

UNIVERSIDADE DE BRASÍLIA
FACULDADE DE ECONOMIA, ADMINISTRAÇÃO E CONTABILIDADE
PROGRAMA DE PÓS-GRADUAÇÃO EM ADMINISTRAÇÃO



PEDRO HENRIQUE MELO ALBUQUERQUE

**TESTES DE EVENTOS EM FINANÇAS CORPORATIVAS: O
USO DE MISTURAS GARCH.**

PEDRO HENRIQUE MELO ALBUQUERQUE

**TESTES DE EVENTOS EM FINANÇAS CORPORATIVAS: O
USO DE MISTURAS GARCH.**

Tese apresentada ao Programa de Pós-Graduação em Administração da Universidade de Brasília para obtenção do título de Doutor em Administração.

Brasília
2012

PEDRO HENRIQUE MELO ALBUQUERQUE

**TESTES DE EVENTOS EM FINANÇAS CORPORATIVAS: O
USO DE MISTURAS GARCH.**

Tese apresentada ao Programa de Pós-Graduação em Administração da Universidade de Brasília para obtenção do título de Doutor em Administração.

Área de concentração:
Finanças

Orientador:
Prof. Dr. Ivan Ricardo Gartner

Brasília
2012

FICHA CATALOGRÁFICA

Albuquerque, Pedro Henrique Melo

TESTES DE EVENTOS EM FINANÇAS CORPORATIVAS: O USO DE MISTURAS GARCH. / . – Brasília, 2012. 240 p.

Tese (Doutorado) — Programa de Pós-Graduação em Administração da Universidade de Brasília. Programa de Pós-Graduação em Administração.

1. Teste de eventos. 2. Finanças. I. Albuquerque, Pedro Henrique Melo II. Universidade de Brasília. Programa de Pós-Graduação em Administração. II. Título.

Tese de Doutorado sob o título "*Teste de eventos usando misturas GARCH à luz de finanças corporativas.*", defendida por Pedro Henrique Melo Albuquerque e aprovada em 9 de agosto de 2012, em Brasília, Distrito Federal, pela banca examinadora constituída pelos doutores:

Prof. Dr. Ivan Ricardo Gartner
Departamento de Administração - UnB
Orientador

Prof. Dr. Gustavo Leonel Gilardoni Avelle
Departamento de Estatística - UnB

Prof. Dr. Herbert Kimura
Departamento de Administração - Mackenzie

Prof. Dr. José Angelo Costa do Amor Divino
Departamento de Economia - UCB

Prof. Dr. Tito Belchior Silva Moreira
Departamento de Economia - UCB

DEDICATÓRIA

A minha noiva, amiga, amada, companheira e futura esposa com quem passarei a minha vida,
Vanessa. A minha mãe por todos os dias de minha vida, ao meu pai e ao meu irmão por
estarem ao meu lado. Aos amigos, pelas alegrias e tristezas.
A todos vocês esse trabalho.

AGRADECIMENTOS

Agradeço ao meu amigo e orientador, Ivan Ricardo Gartner, pelas instruções, conselhos e conversas. Aos examinadores pelas críticas e sugestões sempre pertinentes, os quais auxiliaram na elaboração e melhoria desse trabalho. A todos vocês, o meu muito obrigado.

RESUMO

O estudo de métodos e modelos em econometria financeira tem recebido ampla atenção nesse novo milênio. Modelos que incorporam volatilidades, caudas pesadas e assimetria distribucional têm se tornado mais comuns.

Nesse contexto, o ferramental de Estudos de Eventos necessita ser modernizado de maneira a incorporar os principais fatos estilizados registrados amplamente na literatura financeira.

A presente tese surge para suprir essa lacuna e tem como objetivo propor uma metodologia quantitativa e paramétrica para a avaliação e inferência de retornos associados a eventos em finanças corporativas, corrigindo os pressupostos clássicos e simplórios quanto à distribuição dos retornos de ativos por meio da extensão da proposta de Haas (2004), o qual utiliza misturas de modelos GARCH (MN-GARCH) para ajustar retornos financeiros.

Além de ser uma metodologia inovadora, este ferramental apresentou-se - ao longo trabalho - mais adequado as séries temporais financeiras, tornando-se portanto uma proposta adequada aos pesquisadores, gestores e outros profissionais que desejam mensurar e avaliar o impacto de determinados eventos sobre corporações de interesse.

Ensaio aplicados a finanças corporativas utilizando a metodologia proposta são também apresentados no final dessa tese.

LISTA DE ABREVIATURAS

AIC Akaike Information Criterion.

ALGORÍTMO EM Algoritmo Esperança-Maximização.

ARCH Autoregressive Conditional Heteroskedasticity.

CMRM Constant Mean Return Model.

CAPM Capital Asset Pricing Model.

GARCH Generalized Autoregressive Conditional Heteroskedasticity.

IID Independentes e Identicamente Distribuídos.

LSTM Logistic Smooth Transition Market.

MN-GARCH Mixture Normal GARCH.

MPARCH Mixture Periodically Correlated Autoregressive Conditionally Heteroskedastic.

MS-GARCH Markov switching GARCH.

MS Markov switching.

MV Máxima Verossimilhança.

SA Simulated Annealing.

SOC Self-Organized Criticality.

VaR Valor de Risco.

LISTA DE SÍMBOLOS

$\mathbb{E}(\cdot)$ - operador de esperança.

$\text{sinal}(\cdot)$ - função sinal.

$\log(\cdot)$ - função logarítmica natural.

$\tan(\cdot)$ - função tangente.

$\text{diag}(\mathbf{A})$ - vetor com os valores da diagonal da matriz \mathbf{A} .

$\mathbb{P}(\cdot)$ - medida de probabilidade.

$\mathbb{V}(\cdot)$ - operador de variância.

$AR_{i\tau}$ - retorno anormal para a empresa i no período de tempo τ .

$R_{i\tau}$ - retorno observado para a empresa i e período de tempo τ .

$R_{rf\tau}$ - retorno do ativo livre de risco e período de tempo τ .

$R_{m\tau}$ - retorno sobre a carteira de mercado e período de tempo τ .

\mathcal{F}_τ - o conjunto informacional no tempo τ .

$X \sim F(x)$ - X possui distribuição $F(x)$.

$X \sim N(0, 1)$ - X possui distribuição normal padrão.

$X \sim t_d$ - X possui distribuição t de Student com d graus de liberdade.

\underline{X} - \underline{X} é um vetor na forma $\underline{X} = (X_1, \dots, X_k)^T$.

\mathbf{X} - \mathbf{X} é uma matriz.

$(\underline{X})_r$ - r -ésimo elemento do vetor \underline{X} .

$(\mathbf{X})_{rl}$ - elemento associado a linha r e coluna l da matriz \mathbf{X} .

\approx - aproximadamente.

\propto - proporcional a.

SUMÁRIO

1	Introdução.	13
1.1	Estrutura básica para o Estudo de Eventos.	14
1.2	Estudo de eventos e finanças corporativas.	17
1.3	Taxonomia financeira.	19
1.3.1	Gestão financeira.	21
1.4	Misturas de distribuições.	22
1.5	Objetivos de pesquisa e organização da tese.	23
2	Referencial teórico.	26
2.1	Fatos estilizados em finanças.	26
2.1.1	Desvio da normalidade.	28
2.1.2	Misturas de distribuições em finanças.	31
2.1.3	Aglomerarção de volatilidades.	33
2.2	Propostas metodológicas para Estudo de Eventos.	36
3	Misturas de distribuições.	40
3.1	Misturas finitas de distribuições na ciência.	40
3.2	Estimação de misturas de distribuições.	42
3.2.1	Matriz de informação de Fisher.	44
3.3	Algoritmo EM	45
3.3.1	Passo E.	47
3.3.2	Passo M.	48
3.4	Simulated Annealing.	49

3.4.1	Simulated Annealing na estimação de misturas GARCH.	52
4	Misturas de modelos GARCH.	54
4.1	Modelo MN-GARCH.	57
4.1.1	Estrutura.	58
4.1.2	Identificabilidade.	59
4.1.3	Critério de Informação de Akaike.	61
4.1.4	Adequamento do modelo MN-GARCH aos principais índices mundiais. . .	63
4.2	Proposta para estudo de eventos usando misturas GARCH.	67
4.2.1	Estimação pelo algoritmo EM.	70
5	Ensaio em finanças corporativas.	73
5.1	Evidências empíricas da influência do período eleitoral sobre os retornos da Petrobrás.	74
5.1.1	Referencial teórico.	75
5.1.2	Metodologia.	80
5.1.3	Análise empírica.	83
5.1.4	Conclusão.	91
5.2	Avaliação do efeito da distribuição dos dividendos sobre o retorno das empresas brasileiras usando misturas GARCH.	92
5.2.1	Referencial teórico.	93
5.2.2	Metodologia.	99
5.2.3	Análise empírica.	102
5.2.4	Conclusão.	126
6	Considerações finais.	127

Anexos	133
A Programações utilizadas	133
A.1 Programa 1.	133
A.2 Programa 2.	138
A.2.1 Modelo CMRM - PETR3.	138
A.2.2 Modelo CAPM - PETR3.	146
A.2.3 Modelo MM - PETR3.	155
A.2.4 Modelo CMRM - PETR4.	164
A.2.5 Modelo CAPM - PETR4.	172
A.2.6 Modelo MM - PETR4.	181
A.3 Programa 3.	190
A.4 Programa Funções.	217
Referências Bibliográficas	228
Índice Remissivo	240

1 INTRODUÇÃO.

Em econometria financeira, retornos médios diferentes de zero são considerados retornos anormais, pois contrariam a hipótese de mercados eficientes, como proposto por Fama (1991). Especificamente, em finanças corporativas, os gestores estão interessados em avaliar e testar a existência de retornos anormais e, conseqüentemente, averiguar possíveis ineficiências de mercado após a ocorrência de um determinado tipo de evento corporativo. Assim, Estudo de Eventos, como é conhecido esse ramo da econometria financeira, tem como foco um horizonte temporal associado a um evento específico: o evento focal, pois é o foco de estudo da organização.

Formalmente, Mitchell e Netter (1994) definem Estudo de Eventos como uma técnica estatística que tem como objetivo a estimação do impacto no preço das ações sob ocorrências de eventos como: fusões, divulgação de resultados e quaisquer outras ocorrências (eventos) que possam afetar as organizações. A noção básica, segundo Mitchell e Netter (1994), é a de separar os efeitos de dois tipos de informações sobre os preços das ações, quais sejam: informações que são específicas para a empresa como, por exemplo, o anúncio de dividendos; e informações que afetam diretamente o mercado como um todo: como, por exemplo, mudanças nas taxas de juros.

Entre as abordagens em Estudo de Eventos, a proposta mais usual é aquela que infere sobre os efeitos médios associados aos valores dos ativos. Segundo MacKinlay (1997), a utilidade de tal estudo vem do fato de que a racionalidade, dada no mercado, para os efeitos de um evento é refletida imediatamente no valor dos ativos. Assim, uma medida para o impacto econômico de determinados eventos pode ser construída utilizando os preços dos ativos observados ao longo de um período de tempo relativamente curto e que contenha a data do evento focal.

Já em finanças corporativas, a utilização de métodos de Estudo de Eventos remonta aos textos clássicos de Modigliani e Miller (1958), Miller e Modigliani (1961) e Modigliani e Miller (1963), os quais aduziram os problemas de estrutura de capital para a vanguarda da investi-

gação financeira. Dessa forma, Estudo de Eventos tornou-se uma ferramenta fundamental para análise e estudo empírico dedicado a essas questões.

Inicialmente é útil discutir brevemente a estrutura de um Estudo de Eventos. Essa estrutura servirá como base para a discussão de maiores detalhes, como a incorporação de fatos estilizados na modelagem de Estudo de Eventos.

Embora não exista uma única estrutura, MacKinlay (1997) argumenta que há uma “forma usual” de análise de eventos focais em finanças, essa estrutura é discutida na seção a seguir.

1.1 Estrutura básica para o Estudo de Eventos.

A tarefa inicial para realizar um Estudo de Eventos é definir o evento de interesse (evento focal) e identificar o período durante o qual os preços dos ativos das empresas envolvidas neste evento serão analisados. Na prática, o período de interesse (também denominado janela temporal do evento), muitas vezes, é expandido para vários dias, incluindo, pelo menos, o dia do anúncio do evento focal.

Desta forma, é possível captar o efeito da informação dos anúncios sobre os preços após o fechamento do mercado para um período de tempo específico. Períodos anteriores ao evento de interesse e após esse, também, podem ser utilizados com o intuito de aumentar a massa de dados e, conseqüentemente, a robustez do modelo. Esse aumento, no entanto, deve ser realizado com parcimônia, uma vez que janelas temporais muito extensas podem acabar por “diluir” o efeito do evento focal, no teste de hipótese realizado.

Após a identificação de um evento, é necessário determinar os critérios de seleção para a inclusão de determinadas empresas no estudo. Os critérios podem envolver restrições impostas pela disponibilidade de dados, tais como listagem nas Bolsas de Valores, ou pode envolver restrições, como a participação de uma firma específica e o efeito de um determinado anúncio sobre a corporação.

Avaliação do impacto de um evento focal exige uma medida de retorno anormal. O retorno anormal é definido como a diferença entre o valor do ativo no período de tempo τ e o retorno normal esperado (preditor) para esse mesmo ativo na janela temporal τ , para uma determinada empresa ou grupos de firmas. Para a empresa i e período τ em que o evento de interesse ocorre, o retorno anormal é dado por:

$$AR_{i\tau} = R_{i\tau} - \mathbb{E}(R_{i\tau} | \mathcal{F}_\tau) \quad (1.1)$$

onde $AR_{i\tau}$ é o retorno anormal, $R_{i\tau}$ é o retorno observado para a empresa i e período temporal τ e $\mathbb{E}(R_{i\tau}|\mathcal{F}_\tau)$ é o retorno normal condicionado ao conjunto informacional \mathcal{F}_τ para o período especificado, também, denominado preditor. Há duas escolhas comuns para modelar o retorno normal condicionado ao conjunto informacional disponível, são essas: o modelo de retorno constante da média (*Constant Mean Return Model* - CMRM), onde \mathcal{F}_τ é uma constante, e o modelo de mercado onde \mathcal{F}_τ é o retorno de mercado.

Segundo Khotari e Warner (2006), existem outras propostas como o modelo CAPM, o qual possui em sua estrutura mais simplista, a saber:

$$AR_{i\tau} = R_{i\tau} - \{R_{rf\tau} + \beta_i[\mathbb{E}(R_{m\tau}) - R_{rf\tau}]\} \quad (1.2)$$

onde $R_{m\tau}$ é o retorno da carteira de mercado e $R_{rf\tau}$ representa o retorno do ativo livre de risco. É possível também a utilização de diversos modelos para a estrutura do preditor $\mathbb{E}(R_{i\tau}|\mathcal{F}_\tau)$. Em outras palavras, a estrutura $\mathbb{E}(R_{i\tau}|\mathcal{F}_\tau)$ poderia, por exemplo, seguir um processo auto-regressivo de ordem 1 na forma $\mathbb{E}(R_{i\tau}|\mathcal{F}_\tau) = \beta_0 + \beta_1 R_{i\tau-1}$. Há ainda diversas propostas na literatura para o preditor de interesse $\mathbb{E}(R_{i\tau}|\mathcal{F}_\tau)$ em Estudos de Eventos, por exemplo, alguns estudam examinam as volatilidades dos retornos ((BEAVER, 1968) e (PATELL, 1976)) por meio de preditores não lineares, outras abordagens adicionam ao preditor variáveis exógenas como o volume de negociação (CAMPBELL; WASLEY, 1996) e desempenho contábil (BARBER; LYON, 1996).

Para a análise clássica do retorno anormal é necessária alguma notação matemática com o intuito de facilitar a medição e análise dos retornos anormais. Como apresentado em (1.1), os retornos são indexados no período do evento focal, por meio de τ . Define-se $\tau = 0$ como a data do evento focal, seja também $\tau = T_1 + 1$ a $\tau = T_2$ representando a janela do evento, e $\tau = T_0 + 1$ a $\tau = T_1$ constitui a janela de estimação.

Dessa forma, $L_1 = T_1 - T_0$ e $L_2 = T_2 - T_1$ são o comprimento da janela de estimação e a janela temporal do evento de interesse, respectivamente. Note-se que, mesmo se o evento que está sendo considerado é um anúncio em uma determinada data, é comum definir a duração janela do evento com comprimento maior do que um, dessa maneira, facilitando o uso dos retornos anormais em torno do dia do evento em análise.

Quando aplicável, a janela pós-evento será a partir de $\tau = T_2 + 1$ até $\tau = T_3$, cujo comprimento é dado por $L_3 = T_3 - T_2$. Essa estrutura é apresentada na figura 1.1.

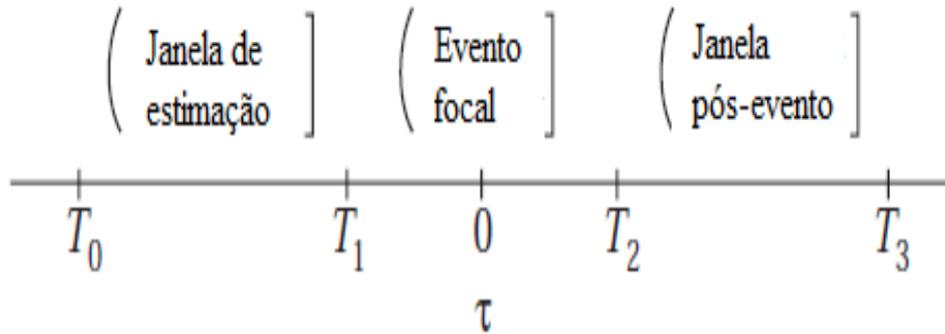


Figura 1.1: Processo temporal para Estudo de Eventos.

Adaptado de MacKinlay (1997).

Fonte: Elaboração do autor.

Segundo MacKinlay (1997), é típico que a janela de estimação e a janela do evento não se sobreponham. Em condições específicas, a estimativa por mínimos quadrados ordinários é consistente para os parâmetros dos preditores frequentemente usados na literatura, como os modelos CMRM e o CAPM.

Uma vez estimados os parâmetros do preditor do modelo, os retornos anormais são estimados de forma que:

$$\widehat{AR}_{i\tau} = R_{i\tau} - \mathbb{E}(\widehat{R}_{i\tau} | \mathcal{F}_\tau) \quad (1.3)$$

para o período de tempo associado ao evento, ou seja, $\tau = T_1 + 1, \dots, T_2$. Quanto à hipótese nula de ausência de efeito sobre os retornos anormais e segundo as condições necessárias para a estimação por mínimos quadrados ordinários tem-se $\widehat{AR}_{i\tau} \sim N\left(0, \mathbb{V}(\widehat{AR}_{i\tau})\right)$.

É possível também testar a nulidade dos retornos anormais por meio de um processo em único passo. Nesse caso, gera-se uma variável indicadora $1_{[T_1 < t \leq T_2]}(t)$ a qual é utilizada como um preditor para o efeito do evento focal, caso o parâmetro associado a essa variável seja estatisticamente diferente de zero. Nesse caso, há indícios da influência do anúncio sobre os retornos observados.

Sem perda de generalidade, considere um preditor linear na forma $\mathbb{E}(R_{i\tau} | \mathcal{F}_\tau) = \beta_0 + \beta_1 X_{i\tau 1} + \dots + \beta_p X_{i\tau p} + \gamma 1_{[T_1 < \tau \leq T_2]}(\tau) + \varepsilon_{i\tau}$, onde $\underline{\theta} = (\beta_0, \dots, \beta_p, \gamma, \sigma^2)^T$ são os parâmetros do modelo linear, $X_{i\tau 1}, \dots, X_{i\tau p}$ são as variáveis que compõem o conjunto informacional \mathcal{F}_τ para a organização i no período τ de tempo e $\varepsilon_{i\tau}$ é o termo estocástico o qual possui, usualmente, distribuição normal com média zero e variância constante σ^2 . Sobre a hipótese nula, o parâmetro γ é igual

a zero e, dessa forma, uma maneira de testar o efeito de um determinado anúncio é adicionar ao modelo uma variável binária que assume valor igual a 1 na janela do evento e valor igual a zero fora dessa janela.

Usualmente, essas abordagens, quando paramétricas, utilizam como pressupostos (direta ou indiretamente): independência, homoscedasticidade e normalidade dos retornos; esses pressupostos vão de encontro dos fatos estilizados discutidos pela literatura financeira, como, por exemplo: aglomerações de volatilidade, retornos com assimetria positiva, retornos extremos e desvios da normalidade ((CONT, 2001); (RACHEV et al., 2005) ; (BIANCHI et al., 2000)). Assim, uma pergunta natural que surge é: *como realizar Testes de Eventos em finanças corporativas na presença dos fatos estilizados associados aos dados financeiros ?* Afim de responder essa questão a presente tese tem como objetivo: *apresentar uma metodologia quantitativa e paramétrica para a avaliação e inferência de retornos associados a eventos em finanças corporativas, corrigindo os pressupostos clássicos quanto à distribuição dos retornos de ativos por meio da extensão da proposta de Haas (2004), o qual utiliza misturas de modelos GARCH (MN-GARCH) para ajustar retornos financeiros.*

1.2 Estudo de eventos e finanças corporativas.

Originalmente desenvolvido como uma ferramenta estatística para a pesquisa empírica em contabilidade e finanças, Estudo de Eventos é utilizado em diversas outras disciplinas, tais como economia, história, direito, marketing e ciências políticas. Inicialmente, o Estudo de Eventos foi aplicado e proposto por Fama et al. (1969), os quais estudaram evidências empíricas que indicavam que mudanças de preços individuais, em sucessivas ações ordinárias, eram aproximadamente não correlacionadas. Utilizando como referencial os trabalhos de Mandelbrot (1963b), Mandelbrot (1966) e Samuelson (1965), Fama et al. (1969) associaram a ausência de correlação das variações sucessivas de preços com a consistência de um mercado eficiente, ou seja, um mercado que se ajusta rapidamente às novas informações. Essas características justificam, inicialmente, a utilização do Estudo de Eventos em finanças corporativas.

Uma vez que grande parte da literatura de finanças corporativas está preocupada com a valorização das empresas e as mudanças no valor da empresa resultante, por exemplo, de mudanças na estrutura de capital, em geral, o valor de uma empresa é difícil de ser medido. No entanto, se há um mercado eficiente para as ações da empresa, o impacto das decisões pode ser medido por meio da variação no preço das ações, em relação ao momento em que a decisão se torna pública.

Assim, para que tais eventos possam ser estudados de diversas maneiras, a literatura de finanças empíricas adotou uma abordagem específica com base em testes estatísticos de significância dos retornos anormais das ações em torno de datas de eventos focais. Este tipo de abordagem também desempenha um papel importante na análise de investimentos. Por exemplo, pode-se estudar o desempenho de ações ou carteiras após uma oferta pública inicial. Outros possíveis exemplos da aplicação dessa abordagem incluem: fusões e aquisições, anúncios corporativos, anúncios de problemas operacionais, dentre outros.

Entre os métodos de estimação dos possíveis modelos para o preditor $\mathbb{E}(R_{it}|\mathcal{F}_t)$ e consequentemente para a estimação dos retornos anormais, estão: mínimos quadrados ordinários, método dos momentos generalizados e máxima verossimilhança. Entretanto, estudos que utilizam essas metodologias, usualmente, possuem como pressupostos: independência entre as observações, variância constante e normalidade. Nesses casos, esses estudos podem incorrer em uma inferência errônea uma vez que seus pressupostos não são satisfeitos para a maioria das séries financeiras e, assim, podem não possuir a significância estatística desejada, desse modo, podendo, em situações extremas, invalidar o estudo. Entre os principais fatos estilizados em finanças, estão aglomerações de volatilidade, retornos com assimetria positiva, retornos com caudas pesadas e desvios da normalidade. Dessa forma, qualquer teste de eventos deve considerar essas características para que o mesmo seja considerado robusto e sua inferência seja a mais escoreita possível.

Assim, como informado no final da seção 1.1, a presente tese apresenta uma metodologia para estudo de eventos em finanças corporativas a qual incorpora os principais fatos estilizados em finanças, utilizando para isso, a proposta de Haas (2004), o qual considera uma mistura de distribuições normais juntamente com uma estrutura do tipo GARCH (denominada MN-GARCH), assim, permitindo uma variância condicional para cada um dos componentes da mistura, bem como um *feedback* dinâmico entre os componentes. Nessa abordagem, o modelo MN-GARCH pode gerar uma desagregação do processo variância condicional em que os componentes da volatilidade dinâmica têm um comportamento, claramente, diferenciado, o que é compatível com a proposta de Estudos de Eventos, cuja hipótese a ser testada é se, após a ocorrência do evento focal, os retornos médios observados (juntamente com sua variância condicional) alteraram-se. Cabe ressaltar também que a proposta de Haas (2004) apesar de bastante geral, não é específica para Testes de Eventos, pois não incorpora em sua formulação, um preditor linear diferente de zero e também a possível presença de eventos corporativos como fatores de mudança no valor médio do retorno da organização explicitando-se assim a inovação desse trabalho. Ademais, trabalhou-se na proposta de metodologia com a utilização de dois regimes: *Bull Market* e *Bear Market*. Apesar dessa nomenclatura, esses regimes podem ser

vistos como períodos de “alta” e “baixa”, “mercado favorável” e “mercado desfavorável” dentre outras terminologias, mas todas com a mesma ideia: um regime com valor médio superior ao valor médio do segundo regime. A justificativa do porque se trabalhar com somente dois regimes é apresentada no referencial teórico da tese (capítulo 2) e está associada a dois fatos estilizados em finanças: segundo a literatura, uma mistura de duas distribuições é suficiente para ajustar a presença de caudas pesadas e assimetria em séries temporais financeiras.

1.3 Taxonomia financeira.

Seguindo a taxonomia apresentada por Drake e Fabozzi (2010), o campo de estudo *finanças* é uma composição de diversas outras ciências como apresenta a figura 1.2.

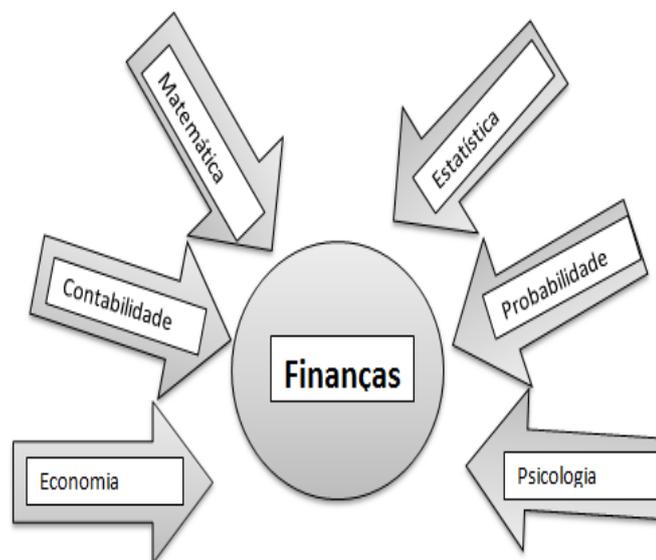


Figura 1.2: Fonte: Elaboração do autor.
Adaptado de Drake e Fabozzi (2010).
Áreas de composição do campo de finanças.

Percebe-se, então, que finanças é uma área multidisciplinar composta de diversos campos. Miller (2000) apresenta ainda que a área de finanças é oriunda de duas grandes fontes, a saber: escolas de finanças e os departamentos de economia.

Segundo Miller (2000), a primeira grande fonte, as escolas de finanças, formou-se originalmente nos departamentos de administração e negócios e possui em seu cerne a elaboração de métodos e modelos aplicados a dados financeiros, como, por exemplo, o modelo *Markowitz*, enquanto os departamentos de economia estão, geralmente, mais dedicados à microestrutura do mercado financeiro e como os seus agentes se comportam em diversas situações, como,

por exemplo, no modelo CAPM.

É claro que essas classificações não são absolutas como aponta Miller (2000)¹, mas apenas uma proposta de classificação dos estudos e estudiosos que têm contribuído para a formação de conhecimento em finanças. Drake e Fabozzi (2010), seguindo os textos clássicos em finanças, segmentam a área de finanças em três grandes campos:

1. mercados de capitais;
2. gestão financeira;
3. gestão de investimentos.

Segundo esses autores, o campo dos mercados de capitais e da teoria do mercado de capitais concentra-se no estudo do sistema financeiro, da estrutura das taxas de juro e dos preços dos ativos de risco. O princípio fundamental da avaliação é que o valor de qualquer ativo financeiro é o valor presente dos fluxos de caixa esperados (GORDON, 1959). Assim, a valorização de um ativo financeiro envolve:

1. estimar os fluxos de caixa esperados;
2. determinar a taxa de juros apropriada ou as taxas de juros que devem ser usadas para descontar os fluxos de caixa; e
3. o cálculo do valor presente esperado dos fluxos de caixa.

A gestão financeira ou finanças empresariais, ou, ainda, por vezes, chamada de finanças corporativas, é a área de especialidade em finanças centrada na tomada de decisões financeiras dentro de uma entidade empresarial. E a gestão de investimentos é a área de especialidade em finanças que lida com a gestão de fundos individuais ou institucionais. Outros termos comumente usados para descrever esta área de finanças são: gestão de ativos, gerenciamento de portfólio, gestão monetária e administração de fortunas. Novamente, essas classificações não são estritas, uma vez que um mesmo estudo pode ser enquadrado em mais de uma classe simultaneamente.

Essa tese pode ser considerada, segundo a taxonomia de Miller (2000), oriunda de um *departamento de administração e negócios*, pois os objetivos serão a elaboração, avaliação e

¹ Por exemplo, o próprio William Forsyth Sharpe - um dos autores do método CAPM - foi orientando de doutorado de Harry Max Markowitz e, segundo Miller (2000), cada método se encontra em uma escola diferente.

aplicação de métodos e modelos a dados financeiros e, conforme a classificação de Drake e Fabozzi (2010), quanto ao macrocampo em finanças, será considerada como *gestão financeira*, visto que o núcleo é a corporação.

1.3.1 Gestão financeira.

Cada decisão tomada em uma empresa tem implicações financeiras, e qualquer decisão que envolva o uso de recursos monetários é uma decisão financeira da organização. Especificamente, finanças corporativas é a área de finanças focada nas decisões monetárias que as empresas realizam e as ferramentas de análise utilizadas para a tomada de decisões com o objetivo de maximizar o valor da firma para os acionistas.

Finanças corporativas englobam diferentes tipos de decisões. Segundo Brigham (1980), essas decisões podem ser classificadas em três grupos: as decisões de investimento, decisões de financiamento e decisões mistas, que envolvem tanto investimento quanto financiamento, centrados na organização (firma). Já uma firma é uma entidade legal, criada sob leis locais e por meio do processo de incorporação. Uma organização (firma) é uma empresa capaz de assumir obrigações contratuais e a realização dos mesmos em seu próprio nome, separadamente dos proprietários, ou, em alguns casos, em conjunto com os proprietários.

Gestores financeiros são cobrados com a responsabilidade de tomar decisões que maximizem a riqueza dos proprietários. Para uma empresa que traduz a responsabilidade em maximizar o valor do patrimônio líquido, se o mercado de ações é eficiente, o valor de uma parcela de ações de uma empresa deve refletir nas expectativas dos investidores sobre as perspectivas futuras da empresa.

O valor de uma ação irá mudar à medida que as expectativas dos investidores sobre o futuro também mudarem. Nesse contexto, o Estudo de Eventos pode ser utilizado como uma ferramenta de apoio à tomada de decisão do gestor da corporação, uma vez que a magnitude do efeito das expectativas dos acionistas sobre o preço da ação pode ser estimada.

Para as decisões de gestores financeiros com o intuito de agregar valor, o valor presente dos benefícios resultantes de decisões deve compensar os custos associados, onde também estão incluídos os custos de capital. Se há uma separação entre propriedade e gestão de uma empresa, isto é, os proprietários não são também os gestores da empresa, existem outros problemas a enfrentar.

1.4 Misturas de distribuições.

Uma maneira de incorporar as particularidades da distribuição das séries financeiras é a utilização de misturas de distribuições. Em probabilidade e estatística, uma mistura de distribuições é a distribuição de probabilidade de uma variável aleatória cujos valores possam ser interpretados como sendo derivados de uma forma simples a partir de um conjunto subjacente de outras variáveis aleatórias.

Particularmente, o valor resultante final é selecionado aleatoriamente entre os valores subjacentes, com certa probabilidade de seleção a ser associada a cada elemento da mistura. As variáveis aleatórias subjacentes podem ser vetores aleatórios, cada um com a mesma dimensão, nesse caso, a mistura de distribuições é uma distribuição multivariada. Nos casos em que cada uma das variáveis aleatórias subjacentes seja contínua, a variável resultante também será contínua e sua função densidade de probabilidade é, por vezes, referida como uma densidade de mistura.

Misturas de distribuições surgem em muitos contextos na literatura e naturalmente quando uma população estatística contém duas ou mais subpopulações (também denominadas regimes). Esses regimes são, por vezes, utilizados como meio de representar variáveis aleatórias não normais.

Dessa forma, misturas de distribuições podem ser utilizadas para a estimação do efeito de eventos focais. Maiores detalhes são discutidos no capítulo 3, desta tese, a seguir no entanto, uma breve explanação de misturas de distribuições é apresentada.

Matematicamente, suponha-se que uma variável aleatória ou vetor aleatório X , o qual toma valores no espaço amostral χ e que a sua distribuição possa ser representada por uma função densidade de probabilidade (ou função massa de probabilidade), tem-se:

$$p(x) = \lambda_1 f_1(x) + \dots + \lambda_k f_k(x) , \text{ para } x \in \chi \quad (1.4)$$

onde $\lambda_j > 0$, $f_j(\cdot) \geq 0$ e $\int_{\chi} dF_j(x) = 1$ para $j = 1, \dots, k$. É necessário também que $\lambda_1 + \dots + \lambda_k = 1$ para que a distribuição resultante também seja uma função densidade de probabilidade ou função massa de probabilidade.

Nesse caso, aponta-se que X é uma mistura de distribuições finita e $p(\cdot)$ é denominado função densidade de uma mistura finita. Os parâmetros $\lambda_1, \dots, \lambda_k$ são denominados pesos da mistura e podem ser interpretados como as probabilidades de uma observação x , com distribuição $p(x)$ vir a ser oriunda do regime j para o peso λ_j .

Com base no breve exposto das seções: Estudos de Eventos 1.2, Taxonomia Financeira 1.3, Finanças Corporativas 1.3.1 e Misturas de distribuições 1.4 a seção 1.5 sintetiza os objetivos da tese, além de apresentar a organização desta.

1.5 Objetivos de pesquisa e organização da tese.

Como apresentado brevemente na seção 1.1, esta tese tem como objetivo propor uma metodologia paramétrica para a análise e estimação do efeito de anúncios à luz de finanças corporativas, incorporando ao modelo os principais fatos estilizados em finanças. A presente tese além de propor uma nova metodologia teórica para o Estudo de Eventos corporativos, aplica essa metodologia a dois ensaios teóricos explanados no capítulo 5.

A proposta aqui apresentada atende aos seguintes quatro requisitos:

1. **Originalidade:** a metodologia proposta e desenvolvida ao longo de toda a tese é original no sentido de “voltar a origem”. Os textos seminais associados à Estudo de Eventos e Fatos Estilizados são apresentados, fornecendo ao leitor, o embasamento teórico para a boa compreensão da proposta aqui aduzida.
2. **Ineditismo:** ao longo da pesquisa (ocorrida até meados de abril do ano de 2012) não foi encontrado nenhum texto que proponha uma metodologia paramétrica para a análise e estimação do efeito de anúncios à luz de finanças corporativas, incorporando neste modelo os principais fatos estilizados em finanças como desvio da normalidade, heterocedasticidade e caudas pesadas. Por conseguinte, a presente tese supre esse *gap* teórico existente em finanças corporativas quanto a propostas metodológicas para a análise e estimação do efeito de eventos sobre os preços das ações das corporações.
3. **Inovação:** a proposta desenvolvida inova por utilizar uma abordagem econométrica - misturas de distribuições GARCH-M para a estimação do efeito de anúncios à luz de finanças corporativas.
4. **Relevância :** atende ao critério de relevância por proporcionar uma ferramenta que reúne os principais fatos estilizados em finanças para a estimação do efeito de eventos sobre os retornos das ações das corporações, mostrando-se mais adequada do que as abordagens tradicionais para a modelagem de séries temporais financeiras como apresentado no capítulo 4 desta tese, adequamento esse apresentado por meio da medida de “perda de informação” (AIC - *Akaike’s Information Criteria*) a qual é minimizada para o modelo MN-GARCH.

Com o intuito de atender ao objetivo proposto, esta tese foi organizada da seguinte forma: o capítulo 2 apresenta o referencial teórico associado aos fatos estilizados em finanças e as propostas metodológicas modernas para o Estudo de Eventos e como as misturas de distribuições são usualmente aplicadas em finanças.

O capítulo 3 expõe formalmente as misturas de distribuições e como essas misturas de distribuições podem ser utilizadas em séries temporais, além de apresentar o processo de estimação, o qual é realizado pelo algoritmo EM. O algoritmo EM (*Expectation-maximization Algorithm*) é um algoritmo desenvolvido por Dempster, Laird e Rubin (1977), o qual é composto por duas etapas: esperança e maximização. Na etapa associada a esperança as variáveis latentes são substituídas pelo seu valor esperado, enquanto na etapa de maximização a verossimilhança do modelo é maximizada. Por se tratar de um algoritmo iterativo, o processo é recursivo até que se atinja uma determinada precisão definida *a priori*.

O capítulo 4 focaliza a proposta de Haas (2004) para a modelagem de séries temporais financeiras, demonstra como essa abordagem pode ser utilizada para Estudo de Eventos, enfoca os critérios para identificabilidade do modelo e apresenta o grau de ajustamento dessa abordagem aos principais índices de bolsas de valores do mundo, comparado com a abordagem frequentemente utilizada.

O capítulo 5 indica dois ensaios da aplicação dessa metodologia em finanças corporativas, bem como descreverá o referencial específico para cada um dos ensaios. Finalmente, o capítulo 6 elenca a conclusão e discussão dos resultados obtidos neste trabalho.

Condensadamente, a organização dessa tese pode ser apresentada da seguinte forma:

1. **Introdução:** contém os objetivos e justificativas da proposta aqui apresentada. (Capítulo 1).
2. **Referencial teórico:** apresenta os principais textos associados aos fatos estilizados em finanças e propostas metodológicas em Estudo de Eventos. Fornece, portanto, as bases teóricas para a formulação da proposta do modelo de misturas GARCH em Testes de Eventos à luz de finanças corporativas. (Capítulo 2).
3. **Metodologia:** contém a descrição e desenvolvimento dos métodos estatísticos/econômicos utilizados como insumos a formulação da proposta de Teste de Eventos em Finanças Corporativas por meio de misturas GARCH. (Capítulos 3 e 4).
4. **Proposta:** a proposta aqui desenvolvida é então apresentada na seção 4.2 com base nas informações esmiuçadas nos capítulos anteriores.
5. **Aplicação:** além da construção de um método para análise e estimação do efeito de anúncios utilizando Testes de Eventos, duas aplicações deste método são desenvolvidas utilizando o campo de Finanças Corporativas. Esses ensaios são apresentados no capítulo 5.
6. **Conclusão:** a conclusão da tese e apresentação dos principais achados são explicitados no capítulo 6.

2 REFERENCIAL TEÓRICO.

O referencial teórico construído para esta tese utilizou-se das seguintes bases de informações: Academic Search Premier, ACM Digital Library, IOPscience, JSTOR Arts & Sciences, Oxford Journals (Oxford University Press), SciELO.ORG, Science (AAAS), ScienceDirect (Elsevier), SpringerLink (MetaPress) e Wiley Online Library.

Optou-se, então, pela construção do referencial teórico de modo que os artigos fossem aplicados a finanças ou que, pelo menos, possuíssem algum apelo quantitativo que pudesse ser aplicado nesse eixo. O presente referencial teórico está dividido nas seguintes seções:

1. Fatos estilizados em finanças.
 - (a) Desvio da normalidade.
 - (b) Misturas de distribuições em finanças.
 - (c) Aglomeração de volatilidades.
2. Propostas metodológicas para Estudo de Eventos.

2.1 Fatos estilizados em finanças.

Um “fato estilizado” é um conjunto de propriedades comuns observadas empiricamente para amostras obtidas em algum ramo de conhecimento, mais especificamente, em econometria financeira. As séries temporais observadas apresentam determinadas características comuns aos dados, essas características são denominadas fatos estilizados. A utilização desses fatos como um mecanismo de pesquisa empírica vem sendo empregado ao longo do tempo, em diversos ramos da ciência. Uma vez identificadas essas características e, após a consistente averiguação das mesmas, modelos teóricos são propostos.

Segundo Chakraborti et al. (2011), o conceito de “fatos estilizados” foi introduzido no campo da macroeconomia por volta de 1960 por Kaldor (1961), o qual defende que um cientista,

ao estudar um fenômeno, “deve ser livre para começar com uma visão estilizada dos fatos”. Em seu trabalho, Kaldor (1961) isolou vários fatos estatísticos caracterizadores do crescimento econômico por longos períodos e em vários países e levou esses padrões robustos como um ponto de partida para a sua modelagem macroeconômica teórica.

No campo de finanças, Ane e Geman (2000) demonstram que os dados usuais associados às séries financeiras não possuem distribuição normal, sendo a distribuição lognormal a que mais se aproxima do padrão dos dados financeiros. Assim, os autores aconselham o uso de métodos não paramétricos para o tratamento e análise de dados financeiros, uma vez que essa abordagem é livre de estruturas paramétricas e uma proposição para a distribuição do processo gerador dos dados torna-se desnecessária.

Cont (2001) apresenta um conjunto de fatos estilizados emergentes em finanças para a análise das variações dos preços em vários tipos de mercados financeiros. Primeiramente, Cont (2001) discute questões gerais comuns a todos os estudos quantitativos associados às séries temporais financeiras. Várias propriedades estatísticas dos retornos dos ativos são, então, descritas no artigo, como: propriedades distribucionais, propriedades da cauda e observações extremas, dependência linear e não linear dos retornos no tempo. O autor também argumenta quanto à importância da incorporação desses fatos estilizados na composição e construção de modelos teóricos e estatísticos com o intuito de acurar a análise dos dados e a formulação teórica de modelos.

Nacionalmente, Costa e Baidya (2001) analisam seis séries de retornos financeiros escolhidas entre as mais líquidas do mercado e de setores diferentes da economia. Os autores estudaram a estacionariedade, a distribuição incondicional e a independência dessas seis séries. Similar a Ane e Geman (2000), Costa e Baidya (2001) afirmam que a caracterização das propriedades estatísticas das séries de retornos das ações é importante para permitir a correta aplicação de modelos aos dados. Os autores identificam ausência de normalidade, caudas pesadas e heteroscedasticidade presente nas séries financeiras estudadas.

Mais recentemente, Chakraborti et al. (2011) revisam os recentes desenvolvimentos teóricos e empíricos geralmente associados ao termo Econofísica e apresentam como os fatos estilizados como aglomerações de volatilidade podem estar relacionados aos principais modelos construídos atualmente em Econofísica, como Jogos de Minoria e *Self-Organized Criticality* (SOC).

Análogo a Kaldor (1961), esse trabalho utiliza os principais fatos estilizados em finanças, já consagrados na literatura, como pilar para a construção de um modelo “mais adequado” à utilização de testes de hipóteses para o Estudo de Eventos. Cont (2001) afirma que os principais

fatos estilizados para os dados de séries temporais financeiras são:

1. **Ausência de autocorrelação linear:** a autocorrelação linear dos retornos financeiros são frequentemente não significantes, exceto para dados observados no período *intraday* com escala inferior a 20 minutos, para os quais o efeito da microestrutura econômica se apresenta fortemente.
2. **Caudas pesadas:** a distribuição incondicional dos retornos segue uma lei de potências ou Pareto nas caudas da distribuição.
3. **Assimetria para ganhos ou perdas:** os dados financeiros possuem frequentemente mais valores negativos do que valores positivos induzindo a uma assimetria.
4. **Aglomerção de volatilidades:** diferentes medidas de volatilidade apresentam autocorrelação positiva durante vários períodos de tempo, dessa forma, altas volatilidades tendem a estar agrupadas no tempo, assim como baixas volatilidades. Fornecendo assim uma indicação natural da presença de dois regimes: um regime com alta volatilidade e um regime com baixa volatilidade.
5. **Efeito de alavancagem:** a maioria das medidas de volatilidade está correlacionada negativamente com os retornos do ativo estudado.

Dentre as características mais comuns presente às séries de dados financeiros, realçam-se o desvio da normalidade, caudas pesadas e a presença de dependência não linear (aglomeração de volatilidades) nos dados temporais. Essas características são discutidas mais detalhadamente nas próximas subseções.

2.1.1 Desvio da normalidade.

Estudos anteriores, como por exemplo, Fama (1965), mostraram que retornos diários possuem caudas mais pesada do que a distribuição normal frequentemente aplicada a dados financeiros.

Muitas abordagens analíticas têm sido propostas para tratar e analisar o desvio da normalidade presente nas séries temporais financeiras. Mandelbrot (1963b) introduziu uma classe de processos estáveis com o intuito de explicar os desvios dos retornos do movimento browniano tradicional.

Segundo Nolan (2010), em teoria da probabilidade, uma variável aleatória é dita ser estável (ou ter uma distribuição estável), se possui a propriedade de que uma combinação linear de

duas variáveis aleatórias independentes e idênticas possui a mesma distribuição. A família de distribuições estáveis é também, por vezes, referida como a distribuição alfa-estável de Lévy.

Em aplicações de modelos estatísticos e econométricos, é comum a utilização do Teorema do Limite Central como uma justificativa para a análise e utilização de métodos que pressupõem, em seu cerne, a normalidade como requisito básico.

O Teorema do Limite Central clássico estabelece que a média de um número suficientemente grande de variáveis aleatórias independentes, cada um com média e variância finita, possuirá aproximadamente distribuição normal (FELLER, 1971).

Entretanto o Teorema do Limite Central possui diversas variantes. Na sua forma comum, as variáveis aleatórias devem ser identicamente distribuídas. A convergência da média para a distribuição normal também ocorre para distribuições não idênticas, uma vez que estejam em conformidade com certas condições.

Na teoria de probabilidade geral, um Teorema do Limite Central é qualquer conjunto de teorias associadas à convergência fraca (convergência em distribuição). Todas expressam o fato de que uma soma de muitas variáveis aleatórias independentes e identicamente distribuídas - iid, ou alternativamente, variáveis aleatórias com tipos específicos de dependência, tenderão a ser distribuídas segundo uma distribuição atratora.

Quando a variância das variáveis aleatórias iid é finita, a distribuição atratora é a distribuição normal. Em contraste, a soma de uma série iid de variáveis aleatórias com distribuições que seguem lei de potência nas caudas diminuindo a uma taxa $1/|x|^{\alpha+1}$, onde $0 < \alpha \leq 2$ e, portanto, com variância infinita, tenderão a uma distribuição estável com o parâmetro de estabilidade (ou índice de estabilidade) igual a α à medida que o número de variáveis aumenta.

Uma distribuição não degenerada é uma distribuição estável se essa satisfaz a seguinte propriedade (RACHEV, 2000, p. 27):

Propriedade 2.1.1 *Sejam X_1 e X_2 cópias independentes de uma variável aleatória X , dizemos que X é uma variável aleatória estável se para quaisquer constantes $a > 0$ e $b > 0$ a variável aleatória $aX_1 + bX_2$ possui a mesma distribuição que $cX + d$ para constantes $c > 0$ e $d \in \mathbb{R}$. A distribuição é dita ser rigorosamente estável se $d = 0$.*

Alguns casos especiais dessa família de distribuição são as distribuições normal, Cauchy, e Lévy, uma vez que todas essas distribuições possuem a propriedade indicada anteriormente. Tais distribuições formam uma família de distribuições contínuas com quatro parâmetros: $\mu \in \mathfrak{R}$ e $\sigma > 0$ são os parâmetros de locação e escala respectivamente e $-1 < \beta < 1$, $0 < \alpha \leq 2$ são

parâmetros de forma que correspondem aproximadamente às medidas de assimetria e concentração, respectivamente. Embora a função densidade de probabilidade para uma distribuição geral estável não possa ser escrita analiticamente, a função característica pode ser, uma vez que qualquer distribuição de probabilidade é determinada pela sua função característica $\phi(t)$, vale então a seguinte relação:

$$f(x) = \frac{1}{2\pi} \int_{-\infty}^{\infty} \phi(t) e^{-itx} dt \quad (2.1)$$

onde a função característica é dada por:

$$\phi(t; \mu, \sigma, \alpha, \beta) = \exp [it\mu - |\sigma t|^\alpha (1 - i\beta \operatorname{sinal}(t)\zeta(t))] \quad (2.2)$$

onde $\operatorname{sinal}(\cdot)$ é o sinal de t e:

$$\zeta(t) = \begin{cases} \tan\left(\frac{\alpha\pi}{2}\right) & \text{para } \alpha \neq 1 \\ -\left(\frac{2}{\pi}\right) \log|t| & \text{para } \alpha = 1 \end{cases} \quad (2.3)$$

Alguns autores, como Mandelbrot (1962), Mandelbrot (1963a), Mandelbrot (1963c), Fama (1965), Officer (1972), Mitnik, Rachev e Paoella (1998) e Teichmoeller (1971), têm associado a distribuição dos retornos de séries financeiras à família de distribuições estáveis, dessa forma, invalidando a utilização do Teorema do Limite Central clássico e reforçando a utilização de outras abordagens para a especificação paramétrica da distribuição dos retornos de ativos financeiros, assim como os testes de hipóteses associados a esses dados.

Dessa forma, a construção de um teste de hipótese para o campo de Estudo de Eventos deveria considerar para a distribuição dos retornos anormais uma distribuição estável com o intuito de tornar a modelagem o mais acurada possível. Apesar da boa adequabilidade apresentada por essa família de distribuições aos dados financeiros, como demonstrado por Mandelbrot (1982), Cheng e Rachev (1994) e Adler, Feldman e Taqqu (1998), a utilização dessa estrutura paramétrica não é trivial de ser utilizada por diversas razões, entre elas, a ausência de uma forma analítica para a função densidade de probabilidade. Outra questão que surge é que o modelo apresentado na equação (2.2) não incorpora a aglomeração de volatilidade frequentemente presente aos dados financeiros, sendo necessária outra abordagem para a construção de testes de hipóteses em Estudos de Eventos.

2.1.2 Misturas de distribuições em finanças.

Segundo Costa e Baidya (2001), a explicação mais aceita atualmente para as caudas pesadas das distribuições de retornos é a de mistura de distribuições. Autores, como Praetz (1972) e Clark (1973), argumentam que esta mistura é de distribuições normais.

Devido à sua grande flexibilidade, o modelo de misturas normais foi amplamente aplicado à distribuição incondicional dos retornos de ativos.

Fama (1965) sugere que uma possibilidade para o desvio da normalidade dos dados, talvez a mais popular para explicação de caudas pesadas, está associada à hipótese de que a distribuição das variações dos preços é na verdade uma mistura de várias distribuições normais com possivelmente a mesma média, mas substancialmente variâncias diferentes, representando assim os vários regimes em que o mercado pode estar.

Kon (1984) argumenta que uma mistura discreta de distribuições normais é suficiente para explicar os fatos estilizados associados à curtose significativa (caudas pesadas) e assimetria positiva significativa na distribuição de taxas diárias de retorno para uma amostra de ações ordinárias e índices financeiros. Diferentemente de Fama (1965), Kon (1984) observou que as misturas possuíam médias estatisticamente diferentes, o que ajuda a explicar a assimetria usual presente nas séries financeiras e, conseqüentemente, o fato estilizado associado à assimetria para ganhos ou perdas. O autor detectou também diferenças significativas nas variâncias dos componentes da mistura o que, segundo o mesmo, ajudaria a explicar a curtose excessiva presente nos dados financeiros. Kon (1984) conclui afirmando que o modelo de misturas normais com variâncias e médias diferentes é superior ao ajuste produzido pelo modelo t de *Student*.

Tucker e Pond (1988) investigam empiricamente os processos candidatos para caracterizar as mudanças do preço do câmbio medido em horizontes limitados. Tucker e Pond (1988) afirmam por meio de estudos empíricos que a distribuição dos retornos dos preços cambiais também apresenta cauda longa e distribuição leptocúrtica, indo ao encontro dos já consagrados fatos estilizados em finanças. Os autores investigam quatro processos: mistura de normais, distribuição t de *Student*, distribuição α -estável e processo *Mixed-Jump*. Esses processos possuem o potencial de modelar as descontinuidades observadas nas taxas de câmbio e a presença de momentos não estacionários, bem como apresentam um apelo econômico interessante. Os autores sugerem que o modelo de misturas normais ajustou-se corretamente à distribuição das seis principais moedas testadas, a saber: a libra esterlina, dólar canadense, marco alemão, franco francês, yen japonês e o franco suíço. Entretanto, como o texto foi produzido antes da formação da União Europeia, o Euro não foi testado, surgindo assim um *gap*

empírico a ser investigado. Um importante fato relatado pelos autores é que até mesmo uma mistura de duas componentes normais é bastante capaz de modelar corretamente a assimetria e a curtose típica dos dados financeiros.

Gridgeman (1970) refere que a usual assimetria e o desvio de curtose presentes nos dados podem ser modelados por meio de misturas de distribuições normais com parâmetros de locação e escala diferenciados. Gridgeman (1970) foi o primeiro a provar que a curtose diferenciada, quando comparada com a distribuição normal, pode ser representada por uma mistura de normais.

Uma vantagem do modelo de misturas normais não compartilhadas por outros pressupostos distribucionais é que esse pode se prestar à interpretação econômica. Considerando a distribuição incondicional, Kon (1984), por exemplo, argumenta que uma mistura discreta de distribuições normais pode ser responsável por uma série de fluxos de informação, tais como a economia como um todo, o mercado específico e empresas específicas, resultando em um componente com três misturas. Há também tentativas de ligação da abordagem mistura aos recentes modelos em economia financeira tentando explicar os fatos estilizados associados aos dados das séries temporais financeiras por meio da interação de grupos heterogêneos (ou regimes heterogêneos).

O modelo de misturas normais também pode ser apropriado a amostras em que os componentes seguem uma sequência de repetição na geração de observações. Por exemplo, o efeito “Dia da semana”, como mencionado por Fama (1965), poderia ser uma possível fonte de misturas de distribuições. Ao analisar subamostras correspondentes, no entanto, Fama (1965) descobriu que o “efeito da segunda-feira” não explica completamente o desvio da normalidade associado aos dados financeiros. No entanto, uma mistura de distribuições pode ser interpretada como representando dias de negociação de diferentes tipos: um componente com variância relativamente baixa, por exemplo, poderia representar “*business as usual*”, tipicamente associado a uma mistura com grande peso, enquanto que componentes com alta volatilidade estariam associados a uma mistura com pequeno peso podendo corresponder a momentos de alta volatilidade causados pela chegada de novas informações substanciais.

A ideia da mistura de normais deu origem a muitos modelos não lineares para as séries de retornos. Dentre os mais difundidos estão os membros da família GARCH, introduzidos inicialmente por Engle (1982) e generalizados por Bollerslev (1986).

2.1.3 Aglomeração de volatilidades.

Na análise de séries temporais financeiras, a maior dificuldade encontrada é a presença de heteroscedasticidade, a qual induz a uma dependência não linear dos dados, sendo que essa modelagem nem sempre é trivial. Essa dependência não linear é apresentada na literatura dos fatos estilizados em finanças como *aglomeração de volatilidade*.

O primeiro modelo capaz de capturar a usual aglomeração de volatilidade foi o modelo autorregressivo de heteroscedasticidade condicional (ARCH - *Autoregressive Conditional Heteroskedasticity*), proposto por Engle (1982). O modelo ARCH tem a vantagem de facilidade na obtenção de propriedades teóricas de interesse, tais como condições de estacionariedade e momentos, além de simplicidade de cálculo numérico.

Alguns anos mais tarde, essa estrutura foi generalizada por Bollerslev (1986) para o modelo ARCH generalizado (GARCH - *Generalized Autoregressive Conditional Heteroskedasticity*). Matematicamente, um processo estocástico X_t é denominado $GARCH(P, Q)$ se satisfaz a equação:

$$\begin{cases} X_t = \sigma_t Z_t \\ \sigma_t^2 = \alpha_0 + \sum_{q=1}^Q \alpha_q X_{t-q}^2 + \sum_{p=1}^P \theta_p \sigma_{t-p}^2 \end{cases} \quad (2.4)$$

onde $\alpha_0 > 0$, $\alpha_q \geq 0$ para $q = 1, \dots, Q$ e $\theta_p \geq 0$ para $p = 1, \dots, P$ e Z_t é uma sequência independente e identicamente distribuída de variáveis aleatórias, tais que $\mathbb{E}(Z_t) = 0$ e $\mathbb{E}(Z_t^2) = 1$. Além dos pressupostos apresentados, é necessário que $\sum_{q=1}^Q \alpha_q + \sum_{p=1}^P \theta_p \leq 1$ para que o processo seja considerado estacionário. O processo é denominado $ARCH(P)$ se $Q = 0$.

A estrutura para Z_t também pode possuir um parâmetro (ou conjunto de parâmetros) de locação, que incorpore o efeito do conjunto informacional disponível, como por exemplo, em Engle e Bollerslev (1986).

Após esta importante descoberta, uma variedade de modelos alternativos GARCH foram propostos. No entanto o modelo GARCH clássico é ainda o modelo de referência para modelagem de séries temporais financeiras devido à sua simplicidade e eficiência ao modelar a heteroscedasticidade condicional.

Com o intuito de modelar os demais fatos estilizados em finanças surgiram, na literatura, diversas variações do modelo GARCH clássico. Nelson (1991) introduziu o modelo EGARCH listando inconvenientes associados ao modelo GARCH, que não incorpora as características usuais das séries temporais financeiras, quais sejam: a falta de assimetria na resposta dos

choques (assimetria para ganhos ou perdas) e em segundo lugar, os modelos GARCH impõem restrições aos parâmetros para assegurar a positividade da variância condicional. Nelson (1991) considerou para a estrutura (2.4) a seguinte forma para a variância condicional:

$$\log(\sigma_t^2) = \alpha_0 + \sum_{q=1}^Q [\phi_q Z_{t-q} + \psi_q (|Z_{t-q}| - \mathbb{E}|Z_{t-q}|)] + \sum_{p=1}^P \theta_p \log(\sigma_{t-p}^2) \quad (2.5)$$

a qual define o modelo $EGARCH(P, Q)$ de Nelson (1991). Para o modelo (2.5) não há restrições de positividade para os parâmetros. A assimetria usual aos dados financeiros é modelada pelo termo $\phi_q Z_{t-q}$.

Segundo Cont (2001), há indícios de que os retornos dos ativos estão correlacionados com a volatilidade presente nos dados. Isso motivou a construção do ARCH-M proposto por Engle, Lilien e Robins (1987), o qual apresenta para Z_t parâmetro de locação diferente de zero.

Engle e Bollerslev (1986) demonstraram que o modelo $GARCH(1, 1)$ é adequado à maioria das séries financeiras. Nessa parametrização, os resultados obtidos sugerem que os parâmetros possuem as seguintes características: $\theta_1 > 0,7$ e $\alpha_1 \approx 1 - \theta_1$. Essas condições motivaram a elaboração do modelo $IGARCH(P, Q)$, no qual $\alpha_1 + \theta_1 = 1$.

Similarmente a Engle e Bollerslev (1986), outros autores afirmam que a estrutura $GARCH(1, 1)$ é suficiente para a modelagem da maioria das séries financeiras.

Terasvirta (1996) afirma que dados de alta frequência associados às séries temporais financeiras e econômicas exibem duas características empíricas: alta curtose e autocorrelação não linear positiva. Estas séries são, muitas vezes, modeladas por meio de um modelo $GARCH(1, 1)$. Terasvirta (1996) indica, no entanto, que, apesar do modelo $GARCH(1, 1)$ ser capaz de ajustar adequadamente a dependência não linear, não é adequado para atender os outros fatos estilizados em finanças, como assimetria e caudas longas.

Starica (2004) investiga a relevância do modelo $GARCH(1, 1)$ como descritor e predictor da dinâmica dos retornos do índice de mercado *Standard & Poors 500* (S & P 500) de ações. O autor apresenta que para essa série de dados o modelo $GARCH(1, 1)$ não demonstrou diferenças (estatisticamente significantes) em relação à abordagem de regressão não paramétrica para a previsão de volatilidade do dia seguinte, mas não apresenta qualquer outra abordagem paramétrica que seja robusta como o modelo $GARCH(1, 1)$ usual.

Posedel (2005) motivado pela popularidade e abrangência do modelo $GARCH(1, 1)$ estuda em profundidade as propriedades do modelo $GARCH(1, 1)$ e os pressupostos associados ao

espaço paramétrico. Particularmente, o autor demonstra a ergodicidade e estacionariedade forte para a variância condicional do processo. O autor também estuda as propriedades estatísticas associadas ao modelo e ao processo de estimação, o qual é realizado usualmente por meio de *quasi*-máxima verossimilhança. Posedel (2005) demonstra ainda a consistência e normalidade assintótica das estimativas dos parâmetros.

Lunde e Hansen (2005) compararam 330 modelos ARCH quanto ao seu potencial de previsibilidade da variância condicional. Os autores não encontraram evidências de que o modelo $GARCH(1,1)$ possa ser superado por qualquer outro modelo ARCH específico. No entanto, segundo Lunde e Hansen (2005), o modelo não é capaz de ajustar dados afetados pelo efeito de alavancagem, sendo, portanto, necessária a utilização de modelos mais sofisticados.

Ashley e Patterson (2010) argumentam que retornos diários são comumente modelados por meio de um processo $GARCH(1,1)$. Os autores testam essa especificação usando como mecanismo de avaliação o modelo proposto por Ashley e Patterson (2006), o qual é capaz de examinar a capacidade do modelo estimado em reproduzir características de interesse particular, como os vários aspectos da dependência não linear presente nas séries temporais financeiras. Usando retornos diários, Ashley e Patterson (2010) concluem que a especificação $GARCH(1,1)$ não pode ser rejeitada. Sendo assim, este modelo parece ser razoavelmente adequado em termos de reprodução dos tipos de dependência não linear frequentemente presentes nas séries financeiras.

Nesse sentido, uma proposta metodológica para a análise e estimação dos efeitos de determinados eventos, por meio da abordagem de Estudo de Eventos, deveria incorporar os fatos estilizados presentes nas séries temporais financeiras. Essa proposta poderia utilizar misturas de distribuições para ajustar as caudas pesadas, assimetria para ganhos ou perdas e o efeito alavancagem, pois a abordagem de misturas decompõe o efeito dessas características e a problemática causada por essas é reduzida. Quanto ao número de misturas a ser utilizado, é suficiente dois regimes (TUCKER; POND, 1988), pois esses podem ser interpretados como mercados em “alta” e mercados em “baixa”. Mas, misturas com um número maior de regimes também é plausível. Entretanto, a abordagem usual de misturas de distribuições não é capaz de ajustar as aglomerações de volatilidade, visto que esse ajuste é bem-realizado por meio de modelos GARCH, especificamente, através do modelo $GARCH(1,1)$.

Dessa forma, a proposta desta tese é a construção de um método que incorpore as principais características dos modelos de misturas e modelo GARCH, dessa maneira, fornecendo uma metodologia robusta e capaz de modelar adequadamente os fatos estilizados em finanças, para a avaliação e inferência de retornos associados a eventos em finanças corporativas. Avanços

metodológicos no campo de Estudo de Eventos têm se limitado principalmente a proposições não paramétricas de testes, como apresentados a seguir.

2.2 Propostas metodológicas para Estudo de Eventos.

Corrado (2011) revisa os principais temas metodológicos para o campo de Estudo de Eventos apresentando, além da abordagem clássica, outras abordagens paramétricas com o intuito de mensurar o efeito do evento focal sobre a volatilidade do ativo, em estudo e abordagens não paramétricas.

Especificamente, considere o modelo de mercado apresentado para mensurar o efeito de um determinado evento focal para o retorno do ativo de uma empresa i :

$$AR_{i\tau} = R_{i\tau} - \alpha - \beta R_{m\tau} \quad (2.6)$$

onde $R_{m\tau}$ é o retorno da carteira de mercado. Sob a hipótese nula de ausência de um desempenho anormal, para uma janela temporal τ os retornos anormais $AR_{i\tau}$ possuirão valor esperado igual a zero e variância estimada por mínimos quadrados dada por (GREENE, 2003):

$$\widehat{\mathbb{V}}(AR_{i\tau}) = \hat{\sigma}_\varepsilon^2 \left(1 + \frac{1}{n} + \frac{(R_{m\tau} - \bar{R}_{m\tau})^2}{\sum_{t \neq \tau} (R_{mt} - \bar{R}_{m\tau})^2} \right) \quad (2.7)$$

onde $\hat{\sigma}_\varepsilon$ denota o erro-padrão do modelo de regressão utilizado para se estimar os parâmetros α e β . Assumindo que os retornos são normalmente distribuídos, a estatística de teste:

$$\frac{\widehat{AR}_{i\tau}}{\sqrt{\widehat{\mathbb{V}}(AR_{i\tau})}} \sim t_{n-2} \quad (2.8)$$

é distribuída segundo uma distribuição t de *Student* com $n - 2$ graus de liberdade. Entretanto, a convergência assintótica para a normalidade dos retornos é a exceção, enquanto a regra é a convergência para a família de distribuições estáveis apresentadas em (2.2), a qual possui somente variância finita no caso do parâmetro de concentração $\alpha = 2$, o que recai na distribuição normal (VOIT, 2005).

Consequentemente, a convergência para a distribuição t de *Student* também está comprometida, visto que essa é oriunda de uma razão na qual o numerador segue uma distribuição normal e o denominador uma distribuição qui-quadrado. Como o numerador frequentemente

diverge da distribuição normal para dados financeiros e como o denominador também necessita do pressuposto de normalidade para que a quantia $\mathbb{V}(AR_{i\tau}) / (n-2)\sigma^2$ possua distribuição qui-quadrado com $n-2$ graus de liberdade (WACKERLY; III; SCHEAFFER, 2002), a utilização do teste clássico (2.8) é desmotivada.

