



# ConBRepro

XIII CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO



IA nas Engenharias

29 nov. a 01 de dezembro 2023

## Comparando Modelos de Projeção da Inflação nos EUA: Uma Análise da Regressão Linear Simples, Suavização Exponencial Dupla e Redes Neurais Artificiais

**Felipe Augusto Santos Borges**

Programa de Pós-Graduação em Engenharia de Produção – UFPR

**Mariana Kleina**

Programa de Pós-Graduação em Engenharia de Produção – UFPR

**Paola Andrea Rico Belalcazar**

Programa de Pós-Graduação em Engenharia de Produção – UFPR

**Marcell Mariano Corrêa Maceno**

Programa de Pós-Graduação em Engenharia de Produção – UFPR

**Resumo:** O artigo centra-se na inflação, um indicador macroeconômico fundamental, e seu impacto nas tomadas de decisões políticas e estratégias empresariais. Com a globalização e a crescente interdependência das economias, compreender a trajetória da inflação, especialmente nos EUA, é imprescindível. Ao mesmo tempo, avanços tecnológicos e o aumento no volume de dados tornam as previsões essenciais em vários domínios, incluindo a economia. O estudo aborda três técnicas de projeção quantitativa (regressão linear simples, método de suavização dupla e redes neurais) aplicadas à inflação dos EUA mensurada pelo Índice de Preços ao Consumidor. Ao comparar esses métodos, o principal objetivo foi identificar o desempenho de cada um na previsão da inflação. A metodologia envolve a utilização de uma série temporal da inflação dos EUA, a análise de sua estacionariedade, tendência e sazonalidade, e a subsequente aplicação das técnicas de previsão. Em conclusão, para séries temporais com tendências claras, os três métodos apresentaram um erro aceitável para o cenário da inflação, podendo ser utilizados para previsões futuras.

**Palavras-chave:** Inflação, Previsão, Regressão Linear Simples, Suavização Exponencial Dupla, Redes Neurais Artificiais.

## Comparative Analysis of Forecasting Methods for U.S. Inflation: Evaluating Simple Linear Regression, Double Exponential Smoothing, and Artificial Neural Networks

**Abstract:** The scientific article focuses on inflation, a fundamental macroeconomic indicator, and its impact on political decision-making and business strategies. With globalization and the growing interdependence of economies, understanding the trajectory of inflation, especially in the US, is essential. Simultaneously, technological advances and the rise in data volume make forecasts crucial in various domains, including economics. The study addresses three quantitative projection techniques (simple linear regression, double smoothing method, and artificial neural networks) applied to US inflation measured by the Consumer Price Index. In comparing these methods, the

primary goal was to identify each one's performance in predicting inflation. The methodology involved using a time series of US inflation, analyzing its stationarity, trend, and seasonality, and subsequently applying the forecasting techniques. In conclusion, for time series with clear trends, all three methods displayed an acceptable error for the inflation scenario and can be used for future forecasts.

**Keywords:** Inflation, Forecasting, Linear Regression, Double Exponential Smoothing, Artificial Neural Networks.

## 1. Introdução

A inflação, como um indicador macroeconômico e um fenômeno monetário (FRIEDMAN 1963), desempenha um papel crucial na tomada de decisões de políticas governamentais, estratégias de negócios e planejamento financeiro. Medindo a taxa na qual os preços dos bens e serviços sobem, e, conseqüentemente, o poder de compra da moeda cai, a inflação afeta tanto economias individuais, quanto coletivas. Em um ambiente globalizado, onde as economias estão cada vez mais interligadas, é necessário compreender a trajetória da inflação em grandes potências econômicas, principalmente nos Estados Unidos. Nas palavras de Stock e Watson (2007), “a inflação tem tornado simultaneamente mais fácil e mais difícil de prever”, desde o início dos anos 80. Mais fácil no sentido em que os erros de previsão têm sido menores, no entanto, mais difícil porque se tornou extremamente complicado superar previsões obtidas com modelos simples.

Acompanhando a explosão recente no volume de dados, e o que estes tem influenciado nas transformações em diversos campos, as previsões ganham um papel ainda mais importante por auxiliarem nos processos de tomada de decisão (CORTEZ, 2002), como por exemplo, previsões de: desastres naturais, clima, bolsa de valores, dentre outras, incluindo a economia. Conforme Einav e Levin (2016) destacam, os métodos da econometria convencional, que frequentemente adotam modelos lineares, buscam controlar a heterogeneidade e as variáveis não observadas, além de determinar relações causais.

