

# Avaliação do Desempenho de Redes Neurais Pulsantes na Detecção de Anomalias

Jeferson Marques de Souza (IC), Hugo Vinícius Leão e Silva (PQ)

PIBIC

Câmpus Anápolis

\* e-mail do pesquisador

**Palavras-Chave:** Redes Neurais, Neuromórfico, Detecção de Anomalias.

## Introdução

Detecção de anomalias diz respeito a encontrar dados que não estão em conformidade com a normalidade. A detecção de anomalias tem aplicações em diversos domínios, dado que é de interesse do analista descobrir os padrões inesperados (CHANDOLA; BANERJEE; KUMAR, 2009).

Redes neurais artificiais (ANN) podem ser usadas como modelos para reconhecimento e detecção de anomalias. Por outro lado, existem as redes neurais pulsantes (SNN) que se comportam de maneira muito próxima de uma rede biológica. As SNN processam a informação através da emissão de pulsos ao longo do tempo, podendo representar e integrar padrões complexos nativamente como tempo e frequência (TAHERKHANI et al., 2020). No entanto, o desenvolvimento das SNN ficou restrito ao campo da computação neuromórfica devido ao seu alto custo em hardware convencional (GHOSH-DASTIDAR; ADELI, 2009). Nesse contexto, uma das áreas em que as SNN se destacam é na detecção de anomalias, dada seu rápido aprendizado e capacidade de adaptação ao inesperado (STRATTON; WABNITZ; HAMILTON, 2020).

De forma a estudar e comparar a efetividade de cada rede faz-se um estudo comparativo entre o estado da arte de detecção de anomalias em redes neurais, a DeviationNetwork, com sua versão SNN (PANG; SHEN, 2019).

## Metodologia

Foram usados três conjuntos de dados que estavam presentes no trabalho da Deviation Network: Thyroid, Fraud e Donors. Executou-se os mesmos experimentos feitos com a Deviation Network trocando as redes a serem avaliadas. Além disso foi avaliada a arquitetura de AutoEncoder, um modelo que também é aplicado na tarefa de detecção de anomalias.

## Resultados e Discussão

Aqui as SNN consistentemente desempenham melhor que as ANN em todos os contextos em que foram aplicadas. Dessa forma, produziram as médias produzidas e dispostas na Tabela 1.

Na Tabela 1 é possível observar que as SNN conseguem uma margem de efetividade considerável sobre as ANN, justificando sua maior capacidade de aprendizado sob mesmas condições.

**Tabela 1.** Resultados dos experimentos realizados

Modelos	AUC-ROC	AUC-PR
ANN AutoEncoder	0,7716	0,0989
snnTorch AutoEncoder	<b>0,8107</b>	<b>0,2371</b>
ANN DevNet	0,9452	0,7468
snnTorch DevNet	<b>0,9683</b>	<b>0,7979</b>

Porém deve-se ressaltar que o tempo de execução das SNN é maior que o das ANN, fazendo com que seja necessário hardware dedicado para extrair o potencial das redes em sua totalidade.

## Conclusões

As SNN de fato representam um avanço em relação às ANN, mas custam muitos recursos computacionais sendo implementadas de forma convencional. O ganho de desempenho pode justificar o maior custo a depender do domínio em que podem ser utilizadas.

## Agradecimentos

Agradeço muito ao meu orientador por comprar o desafio de desbravar esse assunto tão novo e complexo que são as SNN. Agradeço ao IFG por proporcionar a oportunidade de propor esse projeto.

CHANDOLA, Varun; BANERJEE, Arindam; KUMAR, Vipin. Anomaly detection: A survey. *ACM computing surveys (CSUR)*, v. 41, n. 3, p. 1-58, 2009.

GHOSH-DASTIDAR, Samanwoy; ADELI, Hojjat. Spiking neural networks. *International journal of neural systems*, v. 19, n. 04, p. 295-308, 2009

STRATTON, Peter; WABNITZ, Andrew; HAMILTON, Tara Julia. A Spiking Neural Network Based Auto-encoder for Anomaly Detection in Streaming Data. In: **2020 IEEE Symposium Series on Computational Intelligence (SSCI)**. IEEE, 2020. p. 1981-1988.

PANG, Guansong et al. Deep learning for anomaly detection: A review. *ACM Computing Surveys (CSUR)*, v. 54, n. 2, p. 1-38, 2021.

TAHERKHANI, Aboozar et al. A review of learning in biologically plausible spiking neural networks. *Neural Networks*, v. 122, p. 253-272, 2020.