

HELOÍSA ALVES SILVA MARQUES



**MODELO ESTOCÁSTICO PARA DADOS GNSS E
SÉRIES TEMPORAIS DE COORDENADAS GNSS**

TESE

Presidente Prudente

2013

HELOÍSA ALVES SILVA MARQUES

**MODELO ESTOCÁSTICO PARA DADOS GNSS E
SÉRIES TEMPORAIS DE COORDENADAS GNSS**

Tese apresentada ao Programa de Pós-Graduação em Ciências Cartográficas da Faculdade de Ciências e Tecnologia da UNESP (Universidade Estadual Paulista “Júlio de Mesquita Filho”) - Campus de Presidente Prudente.

Candidata: Heloísa Alves Silva Marques

Orientador: Prof. Dr. João Francisco Galera Monico

Co-orientador: Prof. Dr. Manoel Ivanildo Silvestre Bezerra

Presidente Prudente

2013

FICHA CATALOGRÁFICA

M317m	<p>Marques, Heloísa Alves Silva.</p> <p>Modelo estocástico para dados GNSS e séries temporais de coordenadas GNSS / Heloísa Alves Silva Marques. - Presidente Prudente : [s.n.], 2013 205 f. : il.</p> <p>Orientador: João Francisco Galera Monico Tese (doutorado) - Universidade Estadual Paulista, Faculdade de Ciências e Tecnologia Inclui bibliografia</p> <p>1. Modelagem funcional e estocástica. 2. Análise de séries temporais GNSS. 3. Cintilação ionosférica. I. Monico, João Francisco Galera. II. Universidade Estadual Paulista. Faculdade de Ciências e Tecnologia. III. Título.</p>
-------	--

BANCA EXAMINADORA



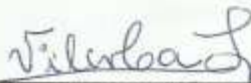
Prof. Dr. JOAO FRANCISCO GALERA MONICO
ORIENTADOR



Prof. Dr. SILVIO ROGÉRIO CORREIA DE FREITAS
(UFPR)



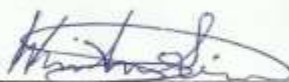
Profa. Dra. ENIUCE MENEZES DE SOUZA
(UEM)



Profa. Dra. VILMA MAYUMI TACHIBANA
(FCT/Unesp)



Profa. Dra. DANIELE BARROCA MARRA ALVES
(FCT/Unesp)



HELOÍSA ALVES DA SILVA

Presidente Prudente (SP), 13 de dezembro de 2013.

Resultado: APROVADA

DADOS CURRICULARES

Heloísa Alves Silva Marques

Nascimento	21.09.1980 – Anápolis – GO
Filiação	Dionisio Teodoro Silva Lúcia das Graças Alves Gontijo Silva
2002 – 2006	Graduação em Engenharia Cartográfica pela Faculdade de Ciências e Tecnologia da UNESP, Campus de Presidente Prudente
2007 – 2009	Mestrado em Ciências Cartográficas pela Faculdade de Ciências e Tecnologia da UNESP, Campus de Presidente Prudente
2009 – 2013	Doutorado em Ciências Cartográficas pela Faculdade de Ciências e Tecnologia da UNESP, Campus de Presidente Prudente

*Ao meu amado esposo Haroldo,
a meus adorados pais Lúcia e Dionisio e
a minha querida irmã Elisane.*

AGRADECIMENTOS

Agradeço primeiramente a Deus, por me dar saúde e força de vontade para lutar e realizar mais esse sonho em minha vida.

Agradeço também a meus queridos pais e minha irmã por todo o carinho e apoio em todos os momentos, apesar da distância.

A meu esposo que sempre esteve ao meu lado e me ajudou de forma direta e indiretamente na construção desse trabalho.

Aos professores Galera e Manoel que me orientaram nesse trabalho e contribuíram para minha formação.

Às minhas queridas amigas Chaenne, Miriam e Tayná que estiveram ao meu lado e sempre me ajudaram nos momentos que mais precisei.

Aos professores Silvio Rogério Correia de Freitas e Eniuce Menezes de Souza pelas considerações realizadas no exame de qualificação. Agradeço também às professoras Daniele Barrocá Marra Alves e Vilma Mayumi Tachibana pela participação na defesa da tese juntamente com os professores Silvio e Eniuce.

A todos os professores do Departamento de Cartografia, aos membros do GEGE (Grupo de Estudos em Geodésica Espacial), aos funcionários da FCT/UNESP e também aos amigos do PPGCC.

Às agências de fomento CAPES e FAPESP pelo incentivo a esse trabalho através do fornecimento de bolsa.

*“Suba o primeiro degrau com fé. Não é necessário que
você veja toda a escada. Apenas dê o primeiro passo.”*

Martin Luther King

*“Por vezes sentimos que aquilo que fazemos não é
senão uma gota de água no mar. Mas o mar seria
menor se lhe faltasse uma gota.”*

Madre Teresa de Calcutá

RESUMO

Os modelos funcionais relacionados com as observações GNSS são mais conhecidos do que os modelos estocásticos, visto que o desenvolvimento destes últimos é mais complexo. Normalmente, utilizam-se modelos estocásticos numa forma simplificada, como o modelo padrão, o qual assume que todas as medidas das observações GNSS têm a mesma variância e são estatisticamente independentes, espacialmente e temporalmente. Porém, tal suposição não reflete a realidade. Desta forma, atualmente os modelos estocásticos vêm sendo pesquisados com maior profundidade, por exemplo, considerando correlação temporal, cintilação ionosférica, dentre outros. O Brasil, por estar numa região geomagnética equatorial, sofre forte influência de cintilação ionosférica e outros efeitos relacionados à ionosfera. Tendo em vista a recente tecnologia de receptores GNSS que proporciona a possibilidade de se obter parâmetros de cintilação ionosférica, este efeito é factível de ser considerado na modelagem estocástica. Mesmo com a realização de uma modelagem estocástica adequada no processamento de dados GNSS, ainda podem restar erros não-modelados (ruídos), os quais devem contaminar as séries temporais das coordenadas obtidas com as observáveis GNSS, em especial aqueles relacionados com fatores que extrapolam a duração de uma dia, que é o período em geral utilizado na modelagem e processamento dos dados. Desta forma, tais ruídos podem ser caracterizados a partir das componentes de variância dos ruídos das séries temporais. Sendo assim, essa pesquisa teve como objetivo expandir as investigações com relação à modelagem estocástica das observações GNSS considerando principalmente os efeitos de cintilação ionosférica na região brasileira. Além disso, teve também como objetivo realizar investigações relacionadas às metodologias para a caracterização de ruídos contidos nas séries temporais de coordenadas GNSS e estabelecer uma metodologia para a construção de modelos funcionais destas séries. Os resultados relacionados à modelagem estocástica dos dados GNSS em períodos de fraca cintilação ionosférica, apontaram melhorias em relação à modelagem estocástica padrão da ordem de 35% e 26% ao considerar, respectivamente, as modelagens em função dos ângulos de elevação dos satélites, em função da cintilação. No caso da integração dos modelos de elevação e cintilação a melhoria foi da ordem de 29%. Já em períodos de moderada cintilação as melhorias atingiram até 50%. Com relação aos experimentos relacionados à caracterização de ruídos nas séries temporais, foram utilizados os métodos de variância de Allan e de estimativa de componentes de variância de ruídos pelo MMQ. O primeiro método forneceu uma visão ampla dos tipos de ruídos contidos nas séries temporais e o segundo permitiu a quantização das componentes de variância dos ruídos contidos nas séries. Através desta quantização foi possível a obtenção de modelos estocásticos que melhor se adequassem às séries temporais, os quais foram utilizados na construção dos modelos funcionais das séries. Sendo assim, os resultados mostraram que a adoção de uma modelagem estocástica adequada que considera os diferentes tipos de ruídos é mais realístico e confiável, o que contribui com uma melhor representação do modelo funcional das séries temporais de coordenadas GNSS.

Palavras-chaves: Posicionamento GNSS; Cintilação Ionosférica; Modelagem Estocástica; Processos Estocásticos; Séries Temporais.

ABSTRACT

Functional models related to GNSS observations are better known than the stochastic models because the development these last one is more complex. Generally, stochastic models are applied in a simplified form, as the standard model, which assumes that all GNSS measurements have the same variance and are statistically independent, spatially and temporally. However, this assumption does not reflect the reality. Therefore, currently the stochastic models have been investigated more deeply, for instance, considering time correlation, ionospheric scintillation, among others. Brazil is located in the equatorial geomagnetic region and because of this suffers strong influence of ionospheric scintillation and other effects related to the ionosphere. Considering the recent technology of the GNSS receivers, that provide ways to obtain parameters of ionospheric scintillation, this effect is feasible of being considered in the stochastic modeling. Even if an adequate stochastic modeling could be applied in the GNSS data processing, it still may remain non-modeled errors (noise) that can influence the coordinate's time series, especially those related to factors that go beyond the duration of one day, which is in general the interval (one day) used in the modeling and data processing. Thus, such noise can be characterized from the noise variance components of the time series. Therefore, this research aimed to expand the investigations regarding the stochastic modeling of GNSS observations mainly considering the ionospheric scintillation effects in the Brazilian region. Furthermore, it also aims to perform investigations related to methodologies for the noise characterization in the GNSS coordinates time series and establish a methodology for building functional models of these series. The results related to GNSS data stochastic modeling in periods of weak ionospheric scintillation, showed improvements in relation to standard stochastic modeling in the order of 35% considering the modeling in function of the satellites elevation angles and in the order of 26% considering the scintillation effects. When considering the satellites elevation angles as well as ionospheric effects the improvements reached approximately 29%. Already in periods of moderate scintillation the improvements achieved were approximately 50%. Concerning the experiments related to the noise characterization in time series, the Allan variance methods and estimation of variance components of the noise MMQ were used. The first method gave a broad overview of the types of noise contained in the time series and the second allowed the quantization of the variance components of the noise in the time series. Through this quantization been possible to obtain stochastic models that best fitted the time series and these were used in the construction of the series functional models. Thus, the results showed that the adoption of an appropriate stochastic modeling that considers the different types of noise is more realistic and reliable, which contributes to a better representation of the functional model of the time series of GNSS coordinates.

Keywords: GNSS Positioning; Ionospheric Scintillation; Stochastic Modelling; Random Process; Time Series.

LISTA DE FIGURAS

Figura 3.1: Efeito de multicaminho no receptor GNSS	51
Figura 3.2: Regiões da ionosfera de acordo com a altitude e a concentração de elétrons ...	52
Figura 3.3: Gráfico de raios X que indicam a existência de explosões solares	53
Figura 3.4: Regiões geográficas da ionosfera	55
Figura 3.5: Representação de bolhas ionosféricas	56
Figura 3.6: Exemplo da ocorrência de cintilação ionosférica.....	57
Figura 3.7: Regiões de ocorrência de cintilações (máxima (a) e mínima (b) atividade solar)	57
Figura 3.8: Localização das estações do projeto CIGALA/CALIBRA	60
Figura 4.1: Conjunto de realizações amostrais de um processo aleatório.....	68
Figura 4.2: Saída de voltagem de um sinal aleatório (sinal com ruído)	71
Figura 4.3: Representação dos tipos de ruídos no domínio do tempo.....	72
Figura 4.4: Esquema do método de cálculo da variância de Allan	73
Figura 4.5: Variância de Allan para os cinco tipos de ruídos mais comuns em osciladores .	74
Figura 4.6: Variância modificada de Allan para os cinco tipos de ruídos mais comuns em osciladores.....	75
Figura 4.7: Representação log-log do desvio-padrão de Allan	76
Figura 5.1: Fluxograma da metodologia envolvida no processamento de dados GNSS no software RT_PPP	93
Figura 5.2: Localização das estações PALM e PRU1 utilizadas nos processamentos de dados GNSS	94
Figura 5.3: Localização das estações utilizadas na análise de séries temporais de coordenadas GNSS	95
Figura 5.4: Fluxograma da metodologia envolvida na análise de séries temporais	96
Figura 6.1: Índices de amplitude de cintilação (S4) da estação PRU1 para o primeiro semestre de 2012	99
Figura 6.2: Índices de amplitude de cintilação (S4) da estação PALM para 08/03/2012	100
Figura 6.3: Índices de amplitude de cintilação (S4) da estação PRU1 para 08/03/2012.....	100
Figura 6.4: Índices de amplitude de cintilação (S4) da estação PALM para 20/10/2012	101
Figura 6.5: Índices de amplitude de cintilação (S4) da estação PRU1 para 20/10/2012.....	101
Figura 6.6: Índices de variância de cintilação (PHI60) da estação PALM para 08/03/2012	102
Figura 6.7: Índices de variância de cintilação (PHI60) da estação PRU1 para 08/03/2012	102

Figura 6.8: Índices de variância de cintilação (PHI60) da estação PALM para 20/10/2012	103
Figura 6.9: Índices de variância de cintilação (PHI60) da estação PRU1 para 20/10/2012	103
Figura 6.10: Índices geomagnéticos para o período de 7 a 10 de março de 2012	104
Figura 6.11: Fluxo de raios X para o período de 7 a 10 de março de 2012	104
Figura 6.12: Índices geomagnéticos para o período de 19 a 22 de outubro de 2012	105
Figura 6.13: Fluxo de raios X para o período de 19 a 22 de outubro de 2012	105
Figura 6.14: Erro 3D da estação PALM para o dia 08/03/2012	107
Figura 6.15: Erro 3D da estação PALM para o dia 20/10/2012	107
Figura 6.16: Erro 3D da estação PRU1 para o dia 08/03/2012	108
Figura 6.17: Erro 3D da estação PRU1 para o dia 20/10/2012	108
Figura 6.18: EMQ 3D da estação PALM para os dias 08/03/2012 e 20/10/2012	109
Figura 6.19: EMQ 3D da estação PRU1 para os dias 08/03/2012 e 20/10/2012	109
Figura 6.20: Perdas de ciclos para a estação PRU1 (20/10/2012)	111
Figura 6.21: Satélites detectados com erros grosseiros e valores de LOM para a estação PRU1 (20/10/2012) -Mod_Padrão	112
Figura 6.22: Satélites detectados com erros grosseiros e valores de LOM para a estação PRU1 (20/10/2012) -Mod_Elev	113
Figura 6.23: Índices de amplitude de cintilação (S4) da estação PALM (19 a 20 de out. de 2012)	114
Figura 6.24: Índices de amplitude de cintilação (S4) da estação PRU1 (19 a 20 de out. de 2012)	115
Figura 6.25: Erro 3D da estação PALM (19 a 20 de outubro de 2012)	115
Figura 6.26: Erro 3D da estação PRU1 (19 a 20 de outubro de 2012)	116
Figura 6.27: Perdas de ciclos para a estação PRU1 (19 a 20 de outubro de 2012)	116
Figura 6.28: EMQ 3D da estação PALM (19 a 20 de out. de 2012)	117
Figura 6.29: EMQ 3D da estação PRU1 (19 a 20 de out. de 2012)	117
Figura 6.30: Análise de tendência da série temporal da componente E (estação BRAZ do SIRGAS-CON)	119
Figura 6.31: Análise de tendência da série temporal da componente N (estação BRAZ do SIRGAS-CON)	120
Figura 6.32: Análise de tendência da série temporal da componente U (estação BRAZ do SIRGAS-CON)	120

Figura 6.33: Resíduos da série temporal da componente E (estação BRAZ do SIRGAS-CON).....	121
Figura 6.34: Resíduos da série temporal da componente N (estação BRAZ do SIRGAS-CON).....	121
Figura 6.35: Resíduos da série temporal da componente U (estação BRAZ do SIRGAS-CON).....	122
Figura 6.36: Análise de tendência da série temporal da componente E (estação BRAZ do JPL)	122
Figura 6.37: Análise de tendência da série temporal da componente N (estação BRAZ do JPL)	123
Figura 6.38: Análise de tendência da série temporal da componente U (estação BRAZ do JPL)	123
Figura 6.39: Resíduos da série temporal da componente E (estação BRAZ do JPL).....	124
Figura 6.40: Resíduos da série temporal da componente N (estação BRAZ do JPL).....	124
Figura 6.41: Resíduos da série temporal da componente U (estação BRAZ do JPL).....	125
Figura 6.42: Série temporal versus série temporal ajustada da estação BRAZ (componente E).....	126
Figura 6.43: Série temporal versus série temporal ajustada da estação BRAZ (componente N).....	126
Figura 6.44: Série temporal versus série temporal ajustada da estação BRAZ (componente V).....	127
Figura 6.45: Gráficos de PSD das séries temporais (E, N e U) da estação BRAZ (SIRGAS-CON).....	128
Figura 6.46: Gráficos de PSD das séries temporais (E, N e U) da estação MAPA (SIRGAS-CON).....	129
Figura 6.47: Gráficos de PSD das séries temporais (E, N e U) da estação POAL (SIRGAS-CON).....	130
Figura 6.48: Gráficos de PSD das séries temporais (E, N e U) da estação PPTE (SIRGAS-CON).....	131
Figura 6.49: Gráficos de PSD das séries temporais (E, N e U) da estação RECF (SIRGAS-CON).....	132
Figura 6.50: Gráfico log-log do ADEV e MDEV para as séries temporais da estação BRAZ (SIRGAS-CON).....	134

Figura 6.51: Gráfico log-log do ADEV e MDEV para as séries temporais da estação MAPA (SIRGAS-CON).....	135
Figura 6.52: Gráfico log-log do ADEV e MDEV para as séries temporais da estação POAL (SIRGAS-CON).....	136
Figura 6.53: Gráfico log-log do ADEV e MDEV para as séries temporais da estação PPTE (SIRGAS-CON).....	137
Figura 6.54: Gráfico log-log do ADEV e MDEV para as séries temporais da estação RECF (SIRGAS-CON).....	138
Figura 6.55: Séries temporais (E) e modelos ajustados (Mod_func_1 e Mod_func_3) da estação BRAZ (JPL)	146
Figura 6.56: Séries temporais (N) e modelos ajustados (Mod_func_1 e Mod_func_3) da estação BRAZ (JPL)	147
Figura 6.57: Séries temporais (U) e modelos ajustados (Mod_func_1 e Mod_func_3) da estação BRAZ (JPL)	148
Figura 6.58: Valores de R^2 nas estimativas dos modelos funcionais das séries temporais (E, N e U)	150
Figura 6.59: Séries temporais (E, N e U) e modelos ajustados (Mod_func_3) da estação BRFT (JPL).....	152
Figura 6.60: Séries temporais (E, N e U) e modelos ajustados (Mod_func_3) da estação CHPI (JPL).....	153
Figura 6.61: Séries temporais (E, N e U) e modelos ajustados (Mod_func_3) da estação SAVO (JPL)	154
Figura 6.62: Séries temporais (E, N e U) e modelos ajustados (Mod_func_3) da estação BRAZ (SIRGAS-CON).....	155
Figura 6.63: Séries temporais (E, N e U) e modelos ajustados (Mod_func_3) da estação MAPA (SIRGAS-CON).....	156
Figura 6.64: Séries temporais (E, N e U) e modelos ajustados (Mod_func_3) da estação POAL (SIRGAS-CON).....	157
Figura 6.65: Séries temporais (E, N e U) e modelos ajustados (Mod_func_3) da estação PPTE (SIRGAS-CON).....	158
Figura 6.66: Séries temporais (E, N e U) e modelos ajustados (Mod_func_3) da estação RECF (SIRGAS-CON)	159

Figura 6.67: Valores de R^2 ajustado nas estimativas dos modelos funcionais das séries temporais com e sem a inclusão do termo quadrático.....	161
Figura 6.68: Séries temporais (U) da estação BRAZ (SIRGAS-CON) e modelos ajustados (Mod_func_3 e Mod_func_3_quad).....	162
Figura 6.69: Séries temporais (U) da estação MAPA (SIRGAS-CON) e modelos ajustados (Mod_func_3 e Mod_func_3_quad).....	163
Figura 6.70: Séries temporais (U) da estação POAL (SIRGAS-CON) e modelos ajustados (Mod_func_3 e Mod_func_3_quad).....	164
Figura 6.71: Séries temporais (U) da estação PPTE (SIRGAS-CON) e modelos ajustados (Mod_func_3 e Mod_func_3_quad).....	165
Figura 6.72: Séries temporais (U) da estação BRAZ (JPL) e modelos ajustados (Mod_func_3 e Mod_func_3_quad)	166
Figura 6.73: Autocorrelação das séries temporais ajustadas (Mod_func_3) da estação BRAZ (SIRGAS-CON).....	168
Figura 6.74: Autocorrelação das séries temporais ajustadas (Mod_func_3) da estação MAPA (SIRGAS-CON).....	169
Figura 6.75: Autocorrelação das séries temporais (E, N e U) ajustadas (Mod_func_3) da estação POAL (SIRGAS-CON).....	170
Figura 6.76: Autocorrelação das séries temporais (E, N e U) ajustadas (Mod_func_3) da estação PPTE (SIRGAS-CON)	171
Figura 6.77: Autocorrelação das séries temporais (E, N e U) ajustadas (Mod_func_3) da estação RECF (SIRGAS-CON).....	172
Figura 6.78: Autocorrelação das séries temporais (E, N e U) ajustadas (Mod_func_3) da estação BRAZ (JPL)	173
Figura 6.79: Autocorrelação das séries temporais (E, N e U) ajustadas (Mod_func_3) da estação BRFT (JPL).....	174
Figura 6.80: Autocorrelação das séries temporais (E, N e U) ajustadas (Mod_func_3) da estação CHPI (JPL)	175
Figura 6.81: Autocorrelação das séries temporais (E, N e U) ajustadas (Mod_func_3) da estação SAVO (JPL).....	176
Figura 6.82: Valores de R^2 ajustado das séries temporais ajustadas utilizando Mod_func_3 e com diferentes modelos estocásticos.....	179
Figura 6.83: Valores de R^2 ajustado das séries temporais da componente U ajustadas utilizando Mod_func_3_quad e com diferentes modelos estocásticos.....	180

Figura 6.84: Desvio-padrão dos resíduos das séries temporais ajustadas utilizando o modelo funcional “Mod_func_3” e os três modelos estocásticos.....	181
Figura 6.85: EPM das séries temporais ajustadas utilizando o Mod_func_3 e os modelos estocásticos “Modelo padrão + ruído branco” e “Modelo padrão + ruído branco + ruído colorido”	183
Figura 6.86: EPM das séries temporais ajustadas utilizando o Mod_func_3_quad e os modelos estocásticos “Modelo padrão + ruído branco” e “Modelo padrão + ruído branco + ruído colorido”	184

LISTA DE TABELAS

Tabela 3.1: Fontes e efeitos dos erros nas observações GNSS	50
Tabela 3.2: Relação entre os índices Kp e ap.....	54
Tabela 3.3: Classificação da atividade geomagnética de acordo com os índices Kp e Ap ...	54
Tabela 3.4: Classificação dos efeitos cintilação ionosférica	58
Tabela 4.1: Exemplos de sinais determinísticos e aleatórios	67
Tabela 4.2: Relação entre o gráfico de potência espectral e o gráfico de variância de Allan 76	
Tabela 6.1: Configurações dos processamentos no software RT_PPP	106
Tabela 6.2: Modelagens estocásticas adotadas nos processamentos realizados no software RT_PPP.....	106
Tabela 6.3: Melhorias (%) no EMQ 3D em relação ao "Mod_Padrão" - estação PALM	110
Tabela 6.4: Melhorias (%) no EMQ 3D em relação ao "Mod_Padrão" - estação PRU1.....	110
Tabela 6.4: Melhorias (%) no EMQ 3D em relação ao "Mod_Padrão" - estação PALM (19 a 20 de out. de 2012).....	118
Tabela 6.5: Caracterização de ruídos a partir do ângulo de inclinação da PSD (Estações SIRGAS-CON).....	133
Tabela 6.6: Caracterização de ruídos a partir do ângulo de inclinação do gráfico de log-log do desvio-padrão de Allan (Estações SIRGAS-CON)	139
Tabela 6.7: Estimativa de componentes de variância e teste w das séries temporais do SIRGAS-CON	140
Tabela 6.8: Estimativa de componentes de variância e teste w das séries temporais do JPL	140
Tabela 6.9: Resumo de estatísticas da estimativa do modelo funcional (10 harmônicos esféricos) da componente E da estação BRAZ (JPL).....	142
Tabela 6.10: Resumo de estatísticas da estimativa do modelo funcional (10 harmônicos esféricos) da componente N da estação BRAZ (JPL)	143
Tabela 6.11: Resumo de estatísticas da estimativa do modelo funcional (10 harmônicos esféricos) da componente U da estação BRAZ (JPL)	143
Tabela 6.12: Modelos funcionais estimados da estação BRAZ (JPL)	144
Tabela 6.13: Modelagens funcionais das séries temporais de coordenadas GNSS.....	145
Tabela 6.14: Modelos estocásticos das séries temporais de coordenadas GNSS	177
Tabela 6.15: Modelos funcionais estimados para as séries temporais do SIRGAS-CON...	186
Tabela 6.16: Modelos funcionais estimados para as séries temporais do JPL.....	187

LISTA DE SIGLAS E ABREVIATURAS

ADEV	–	Desvio-padrão de Allan
ANOVA	–	<i>Analysis of Variance</i>
AVAR	–	<i>Allan variance</i>
BINQUE	–	<i>Best Invariant Quadratic Unbiased Estimation</i>
CALIBRA	–	<i>Countering GNSS high Accuracy applications Limitations due to Ionospheric disturbances in BRAzil</i>
CIGALA	–	<i>Concept for Ionospheric Scintillation Mitigation for Professional GNSS in Latin America</i>
CDMA	–	<i>Code Division Multiple Access</i>
DCBD	–	<i>Delay Code Bias</i>
DD	–	Dupla Diferença
DIA	–	Detecção, Identificação e Adaptação
DLL	–	<i>Delay Lock Loop</i>
FCT	–	Faculdade de Ciências e Tecnologia
FDMA	–	<i>Frequency Division Multiple Access</i>
FFT	–	<i>Fast Fourier Transform</i>
GISTM	–	<i>GPS Ionospheric and TEC Monitor</i>
GLONASS	–	<i>GLOBAL'naya NAVigatsionnaya Sputnikkovaya Sistema</i>
GNSS	–	<i>Global Navigation Satellite System</i>
GOM	–	<i>Global Overall Model</i>
GPS	–	<i>Global Positioning System</i>
IGS	–	<i>International GNSS Service</i>
INGV	–	<i>Istituto Nazionale di Geofisica e Vulcanologia</i>
INPE	–	Instituto Nacional de Pesquisas Espaciais
ISACCO	–	<i>Ionospheric Scintillation Arctic Campaign Coordinated Observations</i>
ISMR	–	<i>Ionospheric Scintillation Monitor Receiver</i>
JPL	–	<i>Jet Propulsion Laboratory</i>
LISN	–	<i>Low-latitude Ionosphere Sensor Network</i>
LOM	–	<i>Local Overall Model</i>
MDEV	–	Desvio-padrão de Allan modificado
MINQUE	–	<i>Minimum Norm Quadratic Unbiased Estimation</i>
MMQ	–	Método dos Mínimos Quadrados
MVC	–	Matriz Variância-Covariância
NGS	–	<i>National Geodetic Survey</i>

PCV	–	<i>Phase Center Variation</i>
PLL	–	<i>Phase Lock Loop</i>
PPGCC	–	Programa de Pós-Graduação em Ciências Cartográficas
PPP	–	Posicionamento por Ponto Preciso
PSD	–	<i>Power Spectral Density</i>
RBMC	–	Rede Brasileira de Monitoramento Contínuo
Rede GNSS SP	–	Rede GNSS do Estado de São Paulo
RINEX	–	<i>Receiver INdependent EXchange format</i>
SBAS	–	<i>Space Based Augmentation. Systems</i>
SD	–	Simple Diferença
SGL	–	Sistema Geodésico Local
SINEX	–	<i>Solution (Software/technique) INdependent EXchange format</i>
SIRGAS	–	Sistema de Referência Geocêntrico para as Américas
SIRGAS-CON	–	SIRGAS de funcionamento CONTínuo
SOPAC	–	<i>Script Orbit and Permanent Array Center</i>
TD	–	Tripla Diferença
TEC	–	<i>Total Electron Content</i>
UNESP	–	Universidade Estadual Paulista “Júlio de Mesquita Filho”
WASS	–	<i>Wide Area Augmentation System</i>

SUMÁRIO

1	INTRODUÇÃO	29
1.1	Contextualização da pesquisa.....	31
1.2	Objetivos	32
1.3	Justificativa.....	33
1.4	Conteúdo da tese.....	34
2	INTRODUÇÃO AO AJUSTAMENTO DAS OBSERVAÇÕES	35
2.1	Ajustamento em lote pelo MMQ.....	35
2.1.1	<i>Controle de qualidade do ajustamento em lote pelo MMQ</i>	36
2.2	Ajustamento recursivo pelo MMQ.....	38
2.2.1	<i>Controle de qualidade do ajustamento recursivo pelo MMQ</i>	39
2.2.1.1	<i>Procedimento DIA local</i>	39
2.2.1.2	<i>Procedimento DIA global</i>	41
2.3	Estimação por Filtro de Kalman	44
3	MODELO MATEMÁTICO DAS OBSERVAÇÕES GNSS	46
3.1	Modelo funcional das observações GNSS e erros envolvidos	46
3.1.1	<i>Erros relacionados às observações GNSS</i>	49
3.1.2	<i>Ionosfera e cintilação ionosférica</i>	51
3.2	Modelo estocástico das observações GNSS.....	60
3.2.1	<i>Modelo estocástico padrão</i>	61
3.2.2	<i>Modelo estocástico em função da variação dos ângulos de elevação dos satélites</i>	62
3.2.3	<i>Modelo estocástico em função da cintilação ionosférica</i>	63
3.2.4	<i>Modelo estocástico em função dos ângulos de elevação dos satélites e da cintilação ionosférica</i>	66
4	PROCESSOS ESTOCÁSTICOS E INTRODUÇÃO A ANÁLISE DE SÉRIES TEMPORAIS	67
4.1	Processos estocásticos	67
4.1.1	<i>Caracterização de ruídos a partir da variância de Allan</i>	72
4.2	Introdução à análise de séries temporais	77

4.2.1	<i>Modelos funcional e estocástico de séries temporais de coordenadas GNSS</i>	78
4.2.2	<i>Estimativa das frequências pelo MMQ e identificação da matriz design adequada para o modelo funcional</i>	80
4.2.3	<i>Estimativa das componentes de variância</i>	83
4.2.3.1	<i>Estimativa de componentes de variância a partir do MMQ</i>	83
4.2.4	<i>Identificação do modelo estocástico adequado</i>	86
4.2.5	<i>Introdução à análise multivariada de séries temporais</i>	87
4.2.5.1	<i>Introdução à estimativa de componentes de variância: caso multivariado</i>	88
5	METODOLOGIA	91
6	RESULTADOS E ANÁLISES	98
6.1	Modelagem estocástica para mitigação dos efeitos de cintilação ionosférica no processamento de dados GNSS na região brasileira	98
6.1.1	<i>Análise dos experimentos</i>	118
6.2	Análise das séries temporais de coordenadas GNSS	119
6.2.1	<i>Análise de séries temporais a partir da variância Allan</i>	128
6.2.2	<i>Estimativa das componentes de variância a partir do MMQ e identificação do modelo estocástico das séries temporais</i>	139
6.2.3	<i>Estimativa do modelo funcional das séries temporais de coordenadas GNSS</i>	141
6.2.3.1	<i>Modificação do modelo funcional</i>	142
6.2.3.2	<i>Modificação do modelo estocástico</i>	177
6.2.4	<i>Análise dos experimentos</i>	185
7	CONCLUSÕES E CONSIDERAÇÕES FINAIS	188
8	RECOMENDAÇÕES E TRABALHOS FUTUROS	192
	REFERÊNCIAS	193
	APÊNDICE A Algoritmo para remoção de outliers em séries temporais a partir do intervalo de predição	199
	APÊNDICE B Gráficos das series temporais do jpl com limite de predição (remoção de outliers)	203

1 INTRODUÇÃO

O *Global Navigation Satellite System* (GNSS) é uma das tecnologias mais utilizadas atualmente para posicionamento geodésico. Ele é constituído pelo *Global Positioning System* (GPS - desenvolvido pelos EUA), *Global'naya Navigatsionnaya Sputnikkovaya Sistema* (GLONASS - desenvolvido pela antiga URSS e mantida atualmente pela Rússia), Galileo (em desenvolvimento pela Comunidade Europeia) e Compass (em desenvolvimento pela China), e sistemas de aumento/complemento *Space Based Augmentation Systems* (SBAS), além de outras definições, tais como integridade e acurácia.

