



UM ESTUDO SOBRE O PROCEDIMENTO DE DESPACHO E SUA INFLUÊNCIA NA DEGRADAÇÃO DOS EQUIPAMENTOS DAS CENTRAIS HIDRELÉTRICAS

Nara do Nascimento Silva

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Planejamento Energético, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Mestre em Planejamento Energético.

Orientador : André Frossard Pereira de Lucena

Rio de Janeiro
Agosto de 2018

UM ESTUDO SOBRE O PROCEDIMENTO DE DESPACHO E SUA INFLUÊNCIA
NA DEGRADAÇÃO DOS EQUIPAMENTOS DAS CENTRAIS HIDRELÉTRICAS

Nara do Nascimento Silva

DISSERTAÇÃO SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO
LUIZ COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA
(COPPE) DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE
DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE
EM CIÊNCIAS EM PLANEJAMENTO ENERGÉTICO.

Examinada por:

Prof. André Frossard Pereira de Lucena, DSc.

Prof. José Roberto Ribas, DSc

Prof. Alexandre Salem Szklo, DSc.

Prof. Reinaldo de Castro Souza, DSc.

RIO DE JANEIRO, RJ - BRASIL

AGOSTO DE 2018

Silva, Nara do Nascimento

Um estudo sobre o procedimento de despacho e sua influência na degradação dos equipamentos das centrais hidrelétricas/ Nara do Nascimento Silva. – Rio de Janeiro: UFRJ/COPPE, 2018.

XIV, 267 p.: il.; 29,7 cm.

Orientador: André Frossard Pereira de Lucena

Dissertação (mestrado) – UFRJ/ COPPE/ Programa de Planejamento Energético, 2018.

Referências Bibliográficas: p. 109-116.

1. Usinas Hidrelétricas 2. Séries temporais. 3. Degradação dos equipamentos. I. Lucena, André Frossard Pereira de. II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Planejamento Energético. III. Título

AGRADECIMENTOS

Primeiramente, gostaria de agradecer aos meus familiares pelo suporte e apoio durante toda essa jornada, principalmente aos meus pais, a minha madrasta e a minha irmã por estarem presentes durante essa fase da minha vida.

Em segundo lugar, agradeço a todos que tornaram este projeto possível, em especial ao Professor André Frossard Pereira de Lucena e Professor José Roberto Ribas, pela disposição em colaborar sempre que foi preciso.

Aos professores da banca, Professor Reinaldo de Castro Souza e Professor Alexandre Szklo pela disponibilidade de tempo, solicitude ao terem aceitado fazer parte da banca avaliadora e pelos valiosos comentários e sugestões.

Ao professor Wilson Calmon pela contribuição e mentoria no desenvolvimento deste trabalho.

Um especial agradecimento aos colegas do projeto de pesquisa: Juliana Severo, Luciana Guimarães e Gabriel Pino.

Ao Dimitri, meu amigo e companheiro, que está sempre do meu lado para ajudar tanto nos momentos difíceis quanto nos bons momentos da vida.

Aos amigos de turma do PPE que tornaram o mestrado um lugar especial. Vocês tornaram esse percurso muito mais agradável.

A todos os meus amigos pela paciência e compreensão. Em especial à Clara Duque, cuja paciência para atender às minhas dúvidas foi além do que seria razoável.

Aos funcionários do Programa de Planejamento Energético – PPE/COPPE, especialmente a Sandrinha e o Paulo pela atenção e disponibilidade na resolução de questões cruciais para todos os mestrandos.

À Corumbá Concessões S/A e ANEEL pelo apoio financeiro no âmbito do projeto de P&D intitulado "Previsão do Processo de Degradação dos Conjuntos Turbo Geradores das UHEs com Base em Diagramas de Estado: Análise das Contingências e Oscilações de Cargas na Região Geoelétrica”.

Resumo da Dissertação apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

UM ESTUDO SOBRE O PROCEDIMENTO DE DESPACHO E SUA INFLUÊNCIA NA DEGRADAÇÃO DOS EQUIPAMENTOS DAS CENTRAIS HIDRELÉTRICAS

Nara do Nascimento Silva

Agosto/2018

Orientador: André Frossard Pereira de Lucena

Programa: Planejamento Energético

Devido ao aumento da carga e penetração das eólicas, as usinas hidrelétricas (UHE) são cada vez mais solicitadas a atuarem no pico da carga, se adaptando a variação da demanda. Dessa forma, elas podem experimentar entre 10 e 12 ciclos de partidas por dia, o que aumenta a probabilidade do desgaste da máquina, reduzindo a confiabilidade e aumentando os custos de manutenção. Neste cenário, as técnicas de manutenção tradicionais precisam ser reavaliadas e novas opções proativas são mais adequadas e eficientes. Para isso, os dados gerados durante a operação deve ser processados a fim de extrair informações que possam ser usadas no aprimoramento das técnicas de manutenção. Este trabalho buscou fornecer uma curva característica dos dados vibracionais provenientes do mancal guia de uma hidrelétrica. Para tal, os modelos Auto-regressivo de Médias Móveis (ARMA), Auto-regressivos Fracionariamente Integrados com Médias Moveis (ARFIMA) e de Heterocedasticidade Condicional Auto-regressiva (ARCH) foram utilizados no ajuste de uma sequência de séries vibracionais captadas no mancal guia durante partidas sucessivas de uma usina hidrelétrica. A modelagem foi realizada nos dados originais da máquina e após os mesmos terem sido filtrados pela Transformada de Wavelet. Os resultados obtidos mostraram que os dados originais foram melhor ajustados do que as séries filtradas, entretanto, os testes estatísticos do ajustamento se revelaram insatisfatórios decorrente do comportamento quase browniano dos dados.

Abstract of Dissertation presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

A STUDY ON THE DISPATCHING PROCESS AND ITS INFLUENCE ON THE
DEGRADATION OF HYDROELECTRIC POWER PLANTS

Nara do Nascimento Silva

August/2018

Advisor: André Frossard Pereira de Lucena

Department: Energy Planning

Hydroelectric power plants (HPP) are frequently used in peak load hours to stabilize power grid operations. For this reason, peak-load units can experience between 10 and 12 start-stop cycles per day. During the starts, the turbines of the HPP operate in transient states, which may increase the wear and tear of the components. Therefore, more start-stop cycles increase maintenance costs. In this scenario, traditional maintenance techniques may be re-evaluated, and new proactive options should be more appropriate and efficient. For this, it is necessary to process and analyze data from the equipment to extract useful information that can help in equipment maintenance. This study aimed to fit time series models to a waveform data from the rolling bearing of an HPP. In order to do so, the Autoregressive Moving Average model (ARMA), the Autoregressive Fractionally Integrated Moving Average model (ARFIMA) and Autoregressive Conditional Heteroskedasticity model (ARCH) were used. This technique was applied to the original waveform data and to the post Wavelet Transformation data. The results obtained showed that the original data were better adjusted than the filtered, however, the statistical test results were proven to be unsatisfactory, due to the quasi brownian behavior of the data.

SUMÁRIO

1	INTRODUÇÃO	1
2	CARACTERÍSTICAS DO SISTEMA INTERLIGADO NACIONAL (SIN)	4
3	O PLANEJAMENTO DA OPERAÇÃO DO SISTEMA	7
3.1	INSERÇÃO DE ENERGIA EÓLICA NO SIN.....	12
3.2	ASSIMETRIAS DO PROCEDIMENTO DE DESPACHO.....	13
4	UNIDADE HIDRELÉTRICA.....	16
4.1	TURBINAS HIDRELÉTRICAS	17
4.2	PARTIDAS E PARADAS.....	19
4.3	MODELOS DE MANUTENÇÃO	20
4.3.1	MANUTENÇÃO BASEADA NA CONDIÇÃO.....	22
5	PROCEDIMENTO METODOLÓGICO	27
5.1	AQUISIÇÃO DE DADOS	27
5.2	ANÁLISE EXPLORATÓRIA.....	29
5.3	FILTRAGEM DOS DADOS.....	31
5.4	ANÁLISE DE SÉRIES TEMPORAIS	32
5.4.1	CARACTERÍSTICAS DAS SÉRIES TEMPORAIS.....	32
5.4.2	MODELOS DE SÉRIES TEMPORAIS	39
6	ESTUDO DE CASO	52
6.1	BASE DE DADOS	52
6.2	ANÁLISE EXPLORATÓRIA.....	53
6.3	CASO 1- ESTUDO DOS DADOS ORIGINAIS.....	60
6.3.1	PROCESSOS LINEARES	66
6.3.2	PROCESSO COM MEMÓRIA LONGA	69
6.4	CASO 2 - ESTUDO DOS DADOS TRANSIENTE	75
6.4.1	PROCESSOS LINEARES	81
6.4.2	PROCESSO COM MEMÓRIA LONGA	85
6.4.3	MODELOS NÃO-LINEARES	90
6.5	CASO 3- ESTUDO DOS DADOS FILTRADOS	95
6.5.1	PROCESSOS LINEARES.....	102
6.5.2	PROCESSO COM MEMÓRIA LONGA	103
6.6	DISCUSSÃO	109
7	CONCLUSÃO	110

REFERÊNCIAS BIBLIOGRÁFICAS	112
ANEXO I – PROGRAMAS REALIZADOS	120
ANEXO II – ANÁLISE EXPLORATÓRIA DOS DADOS	131
ANEXO III – ANÁLISE DESCRITIVA DAS SÉRIES ORIGINAIS	144
ANEXO IV – MODELOS APLICADOS NAS SÉRIES ORIGINAIS	152
ANEXO V – ANÁLISE DOS DADOS TRANSIENTES ORIGINAIS	176
ANEXO VI – APLICAÇÃO DOS MODELOS NAS SÉRIES TRANSIENTES	186
ANEXO VII – ANÁLISE DESCRITIVA TRANSIENTE FILTRADO	246
ANEXO VIII – ANÁLISE DESCRITIVA TRANSIENTE FILTRADO	256

LISTA DE FIGURAS

Figura 1: Balanço de energia elétrica entre os subsistemas. Fonte: ONS, (2016).....	5
Figura 2: Curvas de Custos Imediatos x Futuro. Fonte: Penna, 2009.	8
Figura 3: Horizonte de planejamento da operação e as suas principais decisões. Fonte: Penna, 2009.	9
Figura 4: Geração de energia eólica durante 11 dias no mês de agosto no Nordeste. Fonte: ONS,2018.	13
Figura 5: Curva de carga horária do dia 17/08/2017. Fonte: ONS, (2017)	14
Figura 6: Estruturas de uma UHE. Fonte: SOUZA, (2014)	16
Figura 7: Componentes de uma turbina Francis.....	19
Figura 8: Relação entre custo de manutenção, confiabilidade do equipamento e tempo de falha. Fonte: Peng, Dong e Zuo, (2010).	22
Figura 9: Diferenciação entre prognóstico e diagnóstico. Fonte: Lee <i>et al.</i> , (2014)	25
Figura 10: Posição dos medidores de vibração no mancal guia. Fonte: Corumbá Concessões, (2018a).....	28
Figura 11: Série de dados vibracionais do mancal guia	29
Figura 12: FAC e FACP teórico do passeio aleatório.	38
Figura 13: FAC e FACP da série teórica do processo AR(1).....	40
Figura 14: FAC e FACP do processo MA (1) teórico.....	42
Figura 15: FAC e FACP teórica de um ARMA(1,1).....	43
Figura 16: Resumo da abordagem adotada. Fonte: Box et al.,(2008)	47
Figura 17: Vista área da usina de Corumbá IV. Fonte: Corumbá Concessões (2018)...	52
Figura 18: Comportamento de uma série original selecionada	54
Figura 19: Comportamento das séries selecionadas após a retirada da componente CC.	54
Figura 20: Comportamento da média em partidas selecionadas.	56
Figura 21: Comportamento do desvio em partidas selecionadas.	57
Figura 22: Comportamento da amplitude em partidas selecionadas.	58
Figura 23: Média das partidas originais	59
Figura 24: Desvio-padrão das partidas originais	59
Figura 25: Valores máximo dos dados originais	60
Figura 26: Histograma das séries selecionadas.	61

Figura 27: Gráfico quantil-quantil das séries selecionadas.	62
Figura 28: FAC das séries originais selecionadas nas direções x e y.....	64
Figura 29: FACP das séries originais selecionadas nas direções x e y	65
Figura 30: Gráficos dos resíduos, da FAC, da FACP e do quantil-quantil residual das séries selecionadas.	67
Figura 31: Resíduos padronizados, FAC e teste de Ljung-Box da série selecionada. ...	68
Figura 32: Estimativa do valor de d com q igual a zero nos dados originais	70
Figura 33: Estimativa do valor de d com q=1	71
Figura 34: Estimativa do valor de d com q=2	72
Figura 35: Resultado dos resíduos do modelo ARFIMA (1,0,3,0) nas séries selecionadas.....	74
Figura 36: Séries de dados selecionadas durante o período transiente.....	75
Figura 37: Histograma das séries transientes selecionadas	76
Figura 38: Gráfico quantil-quantil das séries transientes selecionadas	77
Figura 39: Curvas de autocorrelação das séries transientes selecionadas	79
Figura 40: Curvas de FACP das séries transientes selecionadas.....	80
Figura 41: Processo AR(20) para as séries transientes selecionadas.....	81
Figura 42: Comportamento dos resíduos do ARMA(22,3) das séries selecionadas.	83
Figura 43: Resíduos padronizados, FAC e teste de Ljung-Box da série transiente selecionada.....	84
Figura 44: Estimativa do valor de d com q=0 para os dados transientes	86
Figura 45: Estimativa do valor de d com q=1 para os dados transientes	87
Figura 46: Modelos ARFIMA com q igual a dois para os dados transientes.....	88
Figura 47: Verificação modelo ARFIMA(12,0,14,14) para as séries selecionadas	90
Figura 48: Resíduos quadrados, FAC e FACP residuais quadradas do ARMA(22,3) nas séries selecionadas.....	91
Figura 49: Resultado do teste de LM- ARCH para os resíduos padronizados.....	92
Figura 50: Resultado do ARMA(22,3) ARCH(22) para a série transiente selecionada. 94	
Figura 51: Séries filtradas selecionadas no transiente.....	96
Figura 52: Histograma das séries filtradas selecionadas no transiente.....	97
Figura 53: Gráfico quantil-quantil das séries filtradas selecionadas no transiente.....	98
Figura 54: FAC das séries filtradas selecionadas no transiente	100
Figura 55: FACP das séries filtradas selecionadas no transiente	101

Figura 56: AR(60) para séries filtradas selecionadas no transiente.....	102
Figura 57: FAC e FACP diferenciadas nos dados filtrados	103
Figura 58: Estimativa d com q=0 para os dados filtrados	104
Figura 59: Estimativa d para q=1 nos dados filtrados	105
Figura 60: Estimativa d para q=2 nos dados filtrados	106
Figura 61: Estimativa d para q=2 nos dados filtrados para p entre 20 e 40.	107
Figura 62: Modelo ARFIMA(30,0,1,10) das séries filtradas selecionadas no transiente	108

LISTA DE TABELAS

Tabela 1: Capacidade instalada no Brasil em março de 2018. Fonte: ANEEL, (2018)...	6
Tabela 2: Resumo do comportamento teórico dos modelos AR, MA e ARMA. Fonte: BOX et al., (2008)	45
Tabela 3: Variância residual dos modelos estimados.....	66
Tabela 4: Modelos testados na técnica da sobreposição.....	82
Tabela 5: Modelos estimados e suas respectivas variâncias.....	89

LISTA DE QUADROS

Quadro 1: Teste de normalidade de Anderson-Darling nas séries selecionadas	63
Quadro 2: Teste de normalidade de Anderson-Darling nas séries selecionadas	78
Quadro 3: Teste de normalidade de Anderson-Darling nas séries filtradas selecionadas	99

LISTA DE ABREVIATURAS E SIGLAS

ANEEL – Agência Nacional de Energia Elétrica

AR – Auto-regressivo

ARCH – Heterocedasticidade Condicional Auto-regressiva

ARFIMA – Auto-regressivos Fracionariamente Integrados com Médias Móveis

ARMA – Auto-regressivo de Médias Móveis

FAC – Função de Autocorrelação

FACP – Função de Autocorrelação parcial

FCF – Função de Custo Futuro

FCI – Função de Custo Imediato

GARCH – Heterocedasticidade Condicional Auto-regressiva Generalizada

MA – Médias Móveis

MBC – Manutenção Baseada na Condição

MCC – Manutenção Centrada na Confiabilidade

ONS – Operador Nacional do Sistema

SAG – Sistema Automático de Geração

SIN – Sistema Interligado Nacional

UG – Unidade Geradora

UHE – Usina Hidrelétrica

1 INTRODUÇÃO

O Sistema Interligado Nacional (SIN) é um sistema de produção e transmissão de energia, formado por usinas, linhas de transmissão e ativos de distribuição. É essencialmente hidrotérmico de grande porte, com predominância de usinas hidrelétricas (UHE) e com múltiplos proprietários. A sua operação é coordenada e controlada pelo Operador Nacional do Sistema Elétrico (ONS), formado pelas companhias geradoras e transmissoras e fiscalizado pela ANEEL (ANEEL, 2008a).

O planejamento da operação do sistema tem como objetivo a minimização dos custos de operação ao longo de um determinado intervalo de tempo, respeitando as restrições hidráulicas e elétricas e atendendo à demanda do mercado com um determinado risco de déficit pré-estabelecido. O despacho é centralizado, ou seja, o operador (ONS) decide quais usinas serão acionadas. Como não existe oferta de preço para as geradoras, estas declaram sua disponibilidade e o operador calcula o custo de oportunidade de cada uma, executando um modelo de despacho e considerando todas elas como sendo de um único proprietário. O custo de oportunidade, ou valor d'água, representa o preço atribuído a este recurso, definindo a ordem de despacho hidrotérmico (CARVALHO, 2002).

Devido a sua grande complexidade, o sistema é decomposto em diferentes períodos temporais de acordo com suas características físicas e incertezas. Essa divisão visa determinar o despacho ótimo para o atendimento da carga, levando em conta a capacidade de produção das usinas geradoras e de transformação e de transmissão do sistema (ENCINA, 2006; OHISHI, 1990).

O planejamento da operação diária define a quantidade de energia elétrica que cada unidade deve gerar a fim de atender a carga prevista para cada hora. Ao longo do dia, o número de unidades geradoras se altera devido ao comportamento variável da carga. Quando a carga está baixa, menos unidades são comprometidas. Entretanto, o aumento da carga nos horários de pico compromete mais da capacidade das usinas em operação e pode até requisitar um número maior de geradoras (ENCINA, 2006).

As UHEs podem atuar na base ou no pico da carga. A primeira opção tem com condições constantes de operação, enquanto a segunda opera em ambiente flexível, variando a geração de acordo com a demanda. Por sua vez, as hidrelétricas com turbinas Francis são requisitadas a atuar na zona de pico devido a sua flexibilidade, ou seja, elas conseguem aumentar ou diminuir sua carga rapidamente (EPRI, 2017).

Associado a isso, a recente penetração das usinas eólicas promoveu o uso das hidrelétricas no pico da carga. As últimas apresentam intermitências de geração, que não podem ser previstas pelo operador na programação diária e em tempo real. Assim, as usinas hidrelétricas são usadas na mitigação dessa variabilidade gerada pela eólica (ONS, 2017a).

Nessas condições, a quantidade de partidas e paradas aumenta consideravelmente, podendo chegar a 10 ciclos por dia. Tipicamente, as turbinas Francis de base tem em média 1-2 ciclos por dia (TRIVEDI; GANDHI; MICHEL, 2013).

Durante os ciclos de partidas e paradas, as usinas passam pela faixa transiente. Nessa região a turbina experimenta ciclos de *stress* assimétricos, vibrações, desgaste, diminuição da vida útil e aumento nos custos de operação (ENCINA, 2006), fazendo com que as partidas e paradas sejam momentos danosos para turbinas Francis (TRIVEDI; GANDHI; MICHEL, 2013).

Como o impacto econômico da falha em um equipamento pode até mesmo superar o custo de um novo, as manutenções baseadas na condição (MBC) são cada vez mais comuns (STACK; HABETLER; HARLEY, 2003). Esta é uma estratégia que busca evitar manutenções desnecessárias, recomendando reparos somente quando o equipamento apresenta comportamento anormal (JARDINE; LIN; BANJEVIC, 2006).

A sua aplicação é realizada em três etapas: aquisição dos dados; processamento dos dados e decisão de manutenção. A aquisição de dados consiste na coleta e armazenamento das informações captadas, podendo ser dados vibracionais, acústicos, de temperatura, pressão e etc (JARDINE; LIN; BANJEVIC, 2006). Salienta-se que os dados vibracionais são os mais utilizados no monitoramento do mancal guia de UHE (STACK; HABETLER; HARLEY, 2003).

O processamento de dados consiste na limpeza e análise das informações obtidas. A limpeza elimina os erros que podem afetar o resultado da modelagem futura, podendo ser feita por verificação manual ou por gráficos. O próximo passo consiste na aplicação de modelos ou algoritmos na análise e interpretação dos dados captados. Os modelos utilizados dependem principalmente do tipo de dado captado. Para as análises no domínio do tempo, por exemplo, uma das abordagens mais utilizadas são os modelos de séries temporais, que buscam adequar os dados em séries temporais paramétricas e extrair características de acordo com o modelo paramétrico. Entre eles, os modelos mais

conhecidos são os auto-regressivos e os auto-regressivos de médias móveis (JARDINE; LIN; BANJEVIC, 2006).

Finalmente, a última etapa da MBC é o tratamento dos sinais, que busca oferecer suporte para as decisões do operador. Pode ser dividido em diagnóstico e prognóstico. O diagnóstico foca na detecção das falhas após a sua ocorrência, buscando o reconhecimento do padrão do defeito. Por outro lado, o prognóstico foca na previsão das falhas antes que elas ocorram, tendo como alvo a estimativa da vida útil remanescente do equipamento (JARDINE; LIN; BANJEVIC, 2006).

Diante do que foi exposto, este trabalho busca ajustar modelos de séries temporais aos dados de vibração gerados durante as partidas de uma hidrelétrica, a fim de analisar o efeito do aumento do número de partidas na degradação do mancal guia de uma turbina Francis. Para tal, pretende-se estabelecer uma função utilizando os modelos de séries temporais aplicados a um estudo de caso.

Como estudo de caso, a metodologia será aplicada em dados reais da operação da UHE de Corumbá IV.

Este trabalho está organizado da seguinte forma:

O capítulo 2 descreve o sistema elétrico brasileiro, a sua estrutura, suas principais características e as assimetrias causadas em UHE próximas ao centro de carga. O capítulo 3 aborda as características das unidades hidrelétricas e das turbinas Francis. Associado a isso, apresenta os tipos de manutenção existentes e seus objetivos. O capítulo 4 descreve os modelos temporais utilizados, tais quais: o ARMA(p,q), o ARFIMA(p,d,q) e o ARCH/GARCH. O capítulo 5 apresenta a aplicação das séries temporais nos estudos de caso. E, por fim, o capítulo 6 apresenta as conclusões obtidas nesse trabalho.

2 CARACTERÍSTICAS DO SISTEMA INTERLIGADO NACIONAL (SIN)

Segundo o ONS (2018), o Sistema Interligado Nacional (SIN) é um sistema de produção e transmissão de eletricidade, formado por geradoras, linhas de transmissão e ativos de distribuição. É essencialmente hidro-térmico-eólico de grande porte, com predominância de usinas hidrelétricas e com múltiplos proprietários. Ele conecta as regiões Sul, Sudeste, Centro-Oeste, Nordeste e uma parte do Norte. Atualmente menos de 1,0% da energia elétrica requerida encontra-se no sistema isolado ou fora do SIN, sendo que a maior parte está localizada na região norte onde há a presença de floresta densa e heterogênea, além dos rios caudalosos, que impedem a construção de linhas de transmissão.

A operação do SIN é coordenada e controlada pelo ONS, realizada pelas companhias geradoras e transmissoras e fiscalizada pela ANEEL. A conexão entre as regiões tem como principal benefício a troca de energia elétrica entre elas, uma vez que estas apresentam regimes hidrológicos diferentes, assim, a região que se encontra com reservatórios cheios envia eletricidade para aquela com reservatórios mais vazios. Esse intercâmbio de energia elétrica permite a otimização do "estoque de energia elétrica" represado sob a forma de água e aumenta a confiabilidade do sistema (ANEEL, 2008a; ONS, 2017a).

Outra vantagem do SIN é a possibilidade de as hidrelétricas, termelétricas e eólicas agirem de forma complementar. As termelétricas costumam ficar de reserva atuando como um reforço em momentos de pico de demanda ou em períodos em que é preciso preservar o nível dos reservatórios. Também podem atuar estabilizando a carga elétrica da rede (ANEEL, 2008a). Por sua vez, no Nordeste, as eólicas atuam durante condições hidrológicas críticas, possibilitando, o replecionamento de alguns reservatórios, como aconteceu nos últimos anos (ONS, 2017a).

O SIN está dividido em quatro subsistemas principais: o *Subsistema Sudeste/Centro-Oeste*, que é o principal demandante e importador de energia; o *Subsistema Sul*, que possui grande variabilidade de armazenamento e é exportador de energia elétrica para o subsistema Sudeste/Centro-Oeste; o *Subsistema Nordeste*, que dependendo das condições hidrológicas, pode atuar tanto como importador quanto exportador e, por fim, o *Subsistema Norte* que é principalmente exportador (DEUS,

2008). A Figura 1 mostra o balanço de energia elétrica entre esses subsistemas, exibindo as características de cada região.

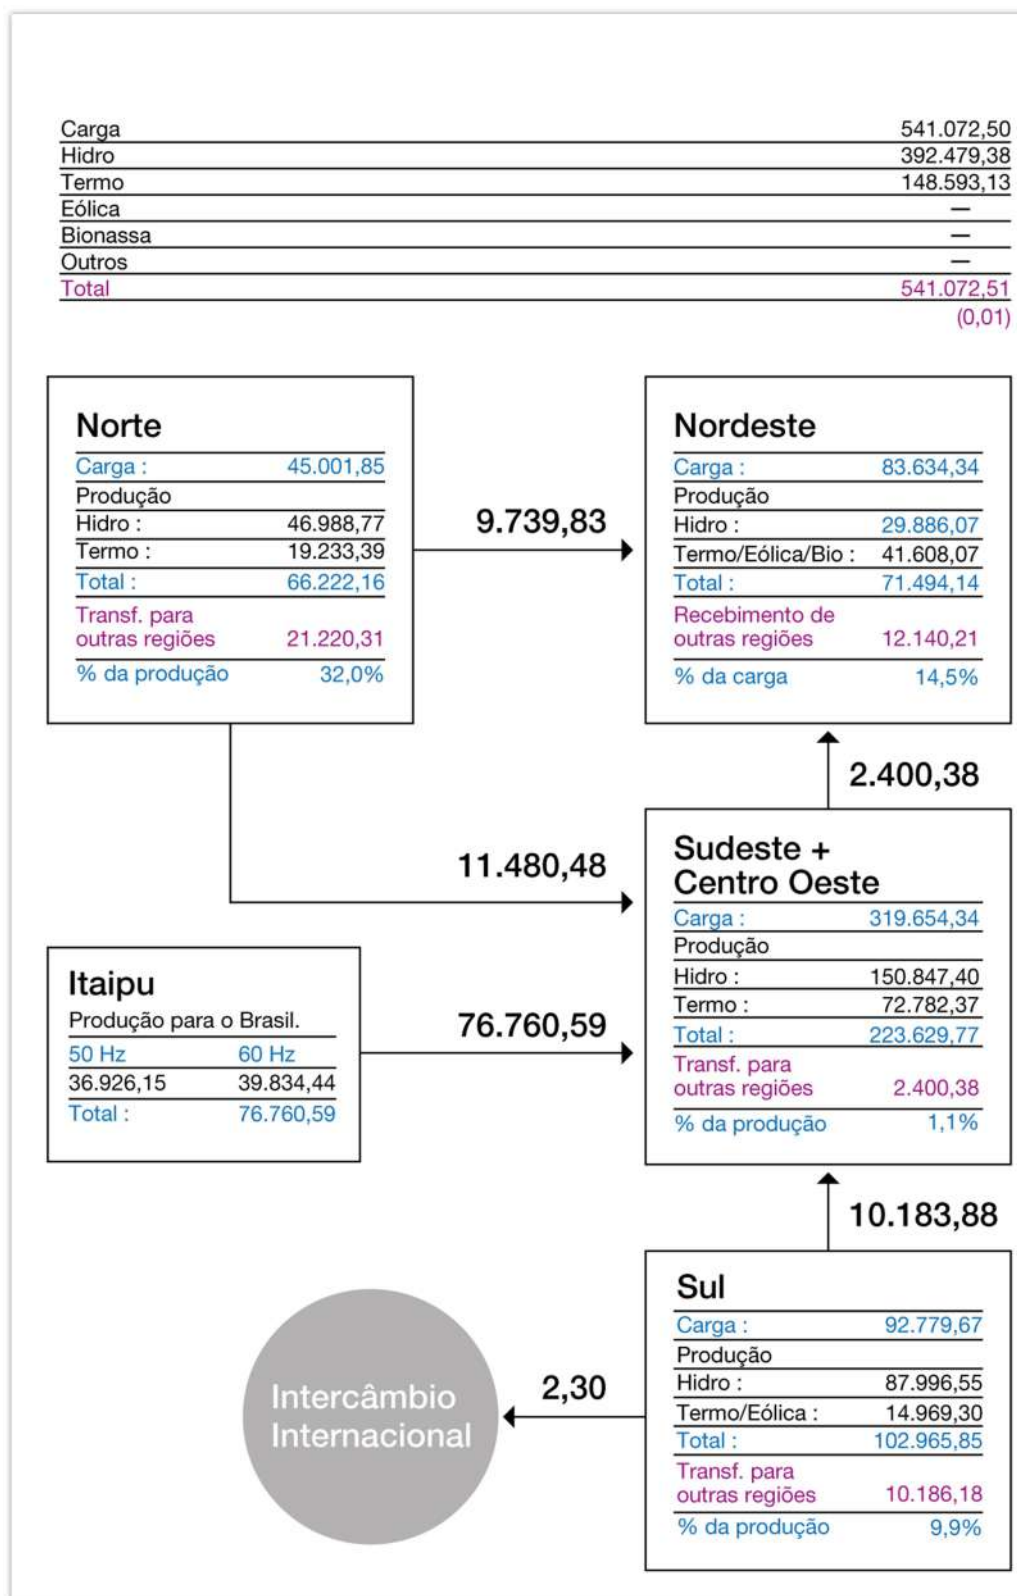


Figura 1: Balanço de energia elétrica entre os subsistemas. Fonte: ONS, (2016)

Atualmente, o país possui 4.916 unidades produtoras de energia, sendo o parque gerador formado por usinas hidrelétricas, pequenas centrais hidrelétricas, centrais geradoras hidrelétricas, usinas termelétricas, usinas termonucleares e entre outras, conforme pode ser visto na Tabela 1.

Salienta-se que, nos últimos anos, houve aumento da quantidade de usinas eólicas instaladas no país. Atualmente elas representam 7,9% da matriz energética, mas espera-se que esse valor alcance 9,7% , equivalente a 16.205MW de energia, até 2021 (ONS, 2017a).

Tabela 1: Capacidade instalada no Brasil em março de 2018. Fonte: ANEEL, (2018)

Tipo	Quantidade	% do total	Potência instalada (kW) ^{1/}	% do total
Usina Hidrelétrica de Energia – UHE	220	4,5	95.619.468	60,4
Pequena Central Hidrelétrica – PCH	429	8,7	5.042.723	3,2
Central Geradora Hidrelétrica – CGH ^{2/}	670	13,6	627.355	0,4
Central Geradora Undi-elétrica - CGU	1	0,0	50	0,0
Usina Termelétrica de Energia – UTE	3.002	61,1	41.539.113	26,2
Usina Termonuclear – UTN	2	0,0	1.990.000	1,3
Central Geradora Eolielétrica – EOL	511	10,4	12.537.943	7,9
Central Geradora Solar Fotovoltaica – UFV ^{3/}	81	1,6	935.325	0,6
Total	4.916	100	158.291.976	100

De um modo geral, o SIN atua de forma integrada, evitando vertimentos nos reservatórios das usinas, minimizando a utilização das termelétricas e equalizando os custos marginais de operação entre as regiões. Sua operação é centralizada e busca a minimização o custo total, tomando decisões operativas no presente baseadas na configuração esperada do sistema no futuro. Por meio de estudos de planejamento e otimização, busca-se garantir o menor custo, a confiabilidade do sistema, a quantidade e a qualidade de energia elétrica requerida pelo mercado (DEUS, 2008).

3 O PLANEJAMENTO DA OPERAÇÃO DO SISTEMA

A operação do Sistema Interligado é uma atividade complexa feita pelo ONS e tem como principal objetivo a preservação da segurança operativa do SIN ao mesmo tempo que promove a utilização ótima dos recursos disponíveis (geração hidrelétrica, termelétrica e as redes de transmissão).

O sistema é composto por usinas com grandes reservatórios, dependendo de regimes com afluições aleatórias. Nessas condições, o operador deve definir o montante de complementação termelétrica a cada intervalo de tempo, o intercâmbio entre os vizinhos e a porcentagem de geração hidrelétrica, com o intuito de minimizar os gastos com combustíveis das térmicas, eventuais compras de eletricidade e custo de déficit (não atendimento à demanda) (CARVALHO, 2002; PENNA, 2009; SORIANO, 2016)

A principal complexidade do planejamento da operação do sistema está relacionada com a incerteza das vazões afluentes futuras, que podem colocar a operação em risco de ineficiência. Se o operador decide guardar a água para usar no futuro e ocorre altas vazões, pode ser necessário verter o excedente, caracterizando-se desperdício de energia guardada. Por outro lado, caso a decisão do operador seja a de usar a água no presente e ocorram vazões reduzidas no futuro, então, pode ser necessário aumentar a complementaridade termelétrica com unidades mais dispendiosas. Portanto, o planejamento de operação é um processo dinâmico, no qual o operador precisa determinar a utilização dos recursos hidrelétricos disponíveis no presente, assegurando a melhor complementação termelétrica no presente e no futuro (D'ARAÚJO, 2009; ENCINA, 1999; QUEIROZ, 2016; RODRIGUES, 2003; SOARES FILHO, 1987).

O acoplamento operativo entre usinas em uma mesma bacia também aumenta a complexidade do planejamento do sistema, uma vez que a operação de uma unidade depende das demais. A grande extensão dos rios brasileiros permite que existam usinas em sequência no mesmo rio e que, conseqüentemente, a água efluente de uma seja parte importante da afluição da unidade imediatamente a jusante no rio (D'ARAÚJO, 2009). Em vista disso, as hidrelétricas constituem-se de um sistema interconectado de geração, no qual suas unidades são dependentes entre si (CARVALHO, 2002; CICOGNA, 2003; ENCINA, 2006; SOARES FILHO, 1987).

O planejamento também deve considerar as restrições do uso múltiplo da água como para a navegação, a irrigação, o controle das cheias, o saneamento e entre outros (CARVALHO, 2002).

A solução ótima do sistema apresenta o equilíbrio entre o benefício do uso da água no presente e o benefício futuro do seu armazenamento. O benefício associado a utilização da água no presente pode ser representado pela Função de Custo Imediato (FCI), enquanto que o benefício do seu armazenamento pode ser descrito pela Função de Custo Futuro (FCF). A Figura 2 mostra o comportamento de ambas funções, sendo que a abscissa representa o volume final armazenado nos reservatórios das hidrelétricas e a ordenada apresenta os valores de FCI e FCF expressos em unidades monetárias. Salienta-se que o FCI aumenta com o volume armazenado, uma vez que a economia da água no presente representa aumento dos gastos com térmicas. Por outro lado, o FCF decresce com o volume armazenado, visto que a economia da água no presente faz com que os gastos com as termelétricas sejam menores no futuro (CARVALHO, 2002; PENNA, 2009; SORIANO, 2016).




Figura 2: Curvas de Custos Imediatos x Futuro. Fonte: Penna, 2009.

O valor que otimiza o uso da água corresponde ao ponto onde as derivadas das FCF e FCI se igualam em módulo. Assim, o uso ótimo da água é o ponto onde a soma dos custos imediatos e futuros é mínima, conforme Figura 2. É importante ressaltar que a interligação entre sistemas vizinhos reduz o custo de operação e aumenta a

confiabilidade do fornecimento, em razão do intercâmbio de energia elétrica e da repartição das reservas (PENNA, 2009; SORIANO, 2016).

Devido à sua grande complexidade e à dificuldade de considerar todos os aspectos do problema em um único modelo, o planejamento da operação foi dividido em seis subproblemas com diferentes horizontes de planejamento e graus de detalhamento, sendo estes de longo prazo, de médio prazo, de curto prazo, diário ou pré-despacho e operação em tempo real (BORGES, 2010). Vale ressaltar que quanto mais distante o horizonte de planejamento, maiores são as incertezas e menor o grau de detalhamento (CEPEL, 2013). A Figura 3 mostra os diferentes horizontes de planejamento e as principais decisões associadas com cada estágio.

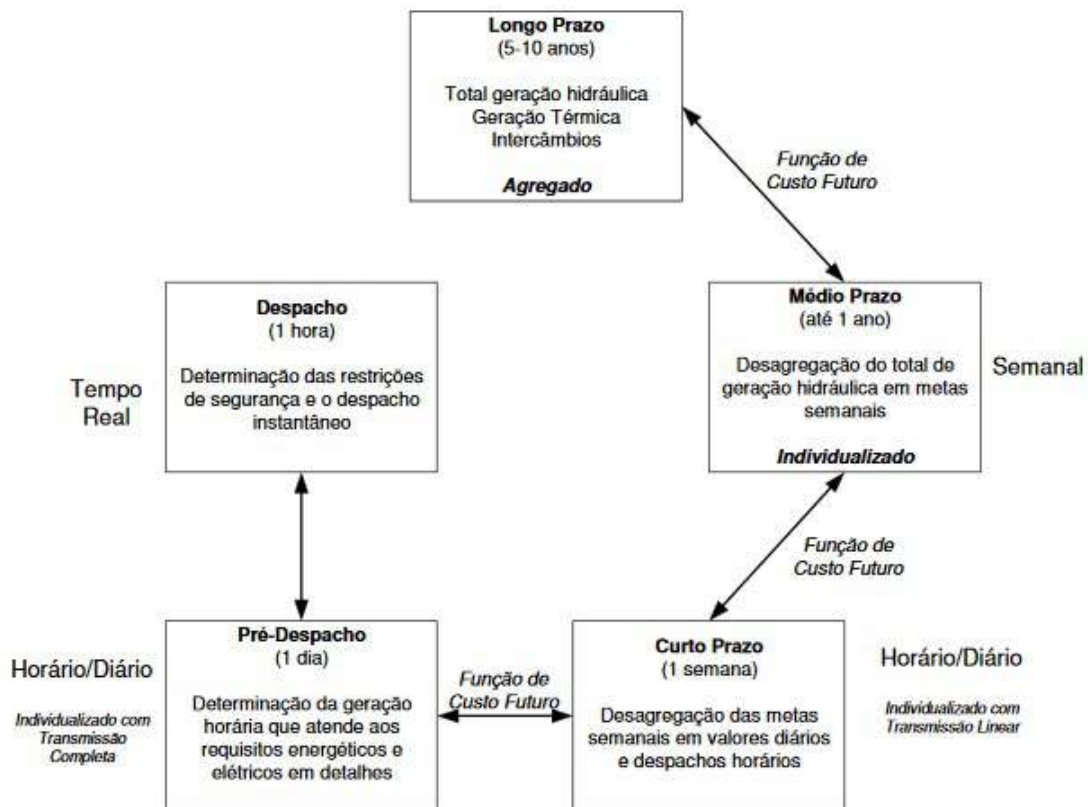


Figura 3: Horizonte de planejamento da operação e as suas principais decisões. Fonte: Penna, 2009.

O planejamento da operação de longo prazo fornece o valor esperado das gerações hidrelétricas e das termelétricas no futuro, o intercâmbio entre os subsistemas e a possibilidade de déficit no sistema (ENCINA, 2006; RODRIGUES, 2003). A otimização do problema é realizada pelo software NEWAVE. Os diversos reservatórios são agregados em um reservatório equivalente de energia representando os quatro

subsistemas. A solução é obtida por programação dinâmica estocástica (CEPEL, 2013; MACEIRA et al., 2002; SORIANO, 2016).

O planejamento da operação de médio prazo determina, através do software DECOMP, as metas semanais de cada usina, de forma a minimizar o custo operacional do sistema. O programa é formulado como um problema de programação linear e considera a demanda especificada, as restrições operativas e as metas definidas no planejamento de longo prazo (CEPEL, 2018a; ENCINA, 2006; MACEIRA et al., 2002).

O planejamento da operação de curto prazo define a operação do sistema com uma semana de antecedência, por isso requer uma representação mais detalhada do sistema. Nesta etapa, a solução ótima do problema é encontrada utilizando o software DESSEM-PAT, que leva em consideração a rede elétrica e suas limitações operativas como, por exemplo, o sistema hidráulico, o transporte da água entre os reservatórios, as limitações das tomadas d'água e entre outros. Neste caso, o problema pode ser considerado praticamente determinístico, devido a boa previsibilidade das aflúncias e da demanda de carga (CEPEL, 2018b; ENCINA, 2006; MACEIRA et al., 2002; SOARES FILHO, 1987)

O planejamento diário da operação (pré-despacho) estipula os programas diários da carga, da geração e do intercâmbio que sejam compatíveis com as metas traçadas pelos planejamentos de ordem superior (ENCINA, 2006). Devido ao horizonte pequeno, considera as condições operativas, hidráulicas e elétricas do sistema em um cenário de vazões e de demandas determinísticas. Além disso, essa etapa define quais unidades devem estar em operação ao longo da programação e estabelece a configuração da rede, o suporte reativo e a preparação para as ações preventivas e corretivas do despacho em tempo real (KADOWAKI, 2012; MACEIRA et al., 2002; PEREIRA et al., 1987; SOARES FILHO, 1987).

A operação em tempo real (despacho) define as cargas para os geradores do parque em cada intervalo de tempo, considerando o atendimento da carga, a capacidade de produção das usinas e a capacidade de transformação e de transmissão do sistema (ENCINA, 2006; OHISHI, 1990).

Portanto, esta seção apresentou algumas das dificuldades enfrentadas pelo planejamento da operação do sistema. Devido a sua alta complexidade, o problema é discretizado de acordo com o horizonte temporal, buscando facilitar a determinação do despacho ótimo e atender as restrições operativas impostas.

3.1 INSERÇÃO DE ENERGIA EÓLICA NO SIN

Nos últimos anos, houve aumento de usinas eólicas no SIN. No Nordeste, por exemplo, a geração eólica foi responsável pelo atendimento de 70% da base horária e 40% base mensal (ONS, 2017a). Todavia, a sua alta variabilidade e sua limitada previsibilidade originam novos desafios para a operação em tempo real (DEMEO et al., 2005).

Associado a isso, essa fonte apresenta intermitência em intervalos curtos de tempo (ONS, 2017a). Ao longo de uma semana, ela pode gerar energia elétrica acima da média diária em um dia e abaixo da média em outro, conforme na Figura 4 (STEINBERGER, 2012). Como a energia elétrica só é gerada quando os ventos sopram, ela não pode ser despachada pelo operador (DEMEO et al., 2005). Outro fator importante é que essa intermitência não pode ser prevista pelo operador na programação diária e na operação em tempo real. Atualmente, as usinas hidrelétricas do Sistema de Automático de Geração¹ (SAG) do Sudeste/Centro-Oeste são usadas na mitigação da variabilidade causada pelas eólicas (ONS, 2017a).

¹ Busca regular a frequência do sistema, de forma a manter o equilíbrio de geração e dos intercâmbios programados através de recursos de controle que atuam em centrais geradoras.

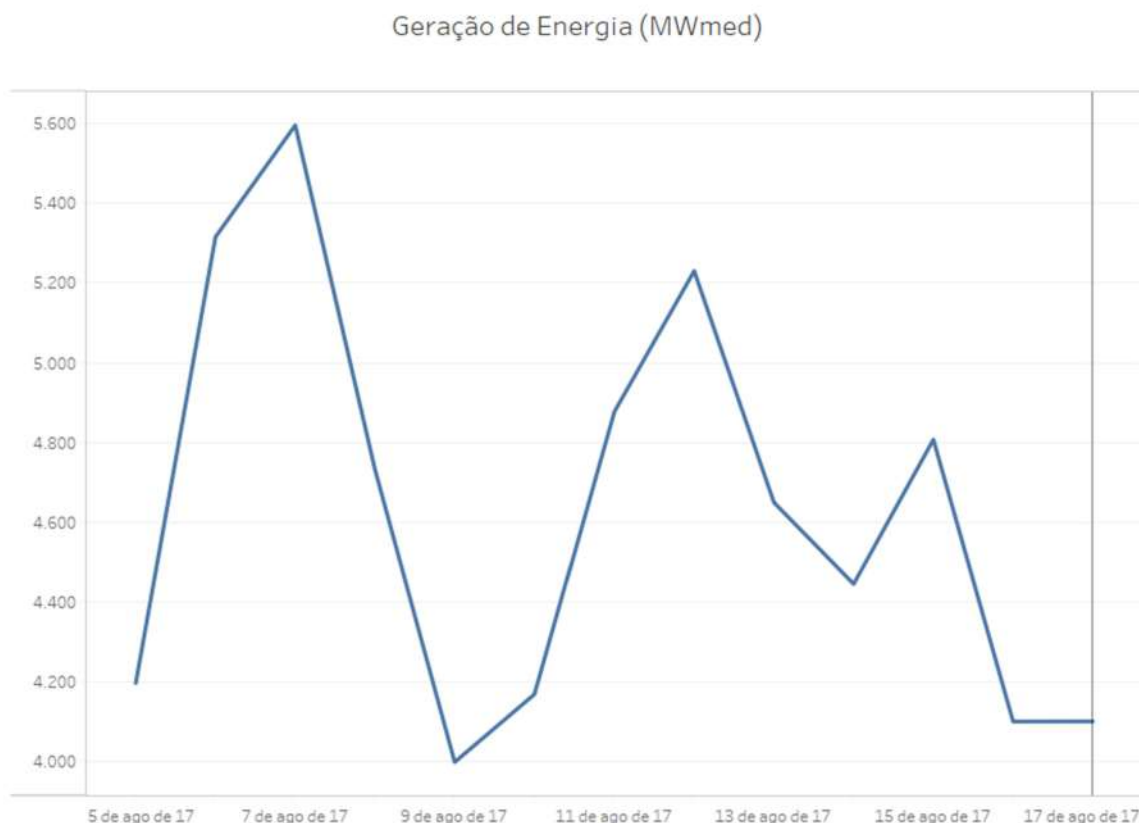


Figura 4: Geração de energia eólica durante 11 dias no mês de agosto no Nordeste.

Fonte: ONS,2018.

3.2 ASSIMETRIAS DO PROCEDIMENTO DE DESPACHO

O planejamento da operação diária define a quantidade de eletricidade que cada usina deverá gerar a fim de atender a carga prevista para cada hora do dia. Com o aumento da demanda e a penetração de fontes intermitentes como a eólica e a solar, as hidrelétricas são cada vez utilizadas nas zonas de pico. Elas podem atuar na base, com condições constantes de operação, ou no pico da carga, com operação flexível, variando a geração de acordo com a demanda.

Ao longo do dia o número de unidades geradoras muda de acordo com a curva de carga. A Figura 5 mostra a variação da carga no SIN no dia 17 de agosto de 2017. Pode-se perceber que no período entre 0:00-6:00, a carga está leve, logo, as usinas em operação podem comprometer menos as suas capacidades. Todavia, o aumento da carga ao longo do dia faz com que seja necessário comprometer mais da capacidade das geradoras e até requisitar um número maior de unidades.

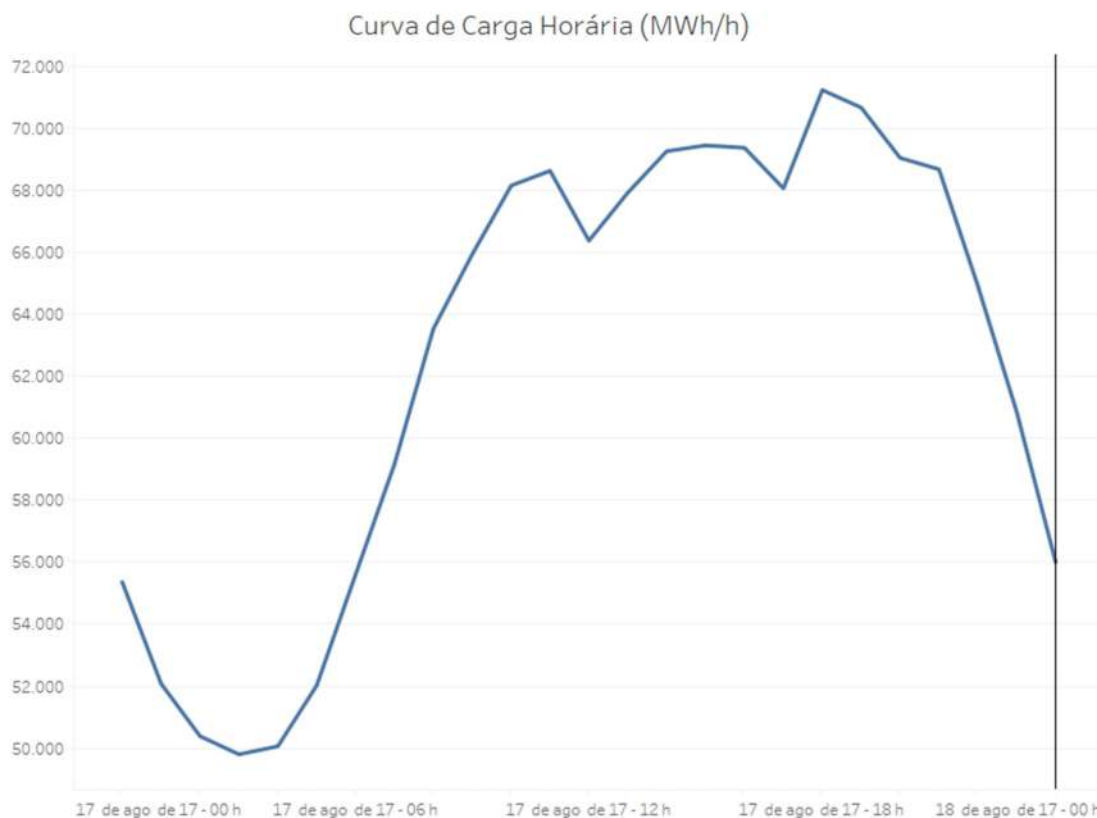


Figura 5: Curva de carga horária do dia 17/08/2017. Fonte: ONS, (2017)

Por causa da sua flexibilidade, as UHEs são solicitadas a suprir a variação da carga, o que ocasiona aumento no número das partidas/paradas das mesmas. Normalmente, usinas que operam na base apresentam 1-2 ciclos de partida/parada por dia, enquanto que as unidades que operam em zonas de pico experimentam entre 10-12 ciclos por dia (EPRI, 2017; TRIVEDI; GANDHI; MICHEL, 2013).

Associado a isso, o uso das hidrelétricas na mitigação da variabilidade e da imprevisibilidade das eólicas também provoca o aumento dos ciclos de partidas e paradas (EPRI, 2017).

Durante esses ciclos, as usinas passam pela faixa transiente. Nesta região, as turbinas experimentam ciclos de *stress* assimétricos, vibrações, desgaste e entre outros. Conforme Poll, Zanutto e Ponge-Ferreira (2006), a operação das turbinas Francis em condições variáveis aumenta a probabilidade de surgirem rachaduras nos equipamentos.

Segundo Nilsson e Sjelvgren (1997), sucessivas partidas e paradas afetam o custo de manutenção ao causar degradação nos equipamentos mecânicos e falha nas máquinas de controle. De um modo geral, estima-se o custo de cada partida em torno de \$3 por MW da capacidade nominal da máquina.

Porém, de acordo com Bjorkvoll e Bakken (2002), cada partida causa abrasão equivalente a um certa quantidade de horas de operação. Por isso, o custo da partida deve aumentar com o tempo de operação da usina, uma vez que reduz o período entre manutenções e a vida útil da máquina.

Por fim, essa seção abordou a assimetria do Sistema Interligado Nacional, evidenciando que hidráulicas que operam na zona de pico apresentam um maior número dos ciclos de partidas e paradas e, conseqüentemente, um maior gasto com manutenções.

4 UNIDADE HIDRELÉTRICA

Usinas hidrelétricas são tecnologias de energia renováveis que geram eletricidade a partir da energia potencial da água. Elas podem ser classificadas de acordo com a sua altura de queda d'água, da vazão, da capacidade ou potência instalada, do tipo de turbina e entre outros. Salienta-se que esses fatores são interdependentes entre si, uma vez que a turbina designada depende da altura de queda d'água e da localização (ANEEL, 2008b).

Normalmente, uma UHE é composta pela barragem, pelo sistema de captação e indução de água, pela casa de força, pelo sistema de restituição da água ao leito do rio e pelo vertedouro, conforme Figura 6.

A barragem tem objetivo de interromper o fluxo normal do rio criando um reservatório de água. Dessa forma, ela gera o desnível necessário entre a montante do rio e o canal de fuga a jusante. O reservatório também pode ser usado para regularização da vazão dos rios em épocas de chuva ou estiagem. As usinas a fio d'água não possuem acúmulo do recurso hídrico e sua geração de energia elétrica ocorre com o fluxo de água do rio (ANEEL, 2008b).




Figura 6: Estruturas de uma UHE. Fonte: SOUZA, (2014)

Os sistemas de captação e adução de água são formados por túneis, canais ou condutos metálicos e tem como principal objetivo conduzir a água do reservatório à casa de força, onde estão localizadas as turbinas, os geradores e os equipamentos

elétricos, de proteção, de controle e de serviços auxiliares. Normalmente esses sistemas possuem uma grade na entrada do canal para evitar que objetos entrem no duto e danifiquem as unidades geradoras (RISSI, 2009).

Na casa de força é onde ocorre a transformação da energia potencial em elétrica pelo movimento das turbinas. Basicamente, elas são pás conectadas a um eixo ligado ao gerador (ANEEL, 2008b). Salienta-se que cada conjunto de turbina e gerador consiste em uma unidade geradora (UG).

Por fim, o vertedouro é o canal por onde a água é liberada sem passar pela casa de força. Isso ocorre quando o seu armazenamento na represa pode comprometer a estrutura física da barragem, ou quando é preciso manter a vazão a jusante do rio e o volume não é turbinável (RISSI, 2009).

4.1 TURBINAS HIDRELÉTRICAS

A turbina é o principal equipamento de uma UHE. Ela converte a energia potencial da água em energia mecânica, que aciona o gerador e produz eletricidade (ENCINA, 1999) (ANEEL, 2008a).

É constituída pela caixa espiral, pelo pré-distribuidor, pelo distribuidor, pelo rotor e pelo tubo de sucção. Proveniente do conduto forçado, a água entra na turbina pela caixa espiral. Depois, segue para o pré-distribuidor onde é direcionada para o distribuidor. Neste ponto, a sua vazão é regulada e a água é distribuída igualmente nas pás do rotor, que acionam o gerador ao se movimentarem. Após a passagem pelo rotor, a água sai pelo duto de sucção e retorna ao leito do rio pelo canal de fuga (SCHAEFFER, 2016)

Existem quatro tipos principais de turbinas: Pelton, Kaplan, Francis e Bulbo. Cada uma é escolhida de acordo com a faixa de altura da queda e da vazão do projeto. Elas são divididas em turbinas de ação e de reação dependendo da forma como o rotor é acionado (ONUDI, 2016).

As turbinas Pelton, por exemplo, são indicadas para regiões com quedas variando entre 350 a 1.100m. Elas podem ter entre um a quatro injetores, que ajustam a vazão turbinada. O eixo pode ser na posição horizontal ou vertical. Geralmente o arranjo mais utilizado apresenta dois injetores com eixo horizontal (SCHAEFFER, 2016).

As turbinas Kaplan são indicadas para regiões com alturas entre 3 a 60m. Elas apresentam uma regulagem independente devido ao sistema de orientação em suas pás no rotor, assim, possuem ótimas características de operação mesmo em cargas parciais.

As turbinas Bulbo são indicadas para lugares com baixa queda e alto fluxo. Elas são usadas em alturas entre 5-20m e podem atingir até 50 MW de potência. Permitem a minimização da área alagada por causa do seu gerador acoplado.

Por fim, as Francis são indicadas para alturas entre 40-400m. por isso são as mais utilizadas no Brasil. Elas são turbinas de reação, que transformam a energia potencial em mecânica no rotor (SCHAEFFER, 2016). Também possuem um tubo de sucção que mantém a continuidade da massa líquida em escoamento, desde a saída do rotor até o nível da água do poço, impedindo que a água caia livremente.

Além dos componentes citados, as turbinas possuem os mancais: guia superior, escora e guia da turbina, conforme mostra a Figura 7. Basicamente eles oferecem sustentação e suporte para o eixo da unidade. O mancal guia, por exemplo, tem a função de manter o eixo girando dentro de uma determinada região e de resistir aos carregamentos radiais, minimizando o desbalanceamento do eixo girante (CORUMBÁ CONCESSÕES, 2018a).

O mancal guia é composto pela carcaça, pelos segmentos, pela postiça e pela tubulação. Os segmentos são revertidos com material patente e estão sujeitos à pressão hidrodinâmica do filme de óleo lubrificante, que reduz a fricção e refrigera a superfície em que ocorre o atrito da parte girante e não-girante da turbina. Existe ainda um sistema de refrigeração para manter a temperatura dentro dos níveis razoáveis prevenindo o aquecimento do mancal e deterioração do óleo.




Figura 7: Componentes de uma turbina Francis

4.2 PARTIDAS E PARADAS

A maioria das UHEs foram projetadas para atuar em condições estáveis de operação. Mas a sua capacidade de restaurar a rede rapidamente, aliado com o aumento da demanda e a inserção das eólicas ocasionaram mudanças significativas nas condições originais (LIU; LUO; WANG, 2016).

Em média, a operação na base exibe 1-2 ciclos de partida e parada por dia, pouca operação a vazio e baixa carga, 25% em carga intermediária, 40% próximo à melhor eficiência e 25% em carga alta. Por outro lado, a operação no pico apresenta 10-12 ciclos de partidas e paradas, 4% da operação a vazio, 24% em baixa carga, 24% em intermediária, 24% em alta e 24% próximo à melhor eficiência (SEIDEL et al., 2014). Essas diferenças nas características operativas causaram a redução na confiabilidade da máquina e aumento dos riscos financeiros e dos custos de manutenção (EPRI, 2017).

Durante a partida, a máquina opera temporariamente no estado transiente. Neste momento, a aceleração e desaceleração do rotor induz forças transientes que podem causar fadiga nos equipamentos, em função disso, este é um dos momentos mais

danosos da operação (GAGNON et al., 2010; TRIVEDI; GANDHI; MICHEL, 2013). Uma partida pode reduzir a vida útil do equipamento tanto quanto anos de operação em condições normais (LIU; LUO; WANG, 2016).

Por sua vez, os mancais guias são mais susceptíveis a problemas devido as forças e vibrações causadas pelos fluidos. O seu desgaste aumenta as vibrações nos eixos laterais, que, potencialmente, aceleram as formações de trincas por fadiga no eixo da turbina. Também fornecem carga adicional ao gerador, que aceleram a fadiga no eixo e em seus componentes (EPRI, 2017; PINO; RIBAS; GUIMARÃES, 2018).

O impacto econômico da falha do mancal representa um risco financeiro para a usina, uma vez que o reparo ou troca pode ser mais caro do que a compra de um novo (STACK; HABETLER; HARLEY, 2003).

O recente aumento do número dos ciclos de partidas e paradas tornou as usinas mais suscetíveis a ocorrência de problemas, reduzindo a confiabilidade e aumentando os gastos com manutenções. Portanto, os métodos tradicionais de inspeção não são adequados as novas condições operacionais. Por isso, novas tecnologias e estratégias de manutenção devem ser usadas para averiguar a presença de danos nos equipamentos (EPRI, 2017).

A próxima seção discutirá os principais modelos de manutenção utilizados no estudo da saúde do equipamento.

4.3 MODELOS DE MANUTENÇÃO

Manutenção é todo conjunto de ações realizadas a fim de manter os ativos físicos em condições desejáveis de operação. Ela busca otimizar o ciclo de vida do ativo físico ou equipamento, maximizando a sua disponibilidade e confiabilidade (PINTELON; PARODI-HERZ, 2008).

A estratégia mais comum consiste em ações reativas que, basicamente, esperam o equipamento quebrar para realizar a manutenção corretiva, sem que haja uma análise ou uma investigação da causa ou da natureza do problema (HANSEN; HALL; KURTZ, 1994; LEE et al., 2014; SUH; KUMARA; MYSORE, 1999). Normalmente, essa estratégia é usada somente em equipamentos que não são críticos (LEE; WANG, 2008). E tem como desvantagem a redução da confiabilidade do sistema e o aumento do custo de manutenção do equipamento (KOTHAMASU et al., 2006).

Por sua vez, a manutenção preventiva busca desacelerar o processo de degradação, prevenindo falhas através da aplicação de rotinas e procedimentos realizados em períodos fixos no tempo sem considerar a condição do item. O cronograma de manutenção é definido levando em conta diversas variáveis tais como os dados históricos, a experiência do operador e entre outras. Essa estratégia promove a redução da probabilidade de falha ou da degradação do sistema. Mas, também pode gerar manutenções prematuras em equipamentos sem degradação e uma não-otimização dos custos (KOTHAMASU et al., 2006; LE, 2015; LEE et al., 2014; PENG; DONG; ZUO, 2010)

Atualmente, esses métodos estão sendo substituídos por políticas mais eficientes. A manutenção preditiva, por exemplo, promove a melhora no desempenho do sistema e o aumento da eficiência do cronograma de revisão. Dessa forma, essa estratégia segue um cronograma de manutenção baseado no monitoramento da saúde do equipamento (KOTHAMASU et al., 2006). Neste caso, a correção ocorre somente quando os indicadores analisados atingem um determinado patamar.

A manutenção preditiva pode ser descrita como um processo que visa restaurar a máquina ao seu estado original ou suficientemente bom. Ela pode ser dividida em manutenção centrada na confiabilidade (MCC) e manutenção baseada na condição (MBC).

A MCC visa aprimorar a confiabilidade do sistema estabelecendo o intervalo entre revisões e determinando quais atividades de correção são efetivas. Ela é usada em sistemas nos quais as informações históricas não podem ser usadas para prever a saúde do equipamento. Desta forma, utiliza ferramenta como FMEA (*Failure Mode and Effect Analysis*) para obter informações que possibilitem a previsão do intervalo entre manutenções (LEE et al., 2014).

A MBC usa os dados coletados de equipamentos individuais para identificar possíveis problemas em seus estágios iniciais e prever a sua evolução. A correção é realizada somente quando há evidência de comportamento anormal no equipamento. Isso ocorre quando o seu estado de degradação está próximo do limite de segurança indicado pelo fabricante (LE, 2015; LEE et al., 2014; PENG; DONG; ZUO, 2010; ZIO; COMPARE, 2013). Associado a isso, ela fornece informações que podem melhorar o cronograma de manutenção, reduzindo o tempo de inatividade do equipamento (LEE; WANG, 2008).

O cronograma fornecido pelo MBC é o resultado da relação entre o custo de manutenção, a confiabilidade do sistema e a previsão acurada da vida útil remanescente do equipamento, conforme Figura 8. Quando o tempo de falha se aproxima de zero, a confiabilidade do sistema diminui. O melhor momento para realizar a manutenção ocorre quando a confiabilidade do sistema começa a decair significativamente (PENG; DONG; ZUO, 2010).

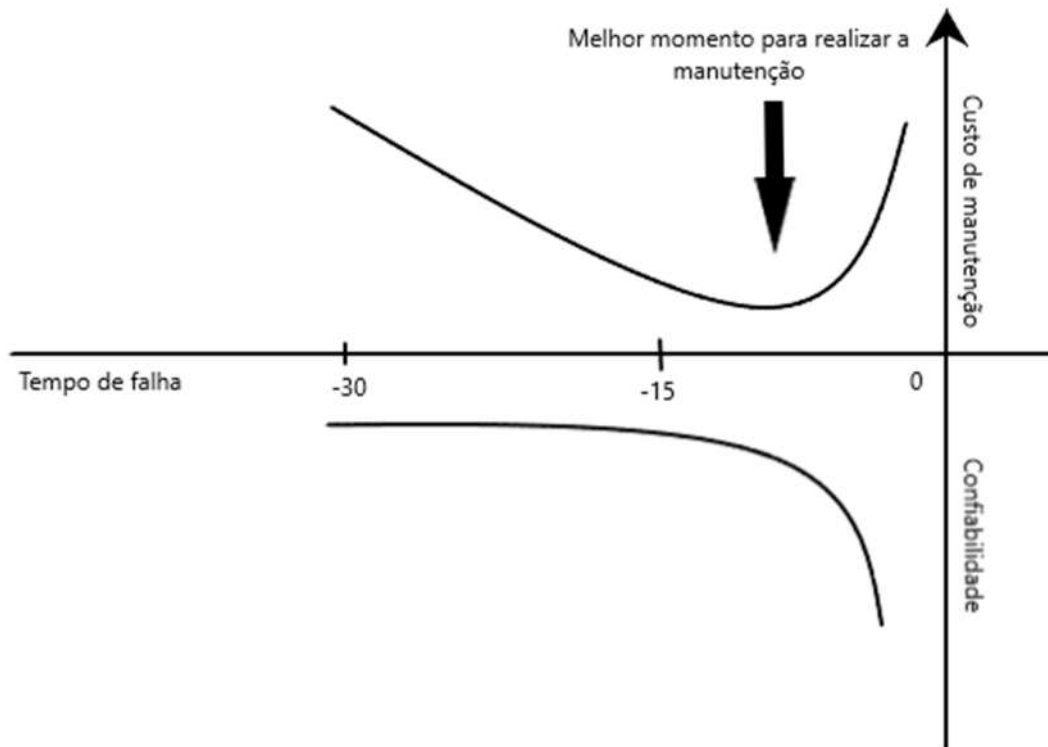


Figura 8: Relação entre custo de manutenção, confiabilidade do equipamento e tempo de falha. Fonte: Peng, Dong e Zuo, (2010).

4.3.1 MANUTENÇÃO BASEADA NA CONDIÇÃO

Existem três passos principais para a aplicação da MBC: a aquisição de dados, quando os dados são coletados e armazenados; o processamento dos dados, quando ocorre a limpeza e tratamento dos sinais; e, por fim, a decisão de manutenção, quando ocorre a otimização da política de manutenção (BOUSDEKIS et al., 2015; JARDINE; LIN; BANJEVIC, 2006). Esses passos serão explicados separadamente nas próximas seções.

4.3.1.1 AQUISIÇÃO DE DADOS

Este passo consiste na captação e no armazenamento dos dados proveniente dos ativos físicos. Eles podem ser provenientes de um evento específico ou do monitoramento da saúde do equipamento. O primeiro apresenta informações sobre o que aconteceu com a máquina. E o segundo representa a saúde ou estado físico do equipamento (JARDINE; LIN; BANJEVIC, 2006).

Ainda segundo os mesmos autores, o monitoramento da condição pode ser feito por diferentes fontes de sinais tais como de vibração, de temperatura, de emissão acústica, amostra do óleo lubrificante, entre outros. Entre esses, as mais utilizadas são as análises dos dados de vibração, das amostras de óleo lubrificante e das emissões acústicas.

A vibração ocorre quando a frequência natural do eixo da máquina combina com as frequências dos componentes em flutuação. É um movimento periódico formado pela amplitude e pela frequência. A amplitude estabelece a severidade e a frequência indica a causa ou natureza. O monitoramento por meio dos dados vibracionais apresenta excelente capacidade de inferir a saúde do equipamento uma vez que é possível visualizar a mudança da tendência dos sinais na presença de um defeito (WANG, 2008).

Em UHEs, uma das técnicas de aquisição mais efetiva é o monitoramento das vibrações nos mancais da turbina e do gerador. Elas são captadas e monitoradas pelos sensores instalados nos equipamentos. Em geral, podem ser causadas por desbalanceamento, desalinhamento da linha do eixo, cavitação e entre outros. O desbalanceamento da máquina ocorre quando o peso do rotor não está igualmente dividido na linha de centro, provocando vibrações radiais que aumentam com a frequência de rotação (MOHANTA et al., 2017). Durante as partidas e paradas, a máquina encontra-se mais suscetível a sofrer com o desbalanceamento e a cavitação da turbina, uma vez que está operando fora do seu ponto nominal (CORUMBÁ CONCESSÕES, 2018a).

Vale ressaltar que as vibração em hidrelétricas podem variar dependendo de diversas variáveis tais como a turbina, o local da medida, as condições operacionais e entre outras (WU et al., 2013).

Em resumo, as vibrações podem conter informações sobre a saúde do equipamento. Portanto, o seu estudo permite a identificação de problemas nos estágios

iniciais e pode prevenir paradas não-programadas (STACK; HABETLER; HARLEY, 2003).

4.3.1.2 PROCESSAMENTO DE DADOS

O primeiro passo dessa etapa é a limpeza dos sinais, que retira possíveis erros ocasionados por diferentes fatores. Em geral, não é facilmente realizada pois requer a inspeção manual ou por ferramentas gráficas. É um passo importante pois garante que os erros gerados no processo não serão analisados e modelados (JARDINE; LIN; BANJEVIC, 2006).

O segundo passo é a análise dos dados captados. Existe uma variedade de modelos que podem ser aplicados, sendo que a técnica escolhida depende basicamente do tipo do sinal extraído. Eles podem ser investigados através de três enfoques diferentes: pelo domínio do tempo, pelo domínio da frequência e pela análise tempo-frequência.

Tradicionalmente, a análise pelo domínio temporal estuda as características estatísticas tais como média, desvio-padrão, amplitude e entre outras. Atualmente, uma nova abordagem utiliza os dados passados para explicar os valores futuros. Ela é usada para modelar dados estacionários buscando extrair algumas características dos sinais captados por meio de uma curva paramétrica. A técnica mais conhecida é o processo Auto-Regressivo de Médias Movéis (ARMA) (JARDINE; LIN; BANJEVIC, 2006).

Ainda segundo os mesmo autores, a análise pelo domínio da frequência é realizada em dados não-paramétricos. Esta abordagem permite o isolamento e a identificação de certas frequências separadamente, assim, é possível extrair determinadas características dos dados. Os métodos mais utilizados são a análise espectral e a transformada de Fast-Fourier.

O estudo pelo domínio do tempo-frequência é usado, principalmente, para sinais não-estacionários. Este domínio utiliza duas funções de distribuição para a visualização das características das falhas (LEE; WANG, 2008). O método mais utilizado é a Transformada de Short Fourier, que divide o sinal em segmentos com pequenas janelas de tempo e aplica a Transformada de Fourier em cada parte (JARDINE; LIN; BANJEVIC, 2006).

Portanto, existem diferentes técnicas que podem ser aplicadas no processamento dos dados. Os resultados obtidos nesta fase fornecem informações que podem ser

usadas no diagnóstico da máquina ou na previsão da vida útil remanescente do equipamento (WANG, 2008). Essa etapa será descrita em detalhes na próxima seção.

4.3.1.3 TRATAMENTO DOS SINAIS

A última etapa da MBC é o tratamento de sinais, que busca oferecer um suporte para as decisões tomadas pelo operador. Essa etapa pode ser dividida em duas principais categorias: diagnóstico e prognóstico (JARDINE; LIN; BANJEVIC, 2006).

Basicamente, o diagnóstico é um processo reativo, ou seja, acontece após a ocorrência de um problema. Ele compara os resultados obtidos do processamento de dados com as características pré-definidas. Desta forma, consegue fornecer informações sobre atual saúde do equipamento investigado (BOUSDEKIS et al., 2015).

Por outro lado, o prognóstico é um processo ativo, que lida com a previsão da falha antes que ela aconteça. Ele é capaz de fornecer informações sobre o desempenho do equipamento ou sistema, sobre a vida útil restante (quando ele irá falhar), sobre a possível natureza e causa da falha (LEE et al., 2014; PENG; DONG; ZUO, 2010).

A Figura 9 ilustra a diferença entre o diagnóstico e o prognóstico. Nota-se que a degradação avança com o tempo até atingir a falha. A partir disso, o processo diagnóstico investiga as características do equipamento. Em contrapartida, o prognóstico atua antes da ocorrência da falha, usando os dados históricos para prever a degradação e a vida útil remanescente (LEE et al., 2014).




Figura 9: Diferenciação entre prognóstico e diagnóstico. Fonte: Lee *et al.*, (2014)

Portanto, o uso da MBC permite que ações sejam tomadas a fim de evitar a ocorrência da falha em um equipamento. O método mais utilizado é a análise dos dados vibracionais. Em UHE, as vibrações podem ser coletadas nos mancais guia do conjunto turbina-gerador. O resultado obtido, após o processamento, pode ser comparado com dados históricos ou pré-definidos a fim de extrair informações que possam aumentar a confiabilidade do sistema e reduzir os custos de manutenção.

Diante do que foi exposto, este trabalho buscou modelar os dados vibracionais do mancal guia de uma unidade geradora a fim de analisar o efeito do número de partidas na degradação do mancal guia de uma turbina Francis. .

5 PROCEDIMENTO METODOLÓGICO

Este capítulo aborda o procedimento metodológico que será usado na modelagem de séries vibracionais captadas durante as partidas sequenciais de uma UG. Os dados serão captados por sensores dispostos no mancal guia de uma hidrelétrica, que foi escolhido devido a sua importância para os custos de manutenção da geradora.

Primeiro, as séries captadas serão analisadas exploratoriamente com o intuito de verificar suas tendências. Depois, elas serão filtradas pela Transformada de *Wavelet*. Por fim, os modelos lineares (AR, MA, ARMA) e de memória longa (ARFIMA) serão aplicados tanto nas séries originais quanto nas séries após a filtragem. Em caso de heterocedasticidade, os modelos não-lineares, ARCH ou GARCH, serão utilizados para ajustar a variância.

O software R será utilizado em todos os estudos (R CORE TEAM, 2017).

Os coeficientes dos modelos lineares serão calculados usando a função *arima* do pacote *forecast* (HYNDMAN; KHANDAKAR, 2008).

No processo ARFIMA, os parâmetros serão estimados pela função *fracdiff* do pacote *fracdiff* (Fraleley et al., 2012). Os coeficientes serão calculados pela função *diffseries*, do mesmo pacote, associada com a função *arima*.

Por último, as estimativas dos coeficientes dos modelos não-lineares serão feitas por meio da função *ugarchfit* do pacote *Rugarch* (GHALANOS, 2018). Os procedimentos desenvolvidos nesse estudo estão dispostos no ANEXO I.

5.1 AQUISIÇÃO DE DADOS

A aquisição dos dados ocorrerá nos primeiros cinco minutos da partida de uma turbina. Ela será realizada por equipamentos de monitoramento de sinais instalados. Assim, busca-se uma amostra sequencial de partidas da máquina durante um determinado período do tempo.

Em hidrelétricas, o monitoramento é feito por sensores de vibração absoluta e relativa instalados nos mancais guia. Os sensores de vibração absoluta têm como objetivo medir a vibração causada pela passagem da água desde o reservatório a montante até a jusante. Eles consistem de acelerômetros instalados nas partes não-girantes, como, por exemplo, nas fixações dos mancais guia do gerador e da turbina e

medem a vibração absoluta dos mancais frente a um referencial inercial (CORUMBÁ CONCESSÕES, 2018a).

Os sensores de vibração relativa visam monitorar a vibração do eixo por meio da medição da distância instantânea entre a cabeça do sensor, fixada no mancal guia da turbina, e a superfície metálica mais externa. Usualmente são instalados entre 2 a 4 sensores ao longo da superfície perimetral do eixo a fim de acoplar as diferentes medições e formar a órbita de trajetória do eixo da máquina. Os medidores são posicionados em uma posição defasada de 90° entre si e de 45° com a vertical como mostrado na Figura 10 (CORUMBÁ CONCESSÕES, 2018a; TANDON; PAREY, 2006)




Figura 10: Posição dos medidores de vibração no mancal guia. Fonte: Corumbá Concessões, (2018a)

Os dados vibracionais captados variam seu comportamento de acordo com o regime operacional da máquina. No período permanente, a velocidade de rotação, abertura do distribuidor e a posição das pás são constantes. Desta forma, as forças que surgem são periódicas ou constantes em magnitude e direção. Por outro lado, no período transiente, ocorre a alteração das variáveis citadas e surgem forças não periódicas causadoras de impulsos com diferentes duração (VLADISLAVLEV et al., 1979).

No regime permanente, as propriedades estatísticas devem ser constantes ao longo do tempo. A média, por exemplo, tende a zero, uma vez que a amplitude apresenta valores positivos e negativos com proporções parecidas (VLADISLAVLEV et al., 1979). A Figura 11 apresenta as vibrações do mancal guia durante a partida da máquina. Após os 200 segundos, a máquina entra no período permanente e os valores oscilam ao redor de zero.

No regime transiente, as propriedades estatísticas devem ser em função do tempo. Ainda na Figura 11, pode-se perceber que entre os 50-200 segundos, a máquina opera no período transiente, como consequência, os valores captados são instáveis.




Figura 11: Série de dados vibracionais do mancal guia

5.2 ANÁLISE EXPLORATÓRIA

Basicamente, a análise exploratória busca evidenciar as principais características estatísticas dos dados, inferir sobre o modelo a ser utilizado, detectar comportamentos anômalos e a estacionariedade das séries. Esse estudo inicial pode ser feito por meio de medidas descritivas como de tendência central (média, percentis e quartis), ou de dispersão (amplitude, variância e desvio-padrão). Neste estudo, ele será realizado nos dados vibracionais originais provenientes de uma UHE.

A representação gráfica dos dados obtidos mostra o comportamento da série em função do tempo. Ela evidencia a presença de tendências crescentes ou decrescentes, estacionariedade, mudanças bruscas de comportamento e *outliers*². Neste trabalho, busca-se, principalmente, avaliar como as séries variam conforme o número de partidas.

Entre as medidas de tendência central, a média é a soma de todos os valores dividido pela quantidade. Cada conjunto de dados apresenta uma única média, que varia

² São dados atípicos, que se diferenciam dos outros da série. Eles podem causar anomalias nos resultados estatísticos. Por isso, indica-se que sejam retirados antes da análise.

de acordo com a série analisada. É importante salientar que essa medida é altamente influenciada por valores extremos, o que pode gerar distorção nos resultados.

Neste trabalho, a média será verificada de duas maneiras diferentes. Primeiro, o seu comportamento ao longo do tempo em cada partida será analisado a fim de verificar os períodos operacionais da máquina. Depois, a sua tendência conforme o número de partidas será analisada pelo gráfico das médias.

Por sua vez, as medidas de dispersão representam a variabilidade do conjunto de dados. Para conjuntos com grande dispersão, os valores tendem a ser maiores, enquanto que conjuntos com pequena dispersão tendem a ser valores próximos a média. Um exemplo de medida de dispersão é a amplitude, que é calculada pela diferença entre o valor máximo e mínimo.

Outra medida de dispersão é a variância, que representa a volatilidade da amostra. Quanto mais volátil, maior será o seu valor. Ela tem como dimensão o quadrado da unidade original. Por isso, utiliza-se, com mais frequência, o desvio-padrão.

Neste trabalho, este último será analisado da mesma forma que a média. Primeiro, com a análise do seu comportamento ao longo de cada partida e, depois, com o gráfico de tendências conforme o número de partidas.

Resumidamente, a média, a amplitude e o desvio-padrão serão usadas para descrever o comportamento dos dados nos diferentes regimes de operação da máquina. Espera-se que, no período transiente, os dados apresentem estatísticas variáveis, enquanto que, no período permanente, os dados tendam a zero. Também serão calculadas as tendências da média, do desvio-padrão e dos valores máximos a fim de verificar como as séries variam conforme o número de partidas.

5.3 FILTRAGEM DOS DADOS

A filtragem dos dados deve eliminar os ruídos gerados durante a aquisição e processamento dos dados. Inicialmente, ruídos térmicos são gerados por causa da baixa velocidade nominal das usinas. Em seguida, a captação dos sinais por sensores de proximidade indutivo atenuam os sinais de alta frequência. Associado a isso, a maioria dos processadores de sinais e conversores analógico-digital comerciais opera com frequência de corte de 20kHz, o que gera ruído de contato devido à baixa qualidade do sinal. Por último, o buffer de memória usado para adquirir e guardar os cinco minutos dos dados captados também interfere na qualidade do sinal (PINO; RIBAS; GUIMARÃES, 2018).

Os sensores de proximidade indutivo são transdutores sem contato usados para medir o deslocamento de uma estrutura vibrante. O sinal proveniente desses sensores é composto da componente alternada (CA) e componente contínua (CC). A CA representa o movimento da superfície metálica em relação à ponta do sensor. Por sua vez, a CC representa a distância média do eixo em relação ao sensor. Ambas componentes são importantes, no entanto a componente CA é a mais interessante para análise das vibrações (COSTA; SENA; MESQUITA, 2010).

Assim, neste trabalho, a CC será retirada antes da aplicação dos processos estocásticos, utilizando o valor médio do sinal em regime permanente (PINO; RIBAS; GUIMARÃES, 2018).

Depois, a filtragem da componente CA será realizada com a transformada de Wavelet, uma vez que os sinais não são estacionários e não podem ser filtrados por técnicas convencionais. Embora os dados sejam discretos, a Equação 1 contínua melhor se adaptou ao sinal (PINO; RIBAS; GUIMARÃES, 2018).

$$\mathcal{W}[x(t)] = X(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} x(t) \psi\left(\frac{t-b}{a}\right) dt \quad \text{Equação 1}$$

Onde $\psi \equiv \psi(t)$ é a função *mother Wavelet*, “a” é o parâmetro da frequência da dilatação e “b” é o parâmetro relacionado com a mudança para o domínio do tempo (PINO; RIBAS; GUIMARÃES, 2018)

5.4 ANÁLISE DE SÉRIES TEMPORAIS

Este capítulo discute sobre os processos que serão usados na modelagem dos dados captados. Isso inclui as principais características das séries temporais tais como a estacionariedade e a função de autocorrelação. Os modelos abordados serão: a) Auto-Regressivo (AR); b) Médias móveis (MA); c) Auto-regressivo de médias móveis (ARMA) e d) Auto-regressivo integrado de médias móveis (ARIMA); por fim, e) Modelos fracionariamente integrados de memória longa. Além disso, serão abordados os modelos não-lineares, que analisam a volatilidade como, por exemplo, modelo auto-regressivo de heterocedasticidade condicional (ARCH) e *generalized* ARCH.

5.4.1 CARACTÉRISTICAS DAS SÉRIES TEMPORAIS

Os processos estocásticos são sequências de observações que evoluem com o tempo e/ou espaço seguindo as leis da probabilidade. Por sua vez, uma série temporal pode ser considerada como uma realização amostral do processo estocástico. Ela é um conjunto de observações ordenadas no tempo, na qual os valores apresentam dependência serial (SOUZA; CAMARGO, 2004). Elas podem ser encontradas em diversas áreas do conhecimento como, por exemplo, os valores diários de temperatura de uma cidade, os índices diários da Bolsa de Valores, a quantidade de venda de automóveis.

De um modo geral, o estudo das séries temporais busca analisar e modelar a dependência serial entre os valores, tendo como objetivo a investigação do mecanismo gerador da série, a descrição do comportamento, a previsão dos dados futuros baseado nos dados passados e a verificação de existência de alguma periodicidade relevante nos dados (MORETTIN; TOLOI, 2004).

Ainda segundo os mesmos autores, independentemente do objetivo, o modelo construído deve ser simples, parcimonioso e probabilístico. Em outras palavras, ele deve ser simples para facilitar o aprendizado dos valores futuros, deve apresentar o menor número de parâmetros possíveis (parcimônia) e, por último, deve ser um processo estocástico.

Antes de descrever as séries temporais é preciso introduzir algumas características como a normalidade, estacionariedade, independência entre os valores, passeio aleatório e ruído branco.

5.4.1.1 NORMALIDADE

Uma série apresenta normalidade quando a sua distribuição de probabilidade segue uma curva normal (distribuição de Gauss ou Gaussiana). E quando a sua função de densidade de probabilidade (fdp) pode ser descrita pela Equação 2, sendo “ μ ”, a média e “ σ^2 ”, a variância .

$$f(x) = (2\pi\sigma^2)^{1/2} \exp\left(-\frac{(x - \mu)^2}{2\sigma^2}\right) \quad \text{Equação 2}$$

Para $-\infty < x < +\infty$ e $\sigma > 0$. A função de densidade da distribuição é convenientemente expressa por $N(\mu, \sigma^2)$.

Uma das propriedades da distribuição normal é que a função de densidade da distribuição apresenta a forma de sino com simetria em relação a μ e achatamento determinado por σ^2 . Se σ for relativamente grande então o gráfico tende a ser “achatado”, enquanto que se σ for relativamente pequeno, o gráfico tende a ser “pontagudo” .

A verificação da normalidade de uma série pode ser realizada por três abordagens diferentes, sendo que a mais simples é por meio da análise de gráficos como histogramas, gráfico quantil-quantil ou Q-Q, box-plot e entre outros. Apesar dos métodos gráficos serem úteis na verificação da normalidade, eles não fornecem evidências conclusivas sobre a normalidade dos dados. Desta forma, testes de normalidade devem ser realizados antes de se concluir sobre a normalidade dos dados (RAZALI; WAH, 2011).

O histograma é um gráfico de barras justapostas, no qual o eixo horizontal apresenta a variável de interesse e o eixo vertical representa a amplitude ou frequência da variável. Ele permite examinar se a distribuição dos dados é simétrica, determinar a região com maior quantidade de valores e a dispersão destes em relação a um valor central. Neste caso, a suposição de normalidade é averiguada quando o histograma parece ser simétrico (BUSSAB; MORETTIN, 2004).

O gráfico Q-Q pode ser usado para avaliar se os dados seguem a distribuição normal. Ele é feito a partir das distribuições marginais de cada componente do valor de

p . Basicamente é um gráfico quantil amostral versus quantil esperado em caso de normalidade. A suposição de normalidade é sustentada quando a configuração dos dados amostrais se aproxima de uma reta. A normalidade não é aceita quando existem pontos que se desviam do comportamento linear (JOHNSON; WICHERN, 2007).

Por fim, o teste de Anderson-Darling pode ser usado na verificação da normalidade dos dados. Esse método foi definido por Anderson e Darling (1954) conforme Equação 5 (RAZALI; WAH, 2011).

$$W_n^2 = n \int_{-\infty}^{+\infty} [F_n(x) - F^*(x)]^2 \psi(F^*(x)) dF^*(x) \quad \text{Equação 3}$$

Onde ψ é o peso não-negativo da função e pode ser computado por:

$$\psi = [(F^*(x)(1 - F^*(x))]^{-1} \quad \text{Equação 4}$$

Assume-se a hipótese nula (H_0) de que os dados são normalmente distribuídos. Assim, para o nível de significância de 5%, os p-valores devem ser maiores que 0,05 para que a hipótese nula não seja rejeitada, ou seja, os dados tenham distribuição normal (RAZALI; WAH, 2011).

5.4.1.2 ESTACIONARIEDADE

Uma série estacionária quando as características do processo estocástico gerador não se alteram em relação ao tempo (SOUZA; CAMARGO, 2004). Teoricamente existem duas formas de estacionariedade: a forte ou estrita e a fraca ou de segunda ordem (MORETTIN; TOLOI, 2004).

Uma série é estritamente estacionária quando suas estatísticas são invariantes com as mudanças na origem do tempo. (SOUZA; CAMARGO, 2004) Em outras palavras, suas propriedades não devem ser afetadas por mudanças temporais (BOX; PIERCE, 1970). O valor final depende somente do intervalo entre o tempo inicial e final, logo, a média e a variância são constantes (MORETTIN; TOLOI, 2004).

Uma série é fracamente estacionária, ou de segunda ordem, quando possui a média e variância constantes para todos os t e a função de covariância depende apenas da distância temporal (BOX et al., 2008).

$$E[x(t)] = \mu \quad \text{Equação 5}$$

$$Var(x(t)) = \sigma^2 \quad \text{Equação 6}$$

$$cov[X(t), X(t + \tau)] = \gamma(\tau) \quad \text{Equação 7}$$

A condição da função de distribuição conjunta invariante resulta que a covariância entre os valores X_t e X_{t+k} , separados por k intervalo, ou defasagens, seja a mesma para todos os tempos. Neste caso, a covariância é chamada de auto-covariância de defasagem k e é definida pela Equação 8 (BOX et al., 2008):

$$\gamma_k \equiv cov[X_t, X_{t+k}] \equiv E[(X_t - \mu)(X_{t+k} - \mu)] \quad \text{Equação 8}$$

Similarmente, a autocorrelação com defasagem k é dada pela Equação 9:

$$\rho_k = \frac{\gamma_k}{\gamma_0} = \frac{Cov(X_t, X_{t+h})}{Var(X_t)} \quad \text{Equação 9}$$

O que implica que o $\rho_0=1$.

A variável de autocorrelação (ρ_k) mede a dependência linear entre as variáveis analisadas. Caso o valor seja zero, então, as variáveis são independentes (TSAY, 2005).

5.4.1.3 NÃO-ESTACIONARIEDADE

Caso a série não seja estacionária, ela pode ser transformada pelo processo de diferenciação, que tem como objetivo retirar as tendências estocásticas. Teoricamente, a série pode ser diferenciada até que se torne estacionária, no entanto, em casos reais, uma ou duas diferenças deve ser suficiente. As equações das diferenciações de primeira e segunda ordem estão representadas pelas Equação 10 e Equação 11, respectivamente (MORETTIN; TOLOI, 1981).

$$X^{dif}(m) = X(m) - X(m - 1) \quad \text{Equação 10}$$

$$X^{dif}(m) = X(m) - 2X(m - 1) + X(t + 2) \quad \text{Equação 11}$$

Onde $m=1,2, 3, \dots$; e Z^{dif} é a nova série de dados estacionários.

5.4.1.4 FUNÇÃO DE AUTOCORRELAÇÃO

A função de autocorrelação verifica se os coeficientes de correlação são significativamente diferentes de zero, dado um certo nível de significância (BOX et al., 2008).

O estimador amostral da autocorrelação de defasagem k ($\hat{\rho}_k$) é dado pela Equação 12 (BOX et al., 2008):

$$\hat{\rho}_k = \frac{\hat{Y}_k}{\hat{Y}_0}, k = 1,2,3, \dots \quad \text{Equação 12}$$

Onde $\hat{Y}_k = 1/N * \sum_{t=1}^{N-k} (X_t - \bar{X})(X_{t-k} - \bar{X})$.

A função de autocorrelação (FAC) é importante na investigação das características de uma série temporal. Ela é um gráfico de ρ_k versus k , com k representando os primeiros coeficientes da série. A função não possui dimensão, uma vez que o numerador e o denominador apresentam a mesma unidade. Os correlogramas são importantes na análise e modelagem das séries temporais pois mostra como cada valor no instante t se relaciona com os valores nos instantes $t+k$ (BOX et al., 2008).

5.4.1.5 FUNÇÃO DE AUTOCORRELAÇÃO PARCIAL

A função de autocorrelação parcial (FACP) é geralmente utilizada na identificação dos processos estocásticos, principalmente o auto-regressivo (TSAY, 2005).

Sabendo que ϕ_{kj} é o j -ésimo coeficiente e que ele deve satisfazer a Equação 13, (Box et al.,2008).

$$\rho_i = \phi_{k1}\rho_{j-1} + \dots + \phi_{k(k-1)}\rho_{j-k+1} + \phi_{kk}\rho_{j-k}; j = 1,2, \dots, k \quad \text{Equação 13}$$

Ao reorganizar a equação para diferentes valores de k com as equações de Yule-Walker, tem-se que:

$$\begin{bmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & \cdots & \rho_{k-2} \\ \vdots & \vdots & 1 & \ddots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \cdots & 1 \end{bmatrix} \begin{bmatrix} \phi_{k1} \\ \phi_{k2} \\ \vdots \\ \phi_{kk} \end{bmatrix} = \begin{bmatrix} \rho_1 \\ \rho_2 \\ \vdots \\ \rho_k \end{bmatrix} \quad \text{Equação 14}$$

Ou:

$$P_k * \phi_k = \rho_k \quad \text{Equação 15}$$

Resolvendo sucessivamente as equações para $k=1, 2, \dots$, obtêm-se:

$$\phi_{11} = \rho_1 \quad \text{Equação 16}$$

$$\phi_{22} = \frac{\rho_2 - \rho_1^2}{1 - \rho_1} \quad \text{Equação 17}$$

Em geral:

$$\phi_{kk} = \frac{|\rho_{kk}^*|}{|\rho_k|} \quad \text{Equação 18}$$

Sendo que ϕ_{kk} representa a função de autocorrelação parcial da camada k .

5.4.1.6 RUÍDO BRANCO

Um processo é uma sequência aleatória ou um ruído branco, quando as variáveis aleatórias são independentes e identicamente distribuídas. Usualmente apresentam média igual a zero e a variância dada por σ^2 . A independência entre os fatores pressupõe que a função de auto-covariância seja dada pela Equação 19 (BOX et al., 2008).

$$\gamma(k) = E(x_t, x_{t+k}) = \begin{cases} \sigma^2, & k = 0 \\ 0, & k \neq 0 \end{cases} \quad \text{Equação 19}$$

A autocorrelação será dada por (SOUZA; CAMARGO, 2004):

$$\rho_k = 1 \text{ para } k = 0 \quad \text{Equação 20}$$

$$\rho_k = 0 \text{ para } k \neq 0 \quad \text{Equação 21}$$

A função de autocorrelação parcial será:

$$\phi_{kk} = 1 \text{ para } k = 0 \quad \text{Equação 22}$$

$$\phi_{kk} = 0 \text{ para } k \neq 0 \quad \text{Equação 23}$$

Embora esse processo tenha propriedades básicas, ele pode ser útil na construção de modelos mais sofisticados.

5.4.1.7 PASSEIO ALEATÓRIO

Um processo $\{X_t\}$ é dito passeio aleatório quando este se altera seguindo alguma distribuição de probabilidade e suas sucessivas observações são independentes. Ele pode ser representado por (SOUZA; CAMARGO, 2004):

$$X_t = X_{t-1} + \varepsilon_t \quad \text{Equação 24}$$

Onde ε_t é o ruído branco.

Sabe-se que a média μ e a variância σ^2 são dependentes do tempo, logo, esse processo não é estacionário (Ehlers, 2007). As funções de autocorrelação e autocorrelação parcial (Figura 12) mostram o comportamento teórico de um passeio aleatório. A FAC não decai com o tempo e a FACP apresenta valor igual a 1 na primeira defasagem. Esse comportamento é esperado em amostras não estacionárias.

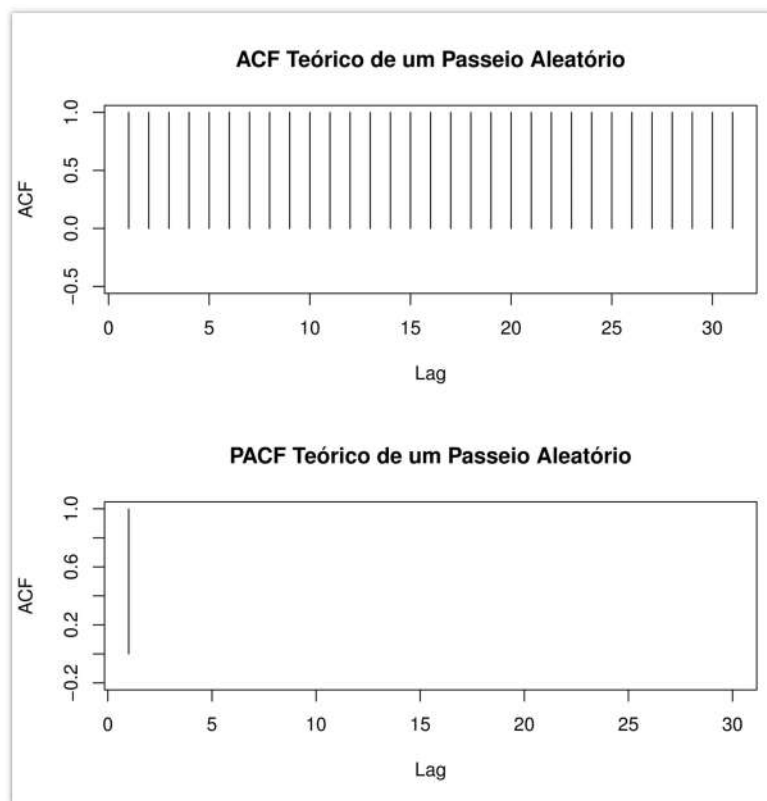


Figura 12: FAC e FACP teórico do passeio aleatório.

5.4.2 MODELOS DE SÉRIES TEMPORAIS

A metodologia que será aplicada nos processos estocásticos foi baseada na abordagem de Box & Jenkins, que consiste em um ciclo iterativo de três estágios: a) identificação com base nas curvas de autocorrelação; b) estimativa dos parâmetros dos modelos identificados e c) verificação ou diagnóstico do modelo ajustado (MORETTIN; TOLOI, 2004).

Caso o modelo ajustado não seja adequado, então volta-se a fase de identificação. Vale ressaltar que a fase crítica desse processo é a identificação do modelo, uma vez que realizada de forma empírica (MORETTIN; TOLOI, 2004).

5.4.2.1 PROCESSOS LINEARES

5.4.2.1.1 PROCESSO AUTO-REGRESSIVO

O processo auto-regressivo (AR) é usado quando é razoável assumir que o valor presente da série $\{X_t\}$ pode ser explicado como uma função de p valores passados, onde p determina o número de passos que são necessários para prever o valor presente. Assim, assume-se que os valores presentes são funções lineares dos valores passados (SHUMWAY; STOFFER, 2011). O processo auto-regressivo pode ser descrito pela Equação 25.

$$x_t = \phi_1 x_{t-1} + \phi_2 \cdot x_{t-2} + \dots + \phi_p \cdot x_{t-p} + a_c \quad \text{Equação 25}$$

Onde p é um integrador não-negativo e a_c é considerado o ruído branco com média zero e variância σ_a^2 (TSAY, 2005)(SHUMWAY; STOFFER, 2011).

Analisando agora o modelo AR com $p=1$, definido por:

$$x_t = \phi_1 x_{t-1} + a_c \quad \text{Equação 26}$$

Onde $-1 < |\phi| < 1$, para satisfazer a condição de estacionariedade de $\{x_t\}$.

A média, variância e FAC para $h \geq 0$ são representadas pela Equação 27, Equação 28 e Equação 29, respectivamente (BOX et al., 2008).

$$E(x_t) = \sum_{j=0}^{\infty} \phi^j \cdot E(w_{t-j}) = 0 \quad \text{Equação 27}$$

$$\sigma_x^2 = \frac{\sigma_a^2}{1 - \phi_1^2} \quad \text{Equação 28}$$

$$\rho_k = \phi^k \quad k \geq 1 \quad \text{Equação 29}$$

Sendo k igual ao número de defasagens.

A Figura 13 mostra a FAC e FACP teórica do modelo AR(1) para $\phi_1 = 0,8$. A FAC decai com uma mistura de exponenciais e senoides amortecidas sem alcançar o zero. Por sua vez a FACP apresenta valor significativo apenas na primeira camada (BOX et al., 2008).

Generalizando o resultado para AR(p), tem-se que a função de autocorrelação é formada por uma mistura de polinômios, exponenciais e senoides amortecidos. Por outro lado, a função de autocorrelação parcial apresenta valores significativos até p , anulando-se bruscamente nas camadas maiores que p (BOX et al., 2008; SOUZA; CAMARGO, 2004)

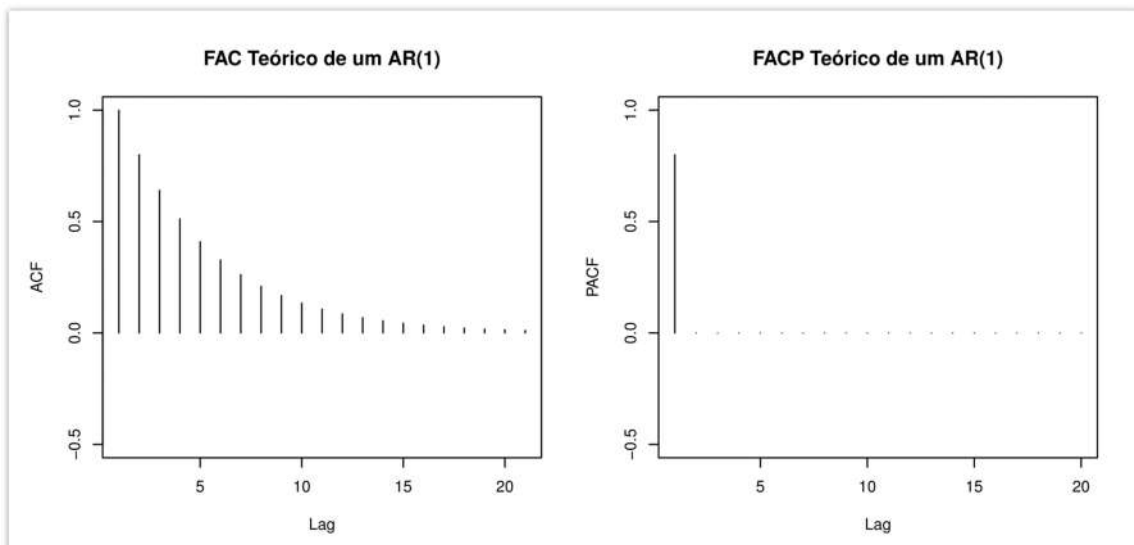


Figura 13: FAC e FACP da série teórica do processo AR(1)

5.4.2.1.2 PROCESSO DE MÉDIAS MÓVEIS

Analisando o modelo de médias móveis, considera-se que um processo $\{X_t\}$ é dito de médias móveis de ordem q , ou MA (q), quando pode ser descrito por: (SHUMWAY; STOFFER, 2011).

$$X_t = a_0 + \theta_1 * a_{t-1} + \dots + \theta_q * a_{t-q} \quad \text{Equação 30}$$

Onde θ_i são os parâmetros, q é o número de camadas e ϵ_t representa uma série Gaussiana de ruído branco com média zero e variância σ_a^2 .

O processo de médias móveis é considerado fracamente estacionário pois é uma combinação linear finita de sequências de ruído branco. Assim, a média, que é invariante no tempo, é dada pela Equação 31 e a variância pode ser descrita pela Equação 32 (TSAY, 2005).

$$E(x_t) = 0 \quad \text{Equação 31}$$

$$Var(X_t) = (1 + \theta_1^2 + \dots + \theta_q^2) * \sigma_a^2 \quad \text{Equação 32}$$

Analisando o processo MA com $q=1$ (MA (1)), tem-se:

$$X_t = a_0 + \theta_1 * a_{t-1} \quad \text{Equação 33}$$

Por sua vez, a FAC é dada pela Equação 34.

$$\rho_k = \begin{cases} \frac{-\theta_2}{2 + \theta_1^2}, & k = 1 \\ 0, & k > 1 \end{cases} \quad \text{Equação 34}$$

Na qual ρ_1 deve satisfazer a Equação 35.

$$|\rho_1| = \frac{|\theta_1|}{(1+\theta_1^2)} \leq \frac{1}{2}. \quad \text{Equação 35}$$

Desta forma, a primeira camada da FAC deve ser diferente de zero, enquanto as outras camadas devem ser insignificantes. Em outras palavras, a FAC da MA(1) sofre corte na primeira camada, como pode ser visto na Figura 14 (BOX et al., 2008).

Por outro lado, a FACP é dada por:

$$\phi_{kk} = \frac{-\theta_1^k(1 - \theta_1^2)}{1 - \theta_1^{2(k+1)}} \quad \text{Equação 36}$$

Onde $|\phi_{kk}| < |\theta_1^k|$.

Conseqüentemente a FACP decresce geometricamente, conforme Figura 14.

Portanto, no processo MA(1), a FAC decai exponencialmente e a FACP sofre corte na primeira camada, ou seja, ele atinge valores não identicamente nulos a partir da camada 1.

Generalizando esse resultado para MA(q), a FAC apresenta q valores diferentes de zero e é identicamente nula para k > q . Enquanto que a FACP decai dominada por exponenciais amortecidas (BOX et al., 2008).

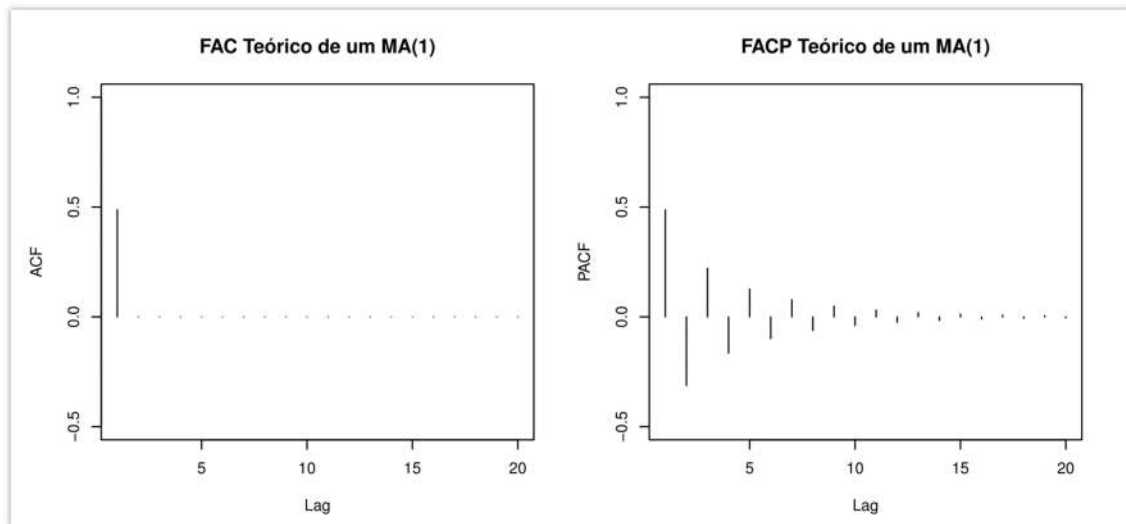


Figura 14: FAC e FACP do processo MA (1) teórico

5.4.2.1.3 PROCESSO AUTO-REGRESSIVO DE MÉDIAS MÓVEIS

Em algumas aplicações, o uso dos modelos AR e MA puros pode ser trabalhoso devido ao grande número de parâmetros. Para superar esta dificuldade, o modelo auto-regressivo de médias móveis foi desenvolvido. Ele é uma combinação dos processos auto-regressivo e de médias móveis e fornece um modelo com menor número de parâmetros para descrever as séries temporais (TSAY, 2005).

Basicamente, o ARMA forma um modelo mais compacto, que pode ser descrito por (TSAY, 2005):

$$x_t = \phi_1 \cdot x_{t-1} + \phi_2 \cdot x_{t-2} + \dots + \phi_p \cdot x_{t-p} + a_t - \theta_1 \cdot a_{t-1} - \theta_2 \cdot a_{t-2} - \dots - \theta_q \cdot a_{t-q} \quad \text{Equação 37}$$

Onde $\{a_t\}$ é o ruído branco e p e q são números inteiros não-negativos.

A primeira parte da Equação 37 representa o processo auto regressivo (AR) e a segunda parte descreve o processo de médias móveis (MA). Assim, não devem existir fatores em comum entre os dois polinômios (TSAY, 2005).

Vale notar que as funções de autocorrelação e autocorrelação parcial ficam um pouco mais complicadas nesse processo, conforme na Figura 15. Para um processo estacionário, a FAC tem um decaimento exponencial ou oscilatório após a defasagem q . Se $p - q < 0$, então a FAC decai como ondas senoidais. Se $p - q \geq 0$, então, os primeiros $q - p + 1$ valores iniciais não seguem esse padrão. Por sua vez, a FACP se comporta como um processo puro de MA sendo dominado por um amortecimento exponencial após a defasagem p (BOX et al., 2008).

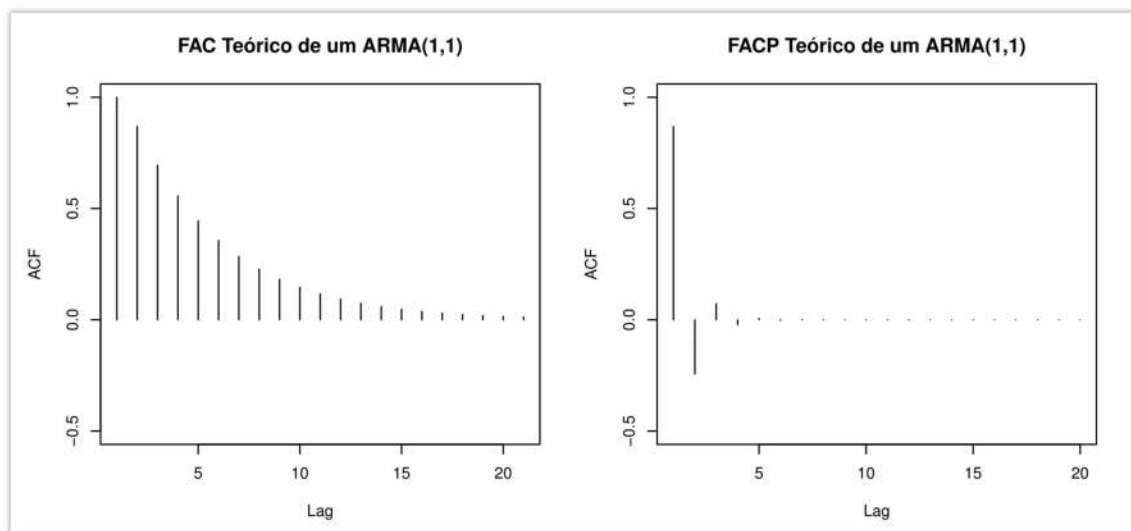


Figura 15: FAC e FACP teórica de um ARMA(1,1)

5.4.2.1.4 PROCESSO AUTO-REGRESSIVO INTEGRADO DE MÉDIAS MÓVEIS

Muitas séries encontradas na prática não são estacionárias. Neste caso, a diferenciação pode ser apropriada para alcançar a estacionariedade antes da aplicação do processo ARMA (BOX et al., 2008).

Basicamente, a diferenciação consiste na transformação de uma série não-estacionária em estacionária seguindo a Equação 38 para a primeira diferença (TSAY, 2005).

$$W_t = y_t - y_{t-1} \quad \text{Equação 38}$$

Em alguns campos científicos, uma série pode ser diferenciada várias vezes para alcançar a estacionariedade. Dessa forma, após d diferenças finitas, o processo é dito não-estacionário homogêneo, ou integrado de ordem d (MORETTIN; TOLOI, 2004).

Um modelo ARMA no qual X_t é substituído pela sua d -ésima diferença $W_t = \nabla^d x_t$ é chamado de processo auto-regressivo integrado de médias móveis (ARIMA) e pode ser descrito pela Equação 39 (SHUMWAY; STOFFER, 2011).

$$W_t = \phi_1 \cdot W_{t-1} + \phi_2 \cdot W_{t-2} + \dots + \phi_p \cdot W_{t-p} + a_t - \theta_1 \cdot a_{t-1} - \theta_2 \cdot a_{t-2} - \dots - \theta_q \cdot a_{t-q} \quad \text{Equação 39}$$

Na maioria dos casos, os valores d mais utilizados são iguais a 1 e a 2, que correspondem a dois diferentes casos de não-estacionariedade. No primeiro, a série oscila em torno de um valor médio e depois salta para outro valor temporário. Já no segundo caso, a série oscila em torno de uma direção e depois muda para outra direção temporária (MORETTIN; TOLOI, 2004; SOUZA; CAMARGO, 2004)

As curvas de autocorrelação tem papel importante na identificação dos processos não-estacionários. Neste caso, a inércia reduz a velocidade de decaimento da FAC, fazendo com que os valores absolutos continuem altos. Após a diferenciação, a aplicação do modelo na série diferenciada segue o comportamento da FAC e FACP teórica dos processos AR, MA e ARMA (BOX et al., 2008).

5.4.2.1.5 APLICAÇÃO DA ABORDAGEM DE BOX & JENKINS

A abordagem recomendada por BOX & JENKINS consiste nos seguintes estágios: identificação, estimação e verificação. A identificação dos modelos tem objetivo de determinar os valores p , q e d com base nas curvas de autocorrelação e autocorrelação parcial (BOX et al., 2008).

O número de diferenças, d , para que a série se torne estacionária é alcançado quando a FAC amostral apresenta decréscimo de seus valores absolutos para camadas altas (SOUZA; CAMARGO, 2004). Na prática, pode ser difícil identificar quando a série é não-estacionária ou de memória longa pois elas apresentam comportamentos similares (EHLERS, 2007).

Os valores de p e q são identificados inicialmente utilizando a FAC e a FACP estimadas. Essas funções devem imitar o comportamento teórico dos modelos AR, MA e ARMA, conforme pode ser visto na Tabela 2

Tabela 2: Resumo do comportamento teórico dos modelos AR, MA e ARMA. Fonte: BOX et al., (2008)

	FAC	FACP
AR(p)	Dominada por exponenciais amortecidas e/ou senoides amortecidos.	Nula para $k > p$.
MA(q)	Nula para $k > q$.	Dominada por exponenciais e/ou senoides amortecidos.
ARMA (p,q)	Decaimento exponencial ou senoidal.	Dominada por amortecimento exponencial.

Após a identificação, o segundo estágio é a estimativa dos parâmetros dos modelos identificados. O método utilizado, neste trabalho, será a soma dos quadrados condicionais, que busca encontrar parâmetros que minimizem a função da soma dos quadrados. Ele é explicado detalhadamente em Box et al., (2008) e Souza e Camargo, (2004).

O último passo na construção do modelo é a verificação ou o diagnóstico do modelo ajustado. Este pode ser feito usando o teste da sobrefixação, no qual modelos com parâmetros extras são estimados para verificar se a sua inclusão reduz consideravelmente a variância residual e se os parâmetros adicionados são significativos. Associado a isso, os resíduos devem ser não-correlacionados e normalmente distribuídos com média zero e variância constante. A presença de correlação nos resíduos pode ser investigada através da FAC e da FACP residual e testada por diferentes testes de *Portmanteau*, que são testes de hipóteses. A distribuição residual pode ser verificada pelo gráfico quantil-quantil, histograma e testes de normalidade (BOX et al., 2008; MORETTIN; TOLOI, 2004; SOUZA; CAMARGO, 2004).

Neste trabalho, o teste de *Portmanteau* utilizado será o teste de Ljung-Box, que é uma modificação do teste de Box-Pierce, tal que:

$$\tilde{Q} = n(n + 2) \sum_{k=1}^K (n - k)^{-1} r_k^2(\hat{a}) \quad \text{Equação 40}$$

Para grandes amostras, as estatísticas modificadas têm distribuição qui-quadrada com média $E(\tilde{Q}) \approx K-p-q$ e $n=N-d$: número de termos da série W_t (BOX et al., 2008; SOUZA; CAMARGO, 2004).

Esse teste considera como hipótese nula (H_0): $\rho_1 = \rho_2 = \dots = \rho_m = 0$ contra a hipótese alternativa (H_a): $\rho_i \neq 0$, onde $i \in \{1, \dots, m\}$. A hipótese deve ser aceita ou rejeitada considerando o valor de p da distribuição qui-quadrado. Quando o valor for maior que 0,05, então, não se pode rejeitar a hipótese nula e o teste indica que os resíduos são não-correlacionados com nível de significância de 5%. Caso seja menor que 0.05, então pode-se rejeitar a hipótese, os resíduos devem ser correlacionados e o modelo não é adequado (TSAY, 2005).

Caso os resíduos do modelo não sejam aleatórios, então o ciclo de identificação, estimação e verificação deve ser continuado até um modelo satisfatório seja encontrado (BOX et al., 2008). A Figura 16 ilustra um resumo da abordagem adotada na modelagem dos dados.

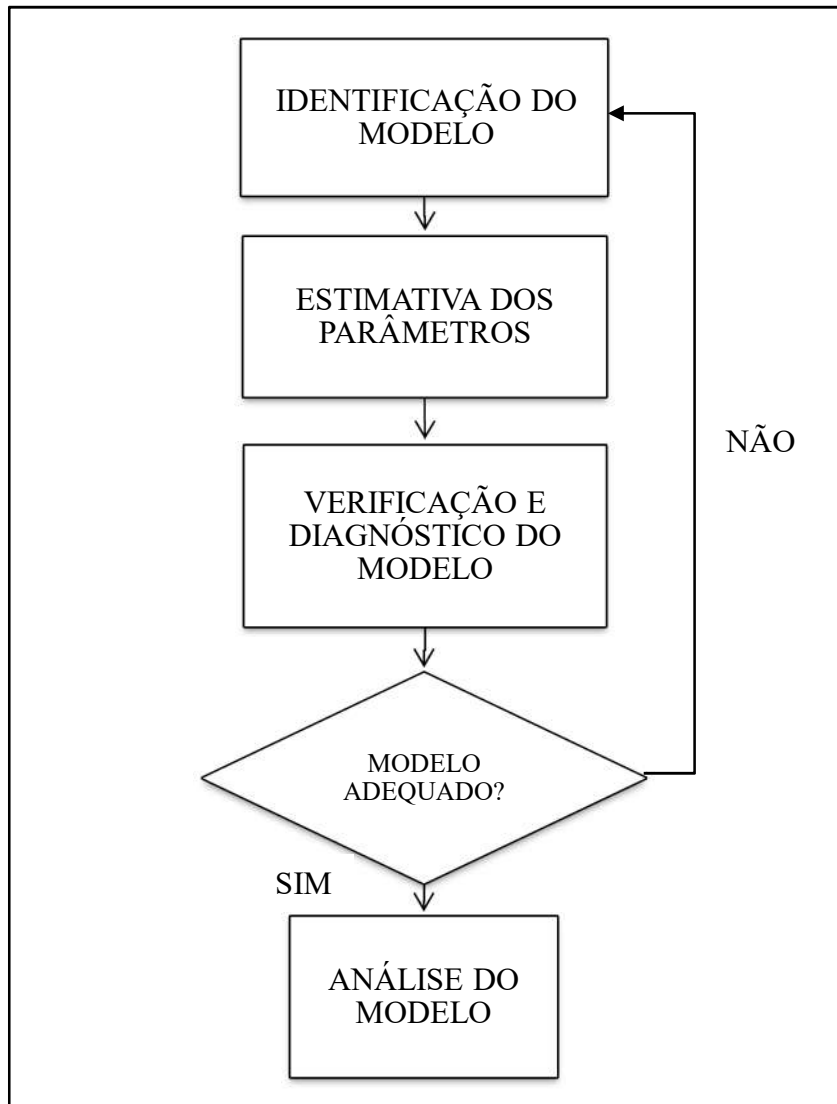


Figura 16: Resumo da abordagem adotada. Fonte: Box et al.,(2008)

5.4.2.2 PROCESSOS COM MEMÓRIA LONGA

Diferentemente das séries estacionárias, as séries temporais com memória longa apresentam FAC com decaimento lento. Essa persistência na atenuação gera um processo ARMA com excessivo número de parâmetros, o que deixa o processo complexo (ZIVOT; WANG, 2006). Este problema motivou o desenvolvimento do processo fracionalmente integrado (MORETTIN; TOLOI, 2004).

As séries com memória longa apresentam forte dependência entre observações separadas por longos períodos. Uma característica importante dessas séries é a impressão da necessidade de diferenciação, pois a FAC da série original aparenta não ser estacionária enquanto a FAC diferenciada parece estar muito diferenciada (MORETTIN; TOLOI, 2004).

Entre os modelos de longa dependência, existem duas classes de modelos principais: os processos auto similares, especialmente, o ruído fracionário Gaussiano e os processos auto-regressivos fracionariamente integrados com médias móveis (ARFIMA) (BERAN, 2017). Este trabalho aborda somente o último processo.

5.4.2.2.1 PROCESSOS FRACIONARIAMENTE INTEGRADOS

O processo auto-regressivo fracionariamente integrados com médias móveis (ARFIMA) pode ser descrito pela Equação 41.

$$\varphi(B)(1 - B)^d z_t = \theta(B) a_t \quad \text{Equação 41}$$

Onde $-0,5 < d < 0,5$.

$\{a_t\}$ é um processo ruído branco com média zero e variância σ_a^2 .

$\varphi(B)$ e $\theta(B)$ são polinômios de B com grau p e q , respectivamente.

Esse modelo foi inicialmente proposto por Hosking (1981) e Granger e Joyeux (1980). O efeito do parâmetro d em observações mais distantes decai hiperbolicamente e os efeitos dos parâmetros φ e θ decaem exponencialmente. Assim, o parâmetro d pode ser usado para descrever a correlação em camadas altas enquanto φ e θ descrevem a correlação nas defasagens baixas (HOSKING, 1981).

Quando $0 < d < 0,5$, o processo arima é estacionário com alta persistência, a FAC e FACP de $\{X_t\}$ são todas positivas e decaem monotonamente ou hiperbolicamente para zero com o aumento das defasagens (HOSKING, 1981).

Por outro lado, quando $-0,5 < d < 0$, o processo tem memória curta e é “anti-persistente”. A FAC e a FACP são negativas exceto na primeira camada e apresentam decaimento monótono e hiperbólico para zero (HOSKING, 1981).

Da mesma forma que o processo ARMA, a estimativa do modelo ARFIMA será realizada seguindo o ciclo iterativo recomendado por Box & Jenkins de identificação do modelo, estimativa dos parâmetros e verificação da série ajustada.

Em suma, uma série temporal pode ser considerada de memória longa se a FAC não é grande em magnitude, mas apresenta decaimento lento com proporções polinomiais, em vez de exponenciais.

5.4.2.3 MODELOS NÃO-LINEARES

Os modelos lineares podem não representar adequadamente séries que apresentam variância condicional evoluindo ao longo do tempo. Elas exibem períodos de alta volatilidade ou variabilidade condicional dependendo dos passados históricos. Desta forma, os modelos não-lineares foram desenvolvidos com o objetivo de captar a evolução da variância. Entre os modelos existentes, essa seção foca nos modelos ARCH e GARCH, que são indicados para séries com heterocedasticidade.

5.4.2.3.1 MODELOS ARCH

Os modelos Auto Regressivos com Heterocedasticidade Condicional (ARCH) têm o objetivo de modelar a variação do quadrado da volatilidade. Esse modelo foi introduzido por Engle (1982) e sua ideia básica é que a média seja não correlacionada, mas dependente, e a dependência da média possa ser descrita pela função quadrática dos valores (TSAY, 2005).

O modelo pode ser descrito pela Equação 42 e Equação 43.

$$X_t = \sqrt{h_t} \varepsilon_t \quad \text{Equação 42}$$

$$h_t = \alpha_0 + \alpha_1 \cdot x_{t-1}^2 + \dots + \alpha_{t-r} \cdot X_{t-m}^2 \quad \text{Equação 43}$$

Onde ε_t é uma sequência de variáveis aleatórias identicamente distribuídas (i.i.d.) com média zero e variância unitária. Para assegurar que a variância condicional seja finita, os parâmetros $\alpha_0 > 0$ e $\alpha_i \geq 0, para i > 0$ (BOX et al., 2008). Na prática, ε_t pode assumir a distribuição normal, *t-student* ou uma distribuição generalizada dos erros (TSAY, 2005).

A aplicação do modelo ARCH deve ser realizada com base nos seguintes passos. Primeiro, as dependências lineares devem ser removida por processos econométricos como, por exemplo, AR, MA, ARMA, ARIMA ou ARFIMA. Os resíduos desse modelo devem ser usados para verificar a presença de heterocedasticidade condicional na FAC e na FACP quadráticas da série. Depois, o modelo preliminar ARCH(m) é identificado e estimado com base na FAC e na FACP residual quadrática. Após a estimativa dos parâmetros, o modelo selecionado deve ser verificado com base na análise da FAC e da FACP dos resíduos padronizados e resíduos padronizados quadráticos. Associado a isso, os resíduos padronizados devem passar por testes de *Portmanteau*, tal como o

Teste de Ljung-Box e o teste de Multiplicador de Lagrange de Engle (LM-Engle). Esses testes têm o intuito de verificar a presença de heterocedasticidade condicional nos resíduos. Por fim, caso o modelo encontrado não seja adequado, então o ciclo continua (BOX et al., 2008; TSAY, 2005).

Vale ressaltar que os resíduos padronizados são calculados pela Equação 44 (TSAY, 2005).

$$\tilde{\alpha}_t = \frac{\alpha_t}{\sigma_t} \quad \text{Equação 44}$$

Onde α_t e σ_t representam os resíduos do modelo ARCH ajustado e a estimativa da variância condicional a cada instante, respectivamente.

Em relação aos testes de hipótese, o teste de Ljung-Box pode utilizado tanto em $\{\tilde{\alpha}_t\}$ quanto em $\{\tilde{\alpha}_t^2\}$. Na primeira opção ele investiga a presença de autocorrelações significativa. Na segunda, ele verifica a presença de heterocedasticidade condicional. Por sua vez, o teste de LM-Engle também verifica a presença de heterocedasticidade nos dados. Ele equivale a um teste de estatística F para o qual $\alpha_i = 0$ ($i=1, \dots, m$) e pode ser descrito em forma de regressão linear pela Equação 45.

$$\begin{aligned} a_t^2 &= \alpha_0 + \alpha_1 * a_{t-1}^2 + \dots + \alpha_m * a_{t-m}^2 + e_t, \\ t &= m + 1, \dots, T \end{aligned} \quad \text{Equação 45}$$

Onde e_t representa o erro, m é um integrador positivo e T é o tamanho da amostra. A estatística converge assintoticamente para uma distribuição qui-quadrada com m graus de liberdade sob a hipótese nula de que não existe efeito ARCH nos resíduos analisados. Assim, se o valor de p da estatística F for menor que um certo nível de significância, então, pode-se rejeitar a hipótese nula (BOX et al., 2008).

Por fim, pela estrutura do modelo, choques positivos e negativos têm o mesmo efeito na volatilidade. E choques altos implicam em uma maior variância condicional, o que significa que grande choques tendem a ser seguidos por outros choques (BOX et al., 2008; TSAY, 2005).

5.4.2.4 MODELO GARCH

Embora o modelo ARCH seja simples, ele requer uma grande quantidade de parâmetros para descrever a volatilidade das séries. Por isso, um modelo alternativo, conhecido como uma generalização do ARCH (GARCH), foi desenvolvido por Bullerslev (1986). O modelo pode ser descrito pela Equação 46 e Equação 47 (BOX et al., 2008).

$$X_t = \sqrt{h_t} \varepsilon_t \quad \text{Equação 46}$$

$$h_t = \alpha_0 + \sum_{i=1}^m \alpha_i x^2_{t-i} + \sum_{j=1}^s \beta_j x^2_{t-j} \quad \text{Equação 47}$$

Onde ε_t é uma i.i.d com média zero e variância unitária, $\alpha_0 > 0$, $\alpha_i \geq 0$, $\beta_j \geq 0$ e $\sum_{i=1}^{\max(m,s)} (\alpha_i + \beta_i) < 1$, o que implica que a variância condicional seja finita. Como no modelo ARCH, ε_t é frequentemente considerado como de distribuição normal ou de *t-Student*. A Equação 47 é reduzida para um modelo de ARCH puro quando $s=0$ (TSAY, 2005).

O modelo GARCH apresenta as mesmas vantagens e desvantagens do ARCH, por exemplo, as volatilidades altas são precedidas de volatilidade grandes. Por sua vez, o procedimento de modelagem do GARCH também segue o mesmo padrão do modelo ARCH, no qual estima-se um processo econométrico antes da aplicação do modelo em questão. Entretanto a especificação do modelo GARCH não é tão simples, na maioria dos casos são usados modelos de ordem baixa, como (1,1), (1,2) e (2,1) (TSAY, 2005). Finalmente, a escolha do modelo pode ser feita baseada em critérios como os resíduos padronizados, resíduos padronizados quadráticos, valores de assimetria e curtose, gráfico quantil-quantil e entre outros (BOX et al., 2008).

6 ESTUDO DE CASO

Neste capítulo serão apresentados os resultados obtidos com a aplicação do procedimento metodológico proposto no capítulo anterior. É importante salientar que o estudo foi realizado com os dados originais da máquina e com os dados obtidos após a filtragem de Wavelet. Os resultados para esses dois casos são apresentados separadamente.

Este capítulo está dividido em: Base de dados, Caso 1- Estudo dos dados originais, Caso 2- Estudo dos dados transientes, gerados enquanto a máquina operava no regime transiente e Caso 3 - Estudo dos dados após filtragem.

6.1 BASE DE DADOS

Os dados do estudo de caso foram coletados na UHE de Corumbá IV, localizada no reservatório formado, principalmente, pela contribuição do rio Corumbá, na cidade de Luziânia, Goiás. A Figura 17 mostra uma vista aérea da usina, que apresenta duas unidades geradoras do tipo Francis com potência instalada de 127MW. A hidrelétrica em questão encontra-se conectada ao SIN (CORUMBÁ CONCESSÕES, 2018b).



Figura 17: Vista aérea da usina de Corumbá IV. Fonte: Corumbá Concessões (2018)

A aquisição dos dados foi realizada por dois sensores de vibração relativa instalados nas direções x e y na UG01. Eles foram coletados pelos funcionários da empresa durante 15 partidas sequenciais no período entre agosto de 2016 e maio de

2017. As partidas ocorreram de acordo com as solicitações do ONS, logo, elas não são igualmente espaçadas no tempo.

Cada partida foi enumerada de um a quinze seguindo a ordem cronológica em que ocorreram. Sabe-se que cada partida tem dois sensores: um na direção x e outro na direção y. Então, cada partida gera duas séries vibracionais, totalizando trinta séries.

Os dados captados correspondem aos cinco minutos iniciais da partida da usina. Cada valor equivale a 0,007 microssegundos, aproximadamente, produzindo 42.800 observações.

Salienta-se que os resultados serão apresentados para algumas séries apenas, para fins de exposição. Os resultados completos poderão ser vistos nos seus respectivos anexos.

Em suma, foram analisadas um total de 30 séries vibracionais, equivalente a quinze partidas da unidade geradora. Cada série apresenta 42.800 observações captadas durante os primeiros cinco minutos de cada partida.

6.2 ANÁLISE EXPLORATÓRIA

Esta seção descreve o estudo do comportamento da média, do desvio-padrão e da amplitude dos dados analisados. Primeiramente, a Figura 18 representa a série selecionada. Nota-se que existe um deslocamento em relação ao eixo das abscissas, que varia a cada partida. Esse deslocamento médio é considerado a componente CC^3 e foi retirado para uma melhor análise dos dados, como pode ser visto na Figura 19.

Ainda é possível perceber que existe um período inicial constante. Isso ocorre devido ao atraso na partida da turbina em relação aos sensores. Assim, esses dados também foram removidos antes da aplicação dos processos econométricos.

³ A componente contínua representa distância média do eixo em relação ao sensor. Para obter mais informações, vide Capítulo 5.

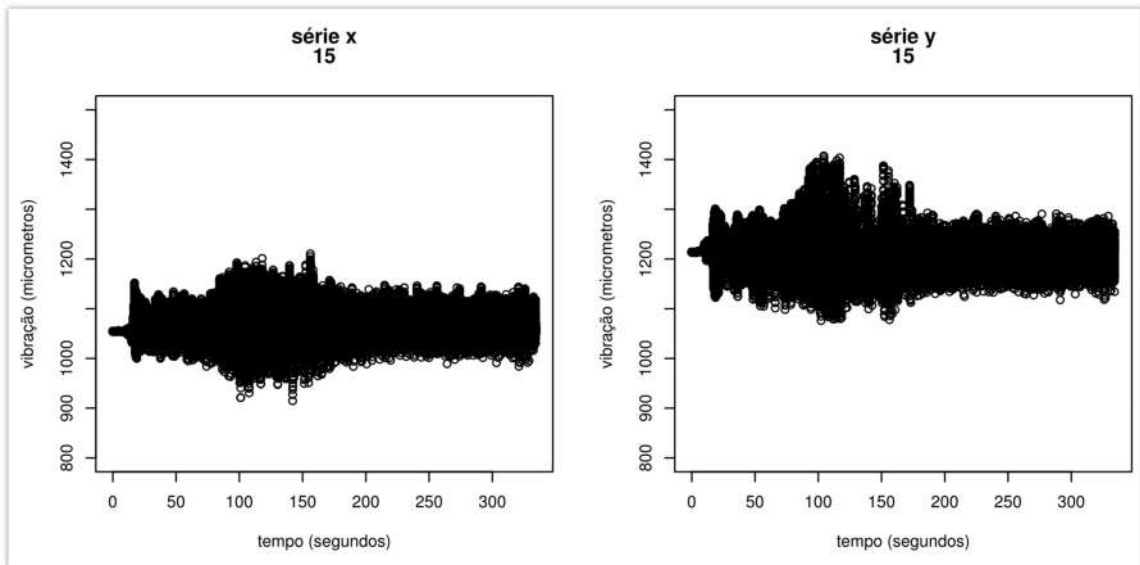


Figura 18: Comportamento de uma série original selecionada⁴




Figura 19: Comportamento das séries selecionadas⁵ após a retirada da componente CC.

A análise exploratória mostrou a mudança estatística devido aos diferentes períodos operacionais nos quais a máquina foi submetida. A Figura 20, a Figura 21 e a Figura 22 foram geradas com base na média, no desvio-padrão e na amplitude a cada 100 valores coletados.

Como pode ser visto na Figura 20, a média apresenta inclinação crescente para as séries na direção x e decrescente para as séries na direção y. Essa variação da

⁴ Para o resultado de todas as séries, vide anexo II.

⁵ Para o resultado de todas as séries, vide anexo II.

inclinação ocorre devido à localização dos sensores. Ademais, a média tende a zero após os 200 segundos, o que indica que a máquina começou a operar no regime permanente.

Em relação ao desvio-padrão (Figura 21), é possível perceber que este apresenta comportamento crescente até os 200 segundos. Após isso, o desvio tende a decrescer lentamente. Por sua vez, a amplitude apresenta comportamento variável até 250 segundos, aproximadamente. Depois seu valor se estabiliza em 100 micrometros.

Assim, como já discutido anteriormente, durante o período transiente ocorre a geração de impulsos não-periódicos ocasionando o aumento da volatilidade, que pode ser visto nas três figuras. A estabilização ocorre durante o regime permanente, no qual as forças existentes tendem a ser periódicas e constantes, gerando dados estacionários e com propriedades estatísticas constantes e média tendendo a zero (VLADISLAVLEV et al., 1979).

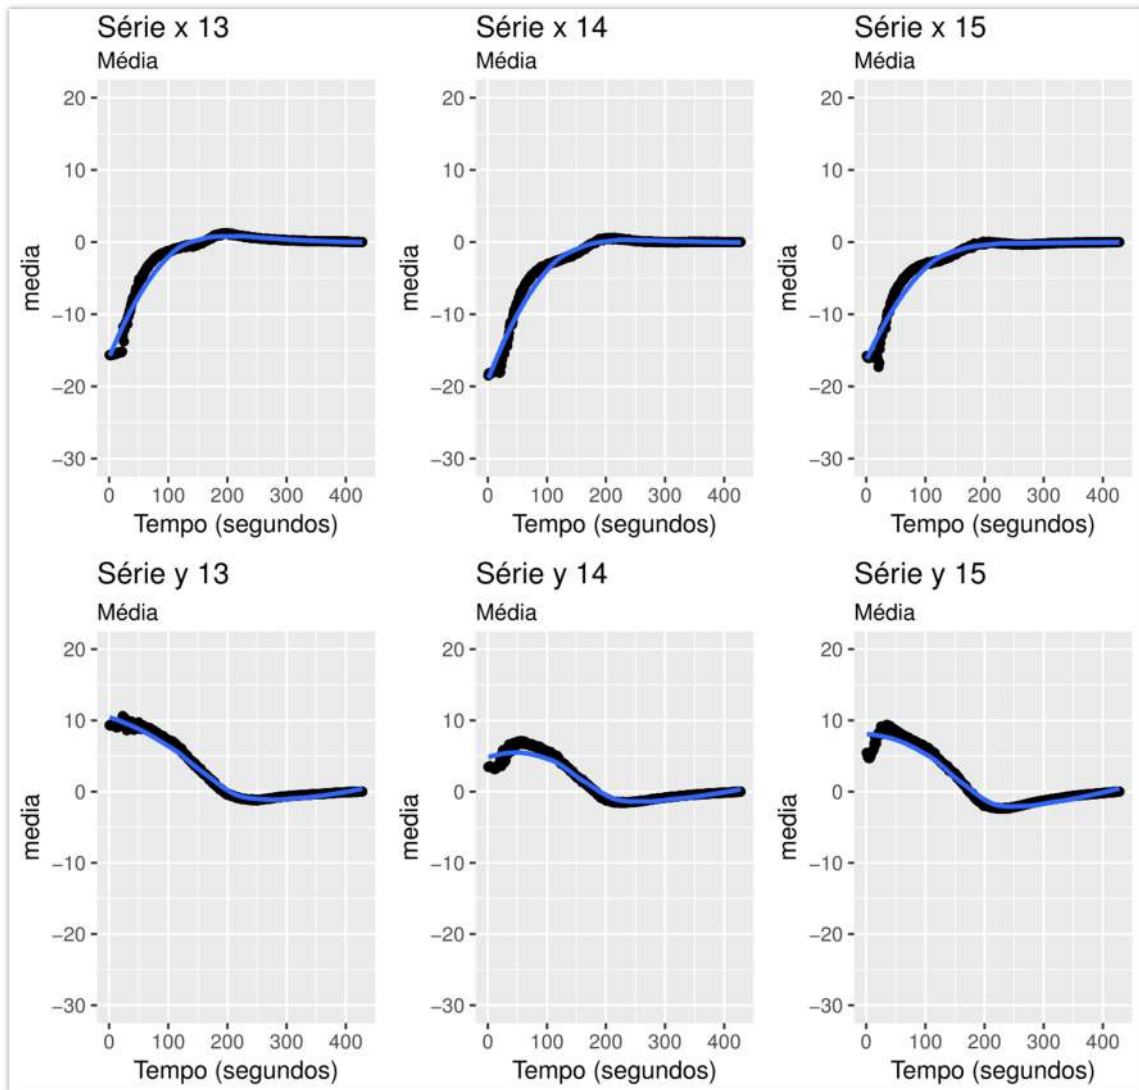


Figura 20: Comportamento da média em partidas selecionadas⁶.

⁶ Para o resultado de todas as séries, vide anexo II.

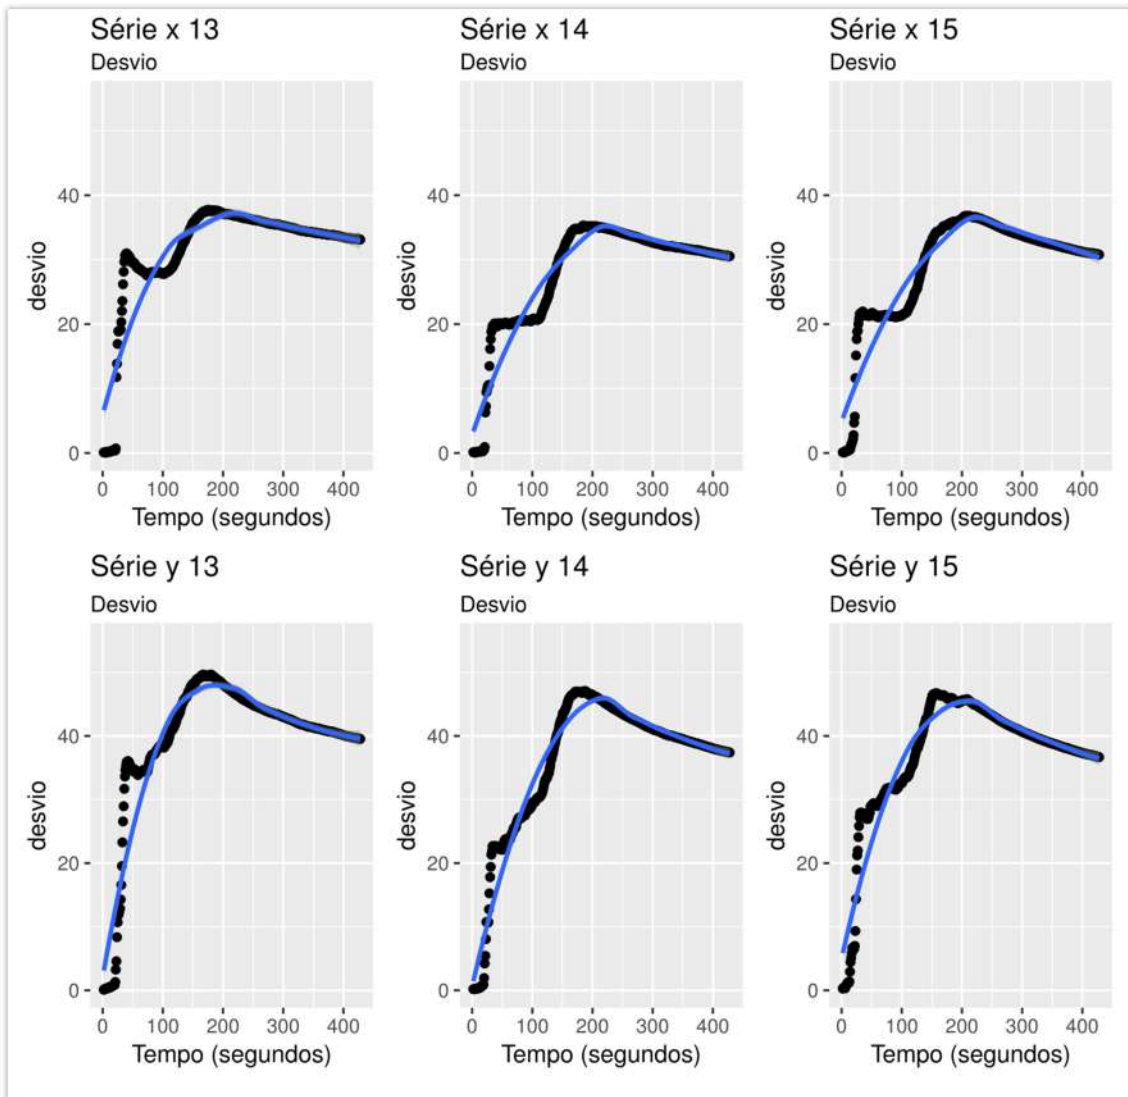


Figura 21: Comportamento do desvio em partidas selecionadas⁷.

⁷ Para o resultado de todas as séries, vide anexo II.

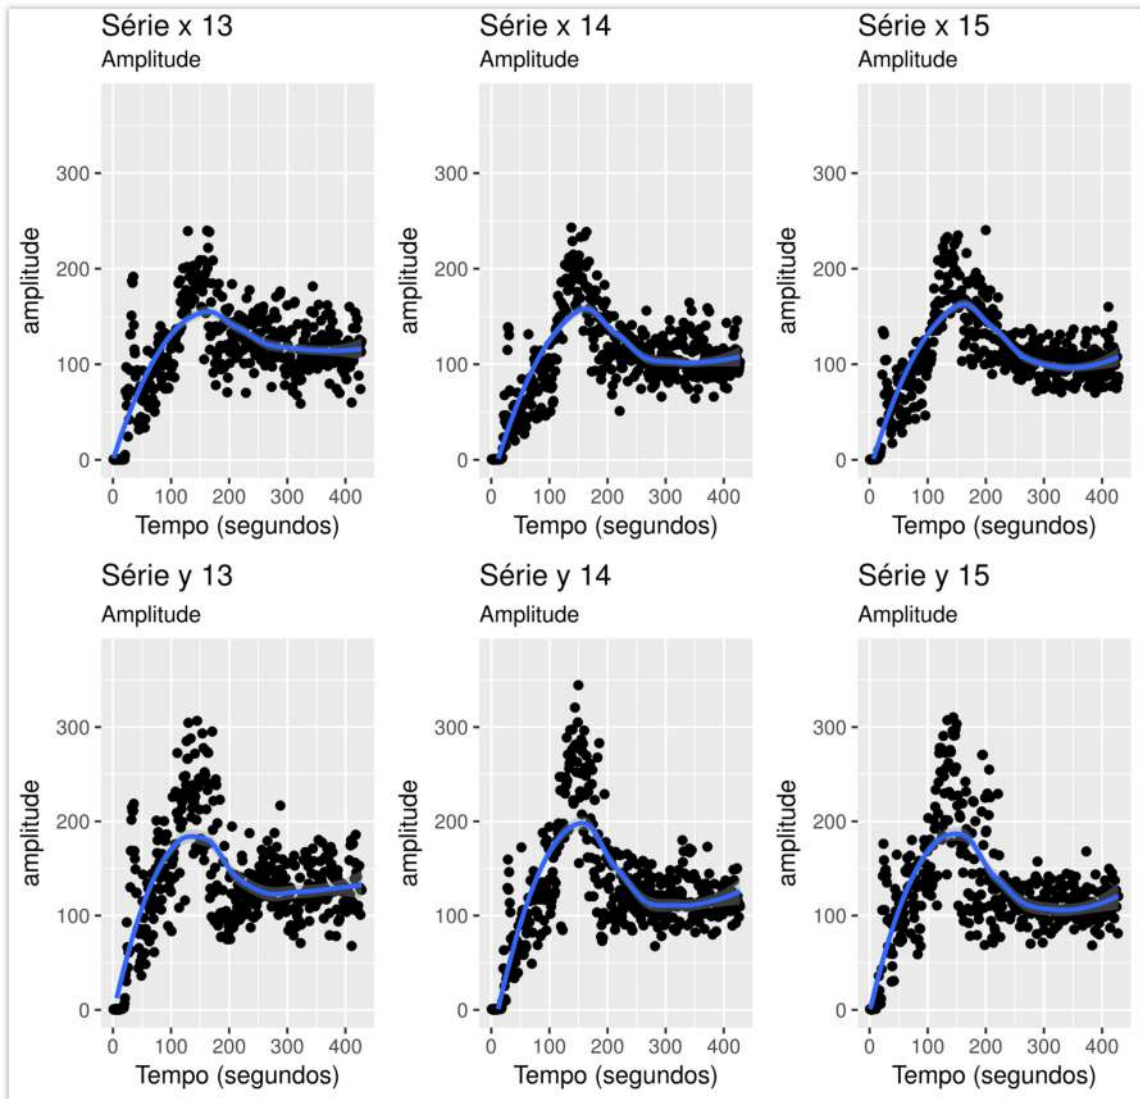


Figura 22: Comportamento da amplitude em partidas selecionadas⁸.

