

Estabilidade em redes de neurônios de integração e disparo sobre efeito de plasticidade homeostática

Marcelo Porto Becker, Rubem Erichsen Junior

Universidade Federal do Rio Grande do Sul



Introdução

A dinâmica de redes neuronais recorrentes em áreas corticais do encéfalo possui grande relevância na codificação de estímulos sensoriais e na produção de respostas motoras. O processamento desse tipo de informação deve levar em conta características tanto espaciais quanto temporais desses estímulos. Observações experimentais já foram realizadas tanto *in vitro* como *in vivo*. Um exemplo a ser citado trata-se das redes responsáveis pela geração dos padrões silábicos no canto de pássaros, as quais dependem fortemente do padrão temporal de disparos para a memorização e o aprendizado. Um possível paradigma de computação considera a codificação de estímulos espaço-temporais como a sequência de disparos realizados pela rede, ou seja, como a trajetória no espaço de estados. Para que uma rede seja capaz de realizar tal codificação, é necessário que ela gere trajetórias atrativas (atratores dinâmicos) bem como sua atividade seja estável no geral.

Buonomano [1] propôs um modelo o qual se baseia em um tipo de plasticidade homeostática chamada de *presynaptic-dependent synaptic scaling* (PSD) capaz de estabilizar a atividade da rede e gerar padrões de disparos. Entretanto, é necessário saber o quão tolerante a ruídos esses padrões são para que esses possam ser caracterizados como memórias. No presente trabalho, avaliamos a tolerância desse modelo a diversos níveis de ruído, bem como observamos possíveis mudanças estruturais nessa rede.

Materiais e Métodos

Inicialmente, construímos redes constituídas de 500 neurônios, sendo destes 400 excitatórios (E) e 100 inibitórios (I) com conexões aleatórias. Conexões entre neurônios excitatórios (EE) foram escolhidas de uma distribuição binomial com média 20, enquanto que as demais conexões (EI, IE, II) foram fixadas em 5. Neurônios foram modelados como neurônios de integração e disparo conforme Carnevale e Hines [2]

$$\tau_m \frac{dv}{dt} = -v + w \sum_k \delta(t - t_k^{spk} - t_k^{delay}),$$

sendo v o potencial de membrana do neurônio, τ a constante de tempo de descarga da membrana, w o peso da conexão, t_k^{spk} o tempo de disparo do neurônio pré-sináptico k , t_k^{delay} o tempo de atraso entre um disparo e a transferência de carga, e δ é a função delta de Dirac.

Como regras de aprendizado, foram utilizadas *Spike-timing dependent plasticity* (STDP) e PSD. STDP foi implementado como proposto por van Rossum [3]

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

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

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

onde W_{ij}^{τ} é a matriz de pesos na etapa τ . PSD foi implementado conforme descrito por Buonomano [1].

$$W_{ij}^{\tau+1} = W_{ij}^{\tau} + \alpha_W A_j^{\tau} (A_{goal} - A_i^{\tau}) W_{ij}^{\tau} \\ A_i^{\tau+1} = A_i^{\tau} + \alpha_A [S_i^{\tau} - A_i^{\tau}].$$

onde A_i^{τ} é a atividade do neurônio i na etapa τ , S_i^{τ} é o número de disparos do neurônio i na etapa τ e $A_{goal} = 1$.

As redes foram treinadas com 1 condição inicial definida como um conjunto de 20 neurônios excitatórios que disparam no tempo zero de cada etapa. Introduzimos ruído na rede selecionando η neurônios desse conjunto e substituindo por outros aleatoriamente a cada etapa.

Para analisar a estabilidade das trajetórias, treinamos inicialmente a rede até a atividade da mesma chegar ao estado estacionário. Em seguida comparamos os tempos de disparos entre duas etapas consecutivas. Se um neurônio disparar em um tempo distinto da etapa anterior, considerando um intervalo de 5% do tempo total da trajetória para mais ou para menos, consideramos um erro. Para cada valor de ruído η , obtivemos então uma razão entre disparos dentro e fora do intervalo.