Existe, no entanto, um procedimento simples e robusto para avaliar a significância estatística dos retornos anormais e que não depende de uma suposição distribucional sobre os retornos. Este procedimento envolve a contagem do número de retornos na janela de estimação e na janela pós-evento, que são maiores ou menores do que o retorno (ou retorno médio) $AR_{i\tau}$. Essa abordagem é uma proposta metodológica não paramétrica baseada no teste do sinal (TOUTENBURG, 1992).

Alguns textos posteriores a Brown e Warner (1980), que envolvem a avaliação do desempenho de testes em Estudos de Eventos sobre a ausência de normalidade dos dados, argumentam que os testes mais bem-sucedidos foram os testes não paramétricos, como o teste do sinal e teste de postos como apresentados em McConnell e Muscarella (1985), Corrado (1989), Lummer e McConnell (1989), Zivney e Thompson (1989) e Corrado e Zivney (1992).

Especificamente, considere $r(AR_{it})$ o posto (ou ranque) dos retornos excessivos para $-\infty < t < \infty$ composto por $m+n$ elementos, onde m é o número de observações fora da janela associada ao evento focal e n é o número de elementos dentro da janela do evento de interesse. Sob a hipótese nula, cada valor de $r(AR_{it})$ possui distribuição uniforme oriunda de uma amostragem sem reposição de inteiros numerados de 1 a $n+m$. A média e a variância para $\sum_{\tau} r(AR_{i\tau})$ são, respectivamente (HETTMANSPERGER, 1984):

$$\mathbb{E}(\sum_{\tau} r(AR_{i\tau})) = n \left(\frac{n+m+1}{2} \right) \quad (2.9)$$

e

$$\mathbb{V}(\sum_{\tau} r(AR_{i\tau})) = nm \left(\frac{n+m+1}{12} \right) \quad (2.10)$$

Logo, a estatística do teste é obtida somando os retornos excessivos padronizados pela sua média e variância, matematicamente:

$$R_i = \frac{\sum_{\tau} r(AR_{i\tau}) - n \left(\frac{n+m+1}{2} \right)}{\sqrt{nm \left(\frac{n+m+1}{12} \right)}} \quad (2.11)$$

onde sob a hipótese nula, $R_i \sim N(0, 1)$. McConnell e Muscarella (1985) propuseram uma gene-

realização do teste de sinais incorporando, assim, possíveis assimetrias presentes no conjunto de dados. Considere $\text{sinal}(AR_{it} - x_i)$ denotando o sinal da diferença entre o retorno excessivo AR_{it} e um valor arbitrário qualquer x_i , dessa forma, seja $p_i^+ = \frac{1}{m} \sum_{t \in \tau} \text{sinal}(AR_{it} - x_i)$ a proporção de sinais positivos tais que:

$$\text{sinal}(AR_{it} - x_i) \begin{cases} 1, & \text{se } AR_{it} > x_i \\ 0, & \text{se } AR_{it} \leq x_i \end{cases} \quad (2.12)$$

Então, a estatística do teste pode ser dada por:

$$S_i = \frac{\sum_{t \in \tau} \text{sinal}(AR_{it} - x_i) - np_i^+}{\sqrt{np_i^+(1-p_i^+)}} \quad (2.13)$$

novamente, sobre a hipótese nula, a estatística é assintoticamente normal com média zero e variância unitária.

Outras propostas encontradas na literatura para a análise de dados não normais utilizam-se do método de reamostragem Bootstrap, como apresentado em Hamill, Opong e McGregor (2002), Hein (2004), Ford e Kline (2006), Baixauli (2007) e Corrado e Truong (2008). Nesse tipo de abordagem, os seguintes passos são realizados para o cômputo da estatística teste:

1. Compute a estatística teste clássica como apresentado em (2.8) e denote-a T^* .
2. Gere B amostras aleatórias com reposição da série para $-\infty < t < \infty$.
3. Para cada amostra calcule a estatística dada em (2.8) e denote-as T^b para $b = 1, \dots, B$.
4. Ordene as B amostras e obtenha o posto no qual a estatística do passo 1 é superior (ou inferior) a alguma estatística do conjunto amostral B .
5. A significância é dada então pela posição do posto obtido pela estatística T^* .

Apesar da abordagem não paramétrica ser livre de pressupostos distribucionais, Corrado (2011) argumenta que os testes paramétricos, quando bem-especificados, possuem robustez e alto poder estatístico, ou seja, alta probabilidade da não incidência do erro do tipo II no teste.

Dessa forma, dentre as propostas paramétricas, pouco tem sido proposto na literatura de Estudo de Eventos, com exceção das abordagens que objetivam mensurar o efeito de um evento focal sobre a volatilidade dos retornos. Inicialmente, esse tipo de discussão partiu de Brown e Warner (1985), que afirmaram que há evidências de um aumento substancial na volatilidade de

uma série de retornos financeiros em torno de alguns tipos de eventos focais, sugerindo, assim, que a variância em alguns Estudos de Evento poderia aumentar, ou diminuir significativamente.

Corhay e Rad (1996) e Wang et al. (2002) utilizam um modelo de mercado, o qual incorpora a mudança temporal da volatilidade, utilizando uma estrutura Generalizada Autoregressiva de Variância Condicional e assumindo para isso que o mercado possa ser ajustado de tal forma que os resíduos do modelo sejam condicionalmente heteroscedásticos, com a seguinte especificação $GARCH(P, Q)$:

$$R_t = \beta_0 + \beta_1 R_{mt} + \sum_{h=1}^H \lambda_h R_{t-h} + \varepsilon_t \quad (2.14)$$

onde $\varepsilon_t | \mathcal{F}_t \sim t_d(0, \sigma_t^2)$ e:

$$\sigma_t^2 = \alpha_0 + \sum_{q=1}^Q \alpha_q \varepsilon_{t-q}^2 + \sum_{p=1}^P \theta_p^2 \sigma_{t-p}^2 \quad (2.15)$$

Nas equações (2.14) e (2.15) são apresentadas as equações da média e variância, respectivamente, \mathcal{F}_t é o conjunto informacional no tempo t , σ_t^2 é a variância condicional no tempo t , $t_d(\cdot)$ é a função densidade de probabilidade da distribuição t de *Student* com d graus de liberdade, para $q > 0$, $\alpha_q \geq 0$ para $q = 1, \dots, Q$ e $p > 0$, $\theta_p \geq 0$ para $p = 1, \dots, P$. Entretanto, essa abordagem, apesar de capturar as aglomerações de volatilidade, não captura a assimetria positiva e a presença de *outliers* usualmente constantes em séries temporais financeiras.

Essa questão continua a ser uma fonte de preocupação entre os pesquisadores de finanças. Particularmente, Higgins e Peterson (1998), Aktas, Bodt e Cousin (2007) e Harrington e Shridder (2007) argumentam que todos os eventos induzem em uma alteração na volatilidade das séries financeiras estudadas e que, dessa forma, a magnitude desse efeito deveria ser estimada e incorporada em todos os testes utilizados para avaliarem a significância estatística dos retornos anormais de um determinado evento.

De maneira mais crítica, poucos são os estudos que incorporam os fatos estilizados em finanças nos modelos que mensuram o efeito de divulgações em finanças. Essa adequação é realizada nesta tese por meio de misturas de distribuições, as quais são detalhadas na continuidade do estudo.

3 MISTURAS DE DISTRIBUIÇÕES.

Misturas finitas de distribuições (ou por simplicidade, misturas de distribuições) têm proporcionado uma abordagem matemática baseada na modelagem estatística de uma grande variedade de fenômenos aleatórios, e isso se dá à sua flexibilidade. Modelos de mistura finita continuam a receber atenção crescente ao longo dos anos (desde o texto seminal de Titterton, Smith e Makov (1985) até textos mais recentes como Schnatter (2006)), associando aplicações às teorias.

Alguns ramos da ciência nos quais misturas finitas de distribuições têm sido aplicadas com sucesso incluem astronomia, biologia, genética, finanças, economia, engenharia e marketing, entre muitos outros campos. Nestas aplicações, modelos de misturas sustentam uma variedade de técnicas em grandes áreas da estatística, como análises de conglomerados, classes latentes, a análise discriminante, análise de imagem e análise de sobrevivência. Entretanto, seu maior papel é produção de informações e adequabilidade aos dados em problemas de inferência estatística (MCLAUGHLAN, 2000).

Outro ponto a favor da utilização de misturas de distribuições é o fato de que qualquer distribuição contínua poder ser aproximada por uma mistura finita de densidades normais com variância comum (ou matriz de covariâncias no caso multivariado) fixada uma determinada precisão. Ademais, modelos de mistura fornecem também uma estrutura paramétrica conveniente para o tratamento de dados cuja distribuição e, conseqüentemente, o processo gerador dos dados é desconhecido ou parcialmente conhecido.

3.1 Misturas finitas de distribuições na ciência.

Segundo Mclaughlan (2000) e Schnatter (2006), a história dos modelos de mistura finita remonta a mais de um século por meio do matemático Karl Pearson, o qual aplicou, pela primeira vez, uma abordagem de misturas de distribuições em um conjunto de dados, com o intuito de segmentar populações em uma amostra observada.

Similarmente ao que foi exposto na seção 1.4, pode-se definir a seguinte estrutura básica para uma mistura finita de distribuições: considere $\underline{X}_1, \dots, \underline{X}_n$ uma amostra aleatória de tamanho n , onde \underline{X}_j é um vetor p -dimensional com função densidade de probabilidade $f(\underline{X}_j)$ em \mathfrak{R}^p . Na prática, \underline{X}_j contém variáveis aleatórias correspondentes a p medidas realizadas na j -ésima observação, segundo algum fenômeno em estudo.

Seja então $\mathbf{X} = (\underline{X}_1^T, \dots, \underline{X}_n^T)$ a amostra completa, isso é, uma n -tupla de pontos em \mathfrak{R}^p , seguindo a notação usual de probabilidade e estatística, uma possível realização desse fenômeno aleatório é representado por letras minúsculas, de forma que $\mathbf{x} = (\underline{x}_1^T, \dots, \underline{x}_n^T)$ pode ser considerado uma amostra observada. Considere a densidade $f(\underline{x}_j) = \sum_{k=1}^K \lambda_k f_k(\underline{x}_j)$ onde $f_k(\underline{x}_j)$ são densidades e λ_k são quantias não negativas, as quais somam um, isso é:

$$\begin{cases} 0 \leq \lambda_k \leq 1 \text{ para } k = 1, \dots, K \text{ e} \\ \sum_{k=1}^K \lambda_k = 1 \end{cases} \quad (3.1)$$

As quantias $\lambda_1, \dots, \lambda_K$ são denominadas proporções da mistura ou simplesmente pesos. Como as funções $f_1(\underline{x}_j), \dots, f_K(\underline{x}_j)$ são densidades é fácil mostrar que:

$$f(\underline{x}_j) = \sum_{k=1}^K \lambda_k f_k(\underline{x}_j) \quad (3.2)$$

também é uma densidade. As funções $f_j(\underline{x}_j)$ são denominadas componentes da mistura. Dessa forma, uma mistura de distribuições é também definida como uma mistura finita de K componentes. Nessa formulação, o número de componentes K é considerado fixo. Mas, em algumas aplicações, essa quantia é um parâmetro que pode ser estimado.

Os modelos de misturas, além de apresentarem uma formulação simples, possuem uma possibilidade de interpretação dos pesos que pode ser útil em diversos estudos. A estrutura apresentada em (3.2) pode também ser formulada da seguinte maneira: seja Z_j uma variável categórica, a qual toma valores $1, \dots, K$ com as seguintes probabilidades $\lambda_1, \dots, \lambda_K$, respectivamente, suponha ainda que a densidade condicional \underline{X}_j dado $Z_j = k$ é $f_k(\underline{x}_j)$ para $k = 1, \dots, K$.

Então, a densidade incondicional, isso é, a densidade marginal de \underline{X}_j é dada por $f(\underline{x}_j)$. Nesse contexto, a variável Z_j pode ser vista como um rótulo para o vetor \underline{X}_j . Entretanto, ao invés de se trabalhar com Z_j , é conveniente trabalhar com o vetor de rótulos \underline{Z}_j , onde a k -ésima posição do vetor é definida como zero, caso a observação \underline{X}_j não pertença a k -ésima componente da mistura, e um se a observação pertence ao k -ésimo componente da mistura.

Assim, \underline{Z}_j é distribuído segundo uma distribuição multinomial, consistindo de K categorias com probabilidades $\lambda_1, \dots, \lambda_K$, isso é:

$$\mathbb{P}(\underline{Z}_j = \underline{z}_j) = \lambda_1^{z_{1j}} \lambda_2^{z_{2j}} \times \dots \times \lambda_K^{z_{Kj}} \quad (3.3)$$

Na interpretação acima para um modelo de misturas, pode-se considerar que a formulação (3.2) representa uma situação na qual \underline{X}_j é amostrada de uma população \mathcal{X} composta por K grupos, G_1, \dots, G_K com as seguintes proporções $\lambda_1, \dots, \lambda_K$. No contexto de séries temporais, a interpretação que pode ser utilizada afirma que λ_k é a proporção de vezes que as observações recaem no regime k ao longo do tempo.

Se a densidade de \underline{X}_j no grupo G_k é dada por $f_k(\underline{x}_j)$ para $k = 1, \dots, K$ então a densidade de \underline{X}_j é uma mistura de K distribuições, ponderada pelas proporções de cada grupo.

Em finanças, fontes de heterogeneidade são, muitas vezes, consideradas como: regimes de mercado, tipos de setores industriais nos quais a firma opera, características da estrutura de capital da organização, região geográfica, risco, etc. Dessa forma, um conjunto de dados observados pode ser segmentado em K grupos heterogêneos (ou regimes), onde cada grupo é um componente da mistura finita de distribuições.

3.2 Estimação de misturas de distribuições.

McLachlan e Krishnan (1997) sugerem que, em muitas aplicações, as densidades $f_k(\underline{x}_j)$ são especificadas de modo que pertençam a alguma família paramétrica. Neste caso, as densidades componentes são parametrizadas tal que $f_k(\underline{x}_j; \underline{\theta}_k)$, onde $\underline{\theta}_k$ é o vetor de parâmetros desconhecidos para a k -ésima componente da mistura. A densidade da mistura $f(\underline{X}_j)$ pode então ser escrita como:

$$f(\underline{x}_j; \underline{\Psi}) = \sum_{k=1}^K \lambda_k f_k(\underline{x}_j; \underline{\theta}_k) \quad (3.4)$$

onde o vetor $\underline{\Psi}$ contendo todos os parâmetros desconhecidos no modelo de mistura pode ser escrito como:

$$\underline{\Psi} = \left(\lambda_1, \dots, \lambda_{K-1}, \underline{\xi}^T \right)^T \quad (3.5)$$

e $\underline{\xi}$ é o vetor que contém todos os parâmetros para $\theta_1, \dots, \theta_K$ considerados, *a priori*, distintos. Define-se também Ω o espaço paramétrico associado a $\underline{\Psi}$. Uma vez que as proporções da mistura somam um, um dos pesos é considerado redundante, pois pode ser obtido pela presença dos outros $K - 1$ pesos.

Usualmente, os parâmetros do modelo de misturas podem ser obtidos por meio de Máxima Verossimilhança (MV). Com essa abordagem a estimativa do vetor de parâmetros d -dimensional $\underline{\Psi}$ para a densidade $f(x_j; \underline{\Psi})$, associado ao vetor aleatório \underline{X}_j , é estimado por $\hat{\underline{\Psi}}$, o qual pode ser obtido pelas seguintes equações:

$$\frac{\partial L(\underline{\Psi})}{\partial \underline{\Psi}} = \underline{0} \quad (3.6)$$

ou equivalentemente

$$\frac{\partial \mathcal{L}(\underline{\Psi})}{\partial \underline{\Psi}} = \frac{\partial \log [L(\underline{\Psi})]}{\partial \underline{\Psi}} = \underline{0} \quad (3.7)$$

onde $L(\underline{\Psi})$ é a função de verossimilhança escrita no caso de independência como:

$$L(\underline{\Psi}) = \prod_{j=1}^n f(x_j; \underline{\Psi}) \quad (3.8)$$

O objetivo da estimativa MV, segundo Lehmann (1980) e Lehmann e Casella (1998), é determinar uma estimativa para a amostra, definida como $\hat{\underline{\Psi}}$, de modo que essa defina uma sequência de raízes da equação de verossimilhança (ou log-verossimilhança) que seja consistente e assintoticamente eficiente. Essa sequência existe sob certas condições de regularidade (CRAMER, 1999). Dessa forma, a estimativa obtida corresponde ao máximo local do espaço paramétrico Ω com probabilidade tendendo a um.

Para modelos de estimação em geral, a verossimilhança usualmente possui um máximo global no interior do espaço paramétrico. Uma vez definida a estrutura da função de verossimilhança, o próximo passo é a sua maximização. O ponto que maximiza globalmente a função de verossimilhança é dado por $\hat{\underline{\Psi}}$ e representa o conjunto de estimativas mais “prováveis” ou “verossímeis” de ocorrer dada a amostra observada.

Em algumas situações, podem existir diversos máximos locais ou não existir máximo global. Especificamente, em modelos de mistura, há alguns casos em que o espaço associado à função de verossimilhança é ilimitado e ou possui diversos máximos locais, o que induz a certo grau de

dificuldade no processo de estimação dos parâmetros. Nesse contexto, o algoritmo de otimização *Simulated Annealing* de Belisle (1992) pode ser útil no auxílio dessas questões. Esse algoritmo é discutido na seção 3.4.

3.2.1 Matriz de informação de Fisher.

Após serem obtidas estimativas para o modelo paramétrico definido, é fundamental a mensuração da significância estatística dessas estimativas, isso pode ser realizado por meio da matriz de informação de Fisher e, conseqüentemente, por meio da matriz de variâncias e covariâncias das estimativas.

A matriz de informação esperada de Fisher para o vetor de parâmetros $\underline{\Psi}$ é definida como:

$$I(\underline{\Psi}) = \mathbb{E}_{\underline{\Psi}} \left[S(\mathbf{X}; \underline{\Psi}) S^T(\mathbf{X}; \underline{\Psi}) \right] \quad (3.9)$$

onde $S(\mathbf{X}; \underline{\Psi})$ é a estatística escore definida como:

$$S(\mathbf{x}; \underline{\Psi}) = \frac{\partial \log [L(\underline{\Psi})]}{\partial \underline{\Psi}} \quad (3.10)$$

o qual nada mais é do que o vetor gradiente da função de log-verossimilhança e $\mathbf{x} = (x_1^T, \dots, x_n^T)$ contém os dados observados.

Sob condições de regularidade (CASELLA; BERGER, 2001), $I(\underline{\Psi})$ pode ser expressa como:

$$I(\underline{\Psi}) = \mathbb{E}_{\underline{\Psi}} \left[I(\underline{\Psi}; \mathbf{X}) \right] \quad (3.11)$$

onde

$$I(\underline{\Psi}; \mathbf{X}) = - \frac{\partial^2 \log [L(\underline{\Psi})]}{\partial \underline{\Psi} \partial \underline{\Psi}^T} \quad (3.12)$$

a qual é o negativo da matriz Hessiana da função de log-verossimilhança. Já a matriz de informação observada é definida substituindo os parâmetros por suas respectivas estimativas. Em outras palavras, a matriz de informação de Fisher observada é dada por $I(\hat{\underline{\Psi}}; \mathbf{X})$.

A matriz de covariância assintótica da estimativa de máxima verossimilhança $\hat{\underline{\Psi}}$ é igual ao

inverso da matriz de informação de Fisher esperada $I(\underline{\Psi})$, a qual pode ser aproximada por $I(\hat{\underline{\Psi}})$, dessa forma, o erro-padrão de $\hat{\underline{\Psi}}_r = (\hat{\underline{\Psi}})_r$ é dado por:

$$EP(\hat{\underline{\Psi}}_r) \approx \left[I(\hat{\underline{\Psi}})^{-1} \right]_{rr}^{\frac{1}{2}} \quad (3.13)$$

para $r = 1, \dots, d$ onde d é o tamanho do vetor de parâmetros e as notações $(\mathbf{X})_{rl}$, $(\underline{X})_r$ representam respectivamente: o elemento associado à linha r e coluna l da matriz \mathbf{X} e r -ésimo elemento do vetor \underline{X} .

É comum, na prática, estimar o inverso da matriz de covariância do estimador de máxima verossimilhança por meio da matriz de informação observada $I(\hat{\underline{\Psi}})$, ao invés da matriz de informação esperada $I(\underline{\Psi})$ avaliada em $\underline{\Psi} = \hat{\underline{\Psi}}$, além disso, por meio dessa abordagem, a matriz de informação observada é mais conveniente de usar do que a matriz de informação esperada, uma vez que não requer o cômputo do valor esperado (EFRON; HINKLEY, 1978).

3.3 Algoritmo EM

A estimação dos parâmetros em um modelo de mistura é usualmente obtida por meio do Algoritmo EM (*Expectation-maximization Algorithm*). Considere a forma:

$$f(\underline{x}_j; \underline{\Psi}) = \sum_{k=1}^K \lambda_k f_k(\underline{x}_j; \underline{\theta}_k) \quad (3.14)$$

para uma amostra observada $\mathbf{x} = (\underline{x}_1^T, \dots, \underline{x}_n^T)$. O vetor $\underline{\Psi} = (\lambda_1, \dots, \lambda_{K-1}, \underline{\xi}^T)^T$ é o vetor contendo todos os parâmetros desconhecidos neste modelo de mistura e $\underline{\xi}$ é o vetor contendo todos os parâmetros em $\underline{\theta}_1, \dots, \underline{\theta}_K$. A estimação direta pode ser realizada por meio do sistema de equações:

$$\frac{\partial \mathcal{L}(\underline{\Psi})}{\partial \underline{\Psi}} = \frac{\partial \log [L(\underline{\Psi})]}{\partial \underline{\Psi}} = \underline{0} \quad (3.15)$$

utilizando alguma álgebra, o estimador de máxima verossimilhança de $\underline{\Psi}$ pode ser manipulado

de modo que $\hat{\Psi}$ satisfaça:

$$\hat{\lambda}_k = \sum_{j=1}^n \tau_k(\underline{x}_j; \hat{\Psi})/n \quad (3.16)$$

para $k = 1, \dots, K$ e também:

$$\sum_{k=1}^K \sum_{j=1}^n \tau_k(\underline{x}_j; \hat{\Psi}) \frac{\partial f_k(\underline{x}_j; \hat{\theta}_k)}{\partial \xi} = \underline{0} \quad (3.17)$$

onde

$$\tau_k(\underline{x}_j; \hat{\Psi}) = \frac{\lambda_k f_k(\underline{x}_j; \hat{\theta}_k)}{\sum_{h=1}^K \lambda_h f_h(\underline{x}_j; \hat{\theta}_h)} \quad (3.18)$$

é a probabilidade, *a posteriori*, de que \underline{X}_j pertença ao componente k da mistura (MCLACHLAN; KRISHNAN, 1997).

Estas manipulações foram utilizadas por vários pesquisadores no passado (como por exemplo, Wu (1983), Jordan (1994) e Demos e Sentana (1998)), em seus esforços para resolver a equação de probabilidade em modelos de mistura com densidades específicas. Utilizando essas formulações é possível a estimação do vetor de parâmetros $\hat{\Psi}$ de maneira iterativa.

Considere uma primeira proposta para $\hat{\Psi}$ representada por $\hat{\Psi}^{(0)}$. Uma nova proposta para $\hat{\Psi}$ dita $\hat{\Psi}^{(1)}$ pode ser obtida utilizando as equações (3.15) a (3.18). Essas iterações são então realizadas até que o algoritmo convirja. Essa técnica é conhecida como Algoritmo EM e foi proposta inicialmente por Dempster, Laird e Rubin (1977), com o intuito de encontrar soluções para as equações apresentadas em (3.15). A aplicação do algoritmo EM para o problema mistura revela de maneira direta a existência de um método iterativo, o qual é utilizado para o cômputo das estimativas dos parâmetros.

A construção teórica do Algoritmo EM para modelos de mistura é iniciado por meio de uma abordagem de variáveis latentes presentes ao conjunto de dados $\mathbf{x} = (\underline{x}_1^T, \dots, \underline{x}_n^T)$. Considere a existência das seguintes variáveis $\mathbf{z} = (\underline{z}_1^T, \dots, \underline{z}_n^T)$. Neste quadro, cada elemento \underline{x}_j é conceituado como tendo surgido de um dos componentes do modelo de mistura apresentado em (3.5), assim, \underline{z}_j é um vetor K -dimensional com $z_{kj} = (\underline{z}_j)_k$ igual a um ou igual a zero, de acordo com \underline{x}_j identificando, assim, se aquela observação é oriunda do componente k da mistura, para

$k = 1, \dots, K$ e $j = 1, \dots, n$.

O vetor completo de dados é, portanto, definido como:

$$\mathbf{x}_c = (\mathbf{x}, \mathbf{z}) \quad (3.19)$$

Os vetores $\underline{z}_1, \dots, \underline{z}_n$ são considerados valores amostrados do conjunto de vetores aleatórios $\underline{Z}_1, \dots, \underline{Z}_n$, os quais possuem distribuição multinomial. Por meio dessa suposição, a log-verossimilhança completa dos dados para $\underline{\Psi}$ é dada por:

$$\log L_c(\underline{\Psi}) = \sum_{k=1}^K \sum_{j=1}^n z_{kj} \left\{ \log(\lambda_k) + \log[f_k(\underline{x}_j; \underline{\theta}_k)] \right\} \quad (3.20)$$

Note que o Algoritmo EM pode ser tratado como um método de imputação de dados em problemas do tipo *missing data*. Dessa forma, esse algoritmo pode ser dividido em duas etapas, a saber: passo E (esperança) e passo M (maximização). Os quais são descritos a seguir.

3.3.1 Passo E.

A adição de variáveis latentes para o problema representados por \underline{z}_j é tratada pelo passo E, o qual toma a esperança condicional da log-verossimilhança completa dos dados, $\log L_c(\underline{\Psi})$ dado o conjunto de dados observados \mathbf{x} , usando para isso o ajuste corrente para o vetor de parâmetros $\underline{\Psi}$.

Seja $\underline{\Psi}^{(0)}$ um ajuste inicial para $\underline{\Psi}$, então, na primeira iteração do algoritmo EM, o passo E requer o cálculo da esperança condicional de $\log L_c(\underline{\Psi})$ dado \mathbf{x} , usando como uma aproximação para $\underline{\Psi}$ o vetor aproximado $\underline{\Psi}^{(0)}$, em outras palavras:

$$Q(\underline{\Psi}; \underline{\Psi}^{(0)}) = \mathbb{E}_{\underline{\Psi}^{(0)}} \left[\log L_c(\underline{\Psi}) | \mathbf{x} \right] \quad (3.21)$$

O operador de esperança $\mathbb{E}_{\underline{\Psi}^{(0)}}(\cdot)$ possui o subscripto $\underline{\Psi}^{(0)}$ com o intuito de transmitir explicitamente que esta esperança está sendo realizada utilizando $\underline{\Psi}^{(0)}$ para $\underline{\Psi}$. Assim, utilizando uma abordagem recursiva, tem-se que a l -ésima iteração do passo E requer o cômputo de $Q(\underline{\Psi}; \underline{\Psi}^{(l)})$, onde $\underline{\Psi}^{(l)}$ é o valor do vetor de parâmetros $\underline{\Psi}$ após a l -ésima iteração do Algoritmo EM.

Como a log-verossimilhança completa é linear nos dados não observáveis z_{ij} , o passo E na

$(l + 1)$ -ésima iteração simplesmente requer o cálculo da esperança condicionada de Z_{ij} dado a amostra observada \mathbf{x} , onde Z_{ij} é a variável aleatória correspondente a z_{ij} . Como:

$$\mathbb{E} [Z_{kj} | \mathbf{x}] = \mathbb{P} [Z_{kj} = 1 | \mathbf{x}] = \tau_k(\underline{x}_j; \underline{\Psi}^{(l)}) \quad (3.22)$$

onde, segundo (3.18):

$$\tau_k(\underline{x}_j; \underline{\Psi}) = \frac{\lambda_k^{(l)} f_k(\underline{x}_j; \underline{\theta}_k^{(l)})}{f_k(\underline{x}_j; \underline{\Psi}^{(l)})} = \frac{\lambda_k^{(l)} f_k(\underline{x}_j; \underline{\theta}_k^{(l)})}{\sum_{h=1}^K \lambda_h^{(l)} f_h(\underline{x}_j; \underline{\theta}_h^{(l)})} \quad (3.23)$$

para $k = 1, \dots, K$ e $j = 1, \dots, n$. A quantia $\tau_k(\underline{x}_j; \underline{\Psi})$ representa a probabilidade *a posteriori* do j -ésimo elemento da amostra, isso é, \underline{x}_j pertencer ao k -ésimo componente da mistura. Usando (3.22) e tomando a esperança condicional de (3.20), dado que \mathbf{x} tem-se:

$$Q(\underline{\Psi}; \underline{\Psi}^{(l)}) = \sum_{k=1}^K \sum_{j=1}^n \tau_k(\underline{x}_j; \underline{\Psi}^{(l)}) \left[\log(\lambda_k) + \log f_k(\underline{x}_j; \underline{\theta}_k) \right] \quad (3.24)$$

3.3.2 Passo M.

O passo M na $(l + 1)$ -ésima iteração requer a maximização global de $Q(\underline{\Psi}; \underline{\Psi}^{(l)})$ dada em (3.24), com respeito a $\underline{\Psi}$ sobre o espaço paramétrico Ω , fornecendo assim uma estimativa atualizada para $\underline{\Psi}$ representada por $\underline{\Psi}^{(l+1)}$. Para o modelo de mistura finita, as estimativas atualizadas $\lambda_k^{(l+1)}$ para as proporções λ_k são calculadas independentemente das estimativas atualizadas $\xi_{\underline{\zeta}}^{(l+1)}$ para $\underline{\zeta}$ contendo os parâmetros desconhecidos da densidade de probabilidade.

Se existe alguma estimativa para z_{ij} , essa é considerada observada. Logo, a estimativa de máxima verossimilhança para λ_k é dada simplesmente por:

$$\hat{\lambda}_k = \sum_{j=1}^n \frac{z_{ij}}{n}, \text{ para } j = 1, \dots, n. \quad (3.25)$$

Como o passo E envolve simplesmente a substituição de cada z_{ij} pela sua esperança condi-

cional corrente dada por $\tau_k(\underline{x}_j; \underline{\Psi}^{(l)})$, obtendo:

$$\hat{\lambda}_k^{(l+1)} = \sum_{j=1}^n \tau_k(\underline{x}_j; \underline{\Psi}^{(l)})/n, \text{ para } k = 1, \dots, K. \quad (3.26)$$

Assim, na formação da estimativa para $\hat{\lambda}_k$ na $(l+1)$ -iteração, há uma contribuição de cada elemento amostral x_j igual à sua probabilidade *a posteriori* (atualmente avaliada) da adesão do k -ésimo componente no modelo de mistura. Dessa forma, a utilização do Algoritmo EM tem uma interpretação intuitivamente atraente.

A atualização do vetor $\underline{\xi}$ no passo M para a $(l+1)$ -ésima iteração pode ser visto de (3.24) que é a estimativa $\underline{\xi}^{(l+1)}$ por meio da solução do seguinte sistema de equações:

$$\sum_{k=1}^K \sum_{j=1}^n \tau_k(\underline{x}_j; \underline{\Psi}^{(l)}) \frac{\partial}{\partial \underline{\xi}} \log \left[f_k \left(\underline{x}_j; \underline{\theta}_k \right) \right] = \underline{0} \quad (3.27)$$

Os passos E e M são realizados até que a diferença $L(\underline{\Psi}^{(l+1)}) - L(\underline{\Psi}^{(l)})$ atinja uma precisão arbitrariamente pequena. Dempster, Laird e Rubin (1977) mostrou que as verossimilhança obtidas nas iterações são não-decrescentes, isso é, $L(\underline{\Psi}^{(l+1)}) \geq L(\underline{\Psi}^{(l)})$ para $l = 0, 1, 2, \dots$. Caso a verossimilhança seja limitada superiormente, o Algoritmo EM sempre convergirá.

Dempster, Laird e Rubin (1977) também indicaram que se a condição fraca de que $Q(\underline{\Psi}; \underline{\phi})$ é contínua para ambos $\underline{\Psi}, \underline{\phi}$ então L^* será um máximo local de $L(\underline{\Psi})$, desde que a sequência não esteja presa em algum ponto de sela. Para evitar situações nas quais o algoritmo fique preso em pontos de sela, o algoritmo *Simulated Annealing* de Belisle (1992) é frequentemente usado.

3.4 Simulated Annealing.

Segundo Laarhoven e Aarts (1987), *Annealing* (recozimento) é o processo metalúrgico de aquecimento de um sólido e, depois, um lento resfriamento até que este cristalize. Os átomos desses sólidos apresentam alta energia quando aquecidos. Isso fornece aos átomos uma liberdade na sua capacidade de se reestruturar e, à medida que a temperatura é reduzida, a energia desses átomos diminui até que um estado de mínima energia seja alcançado.

Em um contexto de otimização, o algoritmo *Simulated Annealing* (SA), também, chamado de algoritmo *Monte Carlo Annealing*, algoritmo *probabilistic hill climbing*, algoritmo *statistical*

cooling ou ainda algoritmo *stochastic relaxation*, procura imitar esse processo. O SA começa com uma “temperatura” muito alta, onde os valores de entrada estão autorizados a assumir uma grande variedade de valores. À medida que o algoritmo continua com seu processo de otimização é permitido que a “temperatura” venha a cair. Isso restringe o grau de variabilidade nos valores de entrada. Esse processo, muitas vezes, leva o algoritmo a uma solução melhor, assim como no caso do processo físico que lida com um metal, esse atinge uma melhor estrutura de cristal através do processo de recozimento.

Com isso, enquanto a temperatura está sendo diminuída, mudanças são produzidas nas entradas, originando sucessivas melhores soluções e um conjunto ideal de valores de entrada quando a “temperatura” está perto de zero. O SA pode ser usado para localizar o mínimo de uma função objetivo e, conseqüentemente, os valores de entrada que minimizam essa função.

A principal característica do algoritmo SA é a capacidade de evitar que se fique preso em mínimos locais, como no algoritmo de *Newton-Raphson*. Isso é feito permitindo ao algoritmo aceitar não somente as melhores soluções, mas também as piores soluções com uma dada probabilidade. A principal desvantagem, a qual é compartilhada pelos algoritmos de busca local estocástica, é que a definição de alguns parâmetros de controle como a temperatura inicial, taxa de resfriamento, número de iterações e a precisão desejada são subjetivas (CHIBANTE, 2010).

A estrutura geral do algoritmo pode ser representada pelo seguinte fluxograma:

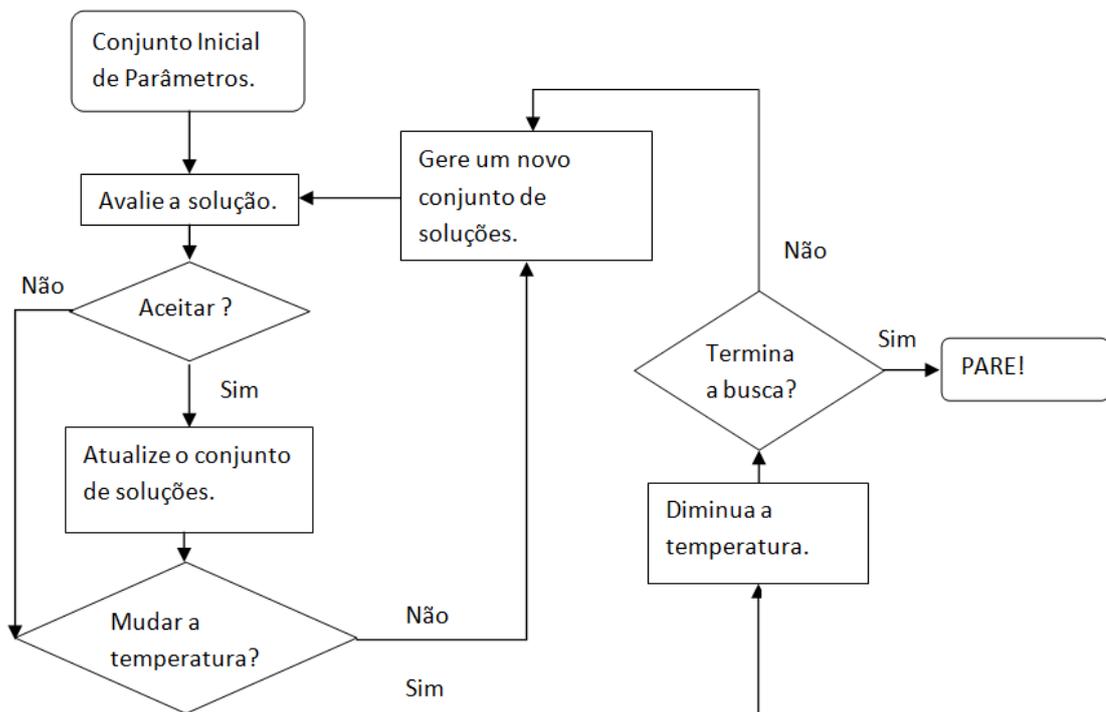


Figura 3.1: Fluxograma do Algoritmo SA.
Adaptado de Chibante (2010), pág. 2.

Segundo Aarts e Korst (1988), o algoritmo SA pode ser considerado um algoritmo da classe *Metropolis*. Algoritmos dessa classe são baseados na técnica de *Monte Carlo*, os quais geram uma sequência de estados para uma determinada função objetivo da seguinte maneira: dado um estado corrente i de uma função objetivo com energia E_i , então, o estado subsequente j é gerado aplicando um mecanismo de perturbação (usualmente estocástico), o qual transforma o estado corrente em um próximo estado com uma pequena distorção, a energia do novo estado é então definida por E_j .

Caso a diferença entre as energias $E_j - E_i$ seja menor ou igual a zero, então, o estado j é aceito como o novo estado; caso essa diferença seja maior do que zero, o estado j é aceito com base na seguinte probabilidade:

$$\exp\left(\frac{E_i - E_j}{\kappa_B T}\right) \quad (3.28)$$

onde T denota a temperatura e κ_B é a constante física de *Boltzmann*. A regra de aceitação definida anteriormente é denominada critério *Metropolis* e o algoritmo em sua forma geral é denominado algoritmo *Metropolis*.

Caso a temperatura do processo seja lentamente reduzida o suficiente, a solução obtida

atinge um equilíbrio no ponto de mínimo. No algoritmo, isso é alcançado através da geração de um grande número de transações para uma dada temperatura. Esse equilíbrio termal é caracterizado pela distribuição de *Boltzmann*, essa distribuição fornece a probabilidade de uma função objetivo estar em um estado i com energia E_i e temperatura T é representado matematicamente por:

$$\mathbb{P}_T(X = i) = \frac{1}{Z(T)} \exp\left(-\frac{E_i}{\kappa_B T}\right) \quad (3.29)$$

onde X é uma variável aleatória denotando o estado corrente da função objetivo. $Z(T)$ é definido como:

$$Z(T) = \sum_j \exp\left(-\frac{E_j}{\kappa_B T}\right) \quad (3.30)$$

onde a soma é realizada para todos os possíveis estados. Belisle (1992) assinala que, sob certas condições, a sequência de estados gerados por estes algoritmos converge em probabilidade para o mínimo global da função, fornecendo assim embasamento para a utilização do algoritmo SA na estimação de problemas de misturas onde há a presença de vários mínimos (máximos) locais.

3.4.1 Simulated Annealing na estimação de misturas GARCH.

Quanto aos aspectos computacionais o algoritmo de *Simulated Annealing* utilizado no desenvolvimento das aplicações realizadas nessa tese foi o disponível no *software* R para o pacote *maxLik* desenvolvido por Henningsen e Toomet (2010).

A parametrização utilizada para a função *maxSANN* oriunda do pacote *maxLik* foi a mesma disponível no formato padrão, qual seja: número de iterações igual a 10000, tolerância de convergência dos parâmetros igual a 10^{-8} e parâmetro de temperatura inicial igual a 10.

Como o algoritmo EM consiste de dois passos, a convergência do algoritmo EM foi definida pela diferença entre os valores das funções de log-verossimilhança completas obtidas nos passos l e $l + 1$, em outras palavras:

$$\delta = |\log L_c(\Psi)^l - \log L_c(\Psi)^{l+1}| < 0.1 \quad (3.31)$$

Como realçado por Chibante (2010) a principal desvantagem, a qual é compartilhada pelos

algoritmos de busca local estocástica como Algoritmos Genéticos e *Simulated Annealing*, por exemplo, é que a definição dos parâmetros de controle como a temperatura inicial, número de iterações e tolerância admitida são subjetivas.

O próximo capítulo (capítulo 4) descreverá o método desenvolvido nessa tese e utilizará o que foi apresentado até aqui como ferramenta no processo de estimação.

4 MISTURAS DE MODELOS GARCH.

Dentre os textos que surgiram posteriormente à proposta inicial de Haas (2004), nenhum utilizou essa ferramenta para a análise e estimação de efeitos sobre anúncios corporativos. Motivando assim o desenvolvimento de um modelo que seja capaz de suprir esse *gap* metodológico. As abordagens apresentadas até então consistiam em aplicações do modelo MN-GARCH (como Alexander e Lazar (2009)) e expansões metodológicas da construção de Haas (2004) (como Cheung e Chung (2011)), essa tese no entanto, apresenta além de um modelo específico para Testes de Eventos por meio de misturas GARCH, dois ensaios envolvendo essa metodologia e uma aplicação aos principais índices financeiros mundiais.

Bentarzi e Hamdi (2008), por sua vez, propuseram o modelo *Mixture Periodically Correlated Autoregressive Conditionally Heteroskedastic* (MPARCH). A estrutura proposta pelos autores incorpora as principais ideias de Haas (2004) em um modelo ARCH com correlação periódica, adequando assim o modelo à presença de alta curtose, *outliers* e caudas pesadas, ao mesmo tempo em que é capaz de capturar a periodicidade exibida na estrutura da autocovariância. O segundo e o quarto momentos do modelo foram obtidos em uma forma fechada e a estimação foi realizada por meio do Algoritmo EM, os autores concluem que o modelo MPARCH é capaz de ajustar-se aos dados reais, mas não comprovam qualquer superioridade em relação ao MN-GARCH.

Haas, Mittnik e Paoletta (2009) propõem uma generalização multivariada assimétrica para a classe de modelos MN-GARCH. Os autores apresentam questões sobre a parametrização, processo de estimação, condições para a estacionariedade e a existência do quarto momento também é discutida. Essa proposta é uma expansão do modelo proposto pelo autor, em 2004, e apresenta bons resultados para a mensuração do Valor de Risco (VaR) para o conjunto de dados utilizado.

Rombouts e Bouaddi (2009), com o intuito de adequar sua proposta aos fatos estilizados de séries temporais financeiras de alta frequência com precisão e parcimônia, apresentam uma mistura finita de distribuições com potência exponencial (similar nas caudas à família de dis-

tribuições estáveis), onde cada componente apresenta heteroscedasticidade condicional assimétrica. Os autores apresentam as condições para a estacionariedade fraca e a forma para o momento incondicional de quarta ordem. Esse modelo é aplicado pelos autores para os retornos dos índices Dow Jones e NASDAQ. Rombouts e Bouaddi (2009) encontram evidência, para o conjunto de dados utilizados, que uma mistura de dois componentes do modelo com potência exponencial e variância heterocedástica supera o modelo MN-GARCH com mais componentes e mais parâmetros.

Alexander e Lazar (2009) argumentam que o modelo GARCH tradicional identifica somente um mecanismo responsável pelo processo gerador da volatilidade nas séries financeiras usuais, além de possuir momentos de ordem superior constantes ao invés desses serem modelados explicitamente. Dessa forma, o modelo GARCH usual não é capaz de capturar a dependência da volatilidade na presença de estados ou regimes nem modelam a assimetria frequentemente presente. Segundo Alexander e Lazar (2009), os modelos do tipo *Markov switching* (MS) especificam diversos estados (regimes) com assimetria e curtose condicionais, os autores afirmam, ainda, que, dessa classe de modelos, aquele que apresenta maior facilidade de estimação é o modelo MN-GARCH de Haas (2004), o qual possui probabilidade de estado constante. Alexander e Lazar (2009) adicionam ao modelo MN-GARCH uma dependência de estados com o intuito de modelar mais precisamente o efeito de alavancagem, utilizando para o estudo empírico um conjunto de índices europeus. Os autores concluem que o modelo MN-GARCH com adequação ao efeito de alavancagem revela melhor ajuste quando comparado a outros 15 modelos de volatilidade condicional.

Galeano e Ausin (2010) propõem um modelo multivariado autorregressivo com heteroscedasticidade condicional generalizada em que as volatilidades condicionais individuais seguem uma distribuição condicional exponencial autorregressiva heteroscedasticidade generalizada e os resíduos seguem uma mistura de distribuições normais. Inferências sobre os parâmetros do modelo e previsão de volatilidades futuras são abordadas por meio de máxima verossimilhança e estimação Bayesiana. Os autores obtêm estimativas para o Valor de Risco de uma dada carteira e a alocação ótima da carteira é obtida seguindo as especificações propostas. Os autores descrevem o bom desempenho da metodologia proposta através de simulações de Monte Carlo por meio da análise dos preços de fechamento dos índices Dow Jones e NASDAQ.

Aknouche e Rabehi (2010) propõem uma classe não linear de modelos para séries temporais em que o processo gerador dos dados segue uma mistura finita de distribuição. A mistura surge na distribuição condicional do processo, a qual é proposta como uma mistura finita de distribuições normais com especificações bilineares. Segundo os autores, esta classe é destinada

a capturar as características especiais de séries temporais, como cauda pesada, multimodalidade, assimetria e mudança de regime. Os autores apresentam propriedades estatísticas associadas ao modelo como a estacionariedade estrita e de segunda ordem, ergodicidade, estrutura de covariância, existência de momentos de ordem superior, comportamento da cauda e invertibilidade. Aknouche e Rabehi (2010) estimam os parâmetros do modelo por meio do Algoritmo EM e concluem que negligenciar a representação bilinear dos dados pode ocasionar uma perda da adequação do modelo.

Ostermark (2010) coloca um processo de estimação para um modelo vetorial autorregressivo com heterocedasticidade cujos erros seguem uma mistura de distribuições normais, para isso o autor combina as técnicas de estimação de mínimos quadrados em dois estágios e o Algoritmo EM, esse procedimento incorpora tanto a identificação das características paramétricas como a própria estimação dos parâmetros do modelo e utiliza algoritmos genéticos para a minimização (maximização) das funções objetivo. O autor argumenta que essa abordagem não requer um conhecimento *a priori* das densidades normais, além de indicar que o algoritmo apresenta uma boa performance na adequação dos dados estudados.

Haas (2010) introduz um modelo de mistura normal assimétrica e de característica *Markov-switching* com o intuito de capturar a assimetria presente na distribuição dos retornos das ações. Conforme o autor, a classe de modelo é motivada pelo fato, usual, da assimetria presente em séries financeiras. As propriedades dinâmicas do processo são derivadas pelo autor e seu desempenho é comparado com respeito a vários modelos concorrentes para três principais bolsas europeias durante um período que abrange, inclusive, a recente turbulência financeira. O autor conclui que o modelo proposto, em geral, possui um desempenho superior aos demais modelos de volatilidade condicional.

Cheung e Chung (2011) desenvolvem uma análise exploratória para uma classe de modelos de memória longa em que os resíduos seguem uma mistura finita de modelos GARCH. Os autores utilizam o método de Monte Carlo para mensurar o desempenho da proposta de série com memória longa em relação ao estimador de máxima verossimilhança. Cheung e Chung (2011) concluem que para dados de inflação o modelo apresentado supera os demais e é capaz de incorporar os fatos estilizados usuais nas séries financeiras.

Rombouts e Stentoft (2011) consideram a precificação de opções utilizando modelos multivariados para retornos de ativos. Especificamente, os autores utilizam da estrutura de Haas (2004) com o intuito de elaborar um modelo para a precificação de opções financeiras o qual incorpora os principais fatos estilizados em finanças.

4.1 Modelo MN-GARCH.

O modelo MN-GARCH, proposto por Haas (2004), possui algumas características que o aproximam à classe de modelos GARCH Markov-switching (MS-GARCH). A abordagem mais popular de modelos MS-GARCH é sugerida por Gray (1996), nesta proposta, o problema de dependência entre os caminhos é tratada diferentemente das propostas usuais, como MS-GARCH de Cai (1994) e Hamilton e Susmel (1994).

A distribuição condicional no modelo de Gray (1996) é uma mistura discreta de K distribuições, as quais são comumente consideradas como normais. Dessa forma, supõe-se que, em cada ponto do tempo, um dos componentes k da mistura gera uma observação para o retorno R_t , onde o processo que seleciona o componente real é uma cadeia de Markov oculta com K dimensões para o espaço de estados.

Dessa forma, o modelo MN-GARCH nada mais é do que uma generalização dos modelos do tipo MS-GARCH, onde cada componente da mistura é considerado um regime, população ou estado onde esses termos podem ser utilizados de forma intercambiável. A utilização desse tipo de modelo é motivada pela literatura, que considera que o mercado e, conseqüentemente, as organizações que o compõem estão sujeitas a diversos regimes.

Barsky e Long (1990) afirmam que o mercado é usualmente segmentado em dois regimes, a saber: *Bull Market* e o *Bear Market*. Esses regimes, segundo os autores, oscilam refletindo, assim, padrões de comportamento dos mercados financeiros, por isso, estudá-los é fundamental para a boa compreensão dos mercados financeiros.

Maheu e McCurdy (2000) descrevem um modelo de Markov-switching, o qual incorpora a dependência de duração para capturar a estrutura não linear para a volatilidade condicional dos retornos das ações. Maheu e McCurdy (2000) utilizam, então, duas possibilidades de regimes, a saber: regimes com retornos altos e estáveis (*Bull Market*) e regimes com retornos baixos e voláteis (*Bear Market*). O modelo utilizado por Maheu e McCurdy (2000) identifica todas as principais crises da bolsa de valores em mais de 160 anos, com dados mensais até a data do texto, em 2000. Os autores identificam que os regimes do tipo *Bull Market* possuem função de risco decrescente com altos retornos no início do regime, já o regime do tipo *Bear Market* apresenta a característica de aumento da volatilidade à medida que o mercado se mantém nesse estado.

Gonzalez et al. (2005) argumentam que poucos são os fenômenos econômicos que atraem mais atenção do que os regimes Bull Market e Bear Market, argumentam ainda que há um consenso de que os mercados *Bull* estão associados com preços das ações persistentemente cres-

cente, o interesse forte dos investidores e melhor bem-estar financeiro. Gonzalez et al. (2005) procuram por pontos de alteração dos regimes quando um mercado passa de *Bull Market* para *Bear Market*, entretanto mantendo seu interesse principal nas propriedades e identificabilidade do regime de alta.

Massey e Wu (2005) inferem que muitos decisores operam em um ambiente dinâmico, no qual a competição e as informações se alteram regularmente, desta forma, a habilidade de detectar e responder a essas mudanças de regime é essencial para o sucesso econômico de qualquer organização. Os autores estudaram as possíveis mudanças de regimes para séries temporais financeiras utilizando para isso abordagens paramétricas Bayesianas e não paramétricas.

Shiu-Sheng e Chen (2009) investigaram quais as possíveis variáveis macroeconômicas que ajudariam a explicar ou prever em qual regime de mercado determinado período se encontra, especificamente, os autores focalizaram atenção no regime do tipo *Bear Market* e concluíram que o conjunto de dados utilizados taxa de juros, taxas de inflação, taxas de desemprego, taxas dos fundos federais, dívida pública federal, dentre outras variáveis, contribuem para a previsibilidade do regime *Bear Market*, para isso, utilizaram métodos paramétricos e não paramétricos.

Utilizando uma estrutura de transição logística, Woodward e Anderson (2009) investigaram quanto os “betas” do portfólio de firmas industriais na Austrália diferem nos regimes *Bull Market* e *Bear Market*. O método denominado *Logistic Smooth Transition Market* (LSTM) permite determinar um parâmetro de corte que possibilita diferenciar entre os estados Bull Market e Bear Market. Os autores concluem que os “betas” são significativamente diferentes para cada um dos regimes considerados, realçando, assim, a importância da diferenciação entre as possíveis populações que compõem as séries temporais financeiras.

Dias, Vermunt e Ramos (2010) afirmam que modelos de misturas finitas têm se comprovado úteis para mensurar heterogeneidade não observada, os autores introduzem um modelo de Misturas em uma estrutura do tipo cadeias de Markov ocultas com o objetivo de incorporar as dimensões temporais e espaciais na previsibilidade da heterogeneidade, simultaneamente.

4.1.1 Estrutura.

A proposta de Haas (2004) considera que os resíduos ε_t de uma série temporal são gerados por K componentes normais em um modelo de mistura finita, seguindo um processo do tipo *GARCH*(P, Q), isso é, um modelo segue uma estrutura MN-GARCH se a distribuição

condicional de ε_t é uma mistura de distribuições normais com média zero tal que:

$$\varepsilon_t | \mathcal{F}_t \sim MN(\lambda_1, \dots, \lambda_K, \mu_1, \dots, \mu_K, \sigma_{1t}^2, \dots, \sigma_{Kt}^2) \quad (4.1)$$

onde \mathcal{F}_t é o conjunto informacional no tempo t , $\lambda_k \in (0, 1)$, $\sum_{k=1}^K \lambda_k = 1$ e $\mu_k = -\sum_{i=1}^{K-1} (\lambda_i / \lambda_k) \mu_i$. Além do mais, a estrutura da variância segue um processo $GARCH(P, Q)$ de forma que:

$$\underline{\sigma}_t^{(2)} = \underline{\alpha}_0 + \sum_{q=1}^Q \underline{\alpha}_q \varepsilon_{t-q}^2 + \sum_{p=1}^P \theta_p \underline{\sigma}_{t-p}^{(2)} \quad (4.2)$$

onde $\underline{\sigma}_t^{(2)} = (\sigma_{t1}^2, \dots, \sigma_{tK}^2)^T$ e $\underline{\alpha}_q = (\alpha_{q1}, \dots, \alpha_{qK})^T$, para $q = 1, \dots, Q$ são vetores de dimensão $K \times 1$ e θ_p para $p = 1, \dots, P$ é uma matriz diagonal $K \times K$ com elementos iguais a $\theta_{p1}, \dots, \theta_{pK}$.

Segundo, Haas (2004) as condições $\underline{\alpha}_0 > \underline{0}$, $\underline{\alpha}_q \geq \underline{0}$ e $\text{diag}(\theta_p) \geq \underline{0}$ para $q = 1, \dots, Q$ e $p = 1, \dots, P$ correspondem às condições de não negatividade de Bollerslev (1986) para o modelo $GARCH(P, Q)$ tradicional, além dessas condições, é necessário que $\sum_{q=1}^Q \underline{\alpha}_q + \sum_{p=1}^P \text{diag}(\theta_p) \leq \underline{1}$ para que o processo seja considerado estacionário. Essa estrutura combina a característica da volatilidade de reversão à média, isso é, a volatilidade persiste após um choque ou evento, mas, na ausência de quaisquer outros choques, a volatilidade retorna ao seu nível usual. A reversão à média é capturada pela estrutura $GARCH(P, Q)$, enquanto os pesos são as proporções de vezes que uma determinada observação tende a cair sobre os regimes ao longo do tempo.

4.1.2 Identificabilidade.

Uma pergunta que surge naturalmente na estimação de modelos de mistura é em quais condições o modelo é considerado identificável. Embora haja sempre a possibilidade de um modelo não ser identificável devido aos diversos regimes possíveis, a seguinte restrição no espaço paramétrico $\lambda_1 > \lambda_2 > \dots > \lambda_K$ é suficiente para evitar problemas de identificabilidade.

De maneira mais formal, Mclaughlan (2000) considera que para a estimação de um vetor de parâmetros Ψ , o qual, no caso do modelo MN-GARCH, é dado por

$$\underline{\Psi} = (\lambda_1, \dots, \lambda_{K-1}, \underline{\alpha}_0^T, \underline{\alpha}_q^T, \text{diag}(\theta_p))^T \quad (4.3)$$

para $q = 1, \dots, Q$, $p = 1, \dots, P$ e $k = 1, \dots, K$. Usualmente, o modelo é dito ser identificável se para uma família de densidades paramétricas $f(\underline{x}_j; \underline{\Psi})$ se valores distintos para $\underline{\Psi}$ produzem

membros distintos da família de densidade paramétrica. Matematicamente:

$$f(\underline{x}_j; \underline{\Psi}) = f(\underline{x}_j; \underline{\Psi}^*) \quad (4.4)$$

se e somente se $\underline{\Psi} = \underline{\Psi}^*$. Identificabilidade para misturas de distribuições é definida de forma um pouco diferente. Suponha que $f(\underline{x}_j; \underline{\Psi})$ tem duas densidades componentes, diga-se $f_i(\underline{x}_j; \underline{\theta}_i)$ e $f_h(\underline{x}_j; \underline{\theta}_h)$ que pertencem à mesma família paramétrica. Então (4.4) ainda é válida mesmo que os rótulos i e h sejam alterados dentro de $\underline{\Psi}$. Ou seja, embora esta classe de misturas possa ser identificável, $\underline{\Psi}$ não o é. De fato, se todas as densidades componentes k pertencem à mesma família paramétrica, então, $f(\underline{x}_j; \underline{\Psi})$ é invariante sob $K!$ permutações dos rótulos dos componentes.

Seja

$$f(\underline{x}_j; \underline{\Psi}) = \sum_{k=1}^K \lambda_k f_k(\underline{x}_j; \underline{\theta}_k) \quad (4.5)$$

e

$$f(\underline{x}_j; \underline{\Psi}^*) = \sum_{k=1}^{K^*} \lambda_k^* f_k(\underline{x}_j; \underline{\theta}_k^*) \quad (4.6)$$

quaisquer dois membros de uma família paramétrica de densidades de mistura. Esta classe de misturas finitas é dita ser identificável para $\underline{\Psi} \subset \Omega$ se

$$f(\underline{x}_j; \underline{\Psi}) \equiv f(\underline{x}_j; \underline{\Psi}^*) \quad (4.7)$$

se e somente se $K = K^*$ e pode-se permutar os rótulos dos componentes tal que:

$$\lambda_k = \lambda_k^* \text{ e } f(\underline{x}_j; \underline{\Psi}) = f(\underline{x}_j; \underline{\Psi}^*), \text{ para } k = 1, \dots, K \quad (4.8)$$

A ausência de identificabilidade de $\underline{\Psi}$ devido ao intercâmbio dos rótulos dos componentes é geralmente tratada pela imposição de uma restrição apropriada em $\underline{\Psi}$. Por exemplo, uma abordagem para evitar a ausência de identificabilidade é proposta por Aitkin e Rubin (1982), onde os autores impõem que:

$$\lambda_1 > \lambda_2 > \dots > \lambda_K \quad (4.9)$$

Uma maneira de escolher entre as diversas possibilidades de modelos de misturas com diferentes regimes e parâmetros é a utilização do Critério de Informação de Akaike.

4.1.3 Critério de Informação de Akaike.

O Critério de Informação Akaike é uma medida relativa da adequação do ajuste de um modelo estatístico. Embora a literatura em econometria e estatística proponha outros diversos critérios de informação como, por exemplo, Critério de Informação de Schwarz - BIC (SCHWARZ, 1978), Critério de Informação Akaike com correção para populações finitas - AICc (HURVICH; TSAI, 1989) e Critério de Informação de Hannan-Quinn - HQ (HANNAN; QUINN, 1979), há pouca concordância quanto a qual método é o ideal, principalmente em séries temporais.

Hannan e Quinn (1979) sugerem que o critério HQ deveria ser utilizado para a determinação da ordem de modelos autoregressivos, para modelos tipo ARMA Brockwell e Davis (2009) sugerem a utilização do Critério de Informação Akaike com correção para populações finitas - AICc. Devido a ausência de uma medida absoluta para a mensuração da possível perda de informação em modelos estatísticos e econométricos definiu-se como critério de informação a medida mais amplamente utilizada e bem conhecida na literatura, qual seja: o Critério de Informação Akaike.

Essa medida foi desenvolvida por Akaike (1974) sob o nome de AIC - *Akaike Information Criterion*. O método baseia-se no conceito de entropia da informação, oferecendo uma medida relativa da perda de informações quando um determinado modelo é usado para descrever a realidade.

De maneira geral, o AIC é definido por:

$$AIC = 2|\underline{\Psi}| - 2\log[L(\underline{\Psi})] \quad (4.10)$$

onde $|\underline{\Psi}|$ é o tamanho (quantidade de parâmetros) do espaço paramétrico e $\log(L(\underline{\Psi}))$ é a log-verossimilhança do modelo de interesse.

Dado um conjunto de modelos candidatos para os dados, o modelo preferido é o aquele com o valor mínimo do AIC. Dessa forma, o Critério de Informação de Akaike não recompensa somente a qualidade do ajuste (medida pela log-verossimilhança), mas, também, penaliza a crescente adição de parâmetros ao modelo, seguindo assim o princípio da parcimônia, no qual se define como “bons” modelos aqueles que apresentam um alto grau de ajuste em contraste com uma baixa quantidade de parâmetros.

O AIC é fundado na teoria da informação, especificamente, suponha que os dados são ger-

ados por algum processo desconhecido f . Considere dois modelos candidatos para representar f : g_1 e g_2 . Se o analista souber que f é o processo gerador dos dados, então, poderia encontrar a informação perdida ao utilizar g_1 ao invés de f por meio do cálculo da divergência de Kullback-Leibler, $DKL(f, g_1)$, similarmente, a informação perdida de usar g_2 para representar f seria encontrada através do cálculo de $DKL(f, g_2)$.

Em outras palavras assume-se que o adequamento de um modelo arbitrário $g_i(X)$ está associado a “distância” da “verdadeira” distribuição de probabilidade $f(X)$. Caso o processo f não esteja disponível, uma maneira seria, então, escolher o modelo g_1 ou g_2 que minimize a perda de informação. Onde:

$$DKL(f, g_i) = \int_{\chi} \log \left[\frac{f(x)}{g_i(x)} \right] dF(x) \quad (4.11)$$

a qual representa a informação perdida quando $g_i(x)$ é usado como aproximação para $f(x)$, onde $i = 1, 2$ e χ representa o espaço amostral da variável aleatória X .

Expandindo a integral de Riemann-Stieltjes (para o caso absolutamente contínuo) tem-se:

$$DKL(f, g_i) = \int_{\chi} \log [f(x)] f(x) dx - \int_{\chi} \log [g_i(x)] f(x) dx \quad (4.12)$$

Como o primeiro termo do lado direito da equação é uma constante que depende somente de g , pode-se comparar modelos utilizando somente:

$$- \int_{\chi} \log [g_i(x)] f(x) dx \quad (4.13)$$

A integral (4.13) pode ser estimada utilizando a função densidade (ou função massa de probabilidade) empírica, assim $\hat{g}(x_i) = 1/n$ para $i = 1, \dots, n$, logo (KONISHI; KITAGAWA, 2007):

$$\mathbb{E}_G [\widehat{\log(f(x))}] = \int \log f(x) d\widehat{G}(x) = \frac{1}{n} \sum_{i=1}^n \log f(x_i) \quad (4.14)$$

Pela lei dos grandes números:

$$\frac{1}{n} \sum_{i=1}^n \log f(x_i) \xrightarrow{\mathbb{P}} \mathbb{E}_G [\log f(x)] \quad (4.15)$$

quando $n \rightarrow \infty$.

Como a log-verossimilhança é dada por $n\mathbb{E}_G [\widehat{\log(f(x))}]$ essa pode ser usada para men-

surar o adequamento em relação ao processo gerador dos dados “correto”. Akaike (1974), no entanto, corrige esse estimador subtraindo o viés estimado:

$$-2 \left[\sum_{i=1}^n \log f(x_i) - \text{viés} \right] \quad (4.16)$$

onde o estimador do viés proposto por (AKAIKE, 1974) é igual ao número de parâmetros livres do modelo e segundo Akaike (1974) o critério é multiplicado por -2 “levando em conta razões históricas”.

Akaike (1974) mostrou que se pode estimar, via AIC, o quanto de informação é perdida ao utilizar g_1 ao invés de g_2 . Esse critério é utilizado para comparar modelos e, dessa forma, auxiliar na escolha do modelo que apresenta menor perda de informação, em outras palavras, escolher o modelo com melhor ajuste e menor quantidade de parâmetros que esteja o mais próximo da realidade o possível. Entretanto a estimativa é válida apenas assintoticamente, se o número de pontos de dados é pequeno, então, alguma correção é muitas vezes necessária. (HURVICH; TSAI, 1989)

Considere os valores AIC de R modelos candidatos, representados por AIC_1, \dots, AIC_R . Seja AIC_{min} o menor Critério de Informação de Akaike apresentado nesse conjunto de modelos candidatos. Então $\exp((AIC_{min} - AIC_i)/2)$ para $i = 1, \dots, R$ pode ser interpretado como a probabilidade relativa do i -ésimo modelo minimizar a perda de informação (estimada) (BURNHAM; ANDERSON, 2002).

Por exemplo, suponha que haja três modelos candidatos com valores de AIC iguais a 150, 151 e 160. Pode-se comparar os demais modelos propostos com base no modelo com menor AIC, ou seja, para o segundo modelo candidato tem-se $\exp((150 - 151)/2)$, o qual é 0,606 vezes mais provável do que o primeiro modelo para minimizar a perda de informações, e o terceiro modelo é $\exp((150 - 160)/2)$, o qual é 0,006 vezes mais provável do que o primeiro modelo para minimizar a perda de informação.

O Critério de Informação de Akaike é utilizado, neste texto, como uma ferramenta para escolha e comparação de modelos uma vez que o princípio da *Navalha de Occam* é seguido.

4.1.4 Adequamento do modelo MN-GARCH aos principais índices mundiais.

Uma pergunta que surge é: “o quão bom é o modelo MN-GARCH, em relação aos demais modelos concorrentes quanto a minimização da perda de informação?”. Em outras palavras,

qual é o grau de ajuste do modelo MN-GARCH sobre os retornos financeiros quando comparado com os demais modelos frequentemente utilizados em finanças ?

Com o intuito de responder a essa questão, essa subseção apresentará medidas de adequamento (*Goodness-of-fit*) para as propostas usuais de processo gerador dos dados em séries temporais financeiras.

Apesar dessa seção não estar ligada diretamente com os objetivos da tese, ela é necessária pois demonstra o quão bom o modelo MN-GARCH é ao se ajustar aos principais índices financeiros mundiais, motivando assim a utilização do método aqui desenvolvido e apresentado posteriormente na seção 4.2.