Em seguida a média, o desvio-padrão e o máximo foram comparados conforme as partidas a fim de analisar as suas tendências. A Figura 23 mostra que as séries nas direções x e y possuem inclinações diferentes com o aumento do número de partidas (P). As séries captadas pelos sensores no eixo x apresentaram as médias positivas com inclinação decrescente. Por outro lado, as séries do eixo y apresentaram médias negativas com inclinação positiva

⁸ Para o resultado de todas as séries, vide anexo II.

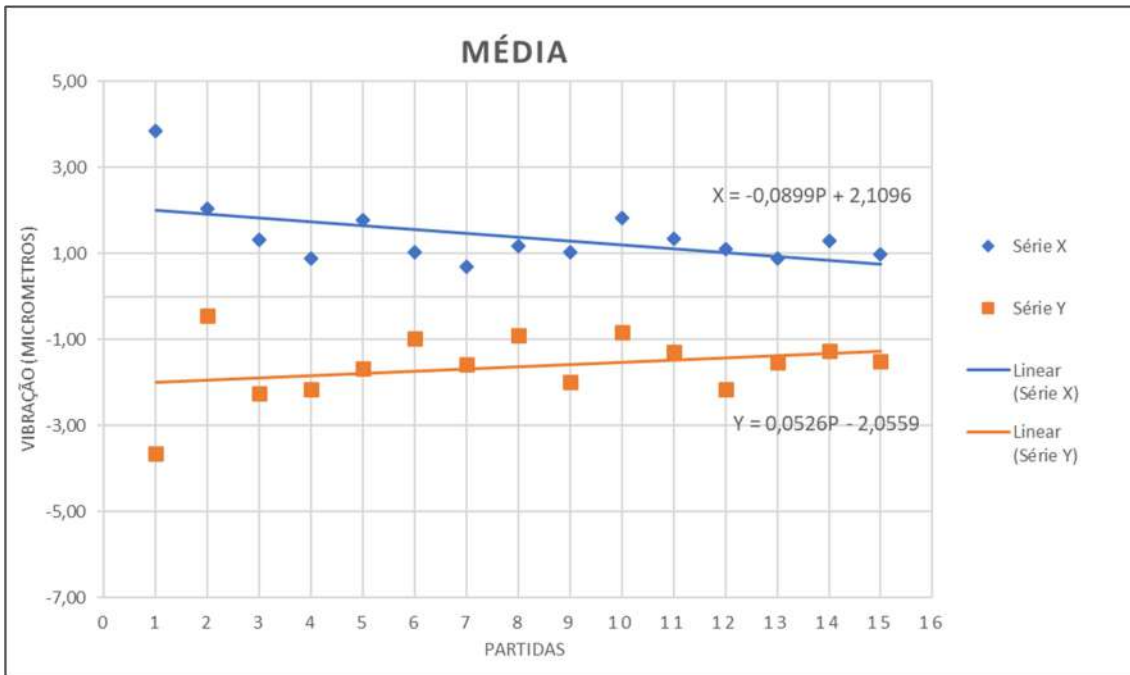


Figura 23: Média das partidas originais

Em relação ao desvio-padrão (Figura 24), ambas direções possuem inclinação negativa, ou seja, a volatilidade das séries reduz com o aumento do número de partidas. Isso indica que as primeiras partidas são mais heterogêneas do que as partidas finais.




Figura 24: Desvio-padrão das partidas originais

Analisando os valores máximos das séries (Figura 25), a direção x possui inclinação negativa, o que revela uma redução nos picos de vibração alcançados durante a partida. Porém, a direção y apresenta a inclinação positiva, evidenciando aumento nos valores dos picos.




Figura 25: Valores máximo dos dados originais

Desta forma, as séries na direção x evidenciaram tendências decrescentes na média, no desvio-padrão e nos máximos conforme o número de partidas. Esse comportamento indica uma possível redução na variabilidade. Em contrapartida, as séries na direção y apresentaram tendências crescentes na média e nos máximos e decrescente no desvio-padrão, o que demonstra que ocorreu redução da variabilidade com o aumento do número de partidas.

6.3 CASO 1- ESTUDO DOS DADOS ORIGINAIS

Esta seção descreve a aplicação da metodologia proposta, seguindo a abordagem recomendada por Box & Jenkins, nos dados originais. Inicialmente, é feita uma análise descritiva das séries temporais, verificando os histogramas, os gráficos dos quantis e as curvas FAC e FACP. Em seguida, os modelos discutidos foram aplicados nas séries analisadas.

A Figura 26 e a Figura 27 apresentam os histogramas e gráficos quantil-quantil das séries selecionadas, respectivamente. Nota-se que as amostras são aproximadamente simétricas. Pelo gráfico quantil-quantil, algumas séries na direção y apresentaram uma pequena assimetria a direita (BUSSAB; MORETTIN, 2004).

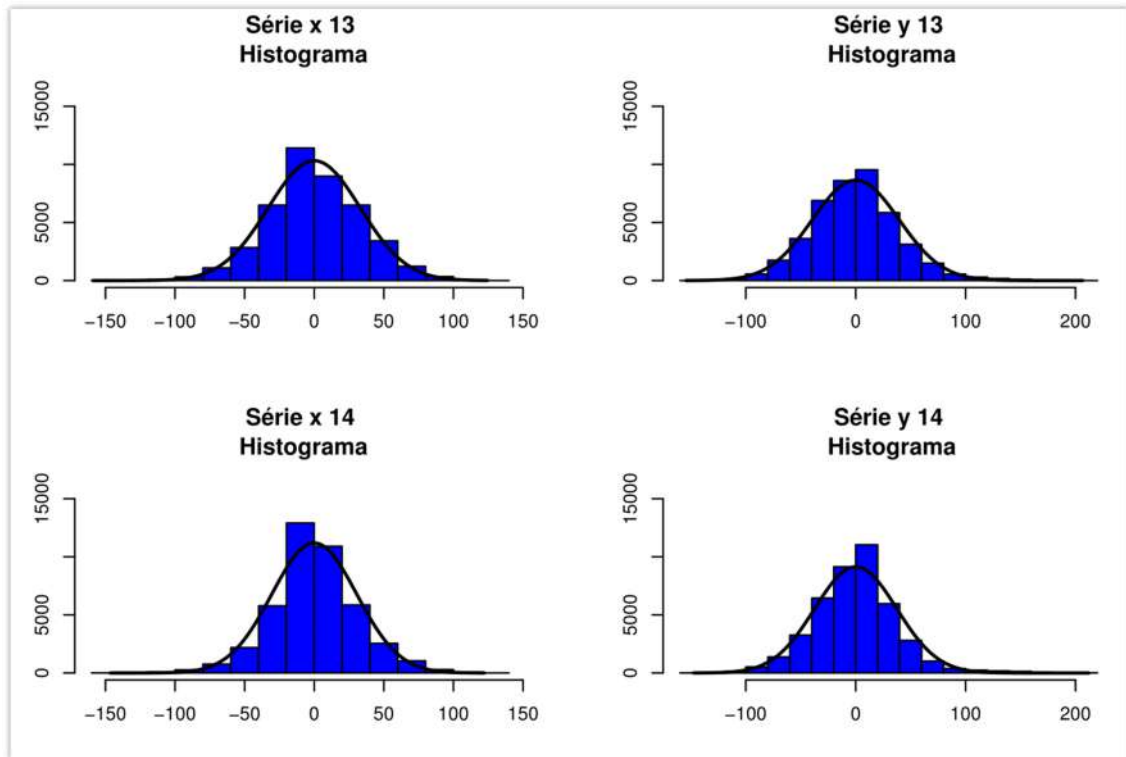


Figura 26: Histograma das séries selecionadas⁹.

⁹ Para o resultado completo, vide anexo III.

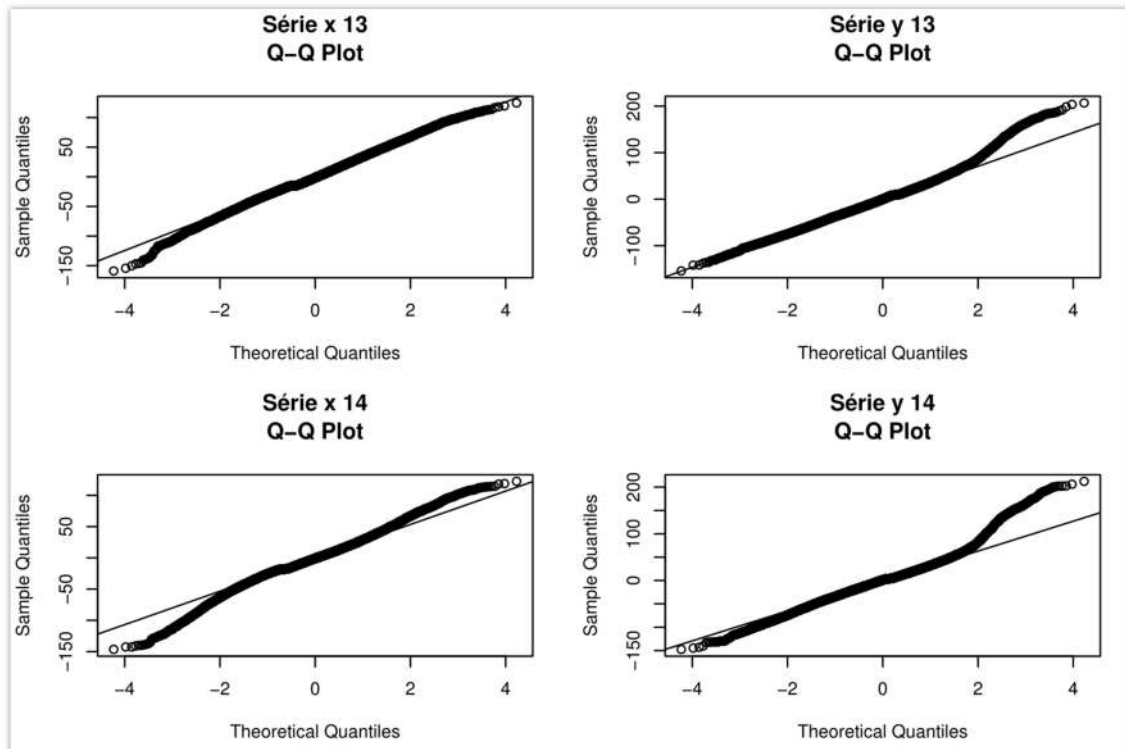


Figura 27: Gráfico quantil-quantil das séries selecionadas¹⁰.

Entretanto, pelo teste de normalidade de Anderson-Darling, não foi possível aceitar a hipótese nula de normalidade, uma vez que os p-valores foram menores que 0,05 conforme pode ser visto no Quadro 1.

¹⁰ Para o resultado completo, vide anexo III.

[1] "Série x 13"		[1] "Série y 13"	
Anderson-Darling normality test			
data:	dadoslimpos[,	data:	dadoslimpos[, i]
A =	4.426	A =	69.498
p-value =	5,57E-08	p-value	< 2.2e-16
[1] "Série x 14"		[1] "Série y 14"	
Anderson-Darling normality test			
data: dadoslimpos[, i]		data: dadoslimpos[, i]	
A =	68.15	A =	108.2
p-value	< 2.2e-16	p-value	< 2.2e-16

Quadro 1: Teste de normalidade de Anderson-Darling nas séries selecionadas

A Figura 28 mostra que as funções de autocorrelação das séries originais não se anulam mesmo em camadas mais altas. Por sua vez, as curvas FACP (Figura 29) apresentam decaimento com corte na camada 20, aproximadamente. Algumas correlações significativas aparecem novamente em torno da camada 40. Diante disso, as séries analisadas podem ser modeladas por um processo AR puro ou ARMA.

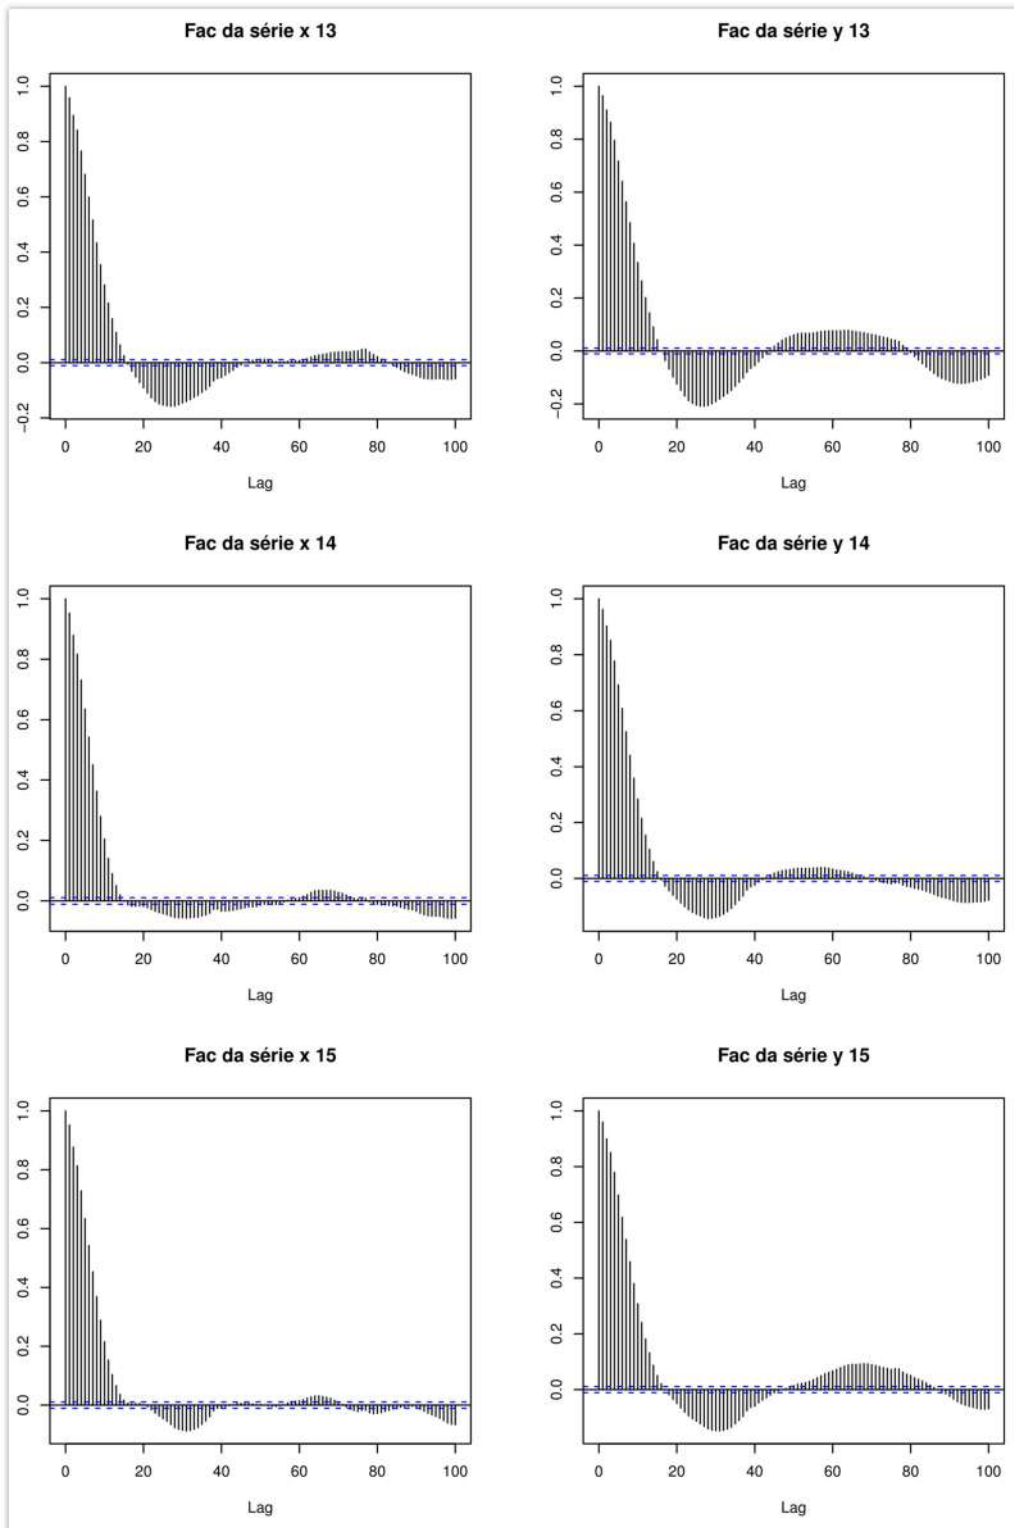


Figura 28: FAC das séries originais selecionadas¹¹ nas direções x e y

¹¹ Para o resultado completo, vide anexo III

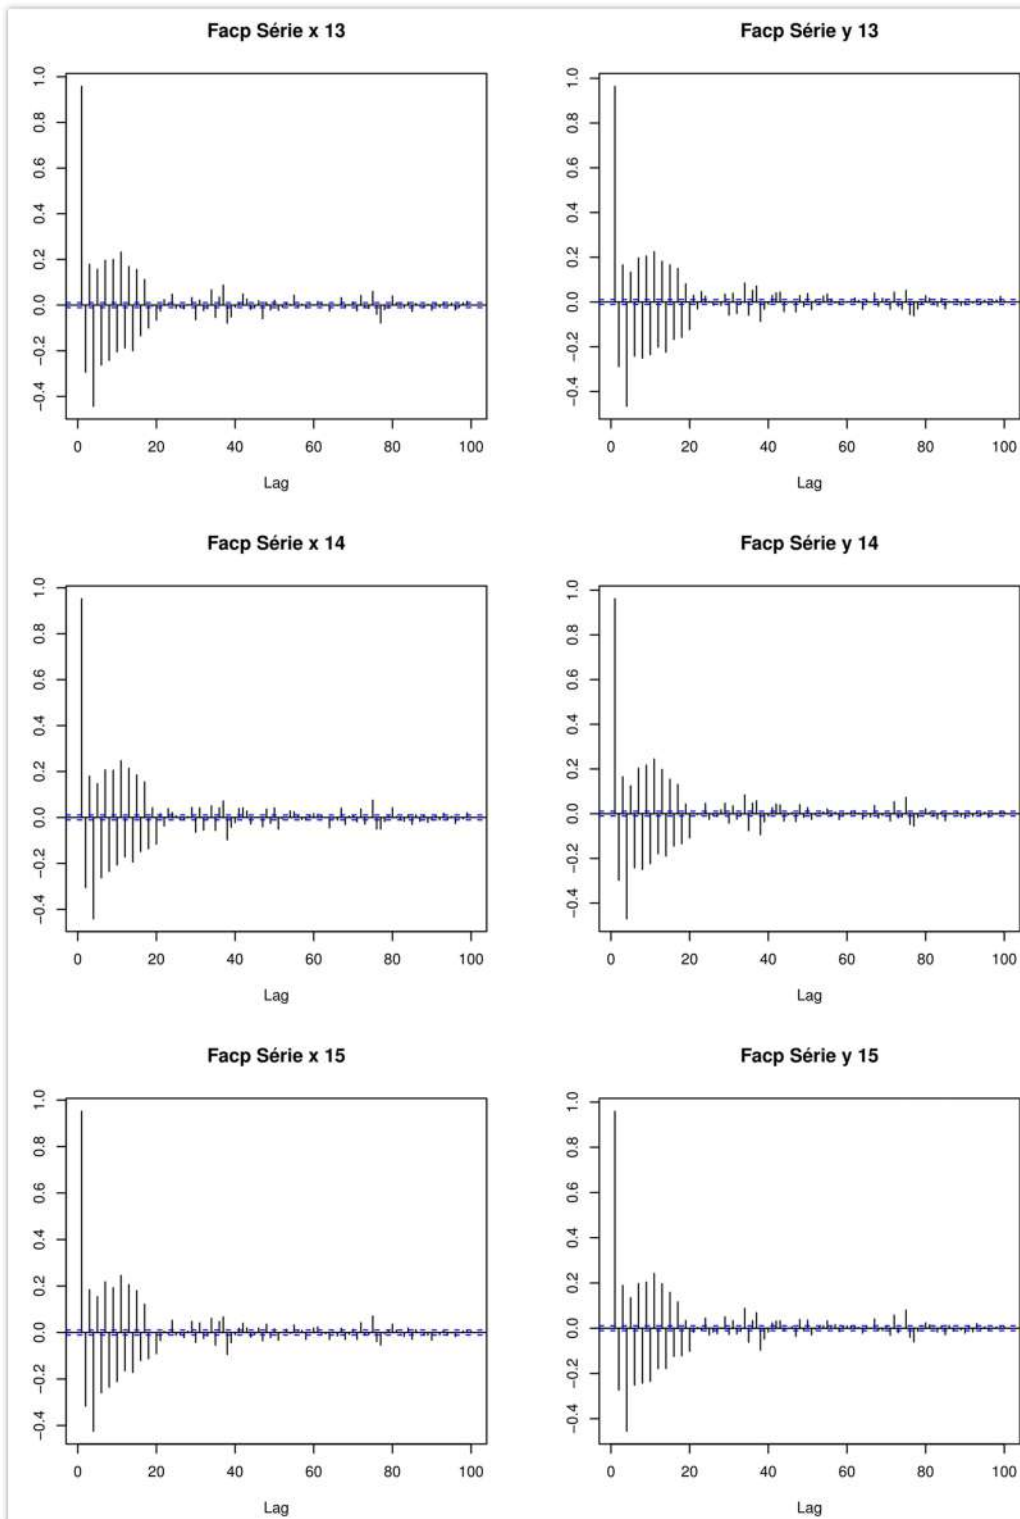


Figura 29: FACF das séries originais selecionadas¹² nas direções x e y

¹² Para o resultado completo, vide anexo III

6.3.1 PROCESSOS LINEARES

Seguindo a seção anterior, os modelos AR(22) e AR(38) foram estimados baseados nas curvas FACP dos dados originais. Novas estimativas tais como AR(37), AR(39) e AR(40), foram realizadas a partir dos resultados obtidos.

O modelo final deve atender aos requisitos em todas as séries analisadas. Em outras palavras, ele não deve apresentar correlações significativas nas curvas FAC e FACP e os p-valores devem ser maiores que 0,05 nas 20 primeiras camadas do teste de hipótese de Ljung-Box. Ademais, o modelo escolhido deve ser simples e parcimonioso.

Dentre os modelos testados, somente o AR(38), o AR(39) e o AR(40) atendem aos requisitos em todas as séries analisadas. A Tabela 3 mostra que, pelo teste da sobrefixação, a adição de parâmetros não promove redução significativa na variância residual. Então, o modelo selecionado é o AR(38) pois apresenta o menor número de parâmetros, estando em conformidade com o princípio da parcimônia.

Tabela 3: Variância residual dos modelos estimados

AR(p)	Variância
p	residual
37	41,13
38	41,12
39	41,12
40	41,00

Analisando os resíduos do modelo AR(38), o primeiro gráfico da Figura 30 mostra o comportamento residual, em vermelho, comparado com os valores originais. Nota-se que o modelo apresenta boa aderência nos valores iniciais. Mas, a partir dos 50 segundos, os dados parecem ter média e desvio-padrão variável. Por sua vez, as curvas FAC e FACP apresentam valores significativos na camada 19. Os gráficos dos quantis residuais aparentam ser aproximadamente simétricos, pois as inclinações no topo direito e canto inferior esquerdo parecem ser iguais.

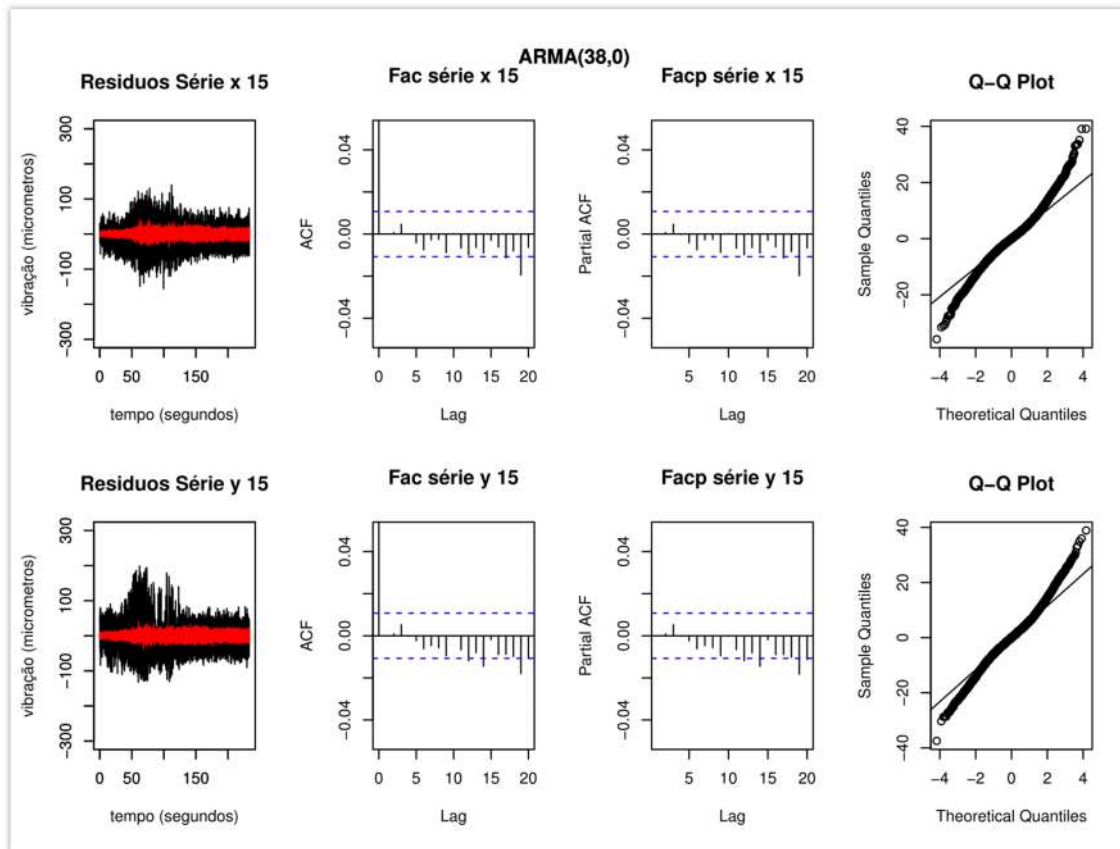


Figura 30: Gráficos dos resíduos, da FAC, da FACP e do quantil-quantil residual das séries selecionadas¹³.

Pela Figura 31, percebe-se que os resíduos padronizados¹⁴ apresentam valores fora do intervalo indicado, o que demonstra que o modelo não representa adequadamente as séries reais. As FACs e os resultado dos testes de Ljung-Box mostram que as séries não possuem correlações significativas. Todavia, como o modelo estimado não adere adequadamente as séries analisadas, então, o modelo ARFIMA será aplicado buscando melhorar a aderência do modelo.

¹³ Para o resultado completo, vide anexo IV

¹⁴ Resíduos padronizados são calculados dividindo os resíduos pelo desvio-padrão estimado. Eles devem apresentar média zero e variância igual a 1. A maioria encontra-se no intervalo entre [-3,3]. As observações fora deste intervalo podem evidenciar que o modelo não representa adequadamente o modelo real (VIEIRA, 2004).

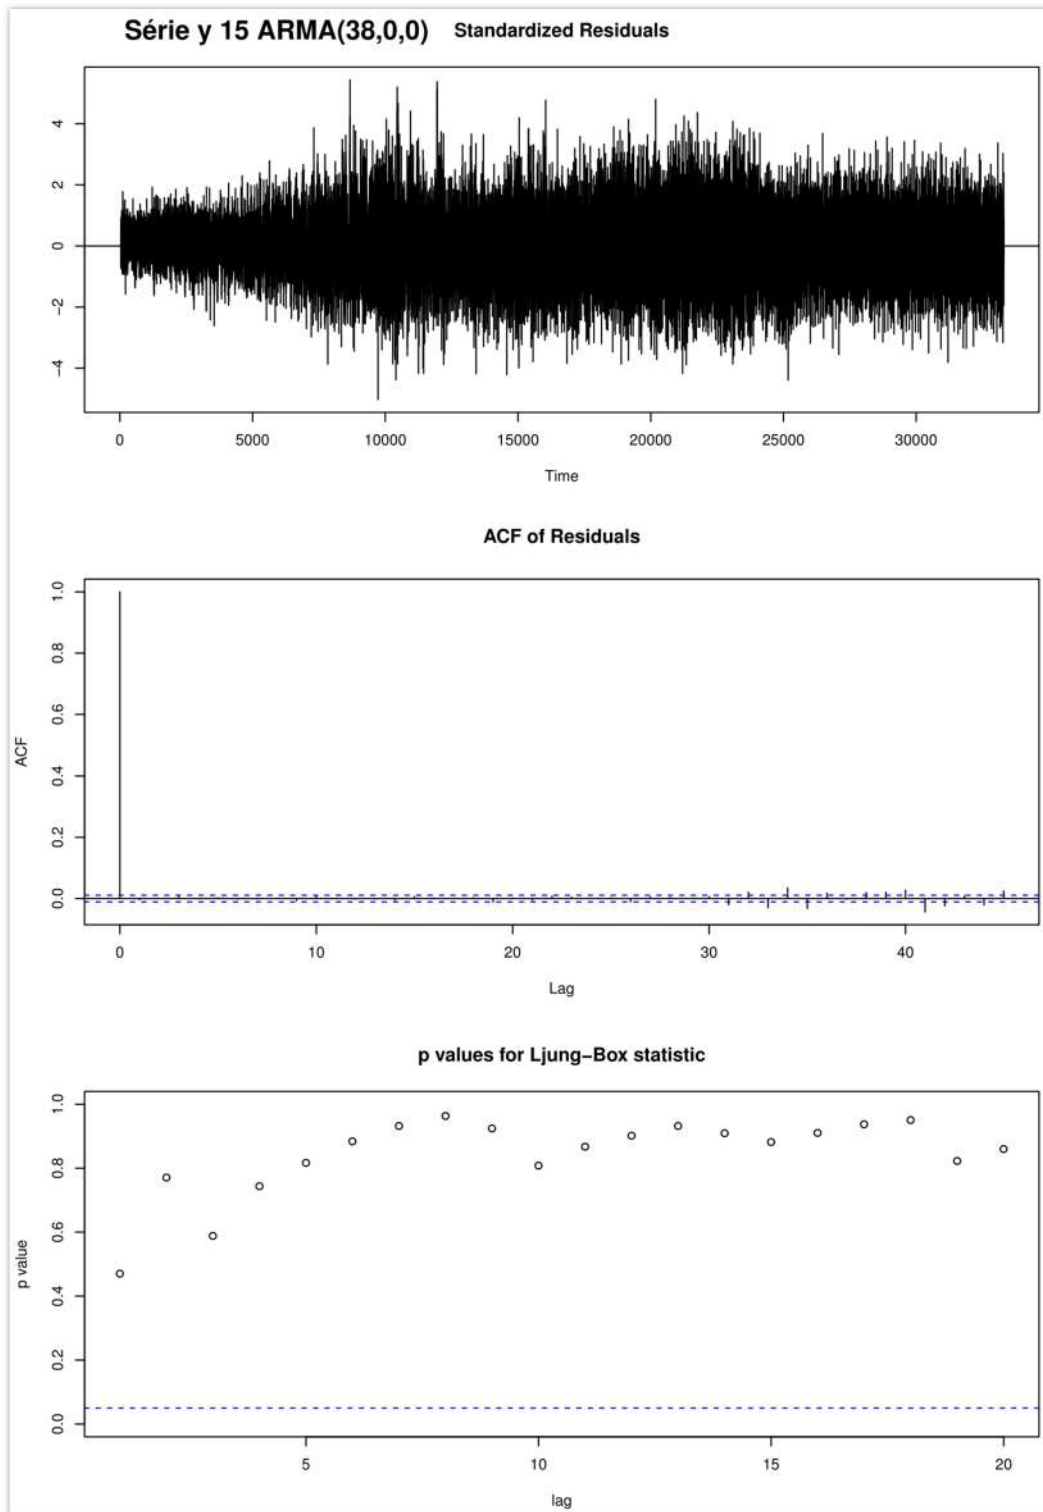


Figura 31: Resíduos padronizados, FAC e teste de Ljung-Box da série selecionada¹⁵.

¹⁵ Para o resultado completo, vide anexo IV

6.3.2 PROCESSO COM MEMÓRIA LONGA

Seguindo a metodologia proposta, a aplicação da função *fracdiff*¹⁶ para determinar o valor do parâmetro d , dado um valor de p e q , resulta na Figura 32, na Figura 33 e na Figura 34.

No primeiro processo, com valor de q igual a zero, a Figura 32 mostra os valores de d estimados pela função com o p variando de 0-20. Com o aumento do q , os valores do parâmetro d tendem a zero, como pode ser visto na Figura 33 e Figura 34. Isso sugere que valores pequenos de p e q devem ser suficientes no processo ARFIMA.

Dessa forma, pela Figura 32, os modelos testes iniciais são ARFIMA(1, 0,3, 0), ARFIMA(1,0,1,0) e ARFIMA(1,0,5,0). Pela Figura 33, tem-se ARFIMA(3,0,5,1) e, pela Figura 34, tem-se ARFIMA(1,0,25,2).

¹⁶ Para obter mais informações, vide Capítulo 5.

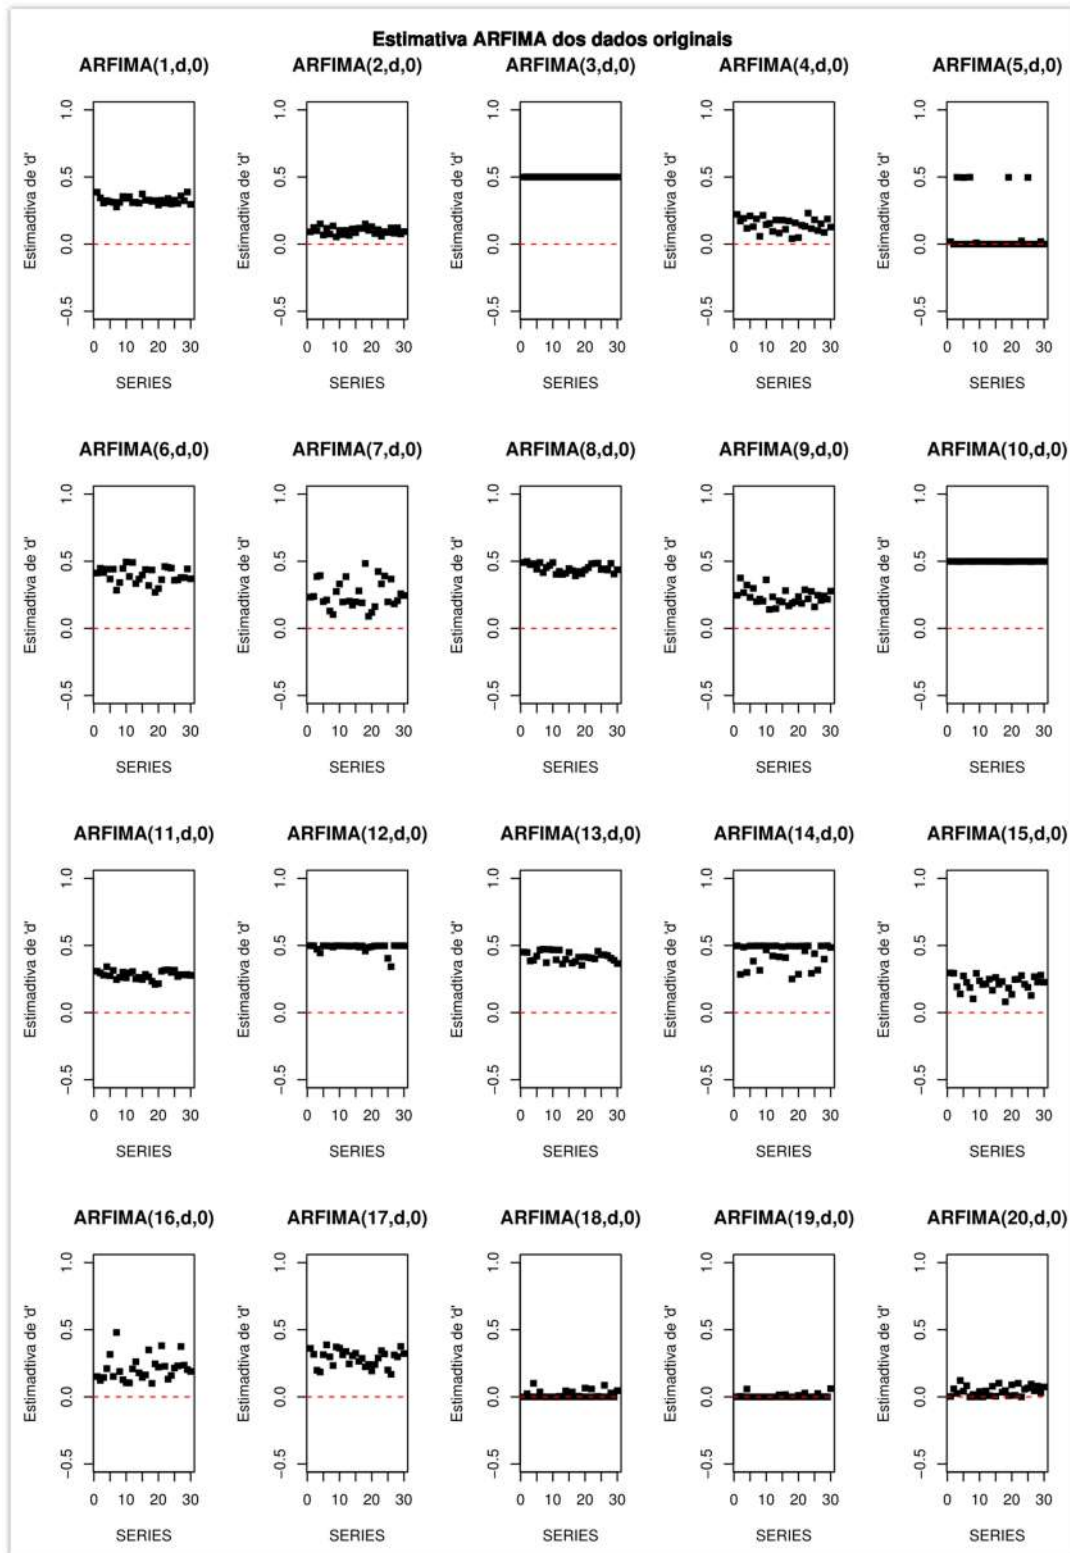


Figura 32: Estimativa do valor de d com q igual a zero nos dados originais

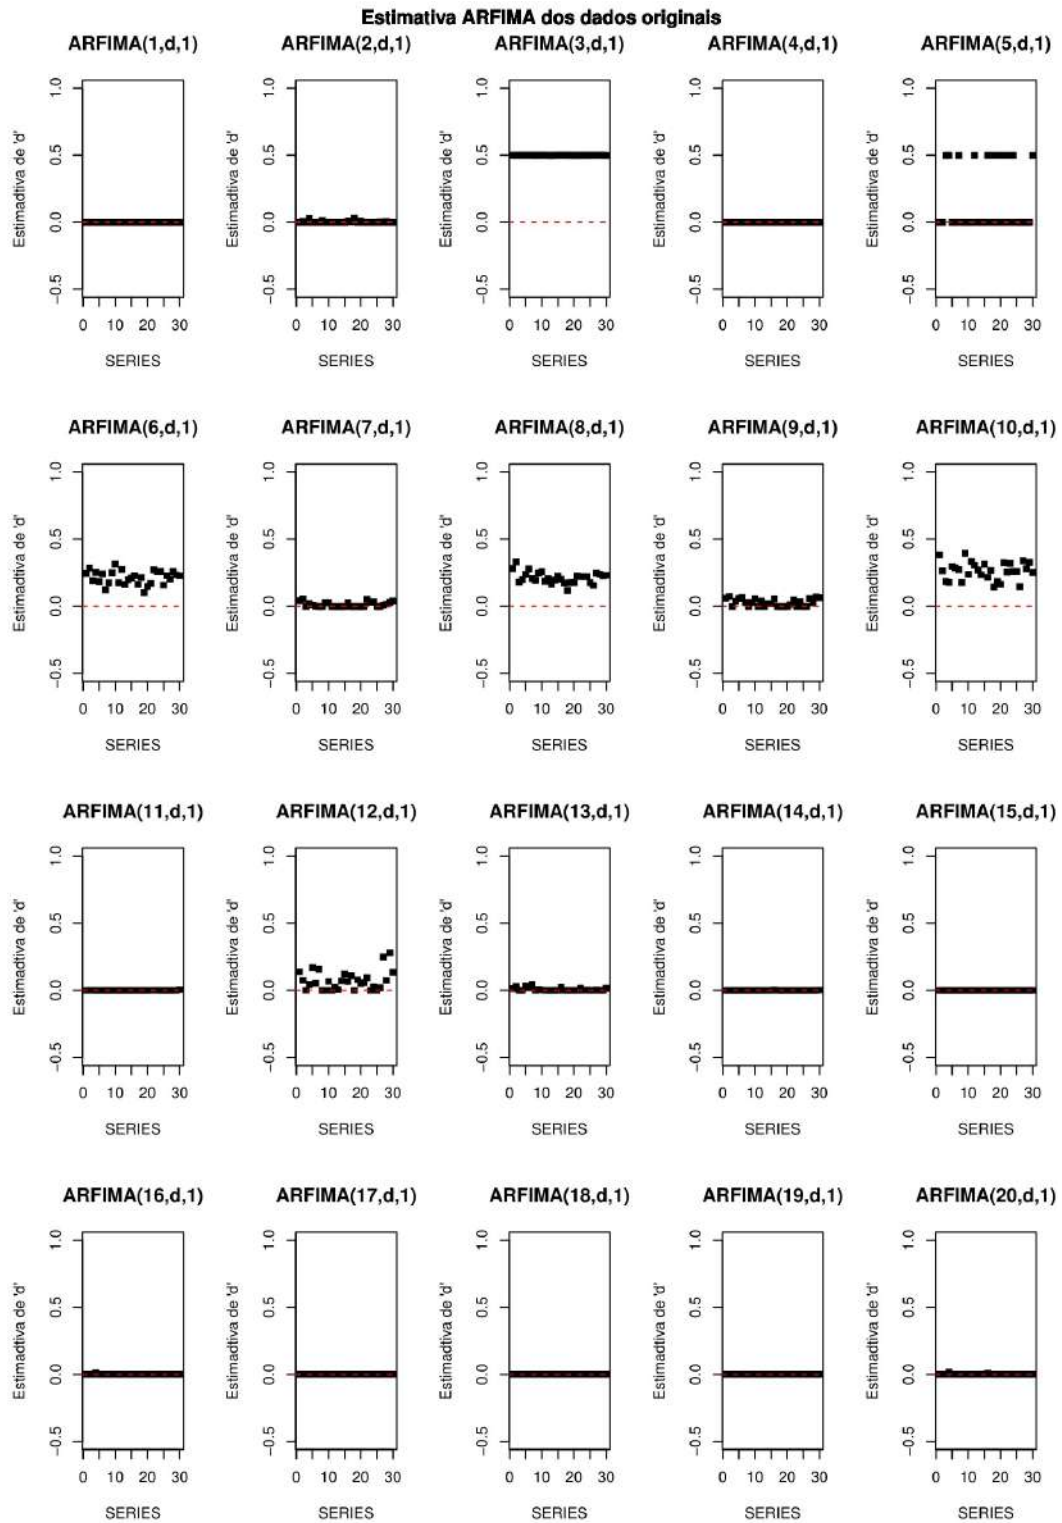


Figura 33: Estimativa do valor de d com $q=1$

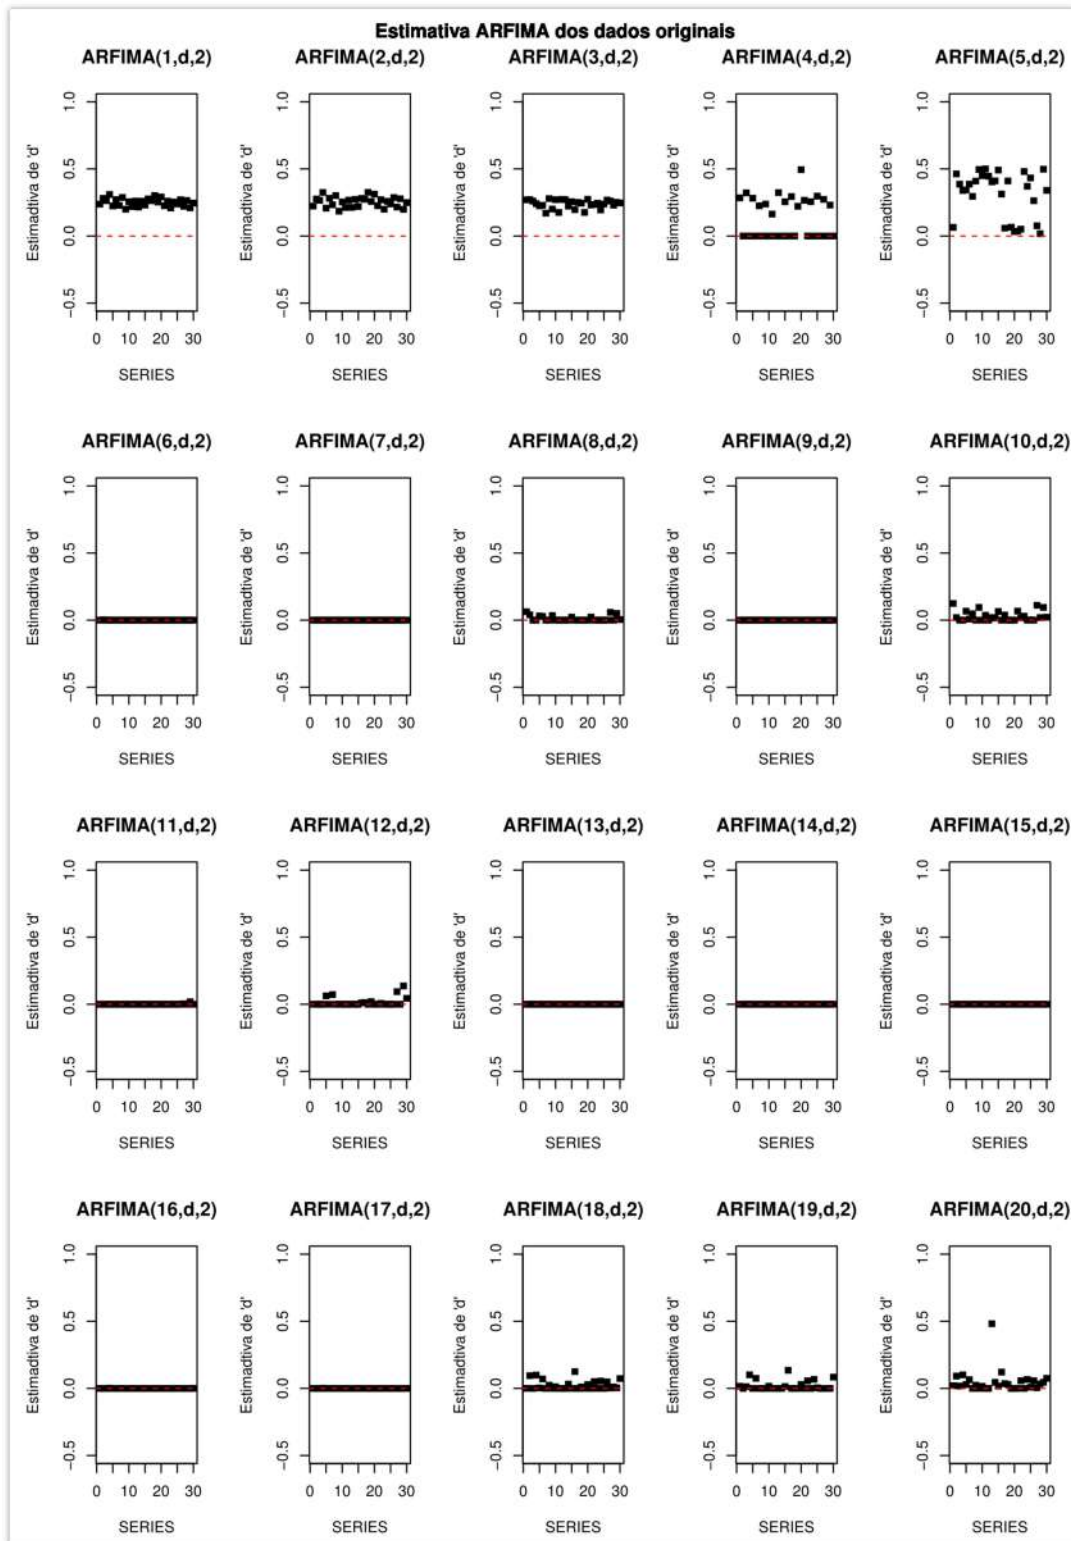


Figura 34: Estimativa do valor de d com $q=2$

Todos os modelos estimados apresentaram correlações significativas nas curvas FAC e FACP, além dos p-valores menores do que 0,05 no teste de Ljung-Box. A Figura 35, por exemplo, mostra o resultado obtido com o ARFIMA (1,0,3,0). Nota-se que não

há uma melhora na aderência dos dados residuais quando comparado com o resultado do modelo AR(38). Esse mesmo resultado foi obtido em todas as séries modeladas, como pode ser visto no ANEXO IV.

Esta dificuldade de atenuação pode ser causada pelo tamanho das séries analisadas. Por isso, uma opção é a separação dos dados levando em consideração os regimes operacionais nos quais a máquina operou.

Assim, os dados serão separados em regime transiente e permanente. Essa divisão será baseada nos resultados obtidos na análise exploratória, nos quais o regime transiente parece terminar por volta dos 200 segundos. Após esse período, começa o regime permanente.

Sabe-se que a maior probabilidade de degradação no mancal guia de UHEs ocorre durante o período transiente uma vez que a máquina está atuando fora da sua faixa operacional. Então, este trabalho focou na modelagem dos dados provenientes do período transiente.

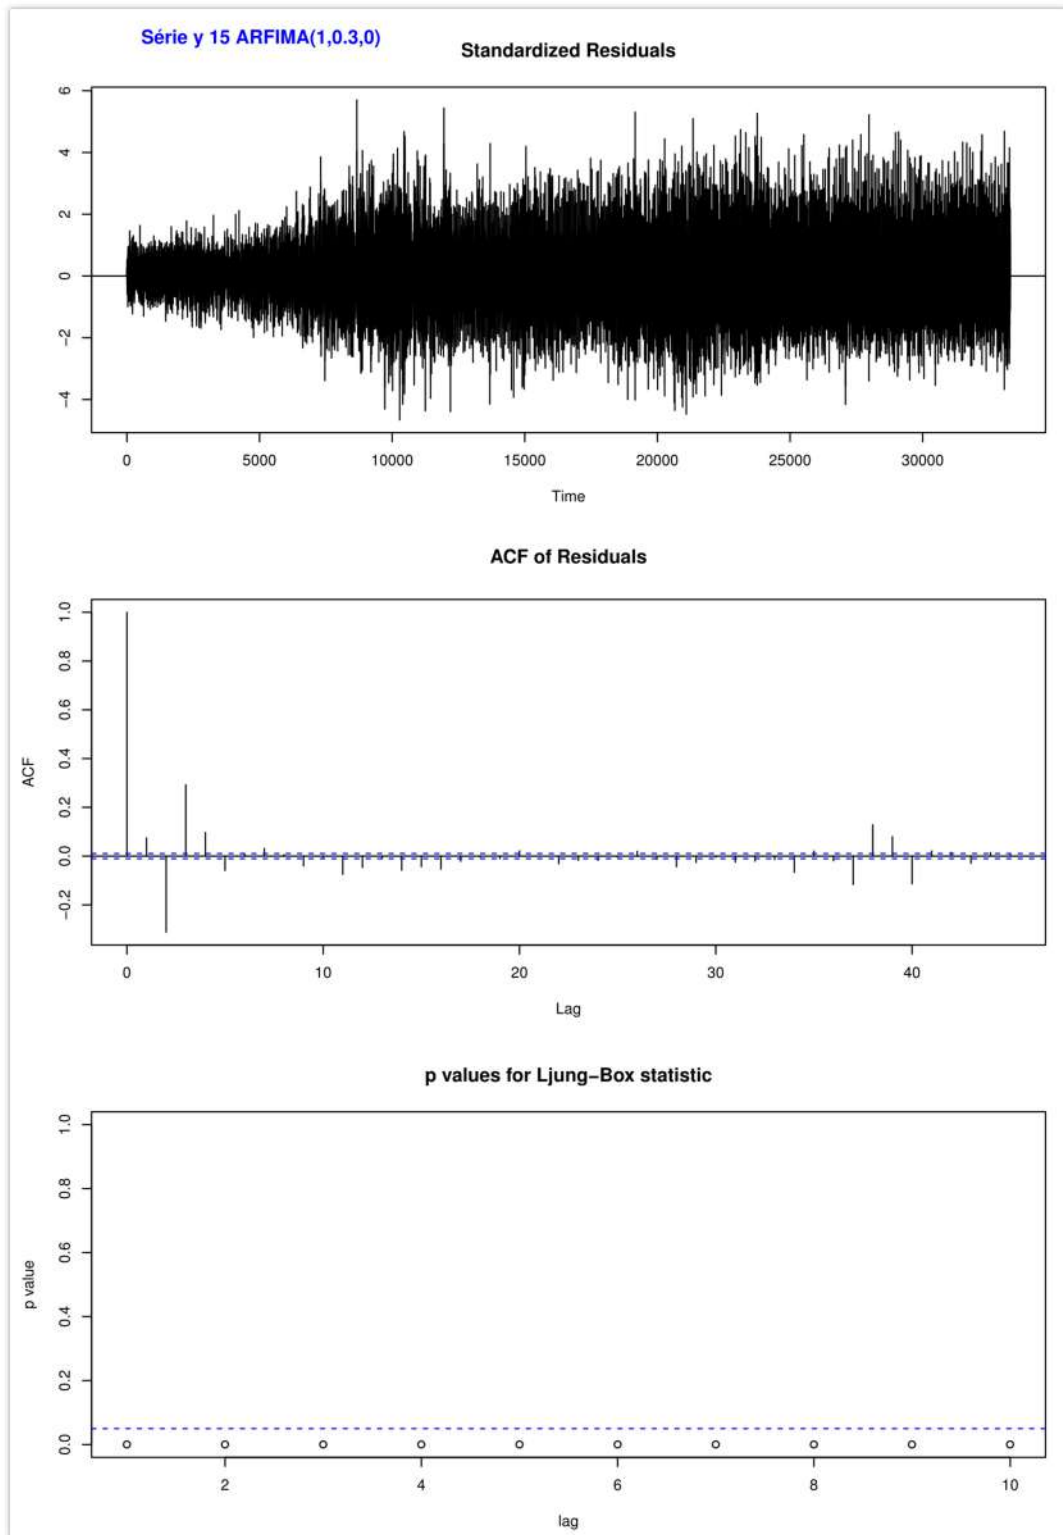


Figura 35: Resultado dos resíduos do modelo ARFIMA (1,0,3,0) nas séries selecionadas¹⁷.

¹⁷ Para o resultado completo, vide anexo IV

6.4 CASO 2 - ESTUDO DOS DADOS TRANSIENTE

Esta seção aborda a modelagem dos dados produzidos durante o período transiente. A Figura 36 mostra as séries ao longo do tempo, percebe-se que as séries direção y apresentam picos mais altos, o que pode estar relacionado com o desbalanceamento do rotor.

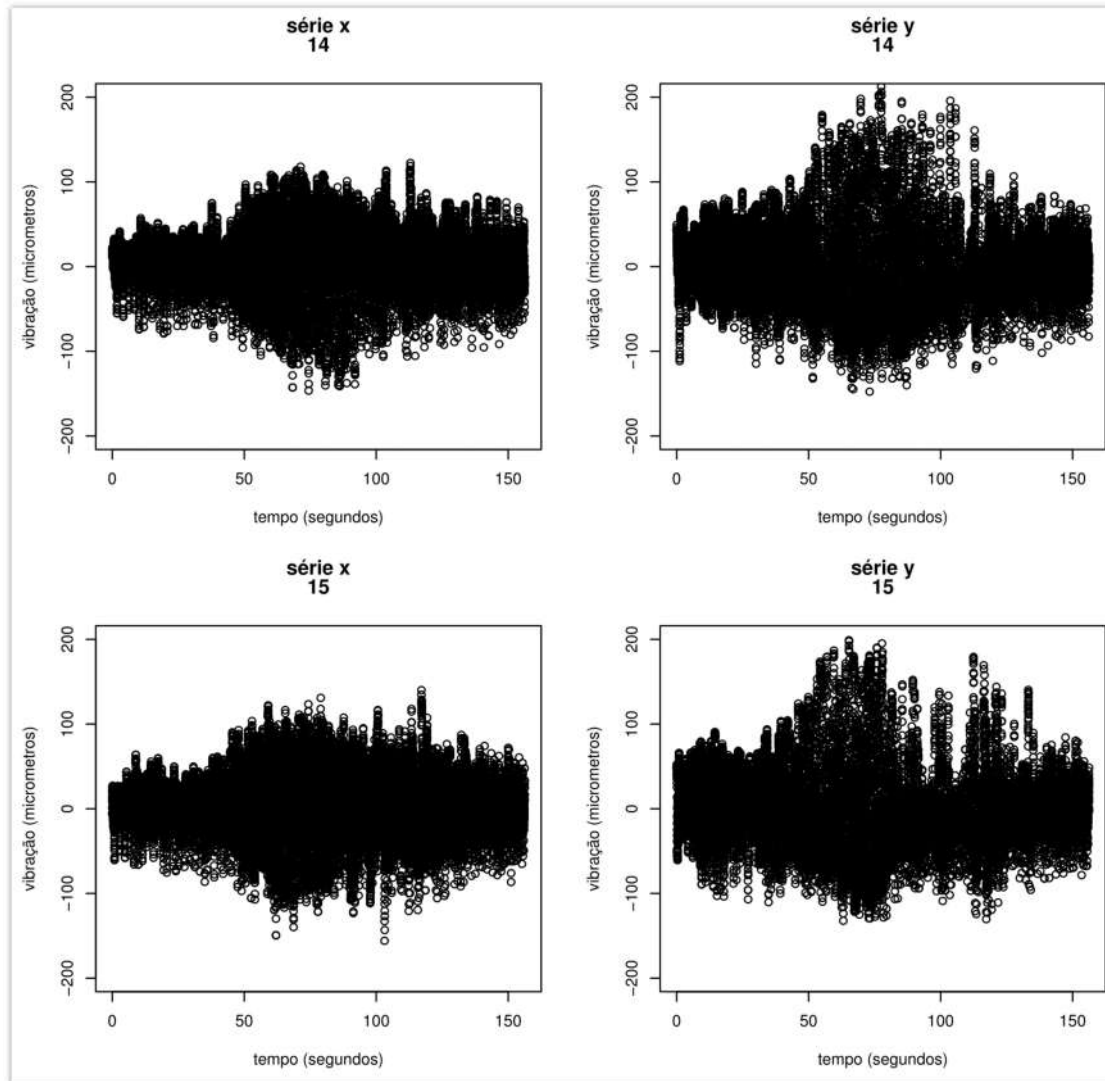


Figura 36: Séries de dados selecionadas ¹⁸ durante o período transiente

O processamento dos dados segue a mesma modelagem das séries originais. Inicialmente, é feita uma análise descritiva, verificando histogramas, gráficos dos

¹⁸ Para o resultado completo, vide anexo V.

quantis e curvas FAC e FACP. Em seguida, a metodologia proposta é aplicada com o intuito encontrar o modelo mais adequado aos dados analisados.

Os histogramas e os gráficos dos quantis representados pela Figura 37 e Figura 38, respectivamente, mostram a distribuição dos dados. As séries na direção x parecem ser simétricas, uma vez que os gráficos dos quantis tem boa aderência à curva de referência. Enquanto que as séries na direção y aparentam estar mais concentradas nos valores negativos, ou seja, elas apresentam leve assimetria a direita, pois os dados no extremo superior do gráfico dos quantis são mais inclinados.

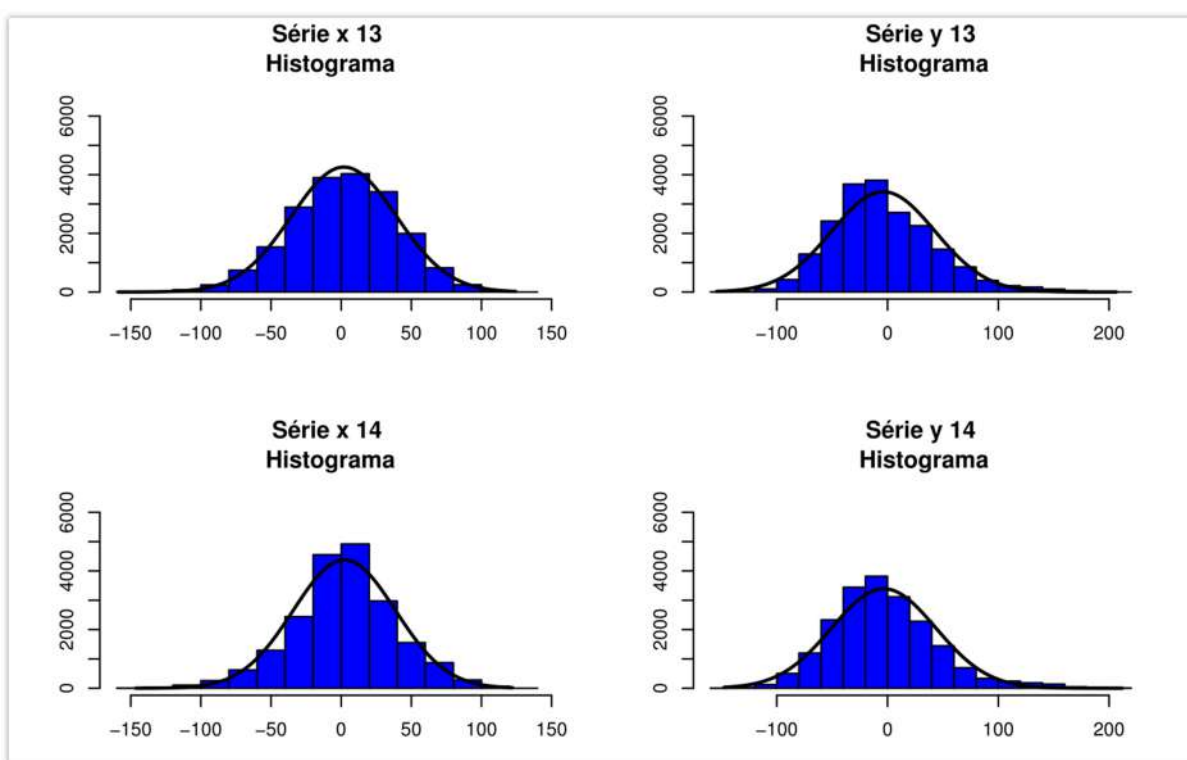


Figura 37: Histograma das séries transientes selecionadas¹⁹

¹⁹ Para o resultado completo, vide anexo V.

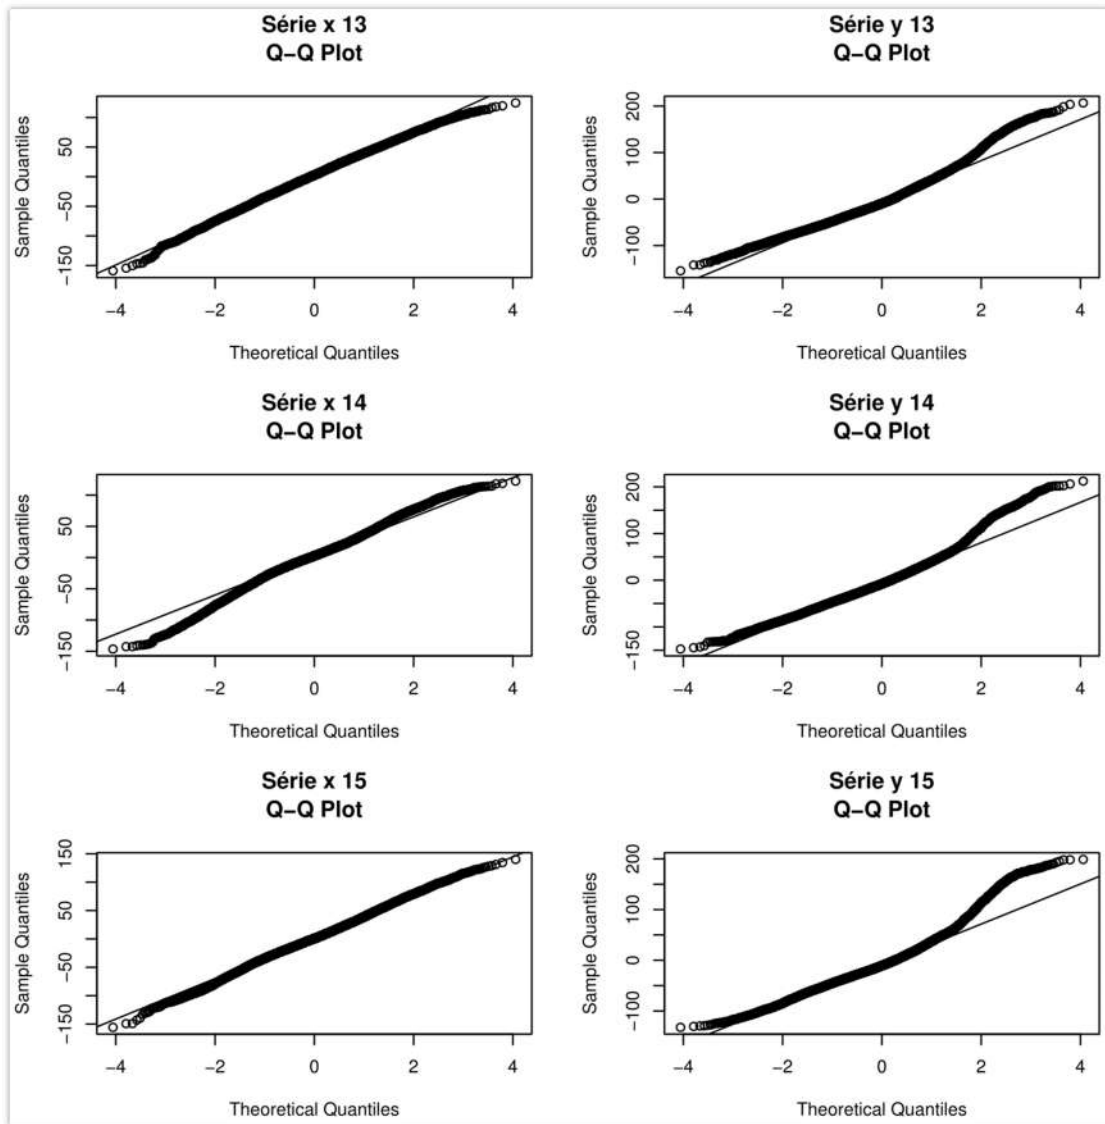


Figura 38: Gráfico quantil-quantil das séries transientes selecionadas²⁰

Entretanto, pelo teste de normalidade de Anderson-Darling, não foi possível aceitar a hipótese nula de normalidade, uma vez que os p-valores foram menores que 0,05, conforme pode ser visto no Quadro 2.

²⁰ Para o resultado completo, vide anexo V.

[1] "Série x 13"		[1] "Série y 13"	
Anderson-Darling normality test			
data: dados.trans[, i]		data: dados.trans[, i]	
A =	48.997	A =	106.01
p-value =	4,05E-09	p-value	< 2.2e-16
[1] "Série x 14"		[1] "Série y 14"	
Anderson-Darling normality test			
data: dados.trans[, i]		data: dados.trans[, i]	
A =	43.037	A =	94.583,00
p-value	< 2.2e-16	p-value	< 2.2e-16
[1] "Série x 15"		[1] "Série y 15"	
Anderson-Darling normality test			
data: dados.trans[, i]		data: dados.trans[, i]	
A =	12.184,00	A =	168.83,
p-value	< 2.2e-16	p-value	< 2.2e-16

Quadro 2: Teste de normalidade de Anderson-Darling nas séries selecionadas

As funções de autocorrelação das séries no período transiente da máquina (Figura 39) possuem decaimento senoidal sem ocorrer corte nas defasagens, tal como os dados originais, esses dados devem seguir um modelo AR puro ou ARMA.

Analisando as funções de autocorrelação parcial (Figura 40), pode-se perceber que existe corte na camada 20, aproximadamente. Por isso, os dados analisados podem ser inicialmente modelados usando o AR puro.

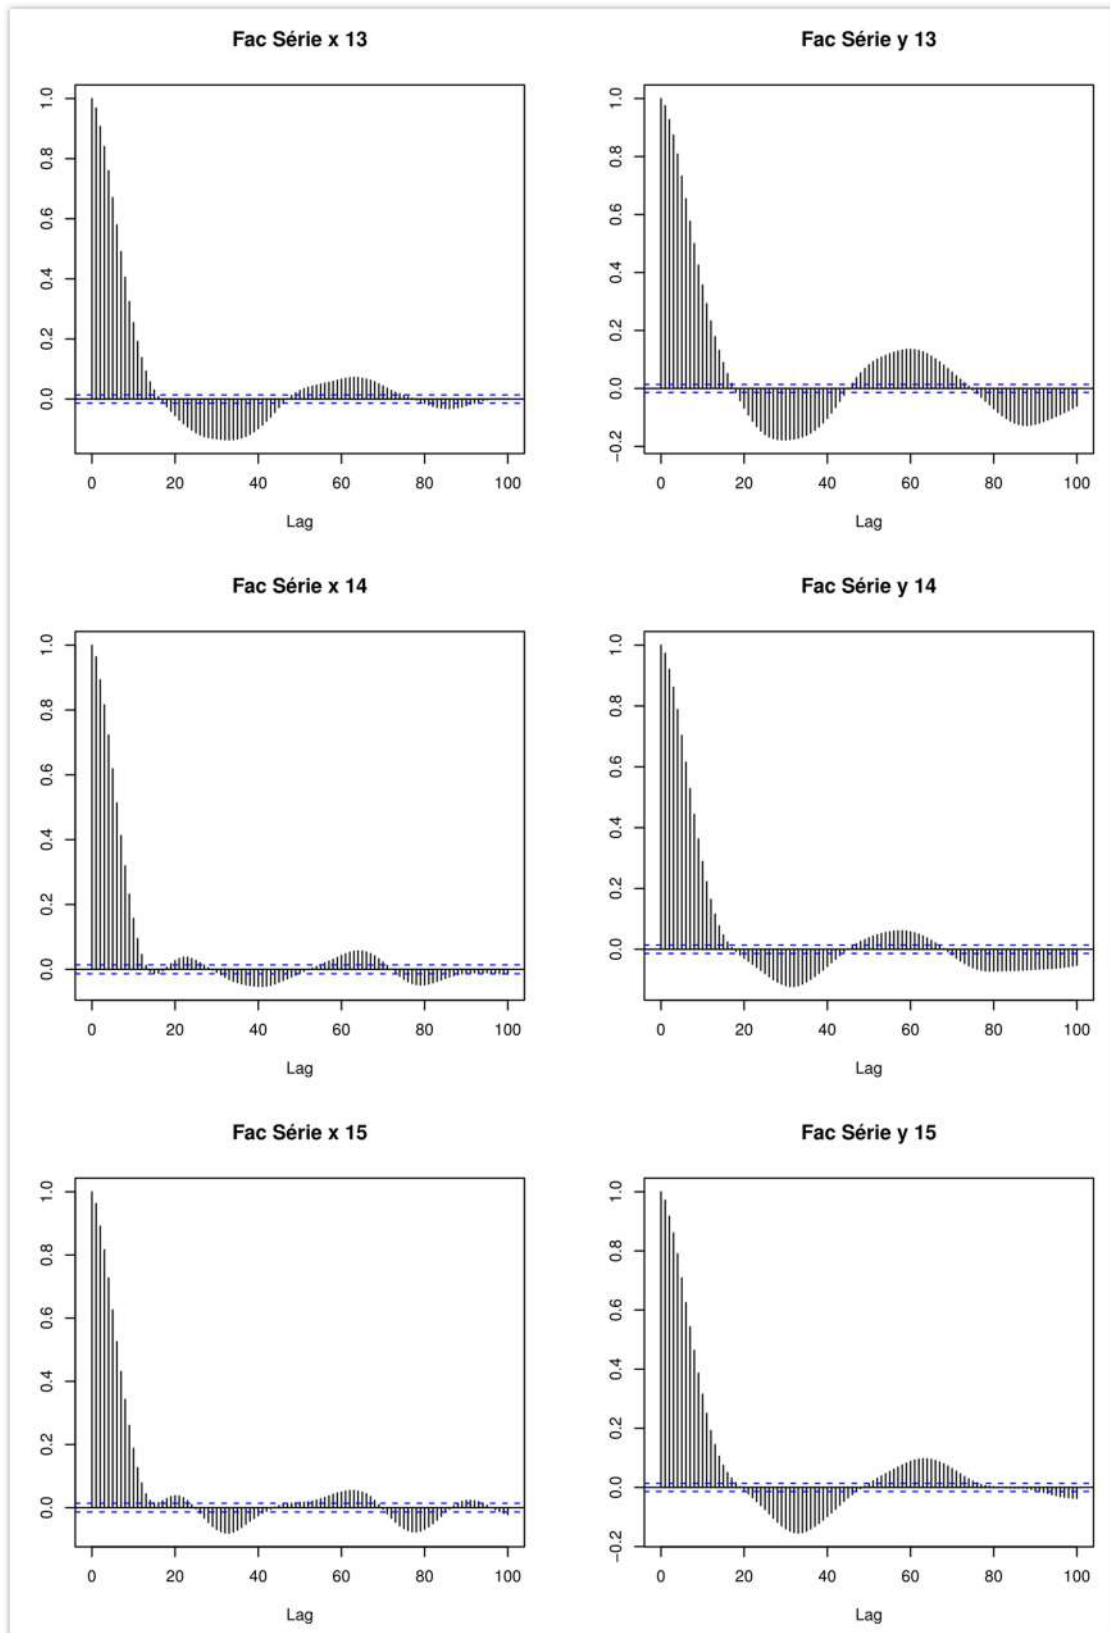


Figura 39: Curvas de autocorrelação das séries transientes selecionadas²¹

²¹ Para o resultado completo, vide anexo V.

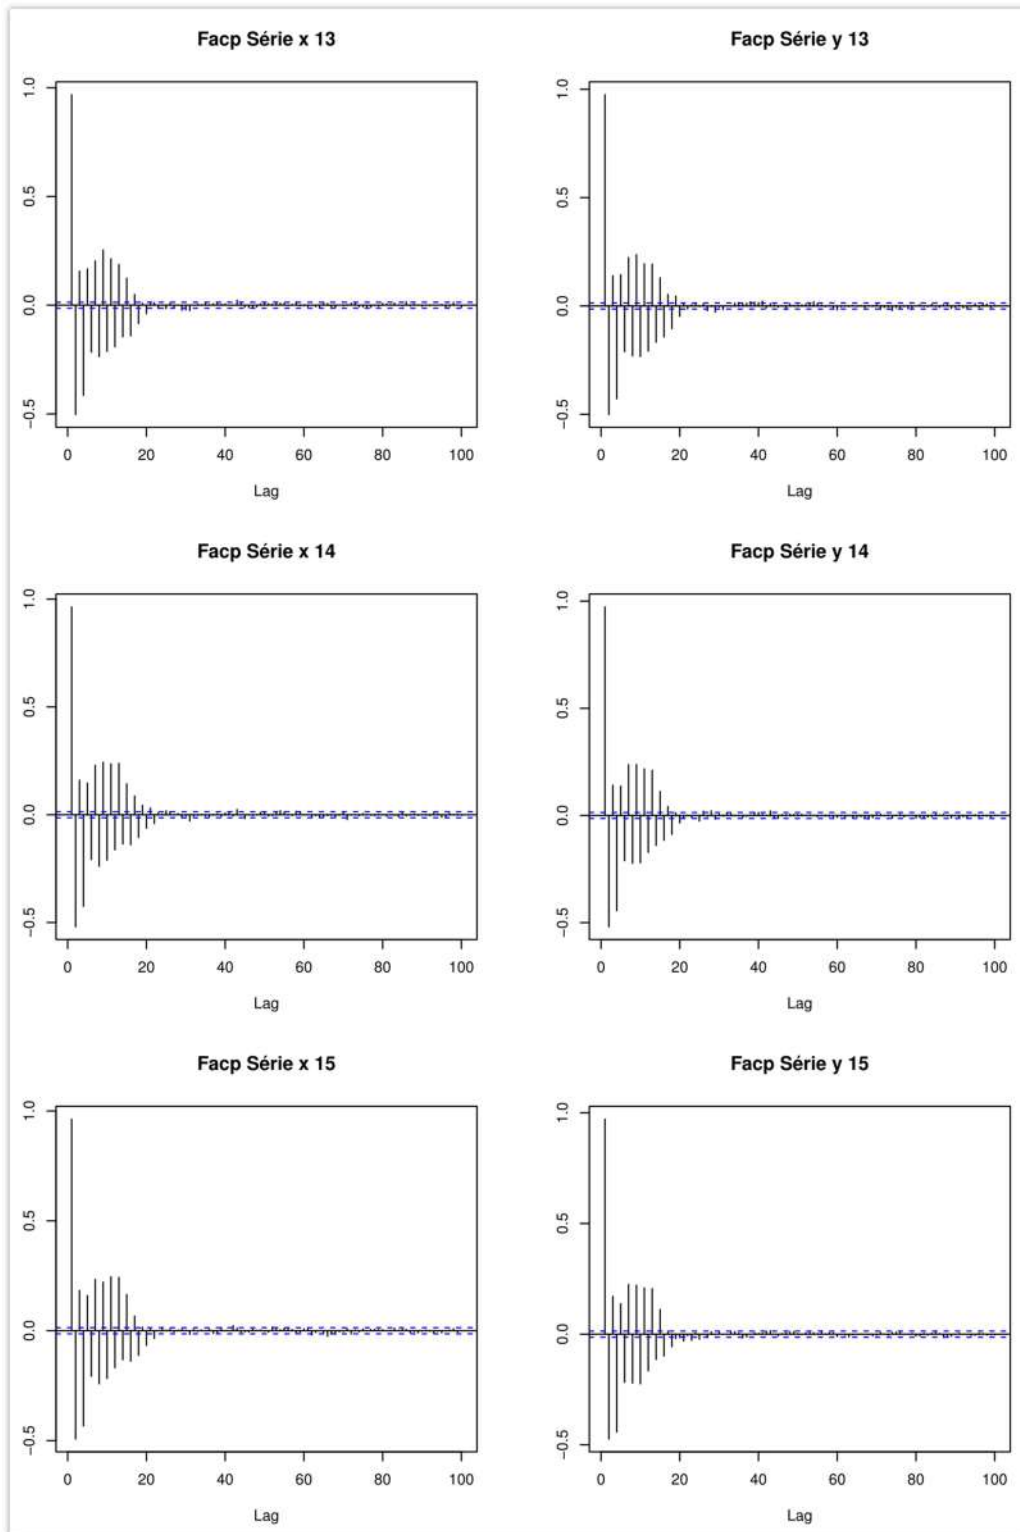


Figura 40: Curvas de FACP das séries transientes selecionadas²²

²² Para o resultado completo, vide anexo V.

6.4.1 PROCESSOS LINEARES

Conforme o resultado obtido na seção anterior, o modelo AR(20) foi inicialmente estimado. A Figura 41 mostra a série *versus* os resíduos, em vermelho, a FAC, FACP e gráfico dos quantis residuais. É possível perceber que a FAC e FACP apresentam correlações significativas.

A partir desse modelo, duas novas possibilidades podem ser consideradas. A primeira é o aumento gradual do parâmetro p do processo AR até que não existam correlações significativas nas séries em estudo. Neste caso, esse requisito foi atendido no AR(25). A outra possibilidade é a aplicação do processo ARMA, em tal caso, a primeira opção foi o ARMA(20,1), que atendeu aos requisitos analisados.

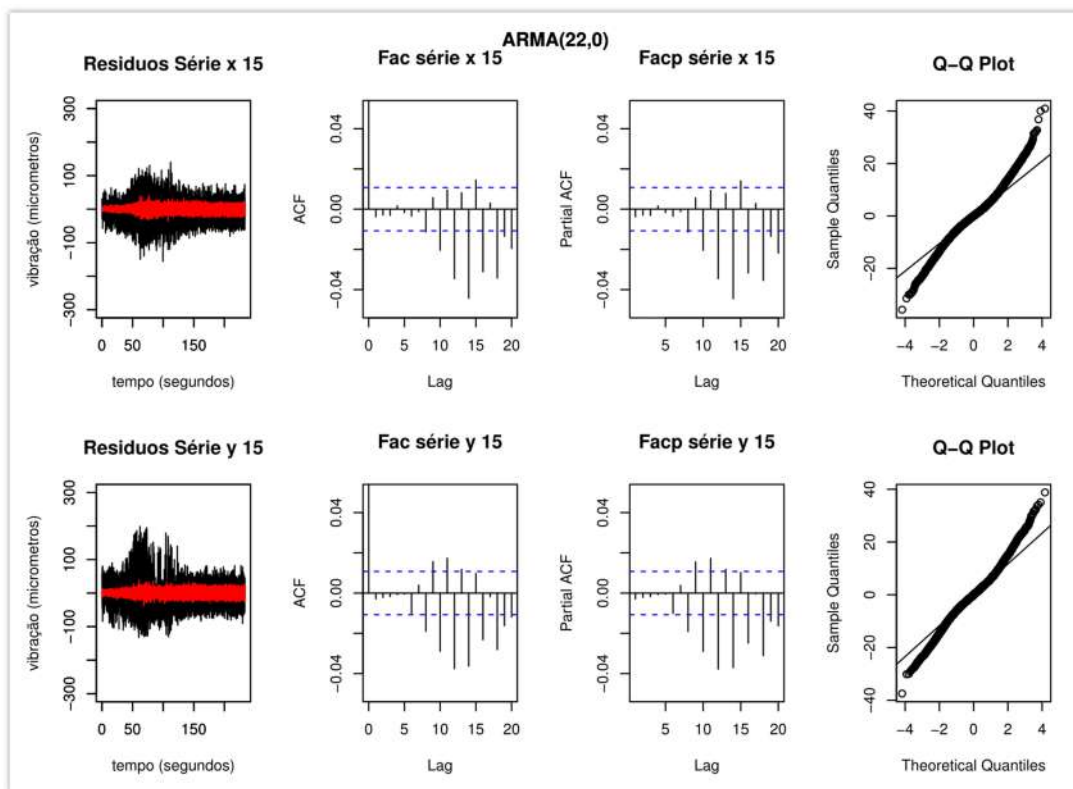


Figura 41: Processo AR(20) para as séries transientes selecionadas

Os modelos AR(25) e ARMA(20,1) atendem aos requisitos da etapa de verificação da abordagem de Box & Jenkins. Mas ainda é preciso testar o ajuste do modelo com a aplicação do teste da sobrefixação. Os resultados desse teste estão expostos na Tabela 4.

Tabela 4: Modelos testados na técnica da sobreposição

DADOS TRANSIENTE ORIGINAIS		
ARMA		Média da variância residual
p	q	
20	1	34,875
20	2	34,543
20	3	33,840
21	1	34,861
21	2	34,388
21	3	33,718
21	4	33,780
22	3	33,626
22	4	33,657
23	3	33,692
25	0	34,737
26	0	34,677

Segundo a Tabela 4, a menor variância residual foi o ARMA(22,3), a Figura 42 mostra que a FAC e FACP residual não contêm correlações significativas. Porém, a série residual, em vermelho, não parece se comportar como ruído branco. Associado a isso, o gráfico quantil-quantil mostra que as séries residuais são assimétricas a direita.

O gráfico dos resíduos padronizados da Figura 43 mostra que o modelo selecionado não se ajusta adequadamente as séries analisadas, uma vez que existem valores fora do intervalo [-3,3].

Apesar de as FACs não apresentarem correlações e dos p-valores serem maiores que 0,05 em todas as séries, o modelo parece não se ajustar adequadamente aos dados analisados. Isto motivou a aplicação do processo de memória longa e, posteriormente, o modelo não-linear, ARCH, para modelar a variância residual.

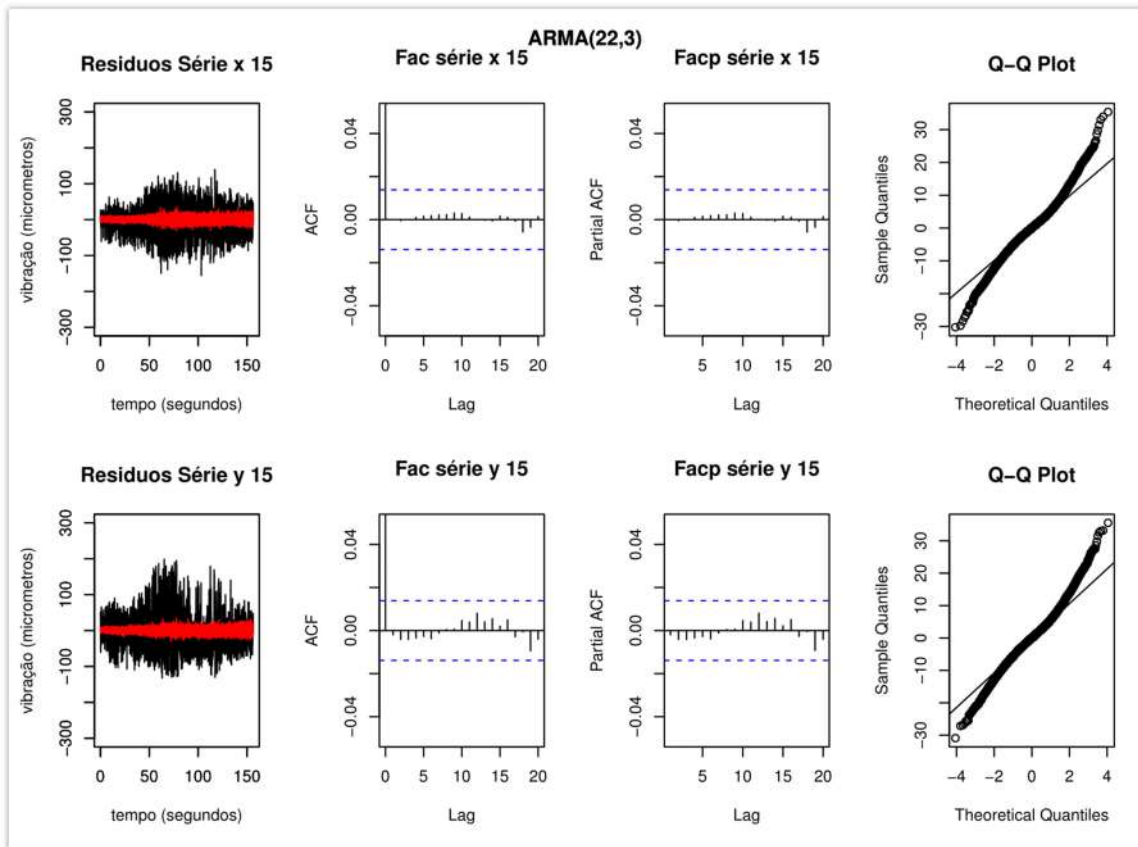


Figura 42: Comportamento dos resíduos do ARMA(22,3) das séries selecionadas²³.

²³ Para o resultado completo, vide anexo VI.

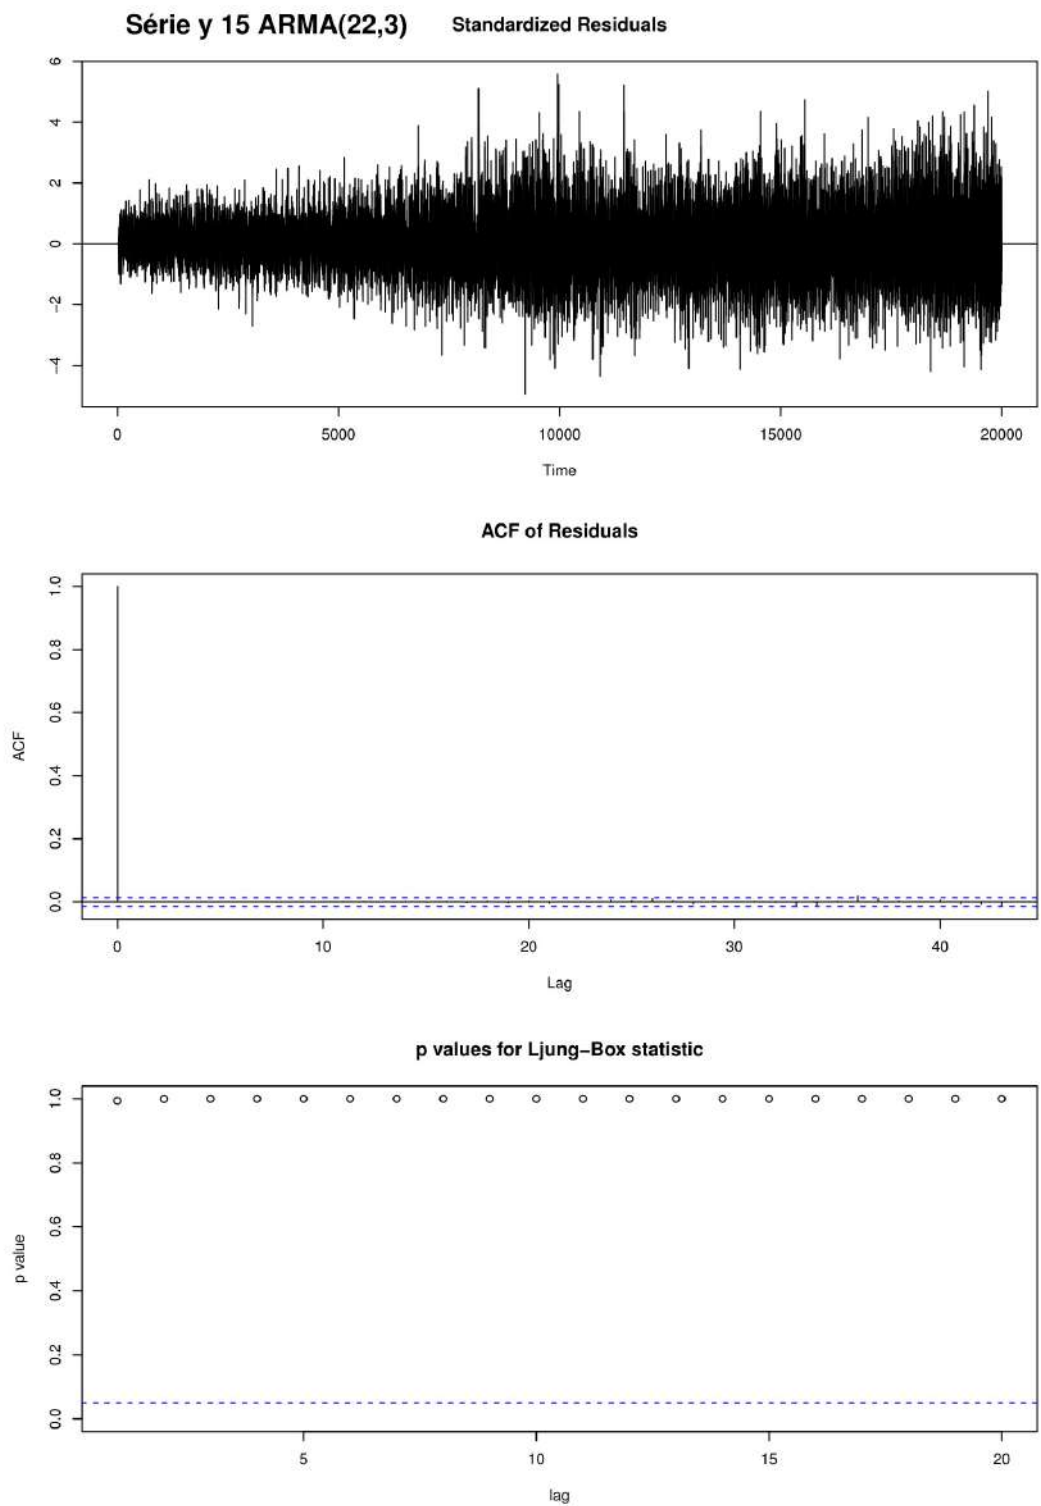


Figura 43: Resíduos padronizados, FAC e teste de Ljung-Box da série transiente selecionada²⁴

²⁴ Para o resultado completo, vide anexo VI.

6.4.2 PROCESSO COM MEMÓRIA LONGA

Seguindo os mesmos passos aplicados nas séries originais, o parâmetro d foi estimado para p variando de zero a vinte e q igual a zero, um e dois, conforme Figura 44, Figura 45 e Figura 46, respectivamente.

Da mesma forma que os dados originais, os valores de d se aproximam de zero com o aumento do p , exceto com p acima de 18 e q igual a 2. Neste caso, ocorre aumento dos valores do parâmetro d .

Com base nas figuras expostas, os modelos ARFIMA(1,0.5,0), (2,0.2,2), (3,0.5,0), (3,0.5,2), (6,0.4,1), (8,0.325,1) e o (10,0.5,0) foram identificados inicialmente.

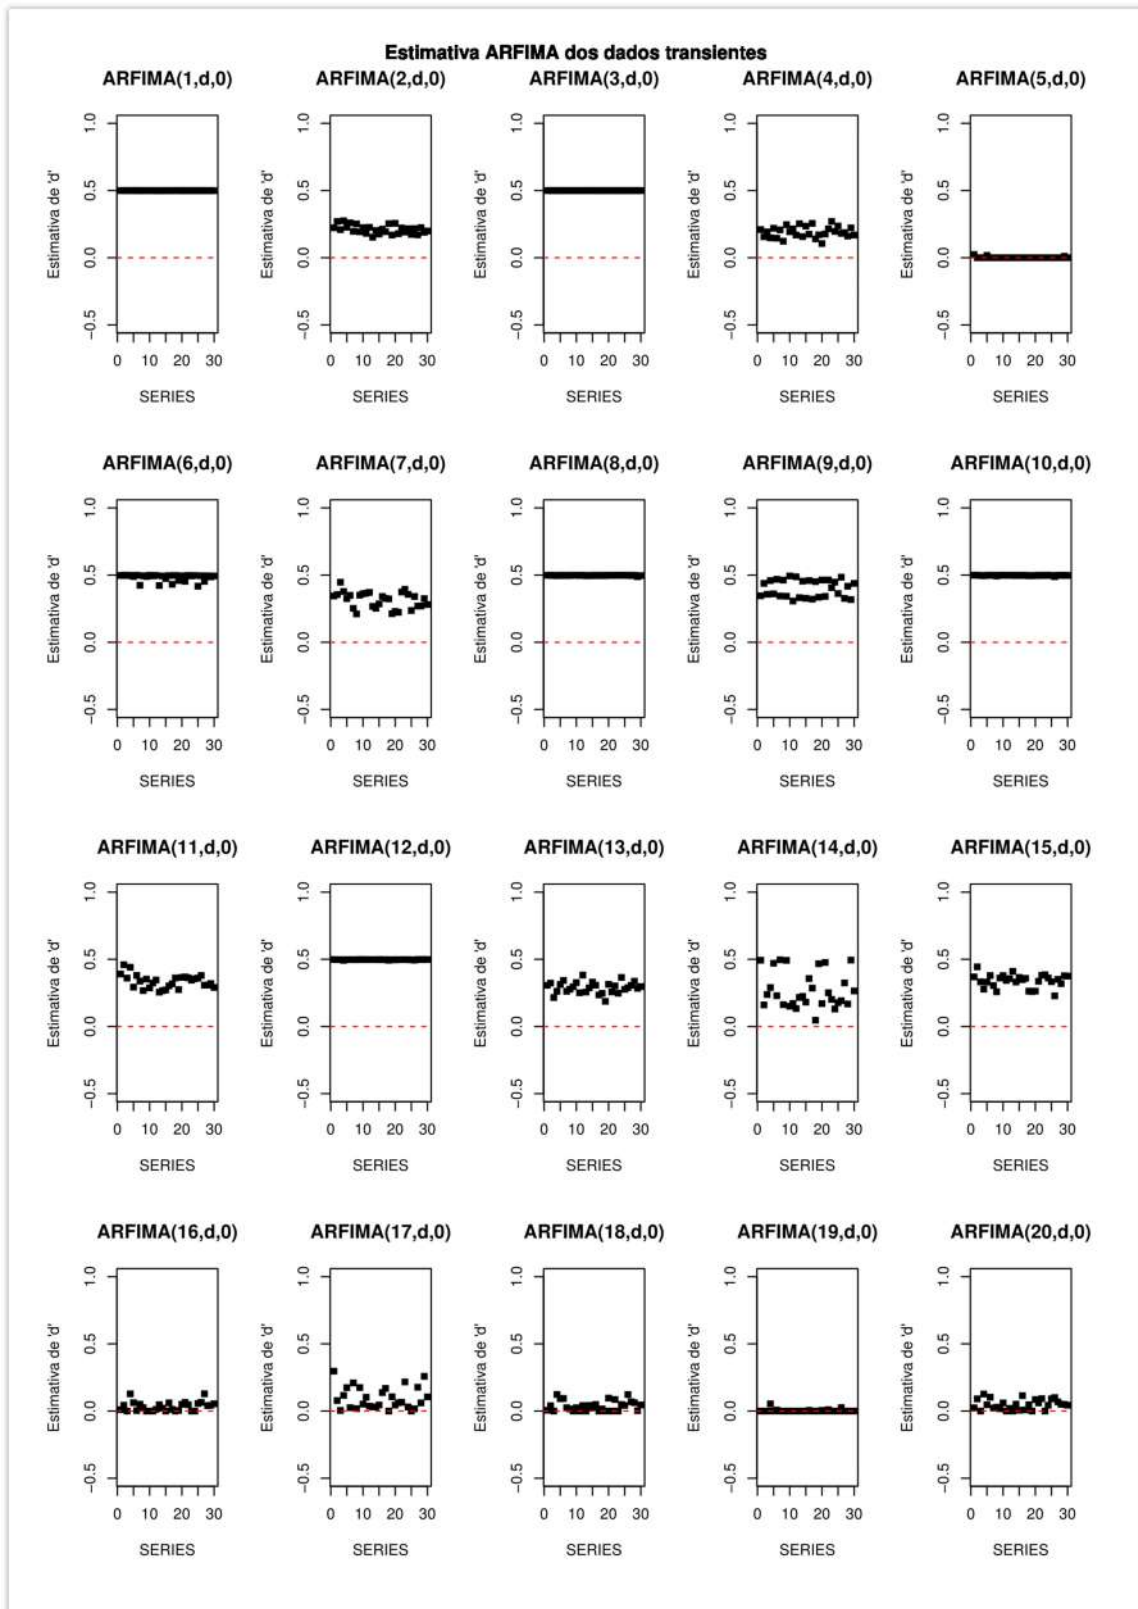


Figura 44: Estimativa do valor de d com $q=0$ para os dados transientes

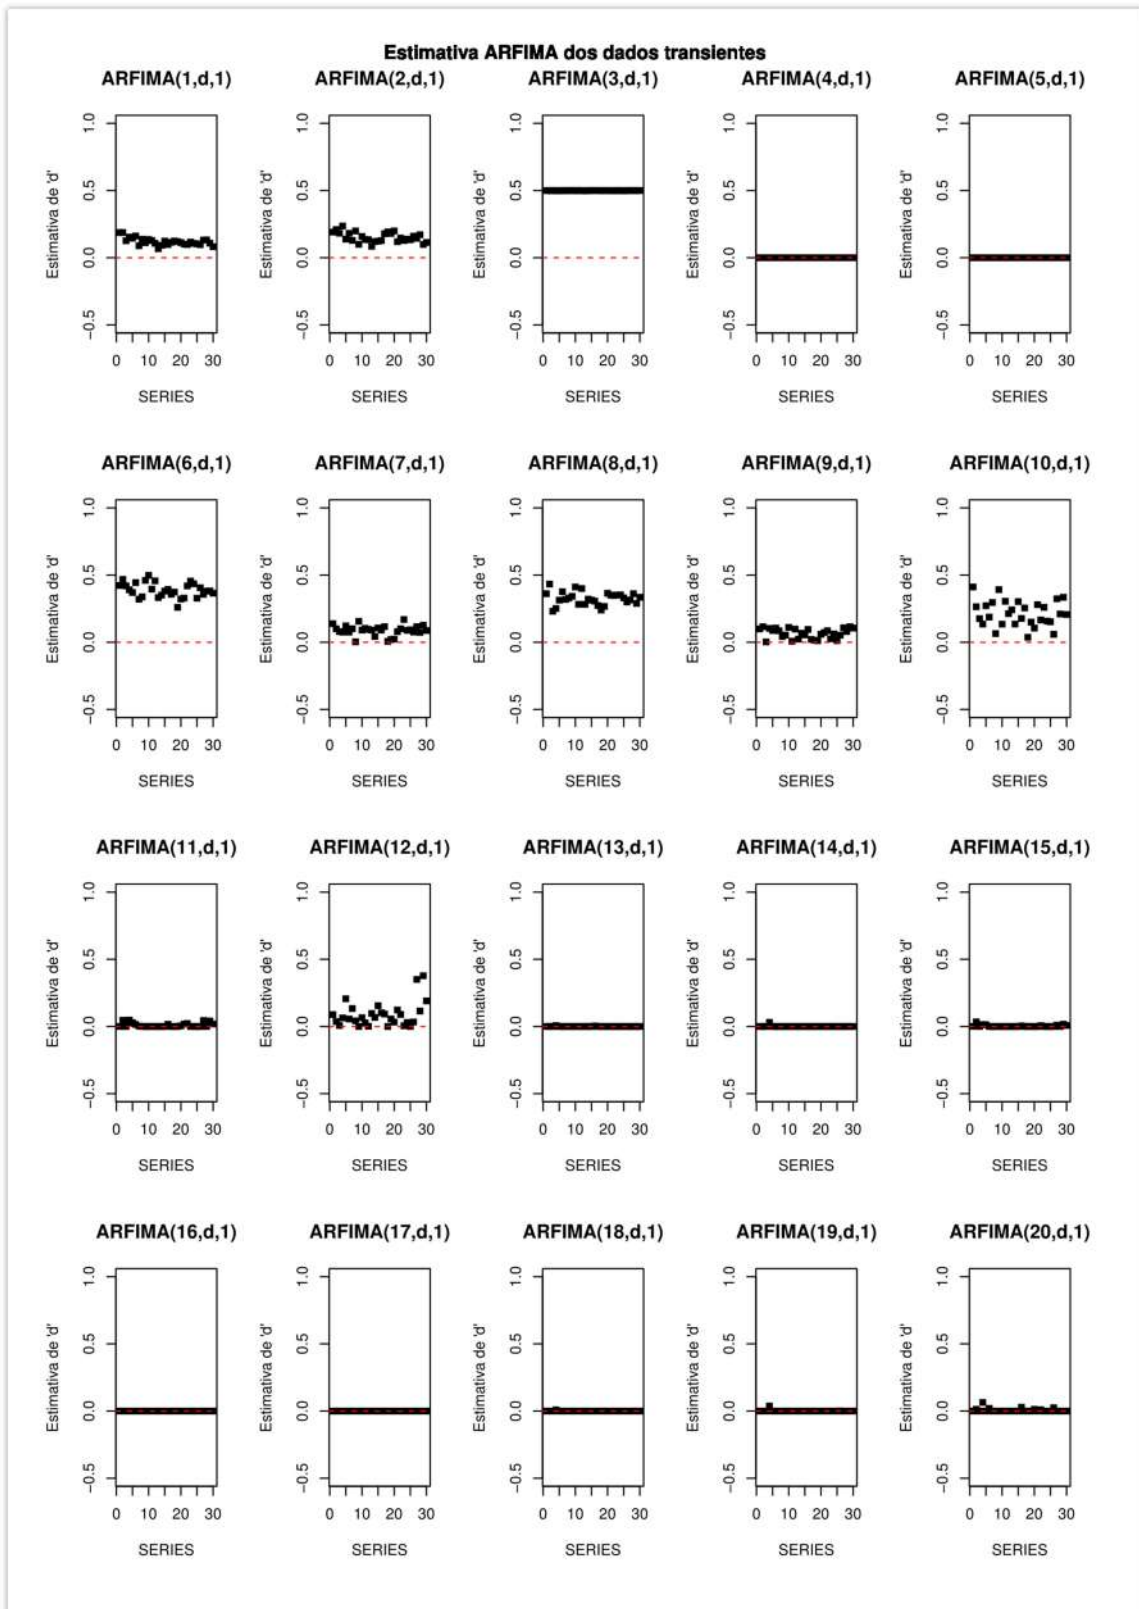


Figura 45: Estimativa do valor de d com $q=1$ para os dados transientes

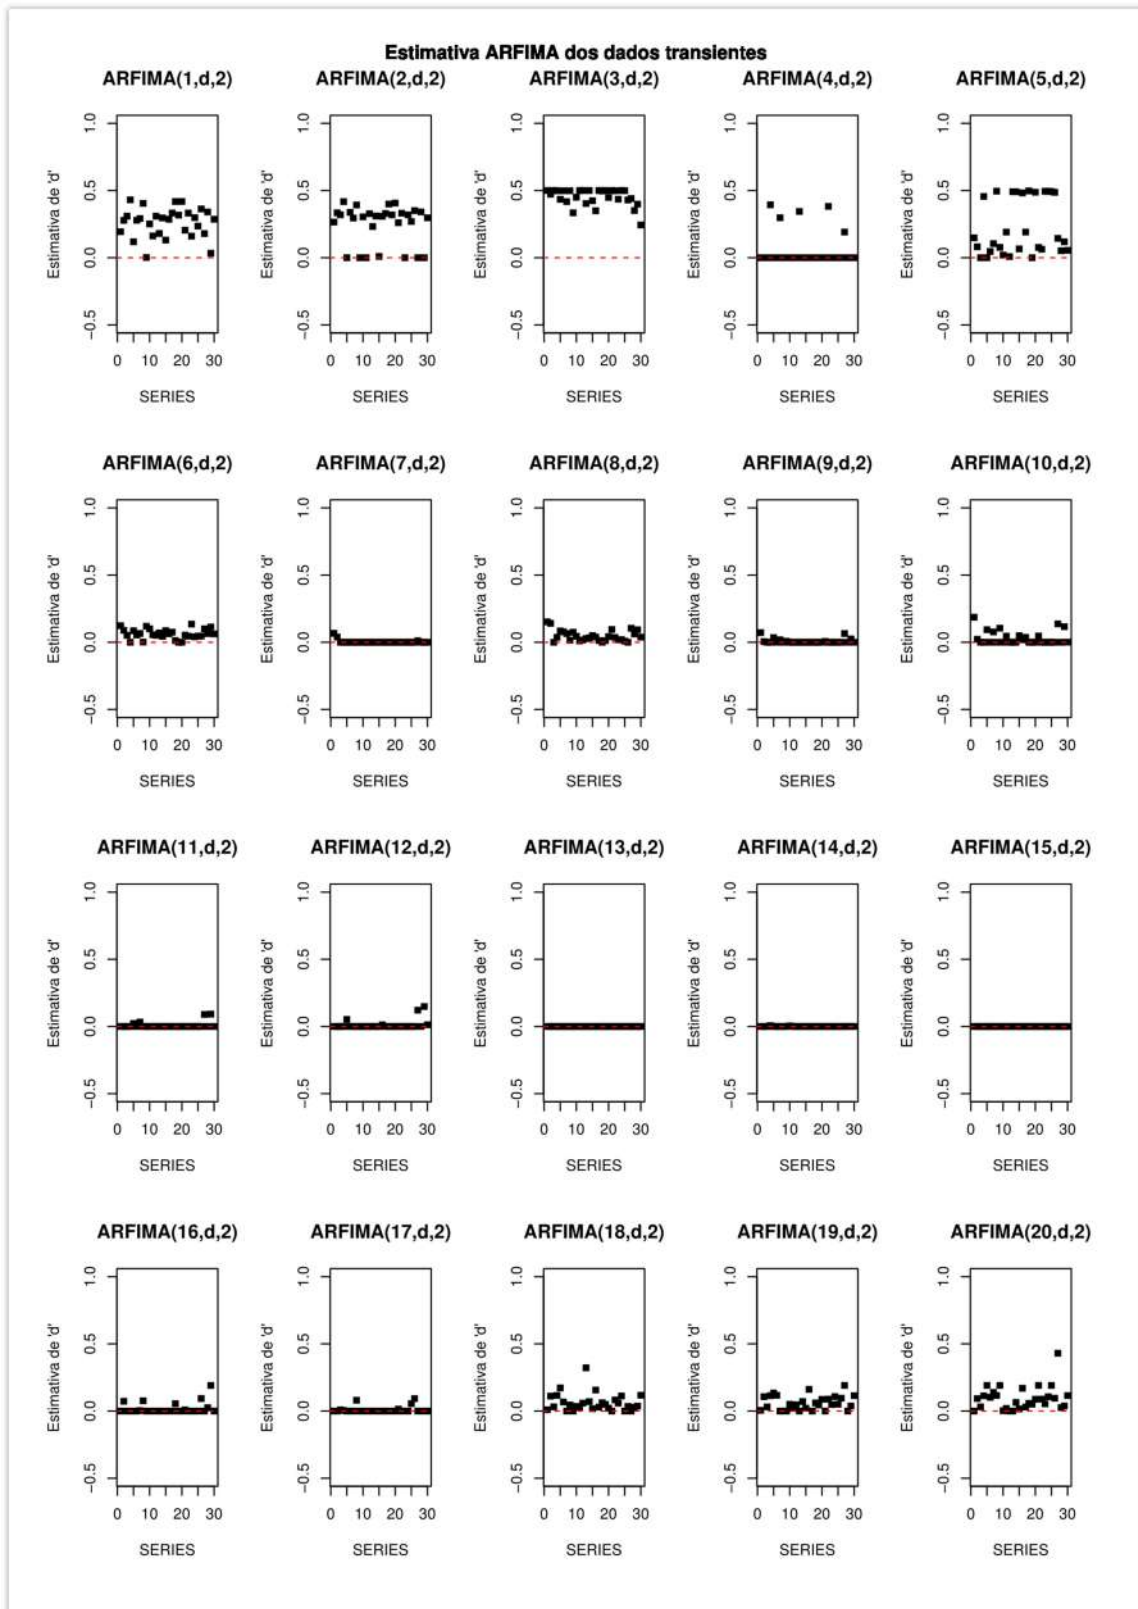


Figura 46: Modelos ARFIMA com q igual a dois para os dados transientes

Como os modelos iniciais não atenderam aos requisitos, o ciclo de identificação, estimativa e verificação continuou. Os modelos estimados com base no resultados

obtidos inicialmente foram o ARFIMA(10,0.05,9), (12,0.5,0), (15,0.09,15), (15,0.08,14), (15,0.07,13), (14,0.12,13), (14,0.1,14), (13,0.13,14), (13,0.12,13), (12,0.14,14), (12,0.06,13), (11,0.12,14), (11,0.06,13) e (12,0.06,13). Lembrando que este trabalho visa encontrar o modelo que possa ser aplicado em todas as séries analisadas. Por isso, algumas estimativas não foram consideradas adequadas.

Entre eles, o modelo ARFIMA(12,0.14,14) atende aos requisitos da etapa de verificação, não possuindo autocorrelação residual significativa e p-valores menores que 0,05 no teste de Ljung Box. Associado a isso, a adição de parâmetros extras não promove a redução considerável na variância residual, como exposto na Tabela 5.

Tabela 5: Modelos estimados e suas respectivas variâncias

ARFIMA			Variância residual
p	d	q	
16	0,10	15	33,74
15	0,09	15	33,74
15	0,08	14	33,74
14	0,1	14	33,75
13	0,13	14	33,78
12	0,13	15	33,77
12	0,14	14	33,78

Pela Figura 47, pode-se perceber que os resíduos parecem não aderir as séries estudadas. Por sua vez, a FAC e a FACP não apresentaram correlações significativas. O gráfico quantil-quantil apresenta assimetria a direita, similarmente aos resultados obtidos no ARMA.

Em suma, ambos processos realizados obtiveram resíduos semelhantes, com heterocedasticidade e levemente assimétricos a direita. Por sua vez, o processo ARFIMA apresentou menor quantidade de parâmetros, mas sua aplicação é mais complexa e necessita de maior recurso computacional. Diante disto, o modelo ARCH será aplicado nos resíduos provenientes do processo ARMA.

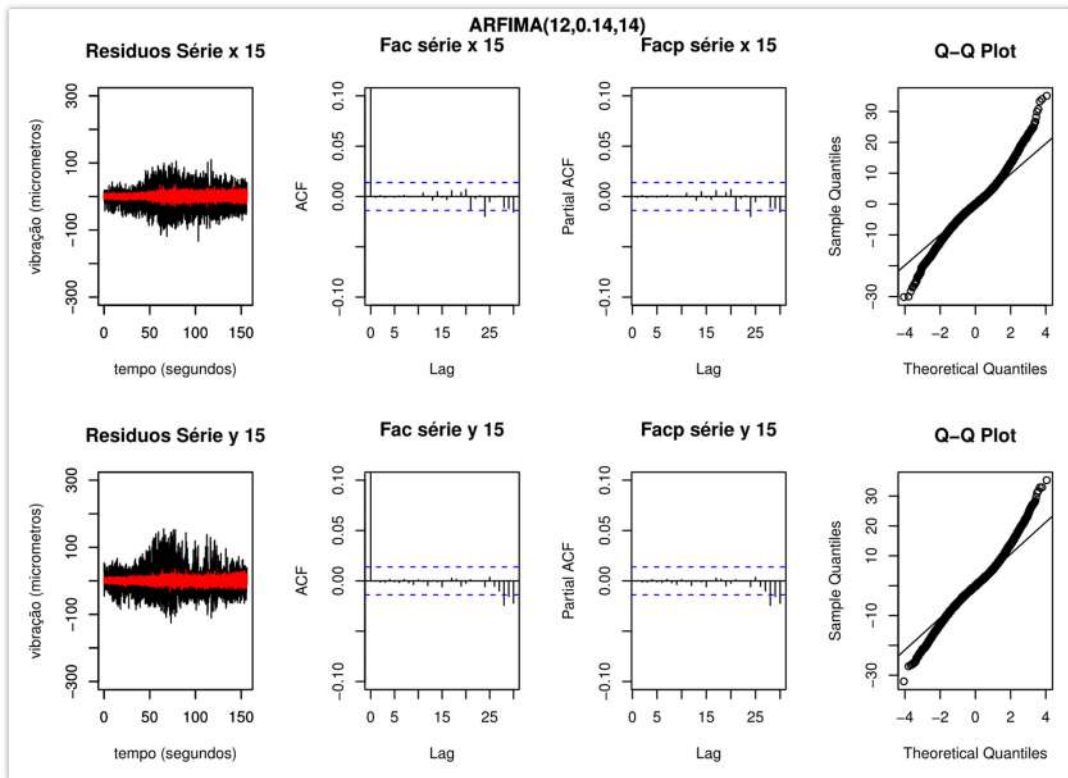


Figura 47: Verificação modelo ARFIMA(12,0,14,14) para as séries selecionadas²⁵

6.4.3 MODELOS NÃO-LINEARES

Antes da aplicação dos modelos não-lineares, a presença de heterocedasticidade deve ser verificada pelos gráficos dos resíduos quadráticos, pelas FAC e FACP quadráticas.

Pelo gráfico residual quadrático da Figura 48, pode-se perceber a presença da volatilidade nas séries analisadas, principalmente após os 50 segundos. Aliado a isso, a FAC e FACP possuem correlações expressivas mesmo em camadas mais altas.

Ainda de acordo com esses últimos gráficos, os modelos ARCH(1), (8), (10), (11), (15), (20), (21), (22), (23), (24), (25) e ARCH(30) foram estimados.

²⁵ Para o resultado completo, vide anexo VI.

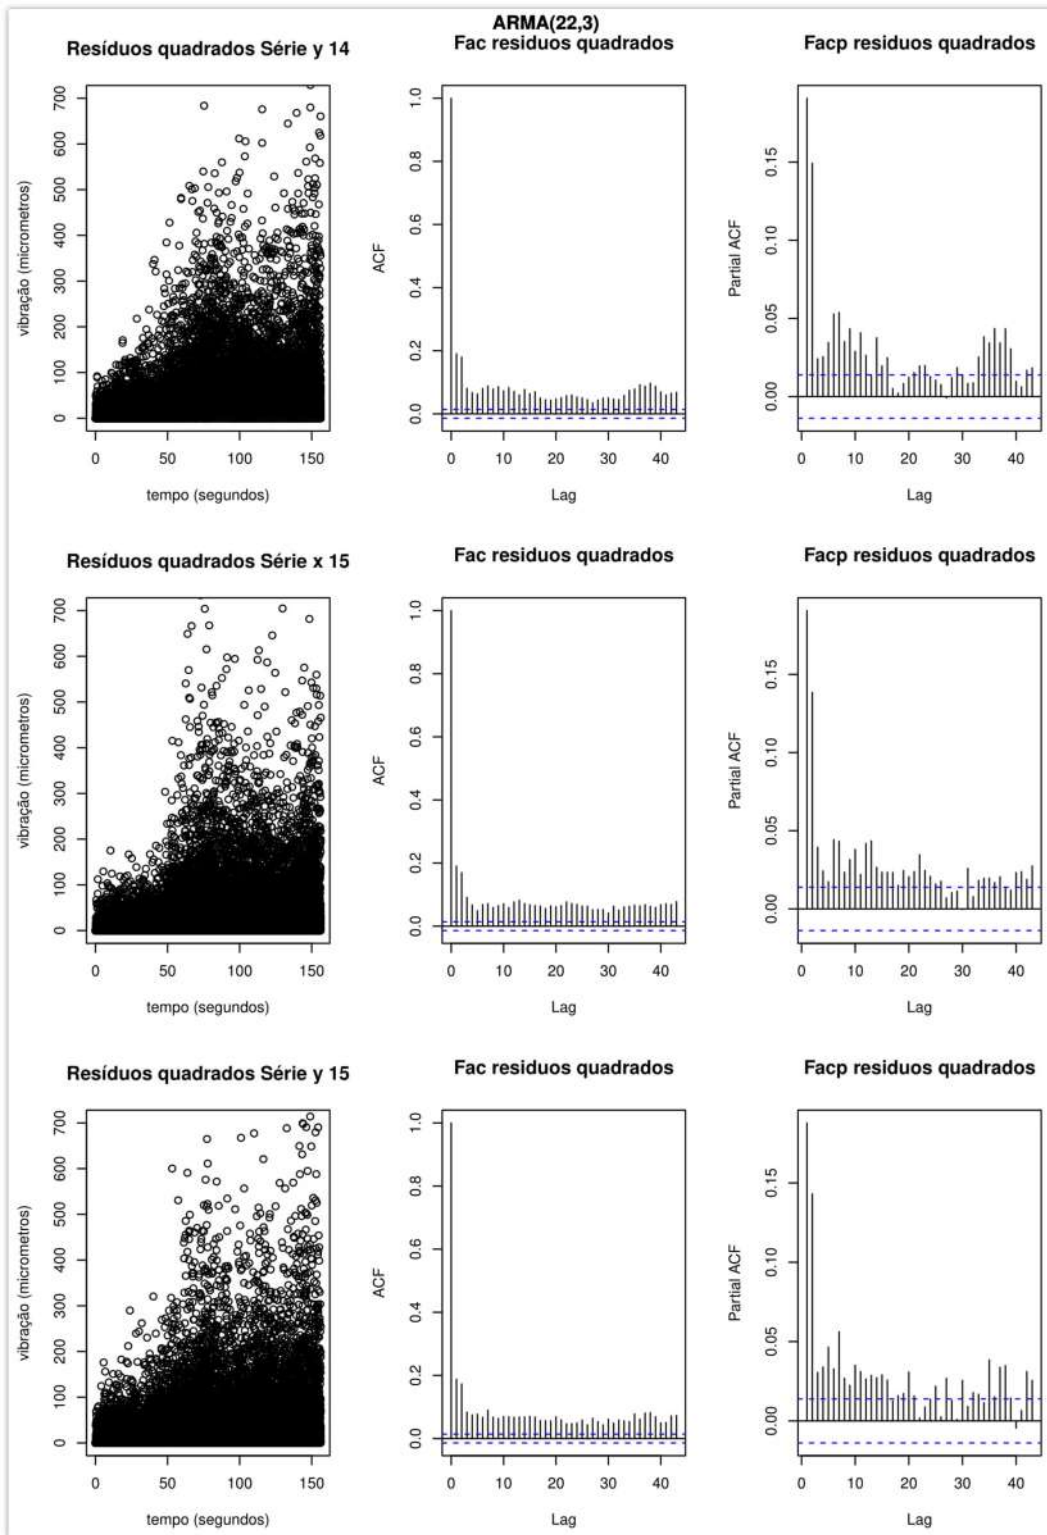


Figura 48: Resíduos quadrados, FAC e FACP residuais quadradas do ARMA(22,3) nas séries selecionadas²⁶.

²⁶ Para o resultado completo, vide anexo VI.

Entre os modelos estimados, o processo ARMA(22,3) ARCH(22) resultou no maior número de séries com p-valor acima do nível de significância de 5% no teste de multiplicador de Lagrange, ARCH-LM. A Figura 49 mostra o resultado do teste em uma série selecionada.

Segundo o resultado obtido na aplicação do teste de hipótese, o modelo se ajustou adequadamente em 26 das 30 séries analisadas.




Figura 49: Resultado do teste de LM- ARCH para os resíduos padronizados.

A partir disso, os gráficos das séries transientes versus os resíduos padronizados (em vermelho), a volatilidade residual (em azul), a FAC e a FACP dos resíduos padronizados, a FAC e a FACP do quadrado dos resíduos padronizados, os gráficos dos quantis e os histogramas foram gerados, como mostra Figura 50. Nota-se que os resíduos padronizados se encontram dispersos próximos a zero. Por sua vez, o gráfico dos quantis e histograma são aproximadamente simétricos, contudo reapareceram algumas correlações significativas na FAC e na FACP residuais padronizadas.

Existem algumas possíveis soluções para este problema. A primeira seria o aumento do número de parâmetros no processo ARMA. Esta alternativa foi testada e não promoveu redução nas correlações restantes em todas as séries. Uma nova possibilidade seria a aplicação de outros processos não-lineares como eGarch, gjrGarch e etc.

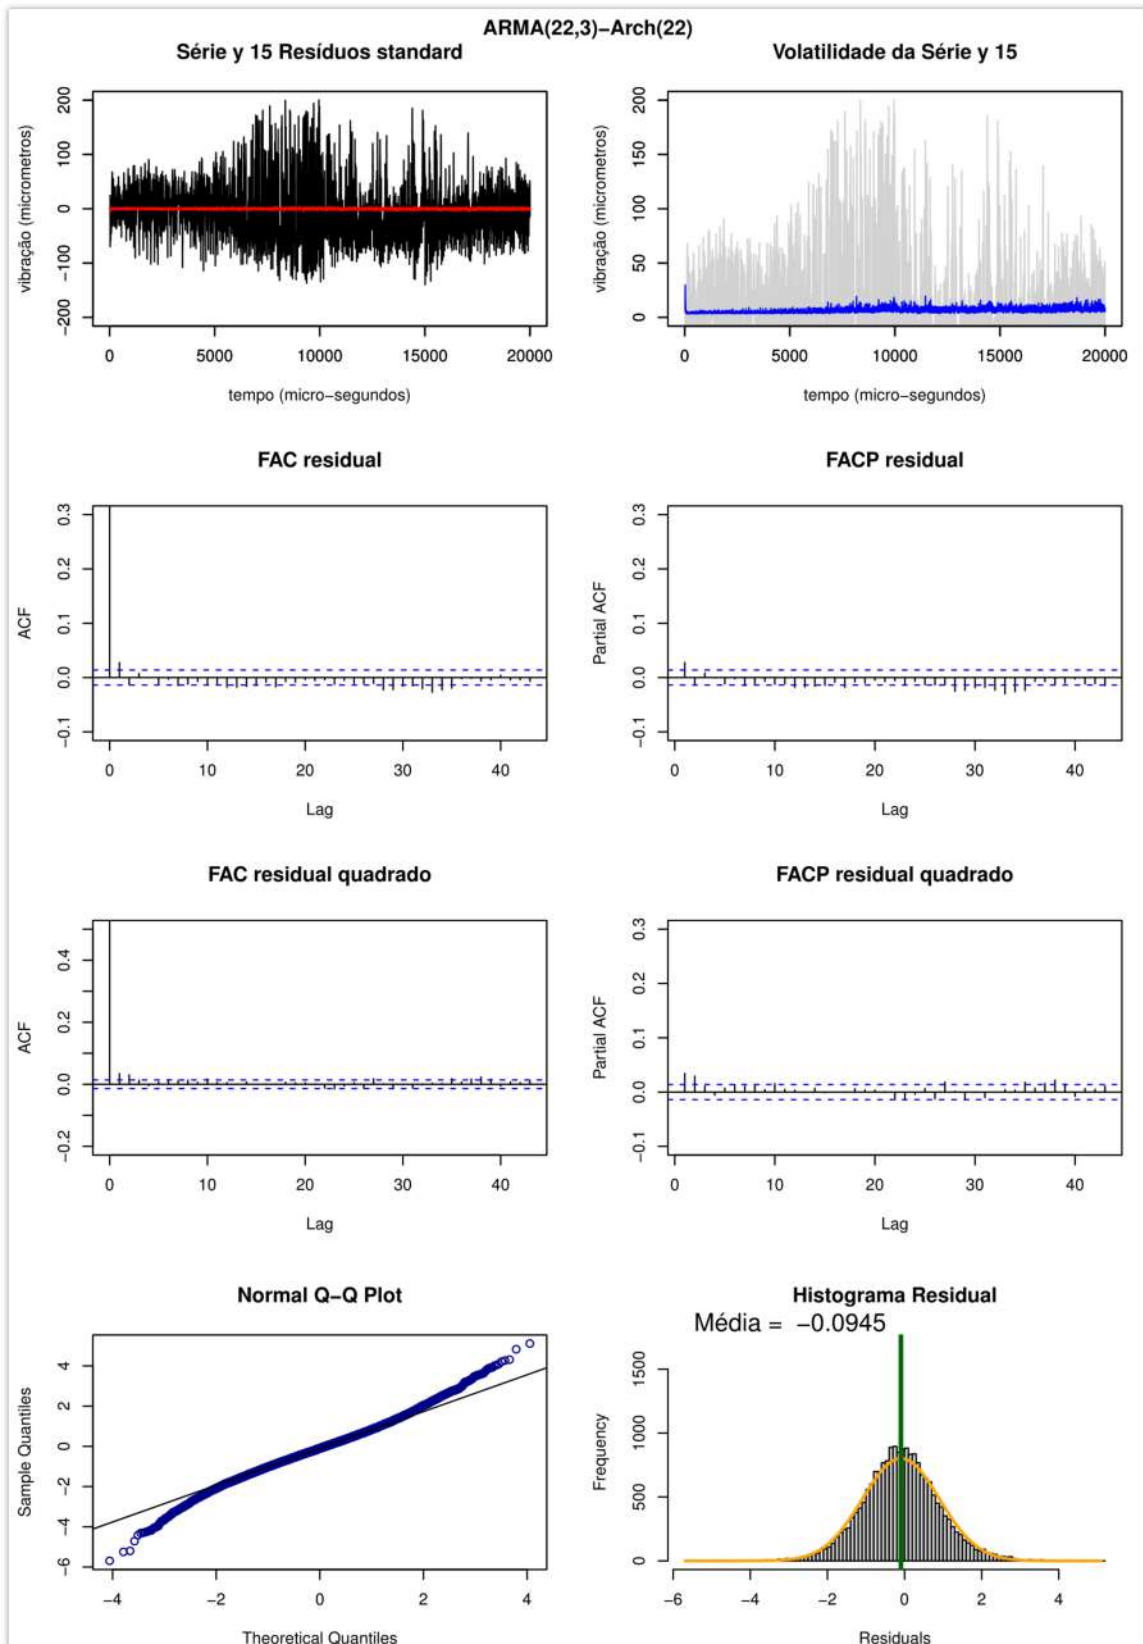


Figura 50: Resultado do ARMA(22,3) ARCH(22) para a série transiente selecionada²⁷

²⁷ Para o resultado completo, vide anexo VI.

6.5 CASO 3- ESTUDO DOS DADOS FILTRADOS

A filtragem da componente CA²⁸ pela Transformada de Wavelet promoveu a eliminação de alguns ruídos gerados durante o processo de captura dos dados.

Em conformidade com estudo realizado anteriormente, sabe-se que a modelagem das séries completas exigiu uma maior demanda computacional e não exibiu resultado satisfatório. Por isso, nas séries filtradas, somente os valores obtidos durante o período transiente serão analisados, o comportamento de algumas séries selecionadas estão exposto na Figura 51.

Inicialmente esta seção apresenta uma análise descritiva das séries temporais, verificando histogramas, gráficos dos quantis e curvas FAC e FACP. Em seguida, exhibe os resultados da aplicação da abordagem de Box & Jenkins nos dados filtrados.

²⁸ Para mais informações, vide Capítulo 5, filtragem de dados.

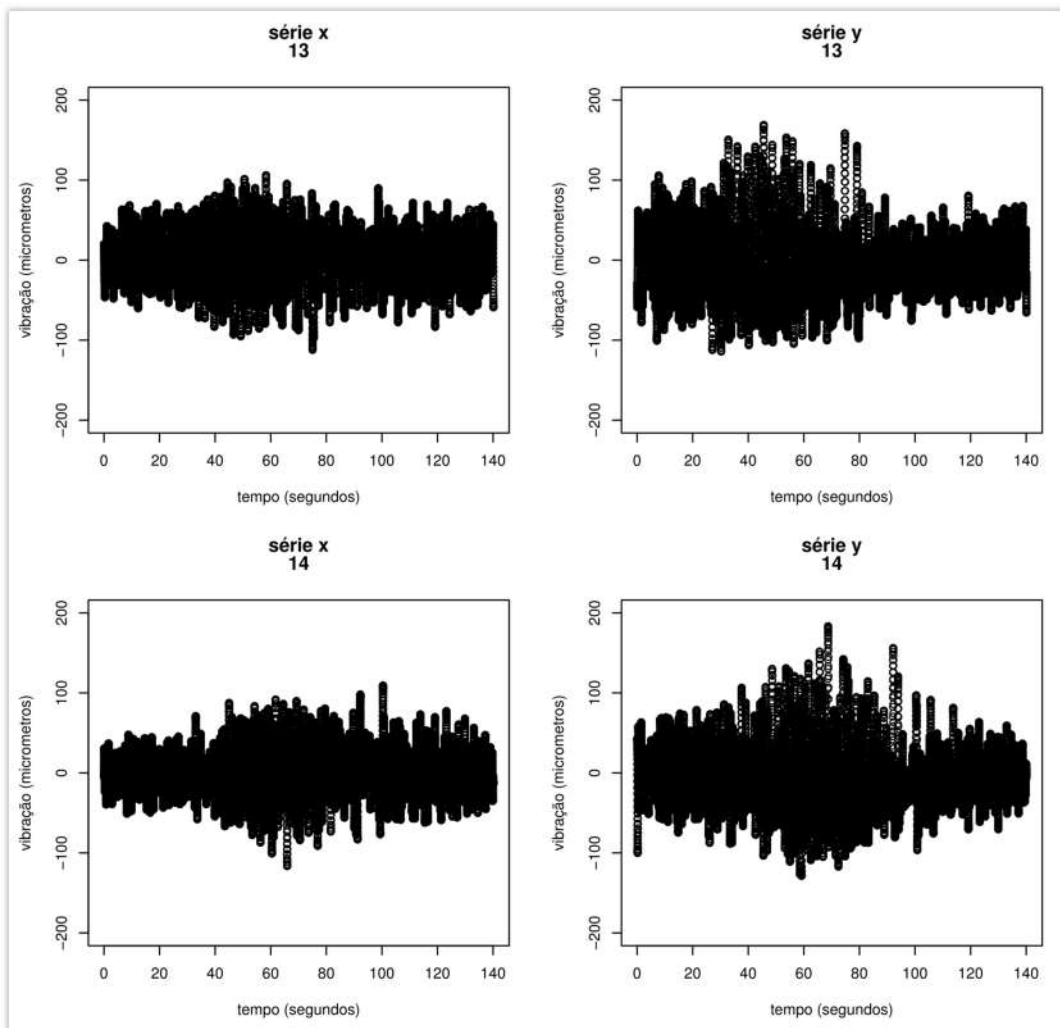


Figura 51: Séries filtradas selecionadas ²⁹ no transiente

Os dados filtrados apresentam comportamento parecido com as séries originais. A título de exemplo, o histograma, Figura 52, e o gráfico dos quantis, Figura 53, mostram que as séries na direção y parecem ser assimétricas a direita de maneira semelhante aos dados originais.

²⁹ Para o resultado completo, vide anexo VII.

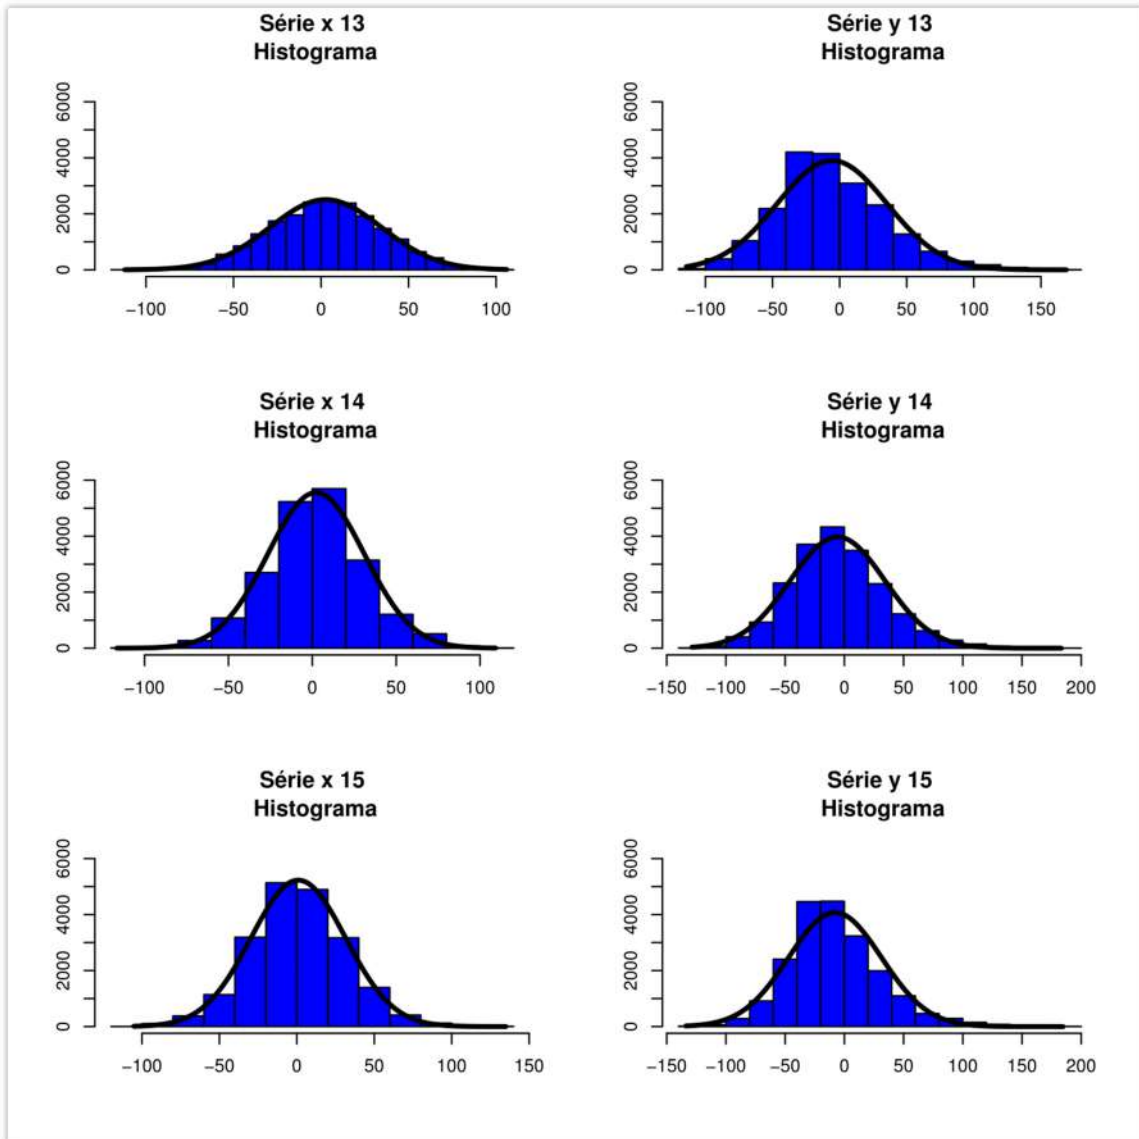


Figura 52: Histograma das séries filtradas selecionadas³⁰ no transiente

³⁰ Para o resultado completo, vide anexo VII.

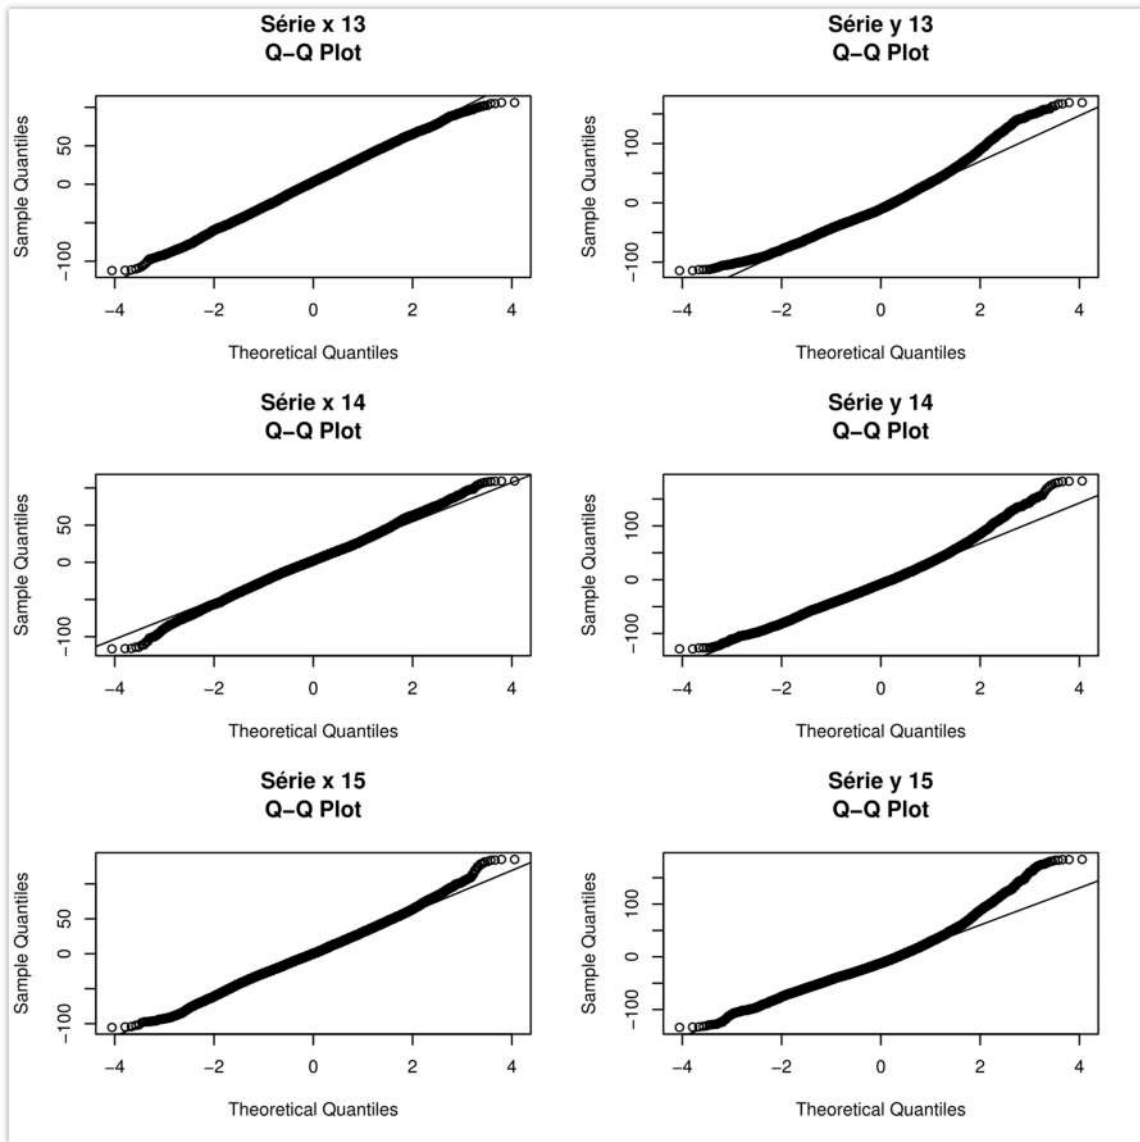


Figura 53: Gráfico quantil-quantil das séries filtradas selecionadas³¹ no transiente

Entretanto, pelo teste de normalidade de Anderson-Darling, não foi possível aceitar a hipótese nula de normalidade, uma vez que os p-valores foram menores que 0,05, conforme pode ser visto no Quadro 3.

³¹ Para o resultado completo, vide anexo VII.

[1] "Série x 13"		[1] "Série y 13"	
Anderson-Darling normality test			
data: dados.fil.tran[, i]		data: dados.fil.tran[, i]	
A =	1.573	A =	85.849
p-value =	0.0004795	p-value	< 2.2e-16
[1] "Série x 14"		[1] "Série y 14"	
Anderson-Darling normality test			
data: dados.fil.tran[, i]		data: dados.fil.tran[, i]	
A =	14.699	A =	44.811
p-value	< 2.2e-16	p-value	< 2.2e-16
[1] "Série x 15"		[1] "Série y 15"	
Anderson-Darling normality test			
data: dados.fil.tran[, i]		data: dados.fil.tran[, i]	
A =	8.189	A =	120.37,
p-value	< 2.2e-16	p-value	< 2.2e-16

Quadro 3: Teste de normalidade de Anderson-Darling nas séries filtradas selecionadas

A Figura 54 mostra que as FACs das séries analisadas decaem lentamente, porém não se anulam. Analisando as FACPs das séries, pode ser mais apropriado a adoção de um modelo AR puro ou ARMA, uma vez que estas apresentam decaimento senoidal com valores nulos a partir da camada 60, aproximadamente (Figura 55).

