

Modelagem nebulosa evolutiva participativa com passo de adaptação variável aplicada a previsão de preços do óleo diesel no Brasil

Eduardo Ravaglia Campos Queiroz * Kaike Sa Teles Rocha Alves **
Fernando Luiz Cyrino Oliveira * Eduardo Pestana de Aguiar **

* Pontifícia Universidade Católica do Rio de Janeiro, RJ,
(eduardo.campos@engenharia.ufjf.br, cyrino@puc-rio.br).

** Universidade Federal de Juiz de Fora, MG,
(kaike.alves@engenharia.ufjf.br, eduardo.aguiar@engenharia.ufjf.br)

Abstract: Transport represents one of the main costs of a logistics operation and is present in the entire supply chain, which connects suppliers, production, and consumers. So, a model that allows forecasting fuel prices becomes a competitive differential for the logistics operator. The present study developed a participatory evolving fuzzy model, with a variable step-size, denominated VS-ePL-KRLS, applied to the forecast of monthly prices of diesel oil S500 and S10, at the national level, for short, medium, and long term horizons. The proposed model presented better accuracy in relation to the existing ones of this class in the literature, without loss of computational performance for all six analyzed scenarios.

Resumo: O transporte representa um dos principais custos de uma operação logística e está presente em toda a cadeia de suprimentos, já que conecta fornecedores, produção e consumidores. Dessarte, um modelo que permita prever os preços dos combustíveis se torna um diferencial competitivo para o operador logístico. O presente estudo desenvolveu um modelo nebuloso evolutivo participativo, com passo de adaptação variável, denominado VS-ePL-KRLS, aplicado à previsão de preços mensais do óleo diesel S500 e S10, em nível nacional, para horizontes de curto, médio e longo prazo. O modelo proposto apresentou uma melhor acurácia comparado aos existentes dessa classe na literatura, sem perdas de desempenho computacional para todos os seis cenários analisados.

Keywords: Forecasting; Time Series; Diesel Oil Prices; Evolving Fuzzy Models; Variable Step-Size.

Palavras-chaves: Previsão; Séries Temporais; Preços do Óleo Diesel; Modelos Nebulosos Evolutivos; Passo de Adaptação Variável.

1. INTRODUÇÃO

A previsão é uma ferramenta essencial no mundo dos negócios, que auxilia na tomada de decisões no planejamento operacional (curto prazo), tático (médio prazo) e estratégico (longo prazo). Em um mundo que demanda processamento de informação e extração de conhecimento de uma forma cada vez mais eficiente e dinâmica, a combinação das técnicas de previsão e aprendizado de máquina vem ganhando notória relevância na modelagem de problemas reais, que se caracterizam pela alta complexidade e presença de incertezas. Diversos autores têm desenvolvido modelos que buscam achar o ponto ótimo no equilíbrio entre qualidade e tempo de resposta.

Recentemente, devido a crescente disponibilidade de dados e necessidade de previsão em tempo real, uma nova classe surgiu no contexto de aprendizado de máquina e se tornou o estado da arte para resoluções de problemas reais. Os algoritmos nebulosos evolutivos são um importante conjunto dessa classe devido a sua capacidade de adaptação ao modelo a medida que novos dados são conhecidos, em

um processo contínuo de aprendizagem através da criação e exclusão de regras (Kasabov and Filev, 2006). Uma grande variedade desses modelos pode ser encontrada na literatura, tendo o modelo *evolving Takagi-Sugeno* (eTS) como um precursor (Angelov and Filev, 2004). Este modelo atualiza o sistema recursivamente, adicionando regras novas ou atualizando regras existentes. Os antecedentes são determinados através de um agrupamento subtrativo (Chiu, 1994) baseado na noção de função potencial e os parâmetros dos consequentes são atualizados através dos Mínimos Quadrados Recursivos (Young, 2012). Porém, esse modelo apresentou falta de robustez na presença de ruído branco, ou seja, esses valores atípicos eram incorporados ao modelo ao invés de serem suavizados.

A lacuna deixada pelo modelo eTS deu origem ao surgimento do modelo *evolving Participatory Learning* (ePL) proposto por Lima et al. (2010). Esse modelo utiliza um algoritmo de agrupamento nebuloso dinâmico não supervisionado para determinação dos antecedentes, cuja metodologia é similar ao aprendizado humano (Yager, 2004). O ser humano tem seu processo de aprendizagem amplificado

