

Determinando Padrões Bursting-Spiking num Modelo Neural

Rosângela Follmann^a Elbert E. N. Macau^b José Demisio S. da Silva^b

^aPrograma de Pós-graduação em Computação Aplicada (CAP)

^bLaboratório Associado de Computação e Matemática Aplicada (LAC)

Instituto Nacional de Pesquisas Espaciais (INPE)

rosangela@lac.inpe.br elbert@lac.inpe.br demisio@lac.inpe.br

Resumo

Rulkov [1] introduziu um modelo para o comportamento de *bursting* e *spiking* de tipos conhecidos de neurônios corticais. No presente trabalho desenvolveu-se um mapa topológico para estabelecer um padrão entre os tipos de atividades neurais relacionados a dois parâmetros de controle. No desenvolvimento deste trabalho foram utilizadas simulações numéricas com redes neurais.

1 Introdução

Para entendermos como o cérebro funciona, precisamos combinar estudos experimentais de sistemas nervosos de animais e humanos com simulações numéricas de modelos cerebrais de grande escala. Nestas simulações precisamos levar em conta a arquitetura complexa do acoplamento entre neurônios, que é sugerida por experimentos biológicos. A complexidade do comportamento temporal é devido ao grande número de correntes iônicas envolvidas na dinâmica não linear dos neurônios, [2]. Num neurônios são observados um dos três tipos de atividades neurais: silêncio, *spiking* e *bursting*, [3]. Estudos indicam que estados de *bursting* são importantes no controle de movimentos rítmicos, sendo também freqüentemente observados na produção de padrões centrais, controlando o comportamento motor. *Bursting* tem sido extensamente observados no

sono e estados patológicos do cérebro. Neurônios em modo *bursting* se diferem de neurônios em modo *spiking* em sua habilidade de transmitir informação e em resposta a estímulos.

No presente trabalho analisa-se a dinâmica do modelo proposto por Rulkov e será desenvolvido um mapa topológico que estabeleça um padrão entre os tipos de atividades neurais.

2 Dinâmica do mapa bidimensional

Rulkov [1], modelou o comportamento neural utilizando um mapa bidimensional, que pode ser escrito da forma

$$\begin{aligned}x_{n+1} &= f(x_n, y_n + \beta_n), \\y_{n+1} &= y_n - \mu(x_n + 1) + \mu\sigma_n,\end{aligned}\tag{1}$$

onde x_n é variável rápida e y_n é variável de dinâmica lenta. A evolução lenta no tempo de y_n é devido aos pequenos valores do parâmetro μ . Os termos σ_n e β_n descrevem influências externas. Ao mapa 1 é adicionado um fato que é capaz de imitar a dinâmica de *spiking* individual com *bursting*, que é a modificação da forma da função não linear $f(x, y)$ que agora é uma função descontínua na forma

$$f(x, y) = \begin{cases} \frac{\alpha}{(1-x)} + y, & x \leq 0 \\ \alpha + y, & 0 < x < \alpha + y \\ -1, & x \geq \alpha + y, \end{cases}\tag{2}$$

onde α é um parâmetro de controle. A dependência de $f(x, y)$ em x é calculada para valores fixos de y , ilustrada na Figura 1. Neste gráfico os valores de α e y estão ilustrando existência de um ciclo limite P , correspondendo a oscilação de *spiking*, a existência de pontos fixos, estável (x_{ps}) e instável (x_{pu}).

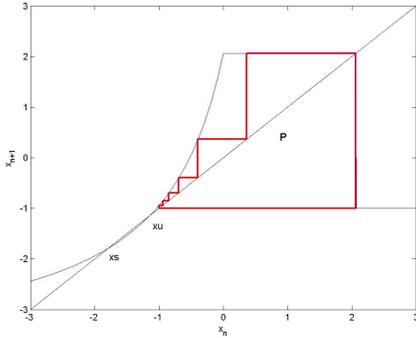


Figura 1: Forma não linear da função $f(x, y)$, para $\alpha = 6.0$ e $y = -3.94$ é ilustrado em azul. A linha vermelha ilustra um ciclo limite P . Os pontos fixos estáveis e instáveis do mapa são indicados por x_s e x_u , respectivamente.

A dinâmica individual do mapa depende somente dos parâmetros de controle α e σ e o mapa pode ser reescrito como

$$\begin{aligned} x_{n+1} &= f(x_n, y_n), \\ y_{n+1} &= y_n - \mu(x_n + 1) + \mu\sigma, \end{aligned} \quad (3)$$

O regime típico de comportamento temporal desta função são mostradas nas Figuras 2 e 3. Quando o valor de α é menor que 4, então dependendo do valor de σ , o mapa gera *spikes* ou permanece em estados estacionários. A frequência de *spikes* aumenta quando o valor de σ é aumentado (ver Figura 2).

Para $\alpha > 4$, as dinâmicas do mapa são capazes de produzir *bursting*. Os regimes de *bursting* são encontrados em regiões intermediárias do parâmetro σ entre as regimes de *spiking* tônicos contínuos e estados estacionários (silêncio). Os *spiking-bursting* incluem regimes *bursting* periódicos e caóticos. Alguns regimes típicos de *spiking-bursting* para diferentes valores de σ são apresentados na Figura 3.