Para que o ajustamento das observações GNSS proporcione resultados realísticos e confiáveis, é necessária uma boa definição tanto do modelo funcional quanto do modelo estocástico. Os modelos funcionais relacionados às observações GNSS estão bem estabelecidos na literatura especializada, tais como em: Teunissen e Kleusberger (1998), Seeber (2003), Leick (2004), Monico (2008), entre outros. O mesmo não acontece no que diz respeito aos modelos estocásticos, pois, na maioria das vezes estes são desenvolvidos de maneira simplificada. Os modelos estocásticos vêm sendo pesquisados com mais profundidade há algum tempo, podendo-se citar trabalhos como os de Wang (1999), Van Dierendonk (2001), Conker et al. (2002), Aquino et al. (2006; 2007; 2009), Silva (2009), Silva et al. (2010), Leandro e Santos (2007), Amiri-Simkooei (2007), Amiri-Simkooei, Tiberius e Teunissen (2008).

No ajustamento pelo Método dos Mínimos Quadrados (MMQ), tanto o modelo funcional quanto o estocástico representam um importante papel no processo de estimação. O modelo estocástico descreve as propriedades estatísticas das observações na forma de Matriz Variância-Covariância (MVC). Em certos casos, há a necessidade de modificar o modelo funcional, por exemplo, adicionando alguns parâmetros. Porém, pode-se obter um resultado equivalente modificando apenas o modelo estocástico, o que é conhecido como equivalência entre o modelo funcional e o estocástico (BLEWITT, 1998).

As observações GNSS são variáveis estocásticas devido aos ruídos nas mesmas (aleatórios) e aos efeitos sistemáticos (não-aleatórios), os quais, em geral, não são incluídos no modelo funcional. Sendo assim, fica evidente que a modelagem estocástica das observações GNSS deve ser realizada adequadamente, uma vez que a qualidade dos parâmetros estimados e o controle de qualidade do ajustamento dependem muito dessas informações a priori.

No processamento dos dados GNSS a partir do MMQ, geralmente, assume-se que as medidas (fase e código) para cada satélite têm a mesma precisão e são estatisticamente independentes. Desta maneira, os modelos estocásticos adotados não são

realísticos, proporcionando assim, no final do processamento dos dados envolvidos, precisões muito otimistas. Uma maneira para solucionar este problema é a adoção e implementação de uma modelagem estocástica mais realística e adequada.

Em 2009 foi concluída uma dissertação (SILVA, 2009) na qual foram investigados e implementados modelos estocásticos que consideram a variação dos ângulos de elevação dos satélites e os efeitos da cintilação ionosférica, tanto no posicionamento relativo quanto no absoluto. As melhorias ao utilizar a modelagem estocástica em função da variação dos ângulos de elevação dos satélites em relação à modelagem padrão (considerando somente as variâncias das observáveis GNSS) atingiram 15% no modo relativo (solução final) e 42% no modo absoluto. Já ao aplicar a modelagem em função da cintilação ionosférica, as melhorias atingiram 93% na solução final do modo relativo e 45% no modo absoluto.

A cintilação ionosférica é provocada pela variação na densidade de elétrons na camada ionosférica, causando assim variações de amplitude, de fase, de polarização e no ângulo do sinal GNSS (KLOBUCHAR, 1996; DAVIES, 1990; CONKER et al., 2002).

As cintilações ionosféricas são particularmente fortes nas zonas aurorais (regiões de altas latitudes e polares da ionosfera) e nas regiões tropicais (região equatorial da ionosfera) durante as noites e próximas aos equinócios (DAVIES, 1990; CONKER et al., 2002). Os efeitos de cintilação ionosférica causam, então, o enfraquecimento e até mesmo a perda do sinal GNSS, dificultando assim, a solução das ambiguidades e conseqüentemente prejudicando os resultados do posicionamento geodésico. Sendo assim, faz-se necessário um aprofundamento na investigação relacionada aos efeitos de cintilação ionosférica, principalmente, com relação à região brasileira.

Mesmo se a modelagem estocástica das observações for a mais adequada possível, ainda podem restar alguns efeitos (ruídos/erros), os quais não foram modelados adequadamente e ficarão inclusos nas séries temporais das coordenadas GNSS, as quais são, em geral, estimadas diariamente. As séries temporais podem conter diferentes tipos de ruídos com comportamento tais como ruído branco (*white-noise*), ruído rosa (*flicker noise*) e/ou caminho aleatório (*random walk*). A caracterização destes tipos de ruídos pode ser feita a partir, por exemplo, da análise de variância de Allan, da análise de potência espectral ou da estimativa das componentes de variância do ruído via MMQ (ZHANG et al., 1997).

Assim como no ajustamento dos dados GNSS, na estimativa das componentes de variância dos ruídos das séries temporais, tanto o modelo funcional quanto o estocástico devem ser adotados de forma a obter soluções mais condizentes com a

realidade. No geral, especificações erradas do modelo funcional e do estocástico afetam as propriedades dos estimadores (AMIRI-SIMKOOEI; TIBERIUS; TEUNISSEN, 2007).

Dentro deste contexto, essa tese de doutorado aborda investigações relacionadas à modelagem estocástica das observações GNSS considerando, por exemplo, a influência dos efeitos cintilação ionosférica na região brasileira. Também são abordadas investigações sobre a modelagem funcional e estocástica das séries temporais de coordenadas GNSS considerando os diferentes tipos de ruídos contidos nas séries.

1.1 Contextualização da pesquisa

O GNSS está em constante desenvolvimento tecnológico, haja vista a modernização dos sinais GPS (ex. código L2C e portadora L5) e o lançamento de novos satélites modernizados. O sistema GLONASS também passa por processo de modernização com lançamentos de novos satélites e a proposta de uso de *Code Division Multiple Access* (CDMA) ao invés de *Frequency Division Multiple Access* (FDMA), tal como no GPS. Pode-se citar também o desenvolvimento de novos sistemas como o Galileo (Comunidade Europeia) e o Compass (China). Toda essa abrangência de sinais e de diferentes sistemas proporcionam novas oportunidades de pesquisas relacionadas à combinação de sinais, a mitigação de efeitos atmosféricos e também a análise de séries temporais de coordenadas GNSS.

Para a disponibilidade do sistema GNSS, há uma grande infraestrutura, nem sempre visível para os usuários, seja no segmento de controle, espacial ou de usuário. Atualmente, os usuários podem contar com uma grande variedade de redes de estações GNSS de monitoramento contínuo, podendo-se citar, por exemplo: *International GNSS Service* (IGS), Sistema de Referência Geocêntrico para as Américas (SIRGAS), Rede Brasileira de Monitoramento Contínuo (RBMC), Rede GNSS do Estado de São Paulo (Rede GNSS SP), etc.

Diante desse contexto, diversas pesquisas científicas no âmbito das Ciências Geodésicas vêm sendo realizadas, como por exemplo, pesquisas relacionadas com a mitigação dos efeitos de cintilação ionosférica. Neste caso, pode-se citar projetos como o *Ionospheric Scintillation Arctic Campaign Coordinated Observations* (ISACCO) (DE FRANCESCHI et al., 2006), o projeto *Concept for Ionospheric Scintillation Mitigation for Professional GNSS in Latin America* (CIGALA) e o projeto *Countering GNSS high Accuracy applications Limitations due to Ionospheric disturbances in BRAZIL* (CALIBRA) (<http://www.galileoic.org/la/?q=node/322>), além de diversos trabalhos nessa área: Conker et al. (2002); Aquino et al. (2006; 2007; 2009); Silva (2009); Silva et al. (2010); Elmas,

Aquino e Dodson (2010), dentre outros. Mas o problema ainda não está totalmente solucionado, com muito espaço para ser pesquisado.

Com relação às séries temporais de coordenadas GNSS, o SIRGAS através da rede SIRGAS-CON disponibiliza coordenadas GNSS das estações da rede com soluções semanais, as quais podem ser utilizadas na construção de séries temporais em termos de componente E, N, U do Sistema Geodésico Local (SGL). Já o JPL fornece as séries temporais em termos de SGL com dados brutos ou séries pré-processadas (ex.: filtragem de erros grosseiros) com soluções diárias. O *Script Orbit and Permanent Array Center* (SOPAC) disponibiliza, através do endereço <ftp://garner.ucsd.edu/pub/timeseries/measures/>, séries temporais (coordenadas cartesianas e locais) de estações IGS, além de disponibilizá-las também considerando a caracterização de ruídos e com uma filtragem baseada num modelo refinado (NIKOLAIDIS, 2002). Alguns trabalhos vêm sendo publicados nessa área, como por exemplo: Amiri-Simkooei (2007); Amiri-Simkooei, Tiberius e Teunissen (2008); Williams (2003, 2004, 2008), entre outros. Trata-se de um assunto ainda relativamente novo, também com espaço para desenvolver pesquisas adicionais ao que se tem na literatura.

Considerando a disponibilidade de dados GNSS associados com informações de cintilação ionosférica na região brasileira e de séries temporais de coordenadas GNSS, é de grande relevância para a área das Ciências Geodésicas a investigação de modelagem estocástica no posicionamento GNSS e a análise funcional e estocástica das séries temporais.

1.2 Objetivos

Nessa tese de doutorado objetiva-se investigar os modelos estocásticos envolvidos nas observáveis GNSS, bem como realizar investigações sobre os modelos funcionais e estocásticos das séries temporais das coordenadas GNSS baseadas na caracterização dos ruídos contidos nas mesmas.

Como objetivos secundários, visando atingir o objetivo geral, compõem os seguintes:

- Modelagem estocástica do posicionamento GNSS considerando efeitos de cintilação ionosférica na região brasileira;
- Caracterização de ruídos em séries temporais de coordenadas GNSS a partir da análise espectral e da variância de Allan;

- Estimativas de componentes de variância considerando os ruídos do tipo ruído branco (*white noise*), ruído rosa (*flicker noise*) e caminho aleatório (*random walk*) nas séries temporais de coordenadas;
- Identificação do modelo funcional para as séries temporais de coordenadas;
- Identificação de modelos estocásticos para a melhor representação do modelo funcional da série temporal, visando a predição das séries temporais de coordenadas.

1.3 Justificativa

Em Silva (2009), modelos estocásticos foram investigados considerando os efeitos de cintilação ionosférica no processamento de dados GNSS. No caso, foram utilizados dados de receptores localizados em regiões de alta latitude disponibilizados pelo projeto ISACCO (DE FRANCESCHI et al., 2006). Neste caso, não foi possível utilizar dados da região equatorial, pois os mesmos não estavam acessíveis. Atualmente, na região brasileira já se têm receptores capazes de coletar dados com informações de cintilação ionosférica através do projeto CIGALA/CALIBRA (<http://is-cigala-calibra.fct.unesp.br/cigala/index.php>).

Vale ressaltar que a causa dos efeitos de cintilação ionosférica em altas latitudes (devido a eventos de tempestades geomagnéticas) é diferente da região equatorial (devido à anomalia equatorial), como é o caso do Brasil, o que requer investigações mais profundas para melhorar a modelagem estocástica para esta região.

Com relação às séries temporais de coordenadas GNSS, estas advêm de processamentos de dados GNSS visando a materialização de redes geodésicas. Apesar de praticamente todos os efeitos sistemáticos serem modelados com processamentos realizados a partir de software científicos, ainda restam efeitos residuais nas séries temporais, principalmente relacionados a séries envolvendo longos períodos de dados, uma vez que os modelos e processamento são válidos para um dia.

Os efeitos residuais das séries podem ser caracterizados em termos de ruídos branco (*white-noise*), ruído rosa (*flicker noise*) e caminho aleatório (*random walk*), o que pode ser feito a partir de diferentes técnicas, tais como variância de Allan, estimativa por MMQ das componentes de variância dos ruídos e outros. Considerando a dimensão territorial brasileira e sua variabilidade em termos de efeitos atmosféricos, a análise de séries temporais, seja univariada ou multivariada, além da caracterização de ruídos é de

grande relevância para o avanço de pesquisas relacionadas às Ciências Geodésicas e áreas afins no Brasil.

É importante considerar que se têm atualmente as séries temporais de coordenadas GNSS de estações no Brasil, as quais são advindas das soluções semanais SIRGAS e das soluções diárias do JPL. Estas séries, com dados em torno de dez anos ou mais representam uma considerável amostragem para modelagem das séries temporais e caracterizações das componentes de variância dos ruídos.

As investigações nesse trabalho visam caracterizar as componentes de variância dos ruídos das séries temporais de coordenadas GNSS na região brasileira, melhorando, conseqüentemente, a construção de modelos funcionais dessas séries. Tais modelos serão utilizados para melhor representação e entendimento das séries temporais, bem como para sua predição, o que poderá beneficiar tanto a Geodésia quanto outras ciências afins.

1.4 Conteúdo da tese

Esta tese está dividida em 8 seções além das referências e apêndices.

Na seção 1 é realizada uma introdução ao assunto e também apresentados os objetivos e a justificativa do trabalho.

A seção 2 aborda uma introdução ao ajustamento de observações e também o controle de qualidade do mesmo.

Os modelos funcionais e estocásticos relacionados às observações GNSS, bem como os erros envolvidos nessas observações são abordados na seção 3.

Já a seção 4 é destinada a uma introdução aos processos estocásticos e análise de séries temporais. Aborda também os assuntos relacionados a caracterização de ruídos de séries temporais.

Na seção 5 é apresentada a metodologia envolvida na tese.

A seção 6 é destinada aos resultados e análises dos experimentos realizados.

As conclusões e considerações finais são apresentadas na seção 7 e as recomendações e trabalhos futuros na seção 8.

2 INTRODUÇÃO AO AJUSTAMENTO DAS OBSERVAÇÕES

A determinação da posição geográfica de uma estação terrestre utilizando observações GNSS, geralmente pode ser obtida a partir do ajustamento pelo MMQ (seção 2). Nesse caso, pode ser realizado através do método paramétrico, quer seja em lote ou recursivo (GEMAEL, 1994; MIKHAIL, 1976; TEUNISSEN, 1998, 2001). Pode-se ainda utilizar a estimação por Filtro de Kalman. Para o controle de qualidade, tanto no ajustamento em lote quanto no recursivo, pode ser utilizado o método denominado DIA (Detecção, Identificação e Adaptação) (CAMARGO, 1992; TEUNISSEN, 1998).

2.1 Ajustamento em lote pelo MMQ

No processamento em lote todas as observações são ajustadas simultaneamente e no recursivo as observações podem ser inseridas à medida que se tornam disponíveis (MONICO, 2008). No método paramétrico, os valores observados ajustados são dados em função dos parâmetros ajustados (TEUNISSEN, 2001):

$$L_a = F(X_a), \quad (2.1)$$

em que $X_a = X_0 + X$, sendo X_0 o vetor dos parâmetros aproximados e X o vetor de correções aos parâmetros aproximados.

O modelo estocástico é representado pela matriz de variância-covariância das observações (Σ_{L_b}) e o modelo funcional linearizado é dado por (GEMAEL, 1994; TEUNISSEN, 2001):

$$V = L - AX, \text{ com } n > u, \quad (2.2)$$

sendo:

n – número de equações ou de observações;

u – número de parâmetros incógnitos;

V – vetor ($n \times 1$) dos resíduos;

$A = \left. \frac{\partial F}{\partial X_a} \right|_{X_0}$ – matriz ($n \times u$) *design* (Jacobiana);

$L = L_b - L_0$ – vetor ($n \times 1$), sendo $L_0 = F(X_0)$ e L_b o vetor dos valores observados.

O critério do MMQ é minimizar a forma quadrática $V^T P V$, sendo $P = \sigma_0^2 \Sigma_{L_b}^{-1}$ e σ_0^2 o fator de variância a priori. De acordo com esse critério, a solução do ajustamento é dada por (GEMAEL, 1994; TEUNISSEN, 2001):

$$X_a = (A^T P A)^{-1} (A^T P L), \quad (2.3)$$

$$\Sigma_{X_a} = \Sigma_X = \hat{\sigma}_0^2 (A^T P A)^{-1}, \quad (2.4)$$

sendo, $\hat{\sigma}_0^2 = \frac{V^T P V}{n-u}$ o fator de variância a posteriori.

Os vetores de observações estimadas (L_a) e de resíduos (V) e suas respectivas MVCs (Σ_{L_a} e Σ_V) são dados por (GEMAEL, 1994):

$$L_a = A X_a + L_0, \quad (2.5)$$

$$V = L_b - L_a, \quad (2.6)$$

$$\Sigma_{L_a} = A \Sigma_{X_a} A^T, \quad (2.7)$$

$$\Sigma_V = \Sigma_{L_b} - \Sigma_{L_a}. \quad (2.8)$$

2.1.1 Controle de qualidade do ajustamento em lote pelo MMQ

Um dos procedimentos mais utilizados no controle de qualidade é baseado em três etapas: Detecção, Identificação e Adaptação, comumente denominado DIA (TEUNISSEN, 1998; CAMARGO, 1992).

A detecção de erro consiste num teste estatístico que é realizado para verificar se ocorreu um erro no modelo matemático e/ou nas observações. O teste leva em consideração as seguintes hipóteses (TEUNISSEN, 1998; 2000; GEMAEL, 1994):

$$\begin{aligned} H_0: E\{\hat{\sigma}_0^2\} &= \sigma_0^2 \\ &\text{contra} \\ H_a: E\{\hat{\sigma}_0^2\} &> \sigma_0^2 \end{aligned} \quad (2.9)$$

A estatística T apropriada para testar as hipóteses é (TEUNISSEN, 1998; 2000; GEMAEL, 1994):

$$T = \frac{\hat{\sigma}_0^2}{\sigma_0^2} gl, \quad (2.10)$$

em que $gl = n - u$ é denominado graus de liberdade.

A hipótese nula será rejeitada, a um nível de confiança de $1 - \alpha$ e $n - u$ graus de liberdade, quando $T > \chi_{1-\alpha, n-u}^2$ (distribuição qui-quadrado). Sendo assim, é detectado erro no ajustamento.

Quando isso ocorre há a necessidade de identificar a observação possível de conter erro. Essa identificação pode ser realizada, por exemplo, a partir do método *Data Snooping* de Baarda, cujas hipóteses são formuladas (TEUNISSEN, 1998; 2000; GEMAEL, 1994):

$$\begin{aligned} H_0: E\{L_b\} &= AX \\ &\text{contra} \\ H_a: E\{L_b\} &= AX + C\nabla, \quad \forall \nabla \neq 0 \end{aligned} \quad (2.11)$$

em que, ∇ é um vetor incógnito de ordem $gl \times 1$ e C uma matriz de ordem $n \times gl$.

Considerando o caso unidimensional, ou seja, $gl = 1$ e \underline{c} um vetor (reduzido da matriz C), a identificação é realizada através do cálculo dos resíduos normalizados, os quais são dados por (TEUNISSEN, 1998):

$$w_i = \frac{\underline{c}_i^T \Sigma_{L_b}^{-1} V}{\sqrt{\underline{c}_i^T \Sigma_{L_b}^{-1} \Sigma_V \Sigma_{L_b}^{-1} \underline{c}_i}}, \quad (2.12)$$

em que, Σ_V é calculada como na Equação 2.8, porém utilizando σ_0^2 ao invés de $\hat{\sigma}_0^2$.

Na Equação 2.12, o numerador representa o resíduo transformado, o denominador o erro estimado e \underline{c} a redundância parcial. Este último é um vetor n -dimensional que contém valores unitários para as observações que serão testadas (i) e valores nulos para as outras. Então, ao analisar um resíduo por vez, o vetor \underline{c} tem a seguinte forma (TEUNISSEN, 1998):

$$\underline{c}_i^T = \begin{bmatrix} 0 & 0 & \cdots & 0 & 1 & 0 & \cdots & 0 & 0 \\ 1 & 2 & \cdots & i-1 & i & i+1 & \cdots & n-1 & n \end{bmatrix}. \quad (2.13)$$

A hipótese nula não é rejeitada, a um nível de significância α_0 ($\alpha_0 = \alpha/n$)

se:

$$-\sqrt{N_{\alpha_0/2}} < w_i < \sqrt{N_{\alpha_0/2}} \text{ ou } -\sqrt{\chi_{\alpha_0,1}^2} < w_i < \sqrt{\chi_{\alpha_0,1}^2}, \quad (2.14)$$

caso contrário, a observação i contém erro.

Como as observações são verificadas uma de cada vez, pode ocorrer de uma ou até todas excederem o valor crítico. Sendo assim, a observação suspeita de conter erro será aquela que tiver o maior valor w_i .

Após a identificação de um erro, é necessária a adaptação da hipótese nula para eliminar a presença de tendências na solução. A adaptação do tipo de processamento realizado pode ser feita através, por exemplo, do cálculo da influência a ser retirada dos parâmetros devido às observações com erros ou o reprocessamento sem a observação com erro.

2.2 Ajustamento recursivo pelo MMQ

O processamento recursivo pelo MMQ é um procedimento de estimação que permite atualizar os estimadores para novas observações sem a necessidade de armazenar todas as observações anteriores. Uma forma de se realizar o ajustamento recursivo pelo MMQ é seguindo as etapas (TEUNISSEN, 2001):

1) Inicialização:

$$\begin{cases} X_0^a = \left(A_0^T \Sigma_{L_0^b}^{-1} A_0 \right)^{-1} \left(A_0^T \Sigma_{L_0^b}^{-1} L_0^b \right) \\ \Sigma_{X_0^a} = \left(A_0^T \Sigma_{L_0^b}^{-1} A_0 \right)^{-1} \end{cases}. \quad (2.15)$$

2) Atualização do vetor dos parâmetros:

$$X_k^a = X_{k-1}^a + K_k V_k \text{ com } k = 1, 2, \dots \quad (2.16)$$

sendo V_k o resíduo predito e K_k a matriz de ganho, os quais são dados por:

$$V_k = L_k^b - A_k X_{k-1}^a, \quad (2.17)$$

$$K_k = \Sigma_{X_{k-1}^a} A_k^T \Sigma_{V_k}^{-1}, \quad (2.18)$$

$$\Sigma_{V_k}^{-1} = \Sigma_{L_k^b} + A_k \Sigma_{X_{k-1}^a} A_k^T. \quad (2.19)$$

3) Atualização da MVC de $\Sigma_{X_k^a}$:

$$\Sigma_{X_k^a} = (I - K_k A_k) \Sigma_{X_{k-1}^a}, \text{ com } k = 1, 2, \dots \quad (2.20)$$

2.2.1 Controle de qualidade do ajustamento recursivo pelo MMQ

No ajustamento recursivo pelo MMQ o procedimento DIA também se dá na forma recursiva, podendo ser local e o global. O procedimento DIA local é quando os testes são realizados no instante k . Se um teste é realizado considerando os instantes anteriores tem-se então o procedimento global. Nas seções 2.2.1.1 2.2.1.2 são apresentados, respectivamente, os procedimentos DIA local e Dia global.

2.2.1.1 Procedimento DIA local

No procedimento DIA local são formuladas as seguintes hipóteses (TEUNISSEN, 1998; 2000):

$$\begin{aligned} H_0^k: E\{V_k\} &= 0 \\ &\text{contra} \\ H_a^k: E\{V_k\} &= C_{V_k} \nabla \end{aligned} \quad (2.21)$$

em que, V_k é o vetor dos resíduos preditos no instante k e C_{V_k} é escolhida como uma matriz regular e quadrada e então $gl = n_k$ (n_k é o número de observações no instante k).

Desde que $C_{V_{ki}} = 0$ para $i < k$, a estatística utilizada para testar H_0 contra H_a é denominada *Local Overall Model* (LOM) e é expressa por (TEUNISSEN, 1998; 2000):

$$T_{LOM}^k = \frac{V_k^T \Sigma_{V_k}^{-1} V_k}{n_k}, \quad (2.22)$$

em que, Σ_{V_k} é a MVC dos resíduos preditos no instante k .

A estatística T_{LOM}^k tem distribuição Qui-quadrado (χ^2), com n_k graus de liberdade. A um determinado nível de significância α é detectada a presença de erro grosseiro se (TEUNISSEN, 1998; 2000):

$$T_{LOM}^k > \chi_{\alpha, n_k}^2. \quad (2.23)$$

Se for detectada a presença de erro grosseiro, a próxima etapa é a identificação da observação que contém o erro. Para tanto, são formuladas as seguintes hipóteses (TEUNISSEN, 1998; 2000):

$$\begin{aligned} H_0^k: E\{V_k\} &= 0 \\ \text{contra} & \\ H_a^k: E\{V_k\} &= c_k \nabla \end{aligned} \quad (2.24)$$

em que, c_k é o vetor reduzido da matriz C_{V_k} , dado por:

$$c_{V_{ki}}^T = \begin{bmatrix} 0 & 0 & \dots & 0 & 1 & 0 & \dots & 0 & 0 \\ 1 & 2 & \dots & i-1 & i & i+1 & \dots & n_{k-1} & n_k \end{bmatrix} \quad (2.25)$$

sendo i , a observação a ser testada.

A estatística local t_k para identificar a observação com o erro é dada por (TEUNISSEN, 1998):

$$t_k = \frac{c_{V_{ki}}^T \Sigma_{V_k}^{-1} V_k}{\sqrt{c_{V_{ki}}^T \Sigma_{V_k}^{-1} c_{V_{ki}}}}. \quad (2.26)$$

Quando a hipótese H_0 é verdadeira a estatística t_k tem distribuição normal padronizada ($N(0,1)$). A identificação consiste, primeiramente, em encontrar o maior valor de $|t_k|$ entre todas as hipóteses alternativas (H_a) especificadas. A observação mais provável de conter o erro é aquela associada à estatística t_k que exceder o valor crítico de $N_{\alpha_0/2}(0,1)$, ou seja (TEUNISSEN, 1998):

$$|t_k| > N_{\alpha_0/2}(0,1). \quad (2.27)$$

Após a identificação é necessário realizar a adaptação para eliminar a presença de tendências (*bias*) no vetor estado filtrado. Uma descrição detalhada dessa etapa é encontrada em Teunissen (1998).

2.2.1.2 Procedimento DIA global

O procedimento DIA local descrito na seção 2.2.1.1 pode ser insensível a tendências não modeladas globais. Nesse caso, são consideradas as seguintes hipóteses globais (TEUNISSEN, 1998):

$$\begin{aligned} H_0^{j,k} : E\{V^{j,k}\} &= 0 \\ &\text{contra} \\ H_a^{j,k} : E\{V^{j,k}\} &= C_V^{j,k} \nabla \end{aligned} \quad (2.28)$$

com o $\sum_{i=j}^k n_i \times 1$ vetor de resíduos preditos $V^{j,k} = (V_j^T, \dots, V_k^T)^T$, sendo j o instante que se considera que o erro está começando a ocorrer.

A estatística utilizada para testar as hipóteses $H_0^{j,k}$ e $H_a^{j,k}$ (Equação 2.28) é denominada *Global Overall Model* (GOM) (TEUNISSEN, 1998):

$$T_{GOM}^{j,k} = \frac{\sum_{i=j}^k V_i^T \Sigma_{V_i}^{-1} V_i}{\sum_{i=j}^k n_i}, \quad (2.29)$$

quando $j = k$, o teste será igual ao teste de detecção local (Eq. 2.22).

Na forma recursiva, a estatística global da Equação 2.29 pode ser escrita como (TEUNISSEN, 1998):

$$T_{GOM}^{j,k} = T_{GOM}^{j,k-1} + G_{j,k}(T_{LOM}^k - T_{GOM}^{j,k-1}), \quad (2.30)$$

em que, $G_{j,k} = n_k / \sum_{i=j}^k n_i$.

A estatística $T_{GOM}^{j,k}$ também segue a distribuição Qui-quadrado com gl_k graus de liberdade ($gl_k = \sum_{i=j}^k n_i$) e o erro global é detectado a um certo nível de significância α se:

$$T_{GOM}^{j,k} > \chi_{\alpha, gl_k}^2. \quad (2.31)$$

Após a etapa de detecção do erro na observação, é realizada a identificação global dos erros detectados no instante k . Para tanto, tem-se as seguintes hipóteses:

$$\begin{aligned} H_0^{j,k}: E\{V^{j,k}\} &= 0 \\ \text{contra} & \\ H_a^{j,k}: E\{V^{j,k}\} &= c_V^{j,k} \nabla \end{aligned} \quad (2.32)$$

em que, $c_V^{j,k} = (c_{V_j}^T, \dots, c_{V_k}^T)^T$ é o vetor reduzido da matriz $C_V^{j,k}$.

Na etapa de identificação a estatística utilizada é expressa por (TEUNISSEN, 1998):

$$T_{gl=1}^{j,k} = (t^{j,k})^2, \quad (2.33)$$

com

$$t^{j,k} = \frac{\sum_{i=j}^k c_{V_i}^T \Sigma_{V_i}^{-1} V_i}{\sum_{i=j}^k c_{V_i}^T \Sigma_{V_i}^{-1} c_{V_i}}. \quad (2.34)$$

Na identificação da observação com erro em cada instante i , a hipótese nula não é rejeitada a um nível de significância α_0 se (CAMARGO, 1992):

$$-N_{\alpha_0/2} < t_i^{j,k} < N_{\alpha_0/2}. \quad (2.35)$$

caso contrário, a observação no instante i contém erro.

Como na etapa de detecção, a estatística de identificação global pode ser escrita na forma recursiva, de forma que a estatística local é utilizada como entrada para novo instante (TEUNISSEN, 1998):

$$(t^{j,k})^2 = (t^{j,k-1})^2 + g_{j,k}((t^k)^2 - (t^{j,k-1})^2), \quad (2.36)$$

em que:

$$g_{j,k} = \frac{c_{V_k}^T \Sigma_{V_k}^{-1} c_{V_k}}{\sum_{i=j}^k c_{V_i}^T \Sigma_{V_i}^{-1} c_{V_i}}, \quad (2.37)$$

$$c_{V_i} = c_i - A_i X_{i,j}, \quad i = j, \dots, k, \quad (2.38)$$

$$X_{i+1,j} = T_{i+1,j} + K_i c_{V_i}, \quad X_{j,j} = 0. \quad (2.39)$$

Após a identificação do erro, a adaptação global faz-se necessária para eliminar a influência da observação com erro no vetor estado e na respectiva MVC, cujos detalhes podem ser encontrados em Teunissen (1998).

2.3 Estimação por Filtro de Kalman

O filtro de Kalman é um método para se estimar o vetor estado de um modelo dinâmico a partir de observações aleatórias. Considerando o filtro de Kalman para sistemas lineares, o modelo dinâmico e o de observação são expressos, respectivamente, por (TEUNISSEN, 1998; CAMARGO, 1992):

$$X_k = T_{k,k-1}X_{k-1} + W_k, \quad (2.40)$$

$$L_k^b = A_k X_k + V_k. \quad (2.41)$$

em que:

$T_{k,k-1}$ – matriz de transição entre os instantes $k - 1$ e k ;

W_k – vetor das correções ao modelo dinâmico;

L_k^b – vetor ($n \times 1$) das observações do instante k ;

A_k – matriz design no instante k ;

X_k – vetor ($u \times 1$) estado aleatório no instante k ;

V_k – vetor ($n \times 1$) de ruído das medidas no instante k .

