

Previsões de séries temporais com diferentes bases de dados usando rede MLP

Time-series forecasts with different databases using MLP network

Cristiellen Heuko da Silva*,
Victor Cesar Simões de Oliveira†, Hugo Valadares Siqueira‡

RESUMO

À medida que a inteligência artificial evoluiu no decorrer dos anos, as redes neurais surgiram como uma ferramenta poderosa, capaz de aprender e tomar decisões, assim como o cérebro humano, analisando questões complexas e solucionando problemas do mundo real. Dessa maneira, utilizou-se a rede neural Perceptron de Múltiplas Camadas (MLP), e buscando analisar sua adaptabilidade e generalização, testou-se duas bases de dados com a mesma estrutura de rede, observando quão precisas as previsões seriam. Variou-se a quantidade de neurônios para cada base, buscando qual valor obteria melhor resultado. A previsão de séries temporais foi satisfatória, chegando em erros EQMs normalizados de 0.0017 e 0.1854 para base de dados do preço do Euro e de produção de energia solar, respectivamente.

PALAVRAS-CHAVE: redes neurais; séries temporais; previsões.

ABSTRACT

As artificial intelligence evolved over the years, neural networks emerged as a powerful tool capable of learning and making decisions, much like the human brain, by analyzing complex issues and solving real-world problems. In this context, the Multilayer Perceptron (MLP) neural network was used and to explore its adaptability and generalization, two datasets with the same network structure were tested to evaluate the accuracy of predictions. The number of neurons for each dataset was varied to determine the optimal configuration. The time series forecasting data generated satisfactory results, with MSE errors of 0.0017 and 0.1854 for the Euro price and solar energy production datasets, respectively.

KEYWORDS: neural network; time series; forecasts.

INTRODUÇÃO

Define-se uma Rede Neural Artificial, como um modelo matemático que tem como inspiração a formação estrutural e funções do sistema nervoso de organismos superiores, além do próprio neurônio. Diante da enorme capacidade do cérebro humano de processar informações rapidamente, pode-se dizer que uma Rede Neural é um sistema designado para modelar a performance cerebral na realização de tarefas e assim como o cérebro, ela é formada por células computacionais interconectadas conhecidas como neurônios artificiais (HAYKIN, 2009).

Os neurônios podem mudar morfológicamente conforme suas atribuições, entretanto, pode-se dizer que todo neurônio é formado por três partes básicas: axônio, dendritos e corpo celular. Paralelamente, apesar de não ser estruturalmente formado pelos mesmos elementos, o neurônio artificial possui partes responsáveis por processar as informações, integrá-las

* Bolsista PIBIC, Fundação Araucária.  Universidade Tecnológica Federal do Paraná, Ponta Grossa, Paraná, Brasil. ✉ cristiellensilva@alunos.utfpr.edu.br. ☎ 0360460106414023.  0009-0002-5817-4233.

† Bolsista PIBIT, CNPQ.  Universidade Tecnológica Federal do Paraná, Ponta Grossa, Paraná, Brasil. ✉ vic-torcesar@alunos.utfpr.edu.br. ☎ 2830129570630114.  0009-0003-8167-2836.

‡ Docente no Departamento de Engenharia Elétrica.  Universidade Tecnológica Federal do Paraná, Ponta Grossa, Paraná, Brasil. ✉ hugosiqueira@utfpr.edu.br. ☎ 6904980376005290.  0000-0002-1278-4602.



às demais e fornecer um sinal de saída, assim como o biológico (DA SILVA; D.; FLAUZINO, 2010). É a partir dessas etapas que a Rede Neural exercita suas importantes características de generalização e adaptabilidade, ou seja, é a partir do aprendizado adquirido que há a otimização dos parâmetros na solução dos problemas (HAYKIN, 2009).

Este relatório apresenta previsões de séries temporais em de duas grandes áreas: economia e engenharia elétrica (COLAS, 2019), (FINACE, 2023). No que diz respeito à economia, realizou-se a previsão de um série relacionada aos valores do Euro, uma importante moeda no cenário mundial. Adquiriu-se os dados do período de 01/04/2010 a 12/30/2022 que contém a variação dos valores do Euro (em reais) ao longo do tempo. Prever a cotação de uma moeda é de grande relevância para aqueles que buscam viajar com mais economia, além de ser um fator de segurança para empresas que buscam realizar transações de compra e venda naquela moeda, podendo significar aumento ou economia de gastos (FÉLIX; NUNES, s.d.).

