

# **A relação entre os índices de produção industrial e de confiança dos consumidores nos Estados Unidos da América**

Dissertação de Mestrado

Inês Miranda Silvestre

Mestrado em

**Ciências Económicas e Empresariais**



# **A relação entre os índices de produção industrial e de confiança dos consumidores nos Estados Unidos da América**

Dissertação de Mestrado

Inês Miranda Silvestre

## **Orientadores**

Prof. Doutor Tiago Mota Dutra  
Prof. Doutor Mário Correia Fernandes  
Prof. Doutor João Carlos Aguiar Teixeira

Dissertação submetida como requisito parcial para obtenção do grau de Mestre em Ciências Económicas e Empresariais, com especialização em Finanças e Contabilidade.



## RESUMO

A presente dissertação analisa a relação empírica entre os índices económicos, nomeadamente o índice de produção industrial e de confiança do consumidor, e a sua volatilidade, utilizando dados dos Estados Unidos desde 1919 até 2023 e 1960 até 2023, respetivamente. Para abordar este assunto, são estimados vários modelos da família GARCH que incluem o *feedback* da volatilidade e efeitos assimétricos. Pelos resultados obtidos, verifica-se que: (i) o índice de produção industrial apresenta efeitos assimétricos, com um desempenho de adequação significativo em relação ao modelo GARCH *standard*; (ii) a inclusão de outros tipos de distribuição que o erro pode assumir melhora o nível de adequação dos modelos; (iii) os modelos testados para o índice de confiança do consumidor apresentam resultados semelhantes em relação ao nível de ajustamento aos dados; (iv) excluindo os meses durante a pandemia COVID-19 e o conflito entre Rússia e Ucrânia obteve-se os mesmos resultados para ambos os índices económicos.

Palavras-chave: crescimento económico, efeito assimétrico, *feedback* da volatilidade, heterocedasticidade condicional, modelos GARCH.

## ABSTRACT

This dissertation examines the empirical relationship between economic indexes, namely the industrial production and the consumer confidence, and their volatility by using United States data over the periods 1919 to 2023 and 1960 to 2023, respectively. To address this topic, several GARCH family models including volatility feedback and the asymmetric effects are estimated. We find that: (i) the industrial production index exhibits asymmetric effects, with significant fitting performance over the standard GARCH model; (ii) the inclusion of distributed innovations in the error term improves the fitting performance of the models; (iii) the models tested for the consumer confidence index exhibit similar performance to fit with the data; (iv) by excluding the months during and after the COVID-19 and the Russia and Ukraine conflict, it leads to the same results for both economic indexes.

Keywords: economic growth, asymmetric effects, volatility feedback, conditional heteroskedasticity, GARCH models.

## ÍNDICE

RESUMO .....	i
ABSTRACT .....	ii
LISTA DE TABELAS .....	iv
LISTA DE FIGURAS .....	v
LISTA DE ABREVIATURAS.....	vi
CAPÍTULO I - INTRODUÇÃO .....	1
CAPÍTULO II - REVISÃO DA LITERATURA .....	3
CAPÍTULO III - METODOLOGIA .....	5
3.1 Dados e estatísticas descritivas .....	5
3.2 Estacionariedade de uma série temporal.....	10
3.3 Modelos da família GARCH .....	12
CAPÍTULO IV - RESULTADOS.....	16
4.1 Resultados obtidos para o INDPRO e ICC nos EUA assumindo uma distribuição normal .....	16
4.2 Resultados obtidos para o INDPRO e ICC nos EUA assumindo uma distribuição <i>t-student</i> .....	19
4.3 Resultados obtidos para o INDPRO e ICC nos EUA assumindo uma distribuição GED .....	22
CAPÍTULO V – TESTES ADICIONAIS.....	28
CAPÍTULO VI – CONCLUSÃO.....	34
REFERÊNCIAS .....	37

## LISTA DE TABELAS

Tabela 1. Estatísticas descritivas para os índices de produção industrial e de confiança do consumidor .....	9
Tabela 2. Teste <i>Augmented Dickey Fuller</i> .....	11
Tabela 3. Teste <i>Phillips-Perron</i> .....	12
Tabela 4. Estimação dos modelos GARCH para os índices de produção industrial e confiança do consumidor nos EUA, assumindo que os erros seguem uma distribuição normal.....	18
Tabela 5. Estimação dos modelos GARCH para os índices de produção industrial e confiança do consumidor nos EUA, assumindo que os erros seguem uma distribuição <i>t-student</i> .....	20
Tabela 6. Estimação dos modelos GARCH <i>standard</i> e GARCH <i>with leverage</i> para o índice de produção industrial desde 1919 até 2023 .....	21
Tabela 7. Estimação dos modelos GARCH para os índices de produção industrial e confiança do consumidor nos EUA, assumindo que os erros seguem uma distribuição do erro generalizado .....	24
Tabela 8. Estimação dos modelos GARCH <i>standard</i> e GARCH <i>with leverage</i> para o índice de produção industrial desde 1919 até 2023 .....	25
Tabela 9. Estimação dos modelos da família GARCH para o índice de produção industrial e de confiança do consumidor .....	27
Tabela 10. Estimação dos modelos GARCH para os índices de produção industrial e confiança do consumidor nos EUA, assumindo que os erros seguem uma distribuição normal.....	31
Tabela 11. Estimação dos modelos GARCH para os índices de produção industrial e confiança do consumidor nos EUA, assumindo que os erros seguem uma distribuição <i>t-student</i> .....	32
Tabela 12. Estimação dos modelos GARCH para os índices de produção industrial e confiança do consumidor nos EUA, assumindo que os erros seguem uma distribuição generalizada do erro.....	33

## LISTA DE FIGURAS

Figura 1. Representação gráfica dos valores mensais do índice de produção industrial nos Estados Unidos de 1919 até 2023.....	6
Figura 2. Representação gráfica dos valores mensais do índice de confiança do consumidor nos Estados Unidos de 1960 até 2023 .....	6
Figura 3. Representação gráfica dos retornos mensais (base logarítmica) do índice de produção industrial nos Estados Unidos de 1919 até 2023 .....	8
Figura 4. Representação gráfica dos retornos mensais (base logarítmica) do índice de confiança dos consumidores nos Estados Unidos de 1960 até 2023 .....	8

## LISTA DE ABREVIATURAS

ADF. *Augmented Dickey-Fuller*  
AIC. *Akaike Information Criterion*  
ARCH. *Autoregressive Conditional Heteroskedasticity*  
EUA. Estados Unidos da América  
G7. Grupo dos Sete  
G. Modelo GARCH *standard*  
GARCH. *Generalized Autoregressive Conditional Heteroskedasticity*  
GED. *Generalized error distribution*  
G-L. Modelo GARCH *with leverage*  
G-M. Modelo GARCH-*in-mean*  
HQC. *Hannan-Quinn Criterion*  
ICC. Índice de confiança do consumidor  
INDPRO. Índice de produção industrial  
LL. *Log Likelihood*  
PIB. Produto Interno Bruto  
PP. *Phillips-Perron*  
SIC. *Bayesiana Schwarz Information Criterion*

## CAPÍTULO I - INTRODUÇÃO

Até aos anos 80, o crescimento económico no longo prazo e as flutuações do ciclo económico eram abordados de forma separada pelos teóricos macroeconómicos. De ora em diante, várias descobertas foram avançadas e enfatizam a importância de considerar as flutuações do ciclo económico e respetivas implicações no crescimento económico. Aliás, estas descobertas apontam para a existência de uma relação entre estes dois indicadores económicos. Alguns autores defendem uma relação positiva entre a variabilidade do ciclo económico e o crescimento da economia no longo prazo, outros defendem uma relação negativa. Em resultado destas descobertas equívocas, a relação em questão permanece pouco clara.

Neste sentido, a presente dissertação procura preencher esta lacuna na literatura existente e, simultaneamente, explora vários caminhos que visem complementá-la. Assim, este estudo passa por analisar a relação empírica entre dois índices económicos norte americanos, mais concretamente o índice de produção industrial e o índice de confiança dos consumidores, e a sua volatilidade, desde 1919 até 2023 e 1960 até 2023, respetivamente. Para atingir este objetivo, são estimados alguns modelos da família *Generalized Autoregressive Conditional Heteroskedasticity* (GARCH) no intuito de incluir o *feedback* da volatilidade e efeitos assimétricos na análise. Por outras palavras, averigua-se se um aumento na variabilidade dos índices contribui para um aumento da variabilidade em períodos seguintes e se um crescimento negativo nos índices provoca um efeito assimétrico na variabilidade dos índices em períodos seguintes. As séries temporais referentes a ambos os índices abrangem um horizonte temporal bastante extenso, o que possibilita determinar a longo prazo o referido efeito assimétrico, assim como o comportamento da volatilidade.

Relativamente ao tratamento dos dados, conta-se com o auxílio do *software* estatístico *Eviews 12 Student Version* para perceber qual o modelo da família GARCH com o melhor nível de adequabilidade face à amostra de dados sob investigação.

Para tornar ainda mais interessante este estudo, reserva-se um capítulo para uma análise mais detalhada, com a intenção de perceber se existem conclusões diferentes antes e após a pandemia COVID-19 e a Guerra na Ucrânia. Recorre-se a estes acontecimentos por serem recentes e por serem períodos com elevada volatilidade. O período temporal considerado para esta análise adicional abrange janeiro de 1919 até fevereiro de 2020 e janeiro de 1960 até fevereiro de 2020 para os índices de produção industrial e de confiança

do consumidor, respetivamente. Este período é igualmente extenso, mas exclui os dados observados a partir de fevereiro de 2020 que correspondem à pandemia e ao conflito entre a Rússia e Ucrânia. Em termos de metodologia, aplicou-se a mesma abordagem econométrica, isto é, os modelos da família GARCH também estimados na amostra completa.

A dissertação está estruturada em seis capítulos. No capítulo I introduz-se o tema e no capítulo II há um levantamento teórico e de literatura empírica. Segue-se o capítulo III com a apresentação dos dados e metodologia aplicada. O capítulo IV divulga os resultados e dá lugar à discussão dos mesmos. O capítulo V cobre uma análise interessante, na medida em que inclui os mais recentes acontecimentos a nível global com variações significativas na economia. Por fim, o capítulo VI reúne as principais conclusões desta investigação.

## CAPÍTULO II – REVISÃO DA LITERATURA

Até à década de 1980, a variável crescimento económico no longo prazo e as flutuações do ciclo económico eram consideradas nas teorias macroeconómicas de forma isolada. Vários autores, como, por exemplo, Kydland e Prescott (1982), incluíram na sua pesquisa o crescimento económico e as flutuações do ciclo económico, mas não era viável a existência de uma relação entre estas variáveis em estudo (Fountas & Karanos, 2006).

Apesar do forte contributo destas duas variáveis nas teorias do ciclo económico na década de 80, a investigação empírica sobre uma possível ligação entre o crescimento económico e a variabilidade do ciclo económico mantém-se pouco clara (Lee, 2010).

Mirman (1971), com a sua investigação acerca da relação entre a volatilidade e o nível ótimo de consumo, argumenta que as flutuações do ciclo económico levam a uma maior incerteza na economia e, por isso, aumenta a poupança por parte dos consumidores por uma questão de prevenção, o que conduz a maiores taxas de crescimento. Contrariamente, Bernanke (1983) avançou com uma pesquisa sobre a relação entre a volatilidade e o momento ótimo de investimento no ciclo económico. Este autor defendeu uma relação inversa entre o crescimento económico e a volatilidade do ciclo económico, uma vez que a variabilidade do ciclo económico leva a uma maior incerteza na economia e tem um impacto negativo no investimento e, conseqüentemente, no crescimento da economia a longo prazo.