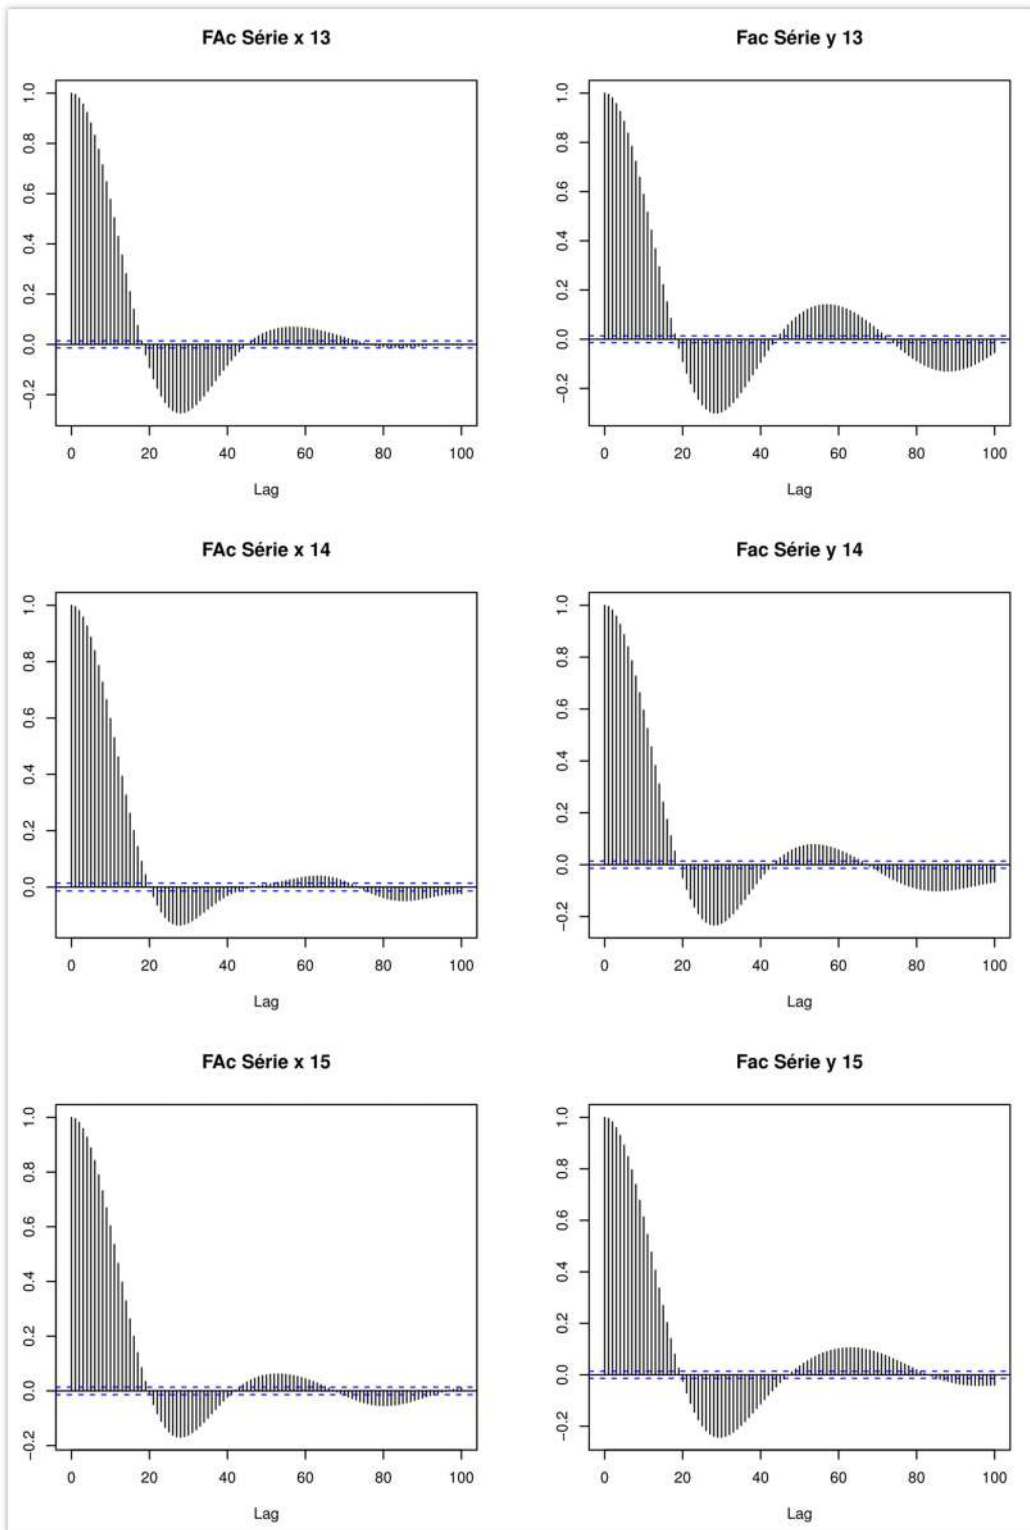


Figura 54: FAC das séries filtradas selecionadas³² no transiente

³² Para o resultado completo, vide anexo VII.

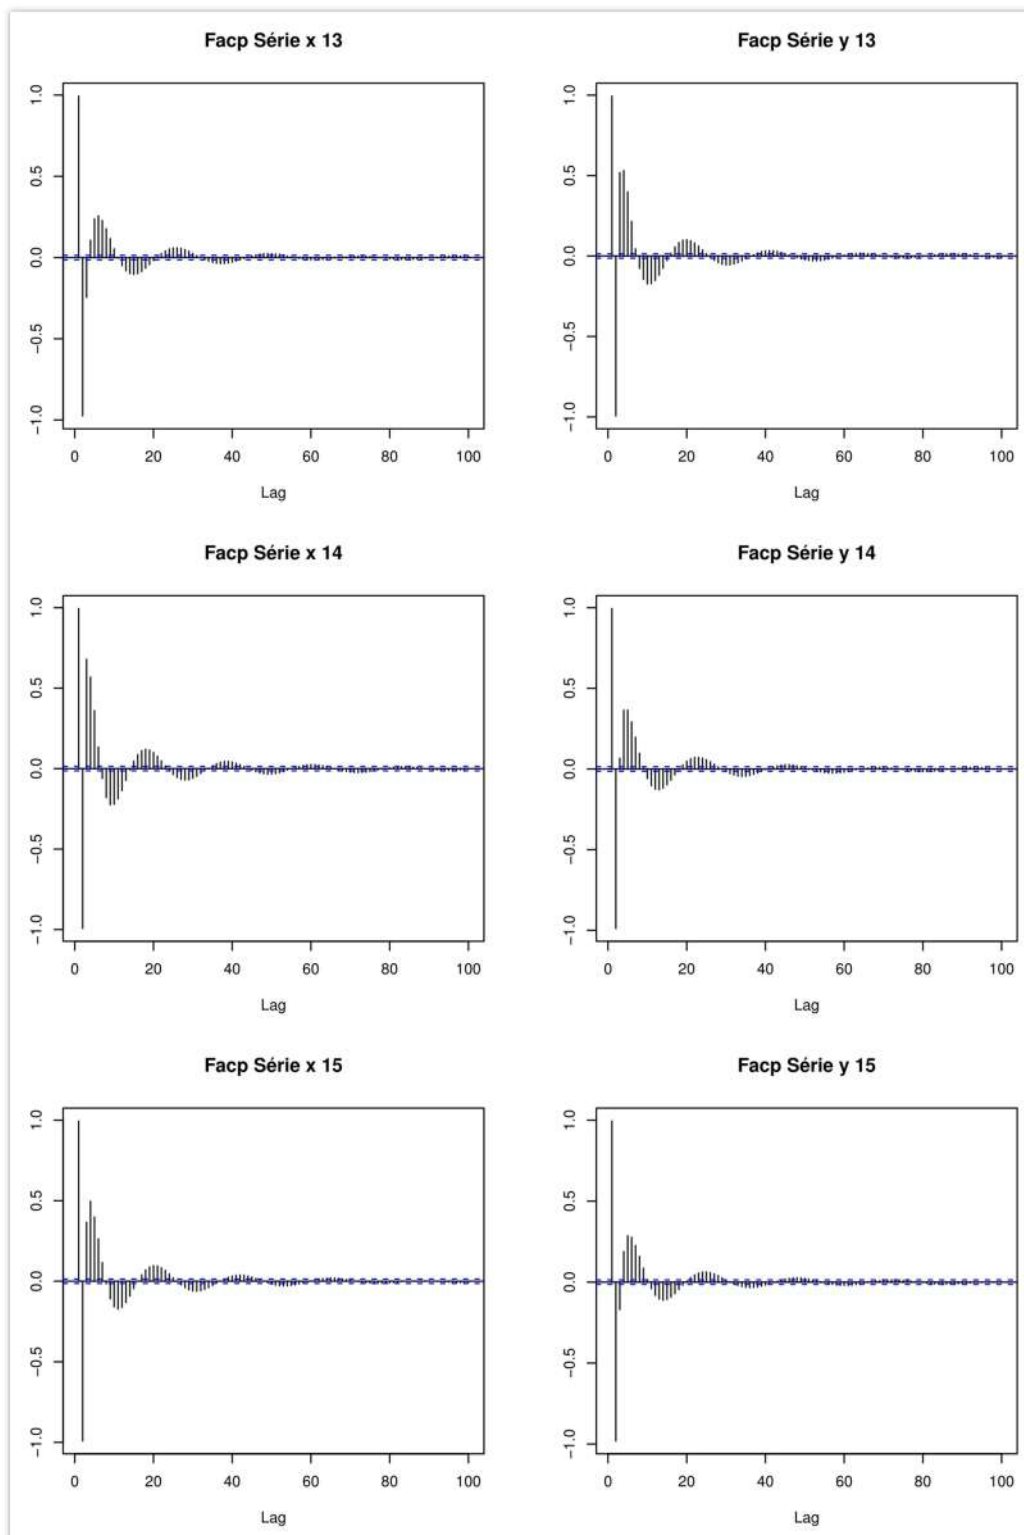


Figura 55: FACP das séries filtradas selecionadas³³ no transiente

³³ Para o resultado completo, vide anexo VII.

6.5.1 PROCESSOS LINEARES

O modelo inicialmente estimado foi escolhido considerando a maior defasagem na qual a FACP é significativa. Pelo resultado da seção anterior, o valor de p foi igual a 60.

Por sua vez, o resultado obtido na aplicação do modelo AR(60) não foi satisfatório, uma vez que algumas séries residuais continuaram apresentando correlações significativas na FAC e FACP, além de não serem normalmente distribuídos, conforme mostrado na Figura 56. Duas possibilidades serão testadas. Na primeira, as séries serão diferenciadas e os modelos lineares serão novamente identificados por meio das curvas FAC e FACP residuais. A segunda alternativa será a aplicação do modelo de memória longa, ARFIMA.

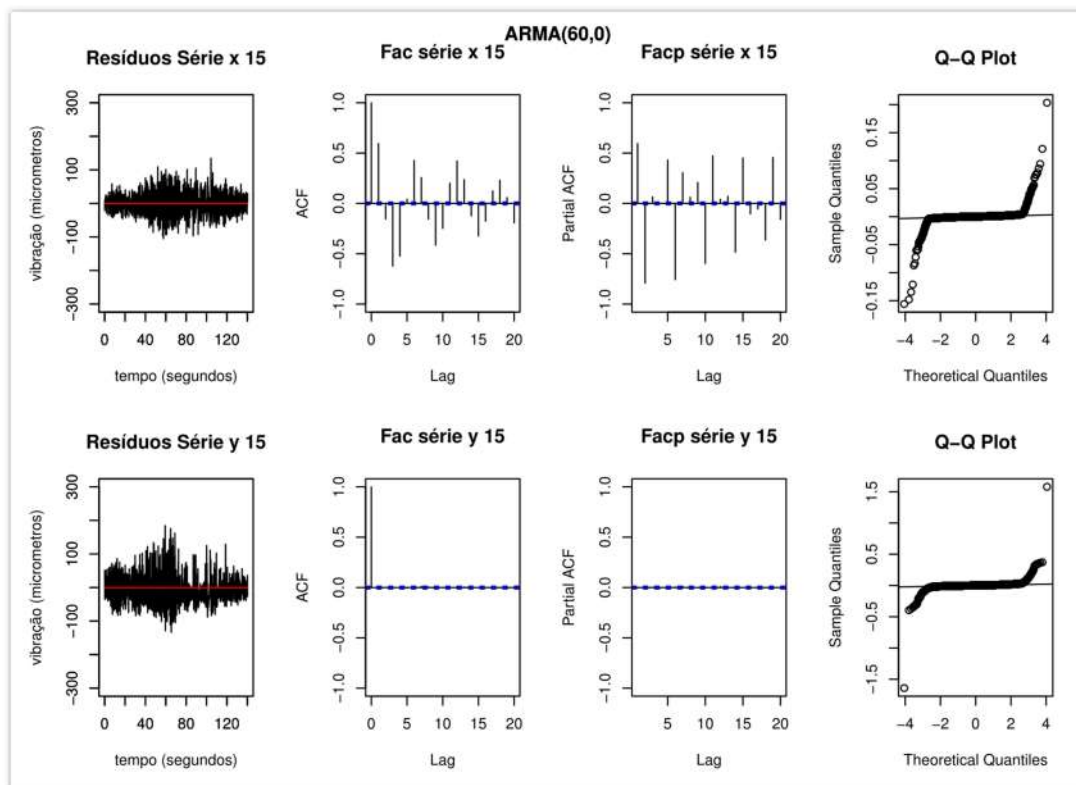


Figura 56: AR(60) para séries filtradas selecionadas³⁴ no transiente

Em relação à diferenciação (Figura 57), pode-se perceber que a FAC continua não apresentando valores nulos mesmo em camadas altas, ou seja, a diferenciação não promoveu a redução da dependência.

³⁴ Para o resultado completo, vide anexo VIII.

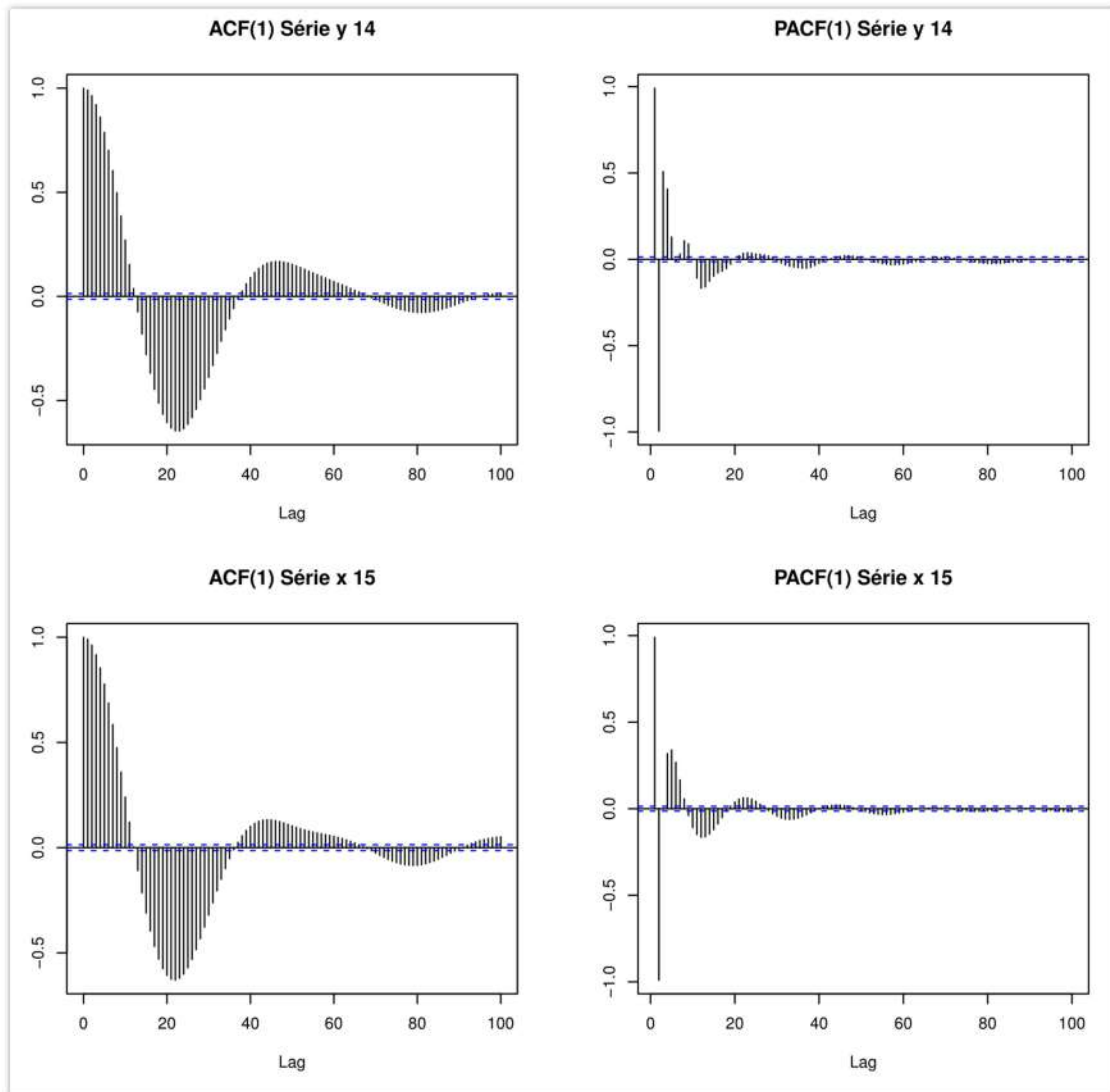


Figura 57: FAC e FACP diferenciadas nos dados filtrados

A partir disso, pode-se dizer que o processo auto-regressivo não deve ser o mais indicado para modelar as séries filtradas, uma vez que a FAC e a FACP residual apresentaram persistência na atenuação mesmo com alto número de parâmetros e após a diferenciação. O próximo passo é a aplicação do modelo ARFIMA.

6.5.2 PROCESSO COM MEMÓRIA LONGA

Seguindo os passos realizados nas seções anteriores, a identificação inicial do modelo ARFIMA teve como base a Figura 58, a Figura 59 e a Figura 60. Elas mostram o valor do parâmetro d com a variação do p dado um q fixo.

De maneira idêntica as séries originais, o valor de d tendeu a zero com o aumento do p , exceto em duas séries analisadas. Nelas o valor de d ficou em torno de

0,5 independente de p e q . Este comportamento pode ser visto mesmo com aumento do valor de p , como mostra a Figura 61. Neste caso, o valor de p foi testado até 40.

Ainda de acordo com as figuras apresentadas, alguns modelos ARFIMA foram testados tais como ARFIMA(1,0.5,0), (1,0.5,1), (20,0.1,0) e entre outros.

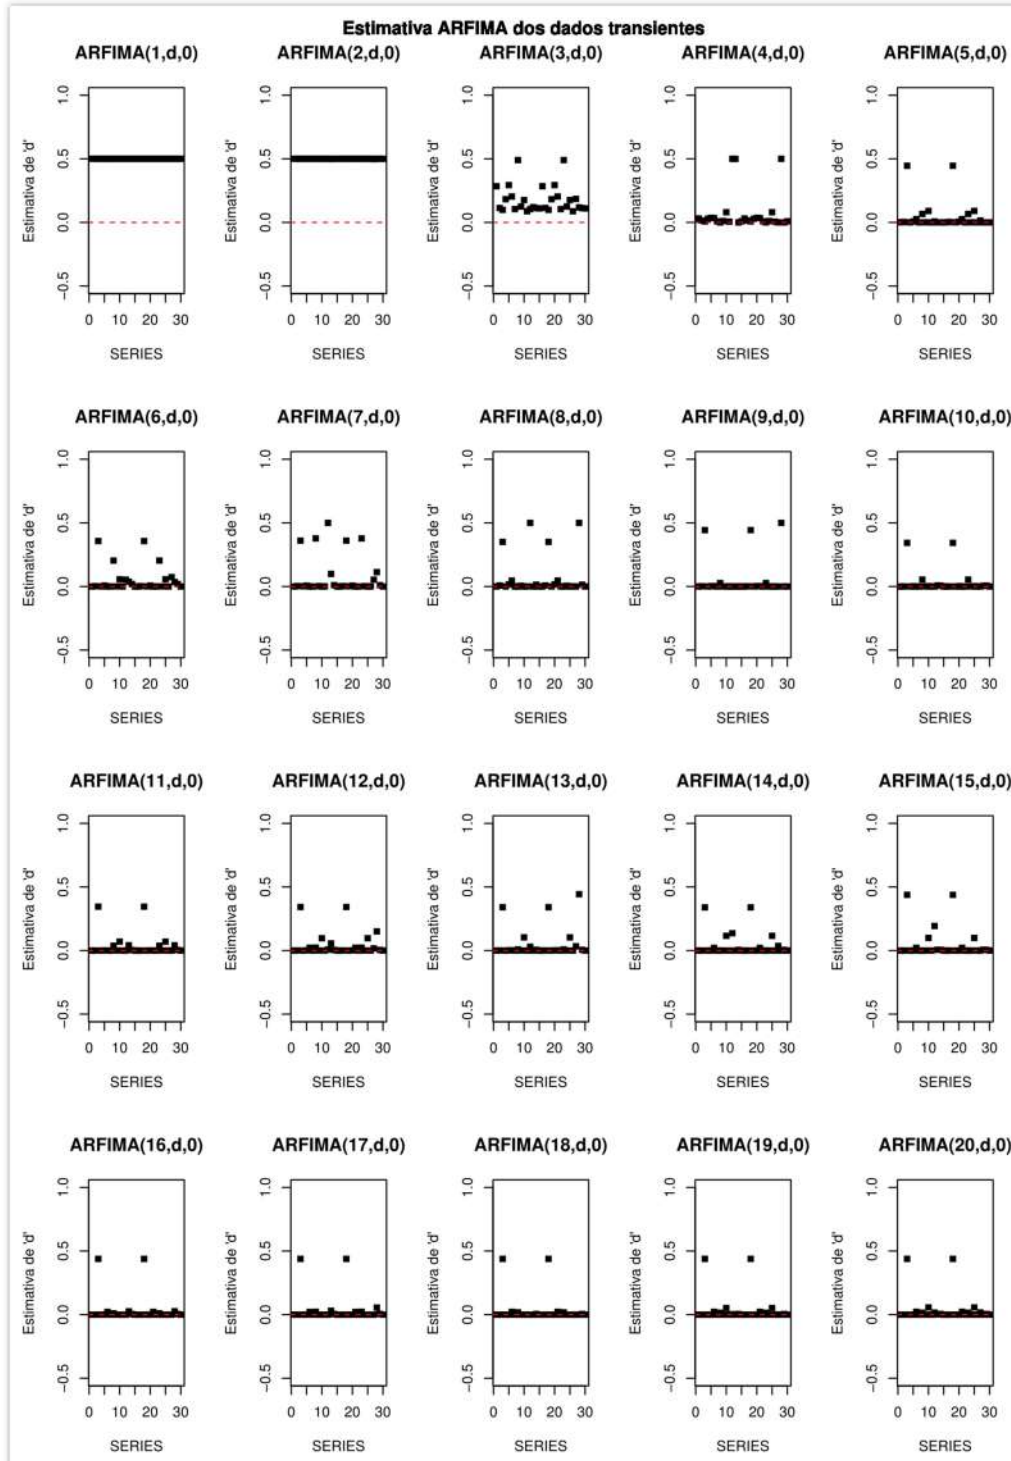


Figura 58: Estimativa d com $q=0$ para os dados filtrados

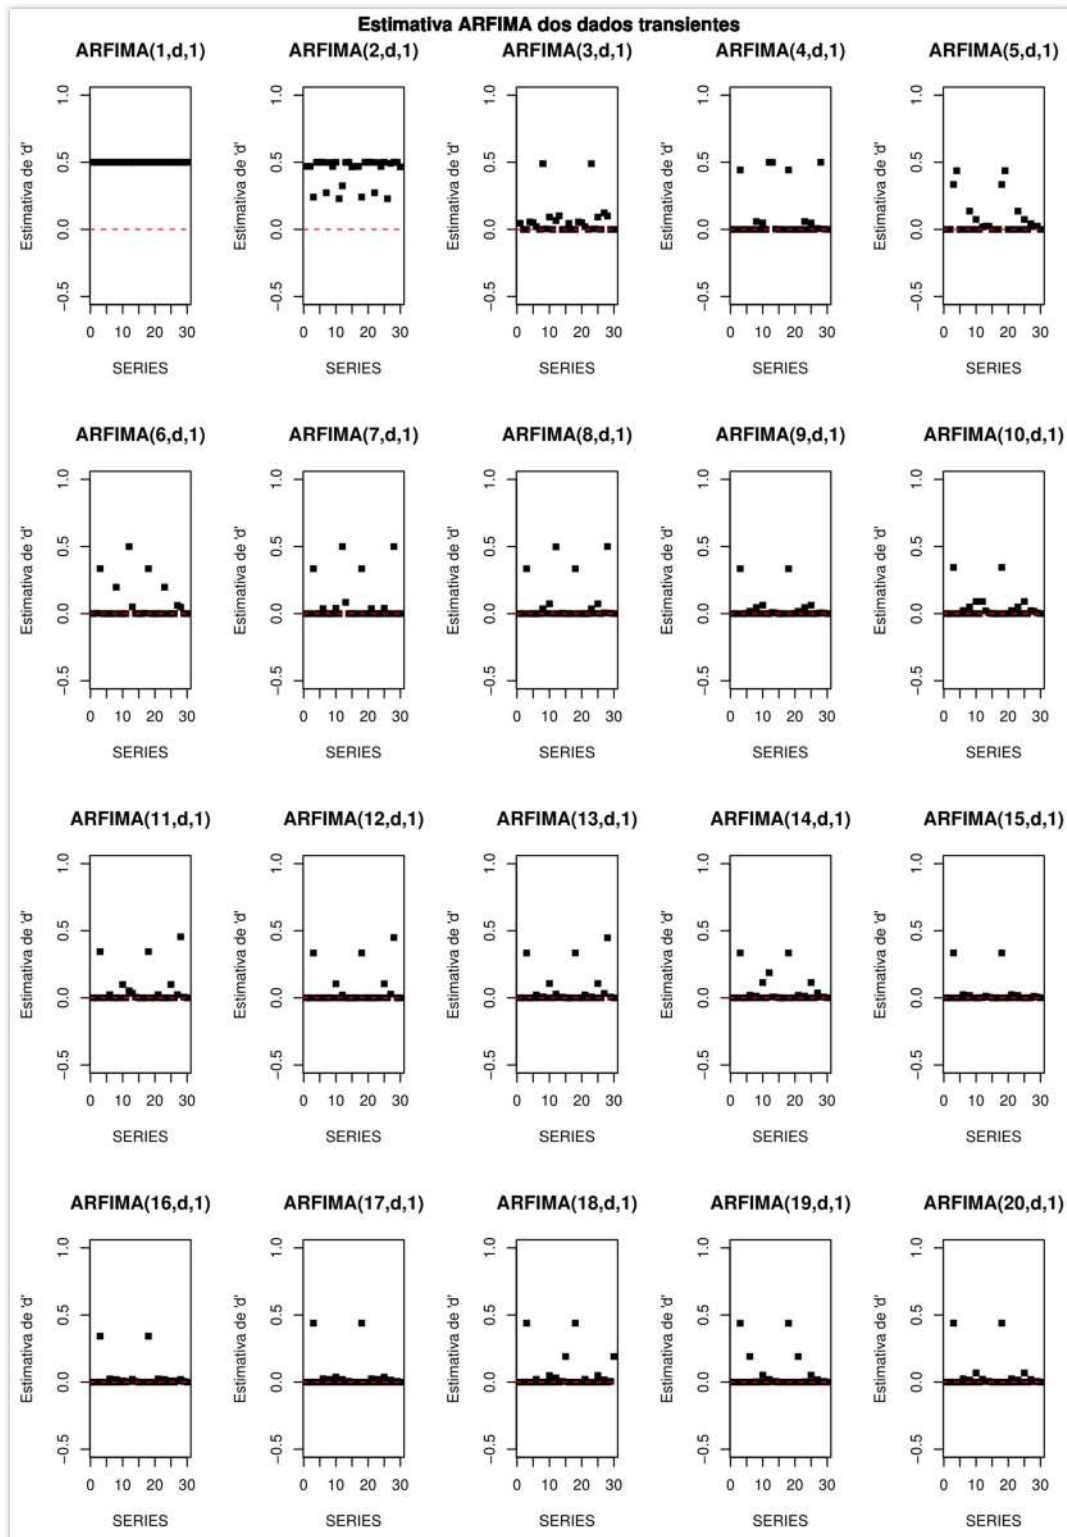


Figura 59: Estimativa d para $q=1$ nos dados filtrados

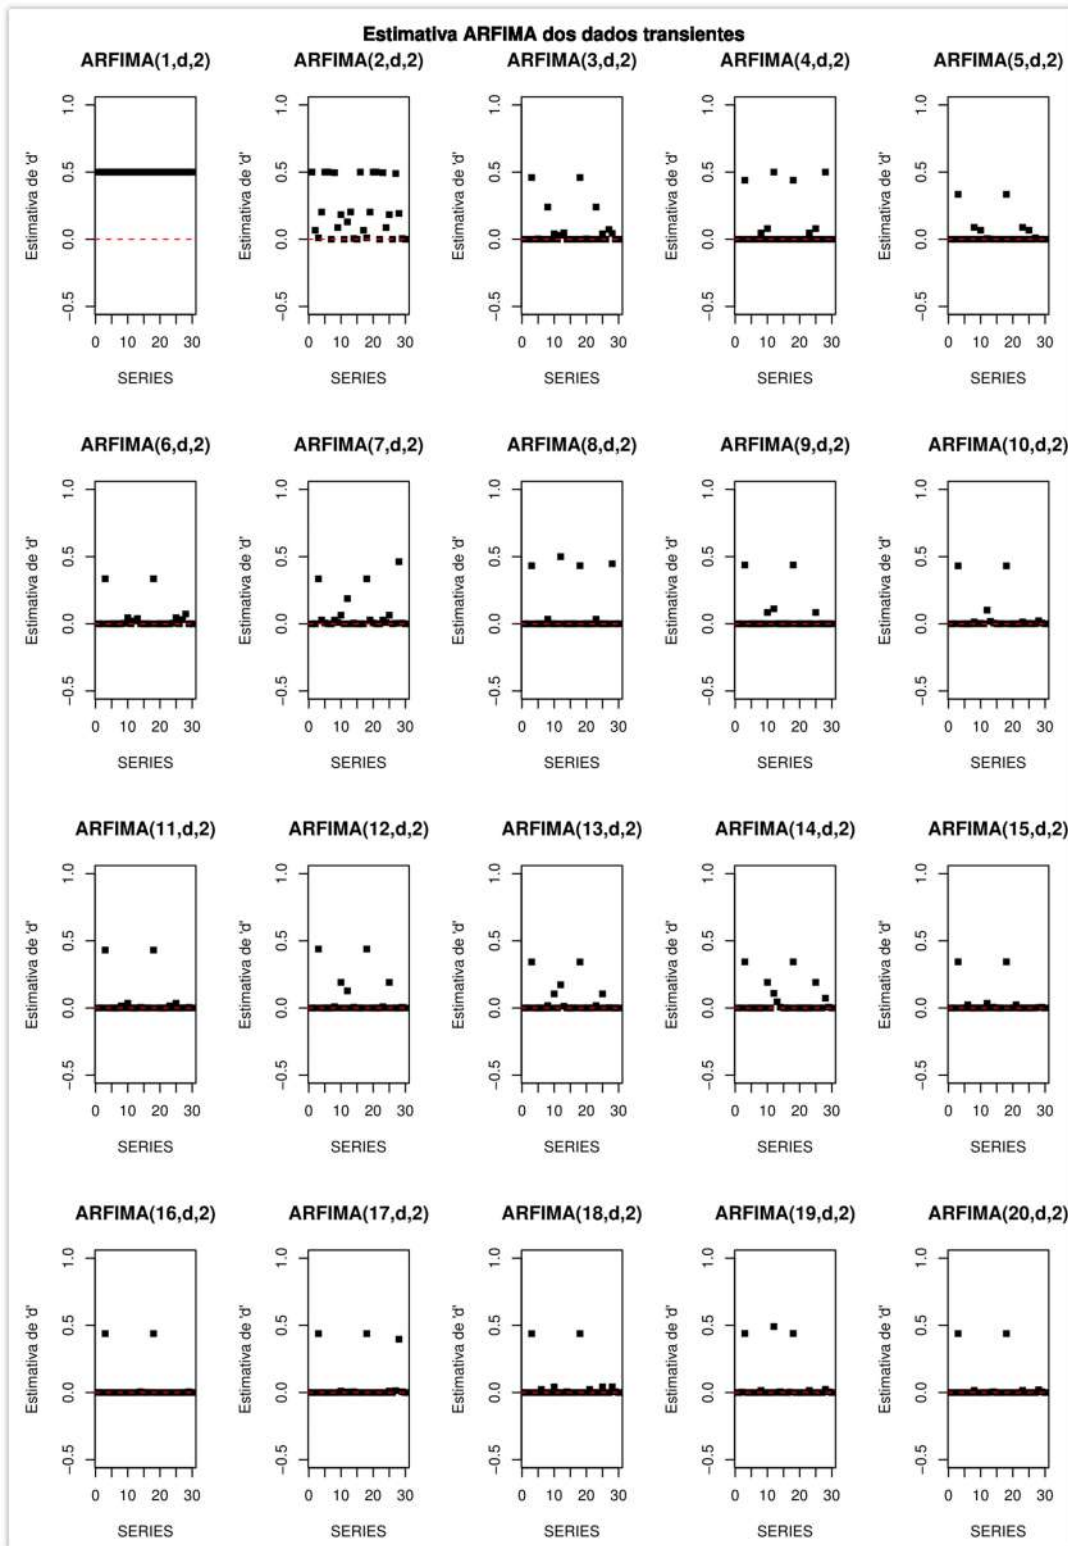


Figura 60: Estimativa d para $q=2$ nos dados filtrados

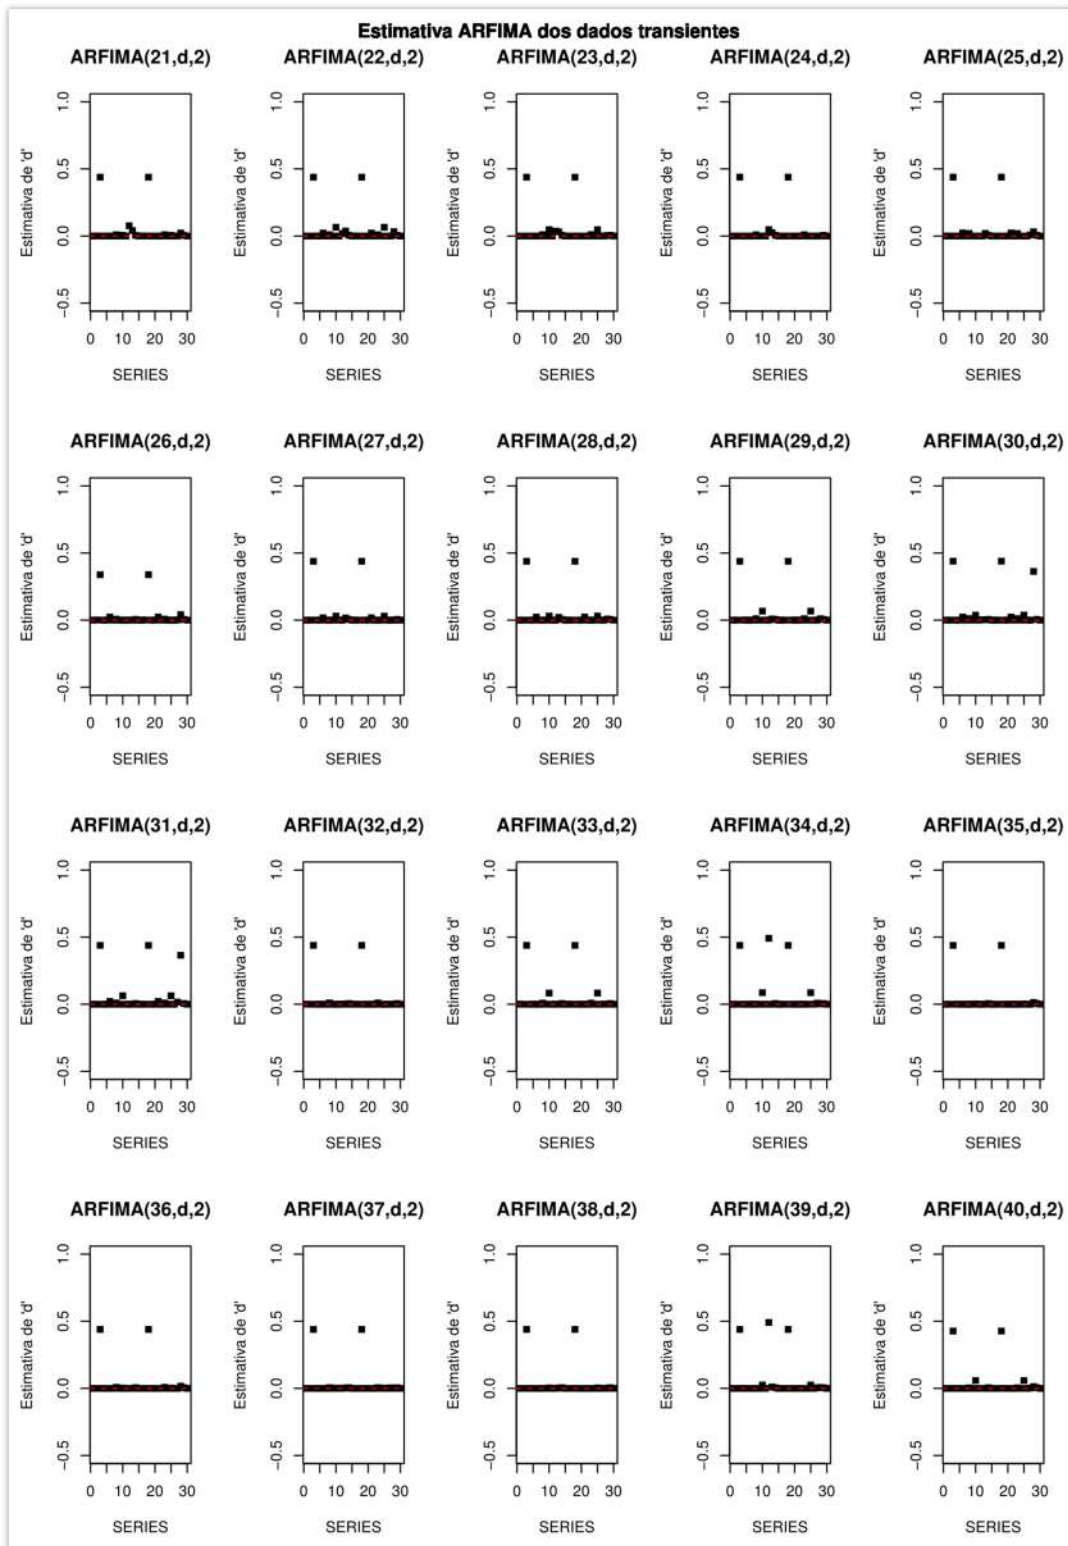


Figura 61: Estimativa d para $q=2$ nos dados filtrados para p entre 20 e 40.

Os resíduos dos modelos testados apresentaram correlações significativas. A partir disso, novos modelos com valores de p e q mais altos foram gradualmente estimados, tais ARFIMA(5,0.4873,10), (10,0.032,20), (20,0.043,10), (20,0.076,16), (20,0.06,17), (30,0.1,10), (30,0.15,30) e entre outros.

Mesmo assim, os resíduos continuaram apresentando forte dependência, como mostra a Figura 62. Nota-se que os resíduos do modelo (em vermelho) aparentam ter média e variância constante, mas não são normalmente distribuídos, como era esperado.

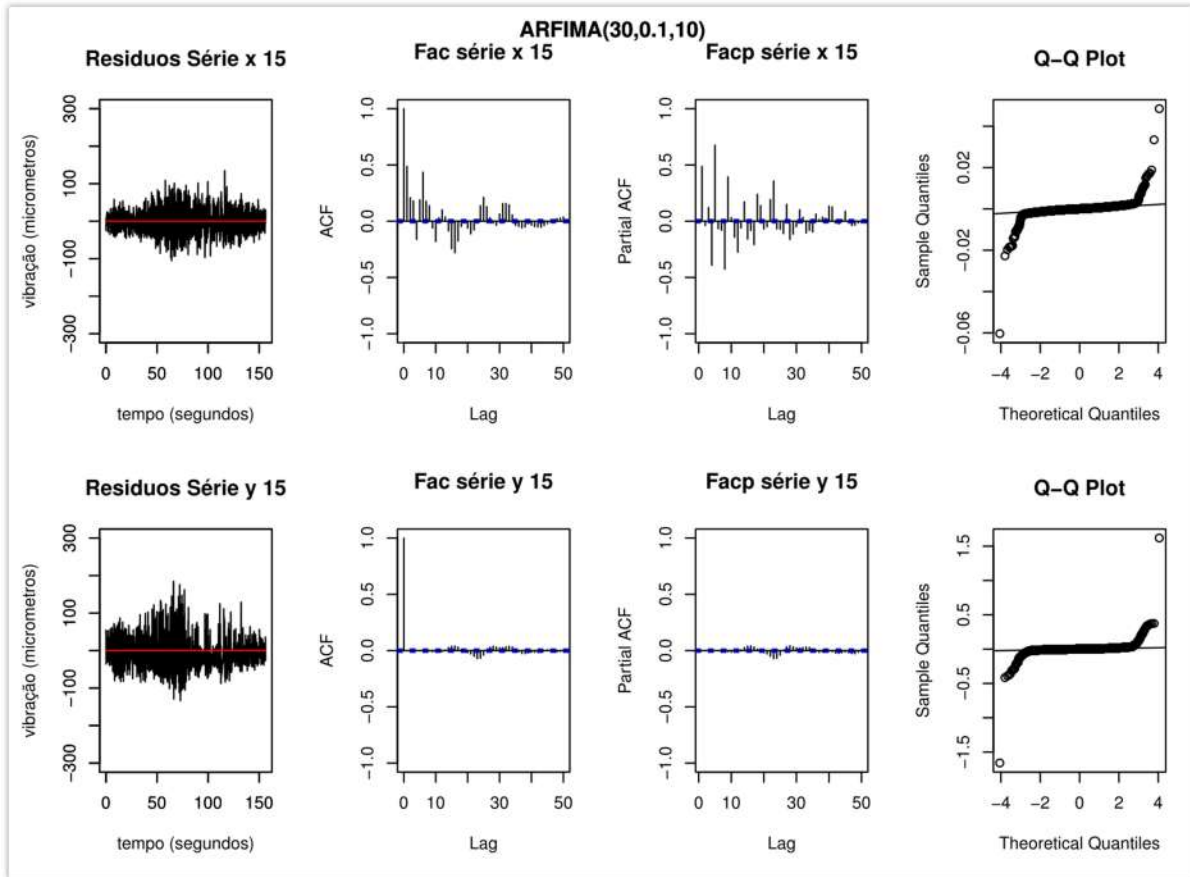


Figura 62: Modelo ARFIMA(30,0.1,10) das séries filtradas selecionadas³⁵ no transiente

Salienta-se que o aumento do número de parâmetros demandou alto esforço computacional, o que inviabilizou algumas aplicações do modelo ARFIMA.

Com base nos resultados obtidos, pode-se dizer que o modelo se ajustou bem aos dados, uma vez que o gráfico residual apresenta comportamento constante. Porém, não houve redução da dependência residual na maioria das séries analisadas.

Associado a isso, a adição de novos parâmetros demandou alto esforço computacional, o que dificultou a modelagem dessas séries vibracionais.

³⁵ Para o resultado completo, vide anexo VIII.

6.6 DISCUSSÃO

Neste capítulo foram abordadas as aplicações das séries temporais na modelagem dos dados vibracionais provenientes de partidas sequenciais de uma UHE, visando ajustar um modelo de série temporal nos dados analisados. Isso foi feito com o intuito de analisar o efeito do número de partidas na degradação do mancal guia em turbinas Francis.

Conforme visto, a modelagem dos dados originais completos não se mostrou efetiva, uma vez que o modelo não se ajustou adequadamente às séries analisadas e apresentou heterocedasticidade residual. Aliado a isso, a grande quantidade de dados analisados, aproximadamente 42.000, gerou alta demanda computacional.

Por sua vez, a análise dos dados provenientes do período transiente permitiu o ajuste de uma série temporal ARMA(22,3). Porém, o modelo apresentou heterocedasticidade residual, que foi ajustada pelo processo ARCH(22) em 26 das 30 séries analisadas. Para um modelo mais satisfatório, indica-se a utilização de outros métodos GARCH, uma vez que o incremento de parâmetros tanto do ARMA quanto do ARCH não melhoraram o ajuste das séries.

Salienta-se ainda que a aplicação do modelo de memória longa nos dados transientes não apresentou resultados que justificassem o uso de um modelo mais complexo e com maior demanda computacional.

Por fim, o ajuste de séries temporais após a filtragem *Wavelet* também não produziu resultados satisfatórios. As séries continuaram apresentando longa dependência mesmo após o ajuste do modelo ARFIMA. Esse resultado mostrou que a filtragem utilizada pode não ter sido a mais adequada, assim, indica-se o uso de outros filtros como, por exemplo, a decomposição *Single Spectrum Analysis (SSA)*.

7 CONCLUSÃO

Com o aumento da demanda de energia elétrica e a penetração das eólicas, as hidrelétricas são mais requisitas a atuar no pico da carga, o que provoca o aumento da quantidade de ciclos de partidas e paradas na máquina. Durante a partida, o equipamento está mais susceptível a *stress* assimétricos e a degradação, reduzindo o seu tempo de vida útil.

Como consequência, as técnicas de manutenções e os cronogramas tradicionais não são recomendados considerando as novas condições operacionais. Assim, as usinas hidrelétricas estão investindo em manutenções baseadas na condição, que buscam evitar inspeções desnecessárias ao recomendar reparos de acordo com as informações coletadas nos equipamentos.

Diante disso, esta dissertação buscou o ajuste de uma curva característica nos dados vibracionais gerados durante as partidas de hidrelétricas, com o propósito de analisar o efeito do número de partidas na degradação do mancal guia de uma turbina Francis. Para tal, os processos de séries temporais: ARMA, ARFIMA e ARCH foram utilizados na modelagem das séries captadas.

A aplicação dos modelos nos três estudos de casos apresentados não obteve resultado satisfatório. Isso pode ter sido causado por diversos fatores, entre eles, a coleta de dados, o tempo de análise do problema, o procedimento utilizado e entre outros.

Como diferentes abordagens de séries temporais univariadas foram realizadas sem êxito, é possível que um modelo que considere outras variáveis explicativas possa apresentar resultados mais robustos. Por exemplo, sabe-se que as partidas foram realizadas em diferentes períodos do ano, assim, o nível de água nos reservatórios também variou, o que pode ter influenciado na vibração da máquina. Além disso, o problema pode ter acontecido durante a coleta de dados, já que pode haver erros associados aos equipamentos responsáveis pelo monitoramento de sinais.

Outro fator importante é o tempo de análise do problema. O aumento do número de partidas influencia na degradação do equipamento. Entretanto a degradação causada por uma única partida pode não ser facilmente percebida no curto prazo. Assim, indica-se o uso de um número maior de partidas de uma mesma hidrelétrica.

Salienta-se ainda que, neste trabalho, os modelos não apresentaram resultados satisfatórios nos dados coletados em uma única UHE contida no SIN, o que não significa que eles não devem ser utilizados em dados provenientes de outras unidades.

Desta forma, recomenda-se a aplicação dos modelos utilizados em dados provenientes de diferentes UHES.

Além disso, outros modelos não-convencionais tais como Single Spectrum Analysis (SSA), podem ser utilizados tanto na modelagem quanto na filtragem dos dados vibracionais de UHES.

Finalmente, segue como sugestão para trabalhos futuros, o uso de uma amostra com maior número de partidas sequenciais de uma mesma hidrelétrica, ou uso de dados de diferentes unidades. Também, indica-se a aplicação de outros filtros de dados como, por exemplo, o Short Fourier, Single Spectrum Analysis (SSA) e entre outros.

REFERÊNCIAS BIBLIOGRÁFICAS

ANEEL. Energia no Brasil e no Mundo. **Atlas de Energia Elétrica do Brasil**, p. 1–12, 2008a.

ANEEL. Energia Hidráulica. **Atlas de energia elétrica do Brasil**, p. 49–61, 2008b.

ANEEL. Boletim de Informações Gerenciais - 1º trimestre 2018. p. 73, 2018.

BERAN, J. **Statistics for long-memory processes**. [s.l.] Routledge, 2017.

BJORKVOLL, T.; BAKKEN, B. Calculating the Start-Up Costs of Hydropower Generators. **14th PSCC**, n. June, p. 24–28, 2002.

BORGES, S. S. **Pré despacho de potência ativa e reativa para sistemas hidrotérmicos utilizando método de pontos interiores e coordenadas retangulares**. [s.l.] Universidade Federal do Paraná, 2010.

BOUSDEKIS, A. et al. A proactive decision making framework for condition-based maintenance. **Industrial Management & Data Systems**, v. 115, n. 7, p. 1225–1250, 2015.

BOX, G. E. P. et al. **Time series analysis: forecasting and control**. [s.l.] John Wiley & Sons, 2008.

BOX, G.; PIERCE, D. Distribution of Residual Autocorrelations in Autoregressive Integrated moving Average Time Series Models. **Journal of the American Statistical Association**, v. 65, n. 332, p. 1509–1526, 1970.

BUSSAB, W. O.; MORETTIN, P. A. Medidas-Resumo. In: **Estatística básica**. 5ª ed. São-Paulo: Editora Saraiva, 2004. p. 35–58.

CARVALHO, L. C. X. DE. **Planejamento de sistemas hidrotérmicos: uma análise comparativa entre as representações a usinas individualizadas e a reservatórios equivalentes de energia**. [s.l.] Florianópolis, SC, 2002.

CEPEL. **Projeto NEWAVE: Modelo Estratégico de Geração Hidrotérmica a**

Subsistemas Equivalentes - Manual do Usuário - Versão 17.5.3. Rio de Janeiro: [s.n.].

CEPEL. DECOMP - Modelo de Planejamento da Operação de Sistemas

Hidrotérmicos Interligados de Curto Prazo. Disponível em:

<<http://www.cepel.br/produtos/decomp-modelo-de-planejamento-da-operacao-de-sistemas-hidrotermicos-interligados-de-curto-prazo.htm>>. Acesso em: 11 ago. 2018a.

CEPEL. DESSEM - Modelo de Despacho Hidrotérmico de Curto Prazo. Disponível

em: <<http://www.cepel.br/produtos/dessem-modelo-de-despacho-hidrotermico-de-curto-prazo.htm>>. Acesso em: 11 ago. 2018b.

CICOGNA, M. A. Sistema de Suporte à Decisão para o Planejamento e a

Programação da Operação de Sistemas de Energia Elétrica. [s.l.] Universidade Estadual de Campinas, 2003.

CORUMBÁ CONCESSÕES. Previsão do Processo de Degradação dos Conjuntos

Turbo Geradores das UHEs com Base em Diagramas de Estado : Análise das

Contingências e Oscilações de Cargas na Região Geométrica Rio de Janeiro, 2018a.

CORUMBÁ CONCESSÕES. UHE Corumbá IV - Visão Geral. Disponível em:

<<http://www.corumbaconcessoes.com.br/uhe-corumba-iv/visao-geral/>>. Acesso em: 25 jul. 2018b.

COSTA, E. DA S.; SENA, A. J. C.; MESQUITA, A. L. A. SOBRE OS SINAIS DE VIBRAÇÃO NO MONITORAMENTO DE UNIDADES HIDROGERADORAS.

Congresso Nacional de Engenharia Mecânica. **Anais...** Campina Grande: ABCM, 2010

D'ARAÚJO, R. P. Setor elétrico brasileiro: uma aventura mercantil. 1^a ed. Brasília:

CONFEA-Conselho Federal de Engenharia, Arquitetura e Agronomia, 2009.

DEMEO, E. A. et al. Wind plant integration [wind power plants]. IEEE Power and

Energy Magazine, v. 3, n. 6, p. 38–46, 2005.

DEUS, M. L. D. Séries Temporais Aplicadas ao Planejamento da Operação do

Sistema Interligado Nacional–SIN. [s.l.] Dissertação de Mestrado, 2008.

EHLERS, R. Análise De Séries Temporais. Departamen ed. Paraná: Universidade

Federal do Paraná, 2007.

ENCINA, A. **Um modelo de otimização de despacho de máquinas em sistemas elétricos**. [s.l.] Universidade Estadual de Campinas, 1999.

ENCINA, A. **Despacho ótimo de unidades geradoras em sistemas hidrelétricos via heurística baseada em relaxação lagrangeana e programação dinâmica** . [s.l.] UNIVERSIDADE ESTADUAL DE CAMPINAS FACULDADE, 2006.

EPRI. **Flexible Operation of Hydropower Plants**. Palo Alto: [s.n.].

FRALEY, C. . ET AL. **Fracdiff: Fractionally differenced ARIMA aka ARFIMA(p,d,q) models**, 2012. Disponível em: <<https://cran.r-project.org/package=fracdiff>>

GAGNON, M. et al. Impact of startup scheme on Francis runner life expectancy. **IOP Conference Series: Earth and Environmental Science**, v. 12, p. 012107, 2010.

GHALANOS, A. Rugarch: Univariate GARCH models. **Journal of Statistical Software**, p. 107, 2018.

GRANGER, C. W. J.; JOYEUX, R. An introduction to long-memory time series models and fractional differencing. **Journal of time series analysis**, v. 1, n. 1, p. 15–29, 1980.

HANSEN, R. J.; HALL, D. L.; KURTZ, S. K. **A new approach to the challenge of machinery prognostics**. ASME 1994 International Gas Turbine and Aeroengine Congress and Exposition. **Anais...Hagua**, Netherlands: American Society of Mechanical Engineers, 1994

HOSKING, J. R. M. Fractional differencing. **Biometrika**, v. 68, n. 1, p. 165–176, 1981.

HYNDMAN, R. J.; KHANDAKAR, Y. Automatic time series forecasting: the forecast package for R. **Journal of Statistical Software**, v. 26, n. 3, p. 1–22, 2008.

JARDINE, A. K. S.; LIN, D.; BANJEVIC, D. A review on machinery diagnostics and prognostics implementing condition-based maintenance. **Mechanical Systems and Signal Processing**, v. 20, n. 7, p. 1483–1510, 2006.

JOHNSON, R. A.; WICHERN, D. W. Applied multivariate statistics. In: **Englewood Cliffs, NJ: Prentice Hall**. 6. ed. New Jersey: Pearson Education, 2007. p. 177–186.

KADOWAKI, M. **Modelo de Programação da Operação de Sistemas Hidrotérmicos Predominantemente Hidrelétricos Short Term Generation Scheduling of Hydro Dominant Hydrothermal Systems**. [s.l.] UNICAMP, 2012.

KOTHAMASU, R. et al. System health monitoring and prognostics -a review of current paradigms and practices 1 Maintenance strategies and motivations for health monitoring 1. **Int J Adv Manuf Technol**, v. 28, p. 1012–1024, 2006.

LE, T. T. **Contribution to deterioration modeling and residual life estimation based on condition monitoring data Contribution to deterioration modeling and residual life estimation based on condition monitoring data**. [s.l.] Université Grenoble Alpes, 2015.

LEE, J. et al. Prognostics and health management design for rotary machinery systems—Reviews, methodology and applications. **Mechanical Systems and Signal Processing**, v. 42, n. 1–2, p. 314–334, 2014.

LEE, J.; WANG, H. New Technologies for Maintenance. In: **Springer Series in Reliability Engineering**. Londres: Springer, 2008. v. 8p. 49–78.

LIU, X.; LUO, Y.; WANG, Z. A review on fatigue damage mechanism in hydro turbines. **Renewable and Sustainable Energy Reviews**, v. 54, p. 1–14, 2016.

MACEIRA, M. et al. Chain of optimization models for setting the energy dispatch and spot price in the Brazilian system. **Power System Computation Conference**, n. June, p. 24–28, 2002.

MOHANTA, R. K. et al. Sources of vibration and their treatment in hydro power stations-A review. **Engineering Science and Technology, an International Journal**, v. 20, n. 2, p. 637–648, 2017.

MORETTIN, P. A.; TOLOI, C. **Análise de séries temporais**. [s.l.: s.n.].

MORETTIN, P. A.; TOLOI, C. M. DE C. **Modelos para previsão de séries temporais**. [s.l.] Instituto de matematica pura e aplicada, 1981. v. 1

NILSSON, O.; SJELVGREN, D. Hydro unit start-up costs and their impact on the short term scheduling strategies of swedish power producers. **IEEE Transactions on Power Systems**, v. 12, n. 1, p. 38–44, 1997.

OHISHI, T. **Planejamento da operação de curto prazo de sistemas hidrotermicos predominantemente hidraulicas**. [s.l.] UNICAMP, 1990.

ONS. **INTERCÂMBIOS DE ENERGIA**. Disponível em: <http://ons.org.br/Paginas/resultados-da-operacao/historico-da-operacao/intercambios_energia>. Acesso em: 20 jul. 2016.

ONS. **Plano da Operação Energética 2017/2021 - PEN 2017**. Rio de Janeiro: [s.n.]. Disponível em: <http://www.ons.org.br/AcervoDigitalDocumentosEPublicacoes/RE-3-0108-2017_PEN2017_SumarioExecutivo.pdf>.

ONS. **Curva de Carga Horária**. Disponível em: <<http://ons.org.br/pt/paginas/resultados-da-operacao/historico-da-operacao>>. Acesso em: 17 ago. 2017b.

ONS. **O QUE É O SIN**. Disponível em: <<http://ons.org.br/paginas/sobre-o-sin/o-que-e-o-sin>>. Acesso em: 7 ago. 2018.

ONUDI. **Pequenas centrais hidrelétricas: Aplicação ao seu desenvolvimento na América Latina e no Caribe** Observatório de Energias Renováveis para a America Latina e Caribe, , 2016.

PENG, Y.; DONG, M.; ZUO, M. J. Current status of machine prognostics in condition-based maintenance: A review. **International Journal of Advanced Manufacturing Technology**, v. 50, n. 1–4, p. 297–313, 2010.

PENNA, D. D. J. **Definição da árvore de cenários de afluências para o planejamento da operação energética de médio prazo**. [s.l.] PUC-RIO, 2009.

PEREIRA, M. V. F. et al. Modelos computacionais para planejamento e operação de sistemas hidrotérmicos de grande porte. **SBA: Controle de Automação**, v. 1, n. 1, p. 31–41, 1987.

PINO, G.; RIBAS, J. R.; GUIMARÃES, L. F. Bearing Diagnostics of Hydro Power

- Plants Using Wavelet Packet Transform and a Hidden Markov Model with Orbit Curves. **Shock and Vibration**, v. 2018, p. 1–12, 2018.
- PINTELO, L.; PARODI-HERZ, A. Maintenance: An Evolutionary Perspective. In: **Springer Series in Reliability Engineering**. Londres: Springer, 2008. v. 8p. 21–48.
- POLL, H. G.; ZANUTTO, J. C.; PONGE-FERREIRA, W. Hydraulic power plant machine dynamic diagnosis. **Shock and Vibration**, v. 13, n. 4–5, p. 409–427, 2006.
- QUEIROZ, A. R. Stochastic hydro-thermal scheduling optimization: An overview. **Renewable and Sustainable Energy Reviews**, v. 62, p. 382–395, 2016.
- R CORE TEAM. **R: A language and environment for statistical computing** Vienna, Austria R Foundation for Statistical Computing, , 2017. Disponível em: <<https://www.r-project.org/>>
- RAZALI, N. M.; WAH, Y. B. Power comparisons of Shapiro-Wilk , Kolmogorov-Smirnov, Lilliefors and Anderson-Darling tests. **Journal of Statistical Modeling and Analytics**, v. 2, n. 1, p. 21–33, 2011.
- RISSI, G. F. **Modelo de otimização de despacho hidrotérmico com risco de déficit controlado**. [s.l.] Universidade de São Paulo, 2009.
- RODRIGUES, R. N. **DESPACHO DE UNIDADES GERADORAS HIDRELÉTRICAS UTILIZANDO LAGRANGEANO AUMENTADO**. [s.l.] UNIVERSIDADE FEDERAL DE SANTA CATARINA, 2003.
- SCHAEFFER, R. **Hidreletricidade e Transmissão de Eletricidade** Rio de Janeiro, 2016.
- SEIDEL, U. et al. **Dynamic loads in Francis runners and their impact on fatigue life**. IOP Conference Series: Earth and Environmental Science. **Anais...2014**
- SHUMWAY, R. H.; STOFFER, D. S. **Time Series Analysis and Its Applications**. 2011.
- SOARES FILHO, S. Planejamento da operação de sistemas hidrotérmicos. **SBA- Controle e Automação**, v. 1, n. 2, p. 122–131, 1987.

SORIANO, G. D. **Métodos de otimização para a resolução do problema do despacho hidrotérmico-eólico em função da não linearidade da altura de queda.** [s.l.] UFPE, 2016.

SOUZA, S. N. M. DE. **Geração de energia elétrica - Hidrelétrica.** Disponível em: <www.unicentro.br/posgraduacao/mestrado/bioenergia/material_didatico/2014/Prof_SAMUEL_Aula_3_GERA_O_DE_ENERGIA_EL_TRICA_HIDREL_TRICA_53710b9176809.pdf>. Acesso em: 1 ago. 2018.

SOUZA, R. C.; CAMARGO, M. E. **Análise e previsão de séries temporais: os modelos ARIMA.** 2^a ed. [s.l.: s.n.].

STACK, J. R.; HABETLER, T. G.; HARLEY, R. G. Effects of machine speed on the development and detection of rolling element bearing faults. **IEEE Power Electronics Letters**, v. 1, n. 1, p. 19–21, 2003.

STEINBERGER, J. M. **Integração Em Larga Escala De Geração Eólica Em Sistemas Hidrotérmicos.** [s.l.] UFRJ, 2012.

SUH, J. H.; KUMARA, S. R. T.; MYSORE, S. P. Machinery fault diagnosis and prognosis: application of advanced signal processing techniques. **CIRP Annals - Manufacturing Technology**, v. 48, n. 1, p. 317–320, 1999.

TANDON, N.; PAREY, A. Condition Monitoring of Rotary Machines. **Condition Monitoring and Control for Intelligent Manufacturing**, p. 109–136, 2006.

TRIVEDI, C.; GANDHI, B.; MICHEL, C. J. Effect of transients on Francis turbine runner life: A review. **Journal of Hydraulic Research**, v. 51, n. 2, p. 121–132, 2013.

TSAY, R. S. **Analysis of financial time series.** [s.l.] John Wiley & Sons, 2005. v. 543

VLADISLAVLEV, L. A. et al. **Vibration of hydro units in hydroelectric power plants.** New Delhi : Springfield, Va.: Amerind Publishing Co. ; Available from the U.S. Dept. of Commerce, National Technical Information Service, 1979.

WANG, W. Condition-based Maintenance Modelling. In: **Springer Series in Reliability Engineering.** Londres: Springer, 2008. v. 8p. 111–131.

WU, Y. et al. Vibration-based condition monitoring. In: **Mechanisms and Machine Science**. [s.l: s.n.]. v. 11p. 431–477.

ZIO, E.; COMPARE, M. Evaluating maintenance policies by quantitative modeling and analysis. **Reliability Engineering and System Safety**, v. 109, 2013.

ZIVOT, E.; WANG, J. Modelling Financial Time Series with S-PLUS. p. 1020, 2006.

ANEXO I – PROGRAMAS REALIZADOS

INICIALIZAÇÃO DOS PROGRAMAS

```
#Inicialização programas
library(gridExtra)
library(grid)
library(plotly)
library(stats)
library(tseries)
library(lmtest)
library(urca)
library(fracdiff)
library(arfima)
library(fBasics)
library(hexView)
library(FitARMA)
library(fArma)
library(fGarch)
library(vars)
library(ArfimaMLM)
library(longmemo)
library(forecast)
library(tidyverse)
library(ggplot2)
library(RColorBrewer)
library(nortest)
library(aTSA)
library(pracma)
library(arfima)

#DADOS COMPLETOS
dadostodos = read.table("dadostodos.csv", header=T, sep=";", dec = ",")
tempo= 0.007009*(1:nrow(dadostodos))
#gráfico de dados todos sem filtro
pdf("dadostodos.pdf", paper="a4", width = 480, height = 480)
par(mfrow=c(5,3))
for(i in 1:ncol(dadostodos)){
  if((i %% 2) == 0) { #separação direções x e y
    a= i/2
    name= c("série y",a, sep="")
  } else {
    b= (i+1)/2
    name= c("série x",b, sep="")
  }
  plot(dadostodos[,i], x= tempo, main=paste(name), ylim=c(800,1500),
       xlab="tempo (segundos)", ylab="vibração (micrometros)") #gráfico
}
dev.off()
```

```

#SÉRIE SEM A COMPONENTE CC
dadosdc = read.table("base_de_dados-comDC.csv", header=T, sep=";", dec = ",")
tempo= 0.007009*(1:nrow(dadosdc))
pdf("dadosdc.pdf", paper="a4", width = 480, height = 480)
par(mfrow=c(5,3))
for(i in 1:ncol(dadosdc)){
  if((i %% 2) == 0) {
    a= i/2
    name= c("série y",a, sep="")
  } else {
    b= (i+1)/2
    name= c("série x",b, sep="")
  }
  plot(dadosdc[,i], x= tempo, main=paste(name), ylim=c(-300,300),
       xlab="tempo (segundos)", ylab="vibração (micrometros)")
}
dev.off()

```

```

#SÉRIE SEM VALORES INICIAIS COM COMPONENTE DC
#inicialização dados limpos
dadoslimpos = read.table("dados-limpos.csv", header=T, sep=";", dec = ",")
tempolimpos= 0.007009*(1:nrow(dadoslimpos))

```

ANÁLISE EXPLORATÓRIA DOS DADOS

```

x.t=seq(1,428)
# COMPORTAMENTO DA MÉDIA
media.t=list ()
media.t[]
media=c()
par(mfrow=c(5,3))
for(i in 1:ncol(dadosdc)){
  c=100
  media=c()
  while (c<=42800){
    media=c(media, mean(dadosdc[c-99:c,i]))
    c=c +100
  }
  if((i %% 2) == 0) {
    a= i/2
    name= paste("Série y ",a,sep="")
  } else {
    b= (i+1)/2
    name= paste("Série x ",b,sep="")
  }
  media=data.frame(media)
  f= ggplot(media, aes(x=x.t,y=media))+

```

```

    geom_point()+
    geom_smooth()+
    ggtitle((name), subtitle ="Média")+
    ylim(c(-30,20))+ xlab("Segundos")+ylab("Vibrações (micrometros)")
    media.t[[i]] <- f
  }
pdf("media-todos.pdf",paper="a4", width = 480, height = 480)
marrangeGrob(grobs = c(media.t), nrow=4, ncol=3,as.table = TRUE,top=NULL)
dev.off()

#COMPORTAMENTO DO DESVIO
desvio.t <- list()
desvio.t[]
desvio=c()
par(mfrow=c(2,5))
for(i in 1:ncol(dadosdc)){
  c=100
  desvio <- c()
  while (c<=42800){
    desvio=c(desvio, sd(dadosdc[c-99:c,i]))
    c=c +100
  }
  if((i %% 2) == 0) {
    a= i/2
    name= paste("Série y ",a,sep="")
  } else {
    b= (i+1)/2
    name= paste("Série x ",b,sep="")
  }
  desvio=data.frame(desvio)
  f= ggplot(desvio, aes(x=x.t,y=desvio))+
    geom_point()+
    geom_smooth()+
    ggtitle(paste(name), subtitle ="Desvio ")+
    ylim(c(0,55))+ xlab("Segundos")+ylab("Vibrações (micrometros)")
  desvio.t[[i]] <- f
}
pdf("Desvio-todos.pdf",paper = "a4", width = 480, height = 480) #output as PDF
marrangeGrob(desvio.t, nrow=4, ncol=3,as.table = FALSE,top=NULL ) #use gridExtra
to put plots together
dev.off()

#COMPORTAMENTO DA AMPLITUDE
amplitude.t <- list()
amplitude.t[]
amplitude =c()
par(mfrow=c(2,5))
for(i in 1:ncol(dadosdc)){
  c=100
  amplitude<- c()

```



```

while (c<=42800){
  amplitude=c(amplitude, max(diff(range(dadosdc[(c-99):(c),i])))
  c=c +100
}
if((i %% 2) == 0) {
  a= i/2
  name= paste("Série y ",a,sep="")
} else {
  b= (i+1)/2
  name= paste("Série x ",b,sep="")
}
x.t=seq(1,428)
amplitude=data.frame(amplitude)
a= ggplot(amplitude, aes(x=x.t,y=amplitude))+
  geom_point()+
  geom_smooth()+
  ggtitle(paste(name), subtitle ="Amplitude")+
  ylim(c(0,375))+ xlab("Segundos")+ ylab("Vibrações (micrometros)")
amplitude.t[[i]] <- a
}
pdf("amplitude-todos.pdf") #output as PDF
marrangeGrob(amplitude.t, nrow=3, ncol=4,as.table = FALSE, top=NULL ) #use
gridExtra to put plots together
dev.off()

```

ANÁLISE DESCRITIVA DAS SÉRIES

```

#SÉRIE DE DADOS
pdf("dadoslimpos.pdf",paper="a4", width = 480, height = 480)
par(mfrow=c(5,2))
for(i in 1:ncol(dadoslimpos)){
  if((i %% 2) == 0) {
    a= i/2
    name= c("série y",a, sep="")
  } else {
    b= (i+1)/2
    name= c("série x",b, sep="")
  }
  plot(dadoslimpos[,i],x= tempolimpos, main=paste(name), ylim=c(-300,300),
    xlab="tempo (segundos)", ylab="vibração (micrometros)")
}
dev.off()

```

```

#HISTOGRAMA
pdf("Histograma-todos.pdf")
par(mfrow=c(3,2))
for(i in 1:ncol(dadoslimpos)){
  h = hist(dadoslimpos[,i],main=" Histograma",ylab="",
    col="blue",xlab = "",ylim=c(0,8000))
  if((i %% 2) == 0) {

```

```

    a= i/2
    name= paste("Série y ",a,sep="")
  } else {
    b= (i+1)/2
    name= paste("Série x ",b,sep="")
  }
  title(paste(name),line=3,adj=0.5, cex=2, outer = FALSE)
  xfit=seq(min(dadoslimpos[,i]), max(dadoslimpos[,i]), length=10000)
  yfit=dnorm(xfit, mean = mean(dadoslimpos[,i]), sd=sd(dadoslimpos[,i]))
  yfit = yfit*diff(h$mids[1:2])*length(dadoslimpos[,i])
  lines(xfit,yfit, lwd=2)
}
dev.off()

#GRÁFICO QUANTIL-QUANTIL
pdf("QQ-geral.pdf")
par(mfrow=c(3,2))
for(i in 1:ncol(dadoslimpos)){
  qq= qqnorm(dadoslimpos[,i], main = "Q-Q Plot")
  qqline(dadoslimpos[,i])
  if((i %% 2) == 0) {
    a= i/2
    name= paste("Série y ",a,sep="")
  } else {
    b= (i+1)/2
    name= paste("Série x ",b,sep="")
  }
  title(paste(name),line=3,adj=0.5, cex=2, outer = FALSE)
}
dev.off()

#TESTE DE NORMALIDADE
library(nortest)
teste=c()
for(i in 1:ncol(dadoslimpos )){
  teste= print(ad.test(dadoslimpos[,i]))
  if((i %% 2) == 0) {
    a= i/2
    name= paste("Série y ",a,sep="")
  } else {
    b= (i+1)/2
    name= paste("Série x ",b,sep="")
  }
  B= print(name)
  A= paste("Resultado Teste de Shapiro")
  out <- capture.output(B,teste)
  cat("Resultado shapiro", out, file="Resultado-Shapiro", sep="\n", append=TRUE)
}

#plotagem curvas ACF

```

```

Lag.Max=100
pdf("ACFS-geral2.pdf",paper = "a4",width = 480, height = 480 ) #output as PDF
par(mfrow=c(5,3))
for(i in 1:ncol(dadoslimpos )){
  if((i %% 2) == 0) {
    a= i/2
    name.acf= paste("Fac da série y ",a,sep="")
  } else {
    b= (i+1)/2
    name.acf= paste("Fac da série x ",b,sep="")
  }
  Acf= acf(dadoslimpos[,i],ylab="",main=paste(name.acf),
    lag.max = Lag.Max)
}
dev.off()

```

#plotagem curvas FAC e FACP com primeira diferença

```

Lag.Max=100
pdf("ACFXS-geral.pdf",paper = "a4",width = 480, height = 480 ) #output as PDF
par(mfrow=c(3,2))
for(i in 1:ncol(dadoslimpos)){
  dados.diff=diff(dadoslimpos[,i])
  if((i %% 2) == 0) {
    a= i/2
    name.acf= paste("Fac Série y ",a,sep="")
  } else {
    b= (i+1)/2
    name.acf= paste("Fac Série x ",b,sep="")
  }
  Acf.t= acf(dados.diff,ylab="",main=paste(name.acf),
    lag.max = Lag.Max)
}
dev.off()

```

#plotagem curvas FAC e FACP com segunda diferença

```

Lag.Max=100
pdf("ACFXXS-geral.pdf",paper = "a4",width = 480, height = 480 ) #output as PDF
par(mfrow=c(3,2))
for(i in 1:ncol(dadoslimpos)){
  dados.diff.2=diff(dadoslimpos[,i],differences = 2)
  if((i %% 2) == 0) {
    a= i/2
    name.acf= paste("Fac Série y ",a,sep="")
  } else {
    b= (i+1)/2
    name.acf= paste("Fac Série x ",b,sep="")
  }
  Acf.t= acf(dados.diff.2,ylab="",main=paste(name.acf),
    lag.max = Lag.Max)
}

```

```
dev.off()
```

APLICAÇÃO DOS MODELOS LINEARES

```
#IDENTIFICAÇÃO DO MODELO #SÉRIES ORIGINAIS
#plotagem curvas FAC e FACP
Lag.Max=100
pdf("pACF-geral.pdf",paper = "a4",width = 480, height = 480 ) #output as PDF
par(mfrow=c(5,3))
for(i in 1:ncol(dadoslimpos )){
  if((i %% 2) == 0) {
    a= i/2
    name.pacf= paste("Facp Série y ",a,sep="")
  } else {
    b= (i+1)/2
    name.pacf= paste("Facp Série x ",b,sep="")
  }
  Pacf=pacf(dadoslimpos [,i],ylab="",main=paste(name.pacf), lag.max = Lag.Max)
}
dev.off()
```

```
# ESTIMATIVA e VERIFICAÇÃO COEFICIENTES ARIMA INICIAL
#ESTIMATIVA INICIAL
#ANÁLISE RESIDUAL
p=38
d=0
q=0
Lag = 20
var=matrix(NA, nrow = ncol(dadoslimpos), ncol=1)
pdf("verificacao-arima-trans37-0.pdf",paper = "a4",width = 480, height = 480 )
par(mfrow=c(4,4))
for(i in 1:ncol(dadoslimpos)){
  Series=ts(dadoslimpos[,i])
  Fit.arima=arima(Series,order=c(p,d,q), method = c("CSS"))
  residuos.arima=Fit.arima$residuals
  if((i %% 2) == 0) {
    a= i/2
    name= paste("Série y ",a,sep="")
  } else {
    b= (i+1)/2
    name= paste("Série x ",b, sep="")
  }
  plot(Series,x=tempolimpos, ylab="vibração (micrometros)",xlab="tempo (segundos)",
    type="l",ylim=c(-300,300), main=paste("Residuos ",name,sep=""))
  par(new=T)
  plot(residuos.arima,x=tempolimpos, type="l",ylab="",xlab="",
    ylim=c(-300,300), col="red")
  title(paste("ARMA(",p,"",q,"")", sep = ""), outer = TRUE, cex=0.8, line = -1.1,
  adj=0.5)
```

```

if((i %% 2) == 0) {
  a= i/2
  name.acf= paste("Fac série y ",a,sep="")
} else {
  b= (i+1)/2
  name.acf= paste("Fac série x ",b, sep="")
}
#ACF
plot(acf(residuos.arima,plot=F,lag.max=Lag)
     ,main=paste(name.acf),ylim=c(-.05,0.05))
if((i %% 2) == 0) {
  a= i/2
  name.pacf= paste("Facp série y ",a,sep="")
} else {
  b= (i+1)/2
  name.pacf= paste("Facp série x ",b, sep="")
}
#PACF
plot(pacf(residuos.arima,plot=F,lag.max=Lag)
     ,main=paste(name.pacf),ylim=c(-.05,0.05))
#GRÁFICO QUANTIL-QUANTIL
qq= qqnorm(residuos.arima, main = "Q-Q Plot")
qqline(residuos.arima)
var[i,]=var(residuos.arima)
}
dev.off()
write.csv2(var, file = "variância-transiente.csv")
print(mean(var[,1]),digits=5)

#VERIFICAÇÃO ARMA
pdf("arima38.pdf",paper = "a4",width = 480, height = 480 ) #output as PDF
p=38
d=0
q=0
par(mfrow=c(1,2))
for(i in 1:ncol(dadoslimpos)){
  if((i %% 2) == 0) {
    a= i/2
    name= paste("Série y ",a," ARMA(",p,",",q,")",sep="")
  } else {
    b= (i+1)/2
    name= paste("Série x ",b," ARMA(",p,",",q,")", sep="")
  }
  serie=ts(dadoslimpos[,i])
  Fit.arima=Arima(serie,order=c(p,d,q), method = c("CSS"))
  tdiag(Fit.arima,x= tempolimpos, gof.lag=20)
  title(paste(name), cex=0.8, outer = TRUE, line = -1.7, adj=0.15)
}
dev.off()

```

APLICAÇÃO MODELO ARFIMA

1. ESTIMATIVA INICIAL ARFIMA

Ar.P.MAX=20

D.estim=matrix(NA,ncol=ncol(dadoslimpos),nrow=Ar.P.MAX)

pdf("Farima-teste-originais.pdf",paper = "a4", width = 480, height = 480)

par(mfrow=c(4,5))

for (k in 0:2) {

 for(j in 1:ncol(dadoslimpos)){

 Serie=dadoslimpos[,j]

 for(i in 1:Ar.P.MAX){

 fit <- fracdiff(Serie,nar=i,nma=k)

 D.estim[i,j]=coef(fit)[1]

 }}

for(i in 1:Ar.P.MAX){

 plot(D.estim[i,],xlab="SERIES",ylab="Estimativa de 'd'",pch=15

 ,main=paste("ARFIMA(",i,",d,",k,")",sep=""),ylim=c(-.5,1))

 abline(h=0,col="red",lty=2)

 title("Estimativa ARFIMA dos dados originais" , cex=0.8,line = -1, outer = TRUE)

}}

par(mfrow=c(1,1))

dev.off()

#6-1 IDENTIFICAÇÃO MODELO ARFIMA

p=1

d=0.25

q=2

pdf("Identificação-arfima5-originais.pdf",paper = "a4", width = 480, height = 480)

#output as PDF

par(mfrow=c(3,3))

for(i in 1:ncol(dadoslimpos)){

 if((i %% 2) == 0) {

 a= i/2

 name= paste("Série y ",a," ARFIMA(",p,",",d,",",q,")",sep="")

 } else {

 b= (i+1)/2

 name= paste("Série x ",b," ARFIMA(",p,",",d,",",q,")", sep="")

 }

 fit <- diffseries(dadoslimpos[,i],d)

 serie=ts(fit)

 Fit.arfima=arima(serie,order= c(p,0,q), method = c("CSS"))

 tsdiag(Fit.arfima)

 title(paste(name), col.main= "blue", cex=0.8, outer = TRUE, line = -1.7, adj=0.15)

}

dev.off()

APLICAÇÃO MODELOS NÃO-LINEARES

p=22

q=3

d=0

Lag = 50

```

pdf("Resíduos-quadrados-transiente22-3.pdf",paper = "a4", width = 480, height = 480)
#output as PDF
par(mfrow=c(5,3))
for(i in 1:ncol(dados.trans)){
  serie.trans=ts(dados.trans[,i])
  Fit.arima=arima(serie.trans,order=c(p,d,q), method = c("CSS"))
  RESIDUALs= Fit.arima$residuals
  RESIDUALS.QUADRADO= RESIDUALs^2 #RESIDUOS QUADRATICO
  if((i %% 2) == 0) {
    a= i/2
    name= paste("Série y ",a,sep="")
  } else {
    b= (i+1)/2
    name= paste("Série x ",b, sep="")
  }
  a=plot(RESIDUALS.QUADRADO, x=tempotrans, main=paste("Resíduos quadrados
",name, sep = ""),
        ylim=c(0,900),xlab="tempo (segundos)", ylab="vibração (micrometros)")
  acf.quadrado=acf(RESIDUALS.QUADRADO, main= "Fac residuos quadrados")
#ACF
  pacf.quadrado=pacf(RESIDUALS.QUADRADO, main= "Facp residuos quadrados")
#PACF
}
dev.off()

```

#ESTIMATIVA MODELO GARCH - TRANSIENTE

```

pdf("Modelo-Garch-Transiente21.pdf",paper = "a4",width = 480, height = 480) #output
as PDF
par(mfrow=c(4,2))
var=matrix(NA, ncol=1, nrow=ncol(dados.trans))
colnames("Variância")
Lag=50
for(i in 1:ncol(dados.trans)){
  serie=dados.trans[,i]
  spec = ugarchspec(variance.model=list(model="sGARCH",
                                     garchOrder=c(22,0)),
                    mean.model=list(armaOrder=c(22,3),include.mean = TRUE),
                    distribution.model = "norm")
  garch.fit.tran = ugarchfit(data = serie, spec=spec, solver = "hybrid",
                             solver.control=list(trace=FALSE, tol=1e-12,delta=1e-11),
                             numderiv.control = list(hess.zero.tol=1e-7))
  Residuals= garch.fit.tran@fit$z #RESÍDUOS STANDARDIZADOS
  x = garch.fit.tran@fit$fitted.values
  if((i %% 2) == 0) {
    a= i/2
    name= paste("Série y ",a,sep="")
  } else {
    b= (i+1)/2
    name= paste("Série x ",b,sep="")
  }
}

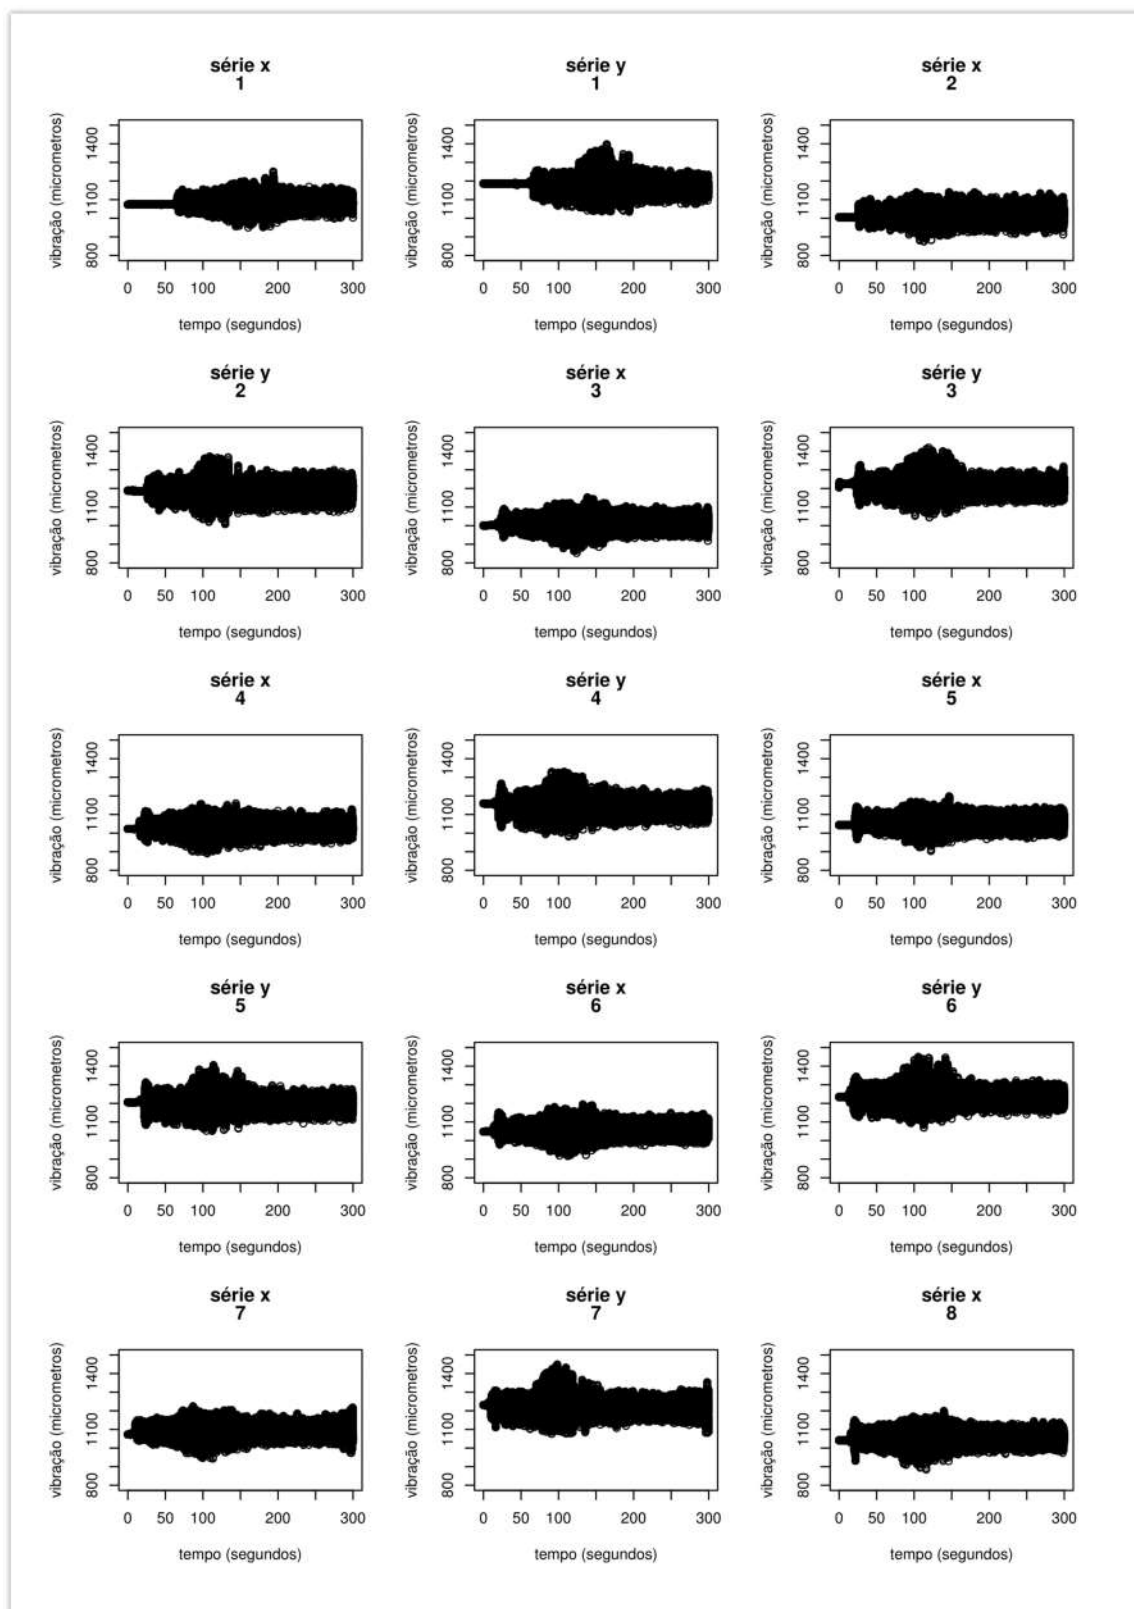
```

```

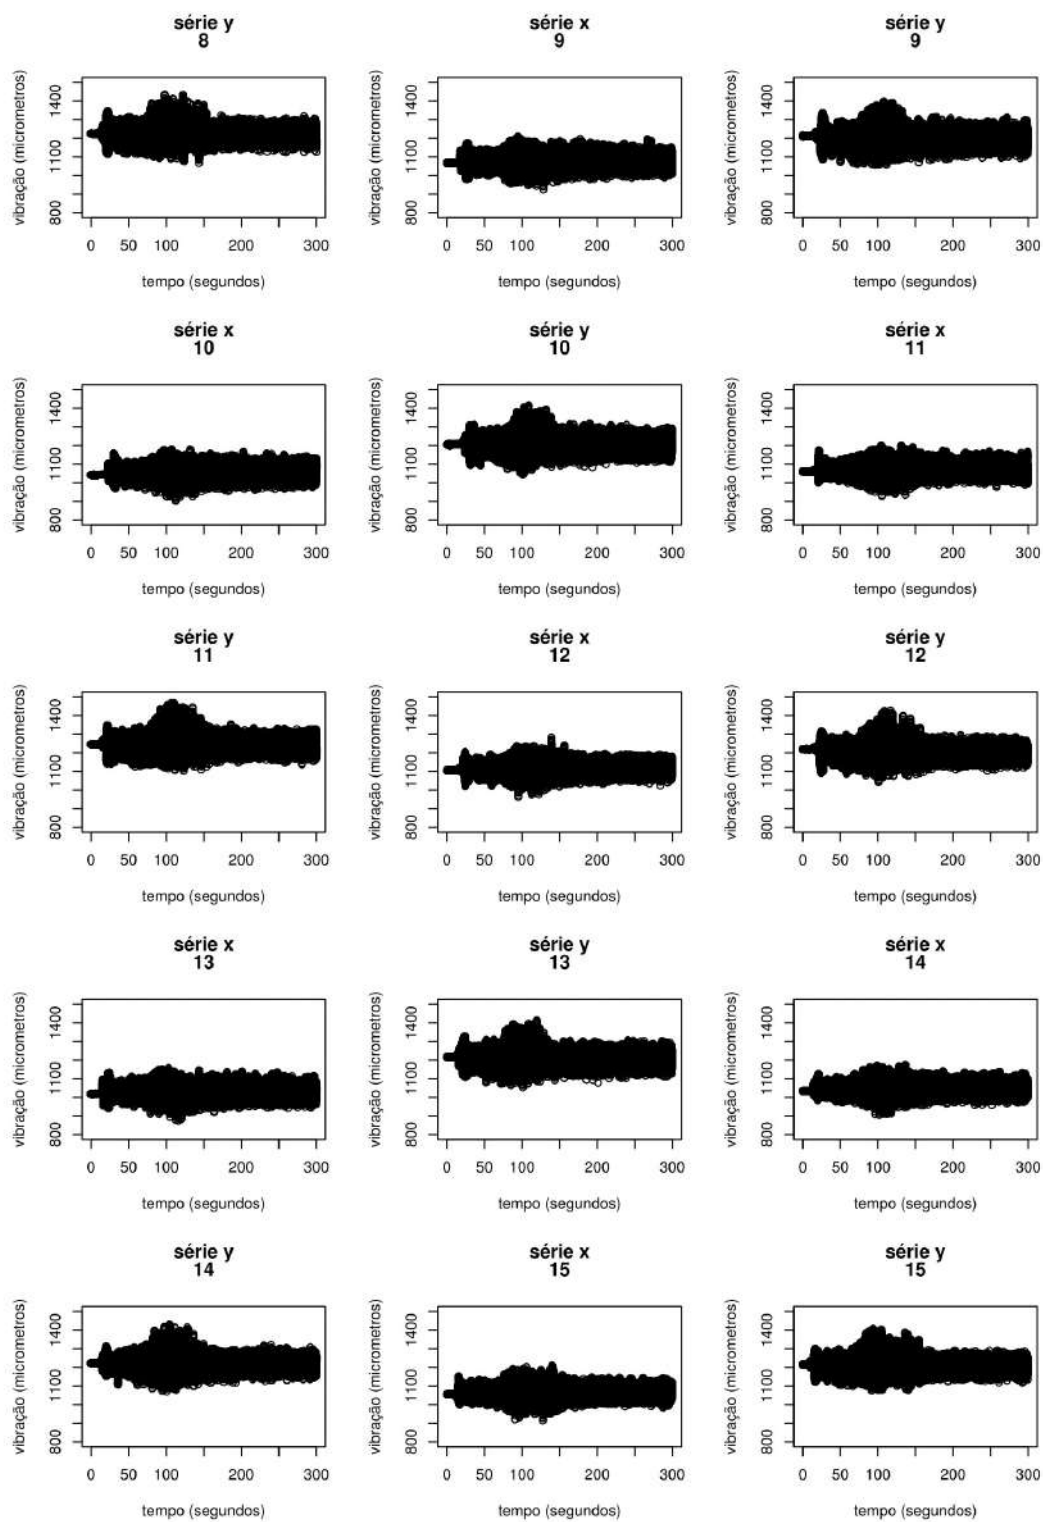
#GRÁFICO RESIDUAL STANDARDIZADO
plot(Residuals,xlab="",ylab="", ylim=c(-200,200), type="l", col="red") #Resíduos
standardizados
title(paste("ARMA(22,3)-Arch(21)"), cex=0.8, outer = TRUE, line = -1.2, adj=0.5)
#GRÁFICO DE VOLATILIDADE
plot(x,type="l", ylim= c(0,200), ylab="",col="light grey",
      xlab="tempo (microsegundos)", main=paste("Volatilidade da ",name, sep = ""))
par(new=T)
plot(garch.fit.tran@fit$sigma, xlab="", type="l",ylab="vibração (micrometros)",
      ylim=c(0,200), col="blue") #Volatilidade
#FAC E FACP RESIDUAL
acf(Residuals, main= "FAC residual",ylim=c(-0.1,0.3)) #FAC resíduos
pacf(Residuals, main= "FACP residual",ylim=c(-0.1,0.3)) #FACP resíduos
acf(Residuals^2, main= "FAC do quadrado residual",ylim=c(-0.2,0.5)) #FAC
dosresíduos quadrados
pacf(Residuals^2, main= "FACP do quadrado residual",ylim=c(-0.1,0.3)) #FACP
resíduos quadrados
#GRÁFICO QUANTIL-QUANTIL
qq= qqnorm(Residuals, col="dark blue")
ql= qqline(Residuals)
#HISTOGRAMA
h= hist(Residuals, col = "light gray", main="Histograma Residual", breaks=100,
ylim=c(0,1700))
xfit=seq(min(Residuals), max(Residuals), length=5000)
yfit=dnorm(xfit, mean = mean(Residuals), sd=sd(Residuals))
yfit = yfit*diff(h$mids[1:2])*length(Residuals)
lines(xfit,yfit, lwd=2, col="orange")
abline(v=mean(Residuals),col="dark green", lwd = 3)
mtext(paste("Média = ", round(mean(Residuals),d=4)), adj= 1,line = -1.5 )
#TESTE DE LJUNG-BOX NOS RESÍDUOS PADRONIZADOS
a= Box.test(Residuals, lag = 10, type = "Ljung-Box")
bt=summary(a)
#RESULTADO EM TXT
var[i,]=var(Residuals)
B= paste(name)
x=print(garch.fit.tran)
A= paste("Resultado Ljung-Box teste")
out <- capture.output(B,x,A,bt)
cat("Resultado Arma Garch", out, file="Resultado-ARMA-Garch- transiente",
sep="\n", append=TRUE)
}
dev.off()
write.csv2(var, file = "Variância residual.csv")

```

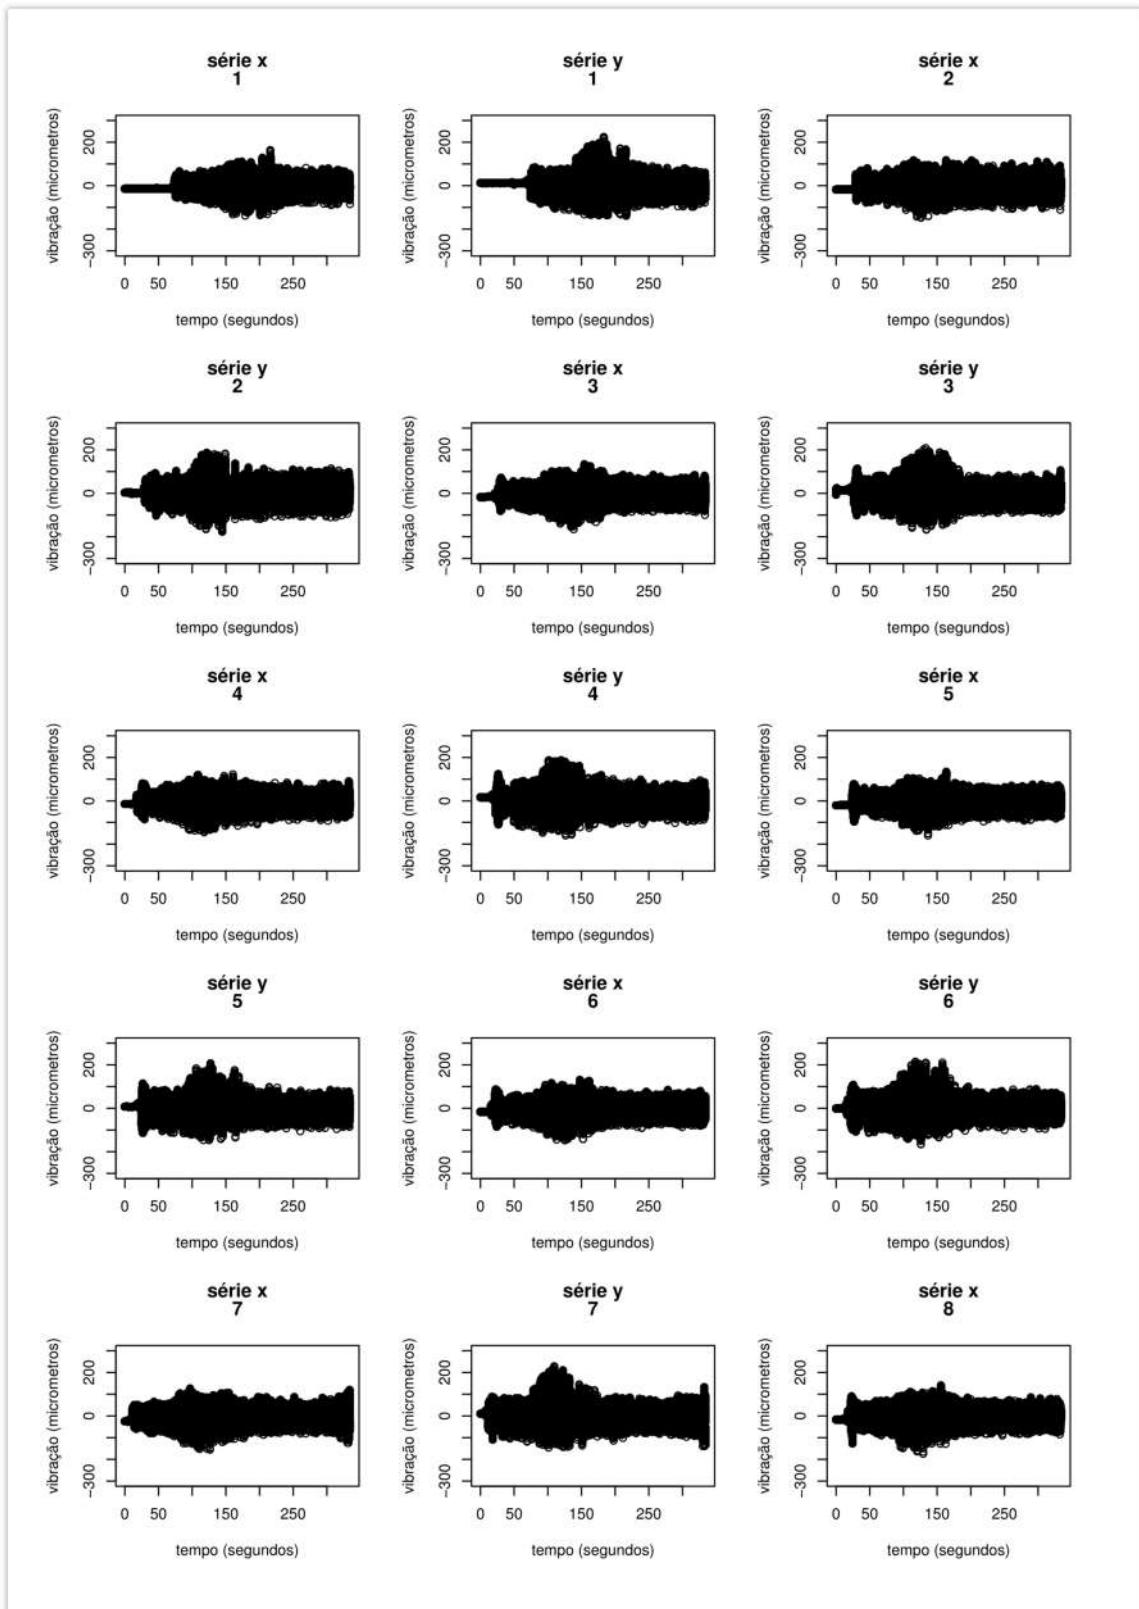

ANEXO II – ANÁLISE EXPLORATÓRIA DOS DADOS



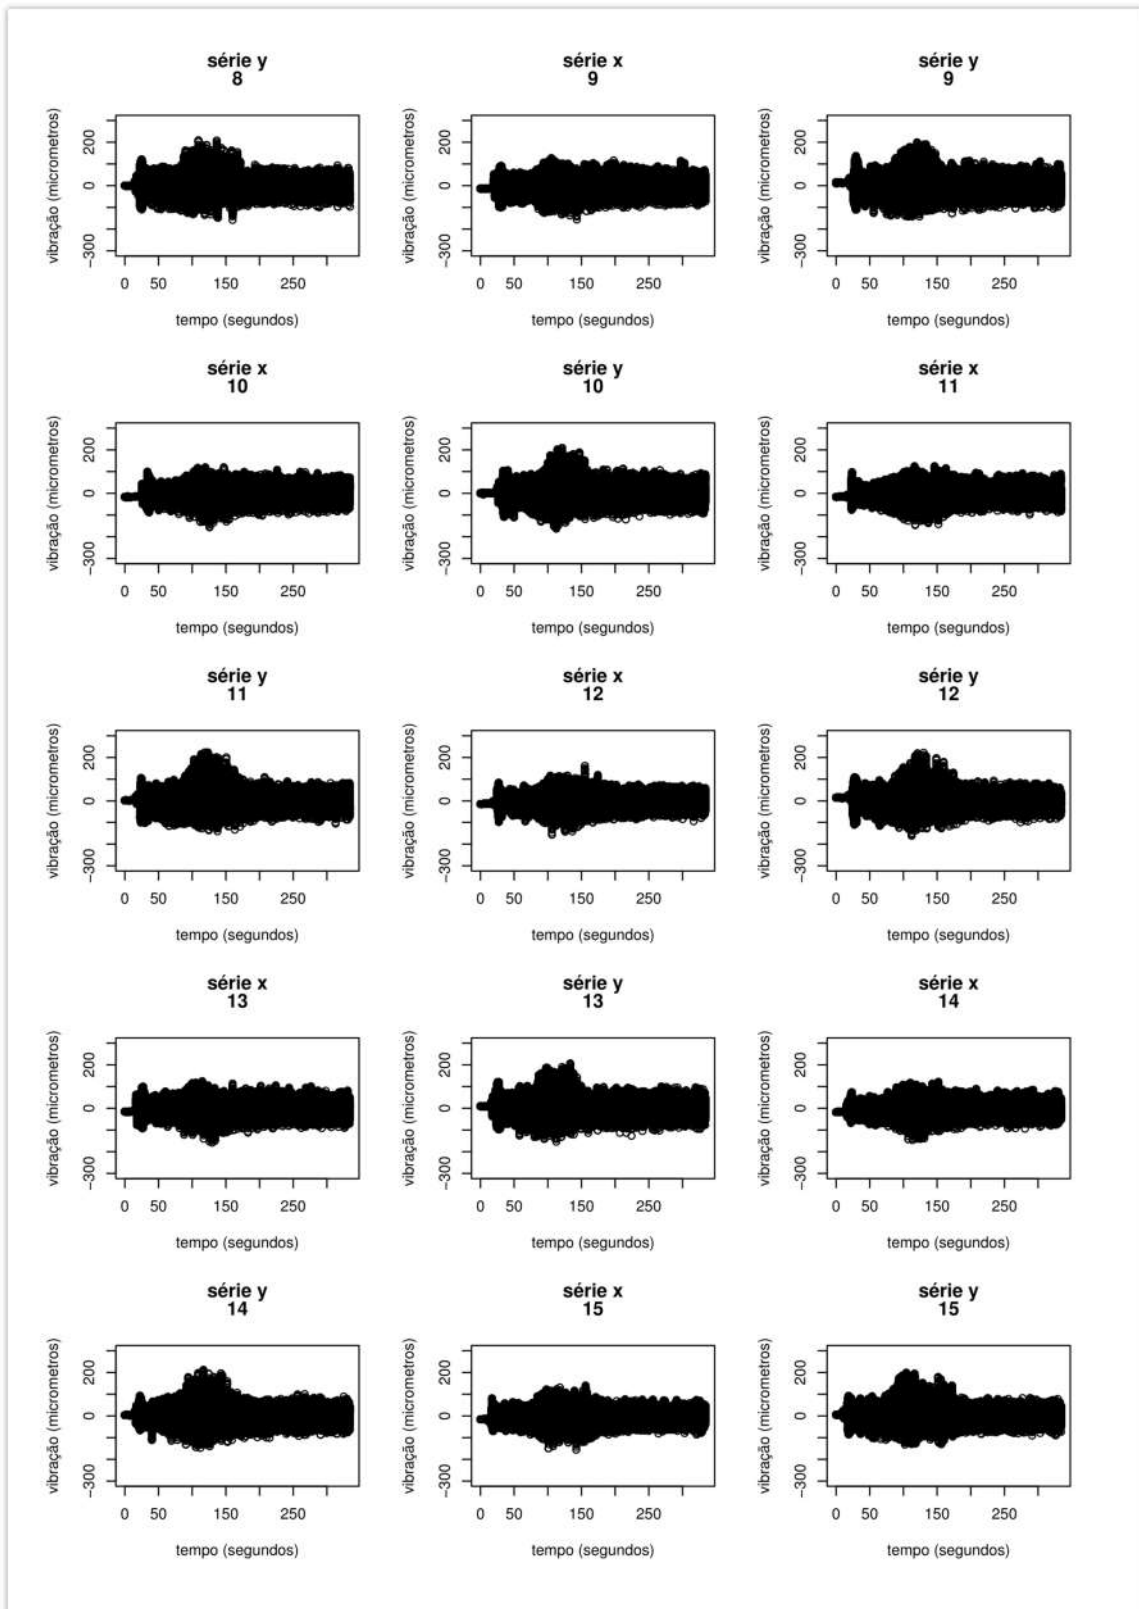
Anexo II - Figura 1: As séries vibracionais originais parte 1



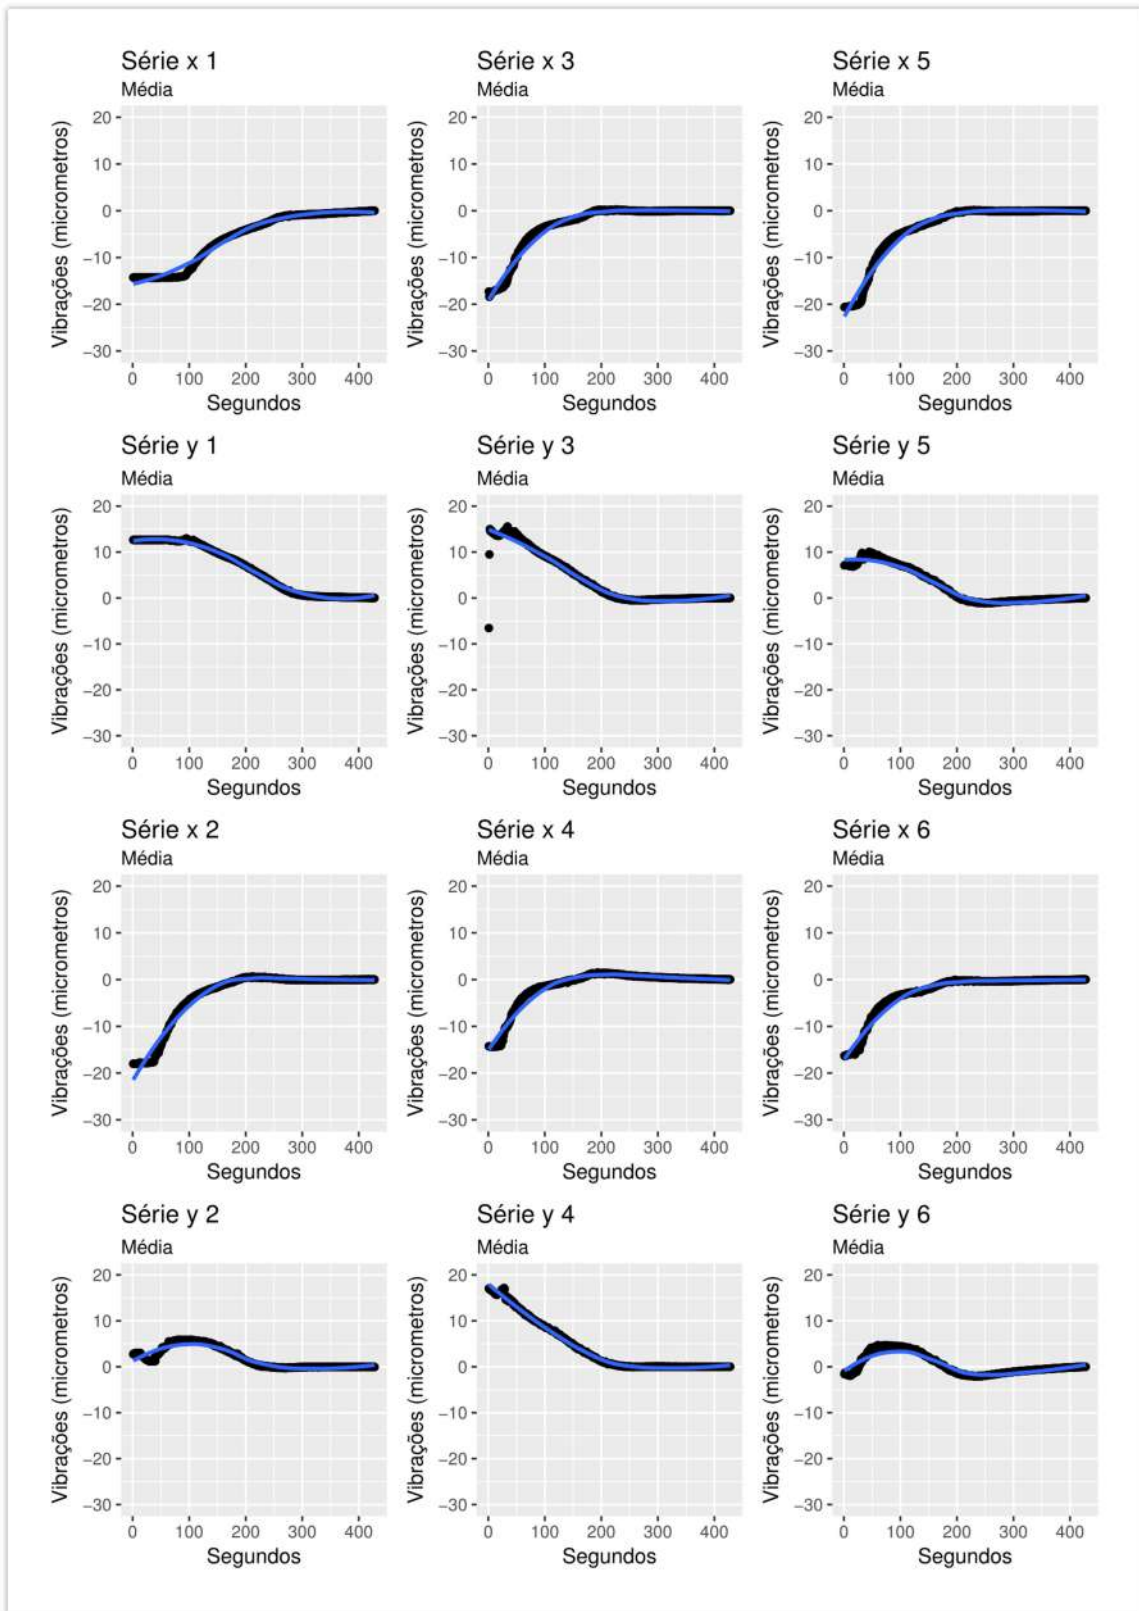
Anexo II - Figura 2: As séries vibracionais originais parte 2



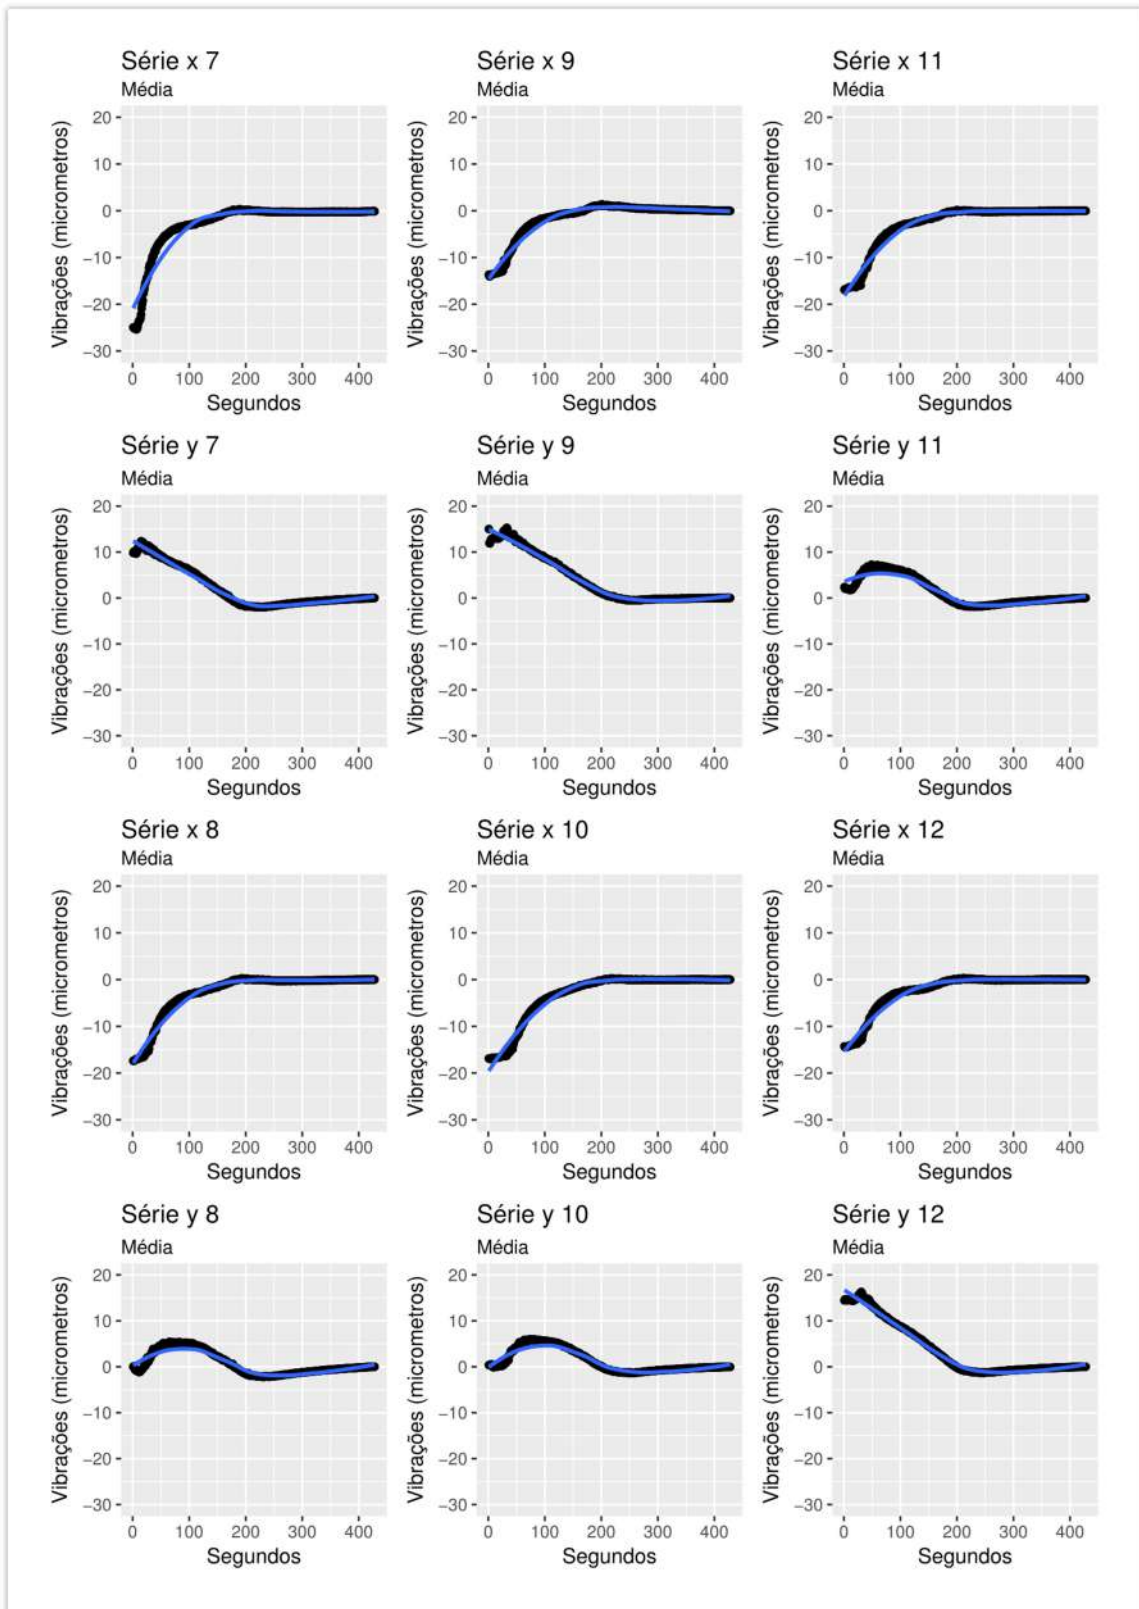
Anexo II - Figura 3: As séries vibracionais originais sem componente contínua parte 1



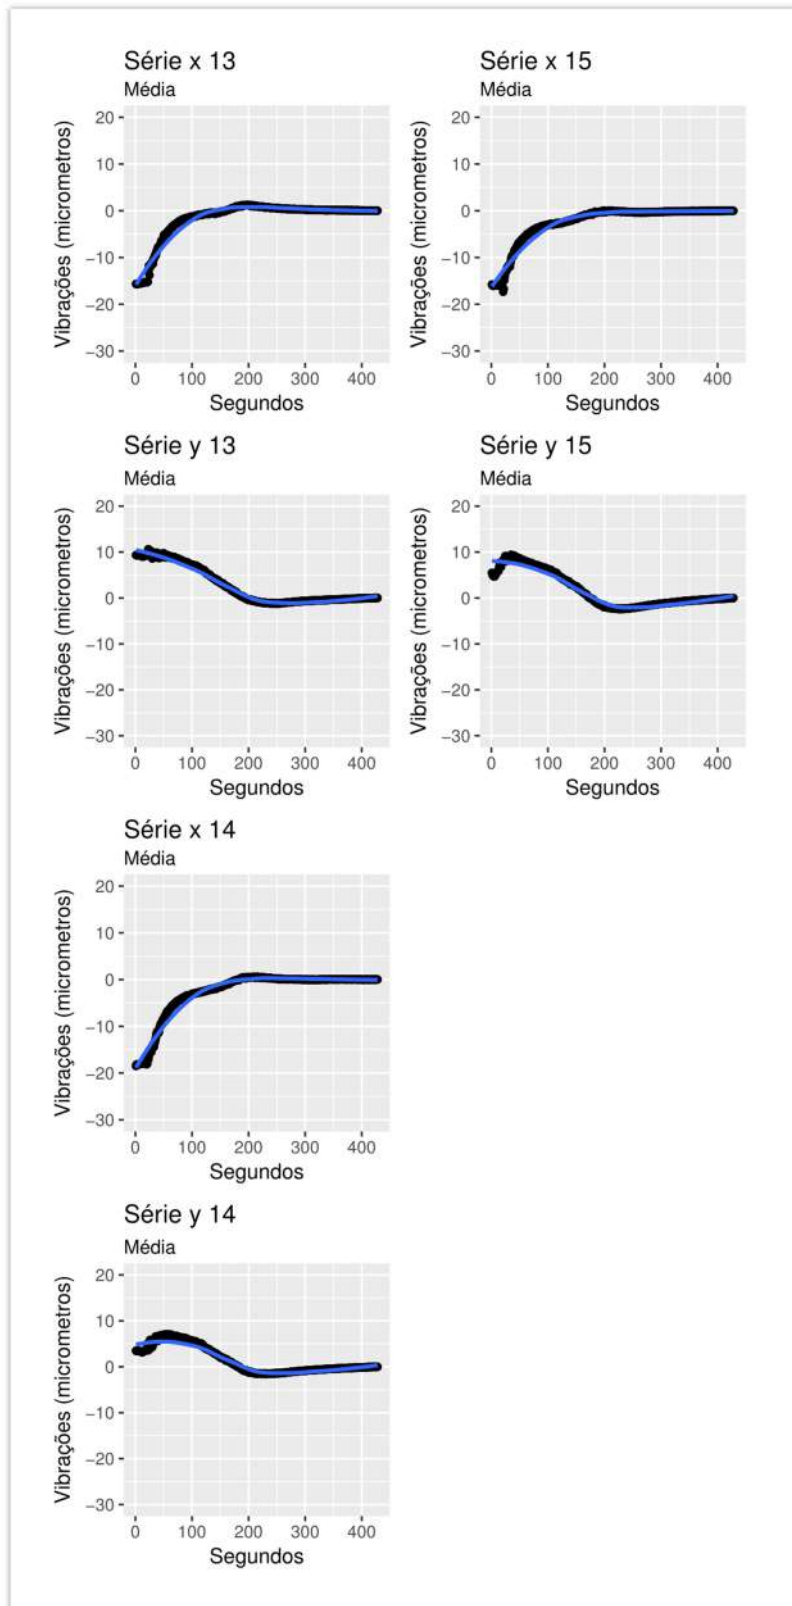
Anexo II - Figura 4: As séries vibracionais originais sem componente contínua parte 2



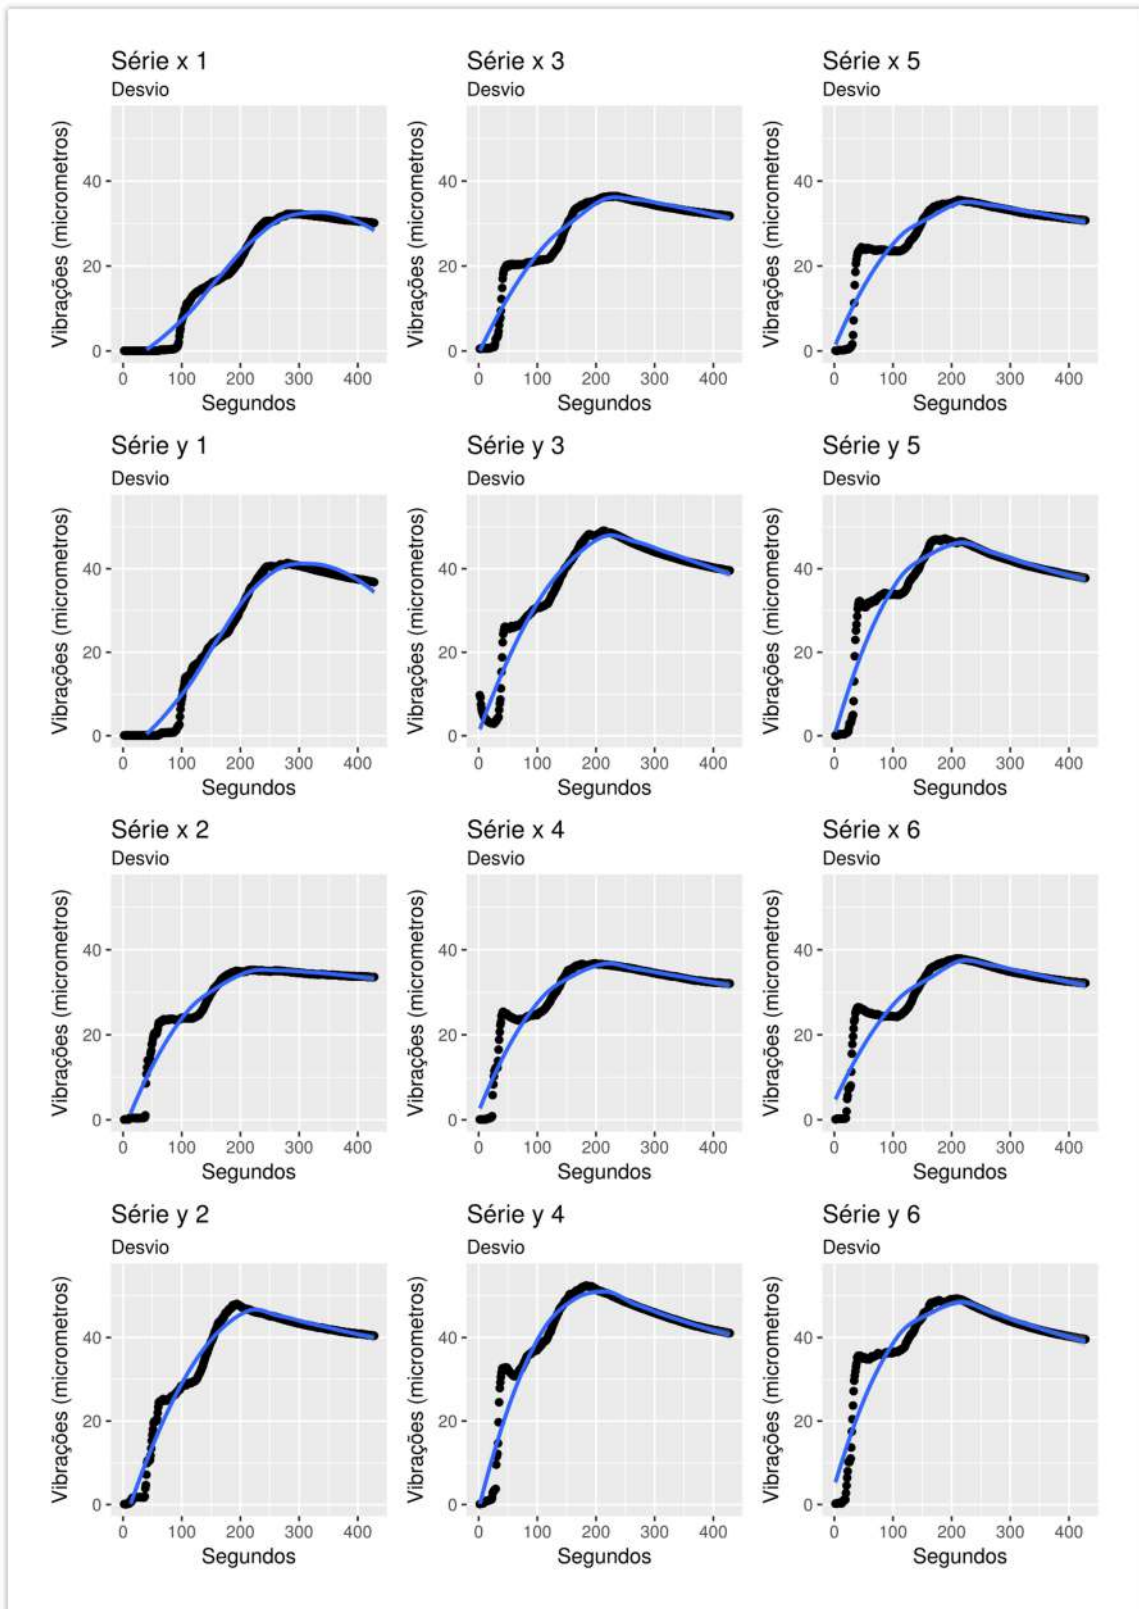
Anexo II - Figura 5: Comportamento da média parte 1



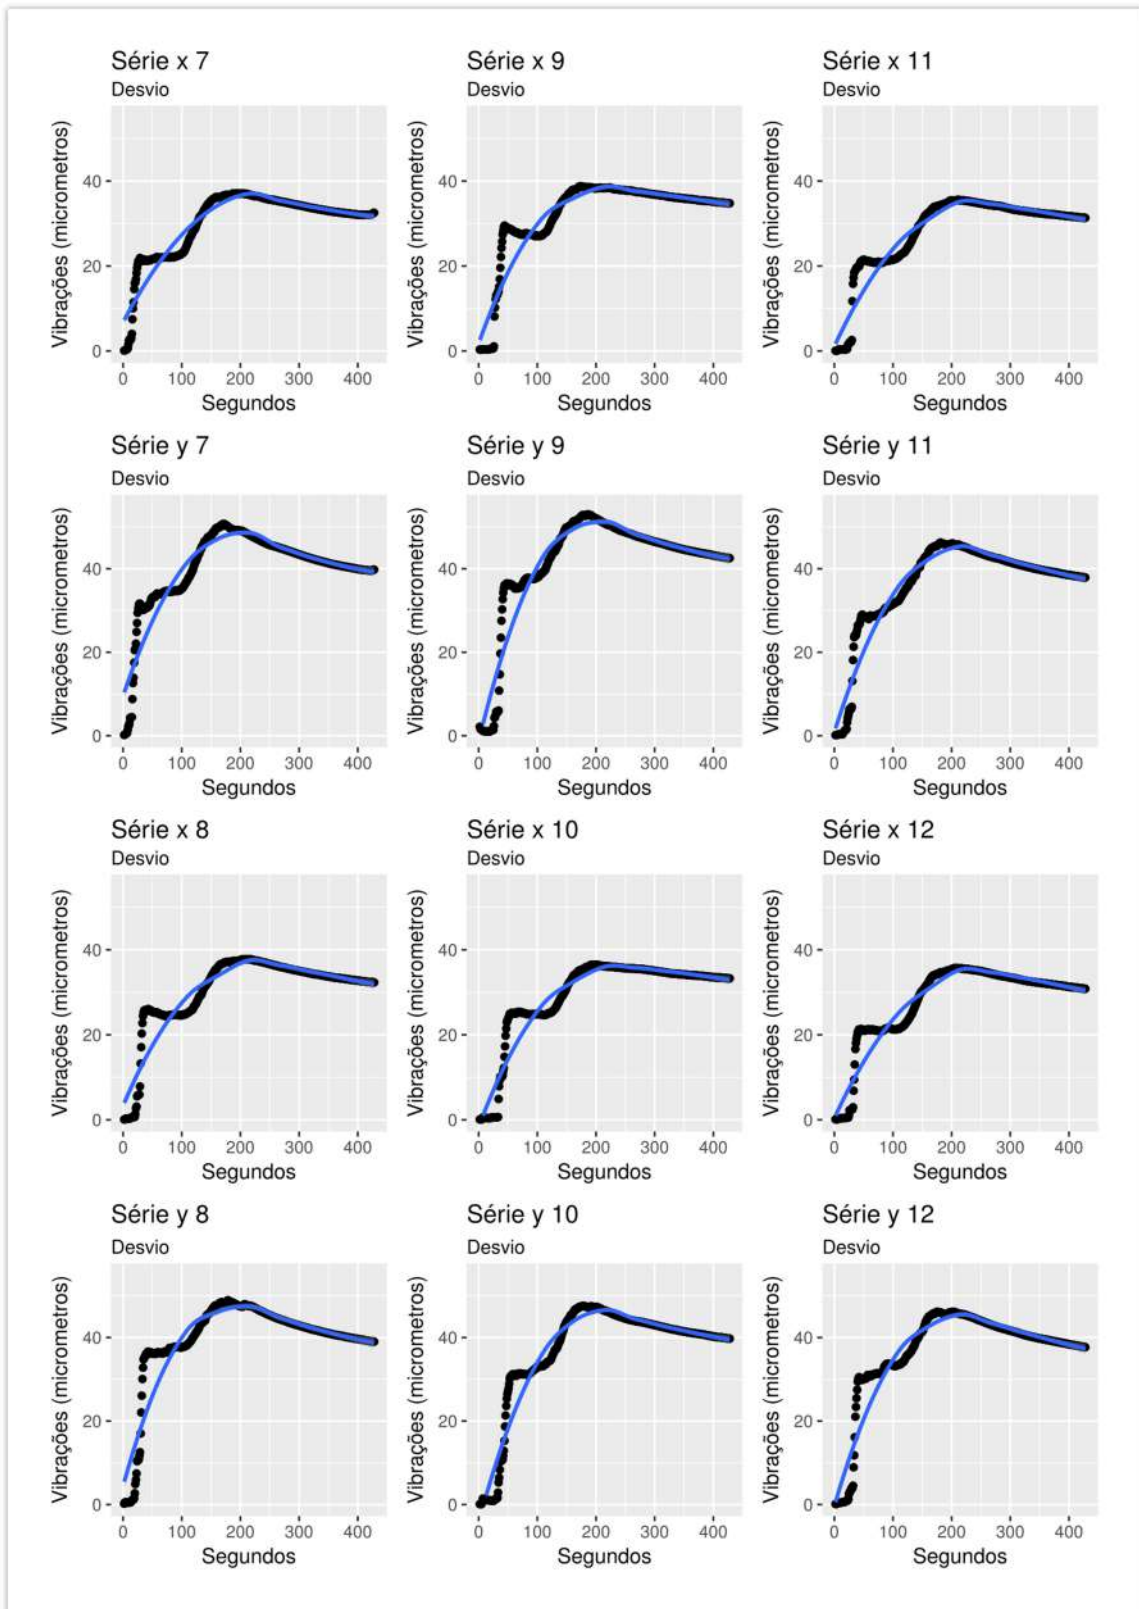
Anexo II - Figura 6: Comportamento da média parte 2



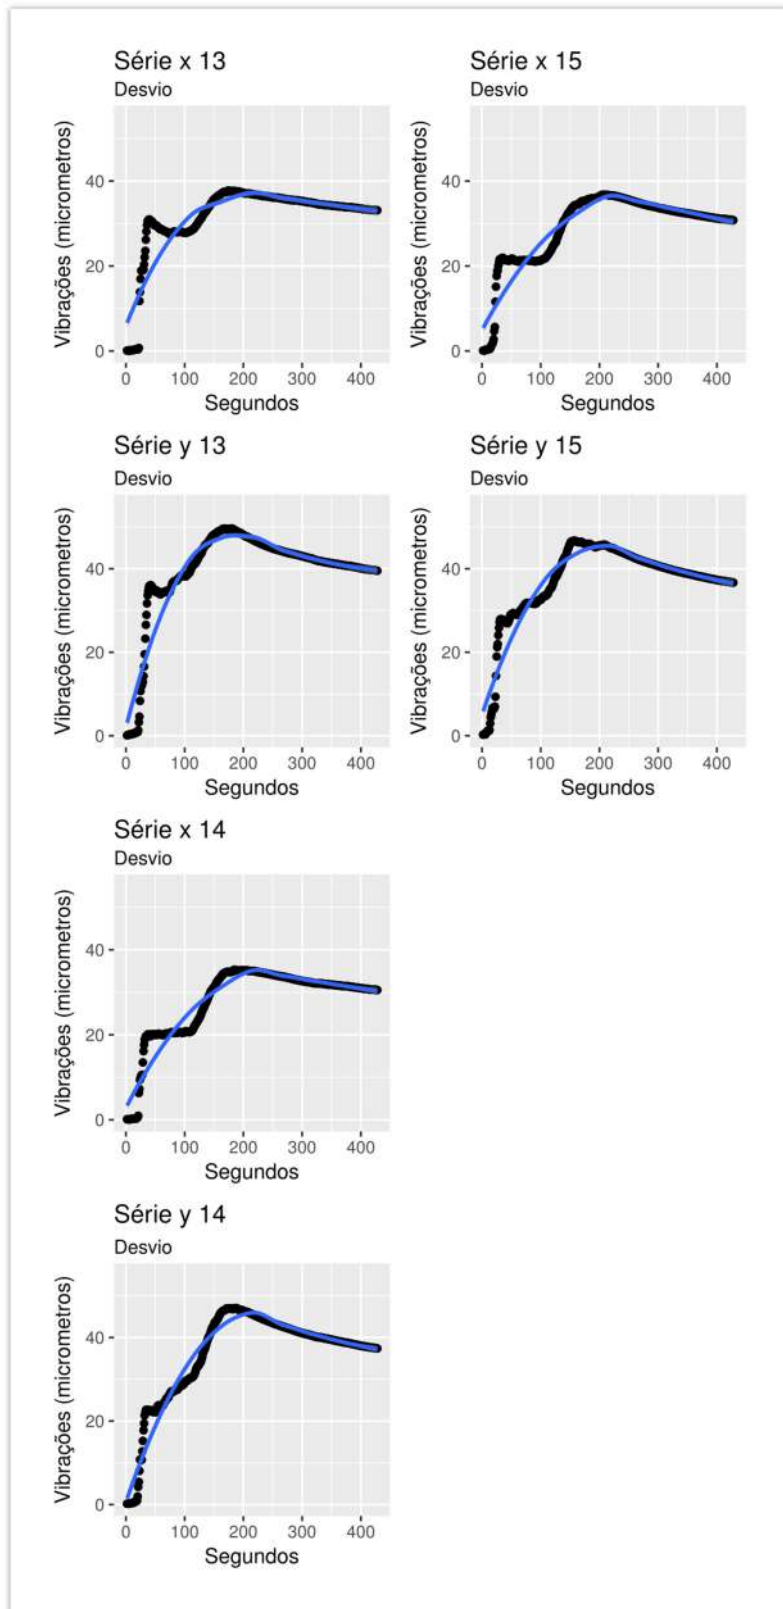
Anexo II - Figura 7: Comportamento da média parte 3



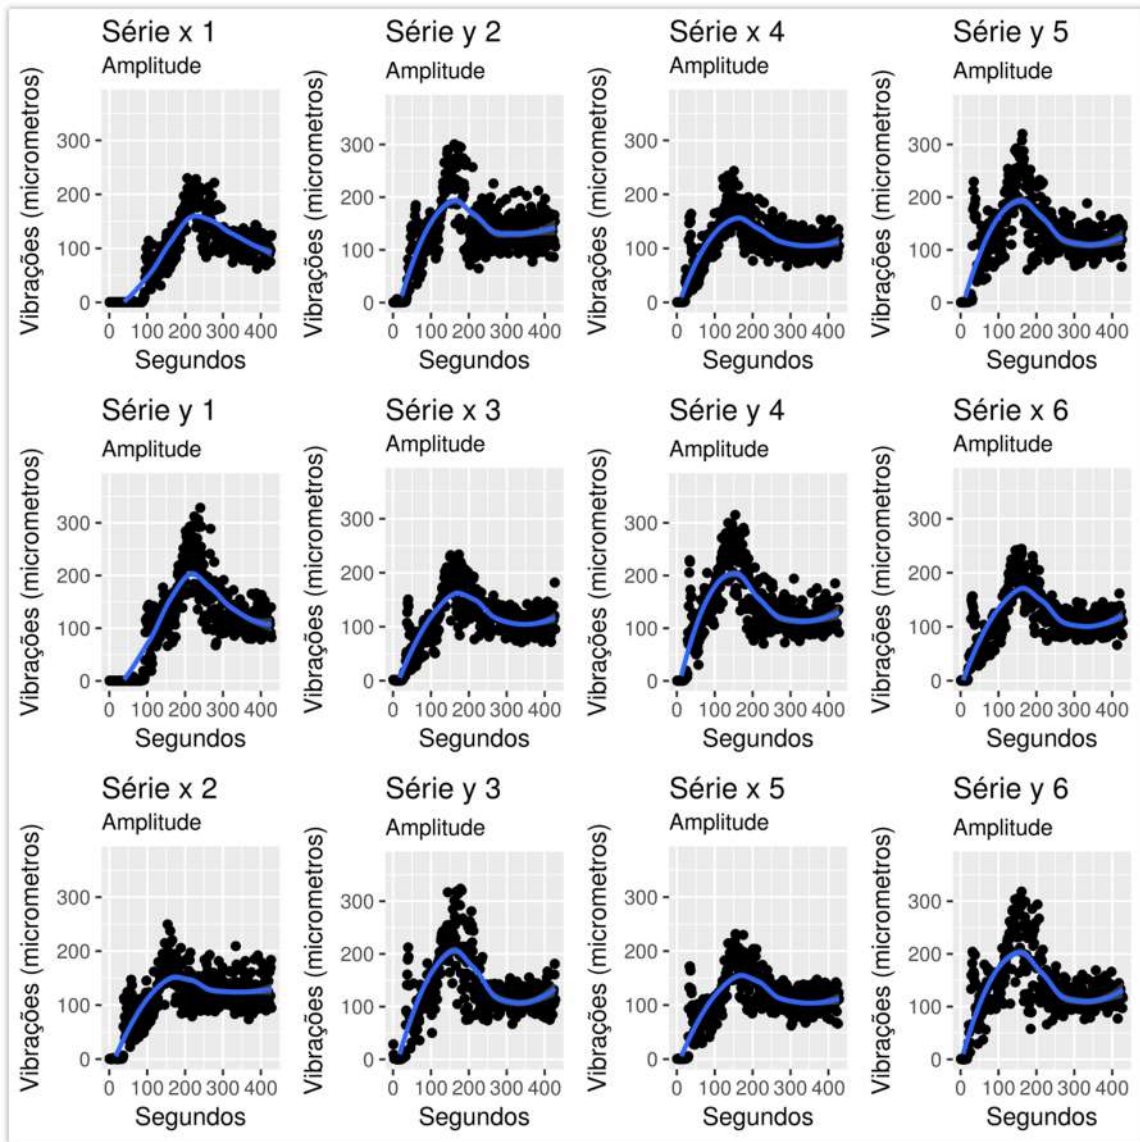
Anexo II - Figura 8: Comportamento do desvio-padrão parte 1



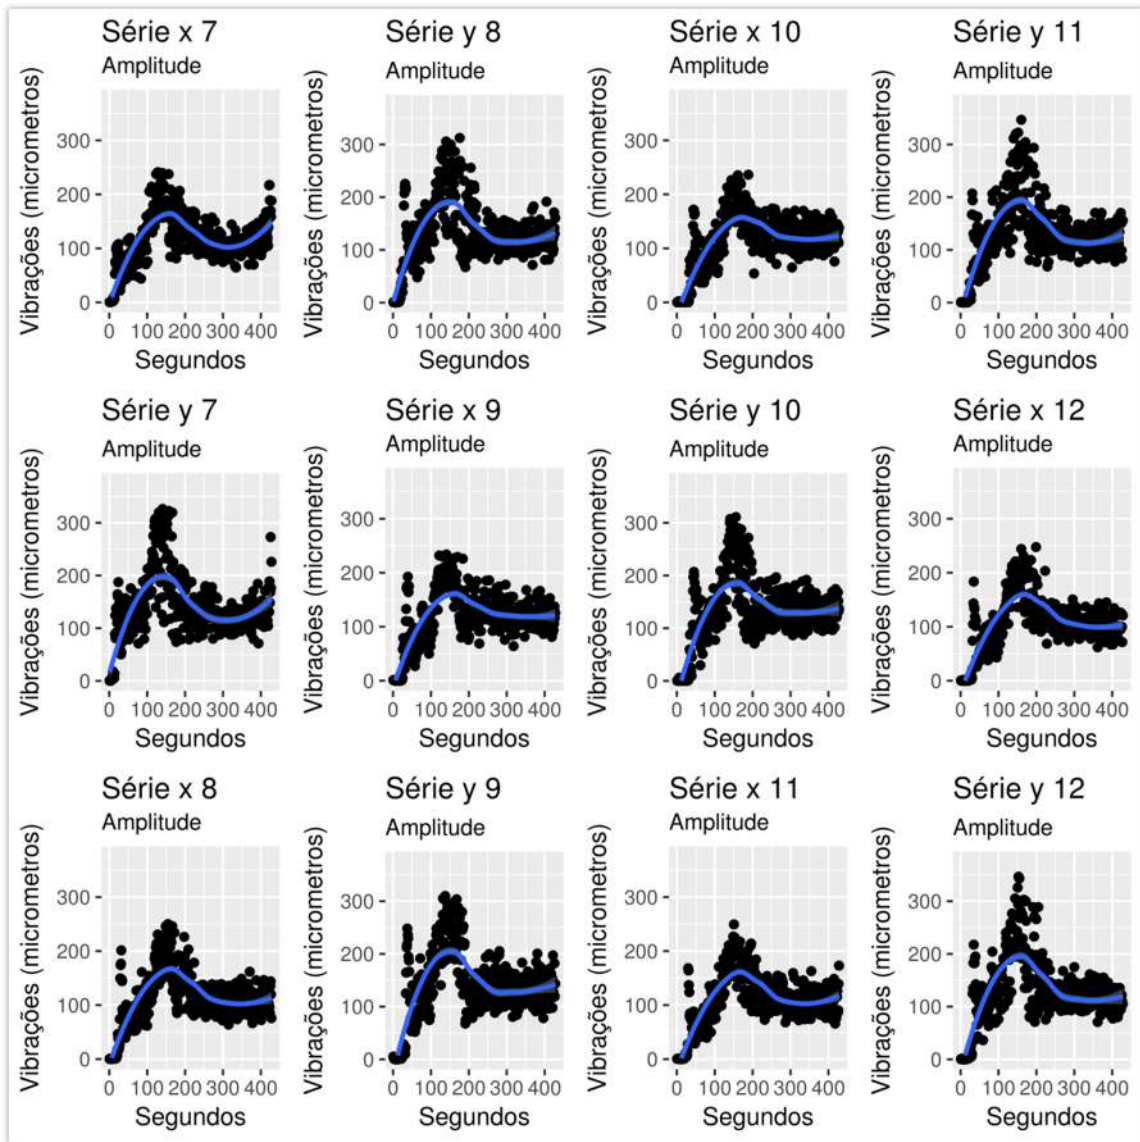
Anexo II - Figura 9: Comportamento do desvio-padrão parte 2



