

脑功能光学成像的迭代广义指示函数分析法

黄晓斌¹, 胡德文², 刘亚东², 周宗潭², 万建伟¹, 董国华²

(1 国防科技大学电子科学与工程学院, 湖南长沙 410073 2 国防科技大学机电工程与自动化学院, 湖南长沙 410073)

摘要: 在脑光学功能成像领域, 由 T. Y okoo 等人提出的广义指示函数法 (Generalized Indicator Functions G IF) 能够在极低信噪比下有效地提取大脑行为模式图。但进一步研究发现, 该算法在处理脑功能光学图像序列时存在计算量大的缺点。为解决一问题, 本文将 W eng 等在处理 FERET 人脸数据库时提出的一种迭代算法与 G IF 算法相结合, 给出了一种迭代格式的 G IF 算法——RG IF (Recursive G IF), RG IF 算法利用迭代计算的特点能大幅削减计算量。利用仿真和实验数据对 G IF 和 RG IF 算法进行了对比分析, 结果表明 RG IF 不仅能够大大节省计算时间, 同时检测效果与 G IF 相当。

关键词: 脑光学功能成像; 广义指示函数法; 迭代广义指示函数法

中图分类号: Q632 文献标识码: A 文章编号: 0372-2112 (2006) 04-0664-06

Recursive Generalized Indicator Functions Method for Analyzing the Optical Imaging of Functional Brain

HUANG Xiao-bin¹, HU De-wen², LIU Ya-dong², ZHOU Zong-tan², WAN Jian-wei¹, DONG Guo-hua²

(1. College of Electronics Science and Technology, National University of Defense Technology, Changsha, Hunan 410073, China;

2. College of Mechatronics and Automation, National University of Defense Technology, Changsha, Hunan 410073, China)

Abstract In the analysis of optical imaging of functional brain, the generalized indicator functions (G IF) algorithm presented by T. Y okoo etc. is an efficient method to extract the brain activity map. But further study shows that this algorithm has the shortage of heavy computation in dealing with brain image series. In order to resolve this problem, a recursive G IF (RG IF) algorithm is presented, which is the combination of W eng's recursive algorithm in dealing with the FERET face database and the G IF algorithm, the RG IF algorithm can sharply reduce the computation utilizing the characteristic of recursive algorithm. We compare the G IF and RG IF algorithms using the simulated and experimental datum, the results show that the RG IF algorithm can relieve the computational burden substantially with almost the same computing precision as that with G IF algorithm.

Keywords optical imaging, functional brain, generalized indicator functions, recursive algorithm

1 引言

利用光学功能成像的方法研究在不同刺激下大脑活动的时空模式, 对于深入研究大脑信息加工的过程和机制以及脑的高级功能具有十分重要的意义。实际上, 脑功能图像不仅包含与试验刺激相关的脑神经细胞活动模式, 即行为模式图 (Activity Map), 这相当于有用信号 (Signal), 还包括由呼吸、脉搏等生理活动所引起的信号响应和外界干扰 (如 CCD 噪声), 即背景模式图^[1] (Background Map), 这些相当于噪声 (Noise)。通常, 行为模式图与背景模式图是不相关的, 并且行为模式图与背景模式图的信噪比 SNR

(Signal to Noise Ratio) 为 10^4 量级^[2], 如此低的 SNR 给行为模式图的提取带来极大的困难。为此学者们提出了一系列算法来克服低 SNR 所带来的检测困难, 如比差法^[3] (Difference Image)、主元成分分析法^[4] (Principal Component Analysis; PCA)、指示函数法^[5] (Indicator Functions IF)、截断比差法^[6] (Truncated Difference)、独立成分分析法^[7] (Independent Component Analysis ICA)、扩展空间解相关法^[8] (Extended Spatial De-correlation ESD) 等。由于受到样本数量的局限, 比差法并不能有效的提高信噪比; PCA 方法假定行为模式与样本图像的某个特征模式是完全相关的, 这在许多情况是不成立的; 指示函数方法只能

应用于单一刺激条件, 限制了该方法的推广; ICA 方法通常要假设各个源是完全独立的, 这在极其复杂的脑信息处理过程中还没有得到证实, 因此该方法的应用还处于探索阶段; ESD 是在强化 ICA 应用条件的基础上提出来的, 故也不是一种很成熟的方法。基于以上这些缺点, T Y Okoo 等于 2001 年提出了一种新的方法——广义指示函数法^[9] (Generalized Indicator Functions G IF)。该方法对物理源未做任何约束, 只是借用模式识别领域内的两个优化准则 (类间方差尽量大, 类内方差尽量小), 实验表明该方法能够在极低信噪比下有效地检测行为模式图, 同时还能够应用于多个刺激条件下。但该方法也存在两个明显缺点——计算量大和不能用于在线观测。G IF 的核心运算为求解一个矩阵特征值问题, 其矩阵的维数为图像的像素个数。因此, 即使对于较低分辨率的图像 (如 70×40), 也需要求解一个维数巨大 (2800 维) 的矩阵特征值问题, 另外在某些情况下, 我们也希望以在线方式得到所检测的激活模式随样本图像增加的变化情况。因此, 本文利用 Wang 等^[10] 的迭代算法思路提出了一种 G IF 的迭代计算方式, 即 RG IF。仿真实验表明, RG IF 能够大大减少 G IF 的运算时间, 其检测效果与 G IF 相当。