O estudo de Zarnowitz e Moore (1986) revelou que o crescimento económico tende a diminuir durante períodos de maior volatilidade. Daí em diante, teorias avançadas destacam a importância de refletir sobre a variável crescimento económico e a variabilidade do ciclo económico conjuntamente, ao invés de separadamente.

Uma década depois, Carporale e McKiernan (1996) utilizaram na sua investigação, com dados do Reino Unido e dos Estados Unidos, um modelo GARCH-*in-mean* para testar o comportamento da volatilidade. Os resultados apontaram para uma relação positiva entre o crescimento económico e a volatilidade em ambos os países.

Stock e Watson (2002) sublinham a importância de analisar o comportamento da volatilidade do crescimento do PIB nos Estados Unidos nos últimos anos e as suas implicações no crescimento da economia americana.

Mais recentemente, e à semelhança de Carporale e McKiernan (1996), Fountas e Karanos (2006) utilizaram modelos da família GARCH para modelar os dados da amostra e obtiveram resultados interessantes. A amostra incluía os três maiores países em termos

económicos: Alemanha, Japão e Estados Unidos da América (EUA). Os autores deste estudo encontraram também uma relação positiva e significativa entre o crescimento económico e a incerteza para a Alemanha e o Japão. Para os dados dos EUA obteve-se resultados diferentes, na medida em que esta relação positiva não era significativa.

Kormendi e Mequire (1985), com base numa abordagem comparativa de dados entre vários países, constataram que os países com maior desvio padrão do crescimento do nível de produção têm tendência a registar taxas de crescimento económico mais elevadas. Com uma lógica de dados mais ampla, isto é, com mais de cem países em análise, Grier e Tullock (1989) avançam com as mesmas conclusões.

Sob outra perspetiva, Ramey e Ramey (1984) identificaram uma relação negativa entre amostras diferentes de países. A pesquisa destes autores mostrou que maior volatilidade conduz a um menor crescimento económico. Martin e Rogers (2000), com o pressuposto de que o crescimento é gerado pelo “*learning by doing*”, descobriram que os países com maior volatilidade no crescimento apresentam um crescimento económico mais baixo.

Lee (2010) investigou a relação empírica entre o crescimento da produção e a volatilidade do ciclo económico, tendo por base uma tabela dinâmica com dados dos países membros do Grupos dos Sete (G7), desde 1965 até 2007, e com o modelo GARCH. O autor concluiu que um maior crescimento económico não conduz a maior variabilidade económica.

Dadas estas descobertas nas últimas décadas, a literatura existente oferece três cenários possíveis para a relação entre o crescimento económico e as flutuações do ciclo económico. Primeiramente, surgiu a possibilidade de estas duas variáveis serem independentes. Posteriormente, com o avanço das teorias de diversos autores, este primeiro cenário foi ponderado e considerou-se as possibilidades de uma associação positiva ou negativa entre a variabilidade do ciclo económico e o crescimento económico.

Há, portanto, uma ambiguidade na literatura teórica e empírica em torno da relação entre a variabilidade do ciclo económico e o crescimento económico no longo prazo, fruto de todas estas descobertas sobre este tema nas décadas passadas. Esta ambiguidade justifica uma investigação mais aprofundada sobre esta questão. É no sentido de preencher esta atual lacuna na literatura existente e de expandir em vários caminhos os aspetos empíricos das descobertas até então feitas que surge a presente dissertação.

## CAPÍTULO III - METODOLOGIA

Este capítulo apresenta os dados sob investigação e menciona a metodologia aplicada, mais concretamente os métodos estatísticos e econométricos utilizados, sendo eles: a estacionariedade das séries, averiguada através dos testes *Augmented Dickey-Fuller* (ADF) e *Phillips-Perron* (PP), e os modelos da família GARCH.

### 3.1 Dados e estatísticas descritivas

O subcapítulo apresenta os dois indicadores económicos cuja relação é investigada no presente estudo, sendo eles: o índice de produção industrial e o índice de confiança do consumidor nos Estados Unidos da América.

De acordo com a plataforma *Federal Reserve System*, o índice de produção industrial (INDPRO) mede a produção real de todos os estabelecimentos dos Estados Unidos da América. O setor industrial é responsável pela maior parte da variação da produção ao longo do percurso do ciclo económico desta nação. O detalhe industrial proporcionado por este índice com periodicidade mensal ajuda a iluminar a evolução da economia dos Estados Unidos.

O índice de confiança dos consumidores (ICC), de acordo com a plataforma *Investing*, mede o nível de confiança dos consumidores na atividade económica. Valores mais elevados do ICC traduzem maior otimismo do consumidor. O ICC segue as flutuações de uma economia, o que significa que a uma maior volatilidade do ciclo económico poderá estar associada uma maior incerteza por parte do consumidor relativamente à situação económica futura de um país. O mesmo será dizer que o nível de confiança do consumidor é menor. Bernanke (1983), Pindyck (1991) e Ramey e Ramey (1991) avançaram com esta linha de pensamento.

Nas Figuras 1 e 2 estão representados os gráficos com os valores mensais dos índices de produção industrial e de confiança do consumidor nos Estados Unidos ao longo do tempo.

Figura 1. Representação gráfica dos valores mensais do índice de produção industrial nos Estados Unidos de 1919 até 2023

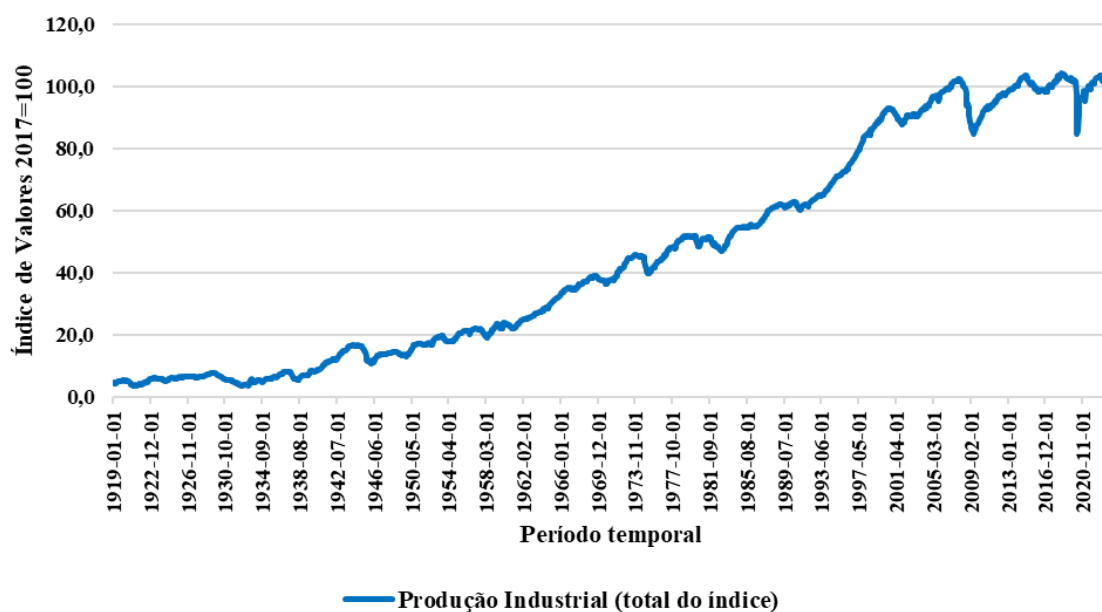



Figura 2. Representação gráfica dos valores mensais do índice de confiança do consumidor nos Estados Unidos de 1960 até 2023



Verifica-se que o índice de produção industrial norte-americano apresenta, de um modo geral, uma tendência crescente para o período em análise. Entre 2007 e 2008, constata-se uma quebra marcada pela crise financeira internacional. Mais recentemente, nota-se que alguns acontecimentos adversos, como a pandemia COVID-19 e a guerra na

Ucrânia, tiveram uma forte influência no comportamento deste índice. Estes períodos de recessão mais recentes, assim como outros que se verificaram ao longo do período em análise, introduziram mais volatilidade na economia, o que é visível graficamente pelas oscilações no índice de confiança do consumidor. É perceptível que inovações negativas no INDPRO, conduzem a maior variabilidade no crescimento económico e, por isso, o ICC apresenta valores inferiores.

Numa lógica de crescimento da economia americana, os índices supramencionados funcionam como variáveis *proxies* e servem de indicadores da situação económica do país.

É de sublinhar que foram escolhidos estes dois índices dos Estados Unidos por se tratar da maior economia do mundo, com forte relevância no que respeita ao risco sistémico, com um produto interno bruto (PIB) altamente significativo, e por demonstrar um desempenho notável face aos desafios económicos que surgiram ao longo do tempo devido a vários fatores.

As séries temporais referentes aos índices de produção industrial e de confiança dos consumidores nos EUA foram recolhidas da plataforma *Federal Reserve Bank of Saint Louis*. A amostra inclui observações mensais que abrangem o período de janeiro de 1919 a agosto de 2023 e de janeiro de 1960 até agosto de 2023, respetivamente.

O interesse ao utilizar estes dois índices americanos é obter um horizonte temporal extenso com uma lógica mensal, incluindo, assim, períodos de variação significativa nas variáveis cuja relação é investigada.

Depois de se obter os valores mensais do INDPRO e do ICC, calculam-se os logaritmos dos mesmos através das seguintes fórmulas, respetivamente:

$$\text{Logaritmo do INDPRO} = \ln\left(\frac{\text{INDPRO}_t}{\text{INDPRO}_{t-1}}\right) \quad (1)$$

$$\text{Logaritmo do ICC} = \ln\left(\frac{\text{ICC}_t}{\text{ICC}_{t-1}}\right) \quad (2)$$

onde  $\text{INDPRO}_t$  corresponde ao valor mensal do índice de produção industrial no momento  $t$  e  $\text{INDPRO}_{t-1}$  refere-se ao valor mensal do índice de confiança do consumidor no momento  $t - 1$ . Segue-se a mesma lógica de pensamento para o índice de confiança do consumidor.

As Figuras 3 e 4 mostram os gráficos dos retornos de ambos os índices no período sob investigação numa base logarítmica.

Figura 3. Representação gráfica dos retornos mensais (base logarítmica) do índice de produção industrial nos Estados Unidos de 1919 até 2023


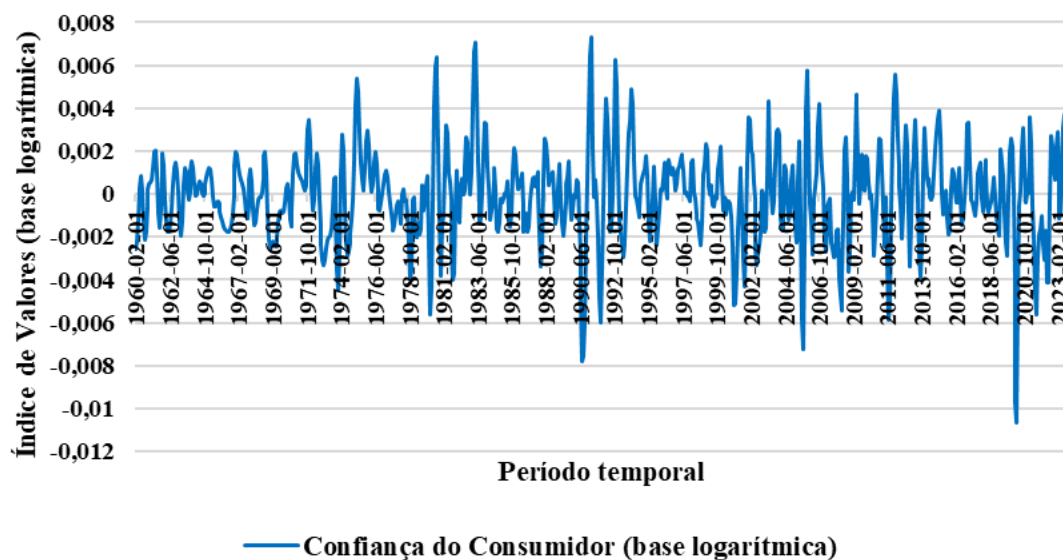


Figura 4. Representação gráfica dos retornos mensais (base logarítmica) do índice de confiança dos consumidores nos Estados Unidos de 1960 até 2023



É de referir que a base logarítmica fornece de uma forma mais precisa a variabilidade do retorno de ambos os índices. A representação gráfica corrobora esta informação. Tal como nas Figuras 1 e 2, é possível observar-se nas Figuras 3 e 4, com mais detalhe, que uma diminuição no crescimento do índice de produção industrial contribui para introduzir mais volatilidade, o que se traduz numa maior incerteza por parte dos consumidores.

