

Comportamento de agentes financeiros em um mercado artificial desenvolvido com o algoritmo *Particle Swarm Optimization*

Behavior of financial agents in an artificial market developed with the Particle Swarm Optimization algorithm

Comportamiento de agentes financieros en un mercado artificial desarrollado con el algoritmo *Particle Swarm Optimization*

Recebido: 04/05/2020 | Revisado: 04/05/2020 | Aceito: 05/05/2020 | Publicado: 12/05/2020

Kerolly Kedma Felix do Nascimento

ORCID: <https://orcid.org/0000-0001-7360-0961>

Universidade Federal Rural de Pernambuco, Brasil

E-mail: kerollyfn@gmail.com

Fábio Sandro dos Santos

ORCID: <https://orcid.org/0000-0002-0135-4981>

Universidade Federal Rural de Pernambuco, Brasil

E-mail: fabio.sandropb@gmail.com

Jader da Silva Jale

ORCID: <https://orcid.org/0000-0001-7414-1154>

Universidade Federal Rural de Pernambuco, Brasil

E-mail: jsj_ce@yahoo.com.br

Tiago Alessandro Espínola Ferreira

ORCID: <https://orcid.org/0000-0002-2131-9825>

Universidade Federal Rural de Pernambuco, Brasil

E-mail: taef.first@gmail.com

Resumo

Os mercados financeiros são sistemas complexos em que os negociadores interagem usando as mais variadas estratégias. Técnicas computacionais que usam agentes inteligentes podem auxiliar na tomada de decisão com o objetivo de maximizar os ganhos. Neste sentido, o objetivo deste artigo é observar o comportamento dos agentes financeiros participantes de mercados

simulados e inferir sobre os ganhos destes agentes. Por meio do algoritmo *Particle Swarm Optimization*, utilizamos dois grupos distintos de agente inteligentes: um grupo utiliza um grau de crença na previsão dos ativos para o dia seguinte e o outro grupo não utiliza, em que ambos interagem entre si buscando maximizar seus ganhos. Foi realizada uma pesquisa exploratória, com análise de natureza quantitativa sobre os dados. Os resultados mostraram que o grupo que usa a previsão é mais homogêneo, apresentando maiores ganhos de riqueza média, com concentrações de capital e de ações adquiridos variando de acordo com a série histórica de preços utilizada (Bitcoin, Ethereum, Litecoin ou Ripple). Diante disso, o procedimento implementado pode ser aperfeiçoado e utilizado para o desenvolvimento de ambientes que visem a melhor compreensão dos mercados financeiros e auxiliem os agentes participantes dos mercados na definição de estratégias de negociação que possibilitem a minimização de perdas financeiras.

Palavras-chave: Mercados financeiros; Simulação computacional; Otimização; PSO.

Abstract

Financial markets are complex systems in which traders interact using the most varied strategies. Computational techniques that use intelligent agents can assist in decision making in order to maximize gains. In this sense, the objective of this article is to observe the behavior of financial agents participating in simulated markets and infer about the gains of these agents. Through the Particle Swarm Optimization algorithm, we used two distinct groups of intelligent agents: one group uses a degree of belief in the prediction of assets for the next day and the other group does not use, in which both interact with each other seeking to maximize their gains. An exploratory research was carried out, with quantitative analysis on the data. The results showed that the group that uses the forecast is more homogeneous, showing higher average wealth gains, with capital and acquired stock concentrations varying according to the historical price series used (Bitcoin, Ethereum, Litecoin, or Ripple). Therefore, the implemented procedure can be improved and used for the development of environments aimed at a better understanding of financial markets and assisting market participants in the definition of trading strategies that enable the minimization of financial losses.

Keywords: Financial markets; Computational simulation; Optimization; PSO.

