

Evaluation of Technical Analysis Trading Rules in a Artificial Stock Market Environment

M. C. R. Leles, M. V. L. Pereira, R. A. Iquiapaza, E. F. Sbruzzi, and C. L. Nascimento Júnior, Member, IEEE

Abstract—Artificial multi-agent systems can be applied to replicate complex processes, including the stock market. In this manuscript, an artificial stock market was simulated. Heterogeneous agents are set to trade by using different investment strategies through a double auction market. The main innovative aspect of this work is to evaluate the performance and effectiveness of agents with different investment strategies based on the combination of Technical/Fundamental Analysis. According to the simulations performed, the results showed that the time series resulting from the interactions among these agents resemble to the real financial series, reproducing some of the stylized facts found in the Literature. Moreover, the statistical analysis reported no significant differences in the distribution mean performance between these diverse agents types.

Index Terms—Multi-agent System, Artificial Stock Market, Heterogeneous Agents, Performance Technical Trading Rules.

I. INTRODUÇÃO

O movimento dos preços dos ativos no mercado financeiro pode ser classificado como um sistema [1]: complexo, não linear, não estacionário e variante no tempo. O preço está sujeito a diversos fatores, dentre os quais podem ser destacados: eventos políticos, notícias econômicas, influência internacional, dentre outros. Diversos estudos comprovam que a predição dos retornos dos ativos financeiros é uma tarefa desafiadora [2].

Uma maneira de se atuar nesse mercado é por meio da Análise Fundamentalista, que utiliza fatores econômicos para estimar os valores intrínsecos dos ativos financeiros. Por outro lado, a Análise Técnica (AT) se baseia no estudo da evolução temporal da série histórica de preços, tendo como premissas básicas [3, 4] os movimentos de mercado refletem tudo o que é importante (oferta e demanda), os preços se movimentam através de tendências e a evolução dos preços apresenta padrões que se repetem.

M. C. R. Leles, professor no Departamento de Tecnologia (DTECH) da Universidade Federal de São João del-Rei (UFSJ), Ouro Branco, Minas Gerais, Brasil, (e-mail: mleles@ufsj.edu.br).

M. V. L. Pereira, estudante de doutorado na Universidade Federal de Minas Gerais (UFMG), Belo Horizonte, e professor no Departamento de Tecnologia (DTECH) da Universidade Federal de São João del-Rei (UFSJ), Ouro Branco, Minas Gerais, Brasil, (e-mail: marcos.vinicius@ufsj.edu.br).

R. A. Iquiapaza, professor do Departamento de Ciências Administrativas (CAD) da Universidade Federal de Minas Gerais (UFMG), Belo Horizonte, Minas Gerais, Brasil, (e-mail: riquiapaza@face.ufmg.br).

E. F. Sbruzzi, professor na Divisão de Ciência da Computação (IEC) do Instituto Tecnológico de Aeronáutica (ITA), São José dos Campos, São Paulo, Brazil, (email: elton@ita.br).

C. L. Nascimento Júnior, professor na Divisão de Engenharia Eletrônica (IEE) do Instituto Tecnológico de Aeronáutica (ITA), São José dos Campos, São Paulo, Brazil, (email: cairo@ita.br).

Diversos tipos de estratégias de negociação baseadas na AT foram propostas na literatura [5]. Algumas se baseiam em indicadores “clássicos” como médias móveis, índice de força relativa, entre outros [2]. Em contrapartida, alguns estudos têm combinado essas ferramentas tradicionais com técnicas de inteligência artificial [6, 7] e de processamento de sinais [8–10]. A utilização da Análise Técnica, embora aceita entre profissionais do mercado financeiro [4], ainda é controversa no meio acadêmico, pois diversos estudos defendem a sua utilização [11], enquanto outros a criticam [12].

Uma alternativa para estudo de sistemas financeiros, que tem aumentado sua popularidade recentemente, se dá por meio de agentes em “mercados financeiros artificiais” [4, 13]. Nessa metodologia, a série estudada é resultado tanto da iteração entre diferentes tipos de agentes (cada participante individual no mercado) quanto do funcionamento detalhado do mecanismo de negociação entre eles. Esse tipo de abordagem possui a capacidade de ir além da modelagem econômica moderna [14, 15], porque esses modelos consideram o mercado como um sistema multi-agente em que cada agente tem características particulares, podendo diferir na forma autônoma como tomam suas decisões. Em contra-partida, na teoria econômica moderna assume-se que cada agente possui acesso igualitário à informação, é racional e que, diante da tomada de decisões envolvendo risco, visa a maximização de sua função de utilidade esperada [16–18].

Diversos modelos baseados em agentes foram propostos [19–21]. Em muitos deles, quando os agentes submetem uma ordem de negociação, enfrentam três parâmetros diferentes no seu processo decisório: o preço, a direção da posição (comprada (*long*) ou vendida (*short*)) e o volume.

Leles et al. [22] propuseram uma plataforma computacional para simulação de um mercado financeiro artificial por meio de um sistema multi-agentes. Partindo do modelo original de Chiarella and Iori [20], no qual os agentes possuem três componentes - aleatório, fundamentalista e grafista-, algumas modificações foram efetuadas de forma a se incluir a possibilidade de utilização de estratégias baseadas na AT pelos agentes. Esse *framework* propicia, portanto, um ambiente em que agentes heterogêneos relacionam-se entre si por meio de um mecanismo de leilão duplo. Dessa interação obtém-se uma série de preços resultante desse mercado artificial, a qual possui algumas características que se assemelham a séries financeiras reais, uma vez que alguns dos fatos estilizados presentes no mercado financeiro foram reproduzidos.

O presente trabalho utiliza a plataforma desenvolvida por Leles et al. [22]. Novas simulações são conduzidas com o propósito de se confrontar os resultados obtidos pelos dife-

rentes tipos de agentes com algumas das principais teorias econômicas vigentes sobre evolução dos preços – Hipótese de Mercados Eficientes [17, 23] e Hipótese de Mercados Adaptativos [24]. O principal objetivo do presente trabalho é, portanto, avaliar o ambiente para simulação de um mercado artificial ao considerar o desempenho e a efetividade de agentes dotados com diferentes estratégias de investimento por meio de diferentes métricas de desempenho. Diversos testes estatísticos são utilizados, embasando uma análise pormenorizada dos resultados experimentais obtidos.

