



ConBRepro

XIV CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO

I CIGELUBRA

Congresso Internacional de Gestão e Engenharia Luso-Brasileiro

04 a 06 de dezembro de 2024

Energias Limpas nas Engenharias

UMA COMPARAÇÃO DE TÉCNICAS DE REGRESSÃO PARA A PREVISÃO DO PIB NACIONAL BRASILEIRO

Jhonnata Novaes Pires

Universidade Tecnológica Federal do Paraná – Pato Branco, Brasil
jhonnata@alunos.utfpr.edu.br

Matheus Henrique Dal Molin Ribeiro

Universidade Tecnológica Federal do Paraná – Pato Branco, Brasil
mribeiro@utfpr.edu.br

Resumo: O crescimento contínuo dos bens e serviços de um país é um dos principais focos dos diversos setores econômicos, pois reflete diretamente a prosperidade e a estabilidade financeira de uma nação. Através dos índices de crescimento, é possível avaliar a riqueza e a sustentabilidade econômica de um país ao longo de períodos determinados, fornecendo uma visão clara sobre seu desempenho. Na literatura econômica, diversos métodos de previsão são empregados para avaliar o crescimento econômico, incluindo técnicas estatísticas avançadas. Entre essas, a regressão linear se destaca por sua simplicidade e eficácia. Dentre os métodos de regressão amplamente utilizados, destacam-se a SVR (Regressão por Vetor de Suporte) e as ANN (Redes Neurais Artificiais), que são conhecidas por lidar bem com dados não lineares e complexos. No entanto, apesar da sofisticação dessas abordagens, este trabalho tem como objetivo comparar os resultados obtidos por essas técnicas e avaliar seus respectivos indicadores de desempenho para identificar qual delas seria mais adequada para a previsão do PIB Nacional Brasileiro. O estudo de caso proposto utilizou os dados do PIB bruto anual do Brasil, cobrindo o período de 1962 a 2023. Apesar de abordagens mais complexas, como SVR e ANN, serem consideradas promissoras para melhorar a acurácia das previsões, os resultados mostraram que a regressão linear simples foi a que apresentou melhor desempenho no contexto analisado. Isso sugere que, em certos casos, a simplicidade pode ser uma vantagem, oferecendo resultados robustos e mais fáceis de interpretar para a previsão do PIB.

Palavras-chave: Previsão, Regressão, PIB Bruto, Brasil.

A COMPARISON OF REGRESSION TECHNIQUES FOR THE FORECAST OF THE BRAZILIAN NATIONAL GDP

Abstract: The continuous growth of a country's goods and services is one of the main focuses of the various economic sectors, as it directly reflects the prosperity and financial stability of a nation. Through growth rates, it is possible to assess the wealth and economic sustainability of a country over certain periods, providing a clear view of its performance. In the economic literature, several forecasting methods are used to assess economic growth, including advanced statistical techniques. Among these, linear regression stands out for its simplicity and effectiveness. Among the widely used regression methods, SVR (Support Vector Regression) and ANN (Artificial Neural Networks)

stand out, which are known to deal well with non-linear and complex data. However, despite the sophistication of these approaches, this work aims to compare the results obtained by these techniques and evaluate their respective performance indicators to identify which of them would be most suitable for forecasting the Brazilian National GDP. The proposed case study used data on Brazil's annual gross GDP, covering the period from 1962 to 2023. Although more complex approaches, such as SVR and ANN, are considered promising to improve the accuracy of the maneuvers, the results showed that simple linear regression performed best in the context analyzed. This suggests that, in certain cases, simplicity can be an advantage, offering robust and easier-to-interpret results for GDP forecasting.

Keywords: Forecast, Regression, Gross GDP, Brazil.

1. Introdução

A economia de um país é influenciada por fatores como políticas monetárias, estabilidade política e investimentos, com o PIB (Produto Interno Bruto) sendo uma das métricas mais importantes para avaliar seu desempenho. O PIB representa o valor agregado dos bens e serviços produzidos, medido anualmente ou trimestralmente. O PIB per capita, que ajusta o PIB pela população, oferece uma medida mais precisa do bem-estar econômico individual, embora sua previsão seja desafiadora devido à relação com a renda e o comportamento do PIB (YENILMEZ I; MUGENZI F, 2023).