Resumen

Los mercados financieros son sistemas complejos en los que los comerciantes interactúan utilizando las estrategias más variadas. Las técnicas computacionales que utilizan agentes

inteligentes pueden ayudar en la toma de decisiones con el fin de maximizar las ganancias. En este sentido, el objetivo de este artículo es observar el comportamiento de los agentes financieros que participan en mercados simulados e inferir sobre las ganancias de estos agentes. A través del algoritmo Particle Swarm Optimization, utilizamos dos grupos distintos de agentes inteligentes: un grupo utiliza un grado de creencia en la predicción de activos para el día siguiente y el otro grupo no utiliza, en el que ambos interactúan entre sí buscando maximizar sus ganancias. Se llevó a cabo una investigación exploratoria, con análisis cuantitativos de los datos. Los resultados mostraron que el grupo que utiliza el pronóstico es más homogéneo, mostrando mayores ganancias medias de riqueza, con el capital y las concentraciones de acciones adquiridas que varían según la serie de precios históricos utilizada (Bitcoin, Ethereum, Litecoin o Ripple). Por lo tanto, el procedimiento implementado puede mejorarse y utilizarse para el desarrollo de entornos orientados a una mejor comprensión de los mercados financieros y ayudar a los participantes del mercado en la definición de estrategias comerciales que permitan la minimización de las pérdidas financieras.

Palabras clave: Mercados financieros; Simulación computacional; Optimización; PSO.

1. Introdução

Os mercados financeiros podem ser considerados sistemas complexos, uma vez que as interações individuais dos agentes participantes do mercado influenciam diretamente no comportamento deste. Cada negociador utiliza regras relativamente simples, se adapta e evolui a partir da experiência adquirida, resultando em um comportamento coletivo (Ramos & Neto, 2015). O estudo desse tipo de fenômeno pode ser feito através da modelagem baseada em agentes, ou seja, um modelo computacional que busca modelar o comportamento global a partir da observação das ações dos indivíduos (particularmente e coletivamente) (Mandes & Winker, 2017).

Nesse sentido, algoritmos de inteligência de enxame têm sido adotados na modelagem baseada em agentes, como Particle Swarm Optimization (Hitam et al., 2019), Ant Colony Optimization (Ahmed et al., 2019), Firefly (Tang et al., 2017) e Cuckoo Search (Lajevardy et al., 2017), entre outros. Tais algoritmos são inspirados em padrões complexos observados na natureza para a elaboração de sistemas computacionais (Serapião, 2017). Particularmente, o algoritmo Particle Swarm Optimization (PSO) é um dos mais populares, possuindo fácil implementação e empregando poucos parâmetros.

Este estudo teve por objetivo avaliar o desempenho dos participantes de um mercado

simulado implementado, investigando os valores dos ganhos médios obtidos por cada um.

Para isso, foi desenvolvido neste trabalho um mercado artificial baseado em agentes utilizando o algoritmo PSO, no qual se busca verificar se a partir de um grau de crença há aumento na riqueza dos agentes que acreditam na previsão dos preços em relação aos que não acreditam. Este grau de crença foi definido para atribuir ou não credibilidade ao valor previsto de preço de mercado dos ativos em cada negociação dos agentes financeiros no ambiente artificial. Para se estudar a dinâmica dos agentes, serão aplicadas as séries de preços de criptomoedas com destaque no cenário internacional, sendo utilizadas as séries diárias de preços das moedas Bitcoin, Ethereum, Litecoin e Ripple.

O restante deste artigo está estruturado como segue. Na seção 2 descreve-se a base de dados utilizada, o algoritmo *Particle Swarm Optimization* e a metodologia implementada. Na seção 3 são abordados os resultados e discussões do artigo. Por fim, na seção 4 encontram-se as considerações finais do artigo.

2. Metodologia

Tipo de Pesquisa

De acordo com Pereira et al. (2018), foi aplicado neste trabalho método estatístico, do tipo quantitativo e aplicação de testes, com o objetivo de obter uma generalização sobre o comportamento dos agentes participantes do mercado simulado.

Dados

Foram utilizadas séries históricas de preços diários das criptomoedas Bitcoin (BTC), Ethereum (ETH), Litecoin (LTC) e Ripple (XRP) disponíveis em <https://coinmetrics.io/data-downloads-2/>. O período de estudo de cada série pode ser visualizado na Tabela 1.

Tabela 1. Descrição dos períodos analisados das quatro criptomoedas.

Criptomoeda	Data do Início	Data do Fim
BTC	09/01/2009	01/07/2019
ETH	30/07/2015	30/06/2019
LTC	12/10/2011	01/07/2019
XRP	02/01/2019	30/06/2019

Fonte: Elaborado pelos autores.