2 G IF 方法简介及其递推计算格式

2.1 G IF 方法介绍

用 $f_m(t, x)$ 表示在第 m 个刺激条件下, t 时刻采集到的脑图像。其中 $x = (x, y)$ 表示图像中像素点的行列位置, $m = 1 \dots, M$; $t = 1 \dots, T$, 通常在每个刺激条件下都是一样的。视 $f_m(t, x)$ 为以 x 为下标序号的图像向量, 为方便起见, 在不引起混淆的情况下, 将 $f_m(t, x)$ 简写成 $f_m(t)$ 。实际上, $f_m(t)$ 是由与刺激相关的激活模式图像 $S_m(t)$ 和背景模式图像 $B_m(t)$ 合成的。图像的 SNR 一般为 10^{-4} 量级, SNR 的具体定义将在仿真部分给出。我们的目标就是在如此低的信噪比下检测出激活图像 $S_m(t)$ 。

首先定义如下一组物理量:

$$f_m(t) = S_m(t) + B_m(t) \quad (1)$$

$$\begin{cases} \bar{f}_m = \frac{1}{T} \sum_{t=1}^T f_m(t), & \bar{f} = \frac{1}{M} \sum_{m=1}^M f_m(t), \\ \bar{f} = \frac{1}{M} \sum_{m=1}^M \bar{f}_m, & \tilde{f}_m(t) = f_m(t) - \bar{f}, \quad f_m(t) = f_m(t) - \bar{f}_m \\ \bar{B}_m = \frac{1}{T} \sum_{t=1}^T B_m(t), & \bar{B}_m = \frac{1}{M} \sum_{m=1}^M B_m(t), \\ \bar{B} = \frac{1}{M} \sum_{m=1}^M \bar{B}_m, & \tilde{B}_m(t) = B_m(t) - \bar{B}_m, \quad B_m(t) = B_m(t) - \bar{B}_m \\ \bar{S}_m = \frac{1}{T} \sum_{t=1}^T S_m(t), & \bar{S}_m = \frac{1}{M} \sum_{m=1}^M S_m(t), \\ \bar{S} = \frac{1}{M} \sum_{m=1}^M \bar{S}_m, & \tilde{S}_m(t) = S_m(t) - \bar{S}, \quad S_m(t) = S_m(t) - \bar{S}_m \end{cases} \quad (2)$$

由式 (1) 和 (2) 的定义, 有如下的关系式:

$$\begin{aligned} \bar{f}_m &= \bar{S}_m + \bar{B}_m, & \tilde{f}_m &= \tilde{S}_m + \tilde{B}_m, \\ \tilde{f}_m(t) &= \tilde{S}_m(t) + \tilde{B}_m(t), & f_m(t) &= S_m(t) + B_m(t) \end{aligned} \quad (3)$$

文 [9] 定义了如下的类间协方差矩阵 \mathbf{K}_s 和类内协方差矩阵 \mathbf{K}_n 的估计表达式:

$$\begin{cases} \mathbf{K}_s = \frac{1}{M-1} \sum_{m=1}^M (\bar{f}_m - \bar{f})(\bar{f}_m - \bar{f})^T \\ \mathbf{K}_n = \frac{1}{M(T-1)} \sum_{m=1}^M \sum_{t=1}^T [f_m(t) - \bar{f}_m][f_m(t) - \bar{f}_m]^T \end{cases} \quad (4)$$

在两个优化准则^[9] 前提下, 通过一系列推导, 激活模式可以通过求解如下特征问题的最大特征值所对应的特征向量 ϕ_1 获取:

$$(\mathbf{K}_s - \alpha \mathbf{K}_n) \phi = 1 \phi \quad (5)$$

式中 α 是一个 F 分位数, 一般取为 $\alpha = F_{0.95}(M-1, M-1)$ 。

显然, 对于较低分辨率的激活模式图像 (如 70×40), 我们需要求解一个维数巨大的矩阵特征值问题, 这将是非常耗时的操作。同时, 当样本增加时, 我们需要重新求解上述问题, 不能进行递推运算。为解决这两个问题, 本文运用文 [10] 的思路推导了一种快速递推算法。首先简要介绍文 [10] 的递推思路。

