

Análise do impacto da sintonia de parâmetros de heurísticas de compra e venda de ações

Analysis of the impact of parameter tuning in stock trading strategies

Renato Rodrigues Chaves Pereira Ferri, Lucas Santos Rodrigues,
Daniel Hasan Dalip, André Rodrigues da Cruz

¹Departamento de Computação
Centro Federal de Educação Tecnológica de Minas Gerais (CEFET-MG)
Av Amazonas 7675 – Nova Gameleira – Belo Horizonte, MG – Brazil

{rrcpf2304,lucasantos2003}@gmail.com, {hasan,dacruz}@cefetmg.br

Abstract. *Trading heuristics are very useful techniques for maximizing profits in the stock market. For better performance, it is necessary to specialize the parameter values of such models. This paper aims to discuss the impact of applying tuners on the parameter adjustment of asset buying and selling heuristics. For this, in a case study, four trading techniques were experimented with and compared regarding their respective returns, when comparing the adoption of a manual configuration with two meta-optimizers, a Genetic Algorithm and I-Race. By selecting financial return as the quality criterion, parameter tuning was done using asset price data from Ibovespa from 2012 to 2014. The validation of the return of each stock buying and selling model was calculated between 2015 and 2021. The results indicate that tuners are statistically capable of improving performance compared to manual configuration. **Keywords:** Financial Market, Parameter Tuning, Genetic Algorithm, I-Race.*

Resumo. *Heurísticas de trading são técnicas muito úteis para maximizar os lucros no mercado de ações. Para um melhor desempenho, se faz necessária a especialização dos valores de parâmetros de tais modelos. Este artigo visa discutir o impacto da aplicação de sintonizadores no ajuste de parâmetros de heurísticas de compra e venda de ativos. Para isso, em um estudo de caso, experimentou-se quatro técnicas de trading que foram comparadas em relação aos respectivos retornos, quando se confronta a adoção de uma configuração manual com a de dois meta-otimizadores, um Algoritmo Genético e o I-Race. Ao selecionar a rentabilidade como critério de qualidade, a sintonia dos parâmetros foi feita utilizando ativos do Ibovespa, cujos dados de preços estão no período de 2012 a 2014. A validação da rentabilidade de cada modelo de compra e venda de ações foram calculados entre 2015 e 2021. O resultados apontam que os sintonizadores são, estatisticamente, capazes de aprimorar o desempenho em relação à configuração manual. **Palavras-chave:** Mercado financeiro, Sintonia de Parâmetros, Algoritmo Genético, I-Race.*

1. Introdução

O mercado de ações permite a participação de múltiplos indivíduos na negociação de ativos buscando bons retornos financeiros. Por se tratar de um sistema competitivo, é natural a evolução das estratégias empregadas visando a maximização dos ganhos e a minimização das perdas através do uso de avanços tecnológicos, visando uma boa relação risco-retorno. Uma dessas evoluções é a adoção de robôs para a realização rápida e eficiente de compra e venda, técnica conhecida como *Algorithmic Trading* [Nutti et al. 2011].

O uso de robôs se tornou uma tendência em mercados financeiros, como dos EUA, devido principalmente ao barateamento da tecnologia e da facilidade de se adotar uma grande variedade de algoritmos. Uma técnica particularmente popular é o uso de algoritmos de computação evolutiva para estratégias de compra e venda, nos quais o uso do Algoritmo Genético (GA) se destaca [Hu et al. 2015].

A grande variedade de Estratégias para Compra e Venda de Ativos (ECVA), cada uma com suas vantagens e desvantagens, torna a decisão de qual heurística a ser utilizada um problema em si. Cada ativo possui propriedades específicas que devem ser levadas em conta ao maximizar o lucro. Portanto, além da escolha da estratégia, também é necessário configurá-la adequadamente para que um desempenho satisfatório seja obtido.

As meta-heurísticas são técnicas de otimização amplamente utilizadas para resolver problemas computacionalmente complexos com muitas variáveis [Osaba et al. 2021]. Esses procedimentos computacionais dependem de uma formulação matemática do problema para explorar de forma inteligente as soluções disponíveis. Nesse sentido, tais algoritmos são recursos viáveis para a sintonização de parâmetros de ECVA.

Apesar de uma implementação cuidadosa das meta-heurísticas ser capaz de encontrar bons resultados, não é garantido a otimalidade das soluções [Hooker et al. 2012]. Dessa forma, é necessário uma validação da eficiência dos sintonizadores de parâmetros.

Este trabalho, visando melhorar a rentabilidade no mercado de ações, investiga o impacto da adoção dos sintonizadores GA [Kramer and Kramer 2017] e *Iterated F-race* (I-Race) [López-Ibáñez et al. 2016], para configurar os parâmetros de quatro ECVAs (baseada em cruzamentos de 2 médias móveis, baseada em cruzamentos de 3 médias móveis, baseada em *momentum*, baseada em reversão a média). O problema de sintonia de parâmetros é considerado aqui como um problema de otimização em que se determina o conjunto de valores das ECVAs que irá maximizar a rentabilidade da negociação de uma certa ação. As ECVAs foram experimentadas computacionalmente, avaliando os lucros gerados por cada uma delas separadamente por ativo, comparando com as respectivas versões configuradas manualmente.