caso já exista um conhecimento prévio sobre o objeto de estudo. De forma similar, no modelo, a atualização da base de regras é uma função das regras existentes e das novas informações recebidas. Os parâmetros dos consequentes são atualizados através dos Mínimos Quadrados Recursivos como no eTS. A fim de expandir o modelo ePL, Vieira et al. (2018) propôs o modelo *evolving Participatory Learning with Kernel Recursive Least Square* (ePL-KRLS), que atualiza os parâmetros dos consequentes através dos Mínimos Quadrados Recursivos Kernelizados (Engel et al., 2004). A vantagem dessa abordagem é uma maior sensibilidade às variações nos dados de entrada, sendo capaz de aproximar sistemas não lineares de forma precisa e eficiente com custo computacional moderado. Os modelos *Set-Membership evolving Participatory Learning with Kernel Recursive Least Square* (SM-ePL-KRLS) e *Enhanced Set-Membership evolving Participatory Learning with Kernel Recursive Least Square* (ESM-ePL-KRLS) propostos por Alves et al. (2020), fez uso da filtragem para atualização, em função do erro, do parâmetro responsável pela adição, atualização ou remoção das regras.

O presente estudo se trata do desenvolvimento do modelo *Variable Step-Size evolving Participatory Learning with Kernel Recursive Least Square* (VS-ePL-KRLS), que visa melhores acurácias sem perdas de desempenho computacional. Neste modelo nebuloso evolutivo, os antecedentes são determinados através de um agrupamento dinâmico não supervisionado, os parâmetros dos consequentes são estimados através dos Mínimos Quadrados Recursivos Kernelizados e o parâmetro que controla a evolução das regras é atualizado através do passo de adaptação variável. Essa teoria é uma tentativa de melhoria da convergência do algoritmo *Least Mean Square* (LMS), mantendo o desempenho em regime permanente (Evans et al., 1993). Comparado aos modelos presentes na literatura, o VS-ePL-KRLS tem uma implementação menos complexa, resultando em uma menor complexidade computacional como observado por de Aguiar et al. (2017).

A pesquisa está organizada da seguinte forma: Contextualização da Aplicação na Seção 2, Modelo Proposto na Seção 3, Resultados Experimentais na Seção 4 e Conclusões na Seção 5.

2. CONTEXTUALIZAÇÃO DA APLICAÇÃO

A gestão de transportes é um dos principais processos logísticos e é também responsável por ligar os elos de uma cadeia de suprimentos, isto é, o abastecimento de insumos e matérias-primas entre fornecedores e produção e a distribuição de produtos finais entre produção e clientes, respectivamente. Tal gestão deve ser feita de maneira efetiva de forma a minimizar os custos e maximizar o nível de serviço.

De acordo com Fleury et al. (2000), os gastos com transportes correspondem a aproximadamente 60% dos custos logísticos de uma empresa e 10% do Produto Interno Bruto nacional. Desses gastos, 40% representam custos fixos, tais como: Certificado de Registro e Licenciamento de Veículo (CRLV), Imposto sobre a Propriedade de Veículos Automotores (IPVA), seguro contra Danos Pessoais causados por Veículos Automotores de via Terrestre (DPVAT), depreciação e salários dos motoristas, ajudantes e mecânicos.

Os 60% restantes representam custos variáveis, particularmente manutenção, pedágios e combustíveis, isso para o caso de um caminhão pesado usado para transporte de cargas (Vilardaga, 2007). Tal pesquisa ainda estima que o combustível equivale a cerca de 58% dos custos variáveis e, conseqüentemente, 35% dos custos de transportes e 21% dos custos logísticos totais. Em um país de dimensões continentais como o Brasil, que utiliza prioritariamente as malhas rodoviárias para transporte de cargas e de passageiros, uma ferramenta que possibilite previsões dos preços do óleo diesel S500 e óleo diesel S10 se torna um diferencial competitivo para o operador logístico.

O modelo desenvolvido objetiva a previsão do preço mensal de revenda do óleo diesel S500 e S10 em nível nacional para horizontes de curto (1 mês a frente), médio (6 meses a frente) e longo (12 meses a frente) prazos. Para tal, foi utilizado a base de dados da Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP, 2020), que contém os preços de distribuição e revenda entre dezembro de 2012 e maio de 2020.

O preço do supracitado combustível é composto por, aproximadamente: 43% de óleo diesel, 10% de biodiesel, 11% de impostos estaduais, 16% de impostos federais e 20% de margem da distribuição e revenda - segundo análise de dados apresentada pela Petrobrás entre 7 de junho de 2020 e 13 de junho de 2020 (Petrobrás, 2020). Indica-se, porque oportuno, que o mercado de óleo diesel automotivo no Brasil é regulamentado pela Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP) e pela Lei Federal 9.478/97 (Lei do Petróleo).

A principal diferença entre o óleo diesel S500 e o S10 está relacionado a concentração de enxofre: o primeiro contém 500 partes por milhão e o segundo contém 10 partes por milhão. Isso afeta diretamente o motor e o meio ambiente, resultando em um melhor funcionamento de ignição e combustão, menor corrosão das peças e menos poluição.

