



# Redes neurais artificiais para previsão de séries temporais

## *Artificial neural networks for time series prediction*

Jefferson Michael de Azevedo Junior\*, Hugo Valadares Siqueira†,

### RESUMO

No presente trabalho, foi realizada a análise e implementação de uma rede neural do tipo perceptron de múltiplas camadas para previsão de séries temporais univariadas. Com o objetivo de avaliar o desempenho desta rede em problemas relevantes de mundo real. A rede foi implementada na linguagem Python em ambiente virtual fornecido pela plataforma *google colab*. O treinamento foi realizado com base de dados disponíveis publicamente, coletadas por *bots* e separadas em intervalos de dez minutos. Os resultados obtidos foram significativos, com taxas de erro na casa dos 0,01 no pior caso avaliado.

**Palavras-chave:** Rede Neural, Séries temporais, Perceptron múltiplas camadas.

### ABSTRACT

In this study, we perform the analysis and implementation of a multilayer perceptron neural network to predict univariate time series. In order to evaluate the performance of this network in relevant real world problems. The network was implemented in Python language in a virtual environment provided by the google collab platform. The training was conducted with publicly available databases, collected by bots and separated into ten-minute intervals. The results obtained were significant, with error rates around 0.01 in the worst case evaluated.

**Keywords:** Neural Network, Time series, Multilayer perceptron.

## 1 INTRODUÇÃO

O estudo das Redes Neurais Artificiais (RNA) tem a sua principal inspiração o funcionamento do sistema nervoso dos organismos superiores (HAYKIN, 2007; RAUBER, 2005). A estrutura cerebral, de forma simplificada, é constituída por uma rede de neurônios. Estes recebem informações pelos dendritos e, através da combinação ponderada das entradas, passam as informações pelos axônios. As conexões entre dendritos e axônios recebem o nome de sinapses (DUBIN, 2013; MOREIRA, 2013). Uma representação dessas características pode ser vista na Fig. 1.


O cérebro humano, por exemplo, consegue processar uma grande quantidade de informações contidas em uma imagem de forma muito rápida e eficaz (RASHID, 2016). Porém, para os computadores, essa tarefa não é tão simples de ser resolvida. A tecnologia ainda está muito distante de conseguir emular o comportamento biológico (HAYKIN, 2007).

\* Ciência da Computação, Universidade Tecnológica Federal do Paraná, Ponta Grossa, Paraná, Brasil; [jefjun@alunos.utfpr.edu.br](mailto:jefjun@alunos.utfpr.edu.br)

† Universidade Tecnológica Federal do Paraná, Campus PG (Ponta Grossa); [hugosiqueira@utfpr.edu.br](mailto:hugosiqueira@utfpr.edu.br)



**Figura 1 – Representação do neurônio biológico**



**Fonte: (NETO; BONINI, 2010).**

Algumas das características da rede neural biológica desejadas no desenvolvimento de uma rede neural artificial são (LOUZADA, 2013; RAUBER, 2005):

- Consistência em condições adversas: A remoção de um neurônio ou dados incompletos não afetam o resultado final;
- Aprendizagem: Exposto a diferentes ambientes, o indivíduo aprende e se adapta;
- Tratamento de incertezas: Capacidade de devolver a resposta correta com informações incompletas ou contraditórias;
- Paralelismo: Diversas funções são executadas ao mesmo tempo, de forma natural. Não existe uma ordem que deve ser seguida.

Dada tais premissas, este trabalho propõe a aplicação de modelos de redes neurais para previsão de séries temporais de mundo real.


## 2 PERCEPTRON DE MÚLTIPLAS CAMADAS

A rede perceptron de múltiplas camadas (*multilayer perceptron* – MLP) consiste em diversos neurônios artificiais interconectados em camadas. Cada conexão tem um peso que é usado para ajustar o nível do sinal recebido amplificando-o ou reduzindo-o. O sinal entra pela camada de entrada, e vai se propagando para frente, pelas camadas ocultas, até ser devolvido pela camada de saída. Quando o sinal passa da última camada, a eficiência da resposta é estimada e a correção baseada na mesma é aplicada, ou seja, os pesos são ajustados. Usualmente se utiliza o algoritmo de retropropagação do erro (*backpropagation*) (HAYKIN, 2007).

Uma MLP tem no mínimo as três camadas acima citadas. Cada uma pode ter um ou mais neurônios artificiais. É a mais conhecida entre as redes neurais artificiais (SIQUEIRA, 2013). Cada camada tem seus neurônios treinados de forma iterativa utilizando como base os dados de entrada. Nesta fase a rede recebe os dados, processa-os e ajusta-os de acordo com o erro entre a saída obtida e a saída real.

