



**UNIVERSIDADE ESTADUAL DE FEIRA DE SANTANA**

Autorizada pelo Decreto Federal nº 77.496 de 27/04/76

Recredenciamento pelo Decreto nº 17.228 de 25/11/2016



**PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO**

**COORDENAÇÃO DE INICIAÇÃO CIENTÍFICA**

## **XXV SEMINÁRIO DE INICIAÇÃO CIENTÍFICA DA UEFS SEMANA NACIONAL DE CIÊNCIA E TECNOLOGIA - 2021**

### **Aplicação de Algoritmos Genéticos de Otimização para a minimização de risco em um Portfólio de Negociações Automatizadas**

**Daniel Fernandes Campos<sup>1</sup>; Angelo Conrado Loula<sup>2</sup> e Carlos Alberto Rodrigues<sup>3</sup>**

1. Bolsista FAPESB/CNPq, Graduando em Engenharia da Computação, Universidade Estadual de Feira de Santana, e-mail: [dfc152@gmail.com](mailto:dfc152@gmail.com)
2. Orientador, Departamento de Ciências Exatas, Universidade Estadual de Feira de Santana, e-mail: [angelocl@uefs.br](mailto:angelocl@uefs.br)
3. Participante do grupo de pesquisa Finanças Computacionais, Departamento de Ciências Exatas, Universidade Estadual de Feira de Santana, e-mail: [carod@uefs.br](mailto:carod@uefs.br)

**PALAVRAS-CHAVE:** Otimização; ATS; portfólio

### **INTRODUÇÃO**

Com a digitalização das bolsas e casas de câmbio houve o surgimento dos chamados Automated Trading System (ATS), que consistem em sistemas que realizam as negociações de uma forma automática no mercado de renda variável, assim não se tem a mais a necessidade de um usuário humano está realizando as operações, como pode ser visto em Pauna (2018), Lu e Alvarez (2016), Paraná (2017), Gao e Chan (2000), Aldridge (2013), Pardo (2011) e Parikh e Shah (2015).

Os ATSS podem operar adotando diferentes estratégias, negociar em inversões de tendências ou tentar identificar padrões de negociações. Assim, esses ATSS começaram a ficar mais robustos, onde portfólios passaram a ser compostos inteiramente desses sistemas que fazem essas operações automáticas, Pauna (2018) e Aldridge (2013). Com essa composição de portfólio com diversos ATS surge a oportunidade de serem feitas otimizações com objetivo de obter um lucro maior com menor risco, Katz e McCormick (2000), Gao e Chan (2000), Aldridge (2013) e Parikh e Shah (2015).

Isto significa que existem portfólios de ATSS que não se utilizam de quaisquer meios de otimização para distribuição dinâmica do capital e que através de otimizações é possível melhorar seu desempenho através de um rebalanceamento inteligente de pesos dentre os ATSS deste portfólio. Deste modo, alguns problemas passados por esses portfólios poderão ser contornados, como longos períodos de perdas, e distribuição não uniforme entre os ATSS, o que pode potencializar os riscos do portfólio.

### **METODOLOGIA**

As negociações foram realizadas no mercado de moedas (Forex) e obtidas pela plataforma myfxbook para os seguintes ATS: Advanced+Scalper-statement, Best+Scalper-statement, EOS\_STD\_risk-statement, Forex+Cyborg-statement, ForexRealProfitEA\_ICMarkets-statement, Night+Owl-statement, NightWalker+EA+and+NY+Close+Scalper-statement e WS-GBP+JPY-statement. O período utilizado foi de 01/01/2018 até 31/03/2020.

As operações são transformadas em uma tabela que mostra a variação de pips (fração de centavos, de acordo com cada moeda) por ATS+moeda por dia. Então esses dados são usados para realizar o walk forward (WF) com períodos de Out Sample (OS) e In Sample (IS) de 3 meses para cada otimização + objetivo. Após isso foi feito o mesmo processo porém habilitando um filtro de correlação para cada período de IS. No IS foi verificada a correlação entre os ATS+moeda e eliminados os que apresentaram valor acima de 30% e esse portfólio filtrado foi usado no IS e OS correspondente. Foram implementadas as otimizações: Monte Carlo, Simulated Annealing, Hill Climbing e por Algoritmo genético e usada uma otimização por Sequential Least Squares Programming (SLSQP)

O ajuste de risco consistiu em criar 1000 portfólios a partir do embaralhamento das operações diárias dos dados que foram utilizados, usando a variação diária de cada par (robô+moeda) para assim termos portfólios gerados aleatoriamente. Desse modo foi aplicado o método de monte carlo, e walk forward, para que a redução do capital (drawdown) não ultrapassasse 20%, ao longo do período de negociações.

