

基于解空间收缩的差分进化算法的 CLAD 序列优化

黄江华, 李 彬, 王 涛

(南方医科大学生物医学工程学院, 广东广州 510515)

摘 要: 连续循环平均去卷积(Continuous Loop Averaging Deconvolution, CLAD)方法是近年来提出的高刺激率条件下提取听觉诱发电位(Auditory Evoked Potential, AEP)的有效方法. 该方法对刺激序列的频域特性提出限制, 给刺激序列的生成带来挑战. 本文在差分进化(Differential Evolution, DE)算法的基础上, 提出一种解空间收缩的差分进化(solution-space contraction DE, scDE)算法; 该算法将刺激序列的频域约束和抖动量融合成一个单目标优化函数. 根据抖动量的变化范围, 提出新的变异算子, 在维持种群多样性的同时保证搜索空间动态缩减从而生成有序性的最优刺激序列. 该方法可以自动地生成各种参数下的低抖动率刺激序列, 和传统随机生成序列人工筛选方式相比在保证噪声抑制能力的同时工作效率大大提高且抖动率更小.

关键词: 差分进化算法; 去卷积; 听觉诱发电位

中图分类号: R318 **文献标识码:** A **文章编号:** 0372-2112 (2014)08-1571-06

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2014.08.017

Optimization of CLAD Sequences Based on Solution-Space Contraction Strategy for Differential Evolution Algorithm

HUANG Jiang-hua, LI Bin, WANG Tao

(School of Biomedical Engineering, Southern Medical University, Guangzhou, Guangdong 510515, China)

Abstract: Continuous loop averaging deconvolution (CLAD) is a newly developed method to recover the transient auditory evoked potential (AEP) from responses evoked by high stimulus rate sequences. This method brings forward a challenge in the generation of an appropriate stimulus sequence which will affect the deconvolution performance. We proposed a variant of differential evolution (DE) algorithm, namely solution-space contraction differential evolution (scDE) algorithm to optimize the sequence associated with an objective function defined in terms of the jitter ratio (JR) and the constraint condition in frequency domain. A dynamic scaling factor F in the mutation process was formulated to guarantee the gradual reduction of the searching-space. The scDE algorithm can be efficient in generating required sequences under various conditions with lower JR. This study is thus significant in promoting the application of CLAD method in basic and clinical research.

Key words: differential evolution (DE) algorithm; deconvolution; auditory evoked potential (AEP)

1 引言

重复性短声刺激提取听觉诱发电位(Auditory Evoked Potential, AEP)是临床上常用的评估听觉神经系统功能的方法. 当刺激率提高, 就会出现相邻刺激诱发的反应首尾重叠现象, 可视为单个刺激声所诱发的暂态 AEP 与刺激序列的循环卷积效应. CLAD (Continuous loop averaging deconvolution) 是一种恢复暂态 AEP 的有效方法^[1-3]. 该方法利用刺激序列的抖动(Jitter)信息, 避免去卷积过程中奇异值影响.

脑电信号的信噪比较小, CLAD 方法中如果刺激序列满足一定的频域约束条件, 可以避免噪声的放大效应^[4]. 约束条件和序列的抖动率相互制约, 抖动越小, 满足约束条件越困难. 因此在生成刺激序列时需要均衡这两者的影响. 虽然我们可以通过频域分析判断一个序列在抑制噪声方面的性能, 但是在实际应用中如何生成满足一定约束条件的优化序列是更加困难和亟待解决的问题.

CLAD 序列的生成是一个非线性的全局优化问题. 传统的优化算法利用单个初始点及所在点的导数等局

部信息实现局部优化,无法避免局部极小的问题,且主要面向线性空间优化.由于 CLAD 序列生成优化问题上不存在解析表达式,且组合优化的搜索空间也随刺激个数的增加而急剧增大,采用传统的优化算法或枚举法无法求出最优解.差分进化(Differential evolution)算法是在遗传算法基础上提出的一种全局优化方法^[5,6].它保留了基于种群的全局搜索策略,采用基于种群差异的变异操作和一对一的选择方式,提高了算法的搜索能力,同时避免了遗传算法中变异方式的不足^[7,8].此外,DE 算法初始化参数少,程序简单且特有的记忆性能动态跟踪当前搜索情况,调整搜索策略,具有较强的鲁棒性和全局搜索能力.