O restante desse texto é organizado como se segue. Na seção II é apresentada a fundamentação teórica dos principais conceitos necessários. A abordagem proposta é discutida na seção III. Os resultados experimentais são reportados na seção IV e discutidos na seção V. A conclusão desse trabalho e algumas direções futuras de pesquisa são explorados da seção VI. Finalmente, no apêndice A são descritos alguns detalhes técnicos da avaliação estatística utilizada.

II. FUNDAMENTAÇÃO TEÓRICA

Nessa seção é apresentada uma breve discussão teórica acerca dos principais conceitos relacionados ao presente trabalho. Esse texto se inicia com uma sucinta revisão de alguns sistemas multi-agentes apresentados anteriormente na literatura, sendo o modelo proposto por Chiarella and Iori [20] detalhado na seção II-A. A utilização de duas ferramentas baseadas na AT é discutida na seção II-B. Algumas características estatísticas comuns a diversas séries financeiras - fatos estilizados - são apresentados na seção II-C. Finalmente, as métricas de desempenho são brevemente exploradas na seção II-D.

Destaca-se, entretanto, que modelos baseados em agentes têm sido aplicados em diversas áreas do conhecimento [25, 26]. Para uma revisão recente sobre plataformas de desenvolvimento desse tipo de sistemas em diferentes aplicações sugere-se Abar et al. [27] e referências nele contidas.

A. Sistemas Multi-Agentes em Finanças

Maslov [28] propõe um modelo simples onde os agentes decidem o preço para comprar (vender) aleatoriamente em algum valor acima (abaixo) do preço atual. Já Lux and Marchesi [19] propõem que os agentes decidam de acordo com a combinação de três componentes - o fundamentalista, o grafista e o aleatório. O primeiro componente se baseia em variáveis intrínsecas das empresas calculadas usando as informações em seu balanço; os agentes vendem (compram) quando o preço é maior (menor) do que o valor intrínseco da ação ou o preço fundamental. O componente grafista usa os dados históricos da série de preços; uma discussão detalhada é adiada para a seção II-B. O componente aleatório, por sua vez, representa os participantes cujo excesso de demanda é randômico.

No modelo de Chiarella and Iori [20], os agentes decidem a direção e o preço, enquanto a quantidade é fixada em uma unidade por pedido. Em termos de direção, a expectativa de retorno de cada agente consiste em uma combinação de três componentes diferentes - fundamentalista, grafista e aleatório:

$$\tilde{r}_{t,t+\tau}^i = g_1^i \frac{p^f - p_t}{p_t} + g_2^i \bar{r}_{L_i} + n_i \varepsilon_t \quad (1)$$

na qual p_t indica o preço do ativo em t , p^f indica o preço fundamentalista, g_1^i é o peso desse componente (valor positivo) e g_2^i é o peso do componente grafista que é positivo no caso dos seguidores de tendência e negativo no caso dos osciladores. Cada agente tem valores diferentes, seguindo uma distribuição normal, de acordo com: $g_1^i \sim \mathcal{N}(0, \sigma_1)$, $g_2^i \sim \mathcal{N}(0, \sigma_2)$ e $n_i \sim \mathcal{N}(0, \sigma_n)$. O parâmetro $\bar{r}_{L_i}^i$ é o valor da média móvel do retorno ao longo do período L_i . Esse parâmetro, entretanto, não é aqui utilizado ($g_2^i = 0$).

Finalmente, a equação do preço futuro esperado do agente i até o momento $t + \tau$ é

$$\tilde{p}_{t+\tau}^i = p_t e^{\tilde{r}_{t,t+\tau}^i} \quad (2)$$

Na seção III-B é explicado como os agentes decidem o preço de compra (venda).

B. Análise Técnica

O objetivo geral da AT é extrair padrões (não lineares) que serão utilizados para a construção de estratégias/regras de negociação, a partir da análise da série de preços de um ativo financeiro. Almeja-se que tais estratégias sejam capazes de capturar movimentos de mercado significativos ignorando suas flutuações aleatórias.

Regras de negociação se baseiam em indicadores que podem ser definidos como um operador que transforma um sinal de entrada (preços históricos) em um sinal de saída (ordens de compra/venda) capaz de evidenciar algumas oportunidades escondidas na dinâmica do mercado [29].

Os indicadores seguidores de tendência produzem sinais que seguem o movimento do mercado. Esses indicadores funcionam melhor em mercados com tendência definida [3]. O indicador mais utilizado para criação dessa classe de estratégias são as Médias Móveis. A média móvel simples, $MA_n[L]$, da série temporal de preços $\{p_t; t = 1, 2, \dots, N\}$, para um período de L dias, onde $L \leq N$, é

$$MA_t[L] = \frac{1}{L} \sum_{l=1}^L p_l \quad (3)$$

Um oscilador é um indicador que flutua acima e abaixo de uma linha central ou entre níveis pré-definidos à medida que seu valor muda ao longo do tempo. Osciladores baseados em uma linha central são usados na identificação da força e/ou direção do *momentum* do movimento dos preços. Como exemplo, pode-se citar oscilador de *Momentum*, que tem como objetivo quantificar a variação dos preços, acompanhando a velocidade com a qual se movem, em determinado período de tempo. É definido como a subtração de um preço passado do preço atual (Equação (4)).

$$M_t[K] = p_t - p_{t-K} \quad (4)$$

C. Fatos Estilizados

Fatos estilizados são utilizados para se avaliar se as simulações oriundas de um mercado financeiro artificial reproduzem algumas das propriedades estatísticas comumente encontradas em séries financeiras reais. Alguns desses fatos referem-se ao formato da função de distribuição de probabilidade dos

retornos. Por exemplo, Cont [30] mostra que distribuições de retornos diários ou intra-diários são leptocúrticas.

D. Métricas de Desempenho

Dentre as diversas métricas de desempenho apresentadas na literatura [3, 31], duas são aqui empregadas. A primeira é baseada no **Lucro** obtido pelo agente i , \mathcal{P}^i , calculado como a diferença entre o capital final, C_f^i , e o capital inicial, C_0^i , de acordo com a Equação (5).

$$\mathcal{P}^i = C_f^i - C_0^i \quad (5)$$

A segunda é o **Índice de Sharpe**, \mathcal{S}^i , uma métrica ajustada pelo risco, baseada na razão entre o retorno médio, \bar{R}^i , obtido pelo agente i (descontado da taxa livre de risco, R_f) e o desvio padrão dos retornos, σ^i , de acordo com a Equação (6).

$$\mathcal{S}^i = \frac{\bar{R}^i - R_f}{\sigma^i} \quad (6)$$

Nesse estudo assume-se, sem perda de generalidade, $R_f = 0$.