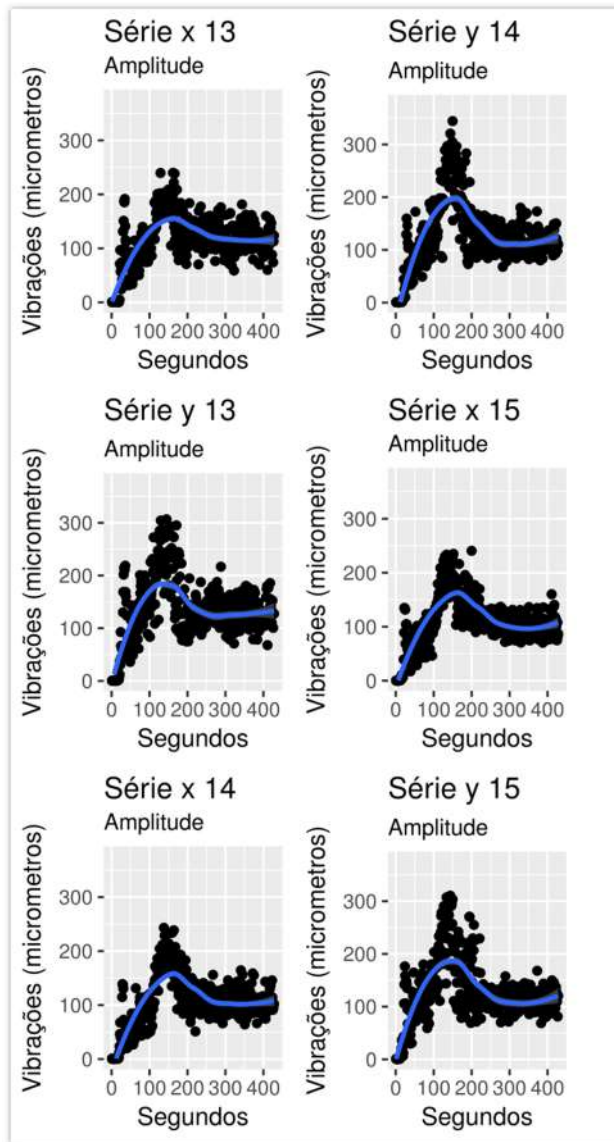
Anexo II - Figura 10: Comportamento do desvio-padrão parte 3



Anexo II - Figura 11: Comportamento da amplitude parte 1

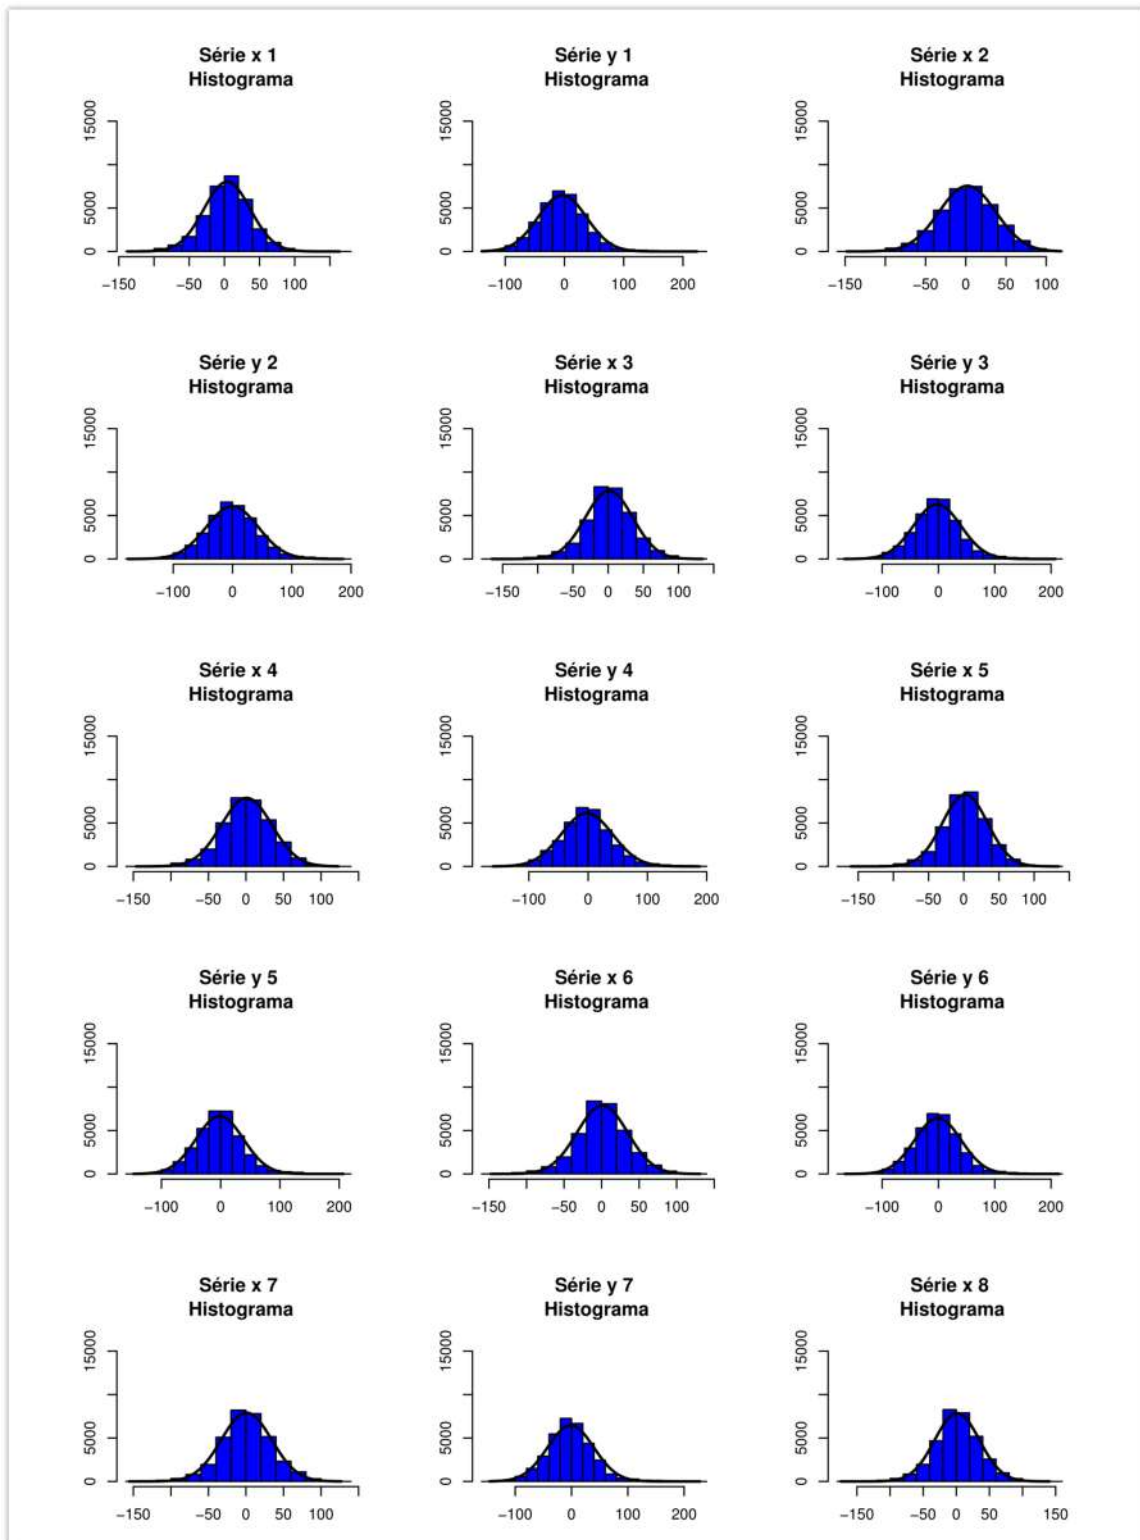


Anexo II - Figura 12: Comportamento da amplitude parte 2

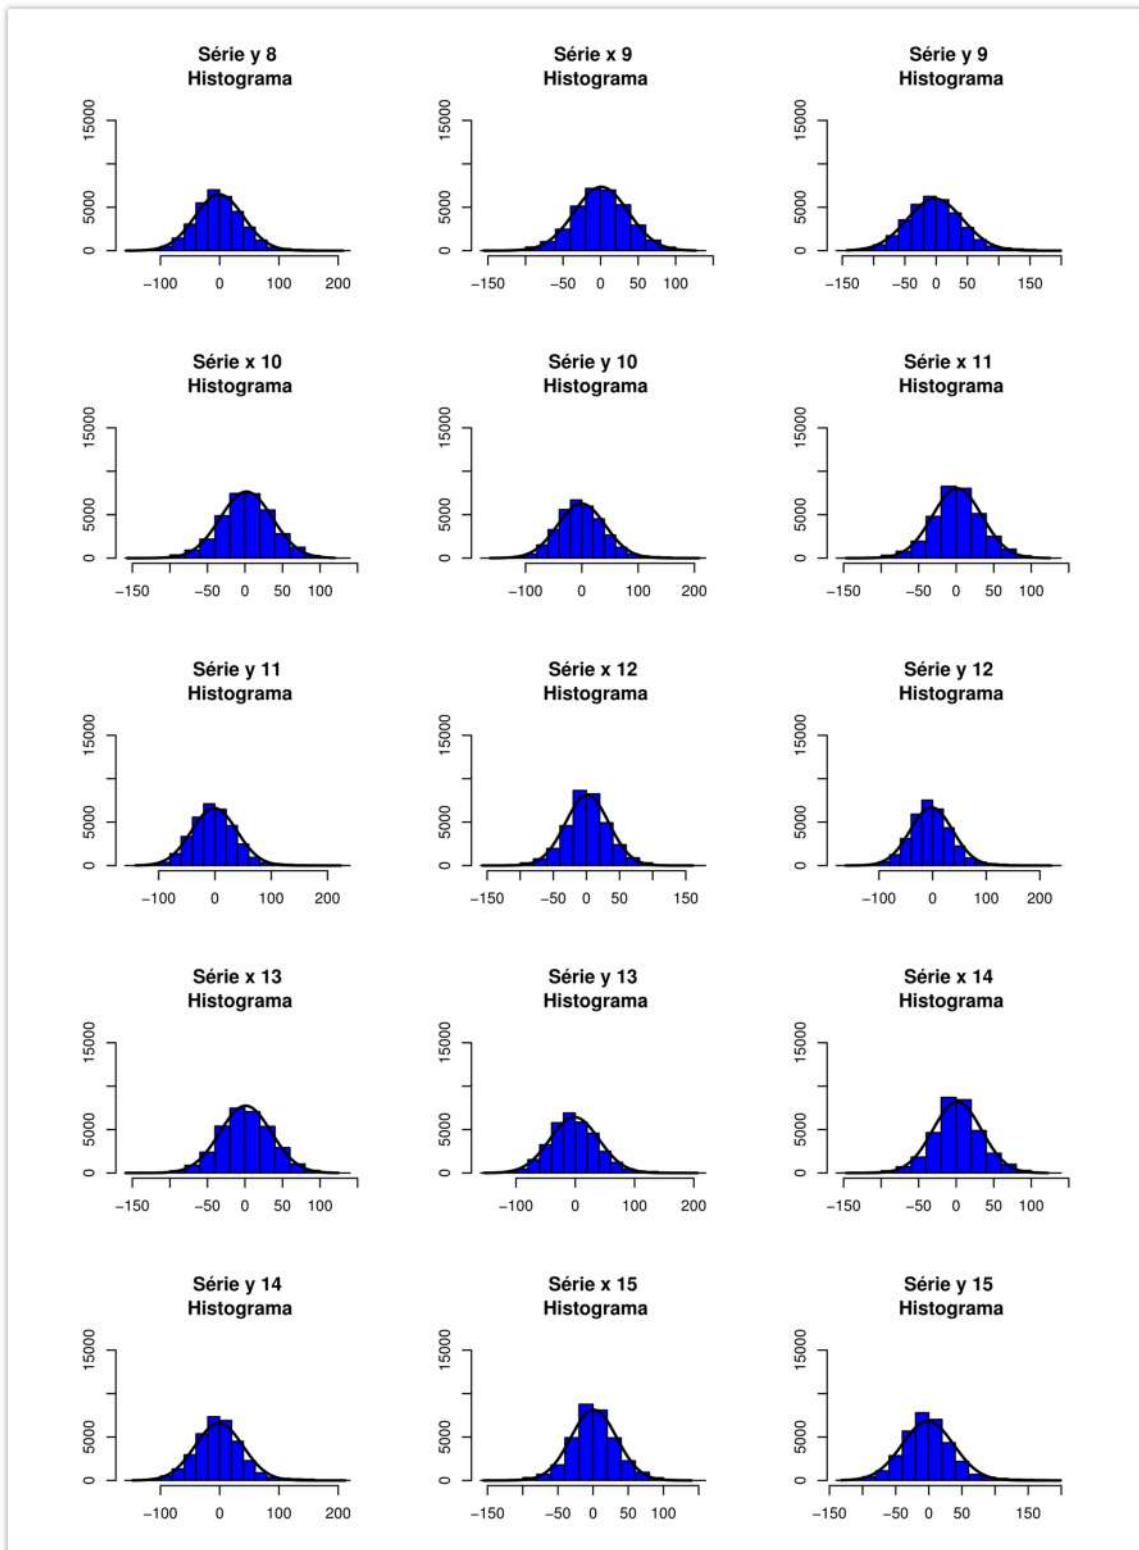


Anexo II - Figura 13: Comportamento da amplitude parte 3

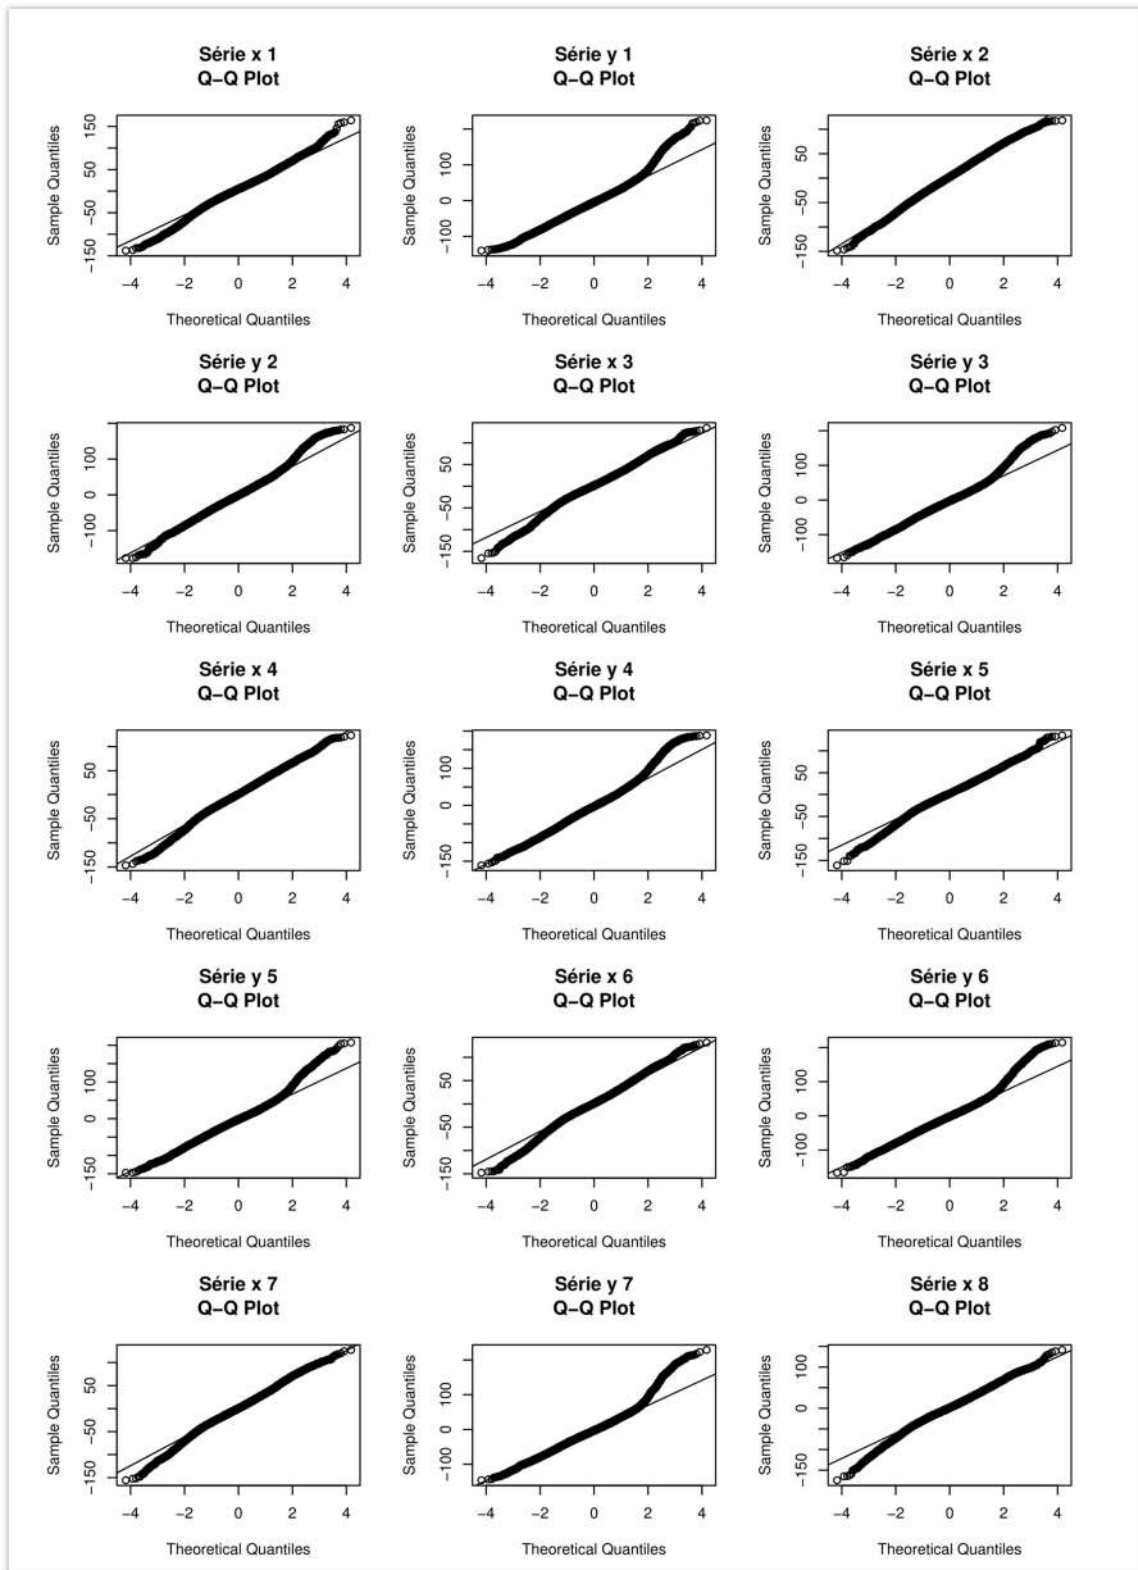
ANEXO III – ANÁLISE DESCRITIVA DAS SÉRIES ORIGINAIS



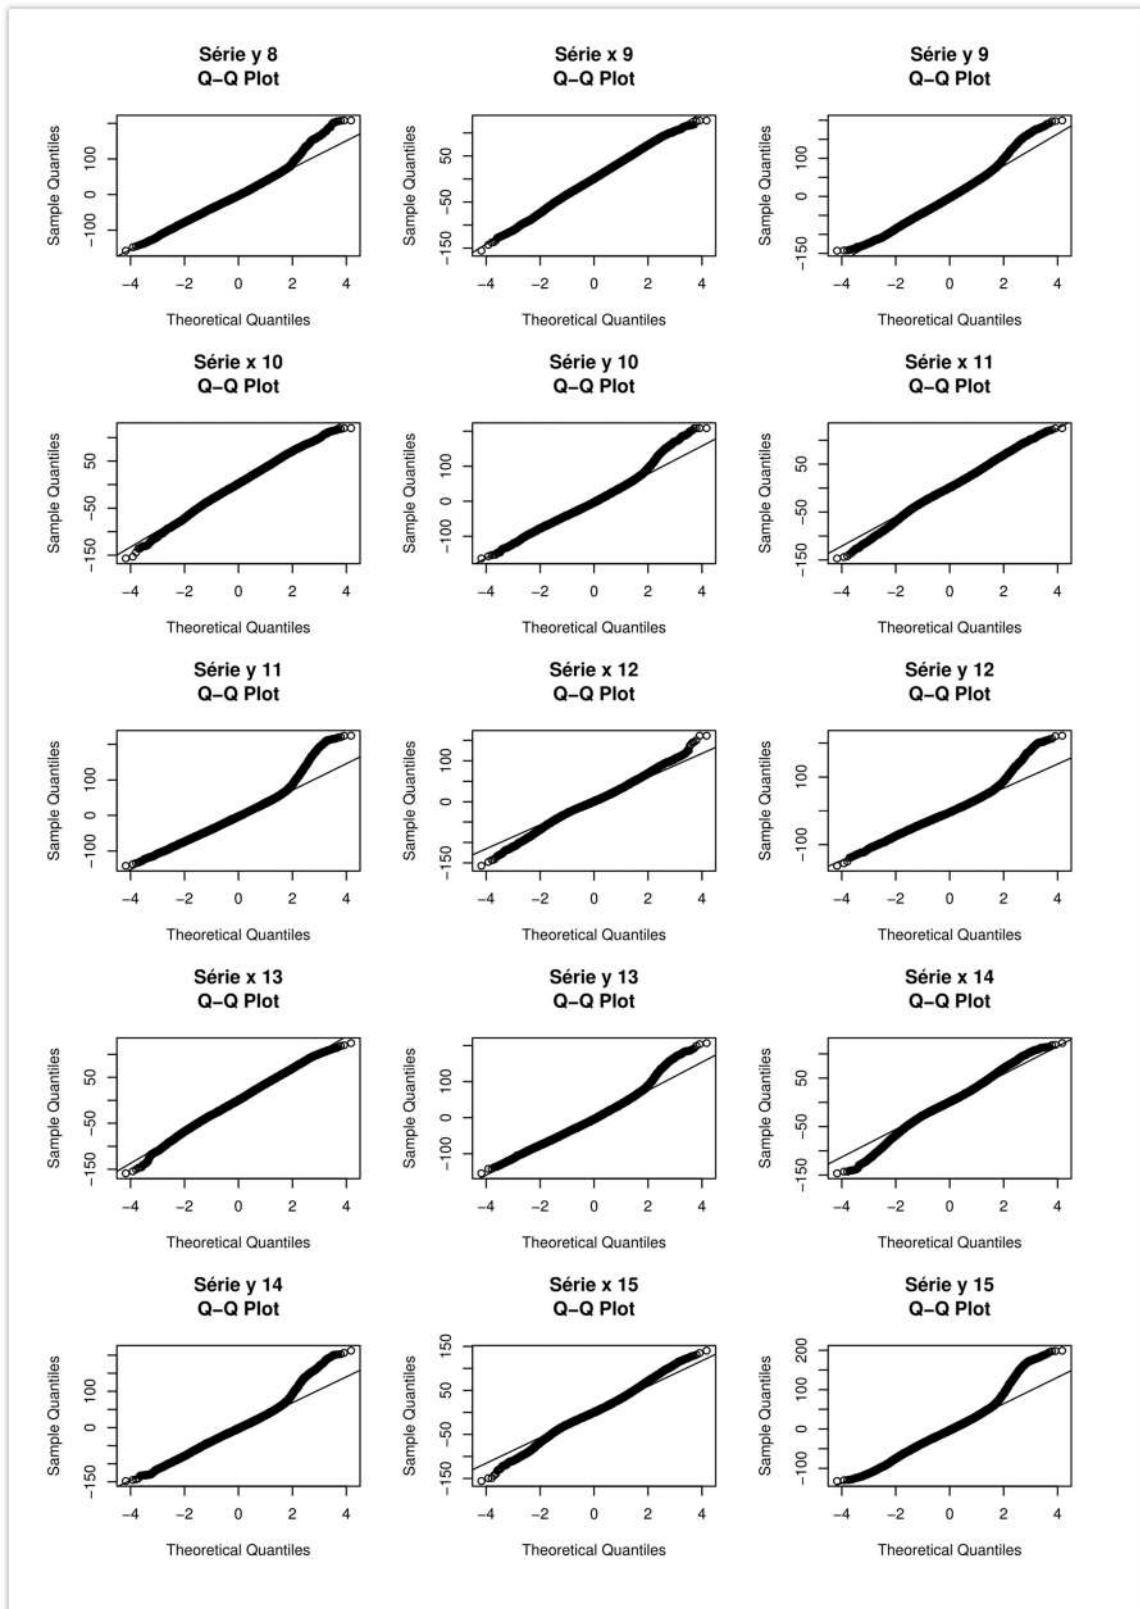
Anexo III - Figura 1: Histograma das séries originais parte 1



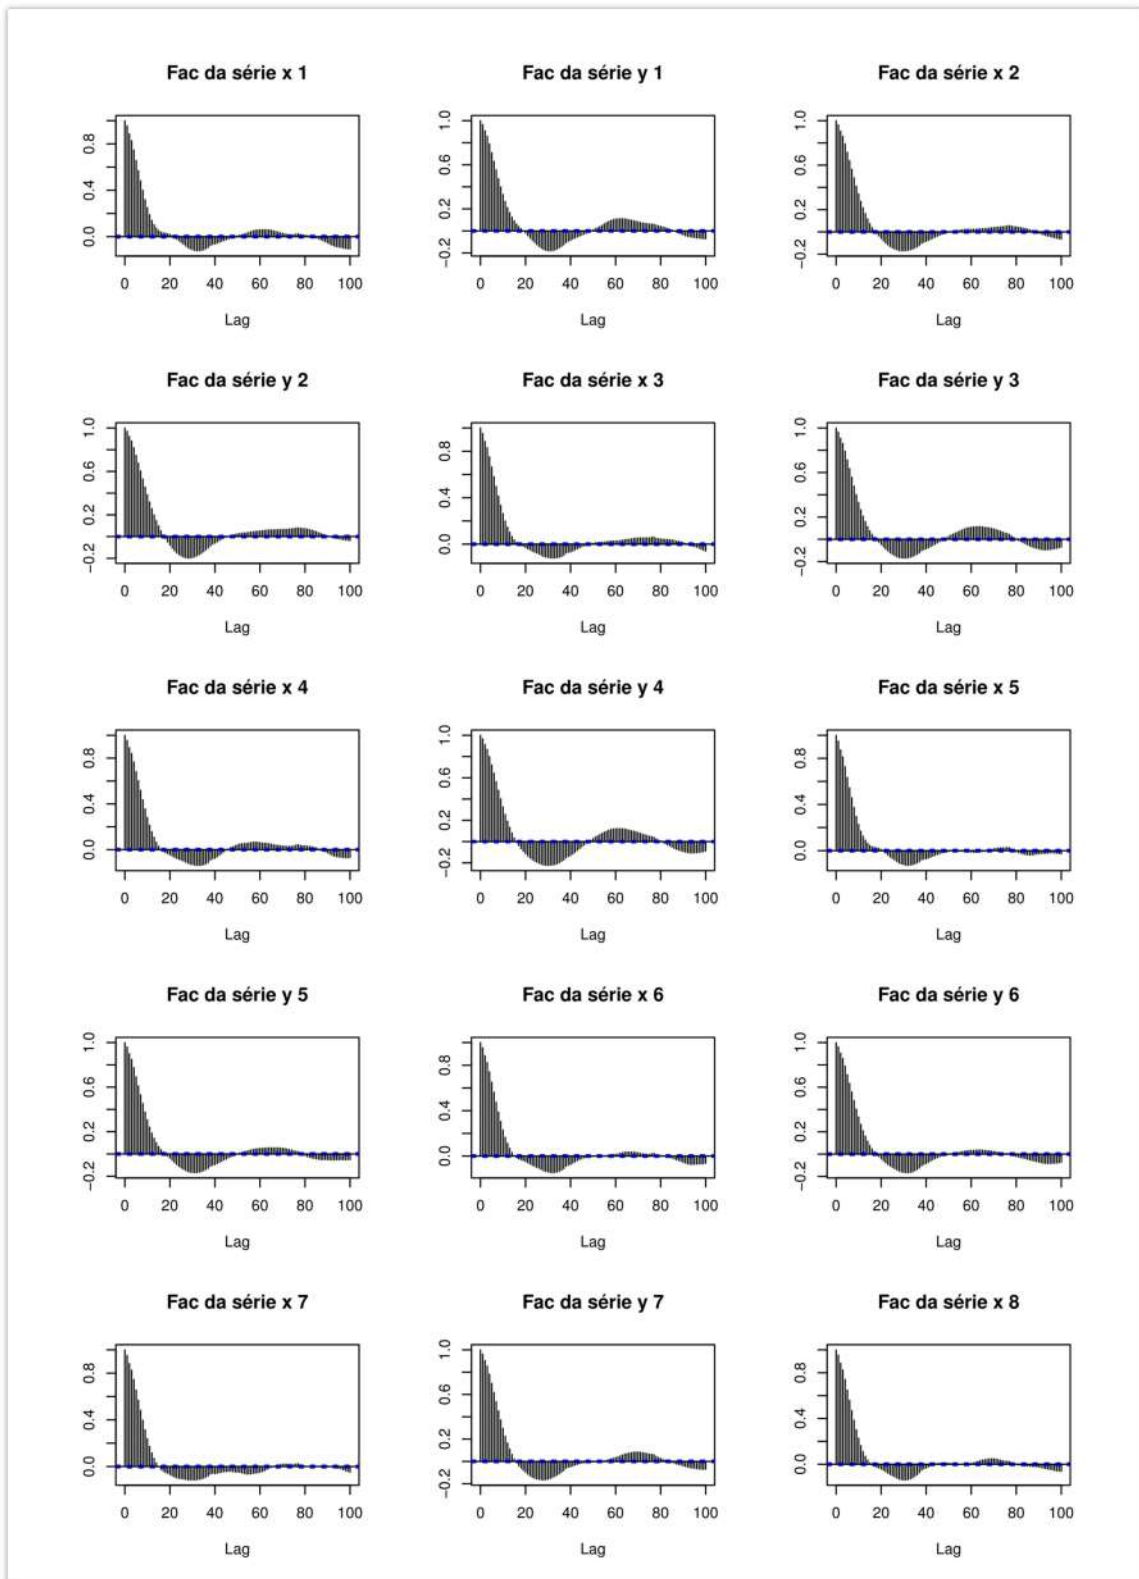
Anexo III - Figura 2: Histograma das séries originais parte 2



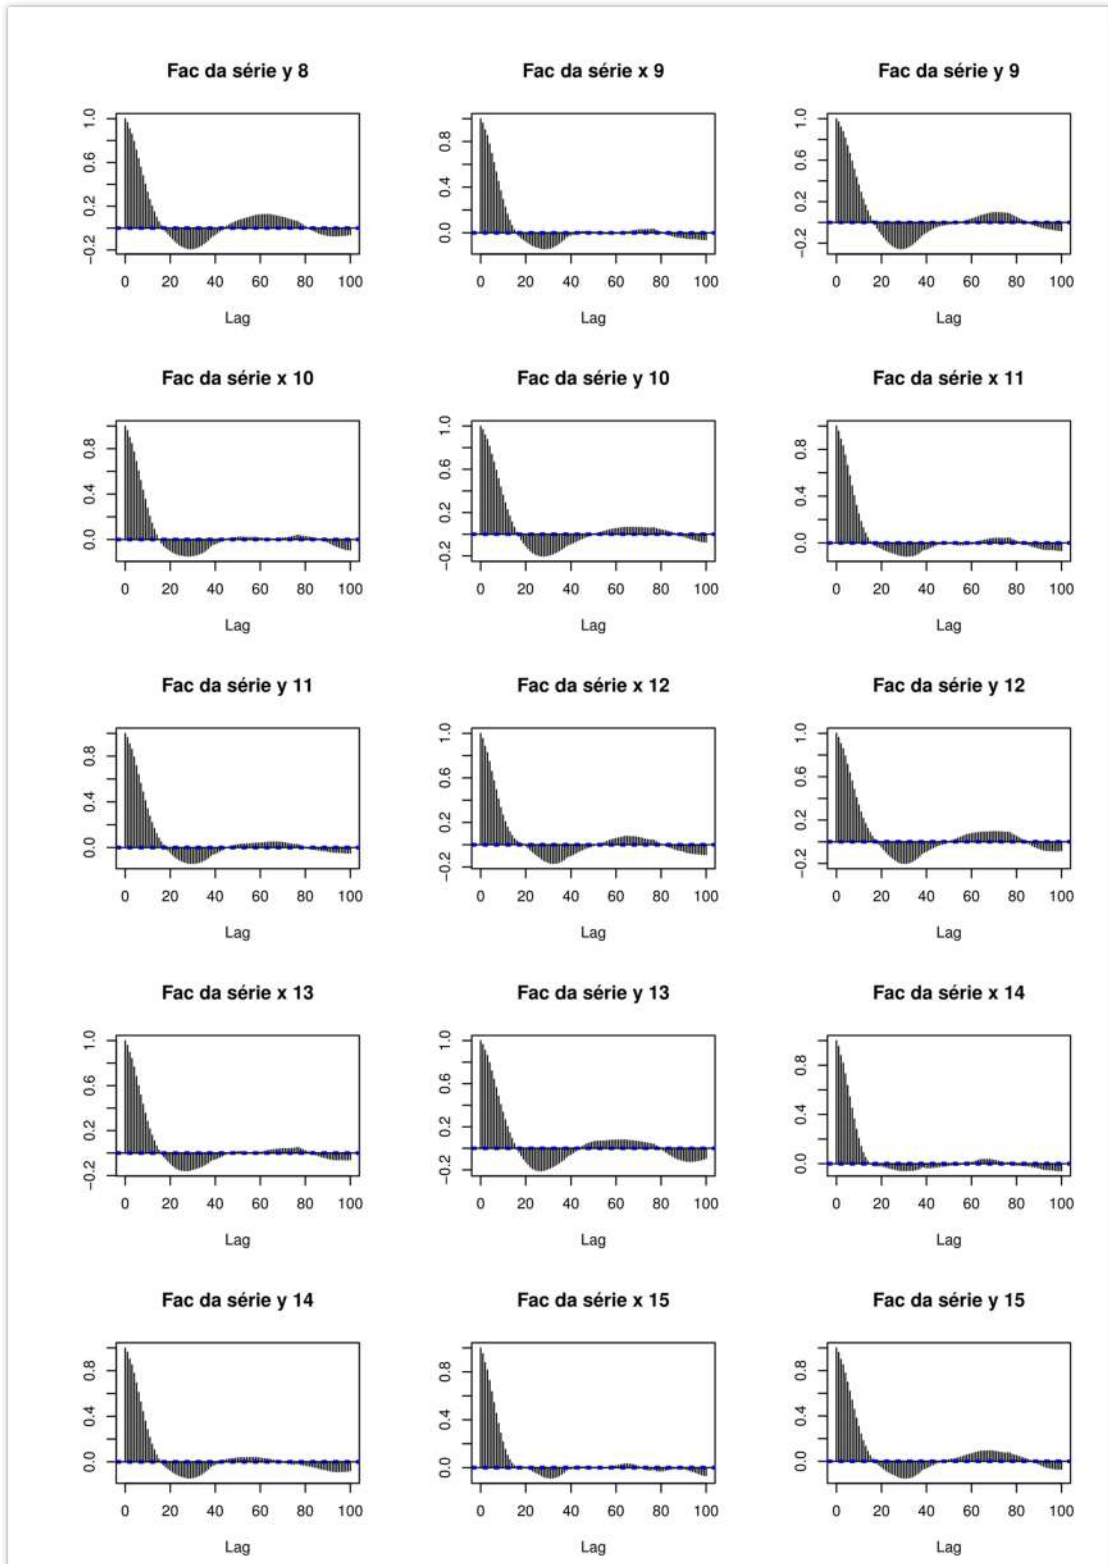
Anexo III - Figura 3: Gráfico quantil-quantil das séries originais parte 1



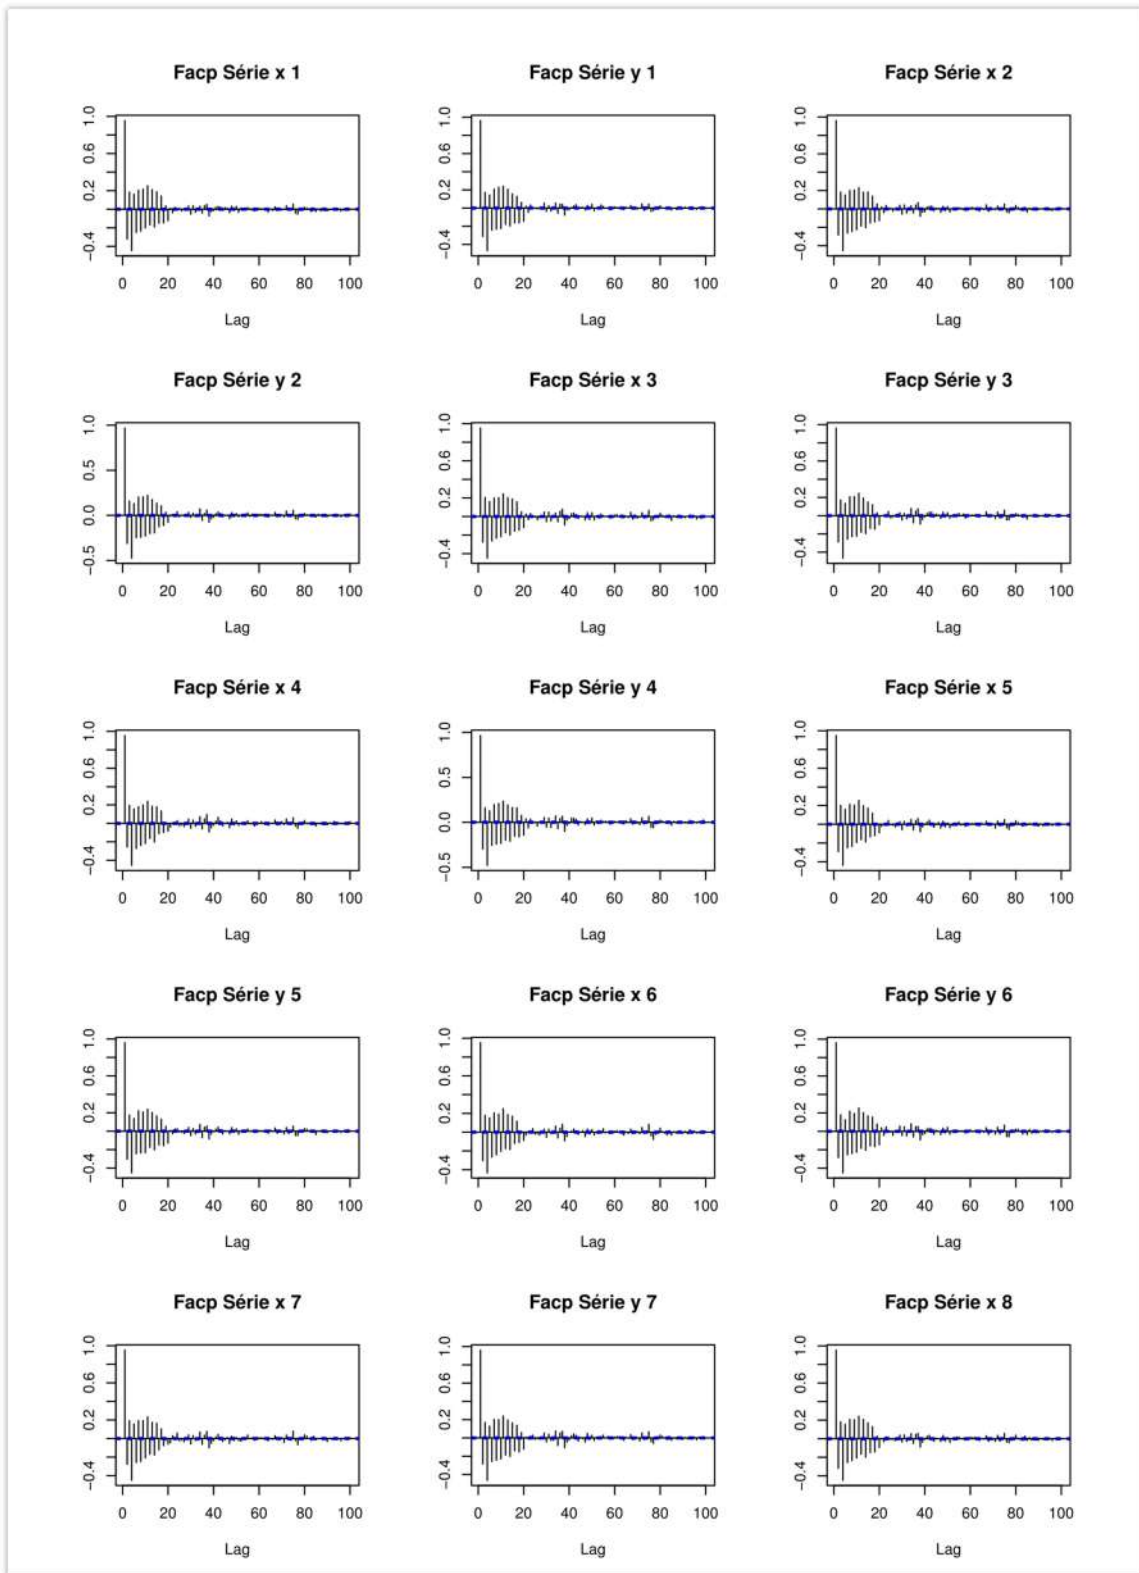
Anexo III - Figura 4: Gráfico quantil-quantil das séries originais parte 2



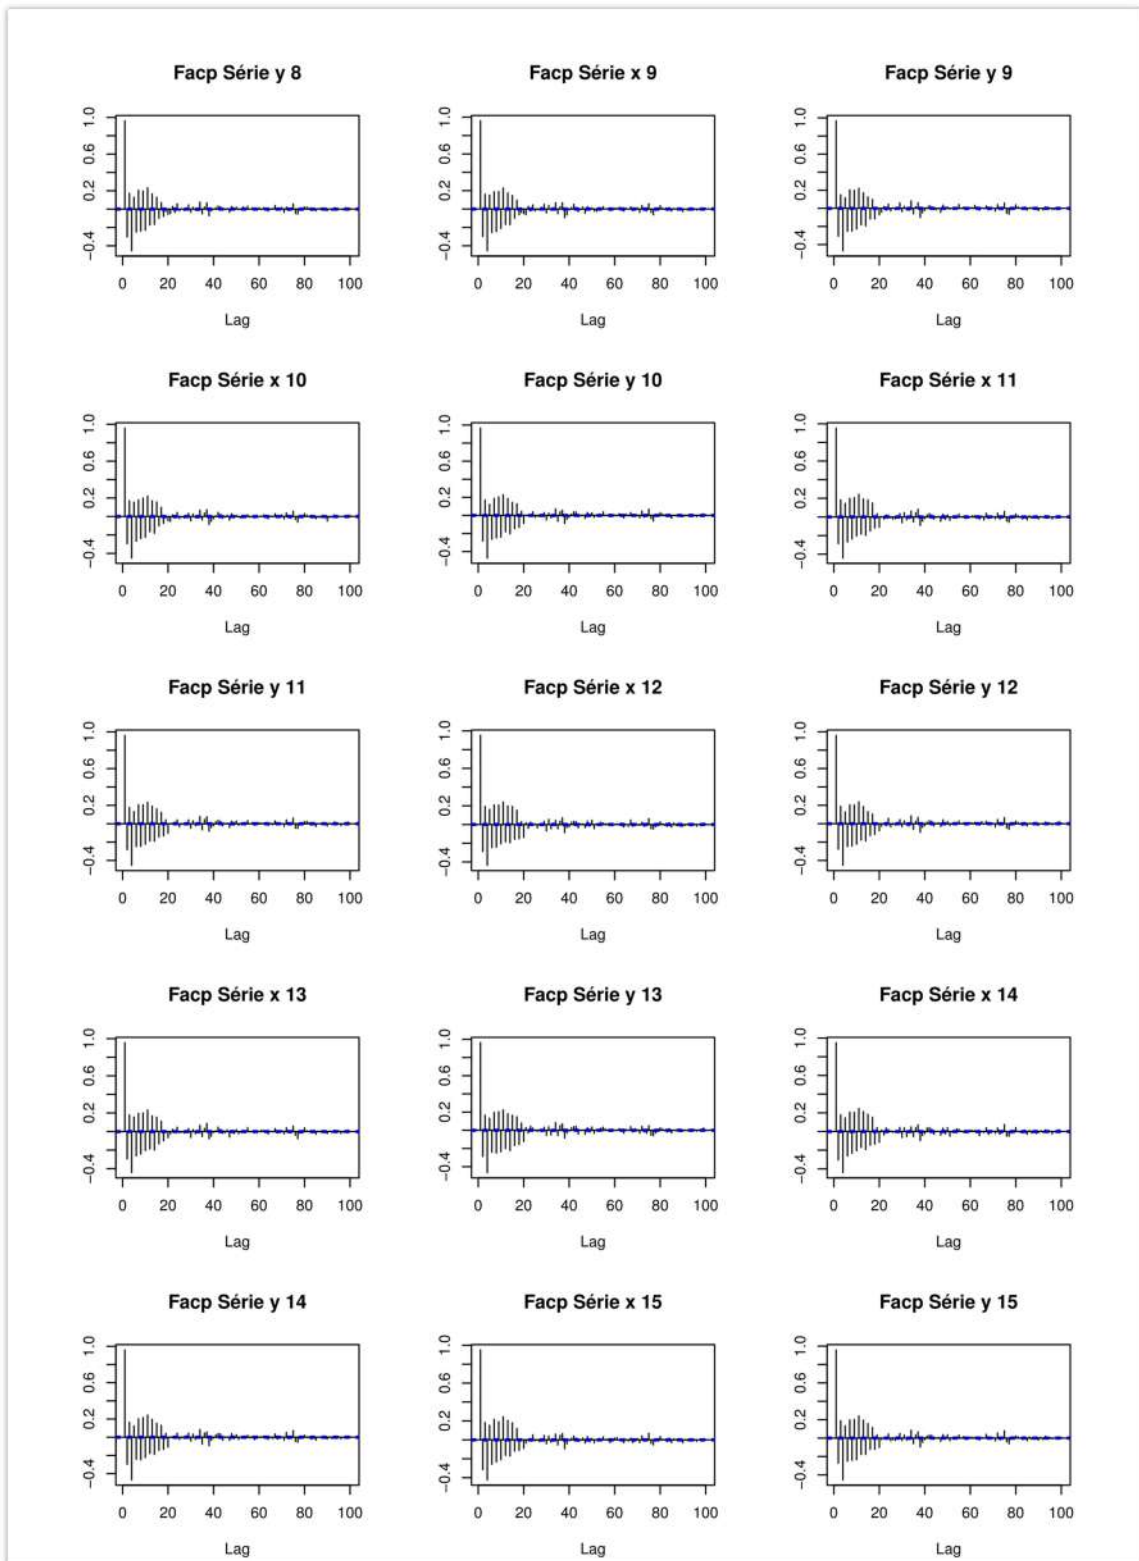
Anexo III - Figura 5: FAC das séries originais parte 1



Anexo III - Figura 6: FAC das séries originais parte 2



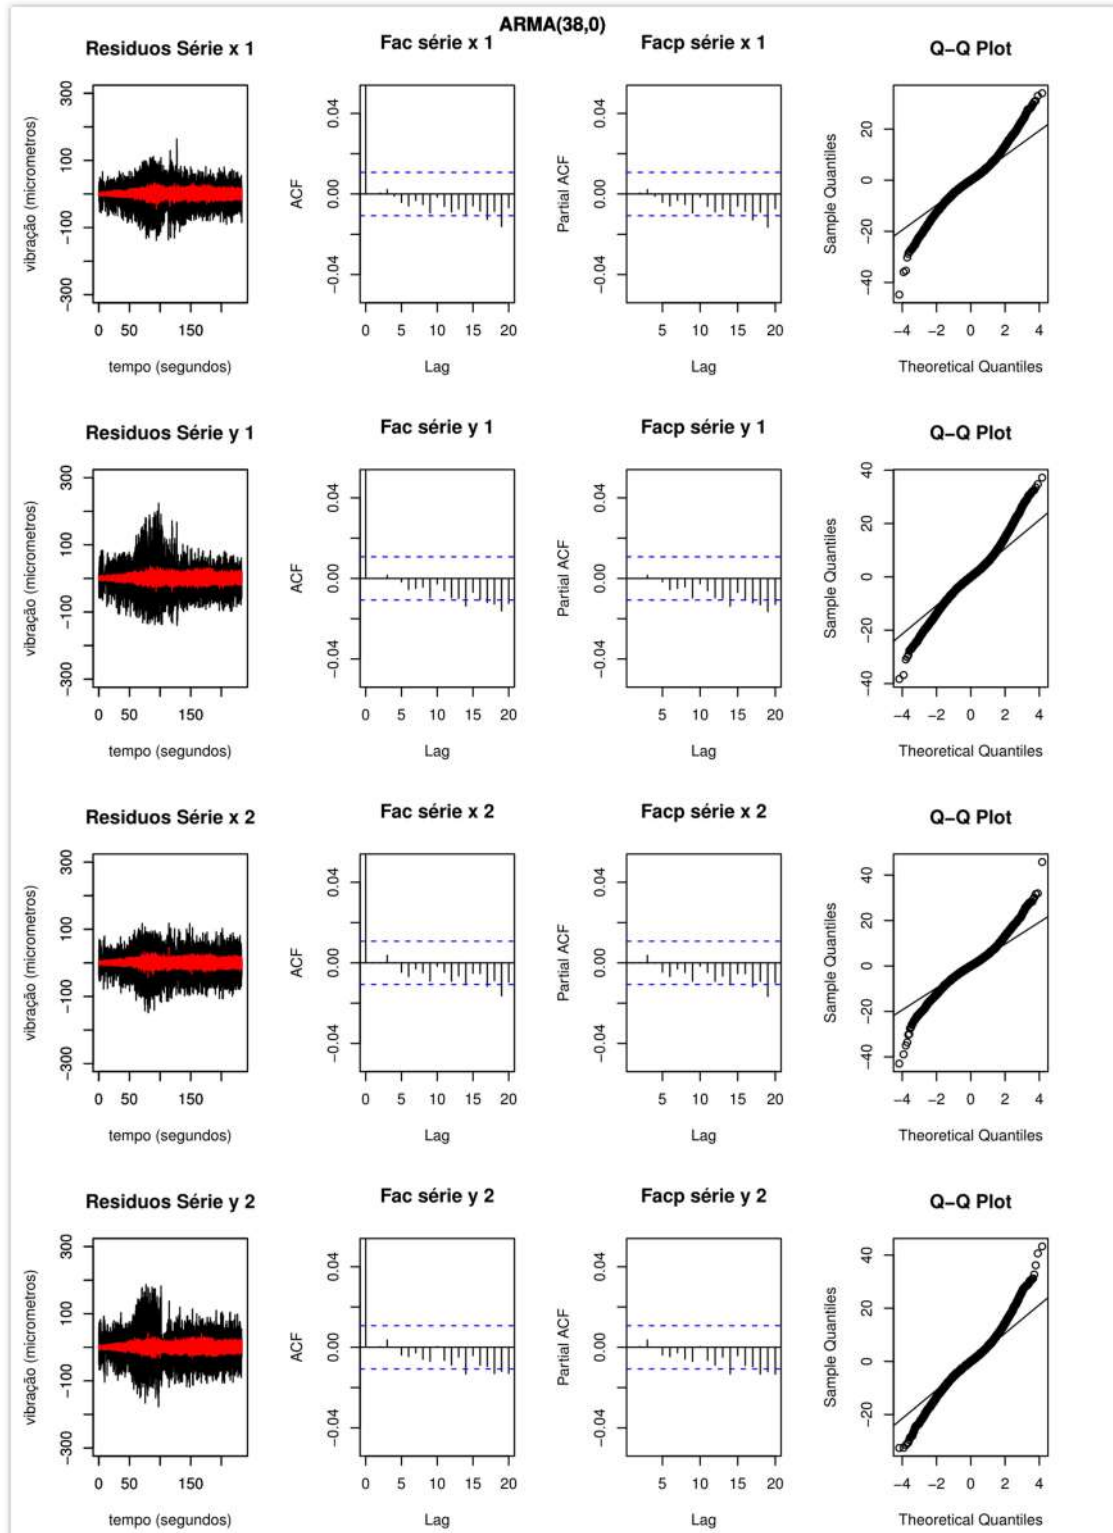
Anexo III - Figura 7: FACP das séries originais parte 1



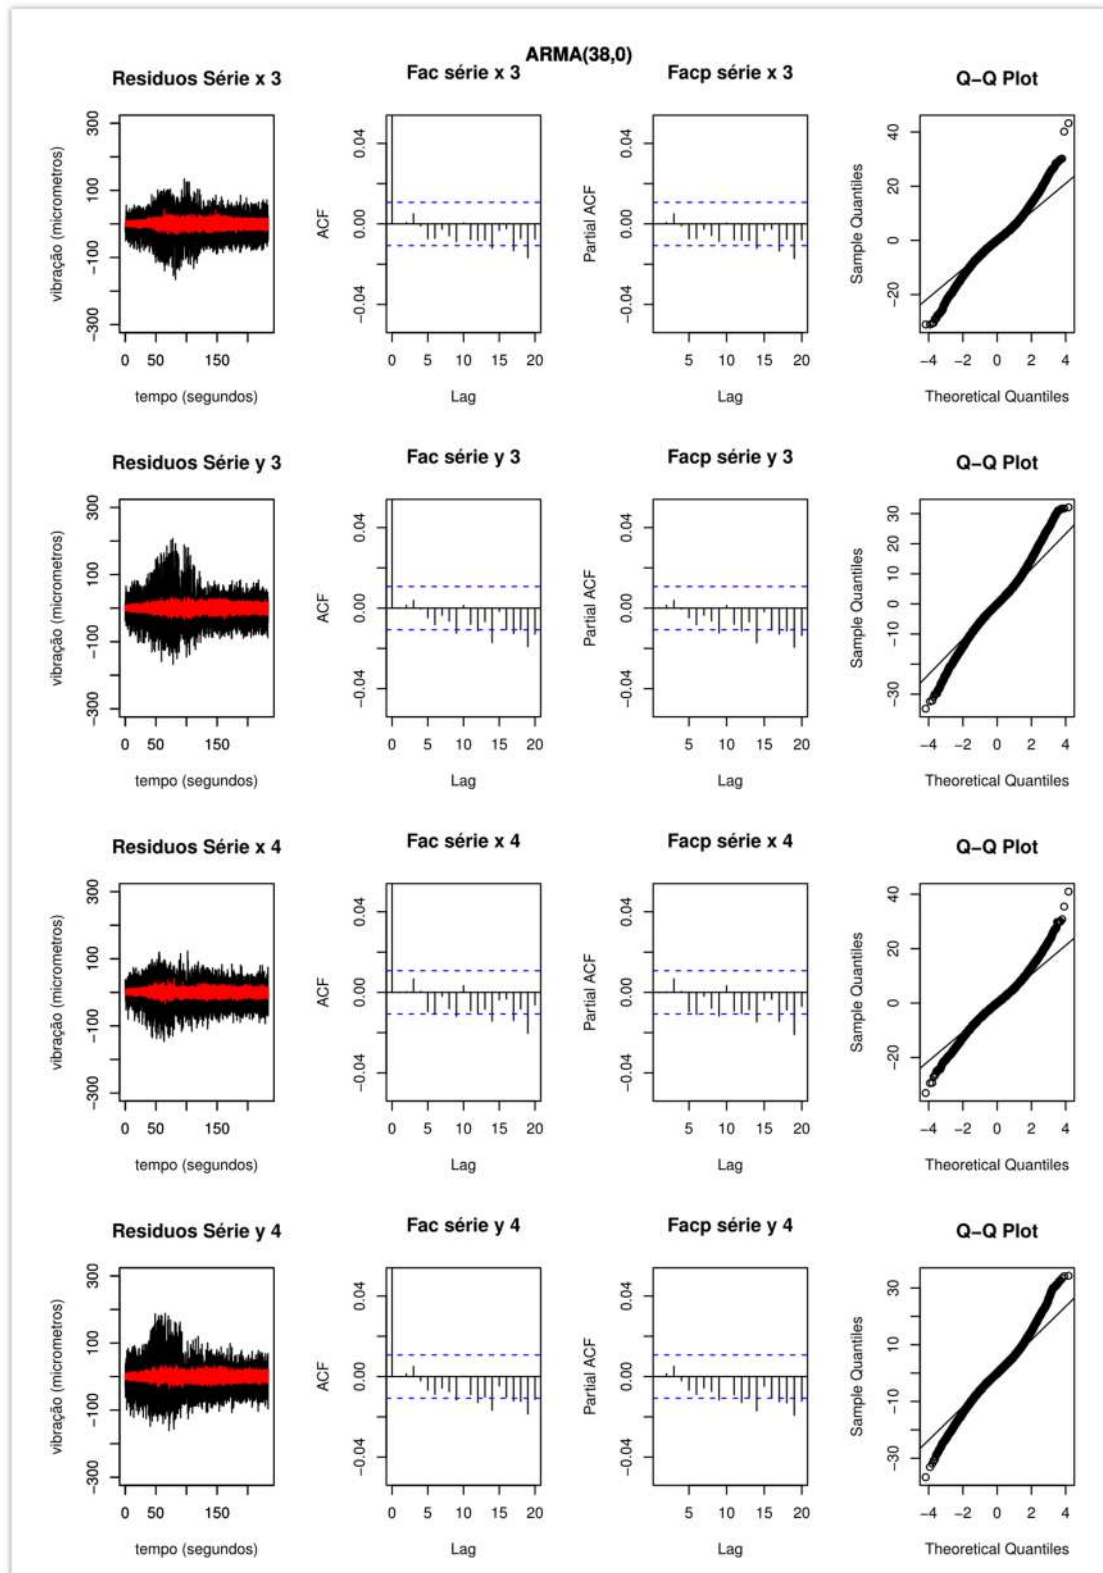
Anexo III - Figura 8: FACP das séries originais parte 2

ANEXO IV – MODELOS APLICADOS NAS SÉRIES ORIGINALS

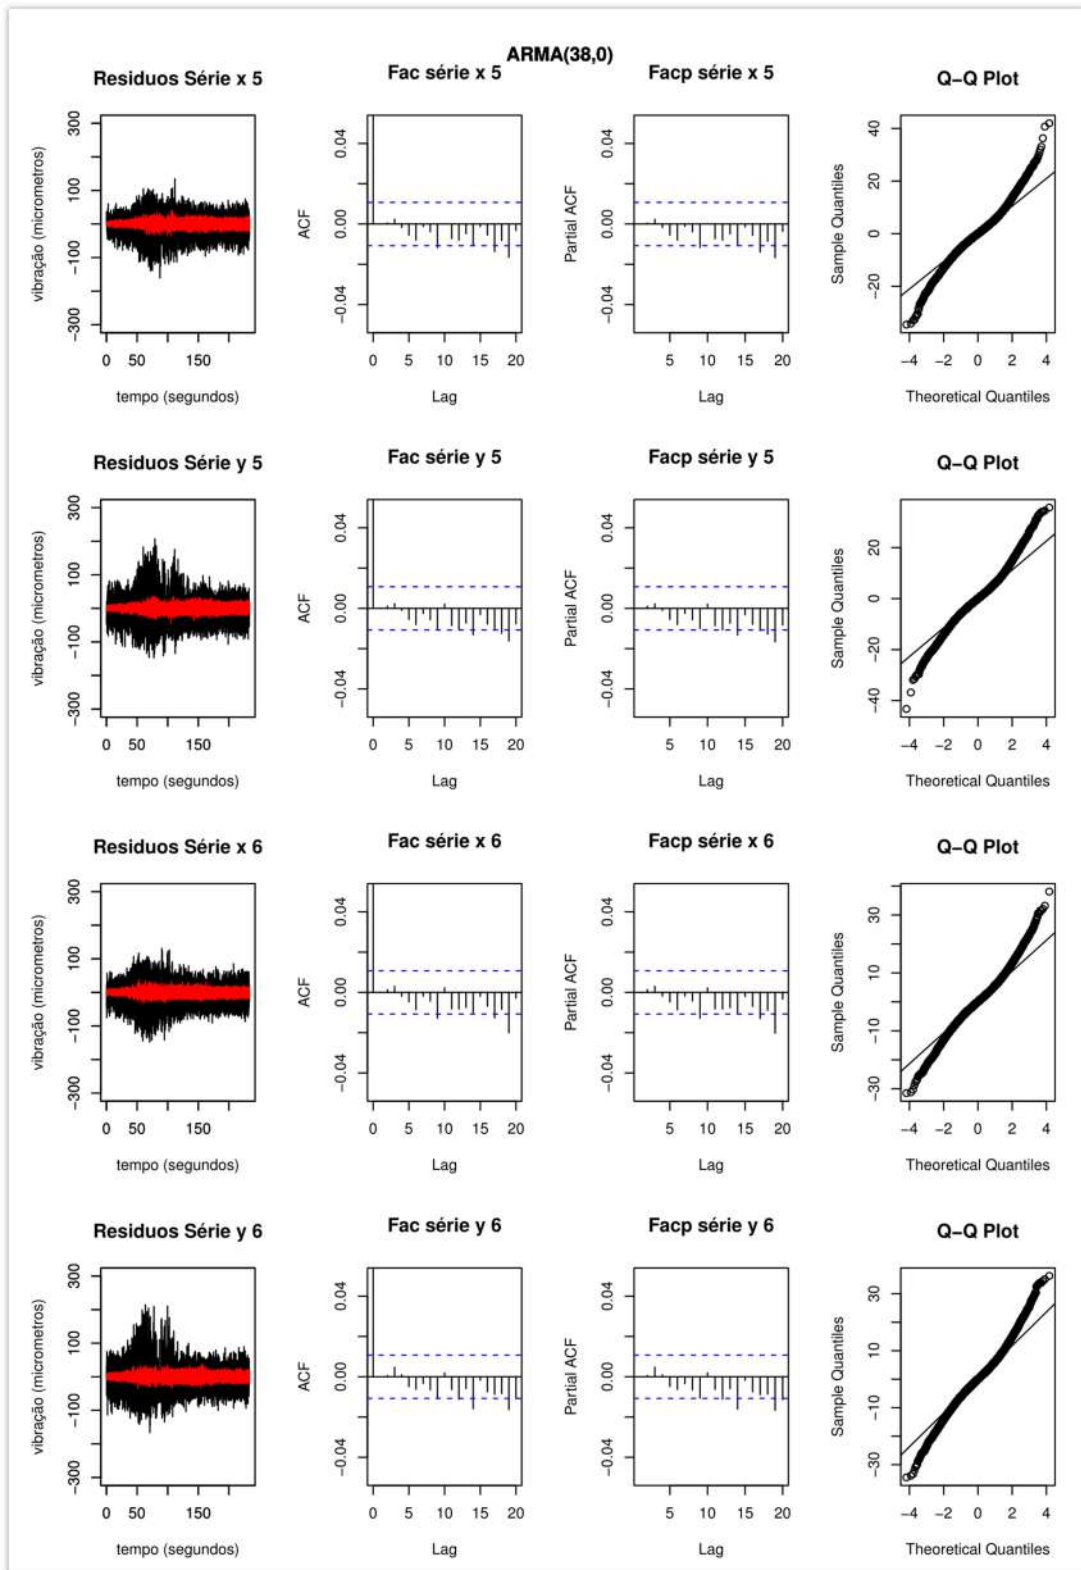
RESULTADOS DA APLICAÇÃO DO MODELO ARMA



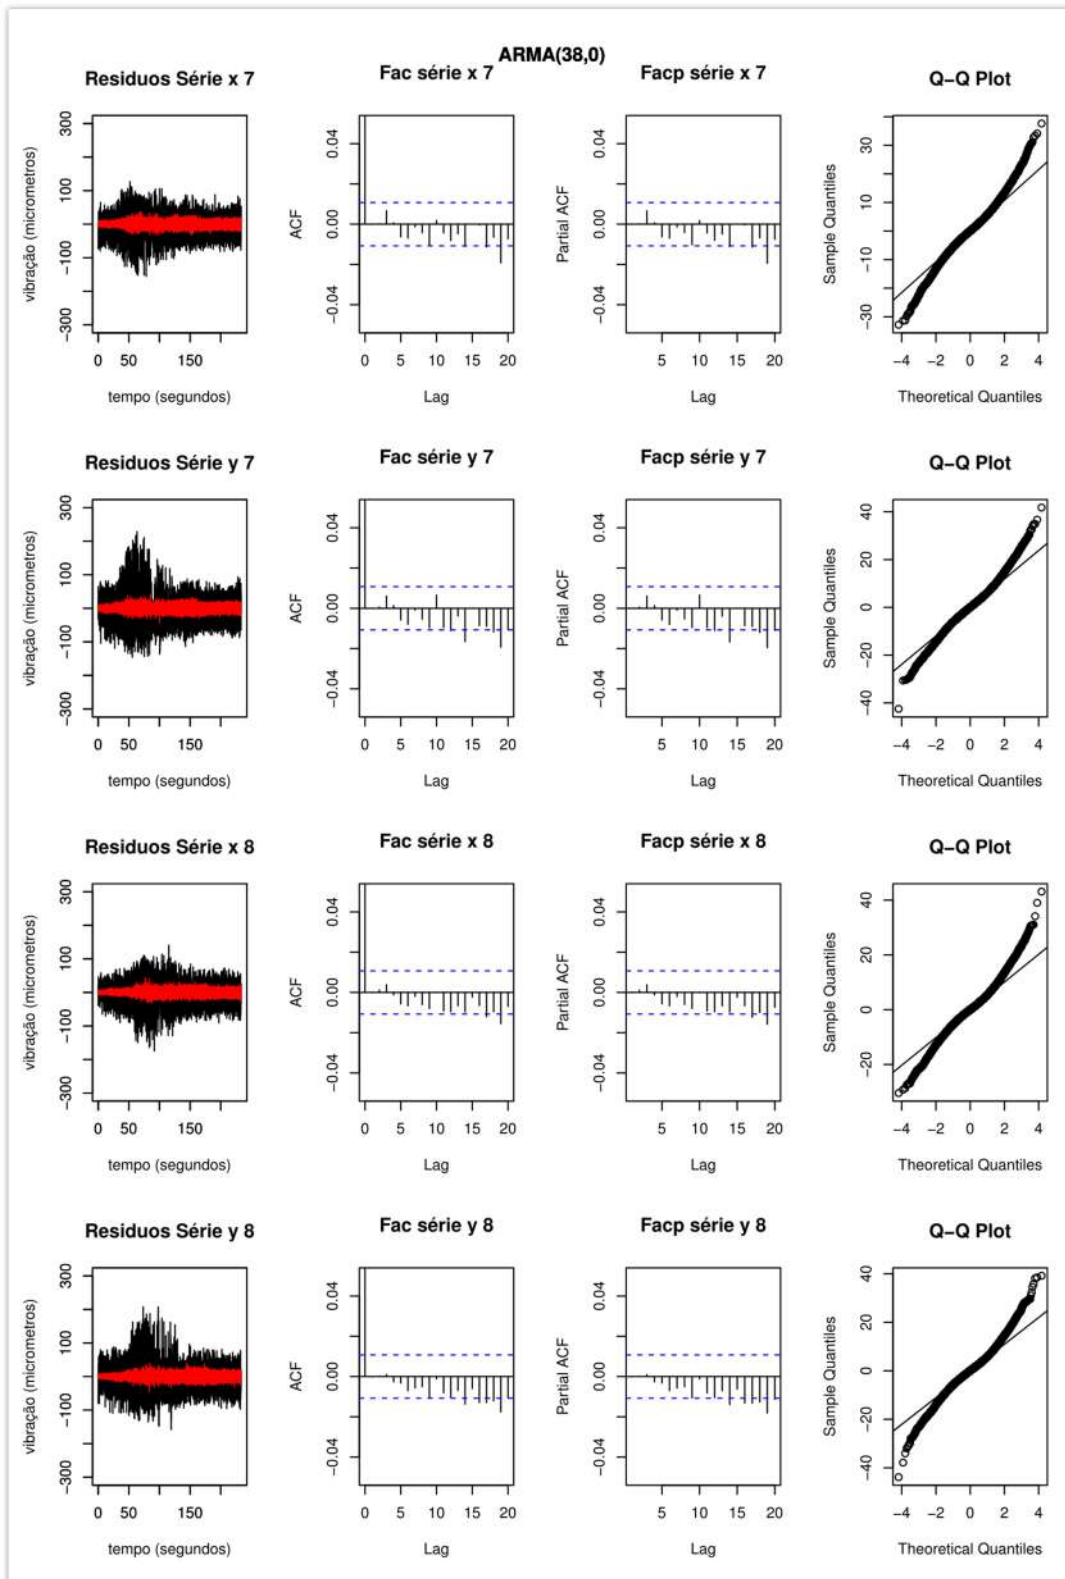
Anexo IV - Figura 1: AR(38) para as séries originais parte 1



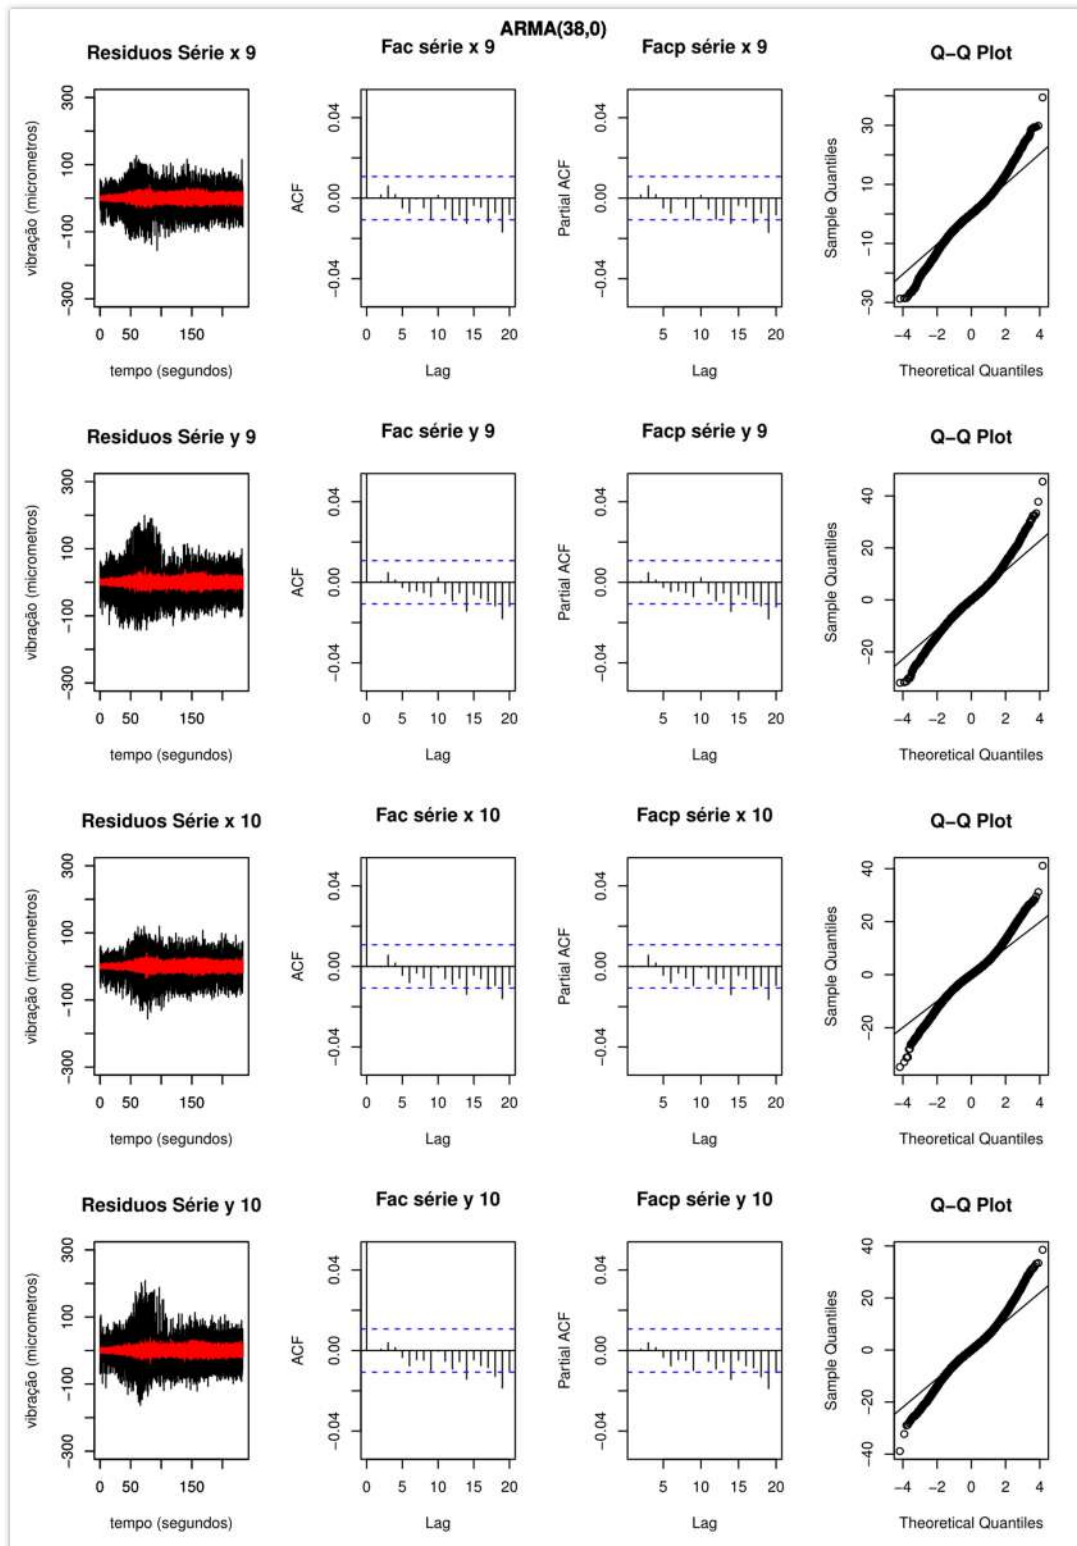
Anexo IV - Figura 2: AR(38) para as séries originais parte 2



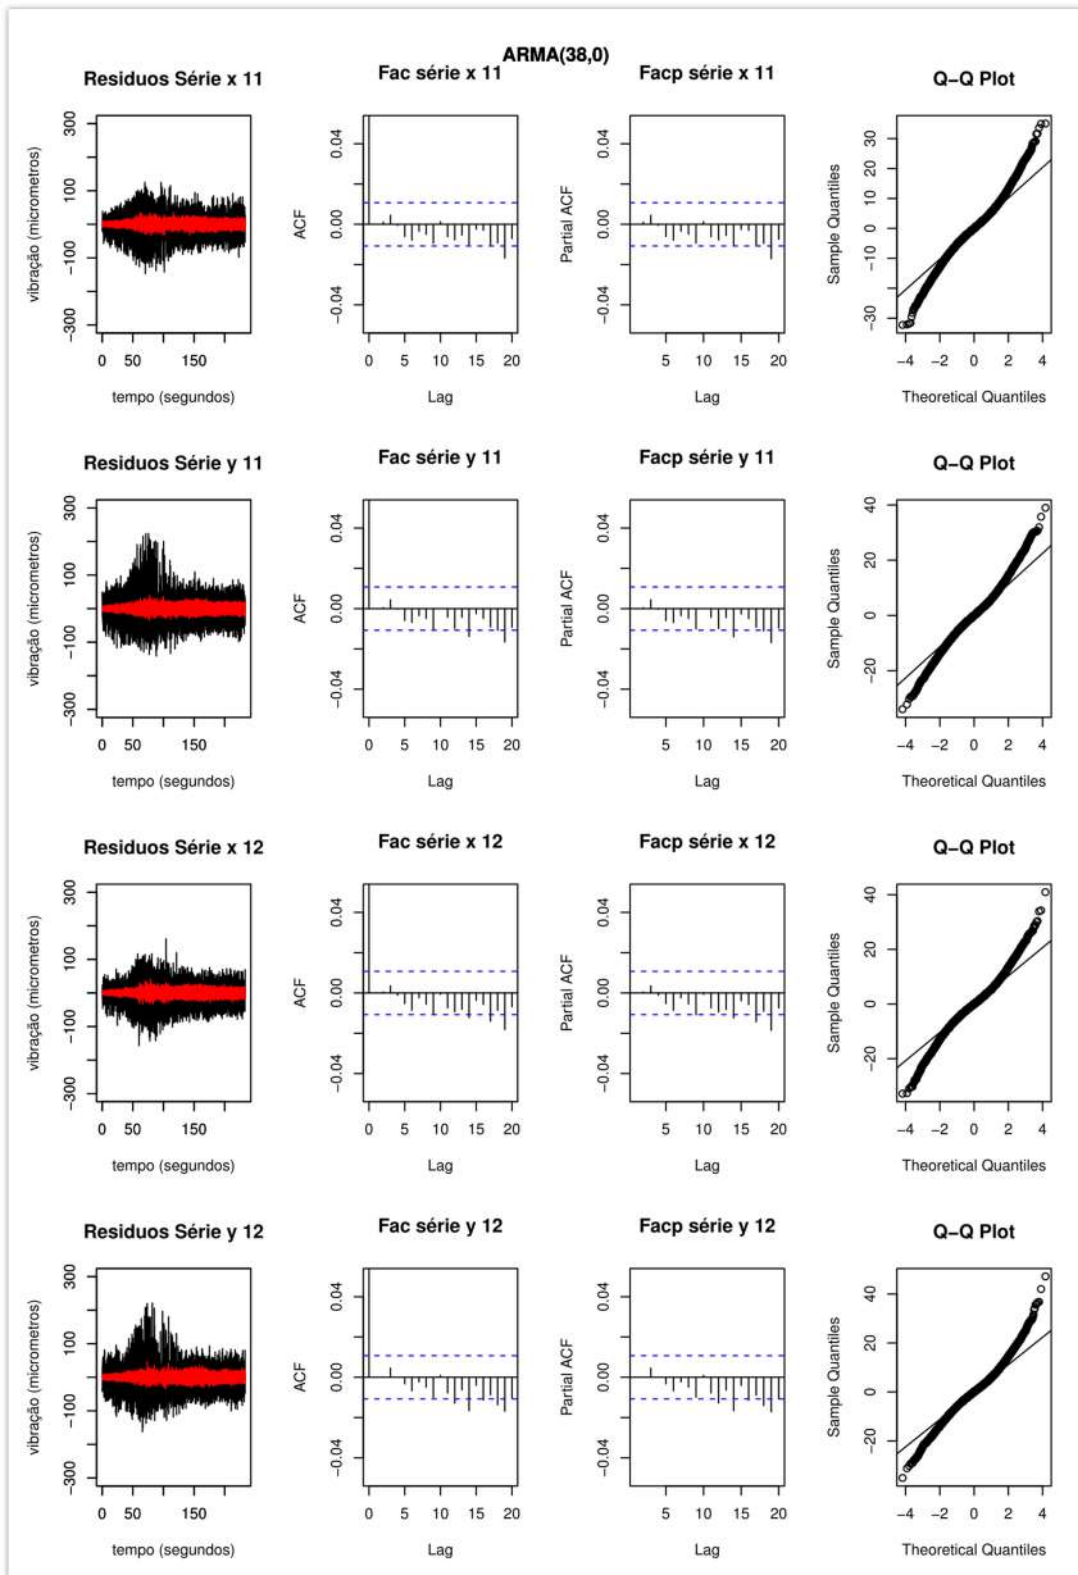
Anexo IV - Figura 3: AR(38) para as séries originais parte 3



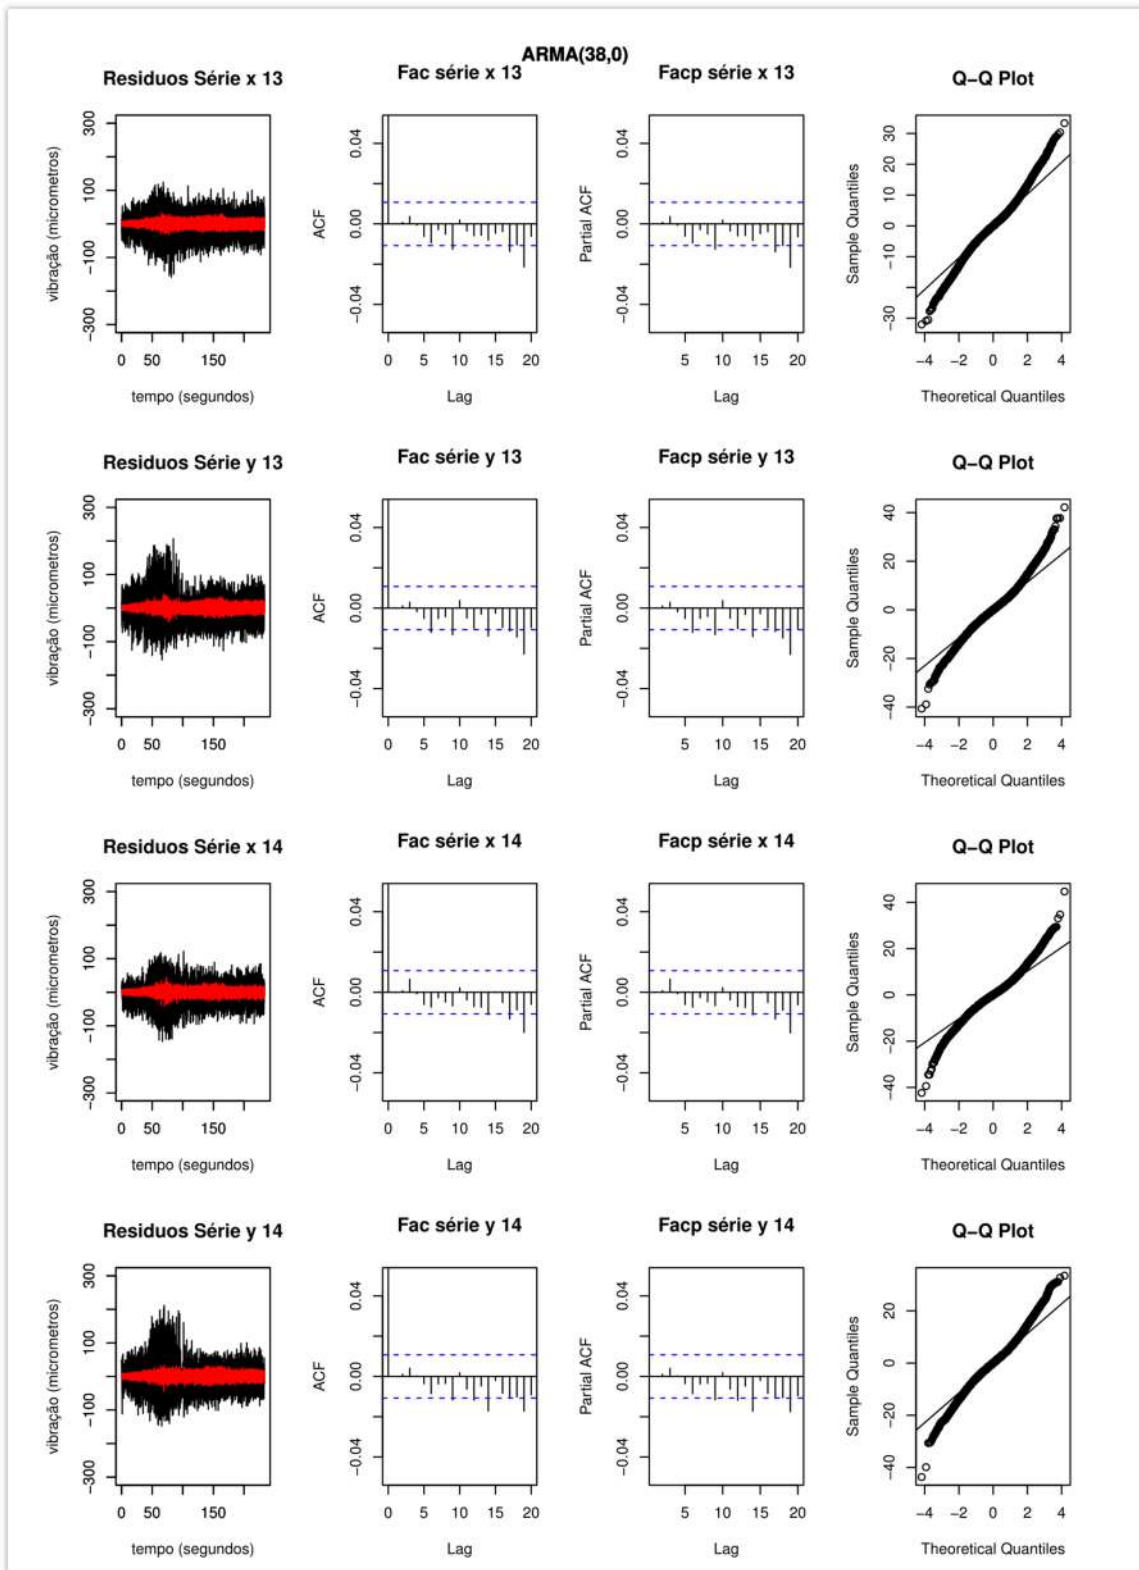
Anexo IV - Figura 4: AR(38) para as séries originais parte 4



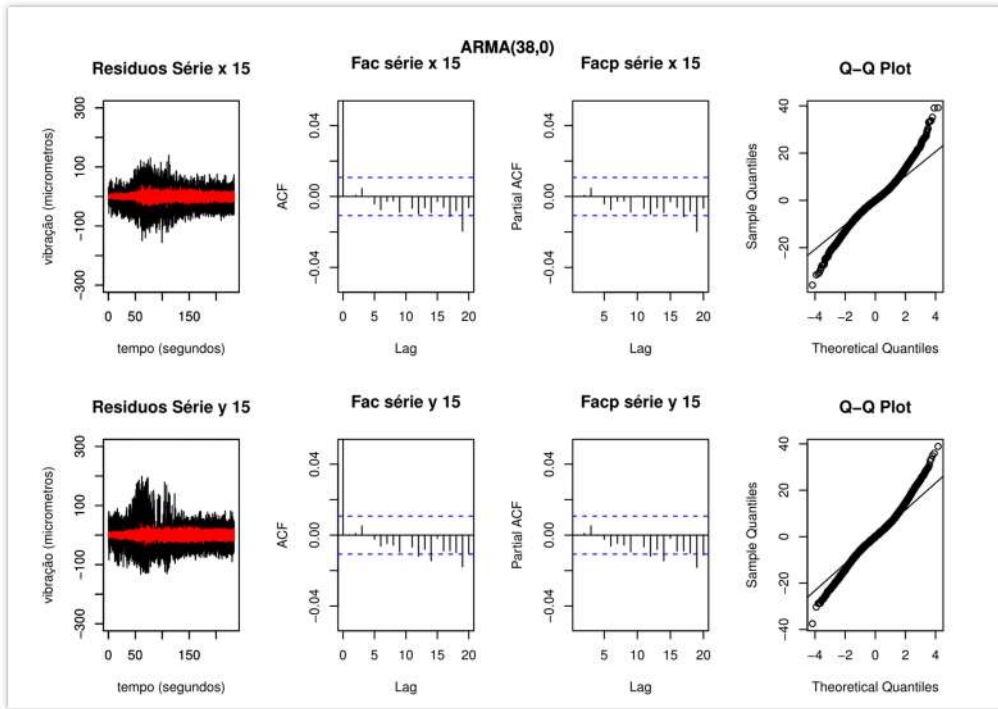
Anexo IV - Figura 5: AR(38) para as séries originais parte 5



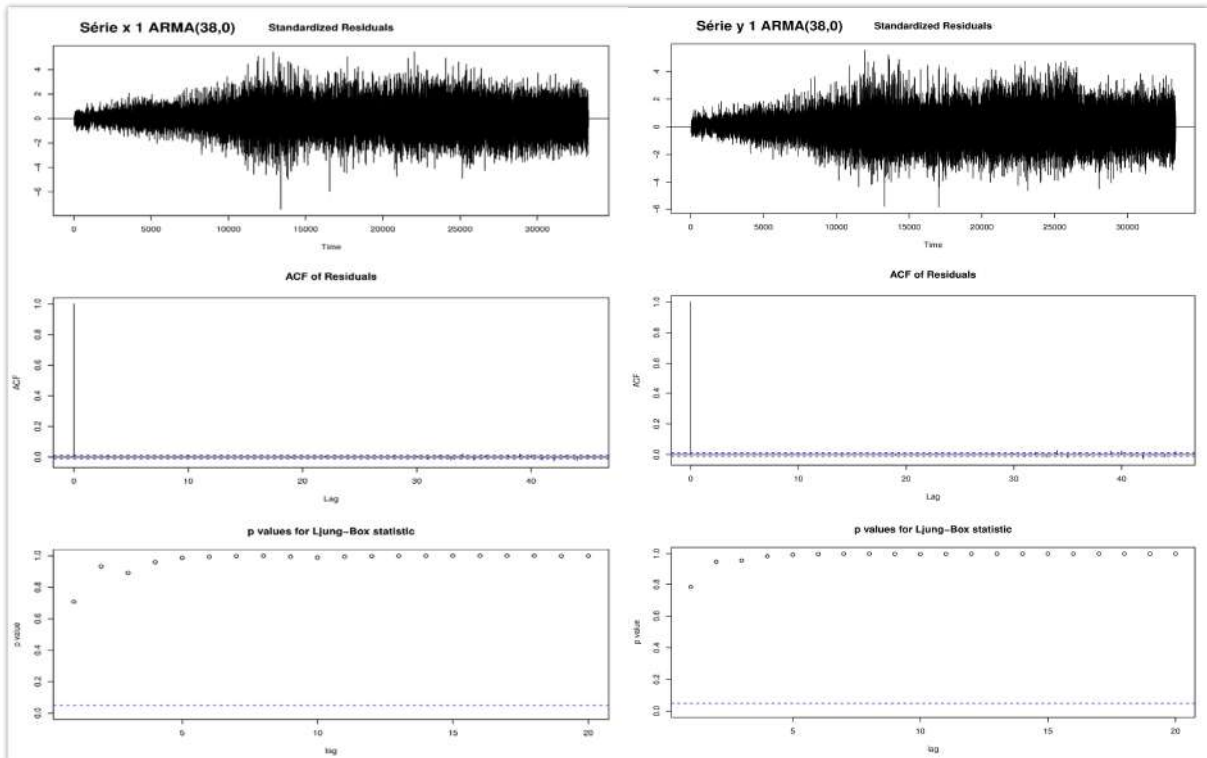
Anexo IV - Figura 6: AR(38) para as séries originais parte 6



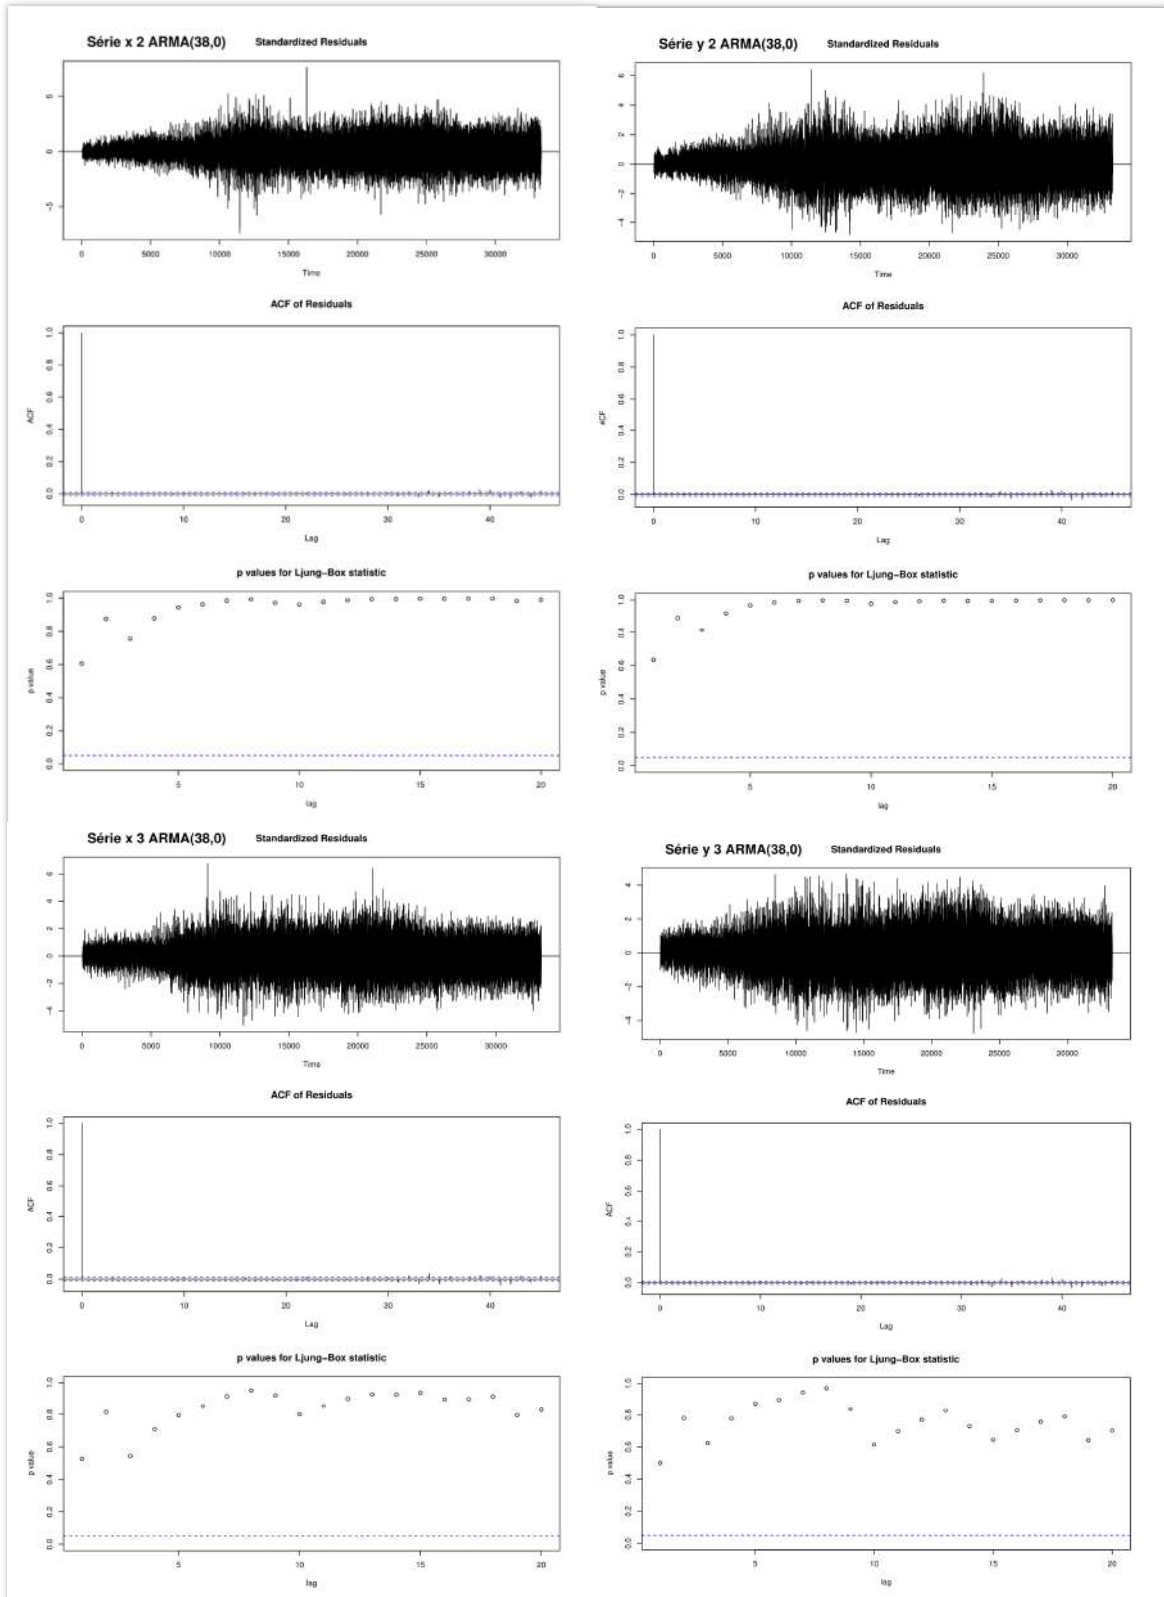
Anexo IV - Figura 7: AR(38) para as séries originais parte 7



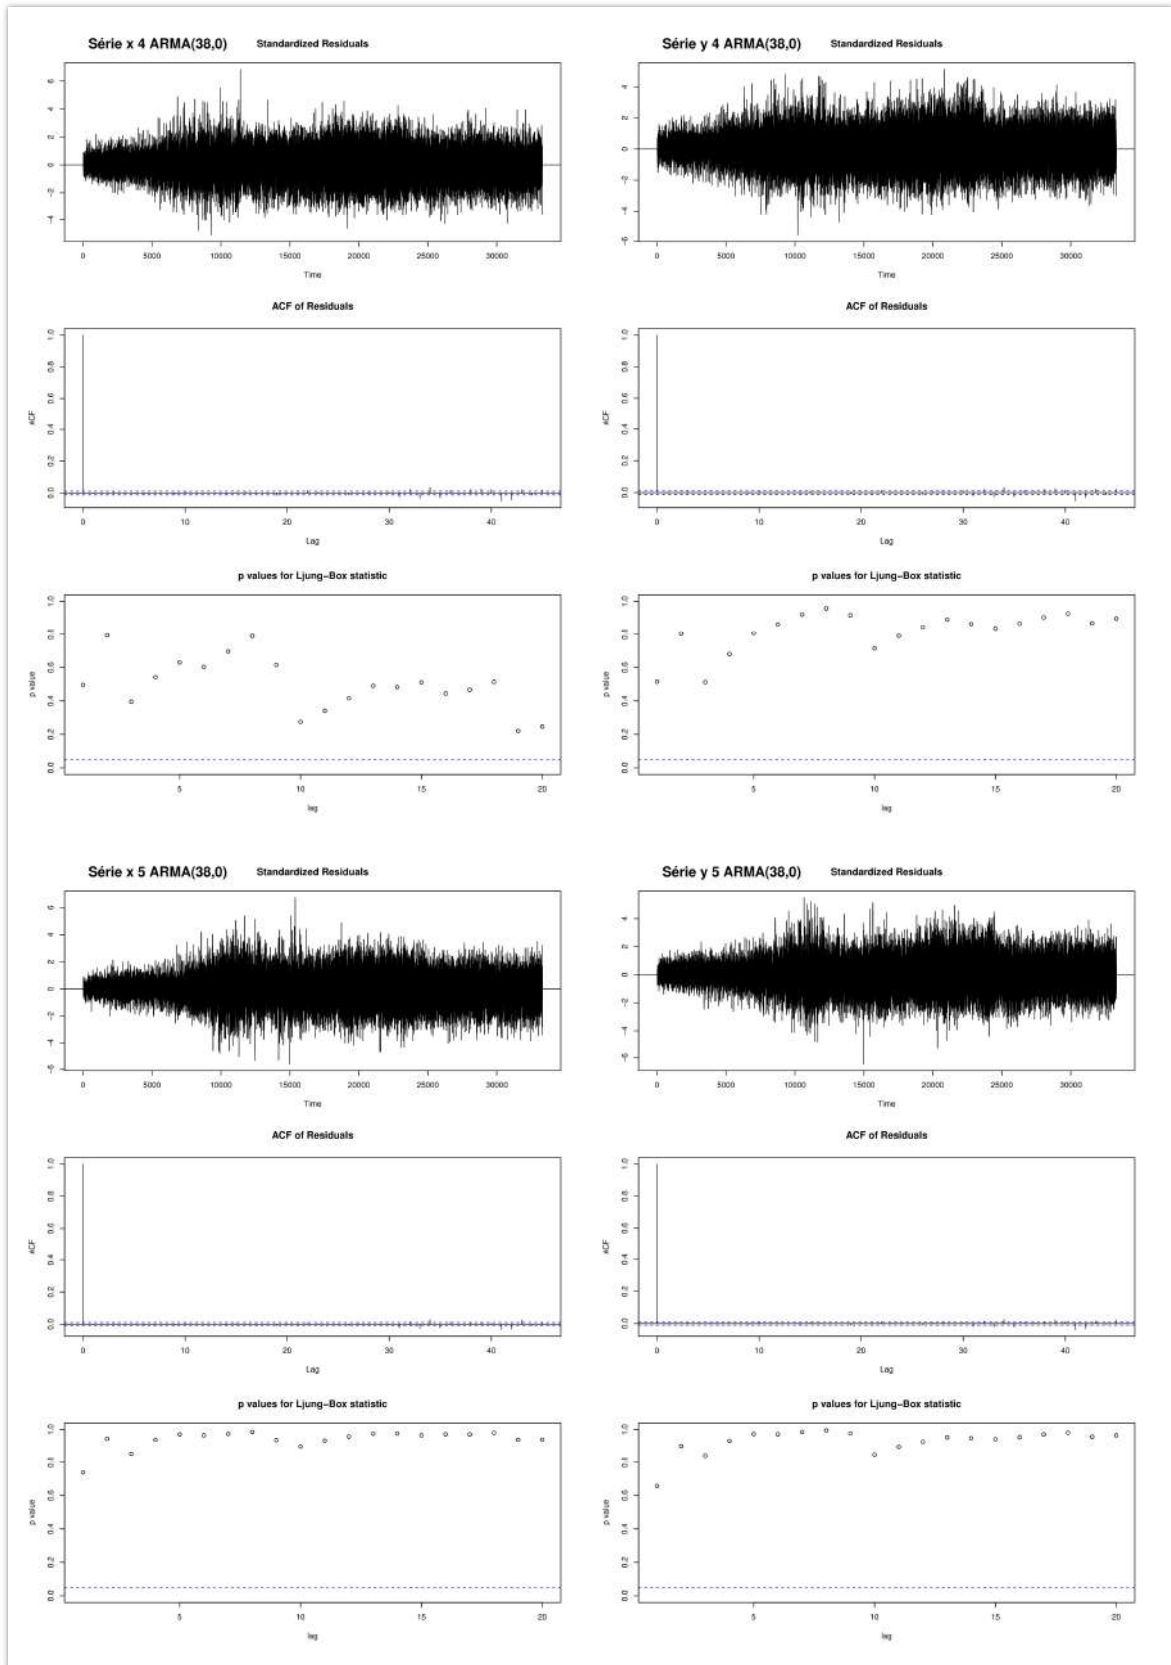
Anexo IV - Figura 8: AR(38) para as séries originais parte 8



Anexo IV - Figura 9: Resíduos padronizados, FAC e teste de Ljung-Box do AR(38) parte 1

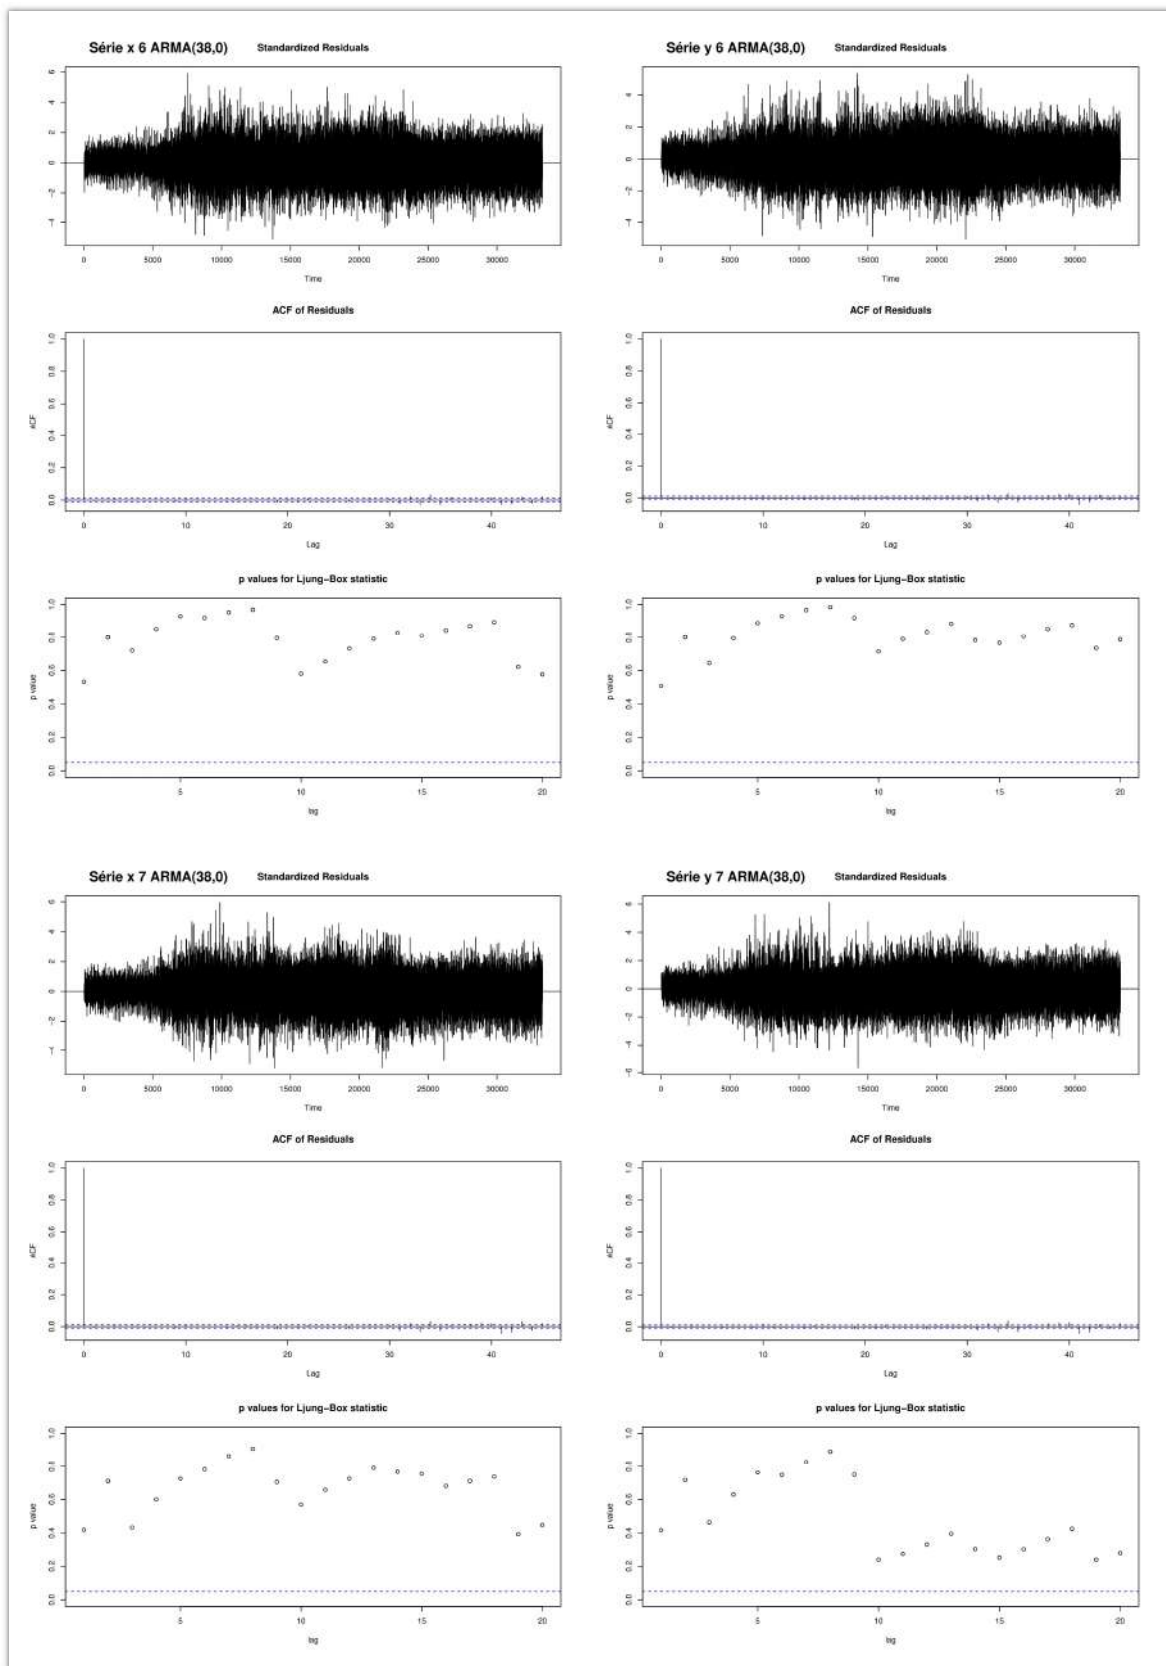


Anexo IV - Figura 10: Resíduos padronizados, FAC e teste de Ljung-Box do AR(38) parte

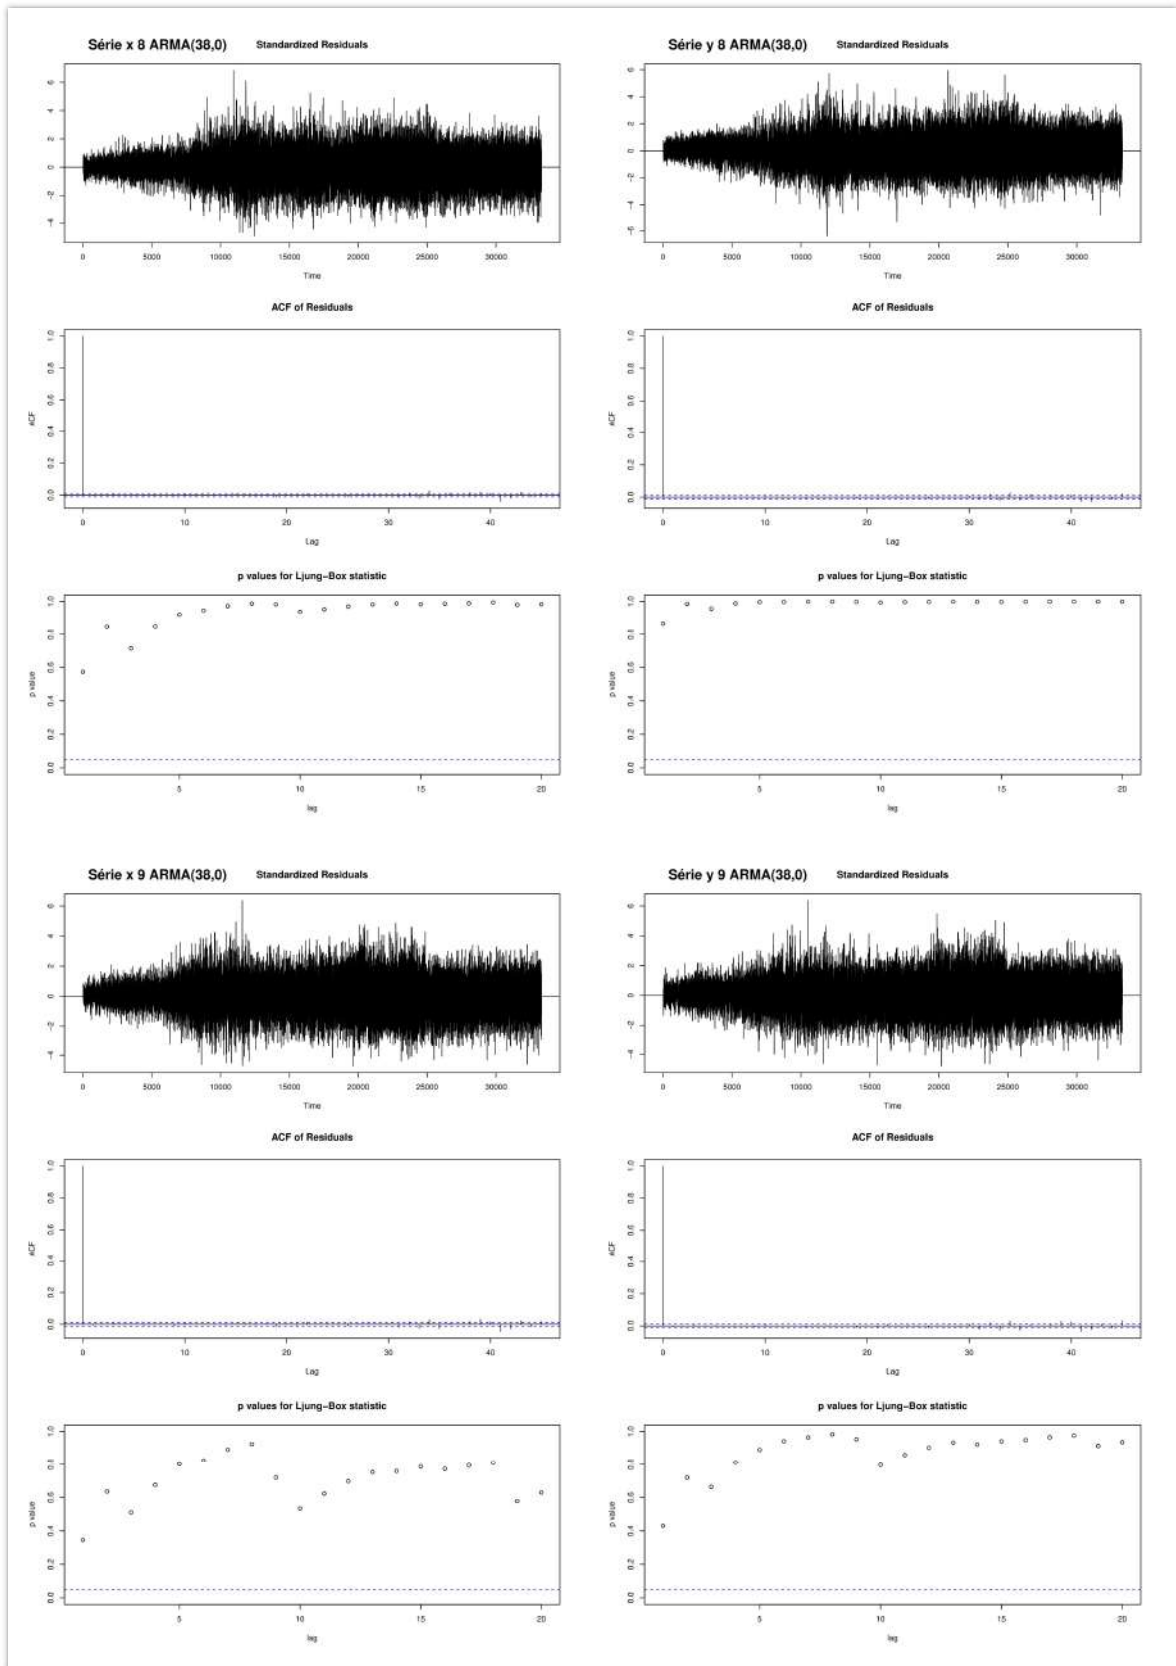


Anexo IV - Figura 11: Resíduos padronizados, FAC e teste de Ljung-Box do AR(38)

parte 3

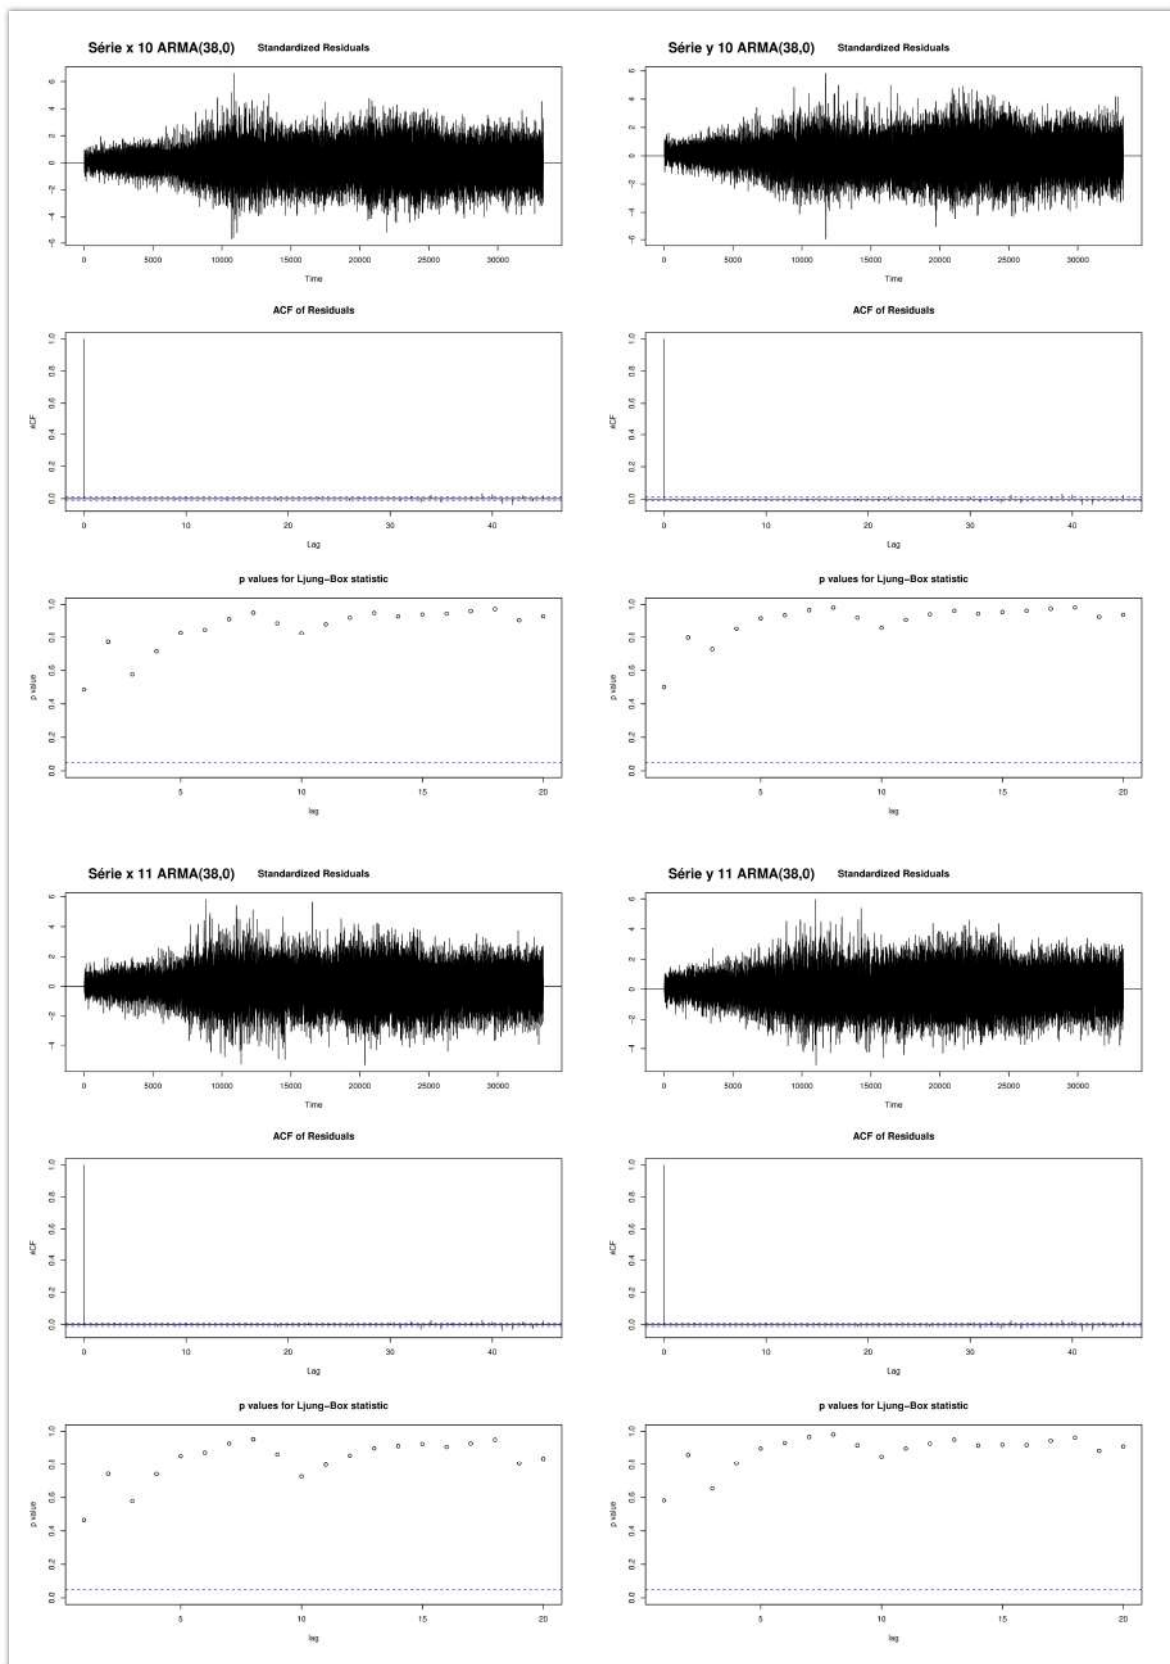


Anexo IV - Figura 12: Resíduos padronizados, FAC e teste de Ljung-Box do AR(38)
 parte 4

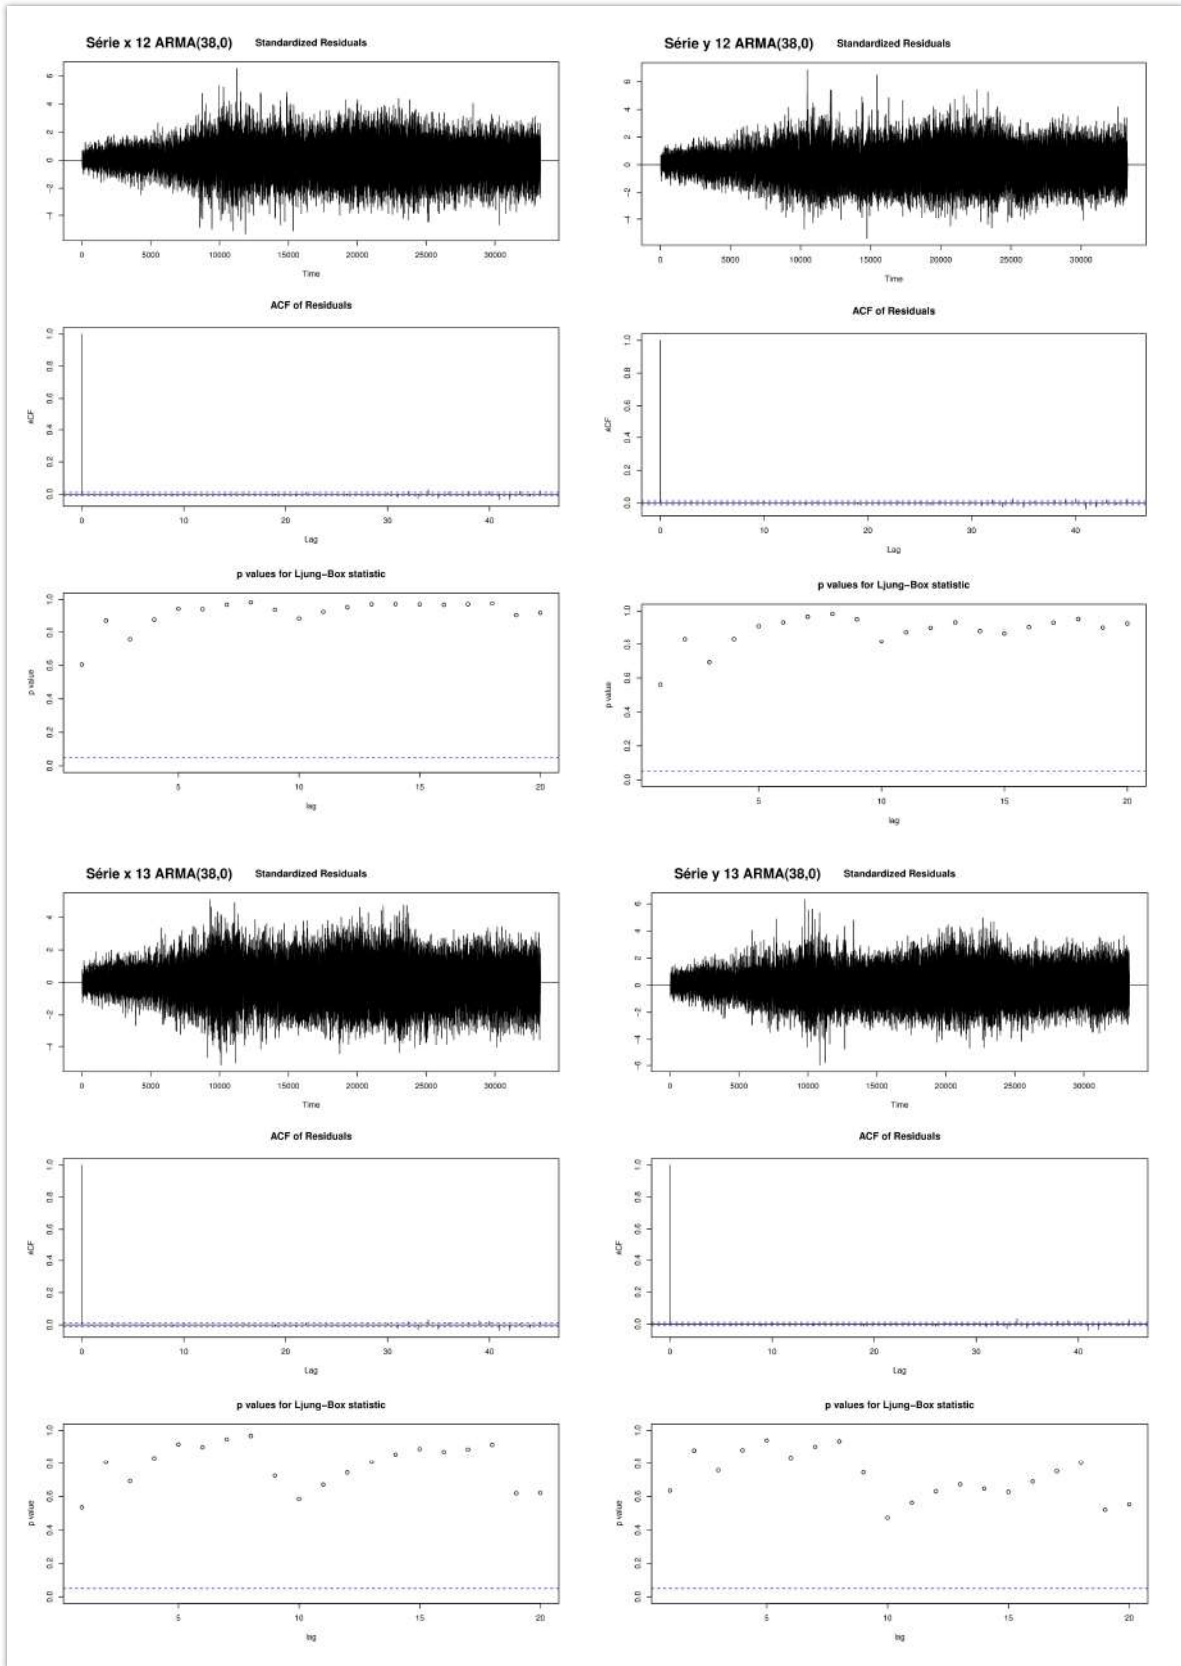


Anexo IV - Figura 13: Resíduos padronizados, FAC e teste de Ljung-Box do AR(38)

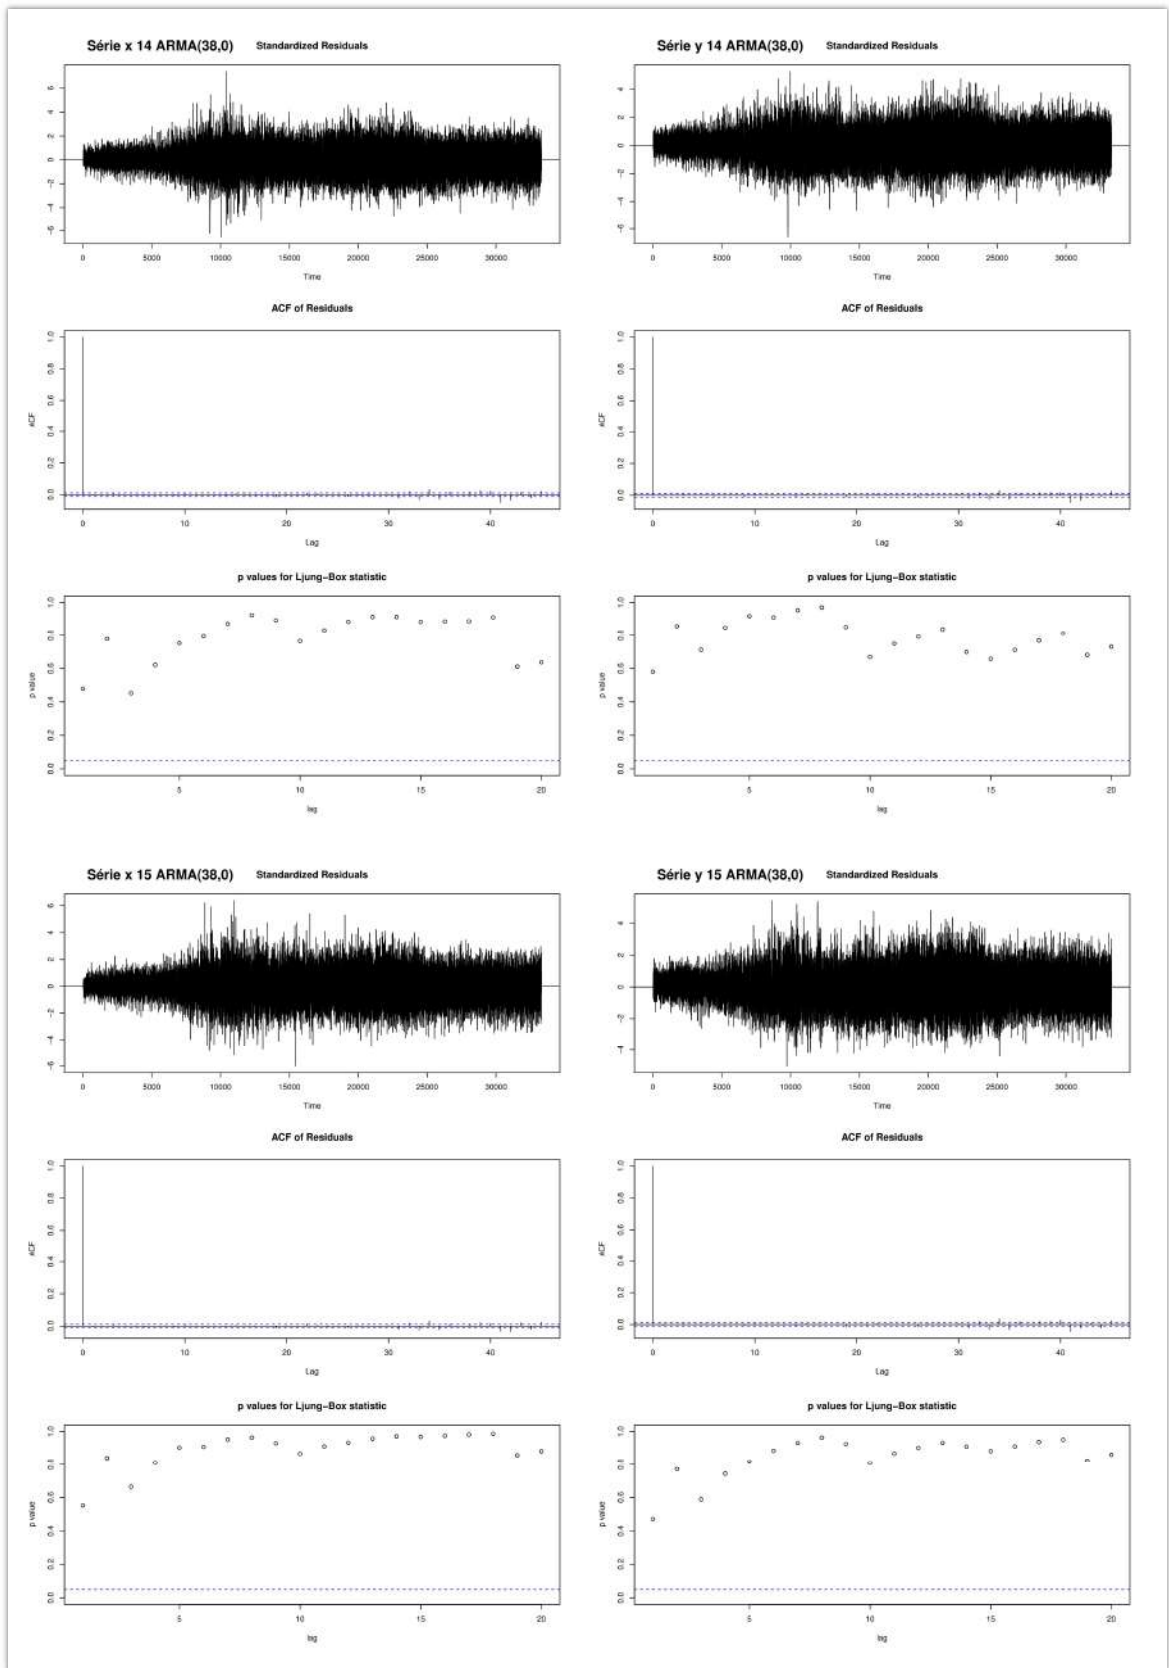
parte 5



Anexo IV - Figura 14: Resíduos padronizados, FAC e teste de Ljung-Box do AR(38)
 parte 6

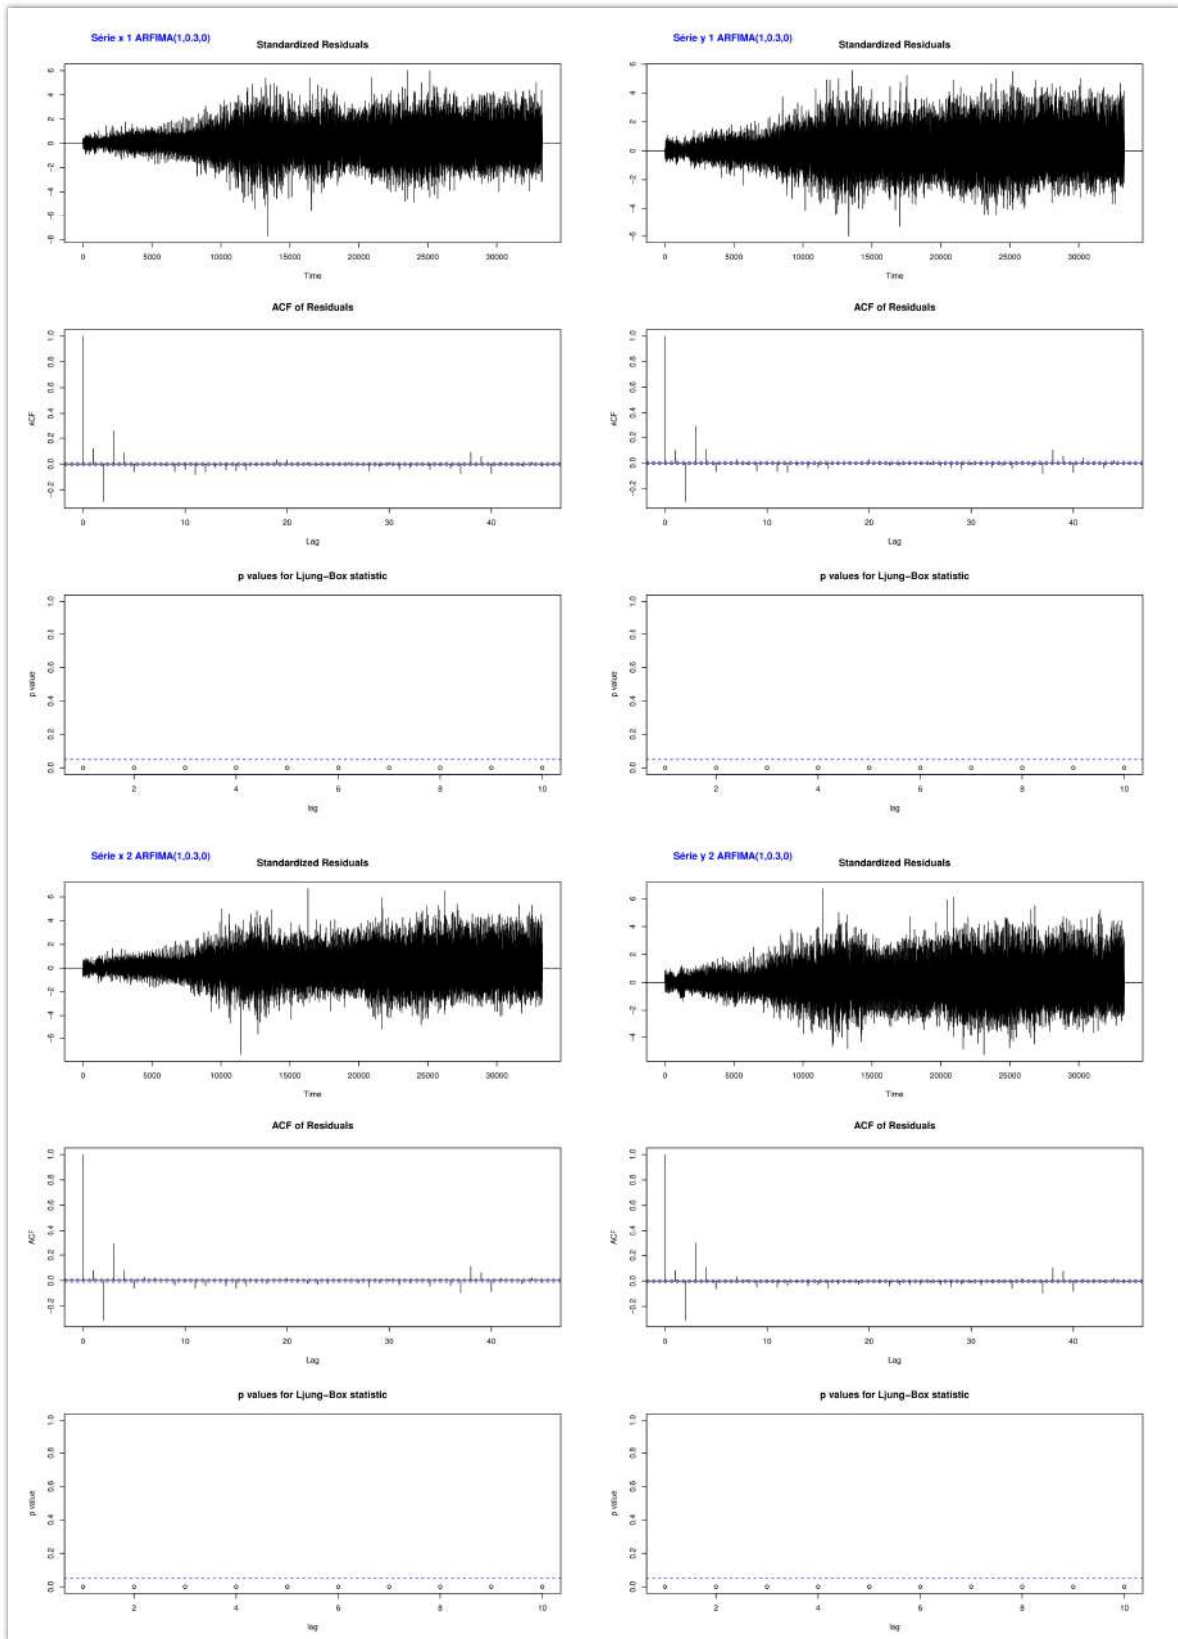


Anexo IV - Figura 15: Resíduos padronizados, FAC e teste de Ljung-Box do AR(38) parte

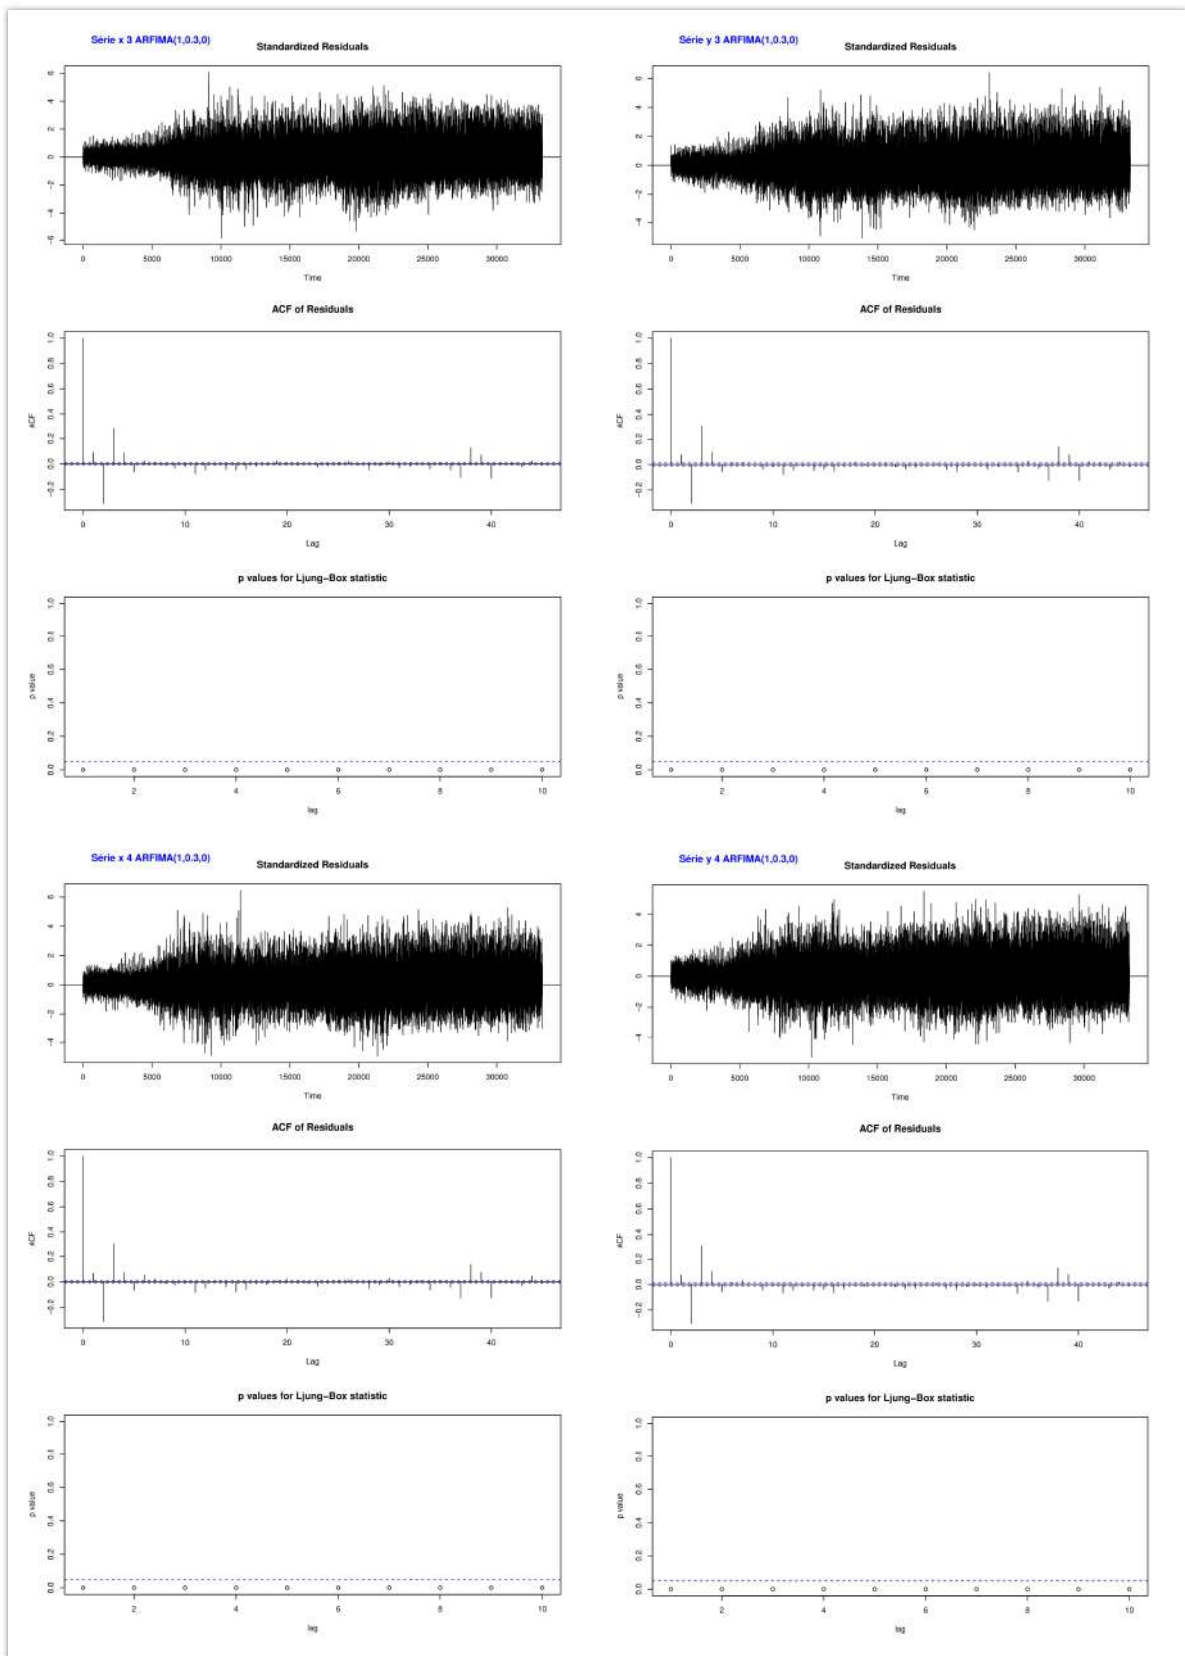


Anexo IV - Figura 16: Resíduos padronizados, FAC e teste de Ljung-Box do AR(38)
 parte 8

