

Efeito da atenção do investidor na eficiência do mercado brasileiro de ações

Marcelo Guzella¹

 <https://orcid.org/0000-0001-5243-8897>
E-mail: marcelo.guzella@professores.ibmec.edu.br

F. Henrique Castro²

 <https://orcid.org/0000-0001-7456-2354>
E-mail: henrique.castro@fgv.br

Verônica de Fátima Santana³

 <https://orcid.org/0000-0002-9105-7488>
E-mail: veronica.santana@fecap.br

¹ Ibmec BH, Departamento de Economia, Belo Horizonte, MG, Brasil
² Fundação Getúlio Vargas, Escola de Economia de São Paulo, São Paulo, SP, Brasil
³ Fundação Escola de Comércio Álvares Penteado, São Paulo, SP, Brasil

Recebido em 21.07.2022 – Desk aceite em 01.08.2022 – 2ª versão aprovada em 29.05.2023
Editor-Chefe: aprovado por Fábio Frezatti, publicado por Andson Braga de Aguiar
Editor Associado: Fabio Gallo Garcia

RESUMO

O objetivo deste artigo foi avaliar a relação entre atenção do investidor, tanto o profissional quanto o não profissional, e a eficiência de mercado brasileiro de ações medida pela previsibilidade dos retornos diários. O papel da atenção do investidor no mercado de capitais é tema controverso, dado que, enquanto alguns estudos evidenciam que ela é capaz de induzir eficiência, outros apontam que contribui essencialmente para maior volatilidade devido a vieses comportamentais. Este trabalho contribui para a literatura de finanças comportamentais, sendo pioneiro na análise do efeito que a atenção do investidor induz aos preços das ações brasileiras. Além disso, não encontramos trabalhos anteriores que comparassem o efeito na eficiência de mercado advindo da atenção de diferentes classes de investidores, medida por meio do acesso a diferentes provedores de informações financeiras. A análise da atenção do investidor medida pelo volume de buscas feitas na internet é pertinente ante a crescente abundância de dados e a inclusão digital. Evidenciar um efeito da atenção na eficiência de mercado contribui para a crítica a essa hipótese clássica. O método consistiu em estimar modelos autorregressivos usando dados diários de 2018 a 2021 de volume de buscas, retornos e volume de transações de ações brasileiras, incluindo interação entre retorno e volume de buscas, para avaliar a influência da atenção na dinâmica dos preços. Neste trabalho, evidenciamos que, no mercado de ações brasileiro, a atenção do investidor contribui para maior eficiência de mercado, medida pela menor previsibilidade dos retornos, mas o efeito mais proeminente advém da atenção do investidor não profissional. Entender como a atenção influencia a incorporação da informação nos preços contribui para uma crítica à hipótese de eficiência de mercado, além de possibilitar a obtenção de ganhos explorando oportunidades a partir do nível de atenção de determinada classe de investidores.

Palavras-chave: finanças comportamentais, atenção do investidor, volume de buscas na internet, previsibilidade de retornos.

Endereço para correspondência

Marcelo Guzella

Ibmec BH, Departamento de Economia
Rua Rio Grande do Norte, 300 – CEP: 30130-130
Funcionários – Belo Horizonte – MG – Brasil

Este é um texto bilíngue. Este artigo também foi traduzido para o idioma inglês, publicado sob o DOI <https://doi.org/10.1590/1808-057x20231635.en>
Este artigo deriva de uma tese de doutorado defendida pelo autor Marcelo Guzella, em 2020.

Trabalho apresentado no XIX Encontro Brasileiro de Finanças, Rio de Janeiro, RJ, Brasil, julho de 2019, e no 6º Encontro Brasileiro de Economia e Finanças Comportamentais, agosto de 2019, São Paulo, SP, Brasil.



1. INTRODUÇÃO

A hipótese de incorporação imediata das informações relevantes no preço dos ativos é uma das mais conhecidas em finanças. Como justificativa teórica, argumenta-se que incentivos, agregação de informação entre investidores e a atuação de arbitradores garantem essa incorporação. No entanto, fenômenos encontrados desafiam esses argumentos, como a autocorrelação dos retornos e efeitos de reversões e de *momentum*. Modelos teóricos têm tentado explicar essas anomalias, como os trabalhos de Amihud (2002) e Barberis et al. (1998).

É razoável imaginar que essas anomalias possam advir também de flutuações nos níveis agregados de atenção. A atenção é um recurso escasso e varia ao longo do tempo. Trabalhos da área de psicologia documentam que pessoas conseguem digerir apenas um subconjunto das informações disponíveis devido a restrições de tempo, e isso pode levar a sobre- ou sub-reações. É o caso do modelo de Sims (2005), que considera a ideia de que a maioria das pessoas pode facilmente encontrar muito mais informação relevante para sua tomada de decisão do que de fato usa para decidir. Essa chamada inatención irracional se baseia na premissa de que agentes têm de selecionar as informações relevantes dentre as disponíveis.

Diversos estudos têm endereçado essa questão nos últimos anos. O modelo de Falkinger (2008), que determina que empresas competem primeiramente pela atenção das pessoas para depois competir pela sua propensão a consumir, contribui para explicar fenômenos documentados, como o *home bias* (Mondria & Wu, 2010; Van Nieuwerburgh & Veldkamp, 2007) e o *equity premium puzzle* (Gabaix & Laibson, 2005).

Nesse contexto, investigamos empiricamente, neste trabalho, o impacto da capacidade limitada de processamento de informações nos preços das ações. A atenção a tanta informação é decisiva para o comportamento dos mercados, o que justifica entender bem qual o efeito transmitido. Por um lado, o excesso de atenção de investidores não profissionais pode criar ruído adicional e volatilidade (Barber & Odean, 2008; Da et al., 2011). Por outro lado, mais atenção pode significar mais informação absorvida pelo mercado, aumentando sua eficiência. Essa conjectura é denominada hipótese de descoberta da informação (Fang & Peress, 2009; Grullon et al., 2004). Ela determina que mais informação absorvida

e refletida nos preços torna os mercados essencialmente menos previsíveis e, por isso, mais eficientes.

Diversos trabalhos anteriores desenvolveram análises para compreender melhor o efeito da atenção do investidor nos mercados financeiros. Dentre esses, pode-se citar o modelo de Andrei e Hasler (2015) sobre o papel da atenção e da incerteza na volatilidade e nos prêmios de risco e a avaliação de Zhang et al. (2013) sobre retornos anormais. Esses trabalhos são referências importantes para examinar o papel da atenção no contexto do mercado de capitais brasileiro.

Nosso trabalho contribui para a literatura de finanças comportamentais sendo pioneiro na análise do efeito que a atenção do investidor induz ao processo de transmissão das informações aos preços das ações brasileiras. Além disso, comparamos o efeito na eficiência de mercado advindo do acesso a diferentes provedores de informações financeiras, sendo um desses o Google, para investidores não profissionais, e o outro a Bloomberg, para profissionais. Não encontramos trabalhos anteriores que realizassem comparação com esse tipo de segregação, o que motiva a abordagem desse problema de pesquisa. Além de explorar as potencialidades da medição da atenção a partir dos volumes de busca feitas na internet, os resultados contribuem para a crítica à hipótese de eficiência de mercado, a identificação de perfis de investidores e o melhor entendimento sobre a previsibilidade dos mercados.

Buscamos, neste estudo, responder se a atenção de investidores profissionais e não profissionais pode afetar a previsibilidade do mercado de ações brasileiro. Nossos achados também podem ajudar empresas que querem ser mais vistas pelos investidores. Entender como a atenção influencia a incorporação da informação nos preços contribui para uma melhor gestão da divulgação de *releases* e publicidade. Além disso, outros participantes do mercado (por exemplo, arbitradores) podem se beneficiar de suas previsibilidades, avaliando o nível de atenção de determinada classe de investidores.

O artigo está estruturado da seguinte forma: na próxima seção, é apresentada a teoria que embasa o estudo, assim como trabalhos anteriores com temas correlatos. Em seguida, descrevemos a metodologia implementada. Por fim, apresentamos os resultados, testes de robustez e considerações finais.

2. REVISÃO DA LITERATURA

Transações comerciais ocorrem entre indivíduos devido a heterogeneidades de preferências, de riquezas ou de crenças. Com foco nas diferenças em crenças, Grossman e Stiglitz (1980) apresentaram uma série de conjecturas descrevendo o mercado como um sistema no qual preços, por meio das ordens de compra e venda, exercem o papel de transferir informações dos mais para os menos informados. Esse sistema não pode estar sempre em equilíbrio, pois isso tiraria qualquer possibilidade de arbitradores terem ganhos a partir de suas atividades custosas. Por isso, teorizam que os preços refletem apenas parcialmente a informação de arbitradores. Dessa forma, gastos com obtenção de informação são compensados.

O trabalho seminal de Grossman e Stiglitz (1980) é base para um paradigma que desafia a ideia de que preços imediatamente refletem toda a informação disponível. Em um processo de incorporação da informação baseada em flutuações no número de informados e em sua utilidade esperada, o nível de atenção dos agentes deve preencher um papel essencial.

