



ARTIGO DE PESQUISA/RESEARCH PAPER


Uma Abordagem de Reinicialização Reativa One-Shot para Previsão de Séries Temporais Financeiras sob Mudança de Conceito

A Reactive One-Shot Reset Approach for Financial Time Series Forecasting under Concept Drift

Gabriel F. Sarmiento   [Universidade Federal de Alagoas (UFAL) | gabriel.sarmiento@arapiraca.ufal.br]

Liedson D. O. Leite  [Universidade Federal de Alagoas (UFAL) | liedson.leite@arapiraca.ufal.br]

Gustavo H. F. de M. Oliveira  [Universidade Federal de Alagoas (UFAL) | gustavo.oliveira@penedo.ufal.br]

 *Sistemas de Informação, Universidade Federal de Alagoas (UFAL), Unidade Educacional de Penedo, Rua Floriano Rosa, s/n, Dom Constantino, Penedo, AL, 57200-000, Brasil.*

Resumo. A previsão de séries temporais é importante para a tomada de decisões no mercado financeiro, mas torna-se desafiadora devido à volatilidade e às mudanças na distribuição dos dados ao longo do tempo — a chamada mudança de conceito (concept drift). Abordagens voltadas a lidar com essa mudança, especialmente as ativas, frequentemente sofrem perda de desempenho por dependerem de janelas de dados grandes para retreinamento. Com base nisso, este trabalho propõe o LOR (Local One-Shot Reset), que utiliza uma única observação para adaptação à mudança. Experimentos com sete séries financeiras reais mostraram que o LOR supera ou se iguala aos métodos tradicionais da literatura que visam tratar o desvio de conceito.

Abstract. Time series forecasting is important for decision-making in the financial market, but it becomes challenging due to volatility and changes in data distribution over time — the so-called concept drift. Approaches designed to handle this drift, especially active ones, often experience performance drops as they rely on large data windows for retraining. To address this, this work proposes LOR (Local One-Shot Reset), a local reset strategy that uses a single observation to adapt to change. Experiments with seven real-world financial time series show that LOR outperforms or performs comparably to traditional state-of-the-art methods designed to handle concept drift.

Palavras-chave: Previsão de Séries Temporais, Mercado Financeiro, Mudança de Conceito, Concept Drift, LOR

Keywords: Time Series Forecasting, Financial Market, Concept Drift, LOR, Adaptive Models

Recebido/Received: 11 June 2026 • **Aceito/Accepted:** 12 June 2026 • **Publicado/Published:** 10 July 2026

1 Introdução

A previsão de séries temporais, como cotações de ações e taxas de câmbio, é fundamental para os mercados financeiros, pois permite a gestão de riscos e a tomada de decisões assertivas de investimento. No entanto, essa é uma tarefa bastante desafiadora devido à volatilidade característica desses dados, que apresentam fortes oscilações Cavalcante *et al.* [2016a].

Comumente, as mudanças que ocorrem nos índices financeiros são causadas por eventos inesperados e fatores externos, como instabilidades políticas, variações econômicas ou o comportamento dos investidores Cavalcante *et al.* [2016b]. Esse tipo de alteração nos dados é conhecido na literatura como mudança de conceito (do inglês: *concept drift*) e ocorre quando a relação estatística entre os dados de entrada do modelo e o alvo a ser predito se modifica ao longo do tempo Lima *et al.* [2022].

Esse desafio ressalta a necessidade de investigação e desenvolvimento de modelos preditivos que não apenas apresentem bom desempenho em dados complexos, mas também mantenham consistência diante das mudanças inerentes ao mercado Zheng *et al.* [2023]. Na literatura, uma das formas mais comuns de lidar com a mudança de conceito é por meio de abordagens ativas, que detectam quando a mudança ocorre

e, então, retreinam completamente o modelo com dados do novo conceito Gama *et al.* [2014].

O retreino é uma estratégia eficiente, pois permite capturar as novas tendências dos dados. No entanto, estratégias de retreinamento baseadas em janelas grandes podem incorporar observações desatualizadas Cai *et al.* [2023], o que pode atrasar a adaptação a novos conceitos e aumentar o erro de predição, especialmente logo após a ocorrência de uma mudança de conceito Zhao and Shen [2025].

