

基于 MATLAB 仿真的神经元锋电位序列的生成

刘培龙, 黄乐天, 林凌鹏

(电子科技大学 通信与信息工程学院, 四川 成都 611731)

摘 要: 为了更加逼真地模拟和分析神经系统, 提出了一种基于 MATLAB 的锋电位序列生成方法, 这种方法既简单又高效. 通过二分高斯(Dichotomized Gaussian DG)模型模拟产生了具有特定相关性系数的二进制锋电位序列, 并且做了相关仿真及分析. 另外, 对这种生成机制扩展到不同时间上的相关性作了分析, 并且提出了一种有效的方法来模拟产生相关的锋电位计数.

关键词: 锋电位序列; 锋电位计数; 相关性; DG 模型; MATLAB

中图分类号: TP311; R338

文献标识码: A

文章编号: 1000-7180(2012)04-0146-04

Generation of Neural Spike Trains Based on MATLAB Simulation

LIU Pei-long, HUANG Le-tian, LIN Ling-peng

(School of Communication and Information Engineering, UESTC, Chengdu 611731, China)

Abstract: For the realistic simulation and analysis of neural systems. This paper describe the method based on MATLAB. This method is not only simple but also efficient. Here, generate correlated binary spike trains by means of the DG model, then do some simulations and analysis. Additionally, this method can naturally extends to correlations over time and propose an elegant way to model correlated neural spike counts.

Key words: spike trains; spike counts; correlations; DG model; MATLAB

1 引言

为了搞清楚神经系统是如何处理神经信息的, 需要了解大量神经元活动的模式, 即在同一时间点不同神经元产生的锋电位构成的序列^[1]. 很短的时间内, 比如说 2 ms, 神经元或者是产生一个锋电位或者是不产生, 因此, 很多个神经元的活动可以用二进制的模式来描述^[2]. 我们的目的就是生成这样二进制的 0,1 序列. 目前已经有很多关于锋电位序列生成方面的研究, 主要的两种方法是通过非齐次泊松随机过程来产生和从一系列源锋电位序列随机获取^[3-4]. 这两种方法都与泊松过程相关, 实际产生过程比较繁琐, 涉及到很多概率、随机过程和矩阵分解的问题. 因此引入一种 DG 分布用于锋电位序列的生成, 由于 MATLAB 具有强大的功能和灵活性, 可对 DG 分布进行建模并抽样得到所需要的 0,1 序

列, 即锋电位序列, 这种方法简单而且效率比较高.

2 系列源锋电位序列获取

假设有 M 个源锋电位序列, 如图 1 所示. 它们是相互独立的泊松过程, 发射频率分别为 $\lambda_1, \dots, \lambda_M$. 把源锋电位序列 k 复制到目标锋电位序列 i , 概率是 $p_{i,k}$. 这样第 i 个锋电位序列的平均发射频率为

$$r_i = \sum_{k=1}^M p_{i,k} \lambda_k \quad (1)$$

如果写成向量的形式为

$$R = P\lambda$$

如上所述, 如果选择好 P 和 λ , 就能生成不同发射频率和相关性的锋电位序列^[4].

这种生成方法只局限于存在源锋电位序列的情况, 要想生成目标锋电位序列必须先产生源锋电位序列. 还有概率矩阵 P 的选取也是很麻烦的, 针对




图1 方法2示意图

每个目标峰电位序列就必须选取 M 个概率,其次这种方法还存在一定的随机性。

3 基于 MATLAB 仿真的锋电位序列生成

3.1 通过 DG 分布获得锋电位序列

假设锋电位序列离散的分布在足够小的时间单位内,这样的话在每一个时间单位内只可能有一个锋电位,如果第 i 个神经元在第 t 个时间单位内发射了一个锋电位则 $X_i(t)=1$,否则 $X_i(t)=0$ 。所以,通过从这 N 个相关的伯努利随机变量的联合分布抽样就能得到所需要的锋电位序列,在这里认为不同时刻之间是不相关的,即对于 $t \neq s$, $X(t)$ 和 $X(s)$ 是相互独立的。

现在来描述一下 DG 分布^[5],它非常适合来产生具有特定相关性的二进制随机向量。一个 DG 分布的样本可以这样来产生,首先从一个 N 维的高斯随机变量 U 采样,然后和一个阈值作比较再确定是 0 或者是 1。如果 $U_i > 0$, $X_i=1$,在这里 $U \sim N(\mu, \Lambda)$,假设 U 具有单位方差,即 $\Lambda_{ii}=1$ 。 X 的均值 r 和协方差 cov 可以由下面的公式得到:

$$r_i = \Phi(\mu_i) \quad (2)$$

$$cov_{i,i} = \Phi(\mu_i)\Phi(-\mu_i) \quad (3)$$

$$cov_{ij} = \Psi(\mu_i, \mu_j, \Lambda_{ij}) \quad (4)$$

$$\Psi(x, y, \lambda) = \Phi_2(x, y, \lambda) - \Phi(x)\Phi(y) \quad (5)$$

式中, Φ 是均值为 0 方差为 1 的高斯分布的分布函数。 $\Phi_2(x, y, \lambda)$ 是相关性为 λ 的二维高斯分布的分布函数。均值 μ_i 可通过 $\mu_i = \Phi^{-1}(r_i)$ 求得。 Λ_{ij} 可通过等式 $cov_{ij} - \Psi(\mu_i, \mu_j, \Lambda_{ij}) = 0$ 找到一个合适的值。