Os modelos estocásticos envolvidos no filtro de Kalman são dados por:

$$\begin{aligned} E\{V_k V_m^T\} &= \Sigma_{V_k} \delta_{k,m}, \\ E\{V_{d_k} V_{d_m}^T\} &= \Sigma_{V_{d_k}} \delta_{k,m}, \\ D\{X_0\} &= \Sigma_{X_0}, \end{aligned} \quad (2.42)$$

em que, $\delta_{k,m}$ é a função delta de Kronecker, sendo $\delta_{k,m} = 1$ quando $k = m$ e $\delta_{k,m} = 0$ quando $k \neq m$.

O filtro de Kalman é uma combinação de predição (na estimação são utilizados somente os dados anteriores a um dado instante t_k) e filtragem (na estimação são utilizados dados obtidos desde uma época anterior até um dado instante t_k). As equações de predição e filtragem são expressas, respectivamente, por (TEUNISSEN, 1998; CAMARGO, 1992):

$$\begin{aligned} X_{k|k-1}^a &= T_{k|k-1} X_{k-1|k-1}^a, \\ X_{k|k}^a &= X_{k|k-1}^a + K_k (L_k^b - A_k X_{k|k-1}^a), \end{aligned} \quad (2.43)$$

em que:

$k|k-1$ – instante k considerando os dados do instante $k-1$;

$k|k$ – instante k considerando os dados até o k -ésimo instante;

K_k – é conhecida como matriz de ganho de Kalman e é dada por:

$$K_k = \Sigma_{X_{k|k-1}^a} A_k^T (A_k \Sigma_{X_{k|k-1}^a} A_k^T + \Sigma_{L_k^b})^{-1}, \quad (2.44)$$

As MVCs dos vetores de estado predito e filtrado são dadas por (CAMARGO, 1992):

$$\begin{aligned} \Sigma_{X_{k|k-1}^a} &= T_{k,k-1} \Sigma_{X_{k-1|k-1}^a} T_{k,k-1}^T + W_k, \\ \Sigma_{X_{k|k}^a} &= (I - K_k A_k \Sigma_{X_{k|k-1}^a}). \end{aligned} \quad (2.45)$$

No caso, se a matriz de transição ($T_{k,k-1}$) for considerada como identidade, a estimação por filtro de Kalman coincide com o ajustamento recursivo por MMQ. A estimação por filtro de Kalman para sistemas não-lineares, o qual envolve iterações, pode ser encontrado com mais detalhes em Teunissen (1998) e Camargo (1992).

3 MODELO MATEMÁTICO DAS OBSERVAÇÕES GNSS

O modelo matemático das observações GNSS envolve o modelo funcional e o modelo estocástico, os quais são apresentados respectivamente, nas seções e 3.1 e 3.2.

3.1 Modelo funcional das observações GNSS e erros envolvidos

As observações GNSS são a pseudodistância, obtida a partir da medida do código, e a fase da onda portadora ou diferença de fase da onda portadora. A medida da pseudodistância é obtida a partir da correlação entre o código gerado pelo satélite no instante de transmissão (t^s) e sua réplica gerada no receptor no instante de recepção (t_r). O modelo funcional da pseudodistância entre o satélite s e o receptor r pode ser escrito como (MONICO, 2008):

$$PD_r^s = \rho_r^s + c(dt_r - dt^s) + I_r^s + T_r^s + dm_r^s + Orb_r^s + v_{PD_r^s}, \quad (3.1)$$

em que:

- ρ_r^s – distância geométrica entre o satélite, no instante de transmissão do sinal, e o receptor, no instante de recepção do sinal;
- c – velocidade da luz no vácuo;
- dt_r – erro do relógio do receptor em relação ao tempo GPS;
- dt^s – erro do relógio do satélite em relação ao tempo GPS;
- I_r^s – erro causado pela ionosfera;
- T_r^s – erro causado pela troposfera;
- dm_r^s – erro causado pelo multicaminho;
- Orb_r^s – erro da posição do satélite;
- $v_{PD_r^s}$ – erro da pseudodistância devido aos efeitos não modelados e aleatórios.

A medida da fase de batimento da onda portadora é obtida a partir da diferença entre a fase gerada pelo satélite, no instante de transmissão do sinal, e sua réplica gerada pelo receptor, no instante de recepção do sinal. Apenas uma medida fracionária é obtida, restando um número inteiro de ciclos desconhecido, denominado ambiguidade (N_r^s).

O modelo funcional envolvendo a fase de batimento da onda portadora pode ser escrito como (SEEBER, 2003):

$$\phi_r^s(t) = \frac{f}{c} (\rho_r^s - I_r^s + T_r^s + dm_r^s + Orb_r^s) + f(dt_r - dt^s) + (\phi^s(t_0) - \phi_r(t_0)) + N_r^s + v_{\phi_r^s}, \quad (3.2)$$

em que:

f – frequência nominal da fase;

$\phi^s(t_0)$ – fase inicial no satélite, correspondente à época de referência t_0 ;

$\phi_r(t_0)$ – fase inicial no receptor, correspondente à época de referência t_0 ;

N_r^s – ambiguidade da fase no instante inicial de rastreamento;

$v_{\phi_r^s}$ – erro da fase da portadora devido aos efeitos não modelados e aleatórios.

Em alguns casos há a possibilidade de realizar combinações lineares das observações GNSS, tais como a *ion-free* (livre da ionosfera), *wide-lane*, *narrow lane*, livre da geometria, entre outras. Existem também as combinações de observações coletadas em distintas estações, por exemplo, combinações de simples, dupla e tripla diferença, entre outras (MONICO, 2005; LEICK, 2004).

A simples diferença (SD) é formada entre dois receptores, dois satélites ou dois instantes, mas normalmente, se utilizam diferenças entre satélites e receptores. Na SD entre dois receptores (r_1 e r_2), supõe-se que estes rastreiam simultaneamente o mesmo satélite s . Na SD o erro do relógio do satélite e o erro da posição do satélite são eliminados. A SD pode ser expressa pelo seguinte modelo funcional (MONICO, 2005):

$$\phi_{SD_{r_1, r_2}}^{s_i} = \phi_{r_1}^{s_i} - \phi_{r_2}^{s_i}. \quad (3.3)$$

Já a dupla diferença (DD) é formada pela diferença entre duas SDs, envolvendo dois satélites e dois receptores. Na DD são eliminados os erros dos relógios dos receptores. As DDs independentes podem ser escritas a partir do modelo funcional (MONICO, 2005):

$$\phi_{DD_{r_1, r_2}}^{s_i, s_{i+1}} = C \phi_{SD_{r_1, r_2}}^{s_i}, \quad (3.4)$$

em que, C é a matriz de coeficientes das simples diferenças de fase.

A matriz C do modelo funcional pode ser definida de duas formas, diferença seqüencial e satélite de referência ou base (TALBOT, 1991 apud MONICO, 2005). No método do satélite base, o qual é mais utilizado, considerando o satélite 1 como base, a matriz C é dada por (MONICO, 2005):

$$C = \begin{bmatrix} 1 & -1 & 0 & \dots & 0 & 0 \\ 1 & 0 & -1 & 0 & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & \dots & 0 & 0 & 0 & -1 \end{bmatrix}. \quad (3.5)$$

A combinação *ion-free* envolve observações no mesmo receptor, portanto, realizada somente com receptores de dupla frequência (L1 e L2). Na combinação *ion-free* são eliminados apenas os efeitos de primeira ordem da ionosfera, restando os efeitos de segunda e terceira ordem (BASSIRI; HAJJ, 1993; ODIJK, 2002; MARQUES, 2008). A equação da fase, considerando apenas estes efeitos pode ser escrita como:

$$\phi_{rLi}^s(t) = \frac{f_{Li}}{c} \rho' + \phi_{Li}^s(t_0) - \phi_{rLi}(t_0) + N_{rLi}^s - \frac{I_{rLi}^{s(1)}}{f_{Li}}, \quad (3.6)$$

em que:

$$i = 1, 2;$$

$$\rho' = \rho_r^s + c(dt_r - dt^s) + T_r^s + dm_r^s + Orb_r^s + v_{\phi_r^s};$$

$I_{rLi}^{s(1)}$ – efeitos de primeira ordem da ionosfera e pode ser dado por (ODIJK, 2002):

$$I_{rLi}^{s(1)} = \frac{I_{rLi}^{s(1)}}{f_{Li}^2} TEC, \quad (3.7)$$

sendo TEC (*Total Electron Content*), o valor do conteúdo total de elétron na ionosfera. Existem diversas formas para a obtenção do valor do TEC, dentre elas, a obtenção a partir da fase, pseudodistância, pseudodistância suavizada pela fase, mapas globais da ionosfera (GIM – *Global Ionosphere Maps*). Mais detalhes podem ser encontrados em Ciruolo et al. (2007) e Matsuoka e Camargo (2004).

A combinação *ion-free*, para o caso da fase, é dada por (MONICO, 2005):

$$\phi_{IF} = m_1 \phi_{rL1}^s + m_2 \phi_{rL2}^s. \quad (3.8)$$

Para que os efeitos de primeira ordem da ionosfera sejam eliminados, as seguintes condições devem ser satisfeitas (GOAD, 1996):

$$\begin{aligned} m_1 \phi_{rL1}^s + m_2 \phi_{rL2}^s &= 0 \quad \text{e} \\ m_1 f_{L1} + m_2 f_{L2} &= f_{L1}. \end{aligned} \quad (3.9)$$

Aplicando estas condições, os valores de m_1 e m_2 , para o caso da fase, são:

$$m_1 = \frac{f_{L1}^2}{f_{L1}^2 - f_{L2}^2} \quad \text{e} \quad m_2 = \frac{f_{L1} f_{L2}}{f_{L1}^2 - f_{L2}^2}. \quad (3.10)$$

No caso, a equação provinda da combinação *ion-free* (Equação 3.8), pode ser utilizada nas combinações de simples, dupla e tripla diferença.

3.1.1 Erros relacionados às observações GNSS

As observações GNSS estão sujeitas a erros aleatórios (inerentes as observações), sistemáticos (podem ser eliminados ou parametrizados) ou grosseiros (devem ser detectados, identificados e eliminados através de um controle de qualidade). Para que se obtenham resultados confiáveis o modelo matemático (funcional e estocástico) estabelecido deve ser válido para a realidade física que se tenta descrever, e capaz de detectar problemas. Assim, as fontes de erros envolvidas nas observações devem ser bem conhecidas. Os diversos erros relacionados às observações GNSS, agrupados de acordo com as possíveis fontes são apresentados na Tabela 3.1 (MONICO, 2008):

Tabela 3.1: Fontes e efeitos dos erros nas observações GNSS

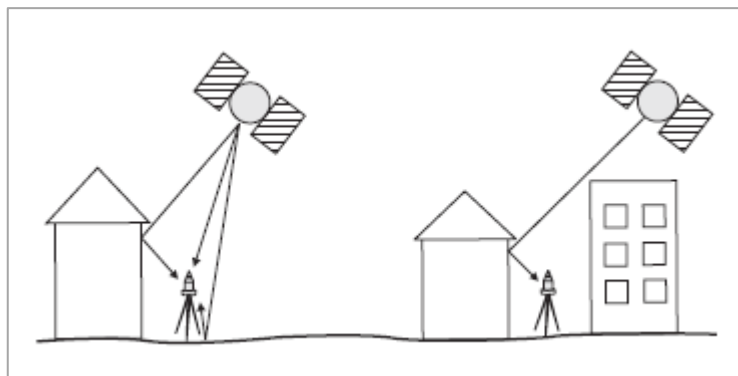
Fontes	Erros
Satélite	Erro da órbita; erro do relógio; relatividade; atraso entre as portadoras no hardware do satélite; centro de fase da antena do satélite, fase <i>wind-up</i>
Propagação do sinal	Erros relacionados à troposfera e à ionosfera; perdas de ciclos; multicaminho ou sinais refletidos; rotação da Terra
Receptor/antena	Erro do relógio; erro entre os canais; atraso entre as portadoras no hardware do satélite; centro de fase da antena do receptor; fase <i>wind-up</i>
Estação (alguns erros são, na realidade, efeitos geodinâmicos e devem ser corrigidos)	Erro nas coordenadas; multicaminho ou sinais refletidos; marés terrestres; movimento do pólo; carga oceânica; pressão da atmosfera

Ao se realizar o Posicionamento por Ponto Preciso (PPP) todos os erros citados na Tabela 3.1 devem ser modelados e/ou estimados, enquanto que no posicionamento relativo, a maioria desses erros é praticamente eliminada, principalmente para linhas de base curtas.

Com relação à ionosfera, há diversos estudos sobre a correção ou modelagem desse efeito. Para o caso de posicionamento por ponto com receptor de simples frequência, pode-se utilizar o modelo de Klobuchar (KLOBUCHAR, 1996) ou Mod_Ion disponível na FCT/UNESP (CAMARGO, 1999). Para o caso de dupla frequência, pode-se utilizar a combinação *ion-free* para a eliminação dos efeitos de primeira ordem da ionosfera. No caso de posicionamento considerando linhas de base curtas esses efeitos são praticamente eliminados a partir do processo de diferenciação (simples e duplas diferenças) das medidas GNSS (MONICO, 2008; SEEBER, 2003). Há ainda a possibilidade da estimativa dos efeitos ionosféricos para o posicionamento por ponto ou dos resíduos ionosféricos das duplas diferenças para o posicionamento relativo (MARQUES, 2008). Com relação aos efeitos ionosféricos de ordem superior, mais especificamente de segunda e terceira ordem, têm-se disponível no NGS (*National Geodetic Survey*) Toolbox (http://www.ngs.noaa.gov/gps-toolbox/RINEX_HO.htm) um aplicativo para corrigir as medidas GPS desses efeitos (MARQUES; MONICO; AQUINO, 2011).

O efeito de multicaminho significa que um ou mais sinais GNSS refletidos em outros “objetos” que alcançam a antena receptora em adição ao sinal direto e, em circunstâncias especiais apenas o sinal refletido alcança a antena, ou seja, apenas multicaminho. Os efeitos de multicaminho podem provocar erros de ordem métrica no posicionamento GNSS (SEEBER, 2003). A Figura 3.1 exemplifica o efeito de multicaminho num receptor GNSS.

Figura 3.1: Efeito de multicaminho no receptor GNSS



Fonte: Seeber (2003).

A redução do multicaminho é possível a partir da seleção de antenas com base na polarização do sinal GPS, o qual é polarizado circularmente à direita. Nesse caso, o sinal refletido uma única vez, dependendo do ângulo de incidência, seria polarizado à esquerda. Na teoria todos os sinais polarizados à esquerda seriam rejeitados pela antena, no entanto, não é o que acontece na prática. Dessa forma, esta técnica deve ser acompanhada de algumas proteções, como por exemplo, o de antenas *choke rings*. Trata-se de uma antena com um plano de terra, ou seja, um disco metálico onde a antena é centrada e que contém uma série de círculos concêntricos com uma altura de aproximadamente um quarto de comprimento de onda (valor máximo do multicaminho para portadora) (MONICO, 2008).

Além do uso de antenas específicas, várias pesquisas vêm sendo realizadas para atenuar o efeito de multicaminho nos dados GNSS, podendo citar trabalhos de Souza (2004; 2008), nos quais a atenuação do multicaminho é realizada utilizando wavelets.


3.1.2 Ionosfera e cintilação ionosférica

Em Geodésia a atmosfera pode ser dividida de acordo com a propagação de sinais GNSS, assim têm-se duas camadas: a troposfera e a ionosfera. A troposfera compreende a camada da atmosfera entre a superfície terrestre até 50 km de altura. Ela é formada por partículas neutras e compostas por diferentes gases. A propagação do sinal depende principalmente do conteúdo de vapor d'água e da temperatura. Já a ionosfera compreende a camada superior da atmosfera, entre 50 e 2000 km de altura, a qual é caracterizada pela presença de íons e elétrons livres. A propagação do sinal é afetada principalmente pelas partículas carregadas livres (SEEBER, 2003; DAVIES, 1990).

De acordo com a altitude e a concentração de elétrons, a ionosfera é dividida nas seguintes regiões (Figura 3.2) (SEEBER, 2003; DAVIES, 1990):

- **Região D:** compreende uma região entre 50 e 85 km e é gerada apenas do lado da Terra iluminado pelo Sol
- **Região E:** compreende uma região entre 85 e 140 km e é dependente do nível de atividade e do ângulo zenital do Sol
- **Região F:** em períodos de alta ionização durante o dia e na estação de verão subdivide-se em duas: F1 e F2. A região F1 compreende uma região entre 140 e 200 km e apresenta grandes variações, as quais estão associadas ao número de manchas solares. Já a região F2 compreende uma região entre 200 e 1000 ou 2000 km.

Figura 3.2: Regiões da ionosfera de acordo com a altitude e a concentração de elétrons




Fonte: <http://ion.le.ac.uk/ionosphere/profile.html>. Acesso: dez. 2013.

Um dos fatores que influenciam a densidade de elétrons na ionosfera são as tempestades geomagnéticas e ocorrem principalmente devido às explosões solares. Uma

explosão solar (*solar flare*) é uma explosão no Sol que acontece quando a energia armazenada em campos magnéticos em forma espiral (*twisted geomagnetic fields*) (geralmente acima das manchas solares) é subitamente liberada. As explosões solares são classificadas de acordo com o brilho de raios X. São classificadas de acordo com a magnitude em X (grande), M (média) e C (pequena). Eventos solares com magnitude X podem provocar interrupções em sinais de rádio e longas tempestades de radiação (<http://www.spaceweather.com/glossary/flareclasses.html>). A Figura 3.3 mostra um gráfico de raios X, no qual é detectada a existência de explosão solar.

Figura 3.3: Gráfico de raios X que indicam a existência de explosões solares



Fonte: <http://www.spaceweather.com/glossary/flareclasses.html>. Acesso em: dez. 2013.

Para determinar a intensidade e a duração de tempestades geomagnéticas são utilizados alguns índices geomagnéticos, dentre eles os índices Ap, Kp, Dst (*Disturbance Storm Time*).

O índice Kp é derivado do índice K, o qual é medido em um único local de observação geomagnética e varia de 0 a 9 para cada intervalo de 3 horas, tendo então 8 valores diários de índice Kp. Cada intervalo de 3 horas é distribuído em 28 níveis de 0o, 0+, 1-, 1o, 1+, ..., 9+, 9o, os quais são expressos em terço de unidade, por exemplo, 5- = 4 2/3, 5o = 5 e 5+ = 5 1/3. Em muitas aplicações é conveniente o uso de um único valor diário, porém, é complicado obter uma média dos 8 valores diários utilizando os índices Kp, devido ao fato desses terem um comportamento quase logarítmico. A partir dos índices Kp, foi derivado o índice ap (no mesmo intervalo), o qual tem um comportamento linear. A média

dos 8 valores de ap proporciona o índice Ap diário. A Tabela 3.2 mostra a relação entre os índices Kp e ap (DAVIES, 1990; MATSUOKA, 2007).

Tabela 3.2: Relação entre os índices Kp e ap

Kp	0o	0+	1-	1o	1+	2-	2o	2+	3-	3o	3+	4-	4o	4+
ap	0	2	3	4	5	6	7	9	12	15	18	22	27	32
Kp	5-	5o	5+	6-	6o	6+	7-	7o	7+	8-	8o	8+	9-	9o
ap	39	48	56	67	80	94	111	132	154	179	207	236	300	400

Fonte: Davies (1990).

A atividade geomagnética pode ser classificada de acordo com os valores dos índices Kp e Ap , como pode ser visto na Tabela 3.3.

Tabela 3.3: Classificação da atividade geomagnética de acordo com os índices Kp e Ap

Atividade geomagnética	Índice Kp	Índice Ap
Calma	0-2	<8
Transição	3	8-15
Ativa	4	16-29
Tempestade fraca	5	30-49
Tempestade intensa	6	50-99
Tempestade muito intensa	7-9	100-400

Fonte: Batista (2003) apud Matsuoka (2007).

A ionosfera pode ser projetada (de forma aproximada) na superfície da Terra em termos de latitude geomagnética. Dessa forma, têm-se as seguintes regiões geográficas da ionosfera (FONSECA JÚNIOR, 2002; SKONE, 2000; RODRIGUES, 2003; DAVIES, 1990):

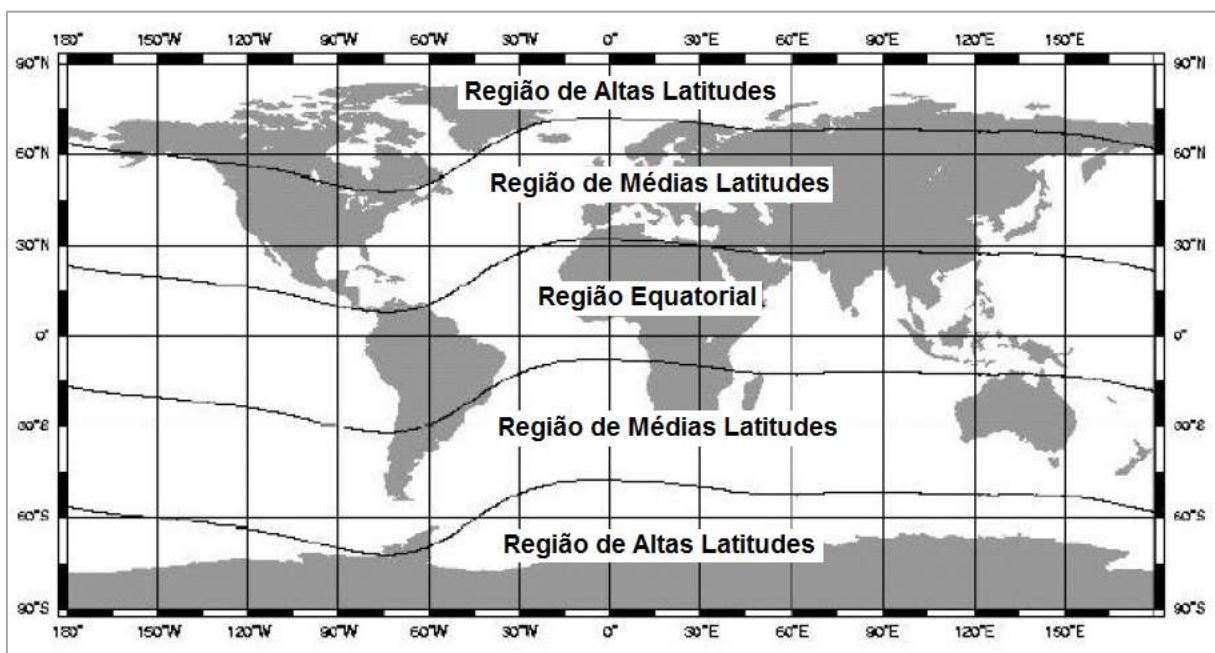
- **Região Equatorial:** correspondente às latitudes geomagnéticas de -20° a $+20^\circ$. Essa região contém os maiores valores de densidade de elétrons, principalmente no início da tarde. Sendo que no equador geomagnético os valores são mais baixos do que nas baixas latitudes $\pm (15^\circ$ a $20^\circ)$, onde se concentram os valores mais altos. Tal fenômeno é denominado anomalia equatorial ou anomalia “Appleton”, ou seja, a anomalia equatorial consiste em dois máximos em densidade de elétron, localizada aproximadamente $\pm 15^\circ$ do equador geomagnético.

As instabilidades do plasma ocorrem na camada F (Figura 3.2), no equador, e normalmente à noite.

- **Região de Médias Latitudes:** correspondente às latitudes geomagnéticas que variam de \pm (20° a 60°);
- **Região de Altas Latitudes:** correspondente às latitudes geomagnéticas que variam de \pm (60° a 90°). Nessa região o pico de densidade de elétrons é pequeno, porém há uma grande instabilidade de plasma.
 - **Região Auroral:** correspondente às latitudes geomagnéticas que variam de \pm (65° a 75°).
 - **Região Polar:** correspondente às latitudes geomagnéticas que variam de \pm (75° a 90°). Nessa região é detectável a variação diurna, o que mostra que a incidência solar é um fator considerável na variação da densidade de elétrons na ionosfera.

A Figura 3.4 mostra as regiões geográficas da ionosfera:

Figura 3.4: Regiões geográficas da ionosfera




Fonte: Adaptada de Fonseca Júnior (2002).

Nas regiões equatoriais há fortes irregularidades na densidade de elétrons constituindo as denominadas bolhas ionosféricas (ou bolhas de plasma). Por definição bolhas ionosféricas são imensas regiões do espaço terrestre onde a densidade de elétrons livres (plasma ionosférico) é acentuadamente reduzida. As bolhas ionosféricas se

desenvolvem no equador geomagnético ao longo das forças do campo geomagnético alcançando até ~10000 km de extensão e até ~100 a 300 km na direção perpendicular. Elas ocorrem no período noturno, frequentemente, entre às 20 e 0 horas local e, em algumas fases do ano podem ocorrer durante toda a noite até o amanhecer. A ocorrência de bolhas ionosféricas é mais predominante na primavera e no verão, que no Brasil corresponde aos meses de outubro a março, sendo a máxima ocorrência entre novembro e janeiro (SANTANA, 2001). A Figura 3.5 exemplifica a ocorrência de bolhas ionosféricas.

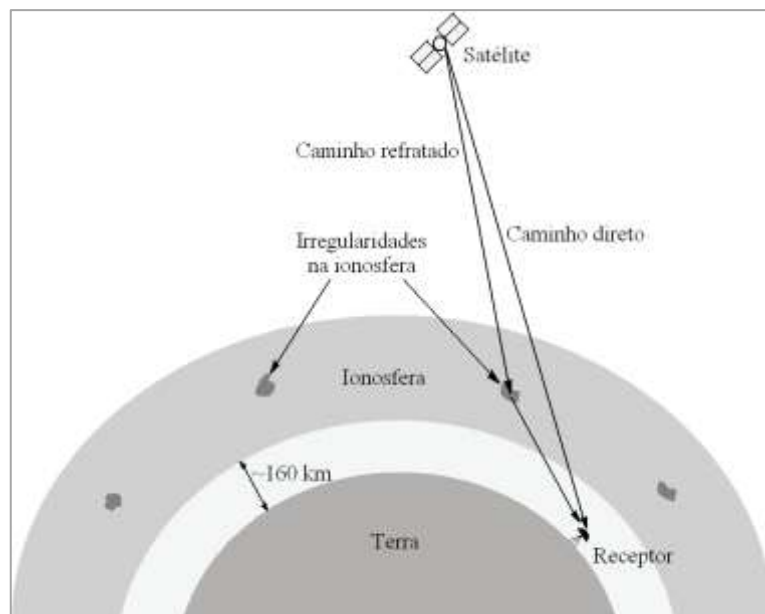
Figura 3.5: Representação de bolhas ionosféricas



Fonte: <http://www.dae.inpe.br>. Acesso em: dez. 2013.

A camada da ionosfera provoca diversos efeitos nos sinais GNSS, dentre eles pode-se citar o avanço na fase e o atraso do grupo. Além disso, variações na densidade de elétrons provocam as denominadas cintilações ionosféricas (KLOBUCHAR, 1996). As cintilações ionosféricas ocorrem devido a pequenas irregularidades na camada da ionosfera provocando variações de amplitude, de fase, de polarização e no ângulo do sinal GNSS. Como resultado, o sinal GNSS alcança a antena receptora via dois caminhos, o caminho direto e o caminho refratado, como mostra a Figura 3.6 (MAINI; AGRAWAL, 2007; DAVIES, 1990; CONKER et al., 2002).


Figura 3.6: Exemplo da ocorrência de cintilação ionosférica



Fonte: Adaptado de Maini e Agrawal (2007).

As três principais regiões geográficas da ionosfera onde ocorrem as cintilações ionosféricas são as regiões equatoriais (ocorrem no período logo após o pôr-do-sol e predominantemente entre setembro e março), as regiões de altas latitudes e as regiões polares (podem ocorrer a qualquer hora local). As cintilações também ocorrem em médias latitudes, porém são menos intensas e não apresentam sérios problemas (SKONE, 2000; RODRIGUES, 2003; DAVIES, 1990; REZENDE, 2009). A Figura 3.7 mostra as regiões onde ocorrem as cintilações ionosféricas no período de máxima e mínima atividade solar:

Figura 3.7: Regiões de ocorrência de cintilações (máxima (a) e mínima (b) atividade solar)



Fonte: Basue Mankenzie(1988) apud Rodrigues (2003).

As ocorrências de cintilações na região equatorial e de baixas latitudes apresentam-se relacionadas com a anomalia equatorial, sendo sua maior intensidade em locais de pico da anomalia. A ocorrência de bolhas ionosféricas nessa região também contribui para a existência de cintilações ionosféricas. Já nas regiões de altas latitudes estão relacionadas com períodos de alta atividade solar e outras atividades extremas tal como a ocorrência de tempestades geomagnéticas (MAINI; AGRAWAL, 2007; SKONE, 2000).

O monitoramento da cintilação ionosférica pode ser feito a partir da medida de cintilação de amplitude e da cintilação da fase. A cintilação de amplitude é monitorada a partir do índice S4. O índice S4 é derivado a partir da intensidade do sinal recebido dos satélites GNSS, pode ser interpretado como o desvio-padrão normalizado (intervalo de um minuto de dados - taxa de amostra de 50 Hz) pela potência média do sinal, ou seja (VAN DIERENDONK, 2001; REZENDE, 2009):

$$S4 = \sqrt{\frac{E\{SI^2\} - E\{SI\}^2}{E\{SI\}^2}}, \quad (3.11)$$

em que $E\{\cdot\}$ é a esperança matemática (média) no intervalo de interesse (60 segundos).

A cintilação ionosférica pode ainda ser monitorada a partir desvio-padrão da fase (σ_ϕ) da cintilação. No geral, os valores de σ_ϕ são calculados a cada 60 segundos em intervalos de 1, 3, 10, 30 e 60 segundos, e depois é feita uma média destes cinco valores sobre um minuto. (VAN DIERENDONK, 2001). Nessa tese o valor de σ_ϕ em 60 segundos é denominado de Phi60.

Os níveis de cintilação ionosférica podem ser classificados de acordo com o valor do índice S4, como pode ser visto na Tabela 3.4 (TIWARI et al., 2011):

Tabela 3.4: Classificação dos efeitos cintilação ionosférica

Forte cintilação	$S4 > 1,0$
Moderada Cintilação	$0,5 \leq S4 \leq 1,0$
Fraca Cintilação	$S4 < 0,5$

O monitoramento da cintilação ionosférica é realizado a partir de receptores capazes de coletar informações relacionadas a esse efeito. Vários projetos são desenvolvidos para o monitoramento da cintilação ionosférica, dentre eles pode-se citar:

- **SCINTMON**: o monitoramento da cintilação é realizado pelo Instituto Nacional de Pesquisas Espaciais (INPE) a partir de uma rede de receptores GEC Plessey GPS Builder II TM desenvolvidos pela Universidade de Cornell. A placa GPS é capaz de rastrear até 11 satélites simultaneamente com uma taxa de 50 Hz (50 amostras por segundo). A frequência utilizada é a L1 (1575,42 MHz) (DE PAULA et al., 2008).
- **SCINTEC**: é um projeto do Instituto Nacional de Pesquisas Espaciais (INPE) o qual monitora a cintilação ionosférica e o *Total Electron Content* (TEC) no Brasil, além de fornecer mapas de cintilação sobre o território brasileiro em tempo real. O monitoramento é feito através de uma rede de receptores GPS CASCADE (placa GEC-Plessey) desenvolvida pela Universidade de Cornell (EUA). O SCINTEC é integrado ao projeto *Low-latitude Ionosphere Sensor Network* (LISN) que tem como finalidade fornecer mapas de cintilação e TEC sobre toda a América do Sul em tempo real (DE PAULA et al., 2008). Para maiores detalhes acessar o endereço: <http://www.inpe.br/scintec/pt/>.
- **ISACCO**: acrônimo de *Ionospheric Scintillations Arctic Campaign Coordinated Observation* é um projeto coordenado pelo *Istituto Nazionale di Geofisica e Vulcanologia* (INGV) da Itália e monitora cintilações ionosféricas nas regiões polares (estações no Ártico e na Antártica) através de receptores *GPS Ionospheric and TEC Monitor* (GISTM). Detalhes em De Franceschi et al. (2006) e no endereço de internet <http://www.eswua.ingv.it/ingv/home.php?res=1024>
- **CIGALA/CALIBRA**: CIGALA é o acrônimo de *Concept for Ionospheric Scintillation Mitigation for Professional GNSS in Latin America*, este projeto visa desenvolver e testar estratégias de mitigação de cintilação ionosférica a serem implementadas em receptores GNSS de multi-frequência. Neste projeto já foi finalizado e receptores desenvolvidos pela empresa europeia Septentrio foram instalados em estações no território brasileiro. CALIBRA é o acrônimo de *Countering GNSS high*

Accuracy applications Limitations due to Ionospheric disturbances in BRAzil e é um projeto de continuação do CIGALA. Tem-se então, atualmente, a rede CIGALA/CALIBRA, como pode ser visto na Figura 3.8. Detalhes estão disponíveis em: <http://www.galileoic.org/la/?q=node/322#3>.

