

OASIS: An Online Adaptive System with Incremental Selection for Concept Drift in Financial Time Series Forecasting

Liedson D. O. Leite¹, Gabriel F. Sarmento¹, Gustavo H. F. de M. Oliveira¹

¹ Sistemas de Informação, Universidade Federal de Alagoas (UFAL)¹.

{liedson.leite, gabriel.sarmiento}@arapiraca.ufal.br
gustavo.oliveira@penedo.ufal.br

Abstract. *Forecasting financial time series is necessary for economic decisions. Still, the instability caused by concept drift tends to compromise the accuracy of models by altering the distribution of data over time. Although some studies address concept drift, many still fail to adequately deal with its variations—both real and virtual—which limits the effectiveness of models in non stationary scenarios. Therefore, this paper proposes the OASIS (Online Adaptive System with Incremental Selection). Results on seven financial series demonstrated that OASIS outperforms or equals methods in the literature that also propose to deal with concept drift.*

Resumo. *A previsão de séries temporais financeiras é necessária para decisões econômicas, mas a instabilidade causada pela mudança de conceito (concept drift) tende a comprometer a acurácia dos modelos ao alterar a distribuição dos dados ao longo do tempo. Embora alguns estudos abordem a mudança de conceito, muitos ainda falham em lidar adequadamente com suas variações — a real e a virtual — o que limita a eficácia dos modelos nesses cenários não estacionários. Por isso, este trabalho propõe o OASIS (On-line Adaptive System with Incremental Selection). Resultados em sete séries financeiras demonstraram que o OASIS supera ou se iguala aos métodos da literatura que também se propõem a lidar com a mudança de conceito.*

1. Introdução

A análise e a previsão de séries temporais financeiras desempenham um papel relevante no campo da economia, uma vez que a variação desses dados influencia diretamente o desenvolvimento de diversos países [Cavalcante et al. 2016a]. Nesse tipo de mercado, a qualidade das previsões fornecidas pelas séries temporais é fundamental para apoiar a tomada de decisão por parte de governantes e investidores [Cavalcante and Oliveira 2015].

Apesar dessa importância, prever séries temporais financeiras é desafiador devido à alta volatilidade, baixa correlação e presença de ruído nos dados [Matsumoto et al. 2019]. O conjunto dessas características frequentemente compromete a precisão dos modelos preditivos, que podem não ser capazes de capturar a complexidade e as variações presentes nesse tipo de dado [Martins et al. 2016].

Essas dificuldades são agravadas pela instabilidade dos padrões observados nas séries temporais financeiras, frequentemente causada por fatores externos. Entre eles,

destacam-se mudanças nas regulamentações governamentais, campanhas publicitárias, alterações em contextos políticos e econômicos, além de transformações na psicologia ou nas expectativas dos investidores [Cavalcante et al. 2016b]. Tais alterações podem provocar mudanças na distribuição dos dados, modificando os padrões utilizados no aprendizado dos modelos preditivos e tornando-os obsoletos. Esse fenômeno é conhecido como mudança de conceito (do inglês: *concept drift*) [Lima et al. 2022].

A mudança de conceito pode alterar o processo gerador dos dados, definido como $P(X, y) = P(y | X)P(X)$. Mudanças em $P(y | X)$, chamadas de reais, indicam que a relação entre entrada (X) e saída (y) mudou, comprometendo diretamente o desempenho do modelo. Já mudanças em $P(X)$, conhecidas como virtuais, afetam apenas a distribuição dos dados de entrada, podendo exigir readequações no aprendizado do modelo. Ambas impactam a performance preditiva e demandam diferentes estratégias de adaptação [Oliveira et al. 2021].

Apesar do impacto direto da mudança de conceito em aplicações reais, esse fenômeno ainda é pouco explorado no contexto da previsão de séries temporais [Lima et al. 2022]. Essa lacuna reforça a necessidade de desenvolver novos sistemas adaptativos, capazes de se ajustar ao dinamismo dos dados e fornecer previsões mais precisas diante dessas alterações [Raimundo 2018]. Perante esse cenário, este trabalho propõe o método OASIS (*On-line Adaptive System with Incremental Selection*), um produto de um projeto de iniciação científica.

