



ConBRepro

XIII CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO



IA nas Engenharias

29 nov. a 01
de dezembro 2023

Otimização de Hiperparâmetros em Modelos SVR para previsão de preços do Petróleo Bruto WTI: Uma Análise Comparativa entre Abordagens de Busca Aleatória (Random Search) e em Grade (Grid Search).

João Lucas Ferreira dos Santos

Programa de Pós-Graduação em Engenharia de Produção – Universidade Tecnológica Federal do Paraná – campus Ponta Grossa

Victor Cesar Simões de Oliveira

Departamento de Engenharia Elétrica – Universidade Tecnológica Federal do Paraná – campus de Ponta Grossa

Cristiellen Heuko da Silva

Departamento de Engenharia Elétrica – Universidade Tecnológica Federal do Paraná – campus de Ponta Grossa

Yslene Rocha Kachba

Departamento de Engenharia de Produção – Universidade Tecnológica Federal do Paraná – campus Ponta Grossa

Hugo Valadares Siqueira

Programa de Pós-Graduação em Engenharia de Produção/Programa de Pós-Graduação em Engenharia Elétrica/Programa de Pós-Graduação em Ciência da Computação – Universidade Tecnológica Federal do Paraná – campus Ponta Grossa

Resumo: Este estudo abordou a otimização de hiperparâmetros em modelos de Regressão por Vetores de Suporte (SVR) com kernel RBF para a previsão de preços do Petróleo Bruto do tipo West Texas Intermediate (WTI). A análise se estende ao longo de um extenso histórico de preços abrangendo de janeiro de 1987 a fevereiro de 2023, com foco no fechamento mensal dos valores. O objetivo principal é melhorar a precisão das previsões por meio da busca de parâmetros, comparando duas abordagens distintas: busca aleatória e busca em Grid. A aleatoriedade inerente à busca Random Search demonstrou ser eficaz na exploração do espaço de hiperparâmetros, enquanto a busca em Grid, devido à sua abordagem exaustiva, tornou-se computacionalmente custosa e menos eficiente. O trabalho contribuiu para o entendimento de como diferentes algoritmos de otimização afetam o desempenho desses modelos na tarefa de previsão de preços de commodities, como o Petróleo. Ao final o modelo que obteve o melhor desempenho foi um SVR usando Random Search com um MSE de 73.8541 e RMSE de 8.5938.

Palavras-chave: Previsão; Petróleo; aprendizado de máquina; otimização; séries temporais

Hyperparameter Optimization in SVR Models for WTI Crude Oil Price Prediction: A Comparative Analysis between Random Search and Grid Search Approaches.

Abstract: This study addressed the hyperparameter optimization in Support Vector Regression (SVR) models with RBF kernel for predicting West Texas Intermediate (WTI) Crude Oil prices. The analysis spans an extensive price history from January 1987 to February 2023, focusing on monthly closing values. The main objective is to enhance prediction accuracy through parameter tuning, comparing two distinct approaches: random search and grid search. The inherent randomness of Random Search has proven effective in exploring the hyperparameter space, while Grid Search, due to its exhaustive approach, became computationally expensive and less efficient. The work contributed to understanding how different optimization algorithms affect the performance of these models in the task of commodity price forecasting, such as Crude Oil. In the end, the model that achieved the best performance was an SVR using Random Search with an MSE of 73.8541 and RMSE of 8.5938.

Keywords: Forecasting; Petroleum; machine learning; optimization; time series

1. Introdução

O processo de previsão em séries temporais depende exclusivamente do tipo de modelo a ser escolhido, e além da escolha, a determinação dos parâmetros que compõem os processos de previsão (modelagem) pode não ser uma tarefa trivial (AL-THALABI, HEYDARI, TAVAKOLI, 2023). Sobretudo, quando a investigação é em relação a uma variável suscetível a interferências nos aspectos geopolíticos, monetários, humanitários e entre outros como é o caso do Petróleo (CHIROMA, et al. 2013; WANG, XIA e LU, 2022; YUAN, LI e HAO, 2023; MONGE, ROJO, GIL-ALANA, 2023).