Para cada ECVA, a sintonia de parâmetros e o experimento de validação consideraram a rentabilidade como critério de qualidade em 40 ativos do Ibovespa, cujos dados de preços estão no período de 2012 a 2014 e 2015 a 2021, respectivamente. Na comparação adotou-se os testes não paramétricos de Friedman e Nemenyi [Derrac et al. 2011] que examinaram a hipótese nula, que afirma que não haver diferença entre configurar os parâmetros de uma ECVA de forma *ad-hoc* ou via heurísticas.

Durante a realização dos experimentos, foi observado que as sintonias de ECVAs com os maiores desempenhos foram aquelas que negociavam ações com maior

frequência. O GA foi o método de sintonia que apresentou a maior rentabilidade em termos absolutos. Entretanto, este também demonstrou piora em algumas das ECVAs quando comparada ao *ad-hoc*, enquanto o *I-Race* atuou de forma mais consistente em mais casos.

O restante deste artigo é organizado da seguinte forma: a Seção 2 apresenta uma revisão bibliográfica referente ao tema deste trabalho; a Seção 3 apresenta a metodologia utilizada para a realização dos experimentos; a Seção 4 apresenta os resultados obtidos; a Seção 5 apresenta as conclusões do trabalho e indica possíveis ações futuras a serem investigadas.

2. Revisão Bibliográfica

O estudo [Nascimento et al. 2022] investiga a relação entre o mercado financeiro e a adoção de técnicas de inteligência artificial, ao aplicar diversos modelos de previsão cuja eficácia varia conforme o período de previsão. Alguns modelos apresentaram bons resultados em períodos de tempo mais longos (90 dias), enquanto outros perdem a precisão após 30 dias. Apesar dessa diferença, é notável que a inteligência artificial é uma ferramenta poderosa para auxiliar investidores na compra e venda de ativos.

O trabalho [Machado et al. 2022] demonstra que técnicas de *trading*, em conjunto com algoritmos que utilizam aprendizado de máquina, são ferramentas que propiciam certa segurança ao atuar no mercado de ações. A pesquisa apontou que o modelo LSTM de previsão de valores, acompanhado de três estratégias de *swing trade*, obteve lucro em 70% das operações na bolsa de valores. Ademais, o estudo [Barboza et al. 2021] examinou a capacidade preditiva do LSTM de prever a tendência de preços de ações com 15 minutos de antecedência. O trabalho destacou que a seleção de variáveis de entrada foi um fator importante para melhorar o desempenho do preditor e garantir resultados satisfatórios.

Estudos como [Gunasekarage and Power 2001] ilustram como estratégias baseadas em médias móveis são capazes de prever tendências no mercado de ações, conseguindo superar ECVAs ingênuas. Enquanto o trabalho [Okunev and White 2003] apresenta como heurísticas de *momentum* conseguem obter sucesso consistentemente, apesar de sua simplicidade. O artigo [Gropp 2004] aponta que estratégias de reversão à média possuem retornos consideráveis em longo prazo. Além disso, os textos [Balvers and Wu 2006] e [Koiijen et al. 2009] sugerem combinar estratégias de *momentum* e de reversão à média para desenvolver ECVAs ainda mais robustas.

Heurísticas são algoritmos que buscam solucionar problemas através da implementação de regras. Apesar de não garantirem otimalidade, elas podem gerar soluções boas em tempo hábil para problemas complexos ou computacionalmente custosos [Gendreau et al. 2010]. Neste trabalho é de interesse que os parâmetros das ECVAs em questão sejam configuradas através de heurísticas de meta-otimização.

A meta-otimização é o processo que visa sintonizar os parâmetros de um algoritmo. Neste são testados múltiplos conjuntos de níveis de parâmetros de entrada da heurística-alvo, buscando a configuração adequada para o problema a ser resolvido. A sintonização pode ser realizada manualmente (*ad-hoc*), mas com a complexidade dos problemas é mais eficaz a adoção de meta-otimizadores dedicados a realizar essa função de forma automatizada [Huang et al. 2019].

O GA é um algoritmo de otimização inspirado nos mecanismos de seleção natural e evolução das espécies. Ao utilizar um conjunto inicial de soluções como uma população de indivíduos, o procedimento realiza simulações ao longo de gerações, descartando membros com o pior desempenho e reproduzindo os mais aptos, cujos descendentes podem sofrer modificações devido aos operadores de cruzamento e mutação. Este processo se repete até que um critério de parada seja satisfeito e a melhor solução encontrada é retornada [Kramer and Kramer 2017].

