



Instituto de
MATEMÁTICA
E ESTATÍSTICA
UFRGS



ESTIMAÇÃO DE VOLATILIDADE UTILIZANDO MODELOS GAS E GARCH

DESIREÉ DE BÖER VELHO

PORTO ALEGRE

2018

DESIREÉ DE BÖER VELHO

Estimação de volatilidade utilizando modelos GAS e GARCH

Trabalho de Conclusão de Curso apresentado
para obtenção do grau de Bacharel em Estatística.

Orientador: Flávio Augusto Ziegelmann

PORTO ALEGRE

2018

AGRADECIMENTOS

Agradeço ao meu orientador, professor Flávio Augusto Ziegelmann, por ter aceitado me orientar neste trabalho, pela dedicação, pela paciência, pelo conhecimento compartilhado, pelas sugestões e por todo o tempo consumido em meu auxílio.

Aos meus pais, pelo incentivo e pelo esforço em me proporcionar as melhores oportunidades, sempre prezando pela educação de qualidade. À minha irmã, pela paciência. Aos meus avós, pelo carinho. E à minha dinda, pelo apoio, pelos conselhos e principalmente, pelo exemplo.

Ao meu querido Arian, pelo incentivo, pela companhia, pelo suporte, pela compreensão e pelo auxílio dados que foram de extrema importância para a realização deste trabalho.

Aos meus amigos pelo suporte emocional, pela torcida e pela compreensão de minha ausência, especialmente à Milena.

Muito obrigada a todos que me auxiliaram a passar por mais este desafio!

*"If you can dream it, you can do it."
(Walt Disney)*

RESUMO

O estudo da volatilidade apresenta um papel importante em áreas como economia e estatística. Este trabalho inicialmente visa, através de dados simulados, identificar se a dinâmica GAS (Generalized Autoregressive Score) traz benefícios em relação à dinâmica GARCH (Generalized Autoregressive Conditional Heteroskedasticity) usada para estimar volatilidade. O modelo GAS, proposto por Creal, Koopman e Lucas (2008), é um modelo de séries temporais para parâmetros variantes no tempo, onde o gradiente da função de probabilidade no instante $t-1$ (em relação ao parâmetro variante no tempo) determina parcialmente a dinâmica do parâmetro variante. O modelo GARCH, proposto por Bollerslev (1986), descreve a dinâmica da variância condicional (volatilidade) como parcialmente dependente dos quadrados passados das observações. Além disso, dados empíricos provenientes da série do índice Bovespa serão analisados a fim de se comparar a performance dos modelos propostos em situações reais.

Palavras-chaves: GAS. GARCH. Séries Temporais. Volatilidade.

ABSTRACT

The study of volatility presents an important role in areas such as economics and statistics. This work initially aims, through simulated data, to identify if the GAS (Generalized Autoregressive Score) dynamics brings benefits in relation to the GARCH (Generalized Autoregressive Conditional Heteroskedasticity) dynamics used to estimate volatility. The GAS model, proposed by Creal, Koopman e Lucas (2008), is a time series model for time varying parameters, where the gradient of the probability function at time $t-1$ (in relation to the time variant parameter) partially determines the dynamics of the variant parameter. In addition, empirical data from the Bovespa index series will be analyzed in order to compare the performance of the proposed models in real situations.

Key-words: GAS. GARCH. Time Series. Volatility.

LISTA DE FIGURAS

Figura 1 – Gráfico da série do Índice Bovespa	14
Figura 2 – Retornos da série do Índice Bovespa	14
Figura 3 – Boxplot dos erros médios e EQM para a volatilidade para o modelo gerador GARCH	21
Figura 4 – Boxplot dos erros médios e EQM para a volatilidade para o modelo gerador GARCH	21
Figura 5 – Boxplot dos erros médios e EQM para a volatilidade para o modelo gerador GARCH	22
Figura 6 – Boxplot dos erros médios e EQM para a volatilidade para o modelo gerador GARCH	22
Figura 7 – Boxplot dos erros médios e EQM para a volatilidade para o modelo gerador GARCH	23
Figura 8 – Boxplot dos erros médios e EQM para a volatilidade para o modelo gerador GARCH	23
Figura 9 – Boxplot dos erros médios e EQM para a volatilidade para o modelo gerador GAS	24
Figura 10 – Boxplot dos erros médios e EQM para a volatilidade para o modelo gerador GAS	24
Figura 11 – Boxplot dos erros e EQM para os parâmetros estimados através do modelo GARCH	25
Figura 12 – Boxplot dos erros e EQM para os parâmetros estimados através do modelo GARCH	25
Figura 13 – Boxplot dos erros e EQM para os parâmetros estimados através do modelo GARCH	26
Figura 14 – Boxplot dos erros e EQM para os parâmetros estimados através do modelo GARCH	27
Figura 15 – Boxplot dos erros e EQM para os parâmetros estimados através do modelo GARCH	27
Figura 16 – Boxplot dos erros e EQM para os parâmetros estimados através do modelo GARCH	28
Figura 17 – Boxplot dos erros e EQM para os parâmetros estimados através do modelo GAS	28
Figura 18 – Boxplot dos erros e EQM para os parâmetros estimados através do modelo GAS	29
Figura 19 – Série dos dados do Ibovespa	30
Figura 20 – Série de retornos do Ibovespa	30

Figura 21 – (a) Histograma dos retornos (b) Q-Qplot dos retornos	31
Figura 22 – Função de autocorrelação dos retornos	32
Figura 23 – Função de autocorrelação parcial dos retornos.	32
Figura 24 – Comportamento da volatilidade	33

LISTA DE TABELAS

Tabela 1 – Estatísticas Descritivas	31
Tabela 2 – Critérios de Informação	33

LISTA DE ABREVIATURAS E SIGLAS

ACF	Autocorrelation Function
AIC	Akaike Information Criterion
ARCH	Autoregressive Conditional Heteroskedasticity
BIC	Bayesian Information Criterion
EQM	Erro Quadrático Médio
GAS	Generalized Autoregressive Score
GARCH	Generalized Autoregressive Conditional Heteroskedasticity
IBOVESPA	Índice da Bolsa de Valores do Estado de São Paulo
PACF	Partial Autocorrelation Function

SUMÁRIO

1	INTRODUÇÃO	11
2	METODOLOGIA	13
2.1	Índice Bovespa	13
2.2	Retornos	13
2.3	Volatilidade	15
2.4	Modelos	15
2.4.1	Modelo ARCH	15
2.4.2	Modelo GARCH	16
2.4.3	Modelo GAS	17
3	ANÁLISE NUMÉRICA	20
3.1	Dados empíricos: Índice Bovespa	29
4	CONSIDERAÇÕES FINAIS	34
	REFERÊNCIAS BIBLIOGRÁFICAS	35
	ANEXO A – SINTAXE NO R	36

1 INTRODUÇÃO

A estimação de volatilidade é alvo de grande interesse em áreas como economia e estatística. O estudo sobre a volatilidade dos retornos dos ativos é destaque em teorias financeiras e é frequentemente utilizado a partir de dados diários, comumente sendo empregado o preço de fechamento. É indispensável que a análise da volatilidade seja feita de maneira adequada, não apenas para o esboço de estratégias ótimas na administração de ativos, mas como também para a percepção de momentos de incerteza no mercado. Com um alto grau de incerteza em relação às crises ou fatores exógenos, tem-se também uma alta variação nos preços e na variância dos retornos, causando assim a possibilidade de notáveis ganhos e/ou perdas (MORAIS; PORTUGAL, 1999).

Para uma melhor compreensão a respeito do comportamento dos mercados e, a partir daí, tornar possível a análise de estratégias de gerenciamento de risco, vários estudos já foram conduzidos via análise dos índices das bolsas de valores do mundo todo, assim como dos retornos de demais ativos (COSTA, 2013). É possível observar, na análise de séries financeiras, períodos de alta e baixa volatilidade, requerendo assim a utilização de modelos heteroscedásticos condicionais, ou seja, modelos que consideram que a variância condicional de uma série temporal não é constante (FIORUCI, 2012).

Os modelos autoregressivos condicionalmente heteroscedásticos (ARCH) foram propostos por Engle (1982) e posteriormente generalizados por Bollerslev (1986), com os modelos generalizados autoregressivos condicionalmente heteroscedásticos (GARCH), alvo de estudo neste trabalho. Existe uma grande diversidade de modelos da família GARCH. No contexto univariado, exemplos são os modelos EGARCH, propostos por Nelson (1991), os modelos TARARCH, propostos por Rabemananjara e Zakoian (1993), entre muitos outros. Tais modelos são amplamente empregados em larga escala para modelagem de volatilidade e baseiam-se na estimação da variação condicional.

O modelo generalizado de escore autoregressivo (GAS), propostos por Creal, Koopman e Lucas (2008), é o foco principal deste trabalho, tendo como característica o uso de uma função escore para descrever a dinâmica dos parâmetros do modelo que são variantes no tempo. O modelo é uma proposta recente, que serve, em particular, para modelar volatilidade. O modelo GARCH gaussiano é um caso particular do GAS.

Os objetivos principais deste trabalho são comparar a qualidade do ajuste das estimações realizadas pelos modelos GAS e GARCH, tanto para dados simulados, quanto para dados empíricos. Os objetivos específicos são modelar a distribuição para os erros do modelo, optando-se pela distribuição normal, distribuição t de student e distribuição t de student assimétrica, para assim investigar se a dinâmica da volatilidade deve ser alterada conjuntamente, de acordo com o modelo GAS.

O presente trabalho está estruturado em quatro capítulos. No primeiro capítulo são apresentadas as motivações para o trabalho, assim como seus respectivos objetivos. No segundo capítulo são introduzidos alguns conceitos a respeito do mercado de ações, de retornos e de volatilidade em séries temporais. Ademais, neste capítulo é iniciada uma revisão bibliográfica referente aos modelos GARCH e GAS. O terceiro capítulo realiza a descrição do estudo com os dados simulados, como também o estudo com o uso dos dados empíricos provenientes do Índice Bovespa. Por fim, é elaborada a conclusão, no qual são abordadas as considerações finais.

2 METODOLOGIA

Esta seção tem como intuito introduzir conceitos sobre o Índice Bovespa, retornos e volatilidade em séries financeiras, assim como descrever os modelos utilizados neste trabalho, a saber modelos GAS e GARCH.

2.1 Índice Bovespa

O índice Bovespa é o principal indicador de desempenho das ações negociadas na Bolsa de Valores do estado de São Paulo. É composto pelas ações de maior volume de negócios nos últimos quatro meses (IBOVESPA, 2018). Foi criado em 02 de janeiro de 1968 e desde então, realiza a simulação de uma carteira teórica de ações. De acordo com Costa (2013) :

Para compor o índice são considerados em sua carteira teórica apenas os papéis que possuam participação superior a 0,1% do volume total negociado. As ações que integram a carteira precisam juntas responder por 80% do volume negociado no mercado a vista nos últimos 12 meses e devem possuir um mínimo de participação em 80% dos pregões elaborados nesse mesmo período. O peso de cada papel na carteira está relacionado ao número de negócios e o volume que a ação apresenta no mercado a vista. Se deixar de atender algum desses critérios a ação é excluída da carteira teórica Bovespa.

A cada quatro meses é realizada a avaliação da composição da carteira, nos meses de janeiro, maio e setembro. O cálculo do índice é feito em tempo real e consiste na soma ponderada das ações constituintes da carteira teórica, representado a seguir:

$$I = \sum P^i Q_i, \quad (1)$$

onde Q_i é a quantidade teórica de cada ação que compõe a carteira e P_i é o último preço respectivo.

2.2 Retornos

Retornos de ativos financeiros podem ser descritos através da diferença entre o logaritmo natural do preço de um ativo no instante t e o logaritmo natural do seu preço no instante t-1, isto é, entre os preços de um ativo entre os instantes t e t-1 (FIORUCI, 2012).

$$y_t = \log \frac{P_t}{P_{t-1}} = p_t - p_{t-1}, \text{ onde } p_t = \log(P_t) \quad (2)$$

Em geral, retornos são modelados ao invés de preços dos ativos, pois os preços são, na maioria dos casos, séries não estacionárias e raramente previsíveis.


A Figura 1 mostra a série de dados diários do Índice Ibovespa do dia 01 de janeiro de 2010 até o dia 18 de maio de 2018, totalizando 2069 observações. É possível observar uma queda no índice desde o ano de 2009 e que esta queda se realça em janeiro de 2016. Após esse período, a série apresenta um notável aumento.

Figura 1 – Gráfico da série do Índice Bovespa



Uma das características da série de retornos é a estacionariedade, como é possível observar na Figura 2, que representa o gráfico de retornos da série dos dados do Índice Bovespa. Além disso, pode-se observar alguns fatos estilizados, como a existência de agrupamentos de volatilidade, caudas pesadas, assimetria e ausência de autocorrelação. A existência de agrupamentos de volatilidade está diretamente associada à existência de autocorrelação entre os quadrados dos retornos. É possível notar que os retornos não apresentam correlação serial, mas seus quadrados apresentam.

Figura 2 – Retornos da série do Índice Bovespa



A distribuição conjunta dos retornos pode ser definida como o produto das distribuições para cada um dos retornos, condicionados aos retornos anteriores, como se observa a seguir:

$$p(y_1, \dots, y_T) = p(y_1)p(y_2/I_2)p(y_3/I_3)\dots p(y_T/I_T), \text{ onde } I_T = \{y_{t-1}, y_{t-2}, \dots\} \quad (3)$$

A variância das distribuições condicionais apresentadas na expressão acima é denominada de volatilidade e será alvo de estudo deste trabalho.

2.3 Volatilidade

Desde Markowitz (1952), a análise da volatilidade é importante na teoria de finanças. De acordo com o autor, a variância também deveria ser analisada, não apenas os retornos dos ativos. No entanto, o modelo de Markowitz pressupõe uma constância na variância condicional dos retornos dos ativos, o que não se verifica empiricamente em séries financeiras. Na década de 1970, alguns estudos foram sendo propostos e ditavam a presença de heteroscedasticidade em séries do mercado financeiro. Mandelbrot (1963) realizou a análise de dados de preços de algodão provenientes dos Estados Unidos, evidenciando valores distintos de variância amostral ao longo da série.

Modelos de heteroscedasticidade condicional foram apresentados por Engle (1982), onde a variância condicional de um retorno em um dado instante t depende dos valores dos retornos passados através de uma função quadrática. Tal modelo foi denominado de ARCH (Autoregressive Conditional Heteroskedasticity). Estes modelos foram generalizados por Bollerslev (1986) e foram chamados de GARCH (Generalized Autoregressive Conditional Heteroskedasticity). Após, diversos modelos de volatilidade foram desenvolvidos. Modelos da família GARCH são introduzidos de maneira mais detalhada na próxima seção.

O estudo de volatilidade é de larga relevância para a análise de séries temporais, pois é uma medida de dispersão dos retornos de um ativo, ou seja, aponta se o preço de um determinado ativo possui uma alta ou baixa variação. Em análise financeira, períodos com alta volatilidade remetem a um maior risco, possibilitando maiores perdas, assim como maiores ganhos. Já períodos com baixa volatilidade, possuem um risco mais baixo.

2.4 Modelos

Nesta seção serão apresentados três modelos que tratam sobre a heteroscedasticidade condicional: os modelos ARCH, GARCH e GAS.

2.4.1 Modelo ARCH

Engle (1982) propôs o primeiro modelo que aborda a heteroscedasticidade condicional em séries financeiras, o modelo ARCH, modelo de heteroscedasticidade condicional autore-

gressivo. Este modelo dita que a variância condicional da série temporal no presente momento depende dos quadrados dos retornos passados. Considerando r_t uma série temporal estacionária de retornos, temos que o modelo ARCH é dado por:

$$r_t = \sqrt{h_t} \varepsilon_t \quad (4)$$

$$h_t = \alpha_0 + \alpha_1 r_{t-1}^2 + \dots + \alpha_q r_{t-p}^2, \quad (5)$$

onde h_t representa a variância condicional de r_t , α_0 representa uma constante e ε_t representa uma sequência de variáveis aleatórias independentes e identicamente distribuídas (i.i.d.) que apresentam média igual a zero e variância igual a um, $\alpha_0 > 0$, $\alpha_i \geq 0$, $i > 0$. Pode-se, por exemplo, supor que ε_t segue uma distribuição normal ou uma distribuição t de Student com v graus de liberdade (MORETTIN, 2008).

