

Otimização Evolutiva Lexicográfica de um Portfólio de Estratégias Automatizadas no Mercado Futuro Brasileiro

Anderson C. Guedes¹, Carlos Alberto Rodrigues¹, Angelo C. Loula¹

¹Universidade Estadual de Feira de Santana (UEFS)
Feira de Santana, Bahia, Brasil

andersoncerg@gmail.com, carod@uefs.br, angelocl@uefs.br

Abstract. *A set of automated trading strategies in capital markets can be organized into a portfolio seeking to maximize returns and minimize losses. The best arrangement for the portfolio requires assigning optimal weights to each strategy, considering different financial indicators. This article proposes the application of an evolutionary algorithm with a lexicographical approach to optimize a portfolio of automated strategies applied to the Brazilian future market. The experiments consider different objective functions of financial indicators, with different orderings, in addition to optimization conditions and temporal variations, applying historical data from future indexes mini-contracts of the Ibovespa and US dollar.*

Resumo. *Um conjunto de estratégias automatizadas de negociação em mercados de capitais pode ser disposto em um portfólio buscando maximização de rendimentos e minimização de perdas. A melhor combinação para o portfólio requer a atribuição de pesos ótimos para cada estratégia, considerando diferentes indicadores financeiros. Neste artigo é proposta a aplicação de um algoritmo evolutivo com abordagem lexicográfica para otimizar um portfólio de estratégias automatizadas aplicadas ao mercado futuro brasileiro. Os experimentos consideram diferentes funções-objetivo de indicadores financeiros, com diferentes ordenações, além de condições de otimização e de variações temporais, aplicando dados históricos de minicontratos do índice futuro do Ibovespa e do dólar.*

1. Introdução

Os investimentos automatizados começaram na década de 70 e a cada ano vem aumentando o percentual dessas negociações nas principais bolsas de valores do mundo [Haynes and Roberts 2017, Paraná 2017]. Estima-se que na bolsa de valores de Nova Iorque mais de 70% das negociações são automatizadas, sendo utilizadas tanto por pessoas físicas quanto pela indústria de fundos de investimentos e instituições financeiras [Nutti et al. 2011, Glantz and Kissell 2014].

No Brasil, a automatização se tornou mais popular a partir de 2013 com a implantação de um sistema atualizado de negociações pela BM&FBovespa e disponibilização pelas grandes corretoras de plataformas com suporte para algoritmos automatizados de negociação [Paraná 2017]. Atualmente, estima-se que mais de 40% das negociações na Bolsa de São Paulo sejam realizadas de modo automatizado [Paraná 2017]. Essas negociações geralmente se concentram em contratos no mercado

futuro por apresentar a vantagem de permitir alavancagem e baixa corretagem, diminuindo os custos de negociação. No mercado futuro, contratos financeiros derivativos, tipicamente de dólar ou Ibovespa, são ativos negociados com uma data e preço futuros predeterminados.

Algoritmos de negociação podem implementar estratégias envolvendo análise técnica ou análise fundamentalista [Nutti et al. 2011]. A análise técnica busca prever as movimentações dos preços dos ativos financeiros no presente com base em padrões existentes de modo consistente nas variações dos preços em períodos passados.

Os investidores usualmente combinam suas estratégias automatizadas distribuídas igualmente em um portfólio para aumentar os lucros, no entanto, tais estratégias adotadas de modo independente estão sujeitas a períodos prolongados de perdas, conhecidos como *drawdown* ou redução de capital devido a períodos de alta correlação. Outra característica importante desses portfólios é que as negociações geralmente começam e terminam no mesmo dia, gerando uma grande quantidade de negociações. Para minimizar esse problema, pode-se aplicar os mesmos princípios de diversificação de ativos sugeridos por Markowitz [Markowitz 1952] a um portfólio de estratégias automatizadas. Nesse cenário, os ativos são as estratégias e os objetivos são a maximização dos rendimentos e a minimização das perdas do portfólio. Logo, a melhor combinação para o portfólio requer a atribuição de pesos ótimos para cada estratégia.

Essa busca por pesos ideais pode ser caracterizada como um problema de otimização. Tal problema requer uma ou mais soluções viáveis que produzem valores máximos (ou mínimos, se o objetivo for minimizar) de um ou mais objetivos, desde que consideradas as restrições de domínio [Deb 2001]. Se apenas um objetivo for passível de otimização, o problema é denominado “mono-objetivo”. Caso exista uma solução para esse problema, ela é considerada “ótima”. Havendo mais de um objetivo otimizável, a otimização é denominada “multiobjetivo”.

