



Ricardo Augusto Manfredini
Geraldo Nunes Corrêa
Bruno Rodrigues de Oliveira
Suellen Teixeira Zavadzki de Pauli
Organizadores

Aplicações de Machine Learning



2021

Ricardo Augusto Manfredini
Geraldo Nunes Corrêa
Bruno Rodrigues de Oliveira
Suellen Teixeira Zavadzki de Pauli
Organizadores

Aplicações de Machine Learning



Pantanal Editora

2021

Copyright© Pantanal Editora

Editor Chefe: Prof. Dr. Alan Mario Zuffo

Editores Executivos: Prof. Dr. Jorge González Aguilera e Prof. Dr. Bruno Rodrigues de Oliveira

Diagramação: A editora. **Diagramação e Arte:** A editora. **Imagens de capa e contracapa:** Canva.com. **Revisão:** O(s) autor(es), organizador(es) e a editora.

Conselho Editorial

Grau acadêmico e Nome

Prof. Dr. Adaylson Wagner Sousa de Vasconcelos
Prof. Msc. Adriana Flávia Neu
Prof. Dra. Albys Ferrer Dubois
Prof. Dr. Antonio Gasparetto Júnior
Prof. Msc. Aris Verdecia Peña
Prof. Arisleidis Chapman Verdecia
Prof. Dr. Arinaldo Pereira da Silva
Prof. Dr. Bruno Gomes de Araújo
Prof. Dr. Caio Cesar Enside de Abreu
Prof. Dr. Carlos Nick
Prof. Dr. Claudio Silveira Maia
Prof. Dr. Cleberton Correia Santos
Prof. Dr. Cristiano Pereira da Silva
Prof. Ma. Dayse Rodrigues dos Santos
Prof. Msc. David Chacon Alvarez
Prof. Dr. Denis Silva Nogueira
Prof. Dra. Denise Silva Nogueira
Prof. Dra. Dennyura Oliveira Galvão
Prof. Dr. Elias Rocha Gonçalves
Prof. Me. Ernane Rosa Martins
Prof. Dr. Fábio Steiner
Prof. Dr. Fabiano dos Santos Souza
Prof. Dr. Gabriel Andres Tafur Gomez
Prof. Dr. Hebert Hernán Soto Gonzáles
Prof. Dr. Hudson do Vale de Oliveira
Prof. Msc. Javier Revilla Armesto
Prof. Msc. João Camilo Sevilla
Prof. Dr. José Luis Soto Gonzales
Prof. Dr. Julio Cezar Uzinski
Prof. Msc. Lucas R. Oliveira
Prof. Dra. Keyla Christina Almeida Portela
Prof. Dr. Leandris Argentele-Martínez
Prof. Msc. Lidiene Jaqueline de Souza Costa Marchesan
Prof. Dr. Marco Aurélio Kistemann
Prof. Msc. Marcos Pisarski Júnior
Prof. Dr. Marcos Pereira dos Santos
Prof. Dr. Mario Rodrigo Esparza Mantilla
Prof. Msc. Mary Jose Almeida Pereira
Prof. Msc. Núbia Flávia Oliveira Mendes
Prof. Msc. Nila Luciana Vilhena Madureira
Prof. Dra. Patrícia Maurer
Prof. Msc. Queila Pahim da Silva
Prof. Dr. Rafael Chapman Auty
Prof. Dr. Rafael Felipe Ratke
Prof. Dr. Raphael Reis da Silva
Prof. Dr. Renato Jaqueto Goes
Prof. Dr. Ricardo Alves de Araújo
Prof. Dra. Sylvana Karla da Silva de Lemos Santos
Prof. Dr. Wéverson Lima Fonseca
Prof. Msc. Wesclen Vilar Nogueira
Prof. Dra. Yilan Fung Boix
Prof. Dr. Willian Douglas Guilherme

Instituição

OAB/PB
Mun. Faxinal Soturno e Tupanciretã
UO (Cuba)
IF SUDESTE MG
Facultad de Medicina (Cuba)
ISCM (Cuba)
UFESSPA
UEA
UNEMAT
UFV
AJES
UFGD
UEMS
IFPA
UNICENTRO
IFMT
UFMG
URCA
ISEPAM-FAETEC
IFG
UEMS
UFF
(Colômbia)
UNAM (Peru)
IFRR
UCG (México)
Mun. Rio de Janeiro
UNMSM (Peru)
UFMT
Mun. de Chap. do Sul
IFPR
Tec-NM (México)
Consultório em Santa Maria
UFJF
UEG
FAQ
UNAM (Peru)
SEDUC/PA
IFB
IFPA
UNIPAMPA
IFB
UO (Cuba)
UFMS
UFPI
UFG
UEMA
IFB
UFPI
FURG
UO (Cuba)
UFT

Conselho Técnico Científico

- Esp. Joacir Mário Zuffo Júnior

- Esp. Maurício Amormino Júnior
- Esp. Tayronne de Almeida Rodrigues
- Lda. Rosalina Eufrausino Lustosa Zuffo

Ficha Catalográfica

Dados Internacionais de Catalogação na Publicação (CIP)
(eDOC BRASIL, Belo Horizonte/MG)

A642 Aplicações de machine learning [livro eletrônico] / Organizadores Ricardo Augusto Manfredini... [et al.]. – Nova Xavantina, MT: Pantanal, 2021. 55 p. : il.

