



Universidade de Aveiro
2020

**CLARA ISABEL
GONÇALVES
MONTEIRO**

**ESTUDO DE VOLATILIDADE APLICADO AO INDICE
NASDAQ COM DADOS DE ALTA FREQUÊNCIA**



Universidade de Aveiro
2020

**CLARA ISABEL
GONÇALVES
MONTEIRO**

**ESTUDO DE VOLATILIDADE AO INDICE NASDAQ
COM DADOS DE ALTA FREQUÊNCIA**

Dissertação apresentada à Universidade de Aveiro para cumprimento dos requisitos necessários à obtenção do grau de Mestre em Economia, realizada sob a orientação científica da Doutora Mara Teresa da Silva Madaleno, Professora Auxiliar do Departamento de Economia, Gestão, Engenharia Industrial e Turismo da Universidade de Aveiro.

À Vó Bina.

o júri

presidente

Prof. Doutor Miguel Lopes Batista Viegas
Professor Auxiliar, Universidade de Aveiro

vogais

Prof. Doutor Vítor Manuel Ferreira Moutinho
Professor Auxiliar, Universidade da Beira Interior

Prof. Doutora Mara Teresa da Silva Madaleno
professora auxiliar do Departamento de Economia, Gestão, Engenharia Industrial e Turismo da
Universidade de Aveiro

agradecimentos

Um agradecimento especial à minha orientadora que foi o principal pilar para a realização do presente estudo, agradeço a disponibilidade, a compreensão e sobretudo o facto de não desistir perante nenhuma dificuldade.

Um agradecimento ao meu núcleo duro: a minha mãe, os meus avós, a Pipoca, o meu namorado, a minha família, amigos incluídos (claro está) que fizeram tudo o que estava ao seu alcance para me proporcionar o melhor. Pelos vossos sacrifícios, pela atenção e pelo carinho o meu muito obrigada.

Resta-me agradecer a três pessoas que me deram um grande empurrão no início deste percurso, a professora Noémia por me mostrar o caminho, o Nuno Araújo por ter sido um pai quando tanto precisei e a minha tia Arminda que tanto fez para que não me visse forçada a desistir!

palavras-chave

Volatilidade, Dados de alta frequência, Modelo GARCH e EGARCH, Retornos, Ações, NASDAQ

resumo

Tradicionalmente, o cálculo das estimativas da volatilidade dos retornos financeiros é realizado usando dados diários. Todavia, verificamos uma crescente disponibilidade de dados registados em intervalos de tempo cada vez mais curtos. Para além disso, a emergência da importância da ciência dos dados nas ciências sociais, aliada aos avanços tecnológicos na área da computação, abriram espaço para a investigação empírica voltada para a análise e aplicação dos dados de alta frequência. Esta aplicação dá-se numa cada vez mais crescente diversidade de aspetos dos mercados financeiros. Adicionalmente, a possibilidade de se obterem estimativas mais precisas de volatilidade tem despertado o interesse de muitos pesquisadores na análise deste tipo de dados. Esta dissertação pretende analisar a volatilidade dos retornos de ações individuais, utilizando para o efeito dados caracterizados por uma frequência superior à diária, neste caso, dados correspondentes ao minuto. Para o efeito, e contrariamente a estudos prévios que por usarem elevados volumes de dados, analisam a volatilidade utilizando apenas um número limitado de ativos, como um índice de mercado, nesta dissertação recolheram-se dados ao minuto para 104 empresas pertencentes ao índice NASDAQ e ao próprio índice.

A volatilidade de um ativo é uma das informações mais importantes para os investidores do mercado financeiro. Esta refere-se às oscilações de uma determinada variável ao longo do tempo. A sua correta previsão é essencial para determinar estratégias de cobertura de risco e ainda permite captar momentos de grande incerteza no mercado. O objetivo passa por verificar a adequação dos modelos GARCH e EGARCH tradicionais, mas para análise do comportamento da volatilidade utilizando-se dados de retornos de alta frequência.

Os resultados permitiram concluir que o Índice NASDAQ e as empresas que o compõem são, na sua generalidade, altamente voláteis e que o período estudado apresenta sinais de assimetria, o que nos permite afirmar que a volatilidade do mercado é maior após “más notícias” do que após “boas notícias”, deixando os investidores mais instáveis e atentos a notícias negativas do que a positivas.

keywords

Volatility, High frequency data, GARCH and EGARCH models, Returns, Stocks, NASDAQ

abstract

Traditionally, the calculation of volatility estimates of financial returns is performed using daily data. However, we found an increasing availability of data recorded in increasingly short time intervals. In addition, the emergence of the importance of data science in the social sciences, coupled with technological advances in the field of computing, opened up space for empirical research aimed at the analysis and application of high frequency data. This application takes place in an increasingly growing diversity of aspects of the financial markets. In addition, the possibility of obtaining more accurate volatility estimates has aroused the interest of many researchers in the analysis of this type of data. This dissertation intends to analyze the volatility of the returns of individual shares, using data characterized by a frequency higher than the daily, in this case, data corresponding to the minute. For this purpose, and contrary to previous studies that use high volumes of data, they analyze volatility using only a limited number of assets, such as a market index, in this dissertation data was collected per minute for 104 companies belonging to the NASDAQ index and to the index itself.

An asset's volatility is one of the most important information for financial market investors. This refers to the oscillations of a given variable over time. Its correct forecast is essential to determine risk hedging strategies and allows to capture moments of great uncertainty in the market. The objective is to verify the adequacy of the traditional GARCH and EGARCH models, but to analyze the behavior of volatility using high frequency returns data.

The results allowed us to conclude that the NASDAQ Index and the companies that compose it are, in general, highly volatile and that in the period studied there is evidence of signs of asymmetry, which allows us to affirm that the market volatility is greater after "bad news" than after "good news", leaving investors more unstable and aware to negative news than positive ones.

Índice

Índice Figuras	iii
Índice Tabelas	iv
Lista Acrónimos	vi
1. Introdução	1
2. Enquadramento e revisão da literatura	5
2.1 Factos sobre a volatilidade dos preços dos ativos	6
2.1.1 Volatilidade Histórica ou Estatística	7
2.1.2 Volatilidade Implícita	7
2.1.3 Volatilidade Futura ou Previsional	8
2.2 Factos estilizados sobre volatilidade	8
2.3 Tipos de modelos de volatilidade	9
2.3.1 Modelo ARCH	10
2.3.2 Modelo GARCH	11
2.3.3 Modelo EGARCH	13
2.4 Uso dos modelos GARCH e EGARCH em dados de elevada frequência	14
3. Dados	17
4. Metodologia	19
4.1 Modelo de Volatilidade - GARCH	19
4.2 Aplicação do modelo EGARCH	20
5. Resultados Empíricos	23
6. Conclusões	31
Referências	33
Anexos	41

Índice Figuras

Figura 1- Cronograma da série NASDAQ.....	24
Figura 2 – Retornos do índice NASDAQ.....	25
Figura 3- Histograma da série de retornos NASDAQ	26

Índice Tabelas

Tabela 1 – Empresas do índice NASDAQ analisadas	17
Tabela 3 – Estatística descritiva da série NASDAQ.....	23
Tabela 4 – Resultados do modelo GARCH(1,1) referentes à série NASDAQ	26
Tabela 5 - Resultados do modelo EGARCH(1,1) referentes à série NASDAQ	28

Índice Tabelas – Anexos

Tabela A 1 – Estatística Descritiva	41
Tabela A 2 – Aplicação do Modelo GARCH.....	47
Tabela A 3 – Estimação do Modelo EGARCH.....	56

Lista Acrónimos

AAL - *American Airlines Group*
AAPL - *Apple Inc.*
ADBE - *Adobe Systems Incorporated*
ADI - *Analog Devices*
ADP - *Automatic Data Processing, Inc.*
ADSR - *Altair Engineering*
AKAM - *Akamai Technologies, Inc.*
ALXN - *Alexion Pharmaceuticals*
AMAT - *Applied Materials, Inc.*
AMGN - *Amgen Inc.*
AMZN - *Amazon, Inc.*
APARCH - *Asymmetric Power ARCH model*
ARCH - *Autoregressive conditional heteroskedasticity*
ARIMA - *Autoregressive integrated moving average*
ATVI - *Activision Blizzard*
AVGO - *Avago Technologies, Inc.*
BBBY - *Bed Bath & Beyond Inc.*
BIDU - *Baidu, Inc.*
BIIB - *Biogen Idec, Inc.*
BMRN - *BioMarin Pharmaceutical*
CA - *Bank of Commerce Holdings*
CELG - *Celgene Corporation*
CERN - *Cerner Corporation*
CHKP - *Check Point Software Technologies Ltd.*
CHTR - *Charter Communications, Inc.*
CMCSA - *Comcast Corporation*
COST - *Costco Wholesale Corporation*
CSCO - *Cisco Systems, Inc.*
CSX - *Corporation Common Stock*
CTRP - *Ctrip.com International, Ltd.*
CTSH - *Cognizant Technology Solutions Corporation*
CTXS - *Citrix Systems, Inc.*
DISCA - *Discovery Communications*
DISCK - *Discovery, Inc. Series C Common Stock*
DISH - *Dish Network, Inc*
DLTR - *Dollar Tree, Inc*
EA - *Electronic Arts*
EBAY- *eBay Inc.*
EGARCH - *Exponential generalized autoregressive conditional heteroscedastic*
ESRX - *Express Scripts, Inc.*
EXPE - *Expedia, Inc.*
FAST- *Fastenal Company*
FB - *Facebook, Inc*
FISV - *Fiserv, Inc*
FOX - *Fox Corp Class B*
FOXA - *21st Century Fox*
GARCH - *Generalized autoregressive conditional heteroskedasticity*

GILD - *Gilead Sciences, Inc.*
GJR-GARCH - *Glosten-Jagannathan-Runkle GARCH model*
GOOGLE - *Alphabet Inc Class A*
HSIC - *Henry Schein, Inc.*
ILMN - *Illumina, Inc.*
INCY - *Incyte Corporation*
INTC - *Intel Corporation*
INTU - *Intuit, Inc.*
ISRG - *Intuitive Surgical Inc*
JD - *American Depositary Shares*
KHC - *Kraft Heinz Company*
LBTYA - *Liberty Global plc*
LBTYK - *Liberty Global PLC Class C*
LLTC - *Linear Technology Corporation*
LRCX - *Lam Research*
LVNTA - *Liberty Interactive*
MAR - *Marriott International, Inc.*
MAT - *Mattel, Inc.*
MCHP - *Microchip Technology*
MDLZ - *Mondelēz International*
MNST - *Monster Beverage*
MSFT - *Microsoft Corporation*
MU - *Micron Technology, Inc.*
MXIM - *Maxim Integrated Products*
MYL - *Mylan, Inc.*
NASDAQ - *National Association of Securities Dealers Automated Quotation System*
NCLH - *Norwegian Cruise Line Holdings Ltd.*
NDX - *National Association of Securities Dealers Automated Quotation System 100*
NFLX - *Netflix*
NTAP - *NetApp, Inc.*
NTES - *NetEase, Inc.*
NVDA - *NVIDIA Corporation*
NXPI - *NXP Semiconductors*
ORLY - *O'Reilly Automotive, Inc.*
PAYX - *Paychex, Inc.*
PCAR - *PACCAR Inc.*
PCLN - *The Priceline Group, Inc.*
PYPL - *PayPal*
QCOM - *QUALCOMM Incorporated*
QVCA - *Qurate Retail In.c*
R-GARCH - *Realized GARCH*
REGN - *Regeneron Pharmaceuticals*
ROST - *Ross Stores Inc.*
S&P - *Standard & Poor's*
SBAC - *SBA Communications*
SBUX - *Starbucks Corporation*
SIRI - *Sirius XM Radio, Inc.*

SRCL - *Stericycle, Inc.*
STX - *Seagate Technology Holdings*
SWKS - *Skyworks Solutions Inc.*
SYMC - *Symantec Corporation*
TMUS - *T-Mobile US*
TRIP - *TripAdvisor*
TSCO - *Tractor Supply Company*
TSLA - *Tesla Motors, Inc.*
TXN - *Texas Instruments, Inc.*
ULTA - *ULTA Beauty*
VIAB - *Viacom Inc.*
VOD - *Vodafone Group, plc*
VRSK - *Verisk Analytics*
VRTX - *Vertex Pharmaceuticals*
WBA - *Walgreens Boots Alliance*
WDC - *Western Digital*
WFM - *Whole Foods Market, Inc*
XLNX - *Xilinx, Inc.*
XRAY - *Dentsply Sirona*
YHOO - *Yahoo! Inc.*

1. Introdução

O tema da volatilidade é considerado, por muitos, como um dos temas cruciais na área das finanças (Moreira et al., 2004; Yan e Yan, 2019). A dificuldade para prever o seu comportamento, uma vez que não é diretamente observável, faz com que a mesma suscite um nível de entrega elevado por parte dos investigadores, uma vez que a sua correta previsão permite captar momentos de incerteza no mercado financeiro, como forma de antecipar estratégias para obtenção de retornos positivos e ganhos adicionais. Assim sendo, para estimar a volatilidade deve recorrer-se a modelos de volatilidade. Um modelo de volatilidade deve ser capaz de prever a volatilidade, de captar e de refletir os factos mais relevantes sobre a volatilidade dos rendimentos dos preços, concretamente, a persistência, reversão à média, impacto assimétrico das boas e más notícias e a influência de variáveis exógenas diversas (Ferreira, 2005).

Estas características desempenham um papel importante no desenvolvimento de instrumentos eficazes na medição e previsão da volatilidade, uma vez que se revelam fundamentais na delineação de estratégias de negócios, na gestão de risco, assim como na valorização de instrumentos derivados, e de técnicas de cobertura de risco para a aplicação eficaz de recursos financeiros (Yan e Yan, 2019). É por esse motivo que é analisada em diversos contextos financeiros onde a mesma é verificada ou para efeitos de previsão, como por exemplo para previsão de preços de petróleo (Chen et al., 2020), para analisar efeitos de *spillovers* entre preços de futuros e preços *spot* (Chang e Lee, 2020), para análise de volatilidade de índices de mercado (Li et al., 2020), previsões de volatilidade de índices de ações de setores em particular como o industrial (Wei et al., 2020), e até para estudar o impacto de choques externos como a atual pandemia nos índices de mercado (Bai et al., 2020).

O uso de dados de elevada frequência para análises de volatilidade é útil para previsões de comportamento uma vez que a incorporação explícita de informação neste tipo de dados melhora significativamente as projeções de volatilidade dos retornos diários (Anderson e Bollerslev, 1998a, b, 1999). Todavia, existem problemas inerentes e autores que defendem a sua não utilização, preferindo os dados diários. Uma das maiores contestações prende-se com o impacto do ruído da microestrutura¹ de mercado, que segundo autores de renome, previne a possibilidade de obter uma estimativa perfeita da variância dos retornos (Aït-Sahalia et al., 2005, 2011); outra prende-se com o facto de dados de alta frequência apresentarem frequentemente quebras e saltos estruturais, o que torna difícil aplicar um modelo ao preço como um processo

¹ O ruído da microestrutura do mercado pode ter origem em diferentes fontes, incluindo a descrição dos dados, as propriedades dos mecanismos de negociação e a existência de *bid-ask spread*. Em intervalos de tempo muito pequenos, estas medidas podem ser fortemente influenciadas pelo ruído, podendo trazer poucas informações sobre a volatilidade do processo de formação do preço. Como o nível de volatilidade é proporcional ao intervalo de tempo entre duas observações sucessivas, conforme o intervalo de tempo aumenta, a incidência do ruído permanece constante, enquanto a informação sobre o valor “verdadeiro” da volatilidade aumenta. Portanto, há uma compensação entre alta frequência e precisão, o que levou os autores a identificar uma frequência de amostragem ideal de 5 minutos (Aït-Sahalia et al., 2005, 2011).

contínuo, conforme é exigido pelos paradigmas das finanças matemáticas (Aït-Sahalia & Jacod, 2009).

Mas longo tem sido o uso destes dados de elevada frequência para efeitos de previsão. Taylor e Xu (1997) avaliaram a existência de informação incremental do marco alemão face ao dólar americano, comparativamente com a obtida a partir de opções cambiais, tendo os resultados corroborado esta hipótese. No mesmo ano, Goodhart e O'hara (1997) chamam à atenção para o facto de que os retornos intradiários apresentam um comportamento particular sistemático, fundamental para modelizar a volatilidade. Todavia, Anderson e Bollerslev (1997) chamam à atenção que os padrões sistemáticos observados em séries financeiras de alta frequência, particularmente nos mercados de ações e de câmbio, são ignorados pela literatura empírica sobre a microestrutura de mercado. Segundo os autores, isso explicaria a aparente inadequação dos modelos tradicionais de volatilidade quando aplicados a séries de alta frequência.

Apesar de algumas críticas conseguimos perceber a utilidade do uso de dados de elevada frequência, uma vez que na literatura encontramos evidências de que melhoraram a previsão de volatilidade (Li et al., 2020; Wei et al., 2020; Bai et al., 2020). Entre outras vantagens dos dados de alta frequência destacamos o facto de 1) melhorarem a nossa compreensão das propriedades dinâmicas da volatilidade, que é a chave para a previsão; 2) as medidas de volatilidade realizada são preditores da volatilidade futura; 3) as medidas de volatilidade realizada permitiram o desenvolvimento de novos modelos de volatilidade que fornecem previsões mais precisas; 4) melhoraram a avaliação das previsões de volatilidade; 5) podem facilitar e melhorar a estimativa de modelos complexos de volatilidade, como modelos de volatilidade de tempo contínuo, pois reduzem a incerteza dos parâmetros; e 6) melhoraram a nossa compreensão das forças motrizes da volatilidade e a sua importância relativa, por exemplo, os dados de alta frequência permitiram uma análise detalhada dos anúncios de notícias e dos seus efeitos nos mercados financeiros.

A incapacidade da modelação de séries temporais com estas características em modelos lineares (ARIMA) despertou a atenção de vários investigadores, como Engle (1982) e Bollerslev (1986). A volatilidade representa o desvio padrão condicional de um instrumento financeiro, em termos estatísticos, o que significa que para efetuar a modelação de séries financeiras que apresentam flutuações ao longo do tempo é necessário recorrer a uma nova classe de modelos – os de heterocedasticidade.

Os modelos de heterocedasticidade condicional autorregressiva (ARCH) foram introduzidos por Engle (1982). Este modelo mesmo depois de tantos anos e de uma massiva investigação sobre o tópico continua a ser um dos mais populares instrumentos estatísticos para capturar a dinâmica da volatilidade do retorno dos ativos e são amplamente usados em todas as áreas de finanças quer por investigadores quer por profissionais.

A maioria dos modelos do tipo ARCH são pensados para aplicação usando dados diários ou semanais (ou mesmo frequências mais baixas). No entanto,

mais recentemente, os dados de maior frequência, por exemplo com uma frequência horária ou mesmo de apenas minutos, começaram a ser disponibilizados. Isso, somada aos avanços tecnológicos na área de computação, permitiu que muitos investigadores iniciassem uma nova abordagem empírica voltada para a análise e aplicação dos dados de alta frequência em diversos aspectos dos mercados financeiros, entre os quais, a análise da volatilidade.

O primeiro tópico a ter em consideração é a adequação do modelo tradicional GARCH e EGARCH aos dados de alta frequência. Os modelos GARCH são amplamente utilizados em finanças, vários são os autores que comprovam que estes modelos são adequados.

Em relação à avaliação de opções, entre os estudos mais recentes estão os de Badescu et al. (2015) e Huang et al. (2017); este último mostrou que usar o modelo GARCH para o índice S&P é mais adequado do que outro método de volatilidade. Em relação à otimização de carteiras, o GARCH é usado por Ranković et al. (2016) e Sahamkhadam et al. (2018).

Börjesson e Löhn (2019) aplicaram modelos GARCH e EGARCH em dados diários e, por comparação, em dados caracterizados por uma frequência superior à diária (15 minutos / 1h), na estimação da volatilidade de 3 empresas cotadas em bolsa: a *Disney*, a *Microsoft* e o *Bank of America*. Concluíram que os modelos reproduzidos a partir de dados com uma frequência superior à diária produzem um melhor ajuste dos modelos da família GARCH em comparação com o uso de dados diários. Esmail e Mohammad (2020) aplicaram modelos GARCH, EGARCH, GJR-GARCH e R-GARCH em dados intradiários de cinco minutos para estimar a variância condicional do ouro. Depois de comparados os resultados obtidos em todos os modelos, os resultados mostram que o método R-GARCH supera os outros métodos. Ainda este ano, Barjasic e Antulov-Fantulin (2020) analisaram séries temporais de retornos de preços ao minuto no mercado da Bitcoin aplicando modelos da família GARCH. Concluíram que o modelo GARCH (1,1) é aquele que melhor se ajusta aos dados utilizados.

O objetivo desta dissertação é contribuir para o conhecimento sobre a volatilidade das rendibilidades do NASDAQ e de 104 das empresas que a ele pertencem, isto, introduzindo o uso de dados de alta frequência registadas a cada minuto, entre julho de 2016 e dezembro do mesmo ano. Para o estudo desta volatilidade, que é realizada de modo individual para cada um dos 105 ativos, foram aplicados os modelos GARCH e EGARCH, seguindo-se assim aquilo que tem sido indicado pela literatura existente como o tipo de modelos mais relevantes para este tipo de análise.

Os resultados permitiram concluir que os valores atuais da volatilidade podem ser explicados pelos valores passados que tendem a persistir com a passagem do tempo, tal como concluído por Akgiray (1989) e Rahman et al. (2002); concluímos ainda que o Índice NASDAQ e as empresas que o compõem são, na sua generalidade, altamente voláteis e que o período estudado apresenta sinais de assimetria, o que nos permite afirmar que a volatilidade do mercado é maior após “más notícias” do que após “boas notícias”, deixando os investidores mais

recetivos a notícias negativas do que a positivas, como concluído também por Antoniou, Homes and Priestley (1998).

O presente trabalho está dividido em seis capítulos. O capítulo 1 faz uma introdução, onde é apresentado um breve resumo do trabalho a ser desenvolvido, dos objetivos a atingir e da importância do tema em estudo. No capítulo 2, é efetuado uma revisão da literatura sobre os tipos de volatilidade, sobre os modelos ARCH, GARCH e EGARCH, bem como sobre as suas propriedades e limitações. O capítulo 3 é dedicado à análise de dados, fazendo-se um breve enquadramento sobre o índice estudado e uma breve descrição sobre os dados recolhidos e utilizados nas estimações econométricas. O capítulo 4 é dedicado à metodologia aplicada para cada um dos modelos estimados. Seguindo-se o capítulo 5 dedicado aos resultados empíricos, que se inicia com uma apresentação das estatísticas descritivas e segue para a apresentação dos resultados obtidos a partir dos modelos estimados. O capítulo 6 encerra o presente trabalho com uma síntese das principais conclusões, indicando algumas das limitações do estudo, bem como procura indicar possíveis avenidas de investigação futura e discutir os resultados obtidos à luz do comportamento do investidor.

2. Enquadramento e revisão da literatura

Kendall (1953) foi o primeiro investigador a interessar-se pelo tema da volatilidade. Volatilidade não é o mesmo que risco, embora possa ser considerada como uma medida de risco. Existem várias definições para volatilidade. Em finanças, volatilidade corresponde à variação de um ativo financeiro durante um certo período, que na sua forma mais simplificada é medida pelo desvio-padrão dos retornos, ou seja, é o risco de mudança do valor do ativo. Portanto, quanto maior a volatilidade do preço do ativo, maior o risco e vice-versa.