Na área de finanças, a busca simultânea por um rendimento máximo e um risco mínimo é um caso de otimização multiobjetivo. Particularmente, valores elevados de retorno e níveis baixos de risco são conflitantes entre si: não é possível maximizar o primeiro sem prejudicar a minimização do segundo. Portanto, pode não ser possível obter apenas uma solução capaz de otimizar os dois objetivos simultaneamente. De qualquer modo, para lidar com essa dificuldade, a tarefa de otimização dessas soluções é realizada por alguma rotina computacional [Deb 2001].

Vale ressaltar que soluções obtidas com dados utilizados na etapa de treino não são condições suficientes para validar uma otimização. Como as soluções podem estar superadaptadas (*overfitting*) aos dados de treino, é necessário aplicá-las em um conjunto separado de dados (i.e. dados de testes) para avaliar o seu desempenho. Um dos tipos de validação mais utilizados é o *backtest*, que abrange uma variedade de métodos que avaliam o desempenho de estratégias em dados históricos. O método *walk forward* [Pardo 1992] é um destes, no qual o desempenho é avaliado somente em negociações *out-of-sample* em período posterior ao da otimização.

O objetivo do trabalho descrito neste artigo, portanto, é avaliar o desempenho de um algoritmo evolutivo que utiliza uma abordagem lexicográfica para otimizar funções-objetivo relacionadas a um portfólio de estratégias automatizadas aplicadas ao mercado

futuro brasileiro. Os resultados obtidos com esse método foram comparados aos de um *baseline* formada por um portfólio cuja distribuição de contratos entre as estratégias é equitativa. Experimentos de *backtest* por *walk forward* foram realizados para avaliar diferentes seleções e ordenações de indicadores financeiros, condições de possível superotimização em períodos de treino e variações de períodos temporais de otimização e de aplicação do portfólio. A otimização dos indicadores de mercado traz uma contribuição para investidores que fazem uso desses portfólios, pois a partir da análise de desempenho é possível avaliar o impacto causado, por exemplo, pela ordem de prioridade desses indicadores.

2. Trabalhos Relacionados

A aplicação de técnicas de Inteligência Computacional para finalidade de tomada de decisão em diversos segmentos do mercado de finanças é tema de trabalhos de diversos autores [Cavalcante et al. 2016], porém, em geral, estão buscando a predição do mercado por uso de aprendizado de máquina. Computação evolutiva também já foi aplicada para otimização neste contexto, como por exemplo para geração automatizada de regras para estratégias de negociação para o mercado de ações [Pimenta et al. 2018] e para o mercado futuro [Cacique and Pereira 2020]. Há ainda trabalhos que buscam obter portfólios ótimos por Algoritmos Evolutivos que utilizam apenas um indicador de mercado para avaliar a carteira de investimentos, por exemplo, com a função-objetivo do índice de Sharpe [Liao et al. 2015] ou da Semi-Variância Média e de retorno diário [Macedo et al. 2017].

No campo das aplicações de técnicas computacionais em finanças, [Liao et al. 2015] aborda o problema da seleção de portfólios que apresentem baixo risco e alto retorno, através do índice de Sharpe combinado a um Algoritmo Genético. Para calcular o risco do portfólio, o estudo adotou como método a padronização de fundos de investimento para reduzir a complexidade computacional. Além disso, o estudo aplicou janelas deslizantes na série temporal com o objetivo de evitar a superadaptação das soluções aos dados. De acordo com os autores, os resultados obtidos mostraram que o método proposto consegue identificar o melhor portfólio, além de obter um desempenho mais eficiente quando comparado ao método tradicional de avaliação de risco.

Uma aplicação de algoritmos evolutivos para produção de portfólios no mercado brasileiro de futuros pode ser encontrada em [Cacique and Pereira 2020]. O estudo tem como objetivo inovar o desenvolvimento de algoritmos de negociações automatizadas baseados em dados históricos de séries financeiras. Os autores propuseram um modelo - denominado *Pattern Searcher* - inspirado em métodos de aprendizado não-supervisionado e otimização evolutiva. O trabalho usa um algoritmo genético aliado a um conjunto específico de indicadores financeiros para encontrar uma região de busca que produza maiores retornos. A partir do método *Pattern Searcher*, foram produzidos os portfólios de estratégias automatizadas, sendo estes também otimizados pelo algoritmo genético. Os resultados obtidos mostraram que o sistema foi capaz de produzir estratégias de negociação e portfólios bastante lucrativos, superando índices de mercado como a taxa Selic e o Ibovespa.