Motivado por essas limitações, este trabalho propõe o LOR (*Local One-Shot Reset*), uma estratégia reativa de adaptação projetada para séries financeiras. Neste trabalho, partimos da hipótese de que, em cenários com mudanças abruptas de conceito, a utilização de informações altamente recentes pode ser mais eficaz do que o uso de janelas históricas extensas. Em particular, argumenta-se que o uso de uma única observação recente pode reduzir a influência de conceitos obsoletos, favorecendo uma adaptação mais rápida do modelo ao novo padrão dos dados.

Nesse contexto, as principais contribuições deste trabalho são: (i) a proposição de um mecanismo de adaptação reativa baseado em reinicialização local com mínima dependência de dados históricos; (ii) a investigação empírica do impacto da quantidade de dados utilizados na adaptação

sob mudança de conceito; e (iii) uma avaliação experimental abrangente em séries financeiras reais, comparando o método proposto com abordagens ativas e passivas da literatura.

Para compreender como essas contribuições serão alcançadas, o artigo foi estruturado da seguinte forma: a Seção 2 apresenta os fundamentos sobre a mudança de conceito e as principais formas de adaptação a esse fenômeno. A Seção 3 descreve o LOR. A Seção 4 detalha os experimentos, e a Seção 5 apresenta os resultados. Por fim, a Seção 6 apresenta as principais conclusões do trabalho.

2 Fundamentação Teórica

2.1 Mudança de Conceito

Em séries temporais, as mudanças nos dados podem se manifestar de diferentes formas, incluindo variações pontuais e alterações estruturais persistentes. As variações pontuais, conhecidas como *outliers*, correspondem a observações isoladas que se desviam do padrão esperado, mas não alteram a estrutura estatística subjacente da série. Em contraste, a mudança de conceito (*concept drift*) caracteriza uma alteração estrutural e contínua nos dados, afetando os padrões aprendidos pelos modelos Gama et al. [2014].

A mudança de conceito pode ser classificada em dois tipos principais: real e virtual. A mudança real ocorre quando há alteração na distribuição condicional da variável de saída dadas as entradas ($P(y|X)$), modificando diretamente a função de mapeamento do modelo. Por outro lado, a mudança virtual se manifesta por alterações na distribuição das variáveis de entrada ($P(X)$), sem necessariamente afetar a relação $P(y|X)$ Gama et al. [2014]. Essas formas de mudança podem ocorrer de maneira separada ou simultânea e ambas causam degradação no desempenho dos modelos preditivos.

2.2 Adaptação à Mudança de Conceito

Em ambientes não estacionários, para que modelos preditivos mantenham sua eficácia, é necessário incorporar mecanismos de adaptação à mudança de conceito Gama et al. [2014]; Lu et al. [2018]; Iwashita and Papa [2019]. As estratégias de adaptação mais comuns são geralmente classificadas em abordagens passivas e ativas.

Métodos passivos atualizam o modelo continuamente ou em intervalos regulares, independentemente da detecção explícita de mudanças. Essas abordagens incluem algoritmos de aprendizado incremental/online, janelas deslizantes e *ensembles* dinâmicos que buscam atualizar periodicamente seus modelos Lu et al. [2018].

Por outro lado, métodos ativos seguem o paradigma “detectar e adaptar”. Nesse paradigma, mecanismos de monitoramento identificam mudanças no fluxo de dados em tempo real e acionam processos de adaptação somente quando necessário Cavalcante [2017]. Uma vez detectada a mudança, diferentes estratégias podem ser empregadas, como retreinamento com dados recentes, ajustes localizados ou substituição do modelo preditivo Žliobaitė et al. [2016].

Apesar de suas vantagens, tanto abordagens passivas quanto ativas apresentam limitações. Métodos passivos podem responder lentamente a mudanças abruptas, enquanto métodos ativos dependem da precisão dos detectores de mudança Cavalcante [2017]. Por essa razão, pesquisas recentes

têm investigado estratégias híbridas ou mecanismos de adaptação mais eficientes Oliveira et al. [2021].

3 Método Proposto

O método proposto, denominado **LOR (Local One-Shot Reset)**, foi desenvolvido para mitigar os impactos das mudanças de conceito (*concept drift*) em séries temporais financeiras. O LOR fundamenta-se em uma estratégia de adaptação em dois níveis — reinicializações locais e globais — integrada a um mecanismo de detecção de mudanças. O fluxo geral do algoritmo é detalhado na Figura 1.