本文应用 DE 算法解决 CLAD 序列优化问题,将序列的频域约束和刺激的抖动率结合,构造了含有约束条件的目标函数;并且选择刺激间隔(Inter-Stimulus Interval, ISI)作为优化变量,并根据序列有序性的特点,提出 scDE 算法以提升其优化性能.通过给出四个不同刺激率下具体序列实例,表明 scDE 算法可有效解决 CLAD 序列的优化问题.

2 CLAD 方法及序列的优化问题模型

刺激序列和 AEP 的线性卷积模型可表示为

$$y(t) = s(t) * x(t) \quad (1)$$

其中 $s(t)$ 表示刺激序列, $x(t)$ 表示暂态 AEP, $y(t)$ 表示记录到的脑电信号, t 为时间变量.刺激序列包含 N 个刺激脉冲, $\{t_n, n = 1, 2, \dots, N\}$ 表示了刺激脉冲出现的时刻.由于信号相对于背景噪声十分微弱,采用刺激序列周期性重复作用于听觉系统,以便利用叠加平均技术提高观测信号的信噪比(signal-to-noise ratio, SNR),所以式(1)可表达为

$$y(t) = x(t) \otimes \sum_{n=1}^N \delta(t - t_n) + e(t) \quad (2)$$

\otimes 表示周期性刺激下的循环卷积, $e(t)$ 表示平均后残余的背景噪声.利用傅里叶变换可将上式表示为频域形式(用大写字母表示)

$$Y(f) = X(f)S(f) + E(f) \quad (3)$$

上式两边同时乘以 $S^{-1}(f)$, 则暂态 AEP 的估计为:

$$\hat{X}(f) = Y(f)S^{-1}(f) = X(f) + E(f)S^{-1}(f) \quad (4)$$

上式解存在的一个必要条件是序列刺激间隔存在抖动,即刺激脉冲非均匀分布^[4].另一方面,由于生理系统普遍存在的适应性和非线性,实际应用时要求刺激脉冲应尽可能为等间隔的均匀序列.同样上式表明去卷积过程中噪声带来的误差由 $S^{-1}(f)$ 控制.即如果某些频段的 $|S(f)|$ 趋于零或非常小,则会放大这些频段的噪声成分,导致式(4)解的不稳定.AEP 信号主要集中在某一较窄频带范围内^[9],故在 AEP 信号所在频带

外可以设置滤波器过滤噪声,所在频带范围内通过适当调整刺激脉冲位置,使其满足 $|S(f)| > 1$ 的约束条件,则可以有效地抑制噪声^[10].

2.1 序列的性质

在实际求解计算时,记录的脑电信号和刺激序列都需要经过相同的抽样率做离散处理.这样刺激序列转换为一个由“1”和“0”组成的二值序列(“1”表示刺激脉冲).刺激序列的生成就是在有限的离散区间选择刺激脉冲出现的位置.得到的离散序列用快速傅里叶变换计算其频域表达.这样虽给计算带来便利,但是也给序列生成带来局限.为此 Wang 等提出利用周期性(设周期为 T)连续时间的刺激序列实现去卷积的方案^[11],该方法得到的是一个离散的频域表达形式,即

$$S(kf_0) = \int_{-\infty}^{+\infty} \sum_{n=1}^N \delta(t - t_n) e^{-jk2\pi f_0 t} dt = \sum_{n=1}^N e^{-jk2\pi f_0 t_n} \quad (5)$$