Um modelo de volatilidade deve ser capaz de prever a volatilidade. Normalmente, um modelo de volatilidade é utilizado para estimar a magnitude absoluta dos retornos. Estas previsões são usadas em gestão de risco, “market making”, “market timing”, seleção da carteira, entre outras atividades financeiras.

Diversos estudos foram realizados para prever a volatilidade usando diferentes modelos, como, por exemplo, Kim et al. (1998), Bollerslev et al. (1992) e West and Cho (1995). De momento, existe um enorme corpo de pesquisa sobre modelos de volatilidade, visto que esta matéria foi abordada e estudada em vários artigos e continua a ser uma linha de pesquisa favorável quer a profissionais quer a académicos (Dai, Zhou, Wen e He, 2020).

Ao longo dos tempos foram feitos múltiplos avanços na história dos modelos econométricos, especialmente no que diz respeito às séries temporais financeiras. O primeiro grande avanço neste campo, de lidar com erros cujas variações são uma função de termos de erros anteriores, foi feito por Engle (1982). Propondo o teste do multiplicador de Lagrange para testar a duração do atraso dos erros ARCH. Pela sua contribuição neste campo, e pela importância atribuída à mesma, Engle acabou por ganhar um prémio Nobel em 2003.

Bollerslev (1986) e Taylor (1987), por sua vez, desenvolveram uma versão generalizada do modelo ARCH, o modelo GARCH, com vista a produzir melhores previsões da volatilidade condicional. Desde então, vários autores adicionaram características ao modelo GARCH “tradicional” com o objetivo de capturar diferentes atributos de retornos que tenham forte influência na estimação da volatilidade condicional. Ora, muitos autores utilizaram os modelos da família GARCH para prever a volatilidade, como, por exemplo, Pagan and Schwert (1990), Franses and Dijk (1996) e Brailsford and Faff (1996).

De forma a ultrapassar algumas das fraquezas dos modelos GARCH, como o facto de ser um modelo simétrico, Nelson (1991) propôs um novo modelo designado por modelo EGARCH. Este modelo é introduzido para poder descrever as diferentes respostas da taxa de rendibilidade aos choques positivos e negativos, sem necessidade de qualquer restrição paramétrica. Mais recentemente, Shaika e Syeda (2019) examinaram o padrão de volatilidade intradiário do mercado de ações da Arábia Saudita usando diferentes modelos da família GARCH, entre os quais o modelo EGARCH e comprovaram que este último captura os efeitos assimétricos dos dados intradiários.

2.1 Factos sobre a volatilidade dos preços dos ativos

A volatilidade refere-se a flutuações de uma variável ao longo de um período temporal. Diversas variáveis estão sujeitas à volatilidade, que pode ser medida pela variação da série temporal relevante (Rabiul e Anwar, 2014). A volatilidade dos preços dos ativos é uma preocupação importante entre os investigadores da área financeira e ainda para os investidores, uma vez que uma elevada volatilidade resulta em imprevisibilidade, incerteza e risco.

Por norma, esta medida é calculada através do desvio-padrão anualizado da variação percentual das cotações diárias, semanais, mensais ou até mesmo dos dados de alta frequência, sendo expressa sob a forma de percentagem. Esta medida é usada para quantificar o risco de deter um ativo que opera no mercado financeiro durante um período medindo a dispersão dos seus rendimentos, e em termos gerais do próprio mercado (Marques, 2017).

O aumento da volatilidade reflete maiores lucros ou maiores perdas, ou seja, maior risco, o que pode afetar adversamente a riqueza do investidor. Quanto menor a volatilidade, mais estável o mercado e maiores as taxas de crescimento (Muhammad, Tayyab e Samreen, 2019).

Mandelbrot (1963) e Fama (1965) relataram evidências de que grandes alterações no preço de um ativo são frequentemente seguidas por outras grandes mudanças, e pequenas mudanças são frequentemente seguidas por pequenas mudanças. A implicação desses acontecimentos de volatilidade, é que os choques de volatilidade atuais influenciarão a expectativa de volatilidade em muitos períodos no futuro.

A previsão da volatilidade futura dependerá das informações atuais, como os retornos. Diz-se que a volatilidade é persistente se o retorno atual tiver um grande efeito na variação da previsão em muitos períodos no futuro. O facto de se poder dizer que a volatilidade “vem e vai” implica que um período de alta volatilidade acabará por dar lugar a uma volatilidade mais normal e, da mesma forma, um período de baixa volatilidade será seguido por um aumento. A reversão à média na volatilidade é geralmente interpretada como uma demonstração de que existe um nível normal de volatilidade para o qual a volatilidade retornará eventualmente. As previsões de volatilidade de longo prazo devem convergir para o mesmo nível normal de volatilidade, independentemente de quando são feitas, o que faz a literatura assumir que a reversão à média na volatilidade implica que a informação atual não tenha qualquer efeito na previsão de longo prazo (Engle e Manganelli, 1999). Os preços das opções são geralmente vistos como consistentes com a reversão à média (Hull, 1999).

Muitos modelos de volatilidade propostos impõem a hipótese de que a volatilidade condicional do ativo é afetada simetricamente por inovações positivas e negativas. O modelo GARCH (1,1), por exemplo, permite que a variância seja afetada apenas pelo quadrado da inovação desfasada, desconsiderando completamente o sinal dessa inovação. Todavia, para os

retornos de ações, é particularmente improvável que os choques positivos e negativos tenham o mesmo impacto sobre a volatilidade. Esta assimetria é, às vezes, atribuída a um efeito de alavancagem (Duță, 2018) e, por vezes, a um efeito de prémio de risco. É fácil de constatar que o mercado em que os preços dos ativos estão inseridos, os acaba por influenciar. Assim, é de esperar que outras variáveis possam conter informações relevantes para a volatilidade de uma série. Foi exatamente isso que Bollerslev e Melvin (1994), Engle e Mezrich (1996) e Engle et al. (1990) constataram.

Além de outros ativos com impacto na série de volatilidade, é possível que os eventos determinísticos também tenham impacto. Notícias quer da empresa, quer de eventos macroeconómicos podem ter uma influência no processo de volatilidade (Barjasic e Antulov-Fantulin, 2020).

A fórmula de cálculo simplificada da volatilidade é dada pelo desvio-padrão de uma série temporal, representada pela expressão da equação (1).

$$\sigma = \sqrt{\frac{\sum_{t=1}^n (X_t - \bar{X})^2}{n-1}} \quad (1)$$

Em que, σ é o desvio-padrão, \bar{X} a media aritmética de X_t e n o número de observações.

A volatilidade pode ser medida de diferentes formas, sendo possível identificar três tipologias distintas: a volatilidade histórica ou estatística, a volatilidade implícita e a volatilidade previsional (Yan e Yan, 2019).

Para além desta classificação, a volatilidade apresenta padrões de comportamento comuns em diferentes mercados, designados na literatura por “factos estilizados” (Costa, 2019).

2.1.1 Volatilidade Histórica ou Estatística

A volatilidade histórica ou estatística mede as flutuações nos preços ocorridos no passado, sendo geralmente utilizada como medida de risco total do ativo financeiro. O método mais simples para a calcular consiste em calcular o desvio-padrão do rendimento periódico dos ativos, durante um período anterior àquele para o qual se pretende prever a volatilidade (ver equação (1)). Quanto maior é a volatilidade, maior será a incerteza.

Pode-se com isto dizer que a volatilidade histórica ou estatística apenas dá indicações do que aconteceu no passado, não sendo linear que as mesmas venham a acontecer no futuro (Bucci, 2017).

2.1.2 Volatilidade Implícita

A volatilidade implícita é a volatilidade incorporada no preço dos ativos, ou seja, é o que o mercado pensa sobre determinado ativo no momento. A volatilidade

implícita é um conceito que se aplica apenas aos contratos de opções, demonstrando os interesses do mercado em relação à volatilidade das opções. Trata-se de uma aproximação muito útil no que toca a conhecer o que o mercado pensa exatamente e num determinado momento sobre o ativo subjacente, ou, quando se deseje, compara preços das opções para preços de exercícios diferentes e para diferentes maturidades.

A volatilidade implícita está em mudança permanente, e apresenta uma forte relação com o preço das opções, na medida em que, se a mesma sobe, o preço da opção também sobe, e vice-versa. O modelo comumente utilizado no mercado financeiro para medir a volatilidade implícita é o Modelo de Black-Sholes.

Akyildirim et al. (2019) analisaram a relação entre a volatilidade do preço de diversas criptomoedas e a volatilidade implícita dos mercados financeiros dos Estados Unidos e da Europa. Concluem que criptomoedas apresentam evidências de aumento da volatilidade durante os períodos em que o “medo” dos investidores é elevado, corroborando o descrito acima.

2.1.3 Volatilidade Futura ou Previsional

A volatilidade futura ou previsional tem em conta a incerteza do futuro e é por isso a mais complexa de estimar, dado a sua dificuldade de estimar o preço do ativo subjacente para o período da opção até ao seu termo.

São vários os métodos propostos para determinar o valor da volatilidade, não existindo um método mais correto para se utilizar. Em geral, são utilizadas variantes aos modelos ARCH (Poon e Granger, 2003) e Garch (Floros, 2008).

Yuan et al. (2019) aplicam modelos GARCH para prever a volatilidade futura e concluem que quando o intervalo da amostra é de 5 minutos em comparação com intervalos de menor frequência, o modelo apresenta melhor desempenho na previsão.

2.2 Factos estilizados sobre volatilidade

Entre os “factos estilizados” mais estudados na literatura encontram-se as *fat tails* na distribuição de rendibilidades, a volatilidade em clusters, o efeito alavanca ou de assimetria, a memória longa das sucessões cronológicas financeiras e os movimentos conjuntos (*co-movements*).

A ampla e variada literatura (Masoliver et al., 2000; Bai e Perron, 2003; Verhoeven e McAleer, 2004; McCauley, 2004) revela que as distribuições das rendibilidades das ações podem ser leptocúrticas ou *fat tailed*, o que significa que apresentam uma concentração mais elevada nas abas relativamente à distribuição normal. Esta particularidade, também conhecida como excesso de curtose, foi identificada inicialmente por Mandelbrot (1963) e Fama (1963, 1965).

As distribuições *fat tailed* podem ter origem em movimentos bruscos pouco frequentes, mas de grande magnitude. O facto de muitas sucessões cronológicas de dados financeiros não se ajustarem à distribuição normal coloca em causa o pressuposto de que as rendibilidades são independentes e identicamente distribuídas (i.i.d.). Peters (1996) refere que uma explicação, geralmente avançada, para a prevalência destas caudas está associada ao facto de a informação ser apresentada de forma aglomerada e não de modo contínuo e linear.

Em meados do século passado, Mandelbrot (1963) e Fama (1965), referem através da identificação de grupos homogêneos na descrição do comportamento das sucessões cronológicas financeiras, a primeira volatilidade em *clusters*. Este fenómeno caracteriza-se pelo facto de, a períodos de grande volatilidade se seguirem períodos de grandes oscilações. De modo semelhante, pequenas alterações nos preços originam alterações de pequena dimensão (Campbell, Lo e MacKinlay, 1997).

O *leverage effect* (efeito de alavanca) ou efeito assimétrico ocorre quando os preços das ações tendem a ser correlacionados negativamente com as variações da volatilidade, ou seja, quando a volatilidade é maior após os choques negativos, comparativamente com os choques positivos de idêntica magnitude (Aydogan, 2016).

De acordo com Silva, Sáfiadi e Castro (2005), observam-se com frequência nos mercados financeiros períodos de intensa volatilidade, após períodos de queda de preços, não sendo sentida de forma tão intensa nos períodos em que os preços se elevam. Do exposto, podemos afirmar que os choques positivos e negativos tendem a gerar impactos distintos na volatilidade (Lin e Tsai, 2018).

Os efeitos de memória de longo prazo (*long memory*) detetados pela primeira vez em contextos não financeiros estão relacionados com um elevado grau de persistência nas observações, isto é, a volatilidade dos mercados financeiros está influenciada por choques muito distantes que se vão repercutindo ao longo do tempo até ao momento presente (Bollerslev e Mikkelsen, 1996).

Por fim, os movimentos conjuntos (*co-movements*) denotam sincronização de comportamentos em diferentes mercados, ou seja, assiste-se a uma tendência para comportamentos similares. Tradicionalmente, tem-se recorrido à correlação para quantificar a dimensão dos movimentos conjuntos e definir o grau de contágio entre os mercados financeiros (Barberis, Shleifer e Wurgler, 2005).

2.3 Tipos de modelos de volatilidade

A modelação da volatilidade tem sido alvo de várias investigações, ao longo dos anos, já que a mesma não é diretamente observável nos mercados. Os objetivos dos modelos de volatilidade passam por demonstrar alguns dos factos estilizados da volatilidade, sendo assim provável que se encontre na literatura

abordagens que visam explicar o comportamento da volatilidade através de modelos de heterocedasticidade condicional.

Existem duas classes gerais de modelos de volatilidade. O primeiro tipo formula a variância condicional diretamente como uma função dos observáveis. Neste caso, toma-se como exemplos os modelos ARCH e GARCH. A segunda classe formula modelos de volatilidade que não são funções dos observáveis e que podem ser chamados de volatilidade latente ou modelos de volatilidade estocástica.

Alguns dos modelos mais utilizados para modelar a volatilidade condicional são considerados ao longo da realização do trabalho: GARCH e EGARCH.

2.3.1 Modelo ARCH

As características das séries temporais financeiras impedem a sua modelação através dos modelos ARIMA clássicos, nomeadamente, por se verificar que a variância dos erros σ^2 não é constante (Sepúlveda 2011).

Um modelo que incorpore a possibilidade do termo do erro não ser constante (volatilidade) designa-se por um modelo de heterocedasticidade. Segundo Tsay (2001), os modelos de heterocedasticidade podem ser classificados em duas categorias: os que utilizam uma função determinística para captar a evolução de σ^2 ; e os que utilizam uma função estocástica para descrever σ^2 .

Desenvolvido por Engle em 1982, surge o modelo ARCH – modelo autorregressivo de heteroscedasticidade condicional, pioneiro em considerar que a variância do termo de erro não é constante, mas sim condicionalmente heteroscedástica, modelando-a como uma média móvel das observações passadas da série temporal. É também um dos modelos mais relevantes na descrição da variância de sucessões cronológicas.

De acordo com Engle (2004), este modelo surgiu pela necessidade de criação de um modelo que validasse a conjectura de Friedman (1977), de que a imprevisibilidade da inflação estaria na origem dos ciclos económicos e que esta incerteza afetaria os investidores.

O modelo ARCH considera que a variância condicional $t(\sigma_t^2)$ é função dos erros passados ao quadrado (ε_{t-i}^2) e pode ser representado com a seguinte fórmula base dada pela equação (2).

Um processo X_t diz-se um processo de ARCH de ordem q se,

$$X_t = \sigma_t \varepsilon_t, \text{ com } \sigma_t^2 = \alpha_0 + \sum_{i=1, q} \alpha_i \varepsilon_{t-i}^2 \quad (2)$$

sendo α_0 e α_i parâmetros do modelo que satisfazem um conjunto de condições ($\alpha_0 > 0$ e $\alpha_i \geq 0, i = 1, 2, \dots, q$) de forma a garantir que a variância não condicionada é finita. Normalmente, considera-se que a variável aleatória ε_t

segue uma distribuição normal. Quando σ_t é constante ao longo do tempo diz-se que X_t é um ruído branco.

A ideia base deste modelo é a de que X_t é não correlacionado mas dependente e que essa dependência pode ser descrita por uma simples função quadrática. Através da estrutura do modelo verifica-se que grandes valores passados de X_t implicarão uma variância condicional σ_t^2 de X_t elevada, isto, é valores elevados de X_t tendem a ser seguidos por valores elevados de X_t . Segundo Tsay (2001) isto significa que a probabilidade de obter variações grandes é maior que a probabilidade de obter uma baixa variância, muito comum em séries temporais financeiras.

Propriedades e limitações do modelo ARCH

De acordo com Tsay (2005), apesar do modelo ARCH ser relativamente simples de determinar, uma das suas desvantagens é o facto de requerer muitos parâmetros para descrever adequadamente a evolução da volatilidade. Todavia, outras limitações podem ser apontadas. Bentes (2009) descreve algumas das principais que foram referidas por Brooks (2002), nomeadamente:

- O modelo supõe que choques positivos ou negativos produzem o mesmo efeito na volatilidade, pois o modelo depende do quadrado dos choques anteriores;
- O modelo não fornece nenhuma forma de compreensão/deteção da fonte das variações de uma série temporal financeira. Apenas fornece uma forma mecânica de descrever a variância condicionada, não esclarecendo sobre quais as causas de tais variações;
- O modelo ARCH tende a devolver previsões exageradas da volatilidade porque responde lentamente a grandes alterações isoladas. A própria estrutura do modelo leva a que grandes valores de X_t tendam a ser seguidos por outros grandes valores de X_t , o que inevitavelmente irá gerar previsões exageradas da volatilidade.

De modo a ultrapassar algumas destas limitações foi desenvolvido o modelo GARCH que iremos analisar em seguida.

2.3.2 Modelo GARCH

Sugerido por Bollerslev (1986), o modelo GARCH (*Generalized Autoregressive Conditional Heteroscedastic*) constitui uma generalização do modelo ARCH e, posteriormente ao trabalho desenvolvido por Engle (2001), tornou-se um modelo muito usado para descrever a variância condicional, por ser um modelo parcimonioso e fácil de estimar.

O modelo GARCH foi proposto baseando-se em extensões consideradas fundamentais e eficientes para definirem mudanças de variâncias nas séries temporais financeiras. Os modelos de volatilidade podem ser utilizados para calcular a volatilidade futura de ativos financeiros, seja com o objetivo de especulação ou com o objetivo de cobertura de risco (*hedge*) (Marques, 2017).

Bollerslev (1986) demonstrou que os modelos GARCH podem proporcionar avaliações corretas para os parâmetros na amostra se o instrumento de medida de volatilidade for adequado, orientando a boas estimativas de volatilidade. No modelo GARCH, a variância condicional do t (σ_t^2) é função dos erros passados ao quadrado (ε_{t-i}^2), mas também dos seus próprios valores passados (σ_{t-j}^2).

Pode ser apresentado como na equação (3).

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^p \beta_j \sigma_{t-j}^2 \quad (3)$$

sendo α_0 , α_i e β_j parâmetros do modelo.

O modelo representado é conhecido como um modelo autorregressivo de heteroscedasticidade condicional generalizado de ordem (p,q) e representa-se como GARCH(p,q), q é o grau de processo ARCH e p é o grau de processo GARCH. Assim, quando $p=0$, o modelo GARCH(0,q) é equivalente ao modelo ARCH(q). Então, para que o modelo tenha covariância estacionária e, como tal, variância incondicional ou uma tendência de convergência, é necessário que se verifiquem as seguintes condições (Tsay, 2005).

$$\alpha_0 > 0 \quad (4)$$

$$\alpha_i \geq 0 \quad (i = 1, 2, \dots, q) \quad (5)$$

$$\beta_j \geq 0 \quad (j = 1, 2, \dots, q) \quad (6)$$

As reservas de desigualdade garantem que a variância condicionada não é negativa. Existindo a hipótese de ser considerada a variabilidade dos rendimentos do período corrente em função da volatilidade dos períodos anteriores, a variabilidade é considerada condicionada. Sendo assim, poderá verificar-se que o nível da volatilidade atual esteja positivamente correlacionado com o nível de volatilidade dos períodos imediatamente anteriores (Brooks, 2002).

Este tipo de modelos possibilita captar factos estilizados tradicionalmente relacionados com os dados de natureza económica e financeira, como por exemplo, a presença de *fat tails* na distribuição empírica das rendibilidades, o fenómeno dos *clusters* de volatilidade ou da não linearidade do seu comportamento e as alterações na capacidade de previsão (Marques, 2017).

O termo *fat tails* designa distribuições com caudas fortemente leptocúrticas. O termo *clusters* de volatilidade define-se pelo facto de períodos de grande volatilidade existirem seguidamente a outros períodos de grandes oscilações, da mesma maneira que períodos de pequena volatilidade, ou seja, períodos de pequenas alterações nos preços, serem consecutivamente seguidos de períodos de modificações de reduzida dimensão dos mesmos (Campbell et al., 1997).

Propriedades e limitações do modelo GARCH

Apesar de ser um modelo com muitas vantagens, também foram detetadas desvantagens, das quais devemos ter em consideração:

- É um modelo simétrico, ou seja, o impacto na volatilidade de um choque negativo é o mesmo que o impacto na volatilidade de um choque positivo;
- A não existência de uma estrutura assimétrica para a volatilidade gera distribuições enviesadas e com efeito sorriso (*skewed distributions*) para os preços previsionais;
- As variações de preços estão negativamente correlacionadas com as variações na volatilidade (*leverage effect*).

Devido a esta evidência empírica foram então desenvolvidas extensões ao modelo GARCH. De facto, o efeito assimétrico é uma das limitações dos modelos ARCH e GARCH.

2.3.3 Modelo EGARCH

Uma das extensões ao modelo GARCH é o modelo EGARCH (*Exponential Generalized Autoregressive Conditional Heteroscedastic*), proposto por Nelson (1991). Com este modelo, pretendia-se ultrapassar alguns dos problemas dos modelos anteriores, particularmente o facto de estes exigirem muitas restrições nos seus parâmetros para garantir a positividade da variância condicional, assim como o facto de estes não conseguirem captar a influência assimétrica dos retornos, na modelização das séries financeiras. O modelo EGARCH também pretende captar o *leverage effect* e garante que a variância seja sempre positiva, por ser apresentada em logaritmos.

Propriedades e limitações do modelo EGARCH

Este modelo é expresso pela equação onde a variância condicionada, σ_t^2 , é uma função assimétrica dos valores passados de u_{ts} , ou seja (equação (7)),

$$\ln \sigma_t^2 = \alpha_0 + \sum_{i=1}^p \beta_i \ln \sigma_{t-1}^2 + \sum_{i=1}^p \alpha_i \left(\frac{|u_{t-i}|}{\sigma_{t-i}} \right) + \sum_{i=1}^p \gamma_i \left(\frac{|u_{t-i}|}{\sigma_{t-i}} \right) \quad (7)$$

Onde:

α_0 – Valor constante

$\beta_i, \alpha_i, \gamma_i$ – Parâmetros do modelo

u_{t-i} – Erro observado em t-i

σ_{t-i} – Desvio-padrão observado em t-i

Pinho et al. (2011) referem que sendo γ o parâmetro referente à assimetria, quando ocorre termos:

- $\gamma < 0$ um choque negativo aumentaria a volatilidade das rendibilidades;
- $\gamma > 0$ um choque positivo diminuiria a volatilidade das rendibilidades;
- $\gamma = 0$ um choque positivo terá um efeito semelhante na volatilidade das rendibilidades ao de um choque negativo da mesma amplitude.

Os modelos EGARCH possuem diferenças significativas relativamente aos modelos GARCH (Tsay, 2005), entre as quais:

- Os modelos EGARCH utilizam $\ln\sigma_t^2$ de forma a contrariar a restrição dos modelos GARCH em que os coeficientes do modelo têm de ser positivos;
- O modelo reage tanto a variações positivas como negativas de X_t , o que não acontece nos modelos de GARCH.