Formato: PDF

Requisitos de sistema: Adobe Acrobat Reader

Modo de acesso: World Wide Web

ISBN 978-65-81460-20-4

DOI <https://doi.org/10.46420/9786581460204>

1. Inteligência artificial. 2. Redes neurais. 3. Aprendizado de máquina. I. Manfredini, Ricardo Augusto. II. Corrêa, Geraldo Nunes. III. Oliveira, Bruno Rodrigues de. IV. Pauli, Suellen Teixeira Zavadzki de.

CDD 006.3

Elaborado por Maurício Amormino Júnior – CRB6/2422



Nossos e-books são de acesso público e gratuito e seu download e compartilhamento são permitidos, mas solicitamos que sejam dados os devidos créditos à Pantanal Editora e também aos organizadores e autores. Entretanto, não é permitida a utilização dos e-books para fins comerciais, exceto com autorização expressa dos autores com a concordância da Pantanal Editora.

Pantanal Editora

Rua Abaete, 83, Sala B, Centro. CEP: 78690-000.
Nova Xavantina – Mato Grosso – Brasil.
Telefone (66) 99682-4165 (Whatsapp).
<https://www.editorapantanal.com.br>
contato@editorapantanal.com.br

APRESENTAÇÃO

Este livro aborda cinco diferentes contextos em que as técnicas de aprendizado de máquina podem ser utilizadas, servindo como referência prática em diferentes abordagens, tais como: previsão de consumo de energia elétrica, previsão do valor do preço do petróleo, classificação de arritmias cardíacas e método para a seleção automática de artigos.

Estas aplicações são explanadas pelos autores e diferentes técnicas de aprendizado de máquina são utilizadas, dentre elas: redes neurais (Dense, convolucional, recorrentes, Perceptron multicamadas, Elman e Jordan), Naïve Bayes e mineração de textos. Para a aplicação os autores empregam os softwares (línguas de programação) Python e R. Com o objetivo de apresentar aplicações de algumas das técnicas com destaque na atualidade, primeiramente há um descritivo a respeito de cada abordagem e então, são reportados os treinamentos dos modelos de aprendizado de máquina e os resultados. As técnicas incluem classificação, regressão e também mineração de texto. As possíveis abordagens para os problemas relatados não se restringem às técnicas utilizadas, mas a intenção é motivar o leitor a explorar aplicações na área de aprendizado de máquina.

O livro é destinado a profissionais, estudantes, pesquisadores e demais interessados no tema aprendizado de máquina, estatística e áreas relacionadas a fim de colaborar com a explanação de possibilidades de aplicações destas técnicas em contextos diversos. Presume-se que o leitor esteja familiarizado com os conceitos básicos de machine learning, álgebra linear, probabilidade, e análise de algoritmos. A intenção com esta obra é, primordialmente, explicar as possibilidades de aplicação dos algoritmos elencados.

Nos capítulos 1 e 2 as técnicas de redes neurais artificiais são aplicadas para a previsão de preço do valor de petróleo e consumo de energia elétrica, respectivamente. Tais técnicas tratam de modelos computacionais inspirados no sistema nervoso central de um animal. Elas são apresentadas como um sistema de neurônios interconectados, que podem computar valores de entradas, simulando o comportamento de redes neurais biológicas. Na primeira abordagem a autora utiliza as redes Perceptron multicamadas, Elman e Jordan, já na segunda o autor faz uso das redes híbridas Dense, convolucional e recorrente.


No capítulo 3 é tratada a classificação de arritmias cardíacas e, além da técnica de Naïve Bayes também é utilizada a Transformada Wavelet, que é uma transformada integral que utiliza função wavelets que são capazes de decompor determinado sinal (dado) em diferentes escalas. Além desta, também é empregada uma técnica de Ensemble, que encapsula os modelos obtidos por vários algoritmos de aprendizagem a fim de obter uma única previsão global. Por fim, no capítulo 4 é abordado um método para a seleção automática de artigos. Para isto, é utilizado mineração de texto, que trata do processo de obtenção de informações importantes de um texto.