其中 $f_0 = 1/T$, 若感兴趣的频带设置为 $[f_L, f_H]$, 序列约束条件可定义为:

$$R(kf_0) = |S^{-1}(kf_0)| - 1 < 0, kf_0 \in [f_L, f_H] \quad (6)$$

2.2 目标函数

如前所述,CLAD 方法希望刺激序列在满足约束的情况下减少抖动.对于一个时间长度为 T 的刺激序列,我们可以将抖动定义为:

$$x_n = t_n - (n-1)\tau \quad (7)$$

其中 $\tau = T/N$ 为平均刺激间隔;由于序列刺激的有序性,即 $t_N > t_{N-1} > \dots > t_1$, 所以刺激抖动应控制在 $[-\delta, \delta]$ 范围内,其中 $\delta < 0.5\tau$.刺激序列的抖动程度采用抖动率(Jitter-Ratio, JR)来表征:

$$JR = \frac{\max\{|x_1|, |x_2|, \dots, |x_n|\}}{\tau} \quad (8)$$

结合约束条件(7),我们定义如下目标函数:

$$f(x) = JR + \beta \sum_{k=k_L}^{k_H} \max(R(kf_0), 0)^2 \quad (9)$$

其中, $k_L = \text{round}(f_L T)$ 和 $k_H = \text{round}(f_H T)$ 为 f_L 和 f_H 在频域上所对应的索引值. β 为约束加权值,一般取一个足够大的数.该式表示,如果约束条件不满足,目标函数值主要取决于式(9)右边的第二项;当序列满足约束条件时,该项为零,目标函数值等于 JR 值.因此优化过程中,首先通过若干次迭代保证约束条件能够满足,然后逐步减少 JR 值,得到最优序列.

3 解空间收缩的差分进化 (solution-space contraction DE, scDE) 算法

差分进化算法针对种群中的每个个体,首先利用随机选取的其他个体间的差异信息得到试验个体,再将试验个体和该个体按照一定的概率进行交叉操作,

最后以“贪婪”机制选择最优个体^[5-8]. 由于寻优过程中是全局搜索, 应用到局部有序的刺激序列寻优问题上容易破坏序列固有的局部有序性. 此外, 实验表明 DE 算法中的变异算子 F 的选择对算法求解性能有着重要的影响, 传统 DE 算法中常取 $[0, 1]$ 之间的某一值, 0.5 是较常用到的值. 研究者对此已经做了很多方面的工作, 包括采用免比例因子^[14], 或者动态比例因子^[13]等方式.

本文提出 scDE 算法是基于刺激序列自身特性, 采用自适应比例因子 F 的迭代策略实现搜索空间动态收缩, 在保证序列满足约束的前提下获得抖动较小的刺激序列. 其算法流程图如图 1 所示.




图1 scDE算法框图

初始化

在 scDE 算法中实际优化变量是抖动量 $\{x_n \in [-\delta, \delta], n = 1, 2, \dots, N\}$, 将其表示为一个 N 维向量 $\mathbf{X} = [x_1, x_2, \dots, x_N]$. 设种群 (Population Number, NP) 为刺激个数 N 的 P 倍, P 为整数. 则初始化向量为

$$\mathbf{X}_i^{(G)} = [x_{1,i}^{(G)}, x_{2,i}^{(G)}, \dots, x_{N,i}^{(G)}], i = 1, \dots, NP \quad (10)$$

G 表示世代数, 初始化时 $G = 0$. 向量中每个单独个体搜索空间均为 $[-\delta^{(G)}, +\delta^{(G)}]$, 其中

$$\delta^{(G)} = JR^{(G)} \times \tau \quad (11)$$

则优化空间为一个超立方体 $\Omega^{(G)} = [-\delta^{(G)}, +\delta^{(G)}]^N$.

自适应变异策略

对于第 G 代中某一确定的目标向量 $\mathbf{X}_i^{(G)}$, 随机选择三个不同于 $\mathbf{X}_i^{(G)}$ 的个体向量 $\mathbf{X}_{r_1}^{(G)}, \mathbf{X}_{r_2}^{(G)}, \mathbf{X}_{r_3}^{(G)}, r_1 \neq r_2 \neq r_3 \neq i$, 通过变异操作得到变异向量 $\mathbf{V}_i^{(G)}$.

$$\mathbf{V}_i^{(G)} = \mathbf{X}_{r_1}^{(G)} + F(\mathbf{X}_{r_2}^{(G)} - \mathbf{X}_{r_3}^{(G)}) \quad (12)$$

F 为比例因子, 其值越大, 种群趋向于全局探索, 反之, 则有利于局部搜索. 根据式 (11) 搜索空间的定义可知, 目标函数的减小意味着优化变量搜索空间的减小.