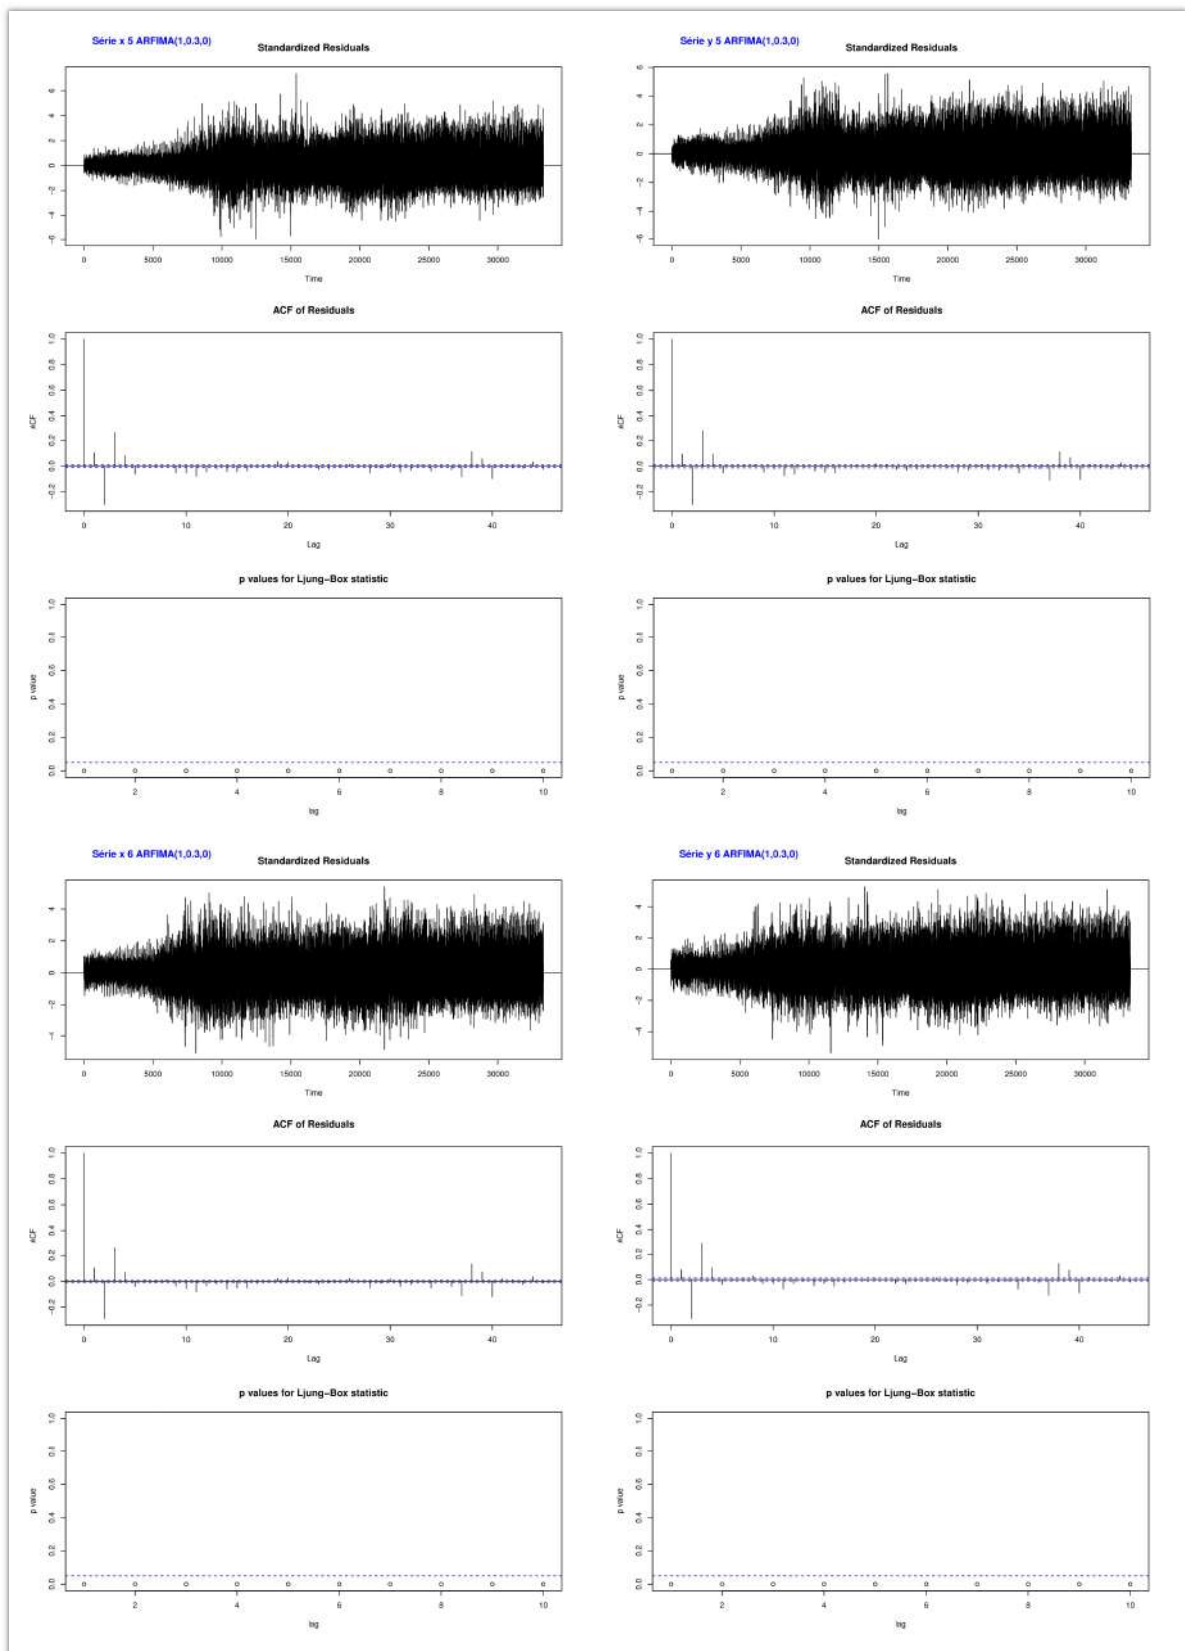
RESULTADOS DA APLICAÇÃO DO MODELO ARFIMA



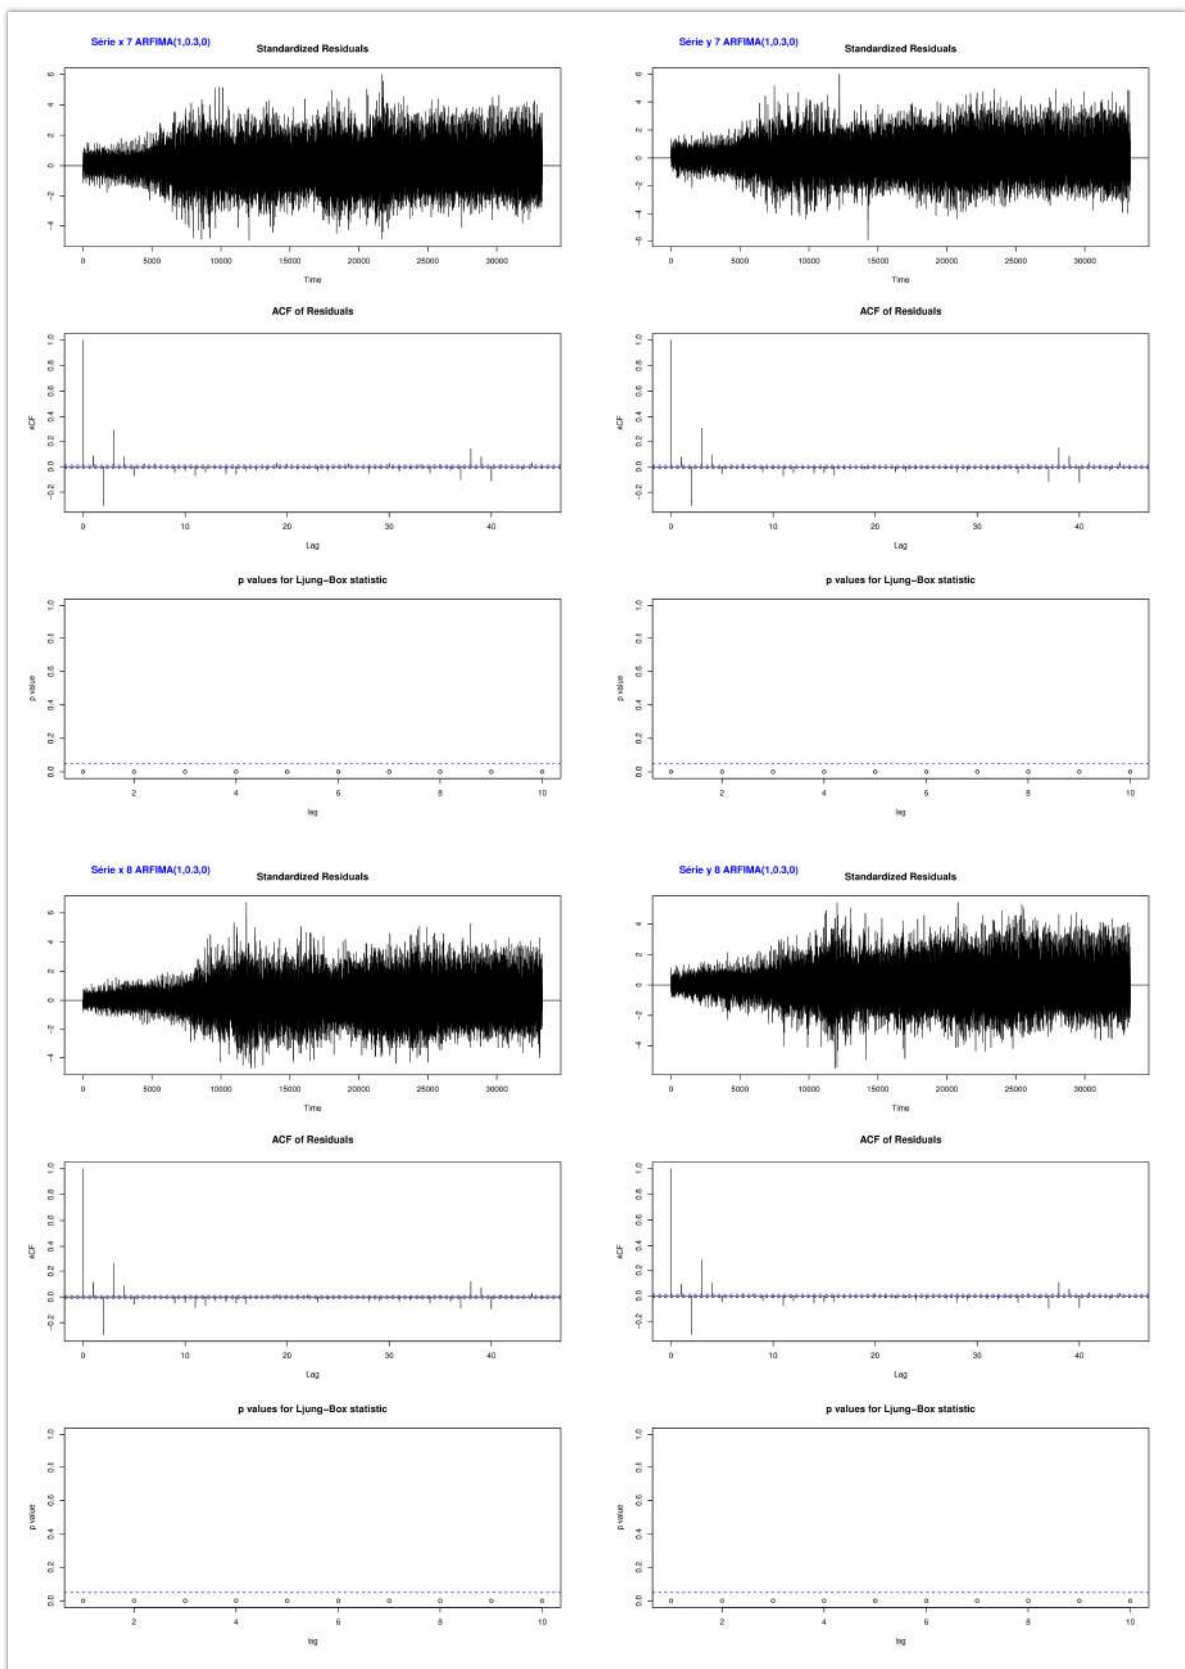
Anexo IV - Figura 17: Resíduos padronizados, FAC e teste de Ljung-Box do ARFIMA(1,0,3,0) parte 1



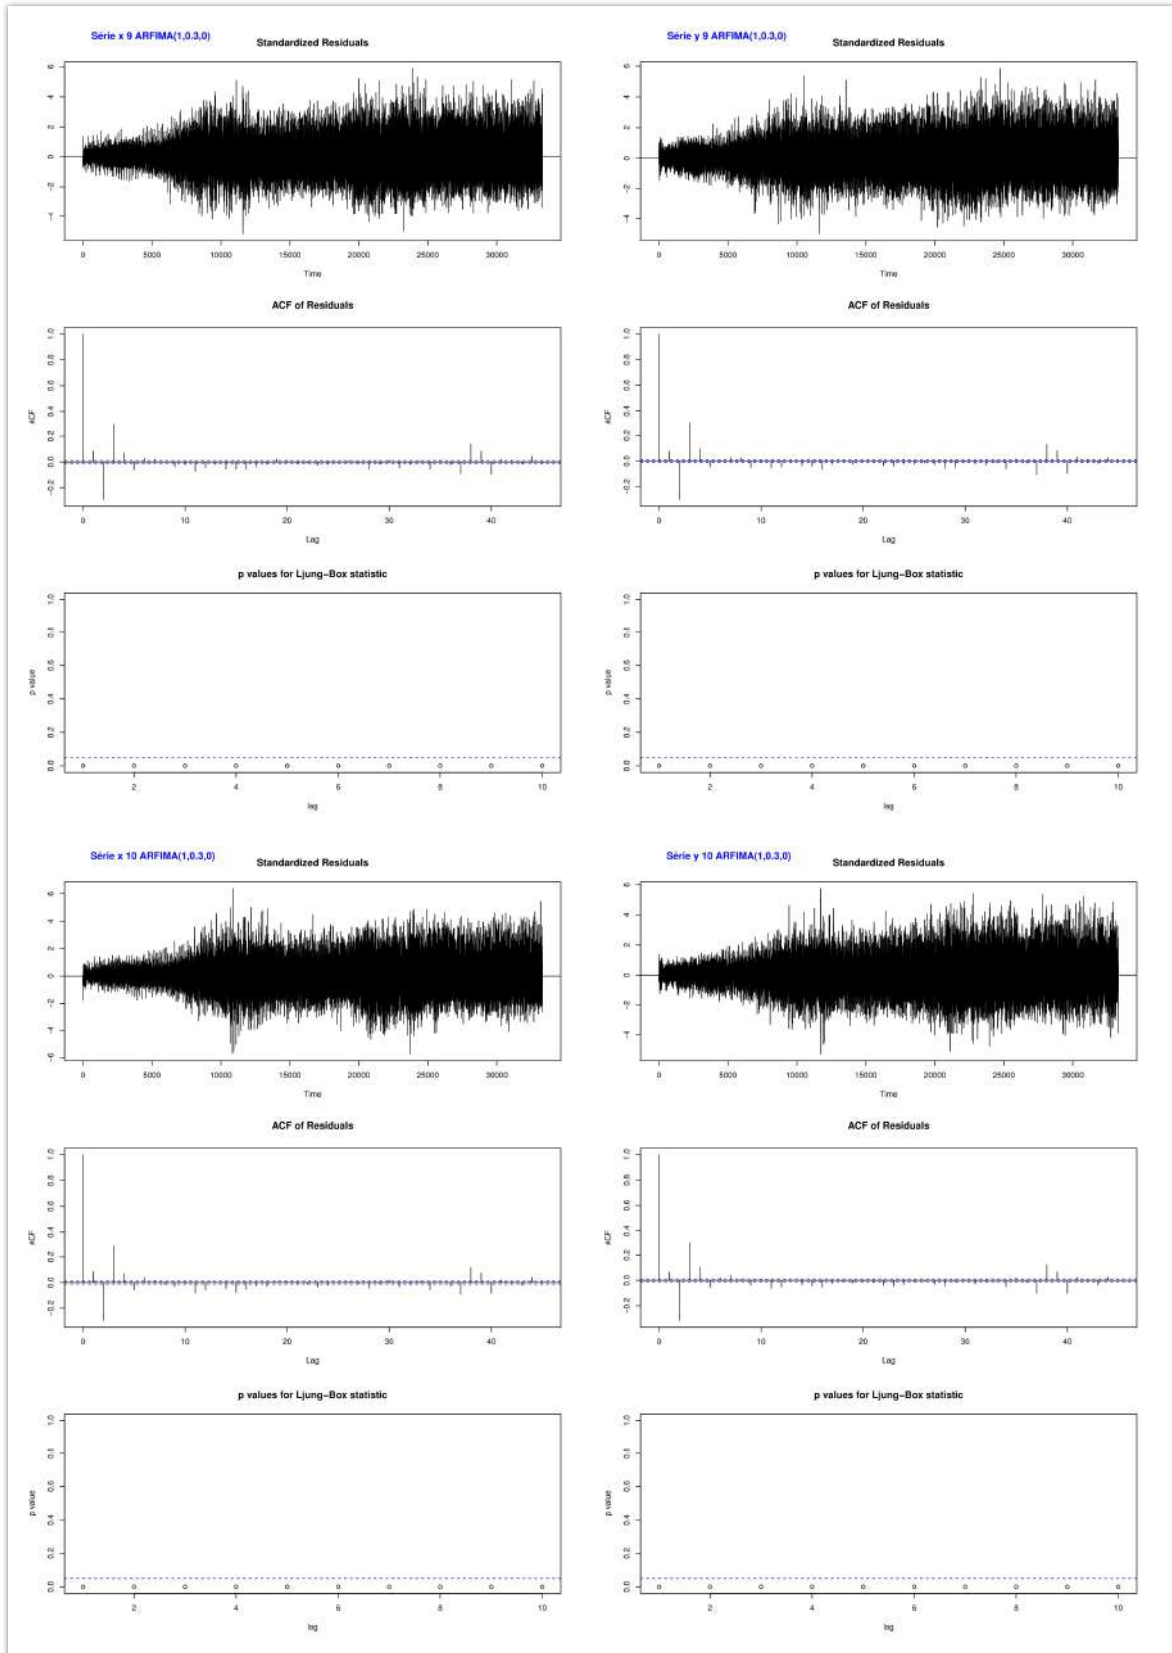
Anexo IV - Figura 18: Resíduos padronizados, FAC e teste de Ljung-Box do ARFIMA(1,0,3,0) parte 2



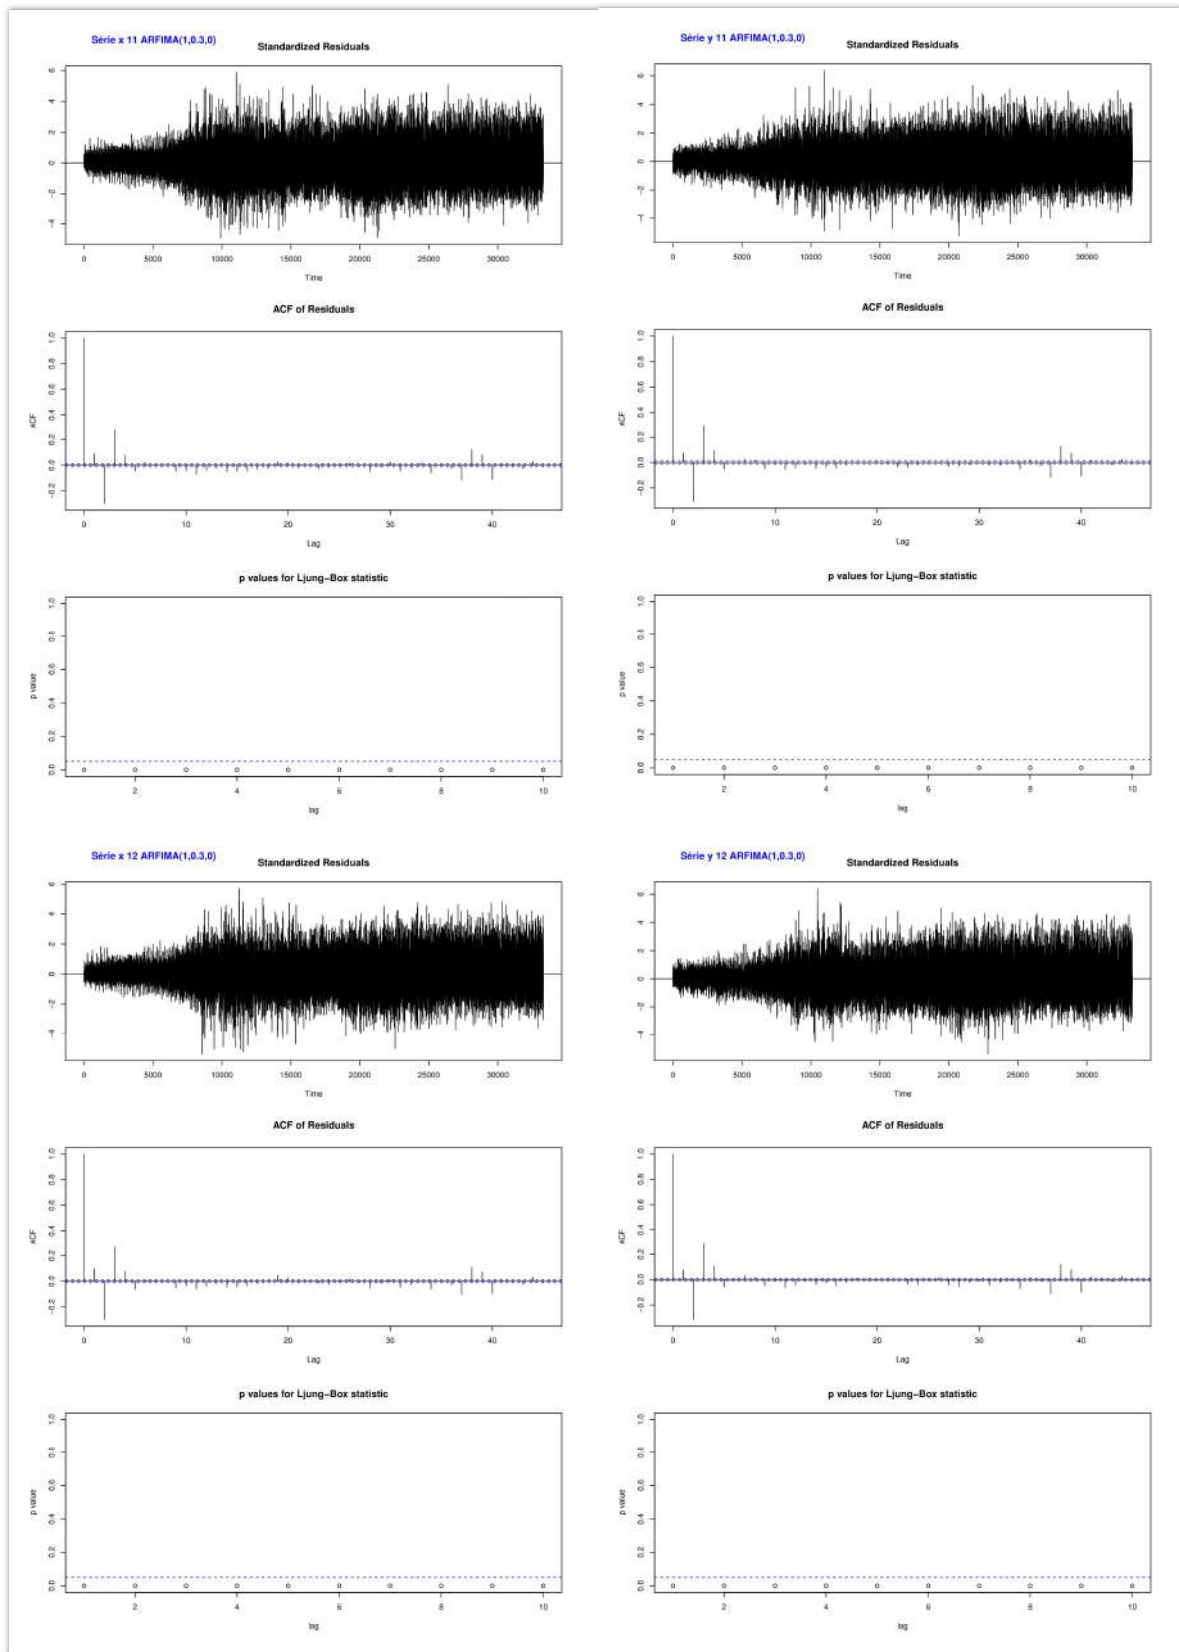
Anexo IV - Figura 19: Resíduos padronizados, FAC e teste de Ljung-Box do ARFIMA(1,0,3,0) parte 3



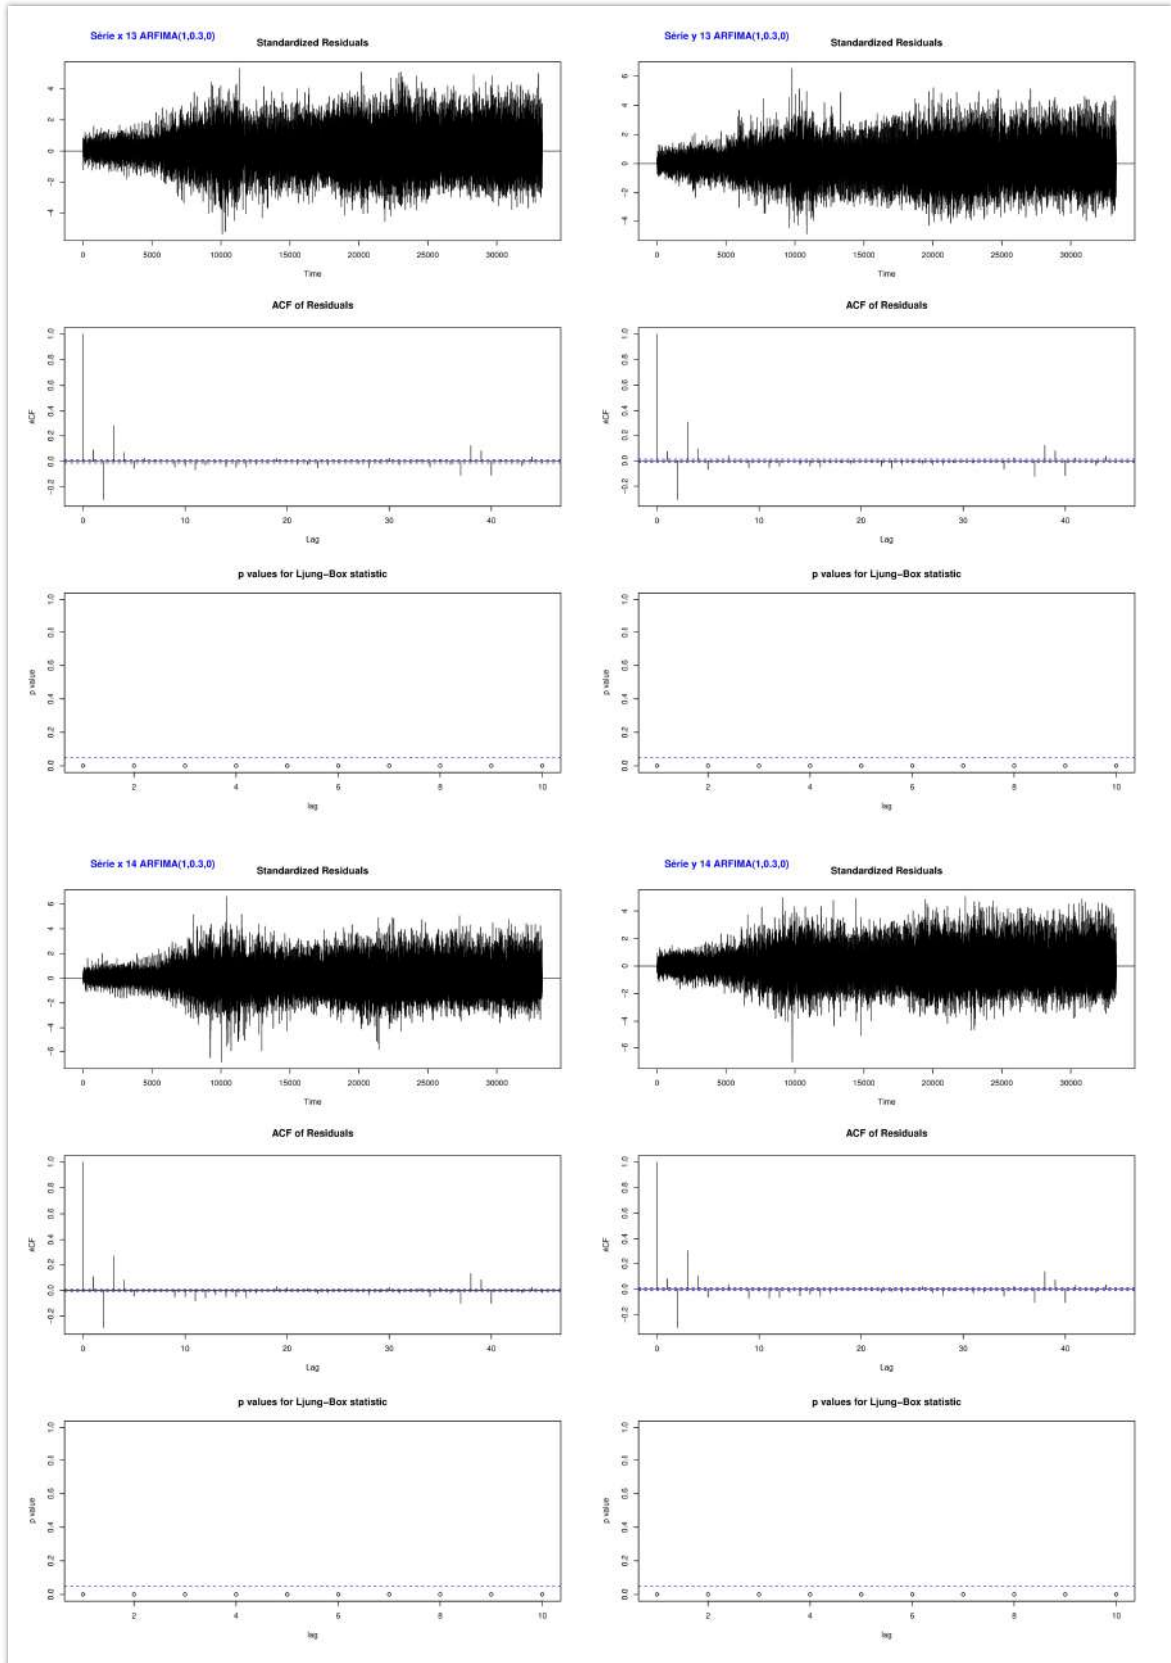
Anexo IV - Figura 20: Resíduos padronizados, FAC e teste de Ljung-Box do ARFIMA(1,0,3,0) parte 4



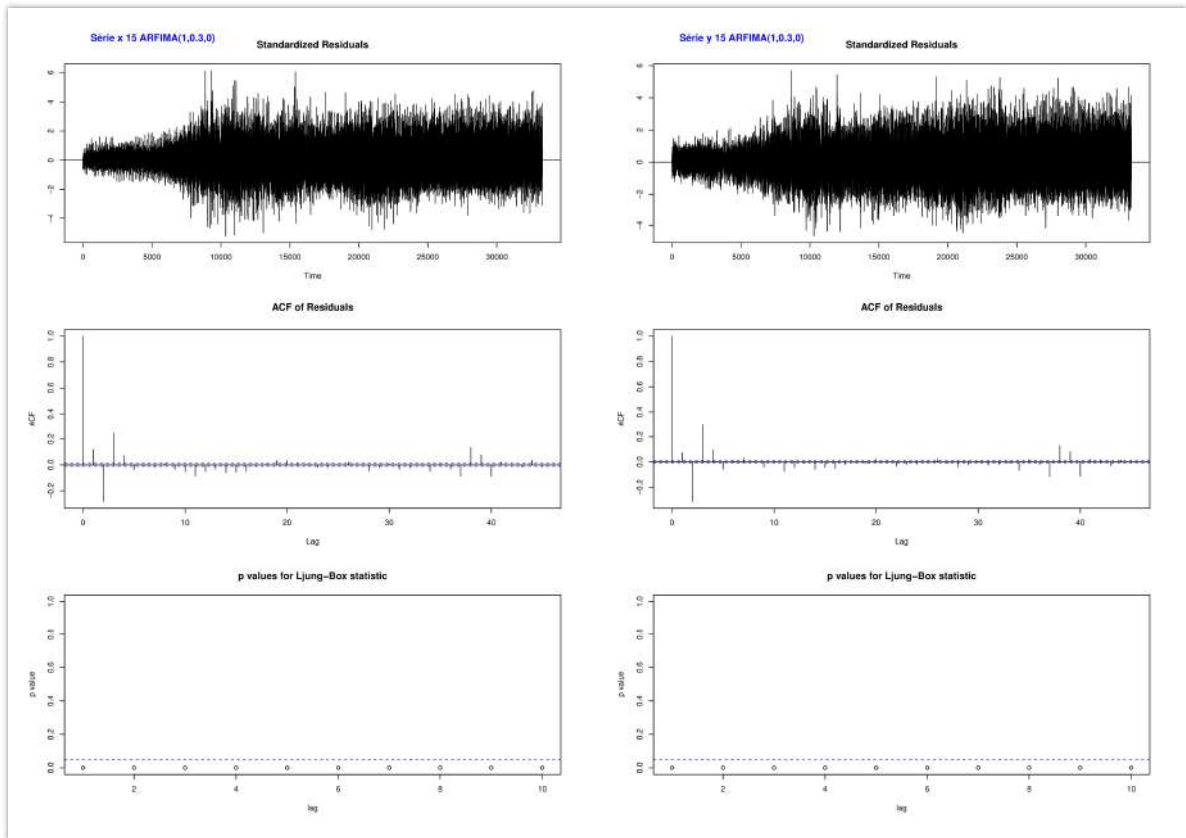
Anexo IV - Figura 21: Resíduos padronizados, FAC e teste de Ljung-Box do ARFIMA(1,0,3,0) parte 5



Anexo IV - Figura 22: Resíduos padronizados, FAC e teste de Ljung-Box do ARFIMA(1,0,3,0) parte 6



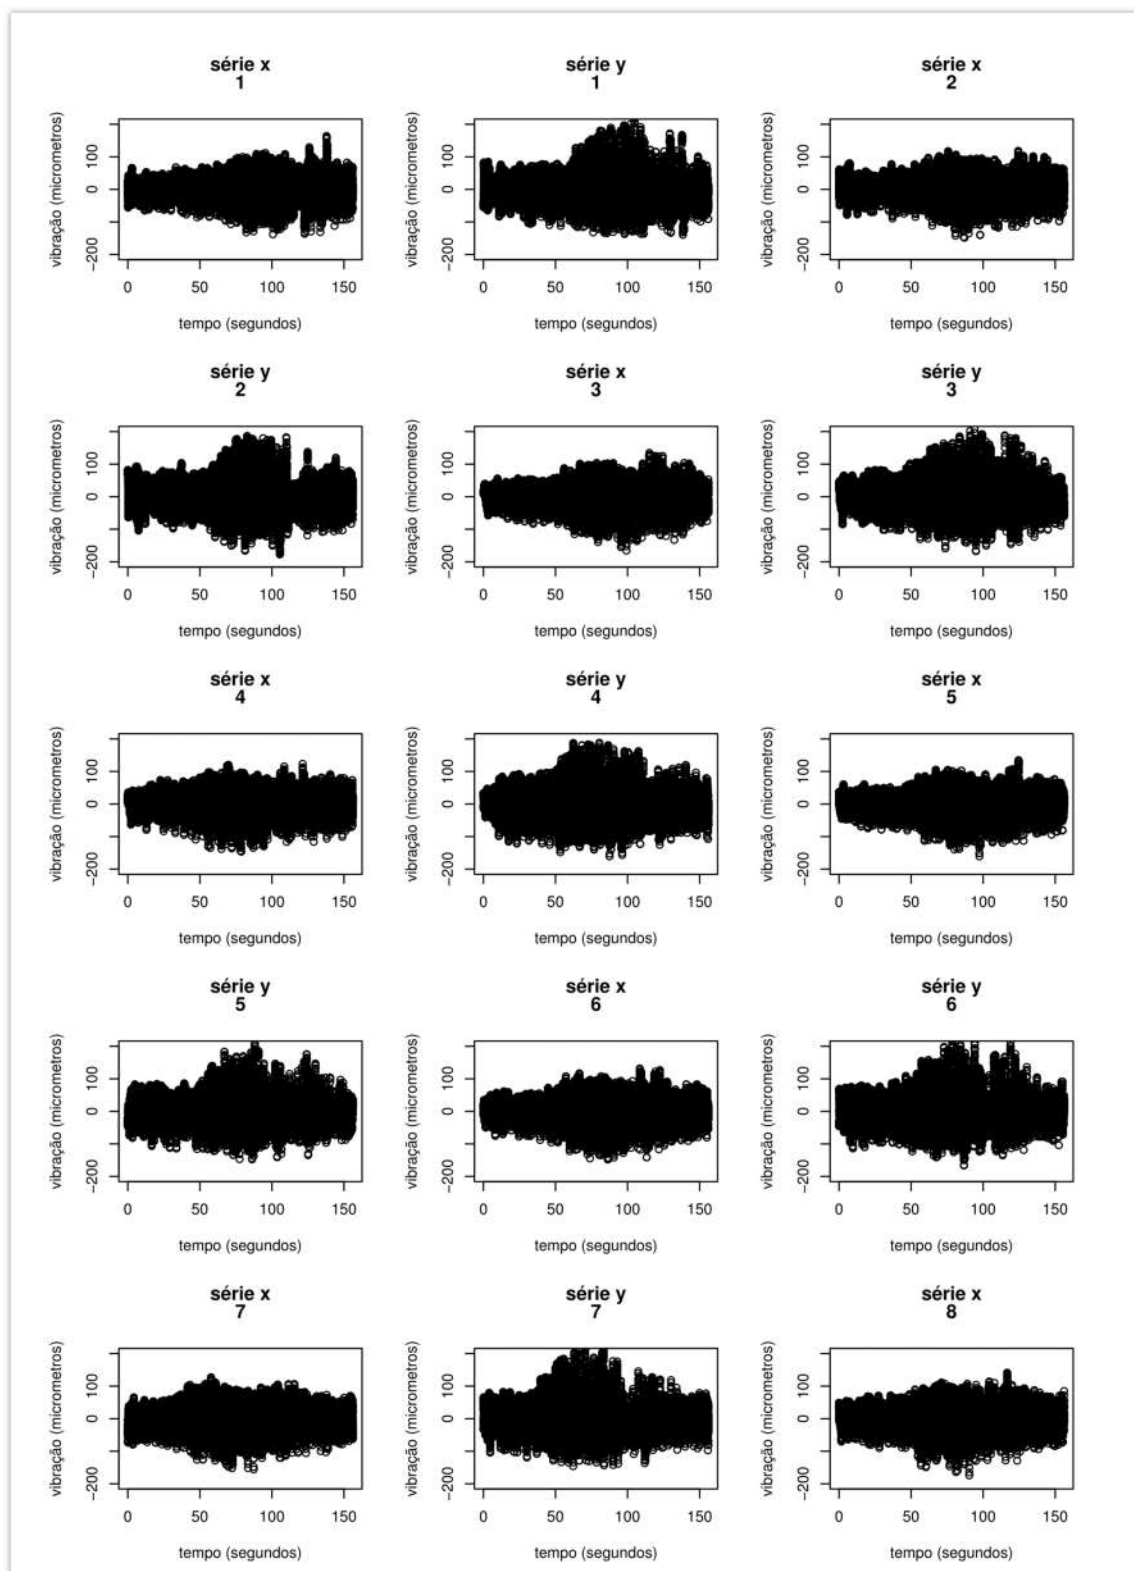
Anexo IV - Figura 23: Resíduos padronizados, FAC e teste de Ljung-Box do ARFIMA(1,0,3,0) parte 7



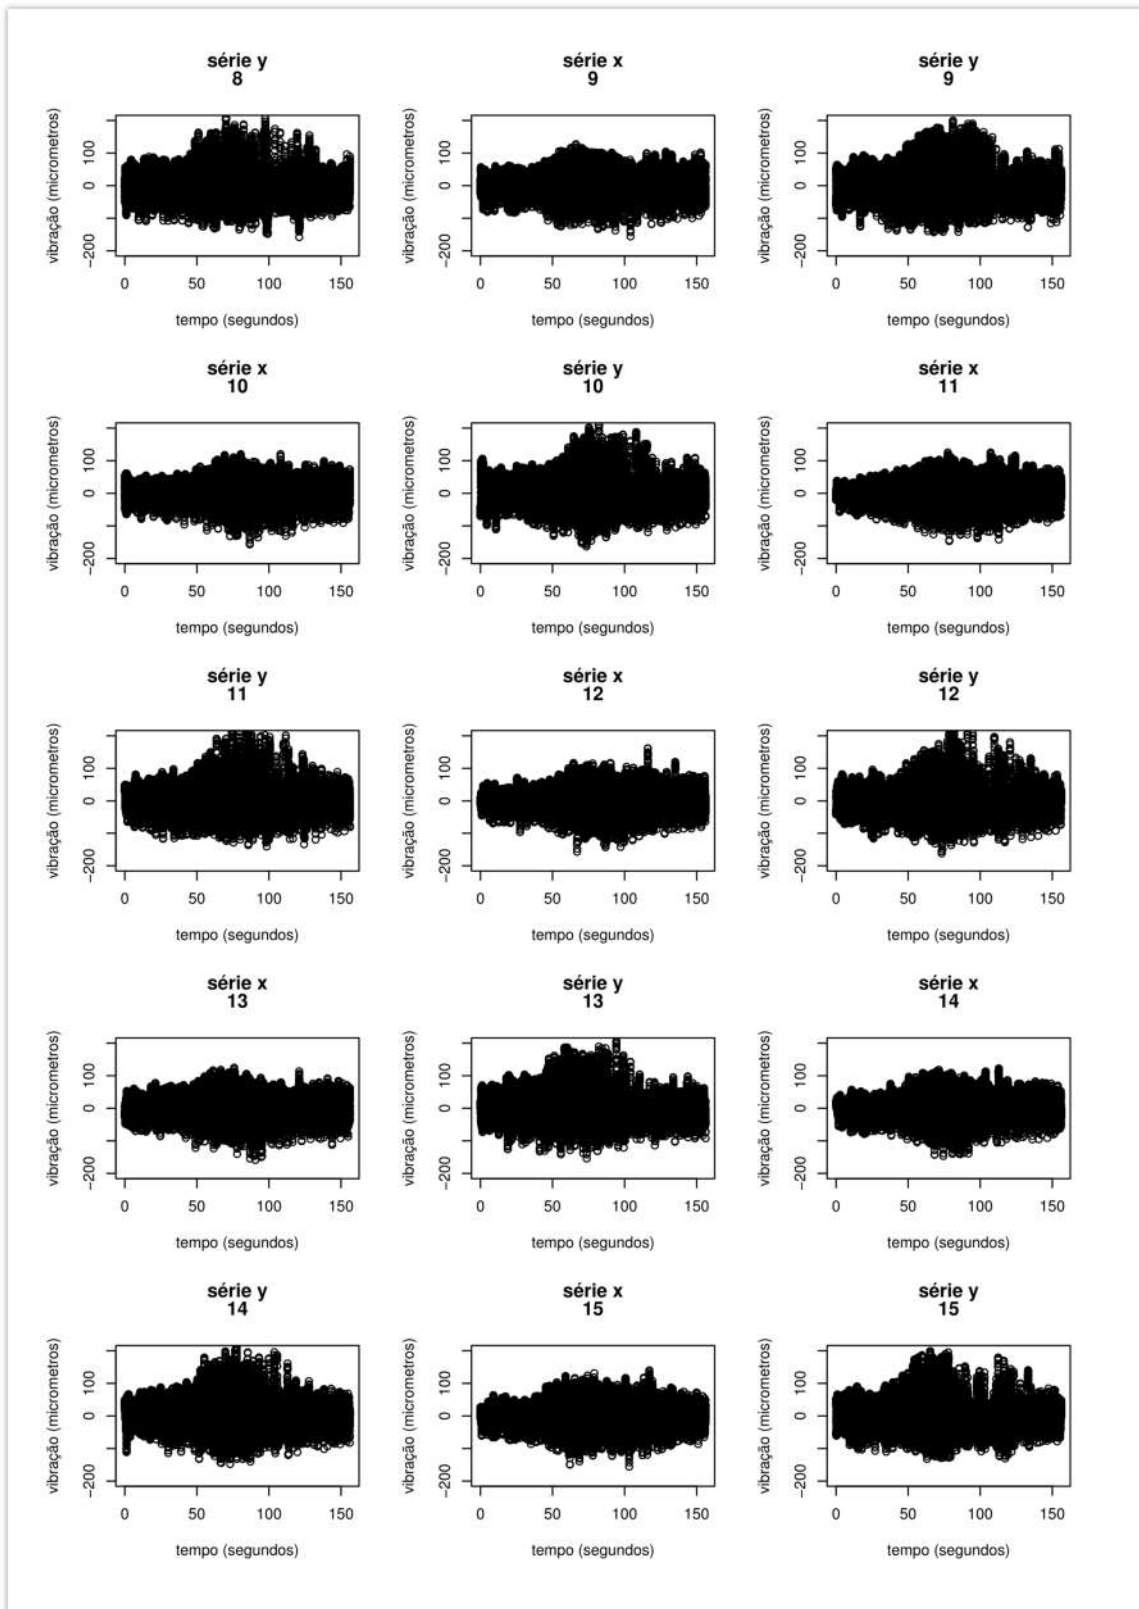
Anexo IV - Figura 24: Resíduos padronizados, FAC e teste de Ljung-Box do ARFIMA(1,0,3,0) parte 8

ANEXO V – ANÁLISE DOS DADOS TRANSIENTES ORIGINAIS

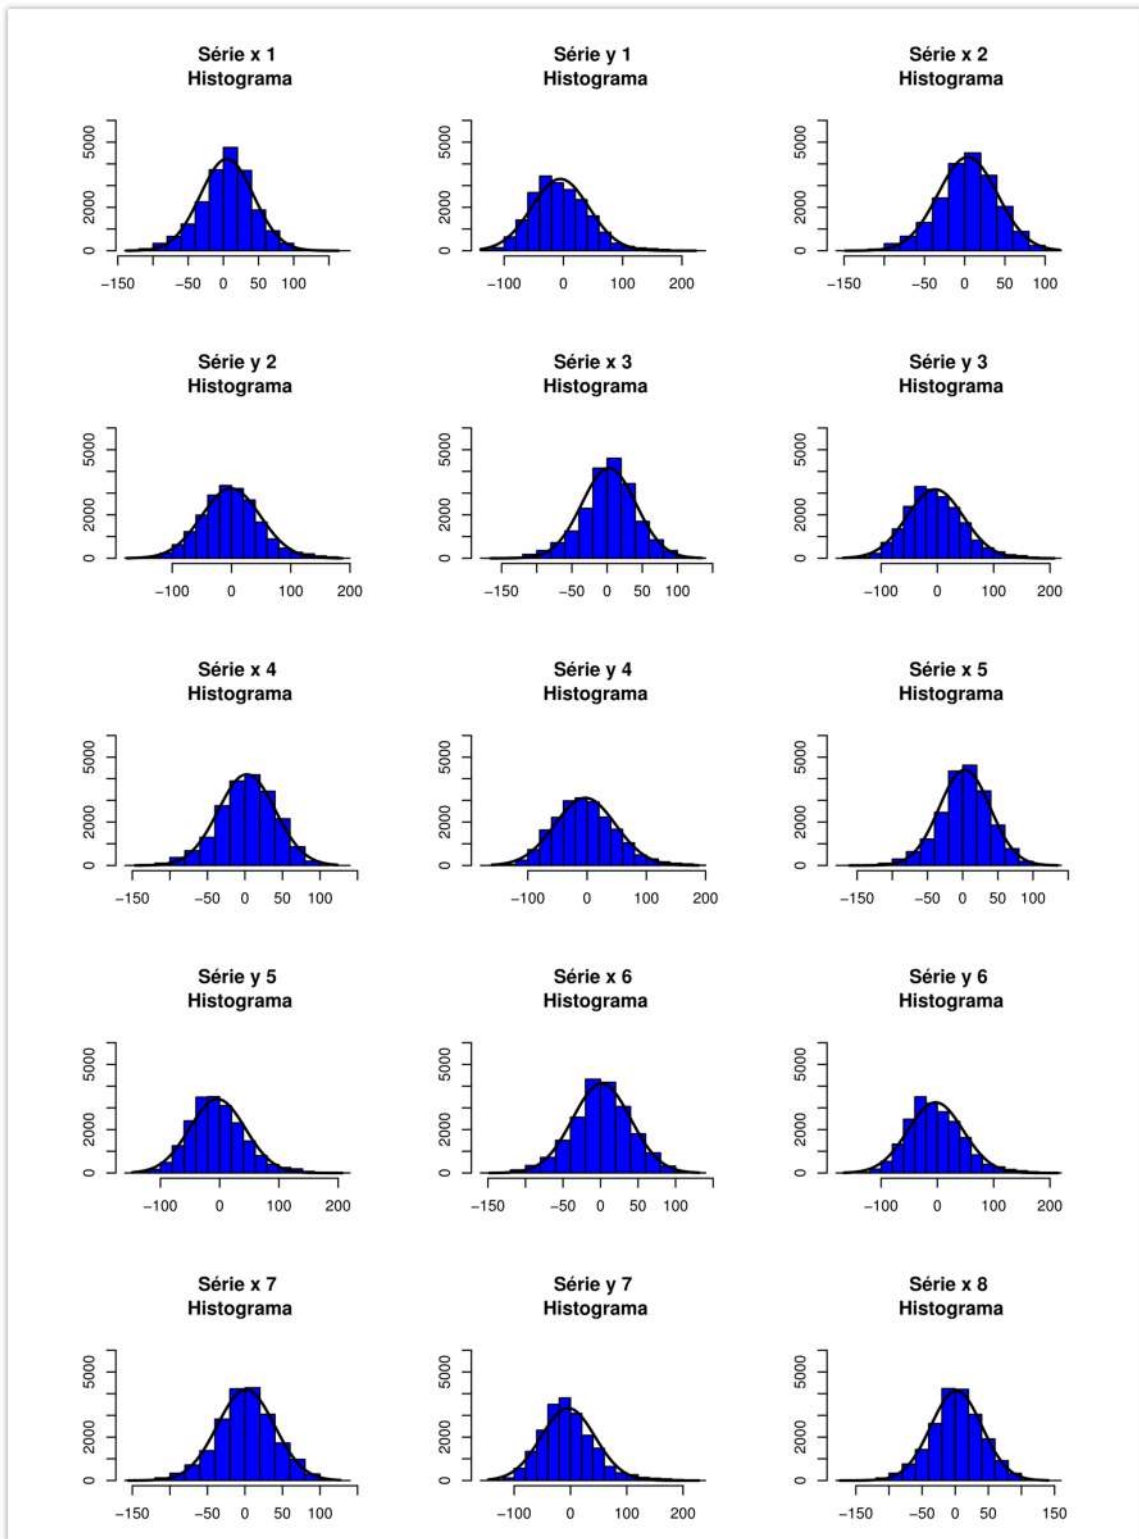
RESULTADOS DA ANÁLISE DESCRITIVA



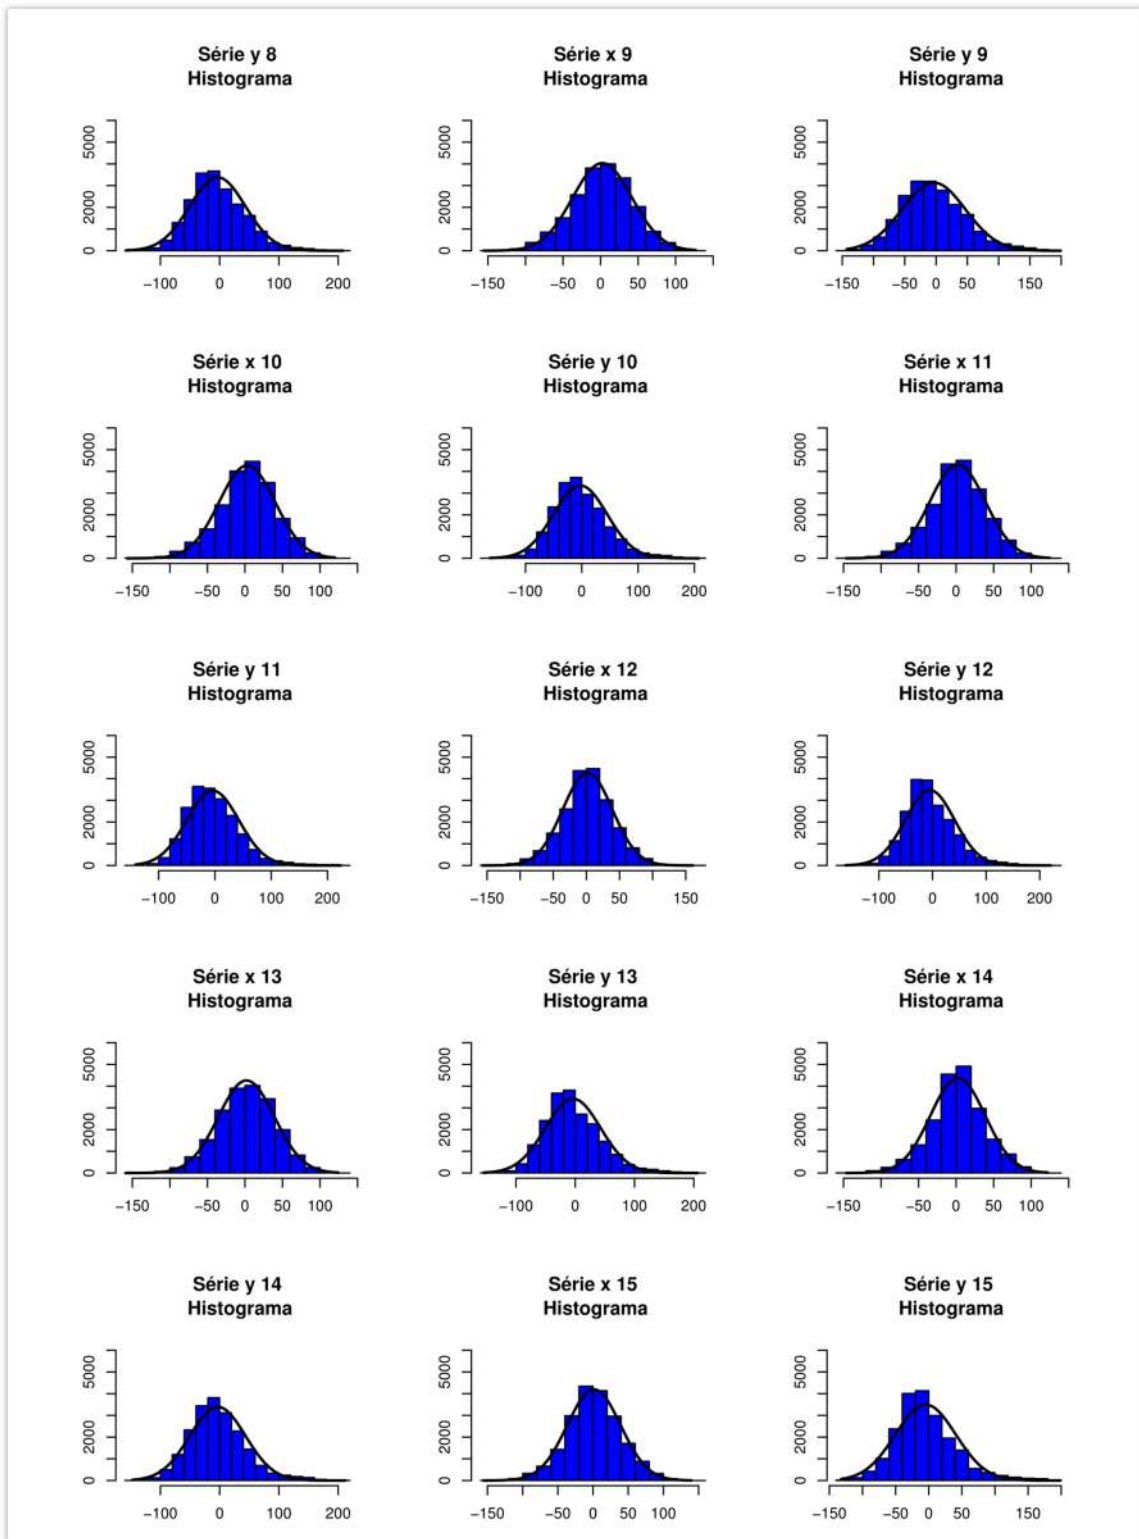
Anexo V- Figura 1: Séries transientes parte 1



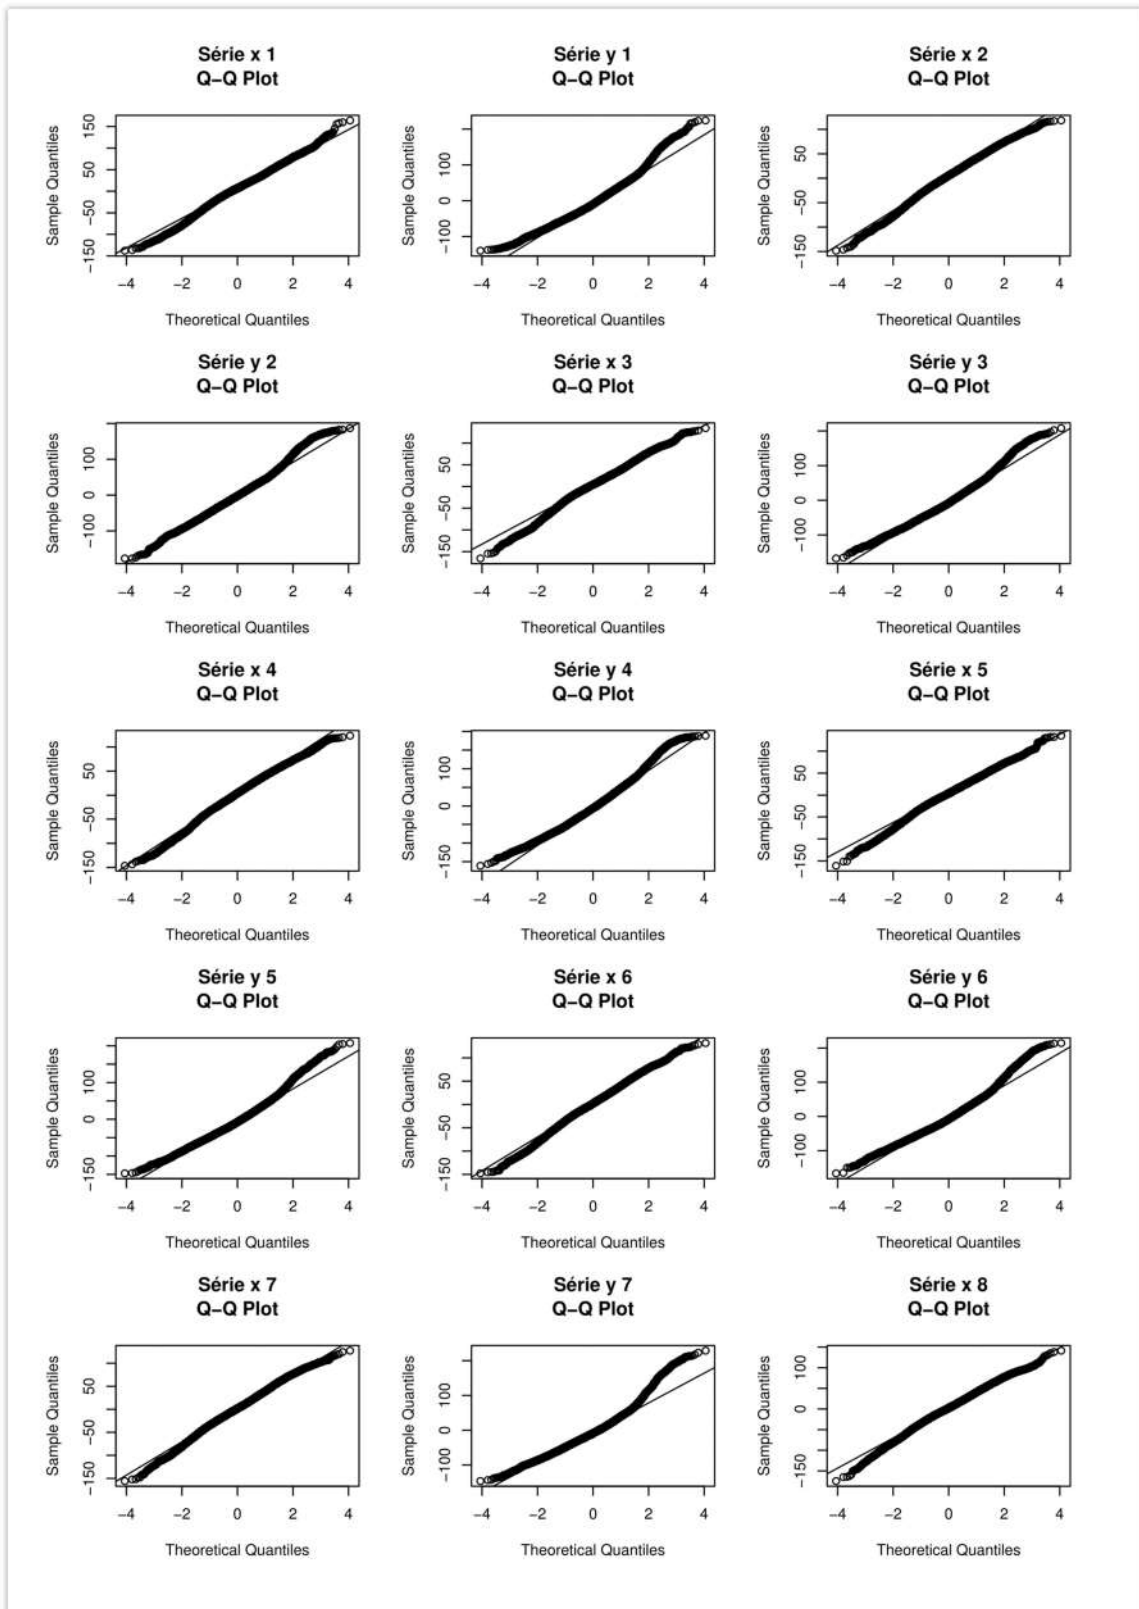
Anexo V- Figura 2: Séries transientes parte 2



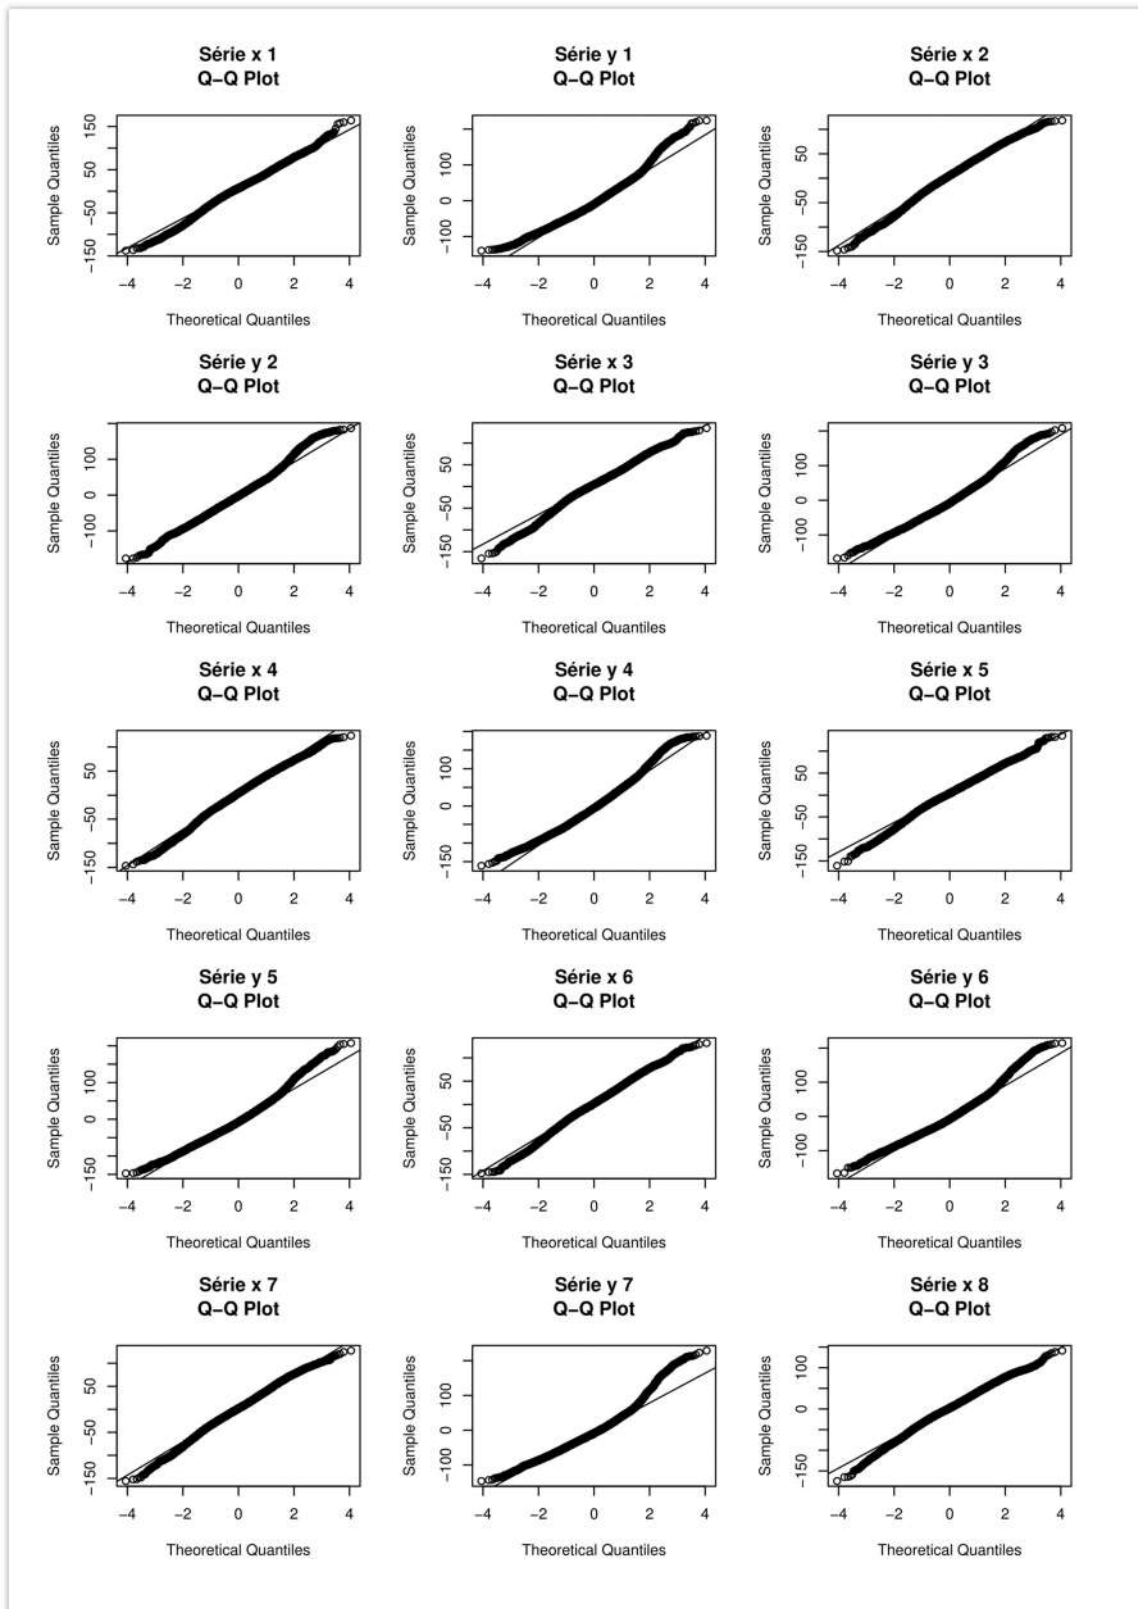
Anexo V- Figura 3: Histograma das séries transientes parte 1



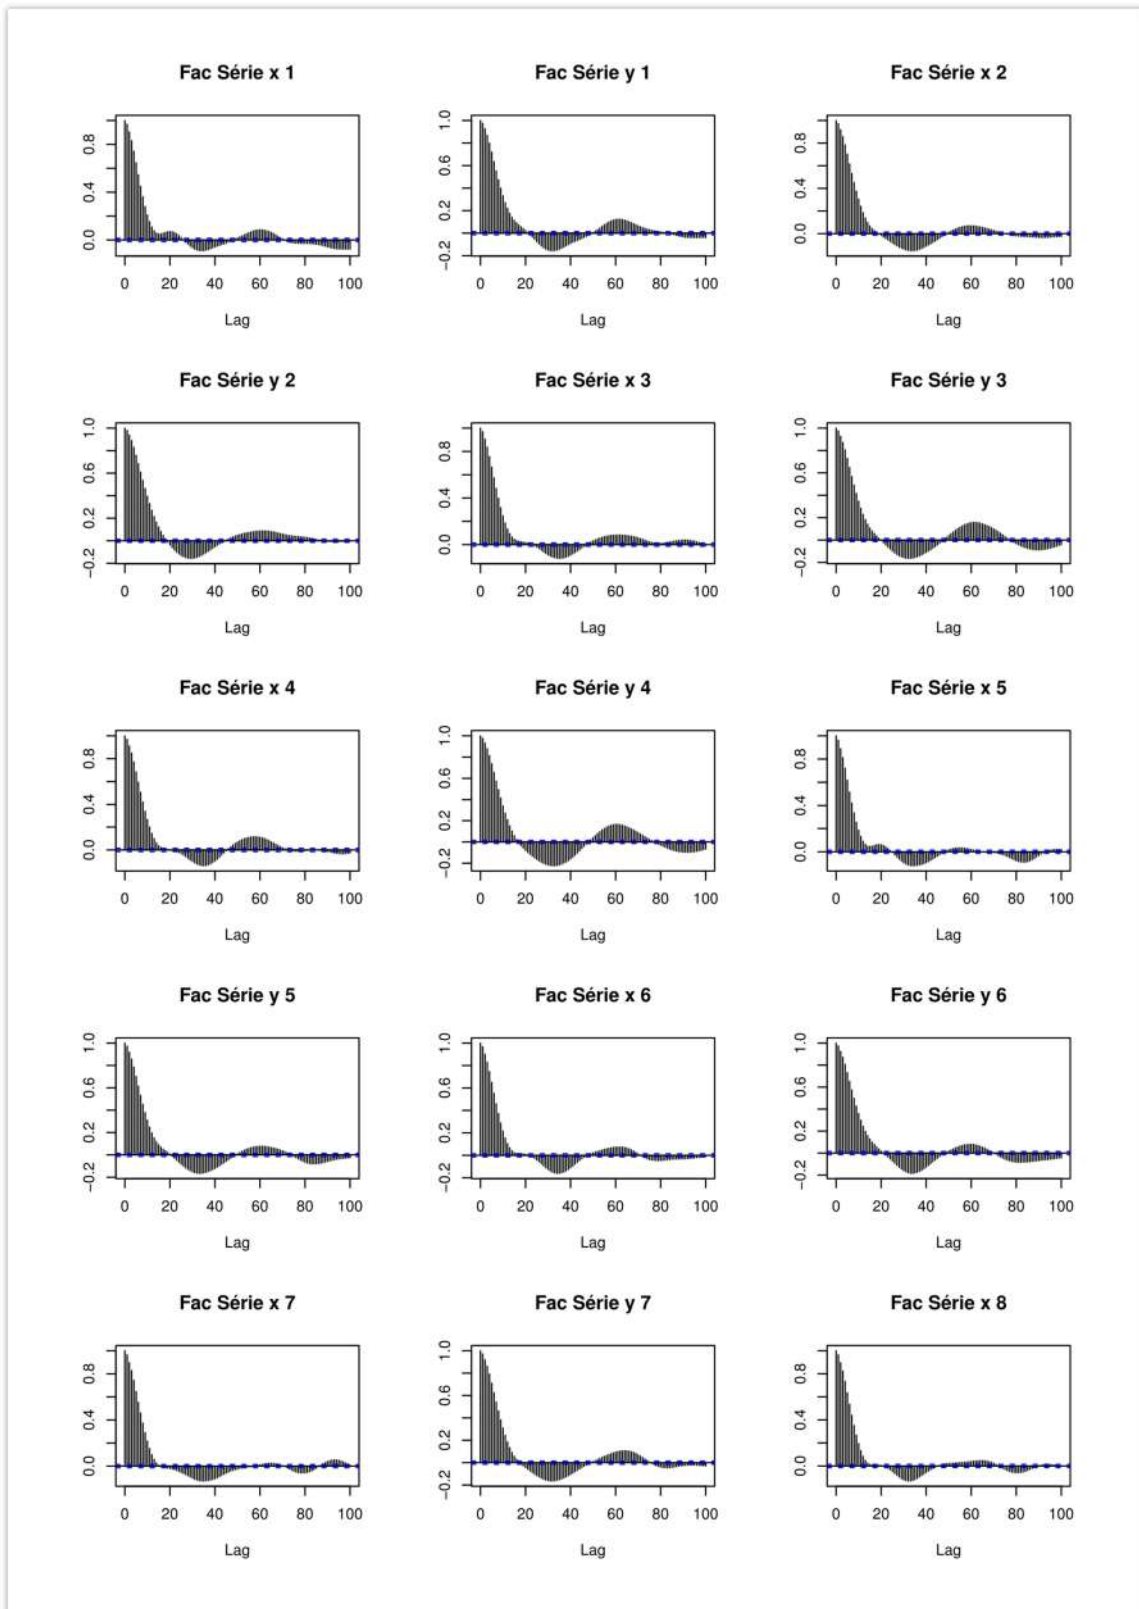
Anexo V- Figura 4: Histograma das séries transientes parte 2



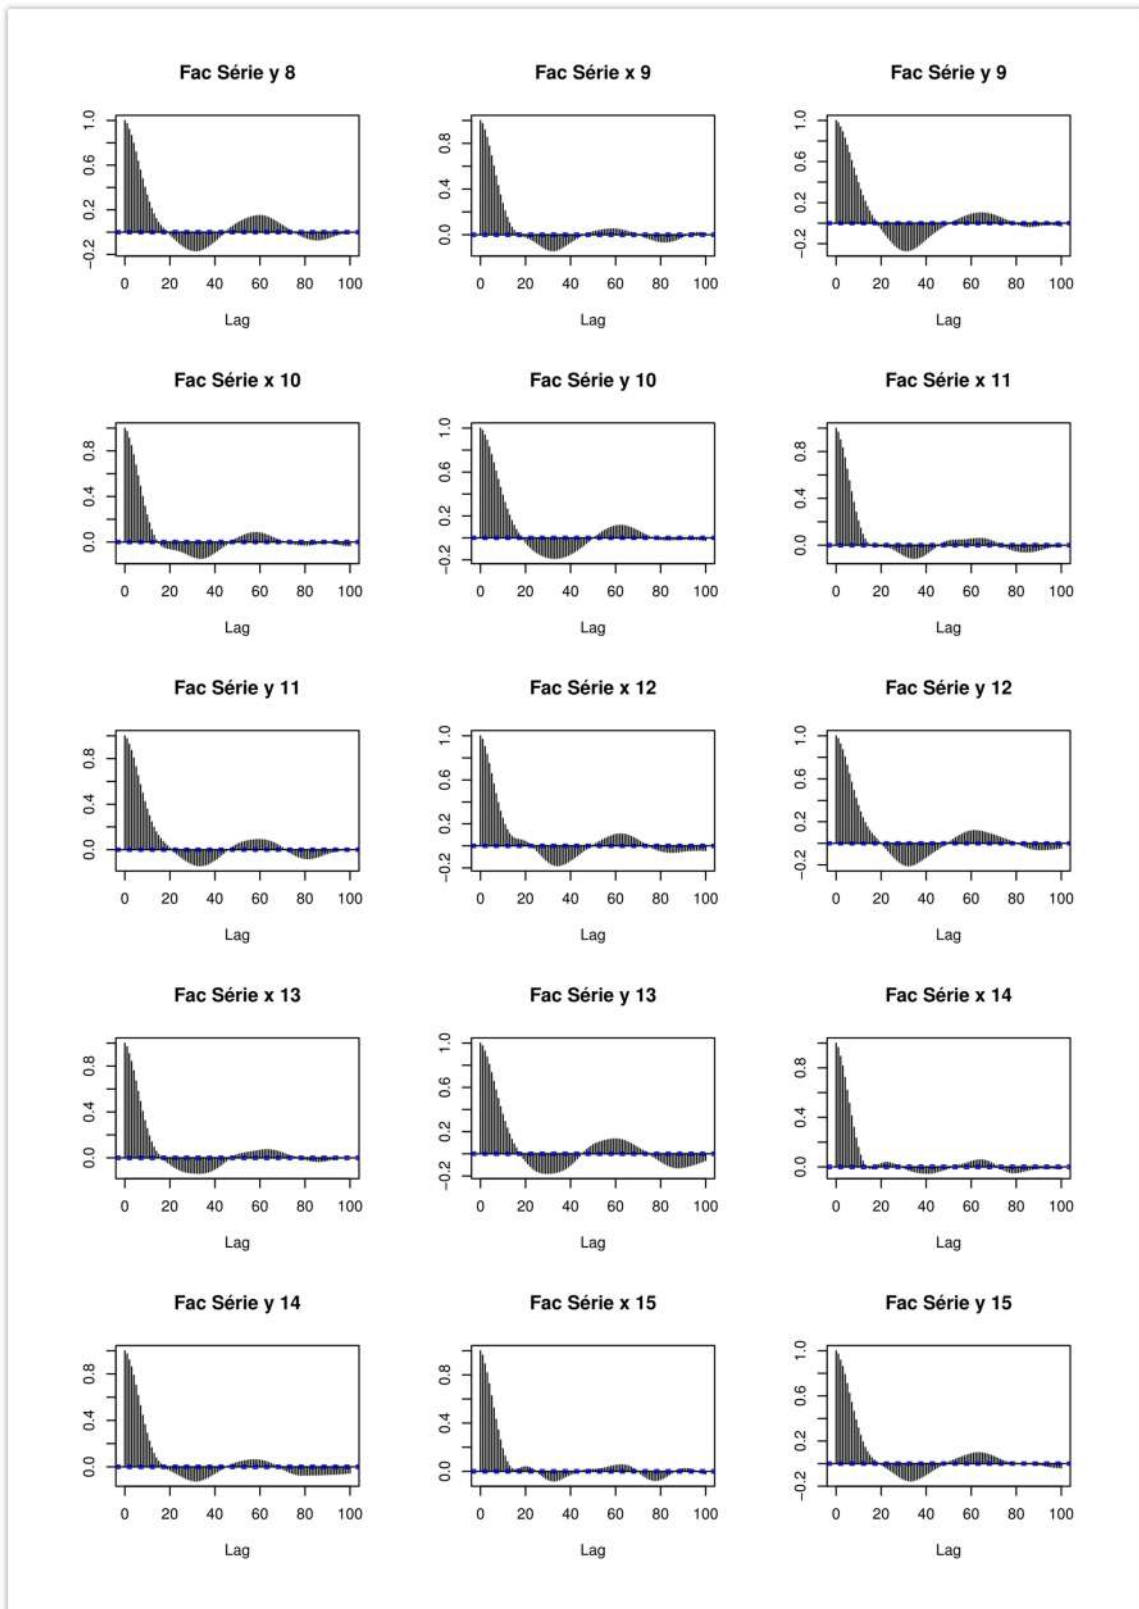
Anexo V- Figura 5: Gráfico dos quantis das séries transientes parte 1



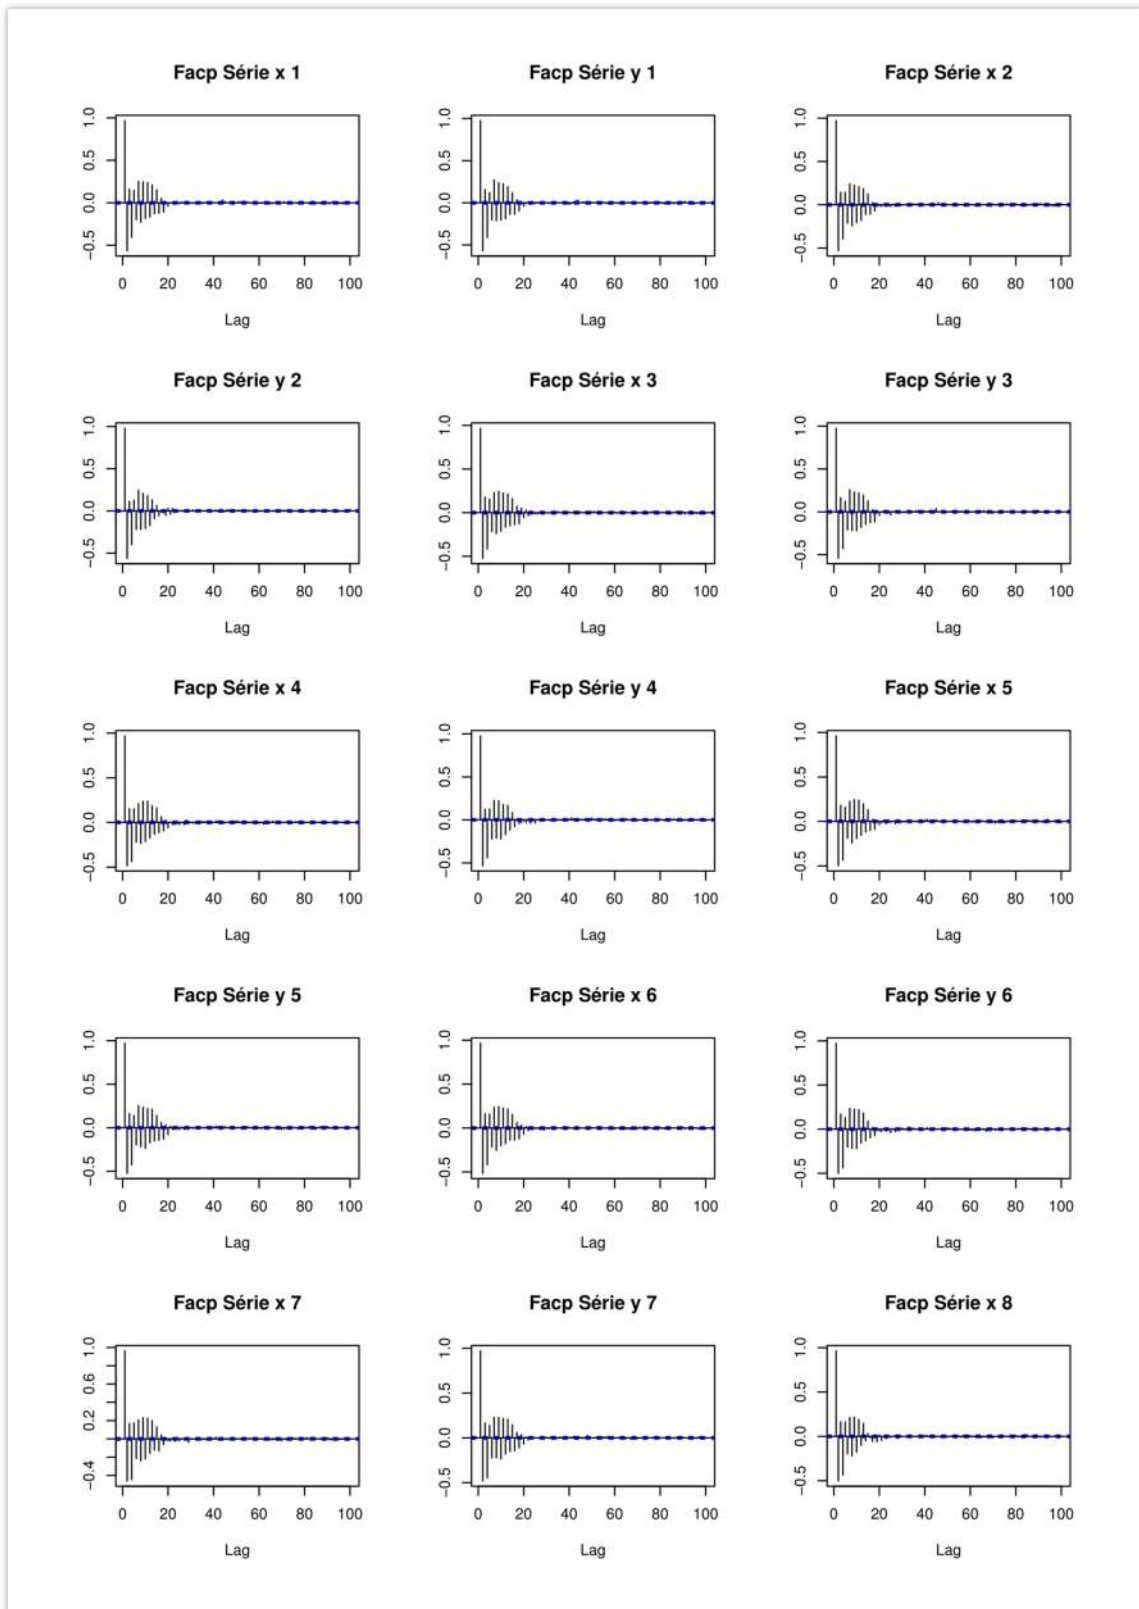
Anexo V- Figura 6: Gráfico dos quantis das séries transientes parte 2



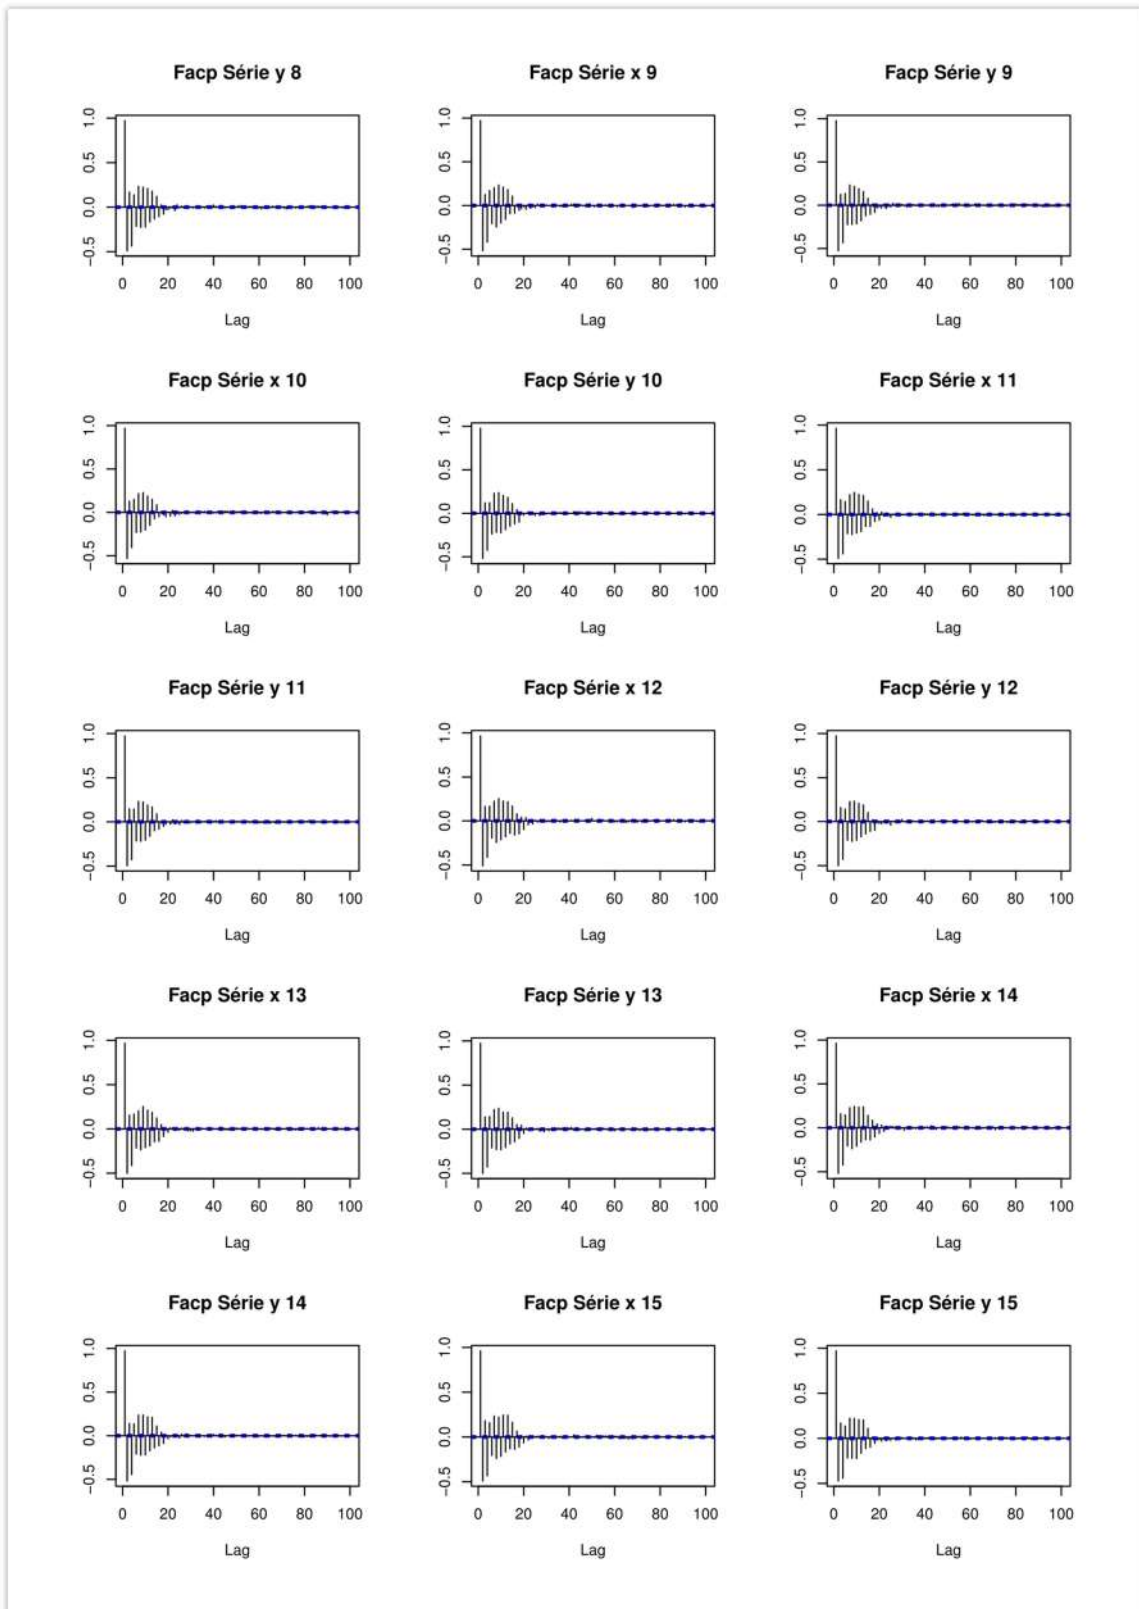
Anexo V- Figura 7: FAC das séries transientes parte 1



Anexo V- Figura 8: FAC das séries transientes parte 2



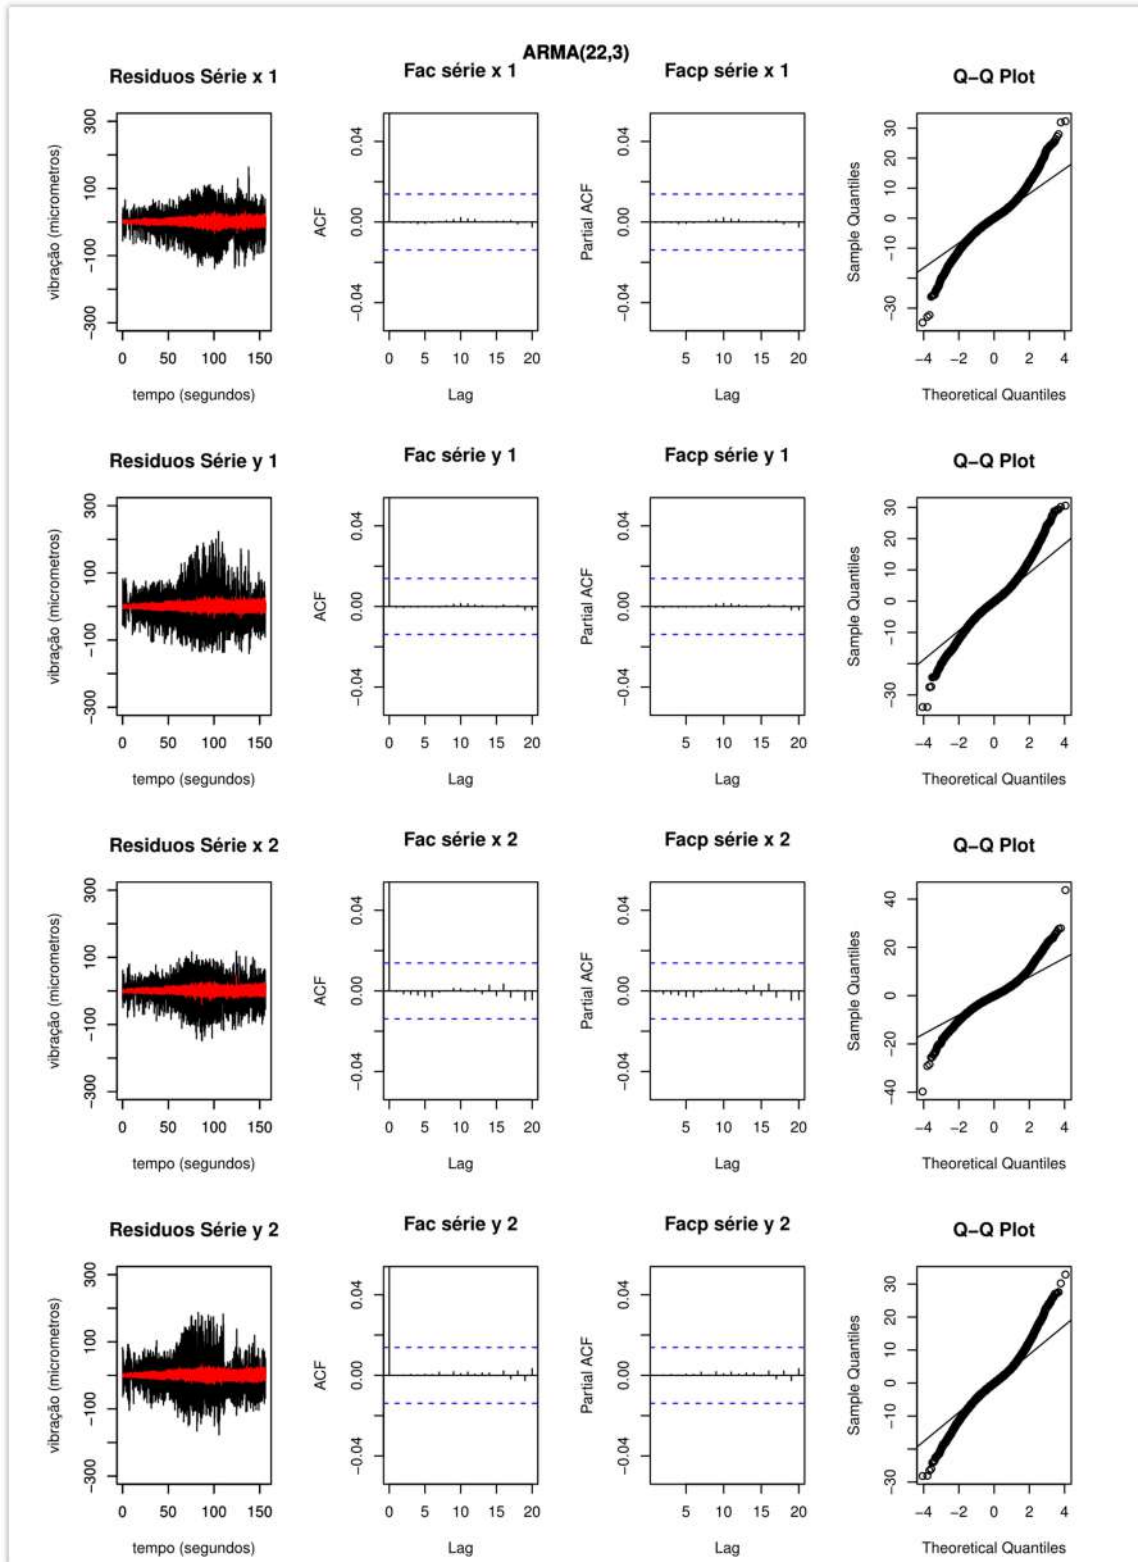
Anexo V- Figura 9: FACP das séries transientes parte 1



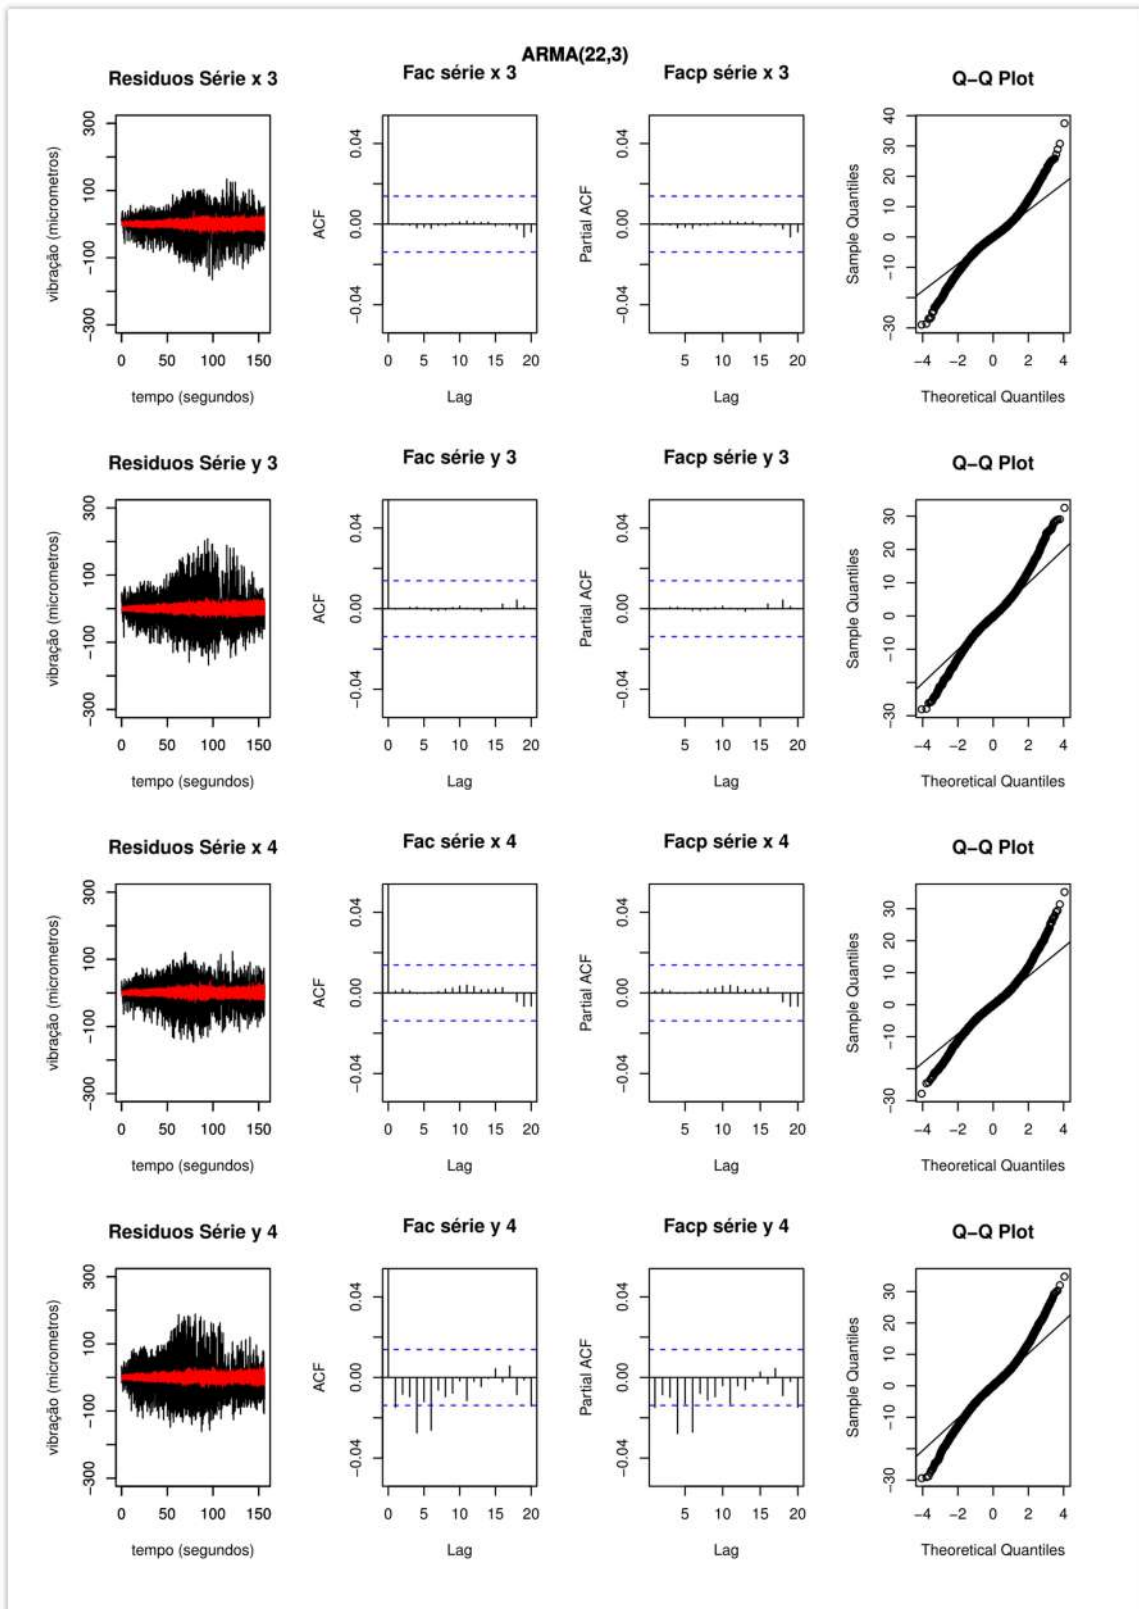
Anexo V- Figura 10: FACP das séries transientes parte 2

ANEXO VI – APLICAÇÃO DOS MODELOS NAS SÉRIES TRANSIENTES

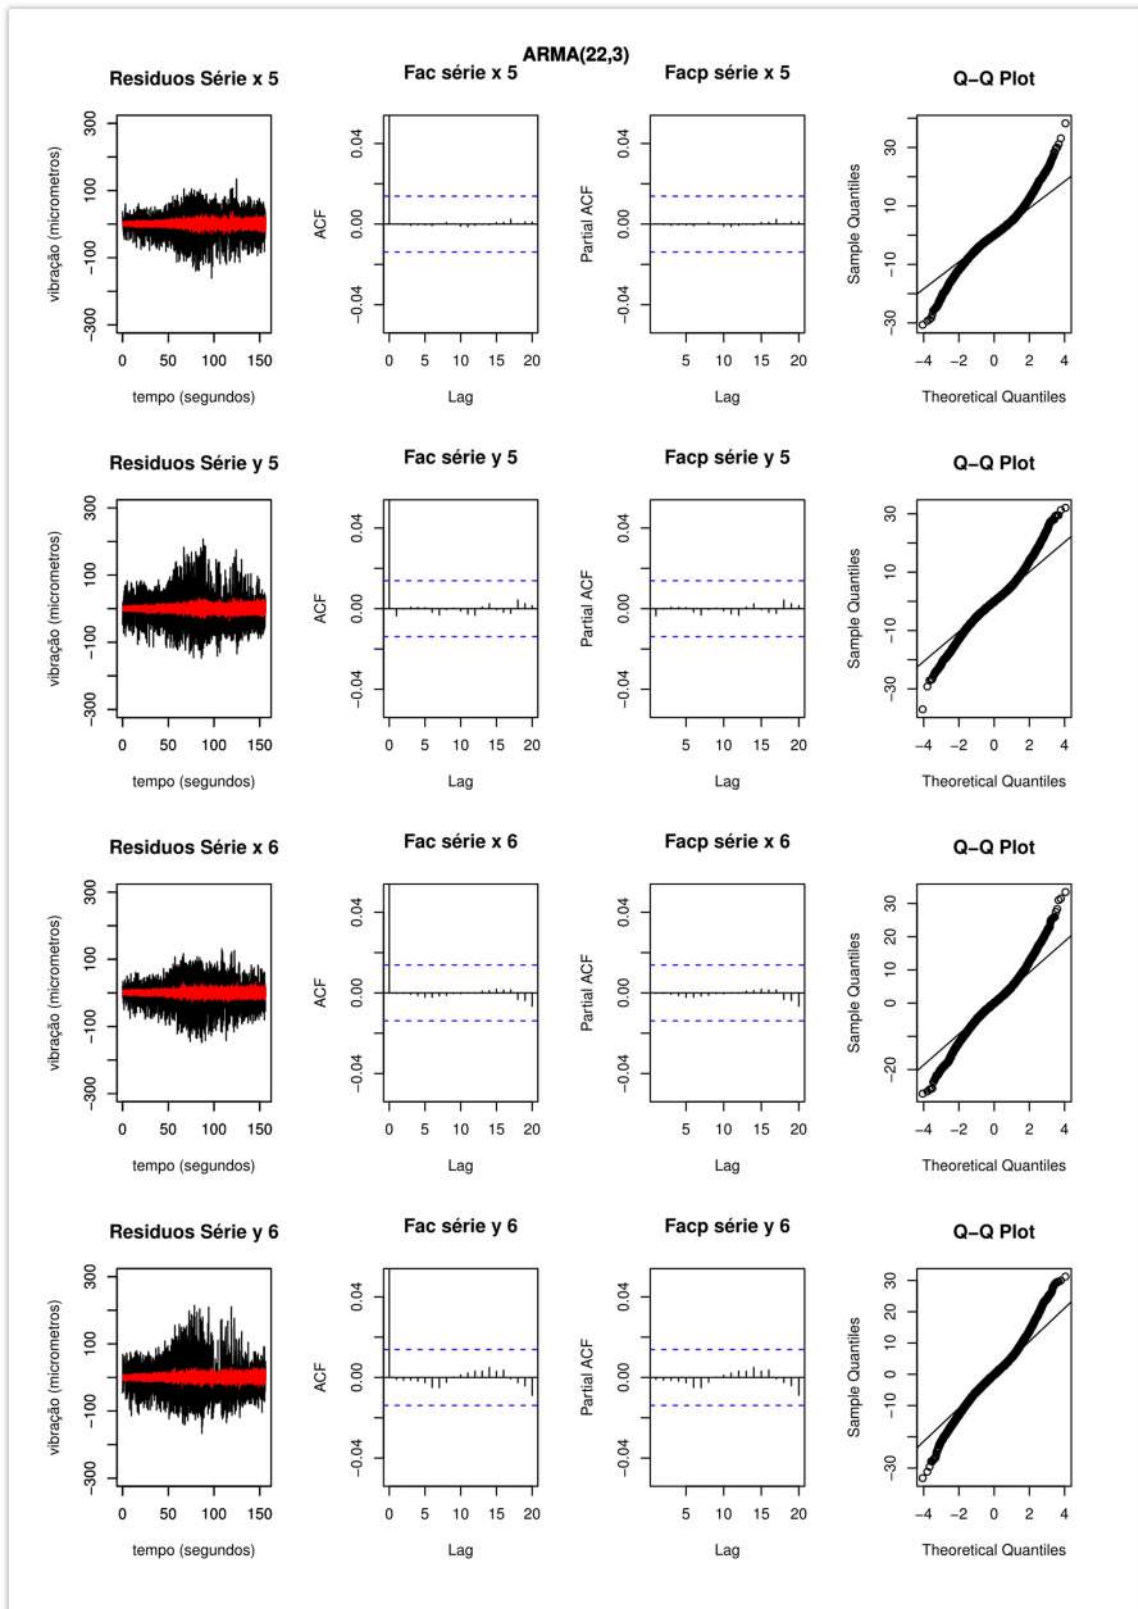
RESULTADOS DA APLICAÇÃO DOS MODELOS LINEARES



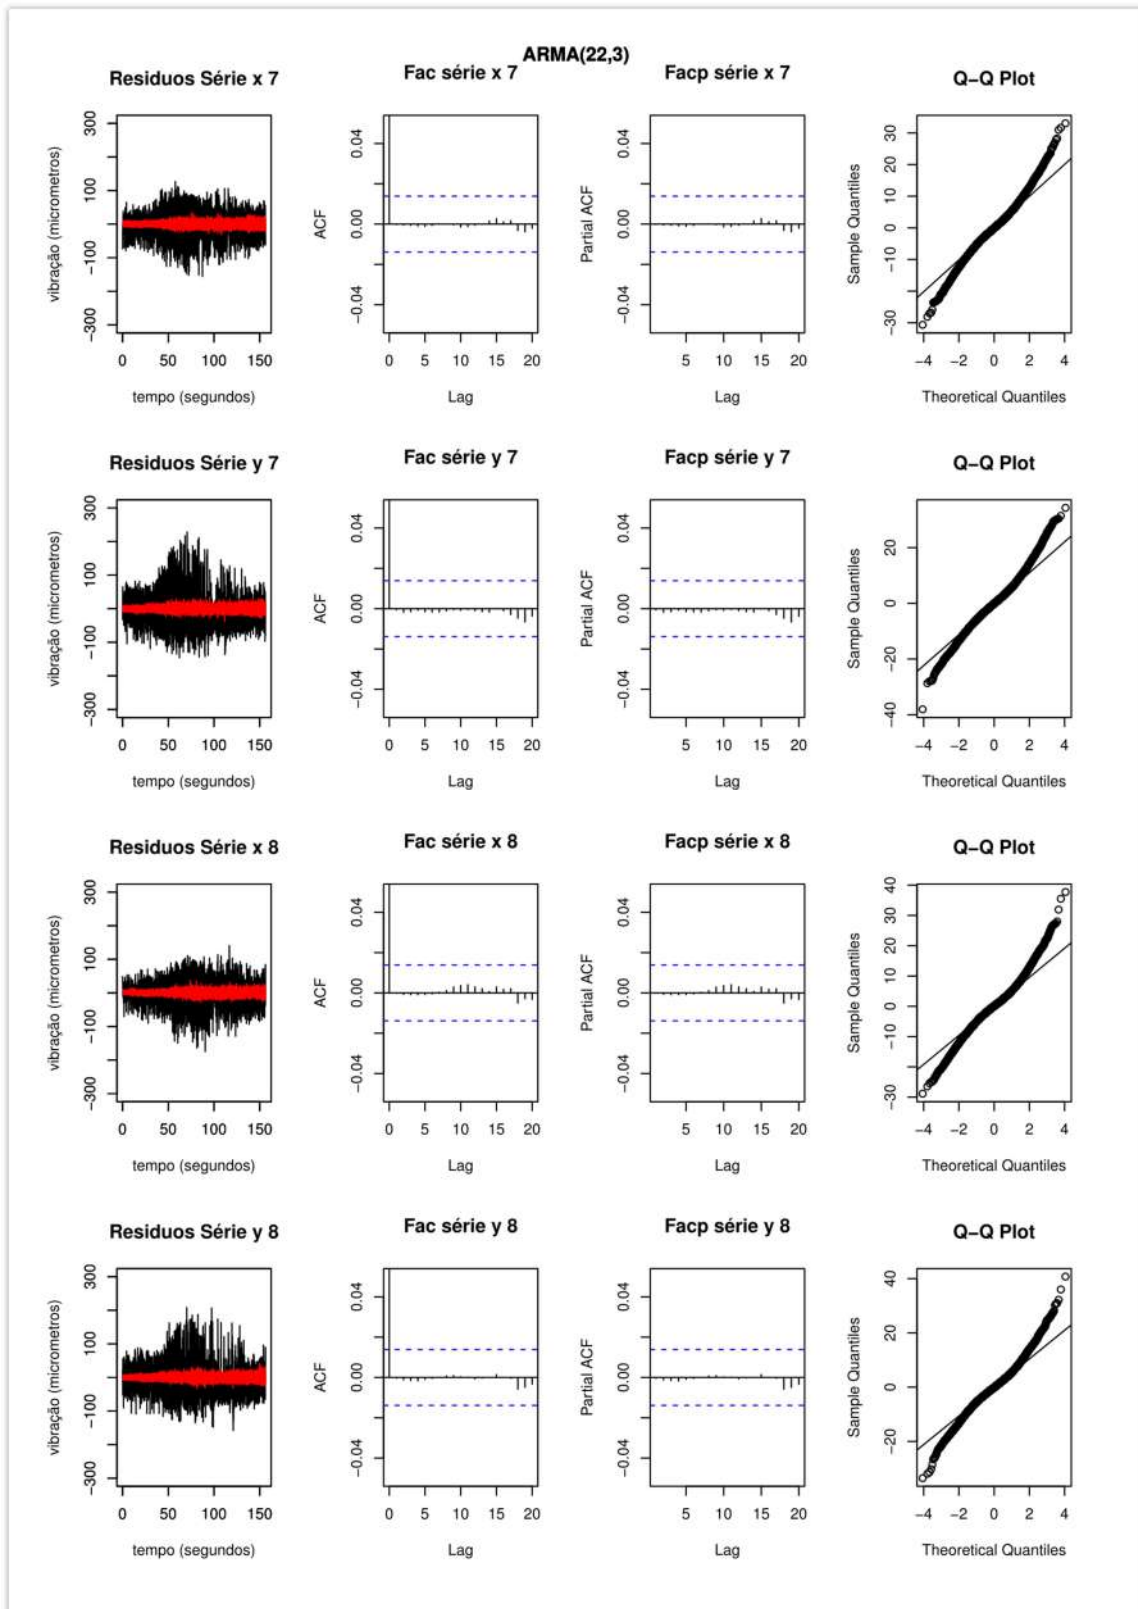
Anexo VI - Figura 1: ARMA(22,3) para as séries transientes parte 1



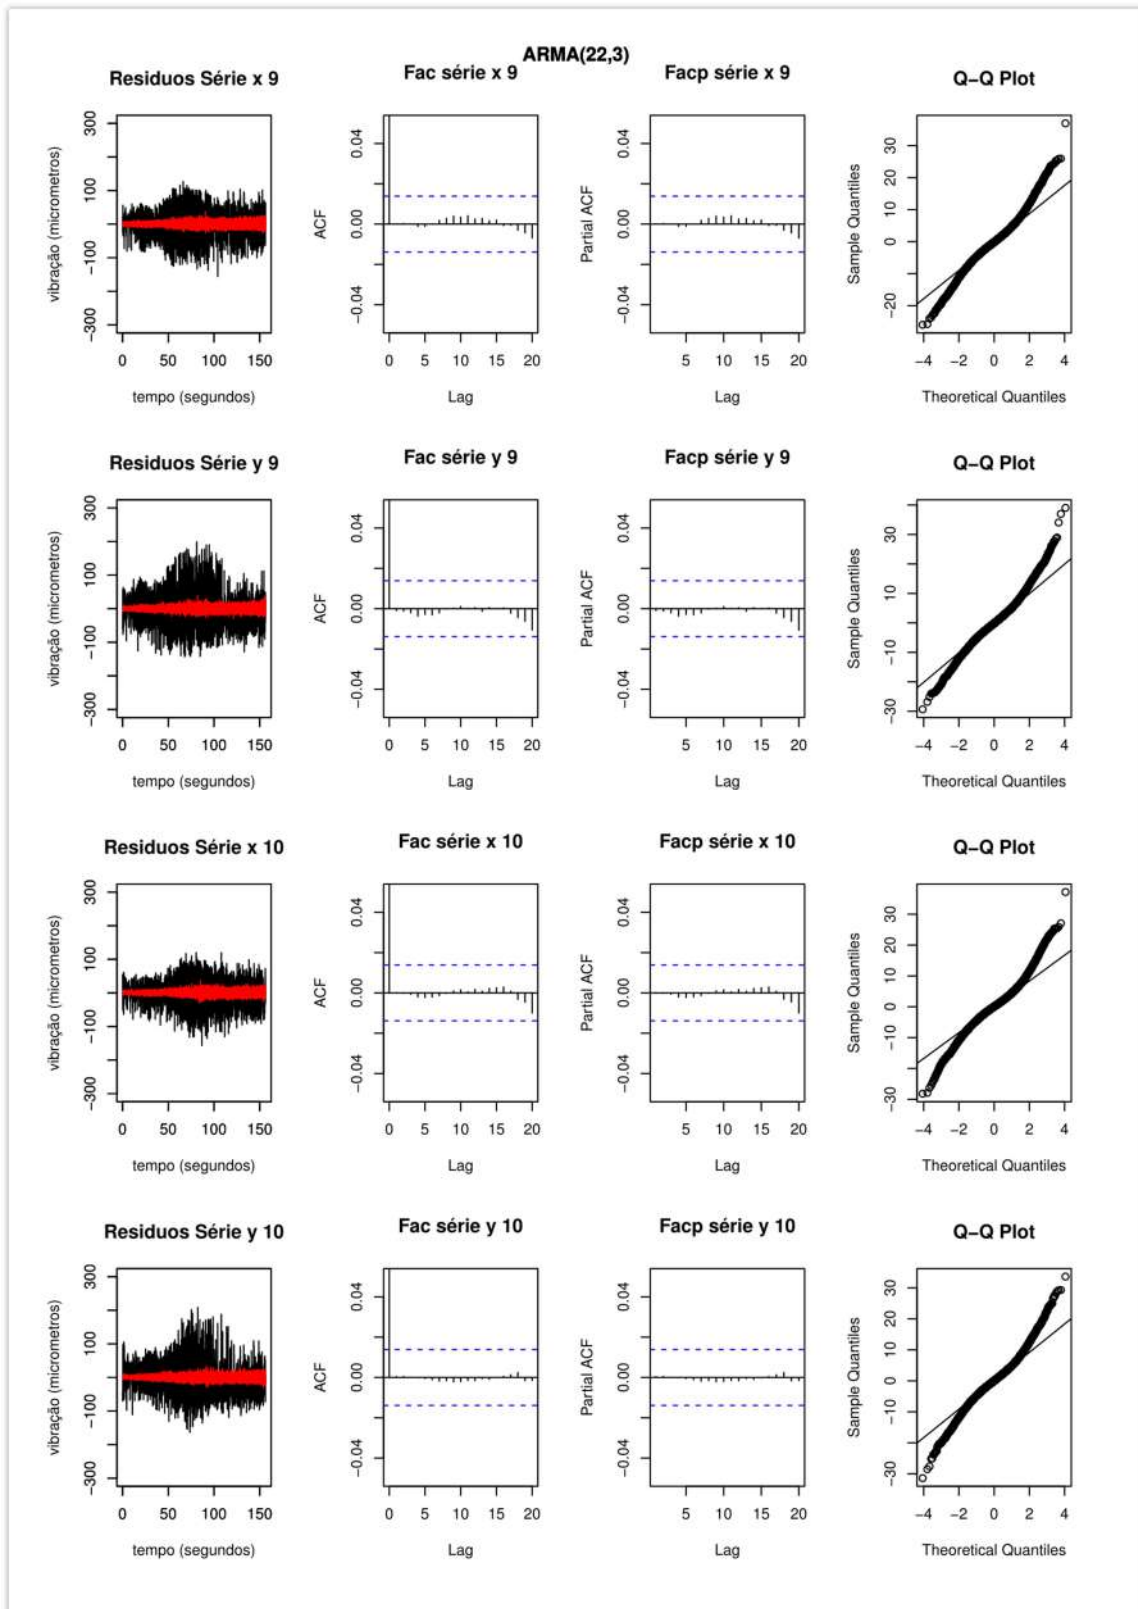
Anexo VI - Figura 2: ARMA(22,3) para as séries transientes parte 2



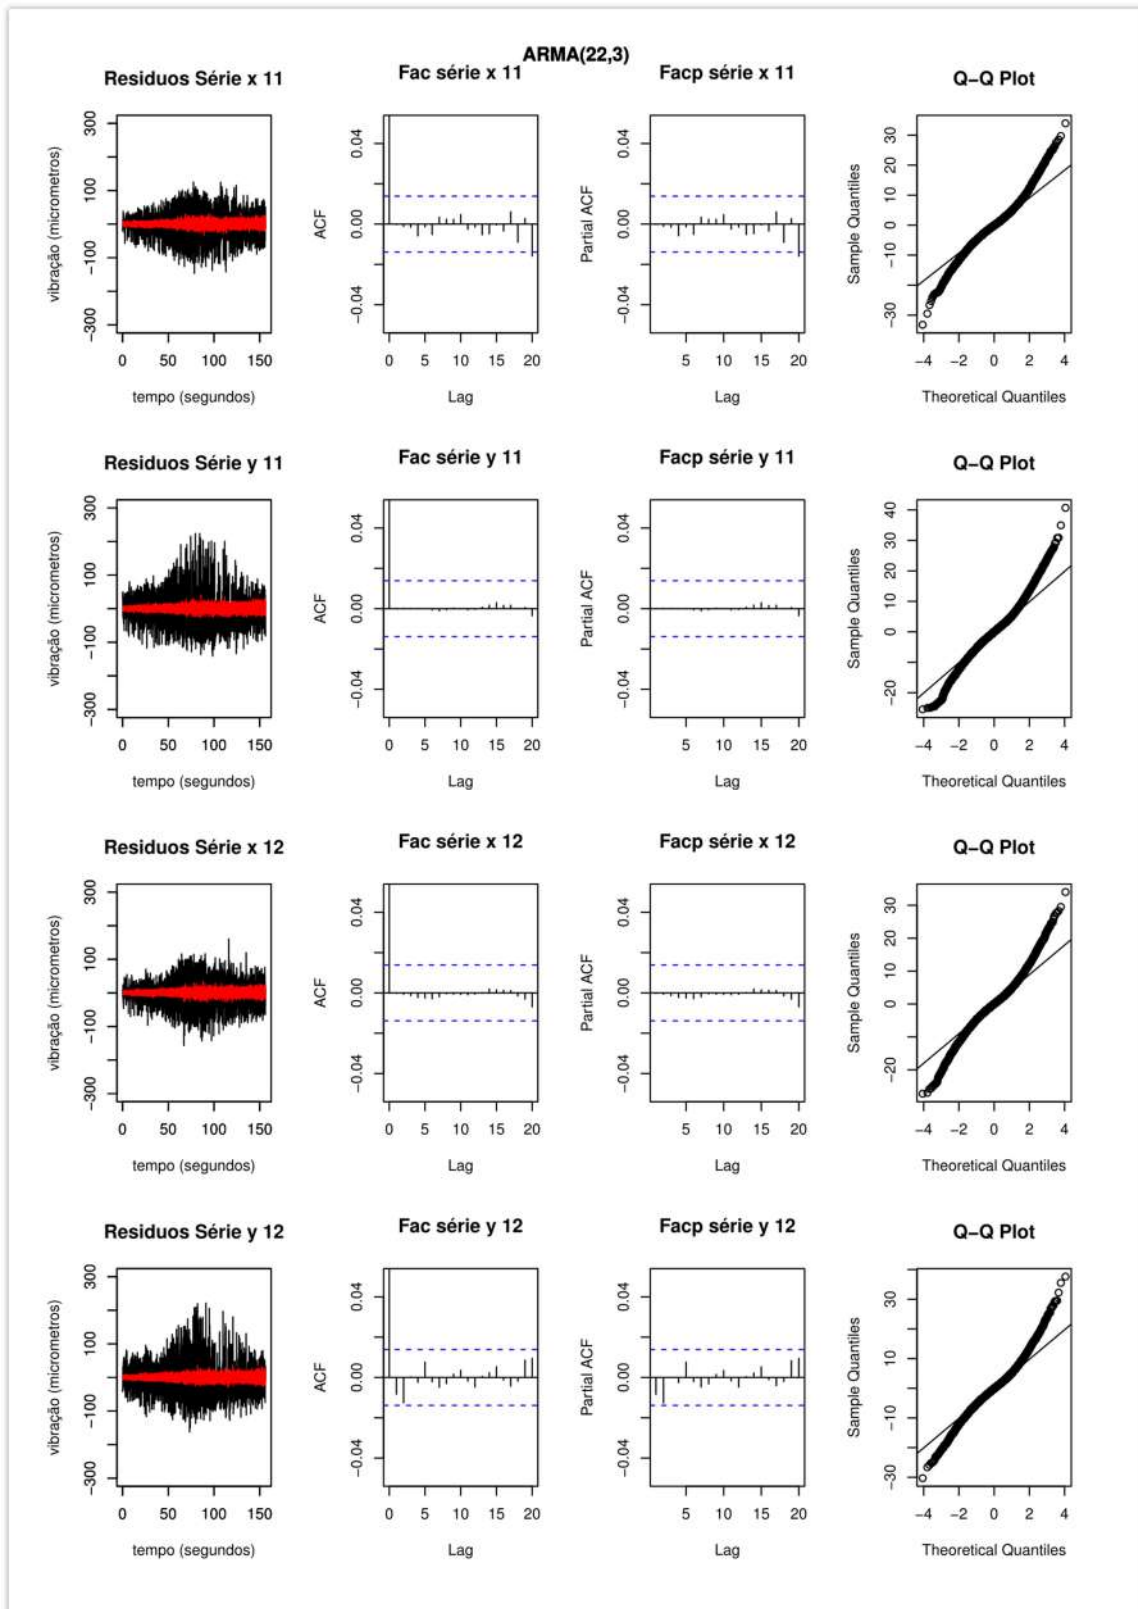
Anexo VI - Figura 3: ARMA(22,3) para as séries transientes parte 3



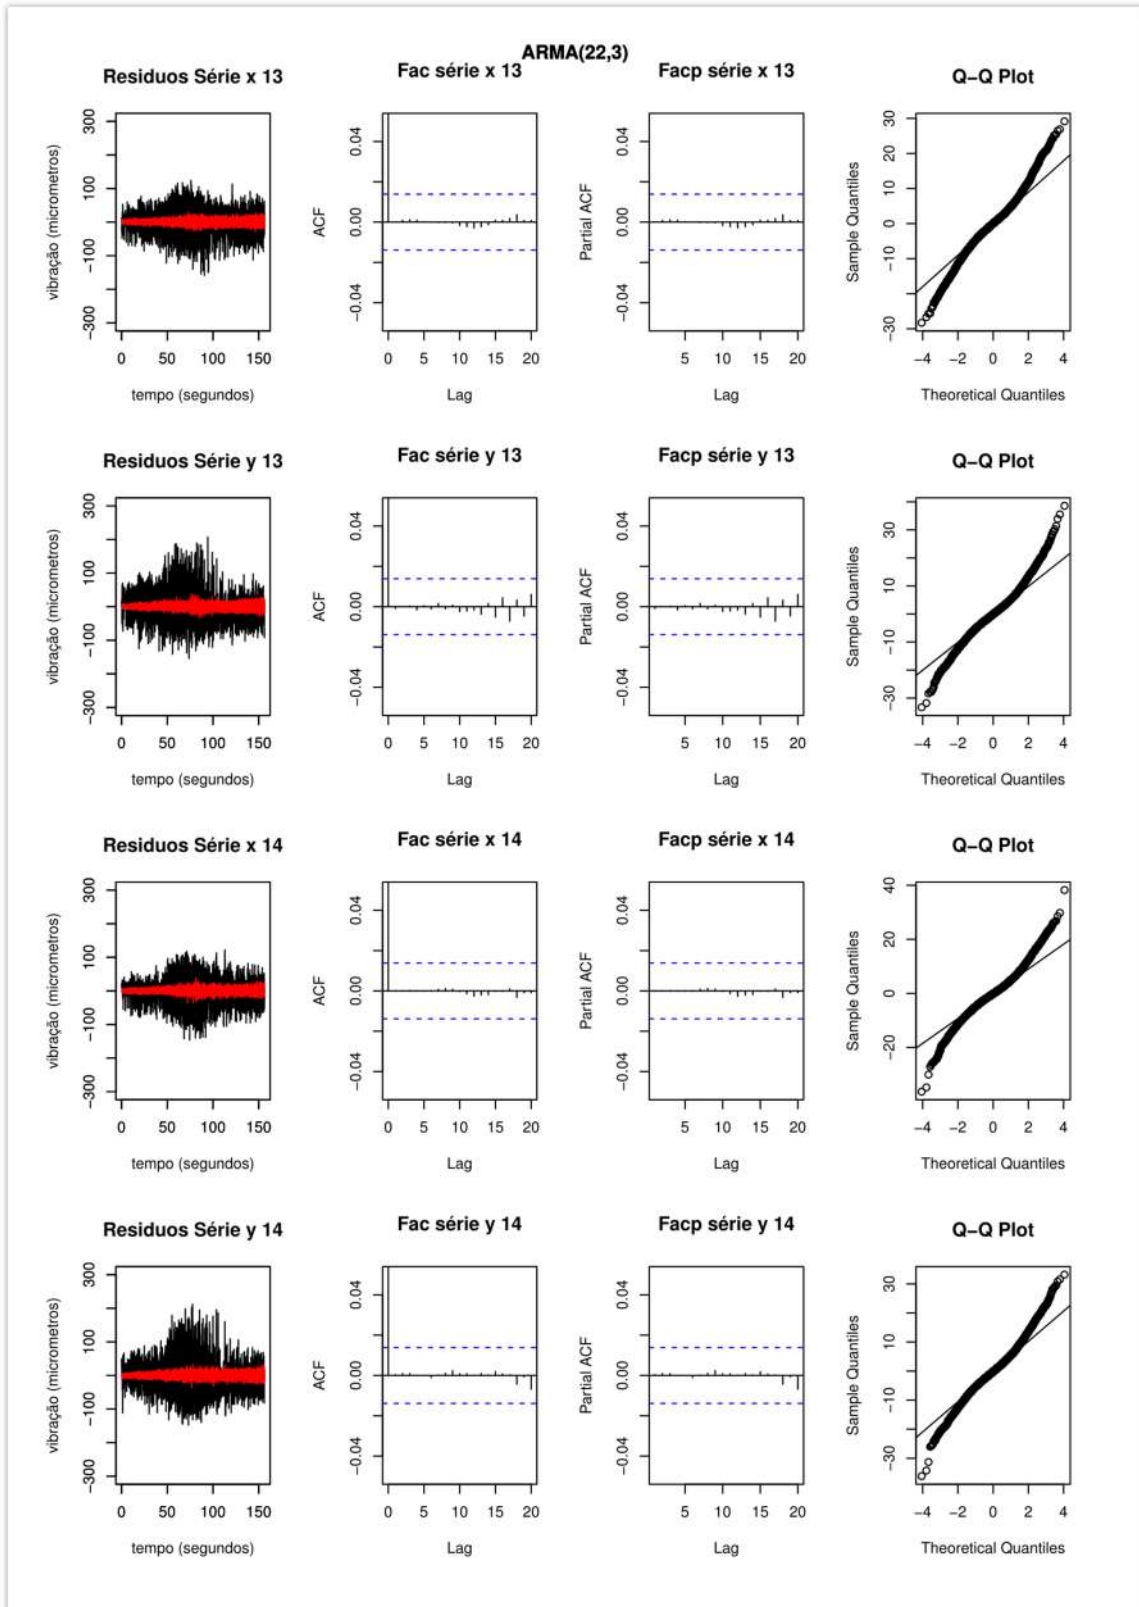
Anexo VI - Figura 4: ARMA(22,3) para as séries transientes parte 4



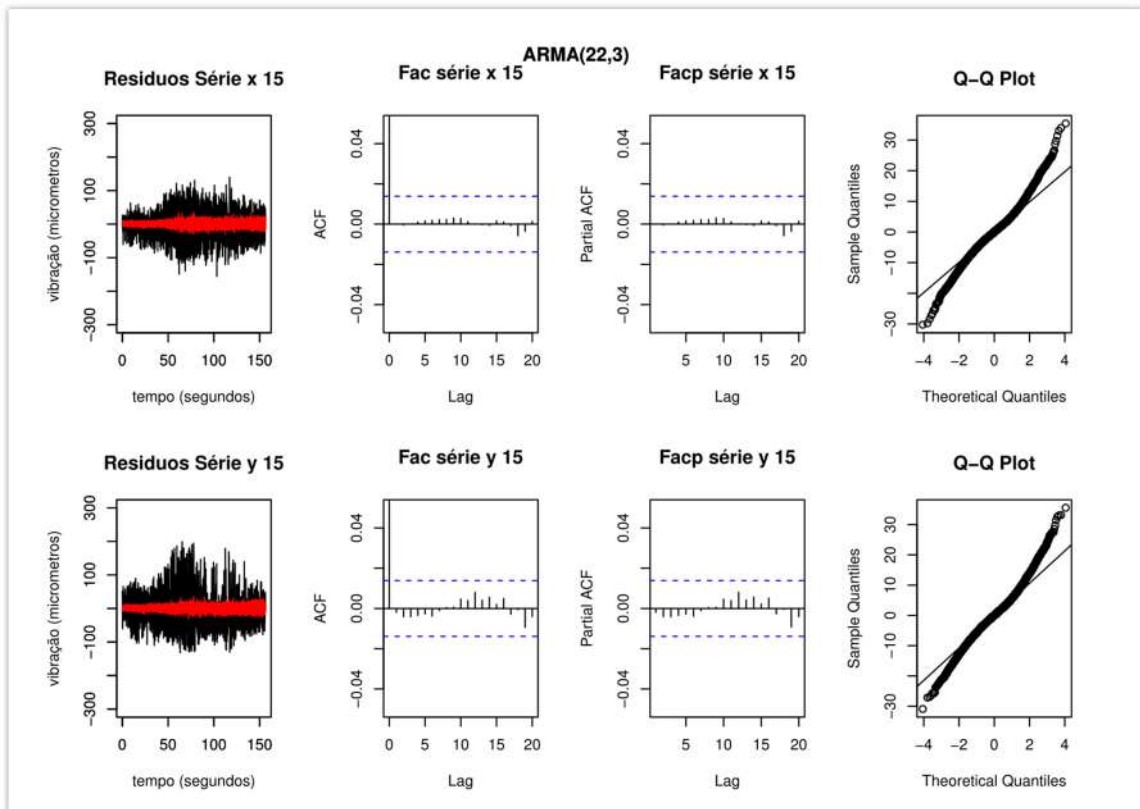
Anexo VI - Figura 5: ARMA(22,3) para as séries transientes parte 5



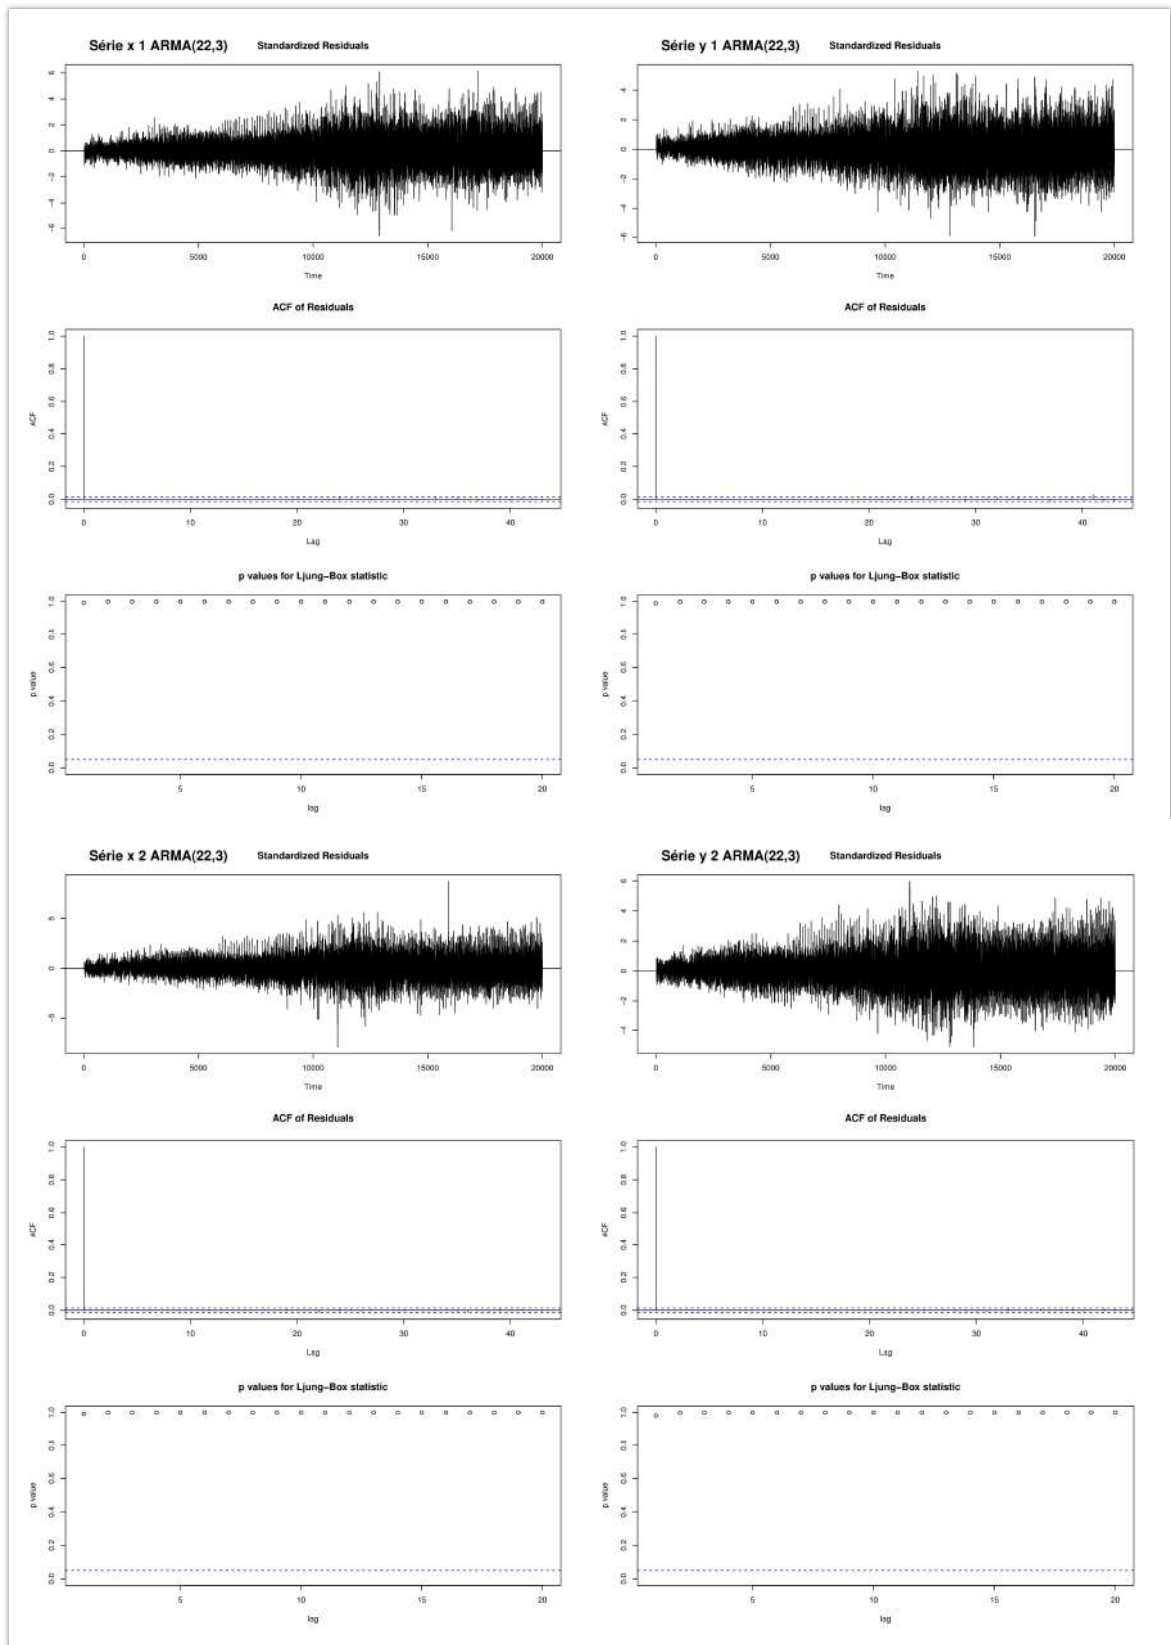
Anexo VI - Figura 6: ARMA(22,3) para as séries transientes parte 6