III. ABORDAGEM PROPOSTA

Nessa seção é apresentada e discutida a abordagem aqui proposta. Na seção III-A são descritos os tipos de agentes utilizados. O mecanismo de negociação entre agentes é detalhado na seção III-B, enquanto o método de estimação do preço é detalhado na seção III-C.

A. Tipos de Agentes

Os agentes são autônomos, isto é, são capazes de interagir com o meio e tomar decisões de forma independente. Mas não são adaptativos, ou seja, não são capazes de aprender com a própria história (comportamento passado). Os agentes possuem informação incompleta e se baseiam em diferentes premissas para formação de sua expectativa de preço futuro, podendo ser divididos em:

- **Modelo de Chiarella and Iori [20]:** sua expectativa de preço se baseia em um componente aleatório e/ou fundamentalista. São divididos em três tipos - Aleatório (ou *Zero Intelligence*), Fundamentalista e combinação dos dois componentes anteriores;
- **Baseados em AT:** utilização de diferentes tipos de indicadores para formação de sua expectativa de preço. São divididos, em função do tipo de indicador utilizado, em Média Móvel e *Momentum*.

B. Mecanismo de Negociação

O mecanismo de negociação se baseia em um mercado de leilão duplo. No modelo original de Chiarella and Iori [20], o preço fundamentalista, parâmetro p^f , é mantido constante ao longo de toda a simulação. No presente trabalho, entretanto, esse parâmetro segue um modelo de passeio aleatório (Equação (7)), com $p_1^f = 100$, $\varepsilon \sim \mathcal{N}(0, n_\varepsilon)$.

$$p_t^f = p_{t-1}^f + \varepsilon \quad (7)$$

Com o intuito de se padronizar a notação para o preço futuro estimando independentemente do tipo de agente, define-se o

preço estimado no instante t como \hat{p}_t . Assim, $\hat{p}_t = \tilde{p}_t$ para o agente baseado em [20], equação (2); $\hat{p}_t = \text{MA}_t[L]$ para o agente baseado em médias móveis, equação (3); e $\hat{p}_t = M_t[K]$ para o agente baseado no oscilador *momentum*, equação (4).

No instante t , o agente i lança uma ordem de compra, b_t^i , (venda, a_t^i) se seu preço estimado for maior (menor) que o preço atual, p_t , de acordo com a Equação (8).

$$\begin{cases} \hat{p}_t = b_t^i, & \text{se } \hat{p}_t \geq p_t; \\ \hat{p}_t = a_t^i, & \text{se } \hat{p}_t < p_t. \end{cases} \quad (8)$$

Se b_t^i (a_t^i) é maior (menor) do que a melhor *ask*, a_t^* , (bid, b_t^*) ocorre uma negociação, isto é tem-se uma *market order*, sendo o preço atual atualizado para esse valor. Caso contrário, a ordem permanecerá no livro de ordens, ou seja, tem-se uma *limit order*. A equação (9) resume essas diferenças.

$$\begin{cases} \text{Limit Order}, & \text{se } b_t^i < a_t^*; \\ \text{Market Order}, & \text{se } b_t^i \geq a_t^*. \end{cases} \quad (9)$$

Uma ordem permanece no livro enquanto nenhuma outra ordem de contrapartida a igualar, ou até o final do período, em que ela será automaticamente cancelada em função da sua duração (*lifespan*), parâmetro τ .

C. Estimação de Preço Futuro

Os agentes inspirados no modelo de [20] utilizam as equações (1) e (2) para definição do preço futuro.

Para utilização de médias móveis como ferramenta de construção de estratégias, deve-se observar o seu cruzamento com a série temporal de preços. Os sinais de compra (venda) são acionados quando a média móvel cruza essas séries de baixo para cima (de cima para baixo).

Para utilização do oscilador *momentum* como ferramentas de construção de estratégias, deve-se observar o seu cruzamento com o valor zero, o que é interpretado como um sinal. O mesmo se refere a um sinal de compra (venda) se o cruzamento ocorre de baixo para cima (cima para baixo).

Destaca-se, entretanto, que para sua utilização para modelar o processo de decisão de um agente, uma modificação nessas regras precisa ser efetuada. De fato, a cada iteração um agente é escolhido aleatoriamente para enviar uma ordem ao mercado. Existe uma baixa probabilidade do agente que usa uma média móvel, por exemplo, ser sorteado exatamente no dia em que ocorre o cruzamento da média móvel com o preço.

Nesse sentido, optou-se por determinar que a ordem emitida pelo agente seja igual à média móvel do período, parâmetro L na equação (3), se o mesmo se basear nesse indicador ou igual ao valor do preço no período utilizado para cálculo do oscilador *momentum*, parâmetro K na equação (4).

Para definição do valor final da ordem a ser lançada, o agente utiliza informações relativas às melhores ordens listadas no livro de ordens, de acordo com a Equação (10), em que $\kappa^i \sim \mathcal{N}(0, \sigma_\kappa)$.

$$\begin{cases} b_t^i = b_t^* + \text{abs}(\kappa^i) \\ a_t^i = a_t^* - \text{abs}(\kappa^i) \end{cases} \quad (10)$$

Destaca-se, contudo, que se $\text{abs}(\kappa^i) > a_t^*$, a simulação seria encerrada e descartada, pois $a_t^i < 0$.

Finalmente, os os parâmetros adotados nas simulações aqui apresentadas (Seção IV) são reportados na Tabela I.

TABELA I
RESUMO DOS PARÂMETROS ADOTADOS NO PRESENTE TRABALHO.

Parâmetros	Descrição	Valores
σ_1^i	Desvio Padrão Fundamentalista	1
n_0	Desvio Padrão Aleatório	1,5
τ	Lifespan	200
σ_{κ}	Media do Deslocamento de preço	3
k^{max}	Spread máximo	0,5
L	Período Média Móvel	5 a 100
K	Período Oscilador <i>Momentum</i>	5 a 100
Δ	Tick size (variação em centavos)	0,01

IV. RESULTADOS EXPERIMENTAIS

Os resultados experimentais do presente trabalho são aqui apresentados. Os agentes podem operar nas duas pontas (*long* e *short*) e, ainda, possuem recursos financeiros ilimitados. Essas condições tendem a aumentar a liquidez do mercado.

A Fig. 1 apresenta as séries financeiras para quatro experimentos em que se variou o preço fundamentalista, enquanto as Fig. 2 e 3 ilustram as duas métricas de desempenho apresentadas na seção II-D.