Λ_{ij} 可以作为衡量神经元 i 和神经元 j 之间相关性强弱的参数。两个神经元之间越不相关它的值越接近于 -1,越相关它的值越接近于 1^[5]。在这里,我们的方法就是通过 MATLAB 来建立这样的 DG 分布,然后抽样得到所需要的锋电位序列。

3.2 仿真结果以及相关分析

产生由 10 个神经元生成的锋电位序列,发射频

率依次为: $r_1=0.1, r_2=0.15, r_3=0.2, r_4=0.3, r_5=0.35, r_6=0.4, r_7=0.5, r_8=0.55, r_9=0.6, r_{10}=0.7$ 任意两个神经元之间的协方差为 $cov_{i,j}=0.02, i \neq j, i, j=1, 2, \dots, 10$ 。仿真结果如图 2 所示。




图2 十个神经元锋电位序列

图 2 中横坐标代表时间,纵坐标代表 10 个不同的神经元。可以看出,随着发射频率的增大,产生的锋电位个数依次增多^[6]。可以设定不同的发射频率以及任意两个神经元之间的相关性,以此来获得想要的锋电位序列。

下面来看一下神经元之间的相关性对多个神经元活动的二进制模式的影响^[7-9]。现在一共有 10 个神经元,所以一共有 2^{10} 也就是 1 024 种可能的模式。在神经元之间是相互独立和具有相关性两种情况下分别看一下它们的直方图,如图 3 所示。




图3 相互独立和 DG 模型下的直方图

图 3 中,横坐标代表着 1024 种可能的模式,纵坐标是每一种模式发生的概率。通过上图可以发现,很多二进制模式发生的概率在神经元之间具有相关性时比它们之间是相互独立的情况下要大^[7]。

另外可以把这两种情况下的直方图汇总到一个图中,这样每一种模式在不同情况下发生的概率就能清晰可见了,如图 4 所示。其中,横坐标对应的是相互独立情况下各个模式发生的概率,纵坐标对应的是 DG 模型下各个模式发生的概率。




图4 神经元之间的相关性带来的影响

3.3 考虑时间相关性的神经元锋电位序列

到目前为止,所假定的条件都是不同时间点之间是不相关的.也就是说多个神经元活动的序列 $X(s)$ 和 $X(t)$ 在不同时间点 s 和 t 之间是相互独立的随机变量.现在扩展到不同时间点之间具有相关性的情况.在这里只简单介绍一下这种情况.通过一个具有时间相关性的高斯过程 $V(t)$ 来得到二进制的样本 $X(t)$,如果 $V_i > 0$, $X_i = 1$,在这里:

$$V(t) \sim N(\mu(t), \Delta(s, t)) \quad (6)$$

式中, $\mu(t)$ 是均值函数, $\Delta(s, t)$ 是协方差函数.

通常情况下,模拟 N 个神经元在 M 个时间单位内的时间相关性大约需要评估 $(M^2 N^2)/2$ 个参数.随着 M 和 N 的增大这将变得非常棘手,在这里考虑一种特殊情况,假定 $V(t)$ 是一个平稳随机过程.因此,发射频率 $\mu(t) = \mu$ 是一个常数,时间协方差 $\Delta(s, t) = \Delta(s - t) = \Delta(\tau)$ 只与时间间隔 $\tau = s - t$ 有关.对于一个给定的 τ 这是一个 $N \times N$ 的矩阵.假定如果延迟超出了 τ_{K-1} 就不存在相关性,则只需要 K 个时间延迟: $\tau = \tau_0, \dots, \tau_{K-1}$,因此只需去评估 KN^2 个参数.这样所需的参数大大减少,便于去模拟产生所需要的锋电位序列,可预测考虑时间相关性在内的锋电位序列与真实的锋电位序列更加接近.

4 基于 MATLAB 仿真的锋电位计数生成

4.1 泊松锋电位计数原理

通常对在某一时点的单个锋电位不感兴趣,而是对一个时间间隔内的锋电位数也就是锋电位计数进行分析.例如,初级视觉皮层区域的神经元的

响应特性与平均发射的锋电位数目的关系已经取得了一定的研究成果.而且,很多关于神经元编码的理论研究只考虑锋电位计数,而不考虑确切时间点的锋电位信息^[8].

