

Universidade Federal do Rio Grande do Sul  
Instituto de Matemática  
Programa de Pós-Graduação em Matemática

**ESTIMAÇÃO EM PROCESSOS COM LONGA  
DEPENDÊNCIA, SAZONALIDADE E  
INOVAÇÕES NORMAIS OU  $\alpha$ -ESTÁVEIS**

Dissertação de Mestrado

**JOSIANE STEIN**

Porto Alegre, 04 de abril de 2012.

**Dissertação submetida por Josiane Stein\* , como requisito parcial para a obtenção do grau de Mestre em Ciência Probabilidade e Estatística, pelo Programa de Pós-Graduação em Matemática Pura, do Instituto de Matemática da Universidade Federal do Rio Grande do Sul.**

**Professor Orientador:**

**Prof. Dr. Cleber Bisognin**

**Banca examinadora:**

**Prof. Dr. Cleber Bisognin (PPGMAT - UFRGS)**

**Prof. Dr. Marcio Valk (UFRGS)**

**Prof. Dr. Rafael Rigão de Souza (PPGMAT - UFRGS)**

**Prof. Dr. Sílvia Regina Costa Lopes (PPGMAT - UFRGS)**

---

\*Bolsista da Coordenação de Aperfeiçoamento de Pessoal de Ensino Superior (CAPES).

# Agradecimentos

À Universidade Federal do Rio Grande do Sul, pelo ensino de qualidade e exce-lentes professores.

A todos professores que tive, se estou aqui hoje, devo a eles, me ensinaram tudo que sei. Em especial, quero agradecer ao professor Cleber Bisognin, pela orientação, compreensão, paciência e dedicação ao trabalho.

À Coordenação de Aperfeiçoamento de Pessoal de Ensino Superior (CAPES), pelo apoio financeiro.

Aos colegas do Programa de Pós-Graduação em Matemática da UFRGS, pelas inúmeras horas de estudo junto, companheirismo e atenção.

Aos amigos, que compreenderam minha ausência em muitos momentos, me apoiaram e deram força sempre.

À minha família, que sempre me apoiou em todas as decisões, pelo incentivo, compreensão, carinho, confiança, dedicação, enfim, por tudo.

# Resumo

Neste trabalho analisamos processos com a propriedade de longa dependência e sazonalidade, com inovações normais ou  $\alpha$ -estáveis. Os processos com inovações  $\alpha$ -estáveis apresentam a característica de ter variância infinita, além da propriedade de longa dependência. Apresentamos um estudo teórico de estimação paramétrica e semiparamétrica, demonstrando propriedades de novos estimadores paramétricos, baseados no estimador proposto por Fox e Taqqu (1986). Além disso, realizamos um estudo baseado em simulações de Monte Carlo, comparando os diversos estimadores definidos. Para a estimação semiparamétrica, utilizamos a metodologia de Geweke e Porter-Hudak (1983) e Reisen (1994), com suas versões robustas. Para a estimação paramétrica, empregamos as propostas de Fox e Taqqu (1986) e os novos estimadores sugeridos.

# Abstract

In this work we analyze processes with the property of long dependence and seasonality, with normal or  $\alpha$ -stable innovations. The processes with  $\alpha$ -stable innovations present infinite variance characteristic, besides the property of long dependence. We also consider a theoretical study of parametric and semi-parametric estimates, we prove properties of new parametric estimators, they're based on the estimator proposed by Fox and Taqqu (1986). Moreover, we accomplish a study based on Monte Carlo simulations comparing the several defined estimators. For the semi-parametric estimate, we use the methodology of Geweke and Porter-Hudak (1983) and Reisen (1994), with their robust versions. For the parametric estimate, we use the proposals of Fox and Taqqu (1986) and the new suggested estimators.

# Índice

<b>Introdução</b>	<b>1</b>
<b>1 Conceitos e Propriedades Básicas</b>	<b>4</b>
1.1 Análise de Séries Temporais . . . . .	4
1.2 Média, Autocovariância e Autocorrelação Amostrais . . . . .	8
1.3 Representação Espectral de Processos . . . . .	9
<b>2 Modelos para Séries Temporais</b>	<b>13</b>
2.1 Processos com Inovações Gaussianas . . . . .	14
2.2 Processos com Inovações $\alpha$ -estáveis . . . . .	20
2.3 Previsão . . . . .	32
<b>3 Estimação dos Parâmetros</b>	<b>37</b>
3.1 Estimadores Semiparamétricos . . . . .	38
3.1.1 Regressão Clássica e Robusta . . . . .	38
3.1.2 Estimador GPH . . . . .	40
3.1.3 Estimador BA . . . . .	44
3.2 Estimadores Paramétricos . . . . .	45
3.2.1 Estimador EMV . . . . .	46
3.2.2 Estimador FT . . . . .	47
3.2.3 Estimador FTmod . . . . .	51
3.2.4 Estimador FTS . . . . .	66

3.2.5	Estimador KM . . . . .	73
3.2.6	Estimador KMmod . . . . .	74
3.2.7	Estimador KMS . . . . .	75
3.2.8	Estimador KMSmod . . . . .	75
<b>4</b>	<b>Simulações</b>	<b>77</b>
4.1	Resultados para Processos com Inovações Gaussianas . . . . .	78
4.2	Resultados para Processos com Inovações $\alpha$ -estáveis . . . . .	97
<b>5</b>	<b>Conclusões e Trabalhos Futuros</b>	<b>125</b>
5.1	Conclusões . . . . .	125
5.2	Trabalhos Futuros . . . . .	127
<b>Referências Bibliográficas</b>		<b>128</b>
<b>Apêndices</b>		<b>131</b>
<b>A Resultados para Processos com Inovações Gaussianas</b>		<b>131</b>
<b>B Resultados para Processos com Inovações <math>\alpha</math>-estáveis</b>		<b>147</b>

# Introdução

Neste trabalho, apresentamos um estudo sobre séries temporais. Uma série temporal é um conjunto de observações ordenadas no tempo. Uma característica essencial em séries temporais é que observações próximas são dependentes e, em alguns casos, mesmo observações bastante espaçadas no tempo possuem dependência, e esse fenômeno é o que chamamos de longa dependência. O objetivo de analisar o comportamento das séries temporais é encontrar modelos que expliquem o seu comportamento, sendo possível assim, fazer previsões dos futuros valores. Encontrar modelos que expliquem a série temporal possibilita descrever efetivamente o seu comportamento. Ser capaz de prever observações futuras da série possibilita fazer planos a respeito do fenômeno estudado e tomar decisões apropriadas.

Séries temporais são aplicadas nas mais diversas áreas do conhecimento. Podem ser aplicadas em economia, por exemplo, em séries que descrevem os preços diários de ações ou taxas mensais de desemprego ou taxas de exportações mensais. Também podem ser aplicadas em epidemiologia, descrevendo o número de casos contabilizados de AIDS por mês, ou de outras doenças. Outra aplicação bastante útil é em meteorologia, no registro de temperaturas ou de marés.

Existem diversos processos já propostos pela literatura para modelar séries temporais. Neste trabalho, iremos abordar dois grandes grupos de processos: processos com distribuição normal e processos com distribuição  $\alpha$ -estável.

Dentre os processos que serão apresentados neste trabalho, encontram-se os processos ARFIMA e SARFIMA com processo de inovação tendo distribuição normal. Estes processos possuem a propriedade da longa dependência. Tal propriedade é caracterizada por função de autocovariância não absolutamente somável, no domínio do tempo, e função densidade espectral ilimitada em zero, no domínio das frequências.

No outro grupo de processos que será estudado, encontram-se os processos ARFIMA e SARFIMA com processo de inovação tendo distribuição  $\alpha$ -estável. Estes, além de apresentarem longa dependência, tem a característica de apresentar variância infinita.

Processos ARFIMA com variância finita foram introduzidos por Granger e Joyeux (1980) e Hosking (1981), e têm sido alvo de muitos estudos. No entanto, muitas séries temporais reais possuem alta variabilidade, sendo necessária a utilização de novos processos, que apresentem variância infinita. Neste sentido, tem aumentado muito o interesse em estudar processos com distribuição  $\alpha$ -estável, introduzidos inicialmente por Samorodnitsky e Taqqu (1994) e Kokoszka e Taqqu (1995).

O objetivo deste trabalho é utilizar diversos estimadores semiparamétricos e paramétricos para a estimação dos parâmetros nos modelos considerados. Dentre as metodologias semiparamétricas que serão abordadas, para processos com inovações normais, estão a metodologia proposta por Geweke e Porter-Hudak (1983) utilizando regressão clássica e robusta, além de uma modificação do estimador anterior utilizando o periodograma suavizado de covariâncias, proposta por Reisen (1994). Para a estimação semiparamétrica de processos com inovações  $\alpha$ -estáveis iremos propor modificações aos estimadores descritos anteriormente, utilizando o periodograma normalizado e um novo periodograma normalizado suavizado de correlações. As metodologias paramétricas aplicadas a processos com inovações normais que serão estudadas são: o método de máxima verossimilhança exata e aproximada, esta última proposta por Fox e Taqqu (1986). Consideraremos, também, duas modificações ao estimador proposto por Fox e Taqqu (1986). Estas duas modificações ainda não são conhecidas na literatura e estão sendo sugeridas neste trabalho. Para estes novos estimadores sugeridos, provamos a consistência e a distribuição assintótica. As metodologias paramétricas que serão aplicadas a processos com inovações  $\alpha$ -estáveis são: a proposta de Klüppelberg e Mikosch (1996) e três modificações novas deste estimador, utilizando um novo periodograma, que será definido no trabalho. Além disso, iremos sugerir dois métodos de previsão para séries temporais, um para processos com distribuição normal e outro para processos com distribuição  $\alpha$ -estável.

Este trabalho encontra-se organizado da seguinte forma. No Capítulo 1 iremos apresentar conceitos iniciais sobre séries temporais, que serão utilizados nos capítulos posteriores. No Capítulo 2 apresentamos os modelos ARMA, ARIMA, ARFIMA, SARFIMA com distribuições normais e  $\alpha$ -estáveis. Além disso, apresentamos dois modelos de previsão. No Capítulo 3 apresentamos diversos métodos de estimação,

paramétricos e semiparamétricos. Dentro os estimadores apresentados, vários já são conhecidos na literatura, mas propomos alguns novos estimadores, visando a melhora na estimação. No Capítulo 4 descrevemos o processo de simulação utilizado, bem como os resultados encontrados. No Capítulo 5 apresentamos as conclusões e propostas para trabalhos futuros.

# Capítulo 1

## Conceitos e Propriedades Básicas

Vamos apresentar neste capítulo algumas definições, teoremas e proposições fundamentais à compreensão do restante deste trabalho. Na Seção 1.1 iremos abordar definições gerais de processos estocásticos, séries temporais, estacionariedade, funções média, autocovariância e autocorrelação e propriedades das mesmas. Na Seção 1.2 apresentamos os estimadores das funções média, autocovariância e autocorrelação. Finalmente, na Seção 1.3, abordamos a análise espectral de processos estocásticos, definindo a função densidade espectral, o periodograma, o periodograma suavizado de covariâncias e suas propriedades.

### 1.1 Análise de Séries Temporais

Começaremos com algumas definições e propriedades básicas sobre análise de séries temporais.

**Definição 1.1.** Sejam  $(\Omega, \mathcal{A}, \mathbb{P})$  um espaço de probabilidade,  $(\mathcal{S}, \sigma)$  um espaço mensurável e  $\mathcal{T}$  um conjunto de índices. Definimos um *Processo Estocástico* como uma coleção de funções mensuráveis de  $(\Omega, \mathcal{A}, \mathbb{P})$  em  $(\mathcal{S}, \sigma)$  indexadas por  $\mathcal{T}$ .

Lembre que um espaço de probabilidade  $(\Omega, \mathcal{A}, \mathbb{P})$  é composto por  $\Omega$  o espaço amostral,  $\mathcal{A}$  uma  $\sigma$ -álgebra e  $\mathbb{P}$  uma medida de probabilidade. Um espaço mensurável  $(\mathcal{S}, \sigma)$  é um conjunto  $\mathcal{S}$  dotado de uma  $\sigma$ -álgebra. Em geral, temos  $\mathcal{S} = \mathbb{R}$  e  $\sigma = \beta(\mathbb{R})$  (borelianos de  $\mathbb{R}$ ), dessa forma, um processo estocástico será uma coleção

de variáveis aleatórias, indexada por  $\mathcal{T} = \mathbb{N}$  ou  $\mathbb{Z}$  ou  $\mathbb{R}$ , em um espaço de probabilidades  $(\Omega, \mathcal{A}, \mathbb{P})$ . Série temporal é uma realização do processo, ou seja, é uma das possíveis trajetórias da família de variáveis aleatórias  $\{X_t\}_{t \in \mathcal{T}}$ .

Se  $\mathcal{T}$  for finito ou enumerável, como  $\mathcal{T} = \{t_1, \dots, t_n\}$ ,  $\mathcal{T} = \mathbb{Z}$  ou  $\mathcal{T} = \mathbb{N}$ , diz-se que o processo tem parâmetro discreto. Se  $\mathcal{T}$  for um intervalo de  $\mathbb{R}$ , ou mesmo o próprio  $\mathbb{R}$ , obtemos um processo com parâmetro contínuo.

A seguir apresentamos a definição de *distribuições finito dimensionais* de um processo estocástico.

**Definição 1.2.** Sejam  $n \in \mathbb{N}$  e  $t_1, t_2, \dots, t_n$  elementos quaisquer de  $\mathcal{T}$ . As *distribuições finito dimensionais* do processo estocástico  $\{X_t\}_{t \in \mathcal{T}}$  são dadas por

$$\mathcal{F}(x_1, x_2, \dots, x_n; t_1, t_2, \dots, t_n) = \mathbb{P}(X_{t_1} \leq x_1, \dots, X_{t_n} \leq x_n) \quad (1.1)$$

Temos que, um processo estocástico estará especificado, se conhecermos todas as suas distribuições finito dimensionais. Uma família de distribuições finito dimensionais definida a partir de um processo estocástico, satisfaz duas condições de compatibilidade:

CC1) Se  $\phi : \{1, \dots, n\} \rightarrow \{1, \dots, n\}$  é uma permutação, então

$$\mathcal{F}(x_1, x_2, \dots, x_n; t_1, t_2, \dots, t_n) = \mathcal{F}(x_{\phi(1)}, x_{\phi(2)}, \dots, x_{\phi(n)}; t_{\phi(1)}, t_{\phi(2)}, \dots, t_{\phi(n)}).$$

CC2) Se  $t_{n+1} \in \mathcal{T}$ , então

$$\mathcal{F}(x_1, x_2, \dots, x_n, \infty; t_1, t_2, \dots, t_n, t_{n+1}) = \mathcal{F}(x_1, x_2, \dots, x_n; t_1, t_2, \dots, t_n).$$

Também pode-se demonstrar, a partir do teorema de existência de Kolmogorov (ver Billingsley, 1995), que se tivermos um conjunto de distribuições finito dimensionais satisfazendo as condições CC1 e CC2, existe um processo estocástico com tais distribuições finito dimensionais associadas.

Como, na maioria dos casos, não conhecemos as distribuições finito dimensionais, precisamos de outras maneiras para obter informações sobre o processo a ser estudado. Duas dessas maneiras são as funções média e autocovariância de um processo, que estão definidas a seguir.

**Definição 1.3.** A *função média* de um processo  $\{X_t\}_{t \in \mathcal{T}}$  é definida por

$$\mu(t) = \mathbb{E}(X_t) \quad (1.2)$$

em que  $t \in \mathcal{T}$ .

**Definição 1.4.** A função de autocovariância de um processo  $\{X_t\}_{t \in \mathcal{T}}$  é

$$\gamma_X(t_1, t_2) = Cov(X_{t_1}, X_{t_2}) = \mathbb{E}(X_{t_1}X_{t_2}) - \mathbb{E}(X_{t_1})\mathbb{E}(X_{t_2}) \quad (1.3)$$

em que  $t_1, t_2 \in \mathcal{T}$ .

**Definição 1.5.** A função de autocorrelação de um processo  $\{X_t\}_{t \in \mathcal{T}}$  é

$$\rho_X(t_1, t_2) = \frac{\gamma_X(t_1, t_2)}{\sqrt{Var(X_{t_1})}\sqrt{Var(X_{t_2})}} \quad (1.4)$$

em que  $t_1, t_2 \in \mathcal{T}$ .

Em particular, na Definição 1.4, se tivermos  $t_1 = t_2 = t$ , a função de autocovariância nos dá a variância do processo:

$$\gamma_X(t, t) = Var(X_t) = \mathbb{E}(X_t^2) - \mathbb{E}^2(X_t), \quad \text{para todo } t \in \mathcal{T}. \quad (1.5)$$

A seguir veremos a definição de processos fortemente estacionários.

**Definição 1.6.** Um processo estocástico é dito ser *fortemente estacionário* se todas as distribuições finito dimensionais permanecem as mesmas sob translações no tempo, ou seja,

$$\mathcal{F}(x_1, \dots, x_n; t_1 + \tau, \dots, t_n + \tau) = \mathcal{F}(x_1, \dots, x_n; t_1, \dots, t_n), \quad (1.6)$$

para todo  $t_1, \dots, t_n, t_1 + \tau, \dots, t_n + \tau$  pertencentes à  $\mathcal{T}$  e  $x_1, \dots, x_n \in \mathbb{R}$ .

A Definição 1.6 é um tanto exigente e muito difícil de ser verificada na prática. Assim, apresentamos a definição de processos estocásticos fracamente estacionários.

**Definição 1.7.** Um processo estocástico é *fracamente estacionário* se e somente se:

- a)  $\mathbb{E}(X_t) = \mu(t) = \mu$ , constante  $\forall t \in \mathcal{T}$ ;
- b)  $\mathbb{E}(|X_t|^2) < \infty$ ,  $\forall t \in \mathcal{T}$ ;
- c)  $\gamma_X(t_1, t_2) = \gamma_X(t_1 + t, t_2 + t)$ , para  $t_1, t_2, t_1 + t, t_2 + t \in \mathcal{T}$ .

Neste trabalho, estaremos interessados apenas nos processos que satisfazem a Definição 1.7. Para simplificar a denominação, chamamos estes processos simplesmente de estacionários. Também iremos considerar o conjunto  $\mathcal{T} = \mathbb{Z} = \{\dots, -3, -2, -1, 0, 1, 2, 3, \dots\}$ .

**Observação 1.1.** Se  $\{X_t\}_{t \in \mathbb{Z}}$  é um processo estacionário, então  $\gamma_X(t_1, t_2) = \gamma_X(t_1 - t_2, 0)$ ,  $\forall t_1, t_2 \in \mathbb{Z}$ . Assim, é conveniente definirmos a *função de autocovariância* em uma única variável,

$$\gamma_X(h) = \gamma_X(h, 0) = Cov(X_{t+h}, X_t), \quad (1.7)$$

para todo  $t, h \in \mathbb{Z}$ .

A *função de autocorrelação* é definida analogamente,

$$\rho_X(h) = \frac{\gamma_X(h)}{\gamma_X(0)}, \quad (1.8)$$

para todo  $t, h \in \mathbb{Z}$ .

A seguir iremos apresentar algumas propriedades das funções de autocovariância e autocorrelação.

**Proposição 1.1.** *Seja  $\{X_t\}_{t \in \mathbb{Z}}$  um processo estacionário real discreto, de média zero, então as funções  $\gamma_X(h)$  e  $\rho_X(h)$  satisfazem as seguintes propriedades:*

- a)  $Var(X_t) = \gamma_X(0) > 0$ , para todo  $t \in \mathbb{Z}$ ;
- b)  $\gamma_X(-h) = \gamma_X(h)$ , para todo  $h \in \mathbb{N}$  ;
- c)  $|\gamma_X(h)| \leq \gamma_X(0)$ , para todo  $h \in \mathbb{Z}$ ;
- d)  $\rho_X(0) = 1$ ;
- e)  $\rho_X(-h) = \rho_X(h)$ , para todo  $h \in \mathbb{N}$ ;
- f)  $|\rho_X(h)| \leq 1$ , para todo  $h \in \mathbb{Z}$ .

**Observação 1.2.** Podemos supor, sem perda de generalidade, que o processo tem média zero, pois, caso contrário, basta considerarmos o processo  $\{X_t - \mu\}_{t \in \mathbb{Z}}$ , em que  $\mu = \mathbb{E}(X_t)$ , para todo  $t \in \mathbb{Z}$ .

## 1.2 Média, Autocovariância e Autocorrelação Amostrais

Podemos caracterizar um processo estacionário Gaussiano por sua média  $\mu$ , funções de autocovariância  $\gamma_X(\cdot)$  e de autocorrelação  $\rho_X(\cdot)$ . Como, na prática, não conhecemos previamente estas funções, precisamos de estimadores para estes valores. A seguir definimos estimadores para  $\mu$ ,  $\gamma_X(\cdot)$  e  $\rho_X(\cdot)$ , obtidos pelo método dos momentos, para um processo estacionário  $\{X_t\}_{t \in \mathbb{Z}}$  com

- a)  $\mathbb{E}(X_t) = \mu$ , para todo  $t \in \mathbb{Z}$ ;
- b)  $Var(X_t) = \sigma_X^2$ , para todo  $t \in \mathbb{Z}$ ;
- c)  $Cov(X_{t+h}X_t) = \gamma_X(h)$ , para todo  $t \in \mathbb{Z}$ .

Consideramos uma série temporal com  $N$  observações,  $\{X_t\}_{t=1}^N$ , obtida a partir do processo  $\{X_t\}_{t \in \mathbb{Z}}$ .

**Definição 1.8.** Um estimador não viciado para a média  $\mu$  é a *média amostral*, definida por

$$\bar{X} = \frac{1}{N} \sum_{i=1}^N X_i, \quad (1.9)$$

que é a *média* das  $N$  observações obtidas da série temporal  $\{X_t\}_{t=1}^N$ .

**Definição 1.9.** Um estimador da função de autocovariância de ordem  $h$  é a *função de autocovariância amostral*, dada por

$$\hat{\gamma}_X(h) = \frac{1}{N} \sum_{i=1}^{N-h} (X_i - \bar{X})(X_{i+h} - \bar{X}), \quad (1.10)$$

ou

$$\hat{\gamma}_X(h) = \frac{1}{N-h} \sum_{i=1}^{N-h} (X_i - \bar{X})(X_{i+h} - \bar{X}), \quad \text{em que } h = 0, 1, 2, \dots \quad (1.11)$$

**Observação 1.3.** Neste trabalho, iremos apenas utilizar o estimador com denominador  $N$ , visto que este apresenta menor variância (para maiores detalhes ver Wei, 1990).

**Definição 1.10.** O estimador da função de autocorrelação de ordem  $h$  é a *função de autocorrelação amostral*, dada por

$$\hat{\rho}_X(h) = \frac{\hat{\gamma}_X(h)}{\hat{\gamma}_X(0)} = \frac{\sum_{i=1}^{N-h} (X_i - \bar{X})(X_{i+h} - \bar{X})}{\sum_{i=1}^N (X_i - \bar{X})^2}, \quad \text{para } h \in \mathbb{N}. \quad (1.12)$$

Para obter uma análise com maiores detalhes sobre as Definições 1.8, 1.9 e 1.10, ver Wei (1990) e Brockwell e Davis (1991). Na próxima seção iremos apresentar conceitos sobre representação espectral de processos.

### 1.3 Representação Espectral de Processos

A análise espectral é uma área interessada em entender melhor o comportamento das séries temporais, tais como periodicidades e longa dependência. Diversos campos do conhecimento aplicam a análise espectral, como nas Engenharias, Física, Economia, Meteorologia, entre outros. A seguir veremos o conceito de função densidade espectral, que é utilizada para a análise espectral de séries temporais estacionárias. A função densidade espectral também é conhecida, simplesmente, como espectro, e, nada mais é, do que o estudo das séries temporais no domínio da frequência. De fato, a função densidade espectral é a transformada de Fourier da função de autocovariância do processo.

**Definição 1.11.** Seja  $\{X_t\}_{t \in \mathbb{Z}}$  um processo estocástico estacionário real, com função de autocovariância absolutamente somável, ou seja,  $\sum_{h \in \mathbb{Z}} |\gamma_X(h)| < \infty$ . Então, a *função densidade espectral* ou *espectro* é definida como a transformada discreta de Fourier de  $\gamma_X(h)$ , isto é,

$$f_X(\lambda) = \frac{1}{2\pi} \sum_{h=-\infty}^{\infty} \gamma_X(h) e^{-i\lambda h}, \quad \lambda \in [-\pi, \pi]. \quad (1.13)$$

**Proposição 1.2.** A função densidade espectral de um processo estacionário real  $\{X_t\}_{t \in \mathbb{Z}}$ , pode ser escrita da seguinte forma

$$f_X(\lambda) = \frac{1}{2\pi} [\gamma_X(0) + 2 \sum_{h=1}^{\infty} \gamma_X(h) \cos(\lambda h)], \quad \lambda \in [-\pi, \pi]. \quad (1.14)$$

**Demonstração:** Pela Definição 1.11, temos que

$$\begin{aligned}
f_X(\lambda) &= \frac{1}{2\pi} \sum_{h=-\infty}^{\infty} \gamma_X(h) e^{-i\lambda h} \\
&= \frac{1}{2\pi} \sum_{h=-\infty}^{\infty} \gamma_X(h) [\cos(\lambda h) - i \sin(\lambda h)] \\
&= \frac{1}{2\pi} \sum_{h=-\infty}^{\infty} \gamma_X(h) \cos(\lambda h) - \frac{i}{2\pi} \sum_{h=-\infty}^{\infty} \gamma_X(h) \sin(\lambda h) \\
&= \frac{1}{2\pi} \gamma_X(0) + \frac{2}{2\pi} \sum_{h=1}^{\infty} \gamma_X(h) \cos(\lambda h) - \frac{i}{2\pi} \sum_{h=-\infty}^{-1} \gamma_X(h) \sin(\lambda h) \\
&\quad - \frac{i}{2\pi} \sum_{h=1}^{\infty} \gamma_X(h) \sin(\lambda h) \\
&= \frac{1}{2\pi} \gamma_X(0) + \frac{1}{\pi} \sum_{h=1}^{\infty} \gamma_X(h) \cos(\lambda h) + \frac{i}{2\pi} \sum_{h=1}^{\infty} \gamma_X(h) \sin(\lambda h) \\
&\quad - \frac{i}{2\pi} \sum_{h=1}^{\infty} \gamma_X(h) \sin(\lambda h) \\
&= \frac{1}{2\pi} [\gamma_X(0) + 2 \sum_{h=1}^{\infty} \gamma_X(h) \cos(\lambda h)].
\end{aligned}$$

■

**Observação 1.4.** A função de autocovariância de um processo estacionário  $\{X_t\}_{t \in \mathbb{Z}}$  pode ser obtida através da transformada discreta inversa de Fourier de  $f_X(\cdot)$ , ou seja

$$\gamma_X(h) = \int_{-\pi}^{\pi} f_X(\lambda) e^{i\lambda h} d\lambda. \quad (1.15)$$

Portanto,  $f_X(\cdot)$  e  $\gamma_X(\cdot)$  formam um par de Fourier.

O teorema a seguir apresenta algumas propriedades básicas da função densidade espectral de processos estocásticos estacionários reais.

**Teorema 1.1.** *Considere um processo estacionário real  $\{X_t\}_{t \in \mathbb{Z}}$  com função de autocovariância absolutamente somável, então a função densidade espectral  $f_X(\lambda)$  é limitada, não negativa e uniformemente contínua. Além disso,  $f_X(\lambda)$  é par e periódica com período  $2\pi$ .*

Para maiores detalhes e demonstração, ver Morettin e Toloi (2004).

A definição a seguir apresenta um estimador para a função densidade espectral.

**Definição 1.12.** Considere uma série temporal com  $N$  observações,  $\{X_t\}_{t=1}^N$ , obtida a partir do processo estacionário  $\{X_t\}_{t \in \mathbb{Z}}$ . A *função periodograma*, denotada por  $I_N(\cdot)$ , é definida por

$$I_N(\lambda) = \frac{1}{2\pi N} \left| \sum_{t=1}^N X_t e^{-i\lambda t} \right|^2, \quad \forall \in [0, \pi]. \quad (1.16)$$

**Proposição 1.3.** A função periodograma de uma série temporal estacionária é dada por

$$I_N(\lambda) = \frac{1}{2\pi} \sum_{|h| < N} \hat{\gamma}_X(h) e^{-i\lambda h} \quad \forall \in [-\pi, \pi]. \quad (1.17)$$

A demonstração da Proposição 1.3 pode ser encontrada em Morettin (2004).

Lembre que um estimador é assintoticamente não viesado, quando a esperança do estimador converge ao parâmetro a ser estimado. Além disso, dizemos que um estimador é consistente, quando ele converge em probabilidade ao parâmetro a ser estimado. Assim, a função periodograma definida na equação (1.16) é um estimador assintoticamente não viesado do espectro, entretanto, é não consistente. Assim, mesmo aumentando o número de observações, a variância de  $I_N(\lambda)$  não decresce. Em virtude disso, foram propostos na literatura estimadores alternativos com a propriedade de consistência. Iremos definir, a seguir, um novo periodograma, que é não viesado e consistente para a função densidade espectral.

**Definição 1.13.** A função periodograma suavizado de covariâncias, denotada por  $I_S(\lambda)$ , é definida como

$$I_S(\lambda) = \frac{1}{2\pi} \sum_{h=-(N-1)}^{N+1} \omega_M(h) \hat{\gamma}_X(h) e^{-i\lambda h}, \quad (1.18)$$

em que,  $\hat{\gamma}_X(\cdot)$  é a função de covariâncias do processo e  $\omega_M(\cdot)$  é uma sequência de pesos ou janela, satisfazendo para um natural  $M < N$ ,

- a)  $0 \leq \omega_M(h) \leq \omega_M(0) = 1$ ;
- b)  $\omega_M(h) = \omega_M(-h)$ , para todo  $h$ ;
- c)  $\omega_M(h) = 0, |h| \geq M$ .

**Observação 1.5.** Para o estimador  $I_S(\cdot)$  ser um estimador da função densidade espectral consistente, precisamos impor algumas condições sobre a escolha de  $M$ :

- a)  $M$  é uma função de  $N$  tal que  $M \rightarrow \infty$ ;
- b)  $\frac{M}{N} \rightarrow 0$  quando  $N \rightarrow \infty$ .

Geralmente considera-se  $M = N^\beta$ ,  $\beta < 1$ . Neste trabalho, consideraremos  $\beta = 0.9$  fixo.

Várias janelas já foram sugeridas na literatura, como a janela retangular, a janela de Bartlett, a janela de Daniell, e janela de Blackman-Tukey, a janela de Parzen entre outras (para maiores detalhes ver Brockwell e Davis, 1991). Neste trabalho utilizaremos a janela de Bartlett, que será definida na Subseção 3.1.3.

# Capítulo 2

## Modelos para Séries Temporais

Neste capítulo iremos apresentar alguns modelos para séries temporais que serão estudados ao longo da dissertação. Inicialmente definiremos um modelo proposto por Box e Jenkins (1976), este é denominado processo auto regressivo integrado de médias móveis, denotado por ARIMA( $p, d, q$ ), que é obtido de termos de equações de diferenças lineares com coeficientes constantes. Em seguida, iremos definir uma generalização dos modelos ARIMA, chamados de modelos ARFIMA( $p, d, q$ ), denominados processos auto regressivos fracionariamente integrados de médias móveis, que foram propostos por Granger e Joyeux (1980) e Hosking (1981). Sua função densidade espectral é ilimitada apenas na frequência zero. Os processos ARFIMA( $p, d, q$ ) são utilizados para modelar séries que apresentam a propriedade de longa dependência. A definição técnica de longa dependência será apresentada mais adiante, neste capítulo, mas, intuitivamente, longa dependência quer dizer que mesmo observações distantes no tempo possuem dependência entre si.

Muitos fenômenos reais, além de apresentarem a característica de longa dependência, apresentam sazonalidade. Sazonalidade quer dizer que o processo se repete durante um certo período de tempo fixo, sua duração é definida como período sazonal e representada por  $s$ . Este tipo de processo recebe o nome de SARFIMA, e é uma generalização do processo ARFIMA. Além disso, sua função densidade espectral é ilimitada em um número finito de frequências em  $[0, \pi]$ , chamadas frequências sazonais.

Os processos ARFIMA e SARFIMA serão apresentados em duas seções. Na Seção 2.1, conforme a definição tradicional, com inovações Gaussianas e, na Seção

2.2, com inovações tendo distribuição  $\alpha$ -estável simétrica.

Antes de definirmos os processos ARFIMA e SARFIMA, é conveniente introduzirmos as seguintes notações  $\mathbb{Z}_\geq = \{k \in \mathbb{Z}; k \geq 0\}$  e  $\mathbb{Z}_\leq = \{k \in \mathbb{Z}; k \leq 0\}$ .

## 2.1 Processos com Inovações Gaussianas

Iniciamos esta seção apresentando a definição de ruído branco.

**Definição 2.1.** Uma sequência de variáveis aleatórias  $\{\varepsilon_t\}_{t \in \mathbb{Z}}$  é dita ser um ruído branco se

$$\mathbb{E}(\varepsilon_t) = 0, \quad \text{Var}(\varepsilon_t) = \sigma_\varepsilon^2 \quad \text{e} \quad \gamma_\varepsilon(h) = \begin{cases} \sigma_\varepsilon^2, & \text{se } h = 0, \\ 0, & \text{se } h \neq 0. \end{cases}$$

Se as variáveis aleatórias possuem distribuição normal, dizemos que o processo  $\{\varepsilon_t\}_{t \in \mathbb{Z}}$  é um ruído branco Gaussiano.

Antes de definirmos os processos ARFIMA e SARFIMA, é necessário definirmos alguns operadores, que serão utilizados ao longo do texto.

**Definição 2.2.** Seja  $\{X_t\}_{t \in \mathbb{Z}}$  um processo estocástico qualquer.

a) Operador translação para o passado, denotado por  $\mathcal{B}$ , é definido por

$$\mathcal{B}(X_t) = X_{t-1}, \dots, \mathcal{B}^m(X_t) = X_{t-m}; \quad (2.1)$$

b) Operador diferença, denotado por  $\nabla$ , é definido por

$$\nabla(X_t) = X_t - X_{t-1} = (1 - \mathcal{B})(X_t). \quad (2.2)$$

Logo temos que  $\nabla = 1 - \mathcal{B}$ .

c) Para qualquer  $D > -1$ , definimos o operador diferença fracionária sazonal por

$$\begin{aligned} \nabla_s^D &= (1 - \mathcal{B}^s)^D = \sum_{k=0}^{\infty} \binom{D}{k} (-\mathcal{B}^s)^k \\ &= 1 - D\mathcal{B}^s + \frac{D(D-1)}{2!} \mathcal{B}^{2s} - \frac{D(D-1)(D-2)}{3!} \mathcal{B}^{3s} + \dots \quad (2.3) \end{aligned}$$

em que

$$\binom{d}{k} = \frac{\Gamma(d+1)}{\Gamma(k+1)\Gamma(d-k+1)},$$

na qual  $\Gamma(\cdot)$  é a função Gama, definida por

$$\Gamma(x) \equiv \begin{cases} \int_0^\infty t^{x-1} e^{-t} dt, & \text{se } x > 0, \\ \infty, & \text{se } x = 0, \\ x^{-1}\Gamma(1+x), & \text{se } x < 0. \end{cases}$$

Se tivermos  $D = d$  e  $s = 1$ , então  $\nabla^d$  é o operador diferença fracionária.

A seguir, definimos o processo auto regressivo de médias móveis, denotado por ARMA  $(p, q)$ .

**Definição 2.3.** Se um processo estocástico  $\{X_t\}_{t \in \mathbb{Z}}$  satisfaz a seguinte equação

$$\phi(\mathcal{B})(X_t - \mu) = \theta(\mathcal{B})\varepsilon_t, \quad t \in \mathbb{Z}, \quad (2.4)$$

em que  $\mu$  é a média do processo,  $\{\varepsilon_t\}_{t \in \mathbb{Z}}$  é um processo ruído branco,  $\phi(\cdot)$  e  $\theta(\cdot)$  são polinômios, com coeficientes constantes reais, de ordem  $p$  e  $q$  (inteiros não negativos), respectivamente, dados por

$$\phi(\mathcal{B}) = 1 - \phi_1\mathcal{B} - \phi_2\mathcal{B}^2 - \cdots - \phi_p\mathcal{B}^p; \quad (2.5)$$

$$\theta(\mathcal{B}) = 1 - \theta_1\mathcal{B} - \theta_2\mathcal{B}^2 - \cdots - \theta_q\mathcal{B}^q. \quad (2.6)$$

Então dizemos que  $\{X_t\}_{t \in \mathbb{Z}}$  é um processo auto regressivo de médias móveis de ordem  $p$  e  $q$ , denotado por ARMA( $p, q$ ).

As duas definições a seguir podem ser aplicadas aos processos ARMA( $p, q$ ), mas também a outros processos que ainda serão definidos.

**Definição 2.4.** Um processo  $\{X_t\}_{t \in \mathbb{Z}}$  é dito ser *causal* se existe uma sequência de constantes  $\{\psi_j\}_{j \in \mathbb{Z}_\geq}$  tal que  $\sum_{j \in \mathbb{Z}_\geq} |\psi_j| < \infty$  e

$$X_t = \sum_{j \in \mathbb{Z}_\geq} \psi_j \varepsilon_{t-j}, \quad t \in \mathbb{Z}. \quad (2.7)$$

**Definição 2.5.** Um processo  $\{X_t\}_{t \in \mathbb{Z}}$  é dito ser *inversível* se existe uma sequência

de constantes  $\{\pi_j\}_{j \in \mathbb{Z}_\geq}$  tal que  $\sum_{j \in \mathbb{Z}_\geq} |\pi_j| < \infty$  e

$$\varepsilon_t = \sum_{j \in \mathbb{Z}_\geq} \pi_j X_{t-j}, \quad t \in \mathbb{Z}. \quad (2.8)$$

Os dois teoremas seguintes apresentam condições para que um processo ARMA  $(p, q)$  seja causal e inversível. As demonstrações podem ser encontradas em Brockwell e Davis (1991).

**Teorema 2.1.** *Seja  $\{X_t\}_{t \in \mathbb{Z}}$  um processo ARMA( $p, q$ ) em que os polinômios  $\phi(\cdot)$  e  $\theta(\cdot)$  não possuem raízes em comum. Então  $\{X_t\}_{t \in \mathbb{Z}}$  é causal se e somente se  $\phi(z) \neq 0$ , para todo  $z \in \mathbb{C}$  tal que  $|z| \leq 1$ . Os coeficientes  $\{\psi_j\}_{j \in \mathbb{Z}_\geq}$  que satisfazem a equação (2.7) são determinados pela relação*

$$\psi(z) = \sum_{j \in \mathbb{Z}_\geq} \psi_j z^j = \frac{\theta(z)}{\phi(z)}, \quad \text{em que } |z| \leq 1. \quad (2.9)$$

**Teorema 2.2.** *Seja  $\{X_t\}_{t \in \mathbb{Z}}$  um processo ARMA( $p, q$ ) em que os polinômios  $\phi(\cdot)$  e  $\theta(\cdot)$  não possuem raízes em comum. Então  $\{X_t\}_{t \in \mathbb{Z}}$  é inversível se e somente se  $\theta(z) \neq 0$ , para todo  $z \in \mathbb{C}$  tal que  $|z| \leq 1$ . Os coeficientes  $\{\pi_j\}_{j \in \mathbb{Z}_\geq}$  que satisfazem a equação (2.8) são determinados pela relação*

$$\pi(z) = \sum_{j \in \mathbb{Z}_\geq} \pi_j z^j = \frac{\phi(z)}{\theta(z)}, \quad \text{em que } |z| \leq 1. \quad (2.10)$$

O teorema seguinte apresenta a função densidade espectral de um processo ARMA( $p, q$ ) e sua demonstração pode ser encontrada em Brockwell e Davis (1991).

**Teorema 2.3.** *Seja  $\{X_t\}_{t \in \mathbb{Z}}$  um processo ARMA( $p, q$ ) satisfazendo a Definição 2.3 onde os polinômios  $\phi(\cdot)$  e  $\theta(\cdot)$  não possuem raízes em comum no círculo unitário. Então  $\{X_t\}_{t \in \mathbb{Z}}$  possui função densidade espectral dada por*

$$f_X(\lambda) = \frac{\sigma_\varepsilon^2}{2\pi} \frac{|\theta(e^{-i\lambda})|^2}{|\phi(e^{-i\lambda})|}, \quad \text{em que } \lambda \in [0, \pi]. \quad (2.11)$$

Os modelos ARMA( $p, q$ ) são utilizados para descrever séries estacionárias, mas muitas séries não possuem essa característica. Algumas séries tornam-se estacionárias se as diferenciarmos. Assim, definimos os modelos ARIMA( $p, d, q$ ) que são uma generalização dos modelos ARMA( $p, q$ ), propostos por Box e Jenkins (1976).

**Definição 2.6.** Um processo  $\{X_t\}_{t \in \mathbb{Z}}$  é dito ser um processo auto regressivo integrado de médias móveis de ordem  $(p, d, q)$ , com média  $\mu$ , denotado por ARIMA( $p, d, q$ ), se satisfaz a equação

$$\phi(\mathcal{B})(1 - \mathcal{B})^d(X_t - \mu) = \theta(\mathcal{B})\varepsilon_t, \quad \text{em que } t \in \mathbb{Z}, \quad (2.12)$$

em que  $(1 - \mathcal{B})^d(X_t - \mu)$  é um processo ARMA( $p, q$ ), com  $d \in \mathbb{N}$ . Os polinômios  $\phi(\cdot)$  e  $\theta(\cdot)$  são dados pelas equações (2.5) e (2.6), respectivamente, e  $\{\varepsilon_t\}_{t \in \mathbb{Z}}$  é um ruído branco.

**Observação 2.1.** a) O modelo dado na Definição 2.6 supõe que a  $d$ -ésima diferença do processo  $\{X_t\}_{t \in \mathbb{Z}}$  pode ser representada por um modelo ARMA( $p, q$ );  
 b) Na maioria dos casos práticos, temos  $d = 1$  ou  $d = 2$ ;  
 c) Para que o modelo dado na Definição 2.6 seja causal e inversível exige-se as mesmas suposições do modelo dado pela Definição 2.3, que são dados pelos Teoremas 2.1 e 2.2.

Uma generalização do processo ARIMA( $p, d, q$ ) é o processo ARFIMA( $p, d, q$ ), que é definido de maneira totalmente análoga ao ARIMA, no entanto, considerando  $d \in \mathbb{R}$ . O processo ARFIMA( $p, d, q$ ) é chamado processo auto regressivo fracionário integrado de médias móveis e possui a propriedade de memória longa. Assim, iremos definir, primeiramente, a propriedade de longa dependência.

**Definição 2.7.** Considere  $\{X_t\}_{t \in \mathbb{Z}}$  um processo estacionário. No domínio do tempo, dizemos que  $\{X_t\}_{t \in \mathbb{Z}}$  é um processo com a propriedade de longa dependência se existe um número real  $d \in (0, 0.5)$  tal que

$$\rho_X(h) \sim K_1 h^{2d-1}, \quad \text{quando } h \rightarrow \infty,$$

em que  $K_1 \neq 0$  e  $\rho_X(\cdot)$  é a função de autocorrelação do processo. Isto é, a função de autocorrelação decresce de forma hiperbólica (suavemente) para zero. De forma equivalente, no domínio da frequência, se

$$f_X(\lambda) \sim K_2 |\lambda|^{-2d}, \quad \text{quando } \lambda \rightarrow 0,$$

em que  $K_2 > 0$  e  $f_X(\cdot)$  é a função densidade espectral do processo.

**Observação 2.2.** a) A notação  $f(x) \sim g(x)$ , quando  $x \rightarrow 0$ , significa que  $\lim_{x \rightarrow 0} \frac{f(x)}{g(x)} = 1$ ;

- b) No domínio do tempo, quando  $d \in (0, 0.5)$ ,  $\rho_X(\cdot)$  decai tão lentamente que  $\sum_{h \in \mathbb{Z}_{\geq}} |\rho_X(h)|$  diverge;
- c) O caso em que  $d = 0$  é chamado de curta dependência.
- d) Uma definição alternativa de longa dependência diz que a função densidade espectral pode ser infinita em outra frequência, que não seja a  $\lambda = 0$ , ou em mais frequências no intervalo  $[0, \pi]$ .

A definição abaixo apresenta o processo ARFIMA( $p, d, q$ ).

**Definição 2.8.** Seja  $\{X_t\}_{t \in \mathbb{Z}}$  um processo com média  $\mu$  satisfazendo a seguinte equação

$$\phi(\mathcal{B})\nabla^d(X_t - \mu) = \theta(\mathcal{B})\varepsilon_t, \quad \text{para todo } t \in \mathbb{Z}, \quad (2.13)$$

em que  $\{\varepsilon_t\}_{t \in \mathbb{Z}}$  é um ruído branco, os polinômios  $\phi(\cdot)$  e  $\theta(\cdot)$  são definidos nas equações (2.5) e (2.6),  $d \in (-0.5, 0.5)$  e  $\nabla^d = (1 - \mathcal{B})^d$ . Então, dizemos que  $\{X_t\}_{t \in \mathbb{Z}}$  é um processo auto regressivo fracionário integrado de média móveis, denotado por ARFIMA( $p, d, q$ ).

Os teoremas a seguir apresentam algumas propriedades dos processos ARFIMA ( $p, d, q$ ), e suas demonstrações podem ser encontradas em Hosking (1981) e Brockwell e Davis (1991).

**Teorema 2.4.** *Seja  $\{X_t\}_{t \in \mathbb{Z}}$  um processo ARFIMA( $p, d, q$ ), dado pela Definição 2.8. Suponha que os polinômios  $\phi(\cdot)$  e  $\theta(\cdot)$  não tenham raízes em comum e que as raízes das equações  $\phi(z) = 0$  e  $\theta(z) = 0$  estejam fora do círculo unitário. Então*

- a) se  $d < 0.5$ , o processo  $\{X_t\}_{t \in \mathbb{Z}}$  é causal com representação média móvel infinita dada por

$$X_t = \sum_{k \in \mathbb{Z}_{\geq}} \psi_k \varepsilon_{t-k}, \quad (2.14)$$

em que  $\{\psi_k\}_{k \in \mathbb{Z}_{\geq}}$  satisfazem a relação

$$\psi(z) = \frac{\theta(z)}{\phi(z)}(1 - z)^{-d};$$

- b) se  $d > -1$ , o processo  $\{X_t\}_{t \in \mathbb{Z}}$  é inversível com representação auto regressiva infinita

$$\varepsilon_t = \sum_{k \in \mathbb{Z}_{\geq}} \pi_k X_{t-k} \quad (2.15)$$

em que  $\{\pi_k\}_{k \in \mathbb{Z}_\geq}$  são os coeficientes que satisfazem a relação

$$\pi(z) = \frac{\phi(z)}{\theta(z)}(1-z)^d;$$

- c) a função de autocorrelação  $\rho_X(\cdot)$  e a função densidade espectral  $f_X(\cdot)$  satisfazem, para  $d \in (-0.5, 0.5)$  e  $d \neq 0$ ,

$$\rho_X(h) \sim Ch^{2d-1}, \quad \text{quando } h \rightarrow \infty, \quad (2.16)$$

em que  $C \neq 0$ , e

$$f_X(\lambda) = \frac{\sigma_\varepsilon^2}{2\pi} \frac{|\theta(e^{-i\lambda})|^2}{|\phi(e^{-i\lambda})|^2} |1 - e^{-i\lambda}|^{-2d} \sim \frac{\sigma_\varepsilon^2}{2\pi} \left[ \frac{\theta(1)}{\phi(1)} \right]^2 \lambda^{-2d}, \quad (2.17)$$

quando  $\lambda \rightarrow 0$ .

Assim, a partir do Teorema 2.4 (item c), conclui-se que o processo ARFIMA( $p, d, q$ ) possui a propriedade da longa dependência se  $d \in (0, 0.5)$ .

O próximo processo que iremos definir é uma extensão dos processos ARFIMA( $p, d, q$ ). Denominado processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>, esse processo tem como característica se repetir durante um período de tempo fixo.

**Definição 2.9.** Seja  $\{X_t\}_{t \in \mathbb{Z}}$  um processo satisfazendo a seguinte equação

$$\phi(\mathcal{B})\Phi(\mathcal{B}^s)\nabla^d\nabla_s^D(X_t - \mu) = \theta(\mathcal{B})\Theta(\mathcal{B}^s)\varepsilon_t, \quad (2.18)$$

em que  $\mu$  é a média do processo,  $\{\varepsilon_t\}_{t \in \mathbb{Z}}$  é um ruído branco,  $s \in \mathbb{N}$  é a sazonalidade,  $\phi(\cdot)$ ,  $\theta(\cdot)$  são os polinômios de ordem  $p$  e  $q$  dados pelas equações (2.5) e (2.6), respectivamente,  $\Phi(\cdot)$  e  $\Theta(\cdot)$  são os polinômios de ordem  $P$  e  $Q$  dados por

$$\Phi(\mathcal{B}) = 1 - \Phi_1\mathcal{B} - \Phi_2\mathcal{B}^2 - \cdots - \Phi_P\mathcal{B}^P; \quad (2.19)$$

$$\Theta(\mathcal{B}) = 1 - \Theta_1\mathcal{B} - \Theta_2\mathcal{B}^2 - \cdots - \Theta_Q\mathcal{B}^Q. \quad (2.20)$$

Então,  $\{X_t\}_{t \in \mathbb{Z}}$  é um processo sazonal auto regressivo fracionariamente integrado de média móvel de ordem  $(p, d, q) \times (P, D, Q)_s$ , denotado por SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>, em que o grau de diferenciação e o grau de diferenciação sazonal são  $d$  e  $D$ , respectivamente.

A seguir, apresentamos um teorema com diversas propriedades dos processos

SARFIMA  $(p, d, q) \times (P, D, Q)_s$ ; sua demonstração e maiores detalhes podem ser encontrados em Bisognin (2007) e Bisognin e Lopes (2009).

**Teorema 2.5.** *Seja  $\{X_t\}_{t \in \mathbb{Z}}$  um processo SARFIMA  $(p, d, q) \times (P, D, Q)_s$  dado pela Definição 2.9. Suponha que as equações  $\phi(z)\Phi(z^s) = 0$  e  $\theta(z)\Theta(z^s) = 0$  não tenham raízes em comum. Então valem as seguintes propriedades.*

- a) *Se  $|d + D| < 0.5$ ,  $|D| < 0.5$ , o processo tem função densidade espectral dada por*

$$f_X(\lambda) = \frac{\sigma_\varepsilon^2}{2\pi} \frac{|\theta(e^{-i\lambda})|^2}{|\phi(e^{-i\lambda})|^2} \frac{|\Theta(e^{-is\lambda})|^2}{|\Phi(e^{-is\lambda})|^2} \left| 2 \operatorname{sen}\left(\frac{\lambda}{2}\right) \right|^{-2d} \left| 2 \operatorname{sen}\left(\frac{s\lambda}{2}\right) \right|^{-2D}, \quad (2.21)$$

*em que  $0 < \lambda \leq \pi$ .*

- b) *O processo é estacionário se  $d + D < 0.5$ ,  $D < 0.5$  e todas as raízes da equação  $\phi(z)\Phi(z^s) = 0$  estão fora do círculo unitário.*
- c) *O processo é causal se  $d < 0.5$ ,  $D < 0.5$  e todas as raízes da equação  $\phi(z)\Phi(z^s) = 0$  estão fora do círculo unitário.*
- d) *O processo é inversível se  $d > -0.5$ ,  $D > -0.5$  e todas as raízes da equação  $\theta(z)\Theta(z^s) = 0$  estão fora do círculo unitário.*
- e) *O processo estacionário possui longa dependência se  $0 < d + D < 0.5$ ,  $0 < D < 0.5$  e todas raízes da equação  $\phi(z)\Phi(z^s) = 0$  estão fora do círculo unitário.*

A seção seguinte trata dos mesmos modelos apresentados nesta seção, no entanto, considerando processos com inovações  $\alpha$ -estáveis.

## 2.2 Processos com Inovações $\alpha$ -estáveis

Na seção anterior, foram definidos diversos processos, todos com inovação na forma de um ruído branco Gaussiano. Tais processos apresentam variância finita, e acabam não explicando bem muitas séries temporais que apresentam variabilidade alta. Neste sentido, veremos nesta seção novos processos que apresentam a característica de ter variância infinita. Iremos considerar os mesmos processos da seção anterior, entretanto, com inovações  $\alpha$ -estáveis. Inicialmente veremos o que quer

dizer uma variável aleatória ter distribuição  $\alpha$ -estável e algumas propriedades desta distribuição, em seguida, definiremos os modelos com inovações  $\alpha$ -estáveis.

**Definição 2.10.** Uma variável aleatória  $X$  é dita ter uma distribuição estável se e somente se para quaisquer constantes positivas  $c_1$  e  $c_2$ , existem constantes  $c > 0$  e  $\delta \in \mathbb{R}$  tais que

$$c_1 X_1 + c_2 X_2 \stackrel{d}{=} cX + \delta \quad (2.22)$$

em que  $X_1$  e  $X_2$  são amostras independentes de  $X$  e  $\stackrel{d}{=}$  denota a igualdade em distribuição.

**Definição 2.11.** Uma variável aleatória  $X$  é dita ter uma distribuição estritamente estável se  $\delta = 0$  para qualquer escolha de  $c_1$  e  $c_2$ .

**Definição 2.12.** Uma variável aleatória  $X$  é dita ter uma distribuição estável simétrica se é estável e simetricamente distribuída em torno do zero, isto é,  $X \stackrel{d}{=} -X$ .

A próxima definição é equivalente a Definição 2.10, como pode ser visto em Feller (1971).

**Definição 2.13.** Uma variável aleatória  $X$  é dita ter uma distribuição estável se para cada  $n \geq 2$ , existem constantes  $c_n > 0$  e  $\delta_n$  tais que

$$X_1 + X_2 + \cdots + X_n \stackrel{d}{=} c_n X + \delta_n \quad (2.23)$$

em que a variável aleatória  $X$  não é concentrada em um ponto (caso degenerado) e  $X, X_1, \dots, X_n$  são independentes e com a mesma distribuição.

As Definições 2.10 e 2.13 são equivalentes, como é demonstrado em Feller (1971). O próximo teorema caracteriza as constantes normalizadoras  $c_n$  e sua demonstração pode ser encontrada em Feller (1971).

**Teorema 2.6.** As constantes normalizadoras são da forma  $c_n = n^{\frac{1}{\alpha}}$ , para  $n \geq 2$  e com  $0 < \alpha \leq 2$ . O índice  $\alpha$  é chamado expoente característico ou índice de estabilidade.

**Exemplo 2.1.** Considere uma variável aleatória  $X$  tendo distribuição  $N(\mu, \sigma^2)$ , então  $X$  tem distribuição estável com  $\alpha = 2$ . De fato,

$$c_1 X_1 + c_2 X_2 \sim N((c_1 + c_2)\mu, (c_1^2 + c_2^2)\sigma^2),$$

então, pela Definição 2.10 temos  $c = (c_1^2 + c_2^2)^{\frac{1}{2}}$  e  $\delta = (c_1 + c_2 - c)\mu$ .

Outra definição equivalente às Definições 2.10 e 2.13, será dada a seguir.

**Definição 2.14.** Uma variável aleatória é dita ter distribuição estável se tem um domínio de atração, isto é, se existe uma sequência de variáveis independentes e identicamente distribuídas (i.i.d.)  $Y_1, Y_2, \dots$ , uma sequência de números positivos  $\{d_n\}_{n \geq 1}$  e números reais  $\{a_n\}_{n \geq 1}$ , tais que

$$\frac{Y_1 + Y_2 + \cdots + Y_n}{d_n} + a_n \xrightarrow{d} X,$$

em que  $\xrightarrow{d}$  é a notação usada para convergência em distribuição.

A próxima definição também é equivalente às Definições 2.10, 2.13 e 2.14.

**Definição 2.15.** Uma variável aleatória é dita ter distribuição  $\alpha$ -estável se existem parâmetros  $0 < \alpha \leq 2, \sigma \geq 0, -1 \leq \beta \leq 1$  e  $\mu$  real, tais que a sua função característica é da seguinte forma

$$\mathbb{E}(e^{itX}) = \begin{cases} \exp\{-\sigma^\alpha |t|^\alpha (1 - i\beta(\text{sign } t) \tan \frac{\pi\alpha}{2}) + i\mu t\}, & \text{se } \alpha \neq 1, \\ \exp\{-\sigma|t| (1 + \frac{2i\beta}{\pi}(\text{sign } t) \ln |t|) + i\mu t\} & \text{se } \alpha = 1. \end{cases}$$

A função  $\text{sign } t$  é definida como

$$\text{sign } t = \begin{cases} -1, & \text{se } t < 0, \\ 0, & \text{se } t = 0, \\ 1, & \text{se } t > 0. \end{cases}$$

Se uma variável aleatória  $X$  tem distribuição  $\alpha$ -estável, denotamos por  $X \stackrel{d}{=} S_\alpha(\sigma, \beta, \mu)$ .

Se  $X$  for  $\alpha$ -estável com  $\beta = \mu = 0$ , então dizemos que  $X$  é  $\alpha$ -estável simétrica, e denotamos por  $S\alpha S$ . Sua função característica é da seguinte forma,

$$\mathbb{E}(e^{itX}) = e^{-\sigma^\alpha |t|^\alpha}, \quad \text{com } t \in \mathbb{R} \quad \text{e } 0 < \alpha \leq 2.$$

O parâmetro  $\sigma$  é chamado parâmetro de escala,  $\beta$  parâmetro de assimetria e  $\mu$  parâmetro de *shift*.

**Observação 2.3.** Se  $0 < \alpha < 2$ , então  $\mathbb{E}|X|^p = \infty$ , para  $p \geq \alpha$ , e para  $0 < p < \alpha$ ,  $\mathbb{E}|X|^p = c(p, \alpha)\sigma^p$ , em que  $c(p, \alpha)$  não depende do parâmetro de escala  $\sigma$ . Portanto, se  $1 < \alpha < 2$ , a variância da variável  $X$  será infinita.

A seguir iremos definir os processos com característica de longa dependência e inovações  $\alpha$ -estáveis.

**Definição 2.16.** Um processo ARFIMA( $p, d, q$ )  $\alpha$ -estável satisfaz a equação (2.13), tendo processo de inovação  $\{\varepsilon_t\}_{t \in \mathbb{Z}}$  formado por variáveis aleatórias independentes e identicamente distribuídas, com distribuição  $\alpha$ -estável simétrica,  $1 < \alpha < 2$ .

**Definição 2.17.** Um processo SARFIMA( $p, d, q$ )  $\times (P, D, Q)_s$   $\alpha$ -estável satisfaz a equação (2.18), tendo processo de inovação  $\{\varepsilon_t\}_{t \in \mathbb{Z}}$  formado por variáveis aleatórias independentes e identicamente distribuídas, com distribuição  $\alpha$ -estável simétrica,  $1 < \alpha < 2$ .

Os processos com inovações da forma ruído branco são caracterizados basicamente pela função de autocovariâncias e função densidade espectral. No entanto, nos processos com inovações  $\alpha$ -estáveis não existe função densidade espectral, pois as variáveis aleatórias  $\alpha$ -estáveis tem variância infinita. Em virtude disso, define-se uma nova função no domínio das frequências, denominada função poder de transferência. Esta função foi inicialmente definida para os processos ARFIMA, mas podemos generalizar para os demais processos citados neste trabalho, a qual será apresentada no Teorema 2.7 a seguir.

O próximo teorema apresenta algumas propriedades dos processos SARFIMA( $p, d, q$ )  $\times (P, D, Q)_s$   $\alpha$ -estáveis.

**Teorema 2.7.** Seja  $\{X_t\}_{t \in \mathbb{Z}}$  um processo SARFIMA( $p, d, q$ )  $\times (P, D, Q)_s$   $\alpha$ -estável, dado pela Definição 2.17. Suponha que as equações  $\phi(z)\Phi(z^s) = 0$  e  $\theta(z)\Theta(z^s) = 0$  não tenham raízes em comum e que  $|D + d| < 1 - \frac{1}{\alpha}$  e  $|D| < 1 - \frac{1}{\alpha}$  com  $1 < \alpha < 2$ . Então valem as seguintes propriedades.

