

Aplicação de Algoritmos de Otimização para a Minimização do Risco em um Portfólio de Negociações Automatizadas

Application of Optimization Algorithms for Risk Minimization in a Portfolio of Automated Trading Systems

Daniel Fernandes Campos¹, Carlos Alberto Rodrigues¹, Angelo C. Loula¹

¹Departamento de Ciências Exatas – Universidade Estadual de Feira de Santana (UEFS)
Feira de Santana, BA – Brasil

dfc152@gmail.com, carod@uefs.br, angelocl@uefs.br

Abstract. *The use of ATS (Automated Trading System) portfolios has become increasingly common in equity markets but this combination is accompanied by high volatility. To alleviate this situation, this work presents a study involving five optimization methods applied to an ATS portfolio operating in the Forex market to increase profits and reduce risk (drawdown), through the definition of optimal capital weights to be applied in each ATS. Technical analysis indicators were used as objective functions. A correlation filter and the Monte Carlo method for risk adjustment are also presented. In most cases, the optimizations based on Sharpe-Ratio and K-Ratio indicators obtained better results than the portfolio of equal weights and the correlation filter contributed to a decrease in risk but also with a decrease in profits.*

Palavras Chave. *Sistema de Negociação Automatizada. Finanças Computacionais. Negociação Algorítmica. Otimização de Portfólio.*

Resumo. *O uso de portfólios de ATS (Automated Trading System) têm se tornado cada vez mais comum nos mercados de renda variável mas essa combinação vem acompanhada de alta volatilidade. Para atenuar essa situação esse trabalho apresenta um estudo envolvendo cinco métodos de otimização aplicados a um portfólio de ATS atuando no mercado Forex para aumentar os lucros e diminuir o risco (drawdown), através da definição de pesos de ótimos de capital a serem aplicados em cada ATS. Foram utilizadas como funções objetivo indicadores de análise técnica. Também é apresentado um filtro de correlação e o método de Monte Carlo para o ajuste do risco. Na maioria dos casos, as otimizações baseadas nos indicadores Sharpe-Ratio e K-Ratio obtiveram resultados melhores que o portfólio de pesos iguais e o filtro de correlação contribuiu com a diminuição do risco mas também com a diminuição dos lucros.*

Keywords. *Automated Trading System. Computational finance. Algorithmic trading. Portfolio Optimization.*

1. Introdução

Com a digitalização das bolsas e corretoras houve o surgimento dos chamados Automated Trading System (ATS), que consistem em sistemas que realizam as negociações de uma forma automática, não havendo mais a necessidade de um usuário humano estar realizando as operações [Huang et al. 2019, Borch and Min 2022]. Os ATS podem, por exemplo, operar adotando diferentes estratégias, negociar em inversões de tendências ou tentar identificar padrões de negociação. Os portfólios de investimentos começaram a ficar mais robustos uma vez que algoritmos passaram a fazer suas operações de modo automático e até mesmo em alta frequência de negociações [Păuna 2018, Aldridge 2013]. Essa nova composição de portfólio gerou a oportunidade de serem feitas otimizações com o objetivo de obter uma performance melhor em seus indicadores, tais como o Sharpe-Ratio, Lucro, K-Ratio, dentre outros. Algumas estratégias realizadas por esses sistemas podem ser vistas em [Hilpisch 2020], [Leshik and Cralle 2011], [Aldridge 2013] e [Parikh and Shah 2015].

Por outro lado existem portfólios que não utilizam quaisquer meios de otimização para distribuição dinâmica do capital, tendo sido construídos simplesmente com a combinação de diversos ATS atuando em um mesmo mercado. Estes sistemas estão sujeitos a prolongados períodos de *drawdown* (redução de capital) e estudos tem sido feitos sobre como controlar esse risco [Maier-Paape 2018, Vezeris et al. 2020]. Nestes casos, através de otimizações seria possível melhorar o rendimento e/ou diminuir o risco destes portfólios através de um rebalanceamento do posicionamento do capital dentre os ATS do portfólio. Deste modo, alguns problemas como perdas consequentes e distribuição não uniforme entre os ATS que podem potencializar os riscos da carteira, poderiam ser minimizados. Algumas das otimizações usadas atualmente são descritas em [Bigiotti and Navarra 2019] e [Cavalcante et al. 2016] abordando diversos modelos aplicados a portfólios de ATS e ações. Por outro lado, observa-se na literatura que ainda são raros os trabalhos que aplicam a Inteligência Computacional nesses sistemas e por esse motivo é justificável que sejam feitos estudos que avaliem o uso desses algoritmos nessa área, que é onde se encontra a motivação desse trabalho.