Figura 3.8: Localização das estações do projeto CIGALA/CALIBRA



Fonte: <http://is-cigala-calibra.fct.unesp.br/is/>. Acesso em: dez. 2013.

3.2 Modelo estocástico das observações GNSS

Quando se realiza o processamento dos dados GNSS no modo relativo utilizando as observações de DDs, a construção da MVC (e conseqüentemente da matriz peso) deve ser baseada na lei de propagação de covariâncias dessas observações. Geralmente, assume-se que as observações de todos os satélites (pseudodistância e/ou fase) são independentes e com mesma variância. Porém, essas considerações são não realísticas. Além disso, a precisão das observações GNSS pode variar de acordo com as condições de medida, tal como o ângulo de elevação do satélite (WANG, 1999).

A adoção incorreta de modelos estocásticos no processamento de dados GNSS, resultará, por exemplo, em estatísticas não confiáveis para as soluções de ambiguidades das DDs no posicionamento relativo e, conseqüentemente, soluções de posicionamento tendenciosas (WANG, 1999).

3.2.1 Modelo estocástico padrão

Normalmente assume-se que todas as medidas da fase da onda portadora ou pseudodistâncias têm a mesma variância (σ_0^2) e ainda que sejam estatisticamente independentes. Então, as observações (ϕ_r^s) são tratadas como independentes e a MVC das observações pode ser formulada como (JIN; WANG; PARK, 2005):

$$\Sigma_{\phi_r^s} = \sigma^2 I, \quad (3.12)$$

em que I é a matriz identidade.

Assim, aplicando a lei de propagação de covariâncias nas equações de simples diferença (SD) da fase (diferença entre duas medidas de fase, Equação 3.3) e dupla diferença (DD) da fase (diferença entre duas simples diferença, Equação 3.4), para o caso do satélite base s_b são dadas, respectivamente, por:

$$\Sigma_{\phi_{SD_{r_1, r_2}^{s_i}}} = 2\sigma^2 I_n, \quad (3.13)$$

$$\Sigma_{\phi_{DD_{r_1, r_2}^{s_b, s_i}}} = 2\sigma^2 \begin{bmatrix} 2 & 1 & \dots & 1 & 1 \\ 1 & 2 & 1 & \dots & 1 \\ 1 & 1 & 2 & \dots & 1 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & 1 & \dots & 1 & 2 \end{bmatrix}. \quad (3.14)$$

Considerando os receptores r_1 e r_2 , bem como os satélites s_i ($i = 1, 2, \dots, n$) o modelo estocástico que envolve observações com variâncias diferentes, porém não correlacionadas, é dados por:

$$\Sigma_{\phi_r^s} = \begin{bmatrix} \sigma_{\phi_{r1}}^{2s_i} & 0 & 0 & 0 & \cdots & 0 & 0 \\ 0 & \sigma_{\phi_{r2}}^{2s_i} & 0 & 0 & \cdots & 0 & 0 \\ 0 & 0 & \sigma_{\phi_{r1}}^{2s_{i+1}} & 0 & \cdots & 0 & 0 \\ 0 & 0 & 0 & \sigma_{\phi_{r2}}^{2s_{i+1}} & \cdots & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & 0 & 0 & \cdots & \sigma_{\phi_{r1}}^{2s_n} & 0 \\ 0 & 0 & 0 & 0 & \cdots & 0 & \sigma_{\phi_{r1}}^{2s_n} \end{bmatrix}. \quad (3.15)$$

Já os modelos estocásticos da SD e da DD da fase, considerando o método do satélite base, são expressos pelas respectivas equações:

$$\Sigma_{\phi_{SD_{r1,r2}}^{s_i}} = \begin{bmatrix} \left(\sigma_{\phi_{r1}}^{2s_i} + \sigma_{\phi_{r2}}^{2s_i} \right) & 0 & 0 & \cdots & 0 \\ 0 & \left(\sigma_{\phi_{r1}}^{2s_{i+1}} + \sigma_{\phi_{r2}}^{2s_{i+1}} \right) & 0 & \cdots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \cdots & \left(\sigma_{\phi_{r1}}^{2s_n} + \sigma_{\phi_{r1}}^{2s_n} \right) \end{bmatrix}, \quad (3.16)$$

$$\Sigma_{\phi_{DD_{r1,r2}}^{s_b,s_i}} = \begin{bmatrix} \left(\sigma_{\phi_{r1,r2}}^{2s_b} + \sigma_{\phi_{r1,r2}}^{2s_i} \right) & \sigma_{\phi_{r1,r2}}^{2s_b} & \sigma_{\phi_{r1,r2}}^{2s_b} & \cdots & \sigma_{\phi_{r1,r2}}^{2s_b} \\ \sigma_{\phi_{r1,r2}}^{2s_b} & \left(\sigma_{\phi_{r1,r2}}^{2s_b} + \sigma_{\phi_{r1,r2}}^{2s_{i+1}} \right) & \sigma_{\phi_{r1,r2}}^{2s_b} & \cdots & \sigma_{\phi_{r1,r2}}^{2s_b} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \sigma_{\phi_{r1,r2}}^{2s_b} & \sigma_{\phi_{r1,r2}}^{2s_b} & \sigma_{\phi_{r1,r2}}^{2s_b} & \cdots & \left(\sigma_{\phi_{r1,r2}}^{2s_b} + \sigma_{\phi_{r1,r2}}^{2s_n} \right) \end{bmatrix}, \quad (3.17)$$

em que, $\sigma_{\phi_{r1,r2}}^{2s_b} = \sigma_{\phi_{r1}}^{2s_b} + \sigma_{\phi_{r2}}^{2s_b}$ e $\sigma_{\phi_{r1,r2}}^{2s_i} = \sigma_{\phi_{r1}}^{2s_i} + \sigma_{\phi_{r2}}^{2s_i}$.

3.2.2 Modelo estocástico em função da variação dos ângulos de elevação dos satélites

Em Silva (2009) foram pesquisados diversos modelos estocásticos em função da variação dos ângulos dos satélites. No caso os formatos das MVCs seguem os padrões das Equações 3.7, 3.8 e 3.9, cujas variâncias das observações podem ser formuladas de acordo com a Equação 3.10 ou com a Equação 3.11:

$$\sigma_{\phi_r^s(t)}^2 = \sigma_{obs}^2 func \quad (3.18)$$

ou

$$\sigma_{\phi_r^s(t)}^2 = \sigma_{obs}^2 func^2, \quad (3.19)$$

em que:

σ_{obs}^2 – variância da observação adotada a priori, correspondendo às medidas de código CA ou P2 ou de fase L1 ou L2.

$func$ – é uma função escrita em função do ângulo de elevação do satélite s com relação ao receptor r e pode ser expressa conforme uma das seguintes expressões (SILVA, 2009; WANG, 1999):

$$func = \frac{1}{\sin(elev_r^s(t))}, \quad (3.20)$$

$$func = \frac{1}{elev_r^s(t)}, \quad (3.21)$$

$$func = e^{-elev_r^s(t)} \text{ ou} \quad (3.22)$$

$$func = \cos(elev_r^s(t)), \quad (3.23)$$

Os modelos estocásticos seguindo as variâncias das Equações 3.18 e 3.19 e as respectivas funções das Equações 3.20 a 3.23 foram implementados e testados por Silva (2009) no posicionamento GNSS absoluto e relativo. No caso, testes também foram realizados envolvendo na modelagem estocástica os efeitos de cintilação ionosférica, o qual será descrito na seção 3.2.3.

3.2.3 Modelo estocástico em função da cintilação ionosférica

Os sinais GPS proporcionam excelentes meios para medir os efeitos de cintilação ionosférica. Atualmente, com a recente tecnologia de receptores GPS, como por exemplo, o GSV4004 da Novatel (VAN DIERENDONK, 2001) e o receptor GNSS da Septentrio, além de modelos para a extração dos parâmetros de cintilação (CONKER et al., 2002), é possível realizar quantificar os efeitos de cintilação.

O rastreamento nos receptores é feito principalmente pelo *Delay Lock Loop* (DLL) e pela *Phase Lock Loop* (PLL). Estes, geralmente embutidos como *hardware* e *software*, asseguram que o código e a fase da onda portadora chegando ao receptor sejam

sincronizados aos códigos e fases gerados no receptor e mantenham-se rastreando os sinais continuamente (LEICK, 1995; WARD, 1996; CONKER et al., 2002).

Assumindo que não há correlação entre a amplitude e a fase da cintilação, a variância do erro de rastreio na saída de PLL pode ser calculada por (KNIGHT; FINN, 1998; HEGARTY, 1997¹ apud CONKER et al., 2002):

$$\sigma_{\phi_{rLi}}^2 = \sigma_{\phi_{sLi}}^2 + \sigma_{\phi_{TLi}}^2 + \sigma_{OSC}^2, \quad (3.24)$$

em que:

$\sigma_{\phi_{sLi}}^2$ – variância da cintilação da fase;

$\sigma_{\phi_{TLi}}^2$ – variância do ruído termal;

σ_{OSC}^2 – variância do oscilador do receptor/satélite (σ_{OSC} assumido ser igual a 0,1 rad).

A variância do ruído termal é dada por:

$$\sigma_{\phi_{TL1}}^2 = \frac{B_n \left[1 + \frac{1}{2\eta(c/n_0)_{L1-CA}(1-2S_4^2(L1))} \right]}{(c/n_0)_{L1-CA}(1-2S_4^2(L1))}, \quad (3.25)$$

em que:

B_n – largura de banda do PLL de L1 de terceira ordem igual a 10 Hz;

$(c/n_0)_{L1-CA}$ – forma fracionária da densidade da razão sinal-ruído (C/N_0), sendo igual a $10^{0,1(C/N_0)_{L1-CA}}$;

η – tempo de integração de pré-deteção, sendo igual a 0,02 s para GPS e 0,002 para *Wide Area Augmentation System* (WAAS);

$S_4(L1) < 0,707$.

Quando não há cintilação, $S_4(L1)$ é igual a zero, a Equação 3.25 torna-se a equação padrão para indicar o ruído termal do receptor. Finalmente, a variância da cintilação da fase para a portadora L1 é dada por (CONKER et al., 2002):

¹ HEGARTY, C. J. *Analytical derivation of maximum tolerable in band interference levels for aviation applications of GNSS*. *Navigation*, v. 44, 1997, p. 25-34.

$$\sigma_{\phi_{\tau L1}}^2 = \frac{\pi T}{k f_n^{p-1} \text{sen}\left(\frac{[2k+1-p]\pi}{2k}\right)}, \text{ para } 1 < p < 2k, \quad (3.26)$$

em que:

T – potência espectral a 1 Hz;

p – inclinação da *Power Spectral Density* (PSD) para $f \gg f_0$, sendo f_0 a frequência correspondente a máxima dimensão da irregularidade na ionosfera;

k – ordem do *loop* (1, 2 ou 3);

f_n – frequência natural do *loop* em Hz.

A Equação 3.18 é válida, desde que $2k - p > 0$ e $p > 1$. Considerando p geralmente entre 1 e 4, a condição é atendida para *loops* de segunda e terceira ordem.

Para um *loop* de terceira ordem $k = 3$, $f_n = 1,91 \text{ Hz}$.

A variância do ruído termal no código CA, na presença de cintilação no código CA é (CONKER et al., 2002):

$$\sigma_{\phi_{\tau}}^2 = \frac{B_n d \left[1 + \frac{1}{\eta(c/n_0)_{L1-CA} (1 - 2S_4^2(L1))} \right]}{2(c/n_0)_{L1-CA} (1 - 2S_4^2(L1))}, \quad (3.27)$$

em que:

B_n – ruído na largura de banda igual a 0,1 Hz;

d – espaçamento correlato em chips CA, de 1 até 0,1.

Outras equações para o código e a fase envolvendo os efeitos de cintilação estão detalhadas em Conker et al. (2002).

Uma maneira de calcular a inclinação do espectro p é através do cálculo da inclinação de uma linha reta obtida a partir de um ajuste linear simples da PSD, o que é feito a partir de *Fast Fourier Transform* (FFT). A cada minuto de dados são calculados valores individuais de p . E a partir de cada valor de p é calculado o valor do comprimento do espectro (T) utilizando a Equação 3.28 (AQUINO et al., 2007):

$$T = \frac{\sigma_{\phi_{60}}^2 (1-p)}{2(25^{(1-p)} - 0,1^{(1-p)})}. \quad (3.28)$$

Outra forma de determinar os valores de p e T é diretamente a partir dos índices de cintilação (σ_ϕ e S_4). Detalhes podem ser vistos em Strangeways (2009) e Elmas, Aquino e Dodson (2010).

3.2.4 Modelo estocástico em função dos ângulos de elevação dos satélites e da cintilação ionosférica

Nessa tese é desenvolvida uma nova modelagem estocástica no processamento de dados GNSS por ponto preciso, a qual considera tanto a variação dos ângulos de elevação dos satélites quanto os efeitos de cintilação ionosférica. Este modelo é expresso da seguinte forma:

$$\sigma_{\phi_{rLi}^s}^2 = \sigma_{obs}^2 \frac{1}{\text{sen}(elev_r^s(t))} + \sigma_{\phi_{sLi}}^2 + \sigma_{\phi_{TLi}}^2 + \sigma_{OSC}^2, \quad (3.29)$$

em que, $\sigma_{\phi_{sLi}}^2$, $\sigma_{\phi_{TLi}}^2$ e σ_{OSC}^2 são os mesmos elementos da Equação 3.16.

Na Equação 3.29, quando $S_4(L1) > 0,707$ o modelo estocástico se torna:

$$\sigma_{\phi_{rLi}^s}^2 = \sigma_{obs}^2 \frac{1}{\text{sen}(elev_r^s(t))}. \quad (3.30)$$

4 PROCESSOS ESTOCÁSTICOS E INTRODUÇÃO A ANÁLISE DE SÉRIES TEMPORAIS

4.1 Processos estocásticos

Um processo estocástico pode ser descrito como um fenômeno estatístico que evolui com o tempo de acordo com leis probabilísticas. Muitos autores usam o termo “processo aleatório” como um sinônimo para processo estocástico. Um processo estocástico pode ser definido como uma coleção de variáveis aleatórias $\{X(t), t \in T\}$, onde T denota o conjunto de tempo em que o processo é definido. As variáveis aleatórias no tempo t podem ser denotadas por $X(t)$ se T é contínuo (normalmente, $-\infty < t < \infty$) e por X_t se T é discreto (normalmente, $t = 0, \pm 1, \pm 2, \dots$). Assim, um processo estocástico é uma coleção de variáveis aleatórias que são ordenadas no tempo. Para um resultado único do processo tem-se somente uma observação em cada variável aleatória e estes valores evoluem no tempo de acordo com leis probabilísticas (GELB et al., 1974; CHATFIELD, 1984).

A definição de processo estocástico ou aleatório está totalmente interligada com a definição de sinais aleatórios. Um sinal pode ser definido como um conjunto de variáveis determinísticas ou aleatórias (dependendo do caso) durante um determinado intervalo de tempo. Alguns exemplos de sinais determinísticos e aleatórios são apresentados na Tabela 4.1 (BROWN; HWANG, 1992):

Tabela 4.1: Exemplos de sinais determinísticos e aleatórios


Sinais Determinísticos	Sinais aleatórios
$x(t) = 10\text{sen}(2\pi t)$	$X(t) = 10 \text{sen}(2\pi t + \theta)$, em que θ é uma variável aleatória uniformemente distribuída entre 0 e 2π ;
$x(t) = \begin{cases} 1, & t \geq 0 \\ 0, & t < 0 \end{cases}$	$X(t) = A \text{sen}(2\pi t + \theta)$ em que θ e A são variáveis aleatórias independentes com distribuições conhecidas
$x(t) = \begin{cases} 1 - e^{-t}, & t \geq 0 \\ 0, & t < 0 \end{cases}$	$X(t)$ = um sinal ruidoso sem uma estrutura determinística particular - que passeia sem objetivo no infinito.

Fonte: Brown e Hwang (1992).

Na Tabela 4.1 verifica-se que os sinais determinísticos não tem qualquer incerteza associada. Eles podem ser descritos por funções matemáticas. É possível escrever a relação funcional entre x e t explicitamente. Entretanto não é realmente necessário, basta saber conceitualmente que há uma relação funcional entre eles. Com relação aos sinais aleatórios da Tabela 4.1 verifica-se que há um elemento de incerteza associado a eles. Estes são formalmente conhecidos como processos aleatórios ou estocásticos. A Figura 4.1 mostra o conjunto de realizações amostrais de um processo

estocástico, o qual é formado por um conjunto de variáveis aleatórias (BROWN; HWANG, 1992):

Figura 4.1: Conjunto de realizações amostrais de um processo aleatório



Fonte: Brown e Hwang (1992).

Pela Figura 4.1 verifica-se que cada sinal ruidoso gerado é chamado de uma realização amostral do processo estocástico. Num determinado tempo t_1 , tem-se as realizações amostrais da variável aleatória $X(t_1)$, por exemplo, na Figura 4.1 são apresentadas quatro realizações amostrais: $X_A(t_1)$, $X_B(t_1)$, $X_C(t_1)$ e $X_D(t_1)$. Se em outro determinado tempo t_2 tem-se mais quatro realizações amostrais. Assim, um conjunto infinito de variáveis aleatórias é gerado pelo processo estocástico $X(t)$ (BROWN; HWANG, 1992).

Uma forma de descrever um processo estocástico é através da função de densidade de probabilidade, tal como para qualquer variável aleatória, mas nesse caso considera-se a dependência no tempo. A probabilidade que $X(t_1)$ tenha valores num certo intervalo é dado pela função de distribuição de probabilidade (GELB et al., 1974):

$$F(x_1, t_1) = Pr[X(t_1) \leq x_1], \quad (4.1)$$

e a correspondente função de densidade de probabilidade dada por:

$$f(x_1, t_1) = \frac{dF(x_1, t_1)}{dx_1}. \quad (4.2)$$

As funções de densidade e de distribuição de probabilidade (Equações 4.1 e 4.2) são adequadas para definir, num senso probabilístico, o intervalo de amplitudes que o processo estocástico exhibe. Para um senso de quão rapidamente os membros do conjunto de realizações de um processo são prováveis de variar é preciso observar a mesma função do membro em mais de um tempo. A probabilidade para a ocorrência de um par de valores em certos intervalos é dada pela função de distribuição de probabilidade conjunta, a qual é expressa por (GELB et al., 1974):

$$F_2(x_1, t_1; x_2, t_2) = Pr[X(t_1) \leq x_1 \text{ e } X(t_2) \leq x_2], \quad (4.3)$$

e a correspondente função de densidade de probabilidade conjunta dada por:

$$f_2(x_1, t_1; x_2, t_2) = \frac{\partial F_2(x_1, t_1; x_2, t_2)}{\partial x_1 \partial x_2}. \quad (4.4)$$

Considerando dois processos estocásticos $X(t)$ e $Y(t)$, uma indicação de características estatísticas conjunta é dada pelas funções de distribuição e de densidade de probabilidade de segunda ordem, respectivamente representadas pelas Equações 4.5 e 4.6.

$$F_2(x, t_1; y, t_2) = Pr[X(t_1) \leq x \text{ e } Y(t_2) \leq y], \quad (4.5)$$

$$f_2(x, t_1; y, t_2) = \frac{\partial F_2(x, t_1; y, t_2)}{\partial x \partial y}. \quad (4.6)$$

Somente os primeiros momentos dessas distribuições são geralmente medidos, os quais são chamados de função de autocorrelação e de função de correlação cruzada e são dados respectivamente, por (GELB et al., 1974; BROWN; HWANG, 1992):

$$R_X(t_1, t_2) = E\{X(t_1)X(t_2)\} = \int_{-\infty}^{\infty} dx_1 \int_{-\infty}^{\infty} dx_2 x_1 x_2 f_2(x_1, t_1; x_2, t_2), \quad (4.7)$$

$$R_{XY}(t_1, t_2) = E\{X(t_1)Y(t_2)\} = \int_{-\infty}^{\infty} dx \int_{-\infty}^{\infty} dy xy f_2(x, t_1; y, t_2). \quad (4.8)$$

A função densidade de probabilidade de segunda ordem não é dependente somente dos tempos de observação t_1 e t_2 , mas também de uma diferença entre eles, assim se t_2 é escrito como (GELB et al., 1974; BROWN; HWANG, 1992):

$$t_2 = t_1 + \tau, \quad (4.9)$$

$f_2(x_1, t_1; x_2, t_2)$ se torna $f_2(x_1, t_1; x_2, t_1 + \tau)$, ou seja é dependente de t_1 e de τ . Então as funções de autocorrelação e correlação cruzada são dadas em função somente de τ , como mostra as Equações 4.10 e 4.11 (GELB et al., 1974; BROWN; HWANG, 1992):

$$R_X(\tau) = E\{X(t_1)X(t_1 + \tau)\}, \quad (\text{caso estacionário}) \quad (4.10)$$

$$R_{XY}(\tau) = E\{X(t_1)Y(t_1 + \tau)\}. \quad (\text{caso estacionário}) \quad (4.11)$$

Qualitativamente se a função de autocorrelação diminui rapidamente com τ , o processo muda rapidamente com o tempo, reciprocamente, se o processo mudar lentamente terá uma função de autocorrelação que diminui lentamente com τ . Então, suspeita-se que há uma informação importante sobre o conteúdo de frequência do processo. Para processos estacionários, há uma importante relação conhecida como “relação Wiener-Khinchine”, expressa por (BROWN; HWANG, 1992):

$$S_X(j\omega) = \mathcal{F}[R_X(\tau)] = \int_{-\infty}^{\infty} R_X(\tau)e^{-j\omega\tau}d\tau, \quad (4.12)$$

em que $\mathcal{F}[\cdot]$ indica a transformada de Fourier e ω tem o significado comum de 2π (frequência em hertz). S_X é chamada de função densidade espectral de potência (*Power Spectral Density* - PSD) ou simplesmente função de densidade espectral.

Alguns exemplos de processos estocásticos são: ruído branco (*white noise*), ruído rosa (*flicker noise*) e caminho aleatório (*random walk*).

Por definição ruído branco (*white-noise*) é aquele que tem sua potência distribuída uniformemente no espectro de potência, ou seja, a PSD é uma constante, ou seja, $S_{rb}(\omega) = \Phi_0$. O nome ruído branco é devido à analogia com o espectro eletromagnético na faixa de luz, no qual a luz branca contém todas as frequências do espectro visível. O ruído branco tem a propriedade de ser um ruído com distribuição Gaussiana (normal), com valor médio nulo e variância constante. A função de autocorrelação é uma função delta (GELB et al., 1974; BROWN; HWANG, 1992; PRESS, 1978):

$$R_{rb}(\tau) = \frac{1}{2\pi} \int_{-\infty}^{\infty} \Phi_0 e^{j\omega\tau} d\omega = \Phi_0 \delta(\tau). \quad (4.13)$$

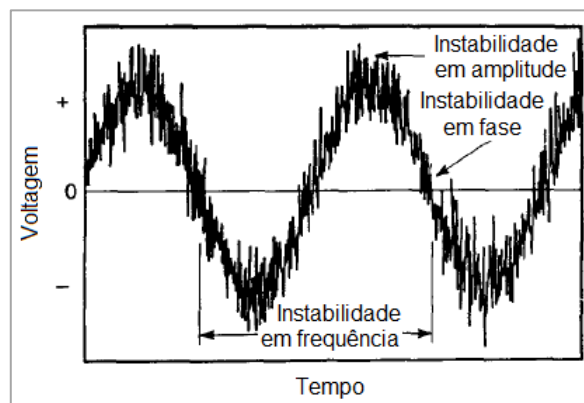
Na definição do delta de Dirac $\delta(\tau)$, o valor da média-quadrática do ruído branco, $R_{rb}(\tau) = \Phi_0\delta(\tau)$, é infinito. Assim, o processo ruído branco não é fisicamente realizável. Ele é um conceito idealizado que, no entanto, serve como uma aproximação muito útil em problemas tais como os que envolvem a largura de banda de um sistema, entre outros (GELB et al., 1974).

Com relação ao processo caminho aleatório (*random walk*), este resulta a partir de sinais não correlacionados (independentes estatisticamente) que são integrados. Sua denominação deriva do exemplo de um homem que caminha a passos de comprimento fixo em direções arbitrárias (GELB et al., 1974). Por definição, é uma integral do processo *white-noise*, ou seja, fazendo a integração de um fator $1/f$ na transformada de Fourier, a função Densidade Espectral do caminho aleatório é dada pelo inverso da frequência ao quadrado ($1/f^2$) (PRESS, 1978):

Já o ruído rosa (*flicker noise*), advém da analogia com o espectro luminoso. A luz vermelha possui a mais baixa frequência do espectro visível e o ruído colorido tem mais energia nas baixas frequências. O ruído rosa tem a propriedade de ser um ruído com distribuição Gaussiana (normal), com valor médio nulo (PRESS, 1978). O ruído rosa é, por definição, aquele cuja função Densidade Espectral de Potência é dada pelo inverso da frequência ($1/f$) (PRESS, 1978):

A caracterização de ruídos pode levar em consideração as instabilidades de frequência, amplitude e fase (tempo) do sinal aleatório. A Figura 4.2 mostra a saída de voltagem de um sinal aleatório de um oscilador mostrando as instabilidades envolvidas.

Figura 4.2: Saída de voltagem de um sinal aleatório (sinal com ruído)




Fonte: Adaptado de Allan et al. (1988).

Os tipos ruídos bem caracterizados em ambos os domínios de frequência e tempo (fase) incluem (GAMBIS, 2002; ALLAN; BARNES, 1981):

- *White noise* (ruído branco) - no domínio do tempo (fase);
- *Flicker noise* (ruído rosa) - no domínio do tempo (fase);
- *Random walk* (caminho aleatório) - no domínio do tempo (fase);
- *Super flicker* (super rosa) - no domínio da frequência;
- *Super white* (super branco) - no domínio da frequência.

A Figura 4.3 mostra a representação dos cinco tipos de ruídos no domínio do tempo.

Figura 4.3: Representação dos tipos de ruídos no domínio do tempo



Fonte: Gambis (2002).

A caracterização dos ruídos pode ser feita no domínio da frequência através, por exemplo, da análise da densidade espectral de potência (Equação 4.12) ou no domínio do tempo (fase) através, por exemplo, do método de variância de Allan. O método de variância de Allan é apresentado na seção 4.1.1.

4.1.1 Caracterização de ruídos a partir da variância de Allan

Cada tipo de ruído tem uma característica única e pode ser identificado através de diferentes técnicas. Uma dessas técnicas é a denominada variância de Allan (*Allan variance* - AVAR), cuja análise é realizada no domínio do tempo e foi proposta por David Allan na década de 1960, a qual consiste numa alteração na fórmula clássica de desvio-padrão, atuando como um filtro para muitos componentes de ruídos (GAMBIS, 2002).


A fórmula clássica do desvio-padrão é dada pela raiz quadrada da variância clássica, a qual é expressa por (GAMBIS, 2002):

$$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2, \quad (4.14)$$

em que, n é o número de dados, x_i é o valor do dado i e μ é a média.

O método de cálculo de variância de Allan pode ser explicado a partir da Figura 4.4, na qual se assume uma amostra de N pontos de dados sendo cada um com um intervalo amostral t_0 . Formando um grupo de n pontos de dados consecutivos ($n < N/2$). Associado a cada grupo tem-se um tempo $\tau = nt_0$ (HOU, 2004; CARVALHO, 2011).

Figura 4.4: Esquema do método de cálculo da variância de Allan



Fonte: Adaptado de Hou (2004).

Assim, a média para cada grupo é dada por (ALLAN et al., 1988):

$$\bar{y}_i = \frac{1}{\tau} \int_{t_i}^{t_i+\tau} y(t) dt = \frac{1}{\tau} [x(t_i + \tau) - x(t_i)] = \frac{1}{\tau} (x_{i+1} - x_i). \quad (4.15)$$

Dessa forma, a variância de Allan é definida como (ALLAN; BARNES, 1981; ALLAN et al., 1988):

$$\sigma_y^2 = \frac{1}{2} E \{ (\bar{y}_{i+1} - \bar{y}_i)^2 \}, \quad (4.16)$$


em que $E\{\cdot\}$ é a esperança matemática.

A expressão para a variância de Allan é rigorosamente dada para um conjunto de dados infinito. Na prática, o conjunto de dados é finito e a variância de Allan pode ser aproximada por (ALLAN et al., 1988):

$$\sigma_y^2(\tau) \approx \frac{1}{2(N-2)} \sum_{i=1}^{N-2} (\bar{y}_{i+1} - \bar{y}_i)^2. \quad (4.17)$$

A Figura 4.5 mostra o gráfico da variância de Allan numa escala de log-log como uma função do tempo amostral τ para um determinado oscilador que exhibe todos os cinco tipos de ruídos mais comuns.

Figura 4.5: Variância de Allan para os cinco tipos de ruídos mais comuns em osciladores



Fonte: Allan et al. (1988).

Na Figura 4.5, a inclinação do ruído super branco e a do super rosa são as mesmas, portanto esses ruídos não são separados nesse tipo de gráfico. Dessa forma, a variância de Allan pode ser modelada pela soma de quatro leis de potência diferentes (ALLAN et al., 1988):

$$\sigma_y^2(\tau) = \sum_{\beta=-2}^1 p_{\beta} \tau^{\beta} = p_{-2} \tau^{-2} + p_{-1} \tau^{-1} + p_0 \tau^0 + p_1 \tau^1, \quad (4.18)$$

em que, $p_{-2} \tau^{-2}$ representa os ruídos super branco e super rosa, $p_{-1} \tau^{-1}$ representa o ruído branco, $p_0 \tau^0$ representa o ruído rosa e $p_1 \tau^1$ representa o ruído caminho aleatório.

Para que haja a distinção entre os ruídos super branco e super rosa (tipos de ruídos que normalmente ocorrem para instabilidades de curto prazo dos osciladores de cristal de quartzo e maser de hidrogênio ativos) pode-se utilizar a variância de Allan modificada, a qual é expressa por (ALLAN; BARNES, 1981; ALLAN et al., 1988):

$$\text{Mod } \sigma_y^2(\tau) \approx \frac{1}{2(N-3n+1)} \sum_{i=1}^{N-3n+1} (\bar{y}'_{i+1} - \bar{y}'_i)^2, \quad (4.19)$$

em que,

$$\bar{y}'_i = \frac{\bar{x}_{i+n} - \bar{x}_i}{\tau} e \quad (4.20)$$


$$\bar{x}_i = \frac{\sum_{k=0}^{n-1} \bar{x}_{i+k}}{n}. \quad (4.21)$$

A expressão da variância de Allan modificada pode também ser expressa em função dos dados iniciais (ALLAN et al., 1988):

$$\text{Mod } \sigma_y^2(\tau) = \frac{1}{2\tau^2 n^2 (N-3n+1)} \sum_{j=1}^{N-3n+1} \left[\sum_{i=j}^{n+j-1} (x_i + 2n - 2x_{i+n} + x_i)^2 \right]^2. \quad (4.22)$$

A Figura 4.6 mostra o gráfico da variância de Allan modificada numa escala de log-log para um determinado oscilador que exhibe todos os cinco tipos de ruídos mais comuns.

