。

两组数据集进行缺失值 0 填充、4 s 想象时间截取预处理操作,训练集和测试集划分为 8:2。




图2 BCI-III Dataset 3a 电极通道

Figure 2 BCI-III Dataset 3a electrode channel

2 研究方法

2.1 FBCSP

FBCSP 用于提取 EEG 的空域特征。用因果切比雪夫 II 型滤波器将 MI-EEG 信号分解为 n 个固定子频带。对每个子频带,计算各类运动想象任务的协方差矩阵 $R_{x|c_i}$:

$$R_{x|c_i} = \frac{x_i x_i^T}{\text{trace}(x_i x_i^T)} \quad (1)$$

其中, x 是 $N \times TN \times T$ 的 EEG 信号, N 为通道数, T 为采样点, $c_i (i = 1, 2, 3, 4)$ 代表 4 类想象任务, x_i 为第 i 类任务对应的 EEG 信号, trace 为矩阵的迹。计算混合空间协方差矩阵 \bar{R} , $\bar{R}_{x|c_i}$ 代表第 i 类任务中所有样本的平均协方差矩阵:

$$\bar{R} = \bar{R}_{x|c_1} + \bar{R}_{x|c_2} + \bar{R}_{x|c_3} + \bar{R}_{x|c_4} \quad (2)$$

对 \bar{R} 进行奇异值分解,得到白化矩阵 P 。将 4 类运动想象信号中的 1 类视作单独一类,其余 3 类视作另一类。以 $i = 1$ 为例,两个新类记作 \bar{R}_1 和 \bar{R}'_1 :

$$\bar{R}_1 = \bar{R}_{x|c_1} \quad (3)$$

$$\bar{R}'_1 = \bar{R}_{x|c_2} + \bar{R}_{x|c_3} + \bar{R}_{x|c_4} \quad (4)$$

利用白化矩阵 P 对两个新类 \bar{R}_1 和 \bar{R}'_1 进行白化变换后,求其特征值 V_1 和特征向量矩阵 U_1 ,取前 m 个特征向量构成新矩阵 U ,计算滤波器投影矩阵 $W_1 = U^T P$ 。以此类推,得到 4 组投影矩阵,构成最终空域滤波器 $W = [W_1, W_2, W_3, W_4]$ 。利用矩阵 W 对信号 x 投影,计算方差比,得到空域特征,将 n 个频带的空域特征拼接,形成特征矩阵 $F = [f_1, \dots, f_j, \dots, f_{4 \times m \times n}]$ 。计算特征向量 f_j 与标签列 C 的互信息,选择 k 个互信息最大的特征列,形成最终空域特征集 $S = \{f_j\}, j = 1, \dots, k$ 。

原始 FBCSP 由空间滤波器 W 对多个固定频带的 EEG 进行空域滤波获得空域特征,即用固定的节律

和空域特征提取参数 m, k , 没有考虑被试在频、空域的特异性。由于 m 是构成空间滤波器 W 的关键, k 决定了特征数量, 如果 m 和 k 过大, 保留的空间信息多, 冗余信息也越多, 如果 m 和 k 过小, 则保留的空间信息少, 会降低空域特征的可分性^[17]。因此, 需要对频带和空域特征提取参数 m 和 k 进行寻优, 得到频带和 m, k 的最优值。

2.2 IPSO 算法

免疫算法 (Immune Algorithm, IA) 是受生物免疫系统启发形成的智能搜索算法, 具备全局搜索的能力^[18]。粒子群优化算法 (Particle Swarm Optimization, PSO) 源于鸟群觅食行为, 它根据自身和群体的搜索经验, 向最优解的方向进化^[19]。本文设计了一种 IPSO 算法以挑选出适合被试者的多个节律和空域特征提取参数: 在 IA 的变异部分引入粒子群更新公式, 取代原始的随机扰动变异方式, 在抗体刷新部分用优化目标代替亲和度, 评价抗体质量, 完成对 FBCSP 方法中的频带、空域特征提取参数 m, k 的寻优, 解决被试特异性问题, 具体步骤如下所示。

Step1: 初始化迭代次数 $G = 30$, 抗体数量 $N = 60$, 抗体 $Q = \{q_1, \dots, q_i, \dots, q_N\}$, 抗体速度 $V = \{v_1, \dots, v_i, \dots, v_N\}$, 其中, $q_i = \{q_i^0, q_i^1, q_i^2, q_i^3, q_i^4\}$ 为需要搜索的频、空参数。对应含义如表 1 所示, $v_i = \{v_i^0, v_i^1, v_i^2, v_i^3, v_i^4\}$ 为各元素对应的速度, 限定范围为 $[-5, 5]$ 。