O modelo ARCH (p), onde p é a ordem do modelo, retrata a variância condicional em função de inovações quadráticas de momentos passados. Em 1986, Bollerslev relatou que, em algumas aplicações, o modelo ARCH resultava em modelos não parcimoniosos, necessitando assim de modelos com ordens mais altas (BOLLERSLEV, 1986).

2.4.2 Modelo GARCH

Em 1986, uma generalização do modelo ARCH foi introduzida por Bollerslev, denominada de modelo GARCH, modelo generalizado de heteroscedasticidade condicional autoregressivo. O modelo GARCH surgiu como uma alternativa para o problema do modelo ARCH, que constantemente exigia o uso de muitos parâmetros para uma adequada descrição do processo de volatilidade dos retornos (TSAY, 2005).

Este modelo define que a variância condicional da série temporal no presente momento depende tanto da variância condicional dos seus valores passados, como também dos quadrados dos retornos passados. A definição de um modelo GARCH (p,q), onde p é a ordem correspondente ao número de defasagens das inovações quadráticas e q é a ordem correspondente ao número de defasagens da variância condicional, é dada da seguinte maneira:

$$r_t = \sqrt{h_t} \varepsilon_t \quad (6)$$

$$h_t = \alpha_0 + \sum_{i=1}^p \alpha_i r_{t-i}^2 + \sum_{j=1}^q \beta_j h_{t-j}, \quad (7)$$

em que ε_t representa uma sequência de variáveis aleatórias independentes e identicamente distribuídas (i.i.d.) que apresentam média igual a zero e variância igual a um, r_t representa uma série temporal estacionária de retornos, h_t representa a variância condicional de r_t , $\alpha_0 > 0$, $\alpha_i \geq 0$, $\beta_j \geq 0$ e $\sum_{i=1}^m (\alpha_i + \beta_i) < 1$. Assim, como no modelo ARCH, é possível supor que ε_t

segue uma distribuição normal ou uma distribuição t de Student com v graus de liberdade, entre outras (MORETTIN, 2008).

Conforme Hamilton (1994), um modelo GARCH apresenta alguns benefícios, em relação ao modelo ARCH, como a parcimônia, ou seja, requer a estimação de um menor número de parâmetros.

Estimação por Máxima Verossimilhança

Segundo Morettin e Toloi (2006), os estimadores dos parâmetros do modelo das equações 6 e 7 são obtidos pelo método de máxima verossimilhança condicional. Supondo normalidade dos ε_t , temos que a log-verossimilhança, condicionada às p primeiras observações, é dada por:

$$l(\alpha, \beta | r_1, r_2, \dots, r_p) \propto -\frac{1}{2} \sum_{t=p+1}^N \ln(h_t) - \frac{1}{2} \sum_{t=p+1}^N \frac{r_t^2}{h_t} \quad (8)$$

As estimativas dos parâmetros são obtidas através de métodos de maximização de $l(\alpha, \beta | r_1, \dots, r_p)$.

2.4.3 Modelo GAS

O modelo de escore generalizado autoregressivo (GAS) consiste em uma nova classe de modelos de séries temporais baseados em um mecanismo de atualização, onde a dinâmica do parâmetro variante no tempo é descrita por um componente autorregressivo e também por um componente defasado do gradiente da função de probabilidade em relação ao parâmetro variante (CREAL; KOOPMAN; LUCAS, 2008). Concomitantemente, Harvey e Chakravarty (2008) propuseram o modelo Beta-t-(E) GARCH, um modelo de escore orientado especificamente para volatilidade, sendo este um caso especial do modelo GAS.

Definição 2.1: Seja y_t a variável dependente de interesse no tempo t , f_t o vetor dos parâmetros variantes no tempo t , x_t o vetor de variáveis exógenas (covariáveis) e θ o vetor de parâmetros estáticos. Sejam, $Y_1^t = \{y_1, \dots, y_t\}$, $F_1^t = \{f_1, \dots, f_t\}$, $X_1^t = \{x_1, \dots, x_t\}$. A informação disponível no tempo t consiste em Y_1^{t-1} , $F_1^{t-1} = \{f_{t-1}, F_1^{t-2}\}$ e X_1^t . Assumimos que y_t é gerado pela densidade preditiva:

$$p(y_t | f_{t-1}, Y_1^{t-1}, X_1^t, F_1^{t-2}; \theta), \text{ onde } t = 1, \dots, n. \quad (9)$$

O mecanismo de atualização dos parâmetros variantes no tempo f_t é dado pela seguinte equação:

$$f_t = \omega + \sum_{i=0}^{p-1} A_i s_{t-i} + \sum_{j=1}^q B_j f_{t-j}, \quad (10)$$

onde ω é um vetor de constantes, as matrizes A_i e B_j possuem dimensões apropriadas para $i = 0, \dots, p-1$ e $j = 1, \dots, q$, ao mesmo tempo que, s_t é uma função do gradiente no tempo t , que depende das observações passadas Y_1^{t-1} , dos parâmetros variantes no tempo F_1^{t-1} e do vetor de parâmetros estático θ . Além disso, todos os coeficientes desconhecidos em (10) são funções de θ , ou seja, $\omega = \omega(\theta)$, $A_i = A_i(\theta)$, $B_j = B_j(\theta)$ para $i = 1, 2, \dots, p$ e $j = 1, 2, \dots, q$. O que difere o modelo GAS dos demais modelos com parâmetros variantes no tempo é a seleção do mecanismo de condução s_t , aplicável em uma larga classe de densidades e modelos não lineares.

Após realizada uma nova observação, o parâmetro variante no tempo f_t realiza uma atualização, conforme a equação (10), se encaminhando para o período $t+1$, onde:

$$s_t = S_t \nabla_t \quad (11)$$

$$\nabla_t = \partial \ln p(y_t | f_t, F_t; \theta) / \partial f_t \quad (12)$$

$$S_t = S(t, f_t, F_t; \theta), \quad (13)$$

em que S_t é uma matriz de ponderação. Dado que o mecanismo de atualização na equação (10) é dependente de um vetor escore ponderado, as equações (9)-(11) constituem as equações generalizadas do modelo GAS com ordens p e q . O modelo resultante é abreviado por GAS (p, q).

Exemplo: Modelo Garch

Considerando o modelo básico $y_t = \sigma_t \varepsilon_t$, temos que o distúrbio gaussiano ε_t possui média zero e variância unitária, enquanto σ_t representa o desvio padrão variante no tempo.

É possível mostrar que o modelo GAS(1,1) com $S_{t-1} = \iota_{t-1}^{-1}$ para $f_t = \sigma_t^2$ é transformado em:

$$f_t = \omega + A_0(y_t^2 - f_{t-1}) + B_1 f_{t-1}, \quad (14)$$

que é equivalente à especificação do modelo padrão GARCH(1,1) de Bollerslev (1986).

Estimação por Máxima Verossimilhança

Segundo Creal, Koopman e Lucas (2008), para uma série temporal y_1, \dots, y_n , pode-se expressar o estimador de máxima verossimilhança a seguir:

$$\max_{\theta} \sum_{t=1}^n l(\theta; y_t; f_t; Y_1^{t-1}; X_1^t; F_1^{t-1}), \quad (15)$$

$$l(\theta; y_t; f_t; Y_1^{t-1}; X_1^t; F_1^{t-1}) = \ln p(y_t | f_t, Y_1^{t-1}, X_1^t, F_1^{t-1}; \theta), \text{ para uma observação de } y_t. \quad (16)$$

O modelo GAS, semelhantemente ao modelo GARCH, define um filtro para os parâmetros variantes no tempo, o que torna a função de verossimilhança simples, sendo necessário apenas realizar a execução do mecanismo de atualização do GAS visto na equação (10) e a avaliação de $p(y_t|f_t, Y_1^{t-1}, X_1^t, F_1^{t-1}; \theta^*)$ para um valor particular θ^* de θ .

Para a especificação GAS(1,1), Creal, Koopman e Lucas (2008) realizam a derivada do gradiente pela regra da cadeia, como segue:

$$\frac{dl_t}{d\theta'} = \frac{\partial \ln p_t}{\partial \theta'} + \frac{\partial \ln p_t}{\partial f_{t-1}'} \frac{\partial f_{t-1}}{\partial \theta'} \quad (17)$$

$$\frac{\partial f_t}{\partial \theta'} = \frac{\partial \omega}{\partial \theta'} + A_0 \frac{\partial s_t}{\partial \theta'} + B_1 \frac{\partial f_{t-1}}{\partial \theta'} + (s_t' \otimes I) \frac{\partial \vec{A}_0}{\partial \theta'} + (f_{t-1}' \otimes I) \frac{\partial \vec{B}_1}{\partial \theta'}, \quad (18)$$

$$\frac{\partial s_t}{\partial \theta'} = S_{t-1} \frac{\partial \nabla t}{\partial \theta'} + (\nabla_t' \otimes I) \frac{\partial \vec{S}_{t-1}}{\partial \theta'}, \quad (19)$$

onde $l_t = l(\theta; y_t; f_t; Y_1^{t-1}; X_1^t; F_1^{t-1})$, $p_t = p(y_t|f_t, Y_1^{t-1}, X_1^t, F_1^{t-1}; \theta)$, $\vec{A} = \text{vec}(A)$ consiste no vetor com as colunas empilhadas da matrix A e \otimes representa o produto de Kronecker. As especificações do modelo GAS com ordem superior podem ser tratadas de forma semelhante através da formulação do modelo GAS, com a atualização da equação. As derivadas da log-verossimilhança podem ser calculadas simultaneamente com os parâmetros variantes no tempo f_t .

3 ANÁLISE NUMÉRICA

No presente capítulo, será apresentado um estudo com simulações e dados empíricos, com o propósito de se analisar a eficiência do modelo GAS frente ao modelo GARCH na estimação de volatilidade. Para geração dos dados simulados e também para as estimações foi utilizado o software R, versão 3.4.3. Os pacotes manipulados para o auxílio nas análises foram o pacote fGarch, constituído por uma coleção de funções para análise e ajuste de modelos de séries temporais financeiras com comportamentos heteroscedásticos e o pacote GAS que foi desenvolvido para simular, estimar e prever modelos GAS univariados e multivariados.

Para a simulação dos dados, um dos modelos geradores foi o modelo GARCH com distribuição de probabilidade para os erros seguindo a distribuição normal, a distribuição t de student e também a distribuição t de student assimétrica. O outro foi o modelo GAS, para o qual foi levado em consideração apenas a distribuição t de student para a distribuição de probabilidade dos erros, visto que o modelo GARCH gaussiano corresponde ao modelo GAS gaussiano.


As amostras simuladas foram manipuladas com tamanhos de 1000 e também 2000. O número de réplicas geradas foi de 10000. As simulações com o modelo gerador GARCH foram estimadas pelo GAS e também pelo GARCH. O mesmo ocorreu para o modelo gerador GAS, onde as estimações foram realizadas com o modelo GARCH e também GAS. O método de estimação dos parâmetros utilizado foi o método de máxima verossimilhança.

O modelo GARCH gerador dos dados teve duas especificações. Na primeira, tomou-se para os parâmetros os valores de $\beta_1 = 0.8$, $\alpha_1 = 0.1$ e $\alpha_0 = 0.05$. Na segunda, tomou-se os valores de $\beta_1 = 0.4$, $\alpha_1 = 0.1$ e $\alpha_0 = 0.05$. Já para os modelos GAS, os valores de parâmetros foram escolhidos a partir das estimativas deste modelo para as séries simuladas com o modelo gerador GARCH. Assim, na primeira especificação, temos $\omega = -0.05$, $A_{2,2} = 0.135$, $B_{2,2} = 0.939$, considerando o valor de graus de liberdade para a distribuição t-student igual a 4. Na segunda especificação, temos $\omega = -1.605$, $A_{2,2} = 0.263$, $B_{2,2} = 0.477$ e graus de liberdade igual a 4.

Para realizar a quantificação do desempenho dos modelos utilizados neste estudo, foi calculada a diferença entre os valores reais dos parâmetros e os valores estimados para os mesmos, onde tal diferença será denominada de erro. Ademais, o erro quadrático médio (EQM) será utilizado como uma segunda medida de quantificação. O mesmo será feito para avaliar as estimativas de volatilidade.

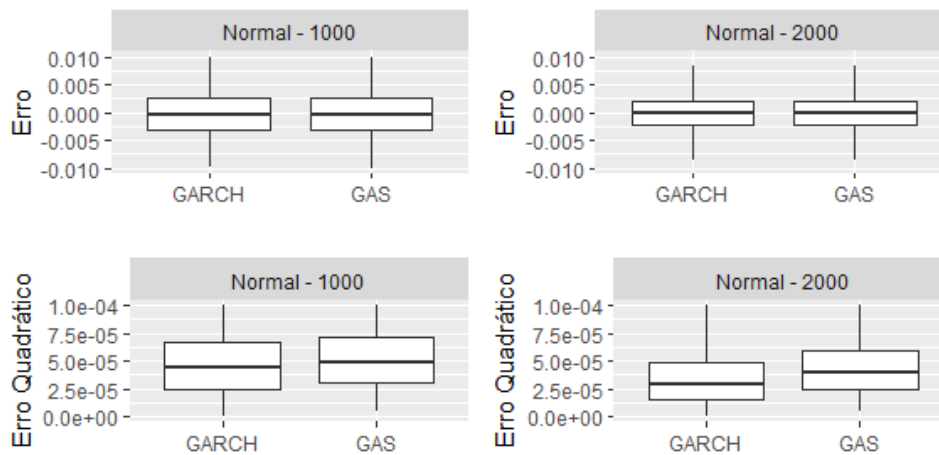
Para o estudo sobre a volatilidade, o primeiro resultado a ser analisado foi para os dados gerados pelo modelo GARCH com parâmetros $\beta_1 = 0.8$, $\alpha_1 = 0.1$ e $\alpha_0 = 0.05$, com os erros seguindo uma distribuição normal. Como pode ser observado no boxplot da figura 3, onde constam os erros médios e também EQMs para os tamanhos de amostra de 1000 e 2000, tem-se um indicativo de que o modelo GARCH apresenta uma melhor performance na estimação, por possuir menores valores de EQM.

Figura 3 – Boxplot dos erros médios e EQM para a volatilidade para o modelo gerador GARCH



Ao analisar os boxplots da figura 4, em que uma simulação análoga foi conduzida, apenas substituindo-se o valor de β_1 para 0.4, há um indicativo de que os estimadores possuem uma ausência de viés, pois o valor para a média dos erros se encontra em torno de zero. Com a análise de EQM, pode-se indicar que o modelo GARCH continuou com um melhor desempenho frente ao modelo GAS.