Dada a relevância e interesse pela assertividade na modelagem desta variável, as pesquisas partem de modelos clássicos, como os modelos de Box-Jenkins e Suavização (TULARAM, SAEED, 2016; SALLES, LONDE, 2020; THEERTHAGIRI, RUBY, 2023), até os modelos inspirados em inteligência computacional (WANG, LI e LI, 2022; NASIR et al., 2023) e modelos híbridos (AZIZ, BARAWI e SHAHIRI, 2020; YUAN, LI e HAO, 2023). Os pesquisadores não chegaram em um consenso sobre qual tecnologia ou metodologia deve ser usada para realizar tal tarefa (WANG, XIA e LU, 2022), evidenciando uma oportunidade constante em testar algoritmos e novas estratégias de busca de parâmetros.

Nesse contexto, como otimizar efetivamente os parâmetros dos modelos de Regressão por Vetores de Suporte (SVR) com kernel RBF para melhorar a precisão das previsões dos preços do Petróleo Bruto tipo West Texas Intermediate (WTI)? E como essa otimização se comporta entre dois algoritmos diferentes?

Este trabalho está voltado a investigar essas questões e demonstrar a importância da otimização de hiperparâmetros em modelos de SVR com kernel RBF na tarefa de estimar o preço do Petróleo Bruto tipo WTI.

O trabalho está estruturado da seguinte forma: Referencial teórico; Metodologia; Tratamento dos Dados; Resultados e Discussões; Conclusões.

2. Referencial Teórico

2.1.1 Support Vector Regression (SVR)

Regressão é uma técnica fundamental na análise de dados e no aprendizado de máquina, e tem como objetivo prever valores numéricos com base em um conjunto de dados de treinamento. O SVR é uma técnica avançada de aprendizado de máquina que se destaca

na resolução de problemas de regressão complexos, especialmente quando as relações entre as variáveis são não lineares (VAPNIK, 1999; LIASHCHYNSKYI e LIASHCHYNSKYI, 2019).

O SVR é uma extensão do *Support Vector Machine* (SVM), originalmente desenvolvido para tarefas de classificação. A essência do SVR reside em encontrar uma função de regressão que minimize o erro de previsão, ao mesmo tempo que controla uma margem ε (epsilon) de erros aceitáveis (AWAD; KHANNA, 2015).

No cerne do SVR encontram-se conceitos fundamentais que desempenham um papel crucial em sua operação, como os vetores de suporte. Esses vetores são um subconjunto dos pontos de dados de treinamento e são selecionados, porque são os mais próximos da função de regressão ideal que o SVR quer encontrar (GUO et al., 2021). Os vetores de suporte desempenham um papel fundamental na determinação da função de regressão final.

Outro conceito chave é a já mencionada margem ε . Essa margem controla a largura da faixa em torno da função de regressão, na qual, os erros de previsão são tolerados. Ou seja, pontos de dados que caem dentro dessa margem não são considerados erros significativos na previsão.

A função de regressão é a parte central do algoritmo de aprendizado. Ela é usada para fazer previsões ou estimativas com base nos dados de entrada. A forma geral de regressão usada pelo SVR está representada na equação 1 (DRUCKER et al., 1997; VAPNIK, 1999):

$$f(x) = \langle w, \phi(x) \rangle + b \quad (1)$$

onde w é o vetor de pesos associados às características de entrada (x), b é um termo de viés (*bias*) que ajuda a calibrar a função de regressão em relação aos dados e $\phi(x)$ é uma função de mapeamento representada por um *kernel*, que influencia a capacidade do SVR em capturar relações entre as variáveis de entrada não lineares. A escolha da função de mapeamento é essencial, sendo que nela, o *kernel* RBF desempenha um papel crucial.

O *kernel* RBF é particularmente adequado para mapear os dados originais em um espaço de características de alta dimensão, chamado espaço *kernel*, cujas as relações entre as variáveis podem se tornar mais lineares. Sua capacidade de capturar relações complexas e não lineares entre as variáveis, é uma das razões pelas quais o *kernel* RBF é amplamente utilizado em problemas de SVR. Sua forma é dada na equação 2 e 3:

$$K(x, x_i) = \exp(-\gamma \|x - x_i\|^2) \quad (2)$$

$$K(x, x_i) = \exp(-\gamma \|x - x_i\|^2) \quad (3)$$

Onde $K(x, x_i)$ é o valor do *kernel* RBF para dois pontos x e x_i , $\|x - x_i\|$ é a distância euclidiana entre x e x_i , e σ é um parâmetro que controla a largura do *kernel* e γ controla influência de cada elemento do treinamento (SMOLA, SCHÖLKOPF, 2004).