O OASIS foi concebido para lidar simultaneamente com mudanças virtuais e reais na previsão de séries temporais financeiras. A estratégia adotada baseia-se nas recomendações da literatura para diferentes tipos de mudanças. Conforme [Oliveira et al. 2021, Saini et al. 2022], em casos de mudanças virtuais, recomenda-se a atualização parcial do conhecimento do modelo, por meio de aprendizado incremental/on-line. Por outro lado, [Gama et al. 2014] argumenta que, após uma mudança real, é indicada a substituição completa do modelo com dados do novo conceito.

Nesse contexto, com o objetivo de superar as limitações dos métodos existentes na literatura — que enfrentam dificuldades durante a transição de um conceito para outro — este trabalho adota como hipótese a aplicação da seleção dinâmica de modelos. Conforme sugerido por [de Oliveira et al. 2021], a escolha dinâmica de diferentes modelos para cada novo dado pode representar uma alternativa eficaz para preservar o desempenho preditivo. Tal abordagem mostra-se especialmente promissora em cenários de instabilidade decorrentes da transição entre conceitos.

Por fim, para alcançar o objetivo proposto, a Seção 2 fundamenta sobre as abordagens usadas na adaptação a mudança de conceito e define a seleção dinâmica de modelos. A Seção 3 descreve o processamento do OASIS. Em seguida, a Seção 4 discute os experimentos realizados e os resultados obtidos. Por fim, a Seção 6 apresenta as conclusões deste estudo.

2. Fundamentação Teórica

2.1. Adaptação a Mudança de Conceito

A mudança de conceito é amplamente estudada em tarefas de classificação de dados, mas seu impacto em problemas de regressão — voltados à previsão de variáveis contínuas

— passou a receber atenção mais recentemente [Lima et al. 2022, Oliveira et al. 2017]. Esse avanço reflete a crescente demanda por sistemas adaptativos em cenários não estacionários, como finanças, energia e monitoramento ambiental [Lima et al. 2022].

Deste modo, estratégias de adaptação a mudança de conceito originalmente desenvolvidas para classificação vêm sendo aplicadas à regressão [Lima et al. 2022]. Segundo [Gama et al. 2014], existem duas abordagens principais: passivas e ativas. Estratégias passivas assumem mudanças contínuas no ambiente e atualizam os modelos de forma incremental, utilizando janelas deslizantes, esquecimento gradual, entre outras técnicas [Lu et al. 2018]. Embora computacionalmente eficientes, tendem a reagir lentamente a mudanças temporalmente abruptas e são vulneráveis a ruídos de conceitos anteriores.

Por outro lado, estratégias ativas detectam explicitamente mudanças de conceito antes de adaptar o modelo. Elas monitoram métricas como erro de predição ou variações estatísticas nos dados, utilizando algoritmos como DDM, EDDM e ADWIN [Lu et al. 2018]. Após a detecção, ações como ajuste de hiperparâmetros, re-treinamento ou substituição de modelos são executadas. Apesar disso, essas abordagens podem sofrer com atrasos na resposta devido a falsas detecções, especialmente em ambientes ruidosos, o que compromete o desempenho preditivo.

Embora eficientes em certos contextos, estratégias ativas e passivas apresentam limitações quando aplicadas isoladamente. Por isso, abordagens híbridas surgem como uma alternativa promissora, combinando a resposta rápida das técnicas passivas com a informação das ativas, adaptando-se conforme o tipo e intensidade da mudança de conceito [Oliveira et al. 2021]. Esse equilíbrio é particularmente relevante em domínios sensíveis, como a previsão de séries temporais financeiras, onde falhas de adaptação podem comprometer decisões críticas.

2.2. Seleção Dinâmica de Modelos

A combinação de múltiplos modelos, conhecida como *ensemble*, é uma abordagem consolidada e eficaz em problemas de aprendizagem de máquina. Essa técnica, ao explorar a diversidade entre modelos individuais, tende a minimizar erros e aumentar a capacidade de generalização [SILVA 2021]. Contudo, o desempenho pode ser comprometido quando modelos pouco eficazes são incluídos no conjunto, o que prejudica o resultado final. Essa limitação motivou o surgimento da seleção dinâmica de modelos, que avalia de forma mais criteriosa a contribuição individual de cada modelo [de Oliveira et al. 2021].