为此我们提出自适应变异策略, 这是实现 scDE 算法的关键. 为方便叙述, 该部分暂时省略世代符号 G . 如果限制变异向量 \mathbf{V}_i 在 Ω 范围内, 同时保证差分运算给出的搜索方向不变, 控制目标向量在空间的任一维度 n 上的投影满足如下不等式:

$$-\delta - x_{n,r_1} \leq F_n \Delta x_{n,r_{23}} \leq \delta - x_{n,r_1} \quad (13)$$

其中 $\Delta x_{n,r_{23}} = x_{n,r_1} - x_{n,r_2}$, F_n 是比例因子在该维度上的分量. 在二维情况下上述关系如图 2 所示. 由于 $F_n > 0$, $|x_{n,r_1}| \leq \delta$, 所以若 $\Delta x_{n,r_{23}}$ 为正, 则 F_n 的限制取决于上式右边; 若 $\Delta x_{n,r_{23}}$ 为负, 则 F_n 的限制取决于上式左边;

若 $\Delta x_{n,r_{23}}$ 恰好为零, 则说明 $\Delta x_{n,r_{23}}$ 垂直于当前维, 此时无法由式 (13) 对 F_n 大小做约束限制, 我们设置 $F_n = F_{\max} = 2$. 故 F_n 表达式如下:




图2 2维空间表示scDE算法的变异运算

$$F_n = \begin{cases} (\delta - x_{n,r_1}) / \Delta x_{n,r_{23}}, & \Delta x_{n,r_{23}} > 0 \\ (-\delta - x_{n,r_1}) / \Delta x_{n,r_{23}}, & \Delta x_{n,r_{23}} < 0 \\ F_{\max}, & \Delta x_{n,r_{23}} = 0 \end{cases} \quad (14)$$

由于变异向量 \mathbf{V}_i 在 N 维都需限定在搜索空间内, 所以 F 表达式为

$$F = \min\{F_1, F_2, \dots, F_n\} \quad (15)$$

交叉

变异向量 $\mathbf{V}_i^{(G)}$ 和目标向量 $\mathbf{X}_i^{(G)}$ 按照如下公式进行交叉操作, 从而生成候选向量 $\mathbf{U}_i^{(G)}$.

$$\mathbf{U}_i^{(G)} = u_{n,i}^{(G)} = \begin{cases} v_{n,i}^{(G)}, & \text{rand}[0, 1] \leq CR \text{ or } n = n_{\text{rand}} \\ x_{n,i}^{(G)}, & \text{others} \end{cases} \quad (16)$$

$n_{\text{rand}} \in \{1, 2, \dots, N\}$, 这样可以保证 $\mathbf{U}_i^{(G)}$ 中至少有一维是由 $\mathbf{V}_i^{(G)}$ 提供. CR 为交叉概率因子, 传统 DE 算法中取值为 $[0, 1]$ 之间的随机数. CR 越大, $\mathbf{V}_i^{(G)}$ 对 $\mathbf{U}_i^{(G)}$ 贡献越大, 局部搜索能力强, 有利于加快收敛速度; 反之, $\mathbf{X}_i^{(G)}$ 贡献越大, 有利于保持种群多样性和提高全局搜索能力. 为了增加种群多样性, 有效控制序列收敛速度, 同时避免早熟现象在文中我们采用时变交叉概率因子^[14].

$$CR^{(G)} = CR_{\min} + \frac{(CR_{\max} - CR_{\min}) * G}{G_{\max}} \quad (17)$$

其中, CR_{\max} 和 CR_{\min} 分别为最大和最小交叉概率, 且 $0 < CR_{\min} < CR_{\max} < 1$; G_{\max} 为算法最大迭代次数, G 为当前迭代次数. 迭代过程中 CR 取值由小变大, 初始阶段 $\mathbf{X}_i^{(G)}$ 对 $\mathbf{U}_i^{(G)}$ 贡献多, 提高全局搜索能力; 后期则相反, 提高局部搜索能力.