Por isso, neste estudo, foram explorados três métodos para projeção quantitativa (regressão linear simples, método de suavização dupla e a rede neural) aplicados aos dados mensais do *Índice de Preços ao Consumidor (IPC)*, a inflação dos EUA. A regressão linear simples, uma abordagem paramétrica, busca compreender e modelar a relação entre variáveis dependentes e independentes. Por outro lado, o método de suavização dupla, uma técnica de séries temporais, é útil para captar tendências e padrões em dados ao longo do tempo. Já as redes neurais podem ser equiparadas a métodos estatísticos de aprendizado e reconhecimento de padrões, sendo também capazes de realizar projeções em séries temporais. Ao comparar e contrastar esses métodos, este artigo visa não apenas projetar a inflação futura, mas encontrar o erro obtido em cada um destes.

## 2. Referencial Teórico

Caracterizada como um conjunto de dados distribuídos de forma uniforme ao longo do tempo (diária, semanal, quinzenal, mensal e ou até anual), as séries temporais podem ser projetadas envolvendo a estimativa de valores futuros com base nestes registros anteriores ou históricos. Conforme Heizer e Render (2001) explicam, ao analisar uma série temporal é essencial decompor os dados históricos em seus elementos, como por exemplo: tendência, sazonalidade, para posteriormente, fazer projeções futuras.

Ainda segundo Heizer e Render (2001) destacam, o processo de elaboração de modelos de previsão envolve sete passos fundamentais: estabelecer o propósito da previsão, escolher os elementos a serem previstos, definir o período da previsão, optar pelos modelos de previsão adequados, coletar dados históricos, executar a previsão e, por fim, validar os

resultados obtidos. De acordo com os autores, é importante reconhecer que as previsões raramente são precisas na íntegra, visto que há fatores externos, muitas vezes imprevistos ou fora de controle, que influenciam os resultados previstos.

## 2.1 Técnicas de previsão utilizadas

### 2.1.1 Regressão Linear Simples

A linha de tendência linear indica um valor que tende a crescer ou decrescer a uma taxa constante, determinada pelo seu coeficiente angular. Esta linha é aplicada em previsões quando os dados históricos exibem uma tendência ascendente ou descendente clara. Na sua formulação,  $Y$  é a variável dependente (o que se quer prever),  $a$  é o coeficiente angular,  $b$  é o coeficiente linear e  $X$  representa a variável independente (o intervalo de tempo).

$$Y = a + bX,$$

$$\text{onde: } b = \frac{n(\sum XY) - (\sum X)(\sum Y)}{n(\sum X^2) - (\sum X)^2} \text{ e } a = \frac{\sum Y - b(\sum X)}{n}$$

### 2.1.2 Suavização Exponencial Dupla

Os modelos de suavização exponencial valorizam mais os últimos valores observados na série temporal por meio da ponderação exponencial deles, e de acordo com a proximidade ao período da previsão (MAKRIDAKIS *et al.*, 1998). O método de suavização exponencial dupla, também chamado de método de Holt, é indicado para séries com tendência linear, porém sem sazonalidade e como já mencionado acima, é atribuído maior importância aos dados mais recentes de um período determinado. Uma das vantagens evidenciadas pelos autores é a capacidade de adaptação da fórmula, que rapidamente se ajusta a novas variações, gerando resultados mais precisos que uma média móvel simples (TUBINO, 1997).

$$P_{t+h} = L_t + hT_t$$

Onde na sua formulação,  $L_t$  é o componente de nível no período  $t$ , dado por  $L_t = \alpha R_t + (1 - \alpha)(L_{t-1} + T_{t-1})$  e  $T_t$  é o componente de tendência no período  $t$ :  $T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1}$ ;  $\alpha$  é a constante de suavização do componente de nível  $L_t$  e  $\beta$  é a constante de suavização do componente de tendência  $T_t$ , onde ambas as constantes estão no intervalo entre  $[0, 1]$ .