O crescimento econômico, medido pela taxa de aumento do PIB, é crucial para o desenvolvimento, trazendo benefícios como criação de empregos e melhoria nos padrões de vida. No entanto, o PIB não abrange todos os aspectos do bem-estar social, como a distribuição de renda e a qualidade de vida, gerando debates sobre sua eficácia como indicador de progresso.

De forma a ter uma visão de status econômico, o estudo tem como objetivo principal avaliar e comparar a eficácia de diferentes técnicas de regressão na previsão do PIB Nacional Brasileiro, utilizando dados do PIB bruto anual de 1962 a 2023. Entre as abordagens analisadas estão a Regressão Linear Simples, Regressão com Descida do Gradiente Estocástico, SVR e MLP. Embora métodos mais complexos como redes neurais e SVR sejam promissores, novos insights contribuem para a escolha de modelos de maior precisão preditiva. Uma tomada de decisão baseada fielmente em informações assertivas, contribui diretamente para estratégias econômicas.

Este estudo é estruturado em seções: a seção 2 apresenta estudos correlacionados, a seção 3 discute modelos matemáticos utilizados, a seção 4 aborda métricas de eficácia, a seção 5 detalha ferramentas, a seção 6 explica os procedimentos de pesquisa, a seção 7 apresenta os resultados, a seção 8 compara os métodos, e a seção 9 resume as descobertas, limitações e propostas para futuras pesquisas.

2. Trabalhos Relacionados

As pesquisas sobre o PIB na literatura são complexas devido à multidimensionalidade dos fatores que o influenciam. Um exemplo é o consumo elétrico, que reflete o desenvolvimento industrial e o conforto residencial. Um aumento no consumo pode indicar crescimento econômico, mas também pode evidenciar ineficiências e desigualdades no acesso à energia, tornando-o um indicador multifacetado. Vasconcelos (2017) realizou uma análise comparativa de diferentes técnicas de regressão para identificar a mais eficaz na previsão do consumo de energia residencial no Brasil (em GWh). As variáveis preditoras incluem o consumo de energia residencial em anos anteriores, o PIB do Brasil e a população do país. O estudo fez previsões com um horizonte de um ano à frente dos dados utilizados para o treinamento, utilizando informações de 1980 a 2014 para prever o ano de 2015. As

avaliações foram realizadas em duas etapas de teste: previsões para os anos de 2004 a 2013 e de 2014 a 2016. O desempenho dos modelos foi avaliado principalmente por meio do Erro Percentual Absoluto Médio (MAPE). Entre as técnicas de regressão analisadas, destacam-se a Regressão Linear (simples e múltipla), Redes Neurais Perceptron Multicamadas (MLP) e a Máquina de Vetores de Suporte para Regressão (SVR). Os resultados dessas técnicas foram comparados com um modelo fuzzy. O estudo concluiu que os métodos de regressão (R.L, MLP e SVR) apresentaram, em média, um desempenho superior em comparação ao modelo fuzzy.

Yenilmez I e Mugenzi F (2023) abordam a importância da distribuição de salários e seu impacto na capacidade de consumo e no bem-estar da população indicando que, uma distribuição desigual limita o acesso a bens essenciais, prejudicando o PIB per capita de um país. Através de redes neurais artificiais (ANN) e a metodologia Box-Jenkins foram realizadas as comparações entre os resultados dos modelos. A pesquisa utilizou dados anuais do PIB per capita, de 1960 a 2021, obtidos do Banco Mundial, considerando as medidas de desempenho: Erro Absoluto Médio (MAE), Erro Quadrático Médio (MSE), Raiz do Erro Quadrático Médio (RMSE), Coeficiente de Determinação (R^2) e Erro Percentual Absoluto Médio (MAPE). Como resultado, os modelos MLP e GRNN superaram o ARIMA.