- a) Se a solução da equação  $\phi(z)\Phi(z^s) = 0$  estiver fora do círculo unitário, então  $\{X_t\}_{t \in \mathbb{Z}}$  é causal. Os coeficientes  $\{\psi_j\}_{j \in \mathbb{Z}_\geq}$  da representação média móvel infinita são dados por

$$\psi(z) = \sum_{j \in \mathbb{Z}_\geq} \psi_j z^j = \frac{\theta(z)\Theta(z^s)}{\phi(z)\Phi(z^s)} (1-z)^{-d} (1-z^s)^{-D}. \quad (2.24)$$

- b) Se a solução da equação  $\theta(z)\Theta(z^s) = 0$  estiver fora do círculo unitário, então  $\{X_t\}_{t \in \mathbb{Z}}$  é inversível. Os coeficientes  $\{\pi_j\}_{j \in \mathbb{Z}_\geq}$  da representação auto regressiva

infinita são dados por

$$\pi(z) = \sum_{j \in \mathbb{Z}_{\geq}} \pi_j z^j = \frac{\phi(z)\Phi(z^s)}{\theta(z)\Theta(z^s)}(1-z)^d(1-z^s)^D. \quad (2.25)$$

- c) Se o processo for causal, a função poder de transferência do processo  $\{X_t\}_{t \in \mathbb{Z}}$  é dada por

$$\begin{aligned} g_X(\lambda) &= \frac{|\theta(e^{-i\lambda})|^2 |\Theta(e^{-is\lambda})|^2}{|\phi(e^{-i\lambda})|^2 |\Phi(e^{-is\lambda})|^2} \left| 2 \sin\left(\frac{\lambda}{2}\right) \right|^{-2d} \left| 2 \sin\left(\frac{s\lambda}{2}\right) \right|^{-2D} \\ &= \left| \sum_{j=0}^{\infty} \psi_j e^{-ij\lambda} \right|^2. \end{aligned} \quad (2.26)$$

**Demonstração:**

- a) Seja  $\{X_t\}_{t \in \mathbb{Z}}$  um processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estável, com média zero, dado pela expressão

$$\phi(\mathcal{B})\Phi(\mathcal{B}^s)(1-\mathcal{B})^d(1-\mathcal{B}^s)^D X_t = \theta(\mathcal{B})\Theta(\mathcal{B}^s)\varepsilon_t.$$

Pelo artigo de Diongue et. al. (2007), temos que, se o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>, com  $P = Q = 0$ , satisfaz as condições  $|D + d| < 1 - \frac{1}{\alpha}$ ,  $|D| < 1 - \frac{1}{\alpha}$ , com  $1 < \alpha < 2$  e a equação  $\phi(z) = 0$  não tem raízes no círculo unitário, então o processo é causal. Logo, podemos escrever

$$\begin{aligned} \Phi(\mathcal{B}^s)X_t &= \Theta(\mathcal{B}^s) \frac{\theta(\mathcal{B})}{\phi(\mathcal{B})(1-\mathcal{B})^d(1-\mathcal{B}^s)^D} \varepsilon_t \\ \Phi(\mathcal{B}^s)X_t &= \Theta(\mathcal{B}^s)Z_t, \end{aligned} \quad (2.27)$$

onde  $Z_t = \frac{\theta(\mathcal{B})}{\phi(\mathcal{B})(1-\mathcal{B})^d(1-\mathcal{B}^s)^D} \varepsilon_t$  é um processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub> com  $P = Q = 0$  e processo de inovação  $\{\varepsilon_t\}_{t \in \mathbb{Z}}$ .

Assim, basta mostrarmos que o processo dado em (2.27) é causal.

Temos, por hipótese, que  $\Phi(z^s) \neq 0$ , para todo  $|z| \leq 1$ . Logo,  $\frac{1}{\Phi(z^s)}$  é uma função analítica e pode ser expressa em série de potências. Assim, existe  $\epsilon > 0$ , tal que

$$\frac{1}{\Phi(z^s)} = \sum_{j \in \mathbb{Z}_{\geq}} \xi_j z^j = \xi(z), \quad \text{para todo } |z| < 1 + \epsilon.$$

Como a série converge para  $|z| < 1 + \epsilon$  e converge para  $|z| < 1 + \frac{\epsilon}{2}$ . Então, temos que,

$$\lim_{j \rightarrow \infty} \xi_j \left(1 + \frac{\epsilon}{2}\right)^j = 0.$$

Ou seja, a sequência  $\left\{ \xi_j \left(1 + \frac{\epsilon}{2}\right)^j \right\}_{j \geq 0}$  converge, logo é limitada. Portanto, existe uma constante  $K > 0$  finita tal que, para todo  $j \geq 0$ ,

$$\left| \xi_j \left(1 + \frac{\epsilon}{2}\right)^j \right| < K, \quad \text{isto é,} \quad |\xi_j| < K \left(1 + \frac{\epsilon}{2}\right)^{-j}.$$

Então,

$$\sum_{j \in \mathbb{Z}_\geq} |\xi_j| < K \sum_{j \in \mathbb{Z}_\geq} \left(1 + \frac{\epsilon}{2}\right)^{-j} < \infty.$$

Além disso,  $\xi(z)\Phi(z^s) \equiv 1$ , para  $|z| \leq 1$ .

Logo, pela Proposição 3.1.2 de Brockwell e Davis (1991), o operador  $\xi(z) = \sum_{j \in \mathbb{Z}_\geq} \xi_j z^j$ , com  $\sum_{j \in \mathbb{Z}_\geq} |\xi_j| < \infty$ , quando aplicado a processos estacionários, herda as propriedades algébricas das séries de potências. Assim, aplicando o operador  $\xi(z)$  a ambos os lados da expressão (2.27), obtemos  $X_t = \xi(\mathcal{B})\Theta(\mathcal{B}^s)Z_t$ .

Portanto, temos a representação

$$X_t = \sum_{j \in \mathbb{Z}_\geq} \psi_j \varepsilon_t, \quad \text{para todo } t \in \mathbb{Z},$$

em que os coeficientes  $\{\psi_j\}_{j \in \mathbb{Z}_\geq}$  são dados pela expressão (2.24). Desta forma, o processo  $\{X_t\}_{t \in \mathbb{Z}}$  é causal.

- b) Seja  $\{X_t\}_{t \in \mathbb{Z}}$  um processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estável, com média zero, dado pela expressão

$$\phi(\mathcal{B})\Phi(\mathcal{B}^s)(1 - \mathcal{B})^d(1 - \mathcal{B}^s)^D X_t = \theta(\mathcal{B})\Theta(\mathcal{B}^s)\varepsilon_t.$$

Pelo artigo de Diongue et. al. (2007), temos que, se o processo SARFIMA ( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estável, com  $P = Q = 0$ , satisfaz as condições  $|D + d| < 1 - \frac{1}{\alpha}$ ,  $|D| < 1 - \frac{1}{\alpha}$ , com  $1 < \alpha < 2$  e a equação  $\theta(z) = 0$  não tem raízes no

círculo unitário, então o processo é inversível. Logo, podemos escrever

$$\begin{aligned}\Phi(\mathcal{B}^s) \frac{\phi(\mathcal{B})}{\theta(\mathcal{B})} (1 - \mathcal{B})^d (1 - \mathcal{B}^s)^D X_t &= \Theta(\mathcal{B}^s) \varepsilon_t \\ \Phi(\mathcal{B}^s) Z_t &= \Theta(\mathcal{B}^s) \varepsilon_t.\end{aligned}\quad (2.28)$$

onde  $Z_t = \frac{\phi(\mathcal{B})}{\theta(\mathcal{B})} (1 - \mathcal{B})^d (1 - \mathcal{B}^s)^D X_t$  e  $\{X_t\}_{t \in \mathbb{Z}}$  é um processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub> com  $P = Q = 0$  e processo de inovação  $\{Z_t\}_{t \in \mathbb{Z}}$ .

Assim, basta mostrarmos que o processo dado em (2.28) é inversível.

Temos, por hipótese, que  $\Theta(z^s) \neq 0$ , para todo  $|z| \leq 1$ . Logo,  $\frac{1}{\Theta(z^s)}$  pode ser expressa em série de potências. Assim, existe  $\epsilon > 0$ , tal que

$$\frac{1}{\Theta(z^s)} = \sum_{j \in \mathbb{Z}_\geq} \eta_j z^j = \eta(z), \quad \forall |z| < 1 + \epsilon.$$

Seguindo os argumentos do item a) teremos que  $\sum_{j \in \mathbb{Z}_\geq} |\eta_j| < \infty$ , além disso,

$$\eta(z)\Theta(z^s) \equiv 1, \quad \text{para todo } |z| \leq 1.$$

E, novamente pela Proposição 3.1.2 de Brockwell e Davis (1991), podemos aplicar o operador  $\eta(z) = \sum_{j \in \mathbb{Z}_\geq} \eta_j z^j$  a ambos os lados da expressão (2.28), obtendo

$$\eta(\mathcal{B})\Phi(\mathcal{B}^s)Z_t = \eta(\mathcal{B})\Theta(\mathcal{B}^s)\varepsilon_t = \varepsilon_t \quad \text{para todo } t \in \mathbb{Z}.$$

Portanto, temos a representação

$$\varepsilon_t = \sum_{j \in \mathbb{Z}_\geq} \pi_j X_t, \quad \text{para todo } t \in \mathbb{Z},$$

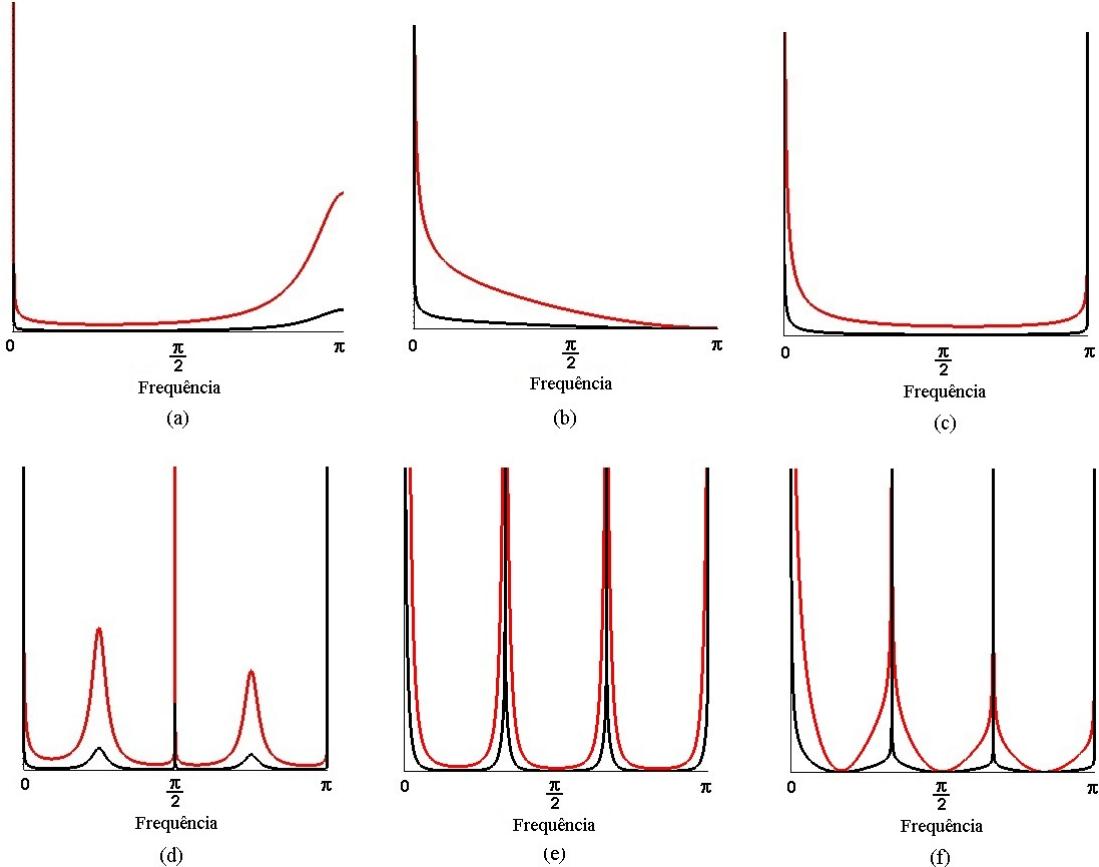
em que os coeficientes  $\{\pi_j\}_{j \in \mathbb{Z}_\geq}$  são dados pela expressão (2.25). Desta forma, o processo é inversível.

- c) É a definição de função poder de transferência de um processo causal.

■

**Observação 2.4.** Neste trabalho, iremos considerar  $1 < \alpha < 2$ , pois, caso  $\alpha = 2$ , teremos a distribuição normal.

**Observação 2.5.** Pelo artigo de Kokoszka e Taqqu (1999), consideramos que uma série temporal com variância infinita tem longa memória, quando a correspondente série com variância finita (inovações na forma de ruído branco) tem longa memória. Logo, em um processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estável, dado pela Definição 2.17, teremos longa memória quando  $0 < d + D < \frac{1}{2}$  e  $0 < D < \frac{1}{2}$  (ver Teorema 2.5, item e)).



**Figura 2.1:** Gráficos das funções densidade espectral (em preto) e poder de transferência (em vermelho) dos seguintes processos: (a) ARFIMA( $p, d, q$ ), com  $p = 1$ ,  $d = 0.2$ ,  $q = 0$  e  $\phi_1 = 0.7$ ; (b) ARFIMA( $p, d, q$ ), com  $p = 0$ ,  $d = 0.2$ ,  $q = 1$  e  $\theta_1 = 0.7$ ; (c) SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub> com  $p = q = 0 = P = Q$ ,  $d = D = 0.2$  e  $s = 2$ ; (d) SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>, com  $P = 1$ ,  $p = q = 0 = Q$ ,  $d = D = 0.2$ ,  $s = 4$  e  $\Phi_1 = 0.7$ ; (e) SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>, com  $P = 1$ ,  $p = q = 0 = Q$ ,  $d = D = 0.2$ ,  $s = 6$  e  $\Phi_1 = -0.7$  e (f) SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>, com  $q = 1 = Q$ ,  $p = 0 = P$ ,  $d = D = 0.2$ ,  $s = 6$ ,  $\theta_1 = 0.2$  e  $\Theta_1 = 0.7$ .

A Figura 2.1 apresenta alguns gráficos da função densidade espectral de processos com inovações ruído branco (em preto), comparando com gráficos da função poder de transferência (em vermelho) dos mesmos processos com inovações  $\alpha$ -estáveis. Note

que a função poder de transferência é a densidade espectral multiplicada por uma constante.

Como nos processos com inovações  $\alpha$ -estáveis não existe a função densidade espectral, mas existe a função poder de transferência, é natural a necessidade de um novo estimador para essa função. Klüppelberg e Mikosch (1996) definem a função periodograma normalizado conforme a seguir.

**Definição 2.18.** Seja  $X_1, X_2, \dots, X_N$  um série temporal obtida a partir do processo  $\{X_t\}_{t \in \mathbb{Z}}$ . A função *periodograma normalizado*, denotada por  $\tilde{I}_N(\cdot)$ , é dada por

$$\tilde{I}_N(\lambda) = \left( \sum_{t=1}^N X_t^2 \right)^{-1} \left| \sum_{t=1}^N X_t e^{-i\lambda t} \right|^2, \quad \text{em que } \lambda \in [-\pi, \pi]. \quad (2.29)$$

**Proposição 2.1.** A função periodograma normalizado pode ser escrita da seguinte forma

$$\tilde{I}_N(\lambda) = \sum_{|h| < N} \hat{\rho}_X(h) e^{-i\lambda h}, \quad \text{em que } \lambda \in [-\pi, \pi], \quad (2.30)$$

em que  $\hat{\rho}_X(\cdot)$  é a função de autocorrelação amostral do processo (ver Definição 1.10).

**Demonstração:** Iremos supor, sem perda de generalidade, que o processo tem média zero. Assim, pela Definição 1.9, temos que

$$\hat{\gamma}_X(0) = \frac{1}{N} \sum_{k=1}^N X_k^2.$$

Então

$$\begin{aligned} \tilde{I}_N(\lambda) &= \frac{\frac{1}{N} \left| \sum_{t=1}^N X_t e^{-i\lambda t} \right|^2}{\frac{1}{N} \sum_{t=1}^N X_t^2} = \frac{\frac{1}{N} \left| \sum_{t=1}^N X_t e^{-i\lambda t} \right|^2}{\hat{\gamma}_X(0)} \\ &= \frac{1}{N \hat{\gamma}_X(0)} \left( \sum_{t=1}^N X_t e^{-i\lambda t} \right) \left( \sum_{s=1}^N X_s e^{i\lambda s} \right) \\ &= \frac{1}{N \hat{\gamma}_X(0)} \sum_{t=1}^N \sum_{s=1}^N X_t X_s e^{-i\lambda(t-s)}. \end{aligned}$$

Fazendo a mudança de variáveis  $h = t - s$ , teremos

$$\begin{aligned}
\tilde{I}_N(\lambda) &= \frac{1}{\hat{\gamma}_X(0)} \sum_{|h|<N} \underbrace{\left( \frac{1}{N} \sum_{t=1}^{N-|h|} X_t X_{t+h} \right)}_{\hat{\gamma}_X(h)} e^{-i\lambda h} \\
&= \frac{1}{\hat{\gamma}_X(0)} \sum_{|h|<N} \hat{\gamma}_X(h) e^{-i\lambda h}
\end{aligned}$$

Ou seja,

$$\begin{aligned}
\tilde{I}_N(\lambda) &= \sum_{|h|<N} \underbrace{\frac{\hat{\gamma}_X(h)}{\hat{\gamma}_X(0)}}_{\hat{\rho}_X(h)} e^{-i\lambda h} \\
&= \sum_{|h|<N} \hat{\rho}_X(h) e^{-i\lambda h}.
\end{aligned}$$

■

**Observação 2.6.** O periodograma normalizado é um estimador não consistente da função  $\frac{g_X(\lambda)}{\psi^2}$ , em que  $g_X(\lambda)$  é a função poder de transferência e

$$\psi^2 = \sum_{j \in \mathbb{Z}_{\geq}} \psi_j^2,$$

com  $\{\psi_j\}_{j \in \mathbb{Z}_{\geq}}$  sendo os coeficientes da representação média móvel infinita do processo, dados pela equação (2.24). Klüppelberg e Mikosch (1994) definem um estimador suavizado consistente para  $\frac{g_X(\lambda)}{\psi^2}$ , aplicando um filtro linear em  $\tilde{I}_N(\cdot)$ .

Neste trabalho iremos definir um novo estimador consistente de  $\frac{g_X(\cdot)}{\psi^2}$ , que chamaremos de *periodograma normalizado suavizado de correlações*.

**Definição 2.19.** O *periodograma normalizado suavizado de correlações* é dado por

$$\tilde{I}_{SN}(\lambda) = \sum_{h=-(N-1)}^{N+1} \omega_M(h) \hat{\rho}_X(h) e^{-i\lambda h} \quad (2.31)$$

em que,  $\hat{\rho}_X(\cdot)$  é a função de autocorrelações do processo e  $\omega_M(h)$  é uma sequência de pesos satisfazendo, para um natural  $M < N$ ,

- a)  $0 \leq \omega_M(h) \leq \omega_M(0) = 1$ ;

b)  $\omega_M(h) = \omega_M(-h)$ , para todo  $h$ ;

c)  $\omega_M(h) = 0, |h| \geq M$ .

**Teorema 2.8.** A função periodograma normalizado suavizado de correlações, dada na Definição 2.19, é um estimador consistente para a função  $\frac{g_X(\lambda)}{\psi^2}$ , em que  $g_X(\lambda)$  é a função poder de transferência e  $\psi^2 = \sum_{j \in \mathbb{Z}_{\geq}} \psi_j^2$ , onde  $\{\psi_j\}_{j \in \mathbb{Z}_{\geq}}$  são os coeficientes da representação média móvel infinita do processo, dados pela equação (2.24).

**Demonstração:** Para verificarmos que este novo estimador é consistente, veja que, da equação (2.30), temos

$$\tilde{I}_N(\lambda) = \frac{1}{2\pi} \sum_{|h| < N} 2\pi \hat{\rho}_X(h) e^{-i\lambda h}, \quad \lambda \in [-\pi, \pi]. \quad (2.32)$$

Logo, a transformada de Fourier discreta inversa de  $\tilde{I}_N(\lambda)$  torna-se

$$2\pi \hat{\rho}_X(h) = \int_{-\pi}^{\pi} \tilde{I}_N(\lambda) e^{i\lambda h} d\lambda,$$

ou seja,

$$\hat{\rho}_X(h) = \frac{1}{2\pi} \int_{-\pi}^{\pi} \tilde{I}_N(\lambda) e^{i\lambda h} d\lambda. \quad (2.33)$$

Pelo artigo de Klüppelberg e Mikosch (1994), temos o periodograma suavizado normalizado, dado por

$$\tilde{T}_{N,X}(\lambda) = \sum_{|h| \leq M} W_N(h) \tilde{I}_N(\lambda_h),$$

em que  $\lambda_h = \lambda + \frac{h}{N}$ . Além disso,

$$W_N(\lambda) = \frac{1}{2\pi} \sum_{h=-(N-1)}^{N+1} \omega_M(h) e^{-i\lambda h}.$$

Klüppelberg e Mikosch (1994) mostram que

$$\tilde{T}_{N,X}(\lambda) \xrightarrow{\mathbb{P}} \frac{g_X(\lambda)}{\psi^2}, \quad \text{quando } N \rightarrow \infty, \quad \text{em que } \lambda \in (0, \pi),$$

se valerem as seguintes condições:

- a)  $X_t = \sum_{j \in \mathbb{Z}_{\geq}} \psi_j \varepsilon_{t-j}$ , com  $\{\varepsilon_t\}_{t \in \mathbb{Z}}$  uma sequência i.i.d. simétrica  $S\alpha S$ ,  $\alpha \in (1, 2)$ , os coeficientes  $\{\psi_j\}_{j \in \mathbb{Z}_{\geq}}$ , satisfazem  $\sum_{j \in \mathbb{Z}_{\geq}} |\psi_j| |j| < \infty$ ;
- b)  $\{W_N\}_{N \in \mathbb{N}}$  é uma sequência de pesos satisfazendo:  $W_N(k) = W_N(-k)$ ,  $W_N(k) \geq 0$ , para todo  $k \in \mathbb{N}$  e  $\sum_{|k| \leq M} W_N(k) = 1$ ;
- c)  $M = M_N$  é uma sequência em  $\mathbb{N}$  tal que:  $M_N \rightarrow \infty$  e  $\frac{M_N}{N} \rightarrow 0$ , quando  $N \rightarrow \infty$ .

Assim, usando (2.33), temos que

$$\begin{aligned}
\tilde{I}_{SN}(\lambda) &= \sum_{h=-(N-1)}^{N+1} \omega_M(h) \hat{\rho}_X(h) e^{-i\lambda h} \\
&= \sum_{h=-(N-1)}^{N+1} \omega_M(h) \frac{1}{2\pi} \int_{-\pi}^{\pi} \tilde{I}_N(\omega) e^{-i(\lambda-\omega)h} d\omega \\
&= \int_{-\pi}^{\pi} \underbrace{\frac{1}{2\pi} \sum_{h=-(N-1)}^{N+1} \omega_M(h) e^{-i(\lambda-\omega)h}}_{W_N(\lambda-\omega)} \tilde{I}_N(\omega) d\omega.
\end{aligned}$$

Ou seja,

$$\begin{aligned}
\tilde{I}_{SN}(\lambda) &= \int_{-\pi}^{\pi} W_N(\lambda - \omega) \tilde{I}_N(\omega) d\omega \\
&= \int_{-\pi}^{\pi} W_N(\lambda) \tilde{I}_N(\omega - \lambda) d\lambda.
\end{aligned}$$

Como podemos escrever o periodograma normalizado suavizado de correlações em função da janela espectral do periodograma normalizado suavizado, teremos que o periodograma normalizado suavizado de correlações, também é consistente para a função  $\frac{g_X(\lambda)}{\psi^2}$ , sob as condições a-c.

■

**Observação 2.7.** Geralmente considera-se  $M = N^\beta$ ,  $\beta < 1$ . Neste trabalho, utilizamos  $\beta = 0.9$ .

No próximo capítulo estudaremos a estimação dos parâmetros dos processos apresentados neste capítulo, mas, antes disso, iremos estudar métodos e propriedades de previsão nos processos descritos neste capítulo.

## 2.3 Previsão

Nesta seção iremos tratar de um dos principais objetivos no estudo de séries temporais, que é o de fazer previsões, a partir de uma série temporal dada e do modelo escolhido. Iniciaremos apresentando previsão para processos SARFIMA( $p, d, q) \times (P, D, Q)_s$  com inovações na forma de ruído branco, depois iremos apresentar previsão para processos com inovações  $\alpha$ -estáveis simétricas.

Suponha que tenhamos uma série temporal  $\{X_t\}_{t=1}^N$ , proveniente de um processo SARFIMA( $p, d, q) \times (P, D, Q)_s$  com inovações na forma de ruído branco Gaussiano, e gostaríamos de prever o valor de  $X_{N+h}$ , para  $h$  passos à frente. A previsão de erro quadrático médio mínimo é dado por

$$\hat{X}_N(h) \equiv \mathbb{E}(X_{N+h}|X_1, \dots, X_N). \quad (2.34)$$

Este valor minimiza o erro quadrático médio de previsão, dado por  $\mathbb{E}(X_{N+h} - \hat{X}_N(h))^2$ . O erro de previsão é dado por

$$e_N(h) = X_{N+h} - \hat{X}_N(h).$$

Para calcularmos as previsões usamos os seguintes fatos

$$a) \mathbb{E}(X_{N+h}|X_1, \dots, X_N) = \begin{cases} X_{N+h}, & \text{se } h \leq 0, \\ \hat{X}_N(h), & \text{se } h \geq 0. \end{cases}$$

$$b) \mathbb{E}(\varepsilon_{N+h}|X_1, \dots, X_N) = \begin{cases} \varepsilon_{N+h}, & \text{se } h \leq 0, \\ 0, & \text{se } h \geq 0. \end{cases}$$

O teorema a seguir apresenta alguns resultados para previsão em processos SARFIMA ( $p, d, q) \times (P, D, Q)_s$  com inovações na forma de ruído branco e a sua demonstração pode ser encontrada em Bisognin (2007).

**Teorema 2.9.** Seja  $\{X_t\}_{t \in \mathbb{Z}}$  um processo SARFIMA( $p, d, q$ ) $\times(P, D, Q)_s$ , com média zero, causal e inversível. Então, para todo  $h \geq 1$ , valem as seguintes afirmações:

- a) A previsão de erro quadrático médio mínimo é dada por

$$\hat{X}_N(h) = - \sum_{k \geq 1} \pi_k \hat{X}_N(h-k),$$

em que  $\{\pi_k\}_{k \in \mathbb{Z}_\geq}$  são os coeficientes da representação auto regressiva infinita.

- b) O erro de previsão é dado por

$$e_N(h) = - \sum_{k=0}^{h-1} \psi_k \varepsilon_{N+h-k},$$

em que  $\{\psi_k\}_{k \in \mathbb{Z}_\geq}$  são os coeficientes da representação média móvel infinita.

- c) A variância teórica do erro de previsão é dada por

$$Var(e_N(h)) = \sigma_\varepsilon^2 \sum_{k=0}^{h-1} \psi_k^2,$$

em que  $\{\psi_k\}_{k \in \mathbb{Z}_\geq}$  são os coeficientes da representação média móvel infinita.

- d) Se o processo  $\{\varepsilon_t\}_{t \in \mathbb{Z}}$  é tal que  $\varepsilon_t \sim N(0, \sigma_\varepsilon^2)$ , para cada  $t \in \mathbb{Z}$ , então o intervalo de confiança a  $100(1 - \gamma)\%$  de confiança para  $X_{N+h}$  é dado por

$$\hat{X}_N(h) - z_{\gamma/2} \hat{\sigma}_\varepsilon \left[ \sum_{k=0}^{h-1} \hat{\psi}_k^2 \right]^{1/2} \leq X_{N+h} \leq \hat{X}_N(h) + z_{\gamma/2} \hat{\sigma}_\varepsilon \left[ \sum_{k=0}^{h-1} \hat{\psi}_k^2 \right]^{1/2},$$

em que  $z_{\gamma/2}$  é o valor tal que  $\mathbb{P}(Z \geq z_{\gamma/2}) = \gamma/2$ ,  $\hat{\sigma}_\varepsilon$  e  $\{\hat{\psi}_k\}_{k \in \mathbb{Z}_\geq}$  são os parâmetros estimados para  $\sigma_\varepsilon$  e  $\{\psi_k\}_{k \in \mathbb{Z}_\geq}$  (abordaremos a estimação dos parâmetros no capítulo seguinte).

Se considerarmos processos com inovações  $\alpha$ -estáveis simétricas ( $S\alpha S$ ), com  $1 < \alpha < 2$ , o preditor definido em (2.34) não é apropriado, pois, como a variância do processo de inovação é infinita, pelo Teorema 2.9 item c), a variância do erro de previsão será infinita também, o que não é adequado. Assim, vamos definir um novo preditor para os processos com inovações  $\alpha$ -estáveis simétricas.

Cline e Brockwell (1985) apresentam um preditor linear para processos ARMA com variância infinita, mas afirmam que este preditor pode ser usado em outros

processos, desde que estes sejam causais. Iremos assumir que  $\{X_t\}_{t \in \mathbb{Z}}$  é um processo causal e inversível, portanto existem sequências  $\{\psi_j\}_{j \in \mathbb{Z}_\geq}$  e  $\{\pi_j\}_{j \in \mathbb{Z}_\geq}$ , tais que

$$X_t = \sum_{j \in \mathbb{Z}_\geq} \psi_j \varepsilon_{t-j} \quad (2.35)$$

e

$$\varepsilon_t = \sum_{j \in \mathbb{Z}_\geq} \pi_j X_{t-j}. \quad (2.36)$$

Além disso, iremos assumir que o processo de inovação  $\{\varepsilon_t\}_{t \in \mathbb{Z}}$  tenha distribuição independente e identicamente distribuída *SaS*, tal que

$$\lim_{h \rightarrow \infty} \frac{\mathbb{P}(|\varepsilon_t| > xh)}{\mathbb{P}(|\varepsilon_t| > h)} = x^{-\alpha}, \quad \text{para todo } x > 0.$$

Para definirmos o novo preditor, considere uma variável aleatória  $Y = \sum_{j \in \mathbb{Z}} r_j \varepsilon_j$ , se  $\sum_{j \in \mathbb{Z}} |r_j|^\alpha < \infty$ , definimos a dispersão de  $Y$ , denotada por  $\text{disp } Y$ , da seguinte forma

$$\text{disp } Y = \sum_{j \in \mathbb{Z}} |r_j|^\alpha.$$

Veja que, podemos reescrever a equação (2.35), fazendo a seguinte mudança de variáveis  $j = t - i$ , ou seja,  $i = t - j$ ,

$$X_t = \sum_{i=-\infty}^{\infty} \psi_{t-i} \varepsilon_i, \quad \text{com } \psi_{t-i} = 0, \quad t - i < 0.$$

Então,

$$\text{disp}(X_t) = \sum_{j \in \mathbb{Z}} |\psi_j|^\alpha = \sum_{j \in \mathbb{Z}_\geq} |\psi_j|^\alpha.$$

Se  $Y = \sum_{j \in \mathbb{Z}} r_j \varepsilon_j$ , então, dada uma série  $\{X_t\}_{t=1}^N$ , definimos o preditor de dispersão linear com erro mínimo de  $Y$ , pela combinação linear

$$\hat{Y} = a_1 X_N + a_2 X_{N-1} + \cdots + a_N X_1,$$

em que os coeficiente  $a_1, \dots, a_N$  minimizam

$$\begin{aligned}
\text{disp}(\hat{Y} - Y) &= \text{disp} \left( a_1 X_N + \dots + a_N X_1 - \sum_{j \in \mathbb{Z}} r_j \varepsilon_j \right) \\
&= \text{disp} \left( a_1 \sum_{j \in \mathbb{Z}} \psi_{N-j} \varepsilon_j + \dots + a_N \sum_{j \in \mathbb{Z}} \psi_{1-j} \varepsilon_j - \sum_{j \in \mathbb{Z}} r_j \varepsilon_j \right) \\
&= \text{disp} \left( \sum_{j \in \mathbb{Z}} (a_1 \psi_{N-j} + \dots + a_N \psi_{1-j} - r_j) \varepsilon_j \right) \\
&= \sum_{j \in \mathbb{Z}} |r_j - (a_1 \psi_{N-j} + \dots + a_N \psi_{1-j})|^\alpha.
\end{aligned}$$

No caso em que  $Y = X_{N+k}$ , minimizamos, com relação à  $a_1, \dots, a_N$ ,

$$\text{disp}(\hat{X}_N(k) - X_{N+k}) = \sum_{j=0}^{k-1} |\psi_j|^\alpha + \sum_{j=k}^{\infty} |\psi_j - (a_1 \psi_{j-k} + \dots + a_N \psi_{j+1-N-k})|^\alpha,$$

pois, veja que

$$\begin{aligned}
\hat{X}_N(k) - X_{N+k} &= a_1 X_N + \dots + a_N X_1 - \sum_{j \in \mathbb{Z}} \psi_{N+k-j} \varepsilon_j \\
&= a_1 \sum_{j \in \mathbb{Z}} \psi_{N-j} \varepsilon_j + \dots + a_N \sum_{j \in \mathbb{Z}} \psi_{1-j} \varepsilon_j - \sum_{j \in \mathbb{Z}} \psi_{N+k-j} \varepsilon_j \\
&= \sum_{j \in \mathbb{Z}} (a_1 \psi_{N-j} + \dots + a_N \psi_{1-j} - \psi_{N+k-j}) \varepsilon_j.
\end{aligned}$$

Logo,

$$\text{disp}(\hat{X}_N(k) - X_{N+k}) = \sum_{i \in \mathbb{Z}} |\psi_{N+k-i} - (a_1 \psi_{N-i} + \dots + a_N \psi_{1-i})|^\alpha \quad (2.37)$$

$$\begin{aligned}
&= \sum_{j \in \mathbb{Z}} |\psi_{N+k-(k+N-j)} - (a_1 \psi_{N-(k+N-j)} + \dots \\
&\quad + a_N \psi_{1-(k+N-j)})|^\alpha \quad (2.38)
\end{aligned}$$

$$= \sum_{j \in \mathbb{Z}} |\psi_j - (a_1 \psi_{-k+j} + \dots + a_N \psi_{1-k-N+j})|^\alpha. \quad (2.39)$$

Obtemos a equação (2.38), fazendo a mudança de variável  $j = k + N - i$ , ou seja,  $i = k + N - j$ , na equação (2.37).

Como temos  $\psi_{j-k} \neq 0$ , apenas quando  $j - k \geq 0$ , ou seja, quando  $j \geq k$ , e

$\psi_{1-k-N+j} \neq 0$ , apenas quando  $1 - k - N + j \geq 0$ , ou seja, quando  $j \geq k + N - 1 \geq k$ , podemos escrever a equação (2.39) como

$$\text{disp}(\hat{X}_N(k) - X_{N+k}) = \sum_{j=0}^{k-1} |\psi_j|^\alpha + \sum_{j=k}^{\infty} |\psi_j - (a_1\psi_{j-k} + \cdots + a_N\psi_{j+1-N-k})|^\alpha.$$

No próximo capítulo iremos abordar diversos métodos de estimativa dos parâmetros dos processos definidos até o momento.

# Capítulo 3

## Estimação dos Parâmetros

Existem, na literatura de séries temporais, diversos estimadores para os parâmetros dos modelos. Por exemplo, precisamos de estimadores para o valor de  $\sigma_\epsilon^2, d, D$  e para os coeficientes dos polinômios  $\phi(\cdot), \Phi(\cdot), \theta(\cdot)$  e  $\Theta(\cdot)$  do processo SARFIMA( $p, d, q) \times (P, D, Q)_s$ . Assim, neste capítulo iremos abordar vários estimadores paramétricos (estimam todos os parâmetros) e semiparamétricos (estimam uma parte dos parâmetros). Iremos dividir este capítulo em duas seções: uma de estimadores semiparamétricos e outra de estimadores paramétricos.

A Seção 3.1 está dividida em 3 subseções. A Subseção 3.1.1 apresenta um estimador baseado na metodologia dos mínimos quadrados e duas metodologias robustas de regressão. Na Subseção 3.1.2 apresentamos um método de estimação dos parâmetros  $d$  e  $D$  baseado em análise de regressão, utilizando a função periodograma, proposto por Geweke e Porter-Hudak (1983). Na Subseção 3.1.3 apresentamos um método de estimação dos parâmetros  $d$  e  $D$  baseado em análise de regressão, utilizando a função periodograma suavizado de covariâncias, proposto por Reisen(1994). A Seção 3.2 está dividida em 8 subseções. Na Subseção 3.2.1 analisamos o estimador de máxima verossimilhança, que estima todos os parâmetros do modelo. Na Subseção 3.2.2 abordamos uma aproximação ao estimador de máxima verossimilhança, proposta por Fox e Taqqu (1986). Na Subseção 3.2.3 apresentamos uma modificação ao estimador de Fox e Taqqu (1986). Na Subseção 3.2.4 propomos outra modificação ao estimador de Fox e Taqqu (1986), utilizando a função periodograma suavizado de covariâncias. Na Subseção 3.2.5, apresentamos um es-

timador para os processos  $\alpha$ -estáveis, proposto por Klüppelberg e Mikosch (1996) para processos lineares gerais com processo de inovação  $\alpha$ -estável. Por fim, nas Subseções 3.2.6, 3.2.7 e 3.2.8 apresentamos três modificações ao estimador proposto por Klüppelberg e Mikosch (1996).

## 3.1 Estimadores Semiparamétricos

Nesta seção iremos apresentar dois estimadores semiparamétricos, que se baseiam em metodologia clássica e robusta de regressão. Estes estimadores estimam o parâmetro  $d$ , nos processos ARFIMA, e os parâmetros  $d$  e  $D$ , nos processos SARFIMA. Assim, esta é uma classe de estimadores que necessita de dois passos para estimar todos os parâmetros do processo. Primeiramente iremos trabalhar com processos com inovações na forma de ruído branco, posteriormente faremos uma observação para os processos com inovações  $\alpha$ -estáveis. Na primeira subseção iremos apresentar algumas propriedades de regressão clássica e robusta, visto que estas serão utilizadas nos estimadores semiparamétricos apresentados posteriormente.

### 3.1.1 Regressão Clássica e Robusta

Inicialmente, definimos o modelo de regressão linear geral com  $l$  variáveis independentes  $X_{tk}$ ,  $1 \leq k \leq l$ ,  $t$  fixo, e uma variável aleatória  $Y_t$  dependente, que possui a forma a seguir

$$Y_t = \eta_0 + \eta_1 X_{t1} + \cdots + \eta_l X_{tl} + \epsilon_t. \quad (3.1)$$

Assumindo  $g(N)$  independentes observações de  $Y_t$  associadas aos valores  $X_{tk}$ , para  $k \in \{1, \dots, l\}$ , o modelo (3.1) apresenta-se como

$$\begin{aligned}
Y_1 &= \eta_0 + \eta_1 X_{11} + \cdots + \eta_l X_{1l} + \epsilon_1 \\
Y_2 &= \eta_0 + \eta_1 X_{21} + \cdots + \eta_l X_{2l} + \epsilon_2 \\
&\vdots &&\vdots \\
Y_{g(N)} &= \eta_0 + \eta_1 X_{g(N)1} + \cdots + \eta_l X_{g(N)l} + \epsilon_{g(N)},
\end{aligned} \tag{3.2}$$

em que os erros  $\{\epsilon_j\}$ , satisfazem as seguintes suposições, para todo  $j \in \{1, \dots, g(N)\}$ ,

- a)  $\mathbb{E}(\epsilon_j) = 0$ ,
- b)  $Var(\epsilon_j) = \sigma_\epsilon^2$ ,
- c)  $Cov(\epsilon_j, \epsilon_k) = 0$ , se  $j \neq k$ .

O estimador de  $\boldsymbol{\eta} = (\eta_0, \eta_1, \dots, \eta_l)$  pelo método dos mínimos quadrados, denotado neste trabalho por  $MQ$ , é o valor  $\hat{\boldsymbol{\eta}}_{MQ} = (\hat{\eta}_0, \hat{\eta}_1, \dots, \hat{\eta}_l) \in \mathbb{R}^{l+1}$  que minimiza a função perda

$$\ell_1(g(N)) = \sum_{j=1}^{g(N)} r_j^2, \tag{3.3}$$

em que os resíduos  $r_j$  são dados por

$$r_j = y_j - \hat{\eta}_0 - \hat{\eta}_1 x_{j1} - \cdots - \hat{\eta}_l x_{jl}. \tag{3.4}$$

Os estimadores obtidos através do procedimento  $MQ$ , sob a hipótese de normalidade dos erros, são consistentes e tem mínima variância entre todos os estimadores não viciados. A presença de *outliers* e pontos de alavanca, que são observações muito distantes das demais, ou mesmo a perda da hipótese de normalidade dos erros são responsáveis por um considerável vício e ineficiência dos estimadores  $MQ$ , para maiores detalhes sobre o assunto, ver Bisognin (2007).

Considerando a presença de *outliers* e pontos de alavanca, surge uma nova proposta, que são os estimadores robustos. Estes não são afetados tão significativamente por *outliers*. Um procedimento de estimação robusta é o dos mínimos quadrados podados (denotados aqui por  $MQP$ ). Os estimadores baseados na regressão (3.2) e obtidos através do procedimento  $MQP$  são os valores  $\hat{\boldsymbol{\eta}}_{MQP} = (\hat{\eta}_0, \hat{\eta}_1, \dots, \hat{\eta}_l) \in \mathbb{R}^{l+1}$  que minimiza a função perda

$$\ell_2(g(N)) = \sum_{j=1}^{m^*} (r^2)_{j:\tilde{m}}, \quad (3.5)$$

em que  $(r^2)_{1:\tilde{m}} \leq \dots \leq (r^2)_{m^*:\tilde{m}}$  são os resíduos ao quadrado ordenados e  $m^*$  é o número de pontos usados no procedimento de otimização. O estimador  $MQP$  foi utilizado por Lopes e Mendes (2006) para a estimação do parâmetro de longa dependência dos processos ARFIMA( $p, d, q$ ) e por Bisognin (2007) para os processos SARFIMA( $p, d, q$ )  $\times$   $(P, D, Q)_s$  com inovações normais.

Outra classe de estimadores robustos utilizados em Lopes e Mendes (2006), denotados por MM, são definidos como a solução  $\hat{\eta}_{MM} = (\hat{\eta}_0, \hat{\eta}_1, \dots, \hat{\eta}_l) \in \mathbb{R}^{l+1}$  que minimiza a função perda

$$\ell_3(g(N)) = \sum_{j=1}^{g(N)} \rho_2 \left( \frac{r_j}{s} \right)^2, \quad (3.6)$$

sujeita a restrição

$$\frac{1}{n} \sum_{j=1}^{g(N)} \rho_1 \left( \frac{r_j}{s} \right) \leq b, \quad (3.7)$$

em que  $\rho_1(\cdot)$  e  $\rho_2(\cdot)$  são funções simétricas, limitadas e não decrescentes em  $[0, \infty)$ , com  $\rho_i(0) = 0$ ,  $\lim_{u \rightarrow \infty} \rho_i(u) = 1$ , para  $i = 1, 2$ ,  $s$  é um parâmetro de escala,  $b$  é definido por  $\mathbb{E}_\phi(\rho_1(u)) = b$ , onde  $\phi$  denota a função de distribuição acumulada da normal padrão e  $r_j$  são os resíduos dados pela equação (3.4), para todo  $j = 1, \dots, g(N)$ .

### 3.1.2 Estimador GPH

Procedimento proposto inicialmente por Geweke e Porter-Hudak (1983) para estimar o parâmetro  $d$  em um processo ARFIMA( $p, d, q$ ). Neste trabalho, apresentaremos uma adaptação baseada na proposta de Geweke e Porter-Hudak (1983) para estimar, além de o parâmetro  $d$ , o parâmetro  $D$ , em um processo SARFIMA( $p, d, q$ )  $\times$   $(P, D, Q)_s$ , proposto por Bisognin (2007).

Seja  $\{X_t\}_{t \in \mathbb{Z}}$  um processo SARFIMA( $p, d, q$ )  $\times$   $(P, D, Q)_s$ , com  $d, D \in (-0.5; 0.5)$ , conforme a Definição 2.9. A função densidade espectral deste processo é dada pela

expressão (2.21). Podemos reescrever a expressão (2.21) da seguinte forma

$$f_X(\lambda) = f_U(\lambda) \left| 2 \operatorname{sen} \left( \frac{\lambda}{2} \right) \right|^{-2d} \left| 2 \operatorname{sen} \left( \frac{s\lambda}{2} \right) \right|^{-2D}, \quad (3.8)$$

em que

$$f_U(\lambda) = \frac{\sigma_\varepsilon^2}{2\pi} \frac{|\theta(e^{-i\lambda})|^2}{|\phi(e^{-i\lambda})|^2} \frac{|\Theta(e^{-is\lambda})|^2}{|\Phi(e^{-is\lambda})|^2}, \quad (3.9)$$

para todo  $0 < \lambda \leq \pi$ .

Aplicando-se a função logarítmica a ambos os lados da equação (3.8), tem-se

$$\ln[f_X(\lambda)] = \ln[f_U(\lambda)] - d \ln \left[ 2 \operatorname{sen} \left( \frac{\lambda}{2} \right) \right]^2 - D \ln \left[ 2 \operatorname{sen} \left( \frac{s\lambda}{2} \right) \right]^2. \quad (3.10)$$

Então somando-se a ambos os lados da equação (3.10) os termos  $\ln[f_U(0)]$  e  $\ln[I_N(\lambda)]$ , em que  $I_N(\lambda)$  é a função periodograma dada pela expressão (1.16), obtemos

$$\begin{aligned} \ln[f_X(\lambda)] + \ln[I_N(\lambda)] &= \ln[f_U(\lambda)] - d \ln \left[ 2 \operatorname{sen} \left( \frac{\lambda}{2} \right) \right]^2 - D \ln \left[ 2 \operatorname{sen} \left( \frac{s\lambda}{2} \right) \right]^2 \\ &\quad + \ln[I_N(\lambda)] + \ln[f_U(0)] - \ln[f_U(0)], \end{aligned}$$

ou seja,

$$\begin{aligned} \ln[I_N(\lambda)] &= \ln[f_U(0)] - d \ln \left[ 2 \operatorname{sen} \left( \frac{\lambda}{2} \right) \right]^2 - D \ln \left[ 2 \operatorname{sen} \left( \frac{s\lambda}{2} \right) \right]^2 \\ &\quad + \ln[f_U(\lambda)] - \ln[f_U(0)] + \ln[I_N(\lambda)] - \ln[f_X(\lambda)]. \end{aligned}$$

Logo, utilizando algumas propriedades da função logarítmica, temos

$$\begin{aligned} \ln[I_N(\lambda)] &= \ln[f_U(0)] - d \ln \left[ 2 \operatorname{sen} \left( \frac{\lambda}{2} \right) \right]^2 - D \ln \left[ 2 \operatorname{sen} \left( \frac{s\lambda}{2} \right) \right]^2 \\ &\quad + \ln \left[ \frac{f_U(\lambda)}{f_U(0)} \right] + \ln \left[ \frac{I_N(\lambda)}{f_X(\lambda)} \right]. \end{aligned} \quad (3.11)$$

Substituindo  $\lambda$  pelas frequências de Fourier,  $\omega_j = \frac{2\pi j}{N}$ , na equação anterior, temos

$$\begin{aligned}\ln[I_N(\omega_j)] &= \ln[f_U(0)] - d \ln \left[ 2 \operatorname{sen} \left( \frac{\omega_j}{2} \right) \right]^2 - D \ln \left[ 2 \operatorname{sen} \left( \frac{s\omega_j}{2} \right) \right]^2 \\ &\quad + \ln \left[ \frac{f_U(\omega_j)}{f_U(0)} \right] + \ln \left[ \frac{I_N(\omega_j)}{f_X(\omega_j)} \right].\end{aligned}\quad (3.12)$$

Considerando o limite máximo de  $j$  igual a  $g(N)$ , tal que  $g(N) \rightarrow \infty$ ,  $\frac{g(N)}{N} \rightarrow 0$ , quando  $N \rightarrow \infty$ , e  $\omega_j \leq \omega_{g(N)}$ , em que  $\omega_{g(N)}$  é pequeno. Então o termo  $\ln \left[ \frac{f_U(\omega_j)}{f_U(0)} \right]$  é desprezível perante os demais termos da equação (3.12). Assim, temos uma aproximação para a equação (3.12), dada por

$$\begin{aligned}\ln[I_N(\omega_j)] &\simeq \ln[f_U(0)] - d \ln \left[ 2 \operatorname{sen} \left( \frac{\omega_j}{2} \right) \right]^2 - D \ln \left[ 2 \operatorname{sen} \left( \frac{s\omega_j}{2} \right) \right]^2 \\ &\quad + \ln \left[ \frac{I_N(\omega_j)}{f_X(\omega_j)} \right]\end{aligned}\quad (3.13)$$

A equação (3.13) é uma forma aproximada da equação de regressão linear múltipla, dada por

$$y_i \simeq \eta_0 + \eta_1 x_{j1} + \eta_2 x_{j2} + \epsilon_j, \quad \text{para todo } j = 1, 2, \dots, g(N), \quad (3.14)$$

em que

$$y_j = \ln[I_N(\omega_j)]; \quad x_{j1} = \ln \left[ 2 \operatorname{sen} \left( \frac{\omega_j}{2} \right) \right]^2; \quad x_{j2} = \ln \left[ 2 \operatorname{sen} \left( \frac{s\omega_j}{2} \right) \right]^2, \quad (3.15)$$

$$\epsilon_j = \ln \left[ \frac{I_N(\omega_j)}{f_X(\omega_j)} \right] + k; \quad \eta_0 = \ln[f_U(0)] - k; \quad k = \mathbb{E} \left( -\ln \left[ \frac{I_N(\omega_j)}{f_X(\omega_j)} \right] \right) \quad (3.16)$$

$$\eta_1 = -d \quad \text{e} \quad \eta_2 = -D. \quad (3.17)$$

Temos que,  $\epsilon_j$  são variáveis aleatórias não correlacionadas com média zero e variância constante, satisfazendo as exigências de um modelo de regressão linear. Os estimadores semiparamétricos pelo método de regressão linear são os valores  $\hat{\boldsymbol{\eta}} = (\hat{\eta}_0, \hat{\eta}_1, \hat{\eta}_2)$  que minimizam a função perda, dada pela equação (3.3). Assim, os estimadores para os parâmetros  $d$  e  $D$ , pelo método de Geweke e Porter Hudak (1983), são denotados por  $\hat{d}_{GPHMQ}$  e  $\hat{D}_{GPHMQ}$ . Quando utilizamos as metodologias

robustas de regressão, os estimadores para os parâmetros  $d$  e  $D$  são denotados por  $\hat{d}_{GPHMM}$  e  $\hat{D}_{GPHMM}$  ou  $\hat{d}_{GPHMQP}$  e  $\hat{D}_{GPHMQP}$ .

**Observação 3.1.** Neste trabalho iremos considerar  $g(N) = N^\kappa$ , com

$$\kappa \in \{0.5; 0.55; 0.60; \dots; \zeta\},$$

em que o último valor  $\zeta$ , depende do tamanho amostral  $N$ . Queremos um valor  $\zeta$  que compreenda o máximo de frequências de Fourier, no intervalo  $(0, \pi)$ . Assim, as frequências de Fourier  $\frac{2\pi j}{N}$  podem atingir no máximo  $\pi$ ; logo, o valor máximo de  $j$  que podemos considerar é

$$\frac{2\pi j}{N} = \pi \implies j = \frac{N}{2}.$$

Portanto,

$$g(N) = N^\zeta = \frac{N}{2} \implies \zeta = \frac{\ln(N/2)}{\ln(N)}.$$

**Observação 3.2.** Considerando  $\{X_t\}_{t \in \mathbb{Z}}$  um processo ARFIMA( $p, d, q$ ), então o estimador proposto por Geweke e Porter-Hudak (1983) tem a forma

$$\hat{d}_{GPH} = \frac{-\sum_{j=1}^{g(N)} (x_{j1} - \bar{x})y_j}{\sum_{j=1}^{g(N)} (x_{j1} - \bar{x})^2}. \quad (3.18)$$

Geweke e Porter-Hudak (1983) mostram que se  $d \in (-0.5; 0)$ , então

$$\lim_{N \rightarrow \infty} \hat{d}_{GPH} = d.$$

Além disso, se  $\lim_{N \rightarrow \infty} \frac{[\ln(N)]^2}{g(N)} = 0$ , então

$$\frac{\hat{d}_{GPH} - d}{\sqrt{Var(\hat{d}_{GPH})}} \xrightarrow{d} Z,$$

em que  $Z \sim N(0, 1)$  e  $Var(\hat{d}_{GPH}) = \frac{\pi^2}{6 \sum_{j=1}^{g(N)} (x_{j1} - \bar{x})^2}$ . Robinson (1995) estende este resultado para  $d \in (-0.5, 0.5)$ .

**Observação 3.3.** Para processos SARFIMA  $\alpha$ -estáveis, propomos um ajuste na metodologia apresentada nesta seção. Utilizamos, no lugar do periodograma, o periodograma normalizado, dado pela Definição 2.18, e no lugar da função densidade

espectral, a função poder de transferência, dada pelo Teorema 2.7 item c), ou seja,

$$\begin{aligned} g_X(\lambda) &= \frac{|\theta(e^{-i\lambda})|^2}{|\phi(e^{-i\lambda})|^2} \frac{|\Theta(e^{-is\lambda})|^2}{|\Phi(e^{-is\lambda})|^2} \left| 2 \operatorname{sen}\left(\frac{\lambda}{2}\right) \right|^{-2d} \left| 2 \operatorname{sen}\left(\frac{s\lambda}{2}\right) \right|^{-2D} \\ &= g_U(\lambda) \left| 2 \operatorname{sen}\left(\frac{\lambda}{2}\right) \right|^{-2d} \left| 2 \operatorname{sen}\left(\frac{s\lambda}{2}\right) \right|^{-2D}, \end{aligned}$$

em que

$$g_U(\lambda) = \frac{|\theta(e^{-i\lambda})|^2}{|\phi(e^{-i\lambda})|^2} \frac{|\Theta(e^{-is\lambda})|^2}{|\Phi(e^{-is\lambda})|^2}.$$

### 3.1.3 Estimador BA

Como visto na Seção 1.3, o periodograma (ver equação (1.16)) é um estimador não consistente da função densidade espectral de um processo. Como alternativa, definimos o periodograma suavizado de covariâncias (ver equação (1.18)), que sob certas condições, é um estimador consistente da função densidade espectral. Em virtude disso, Reisen (1994) sugere substituir o periodograma pelo periodograma suavizado de covariâncias, no estimador proposto por Geweke e Porter-Hudak (1983). Reisen (1994) sugere em seu estudo a utilização da janela de Parzen, mas afirma que outras janelas podem ser utilizadas. Neste trabalho utilizaremos a janela de Bartlett.

O processo de estimação é similar ao do estimador proposto por Geweke e Porter Hudak (1983), descrito na Seção 3.1.2, apenas substituindo a função periodograma pela função periodograma suavizado de covariâncias, com a janela de Bartlett, obtendo a seguinte equação

$$\begin{aligned} \ln[I_S(\omega_j)] &\simeq \ln[f_U(0)] - d \ln \left[ 2 \operatorname{sen}\left(\frac{\omega_j}{2}\right) \right]^2 - D \ln \left[ 2 \operatorname{sen}\left(\frac{s\omega_j}{2}\right) \right]^2 \\ &\quad + \ln \left[ \frac{I_S(\omega_j)}{f_X(\omega_j)} \right], \end{aligned} \tag{3.19}$$

em que  $\omega_j = \frac{2\pi j}{N}$  são as frequências de Fourier,  $j \in \{0, 1, 2, \dots, g(N)\}$ . A janela de Bartlett é dada pela seguinte expressão

$$\omega_M(h) = \begin{cases} 1 - \frac{|h|}{M}, & \text{se } |h| \leq M, \\ 0, & \text{se } |h| > M, \end{cases} \tag{3.20}$$

em que  $M$  é o ponto de truncamento da janela e  $M = N^\beta$  com  $0 < \beta < 1$ . Neste trabalho utilizamos  $\beta = 0.9$ .

Ao compararmos a equação (3.13) com a equação (3.19), vemos que a equação (3.19) também é uma forma aproximada da equação de regressão linear múltipla, dada por

$$y_i \simeq \eta_0 + \eta_1 x_{j1} + \eta_2 x_{j2} + \epsilon_j, \quad \forall j = 1, 2, \dots, g(N), \quad (3.21)$$

em que

$$y_j = \ln[I_S(\omega_j)]; \quad x_{j1} = \ln \left[ 2 \operatorname{sen} \left( \frac{\omega_j}{2} \right) \right]^2; \quad x_{j2} = \ln \left[ 2 \operatorname{sen} \left( \frac{s\omega_j}{2} \right) \right]^2, \quad (3.22)$$

$$\epsilon_j = \ln \left[ \frac{I_S(\omega_j)}{f_X(\omega_j)} \right] + k; \quad \eta_0 = \ln[f_U(0)] - k; \quad k = \mathbb{E} \left( -\ln \left[ \frac{I_S(\omega_j)}{f_X(\omega_j)} \right] \right); \quad (3.23)$$

$$\eta_1 = -d \quad \text{e} \quad \eta_2 = -D. \quad (3.24)$$

Assim, os estimadores semiparamétricos pelo método de regressão linear múltipla são os valores  $\hat{\boldsymbol{\eta}} = (\hat{\eta}_0, \hat{\eta}_1, \hat{\eta}_2)$  que minimizam a função perda, dada pela equação (3.3). Os estimadores para os parâmetros  $d$  e  $D$ , pelo método proposto por Reisen (1994), são denotados por  $\hat{d}_{BAMQ}$  e  $\hat{D}_{BAMQ}$ . Quando utilizamos as metodologias robustas de regressão, os estimadores para os parâmetros  $d$  e  $D$  são denotados por  $\hat{d}_{BAMM}$  e  $\hat{D}_{BAMM}$  ou  $\hat{d}_{BAMQP}$  e  $\hat{D}_{BAMQP}$ .

**Observação 3.4.** Para processos SARFIMA  $\alpha$ -estáveis, propomos um ajuste na metodologia apresentada nesta seção. Utilizamos, no lugar do periodograma, o periodograma normalizado suavizado de correlações, dado pela Definição 2.19, e no lugar da função densidade espectral, a função poder de transferência, dada pelo Teorema 2.7 item c).

## 3.2 Estimadores Paramétricos

Nesta seção iremos apresentar diversos estimadores paramétricos, ou seja, estimadores que estimam todos os parâmetros do processo. Os estimadores apresentados

nas Seções 3.2.1, 3.2.2, 3.2.3 e 3.2.4 são utilizados em processos com inovações na forma de ruído branco, enquanto os estimadores apresentados nas Seções 3.2.5, 3.2.6, 3.2.7 e 3.2.8 são utilizados em processos com inovações  $\alpha$ -estáveis.

### 3.2.1 Estimador EMV

O estimador de máxima verossimilhança é um estimador da classe paramétrica, isto é, tem a capacidade de estimar todos os parâmetros necessários de uma só vez. Para apresentar esse estimador, iremos considerar  $\{X_t\}_{t \in \mathbb{Z}}$  um processo SARFIMA  $(p, d, q) \times (P, D, Q)_s$  causal e inversível, de média zero, com inovações na forma de ruído branco com distribuição normal. Vamos denotar por  $\boldsymbol{\eta}$  o vetor com todos parâmetros desconhecidos, a saber

$$\boldsymbol{\eta} = (\sigma_\varepsilon^2, d, D, \phi_1, \dots, \phi_p, \Phi_1, \dots, \Phi_P, \theta_1, \dots, \theta_q, \Theta_1, \dots, \Theta_Q).$$

Assim, temos que  $\boldsymbol{\eta} \in \vartheta \subseteq \mathbb{R}^k$ ,  $k = p + q + P + Q + 3$ .

Seja  $X_1, \dots, X_N$  uma série temporal obtida do processo  $\{X_t\}_{t \in \mathbb{Z}}$ . Então, como estamos considerando um processo causal, podemos escrever

$$X_t = \sum_{j \in \mathbb{Z}_\geq} \psi_j \varepsilon_{t-j}, \quad t \in \{1, \dots, N\},$$

além disso, estamos considerando que  $\varepsilon_t \sim N(0, \sigma_\varepsilon^2)$ , para  $t \in \mathbb{Z}$ . Assim, a função de distribuição conjunta de  $\mathbf{X} = (X_1, \dots, X_N)'$  é normal multivariada, dada por

$$f(\mathbf{X}; \boldsymbol{\eta}) = (2\pi)^{-N/2} (\det \Sigma_N(\boldsymbol{\eta}))^{-1/2} e^{-\frac{1}{2} \mathbf{X} [\Sigma_N(\boldsymbol{\eta})]^{-1} \mathbf{X}'}, \quad (3.25)$$

em que  $\mathbf{X}' = (X_1, \dots, X_N)'$  e  $\Sigma_N(\boldsymbol{\eta})$  é a matriz quadrada  $N \times N$ , cujos elementos são dados por

$$[\Sigma_N(\boldsymbol{\eta})]_{ij} = \gamma_X(i - j), \quad i, j \in \{1, 2, \dots, N\}.$$

Logo, a função de verossimilhança é dada por

$$L(\boldsymbol{\eta}; \mathbf{X}) = (2\pi)^{-N/2} (\det \Sigma_N(\boldsymbol{\eta}))^{-1/2} e^{-\frac{1}{2} \mathbf{X} [\Sigma_N(\boldsymbol{\eta})]^{-1} \mathbf{X}'}, \quad (3.26)$$

e o logaritmo da função de verossimilhança é

$$\ell(\boldsymbol{\eta}; \mathbf{X}) = -\frac{N}{2} \ln(2\pi) - \frac{1}{2} \ln(\det \Sigma_N(\boldsymbol{\eta})) - \frac{1}{2} \mathbf{X}[\Sigma_N(\boldsymbol{\eta})]^{-1} \mathbf{X}'. \quad (3.27)$$

O estimador de máxima verossimilhança é o ponto de máximo da função de log-verossimilhança, dada por (3.27), com relação ao vetor de parâmetros  $\boldsymbol{\eta}$ , será denotado por  $\hat{\boldsymbol{\eta}}_{EMV}$ . Dahlhaus (1989) mostra que, sob determinadas condições, o estimador de máxima verossimilhança exato é consistente e assintoticamente converge para uma distribuição normal.