### 2.1.3 Redes Neurais Artificiais

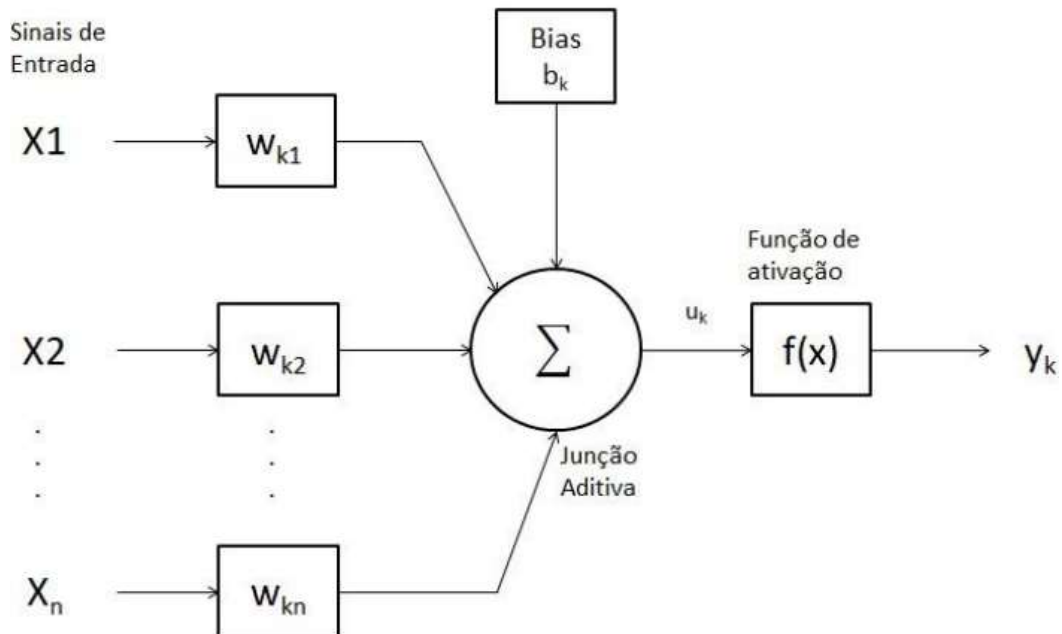
Redes Neurais Artificiais (RNAs) são sistemas modelados a partir da intrincada estrutura do sistema nervoso humano, funcionando como processadores paralelos formados por unidades básicas chamadas neurônios ou nodos. Estas unidades são capazes de acumular e disponibilizar conhecimento baseado em experiências anteriores. Assim como o cérebro humano, as RNAs obtêm conhecimento por meio de interações com o ambiente externo e armazenam esse aprendizado nas conexões ou sinapses entre os nodos (HAYKIN, 2001).

Durante o treinamento, os pesos dessas conexões são recalibrados por algoritmos específicos para cumprir certos propósitos. Além dos ajustes nas conexões, a estrutura interna da RNA pode ser modificada, de maneira análoga ao cérebro humano, onde neurônios podem ser descartados e novas sinapses formadas.

A potência das RNAs está amarrada tanto em sua configuração paralela quanto em sua capacidade de aprender e adaptar-se com base em informações anteriores, permitindo-as responder a situações novas de forma eficaz. Tais atributos as habilitam a abordar questões que seriam excessivamente complicadas por outros meios. No entanto, é crucial entender

que as RNAs, por si só, não são ferramentas universais e, em muitos casos, necessitam ser combinadas a outros métodos para encontrar soluções (HAYKIN, 2001). Mesmo com toda a sua sofisticação, ainda tem-se um longo caminho para criar uma arquitetura que efetivamente simule a complexidade do cérebro humano.

**Figura 1 – Estrutura de um neurônio artificial**



**Fonte: Haykin (2001)**

Haykin (2001) define a unidade central de processamento em uma RNA como o neurônio e é composto por três componentes essenciais: os sinais de entrada com seus respectivos pesos sinápticos, um dispositivo somador e uma função de ativação; a Figura 1 ilustra uma rede neural artificial do tipo *perceptron*, e que pode ser calculada:

$$y_k = f \left( \sum_j w_{kj} x_j + b_k \right)$$

Onde  $x_j$  são as entradas,  $w_{kj}$  são os pesos sinápticos,  $b_k$  é o bias,  $y_k$  é o sinal de saída da RNA e  $f$  é uma função de ativação (HAYKIN, 2001). Os pesos sinápticos são atualizados de modo que a rede apresente o menor erro para um conjunto de treinamento. Quando uma RNA do tipo *perceptron* tem mais que uma camada de processamento, ela recebe o nome de *MultiLayer Perceptron* (HAYKIN, 2001).