Observa-se na Tabela 1 que os períodos de início de cada criptomoeda utilizada são diferentes, dentre as quais a primeira delas, Bitcoin (BTC), com informações das séries históricas de preços a partir do início de 2009.

Algoritmo *Particle Swarm Optimization*

O algoritmo *Particle Swarm Optimization* (PSO) é inspirado no movimento de pássaros e cardumes de peixes, de modo que o processo de otimização acontece a partir do aprendizado durante a competição individual e coletiva dos membros do bando (Pessin & Osório, 2009; Kennedy & Eberhart, 1995). Em analogia aos animais que compõem o bando, o PSO funciona com um conjunto de partículas, chamado enxame. Tais partículas são inseridas aleatoriamente no espaço de busca e são possíveis soluções para o problema abordado. A cada iteração do algoritmo, as partículas atualizam sua posição e sua velocidade no espaço de busca segundo as Equações 1 e 2, respectivamente. Por meio da função, *fitness* avalia-se o desempenho das partículas mantendo-as na busca pela solução ótima procurada.

$$X_i(t + 1) = X_i(t) + V_i(t) \quad (1)$$

$$V_i(t + 1) = w * V_i(t) + c_1 * r_1(p_i - X_i) + c_2 * r_2(p_g - X_i) \quad (2)$$

em que X_i e V_i representam, respectivamente, posição e velocidade da i -ésima partícula, na i -ésima iteração, w o peso inercial, c_1 o cognitivo local, c_2 o cognitivo social, r_1 e r_2 os vetores de números aleatórios, p_i a melhor posição da partícula i e p_g a melhor posição dentre todas as partículas do enxame.

O procedimento computacional do PSO tradicional pode ser visto no Algoritmo 1.

Algoritmo 1: PSEUDOCÓDIGO DO ALGORITMO PSO

```
1  início
2  |  InicializaEnxame();
3  |  para cadaIteracao faça
4  |  |  para cadaParticula faça
5  |  |  |  atualiza a velocidade da partícula usando a Equação 2
6  |  |  |  atualiza a posição da partícula usando a Equação 1
7  |  |  |  avalia a função fitness
8  |  |  |  encontra melhor posição atual
9  |  |  fim
10 |  |  encontra melhor global atual
11 |  fim
12 fim
13 retorna  $p_i$  e  $p_g$ 
```

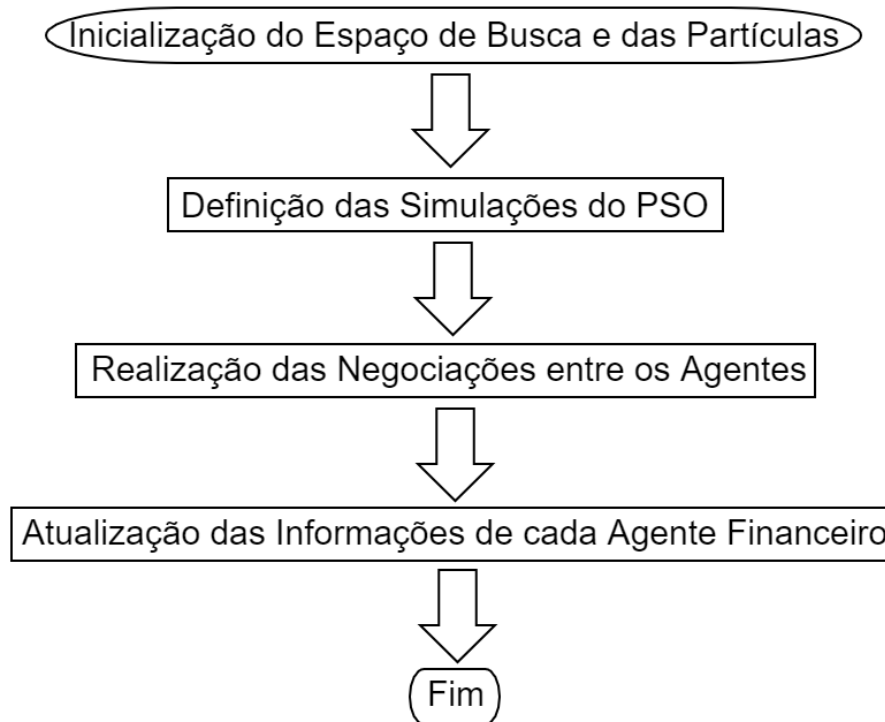
Fonte: Elaborado pelos autores.