选择

比较候选向量 $\mathbf{U}_i^{(G)}$ 和目标向量 $\mathbf{X}_i^{(G)}$ 的目标函数, 并选出下一代个体向量.

$$\mathbf{X}_i^{(G+1)} = \begin{cases} \mathbf{X}_i^{(G)} & f(\mathbf{X}_i^{(G)}) \leq f(\mathbf{U}_i^{(G)}) \\ \mathbf{U}_i^{(G)} & f(\mathbf{X}_i^{(G)}) > f(\mathbf{U}_i^{(G)}) \end{cases} \quad (18)$$

当 $\mathbf{U}_i^{(G)}$ 取代 $\mathbf{X}_i^{(G)}$ 成为下一代个体 $\mathbf{X}_i^{(G+1)}$ 时,重新计算下一代 $JR^{(G+1)}$ 以及下一代搜索空间 $\Omega^{(G+1)}$. 随着迭代的进行,目标函数值逐步减小,搜索空间也随之递减.

终止

重复步骤变异、交叉、选择直到满足终止条件. 按照实际操作,文中的终止条件有三种方式:(1)达到预设最大迭代次数 G_{\max} ;(2)达到预设的最优 JR 值;(3)连续若干次迭代 JR 值保持不变. 在本文以下实验验证情况下均选择第三种条件,即连续 500 次迭代目标函数 JR 值保持不变,则迭代终止.

4 实验结果及讨论

4.1 实验结果

Jeweet 等在文献[10]出版的 BMC 网站上提供了附加文件,给出一系列人工优化的 CLAD(文中称为 QSD)序列. 我们选择其中四组序列(见表 1 的 QS1-4),并按照相同初始条件(序列初始时间长度 T_0 、序列包含刺激个数 N 和感兴趣频段 $[f_L, f_H]$)利用 scDE 算法优化得到对应序列,这里称为 DS 序列. 每种初始条件下进行 5 次实验,再选择最优(JR 值最小)一次结果为当前条件下的 DS 序列,如表 1 所示. 由表 1 可看出四组 DS 序列 JR 值均小于 QS 序列. 表 2 为四组最优 DS 序列中刺激出现时刻 t_n 以及序列长度 T .

表 1 相同条件下获得与文献[10]对应序列

Seq. no.	$T_0(\text{ms})$	N	SR (Hz)	$[f_L, f_H]$ (Hz)	$JR(\%)$	
					QS	DS
1	1625	13	8	[5, 132]	12	10.01
2	1545.5	17	11	[5, 120]	11.85	11.60
3	1600	32	20	[9, 122]	11.97	8.00
4	1600	56	35	[12, 129]	11.99	7.91

4.2 迭代过程中目标函数值的变化

优化算法的能力体现在迭代过程中目标函数的减小速度,能够尽快达到目标函数的期望值是优化算法的目的,scDE 算法时间复杂度和传统 DE 算法一样为 $O(NP * N * G_{\max})$. 图 3 为 DS 四组序列优化过程中随着迭代的进行目标函数值变化图. 横轴为迭代次数 G ,用对数形式表示,即 $G' = \log_{10} G$,纵轴为目标函数值 $f(X)$,每种条件下 5 次实验计算结果如图中细虚线表示,粗实线表示 5 次实验结果的趋势拟合线. 可以看出迭代过程中目标函数值会越来越小,但并非突然陡降,而是按照指数函数下降,继而稳定在某一较小数值上.

下降趋势基本符合 $f(X) = ae^{-bG}$ 规律. 四组 DS 序列拟合曲线参数 a 取值分别为 {2799, 3402, 3757, 5575}, 参数 b 取值分别为 {0.02595, 0.03226, 0.07125, 0.06934}, 确定系数 R^2 分别为 {0.9832, 0.9922, 0.9918, 0.9941}. 并且通过多次实验发现,随着序列中包含的刺激个数增多,参数 a 有变大的趋势,参数 b 则无明显规律.