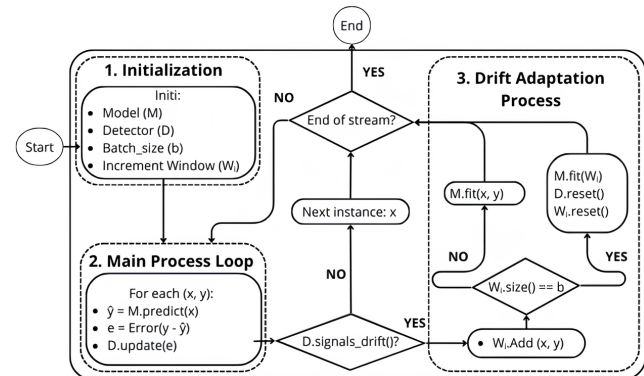


Figura 1. Fluxo de execução do algoritmo LOR.

O processo inicia-se com a etapa de **Initialization**, realizada a partir de um *batch* inicial de dados históricos. Nessa fase, definem-se: (i) o modelo preditivo inicial M ; (ii) o detector de mudanças D ; e (iii) os parâmetros operacionais, como o tamanho do *batch* de adaptação b e a janela incremental W_i .

No **Main Process Loop**, cada nova observação (x, y) é processada sequencialmente. O modelo M recebe a entrada e emite uma predição \hat{y} . Então, quando o valor real y é recebido o erro absoluto $e = |y - \hat{y}|$ é calculado e fornecido ao detector D . Para evitar que retreinos sejam desencadeados por *outliers*, neste trabalho, adotamos o detector Kolmogorov–Smirnov Windowing (KSWIN) devido à sua robustez a ruídos.

Ressalta-se que o foco deste trabalho não está na proposição de novos mecanismos de detecção de mudança, mas sim na investigação de estratégias de adaptação condicionadas a sinais de drift. Dessa forma, o detector atua como um gatilho para o processo de adaptação, sendo o LOR independente da escolha específica do detector.

Na presença de mudança, inicia-se o **Drift Adaptation Process**. Enquanto a janela W_i não é totalmente preenchida, o sistema executa um **reset local** do modelo. Chamamos de **reset local** o processo de treinar (*fit*) um modelo do zero utilizando estritamente a observação atual (x_t, y_t) que desencadeou o alerta. Diferentemente de abordagens baseadas em janelas, essa estratégia elimina completamente a influência de dados históricos potencialmente obsoletos.

Por fim, quando W_i atinge o limiar b , ocorre a **reinicialização global**. Neste estágio, o modelo é retreinado com o conjunto consolidado de b observações, permitindo capturar padrões mais estáveis da nova distribuição estatística antes de retornar ao fluxo de processamento padrão.

Tabela 1. Detalhamento das séries temporais usadas nos experimentos.

Séries	Descrição	Período	Tamanho
AAPL	Apple Inc.	12/12/1980 à 05/05/2025	11192
B3SA3.SA	B3 S.A. - Brasil, Bolsa, Balcão	26/10/2007 à 05/05/2025	4346
IXIC	NASDAQ Composite	05/02/1971 à 05/05/2025	13680
DJI	Dow Jones Industrial Average	02/01/1992 à 05/05/2025	8398
GSPC	S&P 500	30/12/1927 à 05/05/2025	24454
BVSP	IBOVESPA	27/04/1993 à 05/05/2025	7930
USDBRLX	Taxa de câmbio USD/BRL	01/12/2003 à 05/05/2025	5145

4 Experimentos

4.1 Séries Temporais

Avaliamos os algoritmos em sete séries financeiras reais obtidas via API do Yahoo Finance, apresentadas na Tabela 1. A seleção considerou dois critérios principais: relevância histórica e horizonte temporal. A relevância se deve ao fato de serem ativos amplamente acompanhados e utilizados como referência de mercado no Brasil e nos EUA. Já o horizonte temporal reflete que períodos mais longos apresentam maior diversidade de estruturas estatísticas e variações ao longo do tempo.

4.2 Pré-processamento

As séries foram padronizadas por meio de normalização incremental, utilizando o método *Z-score* (StandardScaler da biblioteca *River* Montiel et al. [2021]). Nesse processo, a cada novo ponto da série, a média e o desvio padrão são atualizados de forma online, sem necessidade de armazenamento histórico, o que torna a abordagem adequada ao cenário de fluxo de dados.