Os organizadores

SUMÁRIO

Apresentação	4
Capítulo I.....	6
Predição diária do preço de petróleo WTI	6
Capítulo II	15
Redes Neurais Artificiais Híbridas Para a Predição de Consumo de Energia Elétrica	15
Capítulo III.....	32
Reconhecimento de padrões de arritmias cardíacas no Eletrocardiograma (ECG) empregando Transformada Wavelet e o classificador Naïve Bayes	32
Capítulo IV	45
Uso da mineração de textos na análise exploratória de artigos científicos.....	45
Índice Remissivo	54
Sobre os organizadores.....	55

Predição diária do preço de petróleo WTI

 10.46420/9786581460204cap1

Suellen Teixeira Zavadzki de Pauli^{1*} 

INTRODUÇÃO

Há situações no cotidiano em que nos deparamos com análises de dados obtidos ao longo do tempo, de forma sequencial, sendo estas informações coletadas em intervalos de horas, dias, meses ou outras medidas temporais. Alguns exemplos deste tipo de análise são a previsão de demanda semanal em uma indústria, valores máximos em ações na bolsa de valores a cada minuto, temperatura máxima do ar a cada hora, preço histórico diário do petróleo WTI.

Uma característica intrínica deste tipo de dados é que possuem dependência entre as observações. Neste sentido, há modelos estatísticos bastante sólidos na literatura que concentram-se na análise desta dependência. Tais modelos assumem que a série temporal segue um modelo estocástico com forma conhecida. Inicialmente, a classe de modelos estacionários obteve grande destaque, estes assumem que o processo permanece em equilíbrio estatístico, com propriedades probabilísticas que não mudam ao longo do tempo, variando sobre um nível médio constante fixo e com variância constante. Posteriormente, outros modelos foram propostos, dado o desafio da não estacionariedade das séries (Box et al., 2015).

Um modelo que descreve a estrutura de probabilidade de uma sequência de observações é denominado de processo estocástico. Alguns processos estocásticos estacionários são bastante tradicionais na literatura, como o autorregressivo (*autoregressive*, AR), o média móvel (*moving average*, MA) e o autorregressivo-média móvel (*autoregressive-moving average*, ARMA). Com a necessidade de modelos para procesos não estacionários, foram desenvolvidos também os autorregressivos de média móvel integrada (*autoregressive integrated moving average*, ARIMA). Além destes, há outras variações, para mais detalhes a respeito destes modelos ver (Brockwell et al., 2016; Box et al., 2015).

O mecanismo que gera a série temporal é frequentemente pensado para considerar três componentes: sazonal, tendência e um erro aleatório. A presença de tendência e variação sazonal pode ser difícil de estimar e remover, porém, isto é bastante importante nas abordagens estatísticas tradicionais pois é necessária a especificação para assumir um modelo de série temporal. O uso das redes neurais neste contexto não necessita de especificações das relações entre variáveis de entrada e de saída. As camadas ocultas de uma rede neural removem a necessidade de pré-especificar da natureza do mecanismo

¹ Doutoranda na Universidade Federal do Paraná

* Autor(a) correspondente: est.suellen@gmail.com

de geração de dados. Isso ocorre porque podem aproximar funções de decisão extremamente complexas (Lewis, 2017). Por outro lado, isto não torna menos importantes os modelos tradicionais, dado que a interpretabilidade dos parâmetros fica mais complexa com o uso das RNAs, assim, a escolha do modelo deve ser feita alinhada com o objetivo da análise.

A análise de séries temporais tem aplicação nos mais diversos campos, como ciências ambientais, medicina, ciências sociais, negócios, indústria, governo, economia, entre outros (Montgomery et al., 2008). A fim de ilustrar a variedade de aplicações de diferentes modelos de redes neurais em dados de estrutura temporal, são descritos alguns exemplos da literatura. Ali et al. (2017) aplicaram a rede neural perceptron multicamadas para a previsão de secas, enquanto Dudek (2016) aplicou tal rede para a previsão de preços de eletricidade. Devadoss (2013) fez a previsão para o mercado de ações, também utilizando a rede perceptron multicamadas. Wu et al. (2019) utilizaram as redes Elman e Jordan para previsão de casos de brucelose, uma doença infecciosa. Lee et al. (2018) aplicaram a rede neural recorrente Elman para prever e analisar uma série temporal de consumo de energia elétrica. Wang et al. (2021) aplicou a rede Elman no mercado de ações. Šestanović aplicou a rede Jordan para a previsão de inflação. Neste capítulo a aplicação utilizada é a série diária de petróleo WTI.

Para a aplicação, deseja-se um modelo capaz de realizar a previsão diária de preço de petróleo baseada em informações históricas. Algumas perguntas poderiam surgir neste momento, como qual modelo poderia ser utilizado para solução deste problema e quantos períodos de tempo seriam suficientes para realizar uma boa previsão.