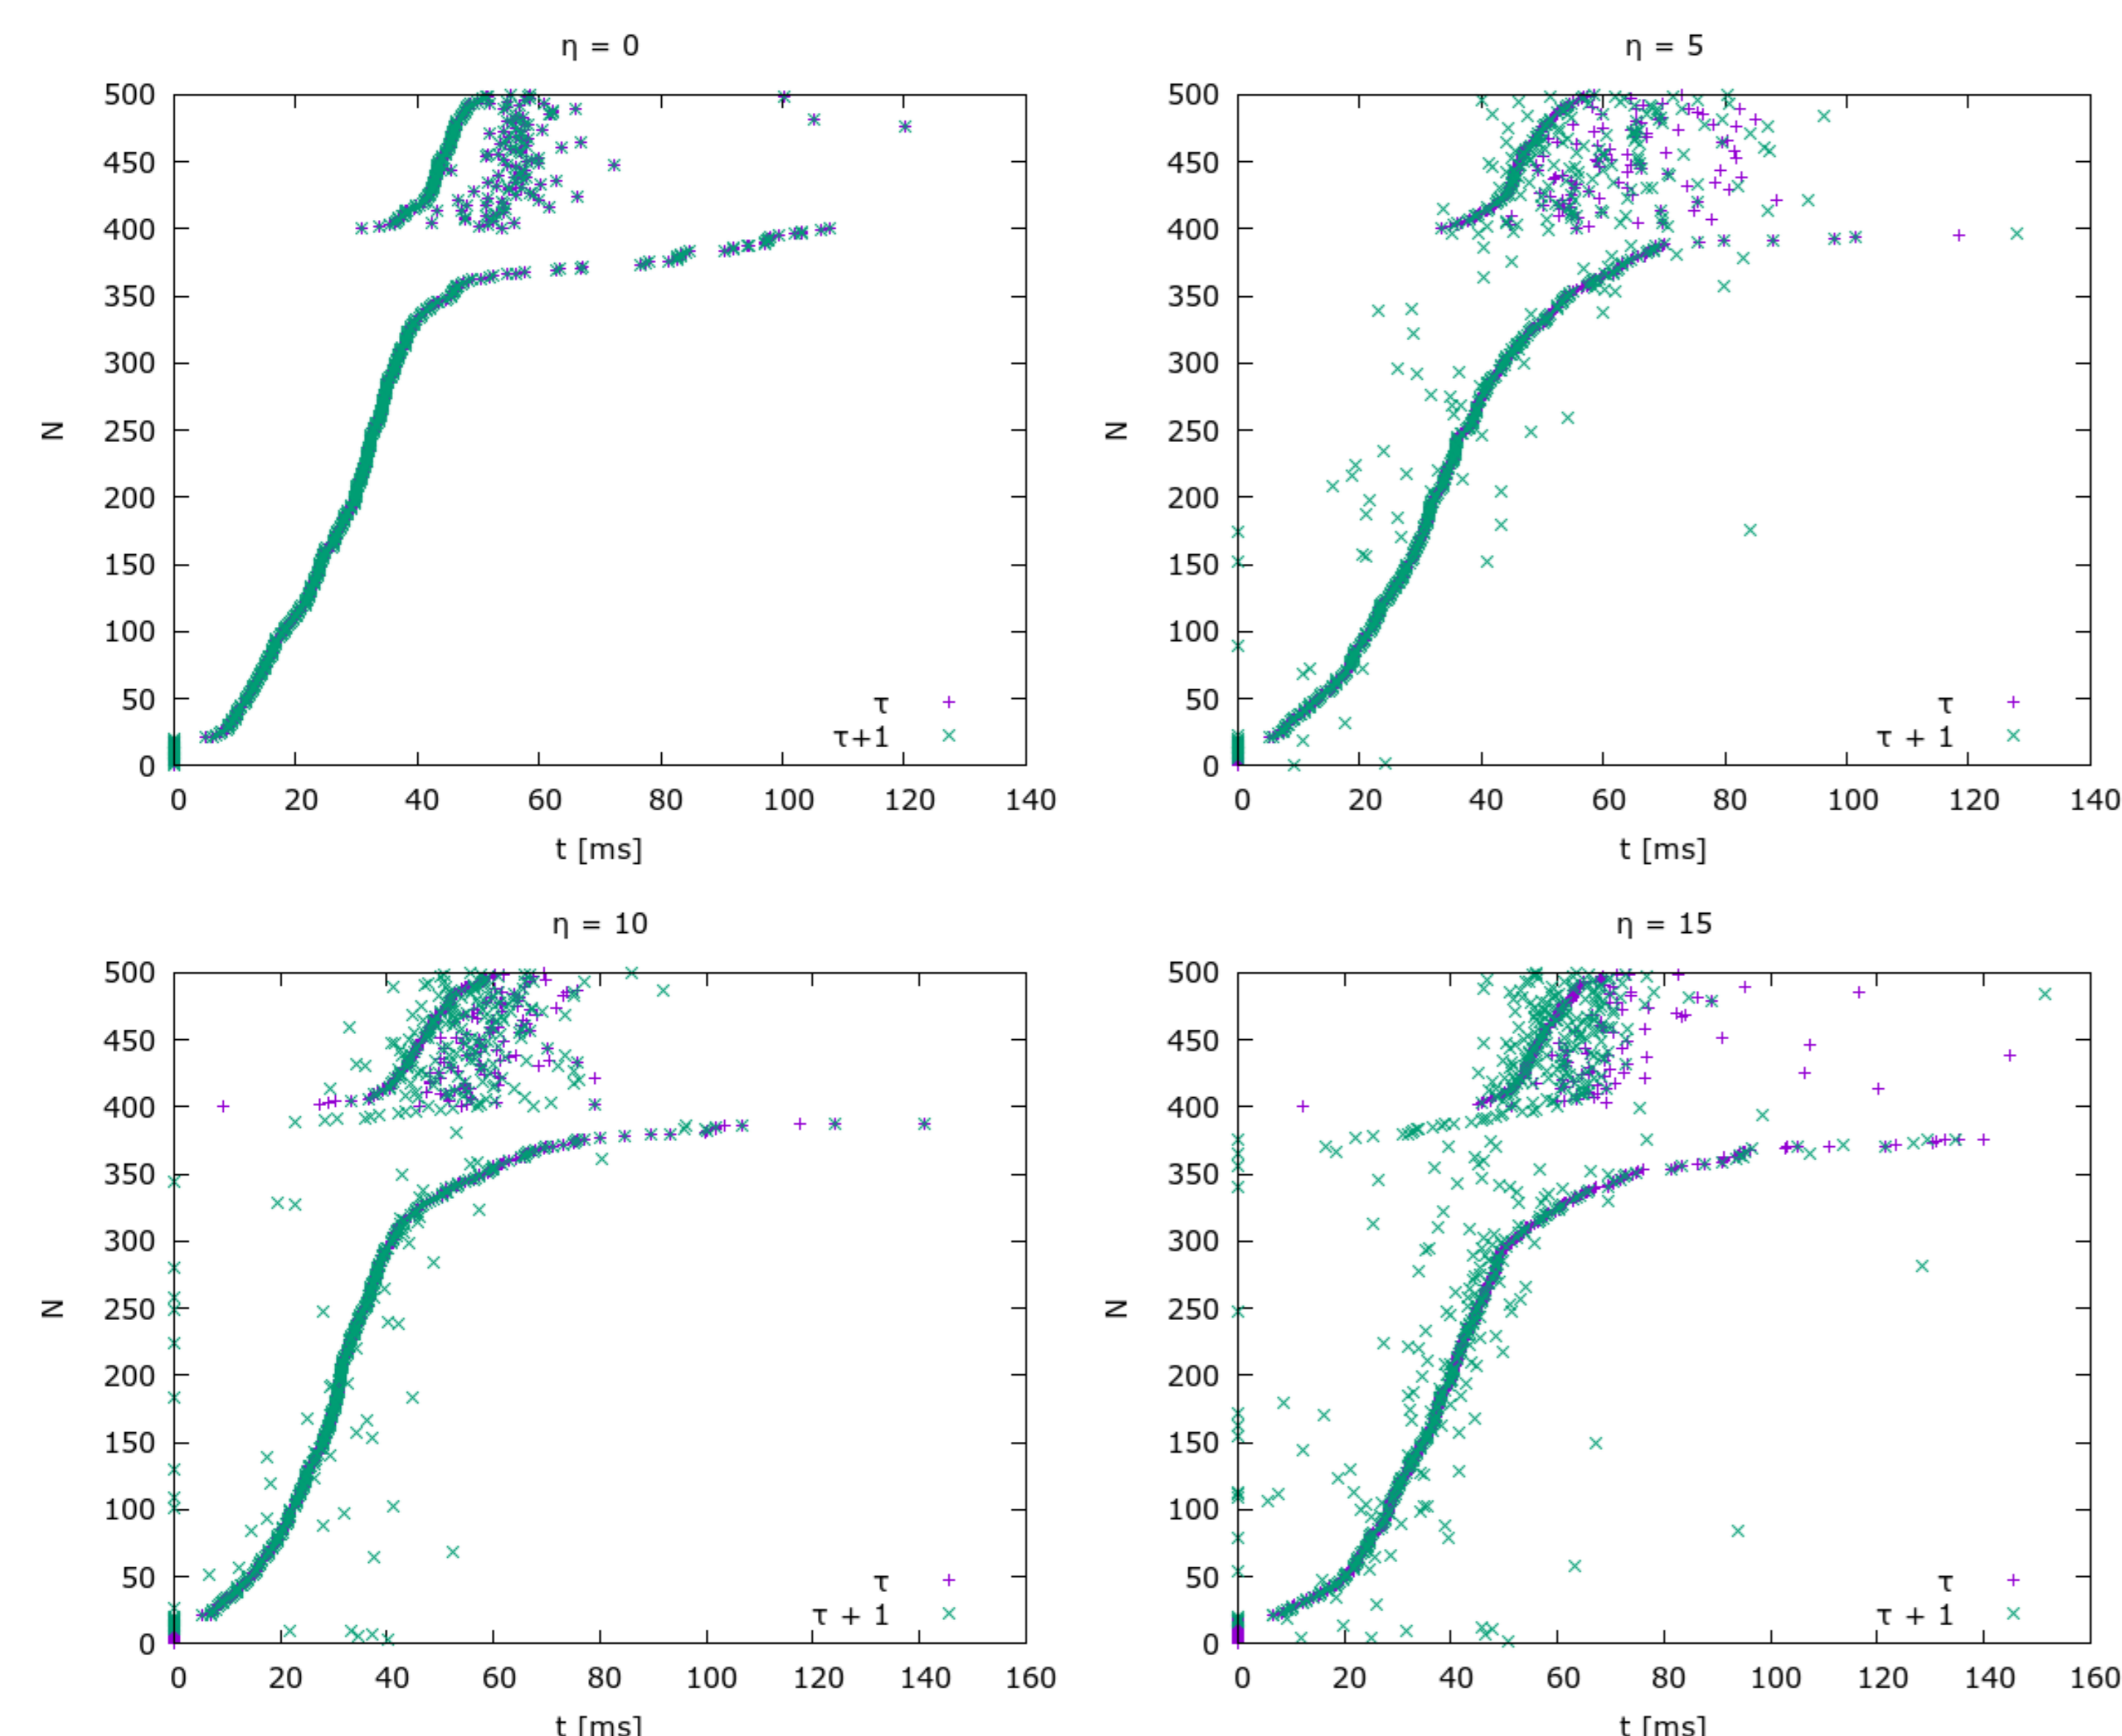


Figura 1: Scatter plot dos disparos da rede em duas etapas consecutivas para distintos valores de η .

Para a análise de estrutura, consideramos a medida de caminho mínimo (SP, do inglês *Shortest Path*) entre cada par de neurônio excitatório, calculado pelo algoritmo de Dijkstra com o inverso dos pesos.

Resultados

Primeiramente plotamos os disparos da rede em duas etapas consecutivas para valores de $\eta = 0, 5, 10, 15$ (figura 1). Notamos que em todos os casos a rede produz uma trajetória clara, porém o ruído aumenta o número de disparos fora dessa trajetória na etapa subsequente. Podemos observar melhor o efeito do ruído na figura 2. Mesmo mantendo apenas um neurônio constante na condição inicial, mais de 55% disparam no tempo correto.




Figura 2: Erro em função do ruído η . Erro é definido como a fração de disparos na etapa subsequente fora do intervalo de tolerância.

Plotamos a distribuição e a matriz de caminhos mínimos para $\eta = 0$ e $\eta = 15$ na figura 3. Podemos notar um pico mais acentuado para a rede sem ruído, enquanto que para a rede com $\eta = 15$, a distribuição é mais achatada, o pico é levemente deslocado para a esquerda e para alguns pares SP é maior que 4. Observamos também uma estrutura de malha nas matrizes de caminhos mínimos, indicando que alguns neurônios são mais bem conectados que outros. Nota-se ainda que a rede sobre efeito de ruído possui mais neurônios bem conectados que a sem ruído, indicado pela coloração mais escura.