Além disso, o SVR incorpora termos de regularização, controlados pelo parâmetro C , para evitar *overfitting*. A função objetiva a ser minimizada no SVR está representada na equação 4:

$$\frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^N (\xi_i + \xi_i^*) \quad (4)$$

Sujeita às restrições das equações 5a, 5b e 5c:

$$y_i - \mathbf{w}^T x_i \leq \varepsilon + \xi_i^* \quad (5a)$$

$$\mathbf{w}^T x_i - y_i \leq \varepsilon + \xi_i \quad (5b)$$

$$\xi_i, \xi_i^* \geq 0 \quad (5c)$$

Nesta função, $\|\mathbf{w}\|^2$ representa a norma do vetor de pesos \mathbf{w} , que é minimizada para encontrar a função de regressão ótima. O parâmetro C controla o *trade-off* entre a minimização do erro de treinamento e a maximização da margem ε . As variáveis ξ_i e ξ_i^* são variáveis de folga (*slack variables*) associadas a cada ponto de dados no conjunto de treinamento. Elas são introduzidas para permitir que alguns pontos de dados fiquem dentro da margem ε ou até mesmo fora da margem, mas com penalizações associadas.

A função objetivo do SVR busca encontrar uma função de regressão que minimiza o erro de treinamento, ao mesmo tempo em que controla o equilíbrio entre a simplificação do modelo e a penalização de treinamento. Isso permite que o SVR encontre um equilíbrio adequado entre a precisão da previsão e a generalização para novos dados (YU; ZHANG; WANG, 2017).

Em resumo, o SVR é uma técnica de aprendizado de máquina eficaz para problemas de regressão complexos, além disso, o uso do *kernel* RBF desempenha um papel crítico em sua capacidade de lidar com relações não lineares. Os conceitos fundamentais, como vetores de suporte, margem ε , função de regressão e regularização, combinados com o poder do *kernel* RBF, tornam o SVR uma ferramenta valiosa na previsão de valores numéricos em cenários do mundo real. A escolha adequada de hiperparâmetros, incluindo o ajuste do *kernel* RBF, e uma compreensão profunda de seu funcionamento, são fundamentais para obter um desempenho satisfatório.

2.1.2 Algoritmos de Aprendizado de Máquina e Busca de Hiperparâmetros

A utilização dos métodos de busca depende da natureza e complexidade dos dados a serem modelados, dito isso, existe uma vasta literatura de aplicação para algoritmos de inspiração biológicas, entre eles: Busca em Grade (Grid Search); Busca Aleatória (Random Search); Otimização Bayesiana; Otimização por Gradiente; Otimização por Gradiente Estocástico; Otimização Multiobjetivo, e entre outros (UBAI, HUSSAIN, MUHAMMAD, 2021). Neste trabalho apenas o método Grid Search e Random Search será utilizado.

A) Grid Search (GD) – É uma técnica utilizada para testar todas as possibilidades possíveis com todos os parâmetros utilizados, neste caso, os parâmetros (C , ε , γ). O critério de avaliação para escolha de parâmetros, pode ser o MSE (PARMEZAN, SOUZA, BATISTA, 2019; ABBASIMEHR, SHABANI e YOUSEFI, 2020; VASILIS, PANTELIS e SOTIRIS, 2020

B) Random Search (RD) – Em vez de testar todas as possibilidades completas, essa técnica testa combinações aleatórias dos resultados, servindo como entrada para o próximo dado a ser testado, o que resulta em um tempo computacional menor em relação ao GD (VILLALOBOS-ARIAS et al., 2020; PUTATUNDA, RAMA, 2020).

2.1.3 Métricas de Avaliação

As métricas de avaliações para os modelos utilizadas foram o Mean Squared Error (MSE) e Root Mean Squared Error (RMSE).

O MSE avalia como a média dos erros quadrados do modelo está se comportando em relação aos dados reais, ou seja, quando mais próximo de 0 melhor é o desempenho do modelo (KOURENTZES, BARROW e PETROPOULOS, 2019). Conforme a equação 6.

$$MSE = \frac{1}{n} \sum_{1}^n (y - \hat{y})^2 \quad (6)$$

Em que y representa os valores previstos; \hat{y} os valores observados; n a Quantidade de valores observada.