Não há uma única resposta para estas questões, afinal, há inúmeros modelos que podem ser aplicado para a previsão de séries históricas, como os exemplos já comentados. É importante saber que antes de se aplicar um modelo deve-se compreender a estrutura do mesmo, há determinados modelos que não podem ser utilizados para variáveis dependentes, que é o caso de séries históricas. Para esta aplicação a técnica escolhida foi a Rede Neural Artificial (RNA), mais especificamente a Perceptron multicamadas, Elman e Jordan.

A divisão das seções está descrita a seguir. A primeira corresponde a materiais e métodos e está dividida na subseção base de dados, na qual o conjunto de dados utilizado é descrito, na subseção Redes Neurais Artificiais, em que há uma breve descrição a respeito da técnica e na Raiz do Erro Quadrático Médio, que contempla a técnica de comparação dos modelos. Na seção metodologia está descrito os detalhes da análise e, por fim, em resultados e discussão está a comparação entre as técnicas.

MATERIAL E MÉTODOS

Base de dados

A série diária de petróleo WTI foi coletada por meio do *software* R (R Core Team, 2021), com o pacote *ipeadata*, os dados são alimentados com informação do *U.S. Energy Information Administration* (EIA). As unidades estão em US\$ por barril de petróleo.

Redes Neuais Artificiais

As Redes Neurais Artificiais são técnicas de aprendizado de máquina que possuem a capacidade de aprendizagem, a qual ocorre nos processos iterativos dos ajustes dos pesos. De acordo com as características do conjunto de exemplos usados no treinamento, pode-se ter uma aprendizagem supervisionada ou não supervisionada, sendo que a primeira ocorre quando cada exemplo apresenta uma saída esperada e quando não existe uma saída esperada a aprendizagem é chamada não supervisionada (Braga et al., 2000).

Diferentes modelos de RNAs já foram desenvolvidos e para esta abordagem serão utilizadas as redes Perceptron multicamadas, Elman e Jordan, todas com aprendizagem supervisionada.

As RNAs foram desenvolvidas com inspiração na neurobiologia. O neurônio é uma unidade de processamento de informação, o qual é essencial para a operação de uma rede neural. As variáveis na rede são consideradas como um conjunto sinais de entrada, cada qual com um determinado peso. Essas informações passam por um somador, o que constitui em um combinador linear. Após isto passa por uma função de ativação, para que seja restringida a saída do neurônio (Fausett, 2006; Haykin, 1999). A Figura 1 ilustra o funcionamento de uma rede, é possível que haja mais de uma camada oculta, porém, aqui vamos nos restringir a uma somente.




Figura 1. Rede Neural Perceptron multicamadas. Adaptado de (de Pauli et al., 2020).

Na rede neural Perceptron multicamadas basicamente há uma camada de entrada com p neurônios, k neurônios na camada oculta e o na de saída, a indexação i corresponde período da série que está passando pela rede. A saída y_i pode ser calculada conforme $y_{io} = g[\sum_{k=1}^m w_{k,o} z(\sum_{l=1}^p w_{j,k} x_{ij})]$, onde $w_{j,k}$ realiza a ponderação do neurônio de entrada j para o oculto k , considerando $j = [0, 1, \dots, p]$

e $k = [0, 1, \dots, m]$ e $w_{k,o}$ o faz de k para a saída o , x_{ij} representa o valor da variável de entrada j no período i , $z(\cdot)$ e $g(\cdot)$ são as funções de ativação da camada oculta e de saída, respectivamente. Para o ajuste dos parâmetros do modelo ocorre, em geral, busca-se minimizar a função de erro do modelo pelo método gradiente (Bishop, 1994; Haykin, 1999).

Aqui foi feita uma breve introdução para a rede Perceptron multicamadas, com a qual é possível ter-se uma ideia do funcionamento das RNAs. Além destas há outras redes, dentre as quais a Elman e a Jordan, que são redes recorrentes e são também utilizadas nesta aplicação, para maiores detalhes destas redes ver em (Elman, 1990; Jordan, 1986).

Raíz do Erro Quadrático Médio

Para a avaliação dos modelos foi utilizado a raiz do erro quadrático médio (*Root Mean Square Error*, RMSE), sendo representado por $\sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2}$, em que y_i corresponde ao valor observado i na série e \hat{y}_i ao valor estimado pelo modelo, com $i = [0, 1, \dots, N]$, sendo N o total de observações avaliadas.

METODOLOGIA

Para a aplicação foi coletado o preço diário do período de 01 de janeiro de 2000 até 31 de março de 2020. Os dados foram divididos em três partes: treinamento, teste e validação. A primeira parte, de 01 de janeiro de 2000 até 25 de março de 2014, o que corresponde a 75% dos dados. A segunda, com 15% dos dados, inicia após o treinamento e finaliza em 23 de março de 2017. A terceira, com 15% dos dados inicia após o teste e finaliza em 31 de março de 2020. Na Figura 2 é possível visualizar a série histórica assim como as divisões descritas.