表 1 抗体元素
Table 1 Antibody elements

特征	q_i^0	q_i^1	q_i^2	q_i^3	q_i^4
名称	m	k	起始频带 l	频带宽度 w	频带个数 n
范围	[1, 22]	[2, 4 mn]	[4, 36]	[2, 6]	[1, 9]

Step2: 将抗体 q_i 带入到 FBCSP 中, 进行特征提取, 并用 SVM 分类, 计算适应度值 fitness。fitness 为优化目标, 即分类准确率, N 为分类样本总数, m_{ii} 为正确分类到第 i 类的样本数。

$$\text{fitness} = \frac{\sum_{i=1}^4 m_{ii}}{N}$$

(5)

Step3: 判断是否满足迭代终止条件, 若满足则终止程序, 输出最优适应度值 fitness 对应的抗体, 即频空参数 $q_i = [m, k, l, w, n]$, 否则继续执行 Step4。

Step4: 将抗体按照适应度值 fitness 从大到小排序, 对排序靠前的 1/2 抗体克隆, 选取适应度值排名第一的抗体作为当前最优解 q_{best} 。

Step5: 对克隆抗体变异, 利用当前最优解 q_{best} 计算粒子群速度更新公式 (6), 然后计算粒子群位置更新公式 (7), 使抗体向最优解方向变异。其中, ω 为惯性因子, 设置为 0.8, c_2 为学习因子, 设置为 1.8, r_2 为 $[0, 1]$ 之间的随机数。

$$v_i(t+1) = \omega v_i(t) + c_2 r_2 [q_{\text{best}} - q_i(t)]$$

(6)

$$q_i(t+1) = q_i(t) + v_i(t+1)$$

(7)

Step6: 刷新种群, 重新初始化 $N/2$ 个抗体, 合并 Step5 中适应度值靠前的 1/2 抗体, 返回 Step2。

2.3 节律自适应的空域特征提取方法

基于节律自适应的 MI-EEG 空域特征提取方法总体实现流程如图 3 所示。模型训练阶段, 利用 IPSO 算法初始化 N 组频、空参数集 q_i , 通过 FBCSP 算法提取多个节律下的初始空域特征集, 利用 SVM 进行特征分类, 计算分类准确率, 通过对免疫粒子群迭代, 用分类准确率评价频、空参数集 q_i 的质量, 对 q_i 筛选、进化获得最优频、空参数 q_{best} , 得到契合被试的多个节律下的空域特征。模型测试阶段, 用 SVM 进行特征分类, 得到最终分类结果。

3 结果与分析

3.1 频-空参数优化的特征提取结果与分析

为验证方法的有效性, 对所述的两个数据集进行特征提取和分类, 分类器为高斯核 SVM。两组数据集的搜寻效果和分类结果如表 2 所示。可以看出, 该方法针对不同被试特点, 对节律和空域特征提取参数做出了自适应调整, 不同被试者寻优得到的最优频、空参数不同, 体现了不同被试者之间的差异性。

研究表明, EEG 信号主要为 4~40 Hz, 当受试者进行运动想象时, mu 节律 (8~12 Hz) 产生于感觉运动区, 出现减小或消失现象, 当受试者处于专注状态时, beta 节律 (13~30 Hz) 发生在顶叶和额叶^[20]。表 2 中, 总体频率范围都集中在 4~40 Hz。A01、A02、A04、A05、A07、A08、A09、K6b、L1b 被试者获得的频带完全覆盖了 mu 节律, A03、A06、K3b 被试者获得的频带覆盖了部分 mu 节律, 对于 beta 节律, 12 名被试均完全包含或部分包含该节律, 符合 EEG 信号的节律特性。对于多数被试, 获得的频带个数较多, 表明从多个频带中进行特征提取能更好地表征 MI-EEG 信号。

表 2 中 BCI-IV Dataset 2a 和 BCI-III Dataset 3a 数据集的平均准确率达到 85.49%, Kappa 系数达到 0.806。观察单个被试的分类效果, BCI-IV Dataset 2a 和 BCI-III Dataset 3a 数据集单个被试的最高准确率