O consumo de CO2 é um indicador de sustentabilidade, com emissões elevadas refletindo práticas econômicas insustentáveis que impactam a saúde pública e o meio ambiente. Essa complexidade exige abordagens interdisciplinares e metodologias rigorosas para compreender a dinâmica econômica e social de uma nação. Qiao et al, (2024) realizou um estudo com o objetivo de prever o consumo de energia e as emissões de CO2 no setor de transportes do Reino Unido, buscando equilibrar a precisão dos modelos de machine learning (ML) e a interoperabilidade dos resultados. A análise utilizou dados anuais de 1990 a 2019, realizando previsões para o ano seguinte ($t+1$). As variáveis de entrada abrangem 22 indicadores divididos em três categorias: socioeconômicas (como PIB per capita e preço da gasolina), transporte (como intensidade energética e participação de veículos elétricos) e energia (como consumo total de energia e orçamento de P&D). As métricas de desempenho utilizadas foram: Raiz do Erro Quadrático Médio (RMSE), Erro Quadrático Médio Relativo (rRMSE), Erro Absoluto Médio (MAE) e Erro Percentual Absoluto Médio (MAPE). Os resultados permitiram concluir que a intensidade de carbono rodoviário é o principal fator influente nas previsões de consumo de energia e emissões de CO2. A Tabela 1 apresenta as especificações de cada trabalho relacionado.

Tabela 1 – Trabalhos relacionados			
Referência	Métodos	Base de Dados	Medidas de Desempenho
Yenilmez, I. and Mugenzi, F.(2023)	MLP, GRNN, LSTM,ARIMA	World Brank Open Data	MAE, MASE, RMSE, R2, MAPE
Vasconcelos (2017)	Fuzzy, R. Linear, MLP, SVR	IPEA, SGS, IBGE	MAPE
Qiao et al (2024)	LSBoost, MLP, SVR, LR, RF, LSTM	UK Departament for Transport	RMSE, rRMSE, MAPE, MAE

Fonte: O Autor (2024)

3. Métodos de Regressão

Francis Galton, pesquisador e precursor do conceito de regressão, tinha como objetivo principal provar a existência relacional entre a hereditariedade do ser humano e suas características através de análises populacionais e tendências de estatura mediana da sociedade em sua época. Para isso, era necessário utilizar de meios matemáticos onde fosse possível criar relações (GALTON, 1886).

Deste modo, a regressão é uma técnica utilizada para modelar e analisar relações entre variáveis, de forma que seja possível realizar previsões e previsões, onde respectivamente temos: Processos de análise onde o alvo dos dados é o momento atual e processo de análise onde o alvo dos dados é o futuro (organização dos dados ao longo do tempo).

Essa metodologia permite que seja criado um vínculo relacional entre variáveis que são dependentes e variáveis independentes utilizando cálculos através de funções matemáticas (GOLBERG, M; CHO, H, 2004).

3.1 Regressão Linear Simples

A regressão linear simples é um modelo que possui uma única variável independente x que tem uma relação com a variável dependente y . A equação para obtê-la é dada por:

$$y = \beta_0 + \beta_1 x + \varepsilon \quad (1)$$

Onde β_0 e $\beta_1 x$ são os coeficientes de regressão estimados e ε é um erro que conta a discrepância entre o valor predito na Equação (1) e o valor observado. O valor predito na Equação (1) é dado por (MONTGOMERY, 2015) (FUMO; BISWAS, 2015).

$$\bar{y} = \bar{\beta}_0 + \bar{\beta}_1 x \quad (2)$$

Onde $\bar{y}$ é o valor predito e $\bar{\beta}_0$ e $\bar{\beta}_1 x$ são os coeficientes estimados

3.1.1 Regressão Linear – Gradiente Descendente Estocástico

A regressão linear com gradiente descendente estocástico assim como a regressão linear simples, busca encontrar a melhor linha reta que descreva a relação entre as variáveis dependentes (y) e variáveis independentes (x), porém, utilizando uma abordagem iterativa de forma a minimizar uma função de custo (GÉRON, 2019).