A seleção dinâmica de modelos possibilita que apenas o modelo mais competente seja utilizado para a predição de cada nova instância. Essa abordagem parte do princípio de que diferentes regiões do espaço de entrada podem demandar especializações distintas [SILVA 2021, de Oliveira et al. 2021]. Assim, em vez de aplicar uma estratégia global baseada na combinação de vários modelos, é possível avaliar a competência local de cada modelo, utilizando métricas como acurácia em janelas recentes ou erro em regiões de vizinhança, promovendo uma escolha mais eficiente e contextualizada.

Essa abordagem é especialmente promissora em ambientes não estacionários sujeitos a mudanças de conceito. Pois, após uma mudança, a seleção dinâmica pode utilizar os dados mais recentes para identificar o modelo mais adequado ao novo conceito, minimizando os efeitos do uso de modelos obsoletos e preservando o desempenho preditivo do sistema [SILVA 2021, de Oliveira et al. 2021]. Dessa forma, a seleção dinâmica de mo-

delos torna-se uma estratégia fundamental para cenários online e não estacionários, como o mercado financeiro, nos quais a adaptação contínua é essencial para manter a acurácia e confiabilidade das previsões.

3. Metodologia

Nesta Seção, apresenta-se o OASIS (*Online Adaptive System with Incremental Selection*), um método desenvolvido para lidar com mudanças de conceito em séries temporais financeiras. A metodologia a seguir descreve, de forma sistemática, as etapas do funcionamento do sistema, conforme ilustrado na Figura 1.

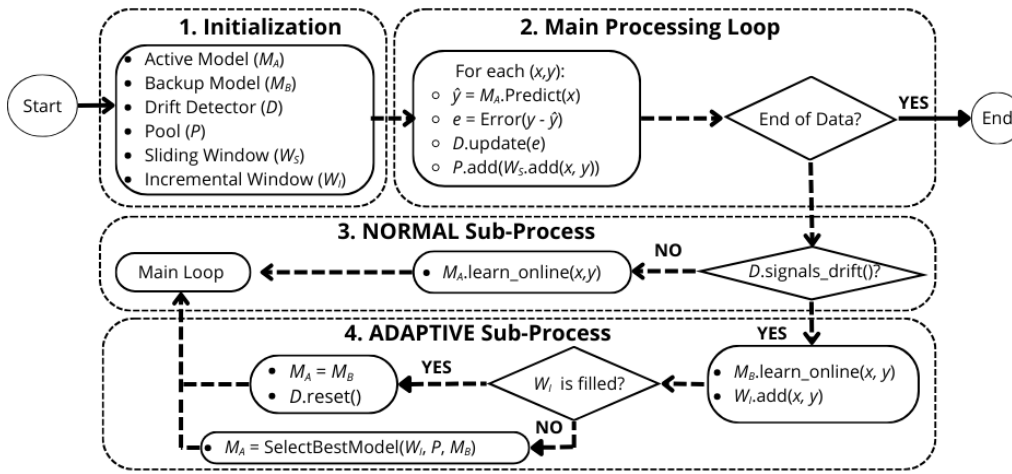


Figura 1. Estrutura geral do OASIS

O processo tem início com a etapa de **Initialization**, que utiliza um conjunto inicial de dados históricos (*batch*) para treinar o modelo preditivo e o seu detector de mudanças. Nesse momento, são inicializados os seguintes componentes: o modelo ativo M_A , responsável por computar as previsões em tempo real; o modelo reserva (backup) M_B , inicialmente inativo, mas usado quando a mudança ocorre; o detector de mudança de conceito D , que monitora o desempenho preditivo do modelo; Um *Pool* P , para armazenar novos modelos; uma janela deslizante W_s usada para treinar novos modelos que serão armazenados no *Pool*; e uma janela incremental W_i , inicialmente inativa, mas usada para armazenar dados após a detecção de uma mudança.