A representação visual genérica de uma MLP pode ser vista na Fig. 2, na qual os círculos representam os neurônios:

Figura 2– Representação visual de uma MLP



Fonte: (NAVLANI, [s.d.])

### 3 MÉTODO (OU PROCEDIMENTOS OPERACIONAIS DA PESQUISA)

Para realizar uma tarefa de previsão de séries temporais, o passo inicial é escolher o tamanho da entrada ou o número de atrasos (*lags*) da rede neural. Entradas maiores, além de serem mais custosas computacionalmente, não garantem uma resposta mais precisa (SIQUEIRA, 2013). Uma alternativa seria testar por força bruta uma grande quantidade de entradas possíveis e escolher qual é a melhor, porém, isso pode ser extremamente custoso e, em alguns casos, inviável. O método escolhido para seleção de entradas foi o *wrapper* de seleção progressiva (BELOTTI, 2019; SIQUEIRA, 2013). Foi utilizado um máximo de 5 atrasos.

Outra etapa importante é o pré-processamento das amostras. Esta representa uma parte importante, pois erros aqui afetam o aprendizado da rede. Equipes de análise de dados chegam a gastar de 30% a 80% do tempo e custo dos projetos neste passo (WANG; WANG, 2019).

O tratamento aplicado foi o z-score, que insere estacionariedade parcial à série (SIQUEIRA, 2013).

As duas bases de dados utilizadas contém a quantidade de usuários conectados aos servidores da empresa Steam do jogo Counter Strike Global Offensive e a outra o número de espectadores do jogo Dota assistindo ao jogo na plataforma Twitch (Disponíveis publicamente em: [Steam Database](#)). Análises desse tipo mostram-se importantes, pois usuários são exigentes e querem um serviço de qualidade, mas os recursos são limitados e precisam ser geridos com eficiência (SANTOS, 2014).


Os dados foram coletados em intervalos de dez minutos entre os períodos de 22/06/2021 as 00:00:00 até 05/07/2021 as 23:50:00 para a quantidade de jogadores e 21/08/2021 as 17:40:00 até 04/09/2021 as 17:30:00 para quantidade de espectadores. Ambas as bases contem 2016 instâncias e foram coletadas por bots que monitoram os servidores.

Da totalidade dos dados, 70% foram usados para treinamento, 15% para validação e os outros 15% para testes e podem ser visualizados na Fig. 3 e na Fig. 4.

As entradas da rede foram ajustadas de acordo com o retorno do algoritmo *wrapper*. Foi utilizado somente uma camada intermediária, com neurônios variando de 10 a 150, em incrementos de 10. A função de ativação utilizada foi a ReLU e a métrica de avaliação foi o erro quadrático médio (MSE).




**Figura 3 – Gráfico dos dados utilizados nas redes: Total de jogadores.**



**Fonte: Autoria própria (2021).**

**Figura 4 – Gráfico dos dados utilizados nas redes: Total de espectadores.**



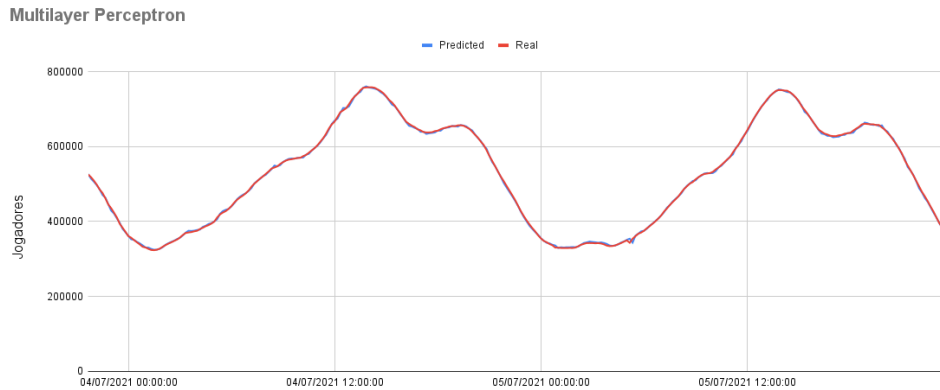
**Fonte: Autoria própria (2021).**

## 4 RESULTADOS

Utilizando os melhores valores encontrados (atrasos do método *wrapper* e quantidade de neurônios da camada intermediária), Pode-se observar na Fig. 5 o resultado dos testes na base de dados com o total de jogadores. O melhor erro encontrando foi de  $\approx 0,000262$ .