2.2 计算特征值问题的递推思路介绍^[10]

假设有如下的特征值问题:

$$\mathbf{A} \phi = 1 \phi \quad (6)$$

式中 \mathbf{A} 是由样本 $u(1), u(2), \dots$ 计算得到的样本协方差矩阵, 使用协方差矩阵的无偏估计表达式, 并将 ϕ 用每一步的估计 $\phi(t)$ 替代, 可以获得一个简要表达式 $v = 1 \phi$, 其中:

$$v(T) = \frac{1}{T} \sum_{t=1}^T u(t) u^T(t) \phi(t) \quad (7)$$

式中 $v(T)$ 是 v 第 T 步的估计 (即获取 T 个样本后的估计)。一旦估计出 v , 则很容易获取特征值和特征向量的估计, 即 $\lambda = \|v\|$, $\phi = v / \|v\|$ 。进一步将式 (7) 中的 $\phi(t)$ 用 $v(t-1) / \|v(t-1)\|$ 替代, 可得如下的表达式:

$$v(T) = \frac{1}{T} \sum_{t=1}^T u(t) u^T(t) \frac{v(t-1)}{\|v(t-1)\|} \quad (8)$$

从而可以得到 v 的递推估计表达式为:

$$\begin{cases} v(T) = \frac{T-1}{T} v(T-1) + \frac{1}{T} u(T) u^T(T) \frac{v(T-1)}{\|v(T-1)\|} \\ v(0) = u(1) \end{cases} \quad (9)$$

为了有效估计, 可以进一步使用如下的递推格式^[10]:

$$\begin{aligned} v(T+1) &= \frac{T-k}{T+1} v(T) + \frac{1+k}{T+1} u(T+1) \\ &\quad \cdot u^T(T+1) \frac{v(T)}{\|v(T)\|} \end{aligned} \quad (10)$$

式中 k 一般取为 2, 文 [11] 已经证明 $v(T) \rightarrow \phi_1$ 。

文 [10] 使用上述的递推方式来计算 FERET 人脸数据库^[13] 的特征脸, 结果表明该算法具有收敛速度快、误差小 (与 PCA 相比) 的优点。

2.3 G IF 的递推计算格式

注意到式(5)和式(6)非常相似,故可以通过某些近似来推导关于式(5)的递推计算格式。

由于:

$$\begin{aligned}\bar{f}_m - \bar{f} &= \frac{1}{T} \sum_{t=1}^T f_m(t) - \frac{1}{M} \sum_{m=1}^M \bar{f}_m \\ &= \frac{1}{T} \sum_{t=1}^T f_m(t) - \frac{1}{MT} \sum_{m=1}^M \sum_{t=1}^T f_m(t) \\ &= \frac{1}{T} \sum_{t=1}^T [f_m(t) - \frac{1}{M} \sum_{m=1}^M f_m(t)] \\ &= \frac{1}{T} \sum_{t=1}^T (f_m(t) - \bar{f}_m) \\ &= \frac{1}{T} \sum_{t=1}^T \tilde{f}_m(t)\end{aligned}\quad (11)$$

故:

$$\begin{aligned}(\bar{f}_m - \bar{f})(\bar{f}_m - \bar{f})^T &= \frac{1}{T^2} \sum_{t=1}^T \sum_{s=1}^T \tilde{f}_m(t) \tilde{f}_m^T(s) \\ &= \frac{1}{T^2} \sum_{t=1}^T \sum_{s=1}^T [\tilde{S}_m(t) + \tilde{B}_m(t)] \\ &\quad \cdot [\tilde{S}_m(s) + \tilde{B}_m(s)]^T \\ &= \frac{1}{T^2} \sum_{t=1}^T \sum_{s=1}^T \tilde{S}_m(t) \tilde{S}_m^T(s) + \frac{1}{T^2} \sum_{t=1}^T \sum_{s=1}^T \\ &\quad \cdot \tilde{S}_m(t) \tilde{B}_m^T(s) + \frac{1}{T^2} \sum_{t=1}^T \sum_{s=1}^T \tilde{B}_m(t) \\ &\quad \cdot \tilde{S}_m^T(s) + \frac{1}{T^2} \sum_{t=1}^T \sum_{s=1}^T \tilde{B}_m(t) \tilde{B}_m^T(s)\end{aligned}\quad (12)$$

当 T 较大,且满足以下三个条件时:

(1)背景模式与激活模式是近似正交的^[12]:

$$\tilde{B}_m(t) \tilde{S}_m^T(s) \approx 0 \text{ 对任意 } t, s \quad (13)$$

(2)在观测时间内,激活模式具有小方差变化特性,即

有:

$$\frac{1}{T^2} \sum_{t=1}^T \sum_{s=1}^T \tilde{S}_m(t) \tilde{S}_m^T(s) \approx \frac{1}{T} \sum_{t=1}^T \tilde{S}_m(t) \tilde{S}_m^T(t) \quad (14)$$

(3)在观测时间内,背景是平稳的,即有:

$$\begin{aligned}\frac{1}{T} \sum_{t=1}^T \tilde{B}_m(t) &\approx 0 \Rightarrow \left(\frac{1}{T} \sum_{t=1}^T \tilde{B}_m(t) \right) \left(\frac{1}{T} \sum_{s=1}^T \tilde{B}_m(s) \right) \\ &= \frac{1}{T} \sum_{t=1}^T \sum_{s=1}^T \tilde{B}_m(t) \tilde{B}_m^T(s) \approx 0\end{aligned}\quad (15)$$

$$\text{const} \equiv \sum_m \approx \frac{1}{T} \sum_{t=1}^T \tilde{B}_m(t) \tilde{B}_m^T(t) \\ - \left(\frac{1}{T} \sum_{t=1}^T \tilde{B}_m(t) \right) \left(\frac{1}{T} \sum_{t=1}^T \tilde{B}_m^T(t) \right) \quad (16)$$

经推导,式(12)可化简为:

$$(\bar{f}_m - \bar{f})(\bar{f}_m - \bar{f})^T = \frac{1}{T} \sum_{t=1}^T \tilde{f}_m(t) \tilde{f}_m^T(t) - \sum_m \quad (17)$$

借助文[10]的推导思路,下面来推导关于式(5)的递推计算格式(即 RG IF). 利用式(2),(17)可将 K_s 和 K_N 转化为:

$$\left\{ \begin{array}{l} \mathbf{K}_s = \frac{1}{M-1} \sum_{m=1}^M (\bar{f}_m - \bar{f})(\bar{f}_m - \bar{f})^T \\ \approx \frac{1}{T(M-1)} \sum_{m=1}^M \sum_{t=1}^T \tilde{f}_m(t) \tilde{f}_m^T(t) - \frac{1}{M-1} \sum_{m=1}^M \sum_m \phi \\ \mathbf{K}_N = \frac{1}{M(T-1)} \sum_{m=1}^M \sum_{t=1}^T [f_m(t) - \bar{f}_m][f_m(t) - \bar{f}_m]^T \\ = \frac{1}{M(T-1)} \sum_{m=1}^M \sum_{t=1}^T f_m(t) \tilde{f}_m^T(t) \end{array} \right. \quad (18)$$

将式(18)代入式(5),借用文[9]的结论,并用 ϕ 的每一步估计 $\phi(t)$ 替代 $\frac{1}{T(M-1)} \sum_{m=1}^M \sum_{t=1}^T \tilde{f}_m(t) \tilde{f}_m^T(t) \phi$ 和 $\frac{1}{M(T-1)} \sum_{m=1}^M \sum_{t=1}^T \tilde{f}_m(t) \tilde{f}_m^T(t) \phi$ 中的 ϕ ,则可获得一个简化

的式子 $v = 1/\phi$,其中:

$$\begin{aligned}v(T) &= \frac{1}{T(M-1)} \sum_{m=1}^M \sum_{t=1}^T \tilde{f}_m(t) \tilde{f}_m^T(t) \phi(t) \\ &- \frac{\alpha}{M(T-1)} \sum_{m=1}^M \sum_{t=1}^T \tilde{f}_m(t) \tilde{f}_m^T(t) \phi(t) \\ &- \frac{1}{M-1} \sum_{m=1}^M \sum_m \phi\end{aligned}\quad (19)$$

同理,也用 $v(t-1)/\|v(t-1)\|$ 替代式(19)中的 $\phi(t)$ 可得:

$$\begin{aligned}v(T) &= \frac{1}{T(M-1)} \sum_{m=1}^M \sum_{t=1}^T \tilde{f}_m(t) \tilde{f}_m^T(t) \frac{v(t-1)}{\|v(t-1)\|} \\ &- \frac{\alpha}{M(T-1)} \sum_{m=1}^M \sum_{t=1}^T \tilde{f}_m(t) \tilde{f}_m^T(t) \\ &\cdot \frac{v(t-1)}{\|v(t-1)\|} - \frac{1}{M-1} \sum_{m=1}^M \sum_m \phi\end{aligned}\quad (20)$$