A variância condicional de um modelo EGARCH evolui de uma forma linear dependendo do sinal de X_{t-1} . No caso de um modelo EGARCH(1,1) o decaimento inicial da função de autocorrelação da variância condicional é mais rápido que o da função exponencial sendo que, posteriormente, ele aproxima-se da função exponencial lentamente. Tal característica faz com que não seja viável utilizar um modelo EGARCH(1,1) para caracterizar processos que apresentam um decaimento lento na função de autocorrelação (Sepulveda, 2011). Malmsten and Terasvirta (2004) concluíram que o modelo simétrico EGARCH(1,1) com ε_t normalmente distribuídos, não é suficientemente flexível para caracterizar processos com elevada curtose e decaimento lento da função de autocorrelação.

Um dos problemas dos modelos EGARCH é o facto de graças à sua estrutura exponencial poder sobrestimar o impacto das observações “aberrantes” na volatilidade. Contudo, a literatura recomenda que os modelos GARCH e EGARCH sejam comparados, uma vez que o modelo GARCH é uma das parametrizações da variância mais utilizados.

2.4 Uso dos modelos GARCH e EGARCH em dados de elevada frequência

A possibilidade de se obterem estimativas mais precisas de volatilidade é um tópico de grande interesse por parte de investigadores e investidores financeiros. Esta possibilidade está associada à cada vez maior disponibilidade de dados de alta frequência, o que abriu espaço para a investigação empírica voltada para a análise e aplicação destes dados.

Kim e Hwang (2020) usam dados ao minuto de duas ações pertencentes à Bolsa de valores Sul-Coreana e concluem que o modelo ARCH pode ser um modelo estatístico importante para ilustrar a dependência direcional da volatilidade intradiária no mercado financeiro.

Matei, Rovira e Agell (2019) propõem uma metodologia que inclui estimativas da volatilidade noturna com dados de alta frequência utilizando o modelo GARCH. Os resultados indicam uma melhoria de previsão usando modelos bivariados em relação àqueles que não incluem estimativas de volatilidade noturna.

Zhang, Mello e Sadeghi (2018) usam dados de alta frequência do mercado de ações Australiano para avaliar a previsibilidade de três modelos do tipo GARCH (GARCH, TGARCH e APARCH). Concluem que, no geral, o modelo APARCH fornece a melhor previsão, o que demonstra a capacidade do modelo APARCH em capturar os retornos leptocúrticos e outros fatos estilizados de volatilidade no mercado de ações australiano.

Ciaiana, Kancsa e Rajcaniovac (2018) aplicam o modelo GARCH com dados de alta frequência para prever o preço da *Bitcoin*. Os seus resultados indicam que a procura de *Bitcoin* e a sua procura especulativa têm um impacto estatisticamente significativo na formação do seu preço. Concluem ainda que os dados de alta frequência (no caso deles, dados de hora a hora) permitem obter percepções adicionais, que permanecem disfarçadas usando preços médios diários ou semanais, como habitual. Sugerem que o estudo com dados de alta frequência é um caminho promissor para pesquisas futuras e deve ser usado para outras moedas virtuais.

Vo (2017) aplica vários modelos da família GARCH para estimar a volatilidade diária daquela que é a maior empresa do ramo de serviços financeiros do mundo de acordo com a revista Forbes, a Citigroup Inc. Concluem que a aplicação destes modelos a retornos de alta frequência oferecem uma qualidade de ajuste superior do que quando ajustados à medida de retorno convencional, afirmando que os dados de alta frequência podem melhorar muito o desempenho das estimativas GARCH. Esta afirmação já tinha sido feita por Martens (2001) que modelou a volatilidade intradiária e concluiu que a previsão da volatilidade diária usando retornos intradiários é superior à da abordagem tradicional usando retornos diários.

3. Dados

Foram utilizados dados de frequência ao minuto, relativos a 104 empresas que compõem o índice NASDAQ, e ainda o próprio índice. Os dados foram recolhidos a 24 de outubro de 2019 do *Computer Science and Engineering*. A amostra contém dados ao minuto do índice anteriormente referido e das empresas da Tabela 1, para um período compreendido entre 26 de julho de 2016 a 30 de dezembro do mesmo ano, num total de 43119 observações para cada série. Devido à escassez de dados de alta frequência, este período foi o único com dados disponíveis para todas as séries estudadas.

O nome NASDAQ refere-se originalmente ao *National Association of Securities Dealers Automated Quotation System*. O índice NDX é composto maioritariamente por empresas tecnológicas. Têm como principal característica o facto das mesmas serem instituições não-financeiras, que laboram no mercado das grandes indústrias (sendo que a maioria das empresas cotadas neste índice estão afetadas ao sector da tecnologia).

Na Tabela 1 é possível verificar a lista de todas as empresas que incorporam o índice que irá ser estudado.

Tabela 1 – Empresas do índice NASDAQ analisadas

Sigla	Empresa	Sigla	Empresa
AAL	American Airlines Group	LBTYA	Liberty Global plc
AAPL	Apple Inc	LBTYK	Liberty Global PLC Class C
ADBE	Adobe Systems Incorporated	LLTC	Linear Technology Corporation
ADI	Analog Devices	LRCX	Lam Research
ADP	Automatic Data Processing, Inc	LVNTA	Liberty Interactive
ADSR	Altair Engineering	MAR	Marriott International, Inc
AKAM	Akamai Technologies, Inc	MAT	Mattel, Inc
ALXN	Alexion Pharmaceuticals	MCHP	Microchip Technology
AMAT	Applied Materials, Inc	MDLZ	Mondelēz International
AMGN	Amgen Inc	MNST	Monster Beverage
AMZN	Amazoncom, Inc	MSFT	Microsoft Corporation
ATVI	Activision Blizzard	MU	Micron Technology, Inc
AVGO	Avago Technologies, Inc	MXIM	Maxim Integrated Products
BBBY	Bed Bath & Beyond Inc	MYL	Mylan, Inc
BIDU	Baiducom, Inc	NCLH	Norwegian Cruise Line Holdings Ltd.
BIIB	Biogen Idec, Inc	NDX	NASDAQ-100
BMRN	BioMarin Pharmaceutical	NFLX	Netflix
CA	CA, Inc	NTAP	NetApp, Inc
CELG	Celgene Corporation	NTES	NetEase, Inc
CERN	Cerner Corporation	NVDA	NVIDIA Corporation
CHKP	Check Point Software Technologies Ltd	NXPI	NXP Semiconductors
CHTR	Charter Communications, Inc	ORLY	O'Reilly Automotive, Inc
CMCSA	Comcast Corporation	PAYX	Paychex, Inc

COST	Costco Wholesale Corporation	PCAR	PACCAR Inc
CSCO	Cisco Systems, Inc	PCLN	The Priceline Group, Inc
CSX	CSX Corporation	PYPL	PayPal
CTRP	Ctrip (Trip.com Group)	QCOM	QUALCOMM Incorporated
CTSH	Cognizant Technology Solutions Corporation	QVCA	Qurate Retail Inc
CTXS	Citrix Systems, Inc	REGN	Regeneron Pharmaceuticals
DISCA	Discovery Communications	ROST	Ross Stores Inc
DISCK	Discovery, Inc. Series C Common Stock	SBAC	SBA Communications
DISH	Dish Network, Inc	SBUX	Starbucks Corporation
DLTR	Dollar Tree, Inc	SIRI	Sirius XM Radio, Inc
EA	Electronic Arts	SRCL	Stericycle, Inc
EBAY	eBay Inc	STX	Seagate Technology Holdings
ESRX	Express Scripts, Inc	SWKS	Skyworks Solutions Inc
EXPE	Expedia, Inc.	SYMC	Symantec Corporation
FAST	Fastenal Company	TMUS	T-Mobile US
FB	Facebook, Inc	TRIP	TripAdvisor
FISV	Fiserv, Inc	TSCO	Tractor Supply Company
FOX	Fox Corp Class B	TSLA	Tesla Motors, Inc
FOXA	21st Century Fox	TXN	Texas Instruments, Inc
GILD	Gilead Sciences, Inc	ULTA	ULTA Beauty
GOOGLE	Alphabet Inc Class A	VIAB	Viacom Inc
HSIC	Henry Schein, Inc	VOD	Vodafone Group, plc
ILMN	Illumina, Inc	VRSK	Verisk Analytics
INCY	Incyte Corporation	VRTX	Vertex Pharmaceuticals
INTC	Intel Corporation	WBA	Walgreens Boots Alliance
INTU	Intuit, Inc	WDC	Western Digital
ISRG	Intuitive Surgical Inc	WFM	Whole Foods Market, Inc
JD	JD.Com Inc	XLNX	Xilinx, Inc
KHC	Kraft Heinz Company	XRAY	Dentsply Sirona
		YHOO	Yahoo! Inc

4. Metodologia

Nesta secção apresentamos a metodologia utilizada para reforçar a apresentação dos modelos já referidos no capítulo 2, aquando da apresentação da revisão da literatura.

Relativamente à notação, seja P_t e P_{t-1} os preços de um ativo nos momentos t e $t-1$, respetivamente, e $r_t = \ln\left(\frac{P_t}{P_{t-1}}\right) = \ln(P_t) - \ln(P_{t-1})$ o log retorno ou o retorno composto continuamente de um ativo no período $t-1$ a t .

Define-se a média e a variância condicionais como, respetivamente (equação (8)).

$$m_t = E_{t-1}[r_t] \text{ e } h_t = E_{t-1}[(r_t - m_t)^2] \quad (8)$$

onde $E_{t-1}[u]$ é a expectativa de uma variável u dada a informação definida no tempo $t-1$. Ora, isso implica que R_t é gerado de acordo com o seguinte processo: $R_t = m_t + \sqrt{h_t}\varepsilon_t$, em que $E_{t-1}[\varepsilon_t] = 0$ e $V_{t-1}[\varepsilon_t] = 1$.

Também é possível determinar os momentos incondicionais do processo, definindo a média e a variância como, respetivamente, $\mu = E[r_t]$ e $\sigma^2 = E[(r_t - \mu)^2]$.

Vários modelos para retornos e volatilidades têm sido propostos e empregues na literatura a dados de elevada frequência, como pudemos constatar anteriormente. Alguns, como os modelos GARCH, são formulados de acordo com os momentos condicionais. Outros modelos, como os modelos de volatilidade estocástica, são expressos em termos de variáveis latentes que facilitam a avaliação de momentos e distribuições incondicionais, e, por outro lado, os modelos de quebra estrutural estocásticos são formulados com base nas distribuições incondicionais.

“Skewness” (assimetria) e “kurtosis” (curtose) são medidas de dispersão estatística usadas para descrever a distribuição.

A assimetria e curtose condicionais são definidas do mesmo modo como, respetivamente, apresentado nas equações (9) e (10).

$$s_t = \frac{E_{t-1}[(r_t - m_t)^3]}{h_{t-1}^{3/2}} \quad (9)$$

e

$$k_t = \frac{E_{t-1}[(r_t - m_t)^4]}{h_{t-1}^2} \quad (10)$$

4.1 Modelo de Volatilidade - GARCH

Utilizamos o modelo GARCH(p, q) na sua formulação generalizada, tal como se apresenta nas equações (11) e (12).

$$R_{it} = c + \beta r_{i(t-1)} \quad (11)$$

$$h_t = w + \sum_{i=1}^p \alpha_i (R_{t-i} - \mu)^2 + \sum_{j=1}^q \beta_j h_{t-j} \quad (12)$$

Este modelo representa uma série de tempo cuja variância não-condicional é constante, enquanto a sua variância condicional às informações disponíveis no período anterior apresenta um comportamento autorregressivo. Pode ser caracterizado por ser uma forma simples e eficaz de modelar a volatilidade de preços, isto é, a incerteza sobre a média desses preços. Este modelo pode ser estimado através da máxima verossimilhança visto que uma distribuição para as inovações, ε_t , foi especificada. O pressuposto comum é o de que as inovações são do tipo *Gaussian*.

Os parâmetros α e β determinam, através da sua dimensão, a dinâmica de curto prazo da volatilidade da série temporal resultante. O coeficiente α significa que a volatilidade reage intensamente aos movimentos do mercado. Já o coeficiente β indica que choques na variância condicional levam muito tempo a desaparecer, e por isso, permite concluir acerca da persistência da volatilidade.

Se α é relativamente elevado e β é relativamente baixo, então a volatilidade tende a ser mais “pontaguda” (apresentar alta reação). Quando $\alpha + \beta$ se aproxima da unidade, choques no período t vão persistir ao longo de períodos futuros e implica a existência de uma “memória longa”. Se a soma dos coeficientes α e β for igual a um, qualquer choque irá levar a uma alteração permanente nos valores futuros de σ_t^2 e, conseqüentemente, os choques na variância condicional serão persistentes.

4.2 Aplicação do modelo EGARCH

Visto que o modelo GARCH é uma das parametrizações da variância condicional mais frequentemente utilizada, pode ser útil comparar os resultados obtidos da aplicação de um modelo GARCH com os resultados obtidos da aplicação de um modelo EGARCH.

No modelo EGARCH, desenvolvido por Nelson (1991), a variância condicional do período t (σ_t^2) é uma função assimétrica dos erros observados passados (ε_{t-i}). Este assume a seguinte forma expressa pelas equações (13) e (14).

$$R_{it} = c + \beta r_{i(t-1)} \quad (13)$$

$$\ln(\sigma_t^2) = \omega + \sum_{i=1}^p \beta_i \ln(\sigma_{t-i}^2) + \sum_{j=1}^q \left(\gamma_j \frac{\varepsilon_{t-i}}{\sigma_{t-j}} + \alpha_j \left| \frac{\varepsilon_{t-i}}{\sigma_{t-j}} - \sqrt{\frac{2}{\pi}} \right| \right) \quad (14)$$

onde \ln designa o logaritmo natural, ω é uma constante real, β_i , γ_j e α_j são parâmetros do modelo, ε_{t-i} corresponde ao erro observado em $t-i$ e σ_{t-j} corresponde ao desvio-padrão observado em $t-j$. O parâmetro γ reflete a relação

entre as variações do preço dos ativos e as variações na volatilidade dos mesmos.

De acordo com Pinho et al. (2011), quando: $\gamma < 0$, um choque negativo aumentaria a volatilidade das rendibilidades; $\gamma > 0$, um choque positivo diminuiria a volatilidade das rendibilidades; $\gamma = 0$, um choque positivo terá um efeito semelhante ao de um choque negativo na volatilidade das rendibilidades.

Se $\gamma \neq 0$, então os choques são assimétricos, ou seja, o impacto de choques positivos na volatilidade é diferente do impacto de choques negativos. Verifica-se a presença do efeito alavancagem se o coeficiente de assimetria for negativo e estatisticamente significativo.

Convém ainda referir que depois dos testes iniciais apropriados se concluiu que para as séries em análise os modelos que ofereciam o melhor ajustamento eram os modelos GARCH(1,1) e EGARCH(1,1), tal como nos autores Narayan e Sharma (2011), Bollerslev et al. (1992), Fwaga et al. (2017), entre outros.

5. Resultados Empíricos

Esta secção inicia com a apresentação das estatísticas descritivas dos dados utilizados, mas por se tratarem de 105 séries de dados de elevada frequência a analisar de modo individual, optamos por apresentar somente os dados para a série de retornos do índice NASDAQ no corpo de texto e os restantes resultados encontram-se no apêndice, na tabela A.1.

Tabela 2 – Estatística descritiva da série NASDAQ

	R_NDX
Mean	4.78E-07
Median	-8.98E-08
Maximum	0.007156
Minimum	-0.00371
Std. Dev.	0.000149
Skewness	3.818886
Kurtosis	221.2083
Jarque-Bera	85650849
Probability	0
Sum	0.020626
Sum Sq. Dev.	0.000957
Observations	43119

De acordo com a estatística descritiva, verificamos que a taxa média de retorno do índice é positiva, apesar de muito próximo de 0, a taxa média de retorno das empresas que o compõem é positiva, ainda que aproximadamente 0, ou seja, os ganhos não são muito significativos. Todavia, trata-se de dados de elevada frequência, pelo que os ganhos expectáveis de minuto a minuto também seriam muito baixos (Li, Zhang, 2017).

O desvio padrão é baixo, o que nos indica que o valor dos ativos pouco varia de um minuto para o outro, os dados são estáveis, o que era expectável segundo a literatura (De Nard et al., 2020; Li, Zhang, 2017).

Skewness (ou coeficiente de assimetria) é a medida da assimetria da distribuição de probabilidade. Certas empresas (ver anexo, tabela A 1) apresentam um coeficiente negativo, implicando esta inclinação negativa, ou seja, que a cauda do lado esquerdo da função de densidade de probabilidade é maior do que a do lado direito, sendo que a maior parte dos valores ficam à direita da média. Quando a inclinação é positiva, concluímos exatamente o oposto. Um valor de zero indica que os valores são uniformemente distribuídos em ambos os lados da média, o que implica uma distribuição simétrica.

O coeficiente de Curtose mede o grau de achatamento da curva de distribuição de probabilidade. Se o seu valor for inferior a três significa que a função de distribuição é mais achatada que a distribuição normal, e se o seu valor for

superior a três, tem-se que a distribuição em questão é mais alta e concentrada do que a distribuição normal. Tal facto verifica-se, uma vez que o valor para este coeficiente é superior a 3 para todas as empresas e para o próprio índice, tal como no estudo realizado por Shaika e Syeda (2019).

Para uma inspeção inicial dos dados recolhidos e tratados procedemos ainda à apresentação gráfica tanto da série de valores de fecho do índice como dos seus retornos (para os restantes valores para cada ação por favor ver anexo, tabela A 1). A figura 1 apresenta o cronograma da série de valores de fecho do índice NASDAQ, utilizando todas as informações disponíveis para o período acima indicado.

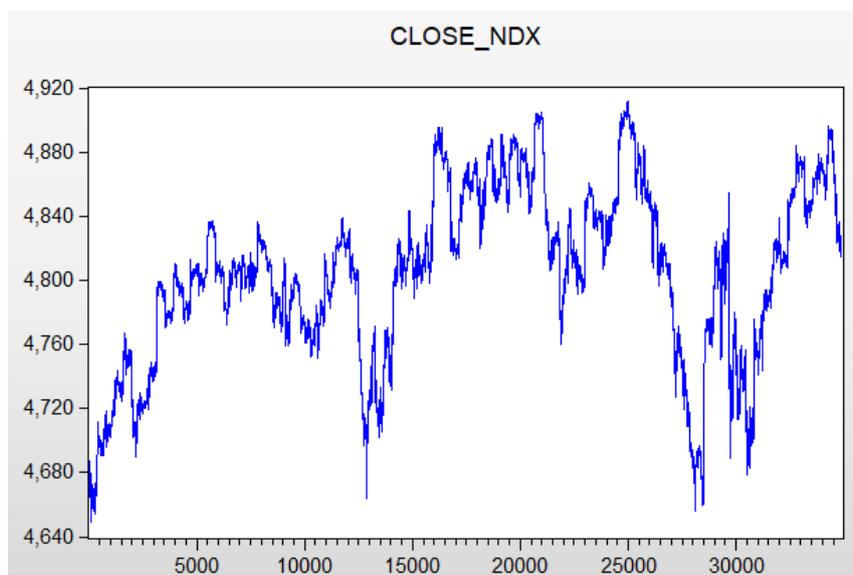


Figura 1- Cronograma da série NASDAQ

Analisando o cronograma da série NASDAQ (Fig.1) verifica-se que esta apresenta uma grande variabilidade o que indicia que a série não é estacionária até à 2ª ordem. Os testes de estacionariedade implementados permitiram-nos verificar isso mesmo, nomeadamente o teste de Dickey-Fuller aumentado², o teste de Phillips-Perron³ e o teste KPSS⁴. Todavia, os resultados dos testes de

² O teste de Dickey-Fuller Aumentado é conhecido na literatura como teste ADF (Augmented Dickey-Fuller).

³ O teste de Phillips - Perron, conhecido na literatura como teste PP é uma generalização do teste de Dickey - Fuller para os casos em que os erros $\{\epsilon_t\}_{t \in Z}$ são correlacionados e, possivelmente, heteroscedásticos.

⁴ Teste criado por Denis Kwiatkowski, Peter C. B. Phillips, Peter Schmidt e Yongcheol Shin, denominado teste KPSS devido aos seus nomes. Tem por finalidade determinar a estacionariedade numa série temporal. As hipóteses do teste são: $H_0 =$ "A série é estacionária"; $H_1 =$ "A série apresenta raiz unitária". Note-se que as hipóteses deste teste não são iguais aos testes de Dickey - Fuller e Phillips - Perron para estacionariedade. A hipótese nula deste teste é igual às hipóteses alternativas nos testes anteriores.

estacionariedade das 105 séries aqui enunciados foram omissos pelo elevado volume de dados a que nos estamos a referir e pela quantidade de outputs já assim produzida (ver anexo, tabela A 1, para as restantes séries, em termos de estatística descritiva, uma vez que os resultados foram muito similares).

Já na Figura 2 apresenta-se a evolução da série de retornos do índice NASDAQ.

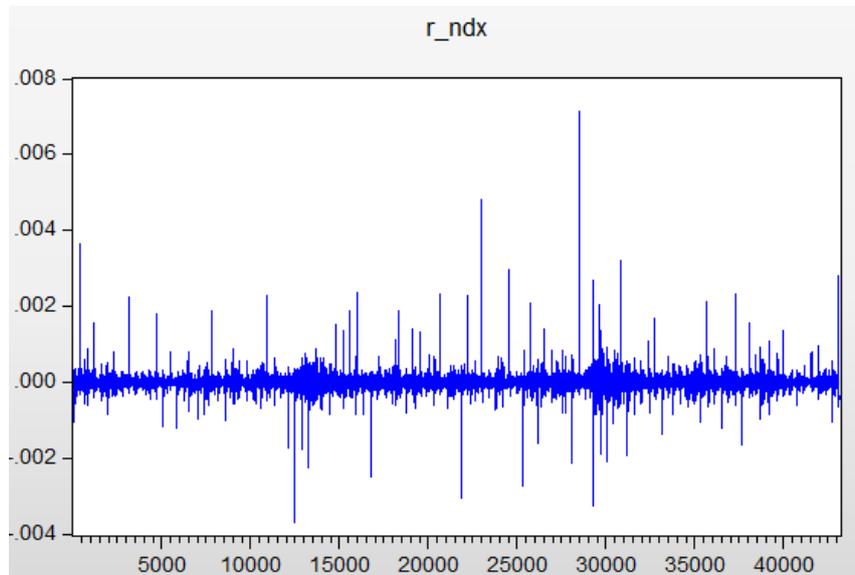


Figura 2 – Retornos do índice NASDAQ

Através da análise da Figura 2 verifica-se que esta aparenta ser estacionária. Resultado confirmado pelos testes de estacionariedade enunciados anteriormente, aquando da sua aplicação às 105 séries de retornos. Deteta-se também umas das características associada à volatilidade, a existência de *clusters*, ou seja, existem períodos na série em que a variabilidade é elevada e outros períodos em que a variabilidade é mais baixa, ou seja, a variabilidade da série ao longo do tempo não é homogénea, justificando o uso de modelos GARCH e EGARCH na análise da volatilidade de séries de ações e índices usando-se dados de elevada frequência.