锋电位计数的统计特性可以这样来模拟,将一段时间间隔 $[0, T]$ 分成 M 段很小的时间单位, $\Delta t = T/M$,所选的时间单位应尽可能小,以使在每一个很小的时间单位内保证最多只有一个锋电位.在第 k 个时间单位内如果第 i 个神经元发射了一个锋电位,则令 $X_{ik} = 1$ 否则是 0.在时间窗 $[0, T]$ 内锋电位计数 Υ 通过将这 M 个随机变量累加得到式(7):

$$\Upsilon_i^{(M)} = \sum_{k=1}^M X_{ik} \quad (7)$$

如果不考虑时间相关性,并且每一个 X_{ik} 有相同的发射频率 $r_i = \mu_i \Delta t$,这样 $\Upsilon_i^{(M)}$ 就是一个参数为 r_i 和 M 的二项分布.因为泊松分布是二项分布的极限分布,这样式(8)就是一个均值为 $\mu_i T$ 的泊松分布.

$$\Upsilon = \lim_{M \rightarrow \infty} \Upsilon_i^{(M)} \quad (8)$$

首先利用 DG 分布模拟前面的锋电位序列 X_{ik} ,然后将它们累加,得到需要的泊松分布,然后从这个泊松分布抽样得到想要的锋电位计数.

4.2 仿真结果及相关分析

(1) 正相关的情况

具体仿真参数如下,泊松分布的均值为 $\lambda_1 = 7$, $\lambda_2 = 9$,协方差 $\text{cov}_{1,2} = 3$,采样数为 10 000,通过 MATLAB 计算的实际的均值为 $\lambda_1 = 6.981$, $\lambda_2 = 8.986$,协方差为 $\text{cov}_{1,2} = 2.869$.仿真结果如图 5 所示,在这里取前 50 个样点.


由图 5(a)可看出,得到了想要的锋电位计数,并且可以看出锋电位数目为 5~10 的情况最多,图 5(b)也证实了这一点,锋电位数目在 5~10 时发生的概率最大.图 5(b)中,左图横坐标代表不同的锋电位数目,纵坐标代表各自发生的概率,右图代表两个锋电位计数之间的相关性,颜色越深正相关性越大.

(2) 负相关的情况


具体仿真参数如下,泊松分布的均值为 $\lambda_1 = 7$, $\lambda_2 = 9$,协方差 $\text{cov}_{1,2} = -3$,采样数为 10 000,通过 MATLAB 计算实际的均值为 $\lambda_1 = 7.005$, $\lambda_2 = 8.981$,协方差为 $\text{cov}_{1,2} = -2.983$.仿真结果如图 6 所示,在这里取前 50 个样点.

5 结束语

本文提出的方法可以有效地产生具有不同发射




(a) 两个神经元锋电位计数




(b) 锋电位计数之间的相关性

图5 正相关锋电位计数



(a) 两个神经元锋电位计数



(b) 锋电位计数之间的相关性


图6 负相关的锋电位计数

频率和相关性的锋电位序列以及锋电位计数,并且用 MATLAB 进行了仿真,得到了所期望的结果.与前面介绍的两种常用方法相比,这种方法简单高效.只需要通过 MATLAB 构造出所需要的 DG 分布,再从 DG 分布抽样便可,省去了很多随机过程、概率以及矩阵方面的运算.另外,对涉及时间相关性的锋电位序列进行了分析讨论,并且通过 MATLAB 产生了一种泊松锋电位计数.这样可以用产生的锋电位序列以及锋电位计数做后面的研究.

参考文献:

- [1] Strong S P, Roland Koberle, William Bialek, et al. Entropy and information in neural spike trains[J]. Physical Review Letters, 1998(80): 197-200.
- [2] Romain Brette. Generation of correlated spike trains [C]. Odyssee Lab, Paris, France: 2008.
- [3] Professor David Heeger. Poisson model of spike generation[R]. 2000.
- [4] 胡选子,谢存禧. 一种条件概率和遗传算法相结合的分类方法[J]. 微电子学与计算机, 2006, 23(10): 170-172.
- [5] Jakob H Macke, Philipp Berens, Alexander S Ecker, et al. Generating spike trains with specified correlation coefficients[J]. Neural Computation, 2009(21): 397-423.
- [6] Jaime de la Rocha, Brent Doiron, Eric Shea Brown, et al. Correlation between neural spike trains increases with firing rate[J]. NATURE, 2007(448): 802-807.
- [7] 宋宜斌,王培进,李凯里. 基于引导因子的神经元学习规则及其应用研究[J]. 微电子学与计算机, 2004, 21(3): 69-72.
- [8] Robert E Kass, Valerie Ventura. A spike-train probability model[J]. Neural Computation, 2001(13): 1713-1720.

作者简介:



刘培龙 男, (1987—), 硕士研究生. 研究方向为神经网络、现代通信中的信号处理.

黄乐天 男, (1984—), 博士研究生. 研究方向为神经网络、现代通信中的信号处理, 通信专用集成电路设计.

林凌鹏, 男, (1987—), 硕士研究生. 研究方向为神经网络、现代通信中的信号处理.