Estudos sobre o uso de métodos de otimização lexicográfica no mercado de capitais são limitados, particularmente para otimização de portfólio de investimentos. Alguns trabalhos encontrados realizam aplicações com programação linear ou inteira mista

[Sawik 2013], mas poucos realizam otimização evolutiva lexicográfica de portfólio. Em [Aranha and Iba 2007], é realizada a otimização mono-objetivo por índice Sharpe dos pesos em portfólio de ativos financeiros e também uma otimização lexicográfica probabilística que inclui o objetivo de distância para o melhor indivíduo da geração, porém não foi utilizada outra função objetivo de índice financeiro.

3. Metodologia

A otimização de portfólio de estratégias automatizadas de negociação que operam no mercado futuro brasileiro pode ser modelada como um problema de distribuição ótima de pesos dentre as estratégias disponíveis, considerando critérios multi-objetivos de indicadores financeiros de interesse. Esta otimização é realizada com base na premissa de que tal distribuição pode capturar padrões de um período de tempo anterior com a finalidade de ser aplicada em um período de tempo posterior. Existem, portanto, desafios relacionados à escolha de indicadores financeiros, de superadaptação e de janelas de tempo a serem considerados ao realizar a otimização desta distribuição.

3.1. Problema de Otimização

Considerando um conjunto E de estratégias de negociação automatizadas e uma quantidade de M minicontratos disponíveis para negociação em um portfólio, uma distribuição de minicontratos (pesos) entre essas estratégias pode ser representada por um vetor $\vec{q} = (q_1, q_2, q_3, \dots, q_n)$ com n estratégias compondo um portfólio. Cada uma das estratégias pode receber uma quantidade positiva inteira e par¹ $q_i \in [0, M]$ de minicontratos, de forma que o total de minicontratos distribuídos seja M . Resguardadas as restrições, o espaço de busca das variáveis de decisão é composto por todas as combinações de números naturais factíveis que representam as distribuições de minicontratos entre estratégias do conjunto E .

Uma distribuição de contratos precisa ser avaliada de maneira objetiva no espaço de funções-objetivo $\vec{F}(q)$. Neste artigo, foi considerado um espaço multi-objetivo com três indicadores financeiros. Assim, o problema de otimização do portfólio de estratégias automatizadas de minicontratos futuros pode ser descrito formalmente como

$$\begin{aligned} \max_{\vec{q}} \quad & \vec{F}(q) = (f_1(\vec{q}), f_2(\vec{q}), f_3(\vec{q})) \\ \text{sujeito a} \quad & q_i = 2k, \quad k \in \mathbb{N} \\ & \sum_{i=1}^n q_i = M \end{aligned} \tag{1}$$

A otimização dos objetivos $f_1(\vec{q})$, $f_2(\vec{q})$ e $f_3(\vec{q})$ será realizada pelo método a priori de ordenação lexicográfica, na qual os objetivos são ordenados por preferência e avaliados sequencialmente segundo esta ordem. Como objetivos, serão considerados os indicadores financeiros de Retorno do portfólio R , Volatilidade (desvio-padrão) do portfólio V , Índice de Sharpe SH , Semi-Desvio SD e Índice de Sortino SO (cf.

¹As estratégias negociam quantidades pares de contratos para que possam concluir a negociação em duas etapas (i.e., com realização parcial).

[Schwager 2017] para formulações). Como trata-se de um problema de maximização serão utilizados $-V$ e $-SV$ na otimização.

O Retorno R do portfólio é a soma ponderada dos retornos geométricos médios individuais das estratégias. A Volatilidade V é uma medida de risco calculada pelo desvio-padrão dos retornos percentuais das estratégias. Já o Semi-Desvio SD é uma versão alternativa do desvio-padrão, que considera somente risco negativo e os retornos positivos são desconsiderados. O Índice de Sharpe equivale à razão entre R e V e o Índice de Sortino é a razão entre R e SD , e ambos são medidas de ponderação da rentabilidade diante de risco.

Se o objetivo é determinar a proporção entre o retorno e o risco do portfólio de investimento, os índices SH e SO seriam as métricas de maior relevância entre as consideradas neste estudo. Logo, tais índices teriam prioridade em uma otimização. Desse modo, os fatores que compõem os índices também seriam otimizados, ainda que indiretamente. Por coerência, os fatores individuais também são agrupados no processo de otimização, de acordo com os seus respectivos índices. Em um algoritmo lexicográfico, dois arranjos possíveis em ordem de prioridade seriam: $[SH, R, V]$ e $[SO, R, SD]$. Uma vez que a relação retorno/risco já está sendo otimizada, é natural - para um investidor racional - assumir que os retornos (R) tenham prioridade sobre a volatilidade (V ou SD).