O *I-Race* é um algoritmo de meta-otimização criado para automatizar a operação de sintonia de parâmetros de heurísticas. Para isso, são realizadas múltiplas iterações de “corridas” entre configurações de parâmetros candidatas, com os melhores competidores de acordo com um critério de qualidade, sendo agrupados para a próxima iteração do algoritmo. Dessa forma, o procedimento é repetido enquanto o orçamento computacional disponibilizado para o método é suficiente. Ao final, as configurações, cujos desempenhos foram estatisticamente melhores, são retornadas [López-Ibáñez et al. 2016].

É importante ressaltar que outros estudos que abordam o cenário de aprendizado de máquina e mercado de ações, como [Nascimento et al. 2022] e [Machado et al. 2022], focam na análise da eficácia de técnicas de *trading* apoiadas a algoritmos de previsão. Por outro lado, o objetivo deste trabalho é analisar como a sintonia de parâmetros de ECVAs, por meio de meta-otimizadores, pode influenciar na rentabilidade das operações.

3. Metodologia

As subseções seguintes descrevem os métodos, as técnicas e as ferramentas computacionais utilizadas no desenvolvimento deste trabalho.

3.1. Estratégias de Trading

Considera-se 4 ECVAs, cujas sintonias de parâmetros via meta-otimização foram comparadas com as respectivas versões configuradas de forma *ad-hoc*: estratégia baseada no cruzamento de 2 em médias móveis (rápida e lenta); estratégia baseada no cruzamento de 3 em médias móveis (rápida, intermediária e lenta); de *momentum*; e de reversão à média. É fundamental destacar que os custos de transações não foram consideradas neste trabalho.

As duas primeiras, as baseadas em médias móveis de preços de ativos, analisam os cruzamentos de pares de médias móveis com diferentes horizontes de tempo, para obterem sinais de compra e venda. Parte-se da ideia que a média móvel é capaz de descrever tendências dos preços no curto, médio e longo prazos. Uma diferença positiva entre uma média móvel rápida e uma mais lenta pode indicar um sinal de compra. Caso a diferença seja negativa, isso pode indicar um sinal de venda [Hilpisch 2021]. Entretanto, definir o valor de tais diferenças é um desafio.

A estratégia de *momentum* determina as oportunidades de compra e venda analisando-se diretamente o desempenho recente de um ativo. Dessa forma, dado uma rentabilidade recente consistentemente positivo, a heurística determina que o desempenho futuro será positivo, indicando boa oportunidade de compra, enquanto o oposto indica uma bom momento para vender [Hilpisch 2021]. Por outro lado, determinar os valores ideais dos limiares dessa estratégia para um dado ativo não é uma tarefa trivial.

A técnica de reversão à média presume que, dado um desvio no desempenho de um ativo, a estabilização ocorrerá em breve. Determina-se quando ocorrerá uma recuperação do valor ou queda de uma alta, indicando, respectivamente, uma oportunidade de compra e de venda [Hilpisch 2021]. Assim, é necessário um meio consistente de configurar os parâmetros desta ECVA para obter um maior retorno. Para formulação matemática e maiores detalhes sobre estas e outras ECVAs, sugere-se [Hilpisch 2021] e [Murphy 1999].

3.2. Sintonia de Parâmetros

Um problema de meta-otimização de parâmetros pode ser definido conforme a Equação 1. Neste modelo, o vetor \mathbf{x} representa o conjunto de parâmetros candidatos da heurística-alvo e que pertence a região viável \mathcal{X} . A qualidade de \mathbf{x} é avaliada pela função de utilidade $u : \mathcal{X} \rightarrow \mathbb{R}$, que é do tipo caixa preta, ruidosa e com alto custo computacional. Isto se justifica pela extração da qualidade dos candidatos a conjunto de parâmetros após a execução da heurística-alvo, que possui um comportamento estocástico.

$$\max u(\mathbf{x}) \quad s.t. : \mathbf{x} \in \mathcal{X} \quad (1)$$

A heurística que analisa a evolução de duas médias móveis exponenciais (rápida e lenta) é denominada aqui EMM1. Ela utiliza cinco parâmetros ajustáveis, $\mathbf{x}_{emm1} = [x_1; \dots; x_5]$, nos intervalos apresentados: a categoria que descreve a referência adotada de preço das ações, $x_1 \in \{open, close, low, high\}$; os períodos tempo, em dias, para o cômputo das médias móveis exponenciais rápida e lenta, $x_2 \in \{2; \dots; 5\}$ e $x_3 \in \{6; \dots; 9\}$, respectivamente (intervalos de interesse no estudo de caso); a definição de valores para os limiares de compra e venda, $x_4, x_5 \in [0,01; 0,15]$, nesta ordem.