Neste artigo será apresentada uma análise da aplicação de diferentes abordagens de otimização de um portfólio composto de ATS atuando no mercado Forex de moedas em contas reais, buscando incrementar o retorno em um nível de risco similar ou inferior ao portfólio sem otimização. Como linha de base utilizou-se uma distribuição igualitária de pesos entre os ATS. As otimizações foram avaliadas aplicando-se testes com dados históricos (*backtesting*) utilizando a metodologia *Walk-Forward* (WF) e foi utilizado um controle de risco através da aplicação do método de Monte Carlo.

O objetivo deste trabalho é comparar os resultados da aplicação de algoritmos de otimização em portfólios de ATS que utilizem Inteligência Computacional com os resultados sem otimização, para verificar se é possível melhorar a rentabilidade desses sistemas. Os resultados indicam que a otimização tende a melhorar os resultados ao passo que a aplicação de filtro para eliminação da correlação contribui para a diminuição do risco mas também dos lucros.

2. Trabalhos relacionados

Trabalhos anteriores tratam do tema da otimização de ações, como por exemplo [Macedo et al. 2017], onde apresenta uma comparação dos resultados das otimizações multiobjetivas NSGA II e SPEA 2 combinadas com análise técnica e aplicadas a um portfólio de ações de diferentes mercados. Os resultados foram superiores para o NSGA II e mostram como o uso de indicadores de análise técnica pode influenciar a fronteira eficiente. Porém com o surgimento dos ATS e de seus respectivos portfólios, estudos começaram a ser publicados visando a sua otimização. [Raudys 2013] e [Raudys and Pabarškaitė 2012] produziram estudos pioneiros utilizando análise estatística multivariada para otimização, verificando a influência da quantidade de ATS, a correlação entre si e sua matriz de covariância para determinar os pesos atribuídos aos elementos. O indicador Sharpe Ratio foi utilizado com função objetivo.

[Freitas et al. 2013] destacam a importância do portfólio para tornar o sistema adaptativo às mudanças do mercado. Apresentam uma arquitetura de ATS descentralizada, na qual o processo de análise de entradas e saídas é decomposto e sinais são gerados para comunicação entre as partes, podendo operar com diferentes estratégias. Assim tendo um sistema distribuído com pouca dependência entre os módulos, pode-se utilizar hardware de alta performance para cada parte do sistema.

[Contreras et al. 2017] desenvolveram a geração de ATS através de uma estratégia de evolução gramatical, que segue um processo evolucionário guiado por uma gramática em que cada ATS define um conjunto de indicadores que serão utilizados nas negociações. Cada indicador é associado a um peso de acordo com os resultados, podendo o peso ser aumentado ou diminuído. Diversos indicadores são levados em consideração para a tomada de decisão de comprar ou vender. Para realizar essa otimização multi-objetivo, foi utilizado o algoritmo genético NSGA -II. O NSGA -II foi escolhido devido ao número reduzido de objetivos, que podem ser acrescentados ou removidos. Os resultados obtidos com a evolução gramatical foram superiores ao algoritmo genético tradicional e o método de comprar e manter *buy and hold*.

Em um trabalho mais recente, [Guedes et al. 2021] fizeram uma avaliação do desempenho de um algoritmo evolutivo que utiliza uma abordagem lexicográfica para otimizar funções-objetivo relacionadas a um portfólio de ATS aplicadas ao mercado futuro do Brasil. Os resultados obtidos com esse método foram comparados aos de um portfólio cuja distribuição de contratos entre as estratégias é equitativa. Diferentes variáveis foram analisadas tais como ordenação de indicadores financeiros, condições de possível superotimização em períodos de treino e variações de períodos temporais de otimização do portfólio. Essa análise apresentou o impacto causado pela ordem de prioridade desses indicadores.