3.1.2 Máquinas de Vetores e Suporte - SVR

O SVR é definido como uma técnica de aprendizado de máquina que permite resolver problemas de regressão através da busca de uma função que se ajusta aos dados do modelo de treinamento, onde, o contexto é determinado pelos pontos da margem de separação (vetores de suporte), definindo a função de regressão pela distância entre os vetores. O treinamento do modelo através do SVR utiliza uma abordagem de supervisionamento voltada ao conceito de perda simétrica, desta forma, a penalização ocorre de forma igualitária, independente de estimativas altas ou baixas (ZHANG; O'DONNELL, 2020).

O principal objetivo alcançado por esse algoritmo é a representação da relação dos atributos em prol do objetivo esperado. Sua base de execução é fundamentada no princípio de minimização de risco, este princípio busca garantir melhor desempenho se comparado com outras técnicas. O treinamento de um modelo através do SVR obrigatoriamente necessita utilizar um subconjunto de dados ao qual é chamado de vetores de suporte. Este tipo de treinamento detém complexidade de tempo de resolução em forma quadrática ou

cúbica, sendo essa complexidade proporcional ao conjunto de amostras de treinamento (LI, et al, 2009) (ZHAO; MAGOULÈS, 2010).

Entre as vantagens de utilização do SVR, destaca-se a abstração de complexidade computacional e independência do dimensionamento de espaço de entrada. A complexidade computacional está diretamente relacionada a quantidade de recursos que são necessários para o treinamento do modelo, onde, é diretamente dependente da dimensionalidade do espaço de entrada, ou seja, o conjunto de características ou variáveis necessárias para a realização da previsão (AWAD; KHANNA, 2015).

3.2 Redes Neurais Perceptron Multicamadas - MLP

As Redes Neurais são um tipo de rede neural artificial projetada para reconhecer padrões em sequências de dados, como texto, genomas, séries temporais ou dados de fala. Foram desenvolvidas para imitar o aprendizado do cérebro humano. São capazes de identificar padrões em dados multidimensionais sem a necessidade de conhecimento prévio do sistema, aprendendo a relação entre variáveis através de registros.

Uma rede neural tem como base a utilização do algoritmo de aprendizagem, esse algoritmo permite armazenar determinado conhecimento, onde, inicialmente o conhecimento está em sua forma experimental, sem um sentido direcionado, de modo que, após o emprego da técnica de aprendizagem por parte da modificação de pesos sinápticos, o conhecimento mapeado fique disponível para uso.

Um dos benefícios das redes neurais é a generalização, onde se refere ao fato de produzir saídas adequadas para entradas que não estavam presentes durante o treinamento (HAKIN, 2007).

4. Medidas de Desempenho

Para realizar comparações de erros entre séries temporais, geralmente é necessário escolher uma única medida de erro. A escolha de uma medida única evita que a utilização de várias métricas torne o processo mais trabalhoso, sem necessariamente oferecer um ganho significativo em termos de interpretação dos resultados (ARMSTRONG; COLLOPY, 1992). No entanto, em certos casos, a aplicação de múltiplas medidas de avaliação pode proporcionar uma visão mais detalhada sobre o desempenho do modelo, permitindo uma análise mais completa dos resultados.

Neste estudo, um dos principais focos é a aplicação de uma medida de tendência central para avaliar a capacidade preditiva dos modelos. A capacidade de previsão é essencial para determinar a confiabilidade das previsões geradas. O MAPE (Mean Absolute Percentage Error), por exemplo, realiza os cálculos com base nas comparações entre os erros relativos de cada previsão e seus valores reais correspondentes (WANG et al., 2009). Essa métrica é particularmente útil para avaliar a precisão relativa de um modelo em termos percentuais. Na fórmula do MAPE, y_t representa os valores reais, y_t^* denota os valores previstos pelo modelo e n é o número de observações.

Por outro lado, o MAE (Mean Absolute Error) é uma medida não percentil, indicada quando se deseja analisar a média da magnitude dos erros nas previsões. Ele calcula a média das diferenças absolutas entre os valores previstos e os valores observados, fornecendo uma medida direta do erro médio (REICH et al., 2016). Essa abordagem é útil em contextos onde a magnitude dos erros é mais relevante do que a variação percentual. Na fórmula do MAE, y_t representa os valores reais, y_t^* denota os valores previstos pelo modelo e n é o número de observações.