A heurística que se baseia no cruzamento de três médias móveis exponenciais (rápida, intermediária, lenta) é alcunhada EMM2. Há dez parâmetros ajustáveis, $\mathbf{x}_{emm2} = [x_1; \dots; x_{10}]$: a referência de preço, $x_1 \in \{open, close, low, high\}$; os horizontes de tempo para o cálculo das médias móveis de prazos rápido, médio e lento, respectivamente, $x_2 \in \{3; \dots; 7\}$, $x_3 \in \{8; \dots; 21\}$ e $x_4 \in \{22; \dots; 60\}$; três limiares que representam sinal de compra para quando, respectivamente, (i) a média rápida cruza acima a intermediária, (ii) a rápida cruza acima a lenta e (iii) a intermediária cruza acima a lenta: $x_5, x_6, x_7 \in [0,01; 0,15]$; de modo análogo e respectivamente, três limiares que representam sinal de venda quando (iv) a média rápida cruza abaixo a intermediária, (v) a rápida cruza abaixo a lenta e (vi) a intermediária cruza abaixo a lenta: $x_8, x_9, x_{10} \in [0,01; 0,15]$.

A estratégia de *momentum* também utiliza cinco parâmetros, $\mathbf{x}_{mom} = [x_1; \dots; x_5]$: o parâmetro de movimento do preço das ações $x_1 \in \{open, close, low, high\}$; o tipo de média móvel a ser utilizada, $x_2 \in \{simples, exponencial, exponencial\ dupla, exponencial\ tripla, triangular, Kaufman\}$; O período da média móvel utilizada, $x_3 \in \{3; \dots; 9\}$; e os valores dos limiares de compra e venda, em porcentagem, $x_4, x_5 \in [0; 0,05]$.

Por fim, a heurística de reversão à média possui os mesmos cinco parâmetros da estratégia de *momentum*, mas com diferentes intervalos de variação, $\mathbf{x}_{rm} = [x_1; \dots; x_5]$: o preço do ativo a ser utilizado, $x_1 \in \{open, close, low, high\}$; a média móvel selecionada para os cálculos, $x_2 \in \{simples, exponencial, exponencial\ dupla, exponencial\ tripla, triangular, Kaufman\}$;

o período da média móvel, $x_3 \in \{2; \dots; 60\}$; e os limiares para a realização das compras e das vendas, $x_4, x_5 \in [0; 5]$.

3.3. Algoritmos de Sintonia

Um dos algoritmos de sintonia adotados foi o Algoritmo Genético (GA), o qual é um método heurístico de otimização baseado na teoria evolucionista proposto por Darwin. No GA as soluções são como os indivíduos, de modo que os mais aptos sobrevivem e se reproduzem para passar os genes às próximas gerações. O melhor indivíduo (vetor de solução em relação ao critério de qualidade) é retornado ao final [Kramer and Kramer 2017].

De uma forma geral, no GA é gerada e avaliada uma população inicial aleatória dentro do espaço de busca. Em seguida, ocorre o laço de repetição que evolui até que um critério de parada seja atingido. Nas iterações, ocorre-se a seleção de pares de soluções pais, que serão usados para a geração de uma população de filhos através do operador de cruzamento. Algumas soluções da população filho podem sofrer pequenas alterações pelo operador de mutação. Depois, os filhos são avaliados pela função de utilidade e juntados à população de pais. Deste último conjunto, armazena-se a melhor solução encontrada (elístico) e uma nova população de pais é passada para a próxima geração (iteração das repetições evolutivas) [Kramer and Kramer 2017].

Os autores em [López-Ibáñez et al. 2016] apresentam o método *I-Race* como um método de meta-otimização através de “corridas” entre conjuntos de parâmetros candidatos. Baseado no algoritmo *F-Race*, proposto em [Birattari et al. 2002], o *I-Race* se destaca ao produzir resultados refinados através da aplicação de múltiplas iterações do *F-Race*.

Dado um conjunto de tipos de parâmetros (numéricos, categóricos e ordinais) e seus intervalos respectivos, o algoritmo cria um grupo inicial de configurações para a realização do processo de corridas iteradas em três passos: (i) amostragem de novas configurações de acordo com os intervalos fornecidos; (ii) a seleção dos melhores candidatos das corridas com base num critério de qualidade; e (iii) a atualização dos intervalos de acordo com os vencedores. Após cada corrida, uma nova iteração é realizada, de modo que o orçamento computacional disponibilizado seja totalmente utilizado e, por fim, as melhores configurações não diferenciadas por um teste estatístico adotado são retornadas.

O uso do GA e do *I-Race* para otimização de parâmetros em algoritmos de *trading* apresenta vantagens específicas que justificam sua seleção. Enquanto o GA é eficaz na exploração global, otimização de múltiplos parâmetros e evolução contínua, o *I-Race* se destaca pela eficiência computacional, aprendizado iterativo e busca robusta. A combinação desses métodos pode levar a uma otimização mais eficiente e eficaz dos algoritmos de compra e venda de ativos, melhorando seu desempenho e adaptabilidade às condições de mercado.

3.4. Planejamento Experimental

Este trabalho apresenta quatro experimentos, um para cada ECVA (EMM1, EMM2, *Momentum* e Reversão à Média), para realizar a comparação da eficácia, em relação à rentabilidade, quando se configura a estratégia de forma manual ou através da sintonia de parâmetros usando GA e *I-Race* (três tratamentos). Em outras palavras, com um nível de significância $\alpha = 0,10$, deseja-se testar a hipótese nula, H_0 , que afirma não haver

Tabela 1. Lista de ativos experimentados.

