

# Avaliação dos efeitos da aplicação de topologia em redes neuronais

Marcelo Porto Becker, Rubem Erichsen Junior

## Introdução

A dinâmica de redes recorrentes em áreas corticais do encéfalo possui grande relevância na codificação de informações sensoriais. O processamento desse tipo de informação deve levar em conta características tanto espaciais como temporais desses estímulos. Estudos sugerem que tal codificação é feita como trajetórias em um espaço de fases e que a estabilidade dessas trajetórias pode ser alcançada por meio de mecanismos plásticos como *presynaptic-dependent synaptic scaling* (PSD). Entretanto nenhum estudo endereçou os efeitos da topologia sobre o processamento desse tipo de estímulo e sobre a estabilidade de tais trajetórias. Em específico, foram avaliados aqui os efeitos da variação da distribuição dos graus de saída da rede, bem como da clusterização sobre a atividade da mesma.

## Materiais e Métodos

Para averiguar esses possíveis efeitos foram construídas redes constituídas de 400 neurônios, sendo destes 320 excitatórios e 80 inibitórios. Neurônios foram modelados como neurônios de integração e disparo conforme Carnevale e Hines [1],

$$\tau \frac{dv}{dt} = -v.$$

sendo  $v$  o potencial de membrana do neurônio e  $\tau$  a constante de tempo de descarga da membrana. Para a variação na distribuição de graus de saída dos neurônios excitatórios ( $k_{out}^{EE}$ ) foi utilizado uma distribuição híbrida com a seguinte forma:

$$k_{out}^{EE} = q_{out}k^{bin} + (1 - q_{out})k^{pow}$$

onde  $k^{bin}$  e  $k^{pow}$  são valores retirados de uma distribuição binomial com média 32 e uma lei de potência, respectivamente.  $q_{out}$  é um parâmetro utilizado para interpolar as distribuições, sendo variado entre simulações. Para as demais conexões  $k_{out}^{EI} = k_{out}^{IE} = k_{out}^{II} = 5$ .

A variação da clusterização da rede foi feita do seguinte modo:  $k_{out}^{EE}$  foi tirado de uma binomial com média 20 sendo que uma fração dessas conexões foram forçadas com os vizinhos mais próximos. As demais conexões  $k_{out}^{EI}, k_{out}^{IE}, k_{out}^{II}$  foram mantidas as mesmas.

Como regras de aprendizado, foram utilizadas STDP e PSD. STDP foi implementado como proposto por van Rossum [2]

$$F(\Delta t) = \begin{cases} c_p \cdot e^{-\Delta t/\tau_p}, & \Delta t > 0 \\ c_d \cdot -e^{\Delta t/\tau_d}, & \Delta t \leq 0 \end{cases}$$

com  $\Delta t = t_{pos} - t_{pre}$ .

$$W_{ij}^{\tau+1} = W_{ij}^{\tau} + W_{ij}^{\tau} \sum_{i=1}^I \sum_{j=1}^J F(t_i - t_j).$$

PSD foi implementado conforme descrito por Buonomano [3].

$$W_{ij}^{\tau+1} = W_{ij}^{\tau} + \alpha_W A_j^{\tau} (A_{goal} - A_i^{\tau}) W_{ij}^{\tau}$$

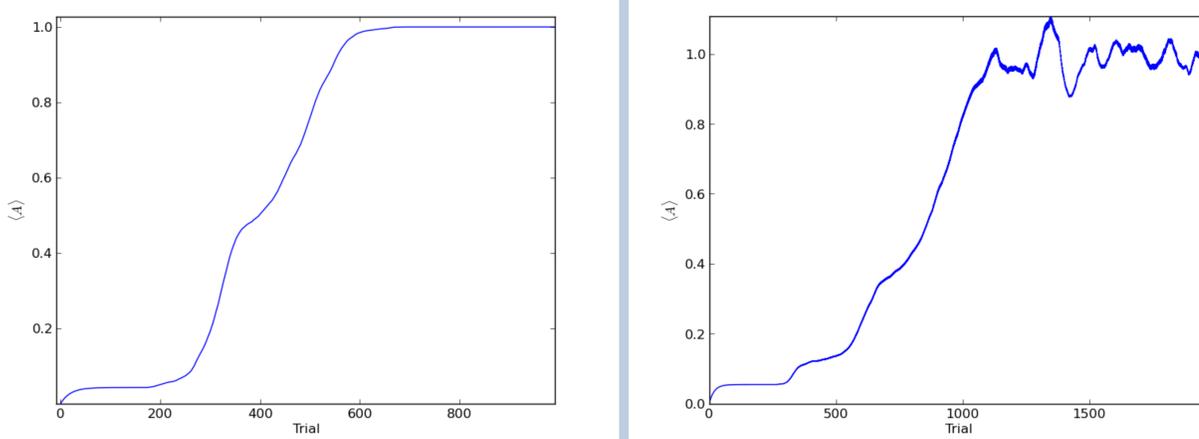
$$A_i^{\tau+1} = A_i^{\tau} + \alpha_A [S_i^{\tau} - A_i^{\tau}].$$

onde  $S_i^{\tau}$  é o número de disparos do neurônio  $i$  na etapa  $\tau$  e  $A_{goal} = 1$ .