Figura 4.6: Variância modificada de Allan para os cinco tipos de ruídos mais comuns em osciladores



Fonte: Allan et al. (1988).

A raiz quadrada da variância de Allan é chamada de desvio-padrão de Allan (ADEV - $\sigma_y(\tau)$) e a raiz quadrada da variância de Allan modificada é denominada desvio-padrão de Allan modificado (MDEV - $Mod \sigma_y(\tau)$).

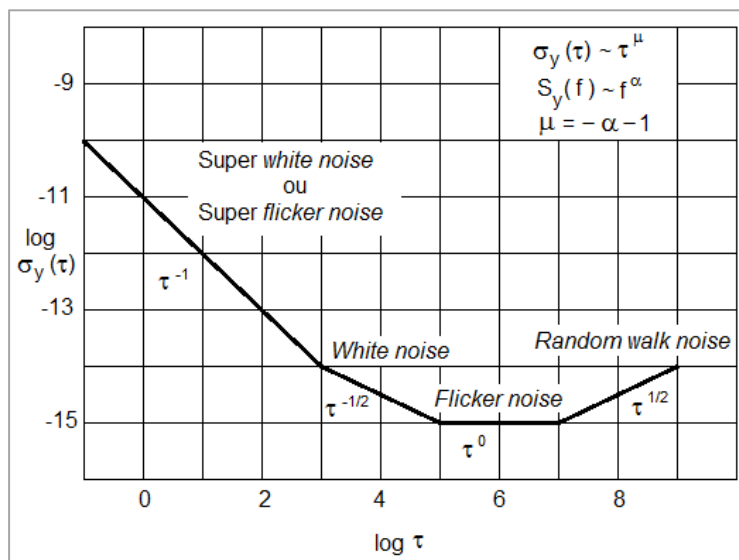
Há uma relação entre o ângulo de inclinação do gráfico de log-log da potência espectral e o ângulo de inclinação do gráfico log-log da variância de Allan, como mostra a **Erro! Fonte de referência não encontrada.**

Tabela 4.2: Relação entre o gráfico de potência espectral e o gráfico de variância de Allan

Tipo de ruído	Ângulo de inclinação do gráfico de log-log da potência espectral (α)	Ângulo de inclinação do gráfico de log-log do Allan variance ($(-\alpha - 1)/2$)
Random Walk	-2	0,5
Flicker	-1	0
White Noise	0	-0,5
Super Flicker	1	-1
Super White	2	-1,5

A Figura 4.7 mostra a caracterização de ruídos a partir da representação log-log do desvio-padrão de Allan (ADEV):

Figura 4.7: Representação log-log do desvio-padrão de Allan



Fonte: Gambis (2002).

4.2 Introdução à análise de séries temporais

Uma série temporal é uma sequência ordenada de observações. Embora a ordenação dos dados seja normalmente através do tempo, ela também pode ser realizada através de outras dimensões, tais como o espaço (WEI, 2006). Considerando que as séries temporais se desenvolvem no tempo ou no espaço, estas podem ser descritas por leis probabilísticas, sendo assim objeto de estudo da teoria dos processos estocásticos (PEREIRA; PAIS; SALES, 1986).

Do ponto de vista da Estatística, o mecanismo gerador da série temporal é considerado como um processo estocástico e a série temporal observada é uma de suas realizações possíveis. Assim, os conceitos de processos estocásticos e séries temporais (não determinísticas) são análogos, respectivamente, aos conceitos de população e de amostra na Estatística Elementar (PEREIRA; PAIS; SALES, 1986).

Uma série temporal pode ser contínua (quando as observações são feitas continuamente no tempo) ou discreta (quando as observações são feitas em tempos específicos, geralmente, igualmente espaçados) (WEI, 2006; MORETTIN; TOLOI, 2004).

Uma das suposições com relação à série temporal é que essa seja estacionária, quando ela se desenvolve aleatoriamente no tempo em torno de uma média constante. Porém, a maioria das séries temporais apresenta alguma forma de não-estacionariedade, por exemplo, tendência. Como a maioria dos procedimentos de análise de séries temporais supõe que estas sejam estacionárias, é necessário transformar os dados originais caso estes se comportem de uma forma não-estacionária (MORETTIN; TOLOI, 2004).

Uma série temporal, com observações $\{Z_t, t = 1, \dots, n\}$, pode ser decomposta como a soma de três componentes não-observáveis (MORETTIN; TOLOI, 2004):

$$Z_t = T_t + S_t + a_t, \quad (4.23)$$

sendo, T_t é a tendência, S_t é a sazonalidade e a_t é a componente aleatória com média zero e variância constante (σ_a^2).

As tendências e as sazonalidades de uma série temporal podem ser obtidas, a partir do ajuste de funções lineares, quadráticas, exponenciais ou trigonométricas, podendo tal estimativa ser realizada a partir do MMQ (MORETTIN; TOLOI, 2004; ROSA, 2008).

Uma forma de analisar uma série temporal (Z_t) é escrevê-la na forma de um sinal ($F(t)$) e um ruído (a_t), como a seguir (MORETTIN; TOLOI, 2004):

$$Z_t = F(t) + a_t, \quad t = 1, \dots, n. \quad (4.24)$$

Existem diversas formas de identificar o tipo de ruído de uma determinada série temporal. Dentre elas pode-se citar a análise a partir do método de variância de Allan (Allan *variance*), o qual é descrito em Allan e Barnes (1981) e El-Sheimy, Hou e Niu (2008), ou a partir da estimação das variâncias desses ruídos, através, por exemplo, do MMQ (AMIRI-SIMKOOEI, 2007).

Atualmente, há diversas ferramentas disponíveis que possibilitam a análise de séries temporais, tanto no domínio temporal (ex. função de autocorrelação, variância de Allan) quanto no domínio de frequências (ex. análise de Fourier, análise espectral) ou em ambos os domínios (ex. análise de *wavelets*). Pode-se citar os softwares AlaVar (EL-SHEIMY; HOU; NIU, 2008), MINITAB (MINITAB, 2005), MatLab (www.mathworks.com), software R (R CORE TEAM, 2012) e Wavelets (<http://atoc.colorado.edu/research/wavelets/>).

4.2.1 Modelos funcional e estocástico de séries temporais de coordenadas GNSS

Os ruídos das séries temporais de coordenadas GNSS são compostos de ruídos, tais como: ruído branco (*white-noise*), ruído rosa (*flicker noise*) e caminho aleatório (*random walk*). A caracterização desses ruídos pode ser obtida através do método de variância de Allan, conforme descrito na seção 4.1.1. Além desse método, pode-se utilizar o método de estimação das componentes de variâncias da MVC das observações baseado no princípio dos mínimos quadrados (AMIRI-SIMKOOEI, 2007; AMIRI-SIMKOOEI; TIBERIUS; TEUNISSEN, 2008).

Ao realizar a estimativa das componentes de variâncias da MVC das observações pelo MMQ, o modelo estocástico das séries temporais se torna mais realístico, já que são considerados os diversos ruídos contidos na mesma.

O modelo funcional de uma série temporal que contém sinais periódicos (ruídos/efeitos não modelados) é representado pela tendência linear ($y_0 + rt$) mais uma soma de q termos trigonométricos individuais (AMIRI-SIMKOOEI; TIBERIUS; TEUNISSEN, 2008):

$$E\{L_b(t)\} = L_0 + rt + \sum_{k=1}^q [a_k \cos(\omega_k t) + b_k \sin(\omega_k t)], \quad (4.25)$$

em que,

L_0 e r , são a interseção e a inclinação da reta;

a_k e b_k são coeficientes dos funções trigonométricas (funções harmônicas);

ω_k é a frequência.

Na Equação 4.25, L_0 , r , a_k e b_k são as incógnitas do ajustamento, sendo que a estimativa desses pode ser feita a partir do MMQ. A determinação da frequência ω_k pode ser realizada utilizando análise espectral (MORETTIN; TOLOI, 2004; WEI, 2006), a partir de periodograma, bem como a partir de análise *wavelets*, baseada em funções senoidais ou também a partir do MMQ, como pode ser visto na seção 4.2.2.

Se o ruído da série temporal das coordenadas GNSS for composto de componentes ruído branco (*white-noise*), ruído rosa (*flicker noise*) e caminho aleatório (*random walk*), com respectivas variâncias (σ_w^2 , σ_f^2 e σ_{rw}^2), o modelo estocástico da série temporal pode ser escrito como (AMIRI-SIMKOOEI; TIBERIUS; TEUNISSEN, 2008):

$$\Sigma_{L_b} = \sigma_w^2 I + \sigma_f^2 Q_f + \sigma_{rw}^2 Q_{rw}, \quad (4.26)$$

em que I é uma matriz identidade quadrada de ordem n (número de dados da série) e Q_f e Q_{rw} são as matrizes cofatoras relacionadas com as componentes ruído branco e caminho aleatório, respectivamente.

A estrutura de Σ_{L_b} é conhecida através de I , Q_f e Q_{rw} , mas σ_w^2 , σ_f^2 e σ_{rw}^2 são valores desconhecidos (incógnitas). Os elementos da matriz Q_f podem ser aproximados por (ZHANG et al., 1997; AMIRI-SIMKOOEI, 2007):

$$q_{ij}^{(f)} = \begin{cases} 9/8 & \text{se } \tau = 0 \\ 9/8 (1 - (\log \tau / \log 2) + 2/24) & \text{se } \tau \neq 0 \end{cases} \quad (4.27)$$

em que, $\tau = |t_j - t_i|$.

No caso da matriz cofatora Q_{rw} , tem-se que no tempo inicial t_0 o processo caminho aleatório é suposto ser nulo. Para dados igualmente espaçados, Q_{rw} pode ser expressa por (AMIRI-SIMKOOEI, 2007):

$$Q_{rw} = f_s^{-1} \begin{bmatrix} 1 & 1 & \dots & 1 \\ 1 & 2 & \dots & 2 \\ \vdots & \vdots & \ddots & \vdots \\ 1 & 2 & \dots & n \end{bmatrix}, \quad \text{com } f_s = (n - 1)/T, \quad (4.28)$$

em que, f_s é a frequência amostral em ano^{-1} e T é a duração (tempo) total de observação.

As variâncias σ_w^2 , σ_f^2 e σ_{rw}^2 podem ser estimadas a partir do método de estimação de componentes de variância baseado no MMQ (seção 4.2.3.1) melhorando assim o modelo estocástico dado pela Equação 4.26 (AMIRI-SIMKOOEI, 2007).

4.2.2 Estimativa das frequências pelo MMQ e identificação da matriz design adequada para o modelo funcional

Considerando o modelo funcional dado pela Equação 4.25, a notação matricial é (AMIRI-SIMKOOEI, 2007; AMIRI-SIMKOOEI; TIBERIUS; TEUNISSEN, 2008):

$$\begin{aligned} E\{L_b\} &= AX + \sum_{k=1}^q A_k X_k, \\ D\{L_b\} &= \Sigma_{L_b}. \end{aligned} \quad (4.29)$$

Na Equação 4.29 L_b é o vetor das observações ($L_b^T = [L_{b_1}, L_{b_2}, \dots, L_{b_n}]$), A é a matriz *design* que contém os dois termos da regressão linear, q é o número de termos trigonométricos, $k = 1, \dots, q$ e A_k e X_k são dados por (AMIRI-SIMKOOEI, 2007; AMIRI-SIMKOOEI; TIBERIUS; TEUNISSEN, 2008):

$$A_k = \begin{bmatrix} \cos(\omega_k t_1) & \text{sen}(\omega_k t_1) \\ \cos(\omega_k t_2) & \text{sen}(\omega_k t_2) \\ \vdots & \vdots \\ \cos(\omega_k t_n) & \text{sen}(\omega_k t_n) \end{bmatrix}, \quad (4.30)$$

$$X_k = \begin{bmatrix} a_k \\ b_k \end{bmatrix}. \quad (4.31)$$

No caso, como a frequência ω_k também é desconhecida, então o problema consiste em encontrar um conjunto de frequências $\omega_1, \dots, \omega_q$, conseqüentemente, a matriz A_k , e em particular o valor q da Equação 4.29. Tal tarefa é realizada a partir da estimação pelo MMQ. Assim, são elaboradas as seguintes hipóteses (iniciando com $i = 1$) (AMIRI-SIMKOOEI, 2007; AMIRI-SIMKOOEI; TIBERIUS; TEUNISSEN, 2008):

$$\begin{aligned} H_0: E\{L_b\} &= AX + \sum_{k=1}^{i-1} A_k X_k \\ &\text{contra} \\ H_a: E\{L_b\} &= AX + \sum_{k=1}^i A_k X_k \end{aligned} \quad (4.32)$$

A detecção e identificação de ω_i são realizadas seguindo os seguintes passos (AMIRI-SIMKOOEI, 2007; AMIRI-SIMKOOEI; TIBERIUS; TEUNISSEN, 2008):

- 1) Passo 1: encontrar a frequência ω_i e a correspondente matriz A_i através do seguinte problema de minimização:

$$\underline{\omega}_i = \arg \min_{\omega_j} \left\| P_{[AA_j]}^\perp L_b \right\|_{\Sigma_{L_b}^{-1}}^2 = \arg \min_{\omega_j} \left\| \hat{V}_a \right\|_{\Sigma_{L_b}^{-1}}^2, \quad (4.33)$$

em que:

$$\|\cdot\|_{\Sigma_{L_b}^{-1}}^2 = (\cdot) \Sigma_{L_b}^{-1} (\cdot);$$

$$\bar{A} = [A \quad A_1 \quad \dots \quad A_{i-1}];$$

\hat{V}_a é o vetor de resíduos do MMQ sob a hipótese alternativa;

A_j tem a mesma estrutura que a matriz A_k (Equação 4.30).

O valor de ω_i que minimiza o critério dado pela Equação 4.33 é fixado para construir A_i . O problema de minimização (Equação 4.33) é equivalente ao problema de maximização (TEUNISSEN, 2000², p.96 apud AMIRI-SIMKOOEI; TIBERIUS; TEUNISSEN, 2008):

² TEUNISSEN, P. J. G. **Adjustment theory: an introduction**. In: *Series on Mathematical Geodesy and Positioning*. Delft University Press. 2000.

$$\underline{\omega}_i = \arg \max_{\omega_j} \left\| P_{\bar{A}_j}^\perp L_b \right\|_{\Sigma_{L_b}^{-1}}^2, \quad \text{com } \bar{A}_j = P_{\bar{A}}^\perp A_j, \quad (4.34)$$

em que:

$$P_{\bar{A}}^\perp = I - \bar{A}(\bar{A}^T \Sigma_{L_b}^{-1} \bar{A})^{-1} \bar{A}^T \Sigma_{L_b}^{-1}, \quad (4.35)$$

$$P_{\bar{A}_j}^\perp = \bar{A}_j \left(\bar{A}_j^T \Sigma_{L_b}^{-1} \bar{A}_j \right)^{-1} \bar{A}_j^T \Sigma_{L_b}^{-1}. \quad (4.36)$$

A Equação 4.34 pode ser também expressa como:

$$\underline{\omega}_i = \arg \max_{\omega_j} \hat{V}_0^T \Sigma_{L_b}^{-1} A_j (A_j^T \Sigma_{L_b}^{-1} A_j)^{-1} A_j^T \Sigma_{L_b}^{-1} \hat{V}_0, \quad (4.37)$$

em que, $\hat{V}_0 = P_{\bar{A}}^\perp L_b$ é o vetor de resíduos dos mínimos quadrados sob a hipótese nula (H_0).

- 2) Passo 2: testar as hipóteses na Equação 4.32, considerando que $\Sigma_{L_b} = \sigma^2 I$, com σ^2 desconhecida, utilizando o seguinte teste estatístico:

$$T_2 = \frac{\left\| P_{\bar{A}_i}^\perp \right\|^2}{2\hat{\sigma}_a^2} = \frac{\hat{V}_0^T A_i (A_i^T P_{\bar{A}}^\perp A_i)^{-1} A_i^T \hat{V}_0}{2\hat{\sigma}_a^2}, \quad (4.38)$$

em que, $\bar{A}_i = P_{\bar{A}}^\perp A_i$ e o estimador para a variância ($\hat{\sigma}_a^2$) têm que ser calculados sob a hipótese alternativa (H_a). Sob a hipótese nula (H_0), o teste estatístico tem uma distribuição de Fisher central (AMIRI-SIMKOOEI; TIBERIUS; TEUNISSEN, 2008):

$$T_2 \sim F(2, n - u - 2i). \quad (4.39)$$

Se H_0 é rejeitada, o valor de i é incrementado e o mesmo procedimento é realizado até encontrar outra frequência ω_i .

4.2.3 Estimativa das componentes de variância

Os resultados advindos do ajustamento das observações GNSS são diretamente influenciados pela MVC (Σ_{L_b}) das observações (L_b). Sendo assim, é de grande importância a adoção correta dessa MVC. Um processo a ser realizado é subdividir a MVC em componentes de variância (σ_k^2) e matrizes cofatoras (Q_k), sendo as primeiras incógnitas e as outras a parte conhecida da MVC:

$$\Sigma_{L_b} = \sum_{k=1}^q \sigma_k^2 Q_k, \quad (4.40)$$

em que q é o número de componentes a serem estimadas.

Existem diversos métodos para a estimativa de componentes de variância, por exemplo (GRODECKI, 1997; SEARLE, 1995; AMIRI-SIMKOOEI; TIBERIUS; TEUNISSEN, 2008):

- *Analysis of Variance* (ANOVA);
- *Minimum Norm Quadratic Unbiased Estimation* (MINQUE);
- *Best Invariant Quadratic Unbiased Estimation* (BIQUE);
- Estimativa a partir de máxima-verossimilhança;
- Estimativa a partir de máxima-verossimilhança marginal ou também chamado de Estimativa a partir de máxima-verossimilhança restrita;
- Estimativa de componentes de variância a partir do MMQ.

Nesta tese será abordada a Estimativa de componentes de variância a partir do MMQ, a qual é apresentada na seção 4.2.3.1.

4.2.3.1 Estimativa de componentes de variância a partir do MMQ

Nessa seção é mostrado como se pode formular um sistema linear de equações de observações para as componentes de variância incógnitas. Seja o seguinte modelo linear (AMIRI-SIMKOOEI, 2007; 2010):

$$\begin{aligned} E\{L_b\} &= AX, \\ D\{L_b\} &= \Sigma_{L_b}, \end{aligned} \quad (4.41)$$

onde, L_b é o vetor de observações, $E\{\cdot\}$ é o operador de esperança matemática, $D\{\cdot\}$ é o operador de dispersão e Σ_{L_b} é dado por (AMIRI-SIMKOOEI, 2007; 2010):

$$\Sigma_{L_b} = \Sigma_{L_0} + \sum_{k=1}^p \sigma_k Q_k. \quad (4.42)$$

O modelo linear na Equação 4.41 contém dois conjuntos de incógnitas:

- Vetor de parâmetros X e
- Vetor de componentes de variâncias $\sigma_k, k = 1, \dots, p$.

É objetivo da estimativa de componentes de variância (ECV) construir um estimador para as componentes de variância incógnitas. Então, a matriz A ($n \times u$) é assumida conhecida e tem *rank* coluna completo. As matrizes cofatoras Q_k ($k = 0, \dots, p$), também são assumidas conhecidas e sua soma ponderada ($\Sigma_{L_0} + \sum_{k=1}^p \sigma_k Q_k$) é assumida ser definida positiva. A matriz Q_0 é a parte conhecida da matriz covariância Σ_{L_b} (AMIRI-SIMKOOEI, 2007; 2010).

A seguir é apresentada uma transformação do vetor de observação L_b , tal que a Equação 4.41 tenha uma forma simplificada.

Seja B a matriz base do espaço nulo de A^T com dimensão $n \times (n - u)$, onde $n - u$ são as colunas linearmente independentes do espaço nulo de A^T : $A^T B = 0$ ou $B^T A = 0$. Então, a seguinte correspondência entre L_b e $(\hat{X}^T, t^T)^T$ existe (AMIRI-SIMKOOEI, 2007; 2010):

$$\begin{bmatrix} \hat{X} \\ t \end{bmatrix} = \begin{bmatrix} \Sigma_{\hat{X}} A^T \Sigma_{L_b}^{-1} \\ B^T \end{bmatrix} L_b \quad \Leftrightarrow \quad y = [A, \Sigma_{L_b} B \Sigma_t^{-1}] \begin{bmatrix} \hat{X} \\ t \end{bmatrix} \quad (4.43)$$

ou

$$\begin{bmatrix} \hat{X} \\ t \end{bmatrix} = \begin{bmatrix} \Sigma_{\hat{X}} A^T \Sigma_{L_b}^{-1} \\ B^T \end{bmatrix} L_b \quad \Leftrightarrow \quad \begin{aligned} L_b &= A \hat{X} \\ L_b &= \Sigma_{L_b} B \Sigma_t^{-1} t \end{aligned} \quad (4.44)$$

Ao aplicar a transformação, dada pelas Equações 4.43 e 4.44, na Equação 4.41, tem-se o modelo linear simplificado (AMIRI-SIMKOOEI, 2007; 2010):

$$\begin{aligned}
E\{L_b\} &= AX \Rightarrow E\left\{\begin{bmatrix} \hat{X} \\ t \end{bmatrix}\right\} = \begin{bmatrix} X \\ 0 \end{bmatrix}, \\
D\{L_b\} &= \Sigma_{L_b} \Rightarrow D\left\{\begin{bmatrix} \hat{X} \\ t \end{bmatrix}\right\} = \begin{bmatrix} \Sigma_{\hat{X}} & 0 \\ 0 & \Sigma_t \end{bmatrix} = \begin{bmatrix} (A^T \Sigma_{L_b}^{-1} A)^{-1} & 0 \\ 0 & B^T \Sigma_{L_b} B \end{bmatrix}. \quad (4.45)
\end{aligned}$$

A partir das Equações 4.41 e 4.45 e, considerando que $E\{t\} = 0$ e $D\{t\} = E\{tt^T\} = B^T \Sigma_{L_b} B$, segue que a equação de observação para as componentes de variância incógnitas (σ_k) é dada por (AMIRI-SIMKOOEI, 2007; 2010):

$$E\{tt^T - B^T Q_0 B\} = \sum_{k=1}^p \sigma_k B^T Q_k B, \quad (4.46)$$

cuja matriz equação consiste de b^2 equações de observações escalares, sendo $b = n - u$ o número de redundância do modelo linear dado pela Equação 4.41.

A solução do ajustamento pode ser obtida a partir de duas maneiras: utilizando o operador vh nas matrizes da Equação 4.46 ou diretamente a partir dos elementos da matriz N e vetor, ou seja, das equações normais.

A solução a partir do operador vh consiste em primeiramente transformar a matriz de equação de observação (Equação 4.46) em um vetor de equações de observações, assim (AMIRI-SIMKOOEI, 2007; 2010):

$$E\{L_{b_{vh}}\} = A_{vh} \sigma, \quad (4.47)$$

em que:

$$L_{b_{vh}} = vh(tt^T - B^T \Sigma_{L_0} B), \quad (4.48)$$

$$A_{vh} = [vh(B^T Q_1 B), \dots, vh(B^T Q_p B)], \quad (4.49)$$

$$\sigma = [\sigma_1, \dots, \sigma_p]^T. \quad (4.50)$$

A solução é dada por:

$$\hat{\sigma} = (A_{vh}^T P_{vh} A_{vh})^{-1} A_{vh}^T P_{vh} L_{b_{vh}}. \quad (4.51)$$

A solução a partir das equações normais, ou seja:

$$X = N^{-1}U, \quad (4.52)$$

é obtida a partir, diretamente dos elementos da matriz N (n_{kl}) e dos elementos do vetor U (u_{kl}) (AMIRI-SIMKOOEI, 2007; 2010):

$$n_{kl} = \frac{1}{2} \text{traço}(Q_k \Sigma_{L_b}^{-1} P_A^\perp Q_l \Sigma_{L_b}^{-1} P_A^\perp), \quad (4.53)$$

$$u_{kl} = \frac{1}{2} V^T \Sigma_{L_b}^{-1} Q_k \Sigma_{L_b}^{-1} V - \frac{1}{2} \text{traço}(Q_k \Sigma_{L_b}^{-1} P_A^\perp Q_l \Sigma_{L_b}^{-1} P_A^\perp), \quad (4.54)$$

em que, V é o vetor dos resíduos e P_A^\perp é o projetor ortogonal no espaço da matriz *design* A , dados, respectivamente, por:

$$V = P_A^\perp L_b, \quad (4.55)$$

$$P_A^\perp = I - A(A^T \Sigma_{L_b}^{-1} A)^{-1} A^T \Sigma_{L_b}^{-1}. \quad (4.56)$$

4.2.4 Identificação do modelo estocástico adequado

Como visto na seção 4.2.1, a matriz Σ_{L_b} é escrita em função das matrizes de I , Q_f e Q_{rw} , as quais são conhecidas e em função das variâncias σ_w^2 , σ_f^2 e σ_{rw}^2 , as quais são incógnitas. O problema consiste em determinar essas variâncias através do método de estimação de variâncias das componentes pelo MMQ. A determinação do modelo estocástico apropriado (determinação de Σ_{L_b}) é realizada através de um teste estatístico de hipóteses sobre esse modelo. Quando não há uma especificação errada no modelo funcional $E\{L_b\} = AX$ são elaboradas, por exemplo, as seguintes hipóteses (AMIRI-SIMKOOEI, 2007):

$$\begin{aligned} H_0: \Sigma_{L_b} &= \sigma_w^2 I \\ &\text{contra} \\ H_a: \Sigma_{L_b} &= \sigma_w^2 I + C_y \nabla \end{aligned} \quad (4.57)$$

em que, C_y é uma matriz cofatora conhecida, por exemplo, Q_f ou Q_{rw} , e ∇ é um parâmetro de variância incógnito. Considerando a hipótese nula H_0 , em que há somente uma

componente de variância no modelo estocástico, ou seja, $\Sigma_{L_b} = \sigma_w^2 I$, pode-se obter o seguinte teste estatístico (AMIRI-SIMKOOEI, 2007):

$$\underline{w} = \frac{b \hat{V}^T C_y \hat{V} - \text{traço}(C_y P_A^\perp) \hat{V}^T \hat{V}}{\sigma_w^2 [2b^2 \text{traço}(C_y P_A^\perp C_y P_A^\perp) - 2b \text{traço}(C_y P_A^\perp)]^{1/2}}, \quad (4.58)$$

em que $b = n - u$ é a redundância do modelo funcional e \hat{V} o vetor de resíduos dos mínimos quadrados sob a hipótese nula H_0 .

São calculados diferentes testes estatísticos (\underline{w}) para as diferentes hipóteses alternativas H_a , isto é, diferentes valores para a matriz cofatora C_y , e selecionado o máximo valor para \underline{w} (AMIRI-SIMKOOEI, 2007).

4.2.5 Introdução à análise multivariada de séries temporais

A análise multivariada de séries temporais é o estudo de modelos estatísticos e métodos de análise que descrevem a relação entre várias séries temporais. Para muitas séries temporais, uma análise mais efetiva pode ser obtida considerando uma série temporal individual como componentes de um vetor de séries temporais e analisar as séries juntamente, ou seja, considerando k séries temporais num determinado tempo t , denotadas pelos vetores $z_{1t}, z_{2t}, \dots, z_{kt}$, pode-se escrever um vetor de séries temporais da seguinte forma: $Z_t = [z_{1t}, z_{2t}, \dots, z_{kt}]'$. Tais processos multivariados surgem quando várias séries temporais são observadas simultaneamente (mesmo tempo t) (BOX; JENKINS; REINSEL, 2008).

Nesse caso, é necessário descrever não somente as propriedades individuais de cada série, mas também as possíveis relações (cruzadas) entre elas, através da análise de correlação entre as componentes do vetor de séries temporais. Os objetivos da análise e modelagem conjunta das séries são de compreender as relações dinâmicas ao longo do tempo entre as séries e de melhorar a precisão das previsões para séries individuais utilizando a informação adicional das relações entre cada série (BOX; JENKINS; REINSEL, 2008).

Um processo estocástico multivariado pode ser descrito de uma forma simples através dos momentos do processo, que no caso bivariado os momentos até

segunda ordem consistem de média, função de covariância e função de covariância cruzada. (PEREIRA; PAES; SALES, 1986):

A análise multivariada de séries temporais pode ser encontrada em referências tais como Lütkepohl³ (2007), Wei (2006) e Reinsel⁴ (1997).

A estimativa de componentes de variância para o caso multivariado de séries temporais de coordenadas GNSS pode ser encontrada em Amiri-Simkooei (2007, 2008). Uma introdução ao assunto é apresentada na seção 4.2.5.1.

4.2.5.1 Introdução à estimativa de componentes de variância: caso multivariado

Em geral, assume-se que os valores de ruído branco e de ruído rosa são diferentes para séries temporais distintas. Considerando o seguinte modelo matemático para r séries temporais:

$$\begin{aligned} E\{L_{b_i}\} &= AX_i, \\ D\{L_{b_i}, L_{b_j}\} &= \underline{\hat{\Sigma}} = \sigma_{ij}^w I + \sigma_{ij}^f Q_f, \end{aligned} \quad (4.59)$$

em que:

$i, j = 1, 2, \dots, r$;

L_{b_i} – vetor de observações ($n \times 1$) para a série temporal i ;

X_i – vetor de parâmetros incógnitos ($u \times 1$) para a série temporal i ;

n – número de observações da série temporal i ;

u – número de parâmetros da série temporal i ;

A – matriz *design*;

I e Q_f – matrizes cofatoras ($u \times u$) relacionadas, respectivamente, ao ruído branco e ao ruído rosa, idênticas para todas as séries temporais;

$D\{\underline{y}_i, \underline{y}_j\} = \underline{\hat{\Sigma}}$ – matriz de covariância (cruzada) entre as séries i e j ($nr \times nr$).

³ LÜTKEPOHL, H. *New introduction to multiple time series analysis*. Berlin: Springer, 2007. 764p.

⁴ REINSEL, G. C. *Elements of multivariate time series analysis*. 2. ed. New York: Springer, 1997. 357p.

Matricialmente tem-se que os vetores totais dos parâmetros incógnitos, das observações e dos resíduos são dados por:

$$X_{n \times r} = [x_1 \quad x_2 \quad \cdots \quad x_r], \quad (4.60)$$

$$Y_{m \times r} = [y_1 \quad y_2 \quad \cdots \quad y_r], \quad (4.61)$$

$$V_{n \times r} = [v_1 \quad v_2 \quad \cdots \quad v_r]. \quad (4.62)$$

O número total de incógnitas do modelo estocástico, que corresponde ao número de elementos de variância (σ_{ij}^w e σ_{ij}^f), é expresso por:

$$n_{total} = 2 [r(r + 1)/2] = r(r + 1). \quad (4.63)$$

As componentes de variâncias (σ_{ij}^w e σ_{ij}^f) de todo o modelo pode ser expresso matricialmente ($r \times r$) da seguinte forma:

$$\Sigma_w = \begin{bmatrix} \sigma_{11}^w & \sigma_{12}^w & \cdots & \sigma_{1r}^w \\ \sigma_{12}^w & \sigma_{22}^w & \cdots & \sigma_{2r}^w \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{1r}^w & \sigma_{2r}^w & \cdots & \sigma_{rr}^w \end{bmatrix}, \quad (4.64)$$

$$\Sigma_f = \begin{bmatrix} \sigma_{11}^f & \sigma_{12}^f & \cdots & \sigma_{1r}^f \\ \sigma_{12}^f & \sigma_{22}^f & \cdots & \sigma_{2r}^f \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{1r}^f & \sigma_{2r}^f & \cdots & \sigma_{rr}^f \end{bmatrix}. \quad (4.65)$$

A estimativa da matriz de covariâncias ($\hat{\Sigma}$) é obtida a partir do método de estimativa de componentes de variância pelo MMQ (similar ao da seção 4.2.3) e é dada por:

$$\hat{\Sigma} = \frac{\hat{V}^T Q^{-1} \hat{V}}{m-n}, \quad (4.66)$$

em que, Q pode ser I ou Q_f e \hat{V} é dado por:

$$\underline{\hat{V}} = P_A^\perp \underline{Y} = [\hat{v}_1 \quad \hat{v}_2 \quad \cdots \quad \hat{v}_r], \quad i = 1, 2, \dots, r, \quad (4.67)$$

em que, \hat{v}_i são os resíduos estimados dos mínimos quadrados da série temporal i obtido com $\underline{\hat{v}} = P_A^\perp L_{b_i}$.