Merton (1987) também faz uma crítica a premissas da teoria clássica, como a de que empresas podem levantar capital imediato e suficiente para investimentos e a pouca importância dada a intermediários financeiros. O autor questiona se os avanços na identificação de anomalias empíricas levarão ao descarte do paradigma de comportamento racional ou se isso poderá ser resolvido nesse arcabouço tradicional. Um modelo de equilíbrio de mercado é proposto, com heterogeneidade na absorção de informações pelos investidores. O modelo considera que um investidor está informado sobre um ativo se ele sabe seus parâmetros (retorno esperado, taxa de investimento físico e constantes de tecnologia de produção). A condição básica para um investidor considerar um ativo na composição da sua carteira é saber desse ativo. Merton (1987) argumenta que, no equilíbrio, o valor de mercado de determinada empresa será sempre menor com informação incompleta, com efeito similar a uma taxa de desconto adicional. Quanto maior a base de investidores, maior será essa diferença. O retorno esperado adicional é proporcional ao custo oculto dessa informação incompleta. A carteira de mercado não é eficiente em termos de média-variância nesse modelo de informação incompleta.

Sims (2005) examina como o nível de atenção contribui para o processo de absorção da informação e encontra que a inércia na reação dos agentes econômicos à disponibilização de informação externa se deve à capacidade limitada da atenção. Essa inércia é tipicamente tratada em modelos

econômicos por meio de custos de ajuste ou atraso de informação ou de implementação. Trabalhos que abordam essas questões comumente apresentam limitações, como a de assumir que os preços são observados sem erros. Isso é equivalente a assumir capacidade de processamento de informação sem restrições.

Atualmente, pode-se questionar se avanços na identificação de anomalias empíricas resultarão na total superação do paradigma do comportamento racional, ou se essa questão será resolvida com base nesse modelo tradicional. Grullon et al. (2004) analisaram os efeitos desse processo gradual de incorporação das informações nos preços, supondo que o impacto da visibilidade da firma entre seus investidores tem ações no mercado de capitais. Com base nessa hipótese, verificaram se o montante gasto com publicidade pela empresa afeta a liquidez de suas ações e sua base de investidores. Seus achados, robustos a diferentes metodologias, evidenciaram que empresas mais visíveis têm ações com maior liquidez e maior número de investidores individuais e profissionais na sua base.

Usando dados de 1993 a 2002 das ações listadas na New York Stock Exchange (NYSE), Fang e Peress (2009) encontraram relação negativa entre cobertura da mídia e retornos. A cobertura da mídia foi apurada pela contagem de artigos em mídia impressa de circulação em massa. Dividindo as ações em tercís segundo o grau de cobertura, foi encontrado retorno anual diferencial de 4,8% entre grupos de ações sem e com muita cobertura (carteiras igualmente ponderadas). Esse prêmio por falta de cobertura se mantém ao controlar por diversas características, como tamanho.

Um dos primeiros trabalhos a investigar, empiricamente e usando dados da internet, a influência da atenção na eficiência de mercado foi o de Vozlyublenniaia (2014). Em uma abordagem inicial, a autora verificou que a atenção dada a um índice tem efeito de curto prazo significativo no seu retorno. Isso é consistente com a hipótese de que informação não descoberta pode ser percebida por investidores como indicando um retorno mais alto (baixo) no futuro e, então, isso levaria a um aumento (redução) nos retornos do ativo. Essa evidência é diferente da ideia de que um aumento na atenção geraria uma pressão de compra e, conseqüentemente, aumento nos preços, estabelecida por Barber e Odean (2008). O impacto dos retornos na atenção, em contrapartida, mostrou-se de longo prazo.

Vozlyublenniaia (2014) avaliou a dinâmica entre variáveis de mercado (retorno e volatilidade) e atenção do investidor para seis diferentes índices de ativos: ações

(Dow Jones Industrial, S&P 500 e Nasdaq), *bonds* (Chicago Board Options Exchange 10 Year Treasury Note Yield Index), *commodities* (índice de óleo cru West Texas Intermediate) e ouro (Chicago Board Options Exchange Gold). A atenção foi medida pelo volume de buscas por cada índice no Google. Os dados foram obtidos em frequência semanal de janeiro de 2004 a dezembro de 2012.

A avaliação do efeito da atenção na previsibilidade dos retornos foi feita incluindo termos de interação de retornos e atenção defasados em modelos autorregressivos. Os resultados mostraram efeitos significativos nessas interações e, mais importante, inversos aos efeitos de autocorrelação. Isso significa que a atenção reduz as autocorrelações dos retornos. Em outras palavras, choques de atenção reduzem a previsibilidade dos retornos e, conseqüentemente, aumentam a eficiência do mercado. As regressões foram controladas por possíveis mudanças nas oportunidades de investimento usando variáveis macroeconômicas.

Os resultados mostraram que os termos de interação indicaram impacto da atenção na redução da previsibilidade nos índices Dow, S&P 500 e de petróleo. Os índices de *commodities* e *bonds* não mostraram relação significativa. No índice da Nasdaq, o mesmo sinal foi encontrado nas autocorrelações e nas interações. Choques de atenção mostraram redução também na previsibilidade da volatilidade de curto prazo nos índices Dow, Nasdaq, ouro e petróleo.

Tantaopas et al. (2016) também investigaram a relação entre atenção e eficiência de mercado, examinando o impacto da quantidade de buscas na internet em variáveis de mercado (retorno, volatilidade e volume de negócios). Os autores endereçaram mercados desenvolvidos e em desenvolvimento da Ásia-Pacífico, relativamente pouco explorados para esse tipo de estudo. A hipótese de descoberta da informação, segundo os autores, segue um processo cíclico que inicia com um retorno anormal devido à reação do mercado a algum evento corporativo. Se esse evento é suficiente para capturar a atenção de alguns investidores, esses investigarão informações sobre a ação da companhia. Caso encontrem notícias boas (ruins), poderão tomar a decisão de comprar (vender) aquela ação, o que resultará no aumento (redução) do seu preço. Segundo eles, a pressão positiva dos preços por excesso de atenção não explica eventos de queda nos preços e não se mantém numa realidade em que vendas a descoberto são permitidas.

Os autores obtiveram dados semanais de volumes de busca no Google de janeiro de 2004 a dezembro de 2014. Foram apurados os índices que contemplam fatias representativas do mercado total, um por país. A eficiência de mercado foi medida pela previsibilidade

dos retornos, das volatilidades e do volume de negócios. Assim como em Vozlyublennai (2014), foram utilizadas interações entre os componentes defasados dessas séries e os da série de atenção. Utilizando uma especificação de vetores autorregressivos (VAR), verificaram aumento da eficiência de mercado em seis países: Hong Kong, Índia, Malásia, Japão, Coreia e Singapura. Nesses três últimos, a presença de uma unidade de atenção contribuiu para a redução na previsibilidade dos retornos em 34,1%, 35,8% e 36,8%, respectivamente.

Com relação à volatilidade, buscas na internet contribuíram para aumentar a eficiência em oito dos 10 mercados (o padrão só não foi evidenciado na Nova Zelândia e Tailândia). Na China, a redução na previsibilidade foi de 56,1%. De forma geral, o efeito de aumento na eficiência foi mais forte em mercados desenvolvidos que em desenvolvimento. No caso das volatilidades, o efeito inverso foi evidenciado. Já a capacidade de a atenção reduzir a previsibilidade da quantidade de negócios não foi encontrada de forma tão expressiva. Somente em Singapura tal efeito foi verificado. Os autores também concluíram que a maioria das relações de causalidade é unidirecional: mudanças em retorno, volatilidade e volume de negócios determinaram mudanças na atenção. Além disso, o sinal da relação depende de quanto tempo se passou desde o impacto, que são de vida curta tanto para países desenvolvidos quanto em desenvolvimento. Esses trabalhos tiveram resultados convergentes na avaliação do efeito da atenção na eficiência dos mercados financeiros.

Este estudo inova ao investigar pioneiramente ações brasileiras individuais em frequência diária. Além disso, verifica duas classes distintas de investidores: profissionais e individuais. Essa abordagem contribui para verificar se esse padrão se mantém nesse importante mercado em desenvolvimento. De acordo com os achados da literatura anterior, esperamos que maiores níveis de atenção diminuam a previsibilidade dos retornos, ou seja:

H_1 : um aumento na atenção dos investidores promove maior eficiência de mercado.

Lux e Marchesi (1999) estabeleceram uma relação entre a atenção de determinados investidores e a volatilidade não fundamental nos mercados. Barber e Odean (2008) evidenciaram o papel de investidores não profissionais na ocorrência de retornos anormais. Como essa classe de investidores está mais susceptível a vieses comportamentais (Cronqvist & Siegel, 2014), sua força pode afetar uma transmissão adequada das informações aos preços. Dentre esses vieses, podem ser citados o de saliência, de ancoragem, de custo afundado, de *status*

quo, de representatividade, o efeito dotação, aversão à perda, a falácia da conjunção e o excesso de autoconfiança (Burton & Shah, 2013).

