



**INSTITUTO SUPERIOR DE GESTÃO**

# **Testes à Correlação entre Mercados e o seu Impacto na Gestão de Carteiras**

**RUI FILIPE DOMINGOS NUNES**

Dissertação apresentada no Instituto Superior de Gestão para obtenção do Grau de Mestre em Gestão Financeira.

Orientador: Professor Henrique Nuno Esteves Correia dos Santos Morais

**LISBOA**

2017

## Sumário

Ao longo das recentes décadas, inúmeros artigos têm vindo a ser publicados no campo das Ciências Financeiras. Nesse mesmo campo, relativamente à área dos Mercados Financeiros, paradoxalmente, com esta lógica, quanto mais o estado da arte for avançando, maior será a complexidade de interpretação do tema. Isto é, quanto maior o conhecimento e avanço de interpretação do comportamento dos mercados, por força da competitividade, mais essa informação será incluída nos mercados e alterando o paradigma anterior. Assim sendo, o estudo realizado prende-se à contínua interpretação do comportamento dos mercados e o seu impacto na gestão de carteiras. Onde são feitos testes aos 12 dos maiores mercados financeiros, através dos seus índices. Seleccionados geograficamente: América, Europa e Ásia, são analisados quanto às suas rendibilidades e variâncias através do Coeficiente de Pearson e modelo GARCH, respetivamente. Onde é possível concluir que existe correlação entre os mercados a nível de direção de evolução de preços, no entanto as diferentes áreas geográficas mudam o quanto são correlacionáveis. Por fim, pelo contrário, é possível verificar que a nível de risco, as correlações são menos acentuadas, tornando-se possível minimizar o risco pelo sentido de direção da variância de cada mercado.

Palavras-Chave: Mercados, Gestão de Carteiras, Rendibilidade, Variância e Correlação.

## **Abstract**

Over the recent decades, numerous articles have been published in the field of Finance. This, in the area of Financial Markets, paradoxically, with this logic, the more the state of the art enhances, so does the complexity of interpretation. That is, the larger the knowledge and interpretation of market behavior gets, due to competitiveness, the more this information will be included in the markets and force the previous paradigm to change. Therefore, the study carried out refers to the continuous interpretation of market behavior and its impact on portfolio management. Where tests are done on 12 of the largest financial markets, through their indexes. Selected geographically: America, Europe and Asia, are analyzed for their returns and variance through Pearson Coefficient and GARCH model, respectively. It is possible to conclude that there is correlation between these markets regarding pricing movements, however the different geographical areas change how much they are correlated. Finally, on the contrary, it is possible to validate that, concerning risk, the correlations are weaker, making it possible to minimize the risk by understanding the direction of the variance for each market.

**Keywords:** Markets, Portfolio Management, Returns, Variance and Correlation.

## **Agradecimentos**

Em primeiro lugar, quero agradecer aos meus pais Maria e Eduardo, aos meus irmãos Eduardo, Luís e Ana, ao meu cunhado Telmo e cunhada Carolina, por todo o apoio oferecido ao longo desta etapa e da minha vida. Deixar ainda uma palavra especial à minha namorada Alexandra, por toda a ajuda e incentivo contínuo para concluir o projeto e fomentar o meu interesse para uma constante evolução e desafio. Dos quais, sem estes, o caminho seria mais árduo e com um menor propósito.

Um agradecimento especial ao meu orientador, Professor Henrique Moraes, por toda a disponibilidade, orientação, paciência e apoio ao longo deste percurso académico. São valores que carregarei para o resto da minha vida, no âmbito profissional e diário. E, ainda, aproveitar para agradecer a todos os meus colegas de turma, em especial aos colegas Edgar Agostinho e Felipe Brás, pelo companheirismo e estímulo académico.

Por fim, humildemente, agradecer a todos aqueles que, de algum modo, partilharam a sua disponibilidade e boa vontade ao longo deste percurso.

## **Simbologia e Abreviaturas**

*S&P – Standard & Poor's*

*FTSE 100 – Financial Times Stock Exchange 100*

*IBEX 35 – Iberia Index 35*

*CAC 40 – Cotation Assistée en Continu 40*

*DAX 30 – Deutscher Aktien Index 30*

*PSI 20 – Portuguese Stock Index 20*

*FTSE MIB – Milano Indice di Borsa*

*Shanghai – Shanghai Stock Exchange (SSE Composite Index)*

*Nikkei – Nikkei heikin kabuka 225*

*S&P/ASX 200 – Australian Securities Exchange*

*PIB – Produto Interno Bruto*

*IPO – Initial Public Offering – Oferta Pública Inicial*

*CAPM – Capital Asset Pricing Model*

*EMH – Efficient Market Hypothesis*

*EWMA – Exponentially Weighted Moving Average*

*TLC – Teorema do Limite Central*

*ARCH – Autoregressive Conditional Heteroskedasticity*

*GARCH – Generalized Autoregressive Conditional Heteroskedasticity*

*MQO – Mínimos Quadrados Ordinários*

*ARMA – Autoregressive Moving Average*

*MLE – Maximum-Likelihood Estimation*

## Índice Geral

Sumário .....	i
Abstract .....	ii
Agradecimentos .....	iii
Simbologia e Abreviaturas .....	iv
Índice de Figuras.....	vii
Índice de Tabelas .....	viii
Índice de Equações.....	ix
1. Introdução .....	1
1.1. Objeto de Estudo .....	1
1.2. Objetivos do Estudo.....	1
1.3. Metodologia Geral.....	2
1.4. Estrutura da Dissertação.....	3
2. Enquadramento Teórico .....	5
2.1. Mercados Financeiros.....	5
2.2. Eficiência de Mercados e Anomalias .....	9
2.3. Gestão de Carteiras .....	12
3. Estudo Empírico .....	14
3.1. Metodologia.....	14
3.2. Caracterização e Descrição do Estudo .....	16
3.2.1. Análise dos Mercados.....	20
3.2.2. Correlação dos Mercados.....	25
3.2.3. Avaliação <i>Intraday</i> .....	30

3.2.3.1. Quanto ao Risco.....	30
3.2.3.2. Análise de GARCH.....	32
3.2.3.2.1. Viabilidade.....	36
3.2.3.2.2. Likelihood .....	37
3.2.3.2.3. Análise a diferentes abordagens .....	40
3.2.3.2.3.1. Aplicação de GARCH e o seu impacto .....	41
3.2.3.2.3.2. Comportamento entre mercados através de GARCH e Médias Móveis.....	42
3.3. Conclusões dos Estudos - Enquadrado Teoricamente .....	48
3.4. Sugestões e Recomendações .....	51
4. Conclusão .....	53
5. Referências Bibliográficas .....	54
6. Netgrafia.....	59
Anexos .....	60

## Índice de Figuras

Figura 1 – Ilustração da Organização do Mercado de Capitais.....	7
Figura 2 – Gráfico ilustrativo de Ineficiência e Eficiência .....	10
Figura 3 – Reação a notícias de OPA (Fonte: Journal of Finance, Volume 36, p. 861) .	11
Figura 4 – Gráfico ilustrativo da diversificação do portefólio. ....	13
Figura 5 - Gráfico da JP Morgan sobre “International Equities – “fat” left tails in historical returns” (Fonte: J.P. Morgan Asset Management study, 2009) .....	20
Figura 6 - Box & Whisker plot das rendibilidade de cada índice, relativamente ao período de 2000 a 2017. ....	21
Figura 7 - Representação de horários dos mercados (com base no horário de Lisboa). .....	32
Figura 8 - Gráfico ilustrativo da variância pelo modelo de GARCH em função da variância total média do mesmo período.....	36
Figura 9 - Gráfico ilustrativo do comportamento dos resultados do EWMA. ....	47

## Índice de Tabelas

Tabela 1 - Estatística descritiva das rendibilidades de 2000 a 2017 para cada Índice. Com p-value = 0,05. ....	21
Tabela 2 – Conjunto de Figuras de Movimentações de Cotações dos Mercados no período de 2000 a 2017. ....	24
Tabela 3 - Matriz de Correlações entre as Rendibilidades dos Mercados no período de 2000 a 2017 (valores de $\rho$ ). ....	26
Tabela 4 – Síntese da Tabela 3 por área geográfica. ....	27
Tabela 5 - Matriz e Tabelas síntese de Correlações entre os Desvios Padrão dos Mercados no período de 2000 a 2017, organizados geograficamente (valores de $\rho$ )....	29
Tabela 6 - Correlações entre os Desvios Padrão de mercados em 2017, ao dia e à hora, respetivamente (valores de $\rho$ ). ....	31
Tabela 7 - resumo do Anexo D das parcelas de ponderação para cada índice e o Critério de Schwarz, relativo a dados históricos de janeiro de 2000 até abril de 2017 (n = 3570). ....	39
Tabela 8 - Estatística descritiva de correlações referente a cada mercado (de abril de 2017 a outubro de 2017). ....	41
Tabela 9 - Conjunto de tabelas de estatística descritiva dos valores de correlação entre a variância observada com a esperada em função de outros mercados .....	46

## Índice de Equações

[1] Fórmula matemática de cálculo dos índices PSI.....	8
[2] Divisor vigente no momento $t$ .....	8
[3] Fórmula de cálculo da Rendibilidade Logarítmica.....	17
[4] Fórmula de equivalência de taxas para diárias em todas as parcelas das rendibilidades .....	17
[5] Fórmula de composição do modelo GARCH.....	35
[6] Fórmula de cálculo da <i>Exponentially Weighted Moving Average</i> .....	43

## **1. Introdução**

Este capítulo apresenta o tópico abordado neste Projeto de Dissertação, isto é, Testes à Correlação entre Mercados e o seu impacto na Gestão de Carteiras. Assim, começará por ser apresentado o objeto e objetivos de estudo, quais as metodologias de modo a alcança-los e, por fim, a estrutura de apresentação para melhor compreensão dos resultados obtidos.

### **1.1. Objeto de Estudo**

A investigação pretende testar as correlações de diversos mercados e os seus impactos no momento de gestão de carteira. Ou seja, analisar diversas formas de interpretação de observações históricas de índices, construindo uma tradução dos mercados, de modo a criar uma perspetiva inovadora no momento de análise dos mesmos para auxílio ao investidor.

O estudo incide sobre doze dos principais índices mundiais: *Standard & Poor's (S&P)*, *Ibovespa*, *Euro Stoxx 50*, *Financial Times Stock Exchange 100 (FTSE 100)*, *Iberia Index 35 (IBEX 35)*, *Cotation Assistée en Continu 40 (CAC 40)*, *Deutscher Aktien Index 30 (DAX 30)*, *Portuguese Stock Index 20 (PSI 20)*, *Milano Indice di Borsa (FTSE MIB)*, *Shanghai Stock Exchange (SSE Composite Index)*, *Nikkei heikin kabuka 225 (Nikkei)* e *Australian Securities Exchange (S&P/ASX 200)*.

Para o efeito, são realizados diversos testes e modelos estatísticos de modo a criar uma análise interpretativa dos dados e, posteriormente, um teste quanto à correlação dos dados obtidos entre os mercados. Isto para um período de janeiro de 2000 a outubro de 2017.

### **1.2. Objetivos do Estudo**

Ao longo da recente década, têm sido realizados inúmeros estudos interpretativos de mercados com diferentes horizontes temporais e diferentes abordagens de interpretação desses dados. Onde, além de ser necessário o estudo contínuo dos mercados ao longo

das suas sessões, torna-se útil formas inovadoras de interpretação das mesmas e as suas abordagens no momento de investimento.

Assim sendo, os objetivos desta investigação consistem, numa primeira fase, recolher informações bibliográficas, com vista a conhecer o universo de instrumentos ao dispor do estudo e do estado da arte que os mercados já incorporam. Numa segunda fase, aplicar alguns instrumentos mais recentes numa ótica inovadora, de modo a criar resultados para novas interpretações. E, por fim, direcionar o estudo para uma gestão de carteira ponderada nos resultados obtidos, enriquecendo o estado da arte das Ciências Financeiras.

### **1.3. Metodologia Geral**

O estudo é realizado com dados obtidos pela *Bloomberg*, dia a dia, referente a doze mercados selecionados por ordem geográfica, dos principais Índices de ações mundiais: os Índices Americanos, *Standard & Poor's (S&P)* e *Ibovespa*; Os Índices Europeus, *Euro Stoxx 50*, *Financial Times Stock Exchange 100 (FTSE 100)*, *Iberia Index 35 (IBEX 35)*, *Cotation Assistée en Continu 40 (CAC 40)*, *Deutscher Aktien Index 30 (DAX 30)*, *Portuguese Stock Index 20 (PSI 20)* e *Milano Indice di Borsa (FTSE MIB)*; E, por fim, os Índices Asiáticos, *Shanghai Stock Exchange (SSE Composite Index)*, *Nikkei heikin kabuka 225 (Nikkei)* e, junto aos Índices Asiáticos, por conveniência, o *Australian Securities Exchange (S&P/ASX 200)*; num período compreendido entre Janeiro de 2000 a Outubro de 2017.

Onde, primeiro, após um devido tratamento financeiro, serão analisados estatisticamente a qualidade dos dados e o perfil observado. Assim, posteriormente, serão realizados testes à correlação da rendibilidade e risco dos mercados e interpretados os resultados numa ótica geográfica, de modo a aferir a sensibilidade entre mercados. Em segundo, os mesmos índices, serão analisados hora a hora num intervalo de tempo compreendido entre abril a outubro de 2017. Fazendo uso das ferramentas fornecidas pelo estado da arte, serão elaborados modelos estatísticos de análise de GARCH e de médias móveis, de modo a tentar compreender se existe alguma correlação entre mercados a nível de

variância e se existe [ainda] alguma possível previsibilidade de resultados entre mercados, via diferença horária, através do uso desses mesmos modelos.

#### **1.4. Estrutura da Dissertação**

De modo a alcançar os objetivos propostos, a dissertação está organizada em quatro capítulos. O primeiro capítulo é dedicado à Introdução. No qual é mencionado o objeto e objetivos do estudo, com as consequentes metodologias aplicadas, de modo a introduzir uma interpretação geral da sua estrutura.

Em seguida, o segundo capítulo é dedicado ao Enquadramento Teórico. Este baseia-se no enquadramento ao tema do estudo, onde inicialmente são abordados os temas gerais da área Financeira, a nível de mercados, e, posteriormente, um aprofundamento mais técnico de modo a criar uma contextualização para interpretação dos resultados. No qual são abordados os temas de Mercados Financeiros, a Eficiência e Anomalias dos Mercados e, por fim, o conceito de Gestão de Carteiras. Em que é criada uma conceção do risco, rentabilidade e tipos de mercados, necessária para a interpretação e perfil para o Estudo Empírico.

Assim sendo, no terceiro capítulo é colocado o Estudo Empírico. Uma vez conhecendo o ambiente teórico do tema, é fornecida a base de dados e a metodologia a ser efetuada de modo a conseguir obter os resultados propostos com o objetivo do projeto. Em seguida, é descrito e caracterizado o estudo como preparação dos dados. Que, por sua vez, é distribuído por duas partes: estudo dia a dia e estudo à hora. Relativamente à primeira, o horizonte temporal é mais alargado, de 2000 a 2017, compreendendo uma tendência geral histórica de médio a longo prazo. Enquanto à segunda, o horizonte temporal é diminuído para 2017 apenas, de modo a tentar prever o comportamento dos mercados por ordem horária, uma vez conhecido a tendência genérica. Assim, por fim, será possível concluir o estudo enquadrado teoricamente, com devidas sugestões para futuros estudos.

Finalizando a dissertação, o capítulo quatro é destinado à Conclusão. Onde é possível encontrar um apanhado geral dos resultados obtidos que desenvolvem o estado da arte,

no qual é evidenciado a conclusão geral, as limitações da investigação e as considerações relevantes.

## 2. Enquadramento Teórico

### 2.1. Mercados Financeiros

A globalização tem criado um grande impacto nas mais diversas áreas, pela sua importância, os mercados financeiros é um dos setores onde esse processo foi mais evidenciado, por consequência, apesar de na sua essência ser comum, a sua definição também tem sofrido alterações.

Na década de 60 e antecedentes, derivado ao termo Mercados Financeiros ter surgido ligado ao mundo de negócios, este era associado como o mercado de ações – *stock market*. No entanto, com o desenvolvimento do conceito e o seu despertar de interesse a nível científico, esse conceito alargou-se a outras noções, como mercado: monetário, de capitais e de valores mobiliários. Segundo Adambekova & Andekina (2013), num estudo sobre interpretação da definição de Mercados Financeiros por diversos autores, nos tempos correntes, o termo pode ser segmentado em três vertentes: *Monetary Concept*, *Capital Market* e *Segmented Concept*. Onde, no entanto, segundo uma definição abrangente e consensual, que será aplicada neste trabalho doravante, os mercados financeiros são designados como qualquer fórum onde compradores e vendedores se encontram, de modo a fazerem trocas – *trading* – dos mais diversos ativos. Sendo este último, geralmente, ativos financeiros, como: ações, obrigações, opções e derivados. Por ativos financeiros entende-se o direito sobre ativos reais, isto é, bens que servem para satisfazer necessidades sociais ou para produzir outros bens ou serviços.

Os mercados financeiros são um pilar de uma economia capitalista, onde este fornece, a empresários e empresas, um meio de acesso direto a financiamento e liquidez, bem como um acompanhamento de preços dos diversos bens. Relativamente ao financiamento, as empresas podem emitir dívida ou ceder parte de participação do negócio a compradores, com o fim de conseguir sustentar novos projetos, reduzindo o risco associado (Ferreira, 2008). Quanto à liquidez, esta é criada pela facilidade de comunicação entre os compradores e vendedores trocarem os seus títulos, por consequência, quanto maior o volume de *trades* no mercado, maior a liquidez. Sem esta estrutura de mercado, os vendedores tinham de procurar compradores de formas menos eficientes, como, por exemplo, através de anúncios. Uma outra vantagem, de uma localização centralizada,

passa pela transparência do preço e da quantidade. Isto é, os compradores conseguem acompanhar qual o preço que, globalmente, o ativo é avaliado e comprarem esses ativos a um valor mais justo, bem como a observação do volume de trocas desses mesmos bens.

Devido ao mercado estar sujeito à lei da oferta e da procura, os mercados sofrem volatilidades de diferentes acentuações, derivado a diversos fatores, sendo alguns deles: o grau de desemprego, o Produto Interno Bruto (PIB), pressão de setores, como por exemplo, o preço de imóveis, entre as mais diversas possibilidades. A complexidade de interpretação depende de cada mercado, não só pelo ativo transacionado, bem como pelos intervenientes - compradores e vendedores - desse mesmo ativo. Essa mesma complexidade fomenta interesse a nível científico nesta área. Além do interesse científico e da participação num mercado, a volatilidade atrai investidores com os mais diversos objetivos e interpretações. Onde se entende por investidor, segundo o Guia de Investidor publicado pela Comissão de Mercado e Valores Mobiliários (CMVM) (2017), que “investidores são todas as pessoas ou empresas que participam no mercado de capitais com o objetivo de, através do financiamento das empresas, valorizarem as suas poupanças ou os seus ativos” (p.68). Entenda-se, assim, por alguém que renuncia ao consumo no imediato e planeia o consumo a prazo, via acumulação de rendimento.

Existem duas grandes componentes de mercados financeiros, Mercado Monetário e Mercado de Capitais (ver Esipov (2004), Kidwell et al. (2000), Sacks & Larren (1996), Barinov & Khmyz (2001), Dolan, Campbell, & Campbell (1993), Mankiw (1994) e outros). Quanto ao Mercado Monetário, é neste onde Instituições Financeiras e emissores de dívida trocam fundos de curto prazo para resolver necessidades de liquidez, onde os instrumentos têm uma maturidade inferior a um ano. Relativamente ao Mercado de Capitais, a sua maior componente é o Mercado de Valores Mobiliários, na qual este é subdividido em outras duas grandes partes, em primeiro, o Mercado Primário e, em seguida, o Mercado Secundário. Quanto ao Mercado Primário, é onde são lançadas as ofertas públicas iniciais (*IPO*) de uma empresa privada que procure financiamento pela via de emissão de dívida, venda de participação na empresa ou outros produtos híbridos. Ou seja, uma entidade competente que ajuda no processo e decidem em conjunto qual o tipo de dívida a contrair. Após essa decisão, a entidade competente calcula qual o valor para a quantidade a ser lançada para o Mercado Secundário, onde se situam os mais

diversos investidores, sendo essa entidade competente que corre o risco na venda dessas participações ao público. É no Mercado Secundário que há acesso ao Mercado de Ações, Mercado de Obrigações, Mercado de *Commodities* e Mercado de Futuros e Derivados (ver Figura 1).

Mercado Monetário	Mercado de Capitais							
	Outro Mercado de Investimento			Mercado de Valores Mobiliários				
	Fundos Mútuos	Garantias de Depósito, Pensões, outros instrumentos de remuneração sem risco	Seguros	Mercado Primário		Mercado Secundário		
				Ofertas Públicas Iniciais (IPO)	Outros	Mercado de Ações	Mercado de Obrigações	Mercado de Commodities, Mercado de Futuros e Derivados

Figura 1 – Ilustração da Organização do Mercado de Capitais

No Mercado de Valores Mobiliários, foram criados Índices de modo a medir, estatisticamente, o mercado em causa como um todo. Na prática, o autor Lo (2016) define um Índice como uma média ponderada de uma lista específica, e relativamente estática, de títulos. Atuando como um indicador da variação de risco ao longo do tempo *versus* a rentabilidade, alargando a sua utilidade como *benchmark* para análise de *performance*, ponderação e melhoramentos. Existindo diversas entidades que conceberam Índices de referência de modo a traduzir mercados e setores económicos, como por exemplo, o *Standard & Poor's 500 (S&P 500)*. Que tem selecionado, de forma ponderada, no seu portefólio, quinhentas empresas Norte Americanas de modo a tentar refletir o comportamento do mercado Norte Americano. Embora não seja possível comprar índices, é possível replica-los ou aplicar em fundos de Instituições Financeiras que replicam esses índices e fazem a sua gestão. Além disso, o conceito de índice tem uma enorme aplicabilidade na área das Ciências Financeiras. Uma vez que pode ser assumido como um indicador do mercado, diversos modelos foram criados em torno desse conceito, como por exemplo, o *Capital Asset Pricing Model (CAPM)* no auxílio ao cálculo do custo do capital, na gestão de uma empresa.

No que respeita à metodologia de construção, um Índice pode ser classificado através de dois critérios, o critério pelo cálculo da média e o sistema por ponderação, por exemplo, pelo preço. Sendo, este último, designado por índice de valor ponderado, onde envolvem a capitalização total ponderada de mercado das empresas pelo seu efeito no índice, levando a que as maiores ações tenham mais peso no índice quando comparado com empresas mais pequenas. Veja-se, por exemplo, o mercado de ações Português (PSI 20). Trata-se de um Índice de seleção, gerido pela *Euronext Indices B.V.* com critérios de seleção quanto ao número de sessões em bolsa<sup>1</sup> e posterior hierarquização em função do valor transacionado calculado com base na informação estatística mais recente<sup>2</sup> sendo as 20 primeiras a pertencer ao Índice (*Euronext*, 2003).

Sendo a fórmula matemática de cálculo dos índices PSI a seguinte:

[1]

$$\text{Índice}_t = \frac{\sum_{i=1}^n p_{i,t} \cdot q_{i,t}}{d_t} \times base$$

Onde:

$n$  = número de emissões integrantes da carteira no momento  $t$ ;

$p_{i,t}$  = última cotação da  $i$ -ésima emissão integrante da carteira no momento  $t$ ;

$q_{i,t}$  = número de ações de  $i$ -ésima emissão integrante da carteira no momento  $t$ ;

$d_t$  = divisor vigente no momento  $t$ .

O divisor resulta do quociente entre a capitalização bolsista da carteira e o respetivo valor do índice, conforme se ilustra seguidamente:

[2]

$$d_t = \frac{\text{Capitalização Bolsista}_{t_0}}{\text{Índice}_{t_0}} \times base$$

---

<sup>1</sup> Obrigatoriedade de vinte sessões contínuas em bolsa.

<sup>2</sup> Referente a um período de 6 meses.

Na qual  $t_0$  é a data em que se verificou o último ajustamento à base de cálculo do índice. O divisor tem, pois, a particularidade de se manter constante até que haja lugar a um ajustamento à base de cálculo do índice, pelo que é um instrumento expedito para o seu cálculo, bastando para tal conhecer a informação da capitalização bolsista do índice, dividi-la pelo divisor e multiplicá-la pela base.

Assim sendo, pode-se verificar que o peso de cada componente integrante no Índice fará alterar todo o comportamento do mesmo. Tanto a nível de preço, bem como a nível de risco. Sendo aqui o risco avaliado pela variância do Índice. No entanto, sendo um índice uma carteira de ações, é ainda relevante avaliar o coeficiente de correlação, uma vez que, a partir de correlações muito fortes, a sua diversificação poderá não traduzir o melhor perfil para alguns investidores.

## **2.2. Eficiência de Mercados e Anomalias**

A eficiência de Mercados, segundo o economista Fama (1970), surge como o conceito de que os Mercados refletem toda a informação disponível. Para o mercado ser, totalmente, eficiente, os preços dos produtos financeiros respondem no imediato. Pelo contrário, se assimilarem a informação de forma gradual, o Mercado revela alguma ineficiência, de acordo com esse *delay*. Com este conceito em mente, Fama formulou a teoria da *Efficient Market Hypothesis* (EMH). Na qual defende a impossibilidade de qualquer investidor em superar o mercado, uma vez que toda a informação já está retido no preço do ativo. Contudo, segundo Buffet & Connors (2010), o Mercado apresenta níveis de ineficiência pelos mais diversos fatores. Fama, no entanto, na sua teoria, compreende essa possibilidade e apresenta três graus de eficiência. A primeira, eficiência fraca, onde se situam os analistas técnicos, que se baseiam nos preços e volumes de transações passadas de modo a conseguir prever o futuro. Em segundo grau, uma eficiência semi-forte, da qual fazem parte as análises fundamentais, onde, além da análise histórica, incorporam informações públicas, isto é, informações económicas e contabilísticas, dividendos, qualidade de gestão, perspectivas sobre novos projetos, etc. E por fim, uma eficiência forte, na qual se aceita que os preços já refletem toda a informação

disponível, seja ela pública ou privada, conferindo assim uma gestão passiva de portfólio e investindo no negócio em si.