Na Tabela 1 e na Figura 1 temos uma abordagem inicial das séries temporais com informações estatísticas e ilustração do seu comportamento. Para melhor entendimento do comportamento de tais séries é necessário à análise de três situações. A primeira refere-se à política de preços dos combustíveis no país, já que, até 2016, era controlado pela Petrobrás, que defasava o repasse das variações internacionais como uma ferramenta de controle da inflação. Após prejuízos financeiros, a estatal mudou tal política e o preço passou a ser controlado pelo barril de petróleo no mercado internacional, cujas cotações variam de acordo com os diversos fatores políticos e econômicos, em escala global. É notório que a oscilação se inicia após a mudança da política de preços, convergindo com as características dinâmicas do mercado internacional. Já a segunda, trata-se de uma queda brusca em 2018, que é referente a sucessivos aumentos dos preços dos combustíveis. O óleo diesel S500 e o S10 aumentaram R\$ 0,293 (8,383%) e R\$ 0,278 (7,755%), respectivamente, nas três primeiras semanas de maio. Isto resultou na Greve dos Caminhoneiros (também conhecido com Crise do Diesel), no período de 21 de maio até 30 de maio, em todo território nacional. Frise-se que uma das reivindicações era a redução do preço do combustível. Por fim, na terceira, temos a ocorrência de uma queda livre de preços em 2020, ocasionada pela pandemia do COVID-19,

já que o preço do barril do óleo despencou e chegou a custar US\$ -37,63 em 20 de abril, uma situação sem precedentes na história.

Tabela 1. Dados Estatísticos Semanais

	S500	S10
Dados	90	90
Média	2,999	3,114
Desvio Padrão	0,460	0,453
Mínimo	2,151	2,226
Primeiro Quartil	2,518	2,658
Mediana	3,014	3,152
Terceiro Quartil	3,387	3,505
Máximo	3,788	3,856




Figura 1. Preços históricos do óleo diesel S500 e S10

3. MODELO PROPOSTO

O modelo *Variable Step-Size evolving Participatory Learning with Kernel Recursive Least Square*, VS-ePL-KRLS, é esquematizado pela Figura 2. Ele é uma extensão dos modelos nebulosos evolutivos: ePL-KRLS proposto por Vieira et al. (2018), SM-ePL-KRLS e ESM-ePL-KRLS propostos por Alves et al. (2020).




Figura 2. Modelo VS-ePL-KRLS

A estrutura do modelo evolutivo proposto é baseada em regras nebulosas do tipo Takagi-Sugeno-Kang (Takagi and Sugeno, 1985; Sugeno and Kang, 1988). A principal vantagem de utilização de sistemas nebulosos é sua propriedade de aproximador universal (Afrazi and Kreinovich, 2020), isto é, tem a capacidade de descrever um sistema não linear através da combinação de subsistemas lineares.

As regras nebulosas supracitadas tem configuração do tipo “SE <antecedente>, ENTÃO <consequente>”, conforme Equação 1, no qual o antecedente é expresso por uma variável linguística e o consequente é expresso por uma função matemática.

$$\mathcal{R}_i : \text{SE } x \text{ é } \mathcal{A}_i, \text{ ENTÃO } \hat{y}_i = f_i(x, \theta_i) \quad (1)$$

em que $\mathcal{R}_i$ é a i -ésima regra, $\mathcal{A}_i$ é o conjunto nebuloso do antecedente da i -ésima regra, $x = [x_1, \dots, x_m]^T \in \mathbb{R}^m$ é o vetor de entrada, $\theta_i = [\theta_{i1}, \dots, \theta_{in_i}]^T \in \mathbb{R}^{n_i}$ é o vetor dos parâmetros dos consequentes para cada n -ésimo elemento do dicionário da i -ésima regra e $\hat{y}_i : \mathbb{R}^m \times \mathbb{R}^{n_i} \rightarrow \mathbb{R}$ é a saída local da i -ésima regra.