3.2. Otimização por Algoritmo Evolutivo Lexicográfico

O algoritmo evolutivo proposto parte de uma população inicial de vetores \vec{q} de distribuições de contratos, que após ser avaliada, é sujeita a uma seleção para reprodução por torneio binário, seguida de operações de mutação e recombinação para gerar uma população de filhos. A população de filhos somada à população dos pais passa por uma seleção de sobrevivência resultando em uma nova população para a próxima geração, repetindo-se o processo até um limite máximo de gerações. A população inicial tem 100 indivíduos gerados aleatoriamente e factíveis, isto é, que atendem as restrições do problema, conforme Eq.1.

Sendo um algoritmo lexicográfico, os operadores de seleção de indivíduos incorporam o método lexicográfico de otimização [Deb 2001, Fishburn 1974]. Assim, a comparação de indivíduos para fins de seleção é realizada de forma sequencial, pela ordem lexicográfica de preferência dos diferentes objetivos. Conforme esta ordem, definida a priori, um objetivo seguinte é considerado somente quando não é possível indicar o melhor indivíduo pelo objetivo anterior. Neste caso, os objetivos para avaliação dos indivíduos são os indicadores financeiros apresentados anteriormente. A seleção para reprodução é realizada por torneio binário, que aleatoriamente combina todos os indivíduos em pares para torneios. Em cada torneio, o indivíduo com maior aptidão conforme critério lexicográfico é selecionado para reprodução. Já a seleção de sobrevivência é determinística e seleciona os 100 indivíduos de maior aptidão por comparação lexicográfica, dentre aqueles da concatenação da população de pais com a população de filhos.

A reprodução gera uma população de filhos por aplicação de operadores de recombinação e mutação, com probabilidade de 50% de aplicação de recombinação e 100% de aplicação de mutação. A recombinação (*crossover*) de dois indivíduos realiza uma combinação das distribuições de contratos no portfólio de cada pai, respeitando

também as restrições do problema. O filho 1 inicia como uma cópia da distribuição do pai 1 e em seguida metade (se for par, ou o número par imediatamente inferior, caso contrário) dos contratos são transferidos para posições indicadas pela distribuição do pai 2. Para isso, uma posição com quantidade não-nula de contratos do filho 1 é selecionada aleatoriamente para transferir 50% de seus contratos para outra posição do filho 1. A posição receptora é escolhida aleatoriamente com probabilidade proporcional à quantidade de contratos que o pai 2 possui em cada posição. Este procedimento de transferência é repetido até que metade dos contratos tenham sido movidos entre posições. Ao final, o filho 1 será uma solução intermediária entre pai 1 e pai 2. O filho 2 é gerado por procedimento análogo, invertendo os papéis dos pais 1 e 2.

O operador de mutação realiza variações na distribuição de contratos de um indivíduo realizando transferências de contratos de um mesmo indivíduo. São selecionadas aleatoriamente 10% das posições da distribuição com quantidades não-nulas de contratos, para doar 50% dos seus contratos para uma outra posição também escolhida aleatoriamente. Na mutação, ambas posições são selecionadas aleatoriamente.

O número de gerações para interrupção da otimização pelo algoritmo evolutivo será uma variável de experimentação. Como a otimização é realizada em um período de tempo para ser aplicada em um período posterior, uma super-otimização pode não ser desejada, uma vez que conduziria a uma superadaptação a um padrão do passado do mercado que pode não ser válido em período posterior. A execução do algoritmo evolutivo por muitas gerações conduz a uma solução mais otimizada e a execução por menos gerações leva a uma solução sub-ótima e menos adaptada ao cenário.

3.3. Experimentação e Conjunto de Dados

Como contexto experimental para otimização será utilizado o método de *backtest*, que representa uma simulação histórica de como um portfólio proposto teria se saído caso fosse implementado ao longo de um período de tempo passado. Para este *backtest*, serão consideradas as estratégias automatizadas desenvolvidas pela empresa MetaRobôs² envolvendo padrões básicos de análise técnica e o conjunto de dados dos registros de negociações reais realizadas durante 57 meses entre os anos de 2015 e 2019. Os objetos de negociação utilizados pelas estratégias automatizadas são minicontratos de dois tipos: mini índice futuro do Ibovespa (WIN) e mini índice futuro do dólar (WDO). Há um total de 26 estratégias, sendo 18 aplicadas aos contratos WIN e 8 aos contratos WDO, incluindo estratégias de tendência e osciladores. Todas as estratégias negociam um valor fixo de dois contratos em cada operação. À exceção de apenas uma das estratégias, todos esses registros são de negociações pertencentes à categoria *Day Trade*³.

Os dados contém informações sobre a entrada e a saída de um estratégia específica em uma negociação e foram agrupados por data de operação para cada estratégia, uma vez que uma mesma estratégia pode ter mais de uma negociação no dia. O conjunto de dados utilizados nos experimentos então contém data, nome da estratégia e lucro (ou perda) das negociações do dia, que representa um valor em reais.