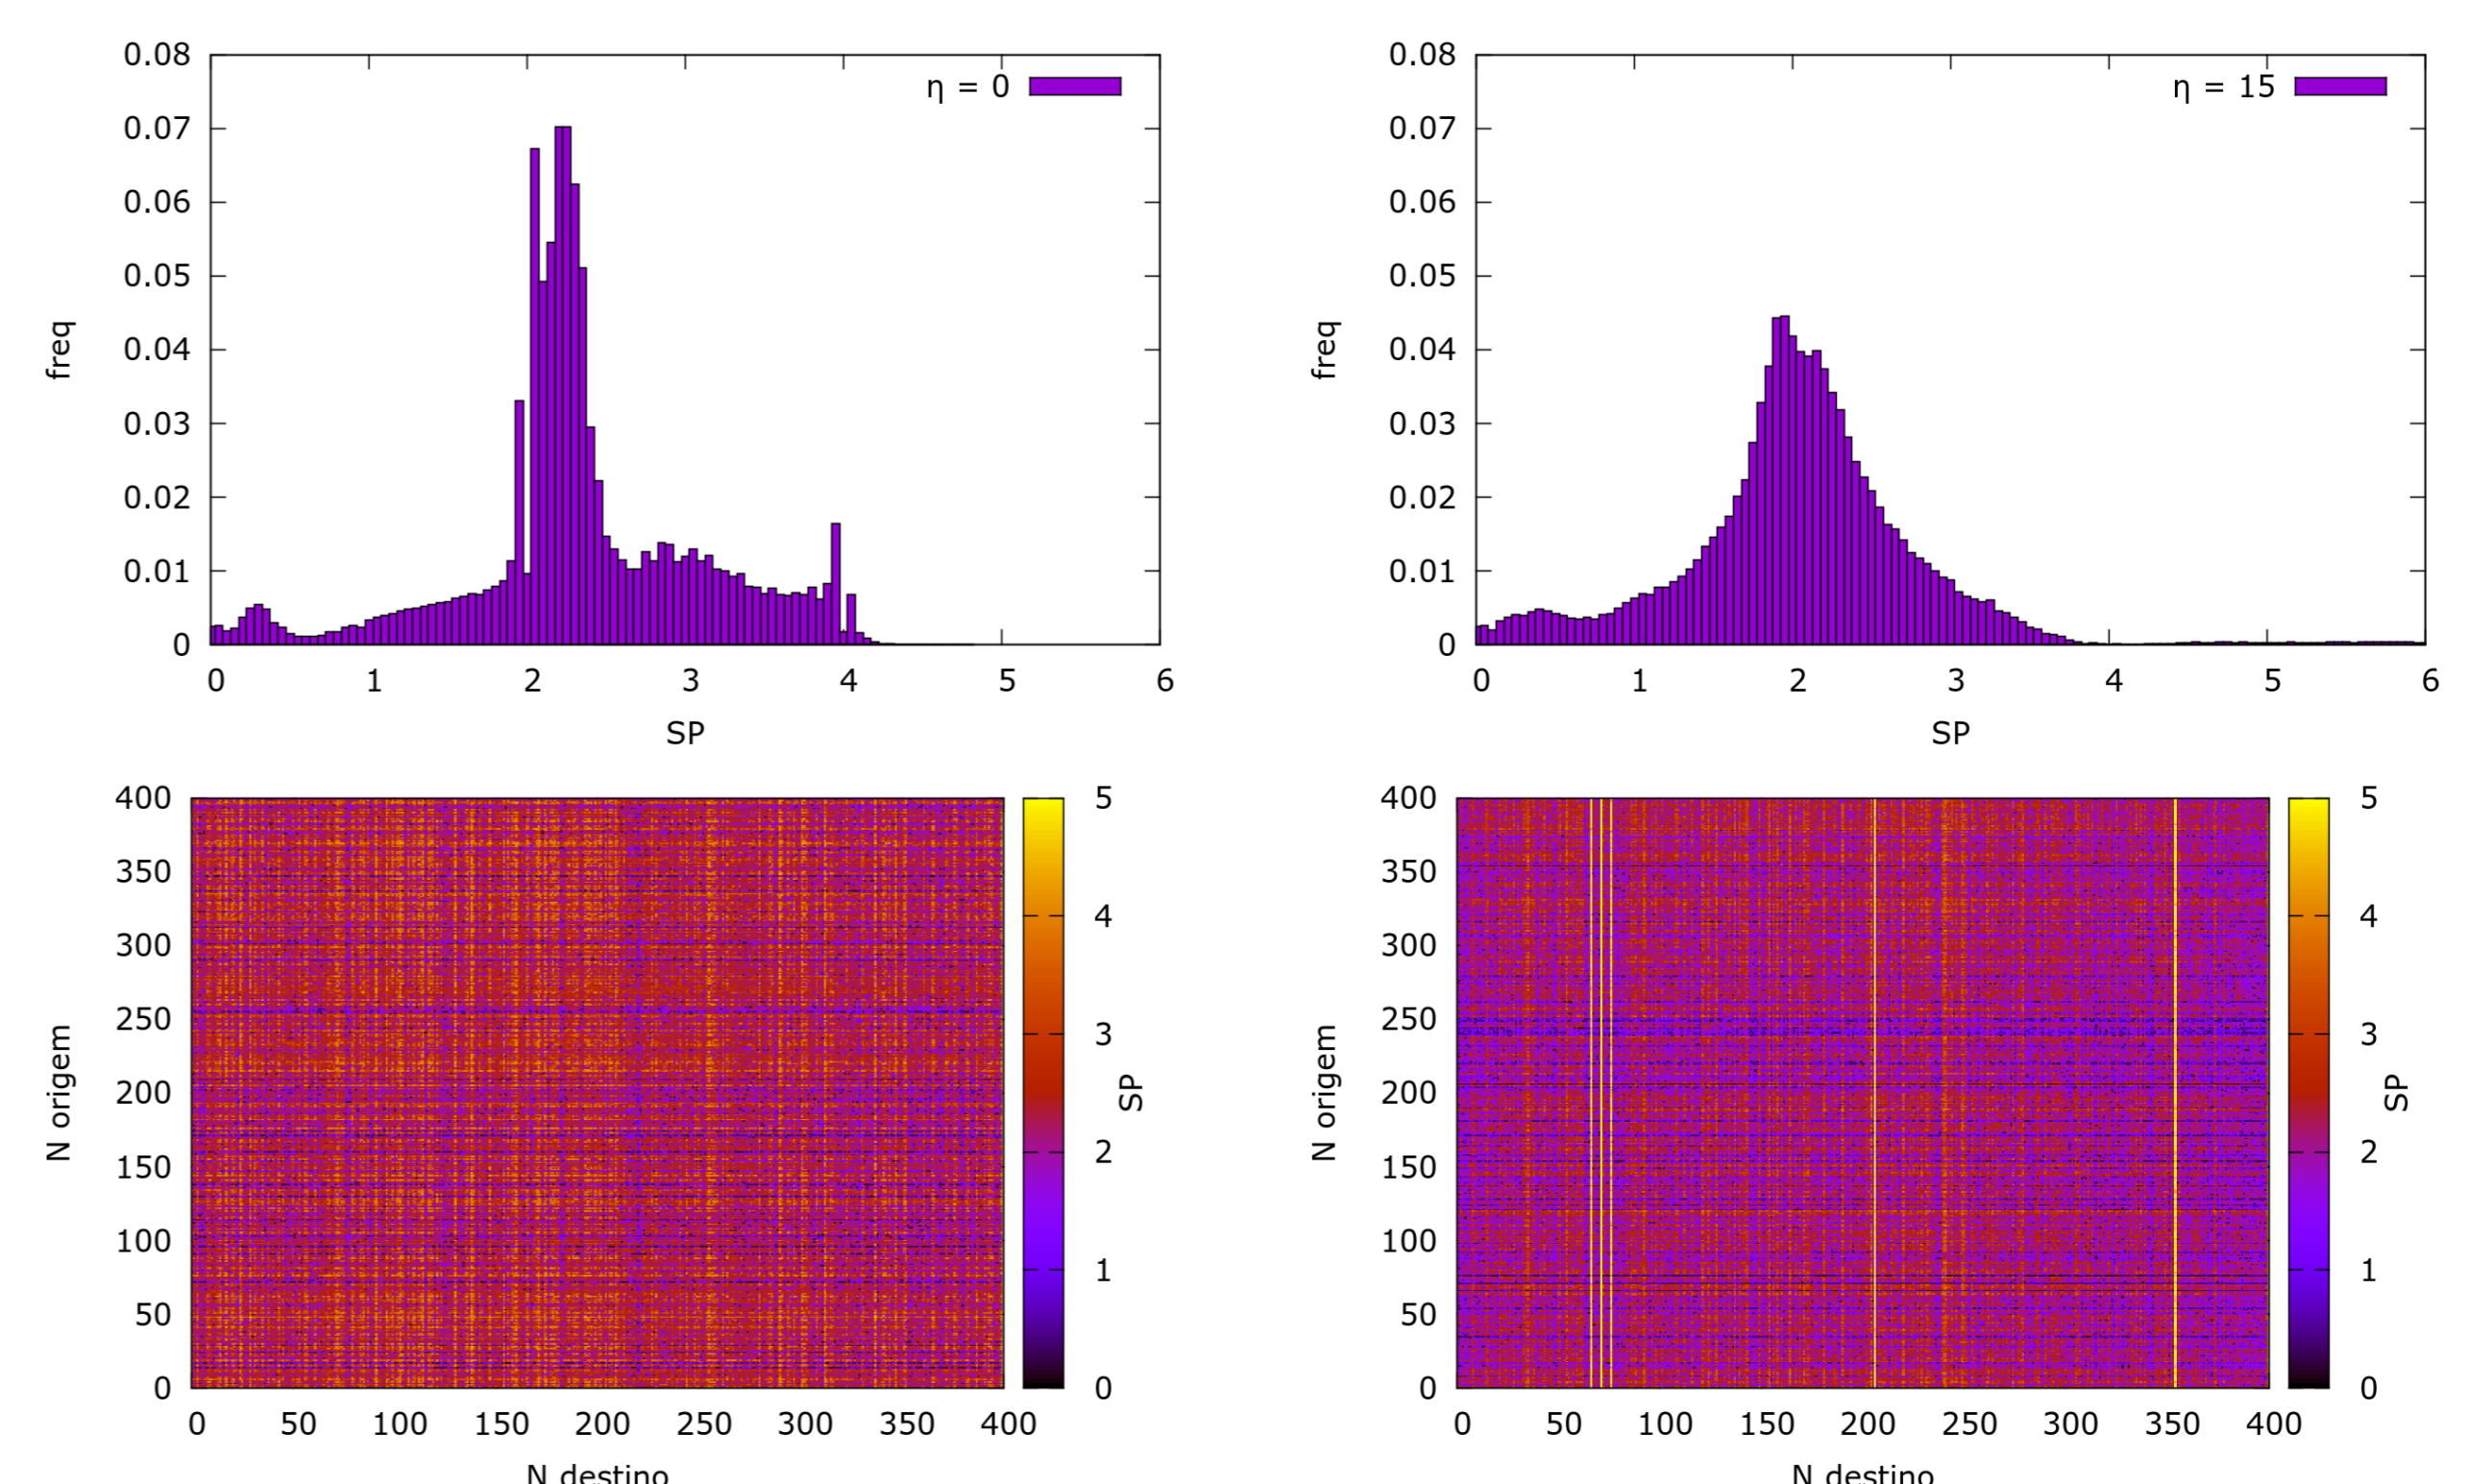


Figura 3: Distribuição (acima) e matriz (abaixo) dos caminhos mínimos para valores de $\eta = 0$ (esquerda) e $\eta = 15$ (direita).

Conclusão

Analisamos aqui o comportamento do modelo frente a diversas níveis de ruído, bem como as alterações na sua estrutura de pesos. O modelo mostrou-se capaz de manter a estrutura da trajetória até mesmo para entradas altamente ruidosas, com disparos ocorrendo nos tempos corretos no mínimo em 55% dos casos (figuras 1 e 2). Observamos também algumas alterações nas estruturas de pesos pela distribuição e matriz de caminhos mínimos (figura 3). A rede sem ruído possui um pico mais acentuado na distribuição, indicando que as regras de aprendizado tiveram mais liberdade para esculpir a estrutura que gera a dinâmica. Já a rede sobre influência de ruído, possui uma forma mais achatada e levemente deslocada para esquerda, mostrando uma menor especificidade. Esse comportamento também pode ser visto na matriz de caminhos mínimos, onde as linhas escuras estão em maior quantidade na rede com ruído.

Entretanto, o presente trabalho avalia apenas o comportamento da rede para uma condição inicial. Uma rede para ser viável deve ser capaz de codificar diversas memórias. O estudo desse modelo na presença de ruído com mais condições iniciais ainda se faz necessário.

Referências

- [1] 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.
- [2] N. T. Carnevale, M. L. Hines, and Hines Discrete. Efficient discrete event simulation of spiking neurons in neuron.
- [3] 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.