

## Introdução

Estudos recentes mostram que dinâmicas neurais complexas produzidas pela arquitetura recorrente dos circuitos do neo-córtex são críticas ao poder computacional do córtex. Entretanto, as regras de aprendizado sináptico subjacentes da criação de propagação de atividades espaço-temporais (trajetórias neurais) estáveis e reproduzíveis não são compreendidas.

Pesquisas mostram que uma forma modificada de dimensionamento sináptico chamada *presynaptic-dependent scaling* (PSD) foi capaz de guiar redes neurais inicialmente conectadas aleatoriamente a desenvolver estados dinâmicos estáveis em resposta a uma entrada inicial.

## Objetivos

Serão examinadas regras de aprendizado sináptico com o objetivo de criar redes recorrentes cuja atividade se propague através da rede em resposta a um estímulo inicial ou incorpore múltiplas trajetórias. Dessa forma, espera-se codificar por meio de diferentes trajetórias, um conjunto de condições iniciais.

## Metodologia

Utiliza-se o modelo de neurônios de integração e disparo (integrate and fire, IF) onde a corrente é impulsiva, na forma de uma delta de Dirac, o que possibilita a integração analítica, evitando a necessidade de integrar numericamente. A equação para o potencial fica:

$$u(t) = RI_o[1 - \exp(-\frac{t - t_d}{\tau_m})] \quad (1)$$

Usamos uma rede com 320 neurônios excitatórios (Ex) e 80 inibitórios (In). Cada neurônio excitatório é conectado aleatoriamente a 20 neurônios excitatórios e a 5 inibitórios. Cada neurônio inibitório é conectado a 5 neurônios excitatórios.

O potencial de repouso é de -60mV e -65mV para os neurônios Ex e In, respectivamente. O limiar de disparo foi definido a partir de uma distribuição normal com médias de -40mV e -45mV para os neurônios Ex e In, respectivamente. As constantes de tempo são de 30ms para os Ex e de 10ms para os In.

A regra de dimensionamento sináptico usada é a *presynaptic-dependent scaling*, representada como:

$$W_{ij}^{\tau+1} = W_{ij}^{\tau} + \alpha_w A_j^{\tau} \cdot (A_{goal} - A_i^{\tau}) \cdot W_{ij}^{\tau} \quad (2)$$

Onde  $W_{ij}$  representa o peso da sinapse do neurônio  $j$  para o  $i$  na tentativa  $\tau$ .  $\alpha_w$  é a taxa de aprendizado,  $\alpha_w = 0.01$ ,  $A_{goal}$  é a atividade alvo da rede (média de disparos por tentativa), definida como 1 para os Ex e 2 para os In.  $A_i$  é a atividade média do neurônio  $i$  na tentativa  $\tau$ ,

$$A_i^{\tau+1} = A_i^{\tau} + \alpha_A [S_i^{\tau} - A_i^{\tau}] \quad (3)$$

Onde  $\alpha_A = 0.05$  é a integração de atividade através da tentativa. O parâmetro  $S^{\tau}$  é o número de disparos na tentativa  $\tau$  para cada célula e acopla a dinâmica de aprendizado e a dinâmica neural.

## Resultados Preliminares

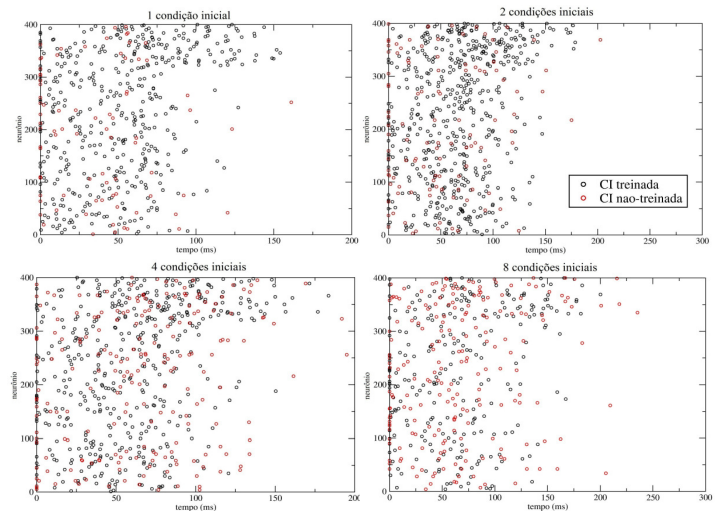


Figura 1: Raster Plot - Disparos da rede vs. tempo para as condições treinadas e não-treinadas.




Figura 2 : Média de  $S^{\tau}$  vs. Trajetória para diferentes números de condições iniciais.




Figura 3: Número de disparos na trajetória vs. o número de condições iniciais, para as condições iniciais treinadas e não-treinadas.

## Conclusões

Analisando os resultados, podemos perceber que mesmo utilizando um modelo simplificado de neurônio, conseguimos incorporar várias trajetórias para um conjunto de até 8 condições iniciais (CI). Na figura 3, podemos ver a capacidade da rede diferenciar as CI treinadas e não-treinadas. Na figura 2, conforme o aumento no número de CI a rede passa a ter picos no número de disparos por neurônio.

## Referências

- J. K. Liu e D. V. Buonomano, *J. Neurosci.* **29** 13172 (2009).
- D. V. Buonomano, *J. Neurophysiol.* **94** 2275 (2005).
- W. Gerstner e W. M. Kistler (2002). *Spiking Neuron Models. Single Neurons, Populations, Plasticity.* Cambridge University Press, disponível em <http://icwww.epfl.ch/~gerstner/SPNM/node25.html>

## Agradecimentos