由式(20)易得:

$$\begin{aligned}v(T+1) &= \frac{1}{(T+1)(M-1)} \sum_{m=1}^M \sum_{t=1}^{T+1} \tilde{f}_m(t) \tilde{f}_m^T(t) \\ &\cdot \frac{v(t-1)}{\|v(t-1)\|} - \frac{\alpha}{MT} \sum_{m=1}^M \sum_{t=1}^{T+1} \tilde{f}_m(t) \tilde{f}_m^T(t) \\ &\cdot \frac{v(t-1)}{\|v(t-1)\|} - \frac{1}{M-1} \sum_{m=1}^M \sum_m \phi \\ &= \frac{1}{(T+1)(M-1)} \sum_{m=1}^M \sum_{t=1}^{T+1} \tilde{f}_m(t) \tilde{f}_m^T(t) \\ &\cdot \frac{v(t-1)}{\|v(t-1)\|} - \frac{\alpha}{MT} \sum_{m=1}^M \sum_{t=1}^{T+1} \tilde{f}_m(t) \tilde{f}_m^T(t) \\ &\cdot \frac{v(t-1)}{\|v(t-1)\|} + \frac{1}{(T+1)(M-1)} \\ &\cdot \sum_{m=1}^M \tilde{f}_m(T+1) \tilde{f}_m^T(T+1) \frac{v(T)}{\|v(T)\|} \\ &- \frac{\alpha}{MT} \sum_{m=1}^M \tilde{f}_m(T+1) \tilde{f}_m^T(T+1) \frac{v(T)}{\|v(T)\|} \\ &- \frac{1}{M-1} \sum_{m=1}^M \sum_m \phi\end{aligned}\quad (21)$$

令: $a(T+1) = \frac{1}{M-1} \sum_{m=1}^M \tilde{f}_m(T+1) \tilde{f}_m^T(T+1) \frac{v(T)}{\|v(T)\|}$,

$b(T+1) = \frac{a}{M} \sum_{m=1}^M f_m(T+1) \bar{f}_m^T(T+1) \frac{v(T)}{\|v(T)\|}$, 且当 T 较大时有 $\frac{T}{T+1} \approx \frac{T-1}{T} \approx \frac{1}{2} \left[\frac{T}{T+1} + \frac{T-1}{T} \right] = \frac{2T^2 - 1}{2T(T+1)} \approx 1$, 则:

$$\begin{aligned} v(T+1) &= \frac{T}{T+1} \left[\frac{1}{T(M-1)} \sum_{m=1}^M \sum_{t=1}^T \bar{f}_m(t) \bar{f}_m^T(t) \right. \\ &\quad \cdot \frac{v(t-1)}{\|v(t-1)\|}] - \frac{T-1}{T} \left[\frac{a}{M(T-1)} \right. \\ &\quad \cdot \sum_{m=1}^M \sum_{t=1}^T f_m(t) \bar{f}_m^T(t) \frac{v(t-1)}{\|v(t-1)\|} + \frac{1}{T+1} \\ &\quad \cdot a(T+1) - \frac{1}{T} b(T+1) - \frac{1}{M-1} \sum_{m=1}^M \hat{\phi} \\ &= \frac{T-1}{T} \left[\frac{1}{T(M-1)} \sum_{m=1}^M \sum_{t=1}^T \bar{f}_m(t) \bar{f}_m^T(t) \right. \\ &\quad \cdot \frac{v(t-1)}{\|v(t-1)\|} - \frac{a}{M(T-1)} \sum_{m=1}^M \sum_{t=1}^T f_m(t) \\ &\quad \cdot \bar{f}_m^T(t) \frac{v(t-1)}{\|v(t-1)\|} - \frac{1}{M-1} \sum_{m=1}^M \hat{\phi} \\ &\quad + \frac{1}{T+1} a(T+1) - \frac{1}{T} b(T+1) \\ &= \frac{T-1}{T} v(T) + \frac{1}{T+1} a(T+1) - \frac{1}{T} b(T+1) \quad (22) \end{aligned}$$

同样考虑到收敛性问题, 结合式(2)可得到如下关于式(5)的递推计算格式(即 RG IF):

$$\left\{ \begin{array}{l} v(T+1) = \frac{T-1-k}{T} v(T) + \frac{1+k}{T+1} a(T+1) - \frac{1+k}{T} b(T+1) \\ \bar{f}_m(T+1) = \frac{T}{T+1} \bar{f}_m(T) + \frac{1}{T} f_m(T+1) \\ \bar{f}_t(T+1) = \frac{1}{M} \sum_{m=1}^M f_m(T+1) \\ v(0) = \frac{1}{M} \sum_{m=1}^M f_m(1) \end{array} \right. \quad (23)$$