O estimador de máxima verossimilhança possui uma deficiência, que é seu baixo desempenho computacional. Para calcular o máximo da função de log-verossimilhança, faz-se necessário inverter matrizes, o que costuma ser muito demorado quando as matrizes são de ordem muito grande, por isso, especialmente para amostras muito grandes (valores grandes de  $N$ ), o estimador de máxima verossimilhança pode ser uma péssima escolha para estimar os parâmetros do processo.

Em virtude disso, Whittle (1951) sugeriu uma aproximação para a matriz de covariâncias  $\Sigma_N(\boldsymbol{\eta})$ , tal aproximação foi utilizada por Hannan (1973) e Fox e Taqqu (1986) para definir um novo estimador, que será abordado na próxima seção.

### 3.2.2 Estimador FT

O estimador proposto por Fox e Taqqu (1986) baseia-se em uma aproximação proposta por Whittle (1951). Inicialmente faremos a dedução para chegar ao estimador aproximado, partindo do estimador de máxima verossimilhança exato.

Veja que, na equação (3.27), o primeiro termo é constante com relação a  $\boldsymbol{\eta}$ , logo pode ser desconsiderado. Assim, precisamos de aproximações para os termos  $\frac{1}{2} \ln(\det \Sigma_N(\boldsymbol{\eta}))$  e  $\frac{1}{2} \mathbf{X}[\Sigma_N(\boldsymbol{\eta})]^{-1} \mathbf{X}'$ .

Para o termo  $\ln(\det \Sigma_N(\boldsymbol{\eta}))$  considere a seguinte aproximação,

$$\lim_{N \rightarrow \infty} \frac{1}{N} \ln(\det \Sigma_N(\boldsymbol{\eta})) = \ln(2\pi) + \frac{1}{2\pi} \int_{-\pi}^{\pi} \ln f_X(x; \boldsymbol{\eta}) dx, \quad (3.28)$$

em que  $f_X(x; \boldsymbol{\eta})$  é a função densidade espectral, que depende do vetor de parâmetros do processo. Nesta seção não iremos considerar o parâmetro  $\sigma_\varepsilon^2$  presente no vetor

$\boldsymbol{\eta}$ , assim  $\boldsymbol{\eta} \in \vartheta \subseteq \mathbb{R}^v$ ,  $v = p + q + P + Q + 2$ , com

$$\boldsymbol{\eta} = (d, D, \phi_1, \dots, \phi_p, \Phi_1, \dots, \Phi_P, \theta_1, \dots, \theta_q, \Theta_1, \dots, \Theta_Q).$$

Além disso, a igualdade (3.28) procede da teoria das matrizes Toeplitz, em Grenander e Szegö (1958, p.65). Temos que  $\Sigma_N(\boldsymbol{\eta})$  é uma forma de Toeplitz, visto que sua diagonal principal é constante. Segundo Grenander e Szegö (1958, p.17), uma forma de Toeplitz tem associada uma função  $f(\cdot)$ , que tem série de Fourier

$$f(x) = \sum_{n \in \mathbb{Z}} c_n e^{inx},$$

em que

$$c_n = \frac{1}{2\pi} \int_{-\pi}^{\pi} f(x) e^{-inx} dx. \quad (3.29)$$

Denotando por  $D_n(f)$  o determinante da forma Toeplitz relacionada a função  $f(\cdot)$ , Grenander e Szegö (1958, p.65) mostram que

$$\lim_{n \rightarrow \infty} [D_n(f)]^{1/n} = \exp \left[ \frac{1}{2\pi} \int_{-\pi}^{\pi} \ln f(x) dx \right]. \quad (3.30)$$

Veja que a função relacionada com a forma Toeplitz  $\Sigma_N(\boldsymbol{\eta})$ , é a função  $2\pi f_X(\lambda; \boldsymbol{\eta})$ , em que  $f_X(\lambda; \boldsymbol{\eta})$  é a função densidade espectral do processo. Isso ocorre devido ao fato que, a matriz  $\Sigma_N(\boldsymbol{\eta})$  é obtida a partir da função de autocovariâncias. Precisamos escrever a função de autocovariâncias de modo que ela fique na forma da equação (3.29). Pela Observação 1.4, podemos escrever

$$\gamma_X(n) = \int_{-\pi}^{\pi} f_X(\lambda; \boldsymbol{\eta}) e^{i\lambda n} d\lambda = \frac{1}{2\pi} \int_{-\pi}^{\pi} 2\pi f_X(\lambda; \boldsymbol{\eta}) e^{i\lambda n} d\lambda \quad (3.31)$$

$$= \frac{1}{2\pi} \int_{\pi}^{-\pi} 2\pi f_X(-x; \boldsymbol{\eta}) e^{-ixn} (-dx) \quad (3.32)$$

$$= \frac{1}{2\pi} \int_{-\pi}^{\pi} 2\pi f_X(x; \boldsymbol{\eta}) e^{-ixn} dx. \quad (3.33)$$

Onde, fazendo  $\lambda = -x$ , ou seja,  $d\lambda = -dx$ , na equação (3.31), obtemos a equação

(3.32).

Portanto, aplicando o resultado da equação (3.30), temos que

$$\begin{aligned}
\lim_{N \rightarrow \infty} [\det \Sigma_N(\boldsymbol{\eta})]^{1/N} &= \exp \left[ \frac{1}{2\pi} \int_{-\pi}^{\pi} \ln (2\pi f_X(x; \boldsymbol{\eta}) dx \right] \\
&= \exp \left[ \frac{1}{2\pi} \int_{-\pi}^{\pi} (\ln (2\pi) + \ln f_X(x; \boldsymbol{\eta})) dx \right] \\
&= \exp \left[ \ln (2\pi) + \frac{1}{2\pi} \int_{-\pi}^{\pi} \ln f_X(x; \boldsymbol{\eta}) dx \right]. \tag{3.34}
\end{aligned}$$

Consequentemente, aplicando a função logarítmica, obtemos

$$\lim_{N \rightarrow \infty} \frac{1}{N} \ln (\det \Sigma_N(\boldsymbol{\eta})) = \ln (2\pi) + \frac{1}{2\pi} \int_{-\pi}^{\pi} \ln f_X(x; \boldsymbol{\eta}) dx. \tag{3.35}$$

Observe que, para os processos que estão sendo abordados neste trabalho, podemos escrever sua função densidade espectral como

$$f_X(\lambda; \boldsymbol{\eta}) = \frac{\sigma_\epsilon^2}{2\pi} k(\lambda; \boldsymbol{\eta}), \tag{3.36}$$

em que a função  $k(\lambda; \boldsymbol{\eta})$  varia dependendo do processo que é considerado. Uma das condições impostas por Hannan (1973) e Fox e Taqqu (1986) para que valham os teoremas sobre a consistência e distribuição assintótica do estimador proposto por eles, é que esta função  $k(\lambda; \boldsymbol{\eta})$  seja normalizada, ou seja,

$$\int_{-\pi}^{\pi} \ln (k(\lambda; \boldsymbol{\eta})) d\lambda \equiv 0. \tag{3.37}$$

Na verdade, é possível demonstrar que a igualdade em (3.37) vale para processos SARFIMA causais e inversíveis (ver Bisognin, 2007). Assim, se utilizarmos essa

condição, podemos reescrever a equação (3.28), obtendo

$$\begin{aligned}
\lim_{N \rightarrow \infty} \frac{1}{N} \ln (\det \Sigma_N(\boldsymbol{\eta})) &= \ln (2\pi) + \frac{1}{2\pi} \int_{-\pi}^{\pi} \ln \left[ \frac{\sigma_\varepsilon^2}{2\pi} k(x; \boldsymbol{\eta}) \right] dx \\
&= \ln (2\pi) + \ln \left[ \frac{\sigma_\varepsilon}{2\pi} \right] + \underbrace{\frac{1}{2\pi} \int_{-\pi}^{\pi} \ln [k(x; \boldsymbol{\eta})] dx}_0 \\
&= \ln (\sigma_\varepsilon^2).
\end{aligned} \tag{3.38}$$

Assim, encontramos uma aproximação que depende apenas de  $\sigma_\varepsilon^2$ , que não estamos considerando presente no vetor de parâmetros desconhecidos. Logo, é um termo constante com relação à  $\boldsymbol{\eta}$ . Portanto, nesta aproximação podemos desconsiderar o termo  $\frac{1}{2} \ln (\det \Sigma_N(\boldsymbol{\eta}))$  da equação (3.27).

Agora falta encontrarmos uma aproximação para o termo  $\frac{1}{2} \mathbf{X} [\Sigma_N(\boldsymbol{\eta})]^{-1} \mathbf{X}'$  da equação (3.27). Whittle (1951) propôs aproximar a matriz  $[\Sigma_N(\boldsymbol{\eta})]^{-1}$  pela matriz  $A_N(\boldsymbol{\eta})$ , de ordem  $N \times N$ , com entradas  $[A_N(\boldsymbol{\eta})]_{ij} = a_{i-j}(\boldsymbol{\eta})$ , em que

$$a_j(\boldsymbol{\eta}) = \frac{1}{(2\pi)^2} \int_{-\pi}^{\pi} e^{ijx} [k(x; \boldsymbol{\eta})]^{-1} dx. \tag{3.39}$$

Então, podemos reescrever a equação (3.27) como

$$\ell(\boldsymbol{\eta}; \mathbf{X}) = -\frac{N}{2} \ln (2\pi) - \frac{N}{2} \sigma_\varepsilon^2 - \frac{1}{2} \mathbf{X} A_N(\boldsymbol{\eta}) \mathbf{X}'. \tag{3.40}$$

Se multiplicarmos por  $-\frac{2}{N}$  a expressão acima, temos

$$-\frac{2}{N} \ell(\boldsymbol{\eta}; \mathbf{X}) = \ln (2\pi) + \sigma_\varepsilon^2 + \frac{\mathbf{X} A_N(\boldsymbol{\eta}) \mathbf{X}'}{N}. \tag{3.41}$$

Note que maximizar a expressão (3.40), é o mesmo que minimizar a expressão (3.41). Também observe que somente o último termo da expressão acima depende de  $\boldsymbol{\eta}$ . Logo, o estimador de máxima verossimilhança aproximado é o valor  $\boldsymbol{\eta}$ , no qual a função  $\mathcal{L}(\boldsymbol{\eta}; \mathbf{X})$  abaixo é mínima.

$$\mathcal{L}(\boldsymbol{\eta}; \mathbf{X}) = \frac{\mathbf{X} A_N(\boldsymbol{\eta}) \mathbf{X}'}{N}. \tag{3.42}$$

Denotamos o estimador de máxima verossimilhança aproximado por  $\hat{\boldsymbol{\eta}}_{FT}$ .

Fox e Taqqu (1986) utilizam o fato de

$$\mathcal{L}(\boldsymbol{\eta}; \mathbf{X}) = \frac{\mathbf{X} A_N(\boldsymbol{\eta}) \mathbf{X}'}{N} = \frac{1}{2\pi} \int_{-\pi}^{\pi} \frac{I_N(x)}{k(x; \boldsymbol{\eta})} dx \quad (3.43)$$

para propor um novo estimador para o vetor de parâmetros  $\boldsymbol{\eta}$ . Além disso, para estimar a variância do processo de inovação, fazem  $\hat{\sigma}_\varepsilon^2 = 2\pi\mathcal{L}(\hat{\boldsymbol{\eta}}; \mathbf{X})$ .

Fox e Taqqu (1986) demonstram que, sob certas condições, os estimadores de  $\boldsymbol{\eta}$  e  $\sigma_\varepsilon^2$  são consistentes e que  $\hat{\boldsymbol{\eta}}_{FT}$  tem distribuição assintótica normal.

Na prática, para utilizarmos o estimador proposto por Fox e Taqqu (1986), considera-se a soma nas frequências de Fourier, ao invés da integral, assim minimizamos a seguinte função com relação a  $\boldsymbol{\eta}$

$$\mathcal{L}^*(\boldsymbol{\eta}; \mathbf{X}) = \frac{1}{N} \sum_t \frac{I_N(\omega_t)}{k(\omega_t; \boldsymbol{\eta})}, \quad (3.44)$$

em que  $\omega_t = \frac{2\pi t}{N}$  são as frequências de Fourier,  $t \in \mathbb{Z}, -\frac{N}{2} < t \leq \lfloor \frac{N}{2} \rfloor$  ( $\lfloor x \rfloor$  é a parte inteira de x). Hannan (1973) mostra que os resultados sobre consistência e distribuição assintótica também valem considerando esta aproximação.

Na próxima seção vamos definir um novo estimador, baseado na proposta de Fox e Taqqu (1986). Provaremos que este novo estimador apresenta as mesmas propriedades do estimador proposto por Fox e Taqqu (1986).

### 3.2.3 Estimador FTmod

Como visto na seção anterior, na prática, para utilizarmos o estimador proposto por Fox e Taqqu (1986), considera-se a soma nos coeficientes de Fourier, no lugar da integral. Assim, vamos modificar o estimador original, calculando a função  $\mathcal{L}^*(\boldsymbol{\eta}; \mathbf{X})$ , dada pela expressão (3.44), não apenas nas frequências de Fourier, passando a calcular em mais frequências.

Considere a seguinte função

$$S_N^2(\boldsymbol{\eta}) = \frac{1}{cN} \sum_t \frac{I_N(\omega_{ct})}{k(\omega_{ct}; \boldsymbol{\eta})}, \quad (3.45)$$

em que  $\omega_{ct} = \frac{2\pi t}{cN}$ , com  $c \in \mathbb{N} - \{1\}$  fixo e finito,  $t \in \mathbb{Z}, -\frac{cN}{2} < t \leq \lfloor \frac{cN}{2} \rfloor$ . O estimador modificado que estamos propondo, denotado por  $\hat{\boldsymbol{\eta}}_N$ , é o valor de  $\boldsymbol{\eta}$ , no qual a função dada pela equação (3.45) é mínima. Além disso, o estimador da variância do processo de inovação é dado por  $\hat{\sigma}_\varepsilon^2 = 2\pi S_N^2(\hat{\boldsymbol{\eta}}_N)$ .

Na aproximação original, calcula-se a soma em  $N$  frequências, com essa nova proposta estaremos somando em  $cN$  frequências. Pretende-se, assim, aprimorar os resultados obtidos com o estimador original.

Para demonstrar os teoremas sobre a consistência desse estimador e de sua distribuição assintótica normal, precisamos supor que valem algumas condições. Vamos considerar  $\{X_t\}_{t \in \mathbb{Z}}$  um processo estacionário, causal e inversível, com média zero e função densidade espectral  $f_X(\lambda; \boldsymbol{\eta}) = \frac{\sigma_\varepsilon^2}{2\pi} k(\lambda; \boldsymbol{\eta})$ , em que  $\sigma_\varepsilon^2$  é a variância do processo de inovação ruído branco,  $\boldsymbol{\eta}$  é o vetor de parâmetros a ser estimado,  $\boldsymbol{\eta} \in \vartheta \subseteq \mathbb{R}^v$  compacto,  $v = p + q + P + Q + 2$ , com

$$\boldsymbol{\eta} = (d, D, \phi_1, \dots, \phi_p, \Phi_1, \dots, \Phi_P, \theta_1, \dots, \theta_q, \Theta_1, \dots, \Theta_Q).$$

Também supomos que a função  $k(\lambda; \boldsymbol{\eta})$  é normalizada, isto é,

$$\int_{-\pi}^{\pi} \ln(k(\lambda; \boldsymbol{\eta})) d\lambda = 0.$$

Considere  $\boldsymbol{\eta}_0$  e  $\sigma_0^2$  o real valor dos parâmetros e suponha que  $\boldsymbol{\eta}_0$  pertence ao interior de  $\vartheta$ . Ainda considere  $\vartheta_0 = \{\boldsymbol{\eta} \in \vartheta; k(\lambda; \boldsymbol{\eta}) > 0, \lambda \in [-\pi, \pi]\}$ , tal que

$$\inf_{\boldsymbol{\eta} \in \vartheta_0} \frac{1}{2\pi} \int_{-\pi}^{\pi} \frac{k(\lambda; \boldsymbol{\eta}_0)}{k(\lambda; \boldsymbol{\eta})} d\lambda = 1.$$

Além destas condições, supomos que a função  $k(\lambda; \boldsymbol{\eta})$  satisfaz uma série de condições que chamaremos de condições A.

Condições A: Existe  $0 < \alpha(\boldsymbol{\eta}) < 1$  tal que para cada  $\delta > 0$ :

A1)  $g(\boldsymbol{\eta}) = \int_{-\pi}^{\pi} \ln(k(x; \boldsymbol{\eta})) dx$  pode ser diferenciada duas vezes sob o sinal da integral;

A2)  $k(x; \boldsymbol{\eta})$  é contínua para todo  $(x; \boldsymbol{\eta}), x \neq 0$ ,  $[k(x; \boldsymbol{\eta})]^{-1} = k^{-1}(x; \boldsymbol{\eta})$  é contínua

para todo  $(x; \boldsymbol{\eta})$  e

$$k(x; \boldsymbol{\eta}) = O(|x|^{-\alpha(\boldsymbol{\eta})-\delta}), \quad \text{quando } x \rightarrow 0;$$

A3)  $\frac{\partial}{\partial \eta_j} k^{-1}(x; \boldsymbol{\eta})$  e  $\frac{\partial^2}{\partial \eta_j \partial \eta_k} k^{-1}(x; \boldsymbol{\eta})$  são contínuas para todo  $(x; \boldsymbol{\eta})$ ,

$$\frac{\partial}{\partial \eta_j} k^{-1}(x; \boldsymbol{\eta}) = O(|x|^{\alpha(\boldsymbol{\eta})-\delta}), \quad \text{quando } x \rightarrow 0, \quad 1 \leq j \leq v$$

e

$$\frac{\partial^2}{\partial \eta_j \partial \eta_k} k^{-1}(x; \boldsymbol{\eta}) = O(|x|^{\alpha(\boldsymbol{\eta})-\delta}), \quad \text{quando } x \rightarrow 0, \quad 1 \leq j, k \leq v;$$

A4)  $\frac{\partial}{\partial x} k(x; \boldsymbol{\eta})$  é contínua para todo  $(x; \boldsymbol{\eta}), x \neq 0$ , e

$$\frac{\partial}{\partial x} k(x; \boldsymbol{\eta}) = O(|x|^{-\alpha(\boldsymbol{\eta})-1-\delta}), \quad \text{quando } x \rightarrow 0;$$

A5)  $\frac{\partial^2}{\partial x \partial \eta_j} k^{-1}(x; \boldsymbol{\eta})$  é contínua para todo  $(x; \boldsymbol{\eta}), x \neq 0$ , e

$$\frac{\partial^2}{\partial x \partial \eta_j} k^{-1}(x; \boldsymbol{\eta}) = O(|x|^{\alpha(\boldsymbol{\eta})-1-\delta}), \quad \text{quando } x \rightarrow 0, \quad 1 \leq j \leq v;$$

A6)  $\frac{\partial^3}{\partial^2 x \partial \eta_j} k^{-1}(x; \boldsymbol{\eta})$  é contínua para todo  $(x; \boldsymbol{\eta}), x \neq 0$ , e

$$\frac{\partial^3}{\partial^2 x \partial \eta_j} k^{-1}(x; \boldsymbol{\eta}) = O(|x|^{\alpha(\boldsymbol{\eta})-2-\delta}), \quad \text{quando } x \rightarrow 0, \quad 1 \leq j \leq v;$$

A notação  $f(x) = O(g(x))$ , quando  $x \rightarrow a$ , quer dizer que, existem  $M, \delta > 0$  tais que  $|f(x)| \leq M|g(x)|$ , para  $|x - a| < \delta$ .

Além das condições acima apresentadas, iremos supor que as funções  $\frac{\partial}{\partial \boldsymbol{\eta}} k^{-1}(\lambda; \boldsymbol{\eta}_0)$  e  $\frac{\partial}{\partial \boldsymbol{\eta}} \ln(k(\lambda; \boldsymbol{\eta}_0))$  são de classe Lipschitz  $\Lambda_\alpha$ ,  $\alpha > \frac{1}{2}$ , ou seja,

$$\sup \left| \frac{\partial}{\partial \boldsymbol{\eta}} k^{-1}(\lambda_1; \boldsymbol{\eta}_0) - \frac{\partial}{\partial \boldsymbol{\eta}} k^{-1}(\lambda_2; \boldsymbol{\eta}_0) \right| = O(\delta^\alpha), \quad \text{para } |\lambda_1 - \lambda_2| \leq \delta$$

e

$$\sup \left| \frac{\partial}{\partial \boldsymbol{\eta}} \ln k(\lambda_1; \boldsymbol{\eta}_0) - \frac{\partial}{\partial \boldsymbol{\eta}} \ln k(\lambda_2; \boldsymbol{\eta}_0) \right| = O(\delta^\alpha), \quad \text{para } |\lambda_1 - \lambda_2| \leq \delta.$$

Para maiores detalhes sobre função Lipschitz, ver Zygmund (1959, p.42).

Em todos os lemas, proposições e teoremas desta seção serão consideradas todas estas condições apresentadas.

Os dois teoremas a seguir apresentam as propriedades de consistência e distribuição assintótica do estimador  $\hat{\boldsymbol{\eta}}_N$ , obtido minimizando-se a equação (3.45).

**Teorema 3.1.** *Sob as condições A, com probabilidade 1,*

$$\lim_{N \rightarrow \infty} \hat{\boldsymbol{\eta}}_N = \boldsymbol{\eta}_0,$$

e

$$\lim_{N \rightarrow \infty} S_N^2(\hat{\boldsymbol{\eta}}_N) = \frac{\sigma_0^2}{2\pi}.$$

**Teorema 3.2.** *Sob as condições A, o vetor aleatório  $\sqrt{N}(\hat{\boldsymbol{\eta}}_N - \boldsymbol{\eta}_0)$  converge em distribuição a um vetor normal com média zero e matriz de covariâncias  $\Omega^{-1}(\boldsymbol{\eta}_0)$ , em que a  $(j, k)$ -ésima entrada da matriz  $\Omega(\boldsymbol{\eta})$  é dada por*

$$\Omega_{jk}(\boldsymbol{\eta}) = \frac{1}{4\pi} \int_{-\pi}^{\pi} \frac{\partial}{\partial \eta_j} \ln(k(\lambda; \boldsymbol{\eta})) \frac{\partial}{\partial \eta_k} \ln(k(\lambda; \boldsymbol{\eta})) d\lambda. \quad (3.46)$$

Para demonstrar esses teoremas, iremos utilizar alguns lemas, que serão apresentados a seguir.

**Lema 3.1.** *Quando  $\boldsymbol{\eta} \in \vartheta_0$ , temos que*

$$\lim_{N \rightarrow \infty} S_N^2(\boldsymbol{\eta}) = \frac{\sigma_0^2}{(2\pi)^2} \int_{-\pi}^{\pi} \frac{k(\lambda; \boldsymbol{\eta}_0)}{k(\lambda; \boldsymbol{\eta})} d\lambda.$$

**Demonstração:** Dado  $\epsilon > 0$ . Seja  $q_T(\lambda; \boldsymbol{\eta}) > 0$ , com  $\lambda \in [-\pi, \pi]$ , a soma de Cesaro, com  $T$  termos, da série de Fourier de  $\frac{1}{k(\lambda; \boldsymbol{\eta})}$ . Esta é dada pela convolução entre a função  $\frac{1}{k(\lambda; \boldsymbol{\eta})}$  e o núcleo de Féjer de ordem  $T$  (ver Iório, 2007, p.134). Definimos o núcleo de Féjer de ordem  $T$  como a função  $K_T : \mathbb{R} \rightarrow \mathbb{C}$ , dada por

$$K_T(x) = \sum_{n=-T}^T \left(1 - \frac{|n|}{T}\right) e^{inx}, \quad \text{em que } x \in \mathbb{R}.$$

Logo, temos que

$$\begin{aligned}
q_T(\lambda; \boldsymbol{\eta}) &= k^{-1} * K_T(\lambda) = \frac{1}{2\pi} \int_{-\pi}^{\pi} \frac{1}{k(x; \boldsymbol{\eta})} \sum_{n=-T}^T \left(1 - \frac{|n|}{T}\right) e^{in(\lambda-x)} dx \\
&= \sum_{n=-T}^T \left(1 - \frac{|n|}{T}\right) \frac{1}{2\pi} \int_{-\pi}^{\pi} \frac{1}{k(x; \boldsymbol{\eta})} e^{in(\lambda-x)} dx \\
&= \sum_{n=-T}^T \left(1 - \frac{|n|}{T}\right) e^{in\lambda} \underbrace{\frac{1}{2\pi} \int_{-\pi}^{\pi} \frac{1}{k(x; \boldsymbol{\eta})} e^{-inx} dx}_{c_n} \\
&= \sum_{n=-T}^T c_n \left(1 - \frac{|n|}{T}\right) e^{in\lambda},
\end{aligned}$$

em que  $c_n$  é o  $n$ -ésimo coeficiente de Fourier de  $\frac{1}{k(x; \boldsymbol{\eta})}$ .

Podemos escolher  $T$  suficientemente grande de forma que

$$\left| \frac{1}{k(\lambda; \boldsymbol{\eta})} - q_T(\lambda; \boldsymbol{\eta}) \right| < \frac{\epsilon}{H},$$

em que  $H = \frac{1}{cN} \sum_t I_N(\omega_{ct}) < \infty$ , pois temos uma soma finita de elementos finitos, em que  $\omega_{ct} = \frac{2\pi t}{cN}$ , com  $c \in \mathbb{N} - \{1\}$  fixo e finito,  $t \in \mathbb{Z}$ ,  $-\frac{cN}{2} < t \leq \lfloor \frac{cN}{2} \rfloor$ . A convergência é uniforme, pois a soma de Cesaro converge uniformemente em  $(\lambda; \boldsymbol{\eta})$ , para  $\boldsymbol{\eta} \in \vartheta_0$ , pois  $\frac{1}{k(\lambda; \boldsymbol{\eta})}$  é uma função contínua e periódica, de período  $2\pi$  (para maiores detalhes ver Iório, 2007, p.135).

Então, temos que

$$\begin{aligned}
\left| S_N^2(\boldsymbol{\eta}) - \frac{1}{cN} \sum_t I_N(\omega_{ct}) q_T(\omega_{ct}; \boldsymbol{\eta}) \right| &= \left| \frac{1}{cN} \sum_t I_N(\omega_{ct}) \left( \frac{1}{k(\omega_{ct}; \boldsymbol{\eta})} - q_T(\omega_{ct}; \boldsymbol{\eta}) \right) \right| \\
&\leq \frac{1}{cN} \sum_t I_N(\omega_{ct}) \underbrace{\left| \frac{1}{k(\omega_{ct}; \boldsymbol{\eta})} - q_T(\omega_{ct}; \boldsymbol{\eta}) \right|}_{<\epsilon/H} \\
&< \frac{1}{cN} \sum_t I_N(\omega_{ct}) \frac{\epsilon}{H} = \epsilon.
\end{aligned}$$

Por outro lado, veja que

$$\begin{aligned} \frac{1}{cN} \sum_t I_N(\omega_{ct}) q_T(\omega_{ct}; \boldsymbol{\eta}) &= \frac{1}{cN} \sum_t I_N(\omega_{ct}) \sum_{n=-T}^T c_n \left(1 - \frac{|n|}{T}\right) e^{in\omega_{ct}} \\ &= \sum_{n=-T}^T c_n \left(1 - \frac{|n|}{T}\right) \frac{1}{cN} \sum_t I_N(\omega_{ct}) e^{in\omega_{ct}}. \end{aligned}$$

Utilizando a equação (1.17) obtemos a seguinte expressão,

$$\begin{aligned} \frac{1}{cN} \sum_t I_N(\omega_{ct}) q_T(\omega_{ct}; \boldsymbol{\eta}) &= \frac{1}{2\pi} \sum_{n=-T}^T c_n \left(1 - \frac{|n|}{T}\right) \sum_t \frac{1}{cN} \sum_{|h|<N} \hat{\gamma}_X(h) e^{-i\omega_{ct}(h-n)} \\ &= \frac{1}{2\pi} \sum_{n=-T}^T c_n \left(1 - \frac{|n|}{T}\right) \frac{1}{cN} \sum_{|h|<N} \hat{\gamma}_X(h) \sum_t e^{-i\omega_{ct}(h-n)}. \end{aligned}$$

Assim, precisamos calcular o somatório  $\sum_t e^{-i\omega_{ct}(h-n)}$ . Para isso, veja que

$$\begin{aligned} \sum_{t=-\lfloor \frac{cN+1}{2} \rfloor}^{\lfloor \frac{cN}{2} \rfloor} e^{-i\frac{2\pi t}{cN}(h-n)} &= \frac{e^{-i\frac{2\pi}{cN}(-\lfloor \frac{cN+1}{2} \rfloor)(h-n)} [1 - \overbrace{(e^{-i\frac{2\pi}{cN}(h-n)})^{cN}}^{=1}]}{1 - e^{-i\frac{2\pi}{cN}(h-n)}} \\ &= \begin{cases} 0, & \text{se } e^{-i\frac{2\pi}{cN}(h-n)} \neq 1, \\ cN, & \text{se } e^{-i\frac{2\pi}{cN}(h-n)} = 1. \end{cases} \end{aligned} \quad (3.47)$$

Temos que

$$e^{-i\frac{2\pi}{cN}(h-n)} = 1 \quad \text{se e somente se } h - n = L(cN), \quad \text{em que } L \in \mathbb{Z}.$$

Então, vamos supor que  $N > T$ , sem perda de generalidade, pois estamos buscando propriedades assintóticas do estimador, isto é, quando o tamanho da amostra tende ao infinito. Podemos dividir em 3 casos:

1º) Se  $h - n = 0$ , então  $h = n$ , logo

$$\sum_{t=-\lfloor \frac{cN+1}{2} \rfloor}^{\lfloor \frac{cN}{2} \rfloor} e^{-i\frac{2\pi t}{cN}0} = \sum_{t=-\lfloor \frac{cN+1}{2} \rfloor}^{\lfloor \frac{cN}{2} \rfloor} 1 = cN.$$

2º) Se  $n < 0$ , então  $-T \leq n < 0$ , ou seja,  $0 < -n \leq T$ . Além disso,  $-N + 1 \leq h \leq N - 1$ .

Então,

$$-N + 1 \leq h < h - n \leq h + T \leq N - 1 + T,$$

como  $N > T$ , temos que  $-N + 1 < h - n < 2N - 1$ . Veja que o expoente  $h - n$  não passa pelos múltiplos de  $cN$ , com exceção do zero. Logo, a soma dada na equação (3.47) só será diferente de zero no caso  $h - n = 0$ , que já foi tratado anteriormente.

3º) Se  $n > 0$ , então  $0 < n \leq T$ , ou seja,  $-T \leq -n < 0$ . Além disso,  $-N + 1 \leq h \leq N - 1$ .

Então,

$$-N + 1 - T \leq h - T < h - n < h \leq N - 1,$$

como  $-N < -T$ , temos que  $-2N + 1 < h - n < N - 1$ . Veja que o expoente  $h - n$  não passa pelos múltiplos de  $cN$ , exceto o zero. Logo, a soma dada na equação (3.47) só será diferente de zero no caso  $h - n = 0$ , que já foi tratado anteriormente.

Portanto, podemos escrever

$$\begin{aligned} \frac{1}{cN} \sum_t I_N(\omega_{ct}) q_T(\omega_{ct}; \boldsymbol{\eta}) &= \frac{1}{2\pi} \sum_{n=-T}^T c_n \left(1 - \frac{|n|}{T}\right) \frac{1}{cN} \hat{\gamma}_X(n) cN \\ &= \frac{1}{2\pi} \sum_{n=-T}^T c_n \left(1 - \frac{|n|}{T}\right) \hat{\gamma}_X(n). \end{aligned}$$

Como temos que  $\hat{\gamma}_X(n)$  converge quase certamente para  $\gamma_X(n)$  (para maiores detalhes, ver Brockwell e Davis, 1991, p.376), então

$$\frac{1}{cN} \sum_t I_N(\omega_{ct}) q_T(\omega_{ct}; \boldsymbol{\eta}) \rightarrow \frac{1}{2\pi} \sum_{n=-T}^T c_n \left(1 - \frac{|n|}{T}\right) \gamma_X(n), \quad \text{com probabilidade 1.}$$

Podemos escrever a função de autocovariância em termos da função densidade espectral do processo, da seguinte forma  $\gamma_X(n) = \int_{-\pi}^{\pi} e^{in\lambda} f_X(\lambda; \boldsymbol{\eta}_0) d\lambda$ .

Também, temos que  $f_X(\lambda; \boldsymbol{\eta}_0) = \frac{\sigma_0^2}{2\pi} k(\lambda; \boldsymbol{\eta}_0)$ .

Logo, segue que

$$\begin{aligned}
\frac{1}{cN} \sum_t I_N(\omega_{ct}) q_T(\omega_{ct}; \boldsymbol{\eta}) &\rightarrow \frac{1}{2\pi} \sum_{n=-T}^T c_n \left(1 - \frac{|n|}{T}\right) \int_{-\pi}^{\pi} e^{in\lambda} \frac{\sigma_0^2}{2\pi} k(\lambda; \boldsymbol{\eta}_0) d\lambda \\
&= \int_{-\pi}^{\pi} \frac{1}{2\pi} \frac{\sigma_0^2}{2\pi} \underbrace{\sum_{n=-T}^T c_n \left(1 - \frac{|n|}{T}\right) e^{in\lambda}}_{q_T(\lambda; \boldsymbol{\eta})} k(\lambda; \boldsymbol{\eta}_0) d\lambda \\
&= \frac{\sigma_0^2}{(2\pi)^2} \int_{-\pi}^{\pi} q_T(\lambda; \boldsymbol{\eta}) k(\lambda; \boldsymbol{\eta}_0) d\lambda.
\end{aligned}$$

Assim, temos

$$\left| S_N^2(\boldsymbol{\eta}) - \frac{\sigma_0^2}{(2\pi)^2} \int_{-\pi}^{\pi} q_T(\lambda; \boldsymbol{\eta}) k(\lambda; \boldsymbol{\eta}_0) d\lambda \right| < \epsilon.$$

Como a soma de Cesaro  $q_T(\lambda; \boldsymbol{\eta})$  converge uniformemente para a função  $k^{-1}(\lambda; \boldsymbol{\eta})$ , segue o resultado do lema.  $\blacksquare$

O lema a seguir não será demonstrado, mas sua demonstração pode ser encontrada em Hannan (1973) e Brockwell e Davis (1991, p.377).

**Lema 3.2.**

$$\frac{1}{2\pi} \int_{-\pi}^{\pi} \frac{k(\lambda; \boldsymbol{\eta}_0)}{k(\lambda; \boldsymbol{\eta})} d\lambda > 1, \quad \text{para } \boldsymbol{\eta} \neq \boldsymbol{\eta}_0.$$

Com estes dois lemas, já podemos demonstrar o Teorema 3.1.

**Demonstração do Teorema 3.1:**

Suponha, por absurdo, que  $\hat{\boldsymbol{\eta}}_N$  não converge para  $\boldsymbol{\eta}_0$ , então existe uma subsequência convergindo para  $\boldsymbol{\eta}' \in \vartheta$ , com  $\boldsymbol{\eta}_0 \neq \boldsymbol{\eta}'$ .

Vamos chamar esta subsequência de  $\hat{\boldsymbol{\eta}}_m$ , em que  $m$  é uma subsequência de  $\mathbb{N}$ . Pelos Lemas 3.1 e 3.2, temos que

$$\begin{aligned}
\lim_{m \rightarrow \infty} S_m^2(\hat{\boldsymbol{\eta}}_m) &= \lim_{m \rightarrow \infty} \frac{1}{cN} \sum_t \frac{I_N(\omega_{ct})}{k(\omega_{ct}; \hat{\boldsymbol{\eta}}_m)} \\
&= \frac{\sigma_0^2}{(2\pi)^2} \int_{-\pi}^{\pi} \frac{k(\lambda; \boldsymbol{\eta}_0)}{k(\lambda; \boldsymbol{\eta}')} d\lambda > \frac{\sigma_0^2}{2\pi}.
\end{aligned}$$

Entretanto, como  $\hat{\boldsymbol{\eta}}_m$  é o ponto de mínimo de  $S_N^2(\boldsymbol{\eta})$ , por definição, existe algum  $\boldsymbol{\eta} \in \vartheta$ , tal que

$$\lim_{m \rightarrow \infty} S_m^2(\hat{\boldsymbol{\eta}}_m) \leq \lim_{m \rightarrow \infty} S_m^2(\boldsymbol{\eta}). \quad (3.48)$$

Pelo Lema 3.1, novamente, temos que

$$\lim_{m \rightarrow \infty} S_m^2(\boldsymbol{\eta}) = \frac{\sigma_0^2}{(2\pi)^2} \int_{-\pi}^{\pi} \frac{k(\lambda; \boldsymbol{\eta}_0)}{k(\lambda; \boldsymbol{\eta})} d\lambda.$$

Assim, como  $S_m^2(\hat{\boldsymbol{\eta}}_m)$  não depende de  $\boldsymbol{\eta}$ , aplicando o ínfimo nos dois lados da equação (3.48), temos

$$\lim_{m \rightarrow \infty} S_m^2(\hat{\boldsymbol{\eta}}_m) = \inf_{\boldsymbol{\eta} \in \vartheta} \left[ \lim_{m \rightarrow \infty} S_m^2(\hat{\boldsymbol{\eta}}_m) \right] \leq \inf_{\boldsymbol{\eta} \in \vartheta} \left[ \frac{\sigma_0^2}{(2\pi)^2} \int_{-\pi}^{\pi} \frac{k(\lambda; \boldsymbol{\eta}_0)}{k(\lambda; \boldsymbol{\eta})} d\lambda \right] = \frac{\sigma_0^2}{2\pi},$$

onde a última igualdade acima segue do Lema 3.2.

Portanto, chegamos à conclusão que

$$\frac{\sigma_0^2}{2\pi} < \lim_{m \rightarrow \infty} S_m^2(\hat{\boldsymbol{\eta}}_m) \leq \frac{\sigma_0^2}{2\pi}.$$

O que é uma contradição, logo, devemos ter  $\boldsymbol{\eta}' = \boldsymbol{\eta}_0$ . Portanto,

$$\lim_{N \rightarrow \infty} \hat{\boldsymbol{\eta}}_N = \boldsymbol{\eta}_0.$$

Também temos que

$$\begin{aligned} \lim_{N \rightarrow \infty} S_N^2(\hat{\boldsymbol{\eta}}_N) &= \lim_{N \rightarrow \infty} \frac{\sigma_0^2}{(2\pi)^2} \int_{-\pi}^{\pi} \frac{k(\lambda; \boldsymbol{\eta}_0)}{k(\lambda; \boldsymbol{\eta}_0)} d\lambda \\ &= \frac{\sigma_0^2}{2\pi}. \end{aligned}$$

■

Para a demonstração do Teorema 3.2, utilizaremos mais alguns lemas, que estão enunciados e demonstrados a seguir.

**Lema 3.3.** *Considere  $\{b_N\}_{N \in \mathbb{N}}$  uma sequência tal que  $b_N \rightarrow \infty$ , quando  $N \rightarrow \infty$ . Seja  $b_N \frac{\partial}{\partial \boldsymbol{\eta}} S_N^2(\boldsymbol{\eta}_0) \xrightarrow{d} Y$ , em que  $Y$  é um vetor aleatório. Então  $b_N(\hat{\boldsymbol{\eta}}_N - \boldsymbol{\eta}_0) \xrightarrow{d} \boldsymbol{\eta}$*

$-\frac{\pi}{\sigma_0^2} W^{-1}(\boldsymbol{\eta}_0)Y$ , em que  $W_{jk}(\boldsymbol{\eta}) = \frac{1}{4\pi} \int_{-\pi}^{\pi} k(\lambda; \boldsymbol{\eta}) \frac{\partial^2}{\partial \eta_j \partial \eta_k} k^{-1}(\lambda; \boldsymbol{\eta}) d\lambda$  é o  $(j, k)$ -ésimo elemento da matriz  $W(\boldsymbol{\eta})$ .

**Demonstração:** Pelo teorema do valor médio, temos que

$$\frac{\partial}{\partial \boldsymbol{\eta}} S_N^2(\hat{\boldsymbol{\eta}}_N) - \frac{\partial}{\partial \boldsymbol{\eta}} S_N^2(\boldsymbol{\eta}_0) = \frac{\partial^2}{\partial \boldsymbol{\eta}^2} S_N^2(\boldsymbol{\eta}_N^*)(\hat{\boldsymbol{\eta}}_N - \boldsymbol{\eta}_0), \quad (3.49)$$

em que  $\hat{\boldsymbol{\eta}}_N < \boldsymbol{\eta}_N^* < \boldsymbol{\eta}_0$ .

Como,  $\hat{\boldsymbol{\eta}}_N$  é o mínimo de  $S_N^2(\boldsymbol{\eta})$ , temos que  $\frac{\partial}{\partial \boldsymbol{\eta}} S_N^2(\hat{\boldsymbol{\eta}}_N) = 0$ , para  $N$  grande. Então, da equação (3.49),

$$\frac{\partial}{\partial \boldsymbol{\eta}} S_N^2(\boldsymbol{\eta}_0) = -\frac{\partial^2}{\partial \boldsymbol{\eta}^2} S_N^2(\boldsymbol{\eta}_N^*)(\hat{\boldsymbol{\eta}}_N - \boldsymbol{\eta}_0).$$

Como temos,  $\hat{\boldsymbol{\eta}}_N < \boldsymbol{\eta}_N^* < \boldsymbol{\eta}_0$  e  $\hat{\boldsymbol{\eta}}_N \rightarrow \boldsymbol{\eta}_0$ , com probabilidade 1, do Teorema 3.1, segue que  $\boldsymbol{\eta}_N^* \rightarrow \boldsymbol{\eta}_0$ , com probabilidade 1. Consequentemente,  $\frac{\partial^2}{\partial \boldsymbol{\eta}^2} S_N^2(\boldsymbol{\eta}_N^*) \rightarrow \frac{\partial^2}{\partial \boldsymbol{\eta}^2} S_N^2(\boldsymbol{\eta}_0)$ , pela continuidade.

Pode-se demonstrar, de forma totalmente análoga ao Lema 3.1, que

$$\lim_{N \rightarrow \infty} \frac{\partial^2}{\partial \boldsymbol{\eta}^2} S_N^2(\boldsymbol{\eta}_0) = \frac{\sigma_0^2}{(2\pi)^2} \int_{-\pi}^{\pi} k(\lambda; \boldsymbol{\eta}_0) \frac{\partial^2}{\partial \boldsymbol{\eta}^2} k^{-1}(\lambda; \boldsymbol{\eta}_0) d\lambda = \frac{\sigma_0^2}{\pi} W(\boldsymbol{\eta}_0).$$

Assim, temos que

$$-b_N \frac{\sigma_0^2}{\pi} W(\boldsymbol{\eta}_0)(\hat{\boldsymbol{\eta}}_N - \boldsymbol{\eta}_0) \xrightarrow{d} Y.$$

Logo,

$$b_N(\hat{\boldsymbol{\eta}}_N - \boldsymbol{\eta}_0) \xrightarrow{d} -\frac{\pi}{\sigma_0^2} W^{-1}(\boldsymbol{\eta}_0)Y.$$

■

**Lema 3.4.** Para quaisquer  $j, k$ ,  $1 \leq j \leq v$ ,  $1 \leq k \leq v$  e para todo  $\boldsymbol{\eta} \in \vartheta \subseteq \mathbb{R}^v$ ,  $v = p + q + P + Q + 2$ , temos que

$$W_{jk}(\boldsymbol{\eta}) = \Omega_{jk}(\boldsymbol{\eta}),$$

em que  $\Omega_{jk}$  é dada pela equação (3.46).

**Demonstração:** Temos que

$$\begin{aligned}
W_{jk}(\boldsymbol{\eta}) &= \frac{1}{4\pi} \int_{-\pi}^{\pi} k(\lambda; \boldsymbol{\eta}) \frac{\partial^2}{\partial \eta_j \partial \eta_k} k^{-1}(\lambda; \boldsymbol{\eta}) d\lambda \\
&= \frac{1}{4\pi} \int_{-\pi}^{\pi} k(\lambda; \boldsymbol{\eta}) \frac{\partial}{\partial \eta_j} \left[ -\frac{1}{k^2(\lambda; \boldsymbol{\eta})} \frac{\partial}{\partial \eta_k} k(\lambda; \boldsymbol{\eta}) \right] d\lambda \\
&= \frac{1}{4\pi} \int_{-\pi}^{\pi} k(\lambda; \boldsymbol{\eta}) \frac{\partial}{\partial \eta_j} \left[ -\frac{1}{k(\lambda; \boldsymbol{\eta})} \frac{\partial}{\partial \eta_k} \ln(k(\lambda; \boldsymbol{\eta})) \right] d\lambda \\
&= -\frac{1}{4\pi} \int_{-\pi}^{\pi} k(\lambda; \boldsymbol{\eta}) \left[ \frac{\partial}{\partial \eta_j} k^{-1}(\lambda; \boldsymbol{\eta}) \frac{\partial}{\partial \eta_k} \ln(k(\lambda; \boldsymbol{\eta})) \right] d\lambda \\
&\quad - \frac{1}{4\pi} \int_{-\pi}^{\pi} k(\lambda; \boldsymbol{\eta}) \left[ \frac{1}{k(\lambda; \boldsymbol{\eta})} \frac{\partial^2}{\partial \eta_j \partial \eta_k} \ln(k(\lambda; \boldsymbol{\eta})) \right] d\lambda \\
&= -\frac{1}{4\pi} \int_{-\pi}^{\pi} k(\lambda; \boldsymbol{\eta}) \left[ -\frac{1}{k^2(\lambda; \boldsymbol{\eta})} \frac{\partial}{\partial \eta_j} k(\lambda; \boldsymbol{\eta}) \frac{\partial}{\partial \eta_k} \ln(k(\lambda; \boldsymbol{\eta})) \right] d\lambda \\
&\quad - \frac{1}{4\pi} \frac{\partial^2}{\partial \eta_j \partial \eta_k} \underbrace{\int_{-\pi}^{\pi} \ln(k(\lambda; \boldsymbol{\eta})) d\lambda}_{=0} \\
&= \frac{1}{4\pi} \int_{-\pi}^{\pi} \frac{1}{k(\lambda; \boldsymbol{\eta})} \frac{\partial}{\partial \eta_j} k(\lambda; \boldsymbol{\eta}) \frac{\partial}{\partial \eta_k} \ln(k(\lambda; \boldsymbol{\eta})) d\lambda \\
&= \frac{1}{4\pi} \int_{-\pi}^{\pi} \frac{\partial}{\partial \eta_j} \ln(k(\lambda; \boldsymbol{\eta})) \frac{\partial}{\partial \eta_k} \ln(k(\lambda; \boldsymbol{\eta})) d\lambda \\
&= \Omega_{jk}(\boldsymbol{\eta}).
\end{aligned}$$

■

**Lema 3.5.** Seja  $I_N(\lambda; \varepsilon)$  o periodograma do processo de inovação  $\{\varepsilon_t\}_{t \in \mathbb{Z}}$ , ou seja,  
 $I_N(\lambda; \varepsilon) = \frac{1}{2\pi N} \left| \sum_{n=1}^N \varepsilon_n e^{in\lambda} \right|^2$ , então

$$a) P \lim_{N \rightarrow \infty} N^{1/2} \left[ \frac{\partial}{\partial \boldsymbol{\eta}} \mathcal{L}(\boldsymbol{\eta}_0; \mathbf{X}) + \frac{1}{2\pi} \int_{-\pi}^{\pi} I_N(\lambda; \varepsilon) \frac{\partial}{\partial \boldsymbol{\eta}} \ln k(\lambda; \boldsymbol{\eta}_0) d\lambda \right] = 0,$$

$$b) \quad P \lim_{N \rightarrow \infty} N^{1/2} \left[ \frac{\partial}{\partial \boldsymbol{\eta}} S_N^2(\boldsymbol{\eta}_0) + \frac{1}{cN} \sum_t I_N(\omega_{ct}; \varepsilon) \frac{\partial}{\partial \boldsymbol{\eta}} \ln k(\omega_{ct}; \boldsymbol{\eta}_0) \right] = 0,$$

em que a notação  $P \lim_{N \rightarrow \infty}$ , quer dizer convergência em probabilidade,  $\frac{\partial}{\partial \boldsymbol{\eta}} S_N^2(\boldsymbol{\eta}_0)$ , quer dizer a derivada da função  $S_N^2(\boldsymbol{\eta})$  com relação à  $\boldsymbol{\eta}$ , aplicada em  $\boldsymbol{\eta}_0$ , e  $\mathcal{L}(\boldsymbol{\eta}_0; \mathbf{X})$  é dada pela equação (3.43).

**Demonstração:**

a) Temos que

$$\begin{aligned} \frac{\partial}{\partial \boldsymbol{\eta}} \mathcal{L}(\boldsymbol{\eta}_0; \mathbf{X}) &= \frac{\partial}{\partial \boldsymbol{\eta}} \left[ \frac{1}{2\pi} \int_{-\pi}^{\pi} \frac{I_N(\lambda)}{k(\lambda; \boldsymbol{\eta})} d\lambda \right] \\ &= \frac{1}{2\pi} \int_{-\pi}^{\pi} I_N(\lambda) \frac{\partial}{\partial \boldsymbol{\eta}} \left[ \frac{1}{k(\lambda; \boldsymbol{\eta}_0)} \right] d\lambda \\ &= \frac{1}{2\pi} \int_{-\pi}^{\pi} I_N(\lambda) \left[ -\frac{\partial}{\partial \boldsymbol{\eta}} k(\lambda; \boldsymbol{\eta}_0) \right] \frac{1}{k^2(\lambda; \boldsymbol{\eta}_0)} d\lambda, \end{aligned} \quad (3.50)$$

em que podemos trocar o sinal da derivada com o da integral, na segunda igualdade, pois a função  $\frac{1}{k(\lambda; \boldsymbol{\eta})}$  é contínua, por hipótese.

Por outro lado, temos que

$$\begin{aligned} &\frac{1}{2\pi} \int_{-\pi}^{\pi} I_N(\lambda; \varepsilon) \frac{\partial}{\partial \boldsymbol{\eta}} \ln k(\lambda; \boldsymbol{\eta}_0) d\lambda \\ &= \frac{1}{2\pi} \int_{-\pi}^{\pi} I_N(\lambda; \varepsilon) \frac{1}{k(\lambda; \boldsymbol{\eta}_0)} \frac{\partial}{\partial \boldsymbol{\eta}} k(\lambda; \boldsymbol{\eta}_0) d\lambda. \end{aligned} \quad (3.51)$$

Assim, somando as equações (3.50) e 3.51, obtemos

$$\begin{aligned} &\frac{\partial}{\partial \boldsymbol{\eta}} \mathcal{L}(\boldsymbol{\eta}_0; \mathbf{X}) + \frac{1}{2\pi} \int_{-\pi}^{\pi} I_N(\lambda; \varepsilon) \frac{\partial}{\partial \boldsymbol{\eta}} \ln k(\lambda; \boldsymbol{\eta}_0) d\lambda \\ &= \frac{1}{2\pi} \int_{-\pi}^{\pi} \frac{1}{k(\lambda; \boldsymbol{\eta}_0)} \frac{\partial}{\partial \boldsymbol{\eta}} k(\lambda; \boldsymbol{\eta}_0) \left[ I_N(\lambda; \varepsilon) - \frac{I_N(\lambda)}{k(\lambda; \boldsymbol{\eta}_0)} \right] d\lambda. \end{aligned} \quad (3.52)$$

Note que

$$\begin{aligned} I_N(\lambda; \varepsilon) &= \frac{1}{2\pi N} \left| \sum_{n=1}^N \varepsilon_n e^{in\lambda} \right|^2 \\ &= \frac{1}{2\pi} \sum_{|h|<N} \hat{\gamma}_\varepsilon(h) e^{-i\lambda h} \xrightarrow{\mathbb{P}} \frac{1}{2\pi} \sum_{h=-\infty}^{\infty} \gamma_\varepsilon(h) e^{-i\lambda h} = \frac{\sigma_0^2}{2\pi}, \end{aligned}$$

em que a convergência é válida, pois sabemos que  $\hat{\gamma}_\varepsilon(h) \xrightarrow{\mathbb{P}} \gamma_\varepsilon(h)$  (na verdade temos a convergência quase certa, mas esta implica em convergência em probabilidade, ver Brockwell e Davis, 1991, p.376). Além disso, temos que

$$\gamma_\varepsilon(h) = \begin{cases} \sigma_0^2, & \text{se } h = 0, \\ 0, & \text{se } h \neq 0. \end{cases}$$

Por outro lado, veja que, por (3.36)

$$\frac{I_N(\lambda)}{k(\lambda; \boldsymbol{\eta}_0)} = \frac{\frac{1}{2\pi} \sum_{|h|<N} \hat{\gamma}_X(h) e^{-i\lambda h}}{\frac{2\pi}{\sigma_0^2} \frac{1}{2\pi} \sum_{h \in \mathbb{Z}} \gamma_X(h) e^{-i\lambda h}} \xrightarrow{\mathbb{P}} \frac{\frac{1}{2\pi} \sum_{h \in \mathbb{Z}} \gamma_X(h) e^{-i\lambda h}}{\frac{1}{\sigma_0^2} \sum_{h \in \mathbb{Z}} \gamma_X(h) e^{-i\lambda h}} = \frac{\sigma_0^2}{2\pi},$$

em que vale a convergência, pois temos  $\hat{\gamma}_X(h) \xrightarrow{\mathbb{P}} \gamma_X(h)$ .

Portanto, podemos concluir que

$$I_N(\lambda; \varepsilon) - \frac{I_N(\lambda)}{k(\lambda; \boldsymbol{\eta}_0)} \xrightarrow{\mathbb{P}} 0. \quad (3.53)$$

Assim, das equações (3.52) e (3.53), segue o resultado.

b) Sabemos que

$$\begin{aligned} \frac{\partial}{\partial \boldsymbol{\eta}} S_N^2(\boldsymbol{\eta}_0) &= \frac{\partial}{\partial \boldsymbol{\eta}} \left[ \frac{1}{cN} \sum_t \frac{I_N(\omega_{ct})}{k(\omega_{ct}; \boldsymbol{\eta}_0)} \right] \\ &= \frac{1}{cN} \sum_t I_N(\omega_{ct}) \frac{\partial}{\partial \boldsymbol{\eta}} \frac{1}{k(\omega_{ct}; \boldsymbol{\eta}_0)} \\ &= \frac{1}{cN} \sum_t I_N(\omega_{ct}) \left[ -\frac{1}{k^2(\omega_{ct}; \boldsymbol{\eta}_0)} \right] \frac{\partial}{\partial \boldsymbol{\eta}} k(\omega_{ct}; \boldsymbol{\eta}_0). \end{aligned} \quad (3.54)$$

Por outro lado, temos

$$\begin{aligned} & \frac{1}{cN} \sum_t I_N(\omega_{ct}; \varepsilon) \frac{\partial}{\partial \boldsymbol{\eta}} \ln k(\omega_{ct}; \boldsymbol{\eta}_0) \\ &= \frac{1}{cN} \sum_t I_N(\omega_{ct}; \varepsilon) \frac{1}{k(\omega_{ct}; \boldsymbol{\eta}_0)} \frac{\partial}{\partial \boldsymbol{\eta}} k(\omega_{ct}; \boldsymbol{\eta}_0). \end{aligned} \quad (3.55)$$

Se somarmos as equações (3.54) e (3.55), chegaremos na seguinte expressão

$$\begin{aligned} & \frac{\partial}{\partial \boldsymbol{\eta}} S_N^2(\boldsymbol{\eta}_0) + \frac{1}{cN} \sum_t I_N(\omega_{ct}; \varepsilon) \frac{\partial}{\partial \boldsymbol{\eta}} \ln k(\omega_{ct}; \boldsymbol{\eta}_0) \\ &= \frac{1}{cN} \sum_t \frac{1}{k(\omega_{ct}; \boldsymbol{\eta}_0)} \frac{\partial}{\partial \boldsymbol{\eta}} k(\omega_{ct}; \boldsymbol{\eta}_0) \left[ I_N(\omega_{ct}; \varepsilon) - \frac{I_N(\omega_{ct})}{k(\omega_{ct}; \boldsymbol{\eta}_0)} \right]. \end{aligned} \quad (3.56)$$

Sabemos, pelo item a), que

$$I_N(\omega_{ct}; \varepsilon) - \frac{I_N(\omega_{ct})}{k(\omega_{ct}; \boldsymbol{\eta}_0)} \xrightarrow{\mathbb{P}} 0.$$

Então, pela equação (3.56), segue o resultado. ■

Com os lemas acima, já conseguimos demonstrar o Teorema 3.2.

### Demonstração do Teorema 3.2:

Pelo Lema 3.3, temos que

$$\sqrt{N}(\hat{\boldsymbol{\eta}}_N - \boldsymbol{\eta}_0) \xrightarrow{d} -\frac{\pi}{\sigma_0^2} W^{-1}(\boldsymbol{\eta}_0) Y.$$

Se aplicarmos o Lema 3.4, podemos escrever

$$\sqrt{N}(\hat{\boldsymbol{\eta}}_N - \boldsymbol{\eta}_0) \xrightarrow{d} -\frac{\pi}{\sigma_0^2} \Omega^{-1}(\boldsymbol{\eta}_0) Y.$$

Então, pelo Lema 3.3, veja que basta mostrarmos a distribuição assintótica de  $\sqrt{N} \frac{\partial}{\partial \boldsymbol{\eta}} S_N^2(\boldsymbol{\eta}_0)$ . Para isso, chame de  $\mathcal{F}(\lambda) = \frac{\partial}{\partial \boldsymbol{\eta}} k^{-1}(\lambda; \boldsymbol{\eta}_0)$  e seja  $\mathcal{F}_N(\lambda)$  a  $N$ -ésima soma de Cesaro da série de Fourier de  $\mathcal{F}(\lambda)$ . Como  $\mathcal{F}(\lambda)$  é uma função de classe Lipschitz de ordem  $1/2 < \alpha < 1$ , pelo Teorema 3.15, encontrado em Zygmund (1959, p.91), temos que  $\mathcal{F}(\lambda) - \mathcal{F}_N(\lambda) = O(N^{-\alpha})$  uniformemente em  $\lambda$ , ou seja, existe  $\kappa_1$

tal que  $\mathcal{F}(\lambda) - \mathcal{F}_N(\lambda) \leq \kappa_1 N^{-\alpha}$ . Então,

$$\begin{aligned} & \sqrt{N} \frac{1}{cN} \sum_t I_N(\omega_{ct}) \mathcal{F}(\omega_{ct}) - \sqrt{N} \frac{1}{cN} \sum_t I_N(\omega_{ct}) \mathcal{F}_N(\omega_{ct}) \\ & \leq \sqrt{N} \frac{1}{cN} \sum_t I_N(\omega_{ct}) \kappa_1 N^{-\alpha} = \kappa_1 \frac{N^{-1/2-\alpha}}{c} \sum_t I_N(\omega_{ct}) \xrightarrow{N \rightarrow \infty} 0. \end{aligned} \quad (3.57)$$

Também sabemos que

$$\sqrt{N} \frac{1}{cN} \sum_t I_N(\omega_{ct}) \mathcal{F}_N(\omega_{ct}) \simeq \frac{\sqrt{N}}{2\pi} \int_{-\pi}^{\pi} I_N(\lambda) \mathcal{F}_N(\lambda) d\lambda. \quad (3.58)$$

Além disso, temos que

$$\begin{aligned} & \frac{\sqrt{N}}{2\pi} \int_{-\pi}^{\pi} I_N(\lambda) \mathcal{F}(\lambda) d\lambda - \frac{\sqrt{N}}{2\pi} \int_{-\pi}^{\pi} I_N(\lambda) \mathcal{F}_N(\lambda) d\lambda \\ & = \frac{\sqrt{N}}{2\pi} \int_{-\pi}^{\pi} I_N(\lambda) [\mathcal{F}(\lambda) - \mathcal{F}_N(\lambda)] d\lambda \\ & \leq \underbrace{\frac{\sqrt{N}}{2\pi} \kappa_1 N^{-\alpha} \int_{-\pi}^{\pi} I_N(\lambda) d\lambda}_{\kappa_2} = \frac{\kappa_1 \kappa_2}{2\pi} N^{1/2-\alpha} \xrightarrow{N \rightarrow \infty} 0, \quad \text{pois } 1/2 < \alpha < 1. \end{aligned} \quad (3.59)$$

Logo, pelas equações (3.57), (3.58) e (3.59), temos que

$$\sqrt{N} \frac{1}{cN} \sum_t I_N(\omega_{ct}) \mathcal{F}(\omega_{ct}) - \frac{\sqrt{N}}{2\pi} \int_{-\pi}^{\pi} I_N(\lambda) \mathcal{F}(\lambda) d\lambda \xrightarrow{N \rightarrow \infty} 0.$$

Se fizermos o mesmo processo para a função  $\mathcal{G}(\lambda) = \frac{\partial}{\partial \boldsymbol{\eta}} \ln k(\lambda; \boldsymbol{\eta}_0)$ , concluiremos que

$$\sqrt{N} \frac{1}{cN} \sum_t I_N(\omega_{ct}; \varepsilon) \mathcal{G}(\omega_{ct}) - \frac{\sqrt{N}}{2\pi} \int_{-\pi}^{\pi} I_N(\lambda; \varepsilon) \mathcal{G}(\lambda) d\lambda \xrightarrow{N \rightarrow \infty} 0.$$

Veja que, aplicando o resultado do Lema 3.5, basta considerarmos a demonstra-

ção para  $\frac{\partial}{\partial \boldsymbol{\eta}} \mathcal{L}(\boldsymbol{\eta}_0; \mathbf{X})$ . Em Fox e Taqqu (1986), podemos encontrar a demonstração de que

$$\frac{\partial}{\partial \boldsymbol{\eta}} \mathcal{L}(\boldsymbol{\eta}_0; \mathbf{X}) \xrightarrow{d} N\left(0; \frac{\sigma_0^4}{\pi^2} \Omega(\boldsymbol{\eta}_0)\right).$$

Seja  $Y$  uma variável aleatória tendo distribuição  $N\left(0; \frac{\sigma_0^4}{\pi^2} \Omega(\boldsymbol{\eta}_0)\right)$ . Portanto, pelo Lema 3.4, podemos escrever

$$\sqrt{N}(\hat{\boldsymbol{\eta}}_N - \boldsymbol{\eta}_0) \xrightarrow{d} -\frac{\pi}{\sigma_0^2} \Omega^{-1}(\boldsymbol{\eta}_0) Y.$$

Seja  $X$  a variável aleatória  $X = -\frac{\pi}{\sigma_0^2} \Omega^{-1}(\boldsymbol{\eta}_0) Y$ , então,

$$\mathbb{E}(X) = 0;$$

$$Var(X) = Var\left(-\frac{\pi}{\sigma_0^2} \Omega^{-1}(\boldsymbol{\eta}_0) Y\right) = \frac{\pi^2}{\sigma_0^4} \Omega^{-2}(\boldsymbol{\eta}_0) \frac{\sigma_0^4}{\pi^2} \Omega(\boldsymbol{\eta}_0) = \Omega^{-1}(\boldsymbol{\eta}_0).$$

O que completa a demonstração. ■

### 3.2.4 Estimador FTS

Outra proposta que temos para este trabalho, é substituir o periodograma, no estimador proposto por Fox e Taqqu (1986), pelo periodograma suavizado de covariâncias (ver equação (1.18)). Assim, vamos definir a seguir este novo estimador.