Assim, pressupondo que nossa primeira hipótese é verdadeira e considerando que o excesso de atenção de investidores não profissionais é mais reconhecido por gerar ruído adicional e volatilidade, apresentamos a segunda hipótese:

H₂: a atenção de investidores profissionais contribui mais para a eficiência de mercado.

3. METODOLOGIA

Nesta seção, descrevemos como foram testadas as hipóteses de redução na previsibilidade induzida por atenção. Apresentamos detalhes sobre as fontes e propriedades das informações financeiras e de volumes de busca, assim como os modelos empíricos e as relações esperadas.

3.1 Amostra

Optamos por analisar o universo de ações individuais já que, embora seja escassa a literatura sobre a influência da atividade na internet no comportamento de índices, é ainda mais escassa para ações individuais. Além disso, a medida de atenção do investidor profissional adotada neste estudo está disponível apenas para esse tipo de ativo. Dessa forma, escolhemos formar nossa amostra a partir das 92 ações que faziam parte do índice Bovespa (Ibovespa) durante o segundo quadrimestre de 2022.

O Ibovespa, o mais popular índice de ações brasileiro, foi criado em 1968 e representa uma referência para investidores no mundo todo. As ações que fazem parte do índice correspondem a cerca de 85% do volume negociado no mercado de capitais brasileiro (B3 S.A. – Brasil, Bolsa, Balcão [B3], 2015). A carteira de ações que serão parte do Ibovespa é redefinida a cada 4 meses. O critério para esse processo leva em consideração, principalmente, o volume de negócios e a presença nos pregões. Os ativos que compõem o Ibovespa são ponderados pelos seus respectivos valores de mercado. Os critérios de seleção dos ativos são descritos em Castro et al. (2019).

Nossa análise compreende indicadores da atenção de investidores tanto profissionais quanto não profissionais. Para a atenção dos investidores não profissionais, foram obtidas séries do volume de buscas feitas no Google. O Google é a ferramenta de busca mais popular do Brasil e da maioria dos países do mundo (Statista, 2014). Por não ser uma ferramenta específica para análises financeiras e por ser gratuita, costuma ser utilizada por investidores

Avaliamos a diferença entre os efeitos das duas diferentes classes de investidores comparando, em cada caso e para um mesmo instante de tempo, as magnitudes (i) do coeficiente que indica previsibilidade dos retornos e (ii) do coeficiente que indica a relação entre retorno e atenção daquela classe. Tendo esses dois coeficientes sinais opostos, quanto mais próximas são suas magnitudes, maior é o efeito de atenuação da previsibilidade pela atenção.

As próximas seções abordam, em mais detalhes, a maneira e as informações com que a análise dessas hipóteses será endereçada.

menos sofisticados. Da et al. (2011) evidenciaram que as buscas no Google capturam a atenção de investidores não profissionais analisando sua correlação com (i) sugestões de ações em programas para o público em geral e (ii) volume de ordens de compra e venda de investidores de varejo.

Dessa forma, no Google Trends, obtivemos séries diárias do índice que refletem o volume de buscas, individualmente, de todas as 92 ações que formavam esse índice no segundo quadrimestre de 2022. Para extrair as séries do índice representativo do volume de buscas no Google de cada ação individual, adotamos como palavra-chave exatamente o *ticker* de cada ação. Essa estratégia evita a influência de buscas feitas com objetivos diferentes de negociação na bolsa de valores, como para consumo e oportunidades de emprego. Além disso, foram filtradas apenas as buscas feitas no Brasil, para evitar efeitos relacionados a fusos horários. Por uma limitação do Google Trends (séries diárias podem ser coletadas por um período máximo de 9 meses e séries semanais podem ser coletadas por um período máximo de 5 anos), primeiro obtivemos as séries diárias por períodos de 9 meses separadamente e depois as concatenamos utilizando o método proposto por Johansson (2014), a partir das séries semanais para o período de janeiro de 2018 a dezembro de 2022. Em seguida, as séries de busca foram normalizadas para ter média 0 e desvio-padrão (DP) unitário, facilitando a interpretação dos resultados.

Com relação à atenção profissional, extraímos as séries de volume de buscas na Bloomberg para cada ação individual que fazia parte do Ibovespa no segundo quadrimestre de 2022, para realizar a análise. A Bloomberg é um provedor pago de informações financeiras que tem interface específica e mais completa e é bastante usado por investidores profissionais e institucionais, como gestores de portfólio e analistas *buy-side* e *sell-side*. Ben-Rephael et al. (2017) apontaram que em torno de 80% dos usuários da Bloomberg trabalham no setor financeiro, incluindo bancos e gestoras

de ativos. Diferentemente das buscas no Google, pesquisas na Bloomberg têm correlação significativamente maior com o volume de transações de investidores institucionais do que com o volume geral. Utilizamos a mesma variável adotada por Ben-Rephael et al. (2017): a News Heat – Daily Max Readership, que combina o número de vezes que cada artigo foi lido pelos usuários com o número de vezes que informações de uma ação específica foram pesquisadas. As séries da Bloomberg foram exportadas para o Excel, usando o *add-in* apropriado, e também foram normalizadas para ter média 0 e DP unitário.

Para as séries diárias dos dois tipos de medidas de atenção, consideramos somente dias em que houve pregão. Como esperado, encontramos diversos dias sem informação disponível, principalmente no início do

período da amostra, já que algumas ações são novas. Por isso, devido à insuficiência de dados, a amostra final contou com apenas 34 das 92 ações. Foram excluídas as ações que não tinham dados por trimestres inteiros ao longo da amostra e que, após essa exclusão, tinham menos de 50% de dados de *search volume* (SV) disponíveis, seja do Google (GSV) ou da Bloomberg (BSV). A Tabela 1 apresenta as empresas da amostra final e suas respectivas ações agrupadas por segmento. Sinalizamos em negrito as ações com maior representatividade no índice, que juntas totalizam mais de 32%.

Depois de obterem os indicadores de atenção, obtemos os log-retornos diários ajustados por dividendos e volume de negócios de cada ação da amostra. As séries foram obtidas na Economatica®.

Tabela 1
Amostra de ações

Setor	Empresa	Ticker	% no Ibovespa
Água e saneamento	Cia de Saneamento Básico de São Paulo	SBSP3	0,75
	BRF	BRFS3	0,73
Alimentos processados	JBS	JBSS3	2,43
	Marfrig	MRFG3	0,32
	Minerva	BEEF3	0,17
	Banco Bradesco	BBDC3	1,12
Bancário	Banco do Brasil	BBDC4	4,61
	Itaú Unibanco	ITUB4	5,66
	Banco do Brasil	BBAS3	2,34
Bebidas	AmBev	ABEV3	3,16
	Centrais Elétricas Brasileiras	ELET3	0,72
Energia elétrica	Centrais Elétricas Brasileiras	ELET6	0,48
	Cia Energética de Minas Gerais	CMIG4	0,78
	CPFL Energia	CPFE3	0,31
	Eneva	ENEV3	0,86
Engenharia e construção	MRV Engenharia	MRVE3	0,15
Exploração de imóveis	BR Malls Participações	BRML3	0,39
Fabricação de aeronaves	Embraer	EMBR3	0,52
Farmacêutico	RaiaDrogasil	RADL3	1,11
	Companhia Siderúrgica Nacional	CSNA3	0,65
Metalurgia e mineração	Gerdau	GGBR4	1,52
	Usiminas	USIM5	0,29
	Vale	VALE3	15,58
	Cosan	CSAN3	1,22
Petróleo, gás e biocombustíveis	Petro Rio	PRIO3	1,11
	Petrobras	PETR3	4,49
	Petrobras	PETR4	6,86
	Braskem	BRKM5	0,53
Químico	Braskem	BRKM5	0,53
Saúde	Qualicorp	QUAL3	0,18
Seguros	BB Seguridade	BBSE3	0,85
Serviços financeiros	Cielo	CIEL3	0,19
Telecomunicações	Telefônica Brasil	VIVT3	1,09
Transporte	CCR	CCRO3	0,69
Transporte aéreo	Gol Linhas Aéreas Inteligentes	GOLL4	0,13

Nota: Algumas companhias têm mais de uma classe de ações, com diferentes direitos. A representatividade no valor de mercado do índice Bovespa (Ibovespa) diz respeito à posição de 23 de junho de 2022. Sinalizamos em negrito as ações com maior representatividade no índice.

Fonte: Elaborada pelos autores.

3.2 Modelo

Para esse teste, adaptamos o método aplicado por Tantaopas et al. (2016) e Vozlyublennaia (2014). Quando o mercado está informacionalmente eficiente, não há dependência serial nos retornos dos ativos (Fama, 1965). Retornos com dependência serial são, ao menos parcialmente, previsíveis. Então, mais eficiência de mercado implica menos previsibilidade dos retornos.