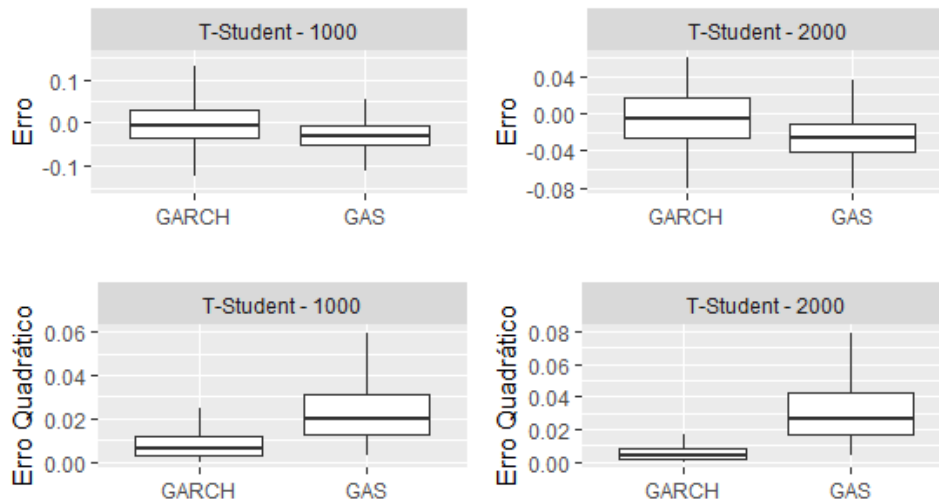
Figura 4 – Boxplot dos erros médios e EQM para a volatilidade para o modelo gerador GARCH



Em seguida, o estudo de volatilidade foi replicado para o modelo gerador GARCH, fixando-se os valores de parâmetros em $\beta_1 = 0.8$, $\alpha_1 = 0.1$ e $\alpha_0 = 0.05$, apenas substituindo-se a distribuição dos erros para uma distribuição t de student com graus de liberdade igual a 4.

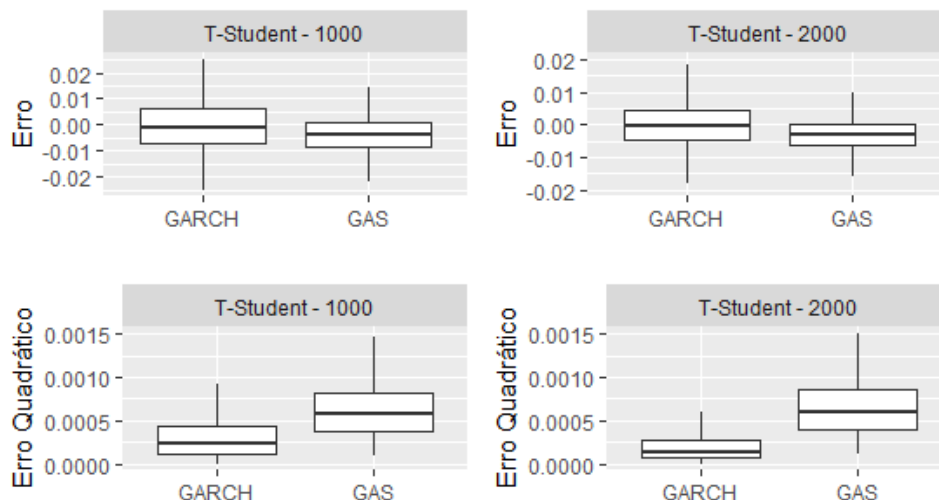
Como é possível observar nos boxplots apresentados na figura 5, que representa os erros médios e EQM para os tamanhos de amostra de 1000 e 2000, há um indicativo da ausência de viés nos erros médios. Ao analisar o EQM, mais uma vez é possível apontar que o modelo GARCH resultou em uma estimação mais próxima dos valores reais de volatilidade.

Figura 5 – Boxplot dos erros médios e EQM para a volatilidade para o modelo gerador GARCH



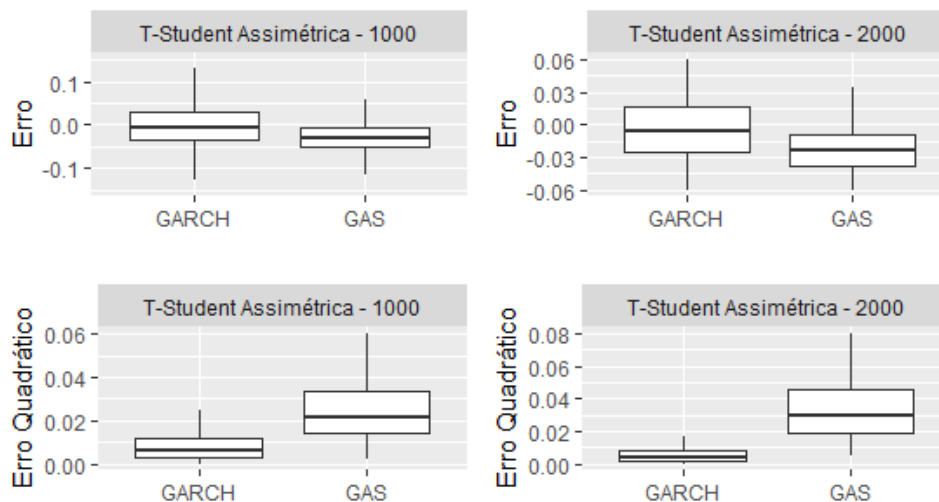
Os boxplots da figura 6 representam os erros médios e EQM para os tamanhos de amostra de 1000 e 2000, assumindo a distribuição t de student para os erros, mantendo-se os demais valores de parâmetros mencionados no parágrafo anterior. Pode-se dizer que ao analisar o EQM, o modelo GARCH indica ser o modelo com maior eficiência no processo de estimação. Além disso, é possível notar ausência de viés nos erros médios.

Figura 6 – Boxplot dos erros médios e EQM para a volatilidade para o modelo gerador GARCH




Os resultados da figura 7 mostram os erros médios e EQM para 4 cenários diferentes, concebendo-se que a distribuição de erros segue uma distribuição t de student assimétrica, mantendo-se o modelo gerador GARCH e os valores de parâmetros fixados em $\beta_1 = 0.8$, $\alpha_1 = 0.1$ e $\alpha_0 = 0.05$. Como pode ser visto, há evidências de que o modelo GARCH revelou ser o melhor estimador de volatilidade em comparação ao modelo GAS.

Figura 7 – Boxplot dos erros médios e EQM para a volatilidade para o modelo gerador GARCH



Já na figura 8, é possível observar os erros médios e EQM, reproduzindo-se as mesmas especificações do parágrafo anterior, com a única diferença de que o parâmetro β_1 assume valor igual a 0.4. Pode-se dizer com a análise gráfica, que o modelo GARCH apresentou melhor desempenho na estimação de volatilidade. Pela proximidade dos erros ao redor do zero, pode-se constatar que há indícios de ausência de viés.

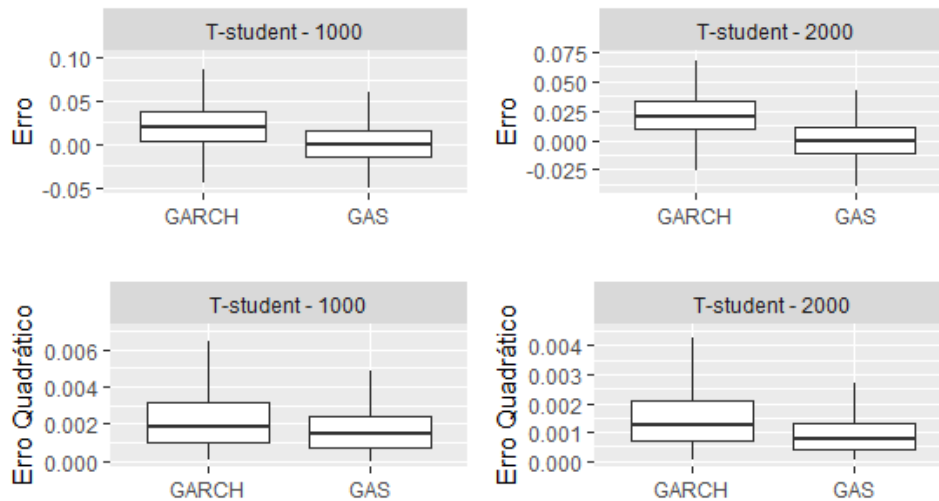
Figura 8 – Boxplot dos erros médios e EQM para a volatilidade para o modelo gerador GARCH



Para a geração dos dados simulados a partir do modelo GAS, foram fixados os valores de parâmetros de $\omega = -0.05$, $A_{2,2} = 0.135$, $B_{2,2} = 0.939$, com distribuição de probabilidade para os erros t de student com 4 graus de liberdade. A partir da análise da figura 9, há uma sugestão de

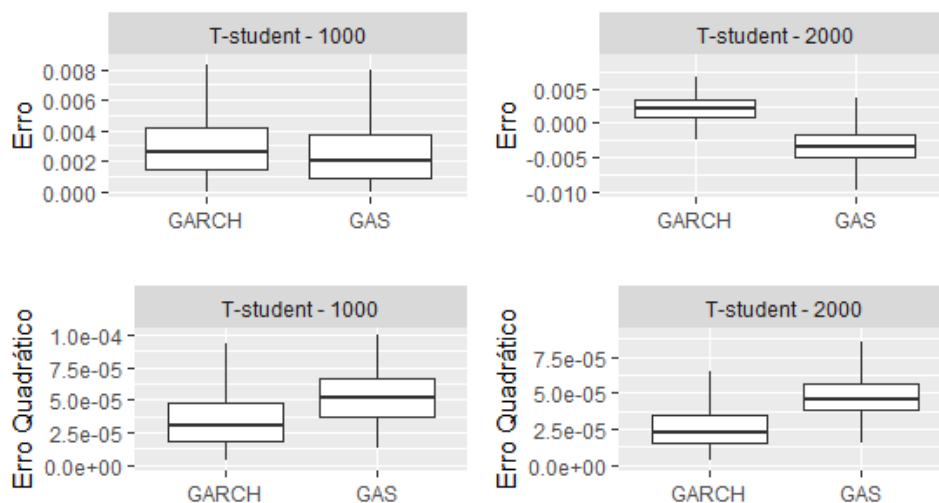
que o EQM do modelo GAS é inferior ao modelo GARCH, indicando sua performance superior. Assim como na análise anterior, pode-se constatar que há indícios de ausência de viés.

Figura 9 – Boxplot dos erros médios e EQM para a volatilidade para o modelo gerador GAS



Já na figura 10, os valores escolhidos para os parâmetros foram de $\omega = -1.605$, $A_{2,2} = 0.263$, $B_{2,2} = 0.477$, sendo empregados para tamanhos de amostra 1000 e 2000, levando-se em conta que os erros assumem distribuição t de student com 4 graus de liberdade. A partir da análise gráfica, é possível notar que há um indício de que o modelo GARCH apresenta melhor comportamento na estimação de volatilidade, devido ao seu valor de EQM inferior ao do modelo GAS.

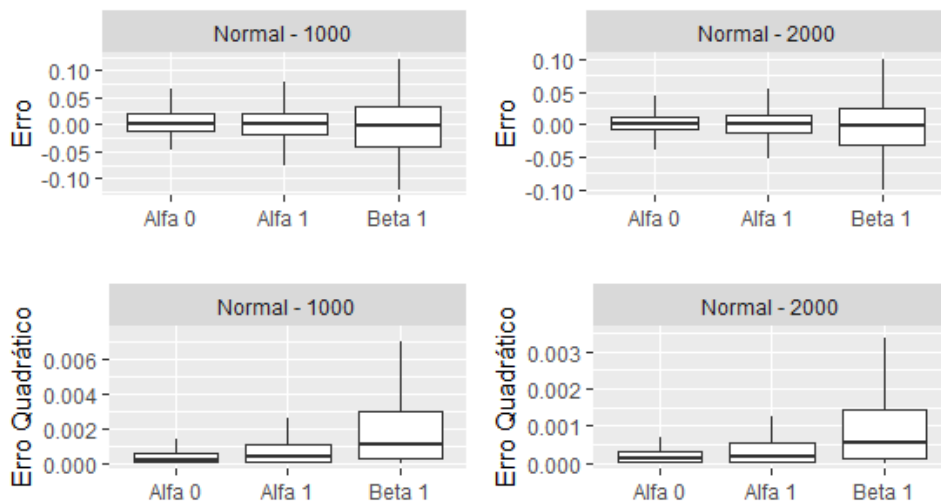
Figura 10 – Boxplot dos erros médios e EQM para a volatilidade para o modelo gerador GAS



Para a análise dos parâmetros, em que o modelo GARCH foi considerado modelo gerador, foram observados os erros e EQM's para as estimativas dos parâmetros de $\beta_1 = 0.8$, $\alpha_1 = 0.1$ e


$\alpha_0 = 0.05$ para um tamanho de amostra igual a 1000, como pode-se observar na figura 11. É possível constatar que os estimadores estão se comportando apropriadamente com ausência de viés, evidenciando uma maior variabilidade no parâmetro β_1 . O mesmo foi verificado para o tamanho de amostral igual a 2000.

Figura 11 – Boxplot dos erros e EQM para os parâmetros estimados através do modelo GARCH



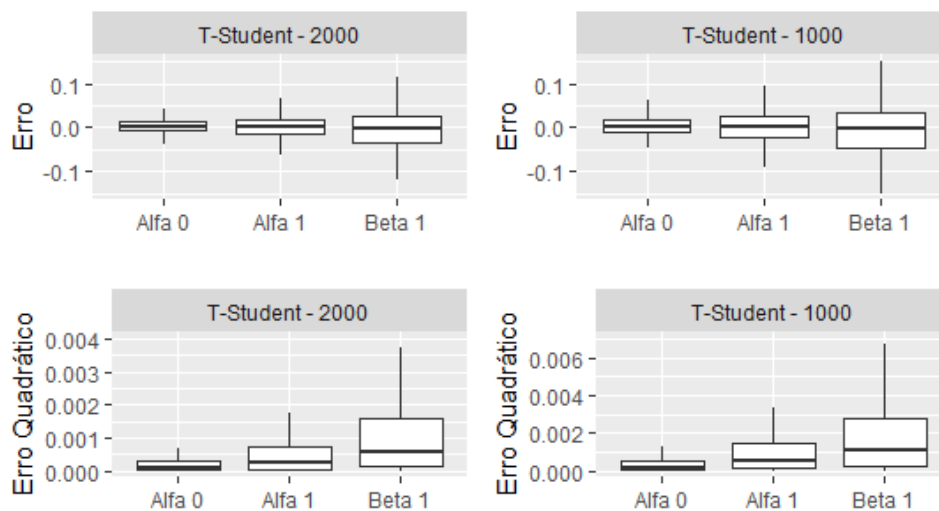
Os boxplots da figura 12 representam os erros e EQM para os tamanhos de amostra de 1000 e 2000, tomando os valores de $\beta_1 = 0.4$, $\alpha_1 = 0.1$ e $\alpha_0 = 0.05$ para os parâmetros do modelo GARCH. Pode-se constatar que os erros não apresentaram indícios de viés, devido a proximidade dos valores da média com o valor zero. Ao analisar o EQM, é possível apontar que o parâmetro α_0 resultou em uma estimação mais próxima dos valores reais, sendo que o parâmetro β_1 obteve indícios de maior variabilidade.

Figura 12 – Boxplot dos erros e EQM para os parâmetros estimados através do modelo GARCH



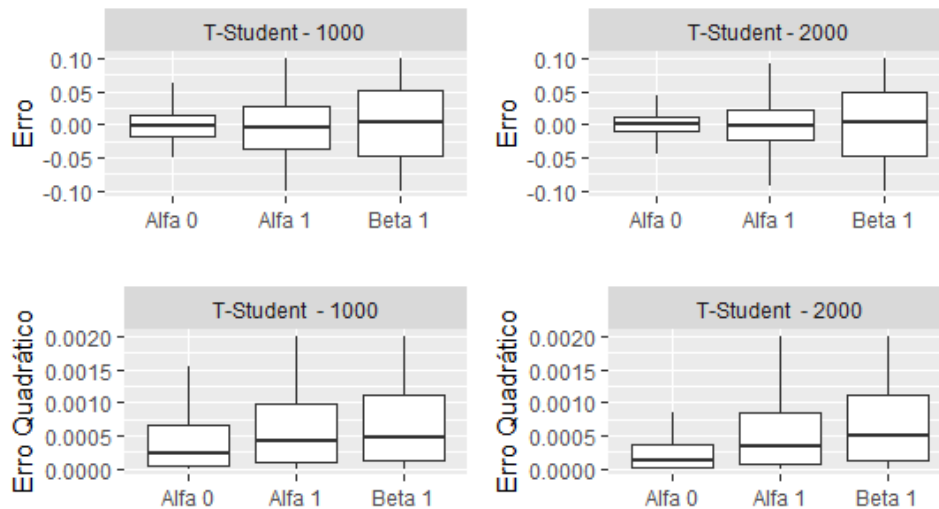
Ainda para o modelo gerador GARCH, foram simulados valores de $\beta_1 = 0.8$, $\alpha_1 = 0.1$ e $\alpha_0 = 0.05$ para os tamanhos de amostra de 1000 e 2000, apenas modificando a distribuição dos erros para uma distribuição t de student com 4 graus de liberdade. Com a análise gráfica dos boxplots mostrados na figura 13, é possível reafirmar o que foi observado na análise anterior, de que há um indício que o parâmetro β_1 possui uma maior variabilidade frente aos parâmetros α_1 e α_0 . Além disso, pode-se constatar que o parâmetro α_0 apresenta menor variabilidade e também menores valores de EQM.