Considere as seguintes funções

$$\bar{S}_N^2(\boldsymbol{\eta}) = \frac{1}{2\pi} \int_{-\pi}^{\pi} \frac{I_s(\lambda)}{k(\lambda; \boldsymbol{\eta})} d\lambda, \quad (3.60)$$

$$\tilde{S}_N^2(\boldsymbol{\eta}) = \frac{1}{N} \sum_t \frac{I_s(\omega_t)}{k(\omega_t; \boldsymbol{\eta})}, \quad (3.61)$$

em que  $\boldsymbol{\eta}$  é o vetor de parâmetros a ser estimado e  $\omega_t = \frac{2\pi t}{N}$  são as frequências de Fourier,  $t \in \mathbb{Z}$ ,  $-\frac{N}{2} < t \leq \lfloor \frac{N}{2} \rfloor$ . Os estimadores modificados que estamos propondo, denotados por  $\bar{\boldsymbol{\eta}}_N$  e  $\tilde{\boldsymbol{\eta}}_N$ , são, respectivamente, os pontos mínimos das equações (3.60) e (3.61). Além disso, os estimadores da variância do processo de inovação são dados por  $\bar{\sigma}_\varepsilon^2 = 2\pi \bar{S}_N^2(\bar{\boldsymbol{\eta}}_N)$  e  $\tilde{\sigma}_\varepsilon^2 = 2\pi \tilde{S}_N^2(\tilde{\boldsymbol{\eta}}_N)$ .

Demonstraremos que estes novos estimadores são consistentes e possuem a mesma distribuição assintótica do estimador proposto na seção anterior, para isso iremos, primeiramente, demonstrar alguns lemas. Iremos supor que as condições A, descritas na seção anterior, são válidas.

**Lema 3.6.** *Quando  $\boldsymbol{\eta} \in \vartheta_0$ , temos que*

$$\lim_{N \rightarrow \infty} \bar{S}_N^2(\boldsymbol{\eta}) = \lim_{N \rightarrow \infty} \tilde{S}_N^2(\boldsymbol{\eta}) = \frac{\sigma_0^2}{(2\pi)^2} \int_{-\pi}^{\pi} \frac{k(\lambda; \boldsymbol{\eta}_0)}{k(\lambda; \boldsymbol{\eta})} d\lambda.$$

**Demonstração:** Iremos provar apenas para  $\tilde{S}_N^2$ , o outro caso é inteiramente análogo. Dado  $\epsilon > 0$ , seja  $q_M(\lambda; \boldsymbol{\eta}) > 0$ ,  $\lambda \in [-\pi, \pi]$ , a soma de Cesaro, com  $M$  termos, da série de Fourier de  $\frac{1}{k(\lambda; \boldsymbol{\eta})}$ .

Podemos escolher  $M$  suficientemente grande, de forma que

$$\left| \frac{1}{k(\lambda; \boldsymbol{\eta})} - q_M(\lambda; \boldsymbol{\eta}) \right| < \frac{\epsilon}{H},$$

em que  $H = \frac{1}{N} \sum_t I_s(\omega_t) < \infty$ , pois temos uma soma finita de elementos finitos. A convergência é uniforme, pois a soma de Cesaro converge uniformemente em  $(\lambda; \boldsymbol{\eta})$ , para  $\boldsymbol{\eta} \in \vartheta_0$ , pois  $\frac{1}{k(\lambda; \boldsymbol{\eta})}$  é uma função contínua e periódica, de período  $2\pi$  (para detalhes ver Iório, 2007, p.135).

Então, temos que

$$\begin{aligned} \left| \tilde{S}_N^2(\boldsymbol{\eta}) - \frac{1}{N} \sum_t I_s(\omega_t) q_M(\omega_t; \boldsymbol{\eta}) \right| &= \left| \frac{1}{N} \sum_t I_s(\omega_t) \left( \frac{1}{k(\omega_t; \boldsymbol{\eta})} - q_M(\omega_t; \boldsymbol{\eta}) \right) \right| \\ &\leq \frac{1}{N} \sum_t I_s(\omega_t) \underbrace{\left| \frac{1}{k(\omega_t; \boldsymbol{\eta})} - q_M(\omega_t; \boldsymbol{\eta}) \right|}_{<\epsilon/H} \\ &< \frac{1}{N} \sum_t I_s(\omega_t) \frac{\epsilon}{H} = \epsilon. \end{aligned}$$

Por outro lado, como sabemos que o periodograma suavizado de covariâncias é

consistente, temos que  $I_s(\omega_t) \xrightarrow{\mathbb{P}} f_X(\omega_t; \boldsymbol{\eta}_0)$ , então

$$\begin{aligned}
\frac{1}{N} \sum_t I_s(\omega_t) q_M(\omega_t; \boldsymbol{\eta}) &\longrightarrow \frac{1}{N} \sum_t f_X(\omega_t; \boldsymbol{\eta}_0) q_M(\omega_t; \boldsymbol{\eta}) \\
&\xrightarrow{N \rightarrow \infty} \frac{1}{2\pi} \int_{-\pi}^{\pi} f_X(\lambda; \boldsymbol{\eta}_0) q_M(\lambda; \boldsymbol{\eta}) d\lambda \\
&= \frac{1}{2\pi} \int_{-\pi}^{\pi} \frac{\sigma_0^2}{2\pi} k(\lambda; \boldsymbol{\eta}_0) q_M(\lambda; \boldsymbol{\eta}) d\lambda \\
&= \frac{\sigma_0^2}{(2\pi)^2} \int_{-\pi}^{\pi} k(\lambda; \boldsymbol{\eta}_0) q_M(\lambda; \boldsymbol{\eta}) d\lambda
\end{aligned}$$

Assim, temos que

$$\left| S_N^2(\boldsymbol{\eta}) - \frac{\sigma_0^2}{(2\pi)^2} \int_{-\pi}^{\pi} q_M(\lambda; \boldsymbol{\eta}) k(\lambda; \boldsymbol{\eta}_0) d\lambda \right| < \epsilon.$$

Como a soma de Cesaro  $q_M(\lambda; \boldsymbol{\eta})$  converge uniformemente para a função  $k^{-1}(\lambda; \boldsymbol{\eta})$ , segue o resultado do lema.  $\blacksquare$

O teorema a seguir apresenta a consistência dos estimadores definidos nesta seção.

**Teorema 3.3.** *Sob as condições A, com probabilidade 1,*

$$\lim_{N \rightarrow \infty} \bar{\boldsymbol{\eta}}_N = \lim_{N \rightarrow \infty} \tilde{\boldsymbol{\eta}}_N = \boldsymbol{\eta}_0,$$

e

$$\lim_{N \rightarrow \infty} \bar{S}_N^2(\bar{\boldsymbol{\eta}}_N) = \lim_{N \rightarrow \infty} \tilde{S}_N^2(\tilde{\boldsymbol{\eta}}_N) = \frac{\sigma_0^2}{2\pi}.$$

**Demonstração:** Proceder exatamente como na demonstração do Teorema 3.1, utilizando Lema 3.6 no lugar do Lema 3.1.  $\blacksquare$

Para demonstrarmos a distribuição assintótica destes estimadores, precisamos de alguns lemas, que estão a seguir.

**Lema 3.7.** *Considere  $\{b_N\}_{N \in \mathbb{N}}$  uma sequência tal que  $b_N \rightarrow \infty$ , quando  $N \rightarrow \infty$ .*

Seja  $b_N \frac{\partial}{\partial \boldsymbol{\eta}} \tilde{S}_N^2(\boldsymbol{\eta}_0) \xrightarrow{d} Y$ , em que  $Y$  é um vetor aleatório. Então

$$b_N(\hat{\boldsymbol{\eta}}_N - \boldsymbol{\eta}_0) \xrightarrow{d} -\frac{\pi}{\sigma_0^2} W^{-1}(\boldsymbol{\eta}_0)Y,$$

em que  $W_{jk}(\boldsymbol{\eta}) = \frac{1}{4\pi} \int_{-\pi}^{\pi} k(\lambda; \boldsymbol{\eta}) \frac{\partial^2}{\partial \eta_j \partial \eta_k} k^{-1}(\lambda; \boldsymbol{\eta}) d\lambda$ .

**Demonstração:** Segue análoga ao Lema 3.3. ■

**Observação 3.5.** O Lema 3.7 também é válido se considerarmos  $\bar{S}_N^2(\boldsymbol{\eta})$ .

**Lema 3.8.** Seja  $I_S(\lambda; \varepsilon)$  o periodograma suavizado de covariâncias do processo de inovação  $\{\varepsilon_t\}_{t \in \mathbb{Z}}$ , ou seja,  $I_S(\lambda; \varepsilon) = \frac{1}{2\pi} \sum_{h=-(N-1)}^{(N+1)} \omega_M(h) \hat{\gamma}_\varepsilon(h) e^{-i\lambda h}$ , então

$$\begin{aligned} a) \quad & P \lim_{N \rightarrow \infty} N^{1/2} \left[ \frac{\partial}{\partial \boldsymbol{\eta}} \mathcal{L}(\boldsymbol{\eta}_0; \mathbf{X}) + \frac{1}{2\pi} \int_{-\pi}^{\pi} I_S(\lambda; \varepsilon) \frac{\partial}{\partial \boldsymbol{\eta}} \ln k(\lambda; \boldsymbol{\eta}_0) d\lambda \right] = 0, \\ b) \quad & P \lim_{N \rightarrow \infty} N^{1/2} \left[ \frac{\partial}{\partial \boldsymbol{\eta}} \tilde{S}_N^2(\boldsymbol{\eta}_0) + \frac{1}{N} \sum_t I_S(\omega_t; \varepsilon) \frac{\partial}{\partial \boldsymbol{\eta}} \ln k(\omega_t; \boldsymbol{\eta}_0) \right] = 0, \end{aligned}$$

em que a notação  $P \lim_{N \rightarrow \infty}$ , quer dizer convergência em probabilidade,  $\frac{\partial}{\partial \boldsymbol{\eta}} \tilde{S}_N^2(\boldsymbol{\eta}_0)$ , quer dizer a derivada da função  $S_N^2(\boldsymbol{\eta})$  com relação à  $\boldsymbol{\eta}$ , aplicada em  $\boldsymbol{\eta}_0$ , e  $\mathcal{L}(\boldsymbol{\eta}_0; \mathbf{X})$  é a equação (3.43).

**Demonstração:**

a) Pelo Lema 5, de Hannan (1973), temos que

$$N^{1/2} \left[ \frac{\partial}{\partial \boldsymbol{\eta}} \mathcal{L}(\boldsymbol{\eta}_0; \mathbf{X}) + \frac{1}{2\pi} \int_{-\pi}^{\pi} I_N(\lambda; \varepsilon) \frac{\partial}{\partial \boldsymbol{\eta}} \ln k(\lambda; \boldsymbol{\eta}_0) d\lambda \right] \xrightarrow{\mathbb{P}} 0.$$

Assim, note que

$$\begin{aligned}
& N^{1/2} \left[ \frac{\partial}{\partial \boldsymbol{\eta}} \mathcal{L}(\boldsymbol{\eta}_0; \mathbf{X}) + \frac{1}{2\pi} \int_{-\pi}^{\pi} I_N(\lambda; \varepsilon) \frac{\partial}{\partial \boldsymbol{\eta}} \ln k(\lambda; \boldsymbol{\eta}_0) d\lambda \right] \\
&= N^{1/2} \left[ \frac{1}{2\pi} \int_{-\pi}^{\pi} I_N(\lambda) \frac{\partial}{\partial \boldsymbol{\eta}} k^{-1}(\lambda; \boldsymbol{\eta}_0) d\lambda + \frac{1}{2\pi} \int_{-\pi}^{\pi} I_N(\lambda; \varepsilon) \frac{\partial}{\partial \boldsymbol{\eta}} \ln k(\lambda; \boldsymbol{\eta}_0) d\lambda \right] \\
&= N^{1/2} \left[ \frac{1}{2\pi} \int_{-\pi}^{\pi} I_N(\lambda) \left( -\frac{1}{k^2(\lambda; \boldsymbol{\eta}_0)} \right) \frac{\partial}{\partial \boldsymbol{\eta}} k(\lambda; \boldsymbol{\eta}_0) d\lambda \right] \\
&\quad + N^{1/2} \left[ \frac{1}{2\pi} \int_{-\pi}^{\pi} I_N(\lambda; \varepsilon) \frac{1}{k(\lambda; \boldsymbol{\eta}_0)} \frac{\partial}{\partial \boldsymbol{\eta}} k(\lambda; \boldsymbol{\eta}_0) d\lambda \right] \\
&= N^{1/2} \left[ \frac{1}{2\pi} \int_{-\pi}^{\pi} \frac{1}{k(\lambda; \boldsymbol{\eta}_0)} \frac{\partial}{\partial \boldsymbol{\eta}} k(\lambda; \boldsymbol{\eta}_0) \left( I_N(\lambda; \varepsilon) - \frac{I_N(\lambda)}{k(\lambda; \boldsymbol{\eta}_0)} \right) d\lambda \right] \xrightarrow{\mathbb{P}} 0.
\end{aligned}$$

Logo, devemos ter  $I_N(\lambda; \varepsilon)$  e  $\frac{I_N(\lambda)}{k(\lambda; \boldsymbol{\eta}_0)}$  convergindo para a mesma expressão. Veja que

$$I_N(\lambda; \varepsilon) = \frac{1}{2\pi} \sum_{|h| < N} \hat{\gamma}_\varepsilon(h) e^{-ih\lambda} \xrightarrow{\mathbb{P}} \frac{1}{2\pi} \sum_{|h| < N} \gamma_\varepsilon(h) e^{-ih\lambda} = \frac{\sigma_0^2}{2\pi},$$

pois sabemos que  $\hat{\gamma}_\varepsilon(h) \xrightarrow{\mathbb{P}} \gamma_\varepsilon(h)$  e, além disso,  $\gamma_\varepsilon(h) = \begin{cases} \sigma_0^2, & \text{se } h = 0, \\ 0, & \text{se } h \neq 0. \end{cases}$

Portanto,

$$I_N(\lambda; \varepsilon) \xrightarrow{\mathbb{P}} \frac{\sigma_0^2}{2\pi}.$$

Consequentemente,

$$\frac{I_N(\lambda)}{k(\lambda; \boldsymbol{\eta}_0)} \xrightarrow{\mathbb{P}} \frac{\sigma_0^2}{2\pi}. \quad (3.62)$$

Também temos que,

$$I_S(\lambda; \varepsilon) = \frac{1}{2\pi} \sum_{h=-(N-1)}^{(N+1)} \omega_M(h) \hat{\gamma}_\varepsilon(h) e^{-i\lambda h} \xrightarrow{\mathbb{P}} \frac{1}{2\pi} \sum_{h=-(N-1)}^{(N+1)} \omega_M(h) \gamma_\varepsilon(h) e^{-i\lambda h},$$

e, como  $\omega_M(0) = 1$ , temos

$$I_S(\lambda; \varepsilon) \xrightarrow{\mathbb{P}} \frac{\sigma_0^2}{2\pi}. \quad (3.63)$$

Portanto, temos

$$\begin{aligned} & N^{1/2} \left[ \frac{\partial}{\partial \boldsymbol{\eta}} \mathcal{L}(\boldsymbol{\eta}_0; \mathbf{X}) + \frac{1}{2\pi} \int_{-\pi}^{\pi} I_S(\lambda; \varepsilon) \frac{\partial}{\partial \boldsymbol{\eta}} \ln k(\lambda; \boldsymbol{\eta}_0) d\lambda \right] \\ &= N^{1/2} \left[ \frac{1}{2\pi} \int_{-\pi}^{\pi} \frac{1}{k(\lambda; \boldsymbol{\eta}_0)} \frac{\partial}{\partial \boldsymbol{\eta}} k(\lambda; \boldsymbol{\eta}_0) \left( I_S(\lambda; \varepsilon) - \frac{I_N(\lambda)}{k(\lambda; \boldsymbol{\eta}_0)} \right) d\lambda \right] \xrightarrow{\mathbb{P}} 0, \end{aligned}$$

pelas equações (3.62) e (3.63).

b) Temos que

$$I_S(\omega_t; \varepsilon) \xrightarrow{\mathbb{P}} f_\varepsilon(\omega_t) = \frac{\sigma_0^2}{2\pi}. \quad (3.64)$$

Além disso,

$$I_S(\omega_t) \xrightarrow{\mathbb{P}} f_X(\omega_t; \boldsymbol{\eta}_0) = \frac{\sigma_0^2}{2\pi} k(\omega_t; \boldsymbol{\eta}_0).$$

O que implica em

$$\frac{I_S(\omega_t)}{k(\omega_t; \boldsymbol{\eta}_0)} \xrightarrow{\mathbb{P}} \frac{\frac{\sigma_0^2}{2\pi} k(\omega_t; \boldsymbol{\eta}_0)}{k(\omega_t; \boldsymbol{\eta}_0)} = \frac{\sigma_0^2}{2\pi}. \quad (3.65)$$

Portanto, pelas equações (3.64) e (3.65), temos que

$$\begin{aligned} & N^{1/2} \left[ \frac{\partial}{\partial \boldsymbol{\eta}} \tilde{S}_N^2(\boldsymbol{\eta}_0) + \frac{1}{N} \sum_t I_S(\omega_t; \varepsilon) \frac{\partial}{\partial \boldsymbol{\eta}} \ln k(\omega_t; \boldsymbol{\eta}_0) \right] \\ &= N^{1/2} \left[ \frac{1}{N} \sum_t \frac{1}{k(\omega_t; \boldsymbol{\eta}_0)} \frac{\partial}{\partial \boldsymbol{\eta}} k(\omega_t; \boldsymbol{\eta}_0) \left( I_S(\omega_t; \varepsilon) - \frac{I_S(\omega_t)}{k(\omega_t; \boldsymbol{\eta}_0)} \right) \right] \xrightarrow{\mathbb{P}} 0. \end{aligned}$$

■

Com os resultados mostrados até agora, estamos em condições de demonstrar a distribuição assintótica dos estimadores.

**Teorema 3.4.** *Sob as condições A, os vetores aleatórios  $\sqrt{N}(\bar{\boldsymbol{\eta}}_N - \boldsymbol{\eta}_0)$  e  $\sqrt{N}(\tilde{\boldsymbol{\eta}}_N - \boldsymbol{\eta}_0)$  convergem em distribuição a um vetor normal com média zero e matriz de*

covariâncias  $\Omega^{-1}(\boldsymbol{\eta}_0)$ , em que a  $(j, k)$ -ésima entrada da matriz  $\Omega(\boldsymbol{\eta})$  é dada por

$$\Omega_{jk}(\boldsymbol{\eta}) = \frac{1}{4\pi} \int_{-\pi}^{\pi} \frac{\partial}{\partial \eta_j} \ln(k(\lambda; \boldsymbol{\eta})) \frac{\partial}{\partial \eta_k} \ln k(\lambda; \boldsymbol{\eta}) d\lambda.$$

**Demonstração:** Iremos fazer a demonstração para  $\tilde{\boldsymbol{\eta}}_N$ . Pelo Lema 3.7, precisamos mostrar um teorema para  $\sqrt{N}\tilde{S}_N^2(\boldsymbol{\eta}_0)$ . Pelos mesmos argumentos da demonstração do Teorema 3.2, temos que

$$\sqrt{N} \left[ \frac{1}{N} \sum_t I_S(\omega_t) \frac{\partial}{\partial \boldsymbol{\eta}} k^{-1}(\omega_t; \boldsymbol{\eta}_0) - \frac{1}{2\pi} \int_{-\pi}^{\pi} I_S(\lambda) \frac{\partial}{\partial \boldsymbol{\eta}} k^{-1}(\lambda; \boldsymbol{\eta}_0) d\lambda \right] \xrightarrow{N \rightarrow \infty} 0. \quad (3.66)$$

Logo, é indiferente considerarmos  $\frac{\partial}{\partial \boldsymbol{\eta}} \bar{S}_N^2(\boldsymbol{\eta}_0)$  ou  $\frac{\partial}{\partial \boldsymbol{\eta}} \tilde{S}_N^2(\boldsymbol{\eta}_0)$ , para a distribuição assintótica.

Analogamente, também temos que

$$\sqrt{N} \left[ \frac{1}{N} \sum_t I_S(\omega_t; \varepsilon) \frac{\partial}{\partial \boldsymbol{\eta}} \ln k(\omega_t; \boldsymbol{\eta}_0) - \frac{1}{2\pi} \int_{-\pi}^{\pi} I_S(\lambda; \varepsilon) \frac{\partial}{\partial \boldsymbol{\eta}} \ln k(\lambda; \boldsymbol{\eta}_0) d\lambda \right] \xrightarrow{N \rightarrow \infty} 0. \quad (3.67)$$

Assim, pelo Lema 3.8 basta considerarmos a prova para  $\sqrt{N} \frac{\partial}{\partial \boldsymbol{\eta}} \mathcal{L}(\boldsymbol{\eta}_0; \mathbf{X})$ , que é dada no artigo de Fox e Taqqu (1986),

$$\frac{\partial}{\partial \boldsymbol{\eta}} \mathcal{L}(\boldsymbol{\eta}_0; \mathbf{X}) \xrightarrow{d} \underbrace{N \left( 0; \frac{\sigma_0^4}{\pi^2} \Omega(\boldsymbol{\eta}_0) \right)}_Y.$$

Portanto, pelo Lema 3.7, podemos escrever

$$\sqrt{N}(\tilde{\boldsymbol{\eta}}_N - \boldsymbol{\eta}_0) \xrightarrow{d} \underbrace{-\frac{\pi}{\sigma_0^2} \Omega^{-1}(\boldsymbol{\eta}_0) Y}_X.$$

Portanto,

$$\mathbb{E}(X) = 0;$$

$$Var(X) = Var \left( -\frac{\pi}{\sigma_0^2} \Omega^{-1}(\boldsymbol{\eta}_0) Y \right) = \frac{\pi^2}{\sigma_0^4} \Omega^{-2}(\boldsymbol{\eta}_0) \frac{\sigma_0^4}{\pi^2} \Omega(\boldsymbol{\eta}_0) = \Omega^{-1}(\boldsymbol{\eta}_0),$$

completando a demonstração. ■

### 3.2.5 Estimador KM

Nesta seção iremos estudar um estimador paramétrico para os processos  $\alpha$ -estáveis. Para isso considere  $\{X_t\}_{t \in \mathbb{Z}}$  um processo linear geral,

$$X_t = \sum_{j \in \mathbb{Z}_\geq} \psi_j \varepsilon_{t-j}, \quad t \in \mathbb{Z}, \quad (3.68)$$

em que as inovações  $\{\varepsilon_t\}_{t \in \mathbb{Z}}$  são variáveis independentes e identicamente distribuídas  $\alpha$ -estáveis simétricas ( $S\alpha S$ ), descritas na Seção 2.2. Considere a seguinte função

$$\sigma_N^2(\boldsymbol{\eta}) = \int_{-\pi}^{\pi} \frac{\tilde{I}_N(\lambda)}{g_X(\lambda; \boldsymbol{\eta})} d\lambda, \quad (3.69)$$

em que  $\tilde{I}_N(\lambda)$  é o periodograma normalizado, dado na Definição 2.18, e  $g_X(\lambda; \boldsymbol{\eta})$  é a função poder de transferência, dada em (2.26), para o processo SARFIMA  $\alpha$ -estável.

Um estimador para o vetor de parâmetros desconhecidos, proposto por Klüppelberg e Mikosch (1996), é o ponto de mínimo da função (3.69), denotado por  $\boldsymbol{\eta}_N^*$ . Inicialmente, Mikosch et al (1995) provam a consistência e distribuição assintótica, se considerássemos um processo ARMA( $p, q$ )  $\alpha$ -estável. Posteriormente, Klüppelberg e Mikosch (1996), provam que o estimador, considerando processos lineares gerais, também é consistente, sob certas condições, e que

$$\left( \frac{N}{\ln N} \right)^{1/\alpha} (\boldsymbol{\eta}_N^* - \boldsymbol{\eta}_0) \xrightarrow{d} 4\pi Q^{-1}(\boldsymbol{\eta}_0) \frac{1}{Y_0} \sum_{k=1}^{\infty} Y_k b_k,$$

em que  $Y_0, Y_1, \dots$  são variáveis aleatórias independentes,  $Y_0 \stackrel{d}{=} S_{\alpha/2}(C_{\alpha/2}^{-2/\alpha}, 1, 0)$  é  $\alpha/2$ -estável,  $\{Y_t\}_{t \in \mathbb{N}}$  são independentes e identicamente distribuídas  $S\alpha S$  com parâmetro de escala  $\sigma = C_\alpha^{1/\alpha}$ ,  $C_\alpha$  é a constante

$$C_\alpha = \begin{cases} \frac{1-\alpha}{\Gamma(2-\alpha) \cos(\pi\alpha/2)}, & \text{se } \alpha \neq 1, \\ \frac{2}{\pi}, & \text{se } \alpha = 1, \end{cases}$$

$\Gamma(\cdot)$  é a função Gama, definida em (2.2),  $Q^{-1}(\boldsymbol{\eta}_0)$  é a inversa da matriz

$$Q(\boldsymbol{\eta}_0) = \int_{-\pi}^{\pi} g_X(\lambda; \boldsymbol{\eta}_0) \frac{\partial^2}{\partial \boldsymbol{\eta}^2} g_X^{-1}(\lambda; \boldsymbol{\eta}_0) d\lambda,$$

e, para  $k \in \mathbb{N}$ ,  $b_k$  é o vetor

$$b_k = \frac{1}{2\pi} \int_{-\pi}^{\pi} e^{ik\lambda} g(\lambda; \boldsymbol{\eta}_0) \frac{\partial}{\partial \boldsymbol{\eta}} g^{-1}(\lambda; \boldsymbol{\eta}_0) d\lambda.$$

Na prática, aproximamos a integral da equação (3.69) pela soma nos coeficientes de Fourier.

Ndongo et. al. (2010) apresenta um estudo com simulações utilizando este estimador para processos SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estáveis, com  $p = q = 0 = P = Q$  e  $s = 4$ . O estudo apresenta resultados promissores.

Iremos apresentar nas seções seguintes, três modificações para este estimador proposto por Klüppelberg e Mikosch (1996). Com relação aos estimadores propostos nas Seções 3.2.6 à 3.2.8 não provamos as propriedades de consistência e distribuição assintótica. Deixamos esta tarefa para futuros trabalhos.

### 3.2.6 Estimador KMmod

Como visto na seção anterior, na prática, para utilizarmos o estimador proposto por Klüppelberg e Mikosch (1996), considera-se a soma nos coeficiente de Fourier, no lugar da integral. Assim, vamos modificar o estimador original, calculando a função  $\tilde{\sigma}_N^2(\boldsymbol{\eta})$ , dada pela equação (3.69), não apenas nas frequências de Fourier, mas em mais frequências.

Considere a seguinte função

$$\tilde{\sigma}_N^2(\boldsymbol{\eta}) = \frac{2\pi}{cN} \sum_t \frac{\tilde{I}_N(\omega_{ct})}{g_X(\omega_{ct}; \boldsymbol{\eta})}, \quad (3.70)$$

em que  $\omega_{ct} = \frac{2\pi t}{cN}$ ,  $c \in \mathbb{N} - \{1\}$  fixo e finito,  $t \in \mathbb{Z}$ ,  $-\frac{cN}{2} < t \leq \lfloor \frac{cN}{2} \rfloor$ ,  $\tilde{I}_N(\lambda)$  é o periodograma normalizado, dado na Definição 2.18, e  $g_X(\lambda; \boldsymbol{\eta})$  é a função poder de transferência, dada em (2.26), para o processo SARFIMA  $\alpha$ -estável. O esti-

mador modificado que estamos propondo, denotado por  $\tilde{\boldsymbol{\eta}}_N^*$ , é o ponto de mínimo da equação (3.70), com relação à  $\boldsymbol{\eta}$ .

### 3.2.7 Estimador KMS

Outra modificação que queremos propor ao estimador proposto por Klüppelberg e Mikosch (1996), é a utilização do periodograma normalizado suavizado de correlações, dado pela Definição 2.19, no lugar do periodograma normalizado. Assim, vamos definir a seguir este novo estimador.

Considere a seguinte função

$$\bar{\sigma}_N^2(\boldsymbol{\eta}) = \int_{-\pi}^{\pi} \frac{\tilde{I}_{SN}(\lambda)}{g_X(\lambda; \boldsymbol{\eta})} d\lambda, \quad (3.71)$$

em que  $\tilde{I}_{SN}(\lambda)$  é o periodograma normalizado suavizado de correlações, dado pela Definição 2.19 e  $g_X(\lambda; \boldsymbol{\eta})$  é a função poder de transferência, dada em (2.26), para o processo SARFIMA  $\alpha$ -estável. O estimador modificado que estamos propondo, denotado por  $\tilde{\boldsymbol{\eta}}_N^*$ , é o ponto de mínimo da equação (3.71). Na prática, aproximamos a integral pela soma nos coeficientes de Fourier.

### 3.2.8 Estimador KMSmod

Como, na prática, para utilizarmos o estimador KMS definido na Subseção 3.2.7, consideramos a soma nos coeficiente de Fourier, no lugar da integral, vamos modificar o estimador original, aproximando a função  $\bar{\sigma}_N^2(\boldsymbol{\eta})$ , dada pela equação (3.71), não apenas pela soma nas frequências de Fourier, passando a calcular a soma em mais frequências.

Considere a seguinte função

$$\hat{\sigma}_N^2(\boldsymbol{\eta}) = \frac{2\pi}{cN} \sum_t \frac{\tilde{I}_{SN}(\omega_{ct})}{g_X(\omega_{ct}; \boldsymbol{\eta})}, \quad (3.72)$$

em que  $\omega_{ct} = \frac{2\pi t}{cN}$ ,  $c \in \mathbb{N} - \{1\}$  fixo e finito,  $t \in \mathbb{Z}, -\frac{cN}{2} < t \leq \lfloor \frac{cN}{2} \rfloor$ ,  $\tilde{I}_{SN}(\lambda)$  é

o periodograma normalizado suavizado de correlações, dado pela Definição 2.19 e  $g_X(\lambda; \boldsymbol{\eta})$  é a função poder de transferência, dada em (2.26), para o processo SARFIMA  $\alpha$ -estável. O estimador modificado que estamos propondo, denotado por  $\hat{\boldsymbol{\eta}}_N^*$ , é o ponto de mínimo da equação (3.72), com relação à  $\boldsymbol{\eta}$ .

# Capítulo 4

## Simulações

Neste capítulo iremos apresentar o método de simulação dos processos apresentados no Capítulo 2. Além disso, iremos fazer a estimativa dos parâmetros para os dados simulados através das diversas metodologias apresentadas no Capítulo 3.

Para gerarmos realizações dos processos iremos utilizar a representação média móvel infinita (ver expressão (2.7)) com apropriado ponto de truncamento. Por ser um processo complexo, este ponto de truncamento da expressão em (2.7) deve ser um valor grande. Neste trabalho, o ponto de truncamento será  $\mathfrak{M} = 10000 + N$ , em que  $N$  é o tamanho da amostra, ou seja

$$X_t = \sum_{j=0}^{\mathfrak{M}} \psi_j \varepsilon_{t-j}. \quad (4.1)$$

A seguir iremos descrever os passos para as simulações das séries de tamanho  $N$ :

- 1º Passo: Calcular o filtro linear  $\{\psi_j\}_{j=0}^{\mathfrak{M}}$ , supondo os valores dos parâmetros conhecidos.
- 2º Passo: Gerar as  $\mathfrak{M}$  inovações (ruídos brancos Gaussianos para processos normais e variáveis  $\alpha$ -estáveis simétricas para processos  $\alpha$ -estáveis).
- 3º Passo: Aplicar o filtro nas inovações, a partir da representação média móvel infinita truncada, dada pela equação (4.1).
- 4º Passo: Aplicado o filtro, é gerada uma série temporal de tamanho  $10000 + N$ . Desconsideramos as 10000 primeiras observações. Gerando, assim, uma série

temporal de tamanho  $N$ .

Iremos dividir este capítulo em duas seções, uma apresentando as simulações para processos com inovações ruído branco normais e outra para processos  $\alpha$ -estáveis. Iremos considerar para as simulações apenas os processos  $\text{SARFIMA}(p, d, q) \times (P, D, Q)_s$  normais e  $\alpha$ -estáveis, pois são os processos mais gerais que definimos neste trabalho. A seguir iremos apresentar as simulações de Monte Carlo para os processos  $\text{SARFIMA}(p, d, q) \times (P, D, Q)_s$  com média  $\mu = 0$  e diferentes valores de  $d, D, p, q, P, Q$  e  $s$ . Consideraremos tamanhos amostrais  $N \in \{500, 1000, 2000\}$ , além disso, o processo de inovação ruído branco tem distribuição normal padrão, isto é,  $\sigma_\varepsilon^2 = 1$  em todas simulações de processos normais; nos processos de inovação  $\alpha$ -estáveis, o parâmetro  $\sigma = 1$  e o parâmetro  $\alpha \in \{1.25; 1.50; 1.75\}$ .

Os resultados apresentados são baseados em 1000 replicações, com séries sazonais geradas a partir do método descrito nos passos 1–4 acima. Para todos os estimadores e casos considerados, foram calculados os valores empíricos da média (mean), do vício (bias), do erro quadrático médio (mse) e da variância (var) em relação às 1000 replicações.

## 4.1 Resultados para Processos com Inovações Gaussianas

Nesta seção, iremos apresentar tabelas com diversos resultados para a estimação semiparamétrica e paramétrica dos processos  $\text{SARFIMA}(p, d, q) \times (P, D, Q)$  com inovações na forma de ruído branco Gaussiano, estacionários e com a propriedade de longa dependência, isto é, quando  $0 < d + D < 0.5$ ,  $0 < D < 0.5$  e todas as raízes da equação  $\phi(z)\Phi(z^s) = 0$  estão fora do círculo unitário.

### Resultados da Estimação Semiparamétrica

Apresentamos simulações para os estimadores semiparamétricos definidos nas Seções 3.1.2 e 3.1.3 para processos normais. Além da metodologia dos mínimos quadrados, denotada por MQ, utilizamos as metodologias robustas MM e MQP, abordadas na Seção 3.1.1. Diversos casos foram considerados nas simulações, mas, por questão de espaço, apresentaremos apenas casos selecionados.

As Tabelas 4.1 à 4.6 referem-se aos processos SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>, nos casos  $p = q = 0 = P = Q$ ,  $d = D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $N \in \{500, 1000, 2000\}$  e  $\kappa \in \{0.70; 0.85\}$ . No Apêndice A apresentamos os resultados da estimação nos processos SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>, nos casos  $p = q = 0 = P = Q$ ,  $d = D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $N \in \{500, 1000, 2000\}$ , com o  $\kappa$  máximo relativo a cada diferente valor de  $N$ . Não apresentamos no corpo do texto este caso, pois, como para cada  $N$  temos um  $\kappa$  diferente, não teríamos como compará-los entre si, então optamos por apresentar os resultados utilizando o maior  $\kappa$  presente nos diversos valores de  $N$ , além de um valor menor de  $\kappa$  para verificarmos a melhora na estimação quando  $\kappa$  aumenta.

Analizando as Tabelas 4.1 e 4.2 e Figuras 4.1 à 4.3, quando  $N = 500$ , podemos notar que, ao aumentarmos o valor de  $\kappa$ , em geral, o vício dos estimadores diminui. O mesmo ocorre quando  $N = 1000$ , notamos ao observar as Tabelas 4.3 e 4.4. Apenas quando  $N = 2000$  (Tabelas 4.5 e 4.6), que não notamos essa melhora com o aumento de  $\kappa$ . Outro aspecto que notamos ao analisar estas tabelas, é que ao aumentarmos o valor de  $N$ , o valor do erro quadrático médio diminui. Note também que, pelas Figuras 4.1 à 4.3 e Tabelas 4.1 à 4.6, os estimadores que utilizam o periodograma suavizado de covariâncias (denotados por BA), possuem menor vício, nos casos analisados. Dentre as metodologias utilizadas para o estimador BA (MQ, MM e MQP), nenhum se sobressai, sendo variados os resultados encontrados. Também observe que, entre os estimadores que utilizam o periodograma comum (denotados por GPH), em quase todos os casos (com exceção de  $N = 500$ ,  $s \in \{6, 12\}$  e  $\kappa = 0.70$ ), o estimador utilizando a metodologia robusta MM, foi o que apresentou menor vício.

As Tabelas 4.3 e 4.4 referentes ao caso  $N = 1000$  mostram que os estimadores de  $d = 0.2$  que se sobressaem são os que utilizam o periodograma normalizado suavizado de correlações (BA), que possuem menor vício. Para estimar  $D = 0.2$  destacam-se os estimadores BA MQ e BA MM.

As Tabelas 4.5 e 4.6 referentes ao caso  $N = 2000$  mostram que os estimadores de  $d = 0.2$  que se sobressaem, possuindo menor vício, são os BA MQ e BA MQP. Para estimar  $D = 0.2$  destaca-se o estimador BA MQ.

A Tabela 4.7 refere-se ao processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>, no caso  $p = 1$ ,  $q = 0 = P = Q$ ,  $d = D = 0.2$ ,  $\phi_1 = 0.5$ ,  $s \in \{4, 6, 12\}$ ,  $N = 1000$  e  $\kappa = 0.85$ . Note que, a estimação dos parâmetros ficou péssima, indiferente do tipo de estimador considerado. No Apêndice A apresentamos resultados semelhantes para o processo

$\text{SARFIMA}(p, d, q) \times (P, D, Q)_s$ , no caso  $q = 1$ ,  $p = 0 = P = Q$ ,  $d = D = 0.2$ ,  $\theta_1 = 0.5$ ,  $s \in \{4, 6, 12\}$ ,  $N \in \{500, 1000, 2000\}$  e  $\kappa = 0.85$ . Tal fato, nos leva a descartar a utilização dos estimadores semiparamétricos descritos neste trabalho, quando temos processos  $\text{SARFIMA}(p, d, q) \times (P, D, Q)_s$ , com  $p \neq 0$  ou  $q \neq 0$  ou  $P \neq 0$  ou  $Q \neq 0$ .

Note que, em todos os casos considerados, o estimador GPH, independente da metodologia utilizada, superestima o verdadeiro valor de  $d$ .

**Tabela 4.1:** Resultado da estimativa semiparamétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>, quando  $p = q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\kappa = 0.70$  e  $N = 500$ .

		$\kappa = 0.70$					
		$s = 4$					
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2473	0.2311	0.2408	0.2213	0.2422	0.2225	0.1939
bias	0.0473	0.0311	0.0408	0.0213	0.0422	0.0225	-0.0061
mse	0.0067	0.0116	0.0063	0.0145	0.0062	0.0137	0.0023
var	0.0044	0.0107	0.0047	0.0141	0.0044	0.0132	0.0022
		$\kappa = 0.70$				$\kappa = 0.70$	
		$s = 6$				<b>GPH MQ</b>	
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2499	0.2372	0.2469	0.2326	0.2452	0.2284	0.1928
bias	0.0499	0.0372	0.0469	0.0326	0.0452	0.0284	-0.0072
mse	0.0080	0.0125	0.0080	0.0159	0.0081	0.0141	0.0026
var	0.0055	0.0112	0.0058	0.0149	0.0060	0.0133	0.0026
		$\kappa = 0.70$				$\kappa = 12$	
		$s = 12$				<b>GPH MQ</b>	
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2502	0.2381	0.2447	0.2378	0.2431	0.2345	0.1867
bias	0.0502	0.0381	0.0447	0.0378	0.0431	0.0345	-0.0133
mse	0.0093	0.0148	0.0120	0.0173	0.0106	0.0179	0.0030
var	0.0068	0.0133	0.0100	0.0159	0.0088	0.0167	0.0029

		$\kappa = 0.70$					
		$s = 12$					
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.1923	0.1976	0.1967	0.1953	0.1915	0.1967	0.1923
bias	0.0024	-0.0026	-0.0085	-0.0147	-0.0085	-0.0033	-0.0077
mse	0.0038	0.0026	0.0049	0.0046	0.0063	0.0069	0.0045
var	0.0074	0.0029	0.0049	0.0046	0.0062	0.0068	0.0044

**Tabela 4.2:** Resultado da estimativa semiparamétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>, quando  $p = q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\kappa = 0.85$  e  $N = 500$ .

		$\kappa = 0.85$					
		$s = 4$					
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2370	0.2141	0.2275	0.2046	0.2332	0.2086	0.1972
bias	0.0370	0.0141	0.0275	0.0046	0.0332	0.0086	-0.0028
mse	0.0045	0.0039	0.0062	0.0072	0.0043	0.0044	0.0017
var	0.0031	0.0037	0.0055	0.0072	0.0032	0.0044	0.0017
		$\kappa = 0.85$				$s = 6$	
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2362	0.2214	0.2277	0.2086	0.2317	0.2164	0.1966
bias	0.0362	0.0214	0.0277	0.0086	0.0317	0.0164	-0.0034
mse	0.0043	0.0040	0.0064	0.0071	0.0044	0.0045	0.0016
var	0.0030	0.0036	0.0056	0.0071	0.0034	0.0043	0.0016
		$\kappa = 0.85$				$s = 12$	
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2336	0.2271	0.2235	0.2160	0.2292	0.2223	0.1943
bias	0.0336	0.0271	0.0235	0.0160	0.0292	0.0223	-0.0057
mse	0.0042	0.0047	0.0065	0.0085	0.0045	0.0056	0.0016
var	0.0030	0.0040	0.0059	0.0082	0.0037	0.0051	0.0016

		$\kappa = 0.85$					
		$s = 4$					
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2370	0.2141	0.2275	0.2046	0.2332	0.2086	0.1996
bias	0.0370	0.0141	0.0275	0.0046	0.0332	0.0086	-0.0004
mse	0.0045	0.0039	0.0062	0.0072	0.0043	0.0044	0.0020
var	0.0031	0.0037	0.0055	0.0072	0.0032	0.0044	0.0020
		$\kappa = 0.85$				$s = 6$	
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2362	0.2214	0.2277	0.2086	0.2317	0.2164	0.1966
bias	0.0362	0.0214	0.0277	0.0086	0.0317	0.0164	-0.0034
mse	0.0043	0.0040	0.0064	0.0071	0.0044	0.0045	0.0016
var	0.0030	0.0036	0.0056	0.0071	0.0034	0.0043	0.0016
		$\kappa = 0.85$				$s = 12$	
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2336	0.2271	0.2235	0.2160	0.2292	0.2223	0.1943
bias	0.0336	0.0271	0.0235	0.0160	0.0292	0.0223	-0.0057
mse	0.0042	0.0047	0.0065	0.0085	0.0045	0.0056	0.0016
var	0.0030	0.0040	0.0059	0.0082	0.0037	0.0051	0.0016

		$\kappa = 0.85$					
		$s = 6$					
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2362	0.2214	0.2277	0.2086	0.2317	0.2164	0.1966
bias	0.0362	0.0214	0.0277	0.0086	0.0317	0.0164	-0.0034
mse	0.0043	0.0040	0.0064	0.0071	0.0044	0.0045	0.0016
var	0.0030	0.0036	0.0056	0.0071	0.0034	0.0043	0.0016
		$\kappa = 0.85$				$s = 12$	
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2336	0.2271	0.2235	0.2160	0.2292	0.2223	0.1943
bias	0.0336	0.0271	0.0235	0.0160	0.0292	0.0223	-0.0057
mse	0.0042	0.0047	0.0065	0.0085	0.0045	0.0056	0.0016
var	0.0030	0.0040	0.0059	0.0082	0.0037	0.0051	0.0016

		$\kappa = 0.85$					
		$s = 12$					
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2336	0.2271	0.2235	0.2160	0.2292	0.2223	0.1943
bias	0.0336	0.0271	0.0235	0.0160	0.0292	0.0223	-0.0057
mse	0.0042	0.0047	0.0065	0.0085	0.0045	0.0056	0.0016
var	0.0030	0.0040	0.0059	0.0082	0.0037	0.0051	0.0016

**Tabela 4.3:** Resultado da estimativa semiparamétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>, quando  $p = q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\kappa = 0.70$  e  $N = 1000$ .

		$\kappa = 0.70$				$\kappa = 0.70$			
		$s = 4$		$s = 6$		$s = 12$			
		<b>GPH MQ</b>	<b>GPH MM</b>	<b>GPH MQP</b>	<b>GPH MM</b>	<b>GPH MQ</b>	<b>GPH MM</b>	<b>GPH MQP</b>	<b>GPH MM</b>
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2307	0.2178	0.2272	0.2060	0.2279	0.2111	0.1986	0.2009	0.2020
bias	0.0307	0.0178	0.0272	0.0060	0.0279	0.0111	-0.0014	0.0009	0.0020
mse	0.0030	0.0057	0.0037	0.0088	0.0032	0.0064	0.0011	0.0028	0.0016
var	0.0020	0.0054	0.0030	0.0088	0.0025	0.0063	0.0011	0.0028	0.0016
mean	0.2365	0.2279	0.2288	0.2179	0.2345	0.2207	0.1991	0.1953	0.2022
bias	0.0365	0.0279	0.0288	0.0179	0.0345	0.0207	-0.0009	-0.0047	0.0022
mse	0.0038	0.0064	0.0043	0.0084	0.0038	0.0068	0.0013	0.0027	0.0024
var	0.0025	0.0056	0.0035	0.0081	0.0026	0.0064	0.0013	0.0027	0.0024
mean	0.2356	0.2362	0.2247	0.2306	0.2311	0.2349	0.1920	0.1959	0.1960
bias	0.0356	0.0362	0.0247	0.0306	0.0311	0.0349	-0.0080	-0.0041	-0.0040
mse	0.0044	0.0074	0.0056	0.0097	0.0047	0.0086	0.0017	0.0025	0.0025
var	0.0031	0.0061	0.0050	0.0088	0.0037	0.0074	0.0016	0.0024	0.0025

**Tabela 4.4:** Resultado da estimativa semiparamétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>, quando  $p = q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\kappa = 0.85$  e  $N = 1000$ .

		$\kappa = 0.85$					
		$s = 4$					
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2235	0.2093	0.2189	0.1981	0.2228	0.2056	0.2011
bias	0.0235	0.0093	0.0189	-0.0019	0.0228	0.0056	0.0006
mse	0.0019	0.0017	0.0034	0.0039	0.0022	0.0021	0.0008
var	0.0014	0.0016	0.0030	0.0039	0.0017	0.0020	0.0008
		$s = 6$				<b>GPH MQ</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2246	0.2140	0.2151	0.2048	0.2209	0.2104	0.2005
bias	0.0246	0.0140	0.0151	0.0048	0.0209	0.0104	0.0005
mse	0.0020	0.0018	0.0031	0.0038	0.0020	0.0021	0.0008
var	0.0014	0.0017	0.0029	0.0038	0.0015	0.0020	0.0008
		$s = 12$				<b>GPH MQP</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2199	0.2206	0.2122	0.2144	0.2169	0.2199	0.1958
bias	0.0199	0.0206	0.0122	0.0144	0.0169	0.0199	-0.0042
mse	0.0019	0.0021	0.0037	0.0041	0.0021	0.0026	0.0009
var	0.0015	0.0017	0.0035	0.0039	0.0019	0.0022	0.0009

**Tabela 4.5:** Resultado da estimativa semiparamétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$ , quando  $p = q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\kappa = 0.70$  e  $N = 2000$ .

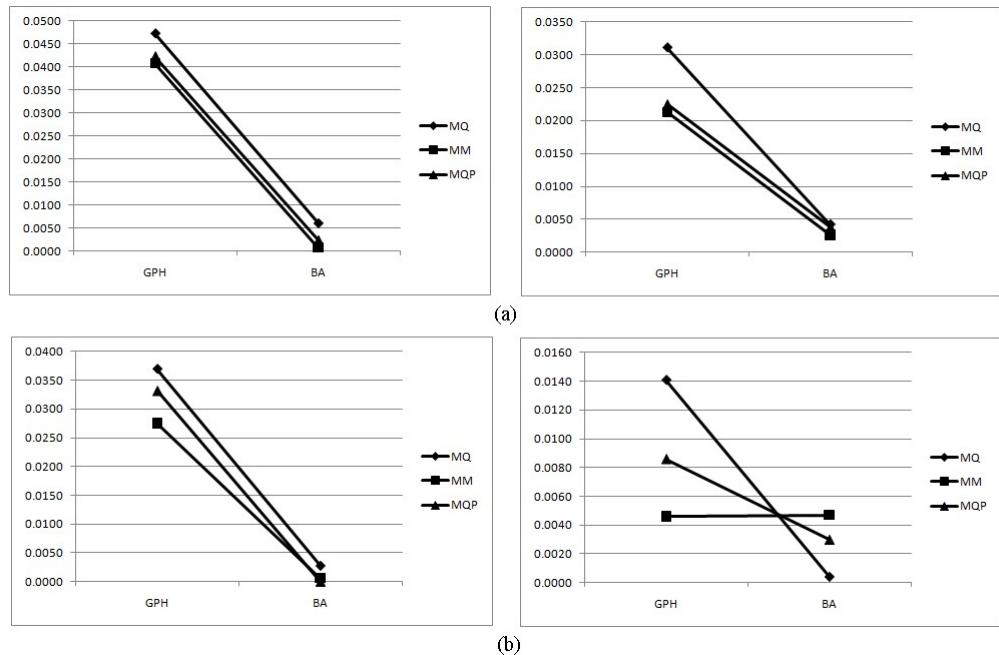
		$\kappa = 0.70$				$\kappa = 0.70$			
		$s = 4$		$s = 6$		$s = 12$			
		<b>GPH MQ</b>	<b>GPH MM</b>	<b>GPH MQP</b>	<b>GPH MM</b>	<b>GPH MQ</b>	<b>GPH MM</b>	<b>GPH MQP</b>	<b>GPH MM</b>
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2205	0.2169	0.2158	0.2097	0.2182	0.2151	0.1999	0.2020	0.2016
bias	0.0205	0.0169	0.0158	0.0097	0.0182	0.0151	-0.0001	0.0020	0.0016
mse	0.0015	0.0031	0.0021	0.0059	0.0015	0.0034	0.0006	0.0016	0.0010
var	0.0010	0.0028	0.0019	0.0059	0.0012	0.0032	0.0006	0.0016	0.0010
		<b>GPH MQ</b>	<b>GPH MM</b>	<b>GPH MQP</b>	<b>GPH MM</b>	<b>GPH MQ</b>	<b>GPH MM</b>	<b>GPH MQP</b>	<b>GPH MM</b>
mean	0.2220	0.2189	0.2124	0.2077	0.2200	0.2174	0.1995	0.1996	0.2007
bias	0.0220	0.0189	0.0124	0.0077	0.0200	0.0174	-0.0005	-0.0004	0.0007
mse	0.0018	0.0031	0.0026	0.0061	0.0019	0.0036	0.0008	0.0015	0.0010
var	0.0013	0.0028	0.0024	0.0060	0.0015	0.0033	0.0008	0.0015	0.0010

**Tabela 4.6:** Resultado da estimativa semiparamétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$ , quando  $p = q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\kappa = 0.85$  e  $N = 2000$ .

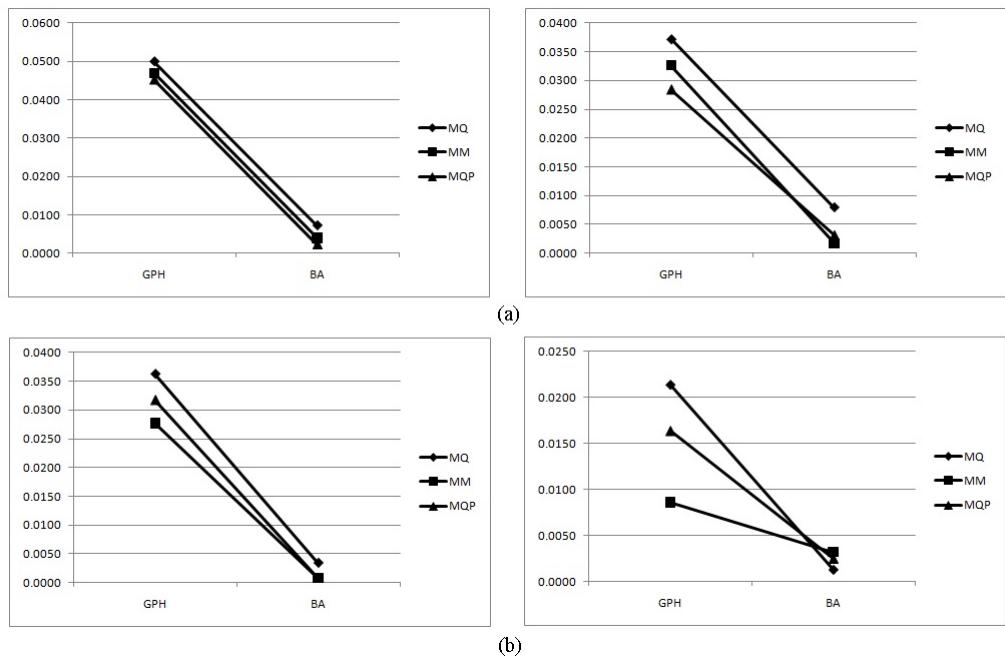
		$\kappa = 0.85$				$\kappa = 0.85$			
		$s = 4$		$s = 6$		$s = 12$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>BA MQ</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2140	0.2068	0.2085	0.2032	0.2118	0.2053	0.2003	0.2024	0.2007
bias	0.0140	0.0068	0.0085	0.0032	0.0118	0.0053	0.0003	0.0024	0.0007
mse	0.0009	0.0009	0.0015	0.0019	0.0009	0.0011	0.0004	0.0005	0.0006
var	0.0007	0.0008	0.0015	0.0019	0.0008	0.0011	0.0004	0.0005	0.0006
mean	0.2138	0.2082	0.2095	0.2042	0.2124	0.2078	0.2003	0.2016	0.2004
bias	0.0138	0.0082	0.0095	0.0042	0.0124	0.0078	0.0003	0.0016	0.0004
mse	0.0009	0.0008	0.0018	0.0019	0.0011	0.0011	0.0004	0.0005	0.0007
var	0.0007	0.0008	0.0017	0.0019	0.0009	0.0010	0.0004	0.0005	0.0008
mean	0.2140	0.2136	0.2089	0.2047	0.2110	0.2111	0.1988	0.2029	0.1995
bias	0.0140	0.0136	0.0089	0.0047	0.0110	0.0111	-0.0012	0.0029	-0.0005
mse	0.0010	0.0011	0.0019	0.0024	0.0012	0.0014	0.0005	0.0005	0.0008
var	0.0008	0.0009	0.0018	0.0024	0.0010	0.0012	0.0005	0.0005	0.0008

**Tabela 4.7:** Resultado da estimativa semiparamétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>, quando  $p = 1, q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $\phi_1 = 0.5$ ,  $s \in \{4, 6, 12\}$ ,  $\kappa = 0.85$  e  $N = 1000$ .

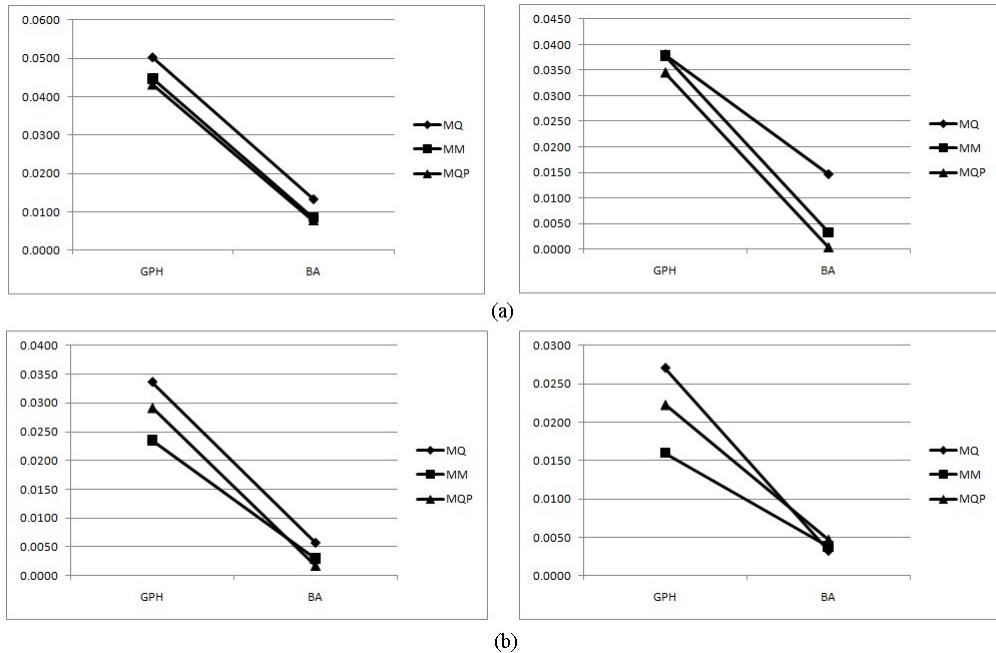
		$\kappa = 0.85$				$\kappa = 0.85$			
		$s = 4$				$s = 6$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MQ</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.5832	0.1291	0.5960	0.1280	0.5922	0.1301	0.5571	0.1203	0.6405
bias	0.3832	-0.0709	0.3960	-0.0720	0.3922	-0.0699	0.3571	-0.0797	0.4405
mse	0.1482	0.0067	0.1605	0.0104	0.1555	0.0073	0.1283	0.0074	0.2003
var	0.0013	0.0017	0.0037	0.0053	0.0017	0.0025	0.0008	0.0010	0.0062
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.5666	0.1585	0.5866	0.1572	0.5796	0.1618	0.5406	0.1468	0.6519
bias	0.3666	-0.0415	0.3866	-0.0428	0.3796	-0.0382	0.3406	-0.0532	0.4519
mse	0.1359	0.0035	0.1532	0.0072	0.1460	0.0038	0.1169	0.0038	0.2157
var	0.0015	0.0018	0.0038	0.0054	0.0019	0.0024	0.0009	0.0010	0.0114
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.5624	0.1916	0.5940	0.1935	0.5809	0.1983	0.5352	0.1737	0.7281
bias	0.3624	-0.0084	0.3940	-0.0065	0.3809	-0.0017	0.3352	-0.0263	0.5281
mse	0.1327	0.0018	0.1616	0.0048	0.1472	0.0028	0.1132	0.0016	0.2943
var	0.0014	0.0017	0.0064	0.0047	0.0022	0.0028	0.0009	0.0009	0.0155
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.5624	0.1916	0.5940	0.1935	0.5809	0.1983	0.5352	0.1737	0.7281
bias	0.3624	-0.0084	0.3940	-0.0065	0.3809	-0.0017	0.3352	-0.0263	0.5281
mse	0.1327	0.0018	0.1616	0.0048	0.1472	0.0028	0.1132	0.0016	0.2943
var	0.0014	0.0017	0.0064	0.0047	0.0022	0.0028	0.0009	0.0009	0.0155
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.5624	0.1916	0.5940	0.1935	0.5809	0.1983	0.5352	0.1737	0.7281
bias	0.3624	-0.0084	0.3940	-0.0065	0.3809	-0.0017	0.3352	-0.0263	0.5281
mse	0.1327	0.0018	0.1616	0.0048	0.1472	0.0028	0.1132	0.0016	0.2943
var	0.0014	0.0017	0.0064	0.0047	0.0022	0.0028	0.0009	0.0009	0.0155
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.5624	0.1916	0.5940	0.1935	0.5809	0.1983	0.5352	0.1737	0.7281
bias	0.3624	-0.0084	0.3940	-0.0065	0.3809	-0.0017	0.3352	-0.0263	0.5281
mse	0.1327	0.0018	0.1616	0.0048	0.1472	0.0028	0.1132	0.0016	0.2943
var	0.0014	0.0017	0.0064	0.0047	0.0022	0.0028	0.0009	0.0009	0.0155
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.5624	0.1916	0.5940	0.1935	0.5809	0.1983	0.5352	0.1737	0.7281
bias	0.3624	-0.0084	0.3940	-0.0065	0.3809	-0.0017	0.3352	-0.0263	0.5281
mse	0.1327	0.0018	0.1616	0.0048	0.1472	0.0028	0.1132	0.0016	0.2943
var	0.0014	0.0017	0.0064	0.0047	0.0022	0.0028	0.0009	0.0009	0.0155
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.5624	0.1916	0.5940	0.1935	0.5809	0.1983	0.5352	0.1737	0.7281
bias	0.3624	-0.0084	0.3940	-0.0065	0.3809	-0.0017	0.3352	-0.0263	0.5281
mse	0.1327	0.0018	0.1616	0.0048	0.1472	0.0028	0.1132	0.0016	0.2943
var	0.0014	0.0017	0.0064	0.0047	0.0022	0.0028	0.0009	0.0009	0.0155
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.5624	0.1916	0.5940	0.1935	0.5809	0.1983	0.5352	0.1737	0.7281
bias	0.3624	-0.0084	0.3940	-0.0065	0.3809	-0.0017	0.3352	-0.0263	0.5281
mse	0.1327	0.0018	0.1616	0.0048	0.1472	0.0028	0.1132	0.0016	0.2943
var	0.0014	0.0017	0.0064	0.0047	0.0022	0.0028	0.0009	0.0009	0.0155
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.5624	0.1916	0.5940	0.1935	0.5809	0.1983	0.5352	0.1737	0.7281
bias	0.3624	-0.0084	0.3940	-0.0065	0.3809	-0.0017	0.3352	-0.0263	0.5281
mse	0.1327	0.0018	0.1616	0.0048	0.1472	0.0028	0.1132	0.0016	0.2943
var	0.0014	0.0017	0.0064	0.0047	0.0022	0.0028	0.0009	0.0009	0.0155
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.5624	0.1916	0.5940	0.1935	0.5809	0.1983	0.5352	0.1737	0.7281
bias	0.3624	-0.0084	0.3940	-0.0065	0.3809	-0.0017	0.3352	-0.0263	0.5281
mse	0.1327	0.0018	0.1616	0.0048	0.1472	0.0028	0.1132	0.0016	0.2943
var	0.0014	0.0017	0.0064	0.0047	0.0022	0.0028	0.0009	0.0009	0.0155
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$						



**Figura 4.1:** Módulo do vício dos estimadores semiparamétricos para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>, com  $p = q = 0 = P = Q$ ,  $N = 500$  e  $s = 4$ , considerando os métodos clássico (MQ) e robustos (MM e MQP). Os gráficos à esquerda são para  $d = 0.2$  e os da direita para  $D = 0.2$ : (a)  $\kappa = 0.70$  e (b)  $\kappa = 0.85$ .