O resultado dos testes na base contendo o número total de espectadores pode ser visto na Fig. 6. Nesse caso o melhor erro encontrando foi de  $\approx 0.014290$ .

**Figura 5 – Gráfico mostrando o resultado da rede MLP contendo o total de jogadores.**



**Fonte: Autoria própria (2021).**

**Figura 6 – Gráfico mostrando o resultado da rede MLP na base de dados contendo o Total de espectadores**



**Fonte: Autoria própria (2021).**

Para obtenção desses resultados foram realizados 15 grupos treinamentos gerais variando o número de neurônios da camada intermediária, com cada grupo treinando 15 redes (devido ao método de seleção progressiva). Ou seja, um total de 450 redes foram treinadas, e mais duas para resposta final. O algoritmo, executado na plataforma *google colab*, termina sua execução em algumas horas. Os gráficos possuem extensão de  $\approx 300$  (variando de acordo com o retorno do método *wrapper*) ou seja 15% da base de dados separados para os testes. Pode-se perceber que a MLP alcançou resultados satisfatórios, com a tendência das curvas sendo bem seguidas para previsões de 1 passo à frente.

## 5 CONCLUSÃO

Redes neurais artificiais são ferramentas gerais para solução de problemas do mundo real, com classificação e previsão de séries temporais. A inspiração biológica vem do funcionamento do sistema nervoso dos organismos superiores.

Neste relatório foi implementada uma rede do tipo perceptron de múltiplas camadas, a qual foi aplicada a previsão de séries temporais univariadas. Diversas configurações foram avaliadas, com vistas a encontrar a melhor topologia para o problema abordado. Os resultados computacionais mostraram a eficiência e viabilidade da proposta para o problema selecionado.



Trabalhos futuros podem ser desenvolvidos com a aplicação de outras arquiteturas, assim como abordando séries de outras naturezas.

## AGRADECIMENTOS

Os autores agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pela bolsa de Iniciação Científica (PIBIC — Af 2020/2021) concedida ao acadêmico Jefferson Michael de Azevedo Junior.

## REFERÊNCIAS

- BELOTTI, J. T. **Previsão de vazões afluentes utilizando redes neurais artificiais e ensembles**. Dissertação (Ciência da Computação)—Ponta Grossa, PR: Universidade Tecnológica Federal do Paraná, 2019.
- DUBIN, M. W. **How the brain works**. [s.l.] John Wiley & Sons, 2013.
- HAYKIN, S. **Redes neurais: princípios e prática**. 2. ed. [s.l.] Bookman Editora, 2007.
- LOUZADA, D. R. **Deteção e caracterização de danos estruturais através de sensores a rede de Bragg e Redes Neurais Artificiais**. Ph. D. dissertation, Mech. Eng.—Rio de Janeiro, RJ: Dept., PUC-Rio, 2013.
- MOREIRA, C. Neurônio. **Revista de Ciência Elementar**, v. 1, n. 1, 2013.
- NAVLANI, A. **Multi-Layer Perceptron Neural Network using Python Machine Learning Geek**, [s.d.]. Disponível em: <<https://machinelearninggeek.com/multi-layer-perceptron-neural-network-using-python/>>. Acesso em: 8 set. 2021
- NETO, A. B.; BONINI, C. DOS S. B. Redes Neurais Artificiais: Apresentação E Utilização Do Algoritmo Perceptron Em Biosistemas/artificial Neural Networks: Introduction and Use of Perceptron Algorithm in Biosystems. **Revista Brasileira de Engenharia de Biosistemas**, v. 4, n. 2, p. 87–95, 2010.
- RASHID, T. **Make your own neural network**. [s.l.] CreateSpace Independent Publishing Platform, 2016.
- RAUBER, T. W. Redes neurais artificiais. **Universidade Federal do Espírito Santo**, v. 29, 2005.
- SANTOS, T. F. M. DOS. **Aplicação de séries temporais e redes neurais em um ambiente de computação em nuvem**. Dissertação (Mestrado Engenharia de Produção)—Santa Maria: Universidade Federal de Santa Maria, 2014.
- SIQUEIRA, H. V. **Máquinas desorganizadas para previsão de séries de vazões**. Tese (Doutorado Engenharia Elétrica e de Computação)—Campinas: Universidade Estadual de Campinas, 2013.
- WANG, X.; WANG, C. Time series data cleaning: A survey. **Ieee Access**, v. 8, p. 1866–1881, 2019.