Algumas estatísticas calculadas a partir das simulações anteriores são reportadas na Tabela II. A Fig. 4 mostra a função de auto-correlação calculada a partir dos retornos apresentados na Fig. 1a. Resultados simulares foram encontrados para as outras simulações apresentadas na Tabela II, mas são omitidos em função da limitação de espaço.

TABELA II
ALGUMAS ESTATÍSTICAS CALCULADAS A PARTIR DOS RETORNOS DAS SIMULAÇÕES APRESENTADAS ANTERIORMENTE.

	Fig. 1a	Fig. 1b	Fig. 1c	Fig. 1d
Curtose	15,375	13,558	14,816	13,790
Assimetria	0,584	0,600	0,489	0,530

V. DISCUSSÃO

Uma forma de avaliação das estratégias de negociação faz uso de séries históricas da evolução temporal do preço de determinado ativo financeiro, técnica conhecida como *backtesting*. A utilização dessa técnica visa verificar o desempenho que teria sido produzido por uma estratégia de negociação quando aplicada em determinado ativo. Diversos estudos se baseiam nesse tipo de abordagem [11, 32, 33].

Destaca-se, entretanto, que o processo de *backtesting* possui algumas limitações. A primeira é a suposição de que o investidor consiga negociar a ação no preço em que a estratégia forneça o sinal de operação. A segunda é que, nesse procedimento de simulação computacional, não é possível se verificar qual seria a influência na dinâmica dos preços provocada pela ordem de operação utilizada.

A abordagem de mercado financeiro artificial utilizando modelos baseados em agentes aqui apresentada pode contribuir com essa discussão, uma vez que diversas estratégias de AT podem ser empregadas e seu estudo pode ser efetuado em diferentes condições de mercado. Essa perspectiva alternativa para estudo de sistemas financeiros não sofre dos dois problemas relacionados ao processo de *backtesting* [34].

Pela análise da Fig. 1 pode-se observar que as séries resultantes da interação entre os agentes e o mecanismo de negociação se assemelha a séries financeiras reais. Essa observação é corroborada pela Fig. 4 em conjunto com a Tabela II. Estatísticas calculadas a partir dos retornos reproduziram alguns dos fatos estilizados observados empiricamente:

- **Ausência de Auto-Correlação:** a função de auto-correlação dos retornos é aproximadamente zero para qualquer valor de atraso, exceto para horizontes de tempos muito curtos, fenômeno *bid-ask bounce* [30];
- **Agrupamento de Volatilidade:** a auto-correlação do valor absoluto (ou quadrado) dos retornos permanece positiva para longos horizontes de tempo [18]. Tal característica é similar à de processos autorregressivos heterocedásticos - ARCH/GARCH [35];
- **Distribuição com Caudas Pesadas:** a distribuição dos retornos em mercados financeiros reais apresenta valores altos para a curtose [36];
- **Assimetria na Distribuição:** em diversos mercados pode-se observar que retornos negativos altos são mais frequentes que os positivos [37].

Na avaliação dos resultados de lucro financeiro e índice de Sharpe, não houve diferença estatisticamente significativa entre as médias dos resultados obtidos pelos diferentes tipos de agentes utilizados nesse estudo. O Apêndice A apresenta uma discussão detalhada dos testes estatísticos aqui utilizados. A distribuição dos desempenhos dos agentes ilustrados nas Fig. 2 e 3 demonstra que, apesar do surgimento de *outliers*, nenhum tipo de agente foi consistentemente superior aos demais em todos os experimentos aqui realizados.

Dentre as diferentes razões que justifiquem esse resultado, podem-se incluir, mas sem se limitar a:

- 1) os valores dos parâmetros são escolhidos aleatoriamente no início da simulação e mantidos constantes ao longo de todo o processo;
- 2) não existe nenhum processo de aprendizado, isto é, os agentes aqui utilizados são não adaptativos, não aprendendo com seus erros; e
- 3) os instantes de operação são aleatórios, o que implica que os agentes dotados de AT enviam uma ordem ao mercado em momentos (em geral) diferentes daqueles em que sua estratégia sinalizaria um ponto de operação.

Esses resultados, apesar do desempenho médio indistinto entre os agentes, ainda não podem ser entendidos como uma simulação que atenda os requisitos da “hipótese de eficiência de mercado” [17, 23, 38]. Tal hipótese, em sua essência, considera que os preços dos ativos financeiros, em qualquer instante no tempo, “refletem plenamente” as informações disponíveis quando se trata de mercados competitivos. Na Fig. 4a, a Função de Auto-Correlação (FAC) e Função de