A Tabela 1 expõe as estatísticas descritivas para ambos os índices norte americanos.

Tabela 1. Estatísticas descritivas para os índices de produção industrial e de confiança do consumidor

Painel A: Estatísticas descritivas		
	Produção industrial	Confiança do consumidor
Média	45,4871	100,0099
Mediana	38,7193	100,4926
Máximo	104,1181	102,8487
Mínimo	3,6835	96,1932
Desvio padrão	34,5998	1,4610
Skewness	0,40	-0,53
Kurtosis	1,69	2,46
Jarque Bera	123,30	44,53
valor-p	0,0000	0,0000
Observações	1256	764
Painel B: Estatísticas descritivas (retornos em base logarítmica)		
	Produção industrial	Confiança do consumidor
Média	0,0024	0,0000
Mediana	0,0028	0,0000
Máximo	0,1532	0,0073
Mínimo	-0,1437	-0,0107
Desvio padrão	0,0193	0,0021
Skewness	-0,0504	-0,2443
Kurtosis	15,79	5,25
Jarque Bera	8549,53	168,98
valor-p	0,0000	0,0000
Observações	1255	763

Ao longo do período em análise, o índice de produção industrial nos Estados Unidos atingiu um volume máximo de produção industrial no valor de 104,1181 e um volume mínimo no valor de 3,6835. O índice de confiança do consumidor registou um valor médio de 100,0099. Entende-se que há um valor elevado para o nível de confiança do consumidor perante um grande volume de produção industrial. Contrariamente, observa-se um valor inferior para a confiança do consumidor em resultado de um menor volume de produção industrial.

O tratamento dos dados será feito com o apoio do *software Eviews 12 Student Version*, de forma a identificar o modelo com o melhor desempenho de ajuste para modelar a

volatilidade dos índices de produção industrial e de confiança dos consumidores nos Estados Unidos.

### 3.2 Estacionariedade de uma série temporal

Uma série temporal é qualquer coisa que seja observada sequencialmente ao longo do tempo (Hyndman e Athanasopoulos, 2018).

Segundo Liu *et al.* (2022), uma série temporal não estacionária é caracterizada pela mudança contínua das suas propriedades físicas ao longo do tempo. A presença de não estacionariedade numa série temporal pode conduzir à perda de dados e informações e, conseqüentemente, pode distorcer os resultados e levar a conclusões incorretas.

A estacionariedade é conferida através dos testes *Augmented Dickey Fuller* e *Phillips-Perron*, recomendados por Dickey e Fuller (1979) e Phillips e Perron (1988), respetivamente. Estes testes são populares e frequentemente empregados na literatura, cujos objetivos são confirmar a inexistência de raízes unitárias, isto é, a estacionariedade da variável em estudo (Silva *et al.*, 2017).

O teste *Augmented Dickey Fuller* tem como hipótese nula a presença de raiz unitária, isto é, a não estacionariedade da série e, como hipótese alternativa, o contrário (Horváth *et al.*, 2013). Rejeitar a hipótese nula significa aceitar a hipótese alternativa e, portanto, a série dos dados é estacionária e não há presença de raízes unitárias. O teste PP acompanha a mesma lógica do teste ADF. O pretendido neste trabalho é rejeitar a hipótese nula em ambos os testes, o que significa que as séries dos dados em estudo são estacionárias.

As Tabelas 2 e 3 evidenciam os resultados obtidos para ambos os testes estatísticos realizados sob a hipótese nula de que as séries temporais são não estacionárias. Rejeita-se a hipótese nula, quando a estatística  $t$  do teste é inferior à estatística  $t$  dos valores críticos ou, em alternativa, quando o *valor-p* é inferior aos níveis críticos.

Assim, a série temporal de produção industrial não rejeita a hipótese nula em ambos os testes e, por isso, existem raízes unitárias e as séries são não estacionárias. Já na série temporal de confiança do consumidor, a hipótese nula não é rejeitada de acordo com o teste ADF. Porém, com base no teste PP, rejeita-se a hipótese nula nos valores críticos de 5% e 10% e não se rejeita a hipótese nula para o nível crítico de 1%. Relativamente às séries temporais em uma base logarítmica, os testes ADF e PP, ilustrados no Painel B das Tabelas 2 e 3, mostram que há evidência estatística de que ambas as séries são estacionárias.

Tabela 2. Teste *Augmented Dickey Fuller*

Augmented Dickey Fuller (ADF)						
Painel A: Séries temporais						
	Valores críticos testados	Estatística $t$	ADF	valor- $p$	ADF	Lags
			0,605035	0,9899		2
Produção Industrial	1%	-3,435356				
	5%	-2,863638				
	10%	-2,567937				
	Valores críticos testados	Estatística $t$	ADF	valor- $p$	ADF	Lags
			-2,822927	0,5550		4
Confiança do Consumidor	1%	-3,438739				
	5%	-2,865132				
	10%	-2,568738				
Painel B: Séries temporais (base logarítmica)						
	Valores críticos testados	Estatística $t$	ADF	valor- $p$	ADF	Lags
			-20,89912	0,0000		0
Produção Industrial	1%	-3,435352				
	5%	-2,863637				
	10%	-2,567936				
	Valores críticos testados	Estatística $t$	ADF	valor- $p$	ADF	Lags
			-12,8294	0,0000		3
Confiança do Consumidor	1%	-3,438739				
	5%	-2,865132				
	10%	-2,568738				

Tabela 3. Teste *Phillips-Perron*

Phillips-Perron (PP)					
Painel A: Séries temporais					
	Valores críticos testados	Estatística $t$	PP	valor- $p$ PP	Bandwidht
			0,460383	0,9853	16
Produção Industrial	1%	-3,435348			
	5%	-2,863635			
	10%	-2,567935			
	Valores críticos testados	Estatística $t$	PP	valor- $p$ PP	Bandwidht
			-3,048063	0,0311	9
Confiança do Consumidor	1%	-3,438694			
	5%	-2,865113			
	10%	-2,568728			
Painel B: Séries temporais (base logarítmica)					
	Valores críticos testados	Estatística $t$	PP	valor- $p$ PP	Bandwidht
			-20,50514	0,0000	7
Produção Industrial	1%	-3,435352			
	5%	-2,863637			
	10%	-2,567936			
	Valores críticos testados	Estatística $t$	PP	valor- $p$ PP	Bandwidht
			-6,470236	0,0000	149
Confiança do Consumidor	1%	-3,438705			
	5%	-2,865118			
	10%	-2,56873			

### 3.3 Modelos da família GARCH

A abordagem econométrica selecionada para explorar a existência de volatilidade e efeitos de alavancagem no crescimento dos índices económicos estudados é conhecida por modelos da família GARCH. No presente trabalho serão abordadas três extensões do modelo GARCH: o modelo GARCH *standard* (G), o modelo GARCH-*in-mean* (G-M) e o modelo GARCH *with leverage* (G-L).

O modelo *Autoregressive Conditional Heteroskedasticity* (ARCH), sugerido por Engle (1982), distingue a variância incondicional da condicional, na medida em que esta última varia ao longo do tempo em função dos erros passados. Por outras palavras, este modelo dá uma visão geral da dinâmica da volatilidade no passado. Bollerslev (1986) propôs uma generalização do modelo ARCH para o modelo GARCH, de forma a suprir algumas limitações do primeiro modelo. Bollersvlev (1986) e Lee (2006) defendem que o modelo GARCH permite uma descrição mais parcimoniosa em várias situações e proporciona um melhor desempenho de ajuste para dados que apresentam fenómenos de

heterocedasticidade e volatilidade. Lee (2006) acrescenta que o modelo GARCH é, portanto, mais eficiente na estimação de modelos.

Contudo, o modelo GARCH não é capaz de capturar os efeitos de alavancagem que são frequentemente observados ao longo de séries financeiras. Este aspeto do modelo GARCH foi sustento de vários estudos que propuseram diversas extensões do modelo GARCH. As extensões do modelo GARCH facilitaram a deteção e compreensão da dinâmica e características de uma determinada série temporal (Glosten *et al.*, 1993).

Em particular, no presente trabalho será abordado o modelo GARCH *standard* e duas das suas extensões: o modelo GARCH-*in-mean* e o modelo GARCH *with leverage*.

O primeiro modelo da família GARCH utilizado para modelar a volatilidade da produção industrial e da confiança do consumidor foi o modelo GARCH *standard*. Este modelo, GARCH (1,1), é descrito através das equações 3 e 4:

$$y_t = \mu + \varepsilon_t, \varepsilon_t \sim N(0, \sigma_t^2) \quad (3)$$

$$\sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \beta_1 \sigma_{t-1}^2 \quad (4)$$

onde o termo de erro segue uma distribuição normal com uma média igual a zero e uma variância dependente do tempo. Para garantir que a variância do processo,  $\sigma_t^2$ , é estritamente positiva e estacionária, é necessário assumir que  $\alpha_0 > 0$ ,  $\alpha_1 \geq 0$ ,  $\beta_1 \geq 0$  e  $\alpha_1 + \beta_1 < 1$ . A equação (3) descreve os dados observados como uma função de outras variáveis mais o termo de erro. A equação (4) mostra a evolução da variância condicional do erro da equação (3) em função das variações condicionais passadas e dos erros desfasados.

A associação entre risco e retorno tem sido um tópico importante na avaliação de ativos. Num determinado período, os investidores exigem um retorno esperado superior em um ativo com maior risco (Glosten *et al.*, 1993). Engle *et al.* (1987) propuseram uma extensão do modelo GARCH *standard*, de modo que a volatilidade condicional pudesse gerar um prémio de risco correspondente aos retornos esperados de um determinado ativo. Esta extensão é denominada de modelo GARCH-*in-mean*, ou modelo GARCH-M. Por outras palavras, este modelo procura testar se os retornos esperados de um ativo específico dependem da sua volatilidade. Em particular, neste estudo, o modelo GARCH-M será relevante para testar se os retornos do INDPRO e ICC em uma base logarítmica dependem da sua volatilidade. O modelo GARCH-M é formulado de acordo com as seguintes equações:

$$y_t = \mu + \lambda \sigma_t^2 + \varepsilon_t, \varepsilon_t \sim N(0, \sigma_t^2) \quad (5)$$

$$\sigma_t^2 = \alpha_0 + \alpha_1 (y_{t-1} - \mu - \lambda \sigma_{t-1}^2)^2 + \beta_1 \sigma_{t-1}^2 \quad (6)$$

Note-se que na equação (5), se  $\lambda = 0$ , obtém-se a equação (3), o que significa que o modelo GARCH-M coincide com o modelo GARCH *standard* quando  $\lambda = 0$ . Da mesma forma, note-se que na equação (5) do modelo GARCH-M, mais concretamente em  $\lambda \sigma_t^2$ , é possível incluir o desvio padrão,  $\lambda \sigma_t$ , ou o logaritmo da variância,  $\log(\lambda \sigma_t^2)$ .