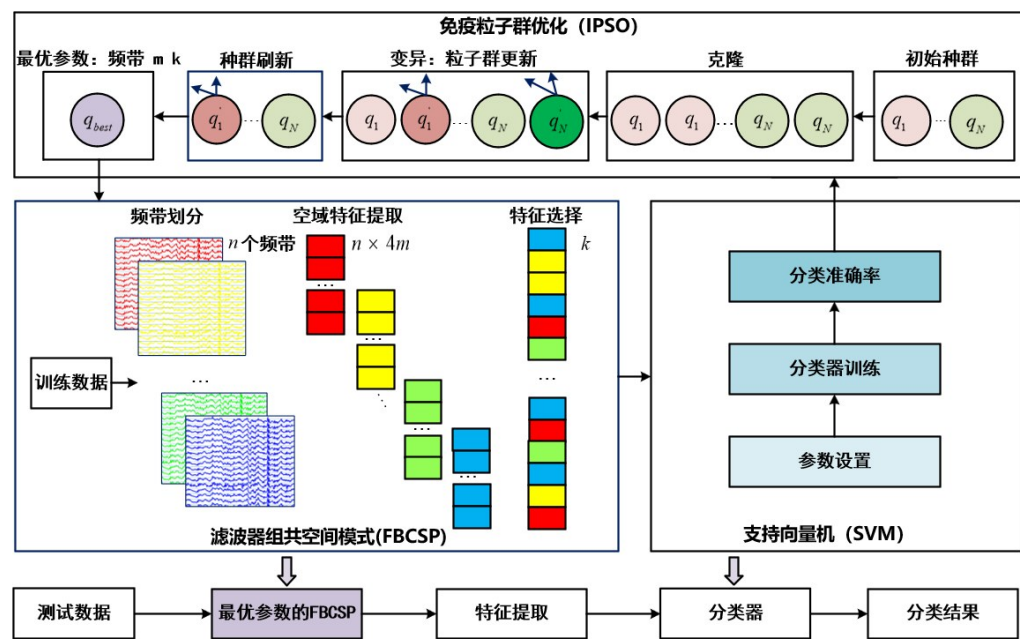


图3 总体实现流程
Figure 3 Overall implementation process

表2 BCI-IV Dataset 2a、BCI-III Dataset 3a数据集频-空参数优化的空域特征分类效果
Table 2 IPSO optimized spatial feature classification results on BCI-IV Dataset 2a and BCI-III Dataset 3a

被试者	频率范围	<i>m</i>	<i>k</i>	准确率%	Kappa 系数
A01	4~8 Hz、6~10 Hz、8~12 Hz、10~14 Hz、12~16 Hz、14~18 Hz、16~20 Hz、18~22 Hz、20~24 Hz	22	100	88.79	0.850
A02	4~10 Hz、8~14 Hz、12~18 Hz、16~22 Hz、20~26 Hz、24~30 Hz、28~34 Hz、32~38 Hz	10	251	70.68	0.609
A03	9~13 Hz、11~15 Hz	19	79	92.24	0.896
A04	6~12 Hz、10~16 Hz、14~20 Hz、18~24 Hz、22~28 Hz、26~32 Hz	9	140	82.75	0.770
A05	4~10 Hz、8~14 Hz、12~18 Hz、16~22 Hz、20~26 Hz、24~30 Hz、28~34 Hz、32~38 Hz	22	338	82.75	0.770
A06	9~14 Hz、12~17 Hz、15~20 Hz、18~23 Hz、21~26 Hz、24~29 Hz	11	194	68.10	0.574
A07	4~10 Hz、8~14 Hz、12~18 Hz、16~22 Hz、20~26 Hz、24~30 Hz、28~34 Hz、32~38 Hz	2	42	94.82	0.931
A08	4~10 Hz、8~14 Hz、12~18 Hz、16~22 Hz	22	80	89.65	0.862
A09	4~8 Hz、6~10 Hz、8~12 Hz、10~14 Hz、12~16 Hz、14~18 Hz、16~20 Hz、18~22 Hz、20~24 Hz	8	211	85.34	0.804
K3b	11~16 Hz、14~19 Hz、17~22 Hz、20~25 Hz、23~28 Hz、26~31 Hz、29~34 Hz、32~37 Hz	6	114	100.0	1.000
K6b	4~10 Hz、8~14 Hz、12~18 Hz、16~22 Hz、20~26 Hz、24~30 Hz、28~34 Hz、32~38 Hz	22	120	83.33	0.777
L1b	4~10 Hz、8~14 Hz、12~18 Hz、16~22 Hz、20~26 Hz、24~30 Hz、28~34 Hz、32~38 Hz	2	25	87.50	0.833
平均值				85.49	0.806