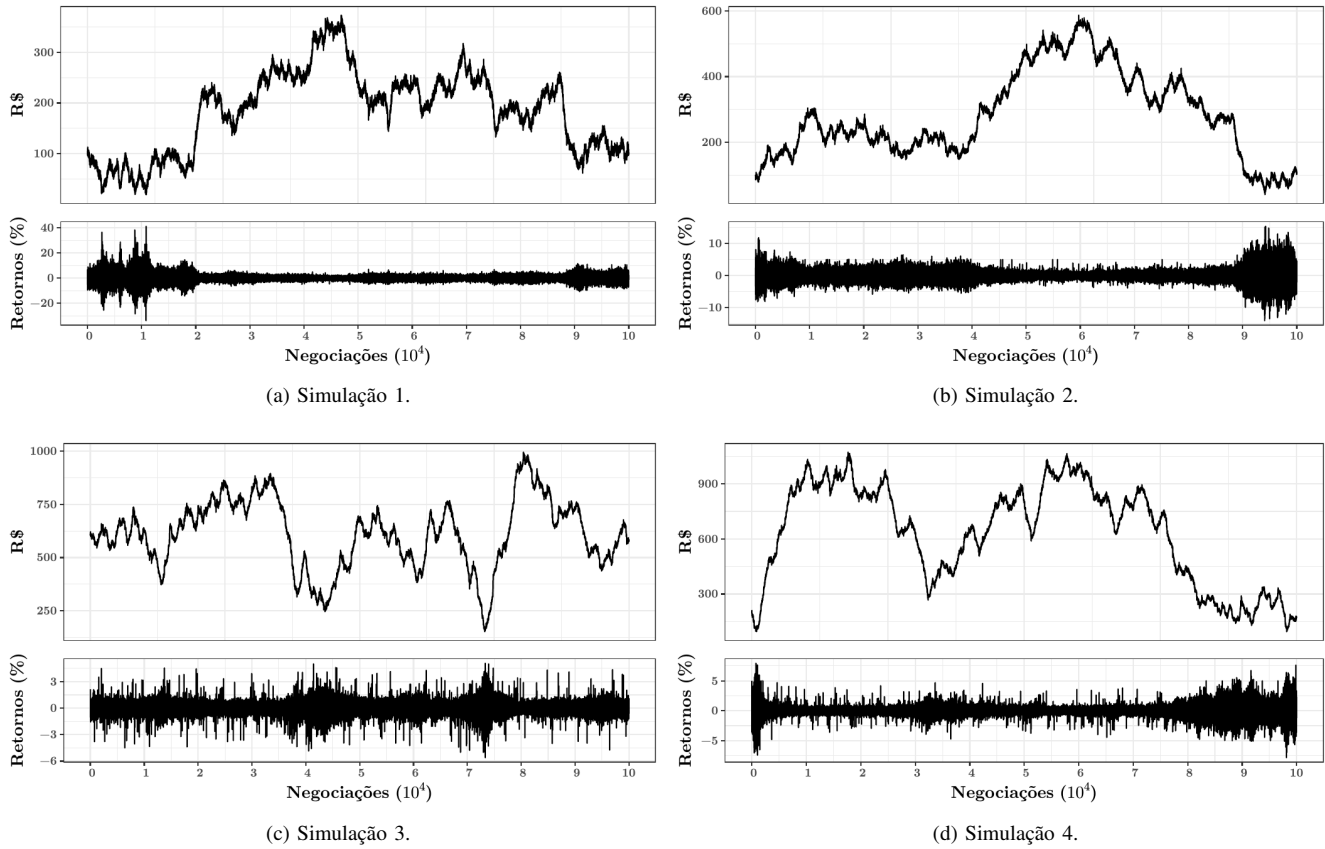


Fig. 1. Evolução da série de preços para diferentes simulações para o preço fundamentalista. Foram usados mil agentes e $\kappa = \mathcal{N}(0, \sigma_\kappa)$, com $\sigma_\kappa = 3$.

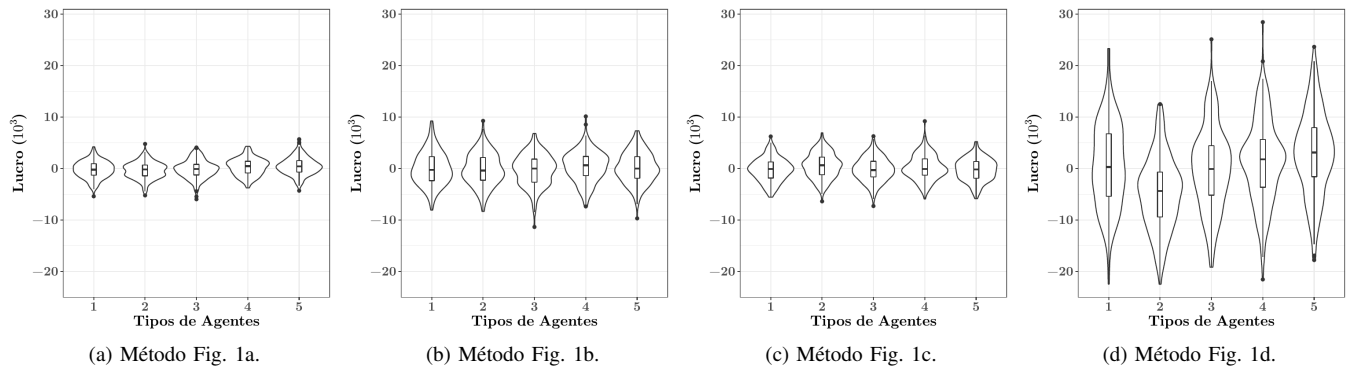


Fig. 2. Gráficos *boxplot*/violino ilustrando o lucro obtido pelos diferentes tipos de agentes: 1) apenas componente aleatório, 2) apenas componente fundamentalista, 3) combinação dos dois anteriores, 4) oscilador *momentum*, e 5) média móvel. Deve-se destacar as diferentes escalas no eixo-*y*.

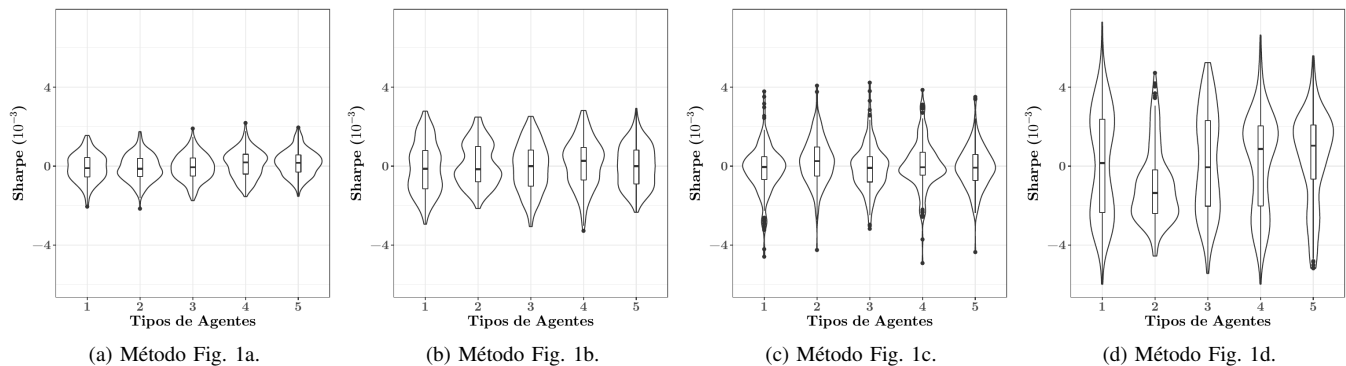


Fig. 3. Gráficos *boxplot*/violino ilustrando o índice de Sharpe obtido pelos diferentes tipos de agentes, seguindo o mesmo procedimento adotado na Fig. 2.



(a) FAC e FACP dos retornos simples $(p_t/p_{t-1} - 1)$ (b) FAC e FACP do quadrado dos retornos simples $((p_t/p_{t-1} - 1)^2)$

Fig. 4. Funções de auto-correlação (FAC) e de auto-correlação parcial (FACP) relativas aos retornos obtidos na Fig. 1a.

Auto-Correlação Parcial (FACP) apontam comportamento dos retornos típicos de processos estocásticos com termos de média-móvel em relação à primeira defasagem. Como mostrado na Fig. 3, em algumas simulações foi possível obter desempenhos superiores.