O pseudocódigo do PSO tradicional exhibe as etapas necessárias para resolução de problemas de otimização com o algoritmo, tais como a minimização ou maximização de funções. Este algoritmo pode ser facilmente implementado, é bastante simples, rápido e utiliza pouca memória computacional.

Procedimento Proposto

O Fluxograma da Figura 1 é uma representação do procedimento adotado para o mercado financeiro artificial implementado.

Figura 1. Fluxograma ilustrando o procedimento realizado para desenvolvimento do mercado simulado.



Fonte: Elaborado pelos autores.

De acordo com a Figura 1, as partículas são inseridas no espaço de busca aleatoriamente e representam os agentes financeiros do mercado simulado. A partir de uma distribuição $U(0,1)$ são definidos os limiares de venda ($\delta[i]$) e de compra ($\lambda[i]$) para cada agente (i). A quantidade de iterações do PSO é definida a partir do comprimento da série temporal utilizada. As partículas são divididas em dois grupos: compradores e vendedores. Destes, existem os que acreditam na previsão do preço para o dia seguinte e os que não acreditam. É definido um fator de crença (ϕ), o qual pode assumir dois valores: 0 (para os que não acreditam na previsão) ou 1 (para os que acreditam na previsão). Para aqueles que acreditam, o preço previsto é definido como $p_p = p(t + lag)$, em que p_p representa o preço previsto, t a iteração atual do algoritmo e $lag = 1$. Assim, $\phi = 1$ indica que esse grupo sabe o valor real da ação no dia seguinte. Para os que não acreditam, $p_p = 0$. A partir dos limiares de venda e de compra são definidos os preços de venda e de compra de cada agente em cada negociação, isto é,

$$p_v = p_m + \delta[i] \quad (3)$$

$$p_c = p_m + \lambda[i] \quad (4)$$

em que p_v representa o preço de venda do ativo, p_m o preço de mercado do ativo negociado e p_c o preço de compra. As negociações acontecem quando $p_v \leq p_c$.

A função *fitness* nesse ambiente tem como objetivo maximizar a riqueza dos agentes financeiros. Para os agentes que não acreditam na previsão, a função *fitness* é atualizada segundo a expressão da Equação 5. Por outro lado, os que acreditam obedecem à Equação 6. Após cada negociação, as informações sobre quantidade de ações, de capital e de riqueza que os agentes possuem são atualizadas.