Figura 2 – Gráfico ilustrativo de Ineficiência e Eficiência

O Mercado assume eficiência e ao mesmo tempo alguma ineficiência. Relativamente à eficiência, uma vez que o preço procura sempre o seu valor real, é esperado que o mercado se aperceba do seu valor e se dê a harmonização para o valor real. No entanto, existem sobre e subreações. Isto é, segundo Buffet & Connors (2010):

*“the price of a stock can be influenced by a “herd” on Wall Street with prices set at the margin by the most emotional person, or the greediest person, or the most depressed person, it is hard to argue that the market always prices rationally.”* (Buffet & Connors 2010, p. 233)

Demonstrando que existe ineficiência com base nas emoções das pessoas e no efeito em massa. Conferindo, por vezes, alguma sobre ou subreação a um determinado produto. Contudo, é esperado que a sua *performance* real venha a ser atingida ao longo do tempo. Keown & Pinkerton (1981) define estes acontecimentos como anomalias. No qual evidenciaram a possibilidade de rendimentos anormais antes do anúncio de uma Oferta Pública de Aquisição (OPA) (ver Figura 3).




Figura 3 – Reação a notícias de OPA (Fonte: *Journal of Finance*, Volume 36, p. 861)

O estudo consiste nos valores médios das cotações das ações de 194 empresas objeto de OPA, na qual foi demonstrado rendimentos anormais implícitos nas cotações, dias antes dessa ordem. A relação entre as anomalias de mercados e a consequente ineficiência, dita a complexidade e as mais diferentes análises que cada mercado e indivíduo podem concluir. Onde, por base, Fama e a sua teoria de Eficiência por diferentes graus tem fundamento para ser considerado válido, de acordo com o tipo de análise que se pretenda realizar, nunca esquecendo as diversas limitações e qual o objetivo pretendido.

### 2.3. Gestão de Carteiras

Uma carteira, de ativos, também definido como Portefólio, corresponde aos títulos detidos por um investidor. Numa carteira, podem existir diferentes tipos de ativos financeiros, sendo eles: de rendimento fixo, variável e de derivados. Quanto aos ativos de rendimento fixo, por via de participação em dívida, existem obrigações, bilhetes de tesouro e certificados de depósito. Relativamente a rendimento variável, isto é, representativos de capital, ações. E por fim os derivados, na qual o seu valor depende da evolução do valor de outros ativos, os ativos subjacentes, sendo alguns deles: opções, futuros, *swaps* e entre outros. Existem ainda diferentes tipos de gestão de carteiras, Gestão Passiva e Gestão Ativa. A primeira compreende que o mercado é eficiente e não tem a necessidade de ser atualizada de forma contínua, onde é criado uma réplica de um índice de mercado, acompanhando o seu crescimento ao longo do tempo. Quanto à última, é necessária uma análise contínua dos títulos, determinar quais os momentos adequados para atuar no mercado, procurar rendimento através da sub e sobreavaliação, analisar padrões de comportamentos e entre outras análises diversas. Independentemente do tipo de gestão, a mesma é de extrema importância de modo a selecionar os títulos racionalmente, de modo a constituir uma carteira diversificada. Bem como determinar os níveis de risco apropriados, conforme o perfil de risco do investidor. E ainda, procurar a eficiência fiscal, uma vez que a fiscalidade pode ter diferenciação em função dos emitentes ou da sua natureza.

De modo a construir uma carteira, é necessário criar poupança e posteriormente investir nos ativos que estejam de acordo com o tipo de investidor e com o seu plano. Uma vez que investir é renunciar ao consumo no imediato, decidir em que ativos aplicar essa poupança e saber avaliar qual o perfil de investidor, de modo a obter rendimento, constitui um elaborado plano e foco de análise científica. No qual o economista *William F. Sharpe*, vencedor do prémio nobel da Economia em 1990, criou o modelo *Capital Asset Pricing Model* (CAPM). O modelo calcula o retorno esperado baseado nos diferentes níveis de risco, demonstrando que para obter uma maior rentabilidade é necessário incorrer em mais risco. Assumindo assim que a volatilidade, isto é, a oscilação dos preços em relação ao seu preço médio, dita o risco e bem como o rendimento de uma carteira. Denominado o risco e a possibilidade de calcular a rentabilidade através do modelo CAPM, *William Sharpe* propôs um rácio entre o prémio de risco e o desvio padrão. No qual se entende

por prêmio de risco, a diferença entre o rendimento do título por um outro ativo sem risco, por exemplo, bilhetes de tesouro de um país. Conferindo a este rácio uma forma de avaliar a qualidade do título, em função do seu retorno pelo risco.

Estas necessidades surgiram da questão da evidenciada por Elton & Gruber (1977), em criar uma carteira diversificada de modo a minimizar o risco.

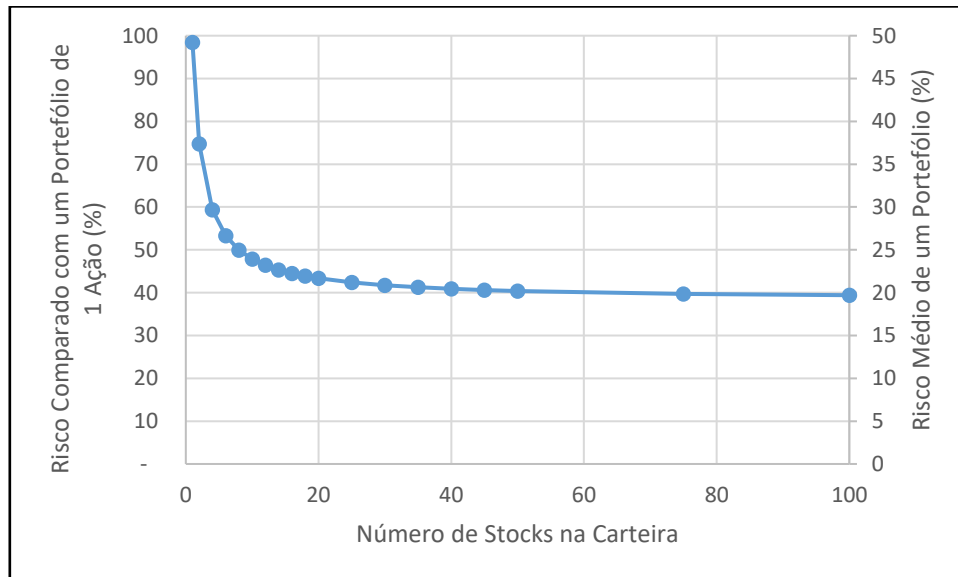


Figura 4 – Gráfico ilustrativo da diversificação do portefólio.

De acordo com Statman (1987), quanto maior o número de títulos em carteira, menor o risco. Por auxílio da Figura 4, verifica-se que o Desvio Padrão médio dos rendimentos de portefólios compostos por uma ação apenas é de 49,2%. O Risco médio do portefólio diminui bastante quanto maior o número de stocks, reduzindo a um máximo de 19,2%. Embora a quantificação tenha sido demonstrada nos anos 80, o conceito de diversificação já era anteriormente teorizado. Harry Markowitz, em 1952, publicou um modelo formal de seleção de carteiras. Tendo sido este o primeiro passo para a gestão de carteiras, com a identificação da fronteira eficiente de ativos de risco.

### 3. Estudo Empírico

#### 3.1. Metodologia

As Ciências Financeiras têm sofrido grande foco a nível científico ao longo destas últimas décadas. As diferentes possibilidades de abordagens foram enriquecendo o tema e mudando conceitos e perspectivas ao longo dos anos. Não apenas pela criatividade a nível de análises, mas bem como o próprio mercado, por força da competitividade, incorpora toda a evolução que é feita a nível científico. Assim sendo, é esperado que esta área seja alvo de uma constante inovação e, conseqüentemente, análise de impacto e das suas razões.

A presente investigação pretende abordar o tema de gestão de carteiras através de análises multivariadas em torno de Índices de Mercado. Isto é, através de diferentes estudos a nível histórico de diversos Índices, abordar diferentes aproximações e conceitos que maximizem a possibilidade de criar uma carteira mais rentável e com minimização do risco, para os diferentes perfis de investidor.

O estudo, numa primeira fase, é realizado com base em dados obtidos pela *Bloomberg*, relativamente a doze, dos principais, Índices de ações mundiais. A seleção de Índices segue uma linha lógica de natureza geográfica, ou seja: os Índices Americanos, *Standard & Poor's (S&P)* e *Ibovespa*; Os Índices Europeus, *Euro Stoxx 50*, *Financial Times Stock Exchange 100 (FTSE 100)*, *Iberia Index 35 (IBEX 35)*, *Cotation Assistée en Continu 40 (CAC 40)*, *Deutscher Aktien Index 30 (DAX 30)*, *Portuguese Stock Index 20 (PSI 20)* e *Milano Indice di Borsa (FTSE MIB)*; E, por fim, os Índices Asiáticos, *Shanghai Stock Exchange (SSE Composite Index)*, *Nikkei heikin kabuka 225 (Nikkei)* e, junto aos Índices Asiáticos, por conveniência, o *Australian Securities Exchange (S&P/ASX 200)*; num intervalo compreendido entre Janeiro de 2000 a Outubro de 2017. Posteriormente, numa segunda fase do estudo, os mesmos Índices, com dados obtidos pela *Bloomberg*, são analisados diariamente, à hora (*intraday*), no período de 2017, relativamente a janeiro até outubro.

Os métodos para análise de dados são sucessivos testes de hipóteses quanto à correlação das rendibilidades e variância. Inicialmente os dados são tratados através de um algoritmo criado para o estudo, de modo a organizar os Índices por datas iguais.

Excluindo quaisquer dados que não possam ser comparados. Posteriormente é aplicado a fórmula de cálculo da rendibilidade e traduzidos para uma perspectiva diária pela taxa de equivalência, conferindo a possibilidade de comparação entre índices.

Após as observações estarem tratadas e em conformidade para análise, serão realizados testes quanto à correlação, através do Coeficiente de Pearson e Matrizes de Correlação. Sendo assim possível compreender as relações entre os mercados para o período de 2000 a 2017, tanto a nível de rendibilidades bem como de variação de risco, a nível geográfico.

Posteriormente, a nível de *intraday*, serão aplicadas análises autorregressivas de GARCH e um modelo de estimativa de valores esperados através de médias móveis derivado do GARCH, o *Exponentially Weighted Moving Average (EWMA)*. Os *outputs* desses modelos serão alvo de análise quanto à hipótese de possível previsão de comportamento de mercados em função de outros devido às diferenças horárias, bem como quanto à aplicabilidade a nível de enquadramento teórico para a gestão de carteiras. Por fim, após desenvolvido o modelo, é adicionado o conceito de médias móveis de modo a incrementar uma variável de *forecast* de longo prazo, sendo assim possível comparar os mercados pelas suas diferenças horárias quanto aos comportamentos da variância.

Assim sendo, o objetivo da presente investigação consiste, numa primeira fase, recolher informações quanto ao estado da arte. Isto é, entender as diferentes abordagens já realizadas e compreender a aplicabilidade das mesmas nas observações correntes. Numa segunda fase, encontrar modelos que tentem analisar comportamentos e que possam criar uma explicação prática para interpretação dos dados observados. E por fim, aplicar os modelos que possam ser usados no presente de modo a constituir alguma força de interpretação, auxiliando para uma visualização mais nítida do futuro. Com isto, serão inseridos, no estado da arte, novas óticas quanto à criação de gestão de carteiras, recorrendo a instrumentos recentemente utilizados nas Ciências Financeiras.

### 3.2. Caracterização e Descrição do Estudo

O estudo segue uma lógica de convergência ao longo da sua apresentação. Isto é, inicialmente os doze índices vão ser, diariamente, analisados quanto a um intervalo temporal de dezassete anos e dez meses e, posteriormente, apenas a um intervalo de dez meses, relativo ao ano de 2017, com dados à hora. Assim sendo, é possível estudar qual a tendência geral no horizonte temporal de, quase, dezoito anos e, posteriormente, interpretar o ano de 2017 e quais as diferenças quanto ao seu comportamento geral. Os doze índices selecionados seguem uma escolha geográfica com preferência de grandeza e de transação, ou seja, são apenas mercados que têm movimentações diárias e existem dados históricos consistentes de modo a ser possível criar um estudo. Criando assim algumas limitações no facto de existirem mais índices Europeus em relação às restantes áreas, forçando a uma análise ponderada.

Relativamente aos dados obtidos para análise ao período de 2000 a 2017, a fonte é da *Bloomberg* com uma amostra média, das cotações dos 12 mercados, de 4490 observações ( $n = 4490$ ) por cada mercado, com um número de observações totais de 53880 ( $N = 53880$ ). No entanto, para análise, é necessário que haja coerência a nível de datas. Deste modo, foi elaborado um tratamento de dados através de um algoritmo criado na linguagem de programação *Python*<sup>3</sup>. O *input* são os dados, em bruto, observados de cada mercado ao longo do período em estudo ( $n = 4490$ ), criando o *output* - por fator de eliminação de todos as observações relativas a dias que não estejam em, pelo menos, um mercado - de dados tratados com 3684 observações por cada mercado ( $n = 3684$ ), num universo de 44208 observações ( $N = 44208$ ). Concluindo que, com o tratamento, foram descartadas 9672 observações que não tinham ligação aos mesmos horizontes temporais em todos os mercados.

Posto isto, com a condição de manter os dados às mesmas datas pelos 12 mercados satisfeita, é necessário absorver informações das mesmas que tornem possível a comparação entre os mercados. De acordo com Strong (2009), a forma mais viável de comparação, tanto a nível de risco como de movimentação de preços, é através do

---

<sup>3</sup> Trata-se de uma linguagem de programação desenvolvida por Guido van Rossum em 1991, com modelo *open source*.

cálculo das rendibilidades, pelo método logarítmico. No qual a fórmula é obtida pela seguinte equação:

[3]

$$R_d = \ln\left(\frac{P_d}{P_{d-1}}\right)$$

Em que:

$R_d$  = Rendibilidade no período  $d$ .

$P_d$  = Preço de fecho no momento  $d$ .

$P_{d-1}$  = Preço de fecho no momento  $d - 1$ .

Deste modo, torna-se possível a comparação entre índices, independentemente do tipo de moeda a que o mercado seja transacionado. No entanto, ainda existe inconsistência dos dados diários, por força do tratamento das observações por eliminação de dias sem correspondência entre os mercados. Isto é, em médias os mercados estão abertos 260 dias, sendo esperado cerca de 4600 observações por mercado, no entanto, após tratamento, foram obtidas 3684 observações ( $n= 3684$ ), ou seja, uma diferença média negativa de 916 observações por mercado. Traduzindo num padrão assimétrico de dados diários. Para resolver a inconsistência encontrada, foram empregues as regras de equivalência de taxas. Uma vez que alguns dados podem ter um reporte de horizonte temporal diferente dos restantes, é aplicada a fórmula de equivalência de taxas para diárias em todas as parcelas das rendibilidades:

[4]

$$R'_d = (1 + R_d)^{\frac{1}{(d)-(d-1)}} - 1$$

Que por sua vez:

$R'_d$  = Rendibilidade no momento  $d$  equivalente ao período  $(d) - (d - 1)$ .

$R_d$  = Rendibilidade no período  $d$ .

$d$  = Momento  $d$ .

$d - 1$  = O período anterior a  $d$ .

Deixando assim a possibilidade de análise entre mercados, independentemente: da tipologia de moeda das cotações de cada mercado, de incongruência de datas e divergência temporal. Pese embora algumas limitações do cálculo das rendibilidades através da função logarítmica que têm de ser consideradas no momento de avaliação. Isto é, de acordo com Dissanaiké & Le Fur (2003), existem alguns problemas que a função logarítmica coloca quando aplicado entre setores, concluindo a necessidade a que estes sejam aplicados com cuidado quanto à natureza dos dados. Kothari & Warner (1997) e Barber & Lyon (1997), revelam ainda que a função logarítmica cria uma assimetria negativa dos dados, tornando os dados a perder alguma informação ou a não se tornar específica o suficiente para algumas conclusões. E na área de avaliação de rendibilidades de investimentos a longo prazo, é debatido se o logaritmo ou uma simples média mais trabalhada de adequação, aos investimentos, se torna mais apropriado, de modo a avaliar as rendibilidades (Jacquier, Kane, & Marcus, 2003).

Por fim, os dados obtidos foram analisados individualmente gráfica e analiticamente, através da aplicação *Statistica*, quanto à Média, Quartis, Variância e Desvio Padrão, Curtose e Enviesamento. As análises foram ainda consideradas quanto à sua distribuição geográfica e impactos. Na qual o seu aprofundamento se segue com a correlação, através do Coeficiente de *Pearson*. Onde foram obtidas duas matrizes de 12 por 12, quanto a correlações da rendibilidade e de risco, com interpretação geográfica. Sendo ainda avaliado a Capacidade Explicativa que cada mercado tem num outro e os impactos inter e intracontinental.

Numa segunda fase, o estudo converge para o ano 2017 com início em 18 de abril até 31 de outubro. Na qual, as observações são à hora e relativo a todos os dias que cada mercado está aberto. A população foi obtida na base de dados da *Bloomberg* em novembro de 2017. A amostra é constituída por 13517 observações ( $N = 13517$ ), com

uma média de 1126 observações por mercado ( $n = 1126$ ). Contudo, pelo fator de incongruência de datas e divergência temporal, a amostra fora reduzida, por força da elaboração de tratamento de dados através de um algoritmo criado na linguagem de programação *Python*. Que reproduziu o *output* de uma população amostral de 11181 observações ( $N = 11181$ ), com uma média de 931 observações por mercado ( $n = 931$ ). Com consideração que, ao contrário do estudo anterior, este estudo tem mercados com quantidades amostrais diferentes, apenas de modo a obter melhor qualidade na aplicação dos modelos, contudo, na altura de análises, foram usados apenas dados que se encontram em conformidade com o exigido para aplicar cada modelo.

Deste modo, conhecendo os dados para análise, é feito um primeiro estudo do comportamento dos dados e correlações dos Desvios Padrão. Tanto para uma *timeframe* à hora como ao dia. Assim, é possível aferir as diferenças de correlação e a diferença que o peso da *timeframe* dita quanto ao ruído causado na análise de correlações dos mercados, mas bem como também quanto à colisão horária. Em seguida, é apresentado o modelo GARCH, as suas condições e o seu propósito. De modo a satisfazer a possibilidade dos dados, é feito um teste de hipótese dos dados quanto à sua normalidade. Posteriormente, é definido quais as ponderações das parcelas empíricas, para cada mercado, do modelo através do método de verosimilhança e selecionado o modelo de GARCH(1,1) como o modelo para análise. Sendo [assim] definido com parcelas de *lag*, tanto para a variância condicional como para o erro, de 1 período, de modo a criar resultados mais próximos dos seus acontecimentos e com menor peso histórico.

Em seguida, com os instrumentos selecionados e denominados, é elaborado a aplicação dos mesmos numa análise referente a cada mercado e o quão próximo consegue acompanhar o comportamento real da variância ao longo de 114 dias, 5 horas por dia ( $n = 570$ ). Após conhecida a viabilidade de GARCH(1,1) como instrumento de sensibilidade do comportamento da variância de cada mercado para períodos subsequentes, o mesmo modelo é aplicado entre mercados numa combinação de 12 por 12 na tentativa de absorver o sentido da variância observada num mercado, com horário anterior, de modo a correlacionar com um mercado posterior, na tentativa de *forecasting*. Para o efeito, são utilizadas as médias móveis de modo a solucionar a diferença horária e transpor os dados para os períodos seguintes.

### 3.2.1. Análise dos Mercados

Empiricamente, é conhecido que as rendibilidades não seguem uma distribuição normal (ver Fama (1965), Rosenberg (1974), (1976)). No entanto, de modo a contornar essa adversidade, é utilizado um universo de valores suficientemente grande de modo a constituir uma amostra aproximadamente normal, ao abrigo do **Teorema do Limite Central (TLC)**. Segundo Sheikh & Qiao (2009), *advisors* na *J.P. Morgan Asset Management*, a maioria das rendibilidades dos diferentes ativos não segue uma distribuição normal.

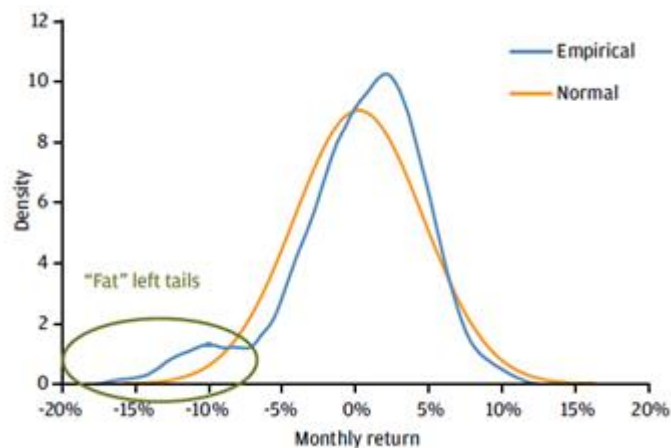



Figura 5 - Gráfico da JP Morgan sobre “International Equities – “fat” left tails in historical returns” (Fonte: J.P. Morgan Asset Management study, 2009)

Veja-se a Figura 5, os autores observaram que a função logarítmica exerce um peso maior nos limites inferiores, o que pesa no teste à normalidade. Onde se vai notar, com mais acentuação, na altura de efetuar a simetria do limite inferior sobre o superior. No entanto, quanto maior o universo da amostra, maior será a tendência de procurar uma normalidade, por vias de correção da largura da curva, corrigindo pela altura da cauda inferior. Assim sendo, é esperado que a simetria não seja encontrada nos limites da curva, no entanto existe uma maior simetria na área central da curva, isto é, dentro de um ou dois desvios padrão. Pese embora o facto de todos os mercados, no estudo, estarem em conformidade com o TLC ( $X' \sim N$ ). Foram elaborados dois testes estatísticos

quanto à normalidade das observações para cada índice através da plataforma *Statistica.*, o *Chi-Square* e o *Jarque-Bera*.


Variable	Valid N	Mean	Median	Minimum	Maximum	Percentile 25.00000	Percentile 75.00000	Variance	Std.Dev.	Skewness	Kurtosis	Sum Sq. Dev.
S&P	3684	0.00011254	0.000394	-0.0947	0.1025	-0.0036	0.004297	0.000111	0.0105	-0.2684	9.8900	0.4086
Ibovespa	3684	0.00039718	0.000313	-0.1210	0.1260	-0.0069	0.007929	0.000235	0.0153	-0.1879	5.1943	0.8648
Euro Stoxx 50	3684	0.00002078	0.000184	-0.0901	0.0808	-0.0054	0.005511	0.000165	0.0129	-0.2440	4.9338	0.6094
FTSE100	3684	0.00000227	0.000249	-0.0927	0.0847	-0.0042	0.004547	0.000107	0.0104	-0.2935	8.0145	0.3953
CAC 40	3684	0.00005682	0.000253	-0.0838	0.0887	-0.0054	0.005768	0.000161	0.0127	-0.1514	5.5504	0.5940
DAX	3684	0.00011354	0.000488	-0.0727	0.1069	-0.0051	0.005716	0.000168	0.0130	-0.1110	5.2401	0.6183
IBEX 35	3684	0.00010557	0.000439	-0.1319	0.0900	-0.0056	0.005871	0.000172	0.0131	-0.4085	7.3124	0.6343
FTSE MIB	3684	0.00006828	0.000405	-0.1333	0.0941	-0.0055	0.005816	0.000178	0.0133	-0.4005	6.8560	0.6562
PSI 20	3684	-0.00014827	0.000120	-0.0725	0.0772	-0.0044	0.004485	0.000109	0.0104	-0.3439	5.0128	0.3999
Shanghai	3684	0.00000435	0.000410	-0.0926	0.0940	-0.0052	0.005669	0.000180	0.0134	-0.2206	6.7498	0.6620
S&P/ASX 200	3684	0.00009644	0.000411	-0.0870	0.0426	-0.0036	0.003961	0.000074	0.0086	-0.8065	7.7538	0.2737
Nikkei	3684	-0.00005797	0.000324	-0.1211	0.0949	-0.0057	0.006040	0.000170	0.0130	-0.7967	9.8417	0.6246

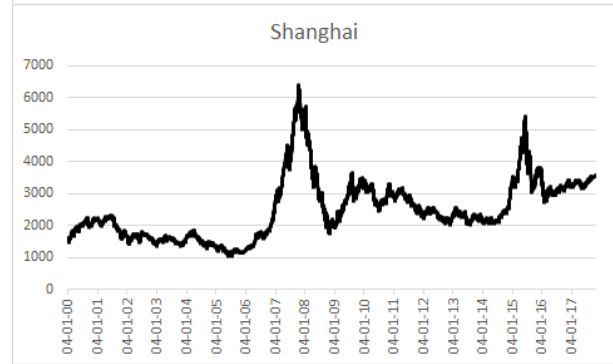




*Tabela 1 - Estatística descritiva das rendibilidades de 2000 a 2017 para cada Índice. Com p-value = 0,05.*




*Figura 6 - Box & Whisker plot das rendibilidade de cada índice, relativamente ao período de 2000 a 2017.*

Por auxílios dos instrumentos, não é possível rejeitar a Hipótese nula ( $H_0$ ) de normalidade das amostras, ao abrigo do TLC e quanto ao teste da soma dos quadrados – *Chi-Square* – por não haver significância para a sua rejeição. Contudo, elaborando o teste *Jarque-Bera*, que avalia a normalidade da amostra quando esta é suficientemente grande ( $N > 2000$ ), forçando a que outros testes não tenham evidência para rejeitar  $H_0$ , demonstra que os dados não seguem uma distribuição normal. Onde, segundo Esch (2003), não cria barreiras quanto à sua utilização e interpretação, o maior problema reside no momento de aplicação de dados para *input* do modelo de seleção de carteira de *Markovic*. É possível ainda verificar que o índice *Ibovespa* segue uma distribuição mais aproximada da normal ( $p\text{-value} = 0.8648$ ) e o *ASX 200* é o mercado com menor aproximação à normal padrão ( $p\text{-value} = 0.2737$ ). Ainda por observação da Tabela 1, é possível verificar que todos os mercados sofrem um enviesamento - *Skewness* – negativo, que se encontra em conformidade com os autores Sheikh & Qiao (2009). A razão deste acontecimento não se prende apenas com o uso de cálculo das rendibilidades através da função logarítmica, mas bem como com o fator da quantidade de dados que se situam no primeiro quartil em função do último. Isto é, o último quartil tem valores superiores ao primeiro quartil, pelo motivo de existir uma média positiva na maioria dos mercados. No entanto, a sua diferença demonstra que a média deveria ser superior ao observado, o que não acontece pelo facto de na primeira metade existirem mais observações a absorverem a segunda metade, fomentando o enviesamento da distribuição – *skewness* - para uma tendência negativa.