Sobre as séries já padronizadas, formulou-se o problema de regressão por meio de uma janela deslizante de 10 *lags* como entrada para todos os algoritmos, de modo que o vetor de entradas (\mathbf{x}_t) para o alvo y_t no tempo t é definido por $\mathbf{x}_t = [y_{t-10}, \dots, y_{t-1}]$. Embora a escolha do número de lags possa influenciar o desempenho preditivo, optou-se por fixar esse valor para todos os métodos a fim de isolar o impacto das estratégias de adaptação à mudança de conceito, que constitui o foco principal deste trabalho.

4.3 Protocolo de Avaliação e Métricas

Adotou-se o protocolo **prequential** (*test-then-train*) Hidalgo et al. [2019], que simula ambientes produtivos: a cada nova instância, o modelo emite uma predição e, na sequência, utiliza o alvo real para atualizar seus parâmetros.

A métrica principal foi o erro absoluto médio acumulado (MAE), definido como $MAE = \frac{1}{T} \sum_{t=1}^T |y_t - \hat{y}_t|$, sendo y_t o valor real, \hat{y}_t a predição e T o total de instâncias. Como os dados foram normalizados via *Z-score*, os valores de MAE situam-se próximos do intervalo [0, 1], facilitando a interpretação.

Embora outras métricas, como o RMSE, também possam ser consideradas, optou-se pelo MAE devido à sua robustez a *outliers* e à sua adequação para capturar mudanças absolutas, especialmente relevantes em ambientes financeiros voláteis. Além disso, como todos os métodos são avaliados sob as

mesmas condições, o MAE fornece uma base consistente para comparação.

Para algoritmos estocásticos, reportou-se a média e o desvio padrão do MAE em 30 execuções. A validação estatística utilizou a biblioteca *autorank* Herbold [2020], aplicando o teste de Friedman e o *post-hoc* de Nemenyi sobre as médias, com significância $\alpha = 0,05$.

4.4 Configuração Experimental

O desempenho do **LOR** foi investigado em três experimentos: (i) avaliação do número de observações utilizadas no retreino; (ii) avaliação do preditor e da estratégia de adaptação à mudança; e (iii) comparação com abordagens da literatura.

No primeiro experimento, comparou-se o método proposto em duas configurações. A primeira realiza o reset com uma única observação, denominada **LOR Unique**. A segunda utiliza uma janela incremental completa, na qual, a cada nova observação, a mais antiga é removida, denominada **LOR Incremental**. Além disso, variou-se a quantidade de *lags* utilizados na predição, considerando os valores em [3, 5, 10].

No segundo experimento, o **LOR** foi avaliado com diferentes preditores, especificamente Regressão Linear (LR) e Random Forest (RF), bem como com e sem o uso do reset local.

No terceiro experimento, o **LOR** foi comparado com métodos ativos (LR com **KSWIN**, **HDDMa** ou **ADWIN**), com um método ativo baseado em **ARIMA** (ARIMA com **KSWIN**) e com métodos passivos (**LinearRegressionOnline**, **HoeffdingTreeRegressor** e **OS-ELM** Huang et al. [2005]).

Os hiperparâmetros de todas as abordagens foram ajustados por meio de Otimização Bayesiana nos 20% iniciais de cada série (conjunto de validação). O espaço de busca e os intervalos de configuração de cada algoritmo estão detalhados na Tabela 2. Para os métodos que utilizam retreinamento em lote, foram avaliados diferentes tamanhos de janela no intervalo [50, 100, 200, 300]. O valor 300 foi selecionado por apresentar desempenho consistentemente competitivo entre os métodos, garantindo uma comparação mais estável e justa.

5 Resultados

5.1 Análise do Número de Observações Usadas no Retreino

O objetivo do primeiro experimento é analisar como a quantidade de dados utilizada na adaptação à mudança de conceito impacta o desempenho do **LOR**. Para isso, comparamos, na

Tabela 2. Espaço de busca e valores finais dos hiperparâmetros

Modelo	Hiperparâmetro	Intervalo / Valores	Valor Selecionado
LinearReg.	fit_interc., copy_X, pos.	{True, False}	True, False, False
RF	n_est, depth, split, leaf	[50, 200], [5, 30], [2, 10], [1, 4]	92, 5, 5, 2
OS-ELM	L, activation	[10, 500], {sigm, sine, tanh, rbf}	20, sigm
	b_size (N_0)	[100, 1000]	100
BayesianLR	alpha (α), beta (β)	$[10^{-6}, 10^1]$, $[10^{-6}, 10^1]$	1.0, 1.0
HoeffdingT	grace_per., leaf_pred.	[10, 500], {mean, adaptive}	100, adap.
	delta (δ), mod_decay	$[10^{-7}, 10^{-1}]$, [0.1, 0.95]	10^{-7} , 0.9

* Escala log-uniforme. Nomes abreviados para fins de formatação.