Inicialmente, os índices de compatibilidade (ρ_i^k) e de alerta (a_i^k) são calculados através das Equações 2 e 3, respectivamente. A compatibilidade quantifica a conformidade entre os dados e as regras. O alerta avalia se uma regra nova deve ser adicionada ou se uma regra existente deve ser atualizada através da comparação com o parâmetro $\tau^k \in [0, 1]$. Se $|a_i^k| > \tau^k$, uma regra nova é adicionada com centro (v_R^{k+1}) representado pela Equação 4. Caso contrário, a regra existente mais compatível é atualizada com centro (v_i^{k+1}) representado pela Equação 5. Para cada instante k , $\tau^k = \beta^{k-1}$.

$$\rho_i^k = 1 - \frac{\|x^k - v_i^k\|}{m} \quad (2)$$

em que $\rho_i^k \in [0, 1]$ é o índice de compatibilidade da i -ésima regra no k -ésimo instante, $x^k \in \mathbb{R}^m$ é o vetor de entrada m -dimensional no k -ésimo instante e $v_i^k \in [0, 1]^m$ é o centro da i -ésima regra no k -ésimo instante. O algoritmo é inicializado com $v_1^1 = x^1$.

$$a_i^k = a_i^{k-1} + \beta^{k-1} (1 - \rho_i^k - a_i^{k-1}) \quad (3)$$

em que $a_i^k \in [0, 1]$ é o índice de alerta da i -ésima regra no k -ésimo instante e $\beta^k \in [0, 1]$ é o parâmetro que controla a taxa de mudança do alerta. O algoritmo é inicializado com $a_1^0 = 0$ e $\beta^0 = 0,18$.

$$v_R^{k+1} = x^k \quad (4)$$

$$v_i^{k+1} = v_i^k + \alpha (v_i^k)^{1-a_i^{k+1}} (x^k - v_i^k) \quad (5)$$

em que $\alpha \in [0, 1]$ é a taxa de aprendizado.

Finalmente, o índice de compatibilidade (ρ_{ij}^k) entre a i -ésima e j -ésima regras são calculados através da Equação 6. Ele qualifica a redundância entre os centros e avalia se uma regra existente deve ser removida através da

comparação com o parâmetro $\gamma^k \in [0, 1]$. Se $\rho_{ij}^k > \gamma^k$, a regra redundante é removida e seu centro (v_i^k) é mesclado com a regra mais compatível representado pela Equação 7. Para cada instante k , $\gamma^k = 1 - \beta^{k-1}$.

$$\rho_{ij}^k = 1 - \frac{1}{m} \sum_{l=1}^m |v_{il}^k - v_{jl}^k| \quad (6)$$

em que $\rho_{ij}^k \in [0, 1]$ é o índice de compatibilidade entre a i -ésima e j -ésima regras no k -ésimo instante para $i \neq j$.

$$v_i^k = \frac{v_i^k + v_j^k}{2} \quad (7)$$

A importância do parâmetro β é notória no modelo. Ele controla o índice de alerta (Equação 3), serve como valor limite para a adição de uma regra nova (Equação 4) ou atualização de uma regra existente (Equação 5) e seu complemento serve como valor limite para a exclusão de uma regra (Equação 7). Este modelo apresenta como novidade a atualização deste em função do erro através da técnica denominada *Variable Step-Size* proposta por Harris et al. (1986). Esta abordagem é representada pela Equação 8, em que os parâmetros $\bar{\gamma}$, α_{VS1} e α_{VS2} foram obtidos por heurística visando diminuir o RMSE.

$$\beta^{k+1} = \begin{cases} \frac{\beta^k}{\alpha_{VS1}}, & \text{se } |\bar{e}^k| > \bar{\gamma} \\ \beta^k \alpha_{VS2}, & \text{caso contrário} \end{cases} \quad (8)$$

A saída local ($\hat{y}_i$) de cada regra, que é uma função que associa os valores de entrada e os parâmetros dos consequentes, é representada pela Equação 9.

$$\hat{y}_i = \sum_{j=1}^{n_i} \theta_{ij}^{k-1} \kappa(d_{ij}^k, x^k) \quad (9)$$

$$\hat{y}_i = \sum_{j=1}^{n_i} \theta_{ij}^{k-1} \exp\left(-\frac{\|d_{ij}^k - x^k\|}{\sqrt{2}\nu_{ij}^k}\right)^2$$

em que θ_{ij}^{k-1} são os parâmetros dos consequentes da i -ésima e j -ésima regras no k -ésimo instante, $\kappa(\cdot)$ é a função gaussiana kernelizada, d_{ij}^k é o elemento do dicionário e ν_{ij}^k é o tamanho kernelizado referentes a i -ésima e j -ésima regras no k -ésimo instante, respectivamente.