分别达到 94.82% 和 100%, 但仍有被试者准确率较低, 如 A06 分类准确率仅为 68.10%。因此, 利用事件相关去同步 (Event-Related Desynchronization, ERD) 和事件相关同步 (Event Related Synchronization, ERS) 现象进一步分析被试信号特性。研究表明, 想象左手、右手、双脚、舌头运动时, C3、Cz、C4 通道会产生如表 3 所示的 ERD/ERS 现象^[1, 21], 可用来区分运动想象任务。

使用 Pfurtscheller 等^[22]提出的方法绘制 A03、

表3 不同任务ERD/ERS现象
Table 3 ERD/ERS phenomenon for different tasks

通道	左手	右手	双脚	舌头
C3	ERS	ERD	ERS	ERS
Cz	-	-	ERD	ERS
C4	ERD	ERS	ERS	ERS

A06 的 ERD/ERS 特性曲线, 如图 4 所示, 横轴 0 刻度 (0 s) 左侧为休息和任务预警时间, 右侧为任务提示

和运动想象时间。当纵轴数值高于刻度0表明发生ERS现象,低于刻度0表明发生ERD现象。图4a为被试A03的ERD/ERS特性曲线,可以看出,在运动想象期间,其左手、右手、舌头运动满足ERD/ERS特性,