Especificamente, utilizando o sistema *Bloomberg*, um conjunto de índices financeiros foi coletado com o intuito de representar o mercado financeiro mundial, dessa forma, os seguintes indicadores foram estudados:

Tabela 4.1: Principais indicadores do mercado mundial.

Fonte: Elaboração do autor.

Índice	País	Região	Índice	País	Região
JALSH	Africa do Sul	África	KOSPI	Korea do Sul	Ásia
SPTSX	Canadá	América do Norte	KLSE	Malásia	Ásia
BATSK	Canadá	América do Norte	NZSE	Nova Zelândia	Ásia
DJI	EUA (Dow Jones)	América do Norte	SHCOMP	Tailândia	Ásia
CCMP	EUA (Nasdaq)	América do Norte	TWSE	Taiwan	Ásia
MERVAL	Argentina	América Latina	DAX	Alemanhã	Europa
IBOV	Brasil	América Latina	MADX	Espanha	Europa
IPSA	Chile	América Latina	CAC	França	Europa
MXX	México	América Latina	ASE	Grécia	Europa
AS51	Austrália	Ásia	BEL20	Países baixos	Europa
XAO	Austrália	Ásia	AEX	Países baixos	Europa
ATX	Austrália	Ásia	OSEAX	Países baixos	Europa
HSI	Hong Kong	Ásia	UKX	Reino Unido	Europa
SENSEX	Índia	Ásia	PX	República Checa	Europa
JCI	Indonésia	Ásia	OMX	Suécia	Europa
TA-100	Israel	Ásia	SMI	Suíça	Europa
NKY	Japão	Ásia	CF	Rússia	Europa/Ásia

O objetivo aqui é avaliar a adequação desses indicadores as seguintes propostas:

1. Distribuição normal.
2. Distribuição normal heterocedástica (GARCH).

3. Distribuição alfa-estável.

4. Misturas GARCH.

Cada um dos modelos propostos foi ajustado considerando o que é patente pelos fatos estilizados em finanças, isso é, o modelo GARCH é razoavelmente ajustado utilizando-se uma estrutura paramétrica do tipo $GARCH(1, 1)$ e a utilização de duas misturas é suficiente para o ajustamento de dados heterogêneos.

Dessa forma, a avaliação do grau de adequação realizada nessa subseção utilizou-se do Critério de Informação de Akaike (AIC) apresentado na subseção 4.1.3.

Tabela 4.2: Critério de Informação de Akaike para os índices mundiais.**Fonte:** Elaboração do autor.

Índice	Normal	GARCH	α -estável	MN-GARCH
AEX	19373,38	3,02	6,37	-16309,93
AS51	2348,78	4,95	5,58	-2305,17
ASE	21704,29	3,68	6,08	-19762,58
ATX	19116,1	3,14	6,35	-16725,17
BATSK	28,94	6,55	6,67	-1,1
BEL20	334,07	8,65	3,89	-278,25
CAC	19621,9	3,29	6,28	-17912,92
CCMP	20486,65	3,26	6,23	-17798,34
DAX	19948,21	3,28	6,26	-17665,74
DJI	16909,18	2,71	6,56	-14708,94
HSI	20998,61	3,55	6,15	-18803,09
IBOV	27392,24	4,52	5,61	-24145,45
INDEXCF	355,95	9,47	3,46	-333,97
IPSA	17392,97	2,91	6,47	-15649,49
JALSH	348,77	7,81	4,41	-284,92
JCI	19766,02	3,35	6,28	-16853,18
KLSE	432,39	8,53	3,87	-368,12
KOSPI	23008,36	3,64	6,08	-20848,45
MADX	439,66	8,05	4,09	-370,21
MERVAL	25391,37	4,33	5,74	-23184,03
MXX	17392,97	2,91	6,47	-15649,49
NKY	19979,82	3,51	6,19	-18512,47
NZSE	337,37	7,56	3,87	-304,07
OMX	20218,14	3,42	6,2	-18543,91
OSEAX	139,87	10,28	6,37	-98,03
PX	2565,04	6,13	5,03	-2258,99
SENSEX	20933,57	3,75	6,05	-19082,35
SHCOMP	178,52	10,65	2,99	-195,66
SMI	17627,22	2,89	6,48	-15169,84
SPTSX	16110,27	2,45	6,67	-13059,85
SPX	17454,56	2,75	6,52	-14815,43
TA-100	450,01	8,25	3,97	-411,09
TWSE	22776,47	3,65	6,09	-20630,33
UKX	17234,4	2,77	6,51	-15001,2
XAO	2348,78	4,95	5,58	-2305,17

É possível notar, com base na tabela 4.2, que o modelo de misturas GARCH (MN-GARCH) é superior aos demais modelos quando o critério utilizado é a minimização da perda de informação. Para o caso nacional, o indicador IBOV, associado ao mercado brasileiro, apresenta as seguintes probabilidades relativas do modelo MN-GARCH minimizar a perda de informação estimada:

Tabela 4.3: Verossimilhança relativa para o índice IBOV entre os principais processos geradores de dados utilizados em finanças.

Fonte: Elaboração do autor.

Modelo	Normal	GARCH	α-estável	MN-GARCH
Normal	1	0	0	0
GARCH	∞	1	1,7246	0
α-estável	∞	0,5798	1	0
MN-GARCH	∞	∞	∞	1

Nota-se que o modelo MN-GARCH, para o índice IBOV, é consistentemente aquele que minimiza a perda de informação dentre as opções consideradas, somente os modelos α -estável e GARCH são competitivos entre si, entretanto o modelo GARCH é aproximadamente 1,7 vezes mais provável de minimizar a perda de informação do que o modelo α -estável.

Cabe ressaltar que essa comparação somente é válida se as famílias de distribuição de probabilidade possuem a mesma parametrização (KONISHI; KITAGAWA, 2007). Essa questão é especialmente sensível para os modelos de aglomeração de volatilidade quando o parâmetro de escala é tratado como precisão e não dispersão (variabilidade), entretanto, ambos os modelos apresentados na tabela 4.3 possuem a mesma parametrização o que permite a comparação entre os modelos segundo critério de perda de informação como a medida AIC e, portanto, os dados apresentados nas tabelas 4.2 e 4.3 corroboram para a superioridade do modelo MN-GARCH frente aos outros modelos frequentemente utilizados em finanças, a saber: distribuição normal, GARCH e α -estável.

4.2 Proposta para estudo de eventos usando misturas GARCH.

Com base no que foi exposto anteriormente, é necessário o desenvolvimento e a utilização de modelos que incorporem os usuais fatos estilizados em finanças, e que esses mesmos modelos minimizem a perda de informação quando comparado a outros modelos candidatos. Dessa forma, a utilização de modelos no campo de Estudos de Eventos não deve seguir um caminho diferente.

Com o objetivo de propor uma metodologia paramétrica para a análise e estimação do efeito de anúncios de eventos, de maneira que essa metodologia incorpore os principais fatos estilizados em finanças, sugere-se que a abordagem paramétrica ideal deva considerar a presença de caudas pesadas, desvios da normalidade, aglomeração de volatilidades, além da possibilidade de inserção de regimes. Sugestão essa acatada no modelo desenvolvido nessa seção.

Todas essas características são adequadas por meio do modelo MN-GARCH, contudo, como a especificação desse modelo requer ainda o número de regimes e a dimensão das defasagens para os parâmetros autorregressivos e de médias móveis, considera-se o que foi apresentado no capítulo 2. O mercado financeiro pode ser segmentado razoavelmente em dois regimes, a saber: *Bear Market* e *Bull Market*. Ademais, a utilização de uma estrutura paramétrica na forma $GARCH(1, 1)$ é suficiente para ajustar e modelar adequadamente a frequente aglomeração de volatilidade presentes nas séries temporais financeiras.

É claro que essa proposta não é absoluta. Mas, seguindo o princípio norteador da *Navalha de Occam* (CRAWLEY, 2005), deseja-se a construção de modelos com a menor quantidade de parâmetros possíveis e o máximo de explicação. O ajustamento do modelo MN-GARCH, quando comparado aos demais modelos, é consistentemente superior. Assim, indicando que essa estrutura é ótima no sentido de minimizar o número de parâmetros envolvidos na estimação e maximizando a explicação (ou minimizando a perda de informação) quando utilizado.

Porém a abordagem usual de Haas (2004) não fornece a possibilidade para a avaliação e inferência de retornos associados a eventos em finanças corporativas, sendo, portanto, necessária uma nova proposta de modelo. Especificamente, considere que o mercado possa ser segmentado em dois regimes: *Bear Market* e *Bull Market*. Então, o número de misturas já determinado é igual a dois, um componente representando o mercado em alta e o outro componente representando o mercado em baixa. Uma questão que surge é, se a magnitude do efeito de anúncios de eventos é igual quando ocorre nesses dois regimes, uma resposta intuitiva (e que posteriormente é validada nessa tese por análises empíricas) é que essa magnitude é diferente dependendo da situação do mercado.

O efeito do anúncio em si só apresenta heterogeneidade que, de certa maneira, está relacionada ao regime de mercado em que o evento ocorre, ademais, a utilização de modelos lhanos, os quais não incorporam os principais fatos estilizados em finanças, pode levar o analista a uma inferência errônea. Como o modelo MN-GARCH tem apresentado bom desempenho na literatura estudada até o momento e motivado pelos resultados assinalados na tabela 4.2, pode-se considerar uma estrutura com dois regimes e que possua um núcleo similar ao modelo $GARCH(1, 1)$. Entretanto, cabe ressaltar que não é possível a generalização da qualidade de

ajuste do modelo MN-GARCH para outros dados e situações, uma vez que esses resultados se mostraram adequados somente ao conjunto de observações estudadas.

Considere que os retornos de uma série temporal financeira $R_{i\tau}$ para uma empresa i e período temporal τ sejam gerados por 2 componentes normais, em um modelo de mistura finita, seguindo um processo do tipo $GARCH(1,1)$, e que esses retornos possam ser afetados por efeitos de anúncios de eventos no período $1_{[T_1 < \tau \leq T_2]}(\tau)$ para o período de tempo associado ao evento, ou seja, $\tau = T_1 + 1, \dots, T_2$. Assim, uma estrutura geral para mensuração da magnitude do efeito de eventos em regimes diferenciados por meio de um modelo que incorpore os principais fatos estilizados em finanças pode ser dada por:

$$\mathbb{E}(R_{i\tau} | \mathcal{F}_\tau) = \mu_{k\tau} + \varepsilon_{i\tau} \quad (4.17)$$

de maneira que:

$$\varepsilon_i | \mathcal{F}_t \sim MN(\lambda_1, \lambda_2, \mu_1, \mu_2, \sigma_{1t}^2, \sigma_{2t}^2) \quad (4.18)$$

onde \mathcal{F}_t é o conjunto informacional no tempo t , $0 < \lambda_1, \lambda_2 < 1$, $\lambda_1 + \lambda_2 = 1$ e $\mu_{k\tau} = \beta_{0k} + \beta_{1k}X_{i\tau 1} + \dots + \beta_{pk}X_{i\tau p} + \gamma_k 1_{[T_1 < \tau \leq T_2]}(\tau)$ é o preditor linear, o qual pode seguir algum modelo como o CMRM, CAPM ou outro tal que γ_k represente a magnitude do efeito de anúncio ou evento corporativo no regime k . Esse parâmetro representará o efeito do evento focal dado condicionado ao regime em que esse evento se encontra, dessa maneira, diferenciando a magnitude do efeito em função do regime em que esse se encontra. É possível também a mensuração do efeito do evento focal no mercado como um todo, nesse caso, faz-se:

$$\gamma = \lambda_1 \gamma_1 + \lambda_2 \gamma_2 \quad (4.19)$$

A estrutura da variância segue um processo $GARCH(1,1)$ de forma que:

$$\underline{\sigma}_t^{(2)} = \underline{\alpha}_0 + \underline{\alpha}_1 \varepsilon_{t-1}^2 + \theta_1 \underline{\sigma}_{t-1}^{(2)} \quad (4.20)$$

onde $\underline{\sigma}_t^{(2)} = (\sigma_{1t}^2, \sigma_{2t}^2)^T$ e $\underline{\alpha}_1 = (\alpha_{11}, \alpha_{12})$, são vetores de dimensão 2×1 e θ_1 é uma matriz diagonal 2×2 com elementos iguais a θ_{p1} e θ_{p2} .

Essa estrutura paramétrica para o efeito de anúncios corporativos é capaz de modelar os principais fatos estilizados em finanças, além de incorporar a heterogeneidade presente em

dados financeiros, associada ao regime de mercado em que os dados se encontram.

4.2.1 Estimação pelo algoritmo EM.

A estimação do modelo de misturas é realizada então pelo Algoritmo EM (DEMPSTER; LAIRD; RUBIN, 1977). A estrutura completa do modelo é dada então por:

$$f(R_{i\tau}|\mathcal{F}_\tau) = \lambda_1 f_1(R_{i\tau}|\mathcal{F}_\tau) + \lambda_2 f_2(R_{i\tau}|\mathcal{F}_\tau) \quad (4.21)$$

onde:

$$f_k(R_{i\tau}|\mathcal{F}_\tau) = \left[2\pi \left(\alpha_{0k} + \alpha_{1k}\varepsilon_{\tau-1}^2 + \theta_{1k}\sigma_{k,\tau-1}^2 \right) \right]^{-\frac{1}{2}} \times \exp \left\{ -\frac{(R_{i\tau} - \mu_{k\tau})^2}{2(\alpha_{0k} + \alpha_{1k}\varepsilon_{\tau-1}^2 + \theta_{1k}\sigma_{k,\tau-1}^2)} \right\} \quad (4.22)$$

para $\mu_{k\tau} = \beta_{0k} + \beta_{1k}X_{i\tau 1} + \dots + \beta_{pk}X_{i\tau p} + \gamma_k 1_{[T_1 < \tau \leq T_2]}(\tau)$ e $k = 1, 2$.

No modelo de misturas trata-se o componente da mistura $z_{\tau k} \in \{0, 1\}$ como um *missing value*, a verossimilhança para o vetor conjunto $(R_{i\tau}, z_{\tau 1}, z_{\tau 2})$ é:

$$\begin{aligned} \mathbb{P}(R_{i\tau} = r_{i\tau}, Z_{\tau 1} = z_{\tau 1}, Z_{\tau 2} = z_{\tau 2}) &= \\ \mathbb{P}(R_{i\tau} = r_{i\tau} | Z_{\tau 1} = z_{\tau 1}, Z_{\tau 2} = z_{\tau 2}) \mathbb{P}(Z_{\tau 1} = z_{\tau 1}, Z_{\tau 2} = z_{\tau 2}) &= \\ \prod_{k=1}^2 \lambda_k^{z_{\tau k}} f_k(R_{i\tau} | \mathcal{F}_\tau, \lambda_k)^{z_{\tau k}} & \end{aligned} \quad (4.23)$$

Assim a verossimilhança completa é dada por:

$$\mathcal{L}(\Psi) = \prod_{\tau=2}^n \prod_{k=1}^2 \lambda_k^{z_{\tau k}} f_k(R_{i\tau} | \mathcal{F}_\tau, \lambda_k)^{z_{\tau k}} \quad (4.24)$$

e a log-verossimilhança é dada por:

$$l(\Psi) = \sum_{\tau=2}^n \sum_{k=1}^2 z_{\tau k} \log(\lambda_k) + \sum_{\tau=2}^n \sum_{k=1}^2 z_{\tau k} \log[f_k(R_{i\tau} | \mathcal{F}_\tau, \lambda_k)] \quad (4.25)$$

No Algoritmo EM o primeiro passo consiste em substituir $z_{\tau k}$ pelo seu valor esperado. Apli-

cando o teorema de *Bayes* tem-se:

$$\begin{aligned} \mathbb{P}(Z_{\tau k} = 1 | R_{i\tau} = r_{i\tau}) &= \frac{\mathbb{P}(R_{i\tau} = r_{i\tau} | Z_{\tau k} = 1) \mathbb{P}(Z_{\tau k} = 1)}{\sum_{l=1}^2 \mathbb{P}(R_{i\tau} = r_{i\tau} | Z_{\tau l} = 1) \mathbb{P}(Z_{\tau l} = 1)} \\ &= \frac{\lambda_k f_k(R_{i\tau} | \mathcal{F}_\tau, \lambda_k)}{\sum_{l=1}^2 \lambda_l f_l(R_{i\tau} | \mathcal{F}_\tau, \lambda_l)} = \hat{\lambda}_{\tau l} \end{aligned} \quad (4.26)$$

O segundo passo do Algoritmo EM consiste em maximizar a log-verossimilhança dada em (4.25) substituindo $z_{\tau k}$ pelo seu valor esperado $\hat{\lambda}_{\tau l}$. Obtendo assim:

$$\mathbb{Q}(\underline{\Psi}, \underline{\Psi}^{(l)}) = \sum_{\tau=2}^n \sum_{k=1}^2 z_{\tau k} \log(\lambda_k) + \sum_{\tau=2}^n \sum_{k=1}^2 z_{\tau k} \log[f_k(R_{i\tau} | \mathcal{F}_\tau, \lambda_k)] \quad (4.27)$$

De maneira sumarizada o Algoritmo EM é estruturado como:

1. Inicie com os valores de λ_1, λ_2 e o vetor de parâmetros $\underline{\Psi}$.
2. Compute a equação (4.26).
3. Maximize a equação (4.27) para o vetor de parâmetros $\underline{\Psi}$ substituindo $z_{\tau k}$ pelo seu valor esperado $\hat{\lambda}_{\tau l}$.
4. Substitua os valores encontrados em ③ no passo ② e repita até que

$$\delta = \left| \mathbb{Q}(\widehat{\underline{\Psi}}, \widehat{\underline{\Psi}}^{(l)}) - \mathbb{Q}(\widehat{\underline{\Psi}}, \widehat{\underline{\Psi}}^{(l+1)}) \right| < 0.1. \quad (4.28)$$

5. Após a convergência do algoritmo as probabilidades estimadas para cada regime são dadas por $\hat{\lambda}_k = \sum_{\tau=2}^n \hat{\lambda}_{\tau k} / n$ para $k = 1, 2$.

Graficamente, o método proposto pode ser representado pelo fluxograma 4.1:

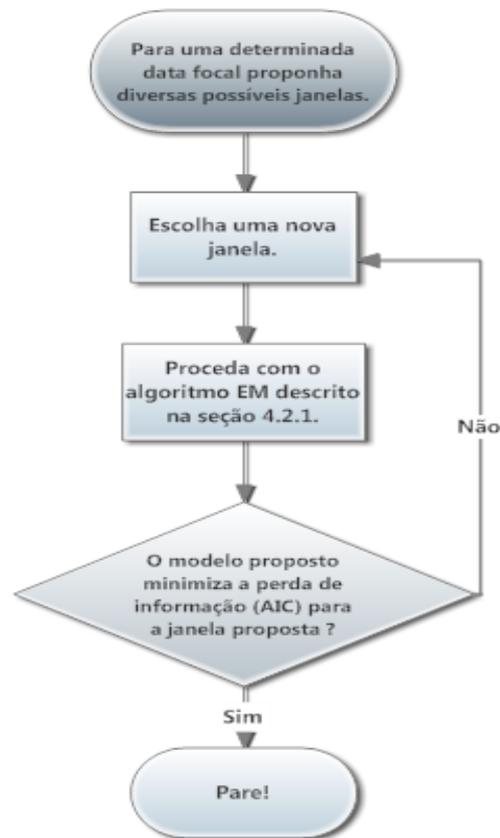


Figura 4.1: Fluxograma para o método proposto.

Fonte: Elaboração do autor.

O fato do modelo incorporar dois possíveis regimes auxilia no ajuste de dados que possuam caudas pesadas, assimetria para ganhos ou perdas e ou apresentem desvio da normalidade. Já a presença de uma estrutura do tipo GARCH em ambos os regimes permite não somente o tratamento das aglomerações de volatilidade no tempo como também diferenciam volatilidades como função do regime em que as observações se encontrem.

Ademais, os resultados obtidos pela comparação dos modelos mais frequentes utilizados em finanças apresentados na tabela 4.3 para o índice Ibovespa e o adequamento desses modelos para os principais índices financeiros mundiais expressos na tabela 4.2 sugerem a superioridade do modelo de misturas GARCH face aos demais modelos, para o conjunto de dados estudados.

Especificamente, em Estudo de Eventos a presença de duas misturas com preditores lineares diferentes possibilita a análise e estimação do efeito de anúncios diferenciadas para cada possível regime viabilizando assim a execução de testes de eventos para cada regime individualmente ou para ambos como apresentado pela equação (4.19).

5 ENSAIOS EM FINANÇAS CORPORATIVAS.

Neste capítulo são apresentados ensaios de métodos de misturas de distribuições GARCH aplicados a Estudos de Eventos de maneira a elucidar as potencialidades do método sugerido nesta tese.

Sem rodeios, o objetivo do capítulo 5 é apresentar como o modelo proposto na seção 4.2 pode ser utilizado em diversas aplicações de finanças corporativas.

Na primeira seção deste capítulo, os retornos da estatal Petrobrás são estudados com o intuito de testar a existência de retornos anormais em períodos eleitorais, no Brasil, à luz da Teoria da Agência. Misturas de modelos GARCH são, dessa maneira, usadas para se modelar corretamente a distribuição dos retornos da estatal com o objetivo de mensurar o impacto do período eleitoral na expectativa dos acionistas. Conclui-se que o período eleitoral influencia negativamente o log-retorno dos preços da estatal, com isso, indicando a presença de um conflito entre o principal e o agente, nesse caso, os acionistas e a União.

Posteriormente, no segundo ensaio, é apresentada uma proposta metodológica para modelagem e inferência em Estudos de Eventos, incorporando em seu cerne os principais fatos estilizados em finanças, diferentemente da abordagem simplória clássica. O interesse desse estudo é medir, avaliar e discutir a influência da distribuição de dividendos das empresas que compõem o IBOVESPA. Para isso foi utilizada uma abordagem de misturas GARCH, a qual é capaz de corrigir e adicionar os principais fatos estilizados em finanças no processo de modelagem e adequação dos dados. Conclui-se que a abordagem tradicional, por não incorporar características comuns a séries temporais financeiras, pode levar a uma inferência errônea e que os dividendos afetam o mercado diferentemente conforme a estrutura presente, quais sejam: *Bear Market* ou *Bull Market*.

5.1 Evidências empíricas da influência do período eleitoral sobre os retornos da Petrobrás.

O mercado de capitais brasileiro possui atualmente organizações públicas com grande influência, seja no volume de ações negociadas seja na popularidade destas. Devido ao fato dessas organizações possuírem uma ingerência política, um conflito entre os acionistas (principal) e a gerência dessas organizações (agente) pode ocorrer, pois esses gestores, por serem, na sua maioria, indicações políticas, podem seguir cursos de ações políticas, os quais não, necessariamente, são os melhores cursos para a organização. Por conseguinte, as decisões tomadas pelo agente podem afetar a utilidade do principal, nesse caso os acionistas, esse conflito é então explorado na literatura por meio da Teoria da Agência.

Nesse contexto, Jensen e Meckling (1976) argumentam que a discricionariedade na contratação de gestores, que não necessariamente participem do capital da empresa, conduz ao problema da separação entre propriedade e controle, sendo que, no caso de ambas as partes agirem visando à maximização de suas próprias utilidades, existirá uma razão para se acreditar que o agente não agirá sempre no melhor interesse do principal.

Uma questão que surge para o caso das organizações brasileiras é o estudo do possível efeito do período eleitoral sobre o retorno financeiro de uma organização, como um indicativo da existência de um conflito agente-principal. Especificamente, neste texto, deseja-se testar se os períodos eleitorais associados a eleição presidencial influenciam na expectativa dos acionistas que detêm ações da Petrobrás, a qual é regida por gestores indicados politicamente¹. Uma vez que a relação entre esses dois atores é caracterizada pela presença de informação assimétrica e como suas utilidades, frequentemente, diferem, suas expectativas podem também diferir, assim, resultando no problema da agência².

Sob tal perspectiva, este ensaio é dividido da seguinte forma: a subseção apresentará o referencial teórico relativo ao conflito agente-principal estudado pela Teoria da Agência. Na subseção , é descrita a abordagem de testes de eventos por meio de misturas GARCH. Na subseção , os resultados são fornecidos e, finalmente, na subseção , as considerações finais são colocadas.

¹ LEI Nº 9.478, DE 6 DE AGOSTO DE 1997.

² Apesar de o acionista majoritário ser o Governo do Brasil (União), ainda assim há conflito entre o agente e o principal, uma vez que há acionistas que possuem função utilidade diferente da utilidade da União.

5.1.1 Referencial teórico.

A Teoria da Agência refere-se a um conjunto de proposições que regem uma organização, a qual é usualmente caracterizada pela grande quantidade de acionistas ou proprietários, os quais permitem que indivíduos separados controlem e direcionem o uso do capital coletivo para ganhos futuros da organização.

Estes indivíduos, em geral, nem sempre possuem ações próprias, mas devem possuir habilidades profissionais relevantes que os auxiliem na gestão da empresa. A Teoria da Agência oferece muitas formas úteis para examinar a relação entre proprietários e gerentes e verificar se o objetivo final (a maximização dos retornos para os acionistas) é alcançado, especialmente quando os gestores não são proprietários ou acionistas da organização.

A ideia de um possível conflito entre dois agentes que possuem objetivos distintos data do século XVII com Smith (1776) e mais recentemente com Berle e Means (1932). Ambos iniciam a discussão atinente às preocupações da separação entre propriedade e controle em uma corporação.

No entanto o conceito formal de Teoria da Agência, como é conhecido atualmente, é devido a Jensen e Meckling (1976), que definiram o “problema da agência” ao comandar uma corporação. Jensen e Meckling (1976) identificaram os gestores como os agentes que são empregados com o objetivo de maximizar os retornos para os acionistas, nesse caso, os principais. Dessa forma, os autores assumem que como os agentes usualmente não possuem recursos da corporação, ou seja, podem não ser acionistas da firma, eles podem incorrer em risco moral (*moral hazard*), como se esquivar de deveres administrativos para desfrutar de lazer e esconder a ineficiência para evitar a perda de recompensas, apenas para aumentar sua própria riqueza pessoal à custa do principal.

Para estruturar melhor o problema da agência, Jensen (1983) define que a Teoria da Agência, em seu cerne, é estratificada em dois segmentos, a saber: Teoria da Agência Positivista e a Teoria Principal-Agente.

Na Teoria Principal-Agente, o objetivo é analisar o quanto de riscos cada uma das partes deve assumir para que possa atingir seus respectivos ganhos, especificamente, o principal deve transferir alguns direitos ao agente que, por sua vez, deve aceitar realizar deveres estabelecidos de maneira legal. Nesse caso, o interesse é na relação agente-principal. Esse tipo de estudo pode ser aplicado a uma gama de relações, como a do empregador-empregado, advogado-cliente, comprador e fornecedor e outros tipos de relacionamentos econômicos.

Já, na abordagem da agência positivista, discute-se como as empresas usam o monitora-

mento contratual sobre a estrutura projetada na primeira etapa (teoria principal-agente) e então possíveis soluções para os problemas da agência são derivadas. A inevitável perda de valor da empresa, que surge com os problemas da agência, juntamente com os custos de monitoramento, é contratual e definida *a priori* como os custos da agência (JENSEN; MECKLING, 1976). Na linha positivista, os pesquisadores concentraram-se em identificar em que o principal e o agente são suscetíveis a determinar objetivos conflitantes, procura-se também descrever os mecanismos de governança que limitam o comportamento do agente quanto à sua administração centrada.

Em ambos os casos, segundo Eisenhardt (1989), a unidade de análise é o contrato legal firmado entre o principal e o agente, o qual pode ser utilizado como uma ferramenta para redução ou eliminação do conflito entre o principal e o agente.

Posteriormente, Fama (1980) integrou os elementos da Teoria da Agência, a Teoria dos Direitos de Propriedade e as Teorias do Mercado financeiro para, então, desenvolver sua Teoria da Estrutura de Propriedade da empresa. O autor define o conceito dos custos de agência e demonstra sua relação com a questão da “separação e controle” dos custos da agência, gerados pela existência de dívida e capital de fora, além de enunciar que carrega custos e o porquê disso.

Salancik e Pfeffer (1980) investigaram evidências empíricas da relação entre a posse do gestor e seu respectivo desempenho para 84 corporações dos EUA. Os autores afirmam, por meio dos dados, que as medidas de desempenho estão relacionadas ao grau de posse que o presidente-executivo da empresa possuía como acionista. Os autores afirmam, no entanto, que a posse não foi relacionada positivamente com a margem de lucro das empresas controladas externamente, mas foi relacionada positivamente com as taxas de retornos dos mercados de ações para as empresas de gestão controlada.

Já Demsetz e Lehn (1985) argumentam que a estrutura de propriedade das empresas varia sistematicamente de forma que sejam consistentes com a maximização de valor. Entre as variáveis que se provaram estatisticamente significantes para a explicação da variação na estrutura de propriedade, para algumas das 511 corporações dos EUA, estão: o tamanho da empresa, a instabilidade da taxa de lucro, se a empresa atua na mídia de massa ou na indústria de esporte.

Em uma abordagem mais qualitativa, Noreen (1988) discute ideias de como incorporar a ética nas relações organizacionais com o intuito de evitar, conscientizar ou, ao menos, reduzir as possibilidades de *moral hazard* dentro das organizações.

Do ponto de vista motivacional, Tosi e Gomez-Mejia (1989) examinaram como os incentivos

fornecidos aos CEO's, em termos de compensação financeira, influenciam os desempenhos desses atores como gestores.

Baiman, May e Mukherji (1990), porém, estudaram uma empresa constituída de um principal e um agente. Nessa organização, o principal contrata o agente para fornecer alguns insumos básicos para o processo de produção. O produto do processo de produção é determinado pelos insumos do agente. Os autores estudam este modelo organizacional com o objetivo de melhor compreender os efeitos da monitorização sobre o contrato de trabalho e, dessa forma, propor uma maneira ideal para a elaboração desses contratos.

Hunt e Hogler (1990) exploraram as semelhanças entre a Teoria Jurídica e a Contábil, com referência nas bases da economia neoclássica. Segundo os autores, os teóricos neoclássicos argumentam que a interferência governamental no mercado de trabalho deve ser minimizada e que os acordos contratuais são um meio superior de resolução de conflitos organizacionais.

Gomez-Mejia e Balkin (1992) testaram 12 hipóteses relativas aos determinantes da remuneração de um corpo docente, pela perspectiva da Teoria da Agência. A amostra foi constituída de 353 professores de administração. Os autores apresentaram como resultados a informação de que os principais determinantes da remuneração do corpo docente são: o número de publicações em *journals* de primeira linha, nos quais o docente é autor e mudanças de afiliação institucional. Outras variáveis, como o desempenho docente ao ensinar e os números de citações em revistas de segunda linha, além de publicações de livros, afetam os rendimentos apenas para membros do corpo docente que têm registros de pesquisa excepcional.

Kesner, Shapiro e Sharma (1994) sugeriram a existência de um conflito de interesses nas relações entre os bancos de investimento e as empresas que eles representam durante as negociações de fusão. Os autores examinaram esta proposição, analisando a associação entre as compensações financeiras dos bancos e os prêmios pagos pelas operações de fusão. Os resultados indicaram uma relação positiva entre o prêmio e a compensação aos bancos de investimento. Esta relação sugere um alinhamento entre os objetivos das metas e dos seus representantes, mas indica desalinhamento e, portanto, conflito de interesses, no caso de licitantes.

Abrahamson e Park (1994) exploraram se, quando e como os gestores escondem intencionalmente resultados negativos da organização para os seus acionistas. Os resultados apresentados pelos autores aventam que os diretores externos, grandes investidores institucionais e contabilistas limitam essa ocultação. Entretanto pequenos investidores institucionais e diretores externos que são acionistas tendem a ocultar resultados negativos, dessa forma, evidenciando o problema da agência.

Parks e Conlon (1995) examinaram como a capacidade de monitorar as ações de um agente e as liberalidades ambientais afetam contratos de remuneração entre o agente e o principal. Parks e Conlon (1995) testam as predições baseadas em ambas as suposições fundamentadas na Teoria da Agência além de uma perspectiva alternativa.

Kunz e Pfaff (2002) argumentam que a Teoria Cognitiva de Avaliação e sua construção hipotética de motivação intrínseca desfrutam de crescente popularidade nas áreas de Administração de Empresas e Economia, dessa forma, o ceticismo em relação a intensificar os incentivos de desempenho e a Teoria da Agência é postulada. De acordo com a Teoria Cognitiva de Avaliação, sugere-se que a remuneração por desempenho pode comprometer a motivação intrínseca de um agente. Logo, em contradição com a teoria da agência, o principal poderia não ter sua função utilidade maximizada no caso de um fornecimento de um contrato de incentivo para o agente. Restringindo a atenção para remuneração por desempenho em empresas de negócios, os autores avaliaram se a teoria da agência enfrenta uma necessidade da incorporação da construção da motivação intrínseca e dos seus “custos ocultos de recompensa”, como postulado por partidários do conceito. Kunz e Pfaff (2002) dissertam que mesmo sobre a ótica da Teoria Cognitiva de Avaliação, a Teoria da Agência não deve ser descartada devido às evidências empíricas encontradas pelos autores.

Booth e Schulz (2004) propõem que um ambiente de forte ética é eficaz em reduzir a tendência dos gestores de projetos em falhar na presença de problemas de agência. Os resultados apoiam essas proposições com um ambiente de forte ética encontrado para reduzir significativamente a tendência dos gestores em falhar. Booth e Schulz (2004) referem que, enquanto os efeitos do problema da agência ainda estiverem presentes em um ambiente de forte conteúdo ético, seu impacto será semelhante ao caso de um ambiente de fraca ética na ausência de problemas de agência. Os autores concluem, desse modo, que a criação de um ambiente de forte ética pode ser uma opção de controle altamente desejável para as organizações em geral.

Iyer, Schwarz e Zenios (2005) desenvolveram e analisaram um modelo agente-principal na especificação de um produto e da produção para um fabricante de automóveis. Nessa relação econômica, o comprador (principal) delega a maior parte das especificações do produto e da atividade de produção para o fornecedor (agente). O fornecedor, por sua vez, atribui o seu recurso para produzir o produto acabado. Os autores, nesse sentido, fornecem uma estratégia para elaboração de contratos que minimize o custo total esperado para o principal.

Cohen e Holder-Webb (2006) estudaram a influência da Teoria da Agência no contexto do ensino acadêmico em contabilidade. Neste texto, os autores examinaram e estenderam a

crítica quanto à falta de habilidade e contextualizações no ensino da Teoria da Agência para alunos de contabilidade e exploraram suas implicações para a pesquisa em contabilidade e educação. Cohen e Holder-Webb (2006) examinaram como a Teoria da Agência, à luz de uma nova dinâmica de ensino, poderia ser ministrada. Por fim, os autores sugeriram formas de melhorar a educação em contabilidade por meio da adoção de múltiplas perspectivas e preparar os alunos para atuar, especificamente, no interesse público.

Ronen e Yaari (2007) consideraram a seguinte questão: se o gerenciamento de resultados é prejudicial aos acionistas, por que eles não projetam contratos que induzem os gestores a revelar a verdade? Para responder a esta pergunta, os autores utilizaram o modelo de relacionamento acionistas-gerente como um jogo principal-agente, cujo agente (o gerente) só observa o resultado econômico. Ronen e Yaari (2007) demonstraram que a responsabilidade limitada (RL) do agente, definido como o pagamento mínimo viável do agente, poderia explicar a demanda por gerenciamento de resultados pelo principal. Especificamente, quando o nível de RL é alto (baixo), um contrato que induz gerenciamento de resultados pode ser menos (mais) caro do que um contrato de verdade reveladora. Segundo os autores, esta descoberta oferece uma nova explicação da demanda por gerenciamento de resultados.

No campo de pesquisas experimentais, Brown, III e Moser (2009) analisaram as experiências associadas a uma série de experimentos em orçamentos participativos, para tanto, examinando o efeito de estruturas de incentivos nos relatórios dos empregados e das decisões de produção. Os autores expandiram as análises dos experimentos para contratação de incentivo de três maneiras: primeiro, classificando a série de experiências de orçamento participativo com base no tipo de incentivo e de informação das estruturas examinadas em cada estudo. Segundo, dos 21 papéis que revisaram, identificaram oito casos específicos para os quais a evidência experimental contradiz uma previsão da Teoria da Agência (ou seja, anomalias). Em terceiro lugar, desenvolveram um esquema de classificação que pode ser usado para organizar as hipóteses em termos de uma previsão da Teoria da Agência, uma previsão comportamental dos concorrentes, ou ainda uma combinação dos dois. Os autores utilizaram essa classificação para ilustrar por que se acredita que os estudos que testam ambas: previsão da Teoria da Agência e a previsão comportamental dos concorrentes são mais propensas a avançar no desenvolvimento da teoria do que aqueles que não testam.

Apesar de vasta a literatura sobre Teoria da Agência, pouco se tem sobre o conflito agente-principal no caso de estatais e sua relação com o período eleitoral, assinaladamente, se uma empresa é governada de modo a maximizar a utilidade do principal, o período eleitoral não deveria influenciar as expectativas de retornos dos acionistas e, conseqüentemente, o preço das

ações. No caso de estatais, o período eleitoral pode ser considerado de grande especulação acionária, uma vez que o resultado do processo eleitoral pode afetar os rumos da organização e, dessa forma, afetar os objetivos dos acionistas (principal).

Uma maneira de averiguar se a expectativa dos acionistas sobre os rumos da organização, durante o período eleitoral, é alterada é por meio de um teste estatístico para a existência de retornos anormais durante esse período.

Assim, para testar se o período eleitoral produz retornos anormais, definiu-se arbitrariamente como ativo de interesse os preços da ação da Petrobrás (PETR3 e PETR4), uma das maiores empresas estatais de capital aberto do Brasil, utilizando, para isso, o modelo MN-GARCH descrito nesta tese e sumarizado na seção 5.1.2.

5.1.2 Metodologia.

Em finanças, retornos médios diferentes de zero são considerados retornos anormais, pois contrariam a hipótese de mercados eficientes, como proposto por Fama (1991), especificamente, em finanças corporativas, os gestores estão interessados em avaliar e testar a existência de retornos anormais e, conseqüentemente, averiguar possíveis ineficiências do mercado após a ocorrência de um determinado tipo de evento corporativo. Assim, estudo de eventos, como é conhecido esse ramo da econometria financeira, tem como foco um horizonte temporal associado a um evento em específico, esse evento também é denominado de evento focal, pois é o foco de estudo da organização.

Entre as abordagens em estudo de eventos, a proposta mais usual é aquela que infere sobre os efeitos médios associados aos preços de ações. Outros tipos de estudos de eventos também surgem na literatura, incluindo estudos de caso que examinam as volatilidades dos retornos (BEAVER, 1968) (PATELL, 1976), volume de negociação (CAMPBELL; WASLEY, 1996), desempenho contábil (BARBER; LYON, 1996) e gerenciamento de resultados por meio de acumulações discricionárias (DECHOW; SLOAN; SWEENEY, 1995), (KOTHARI; LEONE; WASLEY, 2005).

Entretanto, usualmente, essas abordagens, quando paramétricas, utilizam como pressupostos (direta ou indiretamente): independência, homoscedasticidade e normalidade dos retornos; esses pressupostos vão de encontro aos fatos estilizados discutidos pela literatura financeira, quais sejam: aglomerações de volatilidade, retornos com assimetria positiva, retornos extremos (isso é, distribuição com caudas pesadas) e desvios da normalidade (CONT, 2001), Rachev et al. (2005).

Dessa forma, a presente metodologia apresentará uma abordagem quantitativa e paramétrica

para a avaliação e inferência de retornos associados a eventos, corrigindo os pressupostos clássicos e cãndidos quanto à distribuição dos retornos de ativos por meio da extensão da proposta de Haas (2004), o qual utiliza misturas de modelos GARCH (MN-GARCH) para ajustar retornos financeiros.

O evento focal pode ocorrer em diferentes pontos no tempo do calendário ou pode ser agrupado em uma determinada data, como eventos que ocorrem semanal, semestral ou ainda anualmente, e tem como principal objetivo investigar se a distribuição dos retornos no tempo de um evento é anormal em relação ao valor predito do mesmo ativo.

Um modelo de retornos normais deve ser especificado antes do processo de estimação e definição da anormalidade do retorno (KHOTARI; WARNER, 2006). Existe uma grande variedade de modelos associados aos retornos de ativos, especificamente, para cada amostra $i = 1, \dots, n$ dos ativos associados as N corporações em estudo, o retorno do ativo (ou portfólio) i associado a i -ésima organização para o período τ de tempo em relação ao evento, é dada por $R_{i\tau}$, o qual pode ser representado matematicamente por:

$$\mathbb{E}(R_{i\tau} | \mathcal{F}_\tau) = \mu_\tau + \varepsilon_{i\tau} \quad (5.1)$$

onde μ_τ é o nível “normal”. Em outras palavras, é o retorno esperado ou previsto dado um determinado modelo, e $\varepsilon_{i\tau}$, é o componente do retorno que é anormal ou não esperado. Dada esta decomposição do retorno, o retorno anormal $\varepsilon_{i\tau}$ pode ser expresso como a diferença entre o retorno observado e o retorno previsto. Equivalentemente, $\varepsilon_{i\tau}$ é a diferença entre o retorno condicional sobre o evento e o retorno esperado. Assim, o retorno anormal é uma medida direta da mudança inesperada na riqueza da organização associado ao evento em questão. Os diferentes métodos usualmente utilizados em estudo e análise de eventos se diferem na estrutura μ_τ associada ao modelo, especificamente, há três grandes modelos frequentemente aplicados, quais sejam:

Tabela 5.1: Estruturas funcionais usuais em estudo de eventos.

Fonte:Elaboração do autor.

Modelo	Estrutura funcional
<i>Constant Mean Return Model</i>	$\mu_\tau = \mu + 1_{[T_1 < \tau \leq T_2]}(\tau)\gamma$
<i>Market Model</i>	$\mu_\tau = \alpha + \beta R_{m\tau} + 1_{[T_1 < \tau \leq T_2]}(\tau)\gamma$
<i>CAPM Model</i>	$\mu_\tau = R_{rf\tau} + \beta [\mathbb{E}(R_{m\tau}) - R_{rf\tau}] + 1_{[T_1 < \tau \leq T_2]}(\tau)\gamma$

Onde $1_{[T_1 < \tau \leq T_2]}(\tau)$ representa uma variável *dummy* a qual assume valor unitário na presença do evento focal, e suas intermediações T_1 e T_2 , associados ao i -ésimo ativo e zero caso

contrário e $R_{m\tau}$, $R_{rf\tau}$ representam respectivamente os retornos de mercado e livre de risco no período τ . No caso de estudos de eventos, deseja-se testar a seguinte hipótese:

$$\begin{cases} H_0 : \gamma = 0 \\ H_a : \gamma \neq 0 \end{cases} \quad (5.2)$$

onde o parâmetro γ é o parâmetro de interesse associado ao evento focal, no caso deste texto, o período eleitoral é a data de votação para a eleição presidencial ocorrida no ano em questão.

A principal diferença entre as abordagens clássicas de estimação para os modelos descritos na tabela 5.1 e a abordagem utilizando misturas GARCH está na especificação do termo $R_{i\tau}$, enquanto a estimação por OLS ou verossimilhança tradicional pressupõe direta ou indiretamente homoscedasticidade, normalidade e independência dos resíduos, a abordagem por meio de misturas GARCH auxilia na correção desses ajustando o modelo aos principais fatos estilizados, frequentemente presentes nas séries temporais financeiras.

Postula-se, dessa forma, que o mercado é composto de dois regimes, os quais compõem uma mistura de normais. Especificamente, suponha que haja dois regimes de mercado *Bull Market* (períodos de alta) e o *Bear Market* (períodos de baixa). A série financeira, quando observada diretamente, apresenta uma mistura (ou composição) desses dois tipos de mercados, de modo que a distribuição resultante possua assimetria positiva, como sugerem os fatos estilizados em finanças (CONT, 2001).

É possível também mostrar que qualquer distribuição contínua pode ser arbitrariamente bem-aproximada por uma mistura finita de distribuições normais com variância comum no caso univariado, ou com matriz de covariância comum no caso multivariado (MCLAUGHLAN, 2000, p. 176). Assim, a distribuição da série financeira tem um apelo natural quanto à utilização de regimes para sua modelagem e, por meio de misturas de distribuição, pode-se modelar corretamente os principais fatos estilizados em finanças, fornecendo uma metodologia robusta para o cômputo e inferência do efeito dos eventos focais nas organizações.

A proposta dessa metodologia é a construção de uma abordagem para estudo de eventos em finanças corporativas que incorpore os principais fatos estilizados em finanças, para isso, utilizou-se a proposta de Haas (2004), o qual considera uma mistura de distribuições normais juntamente com uma estrutura do tipo GARCH (denominada MN-GARCH), permitindo, dessa maneira, uma variância condicional para cada um dos componentes da mistura, bem como um *feedback* dinâmico entre os componentes, além de admitir que as observações sejam correlacionadas.

Nessa abordagem, o modelo MN-GARCH pode gerar uma desagregação do processo variância condicional, em que os componentes da volatilidade dinâmica têm um comportamento claramente diferenciado, o que é compatível com a proposta de estudos de eventos, cuja hipótese a ser testada é se, após a ocorrência do evento focal, os retornos médios observados (juntamente com sua variância condicional) alteraram-se. A série temporal $R_{i\tau}$ é assumida ser gerada por uma mistura de 2-componentes $GARCH(1, 1)$ como apresentado em 4.2; já a estimação dos parâmetros do modelo foi realizado por meio do algoritmo EM descrito em 3.3.

5.1.3 Análise empírica.

O mercado brasileiro de ativos possui atualmente organizações públicas que possuem grande influência seja no volume de ações negociadas seja na popularidade destas, e devido ao fato dessas organizações possuírem uma ingerência política pode ocorrer um conflito entre os acionistas (principal) e a gerência dessas organizações (agente), uma vez que esses gestores, por serem, na sua maioria, indicações políticas, podem seguir cursos de ações políticos, os quais não necessariamente são os melhores cursos para a organização. Assim, as decisões tomadas pelo agente podem afetar a utilidade do principal, nesse caso, os acionistas, esse conflito é explorado na literatura pela Teoria da Agência.

Especificamente, aqui, vê-se como interessante a possível influência do período eleitoral sobre o log-retorno dos seguintes ativos associados à Petrobrás: PETR3 e PETR4³. Utilizando o sistema *Bloomberg*, os log-retornos financeiros diários para os ativos PETR3 e PETR4 foram obtidos para os anos de 1994 a 2010.

Onde PETR3 é ordinária uma ação nominativa permitindo direito a voto e PETR4 é preferencial nominativa, mas não dá direito a voto. Ambas as séries rejeitam hipótese nula de raiz unitária a um nível crítico de 1% pelo teste de Dickey-Fuller aumentado. A primeira vista esse teste pode ser considerado insuficiente como sugere DeJong et al. (1992).

DeJong et al. (1992) concluem que mesmo em situações favoráveis, os testes de estacionariedade em geral, cumprem mal o seu papel, principalmente quando a estacionariedade testada é da forma de tendência (*trend-stationary*), comum em séries temporais com frequência anual, trimestral e mensal; as quais são frequentemente utilizadas em estudos macroeconômicos.

Entretanto, no caso do ensaio proposto para a tese, os dados seguem uma frequência diária, diferentemente do que foi sugerido por DeJong et al. (1992) (1992), ademais, DeJong et

³Quaisquer *gaps* presentes nas séries temporais foram interpolados linearmente.

al. (1992) concluem que o teste de Dickey-Fuller aumentando é razoavelmente bem-comportado, justificando, assim a utilização do teste Dickey-Fuller nesse ensaio. As estatísticas descritivas são apresentadas na tabela 5.2 para as séries temporais obtidas:

Tabela 5.2: Estatísticas descritivas.

Fonte: Elaboração do autor.

Ativo	Média	Mediana	Assimetria	Curtose	Shapiro-Wilk(P-valor)
PETR3	0,12080	0,03556	0,05707	1,41306	0,9417 (0,0000)
PETR4	0,10040	0,09855	0,00583	1,35272	0,9293 (0,0000)

Fica evidente, pelas estatísticas apresentadas na tabela 5.2, que os retornos dos ativos PETR3 e PETR4 não seguem uma distribuição normal, sendo, portanto, singela a adoção de uma metodologia que possua como pressuposto normalidade para esse conjunto de dados, dessa forma, a fim de ajustar corretamente esse conjunto de dados, aplicou-se o modelo MN-GARCH para as três formas estruturais apresentadas na tabela 5.1, utilizando como janelas para o dia da eleição: 5 dias, 10 dias, 15 dias e 20 dias simetricamente em torno do evento focal⁴.

Para escolher o modelo que melhor se adequou aos dados e que minimiza a perda de informação definiu-se como critério de informação a medida de Akaike (1974), denominada AIC, que oferece uma medida relativa da perda de informações quando um determinado modelo é usado para descrever a realidade, essa informação está disposta na tabela 5.3.

Tabela 5.3: Modelos estimados e seus respectivos AICs.

Fonte: Elaboração do autor.

Modelo	PETR3	PETR4
CMRM5	-18877,00	-18435,31
CMRM10	-19056,80	-18320,70
CMRM15	-18742,08	-18278,19
CMRM20	-18858,44	-18505,84
MM5	-16690,86	-14692,57
MM10	-16715,73	-15279,24
MM15	-16585,33	-14854,26
MM20	-16120,91	-14643,29
CAPM5	-16325,59	-14727,80
CAPM10	-16585,90	-14749,07
CAPM15	-16440,21	-14778,47
CAPM20	-16277,75	-14704,82

⁴O segundo turno também foi considerado, quando houve.

Nos modelos de mercado (MM) e no modelo CAPM, foram utilizados como retornos de mercado e livre de risco, respectivamente, o log-retorno do índice IBOVESPA e o log-retorno da SELIC, ambas as séries foram testadas quanto à presença de raízes unitárias e, assim como os log-retornos dos ativos PETR3 e PETR4, a hipótese nula também foi rejeitada a um nível crítico de 1%.

Note que os melhores modelos, segundo o critério de Akaike (1974), para os ativos PETR3 e PETR4 foram, respectivamente, CMRM10 e CMRM20, cujos parâmetros estimados são dados pelas tabelas 5.4 e 5.5, respectivamente.

Tabela 5.4: Estimativas do modelo CMRM10 para PETR3.

Fonte: Elaboração do autor.

Parâmetro	Estimativa	Erro-Padrão	P-valor
λ_1	0,25383	0,00685	0,00000
α_{01}	0,06323	0,02728	0,02045
α_{11}	0,01512	0,00296	0,00000
θ_{11}	0,97728	0,00532	0,00000
μ_1	-0,02884	0,08510	0,73469
γ_1	-0,62400	0,43880	0,15500
$1 - \lambda_1$	0,74617	0,00685	0,00000
α_{02}	0,19359	0,05902	0,00104
α_{12}	0,15770	0,01782	0,00000
θ_{12}	0,83187	0,01810	0,00000
μ_2	0,17719	0,04340	0,00004
γ_2	-1,14539	0,30783	0,00020

Tabela 5.5: Estimativas do modelo CMRM20 para PETR4.

Fonte: Elaboração do autor.

Parâmetro	Estimativa	Erro-Padrão	P-valor
λ_1	0,10234	0,00477	<0,00001
α_{01}	0,71602	0,24879	0,00400
α_{11}	0,43194	0,06419	<0,00001
α_{21}	0,50348	0,06792	<0,00001
μ_1	-0,12765	0,10426	0,22084
γ_1	-0,11486	0,99165	0,90779
$1 - \lambda_1$	0,89766	0,00477	0,00000
α_{02}	0,13167	0,02898	0,00001
α_{12}	0,08666	0,00925	<0,00001
α_{22}	0,89167	0,01172	<0,00001
μ_2	0,10268	0,03692	0,00541
γ_2	-0,53480	0,19515	0,00613

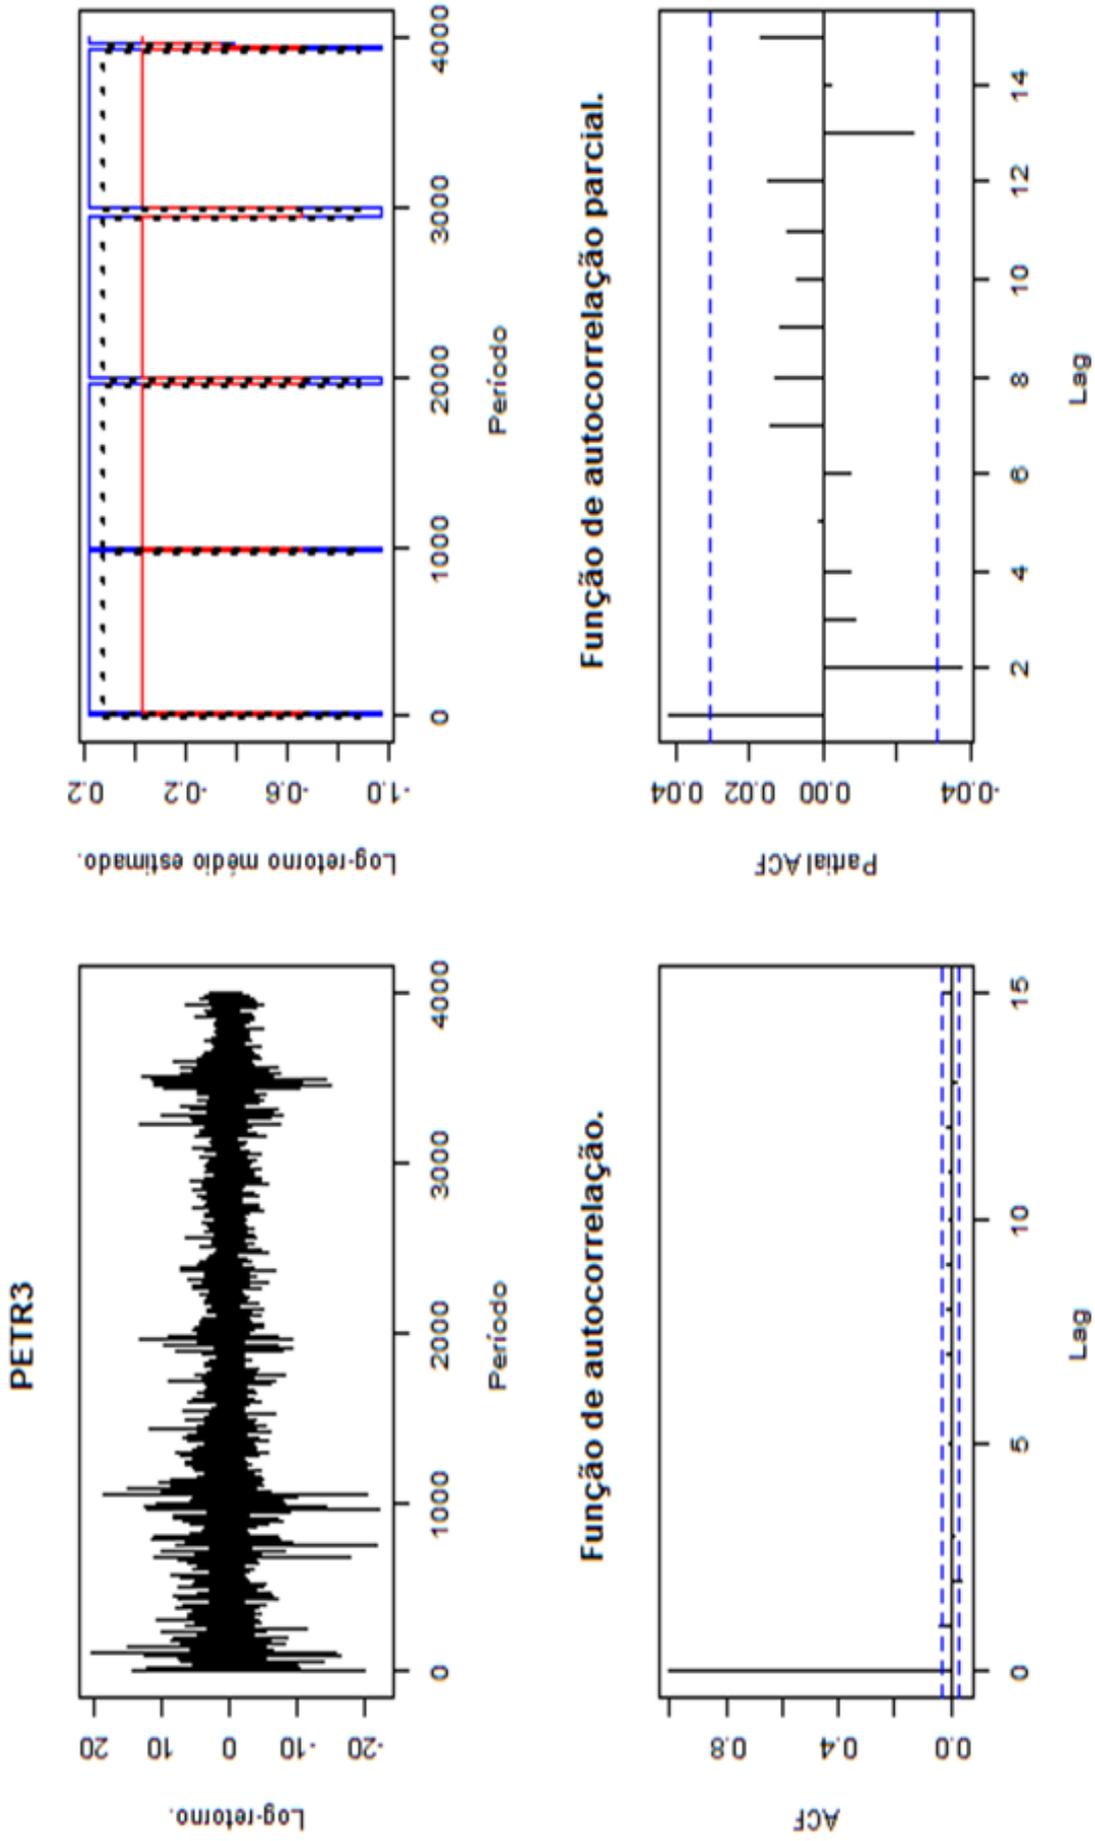
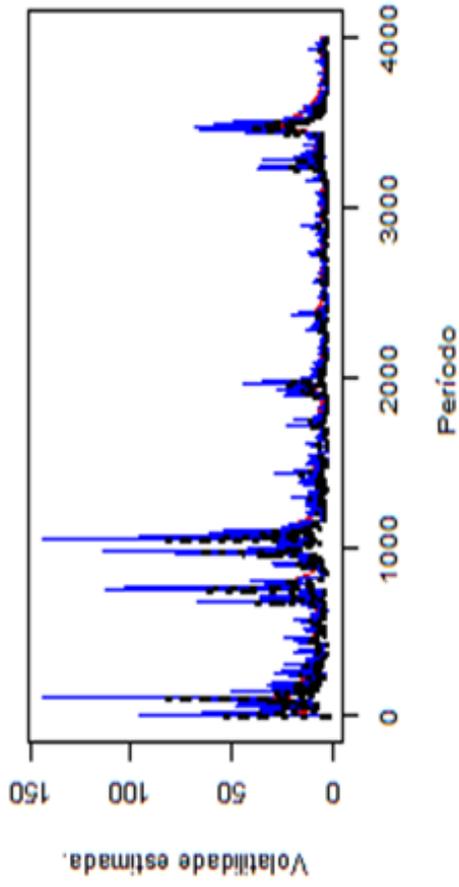
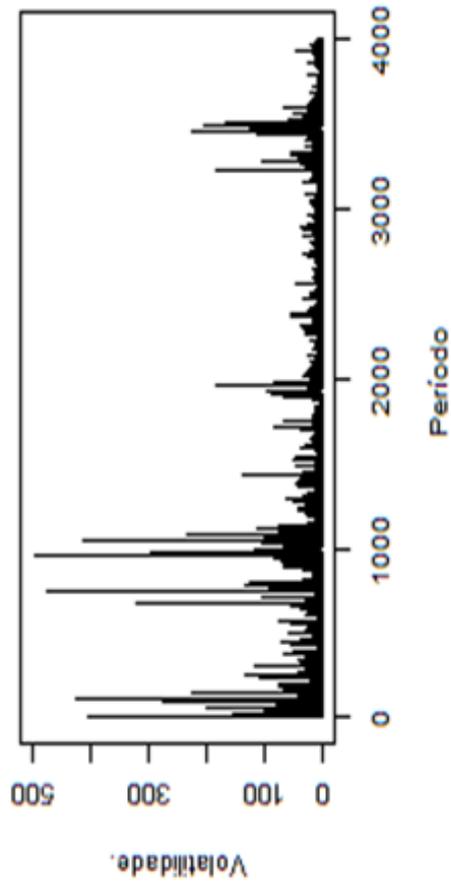


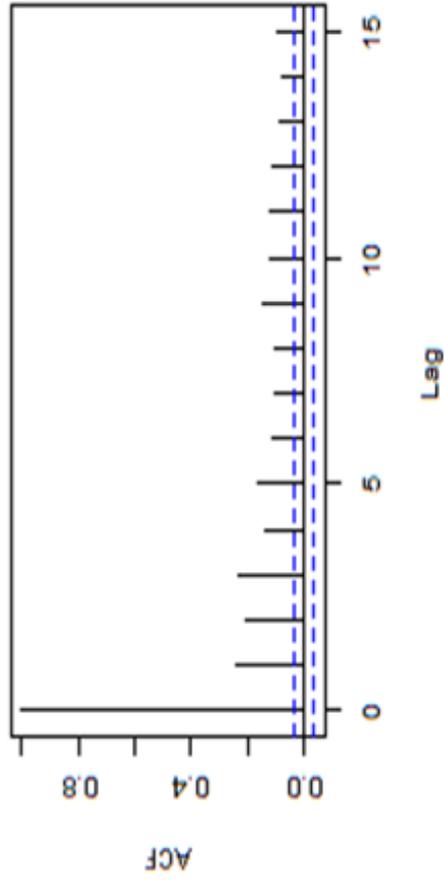
Figura 5.1: Gráficos de adequamento para equação da média para a PETR3.

Fonte: Elaboração do autor.

PETR3



Função de autocorrelação.



Função de autocorrelação parcial.

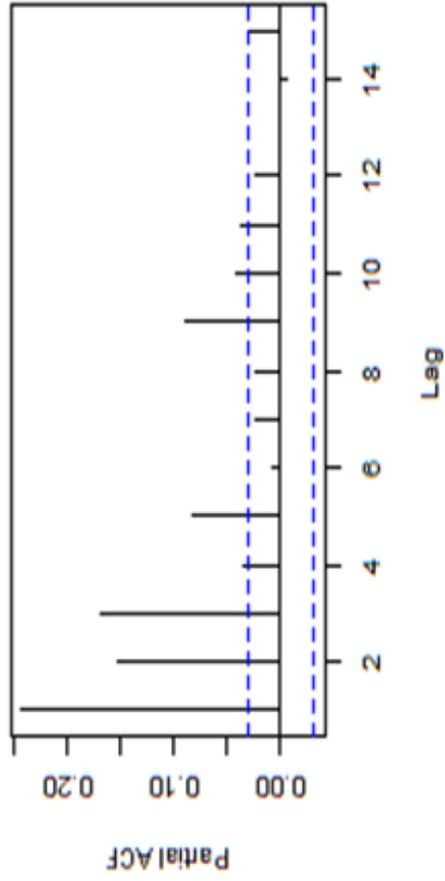
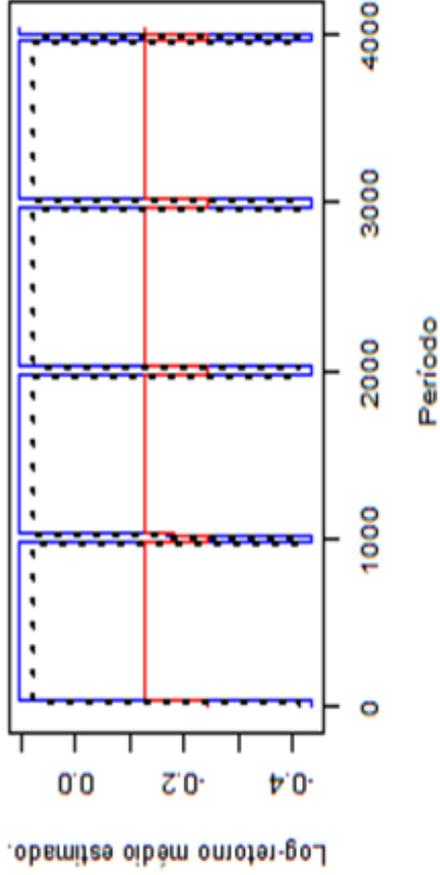
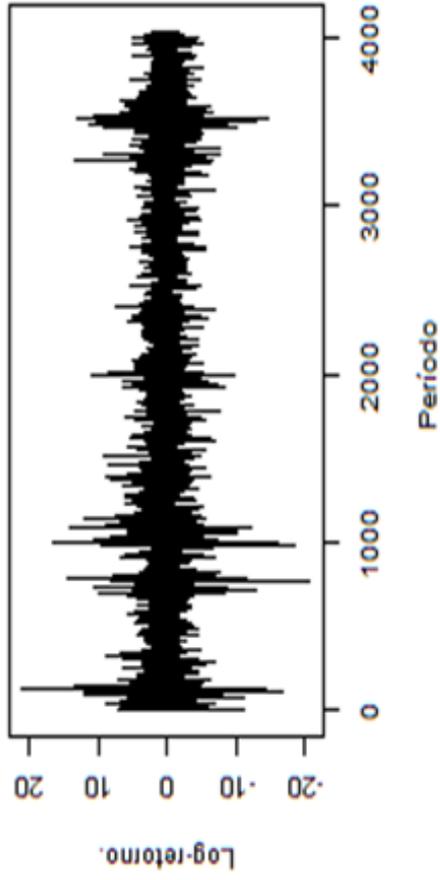


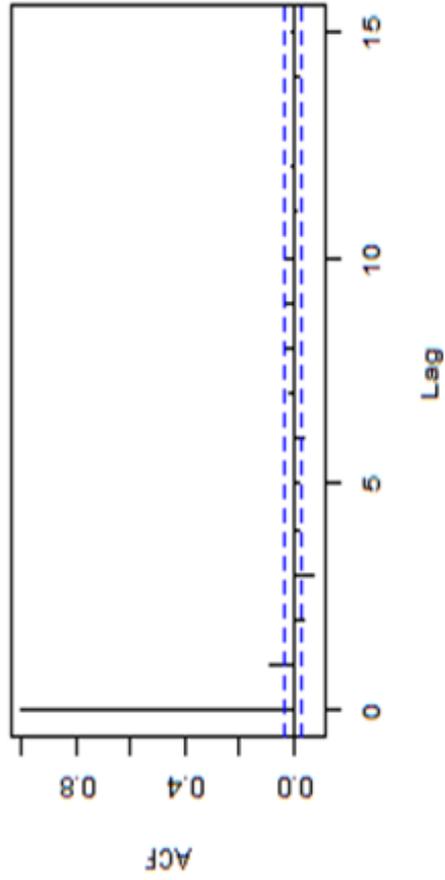
Figura 5.2: Gráficos de adequamento para equação de variância para a PETR3.