Além disso, o coeficiente de determinação R^2 é frequentemente utilizado para avaliar a qualidade de previsão de um modelo, medindo a proporção da variância explicada pelos dados. O valor do R^2 varia de 0 a 1, onde valores próximos a 1 indicam uma boa qualidade de ajuste, enquanto valores próximos de 0 ou negativos indicam que o modelo não consegue explicar bem a variabilidade dos dados, tornando-se ineficaz para fins de previsão. Na fórmula do R^2 , y_t são os valores observados, y_t^* são os valores previstos pelo modelo, $\bar{y}$ representa a média dos valores observados e n é o número de observações.

$$MAPE = \frac{100\%}{n} \sum_{t=1}^n \left| \frac{y_t - y_t^*}{y_t} \right| \quad (3)$$


$$MAE = \frac{1}{n} \sum_{i=1}^n |y_t - y_t^*| \quad (4)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_t - y_t^*)^2}{\sum_{i=1}^n (y_t - \bar{y})^2} \quad (5)$$

5. Dataset

Para os experimentos computacionais deste estudo, foi utilizada a base de dados do PIB, disponível no portal do Banco Central do Brasil (BCB). Esta base abrange o PIB do Brasil de 1962 a 2023, focando em dados anuais, o que possibilita uma análise aprofundada das tendências econômicas ao longo de mais de seis décadas (SGS, 2024). Compreender diversas fases econômicas, como períodos de alta inflação e crises globais, torna essa base especialmente valiosa para analisar padrões econômicos e testar a robustez de modelos econométricos (BLAZEJOWSKI et al, 2019).


Figura 1 – Série Temporal



Fonte: O Autor (2024)

Ao realizar a decomposição da série temporal apresentada na Figura 2, é possível identificar um comportamento geral de crescimento na "Série Observada", refletido claramente em uma "Tendência" de crescimento, que também apresenta um aumento contínuo ao longo do tempo. Este aumento sugere um crescimento consistente nos dados subjacentes. A "Sazonalidade" revela um padrão cíclico bem definido, indicando que há flutuações regulares nos dados que se repetem em intervalos previsíveis, possivelmente refletindo influências sazonais ou cíclicas no contexto analisado. Por outro lado, os "Resíduos" mostram variações que não são capturadas pela tendência e sazonalidade, mas que parecem estar distribuídas aleatoriamente, sem um padrão específico. Isso sugere que, embora a maioria das variações na série seja explicada pelos componentes de tendência e sazonalidade, há ainda elementos imprevisíveis ou ruídos que influenciam os dados, mas sem um impacto significativo ao longo do tempo.


Figura 2 – Decomposição da Série



Fonte: O Autor (2024)


Além da decomposição, as funções de autocorrelação (ACF) e autocorrelação parcial (PACF) foram analisadas para auxiliar na modelagem da série temporal. Essas funções ajudam a identificar dependências temporais nos dados históricos (YAKUBU; SAPUTRA, 2022). A ACF mede a correlação em diferentes lags, incluindo os intermediários, enquanto a PACF foca na correlação em um lag específico. Os gráficos indicaram relevância em até 5 lags, mas como a autocorrelação parcial destacou apenas 1, a escolha de 2 lags foi uma decisão intermediária e arbitrária para o estudo. Os gráficos ACF e PACF, exibidos a seguir, ilustram essas relações, proporcionando uma base sólida para a seleção de modelos econométricos apropriados.

Figura 3 – Gráfico de Autocorrelação



Fonte: O Autor (2024)

Figura 4 – Gráfico de Autocorrelação Parcial



Fonte: O Autor (2024)

6. Metodologia

O processo de análise e previsão dos dados começou com a obtenção das informações a partir de um arquivo CSV contendo os valores anuais de um indicador econômico específico, neste caso, o PIB. Utilizou-se a biblioteca Pandas para organizar essas informações em um DataFrame, facilitando a manipulação e análise subsequente. Os dados foram organizados usando a abordagem Holdout Validation, separando 70% dos registros para o treinamento e ajuste dos modelos e reservando os 30% restantes para

teste e avaliação, conforme a metodologia descrita por TEMPOLA et al. (2021). Essa abordagem garante uma avaliação confiável da performance dos modelos ao dividir os dados de forma balanceada.