识别效果较好;图4b为被试A06的ERD/ERS特性曲线,仅双脚运动符合ERD/ERS特性,识别效果较差,分析原因可能是运动想象不集中导致。

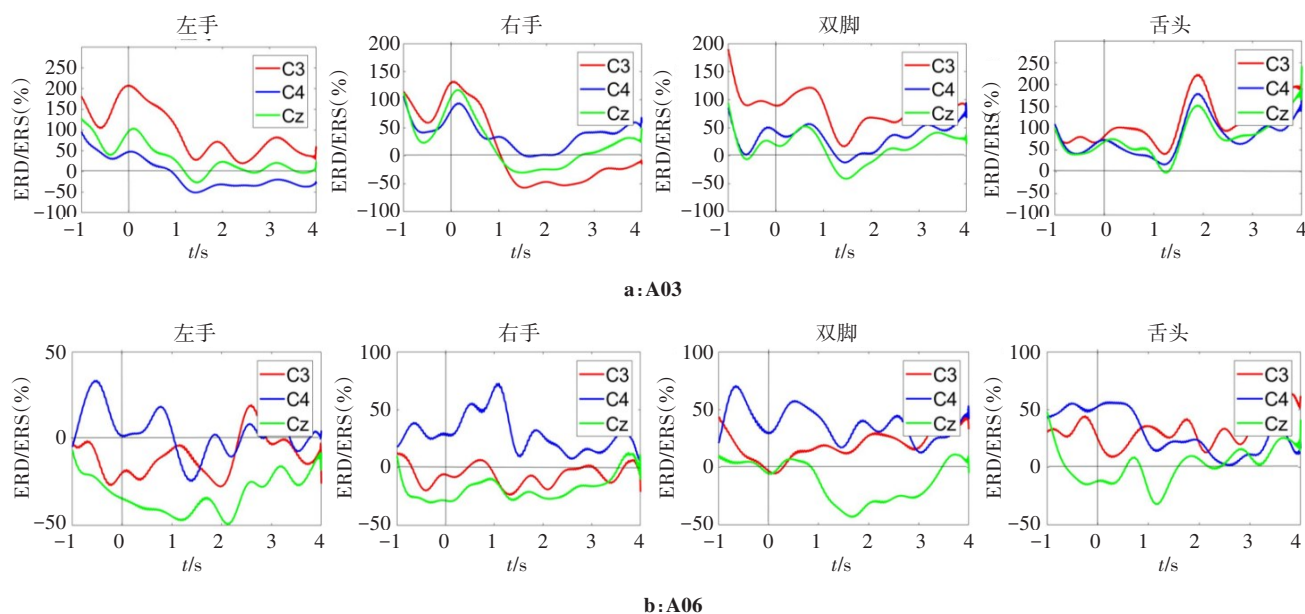


图4 ERD/ERS特性曲线

Figure 4 ERD/ERS characteristic curves

3.2 分类结果对比分析

在相同的预处理条件下,将本文方法与CSP^[7]、FBCSP^[23]、Shallow ConvNet^[24]、EEGNet^[25]算法进行对比,用平均准确率和Kappa系数来评价模型性能,如表4所示。可以看出,本文方法优于其他方法。本文方法相较于CSP方法,准确率和Kappa系数分别提升18.16%和0.242,这是由于CSP仅提取单个频带的空域特征,没有考虑频带对特征质量的影响,获得特征较差。本文方法相比于FBCSP方法,准确率和Kappa系数分别提升10.84%和0.145,这是由于FBCSP方法虽然进行了多频带划分,但是没有针对被试特异性选择适合的频、空参数。本文方法相比于EEGNet、Shallow ConvNet端到端深度学习模型,准确率分别提升9.53%、4.46%,Kappa系数分别提升0.127和0.063,由于MI-EEG信噪比低、数据量小,即使是具有强特征提取能力的深度学习模型,也很难在没有手工提取特征的情况下,从少量样本中自主获取高质量特征。由此表明,本文提出的节律自适应空域特征提取方法,充分利用MI-EEG的强节律特点和空域特征良好的可分性,用寻优的方式挑选出了适合被试的频、空参数,解决了被试特异性问题,提取出适合被试者的空域特征,从而得到较好的分类结果。

为进一步分析改进后模型对4类运动想象信号各自的分类效果,给出总体混淆矩阵,同时与改进前的FBCSP方法混淆矩阵对比。如图5所示,坐标轴LH、RH、F、T分别代表左手、右手、双脚、舌头4种运动想象任务。BCI-IV Dataset 2a数据集中,改进后的方法各类别分类准确率均有提升;BCI-III Dataset 3a数据集中,左手任务准确率没有提升,但其他任务提升较为明显,尤其在双脚和舌头类别中,准确率提升了16.67%和19.05%。

为验证提出的IPSO方法的性能,绘制进化过程,并与IA、PSO两种方法对比。如图6所示,横轴为进化次数,纵轴为每次进化所得的当前最优适应度值。在12名被试中,仅A06、A09、K3b、L1b 4人使用IPSO方法的准确率与其他两种方法持平,其余被试的最终结果均优于其他两种寻优方法,多数情况下,IPSO方法的收敛速度略快于其他两种方法。结果表明,对于本文的寻优问题,用优化目标取代亲和度来评价抗体解的质量可得到更好的频、空参数,并且对于大多数被试有效。

4 结论

为解决多类MI-EEG识别准确率低的问题,从

表 4 不同方法对比
Table 4 Comparison among different methods

被试者	本文方法		CSP+SVM		FBCSP+SVM		EEGNet		Shallow ConvNet	
	准确率%	Kappa 系数	准确率%	Kappa 系数	准确率%	Kappa 系数	准确率%	Kappa 系数	准确率%	Kappa 系数
A01	88.79	0.850	78.44	0.712	84.48	0.793	85.35	0.804	87.93	0.839
A02	70.68	0.609	55.17	0.402	56.89	0.425	50.00	0.333	63.79	0.517
A03	92.24	0.896	81.03	0.747	86.20	0.816	93.96	0.919	93.10	0.908
A04	82.75	0.770	47.41	0.298	62.06	0.494	69.82	0.597	72.41	0.632
A05	82.75	0.770	42.24	0.229	61.20	0.482	48.27	0.310	76.72	0.689
A06	68.10	0.574	51.72	0.356	56.03	0.413	62.93	0.505	63.78	0.517
A07	94.82	0.931	82.75	0.770	89.65	0.862	86.27	0.816	93.96	0.919
A08	89.65	0.862	77.58	0.701	81.89	0.758	83.62	0.781	87.93	0.839
A09	85.34	0.804	71.55	0.620	79.31	0.724	86.20	0.816	80.74	0.743
K3b	100.0	1.000	93.05	0.907	90.27	0.870	97.22	0.962	95.83	0.944
K6b	83.33	0.777	58.33	0.444	68.75	0.583	66.67	0.555	68.75	0.583
L1b	87.50	0.833	68.75	0.583	79.16	0.722	81.25	0.750	87.50	0.786
平均值	85.49	0.806	67.33	0.564	74.65	0.661	75.96	0.679	81.03	0.743