## 2.2 Critério para escolha do modelo

O emprego do modelo selecionado para previsão de valores futuros pode sofrer variação de acordo com seu comportamento em relação a série temporal a ser analisada (PELLEGRINI, 2000).

A comparação dos métodos foi realizada por meio do valor obtido da Raiz do Erro Médio Quadrático, frequentemente conhecida pela sigla REMQ ou RMSE (do inglês "*Root Mean Square Error*"), representada por:

$$REMQ = \sqrt{\frac{\sum_{t=1}^n e_t^2}{n}}$$

Esta medida representa a raiz quadrada da média dos erros (a diferença dos valores observados pelos valores previstos) ao quadrado, e quanto mais próxima de zero melhor.

### 3. Metodologia

Para o desenvolvimento deste trabalho, utilizou-se uma série temporal obtida na plataforma on-line Kaggle (2023), referente a *U.S. Inflation Data*. Na Tabela 1, apresenta-se uma breve descrição dos dados analisados.


Tabela 1 – Variáveis da série temporal

Nome da variável	Descrição	Tipo
<i>Date</i>	Data do dado da inflação obtido, contém informação desde janeiro do ano 1947 até junho do 2023	Data no formato dia/mes/ano
<i>Value</i>	Dado de inflação reportado	Número real entre 21,48 e 304

Fonte: Os autores (2023) - Base de dados Kaggle

A pesquisa foi desenvolvida no software *R*, utilizando dados registrados da inflação dos EUA do período de janeiro de 1947 até junho de 2023, com 918 registros históricos mensais, e que por sua vez, o estudo dividiu-se em três etapas representadas na Figura 2.

Figura 2 – Etapas da pesquisa



Fonte: Os autores (2023)

#### 3.1 Comportamento da série temporal

O primeiro aspecto analisado foi a estacionaridade da série temporal. Para isso, utilizou-se dois testes estatísticos. O Teste Augmented Dickey-Fuller (ADF), que estabelece a hipótese nula de a série não ser estacionária, sendo aceita quando o p valor é maior que o valor crítico (0,05) (MIELKE; RIBEIRO VILLAS BOAS, 2022). O outro teste é o Kwiatkowski-Phillips-Schmidt-Shin (KPSS) o qual tem como hipótese nula a estacionariedade da série, aceita-se quando o p valor é maior que o valor crítico (0,05) (Alberto *et al.*, 2022).

Da mesma forma, para identificar se os dados possuem tendência foi utilizado o teste de Mann-Kendall (MK), onde se o p valor for menor que 0,05, então a série apresenta tendência (ARAÚJO *et al.*, 2015).

Finalmente o último aspecto, a sazonalidade da série temporal é determinada graficamente. Segundo (ACKERMANN; SELLITTO, 2022), a sazonalidade apresenta padrões definidos repetitivos para um determinado intervalo de tempo.

Na Tabela 2, encontram-se os códigos na linguagem *R* para cada um dos componentes analisados na série temporal avaliada.

**Tabela 2 – Código comportamento série temporal no R**

Componente	Teste	Código
Estacionariedade	ADF	adf.test(Inflation\$value)
	KPSS	kps.test(Inflation\$value)
Tendência	mk	mk.test(Inflation\$value)

Fonte: Os autores (2023)

### 3.2 Comparação gráfica dos métodos de previsão

Após a caracterização da série temporal foram escolhidos os métodos de previsão a serem analisados. Conforme os resultados obtidos do comportamento dos dados definiu-se que, a regressão linear, a suavização exponencial dupla e as redes neurais artificiais são os métodos que melhor poderiam se ajustar à série temporal, por causa da tendência identificada.

Em seguida, os três métodos selecionados foram desenvolvidos no software *R* e plotados os gráficos para sua comparação. Apresenta-se os códigos usados na Figuras 3.