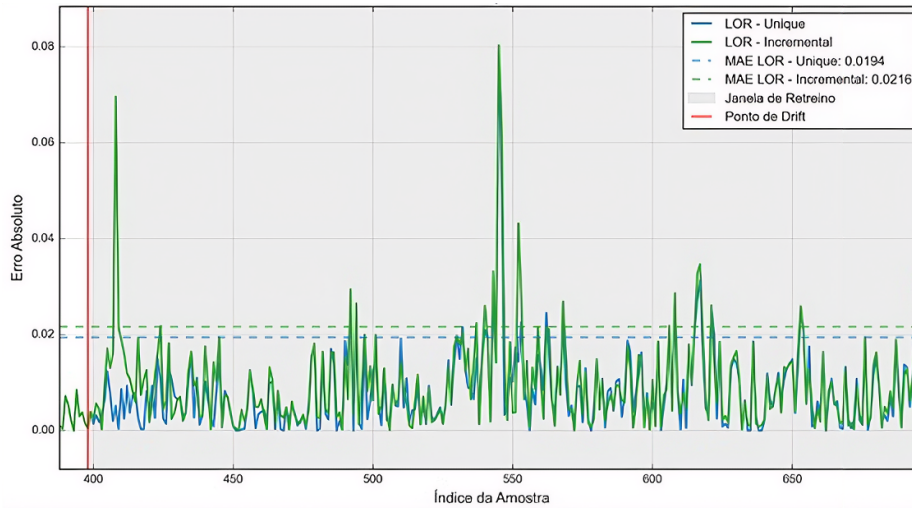


Figura 2. Comparação do método LOR resetando usando uma observação (*unique*) versus usando a janela incremental (*incremental*) para a série BVSP.

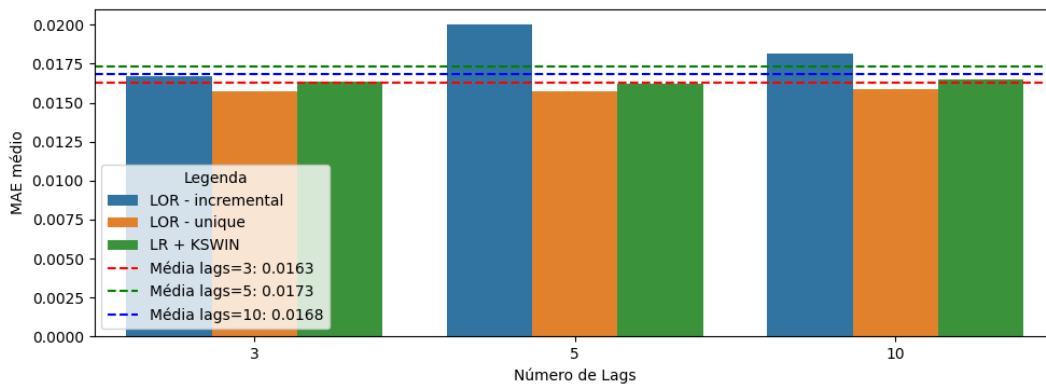


Figura 3. Comparação do método LOR (*unique*), LOR (*incremental*) e LR+KSWIN na série BVSP.

Figura 2, duas estratégias: o reset local com apenas uma observação e o reset utilizando toda a janela incremental a cada nova instância.

Observa-se que o uso de toda a janela incremental (linha verde) resulta em maior degradação do desempenho, evidenciada por picos elevados na série de erro. Em contraste, ao utilizar apenas uma observação (linha azul), o erro apresenta menor variabilidade, corroborando a hipótese de que o acúmulo de dados históricos pode incorporar informações de um conceito obsoleto e prejudicar a adaptação ao novo padrão.