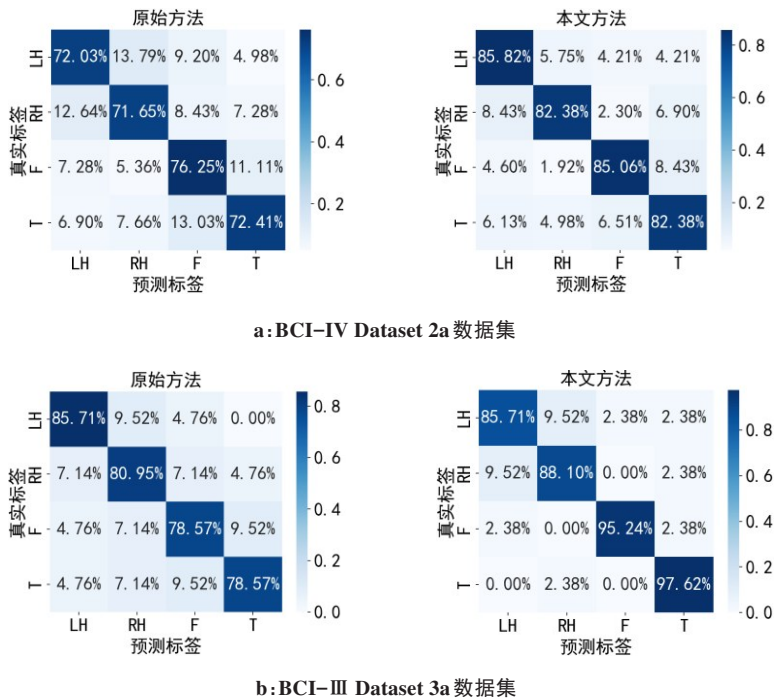


图 5 总体混淆矩阵
Figure 5 Overall confusion matrix

EEG 信号的被试特异性入手,充分利用强节律特点,提出节律自适应的空域特征提取方法。以分类准确率为评价指标,用 IPSO 寻优算法自适应搜寻特征提取过程中涉及到的频、空参数,获取最优节律和空域特征提取参数下的 FBCSP 空域特征,最终在 BCI-IV Dataset 2a、BCI-III Dataset 3a 上的平均分类准确率达

到 85.49%。实验结果表明,本文方法充分考虑了 MI-EEG 在频、空域的被试特异性和节律对特征质量的影响,提取的空域特征更加有效。目前,算法在个别受试者上的准确率仍较低,模型的泛化能力需进一步提高,将在后续工作中继续研究和改进。