A seguir, tem-se a etapa de **Main Processing Loop**, responsável por receber cada novo padrão de entrada x , para que o modelo M_A compute sua previsão. Após a chegada do respectivo rótulo (y), o erro é calculado por meio do MAE (Mean Absolute Error). Esse valor é então usado na atualização do detector D , que monitora a sequência de erros para identificar mudanças significativas no comportamento preditivo do modelo. O MAE foi escolhido como métrica de erro por sua baixa sensibilidade a *outliers* e por limitar o erro a um intervalo entre 0 e 1 — característica importante para o bom funcionamento do detector de mudanças, uma vez que a maioria dos detectores existentes foi originalmente proposto para problemas de classificação e geralmente utiliza esse intervalo.

A cada novo *batch* de observações, ou seja, sempre que o W_s é preenchido, ele é utilizado para treinar um modelo para adicioná-lo ao *Pool* P , então W_s é esvaziado para

receber novos dados. Se P ainda não estiver cheio, o modelo é adicionado diretamente. Caso contrário, ele só será incluído se apresentar desempenho (MAE) superior ao do pior modelo já armazenado em P . Em seguida, o comportamento do sistema varia de acordo com o estado do detector D .

Para a etapa de **Normal Sub-Process**, o sistema treina o modelo M_A de forma incremental utilizando cada novo par de observações (x, y) . Dessa forma, o sistema se torna capaz de acompanhar qualquer mudança virtual que cause apenas alteração na distribuição dos dados de entrada.

A etapa denominada **Adaptive Sub-Process** é ativada sempre que o detector sinaliza a ocorrência de uma mudança de conceito. É importante destacar que, ao indicar uma mudança, o detector aponta que, mesmo com o uso de aprendizado incremental, o sistema apresentou uma queda de desempenho, o que pode caracterizar uma mudança real, na qual há alteração na relação entre os dados de entrada (x) e os de saída (y) .

Nessa situação, todo o conhecimento previamente aprendido pelo modelo torna-se obsoleto, pois um novo padrão emerge com o novo conceito. Por esse motivo, o modelo reserva M_B é iniciado apenas com os dados mais recentes, e a janela incremental W_i passa a armazenar exclusivamente esses novos dados. Enquanto a janela incremental W_i ainda não estiver preenchida com um *batch* completo de dados históricos, a estratégia de seleção dinâmica de modelos é aplicada.

Nessa etapa de seleção dinâmica (*SelectBestModel*), o modelo reserva M_B e todos os modelos do *Pool P* são avaliados com os dados presentes em W_i , utilizando o MAE como métrica de desempenho. Esse processo é repetido a cada novo dado inserido em W_i , com o objetivo de atualizar o modelo de previsão atual M_A com aquele que apresentar melhor desempenho preditivo nos dados do novo conceito.

A abordagem da seleção dinâmica de modelos é motivada por uma limitação dos métodos de aprendizado incremental: em cenários de mudanças que ocorrem temporariamente de maneira abrupta, esses métodos tendem a responder lentamente com baixo desempenho, pois necessitam de muitos dados para ter um desempenho estável. Por esse motivo, a troca dinâmica do modelo de previsão M_A é feita para cada novo dado, buscando evitar perdas de desempenho enquanto o conceito ainda está se estabilizando.

Por fim, quando a janela incremental W_i atinge o tamanho definido do *batch*, isso indica que já há uma quantidade significativa de dados representando o novo conceito. Nesse momento, o modelo reserva M_B pode ser promovido a modelo atual M_A , e o detector D é reiniciado e passa a ser atualizado com os erros obtidos a partir dos dados do novo conceito.

4. Experimentos

Nesta Seção, são descritas as bases utilizadas e o pré-processamento aplicado, o protocolo de avaliação e as métricas empregadas, bem como a configuração experimental adotada.

4.1. Séries Temporais

Para a condução dos experimentos, foram selecionadas séries financeiras obtidas via API do Yahoo Finance, apresentadas na Tabela 1. Essas séries foram escolhidas por representarem algumas das principais ações das bolsas brasileira e americana. Além disso, por

apresentarem diferentes variações ao longo do tempo, podem evidenciar distintos tipos de mudanças de conceito causadas por fatores externos reais.

Para facilitar a leitura dos resultados e aprimorar o processo de treinamento dos algoritmos de aprendizado de máquina, foi utilizada a normalização online dos dados proposta por [Montiel et al. 2021], definida pela seguinte fórmula:

$$z = \frac{x - \mu}{\sigma} \quad (1)$$

Essa abordagem transforma os dados à medida que eles chegam pelo fluxo, ajustando-os para que possuam média (μ) e desvio padrão (σ), atualizados dinamicamente, sem a necessidade de armazenar os dados anteriores.