Por último, considerou-se no presente estudo o modelo GARCH *with leverage*, GARCH-L, sugerido por Glosten *et al.* (1993), com o intuito de capturar um potencial efeito de alavancagem assimétrica na variância condicional. Assim, é possível que a variância condicional apresente um comportamento diferente como resposta aos retornos passados positivos e negativos.

Na verdade, este modelo corresponde à adição do modelo GARCH *standard* com uma variável *dummy* que é multiplicada pelo quadrado do termo de erro e pelo parâmetro indicativo do efeito de alavancagem. O modelo é expresso pela equação (3) e pela seguinte equação:

$$\sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \delta_1 \varepsilon_{t-1}^2 I_{t-1} + \beta_1 \sigma_{t-1}^2 \quad (7)$$

onde  $\delta_1$  é o parâmetro indicativo do efeito de alavancagem assimétrica e  $I$  é o indicador de função da seguinte forma:

$$I_{t-1} = \begin{cases} 1, & \text{se } \varepsilon_{t-1} < 0 \\ 0, & \text{se } \varepsilon_{t-1} \geq 0 \end{cases}$$

Significa isto que  $\varepsilon_{t-1}$  provoca diferentes efeitos sobre a variância condicional,  $\sigma_t^2$ . Assim, é possível reescrever a equação (7) da seguinte forma:

$$\begin{cases} \sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \delta_1 \varepsilon_{t-1}^2 + \beta_1 \sigma_{t-1}^2 \\ \sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \beta_1 \sigma_{t-1}^2 \end{cases} \quad (7)$$

Quando  $\varepsilon_{t-1} < 0$ , o efeito total de alavanca assimétrica é dado por  $(\alpha_1 + \delta_1) \varepsilon_{t-1}^2$  e quando  $\varepsilon_{t-1} \geq 0$ , o efeito total de alavanca assimétrica é dado por  $\alpha_1 \varepsilon_{t-1}^2$ . Por outras palavras, acontecimentos negativos têm um impacto de  $(\alpha_1 + \delta_1)$  na variância condicional e acontecimentos positivos têm um impacto de  $\alpha_1$  na variância condicional. O impacto que os acontecimentos negativos têm na variância condicional (volatilidade) é superior ao dos acontecimentos positivos.

Com o presente estudo, espera-se verificar um valor positivo para  $\delta_1$  no caso de acontecimentos negativos. O mesmo será dizer que acontecimentos negativos conduzem a um efeito assimétrico na variabilidade dos índices em análise nos períodos seguintes.

Repare-se que quando  $\delta_1 = 0$ , o modelo GARCH-L é reduzido à equação (4) e, conseqüentemente, ao modelo GARCH *standard*.

Os modelos da família GARCH supramencionados assumem que os erros seguem uma distribuição normal, isto é,  $\varepsilon_t \sim N(0, \sigma_t^2)$ . Contudo, o erro pode assumir outros tipos de distribuições, como por exemplo, a distribuição *t-student* e distribuição do erro generalizado. Nelson (1991) defendeu o uso de outro tipo de distribuições, com vista a capturar caudas pesadas, normalmente observadas em séries temporais financeiras. Para complementar a presente investigação, averiguar-se-á a adequabilidade dos modelos supra, considerando estes três tipos de distribuição que os erros podem assumir.

A seleção do modelo da família GARCH mais adequado para a amostra de dados terá por base três critérios de decisão: o critério da informação de *Akaike* (AIC), o critério da informação *Bayesiana Schwarz* (SIC) e o critério de *Hannan-Quinn* (HQC).

## CAPÍTULO IV - RESULTADOS

É neste capítulo que são analisados os resultados obtidos desta investigação, fruto do tratamento estatístico dos dados, com o auxílio do *software* estatístico *EViews 12 Student Version*. A análise dos resultados será dividida em subcapítulos, de forma a simplificar a interpretação dos resultados e estabelecer comparações dos mesmos entre os vários tipos de distribuição que os erros podem seguir.

### **4.1 Resultados obtidos para o INDPRO e ICC nos EUA assumindo uma distribuição normal**

O subcapítulo analisa os resultados obtidos para os índices de produção industrial e de confiança do consumidor, ambos nos Estados Unidos, no período compreendido entre os meses de janeiro de 1919 até dezembro de 2023 e de janeiro de 1960 até dezembro de 2023, respetivamente.

A Tabela 4 apresenta os parâmetros resultantes da estimação dos modelos da família GARCH para os dados de ambos os índices. Os parâmetros são estimados pelo método da Máxima Verossimilhança e a sigla LL denota o correspondente logaritmo da verossimilhança para cada modelo estimado. Quanto maior for o valor do logaritmo da verossimilhança, melhor é o ajustamento do modelo ao conjunto de dados. AIC, SIC e HQC refletem os critérios de informação utilizados, sendo eles: o critério da informação de Akaike, (AIC), o critério da informação *Bayesiana Schwarz*, (SIC) e o critério de *Hannan-Quinn* (HQC). Menores valores de AIC, SIC e HQC apontam para modelos com maior qualidade de ajustamento. Note-se que os valores destacados a negrito na Tabela 4 indicam o modelo da família GARCH com o melhor desempenho de ajuste de acordo com os critérios de informação utilizados. Assumiu-se um nível de significância de 5% na estimação dos modelos em estudo.

Em primeiro lugar, é possível constatar que o modelo GARCH *with leverage* apresenta o melhor desempenho de ajuste para a volatilidade da produção industrial americana. Há evidências estatísticas para apoiar o desempenho adequado do modelo G-L em comparação com os restantes modelos estimados. Para além deste modelo apresentar o maior valor de *log likelihood* (LL), apresenta também os menores valores em todos os critérios de informação. Na verdade, a representação gráfica deste índice, assim como a dos seus retornos numa base logarítmica, mostram o efeito assimétrico. É

notável que uma diminuição no crescimento do índice de produção industrial nos EUA, isto é, períodos negativos, contribuem para introduzir mais volatilidade. A última crise financeira internacional em 2008 e a mais recente inovação negativa, a pandemia COVID-19, são dois exemplos interessantes que salientam o efeito assimétrico no INDPRO. É de realçar a significância estatística do parâmetro indicativo do efeito de alavancagem assimétrico,  $\delta_1$ , no índice de produção industrial, uma vez que só reforça a relevância deste modelo em relação aos outros modelos em estudo. O parâmetro  $\delta_1$  assume um valor de 0,451503. O facto deste parâmetro ter um sinal positivo fortifica o efeito de alavancagem assimétrico presente na série temporal. Para uma melhor compreensão deste efeito, substituiu-se os valores dos parâmetros na equação do modelo G-L apresentada no capítulo anterior.

$$\begin{cases} \sigma_t^2 = 6,08E - 06 + 0,257271\varepsilon_{t-1}^2 + 0,451503\varepsilon_{t-1}^2 + 0,596657\sigma_{t-1}^2 \\ \sigma_t^2 = 6,08E - 06 + 0,257271\varepsilon_{t-1}^2 + 0,596657\sigma_{t-1}^2 \end{cases} \quad (7)$$

$$\begin{cases} \sigma_t^2 = 6,08E - 06 + 0,708774 \varepsilon_{t-1}^2 + 0,596657\sigma_{t-1}^2 \\ \sigma_t^2 = 6,08E - 06 + 0,257271\varepsilon_{t-1}^2 + 0,596657\sigma_{t-1}^2 \end{cases} \quad (7)$$

O impacto que os acontecimentos negativos têm na variância condicional (volatilidade) é claramente superior ao dos acontecimentos positivos. É neste impacto que se denota o efeito de alavancagem assimétrico.

Contudo, obteve-se resultados diferentes para o índice de confiança do consumidor nos Estados Unidos. Neste índice, o modelo GARCH-*in-mean*, baseado no logaritmo da variância, revela um desempenho ligeiramente melhor face aos demais modelos. Ao analisar os valores da Tabela 4, de facto este modelo apresenta o maior valor de LL e os menores valores para dois critérios de informação, o AIC e o HQC. Graficamente, o efeito assimétrico não é evidente na Figura 4, o que explica o facto de o modelo G-L não se revelar como o modelo com melhor adequabilidade para os dados desta série temporal.

Sob outra perspetiva, o modelo GARCH *standard* revelou o pior desempenho de ajuste em relação aos restantes modelos para o índice de produção industrial. Isto é válido de acordo com o valor de LL e critérios de informação AIC e HQC. É possível retirar uma conclusão semelhante para o critério SIC, uma vez que os resultados deste critério são muito semelhantes para os modelos GARCH *standard* e GARCH-*in-mean*, baseado na variância. Curiosamente, o modelo GARCH *with leverage* demonstrou o pior desempenho de ajuste para o índice de confiança do consumidor.

Tabela 4. Estimação dos modelos GARCH para os índices de produção industrial e confiança do consumidor nos EUA, assumindo que os erros seguem uma distribuição normal

Painel A: índice de produção industrial nos EUA (base logarítmica)					
	G (1,1)	G-M (desv. p)	G-M (var)	G-M log(var)	G-L
$\mu$	0,002889	0,00149	0,002718	0,016257	0,0024
$\lambda_1$	-	0,178986	-	-	-
$\lambda_2$	-	-	1,965485	-	-
$\lambda_3$	-	-	-	0,001348	-
$\alpha_0$	6,90E-06	6,84E-06	6,87E-06	6,60E-06	6,08E-06
$\alpha_1$	0,507746	0,505085	0,502796	0,500527	0,257271
$\beta_1$	0,567956	0,567878	0,570167	0,016257	0,596657
$\delta_1$	-	-	-	-	0,451503
LL	3833,885	3840,69	3835,894	3844,105	3860,543
AIC	-6,103402	-6,112653	-6,105011	-6,118095	<b>-6,144291</b>
SIC	-6,087036	-6,092195	-6,084553	-6,097637	<b>-6,123833</b>
HQC	-6,097250	-6,104963	-6,097322	-6,110406	<b>-6,136602</b>
Painel B: índice de confiança do consumidor nos EUA (base logarítmica)					
	G (1,1)	G-M (desv. p)	G-M (var)	G-M log(var)	G-L
$\mu$	3,64E-06	-0,000503	-0,000107	0,005294	5,48E-06
$\lambda_1$	-	0,237424	-	-	-
$\lambda_2$	-	-	19,94084	-	-
$\lambda_3$	-	-	-	-	-
$\alpha_0$	9,36E-07	9,42E-07	9,36E-07	9,40E-07	9,45E-07
$\alpha_1$	0,739788	0,755504	0,745505	0,766277	0,698881
$\beta_1$	0,129207	0,113793	0,123498	0,107274	0,127402
$\delta_1$	-	-	-	-	0,075208
LL	3770,359	3771,853	3771,003	3772,687	3770,494
AIC	-9,872502	-9,873795	-9,871568	<b>-9,875983</b>	-9,870233
BIC	<b>-9,848191</b>	-9,843406	-9,841180	-9,845594	-9,839845
HQC	-9,863142	-9,862095	-9,859868	<b>-9,864283</b>	-9,858533

## 4.2 Resultados obtidos para o INDPRO e ICC nos EUA assumindo uma distribuição *t-student*

No presente subcapítulo assume-se que em ambas as séries temporais os erros seguem uma distribuição *t-student*, ao invés da distribuição normal assumida até então. Os resultados obtidos neste subcapítulo serão alvo de comparação com os resultados alcançados no subcapítulo anterior, em que se assume que os erros seguem uma distribuição normal. Com esta comparação procura-se averiguar o contributo que o tipo de distribuição que os erros podem seguir tem na performance dos modelos da família GARCH.