Para as séries temporais i e j , a MVC dos vetores estimados $[\hat{\sigma}_{ij}, \hat{\sigma}_{ii}, \hat{\sigma}_{jj}]$ é dada por:

$$Q_{\hat{\sigma}}^{ij} = \frac{1}{m-n} \begin{bmatrix} \sigma_{ii}\sigma_{jj} + \sigma_{ij}^2 & 2\sigma_{ii}\sigma_{ij} & 2\sigma_{jj}\sigma_{ij} \\ 2\sigma_{ii}\sigma_{ij} & \sigma_{ii}^2 & 2\sigma_{ij}^2 \\ 2\sigma_{jj}\sigma_{ij} & 2\sigma_{ij}^2 & \sigma_{jj}^2 \end{bmatrix}, \quad i = 1, 2, \dots, r. \quad (4.68)$$

O coeficiente de correlação entre as séries temporais i e j é expresso por:

$$\hat{\rho}_{ij} = \frac{\hat{\sigma}_{ij}}{\sqrt{\hat{\sigma}_{ii}\hat{\sigma}_{jj}}} = \frac{\hat{\sigma}_{ij}}{\hat{\sigma}_i\hat{\sigma}_j}, \quad i = 1, 2, \dots, r. \quad (4.69)$$

Mais detalhes sobre a análise multivariada de séries temporais de coordenadas GNSS podem ser obtidos em Amiri-Simkoei (2008).

5 METODOLOGIA

Os experimentos envolvidos na modelagem estocástica do processamento de dados GNSS foram realizados a partir de dados obtidos de receptores GNSS pertencentes à rede CIGALA/CALIBRA localizada no Brasil, os quais fornecem parâmetros necessários para o cálculo de variâncias em função dos efeitos de cintilação ionosférica (modelo de Conker - veja seção 3.2.3). Os receptores PolaRx (Septentrio) da rede CIGALA/CALIBRA coletam dados GNSS a uma taxa de 50 Hz sendo gerados arquivos horários, a partir dos quais podem se obter arquivos de observações GNSS no formato RINEX (*Receiver INdependent EXchange format*) e também arquivos de índices de cintilação e TEC, denominados de ISMR (*Ionospheric Scintillation Monitor Receiver*). Os arquivos ISMR fornecem os índices de cintilação S4 e Phi60, além de outros parâmetros que permitem o cálculo das variâncias das observações GNSS em função dos efeitos de cintilação ionosférica. Tanto as observações GNSS (formato RINEX) quanto os dados advindos dos arquivos ISMR, utilizados nos experimentos desta tese, foram gerados com taxa de coleta de 60 segundos.

Para o cálculo das variâncias em função da cintilação ionosférica foi utilizado o software Tracking Jitter, o qual calcula as variâncias em função de parâmetros advindos de receptores GSV4004 da Novatel (SILVA, 2009). O aplicativo *Tracking Jitter* contém diversas opções de processamento relacionadas com o cálculo das variâncias em função da cintilação, podendo-se destacar a junção dos arquivos binários (Append Files), transformação dos dados binários para ASCII (ParseIsmr), extração dos arquivos RINEX de observação (BinaryToRinex), utilizando o aplicativo “Converter4” da empresa Novatel, e cálculo das variâncias de cintilação com base nas equações implementadas (seção 3.2.3). Nessa tese foi utilizada apenas a opção de cálculo de variâncias em função da cintilação, a qual foi modificada para realizar leituras dos arquivos ISMR advindos da rede CIGALA/CALIBRA com o objetivo de obter os parâmetros necessários para o cálculo das variâncias. Como os arquivos ISMR nesse caso são horários foi também implementado um aplicativo em C/C++ para juntar vários arquivos em um único arquivo diário.

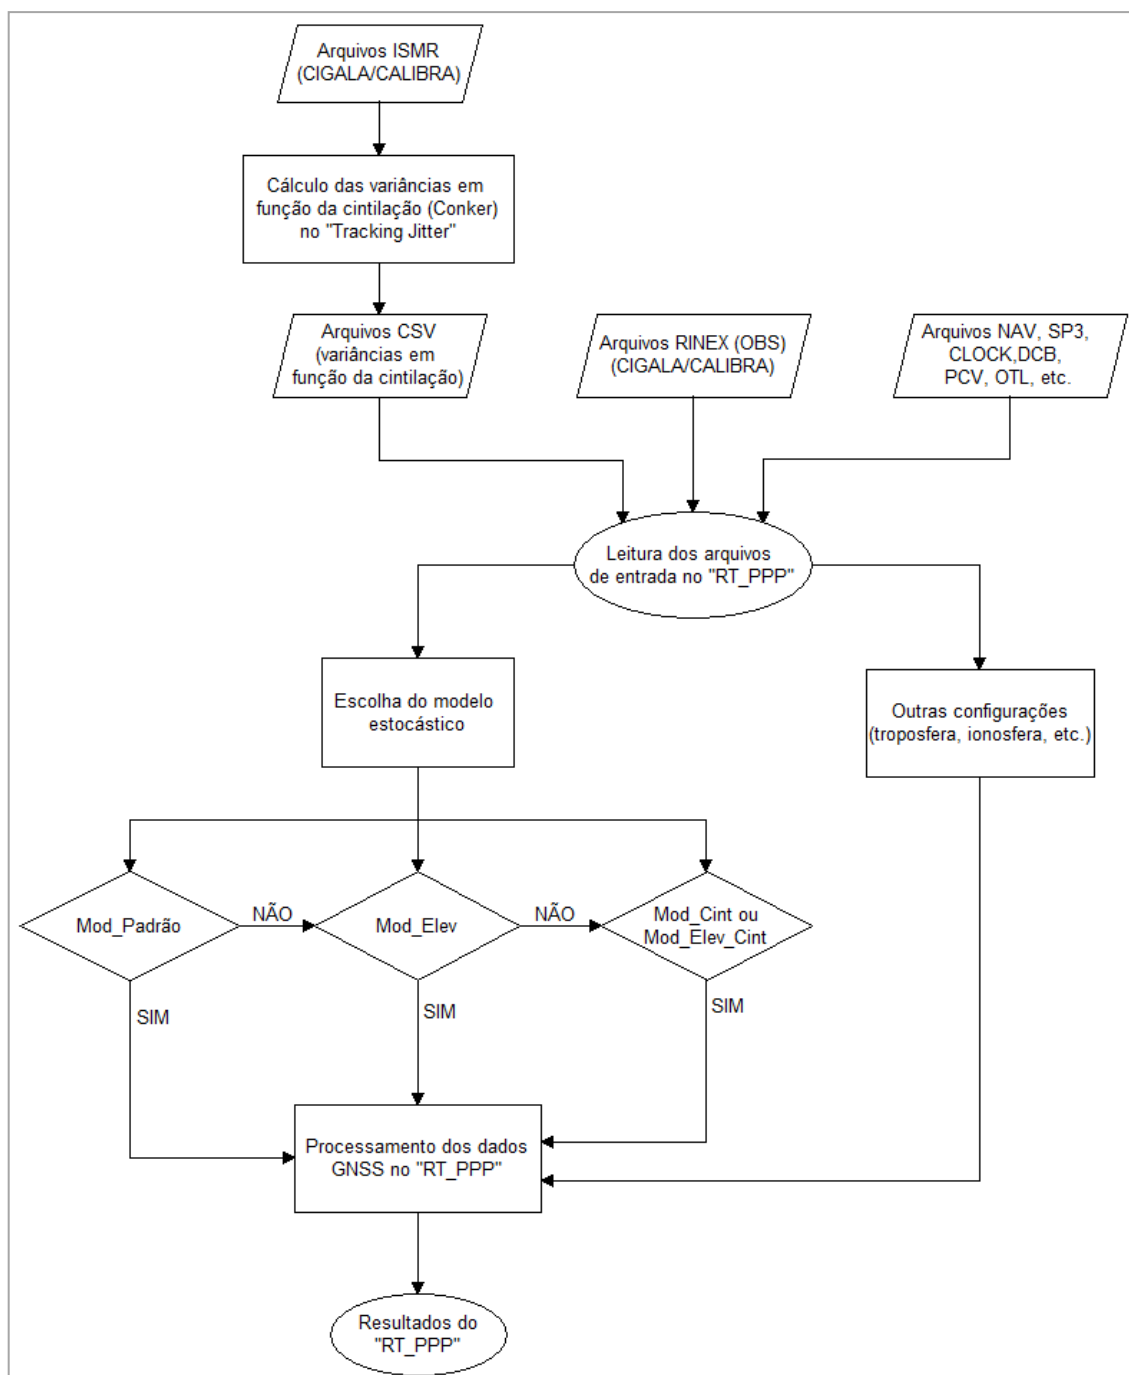
O processamento dos dados GNSS considerando os efeitos de cintilação ionosférica na modelagem estocástica foi realizado no software RT_PPP (*Real Time PPP*), o qual permite pós-processar os dados no modo PPP (MARQUES, 2012). A modelagem estocástica em função da cintilação ionosférica e também a modelagem em função da variação dos ângulos de elevação dos satélites foram implementadas e adaptadas no RT_PPP baseado nos algoritmos já implementados no software de posicionamento por ponto simples (absoluto) denominado PP_Sc (SILVA, 2009).

O software RT_PPP permite realizar o processamento PPP (em tempo real ou pós-processado) no modo estático ou cinemático utilizando Filtro de Kalman e o controle de qualidade a partir do método DIA. Para o caso da ionosfera, pode-se utilizar a combinação *ion-free* ou a estimativa do efeito da ionosfera tratando-a como um parâmetro estocástico. No caso da troposfera, tem-se a opção corrigir a partir de um modelo matemático, por exemplo, a partir do modelo de Hopfield, ou de estimá-la juntamente com os outros parâmetros. Diversos modelos matemáticos são implementados no software RT_PPP podendo-se citar: carga de marés oceânicas e marés de corpos terrestres, PCV (*Phase Center Variation*) da antena do receptor e do satélite, fase *windup*, atraso de hardware (DCB - *Delay Code Bias*), entre outros (MARQUES, 2012). Com relação as ambiguidades da fase onda portadora, o RT_PPP estima-as como solução *float* (MONICO, 2008).

Nos experimentos realizados nesta tese (seção 6.1) foram realizados utilizando o software RT_PPP pós-processado no modo cinemático. Em todos os experimentos utilizou-se efemérides e relógios precisos, arquivos de DCBs, arquivos de marés oceânicas e terrestres, modelo de Hopfield (correção da troposfera), combinação *ion-free* (correção da ionosfera) e máscara de elevação de 10 graus.

A Figura 5.1 mostra o fluxograma representando resumidamente as etapas envolvidas no processamento de dados GNSS no software RT_PPP.

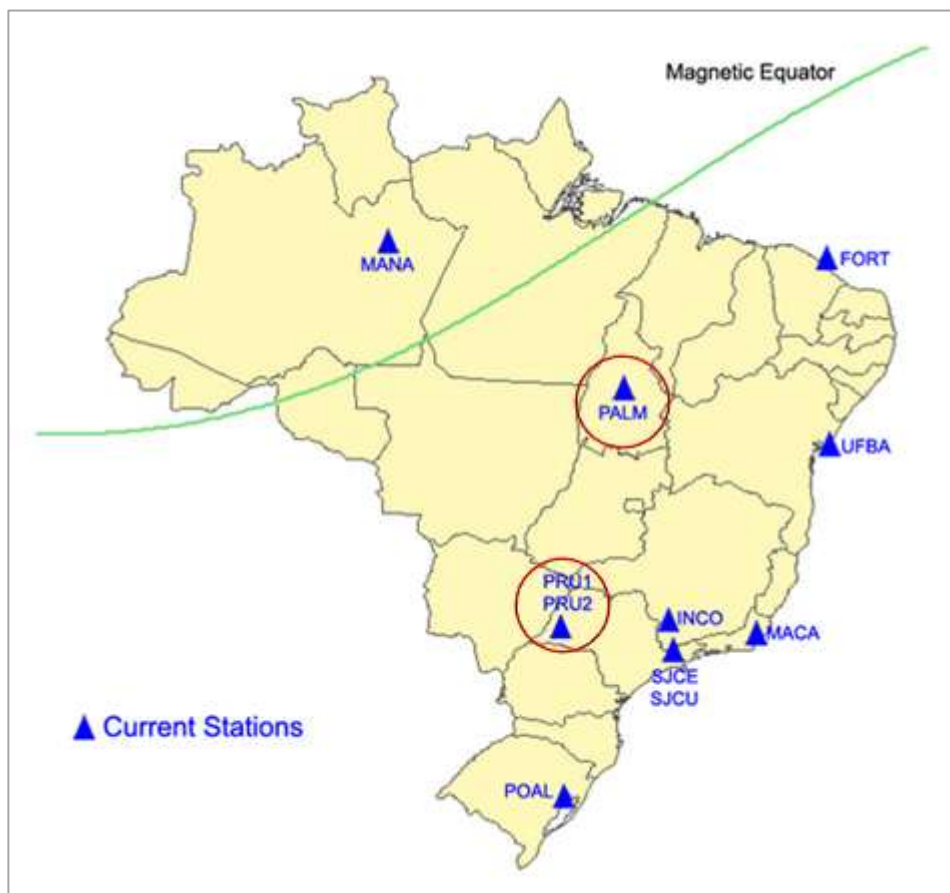
Figura 5.1: Fluxograma da metodologia envolvida no processamento de dados GNSS no software RT_PPP



Na Figura 5.1 os dados de entrada são os arquivos de variâncias em função da cintilação ionosférica (seção 3.2.3) obtidos a partir do software Tracking Jitter, arquivos de observação, efemérides, etc. Após a leitura dos arquivos é verificada as configurações do processamento de dados GNSS (correção da troposfera, da ionosfera, etc.), qual o modelo estocástico a ser utilizado: Mod_Padrão, Mod_Elev, Mod_Cint ou Mod_Elev_Cint (seções 3.2.1 a 3.2.4) e por fim é realizado o processamento dos dados.

Para realizar os experimentos relacionados à modelagem estocástica no processamento de dados GNSS foram utilizados dados das estações PALM e PRU1 da rede CIGALA/CALIBRA, cuja localização é mostrada na Figura 5.2.

Figura 5.2: Localização das estações PALM e PRU1 utilizadas nos processamentos de dados GNSS



No caso das séries temporais de coordenadas GNSS, foram utilizadas séries temporais da rede SIRGAS-CON e séries temporais de estações na região brasileira processadas pelo JPL.


Com relação às séries temporais do SIRGAS-CON, estas foram obtidas a partir de arquivos com soluções semanais no formato SINEX (*Solution (Software/technique) INdependent EXchange format*), os quais contêm, dentre outras informações, as coordenadas cartesianas estimadas (X , Y e Z) e respectivas MVCs. As discrepâncias nas coordenadas cartesianas (DX , DY e DZ) foram calculadas com relação a média das coordenadas (\bar{X} , \bar{Y} e \bar{Z}) considerando todo o período. Em seguida, estes erros foram transformados para o SGL obtendo assim as coordenadas E , N e U em função do tempo. Neste caso, a origem do SGL fica vinculada ao ponto médio, obtido a partir da média das

coordenadas cartesianas. Foram utilizadas as séries temporais das seguintes estações: BRAZ (05/01/2000 a 06/03/2013), MAPA (13/01/2006 a 06/03/2013), POAL (21/01/2000 a 06/03/2013), PPTE (04/01/2006 a 06/03/2013) e RECF (21/01/2000 a 06/03/2013).

As séries temporais do JPL já são fornecidas para as componentes E, N e U (ftp://sideshow.jpl.nasa.gov/pub/JPL_GPS_Timeseries/repro2011b/). Nesse caso, as séries temporais são fornecidas em arquivos com soluções diárias. Foram utilizados dados das estações BRAZ (02/01/2000 a 09/03/2013), BRFT (16/09/2005 a 30/03/2013), CHPI (08/05/2003 a 07/03/2013) e SAVO (08/10/2008 a 30/03/2013).

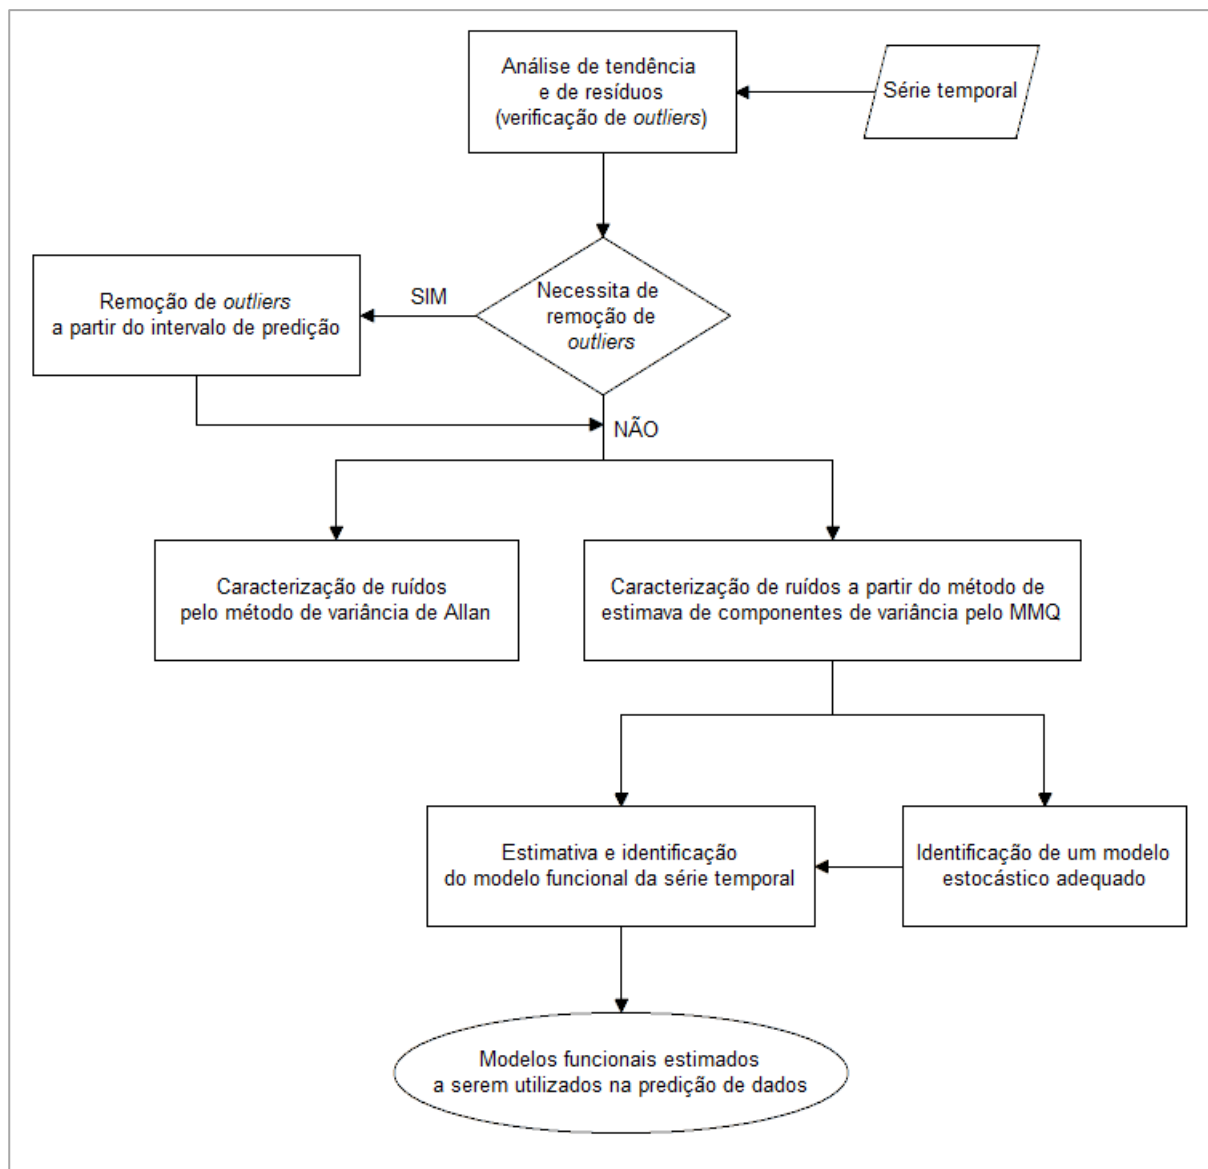
A localização das estações utilizadas na análise de séries temporais de coordenadas GNSS é apresentada na Figura 5.3.

Figura 5.3: Localização das estações utilizadas na análise de séries temporais de coordenadas GNSS



As etapas envolvidas na metodologia relacionada à análise de séries temporais de coordenadas GNSS, as quais foram realizadas nessa tese é apresentada na Figura 5.4 a seguir.

Figura 5.4: Fluxograma da metodologia envolvida na análise de séries temporais



No fluxograma da Figura 5.4 a primeira etapa consiste em obter as séries temporais de coordenadas GNSS no SGL (E, N e U) e realizar a análise de tendência e de resíduos, a partir da qual se verifica a existência de *outliers* (erros grosseiros) nas séries. Para essa análise pode-se utilizar a ferramenta de análise de tendência do software MINITAB (MINITAB, 2005), a partir do qual é possível verificar a existência de *outliers* de forma gráfica. Caso haja outliers nas séries temporais é realizada a remoção destes é baseada no intervalo de predição de cada série, sendo o algoritmo implementado no software R (R CORE TEAM, 2002) e apresentado no APÊNDICE B. A próxima etapa consiste da caracterização de ruídos, a qual é realizada pela variância de Allan (seção 4.1.1) utilizando o software AlaVar (<http://www.alamath.com/alavar/>) e pela estimativa de

componentes de variância dos ruídos pelo MMQ (seção 4.2.3) implementada no software MATLAB (www.mathworks.com). No primeiro método a caracterização dos ruídos é realizada de maneira gráfica. Já no segundo além da estimativa das componentes de variância dos ruídos é realizada a identificação de um modelo estocástico adequado para cada série temporal, considerando os diferentes tipos ruídos (seção 6.2.2). A terceira etapa consiste em estimar os modelos funcionais das séries temporais e identificar quais são os mais representativos e realísticos utilizando algoritmos implementados no software R. Por fim são descritos os modelos funcionais cada série que podem ser utilizados para um melhor entendimento dessas e também para predição de dados.

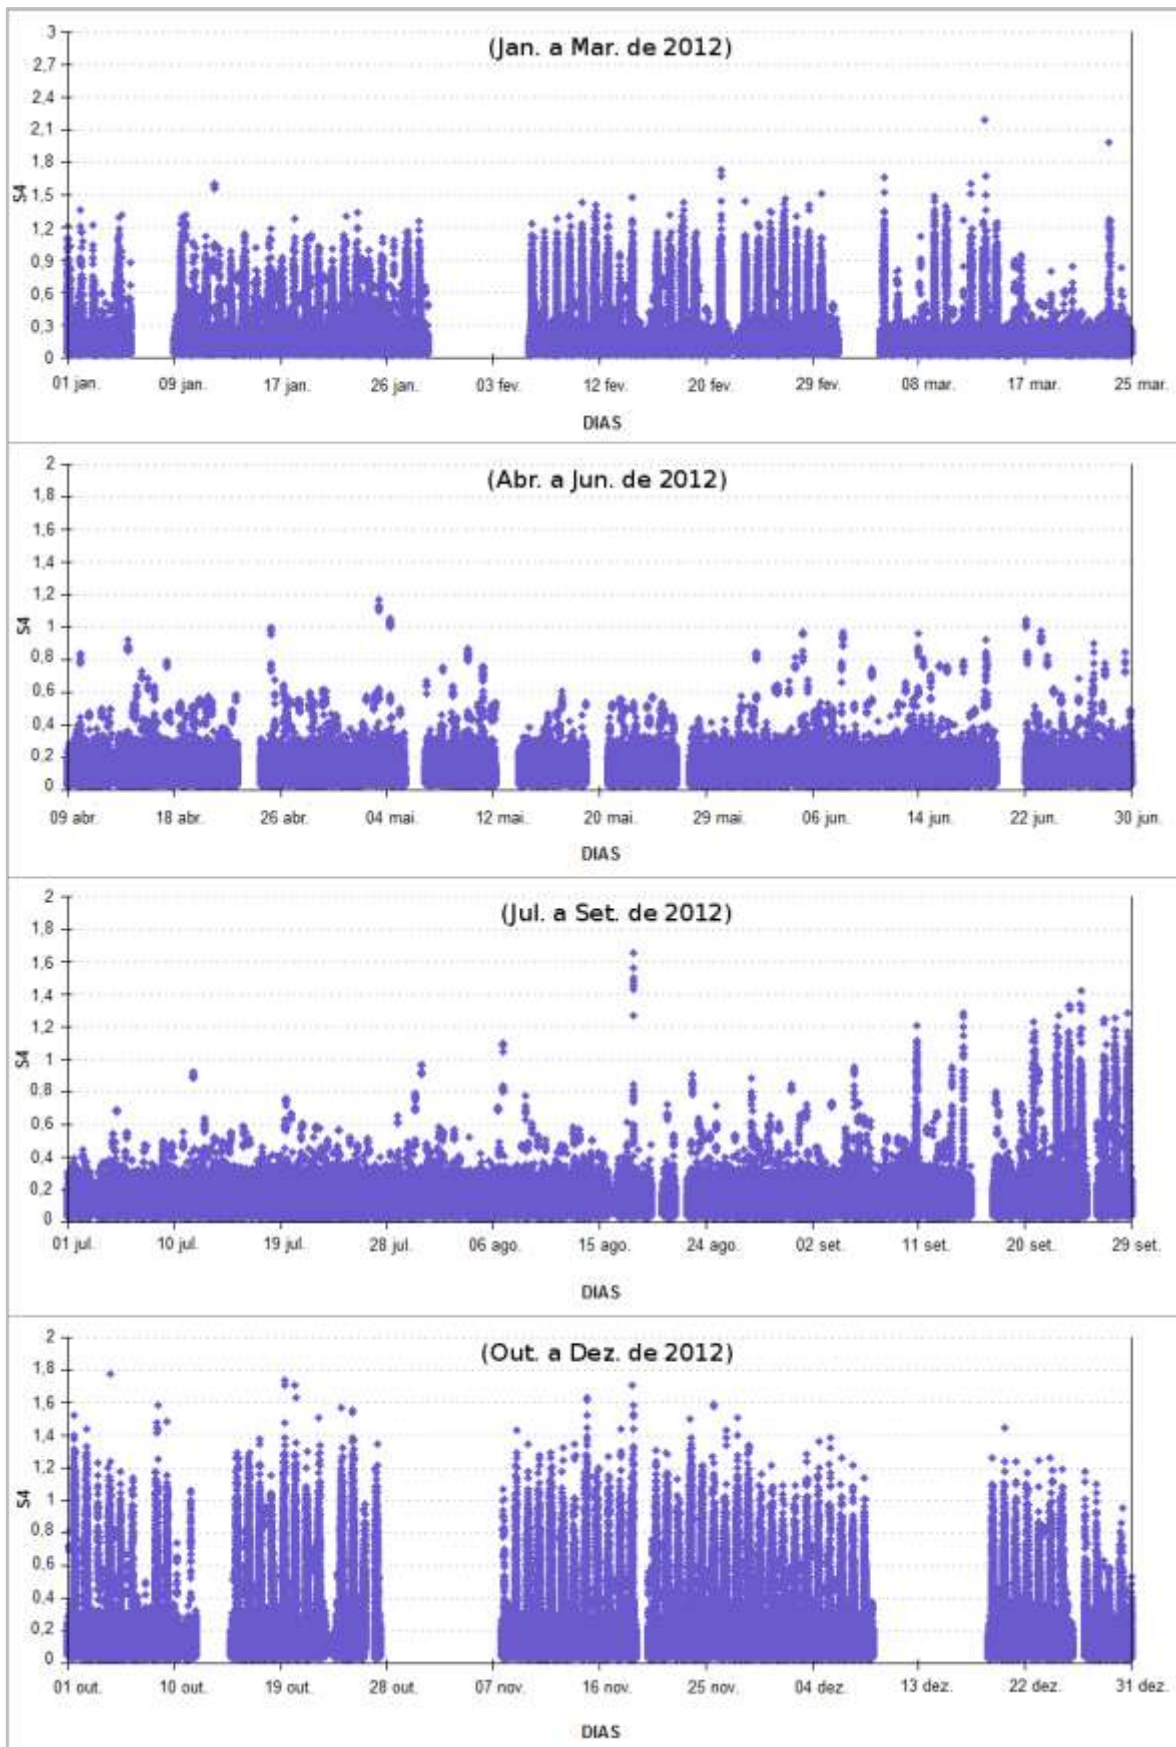
6 RESULTADOS E ANÁLISES

Os resultados serão apresentados em duas seções, ou seja, seções 6.1 e 6.2. A seção 6.1 contém os experimentos relacionados com a modelagem estocástica e mitigação dos efeitos de cintilação ionosférica no Posicionamento Por Ponto Preciso GNSS e a seção 6.2 contém os experimentos relacionados com a análise de séries temporais e estimativa das componentes de variância dos ruídos. Cada uma das seções, seja a 6.1 ou a 6.2 contém sub-seções com os experimentos realizados e ao final de cada seção apresenta-se a análise dos experimentos.

6.1 Modelagem estocástica para mitigação dos efeitos de cintilação ionosférica no processamento de dados GNSS na região brasileira

Nesta seção são apresentados experimentos visando a investigação de modelagem estocástica para mitigação dos efeitos de cintilação ionosférica. Os experimentos foram realizados utilizando dados GPS e de cintilação da rede CIGALA/CALIBRA. Foram utilizadas as estações PALM e PRU1, sendo a escolha destas devido sua localização e aos valores de índice de cintilação S4. Os dados utilizados nos experimentos foram para os dias 08/03/2012 e 20/10/2012, sendo a escolha destes realizada a partir dos valores de índice S4 para a estação PRU1 no ano de 2012, os quais são fornecidos a partir da ferramenta ISMR Query Tool da página de internet da rede CIGALA/CALIBRA (<http://is-cigala-calibra.fct.unesp.br/cigala/index.php>). A Figura 6.1 mostra os valores de índices S4 na estação PRU1 para o ano de 2012, considerando os satélites GPS com ângulos de elevação maiores ou iguais a 20 graus (a escolha dessa máscara de elevação é para evitar a influência de multicaminho).

Figura 6.1: Índices de amplitude de cintilação (S4) da estação PRU1 para o primeiro semestre de 2012



As Figuras 6.2 a 6.5 mostram os valores dos índices S4 das estações PALM e PRU1 para os dias 08/03/2012 e 20/10/2012 considerando os satélites GPS com ângulos de elevação maiores ou iguais a 10° (máscara de elevação adotada nos processamentos).

Figura 6.2: Índices de amplitude de cintilação (S4) da estação PALM para 08/03/2012




Figura 6.3: Índices de amplitude de cintilação (S4) da estação PRU1 para 08/03/2012






Figura 6.4: Índices de amplitude de cintilação (S_4) da estação PALM para 20/10/2012Figura 6.5: Índices de amplitude de cintilação (S_4) da estação PRU1 para 20/10/2012

Nas Figuras 6.2 a 6.5 verifica-se que os dados GPS do dia 08/03/2012 tanto para a estação PALM quanto para a PRU1 estão praticamente todo o dia sob fraca cintilação ionosférica ($S_4 \leq 1$). No caso dos do dia 20/10/2012, a estação PALM apresenta moderada cintilação ionosférica em períodos envolvendo o início e o fim do dia, enquanto que a estação PRU1 no início e no fim do dia está sob forte efeito de cintilação ionosférica ($S_4 > 1$).