$$f_s[i] = c[i] + p[i] * a[i] \quad (5)$$

$$f_c[i] = (c[i] - p_m) + p_p[i] * (a[i] + 1) \quad (6)$$

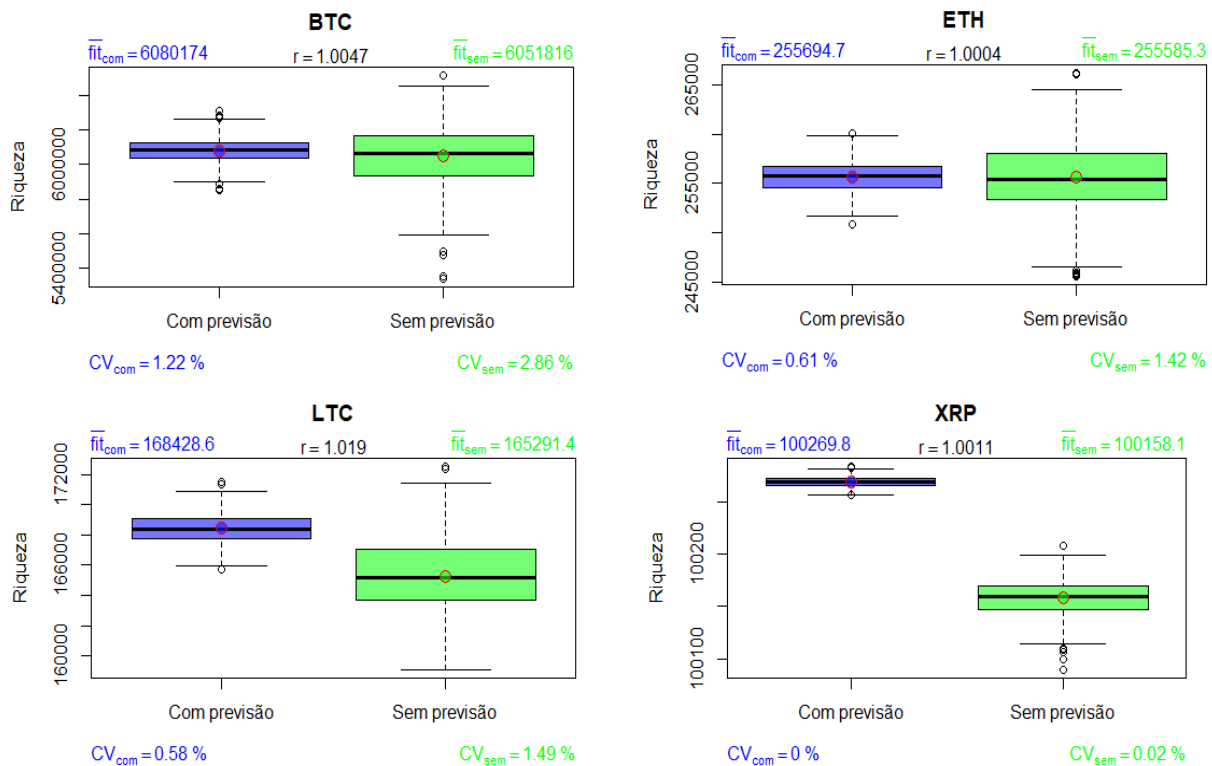
em que f_s indica *fitness* sem previsão, $c[i]$ o capital que o agente i possui, $a[i]$ a quantidade de ações do agente i e f_c o *fitness* com previsão.

Todos os agentes iniciaram com a mesma quantidade de capital (100000) e de ações (500). Foram realizadas 1000 rodadas de negociação entre os agentes em cada iteração do PSO. Cada iteração corresponde a um dia de negociação entre os agentes. Repetiu-se cada simulação 30 vezes e foi extraído o comportamento médio dessas simulações para as análises dos cenários de cada mercado artificial gerado com as informações dos preços do Bitcoin, Ethereum, Litecoin e Ripple.

3. Resultados e Discussão

Na Figura 2 é possível observar os *boxplots* para visualização das distribuições das informações da quantidade de riqueza que os agentes financeiros acumularam com as negociações.

Figura 2. *Boxplots* com dados da quantidade de capital e de ações dos agentes financeiros.