Cabe mencionar que, para treinar a rede neural os dados da série temporal foram divididos em 80% para treinamento (734 dados) da rede e 20% para o teste da RNA (184 dados). Com essa última porcentagem de dados foram realizadas as diferentes comparações efetuadas ao longo do trabalho (tanto graficamente, quanto em relação a medida do REMQ).

**Figura 3 – Códigos do R dos três métodos**

```
#Regressão Linear Simples
TE<-Inflation[(n1+1):nrow(Inflation),]
modelo<-lm(TE$value~TE$date)
Prev_RL<-predict(modelo,list(TE$value))

#Suavização Exponencial Dupla
library(forecast)
Dupla<-holt(y=TE$value,h=1,initial = "optimal")

#Redes Neurais Artificiais
n1<-round(nrow(Inflation)*0.8)
library(nnfor)
rna<-mlp(ts(Inflation[1:n1,2])) #treinamento de rede
Prev_RN<-mlp(ts(Inflation[(n1+1):nrow(Inflation),2]),model=rna)
```

Fonte: Os autores (2023)

### 3.3 Comparação de REMQ dos métodos de previsão

Finalmente, de forma que a identificação do método que se ajustou melhor aos dados seja clara, foi proposta uma comparação com base no erro dos resultados gerados por cada um dos métodos analisados. O erro utilizado foi a Raiz do Erro Médio Quadrático (REMQ).

## 4. Resultados

### 4.1 Comportamento da série temporal

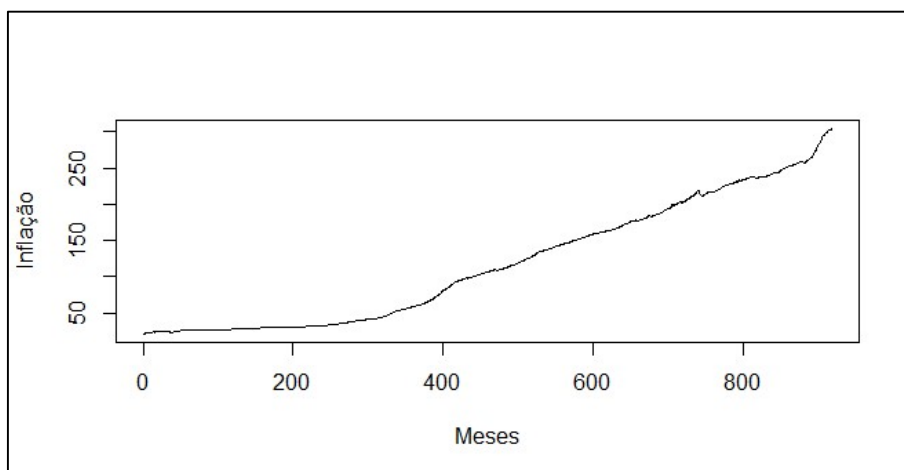
Com a finalidade de ter um melhor conhecimento do comportamento dos dados da série, foram realizados testes para analisar aspectos como estacionariedade e tendência. Adicionalmente com base no gráfico da série temporal, foi determinada a não sazonalidade dos dados.

**Tabela 3 – Comportamento da série temporal**

Aspecto	Teste	p valor
Estacionariedade	ADF	0,9245
	KPSS	0,01
Tendência	mk	2,2e-16

Fonte: Os autores (2023)

**Figura 4 – Série temporal**



Fonte: Os autores (2023)