Tantaopas et al. (2016) e Vozlyublennaia (2014) estimaram VAR das séries de retornos e de SV, incluindo um termo de interação entre os *lags* de retorno e de SV, de modo a verificar como níveis de atenção alteram a autocorrelação dos retornos e, portanto, seu grau de previsibilidade. Enquanto Tantaopas et al. (2016) e Vozlyublennaia (2014) trabalharam com índices agregados de mercado, nossa análise tem formato de painel, já que analisamos diversas ações (N) por diversos períodos de tempo (T). Usualmente, estimações com dados em painel dependem de premissas

assintóticas válidas para painéis curtos, isto é, quanto $N > T$ e N tende a infinito. No entanto, nesta pesquisa, temos $N = 34$ e $T = 940$, formando um painel longo, no qual as inferências devem ser feitas com base na premissa de que T tende a infinito, ou seja, características de séries de tempo devem ser incorporadas no modelo. Conforme Cameron e Trivedi (2005), painéis longos podem ser estimados incorporando um modelo autorregressivo de média móvel (ARMA) para os erros e permitindo que os parâmetros difiram entre as empresas; estimando via *feasible generalized least squares* (FGLS), é possível obter estimativas consistentes para os parâmetros permitindo que os retornos se correlacionem no tempo e entre as empresas. Além disso, como trabalhamos com ações individuais, incluímos no modelo o retorno do Ibovespa como variável de controle.

Nesse sentido, a equação 1 apresenta o modelo do painel autorregressivo (PAR) para os retornos das ações, tal que c é a constante, $r_{t-j,i}$ são os retornos defasados e $\epsilon_{t,i}$ são os termos de erro.

$$r_{t,i} = c + \sum_{j=1}^p [\beta_j r_{t-j,i} + \theta_j SV_{t-j,i} + \delta_j (r_{t-j,i} \times SV_{t-j-1,i})] + \gamma r_{mt} + \epsilon_{t,i} \quad 1$$

O volume de buscas (*search volume*) $SV_{t,i}$ é a *proxy* que representa a atenção. Como mencionado, são usados, como variáveis de atenção, o volume de buscas no Google ($GSV_{t,i}$, ou *Google Search Volume*) e o volume de buscas na Bloomberg ($BSV_{t,i}$, ou *Bloomberg Search Volume*). Os índices i , t e j identificam, respectivamente, cada ação, período de tempo e defasagem. Dessa forma, regredimos os log-retornos ($r_{t,i}$) de cada ação i contra seus termos defasados ($r_{t-j,i}$), os termos de atenção defasados ($SV_{t-j,i}$) e a interação entre termos de retorno e termos de atenção defasados ($r_{t-j,i} \times SV_{t-j-1,i}$). A ordem p é a defasagem máxima dos regressores, definida de acordo com o critério de informação de Akaike, limitado a 5 dias.

Os coeficientes β_j indicam a relação entre $r_{t,i}$ e seus autorregressores. Em contrapartida, δ_j indica como a atenção dos dias anteriores afeta essa relação. Objetiva-se testar a hipótese de que a atenção reduz a previsibilidade dos retornos. Então, sempre que β_j apresenta efeito significativo de $r_{t-j,i}$ em $r_{t,i}$, esperamos que δ_j também mostre efeito significativo, mas oposto, de $r_{t,i} \times SV_{t-1,i}$ em $r_{t,i}$. Em outras palavras, esperamos que maiores níveis de atenção dos investidores reduzam o poder explicativo de retornos passados em retornos correntes.

O modelo permite identificar se, na ocorrência, por exemplo, de eventos corporativos, maiores níveis de atenção estão associados a menos choques transientes por sobre- ou sub-reação, que levam à autocorrelação e iriam de encontro à hipótese de mercado eficiente. Trata-se, portanto, de um teste da forma fraca de eficiência de mercado.

Nosso método também inclui uma especificação com o volume de negociações ($TV_{t,i}$, ou *trading volume*) como variável de controle. Então, o Modelo 1 considera retornos, volume de buscas e interações entre ambos, enquanto o Modelo 2 inclui também o volume de transações como quarto regressor. Não esperamos que o volume de transações altere a relação entre atenção e previsibilidade de retornos. Além do volume de transações, incluímos uma terceira especificação, acrescentando como variáveis de controle os índices preço/lucro (PL) e *market-to-book* (MTB), o tamanho da empresa (medida pelo logaritmo natural do valor de mercado em cada data), o risco da ação (estimado pela volatilidade condicional obtida de um modelo *generalized autoregressive conditional heteroskedasticity* (GARCH) padrão, a taxa dos Certificados de Depósitos Interbancários (CDI) e o *spread* temporal (estimado pela diferença entre os retornos do Índice de Duração Constante ANBIMA (IDkA) IPCA de 10 anos e o IDkA de 2 anos).

4. RESULTADOS EMPÍRICOS

Nesta seção, descrevemos a amostra, apresentando também as correlações entre os diferentes indicadores de volume de buscas. Em seguida, apresentamos os resultados da análise empírica dos efeitos da atenção do investidor na eficiência do mercado de ações.

4.1 Análise Descritiva

A Tabela 2 apresenta características gerais das variáveis envolvidas. A amostra final engloba 31.960 observações referentes a 34 ações e 940 dias de pregão. Para evitar o impacto de *outliers* na análise, as variáveis usadas foram winsorizadas a 1%.

Tabela 2

Estatística descritiva das séries de tempo

	Retorno	Volume (em R\$ milhões)	GSV	BSV	Log Volume
Estatísticas descritivas da amostra completa					
Média	0,048%	12,819	-0,033	-0	15,748
Desvio-padrão	2,569%	16,830	0,670	1	1,250
Mediana	-0,027%	7,515	-0,233	-0,654	15,832
Mínimo	-7,590%	0	-0,719	-0,654	10,624
Máximo	8,178%	490,230	3,355	2,087	18,235
Assimetria	0,197%	4,623	2,392	1,277	-1,144
Curtose	1,303%	46,361	7,750	0,041	3,294
Estatísticas descritivas das médias por ação					
Média	0,048%	12,819	-0,033	-0	15,748
Desvio-padrão	0,091%	13,022	0,264	0,712	1,069
Mediana	0,037%	8,022	-0,083	-0,314	15,719
Mínimo	-0,280%	0,773	-0,375	-0,654	11,989
Máximo	0,282%	68,750	0,726	1,473	17,867
Assimetria	-0,759%	2,610	1,201	0,791	-1,046
Curtose	3,908%	8,236	1,451	-1,012	2,868

Nota: Principais medidas estatísticas das séries de tempo (i) dos log-retornos nominais e ajustados por dividendos e splits, (ii) do volume monetário de transações (em R\$ milhões), (iii) do índice que representa o volume de queries de busca feitas no Google no Brasil e (iv) do índice que representa o volume de leituras e queries de busca na Bloomberg, todas relativas as 34 ações da amostra final. Volumes de transações são apresentados em sua forma regular e logarítmica. O painel superior mostra medidas considerando a amostra completa e o inferior mostra medidas estatísticas calculadas a partir dos valores médios por ação. Usados dados diários de 2018 a 2021.

BSV = Bloomberg search volume; GSV = Google search volume.

Fonte: Elaborada pelos autores.

As medidas evidenciam o volume médio diário de transações de aproximadamente R\$ 12 milhões. O retorno médio diário é de 4,8%, com DP de 257% e mediana de -2,70%. O maior retorno diário observado foi de 256,90% enquanto o menor foi de -759%. O maior volume de transações de uma ação individual em um dia foi 490

milhões, enquanto a maior média diária de negócios ao longo de todo o período e todas as ações foi superior a 68 milhões. Assim, mesmo após a winsorização, ainda há grande variação nos dados. Após a winsorização, as séries de busca no Google já não têm média 0 e DP unitário, indicando alta variação nessas séries.