Figura 2. Série histórica de preço do petróleo WTI. Fonte: A autora.

Para esta aplicação foram consideradas cinco variáveis históricas na camada de entrada do modelo e na camada de saída 6 neurônios. Na Figura 3 é ilustrada a forma de construção da base de dados, em que com valores de preço coletados em quinze dias é possível construir cinco linhas de base, cada qual com cinco valores correspondentes a camada de entrada (t-5, t-4, t-3, t-2, t-1), os quais representam às cinco variáveis históricas e seis à de saída (t, t+1, t+2, t+3, t+4, t+5), que são correspondentes aos seis dias posteriores.

01	02	03	04	05	06	07	08	09	10	11	12	13	14	15
t-5	t-4	t-3	t-2	t-1	t	t+1	t+2	t+3	t+4	t+5				
	t-5	t-4	t-3	t-2	t-1	t	t+1	t+2	t+3	t+4	t+5			
		t-5	t-4	t-3	t-2	t-1	t	t+1	t+2	t+3	t+4	t+5		
			t-5	t-4	t-3	t-2	t-1	t	t+1	t+2	t+3	t+4	t+5	
				t-5	t-4	t-3	t-2	t-1	t	t+1	t+2	t+3	t+4	t+5

Figura 3. Construção da base histórica. Fonte: A autora.

Antes de iniciar o treinamento dos modelos, é interessante verificar as relações entre as variáveis. Neste caso, trata-se de dados históricos diários e portanto já poderia se imaginar que haveria forte relação entre as variáveis, porém, isto nem sempre é evidente. Na Figura 4 estão os valores correspondentes as correlações entre as variáveis. É fácil perceber que esta relação é bastante alta e decresce lentamente conforme os dias se afastam, mesmo observando t-5 com t+5, por exemplo, em que tem-se 10 dias de diferença a correlação ainda é bastante alta.




Figura 4. Correlação entre as variáveis. Fonte: A autora.

Para o treinamento, os dados foram normalizados entre 0 e 1. Para fins de comparação, taxa de aprendizagem e o número de iterações foi mantido igual para todos os modelos. As redes Elman, Jordan e Perceptron multicamadas foram treinadas com as possibilidades de 1 a 5 neurônios na camada oculta e em cada uma destas tentativas com 1 a 5 variáveis na camada de entrada. Para a rede Perceptron multicamadas foram testadas as possibilidades de função de ativação Sigmóide logística e tangente hiperbólica.

RESULTADOS E DISCUSSÃO

Após o período de treinamento, realizado para as respostas de 6 neurônios na camada de saída, os modelos foram avaliados quanto ao valor de raiz do erro quadrático médio, os resultados obtidos constam no mapa de calor da Figura 5. É possível verificar em vermelho os melhores valores obtidos, a rede Perceptron multicamadas em ambas as opções de função de ativação obtiveram melhores resultados se comparados com as redes Elman e Jordan para esta aplicação.