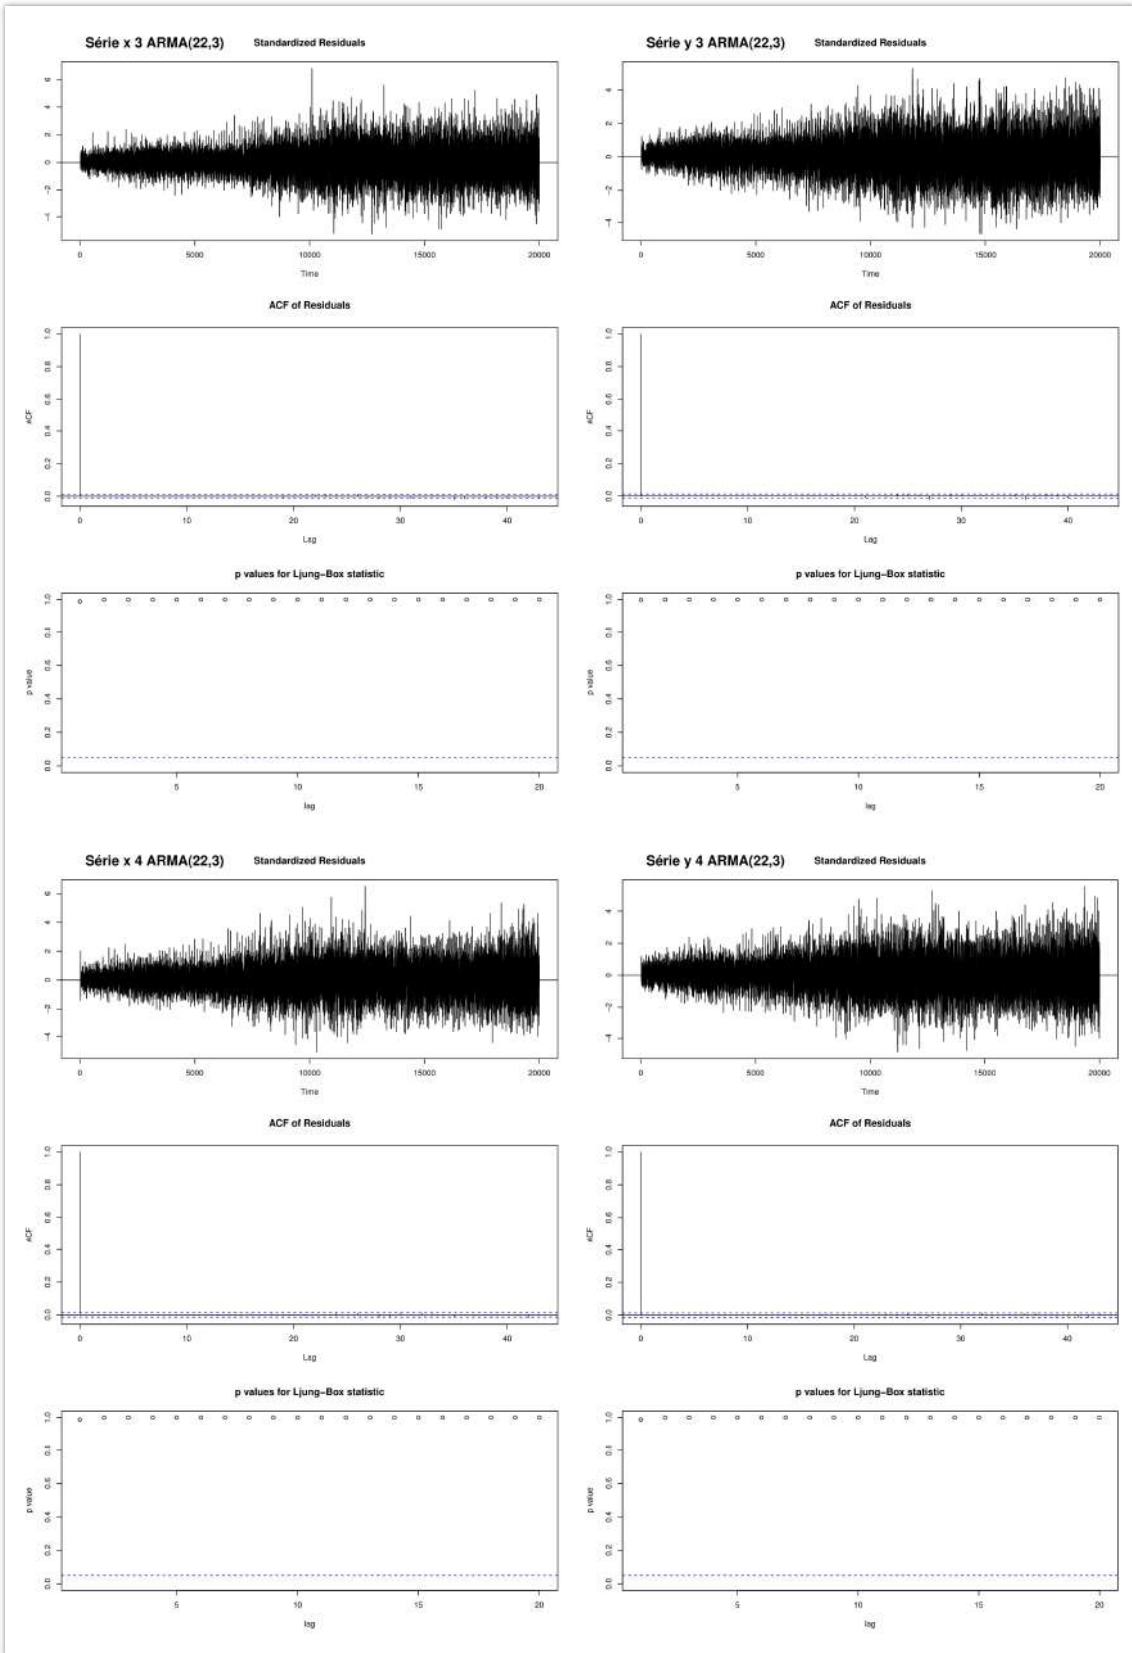
Anexo VI - Figura 7: ARMA(22,3) para as séries transientes parte 7



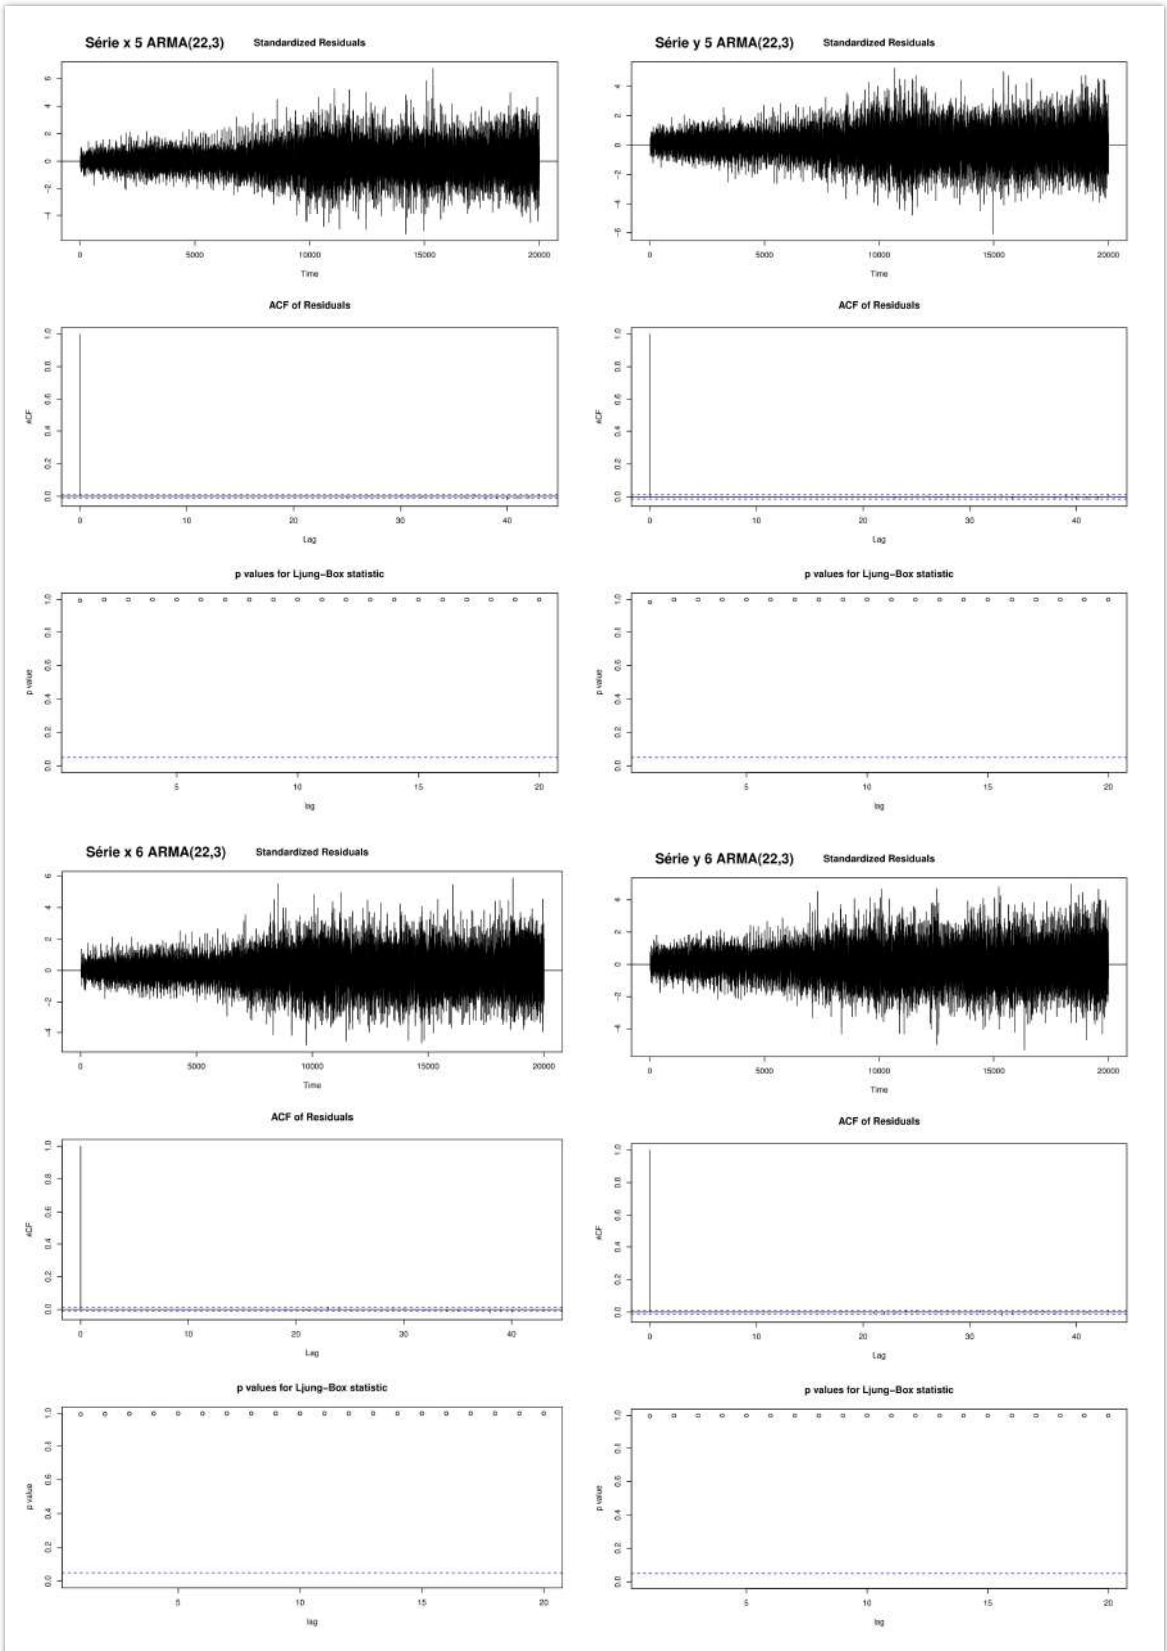
Anexo VI - Figura 8: ARMA(22,3) para as séries transientes parte 8



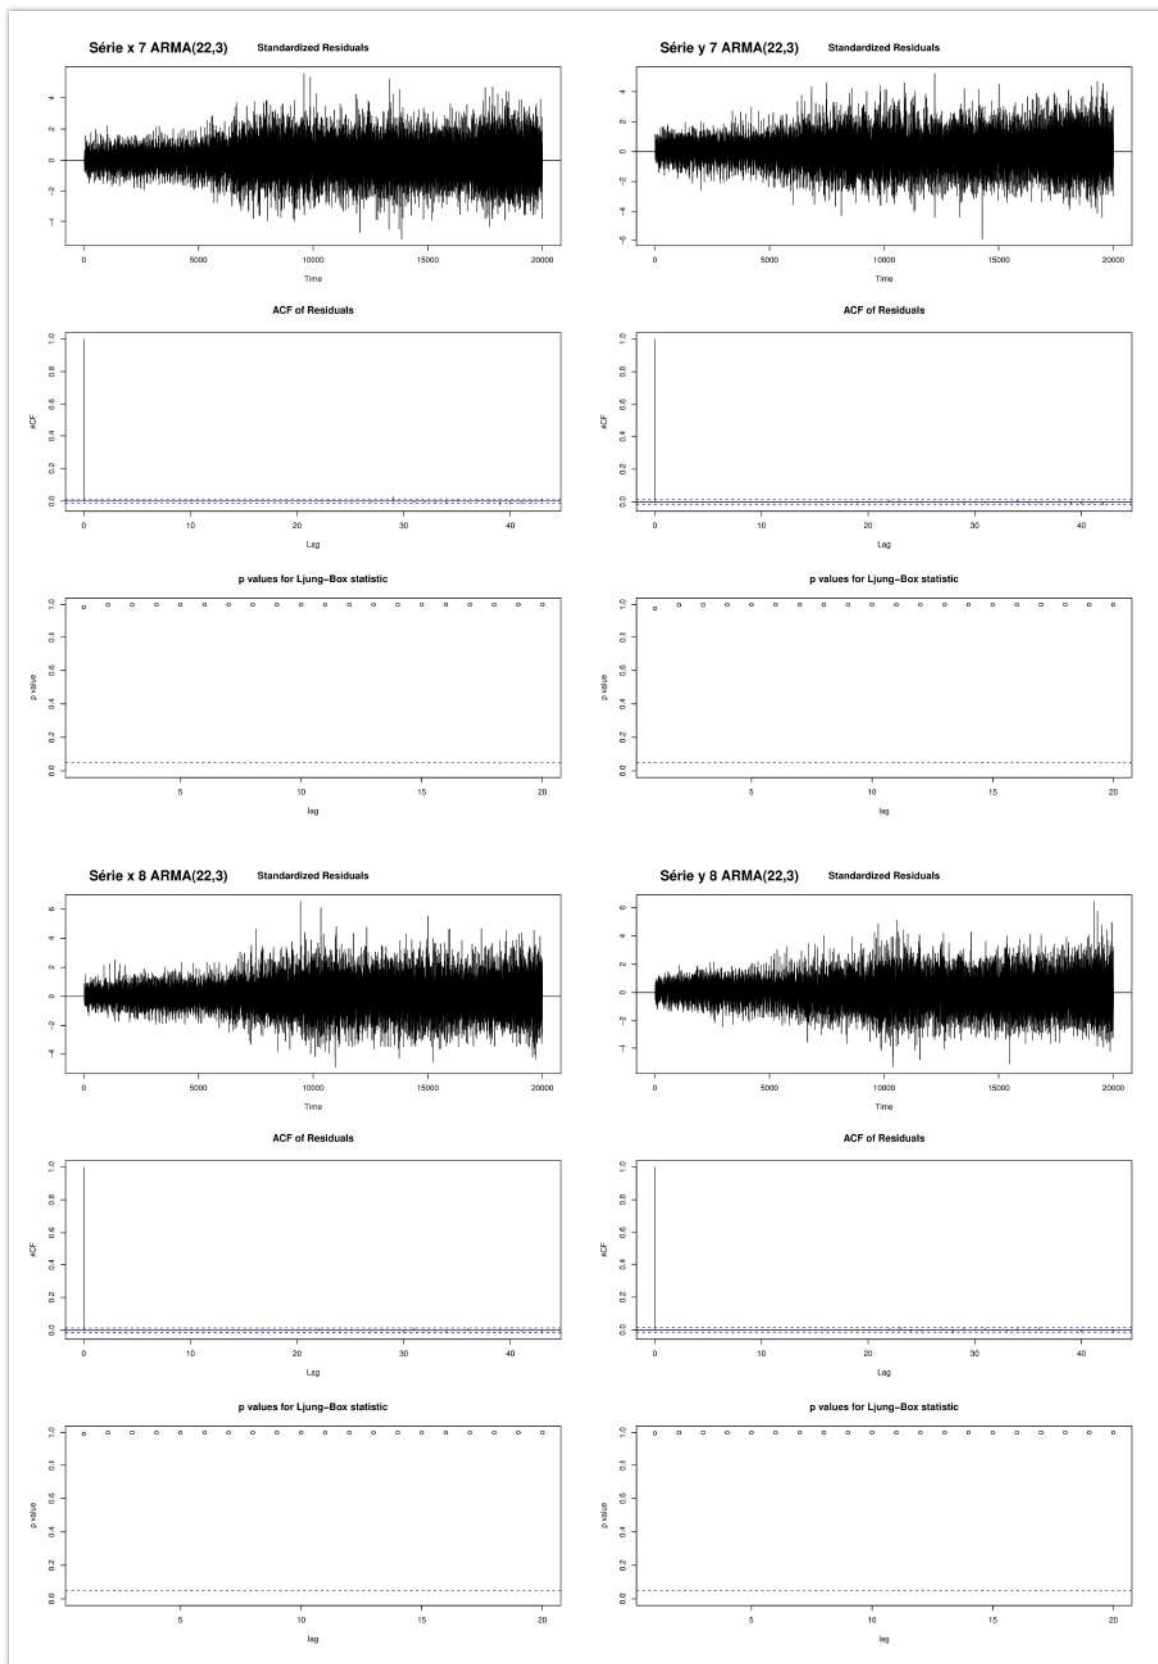
Anexo VI - Figura 9: Resíduos padronizados, FAC e teste de Ljung-Box do ARMA(22,3) para as séries transientes parte 1



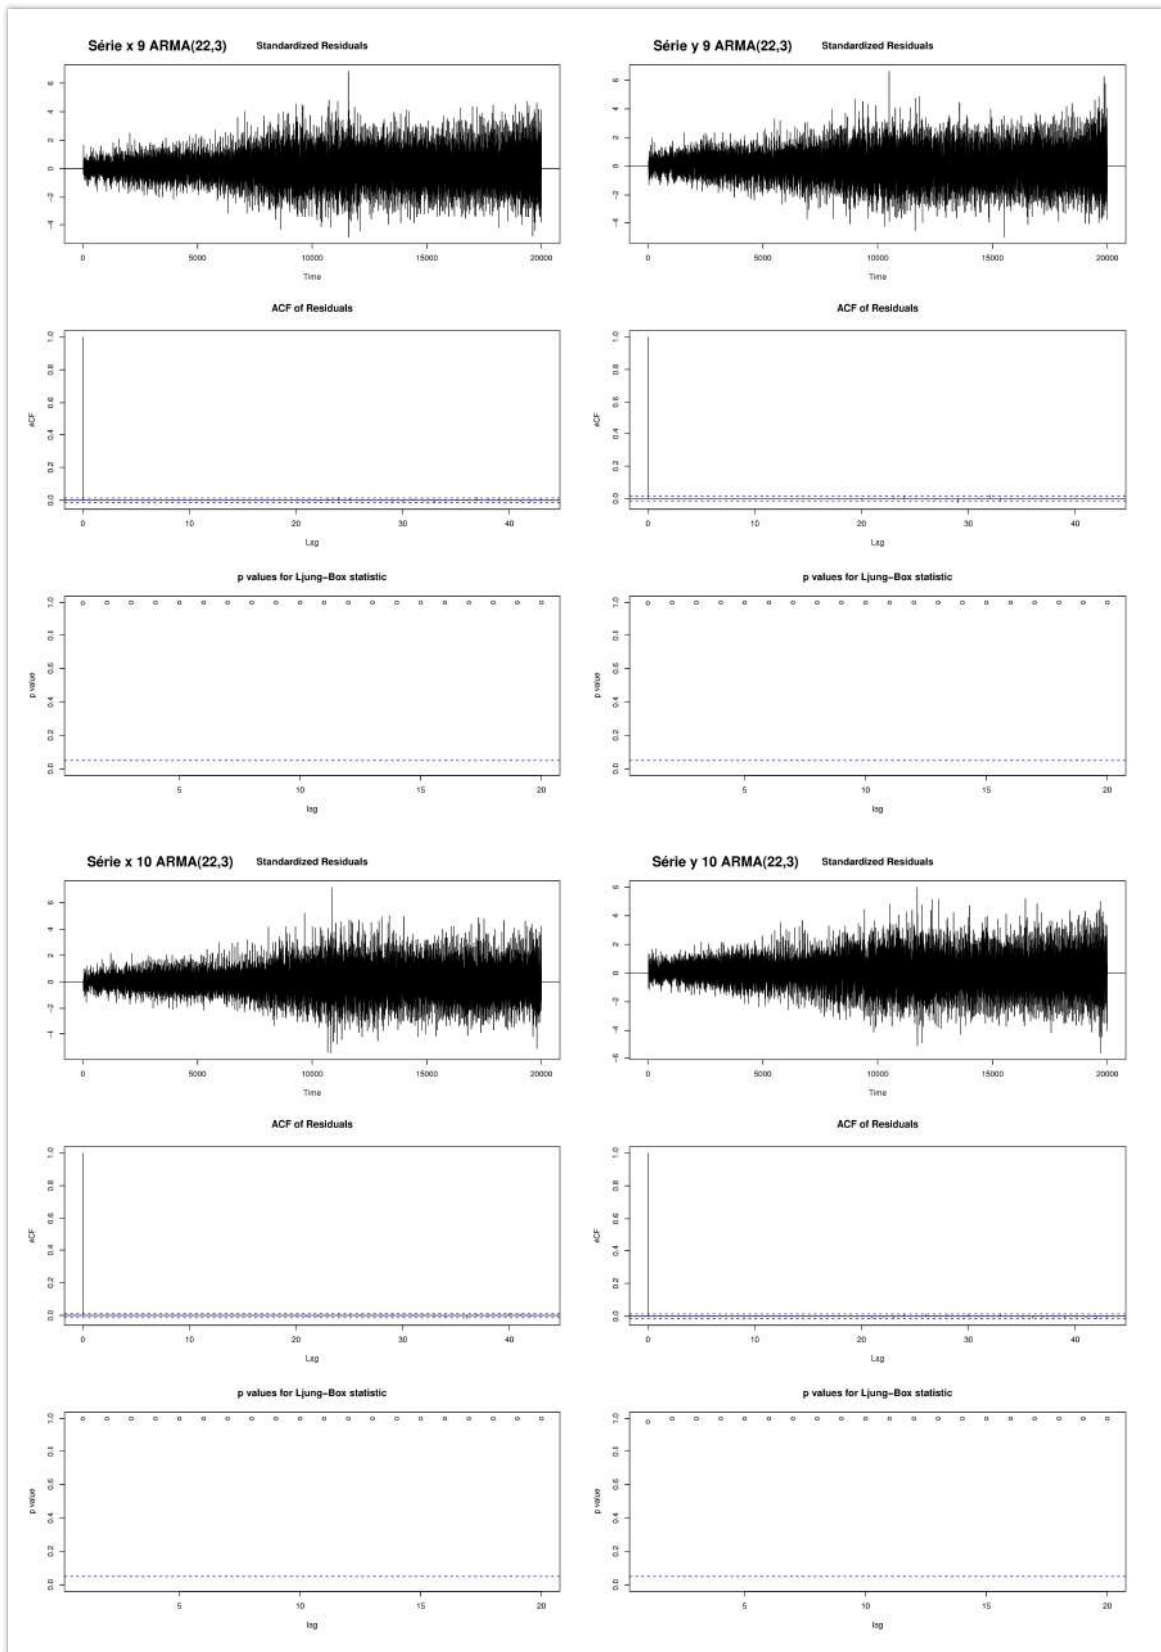
Anexo VI - Figura 10: Resíduos padronizados, FAC e teste de Ljung-Box do ARMA(22,3) para as séries transientes parte 2



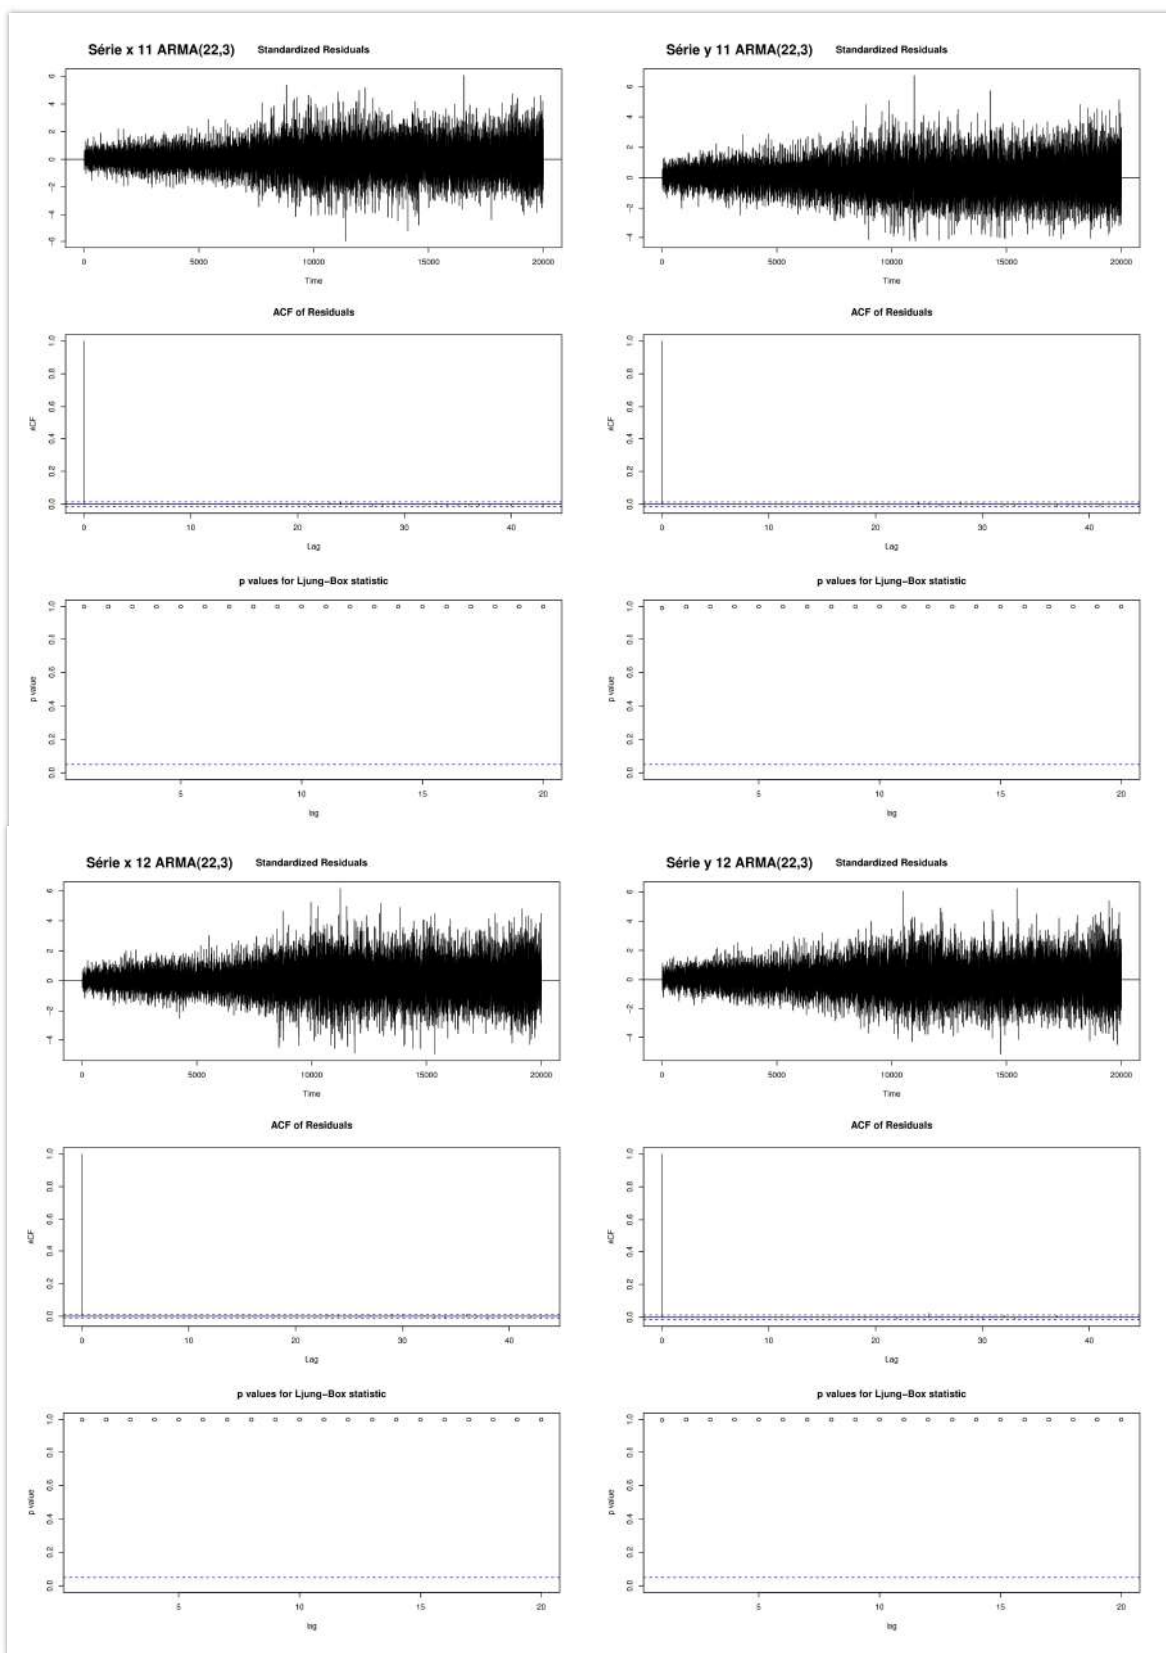
Anexo VI - Figura 11: Resíduos padronizados, FAC e teste de Ljung-Box do ARMA(22,3) para as séries transientes parte 3



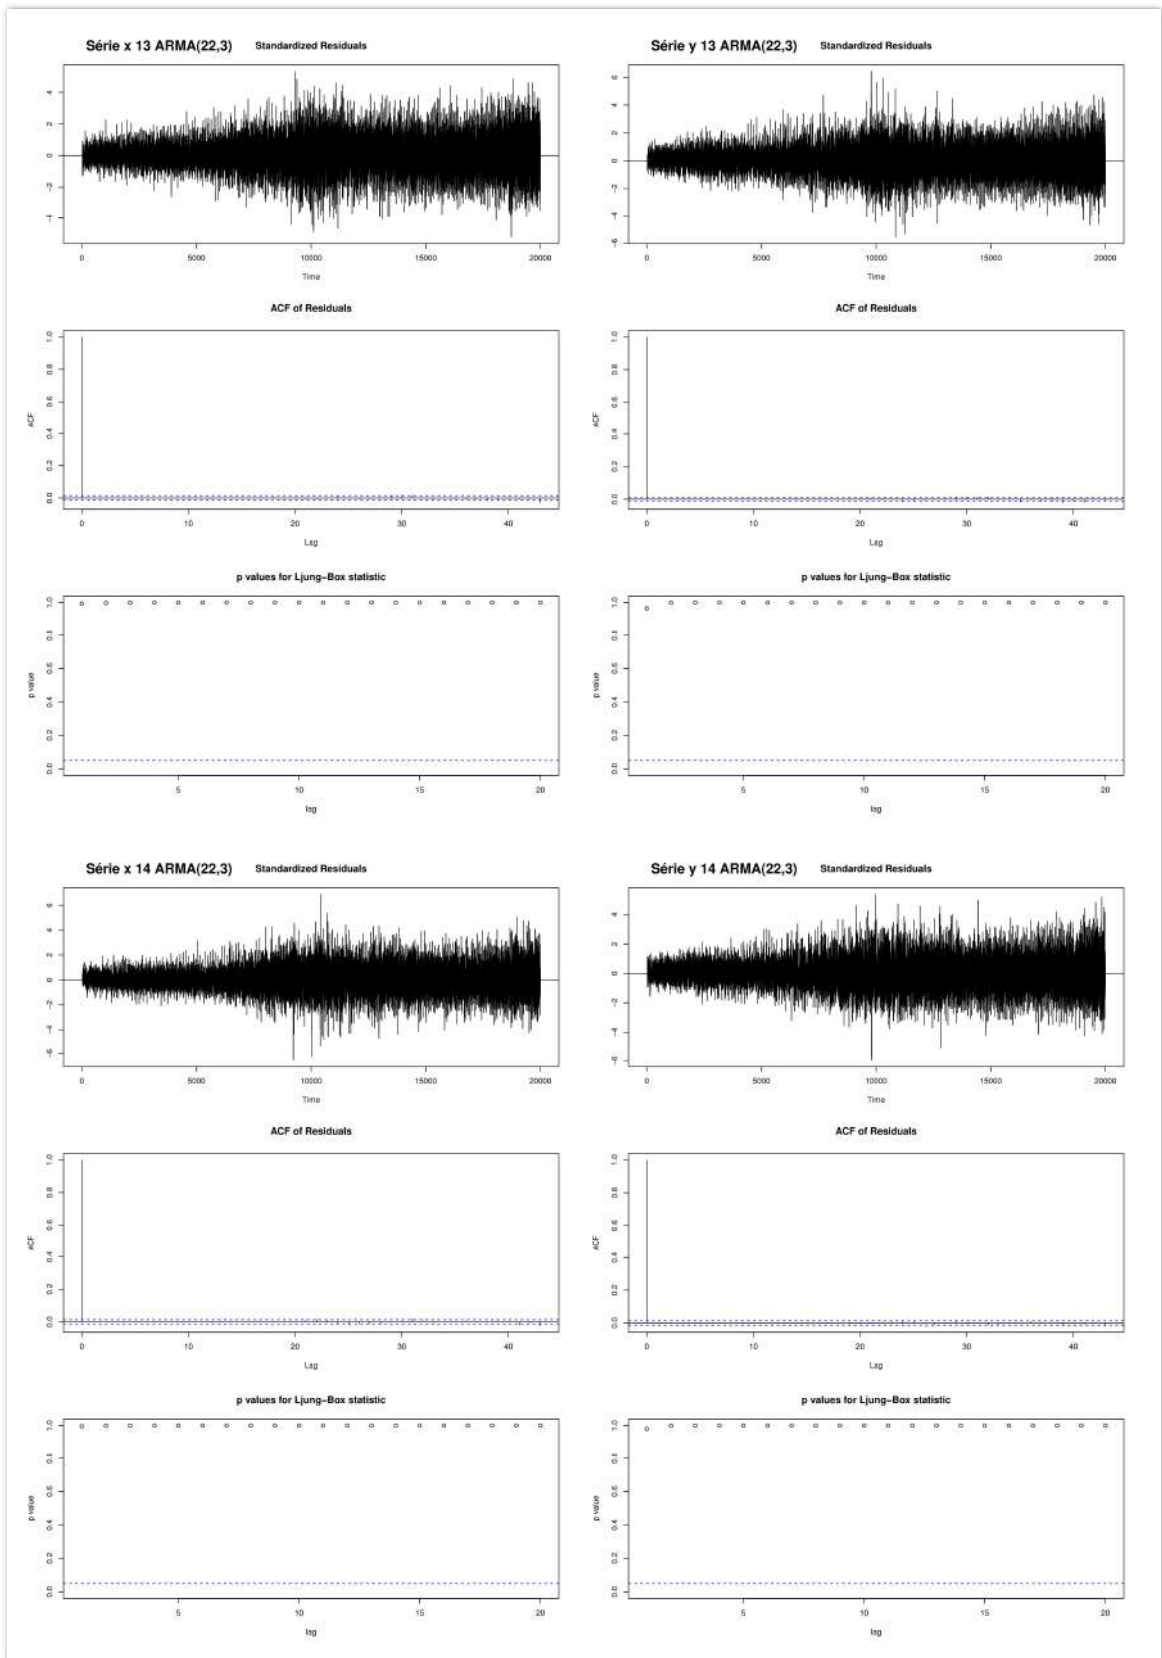
Anexo VI - Figura 12: Resíduos padronizados, FAC e teste de Ljung-Box do ARMA(22,3) para as séries transientes parte 4



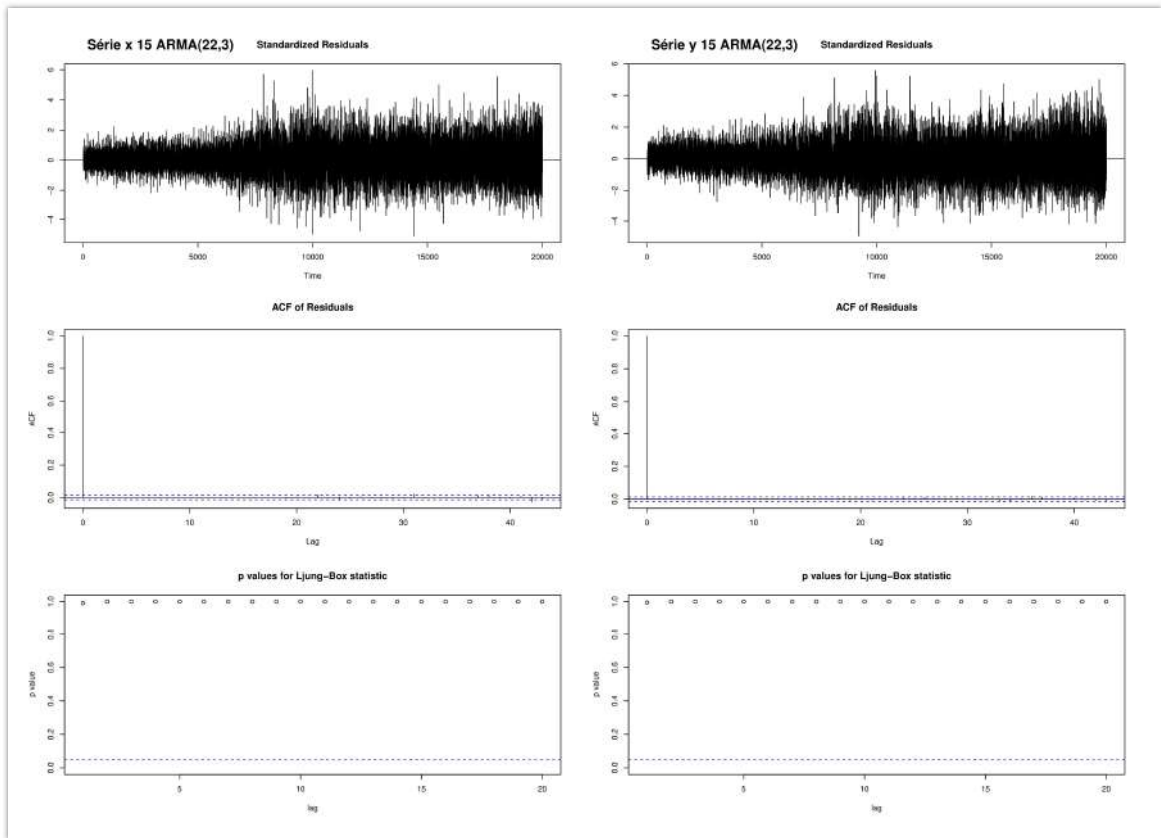
Anexo VI - Figura 13: Resíduos padronizados, FAC e teste de Ljung-Box do ARMA(22,3) para as séries transientes parte 5



Anexo VI - Figura 14: Resíduos padronizados, FAC e teste de Ljung-Box do ARMA(22,3) para as séries transientes parte 6

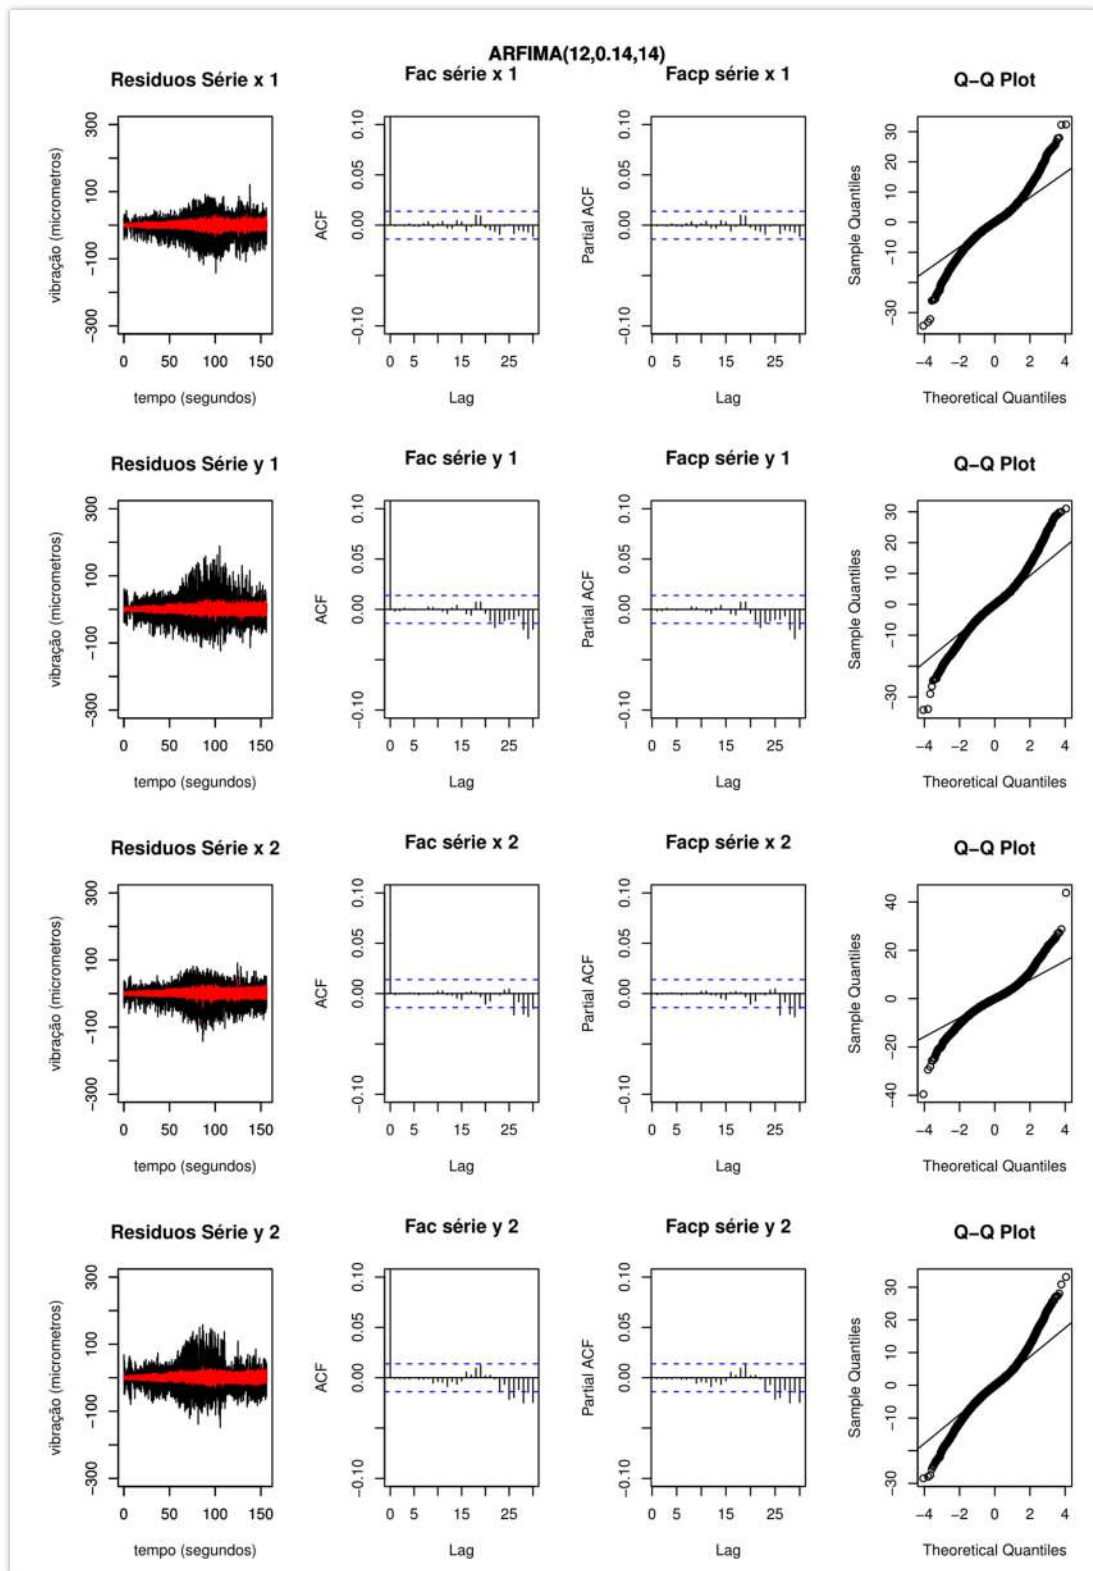


Anexo VI - Figura 15: Resíduos padronizados, FAC e teste de Ljung-Box do ARMA(22,3) para as séries transientes parte 7

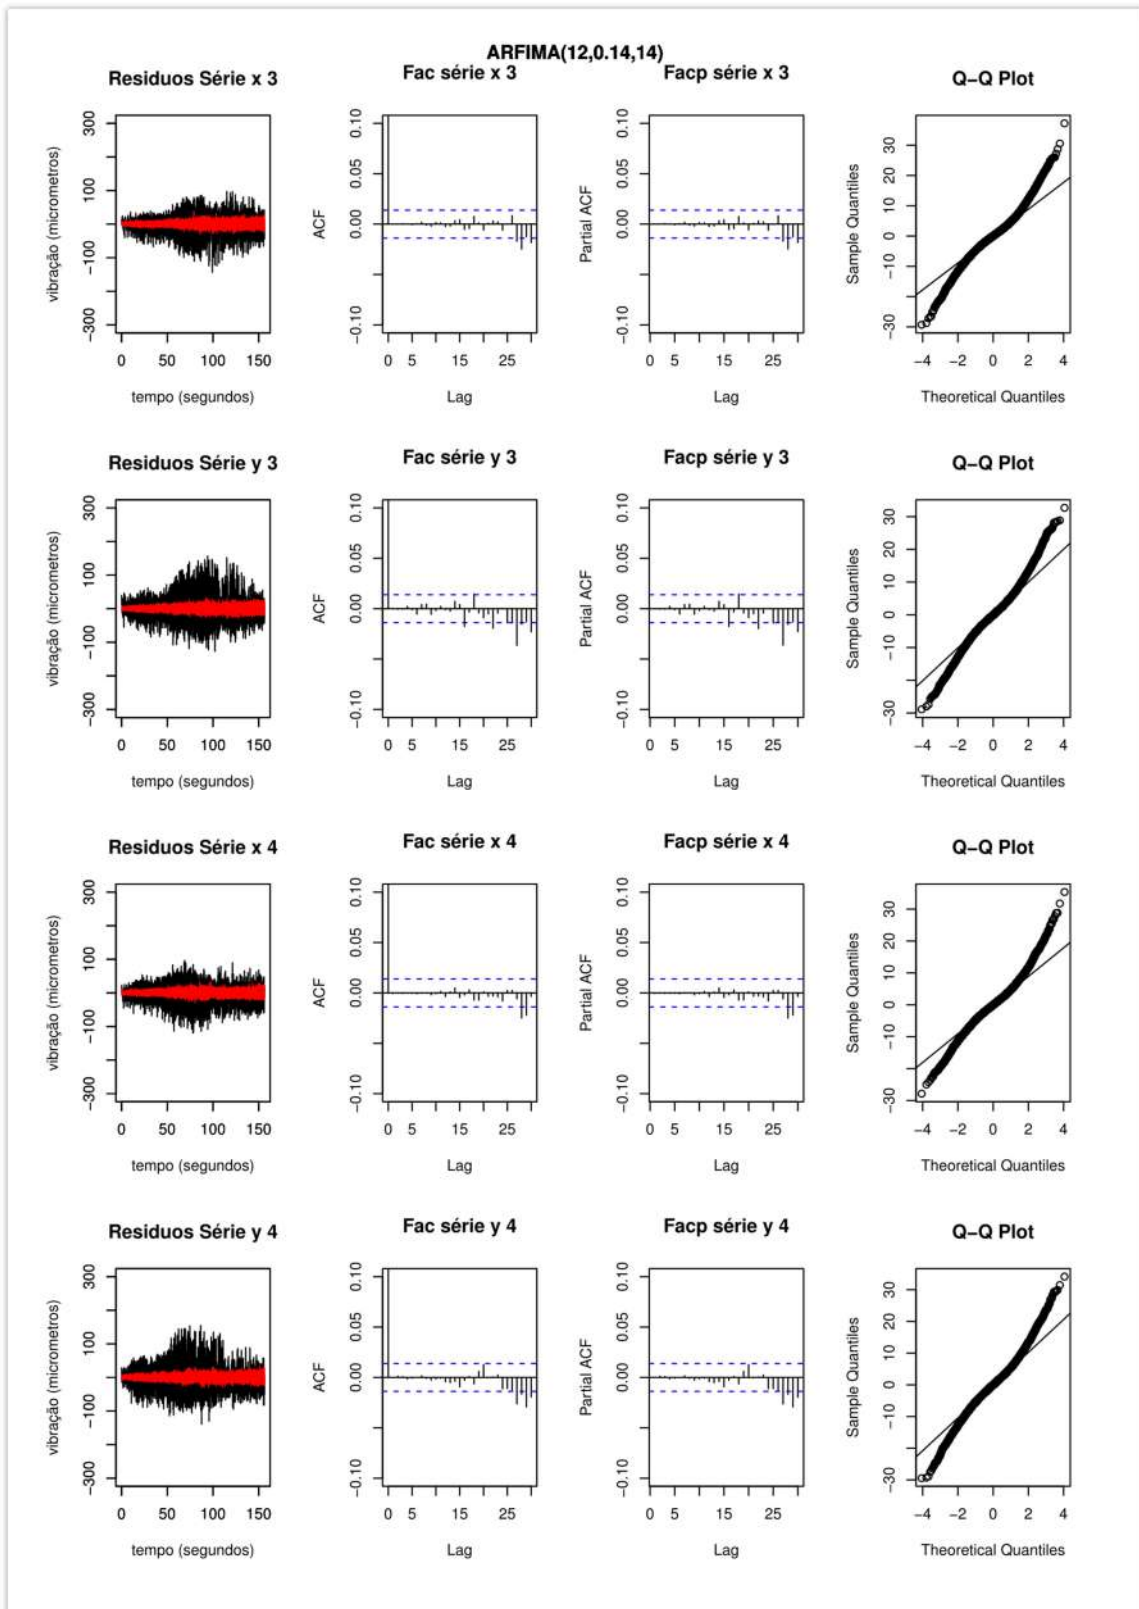


Anexo VI - Figura 16: Resíduos padronizados, FAC e teste de Ljung-Box do ARMA(22,3) para as séries transientes parte 8

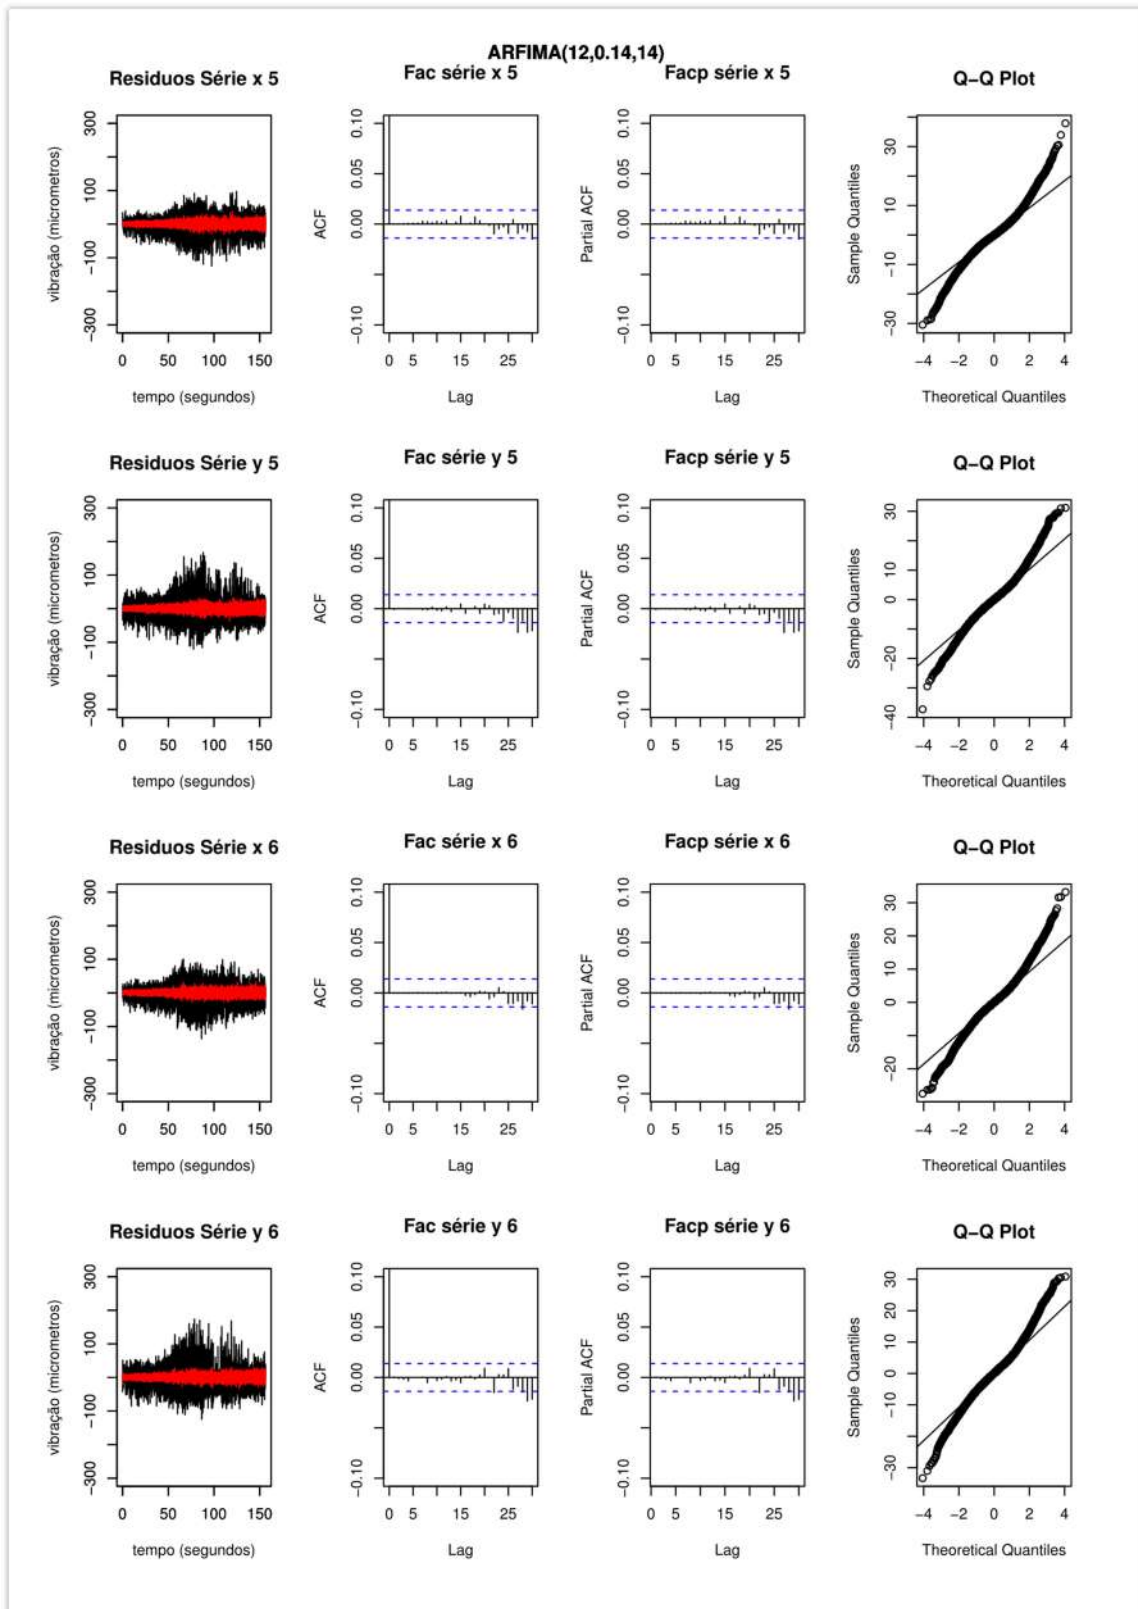
RESULTADOS DA APLICAÇÃO DO MODELO ARFIMA



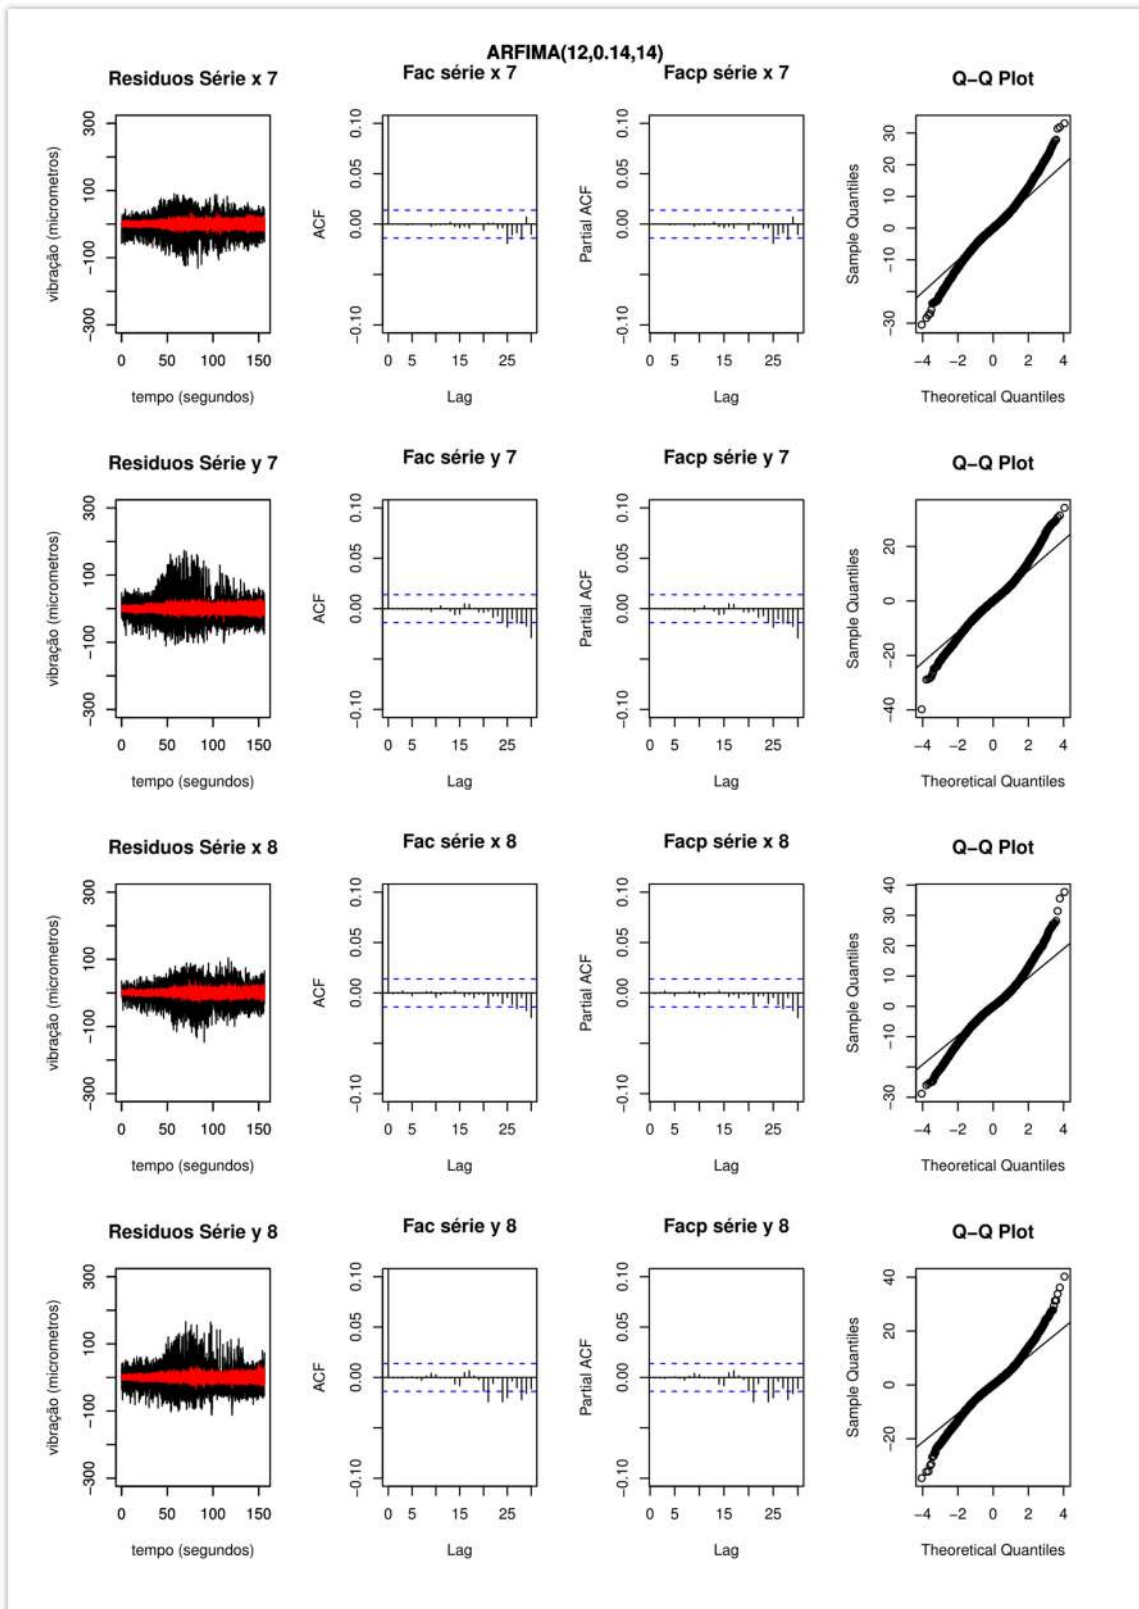
Anexo VI - Figura 17: ARFIMA(12,0,14,14) para as séries transientes parte 1



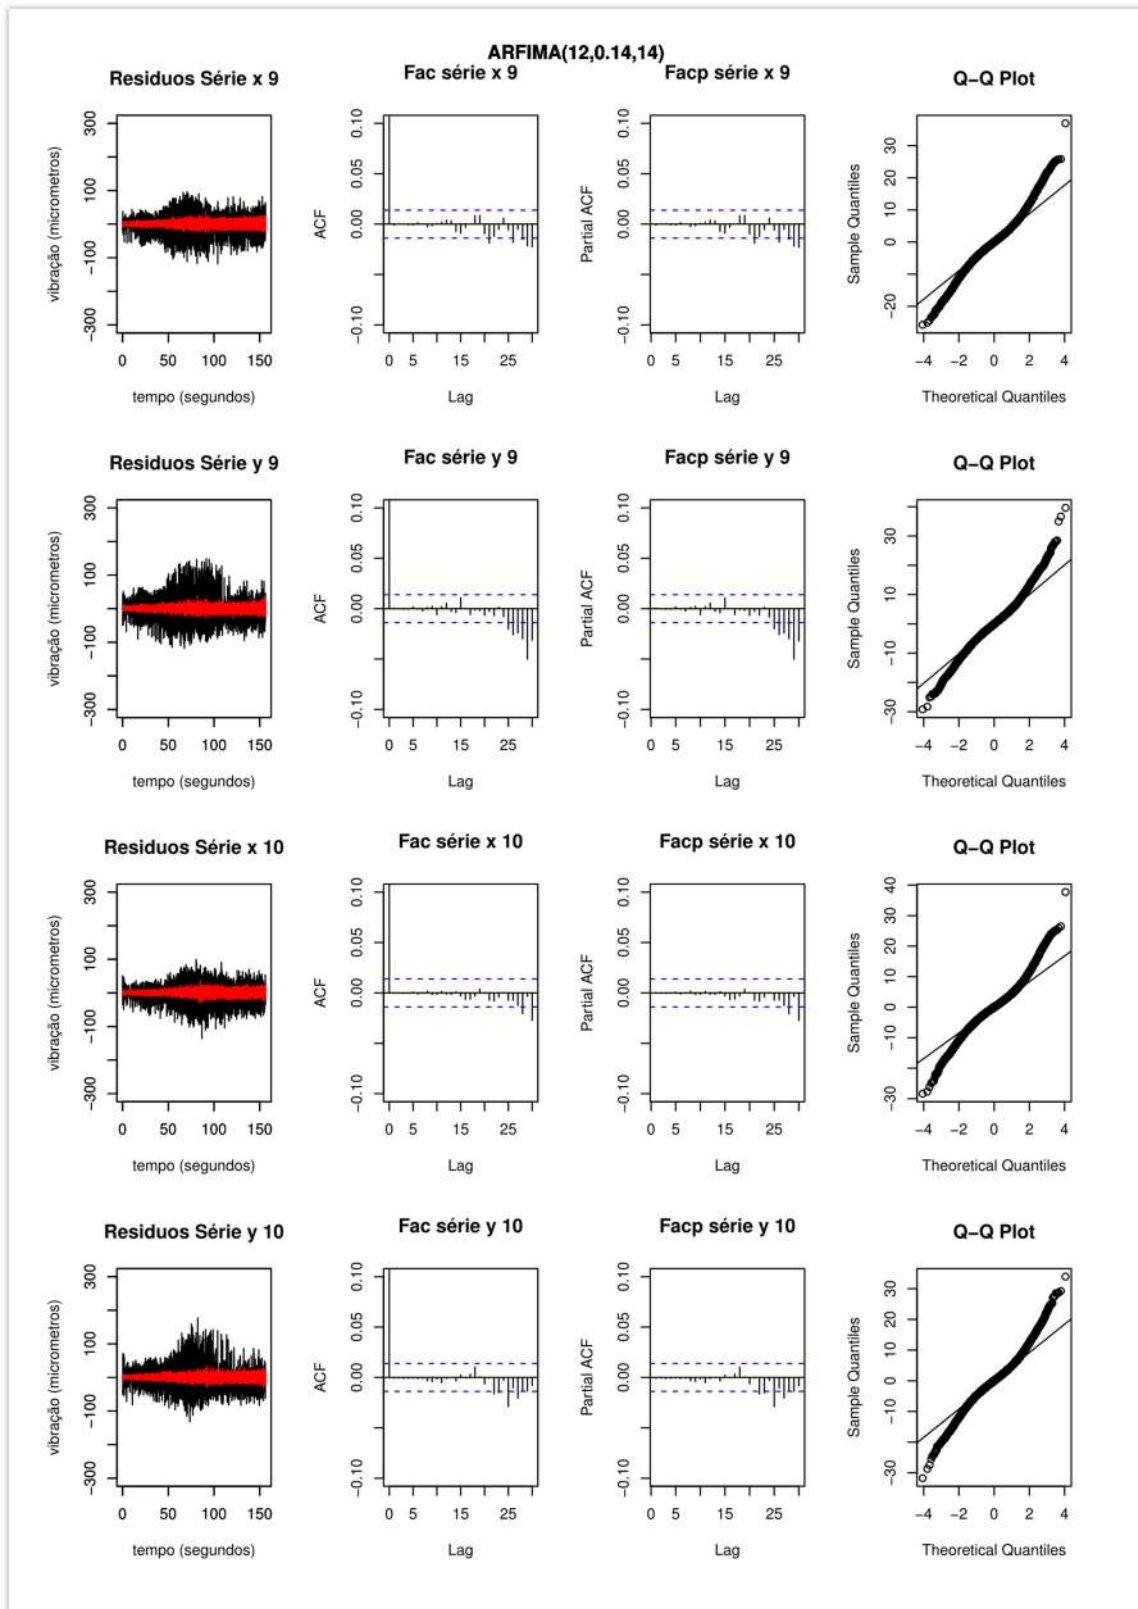
Anexo VI - Figura 18: ARFIMA(12,0,14,14) para as séries transientes parte 2



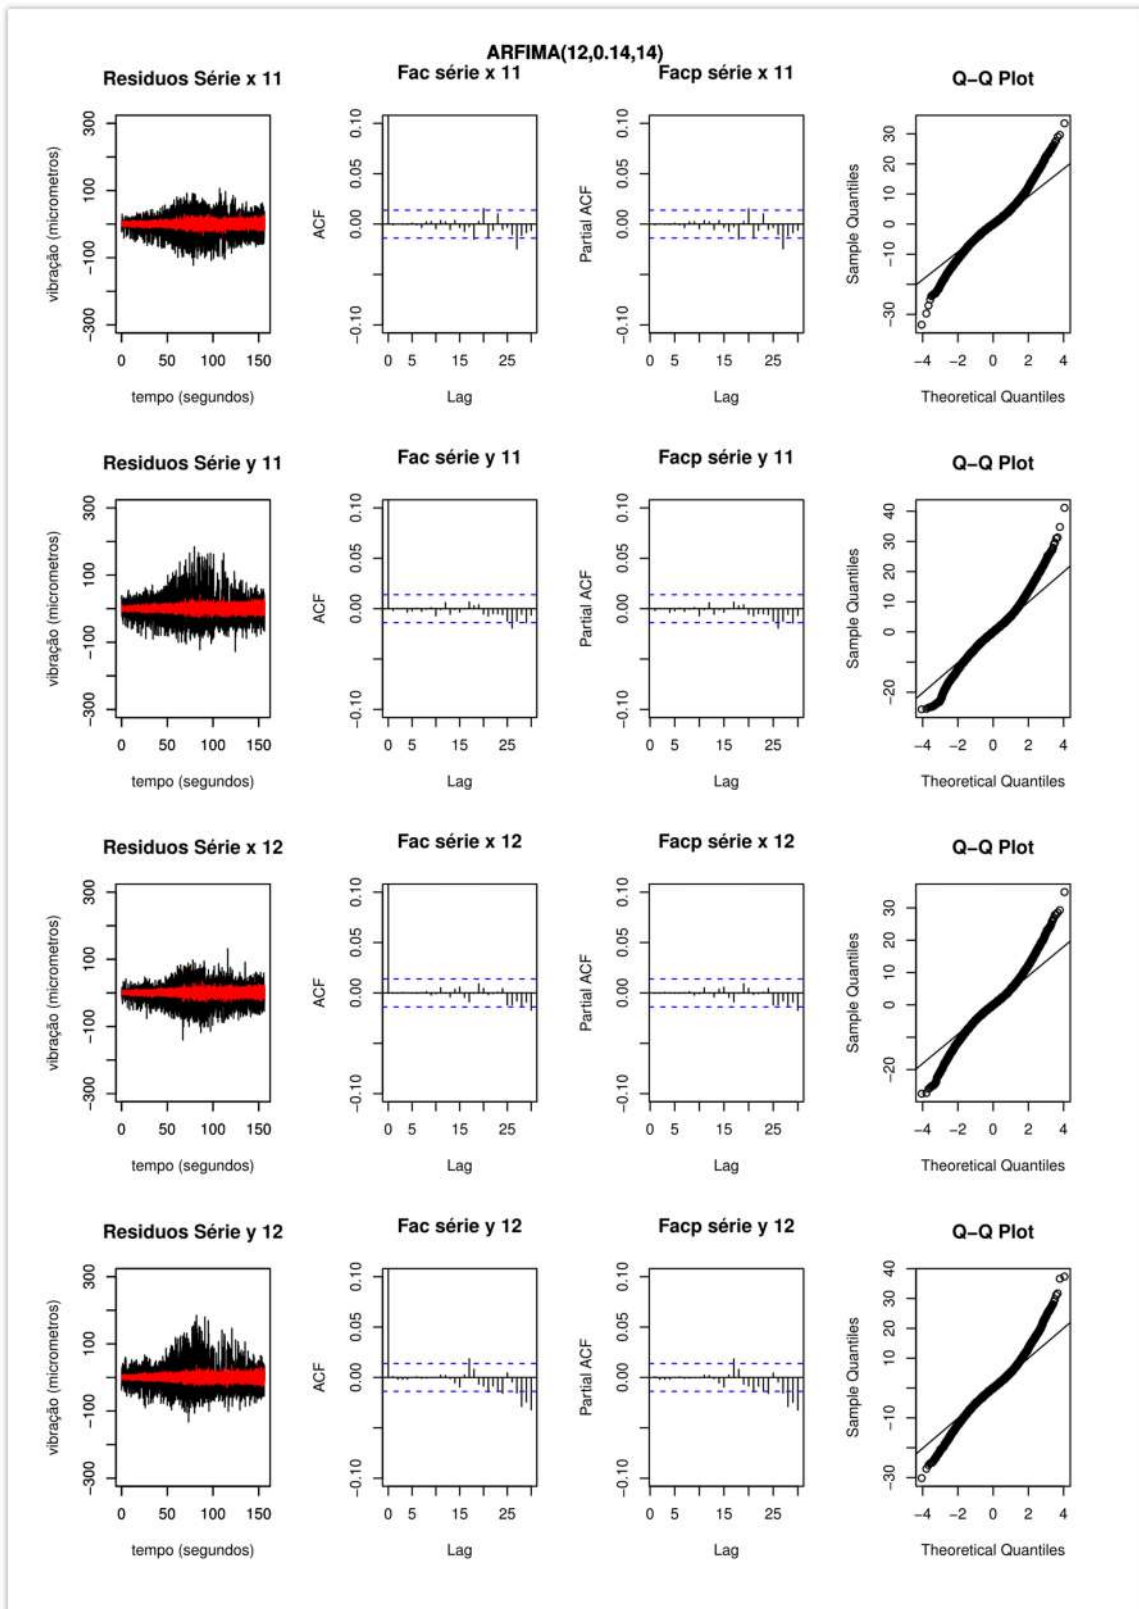
Anexo VI - Figura 19: ARFIMA(12,0,14,14) para as séries transientes parte 3



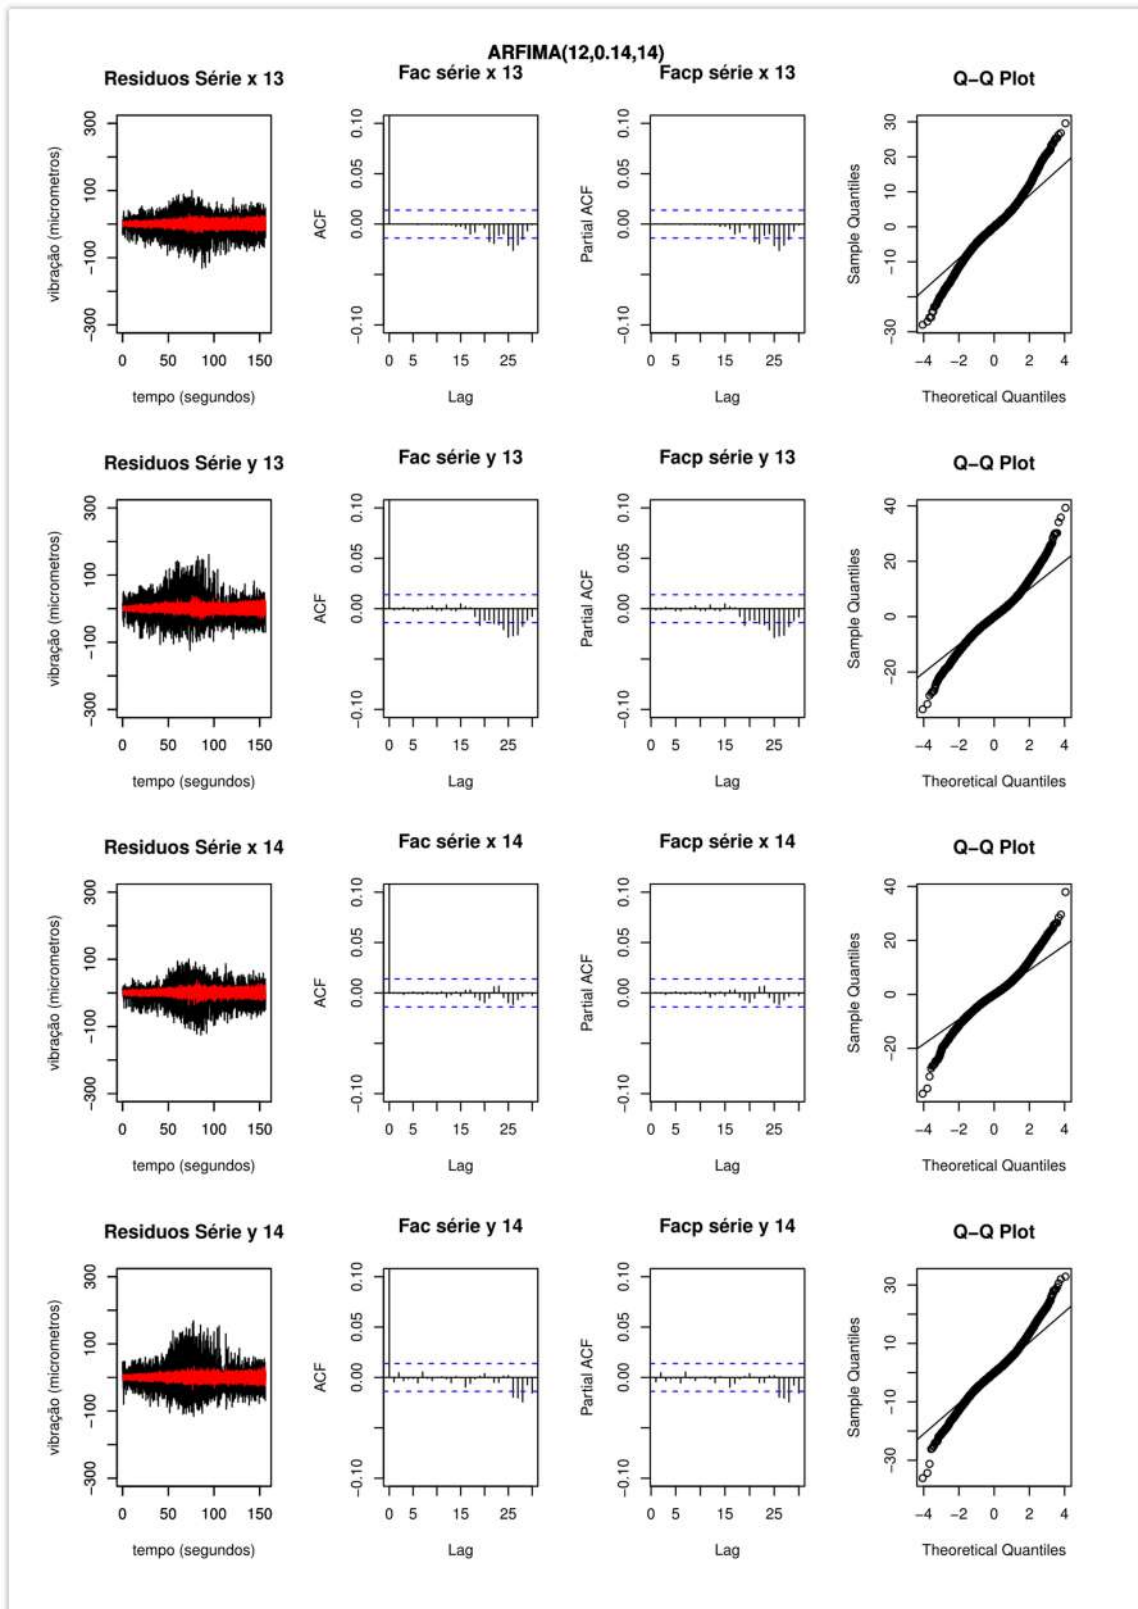
Anexo VI - Figura 20: ARFIMA(12,0,14,14) para as séries transientes parte 4



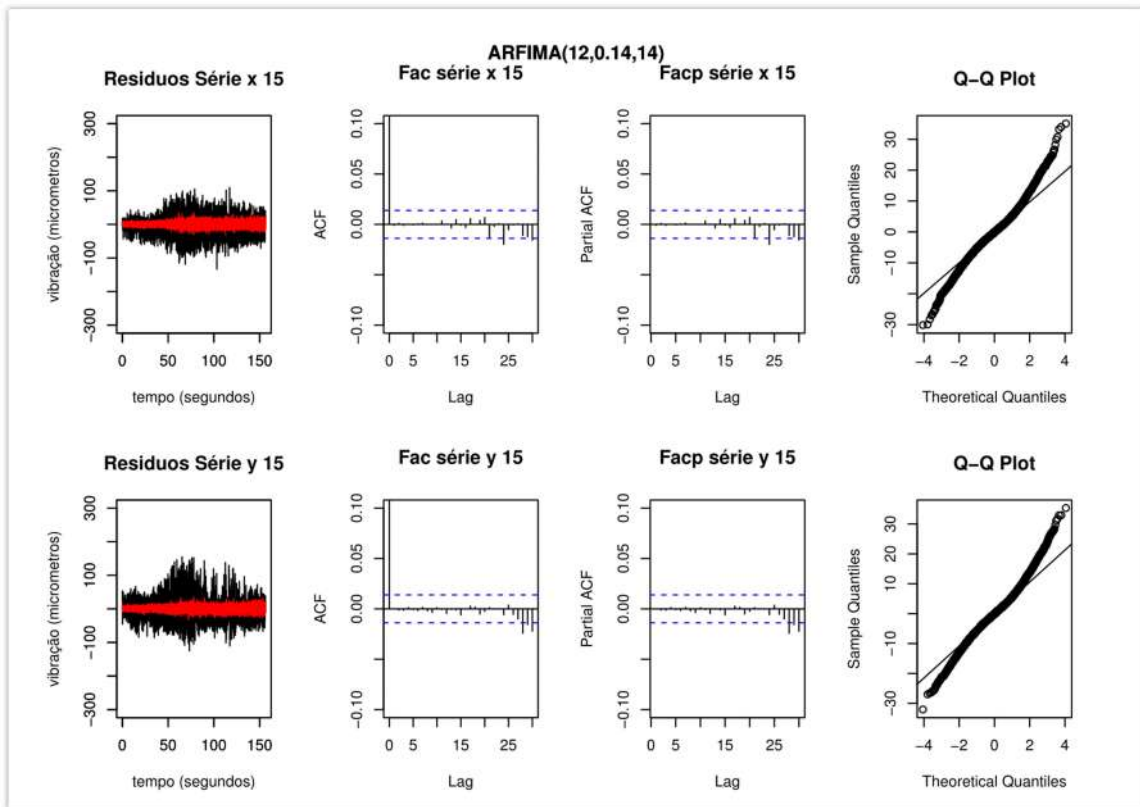
Anexo VI - Figura 21: ARFIMA(12,0,14,14) para as séries transientes parte 5



Anexo VI - Figura 22: ARFIMA(12,0,14,14) para as séries transientes parte 6

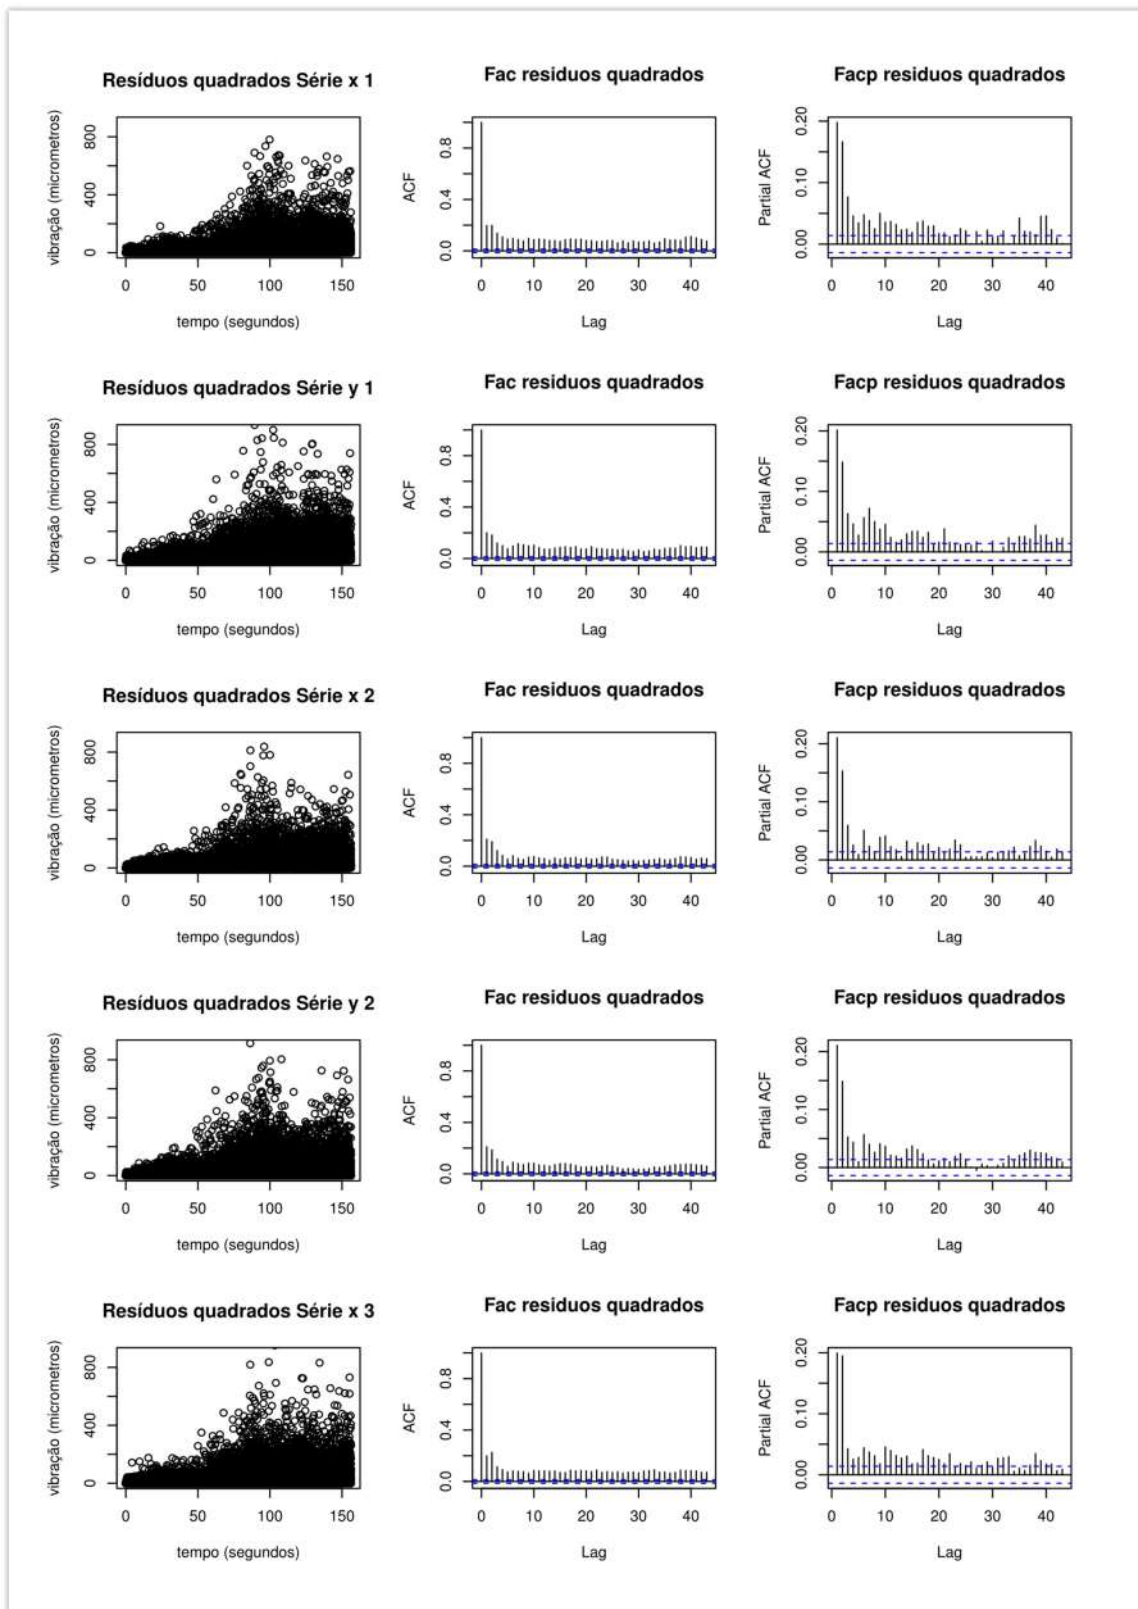


Anexo VI - Figura 23: ARFIMA(12,0,14,14) para as séries transientes parte 7

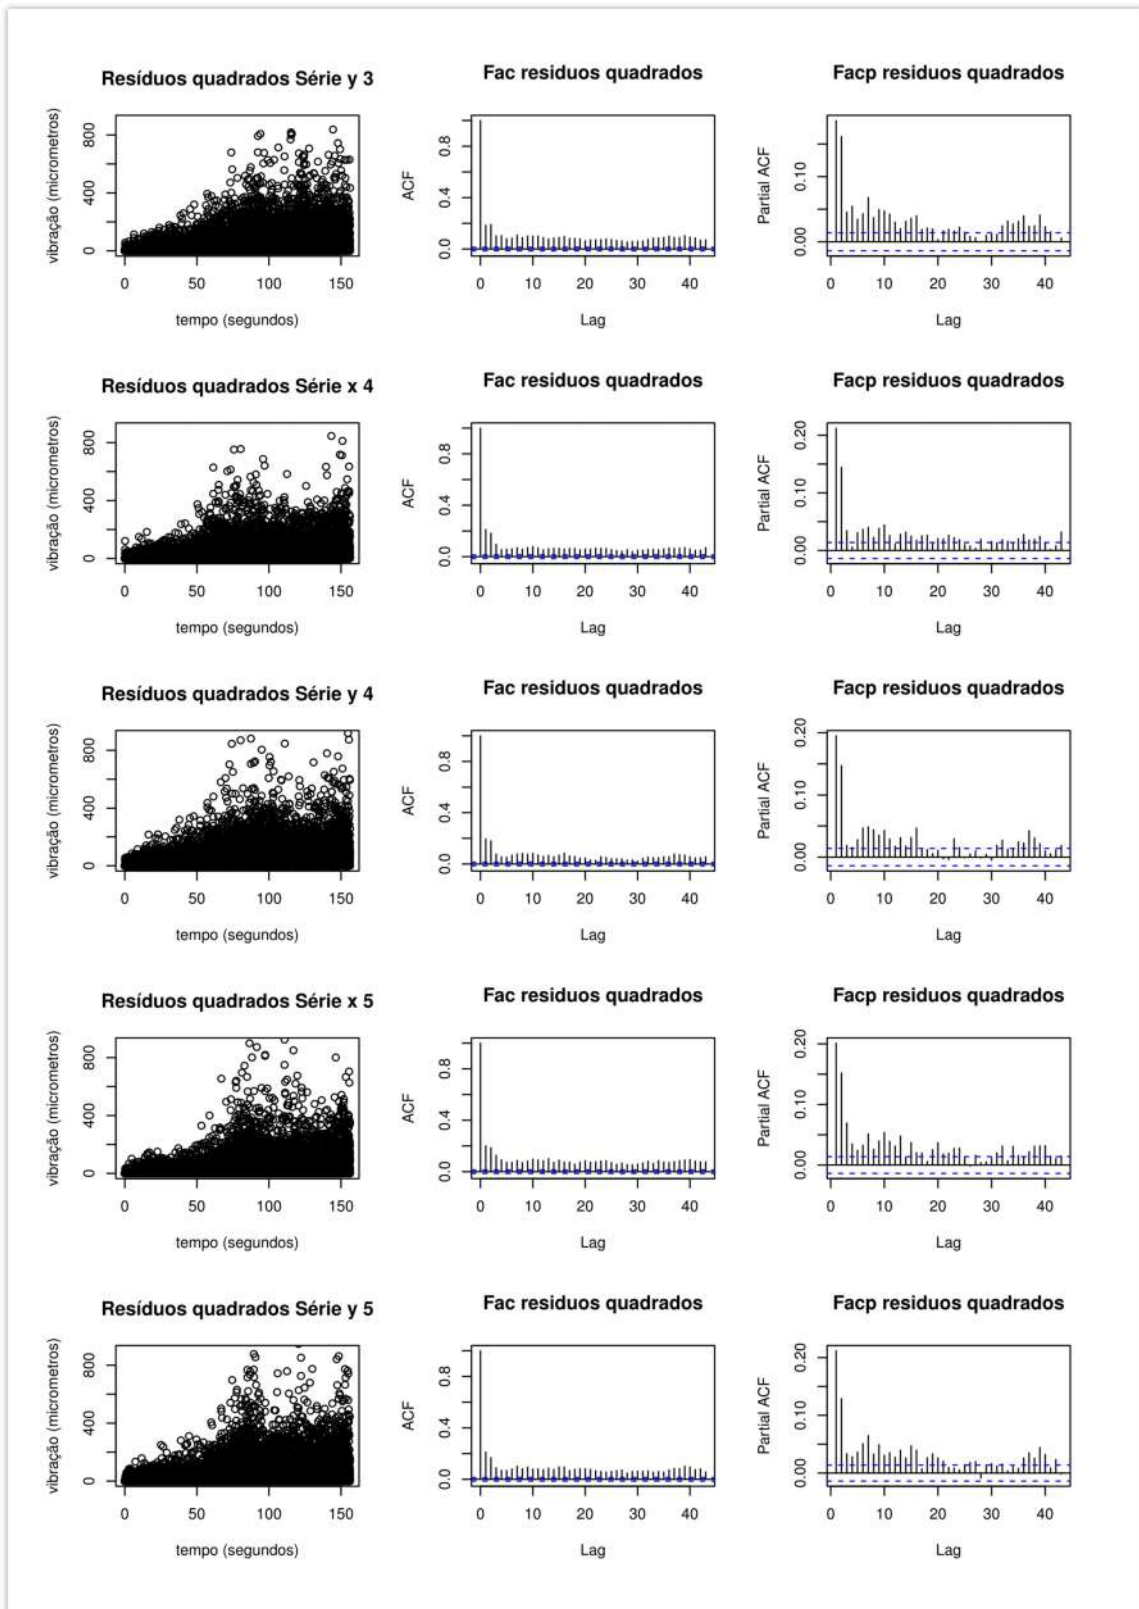


Anexo VI - Figura 24: ARFIMA(12,0,14,14) para as séries transientes parte 8

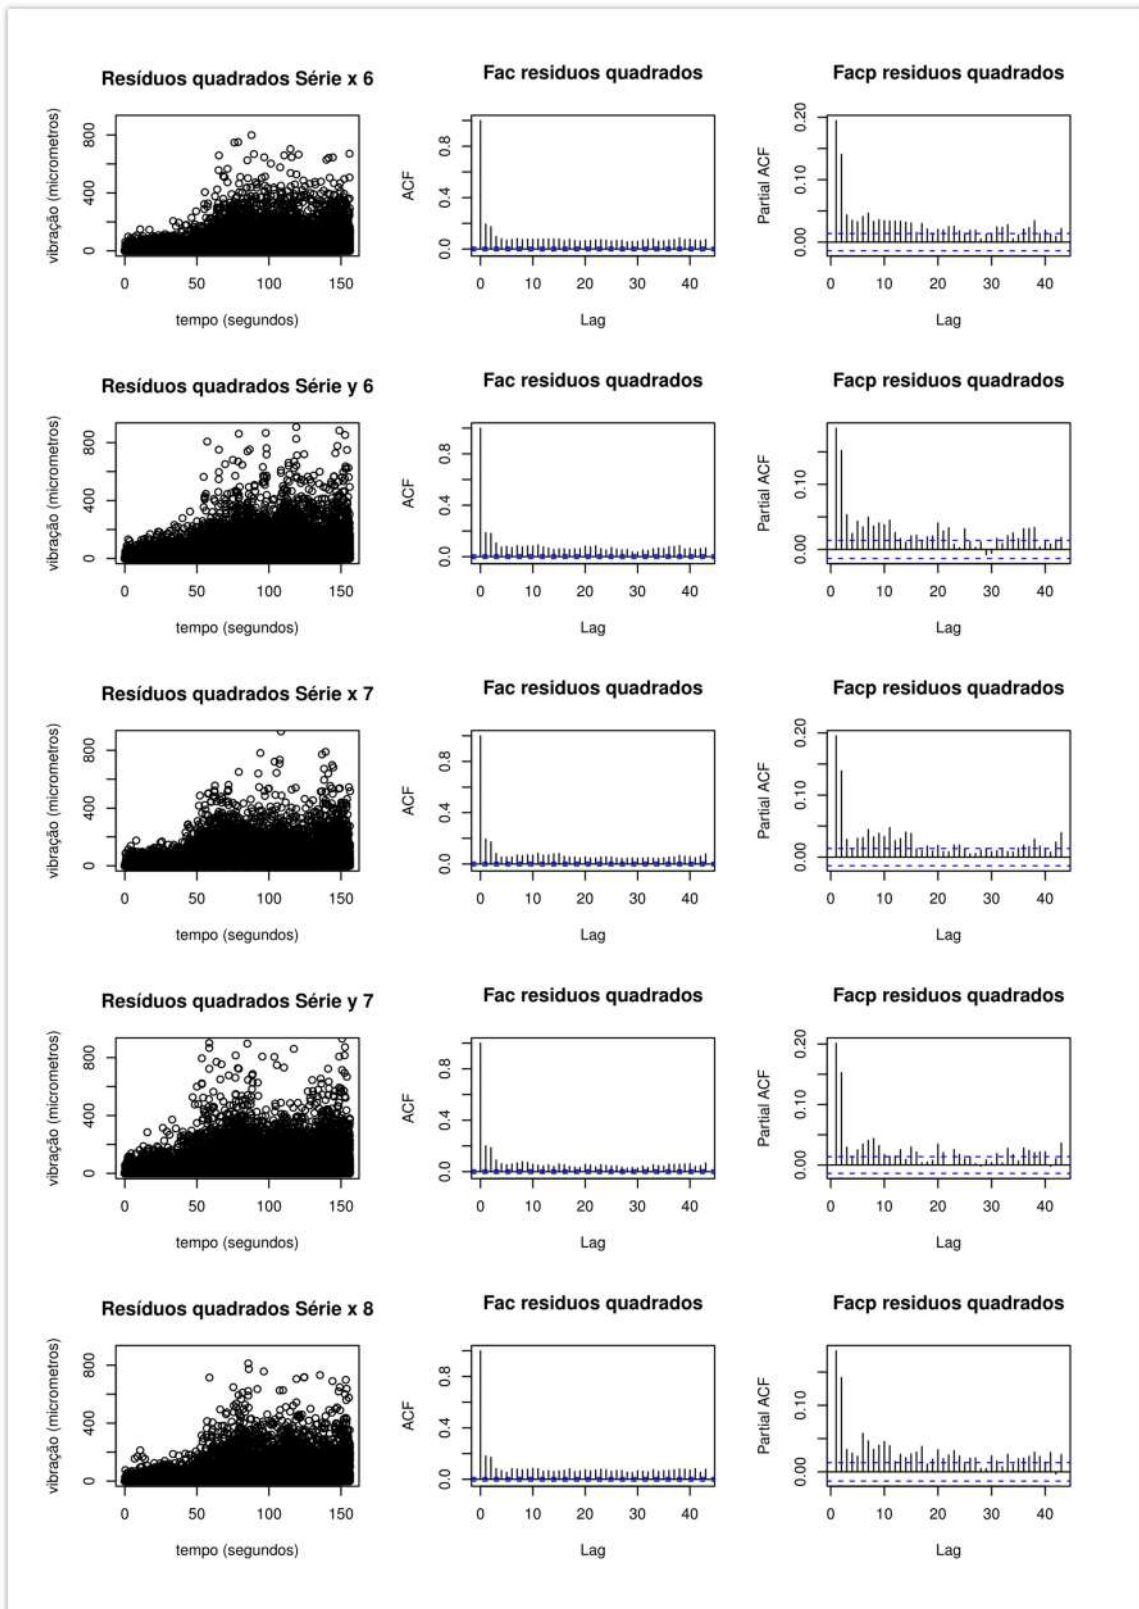
RESULTADOS DA APLICAÇÃO DOS MODELOS NÃO-LINEARES



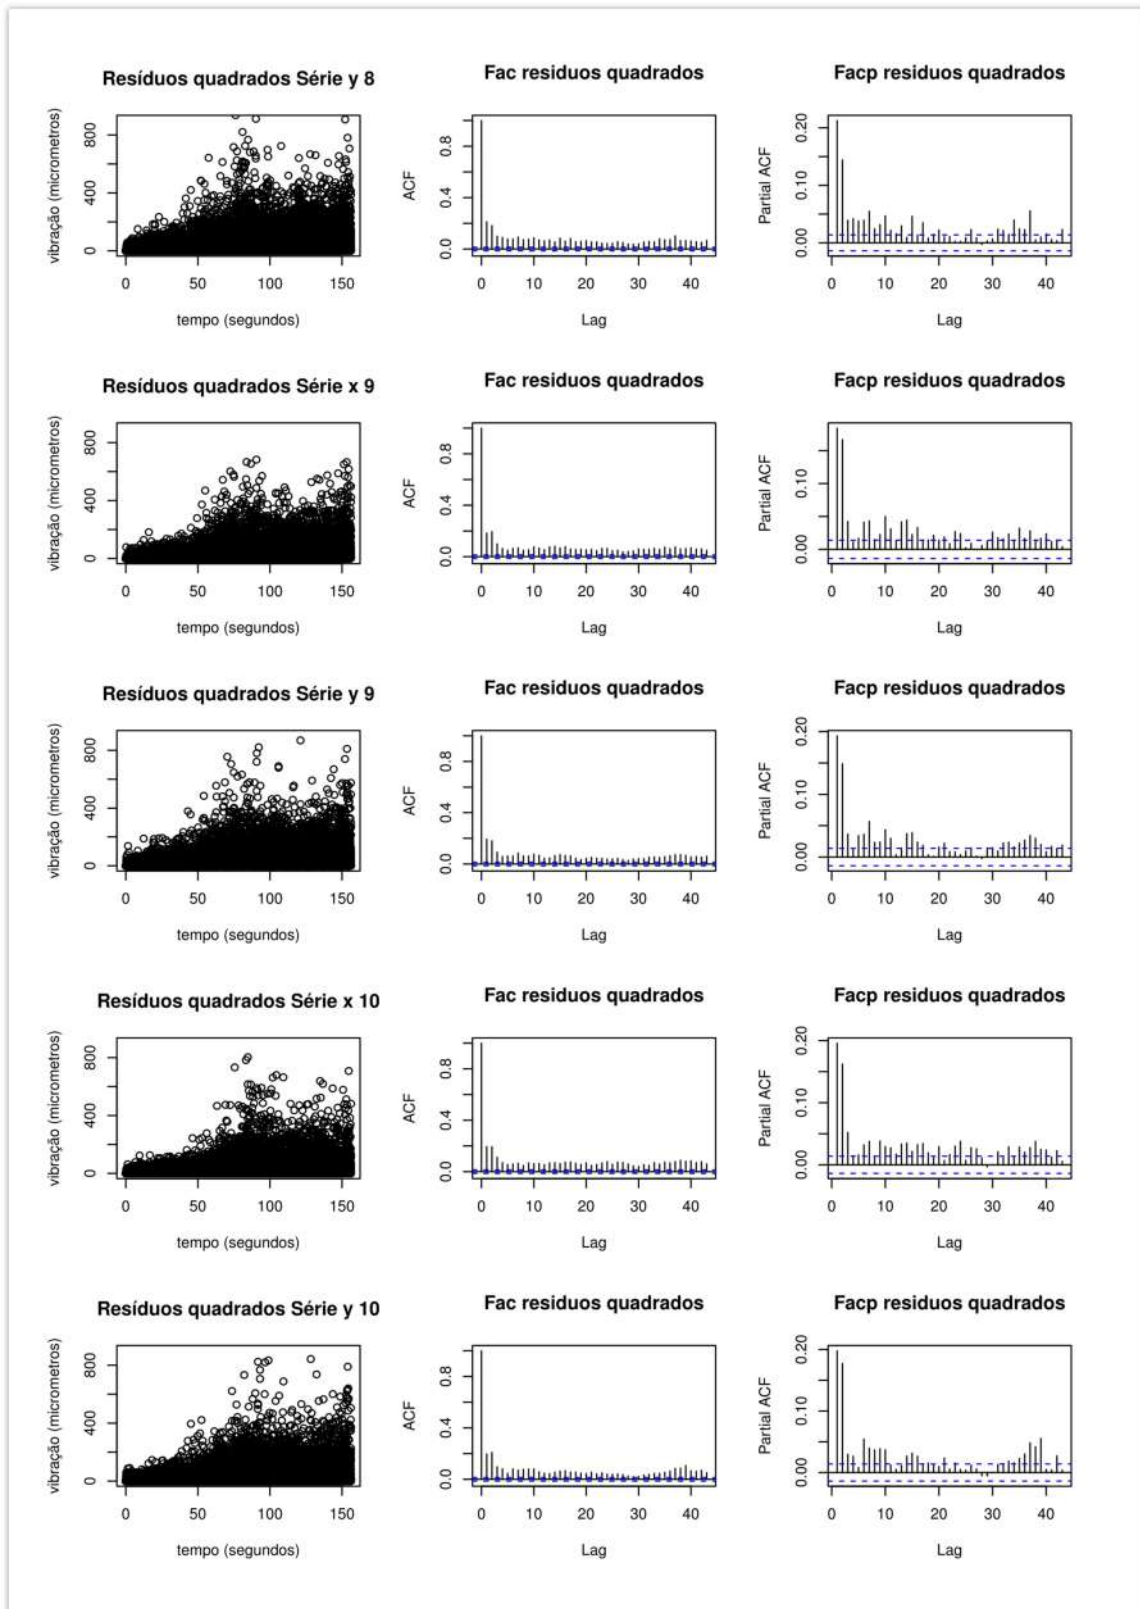
Anexo VI - Figura 25: Resíduos quadrados, FAC e FACP quadráticas parte 1



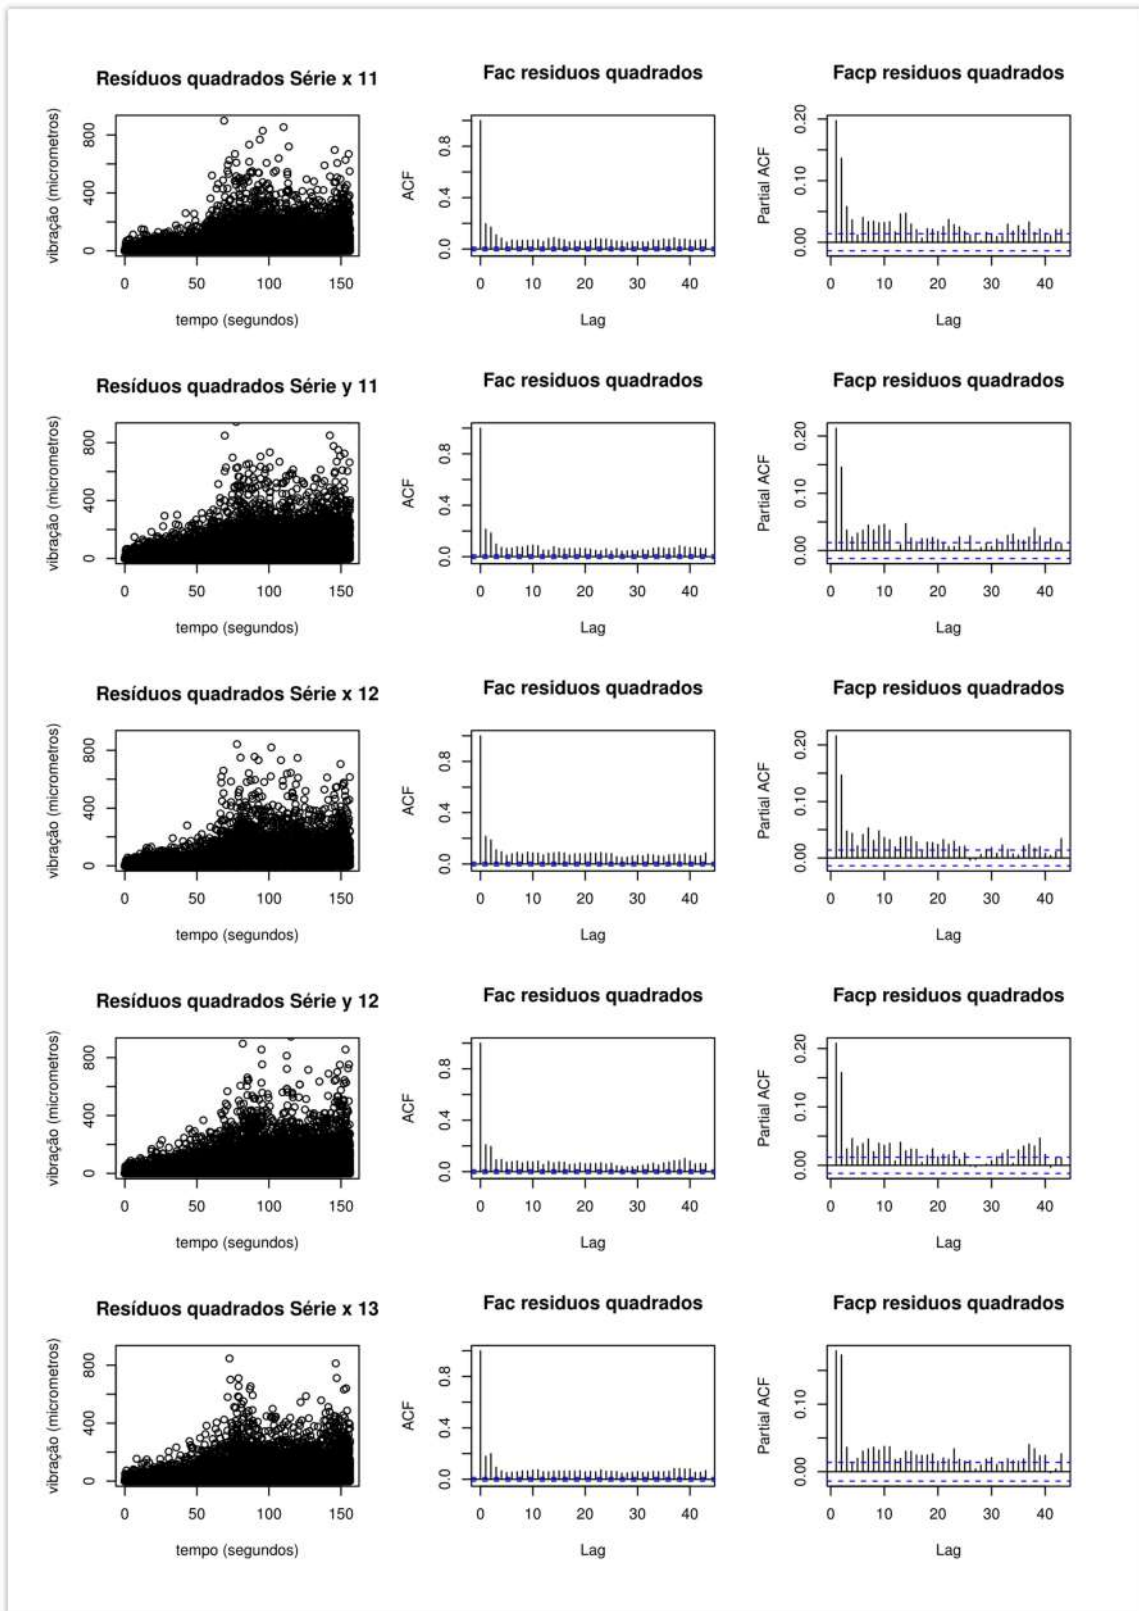
Anexo VI - Figura 26: Resíduos quadrados, FAC e FACP quadráticas parte 2



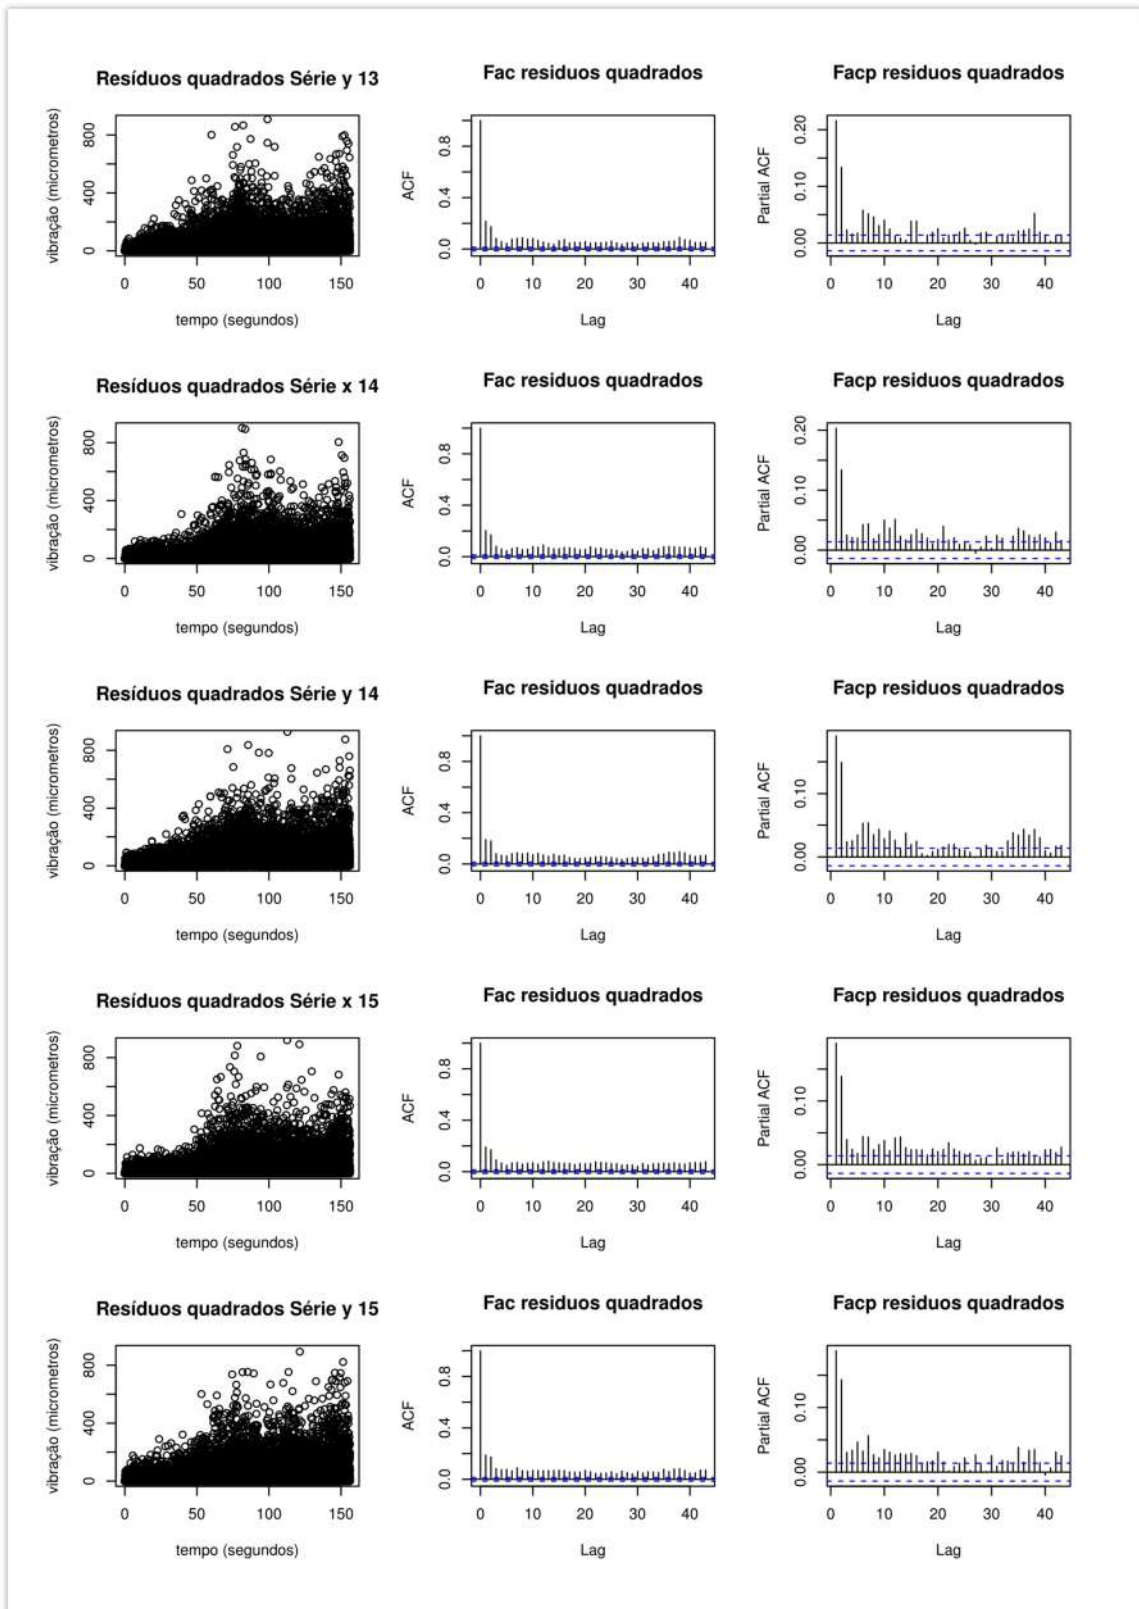
Anexo VI - Figura 27: Resíduos quadrados, FAC e FACP quadráticas parte 3



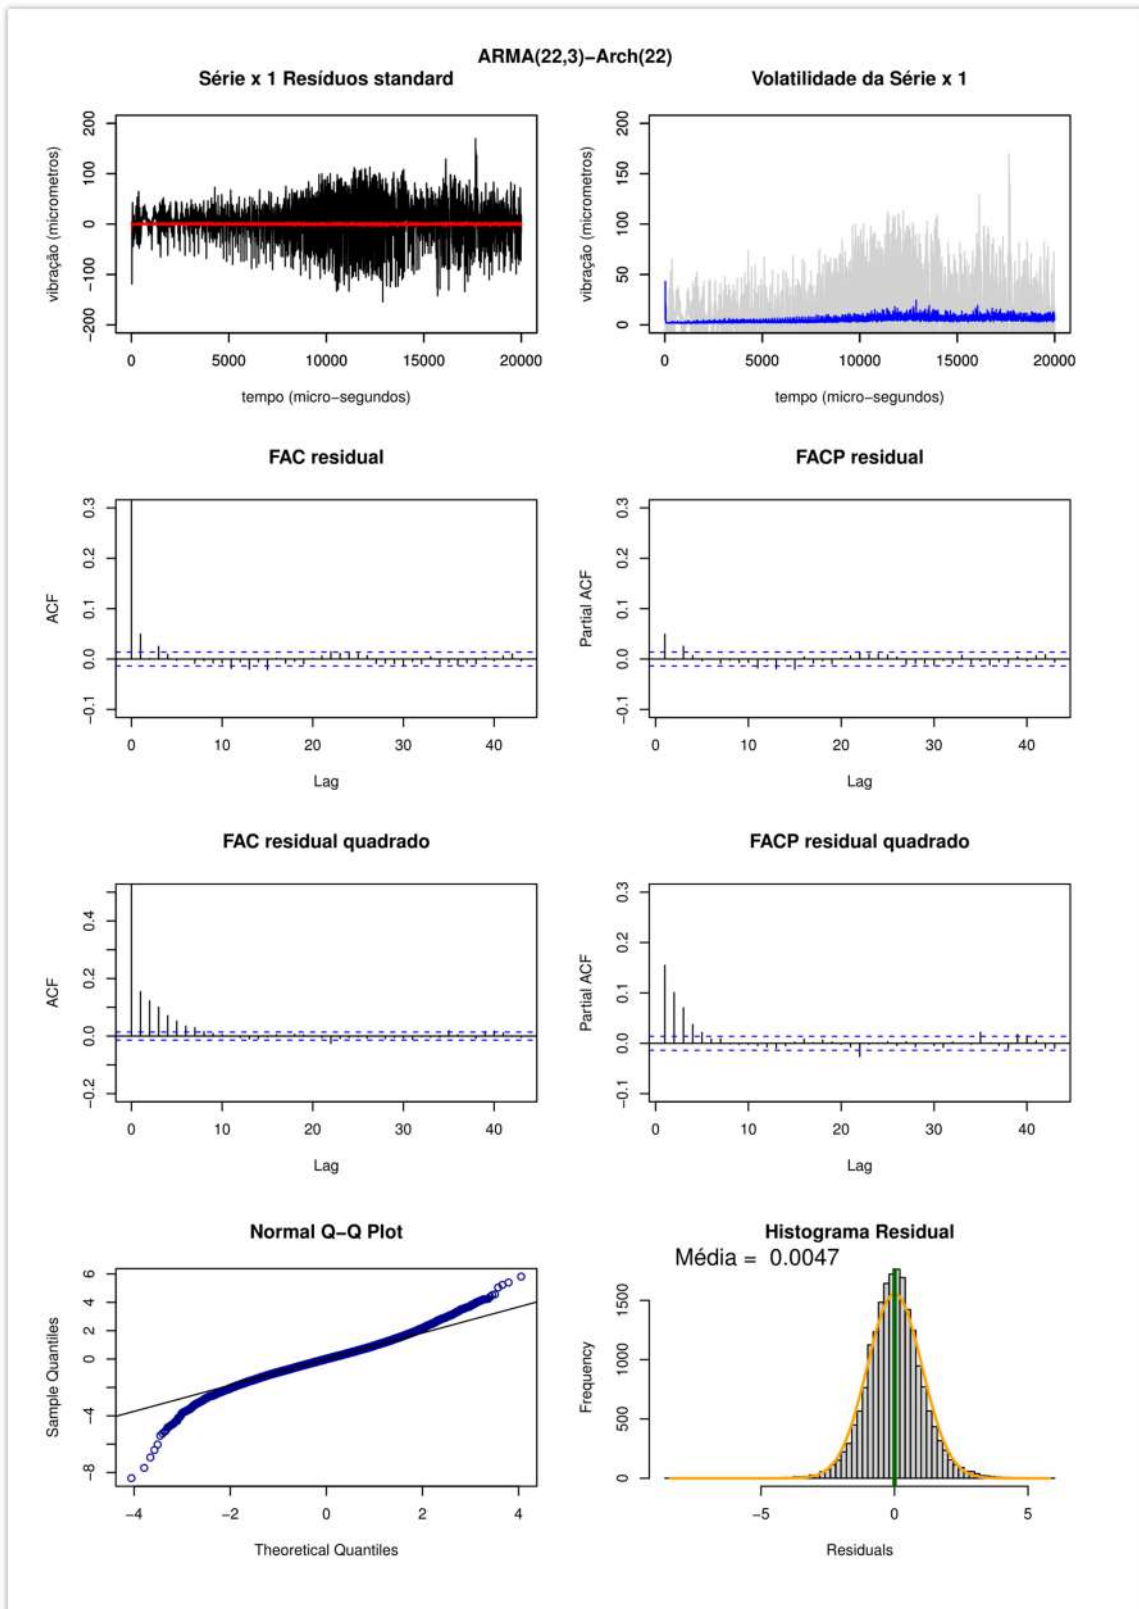
Anexo VI - Figura 28: Resíduos quadrados, FAC e FACP quadráticas parte 4



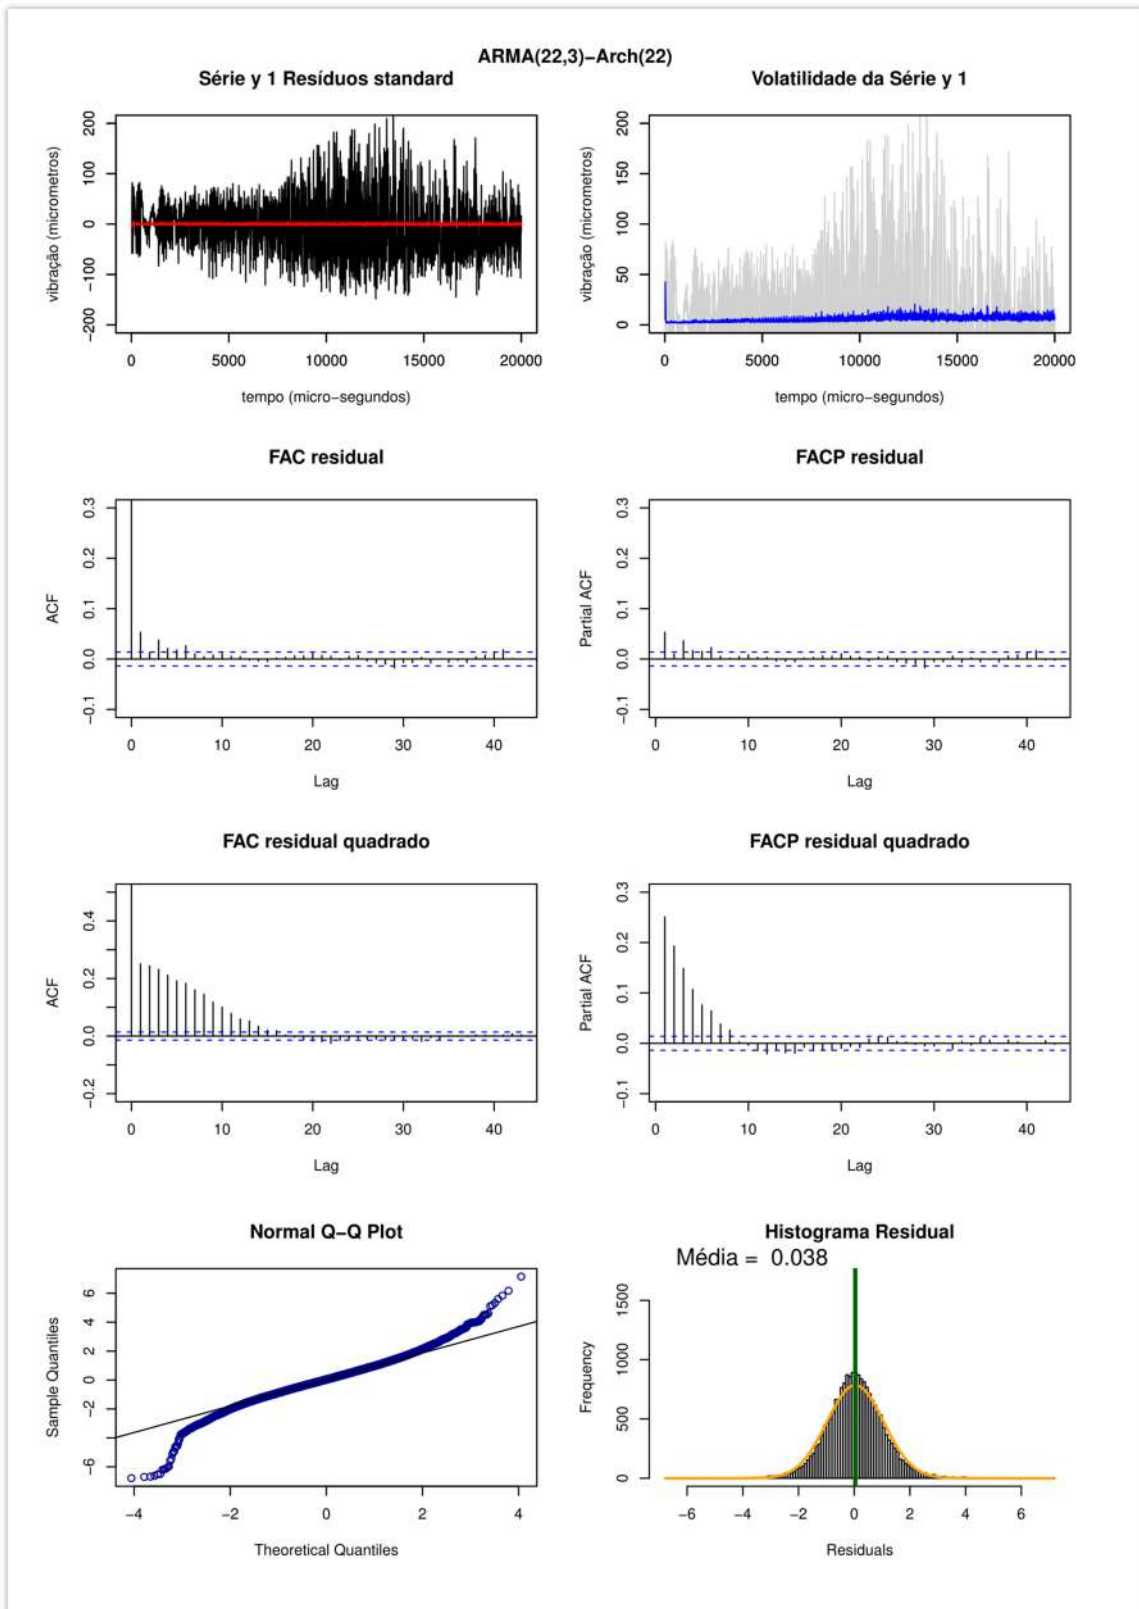
Anexo VI - Figura 29: Resíduos quadrados, FAC e FACP quadráticas parte 5



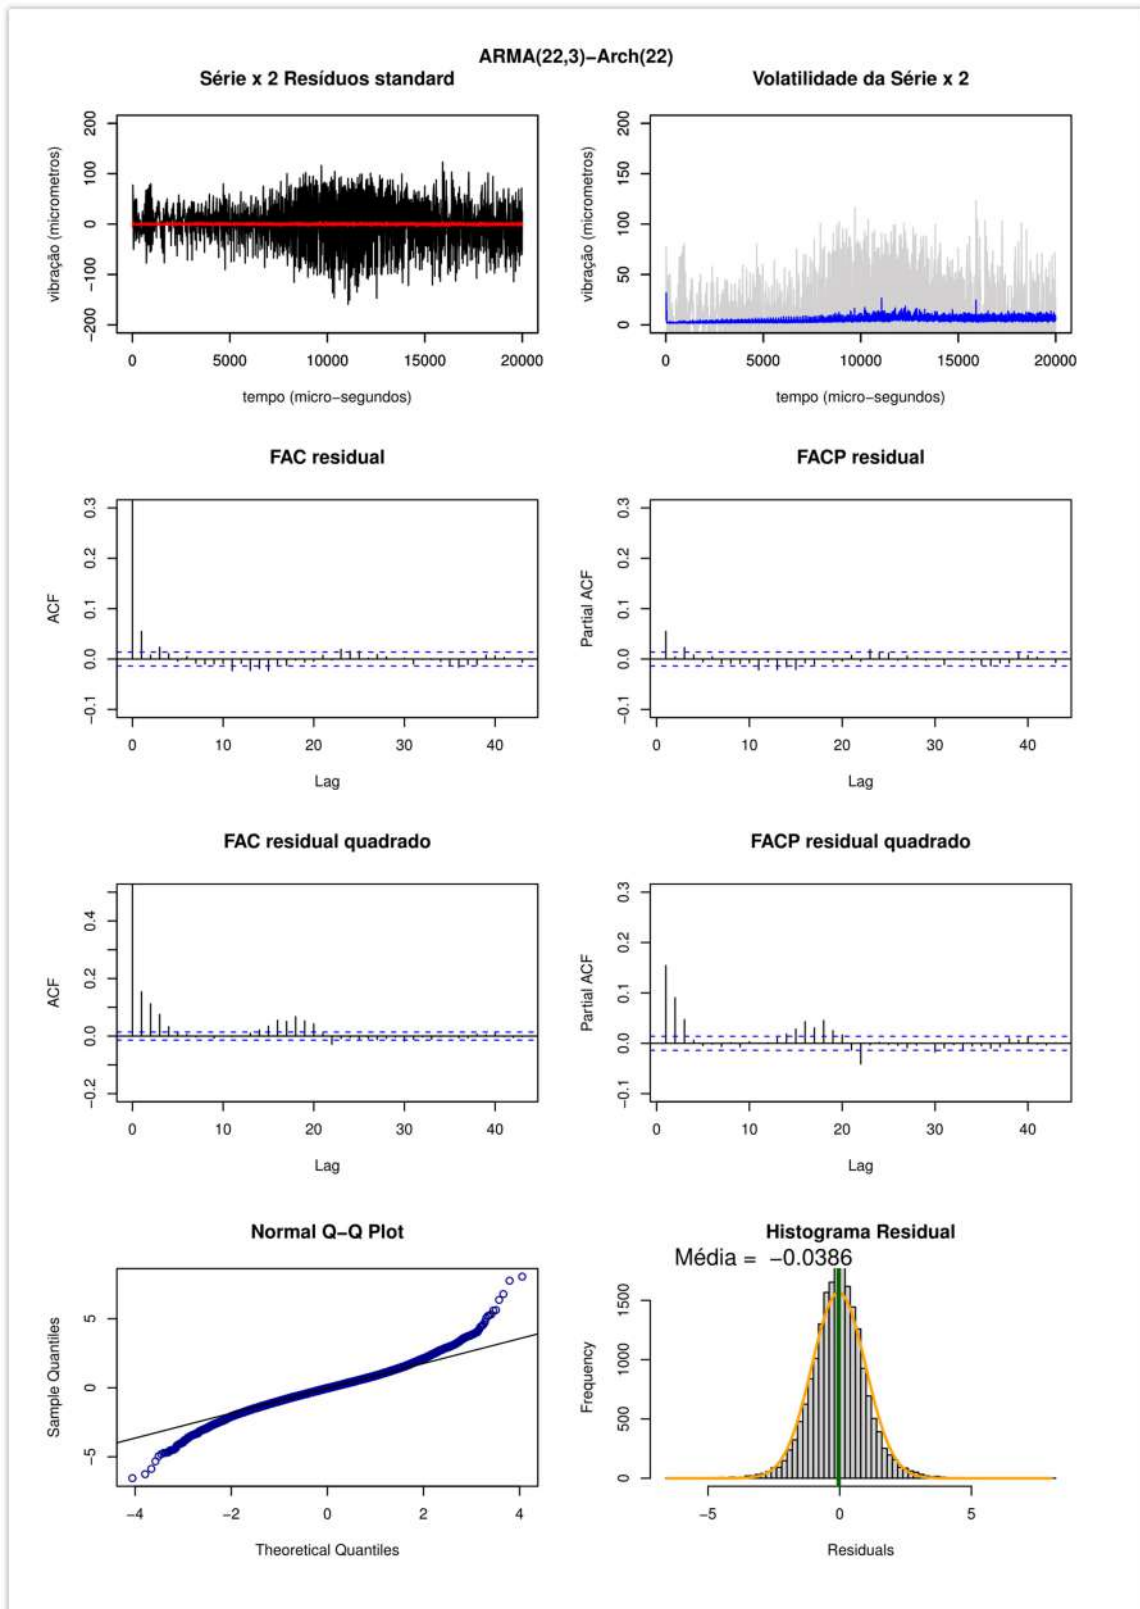
Anexo VI - Figura 30: Resíduos quadrados, FAC e FACP quadráticas parte 6



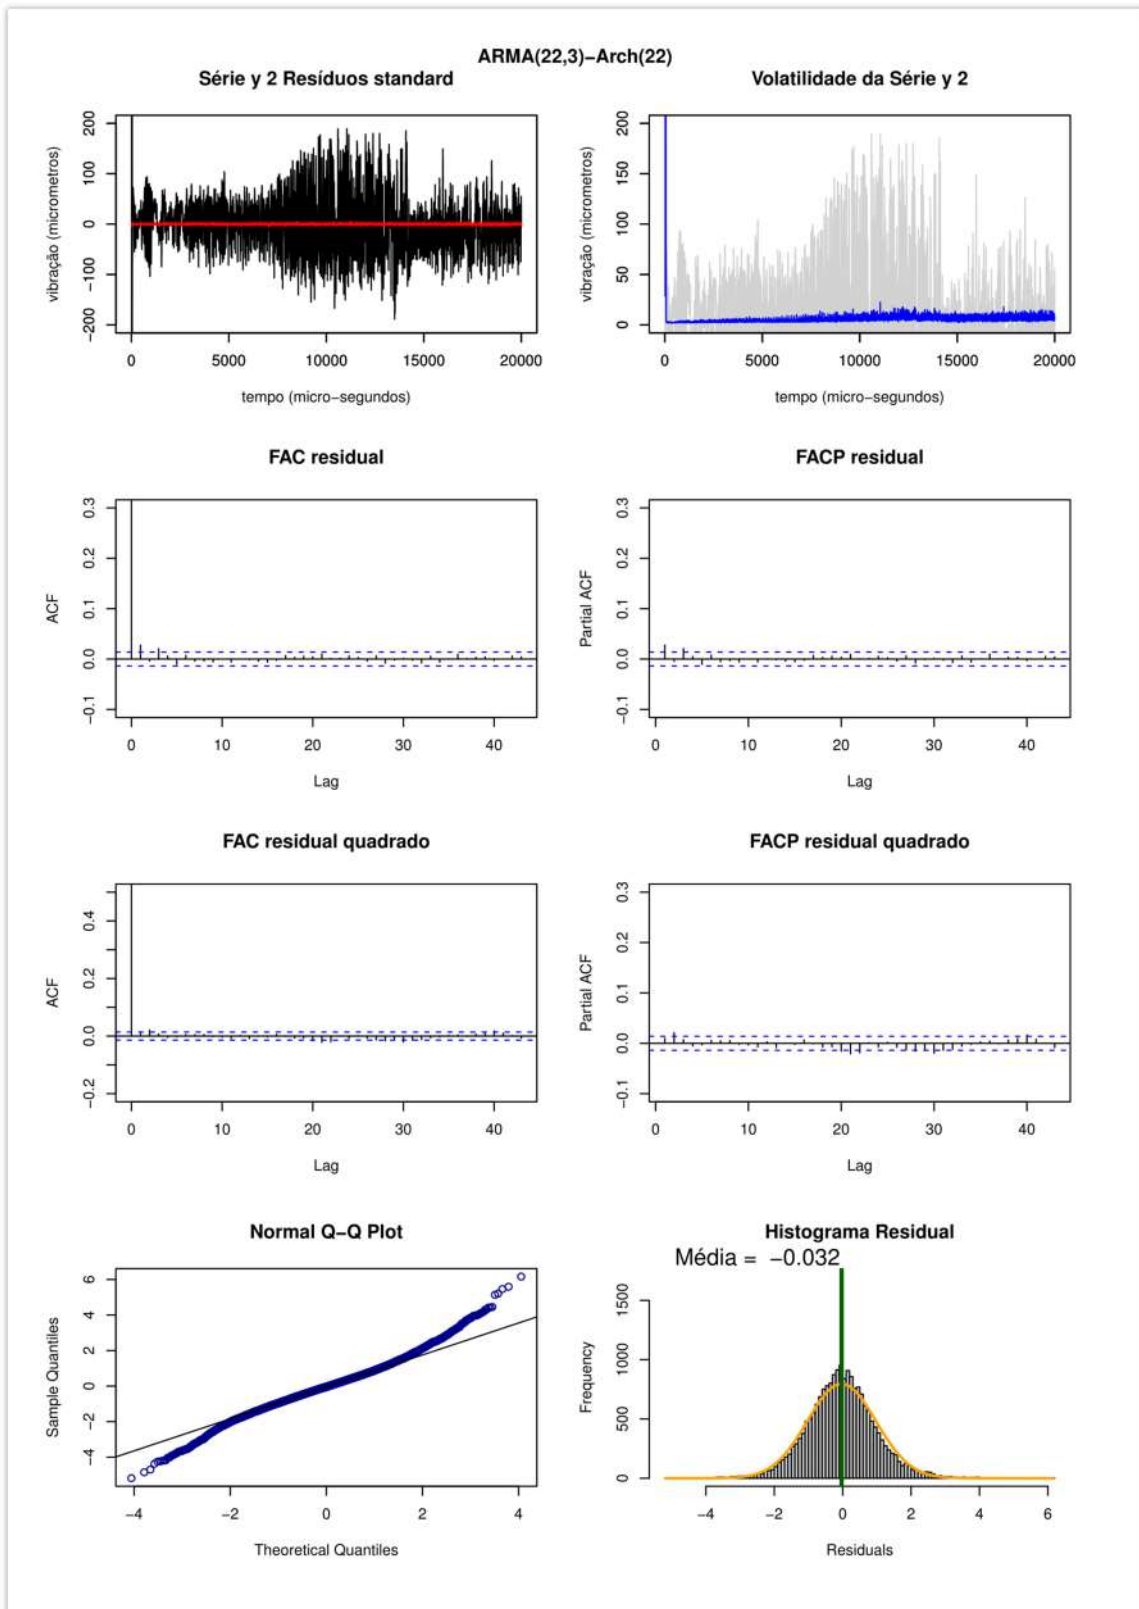
Anexo VI - Figura 31: Resultado modelo ARMA(22,3)- ARCH(22) parte 1



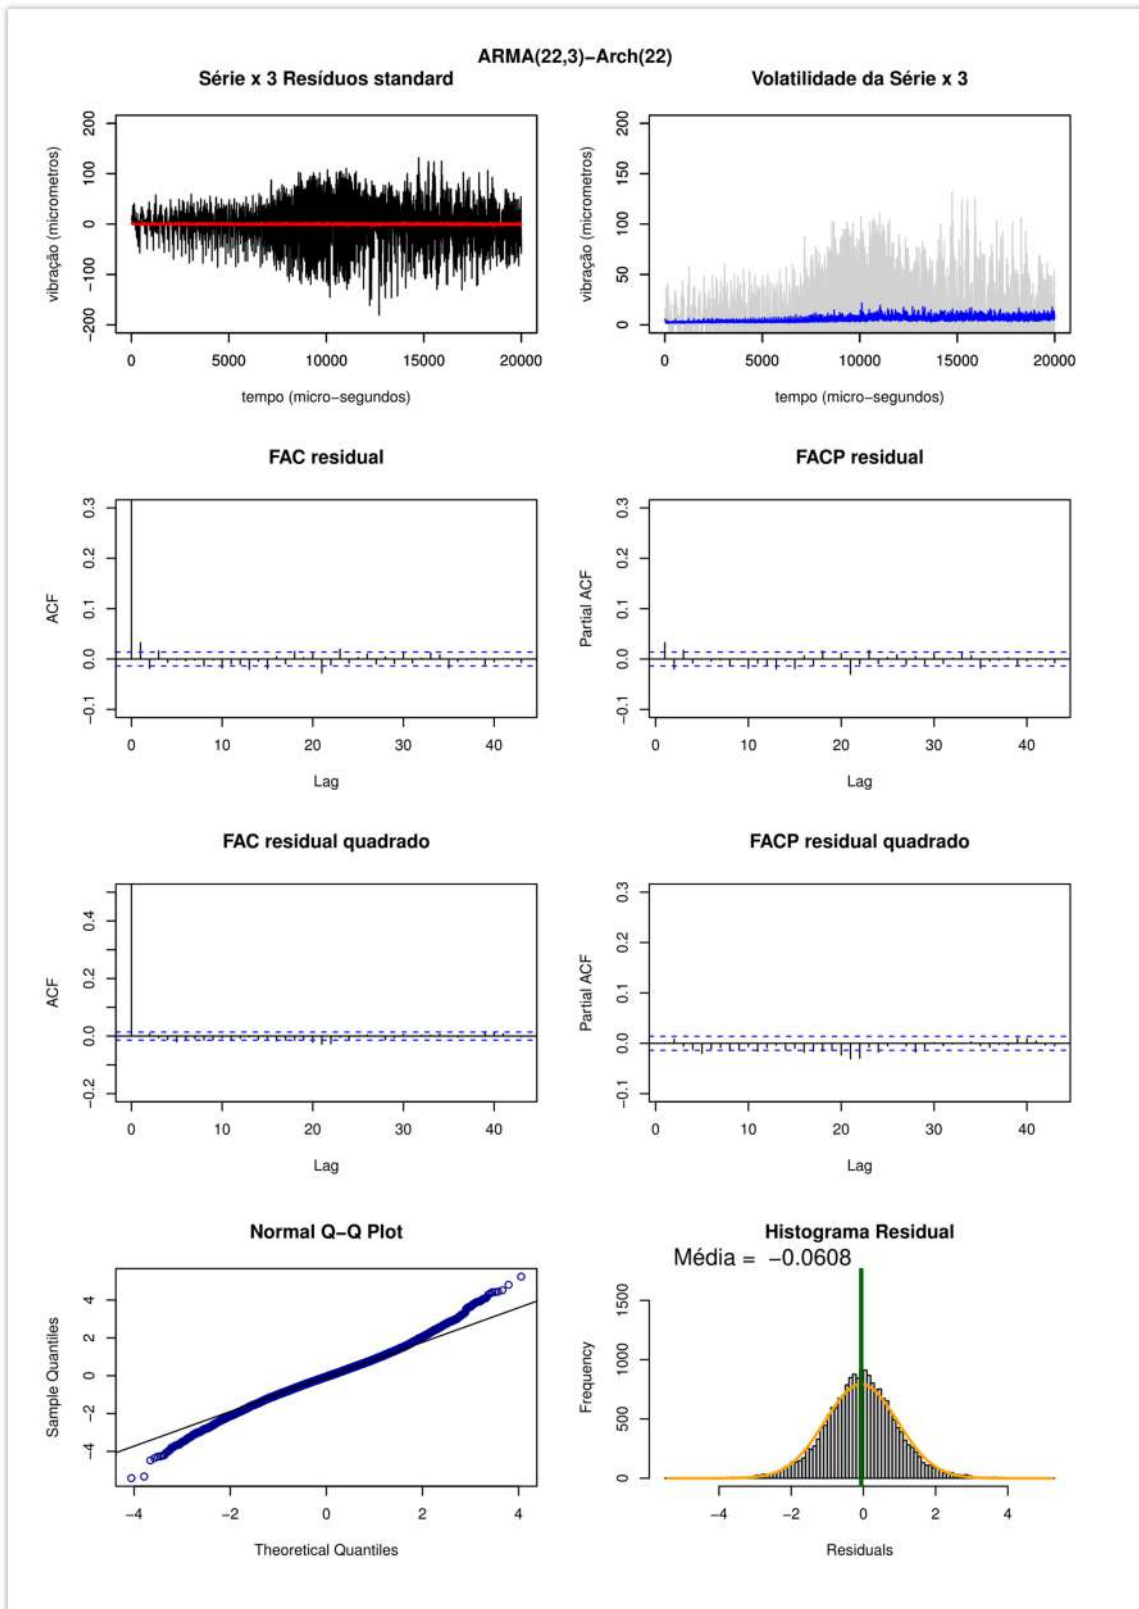
Anexo VI - Figura 32: Resultado modelo ARMA(22,3)- ARCH(22) parte 2