3. Metodologia

O problema a ser analisado neste trabalho é a otimização de pesos para diferentes ATS compondo um portfólio, para maximizar um determinado indicador. As seleção de ATS e os dados de negociações foram obtidos através da plataforma Myfxbook¹, na qual são compartilhadas as informações das negociações realizadas por ATS proprietários utilizando diferentes estratégias baseadas em Análise Técnica atuando no mercado Forex de

¹www.myfxbook.com

moedas em contas reais envolvendo negociações que levam em conta barras de 15 minutos. Foram utilizadas as negociações dos ATS Cyborg, Empire of Scalper, Night Owl, Advanced Scalper, Best Scalper, Avenger, Night Walker e ForexRealProfit, cada um atuando em diversos pares de moedas para o período de janeiro de 2018 a dezembro de 2019. Os pesos atribuídos aos ATS correspondem a frações do lote padrão de 100.000 dólares, sendo fixo para cada ATS.

Foram escolhidos como alternativas de funções-objetivo para otimização, os indicadores Sharpe Ratio e K-Ratio, que representam uma ponderação entre retorno e risco, e o indicador Lucro, para avaliar o efeito de uma otimização somente por ganhos com potencial maior risco [Katz and McCormick 2000]. O indicador de Sharpe-Ration pode ser obtido pela seguinte razão:

$$SR = \frac{R_p}{\sigma_p}$$

onde o R_p corresponde ao retorno do portfólio e σ_p corresponde ao desvio padrão do retorno portfólio.

O indicador de K-Ratio pode ser obtido pela seguinte razão:

$$K = \frac{IRLR}{n \cdot \sigma_p}$$

onde $IRLR$ corresponde à inclinação da reta obtida através de uma regressão linear de quadrados mínimos sobre o retorno cumulativo do portfólio, σ_p corresponde ao desvio padrão da regressão e n ao número de amostras.

Os algoritmos aplicados para a otimização do portfólio foram os métodos *Sequential Least Squares Programming* (SLSQP), *Hill Climbing*, *Simulated Annealing*, Monte Carlo, e Algoritmo Genético. Também foi aplicado um filtro de correlação para remover pares de moedas com correlação maior que 30%, em harmonia com o que foi previsto pela Teoria Moderna de Portfólios, conforme pode ser visto em [Romero Moreno 2011].

Para avaliação dos portfólios, foi utilizada a metodologia *Walk Forward* com períodos de 3 meses de *insample* (IS) para o período de janeiro de 2018 a dezembro de 2019 e 3 meses de *outsample* (OS) para o período de abril de 2018 até março de 2020.

3.1. Problema de Otimização de Pesos

A otimização tem por objetivo determinar qual fração do capital total do portfólio deve ser alocado para cada par ATS+moeda pertencente ao portfólio, tendo como espaço de variáveis de decisão os pesos x_1, x_2, \dots, x_n , correspondentes a frações do capital, onde cada variável de decisão x_i é um valor real tal que $0 \leq x_n \leq 1$ e $x_1 + x_2 + \dots + x_n = 1$. O processo de otimização irá buscar maximizar uma das funções objetivos, Sharpe Ratio, K-Ratio ou Lucro, a partir da avaliação de variações das variáveis de decisão.

Para métodos que requerem um ponto de partida, os valores iniciais correspondem a um portfólio em que todos os pares ATS+moeda disponíveis possuem o mesmo peso ($x_1 = x_2 = \dots = x_n = h$, tal que $h = 1/n$).

Para o método de minimização SLSQP, como se deseja realizar maximizações, as funções objetivos correspondem a função objetivo invertida, multiplicada por -1.

3.2. Filtro de Correlação

Uma das hipóteses a serem testadas era se ao colocar pares ATS+moeda com uma baixa correlação poderiam diminuir as perdas da carteira sem afetar os retornos. Para isso, é proposto o uso de um filtro de correlação obtido através do coeficiente de correlação de Pearson calculado sobre todos os retornos dos ATS. A filtragem foi realizada antes de iniciar a otimização, removendo os pares ATS+moeda cujo coeficiente de correlação esteja acima de 30% e essas correlações foram recalculadas até que não existam mais pares com correlação acima de 30%. Os dados com e sem filtragem serão otimizados para análise.

3.3. Métodos de Otimização

O método *Sequential Least Squares Programming* (SLSQP) é um método iterativo de resolução de problemas de otimização não linear e que podem ser expandidos para resolução por métodos de mínimos quadrados [Kraft 1988].