Complementarmente, investigamos, na Figura 3, o impacto da quantidade de *lags* no retreinamento. Nota-se que o aumento no número de *lags* tende a degradar o desempenho preditivo. Esse comportamento sugere que, em cenários com mudanças abruptas, a inclusão de dados muitos histó-

ricos pode introduzir viés associado a conceitos anteriores, prejudicando a capacidade de adaptação imediata do modelo.

5.2 Análise do Preditor e do Mecanismo de Adaptação

O objetivo do segundo experimento é analisar o impacto do (i) preditor e do (ii) mecanismo de adaptação no desempenho do LOR. Para isso, tomaremos como base os resultados apresentados na Figura 5 para o desempenho médio em todas as séries.

Observa-se que quando comparado o RF com o LR, os resultados indicam que, no contexto experimental avaliado, modelos mais simples são mais eficazes na adaptação a padrões em rápida mudança. Isso pode ser atribuído à menor variância e à maior rapidez de atualização desses modelos, ca-

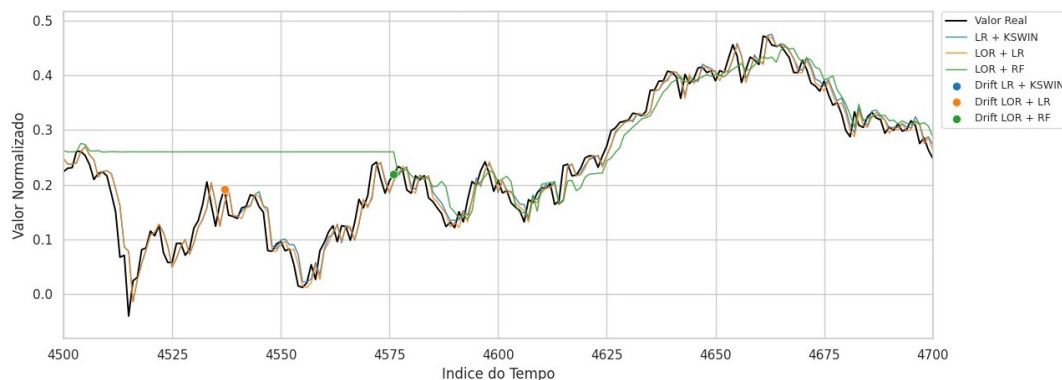


Figura 4. Previsão dos métodos LOR + LR, LOR + RF e LR + KSWIN na série BVSP.

Tabela 3. Resultados dos modelos para o MAE

Séries	Bayesian LR	Hoeffding T	LR+ ADWIN	LR+ HDDM_A	LR+ KSWIN	OS-ELM	ARIMA+ KSWIN	LOR
AAPL	0.00797	0.08325	0.008157	0.010096	0.006900	0.006925	0.006934	0.006560
B3SA3.SA	0.02947	0.03859	0.030514	0.030429	0.034437	0.035123	0.034703	0.030192
BVSP	0.01754	0.02402	0.019567	0.020428	0.016491	0.016388	0.016448	0.015884
DJI	0.01357	0.01712	0.020260	0.041150	0.013411	0.013529	0.013621	0.012131
GSPC	0.00566	0.12080	0.006533	0.004958	0.005663	0.005683	0.005655	0.005113
IXIC	0.00874	0.05142	0.010195	0.008503	0.008171	0.008235	0.008247	0.007570
USDBRLX	0.01984	0.02636	0.019719	0.020380	0.021868	0.022429	0.022377	0.019662

racterísticas vantajosas em cenários com mudanças frequentes de conceito.

5.3 Comparação entre Abordagens que lidam com Mudança de Conceito

O terceiro experimento deste trabalho visa identificar o quão distante o método proposto **LOR** está, em termos de desempenho, em relação às abordagens da literatura. Para isso, apresentamos na Tabela 3 o MAE das abordagens comparadas.

O **LOR**, em relação a média, demonstrou desempenho consistente em todas as séries, com exceção apenas da série B3SA3.SA. Para validar estatisticamente esses resultados, apresenta-se, na Figura 6, o ranking de Friedman em conjunto com o post-hoc de Nemenyi, ilustrado pela distância crítica (CD).

Embora o LOR tenha alcançado a melhor posição média no ranking, diferenças estatisticamente significativas foram observadas apenas em comparação com os métodos **HoeffdingTree** e **OS-ELM**. Isso indica que, apesar de competitivo, o desempenho do **LOR** não é universalmente superior, sendo suas vantagens mais evidentes em cenários específicos, especialmente em cenários que exigem rápida adaptação.