Os parâmetros dos consequentes são estimados usando um método adaptativo não linear denominado *Kernel Recursive Least Square* (KRLS). Ele é uma extensão do método *Recursive Least Square* (RLS), que tem a vantagem de aumentar a dimensão espacial dos dados de entrada através da um função não linear (ϕ), gerando soluções mais simples. Esses valores são calculados determinando o vetor de pesos (ω) resultante da minimização da função de custo ($L(\omega)$). A otimização e sua solução são representadas pelas Equações 10 e 11, respectivamente.

$$\min_{\omega} L(\omega) = \sum_{j=1}^k |y^j - \omega^T \phi^j|^2 + \lambda \|\omega\|^2 \quad (10)$$

$$\begin{aligned} \omega^k &= [\lambda \mathbf{I} + \Phi^k (\Phi^k)^T]^{-1} \Phi^k \mathbf{Y}^k \\ \omega^k &= \Phi^k [\lambda \mathbf{I} + (\Phi^k)^T \Phi^k]^{-1} \mathbf{Y}^k \\ \omega^k &= \Phi^k \mathbf{Q}^k \mathbf{Y}^k \end{aligned} \quad (11)$$

em que $\lambda \in [10^{-5}, 10^{-2}]$ (Haykin et al., 2009) é o parâmetro de regularização para evitar instabilidades numéricas na matriz $\mathbf{Q}^k$ e sobreajuste do modelo aos dados, $\mathbf{I}$ é a matriz identidade, $\Phi = [\phi^1, \dots, \phi^k]$ e $\mathbf{Y} = [y^1, \dots, y^k]^T$.

A função kernelizada, representada pela Equação 12, tem a propriedade de reduzir a dimensão do produto interno e, consequentemente, possibilitar a solução da Equação 11 (Scholkopf and Smola, 2001).

$$\begin{aligned} \mathbf{K}^k &= (\Phi^k)^T \Phi^k \\ \mathbf{K}^k &= \begin{bmatrix} \kappa(x^1, x^1) & \dots & \kappa(x^1, x^k) \\ \vdots & \ddots & \vdots \\ \kappa(x^k, x^1) & \dots & \kappa(x^k, x^k) \end{bmatrix} \\ \mathbf{K}^k &= \begin{bmatrix} \mathbf{K}^{k-1} & g^k \\ (g^k)^T & 1 \end{bmatrix} \end{aligned} \quad (12)$$

em que $\mathbf{K}^k$ é a matriz kernelizada e $g^k = [\Phi^{k-1}]^T \phi^k = [\kappa(x^1, x^k), \dots, \kappa(x^{k-1}, x^k)]^T$.

O vetor de parâmetros dos consequentes é expresso pela Equação 13. A solução é representada pelas Equações 14 e 15 para uma regra nova e uma regra existente, respectivamente. Essa solução é obtida através do cálculo da matriz inversa de $\mathbf{Q}^k$, que devido a alta complexidade computacional é feita de maneira recursiva.

$$\theta^k = \mathbf{Q}^k \mathbf{Y}^k \quad (13)$$

$$\theta^k = [\lambda + \kappa(x^k, x^k)]^{-1} y^{k-1} \quad (14)$$

$$\theta^k = \begin{bmatrix} \theta^{k-1} - z^k [r^k]^{-1} \bar{e}^k \\ [r^k]^{-1} \bar{e}^k \end{bmatrix} \quad (15)$$

em que $z^k = \mathbf{Q}^{k-1} g^k$, $r^k = \lambda + [\phi^k]^T \phi^k - [z^k]^T g^k$ e $\bar{e}^k$ é o erro, ou seja, a diferença entre o valor real (y^k) e o valor previsto ($\hat{y}^k$).

A fim de diminuir a complexidade computacional e aumentar a habilidade de generalização, foi adotado uma estratégia de esparsificação. Essa simplificação é necessária, pois $\mathbf{K}^k$ e, consequentemente, $\mathbf{Q}^k$ tem suas dimensões quadruplicadas para cada novo dado de entrada. Para tal, é criado um dicionário local ($\mathcal{D}^k$) em cada regra e apenas a mais compatível tem seu dicionário atualizado, restringindo apenas as amostras mais relevantes para atualização da matriz kernelizada e do vetor de parâmetros.

Neste modelo, o critério de novidade (Richard et al., 2008) foi o mais adequado, pois ele representa compactamente o conhecimento em cada dicionário local e apresenta baixo custo computacional. Esta técnica consiste inicialmente em calcular a distância mínima (ψ) entre os dados de entrada e cada elemento do dicionário através da Equação 16. Em seguida, são calculados os erros considerando dois cenários: um com a nova amostra no dicionário local (ε) e outro sem a nova amostra no dicionário local (ϵ). Finalmente, é avaliado a coerência entre as amostras e todos os elementos do dicionário local. Se $\psi < \delta = 0,1 \nu_{ij}^k$, há coerência e a amostra não é adicionada ao dicionário local. Caso contrário, não há coerência e a amostra é adicionada ao dicionário local se $\varepsilon < \epsilon$.

$$\psi = \min_{(\forall d_{ij} \in \mathcal{D}_i^k)} \|x^k - d_{ij}^k\| \quad (16)$$

em que ψ é a mínima distância entre os dados de entrada e cada elemento do dicionário local.