A otimização por *Hill Climbing* aplica uma heurística de busca local, partindo de um ponto inicial e buscando aprimoramento iterativo deste ponto selecionando pontos vizinhos com melhor valor objetivo [Nunes 2007]. Foi utilizado no problema um algoritmo padrão de *Hill Climbing* no qual a geração do vizinho é feita através da variação dos pesos de cada ATS+moeda, com a adição e subtração de 0.01, que corresponde a 1% de variação em relação ao valor máximo e mínimo que o peso pode assumir. A busca acontece até que não hajam mais vizinhos do ponto atual que apresentem melhora no resultado.

Simulated Annealing é outra heurística de busca que realiza minimização iterativa, semelhante ao *Hill Climbing*, selecionando pontos vizinhos de melhor valor objetivo, porém permitindo a escolha de pontos vizinhos de pior valor objetivo aplicando um procedimento probabilístico [Nunes 2007]. Para o procedimento de geração de vizinhos é verificado se um passo pode ser dado em uma determinada direção, variando o peso de um determinado par ATS+moeda, de forma similar ao procedimento do *Hill Climbing*. Caso positivo, este ponto será usado para próxima iteração e caso contrário, é dada uma chance de que esse ponto seja escolhido na próxima iteração. Esse processo é repetido novamente, a precisão da busca é aumentada e o tamanho do passo é diminuído.

O método de Monte Carlo realiza repetidas amostragens aleatórias para resolver problemas que possam ser interpretados de forma probabilística [Kroese et al. 2014]. No caso da otimização de Monte Carlo, são geradas várias soluções factíveis aleatórias e escolhida a melhor solução [Dickman and Gilman 1989]. À medida que os pesos são gerados, um novo retorno é calculado até ser encontrado o conjunto de pesos que produz o melhor retorno.

Algoritmo Genético é um meta-método iterativo de busca e otimização, inspirado na evolução natural, baseado em uma população de soluções que, a cada geração, passam por um procedimento de seleção a partir da avaliação de cada indivíduo e em seguida por procedimentos estocásticos de variação dos indivíduos [Nunes 2007]. A seleção aplicada foi elitista, com seleção dos 5% melhores indivíduos para gerar a próxima geração. Após a seleção, iterativamente são escolhidos 2 indivíduos para passar por um processo de *crossover* de um ponto de corte, no qual o gene do novo indivíduo será composto da fusão de 2 pedaços de genes dos pais sendo escolhido um ponto de corte aleatoriamente. Quanto à mutação, foi determinado que para cada gene de cada novo indivíduo exista uma

chance de 4% que esse gene tenha seu valor incrementado em 10% e 4% que esse gene tenha seu valor incrementado de 10%, usando uma população total de 100 indivíduos.

3.4. Avaliação por Walk-Foward

Para a realização dos experimentos e a avaliação dos portfólios, foi aplicado um procedimento com os dados históricos da série temporal (*backtesting*) das negociações dos ATS [Pardo 2011]. Neste método o período total foi separado em diversos sub-períodos de tempo, utilizando um sub-período *insample* (IS) para otimização e um sub-período *outsample* (OS), após o período IS, para avaliação do portfólio. Assim a otimização é realizada obtendo-se os resultados do portfólio somente como os períodos OS.

Para a avaliação dos resultados das otimizações são analisados os indicadores de Maximum Drawdown (Max DD) e Retorno Anualizado (RA). O Max DD é um indicador de risco e corresponde à perda máxima observada de um pico de alta a um vale de baixa de um portfólio, antes que um novo pico seja atingido. O Retorno Anualizado é uma taxa de retorno para um determinado período inferior a um ano, mas calculada como se a taxa fosse para um ano inteiro.

3.5. Simulações de Monte Carlo para ajuste de risco

Para simular cenários para além dos disponíveis nos dados obtidos, foi realizado um procedimento de simulações de Monte Carlo para obter cenários de maior risco de modo que o *drawdown* do capital na otimização *insample* pudesse chegar até no máximo 20%, que é um valor geralmente tolerado pela maioria dos investidores [Queiroz and Rodrigues 2019]. Este ajuste foi realizado para verificar quão robusto é o método adotado ao se aumentar a alavancagem. Para isso, será necessário multiplicar todos os pesos dos ATS por um fator para o aumento do capital aplicado e consequentemente do risco.