Ativos									
VALE3	PETR3	ITUB3	BBDC3	B3SA3	ELET3	ABEV3	RENT3	BBAS3	WEGE3
ITSA3	SUZB3	EQTL3	GGBR3	JBSS3	LREN3	RADL3	PRI03	ENEV3	HYPE3
CSAN3	SBSP3	VIVT3	TOTS3	CMIG3	BRFS3	KLBN3	UGPA3	CCRO3	MGLU3
ENGI3	SANB3	AMER3	CPL3	EGIE3	TIMS3	BRKM3	EMBR3	TAE3	CSNA3

diferença estatística entre sintonizar os parâmetros de uma ECVA de forma *ad-hoc* ou utilizando um meta-otimizador, em relação a mediana da rentabilidade.

Para isto, foram selecionados 40 ativos representativos do índice Ibovespa (Tabela 1), cujos históricos de preço diário foram obtidos da plataforma *Yahoo Finance* utilizando a biblioteca *YFinance* [Aroussi 2022]. Tais dados foram utilizados tanto no processo de sintonia via GA e *I-Race*, que considerou o intervalo 01/01/2012 a 31/12/2014, quanto no de validação no período de 01/01/2015 a 31/12/2021. Na sintonia ou validação de um conjunto de parâmetros, realizada individualmente para cada ativo, um sinal de compra implica na aquisição de no máximo de unidades de ação com R\$1.000,00, e o sinal de venda realiza a negociação de todas as unidades compradas. Em cada execução, o orçamento computacional para ambos os sintonizadores (critério de parada) foi de 5000 avaliações de função de utilidade por ativo.

Após as devidas sintonias de parâmetros para cada ativo, realização da simulação de compra e venda no período de validação para cada ECVA, considerando os tratamentos experimentais de configuração *Manual*, *GA* e *I-Race*, se terá as amostras de rentabilidade. Cada tratamento será representado por 40 amostras de lucro ou prejuízo ao final do intervalo simulado. Para analisar o impacto das sintonizações na performance das heurísticas foram gerados gráficos que descrevem a amostra de valor terminal obtida e aplicados os testes não paramétricos de Friedman *post-hoc* de Nemenyi [Derrac et al. 2011] para validar ou refutar H_0 .

Nesse trabalho, adotou-se a implementação do GA da biblioteca Python *Pymoo* [Blank and Deb 2022] utilizando uma população de 20 indivíduos e operadores padrões para otimização com variáveis mistas (*Mixed Variable GA*): método de amostragem aleatória e método de acasalamento de variáveis mistas padrão com eliminação de duplicatas. No caso do *I-Race*, foi utilizada a implementação em R disponível no pacote *irace* [López-Ibáñez et al. 2016] com as configurações padrões, sendo que apenas o cenário foi modificado para a realização de 5000 experimentos para cada ativo.

4. Resultados

Após a sintonia e simulação, obteve-se as devidas amostras de lucro ou prejuízo para os tratamentos em cada experimento. Os códigos-fonte deste projeto e os dados utilizados e gerados pelos experimentos, como conjuntos de parâmetros *ad-hoc* e sintonizados, rentabilidade final por ação, etc. podem ser acessados pelo endereço <https://github.com/santoslucas/BWAIIF-files>. Dado o limite de espaço, uma análise geral é realizada abaixo.

Para a EMM1, a Figura 1 ilustra a distribuição do valor terminal das 40 ações para cada um dos três tratamentos (sintonizadores de parâmetros). Observa-se, em relação

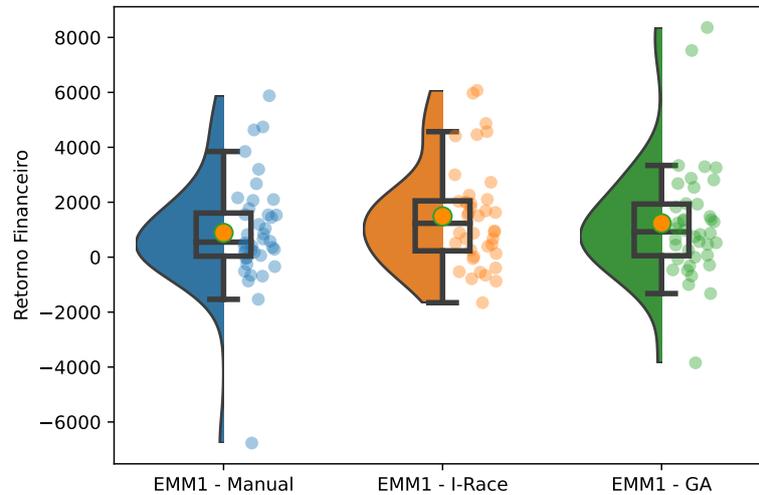


Figura 1. Retornos financeiros para 40 ativos do Ibovespa utilizando a estratégia EMM1 com três técnicas de sintonias de parâmetro.