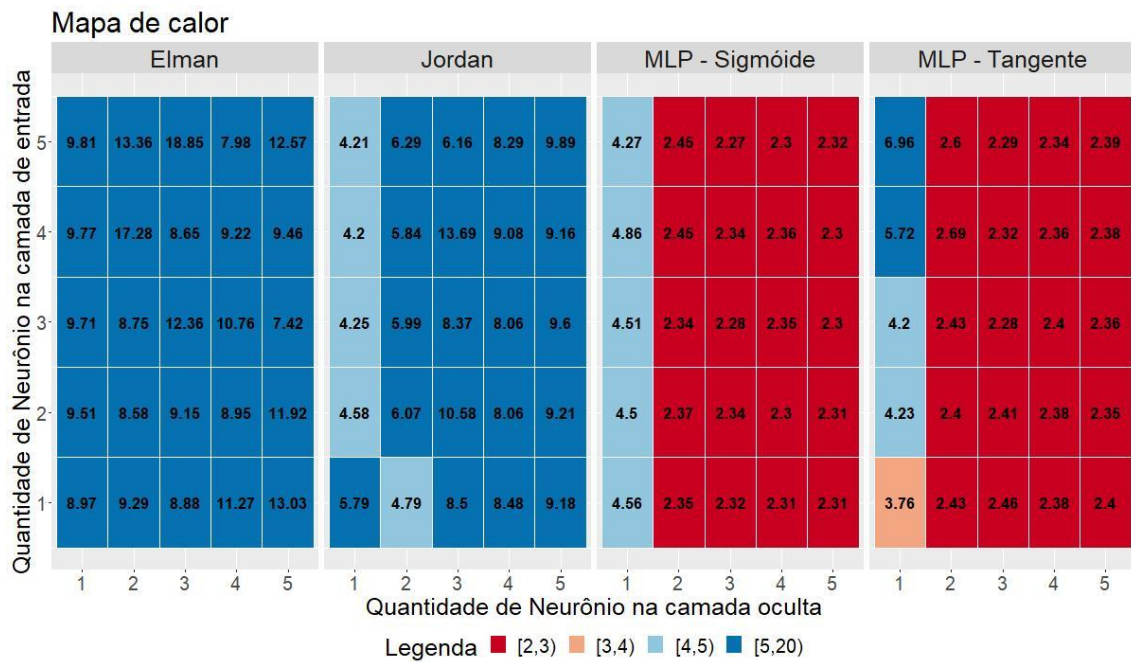


Figura 5. Valores de RMSE em cada configuração de redes no período de teste. Fonte: A autora.

Para a rede Elman o menor valor de RMSE foi de 7,42, com 3 neurônios na camada de entrada e 5 na camada oculta. A rede Jordan, com menor RMSE de 4,20, obteve este resultado com 4 neurônios na camada de entrada e 1 na camada oculta. Na rede Perceptron multicamadas, com a função de ativação Sigmóide, o melhor resultado obtido foi de 2,27, com a função de ativação Tangente foi de 2,28.

Para as possibilidades de rede avaliadas, o melhor resultado encontrado foi da rede Perceptron multicamadas com função de ativação Sigmóide. Com a Figura 6 é possível verificar a previsão para 1 a 6 dias considerando o melhor modelo encontrado em comparação ao observado.