No que respeita aos resultados obtidos para o tipo de distribuição em análise neste subcapítulo, apresentados na Tabela 5, verifica-se que o modelo GARCH *with leverage* é o modelo que melhor se adequa aos dados da produção industrial americana. A forte adequabilidade deste modelo aos dados é justificada com base no maior valor de LL e menores valores de todos os critérios de informação usados que o mesmo revela. É notável o efeito de alavancagem assimétrico nesta série temporal através da estimativa do parâmetro indicativo deste efeito,  $\delta_1$ , que assume um valor positivo de 0,396694. Novamente, e a fim de perceber melhor o efeito de alavancagem assimétrico com outro tipo de distribuição dos erros, substituiu-se as estimativas dos parâmetros na equação deste modelo.

$$\begin{cases} \sigma_t^2 = 6,92E - 06 + 0,326477\varepsilon_{t-1}^2 + 0,396694\varepsilon_{t-1}^2 + 0,557113\sigma_{t-1}^2 \\ \sigma_t^2 = 6,92E - 06 + 0,3264771\varepsilon_{t-1}^2 + 0,557113\sigma_{t-1}^2 \end{cases} \quad (7)$$

$$\begin{cases} \sigma_t^2 = 6,92E - 06 + 0,723171 \varepsilon_{t-1}^2 + 0,557113\sigma_{t-1}^2 \\ \sigma_t^2 = 6,92E - 06 + 0,3264771\varepsilon_{t-1}^2 + 0,557113\sigma_{t-1}^2 \end{cases} \quad (7)$$

Há, portanto, um efeito de alavancagem assimétrico, na medida em que os acontecimentos negativos têm um impacto na volatilidade da produção industrial superior ao dos acontecimentos positivos. O impacto dos acontecimentos negativos é estimado em 0,723171 e o impacto dos acontecimentos positivos é estimado em 0,3264771.

Os resultados obtidos para a confiança do consumidor estão também expressos na Tabela 5. Dos quatro modelos da família GARCH estimados, o modelo GARCH-M, baseado no logaritmo da variância, revelou os melhores resultados no que respeita ao LL e a dois critérios de informação, o AIC e o HQC.

Tabela 5. Estimaco dos modelos GARCH para os  ndices de produo industrial e confiana do consumidor nos EUA, assumindo que os erros seguem uma distribuo *t-student*

Painel A: �ndice de produo industrial nos EUA (base logar�tmica)					
	G (1,1)	G-M (desv. p)	G-M (var)	G-M log(var)	G-L
$\mu$	0,002689	0,001416	0,002529	0,002529	0,002513
$\lambda_1$	-	0,162694	-	-	-
$\lambda_2$	-	-	1,83287	-	-
$\lambda_3$	-	-	-	1,83287	-
$\alpha_0$	7,75E-06	7,25E-06	7,60E-06	7,60E-06	6,92E-06
$\alpha_1$	0,534389	0,525519	0,526389	0,526389	0,326477
$\beta_1$	0,541969	0,550455	0,54702	0,54702	0,557113
$\delta_1$	-	-	-	-	0,396694
LL	3882,115	3888,209	3883,985	3883,985	3894,476
AIC	-6,178670	-6,186787	-6,180055	-6,180055	<b>-6,196775</b>
SIC	-6,158212	-6,162237	-6,155506	-6,155506	<b>-6,172226</b>
HQC	-6,170980	-6,177560	-6,170828	-6,170828	<b>-6,187548</b>
Painel B: �ndice de confiana do consumidor nos EUA (base logar�tmica)					
	G (1,1)	G-M (desv. p)	G-M (var)	G-M log(var)	G-L
$\mu$	1,58E-05	-0,000451	-0,000084	0,00503	1,94E-05
$\lambda_1$	-	0,216845	-	-	-
$\lambda_2$	-	-	17,57483	-	-
$\lambda_3$	-	-	-	0,000402	-
$\alpha_0$	9,62E-07	9,45E-07	9,48E-07	9,39E-07	9,72E-07
$\alpha_1$	0,761613	0,7664	0,762683	0,775132	0,713381
$\beta_1$	0,110123	0,107895	0,111681	0,103854	0,107377
$\delta_1$	-	-	-	-	0,091512
LL	3770,95	3772,13	3771,455	3772,898	3771,13
AIC	-9,871429	-9,871901	-9,870132	<b>-9,873913</b>	-9,869279
BIC	<b>-9,841041</b>	-9,835435	-9,833666	-9,837447	-9,832813
HQC	-9,859729	-9,857861	-9,856092	<b>-9,859873</b>	-9,855239

Em contrapartida, os modelos GARCH *standard* e GARCH-L apresentam os menores n veis de desempenho de ajuste para a volatilidade da produo industrial e para a confiana dos consumidores nos Estados Unidos, respetivamente.

Com base na Tabela 5, verifica-se que, ao considerar outro tipo de distribuo que os erros podem seguir para modelar a volatilidade da produo industrial nos EUA, o

desempenho de todos os modelos da família GARCH melhora em relação aos modelos correspondentes com uma distribuição normal.

A Tabela 6 mostra, resumidamente, os resultados obtidos para o modelo GARCH *standard* e G-L, de forma a facilitar a comparação e interpretação dos resultados entre as distribuições dos erros. Nesta Tabela, considerou-se apenas estes dois modelos, visto que demonstraram o pior e o melhor desempenho em termos de resultados. Já o modelo G-M revelou resultados intermédios e, por isso, foi excluído desta Tabela síntese.

Tabela 6. Estimação dos modelos GARCH *standard* e GARCH *with leverage* para o índice de produção industrial desde 1919 até 2023

Painel A: índice de produção industrial nos EUA (base logarítmica)				
	G(1,1)		G-L	
	Distribuição dos erros			
	Normal	<i>t-student</i>	Normal	<i>t-student</i>
LL	3833,885	3882,115	3860,543	3894,476
AIC	-6,103402	-6,178670	-6,144291	-6,196775
SIC	-6,087036	-6,158212	-6,123833	-6,172226
HQC	-6,097250	-6,170980	-6,136602	-6,187548
$\delta_1$	-	-	0,451503	0,396694
$\alpha_1$	0,507746	0,534389	0,257271	0,326477
$\delta_1 + \alpha_1$	-	-	0,708774	0,723171

Ao comparar os resultados após estimar os modelos da família GARCH supondo que os erros seguem uma distribuição *t-student*, constata-se que o modelo GARCH *with leverage* apresentou melhor desempenho de ajustamento e de adequabilidade para a variabilidade da produção industrial nos EUA relativamente ao modelo GARCH *standard* com uma distribuição normal. Para uma distribuição dos erros *t-student*, a produção industrial revelou, no modelo G-L, um valor de LL superior e os menores valores para todos os critérios de informação em comparação com os resultados que obteve com a distribuição normal dos erros. Além disto, até o modelo GARCH *standard* com uma distribuição *t-student* apresenta melhores resultados e, por isso, melhor desempenho de ajuste aos dados, do que o modelo GARCH *standard* com uma distribuição normal.

No que respeita ao efeito de alavancagem assimétrico, as evidências estatísticas apontam para um efeito superior assumindo que os erros seguem uma distribuição *t-student*. O impacto que os acontecimentos negativos têm na volatilidade da produção

industrial, com uma distribuição normal, assume um valor de 0,708774, enquanto, com uma distribuição *t-student*, assume um valor de 0,723171. Já os acontecimentos positivos têm um impacto na volatilidade desta série estimado em 0,257271 e 0,326477, assumindo que os erros seguem as distribuições normal e *t-student*, respetivamente.

No que concerne à confiança do consumidor nos EUA, a introdução de um novo tipo de distribuição dos erros traduziu-se em resultados bastantes semelhantes aos da distribuição normal e, por isto, não trouxe um impacto significativo aos resultados. Comparando estes resultados com os do índice de produção industrial, a confiança do consumidor indica uma variabilidade menos extrema nos dados. Na verdade, é visível nas Figuras 3 e 4 que existem mais inovações extremas no índice de produção industrial do que no índice de confiança do consumidor. Aliás, o desvio padrão de ambos os índices, de acordo com a Tabela 1, validam esta ideia.

Face aos resultados obtidos, quer para os parâmetros dos modelos da família GARCH quer para os critérios de informação, verifica-se, de um modo geral, uma melhoria em todos os modelos GARCH estimados com uma distribuição *t-student*, em comparação com os modelos correspondentes com uma distribuição normal. Portanto, os resultados estatísticos obtidos apoiam fortemente a inclusão de outros tipos de distribuição dos erros para modelar a volatilidade das séries temporais em estudo.

### **4.3 Resultados obtidos para o INDPRO e ICC nos EUA assumindo uma distribuição GED**

Este subcapítulo admite que os erros seguem uma distribuição generalizada do erro em ambos os índices económicos. De forma a compreender o comportamento dos modelos estimados com este tipo de distribuição, efetuar-se-á uma comparação com os resultados atingidos anteriormente, quer para uma distribuição normal quer para uma distribuição *t-student*.

Os retornos de ambos os índices em uma base logarítmica, destacados no Painel B da Tabela 1, exibem níveis elevados de assimetria e *kurtosis* e, por isso, há que considerar a possibilidade de existir caudas pesadas em ambas as séries temporais. Nelson (1991) defende o uso de outro tipo de distribuições que os erros podem seguir, nomeadamente a distribuição generalizada do erro (GED), com o intuito de capturar caudas pesadas nas séries temporais.

A Tabela 7 relata os resultados obtidos para os índices de produção industrial e de confiança do consumidor assumindo que os erros seguem uma distribuição generalizada do erro.

Para o índice de produção industrial, o modelo GARCH *with leverage* apresentou o maior valor de LL e os valores mais baixos para todos os critérios de decisão e, por isso, mais uma vez, revelou ser o modelo com melhor nível de ajustamento para os dados da produção industrial, assumindo uma distribuição generalizada do erro. O efeito de alavancagem assimétrico encontra-se também presente na série temporal referente à produção industrial em que se admite uma distribuição GED. O parâmetro indicativo deste efeito admite um valor de 0,577413, de acordo com a Tabela 7. Substituiu-se os parâmetros da equação referente ao modelo G-L com as estimativas obtidas com a distribuição GED destacadas na Tabela 7.

$$\begin{cases} \sigma_t^2 = 6,36E - 06 + 0,289549\varepsilon_{t-1}^2 + 0,577413\varepsilon_{t-1}^2 + 0,414388\sigma_{t-1}^2 \\ \sigma_t^2 = 6,36E - 06 + 0,289549\varepsilon_{t-1}^2 + 0,414388\sigma_{t-1}^2 \end{cases} \quad (7)$$

$$\begin{cases} \sigma_t^2 = 6,36E - 06 + 0,866962 \varepsilon_{t-1}^2 + 0,414388\sigma_{t-1}^2 \\ \sigma_t^2 = 6,36E - 06 + 0,289549\varepsilon_{t-1}^2 + 0,414388\sigma_{t-1}^2 \end{cases} \quad (7)$$

Os acontecimentos negativos têm um impacto, no valor de 0,866962, na variabilidade da produção industrial. Este impacto é superior ao dos acontecimentos positivos que assume um valor de 0,289549 e, por isso, presencia-se um efeito de alavancagem assimétrico.