*Tabela 2 – Conjunto de Figuras de Movimentações de Cotações dos Mercados no período de 2000 a 2017.*

Numa análise da Tabela 1 com auxílio da Tabela 2, é possível verificar que o índice PSI 20 tem uma média negativa e a cotação do mercado teve, por consequência, uma descida desde 2000. No entanto, existem índices que não têm o mesmo comportamento, isto é, as cotações similarmemente descaram neste período e no entanto têm uma média positiva, como é o exemplo de: *EuroStoxx*, *CAC 40*, *IBEX 35* e *FTSE MIB*. O *EuroStoxx* é uma carteira que tem peso dos restantes mercados Europeus, por consequência, se os mercados sofrerem uma descida, o *EuroStoxx* segue o mesmo caminho. Relativamente aos mercados *CAC 40*, *IBEX 35* e *FTSE MIB*, a razão para este acontecimento prende-se com uma variância mais elevada destes mercados quanto ao *PSI 20*, observável com auxílio da Figura 6. Por consequência, embora sejam observados valores negativos com mais frequência, explicado pela *skewness*, existem valores suficientemente grandes para absorver as observações negativas de modo a criar uma média positiva. No entanto, o mercado não cresceu derivado a que variações muito positivas de cotações baixas têm menos impacto que essas mesmas variações em cotações elevadas. Deste modo, existiram rendibilidades elevadas quando o preço de cotação estava mais baixo, mas não o suficiente para atingir um crescimento do mercado, mas o suficiente para serem absorvidas pelo número de rendibilidades negativas quando a cotação era superior. Por fim, na Tabela 1, existe o estudo de Curtose – *Kurtosis*. Esta medida indica qual a forma que a curva da distribuição assume. Por referência, uma normal padrão, tem uma Curtose de 3. Assim sendo, é possível verificar que todos os índices têm excesso de Curtose quando comparado com uma distribuição normal, que se traduz numa distribuição mais

concentrada no centro que uma distribuição normal, assumindo uma função probabilidade leptocúrtica.

Relativamente à Figura 6, é possível observar que o *Ibovespa* é o índice mais volátil, com um desvio padrão de 0,0153 ( $\sigma = 0,0153$ ) e o mercado Australiano (*ASX 200*) o menos volátil ( $\sigma = 0,0086$ ). Sendo importante revelar que o mercado Europeu, com exceção do *PSI 20* e do *FTSE 100*, têm volatilidades muito semelhantes ( $\sigma \cong 0,013$ ). Por força deste acontecimento, o *EuroStoxx* segue o mesmo comportamento ( $\sigma = 0,0129$ ). Quando observado a Tabela 2, é possível notar que os únicos mercados que decresceram foram o *CAC 40*, *IBEX 35*, *FTSE MIB* e *PSI 20*, forçando a carteira do *EuroStoxx* também a descer.

Concluindo assim que os mercados Europeus, de um modo geral, seguem uma tendência de semelhança em termos de volatilidade e de comportamento de cotações. Pelo contrário, o mercado Norte Americano tem uma volatilidade muito inferior ao Sul Americano, no entanto ambas as cotações obtiveram um crescimento, observável na Tabela 2. Por fim, no mercado Asiático, os três índices cresceram e é possível verificar que o *Nikkei* e o *Shanghai* têm volatilidades muito semelhantes ( $\sigma \cong 0,013$ ), ao contrário do *ASX 200* que é o menos volátil do universo amostral ( $\sigma = 0,0086$ ).

### **3.2.2. Correlação dos Mercados**

De modo a compreender melhor a aplicabilidade do comportamento dos mercados e a sua tradução no momento de composição de uma carteira, torna-se relevante comparar e selecionar dentro do leque de ativos e adequar quanto ao perfil de investidor. Para o efeito, é necessário avaliar quanto à rentabilidade e ao risco, tanto a nível individual, de cada mercado e bem como a nível de correlações entre mercados. Deste modo, é possível selecionar quais os ativos que constituem uma maior possibilidade de rentabilidade e, em conjunto, minimizar o risco por força de diversificação e/ou outros fatores.

Quanto à rentabilidade, é usado a amostra para cada mercado a nível de rentabilidades ( $n = 3684$ ) e estudado quanto ao Coeficiente de Correlação de *Pearson*, medindo o grau

de correlação entre duas variáveis. O *output* do teste é uma matriz de correlações de 12 por 12 (12x12).

Correlações entre as Rendibilidades dos Mercados de 2000 a 2017												
	S&P	Ibovespa	Euro Stoxx FTSE100	CAC 40	DAX	IBEX 35	FTSE MIB	PSI 20	Shanghai	S&P/ASX	Nikkei	
S&P	1											
Ibovespa	0.6135	1										
Euro Stoxx 50	0.5717	0.4373	1									
FTSE100	0.5294	0.4425	0.8756	1								
CAC 40	0.5477	0.4284	0.9766	0.8838	1							
DAX	0.6008	0.4378	0.9294	0.8001	0.8852	1						
IBEX 35	0.5066	0.4161	0.9052	0.7876	0.8763	0.7888	1					
FTSE MIB	0.5084	0.4029	0.9062	0.7882	0.8832	0.8112	0.8747	1				
PSI 20	0.3854	0.3667	0.6955	0.6461	0.6886	0.6229	0.7262	0.6983	1			
Shanghai	0.0322	0.0921	0.0820	0.0959	0.0831	0.0736	0.0758	0.0734	0.0853	1		
S&P/ASX 200	0.0935	0.1550	0.3104	0.3460	0.3251	0.2726	0.3102	0.2807	0.3141	0.2332	1	
Nikkei	0.1066	0.1594	0.3057	0.3130	0.3145	0.2751	0.2947	0.2747	0.2861	0.2094	0.6138	1

Tabela 3 - Matriz de Correlações entre as Rendibilidades dos Mercados no período de 2000 a 2017 (valores de  $\rho$ ).

O Coeficiente de Pearson, aplicado às rendibilidades, traduz qual a correlação entre mercados quanto ao sentido de evolução das cotações. Ou seja, em períodos que existam evoluções positivas nos dois mercados, haverão correlações positivas e quando contrárias, correlações negativas, no qual o mais próximo de 0, menor a correlação. O coeficiente determina este efeito ao longo de todas as observações do horizonte temporal. Assim sendo, ao abrigo da interpretação do valor de  $\rho$ , é possível verificar que, de um modo geral, as correlações são moderadas, com exceção do mercado Asiático, sendo fracas ou desprezíveis. De modo a facilitar a interpretação, foram realizadas tabelas síntese – Tabela 4 - por área geográfica e a nível de cada índice, onde foi excluído da média de cálculo o índice *EuroStoxx*, por este já ser uma representação dos outros mercados Europeus e colocar uma redundância nas médias. Este fator é observável pela forte correlação que o índice tem com os restantes mercados Europeus, sendo o *CAC 40* a assumir a maior correlação, justificado pelo facto de o *Eurostoxx* ser composto em quase 40% pelo mercado Francês. Uma vez que dos restantes 6 mercados, o mercado Português (PSI 20) é o único que não está presente na carteira de ativos do Eurostoxx, assume uma correlação mais baixa, mas ainda assim significativa que é semelhante à observável na Tabela 4.

	Correlações Gerais Médias Ponderadas	Correlação Média por Continente		
		América	Europa	Ásia
S&P	0.40135	0.6135	0.5131	0.0775
Ibovespa	0.38826	0.6135	0.4157	0.1355
<b>Euro Stoxx 50</b>	<b>0.53955</b>	<b>0.5045</b>	<b>0.8814</b>	<b>0.2327</b>
FTSE100	0.50624	0.4860	0.7811	0.2516
CAC 40	0.52412	0.4880	0.8434	0.2409
DAX	0.50269	0.5193	0.7816	0.2071
IBEX 35	0.49965	0.4614	0.8107	0.2269
FTSE MIB	0.49213	0.4557	0.8111	0.2096
PSI 20	0.42699	0.3761	0.6764	0.2285
Shanghai	0.12155	0.0621	0.0812	0.2213
S&P/ASX 200	0.28530	0.1243	0.3081	0.4235
Nikkei	0.27921	0.1330	0.2930	0.4116

Correlações Entre e Intra Continentes			
	América	Europa	Ásia
América	0.6135		
Europa	0.4644	0.7841	
Ásia	0.1065	0.2274	0.3521

	América	Europa	Ásia
Euro Stoxx 50	0.5045	0.8814	0.2327

Tabela 4 – Síntese da Tabela 3 por área geográfica.

Longin & Solnik (2001) argumentam que a correlação não está relacionada com a volatilidade do mercado (grandes retornos absolutos) *per se*, mas à tendência do mercado. No qual afirmam que a longo prazo é mais fácil de captar essas tendências, sejam elas culturais ou de informação, e onde fluem mais essas tendências. Na Tabela 4, é possível verificar que as tendências são mais sentidas na correlação de mercados do mesmo continente, onde a Europa tem uma correlação forte ( $\rho = 0,78$ ) e a América uma correlação moderada ( $\rho = 0,61$ ). No entanto a Ásia tem uma correlação fraca ( $\rho = 0,35$ ), pelo fator de o índice de *Shanghai* absorver, com correlações baixas quanto ao *ASX 200* e o *Nikkei*, a correlação moderada que o *Nikkei* tem com o *ASX 200* ( $\rho = 0,61$ ). Relativamente às correlações entre os continentes, a correlação mais robusta é entre a América e a Europa, com uma correlação média/fraca ( $\rho = 0,46$ ). Seguido pela relação da Ásia com a Europa e por fim a Ásia com a América, com  $\rho$  de 0,23 e 0,11 respectivamente, considerando, assim, uma correlação desprezível. É possível ainda

verificar que o *EuroStoxx* serve de bom tradutor do mercado Europeu, com correlações muito semelhantes ao observado pelos restantes índices europeus face aos restantes continentes.

Concluindo assim que, o mercado Europeu é o mercado que tem maior correlação com os mercados internacionais, quando comparado face à correlação dos mercados internacionais com os seus internacionais, para um estudo destes 12 mercados no período de 2000 a 2017. Onde o índice de Shanghai apresenta a correlação mais desprezível em relação aos restantes índices, tornando-se uma possibilidade viável na perspetiva de investidor, para uma diversificação de carteira. Objetivamente, o índice de Shanghai não apresenta sinais de correlação com quaisquer mercados em estudo. Este fator pode se dever às barreiras de entrada por diversas direções: a investidores, não inclusão de empresas estrangeiras no índice, políticas rígidas quanto a parcerias com empresas estrangeiras a nível de compras, entre as mais diversas possibilidades.

A nível de risco, foi elaborado um estudo quanto aos Desvios Padrão de cada mercado e testado quanto à sua correlação pelo Coeficiente de *Pearson*. Ao contrário da correlação pela rendibilidade, que mede a direção da cotação – subida ou descida de preço - e compara com o sentido que o outro mercado segue, este teste avalia a variação – maior ou menor - que o mercado tem ao longo do período de 2000 a 2017 face a um outro mercado pela sua variação. Tornando assim possível avaliar a sensibilidade de risco que se toma ao criar uma carteira por esse par de índices.

Correlação dos Desvios Padrão das Observações												
	S&P	Ibovespa	Euro Stoxx	FTSE100	CAC 40	DAX	IBEX 35	FTSE MIB	PSI 20	Shanghai	ASX 200	Nikkei
S&P	1											
Ibovespa	0.5003	1										
Euro Stoxx 50	0.4450	0.3116	1									
FTSE100	0.4480	0.3090	0.7973	1								
CAC 40	0.4469	0.3139	0.9544	0.8105	1							
DAX	0.4767	0.3154	0.8811	0.7224	0.8268	1						
IBEX 35	0.3930	0.2754	0.8364	0.6810	0.8020	0.6941	1					
FTSE MIB	0.3949	0.2688	0.8279	0.6686	0.7967	0.7066	0.7901	1				
PSI 20	0.2929	0.2444	0.5702	0.5315	0.5691	0.4858	0.5974	0.5832	1			
Shanghai	0.1546	0.1258	0.1464	0.1930	0.1595	0.1516	0.1309	0.1191	0.1461	1		
S&P/ASX 200	0.2783	0.1834	0.2810	0.3349	0.3003	0.2478	0.2730	0.2583	0.2715	0.2278	1	
Nikkei	0.2772	0.1679	0.2480	0.2824	0.2462	0.2394	0.2416	0.2212	0.2153	0.1509	0.4962	1

	Correlações Gerais Médias Ponderadas	Correlação Média por Continente		
		América	Europa	Ásia
S&P	0.38193	0.5003	0.4087	0.2367
Ibovespa	0.31573	0.5003	0.2878	<b>0.1590</b>
<b>Euro Stoxx 50</b>	<b>0.47154</b>	<b>0.3783</b>	<b>0.8112</b>	<b>0.2251</b>
FTSE100	0.44380	0.3785	0.6828	0.2701
CAC 40	0.45893	0.3804	0.7610	0.2354
DAX	0.43204	0.3961	0.6871	0.2129
IBEX 35	0.42076	0.3342	0.7129	0.2152
FTSE MIB	0.41345	0.3318	0.7090	0.1995
PSI 20	0.34434	0.2686	0.5534	0.2110
Shanghai	0.15986	0.1402	0.1500	0.1894
S&P/ASX 200	0.29128	0.2309	0.2810	0.3620
Nikkei	0.26238	0.2226	0.2410	0.3235

Correlações Entre e Intra Continentes			
	América	Europa	Ásia
América	0.5003		
Europa	0.3483	0.6844	
Ásia	0.1979	0.2240	0.2916

Tabela 5 - Matriz e Tabelas síntese de Correlações entre os Desvios Padrão dos Mercados no período de 2000 a 2017, organizados geograficamente (valores de  $\rho$ ).

Intracontinentalmente, a Europa tem uma correlação forte de variação de risco ( $\rho = 0,68$ ), enquanto a América tem uma variação média ( $\rho = 0,5$ ) e a Ásia fraca ( $\rho = 0,3$ ). Seguindo o mesmo comportamento observado com as correlações entre rendibilidades. No entanto, o índice *Shanghai* apresenta uma correlação maior com os restantes índices em termos de risco invés da rendibilidade, no entanto a sua correlação continua sem significância ( $\rho' < 0,2$ ). A nível intercontinental, no entanto, não existem evidências relevantes de correlação, apenas no mercado Europeu com o Americano ( $\rho = 0,35$ ), os restantes são desprezíveis.

Assim sendo, é possível concluir que em termos de direção de volatilidade, não existem correlações significativas. Sendo possível criar uma carteira diversificada, no âmbito do aumento ou diminuição de variação dos mercados. Contudo, o *Eurostoxx* apresenta fortes níveis de correlação com os restantes índices Europeus, tornando arriscado formar um portefólio que esteja presente o *Eurostoxx* e outro índice Europeu, por redundância de risco, sendo preferível procurar uma diversificação num mercado menos correlacionado, como por exemplo, o de *Shanghai*.

### 3.2.3. Avaliação Intraday

#### 3.2.3.1. Quanto ao Risco

Numa ótica de convergência, o estudo segue para uma análise quanto ao ano de 2017, de 18 de abril até 31 de outubro. Uma vez compreendendo a tendência geral, torna-se relevante entender qual o comportamento em 2017. Contudo, segundo Ramchand & Susmel (1997), existem algumas contrapartidas em análises com observações obtidas hora a hora, nomeadamente quanto ao ruído que os dados carregam. Isto é, enquanto pode ser observado que, num dia, o mercado subiu, efetivamente o que poderá acontecer hora a hora é traduzir uma falsa sensação de descida, quando, no entanto, o mercado continua com uma tendência geral de subida. Neste caso, a correlação sofre obstruções e tem de ser analisada com alguma prudência e com a ótica do intervalo de tempo – *timeframe* – que lhe está a ser aplicado.

Correlações entre DPs Observados em 2017 (ao dia)												
	S&P	Ibovespa	Euro Stoxx	FTSE100	CAC 40	DAX	IBEX 35	FTSE MIB	PSI 20	Shanghai	ASX 200	Nikkei
S&P	1											
Ibovespa	0.2939	1										
Euro Stoxx	0.3303	0.1583	1									
FTSE100	0.1733	0.1841	0.4648	1								
CAC 40	0.3336	0.1140	0.8826	0.4665	1							
DAX	0.3261	0.0748	0.8815	0.3896	0.7829	1						
IBEX 35	0.1758	0.2043	0.5996	0.2228	0.4650	0.4062	1					
FTSE MIB	0.4471	0.2311	0.4726	0.1473	0.4644	0.3044	0.5632	1				
PSI 20	0.0448	0.3091	0.2802	0.3283	0.2985	0.2129	0.2055	0.1120	1			
Shanghai	0.0537	(0.0277)	(0.0068)	(0.0771)	(0.0248)	(0.0516)	(0.0281)	0.0153	(0.0025)	1		
S&P/ASX	0.0451	(0.0699)	0.2011	0.1011	0.2835	0.2294	(0.0723)	0.0633	0.0868	0.1100	1	
Nikkei	0.2248	0.1795	0.2026	0.1752	0.2466	0.1151	0.1584	0.1981	0.1238	0.0252	0.1419	1

Correlações Entre e Intra Continentes			
	América	Europa	Ásia
América	0.2939		
Europa	0.2182	0.3580	
Ásia	0.0676	0.0856	0.0923

	América	Europa	Ásia
Euro Stoxx 50	0.24	0.60	0.13

Correlações entre DPs Observados em 2017 (à hora)												
	S&P	Ibovespa	Euro Stoxx	FTSE100	CAC 40	DAX	IBEX 35	FTSE MIB	PSI 20	Shanghai	ASX 200	Nikkei
S&P	1											
Ibovespa	0.1558	1										
Euro Stoxx	<b>0.0920</b>	<b>0.0951</b>	1									
FTSE100	(0.0032)	(0.0338)	<b>0.3390</b>	1								
CAC 40	0.0303	0.1330	<b>0.8962</b>	0.3386	1							
DAX	0.0942	0.0752	<b>0.7608</b>	0.2536	0.6583	1						
IBEX 35	0.0858	0.1580	<b>0.5875</b>	0.2032	0.5208	0.3598	1					
FTSE MIB	0.1565	0.1530	<b>0.6068</b>	0.1670	0.5486	0.4054	0.5291	1				
PSI 20	0.0318	0.0297	<b>0.3138</b>	0.1718	0.3069	0.2206	0.3012	0.2654	1			
Shanghai	0.0534	0.0242	<b>0.0455</b>	0.0539	0.0715	0.0649	0.0259	0.0472	0.0789	1		
S&P/ASX	<b>0.0066</b>	<b>(0.0265)</b>	<b>0.0735</b>	<b>0.0208</b>	<b>0.0500</b>	<b>0.0826</b>	<b>0.1000</b>	<b>0.1185</b>	<b>(0.0157)</b>	<b>(0.0151)</b>	1	
Nikkei	0.0817	0.0887	<b>0.0829</b>	0.0517	0.0570	0.0864	0.0849	0.0648	0.0889	<b>(0.0635)</b>	<b>0.0133</b>	1

Correlações Entre e Intra Continentes			
	América	Europa	Ásia
América	0.1558		
Europa	0.0759	0.3500	
Ásia	0.0380	0.0629	(0.0218)


	América	Europa	Ásia
Euro Stoxx 50	0.09	0.58	0.07

Tabela 6 - Correlações entre os Desvios Padrão de mercados em 2017, ao dia e à hora, respetivamente (valores de  $\rho$ ).

Indo de encontro com os autores Ramchand & Susmel (1997), é observável o efeito ruído no cálculo da correlação dos Desvios Padrão. No entanto, de um modo geral, as correlações possuem valores desprezíveis ou fracos, com exceção dos mercados Europeus, tendo correlações médias ou fracas. Onde é possível verificar que o *Eurostoxx* segue uma tradução geral do mercado Europeu, com fortes correlações, independentemente da *timeframe* analisada. Contudo, é relevante ainda mencionar a forte correlação entre o mercado Francês (*CAC 40*) com o Alemão (*DAX*), sendo o índice *CAC 40* o que maior correlação tem entre todos os mercados Europeus. É possível assim entender a razão pela qual a composição da carteira do *Eurostoxx* tem uma maior participação do mercado Francês em relação aos restantes mercados, de modo a traduzir o mercado Europeu fidedignamente como um todo.

Numa análise intergeográfica, a nível de risco, os valores de correlação são desprezíveis por toda a análise. O que traduz uma variação no sentido de aumento e diminuição de risco multivariada ao longo dos continentes, no entanto, a nível intrageográfico já existe algum sentido de direção comum, com exceção da Ásia. Tornando assim a Ásia um

continente interessante no ponto de vista de diversificação. Todavia, é de salientar as limitações do teste elaborado no espectro da *timeframe* à hora. Isto é, o horizonte temporal encontra-se enquadrado na *timeframe*, porém existe divergência temporal relativo aos horários de mercado na análise intercontinentes.



*Figura 7 - Representação de horários dos mercados (com base no horário de Lisboa).*

Veja-se, por observação da Figura 7, que os horários têm diferentes horas de abertura e encerramento do mercado. Este é um dos fatores que tem peso no movimento das cotações do mercado. Essa colisão é limitada quanto às análises hora a hora, no entanto as correlações ao dia são isentas desse erro. A Ásia tem horário de abertura à 1 hora da manhã de Lisboa, encerrando às 7 horas da manhã, antes dos restantes mercados abrirem. O mercado Europeu abre às 8 horas da manhã de Lisboa, abrindo a meio da sessão o mercado Americano, 2 horas da tarde. Posteriormente encerra o mercado Europeu e por fim o Americano, às 4 horas e 9 horas da tarde, respetivamente. Verificando que o mercado Asiático não tem qualquer hora de funcionamento em conjunto com quaisquer dos restantes mercados e o Europeu tem 2 horas de sessão enquanto o mercado Americano também se encontra em funcionamento. Sendo possível concluir que, existem correlações com o mercado Asiático que podem colidir a nível de divergência horária e, no momento de correlação entre o Mercado Europeu e Americano, apenas uma pequena parcela não vai de encontro com essa limitação, havendo espaço para alguma absorção de qualidade a nível da correlação.

### **3.2.3.2. Análise de GARCH**

Segundo Kaplanis (1988), através de comparação de matrizes mensais de rendibilidades, é rejeitado H0 quanto à constante correlação entre mercados internacionais. Entrando [assim] em conformidade com os resultados obtidos, em tese, quando à comparação

entre o horizonte temporal de 2000 a 2017 com 2017 apenas. Formulando o conceito de existirem correlações e variâncias inconstantes ao longo do tempo, por força de outras variáveis. De acordo com os autores King & Wadhvani (1990) e Bertero & Mayer (1990), correlações internacionais tendem a aumentar em período de crises nos mercados (ver ainda Lin, Engle, & Ito (1994), Longin & Solnik (1995), Karolyi & Stulz (1996), Solnik, Boucrelle, & Fur (1996), Ramchand & Susmel (1998), Chesnay & Jondeau (2001), Ang & Bekaert (2002), Dennis, Mayhew, & Stivers (2006), Baele (2009), Silvennoinen & Teräsvirta (2009) e outros). Sendo assim possível concluir a existência de diferentes variâncias em função do tempo, efeito heterocedástico. Ao abrigo do estudo feito pelos autores Bollerslev, Chou, e Kroner (1992), o modelo Autorregressivo ARCH e GARCH captam a alteração da variância dos dados ao longo do tempo, criando um estudo autocorrigido ao longo da amostra populacional.

Os dados em que as variações dos termos de erro<sup>4</sup> não são constantes, na qual é esperado que os termos de erro sejam maiores para alguns pontos ou intervalos dos dados do que para outros, são ditos sofrerem de heterocedasticidade. Na presença de heterocedasticidade, os coeficientes de regressão para uma regressão de Mínimos Quadrados Ordinários (MQO) ainda são imparciais, contudo os erros padrão<sup>5</sup> e os intervalos de confiança estimados por procedimentos convencionais serão mais reduzidos, dando uma falsa sensação de precisão. O termo heterocedasticidade surgiu aplicado a modelos transversais, e não a modelos de séries temporais. Isto é, quando um estudo tem diversas variâncias na mesma amostra por força de uma variável inerente ao estudo que não é perceptível sem compreensão da tipologia dos dados. Ou seja, por exemplo, numa análise a uma relação transversal entre renda e consumo nos dados do agregado familiar, é esperado que o consumo de famílias com rendimentos baixos seja mais reduzido que o de agregados familiares com rendimentos elevados, uma vez que a poupança efetiva de famílias com menores rendimentos, seja menor em formato

---

<sup>4</sup> Os termos de erro do modelo são considerados as rendibilidades ao quadrado. De modo a traduzir o valor da rendibilidade para a variância que o modelo calcula.

<sup>5</sup> O erro padrão da média de uma amostra é uma estimativa do desvio padrão da distribuição das médias de amostras com o mesmo tamanho obtidas da mesma população, e dessa forma uma medida da incerteza associada à estimativa da média na população

absoluto. Numa regressão linear simples entre o consumo doméstico sobre a renda, os termos de erro parecem ser sistematicamente maiores em valor absoluto para os rendimentos mais altos quanto a famílias de rendimentos mais baixos, tornando a aceitação de homocedasticidade<sup>6</sup> implausível. Fazendo então sentido analisar conforme a lógica de várias variâncias dentro das mesmas observações, agrupando por nível de rendimentos, aceitando a heterocedasticidade. Em contraste, caso o estudo fosse realizado quanto ao rendimento nacional médio em função do consumo, é mais lógico pensar que existam alterações ao longo do tempo por força de crise, reformulando a tipologia de atribuição de heterocedasticidade. Porém um estudo recente na estimativa de erros padrão, conhecido como erros padrão robustos<sup>7</sup>, também reduziu a preocupação com a heterocedasticidade. Se o tamanho da amostra for suficientemente grande, então, ao abrigo do MQO, os erros dão uma boa estimativa de erros padrão, mesmo com heterocedasticidade. Todavia, se a amostra for reduzida, a necessidade de uma correção de heterocedasticidade que não afete os coeficientes, e somente corrija os erros padrão assintoticamente, pode ser debatida. Deste modo, torna-se fundamental implementar modelos mais realistas na interpretação dos dados *intraday*.