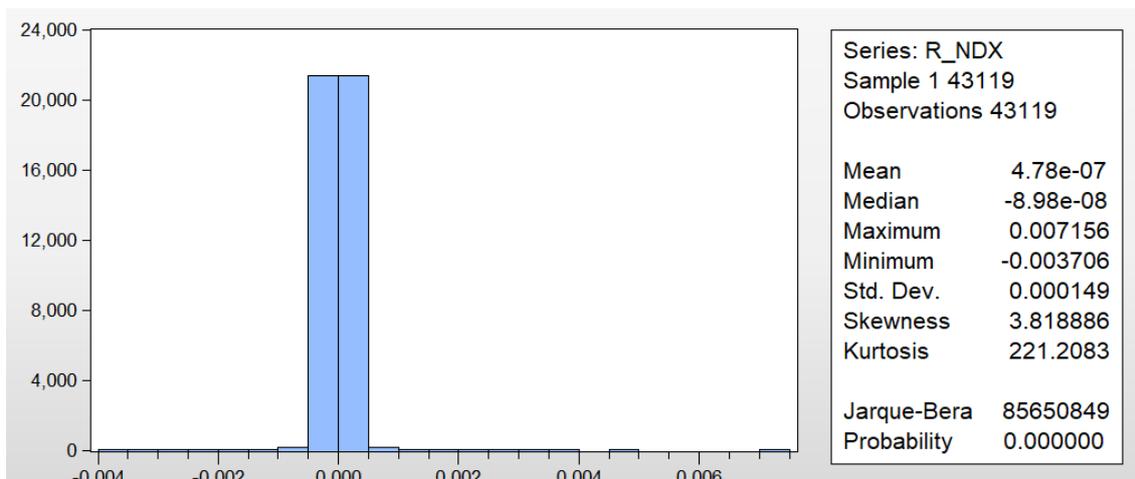


Figura 3 - Histograma da série de retornos NASDAQ

Calcularam-se medidas estatísticas da série de retornos NASDAQ e verificou-se que a sua curtose é maior que a curtose de uma distribuição normal e que segundo o teste Jarque-Bera se rejeita a normalidade dos dados (ver Figura 3). Após confirmação da existência do efeito ARCH, aplicou-se o modelo GARCH(1,1). No seguinte, aconselha-se a análise do apêndice, tabela A 2, para as restantes séries de retornos.

A Tabela 3 exhibe os resultados do modelo GARCH (1,1), obtidos em relação ao índice (NDX). Para as restantes séries, ver anexo, tabela A 2.

Tabela 3 – Resultados do modelo GARCH(1,1) referentes à série NASDAQ

	Coefficiente	Robust standard error	p-value
Constant	3.15E-06	1.73E-07	0.0000
R(-1)	0.086108	0.003551	0.0000
ω	2.14E-09	7.66E-12	0.0000
α	0.431930	0.001084	0.0000
β	0.643733	0.000883	0.0000

Analisando os valores de estimação obtidos através do Eviews, verifica-se que os parâmetros em consideração apresentam um *p-value* igual a 0, o que significa que os parâmetros são estatisticamente significativos a 1%, pelo que o modelo estimado assume a forma da equação (15).

$$X_t = \sigma_t \varepsilon_t \text{ onde } \sigma_t^2 = 2.14E - 09 + 0.431930X_{t-1}^2 + 0.643733\sigma_{t-1}^2 \quad (15)$$

Podemos inferir que o parâmetro R(-1) (retorno do minuto anterior) é importante para explicar o retorno do minuto seguinte, explicando-o de forma positiva.

Ao somarmos os valores $\alpha + \beta$ verificamos que a volatilidade dos retornos é persistente (1.075663). Este resultado é frequentemente observado em dados financeiros de alta frequência (Bollerslev, 2006).

Em relação às restantes séries analisadas, na generalidade tiramos as mesmas conclusões que as retiradas para o índice. Na figura 4 podemos verificar que os valores $\alpha + \beta$ são superiores a 1 para a maioria das séries estudadas. De realçar que a empresa CTSH é a mais persistente, uma vez que a soma entre α e β desta empresa alcança o valor de 3.58, ($\alpha = 3.52$ o que indica uma tendência de instabilidade) (Dedi e Yavas, 2016), já a menos volátil é a AKAM, onde $\alpha + \beta = 0.75$.

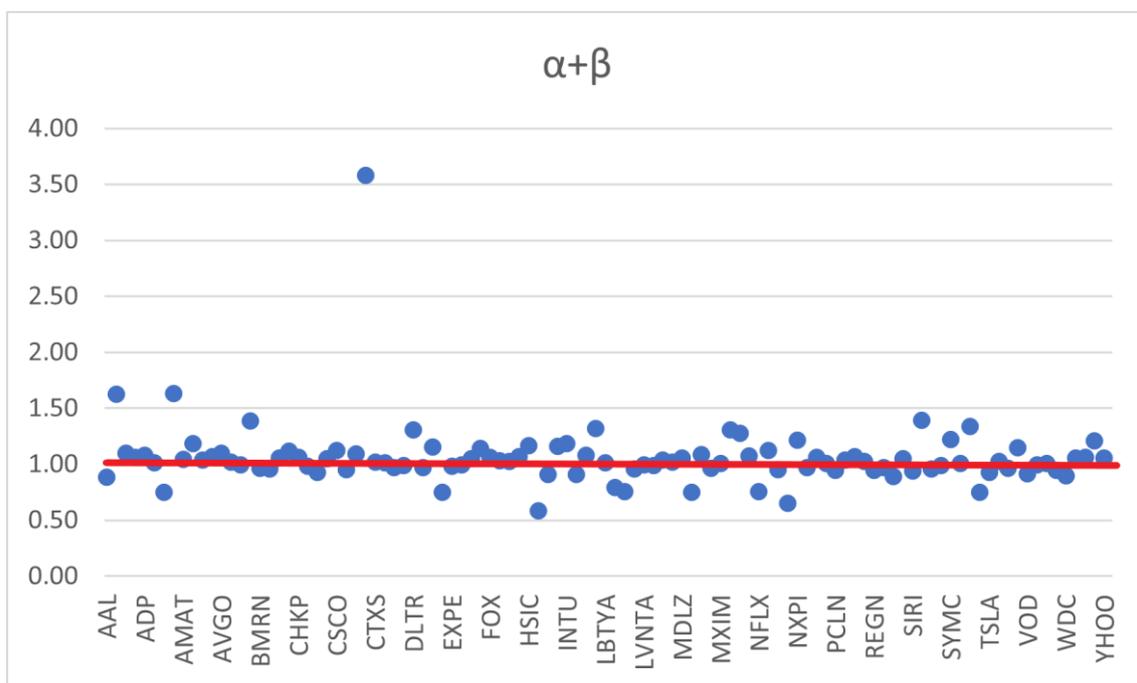


Figura 4 – Modelo GARCH (Estimação de $\alpha + \beta$)

As séries estudadas que não são estatisticamente significativas a 5% são: a AMZN, a CMCSA, a CSX, a GOOGLE, a ILMN, a LVNTA, a MNST, a NVDA, a PYPL, a SIRI, a TSLA e a YHOO, ou seja, 12 empresas num universo de 105.

A Tabela 4 exhibe os resultados do modelo EGARCH (1,1), obtidos em relação ao índice NDX. Para as restantes séries aconselha-se a consulta do anexo, tabela A 3.

Analisando os resultados obtidos verifica-se que todos os coeficientes estimados são estatisticamente significativos e que o parâmetro γ é negativo tal como esperado. Sendo este o parâmetro referente à assimetria, tal significa que o modelo revela a existência de efeitos assimétricos na volatilidade. Assim, as más notícias aumentarão a volatilidade mais do que uma boa notícia, da mesma dimensão - o que normalmente é evidenciado em séries temporais financeiras de preços de ações e taxa de câmbio (Verbeek, 2008).

Tabela 4 - Resultados do modelo EGARCH(1,1) referentes à série NASDAQ

	Coefficiente	Robust Standard Error	p-value
Constante	-8.31E-07	2.73E-07	0.0024
R(-1)	0.093424	0.002350	0.0000
ω	-1.094769	0.005222	0.0000
α	0.286749	0.000617	0.0000
γ	-0.104495	0.000713	0.0000
β	0.948304	0.000286	0.0000

Novamente, os valores de estimação obtidos através do Eviews, mostram que os parâmetros em consideração apresentam um *p-value* igual a 0, o que significa que os parâmetros são estatisticamente significativos a 1%, pelo que o modelo estimado assume a forma da equação (16).

$$X_t = \sigma_t \varepsilon_t \text{ com } \ln \sigma_t^2 = -1.094769 + 0.286749 \frac{|X_{t-1}|}{\sigma_{t-1}} - 0.104495 \frac{|X_{t-1}|}{\sigma_{t-1}} + 0.948304 \ln(\sigma_{t-1}^2) \quad (16)$$

Tendo em conta os resultados acima, é possível verificar que os parâmetros α e β mostram-se positivos, o que implica que há uma relação positiva e significativa entre os retornos do mercado de ações e a volatilidade condicional. Um termo assimétrico positivo implica ainda que choques positivos têm maior impacto na volatilidade do que choques negativos da mesma magnitude. A soma dos parâmetros α e β é de 1.235053, um valor ligeiramente superior ao que se obteve com a aplicação do modelo GARCH (1,1) (1.075663).

Na generalidade das restantes séries retiramos as mesmas informações que reiteramos acerca do índice. Na figura 5 podemos verificar que os valores $\alpha + \beta$ são superiores a 1 para a maioria das séries estudadas. De realçar que para este modelo a empresa TSCO é a mais volátil, indicando que um choque na volatilidade demora a dissipar-se, já a menos volátil é a ILMN com $\alpha + \beta < 0$.

Quando se analisa os valores dos coeficientes, α e β , separadamente, pode-se observar os níveis de reação e persistência da volatilidade em relação a um choque. A empresa que se mostrou com menor reação a um choque foi a ILMN ($\alpha = 0.02176$). No entanto, em relação à persistência, a empresa NXPI é aquela que apresenta maior persistência ($\beta = 0.935261$).

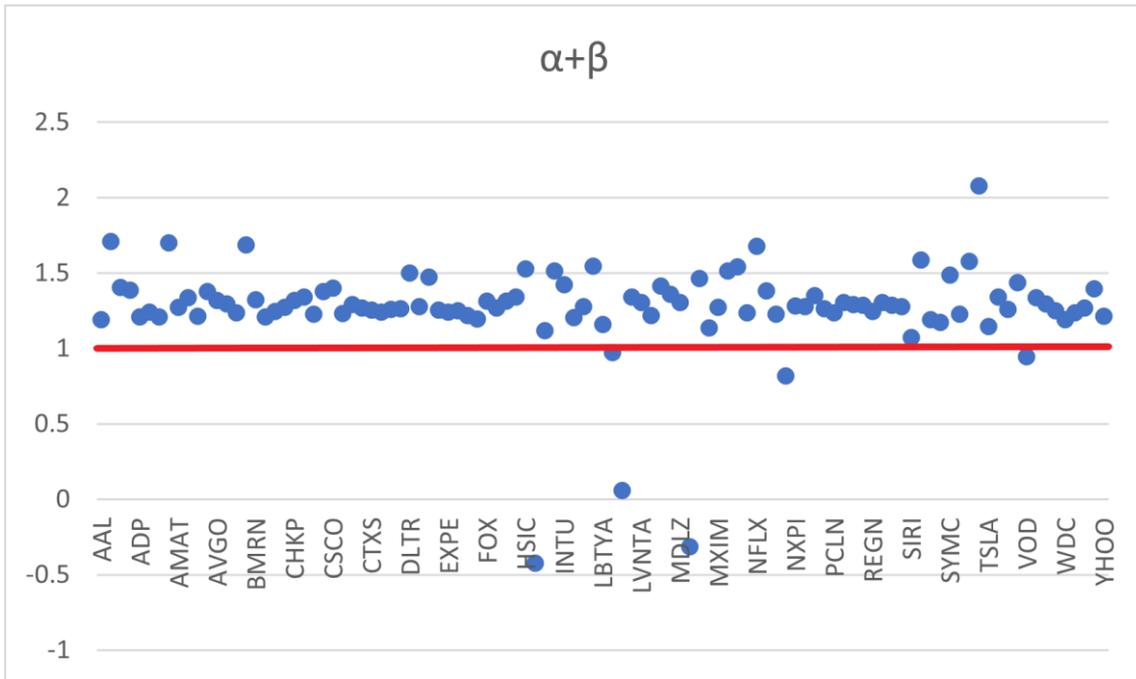


Figura 5 - Modelo EGARCH (Estimação de $\alpha + \beta$)

No que diz respeito ao parâmetro referente à assimetria, γ , podemos confirmar através da figura 6 que a maioria das séries estudadas têm um valor de $\gamma < 0$, há que realçar a empresa TCSO para além ser a mais persistente, é ainda aquela que apresenta o maior valor de γ , podendo afirmar-se que um choque positivo diminuiria a volatilidade das suas rendibilidades.

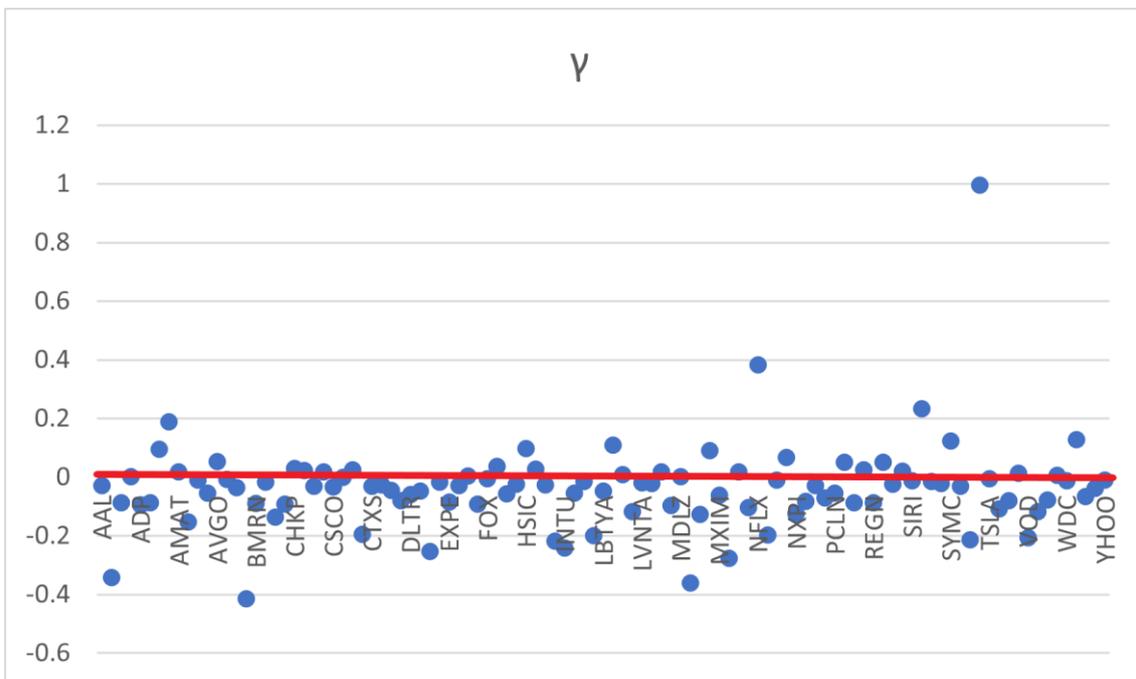


Figura 6 - Modelo EGARCH (parâmetro γ)

As séries estudadas que não são estatisticamente significativas a 5% são: a ADP, AMAT, BBBY, DISCA, ESRX, EXPE, INTU, LBTYA, LLTC, MCHP, NTES, PAYX, PCAR, TXN, WFM e XLNX, ou seja, 16 empresas num universo de 105.

Em relação à persistência verificada associada ao facto de existirem mais reações a choques negativos que a positivos, os nossos resultados vão de encontro aos resultados de diversos autores. Corgnet, Kujal e Porter (2012) concluem que os investidores adotam a abordagem do pior caso para novas informações, reagindo mais a notícias más do que boas. Leippold, Trojani e Vanini (2007) mostram que os preços dos ativos reagem mais às más notícias do que às boas.

Se os mercados fossem realmente eficientes, os preços das ações incorporariam todas as notícias disponíveis, boas e más, em todos os momentos. A única coisa que faria movimentar no sentido ascendente ou descendente a cotação de uma ação seriam as notícias de carácter específico ou individual da empresa – risco residual, e não as notícias do mercado em geral – risco sistemático (Yan e Yan, 2019). Todavia, as pessoas aprendem de maneira diferente com as notícias financeiras, dependendo se as mesmas são boas ou más. Nos mercados financeiros, os investidores serão mais pessimistas sobre comportamentos futuros das ações, quando estiverem a aprender com resultados negativos em vez de resultados positivos, ou quando ouvirem más notícias sobre a economia (Maliq, 2011).

Num contexto negativo, somos biologicamente inclinados a ser mais pessimistas do que deveríamos (Veronesi, 1999), o que é natural se atentarmos ao facto de quais são as nossas decisões e ações durante as crises económicas ou quando enfrentamos reveses. Por exemplo, os gestores empresariais podem estar a subinvestir em atividades produtivas ou em capital humano durante as recessões, não porque estejam a ser cautelosos, mas porque estão programados para reagir exageradamente a más notícias (Howe, 1986). Este ficou conhecido na literatura das finanças comportamentais como o enviesamento do pessimismo (Bateson, 2016; Trimmer, 2016).

6. Conclusões

Dada a atual situação dos mercados financeiros, onde cada vez mais a incerteza se sobrepõe, torna-se cada vez mais fulcral prever e tomar decisões que minimizem as perdas que advêm de riscos ocorridos aquando da tomada de decisões. O mercado de ações é tanto mais atrativo para os investidores quanto maiores são os retornos gerados. Para que os investidores obtenham sucesso devem ser capazes de construir e gerir uma carteira de investimento. É nessa capacidade de construção e gestão que devem ter em consideração a volatilidade, uma vez que esta tem uma forte relação com o desempenho do mercado. Assim, quando o mercado de ações sobe, a volatilidade tende a diminuir e vice-versa. Isto porque quando a volatilidade aumenta, o risco tende a aumentar e, portanto, o retorno a diminuir.

Associado a esta necessidade de previsão da volatilidade como indicador decisivo, para alguns investidores, nas decisões que são tomadas nas atividades bolsistas, surge também a possibilidade de se obterem estimativas mais precisas de volatilidade dada a crescente disponibilidade de dados com uma frequência superior à diária.

Assim, esta pesquisa contribui para a literatura sobre a análise do comportamento dos retornos e volatilidades do mercado de ações NASDAQ e de algumas das suas respetivas empresas, utilizando-se para o efeito dados de alta frequência (ao minuto). Foram utilizados os preços ao minuto de 104 empresas analisadas de modo individual, bem como os preços ao minuto do respetivo índice, entre 26 de julho de 2016 a 30 de dezembro do mesmo ano, num total de 43119 observações para cada série.

Foram aplicados modelos do tipo ARCH, nomeadamente os modelos GARCH (1,1) e EGARCH (1,1), uma vez que através da literatura estudada concluímos que são os que melhor se adaptam a este tipo de análises. Martens (2001), conclui que quão maior for a frequência dos dados utilizados, melhor seria a volatilidade prevista pelo modelo GARCH (1,1).

Através do modelo GARCH (1,1), podemos concluir que a empresa CTSH é aquela que possui a maior reação a um choque ocorrido no mercado, no entanto, não se mostrou tão persistente ao longo do tempo, ou seja, o choque dissipa-se rapidamente, sem refletir maiores impactos sobre os retornos. Sendo ainda assim, uma das mais voláteis. Entre as empresas menos voláteis cujo comportamento de volatilidade dos retornos foi analisado, estão a AKAM, ESRX, ILMN, LLTC, LBTYK, MNST, NFLX, NVDA e TSCO.

Dadas algumas das limitações apontadas na literatura ao uso do modelo GARCH, como o facto de não capturar efeitos assimétricos da volatilidade, decidimos ainda implementar o modelo EGARCH. Através do modelo EGARCH (1,1), podemos concluir que a empresa TSCO é a mais volátil, indicando que um

choque na volatilidade demora a dissipar-se, tendo-se revelado como a menos volátil a ação da empresa ILMN.

Em relação ao parâmetro referente à assimetria, γ , confirmamos que a maioria das séries estudadas têm um valor de $\gamma < 0$. Neste contexto, há que realçar a empresa TCSO que para além de ser a mais persistente, é ainda aquela que apresenta o maior valor de γ , podendo afirmar-se que um choque positivo diminuiria a volatilidade das suas rendibilidades.

Uma queda nas cotações leva a um aumento nos níveis de volatilidade implícita podendo conduzir ao pânico dos investidores. Por sua vez, um acréscimo nas cotações irá reduzir os níveis de volatilidade implícita, reduzindo assim a ansiedade do mercado e levando a uma maior satisfação. Ou seja, os acréscimos nos níveis de volatilidade estão associados às descidas das cotações, enquanto os decréscimos se verificam sempre que as expectativas dos investidores sejam positivas.

Em relação à análise à assimetria de volatilidade, podemos afirmar que o período estudado apresenta sinais de assimetria, apresentando respostas diferentes a choques positivos e negativos. É ainda importante referir, que, desta forma, a volatilidade do mercado é maior após “más notícias” do que após “boas notícias”, deixando os investidores mais atentos a notícias negativas do que a positivas, reagindo mais fortemente e de imediato às mesmas. De enaltecer, que este é um comportamento comum evidenciado na literatura sobre enviesamentos cognitivos dos mercados financeiros, e bem descritos pelas finanças comportamentais. Este é um comportamento detetado na literatura de conservadorismo (Conrad et al., 1999), ambiguidade (Corgnat et al., 2012) e pessimismo (Bateson, 2016).

Este estudo apresenta ainda algumas limitações que podem ser oportunidades de investigações futuras. Desde logo, os dados são de difícil acesso dada a sua frequência o que impossibilitou a definição de um período de tempo mais interessante para a análise. Por serem dados de elevada frequência, a quantidade de dados a tratar acaba por si só a ser uma limitação, que poderá ser ultrapassada com o uso de *softwares* específicos de ciência dos dados para a sua análise (por exemplo, *Python*). Ficamos também limitados às 104 ações mais o índice NASDAQ, pelo que se sugere a inclusão de outros mercados e ações na análise para efeitos comparativos e perceber de que forma algumas informações de mercado condicionam este comportamento de volatilidade. Estudos futuros podem ainda utilizar outros modelos e incluir uma análise de previsão com base por exemplo no R^2 de uma regressão de *Mincer - Zarnowitz* (MZ), ou outros modelos, capazes de entender a relação entre comportamento do investidor e oscilações nos mercados financeiros.

Referências

Ait-Sahalia, Yacine. (2005). How Often to Sample a Continuous-Time Process in the Presence of Market Microstructure Noise. *Review of Financial Studies*. 18. 351-416. 10.1093/rfs/hhi016.

Ait-Sahalia, Yacine & Jacod, Jean. (2009). Testing for Jumps in a Discretely Observed Process. *The Annals of Statistics*. 37. 10.2139/ssrn.1069872.

Akgriray, Vedat. (1989). Conditional Heteroscedasticity in Time Series of Stock Returns: Evidence and Forecasts. *The Journal of Business*. 62. 55-80. 10.1086/296451.

Akyildirim, Erdinc & Corbet, Shaen & Lucey, Brian & Sensoy, Ahmet & Yarovaya, Larisa. (2019). The relationship between implied volatility and cryptocurrency returns. *Finance Research Letters*. 33. 10.1016/j.frl.2019.06.010.