De um modo geral, e comparando os resultados da Tabela 7 com os resultados obtidos na Tabela 4 em que se assume uma distribuição normal, é notável que há uma melhoria na performance de todos os modelos da família GARCH, nos dois índices, ao admitir-se uma distribuição generalizada dos erros.

Para o índice de confiança do consumidor, o modelo GARCH-*in-mean*, de acordo com o logaritmo da variância, revelou ser o modelo mais adequado para os dados. Isto é válido estatisticamente de acordo com os critérios de informação AIC e HQC.

Tabela 7. Estimação dos modelos GARCH para os índices de produção industrial e confiança do consumidor nos EUA, assumindo que os erros seguem uma distribuição do erro generalizado

Painel A: índice de produção industrial nos EUA (base logarítmica)					
	G (1,1)	G-M (desv. p)	G-M (var)	G-M log(var)	G-L
$\mu$	0,002801	0,001517	0,002659	0,01505	0,002548
$\lambda_1$	-	0,16288	-	-	-
$\lambda_2$	-	-	1,689399	-	-
$\lambda_3$	-	-	-	0,001232	-
$\alpha_0$	7,20E-06	6,90E-06	7,09E-06	6,57E-06	6,36E-06
$\alpha_1$	0,518885	0,513413	0,511804	0,50848	0,289549
$\beta_1$	0,552712	0,557255	0,557035	0,563118	0,414388
$\delta_1$	-	-	-	-	0,577413
LL	3869,649	3875,596	3871,18	3879,209	3884,705
AIC	-6,158802	-6,166687	-6,159649	-6,172444	<b>-6,181203</b>
SIC	-6,138345	-6,142138	-6,135100	-6,147895	<b>-6,156654</b>
HQC	-6,151113	-6,157460	-6,150422	-6,163217	<b>-6,171976</b>
Painel B: índice de confiança do consumidor nos EUA (base logarítmica)					
	G (1,1)	G-M (desv. p)	G-M (var)	G-M log(var)	G-L
$\mu$	5,15E-06	-0,000512	-0,000105	0,009475	7,36E-06
$\lambda_1$	-	0,240962	-	-	-
$\lambda_2$	-	-	19,72093	-	-
$\lambda_3$	-	-	-	0,000765	-
$\alpha_0$	9,39E-07	9,42E-07	9,37E-07	8,07E-07	9,49E-07
$\alpha_1$	0,743088	0,754304	0,746704	0,843625	0,701153
$\beta_1$	0,126605	0,11431	0,122791	0,113213	0,12439
$\delta_1$	-	-	-	-	0,078046
LL	3770,384	3771,859	3771,007	3773,2526	3770,525
AIC	-9,869945	-9,871189	-9,868957	<b>-9,874851</b>	-9,868694
SIC	<b>-9,839557</b>	-9,834723	-9,832491	-9,838385	-9,831228
HQC	-9,858245	-9,857149	-9,854917	<b>-9,860811</b>	-9,853654

A Tabela 8 resume os resultados obtidos para os modelos GARCH *standard* e G-L com uma distribuição GED. Os modelos GARCH-M foram excluídos desta Tabela resumo por apresentarem resultados intermédios e por uma questão de facilitar a comparação com os resultados dos subcapítulos anteriores.

Tabela 8. Estimação dos modelos GARCH *standard* e GARCH *with leverage* para o índice de produção industrial desde 1919 até 2023

Painel A: índice de produção industrial nos EUA (base logarítmica)						
	G(1,1)			G-L		
	Distribuição dos erros					
	Normal	<i>t-student</i>	GED	Normal	<i>t-student</i>	GED
LL	3833,885	3882,115	3869,649	3860,543	3894,476	3884,705
AIC	-6,103402	-6,178670	-6,158802	-6,144291	-6,196775	-6,181203
SIC	-6,087036	-6,158212	-6,138345	-6,123833	-6,172226	-6,156654
HQC	-6,097250	-6,170980	-6,151113	-6,136602	-6,187548	-6,171976
$\delta_1$	-	-	-	0,451503	0,396694	0,577413
$\alpha_1$	0,507746	0,534389	0,518885	0,257271	0,326477	0,289549
$\delta_1 + \alpha_1$	-	-	-	0,708774	0,723171	0,866962

Comparando os resultados obtidos nas distribuições dos erros consideradas neste estudo, a qualidade de ajustamento de todos modelos estimados com as distribuições *t-student* e GED melhorou, em comparação com os modelos coincidentes com uma distribuição normal. As evidências estatísticas corroboram com esta ideia.

Note-se que o modelo G-L, com uma distribuição *t-student*, apresentou melhores resultados para todos os critérios de informação e para o logaritmo da verossimilhança, comparativamente com a distribuição GED. Não obstante, o modelo G-L nesta última distribuição revela um efeito de alavancagem assimétrico (0,866962) superior ao verificado na distribuição *t-student* (0,723171).

Relativamente ao índice de confiança do consumidor nos EUA, obteve-se resultados idênticos aos resultados obtidos com as distribuições normais e *t-student*. A análise gráfica da Figura 4, assim como o desvio padrão apresentado na Tabela 1, reforçam esta conclusão.

Por fim e em jeito de culminar o capítulo, a Tabela 9 reúne todos os resultados obtidos nos modelos da família GARCH e nos tipos de distribuição dos erros considerados no presente estudo.

Após estimar todos os modelos da família GARCH e para os vários tipos de distribuição que os erros podem seguir, percebe-se que o modelo GARCH *with leverage* demonstrou ser o modelo mais adequado para modelar a volatilidade da produção industrial americana. Averiguou-se, ainda, que o modelo GARCH-*in-mean*, baseado no logaritmo da variância, revelou ser o modelo com maior nível de adequabilidade para os dados da confiança do consumidor nos EUA. Também se verificou que a inclusão de

outros tipos de distribuição dos erros, para além da distribuição normal, contribui para incrementar a performance de todos os modelos da família GARCH.

Tabela 9. Estimação dos modelos da família GARCH para o índice de produção industrial e de confiança do consumidor

Painel A: índice de produção industrial nos EUA (base logarítmica)															
G(1,1)			G-M (desv.p.)			G-M (var)			G-M log(var)			G-L			
Distribuição dos erros															
	Normal	<i>t-student</i>	GED	Normal	<i>t-student</i>	GED	Normal	<i>t-student</i>	GED	Normal	<i>t-student</i>	GED	Normal	<i>t-student</i>	GED
LL	3833,885	3882,115	3869,649	3840,69	3888,209	3875,596	3835,894	3883,985	3871,18	3844,105	3883,985	3879,209	3860,543	3894,476	3884,705
AIC	-6,103402	-6,178670	-6,158802	-6,112653	-6,186787	-6,166687	-6,105011	-6,180055	-6,159649	-6,118095	-6,180055	-6,172444	<b>-6,144291</b>	<b>-6,196775</b>	<b>-6,181203</b>
SIC	-6,087036	-6,158212	-6,138345	-6,092195	-6,162237	-6,142138	-6,084553	-6,155506	-6,135100	-6,097637	-6,155506	-6,147895	<b>-6,123833</b>	<b>-6,172226</b>	<b>-6,156654</b>
HQC	-6,097250	-6,170980	-6,151113	-6,104963	-6,177560	-6,157460	-6,097322	-6,170828	-6,150422	-6,110406	-6,170828	-6,163217	<b>-6,136602</b>	<b>-6,187548</b>	<b>-6,171976</b>
Painel B: índice de confiança do consumidor nos EUA (base logarítmica)															
G(1,1)			G-M (desv.p.)			G-M (var)			G-M log(var)			G-L			
Distribuição dos erros															
	Normal	<i>t-student</i>	GED	Normal	<i>t-student</i>	GED	Normal	<i>t-student</i>	GED	Normal	<i>t-student</i>	GED	Normal	<i>t-student</i>	GED
LL	3770,359	3770,95	3770,384	3771,853	3772,13	3771,859	3771,003	3771,455	3771,007	3772,687	3772,898	3773,2526	3770,494	3771,13	3770,525
AIC	-9,872502	-9,871429	-9,869945	-9,873795	-9,871901	-9,871189	-9,871568	-9,870132	-9,868957	<b>-9,875983</b>	<b>-9,873913</b>	<b>-9,874851</b>	-9,870233	-9,869279	-9,868694
SIC	<b>-9,848191</b>	<b>-9,841041</b>	<b>-9,839557</b>	-9,843406	-9,835435	-9,834723	-9,841180	-9,833666	-9,832491	-9,845594	-9,837447	-9,838385	-9,839845	-9,832813	-9,831228
HQC	-9,863142	-9,859729	-9,858245	-9,862095	-9,857861	-9,857149	-9,859868	-9,856092	-9,854917	<b>-9,864283</b>	<b>-9,859873</b>	<b>-9,860811</b>	-9,858533	-9,855239	-9,853654

## CAPÍTULO V – TESTES ADICIONAIS

Nos capítulos anteriores investigou-se a dinâmica da volatilidade do crescimento económico nos EUA através de duas variáveis *proxies*: o índice de produção industrial e o índice de confiança do consumidor. Para tal, considerou-se um horizonte temporal bastante extenso, incluindo, assim, na análise, vários acontecimentos históricos e até mesmo acontecimentos globais recentes, nomeadamente a pandemia COVID-19 e o conflito entre a Rússia e Ucrânia. Na verdade, a pandemia COVID-19 e o conflito entre a Rússia e Ucrânia são dois grandes acontecimentos, recentes e globais, que provocaram variações significativas na economia e instabilidade geopolítica.

Com esta análise adicional, pretende-se investigar o impacto destes dois últimos acontecimentos no comportamento da volatilidade dos índices de produção industrial e de confiança do consumidor. A amostra desta análise - denominada subamostra - considera observações com frequência mensal e abrange o período compreendido entre janeiro de 1919 até fevereiro de 2020 para o índice de produção industrial e entre janeiro de 1960 até fevereiro de 2020 para o índice de confiança do consumidor. A subamostra exclui, portanto, os dados observados a partir de fevereiro de 2020 que correspondem à pandemia e ao conflito Rússia-Ucrânia. À semelhança do capítulo anterior, aplicou-se a mesma abordagem econométrica, isto é, os modelos da família GARCH.

Assim, estimou-se novamente os modelos da família GARCH excluindo os dados de ambos os índices a partir de fevereiro de 2020. Considerou-se que os erros seguem uma distribuição normal. A Tabela 10 apresenta os resultados desta nova estimação dos modelos GARCH.

Excluindo a pandemia COVID-19 e o conflito entre a Rússia e Ucrânia, as evidências estatísticas também apontam o modelo GARCH-L como o modelo com melhor desempenho de ajuste para os dados da produção industrial. O modelo G-L apresenta o maior valor para LL e os menores valores para todos os critérios de informação utilizados, em comparação com os restantes modelos da família GARCH. As evidências estatísticas também indicam a presença de um efeito de alavancagem assimétrico na produção industrial. O parâmetro indicativo deste efeito,  $\delta_1$ , assume um valor de 0,618559 e o impacto que os acontecimentos negativos têm na volatilidade da produção industrial, no valor de 0,868541, é superior ao dos acontecimentos positivos no valor de 0,249982. Significa isto que, quer na amostra completa referida no capítulo anterior quer na subamostra do presente capítulo, há provas estatísticas que indicam que a produção

industrial americana segue um efeito de alavancagem assimétrico. Esta coerência na amostra e na subamostra é justificada por duas razões. A primeira é acerca da dimensão do período temporal considerado para a amostra completa e para a subamostra. Ambas consideram um horizonte temporal bastante extenso, nomeadamente 104 e 101 anos, respetivamente. A segunda razão é que, excluindo a pandemia e o conflito Rússia-Ucrânia, são vários os acontecimentos anteriores a estes dois grandes e recentes acontecimentos que impactaram a taxa de crescimento do índice de produção industrial. Pode-se verificar a veracidade desta afirmação graficamente com a Figura 1. Por outro lado, ao excluir a COVID-19 e o conflito militar, é também possível verificar efeitos assimétricos na produção industrial americana, como por exemplo a diminuição da taxa de crescimento deste índice durante a crise financeira internacional em 2008.