O desafio, a nível da economia, é especificar como as informações são usadas para prever a média e a variância da rendibilidade, quando condicionadas à informação histórica. Embora tenham surgido inúmeros esforços para calcular a média da rendibilidade, como tentativa de prever as rendibilidades futuras, praticamente nenhum método estava disponível antes da introdução de modelos *Autoregressive Conditional Heteroskedasticity* (ARCH), proposto por Engle (1982). Posteriormente, por força de tentativa de *forecast* dos mercados na sua aplicação financeira, surgiu o modelo GARCH<sup>8</sup>, desenvolvido por Bollerslev (1986), derivado do modelo ARCH com acréscimo de uma suposição de termos quanto à variância por meio do modelo Autorregressivo de Médias Móveis (ARMA), de modo a ser possível criar uma previsibilidade do

---

<sup>6</sup> Contrário de Heterocedasticidade. Existe uma variância na população.

<sup>7</sup> Definido pelo autor White (1980) como **Mínimos Quadrados Generalizados (MQG)**.

<sup>8</sup> Entenda-se por GARCH - *Generalized Autoregressive Conditional Heteroskedasticity*.

comportamento da variância – *forecast*. O modelo GARCH é composto pela seguinte fórmula:

[5]

$$\sigma_t^2 = \omega + \alpha \varepsilon_{t-1}^2 + \beta \sigma_{t-1}^2$$

Onde:

$\sigma_t^2$  = Variância Condicional.

$\omega$  = Variância histórica de longo prazo do mercado (ponderada). Sendo  $\omega \geq 0$ .

$\varepsilon_{t-1}^2$  = Rendibilidade [ao quadrado] do período anterior, definido como erro.


$\sigma_{t-1}^2$  = Variância do período anterior.

$\alpha$  e  $\beta$  = Ponderadores de peso no modelo. No qual  $\alpha \geq 0$  e  $\beta \geq 0$ .

Obrigando a que:

$$\omega + \alpha + \beta \leq 1$$

Assim sendo, o *output* do modelo ARCH, quando reaplicado ao longo do tempo, é uma sucessão de correções à variância baseado nas observações históricas, invés de seguir uma linha média da variância. Enquanto o *output* do modelo GARCH é uma extensão do modelo para o período seguinte ( $t + 1$ ) ponderado pela importância dos períodos anterior sucessivamente (por  $\omega + \alpha + \beta$ ), definido como *lag*. Deste modo é possível criar uma previsibilidade do comportamento da variância e avaliar a aplicação num portefólio baseado na gestão de risco e alocação de ativos.



*Figura 8 - Gráfico ilustrativo da variância pelo modelo de GARCH em função da variância total média do mesmo período.*

Com auxílio da Figura 8, é possível verificar que o modelo de GARCH tem fatores corretivos quanto aos termos históricos referente às volatilidades. Isto é, quando existe uma maior variância num período, os períodos imediatamente a seguir também sofrem uma maior volatilidade em relação à sua média, onde o oposto também acontece, indo de encontro com a teoria do autor Reider (2009). Na qual o autor defende que quando os mercados sofrem maior volatilidade, é esperado uma maior variância desses mercados nos próximos períodos. No seu estudo, o autor defende [ainda] que a volatilidade não só aumenta em momentos de crise, mas como eventualmente retorna ao nível de volatilidade pré-crise. Não obstante, é ainda possível verificar [na Figura 8] que existe um certo padrão corretivo do modelo em torno da sua variância histórica média, devido à parcela empírica ( $\omega$ ) do modelo, onde a sua aproximação corretiva à média será maior quanto maior o seu ponderador no modelo.

### **3.2.3.2.1. Viabilidade**

De modo a aplicar o modelo de GARCH, os dados necessitam de obedecer a critérios prévios de forma a que o modelo possa criar um *output* fidedigno para o estudo. Caso contrário, a relação entre os dados altera a lógica que o modelo extrapola e concede resultados que não têm interpretações lógicas, como por exemplo, interpretação de variâncias em formas absoluta. Assim sendo, de modo a aplicar o modelo autorregressivo GARCH, é necessário satisfazer a presença de heterocedasticidade. Para o efeito deve-

se recorrer ao Teste de *White*, que avalia a rejeição de homocedasticidade através de um teste ao Qui-quadrado e quanto ao *p-value*, probabilístico de normalidade, relativo a cada índice. Para obtenção dos resultados, foi realizado o estudo através do *software EViews*.

Por visualização dos resultados obtidos na **(TABELA DE CORRELOGRAMAS - ANEXO)**, é possível verificar que pelo teste de *White*, quanto ao Qui-Quadrado e com valores de *p* inferiores a 0,05 (*p-value* < 0,05), existem evidências para rejeitar H0 quanto à hipótese de homocedasticidade. De acordo com Rockafellar & Uryasev (1999) e Patton (2006), não é esperado normalidade nos dados das rendibilidades observadas, tornando-se expectável que a homocedasticidade não estivesse presente na amostra. Segundo os autores Kat & Miffre (2008), empiricamente, para dados históricos com *timeframes* reduzidas, torna-se desnecessário e redundante efetuar testes quanto à normalidade das observações por se verificar regularmente a não normalidade, contudo, ainda assim, enriquecem a análise de dados.

### 3.2.3.2.2. Likelihood

Uma vez comprovada a viabilidade da população quanto à ausência de homocedasticidade, é possível avançar para a aplicação do modelo. No entanto, as parcelas de ponderação ( $\omega$ ,  $\alpha$  e  $\beta$ ) são fatores empíricos e têm de ser arbitradas no momento da utilização de GARCH para cada índice. Os seus valores têm de traduzir, em termos históricos de longo prazo, qual o peso que: em relação a  $\omega$ , a tendência geral de variância observada historicamente que o momento  $t$  retém; quanto ao  $\alpha$ , o peso da rendibilidade *lagged* que momento  $t$  vai verificar; e por fim, ao  $\beta$ , qual o peso que o momento  $t$  absorve da variância do período anterior ( $t - 1$ ); estes fatores para cada observação. Quando aplicadas as ponderações na sucessão de valores, cada momento  $t$  vai traduzir um certo peso histórico, com maior importância nos períodos mais próximos dosados pelos valores de ponderações.

A componente *lag* é selecionada como o tipo de análise que o modelo vai correr e de acordo com o *output* que se pretende do modelo, referente a quantos períodos anteriores vão ser considerados para prever o momento  $t$ . No presente estudo, é executado o

modelo GARCH( $p,q$ ), com  $p = 1$  e  $q = 1$ . Onde a primeira parcela ( $p$ ) refere-se ao *lag* da variância imputada no momento  $t$  e, a segunda parcela ( $q$ ), ao *lag* do erro (rendibilidade ao quadrado) que será incrementada no momento  $t$ . Assim sendo, serão usadas informações do período imediatamente anterior para prever o período imediatamente a seguir. Neste caso, o  $t$  refere-se a 1 hora de mercado e este método traduz uma maior nitidez e precisão quanto ao estudo à hora, uma vez que é feito o *forecast* através de séries históricas aplicadas ao longo da sua previsão também histórica. Contudo, quanto maior o horizonte temporal que se pretenda criar previsibilidade, maior o *lag* ( $p,q$ ) que terá de ser imputado ao modelo.

Após selecionado o tipo de *output* pretendido pelo modelo, deve-se considerar quais as ponderações para os fatores empíricos, na condição de períodos  $p = 1$  e  $q = 1$ . Para o efeito, existe uma fórmula de seleção de probabilidade de valores denominada de Estimativa por Máxima Verossimilhança - *Maximum-Likelihood Estimation* (MLE) -, que consiste em, essencialmente, uma função de probabilidade conjunta. Porém invés de pensar nesta como um conjunto de dados em função de um conjunto de parâmetros, constrói-se o inverso, um conjunto de parâmetros em função dos dados, bastando assim maximizar a função de verossimilhança relativamente a esses parâmetros, que é essencialmente encontrar a moda da distribuição. Para o auxílio de cálculo dos parâmetros a aplicar, foi usado o software *EViews* para cada índice de mercado.

	$\omega$	$\alpha$	$\beta$	Schwarz
S&P 500	1.68E-06	0.09036	0.89239	6.65
Ibovespa	6.94E-06	0.06525	0.90337	5.64
EuroStoxx 50	1.75E-06	0.08515	0.90697	6.12
FTSE 100	1.22E-06	0.09726	0.89313	6.64
CAC 40	1.71E-06	0.08094	0.91043	6.14
DAX	1.77E-06	0.08042	0.91009	6.13
IBEX 35	2.05E-06	0.09689	0.89682	6.06
FTSE MIB	1.21E-06	0.08649	0.9111	6.07
PSI 20	9.44E-07	0.09465	0.90238	6.52
Shanghai	9.29E-07	0.06936	0.9295	6.04
S&P/ASX 200	6.12E-07	0.06144	0.9303	6.94
Nikkei	5.09E-06	0.10375	0.87031	6.02

*Tabela 7 - Resumo do Anexo D das parcelas de ponderação para cada índice e o Critério de Schwarz, relativo a dados históricos de janeiro de 2000 até abril de 2017 (n = 3570).*

Por vias de observação da Tabela 7, os resultados da estimativa do MLE demonstram que existe maior peso no ponderador do  $\beta$  em relação às restantes parcelas, situando-se numa média de 0,9. Quanto ao  $\alpha$ , em média, os valores situam-se nos 0,085 e a parcela  $\omega$  tem uma componente muito reduzida no modelo. Esta última deve-se ao facto de o ponderador se referir à componente da variância média histórica de longo prazo, no qual uma vez que se está a tratar dados à hora, o incremento nos dados é muito reduzido, contudo uma vez que o modelo segue uma lógica de reaplicação, a sua componente é sentida ao longo da sua reaplicação. Relativamente ao  $\beta$ , é o ponderador da variância *lagged* observada no período imediatamente anterior, demonstrando que o MLE deduziu que a razão pela qual os dados seguirem determinado comportamento se deve [maioritariamente] à variância do momento anterior, no qual a força da variância desse momento vai sendo diluída ao longo dos novos cálculos para as variâncias condicionadas ( $\sigma_t^2$ ) dos períodos seguintes, mas em simultâneo, sentida. O mesmo raciocínio aplicado ao ponderador  $\omega$  cria alguma redundância, no facto de os dados já seguirem [inerentemente] o comportamento da tendência de variância geral, justificando a razão da sua parcela reduzida. Porém, o mesmo fator de redundância não é justificado na parcela  $\alpha$ , todavia o seu componente também é consideravelmente inferior ao  $\beta$ . Este deve-se ao facto de  $\alpha$  dosar o peso da componente de erro no modelo por via da

rendibilidade, uma vez que o modelo fornece como *output* uma variância de um índice, quanto menor o peso de  $\alpha$  mais dependente da informação histórica é esse índice. Concluindo que quanto menor for a parcela  $\alpha$ , mais o MLE considerou o índice como menos reativo a dados históricos, ou seja, um mercado mais eficiente. É ainda observável que os valores de critérios de Schwarz têm uma evidência forte. Isto é, de acordo com Schwarz (1978), no momento de cálculo de parâmetros em função de dados pelo MLE, são elaborados cálculos de proximidade do quanto aqueles parâmetros traduzem os dados observados probabilisticamente, agrupados pelas seguintes classes: de 0 a 2 insignificante, 2 a 6 positivos, de 6 a 10 forte e superior a 10 muito forte.

### **3.2.3.2.3. Análise a diferentes abordagens**

Uma vez satisfeito os termos do modelo de GARCH(1,1) em relação à qualidade dos dados para estudo e conhecidos os termos de ponderação de cada mercado com base histórica (de janeiro de 2000 até abril de 2017), existem diversas vertentes e óticas na qual o modelo pode ser aplicado. Inicialmente será elaborado um estudo de relação entre o modelo de GARCH(1,1) com as observações reais do mercado, de modo a entender o quão adequado o modelo baseado em informações históricas consegue criar um *forecast*, referente a abril de 2017 até outubro de 2017. Posteriormente, aplicar o modelo de GARCH(1,1) baseado na variância das observações de um mercado de modo a tentar prever o comportamento de outro, testando a hipótese quanto ao tipo de correlação entre mercados através da previsibilidade do sistema de GARCH. Para o efeito, sob o efeito de uma extensão do teste anterior, é aplicado um conceito recentemente desenvolvido quanto à adição de médias móveis no modelo de GARCH, na tentativa de *forecast* através de outros mercados, e interpretar os seus resultados. Deste modo, é possível corrigir a colisão horária pelo adiantamento de períodos em função dos recentes, sem necessidade de aplicar um *lag* maior no modelo de GARCH e perder informação nos dados.

### 3.2.3.2.3.1. Aplicação de GARCH e o seu impacto

Inicialmente, no estudo, o modelo de GARCH é aplicado na ótica do mercado em aspeto individual. Isto é, numa análise a cada mercado, será usado o modelo de modo a prever o período imediatamente seguinte. As novas observações sofrerão de uma reaplicação do modelo de modo a prever [novamente] o período seguinte e assim sucessivamente. Uma vez corrida a análise pela amostra, é testado quanto à correlação dos dados estimados da variância pelos verificados durante dia a dia, dos 114 dias, 5 horas por dia ( $n = 570$ ), através da aplicação *Statística*.

Variable	Valid N	Mean	Median	Minimum	Maximum	Percentile 25.00000	Percentile 75.00000	Variance	Std.Dev.	Skewness	Kurtosis
S&P	113	0.3732	0.4811	-0.8971	0.9894	0.1167	0.6968	0.1974	0.4443	-0.8407	0.0033
Ibovespa	114	0.4816	0.5699	-0.4777	0.9570	0.2754	0.7539	0.1155	0.3398	-0.8548	0.1698
Euro Stoxx 50	114	0.3767	0.4489	-0.7895	0.9553	0.1061	0.6765	0.1525	0.3906	-0.6913	-0.2294
FTSE100	114	0.3942	0.4279	-0.7416	0.9163	0.2365	0.5969	0.0795	0.2820	-0.7585	1.4442
CAC 40	114	0.4310	0.5278	-0.5967	0.9520	0.1119	0.7388	0.1411	0.3756	-0.6969	-0.4993
DAX	114	0.4003	0.4887	-0.5856	0.9430	0.1782	0.6405	0.1178	0.3433	-0.7641	-0.0799
IBEX 35	114	0.4431	0.5142	-0.5550	0.9192	0.2558	0.6987	0.1096	0.3311	-0.9279	0.4051
FTSE MIB	114	0.3817	0.4524	-0.5889	0.9142	0.1544	0.6873	0.1547	0.3934	-0.8041	-0.3075
PSI 20	114	0.4488	0.4909	-0.4535	0.9606	0.2410	0.7193	0.1020	0.3193	-0.6630	-0.1006
Shanghai	114	0.3081	0.4635	-0.9599	0.9995	-0.1376	0.7623	0.2910	0.5395	-0.6417	-0.6650
S&P/ASX 200	114	0.4889	0.5610	-0.8730	0.9995	0.2218	0.7761	0.1447	0.3805	-0.9952	0.9799
Nikkei	114	0.4891	0.5538	-0.9534	0.9968	0.2901	0.7744	0.1446	0.3803	-1.0088	1.1114

*Tabela 8 - Estatística descritiva de correlações referente a cada mercado (de abril de 2017 a outubro de 2017).*

Após criado uma série de correlações dia a dia para cada mercado através do modelo de GARCH, foi elaborado uma análise de estatística descritiva (Tabela 8). Onde é possível observar, numa primeira abordagem, que a média de correlação é média ou fraca em todos os mercados ( $\bar{x}' = 0,42$ ), traduzindo que a variância esperada através do modelo de GARCH(1,1) não cria uma fonte segura de *forecast*, no entanto o seu grau de correlação não é desprezível, conferindo alguma aplicabilidade. Em termos práticos, uma vez que o modelo segue parâmetros de variância histórica, significa que o período de abril a outubro de 2017 referente a 114 dias em estudo não seguem um comportamento probabilístico de sentido de variância com base histórica. Contudo, veja-se ainda que, nos valores máximo e mínimo de mercados, existem dias com valores de correlação

assimétrico e outros de correlação muito forte. Estas observações de correlação assimétrica cria uma absorção da qualidade da média. Para melhor auxílio de análise, veja-se a tabela de cada mercado em ficheiro anexo (Anexo E). É possível confirmar essa absorção de qualidade na média, de um modo geral para todos os mercados, através de: o primeiro quartil ter correlações positivas; a média encontra-se consideravelmente longe da mediana; e existe um enviesamento em torno do lado direito da distribuição. Constituindo assim uma viabilidade de *forecast* através do modelo de GARCH na medida em que consegue manter a tendência do mercado e antever o tipo de variância correspondente, porém, quando o mercado muda de tendência, o impacto pode ser elevado na altura de correlação.

Sendo assim possível concluir a correlação da variância real quanto à esperada pelo modelo de GARCH(1,1) relativo a informações históricas. No entanto, é necessário cautela no momento de aplicação e avaliação, pois o modelo segue uma linha de tendência baseada no curto a tender para o longo prazo e quando existe uma alteração do sentido da variância, o erro do modelo surge e pode ter um atraso na correção, conforme o grau de alteração.

### **3.2.3.2.3.2. Comportamento entre mercados através de GARCH e Médias Móveis**

Numa segunda fase do estudo pretende-se avaliar o *forecast* da variância através de outros mercados, em função da diferença horária. Ou seja, o modelo de GARCH(1,1) é aplicado a um mercado [A], que já tenha ocorrido, de modo a reter a direção da variância desse mercado [A] que posteriormente será aplicada a um outro mercado [B] e comparado com a variância observada nesse período. Deste modo, por exemplo, será possível verificar se a variância do mercado do *Nikkei*, que está aberto desde a 1 hora da manhã até às 7 horas da manhã (hora local de Lisboa), tem impacto na variância observada pelo mercado que opera depois do encerramento do *Nikkei*, por exemplo, o PSI 20. Contudo, existe o problema de inadequação horária no momento previsional. A solução para o problema levantado deriva dos autores Kolmogorov & Zurbenko (1940) através da Suavização Exponencial. Trata-se de uma média móvel baseada em valores históricos ponderada pela aproximação ao longo do tempo, onde derivado desse estudo, foi criado as Médias Móveis Ponderadas Exponencialmente -

*Exponentially Weighted Moving Average* (EWMA). Deste modo, é possível repercutir a informação histórica criada pelo modelo de GARCH(1,1) e redirecionar o seu comportamento para os períodos seguintes necessários, solucionando o problema temporal.

Por conseguinte, o EWMA segue a seguinte fórmula:

[6]

$$E[\sigma_{n+t}^2] = V_L + (\alpha + \beta)^t \cdot (\sigma_n^2 - V_L)$$

Onde:

$E[\sigma_{n+t}^2]$  = Valor esperado da variância  $t$  momentos à frente de  $n$ .

$V_L$  = Componente histórica relativo à Variância de Longo prazo.

$\alpha$  e  $\beta$  = Ponderadores de peso no modelo. No qual  $\alpha \geq 0$  e  $\beta \geq 0$ .

$\sigma_n^2$  = Variância no momento  $n$ . Onde será usado a variância calculada pelo modelo de GARCH(1,1).

Por observação da fórmula, a primeira componente é autónoma e é referente à variância de longo prazo do índice, as restantes estão condicionadas pelos pesos  $\alpha$  e  $\beta$  em função da longevidade de previsão ( $t$ ). Assim sendo, é esperado que exista uma convergência em torno do valor da variância de longo prazo. As análises seguintes demonstram a correlação entre a variância esperada de cada mercado em função de outros mercados com a Variância observada. Na qual a sua análise deve ser tida em conta com os valores que o *output* do modelo de GARCH(1,1) gerou no estudo anterior para os próprios mercados.

### Correlação da variância de S&P com o esperado em função dos outros mercados.

Variable	Valid N	Mean	Median	Minimum	Maximum	Percentile 25.00000	Percentile 75.00000	Variance	Std.Dev.	Skewness	Kurtosis
Ibovespa	113	0.1341	0.1965	-0.8674	0.9658	-0.2887	0.5710	0.2715	0.5211	-0.2153	-1.132
Euro Stoxx 50	113	0.0901	0.1012	-0.8491	0.9889	-0.3568	0.5684	0.2748	0.5242	0.0229	-1.236
FTSE100	113	-0.0030	0.0130	-0.9541	0.9095	-0.4111	0.4097	0.2597	0.5096	0.0553	-0.957
CAC 40	113	0.0945	0.0827	-0.8144	0.9887	-0.3171	0.5521	0.2507	0.5007	0.0190	-1.113
DAX	113	0.1372	0.1602	-0.8241	0.9886	-0.3325	0.5692	0.2634	0.5133	-0.1033	-1.287
IBEX 35	113	0.0742	0.0488	-0.9007	0.9311	-0.3814	0.5307	0.2678	0.5175	-0.0347	-1.142
FTSE MIB	113	0.1029	0.0659	-0.7417	0.9787	-0.2791	0.5003	0.2192	0.4682	0.1021	-1.033
PSI 20	113	0.1003	0.1424	-0.9777	0.9491	-0.3249	0.5176	0.2477	0.4977	-0.1887	-1.103
Shanghai	113	0.0529	0.1443	-0.9661	0.9926	-0.3749	0.4427	0.2602	0.5101	-0.1783	-1.065
S&P/ASX 200	113	0.0331	0.0490	-0.9377	0.9591	-0.4045	0.5380	0.2628	0.5126	0.0142	-1.046
Nikkei	113	0.0315	0.0319	-0.9621	0.9590	-0.4728	0.5907	0.3200	0.5657	0.0106	-1.311

### Correlação da variância de Ibovespa com o esperado em função dos outros mercados.

Variable	Valid N	Mean	Median	Minimum	Maximum	Percentile 25.00000	Percentile 75.00000	Variance	Std.Dev.	Skewness	Kurtosis
S&P	114	0.1091	0.0856	-0.8852	0.9956	-0.3400	0.5761	0.2927	0.5410	-0.0406	-1.214
Euro Stoxx 50	114	0.1147	0.0635	-0.9448	0.9827	-0.3066	0.5674	0.2705	0.5201	-0.0085	-1.083
FTSE100	114	0.0185	-0.0290	-0.9179	0.9940	-0.3450	0.4249	0.2277	0.4772	0.0486	-0.856
CAC 40	114	0.1031	0.1278	-0.8833	0.9186	-0.3400	0.5625	0.2827	0.5317	-0.0672	-1.214
DAX	114	0.0947	0.1083	-0.9044	0.9619	-0.3220	0.5403	0.2474	0.4974	-0.0583	-1.070
IBEX 35	114	0.0519	0.0941	-0.9178	0.9675	-0.3638	0.4343	0.2496	0.4996	0.0654	-1.006
FTSE MIB	114	0.0434	-0.0038	-0.9566	0.9841	-0.3428	0.4416	0.2552	0.5052	0.1762	-0.887
PSI 20	114	0.0863	0.0409	-0.8299	0.9888	-0.3578	0.4846	0.2467	0.4967	0.0575	-1.088
Shanghai	114	0.0413	0.0089	-0.9195	0.9848	-0.4360	0.5273	0.2913	0.5397	0.0329	-1.187
S&P/ASX 200	114	0.1197	0.1161	-0.9340	0.9953	-0.4061	0.6485	0.2934	0.5416	-0.0545	-1.270
Nikkei	114	0.0066	-0.0944	-0.8699	0.9991	-0.4151	0.4485	0.2498	0.4998	0.3533	-1.065

### Correlação da variância de EuroStoxx com o esperado em função dos outros mercados.

Variable	Valid N	Mean	Median	Minimum	Maximum	Percentile 25.00000	Percentile 75.00000	Variance	Std.Dev.	Skewness	Kurtosis
S&P	114	0.0166	-0.1079	-0.9153	0.9744	-0.3898	0.4840	0.2767	0.5260	0.2091	-1.2024
Ibovespa	114	0.0657	0.0510	-0.9374	0.9701	-0.4081	0.5083	0.2945	0.5427	-0.0592	-1.1929
FTSE100	114	-0.0187	-0.0266	-0.9823	0.9091	-0.4144	0.3587	0.2689	0.5186	0.0892	-1.0457
CAC 40	114	0.2545	0.3630	-0.8734	0.9933	-0.1125	0.6613	0.2529	0.5029	-0.4967	-0.7550
DAX	114	0.2274	0.3699	-0.9300	0.9857	-0.1924	0.6305	0.2510	0.5010	-0.4551	-0.8539
IBEX 35	114	0.1004	0.0894	-0.9474	0.9938	-0.3142	0.5505	0.2670	0.5167	-0.0345	-1.0654
FTSE MIB	114	0.0996	0.0225	-0.9369	0.9882	-0.3656	0.5674	0.2861	0.5349	-0.0138	-1.2432
PSI 20	114	0.0738	0.0029	-0.8838	0.9900	-0.3364	0.5049	0.2410	0.4910	0.0863	-1.0554
Shanghai	114	0.0760	0.0882	-0.9796	0.9647	-0.3727	0.5451	0.2675	0.5172	-0.0357	-1.0854
S&P/ASX 200	114	0.0113	0.0371	-0.9503	0.9938	-0.4144	0.3473	0.2561	0.5060	0.1234	-0.8573
Nikkei	114	0.0178	-0.0336	-0.9217	0.9815	-0.3642	0.4122	0.2446	0.4946	0.2168	-0.9015