Para avaliar o desempenho em *backtest* de propostas de portfólio em relação às funções-objetivo, foi utilizado o método de *walk forward* [Pardo 1992]. Neste método

²<https://metarobos.com/>

³*Day Trade* é uma modalidade de negociações abertas e fechadas no mesmo dia.

há uma janela deslizante de tempo que é sub-dividida em janelas de *In-Sample*, utilizada para otimizar a distribuição para as funções-objetivo, e de *Out-of-Sample*, na qual ocorre a validação do portfólio proposto, obtido pela otimização anterior. A cada período, as janelas de *In-Sample* e *Out-of-Sample* são mutualmente exclusivas e sequenciais. Nos experimentos de avaliação, é realizada primeiro a otimização *In-Sample* aplicando o Algoritmo Evolutivo Lexicográfico para obter uma proposta de portfólio de distribuição de contratos. Este portfólio proposto é em seguida aplicado em um período imediatamente posterior (*Out-of-Sample*) para avaliar seu desempenho, simulando um processo de negociação real no qual o portfólio é selecionado considerando dados do passado para ser aplicado no presente.

A otimização do portfólio na janela *In-Sample* tem como objetivo capturar padrões de mercado existentes naquele período que possam ser aplicados no período posterior da janela de *Out-of-Sample*. Consequentemente, o tamanho destas janelas pode afetar o desempenho do portfólio. Janelas menores de *In-Sample* capturam padrões mais curtos e janelas maiores de *In-Sample* capturam padrões de maior duração. Por outro lado, janelas curtas de *Out-of-Sample* indicam que padrões passados serão aplicados por pouco tempo com demanda de re-otimização mais frequente, enquanto janelas longas de *Out-of-Sample* assumem um padrão passado como válido por mais tempo. Para avaliar o efeito do tamanho das janelas nos resultados do portfólio, serão considerados os seguintes tamanhos das janelas *In-Sample* (IS) e *Out-of-Sample* (OS), respectivamente: 3 meses IS com 3 meses OS, 3 meses IS com 6 meses OS, 6 meses IS com 3 meses OS e 6 meses IS com 6 meses OS. A escolha dessas janelas foi feita levando-se em conta que as negociações ocorrem no mesmo dia.

3.3.1. Comparação e Indicadores de Análise

Como *baseline* para comparação do portfólio otimizado, será utilizado um portfólio de pesos iguais, no qual o total de contratos é distribuído uniformemente entre as estratégias que recebem então quantidades iguais de contratos. Esta estratégia de pesos iguais corresponde à diversificação máxima do portfólio buscando minimizar riscos, não considerando padrões do passado para determinar um portfólio. Esta solução de pesos iguais será introduzida também na população inicial do algoritmo evolutivo para acelerar a otimização na janela *In-Sample*.

Para análise dos resultados, foram calculados os valores dos indicadores de Sortino, Semi-desvio, Sharpe, Volatilidade e Retorno, mesmo quando não são considerados como funções-objetivo na abordagem lexicográfica (Seção 3.2). De forma complementar, foi analisado o coeficiente de Gini da distribuição de contratos no portfólio, uma medida de dispersão que assume o valor de 1 para um portfólio perfeitamente concentrado e 0 para um igualmente ponderado.

4. Resultados e Discussão

Os experimentos realizados utilizaram os dados históricos de negociações de um conjunto de estratégias automatizadas para avaliar diferentes aspectos da otimização lexicográfica evolutiva, considerando variações das funções-objetivo, do número de gerações e do tamanho das janelas temporais.

4.1. Funções-Objetivo

A otimização lexicográfica considera objetivos ordenados por preferência e, portanto, a seleção dos objetivos assim como a ordenação dos objetivos influencia o padrão identificado. Os experimentos foram realizados com dois grupos de combinações de funções-objetivo. No Grupo 1, as ponderações rentabilidade-risco foram prioritárias e as ordenações lexicográficas foram: A) Sharpe, Retorno e Volatilidade (SH, R, V); e B) Sortino, Retorno e Semi-desvio (SO, R, SD). No Grupo 2, o retorno do capital foi priorizado e as ordenações foram: C) Retorno, Volatilidade e Sharpe (R, V, SH) ; e D) Retorno, Semi-desvio e Sortino (R, SD, SO). Para avaliar o desempenho obtido com as funções-objetivo, foram utilizadas 100 gerações e janelas IS e OS de tamanho de 3 meses, considerando um total de 18 janelas IS ou OS.