Tabela 2. Resultados do teste de Nemenyi para EMM1.

Pares	Manual × I-Race	Manual × GA	I-Race × GA
Valor-P	0,049475	0,567898	0,373279

ao uso de parâmetros sintonizados, o efeito da melhoria das estatísticas amostrais média (ponto laranja com borda verde), mediana e quantis superiores de rentabilidade.

Aplicando-se o teste de Friedman nas amostras dos três tratamentos para a heurística EMM1, obteve-se o valor-P 0,0623, que é menor do que o nível de significância α adotado. Logo rejeita-se H_0 , havendo indicativo de diferença significativa em relação a mediana entre, pelo menos, um par de tratamentos. A saída do teste de Nemenyi, apresentada na Tabela 2, mostra diferença entre o par Manual e I-Race, sendo que o segundo resultou em melhores configurações para a heurística EMM1.

O gráfico da Figura 2 apresenta as amostras do valor terminal dos ativos negociados pela EMM2. Pela sintonia do *I-Race*, foi observado o melhor desempenho da heurística pelas mediana e média amostrais. No caso do GA, a mediana encontrada foi próxima ao da configuração manual.

Para os sintonizadores da EMM2, o teste de Friedman retornou o valor-P de 0,0060. Dessa forma, após rejeitar H_0 e aplicar o teste de Nemenyi, cujos resultados estão na Tabela 3, verifica-se que a sintonia via *I-Race* proporcionou um desempenho estatisticamente superior em relação à Manual e GA.

As estratégias de *Momentum* foram as que apresentaram a maior impacto no desempenho devido a sintonização de parâmetros. A Figura 3 ilustra como ocorreu uma

Tabela 3. Resultados do teste de Nemenyi para EMM2.

Pares	Manual - I-Race	Manual - GA	I-Race - GA
Valor-P	0,004967	0,631856	0,065303

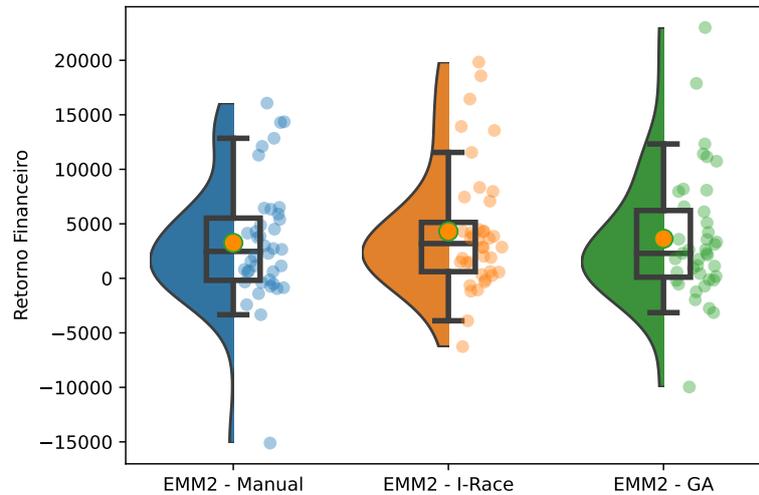


Figura 2. Retornos financeiros para 40 ativos do Ibovespa utilizando a estratégia EMM2 com três técnicas de sintonias de parâmetro.

Tabela 4. Resultados do teste de Nemenyi para *Momentum*.

Pares	Manual × I-Race	Manual × GA	I-Race × GA
Valor-P	0,001000	0,001000	0,900000

melhora considerável utilizando ambos os algoritmos de meta-otimização. Observa-se que com o *I-Race* teve-se as melhores mediana e média amostrais, enquanto o GA induziu os maiores valores absolutos.

O teste de Friedman resultou no valor-P $3 \cdot 10^{-11}$, rejeitando fortemente H_0 para essa heurística. Os resultados do teste de Nemenyi, observados na Tabela 4, demonstram que não há diferença significativa entre a aplicação dos dois métodos de sintonia, que obtiveram resultados melhores do que a configuração manual. Isto demonstra que o impacto da sintonia em ambos os casos é relevante.

Por fim, constata-se através das amostras da heurística de Reversão à Média, ilustradas pela Figura 4, um comportamento diferente do restante. Observa-se que ambos os sintonizadores proporcionaram melhorias no desempenho da estratégia, sendo que agora o GA superou o *I-Race* em termos de mediana, quantis superior e média.

A realização do teste de Friedman para esse conjunto de dados retornou valor-P de 0,0623, permitindo o descarte de H_0 . Pelos resultados do teste de Nemenyi, presentes na Tabela 5, verifica-se que ambos os métodos não possuem diferença quando comparadas com a configuração manual. Uma possível explicação para o ocorrido seria o tempo disponibilizado para o treinamento que, por se tratar de uma heurística focada em retornos no longo prazo, pode ter sido insuficiente. Por outro lado, constata-se a superioridade do GA em relação ao *I-Race*.