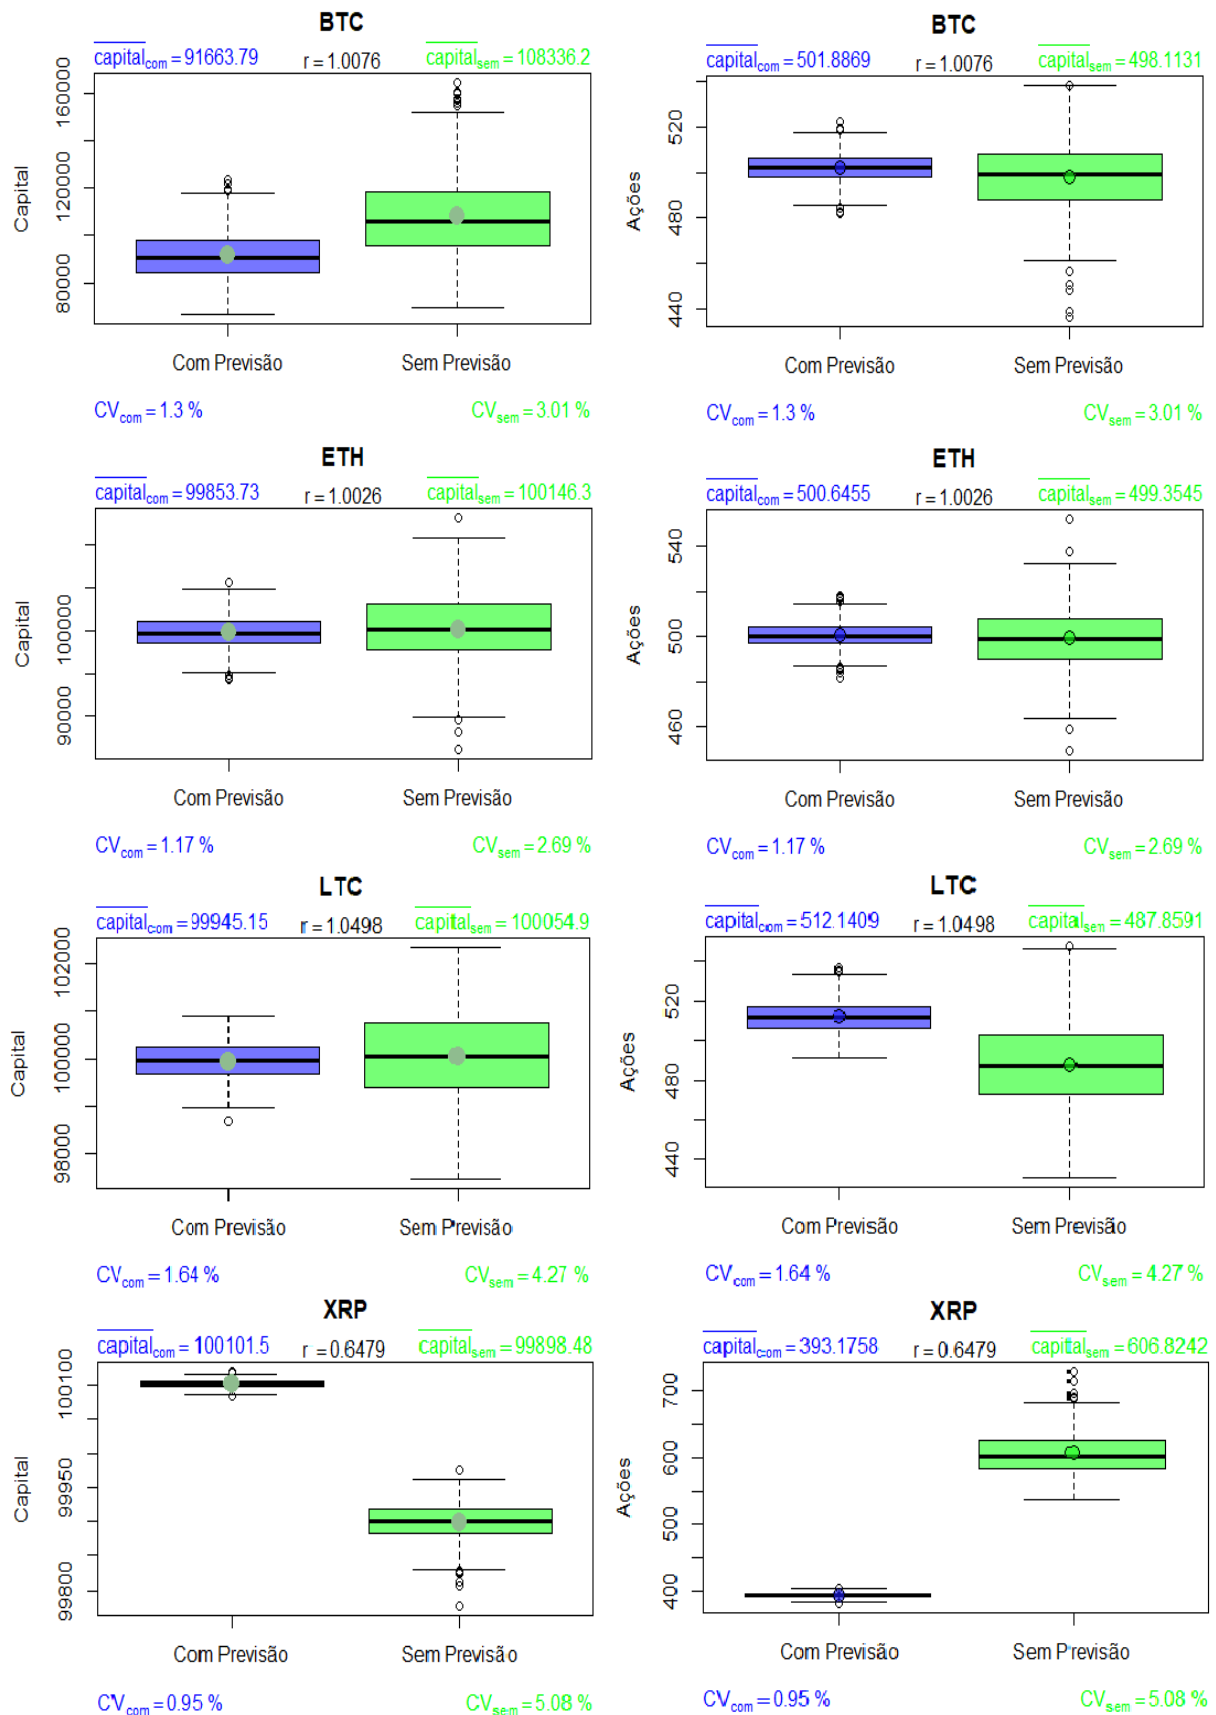


Fonte: Elaborado pelos autores.

Verifica-se na Figura 2 que nos quatro cenários simulados houve aumento na quantidade de riqueza dos agentes que utilizaram o grau de crença na previsão em relação aos que não utilizaram. Além disso, houve redução no valor do coeficiente de variação para todos os casos. A razão entre a quantidade média de riqueza para os casos com previsão (utilizando o grau de crença; $\phi = 1$) e a quantidade média de riqueza para os casos sem previsão (não utilizando o grau de crença; $\phi = 0$) foi maior do que um, indicando que a riqueza média com previsão foi superior para todos os casos. Se fosse menor do que um, indicaria que o segundo grupo (aqueles que não utilizaram o grau de crença) foi maior.

Ao observar a Figura 3, visualiza-se a distribuição dos dados sobre a quantidade de capital e a quantidade de ações que resultou na quantidade de riqueza acumulada pelos agentes do mercado simulado.

Figura 3. *Boxplots* com dados da quantidade de capital e de ações dos agentes financeiros.



Fonte: Elaborado pelos autores.

De acordo com a Figura 3, somente para XRP, a quantidade de ações dos agentes que não utilizaram a previsão ($\phi = 0$) foi superior a quantidade de ações dos agentes que optaram pela crença na previsão ($\phi = 1$), ao passo em que a quantidade de capital acumulada por estes agentes foi maior do que a quantidade acumulada pelos agentes que não utilizaram a previsão ($\phi = 0$). Mesmo com esse comportamento diferente das demais criptomoedas, o algoritmo foi capaz de otimizar a riqueza dos agentes usuários da previsão. Em contrapartida, os agentes que obtiveram sucesso com maior acúmulo de riqueza nos mercados de BTC, ETH e LTC somaram maior quantidade de ações e menor de quantidade de capital fazendo uso da previsão, em detrimento aos que não adotaram grau de crença para previsão.