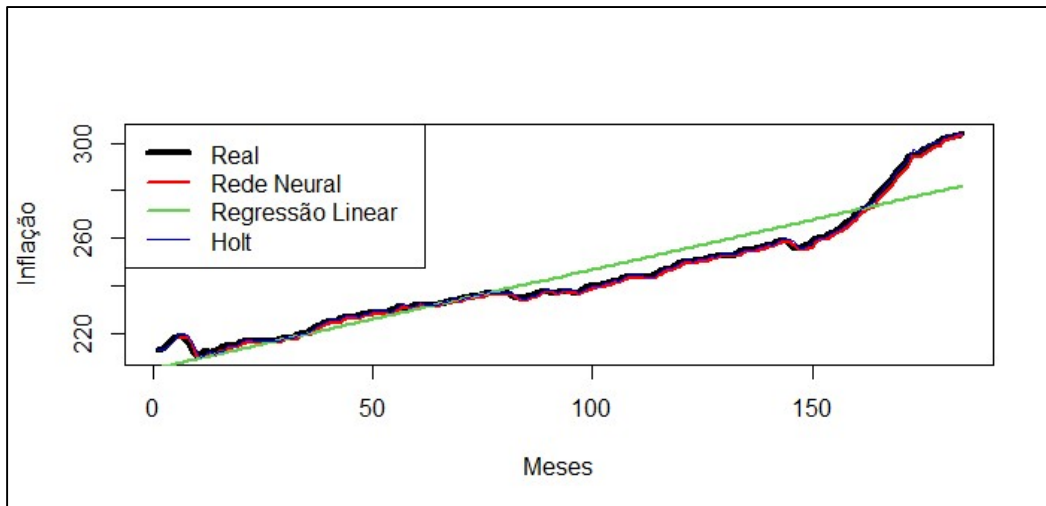
Conforme os resultados mostrados na Tabela 4, pode-se inferir que a série temporal apresenta tendência, sendo que o p valor é menor que o valor crítico (0,05) e não tem estacionariedade devido ao teste ADF, onde o valor crítico é menor que o p valor. No caso do teste KPSS o valor crítico é maior. Além disso, conforme a Figura 4 foi possível observar que o gráfico não exibe movimentos ondulatórios ou picos para intervalos de tempo definidos, por isso, determinar-se que os dados não têm sazonalidade (LIMA *et al.*, 2019).

### 4.2 Comparação gráfica dos métodos de previsão

Após a caracterização da série temporal, foram desenvolvidos os métodos de previsão selecionados no software *R*. Os resultados são apresentados na Figura 5, onde é possível observar que os métodos analisados Rede Neural Artificial e Holt, visivelmente, não denotam uma diferença significativa com os dados originais da série temporal.



**Figura 5 – Comparação gráfica dos métodos**



**Fonte: Os autores (2023)**

Segue a equação ajustada para obter o resultado no método da Regressão Linear Simples.

$$Y = 1,547590 e^{+01} + 1,580574e^{-07} X$$

Onde,


$Y$ : Variável dependente, isto é, o valor da inflação para o tempo  $X$ ;

$X$ : Variável independente, isto é, o número dos meses (1,2,...,184).

Cabe mencionar que os parâmetros da RNA e do método de Holt são escolhidos por meio de uma otimização do software R. No caso da Suavização Exponencial Dupla os valores das constantes  $\alpha$  e  $\beta$  são 0,9989 e 0,1815 respectivamente.

Para a Rede Neural Artificial na primeira camada estabeleceram-se 3 neurônios da série temporal para prever o valor futuro, enquanto na camada oculta foram usados 5 neurônios. Na Figura 6 apresenta-se a RNA obtida.

**Figura 6 – Arquitetura da Rede Neural Artificial usada**



**Fonte: Os autores (2023)**



### 4.3 Comparação de REMQ dos métodos de previsão

Para obter uma comparação mais clara de qual dos métodos de previsão estabelecidos ajustou-se melhor a série temporal, foi calculada a Raiz do Erro Médio Quadrático. Encontram-se os resultados na Tabela 5.

Tabela 4 – Erros dos métodos de previsão

Método	REMQ
Redes Neurais Artificiais	1,377562
Regressão Linear Simples	7,564244
Suavização Exponencial Dupla	0,8425816

Fonte: Os autores (2023)

Identificou-se que o método com melhor previsão da série temporal foi a Suavização Exponencial Dupla com um menor REMQ, em seguida a RNA e finalmente a Regressão Linear Simples com o valor mais alto. O resultado pode ser atribuído ao fato que o método Holt foi desenvolvido para séries temporais que apresentam como padrão uma tendência linear (ALVES *et al.*, 2019; ACKERMANN; SELLITTO, 2022).

### 5. Conclusões

A série temporal com os dados analisados de inflação dos EUA apresentou uma tendência que facilitou o uso de métodos de previsão como a regressão linear simples, suavização exponencial dupla e redes neurais artificiais. Com a finalidade de determinar qual método se ajustaria melhor à série foram realizadas duas comparações. A primeira, realizou-se com base no gráfico, onde não foi possível a identificação do melhor método. A segunda consistiu em uma comparação do erro de cada um dos resultados dos métodos analisados, sendo a suavização exponencial dupla que apresentou o menor REMQ com um valor de 0,8425816. Finalmente, os três métodos apresentaram um erro aceitável para o cenário da inflação, e eles poderiam ser utilizados para previsões futuras, onde não se sabe o valor real da série temporal.