Figura 13 – Boxplot dos erros e EQM para os parâmetros estimados através do modelo GARCH



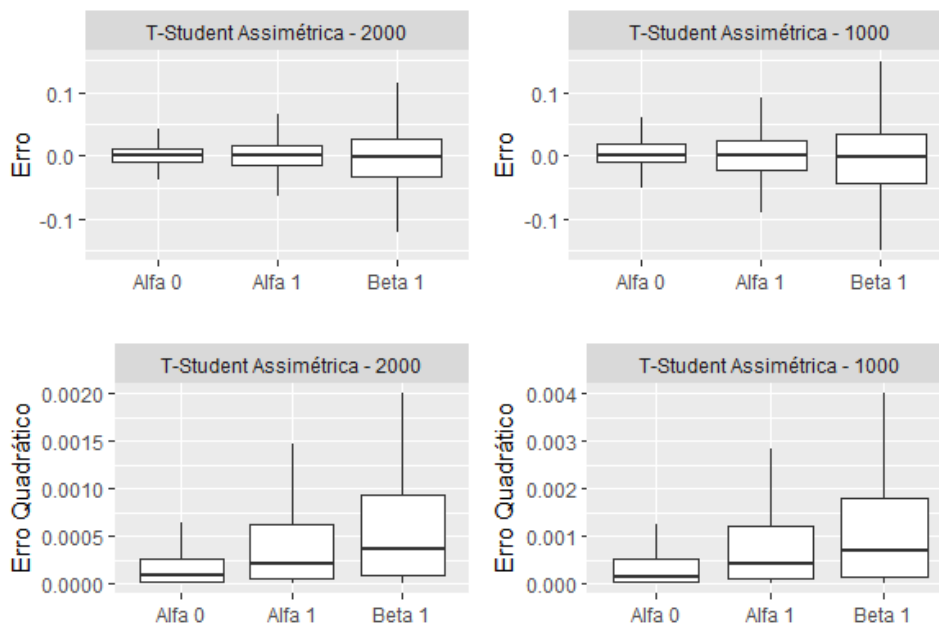
A simulação anterior foi replicada novamente, considerando-se os valores de parâmetros de $\beta_1 = 0.4$, $\alpha_1 = 0.1$ e $\alpha_0 = 0.05$ para amostras de 1000 e 2000 valores. De acordo com os boxplots da figura 14, nota-se que há um indicativo de ausência de viés para os estimadores. Além disso, observa-se uma maior variabilidade para o parâmetro β_1 , seguido pelo parâmetro α_1 .

Figura 14 – Boxplot dos erros e EQM para os parâmetros estimados através do modelo GARCH



Ainda considerando-se o modelo GARCH como gerador, foi realizada a simulação dos dados, a partir da distribuição de erros t de student assimétrica, concebendo-se os valores de parâmetros fixados em $\beta_1 = 0.8$, $\alpha_1 = 0.1$ e $\alpha_0 = 0.05$. Observa-se nos boxplots da figura 15 que há ausência de viés devido a proximidade dos valores dos erros ao valor zero. Além disso, é possível constatar que o parâmetro β_1 possui maior variabilidade.

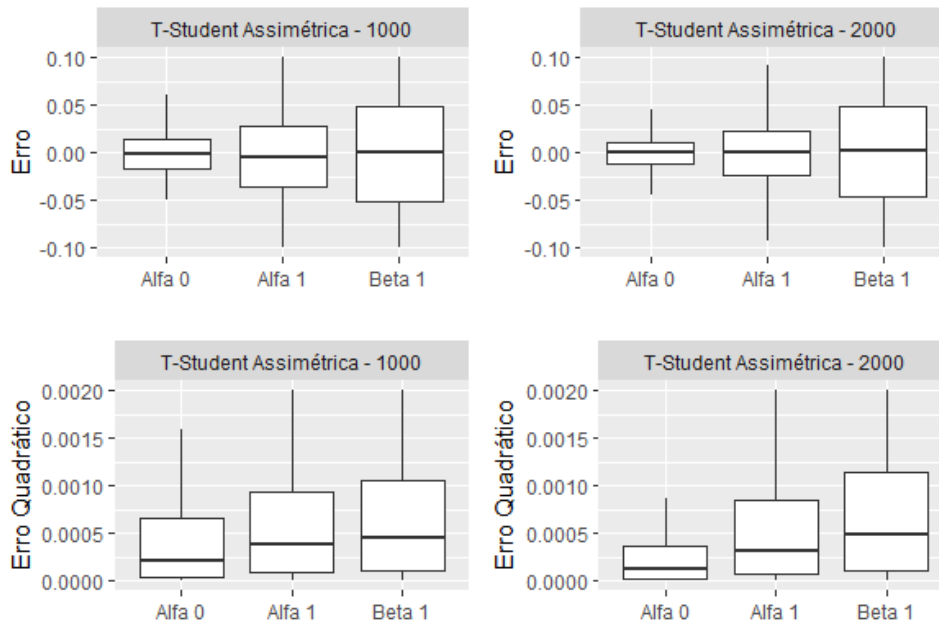
Figura 15 – Boxplot dos erros e EQM para os parâmetros estimados através do modelo GARCH



Já nos boxplots mostrados na figura 16, o mesmo cenário anterior é simulado, com a modificação de que o parâmetro β_1 é fixado em 0.4. Pode-se afirmar que, assim como o resultado

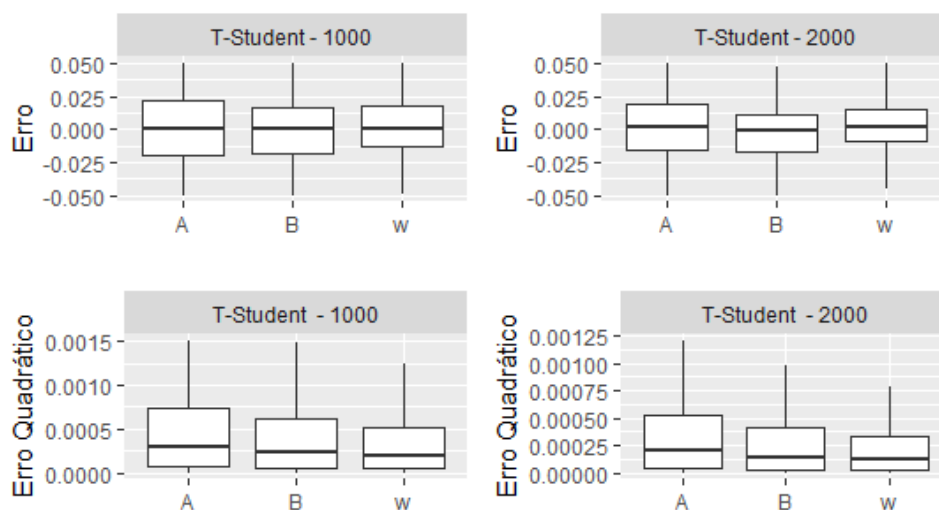
anterior, o parâmetro β_1 apresentou maior variabilidade, com menores valores de EQM para o parâmetro α_0 . Além disso, nota-se a ausência de viés nos erros.

Figura 16 – Boxplot dos erros e EQM para os parâmetros estimados através do modelo GARCH



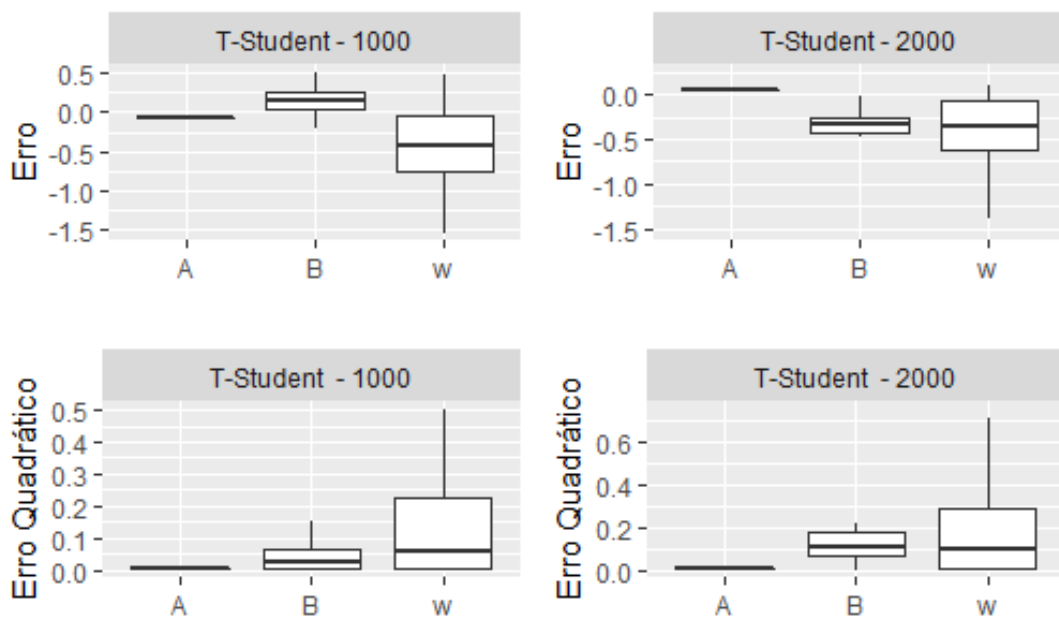
Foi realizada a simulação concebendo-se o modelo GAS como modelo gerador e tamanho de amostra igual a 1000. É possível atestar com a análise dos gráficos da figura 17, onde são apresentadas as estimações para os parâmetros de $\omega = -0.05$, $A_{2,2} = 0.135$, $B_{2,2} = 0.939$, que os erros do modelo não apresentam indicativos de viés e de que o parâmetro ω revela uma menor variabilidade. O mesmo foi constatado para o tamanho de amostra 2000.

Figura 17 – Boxplot dos erros e EQM para os parâmetros estimados através do modelo GAS



Por último, dados simulados foram gerados de acordo com a simulação descrita anteriormente, porém houve a mudança dos valores dos parâmetros para $\omega = -1.605$, $A_{2,2} = 0.263$, $B_{2,2} = 0.477$. Com a análise gráfica do boxplot apresentado na figura 18, pode-se dizer que o parâmetro ω obteve maior variabilidade frente aos demais parâmetros. Observou-se também a presença de viés para os três estimadores dos parâmetros da matriz A , do ω e da matriz B , sugerindo que não há ausência de viés em todo espaço paramétrico.

Figura 18 – Boxplot dos erros e EQM para os parâmetros estimados através do modelo GAS



3.1 Dados empíricos: Índice Bovespa

Para análise dos dados empíricos, o índice escolhido foi o IBOVESPA, pois reflete o mercado brasileiro. A base de dados utilizada para análise constitui-se em 2069 registros diários de preço de fechamento do Índice, compreendendo o período de 01 de janeiro de 2010 até 18 de maio de 2018. Os dados foram obtidos com o auxílio do pacote do R, `quantmod`.


Inicialmente, foi analisado o comportamento gráfico dos dados para o período analisado, em termos de preços e retornos, como é possível observar nas seguintes figuras:

Figura 19 – Série dos dados do Ibovespa



Com a análise do comportamento gráfico, é visto que há uma perceptível queda no índice desde o ano de 2009 e que esta queda se evidencia em janeiro de 2016. No entanto, a série apresenta um aumento considerável a partir deste período.

Figura 20 – Série de retornos do Ibovespa



Ao analisar o gráfico para a série de retornos do Ibovespa mostrado na figura 20, é possível notar a presença de estacionariedade. Também é observado a existência de agrupamentos de volatilidade ao decorrer do tempo, uma característica comum em séries de retornos. Períodos de alta e baixa volatilidade são encontrados, o que evidencia a não homogeneidade da série com o tempo.

Em seguida, foram feitos os cálculos para as estatísticas descritivas da série de retornos dos índices, conforme a Tabela 1.

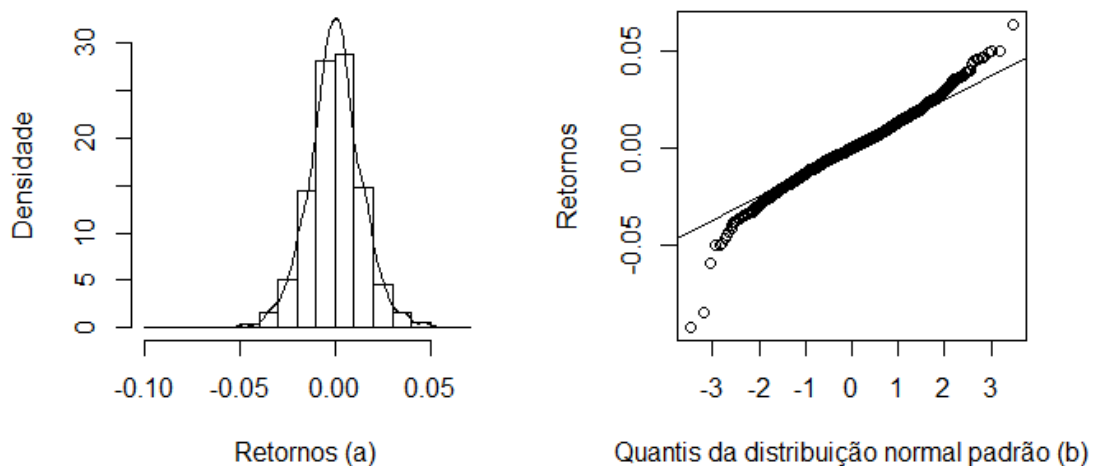
Tabela 1 – Estatísticas Descritivas

Estatística	Retorno dos Índices
Mínimo	-0,092
1º Quartil	-0,008
Mediana	0,00016
Média	0,000086
3º Quartil	0,0084
Máximo	0,064
Desvio Padrão	0,014
Curtose	5,054

Com a análise descritiva, pode-se destacar que há um indicativo de assimetria, pois os valores de média e mediana possuem uma diferença considerável entre si.


Ao observar a Figura 21, em que é apresentado o histograma e também o Q-Qplot da série de retornos, pode-se constatar que a distribuição destes é leptocúrtica, ou seja, possui caudas mais pesadas do que uma distribuição normal, o que se confirma com o valor de curtose igual à 5,054.

Figura 21 – (a) Histograma dos retornos (b) Q-Qplot dos retornos




Após a averiguação de algumas características da série dos índices, seguiu-se para a estimação dos modelos. Primeiramente, foi realizada a análise da função de autocorrelação dos retornos da série de dados e também retornos ao quadrado, como pode ser visto na Figura 22.

Figura 22 – Função de autocorrelação dos retornos



A Figura 23 apresenta a função de autocorrelação parcial dos retornos da série de dados, como pode ser visto a seguir:


Figura 23 – Função de autocorrelação parcial dos retornos.