É interessante notar que a estratégia *momentum*, caracterizada pela alta frequência de negociações, obteve os melhores resultados com ambos os métodos. Já heurística mais conservadora, a de reversão à média, não apresentou aprimoramento com a sintonização. Comparando a EMM1 e a EMM2, essa relação também pode ser observada, já que o uso

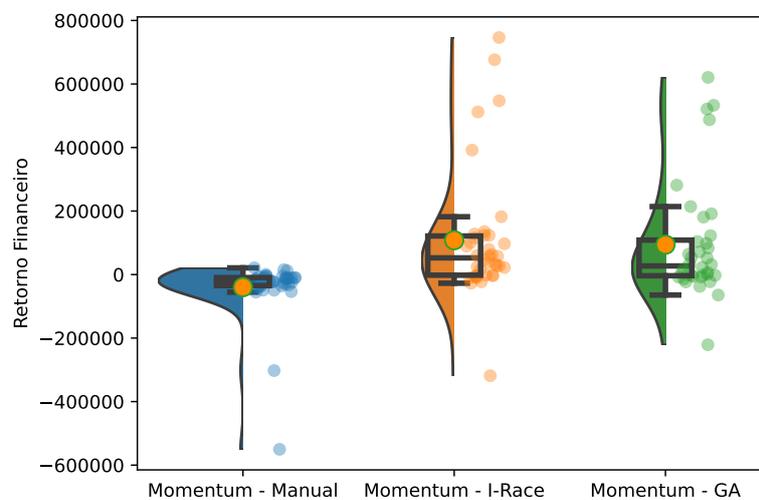


Figura 3. Retornos financeiros para 40 ativos do Ibovespa utilizando a estratégia *Momentum* com três técnicas de sintonias de parâmetro.

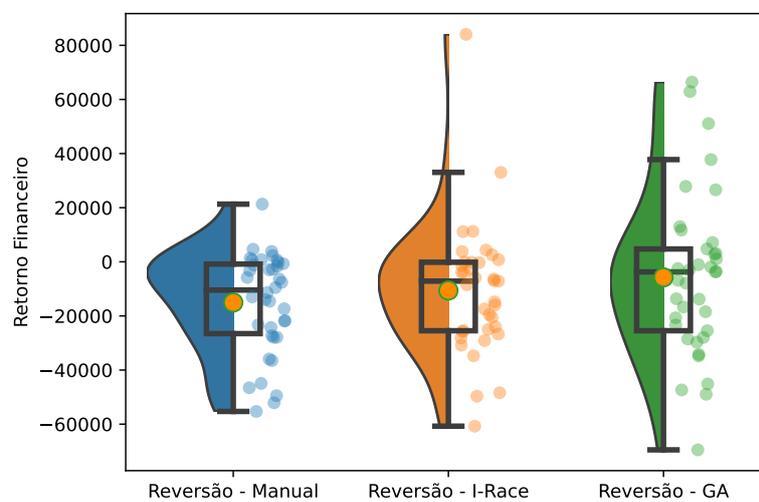


Figura 4. Retornos financeiros para 40 ativos do Ibovespa utilizando a estratégia *Reversão à Média* com três técnicas de sintonias de parâmetro.

Tabela 5. Resultados do teste de Nemenyi para Reversão à Média.

Pares	Manual × I-Race	Manual × GA	I-Race × GA
Valor-P	0,373279	0,567898	0,049475

de mais médias móveis permite que a EMM2 tenha mais oportunidades de negociação, indicando a possibilidade dos métodos de sintonia favorecerem estratégias com uma maior frequência de trocas. Dessa forma, a comparação entre estratégias com natureza distinta de comportamento não foi considerada justa para o contexto deste trabalho.

5. Conclusões e Trabalhos Futuros

Este trabalho apresentou como o uso de algoritmos de meta-otimização para a sintonia de parâmetros é capaz de afetar positivamente o desempenho de ECVAs. Como resultado principal, teve-se o aumento na rentabilidade das heurísticas sintonizadas para a maioria dos casos. As estratégias de *momentum* sobressaíram em relação aos retornos devido a ambos métodos de sintonização. Outra heurística que se destacou foi a de reversão à média, a única na qual a sintonia não teve grandes impactos.

Dada as diferenças de retornos observadas, para os parâmetros retornados pelos métodos de sintonia, acredita-se que ambos tem potencial para serem estudados de forma mais profunda em trabalhos futuros. Almeja-se realizar comparações com outros métodos de sintonização em situações mais custosas com um número maior de parâmetros configuráveis e maior orçamento computacional para realização dos cálculos, assim como sintonizar as ECVAs para um número maior de ativos brasileiros e estrangeiros.