O modelo GARCH-M, baseado no logaritmo da variância, obteve os resultados estatísticos indicados para modelar adequadamente a volatilidade da confiança do consumidor americano. A estimação deste modelo resultou no maior valor de LL e nos valores mais baixos para todos os critérios de informação, em comparação com os outros modelos estimados.

Dado que se pretende compreender o comportamento dos modelos da família GARCH face à volatilidade dos índices, para além da distribuição normal, também são consideradas na análise da subamostra outros tipos de distribuição que os erros podem seguir, sendo elas: a distribuição *t-student* e a distribuição generalizada do erro.

Os resultados obtidos para os dados da subamostra, assumindo que os erros seguem uma distribuição *t-student*, estão salientes na Tabela 11.

As evidências estatísticas também indicam o modelo GARCH-L como o modelo mais adequado para modelar a variabilidade da produção industrial norte-americana, supondo uma distribuição *t-student*. Aliás, o modelo G-L revela melhores resultados estatísticos com uma distribuição *t-student* do que com uma distribuição normal dos erros. Isto pode ser explicado pelos acontecimentos adversos que surgiram ao longo do período temporal considerado. Mesmo excluindo os mais recentes acontecimentos extremos, a pandemia COVID-19 e o conflito Rússia-Ucrânia, atente-se outros grandes acontecimentos que interferiram com este índice, como por exemplo, a grande depressão em 1929, as crises do petróleo, a crise gerada pela “*dot com*” e a crise do *Subprime* nos EUA, entre outros.

Em relação ao índice de confiança do consumidor, com uma distribuição *t-student*, verificou-se que o modelo G-M, baseado no logaritmo da variância, é o mais adequado para os dados da subamostra, conforme todos os critérios de informação utilizados. Na

verdade, os resultados obtidos são muito semelhantes aos resultados atingidos com uma distribuição normal. Portanto, a consideração de outro tipo de distribuição dos erros e a exclusão do período referente à pandemia e ao conflito não contribuiu para alterações significativas na volatilidade do índice de confiança do consumidor nos EUA.

Os resultados estatísticos obtidos para ambos os índices com uma distribuição do erro generalizado estão evidenciados na Tabela 12. Verifica-se que os modelos com melhor desempenho de ajuste aos dados da subamostra com uma distribuição GED coincidem com os modelos eleitos para as distribuições normais e *t-student*, quer para o índice de produção industrial quer para o índice de confiança do consumidor.

Tabela 10. Estimação dos modelos GARCH para os índices de produção industrial e confiança do consumidor nos EUA, assumindo que os erros seguem uma distribuição normal

Painel A: índice de produção industrial nos EUA (base logarítmica)					
	G (1,1)	G-M (desv. p)	G-M (var)	G-M log(var)	G-L
$\mu$	0,002808	0,001322	0,002629	0,016409	0,00241
$\lambda_1$	-	0,19291	-	-	-
$\lambda_2$	-	-	2,177775	-	-
$\lambda_3$	-	-	-	0,001369	-
$\alpha_0$	6,20E-06	6,25E-06	6,23E-06	6,01E-06	5,49E-06
$\alpha_1$	0,464876	0,466448	0,462846	0,457953	0,249982
$\beta_1$	0,585877	0,581256	0,585389	0,588592	0,368525
$\delta_1$	-	-	-	-	0,618559
LL	3735,372	3742,724	3737,496	3745,891	3755,592
AIC	-6,152304	-6,162777	-6,154157	-6,167999	<b>-6,183994</b>
SIC	-6,135483	-6,141751	-6,133131	-6,146973	<b>-6,162968</b>
HQC	-6,145971	-6,154861	-6,146241	-6,160083	<b>-6,176078</b>
Painel B: índice de confiança do consumidor nos EUA (base logarítmica)					
	G (1,1)	G-M (desv. p)	G-M (var)	G-M log(var)	G-L
$\mu$	3,37E-05	-0,000786	-0,000277	0,010282	-3,36E-05
$\lambda_1$	-	0,363911	-	-	-
$\lambda_2$	-	-	46,57864	-	-
$\lambda_3$	-	-	-	0,000826	-
$\alpha_0$	8,43E-07	8,83E-07	8,90E-07	7,52E-07	8,44E-07
$\alpha_1$	0,727259	0,746207	0,73661	0,840067	0,725275
$\beta_1$	0,149346	0,11502	0,118971	0,117025	0,003765
$\delta_1$	-	-	-	-	0,149318
LL	3585,851	3590,241	3589,135	3592,301	3585,851
AIC	-9,935786	-9,945190	-9,942121	<b>-9,950904</b>	-9,933013
SIC	-9,910374	-9,913425	-9,910355	<b>-9,919138</b>	-9,901247
HQC	-9,925976	-9,932928	-9,929858	<b>-9,938641</b>	-9,920751

Tabela 11. Estimação dos modelos GARCH para os índices de produção industrial e confiança do consumidor nos EUA, assumindo que os erros seguem uma distribuição *t-student*

Painel A: índice de produção industrial nos EUA (base logarítmica)					
	G (1,1)	G-M (desv. p)	G-M (var)	G-M log(var)	G-L
$\mu$	0,002716	0,001502	0,002575	0,014194	0,002534
$\lambda_1$	-	0,157766	1,677884	-	-
$\lambda_2$	-	-	-	-	-
$\lambda_3$	-	-	-	0,001153	-
$\alpha_0$	6,86E-06	6,35E-06	6,69E-06	6,01E-06	6,21E-06
$\alpha_1$	0,494136	0,482663	0,485959	0,477467	0,303343
$\beta_1$	0,561164	0,571051	0,566522	0,577962	0,577719
$\delta_1$	-	-	-	-	0,361201
LL	3764,32	3769,541	3765,604	3772,626	3776,384
AIC	-6,198385	-6,205343	-6,198853	-6,210430	<b>-6,216627</b>
SIC	-6,177359	-6,180112	-6,173622	-6,185199	<b>-6,191396</b>
HQC	-6,190469	-6,195844	-6,189353	-6,200931	<b>-6,207128</b>
Painel B: índice de confiança do consumidor nos EUA (base logarítmica)					
	G (1,1)	G-M (desv. p)	G-M (var)	G-M log(var)	G-L
$\mu$	-1,85E-05	-0,000766	-0,000261	0,010271	-1,75E-05
$\lambda_1$	-	0,356429	-	-	-
$\lambda_2$	-	-	45,36043	-	-
$\lambda_3$	-	-	-	0,000825	-
$\alpha_0$	8,71E-07	8,83E-07	8,95E-07	7,47E-07	8,73E-07
$\alpha_1$	0,748284	0,750248	0,747237	0,844959	0,736998
$\beta_1$	0,129194	0,113117	0,112266	0,116487	0,128589
$\delta_1$	-	-	-	-	0,022359
LL	3586,361	3590,283	3589,329	3592,32	3586,372
AIC	-9,934428	-9,942532	-9,939887	<b>-9,948182</b>	-9,931683
SIC	-9,902662	-9,904413	-9,901768	<b>-9,910063</b>	-9,893564
HQC	-9,922166	-9,927817	-9,925172	<b>-9,933467</b>	-9,916967

Tabela 12. Estimação dos modelos GARCH para os índices de produção industrial e confiança do consumidor nos EUA, assumindo que os erros seguem uma distribuição generalizada do erro

Painel A: índice de produção industrial nos EUA (base logarítmica)					
	G (1,1)	G-M (desv. p)	G-M (var)	G-M log(var)	G-L
$\mu$	0,002787	0,001502	0,002651	0,014915	0,002544
$\lambda_1$	-	0,166299	-	-	-
$\lambda_2$	-	-	1,665602	-	-
$\lambda_3$	-	-	-	0,001217	-
$\alpha_0$	6,48E-06	6,22E-06	6,40E-06	5,94E-06	5,79E-06
$\alpha_1$	0,481439	0,475888	0,476443	0,469973	0,27605
$\beta_1$	0,570385	0,57401	0,573079	0,580392	0,597204
$\delta_1$	-	-	-	-	0,361588
LL	3756,111	3761,634	3757,301	3765,083	3769,704
AIC	-6,184849	-6,192307	-6,185162	-6,197994	<b>-6,205613</b>
SIC	-6,163824	-6,167076	-6,159931	-6,172763	<b>-6,180382</b>
HQC	-6,176933	-6,182808	-6,175662	-6,188495	<b>-6,196114</b>
Painel B: índice de confiança do consumidor nos EUA (base logarítmica)					
	G (1,1)	G-M (desv. p)	G-M (var)	G-M log(var)	G-L
$\mu$	-3,33E-05	-0,000846	-0,000288	0,010299	-3,32E-05
$\lambda_1$	-	0,385927	-	-	-
$\lambda_2$	-	-	47,52962	-	-
$\lambda_3$	-	-	-	0,000827	-
$\alpha_0$	8,44E-07	8,86E-07	8,91E-07	7,72E-07	8,44E-07
$\alpha_1$	0,727774	0,738082	0,731572	0,813934	0,725578
$\beta_1$	0,148911	0,117192	0,120961	0,120661	0,004246
$\delta_1$	-	-	-	-	0,148844
LL	3585,851	3590,487	3589,202	3592,91	3585,852
AIC	-9,933014	-9,943098	-9,939534	<b>-9,949820</b>	-9,930241
SIC	-9,901248	-9,904978	-9,901415	<b>-9,911700</b>	-9,892122
HQC	-9,920751	-9,928382	-9,924819	<b>-9,935104</b>	-9,915526

Por último, a não inclusão do período referente à pandemia COVID-19 e ao conflito entre a Rússia e Ucrânia traduziu-se em resultados semelhantes aos verificados no capítulo anterior em que se considerava estes dois acontecimentos adversos. Obteve-se, portanto, as mesmas conclusões com a exclusão da pandemia e o conflito, o que demonstra o contributo parcial destes para a dimensão da amostra completa.

## CAPÍTULO VI – CONCLUSÃO

Na presente dissertação é analisada a dinâmica da volatilidade do crescimento económico nos Estados Unidos através de duas variáveis *proxies*: o índice de produção industrial e o índice de confiança dos consumidores. Pretende-se provar que um aumento na variabilidade dos índices conduz a um aumento da variabilidade nos períodos seguintes e que uma inovação negativa nos índices provoca um efeito assimétrico na volatilidade dos índices nos períodos seguintes.

Para a investigação recolheram-se dados mensais da produção industrial e da confiança do consumidor nos EUA, desde janeiro de 1919 até agosto de 2023 e de janeiro de 1960 até agosto de 2023. Os dados foram recolhidos da plataforma *Federal Reserve Bank of Saint Louis*. A amostra em estudo é extensa o suficiente para incluir vários acontecimentos que impactaram significativamente a economia em geral ao longo do tempo, o que viabiliza detetar no longo prazo o comportamento da volatilidade, bem como o efeito assimétrico supracitado.