Analisando os gráficos, é possível observar que não há valores significativos tanto para a autocorrelação, quanto para a autocorrelação parcial. Em contrapartida, o gráfico das autocorrelações dos retornos ao quadrado possuem autocorrelação para algumas defasagens. Estas características são comumente encontradas em séries de retornos.

Em seguida, foi realizada a estimação de volatilidade, como pode ser visto na Figura 24, que apresenta a volatilidade estimada pelos modelos GAS e GARCH representados pelas cores preta e azul, respectivamente.

Figura 24 – Comportamento da volatilidade



O critério para seleção do melhor modelo consistiu no Critério de Informação de Akaike (AIC) e também no Critério de Informação Bayesiano (BIC). Estes critérios realizam a penalização da função de verossimilhança do modelo conforme a sua complexidade, fazendo que os modelos que são considerados melhores sejam aqueles com maior valor da função de verossimilhança e menor número de parâmetros.

A tabela 2 apresenta os valores de AIC e BIC para os modelos estimados, como é visto a seguir:

Tabela 2 – Critérios de Informação

Estatística	AIC	BIC
Modelo GARCH	-11842.09	-11813.91
Modelo GAS	-11812.51	-11789.97

Dentre os dois modelos ajustados, o modelo GARCH apresentou melhor desempenho na estimação de volatilidade, uma vez que possui menor valor de AIC e também o menor valor de BIC, sendo estes iguais a -11842.09 e -11813.91, respectivamente.

4 CONSIDERAÇÕES FINAIS

As simulações mostraram que as estimações realizadas tanto pelo modelo GAS, quanto pelo modelo GARCH apresentam resultados muito semelhantes. No entanto, para as simulações em que o modelo gerador foi o GARCH, houve indícios de que, ao comparar ambos os modelos, o modelo GARCH fornece melhores estimativas para a volatilidade. Já para o modelo gerador GAS, o melhor estimador dependeu dos valores escolhidos para os parâmetros. Vale ressaltar que, é importante realizar a investigação de demais métodos que avaliem o ajuste para a estimação feita pelos modelos mencionados anteriormente, além do erro médio e do erro quadrático médio. E também é necessário considerar que os resultados são provenientes de uma amostra de dados simulados para cenários especificados com base na literatura.

Conjuntamente, realizou-se neste trabalho uma análise empírica da volatilidade dos retornos do índice Bovespa, utilizando os modelos GARCH e GAS, com a finalidade de realizar a estimação da variância condicional. Observou-se, desta forma, que o modelo GARCH obteve um resultado superior do que o modelo GAS, tanto pelo AIC quanto pelo BIC.

REFERÊNCIAS BIBLIOGRÁFICAS

- BOLLERSLEV, T. Generalized autoregressive conditional heteroskedasticity. **Journal of Econometrics**, v. 31, p. 307–327, 1986.
- COSTA, T. **Análise Dos Retornos Diários Do Índice Bovespa Sob Uma Ótica Não Linear**. 2013. Monografia (Bacharel em Economia), Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, Brasil.
- CREAL, D.; KOOPMAN, S. J.; LUCAS, A. A. A general framework for observation driven time-varying parameter models. **Tinbergen Institute Discussion**, n. 108, 2008.
- ENGLE, R. F. Autoregressive conditional heteroskedasticity with estimates of the variances of u.k. inflation. **Econometrica**, v. 50, n. 4, p. 987–1008, 1982.
- FIORUCI, J. A. **Modelagem de volatilidade via modelos GARCH com erros assimétricos: abordagem Bayesiana**. Dissertação (Mestrado - Programa de Pós-Graduação em Ciências de Computação e Matemática Computacional) — Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, 2012.
- HAMILTON, J. D. **Time Series Analysis**. [S.l.]: Princeton University Press, 1994.
- HARVEY, A.; CHAKRAVARTY, T. **Beta-t-(E)GARCH**. [S.l.], 2008. Disponível em: <<https://EconPapers.repec.org/RePEc:cam:camdae:0840>>.
- IBOVESPA. **Índice Bovespa (Ibovespa)**. 2018. <http://www.bmfbovespa.com.br/pt_br/produtos/indices/indices-amplos/indice-bovespa-ibovespa.htm>. Acesso em 28 de abril de 2018.
- MANDELBROT, B. The variation of certain speculative prices. **Journal of Business**, v. 36, p. 394–419, 1963.
- MARKOWITZ, H. Portfolio selection. **Journal of Finance**, v. 7, p. 71–91, 1952.
- MORAIS, I. A. C.; PORTUGAL, M. S. Modelagem e previsão de volatilidade determinística e estocástica para a série do ibovespa. **Estudos Econômicos**, São Paulo, SP, v. 29, n. 3, p. 303–341, 1999.
- MORETTIN, P. A. **Econometria Financeira: um curso em séries temporais**. São Paulo: Blucher, 2008.
- MORETTIN, P. A.; TOLOI, C. M. C. **Análise de Séries Temporais**. 2. ed. São Paulo: Blucher, 2006.
- NELSON, D. B. Conditional heteroskedasticity in asset returns: A new approach. **Econometrica**, v. 59, p. 347–370, 1991.
- RABEMANANJARA, R.; ZAKOIAN, J. M. Threshold arch models and asymmetries in volatility. **Journal of Applied Econometrics**, v. 8, p. 31–49, 1993.
- TSAY, R. S. **Analysis of financial time series**. 2. ed. New York: John Wiley & Sons, 2005.

ANEXO A – SINTAXE NO R

```

1 library(fGarch)
2 library("GAS")
3
4 #GARCH
5 #NORMAL
6 set.seed(123456)
7 N=10000
8
9 omegadiff1 <- matrix(ncol=1, nrow=N)
10 alphadiff1 <- matrix(ncol=1, nrow=N)
11 betadiff1 <- matrix(ncol=1, nrow=N)
12 omegadiffquad1 <- matrix(ncol=1, nrow=N)
13 alphadiffquad1 <- matrix(ncol=1, nrow=N)
14 betadiffquad1 <- matrix(ncol=1, nrow=N)
15 volgarch_antes <- matrix(ncol=N, nrow=2000)
16 volgarch_depois <- matrix(ncol=N, nrow=2000)
17 volgas1_depois <- matrix(ncol=N, nrow=2000)
18 diffvolgarch <- matrix(ncol=N, nrow=2000)
19 diffvolgas <- matrix(ncol=N, nrow=2000)
20 diffvolgarchquad <- matrix(ncol=N, nrow=2000)
21 diffvolgasquad <- matrix(ncol=N, nrow=2000)
22 diffvolgarch1 <- matrix(ncol=1, nrow=N)
23 diffvolgas1 <- matrix(ncol=1, nrow=N)
24 diffvolgarchquad1 <- matrix(ncol=1, nrow=N)
25 diffvolgasquad1 <- matrix(ncol=1, nrow=N)
26
27 garchspec1 = garchSpec(model = list(mu = 0, omega = 0.05,
28                                   alpha = 0.1, beta = 0.8), cond.dist=c("norm"))
29 gasspec1 <- UniGASSpec(Dist = "norm", ScalingType = "Identity",
30                       GASPar = list(location = FALSE, scale = TRUE, shape =
31                                   FALSE, skewness = FALSE))
32
33 for (j in 1:N){
34   garchsim1 = garchSim(spec = garchspec1, n = 2100, extended=TRUE)
35   garchfit1 = garchFit(formula = ~ garch(1, 1), data=
36                       garchsim1[101:2100], cond.dist=c("norm"))
37   gasfit1 = UniGASFit(gasspec1, garchsim1[101:2100])
38 }

```

```
37  volgarch_antes[,j] = (garchsim1[101:2100,2])^2
38  volgarch_depois[,j] = garchfit1@h.t
39  volgas1_depois[,j] = gasfit1@Estimates$Moments[1:2000,2]
40
41  for (i in 1:2000){
42    diffvolgarch [i,j] = volgarch_depois[i,j] - volgarch_antes[i,j]
43    diffvolgas [i,j] = volgas1_depois[i,j] - volgarch_antes[i,j]
44    diffvolgarchquad [i,j] = (diffvolgarch [i,j])^2
45    diffvolgasquad [i,j] = (diffvolgas [i,j])^2
46  }
47
48  diffvolgarch1[j] = mean(diffvolgarch[,j])
49  diffvolgas1[j] = mean(diffvolgas[,j])
50  diffvolgarchquad1[j] = mean(diffvolgarchquad[,j])
51  diffvolgasquad1[j] = mean(diffvolgasquad[,j])
52
53  omegadiff1[j] = ((garchfit1@fit$matcoef[2,1])-0.05)
54  alphadiff1[j] = ((garchfit1@fit$matcoef[3,1])-0.1)
55  betadiff1[j] = ((garchfit1@fit$matcoef[4,1])-0.8)
56
57  omegadiffquad1[j] = (omegadiff1[j])^2
58  alphadiffquad1[j] = (alphadiff1[j])^2
59  betadiffquad1[j] = (betadiff1[j])^2
60  print(j)
61 }
62
63 set.seed(123456)
64 N=10000
65
66 omegadiff1 <- matrix(ncol=1, nrow=N)
67 alphadiff1 <- matrix(ncol=1, nrow=N)
68 betadiff1 <- matrix(ncol=1, nrow=N)
69 omegadiffquad1 <- matrix(ncol=1, nrow=N)
70 alphadiffquad1 <- matrix(ncol=1, nrow=N)
71 betadiffquad1 <- matrix(ncol=1, nrow=N)
72 volgarch_antes <- matrix(ncol=N, nrow=1000)
73 volgarch_depois <- matrix(ncol=N, nrow=1000)
74 volgas1_depois <- matrix(ncol=N, nrow=1000)
75 diffvolgarch <- matrix(ncol=N, nrow=1000)
76 diffvolgas <- matrix(ncol=N, nrow=1000)
77 diffvolgarchquad <- matrix(ncol=N, nrow=1000)
78 diffvolgasquad <- matrix(ncol=N, nrow=1000)
```

```
79 diffvolgarch1 <- matrix(ncol=1, nrow=N)
80 diffvolgas1 <- matrix(ncol=1, nrow=N)
81 diffvolgarchquad1 <- matrix(ncol=1, nrow=N)
82 diffvolgasquad1 <- matrix(ncol=1, nrow=N)
83
84 garchspec1 = garchSpec(model = list(mu = 0, omega = 0.05,
85                                     alpha = 0.1, beta = 0.8),cond.dist=c("norm"))
86 gasspec1 <- UniGASSpec(Dist = "norm", ScalingType = "Identity",
87                       GASPar = list(location = FALSE, scale = TRUE, shape =
88                                     FALSE, skewness = FALSE))
89
90 for (j in 1:N){
91   garchsim1 = garchSim(spec = garchspec1, n = 1100, extended=TRUE)
92   garchfit1 = garchFit(formula = ~ garch(1, 1),data=
93                       garchsim1[101:1100],cond.dist=c("norm"))
94   gasfit1 = UniGASFit(gasspec1,garchsim1[101:1100])
95
96   volgarch_antes[,j] = (garchsim1[101:1100,2])^2
97   volgarch_depois[,j] = garchfit1@h.t
98   volgas1_depois[,j] = gasfit1@Estimates$Moments[1:1000,2]
99
100   for (i in 1:1000){
101     diffvolgarch [i,j] = volgarch_depois[i,j] - volgarch_antes[i,j]
102     diffvolgas [i,j] = volgas1_depois[i,j] - volgarch_antes[i,j]
103     diffvolgarchquad [i,j] = (diffvolgarch [i,j])^2
104     diffvolgasquad [i,j] = (diffvolgas [i,j])^2
105   }
106
107   diffvolgarch1[j] = mean(diffvolgarch[,j])
108   diffvolgas1[j] = mean(diffvolgas[,j])
109   diffvolgarchquad1[j] = mean(diffvolgarchquad[,j])
110   diffvolgasquad1[j] = mean(diffvolgasquad[,j])
111
112   omegadiff1[j] = ((garchfit1@fit$matcoef[2,1])-0.05)
113   alphadiff1[j] = ((garchfit1@fit$matcoef[3,1])-0.1)
114   betadiff1[j] = ((garchfit1@fit$matcoef[4,1])-0.8)
115
116   omegadiffquad1[j] = (omegadiff1[j])^2
117   alphadiffquad1[j] = (alphadiff1[j])^2
118   betadiffquad1[j] = (betadiff1[j])^2
119   print(j)
120 }
```

```
119
120
121 set.seed(123456)
122 N=10000
123
124 omegadiff1 <- matrix(ncol=1, nrow=N)
125 alphadiff1 <- matrix(ncol=1, nrow=N)
126 betadiff1 <- matrix(ncol=1, nrow=N)
127 omegadiffquad1 <- matrix(ncol=1, nrow=N)
128 alphadiffquad1 <- matrix(ncol=1, nrow=N)
129 betadiffquad1 <- matrix(ncol=1, nrow=N)
130 volgarch_antes <- matrix(ncol=N, nrow=2000)
131 volgarch_depois <- matrix(ncol=N, nrow=2000)
132 volgas1_depois <- matrix(ncol=N, nrow=2000)
133 diffvolgarch <- matrix(ncol=N, nrow=2000)
134 diffvolgas <- matrix(ncol=N, nrow=2000)
135 diffvolgarchquad <- matrix(ncol=N, nrow=2000)
136 diffvolgasquad <- matrix(ncol=N, nrow=2000)
137 diffvolgarch1 <- matrix(ncol=1, nrow=N)
138 diffvolgas1 <- matrix(ncol=1, nrow=N)
139 diffvolgarchquad1 <- matrix(ncol=1, nrow=N)
140 diffvolgasquad1 <- matrix(ncol=1, nrow=N)
141
142 garchspec1 = garchSpec(model = list(mu = 0, omega = 0.05,
143                                     alpha = 0.1, beta = 0.4), cond.dist=c("norm"))
144 gasspec1 <- UniGASSpec(Dist = "norm", ScalingType = "Identity",
145                       GASPar = list(location = FALSE, scale = TRUE, shape =
146                                     FALSE, skewness = FALSE))
147
148 for (j in 1:N){
149   garchsim1 = garchSim(spec = garchspec1, n = 2100, extended=TRUE)
150   garchfit1 = garchFit(formula = ~ garch(1, 1), data=
151                       garchsim1[101:2100], cond.dist=c("norm"))
152   gasfit1 = UniGASFit(gasspec1, garchsim1[101:2100])
153
154   volgarch_antes[,j] = (garchsim1[101:2100,2])^2
155   volgarch_depois[,j] = garchfit1@h.t
156   volgas1_depois[,j] = gasfit1@Estimates$Moments[1:2000,2]
157
158   for (i in 1:2000){
159     diffvolgarch [i,j] = volgarch_depois[i,j] - volgarch_antes[i,j]
160     diffvolgas [i,j] = volgas1_depois[i,j] - volgarch_antes[i,j]
```



```
159     diffvolgarchquad [i,j] = (diffvolgarch [i,j])^2
160     diffvolgasquad [i,j] = (diffvolgas [i,j])^2
161   }
162
163   diffvolgarch1[j] = mean(diffvolgarch[,j])
164   diffvolgas1[j] = mean(diffvolgas[,j])
165   diffvolgarchquad1[j] = mean(diffvolgarchquad[,j])
166   diffvolgasquad1[j] = mean(diffvolgasquad[,j])
167
168   omegadiff1[j] = ((garchfit1@fit$matcoef[2,1])-0.05)
169   alphadiff1[j] = ((garchfit1@fit$matcoef[3,1])-0.1)
170   betadiff1[j] = ((garchfit1@fit$matcoef[4,1])-0.4)
171
172   omegadiffquad1[j] = (omegadiff1[j])^2
173   alphadiffquad1[j] = (alphadiff1[j])^2
174   betadiffquad1[j] = (betadiff1[j])^2
175   print(j)
176 }
177
178 set.seed(123456)
179 N=10000
180
181 omegadiff1 <- matrix(ncol=1, nrow=N)
182 alphadiff1 <- matrix(ncol=1, nrow=N)
183 betadiff1 <- matrix(ncol=1, nrow=N)
184 omegadiffquad1 <- matrix(ncol=1, nrow=N)
185 alphadiffquad1 <- matrix(ncol=1, nrow=N)
186 betadiffquad1 <- matrix(ncol=1, nrow=N)
187 volgarch_antes <- matrix(ncol=N, nrow=1000)
188 volgarch_depois <- matrix(ncol=N, nrow=1000)
189 volgas1_depois <- matrix(ncol=N, nrow=1000)
190 diffvolgarch <- matrix(ncol=N, nrow=1000)
191 diffvolgas <- matrix(ncol=N, nrow=1000)
192 diffvolgarchquad <- matrix(ncol=N, nrow=1000)
193 diffvolgasquad <- matrix(ncol=N, nrow=1000)
194 diffvolgarch1 <- matrix(ncol=1, nrow=N)
195 diffvolgas1 <- matrix(ncol=1, nrow=N)
196 diffvolgarchquad1 <- matrix(ncol=1, nrow=N)
197 diffvolgasquad1 <- matrix(ncol=1, nrow=N)
198
199 garchspec1 = garchSpec(model = list(mu = 0, omega = 0.05,
200                                   alpha = 0.1, beta = 0.4),cond.dist=c("norm"))
```

```

201 gasspec1 <- UniGASSpec(Dist = "norm", ScalingType = "Identity",
202                       GASPar = list(location = FALSE, scale = TRUE, shape =
                                   FALSE, skewness = FALSE))
203
204 for (j in 1:N){
205   garchsim1 = garchSim(spec = garchspec1, n = 1100, extended=TRUE)
206   garchfit1 = garchFit(formula = ~ garch(1, 1),data=
                       garchsim1[101:1100],cond.dist=c("norm"))
207   gasfit1 = UniGASFit(gasspec1,garchsim1[101:1100])
208
209   volgarch_antes[,j] = (garchsim1[101:1100,2])^2
210   volgarch_depois[,j] = garchfit1@h.t
211   volgas1_depois[,j] = gasfit1@Estimates$Moments[1:1000,2]
212
213   for (i in 1:1000){
214     diffvolgarch [i,j] = volgarch_depois[i,j] - volgarch_antes[i,j]
215     diffvolgas [i,j] = volgas1_depois[i,j] - volgarch_antes[i,j]
216     diffvolgarchquad [i,j] = (diffvolgarch [i,j])^2
217     diffvolgasquad [i,j] = (diffvolgas [i,j])^2
218   }
219
220   diffvolgarch1[j] = mean(diffvolgarch[,j])
221   diffvolgas1[j] = mean(diffvolgas[,j])
222   diffvolgarchquad1[j] = mean(diffvolgarchquad[,j])
223   diffvolgasquad1[j] = mean(diffvolgasquad[,j])
224
225   omegadiff1[j] = ((garchfit1@fit$matcoef[2,1])-0.05)
226   alphadiff1[j] = ((garchfit1@fit$matcoef[3,1])-0.1)
227   betadiff1[j] = ((garchfit1@fit$matcoef[4,1])-0.4)
228
229   omegadiffquad1[j] = (omegadiff1[j])^2
230   alphadiffquad1[j] = (alphadiff1[j])^2
231   betadiffquad1[j] = (betadiff1[j])^2
232   print(j)
233 }
234
235 #GARCH, STD
236
237 set.seed(123456)
238 N=10000
239
240 omegadiff1 <- matrix(ncol=1, nrow=N)