A Tabela 2 exibe o resultado das estatísticas F e t-Student para o teste de comparação de variâncias e o teste de comparação de médias da quantidade de riqueza acumulada pelos agentes com uso da previsão a partir do grau de crença. Sendo a hipótese nula (H_0) a igualdade de variâncias no teste F e H_0 a igualdade de médias no teste T.

Tabela 2. Resultados do teste F ao nível de 5% de significância.

Criptomoeda	Teste F	p-valor	Hipótese Aceita
BTC	0.18279	2.2e-16	H_1 (variâncias diferentes)
ETH	0.1826	2.2e-16	H_1 (variâncias diferentes)
LTC	0.15581	2.2e-16	H_1 (variâncias diferentes)
XRP	0.08925	2.2e-16	H_1 (variâncias diferentes)

Fonte: Elaborado pelos autores.

Verifica-se que para todas as criptomoedas a hipótese nula da estatística F foi rejeitada ao nível de significância de 5% (Tabela 2). Com isso, conclui-se que todas as variâncias dos grupos de com e sem previsão são diferentes estatisticamente.

A Tabela 3 exibe o resultado das estatísticas F e t-Student para o teste de comparação de variâncias e o teste de comparação de médias da quantidade de riqueza acumulada pelos agentes sem uso da previsão a partir do grau de crença.

Tabela 3. Resultados do teste t-Student ao nível de 5% de significância.

Criptomoeda	Teste T	p-valor	Hipótese Aceita
BTC	3.3698	0.000795	H_1 (médias diferentes)
ETH	0.61949	0.2679	H_1 (médias iguais)
LTC	26.556	2.2e-16	H_1 (médias diferentes)
XRP	144.2	2.2e-16	H_1 (médias diferentes)

Fonte: Elaborado pelos autores.