Para o RMSE a avaliação está em medir a magnitude média do erro entre o valor previsto e o valor real. Conforme a equação 7.

$$RMSE = \sqrt{MSE} \quad (7)$$

3. Metodologia

Os dados utilizados podem ser consultados em Independent Statistics and Analysis Center, Energy Information Administration (EIA) (EIA, 2023).

Todos os processos realizados neste estudo, como: i) visualização dos dados iniciais, ii) separação entre treino e teste, iii) valores previstos, e iv) avaliações dos modelos, foram utilizadas as respectivas bibliotecas: Matplotlib¹, Numpy², Pandas³, Seaborn⁴, Sklearn⁵ e Statsmodel⁶. Todos os processos citados foram desenvolvidos na linguagem Python.⁷ Utilizando um ambiente de desenvolvimento integrado (IDE) Spyder⁸.

4. Tratamento dos Dados

Inicialmente, os dados foram pré-processados seguindo as etapas correspondentes: formatação de datas, substituição de vírgulas por pontos para tornar números decimais válidos e eliminação de colunas desnecessárias. Após esta primeira etapa, foi possível ilustrar os valores totalizando em 474 observações ao longo do tempo, como apresenta a Figura 1.

¹ Disponível em: <https://matplotlib.org/stable/>

² Disponível em: <https://numpy.org/pt/>

³ Disponível em: <https://pandas.pydata.org/>

⁴ Disponível em: <https://seaborn.pydata.org/>

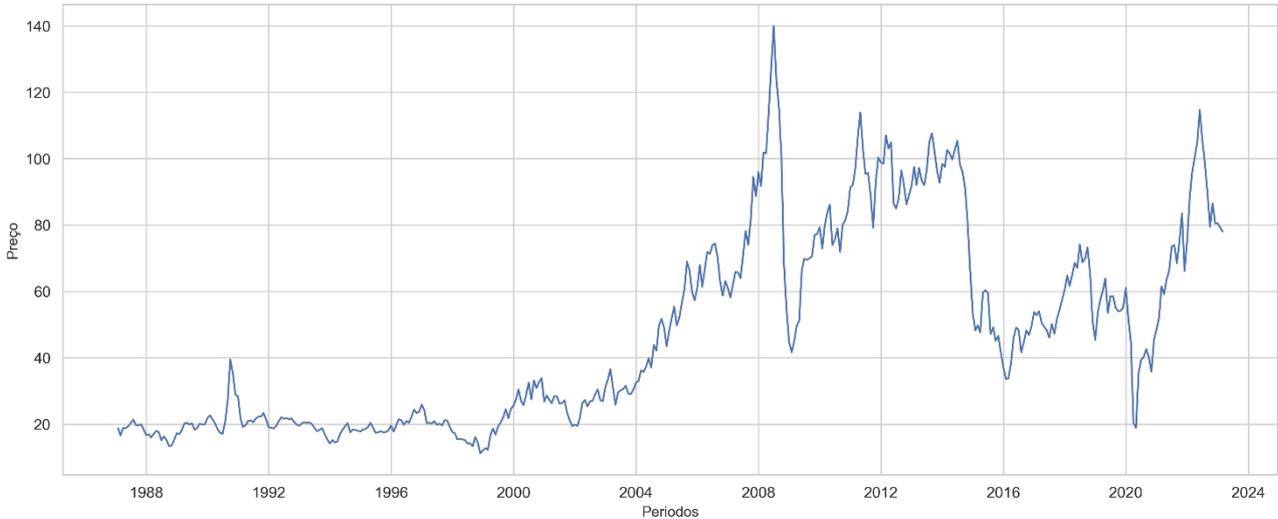
⁵ Disponível em: <https://scikit-learn.org/stable/>

⁶ Disponível em: <https://www.statsmodels.org/stable/index.html>

⁷ Disponível em: <https://www.python.org/>

⁸ Disponível em: <https://www.spyder-ide.org/>

Figura 1 – Petróleo WTI



Fonte: Autores (2023).