As Figuras 6.6 a 6.9 mostram os valores de PHI60 para as estações PALM e PRU1.

Figura 6.6: Índices de variância de cintilação (PHI60) da estação PALM para 08/03/2012




Figura 6.7: Índices de variância de cintilação (PHI60) da estação PRU1 para 08/03/2012




Figura 6.8: Índices de variância de cintilação (PHI60) da estação PALM para 20/10/2012






Figura 6.9: Índices de variância de cintilação (PHI60) da estação PRU1 para 20/10/2012



A partir das Figuras 6.6 a 6.9 pode se verificar que no dia 20/10/2012 no início e fim do dia ocorrem os mais valores de PHI60, sendo ainda maiores que para o dia 08/03/2012, indicando a ocorrência de forte cintilação ionosférica, principalmente para a estação PRU1.


É interessante verificar também os índices geomagnéticos e fluxo de raios X (relacionados a explosões solares) para esses dias, como mostra as Figuras 6.10 a 6.13.

Figura 6.10: Índices geomagnéticos para o período de 7 a 10 de março de 2012




Fonte: Disponível em: <http://www.swpc.noaa.gov/ftpd/warehouse/>. Acesso em: jun. 2013

Figura 6.11: Fluxo de raios X para o período de 7 a 10 de março de 2012




Fonte: Disponível em: <http://www.swpc.noaa.gov/ftpd/warehouse/>. Acesso em: jun. 2013

Figura 6.12: Índices geomagnéticos para o período de 19 a 22 de outubro de 2012



Fonte: Disponível em: <http://www.swpc.noaa.gov/ftplib/warehouse/>. Acesso em: jun. 2013

Figura 6.13: Fluxo de raios X para o período de 19 a 22 de outubro de 2012



Fonte: Disponível em: <http://www.swpc.noaa.gov/ftplib/warehouse/>. Acesso em: jun. 2013

Verifica-se na Figura 6.11 que no dia 07/03/2012 o pico máximo do fluxo de raios X atingiu valores maiores que 10^{-4} o que significa que ocorreu uma grande explosão solar (nível X) nesse dia. Além disso, no período de 07 a 10 de março de 2012 os índices Kp (Figura 6.10) alcançaram altos valores (Kp até 7), indicando alta atividade solar. Já para o período de 19 a 21 de outubro de 2012 os índices geomagnéticos (Figura 6.12) e fluxos de raios X (Figura 6.13) não tiveram grandes alterações, indicando fraca atividade solar. Ao comparar esses gráficos com os gráficos de índices de cintilação ionosférica (S4) (Figura 6.2 a Figura 6.5) verifica-se que não há relação entre os altos valores de S4 e a ocorrência de tempestades solares, sendo então a ocorrência de cintilação provavelmente devido a outros fatores, como por exemplo, ocorrência de bolhas ionosféricas.

Com relação aos processamentos dos dados GPS, estes foram realizados pelo método PPP no software RT_PPP utilizando-se o modo cinemático. Todos os processamentos foram realizados utilizando as configurações mostradas na Tabela 6.1 e as correções apresentadas na seção 5:

Tabela 6.1: Configurações dos processamentos no software RT_PPP

Máscara de elevação	10°
Precisões das observações	$\sigma_{CA} = 0,8$ m; $\sigma_{P2} = 1,0$ m; $\sigma_{L1} = 0,008$ m e $\sigma_{L2} = 0,010$ m
Correção da troposfera	Hopfield
Correção da ionosfera	<i>Ion-free</i>

Foram realizados processamentos para cada estação e cada dia envolvendo as estratégias de modelagem estocástica da Tabela 6.2, visando avaliar a modelagem estocástica mais adequada para dados sob efeitos de cintilação ionosférica na região brasileira.

Tabela 6.2: Modelagens estocásticas adotadas nos processamentos realizados no software RT_PPP

Modelo estocástico	Descrição
Mod_Padrão	Em função das precisões adotadas (Tabela 6.1) das observações (seção 3.2.1)
Mod_Elev	Em função das precisões das observações ponderadas pelo inverso do seno do ângulo de elevação dos satélites (seção 3.2.2, Equações 3.18 e 3.20)
Mod_Cint	Modelagem estocástica em função dos efeitos de cintilação ionosférica (seção 3.2.3)
Mod_Elev_Cint	Modelagem estocástica em função das precisões das observações ponderadas pelo inverso do seno do ângulo de elevação dos satélites e em função dos efeitos de cintilação ionosférica (seção 3.2.4).

A Figura 6.14 até a Figura 6.17 mostram as séries temporais diárias do erro 3D dos diferentes tipos de processamentos PPP, respectivamente, para as estações PALM e PRU1. Os 'erros' assim denominados nos experimentos são calculados em função das diferenças entre as coordenadas estimadas e aquelas de referência da estação (discrepâncias), as quais são apresentadas no SGL (DE , DN e DU). O erro 3D é calculado pela resultante das discrepâncias ($Erro\ 3D = \sqrt{DE^2 + DN^2 + DU^2}$).

Figura 6.14: Erro 3D da estação PALM para o dia 08/03/2012




Figura 6.15: Erro 3D da estação PALM para o dia 20/10/2012




Figura 6.16: Erro 3D da estação PRU1 para o dia 08/03/2012





Figura 6.17: Erro 3D da estação PRU1 para o dia 20/10/2012



Ao analisar a Figura 6.14 e a Figura 6.15 referentes à estação PALM, verifica-se que em vários períodos do dia ao aplicar os modelos estocásticos Mod_Elev, Mod_Cint e Mod_Elev Cint os valores de erro 3D foram menores, principalmente no início e no final do dia. Já com relação à estação PRU1 (Figura 6.16 e Figura 6.17) ocorreu o contrário, principalmente no dia 20/10/2012, quando os dados estavam sob forte efeito de cintilação ionosférica ($S4 > 1$) no início e no final do dia (ver Figura 6.3 e Figura 6.5).

A Figura 6.16, a Figura 6.18 e a Figura 6.19 mostram, respectivamente, o EMQ 3D (Erro Médio Quadrático 3D) para as estações PALM e PRU1, considerando todo o período do processamento e também o início (0h às 4h) e final do período (21h às 24h). O EMQ 3D é a resultante do EMQ em E, N e U.

Figura 6.18: EMQ 3D da estação PALM para os dias 08/03/2012 e 20/10/2012





Figura 6.19: EMQ 3D da estação PRU1 para os dias 08/03/2012 e 20/10/2012



Ao analisar a Figura 6.18 é possível verificar que o EMQ 3D da estação PALM em todos os processamentos ficou abaixo de 0,50 m. Verifica-se também que em todos os casos ao utilizar os modelos estocásticos Mod_Elev, Mod_Cint e Mod_Elev_Cint os valores de EMQ 3D foram menores (abaixo de 0,30 m) que ao utilizar o modelo Mod_Padrão para os dois dias envolvidos. Com relação à estação PRU1 (Figura 6.19) os valores de EMQ 3D ficaram abaixo de 0,30 m para o dia 08/03/2012 das 0h às 4h (início do período) e em alguns casos os valores de EMQ 3D foram melhores ao aplicar os modelos Mod_Elev ou Mod_Cint ao invés do Mod_padrão. No dia 20/10/2012, os valores de EMQ 3D foram menores ao utilizar Mod_Elev, Mod_Cint e Mod_Elev_Cint ao invés de Mod_Padrão, atingindo a magnitude de 6,0 m. Na Tabela 6.3 e na Tabela 6.4 são apresentadas as melhorias em porcentagem ao utilizar diferentes modelagens estocásticas em relação ao modelo Mod_Padrão para a estação PALM e PRU1, respectivamente.

Tabela 6.3: Melhorias (%) no EMQ 3D em relação ao "Mod_Padrão" - estação PALM

Modelo estocástico	08/03/2012 (Fraca cintilação)			20/10/2012 (Moderada cintilação)		
	Todo o período	Início do período	Final do período	Todo o período	Início do período	Final do período
Mod_Elev	13,07	9,97	30,94	44,12	37,62	36,36
Mod_Cint	26,38	28,79	8,75	50,44	45,15	42,85
Mod_Elev_Cint	29,33	24,75	24,75	22,29	26,98	26,27

Tabela 6.4: Melhorias (%) no EMQ 3D em relação ao "Mod_Padrão" - estação PRU1

Modelo estocástico	08/03/2012 (Fraca cintilação)			20/10/2012 (Forte cintilação)		
	Todo o período	Início do período	Final do período	Todo o período	Início do período	Final do período
Mod_Elev	6,62	0,60	35,55	-34,57	-37,32	-19,15
Mod_Cint	19,98	29,90	-71,88	-140,91	-137,09	-38,34
Mod_Elev_Cint	-4,75	2,88	-70,77	-50,16	-50,63	-51,67

Pela Tabela 6.3 verifica-se que no dia 08/03/2012 (cintilação ionosférica fraca) que o modelo que teve a maior melhoria em relação ao Mod_Padrão para todo o período foi o modelo Mod_Elev_Cint alcançando 29%, para o início do período foi o Mod_Cint e para o final do dia foi o Mod_Elev. Já no dia 20/10/2012 o modelo Mod_Cint foi o que obteve a maior melhoria com relação ao Mod_Padrão (todo o período, início e final do período), alcançando uma melhoria de aproximadamente 50% em relação ao Mod_Padrão.

Já na Tabela 6.4, referente à estação PRU1, verifica-se que no dia 08/03/2012 (fraca cintilação), o modelo Mod_Cint foi o que obteve maior melhoria em

relação ao Mod_Padrão, atingindo 20%, porém no final do dia o modelo que obteve maior melhoria foi o Mod_Elev com melhoria da ordem de 35%. Com relação ao dia 20/10/2012, o qual os dados estavam sob forte cintilação ionosfera não houve melhorias ao aplicar as modelagens Mod_Elev, Mod_Cint e Mod_Elev_Cint em relação ao aplicar o Mod_Padrão.

Em resumo, para o período de moderada cintilação como foi o caso do dia 20 de outubro de 2012 (estação PALM), os resultados com a modelagem estocástica Mod_Cint apresentaram melhores resultados em relação ao caso padrão, seja para todo o período ou para o início e o fim do dia. Já para o período de forte cintilação (estação PRU1 - 20/10/2012) os resultados com as modelagens Mod_Elev, Mod_Cint e Mod_Elev_Cint foram piores que ao aplicar a modelagem Mod_Padrão.

No caso dos resultados da estação PRU1 no dia 20/10/2012, uma explicação para o fato da modelagem padrão ter sido melhor que as outras modelagens estocásticas pode estar relacionada com aplicação do procedimento DIA (seção 2.2.1). Ao aplicar a DIA em períodos de forte cintilação ionosférica (estação PRU1 - 20/10/2012), há detecção de vários erros grosseiros. Como este é um período com muitas perdas de ciclos há a dificuldade de identificação de erros grosseiros pela DIA, uma vez que é difícil a classificação de perda de ciclo e erro grosseiro nas medidas de fase do GPS. A Figura 6.20 mostra tempo específico em que foram detectadas perdas de ciclo para cada satélite no dia 20/10/2012 na estação PRU1. As Figuras 6.21 e 6.22 mostram a distribuição de satélites que foram detectados como erros grosseiros e valores de LOM para a estação PRU1 utilizando o Mod_Padrão e o Mod_ELev, respectivamente.

Figura 6.20: Perdas de ciclos para a estação PRU1 (20/10/2012)




Figura 6.21: Satélites detectados com erros grosseiros e valores de LOM para a estação PRU1 (20/10/2012) - Mod_Padrão





Figura 6.22: Satélites detectados com erros grosseiros e valores de LOM para a estação PRU1 (20/10/2012) - Mod_Elev



Ao analisar a Figura 6.21 e a Figura 6.22 verifica-se que houve uma maior detecção de erros grosseiros quando se utilizou a modelagem padrão, sendo estas concentradas no início do período. Verifica-se também que grande parte dos satélites envolvidos na detecção de erros apresentaram muitas perdas de ciclo no período envolvido, como pode ser visto na Figura 6.20.

Retomando as Figuras 6.18 e 6.19 é interessante verificar que os maiores valores do EMQ 3D foram para o início das séries temporais em ambas as estações. No posicionamento por ponto preciso há o problema relacionado à convergência dos resultados no início do processamento, sendo assim, foram utilizados dados correspondendo ao período de 9h do dia 19/10/2012 até às 21h do dia 20/10/2012 das estações PALM e PRU1. Os dados foram processados no software RT_PPP utilizando o modo cinemático e, as configurações adotadas nos processamentos foram as mesmas dos processamentos anteriores (ver Tabela 6.1).

A Figura 6.23 e a Figura 6.24 mostram os valores de índices de cintilação S4 para os dias 19 a 20 de outubro de 2012, respectivamente, para a estação PALM e PRU1.

Figura 6.23: Índices de amplitude de cintilação (S4) da estação PALM (19 a 20 de out. de 2012)





Figura 6.24: Índices de amplitude de cintilação (S4) da estação PRU1 (19 a 20 de out. de 2012)



As séries temporais do erro 3D das estações PALM e PRU1 para o período de 19 a 20 de outubro de 2012 são mostrados na Figura 6.25 e na Figura 6.26.

Figura 6.25: Erro 3D da estação PALM (19 a 20 de outubro de 2012)






Figura 6.26: Erro 3D da estação PRU1 (19 a 20 de outubro de 2012)



Ao analisar a Figura 6.25 referente à estação PALM, pode-se verificar que no período com maior influência dos efeitos de cintilação entre 23 h do dia 19/10/2012 e 4h do dia 20/10/2012 os valores do erro 3D foram melhores ao aplicar uma das modelagens estocásticas Mod_Elev, Mod_Cint ou Mod_Elev_Cint em relação ao aplicar a modelagem Mod_Padrão. Já com relação à estação PRU1 para o mesmo intervalo de tempo (Figura 6.26) em alguns instantes ficaram piores, podendo-se notar várias perdas de ciclos no período entre meia-noite e 4 horas do dia 20/10/2012, conforme mostra a Figura 6.27.

Figura 6.27: Perdas de ciclos para a estação PRU1 (19 a 20 de outubro de 2012)



A Figura 6.28 e a Figura 6.29 mostram, respectivamente, o EMQ 3D para as estações PALM e PRU1 para todo o período, meio do período (entre 23 h do dia 19/10/2012 e 4h do dia 20/10/2012) e final do período (das 18h às 21h do dia 20/10/2012).

Figura 6.28: EMQ 3D da estação PALM (19 a 20 de out. de 2012)





Figura 6.29: EMQ 3D da estação PRU1 (19 a 20 de out. de 2012)



O EMQ 3D para a estação PALM (Figura 6.28) apresentou melhorias ao aplicar a modelagem Mod_Elev, Mod_Cint ou Mod_Elev_Cint em relação ao aplicar a modelagem Mod_Padrão, alcançando valores de abaixo de 0,20 metros. As melhorias em porcentagem são apresentadas na Tabela 6.5.

Tabela 6.5: Melhorias (%) no EMQ 3D em relação ao "Mod_Padrão" - estação PALM (19 a 20 de out. de 2012)

Modelo estocástico	Todo o período	Meio do período	Final do período
Mod_Elev	12,28	34,38	48,69
Mod_Cint	36,57	32,95	45,12
Mod_Elev_Cint	29,27	37,71	48,68

Com relação ao EMQ 3D da estação PRU1 (Figura 6.29) não houve melhorias ao aplicar os modelos estocásticos Mod_Elev, Mod_Cint e Mod_Elev_Cint em relação ao Mod_Padrão, principalmente, no meio do período quando os dados estavam sob forte cintilação ionosférica, sendo que os valores de EMQ 3D atingiram a ordem de 4,5 metros. Para esta estação o único período que se obteve um pouco de melhoria foi no final do período, alcançando a ordem de 22%, sendo o efeito de cintilação nesse período considerado de fraca a moderada ($S4 < 0,6$).

6.1.1 Análise dos experimentos

Os experimentos realizados envolveram dados sob fraca (08/03/2012), moderada (20/10/2012, estação PALM) e forte cintilação ionosférica (20/10/2012, estação PRU1).

Nos períodos de fraca cintilação para a estação PALM, no geral os modelos estocásticos Mod_Elev, Mod_Cint e Mod_Elev_Cint apresentaram melhorias nos resultados ao comparar com a modelagem padrão (Mod_Padrão). Já em períodos de moderada cintilação para esta estação todos apresentaram melhorias sendo que o Mod_Cint apresentou melhor desempenho em relação ao Mod_Padrão (aproximadamente 50% de melhoria).

Com relação ao período de forte cintilação (estação PRU1), os modelos estocásticos não apresentaram melhorias em relação ao modelo padrão, sendo alta a ocorrência de detecção de erros grosseiros pelo método DIA. Além de haver muitas perdas de ciclos, principalmente no período entre 23 horas do dia 19 e 4 horas do dia 20 de outubro de 2012, o que dificulta a etapa de identificação de erros pela DIA, haja vista a dificuldade em classificar como perda de ciclo ou como erro grosseiro nas medidas de fase do GPS.

Diante dos resultados apresentados nos experimentos anteriores, pode-se concluir que a adoção de uma modelagem estocástica adequada no processamento de dados GNSS permite que se obtenham resultados mais confiáveis e realísticos. Contudo, quando se tem dados sob forte cintilação ionosférica mais investigações são necessárias.

6.2 Análise das séries temporais de coordenadas GNSS

No que concerne a análise de série temporal de coordenadas, foram utilizadas as séries temporais de coordenadas GNSS das estações BRAZ, BRFT, CHPI e SAVO pertencentes à RBMC e estimadas pelo JPL (ftp://sideshow.jpl.nasa.gov/pub/JPL_GPS_Timeseries/repro2011b/), além das séries temporais das estações BRAZ, MAPA, POAL, PPTTE e RECF estimadas através do SIRGAS-CON (<ftp://ftp.sirgas.org/pub/gps/SIRGAS/>).

Foram realizadas análises de tendência das séries temporais (E , N e U) no software MiniTab para todas as estações. As Figuras 6.30 a 6.35 mostram os gráficos de análise típica de tendência e de resíduos para as séries temporais da estação BRAZ referentes ao SIRGAS-CON e as Figuras 6.36 a 6.41 para a mesma estação referente ao JPL.

Figura 6.30: Análise de tendência da série temporal da componente E (estação BRAZ do SIRGAS-CON)




Figura 6.31: Análise de tendência da série temporal da componente N (estação BRAZ do SIRGAS-CON)




Figura 6.32: Análise de tendência da série temporal da componente U (estação BRAZ do SIRGAS-CON)




Figura 6.33: Resíduos da série temporal da componente E (estação BRAZ do SIRGAS-CON)

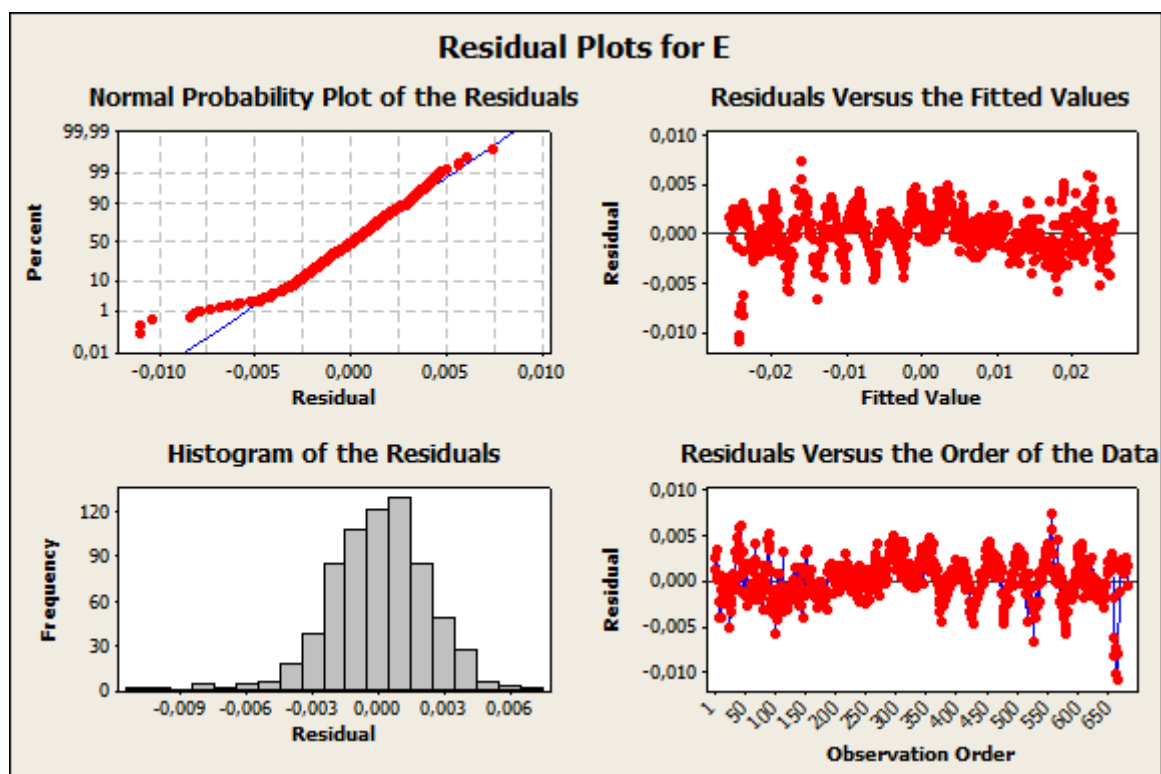


Figura 6.34: Resíduos da série temporal da componente N (estação BRAZ do SIRGAS-CON)

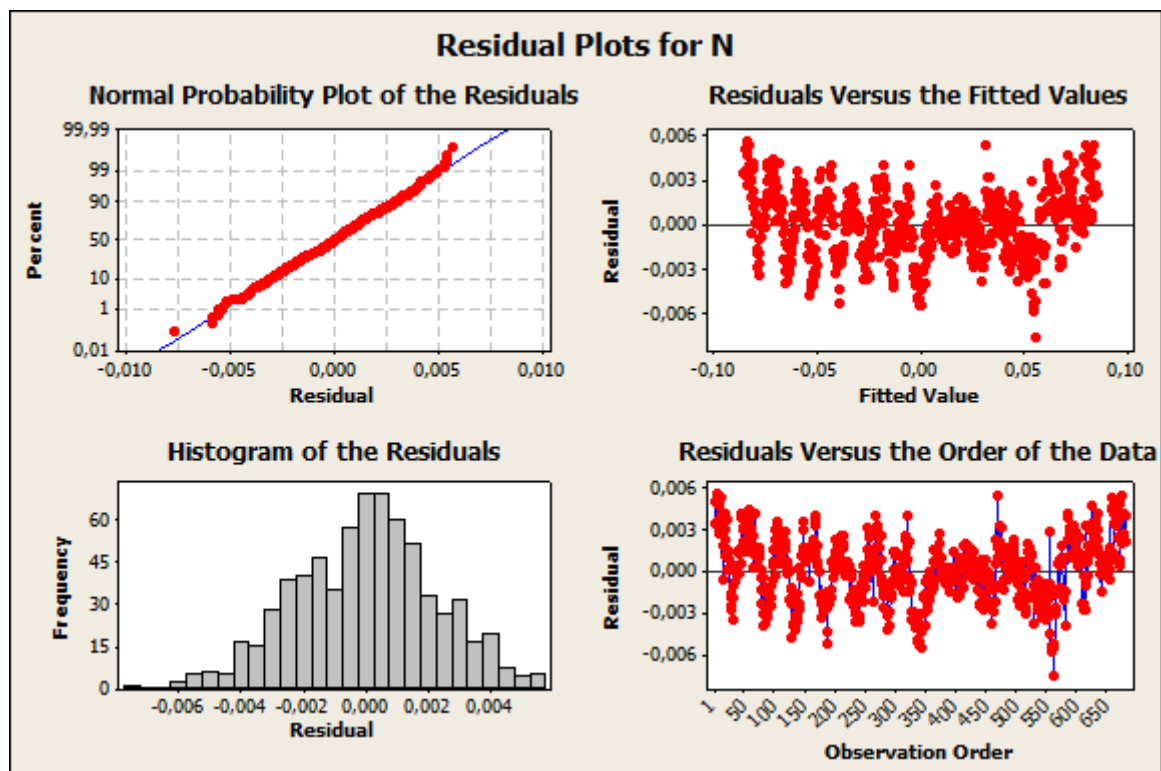


Figura 6.35: Resíduos da série temporal da componente U (estação BRAZ do SIRGAS-CON)

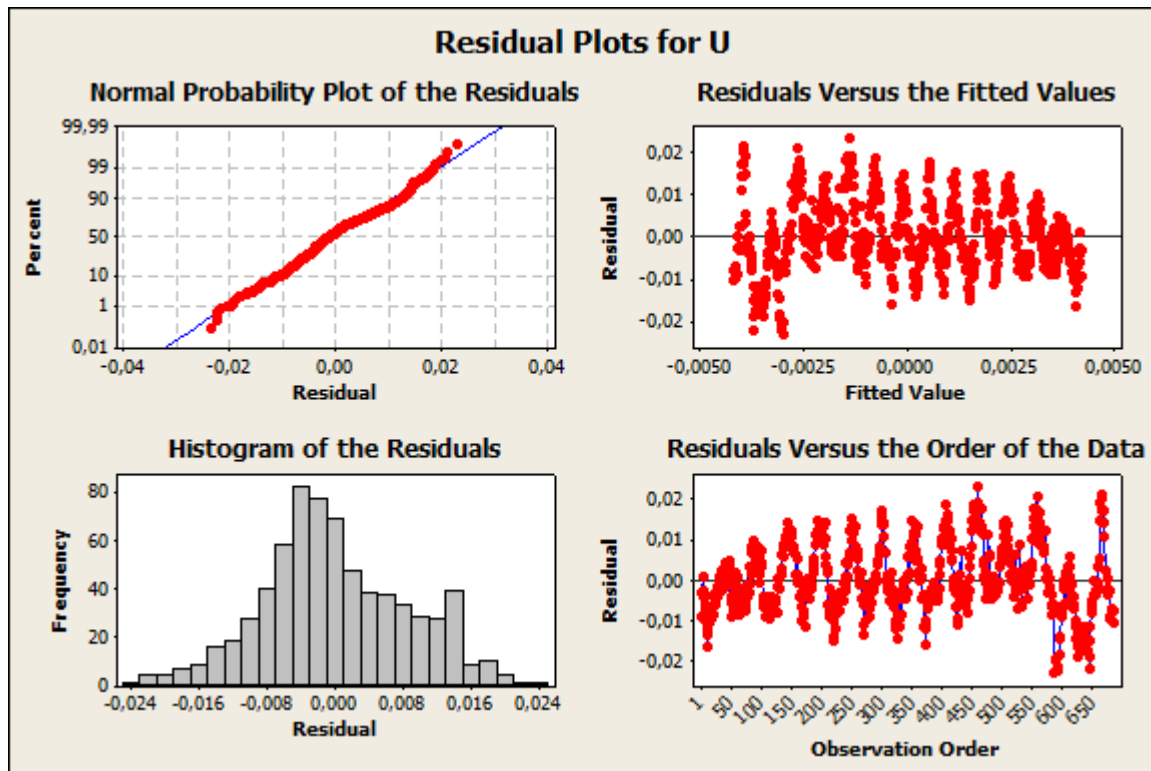


Figura 6.36: Análise de tendência da série temporal da componente E (estação BRAZ do JPL)




Figura 6.37: Análise de tendência da série temporal da componente N (estação BRAZ do JPL)




Figura 6.38: Análise de tendência da série temporal da componente U (estação BRAZ do JPL)




Figura 6.39: Resíduos da série temporal da componente E (estação BRAZ do JPL)

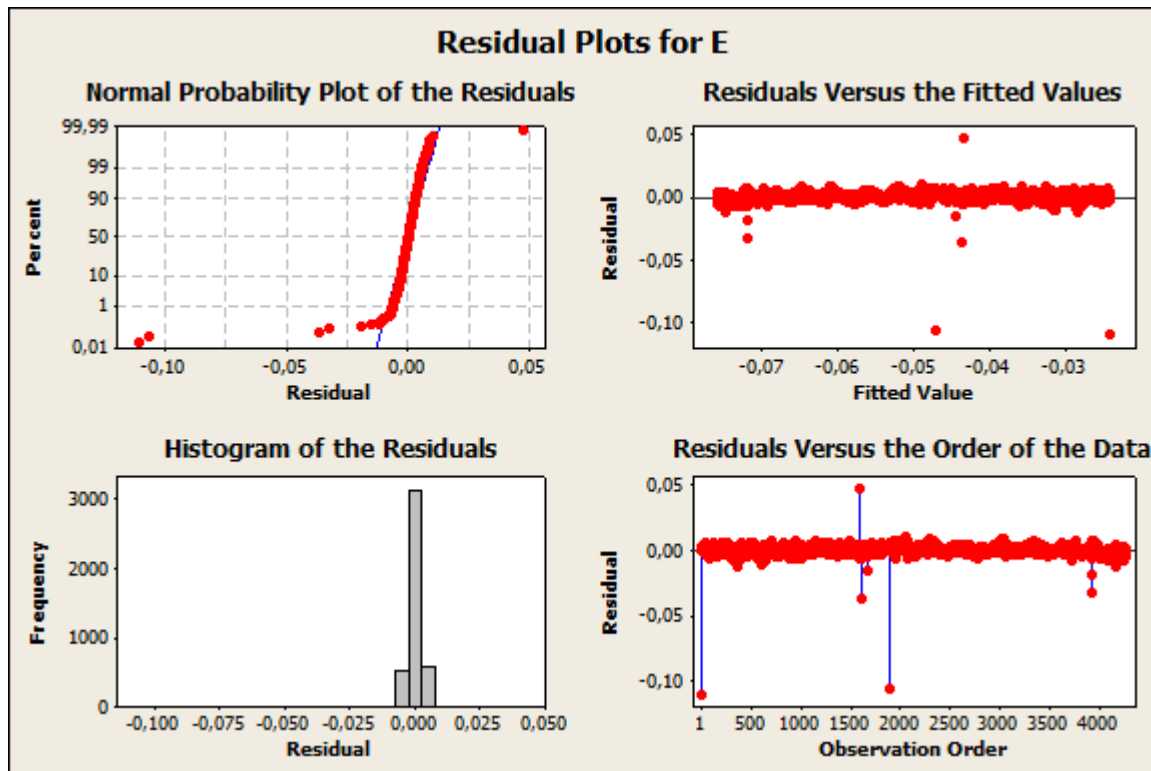


Figura 6.40: Resíduos da série temporal da componente N (estação BRAZ do JPL)