Com a sequência de retornos *insample*, é feita a geração de um conjunto de 1000 sequências aleatórias com os mesmos retornos. A partir da geração desses conjuntos de sequências o capital aplicado a cada ATS foi multiplicado por um fator de calibração sucessivamente, até que seja encontrado um conjunto, cujo *drawdown* não excedesse 20% em 95% de suas sequências. Esse fator foi utilizado como multiplicador para o capital aplicado a cada período *outsample* de modo a aumentar o retorno e risco concordemente.

4. Resultados e discussão

Os portfólios cuja otimização foi realizada no período *insample* (IS) são avaliados pela sua operação no período *outsample* (OS). Estão incluídas as otimizações mono-objetivo, alternando a função objetivo entre K-Ratio (K), lucro (L) e Sharpe-Ratio (S). Foram repetidas as otimizações após a aplicação do filtro de correlação (C) para a remoção de ATS+moeda correlacionadas.

As Tabelas 1 e 2 resumem os resultados obtidos pela aplicação de cada método de otimização conforme a função objetivo. Nestas tabelas são apresentados os resultados das otimizações, com indicação da função objetivo aplicada e da utilização ou não do filtro de correlação, os valores do maior *drawdown* (Max DD) durante todos os períodos OS e do retorno anualizado (RA), considerando a variação de capital após todos os períodos OS. Além disso, é indicado um valor comparativo (multiplicador) do retorno em relação

ao retorno obtido com um portfólio de linha de base (Base Line), no qual os pesos dados a cada par ATS+moeda são iguais para todos os períodos, e também o desvio padrão dos retornos e o valor de Sharpe Ratio anualizado. O valor do comparativo corresponde então à razão entre o retorno da estratégia e o retorno da linha de base.

Tabela 1. Tabela de resultados das otimizações com os dados originais.

Nome	Objetivo	Filtro de Correlação	Max DD(%)	RA (%)	Comparativo	Desvio Padrão (%)	Sharpe-Ratio
SLSQP	Lucro	Não	2.06	10.73	9.47	0.28	2.17
SLSQP	Lucro	Sim	2.66	6.42	5.57	0.20	1.86
SLSQP	K-Ratio	Não	3.06	6.05	5.25	0.17	2.10
Genético	Lucro	Sim	3.23	5.72	4.97	0.21	1.57
Hill Climbing	Lucro	Não	0.90	5.44	4.71	0.12	2.68
Hill Climbing	Sharp-Ratio	Sim	0.91	4.29	3.70	0.01	2.47
Monte Carlo	Lucro	Sim	0.13	2.74	2.35	0.02	8.29
Monte Carlo	Sharp-Ratio	Sim	0.09	2.30	1.97	0.01	10.88
Genético	Sharp-Ratio	Não	0.42	2.28	1.95	0.03	4.06
Hill Climbing	K-Ratio	Não	0.22	2.16	1.85	0.03	3.57
Hill Climbing	K-Ratio	Sim	0.17	2.14	1.83	0.03	4.44
Anneling	Lucro	Sim	0.40	1.92	1.64	0.03	4.17
Anneling	Lucro	Não	0.37	1.92	1.64	0.03	3.87
Genético	Lucro	Não	0.29	1.86	1.59	0.02	4.74
Genético	K-Ratio	Não	0.34	1.83	1.56	0.2	4.54
Anneling	K-Ratio	Sim	0.42	1.82	1.56	0.03	3.78
Hill Climbing	Sharp-Ratio	Não	0.38	1.79	1.53	0.4	2.50
Anneling	Sharp-Ratio	Não	0.37	1.68	1.43	0.03	3.99
Monte Carlo	Lucro	Não	0.47	1.67	1.43	0.03	3.35
Anneling	K-Ratio	Não	0.30	1.65	1.41	0.02	4.24
Hill Climbing	Lucro	Sim	0.39	1.63	1.39	0.04	2.64
Anneling	Sharp-Ratio	Sim	0.37	1.58	1.35	0.02	3.96
Monte Carlo	K-Ratio	Sim	0.32	1.55	1.32	0.03	3.69
Monte Carlo	K-Ratio	Não	0.24	1.53	1.31	0.02	3.88
Genético	K-Ratio	Sim	0.23	1.52	1.29	0.03	3.40
Monte Carlo	Sharp-Ratio	Não	0.35	1.51	1.51	0.02	3.95
SLSQP	Sharp-Ratio	Sim	0.44	1.45	1.24	0.03	3.09
SLSQP	K-Ratio	Sim	0.49	1.24	1.06	0.03	2.81
Genético	Sharp-Ratio	Sim	0.33	1.24	1.24	0.02	3.17
Base Line	Sem otimização	Não	0.28	1.17	1.00	0.02	3.40