Em seguida, foi aplicada a normalização dos dados com a função `StandardScaler()` da biblioteca `sklearn.preprocessing`. Essa etapa ajustou os valores à média e ao desvio padrão, o que é fundamental para modelos que exigem distribuições normalizadas, como as redes neurais e os modelos baseados em gradientes. A normalização dos dados melhora a convergência dos algoritmos de aprendizado de máquina, garantindo que os pesos dos modelos sejam ajustados de forma eficiente durante o treinamento.

Dada a natureza univariada da série temporal, utilizou-se a criação de lags para capturar a dependência dos valores históricos na previsão dos futuros. O uso de lags permite que os modelos considerem a relação entre os valores passados e presentes da série. A quantidade de lags apropriada foi determinada a partir das funções de autocorrelação e autocorrelação parcial (Figuras 3 e 4), o que resultou na escolha de dois lags para compor a base de dados utilizada nos modelos. Esses lags serviram como variáveis preditoras, permitindo que os modelos detectassem padrões nas flutuações dos valores ao longo do tempo.

Para a execução dos modelos, foram definidas as variáveis de entrada X como os lags selecionados, e a variável de saída y representando os valores normalizados da série temporal. A divisão entre os conjuntos de treinamento e teste foi mantida em 70/30, de acordo com a abordagem inicial..

Todo o processo foi implementado em Python, utilizando o Google Colab pela sua eficiência e facilidade de uso. As bibliotecas Pandas e NumPy foram essenciais para a leitura e manipulação dos dados, enquanto o Scikit-Learn permitiu a implementação dos algoritmos de regressão e escalonamento. Para a visualização dos resultados e padrões da série temporal, utilizou-se a biblioteca Matplotlib, que possibilitou uma análise mais clara e detalhada dos modelos. Esse conjunto de ferramentas foi fundamental para garantir a robustez e a eficácia da análise, alinhando-se à necessidade de precisão na previsão dos valores futuros.

7. Análise de Resultados

Figura 5 – Treinamento Regressão Linear




Tabela 2 – Desempenho de Treinamento

Medidas de Desempenho		
MAE	R ²	MAPE (%)
0.049333	0,991737	10.502221

Fonte: O Autor (2024)

Figura 6 – Previsão Regressão Linear





Tabela 3 – Desempenho de previsão

Medidas de Desempenho		
MAE	R ²	MAPE (%)
0.045548	0,996745	5.349242

Fonte: O Autor (2024)

Figura 7 – Treinamento Regressão com Descida do Gradiente Estocástico




Fonte: O Autor (2024)

Tabela 4 – Desempenho de Treinamento		
Medidas de Desempenho		
MAE	R ²	MAPE(%)
0.05533	0,994935	7,652933

Fonte: O Autor (2024)

Figura 8 – Previsão Regressão com Descida do Gradiente Estocástico




Fonte: O Autor (2024)

Tabela 5 – Desempenho de previsão		
Medidas de Desempenho		
MAE	R ²	MAPE (%)
0.05533	0,994935	7,652933

Fonte: O Autor (2024)

Figura 9 – Treinamento SVR




Fonte: O Autor (2024)

Tabela 6 – Desempenho de Treinamento		
Medidas de Desempenho		
MAE	R ²	MAPE (%)
0,059967	0,990323	11,882734

Fonte: O Autor (2024)

Figura 10 – Previsão SVR



Fonte: O Autor (2024)

Tabela 7 – Desempenho de previsão		
Medidas de Desempenho		
MAE	R ²	MAPE (%)
0.049882	0,995694	6,595596

Fonte: O Autor (2024)

Figura 11 – Treinamento MLP





Figura 12 – Previsão MLP



Fonte: O Autor (2024)