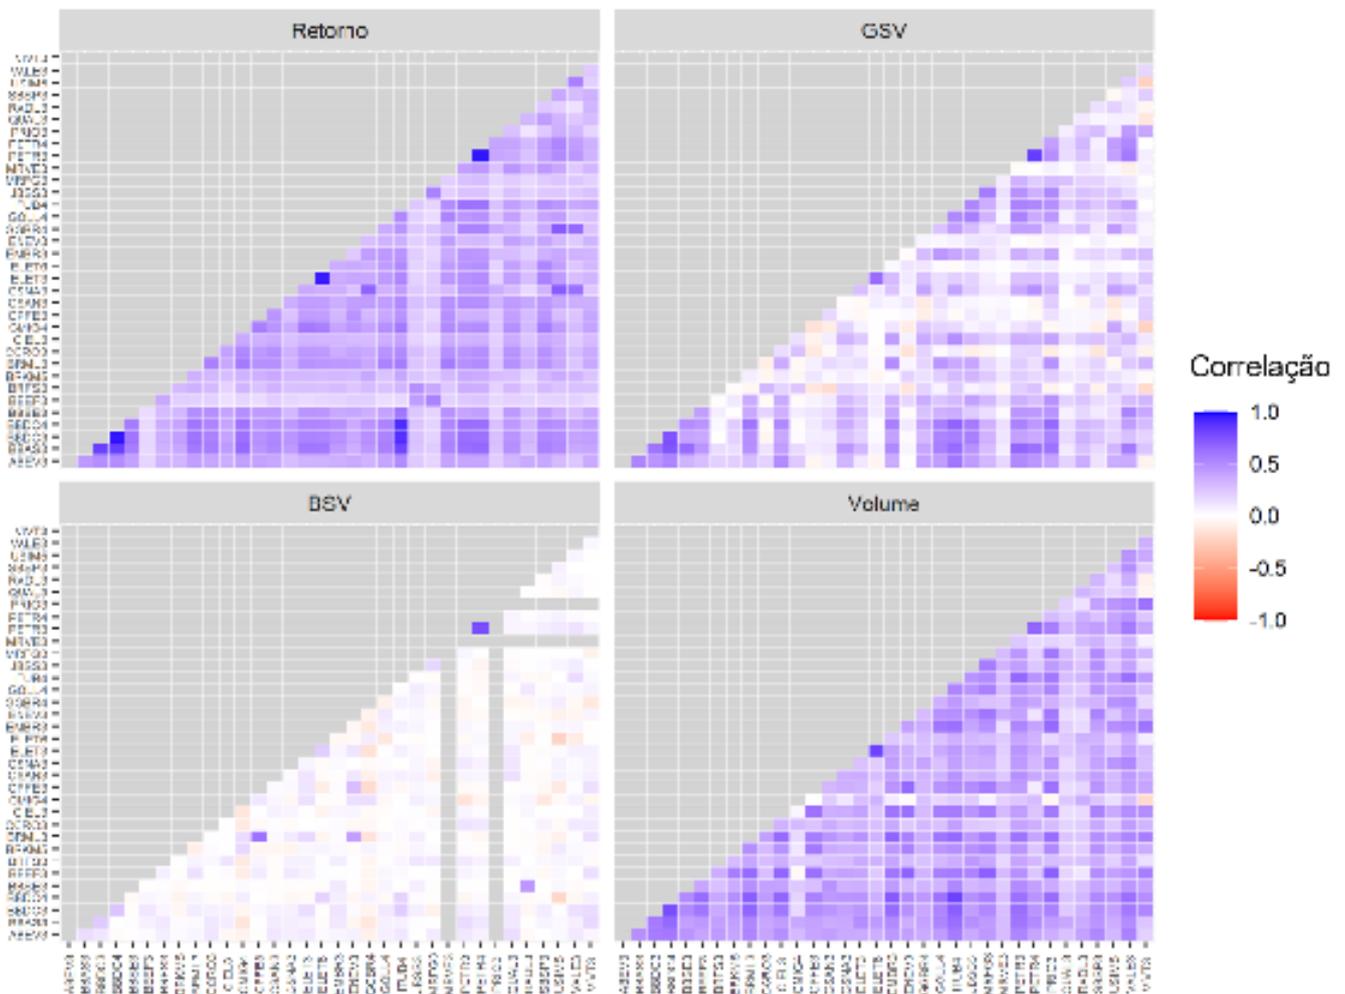


Figura 1 Correlação das variáveis entre os pares de empresa

Fonte: Elaborada pelos autores.

A Figura 1 apresenta as matrizes de correlação entre cada par de ação para o retorno, volume de transações (em logaritmo) e volume de buscas no Google e na Bloomberg. No geral, retorno e volume são correlacionados entre as ações. Na média, os retornos têm correlação de 43,8%, enquanto a correlação média do volume é de 38,4%. Já as séries de buscas têm correlações mais baixas. As buscas no Google têm correlação média de 18,4%, enquanto as buscas na Bloomberg têm correlação média de apenas 2,4%.

A Tabela 3 mostra a correlação entre as variáveis da análise, que capta apenas as correlações contemporâneas, mas a dinâmica temporal das variáveis será analisada com a aplicação do modelo e apresentada na próxima seção. Retorno tem correlação baixa com todas as variáveis, enquanto volume de negociação tem correlação relativamente alta com as medidas de atenção (31,17% com as buscas no Google e 28% com as buscas na Bloomberg). Por fim, os índices de busca têm correlação de apenas 12,5% entre si, sugerindo que os níveis de atenção dos investidores profissionais e de varejo nem sempre se alinham.

Tabela 3

Correlação entre as variáveis do modelo

	Retorno	log volume	GSV	BSV
Retorno	1			
log volume	0,0350	1		
GSV	0,0335	0,3171	1	
BSV	0,0274	0,2800	0,1248	1

BSV = Bloomberg search volume; GSV = Google search volume.

Fonte: Elaborada pelos autores.

Na próxima seção, apresentamos os resultados da modelagem dos retornos das ações por meio de equações com painéis autorregressivos. Essa especificação permite a verificação do efeito da atenção nessas autocorrelações.

4.2 Resultados da Modelagem

A Tabela 4 apresenta os resultados das regressões considerando a atenção não profissional, medida pelas buscas no Google. Os dois primeiros modelos mostram a estimação da equação 1, considerando as buscas no Google (*proxy* para a atenção não profissional) em duas versões, sem e com as defasagens do volume de negociação (em logaritmo). O terceiro modelo apresenta os resultados adicionando as demais variáveis de controle.

Tabela 4

Estimativas dos modelos autorregressivos com buscas no Google, representando a atenção não profissional dos investidores

	Modelo 1	Modelo 2	Modelo 3
	r_t	r_t	r_t
(Intercepto)	0,0096 (0,0119)	-0,1001 (0,0987)	-0,2528 (0,2053)
r_{t-1}	-0,0155*** (0,0047)	-0,0156*** (0,0047)	-0,0169*** (0,0047)
r_{t-2}	-0,0119** (0,0046)	-0,0116** (0,0046)	-0,0116** (0,0047)
r_{t-3}	-0,0017 (0,0046)	-0,0017 (0,0047)	-0,0027 (0,0047)
r_{t-4}	-0,011** (0,0046)	-0,0115** (0,0046)	-0,0128*** (0,0047)
r_{t-5}	0,006 (0,0047)	0,0058 (0,0047)	0,0055 (0,0047)
SV_{t-1}	0,0351* (0,0187)	0,0349* (0,019)	0,0332* (0,0192)
SV_{t-2}	-0,0226 (0,0219)	-0,0199 (0,0221)	-0,0222 (0,0223)
SV_{t-3}	0,0303 (0,022)	0,0298 (0,0221)	0,0336 (0,0223)
SV_{t-4}	-0,0153 (0,0219)	-0,019 (0,0221)	-0,0167 (0,0223)
SV_{t-5}	-0,0181 (0,0188)	-0,0204 (0,019)	-0,0185 (0,0192)
$r_{t-1} \times SV_{t-2}$	0,0124** (0,005)	0,0124** (0,005)	0,0125** (0,0051)
$r_{t-2} \times SV_{t-3}$	0,0018 (0,005)	0,0019 (0,005)	0,0003 (0,0051)
$r_{t-3} \times SV_{t-4}$	-0,0085* (0,005)	-0,0083* (0,005)	-0,0074 (0,0051)
$r_{t-4} \times SV_{t-5}$	0,0082 (0,005)	0,0083* (0,005)	0,0092* (0,0051)
$r_{t-5} \times SV_{t-6}$	-0,0141*** (0,0045)	-0,014*** (0,0045)	-0,0147*** (0,0045)
TV_{t-1}		-0,0054 (0,0213)	-0,0055 (0,0214)
TV_{t-2}		-0,0235 (0,0229)	-0,0208 (0,0231)

Tabela 4
Cont.

	Modelo 1	Modelo 2	Modelo 3
	r_1	r_1	r_1
TV_{t-3}		0,0012 (0,023)	0,0021 (0,0231)
TV_{t-4}		0,0295 (0,0229)	0,0295 (0,023)
TV_{t-5}		0,0051 (0,0212)	0,0009 (0,0213)
r_m	1,0251*** (0,0083)	1,0248*** (0,0083)	0,9976*** (0,0097)
P/L			-0,0002 -0,0002
MTB			0,0013 (0,0036)
$Tamanho$			0,0086 (0,0104)
$Risco$			-0,0106 (0,0183)
CDI			1,7635 (1,6341)
$Spread\ temporal$			0,156*** (0,0294)
Observações	31.790	31.790	31.428
Número de ações	34	34	34
Número de dias	935	935	935
Estatística de Wald	15.690***	15.716***	15.911***

Nota: Os modelos foram estimados com um painel via feasible generalized least squares (FGLS) com correção de Parks-Kmenta e estimação de erros AR(1) com correção Prais-Winsten.

*, **, *** = $p < 0,1$, $p < 0,05$, $p < 0,01$, respectivamente.

Fonte: Elaborada pelos autores.