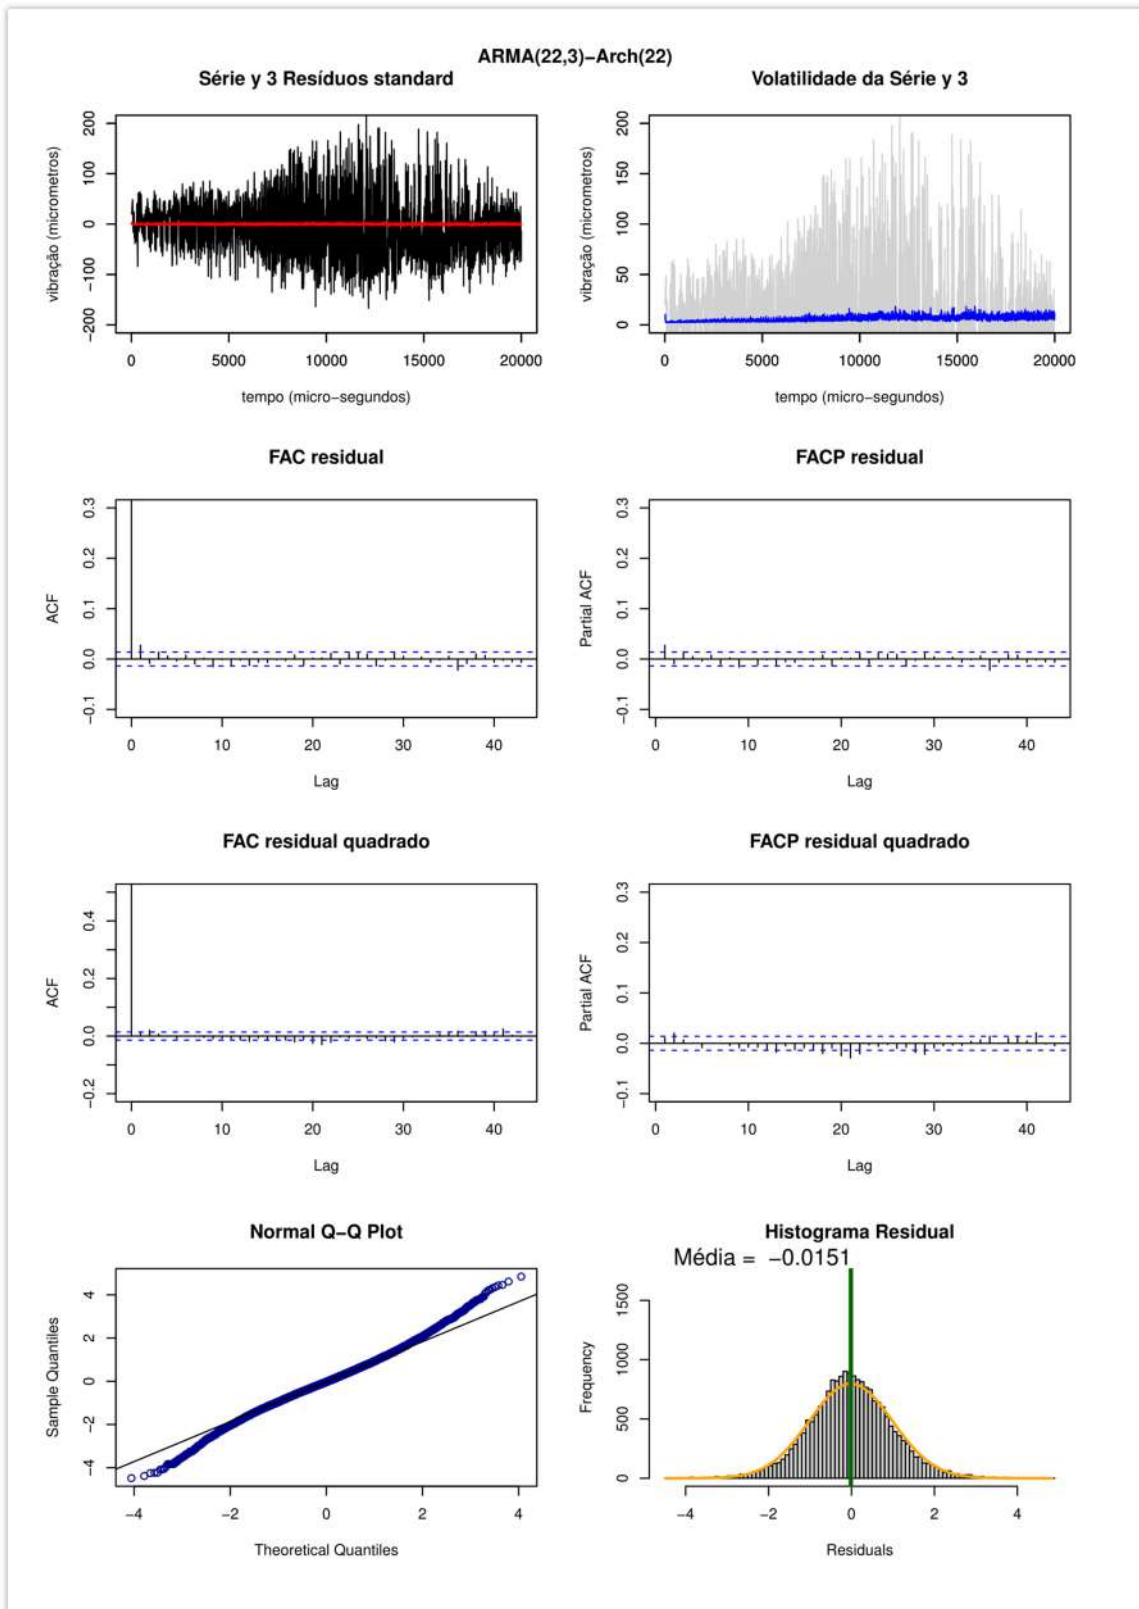
Anexo VI - Figura 33: Resultado modelo ARMA(22,3)- ARCH(22) parte 3



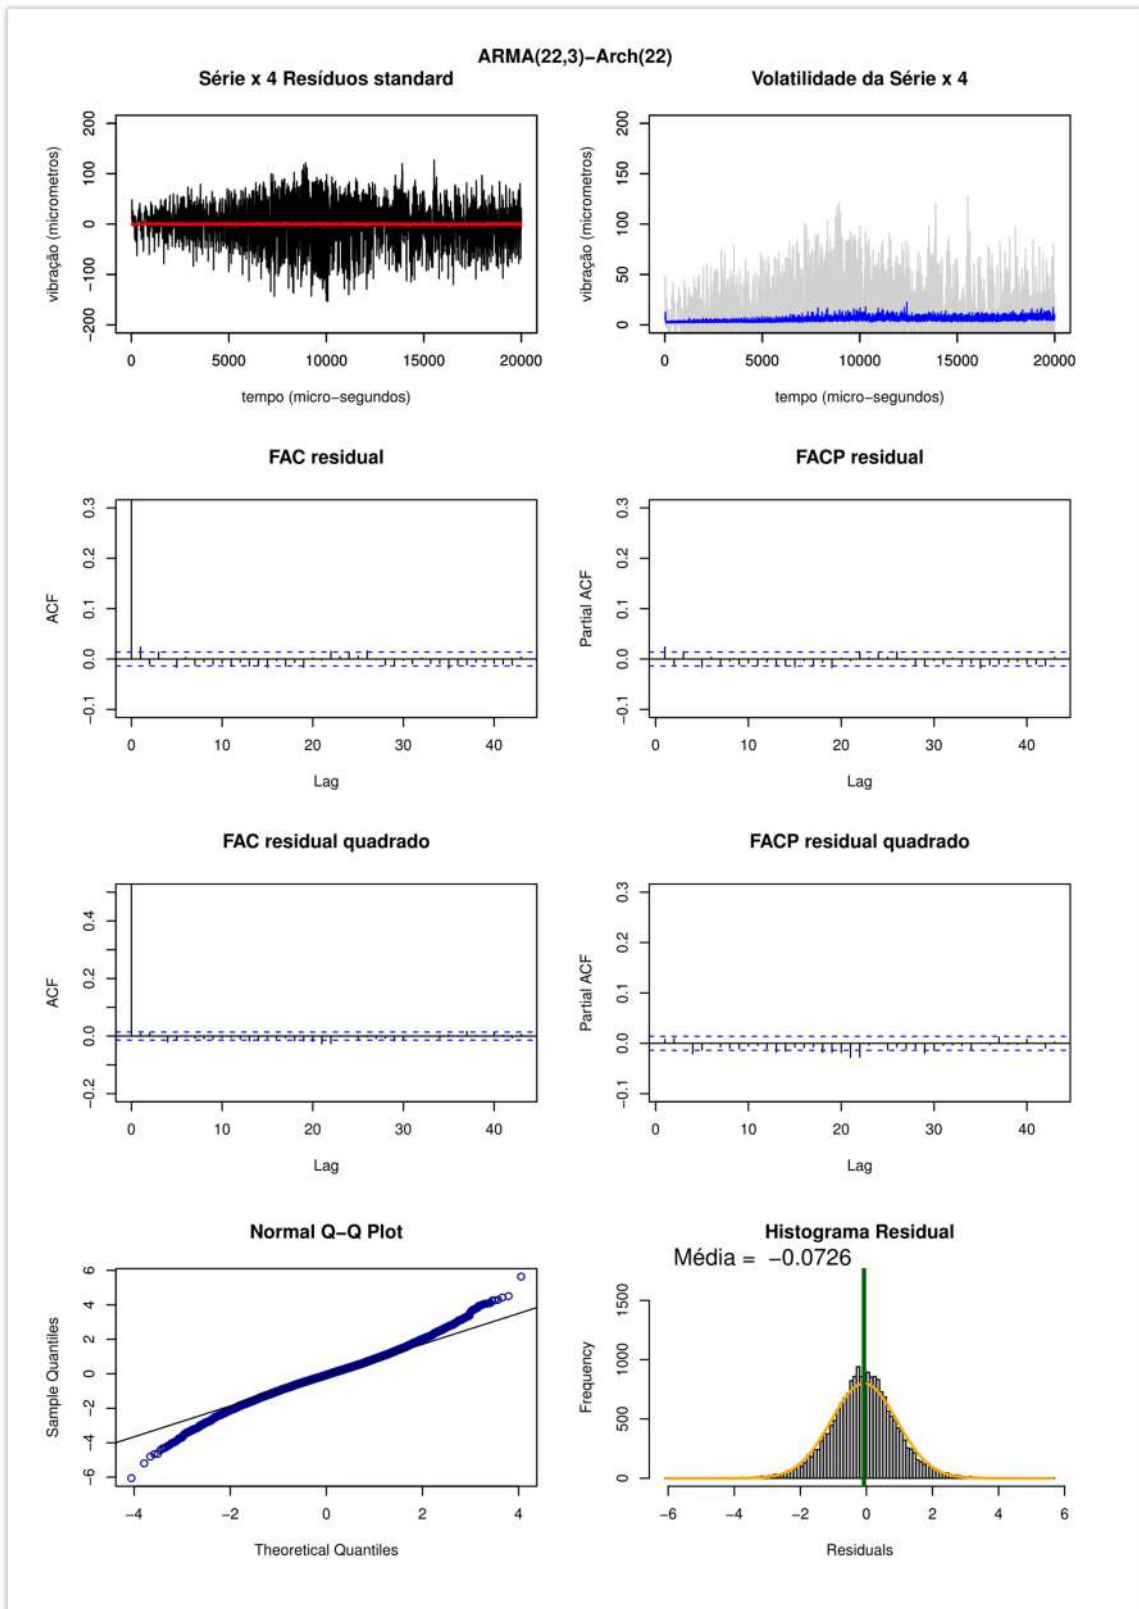
Anexo VI - Figura 34: Resultado modelo ARMA(22,3)- ARCH(22) parte 4



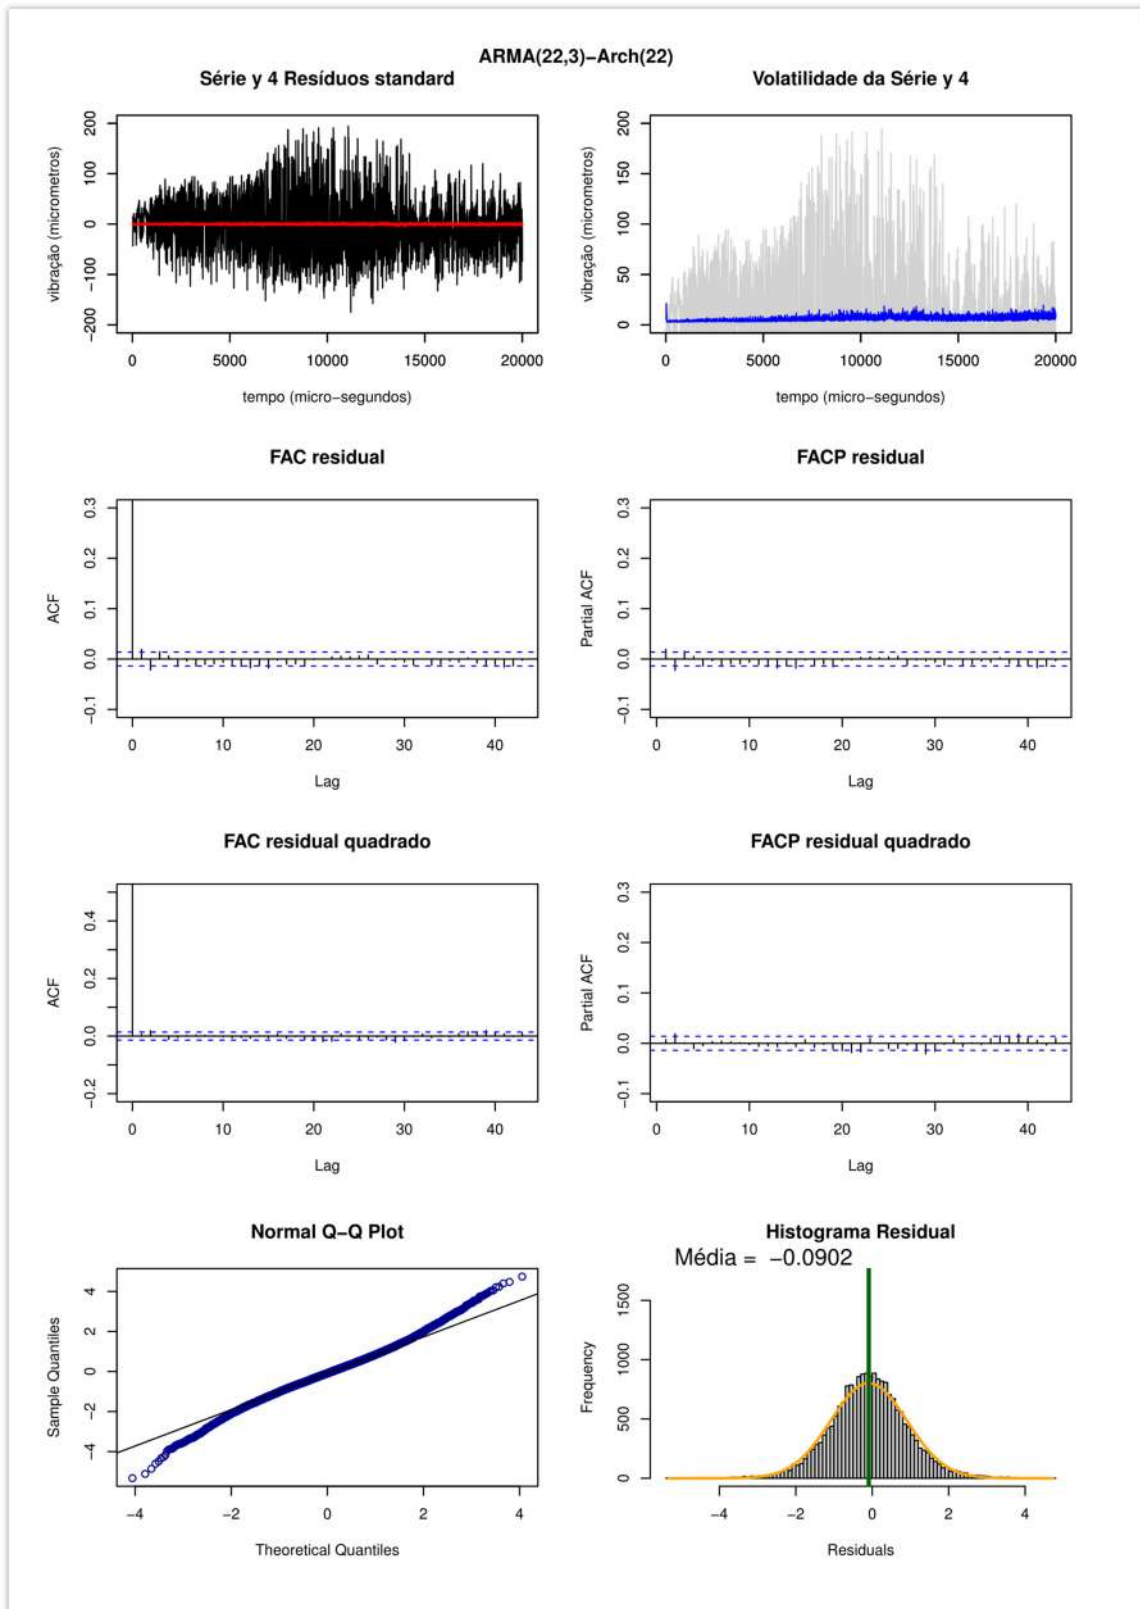
Anexo VI - Figura 35: Resultado modelo ARMA(22,3)- ARCH(22) parte 5



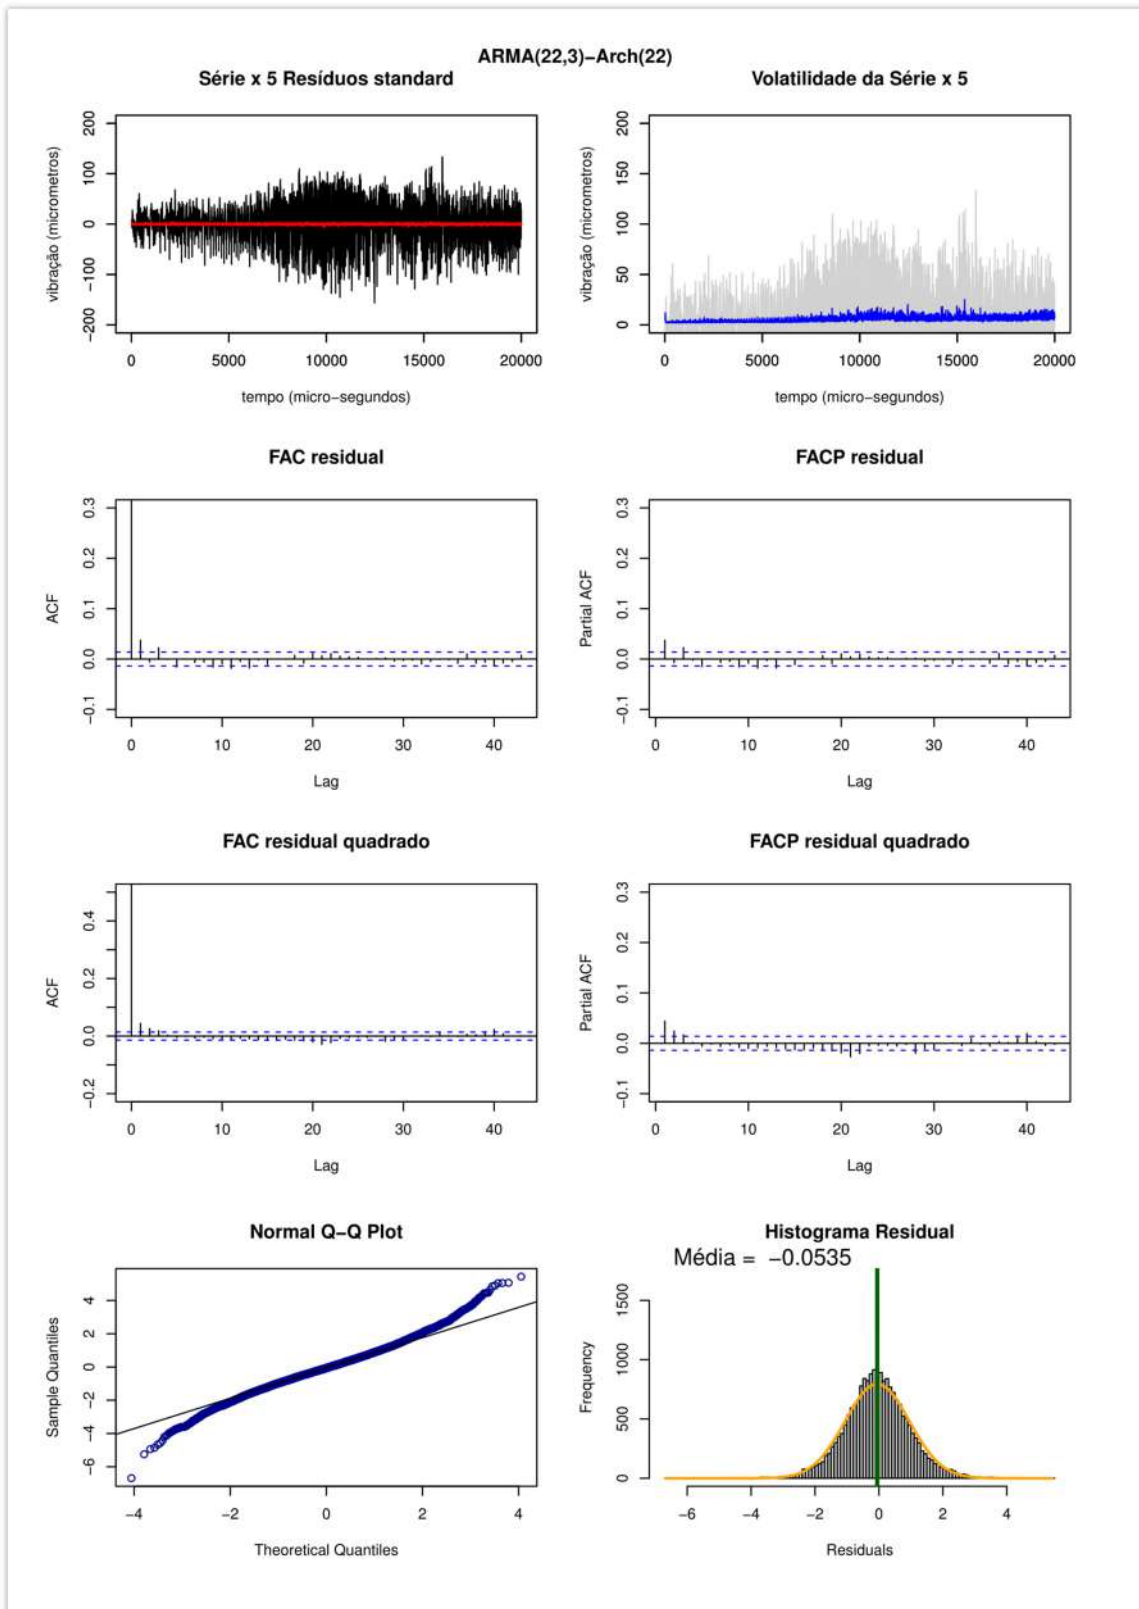
Anexo VI - Figura 36: Resultado modelo ARMA(22,3)- ARCH(22) parte 6



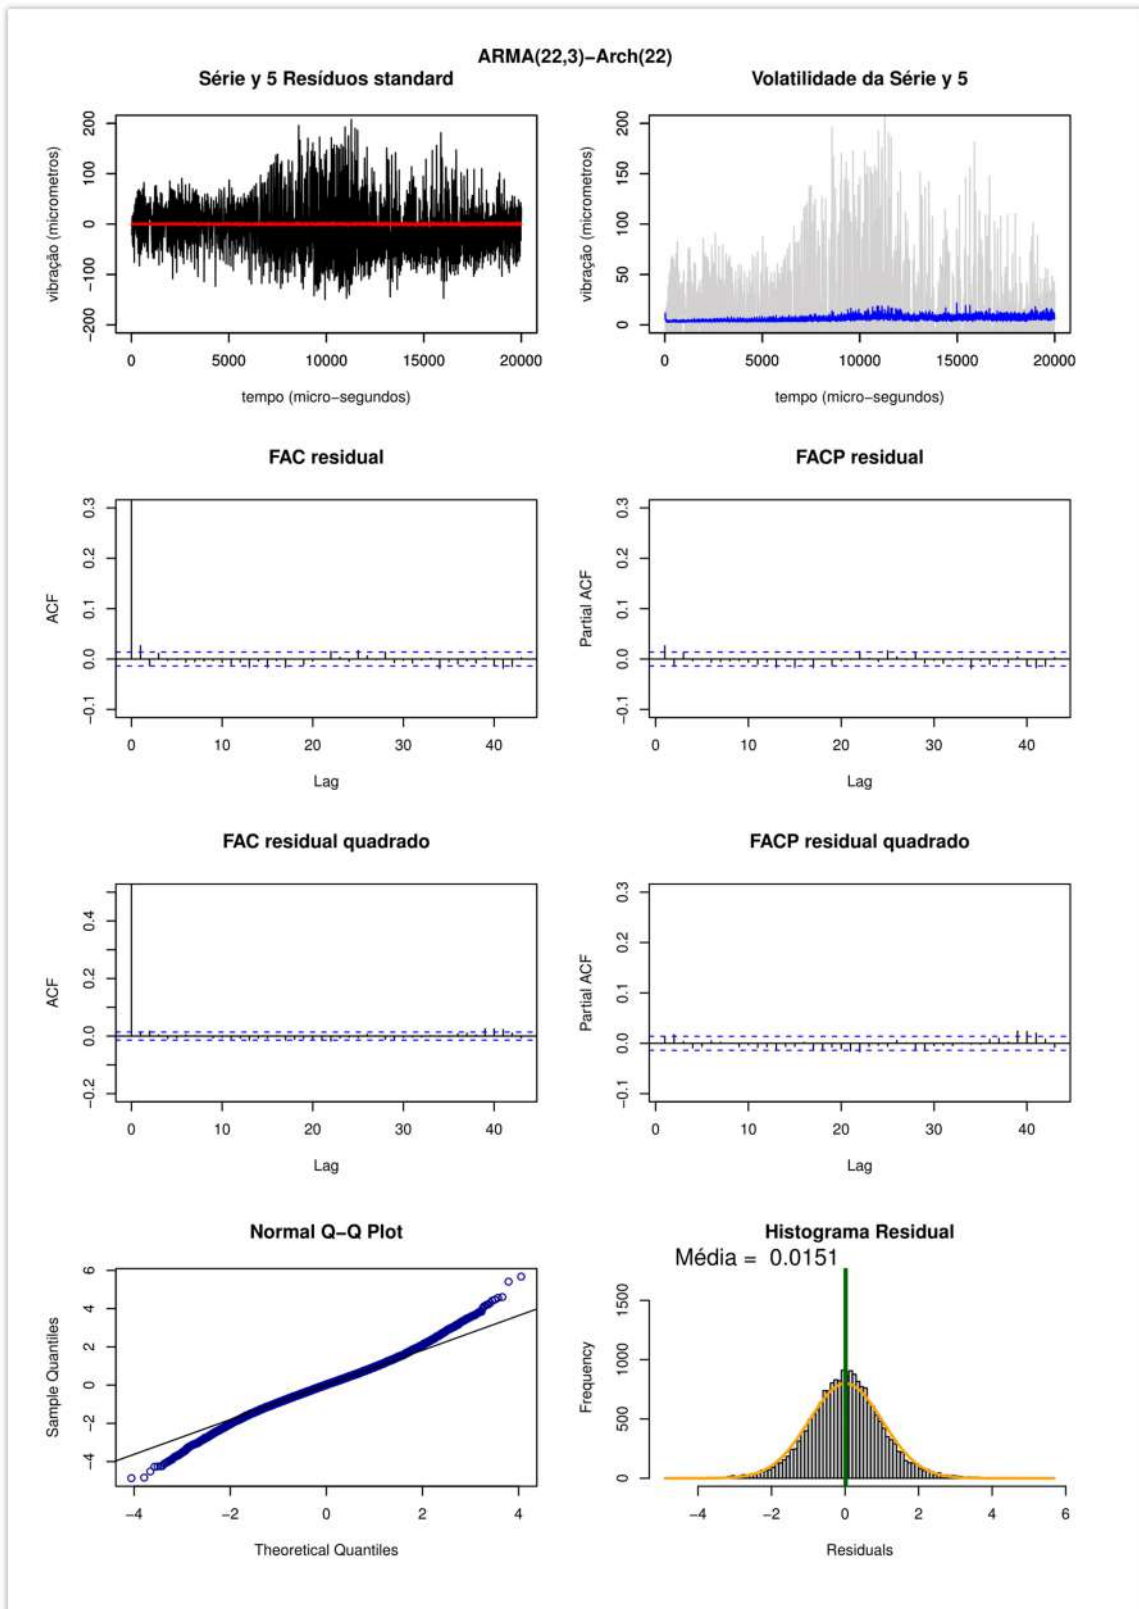
Anexo VI - Figura 37: Resultado modelo ARMA(22,3)- ARCH(22) parte 7



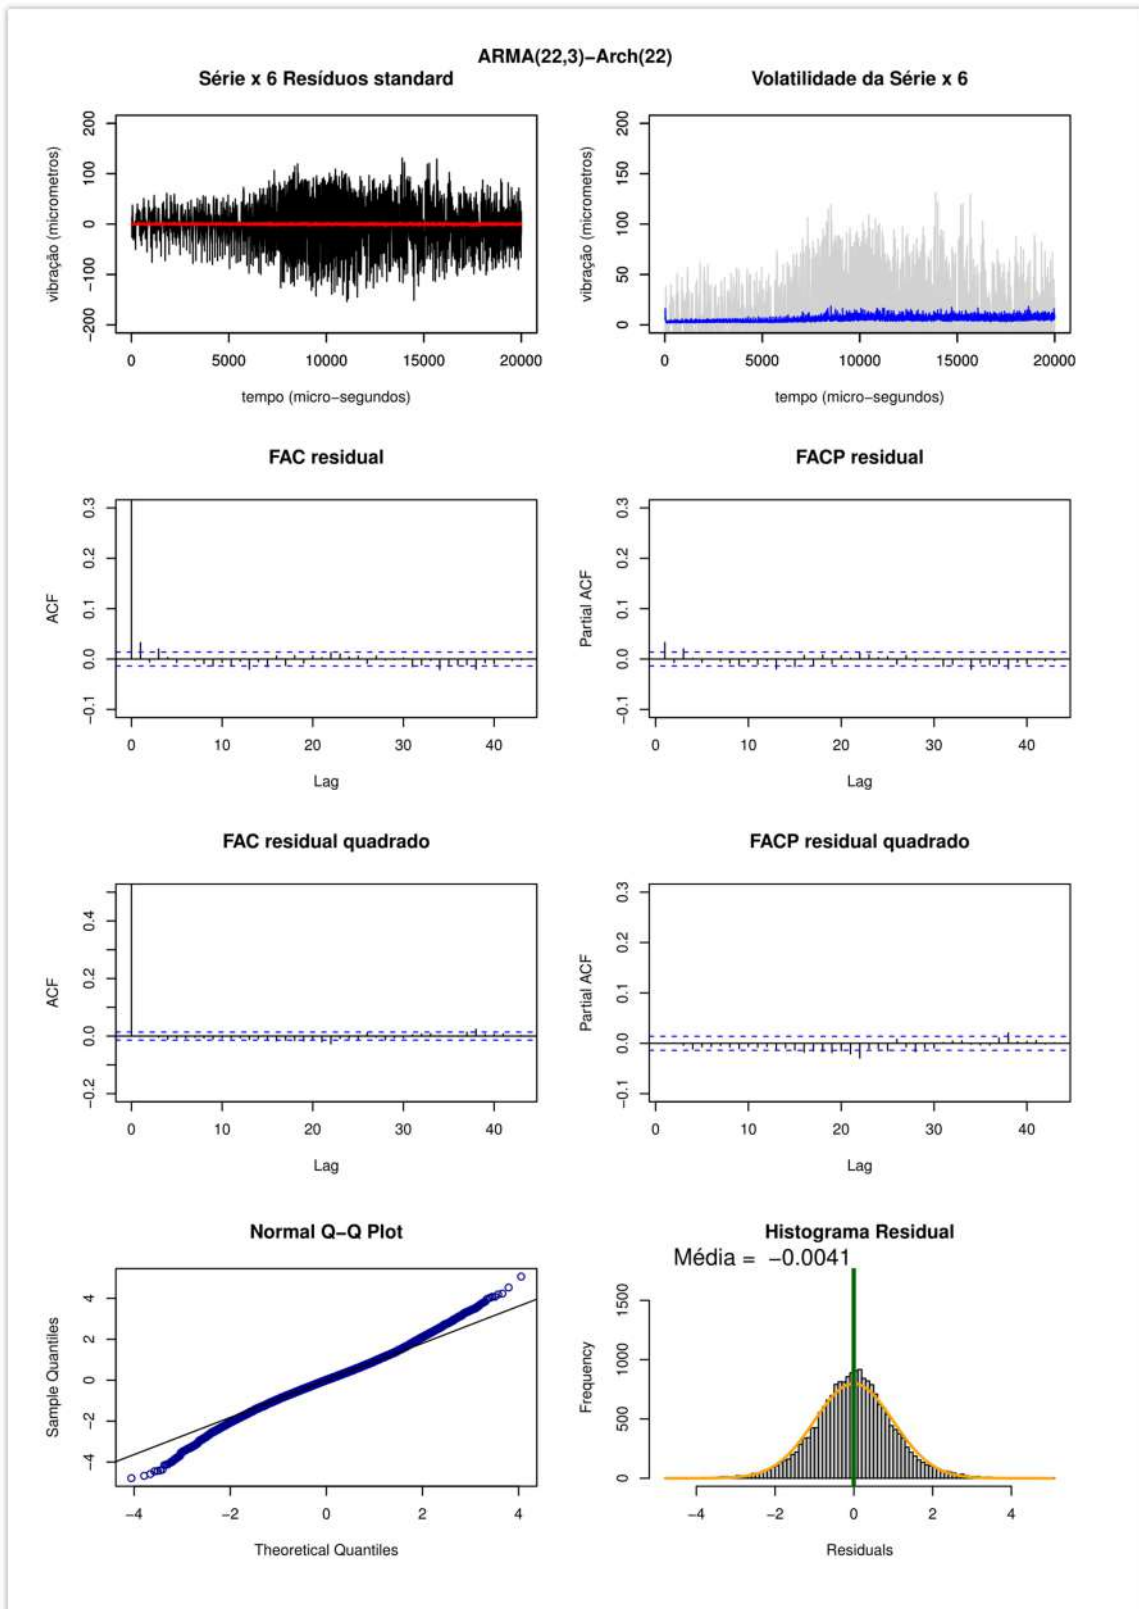
Anexo VI - Figura 38: Resultado modelo ARMA(22,3)- ARCH(22) parte 8



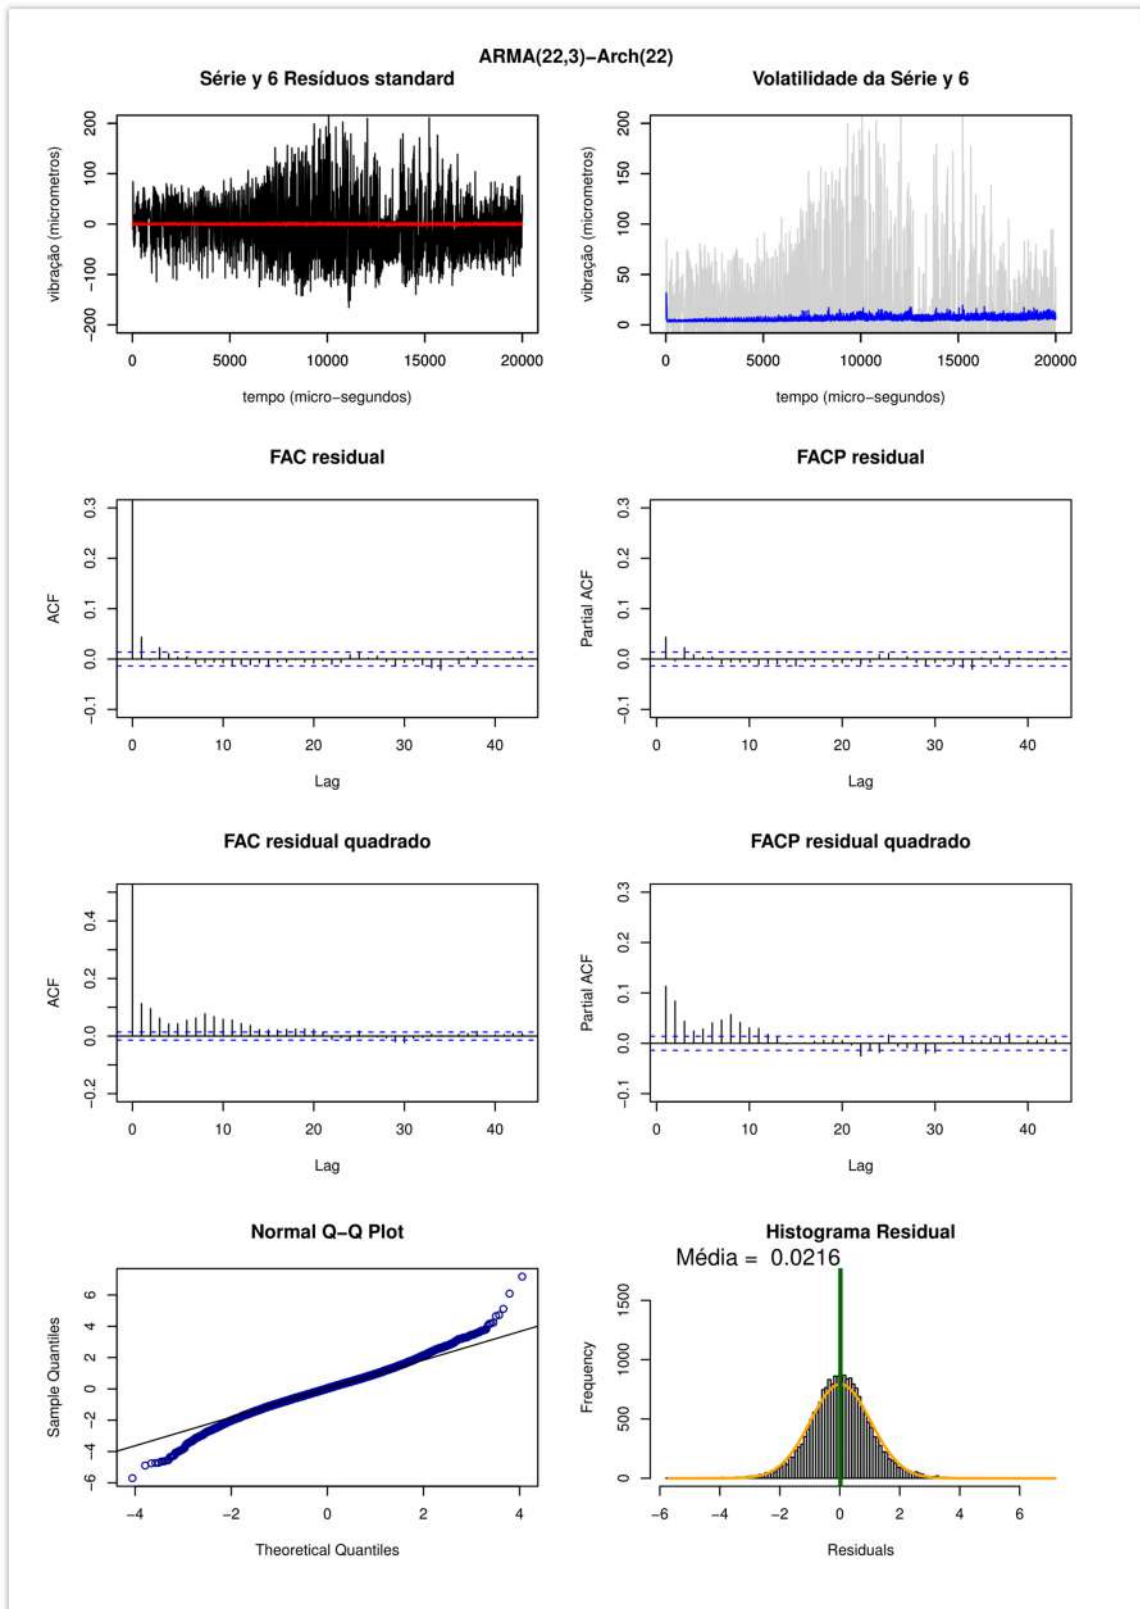
Anexo VI - Figura 39: Resultado modelo ARMA(22,3)- ARCH(22) parte 9



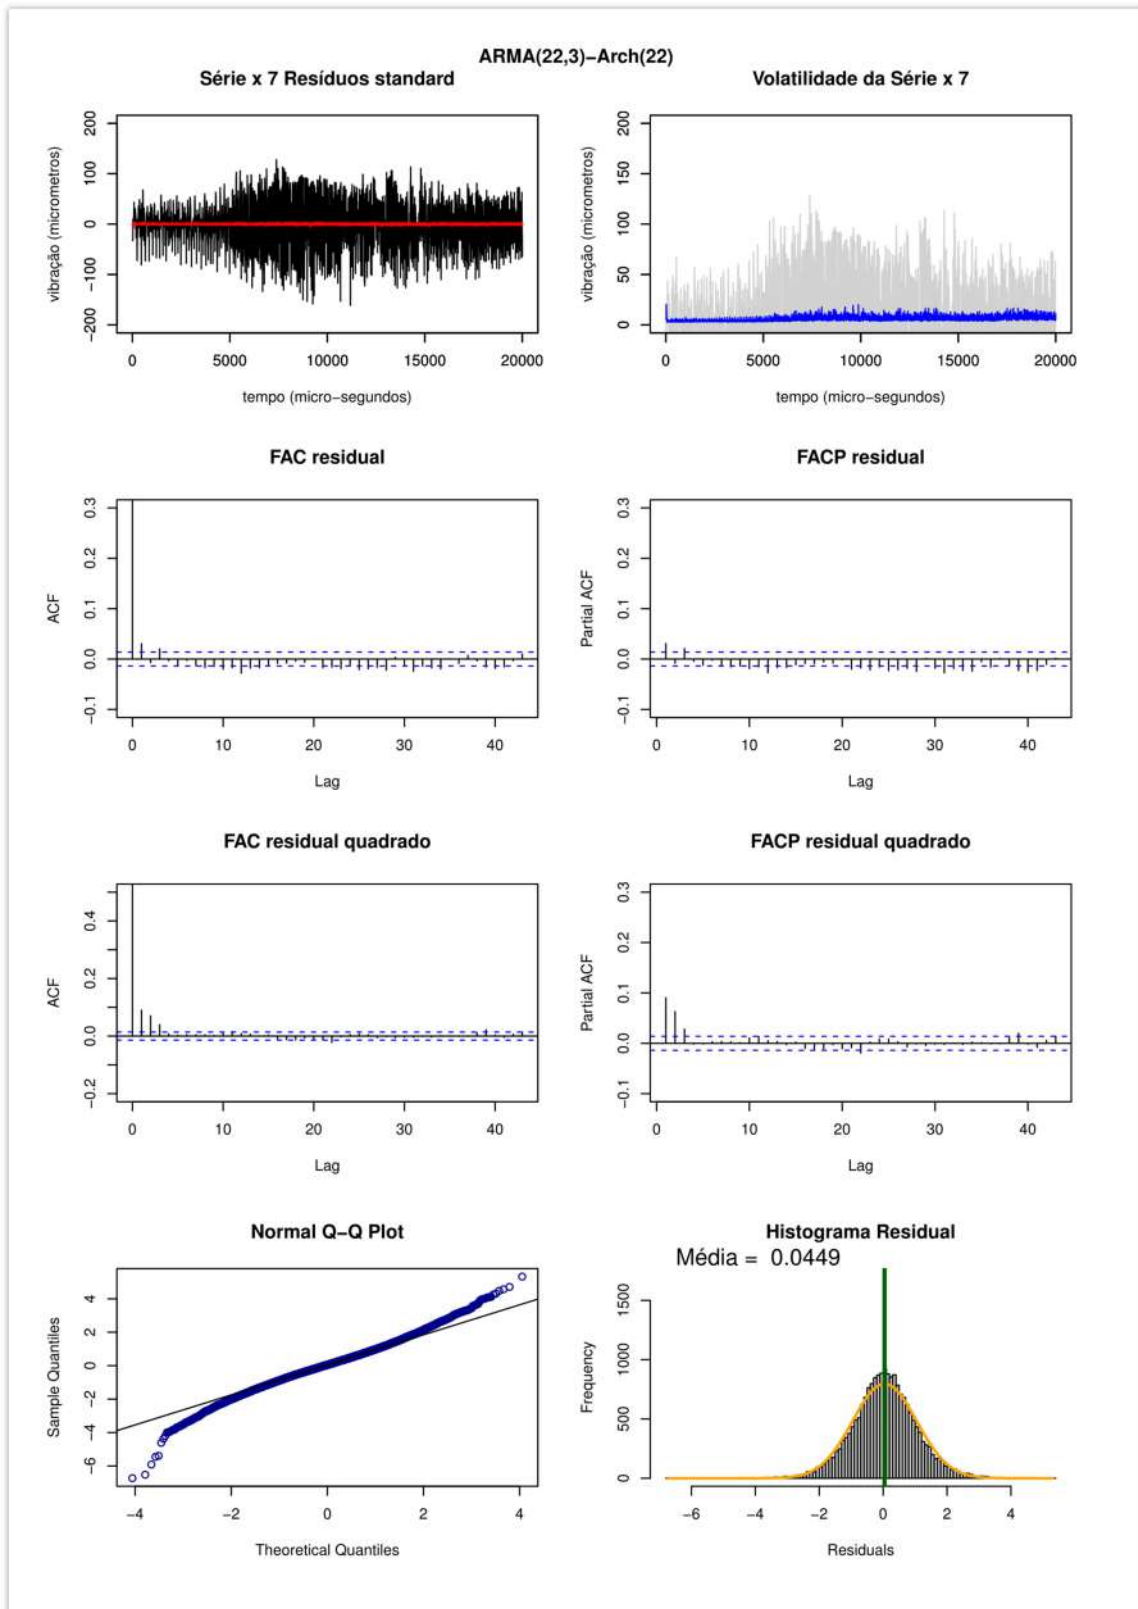
Anexo VI - Figura 40: Resultado modelo ARMA(22,3)- ARCH(22) parte 10



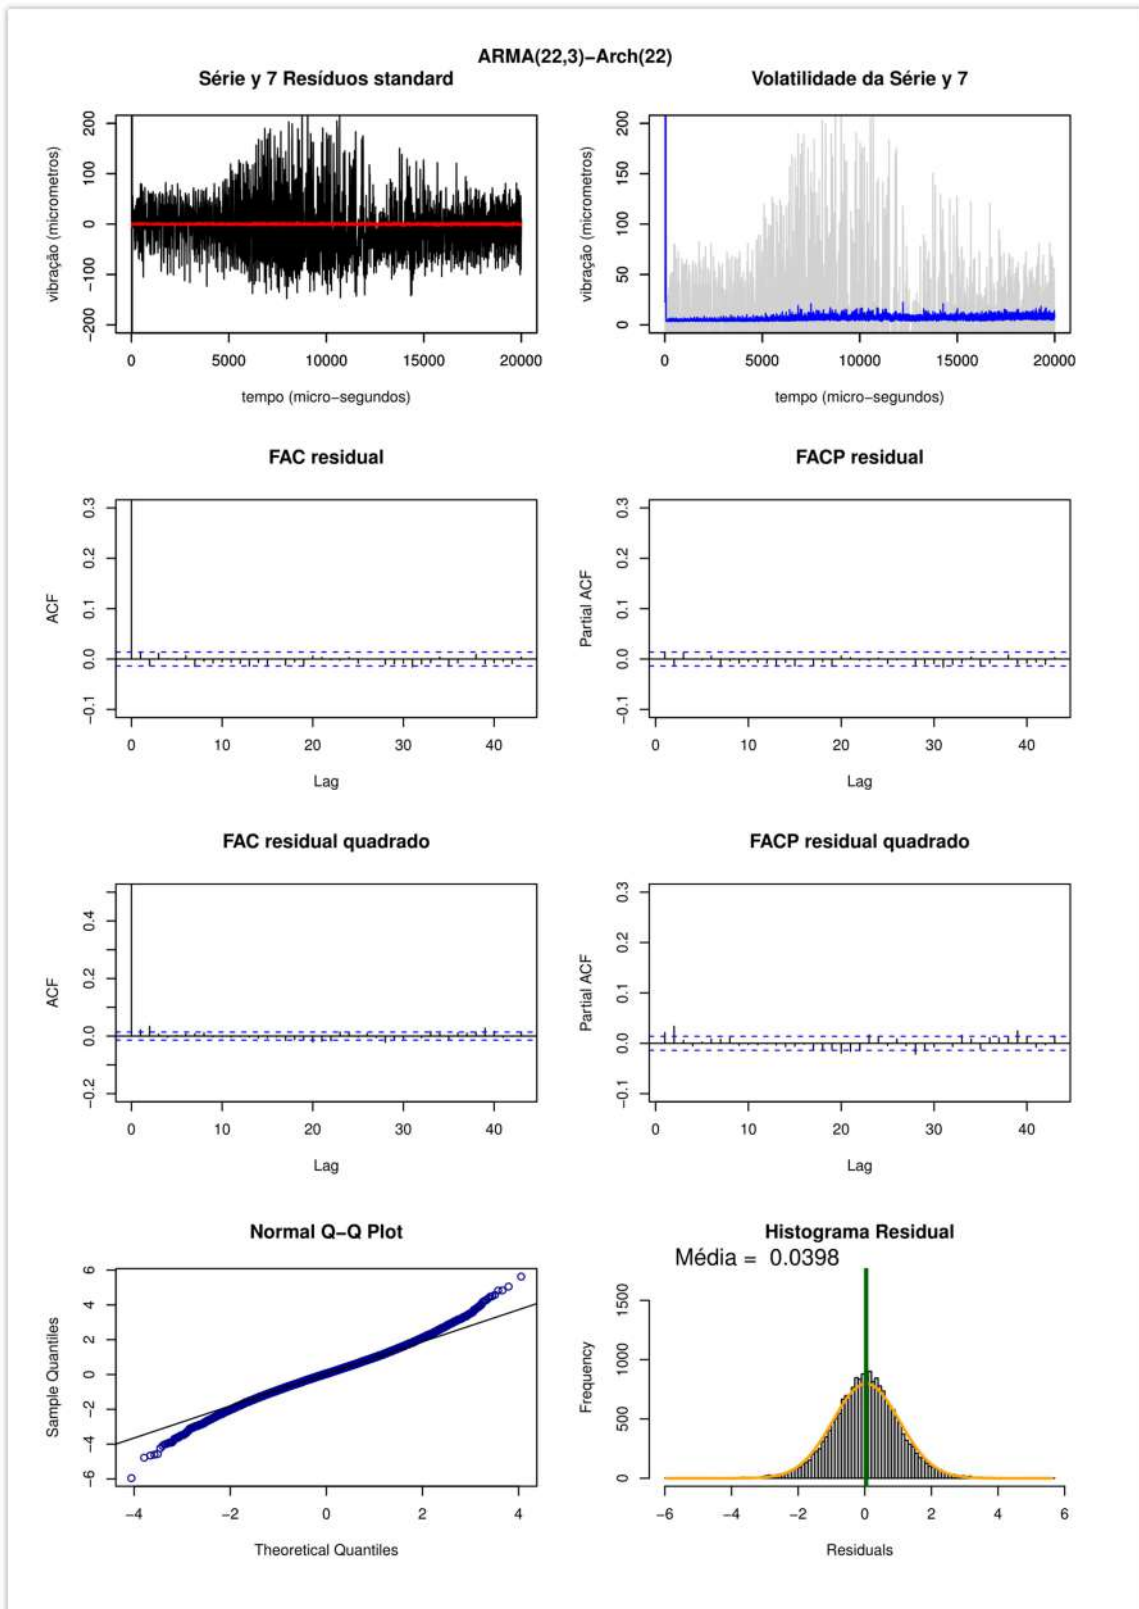
Anexo VI - Figura 41: Resultado modelo ARMA(22,3)- ARCH(22) parte 11



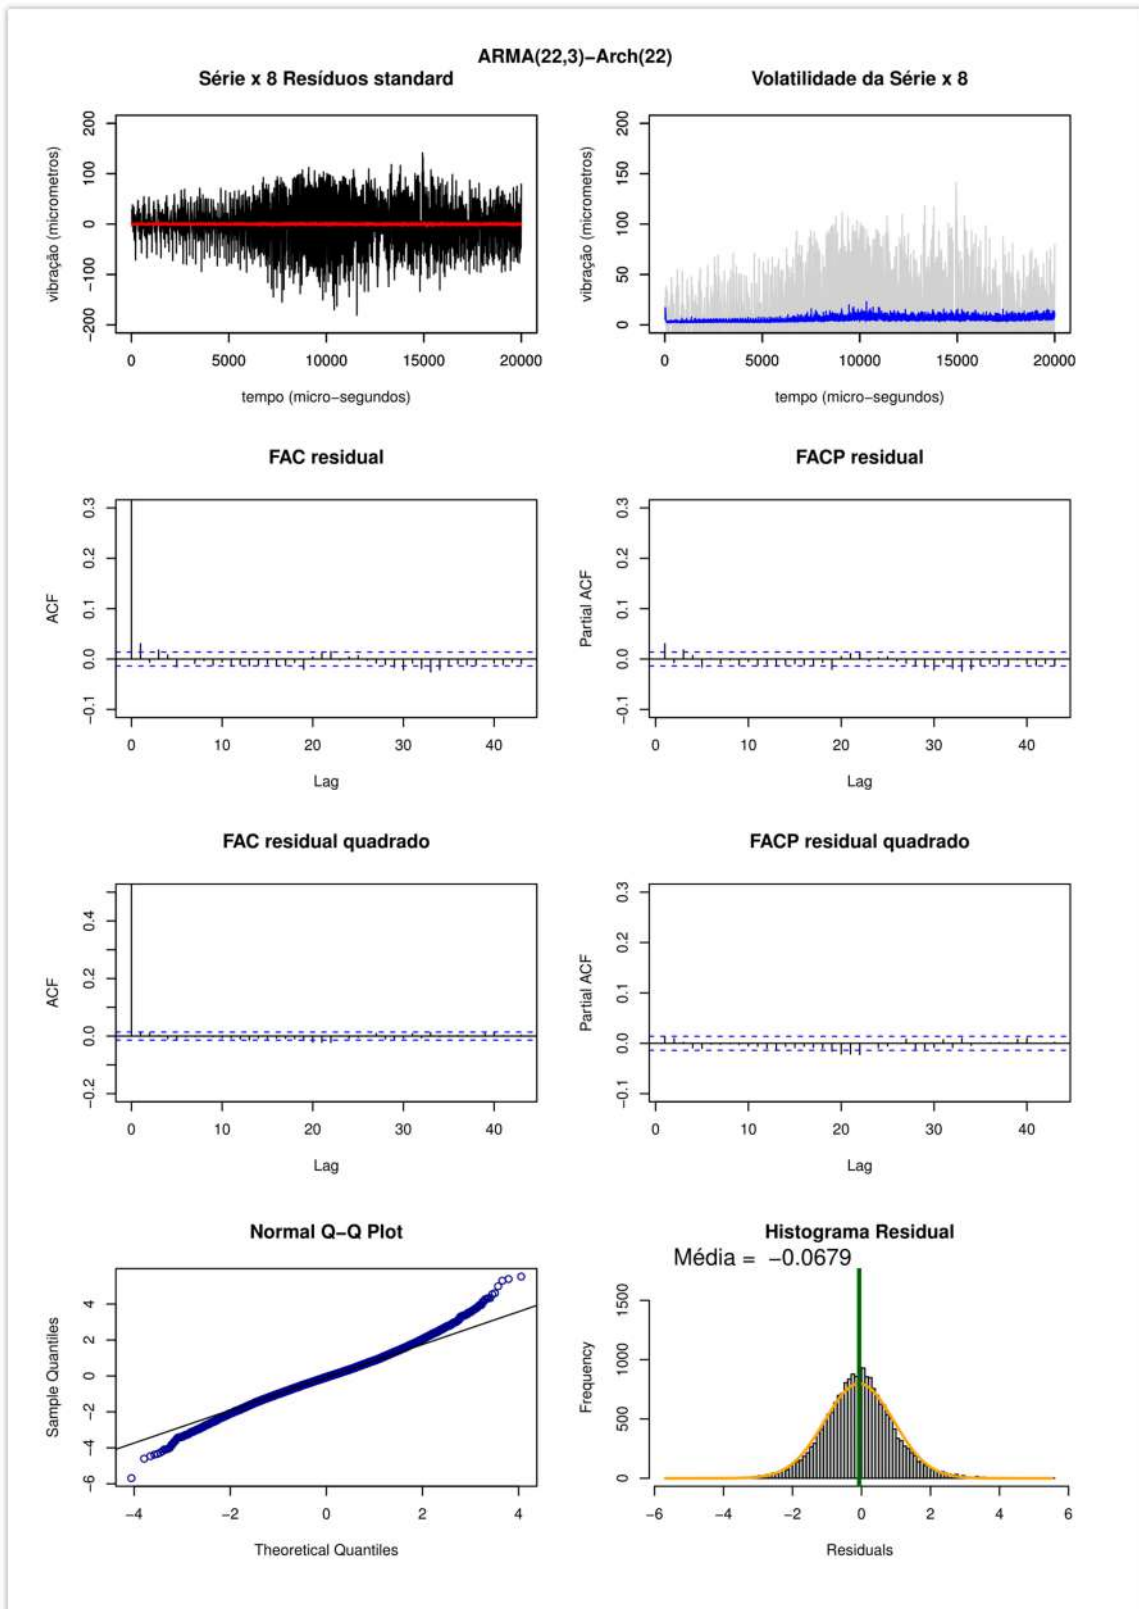
Anexo VI - Figura 42: Resultado modelo ARMA(22,3)- ARCH(22) parte 12



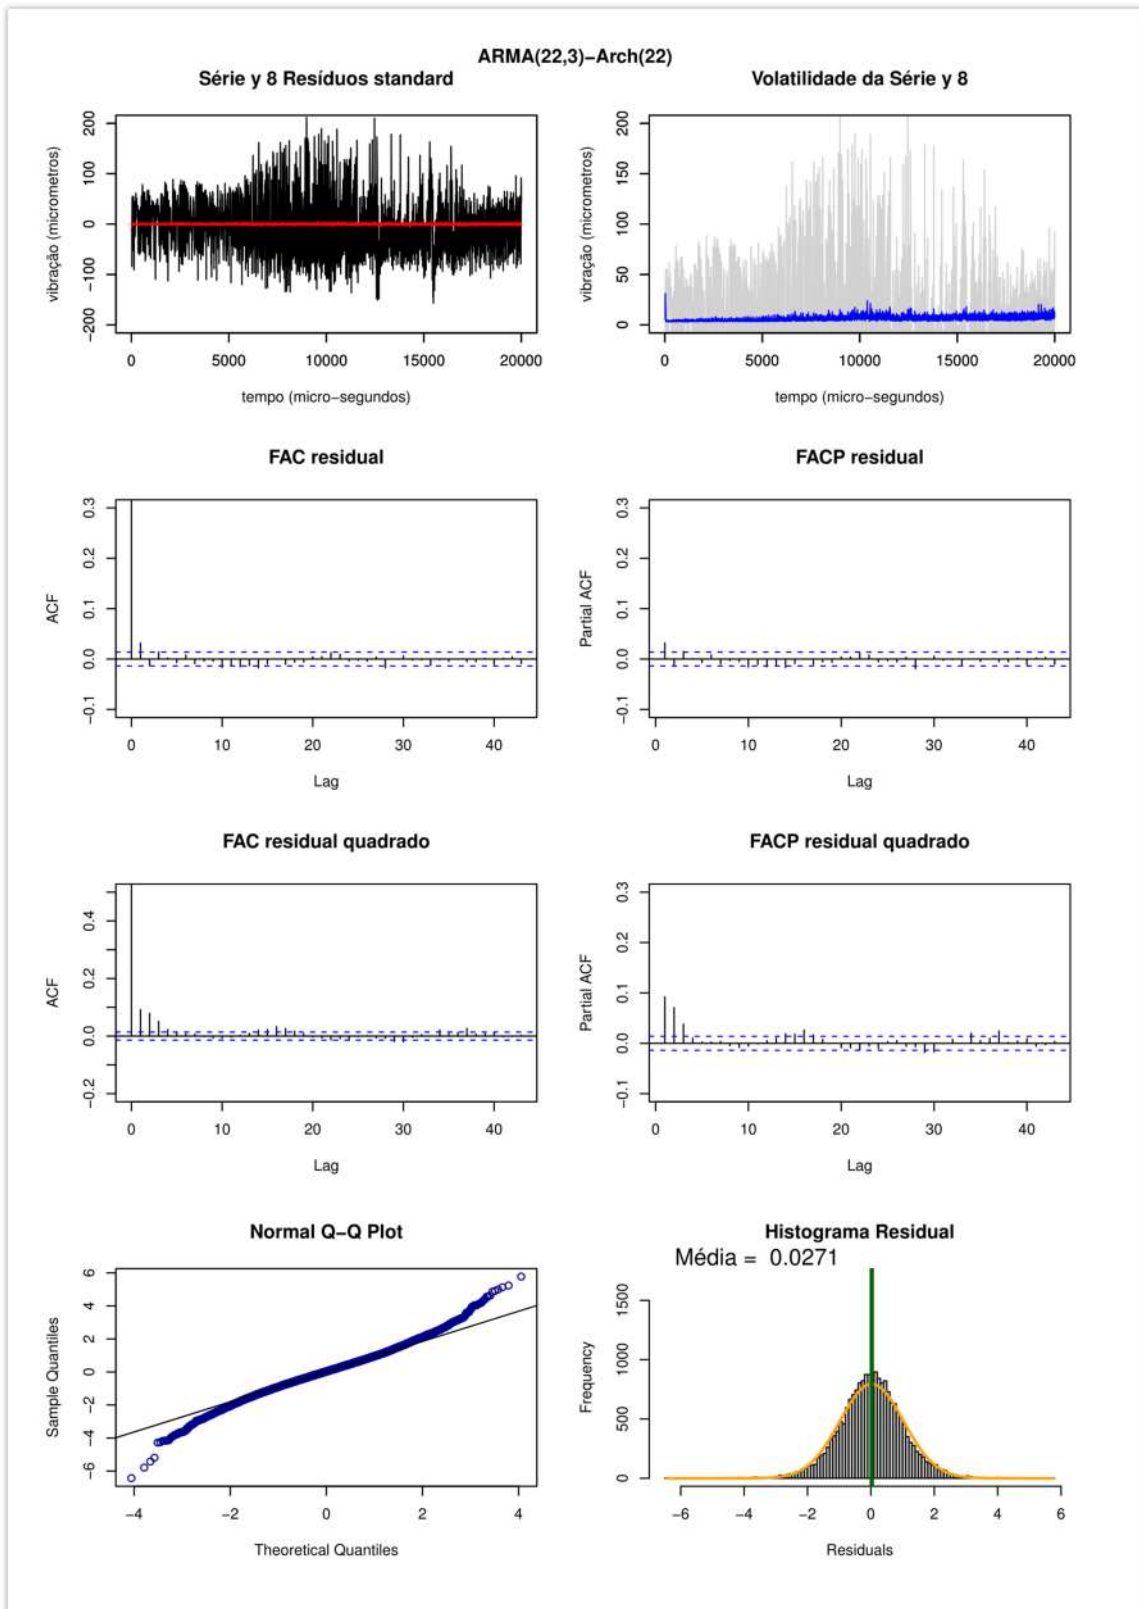
Anexo VI - Figura 43: Resultado modelo ARMA(22,3)- ARCH(22) parte 13



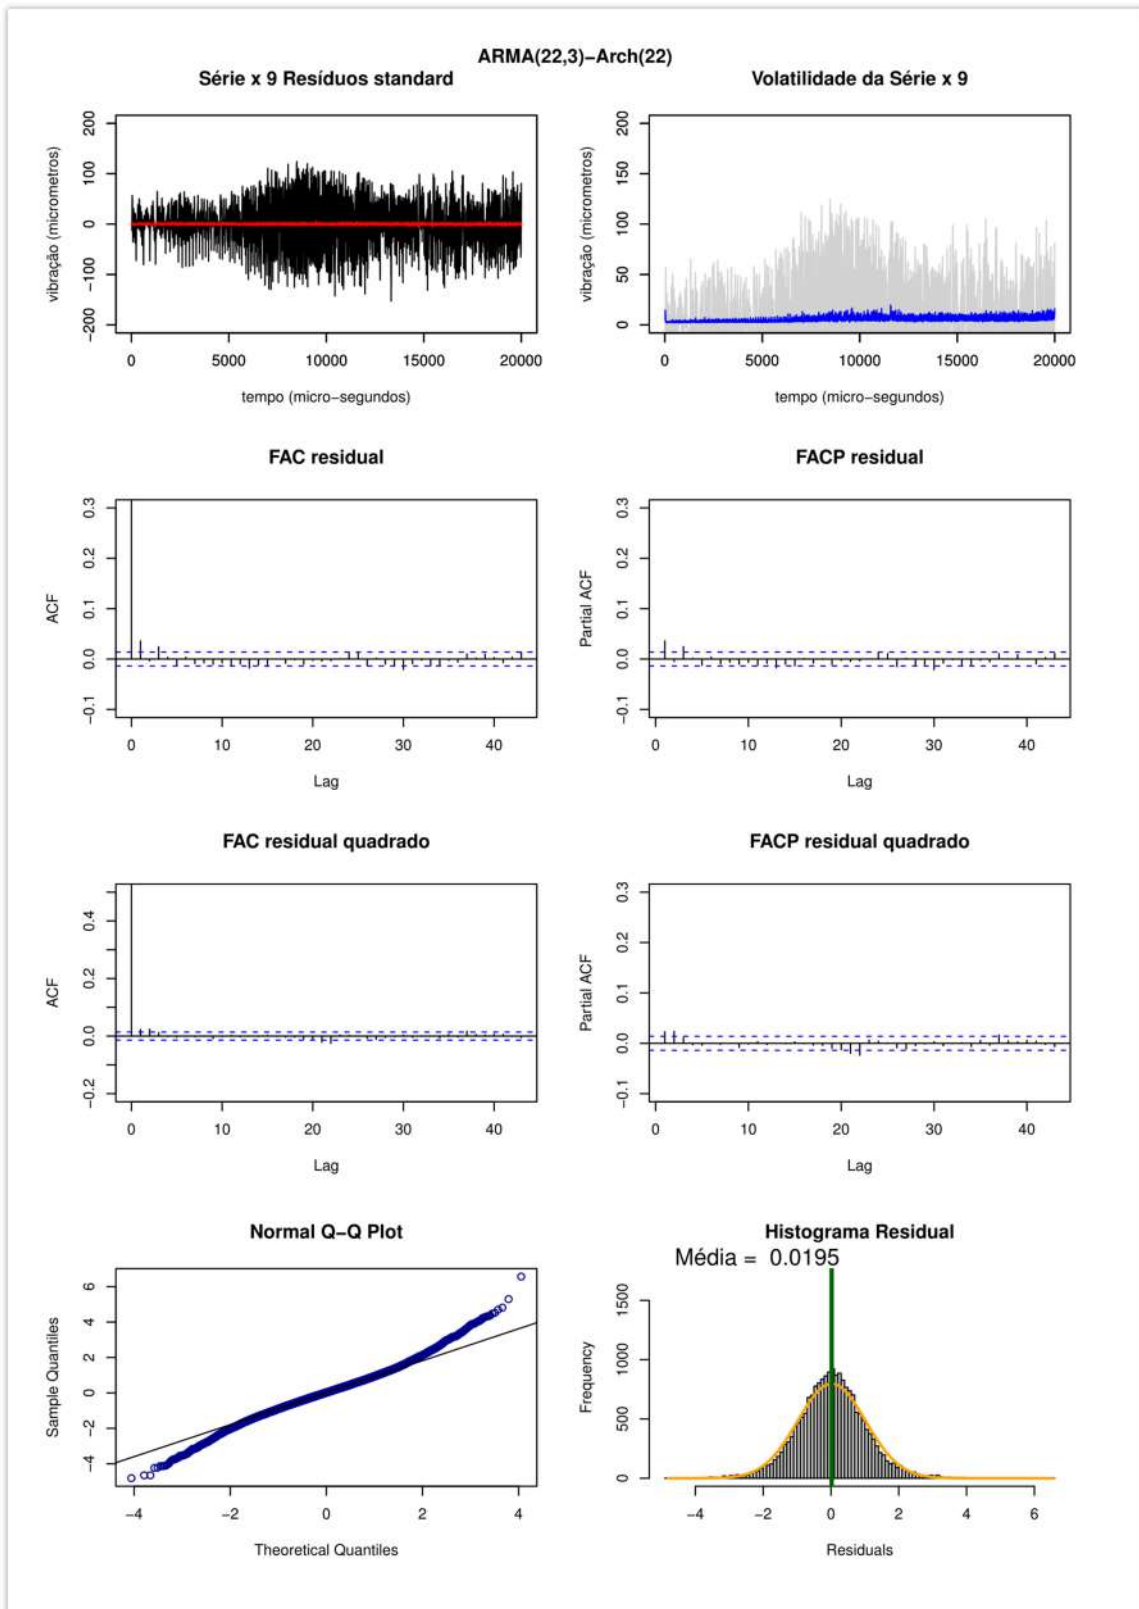
Anexo VI - Figura 44: Resultado modelo ARMA(22,3)- ARCH(22) parte 14



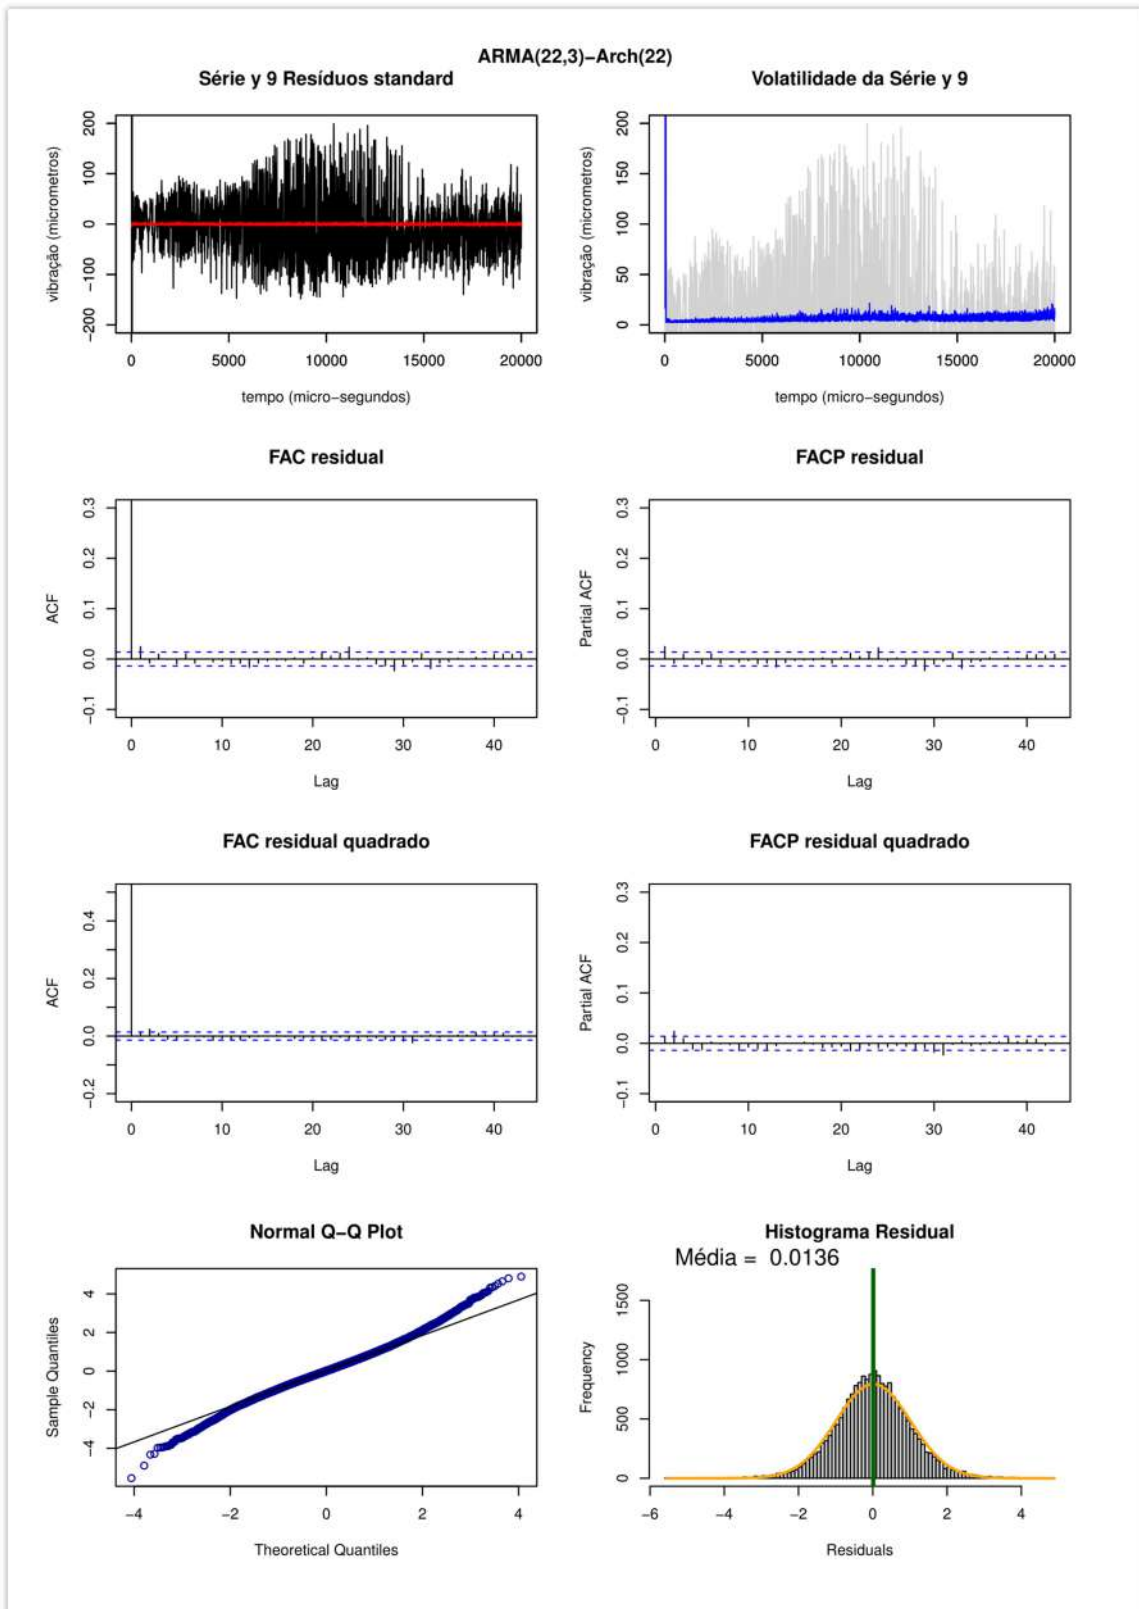
Anexo VI - Figura 45: Resultado modelo ARMA(22,3)- ARCH(22) parte 15



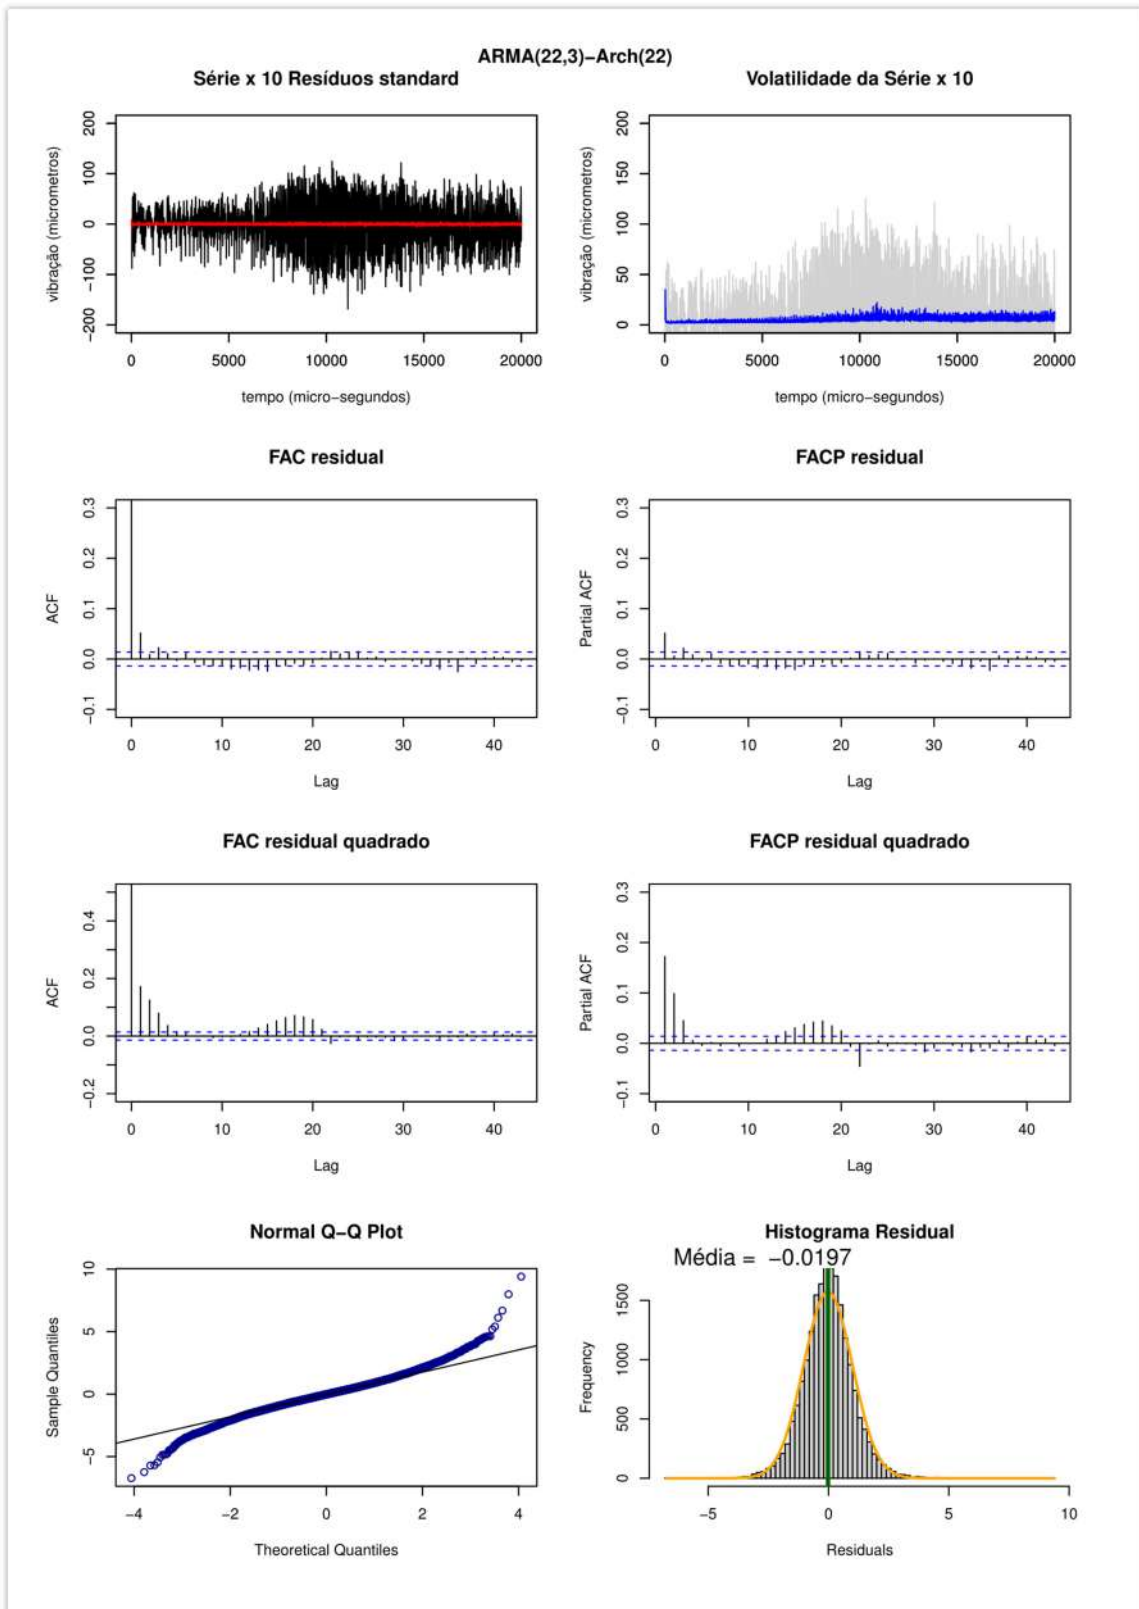
Anexo VI - Figura 46: Resultado modelo ARMA(22,3)- ARCH(22) parte 16



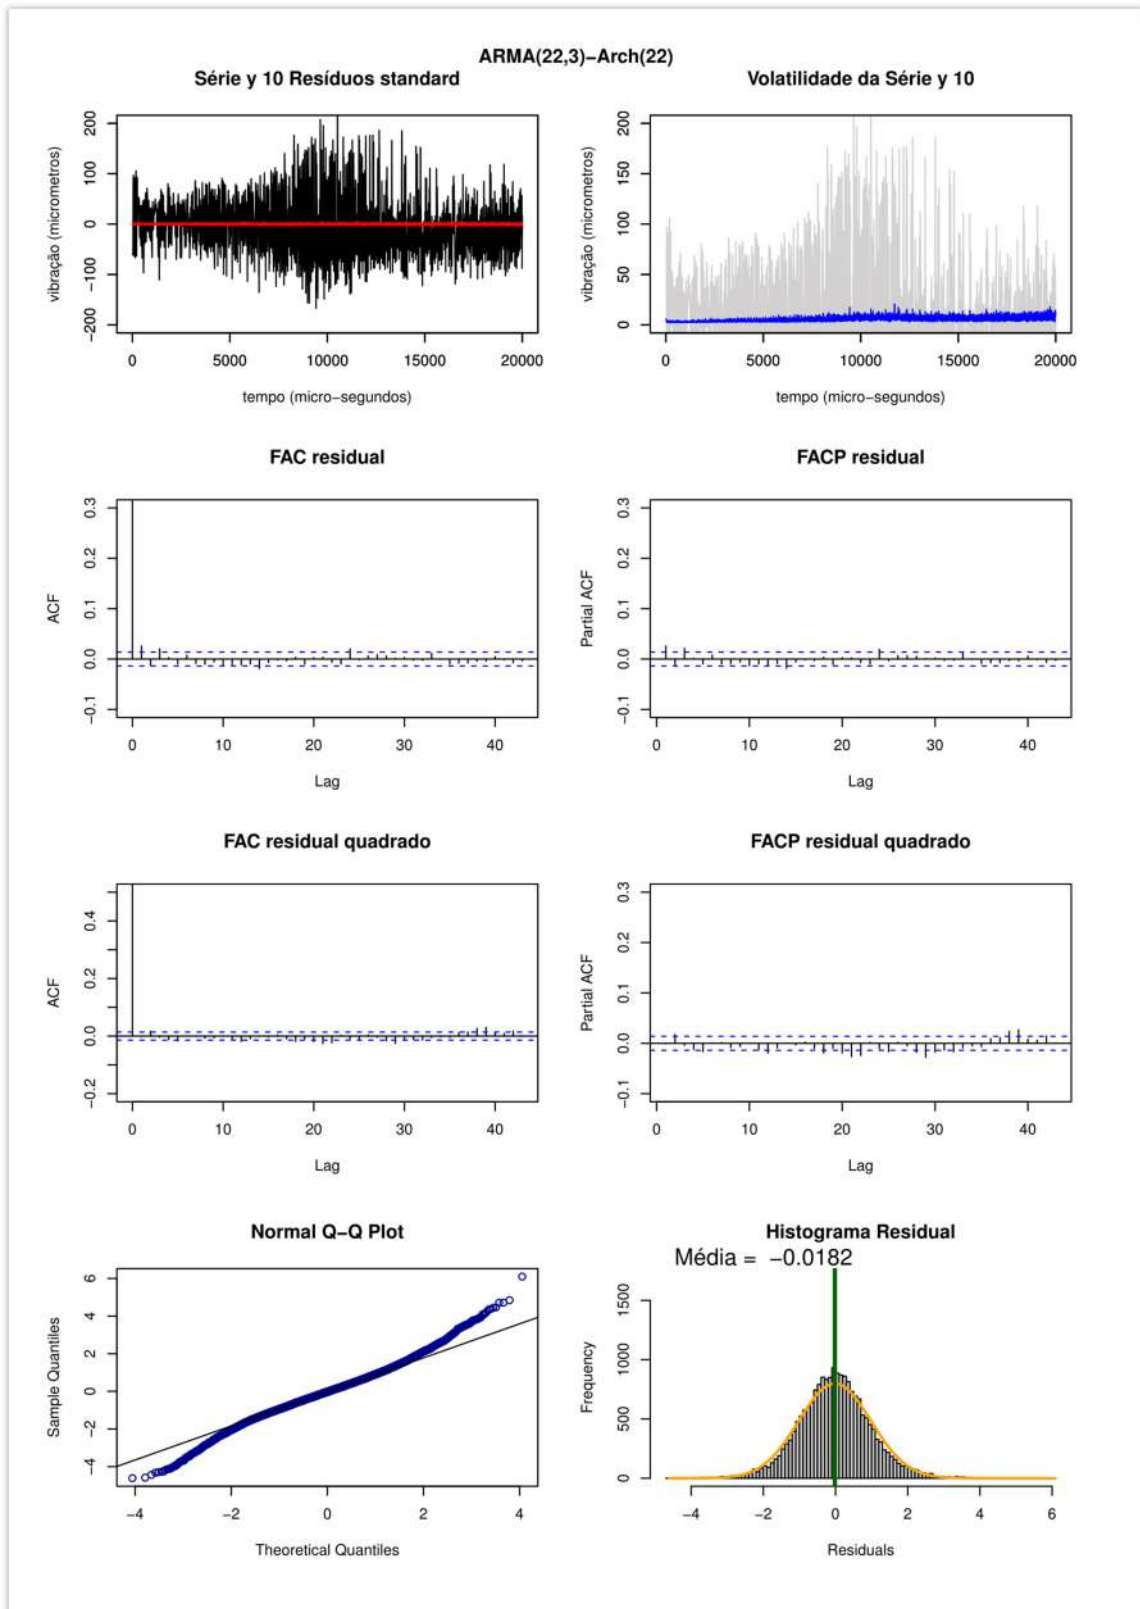
Anexo VI - Figura 47: Resultado modelo ARMA(22,3)- ARCH(22) parte 17



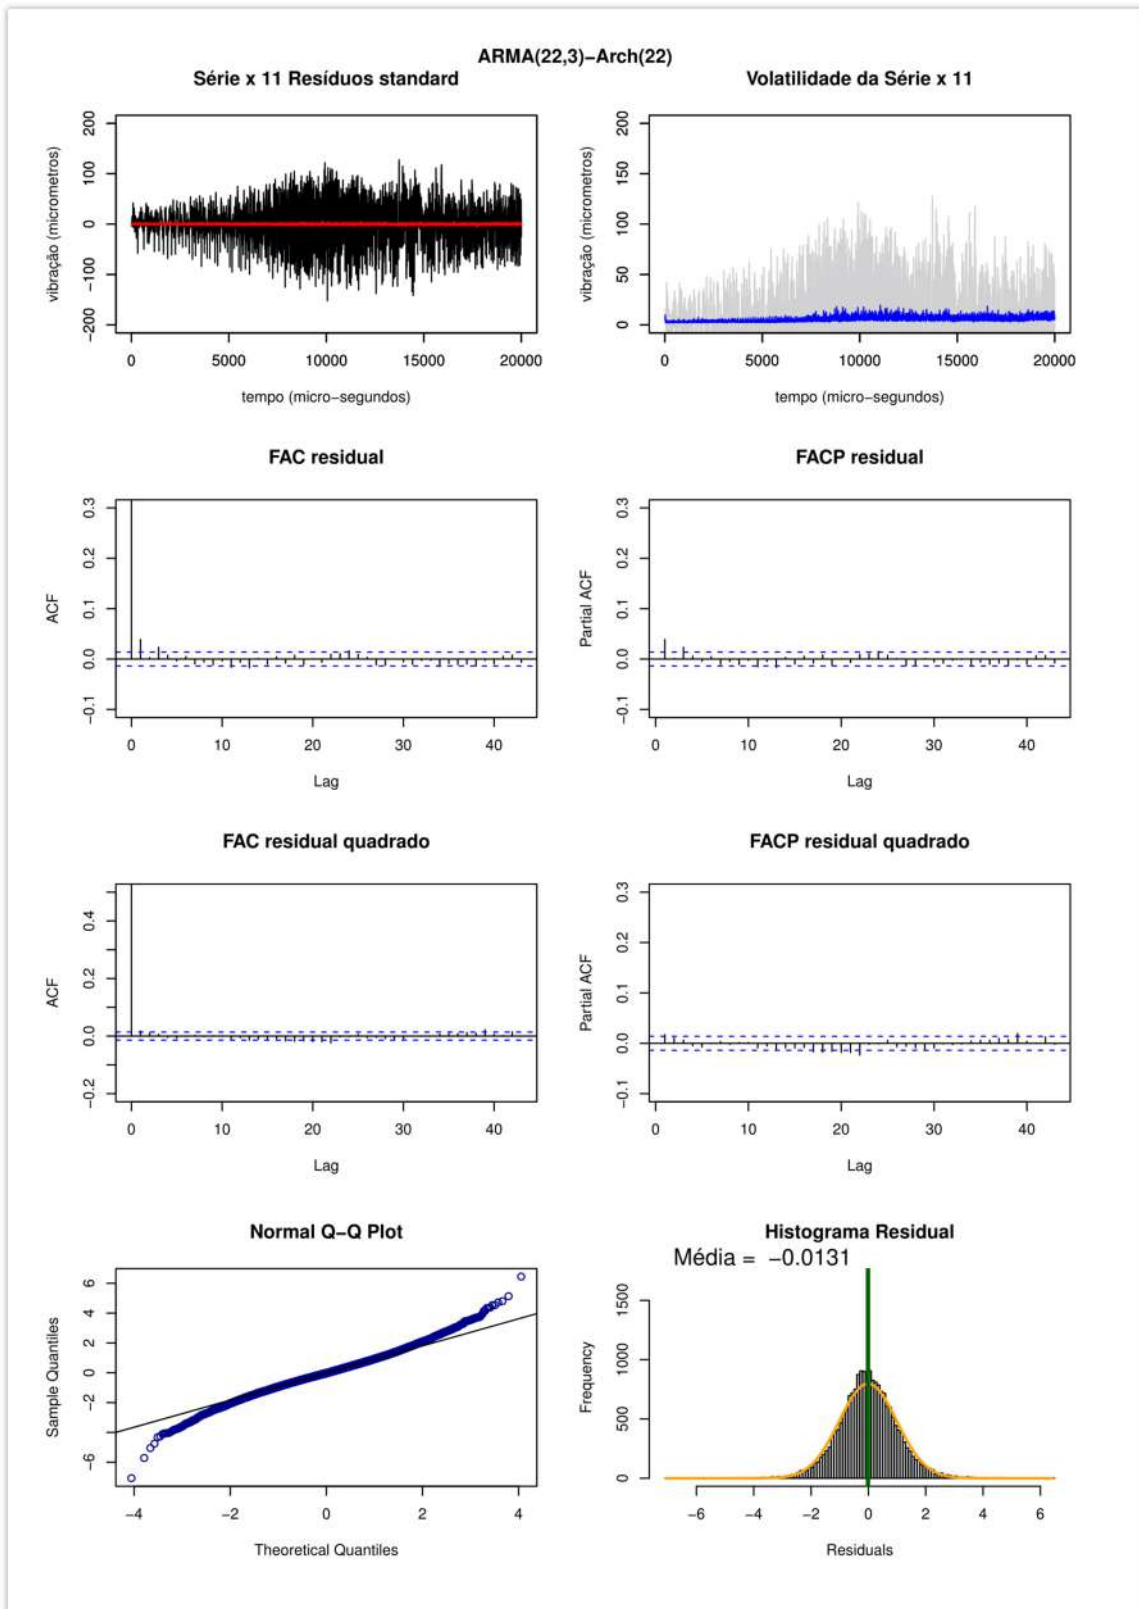
Anexo VI - Figura 48: Resultado modelo ARMA(22,3)- ARCH(22) parte 18



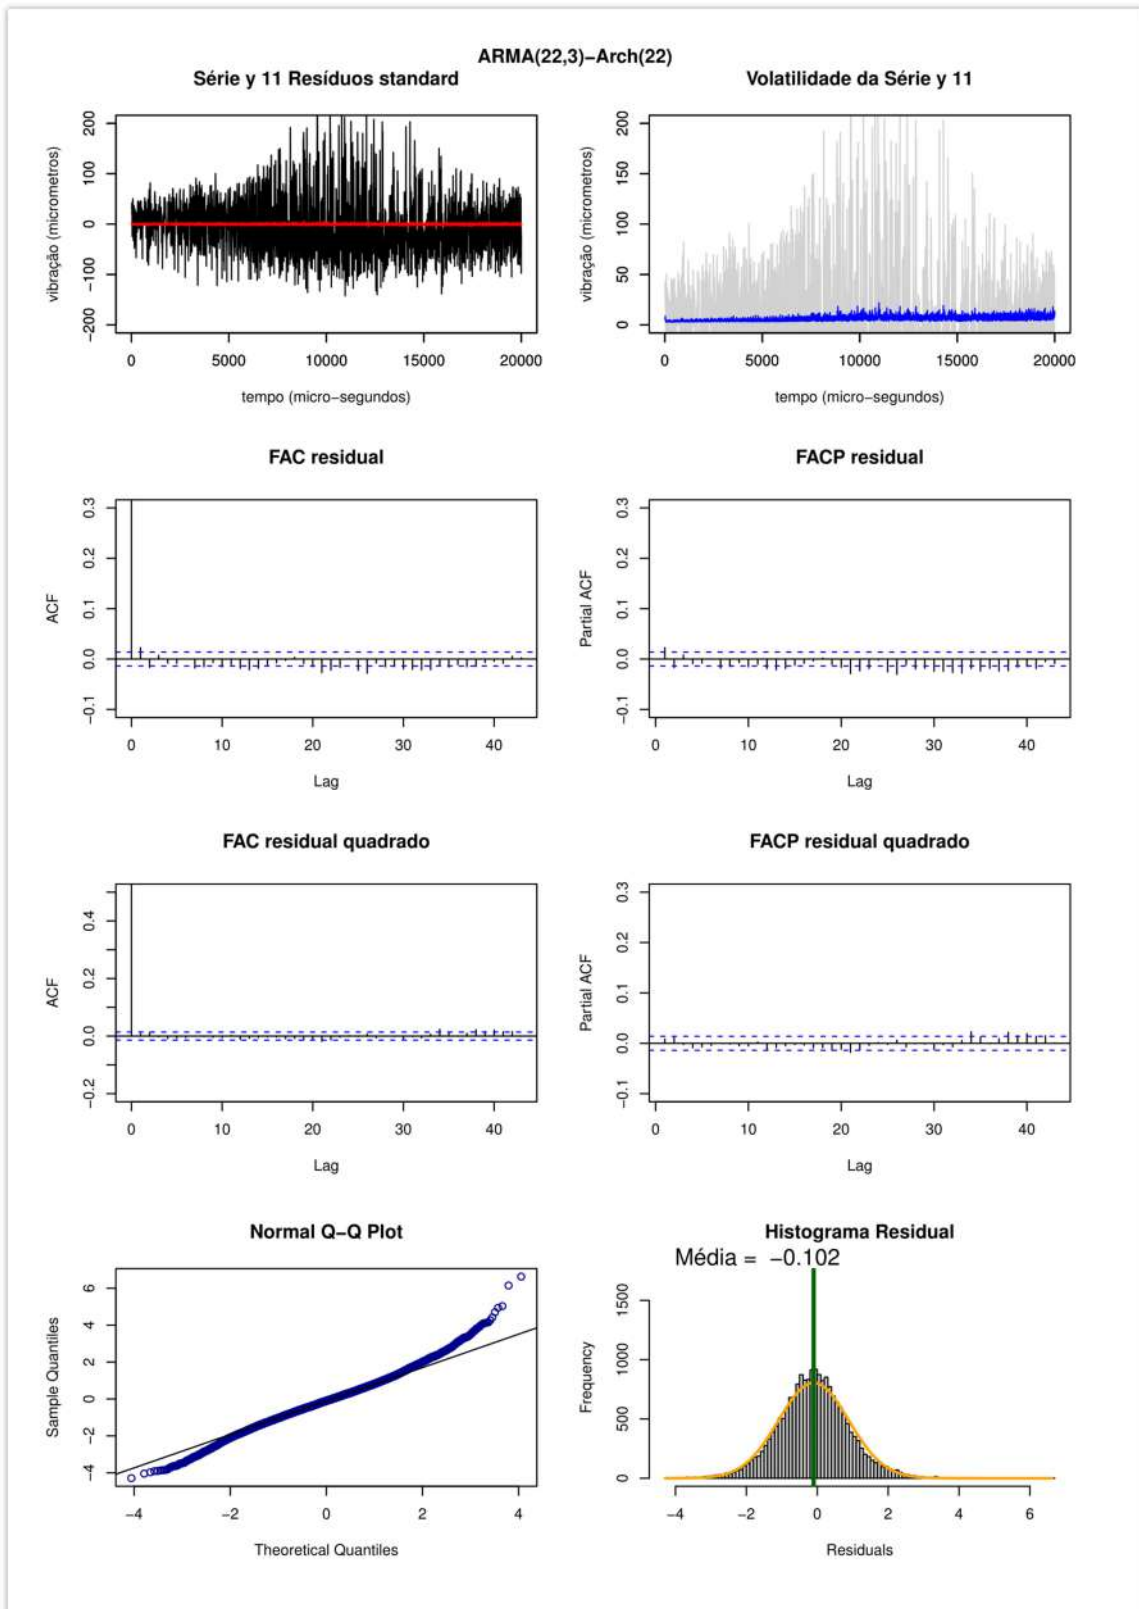
Anexo VI - Figura 49: Resultado modelo ARMA(22,3)- ARCH(22) parte 19



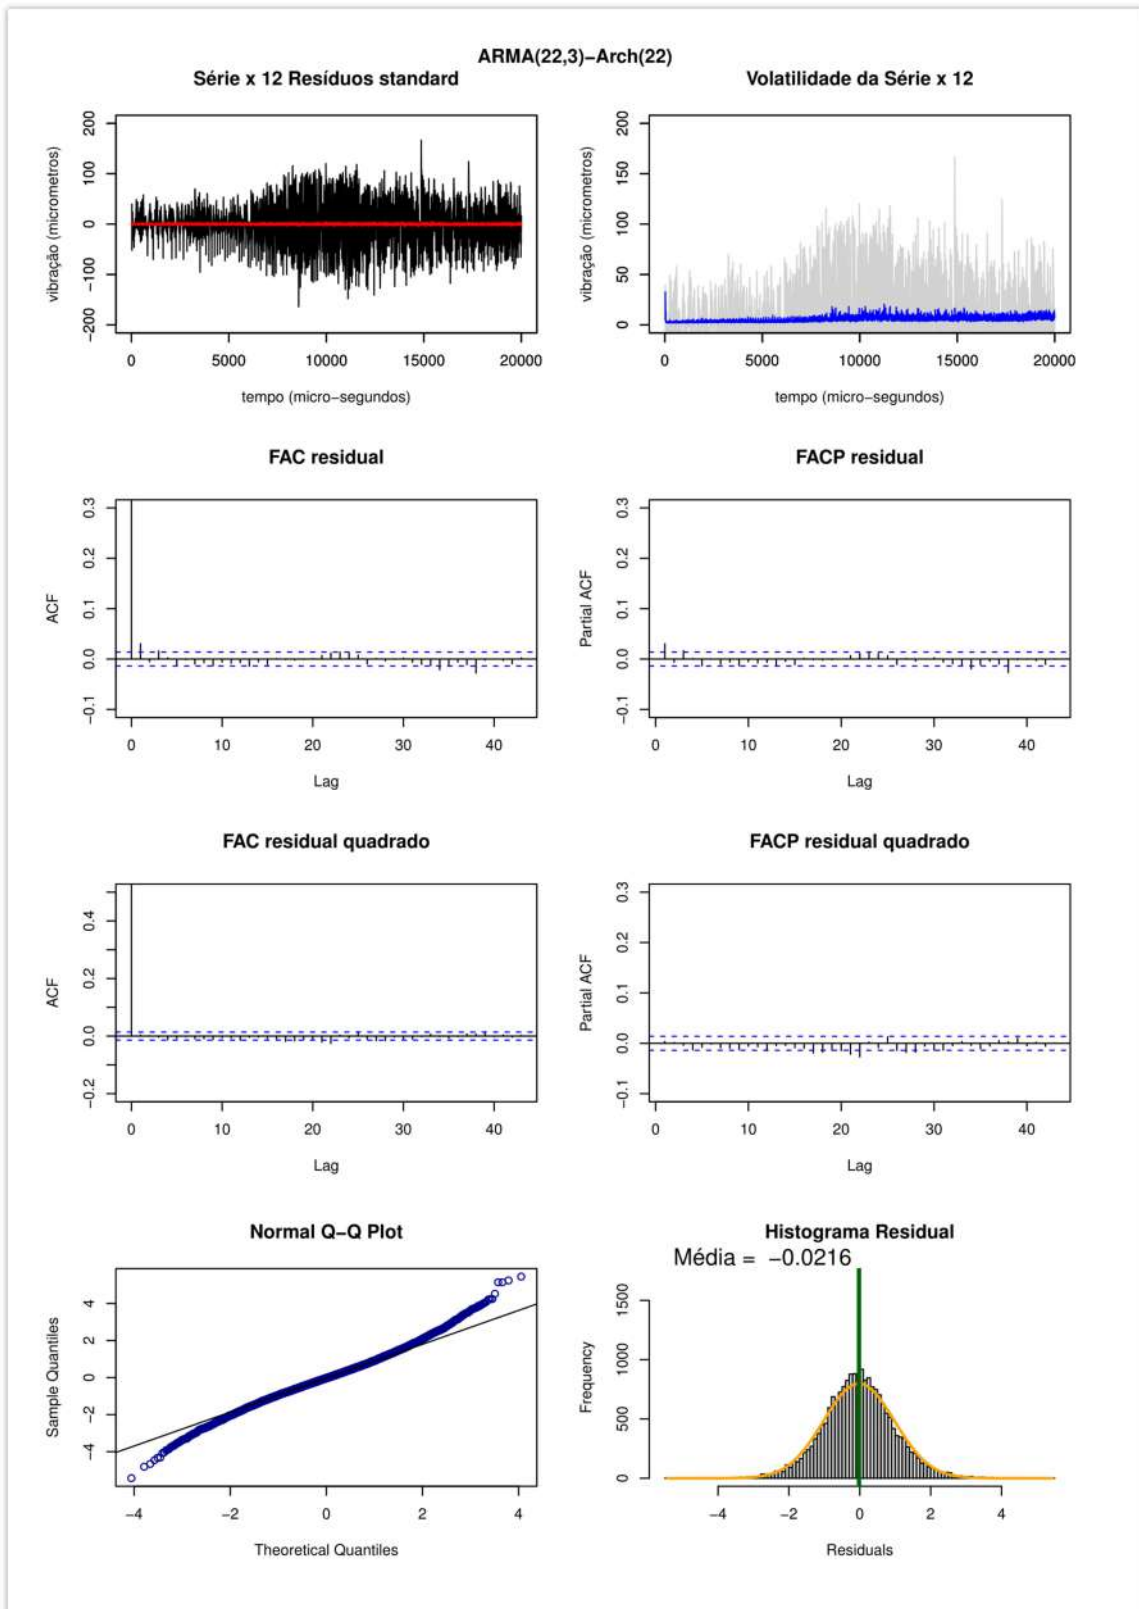
Anexo VI - Figura 50: Resultado modelo ARMA(22,3)- ARCH(22) parte 20



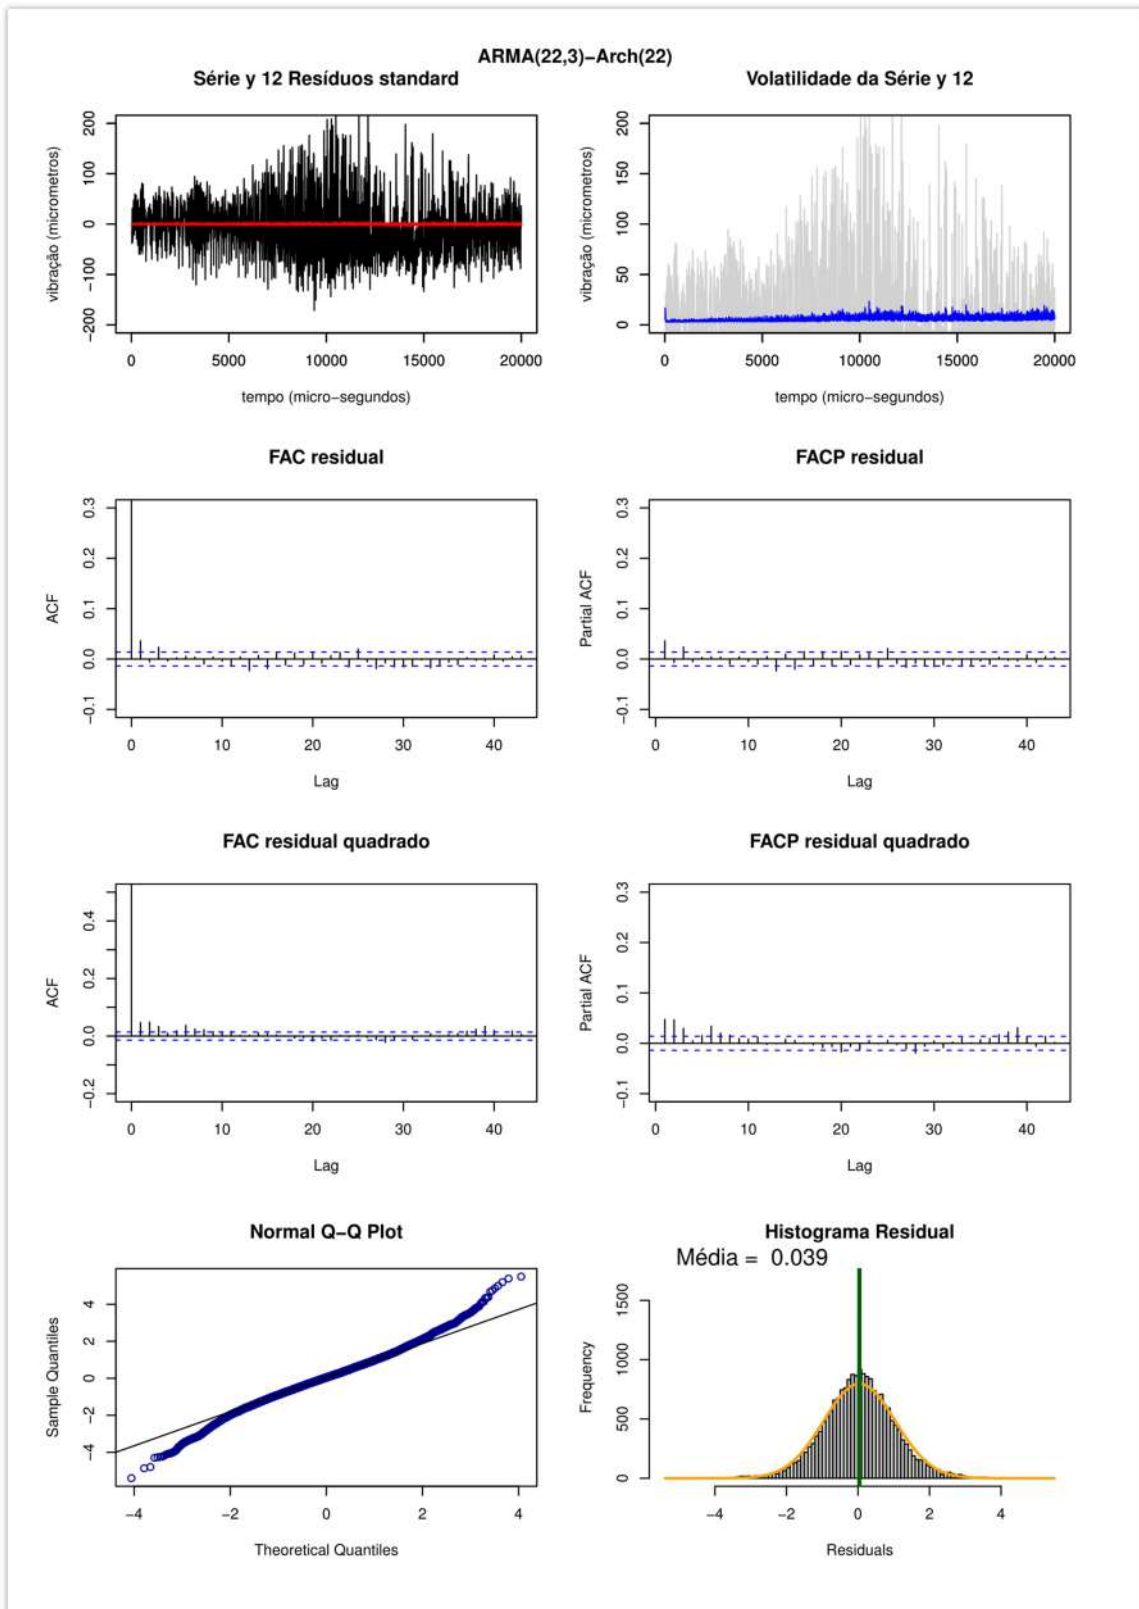
Anexo VI - Figura 51: Resultado modelo ARMA(22,3)- ARCH(22) parte 21



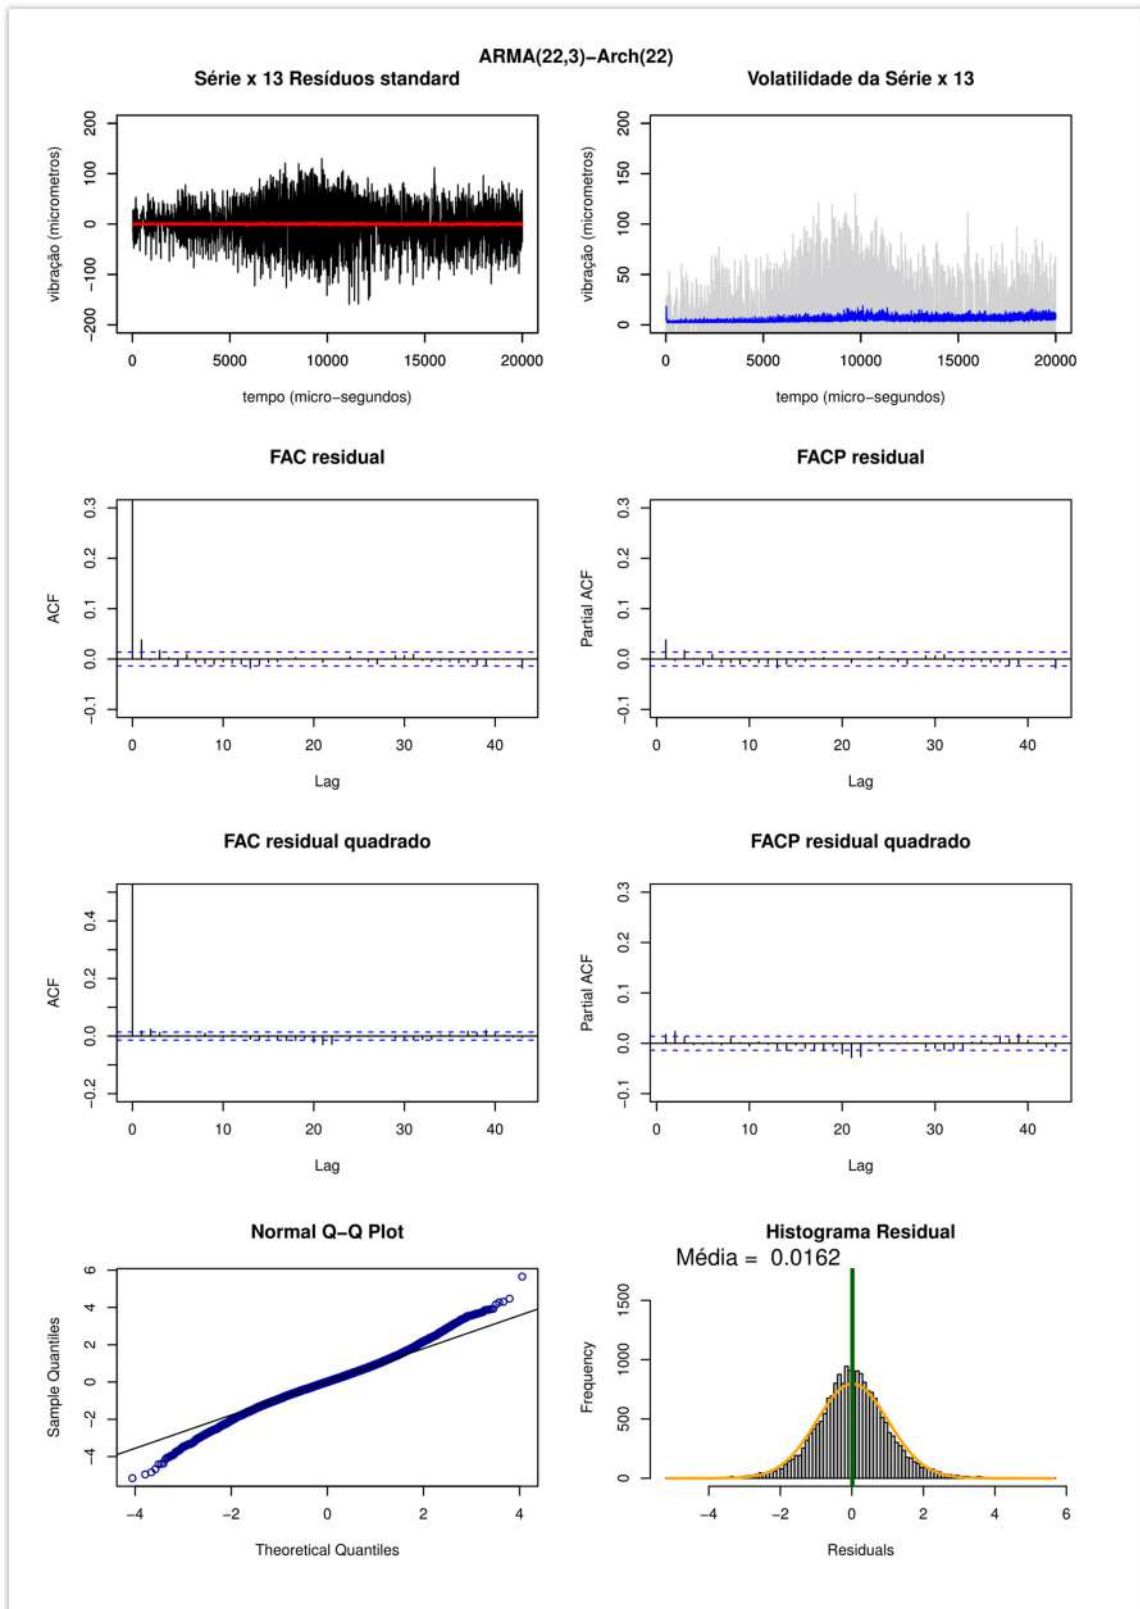
Anexo VI - Figura 52: Resultado modelo ARMA(22,3)- ARCH(22) parte 22



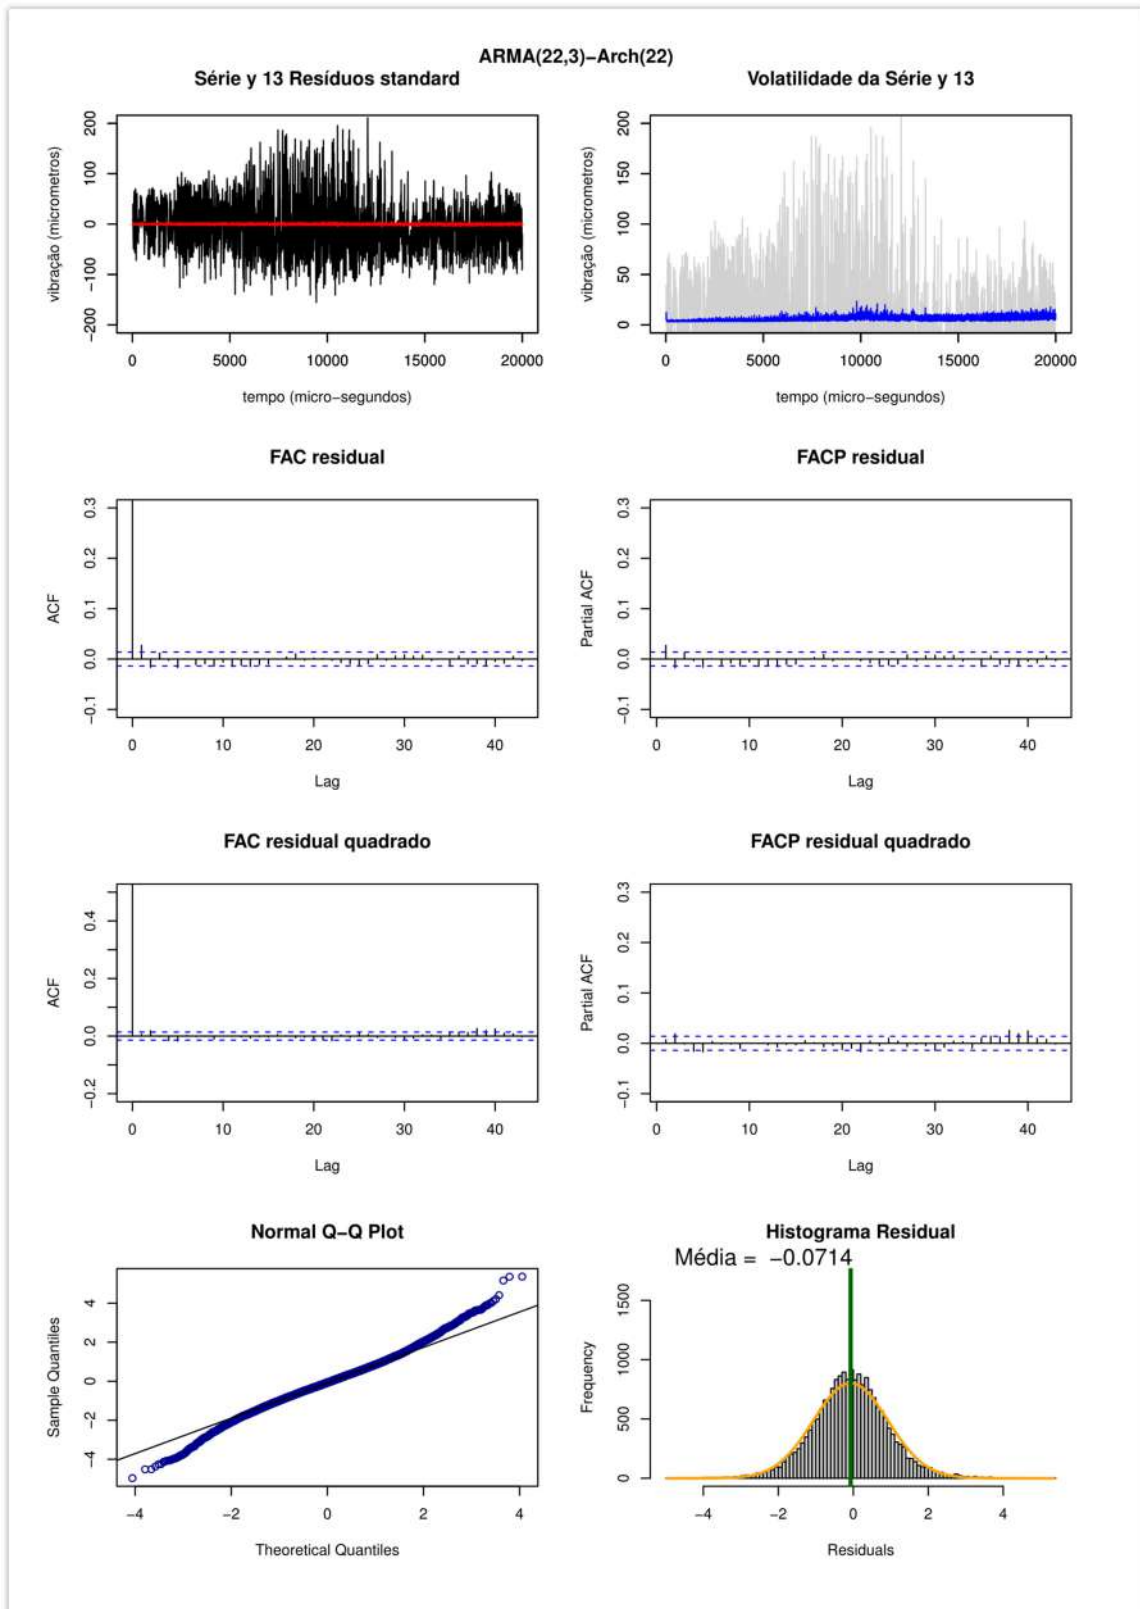
Anexo VI - Figura 53: Resultado modelo ARMA(22,3)- ARCH(22) parte 23



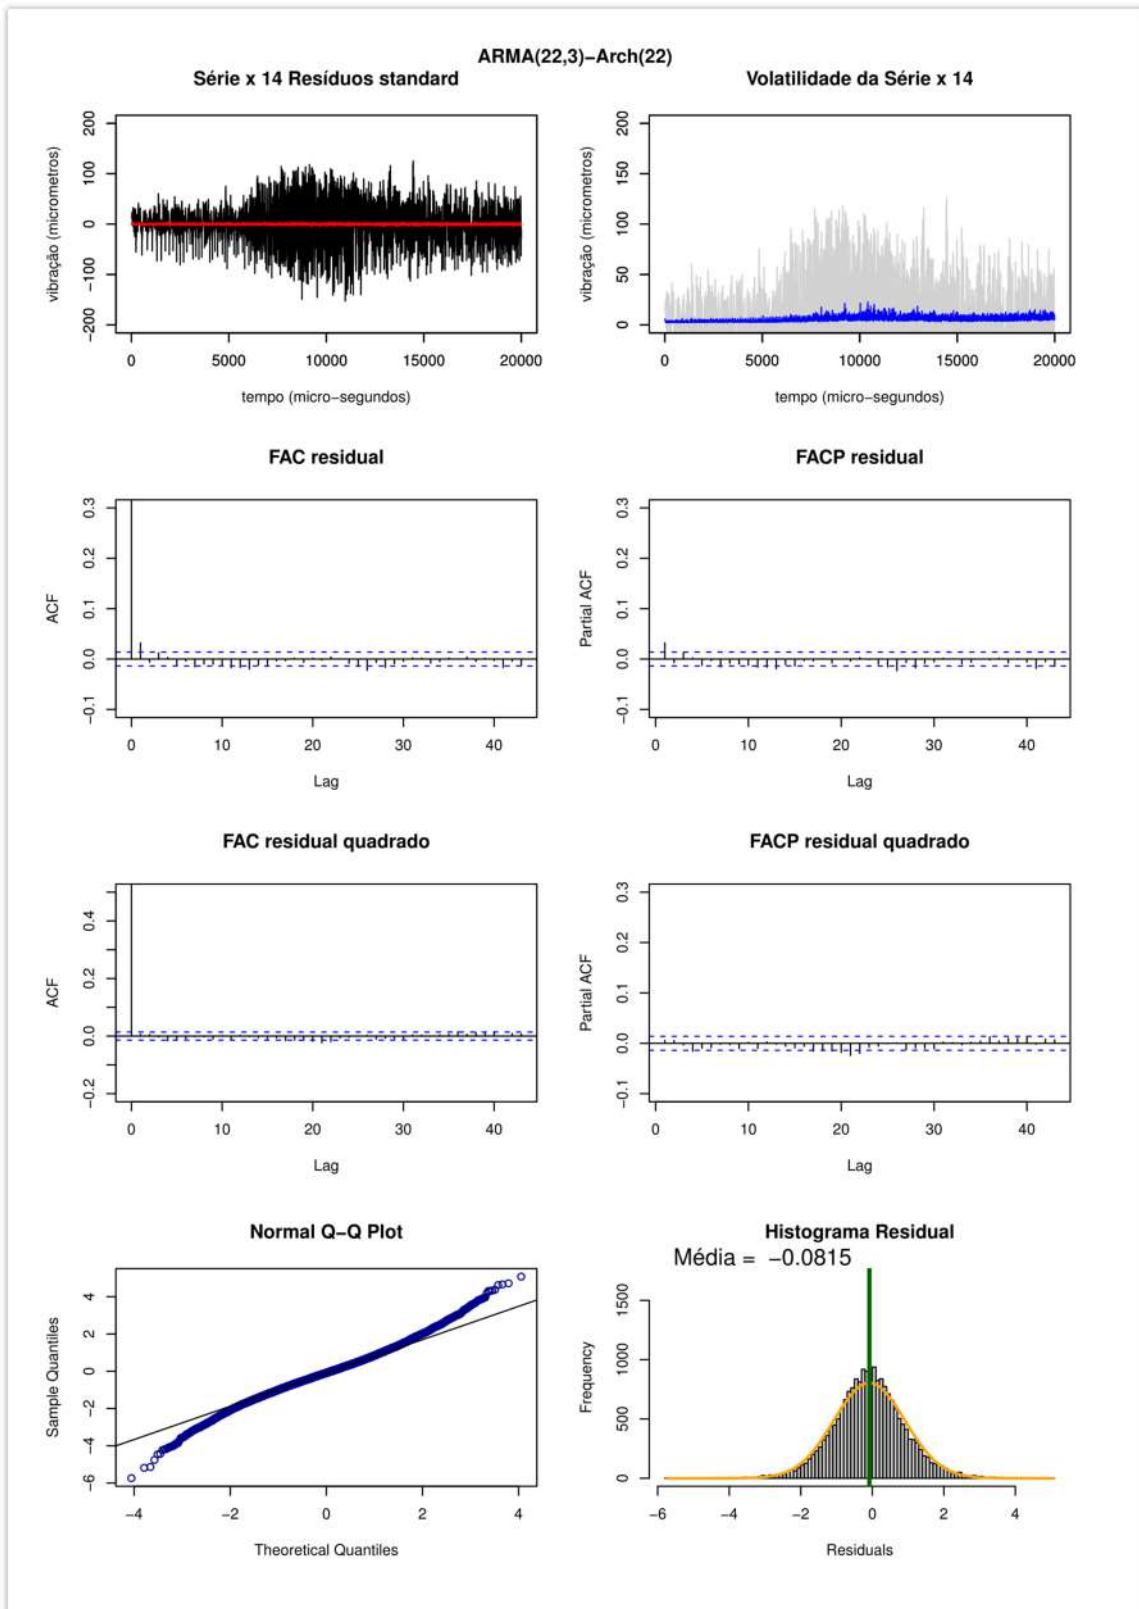
Anexo VI - Figura 54: Resultado modelo ARMA(22,3)- ARCH(22) parte 24



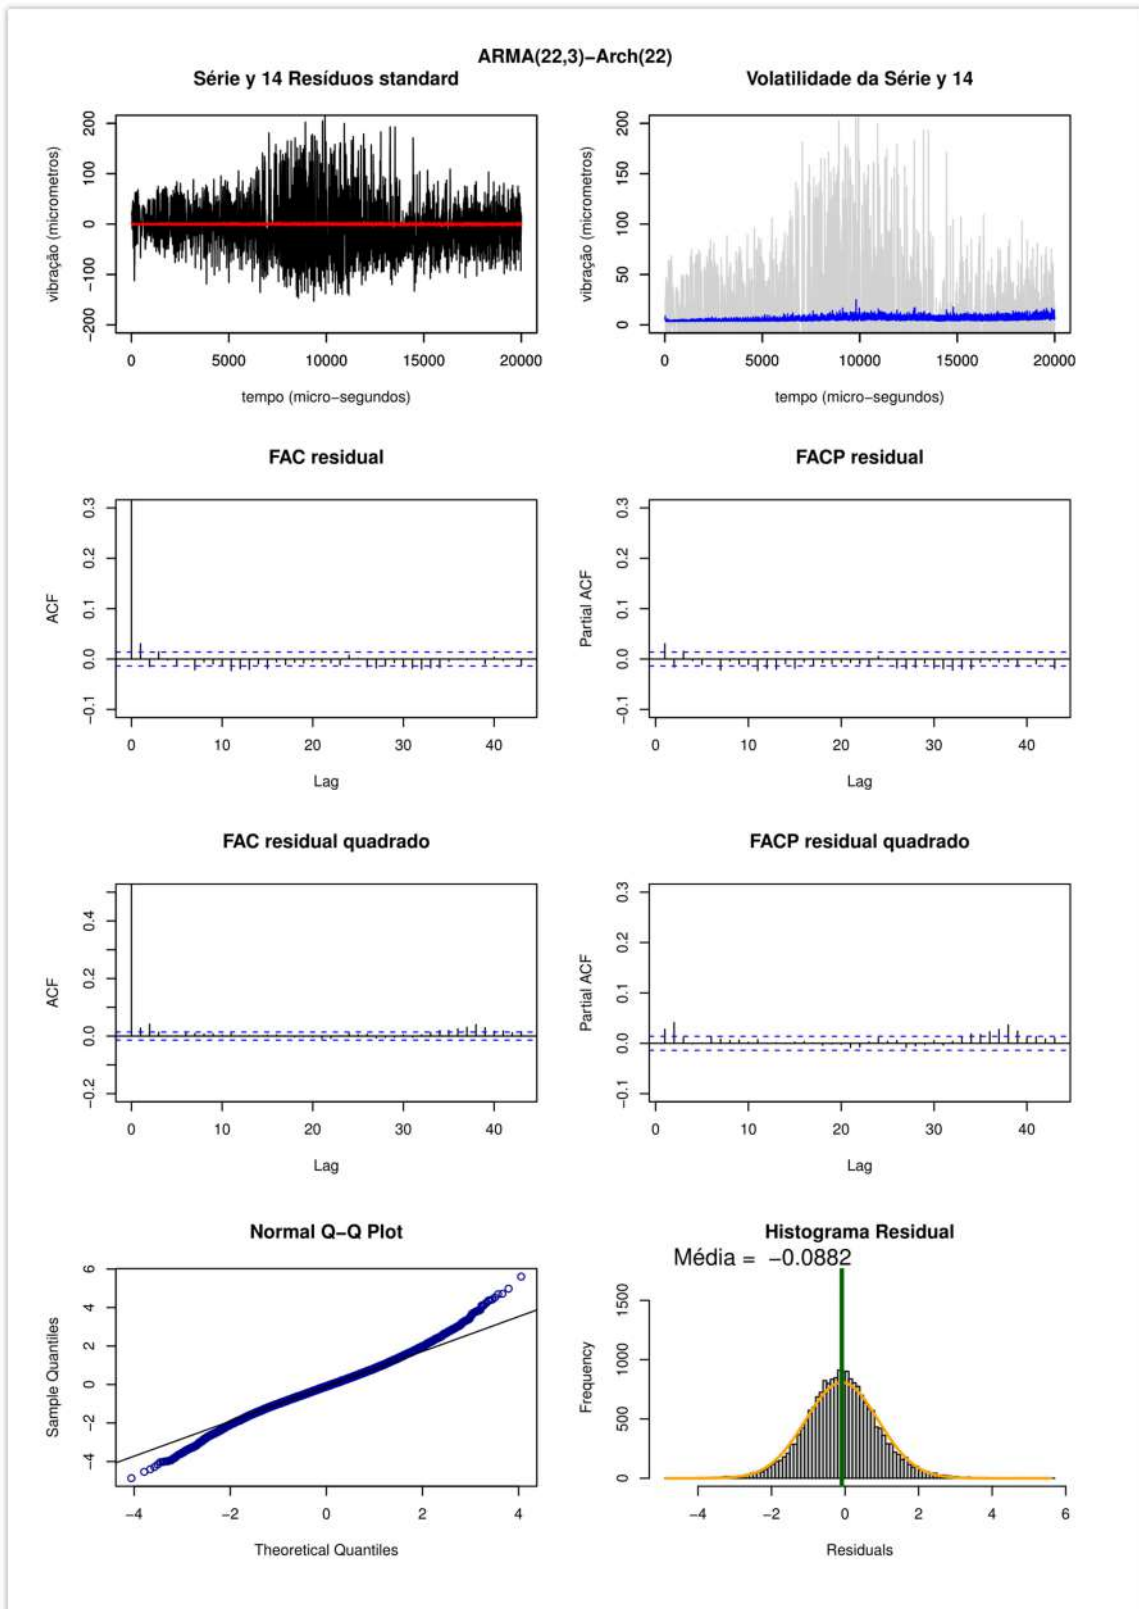
Anexo VI - Figura 55: Resultado modelo ARMA(22,3)- ARCH(22) parte 25



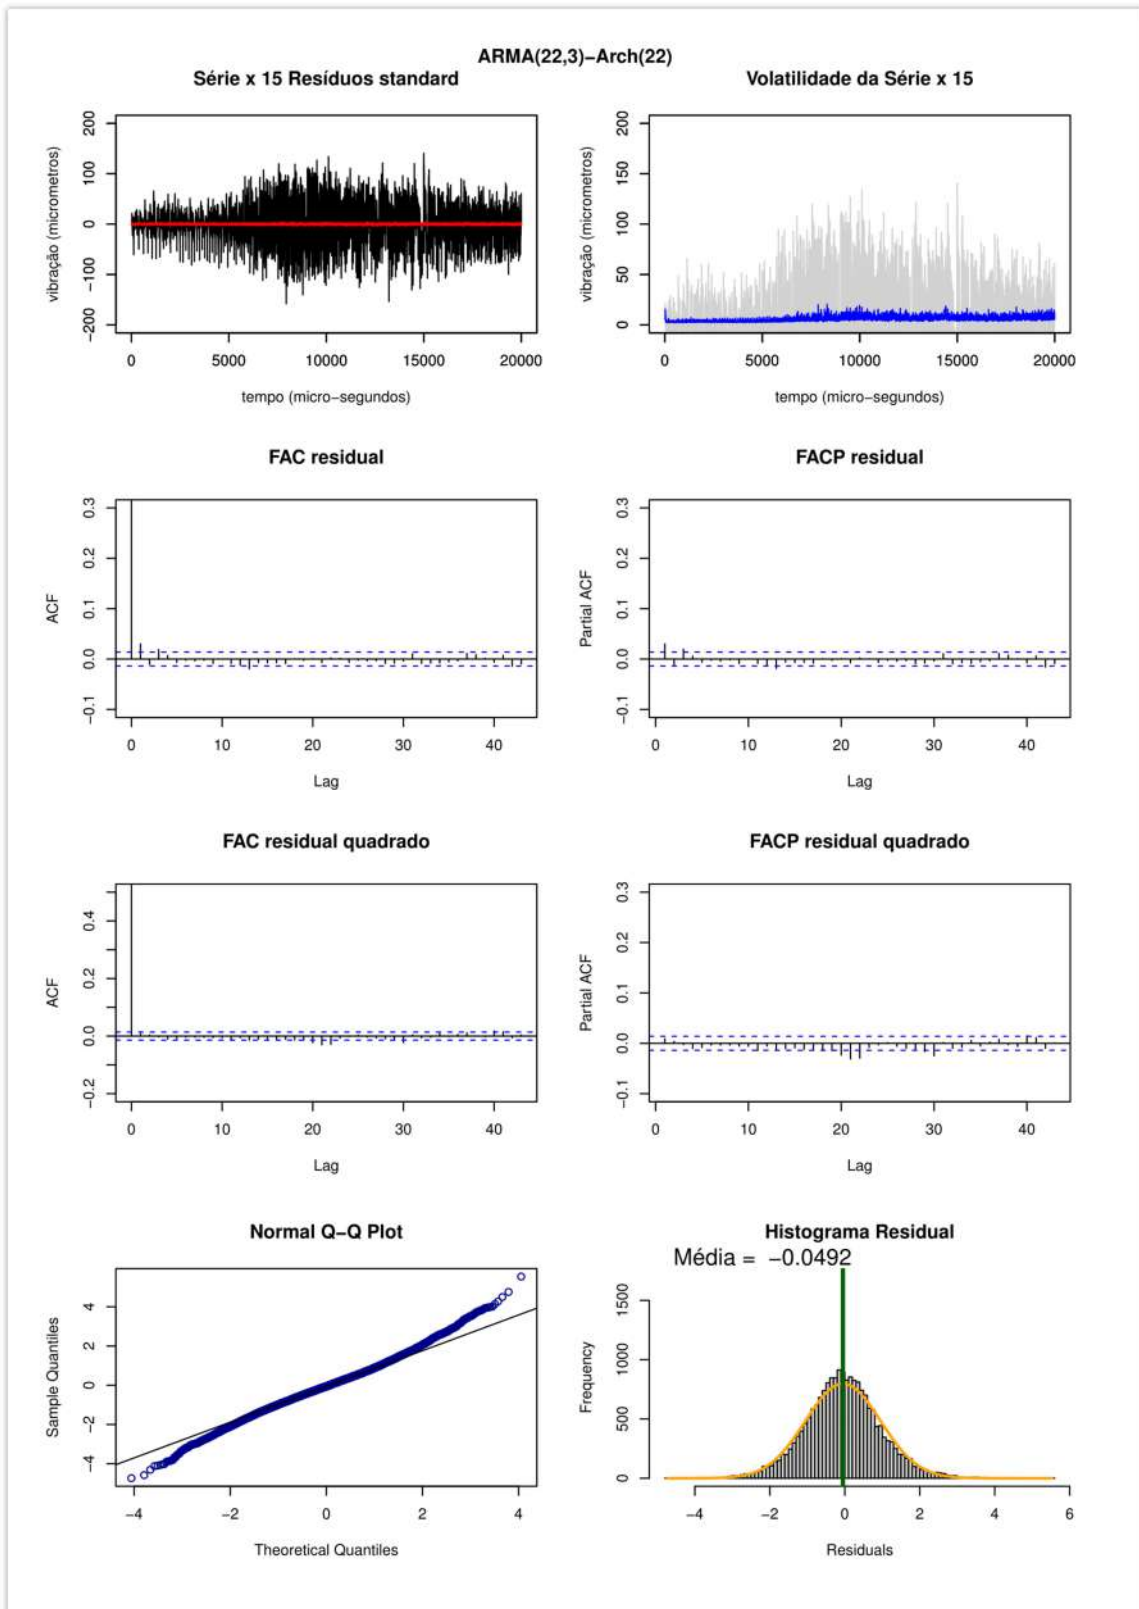
Anexo VI - Figura 56: Resultado modelo ARMA(22,3)- ARCH(22) parte 26



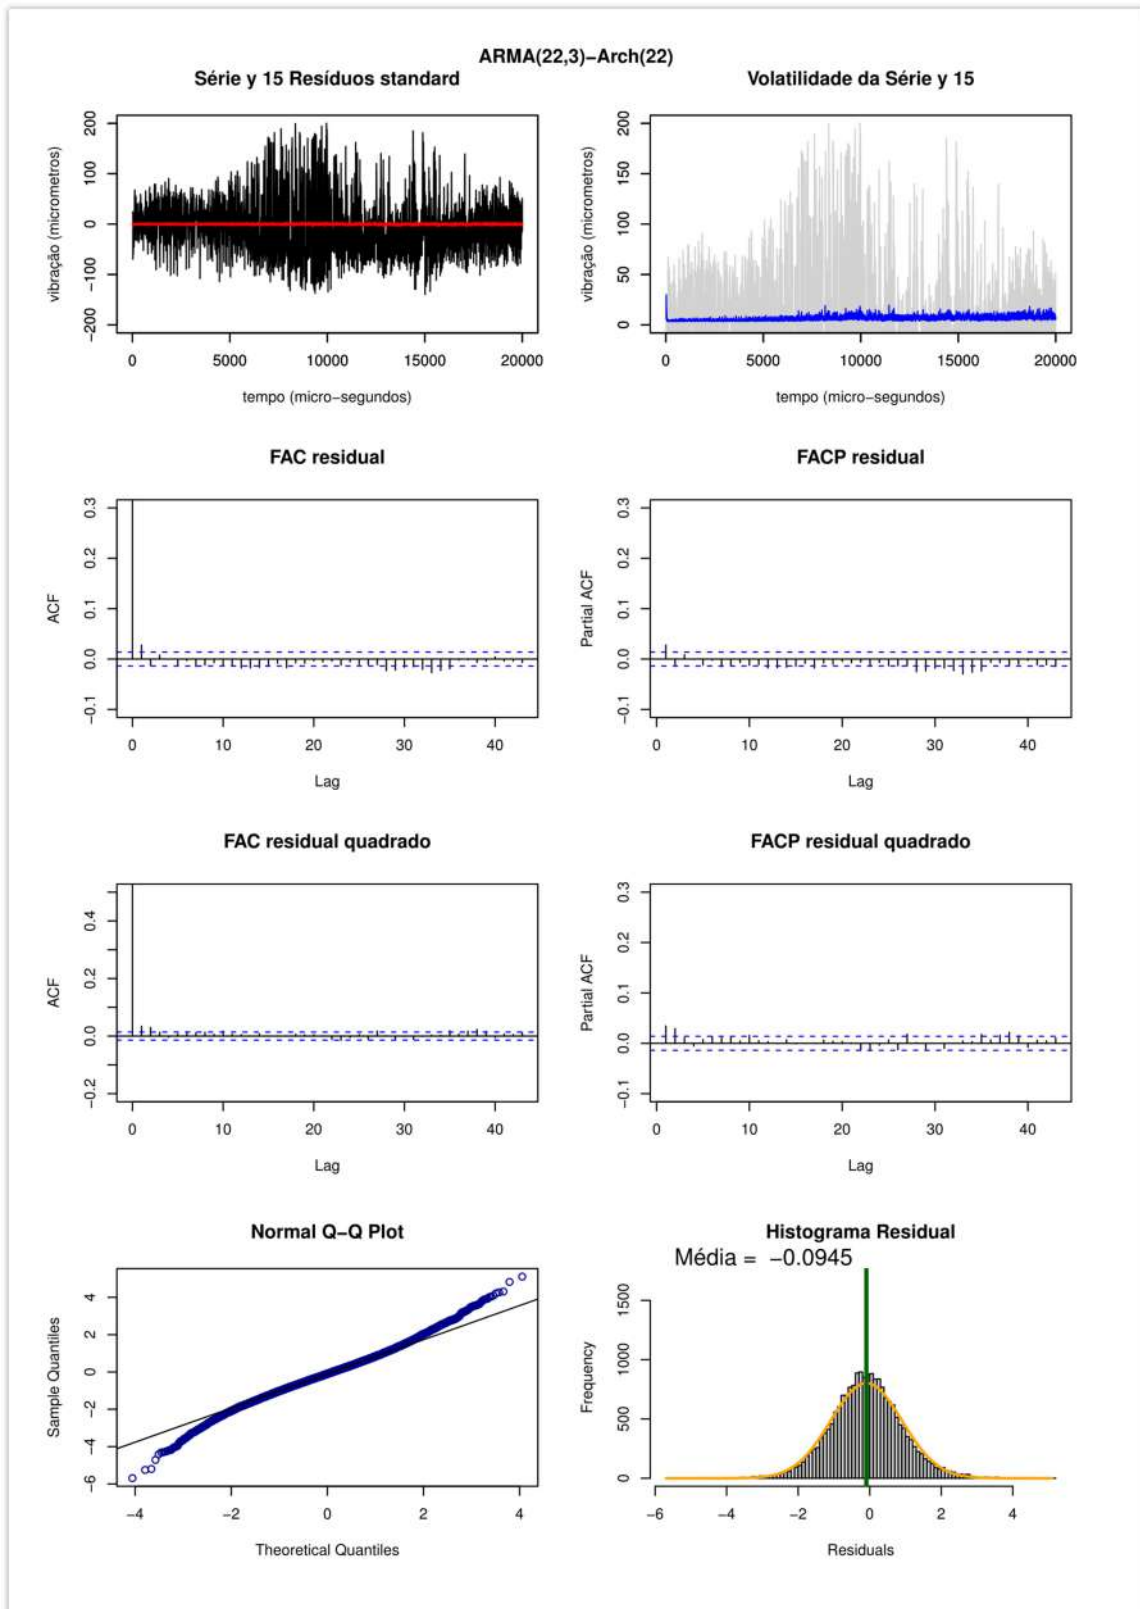
Anexo VI - Figura 57: Resultado modelo ARMA(22,3)- ARCH(22) parte 27