A Tabela 1 apresenta os resultados após a otimização. O máximo *drawdown* variou de 0.09 a 3.23%, indicando que os portfólios estavam assumindo valores baixos de risco. Observa-se que todos os métodos de otimização trouxeram retornos superiores ao Base Line mas alguns apresentaram *drawdown* maior, indicando que alguns métodos aumentaram o risco. Nesse aspecto destaca-se o método SLSQP otimizando o lucro, com os maiores valores de *drawdown* e desvio padrão. No outro extremo, encontram-se os métodos com o filtro de correlação, com os menores valores de *drawdown*, demonstrando sua eficiência em diminuir o risco. Mesmo assim, destaca-se a otimização de Monte Carlo com o Sharpe Ratio como função objetivo, com os menores *drawdown* e desvio padrão mas o maior Sharpe Ratio.

De acordo com a Tabela 2 após a aplicação do ajuste de risco, dentre as otimizações que ficaram acima do Base Line encontram-se 6 otimizações com foco em K-Ratio, 5 com foco em Sharpe-Ratio e 4 de lucro, assim ficando bem distribuídas dentre os objetivos. Quanto aos métodos encontram-se 4 com otimização do tipo *Hill Climbing*,

Tabela 2. Tabela de resultados das otimizações com simulações de Monte Carlo para ajuste de risco.

Nome	Objetivo	Filtro de Correlação	Max DD(%)	RA(%)	Comparativo	Desvio Padrão (%)	Sharpe-Ratio
Hill Climbing	K-Ratio	Não	53.94	2186.27	1.44	7.00	3.62
Monte Carlo	Lucro	Não	37.85	2090.12	1.33	5.33	3.97
Anneling	K-Ratio	Não	37.46	2054.77	1.29	4.60	3.36
Genético	Lucro	Não	28.41	2054.50	1.29	4.70	3.52
Anneling	Sharp-Ratio	Não	37.10	2024.60	1.26	4.31	3.61
Hill Climbing	Lucro	Não	53.94	2003.46	1.24	7.00	3.87
Genético	K-Ratio	Não	43.12	1972.72	1.21	4.32	3.52
Anneling	Lucro	Não	43.00	1962.68	1.20	5.75	3.50
Genético	Sharp-Ratio	Não	46.00	1955.28	1.19	6.02	3.37
Monte Carlo	Sharp-Ratio	Não	37.34	1871.32	1.11	4.52	3.49
Hill Climbing	Sharp-Ratio	Não	54.19	1868.96	1.11	7.10	3.86
Monte Carlo	Sharp-Ratio	Sim	26.92	1831.88	1.07	4.10	3.69
Monte Carlo	K-Ratio	Não	19.93	1827.29	1.07	4.01	3.79
Hill Climbing	K-Ratio	Não	36.58	1803.23	1.04	4.77	3.90
Anneling	K-Ratio	Não	30.03	1760.90	1.00	4.15	3.69
Base Line	Sem otimização	Não	53.94	1759.13	1.00	7.04	3.61
Anneling	Lucro	Sim	22.55	1750.42	0.99	3.82	3.60
Monte Carlo	K-Ratio	Não	48.68	1699.70	0.94	6.16	3.49
Anneling	Sharp-Ratio	Não	27.39	1687.93	0.93	4.19	3.63
Monte Carlo	Lucro	Sim	24.16	1683.71	0.93	3.70	3.92
Hill Climbing	Lucro	Sim	36.58	1651.52	0.90	4.87	4.23
Hill Climbing	Sharp-Ratio	Sim	37.03	1611.42	0.87	4.87	3.95
SLSQP	K-Ratio	Sim	49.32	1573.15	0.83	5.05	4.09
Genético	K-Ratio	Sim	49.72	1449.81	0.73	4.96	4.03
SLSQP	Sharp-Ratio	Sim	65.56	1242.79	0.57	6.90	2.97
Genético	Sharp-Ratio	Sim	62.30	1109.04	0.47	6.28	3.18
Genético	Lucro	Sim	100.00	-100.00	0.00	-	-
SLSQP	Lucro	Sim	100.00	-100.00	0.00	-	-
SLSQP	Lucro	Não	100.00	-100.00	0.00	-	-
SLSQP	K-Ratio	Não	100.00	-100.00	0.00	-	-

4 do tipo Monte Carlo, 4 por *Simulated Annealing* e 3 por Algoritmo Genético.