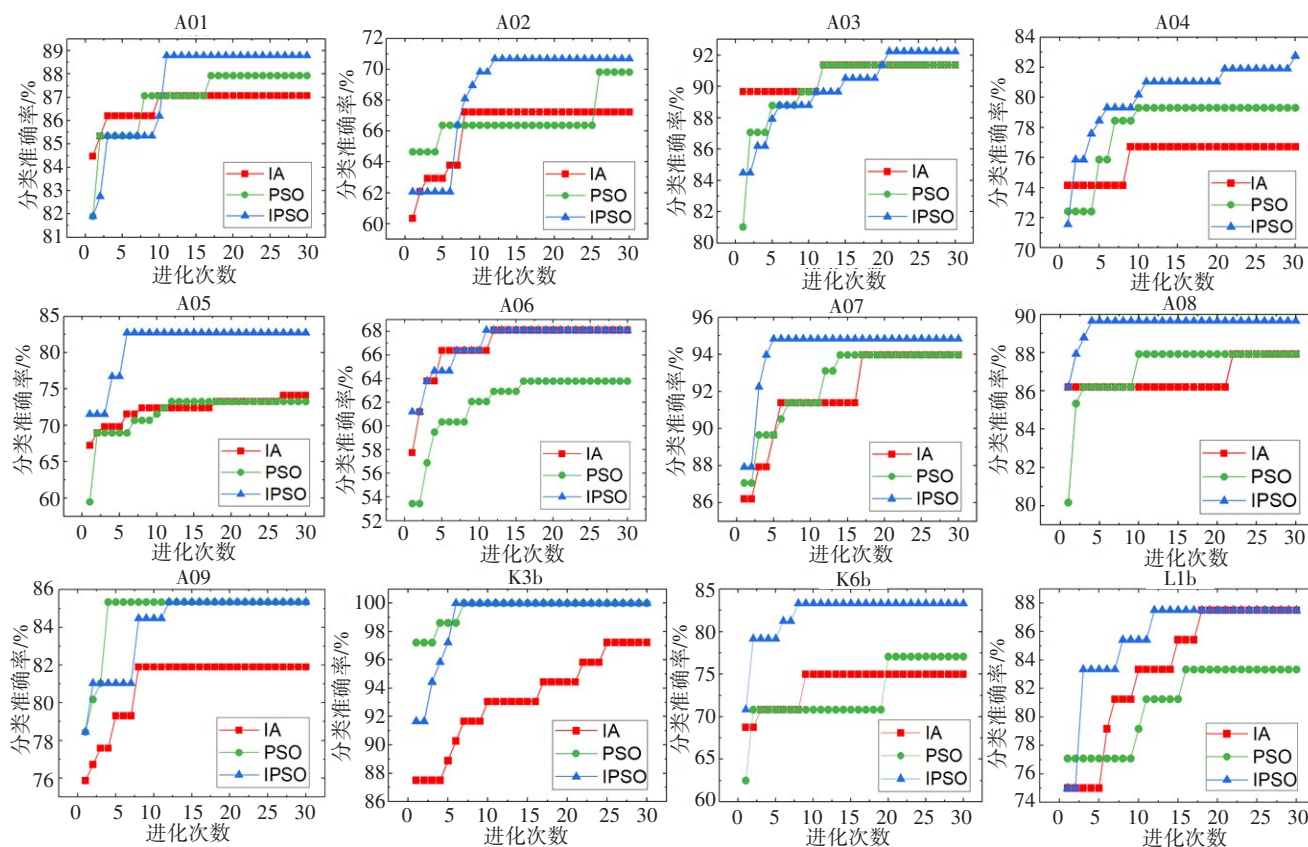


图6 不同寻优算法进化过程

Figure 6 Evolution process of different optimization algorithms

【参考文献】

- [1] 高上凯, 吕宝粮, 张丽清, 等. 脑-计算机交互研究前沿[M]. 上海: 上海交通大学出版社, 2019.
Gao SK, Lü BL, Zhang LQ, et al. Advances in Brain-Computer Interaction [M]. Shanghai: Shanghai Jiao Tong University Press, 2019.
- [2] 王行愚, 金晶, 张宇, 等. 脑控: 基于脑-机接口的人机融合控制[J]. 自动化学报, 2013, 39(3): 208-221.
Wang XY, Jing J, Zhang Y, et al. Brain control: human-computer integration control based on brain-computer interface [J]. Acta Automatica Sinica, 2013, 39(3): 208-221.
- [3] Seidi M, Karwowski W, Farahan FV, et al. Neural decoding of EEG signals with machine learning: a systematic review [J]. Brain Sci, 2021, 11(11): 1525.
- [4] Nicolas-Alonso LF, Corralejo R, Gomez-Pilar J, et al. Adaptive semi-supervised classification to reduce intersession non-stationarity in multiclass motor imagery-based brain-computer interfaces [J]. Neurocomputing, 2015, 159(2): 186-196.
- [5] Yücelba C, Cüneyt S, Yücelba S, et al. Automatic detection of sleep spindles with the use of STFT, EMD and DWT methods[J]. Neural Comput Appl, 2016, 29(8): 17-33.
- [6] 孙会文, 伏云发, 熊馨, 等. 基于HHT运动想象脑电模式识别研究[J]. 自动化学报, 2015, 41(9): 1686-1692.
Sun HW, Fu YF, Xiong X, et al. Identification of EEG induced by motor imagery based on hilbert-huang transform[J]. Acta Automatica Sinica, 2015, 41(9): 1686-1692.
- [7] Xygonakis I, Athanasiou A, Panria N, et al. Decoding motor imagery through common spatial pattern filters at the EEG source space[J]. Comput Intell Neurosci, 2018. Doi: 10.1155/2018/7957408.
- [8] Ma Z, Wang K, Xu M, et al. Transformed common spatial pattern for motor imagery-based brain-computer interfaces[J]. Front Neurosci, 2023, 17: 1116721.
- [9] Chen JX, Jiang DM, Zhang YN. A common spatial pattern and wavelet packet decomposition combined method for EEG-based emotion recognition[J]. Journal of Advanced Computatioanl Intelligence and Intelligent Informatics, 2019, 23(2): 274-281.
- [10] Zhang RL, Zong Q, Dou LQ, et al. A novel hybrid deep learning scheme for four-class motor imagery classification[J]. J Neural Eng, 2019, 16(6): 066004.
- [11] Zahid SZ, Aqil M, Tufail M, et al. Online classification of multiple motor imagery tasks using filter bank based maximum-a-posteriori common spatial pattern filters[J]. IRBM, 2020, 41(3): 141- 150.
- [12] Mishuhina V, Jiang X. Complex common spatial patterns on time-frequency decomposed EEG for brain-computer interface[J]. Pattern Recognition, 2021, 115(1): 107918.
- [13] Sadaf K, Mehrnoosh N, Morteza F, et al. A comprehensive review of the movement imaginary brain-computer interface methods: Challenges and future directions[M]. Artificial Intelligence-Based Brain-Computer Interface. Academic Press, 2022: 23-74.
- [14] 耿雪青, 余青山, 韩笑, 等. 基于人工蜂群优化高斯过程的运动想象脑电信号分类[J]. 传感技术学报, 2017, 30(3): 378-384.
Geng QX, She QS, Han X, et al. Classification of motor imagery EEG based on gaussian process optimized with artificial bee colony[J]. Journal of Transduction Technology, 2017, 30(3): 378-384.
- [15] 汲继跃, 余青山, 张启忠, 等. 最优区域共空间模式的运动想象脑电信号分类方法[J]. 传感技术学报, 2020, 33(1): 34-39.
Ji JY, She QS, Zhang QZ, et al. Optimal region common spatial pattern for motor imagery EEG classification[J]. Journal of Transduction