O processo de escolha de um valor apropriado para o tamanho kernelizado é complexo, pois um valor muito grande pode resultar em todos os dados similares e um valor muito pequeno pode resultar em todos os dados distintos. Neste modelo foi adotado o algoritmo recursivo de Levenberg-Marquardt algorithm (Ngia et al., 1998). Ele é um método de otimização não linear intermediário entre Gradiente e Newton, porém com melhores propriedades convergentes. Este consiste na associação de cada tamanho (ν_{ij}^k) com um elemento do dicionário (d_{ij}^k) objetivando a minimização do erro local. As Equações 17 e 18 representam este valor para uma regra nova e uma regra existente, respectivamente.

$$\nu_{R1}^k = 0,5 \quad (17)$$

$$\nu_i^k = \nu_i^{k-1} + P_i^k \nabla_i^k \tilde{e}_i^k \quad (18)$$

em que $P_i^k = \left[P_i^{k-1} - \frac{P_i^{k-1} \nabla_i^k [\nabla_i^k]^T P_i^{k-1}}{1 + [\nabla_i^k]^T P_i^{k-1} \nabla_i^k} \right]$,

$$\nabla_i^k = \Lambda_i^k \begin{bmatrix} \theta_{i1}^{k-1} - \frac{\|x^k - d_{i1}^k\|^2}{(v_{i1}^{k-1})^3} k(x^k, d_{i1}^k) \\ \vdots \\ \theta_{in_1}^{k-1} - \frac{\|x^k - d_{in_1}^k\|^2}{(v_{in_1}^{k-1})^3} k(x^k, d_{in_1}^k) \end{bmatrix} \text{ e}$$

$\Lambda_i^k \in [0,1]$ é o grau de ativação normalizada da i -ésima regra nebulosa.

A saída global, ou seja, o valor previsto é a média ponderada das saídas locais, considerando as contribuições individuais de cada regra, resultando na natureza não-linear do modelo. Essa variável é representada pela Equação 19:

$$\hat{y} = \sum_{i=1}^R \hat{y}_i \Lambda_i \quad (19)$$

4. RESULTADOS EXPERIMENTAIS

O modelo nebuloso evolutivo participativo com passo de adaptação variável (VS-ePL-KRLS) foi aplicado para a previsão do preço médio mensal do óleo diesel S500 e S10 em nível nacional para curto prazo (1 mês a frente), médio prazo (6 meses a frente) e longo prazo (12 meses a frente). Em seguida, avaliou-se o desempenho do modelo proposto neste trabalho, comparando-o com os modelos evolutivos de melhores resultados existentes na literatura, ePL-KRLS (Vieira et al., 2018), SM-ePL-KRLS (Alves et al., 2020) e ESM-ePL-KRLS (Alves et al., 2020).

A base de dados é composta pelos valores do preço de revenda e do preço de distribuição, no período entre dezembro de 2012 e maio de 2020. Para os horizontes de previsão de curto, médio e longo prazo, os dados usados para treino foram 72 (81%), 66 (79%) e 60 (77%), respectivamente. As métricas utilizadas para a análise da acurácia foram a Raiz do Erro Quadrático Médio (RMSE), o Erro Médio Absoluto (MAE) e o Erro Não Dimensional (NDEI) e a análise do desempenho computacional foi medida através da média de 50 simulações da porcentagem de utilização da CPU em todo o sistema. Para os testes foi usado um computador Intel(R) Core(TM) Processador i3-7020U CPU @ 2,30GHz 2,30 GHz, 4,00 GB de memória RAM instalada e Sistema Operacional de 64 bits.

As Tabelas 2 e 3 descrevem os parâmetros utilizados nos modelos e as Tabelas 4 e 5 os resultados para o óleo diesel S500 e S10, respectivamente. As Figuras 3, 4, 5, 6, 7 e 8 ilustram os resultados.

Tabela 2. Parâmetros gerais

Parameters	Value
α	0,01
β^0	0,18
γ^0	0,18
τ^0	0,82
σ	0,05
λ	10^{-4}
v_0	0,50

Tabela 3. Parâmetros para atualização do β

Modelo	Combustível	Horizonte	$\bar{\gamma}$	α_{VS1}	α_{VS2}
SM-ePL-KRLS	S500	mensal	0,016	-	-
		semestral	0,029	-	-
		anual	0,021	-	-
	S10	mensal	0,014	-	-
		semestral	0,026	-	-
		anual	0,025	-	-
ESM-ePL-KRLS	S500	mensal	0,018	-	-
		semestral	0,029	-	-
		anual	0,006	-	-
	S10	mensal	0,005	-	-
		semestral	0,025	-	-
		anual	0,025	-	-
VS-ePL-KRLS	S500	mensal	0,006	0,90	0,78
		semestral	0,006	0,56	0,05
		anual	0,010	0,50	0,28
	S10	mensal	0,006	0,88	0,74
		semestral	0,003	0,79	0,26
		anual	0,009	0,78	0,57