Apesar do *drawdown* no período IS ter sido mantido até 20% pelas simulações de Monte Carlo, o aumento do risco no período OS trouxe o aumento generalizado do desvio padrão dos retornos, *drawdowns* variando de 19,93% a 100%, significando a perda total do capital. Por sua vez, não houve uma alteração significativa no Sharpe Ratio das estratégias, visto que o aumento do retorno vem acompanhado com o aumento do desvio padrão. Este resultado demonstra que o ajuste de risco com esse método, caso seja feito, deve ter por alvo valores menores no período IS, visto que devido às mudanças do mercado, não há garantia de que o risco será o mesmo ao se passar do período IS para o OS.

Um fato importante notado foi a presença do portfólio de controle Base Line na região central da Tabela 2. Assim percebe-se que uma simples distribuição de pesos iguais entre as estratégias descorrelacionadas da carteira trazem bons resultados quando aplicado a portfólios de ATS.

Através dos testes feitos percebe-se a grande volatilidade nas otimizações com foco em lucro, tendo 3 das 4 otimizações que acabaram perdendo todo o capital inicial e

algumas ficaram também entre as mais lucrativas. Fica evidente que priorizar o lucro e ao mesmo tempo desconsiderar o risco não é recomendável, pois o risco deve ser controlado através de algum outro indicador.

Diversas otimizações obtiveram resultados superiores que o Base Line, sendo que objetivos que representam a relação lucro/risco (K-Ratio e Sharpe-Ratio) obtiveram uma maior quantidade de resultados superiores. De modo geral, pode-se observar que a otimização deve levar em consideração esses dois fatores fundamentais.

Quanto aos métodos de otimização, *Hill Climbing*, Monte Carlo e *Simulated Anneling* obtiveram uma quantidade maior de resultados superiores ao Base Line do que inferiores. A otimização SLSQP trouxe resultados inferiores ao Base Line.

A aplicação do filtro de correlação serviu tanto para diminuir os retornos quanto o *drawdown* das otimizações, indicando que para aumentar o controle do risco, deve-se abrir mão de uma parte dos lucros.

5. Conclusão

Este estudo apresentou diversas otimizações para um portfólio de ATS incluindo um filtro de correlação, para comparação com o portfólio sem otimização. A aplicação dos algoritmos seguiu a metodologia *Walk Forward* de três meses por período e utilizou como funções objetivos os indicadores K-Ratio, Sharpe-Ratio e Lucro.

O aumento do risco pretendido a não exceder um *drawdown* de 20% no *insample* não foi conseguido no *outsample* pelo método de Monte Carlo, indicando que a instabilidade do mercado não permite um ajuste rigoroso do risco. O filtro de correlação reduziu os retornos juntamente com o *drawdown*, sendo indicado para investidores mais conservadores.

As otimizações que tiveram uma quantidade maior de retornos superiores ao Base Line foram aquelas que tiveram como objetivo maximizar relações retorno/risco (K-Ratio e Sharpe-Ratio), indicando a importância de incluir indicadores que levem em conta as variações do capital e risco simultaneamente. Esse estudo por sua vez não é conclusivo no sentido de apontar uma otimização que seja melhor que as demais, mas indica resultados esperados para alternativas de otimização.

Uma limitação desse trabalho é que o portfólio sem pesos já havia produzido resultados positivos e portanto era de se esperar que as otimizações trouxessem resultados ainda melhores. Por outro lado, não seria possível converter um portfólio perdedor em um lucrativo, somente por meio de otimizações.

6. Agradecimentos

Este trabalho foi financiado pela Fundação de Amparo à Pesquisa do Estado da Bahia - Fapesb (Projeto nº 3427/2020).