Com a observação dos dados ao longo do tempo, a próxima etapa consistiu em dividir esse conjunto de dados em duas categorias: treinamento e teste. A divisão foi feita em uma proporção de 75 % e 25%, respectivamente. Esta divisão pode ser observada na Figura 2.

Figura 2 – Petróleo WTI

Dados de Treinamento e Teste



Fonte: Autores (2023).

Após a divisão, os dados foram normalizados. Esta etapa é fundamental para a modelagem de algoritmos de aprendizado de máquina, pois permite mitigar a influência excessiva de valores discrepantes no conjunto de dados. Com esse processo, os dados foram ajustados garantindo uma escala comum e uma média zero.

Dito isso foi possível iniciar a modelagem dos dados, testando todas as possibilidades contidas na Tabela 1.

SVR	
Parâmetros	Valores
C	-3,6,10,100,1000
Kernel	RBF
ϵ	0.1,0.2,0.3,0.4,0.5
γ	-6,3,10,100,1000

Fonte: Autores (2023).

Após uma busca exaustiva dos parâmetros com GD os parâmetros foram $C = 10$; $\gamma = 1$; $\epsilon = 0,2$ esses foram testados novamente considerando uma busca RD, com 300 iterações.

Com os parâmetros definidos para $C = 10$; $\gamma = 1000$; $\epsilon = 0,2$. Nesse contexto, janelas temporais foram incorporadas ao conjunto de treinamento, nas quais, determinou-se o tamanho de 10.

Em vez de dividir os dados em conjuntos fixos de treinamento, teste e validação, essa técnica inicia o treinamento com um pequeno conjunto de dados e, em seguida, desloca a janela de treinamento e validação ao longo do tempo. Em cada iteração, o modelo é treinado com uma parte dos dados iniciais e, em seguida, avaliado na próxima parte, progredindo na série temporal.

O modelo é treinado repetidamente em cada uma dessas janelas temporais, uma após a outra. Após o treinamento em cada janela, o modelo é avaliado com o conjunto de teste correspondente àquela janela. O modelo faz previsões após a janela temporal atual, e os resultados dessas previsões são avaliados usando o MSE e RMSE, registrados para cada janela temporal.

Finalmente para fins didáticos, apresentamos graficamente o comportamento de um único modelo na fase de treinamento como ilustra a Figura 3.

Figura 3 – Treinamento SVR - RD

Ajuste do Modelo SVR no Conjunto de Treinamento - Random Search



Fonte: Autores (2023)

Na fase de treino, é possível observar que o treinamento do modelo se ajustou em pontos com características mais estáveis.

Após a seleção dos modelos e parâmetros, a próxima seção apresenta os resultados ao longo do conjunto de teste do modelo, considerando agora os dois algoritmos RD e GD.

5. Resultados e Discussões

Nesta seção serão apresentados os resultados referentes a modelagem utilizada para as previsões usando ambos os algoritmos de busca. Nesta fase, será avaliado todo o conjunto de teste. A tabela 2 a seguir apresenta o desempenho dos modelos.

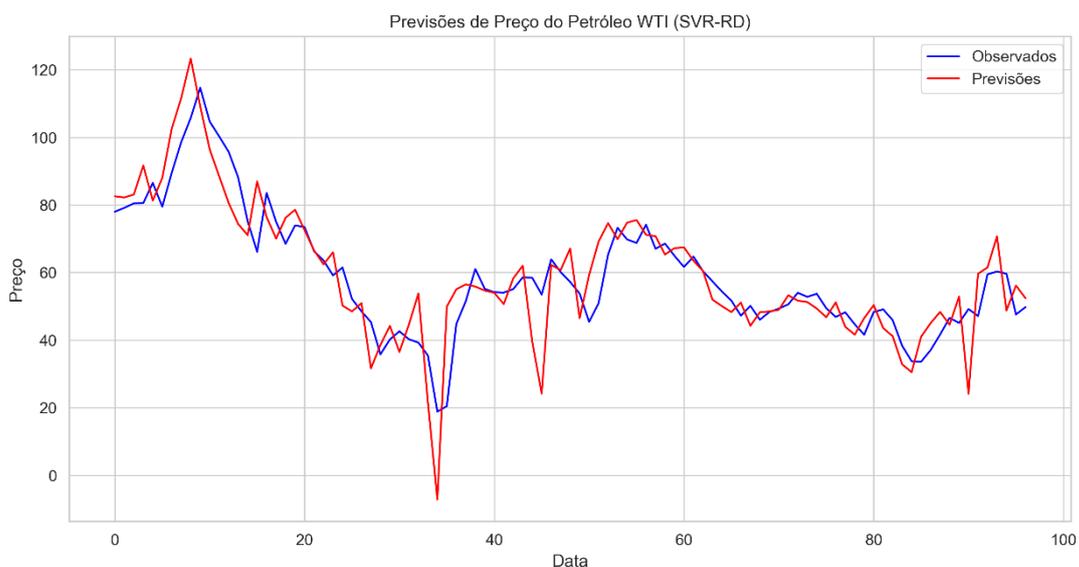
SVR – Fase de Teste		
Otimizadores	MSE	RMSE
GD	226.3765	15.0458
RD	73.8541	8.5938