Por fim, para adequar as séries temporais ao formato de regressão, aplicou-se a técnica de janela deslizante, de modo que, a cada instante de tempo t , o vetor de entrada (x_t) contenha um conjunto de 10 valores imediatamente anteriores (*lags*) ao instante de predição (y_t). A definição de 10 lags foi feita de forma empírica, com base em pequenos experimentos preliminares. Ressalta-se que outras configurações, especialmente específicas para cada série, poderiam ser utilizadas com o objetivo de maximizar os resultados.

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

4.2. Avaliação e Métricas

Para organizar a forma como os dados são usados para treinar e testar as abordagens nos experimentos, foi adotado como protocolo o método **prequential** (ou **teste-seguido-de-treinamento**) [Hidalgo et al. 2019]. Esse método é utilizado para avaliar algoritmos em cenários de fluxo contínuo de dados. A cada nova observação, o modelo realiza uma predição, registra o erro e, em seguida, é atualizado com o dado real. Isso permite acompanhar o desempenho do modelo ao longo do tempo, refletindo sua capacidade de adaptação a mudanças.

Para avaliar a qualidade das previsões, utilizou-se a métrica **MAE**, definida conforme a equação:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2)$$

O **MAE** calcula a média das diferenças absolutas entre os valores reais (y_i) e as previsões (\hat{y}_i). Ele mede o quão distantes, em média, as previsões estão dos valores observados. Valores próximos de 0 indicam boas previsões, enquanto valores mais altos indicam desempenho inferior. Outras métricas, como MSE e RMSE, também poderiam ser consideradas, mas, por questões de espaço, apenas o MAE foi avaliado.

Nos resultados, a avaliação de cada combinação série temporal–modelo foi realizada com base na média e no desvio padrão de trinta execuções independentes, a fim de contemplar a variabilidade inerente a alguns algoritmos estocásticos.

Por fim, para avaliar estatisticamente os resultados, empregou-se a biblioteca *autorank* [Herbold 2020], na média das abordagens ao longo das séries temporais. O *autorank* executa o teste não paramétrico de Friedman, seguido do teste post-hoc Nemenyi para avaliar diferenças significativas a um nível de significância $\alpha = 0,05$. Nos experimentos, apenas a análise visual da distância crítica obtida pelo teste foi utilizada na discussão dos resultados.

4.3. Configuração Experimental

Para mensurar a eficiência das previsões do método proposto, foram realizados dois experimentos. O primeiro, teve como objetivo identificar a melhor forma de realizar a manutenção dos modelos no *Pool P* para os tamanhos de [5, 10, 20]. Nesse experimento foi comparado o OASIS removendo os modelos (i) por tempo, ou seja, ao chegar um modelo novo, o mais antigo é excluído; e (ii) por performance, ou seja, ao adicionar um novo, o modelo com pior desempenho para os dados recentes é removido.

O segundo experimento, teve como objetivo quantificar como as previsões do método proposto estão em relação aos métodos da literatura. Então, para isso foram selecionadas cinco abordagens.

As quatro primeiras são abordagens passivas com aprendizado incremental, utilizadas para avaliar se a proposta de seleção dinâmica pode melhorar as previsões. São elas: (i) **BayesianLinearRegression**, uma abordagem linear com aprendizado incremental baseado no teorema de Bayes; (ii) **HoeffdingTree**, uma árvore de decisão incremental baseada no limite de Hoeffding, capaz de atualizar sua estrutura em tempo real; (iii) **KNN-Regressor**, um método dos vizinhos mais próximos adaptado para fluxos de dados, com janelas de atualização contínua; e (iv) **OS-ELM** (*Online Sequential Extreme Learning Machine*) [Huang et al. 2005], uma rede neural com aprendizado sequencial rápido. Com exceção do OS-ELM, todos os outros algoritmos são determinísticos e podem ser encontrados na biblioteca *River* [Montiel et al. 2021]. Todas as abordagens foram executadas com seus parâmetros de configuração padrão.