式中 k 的范围在 $2 \sim 4$, 通常可取 2。

3 仿真实验及讨论

3.1 仿真刺激

首先定义脑光学图像的信噪比 SNR:

$$SNR = \frac{\|S_m(t, \mathbf{x})\|_x}{\|B_m(t, \mathbf{x})\|_x} \quad (24)$$

式中 $\|\cdot\|_x$ 表示以 \mathbf{x} 为索引求向量 \cdot 的模值。采用下式构造仿真数据:

$$f_m(t, \mathbf{x}) = B_m(t, \mathbf{x}) + r_m(t)p(\mathbf{x}) \quad (25)$$

式中 $t = 1, 2, \dots, 500$, 背景 $B_m(t, \mathbf{x})$ 为每秒 8 帧采集到的真实猫脑图像, 图 1(a)给出其中的一帧; $p(\mathbf{x})$ 为用棋盘格来模拟的行为模式图, 如图 1(b); $r_m(t)$ 用来模拟不同条件的刺激, 如下式:

$$r_m(t) = \begin{cases} 5 \times 10^{-4}, & \text{if } m = 1 \\ -5 \times 10^{-4}, & \text{if } m = 2 \end{cases}$$

这里只用了两个刺激模式, 显然这两个刺激模式是正交的。在每个刺激下都采集 500 帧图像, 图 1(c)为仿真脑图像 $f_m(t, \mathbf{x})$ 。由于极低的信噪比, 用肉眼无法从仿真脑图像中分辨出行模式图。

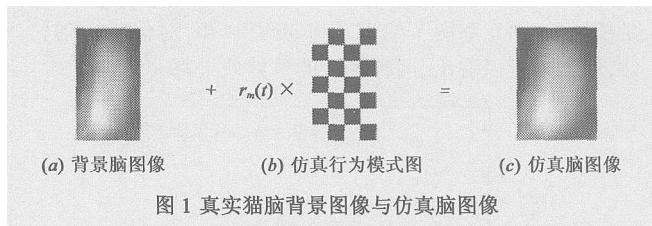


图 1 真实猫脑背景图像与仿真脑图像

为使每帧仿真脑图像具有相同的信噪比, 我们将背景图和行为模式图进行归一化处理, 即 $\|B_m(t, \mathbf{x})\|_x \equiv 1$, $\|p(\mathbf{x})\|_x^2 \equiv 1$, 这种归一化操作是可行的, 因为重要的不在于像素灰度的绝对大小, 而是其相对值大小。可见, 本文构造的仿真脑光学图像的信噪比为:

$$\begin{aligned} SNR &= \frac{\|S_m(t, \mathbf{x})\|_x}{\|B_m(t, \mathbf{x})\|_x} = \frac{|r_m(t)| \times \|p_m(\mathbf{x})\|_x}{\|B_m(t, \mathbf{x})\|_x} \\ &= |r_m(t)| = 5 \times 10^{-4} \end{aligned}$$

为说明所检测出的行为模式图 ϕ 的有效性, 定义如下的有效性因子:

$$E = (\phi, p)_x^2 \quad (26)$$

上式实际上就是检测出的行为模式图 ϕ 与真实行为模式图的内积平方。注意运算之前先将 ϕ 也进行归一化处理。显然 E 在 0~1 间, 且 $E \rightarrow 1$ 时, $\phi \rightarrow p$ 。同时还定义如下一个物理量来考察算法对信噪比 $r_m(t)$ 的估计效果:

$$\Omega_m(t) = (f_m(t), \phi)_x, \quad (27)$$

如果 $\phi \rightarrow p$, 则 $\Omega_m(t) \rightarrow r_m(t)$ 。

分别使用式(5)和式(20)所代表的 G IF 和 RG IF 两种算法进行仿真对比试验。图 2 给出了两种算法的运算时间随样本增加的情况。从图中可以看出, RG IF 迭代运算 500 步所花的时间(497.8 秒)仅相当于 G IF 在 50 个样本情况下计算一次的时间(425.1 秒)。G IF 在 500 个样本时的计算时间为 3716.5 秒。因此 RG IF 的计算效率较 G IF 而言有大幅提高。图 3 给出了 RG IF 和 G IF 的有效性因子随样本增加的变化情况。从图中可以看出, RG IF 的检测效果随样本的增加逐步逼近 G IF, 在样本较少(≤ 200)情况下的检测