Ademais, futuras pesquisa podem incluir a análise de estatísticas adicionais, como o índice de Sharpe, correções para assimetria e curtose, e a consideração de diferentes períodos de estimação e teste para verificar a robustez das estratégias. Além disso, aplicar técnicas de aprendizado de máquina para ajustar os parâmetros das ECVAs de forma recursiva e incluir os custos de transação no treinamento e validação das estratégias são aspectos promissores a serem explorados. Essas abordagens aprimorariam a análise, tornando-a mais completa, adaptável e realista.

Também é de interesse apresentar uma análise mais detalhada dos resultados. Há evidências de que há ativos que não são interessantes de serem negociados via ECVAs, pois ao final retornaram prejuízos em diversos experimentos. Devido a ausência de espaço, isto não foi discutido aqui.

Referências

- Aroussi, R. (2022). Download market data from yahoo! finance api. <https://pypi.org/project/yfinance/>. Accessed: 2022-12-16.
- Balvers, R. J. and Wu, Y. (2006). Momentum and mean reversion across national equity markets. *Journal of Empirical Finance*, 13(1):24–48.
- Barboza, F., Garruti, D. V. T., and Silva, M. F. (2021). Previsões de tendência no brasil: uma aplicação de inteligência artificial. *Congresso UFU de Contabilidade*.
- Birattari, M., Stützle, T., Paquete, L., Varrentrapp, K., et al. (2002). A racing algorithm for configuring metaheuristics. In *Gecco*, volume 2. Citeseer.
- Blank, J. and Deb, K. (2022). pymoo: Multi-objective optimization in python. <https://pymoo.org/index.html>. Accessed: 2023-03-05.
- Derrac, J., García, S., Molina, D., and Herrera, F. (2011). A practical tutorial on the use of nonparametric statistical tests as a methodology for comparing evolutionary and swarm intelligence algorithms. *Swarm and Evolutionary Computation*, 1(1):3–18.

- Gendreau, M., Potvin, J.-Y., et al. (2010). *Handbook of metaheuristics*, volume 2. Springer.
- Gropp, J. (2004). Mean reversion of industry stock returns in the us, 1926–1998. *Journal of Empirical Finance*, 11(4):537–551.
- Gunasekarage, A. and Power, D. M. (2001). The profitability of moving average trading rules in south asian stock markets. *Emerging markets review*, 2(1):17–33.
- Hilpisch, Y. (2021). *Python for Algorithmic Trading*. O’Reilly.
- Hooker, J. N. et al. (2012). *Integrated methods for optimization*, volume 170. Springer.
- Hu, Y., Liu, K., Zhang, X., Su, L., Ngai, E., and Liu, M. (2015). Application of evolutionary computation for rule discovery in stock algorithmic trading: A literature review. *Applied Soft Computing*, 36:534–551.
- Huang, C., Li, Y., and Yao, X. (2019). A survey of automatic parameter tuning methods for metaheuristics. *IEEE transactions on evolutionary computation*, 24(2):201–216.
- Koijen, R. S., Rodriguez, J. C., and Sbuelz, A. (2009). Momentum and mean reversion in strategic asset allocation. *Management science*, 55(7):1199–1213.
- Kramer, O. and Kramer, O. (2017). *Genetic algorithms*. Springer.
- López-Ibáñez, M., Cáceres, L. P., Dubois-Lacoste, J., Stützle, T. G., and Birattari, M. (2016). *The irace package: User guide*. IRIDIA, Institut de Recherches Interdisciplinaires et de Développements en
- López-Ibáñez, M., Dubois-Lacoste, J., Cáceres, L. P., Birattari, M., and Stützle, T. (2016). The irace package: Iterated racing for automatic algorithm configuration. *Operations Research Perspectives*, 3:43–58.
- Machado, A. E., Viana, R. T., Dalip, D. H., Cardoso, R. T., and da Cruz, A. (2022). Avaliação de estratégias de operação em swing trade baseadas em aprendizado de máquina. In *Anais do I Brazilian Workshop on Artificial Intelligence in Finance*, pages 69–80. SBC.
- Murphy, J. J. (1999). *Technical analysis of the financial markets: A comprehensive guide to trading methods and applications*. Penguin.
- Nascimento, O. S., Santos, F. G., and Ferreira, K. H. A. (2022). Previsão de preços de ações utilizando inteligência artificial. In *Anais do I Brazilian Workshop on Artificial Intelligence in Finance*, pages 37–47. SBC.
- Nuti, G., Mirghaemi, M., Treleaven, P., and Yingsaeree, C. (2011). Algorithmic trading. *Computer*, 44(11):61–69.
- Okunev, J. and White, D. (2003). Do momentum-based strategies still work in foreign currency markets? *Journal of Financial and Quantitative Analysis*, 38(2):425–447.
- Osaba, E., Villar-Rodriguez, E., Del Ser, J., Nebro, A. J., Molina, D., LaTorre, A., Suganthan, P. N., Coello Coello, C. A., and Herrera, F. (2021). A tutorial on the design, experimentation and application of metaheuristic algorithms to real-world optimization problems. *Swarm and Evolutionary Computation*, 64:100888.