- Technology, 2020, 33(1): 34-39.
- [16] Qi FF, Wu W, Yu ZL, et al. Spatio-temporal filtering-based channel selection for single-Trial EEG classification[C]//IEEE Trans Cybern, 2021, 51(2): 558-567.
- [17] 褚亚奇, 朱波, 赵新刚, 等. 基于时空特征学习卷积神经网络的运动想象脑电解码方法[J]. 生物医学工程学杂志, 2021, 38(1): 1-9.
Chu YQ, Zhu B, Zhao XG, et al. Convolutional neural network based on temporal-spatial feature learning for motor imagery electroencephalogram signal decoding [J]. Journal of Biomedical Engineering, 2021, 38(1): 1-9.
- [18] 卢彬炜, 闫光辉, 罗浩, 等. 基于多粒子随机游走免疫算法[J]. 武汉大学学报(理学版), 2022, 68(3): 289-296.
Lu BW, Yan GH, Luo H, et al. An immune algorithm based on multi-particle random walk [J]. Journal of Wuhan University (Natural Science Edition), 2022, 68(3): 289-296.
- [19] Xiao YC, Kang N, Hong Y, et al. Misalignment fault diagnosis of DFWT based on IEMD energy entropy and PSO-SVM[J]. Entropy, 2017, 19(1): 6.
- [20] Rajesh PN. 脑机接口导论[M]. 北京: 机械工业出版社, 2016.
- Rajesh PN. Brain-computer interfacing: an introduction[M]. Beijing: China Machine Press, 2016.
- [21] 王盛玉. 多任务运动想象脑-机接口的识别方法研究[D]. 北京: 北京交通大学, 2020.
Wang SY. Recognition method of multi-task motor imagery for brain-computer interface[D]. Beijing: Beijing Jiaotong University, 2020.
- [22] Pfurtscheller G, da Silve FH. Event-related EEG/MEG synchronization and desynchronization: basic principles[J]. Clin Neurophysiol, 1999, 110(11): 1842-1857.
- [23] Kai KA, Zhang YC, Wang CC, et al. Filter bank common spatial pattern algorithm on BCI competition IV datasets 2a and 2b[J]. Front Neurosci, 2012, 6: 39.
- [24] Schirrneister RT, Springenberg JT, Fiederer LD, et al. Deep learning with convolutional neural networks for EEG decoding and visualization[J]. Hum Brain Mapp, 2017, 38(11): 5391-5420.
- [25] Lawhern VJ, Solon AJ, Waytowich NR, et al. EEGNet: a compact convolutional neural network for EEG-based brain-computer interfaces [J]. J Neural Eng, 2018, 15(5): 056013.

(编辑: 薛泽玲)