Finalmente, optou-se por aqui apresentar os resultados para apenas duas técnicas de AT, dentre as muitas existentes [5]. Essa escolha se justificou por três motivos principais: médias móveis e osciladores *momentum* servem para representam dois tipos de estratégias (seguidores de tendência e osciladores, respectivamente) amplamente utilizados; esses foram os indicadores técnicos discutidos em [22], cuja plataforma computacional utilizamos para nossos experimentos; e resultados semelhantes foram obtidos utilizando-se outros tipos de indicadores de TA, tendo sido omitidos por não acrescentar nenhuma nova informação à discussão apresentada.

VI. CONCLUSÃO E TRABALHOS FUTUROS

No presente trabalho foi apresentado um novo modelo para simulação de mercados financeiros artificiais utilizando um sistema multi-agentes. A interação entre diferentes agentes em um mecanismo de leilão duplo propiciou a formação de uma série de preços simulados que replicam os preços obtidos em um mercado financeiro. Os resultados mostram que o modelo proposto é capaz de reproduzir, com sucesso, alguns dos fatos estilizados presentes em mercados financeiros reais.

O desempenho de agentes baseados em AT pode ser avaliado sob diferentes condições de mercado. A abordagem aqui apresentada pode contribuir, portanto, com o debate acadêmico acerca da lucratividade de estratégias baseadas na AT. Especificamente, a avaliação do desempenho financeiro

de dois indicadores não mostrou diferença estatística com relação a estratégias mais simples, mas em alguns cenários esse indicador teve maior variabilidade em ambos os sentidos.

Como trabalhos futuros outras características dos mercados podem ser incorporadas, como agentes adaptativos, capazes de aprender por meio de suas interações com o ambiente e que sejam dotados de Inteligência Artificial; variações na riqueza inicial do agente e no volume de ações negociado podem impactar na dinâmica do mercado; outros fatores fundamentalistas a serem utilizados na precificação de ativos, como, por exemplo, tamanho da empresa, índice *book-to-market*, lucratividade e investimento; a utilização de alavancagem é uma prática comum que também pode ser acrescentada.

AGRADECIMENTOS

Esse trabalho foi parcialmente financiado pela Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), processos no 2016/04992-6 e no 2017/20248-8.

APÊNDICE A ANÁLISE DE VARIÂNCIA

Nessa seção são descritos os testes estatísticos a fim de avaliar se as distribuições dos resultados obtidos pelos diferentes tipos de agentes são significativamente distintas. Uma discussão detalhada acerca desses métodos de avaliação estatística está fora de escopo, mas pode ser obtida, p. ex., em [39].

As simulações computacionais apresentadas na Fig. 1, são identificadas como Experimentos 1, 2, 3 e 4, se referindo, respectivamente, às Fig. 1a, 1b, 1c e 1d. Os cinco diferentes Tipos de Agentes (TA) são identificados como: 1) apenas componente aleatório (TA₁); 2) apenas componente fundamentalista (TA₂); 3) combinação dos dois anteriores (TA₃); 4) oscilador *momentum* (TA₄); e 5) média móvel (TA₅). Finalmente, os resultados apresentados nas Tabelas III, IV e V se referem à métrica de Lucro. Resultados qualitativamente semelhantes foram obtidos para o índice de Sharpe, sendo, portanto, omitidos por exibirem conclusões redundantes.

O teste ANOVA [40] é amplamente empregado para a finalidade de diferenciar distribuições. Para esse caso, a hipótese nula H_0 indica que as amostras das distribuições diferentes possuem médias equivalentes, contra a hipótese alternativa de que ao menos um dos grupos possui média distinta das demais. Por meio dessa análise pode se identificado, portanto, se algum tipo de agente apresenta um desempenho superior aos demais. Entretanto, a confiabilidade do teste ANOVA está atrelada ao atendimento de suas premissas. Os pressupostos de normalidade e homogeneidade da variância entre grupos são necessários para se garantir a eficiência do teste. A Tabela III resume a verificação das premissas do teste ANOVA.

Pela análise da Tabela III pode-se observar que a hipótese de normalidade e de homogeneidade de variâncias não foram rejeitadas. Apesar dos pressupostos para utilização do teste ANOVA terem sido atendidos, houve a realização de outro teste que não se baseia nessas premissas. Nesse sentido, foi escolhido o teste de Kruskal-Wallis (não-paramétrico) como uma alternativa para fins de confirmação. Na Tabela IV são reportados os resultados para esses dois testes.

TABELA III
TESTES DOS PRESSUPOSTOS DO TESTE ANOVA (LUCRO)

	Normalidade	Homogeneidade da Variância
Experimento 1	0,999	0,185
Experimento 2	0,999	0,444
Experimento 3	0,999	0,665
Experimento 4	0,998	1,539

Foi utilizado o teste de Shapiro-Wilk para normalidade e o teste de homogeneidade da variância (ou homocedasticidade) de Levene. São reportados da seguinte forma os valores-p: * $p < 0,1$, ** $p < 0,05$, *** $p < 0,01$.

TABELA IV
TESTES DE SEMELHANÇA ENTRE DISTRIBUIÇÕES (LUCRO).

	ANOVA	Kruskal-Wallis
Experimento 1	9,120***	32,261***
Experimento 2	1,618	6,571
Experimento 3	4,475***	14,962***
Experimento 4	26,976***	99,752***

Os valores-p seguem o padrão adotado na Tabela III.

Pela análise da Tabela IV pode-se observar a rejeição da hipótese de que os grupos apresentam a mesma tendência central para os experimentos 1, 3 e 4. Nesses experimentos computacionais, portanto, o desempenho médio de algum tipo de agente se sobressaiu em relação aos demais. Uma investigação mais detalhada se faz, portanto, necessária. Para tanto, foi utilizado o teste de Tukey, que avaliou a diferença entre as médias entre os pares de diferentes tipos de agentes, conforme apresentado na Tabela V.

TABELA V
TESTE DE TUKEY PARA AVALIAR DIFERENÇA ENTRE MÉDIAS DOS LUCROS ENTRE OS DIFERENTES AGENTES (DIFERENÇA HONESTAMENTE SIGNIFICATIVA).

	TA ₁	TA ₂	TA ₃	TA ₄
<i>Experimento 1:</i>				
TA ₂	-0,167			
TA ₃	0,032	0,199		
TA ₄	0,501**	0,669***	0,469**	
TA ₅	0,686***	0,853***	0,654***	0,185
<i>Experimento 3:</i>				
TA ₂	0,786***			
TA ₃	0,050	-0,736**		
TA ₄	0,429	-0,357	0,379	
TA ₅	0,004	-0,783***	-0,046	-0,425
<i>Experimento 4:</i>				
TA ₂	-5,379***			
TA ₃	-0,709	4,670***		
TA ₄	0,800	6,179***	1,509	
TA ₅	2,272**	7,651***	2,981***	1,472

Os valores-p seguem o padrão adotado na Tabela III.