Tabela 4. Óleo Diesel S500

Horizonte	Algoritmo	Regras	RMSE	MAE	NDEI	% CPU
mensal	ePL-KRLS	2	0,17704	0,12743	0,39268	16,24 ± 3,53
	SM-ePL-KRLS	1	0,09334	0,07207	0,20702	16,00 ± 4,32
	ESM-ePL-KRLS	1	0,10189	0,07537	0,22599	15,26 ± 2,98
	VS-ePL-KRLS	1	0,07000	0,06016	0,15525	15,74 ± 3,87
semestral	ePL-KRLS	2	0,18550	0,13028	0,43578	15,83 ± 3,92
	SM-ePL-KRLS	1	0,18680	0,11007	0,43883	13,53 ± 3,30
	ESM-ePL-KRLS	1	0,21313	0,13551	0,50069	15,15 ± 6,93
	VS-ePL-KRLS	1	0,11135	0,09091	0,26158	13,00 ± 3,72
anual	ePL-KRLS	2	0,22531	0,17290	0,57750	16,36 ± 3,29
	SM-ePL-KRLS	1	0,20330	0,13720	0,52108	13,21 ± 3,68
	ESM-ePL-KRLS	1	0,24976	0,18530	0,64014	13,57 ± 4,64
	VS-ePL-KRLS	1	0,11906	0,08942	0,30517	13,16 ± 3,32

Tabela 5. Óleo Diesel S10

Horizonte	Algoritmo	Regras	RMSE	MAE	NDEI	% CPU
mensal	ePL-KRLS	2	0,16747	0,11815	0,37785	16,21 ± 3,22
	SM-ePL-KRLS	1	0,08223	0,06373	0,18551	14,64 ± 4,76
	ESM-ePL-KRLS	1	0,09232	0,06737	0,20829	14,15 ± 5,23
	VS-ePL-KRLS	1	0,05953	0,05158	0,13430	13,56 ± 4,00
semestral	ePL-KRLS	2	0,18480	0,12947	0,44663	16,75 ± 5,07
	SM-ePL-KRLS	1	0,17603	0,10358	0,42542	13,54 ± 3,68
	ESM-ePL-KRLS	1	0,21841	0,13442	0,52786	14,83 ± 5,57
	VS-ePL-KRLS	1	0,10869	0,08366	0,26269	13,52 ± 3,39
anual	ePL-KRLS	2	0,21280	0,14832	0,57059	17,21 ± 4,88
	SM-ePL-KRLS	1	0,19386	0,12372	0,51981	13,96 ± 4,63
	ESM-ePL-KRLS	1	0,22071	0,15056	0,59181	13,23 ± 3,61
	VS-ePL-KRLS	1	0,12490	0,10133	0,33491	14,05 ± 5,45




Figura 3. Previsão do S500 para horizonte mensal




Figura 6. Previsão do S10 para horizonte mensal




Figura 4. Previsão do S500 para horizonte semestral




Figura 7. Previsão do S10 para horizonte semestral




Figura 5. Previsão do S500 para horizonte anual




Figura 8. Previsão do S10 para horizonte anual

5. CONCLUSÕES

Neste artigo um novo modelo é sugerido para lidar com o problema da previsão de preços de combustíveis. Ele é aplicado aos preços mensais do óleo diesel S500 e S10 no contexto do Brasil para os horizontes mensal, semestral e anual.

A avaliação do *Variable Step-Size evolving Participatory Learning with Kernel Recursive Least Square* foi medida em termos dos erros, número de regras finais e complexidade computacional. O modelo apresentou os melhores resultados através do processo de aprendizado contínuo e adaptável aos novos dados que a estrutura do modelo propicia.

Por fim, o VS-ePL-KRLS apresentou-se como uma excelente ferramenta de apoio à decisão no planejamento logístico operacional, tático e estratégico. Como exemplo, o modelo pode ser usado na otimização da entrega de determinada carga, definindo melhores datas e locais para abastecimento, visando a minimização dos custos da entrega e, consequentemente, a maximização do lucro do operador logístico.

AGRADECIMENTOS

Os autores agradecem à Pontifícia Universidade Católica do Rio de Janeiro (PUC-Rio) e à Universidade Federal de Juiz de Fora (UFJF) pelo apoio técnico durante este trabalho. Os autores também agradecem o apoio financeiro do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) [433389/2018-4 e 307403/2019-0], Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) [APQ-02922-18], Fundação Carlos Chagas Filho de Amparo à Pesquisa do Estado do Rio de Janeiro (FAPERJ) [202.673/2018 e 211.086/2019] e Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) [001].