Em relação aos resultados das abordagens demonstradas na Figura 6, pode-se perceber que, em sua maioria, as abordagens ativas de detecção de mudança de conceito foram superiores às abordagens passivas com aprendizado online, com exceção do **BayesianLinearRegression**.

As abordagens de aprendizado incremental são eficientes em dados nos quais as mudanças ocorrem de maneira lenta; caso contrário, sua adaptação tende a se degradar. Por fim, as abordagens passivas, por reiniciarem completamente o aprendizado, mostraram-se mais consistentes diante da mudança de conceito, o que indica que séries financeiras tendem a apresentar, com maior frequência, mudanças bruscas.

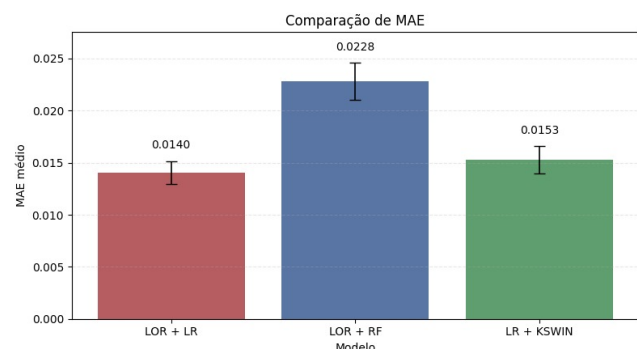


Figura 5. Desempenho médio para todas as séries considerando os métodos LOR + LR ou RF e o LR + KSWIN

Quando ao mecanismo de adaptação, ao comparar o **LR + KSWIN** — equivalente ao **LOR** sem reset local — com sua versão com reset (**LOR + LR**), observa-se que o reset local gera melhorias discretas. Contudo, ao analisar as séries individualmente (Tabela 3), esses ganhos tornam-se mais evidentes em casos como IXIC, USDBRLX e BVSP.

Por fim, a Figura 4 apresenta uma análise visual dos desempenhos desses algoritmos. Observa-se que, em determinados trechos, o **LOR + RF** não captura adequadamente os padrões da série, o que indica uma baixa generalização do RandomForest. Em contraste, o **LOR + LR** demonstra maior aderência aos dados quando comparado ao **LR + KSWIN**, o que indica que o reset local acelera a adaptação a mudança de conceito. Por outro lado, o uso de uma única observação pode limitar a capacidade de generalização do modelo em cenários com mudanças graduais, nos quais a incorporação de múltiplas observações recentes pode ser benéfica.




Figura 6. Ranking de Friedman com pós-teste de Nemenyi.

6 Conclusão

Este trabalho investigou o uso de quantidades mínimas de dados na adaptação a mudanças de conceito em séries temporais financeiras, propondo o método LOR (Local One-Shot Reset). Os resultados indicam que a abordagem é competitiva em relação à literatura, alcançando a melhor posição média, embora com diferenças estatísticas pouco expressivas.

Além disso, as evidências sugerem que, em cenários com mudanças abruptas, o uso de informações altamente recentes — inclusive de uma única observação — pode favorecer uma adaptação mais rápida, ao reduzir a influência de dados obsoletos. Nesse contexto, modelos mais simples, como a Regressão Linear, apresentaram melhor desempenho, possivelmente devido à sua maior capacidade de atualização.

Por outro lado, os ganhos não são uniformes em todos os cenários, indicando a existência de um trade-off entre velocidade de adaptação e capacidade de generalização. Como trabalho futuro, pretende-se investigar estratégias que ajustem dinamicamente a quantidade de dados utilizada no retreinamento, bem como avaliar o método em outros contextos e configurações.

Declarações complementares

Financiamento

Este trabalho foi desenvolvido no âmbito do Programa Institucional de Bolsas de Iniciação Científica (PIBIC), com bolsa financiada pela Universidade Federal de Alagoas (UFAL).

Contribuições dos autores

GS e LL contribuíram para a concepção do modelo, implementação e condução dos experimentos. GO supervisionou a pesquisa. GS redigiu o manuscrito. Todos os autores leram e aprovaram o texto final.

Conflitos de interesse

Os autores declaram que não têm nenhum conflito de interesses.

Disponibilidade de dados e materiais

Os códigos desenvolvidos e os conjuntos de dados utilizados neste trabalho serão disponibilizados mediante solicitação aos autores.