Fonte: Elaboração do autor.

PETR4



Função de autocorrelação.



Função de autocorrelação parcial.

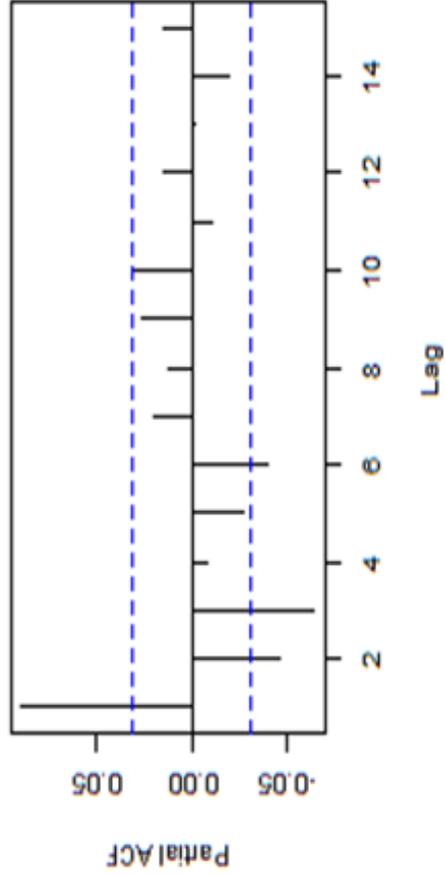
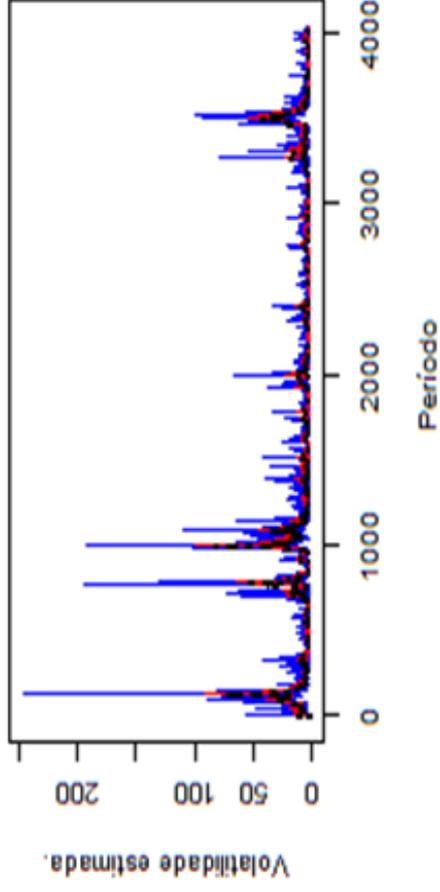
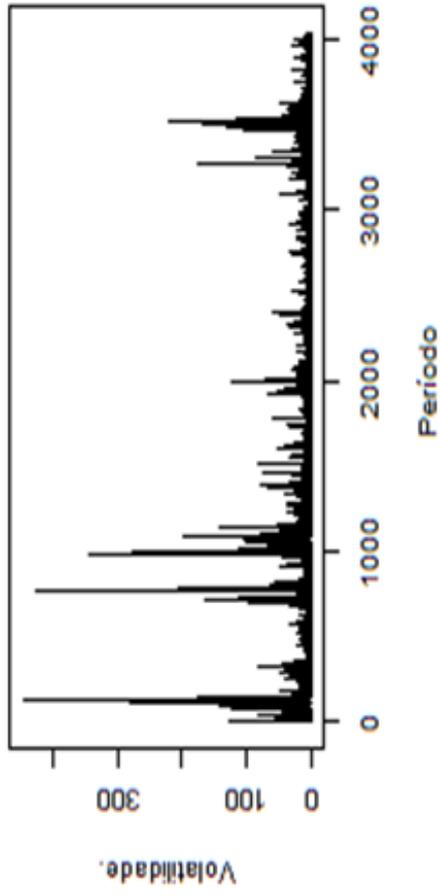


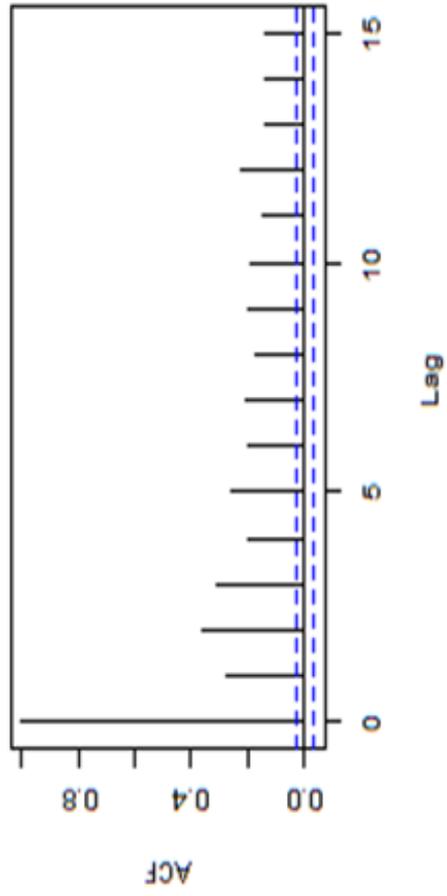
Figura 5.3: Gráficos de adequamento para equação da média para a PETR4.

Fonte: Elaboração do autor.

PETR4



Função de autocorrelação.



Função de autocorrelação parcial.

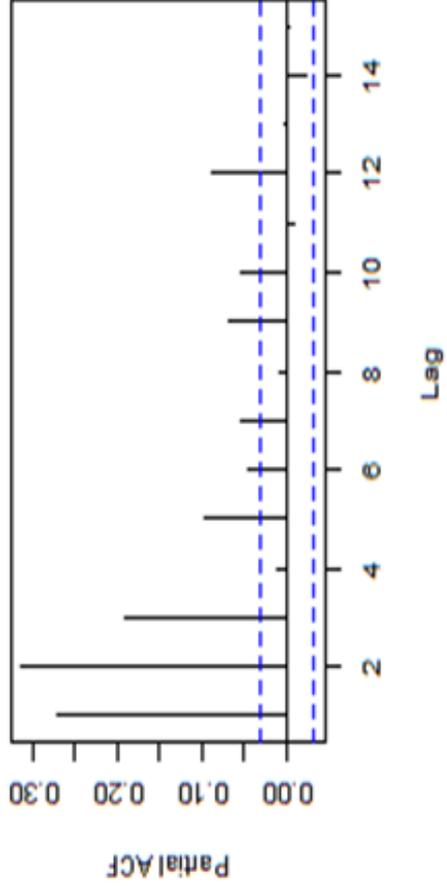


Figura 5.4: Gráficos de adequamento para equação de variação da volatilância para a PETR4.

Fonte: Elaboração do autor.

Nos modelos apresentados nas tabelas 5.4 e 5.5, os parâmetros estão segmentados em dois regimes, a saber: *Bear Market* e *Bull Market*. O regime associado ao *Bear Market* é aquele que possui estimativa pontual média negativa, no caso da PETR3 $\mu_1 = -0,02884$ e na PETR4 $\mu_2 = -0,12765$, já o *Bull Market* é caracterizado por retornos médios superiores a zero, assim, $\mu_2 = 0,17719$ e $\mu_2 = 0,10268$ para PETR3 e PETR4, respectivamente.

Para as observações associadas a PETR3 tem-se que a probabilidade de uma observação pertencer ao regime *Bear Market* é aproximadamente 25,38%; enquanto que essa probabilidade para a PETR4 é aproximadamente 10,23%.

Quanto à volatilidade associada a esses papéis, tem-se que para a PETR3, no caso do *Bear Market*, a volatilidade incondicional, ou seja, aquela associada somente ao papel, é igual $\alpha_{01} = 0,71602$, a magnitude da influência dinâmica na volatilidade com base no erro amostral é $\alpha_{11} = 0,43194$, enquanto que a magnitude da influência da volatilidade passada na volatilidade é igual a $\theta_{11} = 0,50348$, já para o *Bull Market* esses parâmetros são respectivamente $\alpha_{02} = 0,13167$, $\alpha_{12} = 0,08666$ e $\theta_{12} = 0,89167$.

Pode-se notar que no regime *Bear Market* a volatilidade incondicional do ativo é superior a volatilidade incondicional no regime *Bull Market*, ou seja, em situações nas quais a observação se encontra no regime *Bear Market*, para a PETR3, a maior parte do risco está atrelada ao próprio papel. Enquanto no *Bull Market* a maior parte da volatilidade está ajuçada nas respostas das volatilidades (riscos) passados. Quando o mercado (para a PETR3) está no *Bear Market* notícias “ruins” influenciam pouco no risco do papel, enquanto que no *Bull Market* as notícias passadas afetam mais o risco do ativo. Esse mesmo fator se revela na influência do período eleitoral, quando o mercado se encontra no *Bear Market* não há evidências para a rejeição da hipótese de nulidade do efeito do período eleitoral sobre o preço da ação.

No caso da PETR4, para o *Bear Market*, a volatilidade incondicional é igual $\alpha_{01} = 0,06323$, a magnitude da influência dinâmica na volatilidade com base no erro amostral é $\alpha_{11} = 0,01512$, enquanto que a magnitude da influência da volatilidade passada na volatilidade presente é igual a $\theta_{11} = 0,97728$, para o *Bull Market* associado a PETR4, esses parâmetros são respectivamente $\alpha_{02} = 0,19359$, $\alpha_{12} = 0,15770$ e $\theta_{12} = 0,83187$.

Similarmente a PETR3, os resultados obtidos para a PETR4 indicam que quando o mercado está no *Bear Market* notícias “ruins” influenciam pouco no risco do papel, enquanto que no *Bull Market* as notícias passadas influenciam mais o risco do ativo. Todavia, essa influência das informações passadas para a PETR4 é maior do que para a PETR3, possivelmente devido ao fato do ativo ser preferencial nominativo, o qual é parte integrante do capital mas não dá direito à voto.

Para testar a hipótese de que o período eleitoral teria influência sobre os retornos esperados, utiliza-se o parâmetro γ associado ao evento focal de interesse, nesse caso, rejeita-se a hipótese nula de ausência de influência do período eleitoral sobre os retornos médios a um nível de significância de 5% apenas para o regime *Bull Market*. No caso do *Bear Market*, não há evidências de que o período eleitoral possa influenciar o retorno médio dos ativos.

5.1.4 Conclusão.

Devido à posição que o Brasil galga atualmente no contexto financeiro mundial, o estudo das organizações que participam do cenário econômico-financeiro é essencial para que os gestores possam tomar boas decisões, particularmente, a Petrobrás em virtude da sua presença no mercado financeiro nacional, que foi alvo de estudo neste texto.

Como a Petrobrás possui ingerência política em sua estrutura organizacional, a possibilidade da existência de um conflito agente-principal pode estar presente. Este texto examinou a hipótese de que o período eleitoral não influencia as expectativas dos acionistas e, portanto, o retorno médio dos ativos PETR3 e PETR4.

Como essa hipótese nula foi rejeitada a um nível de significância de 5% para o regime *Bull Market* (isso é, os parâmetros γ_2 para PETR3 e γ_2 para PETR4 são estatisticamente diferente de zero), inferem-se os seguintes resultados: o período eleitoral possui influência sobre o retorno médio dos ativos somente quando o regime em questão é um regime de alta (*Bull Market*); a existência de retornos anormais associados aos períodos eleitorais sugere também a presença de um conflito agente-principal como definido pela literatura de Teoria da Agência.

Esse conflito poderia ser tratado por meio da reelaboração dos contratos entre o agente e o principal adicionando ou realçando a condição da não influenciar a política nas decisões organizacionais. Outra possível solução seria o aumento do número de acionistas privados, reduzindo-se assim o poder da União, a qual é o acionista majoritário, sobre as decisões da Petrobrás.

Judicialmente, seria necessária a revisão da Lei nº 9.478, de 6 de agosto de 1997, a qual atribui à gestão da estatal indicações políticas feitas pelo presidente da república. Dessa forma, este ensaio cumpriu com os objetivos propostos, quais sejam: revisão na literatura associada à Teoria da Agência, a proposta de uma nova metodologia para o estudo e análise de eventos corporativos e a aplicação empírica para o caso da Petrobrás quanto à influência política sobre as expectativas dos acionistas.

5.2 Avaliação do efeito da distribuição dos dividendos sobre o retorno das empresas brasileiras usando misturas GARCH.

Seguindo a proposta definida no início do capítulo 5 nesta seção será apresentado o segundo ensaio no qual a proposta de misturas GARCH para Testes de Eventos é aplicada.

Dividendos são pagamentos realizados por uma empresa aos seus membros acionistas - é, dessa forma, a porção dos lucros corporativos pagos ao principal. Usualmente, quando uma empresa obtém um lucro ou excedente monetário, essa verba é alocada de duas formas: pode ser reinvestido no negócio (os chamados lucros acumulados). Ou pode ser distribuído aos acionistas. Essa redistribuição pode ocorrer de duas maneiras: por meio da recompra de ações ou através de dividendos.

Para uma sociedade anônima, o dividendo é atribuído como um montante fixo definido por unidade de ativo, portanto um acionista receberia seus dividendos proporcionalmente à sua participação. Já para uma empresa, na qual os acionistas possuem responsabilidade ilimitada (*joint stock company*), o pagamento de dividendos não é uma despesa, mas, sim, a divisão dos lucros depois de coletados os impostos entre os acionistas. Empresas públicas, todavia costumam pagar dividendos em períodos fixos, mas podem declarar a distribuição de dividendos, a qualquer período, às vezes, chamado de dividendo especial para distingui-lo dos dividendos ordinários distribuídos em períodos fixos predeterminados.

Cooperativas, por sua vez, atribuem dividendos de acordo com a atividade dos membros, de forma que seus dividendos são, muitas vezes, considerados, contabilmente, como uma despesa antes dos impostos.

Uma questão que surge no âmbito de finanças corporativas é como, em que magnitude e, até mesmo, se a distribuição dos dividendos e seus respectivos montantes afetam as expectativas dos retornos médios acionários dos diversos tipos de organizações presentes no mercado financeiro, bem como se esse efeito diferencia-se em função do regime no qual o mercado se encontra (*Bull Market* ou *Bear Market*).

Essa questão pode ser vista como um problema mais geral do ramo: Estudo de Eventos. Uma vez que o objetivo é mensurar não somente o efeito da divulgação e distribuição dos dividendos, mas também avaliar se a magnitude dessa distribuição afeta as expectativas médias dos retornos acionários.

A importância desse estudo para os gestores econômico-financeiros está centrada na for-

mulação de possíveis estratégias de divulgação e distribuição dos dividendos aos acionistas, caso exista significância estatística. Evitando, assim, possíveis “efeitos manada” e tentativas de especulação acionária.

O presente estudo tem como objetivo apresentar uma metodologia quantitativa e paramétrica para a avaliação e inferência da divulgação e distribuição dos dividendos associados às principais organizações de capital aberto cadastradas na BM&FBOVESPA, no ano de 2011 e pertencentes à composição do IBOVESPA no mesmo ano. A metodologia utilizada ajusta os principais fatos estilizados em finanças ao modelo econométrico aplicado, esse modelo pode ser considerado uma extensão da proposta de Haas (2004), o qual utiliza misturas de modelos GARCH (MN-GARCH) para ajustar séries temporais financeiras.

O ensaio está dividido da seguinte forma: na subseção 5.2.1, é apresentado o referencial teórico para o ramo de pesquisa quantitativa de estrutura de capital, centrado na distribuição e divulgação de dividendos. Os principais textos, suas propostas e resultados são apresentados. A subseção 5.2.2 expõe a proposta de misturas de GARCH, seu apelo e interpretação em finanças e como esta abordagem pode ser utilizada com base em uma série de retornos, colocando, dessa forma, uma metodologia de análise de eventos que incorpora os principais fatos estilizados. A subseção número 5.2.3 focaliza um estudo empírico utilizando misturas GARCH com o intuito de mensurar e avaliar se a distribuição e divulgação dos dividendos afeta o retorno médio das organizações brasileiras e se esse efeito se diferencia dependendo do regime de mercado. Finalmente, a última subseção, número 5.2.4, evidencia a discussão e conclusão dos resultados obtidos e as informações apresentadas neste texto.

5.2.1 Referencial teórico.

Como apresentado na primeira seção, a maneira como os dividendos são distribuídos e divulgados depende da organização que está sendo estudada. Dessa forma, nessa seção, focaliza-se o referencial teórico para o ramo de pesquisa quantitativa de estrutura de capital centrado na distribuição e divulgação de dividendos para diversos tipos de organizações. Os principais textos, suas propostas e resultados também são apresentados.

Inicialmente, Woolridge (1983) analisou o efeito de mudanças inesperadas de dividendos sobre os valores dos seguintes tipos de ações: ações ordinárias, ações preferenciais e títulos. O autor identificou dois efeitos potenciais, quais sejam: o efeito de transferência de riqueza e o efeito de sinalização. Em concordância com a literatura produzida até a época do estudo, Woolridge (1983) demonstrou que anúncios positivos (negativos) de dividendos produzem mudanças

positivas (negativas) nas variações dos preços das ações ordinárias. Woolridge (1983) afirma que esses resultados são consistentes com a hipótese de Transferência de Riqueza, a qual assevera que os dividendos são uma forma dos acionistas transferirem riquezas dos credores para si. O autor concluiu que um efeito de Transferência de Riqueza não é necessariamente descartado, mas, caso esse efeito exista, é dominado pelo Efeito de Sinalização, que afirma que alterações no pagamento de dividendos são sinais importantes sobre os lucros futuros da empresa, tanto para os investidores existentes quanto para os investidores potenciais.

Kalay e Subrahmanyam (1984) afirmam que o preço de uma ação ordinária correntemente cai em torno do dia *ex-dividend*⁵. Os autores argumentam que uma vez que as opções de compra escritas em tais subjacentes partes não estão protegidas contra o pagamento de dividendos, o estudo do comportamento dos preços de opções de compra em torno do dia *ex-dividend* é dessa forma crucial. Assumindo uma política de exercício racional por parte dos investidores, os autores demonstram que o comportamento dos preços das opções de compra americanas em torno do dia *ex-dividend* não deve ser diferente do que em qualquer outro dia escolhido arbitrariamente. No entanto a análise empírica conduzida por Kalay e Subrahmanyam (1984), a partir de métodos paramétricos e não paramétricos, indica que, talvez, em razão de uma política de exercícios “errada” por parte dos investidores, retornos anormais são observados em certos casos. Esta constatação lança algumas dúvidas sobre a presunção da eficiência do mercado americano de opção de compra em torno do dia *ex-dividend*.

Healy e Palepu (1988) referem que empresas que iniciam o pagamento de dividendos apresentam variações positivas para os ganhos, tanto antes como após a mudança da política de dividendos; enquanto as omissões de dividendos sugerem mudanças negativas para os ganhos. Os autores demonstram que alterações nos lucros estão positivamente relacionadas com o retorno dos anúncios de dividendos e que reações aos preços de ações em anúncios subsequentes são menores que o normal, desse modo, sugerindo que tais mudanças são parcialmente antecipadas no anúncio de dividendos. Healy e Palepu (1988) indicam que os investidores interpretam os anúncios de dividendos e omissões desses mesmos anúncios como as previsões dos gestores das mudanças futuras no lucro da organização.

Christie (1994) argumenta que a Teoria da Sinalização e a Teoria de Custo da Agência sobre a política de dividendos preveem que omissões nos dividendos produzem uma redução média maior nos valores dos ativos. O autor identifica uma relação em forma de “U” entre os dias de anúncio e os respectivos retornos com o percentual de queda nos dividendos. Entretanto esse efeito, segundo Christie (1994), não pode ser relacionado diretamente com as oportunidades de

⁵A data *ex-dividend* é o dia no qual uma ação passa a ser negociada *ex-dividendo*, ou seja, a partir dessa data um investidor que compra ações não possui direito a dividendos.

crescimento nem a tendência das firmas em atrasar os anúncios de omissão. O autor conclui que, enquanto as empresas que omitem o anúncio de dividendos proporcionam um maior retorno de dividendos por ações, em um prazo de cinco anos de ação; as empresas que reduzem drasticamente os pagamentos de dividendos futuros não percebem indícios de relação com a resposta do mercado.

Boyd e Jagannathan (1994) analisaram os preços das ações ordinárias em torno das datas de *ex-dividend*. Os autores argumentam que os dados dos preços normalmente contêm uma mistura de observações - algumas com e algumas sem arbitragem e/ou com atividades dos captadores de dividendos. A teoria proposta prevê que essa mistura resulta em uma relação não linear entre a queda percentual de preço e o rendimento de dividendos - e não a relação comumente assumida linear. Esta afirmação e outras hipóteses são suportadas pelos resultados obtidos empiricamente pelos autores.

Kao e Wu (1994) propõem um modelo racional de sinalização para investigar o conteúdo informativo dos dividendos. O modelo fornece um teste direto sobre a relação entre os dividendos obtidos inesperadamente e as mudanças nos ganhos. Ao identificar o componente de mudanças dos dividendos obtidos inesperadamente, os autores sugerem um quadro de expectativas que representa o processo de ajustamento de dividendos aos lucros das empresas permanentemente. O método de regressão não linear é usado para estimar o modelo e testar a racionalidade e a hipótese de sinalização. Consistentemente com o que foi proposto por Healy e Palepu (1988), as descobertas desenvolvidas por Kao e Wu (1994) demonstram que os dividendos refletem o passado, o presente e as futuras informações de ganhos.

Johnson (1995) argumenta que modelos teóricos sugerem que a dívida e os dividendos podem servir como substitutos ao livre fluxo de caixa ou dispositivos de sinalização. O autor examina as respostas dos preços das ações aos anúncios diretos de emissões de dívida e testa se existem diferenças sistemáticas entre firmas com baixo e alto payout de dividendos. Johnson (1995) conclui que a resposta dos preços das ações é significativamente positiva para o baixo crescimento de empresas com baixo pagamento de dividendos, e é negativamente relacionada com pagamento transversal de dividendos. Os resultados reforçam os argumentos de que a dívida e dividendos são substitutos e também suportam argumentos de que a dívida fornece livre fluxo de caixa ou benefícios de sinalização, mas sugerem que os benefícios são significantes apenas para as empresas com baixos níveis de substitutos. O autor documenta ainda que o pequeno crescimento do pagamento de baixos dividendos das empresas entra nos mercados de capitais com menor frequência, mas não encontra relação entre a resposta do preço das ações e esta frequência.

Acker (1999) baseia-se nos modelos apresentados por Kim e Verrecchia (1991), os quais associam à quota de volatilidade dos preços e a qualidade dos anúncios. A autora investiga as diferenças na qualidade informacional entre cortes de dividendos e as subidas dos dividendos entre anúncios de dividendos intercalares e finais. Acker (1999) indica que quando os dividendos são cortados, o anúncio provisório é percebido como sendo mais importante do que o final, enquanto que o inverso é verdadeiro, quando os dividendos são maiores. Desvios-padrão implícitos sugerem que a volatilidade esperada é um “pico” no dia do anúncio final. A autora afirma também que um “pico” é esperado após o anúncio interino de um corte no dividendo, mas não após o anúncio de um aumento.

Eaton (1999) examina os retornos das ações anormais nos três anos em torno de mudanças relativamente grandes em dividendos anunciados durante o período 1971-1990. Os principais resultados são que, estatística e economicamente, os pós-anúncios revelam retornos anormais significantes e negativos de 11% e 17% sobre o ano pós-anúncio para as empresas que diminuem dividendos e aqueles que omitem os seus dividendos.

Garrett e Priestley (2000) analisam o comportamento dos dividendos do mercado de ações global. Propõem um modelo que assume que os gestores minimizam os custos de ajuste associados com o fato de esses gestores estarem longe de seu alvo de pagamento de dividendos. A meta é expressa como uma função dos preços das ações defasadas e ganhos permanentes, generalizando os modelos anteriores de comportamento de dividendos. Garrett e Priestley (2000) inovam quanto ao uso de um novo método para medir ganhos permanentes despercebidos com base no filtro de Kalman. Essa especificação do comportamento de dividendos é fortemente apoiada pelos dados relativos a ambos os modelos alternativos e ao longo do tempo. Os autores encontram evidências significantes de suavização de dividendos e das informações transmitidas pelos dividendos com respeito a mudanças positivas inesperadas no atual ganho da firma. Garrett e Priestley (2000) afirmam também que tanto a velocidade de ajuste de dividendos aos dividendos alvos quanto testes de sinalização são sensíveis à especificação do modelo.

Naranjo, Nimalendran e Ryngaert (2000) documentam alguns fatos empíricos sobre os retornos anormais na data *ex-dividend* para ações com dividendos de alto rendimento que estão potencialmente sujeitas a captura de dividendos da empresa. Os autores ponderam que o retorno médio anormal *ex-dividend* são uniformemente negativos em cada ano após a introdução de taxas de comissão negociadas e que a variação temporal dos retornos na data *ex-dividend* durante o período negociado é consistente com as taxas de comissão e com a captura de dividendos corporativos baseados em impostos. Os retornos na data *ex-dividend* são menores

quando o benefício fiscal para captar dividendos corporativos é maior e mais positivo.

Nissim (2001) investigam a relação entre as mudanças de dividendos e de rentabilidade futura, medidos tanto em termos de ganhos futuros e ou lucros futuros anormais. Consistentemente com “o conteúdo de informação da hipótese de dividendos”, os autores assinalam que as mudanças de dividendos fornecem informações sobre o nível de rentabilidade nos anos seguintes. Nissim (2001) também documentam que mudanças de dividendos são positivamente relacionadas com as mudanças nos ganhos em cada um dos dois anos após a mudança de dividendos.

Best e Best (2001) investigam duas hipóteses sobre o conteúdo de informação de anúncios relativos à mudança de dividendos: a primeira é que a “importância” da informação sinalizada por uma mudança de dividendos depende da confiabilidade dos resultados das previsões existentes antes do anúncio de dividendos. A segunda hipótese é que a reação dos preços de ações para anúncios de mudança nos dividendos está relacionada com os ganhos como erro de previsão do tempo do anúncio de dividendos. Esses resultados revelam que o aumento nos dividendos transmite mais informações para as empresas quando pelo menos os analistas financeiros preveem com precisão os ganhos. Os resultados também indicam que o aumento de dividendos e o decréscimo de anúncios fornecem aos participantes do mercado informações que, em média, permitem-lhes diferenciar entre as empresas com base em futuras realizações de ganhos.

Koch e Sun (2004) examinam se o mercado interpreta as mudanças nos dividendos como um sinal sobre a persistência das mudanças nos ganhos passados. Os autores argumentam que antes de observar este sinal, os investidores podem acreditar que as mudanças nos lucros passados não são necessariamente indicativas dos níveis de lucros futuros. Koch e Sun (2004) investigam empiricamente se uma mudança nos dividendos altera as avaliações dos investidores sobre as implicações da valorização do salário passado. Os resultados obtidos pelos autores confirmam a hipótese de que alterações nos dividendos fazem com que os investidores revejam as suas expectativas sobre a persistência de mudanças nos ganhos passados. Este efeito varia previsivelmente com a magnitude da mudança de dividendos e o sinal da mudança dos ganhos passados.

Zhu e Yang (2008) estudaram um modelo de risco do tipo Markov-switching, onde os dividendos são pagos de acordo com uma estratégia de certo limiar, seguindo um processo Markoviano. Os autores avaliam especificamente: probabilidades de ruína, o déficit em ruína e o tempo esperado de ruína. Para estudá-los Zhu e Yang (2008) introduzem funções que envolvem o déficit em ruína e o indicador do evento que mostra a ocorrência da ruína. As funções apre-

sentadas e as expectativas do tempo de ruína são funções do capital inicial as quais satisfazem os sistemas de equações íntegro-diferenciais. Soluções com formas fechadas são derivadas quando o processo de ambiente subjacente Markoviano tem apenas dois estados e as distribuições de tamanho da reivindicação são exponenciais.

Liu, Szewczyk e Zantout (2008) utilizaram uma amostra de 2337 associadas às reduções de dividendos em dinheiro ou omissões sobre os anúncios durante o período de 1927-1999. Os autores relatam indícios de uma relação negativa e dignificante sobre o pós-anúncio, ao longo prazo dos retornos anormais. No entanto este desempenho anormal ao longo prazo é conduzido pelos ganhos pós-anúncios.

Borges (2009) discute o reajuste de preços de ações depois de uma distribuição de dividendos, permitindo diferentes tipos de investidores e imperfeições de mercado, incluindo impostos e custos de transação. Um modelo de arbitragem é desenvolvido para determinar o possível equilíbrio para o ajuste de preço das ações. Após uma distribuição de dividendos, a abordagem é teórica, proporcionando resultados gerais. Na presença de diferentes tipos de investidores, o autor evidencia a existência de um equilíbrio único existente somente na ausência de custos de transação.

Leary e Michaely (2011) documentam as propriedades transversais da suavização de dividendos para empresas públicas e as relacionam com as teorias existentes. Os autores sugerem que a suavização de dividendos é mais comum entre as empresas que não são financeiramente limitadas em face dos baixos níveis de informação assimétrica, e que essas são mais suscetíveis a conflitos de agência.

Nayak e Prabhala (2001) discutem que enquanto o folclore em finanças afirma que efeitos de valorização de divisão são devidos a aumentos nos dividendos associados com *splits*, na verdade, pouco se sabe em relação às magnitudes dos dividendos e das omissões dos mesmos como componentes de efeitos de anúncio.

Jiraporn, Kim e Kim (2011), motivados pela Teoria da Agência, investigam como a qualidade geral de uma empresa de governança corporativa afeta sua política de dividendos. Utilizando uma grande amostra de empresas com governança por meio dos dados oriundos da *Institutional Shareholder Services*, concluem que as empresas com maior governança apresentam uma maior propensão a pagar dividendos, e, similarmente, os detentores de dividendos tendem a pagar maiores dividendos. Os resultados são consistentes com a noção de que os acionistas das empresas, com melhor qualidade de governança, são capazes de forçar os gestores a distribuir mais dinheiro por meio de dividendos, reduzindo assim o que resta para desapropriação por gestores oportunistas.

Fuller e Goldstein (2011) discutem que dividendos realmente importam para os acionistas, mas importam mais em períodos de mercado em declínio (*Bear Market*) do que em mercados mais ativos (*Bull Market*). O retorno das ações que pagam dividendos supera os pagamentos das ações que não o fazem em torno de 1 a 2% a mais por mês, nos mercados em declínio do que nos mercados ativos (*Bull Market*). Fuller e Goldstein (2011) afirmam que estes resultados são economicamente e estatisticamente significantes e robustos para ajustes de risco. Os autores encontram uma resposta assimétrica às mudanças de dividendos com base nas condições de mercado: o aumento de dividendos influencia mais mercados em declínio do que mercados em alta ou mais ativos.

Apesar da vasta literatura sobre divulgação de dividendos e sua influência nos mercados internacionais, escassa é a literatura nacional e, mais saliente do que isso, poucas abordagens incorporam os principais fatos estilizados em finanças discutidos e apresentados por Cont (2001).

A proposta desse texto é medir, testar e avaliar o impacto da divulgação de dividendos das empresas brasileiras que compõem o IBOVESPA por meio do modelo de misturas GARCH, proposto por Haas (2004), o qual incorpora os principais fatos estilizados em finanças e, dessa forma, estima o impacto da distribuição de dividendos de maneira mais fidedigna, metodologia essa apresentada na próxima subseção.

5.2.2 Metodologia.

O evento focal pode ocorrer em diferentes pontos no tempo do calendário ou pode ser agrupado em uma determinada data, como eventos que ocorrem semanal, semestral ou ainda anualmente, e tem como principal objetivo investigar se a distribuição dos retornos no tempo de um evento é anormal em relação ao valor predito do mesmo ativo.

Um modelo de retornos normais deve ser especificado antes do processo de estimação e definição da anormalidade do retorno (KHOTARI; WARNER, 2006). Logo, existe uma grande variedade de modelos associados aos retornos de ativos. Para cada amostra $i = 1, \dots, n$ dos ativos associados as n corporações em estudo, o retorno do ativo (ou portfólio) i associado a i -ésima organização para o período t de tempo em relação ao evento, é dada por $R_{i\tau}$, o qual pode ser representado matematicamente por:

$$\mathbb{E}(R_{i\tau} | \mathcal{F}_\tau) = \mu_\tau + \varepsilon_{i\tau} \quad (5.3)$$

onde $R_{i\tau}$ é o nível “normal”, em outras palavras, é o retorno esperado ou previsto dado um determinado modelo, e $\varepsilon_{i\tau}$, é o componente do retorno que é anormal ou não esperado.

Dada esta decomposição do retorno, o retorno anormal $\varepsilon_{i\tau}$ pode ser expresso como a diferença entre o retorno observado e o retorno previsto. Equivalentemente, $\varepsilon_{i\tau}$ é a diferença entre o retorno condicional sobre o evento e o retorno esperado. Assim, o retorno anormal é uma medida direta da mudança inesperada na riqueza da organização associado ao evento em questão. Os diferentes métodos usualmente utilizados em estudo e análise de eventos se diferem na estrutura μ_τ associada ao modelo. Há quatro grandes modelos frequentemente aplicados, quais sejam:

Tabela 5.6: Estruturas funcionais usuais em estudo de eventos.

Fonte: Elaboração do autor.

Modelo	Estrutura funcional
<i>Constant Mean Return Model</i>	$\mu_\tau = \mu + 1_{[T_1 < \tau \leq T_2]}(\tau)\gamma$
<i>Market Model</i>	$\mu_\tau = \alpha + \beta R_{m\tau} + 1_{[T_1 < \tau \leq T_2]}(\tau)\gamma$
<i>CAPM Model</i>	$\mu_\tau = R_{rf\tau} + \beta [\mathbb{E}(R_{m\tau}) - R_{rf\tau}] + 1_{[T_1 < \tau \leq T_2]}(\tau)\gamma$

Onde $1_{[T_1 < \tau \leq T_2]}(\tau)$ representa uma variável *dummy*, a qual assume valor unitário na presença do evento focal, e suas intermediações T_1 e T_2 , associado ao i -ésimo ativo e zero caso contrário e $R_{m\tau}$, $R_{rf\tau}$ representam respectivamente os retornos de mercado e livre de risco no período τ .

Para o modelo *Constant Mean Return Model* (CMRM) assume-se usualmente que a média é constante para todo o ativo i e o resíduo $\varepsilon_{i\tau}$ segue uma distribuição normal com variância constante (homocedástica), Brown e Warner (1980) argumentam que este modelo, apesar de simples, produz, frequentemente, resultados semelhantes aos dos modelos mais sofisticados, pois a variância dos retornos anormais não é reduzida mesmo que um modelo complexo seja utilizado.

No caso do *Market Model* (MM), $R_{m\tau}$ é o retorno sobre a carteira de mercado, e a especificação linear do modelo segue também um pressuposto de normalidade dos retornos e homoscedasticidade. Note que para esse modelo, quando $\beta = 0$, o modelo de mercado recai no modelo de retorno com média constante, o que o torna uma generalização do primeiro. O modelo de mercado representa uma melhoria em potencial em relação ao modelo de retorno com média constante, removendo a parte do o retorno associada ao retorno do mercado.

Já o modelo CAPM possui em sua estrutura mais simplista, apenas um fator de risco sistemático: o do risco do movimento geral do mercado, o qual é referido como risco de mercado,

a saber: $R_{m\tau}$, já o termo $R_{r,f\tau}$ representa o retorno do ativo livre de risco.

Entre os métodos de estimação dos modelos apresentados na tabela 5.6, estão mínimos quadrados ordinários e máxima verossimilhança. Todavia estudos que se utilizam dessas metodologias geralmente possuem como pressupostos: independência entre as observações, variância constante e normalidade. Nesses casos, esses estudos podem incorrer em uma inferência errônea, pois seus pressupostos não são satisfeitos para a maioria das séries financeiras e, assim, podem não possuir a significância estatística desejada, podendo, em situações extremas, invalidar o estudo. Entre os principais fatos estilizados em finanças, estão aglomerações de volatilidade, retornos com assimetria positiva, retornos com caudas pesadas e desvios da normalidade. Dessa forma qualquer teste de eventos deve considerar essas características para que o mesmo seja considerado robusto e sua inferência seja a mais escoreita o possível.

Admite-se, no entanto, que o mercado é composto de dois regimes, os quais compõem uma mistura de normais. Especificamente, suponha que haja dois regimes de mercado *Bull Market* (períodos de alta) e o *Bear Market* (períodos de baixa). A série financeira, quando observada diretamente, apresenta uma mistura desses dois tipos de mercados, de modo que a distribuição resultante possua assimetria positiva.

É possível também mostrar que qualquer distribuição contínua pode ser arbitrariamente bem-aproximada por uma mistura finita de distribuições normais, com variância comum no caso univariado, ou com matriz de covariância comum no caso multivariado (MCLAUGHLAN, 2000). Assim, a distribuição da série financeira tem um apelo natural quanto à utilização de regimes para sua modelagem e, por meio de misturas de distribuição, pode-se modelar os principais fatos estilizados em finanças, assim, fornecendo uma metodologia robusta para o cômputo e inferência do efeito dos eventos focais nas organizações.

A proposta deste texto é a construção de uma metodologia para estudo de eventos em finanças corporativas que incorpore os principais fatos estilizados em finanças, para isso, utilizou-se a proposta de Haas (2004) o qual considera uma mistura de distribuições normais juntamente com uma estrutura do tipo GARCH (denominada MN-GARCH) permitindo assim uma variância condicional para cada um dos componentes da mistura, bem como um *feedback* dinâmico entre os componentes. Nessa abordagem, o modelo MN-GARCH pode gerar uma desagregação do processo variância condicional em que os componentes da volatilidade dinâmica têm um comportamento, claramente diferenciados, o que é compatível com a proposta de estudos de eventos, onde a hipótese a ser testada é se após a ocorrência do evento focal os retornos médios observados (juntamente com sua variância condicional) se alteraram.

A série temporal $R_{i\tau}$ é assumida ser gerada por uma mistura de 2-componentes $GARCH(1, 1)$

como apresentado em 4.2; já a estimação dos parâmetros do modelo foi realizado por meio do algoritmo EM descrito em 3.3.

5.2.3 Análise empírica.

Segundo a BM&FBOVESPA (2011), o IBOVESPA é o valor atual, em moeda corrente, de uma carteira teórica de ações constituída em 02/01/1968 (valor-base: 100 pontos), a partir de uma aplicação hipotética, onde se supõe não ter sido efetuado nenhum investimento adicional desde então, considerando-se somente os ajustes efetuados em decorrência da distribuição de proventos pelas empresas emissoras. Dessa forma, o índice reflete não apenas as variações dos preços das ações, mas também o impacto da distribuição dos proventos, sendo considerado um indicador que avalia o retorno total de suas ações componentes.

A finalidade básica do IBOVESPA é a de servir como indicador médio do comportamento do mercado. Neste contexto, o presente trabalho mediu o efeito da distribuição de dividendos e sua magnitude para as empresas que compõem o IBOVESPA, a saber:

Tabela 5.7: Empresas que compõem o IBOVESPA listadas em Outubro de 2011.

Fonte: Elaboração do autor.

Nomenclatura	Nomenclatura	Nomenclatura	Nomenclatura
ALLL3*	CPLE6	HYPE3*	PETR4
AMBV4	CRUZ3	ITSA4*	RDCD3
BBAS3	CSAN3	ITUB4*	RSID3
BBDC4	CSNA3	JBSS3*	SANB11
BISA3	CYRE3	KLBN4*	SBSP3*
BRAP4*	DTEX3*	LAME4*	TAMM4
BRFS3	ECOD3*	LIGT3	TIMP3
BRKM5	ELET3	LLXL3*	TLPP4
BRML3*	ELET6	LREN3	TMAR5
BRTO4	ELPL4	MMXM3*	TNLP3
BTOW3	EMBR3	MRFG3	TNLP4
BVMF3	FIBR3*	MRVE3*	TRPL4
CCRO3	GFSA3*	NATU3	UGPA3
CESP6	GGBR4*	OGXP3*	USIM3
CIEL3	GOAU4*	PCAR4	USIM5
CMIG4	GOLL4*	PDGR3	VALE3
CPFE3	HGTX3*	PETR3	VALE5

onde as empresas com asterisco não foram estudadas devido à pequena quantidade de dados disponíveis.

Utilizando os retornos dos ativos das empresas listadas na tabela 5.7 e o valor do retorno do dividendo no período de divulgação (valor do fechamento no dia), os três modelos descritos na tabela 5.6 foram estimados por meio de misturas GARCH, fornecendo, assim, estimativas para cada regime de mercado. A janela temporal foi definida com base no retorno do dividendo da organização, ou seja, na data de distribuição dos dividendos, a janela assumiu valor igual ao retorno do dividendo e fora dessas datas valor igual a zero.

Para escolher o modelo que melhor se adequou aos dados e que minimiza a perda de informação definiu-se como critério de informação a medida de Akaike (1974), denominada AIC, o qual oferece uma medida relativa da perda de informações quando um determinado modelo é usado para descrever a realidade, dessa forma, obteve-se:

Tabela 5.8: Modelos estimados e seus respectivos AICs.

Fonte: Elaboração do autor.

Empresa	AIC CMRM	AIC MM	AIC CAPM	Empresa	AIC CMRM	AIC MM	AIC CAPM
ALLL3	-6922,52	-6606,84	-6610,84	LIGT3	-5401,36	-5072,17	-5072,07
ALLL3	-16374,6	-15461,2	-15465,2	LLXL3	-3305,67	-3130,34	-3134,34
BBAS3	-18832,2	-17288,7	-17292,7	LREN3	-7195,88	-6735,65	-6739,65
BBDC4	-17917,1	-14986,6	-15403,6	MMXM3	-5398,52	-5153,31	-5157,31
BISA3	-4975,76	-4909,46	-4920,16	MRFG3	-4111,95	-4079,98	-4063,26
BRAP4	-12312,5	-10484,3	-10488,3	MRVE3	-4619,79	-4203,05	-4188,6
BRFS3	-15332,1	-14938,7	-14942,7	NATU3	-7256,61	-7161,02	-7026,51
BRKM5	-18810,4	-17548,3	-17552,3	OGXP3	-3381,09	-3180,25	-3167,65
BRML3	-4550,64	-4424,81	-4409,87	PCAR4	-16325	-15978,7	-15982,7
BRTO4	-19402,4	-17679,8	-16918,6	PDGR3	-5055,4	-4652,54	-4671,94
BTOW3	-7149,1	-6593,64	-6600,88	PETR3	-18167,8	-16186,2	-16190,2
BVMF3	-2877,34	-2472,25	-2400,21	PETR4	-17762,7	-14731,7	-14735,7
CCRO3	-9579,15	-9567,35	-9571,35	RDCD3	-4212,54	-3963,19	-3896,33
CESP6	-5157,94	-4694,04	-4842,04	RSID3	-12819,5	-12549,7	-12553,7
CIEL3	-1604,43	-1520,73	-1481,6	SANB11	-1219,44	-1100,71	-1105,1
CMIG4	-14635,6	-12757,2	-12761,2	SBSP3	-16369	-14521,9	-14525,9
CPFE3	-6299,41	-5797,69	-5878,51	TAMM4	-7723,08	-7120,85	-7124,85
CPLE6	-16795,2	-15054	-15126	TIMP3	-15999,5	-15048,6	-15052,6
CRUZ3	-17114,4	-16514,7	-16518,7	TLPP4	-13244	-12099	-12103
CSAN3	-6548,5	-6055,34	-6050,56	TMAR5	-18945,6	-17440,5	-17444,5
CSNA3	-18615,4	-17601,3	-17605,3	TNLP3	-14988,2	-12950,6	-12954,6
CYRE3	-7123,44	-6497,61	-6494,39	TNLP4	-14026,8	-11825,6	-11763,4
DTEX3	-3729,91	-3759,86	-3763,86	TRPL4	-13496,3	-12687,5	-12589
ECOD3	-5106,24	-4928,2	-4932,2	UGPA3	-11525,2	-10928	-10950
ELET3	-19444,5	-16901,5	-16905,5	USIM3	-13029,3	-12220,1	-12224,1
ELET6	-19404,1	-16451	-16455	USIM5	-14819,4	-12840,8	-12458,7
ELPL4	-4689,49	-4187,26	-4197,55	VALE3	-17772,4	-15852,7	-15856,7
EMBR3	-14005,1	-13632	-13636	VALE5	-17640	-15238,4	-15242,4

Os log-retornos diários foram obtidos para cada uma das ações apresentadas na tabela 5.8 por meio do sistema *Bloomberg*, para os anos de 1995 a 2010. Assim como no ensaio apresentado na seção 5.1 todas as séries trabalhadas rejeitaram a hipótese nula de raiz unitária a um nível crítico de 1% pelo teste de Dickey-Fuller aumentado. É interessante notar que para todos os modelos estimados, o Modelo de Média Constante (CMRM) foi aquele que apresentou menor critério de informação de Akaike.

Em seguida, o modelo de CMRM foi estimado assumindo que o mesmo se diferencia em dois regimes de mercado e possui heterocedasticidade condicionada no tempo. Os parâmetros estimados e seus respectivos erros-padrão são apresentados a seguir para cada um dos regimes de mercado:

Tabela 5.9: Estimativas dos melhores modelos segundo critério de informação de AKAIKE para as empresas do IBOVESPA.

Elaboração do autor.

Empresa	Parâmetro	Estimativa	Estatística	Significância
AMBV4	λ_1	0,21023	0,00648	<0,0001
AMBV4	α_{01}	1,13188	5,10073	0,82439
AMBV4	α_{11}	0,28028	6,62022	<0,0001
AMBV4	θ_{11}	0,70327	14,66504	<0,0001
AMBV4	μ_1	0,01757	1,68828	0,09136
AMBV4	γ_1	0,06935	7,9345	<0,0001
AMBV4	$1 - \lambda_1$	0,78977	0,00648	<0,0001
AMBV4	α_{02}	0,91162	99,1927	<0,0001
AMBV4	α_{12}	0,08289	0,91843	0,3584
AMBV4	θ_{12}	0,46348	1,07542	0,28219
AMBV4	μ_2	0,11615	4,17312	0,00003
AMBV4	γ_2	-0,3949	-1,40044	0,16138
BBAS3	λ_1	0,35556	0,00765	<0,0001
BBAS3	α_{01}	0,6652	4,90128	<0,0001
BBAS3	α_{11}	0,61385	11,92922	<0,0001
BBAS3	θ_{11}	0,32598	9,1997	<0,0001
BBAS3	μ_1	0,11421	3,90314	0,00009
BBAS3	γ_1	0,03504	6,28604	<0,0001
BBAS3	$1 - \lambda_1$	0,64444	0,00765	<0,0001
BBAS3	α_{02}	0,95256	117,90862	<0,0001
BBAS3†	α_{12}	-0,08441	-1,65288	0,09836
BBAS3†	θ_{12}	-1,22655	-1,63963	0,10108
BBAS3	μ_2	0,1581	2,87942	0,00398
BBAS3	γ_2	0,18623	0,93528	0,34964
BBDC4	λ_1	0,10972	0,00497	<0,0001
BBDC4	α_{01}	1,88127	4,60112	<0,0001
BBDC4	α_{11}	0,63208	6,78904	<0,0001
BBDC4	θ_{11}	0,36437	5,16687	<0,0001
BBDC4	μ_1	0,1959	3,66631	0,00025

Continua na próxima página

Tabela 5.9 – Continuação da página anterior

Empresa	Parâmetro	Estimativa	Estatística	Significância
BBDC4	γ_1	0,08972	6,69103	<0,0001
BBDC4	$1 - \lambda_1$	0,89028	0,00497	<0,0001
BBDC4	α_{02}	0,87532	45,62585	<0,0001
BBDC4†	α_{12}	-0,36409	-3,0257	0,00248
BBDC4†	θ_{12}	-0,42244	*	*
BBDC4	μ_2	0,06995	1,90243	0,05711
BBDC4	γ_2	-1,05902	-25,3649	<0,0001
BISA3	λ_1	0,15736	0,01134	<0,0001
BISA3	α_{01}	6,83941	2,00279	0,0452
BISA3	α_{11}	0,68633	2,73942	0,00615
BISA3	θ_{11}	0,18088	0,61025	0,54169
BISA3	μ_1	0,13531	2,26356	0,0236
BISA3	γ_1	0,07436	4,79577	<0,0001
BISA3	$1 - \lambda_1$	0,84264	0,01134	<0,0001
BISA3	α_{02}	0,89484	49,21907	<0,0001
BISA3	α_{12}	1,29201	4,58629	<0,0001
BISA3†	θ_{12}	-2,8263	-1,50074	0,13342
BISA3	μ_2	-0,29739	-3,6164	0,0003
BISA3	γ_2	-0,04517	-0,12632	0,89948
BRFS3	λ_1	0,12161	0,00568	<0,0001
BRFS3	α_{01}	1,61203	*	*
BRFS3	α_{11}	0,08798	3,48859	0,00049
BRFS3	θ_{11}	0,88581	*	*
BRFS3	μ_1	0,28263	5,32069	<0,0001
BRFS3	γ_1	0,14763	9,62312	<0,0001
BRFS3	$1 - \lambda_1$	0,87839	0,00568	<0,0001
BRFS3	α_{02}	0,7777	38,46651	<0,0001
BRFS3	α_{12}	0,0694	0,31537	0,75248
BRFS3†	θ_{12}	-1,55142	-6,86643	<0,0001
BRFS3	μ_2	0,01068	0,27715	0,78166
BRFS3	γ_2	1,06737	1,11138	0,26641

Continua na próxima página

Tabela 5.9 – Continuação da página anterior

Empresa	Parâmetro	Estimativa	Estatística	Significância
BRKM5	λ_1	0,24185	0,00682	<0,0001
BRKM5	α_{01}	1,31346	5,60182	<0,0001
BRKM5	α_{11}	0,65822	9,54033	<0,0001
BRKM5	θ_{11}	0,32255	8,65532	<0,0001
BRKM5	μ_1	0,09885	3,31996	0,0009
BRKM5	γ_1	0,06574	8,55546	<0,0001
BRKM5	$1 - \lambda_1$	0,75815	0,00682	<0,0001
BRKM5	α_{02}	0,92245	103,56705	<0,0001
BRKM5	α_{12}	0,12619	3,38631	0,00071
BRKM5	θ_{12}	0,51101	*	*
BRKM5	μ_2	-0,08386	-1,82766	0,0676
BRKM5	γ_2	0,67436	1,81686	0,06924
BRT04	λ_1	0,24589	0,00686	<0,0001
BRT04	α_{01}	1,39425	5,35634	<0,0001
BRT04	α_{11}	0,40268	8,11537	<0,0001
BRT04	θ_{11}	0,52948	12,09191	<0,0001
BRT04	μ_1	0,1108	3,93487	0,00008
BRT04	γ_1	0,02989	7,89724	<0,0001
BRT04	$1 - \lambda_1$	0,75411	0,00686	<0,0001
BRT04	α_{02}	0,95499	160,44744	<0,0001
BRT04†	α_{12}	-0,24363	-2,83183	0,00463
BRT04	θ_{12}	0,13449	0,25544	0,79838
BRT04	μ_2	0,0731	1,46737	0,14228
BRT04	γ_2	0,56935	1,71234	0,08683
BTOW3	λ_1	0,10035	0,00797	<0,0001
BTOW3	α_{01}	1,18783	1,28201	0,19984
BTOW3	α_{11}	0,19305	2,58936	0,00962
BTOW3	θ_{11}	0,6699	4,88172	<0,0001
BTOW3	μ_1	1,139	3,90264	0,0001
BTOW3	γ_1	0,14621	5,95673	<0,0001
BTOW3	$1 - \lambda_1$	0,89965	0,00797	<0,0001

Continua na próxima página

Tabela 5.9 – Continuação da página anterior

Empresa	Parâmetro	Estimativa	Estatística	Significância
BTOW3	α_{02}	0,74277	16,46013	<0,0001
BTOW3†	α_{12}	-0,04957	-0,21564	0,82927
BTOW3	θ_{12}	0,82726	*	*
BTOW3	μ_2	0,02471	0,30512	0,76028
BTOW3	γ_2	0,42354	0,23804	0,81185
BVMF3	λ_1	0,1015	0,0125	<0,0001
BVMF3	α_{01}	3,11806	4,1993	0,00003
BVMF3	α_{11}	0,1975	1,70946	0,08737
BVMF3	θ_{11}	0,77286	13,37888	<0,0001
BVMF3	μ_1	0,08504	1,38143	0,16715
BVMF3	γ_1	0,11711	4,95316	<0,0001
BVMF3	$1 - \lambda_1$	0,8985	0,0125	<0,0001
BVMF3	α_{02}	0,85532	32,68186	<0,0001
BVMF3	α_{12}	0,84402	1,4499	0,14709
BVMF3	θ_{12}	0,27506	*	*
BVMF3	μ_2	-0,04498	-0,45285	0,65066
BVMF3	γ_2	-0,3647	-1,00378	0,31548
CCRO3	λ_1	0,11986	0,00707	<0,0001
CCRO3	α_{01}	2,01326	*	*
CCRO3	α_{11}	0,13051	3,95167	0,00008
CCRO3	θ_{11}	0,84811	*	*
CCRO3	μ_1	0,26022	3,13848	0,0017
CCRO3	γ_1	0,04355	4,47437	0,00001
CCRO3	$1 - \lambda_1$	0,88014	0,00707	<0,0001
CCRO3	α_{02}	0,8848	33,3107	<0,0001
CCRO3	α_{12}	0,46624	1,75885	0,0786
CCRO3†	θ_{12}	-0,08155	-0,14216	0,88695
CCRO3	μ_2	0,13179	2,73055	0,00632
CCRO3	γ_2	0,13261	1,05628	0,29084
CESP6	λ_1	0,09976	0,00908	<0,0001
CESP6	α_{01}	0,5985	1,25952	0,20784

Continua na próxima página

Tabela 5.9 – Continuação da página anterior

Empresa	Parâmetro	Estimativa	Estatística	Significância
CESP6	α_{11}	0,20622	1,64763	0,09943
CESP6	θ_{11}	0,74161	5,54708	<0,0001
CESP6	μ_1	0,51946	3,6364	0,00028
CESP6	γ_1	0,24492	5,91877	<0,0001
CESP6	$1 - \lambda_1$	0,90024	0,00908	<0,0001
CESP6	α_{02}	0,71254	16,87246	<0,0001
CESP6†	α_{12}	-0,17484	-0,7335	0,46325
CESP6	θ_{12}	0,11005	0,19991	0,84155
CESP6	μ_2	0,09115	1,20951	0,22647
CESP6	γ_2	1,00653	0,66233	0,50776
CIEL3	λ_1	0,09903	0,01549	<0,0001
CIEL3	α_{01}	2,1598	1,09811	0,27216
CIEL3	α_{11}	0,30952	1,23291	0,21761
CIEL3	θ_{11}	0,25855	0,67055	0,50251
CIEL3	μ_1	2,91442	3,58141	0,00034
CIEL3	γ_1	0,30862	3,47229	0,00052
CIEL3	$1 - \lambda_1$	0,90097	0,01549	<0,0001
CIEL3	α_{02}	0,12997	0,76469	0,44446
CIEL3	α_{12}	0,03859	0,11301	0,91002
CIEL3†	θ_{12}	-0,11035	-0,16033	0,87262
CIEL3	μ_2	-0,01371	-0,11877	0,90546
CIEL3	γ_2	-0,18901	-0,92061	0,35726
CMIG4	λ_1	0,10146	0,00542	<0,0001
CMIG4	α_{01}	0,33652	1,53019	0,12597
CMIG4	α_{11}	0,19712	3,95648	0,00008
CMIG4	θ_{11}	0,78175	12,80505	<0,0001
CMIG4	μ_1	0,09496	2,79834	0,00514
CMIG4	γ_1	0,08491	6,70587	<0,0001
CMIG4	$1 - \lambda_1$	0,89854	0,00542	<0,0001
CMIG4	α_{02}	0,90328	61,70125	<0,0001
CMIG4	α_{12}	0,44754	3,23233	0,00123

Continua na próxima página

Tabela 5.9 – Continuação da página anterior

Empresa	Parâmetro	Estimativa	Estatística	Significância
CMIG4†	θ_{12}	-0,2613	-0,34542	0,72978
CMIG4	μ_2	-0,0893	-2,00305	0,04517
CMIG4	γ_2	0,41628	1,60385	0,10875
CPFE3	λ_1	0,11206	0,00803	<0,0001
CPFE3	α_{01}	0,95996	1,99162	0,04641
CPFE3	α_{11}	0,54684	4,00153	0,00006
CPFE3	θ_{11}	0,39608	3,11268	0,00185
CPFE3	μ_1	0,1015	2,17089	0,02994
CPFE3	γ_1	0,04561	4,6029	<0,0001
CPFE3	$1 - \lambda_1$	0,88794	0,00803	<0,0001
CPFE3	α_{02}	0,92456	46,16117	<0,0001
CPFE3	α_{12}	0,2952	2,05459	0,03992
CPFE3†	θ_{12}	-0,00669	-0,02465	0,98034
CPFE3	μ_2	0,03273	0,6708	0,50235
CPFE3	γ_2	-0,14346	-1,29288	0,19605
CPLE6	λ_1	0,10043	0,00512	<0,0001
CPLE6	α_{01}	0,31829	19,18123	<0,0001
CPLE6	α_{11}	0,14906	4,33263	0,00001
CPLE6	θ_{11}	0,83895	30,64775	<0,0001
CPLE6	μ_1	0,23575	3,33669	0,00085
CPLE6	γ_1	0,10343	6,59917	<0,0001
CPLE6	$1 - \lambda_1$	0,89957	0,00512	<0,0001
CPLE6	α_{02}	0,86995	40,43081	<0,0001
CPLE6	α_{12}	0,28371	1,94951	0,05123
CPLE6†	θ_{12}	-0,84056	*	*
CPLE6	μ_2	0,09101	2,00794	0,04465
CPLE6	γ_2	0,78626	1,05186	0,29286
CRUZ3	λ_1	0,09994	0,00479	<0,0001
CRUZ3	α_{01}	1,38608	*	*
CRUZ3	α_{11}	0,07927	2,21461	0,02679
CRUZ3	θ_{11}	0,92001	*	*

Continua na próxima página

Tabela 5.9 – Continuação da página anterior

Empresa	Parâmetro	Estimativa	Estatística	Significância
CRUZ3	μ_1	0,39725	6,72861	<0,0001
CRUZ3	γ_1	0,16673	9,42971	<0,0001
CRUZ3	$1 - \lambda_1$	0,90006	0,00479	<0,0001
CRUZ3	α_{02}	0,70067	25,67991	<0,0001
CRUZ3†	α_{12}	-0,31533	-1,33087	0,18323
CRUZ3†	θ_{12}	-0,1726	-0,43222	0,66558
CRUZ3	μ_2	0,12083	3,9094	0,00009
CRUZ3	γ_2	0,12117	1,72284	0,08492
CSAN3	λ_1	0,09983	0,00844	<0,0001
CSAN3	α_{01}	1,24606	4,20501	0,00003
CSAN3	α_{11}	0,17513	1,84066	0,06567
CSAN3	θ_{11}	0,72807	8,09642	<0,0001
CSAN3	μ_1	0,81844	2,53285	0,01131
CSAN3	γ_1	0,16681	4,63552	<0,0001
CSAN3	$1 - \lambda_1$	0,90017	0,00844	<0,0001
CSAN3	α_{02}	0,77441	14,64306	<0,0001
CSAN3	α_{12}	0,0389	1,45018	0,14701
CSAN3	θ_{12}	0,74039	*	*
CSAN3	μ_2	0,0398	0,43677	0,66228
CSAN3	γ_2	1,51017	1,01516	0,31003
CSNA3	λ_1	0,0926	0,00461	<0,0001
CSNA3	α_{01}	0,04607	7,6895	<0,0001
CSNA3	α_{11}	0,10176	2,98614	0,00283
CSNA3	θ_{11}	0,08947	11,6692	<0,0001
CSNA3	μ_1	0,38032	5,70286	<0,0001
CSNA3	γ_1	0,14543	10,2096	<0,0001
CSNA3	$1 - \lambda_1$	0,9074	0,00461	<0,0001
CSNA3	α_{02}	0,76037	34,70232	<0,0001
CSNA3†	α_{12}	-0,75236	-2,66435	0,00771
CSNA3	θ_{12}	0,75193	*	*
CSNA3	μ_2	0,08499	2,33551	0,01952

Continua na próxima página

Tabela 5.9 – Continuação da página anterior

Empresa	Parâmetro	Estimativa	Estatística	Significância
CSNA3	γ_2	0,0301	0,21469	0,83001
CYRE3	λ_1	0,10023	0,00819	<0,0001
CYRE3	α_{01}	0,82845	1,26504	0,20586
CYRE3	α_{11}	0,12197	1,83501	0,0665
CYRE3	θ_{11}	0,83642	10,18245	<0,0001
CYRE3	μ_1	0,76783	3,36188	0,00077
CYRE3	γ_1	0,16024	5,21212	<0,0001
CYRE3	$1 - \lambda_1$	0,89977	0,00819	<0,0001
CYRE3	α_{02}	0,79437	22,21981	<0,0001
CYRE3	α_{12}	0,07565	0,25145	0,80147
CYRE3	θ_{12}	0,2047	0,17915	0,85782
CYRE3	μ_2	0,12763	1,35798	0,17447
CYRE3	γ_2	-0,19532	-0,30521	0,7602
ELET3	λ_1	0,13056	0,00536	<0,0001
ELET3	α_{01}	2,42914	2,2513	0,02437
ELET3	α_{11}	0,19755	4,48102	0,00001
ELET3	θ_{11}	0,79163	12,03352	<0,0001
ELET3	μ_1	0,23558	4,61262	<0,0001
ELET3	γ_1	0,1432	10,11615	<0,0001
ELET3	$1 - \lambda_1$	0,86944	0,00536	<0,0001
ELET3	α_{02}	0,80565	44,50712	<0,0001
ELET3†	α_{12}	-0,00063	-0,00318	0,99746
ELET3†	θ_{12}	-0,47382	-0,6035	0,54618
ELET3	μ_2	0,02447	0,61048	0,54155
ELET3	γ_2	0,31799	0,60519	0,54505
ELET6	λ_1	0,17834	0,00609	<0,0001
ELET6	α_{01}	1,54082	10,08726	<0,0001
ELET6	α_{11}	0,19737	5,68397	<0,0001
ELET6	θ_{11}	0,78759	31,86747	<0,0001
ELET6	μ_1	0,06525	2,62977	0,00854
ELET6	γ_1	0,08111	8,64231	<0,0001

Continua na próxima página

Tabela 5.9 – Continuação da página anterior

Empresa	Parâmetro	Estimativa	Estatística	Significância
ELET6	$1 - \lambda_1$	0,82166	0,00609	<0,0001
ELET6	α_{02}	0,89743	80,5862	<0,0001
ELET6†	α_{12}	-0,15489	-1,1421	0,25341
ELET6†	θ_{12}	-1,16486	*	*
ELET6	μ_2	-0,05145	-1,25805	0,20837
ELET6	γ_2	0,10694	0,91618	0,35957
ELPL4	λ_1	0,32795	0,01439	<0,0001
ELPL4	α_{01}	0,17849	0,73004	0,46536
ELPL4	α_{11}	0,17187	4,44143	0,00001
ELPL4	θ_{11}	0,82595	13,35544	<0,0001
ELPL4	μ_1	0,69346	1,50395	0,13259
ELPL4	γ_1	0,02959	1,26306	0,20657
ELPL4	$1 - \lambda_1$	0,67205	0,01439	<0,0001
ELPL4	α_{02}	0,81629	6,81015	<0,0001
ELPL4†	α_{12}	-0,00214	-0,01907	0,98479
ELPL4†	θ_{12}	-0,54709	-1,83406	0,06664
ELPL4	μ_2	0,02295	0,2868	0,77427
ELPL4	γ_2	-0,1689	-1,25881	0,2081
EMBR3	λ_1	0,19122	0,00717	<0,0001
EMBR3	α_{01}	1,73432	3,57068	0,00036
EMBR3	α_{11}	0,16861	6,47939	<0,0001
EMBR3	θ_{11}	0,82822	26,21437	<0,0001
EMBR3	μ_1	0,9902	3,868	0,00011
EMBR3	γ_1	0,08896	7,34068	<0,0001
EMBR3	$1 - \lambda_1$	0,80878	0,00717	<0,0001
EMBR3	α_{02}	0,64555	10,4088	<0,0001
EMBR3†	α_{12}	-0,33312	-1,91496	0,0555
EMBR3†	θ_{12}	-0,65689	-0,60704	0,54383
EMBR3	μ_2	-0,09422	-2,25169	0,02434
EMBR3	γ_2	0,34282	1,84529	0,06499
LIGT3	λ_1	0,11861	0,00935	<0,0001