Reid et.al (REID; HUSSAIN; TAWFIK, 2014) atingiram um erro quadrático médio normalizado de 0.1220 ao realizar a previsão do preço do dólar em euros. Nesse trabalho houve o teste de outras redes, além da tradicional MLP.

Na outra vertente, no que concerne à engenharia elétrica, novas tendências mundiais de produção de energia mais limpa e de sustentabilidade, proporcionaram um crescimento exponencial da utilização energia solar, essencialmente nas residências. Por ter uma instalação mais simples que outras formas de geração, a energia solar têm se tornado protagonista e provido eletricidade à comunidades mais afastadas e àqueles que buscam economizar na sua conta. Assim, realizar tal previsão em um determinado local pode, indubitavelmente, melhorar etapas de planejamento da operação, além de buscar ampliar locais produtores em potencial (PEREIRA; OLIVEIRA, 2011). Os dados de energia solar foram obtidos pela Administração Oceanográfica e Atmosférica Nacional e os arquivos de dados de produção de energia (saída) do parque solar Urbana-Champaign em kilowatt-hora, do período de 02/01/2016 a 29/10/2017.

De maneira análoga, Sharadga et al. (SHARADGA; HAJIMIRZA; BALOG, 2020) comparou diversas redes para a tarefa de previsão de dados de potência fotovoltaica (MW), datados de 13/01/2010 a 29/10/2010, com base em uma coleta localizada em uma usina fotovoltaica conectada à rede localizada no sul da China. A rede MLP conseguiu um bom desempenho com erro RMSE (*root mean squared-error*) de 1.365, ficando atrás apenas da LSTM (*Long Short Term Memory*) com RMSE de 1.102.

PERCEPTRON DE MÚLTIPLAS CAMADAS (MLP)

O Perceptron é considerado a forma mais simples de representação de uma rede neural, visto que é formado exclusivamente por um neurônio e usa a atualização dos seus pesos sinápticos e bias, como forma de resolver problemas linearmente separáveis.

Uma rede *Perceptron* de Múltiplas Camadas (MLP- *Multilayer Perceptron*) tem como característica, possuir pelo menos uma camada intermediária, também conhecida como camada escondida, entre as camadas de entrada e saída. Diferentemente do *Perceptron*, as MLPs atuam nas mais diversas aplicações por não possuírem a linearidade como uma limitação, contando ainda com uma alta versatilidade (DA SILVA; D.; FLAUZINO, 2010).

No que tange à estrutura da rede MLP, além da sua camada intermediária típica, ela possui uma função de ativação, quase sempre, não-linear e diferenciável. Outro atributo desta rede é a arquitetura *Feedforward*, ou seja, a propagação é unidirecional da entrada

para a saída (DA SILVA; D.; FLAUZINO, 2010).

Em relação ao aprendizado, afirma-se que esse é realizado de maneira supervisionada, ou seja, há uma relação de entrada e saída com base em valores já conhecidos (FONTANA, 2020). No treinamento, há atualização de pesos sinápticos até que se atinja o melhor valor referente ao que é desejado ou que o critério de parada seja atingido. Para isso, é imprescindível que seja feita uma análise de erro, com base na Eq. (3) mostrada mais adiante (BELOTTI *et al.*, 2020).

MATERIAL E MÉTODOS

Para realizar as previsões de séries temporais, o primeiro passo foi a organização das bases de dados utilizadas, visto que essas possuíam dados faltantes e valores nulos. Com estas já estruturadas corretamente, separou-se o conjunto em treinamento, validação e teste, sendo que a porcentagem foi de 70% de treinamento e 15% para validação e 15% teste. Na validação, utilizou-se o tipo *hold-out*.

No que diz respeito à função de ativação utilizada, leva-se em conta a necessidade de uma função diferenciável. Dito isso, optou-se pelo uso da Tangente Hiperbólica (Eq. (1)) e da Sigmoid (Eq. (2)), buscando qual apresentaria um melhor desempenho. Após testes preliminares, verificou-se que a primeira obteve melhor desempenho.

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (1)$$

$$S(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

Ainda sobre a função de ativação, vale ressaltar que para Tangente Hiperbólica, é necessário que a normalização dos dados seja entre -1 e 1, visto que esse intervalo compreende valores não-lineares. Já em relação à função Sigmoid, a normalização foi feita entre os valores 0 e 1.

Para a escolha do número de neurônios da camada intermediária foi utilizada uma metodologia empírica, na qual, executou-se a rede variando a quantidade de neurônios de 5 até 105, dando um salto de 5 em 5. Com essa variação, fica evidente que aumentar a quantidade de neurônios, nem sempre significa melhorar o desempenho da rede (SIQUEIRA *et al.*, 2018).