**Figura 4.2:** Módulo do vício dos estimadores semiparamétricos para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>, com  $p = q = 0 = P = Q$ ,  $N = 500$  e  $s = 6$ , considerando os métodos clássico (MQ) e robustos (MM e MQP). Os gráficos à esquerda são para  $d = 0.2$  e os da direita para  $D = 0.2$ : (a)  $\kappa = 0.70$  e (b)  $\kappa = 0.85$ .



**Figura 4.3:** Módulo do vício dos estimadores semiparamétricos para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>, com  $p = q = 0 = P = Q$ ,  $N = 500$  e  $s = 12$ , considerando os métodos clássico (MQ) e robustos (MM e MQP). Os gráficos à esquerda são para  $d = 0.2$  e os da direita para  $D = 0.2$ : (a)  $\kappa = 0.70$  e (b)  $\kappa = 0.85$ .

## Resultados da Estimação Paramétrica

Iremos considerar, nas simulações, os estimadores paramétricos definidos nas Seções 3.2.2, 3.2.3 e 3.2.4, denotados por FT, FTmod e FTS, respectivamente. Para o estimador FTmod, no qual aproximamos a integral dada em (3.43) por uma soma em mais coeficientes, além dos de Fourier, precisamos definir o valor de  $c$ , na equação (3.45), consideraremos nas simulações apresentadas  $c = 5$ . Além disso, no estimador FTS, iremos utilizar a janela de Bartlett na suavização do periodograma, dada pela equação (3.20).

As Tabelas 4.8 à 4.10 e a Figura 4.4 apresentam resultados para a estimação paramétrica, considerando  $N = 500$ ,  $N = 1000$  e  $N = 2000$ , respectivamente, em um processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>, com  $p = q = 0 = P = Q$ ,  $d = D = 0.2$  e  $s \in \{4, 6, 12\}$ . Note que, para o estimador original FT, proposto por Fox e Taqqu (1986), à medida que o  $N$  aumenta, a estimação de  $d = 0.2$  melhora, no entanto, os estimadores propostos neste trabalho FTmod e FTS melhoram a estimação de  $d = 0.2$ , em todos os casos de  $N$ , diminuindo o vício. O estimador para  $d = 0.2$  com menor vício, para todos  $N$  e  $s$  considerados, é o FTS. Na estimação de  $D = 0.2$ , o

estimador FT melhora à medida que  $N$  aumenta, chegando a zerar o vício, quando  $N = 2000$  e  $s = 6$ , no entanto, os estimadores propostos melhoram a estimação em alguns casos, como quando  $N = 500$  e  $s \in \{6, 12\}$ , nesta situação o estimador FTmod é melhor que os demais, diminuindo o vício, o erro quadrático médio e a variância.

**Tabela 4.8:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q) \times (P, D, Q)_s$ , quando  $p = q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$  e  $N = 500$ .

		$s = 4$					
		FT		FTmod		FTS	
		$d = 0.2$					
<b>mean</b>	0.2459	0.1939		0.2115	0.1893	0.1932	0.1743
	0.0459	-0.0061		0.0115	-0.0107	-0.0068	-0.0257
	0.0045	0.0019		0.0016	0.0015	0.0016	0.0021
	0.0024	0.0019		0.0015	0.0014	0.0015	0.0015
		$s = 6$					
		FT		FTmod		FTS	
		$d = 0.2$					
<b>mean</b>	0.2429	0.1893		0.2089	0.1914	0.1941	0.1613
	0.0429	-0.0107		0.0089	-0.0086	-0.0059	-0.0387
	0.0042	0.0024		0.0015	0.0015	0.0015	0.0030
	0.0023	0.0023		0.0014	0.0015	0.0015	0.0015
		$s = 12$					
		FT		FTmod		FTS	
		$d = 0.2$					
<b>mean</b>	0.2455	0.1691		0.2086	0.1921	0.1920	0.1289
	0.0455	-0.0309		0.0086	-0.0079	-0.0080	-0.0711
	0.0048	0.0032		0.0015	0.0014	0.0014	0.0066
	0.0027	0.0023		0.0014	0.0013	0.0013	0.0016

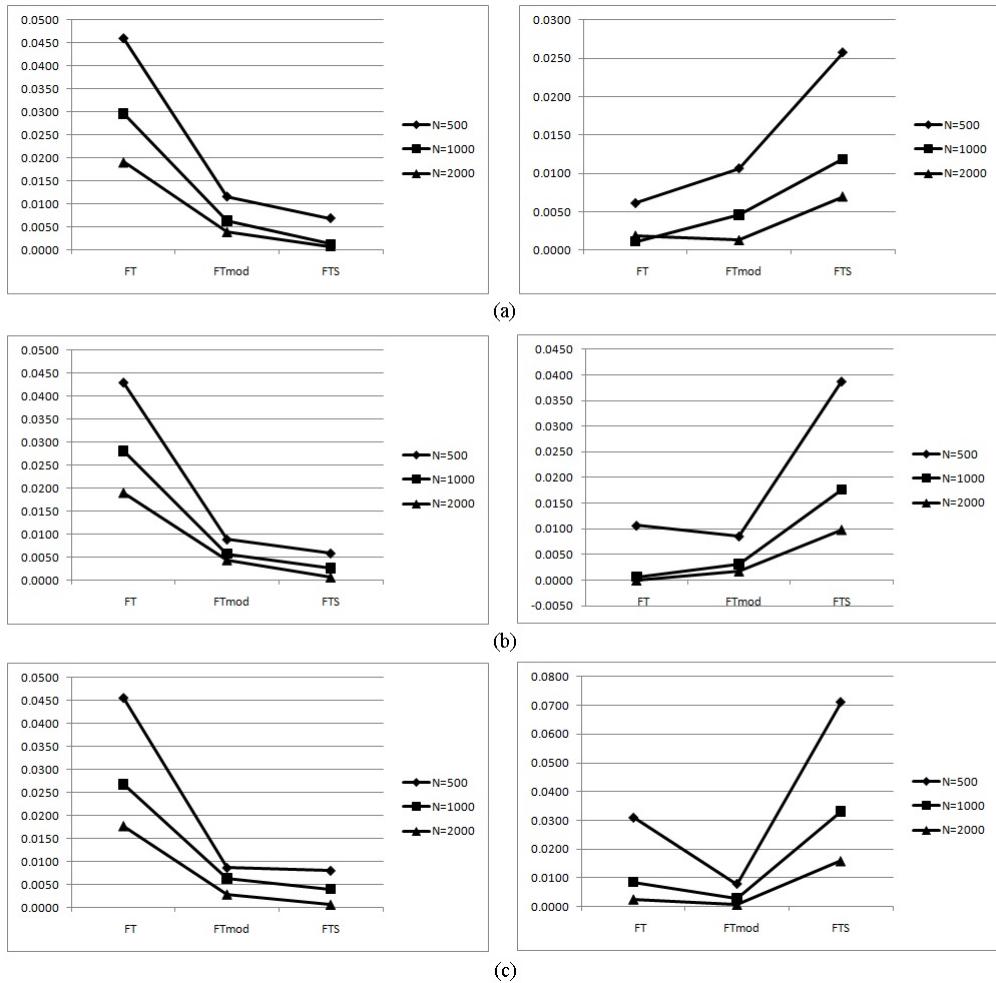
Analizando as Tabelas 4.11 à 4.13, que apresentam resultados para a estimação paramétrica, considerando  $N = 500$ ,  $N = 1000$  e  $N = 2000$ , respectivamente, em um processo SARFIMA( $p, d, q) \times (P, D, Q)_s$ , com  $p = 1$ ,  $q = 0 = P = Q$ ,  $d = D = 0.2$ ,  $\phi_1 = 0.5$  e  $s \in \{4, 6, 12\}$ , observamos que, em geral, nos métodos propostos, a estimação dos parâmetros é melhorada quando o tamanho amostral  $N$  aumenta. Veja que, para a estimação de  $d = 0.2$ , os estimadores FTmod e FTS são melhores que o FT, no sentido de que o vício é menor. Em alguns casos, FTmod é melhor que o FTS e o contrário também ocorre, dependendo do tamanho de  $N$  e  $s$ . No entanto, ambos os estimadores apresentam vício, erro quadrático médio e variância pequenos. Na estimação de  $D = 0.2$ , o estimador FTS tem menor vício apenas no caso em que  $N = 2000$  e  $s = 4$ , nos demais, o estimador FTmod apresenta menor vício. Para a estimação de  $\phi_1 = 0.5$ , no caso em que  $N = 500$  e  $N = 1000$  (com exceção do caso  $s = 12$ ), o estimador FTS tem menor vício que os demais.

**Tabela 4.9:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$ , quando  $p = q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$  e  $N = 1000$ .

		$s = 4$					
		FT		FTmod		FTS	
		$d = 0.2$					
<b>mean</b>		0.2296	0.1989	0.2064	0.1954	0.1987	0.1881
<b>bias</b>		0.0296	-0.0011	0.0064	-0.0046	-0.0013	-0.0119
<b>mse</b>		0.0018	0.0010	0.0007	0.0007	0.0007	0.0009
<b>var</b>		0.0009	0.0010	0.0007	0.0006	0.0007	0.0008
		$s = 6$					
		FT		FTmod		FTS	
		$d = 0.2$					
<b>mean</b>		0.2281	0.1994	0.2058	0.1969	0.1974	0.1824
<b>bias</b>		0.0281	-0.0006	0.0058	-0.0031	-0.0026	-0.0176
<b>mse</b>		0.0019	0.0009	0.0007	0.0007	0.0007	0.0010
<b>var</b>		0.0011	0.0009	0.0007	0.0007	0.0007	0.0007
		$s = 12$					
		FT		FTmod		FTS	
		$d = 0.2$					
<b>mean</b>		0.2268	0.1915	0.2063	0.1970	0.1959	0.1669
<b>bias</b>		0.0268	-0.0085	0.0063	-0.0030	-0.0041	-0.0331
<b>mse</b>		0.0017	0.0011	0.0007	0.0006	0.0007	0.0019
<b>var</b>		0.0010	0.0010	0.0007	0.0006	0.0007	0.0008

**Tabela 4.10:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$ , quando  $p = q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$  e  $N = 2000$ .

		$s = 4$					
		FT		FTmod		FTS	
		$d = 0.2$					
<b>mean</b>		0.2191	0.2019	0.2039	0.1987	0.2008	0.1930
<b>bias</b>		0.0191	0.0019	0.0039	-0.0013	0.0008	-0.0070
<b>mse</b>		0.0008	0.0004	0.0003	0.0004	0.0004	0.0004
<b>var</b>		0.0005	0.0004	0.0003	0.0004	0.0004	0.0004
		$s = 6$					
		FT		FTmod		FTS	
		$d = 0.2$					
<b>mean</b>		0.2189	0.2000	0.2044	0.1983	0.1994	0.1902
<b>bias</b>		0.0189	0.0000	0.0044	-0.0017	-0.0006	-0.0098
<b>mse</b>		0.0008	0.0004	0.0004	0.0004	0.0003	0.0004
<b>var</b>		0.0004	0.0004	0.0003	0.0004	0.0003	0.0003
		$s = 12$					
		FT		FTmod		FTS	
		$d = 0.2$					
<b>mean</b>		0.2177	0.1974	0.2029	0.1992	0.1993	0.1840
<b>bias</b>		0.0177	-0.0026	0.0029	-0.0008	-0.0007	-0.0160
<b>mse</b>		0.0008	0.0004	0.0003	0.0003	0.0003	0.0006
<b>var</b>		0.0005	0.0004	0.0003	0.0003	0.0003	0.0004



**Figura 4.4:** Módulo do vício dos estimadores paramétricos para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>, com  $p = q = 0 = P = Q$ ,  $N \in \{500, 1000, 2000\}$ . Os gráficos à esquerda são para  $d = 0.2$  e os da direita para  $D = 0.2$ : (a)  $s = 4$ , (b)  $s = 6$  e (c)  $s = 12$ .

Quando  $N = 2000$ , o estimador FTmod é o de menor vício, erro quadrático médio e variância. De um modo geral, no caso abordado neste parágrafo, nenhuma das estimativas do estimador FT teve menor vício.

As Tabelas 4.14 à 4.16 referem-se a processos SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>,  $N = 500$ ,  $N = 1000$  e  $N = 2000$ , respectivamente, com  $p = 1$ ,  $q = 0 = P = Q$ ,  $d = D = 0.2$ ,  $\phi_1 = -0.5$  e  $s \in \{4, 6, 12\}$ . Observamos que, em geral, nos estimadores considerados, a estimação dos parâmetros é melhorada quando o tamanho amostral  $N$  aumenta. Veja que, para a estimação de  $d = 0.2$ , os estimadores FTmod e FTS são melhores que o FT, no sentido de que o vício é menor. Em alguns casos, FTmod é melhor que o FTS e o contrário também ocorre, dependendo do tamanho de  $N$  e

**Tabela 4.11:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$ , quando  $p = 1$ ,  $q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\phi_1 = 0.5$  e  $N = 500$ .

	$s = 4$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$
<b>mean</b>	0.3125	0.1728	0.4101	0.2402	0.1784	0.4607	0.1936	0.1660	0.4967
<b>bias</b>	0.1125	-0.0272	-0.0899	0.0402	-0.0216	-0.0393	-0.0064	-0.0340	-0.0033
<b>mse</b>	0.0267	0.0028	0.0227	0.0127	0.0021	0.0143	0.0122	0.0029	0.0138
<b>var</b>	0.0141	0.0021	0.0147	0.0111	0.0016	0.0128	0.0122	0.0017	0.0138
	$s = 6$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$
<b>mean</b>	0.3094	0.1740	0.4057	0.2356	0.1843	0.4605	0.1926	0.1588	0.4952
<b>bias</b>	0.1094	-0.0260	-0.0943	0.0356	-0.0157	-0.0395	-0.0074	-0.0412	-0.0048
<b>mse</b>	0.0249	0.0029	0.0226	0.0108	0.0020	0.0128	0.0115	0.0033	0.0131
<b>var</b>	0.0130	0.0022	0.0137	0.0096	0.0018	0.0113	0.0115	0.0016	0.0131
	$s = 12$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$
<b>mean</b>	0.3068	0.1580	0.4096	0.2277	0.1860	0.4696	0.1785	0.1294	0.5074
<b>bias</b>	0.1068	-0.0420	-0.0904	0.0277	-0.0140	-0.0304	-0.0215	-0.0706	0.0074
<b>mse</b>	0.0248	0.0041	0.0221	0.0095	0.0016	0.0115	0.0108	0.0064	0.0121
<b>var</b>	0.0134	0.0023	0.0139	0.0088	0.0014	0.0106	0.0103	0.0014	0.0121

**Tabela 4.12:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$ , quando  $p = 1$ ,  $q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\phi_1 = 0.5$  e  $N = 1000$ .

	$s = 4$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$
<b>mean</b>	0.2704	0.1843	0.4398	0.2173	0.1910	0.4815	0.1819	0.1865	0.5144
<b>bias</b>	0.0704	-0.0157	-0.0602	0.0173	-0.0090	-0.0185	-0.0181	-0.0135	0.0144
<b>mse</b>	0.0207	0.0012	0.0191	0.0067	0.0009	0.0076	0.0079	0.0011	0.0086
<b>var</b>	0.0157	0.0010	0.0155	0.0065	0.0009	0.0072	0.0076	0.0009	0.0084
	$s = 6$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$
<b>mean</b>	0.2790	0.1865	0.4318	0.2201	0.1915	0.4787	0.1813	0.1820	0.5131
<b>bias</b>	0.0790	-0.0135	-0.0682	0.0201	-0.0085	-0.0213	-0.0187	-0.0180	0.0131
<b>mse</b>	0.0161	0.0011	0.0148	0.0070	0.0009	0.0080	0.0079	0.0011	0.0085
<b>var</b>	0.0099	0.0010	0.0102	0.0066	0.0008	0.0075	0.0075	0.0008	0.0083
	$s = 12$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$
<b>mean</b>	0.2804	0.1826	0.4292	0.2106	0.1953	0.4875	0.1802	0.1657	0.5147
<b>bias</b>	0.0804	-0.0174	-0.0708	0.0106	-0.0047	-0.0125	-0.0198	-0.0343	0.0147
<b>mse</b>	0.0144	0.0013	0.0135	0.0058	0.0007	0.0067	0.0065	0.0019	0.0071
<b>var</b>	0.0079	0.0010	0.0085	0.0057	0.0007	0.0065	0.0061	0.0008	0.0069

**Tabela 4.13:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$ , quando  $p = 1$ ,  $q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\phi_1 = 0.5$  e  $N = 2000$ .

	$s = 4$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$
<b>mean</b>	0.2586	0.1897	0.4479	0.2087	0.1943	0.4905	0.1822	0.1945	0.5158
<b>bias</b>	0.0586	-0.0103	-0.0521	0.0087	-0.0057	-0.0095	-0.0178	-0.0055	0.0158
<b>mse</b>	0.0093	0.0006	0.0088	0.0038	0.0004	0.0043	0.0046	0.0005	0.0049
<b>var</b>	0.0058	0.0005	0.0061	0.0038	0.0004	0.0042	0.0043	0.0004	0.0047
	$s = 6$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$
<b>mean</b>	0.2563	0.1922	0.4498	0.2082	0.1967	0.4897	0.1865	0.1913	0.5109
<b>bias</b>	0.0563	-0.0078	-0.0502	0.0082	-0.0033	-0.0103	-0.0135	-0.0087	0.0109
<b>mse</b>	0.0080	0.0005	0.0078	0.0037	0.0004	0.0042	0.0043	0.0005	0.0048
<b>var</b>	0.0048	0.0005	0.0053	0.0036	0.0004	0.0041	0.0041	0.0004	0.0047
	$s = 12$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$
<b>mean</b>	0.2525	0.1922	0.4530	0.2094	0.1968	0.4898	0.1864	0.1846	0.5102
<b>bias</b>	0.0525	-0.0078	-0.0470	0.0094	-0.0032	-0.0102	-0.0136	-0.0154	0.0102
<b>mse</b>	0.0073	0.0005	0.0070	0.0030	0.0003	0.0035	0.0037	0.0006	0.0042
<b>var</b>	0.0046	0.0004	0.0048	0.0029	0.0003	0.0034	0.0035	0.0004	0.0041

$s$ . Mas, veja que, ambos os estimadores apresentam vício, erro quadrático médio e variância pequenos. Na estimativa de  $D = 0.2$ , os resultados foram muito variados, em alguns casos, o estimador FT tem menor vício (por exemplo, no caso  $s = 4$  e  $N \in \{500, 1000, 2000\}$ ), em outros, o estimador FTmod tem menor vício (quando  $s = 12$  e  $N \in \{500, 1000, 2000\}$ ). Veja que, o estimador FTS não teve menor vício, na estimativa de  $D = 0.2$ , em nenhum dos casos analisados. Para a estimativa de  $\phi_1 = 0.5$ , os resultados encontrados são variados, entretanto, todos estimadores analisados apresentaram vício, erro quadrático médio e variância pequenos.

As Tabelas 4.17 à 4.19 apresentam resultados para a estimação paramétrica, considerando  $N = 500$ ,  $N = 1000$  e  $N = 2000$ , respectivamente, em um processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ), com  $q = 1$ ,  $p = 0 = P = Q$ ,  $d = D = 0.2$ ,  $\theta_1 = 0.5$  e  $s \in \{4, 6, 12\}$ . Em todos os casos considerados nestas tabelas, os estimadores FTmod e FTS tiveram menor vício que o estimador FT, além de erro quadrático médio e variância pequenos. Para a estimativa de  $d = 0.2$ , o estimador FTmod tem maior vício que o FTS, apenas quando  $s = 4$  e  $N \in \{500, 1000, 2000\}$ . Nos demais casos, o estimador de  $d = 0.2$ , com menor vício, é o FTS. Na estimativa de  $D = 0.2$ , o estimador FTmod tem menor vício. Apenas quando  $N = 2000$  e  $s = 4$ , que o estimador FTS tem menor vício. Para a estimativa de  $\theta_1 = 0.5$ , no caso em que

**Tabela 4.14:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$ , quando  $p = 1$ ,  $q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\phi_1 = -0.5$  e  $N = 500$ .

		$s = 4$								
		FT			FTmod			FTS		
		$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$
<b>mean</b>		0.2544	0.1879	-0.5051	0.2131	0.1853	-0.4960	0.1930	0.1666	-0.4937
<b>bias</b>		0.0544	-0.0121	-0.0051	0.0131	-0.0147	0.0040	-0.0070	-0.0334	0.0063
<b>mse</b>		0.0064	0.0023	0.0025	0.0025	0.0018	0.0023	0.0026	0.0029	0.0028
<b>var</b>		0.0035	0.0021	0.0024	0.0023	0.0016	0.0023	0.0026	0.0018	0.0028
		$s = 6$								
		FT			FTmod			FTS		
		$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$
<b>mean</b>		0.2472	0.1853	-0.5016	0.2066	0.1888	-0.4914	0.1946	0.1612	-0.4933
<b>bias</b>		0.0472	-0.0147	-0.0016	0.0066	-0.0112	0.0086	-0.0054	-0.0388	0.0067
<b>mse</b>		0.0059	0.0024	0.0025	0.0024	0.0016	0.0024	0.0020	0.0032	0.0022
<b>var</b>		0.0037	0.0022	0.0025	0.0023	0.0015	0.0023	0.0020	0.0017	0.0022
		$s = 12$								
		FT			FTmod			FTS		
		$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$
<b>mean</b>		0.2472	0.1676	-0.5056	0.2036	0.1909	-0.4919	0.1845	0.1295	-0.4868
<b>bias</b>		0.0472	-0.0324	-0.0056	0.0036	-0.0091	0.0081	-0.0155	-0.0705	0.0132
<b>mse</b>		0.0061	0.0034	0.0026	0.0022	0.0015	0.0023	0.0024	0.0066	0.0025
<b>var</b>		0.0039	0.0023	0.0025	0.0022	0.0014	0.0023	0.0022	0.0016	0.0023

**Tabela 4.15:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$ , quando  $p = 1$ ,  $q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\phi_1 = -0.5$  e  $N = 1000$ .

		$s = 4$								
		FT			FTmod			FTS		
		$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$
<b>mean</b>		0.2319	0.1980	-0.5066	0.2060	0.1957	-0.4987	0.1978	0.1863	-0.4992
<b>bias</b>		0.0319	-0.0020	-0.0066	0.0060	-0.0043	0.0013	-0.0022	-0.0137	0.0008
<b>mse</b>		0.0025	0.0010	0.0013	0.0011	0.0008	0.0011	0.0012	0.0009	0.0011
<b>var</b>		0.0015	0.0010	0.0012	0.0010	0.0008	0.0011	0.0012	0.0007	0.0012
		$s = 6$								
		FT			FTmod			FTS		
		$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$
<b>mean</b>		0.2321	0.1972	-0.5035	0.2033	0.1967	-0.4961	0.1975	0.1828	-0.4954
<b>bias</b>		0.0321	-0.0028	-0.0035	0.0033	-0.0033	0.0039	-0.0025	-0.0172	0.0046
<b>mse</b>		0.0026	0.0010	0.0012	0.0011	0.0007	0.0012	0.0010	0.0011	0.0011
<b>var</b>		0.0016	0.0010	0.0012	0.0011	0.0007	0.0011	0.0010	0.0008	0.0011
		$s = 12$								
		FT			FTmod			FTS		
		$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$
<b>mean</b>		0.2309	0.1880	-0.5030	0.2039	0.1960	-0.4965	0.1953	0.1664	-0.4925
<b>bias</b>		0.0309	-0.0120	-0.0030	0.0039	-0.0040	0.0035	-0.0047	-0.0336	0.0075
<b>mse</b>		0.0026	0.0012	0.0012	0.0011	0.0007	0.0011	0.0010	0.0019	0.0012
<b>var</b>		0.0017	0.0011	0.0012	0.0011	0.0007	0.0011	0.0010	0.0008	0.0012

**Tabela 4.16:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$ , quando  $p = 1$ ,  $q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\phi_1 = -0.5$  e  $N = 2000$ .

	$s = 4$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$
<b>mean</b>	0.2217	0.1998	-0.5044	0.2045	0.1977	-0.5005	0.1993	0.1931	-0.4985
<b>bias</b>	0.0217	-0.0002	-0.0044	0.0045	-0.0023	-0.0005	-0.0007	-0.0069	0.0015
<b>mse</b>	0.0013	0.0004	0.0006	0.0006	0.0004	0.0006	0.0005	0.0004	0.0006
<b>var</b>	0.0008	0.0004	0.0006	0.0005	0.0004	0.0006	0.0005	0.0004	0.0006
	$s = 6$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$
<b>mean</b>	0.2201	0.1997	-0.5037	0.2030	0.1982	-0.4989	0.1985	0.1916	-0.4986
<b>bias</b>	0.0201	-0.0003	-0.0037	0.0030	-0.0018	0.0011	-0.0015	-0.0084	0.0014
<b>mse</b>	0.0011	0.0005	0.0006	0.0005	0.0004	0.0006	0.0005	0.0004	0.0006
<b>var</b>	0.0007	0.0005	0.0006	0.0005	0.0003	0.0006	0.0005	0.0003	0.0006
	$s = 12$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$
<b>mean</b>	0.2208	0.1964	-0.5048	0.2024	0.1982	-0.4986	0.1983	0.1825	-0.4974
<b>bias</b>	0.0208	-0.0036	-0.0048	0.0024	-0.0018	0.0014	-0.0017	-0.0175	0.0026
<b>mse</b>	0.0012	0.0005	0.0006	0.0005	0.0003	0.0006	0.0005	0.0007	0.0005
<b>var</b>	0.0008	0.0005	0.0006	0.0005	0.0003	0.0006	0.0005	0.0004	0.0005

$N = 500$ , o estimador FTmod tem menor vício que os demais.

Diversos outros casos foram considerados nas simulações, mas, por questões de espaço, as tabelas apresentando os resultados encontram-se no Apêndice A. Analisando todas as tabelas de uma forma geral, vemos que quando  $N$  assume valores maiores, os estimadores se equiparam, no entanto, quando  $N$  é menor ( $N = 500$ , por exemplo), os estimadores novos propostos (FTmod e FTS), geralmente, apresentam menor vício, nos casos analisados.

## 4.2 Resultados para Processos com Inovações $\alpha$ -estáveis

Nesta seção, iremos apresentar resultados para a estimação semiparamétrica e paramétrica nos processos SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$   $\alpha$ -estáveis.

**Tabela 4.17:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$ , quando  $q = 1$ ,  $p = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\theta_1 = 0.5$  e  $N = 500$ .

	$s = 4$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\theta_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\theta_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\theta_1 = 0.5$
<b>mean</b>	0.2918	0.1847	0.5563	0.2345	0.1863	0.5194	0.1647	0.1798	0.4589
<b>bias</b>	0.0918	-0.0153	0.0563	0.0345	-0.0137	0.0194	-0.0353	-0.0202	-0.0411
<b>mse</b>	0.0244	0.0023	0.0171	0.0140	0.0020	0.0142	0.0112	0.0022	0.0122
<b>var</b>	0.0160	0.0021	0.0139	0.0129	0.0018	0.0138	0.0100	0.0018	0.0105
	$s = 6$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\theta_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\theta_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\theta_1 = 0.5$
<b>mean</b>	0.2947	0.1776	0.5625	0.2351	0.1874	0.5206	0.1684	0.1645	0.4617
<b>bias</b>	0.0947	-0.0224	0.0625	0.0351	-0.0126	0.0206	-0.0316	-0.0355	-0.0383
<b>mse</b>	0.0247	0.0025	0.0186	0.0146	0.0019	0.0164	0.0113	0.0029	0.0127
<b>var</b>	0.0158	0.0020	0.0147	0.0134	0.0017	0.0160	0.0103	0.0016	0.0112
	$s = 12$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\theta_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\theta_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\theta_1 = 0.5$
<b>mean</b>	0.3030	0.1567	0.5774	0.2292	0.1868	0.5204	0.1740	0.1298	0.4699
<b>bias</b>	0.1030	-0.0433	0.0774	0.0292	-0.0132	0.0204	-0.0260	-0.0702	-0.0301
<b>mse</b>	0.0272	0.0043	0.0213	0.0127	0.0018	0.0141	0.0109	0.0065	0.0128
<b>var</b>	0.0166	0.0025	0.0153	0.0119	0.0016	0.0137	0.0102	0.0016	0.0119

**Tabela 4.18:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$ , quando  $q = 1$ ,  $p = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\theta_1 = 0.5$  e  $N = 1000$ .

	$s = 4$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\theta_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\theta_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\theta_1 = 0.5$
<b>mean</b>	0.2904	0.1908	0.5697	0.2266	0.1926	0.5185	0.1721	0.1913	0.4678
<b>bias</b>	0.0904	-0.0092	0.0697	0.0266	-0.0074	0.0185	-0.0279	-0.0087	-0.0322
<b>mse</b>	0.0194	0.0010	0.0152	0.0084	0.0009	0.0091	0.0070	0.0009	0.0079
<b>var</b>	0.0113	0.0009	0.0103	0.0077	0.0009	0.0088	0.0062	0.0008	0.0069
	$s = 6$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\theta_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\theta_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\theta_1 = 0.5$
<b>mean</b>	0.2898	0.1886	0.5698	0.2299	0.1931	0.5239	0.1832	0.1844	0.4804
<b>bias</b>	0.0898	-0.0114	0.0698	0.0299	-0.0069	0.0239	-0.0168	-0.0156	-0.0196
<b>mse</b>	0.0200	0.0011	0.0161	0.0095	0.0008	0.0099	0.0072	0.0010	0.0078
<b>var</b>	0.0120	0.0009	0.0113	0.0086	0.0008	0.0093	0.0069	0.0008	0.0075
	$s = 12$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\theta_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\theta_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\theta_1 = 0.5$
<b>mean</b>	0.2842	0.1808	0.5673	0.2190	0.1926	0.5133	0.1852	0.1656	0.4829
<b>bias</b>	0.0842	-0.0192	0.0673	0.0190	-0.0074	0.0133	-0.0148	-0.0344	-0.0171
<b>mse</b>	0.0182	0.0013	0.0148	0.0077	0.0008	0.0091	0.0068	0.0020	0.0076
<b>var</b>	0.0111	0.0009	0.0102	0.0073	0.0008	0.0090	0.0066	0.0008	0.0073

**Tabela 4.19:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$ , quando  $q = 1$ ,  $p = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\theta_1 = 0.5$  e  $N = 2000$ .

	$s = 4$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\theta_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\theta_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\theta_1 = 0.5$
<b>mean</b>	0.2738	0.1950	0.5617	0.2152	0.1966	0.5131	0.1830	0.1979	0.4794
<b>bias</b>	0.0738	-0.0050	0.0617	0.0152	-0.0034	0.0131	-0.0170	-0.0021	-0.0206
<b>mse</b>	0.0125	0.0004	0.0106	0.0043	0.0005	0.0047	0.0041	0.0004	0.0047
<b>var</b>	0.0071	0.0004	0.0068	0.0041	0.0005	0.0045	0.0039	0.0004	0.0042
	$s = 6$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\theta_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\theta_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\theta_1 = 0.5$
<b>mean</b>	0.2763	0.1915	0.5661	0.2170	0.1953	0.5146	0.1886	0.1931	0.4851
<b>bias</b>	0.0763	-0.0085	0.0661	0.0170	-0.0047	0.0146	-0.0114	-0.0069	-0.0149
<b>mse</b>	0.0129	0.0005	0.0111	0.0042	0.0004	0.0047	0.0039	0.0004	0.0043
<b>var</b>	0.0071	0.0004	0.0068	0.0039	0.0004	0.0044	0.0037	0.0004	0.0040
	$s = 12$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\theta_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\theta_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\theta_1 = 0.5$
<b>mean</b>	0.2711	0.1922	0.5603	0.2143	0.1958	0.5126	0.1922	0.1839	0.4909
<b>bias</b>	0.0711	-0.0078	0.0603	0.0143	-0.0042	0.0126	-0.0078	-0.0161	-0.0091
<b>mse</b>	0.0114	0.0005	0.0099	0.0038	0.0004	0.0046	0.0032	0.0006	0.0037
<b>var</b>	0.0064	0.0004	0.0062	0.0036	0.0004	0.0044	0.0031	0.0004	0.0037

## Resultados da Estimação Semiparamétrica

Apresentamos resultados obtidos de simulações para os estimadores semiparamétricos definidos nas Seções 3.1.2 e 3.1.3 para processos com inovações  $\alpha$ -estáveis. Além da metodologia dos mínimos quadrados, denotada por MQ, utilizamos as metodologias robustas MM e MQP, abordadas na Seção 3.1.1. Diversos casos foram considerados nas simulações, mas, por questão de espaço, apresentaremos apenas casos selecionados.

As Tabelas 4.20 à 4.25 referem-se aos processos SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$   $\alpha$ -estáveis, nos casos  $p = q = 0 = P = Q$ ,  $d = D = 0.2$ ,  $\alpha = 1.25$ ,  $s \in \{4, 6, 12\}$ ,  $N \in \{500, 1000, 2000\}$  e  $\kappa \in \{0.70; 0.85\}$ . No Apêndice B apresentamos os resultados da estimação nos processos SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$ , nos casos  $p = q = 0 = P = Q$ ,  $d = D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $N \in \{500, 1000, 2000\}$ , com o  $\kappa$  máximo relativo a cada diferente valor de  $N$ . Não apresentamos no corpo do texto este caso, pois não teríamos como compará-los entre si. Note que, os métodos de estimação apresentados, melhoraram as estimativas quando  $\kappa$  aumenta.

Analisando as Tabelas 4.20 e 4.21 e Figuras 4.5 à 4.7, quando  $N = 500$ , podemos notar que, ao aumentarmos o valor de  $\kappa$ , em geral, o vício dos estimadores diminui.

Ao observar as Tabelas 4.22 e 4.23, notamos que o mesmo ocorre quando  $N = 1000$ . Apenas quando  $N = 2000$  (Tabelas 4.24 e 4.25), que não notamos essa melhora com o aumento de  $\kappa$ . Outro aspecto que notamos ao analisar estas tabelas, é que ao aumentarmos o valor de  $N$ , o valor do erro quadrático médio diminui. Note também que, pelas figuras e tabelas, os estimadores de  $d = 0.2$ , que utilizam o periodograma suavizado de covariâncias (denotados por BA), possuem menor vício. Entretanto, dentre as metodologias utilizadas para o estimador BA (MQ, MM e MQP), nenhuma se sobressai, sendo variados os resultados encontrados. Para estimar  $D = 0.2$ , o estimador GPH, com a metodologia robusta MM, apresentou menor vício no caso  $\kappa = 0.85$ ,  $s \in \{4, 6, 12\}$ .

As Tabelas 4.22 e 4.23 referentes ao caso  $N = 1000$  mostram que os estimadores de  $d = 0.2$ , que se sobressaem, são BA MQP e BA MM, possuindo menor vício. Para estimar  $D = 0.2$ , destacam-se os estimadores GPH MM e BA MQ.

As Tabelas 4.24 e 4.25 referentes ao caso  $N = 2000$  evidenciam que os estimadores de  $d = 0.2$ , que se sobressaem, possuindo menor vício, são os que utilizam o periodograma normalizado suavizado de correlações (BA), independente da metodologia. Para estimar  $D = 0.2$ , destaca-se o estimador GPH MM.

A Tabela 4.26 refere-se ao processo SARFIMA( $p, d, q) \times (P, D, Q)_s$ , no caso  $p = 1$ ,  $q = 0 = P = Q$ ,  $d = D = 0.2$ ,  $\phi_1 = 0.5$ ,  $\alpha = 1.25$ ,  $s \in \{4, 6, 12\}$ ,  $N = 1000$  e  $\kappa = 0.85$ . Note que, a estimação do parâmetro  $d = 0.2$  ficou péssima, indiferente do tipo de estimador considerado. Entretanto, a estimação  $D = 0.2$  não ficou tão ruim, mas buscamos um estimador que estime bem todos os parâmetros. No Apêndice B apresentamos resultados semelhantes para o processo SARFIMA( $p, d, q) \times (P, D, Q)_s$ , no caso  $p = 1$ ,  $p = 0 = P = Q$ ,  $d = D = 0.2$ ,  $\phi_1 = 0.5$ ,  $s \in \{4, 6, 12\}$ ,  $N \in \{500, 2000\}$  e  $\kappa = 0.85$ . Tal fato, nos leva a descartar a utilização dos estimadores semi-paramétricos descritos neste trabalho, quando temos processos SARFIMA( $p, d, q) \times (P, D, Q)_s$ , com  $p \neq 0$  ou  $q \neq 0$  ou  $P \neq 0$  ou  $Q \neq 0$ .

Note que, em todos os casos considerados, o estimador GPH, independente da metodologia utilizada, superestima o verdadeiro valor de  $d$ .

**Tabela 4.20:** Resultado da estimação semi-paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$   $\alpha$ -estável, quando  $p = q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\alpha = 1.25$ ,  $\kappa = 0.70$  e  $N = 500$ .

		$\kappa = 0.70$				$\kappa = 0.70$			
		$s = 4$				$s = 6$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MQ</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2695	0.2783	0.2469	0.2250	0.2471	0.2276	0.1888	0.2418	0.1977
bias	0.0695	0.0783	0.0469	0.0250	0.0471	0.0276	-0.0112	0.0418	0.0453
mse	0.0097	0.0193	0.0071	0.0131	0.0067	0.0120	0.0029	0.0131	0.0084
var	0.0049	0.0132	0.0049	0.0125	0.0045	0.0113	0.0028	0.0114	0.0084
<hr/>									
		$\kappa = 0.70$				$\kappa = 0.70$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2741	0.2981	0.2451	0.2698	0.2452	0.2628	0.1856	0.2452	0.1969
bias	0.0741	0.0981	0.0451	0.0698	0.0452	0.0628	-0.0144	0.0452	0.0452
mse	0.0106	0.0356	0.0085	0.0275	0.0075	0.0252	0.0035	0.0195	0.0062
var	0.0052	0.0260	0.0065	0.0227	0.0055	0.0213	0.0033	0.0175	0.0062
<hr/>									
		$\kappa = 0.70$				$\kappa = 0.70$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2804	0.3255	0.2451	0.3028	0.2437	0.2951	0.1760	0.2609	0.1915
bias	0.0804	0.1255	0.0451	0.1028	0.0437	0.0951	-0.0240	0.0609	-0.0085
mse	0.0137	0.0573	0.0102	0.0517	0.0090	0.0460	0.0043	0.0271	0.0050
var	0.0073	0.0416	0.0082	0.0412	0.0071	0.0370	0.0037	0.0234	0.0049

**Tabela 4.21:** Resultado da estimação semi-paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$   $\alpha$ -estável, quando  $p = q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\alpha = 1.25$ ,  $\kappa = 0.85$  e  $N = 500$ .

		$\kappa = 0.85$				$\kappa = 0.85$			
		$s = 4$				$s = 6$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MQ</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2536	0.2378	0.2277	0.2015	0.2348	0.2119	0.1929	0.2282	0.1992
bias	0.0536	0.0378	0.0277	0.0015	0.0348	0.0119	-0.0071	0.0282	-0.0008
mse	0.0063	0.0057	0.0058	0.0050	0.0043	0.0035	0.0020	0.0060	0.0024
var	0.0034	0.0043	0.0050	0.0050	0.0031	0.0033	0.0020	0.0052	0.0024
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2518	0.2622	0.2246	0.2290	0.2324	0.2399	0.1919	0.2388	0.1971
bias	0.0518	0.0622	0.0246	0.0290	0.0324	0.0399	-0.0081	0.0388	-0.0029
mse	0.0060	0.0158	0.0055	0.0129	0.0045	0.0111	0.0024	0.0124	0.0030
var	0.0033	0.0120	0.0049	0.0121	0.0035	0.0096	0.0023	0.0109	0.0030
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2493	0.2856	0.2207	0.2444	0.2978	0.2600	0.1870	0.2544	0.1954
bias	0.0493	0.0856	0.0207	0.0444	0.0278	0.0600	-0.0130	0.0544	-0.0046
mse	0.0057	0.0264	0.0054	0.0180	0.0037	0.0177	0.0022	0.0185	0.0021
var	0.0033	0.0191	0.0050	0.0160	0.0030	0.0141	0.0020	0.0156	0.0021

**Tabela 4.22:** Resultado da estimação semi-paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estável, quando  $p = q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\alpha = 1.25$ ,  $\kappa = 0.70$  e  $N = 1000$ .

		$\kappa = 0.70$					
		$s = 4$					
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2442	0.2496	0.2255	0.2134	0.2287	0.2200	0.1955
bias	0.0442	0.0496	0.0255	0.0134	0.0287	0.0200	-0.0045
mse	0.0045	0.0098	0.0037	0.0073	0.0031	0.0062	0.0013
var	0.0025	0.0073	0.0030	0.0071	0.0023	0.0059	0.0013
		$s = 6$				<b>GPH MQ</b>	
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2480	0.2695	0.2291	0.2396	0.2323	0.2461	0.1941
bias	0.0480	0.0695	0.0291	0.0396	0.0323	0.0461	-0.0059
mse	0.0056	0.0212	0.0055	0.0171	0.0044	0.0149	0.0022
var	0.0033	0.0163	0.0046	0.0155	0.0034	0.0127	0.0021
		$s = 12$				<b>GPH MQ</b>	
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2538	0.2891	0.2294	0.2600	0.2360	0.2687	0.1910
bias	0.0538	0.0891	0.0294	0.0600	0.0360	0.0687	-0.0090
mse	0.0065	0.0280	0.0052	0.0240	0.0045	0.0224	0.0018
var	0.0037	0.0201	0.0043	0.0204	0.0033	0.0177	0.0017

		$\kappa = 0.70$					
		$s = 12$					
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2538	0.2891	0.2294	0.2600	0.2360	0.2687	0.1910
bias	0.0538	0.0891	0.0294	0.0600	0.0360	0.0687	-0.0090
mse	0.0065	0.0280	0.0052	0.0240	0.0045	0.0224	0.0018
var	0.0037	0.0201	0.0043	0.0204	0.0033	0.0177	0.0017

**Tabela 4.23:** Resultado da estimação semi-paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$   $\alpha$ -estável, quando  $p = q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\alpha = 1.25$ ,  $\kappa = 0.85$  e  $N = 1000$ .

		$\kappa = 0.85$				$\kappa = 0.85$			
		$s = 4$				$s = 6$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MQ</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2330	0.2235	0.2182	0.2030	0.2214	0.2117	0.1979	0.2193	0.2004
bias	0.0330	0.0235	0.0182	0.0030	0.0214	0.0117	-0.0021	0.0193	0.0004
mse	0.0028	0.0030	0.0027	0.0034	0.0023	0.0021	0.0009	0.0040	0.0014
var	0.0017	0.0025	0.0023	0.0034	0.0018	0.0020	0.0009	0.0036	0.0014
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2335	0.2372	0.2176	0.2147	0.2226	0.2237	0.1981	0.2263	0.2014
bias	0.0335	0.0372	0.0176	0.0147	0.0226	0.0237	-0.0019	0.0263	0.0014
mse	0.0034	0.0076	0.0038	0.0063	0.0029	0.0054	0.0016	0.0070	0.0032
var	0.0023	0.0062	0.0035	0.0061	0.0024	0.0048	0.0016	0.0064	0.0032
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2326	0.2527	0.2182	0.2239	0.2222	0.2369	0.1972	0.2357	0.2005
bias	0.0326	0.0527	0.0182	0.0239	0.0222	0.0369	-0.0028	0.0357	0.0005
mse	0.0029	0.0110	0.0028	0.0076	0.0021	0.0076	0.0009	0.0088	0.0011
var	0.0018	0.0082	0.0025	0.0070	0.0016	0.0062	0.0009	0.0076	0.0011

**Tabela 4.24:** Resultado da estimativa semi-paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estável, quando  $p = q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\alpha = 1.25$ ,  $\kappa = 0.70$  e  $N = 2000$ .

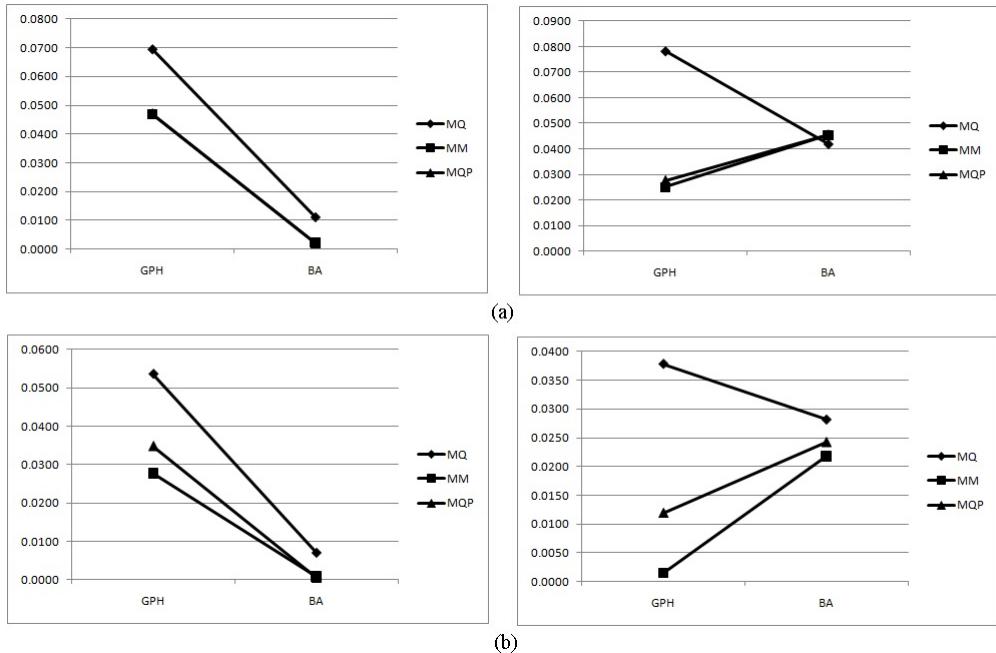
$\kappa = 0.70$										
$\kappa = 0.70$										
$s = 4$										
	<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>BA MQ</b>		<b>BA MM</b>	
	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2269	0.2327	0.2153	0.2126	0.2206	0.2183	0.2001	0.2230	0.2025	0.2215
bias	0.0269	0.0327	0.0153	0.0126	0.0206	0.0183	0.0001	0.0230	0.0025	0.0215
mse	0.0020	0.0055	0.0020	0.0056	0.0016	0.0037	0.0006	0.0054	0.0009	0.0061
var	0.0013	0.0045	0.0018	0.0055	0.0012	0.0034	0.0006	0.0048	0.0009	0.0057
$s = 6$										
	<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>BA MQ</b>		<b>BA MM</b>	
	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2286	0.2397	0.2158	0.2125	0.2222	0.2248	0.1989	0.2202	0.2005	0.2213
bias	0.0286	0.0397	0.0158	0.0125	0.0222	0.0248	-0.0011	0.0202	0.0005	0.0213
mse	0.0024	0.0093	0.0058	0.0080	0.0021	0.0065	0.0008	0.0073	0.0064	0.0077
var	0.0016	0.0078	0.0056	0.0079	0.0016	0.0059	0.0008	0.0069	0.0064	0.0073
$s = 12$										
	<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>BA MQ</b>		<b>BA MM</b>	
	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2370	0.2689	0.2192	0.2385	0.2269	0.2524	0.1967	0.2416	0.1998	0.2445
bias	0.0370	0.0689	0.0192	0.0385	0.0269	0.0524	-0.0033	0.0416	-0.0002	0.0445
mse	0.0035	0.0197	0.0035	0.0134	0.0028	0.0138	0.0012	0.0144	0.0022	0.0167
var	0.0022	0.0150	0.0032	0.0120	0.0021	0.0111	0.0011	0.0127	0.0022	0.0147

**Tabela 4.25:** Resultado da estimativa semi-paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$   $\alpha$ -estável, quando  $p = q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\alpha = 1.25$ ,  $\kappa = 0.85$  e  $N = 2000$ .

$\kappa = 0.85$									
$s = 4$									
	GPH MQ		GPH MM		GPH MQP		BA MQ		BA MM
	$d = 0.2$								
mean	0.2190	0.2150	0.2106	0.2054	0.2148	0.2083	0.2008	0.2142	0.2014
bias	0.0190	0.0150	0.0106	0.0054	0.0148	0.0083	0.0008	0.0142	0.014
mse	0.0012	0.0015	0.0014	0.0017	0.0011	0.0012	0.0004	0.0021	0.0006
var	0.0009	0.0013	0.0013	0.0017	0.0008	0.0012	0.0004	0.0019	0.0006
$s = 6$									
	GPH MQ		GPH MM		GPH MQP		BA MQ		BA MM
	$d = 0.2$								
mean	0.2195	0.2199	0.2139	0.2074	0.2155	0.2142	0.2012	0.2143	0.2027
bias	0.0195	0.0199	0.0139	0.0074	0.0155	0.0142	0.0012	0.0143	0.0027
mse	0.0015	0.0036	0.0017	0.0029	0.0014	0.0027	0.0006	0.0035	0.0009
var	0.0011	0.0032	0.0015	0.0029	0.0012	0.0025	0.0006	0.0033	0.0009
$s = 12$									
	GPH MQ		GPH MM		GPH MQP		BA MQ		BA MM
	$d = 0.2$								
mean	0.2214	0.2375	0.2127	0.2186	0.2156	0.2269	0.1997	0.2299	0.2017
bias	0.0214	0.0375	0.0127	0.0186	0.0156	0.0269	-0.0003	0.0299	0.0117
mse	0.0015	0.0074	0.0017	0.0052	0.0014	0.0055	0.0007	0.0079	0.0009
var	0.0011	0.0060	0.0016	0.0048	0.0011	0.0047	0.0007	0.0070	0.0009

**Tabela 4.26:** Resultado da estimação semi-paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estável, quando  $p = 1$ ,  $q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $\phi_1 = 0.5$ ,  $s \in \{4, 6, 12\}$ ,  $\alpha = 1.25$ ,  $\kappa = 0.85$  e  $N = 1000$ .

		$\kappa = 0.85$				$\kappa = 0.85$			
		$s = 4$				$s = 6$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MQ</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.5924	0.1410	0.6309	0.1397	0.6168	0.1407	0.5549	0.1396	0.6945
bias	0.3924	-0.0590	0.4309	-0.0603	0.4168	-0.0593	0.3549	-0.0604	0.4945
mse	0.1563	0.0058	0.1939	0.0082	0.1771	0.0060	0.1273	0.0082	0.2620
var	0.0023	0.0023	0.0082	0.0046	0.0033	0.0024	0.0013	0.0046	0.0175
		$\kappa = 0.85$				$\kappa = 0.85$			
		$s = 12$				$s = 12$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.5744	0.1824	0.6293	0.1749	0.6036	0.1822	0.5389	0.1711	0.7187
bias	0.3744	-0.0176	0.4293	-0.0251	0.4036	-0.0178	0.3389	-0.0289	0.5187
mse	0.1419	0.0058	0.1969	0.0067	0.1669	0.0046	0.1160	0.0065	0.2914
var	0.0017	0.0055	0.0126	0.0061	0.0040	0.0043	0.0011	0.0057	0.0224

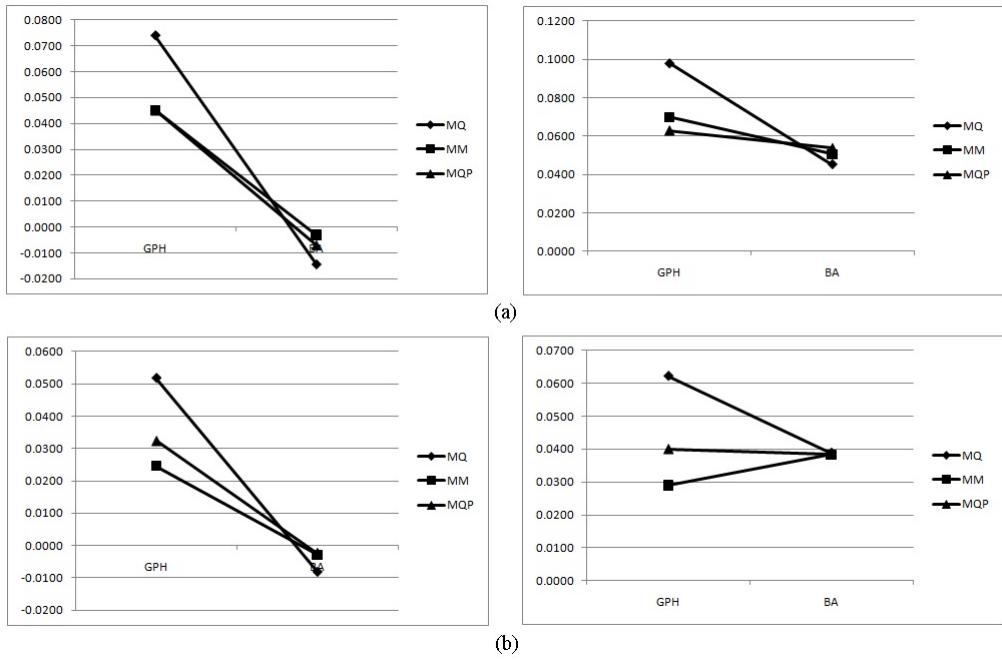


**Figura 4.5:** Módulo do vício dos estimadores semiparamétricos para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estável, com  $p = q = 0 = P = Q$ ,  $\alpha = 1.25$ ,  $N = 500$  e  $s = 4$ , considerando os métodos clássico (MQ) e robustos (MM e MQP). Os gráficos à esquerda são para  $d = 0.2$  e os da direita para  $D = 0.2$ : (a)  $\kappa = 0.70$  e (b)  $\kappa = 0.85$ .

## Resultados da Estimação Paramétrica

Apresentamos os resultados da estimação paramétrica, utilizando alguns dos estimadores definidos na Seção 3.2, para processos SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estáveis, com diversos valores de parâmetros. Escolhemos alguns casos para apresentar neste momento, muitos outros foram considerados e as tabelas apresentando os resultados encontram-se no Apêndice B. Iremos considerar, nas simulações, os estimadores paramétricos definidos nas Seções 3.2.5, 3.2.6, 3.2.7 e 3.2.8, denotados por KM, KMmod, KMS e KMSmod, respectivamente. Para o estimador KMmod, no qual aproximamos a integral dada em (3.69) por uma soma em mais coeficientes, além dos de Fourier, precisamos definir o valor de  $c$ , na equação (3.70), consideraremos o mesmo que utilizamos no estimador análogo para processos normais,  $c = 5$ . Além disso, no estimador KMS, iremos utilizar a janela de Bartlett na suavização do periodograma, dada na equação (3.20).

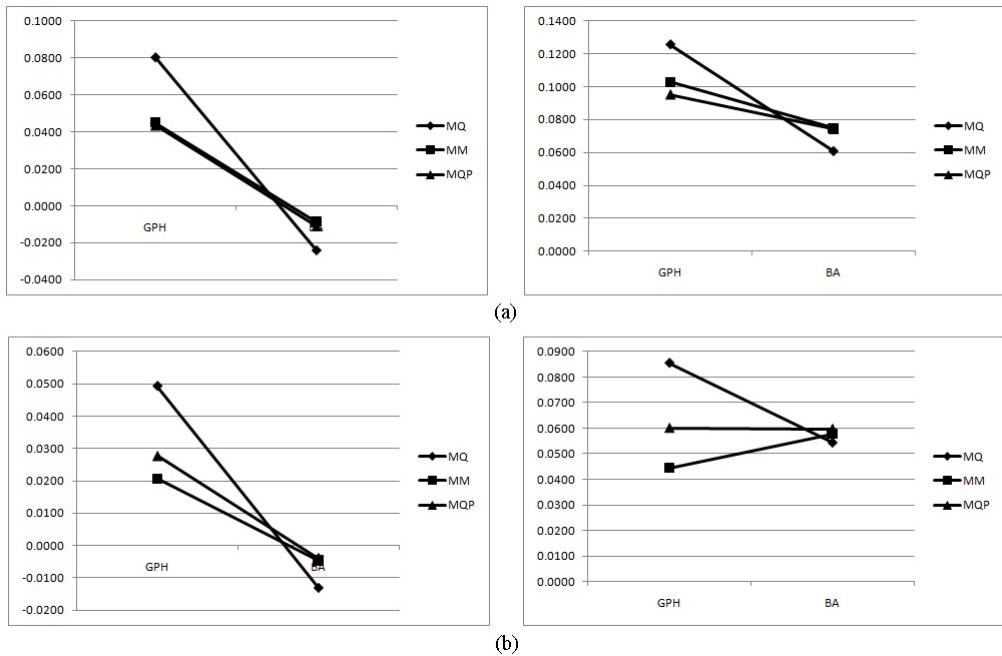
As Tabelas 4.27 à 4.29 e a Figura 4.8 referem-se a processos SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estáveis, com  $p = q = 0 = P = Q$ ,  $d = 0.1$ ,  $D = 0.2$ ,  $\alpha = 1.50$ ,



**Figura 4.6:** Módulo do vício dos estimadores semiparamétricos para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estável, com  $p = q = 0 = P = Q$ ,  $\alpha = 1.25$ ,  $N = 500$  e  $s = 6$ , considerando os métodos clássico (MQ) e robustos (MM e MQP). Os gráficos à esquerda são para  $d = 0.2$  e os da direita para  $D = 0.2$ : (a)  $\kappa = 0.70$  e (b)  $\kappa = 0.85$ .

$s \in \{4, 6, 12\}$  e  $N \in \{500, 1000, 2000\}$ . Note que, com estes valores de parâmetros, pelo Teorema 2.7, temos um processo com longa dependência, causal e inversível. Analisando as tabelas, notamos que, para estimar  $d = 0.1$ , o estimador que apresentou uma sensível melhora foi o KMS, tendo menos vício quando  $s = 4$  e  $N \in \{500, 1000, 2000\}$ ,  $s = 6$  e  $N = 500$ ,  $s = 12$  e  $N \in \{1000, 2000\}$ , além de apresentar erro quadrático médio e variância mínimos na maioria dos casos. Outro aspecto que observamos, ao estimar  $d = 0.1$ , é que ao aumentarmos o tamanho amostral  $N$ , aprimoramos a estimação, diminuindo o vício. Ao estimar  $D = 0.2$ , vemos que o estimador KMS não é tão eficiente, não apresentou menor vício em nenhum dos casos, mas nenhum outro estimador se sobressaiu.