Continua na próxima página

Tabela 5.9 – Continuação da página anterior

Empresa	Parâmetro	Estimativa	Estatística	Significância
LIGT3	α_{01}	2,65053	*	*
LIGT3	α_{11}	0,24247	*	*
LIGT3	θ_{11}	0,70402	*	*
LIGT3	μ_1	0,04879	1,00133	0,31667
LIGT3	γ_1	0,04672	3,51996	0,00043
LIGT3	$1 - \lambda_1$	0,88139	0,00935	<0,0001
LIGT3	α_{02}	0,92987	39,36243	<0,0001
LIGT3†	α_{12}	-0,4746	-1,49239	0,1356
LIGT3†	θ_{12}	-0,36234	-0,36232	0,71711
LIGT3	μ_2	0,133	2,1516	0,03143
LIGT3	γ_2	0,32954	2,69099	0,00712
LREN3	λ_1	0,15116	0,0095	<0,0001
LREN3	α_{01}	2,45344	*	*
LREN3	α_{11}	0,18861	*	*
LREN3	θ_{11}	0,80707	*	*
LREN3	μ_1	1,87473	6,21116	<0,0001
LREN3	γ_1	0,22535	6,45304	<0,0001
LREN3	$1 - \lambda_1$	0,84884	0,0095	<0,0001
LREN3	α_{02}	0,5003	9,42644	<0,0001
LREN3	α_{12}	0,07336	0,23044	0,81775
LREN3†	θ_{12}	-1,33279	-1,48036	0,13878
LREN3	μ_2	0,18783	2,50523	0,01224
LREN3	γ_2	-0,21341	-0,49025	0,62396
MRFG3	λ_1	0,15325	0,01225	<0,0001
MRFG3	α_{01}	5,96839	2,85223	0,00434
MRFG3	α_{11}	0,41621	1,83619	0,06633
MRFG3	θ_{11}	0,52507	34,72552	<0,0001
MRFG3	μ_1	0,0481	3,18132	0,00147
MRFG3	γ_1	0,08482	5,60946	<0,0001
MRFG3	$1 - \lambda_1$	0,84675	0,01225	<0,0001
MRFG3	α_{02}	0,88169	66,57605	<0,0001

Continua na próxima página

Tabela 5.9 – Continuação da página anterior

Empresa	Parâmetro	Estimativa	Estatística	Significância
MRFG3	α_{12}	1,56892	3,9534	0,00008
MRFG3†	θ_{12}	-3,51754	-0,20853	0,83482
MRFG3	μ_2	-0,27939	-3,54064	0,0004
MRFG3	γ_2	-0,49407	*	*
NATU3	λ_1	0,12765	0,00826	<0,0001
NATU3	α_{01}	1,76044	1,68111	0,09274
NATU3	α_{11}	0,29555	2,70169	0,0069
NATU3	θ_{11}	0,6889	5,33954	<0,0001
NATU3	μ_1	0,12427	1,2115	0,2257
NATU3	γ_1	0,05939	2,33312	0,01964
NATU3	$1 - \lambda_1$	0,87235	0,00826	<0,0001
NATU3	α_{02}	0,9089	21,13264	<0,0001
NATU3	α_{12}	0,04154	1,90518	0,05676
NATU3	θ_{12}	0,38298	1,21933	0,22272
NATU3	μ_2	0,08897	1,59786	0,11007
NATU3	γ_2	-0,08733	-0,472	0,63693
PCAR4	λ_1	0,2104	0,00671	<0,0001
PCAR4	α_{01}	2,2745	5,79305	<0,0001
PCAR4	α_{11}	0,4102	7,05602	<0,0001
PCAR4	θ_{11}	0,57318	10,68456	<0,0001
PCAR4	μ_1	0,0293	1,9868	0,04694
PCAR4	γ_1	0,07108	8,86668	<0,0001
PCAR4	$1 - \lambda_1$	0,7896	0,00671	<0,0001
PCAR4	α_{02}	0,90448	97,08057	<0,0001
PCAR4	α_{12}	0,14979	1,38438	0,16624
PCAR4	θ_{12}	0,08682	*	*
PCAR4	μ_2	0,05855	1,74107	0,08167
PCAR4	γ_2	-0,40633	-0,52836	0,59725
PDGR3	λ_1	0,10099	0,00968	<0,0001
PDGR3	α_{01}	0,96231	0,98174	0,32623
PDGR3	α_{11}	0,29833	2,28994	0,02202

Continua na próxima página

Tabela 5.9 – Continuação da página anterior

Empresa	Parâmetro	Estimativa	Estatística	Significância
PDGR3	θ_{11}	0,58065	3,43763	0,00059
PDGR3	μ_1	0,37197	2,37754	0,01743
PDGR3	γ_1	0,10236	3,93871	0,00008
PDGR3	$1 - \lambda_1$	0,89901	0,00968	<0,0001
PDGR3	α_{02}	0,87661	28,94267	<0,0001
PDGR3†	α_{12}	-0,03067	-0,23542	0,81388
PDGR3†	θ_{12}	-0,23523	*	*
PDGR3	μ_2	0,09073	0,84199	0,39979
PDGR3	γ_2	0,35261	0,19682	0,84397
PETR3	λ_1	0,12496	0,00527	<0,0001
PETR3	α_{01}	2,40001	4,46925	0,00001
PETR3	α_{11}	0,22625	5,33828	<0,0001
PETR3	θ_{11}	0,76938	23,03394	<0,0001
PETR3	μ_1	0,066	3,53897	0,0004
PETR3	γ_1	0,0735	8,80133	<0,0001
PETR3	$1 - \lambda_1$	0,87504	0,00527	<0,0001
PETR3	α_{02}	0,89973	88,59155	<0,0001
PETR3	α_{12}	0,03492	0,19391	0,84625
PETR3	θ_{12}	0,14773	*	*
PETR3	μ_2	0,09039	2,79696	0,00516
PETR3	γ_2	-1,07009	-2,488	0,01285
PETR4	λ_1	0,16223	0,00586	<0,0001
PETR4	α_{01}	1,25254	4,50484	0,00001
PETR4	α_{11}	0,39824	6,49571	<0,0001
PETR4	θ_{11}	0,58789	10,20544	<0,0001
PETR4	μ_1	0,04297	3,03113	0,00244
PETR4	γ_1	0,05577	9,88289	<0,0001
PETR4	$1 - \lambda_1$	0,83777	0,00586	<0,0001
PETR4	α_{02}	0,93019	143,09597	<0,0001
PETR4†	α_{12}	-0,64843	-6,36652	<0,0001
PETR4†	θ_{12}	-0,3548	*	*

Continua na próxima página

Tabela 5.9 – Continuação da página anterior

Empresa	Parâmetro	Estimativa	Estatística	Significância
PETR4	μ_2	0,1817	5,17663	<0,0001
PETR4	γ_2	0,96734	25,33335	<0,0001
RDCD3	λ_1	0,09966	0,01024	<0,0001
RDCD3	α_{01}	0,68276	*	*
RDCD3	α_{11}	0,05968	*	*
RDCD3	θ_{11}	0,84737	*	*
RDCD3	μ_1	0,34481	0,7534	0,45121
RDCD3	γ_1	0,09029	1,6046	0,10858
RDCD3	$1 - \lambda_1$	0,90034	0,01024	<0,0001
RDCD3	α_{02}	0,87056	8,42658	<0,0001
RDCD3	α_{12}	0,02091	0,07296	0,94184
RDCD3	θ_{12}	0,13201	0,24934	0,8031
RDCD3	μ_2	-0,04564	-0,45975	0,64569
RDCD3	γ_2	0,09262	0,52321	0,60083
RSID3	λ_1	0,45359	0,01047	<0,0001
RSID3	α_{01}	1,33327	5,68284	<0,0001
RSID3	α_{11}	0,4464	9,65133	<0,0001
RSID3	θ_{11}	0,35489	10,51928	<0,0001
RSID3	μ_1	0,14488	2,51497	0,0119
RSID3	γ_1	0,04313	7,98938	<0,0001
RSID3	$1 - \lambda_1$	0,54641	0,01047	<0,0001
RSID3	α_{02}	0,95659	158,53518	<0,0001
RSID3†	α_{12}	-0,14569	-1,75729	0,07887
RSID3	θ_{12}	0,21241	0,44536	0,65606
RSID3	μ_2	0,22295	1,83566	0,06641
RSID3	γ_2	-0,63112	-1,20142	0,22959
SANB11	λ_1	0,09764	0,01708	<0,0001
SANB11	α_{01}	1,70365	*	*
SANB11	α_{11}	0,16989	0,83065	0,40617
SANB11	θ_{11}	0,50041	*	*
SANB11	μ_1	1,07606	*	*

Continua na próxima página

Tabela 5.9 – Continuação da página anterior

Empresa	Parâmetro	Estimativa	Estatística	Significância
SANB11	γ_1	0,12676	*	*
SANB11	$1 - \lambda_1$	0,90236	0,01708	<0,0001
SANB11	α_{02}	0,57504	*	*
SANB11	α_{12}	0,14701	0,38366	0,70123
SANB11	θ_{12}	0,7149	1,50625	0,132
SANB11	μ_2	-0,0655	-0,5819	0,56063
SANB11	γ_2	0,12689	0,09583	0,92365
TAMM4	λ_1	0,10513	0,00795	<0,0001
TAMM4	α_{01}	0,61429	1,17156	0,24137
TAMM4	α_{11}	0,28753	3,87046	0,00011
TAMM4	θ_{11}	0,70221	9,50323	<0,0001
TAMM4	μ_1	0,59782	4,31407	0,00002
TAMM4	γ_1	0,09086	5,64982	<0,0001
TAMM4	$1 - \lambda_1$	0,89487	0,00795	<0,0001
TAMM4	α_{02}	0,86181	41,5161	<0,0001
TAMM4†	α_{12}	-0,17458	-0,76457	0,44453
TAMM4	θ_{12}	0,40418	0,27237	0,78534
TAMM4	μ_2	0,05894	0,68826	0,49129
TAMM4	γ_2	0,25301	0,23296	0,81579
TIMP3	λ_1	0,09308	0,00527	<0,0001
TIMP3	α_{01}	10,03461	10,10773	<0,0001
TIMP3	α_{11}	0,31476	2,5992	0,00934
TIMP3	θ_{11}	0,67566	12,37189	<0,0001
TIMP3	μ_1	0,19405	815929897,72206	<0,0001
TIMP3	γ_1	0,06997	7,70198	<0,0001
TIMP3	$1 - \lambda_1$	0,90692	0,00527	<0,0001
TIMP3	α_{02}	0,89435	92,92547	<0,0001
TIMP3†	α_{12}	-0,5783	-1,5058	0,13212
TIMP3	θ_{12}	0,4785	*	*
TIMP3	μ_2	0,02385	0,43425	0,66411
TIMP3	γ_2	-0,48967	-0,4662	0,64107

Continua na próxima página

Tabela 5.9 – Continuação da página anterior

Empresa	Parâmetro	Estimativa	Estatística	Significância
TLPP4	λ_1	0,23829	0,00773	<0,0001
TLPP4	α_{01}	1,08012	5,63128	<0,0001
TLPP4	α_{11}	0,63744	8,49651	<0,0001
TLPP4	θ_{11}	0,32678	6,69338	<0,0001
TLPP4	μ_1	0,02595	1,86946	0,06156
TLPP4	γ_1	0,03786	6,83863	<0,0001
TLPP4	$1 - \lambda_1$	0,76171	0,00773	<0,0001
TLPP4	α_{02}	0,95536	140,42614	<0,0001
TLPP4†	α_{12}	-0,14421	-1,971	0,04872
TLPP4†	θ_{12}	-0,2416	-1,37851	0,16805
TLPP4	μ_2	0,00504	0,12172	0,90312
TLPP4	γ_2	0,11939	1,84421	0,06515
TMAR5	λ_1	0,07041	0,0041	<0,0001
TMAR5	α_{01}	0,81857	*	*
TMAR5	α_{11}	0,01958	3,12967	0,00175
TMAR5	θ_{11}	0,97691	*	*
TMAR5	μ_1	0,32462	5,87283	<0,0001
TMAR5	γ_1	0,0854	9,72775	<0,0001
TMAR5	$1 - \lambda_1$	0,92959	0,0041	<0,0001
TMAR5	α_{02}	0,84031	50,60084	<0,0001
TMAR5†	α_{12}	-0,08804	-0,25173	0,80125
TMAR5†	θ_{12}	-0,22921	-0,40435	0,68596
TMAR5	μ_2	0,13286	3,42168	0,00062
TMAR5	γ_2	-0,94794	-3,48012	0,0005
TNLP3	λ_1	0,1275	0,00606	<0,0001
TNLP3	α_{01}	1,43766	3,03549	0,0024
TNLP3	α_{11}	0,11079	5,73177	<0,0001
TNLP3	θ_{11}	0,88429	28,91678	<0,0001
TNLP3	μ_1	0,1683	3,70125	0,00021
TNLP3	γ_1	0,05535	7,37427	<0,0001
TNLP3	$1 - \lambda_1$	0,8725	0,00606	<0,0001

Continua na próxima página

Tabela 5.9 – Continuação da página anterior

Empresa	Parâmetro	Estimativa	Estatística	Significância
TNLP3	α_{02}	0,90387	66,64934	<0,0001
TNLP3†	α_{12}	-0,21301	-0,8724	0,38299
TNLP3†	θ_{12}	-1,83224	*	*
TNLP3	μ_2	0,09214	3,01318	0,00259
TNLP3	γ_2	-0,27054	-0,95108	0,34157
TNLP4	λ_1	0,14689	0,00642	<0,0001
TNLP4	α_{01}	3,19482	4,51241	0,00001
TNLP4	α_{11}	0,63179	5,65048	<0,0001
TNLP4	θ_{11}	0,36642	3,851	0,00012
TNLP4	μ_1	0,03097	1,78809	0,07376
TNLP4	γ_1	0,06706	7,67312	<0,0001
TNLP4	$1 - \lambda_1$	0,85311	0,00642	<0,0001
TNLP4	α_{02}	0,92178	98,54333	<0,0001
TNLP4	α_{12}	0,37371	2,61914	0,00882
TNLP4†	θ_{12}	-0,69858	-0,93748	0,34851
TNLP4	μ_2	-0,09016	-2,16942	0,03005
TNLP4	γ_2	0,30397	1,34533	0,17852
TRPL4	λ_1	0,25423	0,00818	<0,0001
TRPL4	α_{01}	1,54284	4,94548	<0,0001
TRPL4	α_{11}	0,5695	8,40957	<0,0001
TRPL4	θ_{11}	0,378	7,2286	<0,0001
TRPL4	μ_1	0,00691	0,64132	0,52132
TRPL4	γ_1	0,06008	7,44163	<0,0001
TRPL4	$1 - \lambda_1$	0,74577	0,00818	<0,0001
TRPL4	α_{02}	0,93581	118,86249	<0,0001
TRPL4†	α_{12}	-0,18252	-1,96394	0,04954
TRPL4†	θ_{12}	-0,22274	-1,19219	0,23319
TRPL4	μ_2	0,12546	2,66228	0,00776
TRPL4	γ_2	0,45299	1,21107	0,22587
UGPA3	λ_1	0,10311	0,00579	<0,0001
UGPA3	α_{01}	0,90174	3,22941	0,00124

Continua na próxima página

Tabela 5.9 – Continuação da página anterior

Empresa	Parâmetro	Estimativa	Estatística	Significância
UGPA3	α_{11}	0,20134	2,80656	0,00501
UGPA3	θ_{11}	0,56885	5,03342	<0,0001
UGPA3	μ_1	0,12407	3,22441	0,00126
UGPA3	γ_1	0,10461	7,58588	<0,0001
UGPA3	$1 - \lambda_1$	0,89689	0,00579	<0,0001
UGPA3	α_{02}	0,87293	47,98205	<0,0001
UGPA3	α_{12}	0,04671	4,27864	0,00002
UGPA3	θ_{12}	0,94681	2,19382	0,02825
UGPA3	μ_2	0,08461	2,27735	0,02277
UGPA3	γ_2	-0,17106	-0,96071	0,3367
USIM3	λ_1	0,08868	0,00569	<0,0001
USIM3	α_{01}	3,32215	4,98932	<0,0001
USIM3	α_{11}	0,13589	5,231	<0,0001
USIM3	θ_{11}	0,85892	29,77199	<0,0001
USIM3	μ_1	0,15248	3,44915	0,00056
USIM3	γ_1	0,09552	7,08598	<0,0001
USIM3	$1 - \lambda_1$	0,91132	0,00569	<0,0001
USIM3	α_{02}	0,8756	57,28351	<0,0001
USIM3	α_{12}	0,64319	1,53583	0,12458
USIM3†	θ_{12}	-0,32286	*	*
USIM3	μ_2	0,25695	4,58987	<0,0001
USIM3	γ_2	0,01083	0,03572	0,9715
USIM5	λ_1	0,10049	0,00554	<0,0001
USIM5	α_{01}	0,75631	1,37433	0,16934
USIM5	α_{11}	0,06932	1,50167	0,13318
USIM5	θ_{11}	0,83889	8,36235	<0,0001
USIM5	μ_1	0,44026	3,31961	0,0009
USIM5	γ_1	0,0885	6,51052	<0,0001
USIM5	$1 - \lambda_1$	0,89951	0,00554	<0,0001
USIM5	α_{02}	0,86995	38,08393	<0,0001
USIM5	α_{12}	0,12941	0,78032	0,4352

Continua na próxima página

Tabela 5.9 – Continuação da página anterior

Empresa	Parâmetro	Estimativa	Estatística	Significância
USIM5	θ_{12}	0,03208	1,6788	0,09319
USIM5	μ_2	0,03901	0,68716	0,49198
USIM5	γ_2	-1,14422	-2,43136	0,01504
VALE3	λ_1	0,20697	0,00656	<0,0001
VALE3	α_{01}	1,12198	5,6228	<0,0001
VALE3	α_{11}	0,62991	9,84795	<0,0001
VALE3	θ_{11}	0,34203	10,40498	<0,0001
VALE3	μ_1	0,08486	7,6389	<0,0001
VALE3	γ_1	0,05978	8,48044	<0,0001
VALE3	$1 - \lambda_1$	0,79303	0,00656	<0,0001
VALE3	α_{02}	0,92753	131,58145	<0,0001
VALE3	α_{12}	0,16526	5,02749	<0,0001
VALE3	θ_{12}	0,21305	*	*
VALE3	μ_2	0,07754	1,85585	0,06348
VALE3	γ_2	0,4329	*	*
VALE5	λ_1	0,17821	0,00609	<0,0001
VALE5	α_{01}	2,50364	4,56438	0,00001
VALE5	α_{11}	0,4022	7,00402	<0,0001
VALE5	θ_{11}	0,59247	9,80872	<0,0001
VALE5	μ_1	0,07966	3,87395	0,00011
VALE5	γ_1	0,05934	8,70457	<0,0001
VALE5	$1 - \lambda_1$	0,82179	0,00609	<0,0001
VALE5	α_{02}	0,90693	87,13235	<0,0001
VALE5†	α_{12}	-0,04207	-0,3473	0,72837
VALE5†	θ_{12}	-1,95138	*	*
VALE5	μ_2	0,14386	4,29823	0,00002
VALE5	γ_2	-0,36247	-0,69059	0,48982

Para os parâmetros cujas estatísticas e significância foram representadas pelo símbolo de asterisco, a matriz de variâncias e covariâncias estimada não era positiva semi-definida, indicando assim que a topologia da função de log-verossimilhança é um ponto de sela ou a

verossimilhança possui uma estrutura muito *flat*. Já o símbolo † representa as estimativas que não seguem a condição de estacionariedade definida por Haas (2004), isso se deve ao fato do algoritmo *Simulated Annealing* de Belisle (1992) possuir duas condições para término do processo de maximização, quais sejam: número de iterações máximo igual a 10000 ou a tolerância de convergência dos parâmetros menor ou igual a 10^{-8} , nesses casos, o algoritmo atingiu o número máximo de iterações e a tolerância de convergência para os parâmetros não foi satisfeita, indicando assim, diversos pontos de máximo, todos com valores aproximadamente iguais, ou uma topologia *flat* da log-verossimilhança fornecendo estimativas para a magnitude do evento que não satisfazem o pressuposto de estacionariedade para a série, todavia, esses valores foram ainda assim apresentados com um propósito meramente exploratório.

A tabela apresentada anteriormente pode ser simplificada por meio de gráficos como os apresentados nas figuras 5.5 e 5.6. Nestas imagens, o intervalo de confiança a um nível de 95% é apresentado e desta forma, é possível testar a igualdade entre os efeitos das distribuições de dividendos para as empresas em cada um dos possíveis regimes.

**Efeito da divulgação dos dividendos na Bovespa.
(Bear Market)**

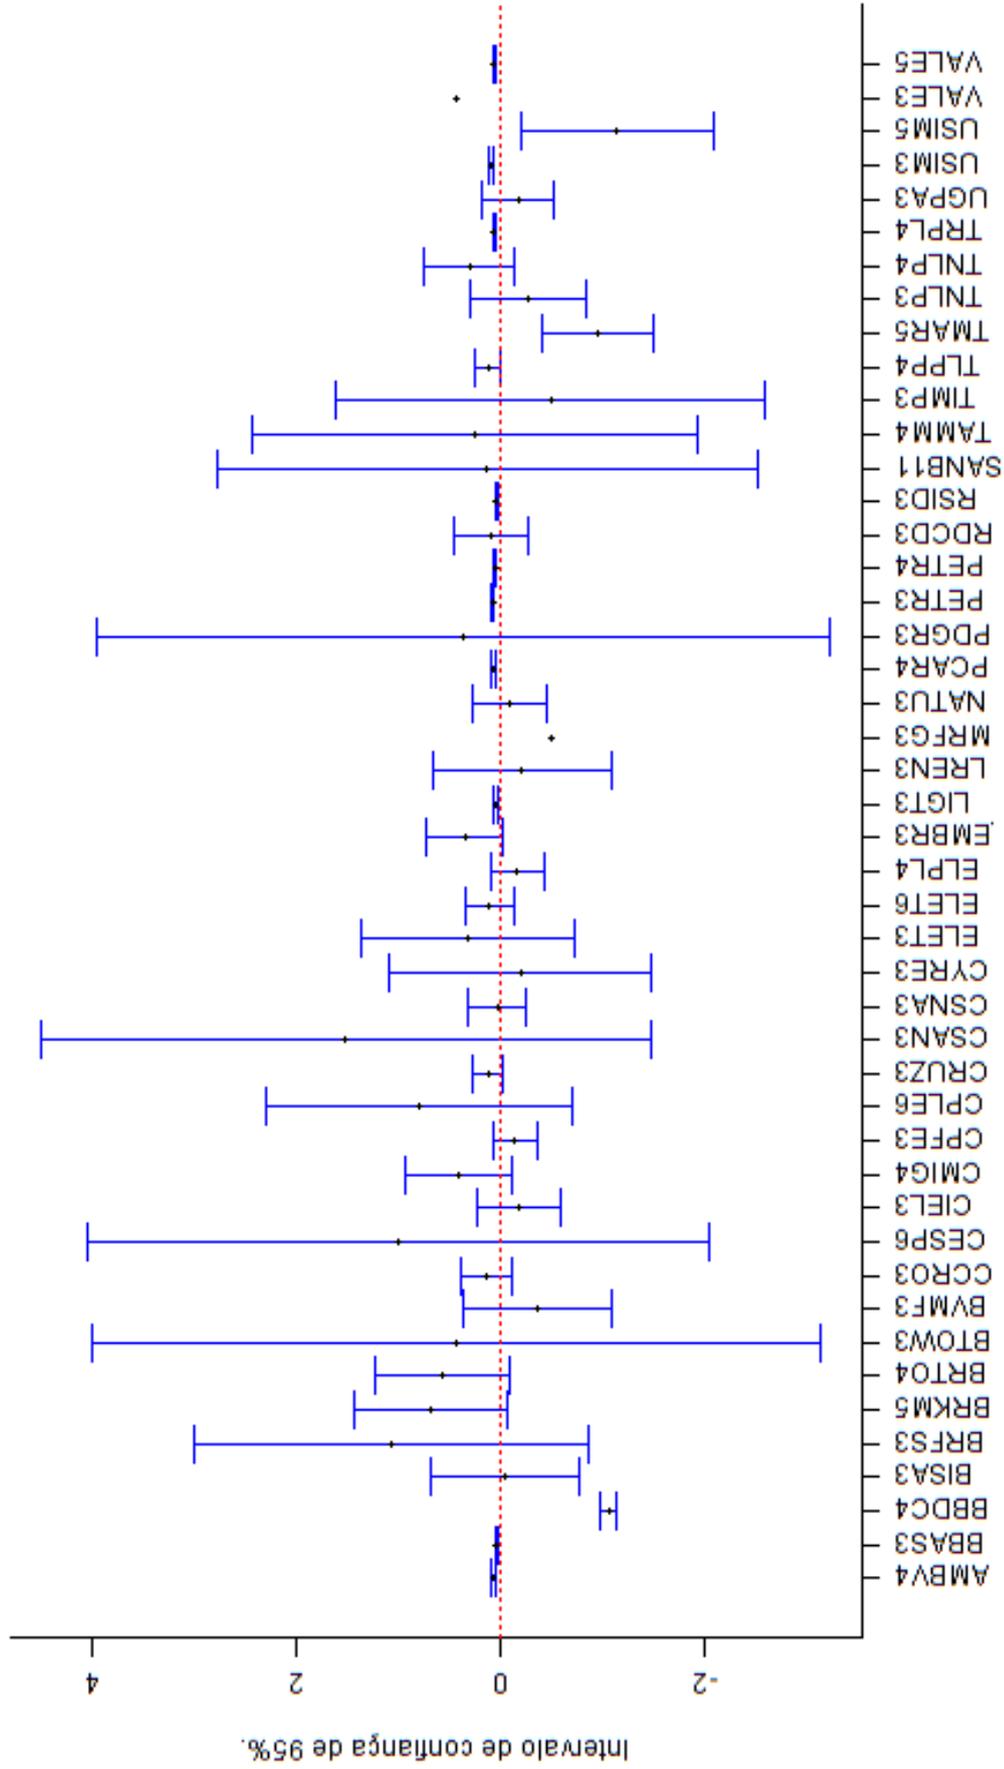


Figura 5.5: Efeito da divulgação dos dividendos na Bovespa. (Bear Market).

Fonte: Elaboração do autor.

Efeito da divulgação dos dividendos na Bovespa. (Bull Market)

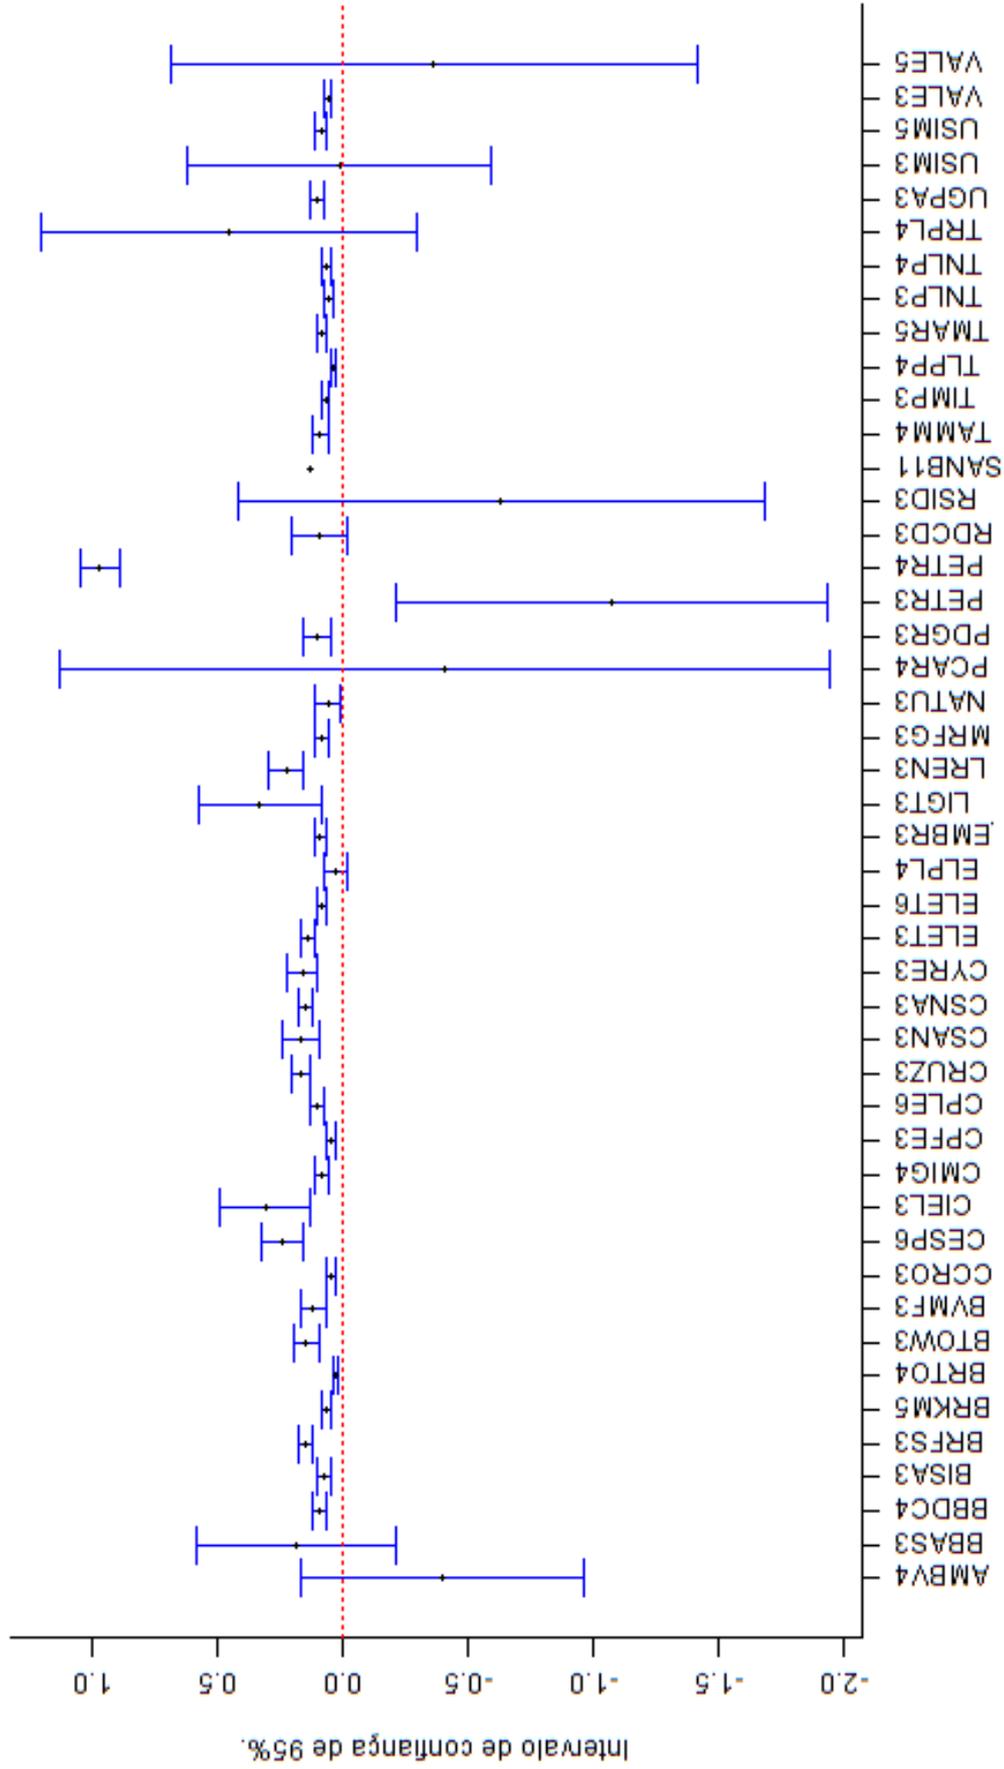


Figura 5.6: Efeito da divulgação dos dividendos na Bovespa. (Bull Market).

Fonte: Elaboração do autor.

5.2.4 Conclusão.

Conclui-se, com base nos dados, que, dependendo do regime em que o mercado se encontra, o efeito da distribuição dos dividendos e sua magnitude diferem. Esse resultado é consistente com Fuller e Goldstein (2011), no sentido que o regime afeta a magnitude da influência dos dividendos no retorno médio das ações, entretanto, para o mercado brasileiro, percebe-se que, no regime *Bull Market*, a distribuição dos dividendos é, em sua maioria, significativa e positiva, individuando que, nesse período, a expectativa da distribuição dos dividendos não é, em média, precificada pelo mercado, entretanto, no período de *Bear Market*, a precificação ocorre para a maioria das organizações.

Ademais, o fato de algumas estimativas não serem consistentes no sentido de satisfazer as condições do modelo MN-GARCH proposto por Haas (2004) indica a sensibilidade do modelo quanto ao tamanho das séries temporais, topologia da função de log-verossimilhança e também parâmetros de calibragem para a maximização do problema de programação matemática. O fato do tamanho da janela ser unitário pode também ter contribuído para os desvios quanto às exigências do modelo MN-GARCH.

Já para as ações que satisfizeram todas as condições necessárias para a validação do modelo, percebe-se uma estrutura diferenciada em relação a influência da magnitude da distribuição dos dividendos para cada um dos possíveis regimes, a saber: *Bear Market* e *Bull Market*.

A variabilidade do efeito da distribuição dos dividendos para cada um dos possíveis regimes também parece se diferenciar entre as diversas corporações o qual é um indicativo da possível heterogeneidade dos dados entre as organizações.

6 CONSIDERAÇÕES FINAIS.

Mensurar o valor de uma empresa é fundamental para os administradores financeiros e esse tema há muito tem sido estudado no campo de finanças. Entretanto, na presença de eventos, sejam eles corporativos ou não, o valor da empresa (representado usualmente pelo preço da ação da firma) pode ser afetado positivamente ou negativamente, ou ainda não apresentar evidências de efeito sobre o retorno da ação. Esses eventos podem ser internos ou externos a empresa e podem afetar ou não o preço de mercado da ação da empresa, especificamente, nessa tese o interesse repousa nos eventos divulgados ao mercado, como por exemplo, a distribuição de dividendos e a execução de eleições nacionais. A divulgação de informações no mercado (representado pelos eventos identificados pelos estudiosos) faz com que os agentes (investidores) assumam comportamentos distintos em relação à negociação dos papéis, o que afeta, conseqüentemente, os níveis de oferta e demanda e, por conseguinte, o nível de preços, do qual se extrai o vetor de retornos. Dessa forma, a metodologia proposta pode ser aplicada a qualquer evento que seja de conhecimento do mercado, a significância do impacto desse evento, bem como o seu diferencial nos possíveis regimes de mercado são então testados pela proposta metodológica dessa tese.

Assim como apresentado no capítulo 1 esta é a principal problemática do Estudo de Eventos em finanças corporativas. Responder questões do tipo: “Como o retorno da ação de uma firma é afetado na presença de um determinado evento ?” é o objetivo central do Estudo de Eventos e a mensuração desse possível efeito é realizada por meio dos Testes de Eventos. Uma vez que a mensuração do valor corporativo é um tema crítico no âmbito de finanças sendo explorado por diversos modelos como, por exemplo, os modelo CAPM, Modelo de Mercado e o modelo de médias constantes para os retornos (*Constant Mean Return Model - CMRM*) a investigação do efeito de determinados eventos sobre esses modelos de precificação é de interesse dos pesquisadores em finanças corporativas.

Os primeiros estudos que investigam os Testes de Eventos em finanças datam do final da década de 50 e início da década de 60 como, por exemplo, os textos seminais de Modigliani e Miller (1958), Miller e Modigliani (1961) e Modigliani e Miller (1963), os quais apresentaram

os problemas de estrutura de capital para a vanguarda da investigação financeira. Entretanto, segundo Corrado (2011), apenas na década de 80 com o texto de Brown e Warner (1980) é que a metodologia para Teste de Eventos tomou a forma que conhecemos hoje e essa estrutura continua a ser amplamente utilizada pelos estudiosos financeiros. Posteriormente a Brown e Warner (1980) outros textos metodológicos foram apresentados para estruturar os Testes de Eventos, especificamente, diversos textos foram produzidos para avaliar o desempenho de Testes de Eventos sobre a ausência de normalidade dos dados, como McConnell e Muscarella (1985), Corrado (1989), Lummer e McConnell (1989), Zivney e Thompson (1989) e Corrado e Zivney (1992). Esses trabalhos argumentam que os testes mais bem-sucedidos na presença de desvio da normalidade foram os testes não paramétricos como o teste do sinal, teste de postos e métodos de reamostragem como o Bootstrap.

Todavia, durante a busca e construção do referencial teórico dessa tese (relatado no capítulo 2) não foram encontrados trabalhos que se proponham a construir Testes de Eventos adequando-o aos principais Fatos Estilizados em finanças. A importância do ajuste dos Testes de Eventos às principais características empíricas presentes nas séries temporais financeiras (denominadas Fatos Estilizados) auxilia na construção de testes de hipóteses mais precisos, principalmente pelo fato de que, para a maioria das séries temporais financeiras, a convergência assintótica distribucional dos dados não recai sobre uma distribuição normal, mas sim sobre uma família de distribuições mais gerais, qual seja: a família de distribuições estáveis.

Ademais, a segmentação do possível efeito do evento sobre o retorno do preço da ação realizado por meio da construção de regimes financeiros também é inovadora, pois proporciona ao campo de Testes de Eventos a possibilidade de questionar não somente se há algum efeito sobre o retorno da ação de uma empresa perante a realização de um evento, mas também determinar como a magnitude desse efeito (e possivelmente até a sua nulidade) se comporta na presença de cada um dos regimes financeiros definidos.

A utilização de regimes (também denominados componentes da mistura de distribuições) não oferece somente uma possibilidade de estudar o impacto de eventos nos possíveis regimes presentes nas séries temporais financeiras, mas oferece também uma forma de modelar alguns outros Fatos Estilizados em finanças, como caudas pesadas ((COSTA; BAIDYA, 2001);(PRAETZ, 1972);(CLARK, 1973)), desvios da normalidade e assimetria distribucional ((FAMA, 1965); (MANDELROT, 1963c)).

Além dos Fatos Estilizados descritos anteriormente, cabe destacar a aglomeração de volatilidades como uma das principais características das séries temporais financeiras. O fato dos retornos das ações serem usualmente heteroscedásticos é um ponto que vai de encontro às

propostas clássicas de Testes de Eventos, as quais assumem variância constante dos retornos financeiros; além do mais, os dados financeiros, além de serem heteroscedásticos, seguem uma estrutura de aglomeração temporal, onde períodos com alta volatilidade são imediatamente sequenciais segundo alguma parametrização de dependência temporal entre as observações e períodos com baixa volatilidade são, também, imediatamente sequenciais as observações com baixa volatilidade, sendo possível modelar essa característica por meio de um modelo GARH (BOLLERSLEV, 1986).

Com o intuito de associar esta a aglomeração de volatilidades com a possibilidade de segmentação de regimes para os resíduos das séries temporais financeiras, Haas (2004) considera uma mistura de distribuições normais juntamente com uma estrutura do tipo GARCH (denominada MN-GARCH), permitindo uma variância condicional para cada um dos componentes da mistura (regime), bem como um *feedback* dinâmico entre os componentes. Nessa abordagem, o modelo MN-GARCH pode gerar uma desagregação do processo variância condicional em que os componentes da volatilidade dinâmica têm um comportamento claramente diferenciado, o que é compatível com a proposta de Estudos de Eventos, cuja hipótese a ser testada é se, após a ocorrência do evento focal, os retornos médios observados (juntamente com sua variância condicional) alteraram-se.

No entanto, a proposta de Haas (2004) apesar de bastante geral, não é específica para Testes de Eventos, pois não incorpora, em sua formulação, um preditor linear diferente de zero e também a possível presença de eventos corporativos como fatores de mudança no valor médio do retorno da organização. Dentre os textos que surgiram posteriormente à proposta de Haas (2004), nenhum utilizou essa ferramenta para a análise e estimação de efeitos sobre anúncios corporativos, Alexander e Lazar (2009), por exemplo, apresentam uma extensão do modelo MN-GARCH com o intuito de ajustar as séries exploradas ao efeito alavancagem presente em algumas séries temporais financeiras, já Cheung e Chung (2011) explorara conceitualmente o modelo MN-GARCH para ajustá-lo a um modelo de memória longa, esta tese, no entanto, adaptou as proposições teóricas ao problema de Testes de Eventos e realizou duas aplicações a problemáticas relevantes no âmbito da Teoria da Agência, contribuindo tanto metodologicamente quanto empiricamente.

Em outras palavras, essa tese apresenta além de um modelo específico para Testes de Eventos por meio de misturas GARCH, dois ensaios envolvendo essa metodologia e uma aplicação de ajuste estatístico do modelo aos principais índices financeiros mundiais. Portanto, a proposta dessa tese não é meramente uma aplicação do modelo desenvolvido por Haas (2004), mas sim, uma contribuição metodológica teórica (seção 4.2) bem como empírica (capítulo 5).

Assim, a presente tese apresentou uma metodologia quantitativa e paramétrica para a avaliação e inferência de retornos associados a eventos em finanças corporativas, corrigindo os pressupostos clássicos quanto à distribuição dos retornos de ativos por meio da extensão da proposta de Haas (2004) bem como, dois ensaios em finanças corporativas utilizando essa metodologia.

Para atingir esse objetivo, foi construído um referencial teórico (capítulo 2) associado a Fatos Estilizados em finanças os quais forneceram as principais características que o modelo para Testes de Eventos deveria seguir e também propostas metodológicas para Testes de Eventos, garantindo assim o ineditismo da proposta aqui desenvolvida.

Em seguida uma revisão dos métodos de misturas de distribuição e o modelo de misturas GARCH foram apresentados (capítulo 3 e capítulo 4, respectivamente) fornecendo assim os insumos necessários para a construção do método para Testes de Eventos proposto na seção 4.2 desta tese.

A contribuição empírica desta tese encontra-se na seção 4.1.4 a qual apresenta a qualidade do ajuste do modelo de misturas GARCH sobre os principais índices financeiros em comparação com os principais processos geradores de dados utilizados em finanças, já no capítulo 5 dois ensaios empíricos são apresentados demonstrando a aplicação do método proposto e comprovando a diferenciação dos impactos dos eventos sobre os dois diferentes regimes.

Para esses dois ensaios em finanças corporativas, examinou-se no primeiro a hipótese de que o período eleitoral não influencia as expectativas dos acionistas para a Petrobras e, portanto, o retorno médio dos ativos: PETR3 e PETR4. Como apresentado no capítulo 5, a hipótese nula de ausência de influência do período eleitoral sobre o retorno dos ativos foi rejeitada a um nível de significância de 5% para o regime *Bull Market*, infere-se daí os seguintes resultados: o período eleitoral possui influência sobre o retorno médio dos ativos da Petrobras somente quando o regime em questão é um regime de alta (*Bull Market*), para períodos de baixa (*Bear Market*) não encontrou-se evidência da influência do período eleitoral sobre os retornos dos ativos da Petrobras, esses resultados foram então discutidos à luz da Teoria da Agência.

O segundo ensaio apresentado no capítulo 5 expôs que, dependendo do regime em que o mercado se encontra, o efeito da distribuição dos dividendos e sua magnitude diferem. Esse resultado é, portanto, consistente com Fuller e Goldstein (2011), no sentido que o regime afeta a magnitude da influência dos dividendos no retorno médio das ações, entretanto, para o mercado brasileiro, percebe-se que, no regime *Bull Market*, a distribuição dos dividendos é, em sua maioria, significativa e positiva, individuando que, nesse período, a expectativa da distribuição dos dividendos não é, em média, precificada pelo mercado, entretanto, no período de *Bear Market*, a precificação ocorre para a maioria das organizações.

Quanto a proposta principal da tese: o método de Testes de Eventos usando misturas GARCH(1,1) com preditor linear diferente de zero, aqui produzido e avaliado (seção 4.1.4) atende aos quatro requisitos propostos na seção 1.5. É original, pois a metodologia proposta e desenvolvida ao longo de toda a tese “volta às origens”. Os textos seminais associados a Estudo de Eventos e Fatos Estilizados foram apresentados, fornecendo ao leitor, o embasamento teórico para a boa compreensão da proposta aqui aduzida.

O trabalho pode ser considerado inédito, uma vez que ao longo da pesquisa não foi encontrado nenhum texto que proponha uma metodologia paramétrica para a análise e estimação do efeito de anúncios à luz de finanças corporativas, incorporando neste modelo os principais Fatos Estilizados em finanças como desvio da normalidade, heteroscedasticidade e caudas pesadas. Dessa forma, a contribuição principal dessa tese é a proposta desenvolvida e apresentada na seção 4.2 onde utiliza-se de duas misturas de modelos do tipo GARCH-M (isso é, com preditor linear diferente de zero e função de possíveis covariáveis) com parametrização na forma GARCH(1,1) para Testes de Eventos.

O modelo apresentado em 4.2 é inovador, pois utiliza uma nova abordagem econométrica - misturas de distribuições GARCH - para a estimação do efeito de anúncios à luz de finanças corporativas. E pode ser considerado relevante para os estudiosos da área de finanças corporativas uma vez que proporciona uma ferramenta que se ajusta aos principais Fatos Estilizados em finanças (isso é, seguindo o referencial apresentado no capítulo 2, a composição de mistura seria capaz de ajustar as caudas pesadas e assimetria distribucional, enquanto a estrutura GARCH(1,1) modelaria as frequentes aglomerações de volatilidade) para a estimação do efeito de eventos sobre as corporações, mostrando-se mais adequada -do ponto de vista de minimização da perda de informação - do que as abordagens tradicionais para a modelagem de séries temporais financeiras como apresentado na seção 4.1.4 dessa tese.

As dificuldades encontradas nesse trabalho estão associadas à extensa demanda computacional para estimação dos modelos MN-GARCH, à presença de múltiplos máximos locais, topologias funcionais nas quais há a presença de pontos de sela e sensibilidade nos parâmetros de calibragem do modelo *Simulated Annealing* de Belisle (1992) na maximização da função de log-verossimilhança.

O fato do algoritmo de maximização ser numérico e heurístico induz a limitações quanto ao grau de precisão das estimativas as quais estão limitadas a valores arbitrários de precisão, número máximo de iterações e também da precisão numérica da máquina. Propostas futuras de análise e pesquisa envolvem a comparação do modelo aqui proposto com a abordagem de modelos GARCH com estrutura alfa-estável, modelos GARCH combinados com misturas de

distribuições estáveis e também misturas de modelos do tipo EGARCH, os quais são capazes de modelar o efeito alavancagem, que está frequentemente presente em séries temporais financeiras. Além dessas possibilidades, sugere-se a exploração de Estudos de Eventos sobre os possíveis diferentes regimes, visto que dessa forma é possível avaliar o efeito dos eventos corporativos sobre cada um dos possíveis regimes presentes nas séries temporais financeiras, abordagem essa ainda inédita em finanças corporativas.

Anexo A – PROGRAMAÇÕES UTILIZADAS

A.1 Programa 1.

Esse programa foi utilizado para estimar os modelos e o critério de informação de Akaike na seção 4.1.4.

```
rm(list = ls(all = TRUE))
#Define o WorkSpace
setwd("C:/Dropbox/Doutorado/Tese/Dados")

nome<-c("JALSH Index", "SPTSX Index", "BATSK Index", "DJI Index", "CCMP Index",
"SPX Index", "MERVAL Index", "IBOV Index", "IPSA Index", "MXX Index",
"AS51 Index", "XAO Index", "ATX Index", "HSI Index", "SENSEX Index",
"JCI Index", "TA-100 Index", "NKY Index", "KOSPI Index", "KLSER Index",
"NZSE Index", "SHCOMP Index", "TWSE Index", "DAX Index", "MADX Index",
"CAC Index", "ASE Index", "BEL20 Index", "AEX Index", "OSEAX Index",
"UKX Index", "PX Index", "OMX Index", "SMI Index", "INDEXCF Index")

i<-1

abre<-paste(nome[i], ".csv", sep="")
dados.df<-read.csv(abre, sep="," )

#Calcula o retorno.
ret<-diff(log(dados.df[, "PX_LAST"]))*100

#Cria tabela resultados
Modelos<-c("Normal", "Garch", "Alfa-Estavel", "Misturas GARCH")
resultado.df<-as.data.frame(Modelos)

#Teste 1: Testa normalidade.
modelo<-lm(ret~1)
resultado.df[1, "AIC"]<-as.array(AIC(modelo))
distribuicaoNormal=function(x)
{
```

```

    return(dnorm(x,mean(ret),sd(ret)))
}

distribuicaoNormalRd<-rnorm(length(ret),mean(ret),sd(ret))
ntest<-ks.test(ret,distribuicaoNormalRd)
resultado.df[1,"KS"]<-as.array(ntest[1])
resultado.df[1,"P-valor"]<-as.array(ntest[2])

#Teste 2: GARCH
library(fGarch)
g <- garchFit(~garch(1,1),ret,cond.dist = "norm")
resultado.df[2,"AIC"]<-as.array(g@fit$ics[1])
media<-g@fit$par[1]
sigma<-g@sigma.t
distribuicaoGARCHRd<-rnorm(length(ret),media,sigma)
ntest<-ks.test(ret,distribuicaoGARCHRd)
resultado.df[2,"KS"]<-as.array(ntest[1])
resultado.df[2,"P-valor"]<-as.array(ntest[2])

#Teste 3: Alfa-Estavel
library(fBasics)
stable<-stableFit(ret,type="mle")
resultado.df[3,"AIC"]<-as.array(stable@fit$minimum)+2*4

estavel<-rstable(length(ret),alpha=stable@fit$estimate[1],
beta=stable@fit$estimate[2], gamma =stable@fit$estimate[3],
delta = stable@fit$estimate[4])

ntest<-ks.test(ret,estavel)
resultado.df[3,"KS"]<-as.array(ntest[1])
resultado.df[3,"P-valor"]<-as.array(ntest[2])

#Teste 4: Misturas GARCH
source("Funcoes.R")
#set.seed<-54648
#sementes<-round(10000*runif(10000))
#Numero de parametros
p<-9

#Inicializa vetor de chutes parametrosMNGARCH(pi,alpha11
#,alpha12,alpha13,alpha21,alpha22,alpha23,mu1,mu2)
parametrosMNGARCH<-rep(0.1,p)

#Vetor de dados
vetor<-ret
library(maxLik)

```

```

#Restricoes
A <- diag(p-1)
A<-rbind(A,rep(0,p-1),rep(0,p-1))

A[9,2]=A[9,3]=-1
A[10,5]=A[10,6]=-1

B = matrix(0,nrow(A),1)
B[7]=B[8]= 1e+15
B[9]=B[10]=1

conta<-1
erro<-100000
vetor<<-ret
while(erro>0.1)
{
  #E-STEP
  matrizEsperancas<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

  for(k in 2:length(vetor))
  {
    mu1<-parametrosMNGARCH[8]
    mu2<-parametrosMNGARCH[9]

    erro2<-vetor[k-1]^2
    sigma21[k]<-parametrosMNGARCH[2]+parametrosMNGARCH[3]
    *erro2+parametrosMNGARCH[4]*sigma21[k-1]
    sigma22[k]<-parametrosMNGARCH[5]+parametrosMNGARCH[6]
    *erro2+parametrosMNGARCH[7]*sigma22[k-1]

    d1<-dnorm(vetor[k],mu1,sqrt(sigma21[k]))
    if(d1==0) d1=0.000000001
    d2<-dnorm(vetor[k],mu2,sqrt(sigma22[k]))
    if(d2==0) d2=0.000000001

    matrizEsperancas[k,1]<-((1+(((1-parametrosMNGARCH[1])
    *d2)/(parametrosMNGARCH[1]*d1)))^(-1))
    matrizEsperancas[k,2]<-(1+((parametrosMNGARCH[1]*d1)
    /((1-parametrosMNGARCH[1])*d2)))^(-1)
  }

  matrizEsperancas[1,]<-0

  #M-STEP

```

```

pi1<-mean(matrizEsperancas[,1])
parametrosMNGARCH[1]<-pi1
pi2<-mean(matrizEsperancas[,2])
parametrosMNGARCHLike<-parametrosMNGARCH[2:length(parametrosMNGARCH)]
res <- maxSANN(logLikelihoodMNGARCH, start=parametrosMNGARCHLike,
  constraints=list(ineqA=A, ineqB=B),random.seed = 434343)
parametrosMNGARCH[2:length(parametrosMNGARCH)]<-res$estimate
parametrosMNGARCH[1]<-pi1
#Guarda a verossimilhanca
if(conta==1)
{
  likeli<-abs(res$maximum)
}
else
{
  erro<-abs(likeli-abs(res$maximum))
  likeli<-abs(res$maximum)
}
conta<-conta+1
}

resultado.df[4,"AIC"]<-(18-2*likeli)
parm<-c(pi1,res$estimate)
sigma21<-rep(1,length(vetor))
sigma22<-rep(1,length(vetor))

dmngarch=function(x,parm)
{
  predito<-rep(0,length(x))

  for(i in 2:length(x))
  {
    mu1<-parm[8]
    mu2<-parm[9]

    erro2<-vetor[i-1]^2
    sigma21[i]<-parm[2]+parm[3]*erro2+parm[4]*sigma21[i-1]
    sigma22[i]<-parm[5]+parm[6]*erro2+parm[7]*sigma22[i-1]

    d1<-dnorm(x[i],mu1,sqrt(sigma21[i]))
    if(d1==0) d1=0.000000001
    d2<-dnorm(x[i],mu2,sqrt(sigma22[i]))
    if(d2==0) d2=0.000000001
    predito[i]<-parm[1]*d1+(1-parm[1])*d2

  }

  return(predito)
}

```

```

}

valorPredito<-dmngarch(ret, parm)
mu<-((parm[1]*parm[8])+((1-parm[1])*parm[9]))
sigma2<-((parm[1]*((parm[8]^2)+sigma21))-mu)+
((1-parm[1])*((parm[9]^2)+sigma22))-mu

rmngarch=function(n, parm)
{
  x=rnorm(1, mu, sqrt(sigma2))
  serie=rep(x, n)
  desvio2=rep(0, n)
  tempo=1:n
  for(i in 2:n)
  {
    aleatorio=runif(1)
    if(aleatorio<parm[1])
    {
      erro2=serie[i-1]^2
      desvio2[i]=parm[2]+parm[3]*erro2+parm[4]*desvio2[i-1]
      serie[i]=rnorm(1, parm[8], sqrt(desvio2[i]))
    }
    else
    {
      erro2=serie[i-1]^2
      desvio2[i]=parm[5]+parm[6]*erro2+parm[7]*desvio2[i-1]
      serie[i]=rnorm(1, parm[9], sqrt(desvio2[i]))
    }
  }
  return(serie)
}

mngarchRd<-rmngarch(length(ret), parm)
ntest<-ks.test(ret, mngarchRd)
resultado.df[4, "KS"]<-as.array(ntest[1])
resultado.df[4, "P-valor"]<-as.array(ntest[2])

salva<-paste("Resultado_", nome[i], ".csv", sep="")
write.csv(resultado.df, salva)

write.csv(resultado.df, "Resultado.csv")
salvaImage<-paste("Resultado_", nome[i], ".Rdata", sep="")
save.image(salvaImage)

```

A.2 Programa 2.

Esse programa foi utilizado para estimar os modelos do ensaio relativo a seção 5.1.

A.2.1 Modelo CMRM - PETR3.

```
#Limpa o WorksPace
rm(list = ls(all = TRUE))

#Define o WorkSPace
setwd("C:/Dropbox/Doutorado/2º Semestre 2011/
Finanças corporativas/Artigo 1/Programas/PETR3")

#Lê os dados das séries financeiras
dados.df<-read.csv("DadosMenor11092011.csv")
names(dados.df)

#Deflacionar o preço da ação, o índice Bovespa e
#a taxa livre de risco (CDI), utilizando o IGP-M.
dados.df[, "LP_PETR3.DEF"]<-dados.df[, "PETR3_LP"]*dados.df[, "INDICE"]
dados.df[, "IBOVESPA.DEF"]<-dados.df[, "IBOVESPA"]*dados.df[, "INDICE"]
dados.df[, "SELIC.DEF"]<-dados.df[, "SELIC"]*dados.df[, "INDICE"]
#dados.df[, "HML.DEF"]<-dados.df[, "HML"]*dados.df[, "INDICE"]
#dados.df[, "SMB.DEF"]<-dados.df[, "SMB"]*dados.df[, "INDICE"]

#Cria as variáveis em forma de retorno
PETR3.ret<-diff(log(dados.df[, "LP_PETR3.DEF"]))*100
IBOVESPA.ret<-diff(log(dados.df[, "IBOVESPA.DEF"]))*100
SELIC.ret<-diff(log(dados.df[, "SELIC.DEF"]))*100
#HML.ret<-diff(log(dados.df[, "HML.DEF"]))*100
#SMB.ret<-diff(log(dados.df[, "SMB.DEF"]))*100
tempo<-seq(1:(length(PETR3.ret)))

#Cria o DataFrame
#retornos.df<-as.data.frame(cbind(tempo,PETR3.ret,
IBOVESPA.ret,SELIC.ret,HML.ret,SMB.ret,
dados.df[2:nrow(dados.df), "Election5"], dados.df[2:nrow(dados.df),
"Election10"], dados.df[2:nrow(dados.df), "Election15"],
dados.df[2:nrow(dados.df), "Election20"]))
retornos.df<-as.data.frame(cbind(tempo,PETR3.ret,
IBOVESPA.ret,SELIC.ret, dados.df[2:nrow(dados.df),
"Election5"], dados.df[2:nrow(dados.df), "Election10"],
dados.df[2:nrow(dados.df), "Election15"],
dados.df[2:nrow(dados.df), "Election20"]))
#names(retornos.df)<-c("Período","Retorno deflacionadao PETR3",
"Retorno deflacionadao IBOVESPA","Retorno deflacionadao SELIC",
```

```

"Retorno deflacionadao HML", "Retorno deflacionadao SMB",
"Eleições janela de 5 dias", "Eleições janela de 10 dias",
"Eleições janela de 15 dias", "Eleições janela de 20 dias")
names(retornos.df) <- c("Período", "Retorno deflacionadao PETR3",
"Retorno deflacionadao IBOVESPA", "Retorno deflacionadao SELIC",
"Eleições janela de 5 dias", "Eleições janela de 10 dias",
"Eleições janela de 15 dias", "Eleições janela de 20 dias")

##### CMRM5 #####
source("Funcoes.R")
set.seed<-54648
sementes<-round(10000*runif(10000))
#Número de parametros
p<-11

#Inicializa vetor de chutes parametrosCMRM5(pi, alpha11,
#alpha12, alpha13, alpha21, alpha22, alpha23, mu1, gamma1, mu2, gamma2)
parametrosCMRM5<-rep(0.1, p)
#parm<-coef(lm(retornos.df[,2]~1+retornos.df[,5]))
#parametrosCMRM5<-c(0.1, 0.1, 0.1, 0.1, 0.1, 0.1, 0.1, parm, parm)

#Vetor de dados
vetor<-retornos.df[,2]
library(maxLik)

#Restrições
A <- diag(p-1)
A<-rbind(A, rep(0, p-1), rep(0, p-1))

A[11,2]=A[11,3]==-1
A[12,5]=A[12,6]==-1

B = matrix(0, nrow(A), 1)
B[7]=B[8]=B[9]=B[10]= 1e+15
B[11]=B[12]=1

conta<-1
erro<-100000

while(erro>0.1)
{
#E-STEP
matrizEsperancas<-matrix(0, length(vetor), 2)
  sigma21<-rep(1, length(vetor))
  sigma22<-rep(1, length(vetor))

for(k in 2:length(vetor))

```

```

{
    mu1<-parametrosCMRM5[8]+parametrosCMRM5[9]*retornos.df[k,5]
    mu2<-parametrosCMRM5[10]+parametrosCMRM5[11]*retornos.df[k,5]

    erro2<-vetor[k-1]^2
    sigma21[k]<-parametrosCMRM5[2]+parametrosCMRM5[3]*
    erro2+parametrosCMRM5[4]*sigma21[k-1]
    sigma22[k]<-parametrosCMRM5[5]+parametrosCMRM5[6]*
    erro2+parametrosCMRM5[7]*sigma22[k-1]

    matrizEsperancas[k,1]<-((1+(((1-parametrosCMRM5[1])*
    dnorm(vetor[k],mu2,sqrt(sigma22[k])))/(parametrosCMRM5[1]*
    dnorm(vetor[k],mu1,sqrt(sigma21[k]))))))^(-1))
    matrizEsperancas[k,2]<-(1+((parametrosCMRM5[1]*dnorm(vetor[k],mu1,
    sqrt(sigma21[k])))/(1-parametrosCMRM5[1])*dnorm(vetor[k],
    mu2,sqrt(sigma22[k])))))^(-1)
}

matrizEsperancas[1,]<-0

#M-STEP
pi1<-mean(matrizEsperancas[,1])
parametrosCMRM5[1]<-pi1
pi2<-mean(matrizEsperancas[,2])
parametrosCMRM5Like<-parametrosCMRM5[2:length(parametrosCMRM5)]
res <- maxSANN(logLikelihoodCMRM5, start=parametrosCMRM5Like,
constraints=list(ineqA=A, ineqB=B),random.seed = sementes[conta])
parametrosCMRM5[2:length(parametrosCMRM5)]<-res$estimate
    parametrosCMRM5[1]<-pi1
    #Guarda a verossimilhanca
    if(conta==1)
    {
    likeli<-abs(res$maximum)
    }
    else
    {
    erro<-abs(likeli-abs(res$maximum))
    likeli<-abs(res$maximum)
    }
    conta<-conta+1
    }
AIC.CMRM5<-(2*p)-2*likeli
Cov.CMRM5<-(-1)*solve(hessian(res))
STD.CMRM5<-sqrt(diag(Cov.CMRM5))
ESTAT.CMRM5<-res$estimate/STD.CMRM5
PARM.CMRM5<-c(pi1,res$estimate)
PVALOR.CMRM5<-2*pnorm(abs(ESTAT.CMRM5),lower.tail = FALSE)
save.image("CMRM5.RData")

```

```
##### CMRM10 #####
source("Funcoes.R")
set.seed<-12548
sementes<-round(10000*runif(10000))
#Número de parametros
p<-11

parametrosCMRM10<-rep(0.1,p)

#Inicializa vetor de chutes parametrosCMRM10(pi,alpha11,
#alpha12,alpha13,alpha21,alpha22,alpha23,mu1,gamma1,mu2,gamma2)
#parm<-coef(lm(retornos.df[,2]~1+retornos.df[,6]))
#parametrosCMRM10<-c(0.1,0.1,0.1,0.1,0.1,0.1,0.1,0.1,parm,parm)

#Vetor de dados
vetor<-retornos.df[,2]
library(maxLik)

#Restrições
A <- diag(p-1)
A<-rbind(A,rep(0,p-1),rep(0,p-1))

A[11,2]=A[11,3]==-1
A[12,5]=A[12,6]==-1

B = matrix(0,nrow(A),1)
B[7]=B[8]=B[9]=B[10]= 1e+15
B[11]=B[12]=1

conta<-1
erro<-100000

while(erro>0.1)
{
  #E-STEP
matrizEsperancas<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

for(k in 2:length(vetor))
{
  mu1<-parametrosCMRM10[8]+parametrosCMRM10[9]*retornos.df[k,6]
  mu2<-parametrosCMRM10[10]+parametrosCMRM10[11]*retornos.df[k,6]

  erro2<-vetor[k-1]^2
  sigma21[k]<-parametrosCMRM10[2]+parametrosCMRM10[3]*
```

```

erro2+parametrosCMRM10[4]*sigma21[k-1]
sigma22[k]<-parametrosCMRM10[5]+parametrosCMRM10[6]*
erro2+parametrosCMRM10[7]*sigma22[k-1]

matrizEsperancas[k,1]<-((1+(((1-parametrosCMRM10[1])*
dnorm(vetor[k],mu2,sqrt(sigma22[k])))/(parametrosCMRM10[1]*
dnorm(vetor[k],mu1,sqrt(sigma21[k]))))))^(-1))
matrizEsperancas[k,2]<-(1+((parametrosCMRM10[1]*dnorm(vetor[k],mu1,
sqrt(sigma21[k])))/(1-parametrosCMRM10[1])*dnorm(vetor[k],
mu2,sqrt(sigma22[k]))))))^(-1)
}

matrizEsperancas[1,]<-0

#M-STEP
pi1<-mean(matrizEsperancas[,1])
parametrosCMRM10[1]<-pi1
pi2<-mean(matrizEsperancas[,2])
parametrosCMRM10Like<-parametrosCMRM10[2:length(parametrosCMRM10)]
res <- maxSANN(logLikelihoodCMRM10, start=parametrosCMRM10Like,
constraints=list(ineqA=A, ineqB=B),random.seed =sementes[conta] )
parametrosCMRM10[2:length(parametrosCMRM10)]<-res$estimate
parametrosCMRM10[1]<-pi1
#Guarda a verossimilhanca
if(conta==1)
{
likeli<-abs(res$maximum)
}
else
{
erro<-abs(likeli-abs(res$maximum))
likeli<-abs(res$maximum)
}
conta<-conta+1
}
AIC.CMRM10<-(2*p)-2*likeli
Cov.CMRM10<-(-1)*solve(hessian(res))
STD.CMRM10<-sqrt(diag(Cov.CMRM10))
ESTAT.CMRM10<-res$estimate/STD.CMRM10
PARM.CMRM10<-c(pi1,res$estimate)
PVALOR.CMRM10<-2*pnorm(abs(ESTAT.CMRM10),lower.tail = FALSE)
save.image("CMRM10.RData")

##### CMRM15 #####
source("Funcoes.R")
set.seed<-87452
sementes<-round(10000*runif(10000))

```

```

#Número de parametros
p<-11

#Inicializa vetor de chutes parametrosCMRM15(pi, alpha11,
alpha12, alpha13, alpha21, alpha22, alpha23, mu1, gamma1, mu2, gamma2)
#parm<-coef(lm(retornos.df[,2]~1+retornos.df[,7]))
#parametrosCMRM15<-c(0.1,0.1,0.1,0.1,0.1,0.1,0.1,parm,parm)
parametrosCMRM15<-rep(0.1,p)

#Vetor de dados
vetor<-retornos.df[,2]
library(maxLik)

#Restrições
A <- diag(p-1)
A<-rbind(A, rep(0,p-1), rep(0,p-1))

A[11,2]=A[11,3]==-1
A[12,5]=A[12,6]==-1

B = matrix(0,nrow(A),1)
B[7]=B[8]=B[9]=B[10]= 1e+15
B[11]=B[12]=1

conta<-1
erro<-100000

while(erro>0.1)
{
  #E-STEP
  matrizEsperancas<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

  for(k in 2:length(vetor))
  {
    mu1<-parametrosCMRM15[8]+parametrosCMRM15[9]*retornos.df[k,7]
    mu2<-parametrosCMRM15[10]+parametrosCMRM15[11]*retornos.df[k,7]

    erro2<-vetor[k-1]^2
    sigma21[k]<-parametrosCMRM15[2]+parametrosCMRM15[3]*
    erro2+parametrosCMRM15[4]*sigma21[k-1]
    sigma22[k]<-parametrosCMRM15[5]+parametrosCMRM15[6]*
    erro2+parametrosCMRM15[7]*sigma22[k-1]

    matrizEsperancas[k,1]<-((1+(((1-parametrosCMRM15[1])*dnorm(vetor[k],
mu2,sqrt(sigma22[k])))/(parametrosCMRM15[1]*dnorm(vetor[k],
mu1,sqrt(sigma21[k]))))))^(-1))
  }
}