```

```
241 alphadiff1 <- matrix(ncol=1, nrow=N)
242 betadiff1 <- matrix(ncol=1, nrow=N)
243 omegadiffquad1 <- matrix(ncol=1, nrow=N)
244 alphadiffquad1 <- matrix(ncol=1, nrow=N)
245 betadiffquad1 <- matrix(ncol=1, nrow=N)
246 volgarch_antes <- matrix(ncol=N, nrow=2000)
247 volgarch_depois <- matrix(ncol=N, nrow=2000)
248 volgas1_depois <- matrix(ncol=N, nrow=2000)
249 diffvolgarch <- matrix(ncol=N, nrow=2000)
250 diffvolgas <- matrix(ncol=N, nrow=2000)
251 diffvolgarchquad <- matrix(ncol=N, nrow=2000)
252 diffvolgasquad <- matrix(ncol=N, nrow=2000)
253 diffvolgarch1 <- matrix(ncol=1, nrow=N)
254 diffvolgas1 <- matrix(ncol=1, nrow=N)
255 diffvolgarchquad1 <- matrix(ncol=1, nrow=N)
256 diffvolgasquad1 <- matrix(ncol=1, nrow=N)
257
258 garchspec1 = garchSpec(model = list(mu = 0, omega = 0.05,
259                                   alpha = 0.1, beta = 0.8),cond.dist=c("std"))
260 gasspec1 <- UniGASSpec(Dist = "std", ScalingType = "Identity",
261                       GASPar = list(location = FALSE, scale = TRUE, shape =
262                                   FALSE, skewness = FALSE))
263
264 for (j in 1:N){
265   garchsim1 = garchSim(spec = garchspec1, n = 2100, extended=TRUE)
266   garchfit1 = garchFit(formula = ~ garch(1, 1),data=
267                       garchsim1[101:2100],cond.dist=c("std"))
268   gasfit1 = UniGASFit(gasspec1,garchsim1[101:2100])
269
270   volgarch_antes[,j] = (garchsim1[101:2100,2])^2
271   volgarch_depois[,j] = garchfit1@h.t
272   volgas1_depois[,j] = gasfit1@Estimates$Moments[1:2000,2]
273
274   for (i in 1:2000){
275     diffvolgarch [i,j] = volgarch_depois[i,j] - volgarch_antes[i,j]
276     diffvolgas [i,j] = volgas1_depois[i,j] - volgarch_antes[i,j]
277     diffvolgarchquad [i,j] = (diffvolgarch [i,j])^2
278     diffvolgasquad [i,j] = (diffvolgas [i,j])^2
279   }
280
281   diffvolgarch1[j] = mean(diffvolgarch[,j])
282   diffvolgas1[j] = mean(diffvolgas[,j])

```

```
281   diffvolgarchquad1[j] = mean(diffvolgarchquad[,j])
282   diffvolgasquad1[j] = mean(diffvolgasquad[,j])
283
284   omegadiff1[j] = ((garchfit1@fit$matcoef[2,1])-0.05)
285   alphadiff1[j] = ((garchfit1@fit$matcoef[3,1])-0.1)
286   betadiff1[j] = ((garchfit1@fit$matcoef[4,1])-0.8)
287
288   omegadiffquad1[j] = (omegadiff1[j])^2
289   alphadiffquad1[j] = (alphadiff1[j])^2
290   betadiffquad1[j] = (betadiff1[j])^2
291   print(j)
292 }
293
294 set.seed(123456)
295 N=10000
296
297 omegadiff1 <- matrix(ncol=1, nrow=N)
298 alphadiff1 <- matrix(ncol=1, nrow=N)
299 betadiff1 <- matrix(ncol=1, nrow=N)
300 omegadiffquad1 <- matrix(ncol=1, nrow=N)
301 alphadiffquad1 <- matrix(ncol=1, nrow=N)
302 betadiffquad1 <- matrix(ncol=1, nrow=N)
303 volgarch_antes <- matrix(ncol=N, nrow=1000)
304 volgarch_depois <- matrix(ncol=N, nrow=1000)
305 volgas1_depois <- matrix(ncol=N, nrow=1000)
306 diffvolgarch <- matrix(ncol=N, nrow=1000)
307 diffvolgas <- matrix(ncol=N, nrow=1000)
308 diffvolgarchquad <- matrix(ncol=N, nrow=1000)
309 diffvolgasquad <- matrix(ncol=N, nrow=1000)
310 diffvolgarch1 <- matrix(ncol=1, nrow=N)
311 diffvolgas1 <- matrix(ncol=1, nrow=N)
312 diffvolgarchquad1 <- matrix(ncol=1, nrow=N)
313 diffvolgasquad1 <- matrix(ncol=1, nrow=N)
314
315 garchspeg1 = garchSpec(model = list(mu = 0, omega = 0.05,
316                                     alpha = 0.1, beta = 0.8),cond.dist=c("std"))
317 gasspeg1 <- UniGASSpec(Dist = "std", ScalingType = "Identity",
318                       GASPar = list(location = FALSE, scale = TRUE, shape =
319                                     FALSE, skewness = FALSE))
319
320 for (j in 1:N){
321   garchsim1 = garchSim(spec = garchspeg1, n = 1100, extended=TRUE)
```

```
322 garchfit1 = garchFit(formula = ~ garch(1, 1),data=
      garchsim1[101:1100],cond.dist=c("std"))
323 gasfit1 = UniGASFit(gasspec1,garchsim1[101:1100])
324
325 volgarch_antes[,j] = (garchsim1[101:1100,2])^2
326 volgarch_depois[,j] = garchfit1@h.t
327 volgas1_depois[,j] = gasfit1@Estimates$Moments[1:1000,2]
328
329 for (i in 1:1000){
330   diffvolgarch [i,j] = volgarch_depois[i,j] - volgarch_antes[i,j]
331   diffvolgas [i,j] = volgas1_depois[i,j] - volgarch_antes[i,j]
332   diffvolgarchquad [i,j] = (diffvolgarch [i,j])^2
333   diffvolgasquad [i,j] = (diffvolgas [i,j])^2
334 }
335
336 diffvolgarch1[j] = mean(diffvolgarch[,j])
337 diffvolgas1[j] = mean(diffvolgas[,j])
338 diffvolgarchquad1[j] = mean(diffvolgarchquad[,j])
339 diffvolgasquad1[j] = mean(diffvolgasquad[,j])
340
341 omegadiff1[j] = ((garchfit1@fit$matcoef[2,1])-0.05)
342 alphadiff1[j] = ((garchfit1@fit$matcoef[3,1])-0.1)
343 betadiff1[j] = ((garchfit1@fit$matcoef[4,1])-0.8)
344
345 omegadiffquad1[j] = (omegadiff1[j])^2
346 alphadiffquad1[j] = (alphadiff1[j])^2
347 betadiffquad1[j] = (betadiff1[j])^2
348 print(j)
349 }
350
351 set.seed(123456)
352 N=10000
353
354 omegadiff1 <- matrix(ncol=1, nrow=N)
355 alphadiff1 <- matrix(ncol=1, nrow=N)
356 betadiff1 <- matrix(ncol=1, nrow=N)
357 omegadiffquad1 <- matrix(ncol=1, nrow=N)
358 alphadiffquad1 <- matrix(ncol=1, nrow=N)
359 betadiffquad1 <- matrix(ncol=1, nrow=N)
360 volgarch_antes <- matrix(ncol=N, nrow=2000)
361 volgarch_depois <- matrix(ncol=N, nrow=2000)
362 volgas1_depois <- matrix(ncol=N, nrow=2000)
```

```

363 diffvolgarch <- matrix(ncol=N, nrow=2000)
364 diffvolgas <- matrix(ncol=N, nrow=2000)
365 diffvolgarchquad <- matrix(ncol=N, nrow=2000)
366 diffvolgasquad <- matrix(ncol=N, nrow=2000)
367 diffvolgarch1 <- matrix(ncol=1, nrow=N)
368 diffvolgas1 <- matrix(ncol=1, nrow=N)
369 diffvolgarchquad1 <- matrix(ncol=1, nrow=N)
370 diffvolgasquad1 <- matrix(ncol=1, nrow=N)
371
372 garchspec1 = garchSpec(model = list(mu = 0, omega = 0.05,
373                                     alpha = 0.1, beta = 0.4),cond.dist=c("std"))
374 gasspec1 <- UniGASSpec(Dist = "std", ScalingType = "Identity",
375                        GASPar = list(location = FALSE, scale = TRUE, shape =
376                                     FALSE, skewness = FALSE))
377
377 for (j in 1:N){
378   garchsim1 = garchSim(spec = garchspec1, n = 2100, extended=TRUE)
379   garchfit1 = garchFit(formula = ~ garch(1, 1),data=
380                       garchsim1[101:2100],cond.dist=c("std"))
381   gasfit1 = UniGASFIT(gasspec1,garchsim1[101:2100])
382   volgarch_antes[,j] = (garchsim1[101:2100,2])^2
383   volgarch_depois[,j] = garchfit1@h.t
384   volgas1_depois[,j] = gasfit1@Estimates$Moments[1:2000,2]
385
386   for (i in 1:2000){
387     diffvolgarch [i,j] = volgarch_depois[i,j] - volgarch_antes[i,j]
388     diffvolgas [i,j] = volgas1_depois[i,j] - volgarch_antes[i,j]
389     diffvolgarchquad [i,j] = (diffvolgarch [i,j])^2
390     diffvolgasquad [i,j] = (diffvolgas [i,j])^2
391   }
392
393   diffvolgarch1[j] = mean(diffvolgarch[,j])
394   diffvolgas1[j] = mean(diffvolgas[,j])
395   diffvolgarchquad1[j] = mean(diffvolgarchquad[,j])
396   diffvolgasquad1[j] = mean(diffvolgasquad[,j])
397
398   omegadiff1[j] = ((garchfit1@fit$matcoef[2,1])-0.05)
399   alphadiff1[j] = ((garchfit1@fit$matcoef[3,1])-0.1)
400   betadiff1[j] = ((garchfit1@fit$matcoef[4,1])-0.4)
401
402   omegadiffquad1[j] = (omegadiff1[j])^2