## **RESULTADOS E DISCUSSÃO**

Para a figura 1, são apresentadas as otimizações seguindo o seguinte padrão: "Metodo\_da\_otimização"\_"CORR"\_"Objetivo\_da\_otimização", sendo "CORR" um marcador para indicar se essa otimização passou pelo filtro de correlação, caso não tenha indica que o filtro não foi usado, assim temos: "minimize" para otimização por SLSQP, "evolução" para algoritmo genético, "monte\_carlo" para monte carlo, "annealing" para Simulated Annealing e "encosta" para Hill Climbing. Já nos objetivos temos os indicadores "K" para k-ratio, "sharp" para sharp-ratio e "lucro" .

As otimizações apresentaram resultados superiores ao portfólio sem otimização (BS – base sample) e o drawdown com valores baixos (sendo o maior de 3,23%). Posteriormente foi usada a otimização com limitação de risco para até 20% com o método de monte carlo e os resultados são apresentados na figura 1.

Após a otimização de risco através do método monte carlo houve uma mudança na ordem dos retornos, provavelmente porque algumas estratégias possuem um melhor resultado de retorno/risco, assim quando foi aumentado o risco que as estratégias estavam se expondo a diferença entre elas foi sendo modificada.

Um fato notado foi a presença do grupo de controle BS, na região central da tabela. Assim, uma simples distribuição de pesos iguais entre elementos da sua carteira traz um resultado superior a algumas otimizações quando aplicado a portfólios de ATS.

Através dos testes feitos percebe-se a grande volatilidade com as otimizações com foco em lucro, tendo 3 das 4 otimizações que acabaram perdendo todo o capital inicial. Apesar desse estudo não ser conclusivo no sentido de apontar uma otimização que seja a melhor que as demais, porém foi observado que o filtro de correlação (pelo menos da forma como foi implementado) pode acabar eliminando bons elementos desnecessariamente e diminuindo o lucro do portfólio, sendo necessário talvez uma análise mais profunda na forma de filtragem.

	Retornos em PIPS	Max DrawDown In % das curvas	Periodo da otimização	Retorno anualizado em %	Comparativo com BS (Base Sample)	Sharp
encosta_K	1190209.28	53.94	2018-04-02 -> 2020-03-31	2186.27	1.436094	3.616590
monte_carlo_lucro	1103638.52	37.85	2018-04-02 -> 2020-03-31	2090.12	1.332076	3.967528
annealing_K	1072511.44	37.46	2018-04-02 -> 2020-03-31	2054.77	1.294675	3.361730
evolução_lucro	1072278.81	28.41	2018-04-02 -> 2020-03-31	2054.50	1.294396	3.522882
annealing_sharp	1046244.36	37.10	2018-04-02 -> 2020-03-31	2024.60	1.263114	3.607730
encosta_lucro	1028008.03	53.94	2018-04-02 -> 2020-03-31	2003.46	1.241202	3.865096
evolução_K	1001740.40	43.12	2018-04-02 -> 2020-03-31	1972.72	1.209641	3.518943
annealing_lucro	993219.93	43.00	2018-04-02 -> 2020-03-31	1962.68	1.199403	3.498256
evolução_sharp	986961.38	46.00	2018-04-02 -> 2020-03-31	1955.28	1.191883	3.366792
monte_carlo_sharp	917133.60	37.34	2018-04-02 -> 2020-03-31	1871.32	1.107982	3.494133
encosta_sharp	915207.39	54.19	2018-04-02 -> 2020-03-31	1868.96	1.105668	3.858687
monte_carlo_sharp_corr	885092.90	26.92	2018-04-02 -> 2020-03-31	1831.88	1.069484	3.694456
encosta_K_corr	862117.82	36.58	2018-04-02 -> 2020-03-31	1803.23	1.041878	3.904679
annealing_K_corr	828652.07	30.03	2018-04-02 -> 2020-03-31	1760.90	1.001668	3.686897
BS	827264.02	53.94	2018-04-02 -> 2020-03-31	1759.13	1.000000	3.608041
annealing_lucro_corr	820455.16	22.55	2018-04-02 -> 2020-03-31	1750.42	0.991819	3.598661
monte_carlo_K_corr	784109.10	20.86	2018-04-02 -> 2020-03-31	1703.41	0.948148	3.890926
monte_carlo_K	781265.04	48.68	2018-04-02 -> 2020-03-31	1699.70	0.944730	3.489494
annealing_sharp_corr	772292.74	27.39	2018-04-02 -> 2020-03-31	1687.93	0.933950	3.632477
monte_carlo_lucro_corr	769079.85	24.16	2018-04-02 -> 2020-03-31	1683.71	0.930089	3.918044
encosta_lucro_corr	744801.80	36.58	2018-04-02 -> 2020-03-31	1651.52	0.900918	4.227252
encosta_sharp_corr	715017.46	37.03	2018-04-02 -> 2020-03-31	1611.42	0.865131	3.950279
minimize_K_corr	687082.38	49.32	2018-04-02 -> 2020-03-31	1573.15	0.831566	4.094767
evolução_K_corr	600278.15	49.72	2018-04-02 -> 2020-03-31	1449.81	0.727267	4.026467
minimize_sharp_corr	465957.95	65.56	2018-04-02 -> 2020-03-31	1242.79	0.565876	2.968291
evolução_sharp_corr	386957.38	62.30	2018-04-02 -> 2020-03-31	1109.04	0.470953	3.177806
evolução_lucro_corr	-5000.00	100.00	2018-04-02 -> 2020-03-31	-100.00	0.000000	-1.148164
minimize_lucro_corr	-5000.00	100.00	2018-04-02 -> 2020-03-31	-100.00	0.000000	-1.148164
minimize_lucro	-5000.00	100.00	2018-04-02 -> 2020-03-31	-100.00	0.000000	-15.616468
minimize_K	-5000.00	100.00	2018-04-02 -> 2020-03-31	-100.00	0.000000	-8.546218