Os três modelos mostram que existe autocorrelação negativa e significativa nos retornos diários das ações analisadas. Assim, os resultados indicam, inicialmente, que os retornos passados têm poder preditivo para os retornos futuros, contradizendo a premissa de não previsibilidade dos retornos da hipótese de mercados eficientes (HME). Em seguida, as estimações dos coeficientes θ_j mostram que um maior volume de buscas no Google está correlacionado com maiores retornos no dia seguinte, sugerindo que a atenção é maior em momentos otimistas. O retorno de mercado (Ibovespa) é altamente significativo em todas as especificações. Já as defasagens do volume de transações não foram significantes em nenhum modelo e, dentre as demais variáveis de controle, apenas o *spread* temporal é significativo. Por fim, as estimativas dos coeficientes δ_j , que medem o efeito moderador da atenção medida pelo volume de buscas no Google, mostram que, no geral, maior atenção está associada à menor autocorrelação. A

primeira e a quinta defasagem da interação são positivas e estatisticamente significantes, diminuindo o efeito da autocorrelação negativa encontrada.

Esse resultado está em linha com nossa primeira hipótese, isto é, de que um aumento na atenção dos investidores promove maior eficiência de mercado, uma vez que maiores níveis de buscas estão relacionados com menor previsibilidade de retornos.

A Tabela 5 mostra as mesmas especificações, considerando a atenção profissional medida pelas buscas na Bloomberg. A estrutura de autocorrelação dos retornos é a mesma dos modelos da Tabela 4, também contradizendo a premissa de não previsibilidade dos retornos da HME; mas, aqui, não há relação entre a atenção e os retornos correntes. As variáveis de controle também apresentam resultados semelhantes aos da Tabela 4. Já as interações entre os retornos defasados e os níveis de atenção, que medem o efeito moderador da atenção medida pelo

volume de buscas na Bloomberg, são significantes (a 10%) nas defasagens 1 e 4, também mostrando que maior atenção está associada à menor autocorrelação, também de acordo com nossa primeira hipótese.

Tabela 5

Estimativas dos modelos autorregressivos com buscas na Bloomberg representando a atenção profissional dos investidores

	Modelo 4	Modelo 5	Modelo 6
	r_t	r_t	r_t
(Intercepto)	0,0091 (0,0118)	-0,112 (0,1058)	-0,2585 (0,2111)
r_{t-1}	-0,0142*** (0,0046)	-0,0144*** (0,0046)	-0,0156*** (0,0046)
r_{t-2}	-0,0108** (0,0046)	-0,0106** (0,0046)	-0,0109** (0,0046)
r_{t-3}	-0,0029 (0,0046)	-0,0029 (0,0046)	-0,0038 (0,0046)
r_{t-4}	-0,0114** (0,0046)	-0,0118** (0,0046)	-0,013*** (0,0046)
r_{t-5}	0,003 (0,0046)	0,0029 (0,0046)	0,0024 (0,0046)
SV_{t-1}	0,0056 (0,0113)	0,0046 (0,0114)	0,0046 (0,0115)
SV_{t-2}	-0,0085 (0,0124)	-0,0075 (0,0124)	-0,0059 (0,0126)
SV_{t-3}	-0,0012 (0,0124)	-0,0017 (0,0125)	0,0011 (0,0126)
SV_{t-4}	0,0026 (0,0124)	0,0004 (0,0124)	-0,0024 (0,0126)
SV_{t-5}	0,0037 (0,0113)	0,0027 (0,0114)	0,003 (0,0115)
$r_{t-1} \times SV_{t-2}$	0,0048* (0,0029)	0,0048* (0,0029)	0,004 (0,0029)
$r_{t-2} \times SV_{t-3}$	-0,0035 (0,0029)	-0,0036 (0,0029)	-0,0031 (0,0029)
$r_{t-3} \times SV_{t-4}$	-0,0003 (0,0029)	-0,0003 (0,0029)	-0,0006 (0,0029)
$r_{t-4} \times SV_{t-5}$	0,0055* (0,0029)	0,0055* (0,0029)	0,0052* (0,0029)
$r_{t-5} \times SV_{t-6}$	-0,0045 (0,0029)	-0,0045 (0,0029)	-0,0046 (0,0029)
TV_{t-1}		0,0018 (0,0212)	0,0007 (0,0214)
TV_{t-2}		-0,0247 (0,023)	-0,0226 (0,0231)
TV_{t-3}		0,0035 (0,023)	0,0043 (0,0232)
TV_{t-4}		0,0281 (0,0229)	0,0293 (0,023)
TV_{t-5}		-0,0011 (0,0212)	-0,0052 (0,0213)
r_m	1,025*** (0,0082)	1,0247*** (0,0082)	0,9972*** (0,0096)
P/L			-0,0002 -0,0002
MTB			0,0015 (0,0036)

Tabela 5

Cont.

	Modelo 4	Modelo 5	Modelo 6
	r_t	r_t	r_t
Tamanho			0,0085 (0,0104)
Risco			-0,0091 (0,0182)
CDI			1,6074 -1,5906
Spread temporal			0,1572*** (0,0292)
Observações	31.756	31.756	31.394
Número de ações	34	34	34
Número de dias	934	934	394
Estatística de Wald	15.819***	15.864***	16.063***

Nota: Os modelos foram estimados com um painel via feasible generalized least squares (FGLS) com correção de Parks-Kmenta e estimação de erros AR(1) com correção Prais-Winsten.

*, **, *** = $p < 0,1$, $p < 0,05$, $p < 0,01$, respectivamente.

Fonte: Elaborada pelos autores.

Tanto na Tabela 4 quanto na Tabela 5, as interações entre os retornos defasados e a atenção têm sinal oposto aos coeficientes das autocorrelações, indicando que os níveis de atenção amenizam a previsibilidade dos retornos, em linha com a primeira hipótese do trabalho, de que a atenção contribui para maior eficiência. Para melhor

entender o efeito de diferentes níveis de atenção na previsibilidade dos retornos, calculamos o efeito parcial dos retornos defasados ($\partial r_t / \partial r_{t-j} = \beta r_{t-j} + \delta(r_{t-j} \times SV_{t-j-1})$) para diferentes valores da variável SV e para as defasagens cuja interação foi significativa nos modelos das tabelas 4 e 5. Os resultados dessa análise são apresentados na Tabela 6.

Tabela 6

Autocorrelação (efeitos parciais) para diferentes níveis de atenção

Atenção não profissional (buscas no Google)				
Lag	Nível de atenção	Modelo 1	Modelo 2	Modelo 3
r_{t-1}	Baixa atenção	-0,0212	-0,0212	-0,0226
r_{t-1}	Mediana atenção	-0,0184	-0,0185	-0,0198
r_{t-1}	Alta atenção	-0,0133	-0,0134	-0,0147
r_{t-5}	Baixa atenção	0,0064	0,0064	0,0067
r_{t-5}	Mediana atenção	0,0033	0,0033	0,0034
r_{t-5}	Alta atenção	-0,0025	-0,0025	-0,0026
Atenção profissional (buscas na Bloomberg)				
Lag	Nível de atenção	Modelo 4	Modelo 5	Modelo 6
r_{t-1}	Baixa atenção	-0,0173	-0,0175	-0,0156
r_{t-1}	Mediana atenção	-0,0173	-0,0175	-0,0156
r_{t-1}	Alta atenção	-0,0140	-0,0142	-0,0156
r_{t-4}	Baixa atenção	-0,0139	-0,0143	-0,0153
r_{t-4}	Mediana atenção	-0,0127	-0,0131	-0,0142
r_{t-4}	Alta atenção	-0,0105	-0,0109	-0,0120

Nota: Baixa atenção é o valor do primeiro quartil da variável de atenção (-0,4544 para as buscas no Google e -0,6536 para as buscas na Bloomberg), mediana atenção é o valor da mediana (-0,2328 para as buscas no Google e -0,6536 para as buscas na Bloomberg) e alta atenção é o valor do terceiro quartil (0,1798 para as buscas no Google e 0,0316 para as buscas na Bloomberg).

Fonte: Elaborada pelos autores.

Na primeira parte da Tabela 6, mostramos o efeito de diferentes níveis da atenção não profissional (buscas no Google) nas autocorrelações de ordem 1 e 5. Nas três

especificações (Modelos 1 a 3 da Tabela 4), à medida que a atenção aumenta, a autocorrelação diminui. Por exemplo, para o Modelo 3, a autocorrelação de ordem 1

com baixa atenção é de -0,0226. Quando a atenção é alta, a autocorrelação cai para -0,0147. Na segunda parte da Tabela 6, mostramos o efeito de diferentes níveis da atenção profissional (buscas na Bloomberg) nas autocorrelações de ordem 1 e 4. Na ordem 1, apenas os modelos 4 e 5 mostram variação na previsibilidade de acordo com a atenção, indicando, nesses casos, também, uma redução da previsibilidade. Na ordem 4, todas as especificações mostram diminuição da previsibilidade com aumento da atenção. Por exemplo, para o Modelo 6, quando a atenção é baixa, a autocorrelação é de -0,0153, caindo para -0,0120 quando a atenção é alta. No entanto, os resultados sugerem que o efeito da atenção profissional é menor que o da não profissional, já que a diminuição da previsibilidade nos modelos 4, 5 e 6 é menor que nos modelos 1, 2 e 3, contrariamente à segunda hipótese deste trabalho.