```

```
403   alphadiffquad1[j] = (alphadiff1[j])^2
404   betadiffquad1[j] = (betadiff1[j])^2
405   print(j)
406 }
407
408 set.seed(123456)
409 N=10000
410
411 omegadiff1 <- matrix(ncol=1, nrow=N)
412 alphadiff1 <- matrix(ncol=1, nrow=N)
413 betadiff1 <- matrix(ncol=1, nrow=N)
414 omegadiffquad1 <- matrix(ncol=1, nrow=N)
415 alphadiffquad1 <- matrix(ncol=1, nrow=N)
416 betadiffquad1 <- matrix(ncol=1, nrow=N)
417 volgarch_antes <- matrix(ncol=N, nrow=1000)
418 volgarch_depois <- matrix(ncol=N, nrow=1000)
419 volgas1_depois <- matrix(ncol=N, nrow=1000)
420 diffvolgarch <- matrix(ncol=N, nrow=1000)
421 diffvolgas <- matrix(ncol=N, nrow=1000)
422 diffvolgarchquad <- matrix(ncol=N, nrow=1000)
423 diffvolgasquad <- matrix(ncol=N, nrow=1000)
424 diffvolgarch1 <- matrix(ncol=1, nrow=N)
425 diffvolgas1 <- matrix(ncol=1, nrow=N)
426 diffvolgarchquad1 <- matrix(ncol=1, nrow=N)
427 diffvolgasquad1 <- matrix(ncol=1, nrow=N)
428
429 garchspec1 = garchSpec(model = list(mu = 0, omega = 0.05,
430                                   alpha = 0.1, beta = 0.4), cond.dist=c("std"))
431 gasspec1 <- UniGASSpec(Dist = "std", ScalingType = "Identity",
432                      GASPar = list(location = FALSE, scale = TRUE, shape =
433                                   FALSE, skewness = FALSE))
434
435 for (j in 1:N){
436   garchsim1 = garchSim(spec = garchspec1, n = 1100, extended=TRUE)
437   garchfit1 = garchFit(formula = ~ garch(1, 1), data=
438                       garchsim1[101:1100], cond.dist=c("std"))
439   gasfit1 = UniGASFit(gasspec1, garchsim1[101:1100])
440
441   volgarch_antes[,j] = (garchsim1[101:1100,2])^2
442   volgarch_depois[,j] = garchfit1@h.t
443   volgas1_depois[,j] = gasfit1@Estimates$Moments[1:1000,2]
```

```
443   for (i in 1:1000){
444     diffvolgarch [i,j] = volgarch_depois[i,j] - volgarch_antes[i,j]
445     diffvolgas [i,j] = volgas1_depois[i,j] - volgarch_antes[i,j]
446     diffvolgarchquad [i,j] = (diffvolgarch [i,j])^2
447     diffvolgasquad [i,j] = (diffvolgas [i,j])^2
448   }
449
450   diffvolgarch1[j] = mean(diffvolgarch[,j])
451   diffvolgas1[j] = mean(diffvolgas[,j])
452   diffvolgarchquad1[j] = mean(diffvolgarchquad[,j])
453   diffvolgasquad1[j] = mean(diffvolgasquad[,j])
454
455   omegadiff1[j] = ((garchfit1@fit$matcoef[2,1])-0.05)
456   alphadiff1[j] = ((garchfit1@fit$matcoef[3,1])-0.1)
457   betadiff1[j] = ((garchfit1@fit$matcoef[4,1])-0.4)
458
459   omegadiffquad1[j] = (omegadiff1[j])^2
460   alphadiffquad1[j] = (alphadiff1[j])^2
461   betadiffquad1[j] = (betadiff1[j])^2
462   print(j)
463 }
464
465 #GARCH SSTD
466
467 set.seed(123456)
468 N=10000
469
470 omegadiff1 <- matrix(ncol=1, nrow=N)
471 alphadiff1 <- matrix(ncol=1, nrow=N)
472 betadiff1 <- matrix(ncol=1, nrow=N)
473 omegadiffquad1 <- matrix(ncol=1, nrow=N)
474 alphadiffquad1 <- matrix(ncol=1, nrow=N)
475 betadiffquad1 <- matrix(ncol=1, nrow=N)
476 volgarch_antes <- matrix(ncol=N, nrow=2000)
477 volgarch_depois <- matrix(ncol=N, nrow=2000)
478 volgas1_depois <- matrix(ncol=N, nrow=2000)
479 diffvolgarch <- matrix(ncol=N, nrow=2000)
480 diffvolgas <- matrix(ncol=N, nrow=2000)
481 diffvolgarchquad <- matrix(ncol=N, nrow=2000)
482 diffvolgasquad <- matrix(ncol=N, nrow=2000)
483 diffvolgarch1 <- matrix(ncol=1, nrow=N)
484 diffvolgas1 <- matrix(ncol=1, nrow=N)
```



```
485 diffvolgarchquad1 <- matrix(ncol=1, nrow=N)
486 diffvolgasquad1 <- matrix(ncol=1, nrow=N)
487
488 garchspec1 = garchSpec(model = list(mu = 0, omega = 0.05,
489                                     alpha = 0.1, beta = 0.8),cond.dist=c("sstd"))
490 gasspec1 <- UniGASSpec(Dist = "sstd", ScalingType = "Identity",
491                       GASPar = list(location = FALSE, scale = TRUE, shape =
492                                     FALSE, skewness = FALSE))
493
494 for (j in 1:N){
495   garchsim1 = garchSim(spec = garchspec1, n = 2100, extended=TRUE)
496   garchfit1 = garchFit(formula = ~ garch(1, 1),data=
497                       garchsim1[101:2100],cond.dist=c("sstd"))
498   gasfit1 = UniGASFit(gasspec1,garchsim1[101:2100])
499
500   volgarch_antes[,j] = (garchsim1[101:2100,2])^2
501   volgarch_depois[,j] = garchfit1@h.t
502   volgas1_depois[,j] = gasfit1@Estimates$Moments[1:2000,2]
503
504   for (i in 1:2000){
505     diffvolgarch [i,j] = volgarch_depois[i,j] - volgarch_antes[i,j]
506     diffvolgas [i,j] = volgas1_depois[i,j] - volgarch_antes[i,j]
507     diffvolgarchquad [i,j] = (diffvolgarch [i,j])^2
508     diffvolgasquad [i,j] = (diffvolgas [i,j])^2
509   }
510
511   diffvolgarch1[j] = mean(diffvolgarch[,j])
512   diffvolgas1[j] = mean(diffvolgas[,j])
513   diffvolgarchquad1[j] = mean(diffvolgarchquad[,j])
514   diffvolgasquad1[j] = mean(diffvolgasquad[,j])
515
516   omegadiff1[j] = ((garchfit1@fit$matcoef[2,1])-0.05)
517   alphadiff1[j] = ((garchfit1@fit$matcoef[3,1])-0.1)
518   betadiff1[j] = ((garchfit1@fit$matcoef[4,1])-0.8)
519
520   omegadiffquad1[j] = (omegadiff1[j])^2
521   alphadiffquad1[j] = (alphadiff1[j])^2
522   betadiffquad1[j] = (betadiff1[j])^2
523   print(j)
524 }
525
526 set.seed(123456)
```

```
525 N=10000
526
527 omegadiff1 <- matrix(ncol=1, nrow=N)
528 alphadiff1 <- matrix(ncol=1, nrow=N)
529 betadiff1 <- matrix(ncol=1, nrow=N)
530 omegadiffquad1 <- matrix(ncol=1, nrow=N)
531 alphadiffquad1 <- matrix(ncol=1, nrow=N)
532 betadiffquad1 <- matrix(ncol=1, nrow=N)
533 volgarch_antes <- matrix(ncol=N, nrow=1000)
534 volgarch_depois <- matrix(ncol=N, nrow=1000)
535 volgas1_depois <- matrix(ncol=N, nrow=1000)
536 diffvolgarch <- matrix(ncol=N, nrow=1000)
537 diffvolgas <- matrix(ncol=N, nrow=1000)
538 diffvolgarchquad <- matrix(ncol=N, nrow=1000)
539 diffvolgasquad <- matrix(ncol=N, nrow=1000)
540 diffvolgarch1 <- matrix(ncol=1, nrow=N)
541 diffvolgas1 <- matrix(ncol=1, nrow=N)
542 diffvolgarchquad1 <- matrix(ncol=1, nrow=N)
543 diffvolgasquad1 <- matrix(ncol=1, nrow=N)
544
545 garchspec1 = garchSpec(model = list(mu = 0, omega = 0.05,
546                                     alpha = 0.1, beta = 0.8),cond.dist=c("sstd"))
547 gasspec1 <- UniGASSpec(Dist = "sstd", ScalingType = "Identity",
548                       GASPar = list(location = FALSE, scale = TRUE, shape =
549                                     FALSE, skewness = FALSE))
550
551 for (j in 1:N){
552   garchsim1 = garchSim(spec = garchspec1, n = 1100, extended=TRUE)
553   garchfit1 = garchFit(formula = ~ garch(1, 1),data=
554                       garchsim1[101:1100],cond.dist=c("sstd"))
555   gasfit1 = UniGASFit(gasspec1,garchsim1[101:1100])
556
557   volgarch_antes[,j] = (garchsim1[101:1100,2])^2
558   volgarch_depois[,j] = garchfit1@h.t
559   volgas1_depois[,j] = gasfit1@Estimates$Moments[1:1000,2]
560
561   for (i in 1:1000){
562     diffvolgarch [i,j] = volgarch_depois[i,j] - volgarch_antes[i,j]
563     diffvolgas [i,j] = volgas1_depois[i,j] - volgarch_antes[i,j]
564     diffvolgarchquad [i,j] = (diffvolgarch [i,j])^2
565     diffvolgasquad [i,j] = (diffvolgas [i,j])^2
566   }
567 }
```



```
606
607 for (j in 1:N){
608   garchsim1 = garchSim(spec = garchspeg1, n = 2100, extended=TRUE)
609   garchfit1 = garchFit(formula = ~ garch(1, 1), data=
        garchsim1[101:2100], cond.dist=c("sstd"))
610   gasfit1 = UniGASFit(gasspeg1, garchsim1[101:2100])
611
612   volgarch_antes[,j] = (garchsim1[101:2100,2])^2
613   volgarch_depois[,j] = garchfit1@h.t
614   volgas1_depois[,j] = gasfit1@Estimates$Moments[1:2000,2]
615
616   for (i in 1:2000){
617     diffvolgarch [i,j] = volgarch_depois[i,j] - volgarch_antes[i,j]
618     diffvolgas [i,j] = volgas1_depois[i,j] - volgarch_antes[i,j]
619     diffvolgarchquad [i,j] = (diffvolgarch [i,j])^2
620     diffvolgasquad [i,j] = (diffvolgas [i,j])^2
621   }
622
623   diffvolgarch1[j] = mean(diffvolgarch[,j])
624   diffvolgas1[j] = mean(diffvolgas[,j])
625   diffvolgarchquad1[j] = mean(diffvolgarchquad[,j])
626   diffvolgasquad1[j] = mean(diffvolgasquad[,j])
627
628   omegadiff1[j] = ((garchfit1@fit$matcoef[2,1])-0.05)
629   alphadiff1[j] = ((garchfit1@fit$matcoef[3,1])-0.1)
630   betadiff1[j] = ((garchfit1@fit$matcoef[4,1])-0.4)
631
632   omegadiffquad1[j] = (omegadiff1[j])^2
633   alphadiffquad1[j] = (alphadiff1[j])^2
634   betadiffquad1[j] = (betadiff1[j])^2
635   print(j)
636 }
637
638 set.seed(123456)
639 N=10000
640
641 omegadiff1 <- matrix(ncol=1, nrow=N)
642 alphadiff1 <- matrix(ncol=1, nrow=N)
643 betadiff1 <- matrix(ncol=1, nrow=N)
644 omegadiffquad1 <- matrix(ncol=1, nrow=N)
645 alphadiffquad1 <- matrix(ncol=1, nrow=N)
646 betadiffquad1 <- matrix(ncol=1, nrow=N)
```

```
647 volgarch_antes <- matrix(ncol=N, nrow=1000)
648 volgarch_depois <- matrix(ncol=N, nrow=1000)
649 volgas1_depois <- matrix(ncol=N, nrow=1000)
650 diffvolgarch <- matrix(ncol=N, nrow=1000)
651 diffvolgas <- matrix(ncol=N, nrow=1000)
652 diffvolgarchquad <- matrix(ncol=N, nrow=1000)
653 diffvolgasquad <- matrix(ncol=N, nrow=1000)
654 diffvolgarch1 <- matrix(ncol=1, nrow=N)
655 diffvolgas1 <- matrix(ncol=1, nrow=N)
656 diffvolgarchquad1 <- matrix(ncol=1, nrow=N)
657 diffvolgasquad1 <- matrix(ncol=1, nrow=N)
658
659 garchspec1 = garchSpec(model = list(mu = 0, omega = 0.05,
660                                     alpha = 0.1, beta = 0.4),cond.dist=c("sstd"))
661 gasspec1 <- UniGASSpec(Dist = "sstd", ScalingType = "Identity",
662                       GASPar = list(location = FALSE, scale = TRUE, shape =
663                                     FALSE, skewness = FALSE))
664
665 for (j in 1:N){
666   garchsim1 = garchSim(spec = garchspec1, n = 1100, extended=TRUE)
667   garchfit1 = garchFit(formula = ~ garch(1, 1),data=
668                       garchsim1[101:1100],cond.dist=c("sstd"))
669   gasfit1 = UniGASFit(gasspec1,garchsim1[101:1100])
670
671   volgarch_antes[,j] = (garchsim1[101:1100,2])^2
672   volgarch_depois[,j] = garchfit1@h.t
673   volgas1_depois[,j] = gasfit1@Estimates$Moments[1:1000,2]
674
675   for (i in 1:1000){
676     diffvolgarch [i,j] = volgarch_depois[i,j] - volgarch_antes[i,j]
677     diffvolgas [i,j] = volgas1_depois[i,j] - volgarch_antes[i,j]
678     diffvolgarchquad [i,j] = (diffvolgarch [i,j])^2
679     diffvolgasquad [i,j] = (diffvolgas [i,j])^2
680   }
681
682   diffvolgarch1[j] = mean(diffvolgarch[,j])
683   diffvolgas1[j] = mean(diffvolgas[,j])
684   diffvolgarchquad1[j] = mean(diffvolgarchquad[,j])
685   diffvolgasquad1[j] = mean(diffvolgasquad[,j])
686
687   omegadiff1[j] = ((garchfit1@fit$matcoef[2,1])-0.05)
688   alphadiff1[j] = ((garchfit1@fit$matcoef[3,1])-0.1)
```

```
687   betadiff1[j] = ((garchfit1@fit$matcoef[4,1])-0.4)
688
689   omegadiffquad1[j] = (omegadiff1[j])^2
690   alphadiffquad1[j] = (alphadiff1[j])^2
691   betadiffquad1[j] = (betadiff1[j])^2
692   print(j)
693 }
694
695 #GAS STD
696
697 set.seed(123456)
698 N=10000
699
700 kappadiff1 <- matrix(ncol=1, nrow=N)
701 kappadiff2 <- matrix(ncol=1, nrow=N)
702 kappadiff3 <- matrix(ncol=1, nrow=N)
703 alfadiff1 <- matrix(ncol=1, nrow=N)
704 betadiff1 <- matrix(ncol=1, nrow=N)
705 kappadiffquad1 <- matrix(ncol=1, nrow=N)
706 kappadiffquad2 <- matrix(ncol=1, nrow=N)
707 kappadiffquad3 <- matrix(ncol=1, nrow=N)
708 alfadiffquad1 <- matrix(ncol=1, nrow=N)
709 betadiffquad1 <- matrix(ncol=1, nrow=N)
710 volgas_antes <- matrix(ncol=N, nrow=1000)
711 volgarch_depois <- matrix(ncol=N, nrow=1000)
712 volgas1_depois <- matrix(ncol=N, nrow=1000)
713 diffvolgarch <- matrix(ncol=N, nrow=1000)
714 diffvolgas <- matrix(ncol=N, nrow=1000)
715 diffvolgarchquad <- matrix(ncol=N, nrow=1000)
716 diffvolgasquad <- matrix(ncol=N, nrow=1000)
717 diffvolgarch1 <- matrix(ncol=1, nrow=N)
718 diffvolgas1 <- matrix(ncol=1, nrow=N)
719 diffvolgarchquad1 <- matrix(ncol=1, nrow=N)
720 diffvolgasquad1 <- matrix(ncol=1, nrow=N)
721
722 gasspec2 <- UniGASSpec(Dist = "std", ScalingType = "Identity",
723                       GASPar = list(location = FALSE, scale = TRUE, shape =
724                                     FALSE))
725 Kappa = c(0.0, -0.05005906, 4)
726 A = matrix(c(0.0 , 0.0 , 0.0 ,
727             0.0 , 0.13494830 , 0.0 ,
728             0.0 , 0.0 , 0.0 ), 3, byrow = TRUE)
```

```

728 B = matrix(c(0.0 , 0.0 , 0.0 ,
729             0.0 , 0.93925037, 0.0 ,
730             0.0 , 0.0 , 0.0),3,byrow = TRUE)
731 for (j in 1:N){
732   gassim2 <- UniGASSim(T.sim = 1100, kappa = Kappa,
733                      A = A, B = B, Dist = "std", ScalingType = "Identity")
734   x <-(getObs(gassim2))
735   gasfit2 = UniGASFit(gasspec2, x[101:1100])
736   garchfit2 = garchFit(formula = ~ garch(1, 1),data=
737                       x[101:1100],cond.dist=c("std"))
737   volgas_antes[,j] = gassim2@Data$Moments[101:1100,2]
738   volgarch_depois[,j] = garchfit2@h.t
739   volgas1_depois[,j] = gasfit2@Estimates$Moments[1:1000,2]
740
741   for (i in 1:1000){
742     diffvolgarch [i,j] = volgarch_depois[i,j] - volgas_antes[i,j]
743     diffvolgas [i,j] = volgas1_depois[i,j] - volgas_antes[i,j]
744     diffvolgarchquad [i,j] = (diffvolgarch [i,j])^2
745     diffvolgasquad [i,j] = (diffvolgas [i,j])^2
746   }
747
748   diffvolgarch1[j] = mean(diffvolgarch[,j])
749   diffvolgas1[j] = mean(diffvolgas[,j])
750   diffvolgarchquad1[j] = mean(diffvolgarchquad[,j])
751   diffvolgasquad1[j] = mean(diffvolgasquad[,j])
752
753   kappadiff1[j] = ((gasfit2@Estimates$lParList$vKappa[1]))
754   kappadiff2[j] = (-0.05005906-(gasfit2@Estimates$lParList$vKappa[2]))
755   kappadiff3[j] = ((gasfit2@Estimates$lParList$vKappa[3])-4)
756   alfadiff1[j] = ((gasfit2@Estimates$lParList$mA[2,2])-0.13494830)
757   betadiff1[j] = ((gasfit2@Estimates$lParList$mB[2,2])-0.93925037)
758
759   kappadiffquad1[j] = (kappadiff1[j])^2
760   kappadiffquad2[j] = (kappadiff2[j])^2
761   kappadiffquad3[j] = (kappadiff3[j])^2
762   alfadiffquad1[j] = (alfadiff1[j])^2
763   betadiffquad1[j] = (betadiff1[j])^2
764 }
765
766 set.seed(123456)
767 N=10000
768