A estabilidade da rede foi aferida observando a sua atividade média  $\langle A \rangle$  dada a apresentação de um certo número de condições iniciais previamente treinadas, sendo o treinamento feito de modo intercalado.

## Resultados

Para todas arquiteturas testadas, a atividade se estabilizou quando a rede foi treinada com uma condição inicial como exemplificado na figura 1 (esquerda). Entretanto, quando treinada com mais de uma condição inicial a atividade oscila em torno do valor de  $A_{goal}$  (fig1 - direita), sendo a amplitude das oscilações maior quanto maior o número de condições iniciais treinadas.

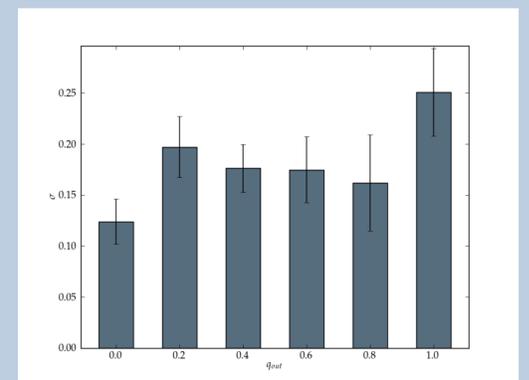


**Figura 1:** Atividade média para uma condição inicial (esquerda); atividade média para duas condições iniciais (direita)

## Resultados

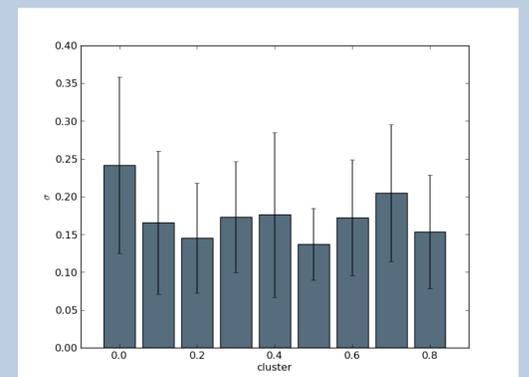
Para verificar os efeitos das diversas arquiteturas utilizadas sobre a estabilidade da rede foi mensurado o desvio padrão  $\sigma$  da atividade em um intervalo de 500 etapas. Para cada arquitetura, as medidas foram realizadas em dez redes distintas.

No caso da variação de  $k_{out}$ , observou-se uma leve tendência à menor instabilidade para  $q_{out}$  baixos (fig2). Entretanto, a alto grau de variação entre redes impossibilita a extração de qualquer conclusão.



**Figura 2**

A variação da clusterização da rede não gerou alteração significativa na estabilidade da rede. Novamente observa-se uma grande flutuação de  $\sigma$  entre trials.



**Figura 3**

## Conclusão

As arquiteturas testadas pouco efeito tiveram na estabilização da atividade da rede. Observou-se também grande variação de  $\sigma$  entre redes com o mesmo tipo de arquitetura. O relativamente pequeno tamanho da rede quando comparado com redes corticais pode ter contribuído na geração de flutuações, assim como a restrição de um disparo por etapa pode ter restringido possíveis efeitos da clusterização como os observados em [4].

## Referências

- [1] N. T. Carnevale and M. L. Hines. Efficient discrete event simulation of spiking neurons in neuron.
- [2] M. C. W. Van Rossum, G. Q. Bi, and G. G. Turrigiano. Stable hebbian learning from spike timing-dependent plasticity. *Journal of Neuroscience*, 20:8812–8821, 2000.
- [3] Dean V. Buonomano. A Learning Rule for the Emergence of Stable Dynamics and Timing in Recurrent Networks. *J Neurophysiol*, 94(4):2275–2283, October 2005.
- [4] A. Litwin-Kumar and B. Doiron. Slow dynamics and high variability in balanced cortical networks with clustered connections. *Nature neuroscience*, 15(11):1498–1505, November 2012.