### Referências

- ACKERMANN, A. E. F.; SELLITTO, M. A. (2022). Métodos de previsão de demanda: uma revisão da literatura. **Innovar**, 32(85), 83–99. <https://doi.org/10.15446/innovar.v32n85.100979>.
- ALBERTO, H., CASAS, M.; OROZCO, F. L. (2022). **Uso de series temporales para el análisis y predicción de consumo de materia prima en la industria maquiladora**. 151(8), 167–176.
- ALVES AMORIM, D.; DE LIMA NETA, R. M. (2023). **Previsão de geração fotovoltaica utilizando redes neurais recorrentes**. Instituto Federal Pernambuco.
- ALVES, C. DA C., HOEPERS, E., CORAZZA, E. J., SANTOS, G. J. DOS CRISTOFOLINI, R.; CRUZ, A. C. DA. (2019). Aplicação de métodos estatísticos com suavização exponencial dupla e tripla para previsão de demanda na gestão de estoques. **Revista Produção Online**, 19(3), 1001–1026. <https://doi.org/10.14488/1676-1901.v19i3.3539>.

ARAÚJO, H. M. DE, TORRES, C., COSTA, F., ROBERTO, P.; TAVARES, L. (2015). Análise de tendência nas séries de precipitação na região metropolitana do Cariri – Ceará. XV SIMPÓSIO DE RECURSOS HÍDRICOS DO NORDESTE ANÁLISE, **Anuais 2015**, 1–10.

CORTEZ, P. (2002), **Modelos inspirados na natureza para a previsão de séries temporais**. 186 f. Tese (Doutorado) - Curso de Informática, Universidade do Minho, Campus de Azurém, 2002. Disponível em:

<<https://repositorium.sdum.uminho.pt/bitstream/1822/13/1/cortez.pdf>>. Acesso em: 18 set. 2023.

EINAV, L.; FARRONATO, C.; LEVIN, J., «Peer-to-Peer Markets». *Annual Review of Economics*, vol. 8, pp. 615-635, 2016.

FRIEDMAN, M. (1963), *Inflation: Causes and Consequences*, New York: Asia Publishing House.

HEIZER, J.; RENDER, B. (2001), **Administração de Operações: Bens e Serviços**. 5. ed. Rio de Janeiro.

HAYKIN, SIMON. **Redes neurais princípios e prática**. 2. ed. Porto Alegre: Bookman, 2001.

LIMA, J. E. C., CASTRO, L. F. DE; CARTAXO, G. A. A. (2019). Aplicação do Modelo SARIMA na Previsão de Demanda no Setor Calçadista / Application of the SARIMA Model in the Forecast for Demand in the Footwear Sector. ID on Line **REVISTA DE PSICOLOGIA**, 13(46), 892–913. <https://doi.org/10.14295/idonline.v13i46.1875>.

MAKRIDAKIS, S.; WHEELWRIGHT, S. C.; HYNDMAN, R. J., *Forecasting. Methods and Applications*. Third Edition. New York: John Wiley & Sons, 1998.

MIELKE, L. V.; VILLAS BOAS, P. (2022). Uso de Modelos de Decomposição em Componentes Não Observáveis para predição de séries temporais não estacionárias de commodities agrícolas. II Workshop de Matemática, Estatística e Computação Aplicadas à Indústria.

PELLEGRINI, F.R. **Metodologia para implementação de Sistemas de Previsão de Demanda**. Porto Alegre RS: UFRS, 2000. 146p. (Dissertação de Mestrado em Engenharia de Produção). Universidade Federal do Rio Grande do Sul. Rio Grande do Sul.

STOCK, J.; WATSON, M. (2007), “Why Has U.S. Inflation Become Harder to Forecast?”, **Journal of Money, Credit and Banking**, Vol. 39, 3-33, 2007.

TUBINO, D. F., *Manual de Planejamento e Controle da Produção*. São Paulo: Atlas, 1997.