### Correlação da variância de FTSE100 com o esperado em função dos outros mercados.

Variable	Valid N	Mean	Median	Minimum	Maximum	Percentile 25.00000	Percentile 75.00000	Variance	Std.Dev.	Skewness	Kurtosis
S&P	114	0.0399	0.0883	-0.9261	0.9724	-0.4304	0.4711	0.2604	0.5103	-0.0110	-1.1752
Ibovespa	114	0.0129	0.0198	-0.9475	0.9785	-0.4361	0.3896	0.2517	0.5017	0.0710	-1.0959
Euro Stoxx 50	114	0.1365	0.1147	-0.8268	0.8818	-0.1855	0.5362	0.2102	0.4585	-0.1204	-0.9315
CAC 40	114	0.1587	0.1402	-0.9445	0.9452	-0.2157	0.6159	0.2305	0.4801	-0.1881	-0.9700
DAX	114	0.0552	0.0203	-0.9217	0.9345	-0.3341	0.5336	0.2463	0.4963	-0.0717	-1.0950
IBEX 35	114	0.0805	0.0705	-0.9311	0.9817	-0.2632	0.5234	0.2426	0.4925	0.0056	-1.0291
FTSE MIB	114	0.0378	-0.0005	-0.8755	0.9869	-0.3760	0.4145	0.2368	0.4866	0.1137	-1.0544
PSI 20	114	0.0359	0.0673	-0.8081	0.9905	-0.4218	0.4133	0.2281	0.4776	0.1078	-1.0751
Shanghai	114	-0.0670	-0.1214	-0.9339	0.9655	-0.5046	0.3734	0.2845	0.5334	0.2089	-1.0784
S&P/ASX 200	114	-0.0167	-0.1069	-0.9470	0.9886	-0.5248	0.4374	0.2988	0.5466	0.2954	-1.0548
Nikkei	114	0.0219	-0.0242	-0.9542	0.9898	-0.4437	0.4716	0.2789	0.5281	0.1311	-1.1482

### Correlação da variância de CAC 40 com o esperado em função dos outros mercados.

Variable	Valid N	Mean	Median	Minimum	Maximum	Percentile 25.00000	Percentile 75.00000	Variance	Std.Dev.	Skewness	Kurtosis
S&P	114	-0.0323	-0.1096	-0.9308	0.9697	-0.4628	0.4169	0.2577	0.5076	0.1569	-1.1394
Ibovespa	114	0.0634	0.0689	-0.9274	0.9170	-0.3824	0.5420	0.2861	0.5349	-0.0710	-1.1434
Euro Stoxx 50	114	0.2988	0.4516	-0.7850	0.9904	-0.1096	0.7112	0.2451	0.4951	-0.5914	-0.9125
FTSE100	114	0.0818	0.0673	-0.9156	0.9695	-0.2639	0.5231	0.2446	0.4946	-0.0709	-1.0387
DAX	114	0.2292	0.2934	-0.8357	0.9637	-0.1806	0.6464	0.2419	0.4918	-0.4588	-0.7978
IBEX 35	114	0.1620	0.1973	-0.9194	0.9888	-0.2302	0.5642	0.2358	0.4856	-0.2628	-0.9528
FTSE MIB	114	0.1516	0.2424	-0.8491	0.9848	-0.3094	0.5362	0.2614	0.5112	-0.1641	-1.1568
PSI 20	114	0.0940	0.0549	-0.8645	0.9805	-0.3594	0.5855	0.2895	0.5380	0.0700	-1.2537
Shanghai	114	0.0448	0.0172	-0.9549	0.9918	-0.3852	0.4962	0.2811	0.5302	0.0351	-1.1076
S&P/ASX 200	114	0.0329	0.0039	-0.8960	0.9736	-0.2596	0.4263	0.2215	0.4706	0.1085	-0.7340
Nikkei	114	0.0431	0.0152	-0.8873	0.9827	-0.3579	0.4586	0.2665	0.5162	0.1496	-1.0672

### Correlação da variância de DAX com o esperado em função dos outros mercados.

Variable	Valid N	Mean	Median	Minimum	Maximum	Percentile 25.00000	Percentile 75.00000	Variance	Std.Dev.	Skewness	Kurtosis
S&P	114	0.0143	-0.0305	-0.9136	0.9791	-0.4715	0.5514	0.3238	0.5691	0.0835	-1.3388
Ibovespa	114	0.0577	0.0582	-0.9912	0.9975	-0.3174	0.4426	0.2344	0.4841	0.0514	-0.9083
Euro Stoxx 50	114	0.1880	0.2587	-0.9598	0.9737	-0.1629	0.5964	0.2396	0.4895	-0.3641	-0.7704
FTSE100	114	0.0368	0.0221	-0.9733	0.9798	-0.3369	0.4111	0.2138	0.4624	0.1264	-0.8248
CAC 40	114	0.1608	0.2002	-0.9802	0.9800	-0.2173	0.5765	0.2650	0.5148	-0.2849	-0.9272
IBEX 35	114	0.0401	0.0915	-0.9581	0.9769	-0.4492	0.4407	0.2771	0.5264	-0.0755	-1.0127
FTSE MIB	114	0.0773	0.0780	-0.9734	0.9715	-0.3150	0.5935	0.2797	0.5288	-0.0782	-1.1805
PSI 20	114	0.0108	-0.0188	-0.9572	0.9931	-0.3952	0.4133	0.2673	0.5170	0.1541	-1.0471
Shanghai	114	0.0944	0.0848	-0.9673	0.9550	-0.3103	0.5089	0.2561	0.5061	-0.0460	-1.0943
S&P/ASX 200	114	0.0039	-0.0129	-0.9604	0.9943	-0.4170	0.4360	0.2637	0.5135	0.0582	-1.0022
Nikkei	114	0.0442	0.0314	-0.9458	0.9916	-0.3035	0.4065	0.2093	0.4575	-0.0456	-0.8086

### Correlação da variância de IBEX 35 com o esperado em função dos outros mercados.

Variable	Valid N	Mean	Median	Minimum	Maximum	Percentile 25.00000	Percentile 75.00000	Variance	Std.Dev.	Skewness	Kurtosis
S&P	114	0.0385	0.0503	-0.9333	0.9971	-0.3354	0.4513	0.2788	0.5280	-0.0176	-1.0005
Ibovespa	114	0.0401	-0.0035	-0.8753	0.9842	-0.4669	0.5036	0.3050	0.5523	0.1440	-1.2572
Euro Stoxx 50	114	0.1277	0.2007	-0.9829	0.9775	-0.3994	0.6242	0.3086	0.5555	-0.1948	-1.2254
FTSE100	114	0.1003	0.1597	-0.9273	0.9725	-0.2994	0.5600	0.2611	0.5110	-0.0128	-1.0735
CAC 40	114	0.1110	0.0605	-0.8798	0.9632	-0.3866	0.6069	0.2947	0.5429	-0.0680	-1.3112
DAX	114	0.0813	0.1232	-0.9477	0.9397	-0.3798	0.5657	0.2962	0.5442	-0.1058	-1.1962
FTSE MIB	114	0.1102	0.1074	-0.9646	0.9720	-0.2924	0.5380	0.2905	0.5390	-0.2030	-1.0181
PSI 20	114	0.0299	-0.0703	-0.9732	0.9707	-0.4158	0.5171	0.2878	0.5365	0.1212	-1.1923
Shanghai	114	0.0911	0.0830	-0.8111	0.9514	-0.3061	0.4409	0.2135	0.4621	0.0939	-1.0324
S&P/ASX 200	114	0.0258	-0.0826	-0.9195	0.9556	-0.3382	0.4231	0.2229	0.4721	0.1487	-0.9022
Nikkei	114	0.0541	0.0204	-0.9892	0.9940	-0.3725	0.5026	0.2759	0.5253	0.1044	-0.9874

### Correlação da variância de FTSE MIB com o esperado em função dos outros mercados.

Variable	Valid N	Mean	Median	Minimum	Maximum	Percentile 25.00000	Percentile 75.00000	Variance	Std.Dev.	Skewness	Kurtosis
S&P	114	0.1362	0.1171	-0.9311	0.9968	-0.2468	0.6329	0.2644	0.5142	-0.1280	-1.0179
Ibovespa	114	0.1514	0.2278	-0.9446	0.9587	-0.3272	0.5908	0.2858	0.5346	-0.3289	-1.0124
Euro Stoxx 50	114	0.2046	0.3481	-0.9580	0.9942	-0.2203	0.6396	0.3214	0.5670	-0.5241	-0.8919
FTSE100	114	0.0400	-0.0194	-0.8661	0.9702	-0.3427	0.4529	0.2468	0.4968	0.0421	-1.0538
CAC 40	114	0.1696	0.2175	-0.9533	0.9957	-0.2892	0.6669	0.3155	0.5617	-0.3027	-1.0817
DAX	114	0.1510	0.2612	-0.9915	0.9823	-0.2949	0.6286	0.3102	0.5570	-0.3943	-1.0038
IBEX 35	114	0.2262	0.3380	-0.9079	0.9857	-0.1507	0.6562	0.2751	0.5245	-0.4177	-1.0025
PSI 20	114	0.0869	0.1409	-0.9644	0.9467	-0.2519	0.4438	0.2499	0.4999	-0.2853	-0.7092
Shanghai	114	0.1014	0.1002	-0.9288	0.9990	-0.2630	0.5054	0.2613	0.5112	-0.0865	-0.9650
S&P/ASX 200	114	0.0140	-0.1264	-0.9322	0.9792	-0.3991	0.4862	0.2608	0.5107	0.2089	-1.0544
Nikkei	114	0.0167	-0.0132	-0.9905	0.9742	-0.4078	0.3925	0.2492	0.4992	0.1247	-1.0284

### Correlação da variância de PSI 20 com o esperado em função dos outros mercados.

Variable	Valid N	Mean	Median	Minimum	Maximum	Percentile 25.00000	Percentile 75.00000	Variance	Std.Dev.	Skewness	Kurtosis
S&P	114	-0.0157	-0.0498	-0.9482	0.9909	-0.3971	0.3756	0.2848	0.5337	0.1489	-0.9426
Ibovespa	114	0.0326	-0.0146	-0.9416	0.9681	-0.3306	0.4710	0.2244	0.4737	0.1222	-0.7899
Euro Stoxx 50	114	0.0890	0.0224	-0.7671	0.9890	-0.2517	0.4628	0.2253	0.4747	-0.0294	-0.9649
FTSE100	114	0.0597	0.0120	-0.8769	0.9710	-0.3162	0.4911	0.2395	0.4894	0.0458	-1.0350
CAC 40	114	0.0592	0.0733	-0.9617	0.8902	-0.3826	0.4975	0.2558	0.5058	-0.1659	-1.0847
DAX	114	0.0473	0.0825	-0.9565	0.9801	-0.3809	0.4416	0.2689	0.5185	-0.0498	-0.9635
IBEX 35	114	0.0659	0.0405	-0.8589	0.9926	-0.3089	0.4190	0.2490	0.4990	0.0127	-0.9725
FTSE MIB	114	0.1040	0.1054	-0.8478	0.9801	-0.3574	0.5241	0.2612	0.5111	-0.0192	-1.1717
Shanghai	114	-0.0364	-0.0815	-0.9700	0.9537	-0.4742	0.3529	0.2588	0.5087	0.1973	-1.0171
S&P/ASX 200	114	-0.0209	-0.0004	-0.9815	0.9878	-0.5252	0.4469	0.2877	0.5363	0.0577	-1.2293
Nikkei	114	0.1424	0.1130	-0.8473	0.9650	-0.3164	0.5582	0.2666	0.5163	-0.1156	-1.1004

### Correlação da variância de Shanghai com o esperado em função dos outros mercados.

Variable	Valid N	Mean	Median	Minimum	Maximum	Percentile 25.00000	Percentile 75.00000	Variance	Std.Dev.	Skewness	Kurtosis
S&P	113	-0.0171	-0.0837	-0.9924	0.9956	-0.5649	0.6067	0.3872	0.6223	0.1079	-1.405
Ibovespa	113	0.0846	0.1282	-0.9911	0.9898	-0.4578	0.6145	0.3937	0.6275	-0.1467	-1.301
Euro Stoxx 50	113	0.0259	0.0321	-0.9928	0.9968	-0.5643	0.6116	0.3784	0.6151	-0.0803	-1.328
FTSE100	113	-0.0315	-0.0851	-0.9895	0.9921	-0.4587	0.4099	0.2998	0.5475	0.1451	-1.008
CAC 40	113	0.0474	0.0433	-0.9895	0.9892	-0.4289	0.6531	0.3619	0.6015	-0.0430	-1.334
DAX	113	0.0416	0.0355	-0.9970	0.9978	-0.4506	0.5813	0.3417	0.5846	-0.0741	-1.185
IBEX 35	113	-0.0453	-0.0753	-0.9799	0.9963	-0.5149	0.4684	0.3421	0.5849	0.0255	-1.232
FTSE MIB	113	-0.0203	-0.1521	-0.9318	0.9903	-0.4080	0.4695	0.3296	0.5741	0.1855	-1.155
PSI 20	113	0.0328	0.0704	-0.9640	0.9809	-0.3835	0.4877	0.3254	0.5705	-0.0730	-1.031
S&P/ASX 200	114	-0.0538	-0.1052	-0.9981	0.9829	-0.5559	0.3759	0.3525	0.5937	0.1883	-1.137
Nikkei	114	-0.0046	0.0573	-0.9455	0.9886	-0.4383	0.3787	0.2907	0.5391	-0.0588	-0.974

### Correlação da variância de ASX 200 com o esperado em função dos outros mercados.

Variable	Valid N	Mean	Median	Minimum	Maximum	Percentile 25.00000	Percentile 75.00000	Variance	Std.Dev.	Skewness	Kurtosis
S&P	113	0.1378	0.1149	-0.9037	0.9960	-0.2538	0.5418	0.2440	0.4940	-0.1002	-1.0079
Ibovespa	113	0.0572	0.0430	-0.8639	0.9781	-0.4180	0.4581	0.2713	0.5209	0.0706	-1.1865
Euro Stoxx 50	113	0.0111	-0.0744	-0.8061	0.9965	-0.3913	0.4028	0.2389	0.4888	0.2683	-1.1083
FTSE100	113	-0.0337	-0.0441	-0.9971	0.9638	-0.4799	0.3861	0.2756	0.5249	0.1749	-0.9490
CAC 40	113	-0.0036	-0.1027	-0.8608	0.9549	-0.3877	0.4321	0.2638	0.5136	0.2997	-1.1161
DAX	113	-0.0092	-0.0810	-0.9014	0.9927	-0.3522	0.3024	0.2272	0.4767	0.4361	-0.6153
IBEX 35	113	0.0145	0.0077	-0.8962	0.9626	-0.3014	0.3439	0.2054	0.4532	0.1562	-0.8129
FTSE MIB	113	0.0049	-0.1039	-0.8420	0.9765	-0.4311	0.4000	0.2557	0.5056	0.3150	-1.0915
PSI 20	113	0.0291	0.0360	-0.9814	0.9970	-0.4519	0.4703	0.2912	0.5396	0.0694	-1.2677
Shanghai	114	0.0023	-0.1535	-0.9522	0.9769	-0.4126	0.4710	0.2647	0.5145	0.3645	-1.0290
Nikkei	114	-0.0112	-0.0605	-0.9157	0.9763	-0.4472	0.3067	0.2474	0.4974	0.2677	-0.9030

### Correlação da variância de Nikkei com o esperado em função dos outros mercados.

Variable	Valid N	Mean	Median	Minimum	Maximum	Percentile 25.00000	Percentile 75.00000	Variance	Std.Dev.	Skewness	Kurtosis
S&P	113	0.0463	0.0662	-0.8527	0.9766	-0.4105	0.4405	0.2666	0.5163	0.1877	-1.2349
Ibovespa	113	0.0692	0.0945	-0.9392	0.9923	-0.4408	0.5395	0.2959	0.5440	0.0126	-1.2763
Euro Stoxx 50	113	-0.0091	-0.0735	-0.9690	0.9561	-0.4646	0.4424	0.2909	0.5394	0.1798	-1.0941
FTSE100	113	-0.0190	-0.0658	-0.9746	0.9710	-0.4819	0.4915	0.3117	0.5583	0.1995	-1.1398
CAC 40	113	-0.0541	-0.1396	-0.9512	0.9653	-0.5264	0.3949	0.2911	0.5396	0.3112	-1.0447
DAX	113	-0.0026	-0.0160	-0.9549	0.9850	-0.4242	0.4334	0.2805	0.5296	-0.0392	-1.0840
IBEX 35	113	0.0473	0.0070	-0.9667	0.9577	-0.4461	0.5303	0.3174	0.5634	-0.0628	-1.2730
FTSE MIB	113	0.0414	0.0112	-0.9634	0.9919	-0.3717	0.4427	0.2481	0.4981	-0.0421	-0.9396
PSI 20	113	-0.0274	-0.1508	-0.8942	0.9940	-0.4460	0.4036	0.2785	0.5277	0.4359	-0.9952
Shanghai	114	-0.1528	-0.2834	-0.9366	0.9678	-0.5483	0.2223	0.2699	0.5195	0.5939	-0.7440
S&P/ASX 200	114	0.0403	0.0049	-0.9689	0.9127	-0.3401	0.4677	0.2524	0.5024	0.0962	-0.9855

Tabela 9 - Conjunto de tabelas de estatística descritiva dos valores de correlação entre a variância observada com a esperada em função de outros mercados

É observável, ao longo dos mercados, o sentido de perda de qualidade da média por força do modelo de GARCH(1,1) não conseguir antever alterações de direção da variância, tornando-o reativo. Uma vez que é aplicada a variância de um mercado para a estimativa de outro, essas alterações da variância são sentidas com mais frequência, empobrecendo a média com maior facilidade. Este fator é verificável nas grandes diferenças dos valores máximos e mínimos, onde [quando] o mercado segue uma tendência durante um prazo longo, então existe correlação, no entanto quando essa tendência inverte, a correlação torna-se assimétrica e absorve a correlação positiva. Assim, de um modo geral, os mercados não aparentam ter quais quer tipos de correlação quanto à variância esperada, todavia nos mercados Europeus existe alguma correlação presente, tornando-os seguidores uns quanto aos outros. Todavia, existe uma margem de erro que o EWMA produz nos dados, criando uma diferença entre o observável na Tabela 9 com Tabela 8.

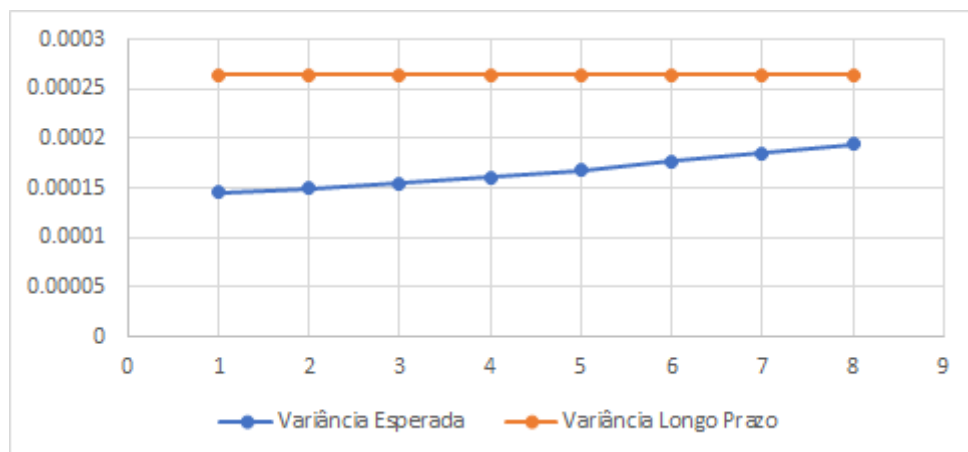


Figura 9 - Gráfico ilustrativo do comportamento dos resultados do EWMA.

Este erro deve-se ao comportamento que o EWMA segue em torno da variância de longo prazo, sem fatores corretivos por meio das observações, observável na Figura 9. Deste modo, por exemplo, quando um mercado sofre uma descida da variância muito acima da sua a longo prazo, o EWMA reproduzirá resultados a convergirem para o seu valor histórico de longo prazo, ou seja, uma subida ao longo do período até chegar à sua

média. Assim, o modelo EWMA falha no acompanhamento de tendências, agarrando-se, para estimativa de valores futuros, ao seu histórico de longo prazo.

Concluindo [assim] que o método de GARCH(1,1) quando aplicado a um mercado de modo a absorver a variância desse mercado na tentativa de prever um outro, por fator de aproveitamento de diferença horária, não é consistente. Ou seja, o modelo enquanto dois mercados seguem a mesma tendência de variância, torna-se um bom estimador de peso para quanto a variância vai evoluir, no entanto quando [pelo menos] um mercado quebra essa tendência, o modelo vai demorar a incorporar essa variância e em simultâneo a reproduzir nos seus valores esperados, conferindo correlações insignificantes ou negativas. Podendo o modelo fazer mais sentido aplicado a *timeframes* maiores, onde as observações sofrem menos ruído e possa ser criado um padrão mais regular. Juntando a esse fator, o erro que EWMA sofre na altura de previsão, faz o modelo de GARCH perder a qualidade de estimador de tendência, extrapolando resultados com correlações insuficientes para auxílio de construção de uma carteira.

### **3.3. Conclusões dos Estudos - Enquadrado Teoricamente**

Como principais conclusões deste estudo, é possível aferir que existe evidência para rejeitar  $H_0$  quanto à normalidade da rendibilidade das cotações dos mercados, sendo necessário refugiar em soluções como o Teorema do Limite Central. Contudo, a fórmula de cálculo da rendibilidade através da função logarítmica cria um enviesamento negativo da distribuição, denotando uma possível menor rendibilidade quanto à realmente observada, período a período. Assim, a análise torna-se mais conservadora quanto à rendibilidade esperada, em troca de excesso de otimismo quanto à variância (risco) observada. Deste modo, é possível aferir utilidade da função logarítmica quanto à rendibilidade, no entanto relativamente à gestão de risco, no momento de decisão, deve-se procurar um outro ativo que tenha uma correlação de variância negativa ou com pouca significância. Isto porque a rendibilidade é comparável, no entanto a variância sem fatores comparativos com outras variâncias não geram informação, sendo útil procurar

resultados de correlação entre variâncias de modo a minimizar o risco através de *hedging*<sup>9</sup>.

Na análise de mercados, relativo ao horizonte temporal da amostra, é possível verificar que os mercados Asiáticos e Americanos cresceram e o Alemão e Britânico foram os únicos mercados Europeus a crescerem, os restantes baixaram. Quanto à volatilidade, o índice do Brasil (*Ibovespa*) é o mais volátil e o Australiano (*ASX 200*) o menos volátil. Sendo possível [ainda] concluir, através do índice tradutor do mercado Europeu (*Eurostoxx 50*), que de um modo geral o mercado Europeu sofreu uma descida e, apesar desse efeito, o mercado Alemão (*DAX*) subiu. Tornando assim o índice *DAX* como um índice seguro quanto a um comportamento mais isolado para seleção de portefólio a nível Europeu, pese embora a sua semelhança em volatilidade.

A nível correlacional, o mercado Europeu tem a maior correlação intra e intercontinental a nível de rendibilidade e risco. Tornando-o no ativo mais fraco na ótica de diversificação internacional quando se pretende efetuar um portefólio a replicar índices. Uma vez que o Shanghai é o mercado menos correlacionável, torna-se um ativo com menos risco de redundância, tanto quanto no campo da rendibilidade como na direção da variância. Em contraste, o *Eurostoxx* é o índice com maior redundância no mercado Europeu, traduzindo fortemente o comportamento da Europa, todavia tendo maior correlação com o mercado Francês (*CAC 40*). Em termos de volatilidade, não existem correlações relevantes internacionalmente, apenas intracontinentalmente nos mercados Europeus e Americanos. Pois, segundo os autores King & Wadhwani (1990) e Bertero & Mayer (1990), correlações tendem a aumentar em período de crises nos mercados. Razão pela qual poderá haver maior correlação no mercado Europeu, devido à crise do setor financeiro sentido entre 2009 e 2014. Tornando viável a diversificação, quanto ao risco, através de uma gestão de carteira com mercados internacionais, minimizando o efeito de contágio.

Relativamente ao período de abril até outubro de 2017, quando analisado os dados com uma *timeframe* à hora comparativamente com os diários, é possível verificar ruído dos dados. Tornando as correlações mais divergentes e diluindo as suas correlações médias.

---

<sup>9</sup> *Hedging* - Instrumento financeiro que visa minimizar ou anular o risco de um ativo contra grandes variações de preço, através de fixação do mesmo via outro produto financeiro.

Adicionando ainda um erro por fatores de divergência horária dos mercados. Contudo, pese embora as limitações, não existem evidências de correlação a nível internacional, existem aliás correlações negativas com o índice de Shanghai, todavia desprezíveis ( $p < 0,09$ ). Sendo ainda possível confirmar que, apesar de não existir o erro da divergência horária nesta análise, o Eurostoxx é um bom medidor de sensibilidade do mercado Europeu, pelas fortes correlações com os restantes índices Europeus. Deste modo, a gestão ativa da carteira a nível de *intraday* é mais previsível quando comparada entre mercados dentro do mesmo horário de funcionamento, caso contrário as limitações do erro horário podem deturpar os resultados esperados e consequentemente a sua gestão.