Referências

Aldridge, I. (2013). *High-frequency trading: a practical guide to algorithmic strategies and trading systems*. John Wiley & Sons.

- Bigiotti, A. and Navarra, A. (2019). Optimizing automated trading systems. In Antipova, T. and Rocha, A., editors, *Digital Science*, pages 254–261, Cham. Springer International Publishing.
- Borch, C. and Min, B. H. (2022). Machine learning and social action in markets: From first- to second-generation automated trading. *Economy and Society*, 0(0):1–25.
- 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.
- Contreras, I., Hidalgo, J. I., and Nunez-Letamendia, L. (2017). A hybrid automated trading system based on multi-objective grammatical evolution. *Journal of Intelligent & Fuzzy Systems*, 32(3):2461–2475.
- Dickman, B. and Gilman, M. (1989). Monte carlo optimization. *Journal of optimization theory and applications*, 60(1):149–157.
- Freitas, F. D., Freitas, C. D., and De Souza, A. F. (2013). System architecture for on-line optimization of automated trading strategies. In *Proceedings of the 6th Workshop on High Performance Computational Finance*, WHPCF '13, New York, NY, USA. Association for Computing Machinery.
- Guedes, A., Rodrigues, C., and Loula, A. (2021). Otimização evolutiva lexicográfica de um portfólio de estratégias automatizadas no mercado futuro brasileiro. In *Anais do XVIII Encontro Nacional de Inteligência Artificial e Computacional*, pages 458–469, Porto Alegre, RS, Brasil. SBC.
- Hilpisch, Y. (2020). *Python for Algorithmic Trading From Idea to Cloud Deployment*. O'Reilly Media.
- Huang, B., Huan, Y., Xu, L. D., Zheng, L., and Zou, Z. (2019). Automated trading systems statistical and machine learning methods and hardware implementation: a survey. *Enterprise Information Systems*, 13(1):132–144.
- Katz, J. O. and McCormick, D. L. (2000). *The encyclopedia of trading strategies*. McGraw-Hill New York.
- Kraft, D. (1988). A software package for sequential quadratic programming. Technical Report DFVLR-FB 88-28, DLR German Aerospace Center – Institute for Flight Mechanics, Koln, Germany.
- Kroese, D. P., Brereton, T. J., Taimre, T., and Botev, Z. I. (2014). Why the monte carlo method is so important today. *Wiley Interdisciplinary Reviews: Computational Statistics*, 6.
- Leshik, E. A. and Cralle, J. (2011). *An introduction to algorithmic trading*. John Wiley & Sons Ltd.
- 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(C):33–43.
- Maier-Paape, S. (2018). Risk averse fractional trading using the current drawdown. *Journal of Risk*, 20(5):117–141.

- Nunes, L. (2007). In Sahni, S., editor, *Fundamentals of Natural Computing*. Chapman & Hall CRC - Computer and Information Science.
- Pardo, R. (2011). *The evaluation and optimization of trading strategies*. John Wiley & Sons.
- Parikh, V. and Shah, P. (2015). Stock prediction and automated trading system. *International Journal of Computer Science & Communication*, 6:104–111.
- Păuna, C. (2018). Automated trading software-design and integration in business intelligence systems. *Database Systems Journal*, pages 22–28.
- Queiroz, I. and Rodrigues, C. (2019). Comparação de métodos de position size nos mercados futuros do brasil. *Revista da FAE*, 22:67–82.
- Raudys, A. and Pabarškaitė, Ž. (2012). Discrete portfolio optimisation for large scale systematic trading applications. In *2012 5th International Conference on BioMedical Engineering and Informatics*, pages 1566–1570.
- Raudys, S. (2013). Portfolio of automated trading systems: Complexity and learning set size issues. *IEEE transactions on neural networks and learning systems*, 24(3):448–459.
- Romero Moreno, C. S. (2011). La teoría moderna de portafolio: Un ensayo sobre sus formulaciones originales y sus repercusiones contemporáneas. *Observatorio de Economía y Operaciones Numéricas - ODEON*, pages 105–118.
- Vezeris, D., Kyrgos, T., Karkanis, I., and Bizergianidou, V. (2020). Automated trading systems' evaluation using d-backtest ps method and wm ranking in financial markets. *Investment Management and Financial Innovations*, 17(2):198–215.