Pela análise da Tabela V pode-se observar que para o Experimento 1 o agente TA₅ exibiu média estatisticamente superior aos agentes TA₁, TA₂ e TA₃ mas não foi considerado significativamente diferente do agente TA₄. No Experimento 2 o agente TA₂ exibiu média estatisticamente superior aos agentes TA₁,

TA₃ e TA₅ mas não foi considerado significativamente diferente do agente TA₄. No Experimento 4 o que pode ser avaliado é que o agente TA₂ apresentou média estatisticamente inferior aos demais e que o agente TA₅ apresentou o mesmo comportamento verificado no Experimento 1.

De acordo com os resultados ilustrados na Tabela V pode-se concluir, portanto, que não foi possível identificar um único TA que apresentasse superioridade de desempenho consistente em todos os experimentos avaliados. Além disso, em nenhum dos experimentos os agentes TA₄ e TA₅ foram considerados distintos. Finalmente, no Experimento 2 não houve diferença estatisticamente significativa entre os diferentes TA.

REFERÊNCIAS

- [1] Z. Eisler and J. Kertesz, "Size matters: some stylized facts of the stock market revisited," *The European Physical Journal B-Condensed Matter and Complex Systems*, vol. 51, no. 1, pp. 145–154, 2006.
- [2] R. T. F. Nazário, J. L. e Silva, V. A. Sobreiro, and H. Kimura, "A literature review of technical analysis on stock markets," *The Quarterly Review of Economics and Finance*, vol. 66, pp. 115–126, 2017.
- [3] J. J. Murphy, *Technical Analysis of the Financial Markets: A Comprehensive Guide to Trading Methods and Applications*. New York Institute of Finance, 1999.
- [4] G. Scott, M. Carr, and M. Cremonie, *Technical Analysis: Modern Perspectives*, ser. CFA Institute Research Foundation Literature Reviews. CFA Institute Research Foundation, 2016.
- [5] R. W. Colby, *The Encyclopedia of Technical Market Indicators*, 2nd ed. McGraw-Hill, 2003.
- [6] R. C. Cavalcante, R. C. Brasileiro, V. L. Souza, J. P. Nobrega, and A. L. Oliveira, "Computational intelligence and financial markets: A survey and future directions," *Expert Systems with Applications*, vol. 55, pp. 194–211, 2016.
- [7] E. F. Sbruzzi, M. C. R. Leles, and C. L. Nascimento Júnior, "Introducing learning automata to financial portfolio components selection," in *2018 Annual IEEE International Systems Conference (SysCon)*, 2018, pp. 1–6.
- [8] M. C. R. Leles, L. A. Mozelli, E. F. Sbruzzi, C. L. Nascimento Júnior, and H. N. Guimarães, "A multicriteria trading system based on singular spectrum analysis trading rules," *IEEE Systems Journal*, 2019.
- [9] M. C. R. Leles, L. A. Mozelli, C. L. Nascimento Júnior, E. F. Sbruzzi, and H. N. Guimarães, "Study on Singular Spectrum Analysis as a new technical oscillator for trading rules design," *Fluctuations and Noise Letters*, vol. 17, no. 4, p. 1850034, 2018.
- [10] M. C. R. Leles, L. A. Mozelli, and H. N. Guimarães, "New trend-following indicator: Using SSA to design trading rules," *Fluctuation and Noise Letters*, vol. 16, no. 2, p. 1750016, 2017.
- [11] W. Brock, J. Lakonishok, and B. LeBaron, "Simple technical trading rules and the stochastic properties of stock returns," *Journal of Finance*, vol. 47, no. 5, pp. 1731–1764, 1992.
- [12] N. Taylor, "The rise and fall of technical trading rule success," *Journal of Banking & Finance*, vol. 40, pp. 286 – 302, 2014.
- [13] Y. M. Rekkik, W. Hachicha, and Y. Boujelbene, "Agent-based Modeling and Investors' Behavior Explanation of Asset Price Dynamics on Artificial Financial Markets," *Procedia Economics and Finance*, vol. 13, pp. 30 – 46, 2014, first Annual Tunisian Society for Financial Studies (TSFS) Finance Conference 2013.
- [14] J. D. Farmer and D. Foley, "The economy needs agent-based modelling," *Nature*, vol. 460, no. 7256, p. 685, 2009.
- [15] J.-P. Bouchaud, "Economics needs a scientific revolution," *Nature*, vol. 455, no. 7217, p. 1181, 2008.
- [16] M. Friedman and L. J. Savage, "The utility analysis of choices involving risk," *Journal of Political Economy*, vol. 56, no. 4, pp. 279–304, 1948.
- [17] E. F. Fama, "Efficient capital markets: A review of theory and empirical work," *The Journal of Finance*, vol. 25, no. 2, pp. 383–417, 1970.
- [18] A. Chakraborti, I. M. Toke, M. Patriarca, and F. Abergel, "Econophysics review: II. agent-based models," *Quantitative Finance*, vol. 11, no. 7, pp. 1013–1041, 2011.
- [19] T. Lux and M. Marchesi, "Volatility clustering in financial markets: a microsimulation of interacting agents," *International Journal of Theoretical and Applied Finance*, vol. 3, no. 04, pp. 675–702, 2000.
- [20] C. Chiarella and G. Iori, "A simulation analysis of the microstructure of double auction markets," *Quantitative Finance*, vol. 2, no. 5, pp. 346–353, 2002.