O quinto e último algoritmo foi o método de detecção de mudança de conceito (v) **KSWIN** (*Kolmogorov–Smirnov Windowing Method*) da biblioteca *River* [Montiel et al. 2021], utilizado em conjunto com o algoritmo de treinamento em *batch LinearRegression* da biblioteca *scikit-learn* [Pedregosa et al. 2011]. Essa combinação representa uma abordagem ativa de detecção, com recomeço do treinamento a cada sinal de mudança. A escolha do KSWIN se deu pelo seu bom desempenho em experimentos prévios, comparando-o com outros detectores como **ADWIN**, **DDM**, **EDDM**, **FHDDM**, **HDDMa**, **HDDMb** e **Page-Hinkley** do *River* [Montiel et al. 2021]. O mesmo processo

foi adotado para a escolha do **LinearRegression (LR)**, que foi avaliado frente a alternativas como **KNN**, **RandomForest**, **Ridge** e **Lasso** do *scikit-learn* [Pedregosa et al. 2011].

Por fim, para o **OASIS**, foi utilizado como regressor base o algoritmo on-line **BayesianLinearRegression** e, como detector de mudança de conceito, o **KSWIN**, pelos motivos apresentados acima. Além disso, o tamanho máximo do *Pool P* foi fixado em 5.

Para o **KSWIN** e **OASIS** que precisam de um *batch* de dados para inicializar o detector de mudanças, foram realizados experimentos prévios em 20% dos dados das séries temporais para os valores de [50, 100, 200 e 300] e o tamanho final escolhido foi de 300. Ressalta-se também que experimentos mais profundos podem ser realizados variando o tamanho do *batch* para cada série visando maximizar os resultados.

5. Resultados

Nesta Seção, são descritos os resultados dos experimentos de (i) análise e qualidade de modelos do *Pool* do método proposto; e (ii) comparação com métodos da literatura.

5.1. Análise da Qualidade de Modelos no *Pool*

O primeiro experimento teve como objetivo identificar a melhor forma de realizar a manutenção dos modelos no *Pool P* do método **OASIS**. A etapa de armazenamento é de extrema importância, visto que a seleção dinâmica dos modelos depende fortemente da qualidade dos modelos armazenados.

A Figura 2 apresenta, em azul, a performance do método **OASIS** excluindo os modelos do *Pool* por tempo, e, em laranja, os modelos sendo excluídos de acordo com sua performance. O eixo X mostra a variação do tamanho do *Pool*, enquanto o eixo Y mostra o desempenho para a série BVSP. Apenas uma base foi selecionada para este experimento, devido ao custo computacional.




Figura 2. Gráfico de caixas da comparação por exclusão de modelos do *Pool (P)* por tempo e desempenho.

Observa-se, na Figura 2, que, conforme o número de modelos no *Pool* aumenta, a performance do sistema tende a diminuir. Isso ocorre porque modelos treinados em conceitos muito antigos passam a permanecer armazenados no *Pool*. Assim, durante a seleção dinâmica, esses modelos, mesmo quando selecionados, não generalizam bem para os novos conceitos.

Por outro lado, observa-se que o método de exclusão de modelos por performance apresentou, em todos os casos, uma melhoria consistente, considerando tanto a mediana

quanto o desvio padrão. A inserção de novos modelos, nesse caso, só ocorre se o modelo apresentar boa performance, contribuindo assim para a melhoria da qualidade do *Pool*.




Figura 3. Comparação entre o OASIS com *Pool* e sem *Pool* para a série BVSP nos pontos 1300 a 1800.

Por fim, a Figura 3 apresenta a comparação dos valores de MAE entre o **OASIS** com e sem *Pool* ao longo da série temporal do BVSP. Nota-se que o modelo com *Pool* (linha azul) apresenta, de forma geral, menores erros e maior estabilidade em relação ao modelo sem *Pool* (linha vermelha). Esses resultados indicam que a utilização do *Pool* contribui positivamente para a robustez e a performance preditiva frente às mudanças na distribuição dos dados.

5.2. Comparação com Abordagens que Lidam com Mudança de Conceito

O segundo experimento tem como objetivo quantificar o desempenho do método proposto, **OASIS**, em comparação com métodos que lidam com mudança de conceito da literatura.