Uma possível explicação para esses resultados é a baixa variabilidade da variável de buscas na Bloomberg, que mede a atenção profissional. Como é possível observar na Tabela 2, a mediana e o mínimo têm o mesmo valor para o índice BSV. O índice GSV (atenção não profissional) apresenta maior variabilidade (há menos observações concentradas em valores iguais). Outra explicação plausível é que, devido a seus vieses comportamentais, o papel do investidor não profissional nos transientes de mercado é mais determinante do que o do investidor profissional. No entanto, esses transientes seriam mais presentes (ou mais expressivos) em momentos de inatenção, e não de atenção, do investidor não profissional.

4.2.1 Análises adicionais

Como nas tabelas 4 e 5 o *spread* temporal foi a única variável de controle com significância para os retornos, nesta seção analisamos se níveis diferentes de *spread*, que mede a incerteza em relação ao futuro no nível macroeconômico (quanto maior o *spread*, maior é a incerteza), afetam a relação entre a atenção e a previsibilidade dos retornos. Para esse teste, estimamos uma regressão incluindo interações triplas entre os retornos defasados, a atenção e o *spread* temporal. Enquanto o *spread* temporal é uma medida de risco macroeconômico, consideramos também uma medida de risco individual de cada ação, a variável *Risco* usada como controle nos modelos 1 a 6. Os resultados dessas estimações não são apresentados por questão de espaço, mostramos apenas os resultados dos efeitos parciais dos retornos defasados (autocorrelação) para diferentes níveis de atenção e de *spread* e risco individual na Tabela 7. Na primeira parte da Tabela 7, mostramos os efeitos parciais das buscas no Google para a primeira defasagem dos retornos, porque essa foi a defasagem cuja interação tripla foi significativa tanto para o *spread* quanto para o risco individual. Já para as buscas na Bloomberg, a interação tripla para o *spread* e o risco individual foi significativa para a quarta defasagem, portanto, essa é a defasagem analisada na segunda parte da Tabela 7.

Tabela 7

Autocorrelação (efeitos parciais) para diferentes níveis de atenção, de spread e de risco individual

Atenção não profissional (Buscas no Google)				
Lag	Nível de atenção	Spread baixo	Spread mediano	Spread alto
r_{t-1}	Baixa atenção	-0,0208	-0,0259	-0,0310
r_{t-1}	Mediana atenção	-0,0202	-0,0228	-0,0254
r_{t-1}	Alta atenção	-0,0190	-0,0170	-0,0149
		Risco baixo	Risco mediano	Risco alto
r_{t-1}	Baixa atenção	-0,0252	-0,0226	-0,0187
r_{t-1}	Mediana atenção	-0,0195	-0,0181	-0,0161
r_{t-1}	Alta atenção	-0,0088	-0,0098	-0,0114
Atenção profissional (Buscas na Bloomberg)				
Lag	Nível de atenção	Spread baixo	Spread mediano	Spread alto
r_{t-4}	Baixa atenção	-0,0129	-0,0147	-0,0165
r_{t-4}	Mediana atenção	-0,0129	-0,0147	-0,0165
r_{t-4}	Alta atenção	-0,0110	-0,0109	-0,0108
		Risco baixo	Risco mediano	Risco alto
r_{t-4}	Baixa atenção	-0,0127	-0,0144	-0,0170
r_{t-4}	Mediana atenção	-0,0127	-0,0144	-0,0170
r_{t-4}	Alta atenção	-0,0134	-0,0134	-0,0132

Nota: Os níveis de atenção são os mesmos definidos na Tabela 6. *Spread* baixo é medido pelo primeiro quartil da variável *spread* (-0,2553), *spread* mediano é um valor nulo e *spread* alto é o terceiro quartil (0,2590). *Risco* baixo é medido pelo primeiro quartil da variável *risco* (1,9200), *risco* mediano é a mediana da variável (2,8200) e *risco* alto é o valor do terceiro quartil (2,8160).

Fonte: Elaborada pelos autores.

Na primeira parte da Tabela 7 (buscas no Google, isto é, atenção não profissional), à medida que o *spread* aumenta, é possível perceber uma maior autocorrelação, sugerindo que incertezas sobre o futuro prejudicam a eficiência informacional do mercado. Para o *spread* baixo, maior atenção gera autocorrelações levemente menores, mas quando o *spread* é alto, a autocorrelação cai para a metade quando a atenção sai de um nível baixo (-0,0310) para alto (-0,0149). Para o risco individual, a interpretação é semelhante: quando a atenção é baixa ou mediana, quanto maior o risco, maior é a autocorrelação, e, para níveis altos de risco, o efeito da atenção é mais forte (a autocorrelação com baixa atenção é de -0,0187 e a com alta atenção é de -0,0114).

Na segunda parte da Tabela 7 (buscas na Bloomberg, isto é, atenção profissional), à medida que o *spread* aumenta (quando a atenção é baixa ou mediana), é possível perceber maior autocorrelação, sugerindo que incertezas sobre o futuro prejudicam a eficiência informacional do mercado. Para o *spread* baixo, maior atenção gera autocorrelações levemente menores, mas quando o *spread* é alto, a autocorrelação cai mais quando a atenção sai de um nível baixo (-0,0165) para alto (-0,0108). Para o risco individual, a interpretação é semelhante para altos

níveis de risco: quando a atenção é baixa ou mediana, a autocorrelação é de -0,0170, e quando a atenção é alta, a autocorrelação cai para -0,0132. Comparando a queda na autocorrelação para a atenção profissional e para a atenção não profissional, a conclusão em relação à segunda hipótese do estudo se mantém: o efeito da atenção não profissional é maior, provavelmente devido às limitações da medida de atenção profissional, conforme comentado na seção anterior.

4.2.2 Análises de robustez

Finalmente, esses resultados são robustos a diversas especificações diferentes. Estimamos as regressões com dados sem winsorização e winsorizados a 5%, com logaritmo na variável de *search volume*, e também usando períodos mais curtos (3 e 2 anos). Além disso, na nossa especificação principal, a atenção está uma ordem de defasagem abaixo do retorno para a análise das autocorrelações (Tantaopas et al., 2016), mas também reestimamos todos os modelos, incluindo a atenção na mesma ordem de defasagem que os retornos (Vozlyublennaiia, 2014), e as conclusões se mantiveram as mesmas. Os resultados dessas análises não foram apresentados por questão de espaço, mas estão disponíveis sob demanda.

5. CONSIDERAÇÕES FINAIS

Neste estudo, investigamos se a eficiência do mercado é afetada pelo nível de atenção dos investidores. A eficiência é medida por uma menor previsibilidade dos retornos, resultante de uma incorporação mais imediata das informações nos preços. O grau de atividade na internet foi adotado como medida de atenção. Realizar buscas na internet é atualmente um processo recorrente para se manter informado sobre ativos negociados em bolsa. Além disso, por não ser diretamente vinculada ao mercado, essa medida não é resultado de equilíbrio, minimizando problemas de endogeneidade.

Usamos medidas de buscas realizadas tanto no Google quanto na Bloomberg. Enquanto o Google é popular, gratuito e direcionado a investidores não profissionais, a Bloomberg é direcionada a investidores mais sofisticados. Isso permite verificar se os efeitos da atenção dependem de qual agente está atento. De acordo com a teoria de descoberta de informação (Tantaopas et al., 2016; Vozlyublennaiia, 2014), maior atenção dos investidores deveria levar à maior eficiência, e nossos resultados são coerentes com essa hipótese. No entanto, diferentemente da nossa hipótese complementar, não encontramos evidências de que a atenção profissional tem papel mais determinante do que a não profissional na

indução de eficiência. Ao contrário do que estabelecemos originalmente, as evidências indicam que fenômenos como racionalidade limitada e comportamento de manada, documentados em estudos anteriores (Chiang & Zheng, 2010; Kahneman, 2003; Sewell, 2007), podem estar mais presentes em momentos de baixa do que de alta atenção do investidor não profissional. Além disso, enquanto, em média, menos informados, esses investidores estão mais propensos à seleção adversa por assimetria de informação (Akerlof, 1970; Cohen et al., 2011).

Para realizar a análise, obtivemos dados diários de 2018 a 2021 referentes a 34 ações individuais. Isso resultou em 935 dias de pregão, suficiente do ponto de vista estatístico. Até onde foi verificado, nosso trabalho é pioneiro em realizar esse tipo de teste em frequência diária. Examinamos algumas das principais ações brasileiras, partindo do Ibovespa. Também pela primeira vez, tal análise de incorporação da informação em preços de ativos de risco é feita segregando a atenção profissional da não profissional. Optamos por examinar ações individuais, em vez de índices, por haver uma literatura mais escassa a respeito desse universo. Além disso, o índice de volume de buscas apresentado pela Bloomberg é disponibilizado apenas para ações.