Com o teste t-Student, verificou-se que apenas em ETH o p-valor foi maior que o nível de 5% de significância (Tabela 3). Isto significa que existem evidências para rejeitar a hipótese nula nesse caso. Com isso, conclui-se que apenas para ETH as médias foram estatisticamente iguais. Para as demais criptomoedas, as médias diferiram entre si.

4. Considerações Finais

Dado que houve aumento na quantidade de riqueza dos agentes que utilizaram o grau de crença na previsão em relação aos que não utilizaram, com algumas diferenças entre a quantidade de capital acumulado e a quantidade de ações, os resultados sugerem que o algoritmo PSO pode ser utilizado para otimizar o ganho dos agentes financeiros no mercado de criptomoedas.

Como trabalhos futuros, podem ser avaliados outros cenários de negociação e incluídos métodos de previsão para o valor futuro do preço de mercado dos ativos negociados pelos agentes financeiros, tais como os modelos de Box e Jenkins, Redes Neurais Artificiais ou modelos híbridos de previsão.

Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Referências

- Ahmed, M. K., Wajiga, G. M., Blamah, N. V., & Modi, B. (2019). Stock Market Forecasting Using ant Colony Optimization Based Algorithm. *American Journal of Mathematical and Computer Modelling*, 4(3), 52-57. <https://doi.org/10.11648/j.ajmcm.20190403.11>.
- Hitam, N. A., Ismail, A. R., & Saeed, F. (2019). An Optimized Support Vector Machine (SVM) based on Particle Swarm Optimization (PSO) for Cryptocurrency Forecasting. *Procedia Computer Science*, 163, 427-433. <https://doi.org/10.1016/j.procs.2019.12.125>.
- Kennedy, J., & Eberhart, R. (1995). Particle swarm optimization. In *Proceedings of ICNN'95-International Conference on Neural Networks* (Vol. 4, pp. 1942-1948). IEEE. <http://doi.org/10.1109/ICNN.1995.488968>.
- Lajevardy, P., Parand, F. A., Rashidi, H., & Rahimi, H. (2017). A hybrid method for load forecasting in smart grid based on neural networks and cuckoo search optimization approach. *International Journal of Renewable Energy Resources*, 5(1), 13-20.
- Mandes, A., & Winker, P. (2017). Complexity and model comparison in agent based modeling of financial markets. *Journal of Economic Interaction and Coordination*, 12(3), 469-506. <https://doi.org/10.1007/s11403-016-0173-0>.
- Pessin, G., & Osório, F. (2009). Otimização por Enxame de Partículas aplicado à formação e atuação de grupos robóticos. *Scientia*, 20(2), 94-106. <http://doi.org/10.4013/sct.2009.20.2.03>.
- Pereira, A.S. et al. (2018). *Metodologia da pesquisa científica*. [e-book]. Santa Maria. Ed. UAB/NTE/UFSM. Acesso em: 5 maio 2020. Disponível em: https://repositorio.ufsm.br/bitstream/handle/1/15824/Lic_Computacao_Metodologia-Pesquisa-Cientifica.pdf?sequence=1.
- Ramos, W. V., & Neto, C. R. (2015). A Utilização da Modelagem de Sistemas Complexos na Construção de um Mercado de Ações Artificial. *Revista Eletrônica do Departamento de Ciências Contábeis & Departamento de Atuária e Métodos Quantitativos (REDECA)*, 2(1), 101-115.

Serapião, A. B. D. S. (2009). Fundamentos de otimização por inteligência de enxames: uma visão geral. *Sba: Controle & Automação Sociedade Brasileira de Automatica*, 20(3), 271-304. <https://doi.org/10.1590/S0103-17592009000300002>.

Tang, L., Wang, A., Xu, Z., & Li, J. (2017). Online-purchasing behavior forecasting with a firefly algorithm-based SVM model considering shopping cart use. *Eurasia Journal of Mathematics, Science and Technology Education*, 13(12), 7967-7983.

Porcentagem de contribuição de cada autor no manuscrito

Kerolly Kedma Felix do Nascimento – 25%

Fábio Sandro dos Santos – 25%

Jader da Silva Jale – 25%

Tiago Alessandro Espínola Ferreira – 25%