表 2 四组最优 DS 序列

DS ($JR\%$)	Stimulus impulse (t_n in ms); Stimulus duration (T in ms)
DS1 (10.01%)	0, 137.10, 262.76, 378.58, 517.21, 633.76, 748.66, 883.71, 997.11, 1134.73, 1271.86, 1385.26, 1509.19; (1638.20)
DS2 (11.60%)	0, 101.45, 185.37, 285.27, 365.64, 452.37, 543.95, 639.74, 737.61, 817.98, 917.51, 1015.2, 1095.61, 1186.97, 1286.89, 1367.26, 1465.13; (1545.50)
DS3 (8.00%)	0, 51.26, 100.42, 154.02, 207.04, 252.71, 306.32, 351.99, 398.00, 450.76, 500.69, 546.36, 599.96, 648.07, 701.52, 747.19, 800.80, 846.47, 899.98, 945.65, 999.26, 1045.70, 1091.37, 1144.98, 1190.90, 1241.55, 1287.22, 1340.82, 1394.43, 1443.02, 1488.95, 1534.98; (1588.44)
DS4 (7.91%)	0, 31.20, 62.41, 89.07, 120.28, 147.59, 178.80, 205.45, 236.66, 263.33, 294.23, 321.51, 348.17, 379.03, 410.09, 437.65, 464.29, 495.51, 525.87, 556.73, 586.57, 615.05, 645.94, 672.59, 701.12, 730.47, 758.15, 784.81, 816.02, 842.66, 872.25, 900.63, 928.25, 958.14, 989.33, 1015.98, 1043.15, 1074.31, 1100.96, 1132.17, 1159.19, 1187.86, 1217.59, 1246.12, 1272.76, 1303.98, 1330.62, 1361.84, 1392.70, 1419.36, 1450.57, 1477.22, 1508.43, 1535.08, 1561.79, 1593.00; (1620.03)

4.3 迭代过程中搜索空间的变化

scDE 算法采用搜索空间递减的策略. 初始化时随机产生 $N \times NP$ 的矩阵向量 $\mathbf{X}_i^{(G)}$, 向量中每一个具体元素都位于 $[-\delta, \delta]$ 区间. 按照式(11)计算 δ 的初始值,若 $JR^{(G=0)}$ 取值太大,搜索空间变大,获得最优序列时间较长;若取值太小,容易导致迭代过程中难以满足约束条件. 一般取比预期目标值稍微大的数值. 文中希望优化得到序列的 JR 值小于文献[10]所提供序列,所以初始值 $JR^{(G=0)}$ 设置为 0.13,若计算过程中满足约束困难,可适当放宽取值. 变异过程中采用自适应比例因子使变异得到的向量同样位于搜索空间内,在经过交叉选择操作后,生成的序列若目标函数值小于上一代,则用新的 JR 值取缔上一代的 JR ,再按照式(11)重新计算搜索空间. 随着目标函数的不断减小,搜索空间也逐渐减小,从而避免破坏序列的有序性,如后面一个刺激位置超过前一个刺激出现时刻的现象.

图 4 所示为 DS1 序列的 5 次实验过程中搜索空间的动态变化图,初始 δ 值均为 15ms.随着迭代进行,搜索空间先是出现较大幅度的下降,继而较小幅度下降,

最后稳定在某一数值上面.且迭代进行到约 800 次左右进入较平缓状态,此时计算所用时间约为 150ms 左右.




图3 迭代过程中目标函数值动态变化图(5条细虚线表示5次实验结果,粗实线为5次结果的拟合,可用指数函数 $f(X)ae^{-bG}$ 描述)




图4 迭代过程中搜索空间动态变化图

5 总结和展望

当采用 CLAD 方法通过频域滤波技术恢复暂态 AEP 时,刺激序列的频域性质将会影响去卷积过程中暂态 AEP 的恢复效果.一般来说,刺激序列抖动越大,序列越容易满足频域约束条件,噪声抑制能力越强.同时若刺激序列抖动过大会使得每个刺激诱发的 AEP 信号

差异显著从而破坏听觉系统的线性假设模型.均衡上述两者的影响,采用本文提出 scDE 算法可以自动生成抖动较小且满足频域约束的优化刺激序列.在算法中我们以融合约束条件的抖动率 JR 作为优化目标函数,提出一种新的自适应比例因子 F 以保证突变产生的变异个体仍然位于搜索空间范围内.通过搜索空间的动态缩小从而实现目标函数的递减,并且得出目标函数下降符合指数函数规律.通过表 1 的对比可知在相同条件下采用本算法优化得到序列 JR 值明显较低,计算效率也明显高于人工筛选方式.后续工作中将进行更深入实验,选择或设计针对该应用的交叉算子以及初始参数值的设置,使算法准确度和效率更高.