Fonte: Autores (2023)

Na análise dos resultados, observa-se que o método RD obteve um desempenho significativamente melhor em comparação ao GR. Isso pode ser atribuído à aleatoriedade na busca de hiperparâmetros, o que capacita a explorar uma gama mais abrangente de combinações de parâmetros (NUNES et al., 2023). Em contraste, o GD varre sistematicamente todo o espaço de busca, tornando-se computacionalmente mais caro, especialmente quando o espaço de busca é extenso e existem vários parâmetros, como neste caso (MOTA et al., 2022).

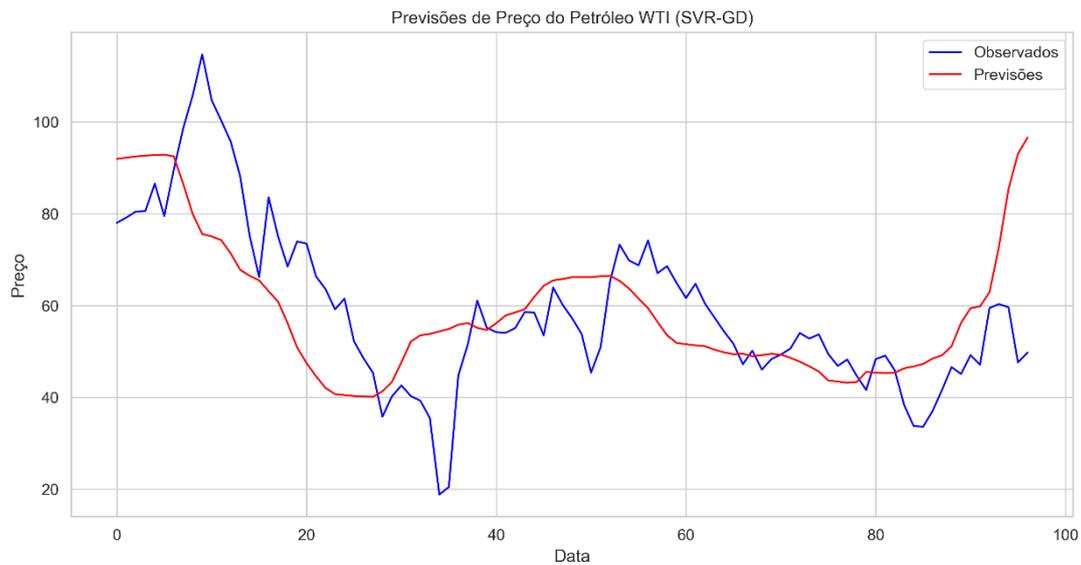
O MSE e o RMSE são métricas que refletem a qualidade das previsões do modelo. No contexto deste estudo, um valor menor de MSE e RMSE indica que as previsões do modelo SVR são mais precisas quando otimizadas com RD, o que é crucial para a modelagem de séries temporais.

Figura 5 – Previsões e Valores Observados



Fonte: Autores (2023)

Figura 6 – Previsões e Valores Observados



Fonte: Autores (2023)

Esses resultados destacam a importância de escolher cuidadosamente a abordagem de otimização de hiperparâmetros ao construir modelos de aprendizado de máquina, pois a escolha certa pode levar a um desempenho substancialmente melhor e economia de recursos computacionais. O parâmetro que obteve valor diferente em ambos os algoritmos foi o γ , responsável por controlar a influência de cada ponto de treinamento nos outros pontos. Com este γ definido, foi possível obter uma generalização melhor, atribuindo ao modelo capacidade de compreender os inúmeros eventos que influenciaram um comportamento não linear dos dados.