```

```

matrizEsperancas[k,2]<-(1+((parametrosCMRM15[1]*dnorm(vetor[k],
mu1,sqrt(sigma21[k])))/(1-parametrosCMRM15[1])*dnorm(vetor[k],mu2,
sqrt(sigma22[k]))))^(-1)
}

matrizEsperancas[1,]<-0

#M-STEP
pi1<-mean(matrizEsperancas[,1])
parametrosCMRM15[1]<-pi1
pi2<-mean(matrizEsperancas[,2])
parametrosCMRM15Like<-parametrosCMRM15[2:length(parametrosCMRM15)]
res <- maxSANN(logLikelihoodCMRM15, start=parametrosCMRM15Like,
constraints=list(ineqA=A, ineqB=B),random.seed = sementes[conta])
parametrosCMRM15[2:length(parametrosCMRM15)]<-res$estimate
  parametrosCMRM15[1]<-pi1
  #Guarda a verossimilhanca
  if(conta==1)
  {
  likeli<-abs(res$maximum)
  }
  else
  {
  erro<-abs(likeli-abs(res$maximum))
  likeli<-abs(res$maximum)
  }
  conta<-conta+1
  }
AIC.CMRM15<-(2*p)-2*likeli
Cov.CMRM15<-(-1)*solve(hessian(res))
STD.CMRM15<-sqrt(diag(Cov.CMRM15))
ESTAT.CMRM15<-res$estimate/STD.CMRM15
PARM.CMRM15<-c(pi1,res$estimate)
PVALOR.CMRM15<-2*pnorm(abs(ESTAT.CMRM15),lower.tail = FALSE)
save.image("CMRM15.RData")

##### CMRM20 #####
source("Funcoes.R")
set.seed<-35748
sementes<-round(10000*runif(10000))
#Número de parametros
p<-11

#Inicializa vetor de chutes parametrosCMRM20(pi,alpha11,alpha12,
#alpha13,alpha21,alpha22,alpha23,mu1,gamma1,mu2,gamma2)
parametrosCMRM20<-rep(0.1,p)
#Vetor de dados

```

```

vetor<-retornos.df[,2]
library(maxLik)

#Restrições
A <- diag(p-1)
A<-rbind(A,rep(0,p-1),rep(0,p-1))

A[11,2]=A[11,3]=-1
A[12,5]=A[12,6]=-1

B = matrix(0,nrow(A),1)
B[7]=B[8]=B[9]=B[10]= 1e+15
B[11]=B[12]=1

conta<-1
erro<-100000

while(erro>0.1)
{
  #E-STEP
  matrizEsperancas<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

  for(k in 2:length(vetor))
  {
    mu1<-parametrosCMRM20[8]+parametrosCMRM20[9]*retornos.df[k,8]
    mu2<-parametrosCMRM20[10]+parametrosCMRM20[11]*retornos.df[k,8]

    erro2<-vetor[k-1]^2
    sigma21[k]<-parametrosCMRM20[2]+parametrosCMRM20[3]*erro2+
    parametrosCMRM20[4]*sigma21[k-1]
    sigma22[k]<-parametrosCMRM20[5]+parametrosCMRM20[6]*erro2+
    parametrosCMRM20[7]*sigma22[k-1]

    matrizEsperancas[k,1]<-((1+(((1-parametrosCMRM20[1])*dnorm(vetor[k],
    mu2,sqrt(sigma22[k])))/(parametrosCMRM20[1])*dnorm(vetor[k],
    mu1,sqrt(sigma21[k])))))^(-1))
    matrizEsperancas[k,2]<-((1+((parametrosCMRM20[1])*dnorm(vetor[k],
    mu1,sqrt(sigma21[k])))/(1-parametrosCMRM20[1])*dnorm(vetor[k],
    mu2,sqrt(sigma22[k])))))^(-1))
  }

  matrizEsperancas[1,]<-0

  #M-STEP
  pil<-mean(matrizEsperancas[,1])
  parametrosCMRM20[1]<-pil

```

```

pi2<-mean(matrizEsperancas[,2])
parametrosCMRM20Like<-parametrosCMRM20[2:length(parametrosCMRM20)]
res <- maxSANN(logLikelihoodCMRM20, start=parametrosCMRM20Like,
  constraints=list(ineqA=A, ineqB=B),random.seed = sementes[conta])
parametrosCMRM20[2:length(parametrosCMRM20)]<-res$estimate
  parametrosCMRM20[1]<-pi1
  #Guarda a verossimilhanca
if(conta==1)
{
likeli<-abs(res$maximum)
}
else
{
erro<-abs(likeli-abs(res$maximum))
likeli<-abs(res$maximum)
}
conta<-conta+1
}
AIC.CMRM20<-(2*p)-2*likeli
Cov.CMRM20<-(-1)*solve(hessian(res))
STD.CMRM20<-sqrt(diag(Cov.CMRM20))
ESTAT.CMRM20<-res$estimate/STD.CMRM20
PARM.CMRM20<-c(pi1,res$estimate)
PVALOR.CMRM20<-2*pnorm(abs(ESTAT.CMRM20),lower.tail = FALSE)
save.image("CMRM20.RData")

```

A.2.2 Modelo CAPM - PETR3.

```

#Limpa o WorksPace
rm(list = ls(all = TRUE))

#Define o WorkSPace
setwd("C:/Dropbox/Doutorado/2º Semestre 2011/
Finanças corporativas/Artigo 1/Programas/PETR3")

#Lê os dados das séries financeiras
dados.df<-read.csv("DadosMenor11092011.csv")
names(dados.df)

#Deflacionar o preço da ação, o índice Bovespa e a
#taxa livre de risco (CDI), utilizando o IGP-M.
dados.df[, "LP_PETR3.DEF"]<-dados.df[, "PETR3_LP"]*dados.df[, "INDICE"]
dados.df[, "IBOVESPA.DEF"]<-dados.df[, "IBOVESPA"]*dados.df[, "INDICE"]
dados.df[, "SELIC.DEF"]<-dados.df[, "SELIC"]*dados.df[, "INDICE"]
#dados.df[, "HML.DEF"]<-dados.df[, "HML"]*dados.df[, "INDICE"]

```

```

#dados.df[, "SMB.DEF"]<-dados.df[, "SMB"]*dados.df[, "INDICE"]

#Cria as variáveis em forma de retorno
PETR3.ret<-diff(log(dados.df[, "LP_PETR3.DEF"]))*100
IBOVESPA.ret<-diff(log(dados.df[, "IBOVESPA.DEF"]))*100
SELIC.ret<-diff(log(dados.df[, "SELIC.DEF"]))*100
#HML.ret<-diff(log(dados.df[, "HML.DEF"]))*100
#SMB.ret<-diff(log(dados.df[, "SMB.DEF"]))*100
tempo<-seq(1:(length(PETR3.ret)))

#Cria o DataFrame
#retornos.df<-as.data.frame(cbind(tempo,PETR3.ret,IBOVESPA.ret,
SELIC.ret,HML.ret,SMB.ret,dados.df[2:nrow(dados.df), "Election5"],
dados.df[2:nrow(dados.df), "Election10"],dados.df[2:nrow(dados.df),
"Election15"],dados.df[2:nrow(dados.df), "Election20"]))
retornos.df<-as.data.frame(cbind(tempo,PETR3.ret,IBOVESPA.ret,
SELIC.ret,dados.df[2:nrow(dados.df), "Election5"],
dados.df[2:nrow(dados.df), "Election10"],dados.df[2:nrow(dados.df),
"Election15"],dados.df[2:nrow(dados.df), "Election20"]))
#names(retornos.df)<-c("Período", "Retorno deflacionadao PETR3",
"Retorno deflacionadao IBOVESPA", "Retorno deflacionadao SELIC",
"Retorno deflacionadao HML", "Retorno deflacionadao SMB", "Eleições
janela de 5 dias", "Eleições janela de 10 dias", "Eleições janela de 15 dias"
, "Eleições janela de 20 dias")
names(retornos.df)<-c("Período", "Retorno deflacionadao PETR3",
"Retorno deflacionadao IBOVESPA", "Retorno deflacionadao SELIC",
"Eleições janela de 5 dias", "Eleições janela de 10 dias",
"Eleições janela de 15 dias", "Eleições janela de 20 dias")

#Interpola linearmente dados faltantes na Bovespa
library(wq)
retornos.df[,3]<- interpTs(retornos.df[,3], gap = 3,
type = c("linear"))
retornos.df[,2]<- interpTs(retornos.df[,2], gap = 3,
type = c("linear"))
retornos.df[,4]<- interpTs(retornos.df[,4], gap = 3,
type = c("linear"))

#Deixa na forma do CAPM
retornos.df[,2]<-retornos.df[,2]-retornos.df[,4]
retornos.df[,3]<-retornos.df[,3]-retornos.df[,4]

##### CAPM5 #####
source("Funcoes.R")
set.seed<-99855
sementes<-round(10000*runif(10000))
#Número de parametros
p<-11

```

```

#Inicializa vetor de chutes parametrosCAPM5(pi, alpha11,
#alpha12, alpha13, alpha21, alpha22, alpha23, mu1, beta1, mu2, beta2)
parametrosCAPM5<-rep(0.1,p)
#parm<-coef(lm(retornos.df[,2]~1+retornos.df[,5]))
#parametrosCAPM5<-c(0.1,0.1,0.1,0.1,0.1,0.1,0.1,parm,parm)

#Vetor de dados
vetor<-retornos.df[,2]
library(maxLik)

#Restrições
A <- diag(p-1)
A<-rbind(A, rep(0, p-1), rep(0, p-1))

A[11,2]=A[11,3]=-1
A[12,5]=A[12,6]=-1

B = matrix(0,nrow(A),1)
B[7]=B[8]=B[9]=B[10]= 1e+15
B[11]=B[12]=1

conta<-1
erro<-100000

while(erro>0.1)
{
  #E-STEP
matrizEsperancas<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

  k<-159
for(k in 2:length(vetor))
{
  mu1<-parametrosCAPM5[8]*retornos.df[k,5]+
  parametrosCAPM5[9]*retornos.df[k,3]
  mu2<-parametrosCAPM5[10]*retornos.df[k,5]+
  parametrosCAPM5[11]*retornos.df[k,3]

  erro2<-vetor[k-1]^2
  sigma21[k]<-parametrosCAPM5[2]+parametrosCAPM5[3]
  *erro2+parametrosCAPM5[4]*sigma21[k-1]
  sigma22[k]<-parametrosCAPM5[5]+parametrosCAPM5[6]
  *erro2+parametrosCAPM5[7]*sigma22[k-1]

  d1<-dnorm(vetor[k],mu1,sqrt(sigma21[k]))
  if(d1==0) d1=0.000000001
}
}

```

```

        d2<-dnorm(vetor[k],mu2,sqrt(sigma22[k]))
        if(d2==0) d2=0.000000001
        matrizEsperancas[k,1]<-((1+(((1-parametrosCAPM5[1])*d2)
        /(parametrosCAPM5[1]*d1))^(-1))
        matrizEsperancas[k,2]<-(1+((parametrosCAPM5[1]*d1)
        /((1-parametrosCAPM5[1])*d2)))^(-1)
    }

matrizEsperancas[1,]<-0

#M-STEP
pi1<-mean(matrizEsperancas[,1])
parametrosCAPM5[1]<-pi1
pi2<-mean(matrizEsperancas[,2])
parametrosCAPM5Like<-parametrosCAPM5[2:length(parametrosCAPM5)]
res <- maxSANN(logLikelihoodCAPM5, start=parametrosCAPM5Like,
  constraints=list(ineqA=A, ineqB=B),random.seed = sementes[conta])
parametrosCAPM5[2:length(parametrosCAPM5)]<-res$estimate
  parametrosCAPM5[1]<-pi1
  #Guarda a verossimilhanca
  if(conta==1)
  {
  likeli<-abs(res$maximum)
  }
  else
  {
  erro<-abs(likeli-abs(res$maximum))
  likeli<-abs(res$maximum)
  }
  conta<-conta+1
  }
AIC.CAPM5<-(2*p)-2*likeli
Cov.CAPM5<-(-1)*solve(hessian(res))
STD.CAPM5<-sqrt(diag(Cov.CAPM5))
ESTAT.CAPM5<-res$estimate/STD.CAPM5
PARM.CAPM5<-c(pi1,res$estimate)
PVALOR.CAPM5<-2*pnorm(abs(ESTAT.CAPM5),lower.tail = FALSE)
save.image("CAPM5.RData")

##### CAPM10 #####
source("Funcoes.R")
set.seed<-35545
sementes<-round(10000*runif(10000))
#Número de parametros
p<-11

parametrosCAPM10<-rep(0.1,p)

```

```

#Inicializa vetor de chutes parametrosCAPM10(pi,alpha11,
alpha12,alpha13,alpha21,alpha22,alpha23,mu1,beta1,mu2,beta2)
#parm<-coef(lm(retornos.df[,2]~1+retornos.df[,6]))
#parametrosCAPM10<-c(0.1,0.1,0.1,0.1,0.1,0.1,0.1,parm,parm)

#Vetor de dados
vetor<-retornos.df[,2]
library(maxLik)

#Restrições
A <- diag(p-1)
A<-rbind(A,rep(0,p-1),rep(0,p-1))

A[11,2]=A[11,3]==-1
A[12,5]=A[12,6]==-1

B = matrix(0,nrow(A),1)
B[7]=B[8]=B[9]=B[10]= 1e+15
B[11]=B[12]=1

conta<-1
erro<-100000

while(erro>0.1)
{
  #E-STEP
matrizEsperancas<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

for(k in 2:length(vetor))
{
  mu1<-parametrosCAPM10[8]*retornos.df[k,6]+
  parametrosCAPM10[9]*retornos.df[k,3]
  mu2<-parametrosCAPM10[10]*retornos.df[k,6]+
  parametrosCAPM10[11]*retornos.df[k,3]

  erro2<-vetor[k-1]^2
  sigma21[k]<-parametrosCAPM10[2]+parametrosCAPM10[3]*
  erro2+parametrosCAPM10[4]*sigma21[k-1]
  sigma22[k]<-parametrosCAPM10[5]+parametrosCAPM10[6]*
  erro2+parametrosCAPM10[7]*sigma22[k-1]

  d1<-dnorm(vetor[k],mu1,sqrt(sigma21[k]))
  if(d1==0) d1=0.000000001
  d2<-dnorm(vetor[k],mu2,sqrt(sigma22[k]))
  if(d2==0) d2=0.000000001
}
}

```

```

        matrizEsperancas[k,1]<-((1+((1-parametrosCAPM10[1])*d2)
        / (parametrosCAPM10[1]*d1)))^(-1))
        matrizEsperancas[k,2]<-(1+((parametrosCAPM10[1]*d1)
        / ((1-parametrosCAPM10[1])*d2)))^(-1)
    }

matrizEsperancas[1,]<-0

#M-STEP
pi1<-mean(matrizEsperancas[,1])
parametrosCAPM10[1]<-pi1
pi2<-mean(matrizEsperancas[,2])
parametrosCAPM10Like<-parametrosCAPM10[2:length(parametrosCAPM10)]
res <- maxSANN(logLikelihoodCAPM10, start=parametrosCAPM10Like,
    constraints=list(ineqA=A, ineqB=B), random.seed =sementes[conta] )
parametrosCAPM10[2:length(parametrosCAPM10)]<-res$estimate
    parametrosCAPM10[1]<-pi1
    #Guarda a verossimilhanca
if (conta==1)
{
likeli<-abs(res$maximum)
}
else
{
erro<-abs(likeli-abs(res$maximum))
likeli<-abs(res$maximum)
}
conta<-conta+1
}
AIC.CAPM10<-(2*p)-2*likeli
Cov.CAPM10<-(-1)*solve(hessian(res))
STD.CAPM10<-sqrt(diag(Cov.CAPM10))
ESTAT.CAPM10<-res$estimate/STD.CAPM10
PARM.CAPM10<-c(pi1,res$estimate)
PVALOR.CAPM10<-2*pnorm(abs(ESTAT.CAPM10),lower.tail = FALSE)
save.image("CAPM10.RData")

##### CAPM15 #####
source("Funcoes.R")
set.seed<-884552
sementes<-round(10000*runif(10000))
#Número de parametros
p<-11

#Inicializa vetor de chutes parametrosCAPM15(pi,alpha11,
#alpha12,alpha13,alpha21,alpha22,alpha23,mu1,beta1,mu2,beta2)
#parm<-coef(lm(retornos.df[,2]~1+retornos.df[,7]))

```

```

#parametrosCAPM15<-c(0.1,0.1,0.1,0.1,0.1,0.1,0.1,parm,parm)
parametrosCAPM15<-rep(0.1,p)

#Vetor de dados
vetor<-retornos.df[,2]
library(maxLik)

#Restrições
A <- diag(p-1)
A<-rbind(A, rep(0,p-1), rep(0,p-1))

A[11,2]=A[11,3]=-1
A[12,5]=A[12,6]=-1

B = matrix(0,nrow(A),1)
B[7]=B[8]=B[9]=B[10]= 1e+15
B[11]=B[12]=1

conta<-1
erro<-100000

while(erro>0.1)
{
  #E-STEP
  matrizEsperancas<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

  for(k in 2:length(vetor))
  {
    mu1<-parametrosCAPM15[8]*retornos.df[k,7]+
    parametrosCAPM15[9]*retornos.df[k,3]
    mu2<-parametrosCAPM15[10]*retornos.df[k,7]+
    parametrosCAPM15[11]*retornos.df[k,3]

    erro2<-vetor[k-1]^2
    sigma21[k]<-parametrosCAPM15[2]+parametrosCAPM15[3]*erro2+
    parametrosCAPM15[4]*sigma21[k-1]
    sigma22[k]<-parametrosCAPM15[5]+parametrosCAPM15[6]*erro2+
    parametrosCAPM15[7]*sigma22[k-1]

    d1<-dnorm(vetor[k],mu1,sqrt(sigma21[k]))
    if(d1==0) d1=0.000000001
    d2<-dnorm(vetor[k],mu2,sqrt(sigma22[k]))
    if(d2==0) d2=0.000000001
    matrizEsperancas[k,1]<-((1+(((1-parametrosCAPM15[1])*d2)
    /(parametrosCAPM15[1]*d1)))^(-1))
    matrizEsperancas[k,2]<-(1+((parametrosCAPM15[1]*d1)

```

```

      /((1-parametrosCAPM15[1])*d2)) ^ (-1)
    }

matrizEsperancas[1,] <- 0

#M-STEP
pi1 <- mean(matrizEsperancas[,1])
parametrosCAPM15[1] <- pi1
pi2 <- mean(matrizEsperancas[,2])
parametrosCAPM15Like <- parametrosCAPM15[2:length(parametrosCAPM15)]
res <- maxSANN(logLikelihoodCAPM15, start=parametrosCAPM15Like,
constraints=list(ineqA=A, ineqB=B), random.seed = sementes[conta])
parametrosCAPM15[2:length(parametrosCAPM15)] <- res$estimate
  parametrosCAPM15[1] <- pi1
  #Guarda a verossimilhanca
  if(conta==1)
  {
  likeli <- abs(res$maximum)
  }
  else
  {
  erro <- abs(likeli-abs(res$maximum))
  likeli <- abs(res$maximum)
  }
  conta <- conta+1
  }
AIC.CAPM15 <- (2*p) - 2*likeli
Cov.CAPM15 <- (-1) * solve(hessian(res))
STD.CAPM15 <- sqrt(diag(Cov.CAPM15))
ESTAT.CAPM15 <- res$estimate/STD.CAPM15
PARM.CAPM15 <- c(pi1, res$estimate)
PVALOR.CAPM15 <- 2*pnorm(abs(ESTAT.CAPM15), lower.tail = FALSE)
save.image("CAPM15.RData")

##### CAPM20 #####
source("Funcoes.R")
set.seed<-33655459
sementes<-round(10000*runif(10000))
#Número de parametros
p<-11

#Inicializa vetor de chutes parametrosCAPM20(pi, alpha11,
#alpha12, alpha13, alpha21, alpha22, alpha23, mu1, beta1, mu2, beta2)
#parametrosCAPM20<-rep(0.1, p)

parametrosCAPM20<-rep(0.1, p)
#Vetor de dados

```

```

vetor<-retornos.df[,2]
library(maxLik)

#Restrições
A <- diag(p-1)
A<-rbind(A, rep(0, p-1), rep(0, p-1))

A[11,2]=A[11,3]=-1
A[12,5]=A[12,6]=-1

B = matrix(0, nrow(A), 1)
B[7]=B[8]=B[9]=B[10]= 1e+15
B[11]=B[12]=1

conta<-1
erro<-100000

while(erro>0.1)
{
  #E-STEP
  matrizEsperancas<-matrix(0, length(vetor), 2)
  sigma21<-rep(1, length(vetor))
  sigma22<-rep(1, length(vetor))

  for(k in 2:length(vetor))
  {
    mu1<-parametrosCAPM20[8]*retornos.df[k, 8]+
      parametrosCAPM20[9]*retornos.df[k, 3]
    mu2<-parametrosCAPM20[10]*retornos.df[k, 8]+
      parametrosCAPM20[11]*retornos.df[k, 3]

    erro2<-vetor[k-1]^2
    sigma21[k]<-parametrosCAPM20[2]+parametrosCAPM20[3]*
      erro2+parametrosCAPM20[4]*sigma21[k-1]
    sigma22[k]<-parametrosCAPM20[5]+parametrosCAPM20[6]*
      erro2+parametrosCAPM20[7]*sigma22[k-1]

    d1<-dnorm(vetor[k], mu1, sqrt(sigma21[k]))
    if(d1==0) d1=0.000000001
    d2<-dnorm(vetor[k], mu2, sqrt(sigma22[k]))
    if(d2==0) d2=0.000000001
    matrizEsperancas[k, 1]<-((1+((1-parametrosCAPM20[1])*d2)
      /(parametrosCAPM20[1]*d1))^(-1))
    matrizEsperancas[k, 2]<-(1+(parametrosCAPM20[1]*d1)
      /((1-parametrosCAPM20[1])*d2))^(-1))
  }

  matrizEsperancas[1,]<-0

```

```

#M-STEP
pi1<-mean(matrizEsperancas[,1])
parametrosCAPM20[1]<-pi1
pi2<-mean(matrizEsperancas[,2])
parametrosCAPM20Like<-parametrosCAPM20[2:length(parametrosCAPM20)]
res <- maxSANN(logLikelihoodCAPM20, start=parametrosCAPM20Like,
  constraints=list(ineqA=A, ineqB=B),random.seed = sementes[conta])
parametrosCAPM20[2:length(parametrosCAPM20)]<-res$estimate
  parametrosCAPM20[1]<-pi1
  #Guarda a verossimilhanca
if(conta==1)
{
likeli<-abs(res$maximum)
}
else
{
erro<-abs(likeli-abs(res$maximum))
likeli<-abs(res$maximum)
}
conta<-conta+1
}
AIC.CAPM20<-(2*p)-2*likeli
Cov.CAPM20<-(-1)*solve(hessian(res))
STD.CAPM20<-sqrt(diag(Cov.CAPM20))
ESTAT.CAPM20<-res$estimate/STD.CAPM20
PARM.CAPM20<-c(pi1,res$estimate)
PVALOR.CAPM20<-2*pnorm(abs(ESTAT.CAPM20),lower.tail = FALSE)
save.image("CAPM20.RData")

```

A.2.3 Modelo MM - PETR3.

```

#Limpa o WorksPace
rm(list = ls(all = TRUE))

#Define o WorkSPace
setwd("C:/Dropbox/Doutorado/2º Semestre 2011/
Finanças corporativas/Artigo 1/Programas/PETR3")

#Lê os dados das séries financeiras
dados.df<-read.csv("DadosMenor11092011.csv")
names(dados.df)

#Deflacionar o preço da ação, o índice Bovespa e
#a taxa livre de risco (CDI), utilizando o IGP-M.

```

```

dados.df[, "LP_PETR3.DEF"]<-dados.df[, "PETR3_LP"]*dados.df[, "INDICE"]
dados.df[, "IBOVESPA.DEF"]<-dados.df[, "IBOVESPA"]*dados.df[, "INDICE"]
dados.df[, "SELIC.DEF"]<-dados.df[, "SELIC"]*dados.df[, "INDICE"]
#dados.df[, "HML.DEF"]<-dados.df[, "HML"]*dados.df[, "INDICE"]
#dados.df[, "SMB.DEF"]<-dados.df[, "SMB"]*dados.df[, "INDICE"]

#Cria as variáveis em forma de retorno
PETR3.ret<-diff(log(dados.df[, "LP_PETR3.DEF"]))*100
IBOVESPA.ret<-diff(log(dados.df[, "IBOVESPA.DEF"]))*100
SELIC.ret<-diff(log(dados.df[, "SELIC.DEF"]))*100
#HML.ret<-diff(log(dados.df[, "HML.DEF"]))*100
#SMB.ret<-diff(log(dados.df[, "SMB.DEF"]))*100
tempo<-seq(1:(length(PETR3.ret)))

#Cria o DataFrame
#retornos.df<-as.data.frame(cbind(tempo,PETR3.ret,IBOVESPA.ret,
SELIC.ret,HML.ret,SMB.ret,dados.df[2:nrow(dados.df),
"Election5"],dados.df[2:nrow(dados.df),"Election10"],
dados.df[2:nrow(dados.df),"Election15"],
dados.df[2:nrow(dados.df),"Election20"]))
retornos.df<-as.data.frame(cbind(tempo,PETR3.ret,IBOVESPA.ret,
SELIC.ret,dados.df[2:nrow(dados.df),"Election5"],
dados.df[2:nrow(dados.df),"Election10"],dados.df[2:nrow(dados.df),
"Election15"],dados.df[2:nrow(dados.df),"Election20"]))
#names(retornos.df)<-c("Período","Retorno deflacionadao PETR3",
"Retorno deflacionadao IBOVESPA","Retorno deflacionadao SELIC",
"Retorno deflacionadao HML","Retorno deflacionadao SMB",
"Eleições janela de 5 dias","Eleições janela de 10 dias",
"Eleições janela de 15 dias","Eleições janela de 20 dias")
names(retornos.df)<-c("Período","Retorno deflacionadao PETR3",
"Retorno deflacionadao IBOVESPA","Retorno deflacionadao SELIC",
"Eleições janela de 5 dias","Eleições janela de 10 dias",
"Eleições janela de 15 dias","Eleições janela de 20 dias")

library(wq)
#Interpola linearmente dados faltantes na Bovespa
retornos.df[,3]<- interpTs(retornos.df[,3], gap = 3,type = c("linear"))

##### MM5 #####
source("Funcoes.R")
set.seed<-855
sementes<-round(10000*runif(10000))
#Número de parametros
p<-13

#Inicializa vetor de chutes parametrosMM5(pi,alpha11,alpha12,
#alpha13,alpha21,alpha22,alpha23,mu1,gamma1,beta1,mu2,gamma2,beta2)

```

```

parametrosMM5<-rep(0.1,p)
#parm<-coef(lm(retornos.df[,2]~1+retornos.df[,5]))
#parametrosMM5<-c(0.1,0.1,0.1,0.1,0.1,0.1,0.1,parm,parm)

#Vetor de dados
vetor<-retornos.df[,2]
library(maxLik)

#Restrições
A <- diag(p-1)
A<-rbind(A,rep(0,p-1),rep(0,p-1))

A[13,2]=A[13,3]==-1
A[14,5]=A[14,6]==-1

B = matrix(0,nrow(A),1)
B[7]=B[8]=B[9]=B[10]=B[11]=B[12]= 1e+15
B[13]=B[14]=1

conta<-1
erro<-100000

while(erro>0.1)
{
#E-STEP
matrizEsperancas<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

for(k in 2:length(vetor))
{
  mu1<-parametrosMM5[8]+parametrosMM5[9]*retornos.df[k,5]
  +parametrosMM5[10]*retornos.df[k,3]
  mu2<-parametrosMM5[11]+parametrosMM5[12]*retornos.df[k,5]
  +parametrosMM5[13]*retornos.df[k,3]

  erro2<-vetor[k-1]^2
  sigma21[k]<-parametrosMM5[2]+parametrosMM5[3]*
  erro2+parametrosMM5[4]*sigma21[k-1]
  sigma22[k]<-parametrosMM5[5]+parametrosMM5[6]*
  erro2+parametrosMM5[7]*sigma22[k-1]

  matrizEsperancas[k,1]<-((1+(((1-parametrosMM5[1])*dnorm(vetor[k],
  mu2,sqrt(sigma22[k])))/(parametrosMM5[1]*dnorm(vetor[k],mu1,
  sqrt(sigma21[k]))))))^(-1))
  matrizEsperancas[k,2]<-(1+((parametrosMM5[1]*dnorm(vetor[k],mu1,
  sqrt(sigma21[k])))/(1-parametrosMM5[1])*dnorm(vetor[k],
  mu2,sqrt(sigma22[k]))))))^(-1)

```

```

}

matrizEsperancas[1,]<-0

#M-STEP
pi1<-mean(matrizEsperancas[,1])
parametrosMM5[1]<-pi1
pi2<-mean(matrizEsperancas[,2])
parametrosMM5Like<-parametrosMM5[2:length(parametrosMM5)]
res <- maxSANN(logLikelihoodMM5, start=parametrosMM5Like,
constraints=list(ineqA=A, ineqB=B),random.seed = sementes[conta])
parametrosMM5[2:length(parametrosMM5)]<-res$estimate
  parametrosMM5[1]<-pi1
  #Guarda a verossimilhanca
if(conta==1)
{
likeli<-abs(res$maximum)
}
else
{
erro<-abs(likeli-abs(res$maximum))
likeli<-abs(res$maximum)
}
conta<-conta+1
}
AIC.MM5<-(2*p)-2*likeli
Cov.MM5<-(-1)*solve(hessian(res))
STD.MM5<-sqrt(diag(Cov.MM5))
ESTAT.MM5<-res$estimate/STD.MM5
PARM.MM5<-c(pi1,res$estimate)
PVALOR.MM5<-2*pnorm(abs(ESTAT.MM5),lower.tail = FALSE)
save.image("MM5.RData")

##### MM10 #####
source("Funcoes.R")
set.seed<-3254
sementes<-round(10000*runif(10000))
#Número de parametros
p<-13

parametrosMM10<-rep(0.1,p)

#Inicializa vetor de chutes parametrosMM10(pi, alpha11, alpha12, alpha13, alpha21,
#alpha22, alpha23, mu1, gamma1, beta1, mu2, gamma2, beta2)
#parm<-coef(lm(retornos.df[,2]~1+retornos.df[,6]))
#parametrosMM10<-c(0.1,0.1,0.1,0.1,0.1,0.1,0.1,0.1,parm,parm)

```

```

#Vetor de dados
vetor<-retornos.df[,2]
library(maxLik)

#Restrições
A <- diag(p-1)
A<-rbind(A, rep(0,p-1), rep(0,p-1))

A[13,2]=A[13,3]=-1
A[14,5]=A[14,6]=-1

B = matrix(0,nrow(A),1)
B[7]=B[8]=B[9]=B[10]=B[11]=B[12]= 1e+15
B[13]=B[14]=1

conta<-1
erro<-100000

while(erro>0.1)
{
  #E-STEP
matrizEsperancas<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

for(k in 2:length(vetor))
{
  mu1<-parametrosMM10[8]+parametrosMM10[9]*retornos.df[k,6]
  +parametrosMM10[10]*retornos.df[k,3]
  mu2<-parametrosMM10[11]+parametrosMM10[12]*retornos.df[k,6]
  +parametrosMM10[13]*retornos.df[k,3]

  erro2<-vetor[k-1]^2
  sigma21[k]<-parametrosMM10[2]+parametrosMM10[3]*erro2+
parametrosMM10[4]*sigma21[k-1]
  sigma22[k]<-parametrosMM10[5]+parametrosMM10[6]*erro2+
parametrosMM10[7]*sigma22[k-1]

  matrizEsperancas[k,1]<-((1+((1-parametrosMM10[1])*dnorm(vetor[k],
mu2,sqrt(sigma22[k])))/(parametrosMM10[1])*dnorm(vetor[k],
mu1,sqrt(sigma21[k]))))^(-1))
  matrizEsperancas[k,2]<-((1+((parametrosMM10[1])*dnorm(vetor[k],mu1,
sqrt(sigma21[k])))/(1-parametrosMM10[1])*dnorm(vetor[k],
mu2,sqrt(sigma22[k]))))^(-1))
}

matrizEsperancas[1,]<-0

```

```

#M-STEP
pi1<-mean(matrizEsperancas[,1])
parametrosMM10[1]<-pi1
pi2<-mean(matrizEsperancas[,2])
parametrosMM10Like<-parametrosMM10[2:length(parametrosMM10)]
res <- maxSANN(logLikelihoodMM10, start=parametrosMM10Like
, constraints=list(ineqA=A, ineqB=B),random.seed =sementes[conta] )
parametrosMM10[2:length(parametrosMM10)]<-res$estimate
  parametrosMM10[1]<-pi1
  #Guarda a verossimilhanca
if(conta==1)
{
likeli<-abs(res$maximum)
}
else
{
erro<-abs(likeli-abs(res$maximum))
likeli<-abs(res$maximum)
}
conta<-conta+1
}
AIC.MM10<-(2*p)-2*likeli
Cov.MM10<-(-1)*solve(hessian(res))
STD.MM10<-sqrt(diag(Cov.MM10))
ESTAT.MM10<-res$estimate/STD.MM10
PARM.MM10<-c(pi1,res$estimate)
PVALOR.MM10<-2*pnorm(abs(ESTAT.MM10),lower.tail = FALSE)
save.image("MM10.RData")

##### MM15 #####
source("Funcoes.R")
set.seed<-68752
sementes<-round(10000*runif(10000))
#Número de parametros
p<-13

#Inicializa vetor de chutes parametrosMM15(pi,alpha11,alpha12,
#alpha13,alpha21,alpha22
#,alpha23,mu1,gamma1,beta1,mu2,gamma2,beta2)
#parm<-coef(lm(retornos.df[,2]~1+retornos.df[,7]))
#parametrosMM15<-c(0.1,0.1,0.1,0.1,0.1,0.1,0.1,parm,parm)
parametrosMM15<-rep(0.1,p)

#Vetor de dados
vetor<-retornos.df[,2]
library(maxLik)

```

```

#Restrições
A <- diag(p-1)
A<-rbind(A, rep(0,p-1), rep(0,p-1))

A[13,2]=A[13,3]==-1
A[14,5]=A[14,6]==-1

B = matrix(0,nrow(A),1)
B[7]=B[8]=B[9]=B[10]=B[11]=B[12]= 1e+15
B[13]=B[14]=1

conta<-1
erro<-100000

while(erro>0.1)
{
  #E-STEP
  matrizEsperancas<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

  for(k in 2:length(vetor))
  {
    mu1<-parametrosMM15[8]+parametrosMM15[9]*retornos.df[k,7]
    +parametrosMM15[10]*retornos.df[k,3]
    mu2<-parametrosMM15[11]+parametrosMM15[12]*retornos.df[k,7]
    +parametrosMM15[13]*retornos.df[k,3]

    erro2<-vetor[k-1]^2
    sigma21[k]<-parametrosMM15[2]+parametrosMM15[3]*erro2
    +parametrosMM15[4]*sigma21[k-1]
    sigma22[k]<-parametrosMM15[5]+parametrosMM15[6]*erro2
    +parametrosMM15[7]*sigma22[k-1]

    matrizEsperancas[k,1]<-((1+(((1-parametrosMM15[1])*dnorm(vetor[k],mu2,
    sqrt(sigma22[k])))/(parametrosMM15[1])*dnorm(vetor[k],mu1,
    sqrt(sigma21[k])))))^(-1))
    matrizEsperancas[k,2]<-(1+((parametrosMM15[1])*dnorm(vetor[k],mu1,
    sqrt(sigma21[k])))/(1-parametrosMM15[1])*dnorm(vetor[k],mu2,
    sqrt(sigma22[k])))))^(-1)
  }

  matrizEsperancas[1,]<-0

  #M-STEP
  pi1<-mean(matrizEsperancas[,1])
  parametrosMM15[1]<-pi1
  pi2<-mean(matrizEsperancas[,2])

```

```

parametrosMM15Like<-parametrosMM15[2:length(parametrosMM15)]
res <- maxSANN(logLikelihoodMM15, start=parametrosMM15Like,
constraints=list(ineqA=A, ineqB=B),random.seed = sementes[conta])
parametrosMM15[2:length(parametrosMM15)]<-res$estimate
  parametrosMM15[1]<-pi1
  #Guarda a verossimilhanca
if (conta==1)
{
likeli<-abs(res$maximum)
}
else
{
erro<-abs(likeli-abs(res$maximum))
likeli<-abs(res$maximum)
}
conta<-conta+1
}
AIC.MM15<-(2*p)-2*likeli
Cov.MM15<-(-1)*solve(hessian(res))
STD.MM15<-sqrt(diag(Cov.MM15))
ESTAT.MM15<-res$estimate/STD.MM15
PARM.MM15<-c(pi1,res$estimate)
PVALOR.MM15<-2*pnorm(abs(ESTAT.MM15),lower.tail = FALSE)
save.image("MM15.RData")

##### MM20 #####
source("Funcoes.R")
set.seed<-852258
sementes<-round(10000*runif(10000))
#Número de parametros
p<-13

#Inicializa vetor de chutes parametrosMM20(pi,alpha11,
#alpha12,alpha13,alpha21,alpha22,
#alpha23,mu1,gamma1,beta1,mu2,gamma2,beta2)
#parametrosMM20<-rep(0.1,p)

parametrosMM20<-rep(0.1,p)
#Vetor de dados
vetor<-retornos.df[,2]
library(maxLik)

#Restrições
A <- diag(p-1)
A<-rbind(A,rep(0,p-1),rep(0,p-1))

A[13,2]=A[13,3]=-1

```

```

A[14,5]=A[14,6]=-1

B = matrix(0,nrow(A),1)
B[7]=B[8]=B[9]=B[10]=B[11]=B[12]= 1e+15
B[13]=B[14]=1

conta<-1
erro<-100000

while(erro>0.1)
{
  #E-STEP
  matrizEsperancas<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

  for(k in 2:length(vetor))
  {
    mu1<-parametrosMM20[8]+parametrosMM20[9]*retornos.df[k,8]
    +parametrosMM20[10]*retornos.df[k,3]
    mu2<-parametrosMM20[11]+parametrosMM20[12]*retornos.df[k,8]
    +parametrosMM20[13]*retornos.df[k,3]

    erro2<-vetor[k-1]^2
    sigma21[k]<-parametrosMM20[2]+parametrosMM20[3]*erro2
    +parametrosMM20[4]*sigma21[k-1]
    sigma22[k]<-parametrosMM20[5]+parametrosMM20[6]*erro2
    +parametrosMM20[7]*sigma22[k-1]

    matrizEsperancas[k,1]<-((1+(((1-parametrosMM20[1])*dnorm(vetor[k],
    mu2,sqrt(sigma22[k])))/(parametrosMM20[1]*dnorm(vetor[k],
    mu1,sqrt(sigma21[k])))))^(-1))
    matrizEsperancas[k,2]<-(1+((parametrosMM20[1]*dnorm(vetor[k],
    mu1,sqrt(sigma21[k])))/(1-parametrosMM20[1])*dnorm(vetor[k],
    mu2,sqrt(sigma22[k])))))^(-1)
  }

  matrizEsperancas[1,]<-0

  #M-STEP
  pi1<-mean(matrizEsperancas[,1])
  parametrosMM20[1]<-pi1
  pi2<-mean(matrizEsperancas[,2])
  parametrosMM20Like<-parametrosMM20[2:length(parametrosMM20)]
  res <- maxSANN(logLikelihoodMM20, start=parametrosMM20Like,
  constraints=list(ineqA=A, ineqB=B),random.seed = sementes[conta])
  parametrosMM20[2:length(parametrosMM20)]<-res$estimate
  parametrosMM20[1]<-pi1

```

```

#Guarda a verossimilhanca
if (conta==1)
{
likeli<-abs(res$maximum)
}
else
{
erro<-abs(likeli-abs(res$maximum))
likeli<-abs(res$maximum)
}
conta<-conta+1
}
AIC.MM20<-(2*p)-2*likeli
Cov.MM20<-(-1)*solve(hessian(res))
STD.MM20<-sqrt(diag(Cov.MM20))
ESTAT.MM20<-res$estimate/STD.MM20
PARM.MM20<-c(pil,res$estimate)
PVALOR.MM20<-2*pnorm(abs(ESTAT.MM20),lower.tail = FALSE)
save.image("MM20.RData")

```

A.2.4 Modelo CMRM - PETR4.

```

#Limpa o WorksPace
rm(list = ls(all = TRUE))

#Define o WorkSPace
setwd("C:/Users/Sony/Desktop/Artigo 1")

#Lê os dados das séries financeiras
dados.df<-read.csv("DadosMenor31082011.csv")
names(dados.df)

#Deflacionar o preço da ação, o índice Bovespa
#e a taxa livre de risco (CDI), utilizando o IGP-M.
dados.df[, "LP_PETR4.DEF"]<-dados.df[, "LP_PETR4"]*dados.df[, "INDICE"]
dados.df[, "IBOVESPA.DEF"]<-dados.df[, "IBOVESPA"]*dados.df[, "INDICE"]
dados.df[, "SELIC.DEF"]<-dados.df[, "SELIC"]*dados.df[, "INDICE"]
#dados.df[, "HML.DEF"]<-dados.df[, "HML"]*dados.df[, "INDICE"]
#dados.df[, "SMB.DEF"]<-dados.df[, "SMB"]*dados.df[, "INDICE"]

#Cria as variáveis em forma de retorno
PETR4.ret<-diff(log(dados.df[, "LP_PETR4.DEF"]))*100
IBOVESPA.ret<-diff(log(dados.df[, "IBOVESPA.DEF"]))*100
SELIC.ret<-diff(log(dados.df[, "SELIC.DEF"]))*100
#HML.ret<-diff(log(dados.df[, "HML.DEF"]))*100

```

```

#SMB.ret<-diff(log(dados.df[, "SMB.DEF"]))*100
tempo<-seq(1:(length(PETR4.ret)))

#Cria o DataFrame
#retornos.df<-as.data.frame(cbind(tempo,PETR4.ret,IBOVESPA.ret,
SELIC.ret,HML.ret,SMB.ret,dados.df[2:nrow(dados.df), "Election5"],
dados.df[2:nrow(dados.df), "Election10"],dados.df[2:nrow(dados.df)
, "Election15"],dados.df[2:nrow(dados.df), "Election20"]))
retornos.df<-as.data.frame(cbind(tempo,PETR4.ret,IBOVESPA.ret,
SELIC.ret,dados.df[2:nrow(dados.df), "Election5"],dados.df[2:nrow(dados.df),
"Election10"],dados.df[2:nrow(dados.df), "Election15"],
dados.df[2:nrow(dados.df), "Election20"]))
#names(retornos.df)<-c("Período", "Retorno deflacionadao PETR4",
"Retorno deflacionadao IBOVESPA", "Retorno deflacionadao SELIC",
"Retorno deflacionadao HML", "Retorno deflacionadao SMB",
"Eleições janela de 5 dias", "Eleições janela de 10 dias",
"Eleições janela de 15 dias", "Eleições janela de 20 dias")
names(retornos.df)<-c("Período", "Retorno deflacionadao PETR4",
"Retorno deflacionadao IBOVESPA", "Retorno deflacionadao SELIC",
"Eleições janela de 5 dias", "Eleições janela de 10 dias",
"Eleições janela de 15 dias", "Eleições janela de 20 dias")

##### CMRM5 #####
source("Funcoes.R")
set.seed<-54648
sementes<-round(10000*runif(10000))
#Número de parametros
p<-11

#Inicializa vetor de chutes parametrosCMRM5(pi,alpha11,
#alpha12,alpha13,alpha21,alpha22,alpha23,mu1,gamma1,mu2,gamma2)
parametrosCMRM5<-rep(0.1,p)
#parm<-coef(lm(retornos.df[,2]~1+retornos.df[,5]))
#parametrosCMRM5<-c(0.1,0.1,0.1,0.1,0.1,0.1,0.1,parm,parm)

#Vetor de dados
vetor<-retornos.df[,2]
library(maxLik)

#Restrições
A <- diag(p-1)
A<-rbind(A, rep(0,p-1), rep(0,p-1))

A[11,2]=A[11,3]==-1
A[12,5]=A[12,6]==-1

B = matrix(0,nrow(A),1)

```

```

B[7]=B[8]=B[9]=B[10]= 1e+15
B[11]=B[12]=1

conta<-1
erro<-100000

while(erro>0.1)
{
#E-STEP
matrizEsperancas<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

for(k in 2:length(vetor))
{
  mu1<-parametrosCMRM5[8]+parametrosCMRM5[9]*retornos.df[k,5]
  mu2<-parametrosCMRM5[10]+parametrosCMRM5[11]*retornos.df[k,5]

  erro2<-vetor[k-1]^2
  sigma21[k]<-parametrosCMRM5[2]+parametrosCMRM5[3]*
  erro2+parametrosCMRM5[4]*sigma21[k-1]
  sigma22[k]<-parametrosCMRM5[5]+parametrosCMRM5[6]*
  erro2+parametrosCMRM5[7]*sigma22[k-1]

  matrizEsperancas[k,1]<-((1+(((1-parametrosCMRM5[1])*dnorm(vetor[k],
  mu2,sqrt(sigma22[k])))/(parametrosCMRM5[1]*dnorm(vetor[k],
  mu1,sqrt(sigma21[k])))))^(-1))
  matrizEsperancas[k,2]<-(1+((parametrosCMRM5[1]*dnorm(vetor[k],mu1,
  sqrt(sigma21[k])))/(1-parametrosCMRM5[1])*dnorm(vetor[k],
  mu2,sqrt(sigma22[k])))))^(-1)
}

matrizEsperancas[1,]<-0

#M-STEP
pi1<-mean(matrizEsperancas[,1])
parametrosCMRM5[1]<-pi1
pi2<-mean(matrizEsperancas[,2])
parametrosCMRM5Like<-parametrosCMRM5[2:length(parametrosCMRM5)]
res <- maxSANN(logLikelihoodCMRM5, start=parametrosCMRM5Like,
constraints=list(ineqA=A, ineqB=B),random.seed = sementes[conta])
parametrosCMRM5[2:length(parametrosCMRM5)]<-res$estimate
  parametrosCMRM5[1]<-pi1
  #Guarda a verossimilhanca
if(conta==1)
{
  likeli<-abs(res$maximum)
}

```

```

else
{
erro<-abs(likeli-abs(res$maximum))
likeli<-abs(res$maximum)
}
conta<-conta+1
}
AIC.CMRM5<-(2*p)-2*likeli
Cov.CMRM5<-(-1)*solve(hessian(res))
STD.CMRM5<-sqrt(diag(Cov.CMRM5))
ESTAT.CMRM5<-res$estimate/STD.CMRM5
PARM.CMRM5<-c(pil,res$estimate)
PVALOR.CMRM5<-2*pnorm(abs(ESTAT.CMRM5),lower.tail = FALSE)
save.image("CMRM5.RData")

##### CMRM10 #####
source("Funcoes.R")
set.seed<-12548
sementes<-round(10000*runif(10000))
#Número de parametros
p<-11

parametrosCMRM10<-rep(0.1,p)

#Inicializa vetor de chutes parametrosCMRM10(pi,alpha11,alpha12,
#alpha13,alpha21,alpha22,alpha23,mu1,gamma1,mu2,gamma2)
#parm<-coef(lm(retornos.df[,2]~1+retornos.df[,6]))
#parametrosCMRM10<-c(0.1,0.1,0.1,0.1,0.1,0.1,0.1,0.1,parm,parm)

#Vetor de dados
vetor<-retornos.df[,2]
library(maxLik)

#Restrições
A <- diag(p-1)
A<-rbind(A,rep(0,p-1),rep(0,p-1))

A[11,2]=A[11,3]==-1
A[12,5]=A[12,6]==-1

B = matrix(0,nrow(A),1)
B[7]=B[8]=B[9]=B[10]= 1e+15
B[11]=B[12]=1

conta<-1
erro<-100000

```

```

while(erro>0.1)
{
  #E-STEP
matrizEsperancas<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

for(k in 2:length(vetor))
{
  mu1<-parametrosCMRM10[8]+parametrosCMRM10[9]*retornos.df[k,6]
  mu2<-parametrosCMRM10[10]+parametrosCMRM10[11]*retornos.df[k,6]

  erro2<-vetor[k-1]^2
  sigma21[k]<-parametrosCMRM10[2]+parametrosCMRM10[3]*erro2
  +parametrosCMRM10[4]*sigma21[k-1]
  sigma22[k]<-parametrosCMRM10[5]+parametrosCMRM10[6]*erro2
  +parametrosCMRM10[7]*sigma22[k-1]

  matrizEsperancas[k,1]<-((1+((1-parametrosCMRM10[1])*dnorm(vetor[k],
mu2,sqrt(sigma22[k])))/(parametrosCMRM10[1]*dnorm(vetor[k],
mu1,sqrt(sigma21[k]))))^(-1))
  matrizEsperancas[k,2]<-((1+((parametrosCMRM10[1])*dnorm(vetor[k],mu1,
sqrt(sigma21[k])))/(1-parametrosCMRM10[1])*dnorm(vetor[k],
mu2,sqrt(sigma22[k]))))^(-1))
}

matrizEsperancas[1,]<-0

#M-STEP
pi1<-mean(matrizEsperancas[,1])
parametrosCMRM10[1]<-pi1
pi2<-mean(matrizEsperancas[,2])
parametrosCMRM10Like<-parametrosCMRM10[2:length(parametrosCMRM10)]
res <- maxSANN(logLikelihoodCMRM10, start=parametrosCMRM10Like,
  constraints=list(ineqA=A, ineqB=B),random.seed =sementes[conta] )
parametrosCMRM10[2:length(parametrosCMRM10)]<-res$estimate
  parametrosCMRM10[1]<-pi1
  #Guarda a verossimilhanca
if(conta==1)
{
  likeli<-abs(res$maximum)
}
else
{
  erro<-abs(likeli-abs(res$maximum))
  likeli<-abs(res$maximum)
}
  conta<-conta+1

```

```

}
AIC.CMRM10<-(2*p)-2*likeli
Cov.CMRM10<-(-1)*solve(hessian(res))
STD.CMRM10<-sqrt(diag(Cov.CMRM10))
ESTAT.CMRM10<-res$estimate/STD.CMRM10
PARM.CMRM10<-c(pi1,res$estimate)
PVALOR.CMRM10<-2*pnorm(abs(ESTAT.CMRM10),lower.tail = FALSE)
save.image("CMRM10.RData")

##### CMRM15 #####
source("Funcoes.R")
set.seed<-87452
sementes<-round(10000*runif(10000))
#Número de parametros
p<-11

#Inicializa vetor de chutes parametrosCMRM15(pi,alpha11,alpha12,
alpha13,alpha21,alpha22,alpha23,mu1,gamma1,mu2,gamma2)
#parm<-coef(lm(retornos.df[,2]~1+retornos.df[,7]))
#parametrosCMRM15<-c(0.1,0.1,0.1,0.1,0.1,0.1,0.1,parm,parm)
parametrosCMRM15<-rep(0.1,p)

#Vetor de dados
vetor<-retornos.df[,2]
library(maxLik)

#Restrições
A <- diag(p-1)
A<-rbind(A,rep(0,p-1),rep(0,p-1))

A[11,2]=A[11,3]==-1
A[12,5]=A[12,6]==-1

B = matrix(0,nrow(A),1)
B[7]=B[8]=B[9]=B[10]= 1e+15
B[11]=B[12]=1

conta<-1
erro<-100000

while(erro>0.1)
{
  #E-STEP
  matrizEsperancas<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

```

```

for(k in 2:length(vetor))
{
    mu1<-parametrosCMRM15[8]+parametrosCMRM15[9]*retornos.df[k,7]
    mu2<-parametrosCMRM15[10]+parametrosCMRM15[11]*retornos.df[k,7]

    erro2<-vetor[k-1]^2
    sigma21[k]<-parametrosCMRM15[2]+parametrosCMRM15[3]*erro2+
parametrosCMRM15[4]*sigma21[k-1]
    sigma22[k]<-parametrosCMRM15[5]+parametrosCMRM15[6]*erro2+
parametrosCMRM15[7]*sigma22[k-1]

    matrizEsperancas[k,1]<-((1+(((1-parametrosCMRM15[1])*dnorm(vetor[k],
mu2,sqrt(sigma22[k])))/(parametrosCMRM15[1]*dnorm(vetor[k],
mu1,sqrt(sigma21[k]))))^(-1))
matrizEsperancas[k,2]<-(1+((parametrosCMRM15[1]*dnorm(vetor[k],mu1,
sqrt(sigma21[k])))/(1-parametrosCMRM15[1])*dnorm(vetor[k],mu2,
sqrt(sigma22[k]))))^(-1)
}

matrizEsperancas[1,]<-0

#M-STEP
pi1<-mean(matrizEsperancas[,1])
parametrosCMRM15[1]<-pi1
pi2<-mean(matrizEsperancas[,2])
parametrosCMRM15Like<-parametrosCMRM15[2:length(parametrosCMRM15)]
res <- maxSANN(logLikelihoodCMRM15, start=parametrosCMRM15Like,
constraints=list(ineqA=A, ineqB=B),random.seed = sementes[conta])
parametrosCMRM15[2:length(parametrosCMRM15)]<-res$estimate
    parametrosCMRM15[1]<-pi1
    #Guarda a verossimilhanca
    if(conta==1)
    {
        likeli<-abs(res$maximum)
    }
    else
    {
        erro<-abs(likeli-abs(res$maximum))
        likeli<-abs(res$maximum)
    }
    conta<-conta+1
}
AIC.CMRM15<-(2*p)-2*likeli
Cov.CMRM15<-(-1)*solve(hessian(res))
STD.CMRM15<-sqrt(diag(Cov.CMRM15))
ESTAT.CMRM15<-res$estimate/STD.CMRM15
PARM.CMRM15<-c(pi1,res$estimate)
PVALOR.CMRM15<-2*pnorm(abs(ESTAT.CMRM15),lower.tail = FALSE)

```

```

save.image("CMRM15.RData")

##### CMRM20 #####
source("Funcoes.R")
set.seed<-35748
sementes<-round(10000*runif(10000))
#Número de parametros
p<-11

#Inicializa vetor de chutes parametrosCMRM20(pi,alpha11,alpha12,
#alpha13,alpha21,alpha22,alpha23,mu1,gamma1,mu2,gamma2)
parametrosCMRM20<-rep(0.1,p)
#Vetor de dados
vetor<-retornos.df[,2]
library(maxLik)

#Restrições
A <- diag(p-1)
A<-rbind(A,rep(0,p-1),rep(0,p-1))

A[11,2]=A[11,3]==-1
A[12,5]=A[12,6]==-1

B = matrix(0,nrow(A),1)
B[7]=B[8]=B[9]=B[10]= 1e+15
B[11]=B[12]=1

conta<-1
erro<-100000

while(erro>0.1)
{
  #E-STEP
  matrizEsperancas<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

  for(k in 2:length(vetor))
  {
    mu1<-parametrosCMRM20[8]+parametrosCMRM20[9]*retornos.df[k,8]
    mu2<-parametrosCMRM20[10]+parametrosCMRM20[11]*retornos.df[k,8]

    erro2<-vetor[k-1]^2
    sigma21[k]<-parametrosCMRM20[2]+parametrosCMRM20[3]
    *erro2+parametrosCMRM20[4]*sigma21[k-1]
    sigma22[k]<-parametrosCMRM20[5]+parametrosCMRM20[6]
    *erro2+parametrosCMRM20[7]*sigma22[k-1]
  }
}

```

```

matrizEsperancas[k,1]<-((1+(((1-parametrosCMRM20[1]
*dnorm(vetor[k],mu2,sqrt(sigma22[k]))/(parametrosCMRM20[1]
*dnorm(vetor[k],mu1,sqrt(sigma21[k]))))))^(-1))
matrizEsperancas[k,2]<-(1+((parametrosCMRM20[1]*dnorm(vetor[k],mu1
,sqrt(sigma21[k])))/((1-parametrosCMRM20[1])*dnorm(
vetor[k],mu2,sqrt(sigma22[k]))))))^(-1)
}

matrizEsperancas[1,]<-0

#M-STEP
pi1<-mean(matrizEsperancas[,1])
parametrosCMRM20[1]<-pi1
pi2<-mean(matrizEsperancas[,2])
parametrosCMRM20Like<-parametrosCMRM20[2:length(parametrosCMRM20)]
res <- maxSANN(logLikelihoodCMRM20, start=parametrosCMRM20Like,
  constraints=list(ineqA=A, ineqB=B),random.seed = sementes[conta])
parametrosCMRM20[2:length(parametrosCMRM20)]<-res$estimate
  parametrosCMRM20[1]<-pi1
  #Guarda a verossimilhanca
  if(conta==1)
  {
  likeli<-abs(res$maximum)
  }
  else
  {
  erro<-abs(likeli-abs(res$maximum))
  likeli<-abs(res$maximum)
  }
  conta<-conta+1
  }
AIC.CMRM20<-(2*p)-2*likeli
Cov.CMRM20<-(-1)*solve(hessian(res))
STD.CMRM20<-sqrt(diag(Cov.CMRM20))
ESTAT.CMRM20<-res$estimate/STD.CMRM20
PARM.CMRM20<-c(pi1,res$estimate)
PVALOR.CMRM20<-2*pnorm(abs(ESTAT.CMRM20),lower.tail = FALSE)
save.image("CMRM20.RData")

```

A.2.5 Modelo CAPM - PETR4.

```

#Limpa o WorksPace
rm(list = ls(all = TRUE))

```

```

#Define o WorkSpace
setwd("C:/Dropbox/Doutorado/2º Semestre 2011/
Finanças corporativas/Artigo 1/Programas/PETR4")

#Lê os dados das séries financeiras
dados.df<-read.csv("DadosMenor31082011.csv")
names(dados.df)

#Deflacionar o preço da ação, o índice Bovespa e
#a taxa livre de risco (CDI), utilizando o IGP-M.
dados.df[, "LP_PETR4.DEF"]<-dados.df[, "LP_PETR4"]*dados.df[, "INDICE"]
dados.df[, "IBOVESPA.DEF"]<-dados.df[, "IBOVESPA"]*dados.df[, "INDICE"]
dados.df[, "SELIC.DEF"]<-dados.df[, "SELIC"]*dados.df[, "INDICE"]
#dados.df[, "HML.DEF"]<-dados.df[, "HML"]*dados.df[, "INDICE"]
#dados.df[, "SMB.DEF"]<-dados.df[, "SMB"]*dados.df[, "INDICE"]

#Cria as variáveis em forma de retorno
PETR4.ret<-diff(log(dados.df[, "LP_PETR4.DEF"]))*100
IBOVESPA.ret<-diff(log(dados.df[, "IBOVESPA.DEF"]))*100
SELIC.ret<-diff(log(dados.df[, "SELIC.DEF"]))*100
#HML.ret<-diff(log(dados.df[, "HML.DEF"]))*100
#SMB.ret<-diff(log(dados.df[, "SMB.DEF"]))*100
tempo<-seq(1:(length(PETR4.ret)))

#Cria o DataFrame
#retornos.df<-as.data.frame(cbind(tempo,PETR4.ret,IBOVESPA.ret,
SELIC.ret,HML.ret,SMB.ret,dados.df[2:nrow(dados.df), "Election5"],
dados.df[2:nrow(dados.df), "Election10"],dados.df[2:nrow(dados.df),
"Election15"],dados.df[2:nrow(dados.df), "Election20"]))
retornos.df<-as.data.frame(cbind(tempo,PETR4.ret,IBOVESPA.ret,
SELIC.ret,dados.df[2:nrow(dados.df), "Election5"],
dados.df[2:nrow(dados.df), "Election10"],dados.df[2:nrow(dados.df),
"Election15"],dados.df[2:nrow(dados.df), "Election20"]))
#names(retornos.df)<-c("Período","Retorno deflacionadao PETR4",
"Retorno deflacionadao IBOVESPA","Retorno deflacionadao SELIC",
"Retorno deflacionadao HML","Retorno deflacionadao SMB",
"Eleições janela de 5 dias","Eleições janela de 10 dias",
"Eleições janela de 15 dias","Eleições janela de 20 dias")
names(retornos.df)<-c("Período","Retorno deflacionadao PETR4",
"Retorno deflacionadao IBOVESPA","Retorno deflacionadao SELIC",
"Eleições janela de 5 dias","Eleições janela de 10 dias",
"Eleições janela de 15 dias","Eleições janela de 20 dias")

#Interpola linearmente dados faltantes na Bovespa
library(wq)
retornos.df[,3]<- interpTs(retornos.df[,3], gap = 3,type = c("linear"))
retornos.df[,2]<- interpTs(retornos.df[,2], gap = 3,type = c("linear"))
retornos.df[,4]<- interpTs(retornos.df[,4], gap = 3,type = c("linear"))

```

```

#Deixa na forma do CAPM
retornos.df[,2]<-retornos.df[,2]-retornos.df[,4]
retornos.df[,3]<-retornos.df[,3]-retornos.df[,4]

##### CAPM5 #####
source("Funcoes.R")
set.seed<-99855
sementes<-round(10000*runif(10000))
#Número de parametros
p<-11

#Inicializa vetor de chutes parametrosCAPM5(pi,alpha11,alpha12,
#alpha13,alpha21,alpha22,alpha23,mu1,beta1,mu2,beta2)
parametrosCAPM5<-rep(0.1,p)
#parm<-coef(lm(retornos.df[,2]~1+retornos.df[,5]))
#parametrosCAPM5<-c(0.1,0.1,0.1,0.1,0.1,0.1,0.1,parm,parm)

#Vetor de dados
vetor<-retornos.df[,2]
library(maxLik)

#Restrições
A <- diag(p-1)
A<-rbind(A,rep(0,p-1),rep(0,p-1))

A[11,2]=A[11,3]==-1
A[12,5]=A[12,6]==-1

B = matrix(0,nrow(A),1)
B[7]=B[8]=B[9]=B[10]= 1e+15
B[11]=B[12]=1

conta<-1
erro<-100000

while(erro>0.1)
{
#E-STEP
matrizEsperancas<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

  k<-159
for(k in 2:length(vetor))
{
  mul<-parametrosCAPM5[8]*retornos.df[k,5]+

```

```

    parametrosCAPM5[9]*retornos.df[k,3]
    mu2<-parametrosCAPM5[10]*retornos.df[k,5]+
    parametrosCAPM5[11]*retornos.df[k,3]

    erro2<-vetor[k-1]^2
    sigma21[k]<-parametrosCAPM5[2]+parametrosCAPM5[3]*erro2+
    parametrosCAPM5[4]*sigma21[k-1]
    sigma22[k]<-parametrosCAPM5[5]+parametrosCAPM5[6]*erro2+
    parametrosCAPM5[7]*sigma22[k-1]

    d1<-dnorm(vetor[k],mu1,sqrt(sigma21[k]))
    if(d1==0) d1=0.000000001
    d2<-dnorm(vetor[k],mu2,sqrt(sigma22[k]))
    if(d2==0) d2=0.000000001
    matrizEsperancas[k,1]<-((1+((1-parametrosCAPM5[1])*d2)
    /(parametrosCAPM5[1]*d1))^(-1))
    matrizEsperancas[k,2]<-(1+(parametrosCAPM5[1]*d1)
    /((1-parametrosCAPM5[1])*d2))^(-1)
  }

matrizEsperancas[1,]<-0

#M-STEP
pi1<-mean(matrizEsperancas[,1])
parametrosCAPM5[1]<-pi1
pi2<-mean(matrizEsperancas[,2])
parametrosCAPM5Like<-parametrosCAPM5[2:length(parametrosCAPM5)]
res <- maxSANN(logLikelihoodCAPM5, start=parametrosCAPM5Like,
  constraints=list(ineqA=A, ineqB=B),random.seed = sementes[conta])
parametrosCAPM5[2:length(parametrosCAPM5)]<-res$estimate
  parametrosCAPM5[1]<-pi1
  #Guarda a verossimilhanca
  if(conta==1)
  {
    likeli<-abs(res$maximum)
  }
  else
  {
    erro<-abs(likeli-abs(res$maximum))
    likeli<-abs(res$maximum)
  }
  conta<-conta+1
}
AIC.CAPM5<-(2*p)-2*likeli
Cov.CAPM5<-(-1)*solve(hessian(res))
STD.CAPM5<-sqrt(diag(Cov.CAPM5))
ESTAT.CAPM5<-res$estimate/STD.CAPM5
PARM.CAPM5<-c(pi1,res$estimate)

```

```

PVALOR.CAPM5<-2*pnorm(abs(ESTAT.CAPM5),lower.tail = FALSE)
save.image("CAPM5.RData")

##### CAPM10 #####
source("Funcoes.R")
set.seed<-35545
sementes<-round(10000*runif(10000))
#Número de parametros
p<-11

parametrosCAPM10<-rep(0.1,p)

#Inicializa vetor de chutes parametrosCAPM10(pi,alpha11,alpha12,
#alpha13,alpha21,alpha22,alpha23,mu1,beta1,mu2,beta2)
#parm<-coef(lm(retornos.df[,2]~1+retornos.df[,6]))
#parametrosCAPM10<-c(0.1,0.1,0.1,0.1,0.1,0.1,0.1,parm,parm)

#Vetor de dados
vetor<-retornos.df[,2]
library(maxLik)

#Restrições
A <- diag(p-1)
A<-rbind(A,rep(0,p-1),rep(0,p-1))

A[11,2]=A[11,3]==-1
A[12,5]=A[12,6]==-1

B = matrix(0,nrow(A),1)
B[7]=B[8]=B[9]=B[10]= 1e+15
B[11]=B[12]=1

conta<-1
erro<-100000

while(erro>0.1)
{
  #E-STEP
matrizEsperancas<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

for(k in 2:length(vetor))
{
  mu1<-parametrosCAPM10[8]*retornos.df[k,6]+
  parametrosCAPM10[9]*retornos.df[k,3]
  mu2<-parametrosCAPM10[10]*retornos.df[k,6]+