O método utilizado para a escolha do melhor modelo, deu-se com base no Erro Quadrático Médio (*Mean squared error*, MSE) descrito na Eq. (3), esse analisado no treinamento e validação.

$$MSE = \frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2 \quad (3)$$

Testou-se também a quantidade de atrasos (*lags*) para a previsão, colocando dois, quatro ou oito. Para estas mudanças, observou-se alguma diferença nos resultados, optando assim pela permanência de dois em ambas as bases de dados.

Em relação às épocas e às rodadas manteve-se a quantidade de 100 épocas e 30 rodadas independentes para o conjunto de dados do preço do Euro, visto que o aumento de épocas não demonstrou mudança significativa no erro, tendo esse já estabilizado. Já nos dados de energia solar, fez-se necessária a realização de 1000 épocas e 30 rodadas.

A escolha de realização de 30 rodadas, deu-se pela possibilidade de chegar a bacias

de atração diferentes, o que pode reduzir ou aumentar o erro, buscando sempre chegar a mínimos locais.

RESULTADOS E DISCUSSÃO

Como mencionado, para aplicar os conhecimentos e entender o funcionamento de uma rede neural na prática, optou-se por analisar as duas bases de dados: previsão de energia solar e previsão do preço do euro. Para tanto, foi considerada uma previsão de 1 passo à frente.

Em relação à previsão de energia, obteve-se os seguintes resultados gráficos nas Fig. 2 e Fig. 1:

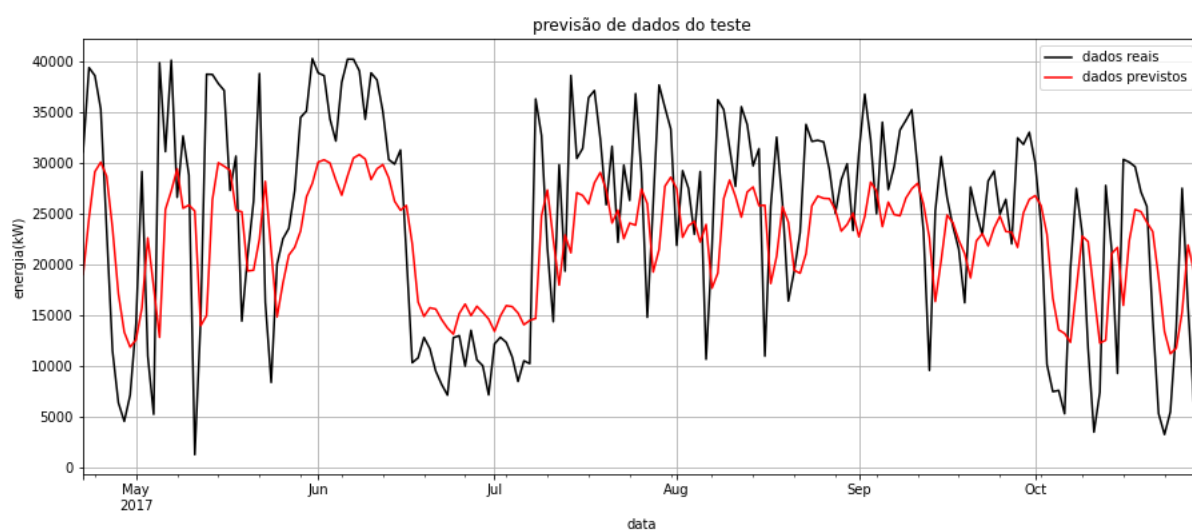


Figura 1 – Gráfico da previsão da rede MLP




Figura 2 – Curva do erro da previsão

Na figura 2, pode-se notar que o erro ficou na faixa de 0.19, sendo que o melhor número de neurônios foi de 20, proporcionando assim um bom resultado da rede na previsão. Na figura 1, em vermelho, tem-se os dados previstos pela rede MLP, datada entre maio e outubro de 2017. Em preto, por outro lado, encontram-se os dados reais que deveriam ter sido obtidos pela MLP.