Observando os resultados das figuras acima, momentos em que os valores reais apresentaram comportamentos mais estáveis, a capacidade de previsão foi mais assertiva. Evidenciando como variáveis externas possuem influência no preço real, que consequentemente impactam na capacidade de treinamento do modelo Figura 3, ou seja, aprender com as amostras *in sample*, que posteriormente impactam no desempenho do modelo para a fase de teste Figuras 4 e 5 *out of sample*.

De modo geral, observa-se como o SVR possui a capacidade de generalizar em séries que possuem relações não lineares, que é o caso do preço do Petróleo. Pois sua capacidade de mapear os dados para um espaço de características de alta dimensionalidade e encontrar um hiperplano de separação que maximize a margem entre as previsões e os dados reais, viabilize sua utilização para séries univariadas como é o caso do preço do Petróleo WTI.

5. Conclusões

O término deste estudo se propôs a otimizar os parâmetros dos modelos de SVR com kernel RBF para aprimorar a precisão das previsões dos preços do Petróleo WTI. Ao longo da pesquisa, avaliamos duas abordagens de otimização de hiperparâmetros: RD e GD. Os resultados obtidos demonstram que a abordagem RD superou a GD em termos de desempenho, apresentando um RMSE significativamente mais baixo.

Os resultados desta pesquisa destacam a importância da otimização de hiperparâmetros na modelagem de séries temporais financeiras, como os preços do Petróleo. A escolha

adequada dos parâmetros pode resultar em modelos mais precisos e, conseqüentemente, em previsões mais confiáveis.

No entanto, vale ressaltar que o desempenho dos modelos SVR com kernel RBF também pode depender da escolha das características e do pré-processamento dos dados, áreas que podem ser exploradas em pesquisas futuras para aprimorar ainda mais a precisão das previsões.

Em última observação, este estudo contribui para uma compreensão mais aprofundada da importância da otimização de hiperparâmetros na modelagem de séries temporais financeiras e destaca a eficácia da abordagem de RD, na busca por parâmetros ótimos. Esses insights podem ser valiosos para profissionais e pesquisadores que buscam melhorar a precisão das previsões de preços de commodities, como o Petróleo Bruto tipo WTI.

Referências

AL-THALABI, Sahera Hussein Zain; HEYDARI, Ali Akbar; TAVAKOLI, Masoud. Using hybrid Artificial Neural Network with Supportive Vector Regression Technique in Modeling and Prediction/With Practical Application. **Utilitas Mathematica**, [s. l.], v. 8, n. 120, p. 130-138, jan. 2023.

AWAD, M.; KHANNA, R. Support Vector Regression. In: **Efficient Learning Machines**. Apress, Berkeley, CA. 2015.

AZIZ, M.; BARAWI, M.; H. SHAHIRI, H. Is Facebook PROPHET Superior than Hybrid ARIMA Model to Forecast Crude Oil Price? **Sains Malaysiana**, [s. l.], v. 8, n. 51, p. 2633-2643, 30 jan. 2020.

CHIROMA, H.; ABDULKAREEM, S.; ABUBAKAR, A.; USMAN, J.M. Computational intelligence techniques with application to crude oil price projection: a literature survey from 2001–2012. **Neural Networks World**.v.23, p.523-551, 2013.

DRUCKER, H., BURGESS, C., KAUFMAN, L., SMOLA, A., & VAPNIK, V. Support vector regression machines. In *Advances in neural information processing systems* (Vol. 9, p. 155–161). 1997. MIT Press.

EIA. **Independent Statistics and Analysis U.S. Energy Information Administration**. Disponível em: < <https://www.eia.gov/>>. Acesso em 01 de setembro de 2023.

GUO, L.; FANG, W.; ZHAO, Q.; WANG, X. The hybrid PROPHET-SVR approach for forecasting product time series demand with seasonality. **Computers & Industrial Engineering**, China, v. 161, n. 161, p. 1-14, 9 ago. 2021.