```

```

    parametrosCAPM10[11]*retornos.df[k,3]

erro2<-vetor[k-1]^2
sigma21[k]<-parametrosCAPM10[2]+parametrosCAPM10[3]
*erro2+parametrosCAPM10[4]*sigma21[k-1]
sigma22[k]<-parametrosCAPM10[5]+parametrosCAPM10[6]
*erro2+parametrosCAPM10[7]*sigma22[k-1]

    d1<-dnorm(vetor[k],mu1,sqrt(sigma21[k]))
    if(d1==0) d1=0.000000001
    d2<-dnorm(vetor[k],mu2,sqrt(sigma22[k]))
    if(d2==0) d2=0.000000001
    matrizEsperancas[k,1]<-((1+((1-parametrosCAPM10[1])*d2)
    /(parametrosCAPM10[1]*d1))^(-1))
    matrizEsperancas[k,2]<-(1+((parametrosCAPM10[1]*d1)
    /((1-parametrosCAPM10[1])*d2))^(-1))
}

matrizEsperancas[1,]<-0

#M-STEP
pi1<-mean(matrizEsperancas[,1])
parametrosCAPM10[1]<-pi1
pi2<-mean(matrizEsperancas[,2])
parametrosCAPM10Like<-parametrosCAPM10[2:length(parametrosCAPM10)]
res <- maxSANN(logLikelihoodCAPM10, start=parametrosCAPM10Like,
  constraints=list(ineqA=A, ineqB=B),random.seed =sementes[conta] )
parametrosCAPM10[2:length(parametrosCAPM10)]<-res$estimate
  parametrosCAPM10[1]<-pi1
  #Guarda a verossimilhanca
  if(conta==1)
  {
  likeli<-abs(res$maximum)
  }
  else
  {
  erro<-abs(likeli-abs(res$maximum))
  likeli<-abs(res$maximum)
  }
  conta<-conta+1
  }
AIC.CAPM10<-(2*p)-2*likeli
Cov.CAPM10<-(-1)*solve(hessian(res))
STD.CAPM10<-sqrt(diag(Cov.CAPM10))
ESTAT.CAPM10<-res$estimate/STD.CAPM10
PARM.CAPM10<-c(pi1,res$estimate)
PVALOR.CAPM10<-2*pnorm(abs(ESTAT.CAPM10),lower.tail = FALSE)
save.image("CAPM10.RData")

```

```

##### CAPM15 #####
source("Funcoes.R")
set.seed<-884552
sementes<-round(10000*runif(10000))
#Número de parametros
p<-11

#Inicializa vetor de chutes parametrosCAPM15(pi,alpha1,
alpha12,alpha13,alpha21,alpha22,alpha23,mu1,beta1,mu2,beta2)
#parm<-coef(lm(retornos.df[,2]~1+retornos.df[,7]))
#parametrosCAPM15<-c(0.1,0.1,0.1,0.1,0.1,0.1,0.1,parm,parm)
parametrosCAPM15<-rep(0.1,p)

#Vetor de dados
vetor<-retornos.df[,2]
library(maxLik)

#Restrições
A <- diag(p-1)
A<-rbind(A, rep(0,p-1), rep(0,p-1))

A[11,2]=A[11,3]=-1
A[12,5]=A[12,6]=-1

B = matrix(0,nrow(A),1)
B[7]=B[8]=B[9]=B[10]= 1e+15
B[11]=B[12]=1

conta<-1
erro<-100000

while(erro>0.1)
{
  #E-STEP
  matrizEsperancas<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

  for(k in 2:length(vetor))
  {
    mu1<-parametrosCAPM15[8]*retornos.df[k,7]+
    parametrosCAPM15[9]*retornos.df[k,3]
    mu2<-parametrosCAPM15[10]*retornos.df[k,7]+
    parametrosCAPM15[11]*retornos.df[k,3]

    erro2<-vetor[k-1]^2
  }
}

```

```

sigma21[k]<-parametrosCAPM15[2]+parametrosCAPM15[3]*
erro2+parametrosCAPM15[4]*sigma21[k-1]
sigma22[k]<-parametrosCAPM15[5]+parametrosCAPM15[6]*
erro2+parametrosCAPM15[7]*sigma22[k-1]

d1<-dnorm(vetor[k],mu1,sqrt(sigma21[k]))
if(d1==0) d1=0.000000001
d2<-dnorm(vetor[k],mu2,sqrt(sigma22[k]))
if(d2==0) d2=0.000000001
matrizEsperancas[k,1]<-((1+(((1-parametrosCAPM15[1])*d2)
/(parametrosCAPM15[1]*d1))^-1))
matrizEsperancas[k,2]<-(1+((parametrosCAPM15[1]*d1)
/((1-parametrosCAPM15[1])*d2))^-1)
}

matrizEsperancas[1,]<-0

#M-STEP
pi1<-mean(matrizEsperancas[,1])
parametrosCAPM15[1]<-pi1
pi2<-mean(matrizEsperancas[,2])
parametrosCAPM15Like<-parametrosCAPM15[2:length(parametrosCAPM15)]
res <- maxSANN(logLikelihoodCAPM15, start=parametrosCAPM15Like,
constraints=list(ineqA=A, ineqB=B),random.seed = sementes[conta])
parametrosCAPM15[2:length(parametrosCAPM15)]<-res$estimate
parametrosCAPM15[1]<-pi1
#Guarda a verossimilhanca
if(conta==1)
{
likeli<-abs(res$maximum)
}
else
{
erro<-abs(likeli-abs(res$maximum))
likeli<-abs(res$maximum)
}
conta<-conta+1
}
AIC.CAPM15<-(2*p)-2*likeli
Cov.CAPM15<-(-1)*solve(hessian(res))
STD.CAPM15<-sqrt(diag(Cov.CAPM15))
ESTAT.CAPM15<-res$estimate/STD.CAPM15
PARM.CAPM15<-c(pi1,res$estimate)
PVALOR.CAPM15<-2*pnorm(abs(ESTAT.CAPM15),lower.tail = FALSE)
save.image("CAPM15.RData")

##### CAPM20 #####

```

```

source("Funcoes.R")
set.seed<-33655459
sementes<-round(10000*runif(10000))
#Número de parametros
p<-11

#Inicializa vetor de chutes parametrosCAPM20(pi,alpha11,alpha12,
#alpha13,alpha21,alpha22,alpha23,mu1,beta1,mu2,beta2)
parametrosCAPM20<-rep(0.1,p)
#Vetor de dados
vetor<-retornos.df[,2]
library(maxLik)

#Restrições
A <- diag(p-1)
A<-rbind(A,rep(0,p-1),rep(0,p-1))

A[11,2]=A[11,3]==-1
A[12,5]=A[12,6]==-1

B = matrix(0,nrow(A),1)
B[7]=B[8]=B[9]=B[10]= 1e+15
B[11]=B[12]=1

conta<-1
erro<-100000

while(erro>0.1)
{
  #E-STEP
  matrizEsperancas<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

  for(k in 2:length(vetor))
  {
    mu1<-parametrosCAPM20[8]*retornos.df[k,8]+
    parametrosCAPM20[9]*retornos.df[k,3]
    mu2<-parametrosCAPM20[10]*retornos.df[k,8]+
    parametrosCAPM20[11]*retornos.df[k,3]

    erro2<-vetor[k-1]^2
    sigma21[k]<-parametrosCAPM20[2]+parametrosCAPM20[3]*erro2
    +parametrosCAPM20[4]*sigma21[k-1]
    sigma22[k]<-parametrosCAPM20[5]+parametrosCAPM20[6]*erro2
    +parametrosCAPM20[7]*sigma22[k-1]

    dl<-dnorm(vetor[k],mu1,sqrt(sigma21[k]))
  }
}

```

```

        if(d1==0) d1=0.000000001
        d2<-dnorm(vetor[k],mu2,sqrt(sigma22[k]))
        if(d2==0) d2=0.000000001
        matrizEsperancas[k,1]<-((1+((1-parametrosCAPM20[1])*d2)
        /(parametrosCAPM20[1]*d1))^(-1))
        matrizEsperancas[k,2]<-(1+((parametrosCAPM20[1]*d1)
        /((1-parametrosCAPM20[1])*d2))^(-1))
    }

matrizEsperancas[1,]<-0

#M-STEP
pi1<-mean(matrizEsperancas[,1])
parametrosCAPM20[1]<-pi1
pi2<-mean(matrizEsperancas[,2])
parametrosCAPM20Like<-parametrosCAPM20[2:length(parametrosCAPM20)]
res <- maxSANN(logLikelihoodCAPM20, start=parametrosCAPM20Like,
  constraints=list(ineqA=A, ineqB=B),random.seed = sementes[conta])
parametrosCAPM20[2:length(parametrosCAPM20)]<-res$estimate
  parametrosCAPM20[1]<-pi1
  #Guarda a verossimilhanca
  if(conta==1)
  {
  likeli<-abs(res$maximum)
  }
  else
  {
  erro<-abs(likeli-abs(res$maximum))
  likeli<-abs(res$maximum)
  }
  conta<-conta+1
  }
AIC.CAPM20<-(2*p)-2*likeli
Cov.CAPM20<-(-1)*solve(hessian(res))
STD.CAPM20<-sqrt(diag(Cov.CAPM20))
ESTAT.CAPM20<-res$estimate/STD.CAPM20
PARM.CAPM20<-c(pi1,res$estimate)
PVALOR.CAPM20<-2*pnorm(abs(ESTAT.CAPM20),lower.tail = FALSE)
save.image("CAPM20.RData")

```

A.2.6 Modelo MM - PETR4.

```

#Limpa o WorksPace
rm(list = ls(all = TRUE))

```

```

#Define o WorkSpace
setwd("C:/Dropbox/Doutorado/2º Semestre 2011/
Finanças corporativas/Artigo 1/Programas/PETR4")

#Lê os dados das séries financeiras
dados.df<-read.csv("DadosMenor31082011.csv")
names(dados.df)

#Deflacionar o preço da ação, o índice Bovespa
#e a taxa livre de risco (CDI), utilizando o IGP-M.
dados.df[, "LP_PETR4.DEF"]<-dados.df[, "LP_PETR4"]*dados.df[, "INDICE"]
dados.df[, "IBOVESPA.DEF"]<-dados.df[, "IBOVESPA"]*dados.df[, "INDICE"]
dados.df[, "SELIC.DEF"]<-dados.df[, "SELIC"]*dados.df[, "INDICE"]
#dados.df[, "HML.DEF"]<-dados.df[, "HML"]*dados.df[, "INDICE"]
#dados.df[, "SMB.DEF"]<-dados.df[, "SMB"]*dados.df[, "INDICE"]

#Cria as variáveis em forma de retorno
PETR4.ret<-diff(log(dados.df[, "LP_PETR4.DEF"]))*100
IBOVESPA.ret<-diff(log(dados.df[, "IBOVESPA.DEF"]))*100
SELIC.ret<-diff(log(dados.df[, "SELIC.DEF"]))*100
#HML.ret<-diff(log(dados.df[, "HML.DEF"]))*100
#SMB.ret<-diff(log(dados.df[, "SMB.DEF"]))*100
tempo<-seq(1:(length(PETR4.ret)))

#Cria o DataFrame
#retornos.df<-as.data.frame(cbind(tempo,PETR4.ret,IBOVESPA.ret
,SELIC.ret,HML.ret,SMB.ret,dados.df[2:nrow(dados.df),"Election5"]
,dados.df[2:nrow(dados.df),"Election10"],dados.df[2:nrow(dados.df)
,"Election15"],dados.df[2:nrow(dados.df),"Election20"]))
retornos.df<-as.data.frame(cbind(tempo,PETR4.ret,IBOVESPA.ret
,SELIC.ret,dados.df[2:nrow(dados.df),"Election5"],
dados.df[2:nrow(dados.df),"Election10"],dados.df[2:nrow(dados.df)
,"Election15"],dados.df[2:nrow(dados.df),"Election20"]))
#names(retornos.df)<-c("Período","Retorno deflacionadao PETR4",
"Retorno deflacionadao IBOVESPA","Retorno deflacionadao SELIC",
"Retorno deflacionadao HML","Retorno deflacionadao SMB",
"Eleições janela de 5 dias","Eleições janela de 10 dias",
"Eleições janela de 15 dias","Eleições janela de 20 dias")
names(retornos.df)<-c("Período","Retorno deflacionadao PETR4",
"Retorno deflacionadao IBOVESPA","Retorno deflacionadao SELIC",
"Eleições janela de 5 dias","Eleições janela de 10 dias",
"Eleições janela de 15 dias","Eleições janela de 20 dias")

library(wq)
#Interpola linearmente dados faltantes na Bovespa
retornos.df[,3]<- interpTs(retornos.df[,3], gap = 3,type = c("linear"))

##### MM5 #####

```

```

source("Funcoes.R")
set.seed<-855
sementes<-round(10000*runif(10000))
#Número de parametros
p<-13

#Inicializa vetor de chutes parametrosMM5(pi, alpha11,
#alpha12, alpha13, alpha21, alpha22, alpha23, mu1, gamma1,
#beta1, mu2, gamma2, beta2)
parametrosMM5<-rep(0.1, p)
#parm<-coef(lm(retornos.df[,2]~1+retornos.df[,5]))
#parametrosMM5<-c(0.1,0.1,0.1,0.1,0.1,0.1,0.1,parm,parm)

#Vetor de dados
vetor<-retornos.df[,2]
library(maxLik)

#Restrições
A <- diag(p-1)
A<-rbind(A, rep(0, p-1), rep(0, p-1))

A[13,2]=A[13,3]=-1
A[14,5]=A[14,6]=-1

B = matrix(0, nrow(A), 1)
B[7]=B[8]=B[9]=B[10]=B[11]=B[12]= 1e+15
B[13]=B[14]=1

conta<-1
erro<-100000

while(erro>0.1)
{
#E-STEP
matrizEsperancas<-matrix(0, length(vetor), 2)
  sigma21<-rep(1, length(vetor))
  sigma22<-rep(1, length(vetor))

for(k in 2:length(vetor))
{
  mu1<-parametrosMM5[8]+parametrosMM5[9]*retornos.df[k,5]
  +parametrosMM5[10]*retornos.df[k,3]
  mu2<-parametrosMM5[11]+parametrosMM5[12]*retornos.df[k,5]
  +parametrosMM5[13]*retornos.df[k,3]

  erro2<-vetor[k-1]^2
  sigma21[k]<-parametrosMM5[2]+parametrosMM5[3]*erro2
  +parametrosMM5[4]*sigma21[k-1]

```

```

sigma22[k]<-parametrosMM5[5]+parametrosMM5[6]*erro2
+parametrosMM5[7]*sigma22[k-1]

matrizEsperancas[k,1]<-((1+(((1-parametrosMM5[1])*dnorm(vetor[k],
mu2,sqrt(sigma22[k])))/(parametrosMM5[1]*dnorm(vetor[k],
mu1,sqrt(sigma21[k]))))))^(-1))
matrizEsperancas[k,2]<-(1+((parametrosMM5[1]*dnorm(vetor[k],
mu1,sqrt(sigma21[k])))/((1-parametrosMM5[1])*dnorm(vetor[k],
mu2,sqrt(sigma22[k]))))))^(-1)
}

matrizEsperancas[1,]<-0

#M-STEP
pi1<-mean(matrizEsperancas[,1])
parametrosMM5[1]<-pi1
pi2<-mean(matrizEsperancas[,2])
parametrosMM5Like<-parametrosMM5[2:length(parametrosMM5)]
res <- maxSANN(logLikelihoodMM5, start=parametrosMM5Like,
constraints=list(ineqA=A, ineqB=B),random.seed = sementes[conta])
parametrosMM5[2:length(parametrosMM5)]<-res$estimate
parametrosMM5[1]<-pi1
#Guarda a verossimilhanca
if(conta==1)
{
likeli<-abs(res$maximum)
}
else
{
erro<-abs(likeli-abs(res$maximum))
likeli<-abs(res$maximum)
}
conta<-conta+1
}
AIC.MM5<-(2*p)-2*likeli
Cov.MM5<-(-1)*solve(hessian(res))
STD.MM5<-sqrt(diag(Cov.MM5))
ESTAT.MM5<-res$estimate/STD.MM5
PARM.MM5<-c(pi1,res$estimate)
PVALOR.MM5<-2*pnorm(abs(ESTAT.MM5),lower.tail = FALSE)
save.image("MM5.RData")

##### MM10 #####
source("Funcoes.R")
set.seed<-3254
sementes<-round(10000*runif(10000))
#Número de parametros
p<-13

```

```

parametrosMM10<-rep(0.1,p)

#Inicializa vetor de chutes parametrosMM10(pi,alpha11,alpha12,alpha13,alpha21,
#alpha22,alpha23,mu1,gamma1,beta1,mu2,gamma2,beta2)
#parm<-coef(lm(retornos.df[,2]~1+retornos.df[,6]))
#parametrosMM10<-c(0.1,0.1,0.1,0.1,0.1,0.1,0.1,parm,parm)

#Vetor de dados
vetor<-retornos.df[,2]
library(maxLik)

#Restrições
A <- diag(p-1)
A<-rbind(A,rep(0,p-1),rep(0,p-1))

A[13,2]=A[13,3]==-1
A[14,5]=A[14,6]==-1

B = matrix(0,nrow(A),1)
B[7]=B[8]=B[9]=B[10]=B[11]=B[12]= 1e+15
B[13]=B[14]=1

conta<-1
erro<-100000

while(erro>0.1)
{
  #E-STEP
matrizEsperancas<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

for(k in 2:length(vetor))
{
  mu1<-parametrosMM10[8]+parametrosMM10[9]*retornos.df[k,6]
  +parametrosMM10[10]*retornos.df[k,3]
  mu2<-parametrosMM10[11]+parametrosMM10[12]*retornos.df[k,6]
  +parametrosMM10[13]*retornos.df[k,3]

  erro2<-vetor[k-1]^2
  sigma21[k]<-parametrosMM10[2]+parametrosMM10[3]*erro2
  +parametrosMM10[4]*sigma21[k-1]
  sigma22[k]<-parametrosMM10[5]+parametrosMM10[6]*erro2
  +parametrosMM10[7]*sigma22[k-1]

  matrizEsperancas[k,1]<-((1+(((1-parametrosMM10[1])*dnorm(vetor[k],

```

```

    mu2,sqrt(sigma22[k]))/(parametrosMM10[1]*dnorm(vetor[k],mu1,
    sqrt(sigma21[k]))))^(-1))
    matrizEsperancas[k,2]<-(1+((parametrosMM10[1]*dnorm(vetor[k],mu1,
    sqrt(sigma21[k])))/(1-parametrosMM10[1])*dnorm(vetor[k],
    mu2,sqrt(sigma22[k]))))^(-1))
  }

matrizEsperancas[1,]<-0

#M-STEP
pi1<-mean(matrizEsperancas[,1])
parametrosMM10[1]<-pi1
pi2<-mean(matrizEsperancas[,2])
parametrosMM10Like<-parametrosMM10[2:length(parametrosMM10)]
res <- maxSANN(logLikelihoodMM10, start=parametrosMM10Like,
  constraints=list(ineqA=A, ineqB=B),random.seed =sementes[conta] )
parametrosMM10[2:length(parametrosMM10)]<-res$estimate
  parametrosMM10[1]<-pi1
  #Guarda a verossimilhanca
if(conta==1)
{
likeli<-abs(res$maximum)
}
else
{
erro<-abs(likeli-abs(res$maximum))
likeli<-abs(res$maximum)
}
conta<-conta+1
}
AIC.MM10<-(2*p)-2*likeli
Cov.MM10<-(-1)*solve(hessian(res))
STD.MM10<-sqrt(diag(Cov.MM10))
ESTAT.MM10<-res$estimate/STD.MM10
PARM.MM10<-c(pi1,res$estimate)
PVALOR.MM10<-2*pnorm(abs(ESTAT.MM10),lower.tail = FALSE)
save.image("MM10.RData")

##### MM15 #####
source("Funcoes.R")
set.seed<-68752
sementes<-round(10000*runif(10000))
#Número de parametros
p<-13

#Inicializa vetor de chutes parametrosMM15(pi,alpha11,
alpha12,alpha13,alpha21,
alpha22,alpha23,mu1,gamma1,beta1,mu2,gamma2,beta2)

```

```

#parm<-coef(lm(retornos.df[,2]~1+retornos.df[,7]))
#parametrosMM15<-c(0.1,0.1,0.1,0.1,0.1,0.1,0.1,parm,parm)
parametrosMM15<-rep(0.1,p)

#Vetor de dados
vetor<-retornos.df[,2]
library(maxLik)

#Restrições
A <- diag(p-1)
A<-rbind(A,rep(0,p-1),rep(0,p-1))

A[13,2]=A[13,3]==-1
A[14,5]=A[14,6]==-1

B = matrix(0,nrow(A),1)
B[7]=B[8]=B[9]=B[10]=B[11]=B[12]= 1e+15
B[13]=B[14]=1

conta<-1
erro<-100000

while(erro>0.1)
{
  #E-STEP
  matrizEsperancas<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

  for(k in 2:length(vetor))
  {
    mu1<-parametrosMM15[8]+parametrosMM15[9]*retornos.df[k,7]
    +parametrosMM15[10]*retornos.df[k,3]
    mu2<-parametrosMM15[11]+parametrosMM15[12]*retornos.df[k,7]
    +parametrosMM15[13]*retornos.df[k,3]

    erro2<-vetor[k-1]^2
    sigma21[k]<-parametrosMM15[2]+parametrosMM15[3]*erro2
    +parametrosMM15[4]*sigma21[k-1]
    sigma22[k]<-parametrosMM15[5]+parametrosMM15[6]*erro2
    +parametrosMM15[7]*sigma22[k-1]

    matrizEsperancas[k,1]<-((1+(((1-parametrosMM15[1])*dnorm(vetor[k],
mu2,sqrt(sigma22[k])))/(parametrosMM15[1]*dnorm(vetor[k],
mu1,sqrt(sigma21[k]))))))^(-1))
    matrizEsperancas[k,2]<-(1+((parametrosMM15[1]*dnorm(vetor[k],mu1,
sqrt(sigma21[k])))/(1-parametrosMM15[1])*dnorm(vetor[k],
mu2,sqrt(sigma22[k]))))))^(-1)
  }
}

```

```

}

matrizEsperancas[1,]<-0

#M-STEP
pi1<-mean(matrizEsperancas[,1])
parametrosMM15[1]<-pi1
pi2<-mean(matrizEsperancas[,2])
parametrosMM15Like<-parametrosMM15[2:length(parametrosMM15)]
res <- maxSANN(logLikelihoodMM15, start=parametrosMM15Like,
  constraints=list(ineqA=A, ineqB=B),random.seed = sementes[conta])
parametrosMM15[2:length(parametrosMM15)]<-res$estimate
  parametrosMM15[1]<-pi1
  #Guarda a verossimilhanca
if(conta==1)
{
likeli<-abs(res$maximum)
}
else
{
erro<-abs(likeli-abs(res$maximum))
likeli<-abs(res$maximum)
}
conta<-conta+1
}
AIC.MM15<-(2*p)-2*likeli
Cov.MM15<-(-1)*solve(hessian(res))
STD.MM15<-sqrt(diag(Cov.MM15))
ESTAT.MM15<-res$estimate/STD.MM15
PARM.MM15<-c(pi1,res$estimate)
PVALOR.MM15<-2*pnorm(abs(ESTAT.MM15),lower.tail = FALSE)
save.image("MM15.RData")

##### MM20 #####
source("Funcoes.R")
set.seed<-852258
sementes<-round(10000*runif(10000))
#Número de parametros
p<-13

#Inicializa vetor de chutes parametrosMM20(pi,alpha11,
#alpha12,alpha13,alpha21,
#alpha22,alpha23,mu1,gamma1,beta1,mu2,gamma2,beta2)
#parametrosMM20<-rep(0.1,p)

parametrosMM20<-rep(0.1,p)
#Vetor de dados

```

```

vetor<-retornos.df[,2]
library(maxLik)

#Restrições
A <- diag(p-1)
A<-rbind(A, rep(0, p-1), rep(0, p-1))

A[13,2]=A[13,3]=-1
A[14,5]=A[14,6]=-1

B = matrix(0,nrow(A),1)
B[7]=B[8]=B[9]=B[10]=B[11]=B[12]= 1e+15
B[13]=B[14]=1

conta<-1
erro<-100000

while(erro>0.1)
{
  #E-STEP
  matrizEsperancas<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

  for(k in 2:length(vetor))
  {
    mu1<-parametrosMM20[8]+parametrosMM20[9]*retornos.df[k,8]
    +parametrosMM20[10]*retornos.df[k,3]
    mu2<-parametrosMM20[11]+parametrosMM20[12]*retornos.df[k,8]
    +parametrosMM20[13]*retornos.df[k,3]

    erro2<-vetor[k-1]^2
    sigma21[k]<-parametrosMM20[2]+parametrosMM20[3]*erro2
    +parametrosMM20[4]*sigma21[k-1]
    sigma22[k]<-parametrosMM20[5]+parametrosMM20[6]*erro2
    +parametrosMM20[7]*sigma22[k-1]

    matrizEsperancas[k,1]<-((1+(((1-parametrosMM20[1])*dnorm(vetor[k],
mu2,sqrt(sigma22[k])))/(parametrosMM20[1]*dnorm(vetor[k],
mu1,sqrt(sigma21[k]))))))^(-1))
    matrizEsperancas[k,2]<-(1+((parametrosMM20[1]*dnorm(vetor[k],mu1,
sqrt(sigma21[k])))/(1-parametrosMM20[1])*dnorm(vetor[k],
mu2,sqrt(sigma22[k]))))))^(-1)
  }

  matrizEsperancas[1,]<-0

  #M-STEP

```

```

pi1<-mean(matrizEsperancas[,1])
parametrosMM20[1]<-pi1
pi2<-mean(matrizEsperancas[,2])
parametrosMM20Like<-parametrosMM20[2:length(parametrosMM20)]
res <- maxSANN(logLikelihoodMM20, start=parametrosMM20Like,
constraints=list(ineqA=A, ineqB=B),random.seed = sementes[conta])
parametrosMM20[2:length(parametrosMM20)]<-res$estimate
  parametrosMM20[1]<-pi1
  #Guarda a verossimilhanca
if(conta==1)
{
likeli<-abs(res$maximum)
}
else
{
erro<-abs(likeli-abs(res$maximum))
likeli<-abs(res$maximum)
}
conta<-conta+1
}
AIC.MM20<-(2*p)-2*likeli
Cov.MM20<-(-1)*solve(hessian(res))
STD.MM20<-sqrt(diag(Cov.MM20))
ESTAT.MM20<-res$estimate/STD.MM20
PARM.MM20<-c(pi1,res$estimate)
PVALOR.MM20<-2*pnorm(abs(ESTAT.MM20),lower.tail = FALSE)
save.image("MM20.RData")

```

A.3 Programa 3.

Esse programa foi utilizado para estimar os modelos do ensaio relativo a seção 5.2. Com o intuito de poupar espaço, apenas o programa do ativo ALLL3 é apresentado. Os demais programas seguem a mesma estrutura exceto pela base de dados a qual é diferente para cada organização.

```

#####
#####          PARTE 1/4          #####
#####
#####

#Limpa o WorksPace
rm(list = ls(all = TRUE))

#Define o WorkSPace

```

```

setwd("C:/Users/Administrador/Desktop/Pedro/Bases")

#Nome da planilha
nome<-c("ALLL3 BS Equity")

file<-paste(nome, ".csv", sep="")
dados.df <- read.csv(file)
names(dados.df)

#Cria as variáveis em forma de retorno
PRECO.ret<-diff(log(dados.df[, "PX_LAST"]))*100
SELIC.ret<-diff(log(dados.df[, "SELIC"]))*100
IBOVESPA.ret<-diff(log(dados.df[, "IBOV"]))*100
DVD.ret<-dados.df[2:nrow(dados.df), "EQY_DVD_NET"]
tempo<-seq(1:(length(PRECO.ret)))

#Cria o DataFrame
retornos.df<-as.data.frame(cbind(tempo,PRECO.ret,
IBOVESPA.ret,SELIC.ret,DVD.ret))
names(retornos.df)<-c("Date", nome, "Ibovespa", "Selic",
"Dividend Indicated Yld")
names(retornos.df)
#Modelo CMRM5
source("Funcoes.R")
set.seed<-54648
sementes<-round(10000*runif(10000))
#Número de parametros
p<-11

#Inicializa vetor de chutes parametrosCMRM5(pi, alpha11,
alpha12, alpha13, alpha21, alpha22, alpha23, mu1, gamma1, mu2, gamma2)
parametrosCMRM5<-rep(0.1, p)

#Vetor de dados
vetor<-retornos.df[,2]
library(maxLik)

#Restrições
A <- diag(p-1)
A<-rbind(A, rep(0, p-1), rep(0, p-1))

A[11,2]=A[11,3]==-1
A[12,5]=A[12,6]==-1

B = matrix(0, nrow(A), 1)
B[7]=B[8]=B[9]=B[10]= 1e+15
B[11]=B[12]=1

```

```

conta<-1
erro<-100000

while(erro>0.1)
{
  #E-STEP
matrizEsperancas<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

for(k in 2:length(vetor))
{
  mu1<-parametrosCMRM5[8]+parametrosCMRM5[9]*
  retornos.df[k,5]
  mu2<-parametrosCMRM5[10]+parametrosCMRM5[11]*
  retornos.df[k,5]

  erro2<-vetor[k-1]^2
  sigma21[k]<-parametrosCMRM5[2]+parametrosCMRM5[3]
  *erro2+parametrosCMRM5[4]*sigma21[k-1]
  sigma22[k]<-parametrosCMRM5[5]+parametrosCMRM5[6]
  *erro2+parametrosCMRM5[7]*sigma22[k-1]

  d1<-dnorm(vetor[k],mu1,sqrt(sigma21[k]))
  if(d1==0) d1=0.000000001
  d2<-dnorm(vetor[k],mu2,sqrt(sigma22[k]))
  if(d2==0) d2=0.000000001

  matrizEsperancas[k,1]<-((1+((1-parametrosCMRM5[1])
  *d2)/(parametrosCMRM5[1]*d1))^(-1))
  matrizEsperancas[k,2]<-(1+((parametrosCMRM5[1]
  *d1)/((1-parametrosCMRM5[1])*d2))^(-1))
}

matrizEsperancas[1,]<-0

#M-STEP
pi1<-mean(matrizEsperancas[,1])
parametrosCMRM5[1]<-pi1
pi2<-mean(matrizEsperancas[,2])
parametrosCMRM5Like<-parametrosCMRM5[2:length(parametrosCMRM5)]
res <- maxSANN(logLikelihoodCMRM5, start=parametrosCMRM5Like,
  constraints=list(ineqA=A, ineqB=B),random.seed = sementes[conta])
parametrosCMRM5[2:length(parametrosCMRM5)]<-res$estimate
  parametrosCMRM5[1]<-pi1
  #Guarda a verossimilhanca
if(conta==1)
{

```

```

likeli<-abs(res$maximum)
}
else
{
erro<-abs(likeli-abs(res$maximum))
likeli<-abs(res$maximum)
}
conta<-conta+1
}
AIC.CMRM<-(2*p)-2*likeli
Cov.CMRM<-(-1)*solve(hessian(res))
STD.CMRM<-sqrt(diag(Cov.CMRM))
ESTAT.CMRM<-res$estimate/STD.CMRM
PARM.CMRM<-c(pi1,res$estimate)
PVALOR.CMRM<-2*pnorm(abs(ESTAT.CMRM),lower.tail = FALSE)

##### CAPM
#Interpola linearmente dados faltantes na Bovespa
library(wq)
retornos.df[,3]<- interpTs(retornos.df[,3], gap = 3,type = c("linear"))
retornos.df[,2]<- interpTs(retornos.df[,2], gap = 3,type = c("linear"))
retornos.df[,4]<- interpTs(retornos.df[,4], gap = 3,type = c("linear"))

#Deixa na forma do CAPM
retornos.df[,2]<-retornos.df[,2]-retornos.df[,4]
retornos.df[,3]<-retornos.df[,3]-retornos.df[,4]

source("Funcoes.R")
set.seed<-99855
sementes<-round(10000*runif(10000))
#Número de parametros
p<-11

#Inicializa vetor de chutes parametrosCAPM5(pi,alpha11,alpha12,
alpha13,alpha21,alpha22,alpha23,mu1,beta1,mu2,beta2)
parametrosCAPM5<-rep(0.1,p)
#parm<-coef(lm(retornos.df[,2]~1+retornos.df[,5]))
#parametrosCAPM5<-c(0.1,0.1,0.1,0.1,0.1,0.1,0.1,parm,parm)

#Vetor de dados
vetor<-retornos.df[,2]
library(maxLik)

#Restrições
A <- diag(p-1)
A<-rbind(A, rep(0,p-1), rep(0,p-1))

```

```

A[11,2]=A[11,3]=-1
A[12,5]=A[12,6]=-1

B = matrix(0,nrow(A),1)
B[7]=B[8]=B[9]=B[10]= 1e+15
B[11]=B[12]=1

conta<-1
erro<-100000

while(erro>0.1)
{
  #E-STEP
  matrizEsperancas<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

  k<-159
  for(k in 2:length(vetor))
  {
    mu1<-parametrosCAPM5[8]*retornos.df[k,5]+
    parametrosCAPM5[9]*retornos.df[k,3]
    mu2<-parametrosCAPM5[10]*retornos.df[k,5]+
    parametrosCAPM5[11]*retornos.df[k,3]

    erro2<-vetor[k-1]^2
    sigma21[k]<-parametrosCAPM5[2]+parametrosCAPM5[3]*
    erro2+parametrosCAPM5[4]*sigma21[k-1]
    sigma22[k]<-parametrosCAPM5[5]+parametrosCAPM5[6]*
    erro2+parametrosCAPM5[7]*sigma22[k-1]

    d1<-dnorm(vetor[k],mu1,sqrt(sigma21[k]))
    if(d1==0) d1=0.000000001
    d2<-dnorm(vetor[k],mu2,sqrt(sigma22[k]))
    if(d2==0) d2=0.000000001
    matrizEsperancas[k,1]<-((1+((1-parametrosCAPM5[1])*d2)
    / (parametrosCAPM5[1]*d1))^(-1))
    matrizEsperancas[k,2]<-(1+((parametrosCAPM5[1]*d1)
    / ((1-parametrosCAPM5[1])*d2))^(-1))
  }

  matrizEsperancas[1,]<-0

  #M-STEP
  pi1<-mean(matrizEsperancas[,1])
  parametrosCAPM5[1]<-pi1
  pi2<-mean(matrizEsperancas[,2])
  parametrosCAPM5Like<-parametrosCAPM5[2:length(parametrosCAPM5)]

```

```

res <- maxSANN(logLikelihoodCAPM5, start=parametrosCAPM5Like,
  constraints=list(ineqA=A, ineqB=B), random.seed = sementes[conta])
parametrosCAPM5[2:length(parametrosCAPM5)]<-res$estimate
  parametrosCAPM5[1]<-pi1
  #Guarda a verossimilhanca
if(conta==1)
{
likeli<-abs(res$maximum)
}
else
{
erro<-abs(likeli-abs(res$maximum))
likeli<-abs(res$maximum)
}
conta<-conta+1
}
AIC.CAPM<-(2*p)-2*likeli
Cov.CAPM<-(-1)*solve(hessian(res))
STD.CAPM<-sqrt(diag(Cov.CAPM))
ESTAT.CAPM<-res$estimate/STD.CAPM
PARM.CAPM<-c(pi1, res$estimate)
PVALOR.CAPM<-2*pnorm(abs(ESTAT.CAPM), lower.tail = FALSE)

##### MM
library(wq)
#Interpola linearmente dados faltantes na Bovespa
retornos.df[,3]<- interpTs(retornos.df[,3], gap = 3, type = c("linear"))

source("Funcoes.R")
set.seed<-855
sementes<-round(10000*runif(10000))
#Número de parametros
p<-13

#Inicializa vetor de chutes parametrosMM5(pi, alpha11, alpha12, alpha13,
alpha21, alpha22, alpha23, mu1, gamma1, beta1, mu2, gamma2, beta2)
parametrosMM5<-rep(0.1, p)

#Vetor de dados
vetor<-retornos.df[,2]
library(maxLik)

#Restrições
A <- diag(p-1)
A<-rbind(A, rep(0, p-1), rep(0, p-1))

A[13,2]=A[13,3]==-1
A[14,5]=A[14,6]==-1

```

```

B = matrix(0,nrow(A),1)
B[7]=B[8]=B[9]=B[10]=B[11]=B[12]= 1e+15
B[13]=B[14]=1

conta<-1
erro<-100000

while(erro>0.1)
{
  #E-STEP
matrizEsperancas<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

for(k in 2:length(vetor))
{
  mu1<-parametrosMM5[8]+parametrosMM5[9]*retornos.df[k,5]
  +parametrosMM5[10]*retornos.df[k,3]
  mu2<-parametrosMM5[11]+parametrosMM5[12]*retornos.df[k,5]
  +parametrosMM5[13]*retornos.df[k,3]

  erro2<-vetor[k-1]^2
  sigma21[k]<-parametrosMM5[2]+parametrosMM5[3]*erro2
  +parametrosMM5[4]*sigma21[k-1]
  sigma22[k]<-parametrosMM5[5]+parametrosMM5[6]*erro2
  +parametrosMM5[7]*sigma22[k-1]

  matrizEsperancas[k,1]<-((1+((1-parametrosMM5[1])*dnorm(vetor[k],mu2,
sqrt(sigma22[k])))/(parametrosMM5[1]*dnorm(vetor[k],mu1,
sqrt(sigma21[k]))))^(-1))
  matrizEsperancas[k,2]<-(1+((parametrosMM5[1]*dnorm(vetor[k],mu1,
sqrt(sigma21[k])))/(1-parametrosMM5[1])*dnorm(vetor[k],
mu2,sqrt(sigma22[k]))))^(-1))
}

matrizEsperancas[1,]<-0

#M-STEP
pi1<-mean(matrizEsperancas[,1])
parametrosMM5[1]<-pi1
pi2<-mean(matrizEsperancas[,2])
parametrosMM5Like<-parametrosMM5[2:length(parametrosMM5)]
res <- maxSANN(logLikelihoodMM5, start=parametrosMM5Like,
constraints=list(ineqA=A, ineqB=B),random.seed = sementes[conta])
parametrosMM5[2:length(parametrosMM5)]<-res$estimate
  parametrosMM5[1]<-pi1
  #Guarda a verossimilhanca

```

```

if (conta==1)
{
likeli<-abs(res$maximum)
}
else
{
erro<-abs(likeli-abs(res$maximum))
likeli<-abs(res$maximum)
}
conta<-conta+1
}
AIC.MM<-(2*p)-2*likeli
Cov.MM<-(-1)*solve(hessian(res))
STD.MM<-sqrt(diag(Cov.MM))
ESTAT.MM<-res$estimate/STD.MM
PARM.MM<-c(pil,res$estimate)
PVALOR.MM<-2*pnorm(abs(ESTAT.MM5),lower.tail = FALSE)

salva<-paste(nome, ".RData", sep="")
save.image(salva)

#####
#####          PARTE 2/4          #####
#####

#Limpa o WorksSpace
rm(list = ls(all = TRUE))

#Define o WorkSpace
setwd("C:/Users/Administrador/Desktop/Pedro/Bases")

#Nome da planilha
nome<-c("AMBV4 BS Equity")

file<-paste(nome, ".csv", sep="")
dados.df <- read.csv(file)
names(dados.df)

#Cria as variáveis em forma de retorno
PRECO.ret<-diff(log(dados.df[, "PX_LAST"]))*100
SELIC.ret<-diff(log(dados.df[, "SELIC"]))*100
IBOVESPA.ret<-diff(log(dados.df[, "IBOV"]))*100
DVD.ret<-dados.df[2:nrow(dados.df), "EQY_DVD_NET"]
tempo<-seq(1:(length(PRECO.ret)))

#Cria o DataFrame
retornos.df<-as.data.frame(cbind(tempo,PRECO.ret,
IBOVESPA.ret,SELIC.ret,DVD.ret))

```

```

names(retornos.df)<-c("Date", nome, "Ibovespa", "Selic",
"Dividend Indicated Yld")
names(retornos.df)
#Modelo CMRM5
source("Funcoes.R")
set.seed<-54648
sementes<-round(10000*runif(10000))
#Número de parametros
p<-11

#Inicializa vetor de chutes parametrosCMRM5(pi, alpha11,
alpha12, alpha13, alpha21, alpha22, alpha23, mu1, gamma1, mu2, gamma2)
parametrosCMRM5<-rep(0.1, p)

#Vetor de dados
vetor<-retornos.df[, 2]
library(maxLik)

#Restrições
A <- diag(p-1)
A<-rbind(A, rep(0, p-1), rep(0, p-1))

A[11, 2]=A[11, 3]==-1
A[12, 5]=A[12, 6]==-1

B = matrix(0, nrow(A), 1)
B[7]=B[8]=B[9]=B[10]= 1e+15
B[11]=B[12]=1

conta<-1
erro<-100000

while(erro>0.1)
{
  #E-STEP
matrizEsperancas<-matrix(0, length(vetor), 2)
  sigma21<-rep(1, length(vetor))
  sigma22<-rep(1, length(vetor))

for(k in 2:length(vetor))
{
  mu1<-parametrosCMRM5[8]+parametrosCMRM5[9]*retornos.df[k, 5]
  mu2<-parametrosCMRM5[10]+parametrosCMRM5[11]*retornos.df[k, 5]

  erro2<-vetor[k-1]^2
  sigma21[k]<-parametrosCMRM5[2]+parametrosCMRM5[3]
  *erro2+parametrosCMRM5[4]*sigma21[k-1]
  sigma22[k]<-parametrosCMRM5[5]+parametrosCMRM5[6]

```

```

*erro2+parametrosCMRM5[7]*sigma22[k-1]

      d1<-dnorm(vetor[k],mu1,sqrt(sigma21[k]))
      if(d1==0) d1=0.000000001
      d2<-dnorm(vetor[k],mu2,sqrt(sigma22[k]))
      if(d2==0) d2=0.000000001

      matrizEsperancas[k,1]<-((1+(((1-parametrosCMRM5[1])*d2)
      /(parametrosCMRM5[1]*d1)))^(-1))
      matrizEsperancas[k,2]<-(1+((parametrosCMRM5[1]*d1)
      /((1-parametrosCMRM5[1])*d2)))^(-1)
    }

matrizEsperancas[1,]<-0

#M-STEP
pil<-mean(matrizEsperancas[,1])
parametrosCMRM5[1]<-pil
pi2<-mean(matrizEsperancas[,2])
parametrosCMRM5Like<-parametrosCMRM5[2:length(parametrosCMRM5)]
res <- maxSANN(logLikelihoodCMRM5, start=parametrosCMRM5Like,
  constraints=list(ineqA=A, ineqB=B),random.seed = sementes[conta])
parametrosCMRM5[2:length(parametrosCMRM5)]<-res$estimate
  parametrosCMRM5[1]<-pil
  #Guarda a verossimilhanca
  if(conta==1)
  {
  likeli<-abs(res$maximum)
  }
  else
  {
  erro<-abs(likeli-abs(res$maximum))
  likeli<-abs(res$maximum)
  }
  conta<-conta+1
  }
AIC.CMRM<-(2*p)-2*likeli
Cov.CMRM<-(-1)*solve(hessian(res))
STD.CMRM<-sqrt(diag(Cov.CMRM))
ESTAT.CMRM<-res$estimate/STD.CMRM
PARM.CMRM<-c(pil,res$estimate)
PVALOR.CMRM<-2*pnorm(abs(ESTAT.CMRM),lower.tail = FALSE)

##### CAPM
#Interpola linearmente dados faltantes na Bovespa
library(wq)
retornos.df[,3]<- interpTs(retornos.df[,3], gap = 3,type = c("linear"))

```

```

retornos.df[,2]<- interpTs(retornos.df[,2], gap = 3,type = c("linear"))
retornos.df[,4]<- interpTs(retornos.df[,4], gap = 3,type = c("linear"))

#Deixa na forma do CAPM
retornos.df[,2]<-retornos.df[,2]-retornos.df[,4]
retornos.df[,3]<-retornos.df[,3]-retornos.df[,4]

source("Funcoes.R")
set.seed<-99855
sementes<-round(10000*runif(10000))
#Número de parametros
p<-11

#Inicializa vetor de chutes parametrosCAPM5(pi,alpha11,alpha12,
alpha13,alpha21,alpha22,alpha23,mu1,beta1,mu2,beta2)
parametrosCAPM5<-rep(0.1,p)
#parm<-coef(lm(retornos.df[,2]~1+retornos.df[,5]))
#parametrosCAPM5<-c(0.1,0.1,0.1,0.1,0.1,0.1,0.1,parm,parm)

#Vetor de dados
vetor<-retornos.df[,2]
library(maxLik)

#Restrições
A <- diag(p-1)
A<-rbind(A,rep(0,p-1),rep(0,p-1))

A[11,2]=A[11,3]==-1
A[12,5]=A[12,6]==-1

B = matrix(0,nrow(A),1)
B[7]=B[8]=B[9]=B[10]= 1e+15
B[11]=B[12]=1

conta<-1
erro<-100000

while(erro>0.1)
{
  #E-STEP
matrizEsperancas<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

  k<-159
for(k in 2:length(vetor))
{
  mul<-parametrosCAPM5[8]*retornos.df[k,5]

```

```

+parametrosCAPM5[9]*retornos.df[k,3]
mu2<-parametrosCAPM5[10]*retornos.df[k,5]
+parametrosCAPM5[11]*retornos.df[k,3]

erro2<-vetor[k-1]^2
sigma21[k]<-parametrosCAPM5[2]+parametrosCAPM5[3]*erro2
+parametrosCAPM5[4]*sigma21[k-1]
sigma22[k]<-parametrosCAPM5[5]+parametrosCAPM5[6]*erro2
+parametrosCAPM5[7]*sigma22[k-1]

d1<-dnorm(vetor[k],mu1,sqrt(sigma21[k]))
if(d1==0) d1=0.000000001
d2<-dnorm(vetor[k],mu2,sqrt(sigma22[k]))
if(d2==0) d2=0.000000001
matrizEsperancas[k,1]<-((1+((1-parametrosCAPM5[1])*d2)
/(parametrosCAPM5[1]*d1))^(-1))
matrizEsperancas[k,2]<-(1+(parametrosCAPM5[1]*d1)
/((1-parametrosCAPM5[1])*d2))^(-1)
}

matrizEsperancas[1,]<-0

#M-STEP
pi1<-mean(matrizEsperancas[,1])
parametrosCAPM5[1]<-pi1
pi2<-mean(matrizEsperancas[,2])
parametrosCAPM5Like<-parametrosCAPM5[2:length(parametrosCAPM5)]
res <- maxSANN(logLikelihoodCAPM5, start=parametrosCAPM5Like,
constraints=list(ineqA=A, ineqB=B),random.seed = sementes[conta])
parametrosCAPM5[2:length(parametrosCAPM5)]<-res$estimate
parametrosCAPM5[1]<-pi1
#Guarda a verossimilhanca
if(conta==1)
{
likeli<-abs(res$maximum)
}
else
{
erro<-abs(likeli-abs(res$maximum))
likeli<-abs(res$maximum)
}
conta<-conta+1
}
AIC.CAPM<-(2*p)-2*likeli
Cov.CAPM<-(-1)*solve(hessian(res))
STD.CAPM<-sqrt(diag(Cov.CAPM))
ESTAT.CAPM<-res$estimate/STD.CAPM
PARM.CAPM<-c(pi1,res$estimate)

```

```

PVALOR.CAPM<-2*pnorm(abs(ESTAT.CAPM),lower.tail = FALSE)

##### MM
library(wq)
#Interpola linearmente dados faltantes na Bovespa
retornos.df[,3]<- interpTs(retornos.df[,3], gap = 3,type = c("linear"))

source("Funcoes.R")
set.seed<-855
sementes<-round(10000*runif(10000))
#Número de parametros
p<-13

#Inicializa vetor de chutes parametrosMM5(pi,alpha11,alpha12,
alpha13,alpha21,alpha22,alpha23,mu1,gamma1,beta1,mu2,gamma2,beta2)
parametrosMM5<-rep(0.1,p)

#Vetor de dados
vetor<-retornos.df[,2]
library(maxLik)

#Restrições
A <- diag(p-1)
A<-rbind(A,rep(0,p-1),rep(0,p-1))

A[13,2]=A[13,3]==-1
A[14,5]=A[14,6]==-1

B = matrix(0,nrow(A),1)
B[7]=B[8]=B[9]=B[10]=B[11]=B[12]= 1e+15
B[13]=B[14]=1

conta<-1
erro<-100000

while(erro>0.1)
{
  #E-STEP
matrizEsperancas<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

for(k in 2:length(vetor))
{
  mu1<-parametrosMM5[8]+parametrosMM5[9]*retornos.df[k,5]
  +parametrosMM5[10]*retornos.df[k,3]
  mu2<-parametrosMM5[11]+parametrosMM5[12]*retornos.df[k,5]
  +parametrosMM5[13]*retornos.df[k,3]

```

```

    erro2<-vetor[k-1]^2
    sigma21[k]<-parametrosMM5[2]+parametrosMM5[3]*erro2
    +parametrosMM5[4]*sigma21[k-1]
    sigma22[k]<-parametrosMM5[5]+parametrosMM5[6]*erro2
    +parametrosMM5[7]*sigma22[k-1]

    matrizEsperancas[k,1]<-((1+(((1-parametrosMM5[1])*dnorm(vetor[k]
    ,mu2,sqrt(sigma22[k])))/(parametrosMM5[1]*dnorm(vetor[k]
    ,mu1,sqrt(sigma21[k]))))))^(-1))
    matrizEsperancas[k,2]<-(1+((parametrosMM5[1]*dnorm(vetor[k],
    mu1,sqrt(sigma21[k])))/(1-parametrosMM5[1])*dnorm(vetor[k],
    mu2,sqrt(sigma22[k]))))))^(-1)
  }

matrizEsperancas[1,]<-0

#M-STEP
pi1<-mean(matrizEsperancas[,1])
parametrosMM5[1]<-pi1
pi2<-mean(matrizEsperancas[,2])
parametrosMM5Like<-parametrosMM5[2:length(parametrosMM5)]
res <- maxSANN(logLikelihoodMM5, start=parametrosMM5Like,
constraints=list(ineqA=A, ineqB=B), random.seed = sementes[conta])
parametrosMM5[2:length(parametrosMM5)]<-res$estimate
  parametrosMM5[1]<-pi1
  #Guarda a verossimilhanca
  if(conta==1)
  {
    likeli<-abs(res$maximum)
  }
  else
  {
    erro<-abs(likeli-abs(res$maximum))
    likeli<-abs(res$maximum)
  }
  conta<-conta+1
}
AIC.MM<-(2*p)-2*likeli
Cov.MM<-(-1)*solve(hessian(res))
STD.MM<-sqrt(diag(Cov.MM))
ESTAT.MM<-res$estimate/STD.MM
PARM.MM<-c(pi1,res$estimate)
PVALOR.MM<-2*pnorm(abs(ESTAT.MM5),lower.tail = FALSE)

salva<-paste(nome, ".RData", sep="")
save.image(salva)

```

```
#####
#####          PARTE 3/4          #####
#####

#Limpa o WorksPace
rm(list = ls(all = TRUE))

#Define o WorkSPace
setwd("C:/Users/Administrador/Desktop/Pedro/Bases")

#Nome da planilha
nome<-c("BBAS3 BS Equity")

file<-paste(nome, ".csv", sep="")
dados.df <- read.csv(file)
names(dados.df)

#Cria as variáveis em forma de retorno
PRECO.ret<-diff(log(dados.df[, "PX_LAST"]))*100
SELIC.ret<-diff(log(dados.df[, "SELIC"]))*100
IBOVESPA.ret<-diff(log(dados.df[, "IBOV"]))*100
DVD.ret<-dados.df[2:nrow(dados.df), "EQY_DVD_NET"]
tempo<-seq(1:(length(PRECO.ret)))

#Cria o DataFrame
retornos.df<-as.data.frame(cbind(tempo,PRECO.ret,
IBOVESPA.ret,SELIC.ret,DVD.ret))
names(retornos.df)<-c("Date", nome, "Ibovespa", "Selic",
"Dividend Indicated Yld")
names(retornos.df)
#Modelo CMRM5
source("Funcoes.R")
set.seed<-54648
sementes<-round(10000*runif(10000))
#Número de parametros
p<-11

#Inicializa vetor de chutes parametrosCMRM5(pi,alpha11,alpha12,
alpha13,alpha21,alpha22,alpha23,mu1,gamma1,mu2,gamma2)
parametrosCMRM5<-rep(0.1,p)

#Vetor de dados
vetor<-retornos.df[,2]
library(maxLik)

#Restrições
A <- diag(p-1)
A<-rbind(A, rep(0,p-1), rep(0,p-1))
```

```

A[11,2]=A[11,3]=-1
A[12,5]=A[12,6]=-1

B = matrix(0,nrow(A),1)
B[7]=B[8]=B[9]=B[10]= 1e+15
B[11]=B[12]=1

conta<-1
erro<-100000

while(erro>0.1)
{
  #E-STEP
  matrizEsperancas<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

  for(k in 2:length(vetor))
  {
    mu1<-parametrosCMRM5[8]+parametrosCMRM5[9]*retornos.df[k,5]
    mu2<-parametrosCMRM5[10]+parametrosCMRM5[11]*retornos.df[k,5]

    erro2<-vetor[k-1]^2
    sigma21[k]<-parametrosCMRM5[2]+parametrosCMRM5[3]*erro2
    +parametrosCMRM5[4]*sigma21[k-1]
    sigma22[k]<-parametrosCMRM5[5]+parametrosCMRM5[6]*erro2
    +parametrosCMRM5[7]*sigma22[k-1]

    d1<-dnorm(vetor[k],mu1,sqrt(sigma21[k]))
    if(d1==0) d1=0.000000001
    d2<-dnorm(vetor[k],mu2,sqrt(sigma22[k]))
    if(d2==0) d2=0.000000001

    matrizEsperancas[k,1]<-((1+(((1-parametrosCMRM5[1])*d2)
    / (parametrosCMRM5[1]*d1)))^(-1))
    matrizEsperancas[k,2]<-(1+((parametrosCMRM5[1]*d1)
    / ((1-parametrosCMRM5[1])*d2)))^(-1))
  }

  matrizEsperancas[1,]<-0

  #M-STEP
  pi1<-mean(matrizEsperancas[,1])
  parametrosCMRM5[1]<-pi1
  pi2<-mean(matrizEsperancas[,2])
  parametrosCMRM5Like<-parametrosCMRM5[2:length(parametrosCMRM5)]
  res <- maxSANN(logLikelihoodCMRM5, start=parametrosCMRM5Like,

```

```

constraints=list(ineqA=A, ineqB=B),random.seed = sementes[conta])
parametrosCMRM5[2:length(parametrosCMRM5)]<-res$estimate
  parametrosCMRM5[1]<-pi1
  #Guarda a verossimilhanca
if(conta==1)
{
likeli<-abs(res$maximum)
}
else
{
erro<-abs(likeli-abs(res$maximum))
likeli<-abs(res$maximum)
}
conta<-conta+1
}
AIC.CMRM<-(2*p)-2*likeli
Cov.CMRM<-(-1)*solve(hessian(res))
STD.CMRM<-sqrt(diag(Cov.CMRM))
ESTAT.CMRM<-res$estimate/STD.CMRM
PARM.CMRM<-c(pi1,res$estimate)
PVALOR.CMRM<-2*pnorm(abs(ESTAT.CMRM),lower.tail = FALSE)

##### CAPM
#Interpola linearmente dados faltantes na Bovespa
library(wq)
retornos.df[,3]<- interpTs(retornos.df[,3], gap = 3,type = c("linear"))
retornos.df[,2]<- interpTs(retornos.df[,2], gap = 3,type = c("linear"))
retornos.df[,4]<- interpTs(retornos.df[,4], gap = 3,type = c("linear"))

#Deixa na forma do CAPM
retornos.df[,2]<-retornos.df[,2]-retornos.df[,4]
retornos.df[,3]<-retornos.df[,3]-retornos.df[,4]

source("Funcoes.R")
set.seed<-99855
sementes<-round(10000*runif(10000))
#Número de parametros
p<-11

#Inicializa vetor de chutes parametrosCAPM5(pi,alpha11,alpha12,
#alpha13,alpha21,alpha22,alpha23,mu1,beta1,mu2,beta2)
parametrosCAPM5<-rep(0.1,p)
#parm<-coef(lm(retornos.df[,2]~1+retornos.df[,5]))
#parametrosCAPM5<-c(0.1,0.1,0.1,0.1,0.1,0.1,0.1,parm,parm)

#Vetor de dados
vetor<-retornos.df[,2]

```

```

library(maxLik)

#Restrições
A <- diag(p-1)
A<-rbind(A, rep(0,p-1), rep(0,p-1))

A[11,2]=A[11,3]==-1
A[12,5]=A[12,6]==-1

B = matrix(0,nrow(A),1)
B[7]=B[8]=B[9]=B[10]= 1e+15
B[11]=B[12]=1

conta<-1
erro<-100000

while(erro>0.1)
{
  #E-STEP
  matrizEsperancas<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

  k<-159
  for(k in 2:length(vetor))
  {
    mu1<-parametrosCAPM5[8]*retornos.df[k,5]+parametrosCAPM5[9]*retornos.df[k,
    mu2<-parametrosCAPM5[10]*retornos.df[k,5]+parametrosCAPM5[11]*retornos.df[k,

    erro2<-vetor[k-1]^2
    sigma21[k]<-parametrosCAPM5[2]+parametrosCAPM5[3]*erro2
    +parametrosCAPM5[4]*sigma21[k-1]
    sigma22[k]<-parametrosCAPM5[5]+parametrosCAPM5[6]*erro2
    +parametrosCAPM5[7]*sigma22[k-1]

    d1<-dnorm(vetor[k],mu1,sqrt(sigma21[k]))
    if(d1==0) d1=0.000000001
    d2<-dnorm(vetor[k],mu2,sqrt(sigma22[k]))
    if(d2==0) d2=0.000000001
    matrizEsperancas[k,1]<-((1+((1-parametrosCAPM5[1])*d2)
    /(parametrosCAPM5[1]*d1))^(-1))
    matrizEsperancas[k,2]<-(1+(parametrosCAPM5[1]*d1)
    /((1-parametrosCAPM5[1])*d2))^(-1)
  }

  matrizEsperancas[1,]<-0

  #M-STEP

```

```

pi1<-mean(matrizEsperancas[,1])
parametrosCAPM5[1]<-pi1
pi2<-mean(matrizEsperancas[,2])
parametrosCAPM5Like<-parametrosCAPM5[2:length(parametrosCAPM5)]
res <- maxSANN(logLikelihoodCAPM5, start=parametrosCAPM5Like,
  constraints=list(ineqA=A, ineqB=B),random.seed = sementes[conta])
parametrosCAPM5[2:length(parametrosCAPM5)]<-res$estimate
  parametrosCAPM5[1]<-pi1
  #Guarda a verossimilhanca
if(conta==1)
{
likeli<-abs(res$maximum)
}
else
{
erro<-abs(likeli-abs(res$maximum))
likeli<-abs(res$maximum)
}
conta<-conta+1
}
AIC.CAPM<-(2*p)-2*likeli
Cov.CAPM<-(-1)*solve(hessian(res))
STD.CAPM<-sqrt(diag(Cov.CAPM))
ESTAT.CAPM<-res$estimate/STD.CAPM
PARM.CAPM<-c(pi1,res$estimate)
PVALOR.CAPM<-2*pnorm(abs(ESTAT.CAPM),lower.tail = FALSE)

##### MM
library(wq)
#Interpola linearmente dados faltantes na Bovespa
retornos.df[,3]<- interpTs(retornos.df[,3], gap = 3,type = c("linear"))

source("Funcoes.R")
set.seed<-855
sementes<-round(10000*runif(10000))
#Número de parametros
p<-13

#Inicializa vetor de chutes parametrosMM5(pi,alpha11,alpha12,
alpha13,alpha21,alpha22,alpha23,mu1,gamma1,beta1,mu2,gamma2,beta2)
parametrosMM5<-rep(0.1,p)

#Vetor de dados
vetor<-retornos.df[,2]
library(maxLik)

#Restrições
A <- diag(p-1)

```

```

A<-rbind(A, rep(0, p-1), rep(0, p-1))

A[13,2]=A[13,3]==-1
A[14,5]=A[14,6]==-1

B = matrix(0, nrow(A), 1)
B[7]=B[8]=B[9]=B[10]=B[11]=B[12]= 1e+15
B[13]=B[14]=1

conta<-1
erro<-100000

while(erro>0.1)
{
  #E-STEP
  matrizEsperancas<-matrix(0, length(vetor), 2)
  sigma21<-rep(1, length(vetor))
  sigma22<-rep(1, length(vetor))

  for(k in 2:length(vetor))
  {
    mu1<-parametrosMM5[8]+parametrosMM5[9]*retornos.df[k, 5]
    +parametrosMM5[10]*retornos.df[k, 3]
    mu2<-parametrosMM5[11]+parametrosMM5[12]*retornos.df[k, 5]
    +parametrosMM5[13]*retornos.df[k, 3]

    erro2<-vetor[k-1]^2
    sigma21[k]<-parametrosMM5[2]+parametrosMM5[3]*erro2
    +parametrosMM5[4]*sigma21[k-1]
    sigma22[k]<-parametrosMM5[5]+parametrosMM5[6]*erro2
    +parametrosMM5[7]*sigma22[k-1]

    matrizEsperancas[k,1]<-((1+(((1-parametrosMM5[1])*dnorm(vetor[k]
    , mu2, sqrt(sigma22[k])))/(parametrosMM5[1]*dnorm(vetor[k]
    , mu1, sqrt(sigma21[k]))))))^(-1))
    matrizEsperancas[k,2]<-(1+((parametrosMM5[1]*dnorm(vetor[k]
    , mu1, sqrt(sigma21[k])))/((1-parametrosMM5[1])*dnorm(vetor[k]
    , mu2, sqrt(sigma22[k]))))))^(-1))
  }

  matrizEsperancas[1,]<-0

  #M-STEP
  pi1<-mean(matrizEsperancas[,1])
  parametrosMM5[1]<-pi1
  pi2<-mean(matrizEsperancas[,2])
  parametrosMM5Like<-parametrosMM5[2:length(parametrosMM5)]
  res <- maxSANN(logLikelihoodMM5, start=parametrosMM5Like,

```

```

constraints=list(ineqA=A, ineqB=B),random.seed = sementes[conta])
parametrosMM5[2:length(parametrosMM5)]<-res$estimate
  parametrosMM5[1]<-pil
  #Guarda a verossimilhanca
if (conta==1)
{
likeli<-abs(res$maximum)
}
else
{
erro<-abs(likeli-abs(res$maximum))
likeli<-abs(res$maximum)
}
conta<-conta+1
}
AIC.MM<-(2*p)-2*likeli
Cov.MM<-(-1)*solve(hessian(res))
STD.MM<-sqrt(diag(Cov.MM))
ESTAT.MM<-res$estimate/STD.MM
PARM.MM<-c(pil,res$estimate)
PVALOR.MM<-2*pnorm(abs(ESTAT.MM5),lower.tail = FALSE)

salva<-paste(nome, ".RData", sep="")
save.image(salva)

#####
#####          PARTE 4/4          #####
#####

#Limpa o WorksPace
rm(list = ls(all = TRUE))

#Define o WorkSPace
setwd("C:/Users/Administrador/Desktop/Pedro/Bases")

#Nome da planilha
nome<-c("BBDC4 BS Equity")

file<-paste(nome, ".csv", sep="")
dados.df <- read.csv(file)
names(dados.df)

#Cria as variáveis em forma de retorno
PRECO.ret<-diff(log(dados.df[, "PX_LAST"]))*100
SELIC.ret<-diff(log(dados.df[, "SELIC"]))*100
IBOVESPA.ret<-diff(log(dados.df[, "IBOV"]))*100
DVD.ret<-dados.df[2:nrow(dados.df), "EQY_DVD_NET"]
tempo<-seq(1:(length(PRECO.ret)))

```

```

#Cria o DataFrame
retornos.df<-as.data.frame(cbind(tempo,PRECO.ret,
IBOVESPA.ret,SELIC.ret,DVD.ret))
names(retornos.df)<-c("Date",nome,"Ibovespa",
"Selic","Dividend Indicated Yld")
names(retornos.df)
#Modelo CMRM5
source("Funcoes.R")
set.seed<-54648
sementes<-round(10000*runif(10000))
#Número de parametros
p<-11

#Inicializa vetor de chutes parametrosCMRM5(pi,alpha11,
alpha12,alpha13,alpha21,alpha22,alpha23,mu1,gamma1,mu2,gamma2)
parametrosCMRM5<-rep(0.1,p)

#Vetor de dados
vetor<-retornos.df[,2]
library(maxLik)

#Restrições
A <- diag(p-1)
A<-rbind(A,rep(0,p-1),rep(0,p-1))

A[11,2]=A[11,3]==-1
A[12,5]=A[12,6]==-1

B = matrix(0,nrow(A),1)
B[7]=B[8]=B[9]=B[10]= 1e+15
B[11]=B[12]=1

conta<-1
erro<-100000

while(erro>0.1)
{
  #E-STEP
matrizEsperancas<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

for(k in 2:length(vetor))
{
  mu1<-parametrosCMRM5[8]+parametrosCMRM5[9]*retornos.df[k,5]
  mu2<-parametrosCMRM5[10]+parametrosCMRM5[11]*retornos.df[k,5]

```

```

erro2<-vetor[k-1]^2
sigma21[k]<-parametrosCMRM5[2]+parametrosCMRM5[3]*erro2
+parametrosCMRM5[4]*sigma21[k-1]
sigma22[k]<-parametrosCMRM5[5]+parametrosCMRM5[6]*erro2
+parametrosCMRM5[7]*sigma22[k-1]

    d1<-dnorm(vetor[k],mu1,sqrt(sigma21[k]))
    if(d1==0) d1=0.000000001
    d2<-dnorm(vetor[k],mu2,sqrt(sigma22[k]))
    if(d2==0) d2=0.000000001

matrizEsperancas[k,1]<-((1+((1-parametrosCMRM5[1])*d2)
/(parametrosCMRM5[1]*d1))^(-1))
matrizEsperancas[k,2]<-(1+(parametrosCMRM5[1]*d1)
/((1-parametrosCMRM5[1])*d2))^(-1)
}

matrizEsperancas[1,]<-0

#M-STEP
pi1<-mean(matrizEsperancas[,1])
parametrosCMRM5[1]<-pi1
pi2<-mean(matrizEsperancas[,2])
parametrosCMRM5Like<-parametrosCMRM5[2:length(parametrosCMRM5)]
res <- maxSANN(logLikelihoodCMRM5, start=parametrosCMRM5Like,
constraints=list(ineqA=A, ineqB=B),random.seed = sementes[conta])
parametrosCMRM5[2:length(parametrosCMRM5)]<-res$estimate
    parametrosCMRM5[1]<-pi1
    #Guarda a verossimilhanca
if(conta==1)
{
likeli<-abs(res$maximum)
}
else
{
erro<-abs(likeli-abs(res$maximum))
likeli<-abs(res$maximum)
}
conta<-conta+1
}
AIC.CMRM<-(2*p)-2*likeli
Cov.CMRM<-(-1)*solve(hessian(res))
STD.CMRM<-sqrt(diag(Cov.CMRM))
ESTAT.CMRM<-res$estimate/STD.CMRM
PARM.CMRM<-c(pi1,res$estimate)
PVALOR.CMRM<-2*pnorm(abs(ESTAT.CMRM),lower.tail = FALSE)

```

```
##### CAPM
#Interpola linearmente dados faltantes na Bovespa
library(wq)
retornos.df[,3]<- interpTs(retornos.df[,3], gap = 3,type = c("linear"))
retornos.df[,2]<- interpTs(retornos.df[,2], gap = 3,type = c("linear"))
retornos.df[,4]<- interpTs(retornos.df[,4], gap = 3,type = c("linear"))

#Deixa na forma do CAPM
retornos.df[,2]<-retornos.df[,2]-retornos.df[,4]
retornos.df[,3]<-retornos.df[,3]-retornos.df[,4]

source("Funcoes.R")
set.seed<-99855
sementes<-round(10000*runif(10000))
#Número de parametros
p<-11

#Inicializa vetor de chutes parametrosCAPM5(pi,alpha11,alpha12,
#alpha13,alpha21,alpha22,alpha23,mu1,beta1,mu2,beta2)
parametrosCAPM5<-rep(0.1,p)
#parm<-coef(lm(retornos.df[,2]~1+retornos.df[,5]))
#parametrosCAPM5<-c(0.1,0.1,0.1,0.1,0.1,0.1,0.1,parm,parm)

#Vetor de dados
vetor<-retornos.df[,2]
library(maxLik)

#Restrições
A <- diag(p-1)
A<-rbind(A,rep(0,p-1),rep(0,p-1))

A[11,2]=A[11,3]==-1
A[12,5]=A[12,6]==-1

B = matrix(0,nrow(A),1)
B[7]=B[8]=B[9]=B[10]= 1e+15
B[11]=B[12]=1

conta<-1
erro<-100000

while(erro>0.1)
{
  #E-STEP
matrizEsperancas<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))
}
```

```

k<-159
for(k in 2:length(vetor))
{
  mu1<-parametrosCAPM5[8]*retornos.df[k,5]+
  parametrosCAPM5[9]*retornos.df[k,3]
  mu2<-parametrosCAPM5[10]*retornos.df[k,5]
  +parametrosCAPM5[11]*retornos.df[k,3]

  erro2<-vetor[k-1]^2
  sigma21[k]<-parametrosCAPM5[2]+parametrosCAPM5[3]*erro2
  +parametrosCAPM5[4]*sigma21[k-1]
  sigma22[k]<-parametrosCAPM5[5]+parametrosCAPM5[6]*erro2
  +parametrosCAPM5[7]*sigma22[k-1]

  d1<-dnorm(vetor[k],mu1,sqrt(sigma21[k]))
  if(d1==0) d1=0.000000001
  d2<-dnorm(vetor[k],mu2,sqrt(sigma22[k]))
  if(d2==0) d2=0.000000001
  matrizEsperancas[k,1]<-((1+((1-parametrosCAPM5[1])*d2)
  /(parametrosCAPM5[1]*d1))^(-1))
  matrizEsperancas[k,2]<-(1+((parametrosCAPM5[1]*d1)
  /((1-parametrosCAPM5[1])*d2))^(-1))
}

matrizEsperancas[1,]<-0

#M-STEP
pi1<-mean(matrizEsperancas[,1])
parametrosCAPM5[1]<-pi1
pi2<-mean(matrizEsperancas[,2])
parametrosCAPM5Like<-parametrosCAPM5[2:length(parametrosCAPM5)]
res <- maxSANN(logLikelihoodCAPM5, start=parametrosCAPM5Like,
  constraints=list(ineqA=A, ineqB=B),random.seed = sementes[conta])
parametrosCAPM5[2:length(parametrosCAPM5)]<-res$estimate
  parametrosCAPM5[1]<-pi1
  #Guarda a verossimilhanca
  if(conta==1)
  {
  likeli<-abs(res$maximum)
  }
  else
  {
  erro<-abs(likeli-abs(res$maximum))
  likeli<-abs(res$maximum)
  }
  conta<-conta+1
  }
AIC.CAPM<-(2*p)-2*likeli

```

```

Cov.CAPM<-(-1)*solve(hessian(res))
STD.CAPM<-sqrt(diag(Cov.CAPM))
ESTAT.CAPM<-res$estimate/STD.CAPM
PARM.CAPM<-c(pil,res$estimate)
PVALOR.CAPM<-2*pnorm(abs(ESTAT.CAPM),lower.tail = FALSE)

##### MM
library(wq)
#Interpola linearmente dados faltantes na Bovespa
retornos.df[,3]<- interpTs(retornos.df[,3], gap = 3,type = c("linear"))

source("Funcoes.R")
set.seed<-855
sementes<-round(10000*runif(10000))
#Número de parametros
p<-13

#Inicializa vetor de chutes parametrosMM5(pi,alpha11,alpha12,
#alpha13,alpha21,alpha22,alpha23,mu1,gamma1,beta1,mu2,gamma2,beta2)
parametrosMM5<-rep(0.1,p)

#Vetor de dados
vetor<-retornos.df[,2]
library(maxLik)

#Restrições
A <- diag(p-1)
A<-rbind(A,rep(0,p-1),rep(0,p-1))

A[13,2]=A[13,3]==-1
A[14,5]=A[14,6]==-1

B = matrix(0,nrow(A),1)
B[7]=B[8]=B[9]=B[10]=B[11]=B[12]= 1e+15
B[13]=B[14]=1

conta<-1
erro<-100000

while(erro>0.1)
{
  #E-STEP
matrizEsperancas<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

for(k in 2:length(vetor))
{

```

```

mu1<-parametrosMM5[8]+parametrosMM5[9]*retornos.df[k,5]
+parametrosMM5[10]*retornos.df[k,3]
mu2<-parametrosMM5[11]+parametrosMM5[12]*retornos.df[k,5]
+parametrosMM5[13]*retornos.df[k,3]

erro2<-vetor[k-1]^2
sigma21[k]<-parametrosMM5[2]+parametrosMM5[3]*erro2
+parametrosMM5[4]*sigma21[k-1]
sigma22[k]<-parametrosMM5[5]+parametrosMM5[6]*erro2
+parametrosMM5[7]*sigma22[k-1]

matrizEsperancas[k,1]<-((1+((1-parametrosMM5[1])*dnorm(vetor[k],
mu2,sqrt(sigma22[k])))/(parametrosMM5[1]*dnorm(vetor[k],
mu1,sqrt(sigma21[k]))))^(-1))
matrizEsperancas[k,2]<-(1+((parametrosMM5[1])*dnorm(vetor[k],mu1,
sqrt(sigma21[k])))/(1-parametrosMM5[1])*dnorm(vetor[k],
mu2,sqrt(sigma22[k]))))^(-1)
}

matrizEsperancas[1,]<-0

#M-STEP
pi1<-mean(matrizEsperancas[,1])
parametrosMM5[1]<-pi1
pi2<-mean(matrizEsperancas[,2])
parametrosMM5Like<-parametrosMM5[2:length(parametrosMM5)]
res <- maxSANN(logLikelihoodMM5, start=parametrosMM5Like,
constraints=list(ineqA=A, ineqB=B),random.seed = sementes[conta])
parametrosMM5[2:length(parametrosMM5)]<-res$estimate
  parametrosMM5[1]<-pi1
  #Guarda a verossimilhanca
  if(conta==1)
  {
  likeli<-abs(res$maximum)
  }
  else
  {
  erro<-abs(likeli-abs(res$maximum))
  likeli<-abs(res$maximum)
  }
  conta<-conta+1
  }
AIC.MM<-(2*p)-2*likeli
Cov.MM<-(-1)*solve(hessian(res))
STD.MM<-sqrt(diag(Cov.MM))
ESTAT.MM<-res$estimate/STD.MM
PARM.MM<-c(pi1,res$estimate)
PVALOR.MM<-2*pnorm(abs(ESTAT.MM5),lower.tail = FALSE)

```

```
salva<-paste(nome, ".RData", sep="")
save.image(salva)
```

A.4 Programa Funções.