Andersen, T. G. & Bollerslev, T. (1997). Intraday periodicity and volatility persistence in financial markets. *Journal of Empirical Finance*, (4):115-158

Andersen, T. G. & Bollerslev, T. (1998a). Answering the skeptics: Yes, standard volatility models do provide accurate forecasts. *International Economic Review*, 39(4):885-905

Andersen, T. G. & Bollerslev, T. (1998b). Deutsche mark-dollar volatility: Intraday activity patterns, macroeconomic announcements, and longer run dependencies. *The Journal of Finance*, 53(1):219-265

Andersen, T. G. & Bollerslev, T. (1999). Forecasting financial market volatility: Sample frequency vis-à-vis forecast horizon. *Journal of Empirical Finance*, 6:457-477.

Antoniou, A., P. Holmes and R. Priestley, "The Effects of Stock Index Futures Trading on Stock Index Volatility: An Analysis of the Asymmetric Response of Volatility to News." *Journal of Futures Markets* 18, 151-166, (1998).

Anwar, Sajid & Beg, Rabiul. (2012). Detecting Volatility Persistence in GARCH Models in the presence of Leverage Effect: A New Approach. *Quantitative Finance*. 14. 10.1080/14697688.2012.716162.

Aydoğan, Berna. (2016). Sentiment dynamics and volatility of international stock markets. *Eurasian Business Review*. 7. 10.1007/s40821-016-0063-3.

Badescu, Alex & Elliott, Robert & Ortega, Juan-Pablo. (2015). Non-Gaussian GARCH option pricing models and their diffusion limits. *European Journal of Operational Research*. 247. 10.1016/j.ejor.2015.06.046.

Bai, Jushan & Perron, Pierre. (2003). Computation and Analysis of Multiple Structural-Change. *Journal of Applied Econometrics*. 18.

Bai, Lan & Wei, Yu & Wei, Guiwu & Li, Xiafei & Zhang, Songyun. (2020). Infectious disease pandemic and permanent volatility of international stock markets: A long-term perspective. *Finance Research Letters*. 101709. 10.1016/j.frl.2020.101709.

Barberis, Nicholas, Andrei Shleifer, and Jeffrey Wurgler. (2005). Comovement. *Journal of Financial Economics* 75 (2): 283-317

Barjašić, Irena & Antulov-Fantulin, Nino. (2020). Time-varying volatility in Bitcoin market and information flow at minute-level frequency.

Bateson, Melissa. (2016). Optimistic and pessimistic biases: a primer for behavioural ecologists. *Current Opinion in Behavioral Sciences*. 12. 115-121. 10.1016/j.cobeha.2016.09.013.

Bentes, Sónia & Menezes, Rui & Ferreira, Nuno. (2013). On the asymmetric behaviour of stock market volatility: Evidence from three countries. *International Journal of Academic Research*. 5. 24-32. 10.7813/2075-4124.2013/5-4/A.4.

Bentes, Sónia & Menezes, Rui & Mendes, Diana. (2007). Long Memory and Volatility Clustering: is the empirical evidence consistent across stock markets?. *arXiv.org, Quantitative Finance Papers*. 387. 10.1016/j.physa.2008.01.046.

Bentes, Sónia (2011) – Sobre a Medição da Volatilidade nos Mercados Bolsistas Internacionais: Evidência dos Países do G7. Lisboa: Edições Colibri/Instituto Politécnico de Lisboa. 230 pp. ISBN 978-989-689-124-4

Bollerslev, Tim & Chou, Ray & Kroner, Kenneth. (1992). ARCH Modeling in Finance: A Review of the Theory and Empirical Evidence. *Journal of Econometrics*. 52. 5-59. 10.1016/0304-4076(92)90064-X.

Bollerslev, Tim & Litvinova, Julia & Tauchen, George. (2006). Leverage and Volatility Feedback Effects in High-Frequency Data. *Journal of Financial Econometrics*. 4. 353-384. 10.1093/jfinec/nbj014.

Bollerslev, Tim & Melvin, Michael. (1994). Bid-Ask Spreads and Volatility in the Foreign Exchange Market: An Empirical Analysis. *Journal of International Economics*. 36. 10.1016/0022-1996(94)90008-6.

Bollerslev, Tim & Mikkelsen, Hans. (1996). Modeling and pricing long memory in stock market volatility. *Journal of Econometrics*. 73. 151-184. 10.1016/0304-4076(95)01736-4.

Bollerslev, Tim. (1986). Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*. 52. 5-59.

Börjesson, Carl, Löhn, Ossian (2019). Univariate GARCH models with realized variance. Department of Statistics Uppsala University. <https://www.diva-portal.org/smash/get/diva2:1326886/FULLTEXT01.pdf>

Brailsford, Timothy & Faff, Robert. (1996). An evaluation of volatility forecasting techniques. *Journal of Banking & Finance*. 20. 419-438. 10.1016/0378-4266(95)00015-1.

Brooks, Chris. (2019). *Introductory Econometrics for Finance*. 10.1017/9781108524872.

Bucci, Andrea. (2018). Forecasting Realized Volatility: A Review. *Journal of Advanced Studies in Finance*. 8. 94-138. 10.14505/jasf.v8.2(16).02.

Campbell, John & Lo, Andrew & MacKinlay, A.Craig. (2012). *The Econometrics of Financial Markets*. 10.2307/j.ctt7skm5.

Chang, Kuang-Liang & Lee, Chingnun. (2020). The asymmetric spillover effect of the Markov switching mechanism from the futures market to the spot market. *International Review of Economics & Finance*. 69. 10.1016/j.iref.2020.06.028.

Chen, Wang & Ma, Feng & Wei, Yu & Liu, Jing. (2020). Forecasting oil price volatility using high-frequency data: New evidence. *International Review of Economics & Finance*. 66. 1-12. 10.1016/j.iref.2019.10.014.

Ciaian, Pavel & Kancs, d'Artis & Rajcaniova, Miroslava. (2018). The Price of BitCoin: GARCH Evidence from High Frequency Data.

Conrad, Jennifer & Cornelli, Bradford & Landsman, Wayne. (2000). When is Bad News Really Bad News. *The Journal of Finance*. 57. 10.2139/ssrn.167888.

Corgnet, Brice & Kujal, Praveen & Porter, David. (2012). Reaction to Public Information in Markets: How Much Does Ambiguity Matter?. *The Economic Journal*. 123. 10.2307/23470562.

Costa, Stefan (2019) – Fatores subjetivos/comportamentais que influenciam o PSI 20 e o IBEX 35. Instituto Politécnico de Viseu. Acesso a 15.11.2020. <https://repositorio.ipv.pt/handle/10400.19/6246>

Dai, Zhifeng & Zhou, Huiting & Wen, Fenghua & He, Shaoyi. (2020). Efficient predictability of stock return volatility: The role of stock market implied volatility. *The North American Journal of Economics and Finance*. 52. 101174. 10.1016/j.najef.2020.101174.

Diebold, Francis & Lopez, Jose. (1999). Forecast Evaluation and Combination. *Handbook of statistics*, 14, 241-268.

Doan, Tom & Shephard, Neil & Kim, Sangjoon & Chib, Siddhartha. (1998). Stochastic Volatility: Likelihood Inference and Comparison with ARCH Models. *Review of Economic Studies*. 65. 361-93. 10.1111/1467-937X.00050.

Duță, Violeta. (2018). Using The Symmetric Models Garch (1.1) And Garch-M (1.1) To Investigate Volatility And Persistence For The European And Us Financial Markets. *Studii Financiare (Financial Studies)*, Centre of Financial and Monetary Research "Victor Slavescu", vol. 22(1), pages 64-86.

Engle, R.F. & Mezrich, J.. (1996). GARCH for groups. *Risk*. 9. 36-40.

Engle, Robert & Manganelli, Simone. (1999). CAViaR: Conditional Autoregressive Value at Risk by Regression Quantiles. *Journal of Business and Economic Statistics*. 22. 10.1198/073500104000000370.

Engle, Robert & Patton, Andrew & Patton, A.. (2008). What Good is a Volatility Model. *Quantitative Finance*. 1. 237-245. 10.1016/B978-075066942-9.50004-2.

Engle, Robert. (1982). Autoregressive Conditional Heteroscedasticity With Estimates of the Variance of United Kingdom Inflation. *Econometrica*. 50.

Engle, Robert. (2001). GARCH 101: the use of ARCH/GARCH models in applied econometrics. *Journal of Economic Perspectives*. 15. 157-168. 10.1257/jep.15.4.157.

Esmail, Abounoori, Mohammad, Amin (2020). Modeling Gold Volatility: Realized GARCH Approach. *Iran. Econ. Rev. Vol. 24, No. 1, 2020. pp. 299-311*
Fama, Eugene. (1963). Mandelbrot and the Stable Paretian Hypothesis. *The Journal of Business*. 36. 420-420. 10.1086/294633.

Fama, Eugene. (1965). The Behavior of Stock Market Price. *Journal of Business - J BUS*. 38. 10.1086/294743.

Floros, Christos. (2008). Modelling Volatility using GARCH Models: Evidence from Egypt and Israel. *Middle Eastern Finance and Economics*. 2.

Gençay, Ramazan & Selcuk, Faruk & Ulugulyagci, Abdurrahman. (2003). High volatility, thick tails and extreme value theory in value-at-risk estimation [J]. *Insurance: Mathematics and Economics*. 33. 337-356. 10.1016/j.insmatheco.2003.07.004.

Granger, Clive & Poon, Ser-Huang. (2003). Forecasting Volatility in Financial Markets: A Review. *Journal of Economic Literature*. 41. 478-539. 10.1257/002205103765762743.

Howe, J. (1986). Evidence on Stock Market Overreaction. *Financial Analysts Journal*, 42(4), 74-77.

- Hsieh, David & Peters, Edgar. (1993). Chaos and Order in the Capital Markets: A New View of Cycles, Prices, and Market Volatility.. *The Journal of Finance*. 48. 2041. 10.2307/2329084.
- Huang, Zhuo & Wang, Tianyi & Hansen, Peter. (2016). Option Pricing with the Realized GARCH Model: An Analytical Approximation Approach: Option Pricing with the Realized GARCH Model. *Journal of Futures Markets*. 37. 10.1002/fut.21821.
- Jagannathan, Ravi & Glosten, Lawrence & Runkle, David. (1993). On the Relation between the Expected Value and the Volatility of the Nominal Excess Return on Stocks. *Journal of Finance*. 48. 1779-1801. 10.1111/j.1540-6261.1993.tb05128.x.
- Kariya, Takeaki & Liu, Regina. (2003). Options, Futures and Other Derivatives. 10.1007/978-1-4419-9230-7_2.
- Kendall, Maurice & Hill, A.. (1953). The Analysis of Economic Time-Series-Part I: Prices. *Journal of the Royal Statistical Society. Series A (General)*. 116. 11. 10.2307/2980947.
- Kim, J.-M., & Hwang, S. Y. (2020). Functional ARCH directional dependence via copula for intraday volatility from high-frequency financial time series. *Applied Economics*, 1–15. 10.1080/00036846.2020.1808184
- Leippold, M., F. Trojani, P. Vanini. (2008). Learning and asset prices under ambiguous information. *Review of Financial Studies* 21: 2565-2597.
- Li, C.W.. (1996). On a double-threshold autoregressive heteroscedastic time series model. *Journal of Applied Econometrics*. 11. 253-274. 10.1002/(SICI)1099-1255(199605)11:3<253::AID-JAE393>3.0.CO;2-8.
- Li, Xiaotong, Zhang, Wenqiang (2017). Research on the Efficiency of Chinese Stock Index Future Market Based on the Test of GARCH Model. *Management & Engineering* 28. 1838-5745
- Li, Y., Luo, L., Liang, C., & Ma, F. (2020). The role of model bias in predicting volatility: evidence from the US equity markets. *China Finance Review International*, ahead-of-print(ahead-of-print). doi:10.1108/cfri-04-2020-0037
- Lin, Wen-Yuan & Tsai, I-Chun. (2018). Black swan events in China's stock markets: Intraday price behaviors on days of volatility. *International Review of Economics & Finance*. 59. 10.1016/j.iref.2018.10.005.
- Lopez, Jose. (2001). Evaluating the Predictive Accuracy of Volatility Models.. *Journal of Forecasting*. 20. 87-109. 10.1002/1099-131X(200103)20:23.0.CO;2-7.

- Malik, F. (2011). Estimating the impact of good news on stock market volatility. *Applied Financial Economics*, 21(8), 545–554. doi:10.1080/09603107.2010.534063
- Mandelbrot, B. B. (1997). The variation of certain speculative prices. In *Fractals and scaling in finance* (pp. 371-418). Springer, New York, NY. 36 394–419
- Mandelbrot, B.B.. (1963a). The Variations of Certain Speculative Prices. *Journal of Business*. 36. 392-417.
- Mandelbrot, Benoit. (1963). New Methods in Statistical Economics. *Journal of Political Economy*. 71. 421-421. 10.1086/258792.
- Mandelbrot, Benoit. (1963b). The Variation of Certain Speculative Prices. *The Journal of Business*. 36. 394-394. 10.1086/294632.
- Marques, Marta (2017) – Aplicação dos modelos Garch, Egarch e Tgarch no DAX-30. Instituto Politécnico de Lisboa. Acesso a 10.10.2020. <https://repositorio.ipl.pt/handle/10400.21/7211>
- Masoliver, Jaume & Montero, Miquel & Porrà, Josep. (2000). Dynamical model describing stock market price distributions. *Physica A: Statistical Mechanics and its Applications*. 283. 559-567. 10.1016/S0378-4371(00)00117-5.
- Matei, Marius & Rovira, & Agell,. (2019). Bivariate Volatility Modeling with High-Frequency Data. *Econometrics*. 7. 41. 10.3390/econometrics7030041.
- Mccauley, Joeph. (2004). Dynamics of Markets: Econophysics and Finance. 10.1017/CBO9780511606588.
- Moreira, João & Lemgruber, Eduardo. (2004). O Uso de Dados de Alta Freqüência na Estimação da Volatilidade e do Valor em Risco para o IBOVESPA. *Revista Brasileira de Economia*. 58. 10.1590/S0034-71402004000100005.
- Narayan, Paresh & Sharma, Susan. (2011). New Evidence on Oil Price and Firm Returns. *Fuel and Energy Abstracts*. 35. 3253-3262. 10.1016/j.jbankfin.2011.05.010.
- Nard, Gianluca & Engle, Robert & Ledoit, Olivier & Wolf, Michael. (2020). Large Dynamic Covariance Matrices: Enhancements Based on Intraday Data. *SSRN Electronic Journal*. 10.2139/ssrn.3662143.
- Nelson, Daniel. (1991). Conditional Heteroskedasticity in Asset Returns: A New Approach. *Econometrica*. 59. 347-70. 10.2307/2938260.
- Pagan, A.R. & Schwert, G.W.. (1990). Alternative models for conditional stock volatility. *Journal of Econometrics*. 3. 87-105.

Rahman, Abdul; Syed, Abdul Malik (2019). Intraday return volatility in Saudi Stock Market: An evidence from Tadawul All Share Index. *Management Science Letters*. 9. 10.5267/j.msl.2019.3.012

Rahman, Shafiqur & Lee, Cheng-few & Ang, Kian. (2002). Intraday return volatility process: Evidence from NASDAQ stocks. *Review of Quantitative Finance and Accounting*. 19. 155-80. 10.1023/A:1020683012149.

Ranković, Vladimir & Drenovak, Mikica & Urosevic, Branko & Jelic, Ranko. (2016). Mean Univariate- GARCH VaR portfolio optimization: Actual portfolio approach. *Computers & Operations Research*. 72. 10.1016/j.cor.2016.01.014.

Sahamkhadam, Maziar & Stephan, Andreas & Östermark, Ralf. (2018). Portfolio optimization based on GARCH-EVT-Copula forecasting models. *International Journal of Forecasting*. 34. 497-506. 10.1016/j.ijforecast.2018.02.004.

Sepúlveda, Ana (2011) – Modelos Heterocedásticos – Arch e Garch. Faculdade de Economia da Universidade do Porto. Acesso a 15.11.2020. <https://repositorio-aberto.up.pt/bitstream/10216/57365/2/TeseMestradoMargaridaSepulveda.pdf>

Shin, Dong. (2018). Forecasting realized volatility: A review. *Journal of the Korean Statistical Society*. 47. 10.1016/j.jkss.2018.08.002.

Silva, Paulo Vitor & Klotzle, Marcelo & Pinto, Antônio & Gomes, Leonardo. (2019). Volatility estimation for cryptocurrencies using Markov-switching GARCH models. *International Journal of Financial Markets and Derivatives*. 7. 1. 10.1504/IJFMD.2019.101234.

Silva, Washington & Safadi, Thelma & Castro, Luiz. (2005). Uma análise empírica da volatilidade do retorno de commodities agrícolas utilizando modelos ARCH: os casos do café e da soja. *Revista De Economia E Sociologia Rural - Rev Econ e Soc Rural*. 43. 10.1590/S0103-20032005000100007.

Taylor, Stephen & Xu, Xinzhong. (1995). The Incremental Volatility Information in One Million Foreign Exchange Quotations. *Journal of Empirical Finance*. 4. 317-340. 10.1016/S0927-5398(97)00010-8.

Tsay, R. S. (2005). *Analysis of financial time series* (Vol. 543). John Wiley & Sons.

Trimmer, Pete. (2016). Optimistic and realistic perspectives on cognitive biases. *Current Opinion in Behavioral Sciences*. 12. 10.1016/j.cobeha.2016.09.004.

Verbeek, Marno. (2014). *A Guide to Modern Econometrics*. Applied Econometrics. 8. 125-132.

Verhoeven, Peter & McAleer, Michael. (2004). Fat tails and asymmetry in financial volatility models. *Mathematics and Computers in Simulation*. 64. 351-361. 10.1016/S0378-4754(03)00101-0.

- Veronesi, P. (1999). Stock Market Overreaction to Bad News in Good Times: A Rational Expectations Equilibrium Model. *The Review of Financial Studies*, 12(5), 975-1007.
- Vo, Long. (2017). Estimating Financial Volatility with High-Frequency Returns. 2. 84-111. 10.20547/jfer1702201.
- Wei, W. (2002). Forecasting stock market volatility with non-linear GARCH models: a case for China. *Applied Economics Letters*, 9(3), 163–166.
- Wei, Y., Bai, L., Yang, K., & Wei, G. (2020). Are industry-level indicators more helpful to forecast industrial stock volatility? Evidence from Chinese manufacturing purchasing managers index. *Journal of Forecasting*. doi:10.1002/for.2696
- West, Kenneth & Cho, Dongchul. (1993). The Predictive Ability of Several Models of Exchange Rate Volatility. *Journal of Econometrics*. 69. 367-391. 10.1016/0304-4076(94)01654-1.
- Yan, Sib0 & Yan, Da. (2019). Volatility Estimation in the Era of High-Frequency Finance. 10.4018/978-1-5225-7805-5.ch006.
- Yavas, Burhan. (2016). Return and volatility spillovers in equity markets: An investigation using various GARCH methodologies. *Cogent Finance and Economics*. 4. 1-18.
- Zakoian, Jean-Michel. (1994). Threshold heteroskedastic models. *Journal of Economic Dynamics and Control*. 18. 931-955. 10.1016/0165-1889(94)90039-6.
- Zhang, Kai & De Mello, Lurion & Sadeghi, Mehdi. (2018). Evaluating Volatility Forecasts with Ultra-High-Frequency Data—Evidence from the Australian Equity Market. *Theoretical Economics Letters*. 08. 1-27. 10.4236/tel.2018.81001.

Anexos

Tabela A 1 – Estatística Descritiva

	R_AAL	R_AAPL	R_ADBE	R_ADI	R_ADP	R_ADSR	R_AKAM	R_ALXN	R_AMAT	R_AMGN	R_AMZN	R_ATVI
Mean	2.6E-06	1.8E-06	5.3E-07	1.7E-06	8.1E-07	2.9E-06	1.6E-06	1.2E-06	1.9E-06	-1.3E-06	1.5E-07	-1.6E-06
Median	0.0E+00	0.0E+00	0.0E+00	0.0E+00	0.0E+00							
Maximum	1.6E-02	3.3E-02	2.5E-02	2.6E-02	7.2E-03	1.7E-02	3.7E-02	3.4E-02	1.9E-02	2.5E-02	9.4E-03	1.5E-02
Minimum	-1.3E-02	-1.6E-02	-1.2E-02	-1.2E-02	-1.5E-02	-1.6E-02	-5.7E-02	-4.6E-02	-1.2E-02	-2.5E-02	-2.0E-02	-2.3E-02
Std. Dev.	4.3E-04	3.0E-04	2.9E-04	3.5E-04	2.4E-04	3.9E-04	4.8E-04	6.7E-04	3.3E-04	3.5E-04	2.9E-04	3.7E-04
Skewness	1.2E-01	2.8E+01	1.5E+01	1.4E+01	-9.6E+00	-1.2E+00	-2.7E+01	5.7E-02	4.2E+00	1.9E+00	-7.6E+00	-6.1E+00
Kurtosis	1.5E+02	3.6E+03	1.4E+03	1.0E+03	8.0E+02	2.5E+02	5.5E+03	8.7E+02	3.4E+02	1.4E+03	6.8E+02	5.1E+02
Jarque-Bera	3.7E+07	2.4E+10	3.6E+09	1.8E+09	1.1E+09	1.1E+08	5.4E+10	1.4E+09	2.1E+08	3.4E+09	8.3E+08	4.6E+08
Probability	0.0E+00	0.0E+00	0.0E+00	0.0E+00	0.0E+00							
Sum	1.1E-01	7.7E-02	2.3E-02	7.4E-02	3.5E-02	1.2E-01	7.0E-02	5.1E-02	8.2E-02	-5.6E-02	6.5E-03	-6.8E-02
Sum Sq. Dev.	7.9E-03	3.8E-03	3.6E-03	5.3E-03	2.4E-03	6.7E-03	9.8E-03	1.9E-02	4.8E-03	5.2E-03	3.5E-03	6.0E-03
Observations	4.3E+04	4.3E+04	4.3E+04	4.3E+04	4.3E+04							
	R_AVGO	R_BBBY	R_BIDU	R_BIIB	R_BMRN	R_CA	R_CELG	R_CERN	R_CHKP	R_CHTR	R_CMCSA	R_COST
Mean	9.8E-07	-8.0E-07	7.0E-07	3.2E-07	-2.8E-07	-5.4E-07	8.5E-07	-2.57E-06	8.84E-07	2.12E-06	2.83E-07	-5.32E-07
Median	0.0E+00	0	0	0	0	0						
Maximum	2.5E-02	6.9E-03	1.4E-02	2.7E-02	3.1E-02	7.4E-03	3.0E-02	0.015025	0.015488	0.028078	0.006185	0.012538
Minimum	-1.3E-02	-1.8E-02	-1.2E-02	-3.4E-02	-1.9E-02	-1.8E-02	-1.0E-02	-0.03116	0.009222	0.014729	0.006548	0.008359
Std. Dev.	3.6E-04	3.7E-04	3.9E-04	5.2E-04	6.2E-04	2.8E-04	4.2E-04	0.000376	0.000289	0.00041	0.000235	0.000228
Skewness	7.8E+00	-3.4E+00	-5.6E-02	3.0E+00	5.4E+00	-6.6E+00	1.5E+01	-15.1237	2.165557	9.779809	0.007775	3.239731
Kurtosis	6.8E+02	1.9E+02	1.4E+02	9.1E+02	3.5E+02	5.2E+02	1.1E+03	1410.12	287.446	707.9331	96.11031	365.2153