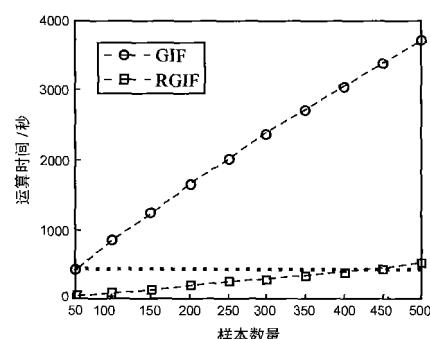


图 2 RGIF 与 GIF 的运算时间对比图

结果较差,但当样本超过 200 时,其检测效果已经与 G IF 相当,并且在样本增加到 500 时,它的有效性因子为 0.9514,而 G IF 在 500 个样本情况下的有效性因子为 0.9410。图 4 和图 5 分别给出了 RG IF 和 G IF 在 500 个样本情况下最终检测出的行为模式图 ϕ , 从中可以看出两者是相当的。图 6 和图 7 给出了 RG IF 和 G IF 对信噪比的估计,从图中可以看出,两种算法的估计效果都非常好。

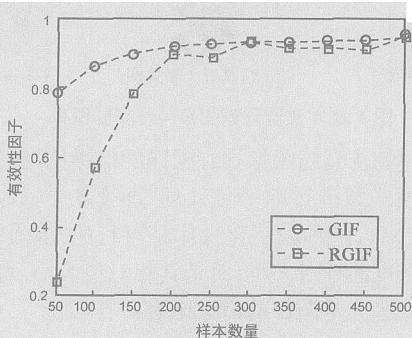


图 3 RGIF 与 GIF 的有效性因子对比图

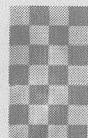


图 4 RGIF 检测出的行为模式图 图 5 GIF 检测出的行为模式图

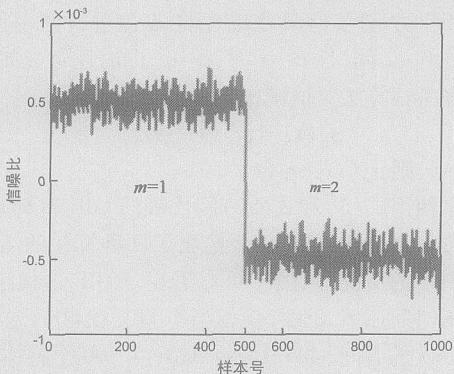


图 6 RGIF 估计信噪比效果图

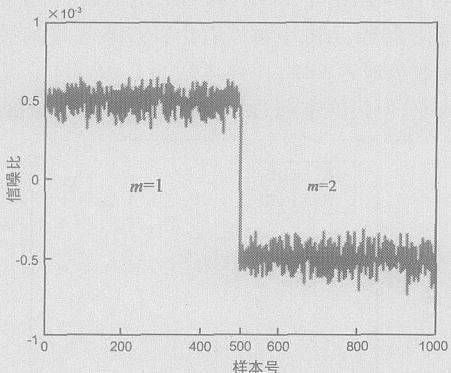


图 7 GIF 估计信噪比效果图

3.2 真实刺激

分别采用 0 度和 90 度的栅栏对猫进行视觉刺激,用

605nm 红光照射猫脑皮层 17 区,CCD 照相机以每秒 4 帧的速率拍摄猫脑皮层的神经活动。刺激在第 8 秒末开始,持续 2 秒,在第 10 秒末撤除,然后继续拍摄 10 秒,整个实验持续 20 秒。总共获得 160 帧皮层活动图像(每个刺激下各 80 帧)。

图 8 给出了两种算法检测出的刺激响应图,其中 G IF 算法花费了 388.25 秒时间,而 RG IF 算法只花费了 38.95 秒时间,然而两者所检测出的刺激模式基本相同(图像中的黑白间隔条纹代表 0 度和 90 度栅栏刺激下的皮层激活区域)。图 9 给出了两种算法检测出的刺激响应模式与原始图像序列的相关结果。从两者的结果都可以看出,当刺激在第 8 秒末加上后,随后的脑皮层图像序列与刺激模式有明显的相关特性。由于是正交刺激,因此刺激响应模式与 0 度栅栏刺激下的脑皮层图像序列呈现正的相关特性,而与 90 度栅栏刺激下的脑皮层图像序列呈现负的相关特性,这说明了我们所提取的刺激响应模式是合理的。从图中还可观察到, G IF 算法提取的模式图要比 RG IF 好一些,这是因为样本数量过少的原因导致的(真正有效的图像是从第 8 秒刺激加上后的图像序列)。