Figura 3 – Gráfico de previsão do euro usando MLP

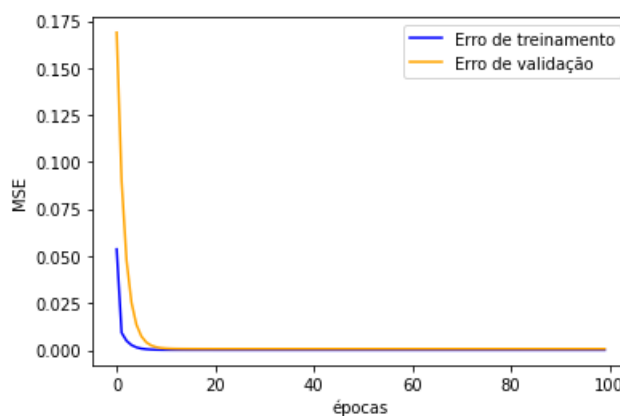


Figura 4 – Curva do erro da previsão

Já na previsão do preço do euro, os gráficos obtidos tiveram este comportamento nas Fig. 4 e Fig. 3:

Na imagem 4, pode-se observar que o erro ficou na faixa de 0.0015, sendo que o melhor número de neurônios foi 80, que geraram os pesos capazes de realizar uma etapa de teste satisfatória. Na figura 3, fica patente o poder de aproximação da referida rede neural.

Outra questão que vale ser ressaltada é o fato da base do euro, possuir mais de 3 mil dados, enquanto a base de energia solar, possuir apenas 600, apresentando características estatísticas distintas.

CONCLUSÕES

Este artigo apresentou a aplicação da rede *Perceptron* de Múltiplas Camadas (MLP), para classificação de duas bases de dados distintas, uma de previsão do preço do euro e a outra, previsão de energia solar.

Os resultados obtidos mostraram que a rede MLP tem uma alta capacidade de realizar previsões, com EQMs normalizados de 0.0017 e 0.1854 para o teste. Isso mostra o potencial de aplicação da MLP e justifica sua popularidade dentre as demais redes.

No que tange a trabalhos futuros sobre o tema, há uma gama de outras configurações de rede que podem ser aplicadas para resolver as previsões, além de utilizar outras bases

de dados para estudo.

Agradecimentos

Agradeço à Fundação Araucária pela bolsa de iniciação científica e à UTFPR.

Conflito de interesse

Não há conflito de interesse

REFERÊNCIAS

BELOTTI, Jônatas *et al.* Neural-Based Ensembles and Unorganized Machines to Predict Streamflow Series from Hydroelectric Plants. **Energies**, v. 13, n. 18, 2020. ISSN 1996-1073. Disponível em: <https://www.mdpi.com/1996-1073/13/18/4769>.

COLAS, Gael. **Machine-Learning-for-Solar-Energy-Prediction**. [S. l.: s. n.], 2019. Disponível em: <https://github.com/ColasGael/Machine-Learning-for-Solar-Energy-Prediction/tree/master/Datasets/daily>.

DA SILVA, I.N.; D., Spatti; FLAUZINO, R. **Redes neurais artificiais para engenharia e ciências aplicadas: curso prático**. São Paulo, SP, Brasil: Artliber, 2010. ISBN 978-85-88098-53-4.

FÉLIX, Ricardo Mourinho; NUNES, Luis Catela. UM MODELO DE PREVISÃO BAYESIANO PARA A ÁREA DO EURO.

FINACE, Yahoo. **Preço do Euro**. [S. l.: s. n.], 2023. Disponível em: <https://finance.yahoo.com/quote/EURUSD%3DX/history?p=EURUSD%3DX>.

FONTANA, Éliton. Introdução aos algoritmos de aprendizagem supervisionada. **Departamento de Engenharia Química, Universidade Federal do Paraná**, 2020.

HAYKIN, S. **Neural networks and learning machines**. Hamilton, Ontario, Canada: Pearson, 2009. ISBN 13: 978-0-13-147139-9.

PEREIRA, M; OLIVEIRA, Manuel-Curso Técnico Instalador de. **Energia solar fotovoltaica**. [S. l.]: Publindústria, 2011.

REID, David; HUSSAIN, Abir Jaafar; TAWFIK, Hissam. Financial time series prediction using spiking neural networks. **PloS one**, Public Library of Science San Francisco, USA, v. 9, n. 8, e103656, 2014.

SHARADGA, Hussein; HAJIMIRZA, Shima; BALOG, Robert S. Time series forecasting of solar power generation for large-scale photovoltaic plants. **Renewable Energy**, Elsevier, v. 150, p. 797–807, 2020.

SIQUEIRA, Hugo *et al.* Performance analysis of unorganized machines in streamflow forecasting of Brazilian plants. **Applied Soft Computing**, v. 68, p. 494–506, 2018. ISSN 1568-4946. DOI: <https://doi.org/10.1016/j.asoc.2018.04.007>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1568494618301935>.