A metodologia selecionada é conhecida por modelos da família GARCH e considerou-se três extensões do modelo GARCH para o presente estudo. O *software* estatístico *Eviews 12 Student Version* desempenhou um papel importante no tratamento dos dados da amostra e na seleção do modelo mais adequado para os dados sob investigação.

Constatou-se que, para uma distribuição normal, o modelo GARCH *with leverage* apresenta evidência estatística que o indicam como o modelo com melhor desempenho de ajuste aos dados da produção industrial nos EUA. Além disto, as evidências estatísticas revelam que a produção industrial segue um efeito de alavancagem assimétrico. Uma inovação negativa no índice de produção industrial provoca mais volatilidade no período seguinte do que uma inovação positiva. Em geral, os resultados obtidos para este índice estão alinhados com a trajetória de crescimento observada no setor da produção industrial na economia americana. Por outro lado, verificou-se que, para a confiança do consumidor, o modelo mais adequado para os dados desta série é modelo GARCH-*in-mean*, baseado no logaritmo da variância. De facto, não há neste índice variações extremas como no índice de produção industrial e, por isso, observa-se uma trajetória mais estacionária neste índice no longo prazo. Assim, os resultados obtidos para o índice de confiança do consumidor fazem jus ao crescimento histórico observado na confiança do consumidor americano no horizonte temporal considerado.

Ao longo do estudo, assumiu-se que os erros podem seguir os seguintes tipos de distribuição: distribuição normal, distribuição *t-student* e distribuição do erro generalizado. Demonstrou-se estatisticamente que o tipo de distribuição que os erros podem seguir é relevante para a performance dos modelos da família GARCH em estudo.

No que concerne à distribuição *t-student*, descobriu-se que, para a produção industrial, os modelos da família GARCH tiveram um melhor nível de desempenho que os modelos coincidentes com uma distribuição normal. Com uma distribuição GED, os modelos GARCH também apresentaram um desempenho superior àquele que demonstraram com uma distribuição normal, mas inferior ao desempenho revelado com uma distribuição *t-student*. Para o índice de confiança do consumidor, os resultados obtidos para os três tipos de distribuição que os erros podem seguir foram bastante semelhantes.

Por último, com a análise adicional da subamostra, excluiu-se os períodos referentes à recente pandemia COVID-19 e o conflito entre a Rússia e Ucrânia na Europa. A não inclusão dos dados mensais a partir de fevereiro de 2020 em diante conduziu a resultados semelhantes. O longo horizonte temporal utilizado na análise para estimar os modelos GARCH pode ser a explicação para o facto de se obter resultados semelhantes. Por isto, estes dois acontecimentos contribuem apenas parcialmente para a dimensão da amostra completa.

Os resultados do presente estudo contribuem para a literatura existente, uma vez que prova estatisticamente a ideia pré-concebida, isto é, que um aumento na variabilidade no INDPRO conduz a um aumento da variabilidade nos períodos seguintes e que este índice segue um efeito de alavancagem assimétrico. O presente estudo tem uma tripla contribuição para a literatura atual. Primeiro, é analisado a dinâmica da volatilidade no crescimento dos índices económicos nos EUA através de uma amostra mensal bastante extensa que abrange mais de cem anos para o índice de produção industrial e mais de sessenta anos para o índice de confiança do consumidor. Utilizou-se os modelos GARCH para incorporar na análise o *feedback* da volatilidade e o efeito de alavancagem assimétrico. Segundo, testou-se a relevância dos tipos de distribuição que os erros podem seguir na performance dos modelos estimados e, por último, obteve-se dados para dois períodos distintos: um período com uma amostra completa, onde se inclui o COVID-19 e o conflito militar, e um período com uma subamostra, onde se exclui o COVID-19 e o conflito militar. Este último contributo permitiu avaliar que os resultados eram adequados com estes dois recentes e adversos acontecimentos a nível global.

Para um estudo futuro, sugere-se a não consideração do modelo GARCH *standard*, visto que já existem outras extensões capazes de capturar efeitos assimétricos numa análise e com melhores níveis de adequabilidade aos dados em estudo. Sugere-se, ainda, a inclusão de outros tipos de distribuição para substituir a distribuição normal no termo de erro.

## REFERÊNCIAS

- Bernanke, B.S., (1983). Irreversibility, uncertainty, and cyclical investment. *The Quarterly Journal of Economics*, 98 (1), 85–106. <https://doi.org/10.2307/1885568>
- Bollerslev, T., (1986). Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, 31, 307–327. [https://doi.org/10.1016/0304-4076\(86\)90063-1](https://doi.org/10.1016/0304-4076(86)90063-1)
- Boungou, W., & Yatié, A., (2022). The impact of the Ukraine-Russia war on world stock market returns. *Economics Letters*, 215, 110516. <https://doi.org/10.1016/j.econlet.2022.110516>
- Caporale, T., & McKiernan, B., (1996). The relationship between output variability and growth: evidence from post war UK data. *Scottish Journal of Political Economy*, 43, 229–236. <https://doi.org/10.1111/j.1467-9485.1996.tb00675.x>
- Cassola, N., De Grauwe, P., Morana, C., & Tirelli, P. (2022). The risks of exiting too early the policy responses to the COVID-19 recession. *Research in Globalization*, 4, 100073. <https://doi.org/10.1016/j.resglo.2021.100073>
- Cermeño, R., & Grier, K.B., (2006). Conditional heteroskedasticity and cross-sectional dependence in panel data: an empirical study of inflation uncertainty in the G7 countries. *Contributions to Economic Analysis*, 274, 259–277. [https://doi.org/10.1016/S0573-8555\(06\)74010-X](https://doi.org/10.1016/S0573-8555(06)74010-X)
- da Silva, R. A., Coronel, D. A., Bender Filho, R., & da Silva, M. L. (2017). Efeito contágio entre a produção industrial brasileira e as principais economias mundiais. *Revista de Contabilidade & Controladoria*, 9(1). 10.5380/rcc.v9i1.44786
- Dickey, D. A., & Fuller, W. A. (1979). Distribution of the estimators for autoregressive time series with a unit root. *Journal of the American Statistical Association*, 74, 427-431. <https://doi.org/10.2307/2286348>
- Endri, E., Aipama, W., & Septiano, R., (2021). Stock price volatility during the COVID-19 pandemic: The GARCH model. *Investment Management and Financial Innovations*, 18(4), 12. 10.21511/imfi.18(4).2021.02
- Engle, R. F., Lilien, D. M., & Robins, R. P. (1987). Estimating time varying risk premia in the term structure: The ARCH-M model. *Econometrica: Journal of the Econometric Society*, 391-407. <https://doi.org/10.2307/1913242>
- Engle, R.F., (1982). Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation. *Econometrica: Journal of the Econometric Society*, 50, 987–1007. <https://doi.org/10.2307/1912773>
- Fernandes, M.C., Dias, J.C., & Nunes, J.P., (2024). Performance comparison of alternative stochastic volatility models and its determinants in energy futures: COVID-19 and Russia – Ukraine conflict features. *Journal of Futures Markets*, 44(3), 343–383. <https://doi.org/10.1002/fut.22469>

- Fountas, S., & Karanasos, M., (2006). The relationship between economic growth and real uncertainty in the G3. *Economic Modelling*, 23(4), 638-647. <https://doi.org/10.1016/j.econmod.2006.03.002>
- Glosten, L.R., Jagannathan, R., & Runkle, D.E., (1993). On the relation between the expected value and the volatility of the nominal excess return on stocks. *Journal of Finance*, 48 (5), 1779–1801. <https://doi.org/10.1111/j.1540-6261.1993.tb05128.x>
- Grier, K.B., & Tullock, G., (1989). An empirical analysis of cross-national economic growth, 1951–1980. *Journal of Monetary Economics*, 24(2), 259–276. [https://doi.org/10.1016/0304-3932\(89\)90006-8](https://doi.org/10.1016/0304-3932(89)90006-8)
- Horváth, L., Kokoszka, P., & Rice, G. (2014). Testing stationarity of functional time series. *Journal of Econometrics*, 179(1), 66-82. <https://doi.org/10.1016/j.jeconom.2013.11.002>
- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: principles and practice*. (2<sup>nd</sup> ed.)
- Kormendi, R.C., & Meguire, P.G., (1985). Macroeconomic determinants of growth: cross-country evidence. *Journal of Monetary Economics*, 16(2), 141–163. [https://doi.org/10.1016/0304-3932\(85\)90027-3](https://doi.org/10.1016/0304-3932(85)90027-3)
- Kydland, F.E., & Prescott, E.C., (1982). Time to build and aggregate fluctuations. *Econometrica: Journal of the Econometric Society*, 1345–1370. <https://doi.org/10.2307/1913386>
- Lee, J., (2006). The comovement between output and prices: Evidence from a dynamic conditional correlation GARCH model. *Economics Letters*, 91(1), 110–116. <https://doi.org/10.1016/j.econlet.2005.11.006>
- Lee, J., (2010). The link between output growth and volatility: Evidence from a GARCH model with panel data. *Economics Letters*, 106(2), 143-145. <https://doi.org/10.1016/j.econlet.2009.11.008>
- Liu, Y., Wu, H., Wang, J., & Long, M., (2022). Non-stationary transformers: Exploring the stationary in time series forecasting. *Advances in Neural Information Processing Systems*, 35, 9881-9893. <https://doi.org/10.48550/arXiv.2205.14415>
- Mahlstein, K., McDaniel, C., Schropp, S., & Tsigas, M. (2022). Estimating the economic effects of sanctions on Russia: an allied trade embargo. *The World Economy*, 45(11), 3344-3383. <https://doi.org/10.1111/twec.13311>
- Martin, P., & Rogers, C.A., (2000). Long-term growth and short-term economic instability. *European Economic Review*, 44(2), 359–381. [https://doi.org/10.1016/S0014-2921\(98\)00073-7](https://doi.org/10.1016/S0014-2921(98)00073-7)
- Mirman, L.J., (1971). Uncertainty and optimal consumption decisions. *Econometrica: Journal of the Econometric Society*, 39(1), 179–185. <https://doi.org/10.2307/1909149>
- Nelson, D. B., (1991). Conditional heteroskedasticity in asset returns: a new approach. *Econometrica*, 59(2), 347-370. <https://doi.org/10.2307/2938260>

- Phillips, P.C., & Perron, P., (1988). Testing for a unit root in time series regression. *Biometrika* 75(2), 335–346. <https://doi.org/10.2307/2336182>
- Pindyck, R., (1991). Irreversibility, uncertainty, and investment. *Journal of Economic Literature*, 29, 1110–1148.
- Ramey, G., & Ramey, V., (1991). Technology commitment and the cost of economic fluctuations. *NBER Working Paper*, 375.
- Ramey, G., & Ramey, V.A., (1994). Cross-country evidence on the link between volatility and growth. *American Economic Association*, 85(5), 1138-1151.
- Wei, Y., Wang, Y., & Huang, D., (2010). Forecasting crude oil market volatility: further evidence using GARCH class models. *Energy Economics*, 32, 1477–1484
- Zarnowitz, V., & Moore, G.H., (1986). Major changes in cyclical behavior, in: *The American business cycle: continuity and change*. University of Chicago Press, (pp. 519–582). University of Chicago Press.

**UNIVERSIDADE DOS AÇORES**  
**Faculdade de Economia e Gestão**

Rua da Mãe de Deus  
9500-321 Ponta Delgada  
Açores, Portugal



**DM**

2024

# A relação entre os índices de produção industrial e de confiança dos consumidores nos Estados Unidos da América

Inês Miranda Silvestre