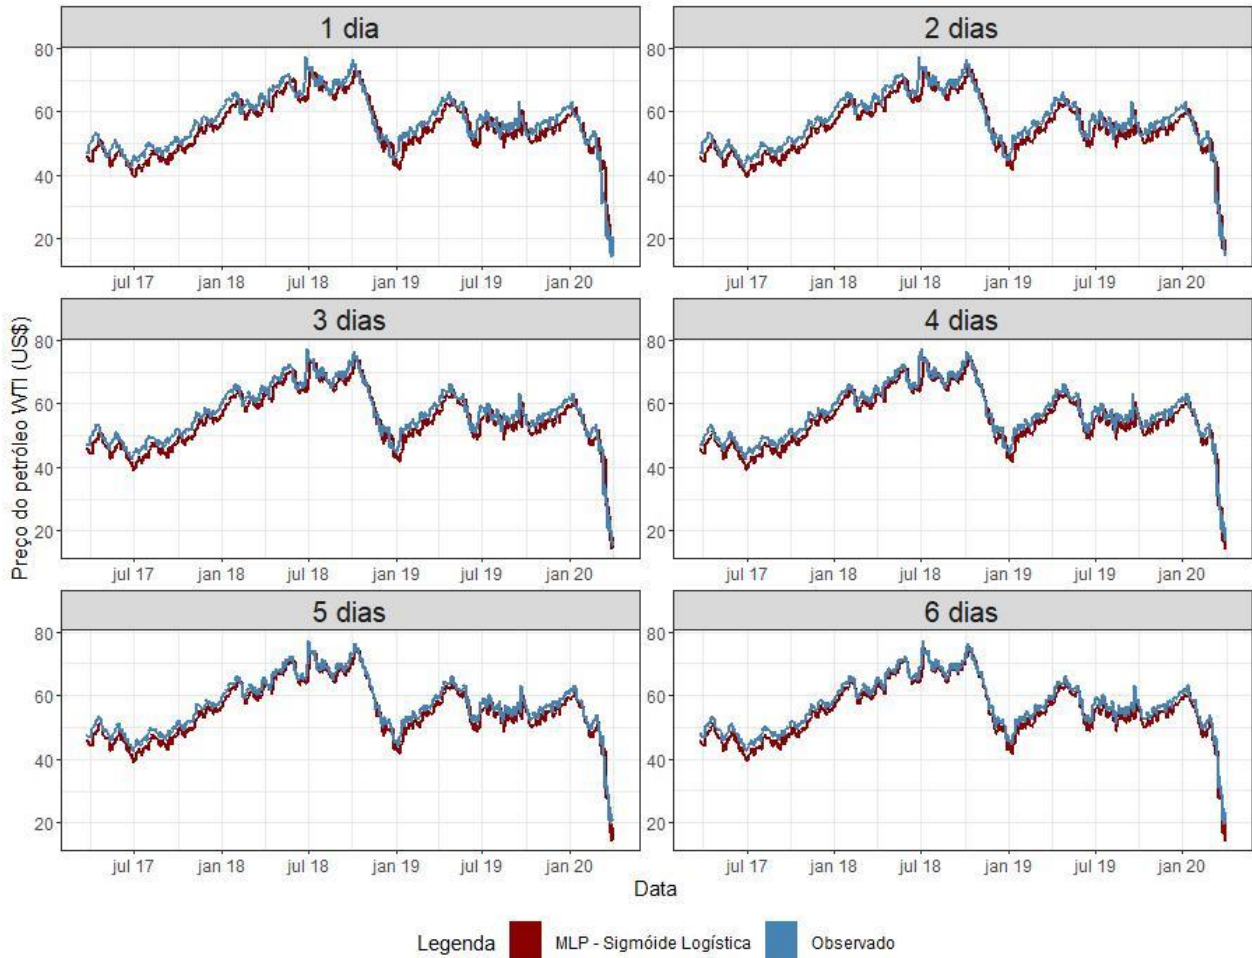


Figura 6. Previsão no período de validação. Fonte: A autora.

O modelo final foi capaz de acompanhar a série, conforme observado na Figura 6, que corresponde ao período de validação. Também é perceptível que a previsão foi adequada para todos os dias. No geral, o erro da previsão aparenta ser de subestimação do valor, pois a linha da previsão está abaixo do valor observado.

Outras técnicas de redes neurais poderiam ser utilizadas esta aplicação, uma delas é a denominada Memória longa de curto prazo (*Long short-term memory*, LSTM), a qual atualmente tem sido destacada para estruturas de dados temporais. Além disto, haveria a possibilidade de testar as redes com maior quantidade de neurônios na camada oculta ou incluindo mais variáveis na entrada. A taxa de aprendizagem e quantidade de iterações poderiam também ser modificadas. Além destas possibilidades ainda existe a opção da modificação do algoritmo de aprendizagem, para a busca de minimização do erro existe uma variedade de derivações do gradiente e além de outras.

Com esta aplicação a ideia principal foi descrever na prática uma possível utilização de uma das técnicas de aprendizado de máquina. Por se tratar de uma base de dados pública o código elaborado permite a total reprodução do que foi feito.

REFERÊNCIAS BIBLIOGRÁFICAS

- Zulifqar A et al. (2017). Forecasting drought using multilayer perceptron artificial neural network model. *Advances in Meteorology*.
- Bishop CM (1994). Neural networks and their applications. *Review of Scientific Instruments*, 65(5): 1803–1832.
- Box George EP et al. (2015). *Time series analysis: forecasting and control*. John Wiley & Sons.
- Braga ADP et al. (2000). *Redes Neurais Artificiais: Teoria e Aplicações* 2 ed. Rio de Janeiro: LTC.
- Brockwell PJ, Davis RA (2016). *Introduction to Time Series and Forecasting*, 3 ed., Springer International Publishing.
- Devadoss AV, Ligorí TAA (2013). Forecasting of stock prices using multi layer perceptron. *International journal of computing algorithm* 2: 440-449.
- Dudek G (2016). Multilayer perceptron for GEFCom2014 probabilistic electricity price forecasting." *International Journal of Forecasting* 32(3): 1057-1060.
- Elman JL (1990). Finding structure in time. *Cogn Sci* 14(2): 179–211
- de Pauli STZ et al. (2020). Comparing Artificial Neural Network Architectures for Brazilian Stock Market Prediction. *Annals of Data Science*, 1-16.
- Fausett LV (2006). *Fundamentals of neural networks: architectures, algorithms and applications*. Pearson Education India.
- Haykin S (2006). *Neural networks: a comprehensive foundation*. Mc Millan, New Jersey.
- Jordan M (1986). Finding structure in time. In: *Proceedings of the eighth annual conference of the cognitive science society*, 531–546.
- Lee CY, Jinho K (2018) The prediction and analysis of the power energy time series by using the elman recurrent neural network. *Journal of the Society of Korea Industrial and Systems Engineering* 41 (1): 84-93.
- Lewis NC (2017). *Neural Networks for Time Series Forecasting with R: An Intuitive Step by Step Blueprint for Beginners*. AusCov.
- Montgomery CD et al. (2008). *Introduction to Time Series Analysis and Forecasting*.
- R Core Team (2021). *R: A language and environment for statistical computing*. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>
- Šestanović T (2019). Jordan neural network for inflation forecasting. *Croatian Operational Research Review*, 23-33.
- Wang Y et al. (2021). Advantages of direct input-to-output connections in neural networks: The Elman network for stock index forecasting. *Information Sciences*, 547: 1066-1079.

Wu W et al. (2019). Time series analysis of human brucellosis in mainland China by using Elman and Jordan recurrent neural networks. *BMC infectious diseases* 19(1): 1-11.