Referências

Cai, Z., Jiang, R., Yang, X., Wang, Z., Guo, D., Kobayashi, H. H., Song, X., and Shibasaki, R. (2023). MemDA: Forecasting urban time series with memory-based drift adaptation. In *Proceedings of the 32nd ACM International Conference on Information and Knowledge Management*, pages 193–202. ACM. DOI: 10.1145/3583780.3614962.

Cavalcante, R. C. (2017). *An adaptive learning system for time series forecasting in the presence of concept drift*. PhD thesis, Universidade Federal de Pernambuco.

Cavalcante, R. C., Brasileiro, R. C., Souza, V. L., Nobrega, J. P., and Oliveira, A. L. (2016a). Computational intelligence and financial markets: A survey and future directions. *Expert Systems with Applications*, 55:194–211. DOI: 10.1016/j.eswa.2016.02.006.

Cavalcante, R. C., Minku, L. L., and Oliveira, A. L. I. (2016b). FEDD: Feature extraction for explicit concept drift detection in time series. In *2016 International Joint Conference on Neural Networks (IJCNN)*, pages 740–747. DOI: 10.1109/IJCNN.2016.7727274.

Gama, J. a., Žliobaitė, I., Bifet, A., Pechenizkiy, M., and Bouchachia, A. (2014). A survey on concept drift adaptation. *ACM Computing Surveys*, 46(4):1–37. DOI: 10.1145/2523813.

Herbold, S. (2020). Autorank: A python package for automated ranking of classifiers. *Journal of Open Source Software*, 5(48):2173. DOI: 10.21105/joss.02173.

Hidalgo, J. I. G., Maciel, B. I., and Barros, R. S. (2019). Experimenting with prequential variations for data stream learning evaluation. *Computational Intelligence*, 35(4):670–692. DOI: 10.1111/coin.12208.

Huang, G.-B., Liang, N.-Y., Rong, H.-J., Saratchandran, P., and Sundararajan, N. (2005). On-line sequential extreme learning machine. *Computational Intelligence*, 20:232–237. Presented at the IASTED International Conference on Computational Intelligence (CI 2005).

Iwashita, A. S. and Papa, J. a. P. (2019). An overview on concept drift learning. *IEEE Access*, 7:1532–1547. DOI: 10.1109/ACCESS.2018.2886026.

Lima, M., Neto, M., Silva Filho, T., and Fagundes, R. A. d. A. (2022). Learning under concept drift for regression—a systematic literature review. *IEEE Access*, 10:45410–45429. DOI: 10.1109/ACCESS.2022.3169785.

Lu, J., Liu, A., Dong, F., Gu, F., Gama, J., and Zhang, G. (2018). Learning under concept drift: A review. *IEEE Transactions on Knowledge and Data Engineering*, 31(12):2346–2363. DOI: 10.1109/TKDE.2018.2876857.

Montiel, J., Halford, M., Mastelini, S. M., Bolmier, G., Sourty, R., Vaysse, R., Zouitine, A., Gomes, H. M., Read, J., Abdessalem, T., et al. (2021). River: machine learning for streaming data in Python. *Journal of Machine Learning Research*, 22(110):1–8.

Oliveira, G. H., Minku, L. L., and Oliveira, A. L. (2021). Tackling virtual and real concept drifts: An adaptive gaus-

- sian mixture model approach. *IEEE Transactions on Knowledge and Data Engineering*, 35(2):2048–2060. DOI: 10.1109/TKDE.2021.3099690.
- Zhao, L. and Shen, Y. (2025). Proactive model adaptation against concept drift for online time series forecasting. In *Proceedings of the 31st ACM SIGKDD Conference on Knowledge Discovery and Data Mining*, pages 2020–2031. ACM. DOI: 10.1145/3690624.3709210.
- Zheng, W., Zhao, P., Chen, G., Zhou, H., and Tian, Y. (2023). A hybrid spiking neurons embedded LSTM network for multivariate time series learning under concept-drift environment. *IEEE Transactions on Knowledge and Data Engineering*, 35(7):6561–6574. DOI: 10.1109/TKDE.2022.3178176.
- Žliobaitė, I., Pechenizkiy, M., and Gama, J. (2016). An overview of concept drift applications. In *Big Data Analysis: New Algorithms for a New Society*, pages 91–114. Springer. DOI: 10.1007/978-3-319-26989-4_4.