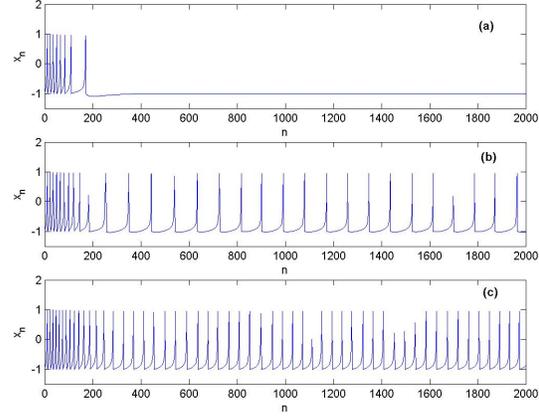


Figura 2: Comportamento temporal da Equação 3 para $\alpha = 3.9$. A Figura 2(a) mostra a transição para o regime de silêncio para $\sigma = -0.01$. (b) o regime de *spiking* tônicos são calculados para $\sigma = 0.1$ e (c) $\sigma = 0.2$.

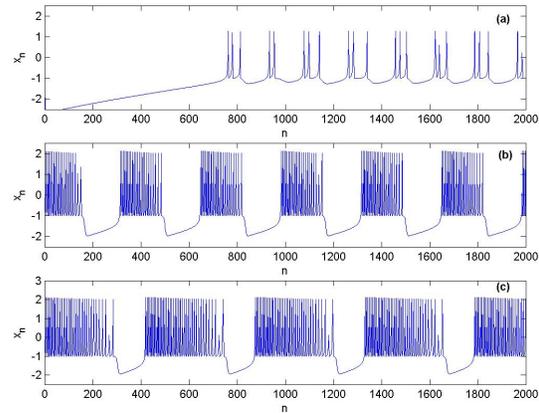


Figura 3: Comportamento de *spiking-bursting* gerado pela Equação 3, para os seguintes valores dos parâmetros; (a) $\alpha = 4.5$, $\sigma = 0.02$, (b) $\alpha = 6$, $\sigma = 0.1$, e (c) $\alpha = 6.0$, $\sigma = 0.35$.

Os resultados da análise apresentada por Rulkov, são sumarizadas no esboço do diagrama de bifurcação plotadas no plano dos parâmetros (σ, α) (ver Figura 4).

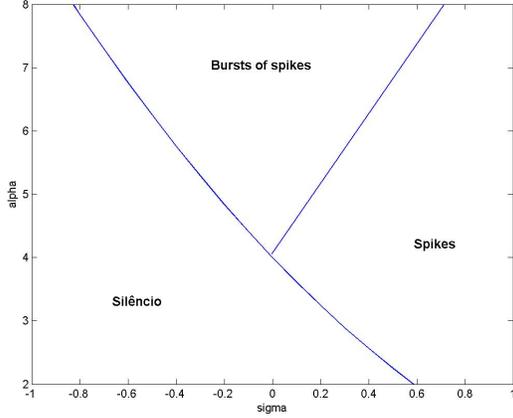


Figura 4: Diagrama de bifurcação no plano (σ, α) .

3 Mapas auto-organizáveis

O mapa auto-organizável é um tipo de rede neural que se caracteriza pela formação de um mapa topográfico dos padrões de entrada, onde as localizações dos neurônios no reticulado correspondem às características intrínsecas dos padrões de entrada, [7].

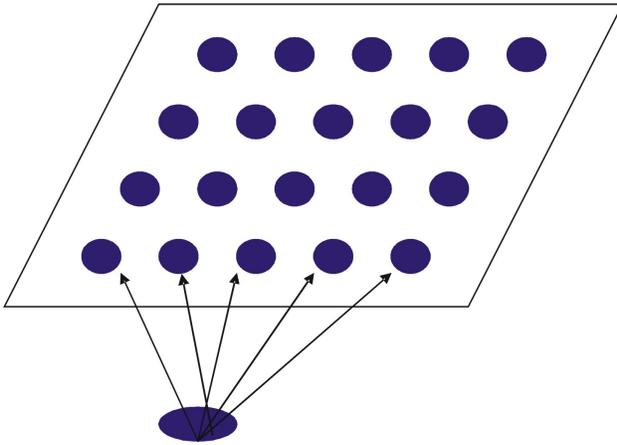


Figura 5: Modelo de Kohonen para mapas auto-organizáveis.

Um diagrama esquemático de uma grade bidimensional de neurônios é mostrado na Figura 5, onde ca-

da neurônio da grade está totalmente conectado a todos os nós de fonte da entrada. Esta grade representa uma estrutura alimentada adiante com uma única camada computacional consistindo de neurônios arranjados em linhas e colunas.