```

```
769 kappadiff1 <- matrix(ncol=1, nrow=N)
770 kappadiff2 <- matrix(ncol=1, nrow=N)
771 kappadiff3 <- matrix(ncol=1, nrow=N)
772 alfadiff1 <- matrix(ncol=1, nrow=N)
773 betadiff1 <- matrix(ncol=1, nrow=N)
774 kappadiffquad1 <- matrix(ncol=1, nrow=N)
775 kappadiffquad2 <- matrix(ncol=1, nrow=N)
776 kappadiffquad3 <- matrix(ncol=1, nrow=N)
777 alfadiffquad1 <- matrix(ncol=1, nrow=N)
778 betadiffquad1 <- matrix(ncol=1, nrow=N)
779 volgas_antes <- matrix(ncol=N, nrow=2000)
780 volgarch_depois <- matrix(ncol=N, nrow=2000)
781 volgas1_depois <- matrix(ncol=N, nrow=2000)
782 diffvolgarch <- matrix(ncol=N, nrow=2000)
783 diffvolgas <- matrix(ncol=N, nrow=2000)
784 diffvolgarchquad <- matrix(ncol=N, nrow=2000)
785 diffvolgasquad <- matrix(ncol=N, nrow=2000)
786 diffvolgarch1 <- matrix(ncol=1, nrow=N)
787 diffvolgas1 <- matrix(ncol=1, nrow=N)
788 diffvolgarchquad1 <- matrix(ncol=1, nrow=N)
789 diffvolgasquad1 <- matrix(ncol=1, nrow=N)
790
791 gasspec2 <- UniGASSpec(Dist = "std", ScalingType = "Identity",
792                       GASPar = list(location = FALSE, scale = TRUE, shape =
793                                     FALSE))
794 Kappa = c(0.0, -0.05005906, 4)
795 A = matrix(c(0.0 , 0.0 , 0.0 ,
796             0.0 , 0.13494830 , 0.0 ,
797             0.0 , 0.0 , 0.0 ), 3, byrow = TRUE)
798 B = matrix(c(0.0 , 0.0 , 0.0 ,
799             0.0 , 0.93925037, 0.0 ,
800             0.0 , 0.0 , 0.0),3,byrow = TRUE)
801 for (j in 1:N){
802   gassim2 <- UniGASSim(T.sim = 2100, kappa = Kappa,
803                       A = A, B = B, Dist = "std", ScalingType = "Identity")
804   x <- (getObs(gassim2))
805   gasfit2 = UniGASFit(gasspec2, x[101:2100])
806   garchfit2 = garchFit(formula = ~ garch(1, 1), data=
807                       x[101:2100], cond.dist=c("std"))
808   volgas_antes[,j] = gassim2@Data$Moments[101:2100,2]
809   volgarch_depois[,j] = garchfit2@h.t
810   volgas1_depois[,j] = gasfit2@Estimates$Moments[1:2000,2]
```



```
809
810   for (i in 1:2000){
811     diffvolgarch [i,j] = volgarch_depois[i,j] - volgas_antes[i,j]
812     diffvolgas [i,j] = volgas1_depois[i,j] - volgas_antes[i,j]
813     diffvolgarchquad [i,j] = (diffvolgarch [i,j])^2
814     diffvolgasquad [i,j] = (diffvolgas [i,j])^2
815   }
816
817   diffvolgarch1[j] = mean(diffvolgarch[,j])
818   diffvolgas1[j] = mean(diffvolgas[,j])
819   diffvolgarchquad1[j] = mean(diffvolgarchquad[,j])
820   diffvolgasquad1[j] = mean(diffvolgasquad[,j])
821
822   kappadiff1[j] = ((gasfit2@Estimates$1ParList$vKappa[1]))
823   kappadiff2[j] = (-0.05005906-(gasfit2@Estimates$1ParList$vKappa[2]))
824   kappadiff3[j] = ((gasfit2@Estimates$1ParList$vKappa[3])-4)
825   alfadiff1[j] = ((gasfit2@Estimates$1ParList$mA[2,2])-0.13494830)
826   betadiff1[j] = ((gasfit2@Estimates$1ParList$mB[2,2])-0.93925037)
827
828   kappadiffquad1[j] = (kappadiff1[j])^2
829   kappadiffquad2[j] = (kappadiff2[j])^2
830   kappadiffquad3[j] = (kappadiff3[j])^2
831   alfadiffquad1[j] = (alfadiff1[j])^2
832   betadiffquad1[j] = (betadiff1[j])^2
833 }
834
835 set.seed(123456)
836 N=10000
837
838 kappadiff1 <- matrix(ncol=1, nrow=N)
839 kappadiff2 <- matrix(ncol=1, nrow=N)
840 kappadiff3 <- matrix(ncol=1, nrow=N)
841 alfadiff1 <- matrix(ncol=1, nrow=N)
842 betadiff1 <- matrix(ncol=1, nrow=N)
843 kappadiffquad1 <- matrix(ncol=1, nrow=N)
844 kappadiffquad2 <- matrix(ncol=1, nrow=N)
845 kappadiffquad3 <- matrix(ncol=1, nrow=N)
846 alfadiffquad1 <- matrix(ncol=1, nrow=N)
847 betadiffquad1 <- matrix(ncol=1, nrow=N)
848 volgas_antes <- matrix(ncol=N, nrow=1000)
849 volgarch_depois <- matrix(ncol=N, nrow=1000)
850 volgas1_depois <- matrix(ncol=N, nrow=1000)
```

```
851 diffvolgarch <- matrix(ncol=N, nrow=1000)
852 diffvolgas <- matrix(ncol=N, nrow=1000)
853 diffvolgarchquad <- matrix(ncol=N, nrow=1000)
854 diffvolgasquad <- matrix(ncol=N, nrow=1000)
855 diffvolgarch1 <- matrix(ncol=1, nrow=N)
856 diffvolgas1 <- matrix(ncol=1, nrow=N)
857 diffvolgarchquad1 <- matrix(ncol=1, nrow=N)
858 diffvolgasquad1 <- matrix(ncol=1, nrow=N)
859
860 gasspec2 <- UniGASSpec(Dist = "std", ScalingType = "Identity",
861                       GASPar = list(location = FALSE, scale = TRUE, shape =
862                                     FALSE))
863 Kappa = c(0.0, -1.605338101, 4)
864 A = matrix(c(0.0 , 0.0 , 0.0 ,
865             0.0 , 0.263276305 , 0.0 ,
866             0.0 , 0.0 , 0.0 ), 3, byrow = TRUE)
867 B = matrix(c(0.0 , 0.0 , 0.0 ,
868             0.0 , 0.477207899, 0.0 ,
869             0.0 , 0.0 , 0.0),3,byrow = TRUE)
870 for (j in 1:N){
871   gassim2 <- UniGASSim(T.sim = 1100, kappa = Kappa,
872                       A = A, B = B, Dist = "std", ScalingType = "Identity")
873   x <- (getObs(gassim2))
874   gasfit2 = UniGASFit(gasspec2, x[101:1100])
875   garchfit2 = garchFit(formula = ~ garch(1, 1), data=
876                       x[101:1100], cond.dist=c("std"))
877   volgas_antes[,j] = gassim2@Data$Moments[101:1100,2]
878   volgarch_depois[,j] = garchfit2@h.t
879   volgas1_depois[,j] = gasfit2@Estimates$Moments[1:1000,2]
880
881   for (i in 1:1000){
882     diffvolgarch [i,j] = volgarch_depois[i,j] - volgas_antes[i,j]
883     diffvolgas [i,j] = volgas1_depois[i,j] - volgas_antes[i,j]
884     diffvolgarchquad [i,j] = (diffvolgarch [i,j])^2
885     diffvolgasquad [i,j] = (diffvolgas [i,j])^2
886   }
887
888   diffvolgarch1[j] = mean(diffvolgarch[,j])
889   diffvolgas1[j] = mean(diffvolgas[,j])
890   diffvolgarchquad1[j] = mean(diffvolgarchquad[,j])
891   diffvolgasquad1[j] = mean(diffvolgasquad[,j])
892 }
```

```
891 kappadiff1[j] = ((gasfit2@Estimates$lParList$vKappa[1]))
892 kappadiff2[j] = (-1.605338101-(gasfit2@Estimates$lParList$vKappa[2]))
893 kappadiff3[j] = ((gasfit2@Estimates$lParList$vKappa[3])-4)
894 alfadiff1[j] = ((gasfit2@Estimates$lParList$mA[2,2])-0.263276305)
895 betadiff1[j] = ((gasfit2@Estimates$lParList$mB[2,2])-0.477207899)
896
897 kappadiffquad1[j] = (kappadiff1[j])^2
898 kappadiffquad2[j] = (kappadiff2[j])^2
899 kappadiffquad3[j] = (kappadiff3[j])^2
900 alfadiffquad1[j] = (alfadiff1[j])^2
901 betadiffquad1[j] = (betadiff1[j])^2
902 }
903
904 set.seed(123456)
905 N=10000
906
907 kappadiff1 <- matrix(ncol=1, nrow=N)
908 kappadiff2 <- matrix(ncol=1, nrow=N)
909 kappadiff3 <- matrix(ncol=1, nrow=N)
910 alfadiff1 <- matrix(ncol=1, nrow=N)
911 betadiff1 <- matrix(ncol=1, nrow=N)
912 kappadiffquad1 <- matrix(ncol=1, nrow=N)
913 kappadiffquad2 <- matrix(ncol=1, nrow=N)
914 kappadiffquad3 <- matrix(ncol=1, nrow=N)
915 alfadiffquad1 <- matrix(ncol=1, nrow=N)
916 betadiffquad1 <- matrix(ncol=1, nrow=N)
917 volgas_antes <- matrix(ncol=N, nrow=2000)
918 volgarch_depois <- matrix(ncol=N, nrow=2000)
919 volgas1_depois <- matrix(ncol=N, nrow=2000)
920 diffvolgarch <- matrix(ncol=N, nrow=2000)
921 diffvolgas <- matrix(ncol=N, nrow=2000)
922 diffvolgarchquad <- matrix(ncol=N, nrow=2000)
923 diffvolgasquad <- matrix(ncol=N, nrow=2000)
924 diffvolgarch1 <- matrix(ncol=1, nrow=N)
925 diffvolgas1 <- matrix(ncol=1, nrow=N)
926 diffvolgarchquad1 <- matrix(ncol=1, nrow=N)
927 diffvolgasquad1 <- matrix(ncol=1, nrow=N)
928
929 gasspec2 <- UniGASSpec(Dist = "std", ScalingType = "Identity",
930                       GASPar = list(location = FALSE, scale = TRUE, shape =
931                                     FALSE))
932 Kappa = c(0.0, -1.605338101, 4)
```

```

932 A = matrix(c(0.0 , 0.0 , 0.0 ,
933             0.0 , 0.263276305 , 0.0 ,
934             0.0 , 0.0 , 0.0 ), 3, byrow = TRUE)
935 B = matrix(c(0.0 , 0.0 , 0.0 ,
936             0.0 , 0.477207899, 0.0 ,
937             0.0 , 0.0 , 0.0),3,byrow = TRUE)
938 for (j in 1:N){
939   gassim2 <- UniGASSim(T.sim = 2100, kappa = Kappa,
940                     A = A, B = B, Dist = "std", ScalingType = "Identity")
941   x <-(getObs(gassim2))
942   gasfit2 = UniGASFit(gasspec2, x[101:2100])
943   garchfit2 = garchFit(formula = ~ garch(1, 1),data=
944                       x[101:2100],cond.dist=c("std"))
945   volgas_antes[,j] = gassim2@Data$Moments[101:2100,2]
946   volgarch_depois[,j] = garchfit2@h.t
947   volgas1_depois[,j] = gasfit2@Estimates$Moments[1:2000,2]
948   for (i in 1:2000){
949     diffvolgarch [i,j] = volgarch_depois[i,j] - volgas_antes[i,j]
950     diffvolgas [i,j] = volgas1_depois[i,j] - volgas_antes[i,j]
951     diffvolgarchquad [i,j] = (diffvolgarch [i,j])^2
952     diffvolgasquad [i,j] = (diffvolgas [i,j])^2
953   }
954
955   diffvolgarch1[j] = mean(diffvolgarch[,j])
956   diffvolgas1[j] = mean(diffvolgas[,j])
957   diffvolgarchquad1[j] = mean(diffvolgarchquad[,j])
958   diffvolgasquad1[j] = mean(diffvolgasquad[,j])
959
960   kappadiff1[j] = ((gasfit2@Estimates$lParList$vKappa[1]))
961   kappadiff2[j] = (-1.605338101-(gasfit2@Estimates$lParList$vKappa[2]))
962   kappadiff3[j] = ((gasfit2@Estimates$lParList$vKappa[3])-4)
963   alfadiff1[j] = ((gasfit2@Estimates$lParList$mA[2,2])-0.13494830)
964   betadiff1[j] = ((gasfit2@Estimates$lParList$mB[2,2])-0.93925037)
965
966   kappadiffquad1[j] = (kappadiff1[j])^2
967   kappadiffquad2[j] = (kappadiff2[j])^2
968   kappadiffquad3[j] = (kappadiff3[j])^2
969   alfadiffquad1[j] = (alfadiff1[j])^2
970   betadiffquad1[j] = (betadiff1[j])^2
971 }
972

```

```
973 #IBOVESPA
974
975 library(quantmod)
976 library(tawny)
977 library(tseries)
978 library(ggplot2)
979
980 pbr <- getSymbols("^BVSP", src = "yahoo", from = "2010-01-01", to =
      "2018-05-21", auto.assign = FALSE)
981 pbr2 <- na.omit(pbr) #retira NA's
982 diffibv2<-diff(log(pbr2)) #calcula retornos
983 pbr3 <- na.omit(diffibv2)
984 x <- pbr3$BVSP.Close
985 summary(x)
986 curtose <- function(y){
987   mean((y- mean(y))^4 / sd(y)^4)
988 }
989
990 curtose(x)
991
992 garchfit1 = garchFit(formula = ~ garch(1, 1), data= x,cond.dist=c("norm"))
993 gasspec1 <- UniGASSpec(Dist = "norm", ScalingType = "Identity",
994                       GASPar = list(location = FALSE, scale = TRUE,
995                                     shape = FALSE, skewness = FALSE))
996 gasfit1 = UniGASFit(gasspec1,data=x)
997 volgarch_depois = garchfit1@sigma.t
998 volgas1_depois = gasfit1@Estimates$Moments[,2]
999 volgarch_depois = garchfit2@h.t
1000 aic_garch <- garchfit1@fit$ics[1]
1001 bic_garch <- garchfit1@fit$ics[2]
1002 aic_gas <- gasfit1@Estimates$IC[1]
1003 bic_gas <- gasfit1@Estimates$IC[2]
1004 AIC <- c(aic_garch,aic_gas)
1005 BIC <- c(bic_garch,bic_gas)
```