REFERÊNCIAS

- Afravi, M. and Kreinovich, V. (2020). Fuzzy systems are universal approximators for random dependencies: A simplified proof. In *Decision Making under Constraints*, 1–5. Springer.
- Alves, K.S.T.R., Hell, M., Oliveira, F.L.C., and de Aguiar, E.P. (2020). An enhanced set-membership evolving participatory learning with kernel recursive least squares applied to thermal modeling of power transformers. *Electric Power Systems Research*, 184, 106334.
- Angelov, P.P. and Filev, D.P. (2004). An approach to online identification of takagi-sugeno fuzzy models. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 34(1), 484–498.
- ANP (2020). Levantamento de preços e de margens de comercialização de combustíveis. <http://www.anp.gov.br/precos-e-defesa-da-concorrenzia/precos/levantamento-de-precos/>. Acessado: 20/06/2020.
- Chiu, S.L. (1994). Fuzzy model identification based on cluster estimation. *Journal of Intelligent & fuzzy systems*, 2(3), 267–278.
- de Aguiar, E.P., Fernando, M.d.A., Vellasco, M.M., and Ribeiro, M.V. (2017). Set-membership type-1 fuzzy logic system applied to fault classification in a switch machine. *IEEE Transactions on Intelligent Transportation Systems*, 18(10), 2703–2712.
- Engel, Y., Mannor, S., and Meir, R. (2004). The kernel recursive least-squares algorithm. *IEEE Transactions on signal processing*, 52(8), 2275–2285.
- Evans, J.B., Xue, P., and Liu, B. (1993). Analysis and implementation of variable step size adaptive algorithms. *IEEE Transactions on Signal Processing*, 41(8), 2517–2535.
- Fleury, P.F., Wanke, P., and Figueiredo, K.F. (2000). *Logística empresarial: a perspectiva brasileira*. Editora Atlas SA.
- Harris, R., Chabries, D., and Bishop, F. (1986). A variable step (vs) adaptive filter algorithm. *IEEE transactions on acoustics, speech, and signal processing*, 34(2), 309–316.
- Haykin, S.S. et al. (2009). Neural networks and learning machines/simon haykin.
- Kasabov, N. and Filev, D. (2006). Evolving intelligent systems: methods, learning, & applications. In *2006 International symposium on evolving fuzzy systems*, 8–18. IEEE.
- Lima, E., Hell, M., Ballini, R., and Gomide, F. (2010). Evolving fuzzy modeling using participatory learning. *Evolving intelligent systems: methodology and applications*, 67–86.
- Ngia, L.S., Sjöberg, J., and Viberg, M. (1998). Adaptive neural nets filter using a recursive levenberg-marquardt search direction. In *Conference Record of Thirty-Second Asilomar Conference on Signals, Systems and Computers (Cat. No. 98CH36284)*, volume 1, 697–701. IEEE.
- Petrobrás (2020). Diesel - composição de preços ao consumidor. <https://petrobras.com.br/pt/produtos-e-servicos/composicao-de-precos-de-venda-ao-consumidor/diesel/>. Acessado: 20/06/2020.
- Richard, C., Bermudez, J.C.M., and Honeine, P. (2008). Online prediction of time series data with kernels. *IEEE Transactions on Signal Processing*, 57(3), 1058–1067.
- Scholkopf, B. and Smola, A.J. (2001). *Learning with kernels: support vector machines, regularization, optimization, and beyond*. MIT press.
- Sugeno, M. and Kang, G. (1988). Structure identification of fuzzy model. *Fuzzy sets and systems*, 28(1), 15–33.
- Takagi, T. and Sugeno, M. (1985). Fuzzy identification of systems and its applications to modeling and control. *IEEE transactions on systems, man, and cybernetics*, (1), 116–132.
- Vieira, R., Gomide, F., and Ballini, R. (2018). Kernel evolving participatory fuzzy modeling for time series forecasting. In *2018 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*, 1–9. IEEE.
- Vilardaga, V. (2007). Choque de gestão no transporte rodoviário. *Anuário de gestão de frotas, treinamento e pós-vendas*, 4, 6–10.
- Yager, R.R. (2004). Participatory learning: A paradigm for more human like learning. In *2004 IEEE International Conference on Fuzzy Systems (IEEE Cat. No. 04CH37542)*, volume 1, 79–84. IEEE.
- Young, P.C. (2012). *Recursive estimation and time-series analysis: an introduction*. Springer Science & Business Media.