As Tabelas 4.30 à 4.32 e a Figura 4.9 referem-se a processos SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estáveis, com  $p = q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $\alpha = 1.25$ ,  $s \in \{4, 6, 12\}$  e  $N \in \{500, 1000, 2000\}$ . Note que, com estes valores de parâmetros, pelo Teorema 2.7, não temos longa dependência, causalidade ou inversibilidade, mesmo assim, observamos que os novos estimadores propostos neste trabalho (KMmod, KMS, KMSmos) foram bastante eficientes, no sentido de terem menor vício em



**Figura 4.7:** Módulo do vício dos estimadores semiparamétricos para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estável, com  $p = q = 0 = P = Q$ ,  $\alpha = 1.25$ ,  $N = 500$  e  $s = 12$ , considerando os métodos clássico (MQ) e robustos (MM e MQP). Os gráficos à esquerda são para  $d = 0.2$  e os da direita para  $D = 0.2$ : (a)  $\kappa = 0.70$  e (b)  $\kappa = 0.85$ .

todos os casos analisados. Ao analisar as tabelas, vemos que, para estimar  $d = 0.2$ , o estimador que apresentou uma sensível melhora foi o KMS, tendo menor vício, erro quadrático médio e variância quando  $N \in \{500, 2000\}$  em todos valores de  $s$  considerados. Ao estimar  $D = 0.2$ , vemos que os estimadores que apresentaram melhor eficiência foram o KMS e KMSmod. O estimador KMS apresentou menor vício, erro quadrático médio e variância quando  $N = 1000$  e  $s \in \{4, 6\}$ , também quando  $N = 2000$  e  $s \in \{4, 6\}$ , nos demais casos, o estimador KMSmod apresentou menor vício.

As Tabelas 4.33 à 4.35 apresentam resultados referentes a processos SARFIMA ( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estáveis, com  $p = 1$ ,  $q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $\phi_1 = 0.5$ ,  $\alpha = 1.25$ ,  $s \in \{4, 6, 12\}$  e  $N \in \{500, 1000, 2000\}$ . Note que, com estes valores de parâmetros, pelo Teorema 2.7, não temos longa dependência, causalidade ou inversibilidade, mesmo assim, observamos que os novos estimadores propostos neste trabalho (KMmod, KMS, KMSmos) foram bastante eficientes, no sentido de terem menor vício na maior parte dos casos analisados. Observando as tabelas, vemos que, para estimar  $d = 0.2$  e  $\phi_1 = 0.5$ , o estimador que apresentou uma sensível

**Tabela 4.27:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$   $\alpha$ -estável, quando  $p = q = 0 = P = Q$ ,  $d = 0.1$ ,  $D = 0.2$ ,  $\alpha = 1.50$ ,  $s \in \{4, 6, 12\}$  e  $N = 500$ .

		$\alpha = 1.50$							
		$s = 4$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.1$	$D = 0.2$	$d = 0.1$	$D = 0.2$	$d = 0.1$	$D = 0.2$	$d = 0.1$	$D = 0.2$
<b>mean</b>		0.1356	0.1994	0.1102	0.1972	0.0913	0.1805	0.0902	0.1831
<b>bias</b>		0.0356	-0.0006	0.0102	-0.0028	-0.0087	-0.0195	-0.0098	-0.0169
<b>mse</b>		0.0033	0.0025	0.0013	0.0020	0.0010	0.0022	0.0011	0.0020
<b>var</b>		0.0020	0.0025	0.0012	0.0019	0.0010	0.0018	0.0010	0.0017
		$\alpha = 1.50$							
		$s = 6$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.1$	$D = 0.2$	$d = 0.1$	$D = 0.2$	$d = 0.1$	$D = 0.2$	$d = 0.1$	$D = 0.2$
<b>mean</b>		0.1355	0.1985	0.1097	0.2016	0.0915	0.1743	0.0885	0.1807
<b>bias</b>		0.0355	-0.0015	0.0097	0.0016	-0.0085	-0.0257	-0.0115	-0.0193
<b>mse</b>		0.0033	0.0030	0.0013	0.0022	0.0011	0.0029	0.0012	0.0026
<b>var</b>		0.0021	0.0030	0.0012	0.0022	0.0011	0.0023	0.0011	0.0022
		$\alpha = 1.50$							
		$s = 12$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.1$	$D = 0.2$	$d = 0.1$	$D = 0.2$	$d = 0.1$	$D = 0.2$	$d = 0.1$	$D = 0.2$
<b>mean</b>		0.1345	0.1846	0.1081	0.2068	0.0896	0.1465	0.0860	0.1629
<b>bias</b>		0.0345	-0.0154	0.0081	0.0068	-0.0104	-0.0535	-0.0140	-0.0371
<b>mse</b>		0.0034	0.0043	0.0013	0.0029	0.0012	0.0061	0.0013	0.0038
<b>var</b>		0.0022	0.0041	0.0012	0.0028	0.0011	0.0032	0.0011	0.0024

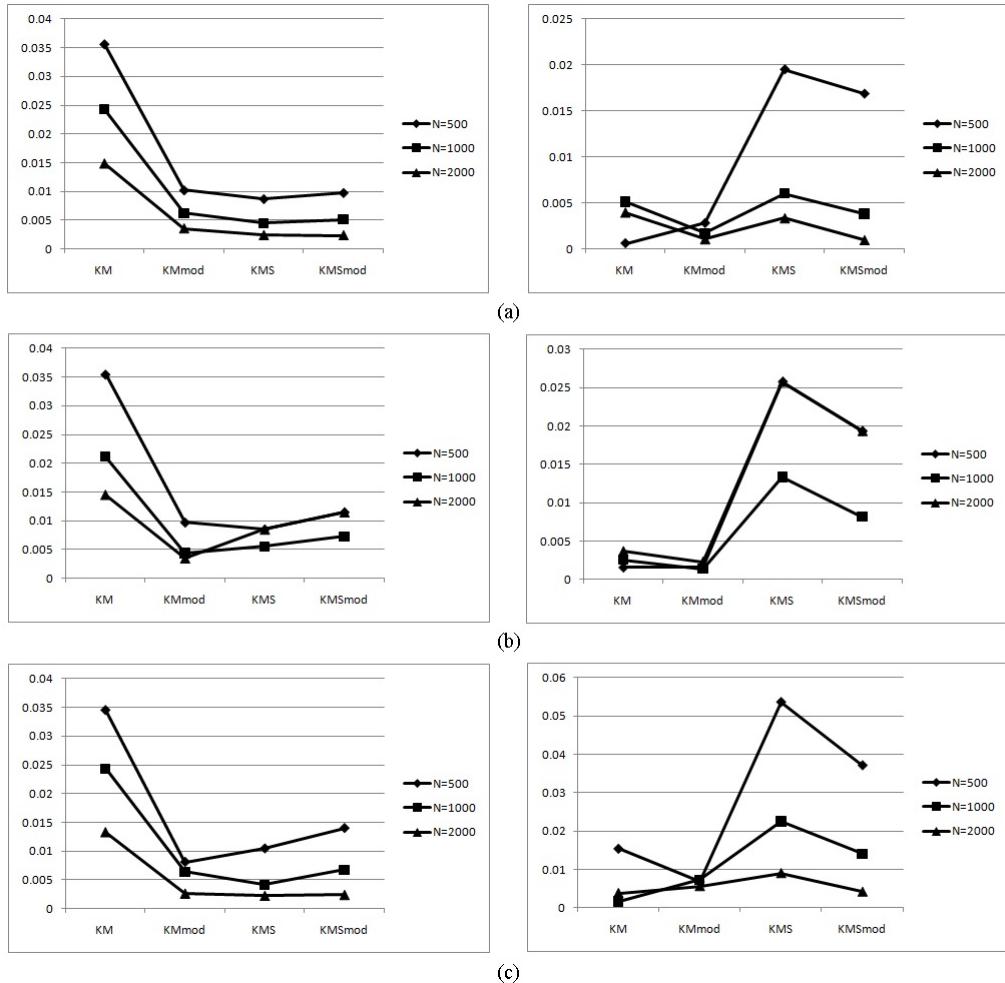
melhora foi o KMS, tendo menor vício em todos os casos de  $N$  e  $s$  apresentados pelas tabelas. Ao estimar  $D = 0.2$ , todos os estimadores considerados apresentaram menor vício em pelo menos um caso analisado.

**Tabela 4.28:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$   $\alpha$ -estável, quando  $p = q = 0 = P = Q$ ,  $d = 0.1$ ,  $D = 0.2$ ,  $\alpha = 1.50$ ,  $s \in \{4, 6, 12\}$  e  $N = 1000$ .

		$\alpha = 1.50$							
		$s = 4$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.1$	$D = 0.2$	$d = 0.1$	$D = 0.2$	$d = 0.1$	$D = 0.2$	$d = 0.1$	$D = 0.2$
<b>mean</b>		0.1243	0.2051	0.1063	0.2017	0.0955	0.1940	0.0949	0.1962
<b>bias</b>		0.0243	0.0051	0.0063	0.0017	-0.0045	-0.0060	-0.0051	-0.0038
<b>mse</b>		0.0015	0.0014	0.0006	0.0010	0.0006	0.0010	0.0006	0.0012
<b>var</b>		0.0009	0.0014	0.0005	0.0010	0.0005	0.0010	0.0006	0.0012
		$\alpha = 1.50$							
		$s = 6$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.1$	$D = 0.2$	$d = 0.1$	$D = 0.2$	$d = 0.1$	$D = 0.2$	$d = 0.1$	$D = 0.2$
<b>mean</b>		0.1211	0.2026	0.1044	0.2014	0.0945	0.1867	0.0927	0.1918
<b>bias</b>		0.0211	0.0026	0.0044	0.0014	-0.0055	-0.0133	-0.0073	-0.0082
<b>mse</b>		0.0013	0.0017	0.0005	0.0012	0.0005	0.0013	0.0006	0.0015
<b>var</b>		0.0009	0.0017	0.0005	0.0012	0.0005	0.0011	0.0005	0.0015
		$\alpha = 1.50$							
		$s = 12$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.1$	$D = 0.2$	$d = 0.1$	$D = 0.2$	$d = 0.1$	$D = 0.2$	$d = 0.1$	$D = 0.2$
<b>mean</b>		0.1243	0.2016	0.1064	0.2073	0.0958	0.1775	0.0933	0.1859
<b>bias</b>		0.0243	0.0016	0.0064	0.0073	-0.0042	-0.0225	-0.0067	-0.0141
<b>mse</b>		0.0015	0.0026	0.0006	0.0016	0.0005	0.0022	0.0006	0.0022
<b>var</b>		0.0009	0.0026	0.0005	0.0016	0.0005	0.0017	0.0005	0.0020

**Tabela 4.29:** Resultado da estimativa paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$   $\alpha$ -estável, quando  $p = q = 0 = P = Q$ ,  $d = 0.1$ ,  $D = 0.2$ ,  $\alpha = 1.50$ ,  $s \in \{4, 6, 12\}$  e  $N = 2000$ .

		$\alpha = 1.50$							
		$s = 4$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.1$	$D = 0.2$	$d = 0.1$	$D = 0.2$	$d = 0.1$	$D = 0.2$	$d = 0.1$	$D = 0.2$
<b>mean</b>		0.1149	0.2040	0.1036	0.2011	0.0976	0.1966	0.0976	0.1990
<b>bias</b>		0.0149	0.0040	0.0036	0.0011	-0.0024	-0.0034	-0.0024	-0.0010
<b>mse</b>		0.0007	0.0010	0.0003	0.0007	0.0002	0.0004	0.0003	0.0005
<b>var</b>		0.0005	0.0009	0.0003	0.0007	0.0002	0.0004	0.0002	0.0005
		$\alpha = 1.50$							
		$s = 6$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.1$	$D = 0.2$	$d = 0.1$	$D = 0.2$	$d = 0.1$	$D = 0.2$	$d = 0.1$	$D = 0.2$
<b>mean</b>		0.1145	0.2037	0.1035	0.2023	0.0915	0.1743	0.0885	0.1807
<b>bias</b>		0.0145	0.0037	0.0035	0.0023	-0.0085	-0.0257	-0.0115	-0.0193
<b>mse</b>		0.0007	0.0007	0.0004	0.0006	0.0011	0.0029	0.0012	0.0026
<b>var</b>		0.0005	0.0007	0.0004	0.0006	0.0011	0.0023	0.0011	0.0022
		$\alpha = 1.50$							
		$s = 12$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.1$	$D = 0.2$	$d = 0.1$	$D = 0.2$	$d = 0.1$	$D = 0.2$	$d = 0.1$	$D = 0.2$
<b>mean</b>		0.1133	0.2038	0.1027	0.2056	0.0977	0.1910	0.0975	0.1959
<b>bias</b>		0.0133	0.0038	0.0027	0.0056	-0.0023	-0.0090	-0.0025	-0.0041
<b>mse</b>		0.0006	0.0012	0.0003	0.0009	0.0002	0.0011	0.0002	0.0011
<b>var</b>		0.0004	0.0012	0.0002	0.0009	0.0002	0.0010	0.0002	0.0011



**Figura 4.8:** Módulo do vício dos estimadores paramétricos para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estáveis, com  $p = q = 0 = P = Q$ ,  $\alpha = 1.50$ ,  $N \in \{500, 1000, 2000\}$ . Os gráficos à esquerda são para  $d = 0.1$  e os da direita para  $D = 0.2$ : (a)  $s = 4$ , (b)  $s = 6$  e (c)  $s = 12$ .

**Tabela 4.30:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q) \times (P, D, Q)_s$   $\alpha$ -estável, quando  $p = q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $\alpha = 1.25$ ,  $s \in \{4, 6, 12\}$  e  $N = 500$ .

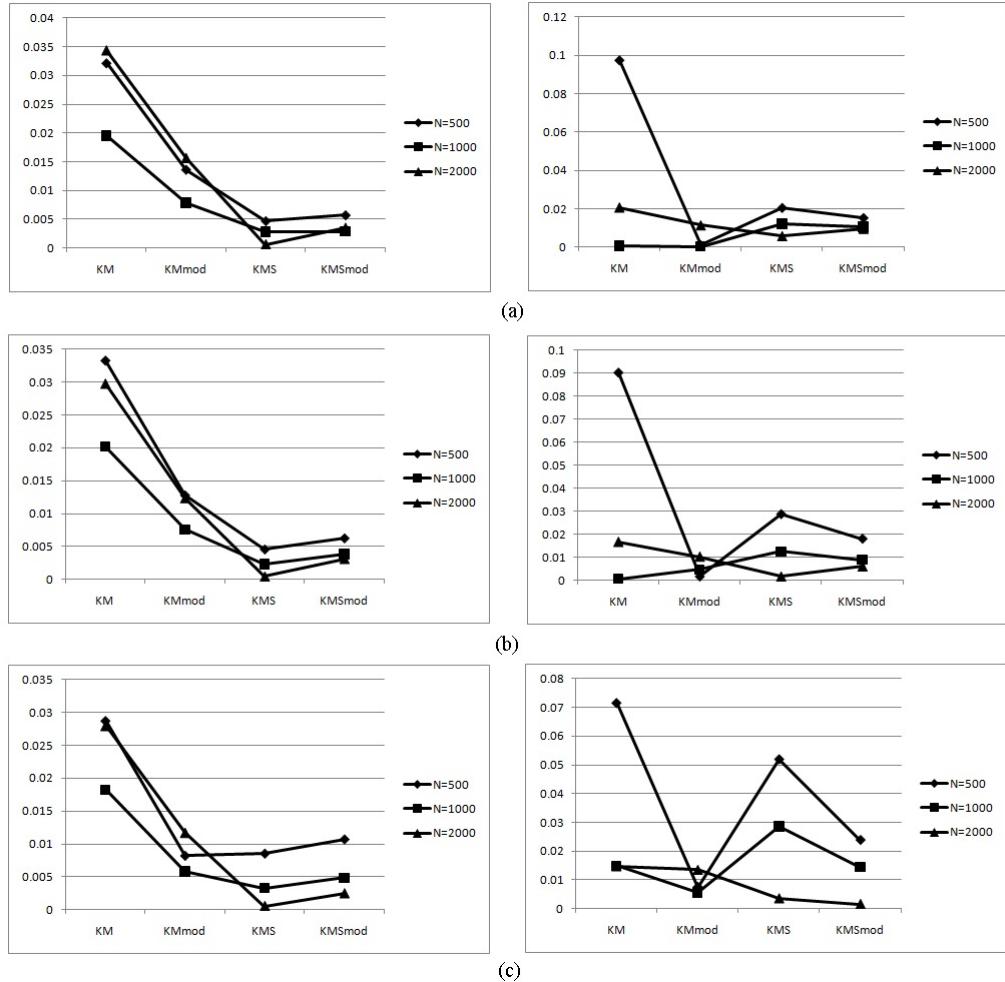
		$\alpha = 1.25$							
		$s = 4$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
<b>mean</b>		0.2829	0.2326	0.2421	0.2175	0.1959	0.1965	0.1955	0.2002
<b>bias</b>		0.0829	0.0326	0.0421	0.0175	-0.0041	-0.0035	-0.0045	0.0002
<b>mse</b>		0.0115	0.0061	0.0053	0.0033	0.0013	0.0033	0.0015	0.0039
<b>var</b>		0.0046	0.0050	0.0036	0.0030	0.0012	0.0033	0.0015	0.0039
		$\alpha = 1.25$							
		$s = 6$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
<b>mean</b>		0.2298	0.2166	0.2387	0.2236	0.1911	0.1927	0.1893	0.1971
<b>bias</b>		0.0298	0.0166	0.0387	0.0236	-0.0089	-0.0073	-0.0107	-0.0029
<b>mse</b>		0.0020	0.0018	0.0052	0.0045	0.0014	0.0047	0.0016	0.0044
<b>var</b>		0.0011	0.0016	0.0037	0.0040	0.0013	0.0047	0.0015	0.0044
		$\alpha = 1.25$							
		$s = 12$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
<b>mean</b>		0.2798	0.2233	0.2369	0.2327	0.1914	0.1717	0.1874	0.1871
<b>bias</b>		0.0798	0.0233	0.0369	0.0327	-0.0086	-0.0283	-0.0126	-0.0129
<b>mse</b>		0.0110	0.0081	0.0046	0.0061	0.0014	0.0066	0.0017	0.0059
<b>var</b>		0.0047	0.0076	0.0033	0.0050	0.0013	0.0058	0.0016	0.0057

**Tabela 4.31:** Resultado da estimativa paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$   $\alpha$ -estável, quando  $p = q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $\alpha = 1.25$ ,  $s \in \{4, 6, 12\}$  e  $N = 1000$ .

		$\alpha = 1.25$							
		$s = 4$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
<b>mean</b>		0.2523	0.2240	0.2237	0.2117	0.1989	0.1999	0.2007	0.2043
<b>bias</b>		0.0523	0.0240	0.0237	0.0117	-0.0011	-0.0001	0.0007	0.0043
<b>mse</b>		0.0052	0.0031	0.0022	0.0017	0.0006	0.0014	0.0007	0.0019
<b>var</b>		0.0025	0.0025	0.0017	0.0016	0.0006	0.0014	0.0007	0.0019
		$\alpha = 1.25$							
		$s = 6$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
<b>mean</b>		0.2521	0.2303	0.2257	0.2207	0.1974	0.2025	0.1978	0.2078
<b>bias</b>		0.0521	0.0303	0.0257	0.0207	-0.0026	0.0025	-0.0022	0.0078
<b>mse</b>		0.0053	0.0047	0.0028	0.0032	0.0007	0.0025	0.0007	0.0030
<b>var</b>		0.0026	0.0037	0.0022	0.0027	0.0007	0.0025	0.0007	0.0030
		$\alpha = 1.25$							
		$s = 12$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
<b>mean</b>		0.2471	0.2218	0.2196	0.2224	0.1968	0.1895	0.1963	0.1966
<b>bias</b>		0.0471	0.0218	0.0196	0.0224	-0.0032	-0.0105	-0.0037	-0.0034
<b>mse</b>		0.0043	0.0042	0.0019	0.0034	0.0005	0.0029	0.0006	0.0029
<b>var</b>		0.0021	0.0037	0.0015	0.0029	0.0005	0.0028	0.0006	0.0029

**Tabela 4.32:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$   $\alpha$ -estável, quando  $p = q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $\alpha = 1.25$ ,  $s \in \{4, 6, 12\}$  e  $N = 2000$ .

		$\alpha = 1.25$							
		$s = 4$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
<b>mean</b>		0.2344	0.2207	0.2156	0.2114	0.2006	0.2058	0.2035	0.2096
<b>bias</b>		0.0344	0.0207	0.0156	0.0114	0.0006	0.0058	0.0035	0.0096
<b>mse</b>		0.0026	0.0023	0.0014	0.0014	0.0004	0.0014	0.0005	0.0017
<b>var</b>		0.0015	0.0019	0.0011	0.0012	0.0004	0.0013	0.0005	0.0016
		$\alpha = 1.25$							
		$s = 6$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
<b>mean</b>		0.2298	0.2166	0.2124	0.2103	0.2004	0.2016	0.2031	0.2061
<b>bias</b>		0.0298	0.0166	0.0124	0.0103	0.0004	0.0016	0.0031	0.0061
<b>mse</b>		0.0020	0.0018	0.0009	0.0012	0.0003	0.0011	0.0004	0.0013
<b>var</b>		0.0011	0.0016	0.0008	0.0011	0.0003	0.0011	0.0004	0.0013
		$\alpha = 1.25$							
		$s = 12$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
<b>mean</b>		0.2280	0.2148	0.2117	0.2135	0.2005	0.1964	0.2025	0.2016
<b>bias</b>		0.0280	0.0148	0.0117	0.0135	0.0005	-0.0036	0.0025	0.0016
<b>mse</b>		0.0017	0.0021	0.0008	0.0018	0.0002	0.0014	0.0003	0.0016
<b>var</b>		0.0009	0.0019	0.0007	0.0016	0.0002	0.0014	0.0003	0.0016



**Figura 4.9:** Módulo do vício dos estimadores paramétricos para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estáveis, com  $p = q = 0 = P = Q$ ,  $\alpha = 1.25$ ,  $N \in \{500, 1000, 2000\}$ . Os gráficos à esquerda são para  $d = 0.2$  e os da direita para  $D = 0.2$ : (a)  $s = 4$ , (b)  $s = 6$  e (c)  $s = 12$ .

**Tabela 4.33:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  (P, D, Q)<sub>s</sub>  $\alpha$ -estável, quando  $p = 1$ ,  $q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $\phi_1 = 0.5$ ,  $\alpha = 1.25$ ,  $s \in \{4, 6, 12\}$  e  $N = 500$ .

		$\alpha = 1.25$							
		$s = 4$				$s = 6$			
		<b>KM</b>		<b>KMmod</b>		<b>KMS</b>		<b>KMSmod</b>	
		$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$
mean	0.3336	0.1890	0.3955	0.2819	0.1958	0.4320	0.1645	0.1926	0.5290
bias	0.1336	-0.0110	-0.1045	0.0819	-0.0042	-0.0680	-0.0355	-0.0074	0.0290
mse	0.0307	0.0026	0.0231	0.0183	0.0023	0.0153	0.0110	0.0029	0.0109
var	0.0129	0.0025	0.0122	0.0116	0.0023	0.0107	0.0098	0.0029	0.0101
		$\alpha = 1.25$				$\alpha = 1.25$			
		<b>KM</b>		<b>KMmod</b>		<b>KMS</b>		<b>KMSmod</b>	
		$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$
mean	0.3316	0.1970	0.3945	0.2761	0.2046	0.4370	0.1670	0.1877	0.5245
bias	0.1316	-0.0030	-0.1055	0.0761	0.0046	-0.0630	-0.0330	-0.0123	0.0245
mse	0.0290	0.0029	0.0224	0.0168	0.0026	0.0140	0.0102	0.0036	0.0102
var	0.0116	0.0029	0.0112	0.0110	0.0026	0.0100	0.0091	0.0035	0.0096
		$\alpha = 1.25$				$\alpha = 1.25$			
		$s = 12$				$s = 12$			
		<b>KM</b>		<b>KMmod</b>		<b>KMS</b>		<b>KMSmod</b>	
		$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$
mean	0.3140	0.1879	0.4049	0.2593	0.2183	0.4486	0.1693	0.1610	0.5175
bias	0.1140	-0.0121	-0.0951	0.0593	0.0183	-0.0514	-0.0307	-0.0390	0.0175
mse	0.0260	0.0048	0.0219	0.0157	0.0041	0.0141	0.0087	0.0061	0.0093
var	0.0130	0.0046	0.0129	0.0122	0.0038	0.0114	0.0078	0.0045	0.0090

**Tabela 4.34:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  (P, D, Q)<sub>s</sub>  $\alpha$ -estável, quando  $p = 1$ ,  $q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $\phi_1 = 0.5$ ,  $\alpha = 1.25$ ,  $s \in \{4, 6, 12\}$  e  $N = 1000$ .

		$\alpha = 1.25$							
		$s = 4$				$s = 6$			
		<b>KM</b>		<b>KMmod</b>		<b>KMS</b>		<b>KMSmod</b>	
		$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$
mean	0.3098	0.1916	0.4072	0.2488	0.1979	0.4580	0.1707	0.2004	0.5268
bias	0.1098	-0.0084	-0.0928	0.0488	-0.0021	-0.0420	-0.0293	0.0004	0.0268
mse	0.0216	0.0011	0.0174	0.0099	0.0010	0.0083	0.0062	0.0016	0.0059
var	0.0096	0.0010	0.0088	0.0075	0.0010	0.0066	0.0053	0.0016	0.0052
		$\alpha = 1.25$				$\alpha = 1.25$			
		<b>KM</b>		<b>KMmod</b>		<b>KMS</b>		<b>KMSmod</b>	
		$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$
mean	0.3076	0.1979	0.4080	0.2483	0.2052	0.4593	0.1798	0.1978	0.5172
bias	0.1076	-0.0021	-0.0920	0.0483	0.0052	-0.0407	-0.0202	-0.0022	0.0172
mse	0.0212	0.0014	0.0173	0.0102	0.0015	0.0086	0.0057	0.0018	0.0060
var	0.0096	0.0014	0.0089	0.0079	0.0014	0.0070	0.0053	0.0018	0.0058
		$\alpha = 1.25$				$\alpha = 1.25$			
		$s = 12$				$s = 12$			
		<b>KM</b>		<b>KMmod</b>		<b>KMS</b>		<b>KMSmod</b>	
		$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$
mean	0.3065	0.2032	0.4079	0.2418	0.2138	0.4642	0.1812	0.1862	0.5147
bias	0.1065	0.0032	-0.0921	0.0418	0.0138	-0.0358	-0.0188	-0.0138	0.0147
mse	0.0209	0.0026	0.0173	0.0092	0.0023	0.0079	0.0049	0.0027	0.0053
var	0.0096	0.0026	0.0089	0.0075	0.0021	0.0066	0.0046	0.0025	0.0050

**Tabela 4.35:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  (P, D, Q)<sub>s</sub>  $\alpha$ -estável, quando  $p = 1$ ,  $q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $\phi_1 = 0.5$ ,  $\alpha = 1.25$ ,  $s \in \{4, 6, 12\}$  e  $N = 2000$ .

$\alpha = 1.25$									
$s = 4$									
		<b>KM</b>		<b>KMmod</b>		<b>KMS</b>		<b>KMSmod</b>	
$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$
mean	0.2902	0.1964	0.4196	0.2395	0.2007	0.4645	0.1860	0.2031	0.5129
bias	0.0902	-0.0036	-0.0804	0.0395	0.0007	-0.0355	-0.0140	0.0031	0.0129
mse	0.0146	0.0007	0.0127	0.0066	0.0006	0.0059	0.0036	0.0009	0.0036
var	0.0065	0.0007	0.0062	0.0051	0.0006	0.0046	0.0034	0.0009	0.0035
$\alpha = 1.25$									
$s = 6$									
		<b>KM</b>		<b>KMmod</b>		<b>KMS</b>		<b>KMSmod</b>	
$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$
mean	0.2895	0.2030	0.4192	0.2383	0.2059	0.4658	0.1880	0.2022	0.5102
bias	0.0895	0.0030	-0.0808	0.0383	0.0059	-0.0342	-0.0120	0.0022	0.0102
mse	0.0142	0.0012	0.0126	0.0064	0.0012	0.0058	0.0033	0.0013	0.0039
var	0.0062	0.0012	0.0061	0.0049	0.0012	0.0046	0.0032	0.0013	0.0038
$\alpha = 1.25$									
$s = 12$									
		<b>KM</b>		<b>KMmod</b>		<b>KMS</b>		<b>KMSmod</b>	
$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$
mean	0.2813	0.2088	0.4279	0.2303	0.2106	0.4739	0.1890	0.1973	0.5103
bias	0.0813	0.0088	-0.0721	0.0303	0.0106	-0.0261	-0.0110	-0.0027	0.0103
mse	0.0127	0.0020	0.0112	0.0055	0.0015	0.0051	0.0032	0.0016	0.0036
var	0.0061	0.0019	0.0060	0.0045	0.0014	0.0044	0.0031	0.0016	0.0035

Veja que as Tabelas 4.36 à 4.38 apresentam resultados para o processo SARFIMA  $(p, d, q) \times (P, D, Q)_s$   $\alpha$ -estável, quando  $p = q = 1 = P = Q$ ,  $d = 0.1$ ,  $D = 0.2$ ,  $\phi_1 = 0.5$ ,  $\Phi_1 = -0.5$ ,  $\theta_1 = -0.5$ ,  $\Theta_1 = 0.5$ ,  $\alpha = 1.50$ ,  $s = 6$  e  $N \in \{500, 1000, 2000\}$ , com estes parâmetros, estamos na situação de processo com as propriedades de longa dependência, causalidade e invertibilidade. Analisando as tabelas observamos que, mesmo com o processo completo, isto é, apresentando todos parâmetros, a estimativa ainda apresenta vício relativamente pequeno, se comparado com os resultados da estimativa semiparamétrica de processo apresentando alguns dos polinômios diferentes de 1. Não há um estimador que se sobressaia nesta situação, apenas quando  $N = 2000$ , que o estimador KMmod apresenta estimativas com menor vício para todos os parâmetros, além de valores pequenos para o erro quadrático médio e variância.

**Tabela 4.36:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$   $\alpha$ -estável, quando  $p = q = 1 = P = Q$ ,  $d = 0.1$ ,  $D = 0.2$ ,  $\phi_1 = 0.5$ ,  $\Phi_1 = -0.5$ ,  $\theta_1 = -0.5$ ,  $\Theta_1 = 0.5$ ,  $\alpha = 1.50$ ,  $s = 6$  e  $N = 500$ .

		$\alpha = 1.50$							
		$s = 6$							
		KM			KMmod				
		$d = 0.1$	$D = 0.2$	$\phi_1 = 0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.2$	$\phi_1 = 0.5$
		$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.2$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$
mean	0.2160	0.1145	0.3754	-0.4998	-0.5042	0.3819	0.1442	0.1615	0.4438
bias	0.1160	-0.0855	-0.1246	0.0002	-0.0042	-0.1181	0.0442	-0.0385	-0.0562
mse	0.0247	0.0164	0.0288	0.0034	0.0021	0.0223	0.0085	0.0099	0.0134
var	0.0112	0.0091	0.0132	0.0034	0.0021	0.0083	0.0066	0.0084	0.0102
mean	0.0758	0.0592	0.5011	-0.4682	-0.4902	0.2928	0.0476	0.0392	0.5089
bias	-0.0242	-0.1408	0.0011	0.0318	0.0098	-0.2072	-0.0524	-0.1608	0.0089
mse	0.0041	0.0237	0.0063	0.0029	0.0023	0.0477	0.0054	0.0281	0.0102
var	0.0035	0.0039	0.0063	0.0019	0.0022	0.0048	0.0027	0.0022	0.0101

**Tabela 4.37:** Resultado da estimativa paramétrica para o processo SARFIMA( $p, d, q) \times (P, D, Q)_s$   $\alpha$ -estável, quando  $p = q = 1 = P = Q$ ,  $d = 0.1$ ,  $D = 0.2$ ,  $\phi_1 = 0.5$ ,  $\Phi_1 = -0.5$ ,  $\theta_1 = -0.5$ ,  $\Theta_1 = 0.5$ ,  $\alpha = 1.50$ ,  $s = 6$  e  $N = 1000$ .

		$\alpha = 1.50$							
		$s = 6$				$s = 6$			
		<b>KM</b>				<b>KMmod</b>			
		$d = 0.1$	$D = 0.2$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.2$
mean	0.1658	0.1475	0.4271	-0.5009	-0.5037	0.4318	0.1205	0.1774	0.4694
bias	0.0658	-0.0525	-0.0729	-0.0009	-0.0037	-0.0682	0.0205	-0.0226	-0.0306
mse	0.0106	0.0114	0.0131	0.0016	0.0010	0.0140	0.0042	0.0067	0.0091
var	0.0063	0.0087	0.0078	0.0016	0.0010	0.0094	0.0037	0.0062	0.0082
		$d = 0.1$	$D = 0.2$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.2$
mean	0.0707	0.0864	0.5182	-0.4814	-0.4943	0.3497	0.0465	0.0696	0.5264
bias	-0.0293	-0.1136	0.0182	0.0186	0.0057	-0.1503	-0.0535	-0.1304	0.0264
mse	0.0031	0.0163	0.0036	0.0012	0.0010	0.0266	0.0046	0.0187	0.0047
var	0.0022	0.0034	0.0032	0.0009	0.0009	0.0040	0.0017	0.0017	0.0040

**Tabela 4.38:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q) \times (P, D, Q)_s$   $\alpha$ -estável, quando  $p = q = 1 = P = Q$ ,  $d = 0.1$ ,  $D = 0.2$ ,  $\phi_1 = 0.5$ ,  $\Phi_1 = -0.5$ ,  $\theta_1 = -0.5$ ,  $\Theta_1 = 0.5$ ,  $\alpha = 1.50$ ,  $s = 6$  e  $N = 2000$ .

		$\alpha = 1.50$							
		$s = 6$				$s = 6$			
		<b>KM</b>				<b>KMmod</b>			
		$d = 0.1$	$D = 0.2$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.2$
mean	0.1410	0.1735	0.4566	-0.4991	-0.5009	0.4670	0.1089	0.1894	0.4886
bias	0.0410	-0.0265	-0.0434	0.0009	-0.0009	-0.0330	0.0089	-0.0106	-0.0114
mse	0.0049	0.0056	0.0058	0.0010	0.0006	0.0070	0.0023	0.0040	0.0033
var	0.0032	0.0050	0.0039	0.0010	0.0006	0.0060	0.0023	0.0039	0.0032
		$d = 0.1$	$D = 0.2$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.2$
mean	0.0802	0.1361	0.5143	-0.4882	-0.4949	0.4140	0.0557	0.1095	0.5588
bias	-0.0198	-0.0639	0.0143	0.0118	0.0051	-0.0860	-0.0443	-0.0905	0.0288
mse	0.0022	0.0068	0.0036	0.0007	0.0024	0.0105	0.0032	0.0099	0.0034
var	0.0018	0.0027	0.0034	0.0006	0.0024	0.0031	0.0012	0.0017	0.0026

# Capítulo 5

## Conclusões e Trabalhos Futuros

### 5.1 Conclusões

Neste trabalho, além de apresentarmos diversas definições e propriedades conhecidas na literatura de séries temporais, abordamos duas classes de processos estocásticos, uma de processos com inovações na forma de ruído branco Gaussiano e outra de processos com inovações  $\alpha$ -estáveis. Para os processos SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estáveis, destacamos o Teorema 2.7, que apresenta condições de causalidade, inversibilidade e a função poder de transferência. Além disso, destacamos a nova definição de periodograma suavizado de correlações, sobre a qual mostramos a convergência em probabilidade. Para a estimação em processos com inovações na forma de ruído branco, destacamos a definição e demonstração de consistência e distribuição normal assintótica dos estimadores paramétricos dados nas Seções 3.2.3 e 3.2.4. Além disso, definimos diversos estimadores semiparamétricos e paramétricos conhecidos na literatura. Para a estimação em processos  $\alpha$ -estáveis definimos outros novos estimadores, além de estimadores conhecidos na literatura, que foram aplicados em simulações.

Realizamos diversas simulações de Monte Carlo, variando os parâmetros do processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>, normal e  $\alpha$ -estável, conforme a seguir:  $p, q, P, Q \in \{0, 1\}$ ,  $d, D \in \{0.2, 0.1\}$ ,  $s \in \{4, 6, 12\}$ , tamanho amostral  $N \in \{500, 1000, 2000\}$  e número de regressores, na estimativa semiparamétrica,  $g(N) = N^\kappa$ , com  $\kappa \in \{0.5; 0.55; 0.60; \dots; \zeta\}$ , em que o último valor  $\zeta$ , depende do tamanho

amostral  $N$ .

Nos resultados obtidos na estimação semiparamétrica, para os processos SARFIMA  $(p, d, q) \times (P, D, Q)_s$  com inovações na forma de ruído branco Gaussiano, notamos que em todos estimadores considerados, ao aumentarmos o valor de  $\kappa$ , isto é, ao aumentarmos o número de regressores, diminuímos o vício. Ao aumentarmos o tamanho amostral  $N$ , diminuímos o erro quadrático médio. O estimador BA é o que apresentou menor vício nos casos analisados, mas nenhuma das metodologias se destacou. Dentre as metodologias utilizadas com o estimador GPH, se destaca a metodologia robusta MM, apresentando menor vício em grande parte dos casos. Também constatamos que, se considerarmos processos mais elaborados, apresentando mais parâmetros, como  $p = 1$ , a estimação é fortemente afetada de forma negativa, sugerindo que não seja utilizada a estimação semiparamétrica nesses casos. Outro fato observado é que, em todos os casos considerados, o estimador GPH, independente da metodologia utilizada, superestima o verdadeiro valor de  $d$ .

Os resultados encontrados para a estimação paramétrica dos processos SARFIMA  $(p, d, q) \times (P, D, Q)_s$  com inovações na forma de ruído branco Gaussiano, mostraram que, em todos os casos abordados no trabalho, a estimação de  $d$  foi melhorada, no sentido de diminuir o vício, nos novos estimadores propostos FT-mod e FTS, se comparados com o estimador original FT. Já, na estimação de  $D$ , os estimadores FTmod e FTS não foram tão eficientes, apresentando maior vício que o estimador FT, em diversos casos. Outro fato observado é que, mesmo que consideremos mais parâmetros no processo, como, por exemplo,  $p \neq 0$  ou  $q \neq 0$ , a estimação, de forma geral, permanece eficiente, o que não acontece com os estimadores semiparamétricos, sugerindo, assim, a utilização dos estimadores paramétricos nos casos de processos mais completos. Também concluímos que, na estimação de  $d$ , em geral, os estimadores paramétricos apresentaram menor vício do que os semiparamétricos. Entretanto, na estimação de  $D$ , os estimadores semiparamétricos apresentaram menor vício que os paramétricos.

Os resultados encontrados para a estimação semiparamétrica dos processos SARFIMA  $(p, d, q) \times (P, D, Q)_s$  com inovações  $\alpha$ -estáveis, notamos que em todos estimadores considerados, ao aumentarmos o valor de  $\kappa$ , isto é, ao aumentarmos o número de regressores, diminuímos o vício. Ao aumentarmos o tamanho amostral  $N$ , além de diminuirmos o vício, também diminuímos o erro quadrático médio. Os resultados apontam que, para uma grande parte dos casos analisados, as versões utilizando o periodograma normalizado suavizado de correlações, isto é, os estimadores

BA MQ, BA MM e BA MPQ, apresentaram melhor desempenho na estimação de  $d$ . A versão utilizando o periodograma normalizado com a metodologia robusta MM, isto é, o estimador GPH MM, apresentou maior eficiência na estimação de  $D$ , em diversos casos analisados. Também constatamos que, se considerarmos processos apresentando mais parâmetros, como  $p = 1$ , a estimação é afetada de forma negativa, especialmente na estimação de  $d$ , sugerindo que não seja utilizada a estimação semiparamétrica nesses casos. Outro fato observado é que, assim como nos processos com inovações ruído branco normal, o estimador GPH, independente da metodologia utilizada, superestima o verdadeiro valor de  $d$ .

Os resultados encontrados para a estimação paramétrica dos processos SARFIMA  $(p, d, q) \times (P, D, Q)_s$  com inovações  $\alpha$ -estáveis mostram que, para a maior parte dos casos analisados, as versões modificadas do estimador KM, isto é, os estimadores KMmod, KMS e KMSmod, apresentaram melhor desempenho. Nos casos que consideramos o processo SARFIMA  $(p, d, q) \times (P, D, Q)_s$   $\alpha$ -estável, com  $p = q = 0 = P = Q$ , para a estimação de  $d$ , o estimador KMS se destacou, apresentando menor vício na maior parte dos casos. Já na estimação de  $D$ , os estimadores modificados não foram tão bons, sendo que o estimador original KMS apresentou menor vício que os demais em alguns casos. Se considerarmos  $p = 1$ , então, o estimador que apresentou menor vício para estimar  $\phi_1$  foi o KMS. Para o processo completo, isto é, apresentando todos os parâmetros, perdemos um pouco da qualidade de estimação, mas temos vício relativamente pequeno, se compararmos com os resultados da estimação semiparamétrica de processos com alguns dos polinômios diferentes de um.

## 5.2 Trabalhos Futuros

Como sugestões para trabalhos futuros, destacamos:

- a) Demonstrar propriedades dos estimadores para processos  $\alpha$ -estáveis, definidos nas Seções 3.2.6, 3.2.7 e 3.2.8, denotados por KMmod, KMS e KMSmod;
- b) Estimar o parâmetro  $\alpha$  nos processos  $\alpha$ -estáveis;
- c) Fazer um estudo prático de previsão, com os preditores lineares definidos na Seção 2.3;
- d) Realizar uma aplicação à série real.

# Bibliografia

- [1] Billingsley, P. *Probability and Measure*. New York: Wiley-Interscience, 1995.
- [2] Bisognin, C. *Estimação e Previsão em Processos SARFIMA( $p, d, q$ ) $\times(P, D, Q)_s$  na Presença de Outliers*. Tese de Doutorado - UFRGS. Porto Alegre, 2007.
- [3] Bisognin, C.; Lopes, S.R.C. Estimation and Forecasting the Long-Memory Parameter in the Presence of Periodicity. *Journal of Forecasting*, Vol. **26** (6), p. 405-427, 2007.
- [4] Bisognin, C.; Lopes, S.R.C. Properties of Seasonal Long Memory Processes. *Mathematical and Computer Modelling*, Vol. **49** (9-10), p. 1837-1851, 2009.
- [5] Box, G.E.P.; Jenkins, G.M. *Time Series Analysis Forecasting and Control*. San Francisco: Holden-Day, 1976.
- [6] Brockwell, P.J.; Davis, R.A. *Time Series: Theory and Methods*. New York: Springer-Verlag, 1991.
- [7] Cline, D.B.H. Linear Prediction of ARMA Processes with Infinite Variance. *Stochastic Processes and their Applications*, Vol. **19** (2), p. 281-296, 1985.
- [8] Dahlhaus, R. Efficient Parameter Estimation for Self-Similar Processes. *Annals of Statistics*, Vol. **17** (4), p. 1749-1766, 1989.
- [9] Diongue, A.K.; Diop, A.; Ndongo, M. Seasonal Fractional ARIMA with Stable Innovations. *Statistics & Probability Letters*, Vol. **78** (12), p.1404-1411, 2008.
- [10] Feller, W. *An Introduction to Probability Theory and its Applications*. New York: John Wiley e Sons, Vol.2, 1971.
- [11] Fox, R.; Taqqu, M.S. Large-Sample Properties of Estimates for Strongly Stationary Gaussian Time Series. *Annals of Statistics*, Vol. **14** (2), p.517-532, 1986.

- [12] Geweke, J.; Porter-Hudak, S. The Estimation and Application of Long Memory Time Series Model. *Journal of Time Series Analysis*, Vol. **4** (4), p. 221-238, 1983.
- [13] Granger, C.W.J.; Joyeux, R. An Introduction to Long Memory Time Series Models and Fractional Differencing. *Journal of Time Series Analysis*, Vol. **1** (1), p.15-29, 1980.
- [14] Grenander, U.; Szegö, G. *Toeplitz Forms and their Application*. Berkeley e Los Angeles: University of California Press, 1958.
- [15] Hannan, E.J. The Asymptotic Theory of Linear Time-Series Models. *Journal of Applied Probability*, Vol. **10** (1), p.130-145, 1973.
- [16] Hosking, J.R.M. Fractional Differencing. *Biometrika*, Vol. **68** (1), p.165-176, 1981.
- [17] Iório, V. *EDP, um curso de graduação*. Rio de Janeiro: Impa, 2007.
- [18] Mikosch, T.; Gadrich, T.; Klüppelberg, C.; Adler, R.J. Parameter Estimation for ARMA Models with Infinite Variance Innovations. *The Annals of Statistics*, Vol. **23** (1), p. 305-326, 1995.
- [19] Klüppelberg, C.; Mikosch, T. Parameter Estimation for a Misspecified ARMA Model with Infinite Variance Innovations. *Journal of Mathematical Sciences*, Vol. **78** (1), p. 60-65, 1996.
- [20] Klüppelberg, C.; Mikosch, T. The Integrated Periodogram for Stable Processes. *The Annals os Statistics*, Vol. **24** (5), p. 1855-1879, 1996.
- [21] Klüppelberg, C.; Mikosch, T. Some Limit Theory for the Self-Normalised Periodogram of Stable Processes. *Scandinavian Journal of Statistics*, Vol. **21** (4), p. 485-491, 1994.
- [22] Kokoszka, P.S.; Taqqu, M.S. Discrete Time Parametric Models with Long Memory and Infinite Variance. *Mathematical and Computer Modelling*, Vol. **29**, p.203-215, 1999.
- [23] Kokoszka, P.S.; Taqqu, M.S. Fractional ARIMA with Stable Innovations. *Stochastic Processes and their Applications*, Vol. **60** (1), p.19-47, 1995.

- [24] Lopes, S.R.C.; Mendes, B.V.M. Bandwidth Selection in Classical and Robust Estimation of Long Memory. *International Journal of Statistics and Systems*, Vol. **1**(2), p. 177-200, 2006.
- [25] Morettin, P.A.; Toloi, C.M.C. *Análise de Séries Temporais*. São Paulo: Edgard Blücher, 2004.
- [26] Ndongo, M.; Diongue, A.K.; Diop, A.; Dossou-Gbété, S. Estimation of Long-Memory Parameters for Seasonal Fractional ARIMA with Stable Innovations. *Statistical Methodology*, Vol. **7** (2), p. 141-151, 2010.
- [27] Reisen, V.A. Estimation of the Fractional Difference Parameter in the ARIMA( $p, d, q$ ) Model Using the Smoothed Periodogram. *Journal of Time Series Analysis*, Vol. **15** (3), p. 335-350, 1994.
- [28] Robinson, P.M. Log-Periodogram Regression of Time Series with Long Range Dependence. *Annals of Statistics*, Vol. **23** (3), p. 1048-1072, 1995.
- [29] Samorodnitsky, G.; Taqqu, M.S. *Stable Non-Gaussian Random Processes: Stochastic Models with Infinite Variance*. New York: Chapman & Hall, 1994.
- [30] Wei, W.W.S. *Time Series Analysis : Univariate and Multivariate Methods*. Redwood City: Addison-Wesley, 1990.
- [31] Whittle, P. *Hypothesis Testing in Time Series Analysis*. New York: Hafner, 1951.
- [32] Zygmund, A. *Trigonometric Series*. Cambridge: Cambridge University Press, Vol I, 1959.

## **Apêndice A**

### **Resultados para Processos com Inovações Gaussianas**

Neste apêndice apresentamos os resultados da estimação semiparamétrica e paramétrica dos parâmetros para processos SARFIMA( $p, d, q) \times (P, D, Q)_s$  que possuem inovações na forma de ruído branco com distribuição normal padrão.

## Estimação Semiparamétrica

**Tabela A.1:** Resultado da estimativa semiparamétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>, quando  $p = q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\kappa = 0.888$  ( $\kappa$  máximo) e  $N = 500$ .

		$\kappa = 0.70$				$\kappa = 0.70$			
		$s = 4$		$s = 6$		$s = 12$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>BA MQ</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2347	0.2127	0.2232	0.2011	0.2303	0.2077	0.1973	0.2006	0.2010
bias	0.0347	0.0127	0.0232	0.0011	0.0303	0.0077	-0.0027	0.0006	0.0010
mse	0.0041	0.0031	0.0060	0.0063	0.0039	0.0037	0.0016	0.0017	0.0024
var	0.0029	0.0029	0.0054	0.0063	0.0030	0.0037	0.0016	0.0017	0.0024
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>BA MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2328	0.2180	0.2243	0.2039	0.2286	0.2136	0.1972	0.1986	0.1997
bias	0.0328	0.0180	0.0243	0.0039	0.0286	0.0136	-0.0028	-0.0014	-0.0003
mse	0.0038	0.0033	0.0063	0.0063	0.0038	0.0039	0.0015	0.0017	0.0023
var	0.0027	0.0029	0.0057	0.0063	0.0030	0.0037	0.0015	0.0017	0.0023
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>BA MQ</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2309	0.2256	0.2226	0.2122	0.2268	0.2215	0.1957	0.1980	0.1984
bias	0.0309	0.0256	0.0226	0.0122	0.0268	0.0215	-0.0043	-0.0020	-0.0016
mse	0.0036	0.0040	0.0057	0.0077	0.0039	0.0047	0.0014	0.0017	0.0022
var	0.0026	0.0033	0.0052	0.0075	0.0032	0.0042	0.0014	0.0017	0.0022

**Tabela A.2:** Resultado da estimativa semiparamétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>, quando  $p = q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\kappa = 0.899$  ( $\kappa$  máximo) e  $N = 1000$ .

		$\kappa = 0.70$				$\kappa = 0.70$			
		$s = 4$		$s = 6$		$s = 12$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>BA MQ</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2217	0.2070	0.2185	0.1976	0.2203	0.2035	0.2003	0.2006	0.2012
bias	0.0217	0.0070	0.0185	-0.0024	0.0203	0.0035	0.0003	0.0006	0.0012
mse	0.0017	0.0013	0.0031	0.0031	0.0019	0.0016	0.0008	0.0008	0.0011
var	0.0012	0.0012	0.0028	0.0031	0.0015	0.0016	0.0008	0.0008	0.0013
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>BA MQ</b>	
mean	0.2214	0.2125	0.2135	0.2048	0.2166	0.2094	0.2003	0.2014	0.2005
bias	0.0214	0.0125	0.0135	0.0048	0.0166	0.0094	0.0003	0.0014	0.0005
mse	0.0017	0.0015	0.0027	0.0030	0.0017	0.0018	0.0007	0.0008	0.0011
var	0.0012	0.0013	0.0025	0.0030	0.0014	0.0017	0.0007	0.0008	0.0011
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>BA MQ</b>	
mean	0.2155	0.2187	0.2102	0.2120	0.2135	0.2176	0.1957	0.2030	0.1983
bias	0.0155	0.0187	0.0102	0.0120	0.0135	0.0176	-0.0043	0.0030	-0.0017
mse	0.0014	0.0016	0.0030	0.0034	0.0017	0.0020	0.0007	0.0008	0.0010
var	0.0012	0.0013	0.0029	0.0033	0.0015	0.0015	0.0017	0.0008	0.0010

**Tabela A.3:** Resultado da estimativa semiparamétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>, quando  $p = q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\kappa = 0.908$  ( $\kappa$  máximo) e  $N = 2000$ .

		$\kappa = 0.70$				$\kappa = 0.70$			
		$s = 4$		$s = 6$		$s = 12$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>BA MQ</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2122	0.2049	0.2073	0.2019	0.2102	0.2054	0.2000	0.2022	0.2000
bias	0.0122	0.0049	0.0073	0.0019	0.0102	0.0054	0.0000	0.0022	0.0000
mse	0.0007	0.0006	0.0014	0.0014	0.0009	0.0004	0.0004	0.0006	0.0006
var	0.0006	0.0006	0.0014	0.0014	0.0008	0.0009	0.0004	0.0004	0.0005
mean	0.2124	0.2070	0.2090	0.2045	0.2107	0.2060	0.2008	0.2019	0.2009
bias	0.0124	0.0070	0.0090	0.0045	0.0107	0.0060	0.0008	0.0019	0.0009
mse	0.0007	0.0006	0.0015	0.0014	0.0009	0.0009	0.0004	0.0004	0.0006
var	0.0006	0.0006	0.0014	0.0014	0.0008	0.0008	0.0004	0.0004	0.0006
mean	0.2112	0.2115	0.2080	0.2039	0.2089	0.2102	0.1991	0.2029	0.1993
bias	0.0112	0.0115	0.0080	0.0039	0.0089	0.0102	-0.0009	0.0029	-0.0007
mse	0.0007	0.0008	0.0014	0.0016	0.0009	0.0010	0.0004	0.0004	0.0006
var	0.0006	0.0007	0.0013	0.0016	0.0008	0.0009	0.0004	0.0004	0.0007

**Tabela A.4:** Resultado da estimação semiparamétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>, quando  $q = 1$ ,  $p = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $\theta_1 = 0.5$ ,  $s \in \{4, 6, 12\}$ ,  $\kappa = 0.85$  e  $N = 500$ .

		$\kappa = 0.85$				$\kappa = 0.85$			
		$s = 4$		$s = 6$		$s = 12$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>BA MQ</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	-0.1443	0.3019	-0.2084	0.2614	-0.1884	0.2705	-0.1788	0.2857	-0.2510
bias	-0.3443	0.1019	-0.4084	0.0614	-0.3884	0.0705	-0.3788	0.0857	-0.4510
mse	0.1214	0.0141	0.1791	0.0112	0.1565	0.0100	0.1452	0.0094	0.2142
var	0.0029	0.0037	0.0123	0.0075	0.0057	0.0050	0.0017	0.0021	0.0108
mean	-0.1266	0.2759	-0.2060	0.2292	-0.1750	0.2427	-0.1628	0.2541	-0.2534
bias	-0.3266	0.0759	-0.4060	0.0292	-0.3750	0.0427	-0.3628	0.0541	-0.4534
mse	0.1098	0.0094	0.1785	0.0094	0.1469	0.0068	0.1333	0.0047	0.2213
var	0.0032	0.0037	0.0137	0.0085	0.0062	0.0050	0.0017	0.0018	0.0157
mean	-0.1248	0.2528	-0.2304	0.2147	-0.1914	0.2223	-0.1621	0.2221	-0.3163
bias	-0.3248	0.0528	-0.4304	0.0147	-0.3914	0.0223	-0.3621	0.0221	-0.5163
mse	0.1090	0.0070	0.2052	0.0091	0.1612	0.0061	0.1328	0.0024	0.2881
var	0.0035	0.0042	0.0199	0.0089	0.0080	0.0056	0.0017	0.0019	0.0215

**Tabela A.5:** Resultado da estimação semiparamétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>, quando  $q = 1, p = 0 = P = Q$ ,  $d = 0.2, D = 0.2, \theta_1 = 0.5, s \in \{4, 6, 12\}, \kappa = 0.85$  e  $N = 1000$ .

		$\kappa = 0.85$				$\kappa = 0.85$			
		$s = 4$				$s = 6$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MQ</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	-0.1392	0.2934	-0.2015	0.2579	-0.1750	0.2711	-0.1619	0.2850	-0.2402
bias	-0.3392	0.0934	-0.4015	0.0579	-0.3750	0.0711	-0.3619	0.0850	-0.4402
mse	0.1163	0.0104	0.1686	0.0081	0.1434	0.0077	0.1317	0.0082	0.2010
var	0.0013	0.0016	0.0074	0.0047	0.0028	0.0027	0.0008	0.0010	0.0072
<hr/>									
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	-0.1217	0.2677	-0.1979	0.2283	-0.1609	0.2430	-0.1449	0.2545	-0.2468
bias	-0.3217	0.0677	-0.3979	0.0283	-0.3609	0.0430	-0.3449	0.0545	-0.4468
mse	0.1050	0.0063	0.1680	0.0056	0.1332	0.0044	0.1198	0.0040	0.2113
var	0.0015	0.0017	0.0097	0.0048	0.0029	0.0026	0.0008	0.0010	0.0117
<hr/>									
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	-0.1198	0.2458	-0.2356	0.2101	-0.1760	0.2225	-0.1424	0.2279	-0.3374
bias	-0.3198	0.0458	-0.4356	0.0101	-0.3760	0.0225	-0.3424	0.0279	-0.5374
mse	0.1040	0.0040	0.2042	0.0047	0.1454	0.0032	0.1182	0.0017	0.3667
var	0.0017	0.0019	0.0145	0.0046	0.0041	0.0027	0.0009	0.0009	0.0178
<hr/>									
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	-0.1198	0.2458	-0.2356	0.2101	-0.1760	0.2225	-0.1424	0.2279	-0.3374
bias	-0.3198	0.0458	-0.4356	0.0101	-0.3760	0.0225	-0.3424	0.0279	-0.5374
mse	0.1040	0.0040	0.2042	0.0047	0.1454	0.0032	0.1182	0.0017	0.3667
var	0.0017	0.0019	0.0145	0.0046	0.0041	0.0027	0.0009	0.0009	0.0178
<hr/>									
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	-0.1198	0.2458	-0.2356	0.2101	-0.1760	0.2225	-0.1424	0.2279	-0.3374
bias	-0.3198	0.0458	-0.4356	0.0101	-0.3760	0.0225	-0.3424	0.0279	-0.5374
mse	0.1040	0.0040	0.2042	0.0047	0.1454	0.0032	0.1182	0.0017	0.3667
var	0.0017	0.0019	0.0145	0.0046	0.0041	0.0027	0.0009	0.0009	0.0178
<hr/>									
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	-0.1198	0.2458	-0.2356	0.2101	-0.1760	0.2225	-0.1424	0.2279	-0.3374
bias	-0.3198	0.0458	-0.4356	0.0101	-0.3760	0.0225	-0.3424	0.0279	-0.5374
mse	0.1040	0.0040	0.2042	0.0047	0.1454	0.0032	0.1182	0.0017	0.3667
var	0.0017	0.0019	0.0145	0.0046	0.0041	0.0027	0.0009	0.0009	0.0178
<hr/>									
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	-0.1198	0.2458	-0.2356	0.2101	-0.1760	0.2225	-0.1424	0.2279	-0.3374
bias	-0.3198	0.0458	-0.4356	0.0101	-0.3760	0.0225	-0.3424	0.0279	-0.5374
mse	0.1040	0.0040	0.2042	0.0047	0.1454	0.0032	0.1182	0.0017	0.3667
var	0.0017	0.0019	0.0145	0.0046	0.0041	0.0027	0.0009	0.0009	0.0178
<hr/>									
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	-0.1198	0.2458	-0.2356	0.2101	-0.1760	0.2225	-0.1424	0.2279	-0.3374
bias	-0.3198	0.0458	-0.4356	0.0101	-0.3760	0.0225	-0.3424	0.0279	-0.5374
mse	0.1040	0.0040	0.2042	0.0047	0.1454	0.0032	0.1182	0.0017	0.3667
var	0.0017	0.0019	0.0145	0.0046	0.0041	0.0027	0.0009	0.0009	0.0178
<hr/>									
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	-0.1198	0.2458	-0.2356	0.2101	-0.1760	0.2225	-0.1424	0.2279	-0.3374
bias	-0.3198	0.0458	-0.4356	0.0101	-0.3760	0.0225	-0.3424	0.0279	-0.5374
mse	0.1040	0.0040	0.2042	0.0047	0.1454	0.0032	0.1182	0.0017	0.3667
var	0.0017	0.0019	0.0145	0.0046	0.0041	0.0027	0.0009	0.0009	0.0178
<hr/>									
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	-0.1198	0.2458	-0.2356	0.2101	-0.1760	0.2225	-0.1424	0.2279	-0.3374
bias	-0.3198	0.0458	-0.4356	0.0101	-0.3760	0.0225	-0.3424	0.0279	-0.5374
mse	0.1040	0.0040	0.2042	0.0047	0.1454	0.0032	0.1182	0.0017	0.3667
var	0.0017	0.0019	0.0145	0.0046	0.0041	0.0027	0.0009	0.0009	0.0178
<hr/>									
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	-0.1198	0.2458	-0.2356	0.2101	-0.1760	0.2225	-0.1424	0.2279	-0.3374
bias	-0.3198	0.0458	-0.4356	0.0101	-0.3760	0.0225	-0.3424	0.0279	-0.5374
mse	0.1040	0.0040	0.2042	0.0047	0.1454	0.0032	0.1182	0.0017	0.3667
var	0.0017	0.0019	0.0145	0.0046	0.0041	0.0027	0.0009	0.0009	0.0178
<hr/>									
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2</math$					

**Tabela A.6:** Resultado da estimação semiparamétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>, quando  $q = 1$ ,  $p = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $\theta_1 = 0.5$ ,  $s \in \{4, 6, 12\}$ ,  $\kappa = 0.85$  e  $N = 2000$ .