- [21] M. C. R. Leles, E. F. Sbruzzi, C. L. Nascimento Júnior, and J. M. P. Oliveira, "Trading Switching Setup Based on Reinforcement Learning Applied to a Multiagent System Simulation of Financial Markets," in *2019 Annual IEEE International Systems Conference*. IEEE, 2019, pp. 1–8.
- [22] M. C. R. Leles, E. F. Sbruzzi, C. L. Nascimento, and J. M. P. Oliveira, "A MatLab Computational Framework for Multiagent System Simulation of Financial Markets," in *2019 IEEE International Systems Conference (SysCon)*. IEEE, 2019, pp. 1–8.
- [23] E. F. Fama, "Efficient capital markets: II," *The Journal of Finance*, vol. 46, no. 5, pp. 1575–1617, 1991.
- [24] A. W. Lo, "Adaptive markets hypothesis: Market efficiency from an evolutionary perspective," *Journal of Portfolio Management*, vol. 30, pp. 15–29, 2004.
- [25] K. Raya, C. G. Gaxiola, and M. Castanon, "Agent-based model for self management of network flows using negotiation," *IEEE Latin America Transactions*, vol. 16, no. 1, pp. 210–215, 2018.
- [26] U. Wilensky and W. Rand, *An introduction to Agent-Based Modeling: Modeling Natural, Social, and Engineered Complex Systems with NetLogo*. MIT Press, 2015.
- [27] S. Abar, G. K. Theodoropoulos, P. Lemarinier, and G. M. O'Hare, "Agent based modelling and simulation tools: A review of the state-of-art software," *Computer Science Review*, vol. 24, pp. 13–33, 2017.
- [28] S. Maslov, "Simple model of a limit order-driven market," *Physica A: Statistical Mechanics and its Applications*, vol. 278, no. 3–4, pp. 571–578, 2000.
- [29] A. W. Lo, H. Mamaysky, and J. Wang, "Foundations of technical analysis: Computational algorithms, statistical inference, and empirical implementation," *The Journal of Finance*, vol. 55, no. 4, pp. 1705–1765, 2000.
- [30] R. Cont, "Empirical properties of asset returns: stylized facts and statistical issues," *Quantitative Finance*, vol. 1, no. 2, pp. 223–236, 2001.
- [31] M. Metghalchi, L. A. Hayes, and F. Niroomand, "A technical approach to equity investing in emerging markets," *Review of Financial Economics*, vol. 37, no. 3, pp. 389–403, 2019.
- [32] Y. Deng, F. Bao, Y. Kong, Z. Ren, and Q. Dai, "Deep direct reinforcement learning for financial signal representation and trading," *IEEE Transactions on Neural Networks and Learning Systems*, vol. 28, no. 3, pp. 653–664, 2017.
- [33] G. Yang, Y. Chen, and J. Huang, "The highly intelligent virtual agents for modeling financial markets," *Physica A: Statistical Mechanics and its Applications*, vol. 443, pp. 98 – 108, 2016.
- [34] K. Yim, G. Oh, and S. Kim, "Understanding financial market states using an artificial double auction market," *PloS One*, vol. 11, no. 3, p. e0152608, 2016.
- [35] R. F. Engle, "Autoregressive conditional heteroscedasticity with estimates of the variance of united kingdom inflation," *Econometrica*, vol. 50, no. 4, pp. 987–1007, 1982.
- [36] R. W. Banz, "The relationship between return and market value of common stocks," *Journal of Financial Economics*, vol. 9, no. 1, pp. 3–18, 1981.
- [37] W. Easterly and R. Levine, "What have we learned from a decade of empirical research on growth? it's not factor accumulation: Stylized facts and growth models," *The World Bank Economic Review*, vol. 15, no. 2, pp. 177–219, 2001.
- [38] E. F. Fama, "Market efficiency, long-term returns, and behavioral finance," *Journal of Financial Economics*, vol. 49, no. 3, pp. 283–306, 1998.
- [39] B. Yandell, *Practical Data Analysis for Designed Experiments*, ser. Chapman & Hall/CRC Texts in Statistical Science. Taylor & Francis, 1997.
- [40] D. Freedman, R. Pisani, and R. Purves, "Statistics (international student edition)," *Pisani, R. Purves, 4th edn. WW Norton & Company, New York*, 2007.



Michel C. R. Leles Possui graduação em Engenharia de Controle e Automação pela Universidade Federal de Minas Gerais (UFMG). Possui Mestrado e Doutorado em Engenharia Elétrica, também pela UFMG. Desde 2010 é Professor da Universidade Federal de São João del-Rei, Campus Alto Paraopeba, lotado no Departamento de Tecnologia. Sua pesquisa tem enfoque na grande área de *Data Science*, especialmente incluindo ferramentas de inteligência artificial, análise de séries temporais, processamento de sinais e finanças computacionais.



Marcos V. L. Pereira Possui graduação em Engenharia de Controle e Automação pela Universidade Federal de Minas Gerais (UFMG) concluída em 2003. Possui Mestrado em Engenharia Elétrica (UFMG) concluído em 2006, e Doutorado em Finanças/Administração (UFMG), concluído em 2020. Desde 2013 é Professor da Universidade Federal de São João del-Rei, Campus Alto Paraopeba, onde atua nos cursos de Engenharia Mecatrônica e Engenharia de Telecomunicações. Tem interesses relativos a pesquisas em finanças (teoria dos portfólios e análises de séries financeiras); modelagem e controle de sistemas dinâmicos; e inteligência computacional.



Robert A. Iquiapaza Possui graduação em Economia pela Universidad Nacional de San Agustín (UNSA). Possui Mestrado e Doutorado em Finanças/Administração pela Universidade Federal de Minas Gerais (UFMG). Desde 2010 é Professor da UFMG, onde atua principalmente nos cursos de graduação em Controladoria e Finanças e Administração; e nos cursos de mestrado/doutorado em Administração e Controladoria e Contabilidade. Tem interesse de pesquisas em finanças corporativas, mercado de capitais e financeiros, modelos econômicos, séries financeiras, modelagem e simulação computacional.



Elton F. Sbruzzi PhD em Finanças Computacionais pela *University of Essex*, UK. Mestre em Economia pela Universidade Federal do Rio Grande do Sul. Graduado em Economia pela Universidade Estadual de Campinas. Professor Adjunto na Divisão de Ciência da Computação do Instituto Tecnológico de Aeronáutica, desde 2018. Desenvolve pesquisa interdisciplinar abrangendo a aplicação de Ciência de Dados e Inteligência Artificial em várias áreas do conhecimento.



Cairo L. Nascimento Júnior Possui graduação em Engenharia Elétrica pela Universidade Federal de Uberlândia, mestrado em Engenharia Eletrônica e Computação pelo Instituto Tecnológico de Aeronáutica (ITA) e doutorado em Engenharia Elétrica e Eletrônica pela *University of Manchester Institute of Science and Technology, Control Systems Centre*, UK. Atua como professor no ITA, Divisão de Engenharia Eletrônica, Departamento de Sistemas e Controle, desde 1986. Tem experiência na área de Engenharia Elétrica, com ênfase em Controle de Sistemas Dinâmicos e na aplicação de técnicas de inteligência computacional para o desenvolvimento de soluções para problemas reais.