Tabela 2. Resultados dos modelos para o MAE

Séries	BayesianLR	HoeffTree	KNNOnline	LR+KSWIN	OS-ELM	OASIS
AAPL	0.00797	0.08325	0.01110	0.015353 (0.004629)	0.006925 (0.000193)	0.007752 (0.000015)
B3SA3.SA	0.02947	0.03859	0.04686	0.044037 (0.005444)	0.035123 (0.004034)	0.029412 (0.000081)
BVSP	0.01754	0.02402	0.02436	0.022046 (0.002917)	0.016388 (0.000383)	0.017215 (0.000057)
DJI	0.01357	0.01712	0.01858	0.018635 (0.003416)	0.013529 (0.000398)	0.013092 (0.000028)
GSPC	0.00566	0.12080	0.00765	0.011397 (0.002241)	0.005683 (0.000327)	0.005494 (0.000009)
IXIC	0.00874	0.05142	0.01185	0.015228 (0.003367)	0.008235 (0.00032)	0.008457 (0.000011)
USDBRLX	0.01984	0.02636	0.02848	0.025008 (0.002132)	0.022429 (0.001418)	0.019689 (0.00002)




Figura 4. Ranking de Friedman com pós-teste de Nemenyi.

A análise inicia-se a partir dos resultados apresentados na Tabela 2, onde se observa que, em todos os casos, o desempenho do **OASIS** é superior ao dos demais métodos avaliados. De acordo com o ranking de Friedman (Figura 4), o **OASIS** ocupa a primeira posição entre os algoritmos com melhores performances. No entanto, segundo a Distância Crítica (CD) do teste de Nemenyi, não há evidências estatísticas suficientes para afirmar, com significância, que o OASIS supera os métodos **LR+KSWIN** e **BayesianLinearRegression**. Essa limitação pode ser atribuída, principalmente, ao número reduzido de apenas sete séries temporais utilizadas no experimento.

Apesar disso, identifica-se que o desempenho do **OASIS** foi superior ao de seu principal concorrente, o **BayesianLinearRegression** que é seu regressor base. Essa superioridade é atribuída ao mecanismo de seleção dinâmica de regressores desenvolvido neste trabalho. Ao analisar os resultados da Tabela 2, nota-se uma melhoria consistente em todas as séries temporais avaliadas, o que confirma a hipótese de que aplicar a seleção dinâmica em momentos de transição conceitual pode mitigar a degradação do sistema e, consequentemente, melhorar os resultados preditivos.



Figura 5. Previsões dos algoritmos comparados na série BVSP para os pontos de 4532 a 4674

Para compreender essa melhoria visualmente, apresenta-se na Figura 5 as previsões de todos os algoritmos comparados na série BVSP, restringindo-se ao intervalo de observações entre 4532 e 4674, em razão da extensão da série. Alguns pontos importantes podem ser destacados nessa análise. Primeiramente, tanto o método **LR+KSWIN** quanto o **OASIS** detectaram mudanças de conceito nesse trecho, embora em momentos distintos. Isso se deve ao fato de que a degradação do desempenho dos regressores ocorreu em pontos diferentes da sequência temporal.

Além disso, observa-se que os algoritmos **HoeffdingTree** e **KNNOnline** apresentaram os piores desempenhos, evidenciado pela maior distância de suas previsões (representadas pelas cores rosa e marrom, respectivamente) em relação aos dados reais (linha em preto). Em contrapartida, os métodos **LR+KSWIN**, **BayesianLinearRegression** e **OASIS** foram os que mais se aproximaram dos valores observados, demonstrando maior precisão.

Por fim, os resultados apresentados confirmam a sugestão de trabalhos da literatura que a adoção de estratégias combinadas para lidar com mudanças de conceito pode proporcionar melhorias consistentes no desempenho preditivo. Esse efeito é ainda mais

evidente em séries financeiras, que costumam apresentar padrões de modelagem complexos e dinâmicos.

6. Conclusão

Este estudo consistiu em propor e avaliar o **OASIS** (*On-line Adaptive System with Incremental Selection*), um sistema adaptativo projetado para mitigar os efeitos da mudança de conceito na previsão de séries temporais financeiras. A metodologia empregada no OASIS integra de forma estratégica o aprendizado incremental, a seleção dinâmica de modelos e um processo de retreinamento guiado por um detector de mudanças.