Numa análise a cada mercado individualmente, é possível verificar várias variâncias ao longo do tempo, denominando esse fator como heterocedástico. De modo a estudar um mercado quanto à sua volatilidade, foi elaborado um teste de *White*, onde se rejeita a hipótese de homocedasticidade. Sendo possível criar modelos de GARCH, de modo a auxiliar a sua análise de variância numa perspetiva previsional. Uma vez satisfeitas as condições empíricas dos ponderados que melhor traduzem cada mercado historicamente ( $\omega$ ,  $\alpha$  e  $\beta$ ) através do método do MLE, é possível criar um modelo de previsão da variância para cada mercado. Onde, posteriormente, é avaliado a qualidade do *output* do modelo através da correlação do resultado previsional com o observado no mercado. Assim sendo, foram verificadas correlações consideráveis das variâncias observadas com as esperadas pelo modelo de GARCH(1,1), contudo a sua média de correlação foi média/baixa, devido ao facto de o modelo seguir a tendência do mercado e quando existe uma alteração de variância rápida, o modelo demora alguns períodos a incorporar essa alteração e cria, numa primeira fase, uma correlação negativa que vai acertando ao longo dos períodos ( $t$ ). Contudo, é uma ferramenta útil quanto ao *forecast* do risco dos mercados quanto a uma tendência. De modo a adequar a composição de uma carteira com o uso do modelo de GARCH(1,1), será útil procurar criar um portefólio que tenham ativos não correlacionáveis com esses fatores de alteração de variância, de modo a criar tempo para o modelo adequar quando um mercado sofre de uma alteração de volatilidade. Assim, conhecendo a tendência esperada, em conjunto com a correlação dos mercados internacionais, é possível criar carteiras mais seguras a nível previsional. No entanto, o modelo de GARCH(1,1) não é um bom estimador de variância entre comportamento de mercados com horários diferentes, na medida em que demora a

incorporar alteração de variâncias, tornando-se inconsistente quando [pelo menos] um mercado não segue uma tendência estável e previsível. Todavia, poderá fazer sentido para períodos de mais longo prazo (com menos ruído), através de aumento do *lag* ou outras de análises com uma *timeframe* superior. A inclusão do EWMA no modelo faz perder o foco que o modelo de GARCH(1,1) absorve da direção da variância do mercado, uma que vez que este forçará as observações a tenderem para a sua Variância de longo prazo independentemente da tendência. Concluindo que a aplicabilidade do modelo de GARCH(1,1) para um mercado é mais útil no seu *forecast* de volatilidade, não para uma previsão da variância baseada em outros mercados.

Em conclusão, como nota final, rendibilidades históricas não são indicativas de rendibilidades futuras. Bem como os resultados obtidos, no estudo, não podem ser considerados representativos dos mercados analisados e usados como análise única no momento de investimento. Onde quaisquer análises fundamentais representadas, devem ser tidas em conta o seu contexto em estudo e com uma aplicação de decisão financeira responsável.

### **3.4. Sugestões e Recomendações**

Os temas relacionados com o estudo da volatilidade dos mercados financeiros e o efeito de contágio entre os vários índices bolsistas são de uma contínua utilidade para os investidores e essenciais para uma gestão mais atualizada de carteiras de investimento. Enriquecendo o campo das ciências financeiras e a qualidade dos instrumentos disponíveis.

Numa fase inicial, o presente estudo analisou 12 índices internacionais, subdivididos por três áreas geográficas. No entanto, o número de índices das áreas Americanas e Asiáticas são limitadas, podendo não representar fidedignamente um estudo de tendência do continente. De forma a encontrar resultados mais fiéis a cada área geográfica, deve-se incluir mais índices que tenham base de dados suficientes para serem analisados. Conferindo mais precisão no momento de interpretação. Outra sugestão passa por incluir outras variáveis que sejam indicatórias de tendência, como por exemplo, as taxas de juro. Deste modo, é possível avaliar qual o peso de outras

variáveis no momento da correlação de mercados. Auxiliando na interpretação de cada mercado e na decisão de um investidor.

Relativamente ao estudo através do modelo de GARCH. Foi possível verificar as mais diferentes possibilidades de teste que o modelo permite. Primeiro, seria útil testar, para a mesma base de dados, modelos de GARCH com atrasos (*lag*) diferentes no modelo e criar uma previsibilidade desse modelo, comparando posteriormente com os obtidos no presente estudo. Tanto numa ótica de ruído como de comportamento. Em segundo lugar, aplicar o modelo de GARCH para diferentes *timeframes* até encontrar um momento ótimo entre a variável qualidade e quantidade de dados com a variável ruído. E por fim, em terceiro lugar, efetuar um *mock-up test* com o modelo de GARCH e extrapolar resultados em unidades monetárias. Pois, no presente teste, o modelo de GARCH não demonstra em que momento a correlação entre a variância esperada com a real fica negativa, ou seja, não é possível ter uma sensibilização do peso do erro na carteira no momento desse erro.

Concluindo que é de interesse a constante análise aos mercados, uma vez que estes são contínuos. E encontrar outros modelos e diferentes formas de análise de modo a tentar interpretar os mercados de novas perspectivas.

#### 4. Conclusão

Devido ao efeito da globalização, os mercados financeiros tornaram-se cada vez mais integrados, registando-se uma difusão de informação à escala global. As informações provenientes de um mercado poderão ser importantes para outros mercados e, em determinadas circunstâncias, condicionar o comportamento dos mesmos. Assim sendo, torna-se relevante analisar o comportamento de cada mercado, quanto à rendibilidade e volatilidade, e as suas correlações. Deste modo, é possível interpretar os mercados de uma forma mais realista e ponderada, facilitando a implementação de estratégias no momento de investimento para uma melhor gestão de um portefólio e consequente avanço científico.

Face às mais diversas abordagens que podem ser realizadas relativamente aos mercados financeiros, no estudo das rendibilidades e risco dos mercados Europeus, Americanos e Asiáticos, referente ao período de 2000 a 2017 para dados diários, é possível concluir que existe correlação entre os mercados a nível de rendibilidade. Conferindo uma baixa diversificação a nível de risco no momento de composição de um portfólio. Contudo, a diferença geográfica atenua o nível de correlação, onde os mercados Orientais e da Oceânia oferecem soluções mais diversificáveis a nível de movimento de preços. Posteriormente, numa análise aos mesmos mercados para o período de 2017 com dados à hora, constata-se um ruído das observações que absorvem a qualidade das análises. Todavia, é possível aferir que o mercado Europeu tem uma tendência de correlação forte em comparação com os restantes Continentes. Denominando [assim] como o pior mercado para procurar soluções de diversificação intracontinentalmente. Por outro lado, o mercado Asiático oferece comportamentos isolados, ideais na minimização de risco. Por fim, dentro de uma infinidade de instrumentos financeiros, o modelo GARCH aplicado a dados à hora, cria resultados satisfatórios a nível de comportamento da variância. Contudo, falha na tentativa de absorção do sentido da variância de um mercado de modo a tentar prever outro, derivado à necessidade de incluir outros modelos possíveis de margem de erro.

Deste modo, o estudo atingiu algumas limitações a nível de modelos e diferenças horárias. Onde não foi possível criar aplicabilidade, para o caso presente, dos modelos de modo a atingir o objetivo pretendido. No entanto, o modelo GARCH tornou-se um bom

modo de ter uma primeira abordagem à estimativa do comportamento da variância. Tendo sido ainda possível constatar que o ruído dos dados criam falsos comportamentos esperados da variância, aumentado a margem de erro do modelo.

Assim sendo, para um futuro estudo e recorrendo à presente dissertação, é ideal aumentar o número de mercados de modo a homogeneizar a amostra geográfica e testar o modelo GARCH com aplicações reais. Tanto para diferentes pesos do fator *lag*, bem como para diferentes *timeframes*. Na tentativa de procurar o ponto ótimo que melhor prevê a representação da população. De seguida, testar a possibilidade de *forecast* por diferentes abordagens. Inicialmente quanto aos próprios mercados nas suas diferentes *timeframes*, compreendendo se existe algum peso na variável da tipologia dos dados pelo fator erro de ruído dos dados. Em segundo, após conhecido a *timeframe* ótima, encontrar diferentes instrumentos financeiros possíveis de repercussão de dados, de modo a tentar manter os dados fidedignos ao seu comportamento original. E por fim, entender qual o melhor horizonte que esses dados podem ser comparáveis no outro mercado, isto é, quanto tempo o novo mercado leva a incluir essas variações até [depois] começar a criar as suas próprias variações.

Concluindo que assim que novos instrumentos financeiros vão sendo criados, quanto maior o número de análises e testes aos mesmos por novas tentativas de implementação de perspectivas, maior será o enriquecimento do estado da arte e mais progressiva é a sua evolução.

## 5. Referências Bibliográficas

- Adambekova, A. A., & Andekina, R. E. (2013). Financial Market and its Definitions: Transformation of Scientific Concepts. *World Applied Sciences Journal 27 (Education, Law, Economics, Language and Communication)*, pp. 12-16.
- Ang, A., & Bekaert, G. (2002). International Asset Allocation With Regime Shifts. *The Review of Financial Studies*, pp. 1137-1187.
- Baele, L. (2009). Volatility Spillover Effects in European Equity Markets. *Journal of Financial and Quantitative Analysis*, pp. 373-401.
- Barber, B., & Lyon, J. (1997). Detecting long-run abnormal stock returns: The empirical power and specification of test statistics. *Journal of Financial Economics*, pp. 341-372.
- Barinov, & Khmyz. (2001). Markets of currency and securities. Moscovo.
- Bertero, E., & Mayer, C. (1990). Structure and performance: Global interdependence of stock markets around the crash of October 1987. *European Economic Review*, pp. 1155-1180.
- Bollerslev, T. (1986). Generalized Autoregressive Conditional. *Journal of Econometrics*, pp. 307-327.
- Bollerslev, T., Chou, R., & Kroner, K. (1992). ARCH modeling in finance: A review of the theory and empirical evidence. *Journal of Econometrics*, pp. 5-59.
- Buffet, W., & Connors, R. (2010). *Warren Buffett on Business: Principles from the Sage of Omaha*.
- Campbell, C., Campbell, R., & Dolan, E. (1993). Money, Banking, and Monetary Policy. Harcourt School.
- Chesnay, F., & Jondeau, E. (2001). Does Correlation Between Stock Returns Really Increase During Turbulent Periods? *Economic Notes*, pp. 53-80.
- Dissanaike, G., & Le Fur, A. (2003). On the Use of the Log CAR Measure in Event Studies. *Journal of Business Finance & Accounting*, pp. 1165-1170.

- Elton, E., & Gruber, M. (1977). Risk Reduction and Portfolio Size: An Analytical Solution. *The Journal of Business*, pp. 415-437.
- Esch, D. (2003). *Non Normality Facts & Fallacies*. New Frontier Advisors, LLC.
- Esipov, V. (2004). *Financial market and its securities*. Moscovo: Complekt.
- Fama, E. (1965). The Behavior of Stock-Market Prices. *Journal of Business*, pp. 34-105.
- Fama, E. (1970). Efficient Capital Markets: A Review of Theory and Empirical Work. *The Journal of Finance*.
- Ferreira, D. (2008). *Futuros e Outros Derivados. 1ª Edição*. Lisboa: Edições Sílabo.
- François, L., & Solnik, B. (2001). Extreme Correlation of International Equity Markets. *The Journal of Finance*, pp. 649-676.
- Jacquier, E., Kane, A., & Marcus, A. (2003). Geometric or Arithmetic Mean: A Reconsideration. *Financial Analysts Journal*, pp. 46-53.
- Kaplanis, E. (1988). Stability and forecasting of the comovement measures of international stock market returns. *Journal of International Money and Finance*, pp. 63-75.
- Karolyi, A., & Stulz, R. (1996). Why Do Markets Move Together? An Investigation of U.S.-Japan Stock Return Comovements. *The Journal of Finance*, pp. 951-986.
- Kat, H., & Miffre, J. (2008). The Impact of Non-Normality Risks and Tactical Trading on Hedge Fund Alphas. *Journal of Alternative Investments*, pp. 8-22.
- Keown, A., & Pinkerton, J. (1981). Merger Announcements and Insider Trading Activity: An Empirical Investigation. *Journal of Finance*, pp. 855-869.
- Kidwell, D., Blackwell, D., Whidbee, D., & Sias, R. (2000). *Financial Institutions, Markets, and Money*, 11th Edition. Texas.
- King, M., & Wadhvani, S. (1990). Transmission of Volatility between Stock Markets. *The Review of Financial Studies*, pp. 5-33.
- Kothari, S., & Warner, J. (1997). Measuring long-horizon security price performance. *Journal of Financial Economics*, pp. 301-339.

- Lin, W.-L., Engle, R., & Ito, T. (1994). Do Bulls and Bears Move Across Borders? International Transmission of Stock Returns and Volatility. *The Review of Financial Studies*, pp. 507-538.
- Lo, A. (2016). What is an Index? *The Journal of Portfolio Management*.
- Longin, F., & Solnik, B. (1995). Is the correlation in international equity returns constant: 1960–1990? *Journal of International Money and Finance*, pp. 3-26.
- Mankiw, N. G. (1994). *Macroeconomics*. macmillan.
- Markowitz, H. (1959). *Portfolio Selection*. New York, United States of America: John Wiley & Sons, Inc.
- Patton, A. (2006). Modelling Asymmetric Exchange Rate Dependence. *International Economic Review*, pp. 527-556.
- Ramchand, L., & Susmel, R. (1997). Volatility and Cross Correlation Across Major Stock Markets. University of Houston.
- Ramchand, L., & Susmel, R. (1998). Volatility and cross correlation across major stock markets. *Journal of Empirical Finance*, pp. 397-416.
- Reider, R. (2009). *Volatility Forecasting I: GARCH Models, Time Series Analysis and Statistical Arbitrage Notes*. New York University.
- Robert, E. (1982). Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. *Journal of the Econometric Society*, pp. 987-1007.
- Rockafellar, R. T., & Uryasev, S. (1999). Optimization of conditional value-at-risk. *Journal of Banking and Finance*, pp. 1443-1471.
- Rosenberg, N. (1974). Science, Invention and Economic Growth. *The Economic Journal*, pp. 90-108.
- Rosenberg, N. (1976). Problems in the Economist's Conceptualization of Technological Innovation . *History of Political Economy*, pp. 456-481.
- Sachs, J., & Larren, F. (s.d.). *Macroeconomics in the Global Economy*.

- Schwarz, G. (1978). Estimating the Dimension of a Model. *The Annals of Statistics*, pp. 461-464.
- Sheikh, A., & Qiao, H. (2009). Non-normality of Market Returns. J.P. Morgan Asset Management.
- Silvennoinen, A., & Teräsvirta, T. (2009). Modeling Multivariate Autoregressive Conditional Heteroskedasticity with the Double Smooth Transition Conditional Correlation GARCH Model. *Journal of Financial Econometrics*, pp. 373-411.
- Solnik, B., Boucrelle, C., & Le Fur, Y. (1996). International Market Correlation and Volatility. *Financial Analysts Journal*, pp. 17-34.
- Statman, M. (1987). How Many Stocks Make a Diversified Portfolio? *Journal of Financial and Quantitative Analysis*.
- Stivers, C., Dennis, P., & Mayhew, S. (2006). Stock Returns, Implied Volatility Innovations, and the Asymmetric Volatility Phenomenon. *Journal of Financial and Quantitative Analysis*, pp. 381-406.
- Strong, R. (2009). *Portfolio Construction, Management, and Protection*. South-Western.






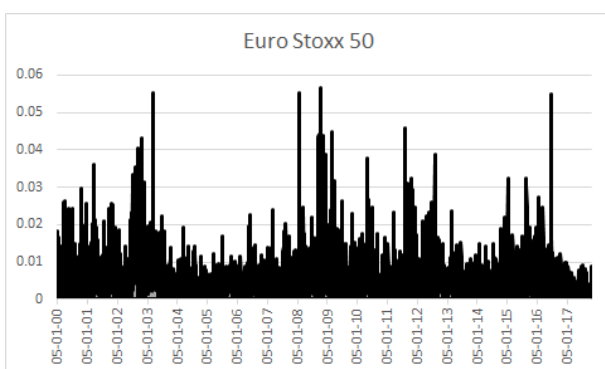


## 6. Netgrafia





Heakal, R. (10 de Outubro de 2017). *Forbes*. Obtido de Forbes:

<https://www.forbes.com/sites/investopedia/2013/11/01/what-is-market-efficiency/#5e78cdea1d2d>









# Anexos





## Anexo A – Tabelas de Desvio Padrão das Rendibilidades no período de 2000 a 2017.





**Anexo B – Tabela das Rendibilidades dos Mercados referentes ao período de 2000 a 2017.**





**Anexo C – Tabelas do Teste *White* nos diferentes mercados – Correlogramas – referente ao período de 2000 a 2017.**

Sample: 4/01/2000 13/04/2017 Included observations: 3570		Index: S&P 500				
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.157	0.157	88.239	0.000
		2	0.181	0.161	205.64	0.000
		3	0.230	0.190	394.00	0.000
		4	0.247	0.185	612.99	0.000
		5	0.345	0.275	1039.1	0.000
		6	0.190	0.077	1168.0	0.000
		7	0.150	0.003	1248.7	0.000
		8	0.180	0.012	1364.9	0.000
		9	0.352	0.221	1809.6	0.000
		10	0.241	0.092	2018.1	0.000
		11	0.191	0.053	2148.8	0.000
		12	0.266	0.133	2401.8	0.000
		13	0.161	-0.023	2494.6	0.000
		14	0.200	-0.053	2637.9	0.000
		15	0.228	0.036	2823.8	0.000
		16	0.143	-0.020	2897.3	0.000
		17	0.118	-0.084	2947.2	0.000
		18	0.172	-0.015	3053.4	0.000
		19	0.173	0.015	3160.8	0.000
		20	0.227	0.081	3345.5	0.000
		21	0.169	0.006	3448.0	0.000
		22	0.154	0.041	3533.0	0.000
		23	0.131	-0.025	3594.6	0.000
		24	0.164	-0.033	3691.6	0.000
		25	0.130	-0.037	3752.7	0.000
		26	0.113	0.003	3798.4	0.000
		27	0.157	0.045	3887.7	0.000
		28	0.075	-0.039	3908.1	0.000
		29	0.104	-0.040	3947.2	0.000
		30	0.095	-0.053	3979.9	0.000
		31	0.121	-0.005	4032.9	0.000
		32	0.106	-0.017	4073.5	0.000
		33	0.135	0.071	4139.2	0.000
		34	0.072	-0.010	4158.2	0.000
		35	0.092	0.006	4189.0	0.000
		36	0.086	-0.032	4215.8	0.000

Sample: 4/01/2000 13/04/2017 Included observations: 3570		Index: Ibovespa				
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.124	0.124	54.899	0.000
		2	0.226	0.214	237.01	0.000
		3	0.098	0.053	271.50	0.000
		4	0.233	0.182	465.62	0.000
		5	0.277	0.233	739.94	0.000
		6	0.119	0.007	790.40	0.000
		7	0.120	0.004	842.33	0.000
		8	0.111	0.030	886.25	0.000
		9	0.281	0.183	1169.3	0.000
		10	0.179	0.071	1284.3	0.000
		11	0.203	0.093	1431.6	0.000
		12	0.110	0.020	1475.2	0.000
		13	0.115	-0.037	1522.9	0.000
		14	0.173	0.020	1630.6	0.000
		15	0.062	-0.074	1644.3	0.000
		16	0.132	0.014	1707.1	0.000
		17	0.078	0.018	1728.8	0.000
		18	0.142	0.029	1801.4	0.000
		19	0.106	0.005	1841.9	0.000
		20	0.165	0.071	1939.5	0.000
		21	0.087	-0.014	1966.8	0.000
		22	0.122	0.018	2020.0	0.000
		23	0.065	-0.039	2035.3	0.000
		24	0.054	-0.036	2045.8	0.000
		25	0.065	-0.030	2060.9	0.000
		26	0.071	0.020	2079.2	0.000
		27	0.102	0.036	2116.8	0.000
		28	0.010	-0.062	2117.1	0.000
		29	0.043	-0.040	2123.8	0.000
		30	0.081	0.031	2147.5	0.000
		31	0.072	-0.011	2166.4	0.000
		32	0.038	-0.024	2171.7	0.000
		33	0.022	0.014	2173.4	0.000
		34	0.021	-0.011	2174.9	0.000
		35	0.039	-0.001	2180.3	0.000
		36	0.021	-0.036	2181.8	0.000

Sample: 4/01/2000 13/04/2017 Included observations: 3570		Index: EuroStoxx 50				
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.148	0.148	78.158	0.000
		2	0.213	0.196	240.65	0.000
		3	0.179	0.132	354.86	0.000
		4	0.196	0.132	492.56	0.000
		5	0.189	0.112	620.70	0.000
		6	0.113	0.014	666.62	0.000
		7	0.168	0.075	767.89	0.000
		8	0.139	0.049	837.18	0.000
		9	0.253	0.169	1066.0	0.000
		10	0.138	0.035	1134.5	0.000
		11	0.140	0.018	1205.0	0.000
		12	0.177	0.065	1317.6	0.000
		13	0.148	0.030	1395.6	0.000
		14	0.143	0.018	1469.2	0.000
		15	0.100	-0.007	1505.0	0.000
		16	0.155	0.043	1591.3	0.000
		17	0.152	0.049	1673.8	0.000
		18	0.169	0.053	1776.5	0.000
		19	0.088	-0.032	1804.2	0.000
		20	0.157	0.050	1893.0	0.000
		21	0.128	0.005	1951.4	0.000
		22	0.097	-0.022	1985.2	0.000
		23	0.106	0.000	2025.8	0.000
		24	0.085	-0.008	2051.7	0.000
		25	0.104	-0.007	2090.4	0.000
		26	0.150	0.065	2171.2	0.000
		27	0.091	-0.012	2201.3	0.000
		28	0.083	-0.011	2226.4	0.000
		29	0.102	-0.001	2263.7	0.000
		30	0.065	-0.041	2279.1	0.000
		31	0.056	-0.027	2290.2	0.000
		32	0.083	0.015	2314.8	0.000
		33	0.060	-0.011	2327.8	0.000
		34	0.060	-0.015	2340.8	0.000
		35	0.091	0.020	2370.4	0.000
		36	0.062	-0.005	2384.1	0.000

Sample: 4/01/2000 13/04/2017 Included observations: 3570		Index: FTSE 100				
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.171	0.171	104.74	0.000
		2	0.299	0.278	424.00	0.000
		3	0.210	0.140	581.19	0.000
		4	0.214	0.108	745.32	0.000
		5	0.241	0.138	953.29	0.000
		6	0.116	-0.019	1001.8	0.000
		7	0.178	0.044	1115.0	0.000
		8	0.151	0.052	1196.7	0.000
		9	0.351	0.272	1637.1	0.000
		10	0.195	0.077	1773.9	0.000
		11	0.205	0.021	1924.2	0.000
		12	0.233	0.074	2118.6	0.000
		13	0.143	-0.035	2192.1</	

Sample: 4/01/2000 13/04/2017  
Included observations: 3570

**Index: CAC 40**

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.136	0.136	66.188	0.000
		2 0.189	0.174	194.07	0.000
		3 0.159	0.120	284.34	0.000
		4 0.178	0.125	397.89	0.000
		5 0.208	0.146	553.31	0.000
		6 0.092	0.002	583.49	0.000
		7 0.138	0.050	651.20	0.000
		8 0.148	0.070	729.15	0.000
		9 0.254	0.180	959.98	0.000
		10 0.167	0.073	1060.4	0.000
		11 0.131	0.022	1121.8	0.000
		12 0.204	0.098	1270.8	0.000
		13 0.127	0.004	1328.5	0.000
		14 0.172	0.041	1435.0	0.000
		15 0.103	-0.000	1473.0	0.000
		16 0.132	0.024	1535.2	0.000
		17 0.138	0.021	1603.6	0.000
		18 0.150	0.036	1684.0	0.000
		19 0.088	-0.038	1712.0	0.000
		20 0.133	0.033	1775.7	0.000
		21 0.158	0.042	1865.2	0.000
		22 0.082	-0.036	1889.1	0.000
		23 0.115	0.003	1936.9	0.000
		24 0.072	-0.025	1955.4	0.000
		25 0.097	-0.007	1989.2	0.000
		26 0.149	0.057	2069.2	0.000
		27 0.073	-0.015	2088.5	0.000
		28 0.086	-0.008	2115.0	0.000
		29 0.098	0.013	2150.0	0.000
		30 0.059	-0.056	2162.7	0.000
		31 0.061	-0.021	2176.1	0.000
		32 0.077	0.011	2197.5	0.000
		33 0.063	-0.004	2211.8	0.000
		34 0.051	-0.018	2221.3	0.000
		35 0.087	0.013	2248.5	0.000
		36 0.062	0.006	2262.5	0.000

Sample: 4/01/2000 13/04/2017  
Included observations: 3570

**Index: DAX**

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.139	0.139	68.677	0.000
		2 0.207	0.191	221.13	0.000
		3 0.163	0.120	315.79	0.000
		4 0.225	0.169	497.00	0.000
		5 0.137	0.058	564.15	0.000
		6 0.199	0.112	705.83	0.000
		7 0.155	0.065	791.30	0.000
		8 0.167	0.062	891.54	0.000
		9 0.280	0.199	1172.0	0.000
		10 0.172	0.056	1278.3	0.000
		11 0.191	0.066	1409.2	0.000
		12 0.151	0.022	1491.0	0.000
		13 0.190	0.047	1620.9	0.000
		14 0.120	-0.006	1672.2	0.000
		15 0.138	-0.010	1740.7	0.000
		16 0.159	0.043	1831.1	0.000
		17 0.165	0.037	1929.0	0.000
		18 0.127	-0.016	1986.5	0.000
		19 0.109	-0.031	2029.1	0.000
		20 0.181	0.059	2146.4	0.000
		21 0.112	-0.009	2191.4	0.000
		22 0.108	-0.028	2233.2	0.000
		23 0.100	-0.007	2269.3	0.000
		24 0.125	0.014	2325.2	0.000
		25 0.121	0.021	2378.2	0.000
		26 0.147	0.036	2456.2	0.000
		27 0.084	-0.017	2481.6	0.000
		28 0.096	-0.005	2514.7	0.000
		29 0.127	0.018	2573.0	0.000
		30 0.069	-0.035	2590.1	0.000
		31 0.077	-0.010	2611.8	0.000
		32 0.070	-0.015	2629.5	0.000
		33 0.072	-0.025	2648.4	0.000
		34 0.076	-0.000	2669.3	0.000
		35 0.097	0.014	2703.3	0.000
		36 0.086	0.020	2730.3	0.000