		$\kappa = 0.85$				$\kappa = 0.85$			
		$s = 4$				$s = 6$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MQ</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	-0.1315	0.2886	-0.1841	0.2556	-0.1596	0.2676	-0.1454	0.2829	-0.2257
bias	-0.3315	0.0886	-0.3841	0.0556	-0.3596	0.0676	-0.3454	0.0829	-0.4257
mse	0.1106	0.0087	0.1516	0.0058	0.1308	0.0060	0.1197	0.0074	0.1858
var	0.0007	0.0009	0.0040	0.0027	0.0015	0.0014	0.0004	0.0005	0.0045
<hr/>									
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	-0.1142	0.2596	-0.1802	0.2269	-0.1495	0.2402	-0.1279	0.2530	-0.2362
bias	-0.3142	0.0596	-0.3802	0.0269	-0.3495	0.0402	-0.3279	0.0530	-0.4362
mse	0.0994	0.0044	0.1495	0.0031	0.1240	0.0029	0.1080	0.0033	0.1987
var	0.0007	0.0009	0.0050	0.0024	0.0018	0.0013	0.0005	0.0005	0.0084
<hr/>									
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	-0.1096	0.2406	-0.2215	0.2093	-0.1585	0.2203	-0.1248	0.2503	-0.3668
bias	-0.3096	0.0406	-0.4215	0.0093	-0.3585	0.0203	-0.3248	0.0303	-0.5668
mse	0.0966	0.0026	0.1875	0.0026	0.1313	0.0018	0.1060	0.0014	0.3346
var	0.0008	0.0009	0.0098	0.0025	0.0028	0.0014	0.0005	0.0005	0.0134
<hr/>									
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	-0.1096	0.2406	-0.2215	0.2093	-0.1585	0.2203	-0.1248	0.2503	-0.3668
bias	-0.3096	0.0406	-0.4215	0.0093	-0.3585	0.0203	-0.3248	0.0303	-0.5668
mse	0.0966	0.0026	0.1875	0.0026	0.1313	0.0018	0.1060	0.0014	0.3346
var	0.0008	0.0009	0.0098	0.0025	0.0028	0.0014	0.0005	0.0005	0.0134
<hr/>									
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	-0.1096	0.2406	-0.2215	0.2093	-0.1585	0.2203	-0.1248	0.2503	-0.3668
bias	-0.3096	0.0406	-0.4215	0.0093	-0.3585	0.0203	-0.3248	0.0303	-0.5668
mse	0.0966	0.0026	0.1875	0.0026	0.1313	0.0018	0.1060	0.0014	0.3346
var	0.0008	0.0009	0.0098	0.0025	0.0028	0.0014	0.0005	0.0005	0.0134
<hr/>									
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	-0.1096	0.2406	-0.2215	0.2093	-0.1585	0.2203	-0.1248	0.2503	-0.3668
bias	-0.3096	0.0406	-0.4215	0.0093	-0.3585	0.0203	-0.3248	0.0303	-0.5668
mse	0.0966	0.0026	0.1875	0.0026	0.1313	0.0018	0.1060	0.0014	0.3346
var	0.0008	0.0009	0.0098	0.0025	0.0028	0.0014	0.0005	0.0005	0.0134
<hr/>									
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	-0.1096	0.2406	-0.2215	0.2093	-0.1585	0.2203	-0.1248	0.2503	-0.3668
bias	-0.3096	0.0406	-0.4215	0.0093	-0.3585	0.0203	-0.3248	0.0303	-0.5668
mse	0.0966	0.0026	0.1875	0.0026	0.1313	0.0018	0.1060	0.0014	0.3346
var	0.0008	0.0009	0.0098	0.0025	0.0028	0.0014	0.0005	0.0005	0.0134
<hr/>									
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	-0.1096	0.2406	-0.2215	0.2093	-0.1585	0.2203	-0.1248	0.2503	-0.3668
bias	-0.3096	0.0406	-0.4215	0.0093	-0.3585	0.0203	-0.3248	0.0303	-0.5668
mse	0.0966	0.0026	0.1875	0.0026	0.1313	0.0018	0.1060	0.0014	0.3346
var	0.0008	0.0009	0.0098	0.0025	0.0028	0.0014	0.0005	0.0005	0.0134
<hr/>									
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	-0.1096	0.2406	-0.2215	0.2093	-0.1585	0.2203	-0.1248	0.2503	-0.3668
bias	-0.3096	0.0406	-0.4215	0.0093	-0.3585	0.0203	-0.3248	0.0303	-0.5668
mse	0.0966	0.0026	0.1875	0.0026	0.1313	0.0018	0.1060	0.0014	0.3346
var	0.0008	0.0009	0.0098	0.0025	0.0028	0.0014	0.0005	0.0005	0.0134
<hr/>									
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	-0.1096	0.2406	-0.2215	0.2093	-0.1585	0.2203	-0.1248	0.2503	-0.3668
bias	-0.3096	0.0406	-0.4215	0.0093	-0.3585	0.0203	-0.3248	0.0303	-0.5668
mse	0.0966	0.0026	0.1875	0.0026	0.1313	0.0018	0.1060	0.0014	0.3346
var	0.0008	0.0009	0.0098	0.0025	0.0028	0.0014	0.0005	0.0005	0.0134
<hr/>									
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	-0.1096	0.2406	-0.2215	0.2093	-0.1585	0.2203	-0.1248	0.2503	-0.3668
bias	-0.3096	0.0406	-0.4215	0.0093	-0.3585	0.0203	-0.3248	0.0303	-0.5668
mse	0.0966	0.0026	0.1875	0.0026	0.1313	0.0018	0.1060	0.0014	0.3346
var	0.0008	0.0009	0.0098	0.0025	0.0028	0.0014	0.0005	0.0005	0.0134
<hr/>									
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D =$						

## Estimação Paramétrica

**Tabela A.7:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q) \times (P, D, Q)_s$ , quando  $q = 1$ ,  $p = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\theta_1 = -0.5$  e  $N = 500$ .

		$s = 4$								
		<b>FT</b>			<b>FTmod</b>			<b>FTS</b>		
		$d = 0.2$	$D = 0.2$	$\theta_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\theta_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\theta_1 = -0.5$
<b>mean</b>		0.2509	0.1907	-0.4837	0.2126	0.1888	-0.4952	0.1972	0.1733	-0.4944
<b>bias</b>		0.0509	-0.0093	0.0163	0.0126	-0.0112	0.0048	-0.0028	-0.0267	0.0056
<b>mse</b>		0.0065	0.0022	0.0035	0.0026	0.0017	0.0025	0.0022	0.0022	0.0024
<b>var</b>		0.0039	0.0021	0.0032	0.0024	0.0016	0.0025	0.0022	0.0015	0.0023
		$s = 6$								
		<b>FT</b>			<b>FTmod</b>			<b>FTS</b>		
		$d = 0.2$	$D = 0.2$	$\theta_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\theta_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\theta_1 = -0.5$
<b>mean</b>		0.2468	0.1890	-0.4865	0.2083	0.1912	-0.4996	0.1949	0.1599	-0.4935
<b>bias</b>		0.0468	-0.0110	0.0135	0.0083	-0.0088	0.0004	-0.0051	-0.0401	0.0065
<b>mse</b>		0.0059	0.0022	0.0034	0.0021	0.0016	0.0025	0.0023	0.0031	0.0022
<b>var</b>		0.0037	0.0021	0.0032	0.0021	0.0015	0.0025	0.0023	0.0015	0.0022
		$s = 12$								
		<b>FT</b>			<b>FTmod</b>			<b>FTS</b>		
		$d = 0.2$	$D = 0.2$	$\theta_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\theta_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\theta_1 = -0.5$
<b>mean</b>		0.2468	0.1642	-0.4860	0.2064	0.1883	-0.5026	0.1898	0.1253	-0.4989
<b>bias</b>		0.0468	-0.0358	0.0140	0.0064	-0.0117	-0.0026	-0.0102	-0.0747	0.0011
<b>mse</b>		0.0062	0.0038	0.0034	0.0021	0.0016	0.0024	0.0022	0.0071	0.0024
<b>var</b>		0.0040	0.0025	0.0032	0.0021	0.0014	0.0024	0.0021	0.0015	0.0024

**Tabela A.8:** Resultado da estimativa paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>, quando  $q = 1$ ,  $p = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\theta_1 = -0.5$  e  $N = 1000$ .

	$s = 4$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\theta_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\theta_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\theta_1 = -0.5$
<b>mean</b>	0.2319	0.1966	-0.4903	0.2074	0.1937	-0.4981	0.1998	0.1862	-0.4968
<b>bias</b>	0.0319	-0.0034	0.0097	0.0074	-0.0063	0.0019	-0.0002	-0.0138	0.0032
<b>mse</b>	0.0026	0.0010	0.0015	0.0012	0.0008	0.0012	0.0012	0.0009	0.0012
<b>var</b>	0.0016	0.0010	0.0014	0.0012	0.0008	0.0012	0.0012	0.0007	0.0012
	$s = 6$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\theta_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\theta_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\theta_1 = -0.5$
<b>mean</b>	0.2319	0.1969	-0.4907	0.2066	0.1951	-0.4983	0.1969	0.1804	-0.4989
<b>bias</b>	0.0319	-0.0031	0.0093	0.0066	-0.0049	0.0017	-0.0031	-0.0196	0.0011
<b>mse</b>	0.0026	0.0009	0.0014	0.0011	0.0007	0.0011	0.0010	0.0011	0.0010
<b>var</b>	0.0016	0.0009	0.0013	0.0010	0.0007	0.0011	0.0010	0.0007	0.0010
	$s = 12$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\theta_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\theta_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\theta_1 = -0.5$
<b>mean</b>	0.2318	0.1870	-0.4903	0.2049	0.1970	-0.5007	0.1974	0.1655	-0.4965
<b>bias</b>	0.0318	-0.0130	0.0097	0.0049	-0.0030	-0.0007	-0.0026	-0.0345	0.0035
<b>mse</b>	0.0027	0.0011	0.0016	0.0011	0.0007	0.0011	0.0010	0.0020	0.0011
<b>var</b>	0.0017	0.0010	0.0015	0.0010	0.0007	0.0011	0.0010	0.0008	0.0011

**Tabela A.9:** Resultado da estimativa paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>, quando  $q = 1$ ,  $p = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\theta_1 = -0.5$  e  $N = 2000$ .

	$s = 4$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\theta_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\theta_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\theta_1 = -0.5$
<b>mean</b>	0.2200	0.2006	-0.4926	0.2038	0.1975	-0.4993	0.2015	0.1930	-0.4984
<b>bias</b>	0.0200	0.0006	0.0074	0.0038	-0.0025	0.0007	0.0015	-0.0070	0.0016
<b>mse</b>	0.0011	0.0004	0.0007	0.0006	0.0004	0.0006	0.0006	0.0004	0.0006
<b>var</b>	0.0007	0.0004	0.0006	0.0006	0.0004	0.0006	0.0006	0.0004	0.0006
	$s = 6$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\theta_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\theta_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\theta_1 = -0.5$
<b>mean</b>	0.2209	0.2007	-0.4934	0.2036	0.1977	-0.4997	0.1992	0.1918	-0.4980
<b>bias</b>	0.0209	0.0007	0.0066	0.0036	-0.0023	0.0003	-0.0008	-0.0082	0.0020
<b>mse</b>	0.0011	0.0004	0.0007	0.0005	0.0003	0.0006	0.0005	0.0004	0.0005
<b>var</b>	0.0007	0.0004	0.0006	0.0005	0.0003	0.0006	0.0005	0.0003	0.0005
	$s = 12$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\theta_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\theta_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\theta_1 = -0.5$
<b>mean</b>	0.2191	0.1962	-0.4933	0.2039	0.1991	-0.4991	0.1982	0.1824	-0.4992
<b>bias</b>	0.0191	-0.0038	0.0067	0.0039	-0.0009	0.0009	-0.0018	-0.0176	0.0008
<b>mse</b>	0.0010	0.0005	0.0007	0.0005	0.0003	0.0006	0.0005	0.0007	0.0005
<b>var</b>	0.0007	0.0005	0.0007	0.0005	0.0003	0.0006	0.0005	0.0004	0.0005

**Tabela A.10:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$ , quando  $P = 1$ ,  $p = q = 0 = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\Phi_1 = 0.5$  e  $N = 500$ .

	$s = 4$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\Phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\Phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\Phi_1 = 0.5$
<b>mean</b>	0.2638	0.2181	0.4737	0.2162	0.1557	0.5254	0.1959	0.0861	0.5818
<b>bias</b>	0.0638	0.0181	-0.0263	0.0162	-0.0443	0.0254	-0.0041	-0.1139	0.0818
<b>mse</b>	0.0064	0.0170	0.0185	0.0018	0.0110	0.0108	0.0016	0.0204	0.0168
<b>var</b>	0.0023	0.0167	0.0178	0.0016	0.0090	0.0102	0.0016	0.0075	0.0101
	$s = 6$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\Phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\Phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\Phi_1 = 0.5$
<b>mean</b>	0.2614	0.1693	0.5112	0.2150	0.1662	0.5108	0.1920	0.0633	0.5952
<b>bias</b>	0.0614	-0.0307	0.0112	0.0150	-0.0338	0.0108	-0.0080	-0.1367	0.0952
<b>mse</b>	0.0065	0.0186	0.0194	0.0019	0.0098	0.0104	0.0018	0.0225	0.0146
<b>var</b>	0.0027	0.0177	0.0193	0.0017	0.0087	0.0103	0.0017	0.0038	0.0056
	$s = 12$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\Phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\Phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\Phi_1 = 0.5$
<b>mean</b>	0.2433	0.0412	0.6481	0.2160	0.1422	0.5320	0.1920	0.0231	0.6205
<b>bias</b>	0.0433	-0.1588	0.1481	0.0160	-0.0578	0.0320	-0.0080	-0.1769	0.1205
<b>mse</b>	0.0042	0.0297	0.0285	0.0020	0.0114	0.0108	0.0016	0.0322	0.0169
<b>var</b>	0.0024	0.0044	0.0066	0.0018	0.0081	0.0098	0.0016	0.0010	0.0024

**Tabela A.11:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$ , quando  $P = 1$ ,  $p = q = 0 = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\Phi_1 = 0.5$  e  $N = 1000$ .

	$s = 4$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\Phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\Phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\Phi_1 = 0.5$
<b>mean</b>	0.2367	0.1942	0.4973	0.2103	0.1670	0.5238	0.2003	0.1113	0.5708
<b>bias</b>	0.0367	-0.0058	-0.0027	0.0103	-0.0330	0.0238	0.0003	-0.0887	0.0708
<b>mse</b>	0.0022	0.0104	0.0107	0.0009	0.0068	0.0072	0.0008	0.0132	0.0111
<b>var</b>	0.0009	0.0103	0.0107	0.0008	0.0057	0.0066	0.0008	0.0053	0.0061
	$s = 6$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\Phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\Phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\Phi_1 = 0.5$
<b>mean</b>	0.2385	0.1800	0.5132	0.2086	0.1722	0.5188	0.2009	0.0896	0.5868
<b>bias</b>	0.0385	-0.0200	0.0132	0.0086	-0.0278	0.0188	0.0009	-0.1104	0.0868
<b>mse</b>	0.0025	0.0108	0.0110	0.0008	0.0066	0.0069	0.0008	0.0166	0.0123
<b>var</b>	0.0011	0.0104	0.0108	0.0008	0.0059	0.0065	0.0008	0.0044	0.0048
	$s = 12$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\Phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\Phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\Phi_1 = 0.5$
<b>mean</b>	0.2390	0.1149	0.5747	0.2094	0.1623	0.5260	0.1981	0.0373	0.6223
<b>bias</b>	0.0390	-0.0851	0.0747	0.0094	-0.0377	0.0260	-0.0019	-0.1627	0.1223
<b>mse</b>	0.0028	0.0175	0.0161	0.0008	0.0073	0.0077	0.0007	0.0280	0.0171
<b>var</b>	0.0012	0.0102	0.0106	0.0007	0.0059	0.0070	0.0007	0.0015	0.0022

**Tabela A.12:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$ , quando  $P = 1$ ,  $p = q = 0 = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\Phi_1 = 0.5$  e  $N = 2000$ .

	$s = 4$								
	<b>FT</b>			<b>FTmod</b>			<b>FTS</b>		
	$d = 0.2$	$D = 0.2$	$\Phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\Phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\Phi_1 = 0.5$
<b>mean</b>	0.2193	0.1926	0.5031	0.2054	0.1782	0.5168	0.2020	0.1389	0.5529
<b>bias</b>	0.0193	-0.0074	0.0031	0.0054	-0.0218	0.0168	0.0020	-0.0611	0.0529
<b>mse</b>	0.0008	0.0059	0.0061	0.0004	0.0042	0.0045	0.0004	0.0077	0.0071
<b>var</b>	0.0004	0.0059	0.0061	0.0004	0.0038	0.0042	0.0004	0.0039	0.0043
	$s = 6$								
	<b>FT</b>			<b>FTmod</b>			<b>FTS</b>		
	$d = 0.2$	$D = 0.2$	$\Phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\Phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\Phi_1 = 0.5$
<b>mean</b>	0.2207	0.1807	0.5155	0.2049	0.1790	0.5166	0.2021	0.1191	0.5700
<b>bias</b>	0.0207	-0.0193	0.0155	0.0049	-0.0210	0.0166	0.0021	-0.0809	0.0700
<b>mse</b>	0.0009	0.0067	0.0068	0.0004	0.0035	0.0039	0.0003	0.0103	0.0090
<b>var</b>	0.0005	0.0064	0.0066	0.0003	0.0031	0.0036	0.0003	0.0038	0.0041
	$s = 12$								
	<b>FT</b>			<b>FTmod</b>			<b>FTS</b>		
	$d = 0.2$	$D = 0.2$	$\Phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\Phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\Phi_1 = 0.5$
<b>mean</b>	0.2244	0.1372	0.5591	0.2057	0.1788	0.5164	0.2019	0.0699	0.6080
<b>bias</b>	0.0244	-0.0628	0.0591	0.0057	-0.0212	0.0164	0.0019	-0.1301	0.1080
<b>mse</b>	0.0011	0.0103	0.0098	0.0004	0.0037	0.0040	0.0004	0.0196	0.0143
<b>var</b>	0.0005	0.0064	0.0063	0.0004	0.0032	0.0038	0.0003	0.0027	0.0027

**Tabela A.13:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$ , quando  $P = 1$ ,  $p = q = 0 = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\Phi_1 = -0.5$  e  $N = 500$ .

	$s = 4$								
	<b>FT</b>			<b>FTmod</b>			<b>FTS</b>		
	$d = 0.2$	$D = 0.2$	$\Phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\Phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\Phi_1 = -0.5$
<b>mean</b>	0.2389	0.1895	-0.4875	0.2103	0.1851	-0.4879	0.1932	0.1555	-0.4625
<b>bias</b>	0.0389	-0.0105	0.0125	0.0103	-0.0149	0.0121	-0.0068	-0.0445	0.0375
<b>mse</b>	0.0039	0.0034	0.0030	0.0017	0.0024	0.0027	0.0015	0.0043	0.0037
<b>var</b>	0.0024	0.0033	0.0029	0.0016	0.0021	0.0025	0.0014	0.0023	0.0023
	$s = 6$								
	<b>FT</b>			<b>FTmod</b>			<b>FTS</b>		
	$d = 0.2$	$D = 0.2$	$\Phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\Phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\Phi_1 = -0.5$
<b>mean</b>	0.2377	0.1768	-0.4741	0.2088	0.1830	-0.4822	0.1923	0.1409	-0.4499
<b>bias</b>	0.0377	-0.0232	0.0259	0.0088	-0.0170	0.0178	-0.0077	-0.0591	0.0501
<b>mse</b>	0.0039	0.0041	0.0034	0.0016	0.0025	0.0026	0.0015	0.0058	0.0050
<b>var</b>	0.0025	0.0035	0.0028	0.0015	0.0022	0.0023	0.0015	0.0023	0.0025
	$s = 12$								
	<b>FT</b>			<b>FTmod</b>			<b>FTS</b>		
	$d = 0.2$	$D = 0.2$	$\Phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\Phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\Phi_1 = -0.5$
<b>mean</b>	0.2363	0.1359	-0.4390	0.2065	0.1828	-0.4759	0.1886	0.0910	-0.4105
<b>bias</b>	0.0363	-0.0641	0.0610	0.0065	-0.0172	0.0241	-0.0114	-0.1090	0.0895
<b>mse</b>	0.0041	0.0076	0.0067	0.0014	0.0022	0.0028	0.0016	0.0138	0.0106
<b>var</b>	0.0028	0.0035	0.0030	0.0014	0.0019	0.0022	0.0015	0.0020	0.0026

**Tabela A.14:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>, quando  $P = 1$ ,  $p = q = 0 = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\Phi_1 = -0.5$  e  $N = 1000$ .

	$s = 4$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\Phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\Phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\Phi_1 = -0.5$
<b>mean</b>	0.2245	0.1982	-0.4949	0.2063	0.1925	-0.4941	0.1980	0.1796	-0.4811
<b>bias</b>	0.0245	-0.0018	0.0051	0.0063	-0.0075	0.0059	-0.0020	-0.0204	0.0189
<b>mse</b>	0.0017	0.0014	0.0013	0.0008	0.0011	0.0011	0.0007	0.0015	0.0015
<b>var</b>	0.0011	0.0014	0.0013	0.0007	0.0011	0.0011	0.0007	0.0011	0.0011
	$s = 6$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\Phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\Phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\Phi_1 = -0.5$
<b>mean</b>	0.2251	0.1792	-0.4785	0.2066	0.1934	-0.4938	0.1954	0.1711	-0.4731
<b>bias</b>	0.0251	-0.0208	0.0215	0.0066	-0.0066	0.0062	-0.0046	-0.0289	0.0269
<b>mse</b>	0.0018	0.0023	0.0018	0.0008	0.0010	0.0011	0.0007	0.0020	0.0019
<b>var</b>	0.0012	0.0018	0.0014	0.0007	0.0010	0.0010	0.0007	0.0011	0.0012
	$s = 12$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\Phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\Phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\Phi_1 = -0.5$
<b>mean</b>	0.2263	0.1765	-0.4747	0.2049	0.1927	-0.4908	0.1963	0.1453	-0.4532
<b>bias</b>	0.0263	-0.0235	0.0253	0.0049	-0.0073	0.0092	-0.0037	-0.0547	0.0468
<b>mse</b>	0.0018	0.0023	0.0019	0.0007	0.0010	0.0011	0.0007	0.0041	0.0035
<b>var</b>	0.0011	0.0017	0.0012	0.0007	0.0009	0.0011	0.0007	0.0011	0.0013

**Tabela A.15:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>, quando  $P = 1$ ,  $p = q = 0 = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\Phi_1 = -0.5$  e  $N = 2000$ .

	$s = 4$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\Phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\Phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\Phi_1 = -0.5$
<b>mean</b>	0.2176	0.2012	-0.4998	0.2028	0.1958	-0.4959	0.1997	0.1902	-0.4903
<b>bias</b>	0.0176	0.0012	0.0002	0.0028	-0.0042	0.0041	-0.0003	-0.0098	0.0097
<b>mse</b>	0.0008	0.0006	0.0006	0.0003	0.0005	0.0005	0.0003	0.0006	0.0007
<b>var</b>	0.0005	0.0006	0.0006	0.0003	0.0005	0.0005	0.0003	0.0005	0.0006
	$s = 6$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\Phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\Phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\Phi_1 = -0.5$
<b>mean</b>	0.2150	0.1996	-0.4968	0.2024	0.1968	-0.4962	0.1982	0.1860	-0.4870
<b>bias</b>	0.0150	-0.0004	0.0032	0.0024	-0.0032	0.0038	-0.0018	-0.0140	0.0130
<b>mse</b>	0.0007	0.0007	0.0006	0.0003	0.0005	0.0006	0.0003	0.0007	0.0007
<b>var</b>	0.0004	0.0007	0.0006	0.0003	0.0004	0.0005	0.0003	0.0005	0.0005
	$s = 12$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\Phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\Phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\Phi_1 = -0.5$
<b>mean</b>	0.2158	0.1935	-0.4912	0.2030	0.1972	-0.4941	0.1977	0.1738	-0.4766
<b>bias</b>	0.0158	-0.0065	0.0088	0.0030	-0.0028	0.0059	-0.0023	-0.0262	0.0234
<b>mse</b>	0.0008	0.0007	0.0007	0.0003	0.0005	0.0006	0.0003	0.0012	0.0011
<b>var</b>	0.0005	0.0007	0.0006	0.0003	0.0005	0.0006	0.0003	0.0005	0.0006

**Tabela A.16:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$ , quando  $Q = 1$ ,  $p = q = 0 = P$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\Theta_1 = 0.5$  e  $N = 500$ .

	$s = 4$								
	<b>FT</b>			<b>FTmod</b>			<b>FTS</b>		
	$d = 0.2$	$D = 0.2$	$\Theta_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\Theta_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\Theta_1 = 0.5$
<b>mean</b>	0.2398	0.1682	0.4483	0.2098	0.1564	0.4485	0.1893	0.0725	0.3640
<b>bias</b>	0.0398	-0.0318	-0.0517	0.0098	-0.0436	-0.0515	-0.0107	-0.1275	-0.1360
<b>mse</b>	0.0039	0.0124	0.0138	0.0020	0.0106	0.0146	0.0015	0.0192	0.0226
<b>var</b>	0.0023	0.0114	0.0111	0.0019	0.0087	0.0120	0.0014	0.0029	0.0041
	$s = 6$								
	<b>FT</b>			<b>FTmod</b>			<b>FTS</b>		
	$d = 0.2$	$D = 0.2$	$\Theta_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\Theta_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\Theta_1 = 0.5$
<b>mean</b>	0.2374	0.1184	0.3970	0.2045	0.1573	0.4465	0.1845	0.0597	0.3501
<b>bias</b>	0.0374	-0.0816	-0.1030	0.0045	-0.0427	-0.0535	-0.0155	-0.1403	-0.1499
<b>mse</b>	0.0041	0.0136	0.0179	0.0020	0.0100	0.0143	0.0016	0.0219	0.0259
<b>var</b>	0.0027	0.0070	0.0073	0.0020	0.0082	0.0115	0.0014	0.0022	0.0034
	$s = 12$								
	<b>FT</b>			<b>FTmod</b>			<b>FTS</b>		
	$d = 0.2$	$D = 0.2$	$\Theta_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\Theta_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\Theta_1 = 0.5$
<b>mean</b>	0.2376	0.0508	0.3162	0.2043	0.1451	0.4304	0.1858	0.0258	0.3093
<b>bias</b>	0.0376	-0.1492	-0.1838	0.0043	-0.0549	-0.0696	-0.0142	-0.1742	-0.1907
<b>mse</b>	0.0042	0.0239	0.0366	0.0016	0.0096	0.0134	0.0016	0.0309	0.0379
<b>var</b>	0.0027	0.0017	0.0029	0.0016	0.0066	0.0086	0.0014	0.0005	0.0016

**Tabela A.17:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$ , quando  $Q = 1$ ,  $p = q = 0 = P$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\Theta_1 = 0.5$  e  $N = 1000$ .

	$s = 4$								
	<b>FT</b>			<b>FTmod</b>			<b>FTS</b>		
	$d = 0.2$	$D = 0.2$	$\Theta_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\Theta_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\Theta_1 = 0.5$
<b>mean</b>	0.2214	0.1872	0.4785	0.2056	0.1750	0.4731	0.1951	0.1123	0.4061
<b>bias</b>	0.0214	-0.0128	-0.0215	0.0056	-0.0250	-0.0269	-0.0049	-0.0877	-0.0939
<b>mse</b>	0.0014	0.0105	0.0106	0.0009	0.0067	0.0079	0.0007	0.0113	0.0129
<b>var</b>	0.0010	0.0104	0.0101	0.0008	0.0060	0.0072	0.0007	0.0037	0.0041
	$s = 6$								
	<b>FT</b>			<b>FTmod</b>			<b>FTS</b>		
	$d = 0.2$	$D = 0.2$	$\Theta_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\Theta_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\Theta_1 = 0.5$
<b>mean</b>	0.2232	0.1567	0.4450	0.2040	0.1733	0.4670	0.1942	0.0909	0.3841
<b>bias</b>	0.0232	-0.0433	-0.0550	0.0040	-0.0267	-0.0330	-0.0058	-0.1091	-0.1159
<b>mse</b>	0.0016	0.0093	0.0106	0.0009	0.0062	0.0088	0.0007	0.0146	0.0169
<b>var</b>	0.0010	0.0075	0.0076	0.0009	0.0055	0.0078	0.0007	0.0027	0.0035
	$s = 12$								
	<b>FT</b>			<b>FTmod</b>			<b>FTS</b>		
	$d = 0.2$	$D = 0.2$	$\Theta_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\Theta_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\Theta_1 = 0.5$
<b>mean</b>	0.2252	0.0898	0.3726	0.2025	0.1644	0.4568	0.1922	0.0418	0.3325
<b>bias</b>	0.0252	-0.1102	-0.1274	0.0025	-0.0356	-0.0432	-0.0078	-0.1582	-0.1675
<b>mse</b>	0.0019	0.0158	0.0199	0.0008	0.0063	0.0079	0.0007	0.0260	0.0296
<b>var</b>	0.0013	0.0037	0.0037	0.0008	0.0051	0.0061	0.0006	0.0009	0.0015

**Tabela A.18:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$ , quando  $Q = 1$ ,  $p = q = 0 = P$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\Theta_1 = 0.5$  e  $N = 2000$ .

	$s = 4$								
	<b>FT</b>			<b>FTmod</b>			<b>FTS</b>		
	$d = 0.2$	$D = 0.2$	$\Theta_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\Theta_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\Theta_1 = 0.5$
<b>mean</b>	0.2128	0.2070	0.5018	0.2022	0.1853	0.4840	0.1990	0.1513	0.4459
<b>bias</b>	0.0128	0.0070	0.0018	0.0022	-0.0147	-0.0160	-0.0010	-0.0487	-0.0541
<b>mse</b>	0.0006	0.0064	0.0063	0.0004	0.0031	0.0039	0.0004	0.0050	0.0061
<b>var</b>	0.0005	0.0063	0.0063	0.0004	0.0028	0.0037	0.0004	0.0026	0.0031
	$s = 6$								
	<b>FT</b>			<b>FTmod</b>			<b>FTS</b>		
	$d = 0.2$	$D = 0.2$	$\Theta_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\Theta_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\Theta_1 = 0.5$
<b>mean</b>	0.2135	0.1864	0.4814	0.2025	0.1841	0.4802	0.1987	0.1369	0.4313
<b>bias</b>	0.0135	-0.0136	-0.0186	0.0025	-0.0159	-0.0198	-0.0013	-0.0631	-0.0687
<b>mse</b>	0.0007	0.0055	0.0057	0.0004	0.0031	0.0045	0.0003	0.0064	0.0075
<b>var</b>	0.0005	0.0053	0.0053	0.0004	0.0029	0.0041	0.0003	0.0024	0.0027
	$s = 12$								
	<b>FT</b>			<b>FTmod</b>			<b>FTS</b>		
	$d = 0.2$	$D = 0.2$	$\Theta_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\Theta_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\Theta_1 = 0.5$
<b>mean</b>	0.2135	0.1411	0.4313	0.2021	0.1812	0.4759	0.1971	0.0855	0.3770
<b>bias</b>	0.0135	-0.0589	-0.0687	0.0021	-0.0188	-0.0241	-0.0029	-0.1145	-0.1230
<b>mse</b>	0.0007	0.0071	0.0084	0.0004	0.0029	0.0041	0.0003	0.0147	0.0171
<b>var</b>	0.0005	0.0037	0.0037	0.0004	0.0025	0.0035	0.0003	0.0016	0.0020

**Tabela A.19:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$ , quando  $Q = 1$ ,  $p = q = 0 = P$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\Theta_1 = -0.5$  e  $N = 500$ .

	$s = 4$								
	<b>FT</b>			<b>FTmod</b>			<b>FTS</b>		
	$d = 0.2$	$D = 0.2$	$\Theta_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\Theta_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\Theta_1 = -0.5$
<b>mean</b>	0.2483	0.1891	-0.4959	0.2105	0.1855	-0.4978	0.1980	0.1578	-0.4925
<b>bias</b>	0.0483	-0.0109	0.0041	0.0105	-0.0145	0.0022	-0.0020	-0.0422	0.0075
<b>mse</b>	0.0046	0.0033	0.0025	0.0017	0.0023	0.0022	0.0016	0.0042	0.0019
<b>var</b>	0.0023	0.0032	0.0025	0.0016	0.0020	0.0022	0.0016	0.0024	0.0019
	$s = 6$								
	<b>FT</b>			<b>FTmod</b>			<b>FTS</b>		
	$d = 0.2$	$D = 0.2$	$\Theta_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\Theta_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\Theta_1 = -0.5$
<b>mean</b>	0.2500	0.1831	-0.4953	0.2112	0.1888	-0.4908	0.1967	0.1459	-0.4862
<b>bias</b>	0.0500	-0.0169	0.0047	0.0112	-0.0112	0.0092	-0.0033	-0.0541	0.0138
<b>mse</b>	0.0048	0.0032	0.0025	0.0016	0.0020	0.0022	0.0017	0.0050	0.0019
<b>var</b>	0.0023	0.0030	0.0025	0.0015	0.0019	0.0022	0.0016	0.0021	0.0017
	$s = 12$								
	<b>FT</b>			<b>FTmod</b>			<b>FTS</b>		
	$d = 0.2$	$D = 0.2$	$\Theta_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\Theta_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\Theta_1 = -0.5$
<b>mean</b>	0.2497	0.1446	-0.5004	0.2105	0.1836	-0.4825	0.1948	0.1002	-0.4791
<b>bias</b>	0.0497	-0.0554	-0.0004	0.0105	-0.0164	0.0175	-0.0052	-0.0998	0.0209
<b>mse</b>	0.0052	0.0066	0.0024	0.0017	0.0023	0.0025	0.0016	0.0119	0.0017
<b>var</b>	0.0027	0.0035	0.0024	0.0016	0.0020	0.0022	0.0016	0.0020	0.0013

**Tabela A.20:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>, quando  $Q = 1$ ,  $p = q = 0 = P$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\Theta_1 = -0.5$  e  $N = 1000$ .

	$s = 4$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\Theta_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\Theta_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\Theta_1 = -0.5$
<b>mean</b>	0.2314	0.1994	-0.4913	0.2065	0.1932	-0.4981	0.2008	0.1801	-0.4944
<b>bias</b>	0.0314	-0.0006	0.0087	0.0065	-0.0068	0.0019	0.0008	-0.0199	0.0056
<b>mse</b>	0.0020	0.0014	0.0013	0.0007	0.0011	0.0011	0.0007	0.0014	0.0011
<b>var</b>	0.0010	0.0014	0.0013	0.0007	0.0010	0.0011	0.0007	0.0010	0.0011
	$s = 6$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\Theta_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\Theta_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\Theta_1 = -0.5$
<b>mean</b>	0.2330	0.1956	-0.4962	0.2083	0.1939	-0.4938	0.1993	0.1738	-0.4924
<b>bias</b>	0.0330	-0.0044	0.0038	0.0083	-0.0061	0.0062	-0.0007	-0.0262	0.0076
<b>mse</b>	0.0021	0.0014	0.0013	0.0008	0.0010	0.0011	0.0007	0.0017	0.0010
<b>var</b>	0.0010	0.0014	0.0012	0.0007	0.0009	0.0010	0.0007	0.0010	0.0010
	$s = 12$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\Theta_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\Theta_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\Theta_1 = -0.5$
<b>mean</b>	0.2292	0.1810	-0.4988	0.2049	0.1970	-0.5007	0.1995	0.1503	-0.4857
<b>bias</b>	0.0292	-0.0190	0.0012	0.0049	-0.0030	-0.0007	-0.0005	-0.0497	0.0143
<b>mse</b>	0.0020	0.0021	0.0012	0.0011	0.0007	0.0011	0.0008	0.0036	0.0010
<b>var</b>	0.0011	0.0017	0.0012	0.0010	0.0007	0.0011	0.0008	0.0011	0.0008

**Tabela A.21:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>, quando  $Q = 1$ ,  $p = q = 0 = P$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\Theta_1 = -0.5$  e  $N = 2000$ .

	$s = 4$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\Theta_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\Theta_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\Theta_1 = -0.5$
<b>mean</b>	0.2198	0.2013	-0.4959	0.2051	0.1963	-0.4990	0.2013	0.1920	-0.4954
<b>bias</b>	0.0198	0.0013	0.0041	0.0051	-0.0037	0.0010	0.0013	-0.0080	0.0046
<b>mse</b>	0.0009	0.0006	0.0006	0.0004	0.0004	0.0005	0.0004	0.0006	0.0005
<b>var</b>	0.0005	0.0006	0.0006	0.0004	0.0004	0.0005	0.0004	0.0005	0.0005
	$s = 6$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\Theta_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\Theta_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\Theta_1 = -0.5$
<b>mean</b>	0.2207	0.2020	-0.4945	0.2042	0.1972	-0.4971	0.2013	0.1866	-0.4960
<b>bias</b>	0.0207	0.0020	0.0055	0.0042	-0.0028	0.0029	0.0013	-0.0134	0.0040
<b>mse</b>	0.0009	0.0006	0.0007	0.0004	0.0005	0.0005	0.0004	0.0007	0.0005
<b>var</b>	0.0005	0.0006	0.0007	0.0004	0.0005	0.0005	0.0004	0.0005	0.0005
	$s = 12$								
	FT			FTmod			FTS		
	$d = 0.2$	$D = 0.2$	$\Theta_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\Theta_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\Theta_1 = -0.5$
<b>mean</b>	0.2198	0.1942	-0.4974	0.2026	0.1988	-0.4938	0.2003	0.1769	-0.4911
<b>bias</b>	0.0198	-0.0058	0.0026	0.0026	-0.0012	0.0062	0.0003	-0.0231	0.0089
<b>mse</b>	0.0008	0.0007	0.0006	0.0003	0.0005	0.0006	0.0003	0.0011	0.0006
<b>var</b>	0.0005	0.0007	0.0006	0.0003	0.0005	0.0005	0.0003	0.0005	0.0005

## **Apêndice B**

### **Resultados para Processos com Inovações $\alpha$ -estáveis**

Neste apêndice apresentamos os resultados da estimação semiparamétrica e paramétrica dos parâmetros para processos SARFIMA( $p, d, q$ ) $\times(P, D, Q)_s$  que possuem inovações *alpha*-estáveis com  $\alpha \in \{1.25; 1.50; 1.75\}$ .

## Estimação Semiparamétrica

**Tabela B.1:** Resultado da estimação semiparamétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estável, quando  $p = q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\alpha = 1.25$ ,  $\kappa = 0.888$  ( $\kappa$  máximo) e  $N = 500$ .

		$\kappa = 0.70$				$\kappa = 0.70$			
		$s = 4$				$s = 6$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MQ</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2508	0.2318	0.2285	0.1987	0.2333	0.2088	0.1935	0.2259	0.1987
bias	0.0508	0.0318	0.0285	-0.0013	0.0333	0.0088	-0.0065	0.0259	-0.0013
mse	0.0058	0.0045	0.0055	0.0048	0.0041	0.0030	0.0019	0.0052	0.0024
var	0.0032	0.0034	0.0047	0.0048	0.0030	0.0030	0.0019	0.0046	0.0024
		$\kappa = 0.70$				$\kappa = 0.70$			
		$s = 12$				$s = 12$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2468	0.2565	0.2214	0.2265	0.2284	0.2379	0.1927	0.2366	0.1977
bias	0.0468	0.0565	0.0214	0.0265	0.0284	0.0379	-0.0073	0.0366	-0.0023
mse	0.0053	0.0135	0.0054	0.0106	0.0040	0.0096	0.0022	0.0111	0.0025
var	0.0031	0.0103	0.0050	0.0099	0.0031	0.0082	0.0021	0.0098	0.0025

**Tabela B.2:** Resultado da estimação semiparamétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estável, quando  $p = q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\alpha = 1.25$ ,  $\kappa = 0.899$  ( $\kappa$  máximo) e  $N = 1000$ .

$\kappa = 0.70$							
$s = 4$							
		GPH MQ		GPH MM		GPH MQP	
		$d = 0.2$					
mean	0.2305	0.2194	0.2163	0.2014	0.2204	0.2090	0.1982
bias	0.0305	0.0194	0.0163	0.0014	0.0204	0.0090	-0.0018
mse	0.0026	0.0023	0.0027	0.0029	0.0022	0.0020	0.0008
var	0.0016	0.0019	0.0025	0.0029	0.0018	0.0019	0.0008
$\kappa = 0.70$							
$s = 6$							
		GPH MQ		GPH MM		GPH MQP	
		$d = 0.2$					
mean	0.2304	0.2322	0.2174	0.2126	0.2202	0.2203	0.1991
bias	0.0304	0.0322	0.0174	0.0126	0.0202	0.0203	-0.0009
mse	0.0030	0.0060	0.0034	0.0051	0.0026	0.0045	0.0015
var	0.0021	0.0050	0.0031	0.0050	0.0022	0.0041	0.0015
$\kappa = 0.70$							
$s = 12$							
		GPH MQ		GPH MM		GPH MQP	
		$d = 0.2$					
mean	0.2267	0.2466	0.2146	0.2190	0.2186	0.2328	0.1982
bias	0.0267	0.0466	0.0146	0.0190	0.0186	0.0328	-0.0018
mse	0.0022	0.0088	0.0023	0.0059	0.0016	0.0060	0.0008
var	0.0015	0.0066	0.0021	0.0055	0.0013	0.0050	0.0008

$\kappa = 0.2$							
$s = 4$							
		GPH MQ		GPH MM		GPH MQP	
		$d = 0.2$					
mean	0.2015	0.2154	0.0155	0.0154	0.0010	0.0031	0.0010
bias	0.0015	0.0154	0.0015	0.0015	0.0010	0.0031	0.0010
mse	0.0029	0.0029	0.0031	0.0031	0.0031	0.0031	0.0029

$\kappa = 0.2$							
$s = 6$							
		GPH MQ		GPH MM		GPH MQP	
		$d = 0.2$					
mean	0.2015	0.2154	0.0155	0.0154	0.0010	0.0031	0.0010
bias	0.0015	0.0154	0.0015	0.0015	0.0010	0.0031	0.0010
mse	0.0029	0.0029	0.0031	0.0031	0.0031	0.0031	0.0029

$\kappa = 0.2$							
$s = 12$							
		GPH MQ		GPH MM		GPH MQP	
		$d = 0.2$					
mean	0.2014	0.2322	0.0144	0.0144	0.0010	0.0029	0.0010
bias	0.0014	0.0322	0.0014	0.0014	0.0010	0.0029	0.0010
mse	0.0029	0.0029	0.0031	0.0031	0.0031	0.0031	0.0029

**Tabela B.3:** Resultado da estimação semiparamétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$   $\alpha$ -estável, quando  $p = q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\alpha = 1.25$ ,  $\kappa = 0.908$  ( $\kappa$  máximo) e  $N = 2000$ .

$\kappa = 0.70$							
$s = 4$							
	GPH MQ		GPH MM		GPH MQP		
	$d = 0.2$						
mean	0.2171	0.2120	0.2102	0.2045	0.2135	0.2075	0.2009
bias	0.0171	0.0120	0.0102	0.0045	0.0135	0.0075	0.0009
mse	0.0010	0.0011	0.0012	0.0012	0.0010	0.0010	0.0003
var	0.0008	0.0009	0.0011	0.0011	0.0009	0.0010	0.0003
$\kappa = 0.70$							
$s = 6$							
	GPH MQ		GPH MM		GPH MQP		
	$d = 0.2$						
mean	0.2171	0.2166	0.2123	0.2064	0.2145	0.2104	0.2015
bias	0.0171	0.0166	0.0123	0.0064	0.0145	0.0104	0.0015
mse	0.0013	0.0027	0.0015	0.0021	0.0013	0.0019	0.0006
var	0.0010	0.0024	0.0013	0.0020	0.0011	0.0018	0.0006
$\kappa = 0.70$							
$s = 12$							
	GPH MQ		GPH MM		GPH MQP		
	$d = 0.2$						
mean	0.2166	0.2311	0.2101	0.2169	0.2124	0.2233	0.1997
bias	0.0166	0.0311	0.0101	0.0169	0.0124	0.0233	-0.0003
mse	0.0011	0.0056	0.0013	0.0042	0.0011	0.0042	0.0005
var	0.0008	0.0047	0.0012	0.0039	0.0010	0.0037	0.0005

**Tabela B.4:** Resultado da estimação semiparamétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estável, quando  $p = q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\alpha = 1.50$ ,  $\kappa = 0.85$  e  $N = 500$ .

		$\kappa = 0.70$				$\kappa = 0.70$					
		$s = 4$				$s = 6$					
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>BAMM</b>		<b>BAMQP</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2441	0.2256	0.2260	0.2027	0.2299	0.2116	0.1954	0.2103	0.1994	0.2096	0.2002
bias	0.0441	0.0256	0.0260	0.0027	0.0299	0.0116	-0.0046	0.0103	-0.0066	0.0096	0.0002
mse	0.0046	0.0039	0.0056	0.0059	0.0038	0.0035	0.0015	0.0022	0.0020	0.0033	0.0019
var	0.0026	0.0032	0.0050	0.0059	0.0029	0.0034	0.0015	0.0021	0.0020	0.0032	0.0019
		$\kappa = 0.70$				$\kappa = 0.70$					
		$s = 4$				$s = 6$					
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>BAMM</b>		<b>BAMQP</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2456	0.2382	0.2235	0.2164	0.2330	0.2237	0.1952	0.2140	0.1986	0.2158	0.1990
bias	0.0456	0.0382	0.0235	0.0164	0.0330	0.0237	-0.0048	0.0140	-0.0014	0.0158	-0.0010
mse	0.0049	0.0067	0.0056	0.0083	0.0041	0.0057	0.0016	0.0041	0.0023	0.0053	0.0020
var	0.0028	0.0052	0.0050	0.0080	0.0030	0.0052	0.0015	0.0039	0.0023	0.0051	0.0020
		$\kappa = 0.70$				$\kappa = 0.70$					
		$s = 12$				$s = 12$					
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>BAMM</b>		<b>BAMQP</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2414	0.2499	0.2219	0.2235	0.2264	0.2365	0.1917	0.2200	0.1962	0.2241	0.1978
bias	0.0414	0.0499	0.0219	0.0235	0.0264	0.0365	-0.0083	0.0200	-0.0038	0.0241	-0.0022
mse	0.0049	0.0114	0.0060	0.0114	0.0039	0.0084	0.0016	0.0067	0.0022	0.0084	0.0019
var	0.0032	0.0089	0.0055	0.0108	0.0032	0.0070	0.0015	0.0063	0.0022	0.0078	0.0019

**Tabela B.5:** Resultado da estimação semiparamétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estável, quando  $p = q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\alpha = 1.50$ ,  $\kappa = 0.85$  e  $N = 1000$ .

		$\kappa = 0.70$				$\kappa = 0.70$			
		$s = 4$				$s = 6$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MQ</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2271	0.2179	0.2170	0.1982	0.2205	0.2073	0.1980	0.2097	0.2010
bias	0.0271	0.0179	0.0170	-0.0018	0.0205	0.0073	-0.0020	0.0097	0.0010
mse	0.0024	0.0024	0.0032	0.0034	0.0022	0.0020	0.0010	0.0019	0.0018
var	0.0017	0.0020	0.0029	0.0034	0.0018	0.0019	0.0010	0.0018	0.0018
		$\kappa = 0.70$				$\kappa = 0.70$			
		$s = 4$				$s = 6$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MQ</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2257	0.2234	0.2157	0.2101	0.2195	0.2159	0.1985	0.2101	0.2009
bias	0.0257	0.0234	0.0157	0.0101	0.0195	0.0159	-0.0015	0.0101	0.0009
mse	0.0021	0.0030	0.0027	0.0034	0.0017	0.0025	0.0007	0.0019	0.0011
var	0.0014	0.0024	0.0024	0.0033	0.0013	0.0022	0.0007	0.0018	0.0011
		$\kappa = 0.70$				$\kappa = 0.70$			
		$s = 12$				$s = 12$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MQ</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2269	0.2349	0.2162	0.2165	0.2204	0.2276	0.1970	0.2162	0.1992
bias	0.0269	0.0349	0.0162	0.0165	0.0204	0.0276	-0.0030	0.0162	-0.0008
mse	0.0023	0.0049	0.0030	0.0051	0.0021	0.0039	0.0008	0.0031	0.0012
var	0.0015	0.0037	0.0027	0.0048	0.0017	0.0032	0.0008	0.0029	0.0012

**Tabela B.6:** Resultado da estimação semiparamétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estável, quando  $p = q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\alpha = 1.50$ ,  $\kappa = 0.85$  e  $N = 2000$ .

$\kappa = 0.70$							
$s = 4$							
	GPH MQ		GPH MM		GPH MQP		
	$d = 0.2$						
mean	0.2149	0.2109	0.2095	0.2026	0.2133	0.2062	0.1998
bias	0.0149	0.0109	0.0095	0.0026	0.0133	0.0062	-0.0002
mse	0.0011	0.0014	0.0016	0.0018	0.0011	0.0013	0.0005
var	0.0009	0.0013	0.0015	0.0018	0.0009	0.0013	0.0005
$s = 6$							
	GPH MQ		GPH MM		GPH MQP		
	$d = 0.2$						
mean	0.2167	0.2149	0.2103	0.2049	0.2125	0.2100	0.1999
bias	0.0167	0.0149	0.0103	0.0049	0.0125	0.0100	-0.0001
mse	0.0009	0.0016	0.0014	0.0020	0.0009	0.0013	0.0004
var	0.0007	0.0014	0.0013	0.0020	0.0007	0.0012	0.0004
$s = 12$							
	GPH MQ		GPH MM		GPH MQP		
	$d = 0.2$						
mean	0.2176	0.2225	0.2103	0.2089	0.2135	0.2172	0.1996
bias	0.0176	0.0225	0.0103	0.0089	0.0135	0.0172	-0.0004
mse	0.0011	0.0028	0.0016	0.0026	0.0010	0.0022	0.0004
var	0.0008	0.0023	0.0015	0.0025	0.0008	0.0019	0.0004

**Tabela B.7:** Resultado da estimação semiparamétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estável, quando  $p = q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\alpha = 1.75$ ,  $\kappa = 0.85$  e  $N = 500$ .

$\kappa = 0.70$								
$s = 4$								
	GPH MQ		GPH MM		GPH MQP		BA MQ	
	$d = 0.2$							
mean	0.2362	0.2173	0.2267	0.2004	0.2316	0.2116	0.1953	0.2032
bias	0.0362	0.0173	0.0267	0.0004	0.0316	0.0116	-0.0047	0.0032
mse	0.0041	0.0037	0.0063	0.0063	0.0041	0.0039	0.0016	0.0018
var	0.0028	0.0034	0.0056	0.0063	0.0031	0.0037	0.0016	0.0018
$\kappa = 0.70$								
$s = 6$								
	GPH MQ		GPH MM		GPH MQP		BA MQ	
	$d = 0.2$							
mean	0.2375	0.2258	0.2240	0.2120	0.2309	0.2192	0.1957	0.2036
bias	0.0375	0.0258	0.0240	0.0120	0.0309	0.0192	-0.0043	0.0036
mse	0.0044	0.0042	0.0055	0.0073	0.0040	0.0044	0.0016	0.0021
var	0.0030	0.0036	0.0049	0.0071	0.0031	0.0040	0.0016	0.0020
$\kappa = 0.70$								
$s = 12$								
	GPH MQ		GPH MM		GPH MQP		BA MQ	
	$d = 0.2$							
mean	0.2375	0.2332	0.2192	0.2158	0.2288	0.2280	0.1933	0.2039
bias	0.0375	0.0332	0.0192	0.0158	0.0288	0.0280	-0.0067	0.0039
mse	0.0046	0.0066	0.0059	0.0088	0.0041	0.0070	0.0015	0.0032
var	0.0032	0.0055	0.0055	0.0086	0.0033	0.0062	0.0015	0.0032

$\kappa = 0.2$								
$s = 4$								
	GPH MQ		GPH MM		GPH MQP		BA MM	
	$d = 0.2$							
mean	0.1999	0.2054	-0.0010	0.0055	0.1990	0.2055	0.1999	0.2054
bias	0.0022	0.0026	0.0023	0.0032	0.0023	0.0032	-0.0022	0.0025
mse	0.0022	0.0025	0.0023	0.0032	0.0023	0.0032	0.0022	0.0025
var	0.0021	0.0024	0.0021	0.0033	0.0023	0.0033	0.0021	0.0029

$\kappa = 0.2$								
$s = 6$								
	GPH MQ		GPH MM		GPH MQP		BA MM	
	$d = 0.2$							
mean	0.1990	0.2088	0.0004	0.0068	0.2004	0.2068	0.1990	0.2088
bias	0.0021	0.0030	0.0023	0.0034	0.0023	0.0034	-0.0010	0.0088
mse	0.0021	0.0029	0.0023	0.0033	0.0023	0.0033	0.0021	0.0029
var	0.0021	0.0029	0.0023	0.0033	0.0023	0.0033	0.0021	0.0029

$\kappa = 0.2$								
$s = 12$								
	GPH MQ		GPH MM		GPH MQP		BA MM	
	$d = 0.2$							
mean	0.1978	0.2115	0.0118	0.0118	0.1980	0.2118	0.1978	0.2115
bias	0.0022	0.0115	-0.0020	0.0118	-0.0067	0.0039	0.0118	-0.0022
mse	0.0021	0.0045	0.0025	0.0051	0.0015	0.0032	0.0025	0.0050
var	0.0021	0.0044	0.0025	0.0050	0.0015	0.0032	0.0025	0.0044

**Tabela B.8:** Resultado da estimação semiparamétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estável, quando  $p = q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\alpha = 1.75$ ,  $\kappa = 0.85$  e  $N = 1000$ .

$\kappa = 0.70$								
$s = 4$								
	GPH MQ		GPH MM		GPH MQP		BA MQ	
	$d = 0.2$							
mean	0.2249	0.2118	0.2141	0.2005	0.2183	0.2078	0.1987	0.2046
bias	0.0249	0.0118	0.0141	0.0005	0.0183	0.0078	-0.0013	0.0046
mse	0.0019	0.0018	0.0029	0.0036	0.0019	0.0020	0.0008	0.0010
var	0.0013	0.0016	0.0027	0.0036	0.0016	0.0019	0.0008	0.0010
$\kappa = 0.70$								
$s = 6$								
	GPH MQ		GPH MM		GPH MQP		BA MQ	
	$d = 0.2$							
mean	0.2231	0.2170	0.2137	0.2043	0.2177	0.2112	0.1969	0.2030
bias	0.0231	0.0170	0.0137	0.0043	0.0177	0.0112	-0.0031	0.0030
mse	0.0021	0.0022	0.0035	0.0042	0.0021	0.0023	0.0009	0.0013
var	0.0016	0.0020	0.0033	0.0042	0.0018	0.0022	0.0009	0.0012
$\kappa = 0.70$								
$s = 12$								
	GPH MQ		GPH MM		GPH MQP		BA MQ	
	$d = 0.2$							
mean	0.2243	0.2246	0.2131	0.2120	0.2194	0.2199	0.1974	0.2055
bias	0.0243	0.0246	0.0131	0.0120	0.0194	0.0199	-0.0026	0.0055
mse	0.0021	0.0029	0.0034	0.0044	0.0020	0.0028	0.0008	0.0014
var	0.0015	0.0023	0.0032	0.0043	0.0017	0.0024	0.0008	0.0014

**Tabela B.9:** Resultado da estimação semiparamétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estável, quando  $p = q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $s \in \{4, 6, 12\}$ ,  $\alpha = 1.75$ ,  $\kappa = 0.85$  e  $N = 2000$ .

		$\kappa = 0.70$				$\kappa = 0.70$					
		$s = 4$				$s = 6$					
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>BAMM</b>		<b>BAMQP</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2133	0.2080	0.2104	0.2011	0.2127	0.2057	0.2001	0.2041	0.2009	0.2045	0.2011
bias	0.0133	0.0080	0.0104	0.0011	0.0127	0.0057	0.0001	0.0041	0.0009	0.0045	0.0011
mse	0.0008	0.0009	0.0016	0.0017	0.0010	0.0004	0.0004	0.0005	0.0006	0.0009	0.0007
var	0.0006	0.0008	0.0015	0.0017	0.0008	0.0010	0.0010	0.0004	0.0005	0.0008	0.0005
		$\kappa = 0.70$				$\kappa = 0.70$					
		$s = 4$				$s = 6$					
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>BAMM</b>		<b>BAMQP</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2152	0.2089	0.2125	0.2026	0.2136	0.2073	0.2006	0.2023	0.2021	0.2027	0.2017
bias	0.0152	0.0089	0.0125	0.0026	0.0136	0.0073	0.0006	0.0023	0.0021	0.0027	0.0017
mse	0.0010	0.0010	0.0016	0.0020	0.0010	0.0011	0.0004	0.0007	0.0006	0.0010	0.0005
var	0.0007	0.0010	0.0014	0.0020	0.0008	0.0011	0.0004	0.0007	0.0006	0.0010	0.0005
		$\kappa = 0.70$				$\kappa = 0.70$					
		$s = 12$				$s = 12$					
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>BAMM</b>		<b>BAMQP</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.2162	0.2177	0.2102	0.2081	0.2130	0.2129	0.2002	0.2061	0.2016	0.2079	0.2015
bias	0.0162	0.0177	0.0102	0.0081	0.0130	0.0129	0.0002	0.0061	0.0016	0.0079	0.0015
mse	0.0010	0.0014	0.0017	0.0020	0.0011	0.0013	0.0004	0.0008	0.0007	0.0011	0.0006
var	0.0008	0.0011	0.0016	0.0019	0.0009	0.0012	0.0004	0.0007	0.0007	0.0011	0.0006

**Tabela B.10:** Resultado da estimação semiparamétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estável, quando  $p = 1$ ,  $q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $\phi_1 = 0.5$ ,  $s \in \{4, 6, 12\}$ ,  $\alpha = 1.25$ ,  $\kappa = 0.85$  e  $N = 500$ .

		$\kappa = 0.85$				$\kappa = 0.85$			
		$s = 4$				$s = 6$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MQ</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.6340	0.1509	0.6640	0.1318	0.6508	0.1411	0.5657	0.1449	0.7167
bias	0.4340	-0.0491	0.4640	-0.0682	0.4508	-0.0589	0.3657	-0.0551	0.5167
mse	0.1916	0.0071	0.2225	0.0125	0.2072	0.0075	0.1366	0.0113	0.2878
var	0.0033	0.0047	0.0072	0.0079	0.0040	0.0040	0.0029	0.0083	0.0208
<hr/>									
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.6116	0.2007	0.6584	0.1845	0.6391	0.1927	0.5470	0.1770	0.7304
bias	0.4116	0.0007	0.4584	-0.0155	0.4391	-0.0073	0.3470	-0.0230	0.5304
mse	0.1728	0.0124	0.2227	0.0131	0.1987	0.0109	0.1230	0.0115	0.3045
var	0.0034	0.0124	0.0126	0.0128	0.0058	0.0109	0.0026	0.0110	0.0232
<hr/>									
		$\kappa = 0.85$				$\kappa = 0.85$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MM</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.6109	0.2612	0.6682	0.2408	0.6469	0.2538	0.5450	0.2252	0.7633
bias	0.4109	0.0612	0.4682	0.0408	0.4469	0.0538	0.3450	0.0252	0.5633
mse	0.1721	0.0211	0.2316	0.0192	0.2062	0.0177	0.1209	0.0144	0.3330
var	0.0032	0.0173	0.0124	0.0175	0.0065	0.0148	0.0018	0.0138	0.0157
<hr/>									

**Tabela B.11:** Resultado da estimação semiparamétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estável, quando  $p = 1$ ,  $q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $\phi_1 = 0.5$ ,  $s \in \{4, 6, 12\}$ ,  $\alpha = 1.25$ ,  $\kappa = 0.85$  e  $N = 2000$ .

		$\kappa = 0.85$				$\kappa = 0.85$			
		$s = 4$				$s = 6$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MQ</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.5649	0.1332	0.6164	0.1434	0.5934	0.1419	0.5460	0.1323	0.6669
bias	0.3649	-0.0668	0.4164	-0.0566	0.3934	-0.0581	0.3460	-0.0677	0.4969
mse	0.1341	0.0056	0.1836	0.0061	0.1574	0.0049	0.1202	0.0062	0.2640
var	0.0010	0.0011	0.0102	0.0029	0.0026	0.0015	0.0005	0.0016	0.0171
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MQ</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.5484	0.1701	0.6087	0.1761	0.5799	0.1762	0.5283	0.1640	0.7195
bias	0.3484	-0.0299	0.4087	-0.0239	0.3799	-0.0238	0.3283	-0.0360	0.5195
mse	0.1224	0.0035	0.1805	0.0034	0.1477	0.0025	0.1084	0.0041	0.2946
var	0.0010	0.0026	0.0135	0.0029	0.0034	0.0020	0.0006	0.0028	0.0248
		$s = 12$				$s = 12$			
		<b>GPH MQ</b>		<b>GPH MM</b>		<b>GPH MQP</b>		<b>GPH MQ</b>	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
mean	0.5462	0.2055	0.6475	0.2069	0.6076	0.2090	0.5248	0.1978	0.8055
bias	0.3462	0.0055	0.4475	0.0069	0.4076	0.0090	0.3248	-0.0022	0.6055
mse	0.1207	0.0051	0.2162	0.0044	0.1748	0.0040	0.1060	0.0057	0.3774
var	0.0008	0.0051	0.0159	0.0043	0.0087	0.0039	0.0005	0.0057	0.0107

## Estimação Paramétrica

**Tabela B.12:** Resultado da estimativa paramétrica para o processo SARFIMA( $p, d, q) \times (P, D, Q)_s$   $\alpha$ -estável, quando  $p = q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $\alpha = 1.75$ ,  $s \in \{4, 6, 12\}$  e  $N = 500$ .

		$\alpha = 1.75$							
		$s = 4$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
<b>mean</b>		0.2520	0.2016	0.2163	0.1953	0.1966	0.1782	0.1974	0.1795
<b>bias</b>		0.0520	0.0016	0.0163	-0.0047	-0.0034	-0.0218	-0.0026	-0.0205
<b>mse</b>		0.0052	0.0026	0.0019	0.0018	0.0013	0.0022	0.0014	0.0023
<b>var</b>		0.0025	0.0026	0.0016	0.0017	0.0013	0.0018	0.0014	0.0019
		$\alpha = 1.75$							
		$s = 6$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
<b>mean</b>		0.2541	0.1976	0.2165	0.1960	0.1963	0.1672	0.1953	0.1726
<b>bias</b>		0.0541	-0.0024	0.0165	-0.0040	-0.0037	-0.0328	-0.0047	-0.0274
<b>mse</b>		0.0054	0.0025	0.0018	0.0015	0.0014	0.0027	0.0015	0.0024
<b>var</b>		0.0025	0.0025	0.0015	0.0015	0.0014	0.0016	0.0015	0.0017
		$\alpha = 1.75$							
		$s = 12$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
<b>mean</b>		0.2509	0.1766	0.2136	0.1973	0.1934	0.1359	0.1910	0.1527
<b>bias</b>		0.0509	-0.0234	0.0136	-0.0027	-0.0066	-0.0641	-0.0090	-0.0473
<b>mse</b>		0.0054	0.0038	0.0016	0.0018	0.0012	0.0062	0.0014	0.0040
<b>var</b>		0.0028	0.0032	0.0015	0.0018	0.0012	0.0020	0.0013	0.0017

**Tabela B.13:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estável, quando  $p = q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $\alpha = 1.75$ ,  $s \in \{4, 6, 12\}$  e  $N = 1000$ .