KOURENTZES, N.; BARROW, D.; PETROPOULOS, F. Another look at forecast selection and combination: Evidence from forecast pooling. **International Journal of Production Economics**, Volume 209, Pages 226-235. 2019.

LIASHCHYNKYI, P.; LIASHCHYNSKYI, P. Grid Search, Random Search, Genetic Algorithm: A Big Comparison for NAS. **Computer Science Machine Learning**.p.1-11, Dez 2019.

MONGE, M.; ROJO, R.R.F.M.; GIL-ALANA; A.L. The impact of geopolitical risk on the behavior of oil prices and freight rates. **Energy**. [s. l], v.269, p. 1-9. Jan 2023.

MOTA, B.S.C.; ALBUQUERQUE, S.A.; CAMPOS, S.H.M.;TIBA, C. Modelagem computacional da série temporal da irradiação global horizontal estimada por dados de satélite.**In**. IX Congresso Brasileiro de Energia Solar – Florianópolis 2022.

Nunes, M.R.L; Veras, S.J.; SILVA, R.P.J; CONTE, S.M.N.T; SANTOS, C.J.W; OLIVEIRA, L.C.R. Use of Arima and SVM for forecasting time series of the Brazilian electrical system. **Research, Society and Development**.V.12, n.3 fev 2023.

PUTATUNDA, S.; RAMA, K. A Modified Bayesian Optimization based Hyper-Parameter Tuning Approach for Extreme Gradient Boosting. **In**. International Conference On Information Processing (Icinpro). Bengaluru, p. 1-6. 14 maio 2020.

SALLES, A. Assis de; LONDE, M. A. Determination of petroleum price expectations in the international market through classic forecast models. **Brazilian Journals Of Business**, Curitiba, v. 2, n. 1, p. 228-241, 15 jan. 2020.

SMOLA, A.J.; SCHÖLKOPF, B. A tutorial on support vector regression. **Statistics and Computing** 14, p.199–222. 2004.

THEERTHAGIRI, P.; RUBY, A.U. Seasonal learning based ARIMA algorithm for prediction of Brent oil Price trends. **Multimed Tools Appl**.v.82.p.1-20.

TULARAM, A, G.; SAEED, T. Oil-Price Forecasting Based on Various Univariate Time-Series Models. **American Journal of Operations Research**.v.6, p.226-235, jan2016.

UBAID, A.; HUSSAIN, F.; MUHAMMAD, S. Container Shipment Demand Forecasting in the Australian Shipping Industry: A Case Study of Asia–Oceania Trade Lane. **Journal Of Marine Science And Engineering**, [s. l], v. 9, n. 9, p. 1-20, 01 jan. 2021.

VAPNIK, V.; GOLOWICH, S.E.; SMOLA A. Support vector method for function approximation, regression estimation, and signal processing. **In**: Mozer, M.C.;Jordan, M.; Petsche, T.; Eds., Advances in Neural Information Processing Systems 9, MIT Press, Cambridge, 1997. p.281-287.

VAPNIK, Vladimir. The nature of statistical learning theory. **Springer science & business media**, 1999.

VILLALOBOS-ARIAS, L.; QUESADA-LÓPEZ, C.; GUEVARA-COTO, J.; MARTÍNEZ, A.; JENKINS, M. Evaluating Hyper-parameter Tuning using Random Search in Support Vector Machines for Software Effort Estimation. **In**: International Conference On Predictive Models And Data Analytics In Software, [s. l], p. 31-40, 08 nov. 2020.

WANG, L.; XIA Y.; LU Y. A Novel Forecasting Approach by the GA-SVR-GRNN Hybrid Deep Learning Algorithm for Oil Future Prices. **Comput Intell Neurosci**. 2022 Aug 21;2022:4952215. doi: 10.1155/2022/4952215. PMID: 36045986; PMCID: PMC9420587.

YU L.; ZHANG X.; WANG S. Assessing Potentiality of Support Vector Machine Method in Crude Oil Price Forecasting. **Eurasia jornal of mathematics, sciece and technology education**.13(12), p.7893-7904. 2017.

YUAN, J.; LI, J.; HAO, J. A dynamic clustering ensemble learning approach for crude oil price forecsating. **Engineering Applications Of Artificial Intelligence**, [s. l], v. 123, p. 1-17, 8 abr. 2023.