Sample: 4/01/2000 13/04/2017  
Included observations: 3570

**Index: IBEX 35**

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.085	0.085	25.898	0.000
		2 0.135	0.129	91.129	0.000
		3 0.133	0.115	154.62	0.000
		4 0.108	0.077	196.45	0.000
		5 0.190	0.155	325.75	0.000
		6 0.060	0.008	338.45	0.000
		7 0.152	0.098	421.10	0.000
		8 0.098	0.040	455.36	0.000
		9 0.202	0.151	601.35	0.000
		10 0.115	0.040	648.89	0.000
		11 0.069	-0.001	665.90	0.000
		12 0.134	0.048	729.84	0.000
		13 0.082	0.016	753.87	0.000
		14 0.091	-0.003	783.57	0.000
		15 0.043	-0.025	790.20	0.000
		16 0.101	0.033	826.81	0.000
		17 0.089	0.018	855.20	0.000
		18 0.101	0.035	891.63	0.000
		19 0.056	-0.018	902.90	0.000
		20 0.077	0.027	924.02	0.000
		21 0.108	0.038	966.28	0.000
		22 0.055	-0.002	977.21	0.000
		23 0.075	0.012	997.32	0.000
		24 0.034	-0.015	1001.5	0.000
		25 0.052	-0.014	1011.1	0.000
		26 0.063	0.004	1025.5	0.000
		27 0.046	-0.002	1033.1	0.000
		28 0.044	-0.008	1040.2	0.000
		29 0.038	-0.006	1045.2	0.000
		30 0.032	-0.027	1049.0	0.000
		31 0.035	0.000	1053.5	0.000
		32 0.038	0.004	1058.8	0.000
		33 0.026	-0.006	1061.2	0.000
		34 0.021	-0.011	1062.8	0.000
		35 0.039	0.012	1068.2	0.000
		36 0.028	0.003	1071.0	0.000

Sample: 4/01/2000 13/04/2017  
Included observations: 3570

**Index: FTSE MIB**

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.112	0.112	44.760	0.000
		2 0.138	0.127	112.60	0.000
		3 0.152	0.128	195.49	0.000
		4 0.108	0.068	237.14	0.000
		5 0.156	0.113	323.93	0.000
		6 0.088	0.032	351.44	0.000
		7 0.102	0.046	388.57	0.000
		8 0.123	0.066	442.61	0.000
		9 0.185	0.136	565.83	0.000
		10 0.111	0.039	609.61	0.000
		11 0.086	0.010	636.19	0.000
		12 0.136	0.061	702.22	0.000
		13 0.069	-0.006	719.53	0.000
		14 0.101	0.023	756.30	0.000
		15 0.056	-0.015	767.63	0.000
		16 0.081	0.020	791.06	0.000
		17 0.077	0.004	812.22	0.000
		18 0.121	0.060	864.67	0.000
		19 0.066	-0.003	880.44	0.000
		20 0.089	0.030	909.14	0.000
		21 0.108	0.036	950.91	0.000
		22 0.093	0.035	981.86	0.000
		23 0.072	-0.000	1000.4	0.000
		24 0.061	-0.000	1013.9	0.000
		25 0.055	-0.008	1024.8	0.000
		26 0.065	0.001	1040.0	0.000
		27 0.053	-0.010	1050.0	0.000
		28 0.042	-0.014	1056.2	0.000
		29 0.062	0.011	1070.2	0.000
		30 0.020	-0.045	1071.7	0.000
		31 0.042	-0.006	1078.1	0.000
		32 0.040	-0.005	1084.0	0.000
		33 0.039	0.006	1089.3	0.000
		34 0.019	-0.024	1090.6	0.000
		35 0.025	-0.004	1092.9	0.000
		36 0.054	0.025	1103.5	0.000

Sample: 4/01/2000 13/04/2017  
Included observations: 3570

Index: PSI 20

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.128	0.128	58.707	0.000
		2	0.152	0.138	141.44	0.000
		3	0.178	0.149	254.89	0.000
		4	0.103	0.053	293.16	0.000
		5	0.156	0.104	379.79	0.000
		6	0.087	0.023	406.85	0.000
		7	0.108	0.051	448.79	0.000
		8	0.115	0.052	495.84	0.000
		9	0.269	0.227	755.61	0.000
		10	0.120	0.035	807.48	0.000
		11	0.098	0.004	842.01	0.000
		12	0.154	0.053	927.24	0.000
		13	0.047	-0.038	935.14	0.000
		14	0.104	0.011	973.56	0.000
		15	0.076	0.008	994.30	0.000
		16	0.095	0.037	1026.5	0.000
		17	0.083	0.001	1051.5	0.000
		18	0.136	0.047	1118.0	0.000
		19	0.071	-0.016	1136.2	0.000
		20	0.078	0.009	1158.0	0.000
		21	0.116	0.028	1205.9	0.000
		22	0.019	-0.034	1207.2	0.000
		23	0.082	0.016	1231.1	0.000
		24	0.040	-0.021	1236.8	0.000
		25	0.040	-0.013	1242.6	0.000
		26	0.075	0.016	1262.9	0.000
		27	0.037	-0.022	1267.8	0.000
		28	0.032	-0.023	1271.5	0.000
		29	0.031	-0.012	1275.0	0.000
		30	0.011	-0.049	1275.4	0.000
		31	0.053	0.044	1285.5	0.000
		32	0.045	0.013	1293.0	0.000
		33	0.023	-0.004	1294.9	0.000
		34	0.029	0.005	1298.0	0.000
		35	0.053	0.017	1308.2	0.000
		36	0.050	0.026	1317.3	0.000

Sample: 4/01/2000 13/04/2017  
Included observations: 3570

Index: SHANGHAI

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.132	0.132	62.656	0.000
		2	0.117	0.102	111.91	0.000
		3	0.140	0.116	182.14	0.000
		4	0.145	0.109	257.58	0.000
		5	0.116	0.068	305.43	0.000
		6	0.057	0.001	316.86	0.000
		7	0.115	0.068	363.86	0.000
		8	0.102	0.050	401.17	0.000
		9	0.097	0.046	434.59	0.000
		10	0.086	0.034	460.80	0.000
		11	0.081	0.026	484.36	0.000
		12	0.094	0.037	515.80	0.000
		13	0.091	0.038	545.62	0.000
		14	0.080	0.024	568.66	0.000
		15	0.073	0.017	587.83	0.000
		16	0.063	0.005	602.00	0.000
		17	0.101	0.049	638.47	0.000
		18	0.110	0.057	681.77	0.000
		19	0.094	0.037	713.83	0.000
		20	0.059	-0.006	726.31	0.000
		21	0.083	0.020	750.90	0.000
		22	0.077	0.012	772.35	0.000
		23	0.076	0.020	792.89	0.000
		24	0.049	-0.007	801.53	0.000
		25	0.094	0.041	833.28	0.000
		26	0.076	0.014	853.92	0.000
		27	0.056	-0.001	865.02	0.000
		28	0.037	-0.020	869.81	0.000
		29	0.057	0.005	881.55	0.000
		30	0.062	0.009	895.57	0.000
		31	0.102	0.061	933.13	0.000
		32	0.074	0.023	953.05	0.000
		33	0.037	-0.020	957.90	0.000
		34	0.141	0.091	1029.4	0.000
		35	0.096	0.032	1062.8	0.000
		36	0.055	-0.012	1073.8	0.000

Sample: 4/01/2000 13/04/2017  
Included observations: 3570

Index: S&P/ASX 200

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.112	0.112	45.065	0.000
		2	0.206	0.196	196.59	0.000
		3	0.321	0.295	564.23	0.000
		4	0.120	0.048	615.98	0.000
		5	0.254	0.155	846.93	0.000
		6	0.137	0.009	914.09	0.000
		7	0.159	0.058	1004.2	0.000
		8	0.208	0.078	1158.5	0.000
		9	0.212	0.140	1320.0	0.000
		10	0.193	0.073	1452.8	0.000
		11	0.081	-0.071	1476.6	0.000
		12	0.123	-0.046	1530.7	0.000
		13	0.165	0.043	1628.4	0.000
		14	0.137	0.062	1695.5	0.000
		15	0.145	0.048	1770.6	0.000
		16	0.139	0.034	1839.9	0.000
		17	0.183	0.068	1960.6	0.000
		18	0.108	-0.036	2002.3	0.000
		19	0.182	0.071	2121.1	0.000
		20	0.115	0.007	2168.8	0.000
		21	0.078	-0.018	2190.6	0.000
		22	0.252	0.125	2418.2	0.000
		23	0.085	-0.014	2444.5	0.000
		24	0.114	-0.020	2491.4	0.000
		25	0.114	-0.055	2538.0	0.000
		26	0.099	0.013	2573.4	0.000
		27	0.092	-0.040	2603.7	0.000
		28	0.058	-0.023	2615.7	0.000
		29	0.141	0.061	2687.1	0.000
		30	0.100	0.031	2722.9	0.000
		31	0.096	-0.006	2755.8	0.000
		32	0.152	0.037	2838.7	0.000
		33	0.036	-0.035	2843.4	0.000
		34	0.102	0.010	2881.0	0.000
		35	0.064	-0.042	2895.6	0.000
		36	0.079	0.023	2918.0	0.000

Sample: 4/01/2000 13/04/2017  
Included observations: 3570

Index: Nikkei

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.163	0.163	95.204	0.000
		2	0.219	0.197	265.88	0.000
		3	0.253	0.205	494.27	0.000
		4	0.213	0.133	655.98	0.000
		5	0.230	0.131	845.54	0.000
		6	0.225	0.111	1026.5	0.000
		7	0.119	-0.022	1077.5	0.000
		8	0.137	-0.007	1144.5	0.000
		9	0.251	0.142	1370.4	0.000
		10	0.173	0.064	1477.8	0.000
		11	0.180	0.056	1594.4	0.000
		12	0.095	-0.054	1627.0	0.000
		13	0.162	0.038	1721.7	0.000
		14	0.135	0.000	1786.6	0.000
		15	0.121	-0.011	1839.4	0.000
		16	0.078	-0.035	1861.4	0.000
		17	0.056	-0.042	1872.7	0.000
		18	0.066	-0.031	1888.1	0.000
		19	0.106	0.024	1928.6	0.000
		20	0.060	-0.015	1941.5	0.000
		21	0.041	-0.010	1947.5	0.000
		22	0.052	-0.009	1957.2	0.000
		23	0.056	0.009	1968.5	0.000
		24	0.032	-0.030	1972.2	0.000
		25	0.045	0.007	1979.4	0.000
		26	0.017	-0.005	1980.5	0.000
		27	0.043	0.033	1987.2	0.000
		28	0.008	-0.030	1987.4	0.000
		29	0.073	0.060	2006.6	0.000
		30	0.023	0.007	2008.5	0.000
		31	0.036	0.024	2013.1	0.000
		32	0.034	-0.001	2017.2	0.000
		33	0.008	-0.022	2017.4	0.000
		34	0.035	0.008	2022.0	0.000
		35	0.031	0.013	2025.4	0.000
		36	0.000	-0.025	2025.4	0.000

**Anexo D – Resultados dos componentes Empíricos para o modelo GARCH referente a cada mercado e os seus critérios, relativo ao período de abril 2017 a outubro de 2017.**

<p>Dependent Variable: S_P Method: ML ARCH - Normal distribution (BFGS / Marquardt steps) Date: 07/12/17 Time: 22:15 Sample: 4/01/2000 13/04/2017 Included observations: 3570 Convergence achieved after 23 iterations Coefficient covariance computed using outer product of gradients Presample variance: backcast (parameter = 0.7) GARCH = C(2) + C(3)*RESID(-1)^2 + C(4)*GARCH(-1)</p> <table border="1"> <thead> <tr> <th>Variable</th> <th>Coefficient</th> <th>Std. Error</th> <th>z-Statistic</th> <th>Prob.</th> </tr> </thead> <tbody> <tr> <td>C</td> <td>0.000402</td> <td>0.000128</td> <td>3.142335</td> <td>0.0017</td> </tr> </tbody> </table> <p>Variance Equation</p> <table border="1"> <thead> <tr> <th></th> <th>C</th> <th>RESID(-1)^2</th> <th>GARCH(-1)</th> </tr> </thead> <tbody> <tr> <td>C</td> <td>1.68E-06</td> <td>1.70E-07</td> <td>9.936399</td> </tr> <tr> <td>RESID(-1)^2</td> <td>0.090356</td> <td>0.005817</td> <td>15.53439</td> </tr> <tr> <td>GARCH(-1)</td> <td>0.892392</td> <td>0.006522</td> <td>136.8203</td> </tr> </tbody> </table> <table border="1"> <tbody> <tr> <td>R-squared</td> <td>-0.000790</td> <td>Mean dependent var</td> <td>0.000102</td> </tr> <tr> <td>Adjusted R-squared</td> <td>-0.000790</td> <td>S.D. dependent var</td> <td>0.010674</td> </tr> <tr> <td>S.E. of regression</td> <td>0.010679</td> <td>Akaike info criterion</td> <td>-6.656925</td> </tr> <tr> <td>Sum squared resid</td> <td>0.406975</td> <td>Schwarz criterion</td> <td>-6.650001</td> </tr> <tr> <td>Log likelihood</td> <td>11886.61</td> <td>Hannan-Quinn criter.</td> <td>-6.654457</td> </tr> <tr> <td>Durbin-Watson stat</td> <td>2.112799</td> <td></td> <td></td> </tr> </tbody> </table>	Variable	Coefficient	Std. Error	z-Statistic	Prob.	C	0.000402	0.000128	3.142335	0.0017		C	RESID(-1)^2	GARCH(-1)	C	1.68E-06	1.70E-07	9.936399	RESID(-1)^2	0.090356	0.005817	15.53439	GARCH(-1)	0.892392	0.006522	136.8203	R-squared	-0.000790	Mean dependent var	0.000102	Adjusted R-squared	-0.000790	S.D. dependent var	0.010674	S.E. of regression	0.010679	Akaike info criterion	-6.656925	Sum squared resid	0.406975	Schwarz criterion	-6.650001	Log likelihood	11886.61	Hannan-Quinn criter.	-6.654457	Durbin-Watson stat	2.112799			<p>Dependent Variable: IBOVESPA Method: ML ARCH - Normal distribution (BFGS / Marquardt steps) Date: 07/12/17 Time: 22:09 Sample: 4/01/2000 13/04/2017 Included observations: 3570 Convergence achieved after 25 iterations Coefficient covariance computed using outer product of gradients Presample variance: backcast (parameter = 0.7) GARCH = C(2) + C(3)*RESID(-1)^2 + C(4)*GARCH(-1)</p> <table border="1"> <thead> <tr> <th>Variable</th> <th>Coefficient</th> <th>Std. Error</th> <th>z-Statistic</th> <th>Prob.</th> </tr> </thead> <tbody> <tr> <td>C</td> <td>0.000567</td> <td>0.000226</td> <td>2.509260</td> <td>0.0121</td> </tr> </tbody> </table> <p>Variance Equation</p> <table border="1"> <thead> <tr> <th></th> <th>C</th> <th>RESID(-1)^2</th> <th>GARCH(-1)</th> </tr> </thead> <tbody> <tr> <td>C</td> <td>6.94E-06</td> <td>1.08E-06</td> <td>6.443122</td> </tr> <tr> <td>RESID(-1)^2</td> <td>0.065251</td> <td>0.006129</td> <td>10.64653</td> </tr> <tr> <td>GARCH(-1)</td> <td>0.903365</td> <td>0.009433</td> <td>95.76800</td> </tr> </tbody> </table> <table border="1"> <tbody> <tr> <td>R-squared</td> <td>-0.000141</td> <td>Mean dependent var</td> <td>0.000384</td> </tr> <tr> <td>Adjusted R-squared</td> <td>-0.000141</td> <td>S.D. dependent var</td> <td>0.015432</td> </tr> <tr> <td>S.E. of regression</td> <td>0.015433</td> <td>Akaike info criterion</td> <td>-5.646779</td> </tr> <tr> <td>Sum squared resid</td> <td>0.850087</td> <td>Schwarz criterion</td> <td>-5.639854</td> </tr> <tr> <td>Log likelihood</td> <td>10083.50</td> <td>Hannan-Quinn criter.</td> <td>-5.644310</td> </tr> <tr> <td>Durbin-Watson stat</td> <td>1.959488</td> <td></td> <td></td> </tr> </tbody> </table>	Variable	Coefficient	Std. Error	z-Statistic	Prob.	C	0.000567	0.000226	2.509260	0.0121		C	RESID(-1)^2	GARCH(-1)	C	6.94E-06	1.08E-06	6.443122	RESID(-1)^2	0.065251	0.006129	10.64653	GARCH(-1)	0.903365	0.009433	95.76800	R-squared	-0.000141	Mean dependent var	0.000384	Adjusted R-squared	-0.000141	S.D. dependent var	0.015432	S.E. of regression	0.015433	Akaike info criterion	-5.646779	Sum squared resid	0.850087	Schwarz criterion	-5.639854	Log likelihood	10083.50	Hannan-Quinn criter.	-5.644310	Durbin-Watson stat	1.959488		
Variable	Coefficient	Std. Error	z-Statistic	Prob.																																																																																																	
C	0.000402	0.000128	3.142335	0.0017																																																																																																	
	C	RESID(-1)^2	GARCH(-1)																																																																																																		
C	1.68E-06	1.70E-07	9.936399																																																																																																		
RESID(-1)^2	0.090356	0.005817	15.53439																																																																																																		
GARCH(-1)	0.892392	0.006522	136.8203																																																																																																		
R-squared	-0.000790	Mean dependent var	0.000102																																																																																																		
Adjusted R-squared	-0.000790	S.D. dependent var	0.010674																																																																																																		
S.E. of regression	0.010679	Akaike info criterion	-6.656925																																																																																																		
Sum squared resid	0.406975	Schwarz criterion	-6.650001																																																																																																		
Log likelihood	11886.61	Hannan-Quinn criter.	-6.654457																																																																																																		
Durbin-Watson stat	2.112799																																																																																																				
Variable	Coefficient	Std. Error	z-Statistic	Prob.																																																																																																	
C	0.000567	0.000226	2.509260	0.0121																																																																																																	
	C	RESID(-1)^2	GARCH(-1)																																																																																																		
C	6.94E-06	1.08E-06	6.443122																																																																																																		
RESID(-1)^2	0.065251	0.006129	10.64653																																																																																																		
GARCH(-1)	0.903365	0.009433	95.76800																																																																																																		
R-squared	-0.000141	Mean dependent var	0.000384																																																																																																		
Adjusted R-squared	-0.000141	S.D. dependent var	0.015432																																																																																																		
S.E. of regression	0.015433	Akaike info criterion	-5.646779																																																																																																		
Sum squared resid	0.850087	Schwarz criterion	-5.639854																																																																																																		
Log likelihood	10083.50	Hannan-Quinn criter.	-5.644310																																																																																																		
Durbin-Watson stat	1.959488																																																																																																				
<p>Dependent Variable: EURO_STOXX_50 Method: ML ARCH - Normal distribution (BFGS / Marquardt steps) Date: 07/12/17 Time: 22:00 Sample: 4/01/2000 13/04/2017 Included observations: 3570 Convergence achieved after 31 iterations Coefficient covariance computed using outer product of gradients Presample variance: backcast (parameter = 0.7) GARCH = C(2) + C(3)*RESID(-1)^2 + C(4)*GARCH(-1)</p> <table border="1"> <thead> <tr> <th>Variable</th> <th>Coefficient</th> <th>Std. Error</th> <th>z-Statistic</th> <th>Prob.</th> </tr> </thead> <tbody> <tr> <td>C</td> <td>0.000438</td> <td>0.000152</td> <td>2.883865</td> <td>0.0039</td> </tr> </tbody> </table> <p>Variance Equation</p> <table border="1"> <thead> <tr> <th></th> <th>C</th> <th>RESID(-1)^2</th> <th>GARCH(-1)</th> </tr> </thead> <tbody> <tr> <td>C</td> <td>1.75E-06</td> <td>2.95E-07</td> <td>5.923866</td> </tr> <tr> <td>RESID(-1)^2</td> <td>0.085151</td> <td>0.005417</td> <td>15.71907</td> </tr> <tr> <td>GARCH(-1)</td> <td>0.906969</td> <td>0.005927</td> <td>153.0262</td> </tr> </tbody> </table> <table border="1"> <tbody> <tr> <td>R-squared</td> <td>-0.001061</td> <td>Mean dependent var</td> <td>1.32E-05</td> </tr> <tr> <td>Adjusted R-squared</td> <td>-0.001061</td> <td>S.D. dependent var</td> <td>0.013033</td> </tr> <tr> <td>S.E. of regression</td> <td>0.013040</td> <td>Akaike info criterion</td> <td>-6.125709</td> </tr> <tr> <td>Sum squared resid</td> <td>0.606845</td> <td>Schwarz criterion</td> <td>-6.118784</td> </tr> <tr> <td>Log likelihood</td> <td>10938.39</td> <td>Hannan-Quinn criter.</td> <td>-6.123240</td> </tr> <tr> <td>Durbin-Watson stat</td> <td>1.986986</td> <td></td> <td></td> </tr> </tbody> </table>	Variable	Coefficient	Std. Error	z-Statistic	Prob.	C	0.000438	0.000152	2.883865	0.0039		C	RESID(-1)^2	GARCH(-1)	C	1.75E-06	2.95E-07	5.923866	RESID(-1)^2	0.085151	0.005417	15.71907	GARCH(-1)	0.906969	0.005927	153.0262	R-squared	-0.001061	Mean dependent var	1.32E-05	Adjusted R-squared	-0.001061	S.D. dependent var	0.013033	S.E. of regression	0.013040	Akaike info criterion	-6.125709	Sum squared resid	0.606845	Schwarz criterion	-6.118784	Log likelihood	10938.39	Hannan-Quinn criter.	-6.123240	Durbin-Watson stat	1.986986			<p>Dependent Variable: FTSE100 Method: ML ARCH - Normal distribution (BFGS / Marquardt steps) Date: 07/12/17 Time: 22:02 Sample: 4/01/2000 13/04/2017 Included observations: 3570 Convergence achieved after 32 iterations Coefficient covariance computed using outer product of gradients Presample variance: backcast (parameter = 0.7) GARCH = C(2) + C(3)*RESID(-1)^2 + C(4)*GARCH(-1)</p> <table border="1"> <thead> <tr> <th>Variable</th> <th>Coefficient</th> <th>Std. Error</th> <th>z-Statistic</th> <th>Prob.</th> </tr> </thead> <tbody> <tr> <td>C</td> <td>0.000271</td> <td>0.000120</td> <td>2.262756</td> <td>0.0237</td> </tr> </tbody> </table> <p>Variance Equation</p> <table border="1"> <thead> <tr> <th></th> <th>C</th> <th>RESID(-1)^2</th> <th>GARCH(-1)</th> </tr> </thead> <tbody> <tr> <td>C</td> <td>1.22E-06</td> <td>1.89E-07</td> <td>6.461102</td> </tr> <tr> <td>RESID(-1)^2</td> <td>0.097260</td> <td>0.006142</td> <td>15.83572</td> </tr> <tr> <td>GARCH(-1)</td> <td>0.893126</td> <td>0.006271</td> <td>142.4312</td> </tr> </tbody> </table> <table border="1"> <tbody> <tr> <td>R-squared</td> <td>-0.000646</td> <td>Mean dependent var</td> <td>4.80E-06</td> </tr> <tr> <td>Adjusted R-squared</td> <td>-0.000646</td> <td>S.D. dependent var</td> <td>0.010489</td> </tr> <tr> <td>S.E. of regression</td> <td>0.010492</td> <td>Akaike info criterion</td> <td>-6.648003</td> </tr> <tr> <td>Sum squared resid</td> <td>0.392887</td> <td>Schwarz criterion</td> <td>-6.641079</td> </tr> <tr> <td>Log likelihood</td> <td>11870.69</td> <td>Hannan-Quinn criter.</td> <td>-6.645534</td> </tr> <tr> <td>Durbin-Watson stat</td> <td>2.017859</td> <td></td> <td></td> </tr> </tbody> </table>	Variable	Coefficient	Std. Error	z-Statistic	Prob.	C	0.000271	0.000120	2.262756	0.0237		C	RESID(-1)^2	GARCH(-1)	C	1.22E-06	1.89E-07	6.461102	RESID(-1)^2	0.097260	0.006142	15.83572	GARCH(-1)	0.893126	0.006271	142.4312	R-squared	-0.000646	Mean dependent var	4.80E-06	Adjusted R-squared	-0.000646	S.D. dependent var	0.010489	S.E. of regression	0.010492	Akaike info criterion	-6.648003	Sum squared resid	0.392887	Schwarz criterion	-6.641079	Log likelihood	11870.69	Hannan-Quinn criter.	-6.645534	Durbin-Watson stat	2.017859		
Variable	Coefficient	Std. Error	z-Statistic	Prob.																																																																																																	
C	0.000438	0.000152	2.883865	0.0039																																																																																																	
	C	RESID(-1)^2	GARCH(-1)																																																																																																		
C	1.75E-06	2.95E-07	5.923866																																																																																																		
RESID(-1)^2	0.085151	0.005417	15.71907																																																																																																		
GARCH(-1)	0.906969	0.005927	153.0262																																																																																																		
R-squared	-0.001061	Mean dependent var	1.32E-05																																																																																																		
Adjusted R-squared	-0.001061	S.D. dependent var	0.013033																																																																																																		
S.E. of regression	0.013040	Akaike info criterion	-6.125709																																																																																																		
Sum squared resid	0.606845	Schwarz criterion	-6.118784																																																																																																		
Log likelihood	10938.39	Hannan-Quinn criter.	-6.123240																																																																																																		
Durbin-Watson stat	1.986986																																																																																																				
Variable	Coefficient	Std. Error	z-Statistic	Prob.																																																																																																	
C	0.000271	0.000120	2.262756	0.0237																																																																																																	
	C	RESID(-1)^2	GARCH(-1)																																																																																																		
C	1.22E-06	1.89E-07	6.461102																																																																																																		
RESID(-1)^2	0.097260	0.006142	15.83572																																																																																																		
GARCH(-1)	0.893126	0.006271	142.4312																																																																																																		
R-squared	-0.000646	Mean dependent var	4.80E-06																																																																																																		
Adjusted R-squared	-0.000646	S.D. dependent var	0.010489																																																																																																		
S.E. of regression	0.010492	Akaike info criterion	-6.648003																																																																																																		
Sum squared resid	0.392887	Schwarz criterion	-6.641079																																																																																																		
Log likelihood	11870.69	Hannan-Quinn criter.	-6.645534																																																																																																		
Durbin-Watson stat	2.017859																																																																																																				