Jarque-Bera	8.2E+08	6.3E+07	3.4E+07	1.5E+09	2.2E+08	4.8E+08	2.0E+09	3.56E+09	1.45E+08	8.93E+08	15575896	2.36E+08
Probability	0.0E+00	0.0E+00	0.0E+00	0.0E+00	0.0E+00	0.0E+00	0.0E+00	0	0	0	0	0
Sum	4.2E-02	-3.4E-02	3.0E-02	1.4E-02	-1.2E-02	-2.3E-02	3.7E-02	-0.110646	0.038124	0.091409	0.012209	0.022926
Sum Sq. Dev.	5.5E-03	6.0E-03	6.6E-03	1.2E-02	1.7E-02	3.3E-03	7.7E-03	0.006107	0.003614	0.007255	0.00239	0.002235
Observations	4.3E+04	4.3E+04	4.3E+04	4.3E+04	4.3E+04	4.3E+04	4.3E+04	43119	43119	43119	43119	43119
	R_CSCO	R_CSX	R_CTRP	R_CTSH	R_CTXS	R_DISCA	R_DISCK	R_DISH	R_DLTR	R_EA	R_EBAY	R_ESRX
Mean	-1.85E-07	2.35E-06	-6.16E-07	-4.32E-07	3.22E-07	8.83E-07	5.12E-07	1.51E-06	-2.25E-06	1.94E-07	-3.11E-07	-1.10E-06
Median	0	0	0	0	0	0	0	0	0	0	0	0
Maximum	0.010396	0.010267	0.041306	0.037027	0.017384	0.019374	0.014304	0.010578	0.032372	0.008297	0.016456	0.022121
Minimum	-	-	-	-	-	-	-	-	-	-	-	-
	0.023603	0.004676	-0.01493	0.050167	0.017662	0.014521	0.016964	-0.017033	0.031443	-0.01535	0.042327	0.015772
Std. Dev.	0.000265	0.000285	0.000448	0.000464	0.00032	0.00039	0.000377	0.000389	0.000392	0.000342	0.000383	0.000359
Skewness	-	-	-	-	-	-	-	-	-	-	-	-
	15.95782	2.469852	18.13129	18.11251	0.287841	1.512166	0.720712	-2.282658	0.634355	2.186289	32.22028	3.128417
Kurtosis	1584.286	94.66045	1776.199	4217.665	472.4792	245.3106	201.4084	219.6813	2127.741	159.4508	3701.668	540.5517
Jarque-Bera	4.49E+09	15138433	5.65E+09	3.19E+10	3.96E+08	1.06E+08	70729478	84390429	8.11E+09	44010065	2.46E+10	5.19E+08
Probability	0	0	0	0	0	0	0	0	0	0	0	0
Sum	-	-	-	-	-	-	-	-	-	-	-	-
	0.007972	0.101145	0.026541	0.018613	0.013888	0.038089	0.022083	0.065097	0.097135	0.008379	0.013404	0.047501
Sum Sq. Dev.	0.003036	0.003514	0.008666	0.009299	0.004405	0.006553	0.00614	0.006529	0.00664	0.005041	0.006334	0.005565
Observations	43119	43119	43119	43119	43119	43119	43119	43119	43119	43119	43119	43119
	R_EXPE	R_FAST	R_FB	R_FISV	R_FOX	R_FOXA	R_GILD	R_GOOGLE	R_HSIC	R_ILMN	R_INCY	R_INTC
Mean	-3.35E-07	1.18E-06	-5.86E-07	-1.86E-07	2.30E-07	4.64E-07	-1.65E-06	7.10E-07	-9.60E-07	6.54E-07	3.02E-06	4.30E-07
Median	0	0	0	0	0	0	0	0	0	0	0	0
Maximum	0.00958	0.007575	0.014594	0.007692	0.015409	0.016658	0.015782	0.017631	0.013449	0.057697	0.025049	0.013336

Minimum	-	-	-	-	-	-	-	-	-	-	-	-
	0.023436	-0.00712	0.017847	0.026829	0.016957	0.016783	0.006677	-0.006185	0.022954	0.134816	0.021237	0.020614
Std. Dev.	0.000346	0.000298	0.000289	0.000281	0.000327	0.000337	0.000294	0.000266	0.000366	0.000865	0.000708	0.000268
Skewness	-	-	-	-	-	-	-	-	-	-	-	-
	6.257311	0.543863	4.029049	22.73189	0.920985	0.13081	4.062529	7.72236	5.396171	80.89574	4.17005	8.964822
Kurtosis	547.2952	80.77915	607.188	2087.459	448.578	431.7199	269.4744	510.969	493.601	14175.92	186.2675	1077.545
Jarque-Bera	5.33E+08	10870981	6.56E+08	7.81E+09	3.57E+08	3.30E+08	1.28E+08	4.64E+08	4.33E+08	3.61E+11	60468199	2.08E+09
Probability	0	0	0	0	0	0	0	0	0	0	0	0
Sum	-	-	-	-	-	-	-	-	-	-	-	-
	0.014438	0.050796	-0.02526	0.008013	0.009914	0.019987	0.070946	0.030635	0.041388	0.028219	0.130414	0.018522
Sum Sq. Dev.	0.005171	0.003819	0.003599	0.003416	0.00462	0.004901	0.003724	0.003053	0.005761	0.032235	0.021593	0.003088
Observations	43119	43119	43119	43119	43119	43119	43119	43119	43119	43119	43119	43119
	R_INTU	R_ISRG	R_JD	R_KHC	R_LBTYA	R_LBTYK	R_LLTC	R_LRCX	R_LVNTA	R_MAR	R_MAT	R_MCHP
Mean	1.74E-07	9.89E-07	1.53E-06	-2.00E-07	3.19E-07	2.29E-07	2.46E-06	1.62E-06	1.60E-06	1.56E-06	-1.54E-06	1.54E-06
Median	0	0	0	0	0	0	0	0	0	0	0	0
Maximum	0.009022	0.008893	0.034156	0.021349	0.019054	0.046756	0.064558	0.012163	0.016823	0.007152	0.027745	0.022928
Minimum	-	-	-	-	-	-	-	-	-	-	-	-
	0.021546	0.014299	-0.0137	0.019305	-0.04189	0.049196	0.013195	-0.011188	0.018867	0.009622	0.018569	0.012048
Std. Dev.	0.00029	0.00035	0.000508	0.00028	0.000492	0.000564	0.000393	0.000355	0.000442	0.000282	0.00037	0.000353
Skewness	-	-	-	-	-	-	-	-	-	-	-	-
	17.66842	1.656165	13.66424	1.888596	15.29121	7.988172	111.587	1.089942	0.904475	0.087053	7.713024	9.564405
Kurtosis	1440.857	108.3778	975.4443	1377.215	1462.622	2840.242	17704.21	143.803	230.5592	108.6694	967.331	677.5622
Jarque-Bera	3.72E+09	19970308	1.70E+09	3.39E+09	3.83E+09	1.45E+10	5.63E+11	35627505	93040864	20061223	1.67E+09	8.18E+08
Probability	0	0	0	0	0	0	0	0	0	0	0	0
Sum	-	-	-	-	-	-	-	-	-	-	-	-
	0.007507	0.042637	0.066035	-0.00862	0.013745	0.009878	0.106102	0.07001	0.068868	0.067137	0.066439	0.066397
Sum Sq. Dev.	0.003637	0.005286	0.011148	0.003387	0.010428	0.013704	0.006648	0.005433	0.008406	0.003441	0.005895	0.005367
Observations	43119	43119	43119	43119	43119	43119	43119	43119	43119	43119	43119	43119

	R_MDLZ	R_MNST	R_MSFT	R_MU	R_MXIM	R_MYL	R_NCLH	R_NDX	R_NFLX	R_NTAP	R_NTES	R_NVDA
Mean	-3.11E-07	-1.29E-05	9.69E-07	4.50E-06	-1.40E-07	-2.16E-06	5.84E-07	4.78E-07	3.12E-06	2.90E-06	1.72E-06	6.48E-06
Median	0	0	0	0	0	0	0	-8.98E-08	0	0	0	0
Maximum	0.021464	0.016991	0.022398	0.046864	0.013774	0.051233	0.01755	0.007156	0.068089	0.044417	0.016729	0.069712
Minimum	-	-	-	-	-	-	-	-	-	-	-	-
	0.014588	-0.47499	0.005096	0.011629	0.010631	0.009722	-0.02992	-0.003706	-0.00875	-0.01318	0.020803	0.018765
Std. Dev.	0.000306	0.002321	0.000247	0.000565	0.000305	0.000548	0.000501	0.000149	0.000499	0.000456	0.000574	0.000571
Skewness	7.765793	198.7509	17.73887	14.47444	0.661372	23.40989	7.042491	3.818886	58.88779	28.62502	-0.40408	42.20274
Kurtosis	799.0085	40661.33	1632.853	1140.212	201.8159	2028.565	572.6793	221.2083	8061.107	2696.676	133.5629	5209.981
Jarque-Bera	1.14E+09	2.97E+12	4.77E+09	2.32E+09	71019733	7.38E+09	5.83E+08	85650849	1.17E+11	1.30E+10	30627638	4.87E+10
Probability	0	0	0	0	0	0	0	0	0	0	0	0
Sum	-	-	-	-	-	-	-	-	-	-	-	-
	0.013417	0.556493	0.041766	0.194019	0.006024	0.093057	0.025169	0.020626	0.134485	0.125021	0.074277	0.279294
Sum Sq. Dev.	0.004025	0.232324	0.002624	0.013764	0.004023	0.012961	0.010802	0.000957	0.010731	0.008971	0.014192	0.014076
Observations	43119	43119	43119	43119	43119	43119	43119	43119	43119	43119	43119	43119
	R_NXPI	R_ORLY	R_PAYX	R_PCAR	R_PCLN	R_PYPL	R_QCOM	R_QVCA	R_REGN	R_ROST	R_SBAC	R_SBUX
Mean	1.40E-06	-4.29E-07	8.91E-08	1.61E-06	2.17E-06	4.59E-07	6.72E-07	-2.80E-06	-1.24E-06	7.45E-07	-5.70E-07	-5.13E-07
Median	0	0	0	0	0	0	0	0	0	0	0	0
Maximum	0.04878	0.009604	0.007861	0.01399	0.023316	0.018867	0.016188	0.008824	0.021531	0.013571	0.009434	0.007508
Minimum	-	-	-	-	-	-	-	-	-	-	-	-
	0.014853	0.016211	0.010685	0.012118	0.003974	0.010251	0.011343	-0.022145	0.022846	0.009218	0.012044	0.014414
Std. Dev.	0.000429	0.000317	0.000234	0.000328	0.000335	0.000317	0.000322	0.000459	0.00056	0.000296	0.000362	0.000242
Skewness	39.96701	3.632556	2.872701	1.244079	11.10226	4.38915	4.023169	-5.74593	0.002446	3.152591	0.074485	6.775398
Kurtosis	4236.969	366.6421	260.9945	205.0327	717.266	357.5117	270.9568	264.1498	186.8786	193.642	131.29	514.6868
Jarque-Bera	3.22E+10	2.38E+08	1.20E+08	73344323	9.17E+08	2.26E+08	1.29E+08	1.23E+08	60746325	65368650	29569485	4.71E+08

Probability	0	0	0	0	0	0	0	0	0	0	0	0
Sum	0.060279	-	0.003844	0.069249	0.093477	0.01978	0.028957	-0.120736	0.053563	0.032103	0.024582	-
Sum Sq. Dev.	0.007925	0.004345	0.002368	0.004636	0.004831	0.004329	0.004472	0.009092	0.013501	0.003785	0.005665	0.002518
Observations	43119	43119	43119	43119	43119	43119	43119	43119	43119	43119	43119	43119
	R_SIRI	R_SRCL	R_STX	R_SWKS	R_SYMC	R_TMUS	R_TRIP	R_TSCO	R_TSLA	R_TXN	R_ULTA	R_VIAB
Mean	3.92E-07	-3.03E-06	1.95E-06	1.42E-06	1.62E-06	2.63E-06	-3.68E-06	-1.91E-06	-4.42E-07	3.00E-07	2.36E-07	-2.36E-06
Median	0	0	0	0	0	0	0	0	0	0	0	0
Maximum	0.004617	0.021039	0.013093	0.014459	0.022925	0.014615	0.010487	0.006539	0.018683	0.00917	0.023256	0.022329
Minimum	-	-	-	-	-	-	-	-	-	-	-	-
	0.013428	0.040487	0.014337	0.013287	0.041512	0.010717	0.070865	-0.070523	0.018268	-0.0123	0.011329	0.023925
Std. Dev.	0.00047	0.000448	0.000487	0.000423	0.00041	0.000361	0.000552	0.000464	0.000444	0.000245	0.000375	0.00045
Skewness	-	-	-	-	-	-	-	-	-	-	-	-
	0.636678	20.41692	0.623924	0.229216	20.26404	3.969588	55.93899	-81.93256	0.881482	0.952461	5.086785	0.486623
Kurtosis	22.26143	2246.52	83.36245	130.972	3082.484	199.188	6763.631	12360.87	196.466	254.1486	441.0995	414.0148
Jarque-Bera	669465.6	9.05E+09	11605625	29423399	1.70E+10	69264875	8.21E+10	2.74E+11	67251637	1.13E+08	3.45E+08	3.04E+08
Probability	0	0	0	0	0	0	0	0	0	0	0	0
Sum	0.016916	-	0.083946	0.06131	0.069679	0.113274	0.158593	-0.082414	-0.01907	0.012945	0.010185	-
	0.016916	0.130741	0.083946	0.06131	0.069679	0.113274	0.158593	-0.082414	-0.01907	0.012945	0.010185	0.101908
Sum Sq. Dev.	0.00952	0.00864	0.010211	0.007697	0.007241	0.005606	0.013155	0.009302	0.008484	0.002578	0.006051	0.008728
Observations	43119	43119	43119	43119	43119	43119	43119	43119	43119	43119	43119	43119
	R_VOD	R_VRSK	R_VRTX	R_WBA	R_WDC	R_WFM	R_XLNX	R_XRAY	R_YHOO			
Mean	-2.46E-06	-3.71E-07	-1.91E-06	1.43E-07	2.62E-06	-1.01E-06	1.88E-06	-6.70E-07	1.67E-07			
Median	0	0	0	0	0	0	0	0	0			
Maximum	0.007892	0.010901	0.029974	0.00858	0.025684	0.021485	0.012154	0.034294	0.011908			
Minimum	-	-	-	-	-	-	-	-	-			
	0.009299	0.011757	0.009941	0.017629	0.025138	0.023747	0.012182	-0.03444	0.010204			

Std. Dev.	0.000259	0.000254	0.000571	0.00027	0.000537	0.000396	0.000299	0.000384	0.000307			
Skewness	- 3.580137	- 2.917775	3.931908	- 6.478309	2.873245	- 2.708464	- 0.395781	-0.440621	- 0.800237			
Kurtosis	305.9264	363.0635	233.3027	543.3551	350.0816	714.5089	228.1053	3022.434	183.8907			
Jarque-Bera	1.65E+08	2.33E+08	95402861	5.25E+08	2.16E+08	9.10E+08	91040439	1.64E+10	58792754			
Probability	0	0	0	0	0	0	0	0	0			
Sum	-0.10617	- 0.015998	-0.08232	0.006148	0.112802	-0.04356	0.081024	-0.028882	0.007195			
Sum Sq. Dev.	0.002892	0.002775	0.01405	0.003143	0.012448	0.006771	0.003858	0.006372	0.004066			
Observations	43119	43119	43119	43119	43119	43119	43119	43119	43119			

Tabela A 2 – Aplicação do Modelo GARCH

	AAL			AAPL			ADBE			ADI		
	Coefficient	Robust standard error	p-value									
Constant	2.24E-06	1.06E-06	0.03550	1.78E-05	2.34E-07	0.00000	6.14E-06	3.35E-07	0.00000	-3.05E-07	1.86E-07	0.09980
R(-1)	-0.03913	0.003395	0.00000	-0.06167	0.000554	0.00000	-0.01434	0.003479	0.00000	-0.07658	0.001729	0.00000
ω	2.85E-08	2.15E-10	0.00000	6.15E-09	3.65E-11	0.00000	3.64E-09	2.61E-11	0.00000	8.41E-09	2.44E-11	0.00000
α	0.224958	0.001774	0.00000	1.20176	0.001409	0.00000	0.40355	0.000513	0.00000	0.420774	0.001139	0.00000
β	0.6588	0.002492	0.00000	0.421264	0.000827	0.00000	0.692044	0.00076	0.00000	0.639636	0.000745	0.00000
	ADP			ADSR			AKAM			ALXN		
	Coefficient	Robust standard error	p-value									
Constant	1.25E-05	3.24E-07	0.00000	1.50E-05	5.21E-07	0.00000	1.31E-05	5.02E-06	0.00920	-2.68E-05	2.05E-07	0.00000
R(-1)	-0.07002	0.001849	0.00000	-0.01983	0.001257	0.00000	0.001431	0.013484	0.91550	0.091063	0.001349	0.00000
ω	1.51E-09	7.96E-12	0.00000	7.50E-09	5.42E-11	0.00000	1.19E-07	1.34E-09	0.00000	8.58E-08	4.00E-10	0.00000
α	0.222267	0.001087	0.00000	0.202917	0.000609	0.00000	0.147193	0.006655	0.00000	1.409956	0.003298	0.00000
β	0.857672	0.000528	0.00000	0.808009	0.000767	0.00000	0.601309	0.004323	0.00000	0.221161	0.001005	0.00000
	AMAT			AMGN			AMZN			ATVI		
	Coefficient	Robust standard error	p-value									
Constant	-4.37E-06	2.69E-07	0.00000	7.73E-06	2.34E-07	0.00000	-2.37E-07	3.63E-07	0.51450	1.87E-06	5.04E-07	0.00020
R(-1)	-0.11414	0.0026	0.00000	-0.1468	0.001408	0.00000	-0.05749	0.002284	0.00000	-0.06773	0.002462	0.00000
ω	5.27E-09	4.64E-11	0.00000	8.11E-10	1.29E-11	0.00000	2.28E-09	1.19E-11	0.00000	6.72E-09	3.14E-11	0.00000
α	0.278205	0.001062	0.00000	0.389698	0.00127	0.00000	0.195965	0.000503	0.00000	0.359048	0.000807	0.00000
β	0.767735	0.000621	0.00000	0.797009	0.000475	0.00000	0.843129	0.00044	0.00000	0.710009	0.000672	0.00000

	AVGO			BBBY			BIDU			BIIB		
	Coefficient	Robust standard error	p-value									
Constant	-8.18E-07	4.08E-07	0.04490	-1.23E-06	5.98E-07	0.03990	3.59E-06	7.33E-07	0.00000	3.55E-05	5.38E-07	0.00000
R(-1)	0.019804	0.00217	0.00000	-0.03678	0.002358	0.00000	-0.07472	0.002006	0.00000	0.051461	0.000924	0.00000
ω	4.12E-09	2.31E-11	0.00000	7.18E-09	7.97E-11	0.00000	1.04E-08	6.55E-11	0.00000	5.71E-08	1.88E-10	0.00000
α	0.313659	0.001377	0.00000	0.272706	0.001297	0.00000	0.22178	0.000841	0.00000	1.101111	0.002068	0.00000
β	0.782871	0.000677	0.00000	0.743897	0.001721	0.00000	0.771584	0.00096	0.00000	0.288402	0.001192	0.00000
	BMRN			CA			CELG			CERN		
	Coefficient	Robust standard error	p-value									
Constant	5.89E-06	5.53E-07	0.00000	-1.30E-06	4.42E-07	0.00330	1.85E-05	1.11E-06	0.00000	8.82E-06	3.10E-07	0.00000
R(-1)	-0.05401	0.00284	0.00000	-0.05519	0.003695	0.00000	-0.11676	0.002373	0.00000	0.029788	0.001148	0.00000
ω	5.40E-08	3.45E-10	0.00000	5.45E-09	2.15E-11	0.00000	2.61E-09	3.59E-11	0.00000	2.41E-09	1.08E-11	0.00000
α	0.438707	0.001363	0.00000	0.202065	0.0011	0.00000	0.17657	0.001245	0.00000	0.284827	0.000976	0.00000
β	0.527222	0.002471	0.00000	0.755864	0.000907	0.00000	0.877723	0.000879	0.00000	0.833478	0.000504	0.00000
	CHKP			CHTR			CMCSA			COST		
	Coefficient	Robust standard error	p-value									
Constant	-2.82E-06	3.39E-07	0.00000	-3.61E-06	5.70E-07	0.00000	-2.64E-07	3.88E-07	0.49710	-3.30E-06	2.25E-07	0.00000
R(-1)	-0.05213	0.001802	0.00000	-0.01704	0.002486	0.00000	-0.06459	0.002994	0.00000	-0.06998	0.002254	0.00000
ω	9.11E-09	6.49E-11	0.00000	1.22E-08	1.05E-10	0.00000	6.56E-09	3.94E-11	0.00000	3.54E-09	2.38E-11	0.00000
α	0.451439	0.00157	0.00000	0.32219	0.001872	0.00000	0.275249	0.001412	0.00000	0.387874	0.000971	0.00000
β	0.612737	0.001844	0.00000	0.661196	0.002138	0.00000	0.649963	0.001879	0.00000	0.664369	0.001178	0.00000
	CSCO			CSX			CTRP			CTSH		

	Coefficient	Robust standard error	p-value	Coefficient	Robust standard error	p-value	Coefficient	Robust standard error	p-value	Coefficient	Robust standard error	p-value
Constant	6.29E-07	3.02E-07	0.03750	-8.27E-07	4.78E-07	0.08350	9.50E-07	4.30E-07	0.02740	2.18E-05	1.01E-07	0.00000
R(-1)	-0.12606	0.001052	0.00000	-0.07794	0.003729	0.00000	-0.1145	0.000986	0.00000	-0.10294	0.001715	0.00000
ω	2.99E-09	2.05E-11	0.00000	6.30E-09	3.36E-11	0.00000	2.03E-09	1.27E-11	0.00000	3.09E-08	9.27E-11	0.00000
α	0.421147	0.00164	0.00000	0.190422	0.001252	0.00000	0.242049	0.000864	0.00000	3.518342	0.002928	0.00000
β	0.703072	0.001228	0.00000	0.762069	0.000853	0.00000	0.847546	0.000397	0.00000	0.063385	0.0006	0.00000
	CTXS			DISCA			DISCK			DISH		
	Coefficient	Robust standard error	p-value	Coefficient	Robust standard error	p-value	Coefficient	Robust standard error	p-value	Coefficient	Robust standard error	p-value
Constant	3.44E-06	4.67E-07	0.00000	2.99E-06	6.83E-07	0.00000	8.06E-06	5.43E-07	0.00000	1.71E-05	7.14E-07	0.00000
R(-1)	-0.06077	0.003031	0.00000	-0.03836	0.002372	0.00000	-0.04741	0.002944	0.00000	-0.08858	0.004088	0.00000
ω	4.99E-09	1.95E-11	0.00000	6.31E-09	5.44E-11	0.00000	1.43E-08	1.03E-10	0.00000	1.13E-08	6.03E-11	0.00000
α	0.231639	0.000705	0.00000	0.192372	0.000862	0.00000	0.299762	0.000983	0.00000	0.257744	0.000809	0.00000
β	0.785206	0.000579	0.00000	0.818436	0.000869	0.00000	0.669964	0.001662	0.00000	0.727617	0.000989	0.00000
	DLTR			EA			EBAY			ESRX		
	Coefficient	Robust standard error	p-value	Coefficient	Robust standard error	p-value	Coefficient	Robust standard error	p-value	Coefficient	Robust standard error	p-value
Constant	7.29E-06	2.94E-07	0.00000	6.09E-06	6.22E-07	0.00000	2.68E-06	3.33E-07	0.00000	2.05E-06	6.56E-07	0.00180
R(-1)	-0.01441	0.001456	0.00000	-0.06062	0.003616	0.00000	-0.05924	0.003722	0.00000	-0.06446	0.002724	0.00000
ω	6.49E-09	3.84E-11	0.00000	9.00E-09	4.97E-11	0.00000	2.44E-09	1.38E-11	0.00000	2.34E-08	4.56E-11	0.00000
α	0.658765	0.001913	0.00000	0.237318	0.001513	0.00000	0.344589	0.000689	0.00000	0.150294	0.000563	0.00000
β	0.648784	0.001016	0.00000	0.732309	0.001356	0.00000	0.807339	0.000238	0.00000	0.600187	0.000695	0.00000
	EXPE			FAST			FB			FISV		