Tabela 1. Valores Médios e Desvio-Padrão dos Indicadores (Grupo 1)

	<i>Baseline</i>	(A) SH, R, V	(B) SO, R, SD
Sharpe	0.291 ± 0.083	0.575 ± 0.102	0.126 ± 0.112
Sortino	0.601 ± 0.207	0.300 ± 0.274	0.512 ± 0.806
Retorno	0.002 ± 0.001	0.004 ± 0.003	0.008 ± 0.008
Volatilidade	0.005 ± 0.003	0.039 ± 0.056	0.315 ± 0.649
Semi-desvio	0.002 ± 0.001	0.033 ± 0.058	0.263 ± 0.647

Tabela 2. Gini dos Portfólios do Grupo 1

	(A) SH, R, V	(B) SO, R, SD
Gini Médio	0.645	0.813

Tabela 3. Capital Acumulado do Portfólio (Grupo 1)

	<i>Baseline</i>	(A) SH, R, V	(B) SO, R, SD
Capital	618.457,00	664.004,00	707.569.00

A Tabela 1 mostra os valores médios por janela e os respectivos desvios-padrão dos indicadores de mercado ao longo das iterações das janelas OS aplicando portfólios obtidos na otimização da janela IS, em conjunto com resultados obtidos com o *baseline* de distribuição equitativa de contratos. A combinação *A* apresenta média superior para Sharpe na janela OS em relação à combinação *B* e à linha base. Isto indica que a otimização IS pela combinação *A* possivelmente capturou padrões de distribuição de pesos do portfólio que são consistentes para aplicação em janela OS. Já a otimização pela combinação *B* obteve alto valor de desvio padrão de Sortino e uma média inferior à linha base, indicando instabilidade na aplicação OS do padrão identificado em IS. Por outro lado, as otimizações para as combinações *A* e *B* conseguem obter retornos superiores à linha base nas janelas de OS, o que pode ser confirmado pelo capital acumulado ao final do período exibido na Tabela 3. Mas isso é acompanhado de um risco maior, observando a Volatilidade, que é superior na combinação *B*. Essa volatilidade excessiva pode ser consequência de uma concentração de contratos em poucas estratégias. Pela Tabela 2, verifica-se que de fato a combinação *B* tem índice de Gini superior e conduziu a portfólios mais concentrados.

Analogamente, as combinações *C* e *D* foram comparadas quanto aos indicadores de mercado (Tabela 4). O retorno obtido por estas combinações obtém média de retorno maior nas janelas OS, mas com desvio padrão também maior, indicando instabilidade nos retornos. O capital acumulado na Tabela 6 indica que é obtido um capital final maior na combinação *D* e menor na combinação *C*, em relação às anteriores. A grande volatilidade da combinação *C* reforça que a exposição ao risco prejudicou os retornos neste caso. Em ambas combinações, os portfólios são concentrados em poucas estratégias com índice de Gini alcançando valores próximos de 1 (Tabela 5). Ao comparar os resultados dos Grupos 1 e 2, pode-se evidenciar que ao priorizar o retorno na otimização IS, obtém-se um comportamento mais instável na aplicação OS com portfólios concentrados, indicativos de superadaptação. Portanto, um investidor não busca esta exposição ao risco e provavelmente consideraria a aplicação de uma das combinações do Grupo 1 na otimização do seu portfólio.

Tabela 4. Valores Médios e Desvio-Padrão dos Indicadores (Grupo 2)

	<i>Baseline</i>	(C) R, V, SH	(D) R, SD, SO
Sharpe	0.291 ± 0.083	0.050 ± 0.075	0.058 ± 0.086
Sortino	0.601 ± 0.207	0.153 ± 0.219	0.246 ± 0.442
Retorno	0.002 ± 0.001	0.018 ± 0.021	0.019 ± 0.019
Volatilidade	0.005 ± 0.003	13.243 ± 50.057	1.431 ± 1.995
Semi-desvio	0.002 ± 0.001	12.439 ± 50.093	0.585 ± 0.800

Tabela 5. Gini dos Portfólios do Grupo 2

	(C) R, V, SH	(D) R, SD, SO
Gini Médio	0.949	0.946

Tabela 6. Capital Acumulado do Portfólio (Grupo 2)

	<i>Baseline</i>	(C) R, V, SH	(D) R, SD, SO
Capital	618.457,00	616.115,00	777.020,00

4.2. Número de Gerações

Ao longo das gerações do algoritmo evolutivo, uma solução cada vez mais otimizada para os objetivos é identificada. Uma otimização excessiva de uma solução para uma janela de IS pode não conduzir a um comportamento desejável na janela de OS. Assim, foram realizados experimentos com interrupção em gerações distintas para avaliar se soluções sub-ótimas em IS podem levar a melhores soluções OS. Para as funções-objetivo, foi selecionada a configuração *B* que apresentou os melhores resultados para retorno e capital, com níveis intermediários de indicadores de risco. Para facilitar as comparações, foram mantidos os três meses para as janelas IS e OS.