参考文献

[1] Ö Özdamar, J Bohórquez. Signal-to-noise ratio and frequency analysis of continuous loop averaging deconvolution (CLAD) of overlapping evoked potentials[J]. Journal of the Acoustical Society of America, 2006, 119(1): 429 – 438.

- [2] Ö Özdamar, R E Delgado, E Yavuz, et al. Deconvolution of auditory evoked potentials obtained at high stimulus rates [A]. First International IEEE EMBS Conference [C]. USA: IEEE, 2003. 285 – 288.
- [3] R E Delgado, Ö Özdamar. Deconvolution of evoked responses obtained at high stimulus rates [J]. Journal of the Acoustical Society of America, 2004, 115(3): 1242 – 1251.
- [4] D L Jewett, G Caplovitz, B Baird, et al. The use of QSD (q-sequence deconvolution) to recover superposed, transient evoked-responses [J]. Clinical Neurophysiology, 2004, 115(12): 2754 – 2775.
- [5] R Storn, K V Price. Differential evolution-A simple and efficient adaptive scheme for global optimization over continuous spaces [R]. USA: ICSI, Berkeley, 1995.
- [6] R Storn, K V Price. Differential evolution-a simple and efficient heuristic for global optimization over continuous spaces [J]. Journal of Global Optimization, 1997, 11: 341 – 359.
- [7] 刘波, 王凌, 金以慧. 差分进化算法研究进展 [J]. 控制与决策, 2007, 22(7): 721 – 729.
Liu Bo, Wang Ling, Jin Yi-hui. Advances in differential evolution [J]. Control and Decision, 2007, 22(7): 721 – 729. (in Chinese)
- [8] S Das, P N Suganthan. Differential evolution: A survey of the state-of-the-art [J]. IEEE Trans Evol Comput, 2011, 15(1): 4 – 31.
- [9] T W Picton. Human Auditory Evoked Potentials [M]. San Diego: Plural Publishing, 2010. 285 – 333.
- [10] D L Jewett, T Hart, L J Larson-Prior, et al. Human sensory-evoked responses differ coincident with either "fusion-memory" or "flash-memory", as shown by stimulus repetition-rate effects [J]. BMC Neurosci, 2006, 7: 18.
- [11] Tao Wang, Jianghua Huang, Lin Lin, Chang'an Zhan. Continuous and discrete-time stimulus sequences for high stimulus rate paradigm in evoked potential studies [J]. Computational and Mathematical Methods in Medicine, 2013, <http://www.hindawi.com/journals/cmmm/2013/396034/abs/>.
- [12] H K Kim, J K Chong, K Y Park, et al. Differential evolution strategy for constrained global optimization and application to practical engineering problems [J]. IEEE Transactions on Magnetism, 2007, 43(4): 1565 – 1568.
- [13] 张晓伟, 刘三阳. 免比例因子 F 的差分进化算法 [J]. 电子学报, 2009, 36(6): 1318 – 1323.
Zhang Xiao-wei, Liu San-yang. Differential evolution without the scale factor F [J]. Acta Electronica Sinica, 2009, 36(6): 1318 – 1323. (in Chinese)
- [14] 吴亮红, 王耀南, 袁小芳, 等. 自适应二次变异差分进化算法 [J]. 控制与决策, 2006, 21(8): 898 – 902.
Wu Liang-hong, Wang Yao-nan, Yuan Xiao-fang, et al. Differential evolution algorithm with adaptive second mutation [J]. Control and Decision, 2006, 21(8): 898 – 902. (in Chinese).

作者简介



黄江华 女, 1988 年 8 月出生, 重庆忠县人. 现为南方医科大学生物医学工程专业硕士研究生, 主要研究方向为生物电信号处理.

E-mail: jianghua_huang@126.com



李彬 男, 1964 年 3 月出生, 河南焦作人. 教授、博士. 主要研究方向为医学图像处理、优化算法.

E-mail: libin371@smu.edu.cn



王涛(通信作者) 男, 1967 年 6 月出生, 安徽阜阳人, 教授、博士. 主要研究方向为生物医学信号处理、神经工程.

E-mail: taowang@smu.edu.cn