	Coefficient	Robust standard error	p-value	Coefficient	Robust standard error	p-value	Coefficient	Robust standard error	p-value	Coefficient	Robust standard error	p-value
Constant	6.61E-06	7.10E-07	0.00000	3.09E-06	3.77E-07	0.00000	1.32E-06	3.33E-07	0.00010	1.25E-05	3.14E-07	0.00000
R(-1)	-0.07278	0.004322	0.00000	-0.06323	0.002986	0.00000	0.026587	0.001892	0.00000	-0.1655	0.001903	0.00000
ω	8.03E-09	5.33E-11	0.00000	5.05E-09	4.48E-11	0.00000	1.92E-09	4.97E-12	0.00000	8.87E-10	5.99E-12	0.00000
α	0.222061	0.001025	0.00000	0.218903	0.00085	0.00000	0.207664	0.000585	0.00000	0.260486	0.001031	0.00000
β	0.758027	0.000994	0.00000	0.774303	0.001066	0.00000	0.84447	0.000408	0.00000	0.878221	0.000386	0.00000
	FOX			FOXA			GILD			GOOGLE		
	Coefficient	Robust standard error	p-value	Coefficient	Robust standard error	p-value	Coefficient	Robust standard error	p-value	Coefficient	Robust standard error	p-value
Constant	-7.05E-07	2.38E-07	0.00300	-1.03E-06	3.92E-07	0.00860	-5.52E-07	3.24E-07	0.08820	-4.58E-07	4.43E-07	0.30090
R(-1)	-0.11287	0.002459	0.00000	-0.05143	0.00184	0.00000	0.00512	0.001582	0.00120	-0.07518	0.001727	0.00000
ω	2.25E-09	2.69E-11	0.00000	2.52E-09	2.19E-11	0.00000	7.05E-09	5.37E-11	0.00000	2.19E-09	2.24E-11	0.00000
α	0.261066	0.001038	0.00000	0.199679	0.000966	0.00000	0.382887	0.001136	0.00000	0.312319	0.001117	0.00000
β	0.80338	0.000827	0.00000	0.83063	0.000773	0.00000	0.639512	0.001778	0.00000	0.755682	0.001013	0.00000
	HSIC			ILMN			INCY			INTC		
	Coefficient	Robust standard error	p-value	Coefficient	Robust standard error	p-value	Coefficient	Robust standard error	p-value	Coefficient	Robust standard error	p-value
Constant	-1.73E-05	2.99E-07	0.00000	3.02E-05	8.30E-06	0.00030	8.21E-06	1.46E-06	0.00000	6.59E-06	3.69E-07	0.00000
R(-1)	-0.05718	0.002474	0.00000	-0.00934	0.011772	0.42750	-0.07279	0.0054	0.00000	-0.07201	0.002609	0.00000
ω	2.13E-08	8.51E-11	0.00000	5.00E-07	3.17E-08	0.00000	4.55E-08	4.25E-10	0.00000	5.75E-09	5.97E-11	0.00000
α	0.788364	0.004062	0.00000	0.02176	0.001666	0.00000	0.125316	0.000852	0.00000	0.618443	0.001498	0.00000
β	0.380345	0.002065	0.00000	0.5597	0.027562	0.00000	0.780305	0.001865	0.00000	0.540224	0.001606	0.00000
	INTU			ISRG			JD			KHC		

	Coefficient	Robust standard error	p-value	Coefficient	Robust standard error	p-value	Coefficient	Robust standard error	p-value	Coefficient	Robust standard error	p-value
Constant	6.82E-06	1.86E-07	0.00000	5.82E-06	1.05E-06	0.00000	-3.10E-06	5.34E-07	0.00000	4.82E-06	3.28E-07	0.0000
R(-1)	0.035765	0.00155	0.00000	-0.1581	0.00327	0.00000	-0.05958	0.001534	0.00000	0.069129	0.002215	0.0000
ω	1.17E-08	4.47E-11	0.00000	1.33E-08	1.66E-10	0.00000	5.77E-09	3.23E-11	0.00000	5.33E-09	4.65E-11	0.0000
α	0.769198	0.001312	0.00000	0.178476	0.001209	0.00000	0.250849	0.000846	0.00000	0.783634	0.003297	0.0000
β	0.415348	0.001392	0.00000	0.732997	0.002395	0.00000	0.831453	0.00059	0.00000	0.532753	0.00137	0.0000
	LBTYA			LBTYK			LLTC			LRCX		
	Coefficient	Robust standard error	p-value	Coefficient	Robust standard error	p-value	Coefficient	Robust standard error	p-value	Coefficient	Robust standard error	p-value
Constant	2.68E-05	5.59E-07	0.0000	-2.85E-05	1.39E-06	0.0000	-3.13E-05	2.24E-06	0.00000	1.27E-05	7.32E-07	0.00000
R(-1)	0.116561	0.00269	0.0000	-0.06237	0.011269	0.0000	0.203936	0.012239	0.00000	-0.05818	0.002658	0.00000
ω	8.44E-08	5.54E-10	0.0000	1.54E-07	2.82E-09	0.0000	2.52E-08	7.68E-10	0.00000	1.99E-08	1.26E-10	0.00000
α	0.740285	0.005971	0.0000	0.339694	0.004553	0.0000	0.153308	0.004653	0.00000	0.412047	0.001768	0.00000
β	0.26995	0.003005	0.0000	0.451318	0.008596	0.0000	0.601113	0.011304	0.00000	0.545541	0.001995	0.00000
	LVNTA			MAR			MAT			MCHP		
	Coefficient	Robust standard error	p-value	Coefficient	Robust standard error	p-value	Coefficient	Robust standard error	p-value	Coefficient	Robust standard error	p-value
Constant	9.10E-08	7.27E-07	0.90050	1.62E-06	4.39E-07	0.00020	8.33E-06	3.17E-07	0.00000	1.19E-05	4.63E-07	0.00000
R(-1)	-0.04319	0.002727	0.00000	-0.01033	0.003146	0.00100	-0.10259	0.003458	0.00000	-0.01787	0.002506	0.00000
ω	1.89E-08	4.80E-11	0.00000	3.95E-09	2.55E-11	0.00000	2.41E-08	1.38E-10	0.00000	1.64E-08	1.42E-10	0.00000
α	0.32291	0.000758	0.00000	0.180921	0.000657	0.00000	0.59207	0.001857	0.00000	0.417436	0.001935	0.00000
β	0.670697	0.000665	0.00000	0.807177	0.000755	0.00000	0.445885	0.002006	0.00000	0.601386	0.002776	0.00000
	MDLZ			MNST			MSFT			MU		

	Coefficient	Robust standard error	p-value									
Constant	1.59E-06	3.96E-07	0.00010	-1.40E-05	0.0001	0.88930	2.88E-06	5.18E-07	0.00000	-1.92E-05	1.83E-06	0.00000
R(-1)	-0.08654	0.001893	0.00000	-0.00359	0.130485	0.97800	-0.02149	0.003044	0.00000	-0.06548	0.004648	0.00000
ω	4.14E-09	1.18E-11	0.00000	3.36E-06	4.05E-07	0.00000	2.37E-09	2.63E-11	0.00000	2.32E-08	2.54E-10	0.00000
α	0.304446	0.001007	0.00000	0.149726	0.07259	0.03910	0.404323	0.001564	0.00000	0.109231	0.001572	0.00000
β	0.750096	0.000665	0.00000	0.599688	0.048508	0.00000	0.683222	0.001277	0.00000	0.852754	0.001621	0.00000
	MXIM			MYL			NCLH			NDX		
	Coefficient	Robust standard error	p-value									
Constant	2.93E-06	4.64E-07	0.00000	1.51E-05	5.25E-07	0.00000	2.72E-05	1.95E-07	0.00000	3.15E-06	1.73E-07	0.00000
R(-1)	-0.0543	0.003399	0.00000	-0.02717	0.002524	0.00000	-0.08214	0.002037	0.00000	0.086108	0.003551	0.00000
ω	5.68E-09	2.51E-11	0.00000	8.25E-09	4.59E-11	0.00000	5.96E-08	2.85E-10	0.00000	2.14E-09	7.66E-12	0.00000
α	0.252444	0.000771	0.00000	0.622992	0.001116	0.00000	1.020518	0.001249	0.00000	0.43193	0.001084	0.00000
β	0.754697	0.000553	0.00000	0.684272	0.000189	0.00000	0.257184	0.002079	0.00000	0.643733	0.000883	0.00000
	NFLX			NTAP			NTES			NVDA		
	Coefficient	Robust standard error	p-value									
Constant	-2.91E-05	4.87E-06	0.00000	2.82E-05	2.86E-07	0.00000	4.51E-06	1.26E-06	0.00030	-2.58E-06	4.89E-06	0.59720
R(-1)	0.011567	0.012571	0.35750	0.107435	0.002582	0.00000	-0.04451	0.00302	0.00000	0.021132	0.008543	0.01340
ω	1.20E-07	3.95E-09	0.00000	4.15E-08	1.23E-10	0.00000	2.38E-08	1.35E-10	0.00000	1.78E-07	7.99E-09	0.00000
α	0.157715	0.005372	0.00000	0.675118	0.003892	0.00000	0.179206	0.001125	0.00000	0.058702	0.003095	0.00000
β	0.599752	0.013254	0.00000	0.447334	0.001047	0.00000	0.774002	0.00112	0.00000	0.593636	0.018222	0.00000
	NXPI			ORLY			PAYX			PCAR		

	Coefficient	Robust standard error	p-value									
Constant	-3.65E-05	1.24E-07	0.00000	7.97E-06	3.97E-07	0.00000	3.80E-06	2.17E-07	0.00000	5.23E-06	3.24E-07	0.00000
R(-1)	-0.04341	0.003883	0.00000	-0.1183	0.002972	0.00000	-0.03231	0.002419	0.00000	-0.0671	0.003219	0.00000
ω	-5.89E-10	1.36E-12	0.00000	1.15E-08	1.32E-10	0.00000	4.18E-09	1.38E-11	0.00000	8.51E-09	2.83E-11	0.00000
α	0.280005	0.000288	0.00000	0.331472	0.002216	0.00000	0.396023	0.001339	0.00000	0.303153	0.001341	0.00000
β	0.935261	8.20E-05	0.00000	0.640963	0.0033	0.00000	0.665124	0.00084	0.00000	0.705179	0.000728	0.00000
	PCLN			PYPL			QCOM			QVCA		
	Coefficient	Robust standard error	p-value									
Constant	3.13E-06	1.10E-06	0.00430	-4.43E-06	4.35E-07	0.00000	5.16E-06	3.59E-07	0.00000	-6.65E-06	6.59E-07	0.00000
R(-1)	-0.14903	0.004671	0.00000	-0.00444	0.002583	0.08560	-0.03422	0.003352	0.00000	-0.01137	0.003375	0.00080
ω	9.55E-09	1.64E-10	0.00000	5.59E-09	6.69E-11	0.00000	1.34E-09	1.15E-11	0.00000	5.37E-09	7.07E-11	0.00000
α	0.193824	0.001111	0.00000	0.298879	0.002138	0.00000	0.22093	0.000645	0.00000	0.213123	0.001229	0.00000
β	0.753355	0.002392	0.00000	0.736061	0.002176	0.00000	0.846966	0.000279	0.00000	0.809728	0.001189	0.00000
	REGN			ROST			SBAC			SBUX		
	Coefficient	Robust standard error	p-value									
Constant	1.23E-05	1.04E-06	0.00000	-6.52E-06	4.62E-07	0.00000	1.02E-06	3.64E-07	0.00520	-3.76E-07	1.46E-07	0.00990
R(-1)	-0.12088	0.004625	0.00000	-0.05173	0.001879	0.00000	-0.04507	0.00189	0.00000	-0.11067	0.001672	0.00000
ω	2.80E-08	2.25E-10	0.00000	8.56E-09	5.79E-11	0.00000	2.40E-08	1.63E-10	0.00000	1.73E-09	1.69E-11	0.00000
α	0.198521	0.00111	0.00000	0.323193	0.001548	0.00000	0.381619	0.0018	0.00000	0.242632	0.001418	0.00000
β	0.74977	0.001596	0.00000	0.647332	0.001922	0.00000	0.507755	0.002808	0.00000	0.80998	0.001137	0.00000
	SIRI			SRCL			STX			SWKS		

	Coefficient	Robust standard error	p-value									
Constant	1.52E-07	1.85E-06	0.93470	1.01E-06	4.34E-07	0.01940	4.11E-06	1.02E-06	0.00010	6.57E-06	1.02E-06	0.00000
R(-1)	-0.3957	0.004648	0.00000	0.053939	0.002802	0.00000	0.020039	0.004286	0.00000	-0.02402	0.004005	0.00000
ω	1.16E-08	3.92E-10	0.00000	2.10E-08	8.79E-11	0.00000	1.14E-08	1.13E-10	0.00000	6.37E-09	2.42E-11	0.00000
α	0.080248	0.001983	0.00000	1.071675	0.002613	0.00000	0.12903	0.001	0.00000	0.107531	0.000442	0.00000
β	0.859988	0.003433	0.00000	0.321191	0.001481	0.00000	0.831538	0.001281	0.00000	0.878092	0.00031	0.00000
	SYMC			TMUS			TRIP			TSCO		
	Coefficient	Robust standard error	p-value									
Constant	-1.68E-06	2.32E-07	0.00000	6.84E-06	6.00E-07	0.00000	2.97E-06	2.82E-07	0.00000	-1.31E-05	5.72E-06	0.02200
R(-1)	-0.22029	0.003777	0.00000	-0.02948	0.00372	0.00000	0.02979	0.002014	0.00000	-0.0468	0.015299	0.00220
ω	5.22E-10	2.84E-11	0.00000	3.42E-09	2.21E-11	0.00000	8.33E-09	4.48E-11	0.00000	1.22E-07	3.83E-09	0.00000
α	0.396686	0.001079	0.00000	0.136267	0.000404	0.00000	0.739923	0.001481	0.00000	0.147526	0.007936	0.00000
β	0.826367	0.000487	0.00000	0.870096	0.000251	0.00000	0.598351	0.000509	0.00000	0.598792	0.012644	0.00000
	TSLA			TXN			ULTA			VIAB		
	Coefficient	Robust standard error	p-value									
Constant	5.06E-07	1.32E-06	0.70060	4.20E-06	6.17E-07	0.00000	1.59E-06	8.44E-07	0.05950	-1.57E-05	1.98E-07	0.00000
R(-1)	-0.04098	0.004826	0.00000	0.031383	0.002019	0.00000	-0.16067	0.003208	0.00000	-0.06267	0.001499	0.00000
ω	1.68E-08	1.62E-10	0.00000	4.86E-09	2.81E-11	0.00000	1.36E-08	1.48E-10	0.00000	2.63E-08	1.27E-10	0.00000
α	0.118174	0.00099	0.00000	0.35488	0.001275	0.00000	0.253593	0.001617	0.00000	0.662355	0.000962	0.00000
β	0.811752	0.001424	0.00000	0.669168	0.001212	0.00000	0.712343	0.002316	0.00000	0.485152	0.001352	0.00000
	VOD			VRSK			VRTX			WBA		

	Coefficient	Robust standard error	p-value									
Constant	2.80E-06	2.37E-07	0.00000	4.71E-06	4.21E-07	0.00000	1.72E-05	8.93E-07	0.00000	-7.15E-06	3.65E-07	0.00000
R(-1)	-0.04743	0.001734	0.00000	-0.07749	0.00392	0.00000	-0.12547	0.00394	0.00000	-0.00743	0.002119	0.00050
ω	3.52E-08	6.38E-11	0.00000	7.11E-09	4.03E-11	0.00000	1.30E-08	7.57E-11	0.00000	1.61E-08	5.95E-11	0.00000
α	0.815242	0.001628	0.00000	0.378769	0.001701	0.00000	0.202218	0.001394	0.00000	0.472707	0.001931	0.00000
β	0.099688	0.001382	0.00000	0.6184	0.001733	0.00000	0.80331	0.000706	0.00000	0.469793	0.002011	0.00000
	WDC			WFM			XLNX			XRAY		
	Coefficient	Robust standard error	p-value									
Constant	-6.29E-06	7.21E-07	0.00000	-1.71E-05	6.18E-07	0.00000	8.66E-06	2.78E-07	0.00000	6.63E-06	2.50E-07	0.00000
R(-1)	0.025339	0.002381	0.00000	-0.12631	0.004789	0.00000	-0.06956	0.002157	0.00000	0.082327	0.001717	0.00000
ω	6.10E-08	3.12E-10	0.00000	4.00E-09	2.06E-11	0.00000	2.38E-09	1.46E-11	0.00000	2.80E-09	1.64E-11	0.00000
α	0.349001	0.001341	0.00000	0.20346	0.000633	0.00000	0.241584	0.001191	0.00000	0.439579	0.001083	0.00000
β	0.545564	0.001992	0.00000	0.85076	0.000241	0.00000	0.821453	0.000682	0.00000	0.767231	0.000343	0.00000
	YHOO											
	Coefficient	Robust standard error	p-value									
Constant	-2.13E-07	3.04E-07	0.48340									
R(-1)	-0.09054	0.002255	0.00000									
ω	1.77E-09	1.64E-11	0.00000									
α	0.201517	0.000771	0.00000									
β	0.853349	0.000443	0.00000									

Tabela A 3 – Estimação do Modelo EGARCH

	AAL			AAPL			ADBE			ADI		
	Coefficient	Robust standard error	p-value									
Constant	-3.30E-06	8.76E-07	0.00020	-6.39E-07	2.96E-07	0.03070	-3.27E-06	5.08E-07	0.00000	-6.16E-06	2.13E-07	0.00000
R(-1)	-0.03366	0.002854	0.00000	-0.04556	0.000486	0.00000	-0.02229	0.002402	0.00000	-0.08602	0.00186	0.00000
ω	-2.83944	0.018926	0.00000	-3.95401	0.014685	0.00000	-1.58088	0.009283	0.00000	-1.60734	0.003516	0.00000
α	0.358531	0.001855	0.00000	0.915716	0.001429	0.00000	0.479773	0.000454	0.00000	0.467948	0.001102	0.00000
γ	-0.02985	0.001309	0.00000	-0.34154	0.001556	0.00000	-0.08708	0.001065	0.00000	0.002042	0.000648	0.00160
β	0.833423	0.00114	0.00000	0.795943	0.000883	0.00000	0.924021	0.000545	0.00000	0.919532	0.000189	0.00000
	ADP			ADSR			AKAM			ALXN		
	Coefficient	Robust standard error	p-value									
Constant	1.76E-07	3.51E-07	0.61700	7.14E-06	6.38E-07	0.00000	5.77E-06	8.53E-07	0.00000	-3.79E-06	1.08E-06	0.00050
R(-1)	-0.04868	0.002235	0.00000	-0.03226	0.001344	0.00000	0.083509	0.005232	0.00000	0.112489	0.001858	0.00000
ω	-0.97948	0.005133	0.00000	-1.05737	0.005532	0.00000	-0.70018	0.0068	0.00000	-6.46903	0.020464	0.00000
α	0.257699	0.001267	0.00000	0.296293	0.000806	0.00000	0.24459	0.001567	0.00000	1.08971	0.002039	0.00000
γ	-0.09419	0.000984	0.00000	-0.08778	0.000789	0.00000	0.095994	0.001254	0.00000	0.189419	0.002753	0.00000
β	0.950744	0.000277	0.00000	0.945425	0.000333	0.00000	0.963565	0.000398	0.00000	0.609839	0.001331	0.00000
	AMAT			AMGN			AMZN			ATVI		
	Coefficient	Robust standard error	p-value									
Constant	-4.52E-09	7.47E-07	0.99520	-6.15E-06	3.46E-07	0.00000	7.64E-07	3.54E-07	0.03100	-1.50E-06	5.79E-07	0.00970
R(-1)	-0.10721	0.003049	0.00000	-0.12065	0.001378	0.00000	-0.06398	0.002036	0.00000	-0.08543	0.00188	0.00000
ω	-1.44466	0.00833	0.00000	-0.80692	0.003721	0.00000	-0.83653	0.00438	0.00000	-1.75381	0.006815	0.00000

α	0.350474	0.001346	0.00000	0.371679	0.000694	0.00000	0.255628	0.000487	0.00000	0.467549	0.000795	0.00000
γ	0.017861	0.00111	0.00000	-0.15225	0.000852	0.00000	-0.00998	0.000527	0.00000	-0.05548	0.000934	0.00000
β	0.924828	0.00049	0.00000	0.964399	0.000231	0.00000	0.959144	0.000251	0.00000	0.909984	0.000403	0.00000
	AVGO			BBBY			BIDU			BIIB		
	Coefficient	Robust standard error	p-value									
Constant	1.28E-05	5.70E-07	0.00000	2.43E-07	7.42E-07	0.74310	1.20E-06	5.80E-07	0.03940	5.96E-07	4.95E-07	0.22860
R(-1)	-0.07479	0.002781	0.00000	-0.03621	0.002319	0.00000	-0.05409	0.002143	0.00000	0.046581	0.000989	0.00000
ω	-1.49711	0.00746	0.00000	-1.44361	0.011601	0.00000	-1.50177	0.008796	0.00000	-5.16863	0.011547	0.00000
α	0.398217	0.001626	0.00000	0.371049	0.001231	0.00000	0.319896	0.001115	0.00000	0.982474	0.001299	0.00000
γ	0.052818	0.000848	0.00000	-0.00737	0.001187	0.00000	-0.03481	0.000816	0.00000	-0.41371	0.001202	0.00000
β	0.921959	0.000433	0.00000	0.925509	0.000681	0.00000	0.918298	0.000515	0.00000	0.703478	0.000739	0.00000
	BMRN			CA			CELG			CERN		
	Coefficient	Robust standard error	p-value									
Constant	3.93E-06	1.40E-06	0.00490	-9.75E-06	4.99E-07	0.00000	-1.69E-06	7.64E-07	0.02700	-6.65E-06	4.26E-07	0.00000
R(-1)	-0.08812	0.00255	0.00000	-0.05108	0.003428	0.00000	-0.0814	0.002532	0.00000	0.013742	0.001692	0.00000
ω	-2.81434	0.017243	0.00000	-1.84904	0.007322	0.00000	-0.83918	0.007743	0.00000	-0.91303	0.003853	0.00000
α	0.489534	0.002299	0.00000	0.310093	0.001296	0.00000	0.289387	0.001334	0.00000	0.316809	0.001095	0.00000
γ	-0.08933	0.001874	0.00000	-0.0167	0.000964	0.00000	-0.13597	0.001275	0.00000	-0.09194	0.001088	0.00000
β	0.835175	0.001041	0.00000	0.901234	0.000423	0.00000	0.958612	0.000471	0.00000	0.954704	0.000208	0.00000
	CHKP			CHTR			CMCSA			COST		
	Coefficient	Robust standard error	p-value									
Constant	-3.11E-06	4.18E-07	0.00000	-5.06E-06	7.22E-07	0.00000	-1.84E-06	4.67E-07	0.00010	1.02E-06	2.52E-07	0.00010