A hipótese de que a combinação das estratégias referidas seria eficaz para manter a acurácia preditiva em cenários não estacionários foi consistentemente confirmada. Os experimentos conduzidos demonstraram que o **OASIS** alcançou um desempenho superior ou, no mínimo, comparável aos métodos de referência da literatura, como evidenciado pelas métricas de MAE e pela análise do ranking de Friedman. Destaca-se a relevância da gestão do *Pool* de modelos, com a exclusão baseada na performance, que se mostrou eficiente para a estabilidade do sistema. A superioridade do **OASIS** em relação ao seu regressor base, o **BayesianLinearRegression**, reforça a eficácia do mecanismo de seleção dinâmica em transições de conceito, contribuindo significativamente para a mitigação da degradação do desempenho.

Apesar dos resultados promissores, reconhecem-se limitações inerentes ao escopo deste estudo, como o número restrito de séries temporais financeiras utilizadas, o que pode ter influenciado a significância estatística em algumas comparações. Mas, para trabalhos futuros, sugere-se a expansão da base de dados experimentais a fim de fortalecer a validade externa dos resultados. Além disso, a investigação de métodos para otimização automática de hiperparâmetros, a comparação com detectores de mudança mais complexos e abordagens passivas baseadas em *ensemble*.

Referências

- 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.
- Cavalcante, R. C., Minku, L. L., and Oliveira, A. L. (2016b). Fedd: Feature extraction for explicit concept drift detection in time series. In *2016 International joint conference on neural networks (IJCNN)*, pages 740–747. IEEE.
- Cavalcante, R. C. and Oliveira, A. L. (2015). An approach to handle concept drift in financial time series based on extreme learning machines and explicit drift detection. In *2015 international joint conference on neural networks (IJCNN)*, pages 1–8. IEEE.
- de Oliveira, J. F., Silva, E. G., and de Mattos Neto, P. S. (2021). A hybrid system based on dynamic selection for time series forecasting. *IEEE Transactions on Neural Networks and Learning Systems*, 33(8):3251–3263.
- Gama, J., Žliobaitė, I., Bifet, A., Pechenizkiy, M., and Bouchachia, A. (2014). A survey on concept drift adaptation. *ACM computing surveys (CSUR)*, 46(4):1–37.
- Herbold, S. (2020). Autorank: A python package for automated ranking of classifiers. *Journal of Open Source Software*, 5(48):2173.

- 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.
- Huang, G.-B., Liang, N.-Y., Rong, H.-J., Saratchandran, P., and Sundararajan, N. (2005). On-line sequential extreme learning machine. *Computational Intelligence*, 2005:232–237.
- 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.
- 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.
- Martins, L. E. V. et al. (2016). Modelos de volatilidade: Um estudo comparativo.
- Matsumoto, D. K. F. et al. (2019). Estudo em séries temporais financeiras utilizando redes neurais recorrentes.
- 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.
- Oliveira, G. H., Cavalcante, R. C., Cabral, G. G., Minku, L. L., and Oliveira, A. L. (2017). Time series forecasting in the presence of concept drift: A pso-based approach. In *2017 IEEE 29th International Conference on Tools with Artificial Intelligence (ICTAI)*, pages 239–246. IEEE.
- Oliveira, G. H., Minku, L. L., and Oliveira, A. L. (2021). Tackling virtual and real concept drifts: An adaptive gaussian mixture model approach. *IEEE Transactions on Knowledge and Data Engineering*, 35(2):2048–2060.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., and Duchesnay, E. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12:2825–2830.
- Raimundo, M. S. (2018). *Desenvolvimento de um modelo adaptativo baseado em um sistema SVR-Wavelet híbrido para previsão de séries temporais financeiras*. PhD thesis, Universidade de São Paulo.
- Saini, R., Mussbacher, G., Guo, J. L., and Kienzle, J. (2022). Machine learning-based incremental learning in interactive domain modelling. In *Proceedings of the 25th International Conference on Model Driven Engineering Languages and Systems*, pages 176–186.
- SILVA, E. G. d. (2021). Uma abordagem de seleção dinâmica de preditores baseada nas janelas temporais mais recentes.