		$\alpha = 1.75$							
		$s = 4$							
		KM		KMmod		KMS		KMSmod	
mean	$d = 0.2$	$D = 0.2$		$d = 0.2$					
	0.2335	0.2047		0.2099	0.1986	0.1993	0.1903	0.2018	0.1914
	0.0335	0.0047		0.0099	-0.0014	-0.0007	-0.0097	0.0018	-0.0086
	0.0024	0.0012		0.0010	0.0009	0.0007	0.0011	0.0008	0.0011
bias	$d = 0.2$	$D = 0.2$		$d = 0.2$					
	0.0012	0.0012		0.0009	0.0009	0.0007	0.0010	0.0008	0.0010
	$\alpha = 1.75$								
	$s = 6$								
		KM		KMmod		KMS		KMSmod	
mean	$d = 0.2$	$D = 0.2$		$d = 0.2$					
	0.2309	0.2051		0.2072	0.2012	0.1971	0.1870	0.1987	0.1901
	0.0309	0.0051		0.0072	0.0012	-0.0029	-0.0130	-0.0013	-0.0099
	0.0022	0.0013		0.0008	0.0009	0.0007	0.0011	0.0007	0.0011
bias	$d = 0.2$	$D = 0.2$		$d = 0.2$					
	0.0012	0.0013		0.0008	0.0009	0.0006	0.0009	0.0007	0.0010
	$\alpha = 1.75$								
	$s = 12$								
		KM		KMmod		KMS		KMSmod	
mean	$d = 0.2$	$D = 0.2$		$d = 0.2$					
	0.2314	0.1942		0.2071	0.1991	0.1974	0.1680	0.1975	0.1747
	0.0314	-0.0058		0.0071	-0.0009	-0.0026	-0.0320	-0.0025	-0.0253
	0.0021	0.0013		0.0007	0.0008	0.0006	0.0019	0.0007	0.0015
bias	$d = 0.2$	$D = 0.2$		$d = 0.2$					
	0.0011	0.0013		0.0006	0.0008	0.0006	0.0008	0.0006	0.0009

**Tabela B.14:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estável, quando  $p = q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $\alpha = 1.75$ ,  $s \in \{4, 6, 12\}$  e  $N = 2000$ .

		$\alpha = 1.75$							
		$s = 4$							
		KM		KMmod		KMS		KMSmod	
mean	$d = 0.2$	$D = 0.2$		$d = 0.2$					
	0.2201	0.2041		0.2050	0.1994	0.1998	0.1953	0.2030	0.1970
	0.0201	0.0041		0.0050	-0.0006	-0.0002	-0.0047	0.0030	-0.0030
	0.0009	0.0006		0.0004	0.0004	0.0003	0.0004	0.0004	0.0004
bias	$d = 0.2$	$D = 0.2$		$d = 0.2$					
	0.0005	0.0005		0.0004	0.0004	0.0003	0.0004	0.0004	0.0004
	$\alpha = 1.75$								
	$s = 6$								
		KM		KMmod		KMS		KMSmod	
mean	$d = 0.2$	$D = 0.2$		$d = 0.2$					
	0.2205	0.2036		0.2053	0.1999	0.2003	0.1926	0.2029	0.1953
	0.0205	0.0036		0.0053	-0.0001	0.0003	-0.0074	0.0029	-0.0047
	0.0009	0.0005		0.0004	0.0003	0.0003	0.0004	0.0003	0.0004
bias	$d = 0.2$	$D = 0.2$		$d = 0.2$					
	0.0005	0.0005		0.0003	0.0003	0.0003	0.0003	0.0003	0.0004
	$\alpha = 1.75$								
	$s = 12$								
		KM		KMmod		KMS		KMSmod	
mean	$d = 0.2$	$D = 0.2$		$d = 0.2$					
	0.2188	0.2006		0.2041	0.2016	0.1993	0.1866	0.2013	0.1896
	0.0188	0.0006		0.0041	0.0016	-0.0007	-0.0134	0.0013	-0.0104
	0.0008	0.0005		0.0004	0.0005	0.0003	0.0007	0.0003	0.0005
bias	$d = 0.2$	$D = 0.2$		$d = 0.2$					
	0.0005	0.0005		0.0003	0.0005	0.0003	0.0005	0.0003	0.0004

**Tabela B.15:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estável, quando  $p = q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $\alpha = 1.50$ ,  $s \in \{4, 6, 12\}$  e  $N = 500$ .

		$\alpha = 1.50$							
		$s = 4$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
<b>mean</b>		0.2662	0.2130	0.2262	0.2016	0.1955	0.1812	0.1959	0.1836
<b>bias</b>		0.0662	0.0130	0.0262	0.0016	-0.0045	-0.0188	-0.0041	-0.0164
<b>mse</b>		0.0078	0.0031	0.0029	0.0019	0.0013	0.0021	0.0015	0.0022
<b>var</b>		0.0034	0.0030	0.0022	0.0019	0.0013	0.0017	0.0015	0.0019
		$\alpha = 1.50$							
		$s = 6$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
<b>mean</b>		0.2632	0.2118	0.2246	0.2080	0.1942	0.1773	0.1926	0.1822
<b>bias</b>		0.0632	0.0118	0.0246	0.0080	-0.0058	-0.0227	-0.0074	-0.0178
<b>mse</b>		0.0075	0.0038	0.0029	0.0029	0.0012	0.0035	0.0014	0.0031
<b>var</b>		0.0035	0.0037	0.0023	0.0028	0.0012	0.0030	0.0013	0.0028
		$\alpha = 1.50$							
		$s = 12$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
<b>mean</b>		0.2643	0.1970	0.2225	0.2109	0.1922	0.1493	0.1893	0.1650
<b>bias</b>		0.0643	-0.0030	0.0225	0.0109	-0.0078	-0.0507	-0.0107	-0.0350
<b>mse</b>		0.0076	0.0046	0.0024	0.0028	0.0013	0.0055	0.0015	0.0038
<b>var</b>		0.0035	0.0046	0.0019	0.0026	0.0012	0.0029	0.0014	0.0026

**Tabela B.16:** Resultado da estimativa paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estável, quando  $p = q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $\alpha = 1.50$ ,  $s \in \{4, 6, 12\}$  e  $N = 1000$ .

		$\alpha = 1.50$							
		$s = 4$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
<b>mean</b>		0.2404	0.2122	0.2143	0.2035	0.1981	0.1939	0.2005	0.1959
<b>bias</b>		0.0404	0.0122	0.0143	0.0035	-0.0019	-0.0061	0.0005	-0.0041
<b>mse</b>		0.0033	0.0018	0.0013	0.0011	0.0006	0.0011	0.0007	0.0013
<b>var</b>		0.0017	0.0017	0.0011	0.0011	0.0006	0.0011	0.0007	0.0013
		$\alpha = 1.50$							
		$s = 6$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
<b>mean</b>		0.2393	0.2139	0.2130	0.2070	0.1975	0.1916	0.1988	0.1958
<b>bias</b>		0.0393	0.0139	0.0130	0.0070	-0.0025	-0.0084	-0.0012	-0.0042
<b>mse</b>		0.0032	0.0021	0.0012	0.0013	0.0006	0.0013	0.0007	0.0015
<b>var</b>		0.0016	0.0019	0.0011	0.0013	0.0006	0.0012	0.0007	0.0015
		$\alpha = 1.50$							
		$s = 12$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
<b>mean</b>		0.2386	0.2083	0.2121	0.2103	0.1969	0.1785	0.1970	0.1851
<b>bias</b>		0.0386	0.0083	0.0121	0.0103	-0.0031	-0.0215	-0.0030	-0.0149
<b>mse</b>		0.0031	0.0022	0.0011	0.0016	0.0006	0.0019	0.0007	0.0016
<b>var</b>		0.0016	0.0021	0.0010	0.0015	0.0006	0.0014	0.0007	0.0013

**Tabela B.17:** Resultado da estimativa paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$   $\alpha$ -estável, quando  $p = q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $\alpha = 1.50$ ,  $s \in \{4, 6, 12\}$  e  $N = 2000$ .

		$\alpha = 1.50$							
		$s = 4$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
<b>mean</b>		0.2242	0.2089	0.2079	0.2024	0.2000	0.1977	0.2033	0.2000
<b>bias</b>		0.0242	0.0089	0.0079	0.0024	0.0000	-0.0023	0.0033	0.0000
<b>mse</b>		0.0014	0.0009	0.0006	0.0007	0.0003	0.0006	0.0004	0.0008
<b>var</b>		0.0008	0.0008	0.0006	0.0006	0.0003	0.0005	0.0004	0.0008
		$\alpha = 1.50$							
		$s = 6$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
<b>mean</b>		0.2243	0.2084	0.2077	0.2031	0.1999	0.1950	0.2027	0.1984
<b>bias</b>		0.0243	0.0084	0.0077	0.0031	-0.0001	-0.0050	0.0027	-0.0016
<b>mse</b>		0.0014	0.0011	0.0006	0.0007	0.0003	0.0006	0.0004	0.0008
<b>var</b>		0.0008	0.0010	0.0006	0.0007	0.0003	0.0006	0.0004	0.0008
		$\alpha = 1.50$							
		$s = 12$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$	$d = 0.2$	$D = 0.2$
<b>mean</b>		0.2229	0.2089	0.2060	0.2068	0.1989	0.1911	0.2005	0.1961
<b>bias</b>		0.0229	0.0089	0.0060	0.0068	-0.0011	-0.0089	0.0005	-0.0039
<b>mse</b>		0.0012	0.0015	0.0005	0.0010	0.0003	0.0010	0.0004	0.0013
<b>var</b>		0.0006	0.0014	0.0004	0.0009	0.0003	0.0009	0.0004	0.0013

**Tabela B.18:** Resultado da estimativa paramétrica para o processo SARFIMA( $p, d, q) \times (P, D, Q)_s$   $\alpha$ -estável, quando  $p = q = 0 = P = Q$ ,  $d = 0.1$ ,  $D = 0.1$ ,  $\alpha = 1.25$ ,  $s \in \{4, 6, 12\}$  e  $N = 500$ .

		$\alpha = 1.25$							
		$s = 4$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.1$	$D = 0.1$	$d = 0.1$	$D = 0.1$	$d = 0.1$	$D = 0.1$	$d = 0.1$	$D = 0.1$
<b>mean</b>		0.1322	0.0972	0.1136	0.1012	0.0953	0.0794	0.0943	0.0847
<b>bias</b>		0.0322	0.0972	0.0136	0.0012	-0.0047	-0.0206	-0.0057	-0.0153
<b>mse</b>		0.0036	0.0129	0.0016	0.0025	0.0008	0.0024	0.0009	0.0021
<b>var</b>		0.0025	0.0035	0.0014	0.0025	0.0008	0.0019	0.0008	0.0018
		$\alpha = 1.25$							
		$s = 6$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.1$	$D = 0.1$	$d = 0.1$	$D = 0.1$	$d = 0.1$	$D = 0.1$	$d = 0.1$	$D = 0.1$
<b>mean</b>		0.1332	0.0901	0.1127	0.1017	0.0955	0.0713	0.0938	0.0819
<b>bias</b>		0.0332	0.0901	0.0127	0.0017	-0.0045	-0.0287	-0.0062	-0.0181
<b>mse</b>		0.0035	0.0117	0.0014	0.0023	0.0009	0.0028	0.0009	0.0021
<b>var</b>		0.0024	0.0036	0.0012	0.0023	0.0009	0.0020	0.0009	0.0018
		$\alpha = 1.25$							
		$s = 12$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.1$	$D = 0.1$	$d = 0.1$	$D = 0.1$	$d = 0.1$	$D = 0.1$	$d = 0.1$	$D = 0.1$
<b>mean</b>		0.1287	0.0717	0.1083	0.1075	0.0914	0.0479	0.0892	0.0761
<b>bias</b>		0.0287	0.0717	0.0083	0.0075	-0.0086	-0.0521	-0.0108	-0.0239
<b>mse</b>		0.0029	0.0093	0.0011	0.0033	0.0009	0.0057	0.0009	0.0032
<b>var</b>		0.0020	0.0042	0.0010	0.0032	0.0008	0.0030	0.0007	0.0026

**Tabela B.19:** Resultado da estimativa paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$   $\alpha$ -estável, quando  $p = q = 0 = P = Q$ ,  $d = 0.1$ ,  $D = 0.1$ ,  $\alpha = 1.25$ ,  $s \in \{4, 6, 12\}$  e  $N = 1000$ .

		$\alpha = 1.25$							
		$s = 4$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.1$	$D = 0.1$	$d = 0.1$	$D = 0.1$	$d = 0.1$	$D = 0.1$	$d = 0.1$	$D = 0.1$
<b>mean</b>		0.1195	0.0994	0.1079	0.1004	0.0972	0.0878	0.0971	0.0895
<b>bias</b>		0.0195	-0.0006	0.0079	0.0004	-0.0028	-0.0122	-0.0029	-0.0105
<b>mse</b>		0.0014	0.0017	0.0007	0.0011	0.0003	0.0009	0.0004	0.0009
<b>var</b>		0.0010	0.0017	0.0006	0.0011	0.0003	0.0007	0.0004	0.0007
		$\alpha = 1.25$							
		$s = 6$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.1$	$D = 0.1$	$d = 0.1$	$D = 0.1$	$d = 0.1$	$D = 0.1$	$d = 0.1$	$D = 0.1$
<b>mean</b>		0.1202	0.0993	0.1076	0.1048	0.0977	0.0874	0.0961	0.0910
<b>bias</b>		0.0202	-0.0007	0.0076	0.0048	-0.0023	-0.0126	-0.0039	-0.0090
<b>mse</b>		0.0014	0.0020	0.0007	0.0020	0.0005	0.0018	0.0004	0.0015
<b>var</b>		0.0010	0.0020	0.0007	0.0019	0.0005	0.0016	0.0004	0.0015
		$\alpha = 1.25$							
		$s = 12$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.1$	$D = 0.1$	$d = 0.1$	$D = 0.1$	$d = 0.1$	$D = 0.1$	$d = 0.1$	$D = 0.1$
<b>mean</b>		0.1182	0.0850	0.1058	0.1056	0.0967	0.0714	0.0951	0.0855
<b>bias</b>		0.0182	-0.0150	0.0058	0.0056	-0.0033	-0.0286	-0.0049	-0.0145
<b>mse</b>		0.0012	0.0022	0.0005	0.0018	0.0003	0.0026	0.0004	0.0018
<b>var</b>		0.0009	0.0020	0.0005	0.0018	0.0003	0.0018	0.0003	0.0016

**Tabela B.20:** Resultado da estimativa paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$   $\alpha$ -estável, quando  $p = q = 0 = P = Q$ ,  $d = 0.1$ ,  $D = 0.1$ ,  $\alpha = 1.25$ ,  $s \in \{4, 6, 12\}$  e  $N = 2000$ .

		$\alpha = 1.25$							
		$s = 4$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.1$	$D = 0.1$	$d = 0.1$	$D = 0.1$	$d = 0.1$	$D = 0.1$	$d = 0.1$	$D = 0.1$
<b>mean</b>		0.1114	0.0997	0.1051	0.1012	0.0992	0.0957	0.0993	0.0964
<b>bias</b>		0.0114	-0.0003	0.0051	0.0012	-0.0008	-0.0043	-0.0007	-0.0036
<b>mse</b>		0.0006	0.0008	0.0003	0.0007	0.0002	0.0008	0.0002	0.0009
<b>var</b>		0.0005	0.0008	0.0003	0.0007	0.0002	0.0007	0.0002	0.0009
		$\alpha = 1.25$							
		$s = 6$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.1$	$D = 0.1$	$d = 0.1$	$D = 0.1$	$d = 0.1$	$D = 0.1$	$d = 0.1$	$D = 0.1$
<b>mean</b>		0.1118	0.0981	0.1036	0.1017	0.0986	0.0925	0.0982	0.0948
<b>bias</b>		0.0118	-0.0019	0.0036	0.0017	-0.0014	-0.0075	-0.0018	-0.0052
<b>mse</b>		0.0006	0.0007	0.0003	0.0007	0.0002	0.0007	0.0002	0.0008
<b>var</b>		0.0004	0.0007	0.0003	0.0007	0.0002	0.0007	0.0002	0.0007
		$\alpha = 1.25$							
		$s = 12$							
		KM		KMmod		KMS		KMSmod	
		$d = 0.1$	$D = 0.1$	$d = 0.1$	$D = 0.1$	$d = 0.1$	$D = 0.1$	$d = 0.1$	$D = 0.1$
<b>mean</b>		0.1103	0.0936	0.1025	0.1032	0.0977	0.0848	0.0970	0.0911
<b>bias</b>		0.0103	-0.0064	0.0025	0.0032	-0.0023	-0.0152	-0.0030	-0.0089
<b>mse</b>		0.0005	0.0011	0.0003	0.0009	0.0002	0.0011	0.0002	0.0009
<b>var</b>		0.0004	0.0011	0.0003	0.0009	0.0002	0.0009	0.0002	0.0008

**Tabela B.21:** Resultado da estimativa paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) <sub>$s$</sub>   $\alpha$ -estável, quando  $p = 1$ ,  $q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $\phi_1 = 0.5$ ,  $\alpha = 1.50$ ,  $s \in \{4, 6, 12\}$  e  $N = 500$ .

$\alpha = 1.50$									
$s = 4$									
	<b>KM</b>		<b>KMmod</b>		<b>KMS</b>		<b>KMSmod</b>		
	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$
mean	0.3311	0.1804	0.3965	0.2627	0.1870	0.4447	0.1760	0.1795	0.5159
bias	0.1311	-0.0196	-0.1035	0.0627	-0.0130	-0.0553	-0.0240	-0.0205	0.0159
mse	0.0310	0.0024	0.0240	0.0163	0.0019	0.0158	0.0113	0.0025	0.0118
var	0.0138	0.0020	0.0133	0.0124	0.0018	0.0128	0.0107	0.0021	0.0116
$\alpha = 1.50$									
	<b>KM</b>		<b>KMmod</b>		<b>KMS</b>		<b>KMSmod</b>		
	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$
mean	0.3321	0.1823	0.3929	0.2609	0.1946	0.4470	0.1819	0.1718	0.5109
bias	0.1321	-0.0177	-0.1071	0.0609	-0.0054	-0.0530	-0.0181	-0.0282	0.0109
mse	0.0291	0.0023	0.0234	0.0142	0.0020	0.0135	0.0097	0.0031	0.0106
var	0.0116	0.0020	0.0119	0.0105	0.0020	0.0107	0.0094	0.0023	0.0105
$\alpha = 1.50$									
	<b>KM</b>		<b>KMmod</b>		<b>KMS</b>		<b>KMSmod</b>		
	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$
mean	0.3201	0.1759	0.4009	0.2484	0.2046	0.4553	0.1728	0.1455	0.5151
bias	0.1201	-0.0241	-0.0991	0.0484	0.0046	-0.0447	-0.0272	-0.0545	0.0151
mse	0.0266	0.0037	0.0217	0.0121	0.0023	0.0122	0.0081	0.0055	0.0087
var	0.0122	0.0031	0.0119	0.0097	0.0023	0.0102	0.0074	0.0026	0.0085

**Tabela B.22:** Resultado da estimativa paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estável, quando  $p = 1$ ,  $q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $\phi_1 = 0.5$ ,  $\alpha = 1.50$ ,  $s \in \{4, 6, 12\}$  e  $N = 1000$ .

$\alpha = 1.50$									
$s = 4$									
	<b>KM</b>		<b>KMmod</b>		<b>KMS</b>		<b>KMSmod</b>		
	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$
mean	0.3088	0.1897	0.4060	0.2439	0.1945	0.4588	0.1776	0.1944	0.5184
bias	0.1088	-0.0103	-0.0940	0.0439	-0.0055	-0.0412	-0.0224	-0.0056	0.0184
mse	0.0212	0.0011	0.0183	0.0090	0.0009	0.0091	0.0073	0.0010	0.0077
var	0.0093	0.0010	0.0095	0.0071	0.0008	0.0074	0.0068	0.0010	0.0074
$\alpha = 1.50$									
$s = 6$									
	<b>KM</b>		<b>KMmod</b>		<b>KMS</b>		<b>KMSmod</b>		
	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$
mean	0.3036	0.1929	0.4107	0.2391	0.1985	0.4646	0.1837	0.1896	0.5125
bias	0.1036	-0.0071	-0.0893	0.0391	-0.0015	-0.0354	-0.0163	-0.0104	0.0125
mse	0.0200	0.0013	0.0168	0.0082	0.0010	0.0077	0.0058	0.0013	0.0063
var	0.0093	0.0012	0.0089	0.0067	0.0010	0.0064	0.0055	0.0012	0.0062
$\alpha = 1.50$									
$s = 12$									
	<b>KM</b>		<b>KMmod</b>		<b>KMS</b>		<b>KMSmod</b>		
	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$
mean	0.2904	0.1925	0.4212	0.2242	0.2027	0.4775	0.1785	0.1751	0.5164
bias	0.0904	-0.0075	-0.0788	0.0242	0.0027	-0.0225	-0.0215	-0.0249	0.0164
mse	0.0171	0.0017	0.0151	0.0070	0.0011	0.0071	0.0056	0.0020	0.0061
var	0.0090	0.0016	0.0089	0.0064	0.0011	0.0066	0.0052	0.0014	0.0059

**Tabela B.23:** Resultado da estimativa paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) <sub>$s$</sub>   $\alpha$ -estável, quando  $p = 1$ ,  $q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $\phi_1 = 0.5$ ,  $\alpha = 1.50$ ,  $s \in \{4, 6, 12\}$  e  $N = 2000$ .

$\alpha = 1.50$									
$s = 4$									
	<b>KM</b>		<b>KMmod</b>		<b>KMS</b>		<b>KMSmod</b>		
	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$
mean	0.2788	0.1931	0.4296	0.2270	0.1967	0.4746	0.1894	0.1981	0.5095
bias	0.0788	-0.0069	-0.0704	0.0270	-0.0033	-0.0254	-0.0106	-0.0119	0.0095
mse	0.0118	0.0005	0.0106	0.0045	0.0004	0.0047	0.0037	0.0006	0.0040
var	0.0056	0.0005	0.0057	0.0038	0.0004	0.0040	0.0036	0.0006	0.0039
$\alpha = 1.50$									
	<b>KM</b>		<b>KMmod</b>		<b>KMS</b>		<b>KMSmod</b>		
	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$
mean	0.2989	0.1981	0.4399	0.2183	0.2009	0.4844	0.1836	0.1978	0.5162
bias	0.0689	-0.0019	-0.0601	0.0183	0.0009	-0.0156	-0.0164	-0.0022	0.0162
mse	0.0103	0.0008	0.0089	0.0040	0.0006	0.0038	0.0035	0.0008	0.0037
var	0.0056	0.0008	0.0053	0.0037	0.0006	0.0036	0.0032	0.0008	0.0034
$\alpha = 1.50$									
	<b>KM</b>		<b>KMmod</b>		<b>KMS</b>		<b>KMSmod</b>		
	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = 0.5$
mean	0.2664	0.1994	0.4409	0.2163	0.2034	0.4853	0.1877	0.1898	0.5110
bias	0.0664	-0.0006	-0.0591	0.0163	0.0034	-0.0147	-0.0123	-0.0102	0.0110
mse	0.0093	0.0009	0.0082	0.0035	0.0006	0.0034	0.0033	0.0009	0.0033
var	0.0049	0.0009	0.0047	0.0032	0.0006	0.0031	0.0031	0.0008	0.0032

**Tabela B.24:** Resultado da estimativa paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estável, quando  $p = 1$ ,  $q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $\phi_1 = -0.5$ ,  $\alpha = 1.25$ ,  $s \in \{4, 6, 12\}$  e  $N = 500$ .

$\alpha = 1.25$									
$s = 4$									
	KM		KMmod		KMS		KMSmod		
	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$
mean	0.2894	0.2243	-0.5143	0.2416	0.2124	-0.5027	0.1916	0.1921	-0.4929
bias	0.0894	0.0243	-0.0143	0.0416	0.0124	-0.0027	-0.0084	-0.0079	0.0071
mse	0.0136	0.0051	0.0024	0.0060	0.0030	0.0021	0.0022	0.0031	0.0023
var	0.0056	0.0045	0.0022	0.0042	0.0028	0.0021	0.0021	0.0031	0.0023
$\alpha = 1.25$									
$s = 6$									
	KM		KMmod		KMS		KMSmod		
	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$
mean	0.2932	0.2317	-0.5194	0.2449	0.2240	-0.5058	0.1890	0.1936	-0.4927
bias	0.0932	0.0317	-0.0194	0.0449	0.0240	-0.0058	-0.0110	-0.0064	0.0073
mse	0.0149	0.0063	0.0022	0.0070	0.0040	0.0016	0.0019	0.0040	0.0016
var	0.0063	0.0053	0.0018	0.0050	0.0034	0.0016	0.0017	0.0039	0.0016
$\alpha = 1.25$									
$s = 12$									
	KM		KMmod		KMS		KMSmod		
	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$
mean	0.2802	0.2136	-0.5182	0.2309	0.2270	-0.5024	0.1874	0.1672	-0.4899
bias	0.0802	0.0136	-0.0182	0.0309	0.0270	-0.0024	-0.0126	-0.0328	0.0101
mse	0.0118	0.0066	0.0022	0.0043	0.0050	0.0016	0.0017	0.0061	0.0018
var	0.0054	0.0064	0.0019	0.0034	0.0043	0.0016	0.0015	0.0051	0.0017

**Tabela B.25:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) <sub>$s$</sub>   $\alpha$ -estável, quando  $p = 1$ ,  $q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $\phi_1 = -0.5$ ,  $\alpha = 1.25$ ,  $s \in \{4, 6, 12\}$  e  $N = 1000$ .

$\alpha = 1.25$									
$s = 4$									
	KM		KMmod		KMS		KMSmod		
	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$
mean	0.2604	0.2208	-0.5137	0.2273	0.2112	-0.5048	0.1974	0.2006	-0.4975
bias	0.0604	0.0208	-0.0137	0.0273	0.0112	-0.0048	-0.0026	0.0006	-0.0025
mse	0.0071	0.0033	0.0012	0.0033	0.0021	0.0009	0.0009	0.0019	0.0008
var	0.0035	0.0029	0.0010	0.0025	0.0019	0.0009	0.0009	0.0019	0.0008
$\alpha = 1.25$									
$s = 6$									
	KM		KMmod		KMS		KMSmod		
	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$
mean	0.2599	0.2250	-0.5139	0.2260	0.2160	-0.5035	0.1959	0.1990	-0.4953
bias	0.0599	0.0250	-0.0139	0.0260	0.0160	-0.0035	-0.0041	-0.0010	0.0047
mse	0.0072	0.0041	0.0014	0.0032	0.0023	0.0011	0.0010	0.0020	0.0010
var	0.0036	0.0035	0.0013	0.0026	0.0020	0.0010	0.0009	0.0020	0.0010
$\alpha = 1.25$									
$s = 12$									
	KM		KMmod		KMS		KMSmod		
	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$
mean	0.2546	0.2200	-0.5149	0.2213	0.2206	-0.5034	0.1950	0.1892	-0.4948
bias	0.0546	0.0200	-0.0149	0.0213	0.0206	-0.0034	-0.0050	-0.0108	0.0052
mse	0.0057	0.0045	0.0011	0.0023	0.0033	0.0007	0.0007	0.0032	0.0007
var	0.0027	0.0041	0.0009	0.0018	0.0029	0.0007	0.0007	0.0031	0.0006

**Tabela B.26:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) <sub>$s$</sub>   $\alpha$ -estável, quando  $p = 1$ ,  $q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $\phi_1 = -0.5$ ,  $\alpha = 1.25$ ,  $s \in \{4, 6, 12\}$  e  $N = 2000$ .

$\alpha = 1.25$									
$s = 4$									
	KM		KMmod		KMS		KMSmod		
	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$
mean	0.2354	0.2132	-0.5093	0.2151	0.2074	-0.5032	0.2001	0.2027	-0.4991
bias	0.0354	0.0132	-0.0093	0.0151	0.0074	-0.0032	0.0001	0.0027	0.0009
mse	0.0029	0.0016	0.0006	0.0015	0.0011	0.0004	0.0005	0.0004	0.0004
var	0.0016	0.0014	0.0005	0.0013	0.0011	0.0004	0.0005	0.0011	0.0013
$\alpha = 1.25$									
$s = 6$									
	KM		KMmod		KMS		KMSmod		
	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$
mean	0.2346	0.2155	-0.5095	0.2135	0.2095	-0.5026	0.2005	0.2017	-0.4985
bias	0.0346	0.0155	-0.0095	0.0135	0.0095	-0.0026	0.0005	0.0017	0.0015
mse	0.0028	0.0018	0.0006	0.0012	0.0011	0.0004	0.0005	0.0011	0.0004
var	0.0016	0.0015	0.0005	0.0011	0.0010	0.0004	0.0005	0.0011	0.0004
$\alpha = 1.25$									
$s = 12$									
	KM		KMmod		KMS		KMSmod		
	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$
mean	0.2349	0.2198	-0.5109	0.2136	0.2174	-0.5029	0.1987	0.2016	-0.4979
bias	0.0349	0.0198	-0.0109	0.0136	0.0174	-0.0029	-0.0013	0.0016	0.0021
mse	0.0026	0.0031	0.0006	0.0012	0.0023	0.0004	0.0004	0.0022	0.0004
var	0.0014	0.0027	0.0005	0.0010	0.0020	0.0004	0.0004	0.0022	0.0004

**Tabela B.27:** Resultado da estimativa paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) <sub>$s$</sub>   $\alpha$ -estável, quando  $p = 1$ ,  $q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $\phi_1 = -0.5$ ,  $\alpha = 1.50$ ,  $s \in \{4, 6, 12\}$  e  $N = 500$ .

$\alpha = 1.50$									
$s = 4$									
		KM		KMmod		KMS		KMSmod	
		$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$
mean	0.2707	0.2067	-0.5099	0.2244	0.1993	-0.5003	0.1930	0.1807	-0.4947
bias	0.0707	0.0067	-0.0099	0.0244	-0.0007	-0.0003	-0.0070	-0.0193	0.0053
mse	0.0094	0.0030	0.0026	0.0034	0.0018	0.0017	0.0019	0.0024	0.0019
var	0.0044	0.0029	0.0025	0.0028	0.0018	0.0017	0.0018	0.0020	0.0019
$\alpha = 1.50$									
$s = 6$									
		KM		KMmod		KMS		KMSmod	
		$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$
mean	0.2690	0.2096	-0.5107	0.2254	0.2074	-0.4986	0.1921	0.1771	-0.4910
bias	0.0690	0.0096	-0.0107	0.0254	0.0074	0.0014	-0.0079	-0.0229	0.0090
mse	0.0093	0.0040	0.0023	0.0039	0.0023	0.0019	0.0019	0.0028	0.0021
var	0.0046	0.0039	0.0022	0.0033	0.0022	0.0019	0.0019	0.0023	0.0020
$\alpha = 1.50$									
$s = 12$									
		KM		KMmod		KMS		KMSmod	
		$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$
mean	0.2707	0.1969	-0.5125	0.2212	0.2134	-0.4965	0.1864	0.1516	-0.4872
bias	0.0707	-0.0031	-0.0125	0.0212	0.0134	0.0035	-0.0136	-0.0484	0.0128
mse	0.0096	0.0052	0.0023	0.0032	0.0034	0.0018	0.0019	0.0059	0.0022
var	0.0046	0.0052	0.0021	0.0028	0.0032	0.0018	0.0018	0.0036	0.0020

**Tabela B.28:** Resultado da estimativa paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estável, quando  $p = 1$ ,  $q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $\phi_1 = -0.5$ ,  $\alpha = 1.50$ ,  $s \in \{4, 6, 12\}$  e  $N = 1000$ .

$\alpha = 1.50$									
$s = 4$									
		KM		KMmod		KMS		KMSmod	
		$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$
mean	0.2446	0.2103	-0.5080	0.2140	0.2033	-0.5004	0.1968	0.1942	-0.4963
bias	0.0446	0.0103	-0.0080	0.0140	0.0033	-0.0004	-0.0032	-0.0058	0.0037
mse	0.0044	0.0016	0.0011	0.0017	0.0010	0.0009	0.0009	0.0011	0.0010
var	0.0024	0.0015	0.0010	0.0015	0.0010	0.0009	0.0009	0.0011	0.0013
$\alpha = 1.50$									
$s = 6$									
		KM		KMmod		KMS		KMSmod	
		$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$
mean	0.2454	0.2115	-0.5104	0.2143	0.2059	-0.5013	0.1964	0.1908	-0.4967
bias	0.0454	0.0115	-0.0104	0.0143	0.0059	-0.0013	-0.0036	-0.0092	0.0033
mse	0.0043	0.0020	0.0010	0.0016	0.0012	0.0007	0.0008	0.0013	0.0008
var	0.0022	0.0019	0.0009	0.0014	0.0012	0.0007	0.0008	0.0012	0.0007
$\alpha = 1.50$									
$s = 12$									
		KM		KMmod		KMS		KMSmod	
		$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$
mean	0.2475	0.2084	-0.5119	0.2142	0.2099	-0.5007	0.1971	0.1787	-0.4955
bias	0.0475	0.0084	-0.0119	0.0142	0.0099	-0.0007	-0.0029	-0.0213	0.0045
mse	0.0048	0.0028	0.0013	0.0016	0.0017	0.0009	0.0009	0.0021	0.0009
var	0.0025	0.0027	0.0011	0.0014	0.0016	0.0009	0.0009	0.0017	0.0009

**Tabela B.29:** Resultado da estimativa paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) <sub>$s$</sub>   $\alpha$ -estável, quando  $p = 1$ ,  $q = 0 = P = Q$ ,  $d = 0.2$ ,  $D = 0.2$ ,  $\phi_1 = -0.5$ ,  $\alpha = 1.50$ ,  $s \in \{4, 6, 12\}$  e  $N = 2000$ .

$\alpha = 1.50$									
$s = 4$									
		KM		KMmod		KMS		KMSmod	
		$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$
mean	0.2292	0.2063	-0.5073	0.2094	0.2016	-0.5016	0.2001	0.1969	-0.4990
bias	0.0292	0.0063	-0.0073	0.0094	0.0016	-0.0016	0.0001	-0.0031	0.0010
mse	0.0019	0.0009	0.0005	0.0008	0.0006	0.0004	0.0004	0.0006	0.0005
var	0.0011	0.0008	0.0005	0.0007	0.0006	0.0004	0.0004	0.0006	0.0005
$\alpha = 1.50$									
$s = 6$									
		KM		KMmod		KMS		KMSmod	
		$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$
mean	0.2284	0.2066	-0.5072	0.2087	0.2026	-0.5009	0.2003	0.1951	-0.4984
bias	0.0284	0.0066	-0.0072	0.0087	0.0026	-0.0009	0.0003	-0.0049	0.0016
mse	0.0018	0.0009	0.0006	0.0008	0.0006	0.0005	0.0004	0.0007	0.0005
var	0.0010	0.0009	0.0005	0.0007	0.0006	0.0005	0.0004	0.0007	0.0005
$\alpha = 1.50$									
$s = 12$									
		KM		KMmod		KMS		KMSmod	
		$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$	$\phi_1 = -0.5$	$d = 0.2$	$D = 0.2$
mean	0.2274	0.2087	-0.5075	0.2082	0.2080	-0.5006	0.1993	0.1925	-0.4979
bias	0.0274	0.0087	-0.0075	0.0082	0.0080	-0.0006	-0.0007	-0.0075	0.0021
mse	0.0017	0.0018	0.0005	0.0007	0.0012	0.0004	0.0004	0.0012	0.0004
var	0.0010	0.0017	0.0004	0.0007	0.0011	0.0004	0.0004	0.0012	0.0004

**Tabela B.30:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estável, quando  $p = q = 1 = P = Q$ ,  $d = 0.1$ ,  $D = 0.2$ ,  $\phi_1 = 0.5$ ,  $\Phi_1 = -0.5$ ,  $\theta_1 = -0.5$ ,  $\Theta_1 = 0.5$ ,  $\alpha = 1.50$ ,  $s = 4$  e  $N = 500$ .

		$\alpha = 1.50$							
		$s = 4$							
		KM			KMmod				
		$d = 0.1$	$D = 0.2$	$\phi_1 = 0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.2$	$\phi_1 = 0.5$
		$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.2$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$
mean	0.2278	0.1366	0.3623	-0.4977	-0.5035	0.4228	0.1515	0.1537	0.4363
bias	0.1278	-0.0634	-0.1377	0.0023	-0.0035	-0.0772	0.0515	-0.0463	-0.0637
mse	0.0272	0.0154	0.0313	0.0034	0.0019	0.0179	0.0090	0.0109	0.0149
var	0.0108	0.0114	0.0124	0.0034	0.0019	0.0119	0.0063	0.0088	0.0109
mean	0.0723	0.0568	0.5075	-0.4614	-0.4962	0.3039	0.0561	0.0465	0.5007
bias	-0.0277	-0.1432	0.0075	0.0386	0.0038	-0.1961	-0.0439	-0.1535	0.0007
mse	0.0036	0.0236	0.0045	0.0031	0.0018	0.0427	0.0045	0.0257	0.0048
var	0.0028	0.0031	0.0045	0.0016	0.0017	0.0043	0.0025	0.0021	0.0048

**Tabela B.31:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estável, quando  $p = q = 1 = P = Q$ ,  $d = 0.1$ ,  $D = 0.2$ ,  $\phi_1 = 0.5$ ,  $\Phi_1 = -0.5$ ,  $\theta_1 = -0.5$ ,  $\Theta_1 = 0.5$ ,  $\alpha = 1.50$ ,  $s = 4$  e  $N = 1000$ .

		$\alpha = 1.50$							
		$s = 4$							
		KM			KMmod				
		$d = 0.1$	$D = 0.2$	$\phi_1 = 0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.2$	$\phi_1 = 0.5$
		$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.2$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$
mean	0.1818	0.1584	0.4126	-0.5008	-0.5002	0.4577	0.1313	0.1749	0.4648
bias	0.0818	-0.0416	-0.0874	-0.0008	-0.0002	-0.0423	0.0313	-0.0251	-0.0352
mse	0.0133	0.0107	0.0154	0.0015	0.0010	0.0111	0.0052	0.0074	0.0069
var	0.0066	0.0090	0.0077	0.0015	0.0010	0.0093	0.0042	0.0068	0.0057
mean	0.1040	0.5074	-0.4773	-0.4964	0.3751	0.0613	0.0843	0.5125	-0.4408
bias	-0.0163	-0.0960	0.0074	0.0227	0.0036	-0.1249	-0.0387	-0.1157	0.0125
mse	0.0029	0.0128	0.0036	0.0016	0.0009	0.0199	0.0033	0.0156	0.0026
var	0.0026	0.0036	0.0035	0.0011	0.0009	0.0043	0.0018	0.0022	0.0024

**Tabela B.32:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$   $\alpha$ -estável, quando  $p = q = 1 = P = Q$ ,  $d = 0.1$ ,  $D = 0.2$ ,  $\phi_1 = 0.5$ ,  $\Phi_1 = -0.5$ ,  $\theta_1 = -0.5$ ,  $\Theta_1 = 0.5$ ,  $\alpha = 1.50$ ,  $s = 4$  e  $N = 2000$ .

		$\alpha = 1.50$							
		$s = 4$							
		KM			KMmod				
		$d = 0.1$	$D = 0.2$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.2$
		$d = 0.1$	$D = 0.2$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.2$
mean	0.1520	0.1822	0.4446	-0.4992	-0.5005	0.4809	0.1154	0.1848	0.4800
bias	0.0520	-0.0178	-0.0554	0.0008	-0.0005	-0.0191	0.0154	-0.0152	-0.0200
mse	0.0061	0.0049	0.0069	0.0009	0.0004	0.0059	0.0026	0.0034	0.0053
var	0.0034	0.0046	0.0038	0.0009	0.0004	0.0056	0.0024	0.0031	0.0049
mean	0.1502	0.5102	-0.4871	-0.4975	0.4314	0.0680	0.11263	0.5160	-0.4549
bias	-0.0164	-0.0498	0.0102	0.0129	0.0025	-0.0686	-0.0320	-0.0737	0.0160
mse	0.0020	0.0049	0.0022	0.0007	0.0005	0.0077	0.0025	0.0073	0.0029
var	0.0017	0.0024	0.0021	0.0006	0.0005	0.0030	0.0015	0.0018	0.0026

**Tabela B.33:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estável, quando  $p = q = 1 = P = Q$ ,  $d = 0.1$ ,  $D = 0.2$ ,  $\phi_1 = 0.5$ ,  $\Phi_1 = -0.5$ ,  $\theta_1 = -0.5$ ,  $\Theta_1 = 0.5$ ,  $\alpha = 1.50$ ,  $s = 12$  e  $N = 500$ .

		$\alpha = 1.50$							
		$s = 12$							
		KM			KMmod				
		$d = 0.1$	$D = 0.2$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.2$
		$d = 0.1$	$D = 0.2$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.2$
mean	0.2376	0.1074	0.3592	-0.5041	-0.5051	0.2945	0.1278	0.1663	0.4583
bias	0.1376	-0.0926	-0.1408	-0.0041	-0.0051	-0.2055	0.0278	-0.0337	-0.0417
mse	0.0317	0.0215	0.0360	0.0039	0.0049	0.0511	0.0061	0.0105	0.0122
var	0.0128	0.0129	0.0162	0.0039	0.0049	0.0089	0.0054	0.0094	0.0105
mean	0.0735	0.0750	0.4823	-0.4854	-0.4814	0.2251	0.0485	0.0156	0.5030
bias	-0.0265	-0.1250	-0.0177	0.0146	0.0186	-0.2749	-0.0515	-0.1844	0.0030
mse	0.0048	0.0226	0.0144	0.0060	0.0079	0.0842	0.0053	0.0348	0.0089
var	0.0041	0.0069	0.0141	0.0058	0.0076	0.0086	0.0026	0.0008	0.0089

**Tabela B.34:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$   $\alpha$ -estável, quando  $p = q = 1 = P = Q$ ,  $d = 0.1$ ,  $D = 0.2$ ,  $\phi_1 = 0.5$ ,  $\Phi_1 = -0.5$ ,  $\theta_1 = -0.5$ ,  $\Theta_1 = 0.5$ ,  $\alpha = 1.50$ ,  $s = 12$  e  $N = 1000$ .

		$\alpha = 1.50$							
		$s = 12$							
		KM			KMmod				
		$d = 0.1$	$D = 0.2$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.2$
		$d = 0.1$	$D = 0.2$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.2$
mean	0.1557	0.0985	0.4413	-0.4996	-0.5031	0.3666	0.1094	0.1804	0.4843
bias	0.0557	-0.1015	-0.0587	0.0004	-0.0031	-0.1334	0.0094	-0.0196	-0.0157
mse	0.0097	0.0176	0.0112	0.0014	0.0010	0.0238	0.0031	0.0071	0.0047
var	0.0066	0.0073	0.0078	0.0014	0.0010	0.0061	0.0030	0.0068	0.0045
mean	0.0704	0.0539	0.5167	-0.4856	-0.4893	0.3000	0.0461	0.0338	0.5274
bias	-0.0296	-0.1461	0.0167	0.0144	0.0107	-0.2000	-0.0539	-0.1662	0.0274
mse	0.0029	0.0257	0.0034	0.0010	0.0012	0.0431	0.0045	0.0284	0.0042
var	0.0021	0.0043	0.0031	0.0008	0.0011	0.0031	0.0016	0.0008	0.0035

**Tabela B.35:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q) \times (P, D, Q)_s$   $\alpha$ -estável, quando  $p = q = 1 = P = Q$ ,  $d = 0.1$ ,  $D = 0.2$ ,  $\phi_1 = 0.5$ ,  $\Phi_1 = -0.5$ ,  $\theta_1 = -0.5$ ,  $\Theta_1 = 0.5$ ,  $\alpha = 1.50$ ,  $s = 12$  e  $N = 2000$ .

		$\alpha = 1.50$							
		$s = 12$							
		KM			KMmod				
		$d = 0.1$	$D = 0.2$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.2$
mean	0.1317	0.1438	0.4655	-0.5008	-0.5016	0.4274	0.1094	0.1804	0.4843
bias	0.0317	-0.0562	-0.0345	-0.0008	-0.0016	-0.0726	0.0094	-0.0196	-0.0157
mse	0.0041	0.0085	0.0054	0.0007	0.0006	0.0107	0.0031	0.0071	0.0047
var	0.0031	0.0053	0.0042	0.0007	0.0005	0.0055	0.0030	0.0068	0.0045
mean	0.0763	0.0880	0.5173	-0.4901	-0.4939	0.3586	0.0537	0.0715	0.5315
bias	-0.0237	-0.1120	0.0173	0.0099	0.0061	-0.1414	-0.0463	-0.1285	0.0315
mse	0.0021	0.0152	0.0024	0.0006	0.0005	0.0226	0.0036	0.0175	0.0040
var	0.0016	0.0027	0.0021	0.0005	0.0004	0.0026	0.0015	0.0010	0.0030

**Tabela B.36:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q) \times (P, D, Q)_s$   $\alpha$ -estável, quando  $p = q = 1 = P = Q$ ,  $d = 0.1$ ,  $D = 0.1$ ,  $\phi_1 = 0.5$ ,  $\Phi_1 = -0.5$ ,  $\theta_1 = -0.5$ ,  $\Theta_1 = 0.5$ ,  $\alpha = 1.25$ ,  $s = 4$  e  $N = 500$ .

		$\alpha = 1.25$							
		$s = 4$							
		KM			KMmod				
		$d = 0.1$	$D = 0.1$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.1$
		$d = 0.1$	$D = 0.1$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.1$
mean	0.2398	0.1054	0.3515	-0.4906	-0.5047	0.4735	0.1427	0.0868	0.4493
bias	0.1398	0.1054	-0.1485	0.0094	-0.0047	-0.0265	0.0427	-0.0132	-0.0507
mse	0.0324	0.0227	0.0353	0.0046	0.0025	0.0126	0.0083	0.0081	0.0127
var	0.0129	0.0116	0.0132	0.0045	0.0025	0.0119	0.0065	0.0080	0.0101
mean	0.0713	0.0729	0.5070	-0.4544	-0.4973	0.3770	0.0397	0.0312	0.5062
bias	-0.0287	-0.0271	0.0070	0.0456	0.0027	-0.1230	-0.0603	-0.0688	0.0662
mse	0.0040	0.0099	0.0053	0.0047	0.0050	0.0223	0.0060	0.0089	0.0097
var	0.0032	0.0092	0.0053	0.0026	0.0050	0.0072	0.0023	0.0041	0.0104

**Tabela B.37:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$   $\alpha$ -estável, quando  $p = q = 1 = P = Q$ ,  $d = 0.1$ ,  $D = 0.1$ ,  $\phi_1 = 0.5$ ,  $\Phi_1 = -0.5$ ,  $\theta_1 = -0.5$ ,  $\Theta_1 = 0.5$ ,  $\alpha = 1.25$ ,  $s = 4$  e  $N = 1000$ .

		KM				s = 4				KMmod			
		$d = 0.1$	$D = 0.1$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.1$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$
mean	0.1743	0.0842	0.4199	-0.4972	-0.5029	0.4782	0.1251	0.0877	0.4703	-0.4966	-0.4969	0.4796	
bias	0.0743	-0.0158	-0.0801	0.0028	-0.0029	-0.0218	0.0251	-0.0123	-0.0297	0.0034	0.0031	-0.0204	
mse	0.0118	0.0084	0.0133	0.0015	0.0011	0.0083	0.0041	0.0054	0.0055	0.0057	0.0043	0.0079	
var	0.0063	0.0082	0.0069	0.0015	0.0011	0.0079	0.0035	0.0052	0.0046	0.0057	0.0043	0.0075	
		KM				s = 4				KMmod			
		$d = 0.1$	$D = 0.1$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.1$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$
mean	0.0636	0.0412	0.5263	-0.4732	-0.5004	0.3982	0.0381	0.0332	0.5300	-0.4302	-0.4836	0.3213	
bias	-0.0364	-0.0588	0.0263	0.0268	-0.0004	-0.1018	-0.0619	-0.0668	0.0300	0.0698	0.0164	-0.1787	
mse	0.0029	0.0064	0.0027	0.0014	0.0010	0.0334	0.0051	0.0061	0.0031	0.0114	0.0041	0.0364	
var	0.0015	0.0030	0.0020	0.0007	0.0010	0.0031	0.0013	0.0016	0.0022	0.0065	0.0039	0.0045	

**Tabela B.38:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$   $\alpha$ -estável, quando  $p = q = 1 = P = Q$ ,  $d = 0.1$ ,  $D = 0.1$ ,  $\phi_1 = 0.5$ ,  $\Phi_1 = -0.5$ ,  $\theta_1 = -0.5$ ,  $\Theta_1 = 0.5$ ,  $\alpha = 1.25$ ,  $s = 4$  e  $N = 2000$ .

		$\alpha = 1.25$							
		$s = 4$							
		KM			KMmod				
		$d = 0.1$	$D = 0.1$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.1$
		$d = 0.1$	$D = 0.1$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.1$
mean	0.1405	0.0812	0.4565	-0.4978	-0.4992	0.4804	0.1120	0.0898	0.4847
bias	0.0405	-0.0188	-0.0435	0.0022	0.0008	-0.0196	0.0120	-0.0102	-0.0153
mse	0.0049	0.0048	0.0056	0.0010	0.0005	0.0052	0.0023	0.0033	0.0029
var	0.0033	0.0045	0.0038	0.0010	0.0005	0.0048	0.0021	0.0032	0.0027
		$\alpha = 1.25$			$s = 4$				
		$d = 0.1$	$D = 0.1$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.1$
mean	0.0769	0.0539	0.5162	-0.4857	-0.4991	0.4308	0.0492	0.0489	0.5301
bias	-0.0231	-0.0461	0.0162	0.0143	0.0099	-0.0692	-0.0508	-0.0511	0.0301
mse	0.0018	0.0038	0.0019	0.0007	0.0003	0.0069	0.0035	0.0039	0.0022
var	0.0013	0.0013	0.0017	0.0017	0.0005	0.0021	0.0009	0.0013	0.0013

**Tabela B.39:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$   $\alpha$ -estável, quando  $p = q = 1 = P = Q$ ,  $d = 0.1$ ,  $D = 0.1$ ,  $\phi_1 = 0.5$ ,  $\Phi_1 = -0.5$ ,  $\theta_1 = -0.5$ ,  $\Theta_1 = 0.5$ ,  $\alpha = 1.25$ ,  $s = 6$  e  $N = 500$ .

		$\alpha = 1.25$							
		$s = 6$							
		KM			KMmod				
		$d = 0.1$	$D = 0.1$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.1$
		$d = 0.1$	$D = 0.1$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.1$
mean	0.2390	0.1050	0.3587	-0.4903	-0.5024	0.4557	0.1388	0.0998	0.4526
bias	0.1390	0.1050	-0.1413	0.0097	-0.0024	-0.0443	0.0388	-0.0002	-0.0474
mse	0.0333	0.0221	0.0366	0.0060	0.0055	0.0122	0.0070	0.0085	0.0109
var	0.0140	0.0111	0.0167	0.0059	0.0055	0.0103	0.0055	0.0085	0.0086
mean	0.0743	0.0911	0.4949	-0.4612	-0.4826	0.3602	0.0601	0.0538	0.4971
bias	-0.0257	-0.0089	-0.0051	0.0388	0.0174	-0.1398	-0.0399	-0.0462	-0.0029
mse	0.0054	0.0123	0.0138	0.0133	0.0127	0.0288	0.0106	0.0114	0.0307
var	0.0048	0.0123	0.0138	0.0118	0.0124	0.0092	0.0090	0.0093	0.0307

**Tabela B.40:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$   $\alpha$ -estável, quando  $p = q = 1 = P = Q$ ,  $d = 0.1$ ,  $D = 0.1$ ,  $\phi_1 = 0.5$ ,  $\Phi_1 = -0.5$ ,  $\theta_1 = -0.5$ ,  $\Theta_1 = 0.5$ ,  $\alpha = 1.25$ ,  $s = 6$  e  $N = 1000$ .

		$\alpha = 1.25$							
		$s = 6$							
		KM			KMmod				
		$d = 0.1$	$D = 0.1$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.1$
		$d = 0.1$	$D = 0.1$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.1$
mean	0.1687	0.0778	0.4277	-0.4960	-0.5038	0.4646	0.1171	0.0934	0.4776
bias	0.0687	-0.0222	-0.0723	0.0040	-0.0038	-0.0354	0.0171	-0.0066	-0.0224
mse	0.0114	0.0082	0.0125	0.0016	0.0010	0.0080	0.0036	0.0052	0.0048
var	0.0067	0.0077	0.0073	0.0015	0.0010	0.0068	0.0034	0.0051	0.0043
mean	0.0630	0.0478	0.5243	-0.4761	-0.4955	0.3948	0.0339	0.0271	0.5349
bias	-0.0370	-0.0522	0.0243	0.0239	0.0045	-0.1052	-0.0661	-0.0729	0.0349
mse	0.0035	0.0075	0.0064	0.0018	0.0010	0.0149	0.0061	0.0075	0.0077
var	0.0021	0.0048	0.0059	0.0012	0.0010	0.0039	0.0018	0.0022	0.0065

		$\alpha = 1.25$							
		$s = 6$							
		KM			KMmod				
		$d = 0.1$	$D = 0.1$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.1$
		$d = 0.1$	$D = 0.1$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.1$
mean	0.0687	0.0778	0.4277	-0.4960	-0.5038	0.4646	0.1171	0.0934	0.4776
bias	-0.0222	-0.0723	0.0040	-0.0038	-0.0354	0.0171	-0.0066	-0.0224	0.0015
mse	0.0125	0.0016	0.0010	0.0080	0.0036	0.0052	0.0048	0.0043	0.0055
var	0.0073	0.0015	0.0010	0.0068	0.0034	0.0051	0.0043	0.0049	0.0069
mean	0.0478	0.5243	-0.4761	-0.4955	0.3948	0.0339	0.0271	0.5349	-0.4361
bias	-0.0522	0.0243	0.0239	0.0045	-0.1052	-0.0661	-0.0729	0.0349	0.0639
mse	0.0075	0.0064	0.0018	0.0010	0.0149	0.0061	0.0075	0.0077	0.0175
var	0.0048	0.0059	0.0012	0.0010	0.0039	0.0018	0.0022	0.0065	0.0134

**Tabela B.41:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$   $\alpha$ -estável, quando  $p = q = 1 = P = Q$ ,  $d = 0.1$ ,  $D = 0.1$ ,  $\phi_1 = 0.5$ ,  $\Phi_1 = -0.5$ ,  $\theta_1 = -0.5$ ,  $\Theta_1 = 0.5$ ,  $\alpha = 1.25$ ,  $s = 6$  e  $N = 2000$ .

		$\alpha = 1.25$							
		$s = 6$							
		KM			KMmod				
		$d = 0.1$	$D = 0.1$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.1$
		$d = 0.1$	$D = 0.1$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.1$
mean	0.1312	0.0711	0.4651	-0.4983	-0.5007	0.4665	0.1087	0.0966	0.4880
bias	0.0312	-0.0289	-0.0349	0.0017	-0.0007	-0.0335	0.0087	-0.0034	-0.0120
mse	0.0042	0.0051	0.0050	0.0008	0.0026	0.0057	0.0022	0.0041	0.0049
var	0.0032	0.0043	0.0038	0.0008	0.0026	0.0046	0.0022	0.0041	0.0048
mean	0.0709	0.0424	0.5241	-0.4865	-0.4980	0.4147	0.0364	0.0401	0.5466
bias	-0.0291	-0.0576	0.0241	0.0135	0.0020	-0.0853	-0.0636	-0.0599	0.0466
mse	0.0020	0.0051	0.0021	0.0005	0.0003	0.0093	0.0050	0.0046	0.0034
var	0.0012	0.0018	0.0015	0.0003	0.0003	0.0020	0.0010	0.0011	0.0012

**Tabela B.42:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estável, quando  $p = q = 1 = P = Q$ ,  $d = 0.1$ ,  $D = 0.1$ ,  $\phi_1 = 0.5$ ,  $\Phi_1 = -0.5$ ,  $\theta_1 = -0.5$ ,  $\Theta_1 = 0.5$ ,  $\alpha = 1.25$ ,  $s = 12$  e  $N = 500$ .

		$\alpha = 1.25$							
		$s = 12$							
		KM			KMmod				
		$d = 0.1$	$D = 0.1$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.1$
		$d = 0.1$	$D = 0.1$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.1$
mean	0.3222	0.1535	0.2780	-0.5129	-0.5065	0.3651	0.1294	0.0974	0.4595
bias	0.2222	0.1535	-0.2220	-0.0129	-0.0065	-0.1349	0.0294	-0.0026	-0.0405
mse	0.0635	0.0429	0.0684	0.0044	0.0142	0.0413	0.0063	0.0077	0.0099
var	0.0142	0.0193	0.0192	0.0042	0.0142	0.0231	0.0055	0.0077	0.0083
		KM			KMmod				
		$d = 0.1$	$D = 0.1$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.1$
mean	0.0778	0.1492	0.4832	-0.4808	-0.4943	0.2496	0.0480	0.0227	0.4956
bias	-0.0222	0.0492	-0.0168	0.0192	0.0057	-0.2504	-0.0520	-0.0773	-0.044
mse	0.0055	0.0196	0.0155	0.0075	0.0096	0.0817	0.0074	0.0094	0.0214
var	0.0050	0.0172	0.0152	0.0071	0.0096	0.0190	0.0047	0.0035	0.0214

**Tabela B.43:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) <sub>$s$</sub>   $\alpha$ -estável, quando  $p = q = 1 = P = Q$ ,  $d = 0.1$ ,  $D = 0.1$ ,  $\phi_1 = 0.5$ ,  $\Phi_1 = -0.5$ ,  $\theta_1 = -0.5$ ,  $\Theta_1 = 0.5$ ,  $\alpha = 1.25$ ,  $s = 12$  e  $N = 1000$ .

		$\alpha = 1.25$							
		$s = 12$							
		KM			KMmod				
		$d = 0.1$	$D = 0.1$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.1$
		$d = 0.1$	$D = 0.1$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.1$
mean	0.1969	0.0999	0.4021	-0.4980	-0.5065	0.4451	0.1126	0.0971	0.4628
bias	0.0969	-0.0001	-0.0979	0.0020	-0.0065	-0.0549	0.0126	-0.0029	-0.0172
mse	0.0186	0.0127	0.0200	0.0028	0.0043	0.0105	0.0030	0.0057	0.0043
var	0.0093	0.0127	0.0104	0.0028	0.0042	0.0075	0.0028	0.0057	0.0040
		KM			KMmod				
		$d = 0.1$	$D = 0.1$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.1$
mean	0.0702	0.0984	0.5151	-0.4785	-0.4839	0.3835	0.0335	0.0139	0.5391
bias	-0.0298	-0.0016	0.0151	0.0215	0.0161	-0.1165	-0.0665	-0.0861	-0.4511
mse	0.0041	0.0132	0.0063	0.0055	0.0097	0.0211	0.0063	0.0086	0.0489
var	0.0032	0.0132	0.0060	0.0051	0.0095	0.0076	0.0018	0.0012	0.0039

**Tabela B.44:** Resultado da estimação paramétrica para o processo SARFIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ )<sub>s</sub>  $\alpha$ -estável, quando  $p = q = 1 = P = Q$ ,  $d = 0.1$ ,  $D = 0.1$ ,  $\phi_1 = 0.5$ ,  $\Phi_1 = -0.5$ ,  $\theta_1 = -0.5$ ,  $\Theta_1 = 0.5$ ,  $\alpha = 1.25$ ,  $s = 12$  e  $N = 2000$ .

		$\alpha = 1.25$							
		$s = 12$							
		KM			KMmod				
		$d = 0.1$	$D = 0.1$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.1$
		$d = 0.1$	$D = 0.1$	$\phi_1 = 0.5$	$\Phi_1 = -0.5$	$\theta_1 = -0.5$	$\Theta_1 = 0.5$	$d = 0.1$	$D = 0.1$
mean	0.1332	0.0567	0.4653	-0.4984	-0.5008	0.4444	0.1057	0.0963	0.4912
bias	0.0332	-0.0433	-0.0347	0.0016	-0.0008	-0.0556	0.0057	-0.0037	-0.0988
mse	0.0047	0.0075	0.0061	0.0005	0.0004	0.0076	0.0017	0.0038	0.0035
var	0.0036	0.0056	0.0049	0.0005	0.0004	0.0045	0.0017	0.0038	0.0034
mean	0.0707	0.0462	0.5235	-0.4875	-0.4907	0.4029	0.0407	0.0217	0.5428
bias	-0.0293	-0.0538	0.0235	0.0125	0.0093	-0.0971	-0.0593	-0.0783	0.0428
mse	0.0025	0.0076	0.0028	0.0022	0.0024	0.032	0.0044	0.0069	0.0034
var	0.0016	0.0047	0.0023	0.0020	0.0023	0.0038	0.0009	0.0008	0.0016