Tabela 8 – Desempenho de Treinamento		
Medidas de Desempenho		
MAE	R ²	MAPE (%)
0,051121	0,99262	10,028435

Fonte: O Autor (2024)

Fonte: O Autor (2024)

Tabela 9 – Desempenho de previsão		
Medidas de Desempenho		
MAE	R ²	MAPE (%)
0.047799	0,995723	7,438951

Fonte: O Autor (2024)

A comparação dos modelos durante o treinamento revela que o MLP tem o melhor desempenho, com MAE de 0.051121, R² de 0.99262 e MAPE de 10.03%, indicando alta precisão e excelente ajuste aos dados. A Regressão Linear é eficiente, mas ligeiramente inferior, com MAE de 0.049333, R² de 0.991731 e MAPE de 10.50%. A Regressão com Descida do Gradiente Estocástico tem desempenho menor (MAE 0.055092, R² 0.990861, MAPE 11.24%), enquanto o SVR apresenta o pior resultado, com MAE de 0.059967, R² de 0.990323 e MAPE de 11.88%, sendo menos eficiente nas previsões.

Tabela 10 – Comparativo de Treinamento			
Medidas de Desempenho			
Modelos	MAE	R ²	MAPE (%)
MLP	0,051121	0,99262	10,028435
Regressão Linear	0,049333	0,991731	10,502221
Regressão DGE	0,055092	0,990861	11,239363
SVR	0,059967	0,990323	11,882734

Fonte: O Autor (2024)

Para previsão, a Regressão Linear apresentou o melhor desempenho (MAE 0.045548, R² 0.996745, MAPE 5.35%), mostrando grande precisão e ajuste aos dados. O SVR teve resultados sólidos (MAE 0.049882, R² 0.995694, MAPE 6.60%), seguido de perto pelo MLP (MAE 0.047799, R² 0.995723, MAPE 7.44%). A Regressão com Descida do Gradiente Estocástico obteve o pior desempenho, com o maior erro (MAE 0.05533, R² 0.994935, MAPE 7.65%), sendo o menos eficiente nas previsões.

Tabela 11 – Comparativo de Previsão			
Medidas de Desempenho			
Modelos	MAE	R ²	MAPE (%)
Regressão Linear	0,045548	0,996775	5,349242
SVR	0,049882	0,995694	6,595596
MLP	0,047799	0,995723	7,438951
Regressão DGE	0,05533	0,994935	7,652933

Fonte: O Autor (2024)

8. Conclusão

Este estudo comparou diferentes técnicas de regressão para previsão de séries temporais do PIB, evidenciando a Regressão Linear como a mais precisa, com um MAE de 0.045548, R² de 0.996745 e MAPE de 5.35%. A validação Holdout (70% para treino e 30% para teste) e a normalização dos dados foram fundamentais para garantir a eficácia dos resultados. A Regressão Linear demonstrou ser eficiente em cenários de menor complexidade, enquanto modelos mais sofisticados, como MLP e SVR, apresentaram bom desempenho, mas sem superar a simplicidade da regressão linear.

Os indicadores de desempenho (MAE, R² e MAPE) permitiram uma análise abrangente, destacando a importância de uma abordagem multifacetada para a avaliação de modelos

preditivos. A pesquisa sugere que, em determinados contextos, modelos simples podem superar alternativas mais complexas, desde que acompanhados de uma preparação adequada dos dados e uma validação robusta.

Entretanto, a abordagem Holdout pode não capturar todas as nuances das séries temporais, e a análise limitada a quatro técnicas de regressão pode restringir a generalização dos resultados. Modelos como `DecisionTreeRegressor`, `KNeighborsRegressor` e `XGBoost` poderiam ser explorados para ampliar a comparação.

Como continuidade, propõe-se a previsão do PIB para 2024 com o melhor modelo identificado, além de aplicar validação cruzada e integrar dados multivariados para aumentar a precisão. A inclusão de novos modelos de aprendizado de máquina pode oferecer insights adicionais, contribuindo para a melhoria das previsões econômicas em futuros estudos.