R(-1)	-0.07288	0.002946	0.00000	-0.02083	0.002558	0.00000	-0.07281	0.002883	0.00000	-0.09094	0.002175	0.00000
ω	-2.16353	0.011853	0.00000	-2.09652	0.016869	0.00000	-2.43534	0.018485	0.00000	-2.06315	0.014469	0.00000
α	0.433818	0.001218	0.00000	0.452257	0.001909	0.00000	0.355772	0.001886	0.00000	0.480117	0.001378	0.00000
γ	0.030344	0.001163	0.00000	0.022092	0.00131	0.00000	-0.03004	0.001321	0.00000	0.018707	0.000868	0.00000
β	0.885439	0.000704	0.00000	0.888638	0.000981	0.00000	0.870397	0.001011	0.00000	0.897691	0.000801	0.00000
	CSCO			CSX			CTRP			CTSH		
	Coefficient	Robust standard error	p-value									
Constant	3.05E-07	3.65E-07	0.40330	-4.42E-06	6.51E-07	0.00000	1.93E-06	4.57E-07	0.00000	-7.01E-06	5.86E-07	0.00000
R(-1)	-0.11936	0.001436	0.00000	-0.10051	0.002807	0.00000	-0.10666	0.001547	0.00000	-0.18206	0.002726	0.00000
ω	-1.67257	0.009527	0.00000	-2.06839	0.008804	0.00000	-0.63219	0.002247	0.00000	-0.78805	0.004944	0.00000
α	0.484204	0.001679	0.00000	0.344916	0.001754	0.00000	0.317648	0.001003	0.00000	0.312552	0.001333	0.00000
γ	-0.03395	0.001139	0.00000	-0.00174	0.001221	0.15310	0.024203	0.000706	0.00000	-0.19432	0.000759	0.00000
β	0.91855	0.000515	0.00000	0.888774	0.00052	0.00000	0.971997	0.000134	0.00000	0.95772	0.000274	0.00000
	CTXS			DISCA			DISCK			DISH		
	Coefficient	Robust standard error	p-value									
Constant	1.10E-06	4.51E-07	0.01440	3.23E-08	5.60E-07	0.95400	9.46E-06	6.07E-07	0.00000	1.06E-05	8.46E-07	0.00000
R(-1)	-0.05179	0.002653	0.00000	-0.0479	0.001997	0.00000	-0.0618	0.00244	0.00000	-0.08339	0.003132	0.00000
ω	-1.32111	0.00601	0.00000	-1.22279	0.008662	0.00000	-2.10213	0.017432	0.00000	-1.81306	0.010588	0.00000
α	0.323018	0.000843	0.00000	0.307698	0.001152	0.00000	0.374168	0.001549	0.00000	0.363553	0.001335	0.00000
γ	-0.03057	0.000673	0.00000	-0.02563	0.000857	0.00000	-0.04595	0.000827	0.00000	-0.07981	0.001149	0.00000
β	0.931778	0.000343	0.00000	0.935301	0.000516	0.00000	0.883831	0.00102	0.00000	0.901587	0.000644	0.00000
	DLTR			EA			EBAY			ESRX		

	Coefficient	Robust standard error	p-value									
Constant	7.10E-06	5.38E-07	0.00000	-4.29E-06	5.16E-07	0.00000	1.86E-06	2.68E-07	0.00000	8.19E-07	4.38E-07	0.06150
R(-1)	-0.03653	0.002082	0.00000	-0.08301	0.002395	0.00000	-0.06483	0.003789	0.00000	0.027802	0.002054	0.00000
ω	-1.76493	0.007129	0.00000	-1.9055	0.010465	0.00000	-7.00107	0.030026	0.00000	-1.2162	0.005824	0.00000
α	0.588146	0.001752	0.00000	0.381554	0.001726	0.00000	0.871845	0.00171	0.00000	0.321161	0.000418	0.00000
γ	-0.05941	0.001732	0.00000	-0.0486	0.001422	0.00000	-0.25314	0.001588	0.00000	-0.01661	0.000744	0.00000
β	0.911156	0.000413	0.00000	0.897933	0.0006	0.00000	0.602336	0.001802	0.00000	0.936196	0.000346	0.00000
	EXPE			FAST			FB			FISV		
	Coefficient	Robust standard error	p-value									
Constant	9.30E-07	6.18E-07	0.13250	8.75E-07	5.73E-07	0.12680	2.08E-06	4.09E-07	0.00000	1.97E-06	4.66E-07	0.00000
R(-1)	-0.09148	0.003503	0.00000	-0.04452	0.002582	0.00000	0.021952	0.001544	0.00000	-0.14988	0.002751	0.00000
ω	-1.32928	0.007943	0.00000	-1.32526	0.010631	0.00000	-0.76675	0.001575	0.00000	-0.85591	0.004666	0.00000
α	0.310138	0.000961	0.00000	0.317306	0.001005	0.00000	0.254604	0.000649	0.00000	0.241669	0.00123	0.00000
γ	-0.08387	0.001072	0.00000	-0.02797	0.000971	0.00000	0.005051	0.000539	0.00000	-0.09169	0.000736	0.00000
β	0.930431	0.000486	0.00000	0.932086	0.000629	0.00000	0.963049	7.43E-05	0.00000	0.956565	0.000283	0.00000
	FOX			FOXA			GILD			GOOGLE		
	Coefficient	Robust standard error	p-value									
Constant	-3.92E-06	5.71E-07	0.00000	6.20E-06	4.94E-07	0.00000	-4.80E-06	5.71E-07	0.00000	-2.06E-06	4.58E-07	0.00000
R(-1)	-0.07323	0.002625	0.00000	-0.04106	0.001662	0.00000	-0.02474	0.002021	0.00000	-0.09468	0.002333	0.00000
ω	-1.21085	0.008055	0.00000	-1.07561	0.007398	0.00000	-1.52232	0.012238	0.00000	-1.10319	0.007614	0.00000
α	0.371527	0.001184	0.00000	0.320935	0.001104	0.00000	0.389391	0.001555	0.00000	0.391244	0.001283	0.00000
γ	-0.0059	0.001069	0.00000	0.037877	0.000634	0.00000	-0.05608	0.001347	0.00000	-0.02378	0.00109	0.00000

β	0.940543	0.000473	0.00000	0.9468	0.000421	0.00000	0.923761	0.00068	0.00000	0.949828	0.000419	0.00000
	HSIC			ILMN			INCY			INTC		
	Coefficient	Robust standard error	p-value									
Constant	-5.49E-06	5.12E-07	0.00000	-1.20E-05	2.15E-06	0.00000	1.70E-05	7.88E-07	0.00000	-4.73E-06	4.61E-07	0.00000
R(-1)	-0.03174	0.002229	0.00000	-0.08703	0.004886	0.00000	-0.07684	0.003892	0.00000	-0.05582	0.002183	0.00000
ω	-5.12117	0.029586	0.00000	-20.9556	0.141875	0.00000	-1.87939	0.012965	0.00000	-4.49314	0.024788	0.00000
α	0.810573	0.00259	0.00000	0.050938	0.001443	0.00000	0.234311	0.000851	0.00000	0.75424	0.001502	0.00000
γ	0.098484	0.001918	0.00000	0.02821	0.000906	0.00000	-0.0265	0.001074	0.00000	-0.21762	0.001328	0.00000
β	0.715314	0.001757	0.00000	-0.47518	0.009997	0.00000	0.883025	0.000839	0.00000	0.762351	0.001485	0.00000
	INTU			ISRG			JD			KHC		
	Coefficient	Robust standard error	p-value									
Constant	3.96E-07	2.05E-07	0.05360	-2.13E-06	1.08E-06	0.04780	-2.41E-06	4.69E-07	0.00000	-6.21E-06	5.35E-07	0.00000
R(-1)	-0.04504	0.001898	0.00000	-0.15371	0.00332	0.00000	-0.05058	0.001709	0.00000	0.03667	0.001979	0.00000
ω	-2.43237	0.012175	0.00000	-2.0251	0.023108	0.00000	-0.91445	0.004365	0.00000	-2.49374	0.014234	0.00000
α	0.547425	0.001344	0.00000	0.316269	0.001664	0.00000	0.325164	0.001029	0.00000	0.672747	0.002458	0.00000
γ	-0.24176	0.000926	0.00000	-0.05429	0.00151	0.00000	-0.01527	0.000776	0.00000	-0.19868	0.001843	0.00000
β	0.874454	0.000698	0.00000	0.887521	0.001407	0.00000	0.953131	0.000246	0.00000	0.875663	0.000865	0.00000
	LBTYA			LBTYK			LLTC			LRCX		
	Coefficient	Robust standard error	p-value									
Constant	-1.02E-08	1.58E-06	0.99480	1.02E-05	1.76E-06	0.00000	-8.15E-08	3.12E-06	0.97910	5.33E-06	5.21E-07	0.00000
R(-1)	2.80E-05	0.003191	0.99300	-0.06773	0.001185	0.00000	0.010459	0.001024	0.00000	-0.01473	0.001878	0.00000
ω	-2.07597	0.021799	0.00000	-2.26781	0.039853	0.00000	-15.3084	0.037214	0.00000	-3.21283	0.014322	0.00000

α	0.284958	0.002715	0.00000	0.116751	0.001575	0.00000	0.013951	0.000121	0.00000	0.519629	0.001745	0.00000
γ	-0.04668	0.002668	0.00000	0.108996	0.001565	0.00000	0.009249	0.000125	0.00000	-0.11825	0.001364	0.00000
β	0.873875	0.001386	0.00000	0.85445	0.002575	0.00000	0.046228	0.002321	0.00000	0.821386	0.000849	0.00000
	LVNTA			MAR			MAT			MCHP		
	Coefficient	Robust standard error	p-value									
Constant	-9.98E-06	8.41E-07	0.00000	-2.57E-06	4.33E-07	0.00000	8.89E-06	3.63E-07	0.00000	2.04E-07	3.65E-07	0.57690
R(-1)	-0.05696	0.003108	0.00000	-0.02385	0.002528	0.00000	-0.08914	0.002969	0.00000	0.002908	0.003245	0.37020
ω	-2.16	0.008074	0.00000	-1.28383	0.007187	0.00000	-4.42647	0.022732	0.00000	-2.84693	0.017659	0.00000
α	0.427593	0.001051	0.00000	0.284711	0.001011	0.00000	0.665471	0.001587	0.00000	0.515885	0.000926	0.00000
γ	-0.01922	0.001099	0.00000	-0.0215	0.00091	0.00000	0.01862	0.001043	0.00000	-0.09605	0.001599	0.00000
β	0.879324	0.000513	0.00000	0.933777	0.000406	0.00000	0.750284	0.001358	0.00000	0.842846	0.001053	0.00000
	MDLZ			MNST			MSFT			MU		
	Coefficient	Robust standard error	p-value									
Constant	2.85E-06	6.19E-07	0.00000	-0.00031	2.02E-05	0.00000	-3.19E-06	4.88E-07	0.00000	4.92E-06	8.23E-07	0.00000
R(-1)	-0.07518	0.002399	0.00000	0.157976	0.002248	0.00000	-0.01834	0.002224	0.00000	-0.08925	0.003101	0.00000
ω	-1.14573	0.004743	0.00000	-12.1422	0.177287	0.00000	-1.88555	0.015876	0.00000	-1.39473	0.009686	0.00000
α	0.360437	0.001152	0.00000	-0.32382	0.00665	0.00000	0.551739	0.002112	0.00000	0.222224	0.001692	0.00000
γ	0.001862	0.000731	0.01080	-0.36173	0.00667	0.00000	-0.1267	0.001916	0.00000	0.091629	0.000866	0.00000
β	0.94435	0.000241	0.00000	0.010893	0.014302	0.44630	0.911045	0.000902	0.00000	0.916209	0.00059	0.00000
	MXIM			MYL			NCLH			NDX		
	Coefficient	Robust standard error	p-value									
Constant	-2.40E-06	4.99E-07	0.00000	-2.64E-05	8.75E-07	0.00000	1.91E-05	6.40E-07	0.00000	-8.31E-07	2.73E-07	0.00240

R(-1)	-0.07246	0.002922	0.00000	0.016654	0.002408	0.00000	-0.06926	0.002571	0.00000	0.093424	0.00235	0.00000
ω	-1.76289	0.00656	0.00000	-1.6569	0.003625	0.00000	-6.1234	0.026522	0.00000	-1.09477	0.005222	0.00000
α	0.364472	0.000956	0.00000	0.600941	0.001243	0.00000	0.903426	0.001027	0.00000	0.286749	0.000617	0.00000
γ	-0.06104	0.000951	0.00000	-0.27635	0.000537	0.00000	0.017623	0.001489	0.00000	-0.1045	0.000713	0.00000
β	0.90712	0.000382	0.00000	0.914591	0.000252	0.00000	0.638764	0.001674	0.00000	0.948304	0.000286	0.00000
	NFLX			NTAP			NTES			NVDA		
	Coefficient	Robust standard error	p-value									
Constant	-9.70E-06	4.30E-07	0.00000	1.93E-05	1.04E-06	0.00000	-1.24E-06	8.80E-07	0.1584	-3.84E-05	2.24E-06	0.00000
R(-1)	0.14778	0.002721	0.00000	0.051617	0.002851	0.00000	-0.05174	0.002287	0.00000	-0.02561	0.005235	0.00000
ω	-8.69809	0.029658	0.00000	-2.27651	0.013505	0.00000	-1.92399	0.009495	0.00000	-6.75702	0.092675	0.00000
α	1.185214	0.002046	0.00000	0.507455	0.002409	0.00000	0.341202	0.001346	0.00000	0.262118	0.003486	0.00000
γ	0.383255	0.002181	0.00000	-0.19797	0.00221	0.00000	-0.00915	0.001113	0.00000	0.066326	0.002488	0.00000
β	0.493069	0.001804	0.00000	0.873048	0.000867	0.00000	0.88786	0.00058	0.00000	0.55695	0.006119	0.00000
	NXPI			ORLY			PAYX			PCAR		
	Coefficient	Robust standard error	p-value									
Constant	-2.14E-05	5.18E-07	0.00000	7.71E-06	6.13E-07	0.00000	-1.27E-07	2.90E-07	0.66070	-7.37E-07	4.46E-07	0.09830
R(-1)	-0.05887	0.002083	0.00000	-0.16227	0.002053	0.00000	-0.0462	0.002165	0.00000	-0.05026	0.002617	0.00000
ω	-0.20939	0.001935	0.00000	-2.02418	0.016283	0.00000	-2.17249	0.008917	0.00000	-1.85618	0.008071	0.00000
α	0.288906	0.000561	0.00000	0.384701	0.001735	0.00000	0.463179	0.001606	0.00000	0.364449	0.001247	0.00000
γ	-0.12568	0.000746	0.00000	-0.08151	0.001211	0.00000	-0.02867	0.001178	0.00000	-0.07117	0.000982	0.00000
β	0.995726	0.000129	0.00000	0.891517	0.000921	0.00000	0.889299	0.000477	0.00000	0.900428	0.000463	0.00000
	PCLN			PYPL			QCOM			QVCA		

	Coefficient	Robust standard error	p-value									
Constant	9.27E-06	9.73E-07	0.00000	3.12E-06	5.70E-07	0.00000	-1.93E-06	5.02E-07	0.00010	-5.06E-06	7.89E-07	0.00000
R(-1)	-0.15153	0.004654	0.00000	-0.02184	0.002502	0.00000	-0.06082	0.001578	0.00000	-0.02174	0.003806	0.00000
ω	-1.655	0.022869	0.00000	-1.64605	0.017703	0.00000	-0.95289	0.004551	0.00000	-1.12718	0.010448	0.00000
α	0.327107	0.001389	0.00000	0.392171	0.001906	0.00000	0.337808	0.00094	0.00000	0.343103	0.001481	0.00000
γ	-0.05368	0.001754	0.00000	0.05112	0.001073	0.00000	-0.08683	0.000862	0.00000	0.024351	0.001023	0.00000
β	0.91156	0.00137	0.00000	0.914909	0.001014	0.00000	0.95499	0.000266	0.00000	0.942583	0.000637	0.00000
	REGN			ROST			SBAC			SBUX		
	Coefficient	Robust standard error	p-value									
Constant	4.91E-06	1.27E-06	0.00010	-3.53E-06	5.22E-07	0.00000	-3.31E-06	6.99E-07	0.00000	-1.18E-06	4.17E-07	0.00460
R(-1)	-0.147	0.003884	0.00000	-0.04066	0.002513	0.00000	-0.02671	0.002341	0.00000	-0.1157	0.001645	0.00000
ω	-1.73103	0.011057	0.00000	-2.38649	0.013466	0.00000	-3.76626	0.020902	0.00000	-1.18356	0.009616	0.00000
α	0.343723	0.001503	0.00000	0.431836	0.001536	0.00000	0.499175	0.001922	0.00000	0.333555	0.001581	0.00000
γ	-0.08818	0.001405	0.00000	0.050966	0.001255	0.00000	-0.02294	0.001777	0.00000	0.019504	0.000619	0.00000
β	0.900954	0.000687	0.00000	0.873374	0.000762	0.00000	0.786733	0.00123	0.00000	0.942493	0.000517	0.00000
	SIRI			SRCL			STX			SWKS		
	Coefficient	Robust standard error	p-value									
Constant	-3.98E-06	1.88E-06	0.03460	1.50E-05	4.10E-07	0.00000	9.01E-06	7.54E-07	0.00000	6.41E-06	7.61E-07	0.00000
R(-1)	-0.39172	0.004478	0.00000	0.062483	0.002241	0.00000	0.005679	0.003416	0.09650	-0.02733	0.003232	0.00000
ω	-1.21486	0.032479	0.00000	-4.88264	0.016786	0.00000	-1.15011	0.008799	0.00000	-0.92314	0.003004	0.00000
α	0.145042	0.002667	0.00000	0.855748	0.002195	0.00000	0.253362	0.001184	0.00000	0.22222	0.000737	0.00000
γ	-0.01155	0.002192	0.00000	0.232487	0.001569	0.00000	-0.0156	0.000694	0.00000	-0.02169	0.000923	0.00000

β	0.928422	0.002013	0.00000	0.729198	0.001001	0.00000	0.936904	0.000532	0.00000	0.950311	0.000183	0.00000
	SYMC			TMUS			TRIP			TSCO		
	Coefficient	Robust standard error	p-value									
Constant	2.61E-05	6.68E-07	0.00000	3.98E-06	9.74E-07	0.00000	-1.53E-05	6.52E-07	0.00000	-1.42E-05	3.40E-07	0.00000
R(-1)	-0.24134	0.004258	0.00000	-0.00919	0.003268	0.00490	0.017874	0.002123	0.00000	-0.51513	0.001538	0.00000
ω	-1.0115	0.008221	0.00000	-0.97031	0.007928	0.00000	-2.25698	0.005814	0.00000	-12.444	0.022191	0.00000
α	0.530978	0.001335	0.00000	0.276762	0.000806	0.00000	0.693577	0.001673	0.00000	1.80735	0.004353	0.00000
γ	0.124074	0.001175	0.00000	-0.03009	0.000763	0.00000	-0.21249	0.0016	0.00000	0.995619	0.004155	0.00000
β	0.954289	0.000503	0.00000	0.950774	0.000495	0.00000	0.884006	0.000392	0.00000	0.269197	0.001372	0.00000
	TSLA			TXN			ULTA			VIAB		
	Coefficient	Robust standard error	p-value									
Constant	-2.27E-06	9.06E-07	0.01210	-7.17E-07	4.38E-07	0.10170	1.41E-08	8.77E-07	0.98720	-1.34E-05	7.25E-07	0.00000
R(-1)	-0.07595	0.003681	0.00000	0.012071	0.002167	0.00000	-0.18843	0.002978	0.00000	-0.0551	0.002624	0.00000
ω	-1.49175	0.010189	0.00000	-2.38914	0.012281	0.00000	-1.54435	0.010686	0.00000	-2.86503	0.014577	0.00000
α	0.23196	0.001249	0.00000	0.464195	0.001284	0.00000	0.340373	0.001538	0.00000	0.594237	0.001261	0.00000
γ	-0.00608	0.001192	0.00000	-0.10807	0.001357	0.00000	-0.08113	0.001312	0.00000	0.012224	0.001782	0.00000
β	0.913783	0.000629	0.00000	0.876459	0.000694	0.00000	0.917059	0.000621	0.00000	0.840783	0.000896	0.00000
	VOD			VRSK			VRTX			WBA		
	Coefficient	Robust standard error	p-value									
Constant	-1.24E-05	5.03E-07	0.00000	-2.30E-06	4.55E-07	0.00000	7.00E-06	1.26E-06	0.00000	-9.16E-06	5.48E-07	0.00000
R(-1)	-0.06442	0.002414	0.00000	-0.08826	0.002827	0.00000	-0.13164	0.002472	0.00000	-0.01751	0.00309	0.00000
ω	-12.1895	0.030931	0.00000	-2.22147	0.0173	0.00000	-1.30124	0.004905	0.00000	-4.87038	0.026664	0.00000

α	0.656451	0.001472	0.00000	0.450407	0.00125	0.00000	0.364481	0.001741	0.00000	0.522119	0.00184	0.00000
γ	-0.20542	0.001392	0.00000	-0.1183	0.001323	0.00000	-0.07807	0.001347	0.00000	0.00552	0.001615	0.00060
β	0.287608	0.001842	0.00000	0.885188	0.000976	0.00000	0.930901	0.000326	0.00000	0.726331	0.001553	0.00000
	WDC			WFM			XLNX			XRAY		
	Coefficient	Robust standard error	p-value									
Constant	-1.96E-05	9.01E-07	0.00000	5.95E-09	1.10E-06	0.99570	1.14E-08	2.82E-07	0.96780	6.71E-06	5.24E-07	0.00000
R(-1)	0.044438	0.001982	0.00000	-0.13306	0.003511	0.00000	-0.062	0.00219	0.00000	0.03051	0.002267	0.00000
ω	-2.6313	0.022682	0.00000	-1.20496	0.003621	0.00000	-1.01284	0.004215	0.00000	-1.53156	0.007065	0.00000
α	0.349029	0.002047	0.00000	0.301796	0.000605	0.00000	0.319545	0.001142	0.00000	0.47202	0.001087	0.00000
γ	-0.01257	0.001185	0.00000	0.128839	0.001832	0.00000	-0.06712	0.000812	0.00000	-0.03808	0.001708	0.00000
β	0.840674	0.001407	0.00000	0.935443	0.000237	0.00000	0.950707	0.000238	0.00000	0.922537	0.000412	0.00000
	YHOO											
	Coefficient	Robust standard error	p-value									
Constant	-2.97E-06	6.01E-07	0.00000									
R(-1)	-0.10124	0.001869	0.00000									
ω	-0.79026	0.004091	0.00000									
α	0.253564	0.001062	0.00000									
γ	-0.00976	0.000813	0.00000									
β	0.961453	0.000232	0.00000									