Na Tabela 7 são exibidos resultados médios nas janelas OS. À medida que o número de gerações diminui, há pequenas variações nos indicadores, com redução das médias. A concentração de contratos também diminui pouco, ao analisar os índices Gini da Tabela 8. O capital acumulado também segue a mesma redução (Tabela 9). Isto indica

que o algoritmo evolutivo já captura uma padrão geral nas primeiras gerações e realiza uma otimização gradual e sem grande variação. Não é possível destacar, nesta condição, uma solução sub-ótima que possa ter comportamento diferenciado na janela OS.

Tabela 7. Valores Médios e Desvio-Padrão dos Indicadores (Combinação B)

	25 Ger	50 Ger	100 Ger
Sharpe	0.097 ± 0.109	0.116 ± 0.121	0.126 ± 0.112
Sortino	0.448 ± 0.824	0.580 ± 1.047	0.512 ± 0.806
Retorno	0.007 ± 0.011	0.007 ± 0.015	0.008 ± 0.008
Volatilidade	0.293 ± 0.511	0.307 ± 0.432	0.315 ± 0.649
Semi-desvio	0.077 ± 0.104	0.196 ± 0.415	0.263 ± 0.647

Tabela 8. Índices de Gini (Combinação B)

	25 Ger	50 Ger	100 Ger
Gini Médio	0.784	0.804	0.813

Tabela 9. Capital Acumulado do Portfólio (Combinação B)

	25 Ger	50 Ger	100 Ger
Capital	703.380,00	706.137,00	707.569,00

4.3. Tamanho das Janelas

Soluções obtidas por otimização trazem consigo padrões temporais da janela IS que são aplicada em uma janela OS. O tamanho da janela IS afeta o tipo de padrão que pode ser capturado pela otimização, janelas IS maiores permitem identificar padrões mais consistentes ao longo da janela. Já o tamanho da janela OS indica por quanto tempo o investidor decide manter sua escolha de portfólio, um período curto pode não ser suficiente para obter resultados e um período longo pode não manter um padrão do passado.

Com o objetivo de avaliar o impacto da escolha do tamanho das janelas e possíveis configurações de portfólio superadaptadas aos períodos IS e de detectar as melhores soluções em períodos OS, foram avaliadas quatro configurações de janelas IS-OS: 3 meses - 3 meses, 3 meses - 6 meses, 6 meses - 3 meses e 6 meses - 6 meses. Foi mantida a combinação *B* utilizada na seção anterior e 50 gerações de limite, por ser um cenário intermediário de otimização.

Após a avaliação dos indicadores (Tabela 10), os valores sugerem que as configurações com OS de 3 meses tem valores superiores de Sortino e de Sharpe em relação à janela OS de 6 meses. No entanto, observa-se uma menor concentração de contratos somente na configuração de IS de 6 meses e OS de 3 meses (Tabela 11). Quanto ao capital acumulado (Tabela 12), o maior valor é obtido pela configuração 3 meses - 3 meses, com grande diferença em relação as outras configurações. Assim, no geral, os resultados parecem evidenciar que as configurações de OS de 3 meses são superiores às de OS de 6 meses, sugerindo que aplicar o mesmo portfólio em períodos de maior duração gera resultados inferiores devido a mudanças nos padrões de mercado.

Tabela 10. Valores Médios dos Indicadores (AlgGenLex50G)

	IS=3 / OS=3	IS=3 / OS=6	IS=6 / OS=3	IS=6 / OS=6
Sharpe	0.116 ± 0.121	0.036 ± 0.050	0.126 ± 0.112	0.047 ± 0.144
Sortino	0.580 ± 1.047	0.102 ± 0.185	0.512 ± 0.806	0.130 ± 0.240
Retorno	0.007 ± 0.015	0.006 ± 0.005	0.008 ± 0.008	0.002 ± 0.011
Volatilidade	0.307 ± 0.432	0.207 ± 0.182	0.315 ± 0.649	0.266 ± 0.587
Semi-desvio	0.196 ± 0.415	0.149 ± 0.168	0.263 ± 0.647	0.085 ± 0.132

Tabela 11. Índices de Gini (AlgGenLex50G)

	IS=3 / OS=3	IS=3 / OS=6	IS=6 / OS=3	IS=6 / OS=6
Gini (Médio)	0.804	0.803	0.733	0.755

Tabela 12. Capital Acumulado do Portfólio (AlgGenLex50G)

	IS=3 / OS=3	IS=3 / OS=6	IS=6 / OS=3	IS=6 / OS=6
Capital	706.137,00	446.365,00	449.051,00	545.743,00

5. Conclusão

Esse estudo abordou o problema de avaliação de desempenho de um algoritmo evolutivo com abordagem lexicográfica que visa otimizar índices de mercado de um portfólio de estratégias automatizadas. As principais condições de otimização foram: escolha do conjunto e da ordem lexicográfica das funções-objetivo, número de gerações do algoritmo genético e diferentes tamanhos possíveis para as janelas IS e OS. Tais variáveis, presentes nos casos de uso dos experimentos, revelam a complexidade envolvida na análise dos resultados.