<p>Dependent Variable: CAC_40  Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)  Date: 07/12/17 Time: 21:54  Sample: 4/01/2000 13/04/2017  Included observations: 3570  Convergence achieved after 27 iterations  Coefficient covariance computed using outer product of gradients  Presample variance: backcast (parameter = 0.7)  GARCH = C(2) + C(3)*RESID(-1)^2 + C(4)*GARCH(-1)</p>	<p>Dependent Variable: DAX  Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)  Date: 07/12/17 Time: 21:59  Sample: 4/01/2000 13/04/2017  Included observations: 3570  Convergence achieved after 26 iterations  Coefficient covariance computed using outer product of gradients  Presample variance: backcast (parameter = 0.7)  GARCH = C(2) + C(3)*RESID(-1)^2 + C(4)*GARCH(-1)</p>																																																
<table border="1"> <thead> <tr> <th>Variable</th> <th>Coefficient</th> <th>Std. Error</th> <th>z-Statistic</th> <th>Prob.</th> </tr> </thead> <tbody> <tr> <td>C</td> <td>0.000432</td> <td>0.000154</td> <td>2.805102</td> <td>0.0050</td> </tr> </tbody> </table>	Variable	Coefficient	Std. Error	z-Statistic	Prob.	C	0.000432	0.000154	2.805102	0.0050	<table border="1"> <thead> <tr> <th>Variable</th> <th>Coefficient</th> <th>Std. Error</th> <th>z-Statistic</th> <th>Prob.</th> </tr> </thead> <tbody> <tr> <td>C</td> <td>0.000574</td> <td>0.000156</td> <td>3.676526</td> <td>0.0002</td> </tr> </tbody> </table>	Variable	Coefficient	Std. Error	z-Statistic	Prob.	C	0.000574	0.000156	3.676526	0.0002																												
Variable	Coefficient	Std. Error	z-Statistic	Prob.																																													
C	0.000432	0.000154	2.805102	0.0050																																													
Variable	Coefficient	Std. Error	z-Statistic	Prob.																																													
C	0.000574	0.000156	3.676526	0.0002																																													
<p>Variance Equation</p> <table border="1"> <thead> <tr> <th></th> <th>Coefficient</th> <th>Std. Error</th> <th>z-Statistic</th> <th>Prob.</th> </tr> </thead> <tbody> <tr> <td>C</td> <td>1.71E-06</td> <td>2.83E-07</td> <td>6.041865</td> <td>0.0000</td> </tr> <tr> <td>RESID(-1)^2</td> <td>0.080943</td> <td>0.005247</td> <td>15.42800</td> <td>0.0000</td> </tr> <tr> <td>GARCH(-1)</td> <td>0.910431</td> <td>0.005774</td> <td>157.6831</td> <td>0.0000</td> </tr> </tbody> </table>		Coefficient	Std. Error	z-Statistic	Prob.	C	1.71E-06	2.83E-07	6.041865	0.0000	RESID(-1)^2	0.080943	0.005247	15.42800	0.0000	GARCH(-1)	0.910431	0.005774	157.6831	0.0000	<p>Variance Equation</p> <table border="1"> <thead> <tr> <th></th> <th>Coefficient</th> <th>Std. Error</th> <th>z-Statistic</th> <th>Prob.</th> </tr> </thead> <tbody> <tr> <td>C</td> <td>1.77E-06</td> <td>2.79E-07</td> <td>6.334571</td> <td>0.0000</td> </tr> <tr> <td>RESID(-1)^2</td> <td>0.080424</td> <td>0.005741</td> <td>14.00884</td> <td>0.0000</td> </tr> <tr> <td>GARCH(-1)</td> <td>0.910094</td> <td>0.006240</td> <td>145.8486</td> <td>0.0000</td> </tr> </tbody> </table>		Coefficient	Std. Error	z-Statistic	Prob.	C	1.77E-06	2.79E-07	6.334571	0.0000	RESID(-1)^2	0.080424	0.005741	14.00884	0.0000	GARCH(-1)	0.910094	0.006240	145.8486	0.0000								
	Coefficient	Std. Error	z-Statistic	Prob.																																													
C	1.71E-06	2.83E-07	6.041865	0.0000																																													
RESID(-1)^2	0.080943	0.005247	15.42800	0.0000																																													
GARCH(-1)	0.910431	0.005774	157.6831	0.0000																																													
	Coefficient	Std. Error	z-Statistic	Prob.																																													
C	1.77E-06	2.79E-07	6.334571	0.0000																																													
RESID(-1)^2	0.080424	0.005741	14.00884	0.0000																																													
GARCH(-1)	0.910094	0.006240	145.8486	0.0000																																													
<table border="1"> <tbody> <tr> <td>R-squared</td> <td>-0.000910</td> <td>Mean dependent var</td> <td>4.40E-05</td> </tr> <tr> <td>Adjusted R-squared</td> <td>-0.000910</td> <td>S.D. dependent var</td> <td>0.012863</td> </tr> <tr> <td>S.E. of regression</td> <td>0.012868</td> <td>Akaike info criterion</td> <td>-6.150446</td> </tr> <tr> <td>Sum squared resid</td> <td>0.591010</td> <td>Schwarz criterion</td> <td>-6.143521</td> </tr> <tr> <td>Log likelihood</td> <td>10982.55</td> <td>Hannan-Quinn criter.</td> <td>-6.147977</td> </tr> <tr> <td>Durbin-Watson stat</td> <td>1.994517</td> <td></td> <td></td> </tr> </tbody> </table>	R-squared	-0.000910	Mean dependent var	4.40E-05	Adjusted R-squared	-0.000910	S.D. dependent var	0.012863	S.E. of regression	0.012868	Akaike info criterion	-6.150446	Sum squared resid	0.591010	Schwarz criterion	-6.143521	Log likelihood	10982.55	Hannan-Quinn criter.	-6.147977	Durbin-Watson stat	1.994517			<table border="1"> <tbody> <tr> <td>R-squared</td> <td>-0.001273</td> <td>Mean dependent var</td> <td>0.000105</td> </tr> <tr> <td>Adjusted R-squared</td> <td>-0.001273</td> <td>S.D. dependent var</td> <td>0.013126</td> </tr> <tr> <td>S.E. of regression</td> <td>0.013135</td> <td>Akaike info criterion</td> <td>-6.136192</td> </tr> <tr> <td>Sum squared resid</td> <td>0.615707</td> <td>Schwarz criterion</td> <td>-6.129268</td> </tr> <tr> <td>Log likelihood</td> <td>10957.10</td> <td>Hannan-Quinn criter.</td> <td>-6.133724</td> </tr> <tr> <td>Durbin-Watson stat</td> <td>1.981379</td> <td></td> <td></td> </tr> </tbody> </table>	R-squared	-0.001273	Mean dependent var	0.000105	Adjusted R-squared	-0.001273	S.D. dependent var	0.013126	S.E. of regression	0.013135	Akaike info criterion	-6.136192	Sum squared resid	0.615707	Schwarz criterion	-6.129268	Log likelihood	10957.10	Hannan-Quinn criter.	-6.133724	Durbin-Watson stat	1.981379		
R-squared	-0.000910	Mean dependent var	4.40E-05																																														
Adjusted R-squared	-0.000910	S.D. dependent var	0.012863																																														
S.E. of regression	0.012868	Akaike info criterion	-6.150446																																														
Sum squared resid	0.591010	Schwarz criterion	-6.143521																																														
Log likelihood	10982.55	Hannan-Quinn criter.	-6.147977																																														
Durbin-Watson stat	1.994517																																																
R-squared	-0.001273	Mean dependent var	0.000105																																														
Adjusted R-squared	-0.001273	S.D. dependent var	0.013126																																														
S.E. of regression	0.013135	Akaike info criterion	-6.136192																																														
Sum squared resid	0.615707	Schwarz criterion	-6.129268																																														
Log likelihood	10957.10	Hannan-Quinn criter.	-6.133724																																														
Durbin-Watson stat	1.981379																																																
<p>Dependent Variable: IBEX_35  Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)  Date: 07/12/17 Time: 22:08  Sample: 4/01/2000 13/04/2017  Included observations: 3570  Convergence achieved after 25 iterations  Coefficient covariance computed using outer product of gradients  Presample variance: backcast (parameter = 0.7)  GARCH = C(2) + C(3)*RESID(-1)^2 + C(4)*GARCH(-1)</p>	<p>Dependent Variable: FTSE_MIB  Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)  Date: 07/12/17 Time: 22:04  Sample: 4/01/2000 13/04/2017  Included observations: 3570  Convergence achieved after 30 iterations  Coefficient covariance computed using outer product of gradients  Presample variance: backcast (parameter = 0.7)  GARCH = C(2) + C(3)*RESID(-1)^2 + C(4)*GARCH(-1)</p>																																																
<table border="1"> <thead> <tr> <th>Variable</th> <th>Coefficient</th> <th>Std. Error</th> <th>z-Statistic</th> <th>Prob.</th> </tr> </thead> <tbody> <tr> <td>C</td> <td>0.000459</td> <td>0.000148</td> <td>3.108384</td> <td>0.0019</td> </tr> </tbody> </table>	Variable	Coefficient	Std. Error	z-Statistic	Prob.	C	0.000459	0.000148	3.108384	0.0019	<table border="1"> <thead> <tr> <th>Variable</th> <th>Coefficient</th> <th>Std. Error</th> <th>z-Statistic</th> <th>Prob.</th> </tr> </thead> <tbody> <tr> <td>C</td> <td>0.000373</td> <td>0.000158</td> <td>2.363856</td> <td>0.0181</td> </tr> </tbody> </table>	Variable	Coefficient	Std. Error	z-Statistic	Prob.	C	0.000373	0.000158	2.363856	0.0181																												
Variable	Coefficient	Std. Error	z-Statistic	Prob.																																													
C	0.000459	0.000148	3.108384	0.0019																																													
Variable	Coefficient	Std. Error	z-Statistic	Prob.																																													
C	0.000373	0.000158	2.363856	0.0181																																													
<p>Variance Equation</p> <table border="1"> <thead> <tr> <th></th> <th>Coefficient</th> <th>Std. Error</th> <th>z-Statistic</th> <th>Prob.</th> </tr> </thead> <tbody> <tr> <td>C</td> <td>2.05E-06</td> <td>2.99E-07</td> <td>6.855292</td> <td>0.0000</td> </tr> <tr> <td>RESID(-1)^2</td> <td>0.096887</td> <td>0.005566</td> <td>17.40691</td> <td>0.0000</td> </tr> <tr> <td>GARCH(-1)</td> <td>0.896817</td> <td>0.006439</td> <td>139.2702</td> <td>0.0000</td> </tr> </tbody> </table>		Coefficient	Std. Error	z-Statistic	Prob.	C	2.05E-06	2.99E-07	6.855292	0.0000	RESID(-1)^2	0.096887	0.005566	17.40691	0.0000	GARCH(-1)	0.896817	0.006439	139.2702	0.0000	<p>Variance Equation</p> <table border="1"> <thead> <tr> <th></th> <th>Coefficient</th> <th>Std. Error</th> <th>z-Statistic</th> <th>Prob.</th> </tr> </thead> <tbody> <tr> <td>C</td> <td>1.21E-06</td> <td>1.96E-07</td> <td>6.196009</td> <td>0.0000</td> </tr> <tr> <td>RESID(-1)^2</td> <td>0.086491</td> <td>0.004826</td> <td>17.92271</td> <td>0.0000</td> </tr> <tr> <td>GARCH(-1)</td> <td>0.911102</td> <td>0.005169</td> <td>176.2750</td> <td>0.0000</td> </tr> </tbody> </table>		Coefficient	Std. Error	z-Statistic	Prob.	C	1.21E-06	1.96E-07	6.196009	0.0000	RESID(-1)^2	0.086491	0.004826	17.92271	0.0000	GARCH(-1)	0.911102	0.005169	176.2750	0.0000								
	Coefficient	Std. Error	z-Statistic	Prob.																																													
C	2.05E-06	2.99E-07	6.855292	0.0000																																													
RESID(-1)^2	0.096887	0.005566	17.40691	0.0000																																													
GARCH(-1)	0.896817	0.006439	139.2702	0.0000																																													
	Coefficient	Std. Error	z-Statistic	Prob.																																													
C	1.21E-06	1.96E-07	6.196009	0.0000																																													
RESID(-1)^2	0.086491	0.004826	17.92271	0.0000																																													
GARCH(-1)	0.911102	0.005169	176.2750	0.0000																																													
<table border="1"> <tbody> <tr> <td>R-squared</td> <td>-0.000679</td> <td>Mean dependent var</td> <td>0.000113</td> </tr> <tr> <td>Adjusted R-squared</td> <td>-0.000679</td> <td>S.D. dependent var</td> <td>0.013277</td> </tr> <tr> <td>S.E. of regression</td> <td>0.013282</td> <td>Akaike info criterion</td> <td>-6.068409</td> </tr> <tr> <td>Sum squared resid</td> <td>0.629594</td> <td>Schwarz criterion</td> <td>-6.061485</td> </tr> <tr> <td>Log likelihood</td> <td>10836.11</td> <td>Hannan-Quinn criter.</td> <td>-6.065940</td> </tr> <tr> <td>Durbin-Watson stat</td> <td>1.952481</td> <td></td> <td></td> </tr> </tbody> </table>	R-squared	-0.000679	Mean dependent var	0.000113	Adjusted R-squared	-0.000679	S.D. dependent var	0.013277	S.E. of regression	0.013282	Akaike info criterion	-6.068409	Sum squared resid	0.629594	Schwarz criterion	-6.061485	Log likelihood	10836.11	Hannan-Quinn criter.	-6.065940	Durbin-Watson stat	1.952481			<table border="1"> <tbody> <tr> <td>R-squared</td> <td>-0.000599</td> <td>Mean dependent var</td> <td>4.27E-05</td> </tr> <tr> <td>Adjusted R-squared</td> <td>-0.000599</td> <td>S.D. dependent var</td> <td>0.013506</td> </tr> <tr> <td>S.E. of regression</td> <td>0.013510</td> <td>Akaike info criterion</td> <td>-6.079797</td> </tr> <tr> <td>Sum squared resid</td> <td>0.651379</td> <td>Schwarz criterion</td> <td>-6.072872</td> </tr> <tr> <td>Log likelihood</td> <td>10856.44</td> <td>Hannan-Quinn criter.</td> <td>-6.077328</td> </tr> <tr> <td>Durbin-Watson stat</td> <td>2.026931</td> <td></td> <td></td> </tr> </tbody> </table>	R-squared	-0.000599	Mean dependent var	4.27E-05	Adjusted R-squared	-0.000599	S.D. dependent var	0.013506	S.E. of regression	0.013510	Akaike info criterion	-6.079797	Sum squared resid	0.651379	Schwarz criterion	-6.072872	Log likelihood	10856.44	Hannan-Quinn criter.	-6.077328	Durbin-Watson stat	2.026931		
R-squared	-0.000679	Mean dependent var	0.000113																																														
Adjusted R-squared	-0.000679	S.D. dependent var	0.013277																																														
S.E. of regression	0.013282	Akaike info criterion	-6.068409																																														
Sum squared resid	0.629594	Schwarz criterion	-6.061485																																														
Log likelihood	10836.11	Hannan-Quinn criter.	-6.065940																																														
Durbin-Watson stat	1.952481																																																
R-squared	-0.000599	Mean dependent var	4.27E-05																																														
Adjusted R-squared	-0.000599	S.D. dependent var	0.013506																																														
S.E. of regression	0.013510	Akaike info criterion	-6.079797																																														
Sum squared resid	0.651379	Schwarz criterion	-6.072872																																														
Log likelihood	10856.44	Hannan-Quinn criter.	-6.077328																																														
Durbin-Watson stat	2.026931																																																

Dependent Variable: PSI\_20  
Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)  
Date: 07/12/17 Time: 22:13  
Sample: 4/01/2000 13/04/2017  
Included observations: 3570  
Convergence achieved after 27 iterations  
Coefficient covariance computed using outer product of gradients  
Presample variance: backcast (parameter = 0.7)  
GARCH = C(2) + C(3)\*RESID(-1)^2 + C(4)\*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C	0.000366	0.000133	2.755592	0.0059

Variance Equation

	Coefficient	Std. Error	z-Statistic	Prob.
C	9.44E-07	1.33E-07	7.092966	0.0000
RESID(-1)^2	0.094651	0.005958	15.88503	0.0000
GARCH(-1)	0.902381	0.005785	155.9860	0.0000

R-squared	-0.002484	Mean dependent var	-0.000159
Adjusted R-squared	-0.002484	S.D. dependent var	0.010536
S.E. of regression	0.010550	Akaike info criterion	-6.529347
Sum squared resid	0.397206	Schwarz criterion	-6.522422
Log likelihood	11658.88	Hannan-Quinn criter.	-6.526878
Durbin-Watson stat	1.868763		

Dependent Variable: SHANGHAI  
Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)  
Date: 07/12/17 Time: 22:20  
Sample: 4/01/2000 13/04/2017  
Included observations: 3570  
Convergence achieved after 33 iterations  
Coefficient covariance computed using outer product of gradients  
Presample variance: backcast (parameter = 0.7)  
GARCH = C(2) + C(3)\*RESID(-1)^2 + C(4)\*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C	6.96E-05	0.000142	0.490878	0.6235

Variance Equation

	Coefficient	Std. Error	z-Statistic	Prob.
C	9.29E-07	1.89E-07	4.911507	0.0000
RESID(-1)^2	0.069361	0.003893	17.81615	0.0000
GARCH(-1)	0.929496	0.003623	256.5619	0.0000

R-squared	-0.000036	Mean dependent var	-1.25E-05
Adjusted R-squared	-0.000036	S.D. dependent var	0.013600
S.E. of regression	0.013600	Akaike info criterion	-6.044173
Sum squared resid	0.660120	Schwarz criterion	-6.037248
Log likelihood	10792.85	Hannan-Quinn criter.	-6.041704
Durbin-Watson stat	2.078523		

Dependent Variable: S\_P\_ASX\_200  
Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)  
Date: 07/12/17 Time: 22:18  
Sample: 4/01/2000 13/04/2017  
Included observations: 3570  
Convergence achieved after 28 iterations  
Coefficient covariance computed using outer product of gradients  
Presample variance: backcast (parameter = 0.7)  
GARCH = C(2) + C(3)\*RESID(-1)^2 + C(4)\*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C	0.000393	0.000110	3.581451	0.0003

Variance Equation

	Coefficient	Std. Error	z-Statistic	Prob.
C	6.12E-07	1.06E-07	5.788812	0.0000
RESID(-1)^2	0.061440	0.004281	14.35073	0.0000
GARCH(-1)	0.930295	0.004872	190.9629	0.0000

R-squared	-0.001145	Mean dependent var	9.80E-05
Adjusted R-squared	-0.001145	S.D. dependent var	0.008708
S.E. of regression	0.008713	Akaike info criterion	-6.944841
Sum squared resid	0.270957	Schwarz criterion	-6.937916
Log likelihood	12400.54	Hannan-Quinn criter.	-6.942372
Durbin-Watson stat	2.022991		

Dependent Variable: NIKKEI  
Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)  
Date: 07/12/17 Time: 22:12  
Sample: 4/01/2000 13/04/2017  
Included observations: 3570  
Convergence achieved after 24 iterations  
Coefficient covariance computed using outer product of gradients  
Presample variance: backcast (parameter = 0.7)  
GARCH = C(2) + C(3)\*RESID(-1)^2 + C(4)\*GARCH(-1)


Variable	Coefficient	Std. Error	z-Statistic	Prob.
C	0.000264	0.000176	1.501217	0.1333

Variance Equation


	Coefficient	Std. Error	z-Statistic	Prob.
C	5.09E-06	6.00E-07	8.481570	0.0000
RESID(-1)^2	0.103746	0.005413	19.16493	0.0000
GARCH(-1)	0.870314	0.007815	111.3576	0.0000

R-squared	-0.000691	Mean dependent var	-8.28E-05
Adjusted R-squared	-0.000691	S.D. dependent var	0.013201
S.E. of regression	0.013206	Akaike info criterion	-6.022699
Sum squared resid	0.622389	Schwarz criterion	-6.015774
Log likelihood	10754.52	Hannan-Quinn criter.	-6.020230
Durbin-Watson stat	2.096092		

**Anexo E** – Conjunto de Análises Gráficas e Estatísticas dos Mercados referente às correlações da variância observada dos mercados com os obtidos no modelo GARCH(1,1), referente ao período de abril de 2017 até outubro de 2017.




### Graphical Summary for Ibovespa




Mean:	0.482
Std.Dev.:	0.340
Variance:	0.115
Std.Err.Mean	0.0318
Skewness:	-0.855
Valid N:	114
Minimum:	-0.478
Lower Quartile	0.275
Median:	0.570
Upper Quartile	0.754
Maximum:	0.957
95% Confidence for Std Dev	
Lower	0.301
Upper	0.391
95% Confidence for Mean	
Lower	0.419
Upper	0.545
95% Prediction for Observation	
Lower	-0.195
Upper	1.158

### Graphical Summary for Euro Stoxx 50




Mean:	0.377
Std.Dev.:	0.391
Variance:	0.153
Std.Err.Mean	0.0366
Skewness:	-0.691
Valid N:	114
Minimum:	-0.790
Lower Quartile	0.106
Median:	0.449
Upper Quartile	0.676
Maximum:	0.955
95% Confidence for Std Dev	
Lower	0.346
Upper	0.449
95% Confidence for Mean	
Lower	0.304
Upper	0.449
95% Prediction for Observation	
Lower	-0.400
Upper	1.154

### Graphical Summary for FTSE100




Mean:	0.394
Std.Dev.:	0.282
Variance:	0.0795
Std.Err.Mean	0.0264
Skewness:	-0.758
Valid N:	114
Minimum:	-0.742
Lower Quartile	0.236
Median:	0.428
Upper Quartile	0.597
Maximum:	0.916
95% Confidence for Std Dev	
Lower	0.250
Upper	0.324
95% Confidence for Mean	
Lower	0.342
Upper	0.447
95% Prediction for Observation	
Lower	-0.167
Upper	0.955

### Graphical Summary for CAC 40




Mean:	0.431
Std.Dev.:	0.376
Variance:	0.141
Std.Err.Mean	0.0352
Skewness:	-0.697
Valid N:	114
Minimum:	-0.597
Lower Quartile	0.112
Median:	0.528
Upper Quartile	0.739
Maximum:	0.952
95% Confidence for Std Dev	
Lower	0.332
Upper	0.432
95% Confidence for Mean	
Lower	0.361
Upper	0.501
95% Prediction for Observation	
Lower	-0.316
Upper	1.178

### Graphical Summary for DAX




Mean:	0.400
Std.Dev.:	0.343
Variance:	0.118
Std.Err.Mean	0.0322
Skewness:	-0.764
Valid N:	114
Minimum:	-0.586
Lower Quartile	0.178
Median:	0.489
Upper Quartile	0.641
Maximum:	0.943
95% Confidence for Std Dev	
Lower	0.304
Upper	0.395
95% Confidence for Mean	
Lower	0.337
Upper	0.464
95% Prediction for Observation	
Lower	-0.283
Upper	1.083

### Graphical Summary for IBEX 35



Mean:	0.443
Std.Dev.:	0.331
Variance:	0.110
Std.Err.Mean	0.0310
Skewness:	-0.928
Valid N:	114
Minimum:	-0.555
Lower Quartile	0.256
Median:	0.514
Upper Quartile	0.699
Maximum:	0.919
95% Confidence for Std Dev	
Lower	0.293
Upper	0.381
95% Confidence for Mean	
Lower	0.382
Upper	0.504
95% Prediction for Observation	
Lower	-0.216
Upper	1.102

### Graphical Summary for FTSE MIB



Mean: 0.382  
 Std.Dev.: 0.393  
 Variance: 0.155  
 Std.Err.Mean: 0.0368  
 Skewness: -0.804


Valid N: 114  
 Minimum: -0.589  
 Lower Quartile: 0.154  
 Median: 0.452  
 Upper Quartile: 0.687  
 Maximum: 0.914

95% Confidence for Std Dev  
 Lower: 0.348  
 Upper: 0.452

95% Confidence for Mean  
 Lower: 0.309  
 Upper: 0.455

95% Prediction for Observation  
 Lower: -0.401  
 Upper: 1.164

### Graphical Summary for PSI 20



Mean: 0.449  
 Std.Dev.: 0.319  
 Variance: 0.102  
 Std.Err.Mean: 0.0299  
 Skewness: -0.663


Valid N: 114  
 Minimum: -0.453  
 Lower Quartile: 0.241  
 Median: 0.491  
 Upper Quartile: 0.719  
 Maximum: 0.961

95% Confidence for Std Dev  
 Lower: 0.283  
 Upper: 0.367

95% Confidence for Mean  
 Lower: 0.390  
 Upper: 0.508


95% Prediction for Observation  
 Lower: -0.187  
 Upper: 1.084

### Graphical Summary for Shanghai




Mean:	0.308
Std.Dev.:	0.539
Variance:	0.291
Std.Err.Mean	0.0505
Skewness:	-0.642
Valid N:	114
Minimum:	-0.960
Lower Quartile	-0.138
Median:	0.463
Upper Quartile	0.762
Maximum:	0.999
95% Confidence for Std Dev	
Lower	0.477
Upper	0.620
95% Confidence for Mean	
Lower	0.208
Upper	0.408
95% Prediction for Observation	
Lower	-0.765
Upper	1.382

### Graphical Summary for S&P/ASX 200



Mean:	0.489
Std.Dev.:	0.380
Variance:	0.145
Std.Err.Mean	0.0356
Skewness:	-0.995
Valid N:	114
Minimum:	-0.873
Lower Quartile	0.222
Median:	0.561
Upper Quartile	0.776
Maximum:	1.000
95% Confidence for Std Dev	
Lower	0.337
Upper	0.437
95% Confidence for Mean	
Lower	0.418
Upper	0.560
95% Prediction for Observation	
Lower	-0.268
Upper	1.246

### Graphical Summary for Nikkei



Mean: 0.489  
 Std.Dev.: 0.380  
 Variance: 0.145  
 Std.Err.Mean: 0.0356  
 Skewness: -1.009  
 Valid N: 114  
 Minimum: -0.953  
 Lower Quartile: 0.290  
 Median: 0.554  
 Upper Quartile: 0.774  
 Maximum: 0.997

95% Confidence for Std Dev  
 Lower: 0.337  
 Upper: 0.437

95% Confidence for Mean  
 Lower: 0.419  
 Upper: 0.560

95% Prediction for Observation  
 Lower: -0.268  
 Upper: 1.246