Anexo VI - Figura 58: Resultado modelo ARMA(22,3)- ARCH(22) parte 28

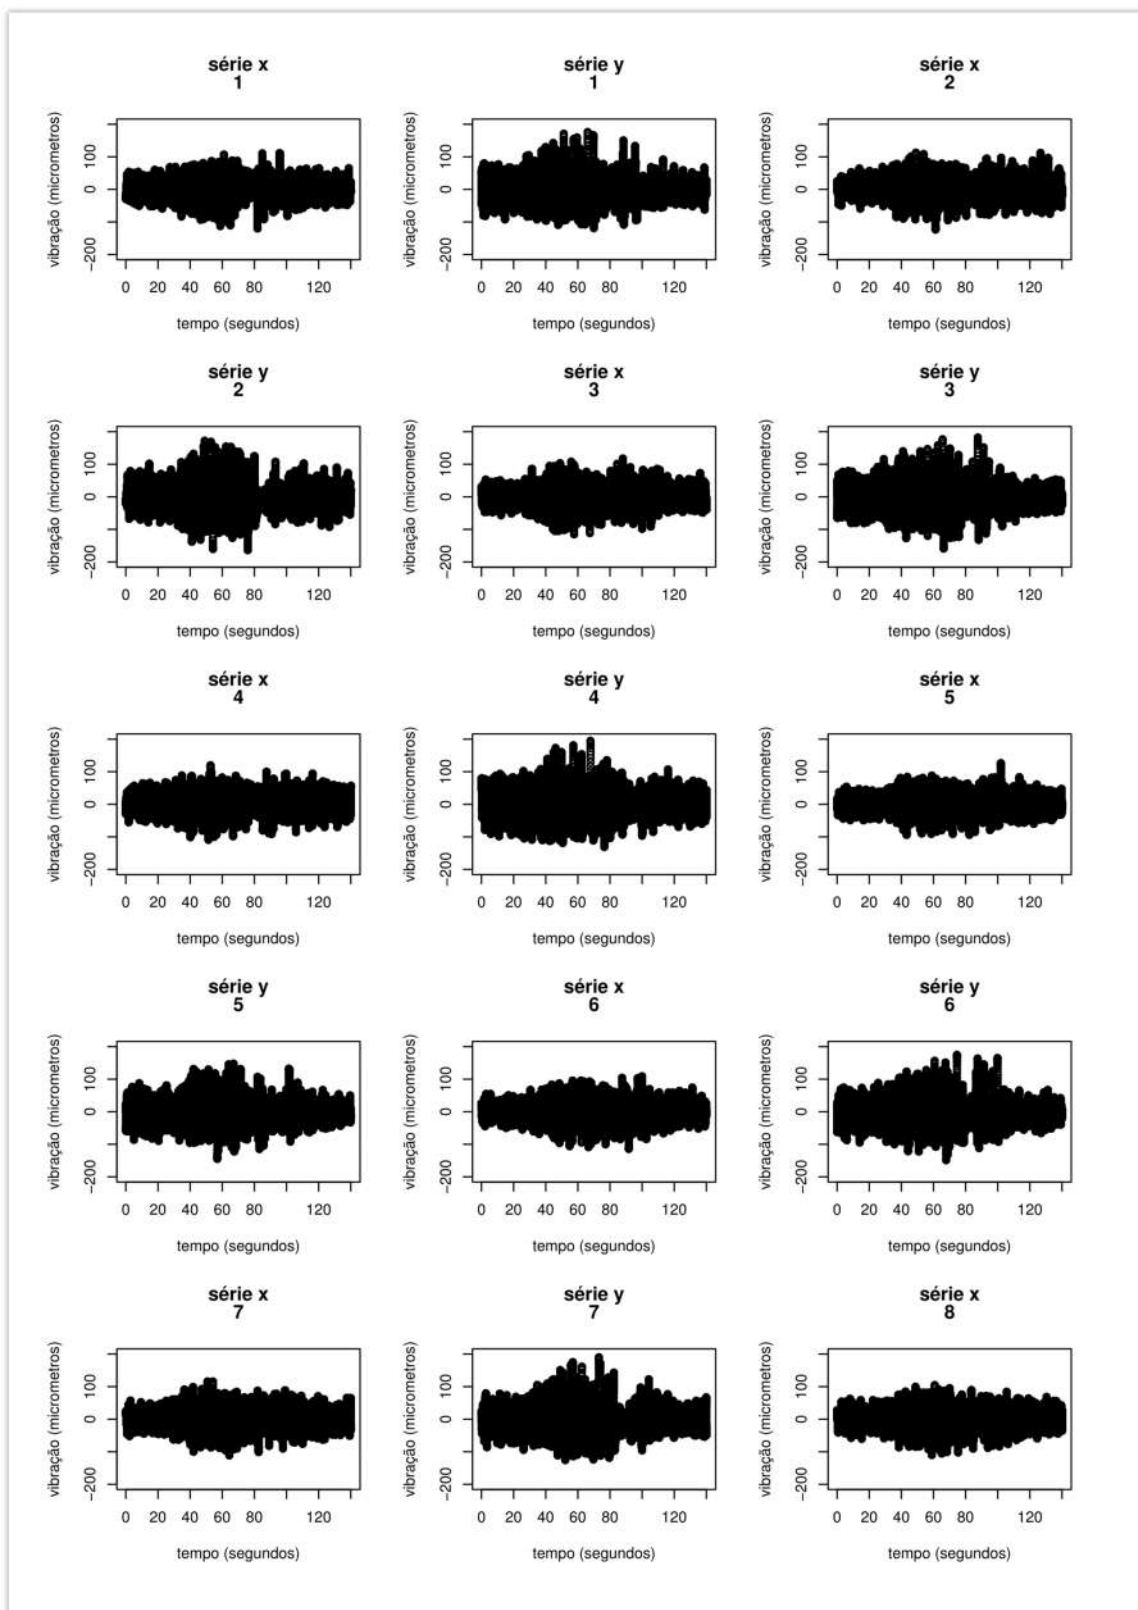


Anexo VI - Figura 59: Resultado modelo ARMA(22,3)- ARCH(22) parte 29

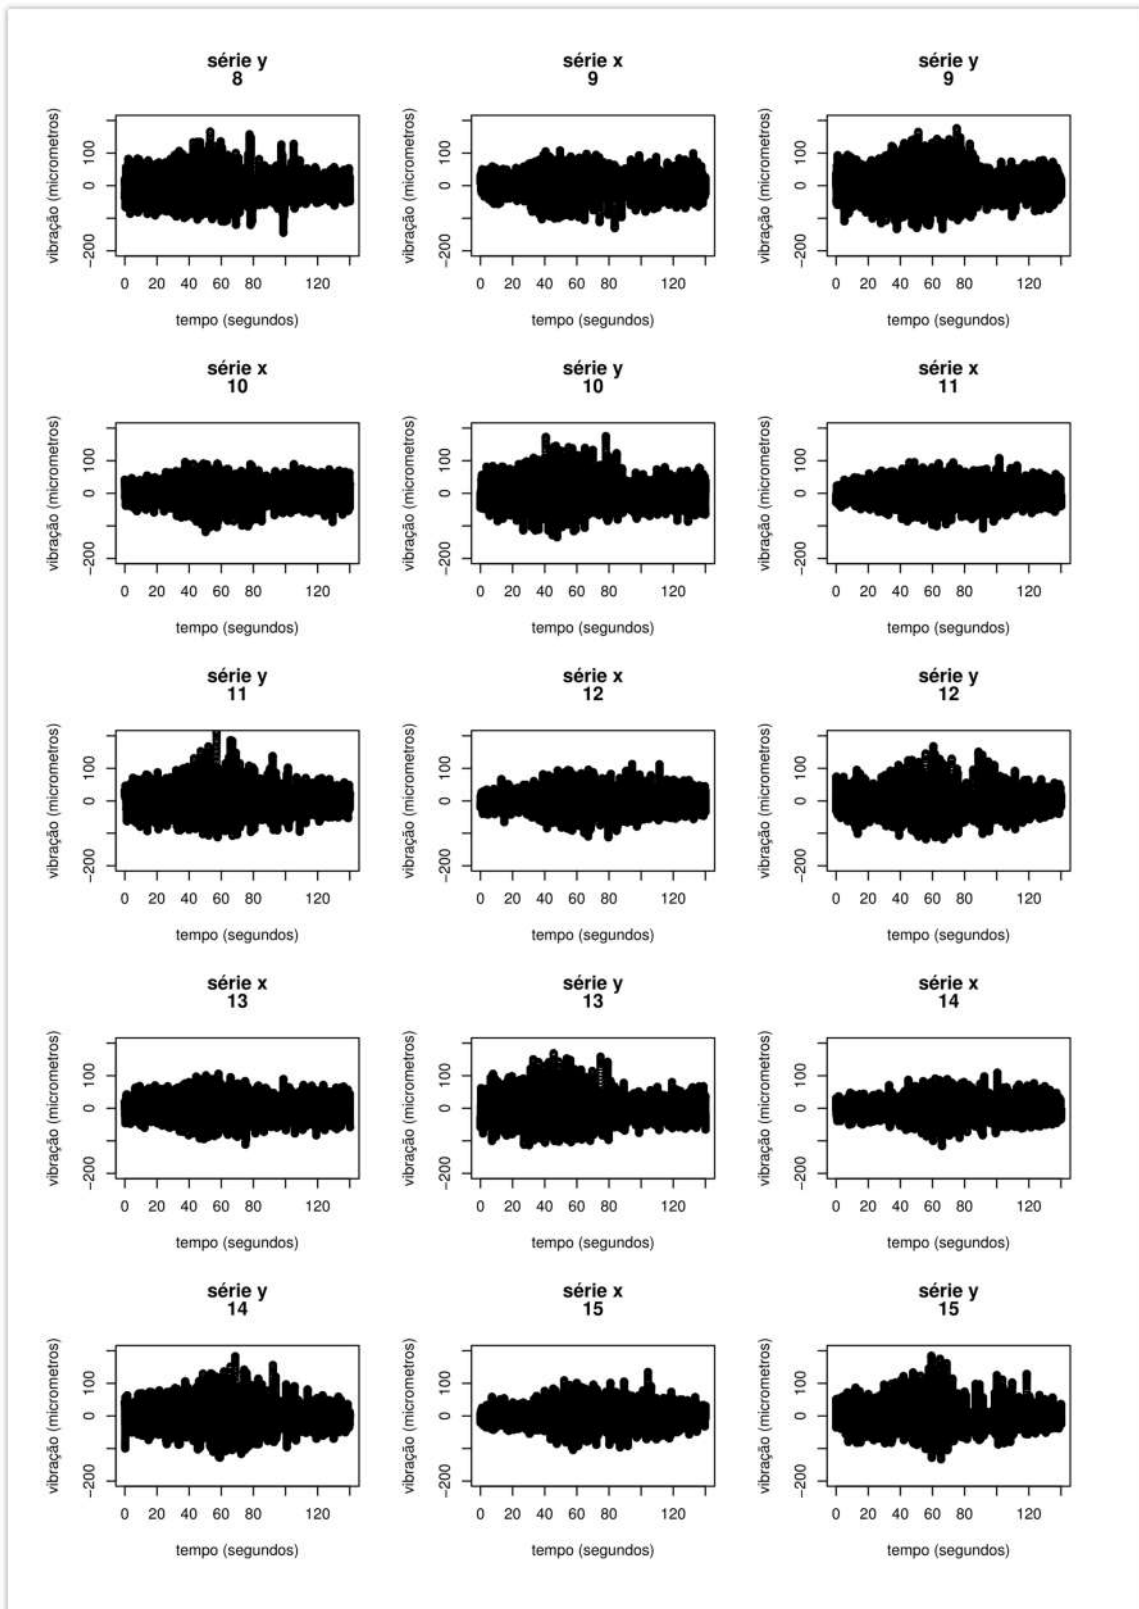


Anexo VI - Figura 60: Resultado modelo ARMA(22,3)- ARCH(22) parte 30

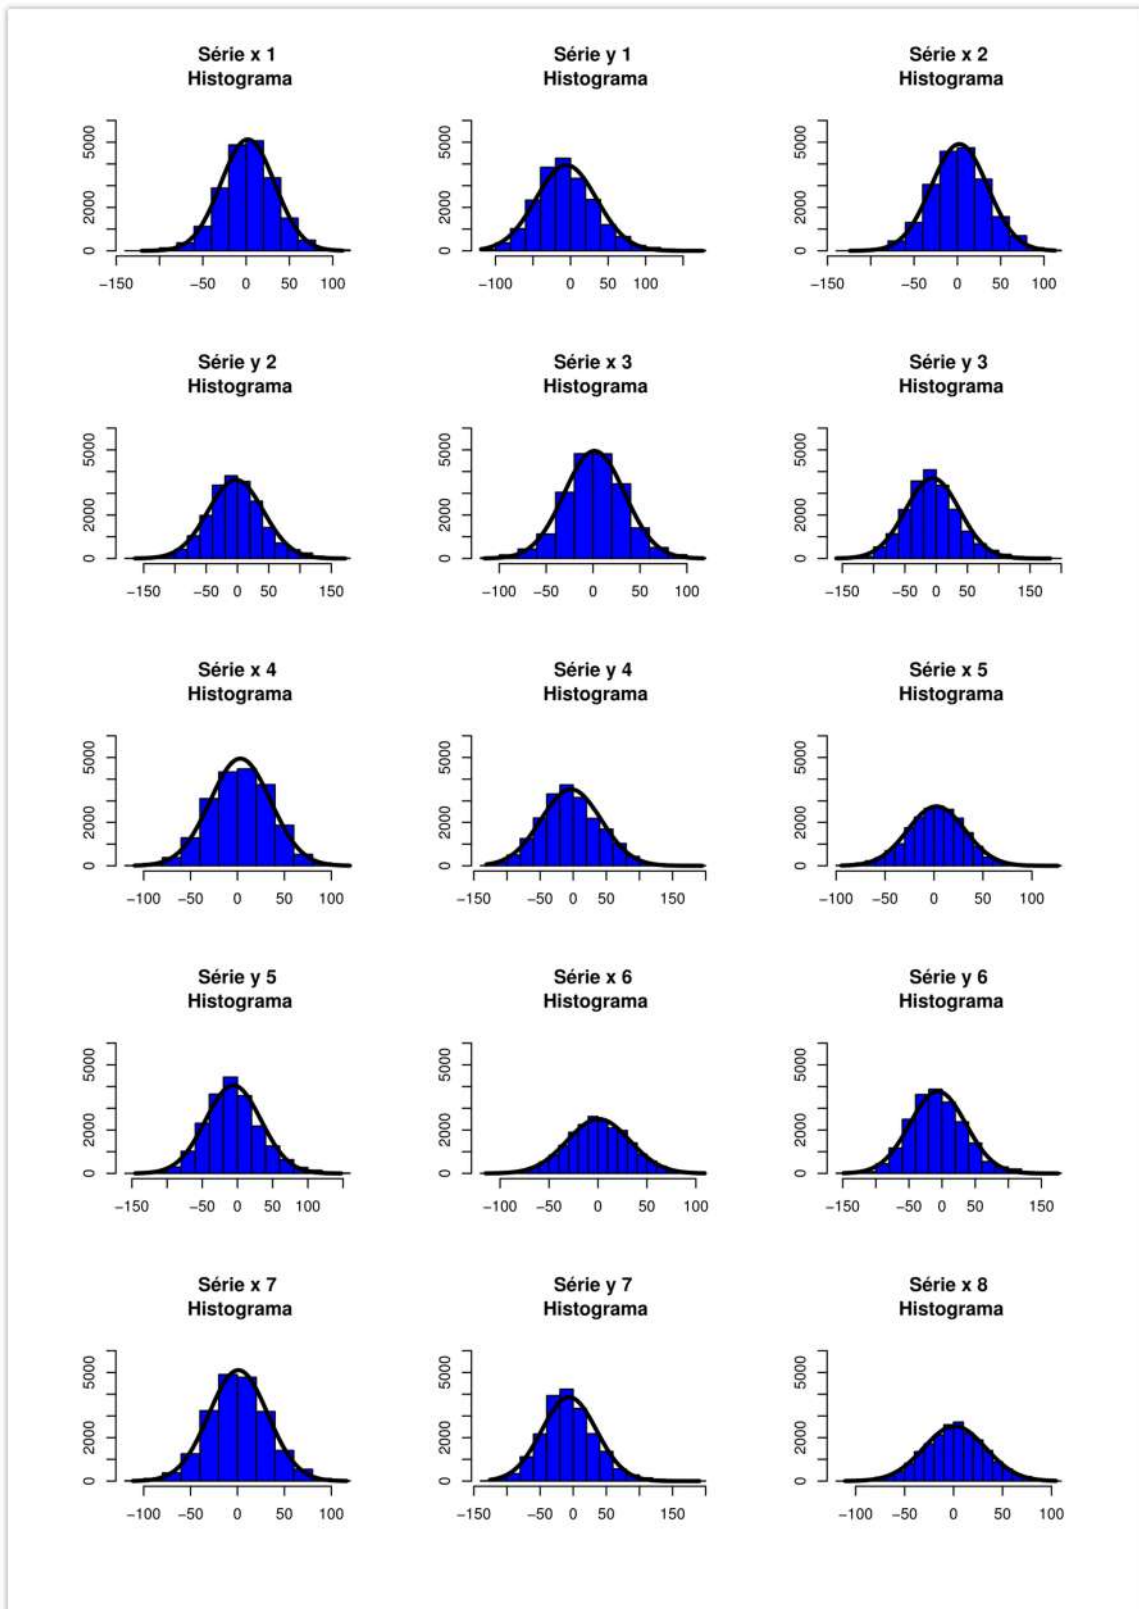
ANEXO VII – ANÁLISE DESCRITIVA TRANSIENTE FILTRADO



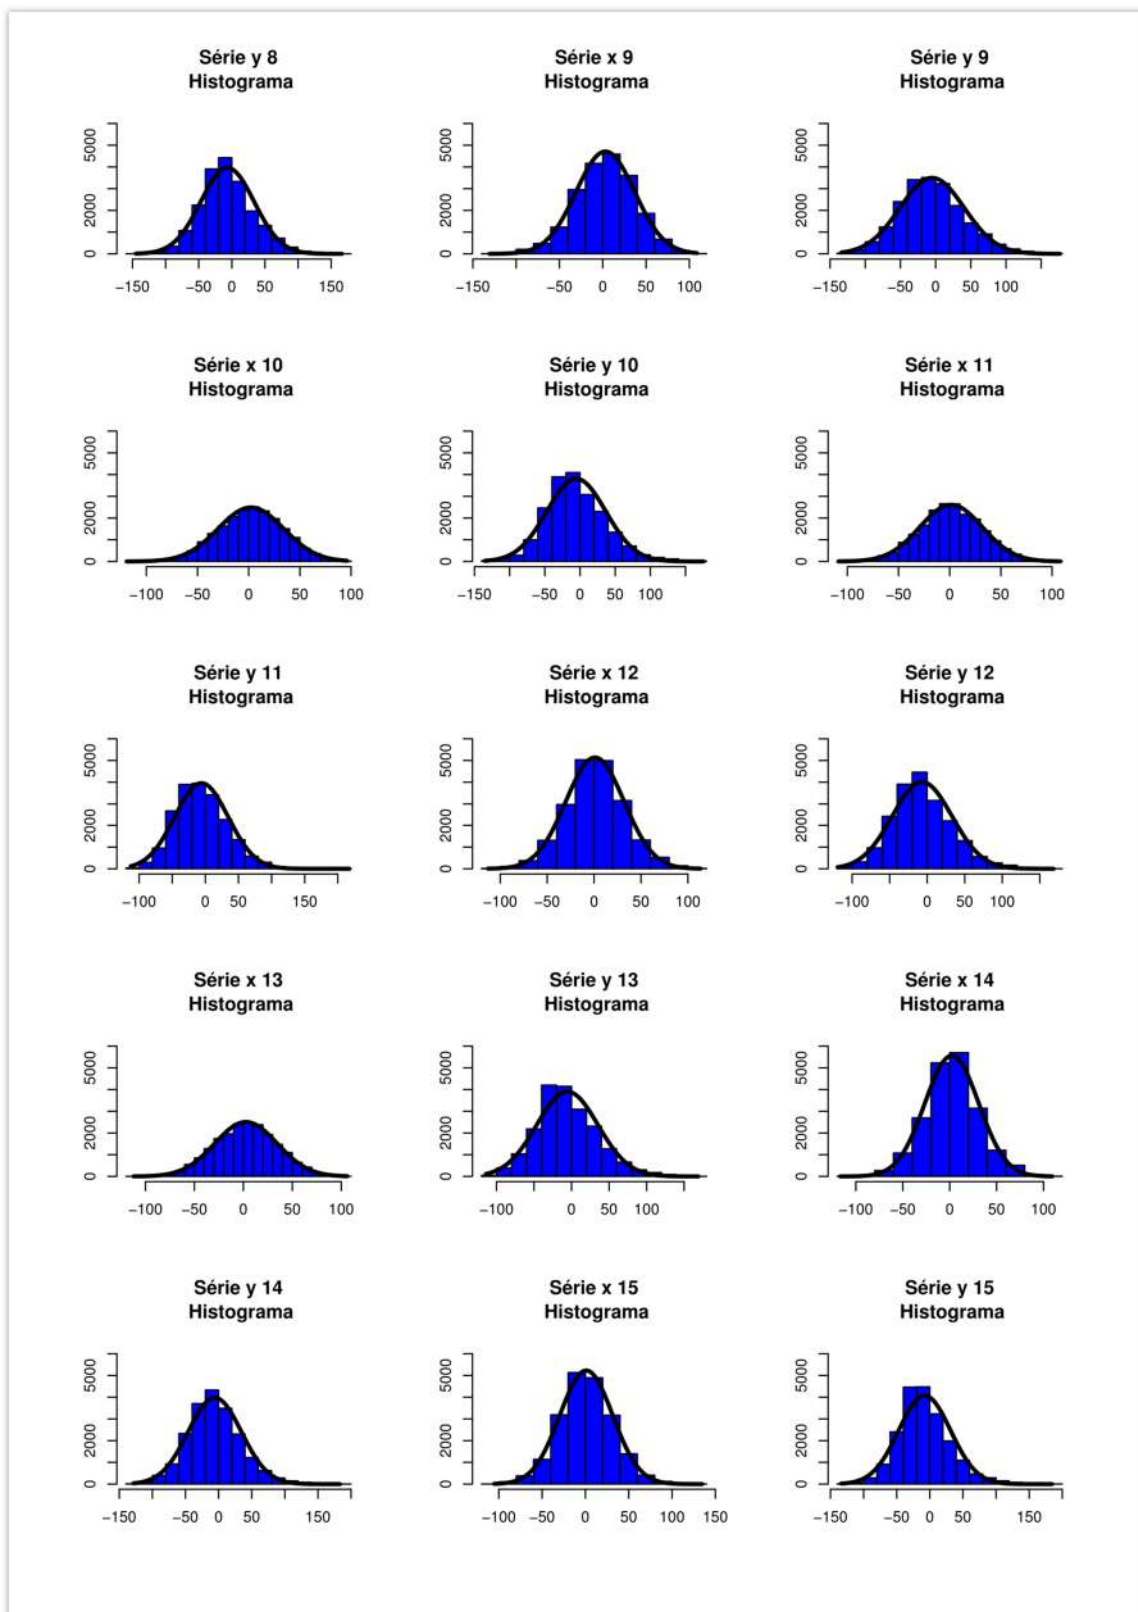
Anexo VII - Figura 1: Séries filtradas no regime transiente parte 1



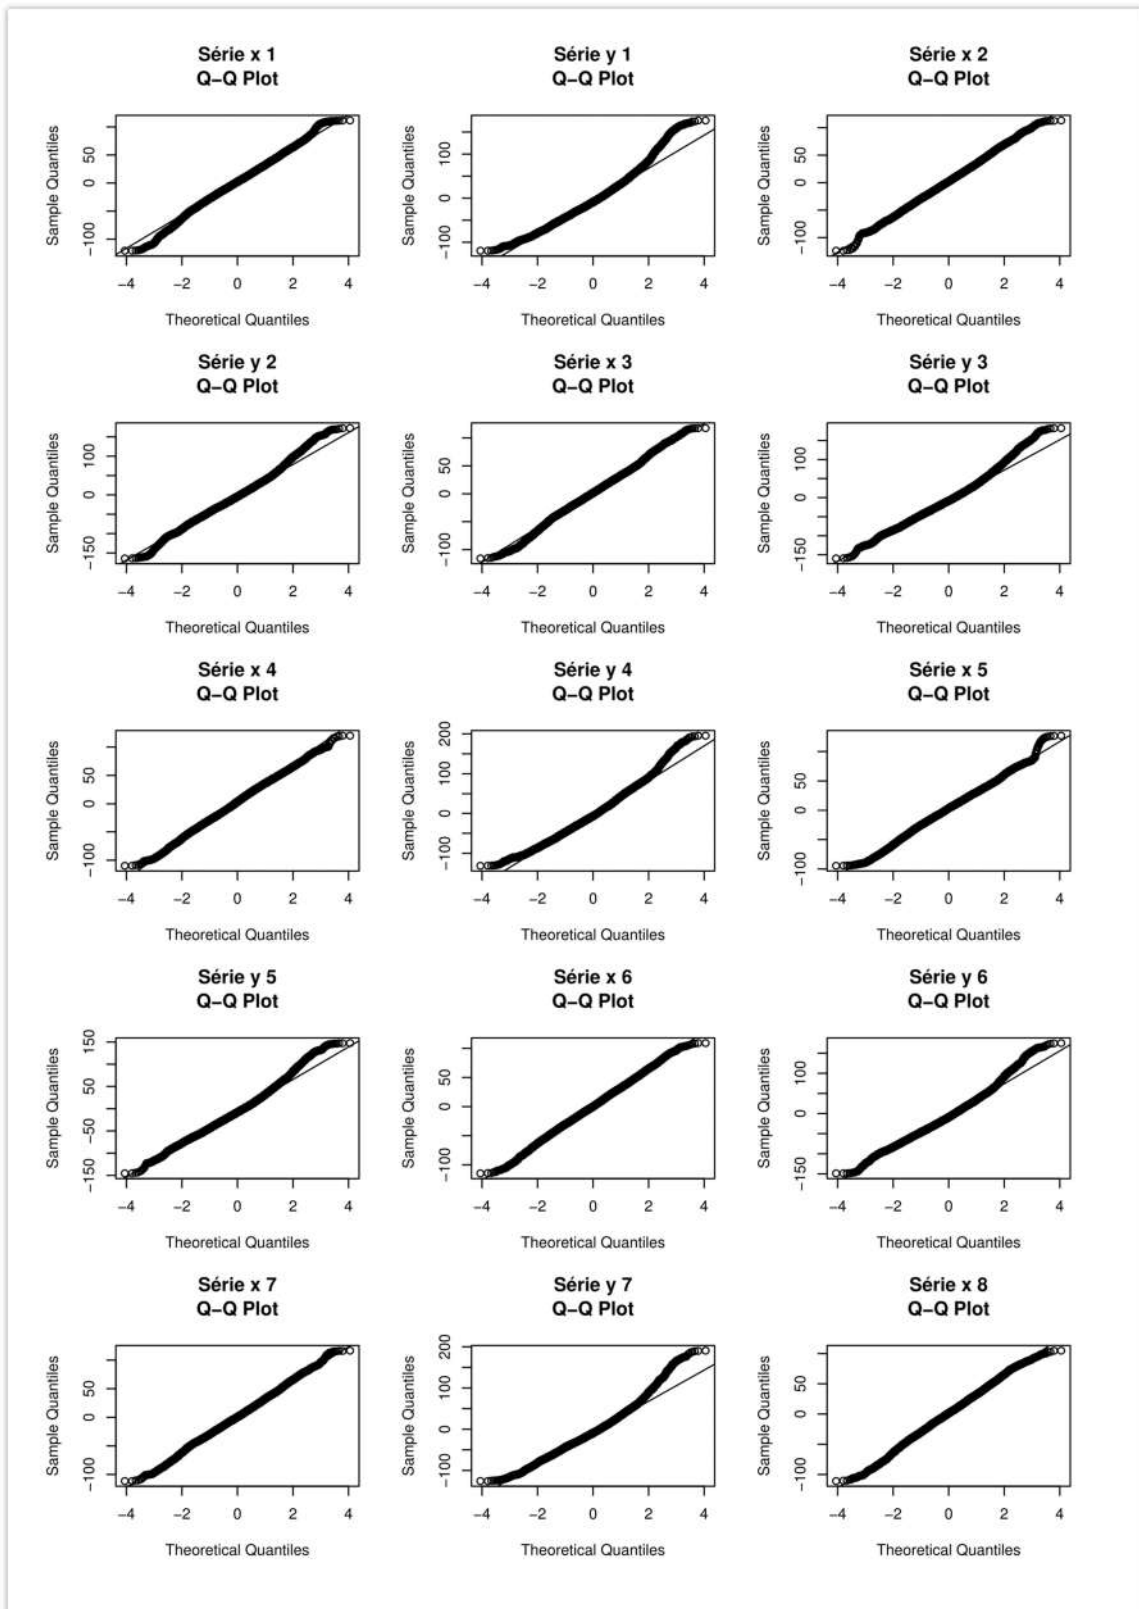
Anexo VII - Figura 2: Séries filtradas no regime transiente parte 2



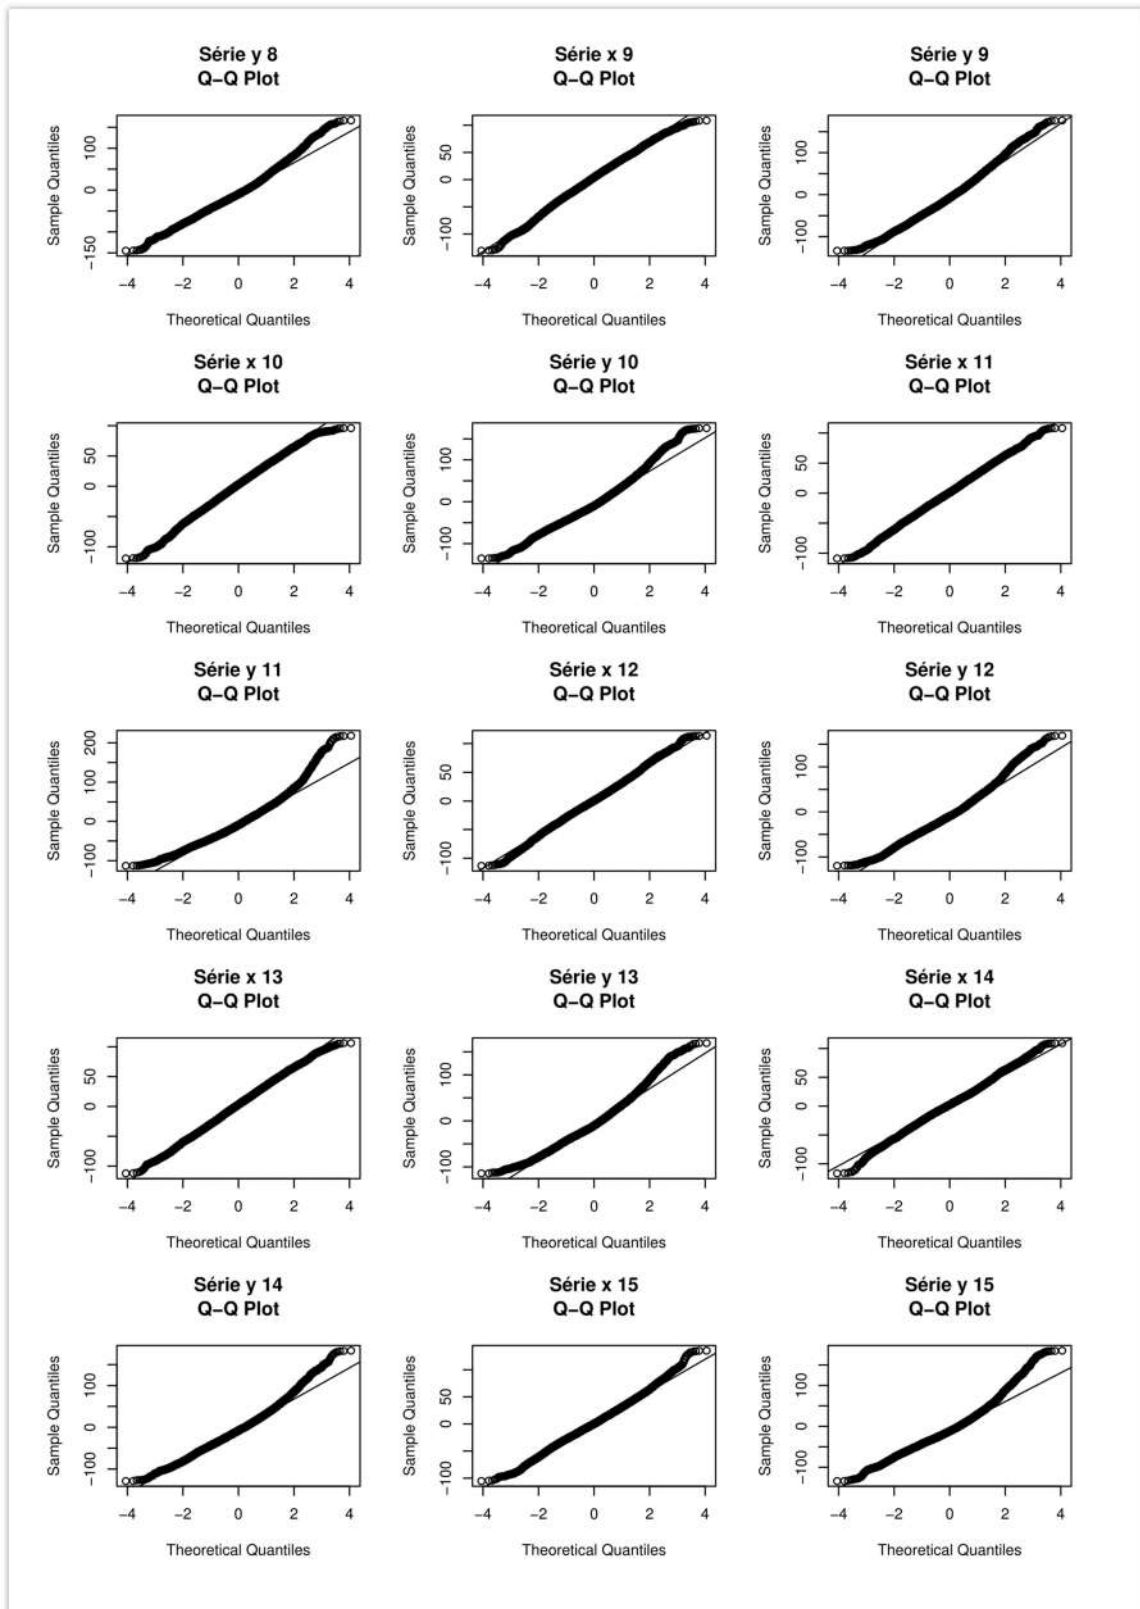
Anexo VII - Figura 3: Histograma das séries filtradas no regime transiente parte 1



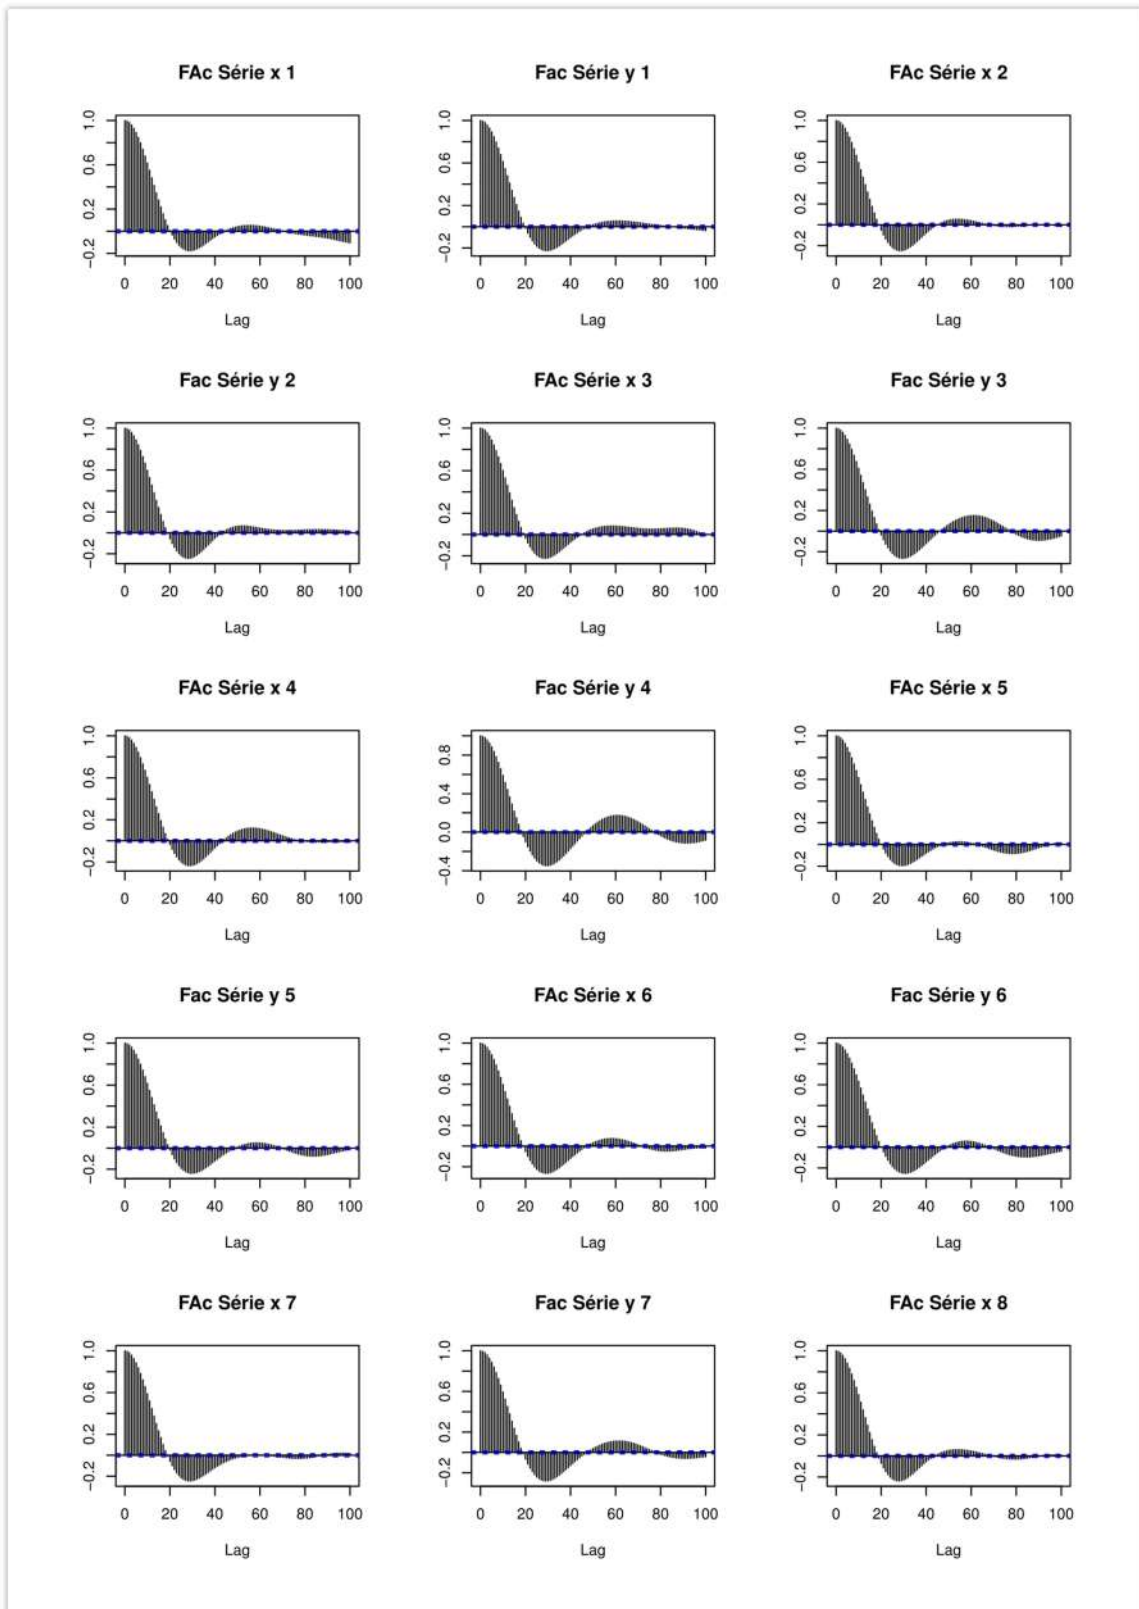
Anexo VII - Figura 4: Histograma das séries filtradas no regime transiente parte 2



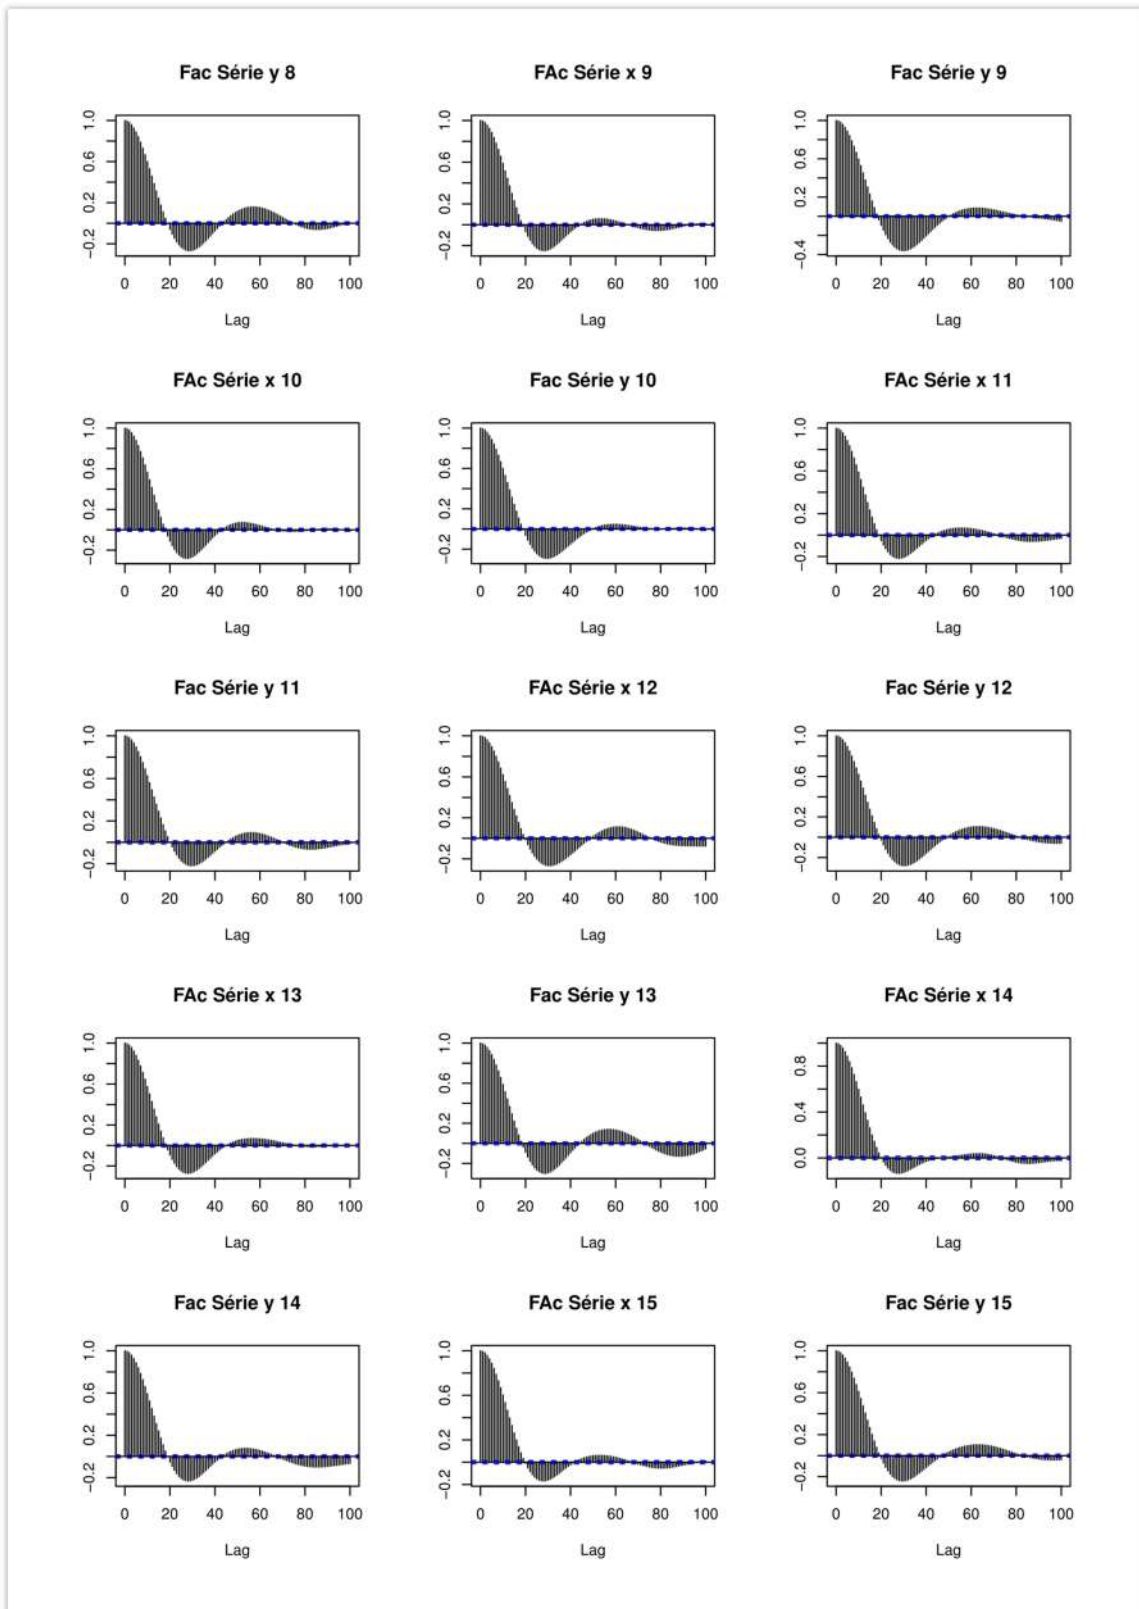
Anexo VII - Figura 5: Gráfico dos quantis das séries filtradas no regime transiente parte



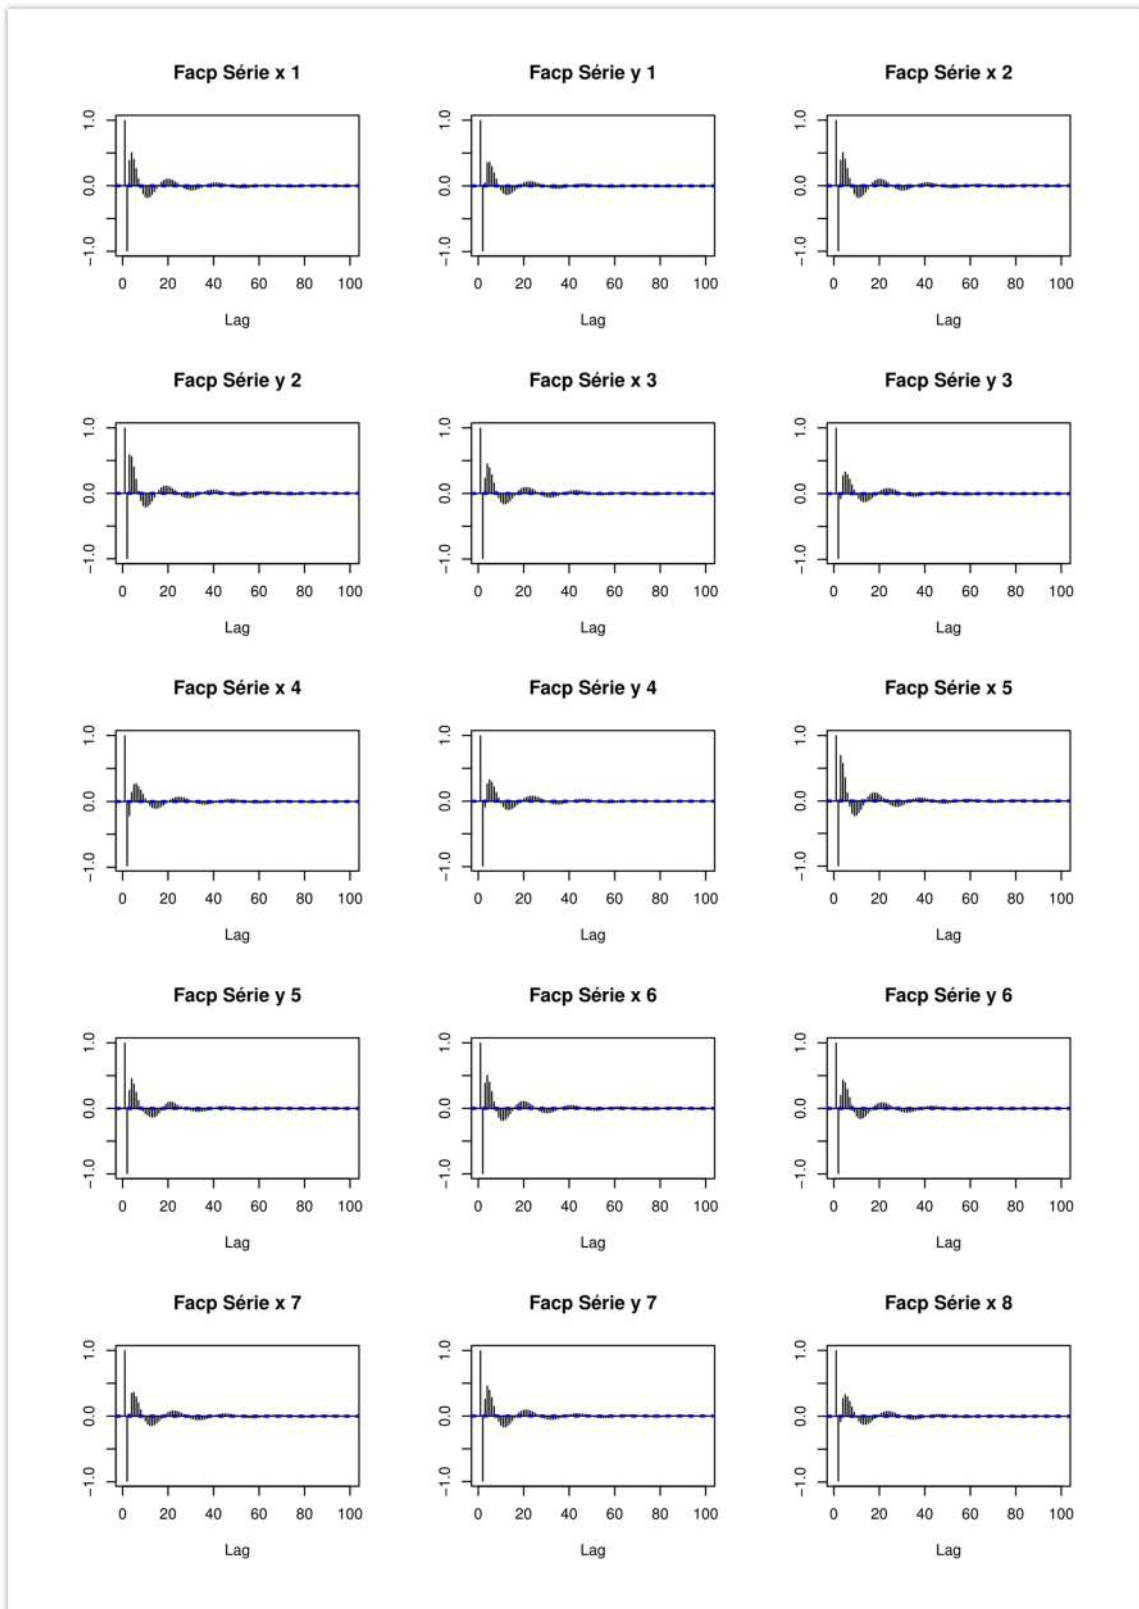
Anexo VII - Figura 6: Gráfico dos quantis das séries filtradas no regime transiente parte



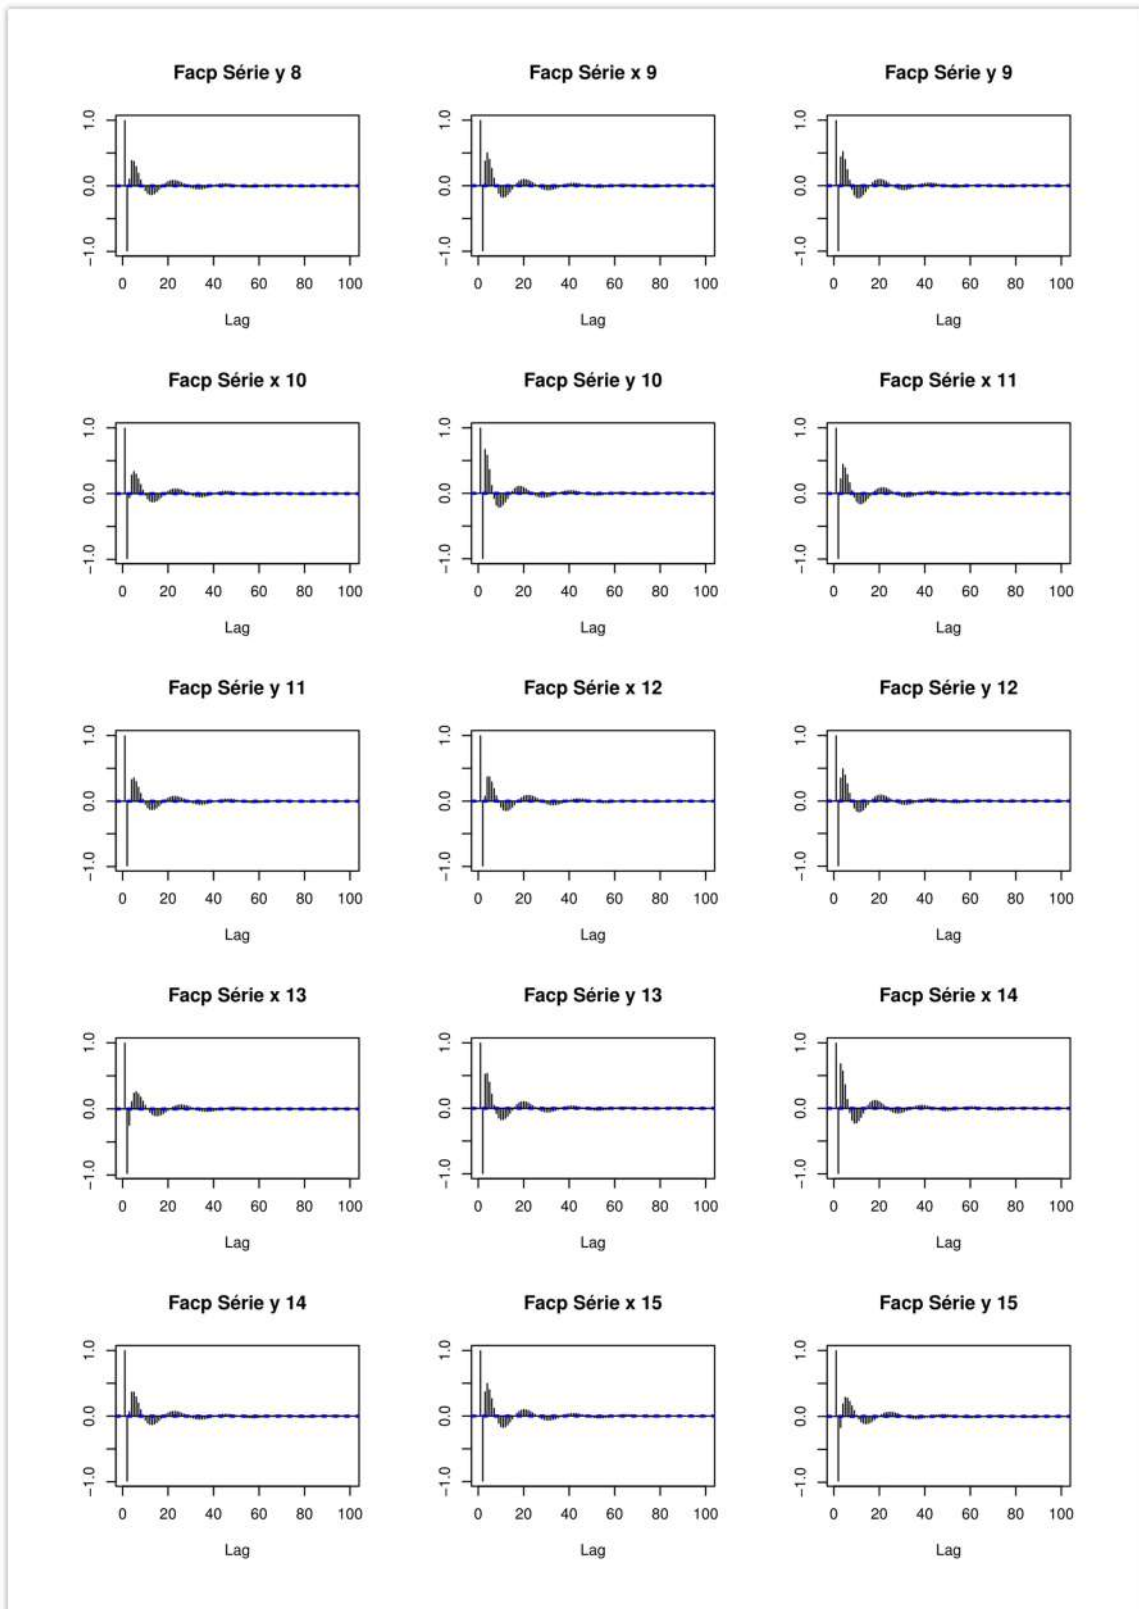
Anexo VII - Figura 7: FAC das séries filtradas no regime transiente parte 1



Anexo VII - Figura 8: FAC das séries filtradas no regime transiente parte 2



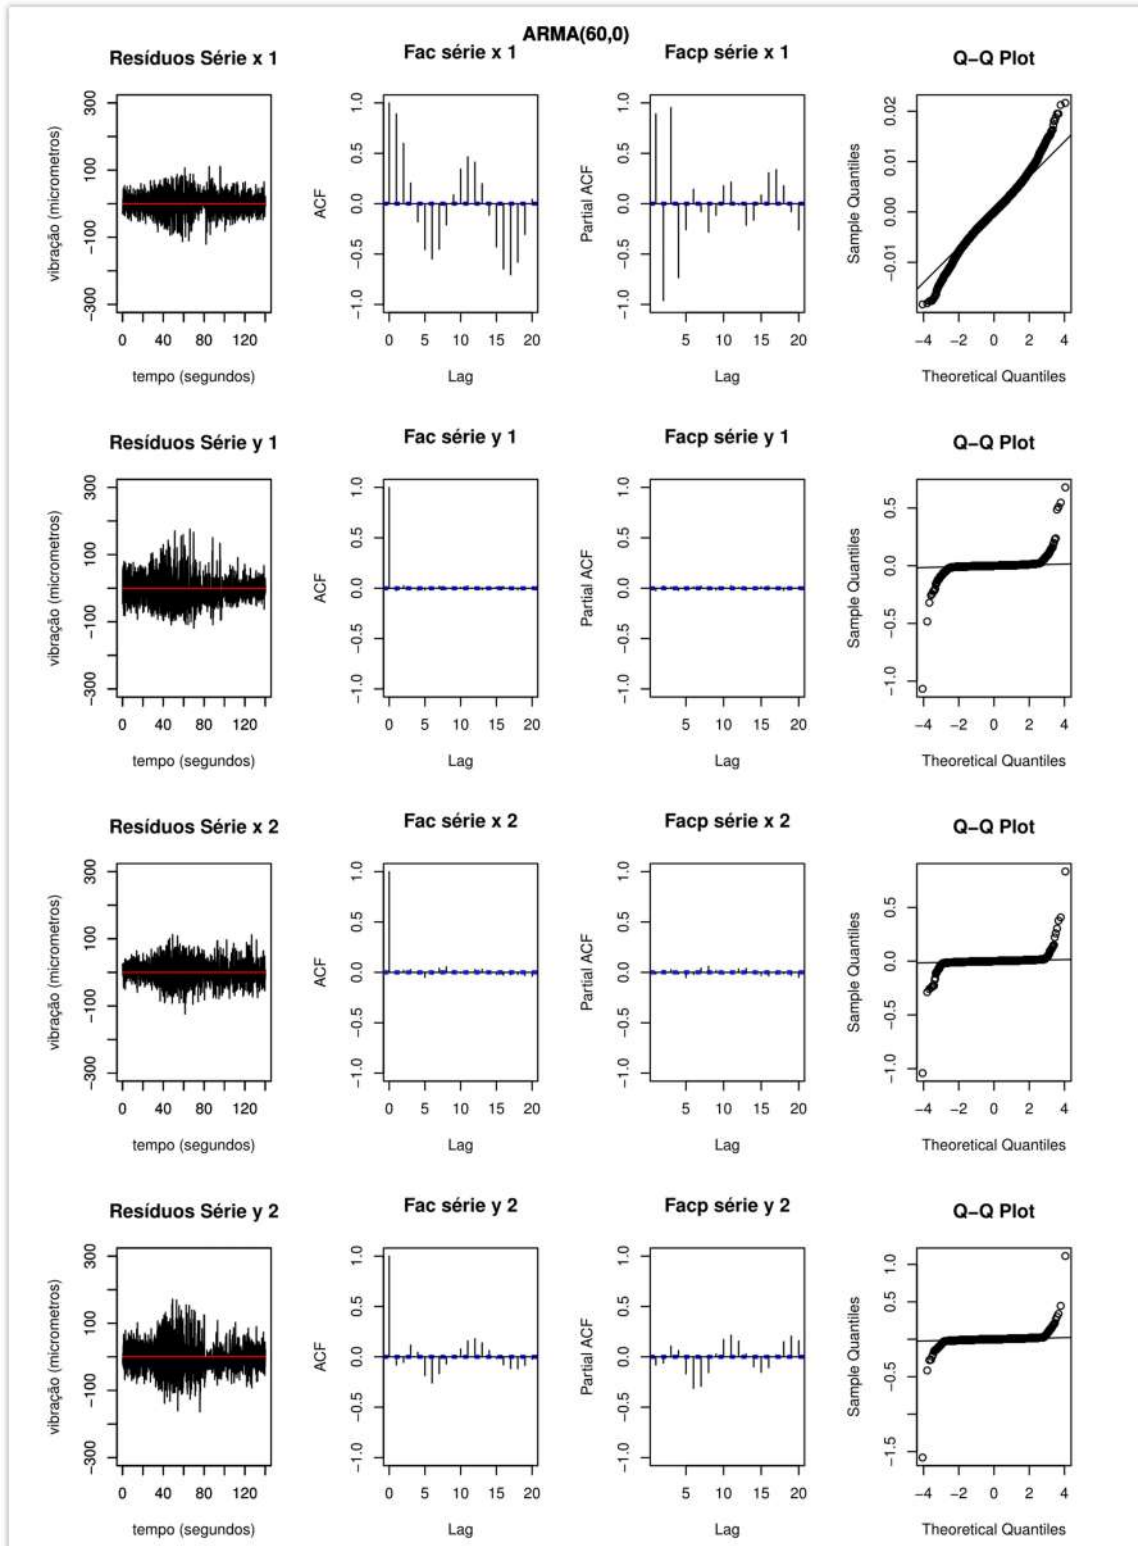
Anexo VII - Figura 9: FACP das séries filtradas no regime transiente parte 1



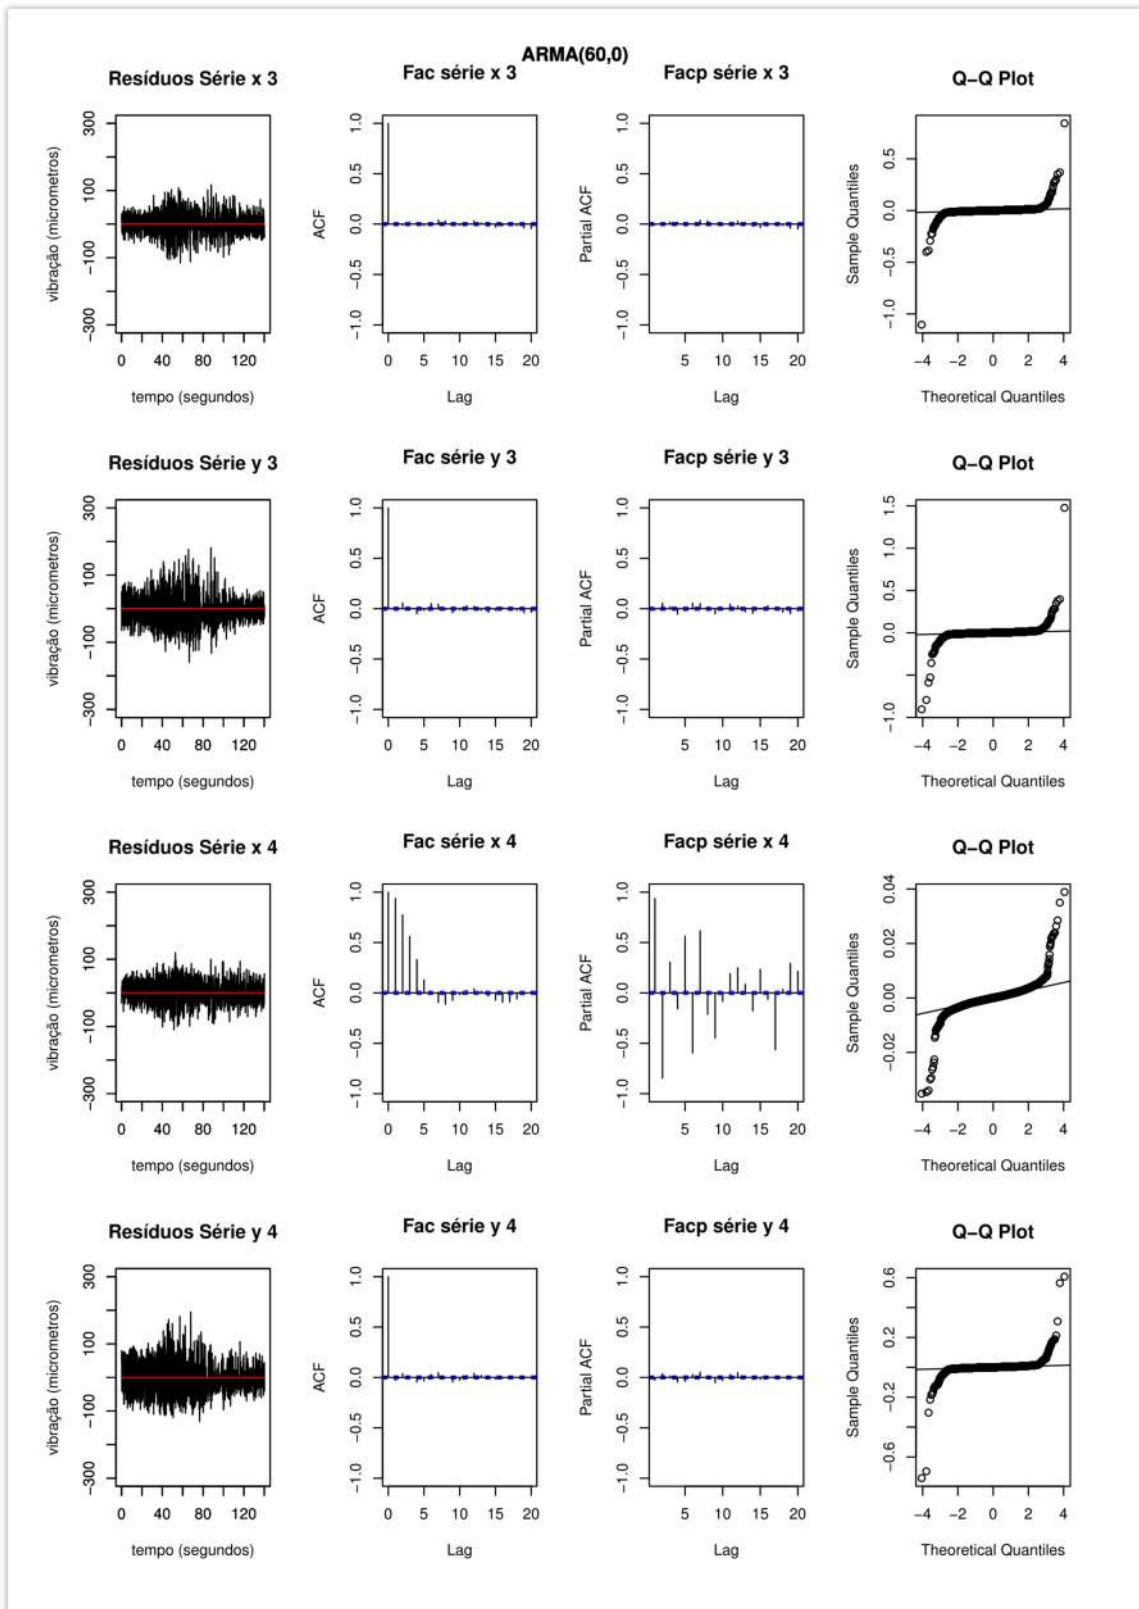
Anexo VII - Figura 10: FACP das séries filtradas no regime transiente parte 2

ANEXO VIII – ANÁLISE DESCRITIVA TRANSIENTE FILTRADO

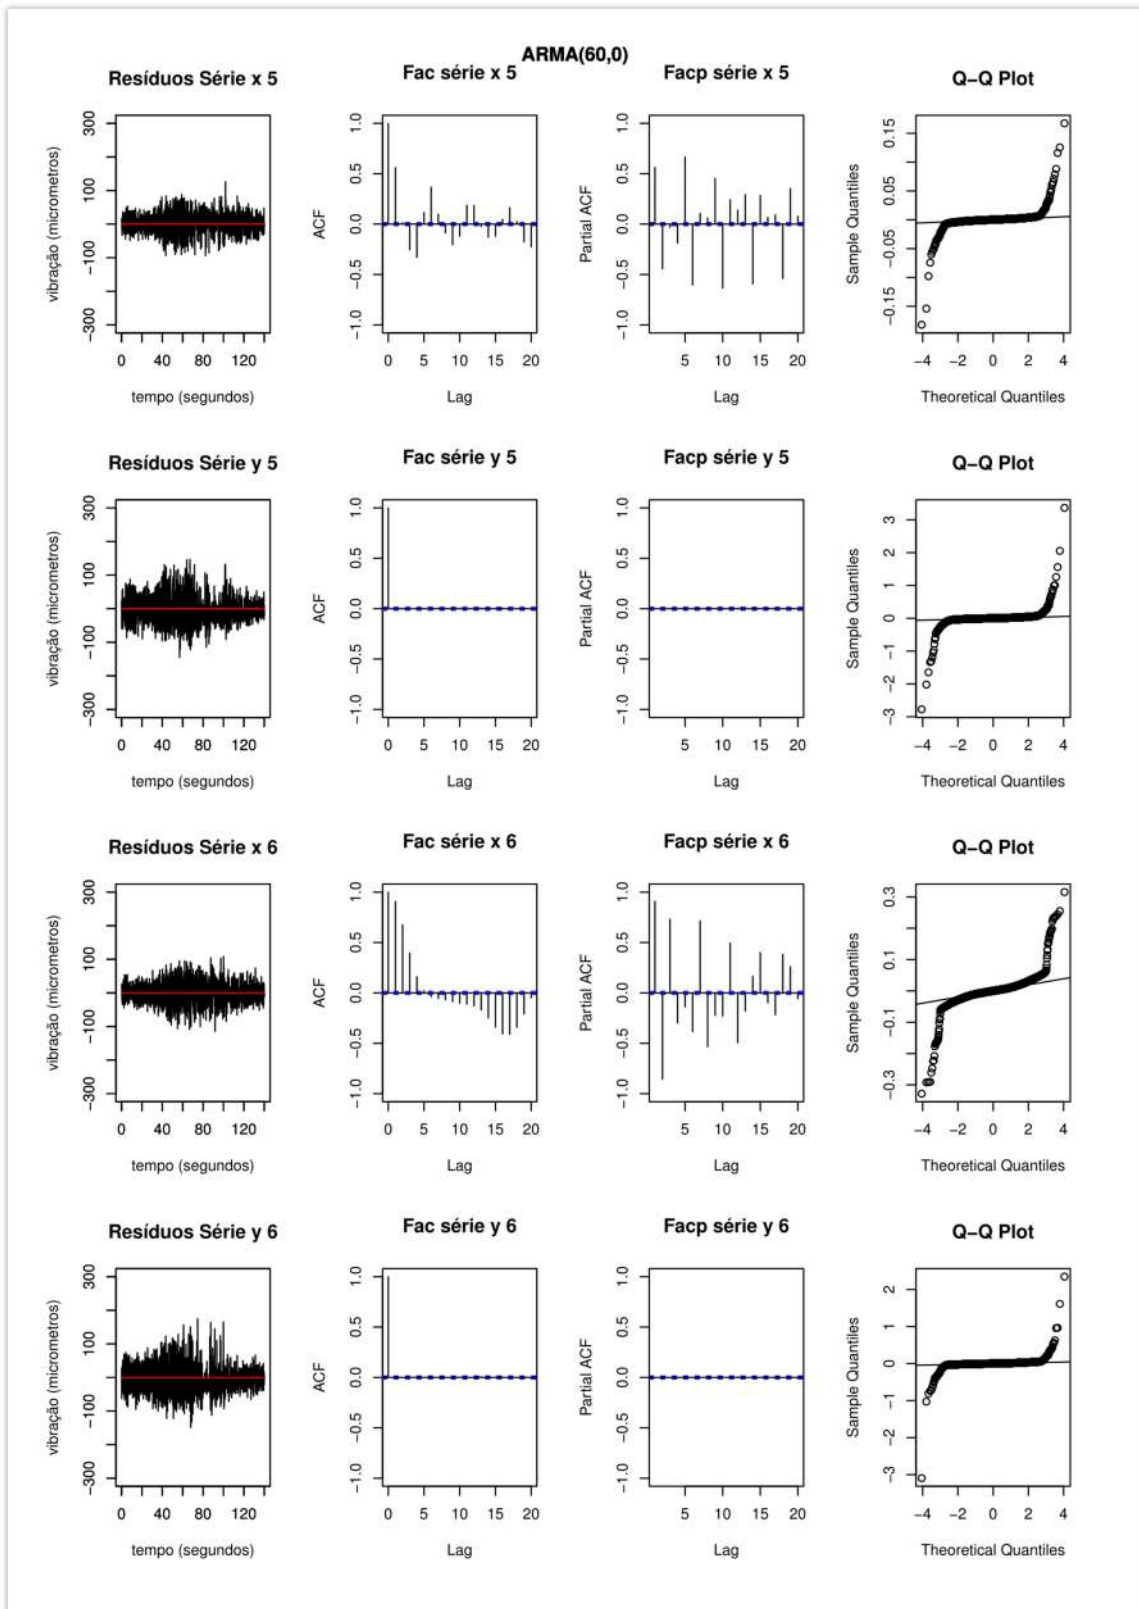
RESULTADOS DA APLICAÇÃO DO MODELO ARMA



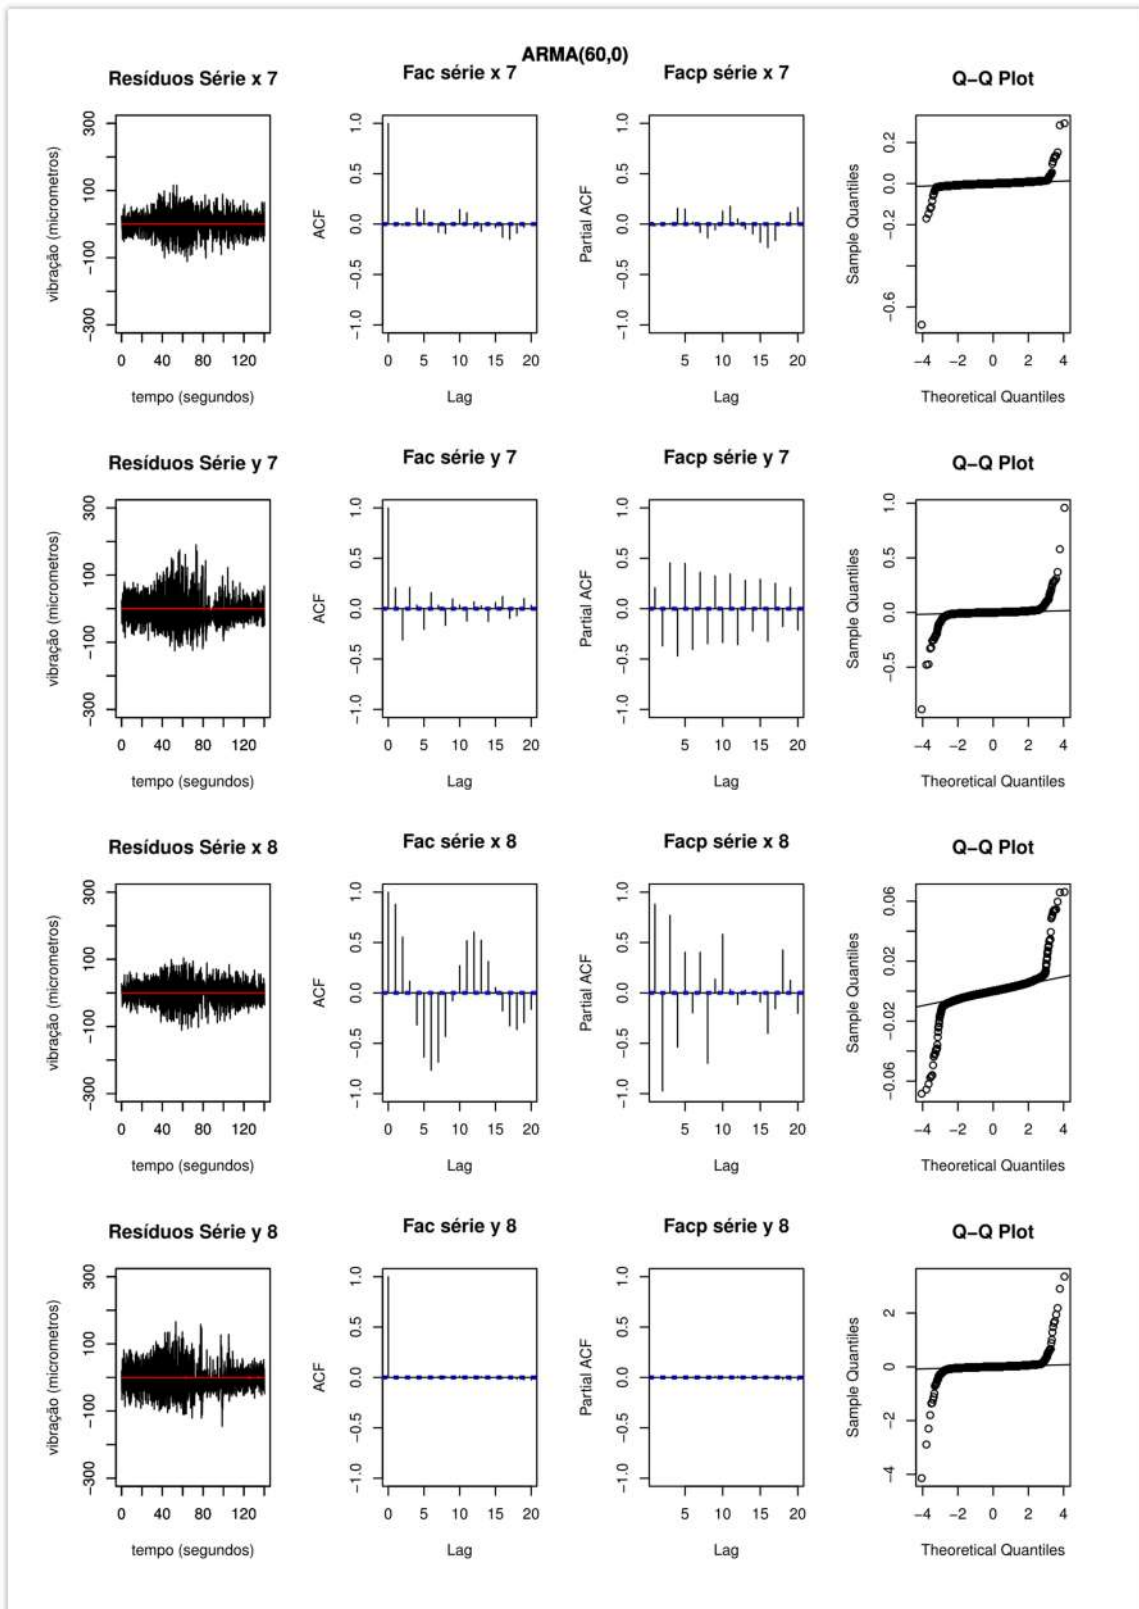
Anexo VIII - Figura 1: Resultado modelo AR(60) parte 1



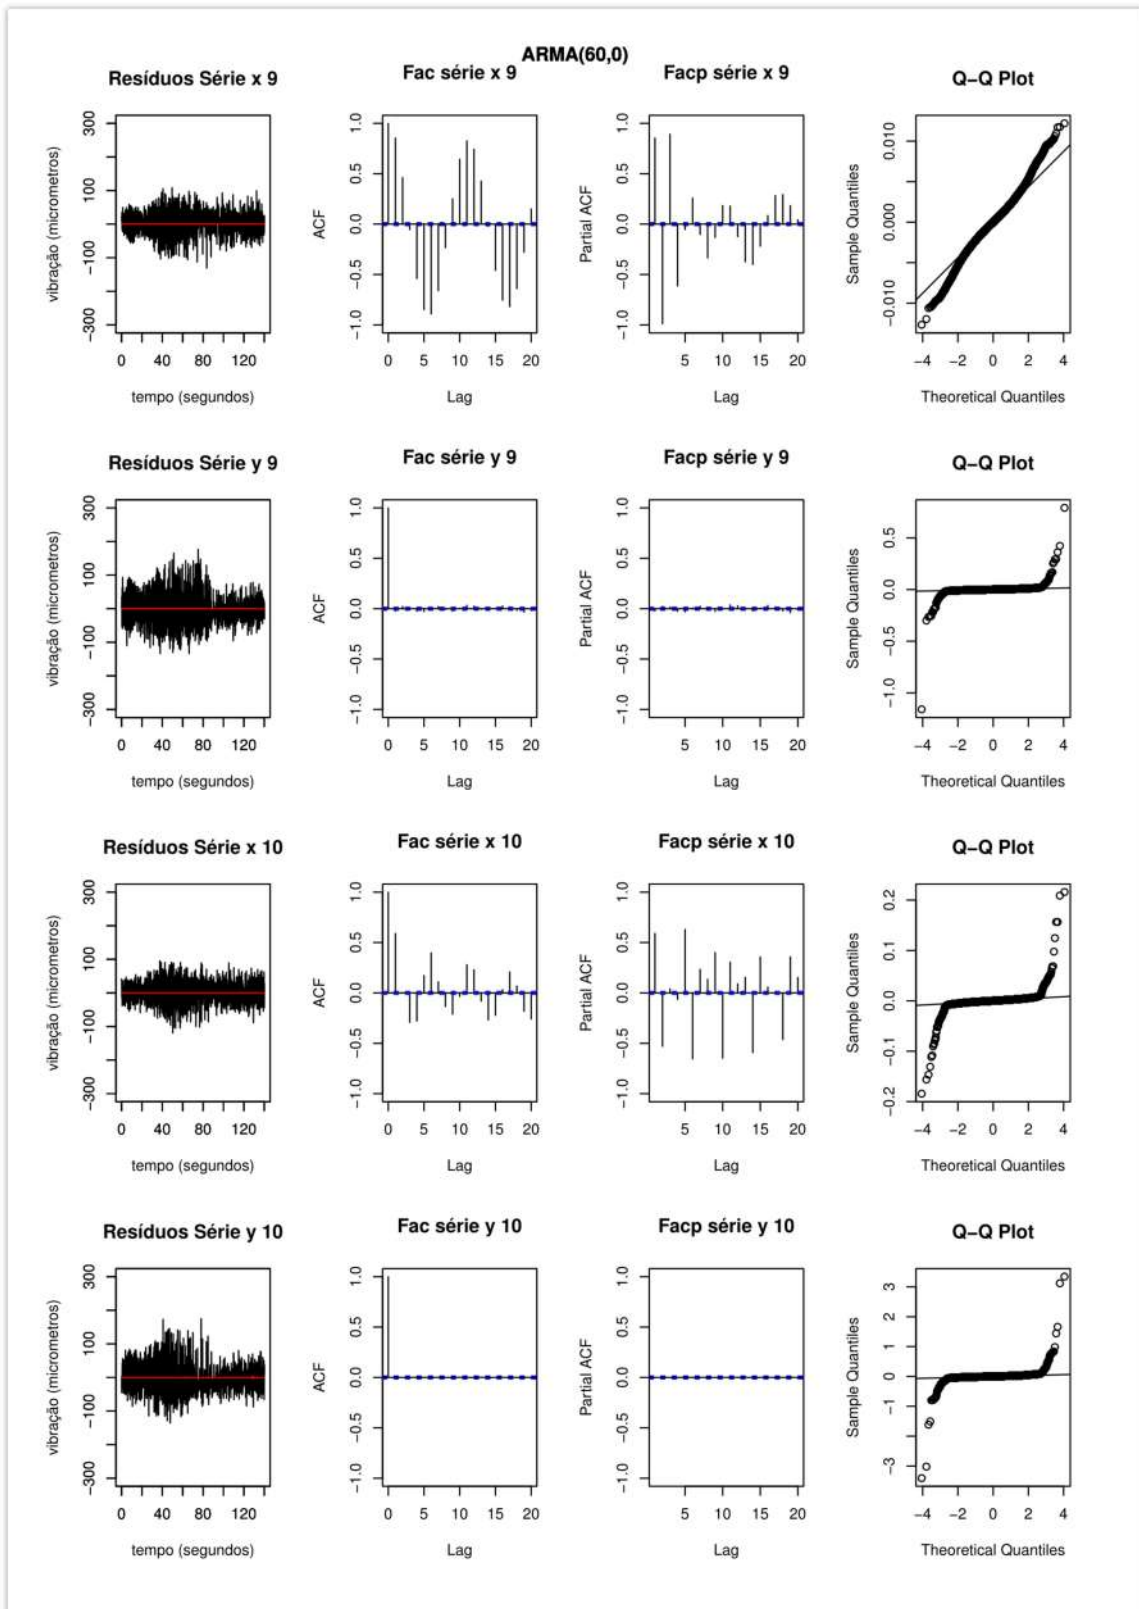
Anexo VIII - Figura 2: Resultado modelo AR(60) parte 2



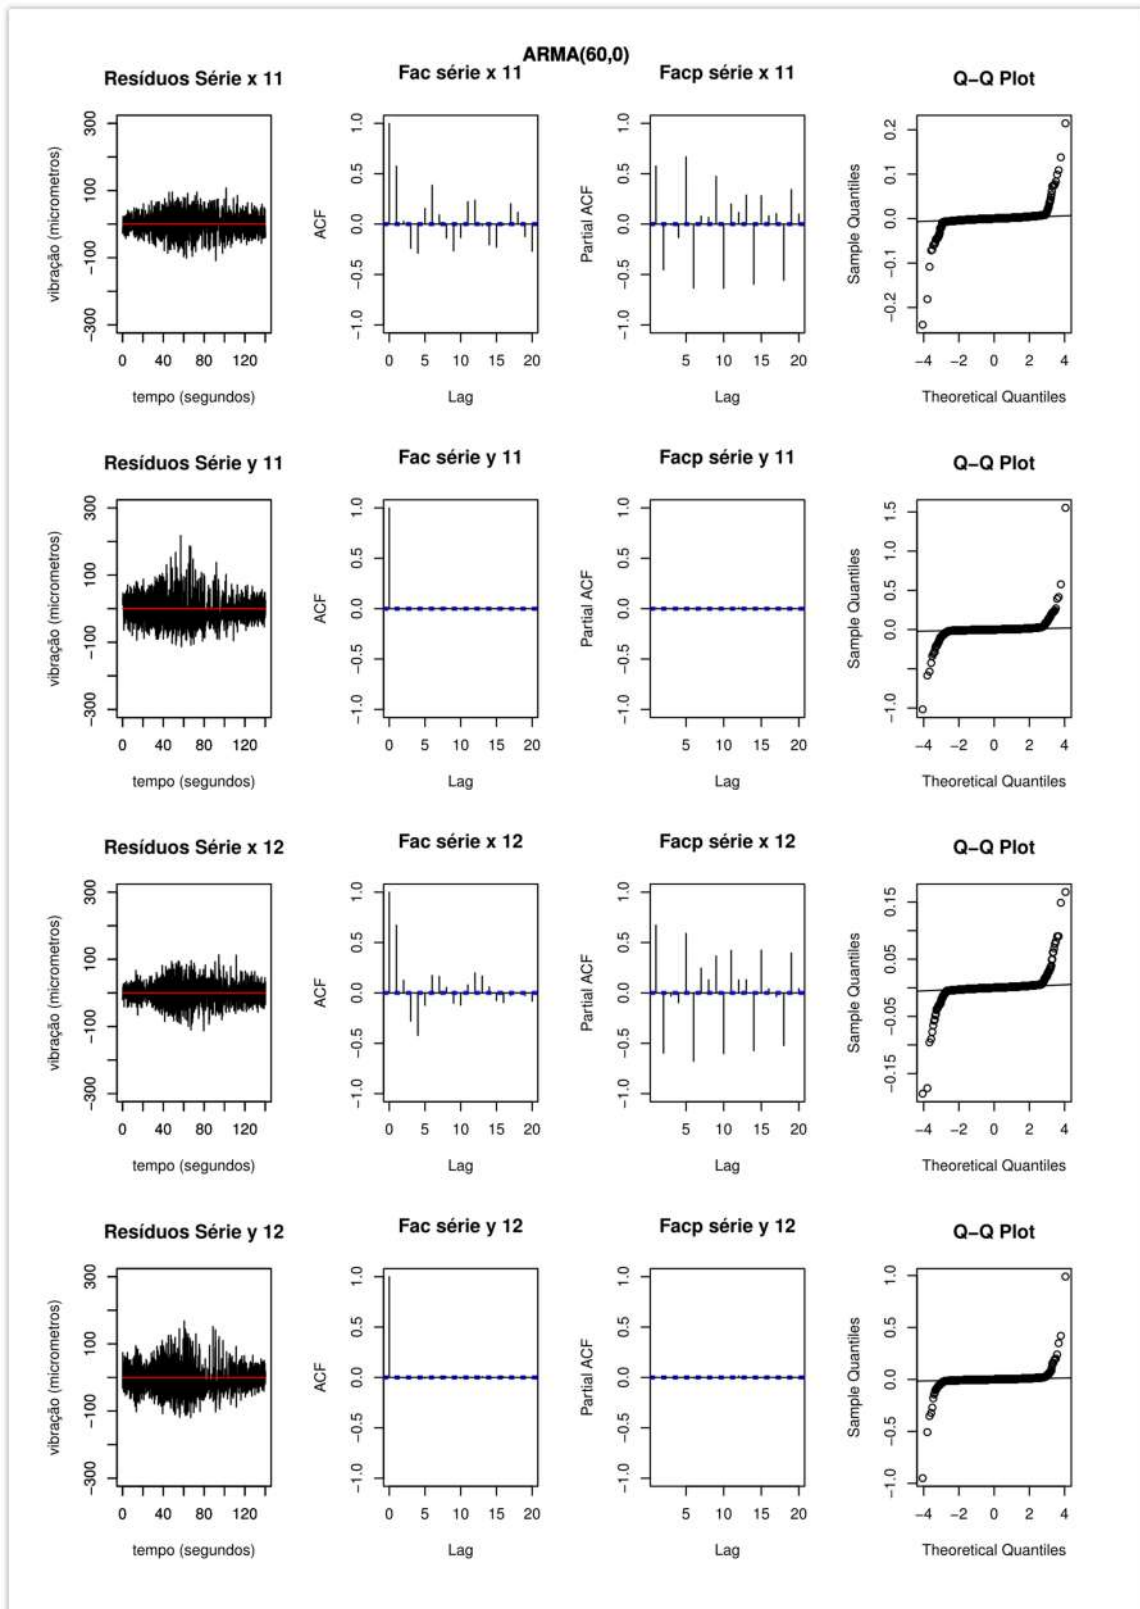
Anexo VIII - Figura 3: Resultado modelo AR(60) parte 3



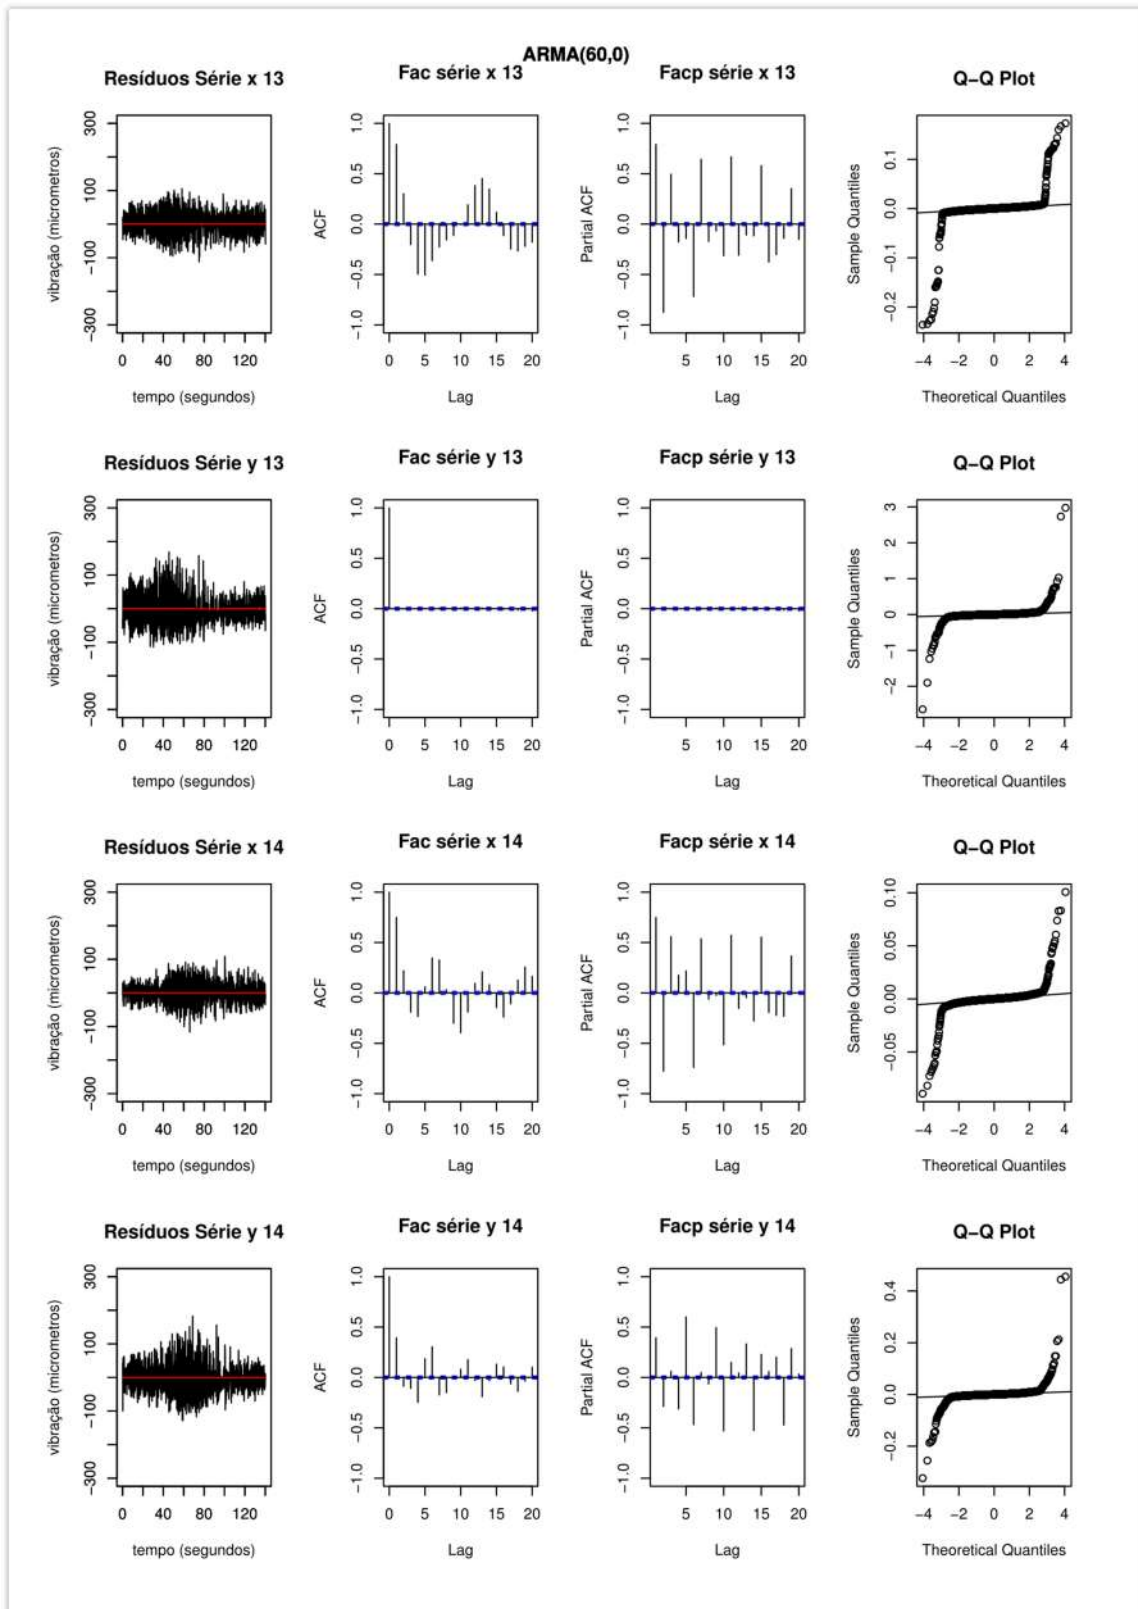
Anexo VIII - Figura 4: Resultado modelo AR(60) parte 4



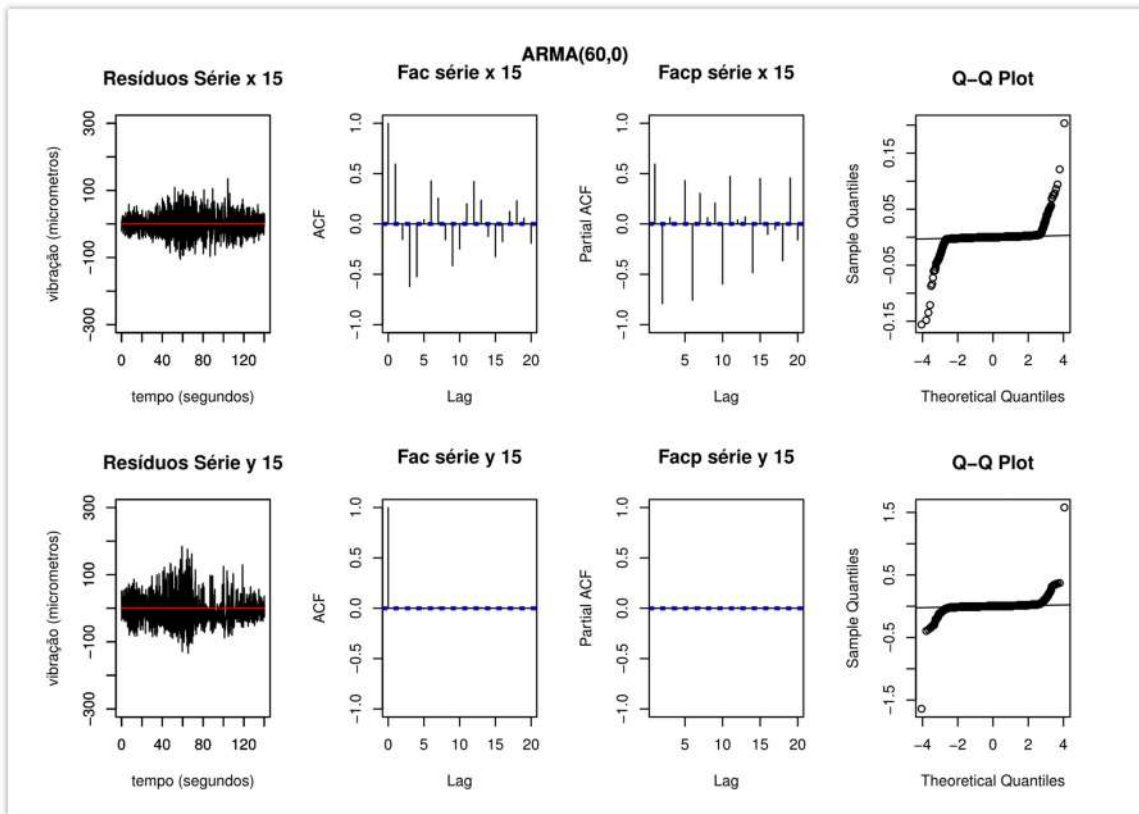
Anexo VIII - Figura 5: Resultado modelo AR(60) parte 5



Anexo VIII - Figura 6: Resultado modelo AR(60) parte 6

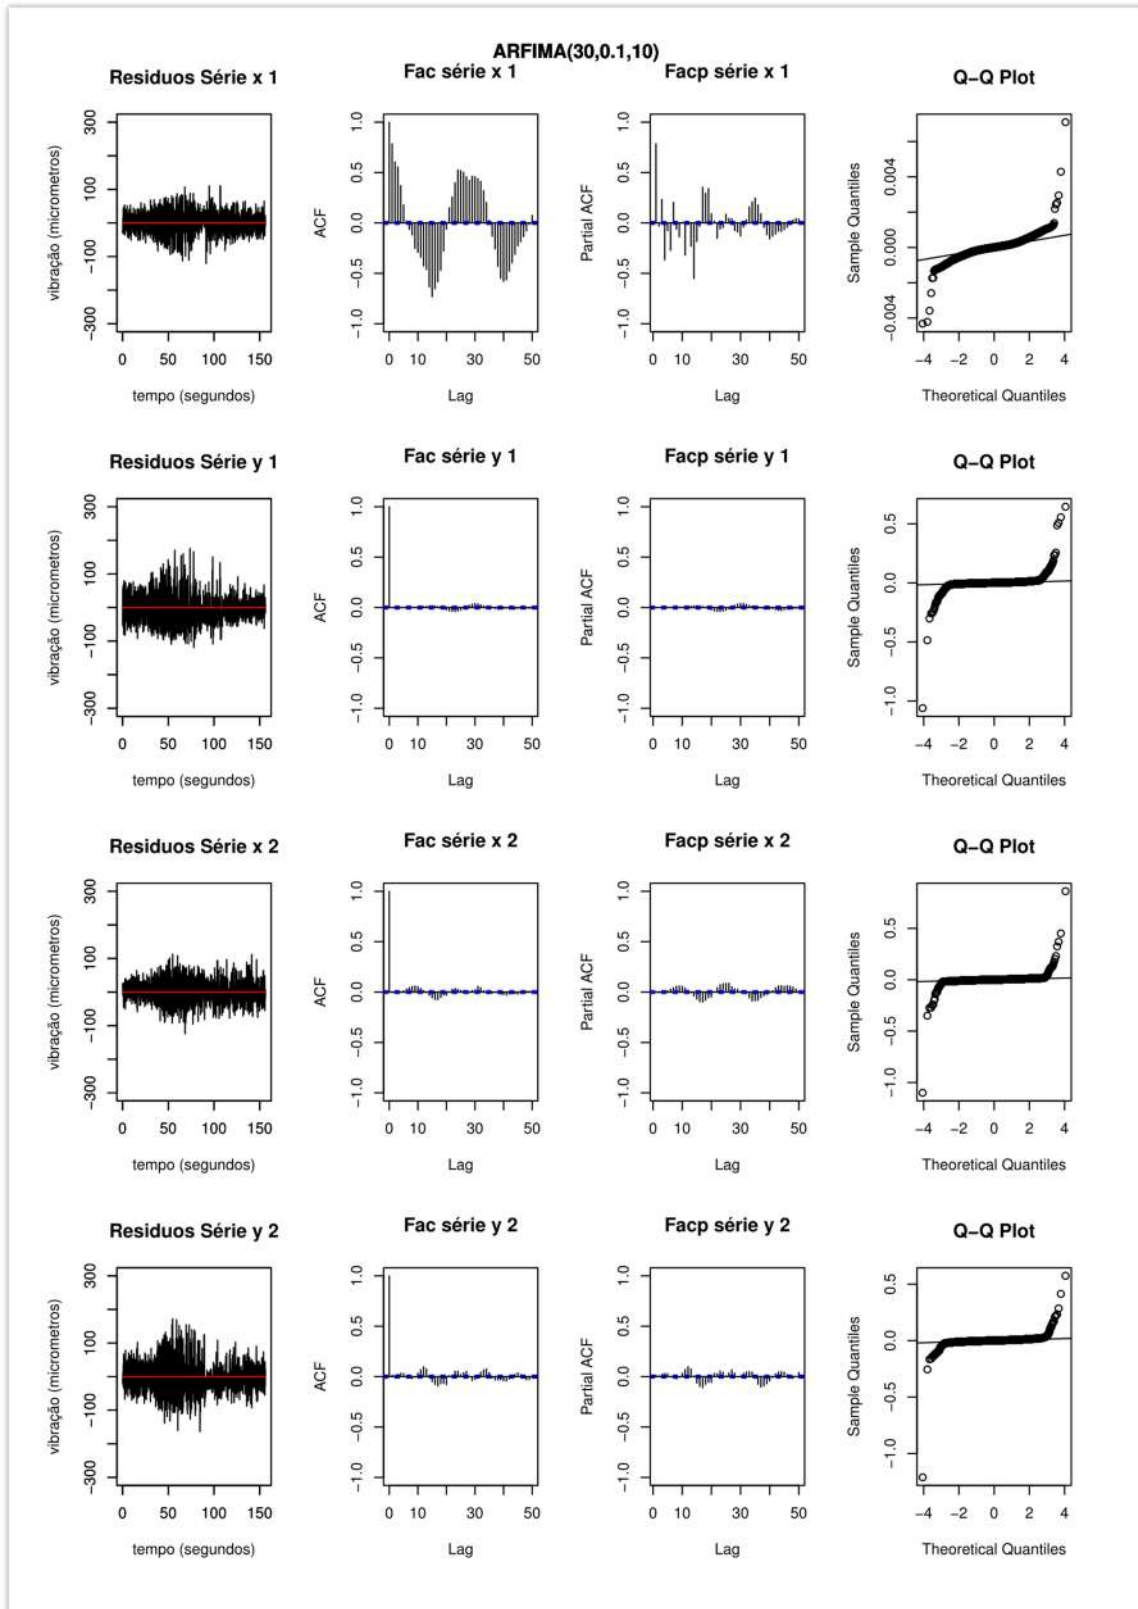


Anexo VIII - Figura 7: Resultado modelo AR(60) parte 7

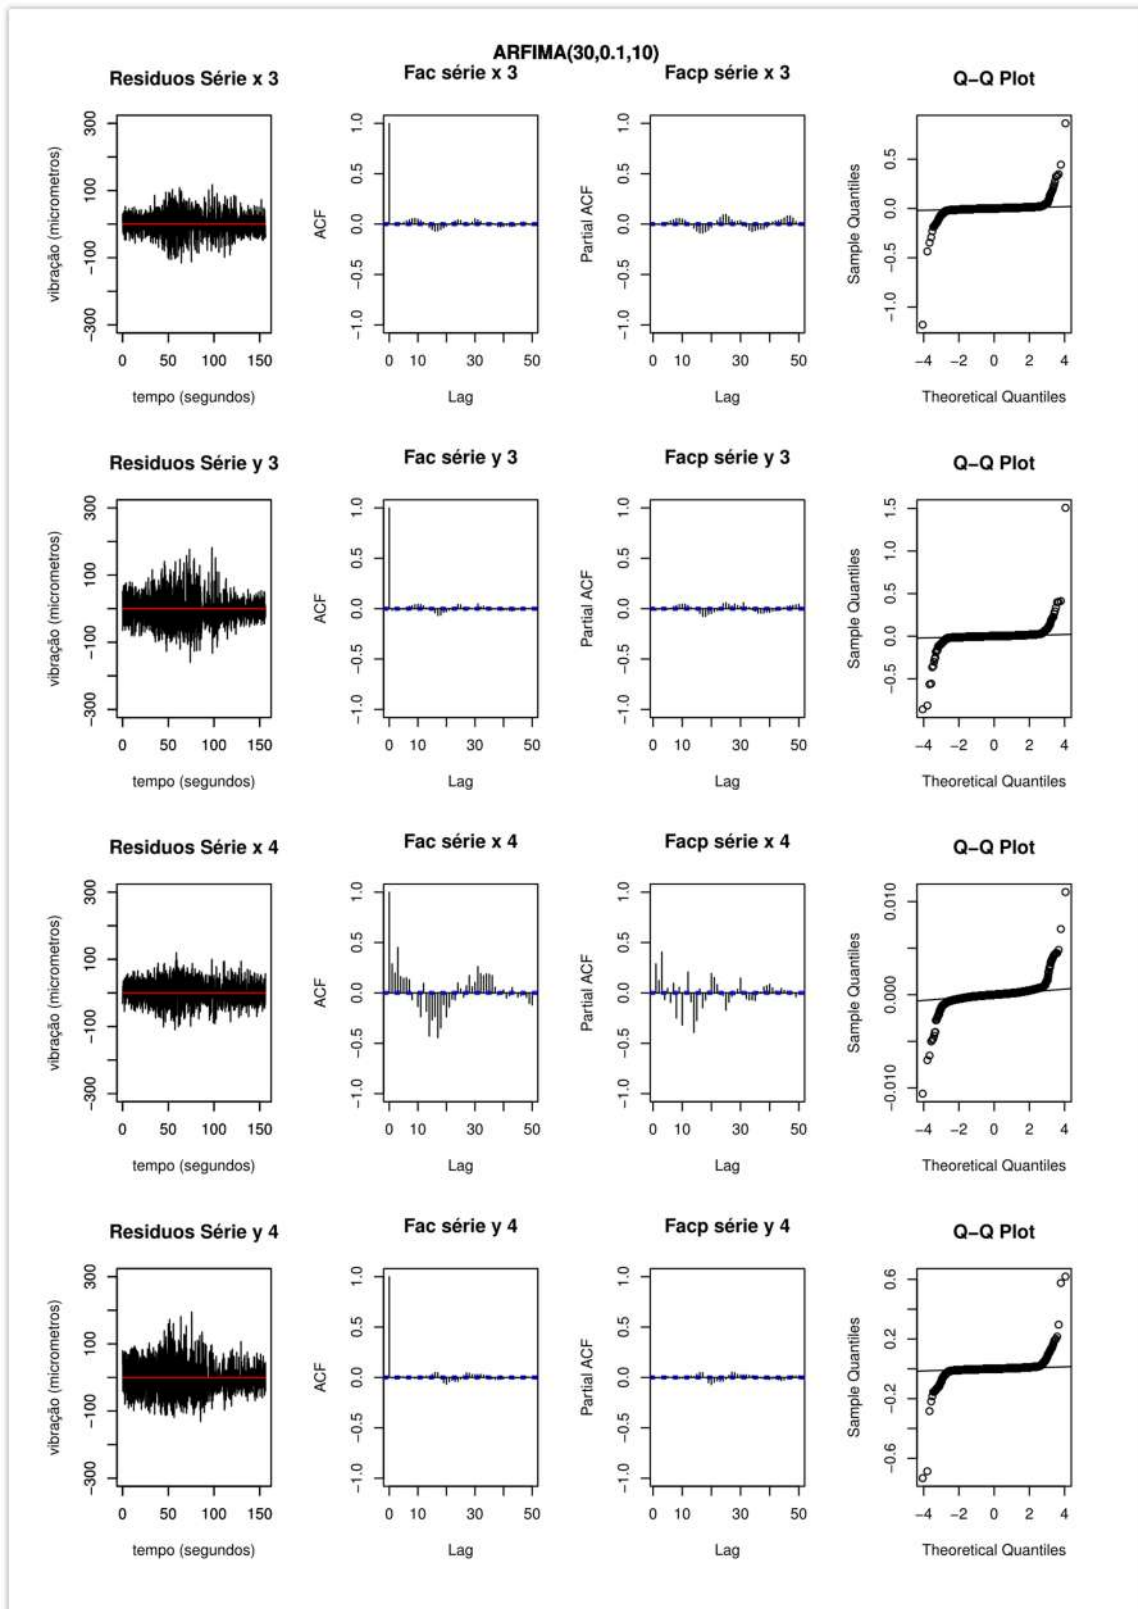


Anexo VIII - Figura 8: Resultado modelo AR(60) parte 8

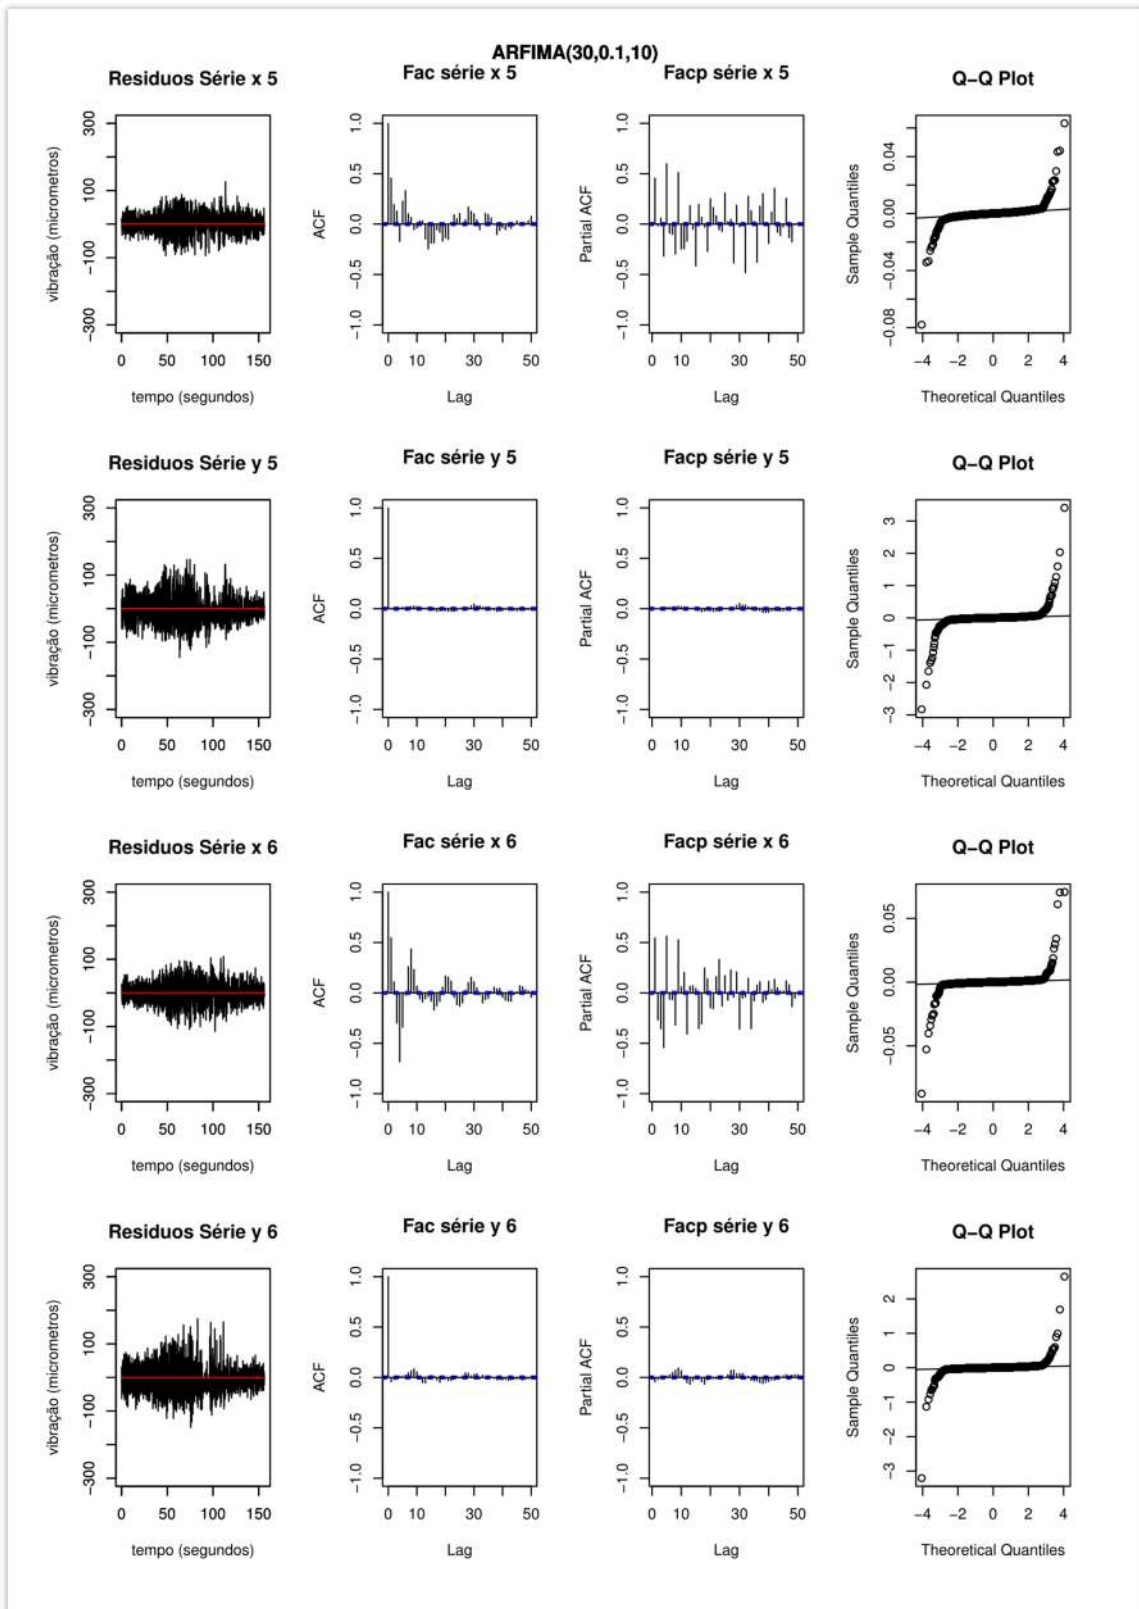
RESULTADOS DA APLICAÇÃO DO MODELO ARFIMA



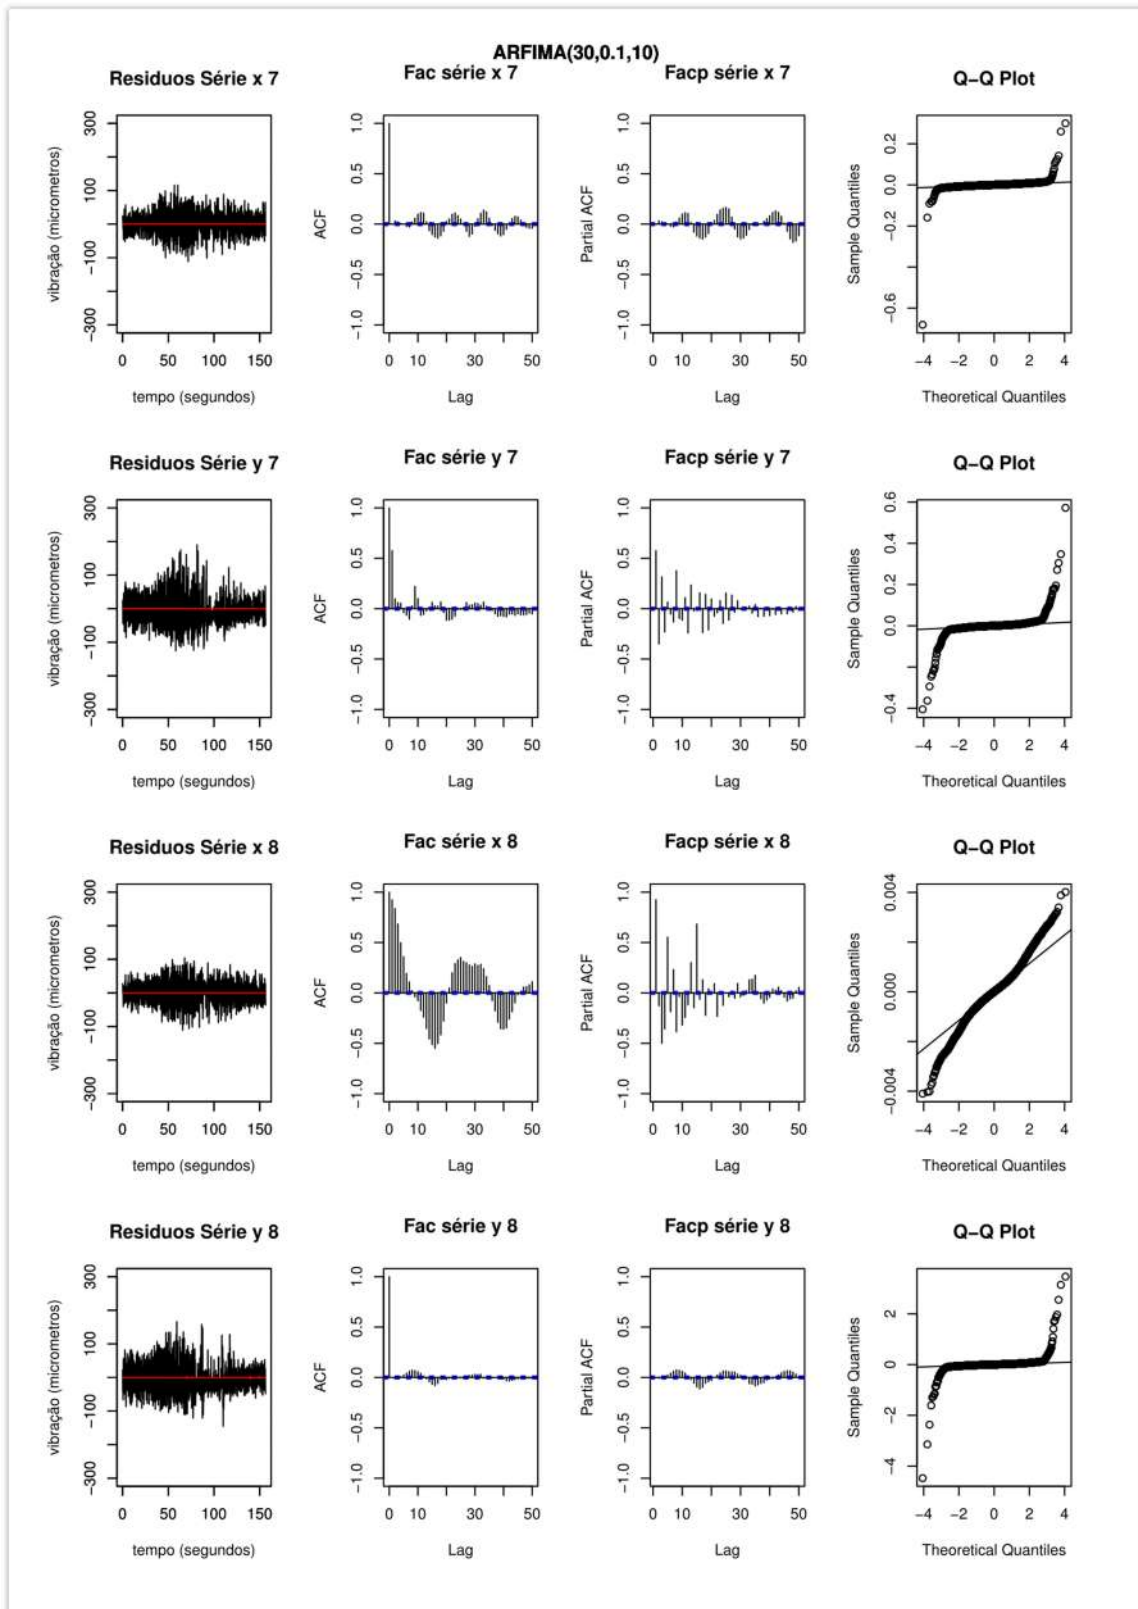
Anexo VIII - Figura 9: Resultado modelo ARFIMA(30, 0,1,10) parte 1



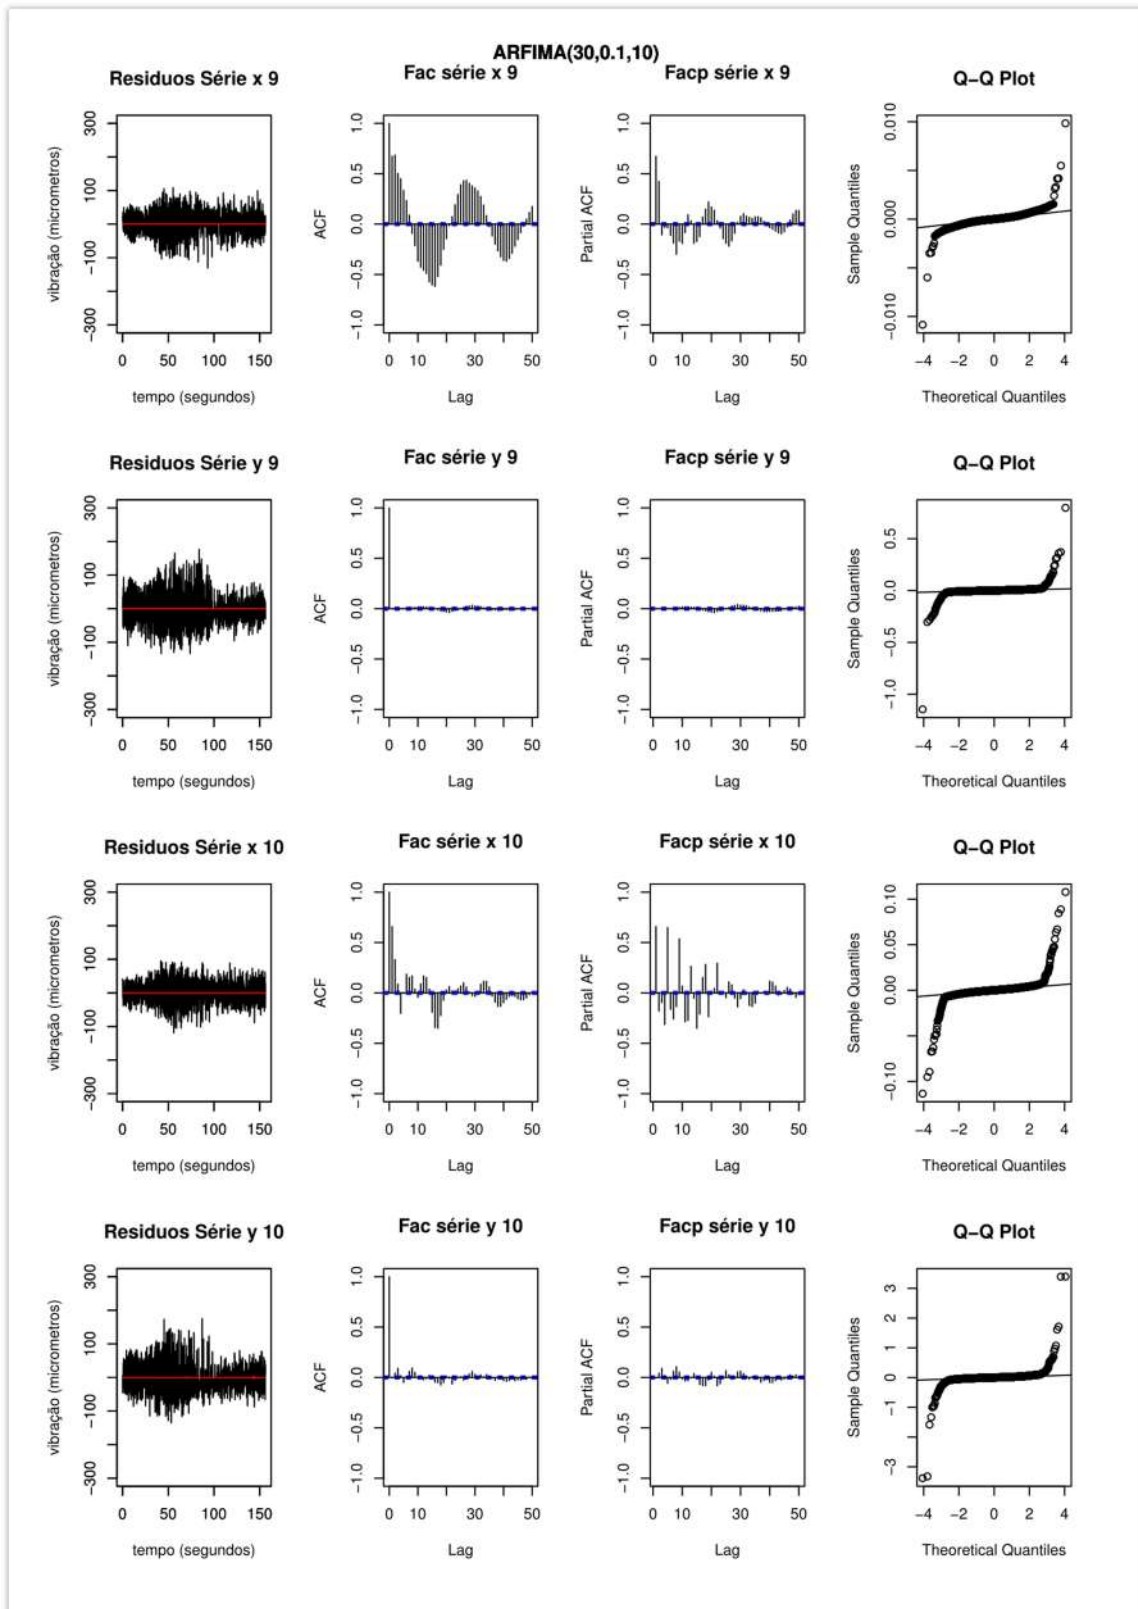
Anexo VIII - Figura 10: Resultado modelo ARFIMA(30, 0,1,10) parte 2



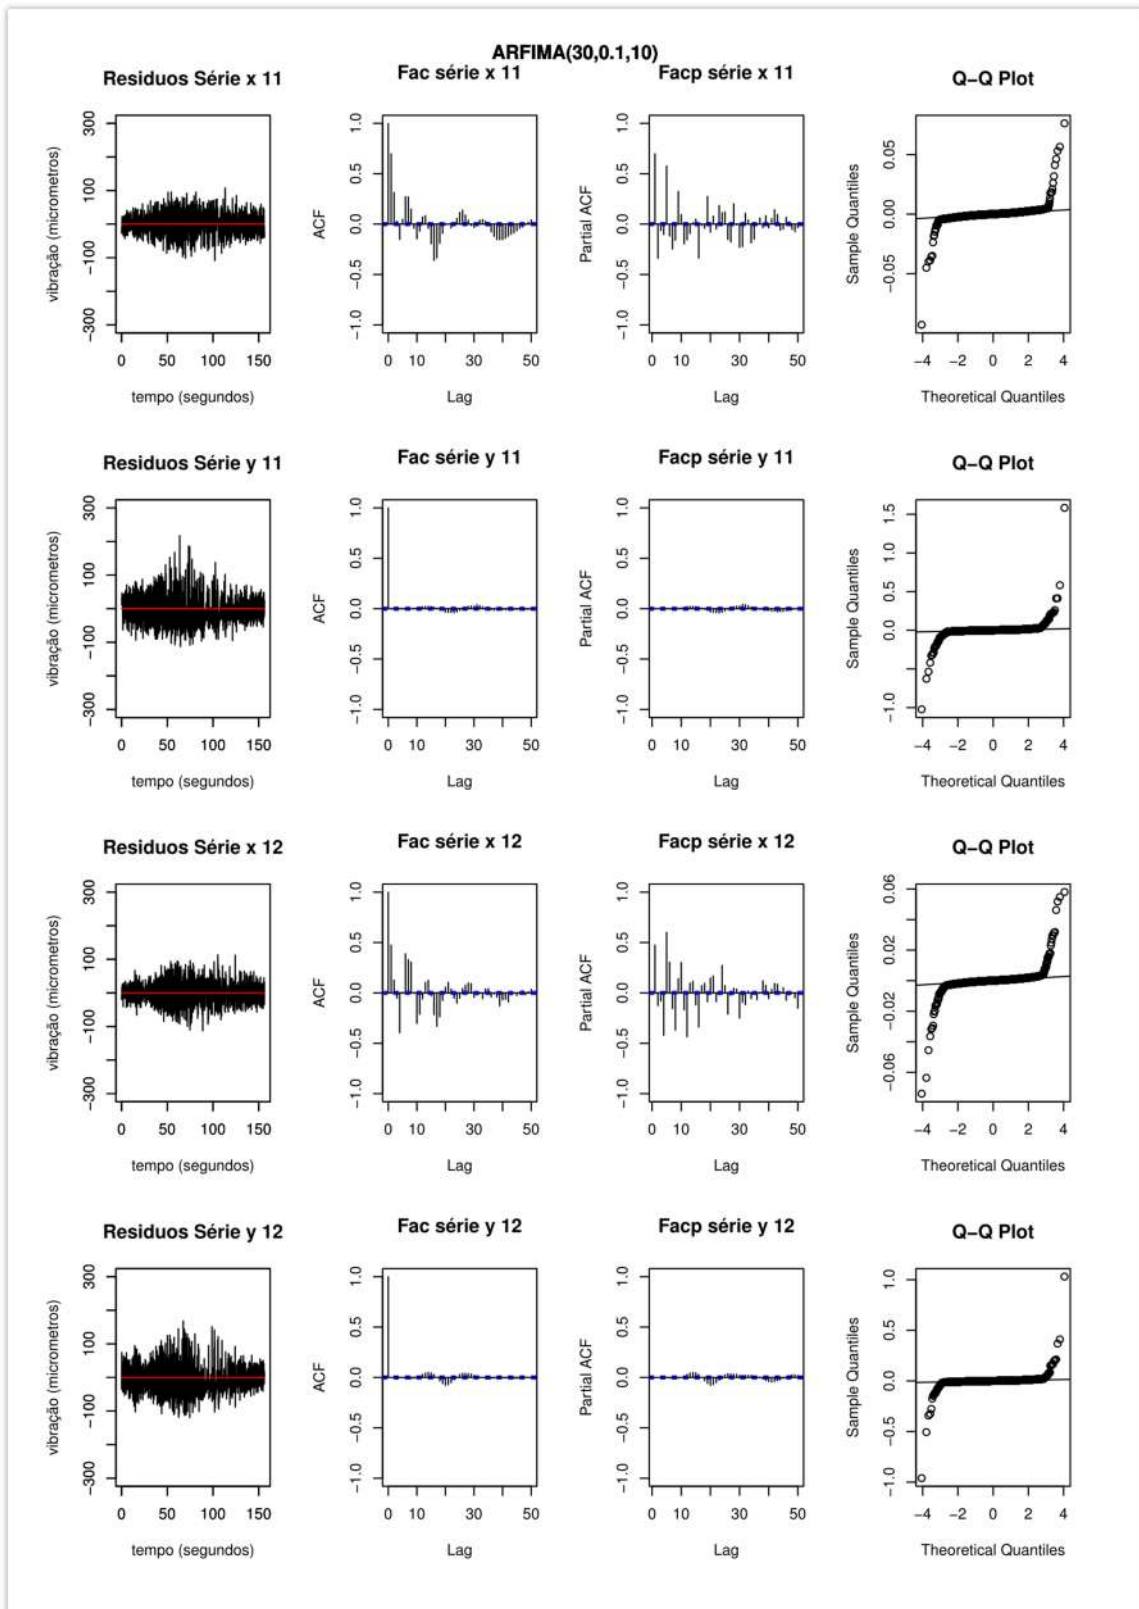
Anexo VIII - Figura 11: Resultado modelo ARFIMA(30, 0,1,10) parte 3



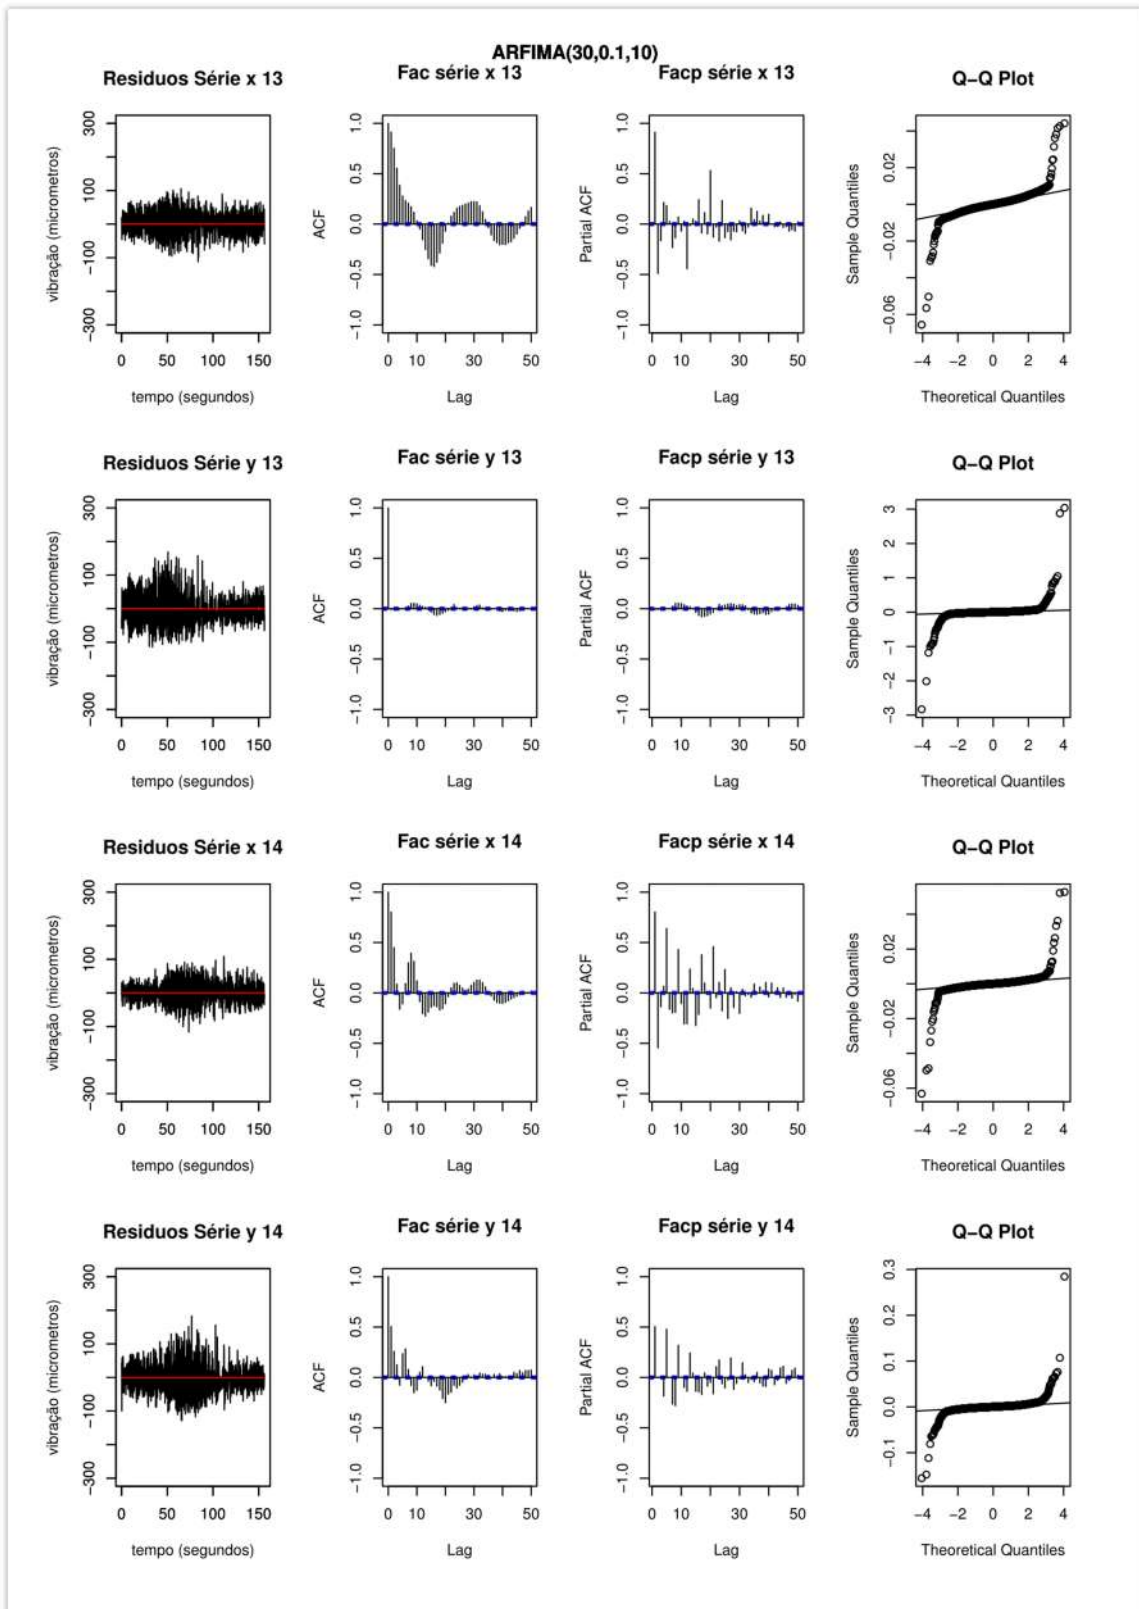
Anexo VIII - Figura 12: Resultado modelo ARFIMA(30, 0,1,10) parte 4



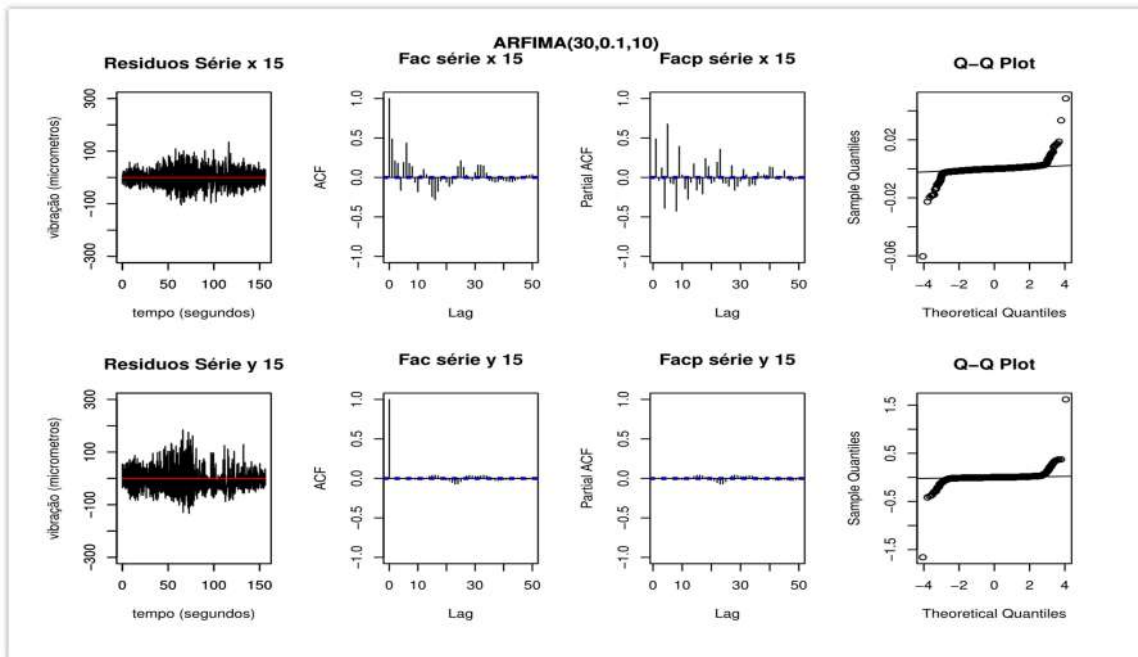
Anexo VIII - Figura 13: Resultado modelo ARFIMA(30, 0,1,10) parte 5



Anexo VIII - Figura 14: Resultado modelo ARFIMA(30, 0,1,10) parte 6



Anexo VIII - Figura 15: Resultado modelo ARFIMA(30, 0,1,10) parte 7



Anexo VIII - Figura 16: Resultado modelo ARFIMA(30, 0,1,10) parte 8