**Figura 1:** Tabela de resultados out sample das otimizações com controle de risco através do método monte carlo, mostrando o retorno em pips, o máximo drawdown em %, periodo de Out Sample, o retorno anualizado em %, comparativo com o resultado do base sample e o Sharpe-ratio . Fonte: Próprio autor

## CONCLUSÃO

Como resultado deste trabalho obtivemos que as melhores otimizações com objetivo específico foram em ordem: hill climbing com objetivo em maximizar o k-ratio, monte carlo com objetivo em maximizar o lucro, simulated annealing com objetivo em maximizar o k-ratio. Dentre os objetivos de otimização, as que tiveram um resultado

melhor que a base sample foi a otimização tendo como objetivo o indicador k-ratio e dos métodos de otimização levando em conta todos os objetivos temos simulated annealing e hill climbing.

Os melhores indicadores como objetivo para os métodos de otimização foram: monte carlo: maximizar lucro, Hill Climbing: maximizar k-ratio, simulated annealing: maximizar k-ratio, algoritmo genético: maximizar lucro, SLSQP : maximizar o k-ratio com filtro de correlação. Já para os indicadores, as melhores técnicas de otimização foram: k-ratio: hill climbing, sharpe-ratio: simulated annealing, lucro: monte carlo.

O controle de risco utilizando o método de monte carlo, ajustado para um mínimo de 20% no IS, não garante que esse limite será respeitado no OS, visto que o drawdown variou de 20 a 54%, conforme pode ser visto na figura 1.

## REFERÊNCIAS

- PĂUNA, CRISTIAN. 2018. Automated Trading Software - Design and Integration in Business Intelligence Systems. Database Systems Journal BOARD.
- Lu, NING e Alvarez, S. 2016. A machine learning approach to automated trading. Boston, MA, USA: Boston College Computer Science Senior.
- Paraná, E. (2017). A digitalização do mercado de capitais no brasil: tendências recentes.
- Katz, Jeffrey OWEN e McCormick, Donna L. 2000. The encyclopedia of trading strategies. McGraw-Hill New York.
- Gao, XIU e Chan, LAIWAN. 2000. An algorithm for trading and portfolio management using q-learning and sharpe ratio maximization. Em Proceedings of the international conference on neural information processing.
- Aldridge, IRENE. 2013. High-frequency trading: a practical guide to algorithmic strategies and trading systems, volume 604. John Wiley & Sons.
- Pardo, R. (2011). The evaluation and optimization of trading strategies, volume 314. John Wiley & Sons.
- Parikh, V. and Shah, P. (2015). Stock prediction and automated trading system. IJCS.
- de Castro, L.N. (2006). Fundamentals of Natural Computing: Basic Concepts, Algorithms, and Applications (1st ed.). Chapman and Hall/CRC. <https://doi.org/10.1201/9781420011449>
- de Castro, L.N. (2006). Fundamentals of Natural Computing: Basic Concepts, Algorithms, and Applications (1st ed.). Chapman and Hall/CRC. <https://doi.org/10.1201/9781420011449>