Referências

ARMSTRONG, J. S. AND COLLOPY, F. Error measures for generalizing about forecasting methods: Empirical comparisons. **International Journal Forecasting**, 1992, n.8, p.69-80.

AWAD, M. AND KHANNA, R. **Efficient Learning Machines**. Apress, 2015.

BLAZEJOWSKI, M., KWIATKOWSKI, J., AND GAZDA, J. Sources of economic growth: A global perspective. **Sustainability**, 2019, v.11, n.1.

DAMODAR N. GUJARATI AND DAWN C. PORTER. **Econometria Básica**, 5. ed, 2011, p. 213.

FUMO, N. AND BISWAS, R. Regression analysis for prediction of residential energy consumption. **Renewable and Sustainable Energy Reviews**, 2015, n.47, p. 332-343.

GALTON, F. Regression towards mediocrity in hereditary stature. **The Journal of the Anthropological Institute of Great Britain and Ireland**, 1886, n.15, p. 246-263.

GOLBERG, M; CHO, H. **Introduction to Regression Analysis**. Wit Press, 2004.

GÉRON, A. **Hands-on Machine Learning with Scikit-Learn, Keras, and Tensor-Flow**. O'Reilly Media, 2019.

HAKIN, S. **Redes Neurais Princípios e Prática**, 2007, 2. ed, p.28 - 32. Bookman.

LI, Q., MENG, Q., CAI, J., YOSHINO, H., AND MOCHIDA, A. Applying support vector machine to predict hourly cooling load in the building. **Applied Energy**, 2009, n.37, p.545-553.

MONTGOMERY, D. C. **Introduction to Linear Regression**. John Wiley Sons, 2015.

QIAO, Q., ESKANDARI, H., SAADATMAND, H., AND SAHRAEI, M. A. An interpretable multi-stage forecasting framework for energy consumption and co2 emissions for the transportation sector. **Energy**, 286, (2024).

REICH, N.G., LESSLER, J., SAKREJDA, K., LAUER, S.A., IAMSIRITHAWORN, S., CUMMINGS, D.A.T. Case study in evaluating time series prediction models using the relative mean absolute error. **The American Statistician**, 2016, v.70, n.3, p.285-292.

SGS (2023). **Banco central do brasil - sgs - sistema gerenciador de séries temporais-produto interno bruto em r\$ correntes**. Disponível em: <<https://www3.bcb.gov.br/sgspub/localizarseries/localizarSeries.do?method=prepararTelaLocalizarSerie>> Acesso em: 09 out. 2024 - Fonte: BCB-Depec.

TEMPOLA, F., ROSIHAN, R., AND ADAWIYAH, R. Holdout validation for comparison classification naive bayes and knn of recipient kartu indonesia pintar. In IOP Conference Series: **Materials Science and Engineering**, 2021.

VASCONCELOS, L. Uma comparação de técnicas de regressão para a previsão de consumo de energia residencial no cenário nacional. **XLIX Simpósio Brasileiro de Pesquisa Operacional**, (2017).

WANG, W.-C., CHAU, K.-W., CHENG, C.-T., AND QIU, L. A comparison of performance of several artificial intelligence methods for forecasting monthly discharge time series. **Journal of Hydrology**, 2009, n.374, p.294-306.

YAKUBU, U. A. AND SAPUTRA, M. P. A. Time series model analysis using autocorrelation function (acf) and partial autocorrelation function (pacf) for e-wallet transactions during a pandemic. **International Journal of Global Operations Research**, 2022, v.3, n.2, p.83.

YENILMEZ, I. AND MUGENZI, F. Estimation of conventional and innovative models for rwanda's gdp per capita: A comparative analysis of artificial neural networks and box-jenkins methodologies. **Scientific African**, 2003.

ZHANG, F. AND O'DONNELL, L. J. **Support vector regression**. Springer, 2020

ZHAO, H. AND MAGOULÈS, F. Parallel support vector machines applied to the prediction of multiple buildings energy consumption. **Journal of Algorithms & Computational Technology**, 2010, v.4, n.2 p.231-249