Os experimentos mostraram que a ordem lexicográfica de otimização das funções produz diferentes impactos na quantidade de capital acumulado. O número de gerações do algoritmo, no entanto, não produziu diferenças significativas na concentração de contratos pelas estratégias automatizadas e no capital acumulado do portfólio. O tamanho das janelas IS e OS, por sua vez, levou a diferenças significativas nos valores de capital.

Vale ressaltar, entretanto, que esse estudo não abordou outras sequências lexicográficas menos correlacionadas (e.g. Sortino, Sharpe e Semi-desvio) que poderiam, eventualmente, produzir um desempenho superior ao obtido com os experimentos realizados.

Em trabalhos futuros, algoritmos evolutivos multiobjetivos podem ser utilizados para avaliar portfólios com, pelo menos, três indicadores de mercado. Além disso, há a possibilidade de avaliar o desempenho de portfólios formados por subconjuntos das estratégias automatizadas que compuseram a carteira de negociações avaliada nesse estudo.

Referências

Aranha, C. and Iba, H. (2007). Modelling cost into a genetic algorithm-based portfolio optimization system by seeding and objective sharing. In *2007 IEEE Congress on Evolutionary Computation*, pages 196–203. IEEE.

- Cacique, F. V. and Pereira, A. C. M. (2020). Pattern searcher for decision making of trading agents using genetic algorithm. In *2020 IEEE Congress on Evolutionary Computation (CEC)*, pages 1–8.
- Cavalcante, R. C., Brasileiro, R. C., Souza, V. L., Nobrega, J. P., and Oliveira, A. L. (2016). Computational intelligence and financial markets: A survey and future directions. *Expert Systems with Applications*, 55:194 – 211.
- Deb, K. (2001). *Multi-Objective Optimization Using Evolutionary Algorithms*. John Wiley & Sons, Inc., New York, NY, USA.
- Fishburn, P. C. (1974). Exceptional paper—lexicographic orders, utilities and decision rules: A survey. *Management science*, 20(11):1442–1471.
- Glantz, M. and Kissell, R. (2014). *Multi-Asset Risk Modeling: Techniques for a Global Economy in an Electronic and Algorithmic Trading Era*. Academic Press.
- Haynes, R. and Roberts, J. S. (2017). Automated trading in futures markets-update. *White paper, Office of the Chief Economist, Commodity Futures Trading Commission*.
- Liao, B.-Y., Chen, H.-W., Kuo, S.-Y., and Chou, Y.-H. (2015). Portfolio optimization based on novel risk assessment strategy with genetic algorithm. In *2015 IEEE International Conference on Systems, Man, and Cybernetics*, pages 2861–2866.
- Macedo, L. L., Godinho, P., and Alves, M. J. (2017). Mean-semivariance portfolio optimization with multiobjective evolutionary algorithms and technical analysis rules. *Expert Systems with Applications*, 79:33–43.
- Markowitz, H. (1952). Portfolio selection. *The Journal of Finance*, 7(1):77–91.
- Nuti, G., Mirghaemi, M., Treleaven, P., and Yingsaeree, C. (2011). Algorithmic trading. *Computer*, (11):61–69.
- Paraná, E. (2017). A digitalização do mercado de capitais no brasil: tendências recentes. *Boletim de Economia e Política Internacional*, BEPI(25):43–71.
- Pardo, R. (1992). *Design, testing, and optimization of trading systems*, volume 2. John Wiley & Sons.
- Pimenta, A., Nametala, C. A. L., Guimarães, F. G., and Carrano, E. G. (2018). An automated investing method for stock market based on multiobjective genetic programming. *Computational Economics*, 52(1):125–144.
- Sawik, B. (2013). Survey of multi-objective portfolio optimization by linear and mixed integer programming. In *Applications of management science*. Emerald Group Publishing Limited.
- Schwager, J. D. (2017). *A Complete Guide to the Futures Market: Technical Analysis, Trading Systems, Fundamental Analysis, Options, Spreads, and Trading Principles*. John Wiley & Sons.