ÍNDICE REMISSIVO

A

algoritmo, 13, 25, 27, 42, 51
aprendizado de máquina, 4, 9, 13, 16, 17, 35,
37, 43
arritmia, 41

C

classificação, 4, 17, 37, 39
conhecimento, 46, 47, 50, 53
convolucional
rede neural, 4, 21

D

Dense
rede neural, 4, 22

E

Elman
rede neural, 4, 8, 9, 10, 12, 14, 15
energia elétrica, 4, 8, 16, 17, 21, 24, 27, 29
ensemble, 31

J

Jordan
rede neural, 4, 8, 9, 10, 12, 14, 15

M

mineração de texto, 4, 48

P

padrão, 24, 33, 37, 38, 41, 42
petróleo, 4, 7, 8, 10
predição, 4, 16, 17, 18, 21, 25, 26, 28, 29, 38, 43
pré-processamento, 43, 51, 52
Pubmed, 48, 49, 51


R


recorrente
rede neural, 4, 8, 21, 22
rede neural, 7, 8, 9, 17, 20


S


série temporal, 7, 8, 16, 17, 21, 24


SOBRE OS ORGANIZADORES

 **Ricardo Augusto Manfredini** Possui graduação em Bacharel em Ciências da Computação pela Universidade de Caxias do Sul (1990), mestrado em Ciências da Computação pela Universidade Federal do Rio Grande do Sul (2001) , doutorado pelo Instituto de Biotecnologia da Universidade de Caxias do Sul(2015) e pós-doutorado no GECAD do Instituto Superior de Engenharia do Porto em Inteligência Artificial e IoT, também é professor do Instituto Federal de Ciências e Tecnologia do Rio Grande do Sul - campus Farroupilha. Tem experiência na área de Ciência da Computação, com ênfase em Programação, Engenharia de Software e Tolerância a Falhas, atuando principalmente nos seguintes temas: IoT & IA (2020), bioinformática, injeção de falhas, sistemas distribuídos, tolerância a falhas, metodologias de desenvolvimento de sistemas e linguagens de programação.

 **Geraldo Nunes Corrêa** Possui graduação em Ciência da Computação pela Universidade de São Paulo (1991), mestrado em Ciências da Computação (Área de Inteligência Artificial, Banco de Dados e Manufatura) pela Universidade de São Paulo (1994) e doutorado em Engenharia Mecânica (Departamento de Engenharia de Produção) pela Universidade de São Paulo (1999). Pós doutorado em Mineração de Textos no Instituto de Ciências Matemáticas e Computação da Universidade de São Paulo (2013). Consultor em soluções educacionais. Mentor de Startups. Empreendedor Digital.

 **Bruno Rodrigues de Oliveira** Graduado em Matemática pela Universidade Estadual de Mato Grosso do Sul (UEMS, 2008). Mestrado (2015) e Doutorado (2020) em Engenharia Elétrica pela Universidade Estadual Paulista Júlio de Mesquita Filho (UNESP, 2015). Atualmente é Analista Judiciário no Tribunal de Justiça de Mato Grosso do Sul e professor de Matemática no Colégio Maper e Editor na Pantanal Editora. Tem experiência nos temas: Matemática, Processamento de Sinais via Transformada Wavelet, Análise Hierárquica de Processos, Teoria de Aprendizagem de Máquina e Inteligência Artificial.

 **Suellen Teixeira Zavadzki de Pauli** Doutoranda em Métodos Numéricos na Universidade Federal do Paraná, possui mestrado em Engenharia da Produção pela Universidade Federal do Paraná (2020), pós-graduação em Engenharia da Confiabilidade pela Universidade Tecnológica Federal do Paraná (2016) e graduação em Estatística pela Universidade Federal do Paraná (2013). Possui experiência com monitoramento de modelos estatísticos de crédito e análise de indicadores. Atuação no planejamento e estratégia de campanhas de marketing através da análise de produtos e de perfil de clientes, dashboards analíticos e KPIs. Geração e implementação de simulador de oferta ideal para o cliente (next best offer). Experiência na avaliação de dados e cenários, utilização de técnicas estatísticas (análises descritivas, árvores de decisão, testes estatísticos). Experiência como professor substituto na Universidade Tecnológica Federal do Paraná (2020). Experiência com pesquisa em redes neurais artificiais aplicadas em dados de séries temporais (preço de petróleo e valor de ações), modelos mistos, análise de variância, entre outras técnicas. Familiaridade com linguagem SQL e ferramentas de análises como SAS, SPSS, R, Phyton e pacotes office. Coorganizadora do RLadies Curitiba.



Pantanal Editora

Rua Abaete, 83, Sala B, Centro. CEP: 78690-000

Nova Xavantina – Mato Grosso – Brasil

Telefone (66) 99682-4165 (Whatsapp)

<https://www.editorapantanal.com.br>

contato@editorapantanal.com.br