Para essa análise, desenvolvemos modelos autorregressivos dos retornos que incluíram, como regressores, interações entre esses retornos defasados e índices de busca na internet pelo *ticker* da ação. Foi encontrado um efeito minimizador da previsibilidade dos retornos, considerando tanto a atenção profissional quanto não profissional. O processo de descoberta da informação é o mecanismo por meio do qual a atenção induz eficiência aos mercados. Esse processo começa a partir de uma variação expressiva de preço, resultante de um fato relevante. O fato captura a atenção de alguns investidores, que então buscam mais informações para subsidiar sua decisão de comprar, vender ou manter o ativo. Trata-se, então, de um processo que naturalmente faz transmitir informações aos preços, sendo a atenção um requisito para sua ocorrência.

Objetivamos fazer algumas contribuições ao desenvolver uma análise pioneira do efeito que a atenção de diferentes classes de investidores gera na previsibilidade do mercado. Primeiramente, reconhecemos a importância da atenção e da atuação por investidores profissionais na incorporação das informações nos preços. Além de contribuir para a literatura a respeito da hipótese de eficiência de mercado, a análise envolvendo volume de buscas feitas na internet

é particularmente relevante, dada a grande quantidade de informação que as pessoas atualmente produzem e compartilham digitalmente. Os resultados mostram que a atenção de investidores de diferentes perfis tem diferentes efeitos na previsibilidade dos preços.

Nosso estudo tem algumas limitações que podem ser tratadas em pesquisas futuras. Em termos metodológicos, selecionamos apenas empresas que fazem parte do Ibovespa, apenas a atenção em dias de pregão, e eliminamos valores extremos da série de atenção. Com relação à argumentação teórica, variações nos riscos (e conseqüentemente nos prêmios de risco) limitam a associação entre previsibilidade dos retornos e eficiência de mercado. Buscamos contornar essa limitação controlando pela volatilidade, mas encorajamos a busca por formas alternativas de estabelecer essa associação.

Pesquisas futuras podem também endereçar a implementação de modelos empíricos para compreender melhor os mecanismos por meio dos quais a atenção induz eficiência de mercado. Outro caminho promissor para complementar nossos achados é avaliar a possibilidade de ganhos com estratégias de investimento que levam em conta a maior previsibilidade dos preços das ações em momentos de atenção reduzida.

REFERÊNCIAS

- Akerlof, G. A. (1970). The market for “lemons”: Quality uncertainty and the market mechanism. *The Quarterly Journal of Economics*, 84(3), 488-500. <https://doi.org/10.2307/1879431>
- Amihud, Y. (2002). Illiquidity and stock returns: Cross-section and time-series effects. *Journal of Financial Markets*, 5(1), 31-56. [https://doi.org/10.1016/S1386-4181\(01\)00024-6](https://doi.org/10.1016/S1386-4181(01)00024-6)
- Andrei, D., & Hasler, M. (2015). Investor attention and stock market volatility. *Review of Financial Studies*, 28(1), 33-72. <https://doi.org/10.1093/rfs/hhu059>
- B3 S.A. – Brasil, Bolsa, Balcão. (2015). *Metodologia do índice Bovespa*. <https://www.b3.com.br/data/files/1C/56/F7/D5/96E615107623A41592D828A8/IBOV-Metodologia-pt-br.pdf>
- Barber, B. M., & Odean, T. (2008). All that glitters: The effect of attention and news on the buying behavior of individual and institutional investors. *Review of Financial Studies*, 21(2), 785-818. <https://doi.org/10.1093/rfs/hhm079>
- Barberis, N., Shleifer, A., & Vishny, R. (1998). A model of investor sentiment. *Journal of Financial Economics*, 49(3), 307-343. [https://doi.org/10.1016/S0304-405X\(98\)00027-0](https://doi.org/10.1016/S0304-405X(98)00027-0)
- Ben-Rephael, A., Da, Z., & Israelsen, R. D. (2017). It depends on where you search: Institutional investor attention and underreaction to news. *The Review of Financial Studies*, 30(9), 3009-3047. <https://doi.org/10.1093/rfs/hhx031>
- Burton, E. T., & Shah, S. N. (2013). *Behavioral finance: Understanding the social, cognitive, and economic debates* (Vol. 854). John Wiley & Sons.
- Cameron, A. C., & Trivedi, P. K. (2005). *Microeconometrics: Methods and applications*. Cambridge University Press.
- Castro, F. H., Edi Jr., W., Santana, V. F., & Yoshinaga, C. E. (2019). Fifty-year history of the Ibovespa. *Revista Brasileira de Finanças*, 17(3), 47-65.
- Chiang, T. C., & Zheng, D. (2010). An empirical analysis of herd behavior in global stock markets. *Journal of Banking & Finance*, 34(8), 1911-1921. <https://doi.org/10.1016/j.jbankfin.2009.12.014>
- Cohen, J., Holder-Webb, L., Nath, L., & Wood, D. (2011). Retail investors' perceptions of the decision-usefulness of economic performance, governance, and corporate social responsibility disclosures. *Behavioral Research in Accounting*, 23(1), 109-129. <https://doi.org/10.2308/bria.2011.23.1.109>
- Cronqvist, H., & Siegel, S. (2014). The genetics of investment biases. *Journal of Financial Economics*, 113(2), 215-234. <https://doi.org/10.1016/j.jfineco.2014.04.004>
- Da, Z., Engelberg, J., & Gao, P. (2011). In search of attention. *The Journal of Finance*, 66(5), 1461-1499. <https://doi.org/10.1111/j.1540-6261.2011.01679.x>

- Falkinger, J. (2008). Limited attention as a scarce resource in information-rich economies. *The Economic Journal*, 118(532), 1596-1620. <https://doi.org/10.1111/j.1468-0297.2008.02182.x>
- Fama, E. F. (1965). The behavior of stock-market prices. *The Journal of Business*, 38(1), 34-105.
- Fang, L., & Peress, J. (2009). Media coverage and the cross-section of stock returns. *The Journal of Finance*, 64(5), 2023-2052. <https://doi.org/10.1111/j.1540-6261.2009.01493.x>
- Gabaix, X., & Laibson, D. (2005). *Bounded rationality and directed cognition*. Harvard University.
- Grossman, S. J., & Stiglitz, J. E. (1980). On the impossibility of informationally efficient markets. *The American Economic Review*, 70(3), 393-408.
- Grullon, G., Kanatas, G., & Weston, J. P. (2004). Advertising, breadth of ownership, and liquidity. *The Review of Financial Studies*, 17(2), 439-461. <https://doi.org/10.1093/rfs/hhg039>
- Johansson, E. (2014). *Creating daily search volume data from weekly and daily data*. <https://erikjohansson.blogspot.com/2014/12/creating-daily-search-volume-data-from.html>
- Kahneman, D. (2003). Maps of bounded rationality: Psychology for behavioral economics. *American Economic Review*, 93(5), 1449-1475. <https://doi.org/10.1257/000282803322655392>
- Lux, T., & Marchesi, M. (1999). Scaling and criticality in a stochastic multi-agent model of a financial market. *Nature*, 397(6719), 498-500.
- Merton, R. C. (1987). A simple model of capital market equilibrium with incomplete information. *The Journal of Finance*, 42(3), 483-510.
- Mondria, J., & Wu, T. (2010). The puzzling evolution of the home bias, information processing and financial openness. *Journal of Economic Dynamics and Control*, 34(5), 875-896. <https://doi.org/10.1016/j.jedc.2009.12.004>
- Sewell, M. (2007). *Behavioural finance*. https://www.academia.edu/2813323/Behavioural_Finance
- Sims, C. A. (2005). *Rational inattention: A research agenda*. <https://www.bundesbank.de/resource/blob/703284/82d389a1de62876b9151575e466767cd/mL/2005-09-27-dkp-34-data.pdf>
- Statista. (2014). *Popular online search engines in Brazil as of May 2014, based on market share*. <https://www.statista.com/statistics/309652/brazil-market-share-search-engine/>
- Tantaopas, P., Padungsaksawasdi, C., & Treepongkaruna, S. (2016). Attention effect via internet search intensity in Asia-Pacific stock markets. *Pacific-Basin Finance Journal*, 38, 107-124. <https://doi.org/10.1016/j.pacfin.2016.03.008>
- Van Nieuwerburgh, S., & Veldkamp, L. (2007). *Information immobility and the home bias puzzle* [Working Paper]. Wiley Online Library. <https://doi.org/10.1111/j.1540-6261.2009.01462.x>
- Vozlyublennia, N. (2014). Investor attention, index performance, and return predictability. *Journal of Banking & Finance*, 41, 17-35. <https://doi.org/10.1016/j.jbankfin.2013.12.010>
- Zhang, W., Shen, D., Zhang, Y., & Xiong, X. (2013). Open source information, investor attention, and asset pricing. *Economic Modelling*, 33, 613-619. <https://doi.org/10.1016/j.econmod.2013.03.018>