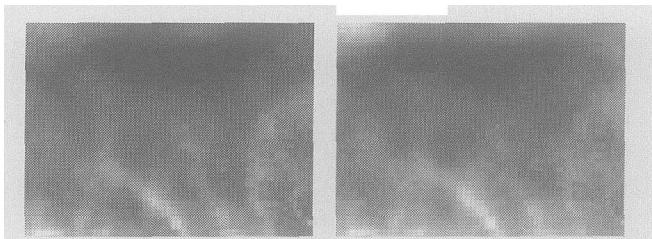


图 8 GIF 与 RGIF 算法检测的刺激响应模式

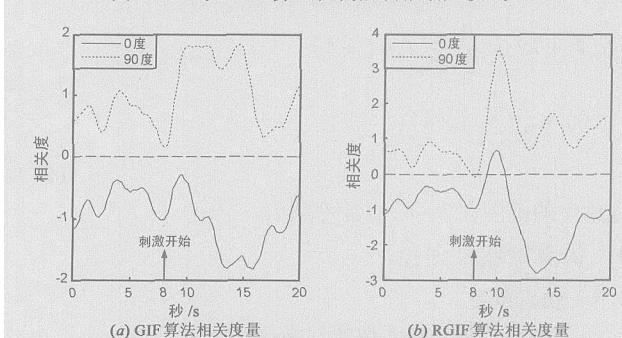


图 9 GIF 与 RGIF 算法检测出的刺激响应模式与原始图像序列的相关结果

4 结束语

本文针对 G IF 算法计算量大、不能在线观测的不足,提出了基于该算法的一种递推计算格式 RG IF, 仿真试验表明该算法不仅能够大大节省计算时间,而且当样本数积累到一定数目后(通常只需几百个样本),能够完全达到甚至超过 G IF 的检测效果。下一步的工作将研究 RG IF 在真实刺激下的脑图像检测效果。

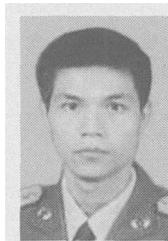
致谢 文中所用猫皮层光学脑图像数据是我们在复旦大学生命科学院寿天德教授的实验室,对某本征光学

功能成像装置做适当技术改造后采集到的。感谢寿天德教授和沈威博士生的帮助。

参考文献:

- [1] Toga A W, Mazziotta J C. Brain Mapping: The Methods [M]. Second Edition Holland Academic Press, 2002: 97– 140.
- [2] Arieli A, Sterkin A, Grinvald A, et al. Dynamics of ongoing activity: explanation of the large variability in evoked cortical responses [J]. Science, 1996, 273(5283): 1868– 1871.
- [3] Basden G, Salama G. Voltage sensitive dyes reveal a modular organization in monkey striate cortex [J]. Nature, 1986, 321(6070): 579– 585.
- [4] Sirovich L, Everson R, Kaplan E, et al. Modeling the functional organization of the visual cortex [J]. Physica D, 1996, 96(1-4): 355– 366.
- [5] Everson R, Knight B, Sirovich L. Separating spatially distributed response to stimulation from background I optical imaging [J]. Biological Cybernetics, 1997, 77(6): 407– 417.
- [6] Gabby M, Brennan C, Kaplan E, et al. A principal components-based method for the detection for neuronal activity maps: Application to optical imaging [J]. NeuroImage, 2000, 11(4): 313– 325.
- [7] Hyvärinen A, Oja E. A fast fixed-point algorithm for independent component analysis [J]. Neural Computation, 1997, 9(7): 1483– 1492.
- [8] Stüber M, Schiebel O, Osto T, et al. Principal component analysis and blind separation of sources for optical imaging of intrinsic signals [J]. NeuroImage, 2000, 11(5): 482– 490.
- [9] Yokoo T, Knight B, Sirovich L. An optimization approach to signal extraction from noisy multivariate data [J]. NeuroImage, 2001, 14(6): 1309– 1326.
- [10] Wang J Y, Zhang Y L, et al. Covariance-free incremental principal component analysis [J]. IEEE Trans PAMI, 2003, 25(8): 1034– 1040.
- [11] Zhang Y L, Wang J Y. Convergence analysis of complementary and incremental principal component analysis [R]. Technical Report M SU-CSE-01-23, East Lansing USA: Dept of Computer Science and Eng Michigan State University, Aug, 2001.
- [12] Sirovich L, Kaplan E. Analysis method for optical imaging [EB/OL]. <http://cambridge.mssm.edu/>, 2001. 17.
- [13] Phillips P J Moon H, Rauss P, et al. The FERET evaluation methodology for face recognition algorithms [J]. IEEE Trans PAMI, 2000, 22(10): 1090– 1104.

作者简介:



黄晓斌 男, 1978年6月出生于江西省宜春市, 现为国防科技大学电子科学与工程学院博士研究生, 从事脑功能光学成像、模式识别方面的研究 E-mail hxb_kjyuan2000@163.net



胡德文 男, 1963年出生, 博士, 教授, 博士生导师, 主要从事系统辨识、神经网络、图像处理和认知科学等方面工作。

E-mail dw_hu@nudt.edu.cn

刘亚东 男, 1977年出生, 现为国防科技大学机电与工程学院博士研究生, 主要从事神经成像分析的研究, 在 NeuroImage, Science in China等杂志上发表过文章。