O algoritmo responsável pela formação do mapa auto-organizável é iniciado com pesos sinápticos aleatórios pequenos da grade. Após a inicialização da grade há três processos essenciais envolvidos na formação do mapa auto-organizável:

1. **Competição:** Para cada padrão apresentado na entrada da rede busca-se um neurônio que melhor represente a rede. O melhor neurônio será aquele que possuir a menor distância entre o vetor de entrada (X) e o vetor de pesos sinápticos (W_j).
2. **Cooperação:** O neurônio vencedor determina a localização espacial da vizinhança topológica dos neurônios excitados. Em particular, um neurônio que está disparando tende a excitar mais fortemente os neurônios da sua vizinhança imediata do que àqueles distante dele. Esta observação nos leva a uma função que decaia suavemente com a distância lateral, a função que satisfaz esta condição é função gaussiana

$$h_{j,i(x)}(n) = \exp\left(-\frac{d_{j,i}^2}{2\sigma_1^2(n)}\right), \quad n = 0, 1, 2, \dots, \quad (4)$$

onde σ_1 é a largura efetiva da vizinhança topológica.

3. **Adaptação Sináptica:** Este último mecanismo permite a atualização dos neurônios excitados dentro da vizinhança topológica determinada pelo neurônio vencedor. O vetor peso é atualizado por

$$w_j(n+1) = w_j(n) + \eta(n)h_{j,i(x)}(n)(x - w_j(n)) \quad (5)$$

onde η é a taxa de aprendizagem que deve diminuir no tempo, iniciando em um valor η_0 e decrescendo com um decaimento exponencial dado por

$$\eta(n) = \eta_0 \exp\left(-\frac{n}{\tau}\right), \quad n = 0, 1, 2, \dots, \quad (6)$$

onde τ é uma constante de tempo.

4 Aplicando o Método

Foram gerados 15 conjuntos de dados a partir do comportamento temporal da função bidimensional, para diferentes valores dos parâmetros α e σ . Utilizando-se de um programa feito em Matlab, gerou-se um mapa topológico bidimensional 5×5 , sendo a taxa inicial de aprendizagem $\eta_0 = 0.1$, a constante de tempo $\tau = 1000$, largura efetiva da vizinhança topológica $\sigma_1 = 0.4$. Foram treinadas 1000 épocas.

Os resultados são mostrados na Figura 6, onde percebe-se que o mapa gerou três tonalidades diferentes de cores, correspondentes as três classes: silence, *spiking* e *bursting*.

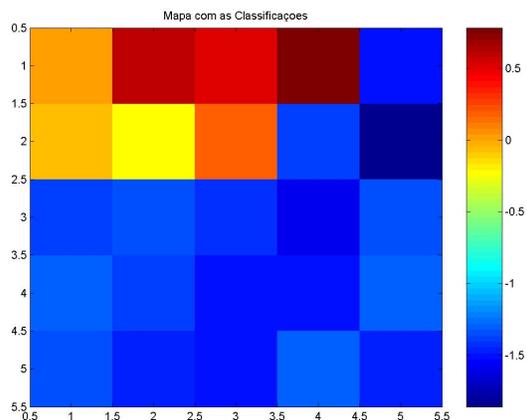


Figura 6: Distribuição das classes

Os mapas mostrados na Figura 6 se referem as características dos dados de entrada, onde os tons em azul representam valores baixos e os tons em vermelho representam valores mais altos, podemos verificar que o estado de silêncio se refere a valores menores (em azul), o estado de *spiking* agruparam-se em valores positivos (em vermelho-laranja) e o estado de *Burst* agruparam-se no canto esquerdo inferior do mapa (vermelho escuro).

5 Conclusão

Através do modelo proposto por Rulkov para determinar as atividades neurais de um neurônio biológico, se obteve os dados de entrada. A partir destes, gerou-se o mapa representado na Figura 6, e obteve-se uma boa classificação e identificação dos padrões. Pretende-se continuar os estudos e verificar com mais precisão os parâmetros que geram os diferentes tipos de atividades neurais.

Referências

- [1] Rulkov, N. F., Modeling of spiking-bursting neural behavior using two-dimensional map, *Physical Review E*, 2002, v.65, n.04,1-9.
- [2] Shilnikov, A.; Calabrese, L. R; Cymbalyuk, G., Mechanism of bi-stability: tonic spiking and bursting in a neuron model, *APS,Atlanta*, 2004, 123, 1-7.
- [3] Izhikevich, M. E., Simple Model of spiking neurons, *IEEE Transactions on neural networks*, 2003, vol.14, no.6, 1569-1572.
- [4] Vesato, J.; Himberg, J.; Alhoniemi, E.; Parhankangas, J., Self-organizing map in Matlab: the SOM Toolbox, *In Proc. of the Matlab DSP Conference*, 1999.
- [5] Haykin, S.: *REDES NEURAIAS: Princípios e práticas*,Bookman, 2001.
- [6] Fausset, L. V.: *FUNDAMENTALS of NEURAL NETWORKS: Architectures, Algoritmos, and Applications*,Prentice-Hall, 1994.
- [7] Kohonen, T.: *Self-Organizing Maps*, Springer, Berlin, 1995.