Esse programa foi compartilhado por todos os demais, pois contém as estruturas das funções de log-verossimilhança e da log-verossimilhança ponderada para os modelos estudados.

```
#Verossimilhança ponderada CMM5
logLikelihoodMNGARCH=function(parametrosLike)
{
  #parametrosMNGARCH(alpha11,alpha12,alpha13,alpha21,
  #alpha22,alpha23,mu1,mu2
  matrizDensidade<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

  for(i in 2:length(vetor))
  {
    mu1<-parametrosLike[7]
    mu2<-parametrosLike[8]

    erro2<-vetor[i-1]^2
    sigma21[i]<-parametrosLike[1]+parametrosLike[2]*erro2
    +parametrosLike[3]*sigma21[i-1]
    sigma22[i]<-parametrosLike[4]+parametrosLike[5]*erro2
    +parametrosLike[6]*sigma22[i-1]

    d1<-dnorm(vetor[i],mu1,sqrt(sigma21[i]))
    if(d1==0) d1=0.000000001
    d2<-dnorm(vetor[i],mu2,sqrt(sigma22[i]))
    if(d2==0) d2=0.000000001
    matrizDensidade[i,1]<-log(d1)
    matrizDensidade[i,2]<-log(d2)

  }
  somaLogLik<-sum(matrizEsperancas*matrizDensidade)

  return(somaLogLik)
}
```

```

#Verossimilhança ponderada CMRM5
logLikelihoodCMRM5=function(parametrosLike)
{
  #parametrosCMRM5(alpha11,alpha12,alpha13,alpha21,alpha22
  #,alpha23,mu1,gamma1,mu2,gamma2
matrizDensidade<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

for(i in 2:length(vetor))
{
  mu1<-parametrosLike[7]+parametrosLike[8]*retornos.df[i,5]
  mu2<-parametrosLike[9]+parametrosLike[10]*retornos.df[i,5]

  erro2<-vetor[i-1]^2
  sigma21[i]<-parametrosLike[1]+parametrosLike[2]*erro2
  +parametrosLike[3]*sigma21[i-1]
  sigma22[i]<-parametrosLike[4]+parametrosLike[5]*erro2
  +parametrosLike[6]*sigma22[i-1]

  d1<-dnorm(vetor[i],mu1,sqrt(sigma21[i]))
  if(d1==0) d1=0.000000001
  d2<-dnorm(vetor[i],mu2,sqrt(sigma22[i]))
  if(d2==0) d2=0.000000001
  matrizDensidade[i,1]<-log(d1)
  matrizDensidade[i,2]<-log(d2)

}
somaLogLik<-sum(matrizEsperancas*matrizDensidade)

return(somaLogLik)

}

#Verossimilhança ponderada CMRM10
logLikelihoodCMRM10=function(parametrosLike)
{
  #parametrosCMRM10(alpha11,alpha12,alpha13,alpha21,
  alpha22,alpha23,mu1,gamma1,mu2,gamma2
matrizDensidade<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

for(i in 2:length(vetor))
{
  mu1<-parametrosLike[7]+parametrosLike[8]*retornos.df[i,6]

```

```

mu2<-parametrosLike[9]+parametrosLike[10]*retornos.df[i,6]

erro2<-vetor[i-1]^2
sigma21[i]<-parametrosLike[1]+parametrosLike[2]*erro2
+parametrosLike[3]*sigma21[i-1]
sigma22[i]<-parametrosLike[4]+parametrosLike[5]*erro2
+parametrosLike[6]*sigma22[i-1]

d1<-dnorm(vetor[i],mu1,sqrt(sigma21[i]))
if(d1==0) d1=0.000000001
d2<-dnorm(vetor[i],mu2,sqrt(sigma22[i]))
if(d2==0) d2=0.000000001
matrizDensidade[i,1]<-log(d1)
matrizDensidade[i,2]<-log(d2)

}
somaLogLik<-sum(matrizEsperancas*matrizDensidade)

return(somaLogLik)

}

```

```

#Verossimilhança ponderada CMRM15
logLikelihoodCMRM15=function(parametrosLike)
{
  #parametrosCMRM15(alpha11,alpha12,alpha13,alpha21,alpha22
  #,alpha23,mu1,gamma1,mu2,gamma2
  matrizDensidade<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

  for(i in 2:length(vetor))
  {
    mu1<-parametrosLike[7]+parametrosLike[8]*retornos.df[i,7]
    mu2<-parametrosLike[9]+parametrosLike[10]*retornos.df[i,7]

    erro2<-vetor[i-1]^2
    sigma21[i]<-parametrosLike[1]+parametrosLike[2]*erro2
    +parametrosLike[3]*sigma21[i-1]
    sigma22[i]<-parametrosLike[4]+parametrosLike[5]*erro2
    +parametrosLike[6]*sigma22[i-1]

    d1<-dnorm(vetor[i],mu1,sqrt(sigma21[i]))
    if(d1==0) d1=0.000000001
    d2<-dnorm(vetor[i],mu2,sqrt(sigma22[i]))
    if(d2==0) d2=0.000000001
  }
}

```

```

        matrizDensidade[i,1]<-log(d1)
        matrizDensidade[i,2]<-log(d2)

    }
    somaLogLik<-sum(matrizEsperancas*matrizDensidade)

    return(somaLogLik)

}

#Verossimilhança ponderada CMRM20
logLikelihoodCMRM20=function(parametrosLike)
{
    #parametrosCMRM20(alpha11,alpha12,alpha13,alpha21,
    #alpha22,alpha23,mu1,gamma1,mu2,gamma2
    matrizDensidade<-matrix(0,length(vetor),2)
    sigma21<-rep(1,length(vetor))
    sigma22<-rep(1,length(vetor))

    for(i in 2:length(vetor))
    {
        mu1<-parametrosLike[7]+parametrosLike[8]*retornos.df[i,8]
        mu2<-parametrosLike[9]+parametrosLike[10]*retornos.df[i,8]

        erro2<-vetor[i-1]^2
        sigma21[i]<-parametrosLike[1]+parametrosLike[2]*erro2
        +parametrosLike[3]*sigma21[i-1]
        sigma22[i]<-parametrosLike[4]+parametrosLike[5]*erro2
        +parametrosLike[6]*sigma22[i-1]

        d1<-dnorm(vetor[i],mu1,sqrt(sigma21[i]))
        if(d1==0) d1=0.000000001
        d2<-dnorm(vetor[i],mu2,sqrt(sigma22[i]))
        if(d2==0) d2=0.000000001
        matrizDensidade[i,1]<-log(d1)
        matrizDensidade[i,2]<-log(d2)

    }
    somaLogLik<-sum(matrizEsperancas*matrizDensidade)

    return(somaLogLik)

}

#Verossimilhança ponderada MM5
logLikelihoodMM5=function(parametrosLike)

```

```

{
  #parametrosMM5(alpha11,alpha12,alpha13,alpha21,alpha22,
  #alpha23,mu1,gamma1,beta1,mu2,gamma2,beta2
  matrizDensidade<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

for(i in 2:length(vetor))
{
  mu1<-parametrosLike[7]+parametrosLike[8]*retornos.df[i,5]
  +parametrosLike[9]*retornos.df[i,3]
  mu2<-parametrosLike[10]+parametrosLike[11]*retornos.df[i,5]
  +parametrosLike[12]*retornos.df[i,3]

  erro2<-vetor[i-1]^2
  sigma21[i]<-parametrosLike[1]+parametrosLike[2]*erro2
  +parametrosLike[3]*sigma21[i-1]
  sigma22[i]<-parametrosLike[4]+parametrosLike[5]*erro2
  +parametrosLike[6]*sigma22[i-1]

  d1<-dnorm(vetor[i],mu1,sqrt(sigma21[i]))
  if(d1==0) d1=0.000000001
  d2<-dnorm(vetor[i],mu2,sqrt(sigma22[i]))
  if(d2==0) d2=0.000000001
  matrizDensidade[i,1]<-log(d1)
  matrizDensidade[i,2]<-log(d2)

}
somaLogLik<-sum(matrizEsperancas*matrizDensidade)

return(somaLogLik)

}

#Verossimilhança ponderada MM10
logLikelihoodMM10=function(parametrosLike)
{
  #parametrosMM10(alpha11,alpha12,alpha13,alpha21
  #,alpha22,alpha23,mu1,gamma1,beta1,mu2,gamma2,beta2
  matrizDensidade<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

for(i in 2:length(vetor))
{
  mu1<-parametrosLike[7]+parametrosLike[8]*retornos.df[i,6]
  +parametrosLike[9]*retornos.df[i,3]

```

```

mu2<-parametrosLike[10]+parametrosLike[11]*retornos.df[i,6]
+parametrosLike[12]*retornos.df[i,3]

erro2<-vetor[i-1]^2
sigma21[i]<-parametrosLike[1]+parametrosLike[2]*erro2
+parametrosLike[3]*sigma21[i-1]
sigma22[i]<-parametrosLike[4]+parametrosLike[5]*erro2
+parametrosLike[6]*sigma22[i-1]

d1<-dnorm(vetor[i],mu1,sqrt(sigma21[i]))
if(d1==0) d1=0.000000001
d2<-dnorm(vetor[i],mu2,sqrt(sigma22[i]))
if(d2==0) d2=0.000000001
matrizDensidade[i,1]<-log(d1)
matrizDensidade[i,2]<-log(d2)

}
somaLogLik<-sum(matrizEsperancas*matrizDensidade)

return(somaLogLik)

}

#Verossimilhança ponderada MM15
logLikelihoodMM15=function(parametrosLike)
{
  #parametrosMM15(alpha11,alpha12,alpha13,alpha21,
  #alpha22,alpha23,mu1,gamma1,beta1,mu2,gamma2,beta2
  matrizDensidade<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

  for(i in 2:length(vetor))
  {
    mu1<-parametrosLike[7]+parametrosLike[8]*retornos.df[i,7]
    +parametrosLike[9]*retornos.df[i,3]
    mu2<-parametrosLike[10]+parametrosLike[11]*retornos.df[i,7]
    +parametrosLike[12]*retornos.df[i,3]

    erro2<-vetor[i-1]^2
    sigma21[i]<-parametrosLike[1]+parametrosLike[2]*erro2
    +parametrosLike[3]*sigma21[i-1]
    sigma22[i]<-parametrosLike[4]+parametrosLike[5]*erro2
    +parametrosLike[6]*sigma22[i-1]

    d1<-dnorm(vetor[i],mu1,sqrt(sigma21[i]))

```

```

        if(d1==0) d1=0.000000001
        d2<-dnorm(vetor[i],mu2,sqrt(sigma22[i]))
        if(d2==0) d2=0.000000001
        matrizDensidade[i,1]<-log(d1)
        matrizDensidade[i,2]<-log(d2)
    }
    somaLogLik<-sum(matrizEsperancas*matrizDensidade)

    return(somaLogLik)
}

#Verossimilhança ponderada MM20
logLikelihoodMM20=function(parametrosLike)
{
    #parametrosMM20(alpha11,alpha12,alpha13,alpha21,alpha22,
    #alpha23,mu1,gamma1,beta1,mu2,gamma2,beta2
    matrizDensidade<-matrix(0,length(vetor),2)
    sigma21<-rep(1,length(vetor))
    sigma22<-rep(1,length(vetor))

    for(i in 2:length(vetor))
    {
        mu1<-parametrosLike[7]+parametrosLike[8]*retornos.df[i,8]
        +parametrosLike[9]*retornos.df[i,3]
        mu2<-parametrosLike[10]+parametrosLike[11]*retornos.df[i,8]
        +parametrosLike[12]*retornos.df[i,3]

        erro2<-vetor[i-1]^2
        sigma21[i]<-parametrosLike[1]+parametrosLike[2]*erro2
        +parametrosLike[3]*sigma21[i-1]
        sigma22[i]<-parametrosLike[4]+parametrosLike[5]*erro2
        +parametrosLike[6]*sigma22[i-1]

        d1<-dnorm(vetor[i],mu1,sqrt(sigma21[i]))
        if(d1==0) d1=0.000000001
        d2<-dnorm(vetor[i],mu2,sqrt(sigma22[i]))
        if(d2==0) d2=0.000000001
        matrizDensidade[i,1]<-log(d1)
        matrizDensidade[i,2]<-log(d2)
    }
    somaLogLik<-sum(matrizEsperancas*matrizDensidade)

    return(somaLogLik)
}

```

```

}

#Verossimilhança ponderada CAPM5
logLikelihoodCAPM5=function(parametrosLike)
{
  #parametrosCAPM5(alpha11,alpha12,alpha13,alpha21,
  alpha22,alpha23,mu1,beta1,mu2,beta2
  matrizDensidade<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

  for(i in 2:length(vetor))
  {
    mu1<-parametrosLike[7]*retornos.df[i,5]
    +parametrosLike[8]*retornos.df[i,3]
    mu2<-parametrosLike[9]*retornos.df[i,5]
    +parametrosLike[10]*retornos.df[i,3]

    erro2<-vetor[i-1]^2
    sigma21[i]<-parametrosLike[1]+parametrosLike[2]*
    erro2+parametrosLike[3]*sigma21[i-1]
    sigma22[i]<-parametrosLike[4]+parametrosLike[5]*
    erro2+parametrosLike[6]*sigma22[i-1]

    d1<-dnorm(vetor[i],mu1,sqrt(sigma21[i]))
    if(d1==0) d1=0.000000001
    d2<-dnorm(vetor[i],mu2,sqrt(sigma22[i]))
    if(d2==0) d2=0.000000001
    matrizDensidade[i,1]<-log(d1)
    matrizDensidade[i,2]<-log(d2)

  }
  somaLogLik<-sum(matrizEsperancas*matrizDensidade)

  return(somaLogLik)
}

#Verossimilhança ponderada CAPM10
logLikelihoodCAPM10=function(parametrosLike)
{
  #parametrosCAPM10(alpha11,alpha12,alpha13,alpha21,
  #alpha22,alpha23,mu1,beta1,mu2,beta2
  matrizDensidade<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

```

```

for(i in 2:length(vetor))
{
  mu1<-parametrosLike[7]*retornos.df[i,6]
  +parametrosLike[8]*retornos.df[i,3]
  mu2<-parametrosLike[9]*retornos.df[i,6]
  +parametrosLike[10]*retornos.df[i,3]

  erro2<-vetor[i-1]^2
  sigma21[i]<-parametrosLike[1]+parametrosLike[2]
  *erro2+parametrosLike[3]*sigma21[i-1]
  sigma22[i]<-parametrosLike[4]+parametrosLike[5]
  *erro2+parametrosLike[6]*sigma22[i-1]

  d1<-dnorm(vetor[i],mu1,sqrt(sigma21[i]))
  if(d1==0) d1=0.000000001
  d2<-dnorm(vetor[i],mu2,sqrt(sigma22[i]))
  if(d2==0) d2=0.000000001
  matrizDensidade[i,1]<-log(d1)
  matrizDensidade[i,2]<-log(d2)

}
somaLogLik<-sum(matrizEsperancas*matrizDensidade)

return(somaLogLik)

}

#Verossimilhança ponderada CAPM15
logLikelihoodCAPM15=function(parametrosLike)
{
  #parametrosCAPM15(alpha11,alpha12,alpha13,alpha21
  #,alpha22,alpha23,mu1,beta1,mu2,beta2
  matrizDensidade<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

  for(i in 2:length(vetor))
  {
    mu1<-parametrosLike[7]*retornos.df[i,7]
    +parametrosLike[8]*retornos.df[i,3]
    mu2<-parametrosLike[9]*retornos.df[i,7]
    +parametrosLike[10]*retornos.df[i,3]

    erro2<-vetor[i-1]^2
    sigma21[i]<-parametrosLike[1]+parametrosLike[2]

```

```

*erro2+parametrosLike[3]*sigma21[i-1]
sigma22[i]<-parametrosLike[4]+parametrosLike[5]
*erro2+parametrosLike[6]*sigma22[i-1]

d1<-dnorm(vetor[i],mu1,sqrt(sigma21[i]))
if(d1==0) d1=0.000000001
d2<-dnorm(vetor[i],mu2,sqrt(sigma22[i]))
if(d2==0) d2=0.000000001
matrizDensidade[i,1]<-log(d1)
matrizDensidade[i,2]<-log(d2)

}
somaLogLik<-sum(matrizEsperancas*matrizDensidade)

return(somaLogLik)

}

#Verossimilhança ponderada CAPM20
logLikelihoodCAPM20=function(parametrosLike)
{
  #parametrosCAPM20(alpha11,alpha12,alpha13,
  #alpha21,alpha22,alpha23,mu1,beta1,mu2,beta2
  matrizDensidade<-matrix(0,length(vetor),2)
  sigma21<-rep(1,length(vetor))
  sigma22<-rep(1,length(vetor))

  for(i in 2:length(vetor))
  {
    mu1<-parametrosLike[7]*retornos.df[i,8]
    +parametrosLike[8]*retornos.df[i,3]
    mu2<-parametrosLike[9]*retornos.df[i,8]
    +parametrosLike[10]*retornos.df[i,3]

    erro2<-vetor[i-1]^2
    sigma21[i]<-parametrosLike[1]+parametrosLike[2]*erro2
    +parametrosLike[3]*sigma21[i-1]
    sigma22[i]<-parametrosLike[4]+parametrosLike[5]*erro2
    +parametrosLike[6]*sigma22[i-1]

    d1<-dnorm(vetor[i],mu1,sqrt(sigma21[i]))
    if(d1==0) d1=0.000000001
    d2<-dnorm(vetor[i],mu2,sqrt(sigma22[i]))
    if(d2==0) d2=0.000000001
    matrizDensidade[i,1]<-log(d1)
    matrizDensidade[i,2]<-log(d2)
  }
}

```

```
}  
somaLogLik<-sum(matrizEsperancas*matrizDensidade)  
  
return (somaLogLik)  
  
}
```

REFERÊNCIAS BIBLIOGRÁFICAS

- AARTS, E.; KORST, J. *Simulated Annealing and Boltzmann Machines: A Stochastic Approach to Combinatorial Optimization and Neural Computing*. 1. ed. [S.l.]: Wiley, 1988. Hardcover. ISBN 0471921467.
- ABRAHAMSON, E.; PARK, C. Concealment of negative organizational outcomes: An agency theory perspective. *Academy of Management Journal*, Academy of Management, v. 37, n. 5, p. 1302–1334, 1994. Disponível em: <<http://www.jstor.org/stable/256674?origin=crossref>>.
- ACKER, D. Stock return volatility and dividend announcements. *Review of Quantitative Finance and Accounting*, v. 12, n. 3, p. 221–42, 1999.
- ADLER, R. J.; FELDMAN, R. E.; TAQQU, M. S. *A practical guide to heavy tails : statistical techniques and applications*. Boston: Birkhauser, 1998.
- AITKIN, M.; RUBIN, D. B. Estimation and Hypothesis Testing in Finite Mixture Models. 1982. Disponível em: <<http://www.jstor.org/stable/2345545>>.
- AKAIKE, H. A new look at the statistical model identification. *Automatic Control, IEEE Transactions on*, IEEE, v. 19, n. 6, p. 716–723, dez. 1974. ISSN 0018-9286. Disponível em: <<http://dx.doi.org/10.1109/TAC.1974.1100705>>.
- AKNOUCHE, A.; RABEHI, N. On an independent and identically distributed mixture bilinear time-series model. *Journal of Time Series Analysis*, Wiley-Blackwell Publishing, Inc, Commerce Place, 350 Main St, Malden 02148, Ma USA, 31, n. 2, p. 113–131, MAR 2010. ISSN 0143-9782.
- AKTAS, N.; BODT, E. de; COUSIN, J.-G. Event studies with a contaminated estimation period. *Journal of Corporate Finance*, v. 13, n. 1, p. 129–145, March 2007.
- ALEXANDER, C.; LAZAR, E. Modelling Regime-Specific Stock Price Volatility. *Oxford Bulletin Of Economics and Statistics*, Wiley-Blackwell Publishing, Inc, Commerce Place, 350 Main St, Malden 02148, Ma USA, 71, n. 6, p. 761–797, DEC 2009. ISSN 0305-9049.
- ANE, T.; GEMAN, H. Order flow, transaction clock, and normality of asset returns. *Journal of Finance*, v. 55, n. 5, p. 2259–2284, October 2000. Disponível em: <<http://ideas.repec.org/a/bla/jfinan/v55y2000i5p2259-2284.html>>.
- ASHLEY, R. A.; PATTERSON, D. M. Evaluating the effectiveness of state-switching time series models for u.s. real output. *Journal of Business & Economic Statistics*, v. 24, p. 266–277, July 2006. Disponível em: <<http://ideas.repec.org/a/bes/jnlbes/v24y2006p266-277.html>>.
- ASHLEY, R. A.; PATTERSON, D. M. A test of the garch(1, 1) specification for daily stock returns. *Macroeconomic Dynamics*, v. 14, n. S1, p. 137–144, May 2010.
- BAIMAN, S.; MAY, J. H.; MUKHERJI, A. *Optimal employment contracts and the returns to monitoring in a principal-agent context*. [S.l.: s.n.], 1990. 761-799 p.

- BAIXAULI, J. S. Abnormal performance in small portfolios with event-induced volatility: The case of stock splits. *Journal of Financial Research*, v. 30, n. 1, p. 35–52, 2007.
- BARBER, B. M.; LYON, J. D. Detecting abnormal operating performance: The empirical power and specification of test statistics. *Journal of Financial Economics*, v. 41, p. 359–399, 1996.
- BARSKY, R. B.; LONG, J. B. D. Bull and bear markets in the twentieth century. *The Journal of Economic History*, v. 50, n. 02, p. 265–281, June 1990.
- BEAVER, W. The information content of annual earnings announcements. *Journal of Accounting Research Supplement*, v. 6, p. 67–92, 1968.
- BELISLE, C. J. P. Convergence theorems for a class of simulated annealing algorithms on rd. *Journal of Applied Probability*, v. 29, n. 4, p. 885–895, 1992. Disponível em: <<http://www.jstor.org/stable/3214721>>.
- BENTARZI, M.; HAMDI, F. Mixture periodic autoregressive conditional heteroskedastic models. *Computational Statistics and Data Analysis*, v. 53, n. 1, p. 1 – 16, 2008. ISSN 0167-9473. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S016794730800323X>>.
- BERLE, A.; MEANS, G. *The Modern Corporation and Private Property*. [S.l.]: Mac Millan, N.Y., 1932.
- BEST, R. J.; BEST, R. W. Prior information and the market reaction to dividend changes. *Review of Quantitative Finance and Accounting*, v. 17, n. 4, p. 361–76, 2001.
- BIANCHI, M. L.; RACHEV, S. T.; KIM, Y. S.; FABOZZI, F. J. Tempered infinitely divisible distributions and processes. *Theory of Probability and Its Applications (TVP)*, Society for Industrial and Applied Mathematics (SIAM), 2000.
- BM&FBOVESPA. *Ibovespa. Acesso em 26/10/2011*. [S.l.]: <http://www.bmfbovespa.com.br/Indices/download/IBovespa.pdf>, 2011.
- BOLLERSLEV, T. Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, v. 31, n. 3, p. 307–327, April 1986. Disponível em: <<http://ideas.repec.org/a/eee/econom/v31y1986i3p307-327.html>>.
- BOOTH, P.; SCHULZ, A. K. D. The impact of an ethical environment on managers' project evaluation judgments under agency problem conditions. *Accounting, Organizations and Society*, v. 29, n. 5-6, p. 473–488, 2004. Disponível em: <<http://EconPapers.repec.org/RePEc:eee:aosoci:v:29:y:2004:i:5-6:p:473-488>>.
- BORGES, M. R. A model of stock price adjustment after dividends. *Journal of Economic Studies*, v. 36, n. 5, p. 508–521, 2009.
- BOYD, J. H.; JAGANNATHAN, R. Ex-dividend price behavior of common stocks. *Review of Financial Studies*, v. 7, n. 4, p. 711–741, 1994.
- BRIGHAM, E. *Fundamentals of financial management*. 2. ed. ed. Hinsdale, Ill.: Dryden Press, 1980. ISBN 0030547717.
- BROCKWELL, P. J.; DAVIS, R. A. *Time series: theory and methods. Second edition*. New York, NY, USA: Springer-Verlag New York, Inc., 2009. ISBN 0-387-96406-1.

BROWN, J. L.; III, J. H. E.; MOSER, D. V. Agency theory and participative budgeting experiments. *Journal of Management Accounting Research*, v. 21, n. 1, p. 317–345, 2009.

BROWN, S.; WARNER, J. B. Measuring security price performance. *Journal of Financial Economics*, v. 8, p. 205–258, 1980.

BROWN, S.; WARNER, J. B. Using daily stock returns: The case of event studies. *Journal of Financial Economics*, v. 14, p. 3–31, 1985.

BURNHAM, K.; ANDERSON, D. *Model selection and multimodel inference: a practical information-theoretic approach*. 2nd. ed. Springer, 2002. Hardcover. ISBN 0387953647. Disponível em: <<http://www.amazon.com/exec/obidos/redirect?tag=citeulike07-20&path=ASIN/0387953647>>.

CAI, J. A Markov Model of Switching-Regime ARCH. *Journal of Business & Economic Statistics*, American Statistical Association, v. 12, n. 3, 1994. ISSN 07350015. Disponível em: <<http://dx.doi.org/10.2307/1392087>>.

CAMPBELL, C.; WASLEY, C. Measuring abnormal trading volume for samples of nyse/ase and nasdaq securities using parametric and nonparametric test statistics. *Review of Quantitative Finance and Accounting*, v. 6, p. 309–326, 1996.

CASELLA, G.; BERGER, R. *Statistical Inference*. [S.l.]: Duxbury Resource Center, 2001. Textbook Binding. ISBN 0534243126.

CHAKRABORTI, A.; TOKE, I. M.; PATRIARCA, M.; ABERGEL, F. Econophysics: Empirical facts and agent-based models. *Quantitative Finance*, v. 11, p. 1013, 2011. Disponível em: <<http://www.citebase.org/abstract?id=oai:arXiv.org:0909.1974>>.

CHENG, B.; RACHEV, S. T. *The Stable Fit To Asset Returns*. Santa Barbara, 1994.

CHEUNG, Y.-W.; CHUNG, S.-K. A long memory model with normal mixture garch. *Computational Economics*, Springer Netherlands, v. 38, p. 517–539, 2011. ISSN 0927-7099. 10.1007/s10614-011-9274-y. Disponível em: <<http://dx.doi.org/10.1007/s10614-011-9274-y>>.

CHIBANTE, R. *Simulated Annealing, Theory with Applications*. Sciyo, 2010. (Global Optimization). ISBN 978-953-307-134-3. Disponível em: <<http://www.intechopen.com/books/show/title/simulated-annealing-theory-with-applications>>.

CHRISTIE, W. G. Are dividend omissions truly the cruelest cut of all? *Journal of Financial and Quantitative Analysis*, v. 29, n. 03, p. 459–480, September 1994.

CLARK, P. K. A subordinated stochastic process model with finite variance for speculative prices. *Econometrica*, The Econometric Society, v. 41, n. 1, p. pp. 135–155, 1973. ISSN 00129682. Disponível em: <<http://www.jstor.org/stable/1913889>>.

COHEN, J. R.; HOLDER-WEBB, L. L. Rethinking the influence of agency theory in the accounting academy. *Issues In Accounting Education*, p. 17–30, 2006.

CONT, R. Empirical properties of asset returns: stylized facts and statistical issues. *Quantitative Finance*, v. 1, p. 223–236, 2001.

CORHAY, A.; RAD, A. T. Conditional heteroskedasticity adjusted market model and an event study. *The Quarterly Review of Economics and Finance*, v. 36, n. 4, p. 529–538, 1996. Disponível em: <<http://ideas.repec.org/a/eee/quaeco/v36y1996i4p529-538.html>>.

CORRADO, C. J. A nonparametric test for abnormal security-price performance in event studies. *Journal of Financial Economics*, v. 23, n. 2, p. 385–395, August 1989.

CORRADO, C. J. Event studies: A methodology review. *Accounting & Finance*, Blackwell Publishing Ltd, v. 51, n. 1, p. 207–234, 2011. ISSN 1467-629X. Disponível em: <<http://dx.doi.org/10.1111/j.1467-629X.2010.00375.x>>.

CORRADO, C. J.; TRUONG, C. Conducting event studies with asia-pacific security market data. *Pacific-Basin Finance Journal*, v. 16, n. 5, p. 493–521, November 2008.

CORRADO, C. J.; ZIVNEY, T. L. The specification and power of the sign test in event study hypothesis tests using daily stock returns. *Journal of Financial and Quantitative Analysis*, v. 27, n. 03, p. 465–478, September 1992.

COSTA, P. H. S.; BAIDYA, T. K. N. Propriedades estatísticas das séries de retornos das principais ações brasileiras. *Pesquisa Operacional*, v. 21, n. 1, p. 61–87, 2001. Disponível em: <<http://www.citebase.org/abstract?id=oai:arXiv.org:0909.1974>>.

CRAMER, H. *Mathematical methods of statistics*. [S.l.]: Princeton University Press, 1999.

CRAWLEY, M. *Statistics: an introduction using R*. Chichester: Wiley, 2005.

DECHOW, P. M.; SLOAN, R. G.; SWEENEY, A. P. Detecting Earnings Management. *The Accounting Review*, American Accounting Association, v. 70, n. 2, p. 193–225, 1995. ISSN 00014826. Disponível em: <<http://dx.doi.org/10.2307/248303>>.

DEJONG, D. N.; NANKERVIS, J. C.; SAVIN, N. E.; WHITEMAN, C. H. The power problems of unit root test in time series with autoregressive errors. *Journal of Econometrics*, v. 53, n. 1-3, p. 323–343, 1992.

DEMOS, A.; SENTANA, E. An em algorithm for conditionally heteroscedastic factor models. *Journal of Business & Economic Statistics*, American Statistical Association, v. 16, n. 3, p. pp. 357–361, 1998. ISSN 07350015. Disponível em: <<http://www.jstor.org/stable/1392512>>.

DEMPSTER, A. P.; LAIRD, N. M.; RUBIN, D. B. Maximum Likelihood from Incomplete Data via the EM Algorithm. *Journal of the Royal Statistical Society. Series B (Methodological)*, Blackwell Publishing for the Royal Statistical Society, v. 39, n. 1, p. 1–38, 1977. ISSN 00359246. Disponível em: <<http://web.mit.edu/6.435/www/Dempster77.pdf>>.

DEMSETZ, H.; LEHN, K. The structure of corporate ownership: Causes and consequences. *Journal of Political Economy*, v. 93, n. 6, p. 1155–77, December 1985. Disponível em: <<http://ideas.repec.org/a/ucp/jpolec/v93y1985i6p1155-77.html>>.

DIAS, J. G.; VERMUNT, J. K.; RAMOS, S. Mixture hidden markov models in finance research. In: FINK, A.; LAUSEN, B.; SEIDEL, W.; ULTSCH, A. (Ed.). *Advances in Data Analysis, Data Handling and Business Intelligence*. [S.l.]: Springer Berlin Heidelberg, 2010, (Studies in Classification, Data Analysis, and Knowledge Organization). p. 451–459. ISBN 978-3-642-01044-6.

- DRAKE, P. P.; FABOZZI, F. *The Basics of Finance: An Introduction to Financial Markets, Business Finance, and Portfolio Management*. New Jersey: Wiley, 2010. ISBN 04-7060-971-0.
- EATON, R. D. V. Stock price adjustment to the information in dividend changes. *Review of Quantitative Finance and Accounting*, v. 12, n. 2, p. 113–33, 1999.
- EFRON, B.; HINKLEY, D. V. Assessing the accuracy of the maximum likelihood estimator: Observed versus expected Fisher information. *Biometrika*, v. 65, n. 3, p. 457–483, dez. 1978. Disponível em: <<http://dx.doi.org/10.1093/biomet/65.3.457>>.
- EISENHARDT, K. M. Agency Theory: An Assessment and Review. *The Academy of Management Review*, Academy of Management, v. 14, n. 1, p. 57–74, 1989. ISSN 03637425. Disponível em: <<http://dx.doi.org/10.2307/258191>>.
- ENGLE, R.; BOLLERSLEV, T. Modelling the persistence of conditional variances. *Econometric Reviews*, Taylor & Francis, v. 5, n. 1, p. 1–50, 1986.
- ENGLE, R. F. Autoregressive conditional heteroscedasticity with estimates of the variance of united kingdom inflation. *Econometrica*, The Econometric Society, v. 50, n. 4, p. pp. 987–1007, 1982. ISSN 00129682. Disponível em: <<http://www.jstor.org/stable/1912773>>.
- ENGLE, R. F.; LILIEN, D. M.; ROBINS, R. P. Estimating time varying risk premia in the term structure: The arch-m model. *Econometrica*, The Econometric Society, v. 55, n. 2, p. pp. 391–407, 1987. ISSN 00129682. Disponível em: <<http://www.jstor.org/stable/1913242>>.
- FAMA, E. The behavior of stock market prices. *Journal of Business*, v. 38, p. 34–105, 1965.
- FAMA, E. Efficient capital markets: li. *Journal of Finance*, v. 46, p. 1575–1671, 1991.
- FAMA, E.; LAWRENCE, F.; MICHAEL, J. C.; RICHARD, R. The adjustment of stock prices to new information. *International Economic Review*, v. 10, p. 1–21, 1969.
- FAMA, E. F. Agency problems and the theory of the firm. *Journal of Political Economy*, JSTOR, v. 88, n. 2, p. 288–307, 1980. Disponível em: <<http://www.journals.uchicago.edu/doi/abs/10.1086/260866>>.
- FELLER, W. *An Introduction to Probability Theory and Its Applications, Vol. 2*. 3rd ed.. ed. New York: Wiley, 1971.
- FORD, G. S.; KLINE, A. D. Event Studies for Merger Analysis: An Evaluation of the Effects of Non-Normality on Hypothesis Testing. *SSRN eLibrary*, SSRN, 2006.
- FULLER, K. P.; GOLDSTEIN, M. A. Do dividends matter more in declining markets? *Journal of Corporate Finance*, v. 17, n. 3, p. 457–473, June 2011. Disponível em: <<http://ideas.repec.org/a/eee/corfin/v17y2011i3p457-473.html>>.
- GALEANO, P.; AUSIN, M. C. The Gaussian Mixture Dynamic Conditional Correlation Model: Parameter Estimation, Value at Risk Calculation, and Portfolio Selection. *Journal Of Business & Economic Statistics*, Amer Statistical Assoc, 732 N Washington St, Alexandria, Va 22314-1943 Usa, 28, n. 4, p. 559–571, OCT 2010. ISSN 0735-0015.
- GARRETT, I.; PRIESTLEY, R. Dividend behaviour and dividend signaling. *Journal of Financial and Quantitative Analysis*, v. 35, n. 02, p. 173–189, 2000.

GOMEZ-MEJIA, L. R.; BALKIN, D. B. Determinants of faculty pay: An agency theory perspective. *Academy of Management Journal*, Academy of Management, v. 35, n. 5, p. 921–955, 1992. Disponível em: <<http://www.jstor.org/stable/256535?origin=crossref>>.

GONZALEZ, L.; POWELL, J. G.; SHI, J.; WILSON, A. Two centuries of bull and bear market cycles. *International Review of Economics and Finance*, v. 14, n. 4, p. 469 – 486, 2005. ISSN 1059-0560. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1059056004000322>>.

GORDON, M. J. Dividends, earnings, and stock prices. *The Review of Economics and Statistics*, The MIT Press, v. 41, n. 2, p. pp. 99–105, 1959. ISSN 00346535. Disponível em: <<http://www.jstor.org/stable/1927792>>.

GRAY, S. F. Modeling the conditional distribution of interest rates as a regime-switching process. *Journal of Financial Economics*, v. 42, n. 1, p. 27–62, September 1996. Disponível em: <<http://ideas.repec.org/a/eee/jfinec/v42y1996i1p27-62.html>>.

GREENE, W. H. *Econometric Analysis*. 5.. ed. Upper Saddle River, NJ: Prentice Hall, 2003.

GRIDGEMAN, N. T. A comparison of two methods of analysis of mixtures of normal distributions. *Technometrics*, v. 12, p. 823–833, 1970.

HAAS, M. Mixed normal conditional heteroskedasticity. *Journal of Financial Econometrics*, Society for Industrial and Applied Mathematics (SIAM), v. 2, p. 211–250, 2004.

HAAS, M. Skew-Normal Mixture and Markov-Switching GARCH Processes. *Studies In Nonlinear Dynamics And Econometrics*, Berkeley Electronic Press, 2809 Telegraph Avenue, Ste 202, Berkeley, Ca 94705 USA, 14, n. 4, 2010. ISSN 1081-1826.

HAAS, M.; MITTNIK, S.; PAOLELLA, M. S. Asymmetric multivariate normal mixture GARCH. *COMPUTATIONAL STATISTICS AND DATA ANALYSIS*, ELSEVIER SCIENCE BV, PO BOX 211, 1000 AE AMSTERDAM, NETHERLANDS, 53, n. 6, p. 2129–2154, APR 15 2009. ISSN 0167-9473.

HAMILL, P. A.; OPONG, K. K.; MCGREGOR, P. Equity option listing in the uk: a comparison of market-based research methodologies. *Journal of Empirical Finance*, v. 9, n. 1, p. 91–108, 2002.

HAMILTON, J. D.; SUSMEL, R. Autoregressive conditional heteroskedasticity and changes in regime. *Journal of Econometrics*, v. 64, n. 1-2, p. 307–333, 1994. Disponível em: <<http://ideas.repec.org/a/eee/econom/v64y1994i1-2p307-333.html>>.

HANNAN, E. J.; QUINN, B. G. The Determination of the Order of an Autoregression. *Journal of the Royal Statistical Society. Series B (Methodological)*, Blackwell Publishing for the Royal Statistical Society, v. 41, n. 2, p. 190–195, 1979. ISSN 00359246. Disponível em: <<http://dx.doi.org/10.2307/2985032>>.

HARRINGTON, S. E.; SHRIDER, D. G. All events induce variance: Analyzing abnormal returns when effects vary across firms. *Journal of Financial and Quantitative Analysis*, v. 42, n. 01, p. 229–256, March 2007.

HEALY, P. M.; PALEPU, K. G. Earnings information conveyed by dividend initiations and omissions. *Journal of Financial Economics*, v. 21, n. 2, p. 149–175, September 1988.

- HEIN, S. E. Improving tests of abnormal returns by bootstrapping the multivariate regression model with event parameters. *Journal of Financial Econometrics*, v. 2, n. 3, p. 451–471, 2004.
- HENNINGSEN, A.; TOOMET, O. maxlik : A package for maximum likelihood estimation in r. *October*, 2010.
- HETTMANSPERGER, T. P. *Statistical Inference based on Ranks*. Wiley, 1984. 69–79-79 p. Disponível em: <<http://dx.doi.org/10.1007/BF02294090>>.
- HIGGINS, E. J.; PETERSON, D. R. The power of one and two sample t-statistics given event-induced variance increases and nonnormal stock returns: A comparative study. *Quarterly Journal of Business and Economics*, v. 37, n. 1, p. 27–49, 1998.
- HUNT, H. I.; HOGLER, R. L. Agency theory as ideology: A comparative analysis based on critical legal theory and radical accounting. *Accounting, Organizations and Society*, v. 15, n. 5, p. 437–454, 1990. Disponível em: <<http://ideas.repec.org/a/eee/aosoci/v15y1990i5p437-454.html>>.
- HURVICH, C. M.; TSAI, c.-L. Regression and time series model selection in small samples. *Biometrika*, v. 76, n. 2, p. 297–307, jun. 1989. Disponível em: <<http://dx.doi.org/10.1093/biomet/76.2.297>>.
- IYER, A. V.; SCHWARZ, L. B.; ZENIOS, S. A. A principal-agent model for product specification and production. *Management Science*, v. 51, n. 1, p. 106–119, 2005. Disponível em: <<http://EconPapers.repec.org/RePEc:inm:ormnsc:v:51:y:2005:i:1:p:106-119>>.
- JENSEN, M. C. Organization theory and methodology. *Accounting Review*, JSTOR, v. 58, n. 2, p. 319–339, 1983. Disponível em: <<http://www.ssrn.com/abstract=94036>>.
- JENSEN, M. C.; MECKLING, W. H. Theory of the firm: Managerial behavior, agency costs and ownership structure. *Journal of Financial Economics*, v. 3, n. 4, p. 305–360, October 1976. Disponível em: <<http://ideas.repec.org/a/eee/jfinec/v3y1976i4p305-360.html>>.
- JIRAPORN, P.; KIM, J.-C.; KIM, Y. S. Dividend payouts and corporate governance quality: An empirical investigation. *The Financial Review*, v. 46, n. 2, p. 251–279, 2011.
- JOHNSON, S. A. Dividend payout and the valuation effects of bond announcements. *Journal of Financial and Quantitative Analysis*, v. 30, n. 03, p. 407–423, 1995.
- JORDAN, M. I. Hierarchical mixtures of experts and the em algorithm. *Neural Computation*, v. 6, p. 181–214, 1994.
- KALAY, A.; SUBRAHMANYAM, M. G. The ex-dividend day behavior of option prices. *The Journal of Business*, v. 57, n. 1, p. 113–28, 1984.
- KALDOR, N. Economic growth and capital accumulation. *The Theory of Capital*, 1961.
- KAO, C.; WU, C. Rational expectations, information signalling and dividend adjustment to permanent earnings. *The Review of Economics and Statistics*, v. 76, n. 3, p. 490–502, 1994.
- KESNER, I. F.; SHAPIRO, D. L.; SHARMA, a. *Brokering mergers: An agency theory perspective on the role of representatives*. [S.l.: s.n.], 1994. 703-721 p.

- KHOTARI, S. P.; WARNER, J. B. Econometrics of event studies. *Espen Eckbo (ed.), Handbook of Corporate Finance: Empirical Corporate Finance*, Handbooks in Finance Series Elsevier/North-Holland, Volume A, p. 3–36, 2006.
- KIM, O.; VERRECCHIA, R. E. Market reaction to anticipated announcements. *Journal of Financial Economics*, v. 30, n. 2, p. 273–309, 1991.
- KOCH, A. S.; SUN, A. X. Dividend changes and the persistence of past earnings changes. *Journal of Finance*, SSRN, v. 59, p. 2093–2116, 2004.
- KON, S. J. Models of stock returns - a comparison. *The Journal of Finance*, v. 39, n. 1, p. 147–165, 1984.
- KONISHI, S.; KITAGAWA, G. *Information Criteria and Statistical Modeling (Springer Series in Statistics)*. Springer, 2007. Hardcover. ISBN 0387718869. Disponível em: <<http://www.amazon.com/exec/obidos/redirect?tag=citeulike07-20&path=ASIN/0387718869>>.
- KOTHARI, S.; LEONE, A. J.; WASLEY, C. E. Performance matched discretionary accrual measures. *Journal of Accounting and Economics*, v. 39, n. 1, p. 163–197, February 2005.
- KUNZ, A. H.; PFAFF, D. Agency theory, performance evaluation, and the hypothetical construct of intrinsic motivation. *Accounting, Organizations and Society*, v. 27, n. 3, p. 275–295, April 2002. Disponível em: <<http://ideas.repec.org/a/eee/aosoci/v27y2002i3p275-295.html>>.
- LAARHOVEN, P. J. van; AARTS, E. H. *Simulated Annealing: Theory and Applications (Mathematics and Its Applications)*. 1. ed. [S.l.]: Springer, 1987. Hardcover. ISBN 9027725136.
- LEARY, M. T.; MICHAELY, R. Determinants of dividend smoothing: Empirical evidence. *Review of Financial Studies*, v. 24, n. 10, p. 3197–3249, 2011.
- LEHMANN, E. L. Efficient likelihood estimators. *The American Statistician*, v. 34, n. 4, p. 233–235, 1980. ISSN 0003-1305 (print), 1537-2731 (electronic).
- LEHMANN, E. L.; CASELLA, G. *Theory of Point Estimation*. [S.l.]: Springer (2nd ed.), 1998.
- LIU, Y.; SZEWCZYK, S. H.; ZANTOUT, Z. Underreaction to dividend reductions and omissions? *Journal of Finance*, v. 63, n. 2, p. 987–1020, 2008.
- LUMMER, S. L.; MCCONNELL, J. J. Further evidence on the bank lending process and the capital-market response to bank loan agreements. *Journal of Financial Economics*, v. 25, n. 1, p. 99–122, November 1989.
- LUNDE, A.; HANSEN, P. R. A forecast comparison of volatility models: does anything beat a garch(1,1)? *Journal of Applied Econometrics*, v. 20, n. 7, p. 873–889, 2005. Disponível em: <<http://ideas.repec.org/a/jae/japmet/v20y2005i7p873-889.html>>.
- MACKINLAY, A. C. Event studies in economics and finance. *Journal of Economic Literature*, XXXV, p. 13–39, 1997.
- MAHEU, J. M.; MCCURDY, T. H. Identifying bull and bear markets in stock returns. *Journal of Business & Economic Statistics*, American Statistical Association, v. 18, n. 1, p. pp. 100–112, 2000. ISSN 07350015. Disponível em: <<http://www.jstor.org/stable/1392140>>.

MANDELBROT, B. B. Paretian distributions and income maximization. *Quart. J. Econ.*, v. 76, n. 1, p. 57–85, fev. 1962.

MANDELBROT, B. B. New methods in statistical economics. *Journal of Political Economy*, v. 71, p. 421, 1963. Disponível em: <<http://ideas.repec.org/a/ucp/jpolec/v71y1963p421.html>>.

MANDELBROT, B. B. The variation of certain speculative price. *Journal of Business*, XXXVI, p. 394–419, 1963.

MANDELBROT, B. B. The variation of certain speculative prices. *The Journal of Business*, v. 36, p. 394, 1963. Disponível em: <<http://ideas.repec.org/a/ucp/jnlbus/v36y1963p394.html>>.

MANDELBROT, B. B. Forecasts of future prices, unbiased markets, and 'martingale' models. *Journal of Business*, XXXIX, p. 242–255, 1966.

MANDELBROT, B. B. *The Fractal Geometry of Nature*. 1. ed. Times Books, 1982. Hardcover. ISBN 9780716711865. Disponível em: <<http://www.amazon.com/exec/obidos/redirect?tag=citeulike07-20&path=ASIN/0716711869>>.

MASSEY, C.; WU, G. Detecting regime shifts: The causes of under- and overreaction. *Management Science*, v. 51, n. 6, p. 932–947, June 2005. Disponível em: <<http://ideas.repec.org/a/inm/ormnsc/v51y2005i6p932-947.html>>.

MCCONNELL, J. J.; MUSCARELLA, C. J. Corporate capital expenditure decisions and the market value of the firm. *Journal of Financial Economics*, v. 14, n. 3, p. 399–422, September 1985.

MCLACHLAN, G.; KRISHNAN, T. *The EM algorithm and extensions*. New York: Wiley, 1997.

MCLAUGHLAN, G. J. *Finite Mixture Models*. [S.l.]: Wiley, 2000.

MILLER, M. H. The history of finance: An eyewitness account. *Journal of Applied Corporate Finance*, Blackwell Publishing Ltd, v. 13, n. 2, p. 8–14, 2000. ISSN 1745-6622. Disponível em: <<http://dx.doi.org/10.1111/j.1745-6622.2000.tb00050.x>>.

MILLER, M. H.; MODIGLIANI, F. Dividend policy, growth, and the valuation of shares. *The Journal of Business*, The University of Chicago Press, v. 34, n. 4, p. 411–433, 1961. ISSN 00219398. Disponível em: <<http://www.jstor.org/stable/2351143>>.

MITCHELL, M. L.; NETTER, J. M. The role of financial economics in securities fraud cases: Applications at the Securities and Exchange Commission. *The Business Lawyer*, v. 49, n. 2, p. 545–590, fev. 1994.

MITTNIK, S.; RACHEV, S. T.; PAOLELLA, M. S. Stable paretian modeling in finance: some empirical and theoretical aspects. In: _____. Cambridge, MA, USA: Birkhauser Boston Inc., 1998. p. 79–110. ISBN 0-8176-3951-9. Disponível em: <<http://dl.acm.org/citation.cfm?id=292595.292604>>.

MODIGLIANI, F.; MILLER, M. H. The cost of capital, corporation finance and the theory of investment. *The American Economic Review*, American Economic Association, v. 48, n. 3, p. 261–297, 1958. ISSN 00028282. Disponível em: <<http://www.jstor.org/stable/1809766>>.

- MODIGLIANI, F.; MILLER, M. H. Corporate income taxes and the cost of capital: A correction. *The American Economic Review*, American Economic Association, v. 53, n. 3, p. 433–443, 1963. ISSN 00028282. Disponível em: <<http://www.jstor.org/stable/1809167>>.
- NARANJO, A.; NIMALENDRAN, M.; RYNGAERT, M. Time variation of ex-dividend day stock returns and corporate dividend capture: A reexamination. *Journal of Finance*, v. 55, n. 5, p. 2357–2372, October 2000.
- NAYAK, S.; PRABHALA, N. R. Disentangling the dividend information in splits: A decomposition using conditional event-study methods. *The Review of Financial Studies*, Oxford University Press. Sponsor: The Society for Financial Studies., v. 14, n. 4, p. pp. 1083–1116, 2001. ISSN 08939454. Disponível em: <<http://www.jstor.org/stable/2696736>>.
- NELSON, D. B. Conditional heteroskedasticity in asset returns: A new approach. *Econometrica*, v. 59, n. 2, p. 347–70, March 1991. Disponível em: <<http://ideas.repec.org/a/ecm/emetrp/v59y1991i2p347-70.html>>.
- NISSIM, D. Dividend changes and future profitability. *Journal of Finance*, v. 56, n. 6, p. 2111–2133, December 2001.
- NOLAN, J. P. *Stable Distributions - Models for Heavy Tailed Data*. Boston: Birkhäuser, 2010.
- NOREEN, E. The economics of ethics: A new perspective on agency theory. *Accounting, Organizations and Society*, v. 13, n. 4, p. 359–369, June 1988. Disponível em: <<http://ideas.repec.org/a/eee/aosoci/v13y1988i4p359-369.html>>.
- OFFICER, R. R. Distribution of stock returns. *Journal of the American Statistical Association*, v. 67, p. 807–812, 1972.
- OSTERMARK, R. Concurrent processing of heteroskedastic vector-valued mixture density models. *Journal of Applied Statistics*, Routledge Journals, Taylor & Francis Ltd, 4 Park Square, Milton Park, Abingdon Ox14 4rn, Oxfordshire, England, 37, n. 10, p. 1637–1659, 2010. ISSN 0266-4763.
- PARKS, J. M. L.; CONLON, E. J. Compensation contracts: do agency theory assumptions predict negotiated agreements ? *Academy of Management Journal*, v. 38, n. 3, p. 821–838, 1995.
- PATELL, J. Corporate forecasts of earnings per share and stock price behavior: Empirical tests. *Journal of Accounting Research*, v. 14, p. 246–276, 1976.
- POSEDEL, P. Properties and estimation of garch (1, 1) model. *Metodoloski zvezki*, v. 2, n. 2, p. 243–257, 2005.
- PRAETZ, P. D. The distribution of share price changes. *The Journal of Business*, The University of Chicago Press, v. 45, n. 1, p. pp. 49–55, 1972. ISSN 00219398. Disponível em: <<http://www.jstor.org/stable/2351598>>.
- RACHEV, S. *Stable Paretian Models in Finance*. [S.l.]: Wiley, 2000.
- RACHEV, S.; STOYANOV, S.; BIGLOVA, A.; FABOZZI, F. An empirical examination of daily stock return distributions for u.s. stocks. *Data Analysis and Decision Support: Studies in Classification, Data Analysis, and Knowledge Organization*, p. 269–281, 2005.

ROMBOUTS, J. V.; STENTOFT, L. Multivariate option pricing with time varying volatility and correlations. *Journal of Banking and Finance*, v. 35, n. 9, p. 2267 – 2281, 2011. ISSN 0378-4266. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S037842661100046X>>.

ROMBOUTS, J. V. K.; BOUADDI, M. Mixed Exponential Power Asymmetric Conditional Heteroskedasticity. *STUDIES IN NONLINEAR DYNAMICS AND ECONOMETRICS*, BERKELEY ELECTRONIC PRESS, 2809 TELEGRAPH AVENUE, STE 202, BERKELEY, CA 94705 USA, 13, n. 3, 2009. ISSN 1081-1826.

RONEN, J.; YAARI, V. Demand for the truth in principal-agent relationships. *Review of Accounting Studies*, Springer Netherlands, v. 12, p. 125–153, 2007. ISSN 1380-6653. 10.1007/s11142-006-9021-0. Disponível em: <<http://dx.doi.org/10.1007/s11142-006-9021-0>>.

SALANCIK, G. R.; PFEFFER, J. Effects of ownership and performance on executive tenure in u.s. corporations. *Academy of Management Journal*, JSTOR, v. 23, n. 4, p. 653–664, 1980. Disponível em: <<http://www.jstor.org/stable/255554>>.

SAMUELSON, P. A. Proof that properly anticipated prices fluctuate randomly. *Industrial Management Review*, p. 41–49, 1965.

SCHNATTER, F. S. *Finite mixture and Markov switching models*. [S.l.]: Springer Verlag, 2006.

SCHWARZ, G. Estimating the Dimension of a Model. *The Annals of Statistics*, Institute of Mathematical Statistics, v. 6, n. 2, p. 461–464, 1978. ISSN 00905364. Disponível em: <<http://dx.doi.org/10.2307/2958889>>.

SHIU-SHENG; CHEN. Predicting the bear stock market: Macroeconomic variables as leading indicators. *Journal of Banking and Finance*, v. 33, n. 2, p. 211 – 223, 2009. ISSN 0378-4266. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0378426608001544>>.

SMITH, A. *The Wealth of Nations (Bantam Classics)*. [S.l.]: Bantam Classics, 1776. Mass Market Paperback. ISBN 0553585975.

STARICA, C. *Is GARCH(1,1) as good a model as the Nobel prize accolades would imply?* [S.l.], nov. 2004. Disponível em: <<http://ideas.repec.org/p/wpa/wuwpem/0411015.html>>.

TEICHMOELLER, J. A note on the distribution of stock price changes. *Journal of the American Statistical Association*, v. 66, n. 334, p. 282–284, 1971.

TERASVIRTA, T. *Two Stylized Facts and the Garch (1,1) Model*. [S.l.], 1996. Disponível em: <<http://EconPapers.repec.org/RePEc:hhs:hastef:0096>>.

TITTERINGTON, D.; SMITH, A.; MAKOV, E. *Statistical Analysis of Finite Mixture Distributions*. Chichester: Wiley, 1985.

TOSI, H. L.; GOMEZ-MEJIA, L. R. The decoupling of ceo pay and performance: An agency theory perspective. *Administrative Science Quarterly*, v. 34, n. 2, p. 169–189, 1989. Disponível em: <<http://www.jstor.org/stable/2989894?origin=crossref>>.

TOUTENBURG, H. *Mathematical statistics with applications*, 4th edition: Mendenhall, w., wackerly, d.d., schaeffer, r.l., pws-kent publishing company, boston (1990), 752 pp, isbn 0-534-92026-8. *Computational Statistics & Data Analysis*, v. 13, n. 1, p. 109–109, 1992.

TUCKER, A. L.; POND, L. The probability distribution of foreign exchange price changes: Tests of candidate processes. *The Review of Economics and Statistics*, The MIT Press, v. 70, n. 4, p. pp. 638–647, 1988. ISSN 00346535. Disponível em: <<http://www.jstor.org/stable/1935827>>.

VOIT, J. *The statistical mechanics of financial markets*. 3. ed.. ed. Berlin [u.a.]: Springer, 2005. (Texts and monographs in physics). ISBN 978-3-540-26285-5.

WACKERLY, D. D.; III, W. M.; SCHEAFFER, R. L. *Mathematical Statistics with Applications*. sixth edition. [S.l.]: Duxbury Advanced Series, 2002.

WANG, Z.; SALIN, V.; HOOKER, N.; LEATHAM, D. Stock market reaction to food recalls: a garch application. *Applied Economics Letters*, v. 9, n. 15, p. 979–987, 2002. Disponível em: <<http://www.ingentaconnect.com/content/routledg/rael/2002/00000009/00000015/art00003>>.

WOODWARD, G.; ANDERSON, H. M. Does beta react to market conditions? estimates of 'bull' and 'bear' betas using a nonlinear market model with an endogenous threshold parameter. *Quantitative Finance*, v. 9, n. 8, p. 913–924, 2009. Disponível em: <<http://EconPapers.repec.org/RePEc:taf:quantf:v:9:y:2009:i:8:p:913-924>>.

WOOLRIDGE, J. R. Dividend changes and security prices. *Journal of Finance*, v. 38, n. 5, p. 1607–1615, 1983.

WU, C. F. J. On the convergence properties of the em algorithm. *The Annals of Statistics*, Institute of Mathematical Statistics, v. 11, n. 1, p. pp. 95–103, 1983. ISSN 00905364. Disponível em: <<http://www.jstor.org/stable/2240463>>.

ZHU, J.; YANG, H. Ruin theory for a markov regime-switching model under a threshold dividend strategy. *Insurance: Mathematics and Economics*, v. 42, n. 1, p. 311–318, 2008. Disponível em: <<http://EconPapers.repec.org/RePEc:eee:insuma:v:42:y:2008:i:1:p:311-318>>.

ZIVNEY, T. L.; THOMPSON, D. J. The specification and power of the sign test in measuring security price performance: Comments and analysis. *The Financial Review*, v. 24, n. 4, p. 581–88, November 1989.

ÍNDICE REMISSIVO

aglomeração de volatilidades, 33
algoritmo EM, 45
conclusao, 127
desvio da normalidade, 28
ensaios em finanças corporativas, 73
Estudo de Eventos, 14
fatos estilizados, 26
finanças corporativas, 21

identificabilidade, 59
misturas de distribuições, 22
misturas de distribuições em finanças, 31
misturas de modelos GARCH, 54
misturas finitas de distribuições, 40
referencial teórico, 26
simulated annealing, 49
taxonomia financeira, 19