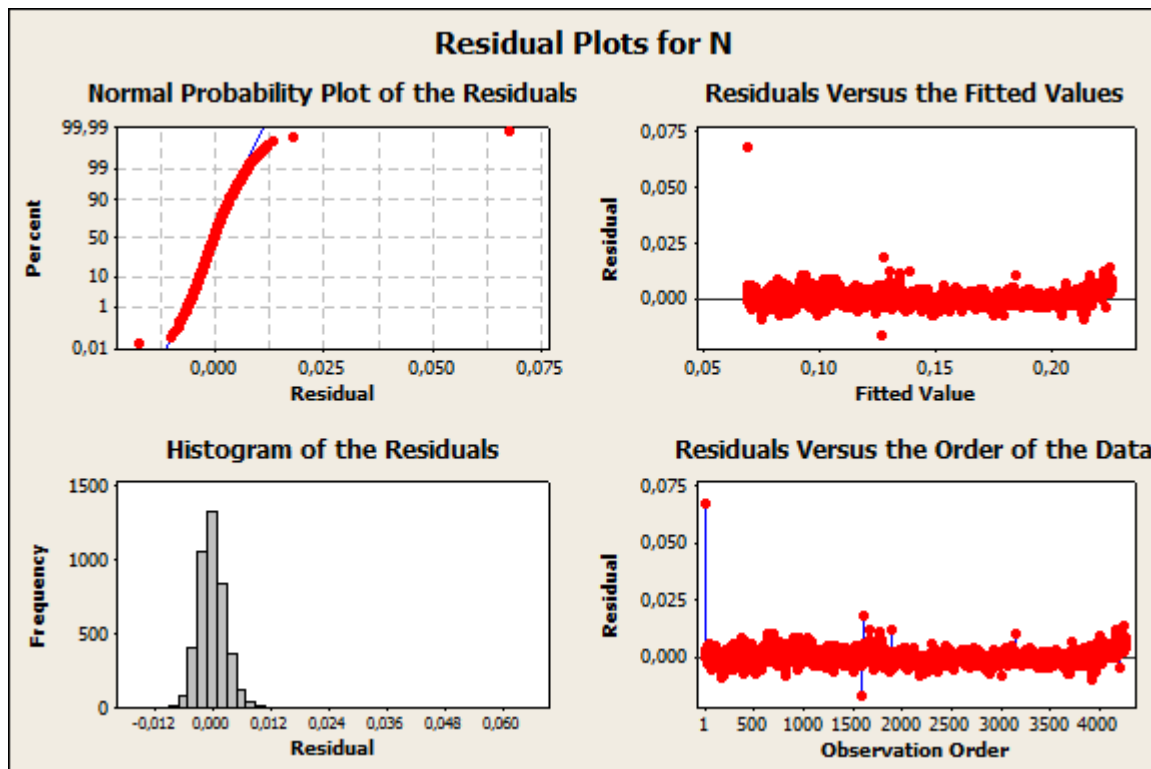
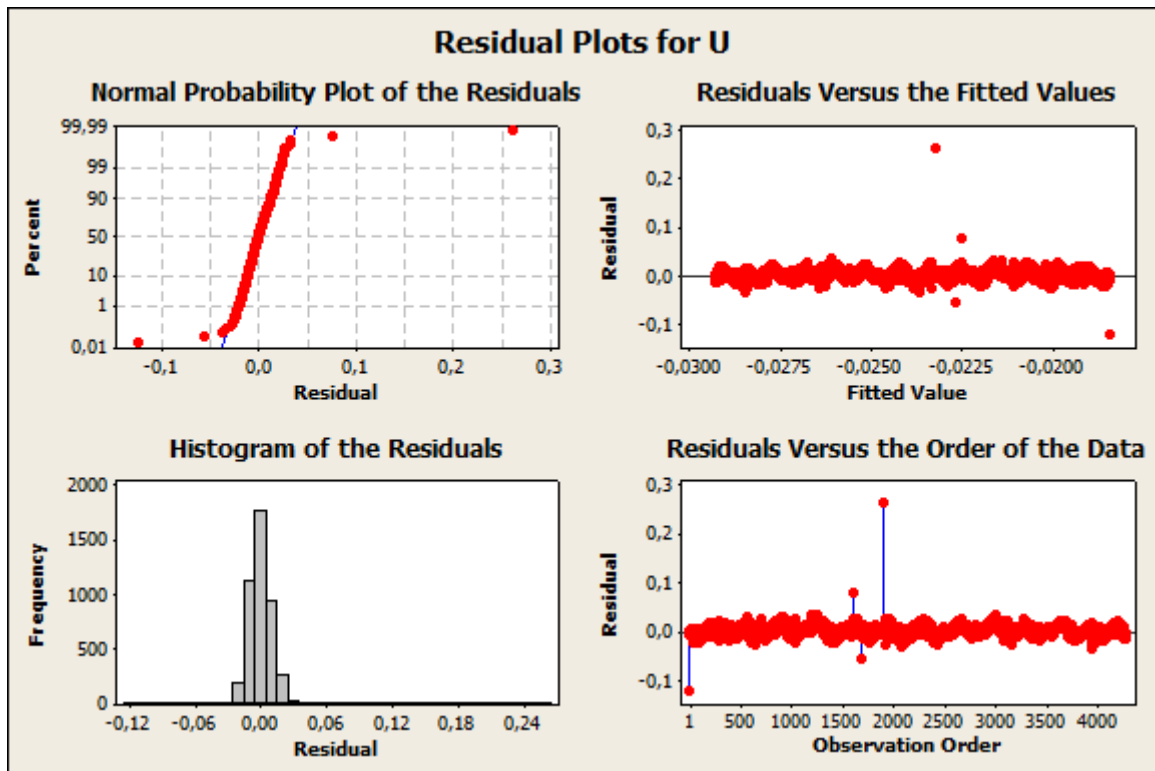


Figura 6.41: Resíduos da série temporal da componente U (estação BRAZ do JPL)



Nas Figuras 6.30 a 6.35 referentes a estação BRAZ do SIRGAS-CON verifica-se que graficamente que não há presença de erros grosseiros (*outliers*). Essas séries temporais foram obtidas a partir de arquivos com soluções semanais no formato SINEX, os quais contêm, dentre outras informações, as coordenadas cartesianas (X , Y e Z) estimadas e respectivas MVCs das estações de toda a rede. Nesse caso, as diferenças em relação a média nas coordenadas cartesianas (DX , DY e DZ) foram transformadas para o sistema de coordenadas geodésicas local (SGL). A média das coordenadas foi tomada como origem do sistema de referência, para então se obter DE , DN e DU . Como essas soluções já passam por um pós-processamento não houve a necessidade de remoção de erros grosseiros.

Já com relação às séries temporais da estação BRAZ do JPL, é possível verificar a partir da Figura 6.36 até a Figura 6.41 que as séries temporais apresentam alguns erros grosseiros (*outliers*). As séries do JPL que foram utilizadas são denominadas de séries “brutas”, ou seja, séries construídas a partir de soluções diárias e que até então não passaram por nenhum pós-processamento. Sendo assim, para realizar a análise dessas séries temporais é necessária a remoção dos de erros grosseiros.

A remoção de erros grosseiros das séries temporais do JPL foi realizada no software R a partir da análise do intervalo de predição de cada série com um nível de

confiança de 99% (R CORE TEAM, 2012; MORETIN; TOLOI, 2004). As Figuras 6.42, 6.43 e 6.44 mostram os gráficos relacionados às séries temporais da estação BRAZ (E , N e V), nos quais os valores na ordenada correspondem as componentes de coordenadas e os valores na abcissa correspondem à série temporal ajustada (Mod_func_3). A linha tracejada em vermelho corresponde ao intervalo de predição de cada série, o qual foi utilizado como limiar para a remoção dos *outliers*.

Figura 6.42: Série temporal versus série temporal ajustada da estação BRAZ (componente E)

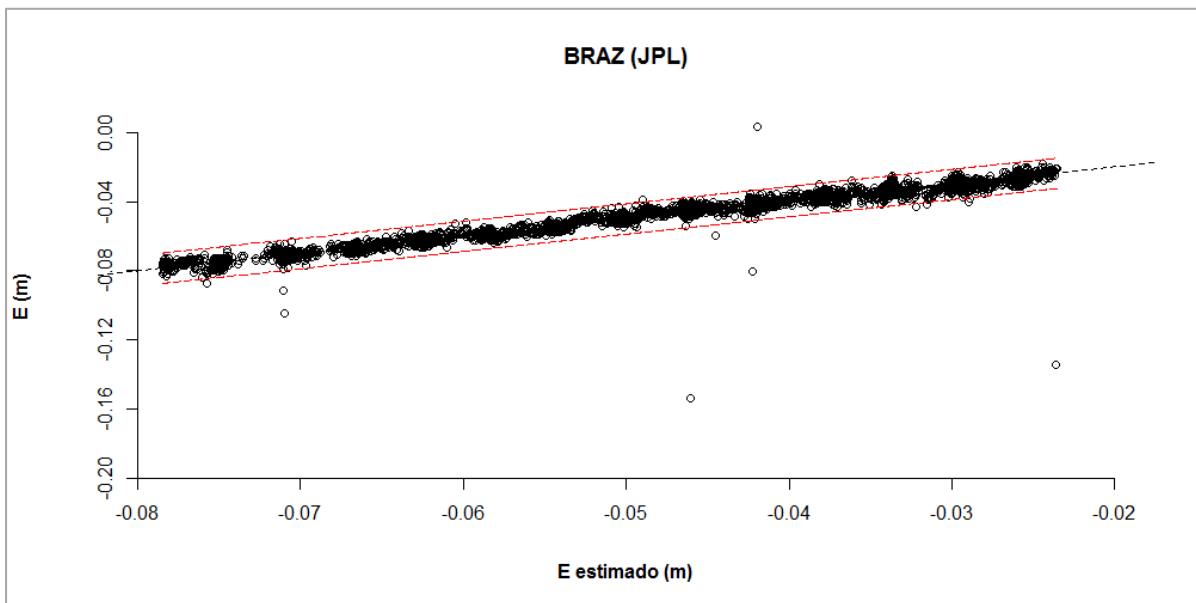


Figura 6.43: Série temporal versus série temporal ajustada da estação BRAZ (componente N)

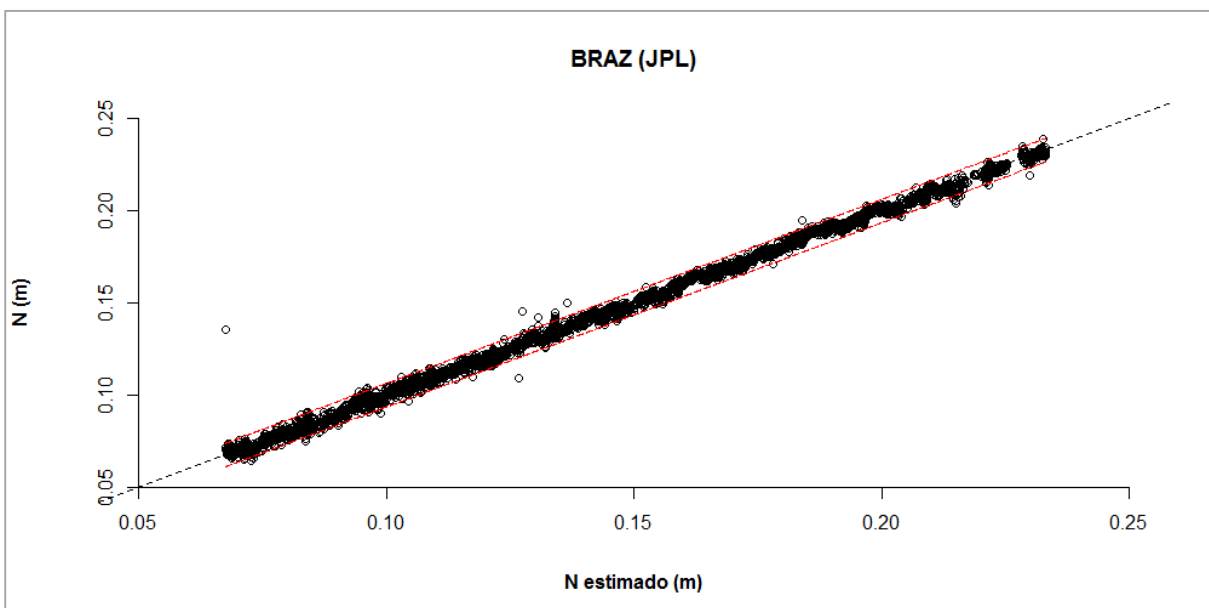



Figura 6.44: Série temporal versus série temporal ajustada da estação BRAZ (componente V)



O mesmo procedimento foi realizado para as estações BRFT, CHPI e SAVO, sendo que os gráficos são apresentados no APÊNDICE B. O algoritmo desenvolvido no software R encontra-se no APÊNDICE A.

Após as análises iniciais de tendência e remoção de erros grosseiros, a próxima etapa consistiu em realizar a análise das séries temporais a partir da variância Allan, a qual é descrita na seção 6.2.1.

6.2.1 Análise de séries temporais a partir da variância Allan

As séries temporais das estações BRAZ, MAPA, PPTA, POAL e RECF (SIRGAS-CON) foram analisadas através do software AlaVar. A Figura 6.45 até a Figura 6.49 mostram os gráficos de PSD (*Power Spectral Density*) das estações para as componentes E , N e U .

Figura 6.45: Gráficos de PSD das séries temporais (E, N e U) da estação BRAZ (SIRGAS-CON)

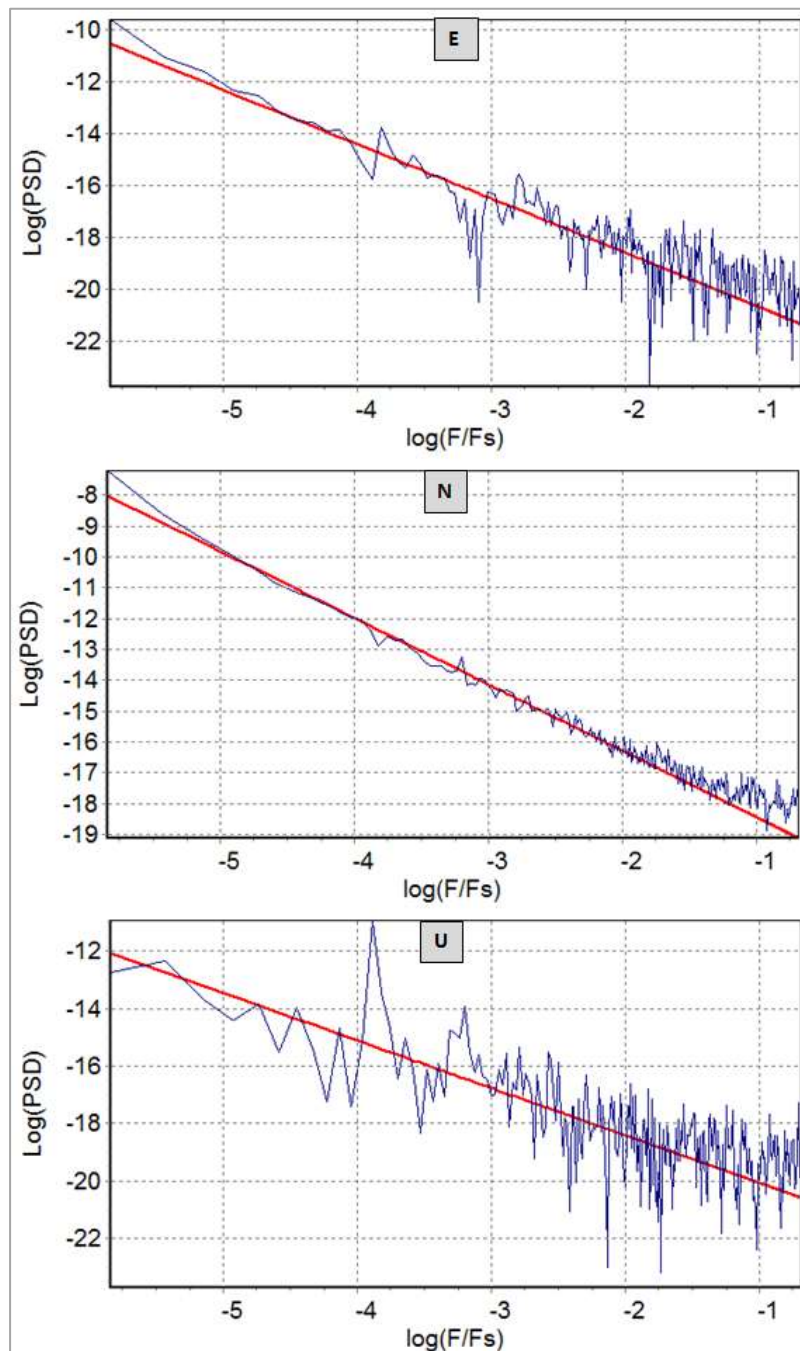


Figura 6.46: Gráficos de PSD das séries temporais (E, N e U) da estação MAPA (SIRGAS-CON)




Figura 6.47: Gráficos de PSD das séries temporais (E, N e U) da estação POAL (SIRGAS-CON)

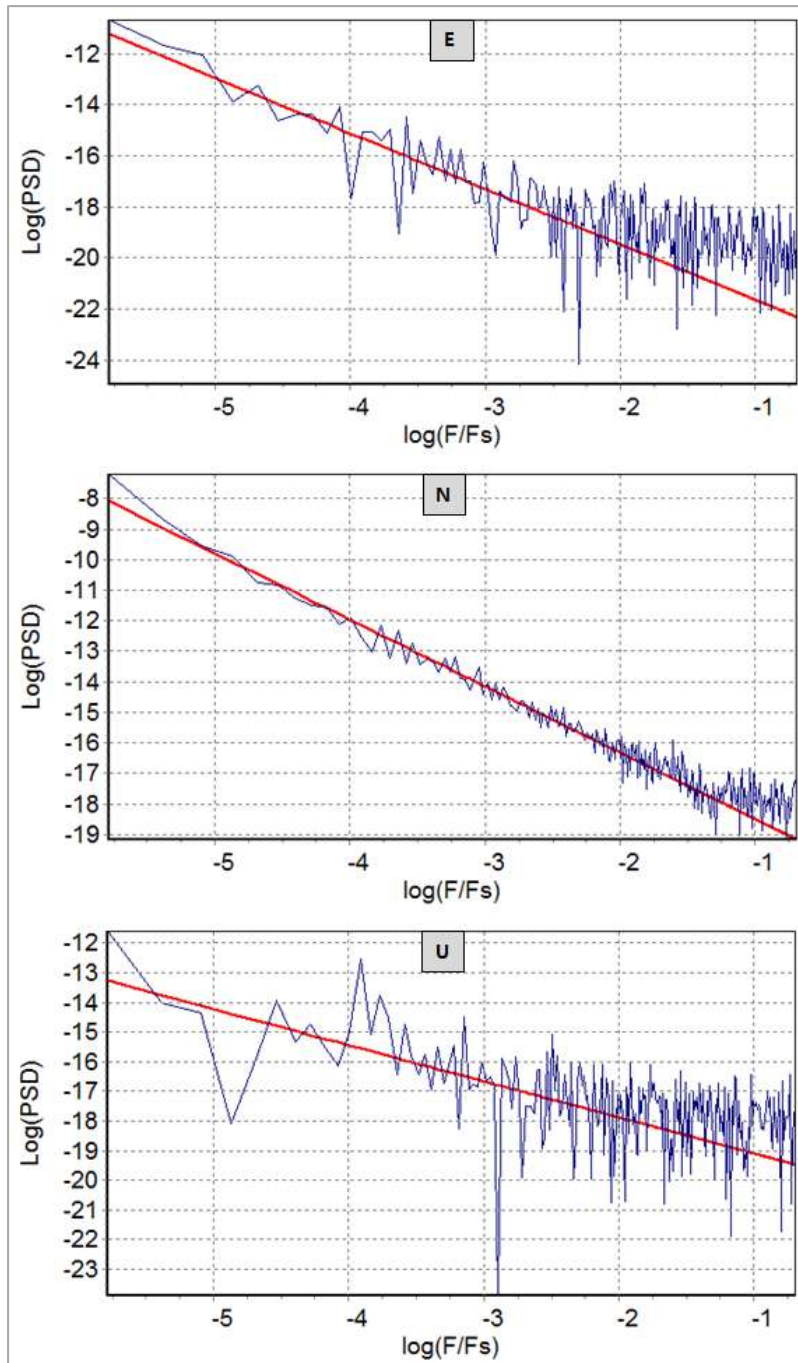


Figura 6.48: Gráficos de PSD das séries temporais (E, N e U) da estação PPTe (SIRGAS-CON)

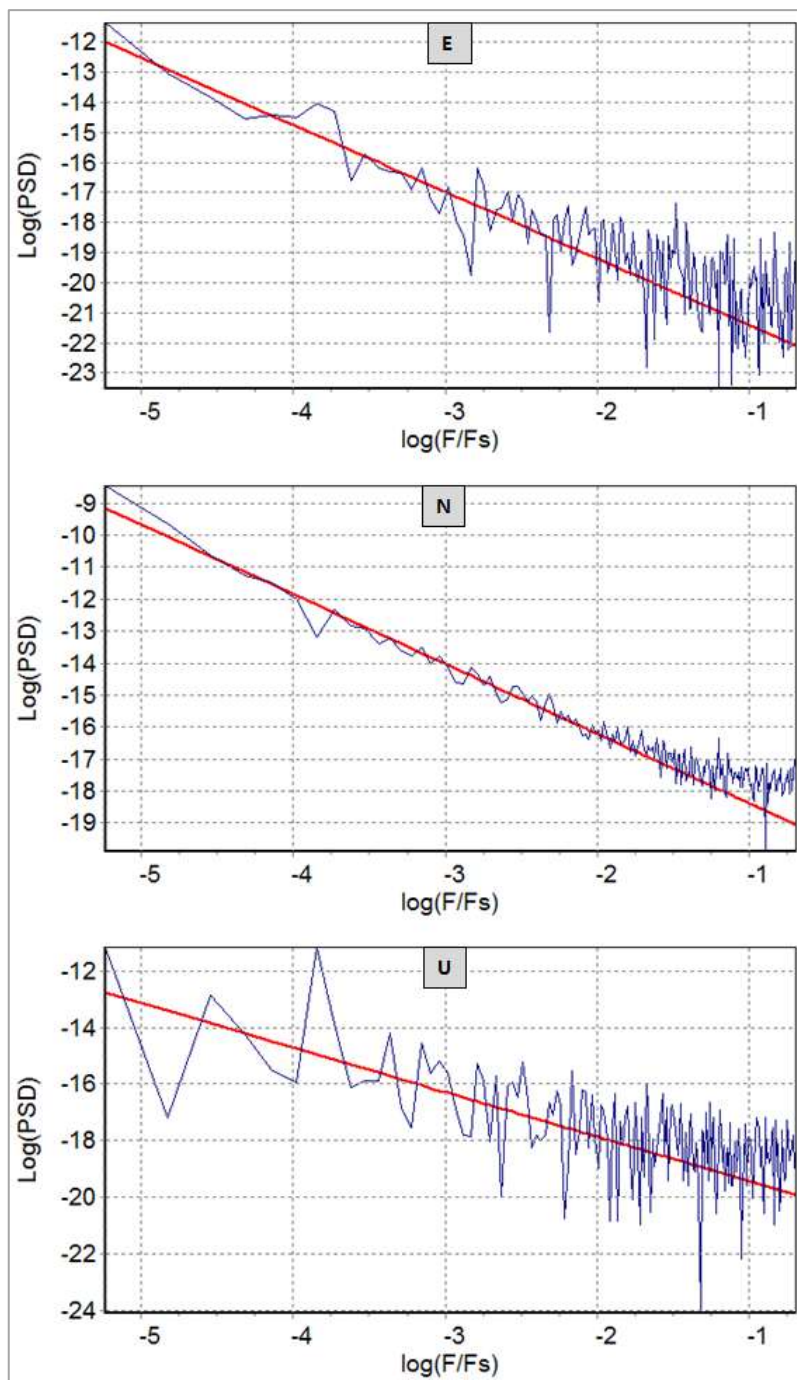
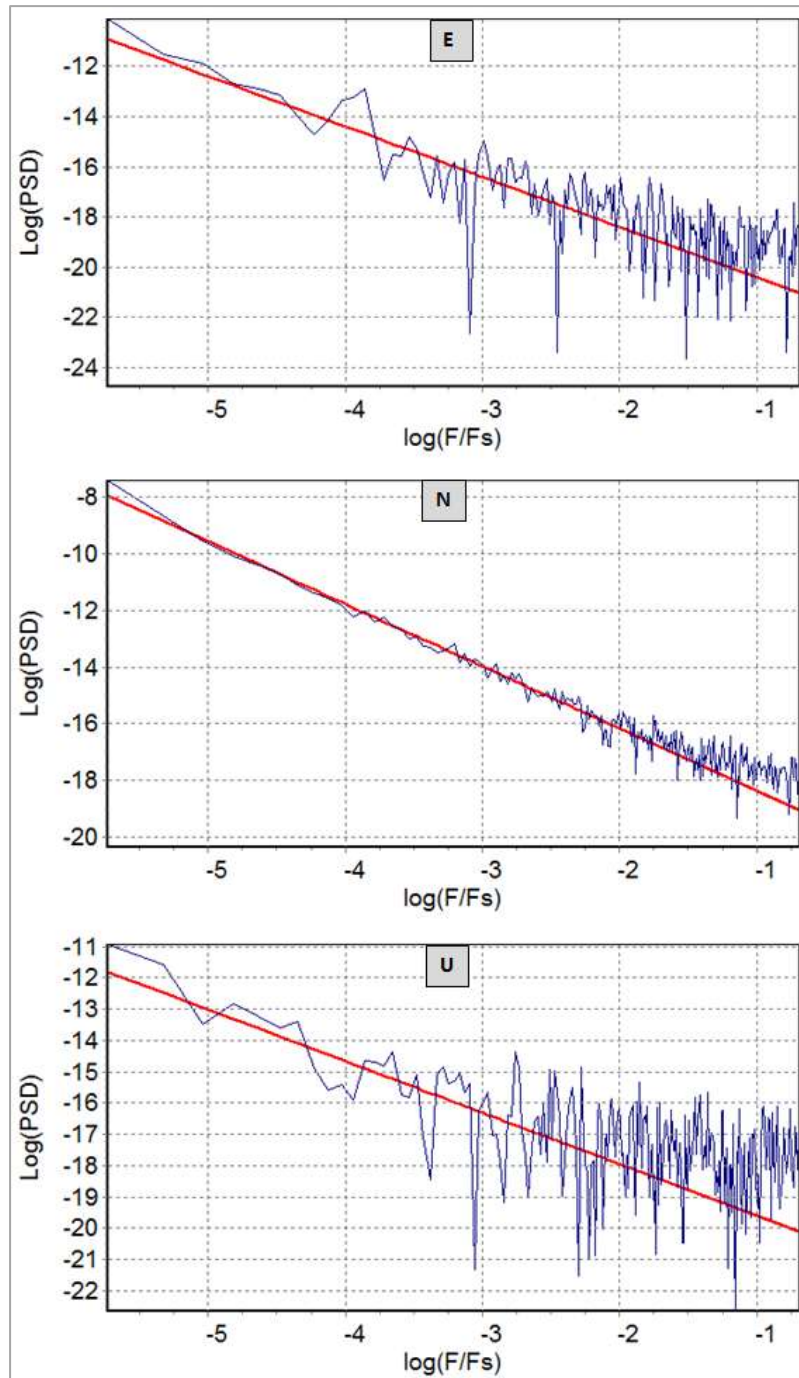


Figura 6.49: Gráficos de PSD das séries temporais (E, N e U) da estação RECF (SIRGAS-CON)



A partir do ângulo (α) de inclinação dos gráficos de PSD das séries temporais (Figura 6.45 a Figura 6.49) podem-se identificar os tipos de ruídos contidos nas séries, conforme mostra a Tabela 6.6 em comparação com a Tabela 4.2.

Tabela 6.6: Caracterização de ruídos a partir do ângulo de inclinação da PSD (Estações SIRGAS-CON)

Estação	E		N		U	
	α	Tipo de ruído	α	Tipo de ruído	α	Tipo de ruído
BRAZ	-2,1	Caminho aleatório	-2,2	Caminho aleatório	-1,7	Caminho aleatório
MAPA	-2,2	Caminho aleatório	-2,3	Caminho aleatório	-0,81	Ruído rosa
POAL	-2,2	Caminho aleatório	-2,2	Caminho aleatório	-1,2	Ruído rosa
PPTÉ	-2,2	Caminho aleatório	-2,2	Caminho aleatório	-1,6	Caminho aleatório
RECF	-2,0	Caminho aleatório	-2,2	Caminho aleatório	-1,7	Caminho aleatório

Foram construídos também os gráficos log-log de desvio-padrão de Allan (ADEV e MDEV) para cada uma das estações, os quais são mostrados nas Figuras de 6.50 a 6.54.

Figura 6.50: Gráfico log-log do ADEV e MDEV para as séries temporais da estação BRAZ (SIRGAS-CON)

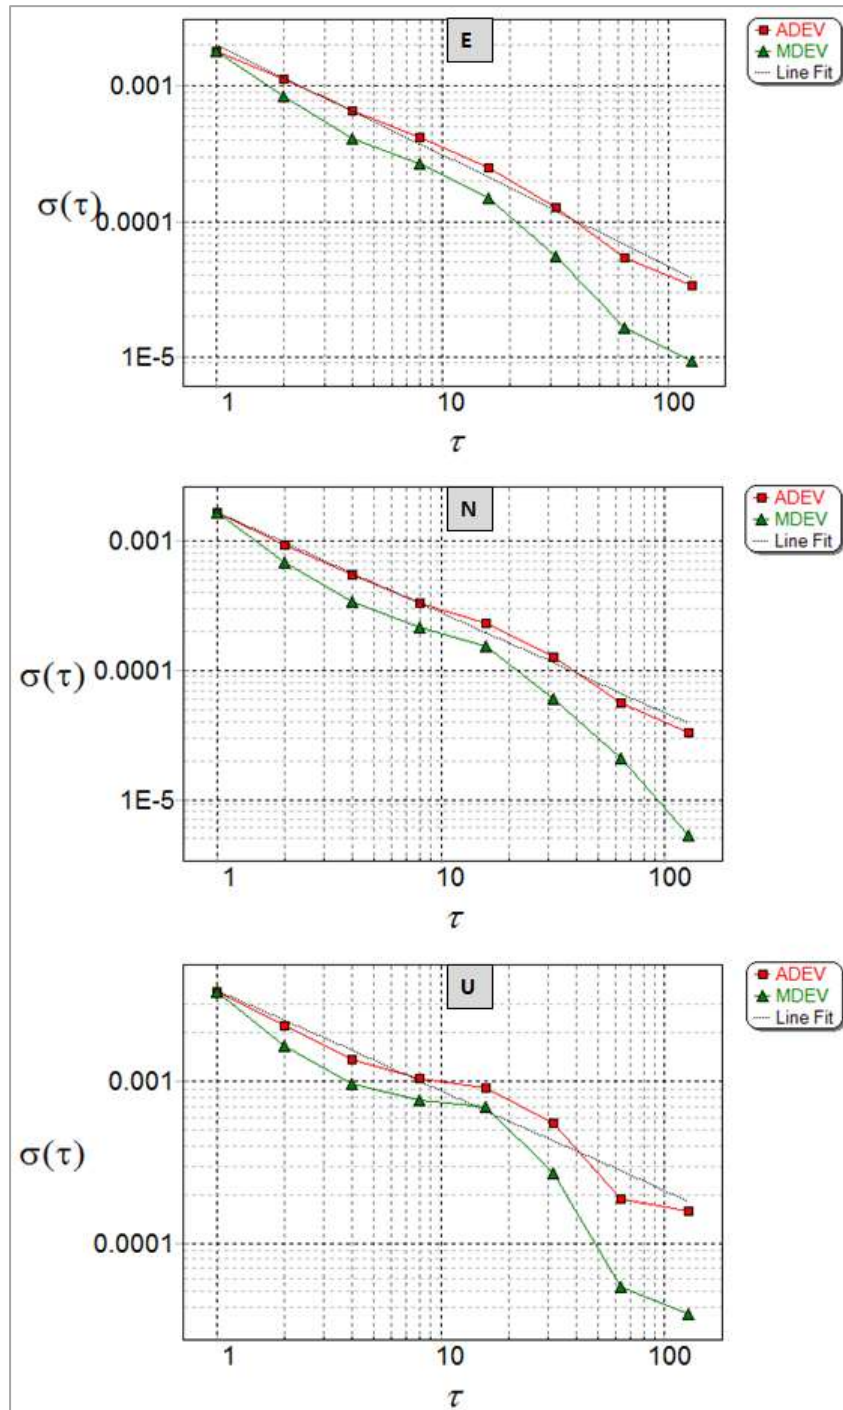


Figura 6.51: Gráfico log-log do ADEV e MDEV para as séries temporais da estação MAPA (SIRGAS-CON)

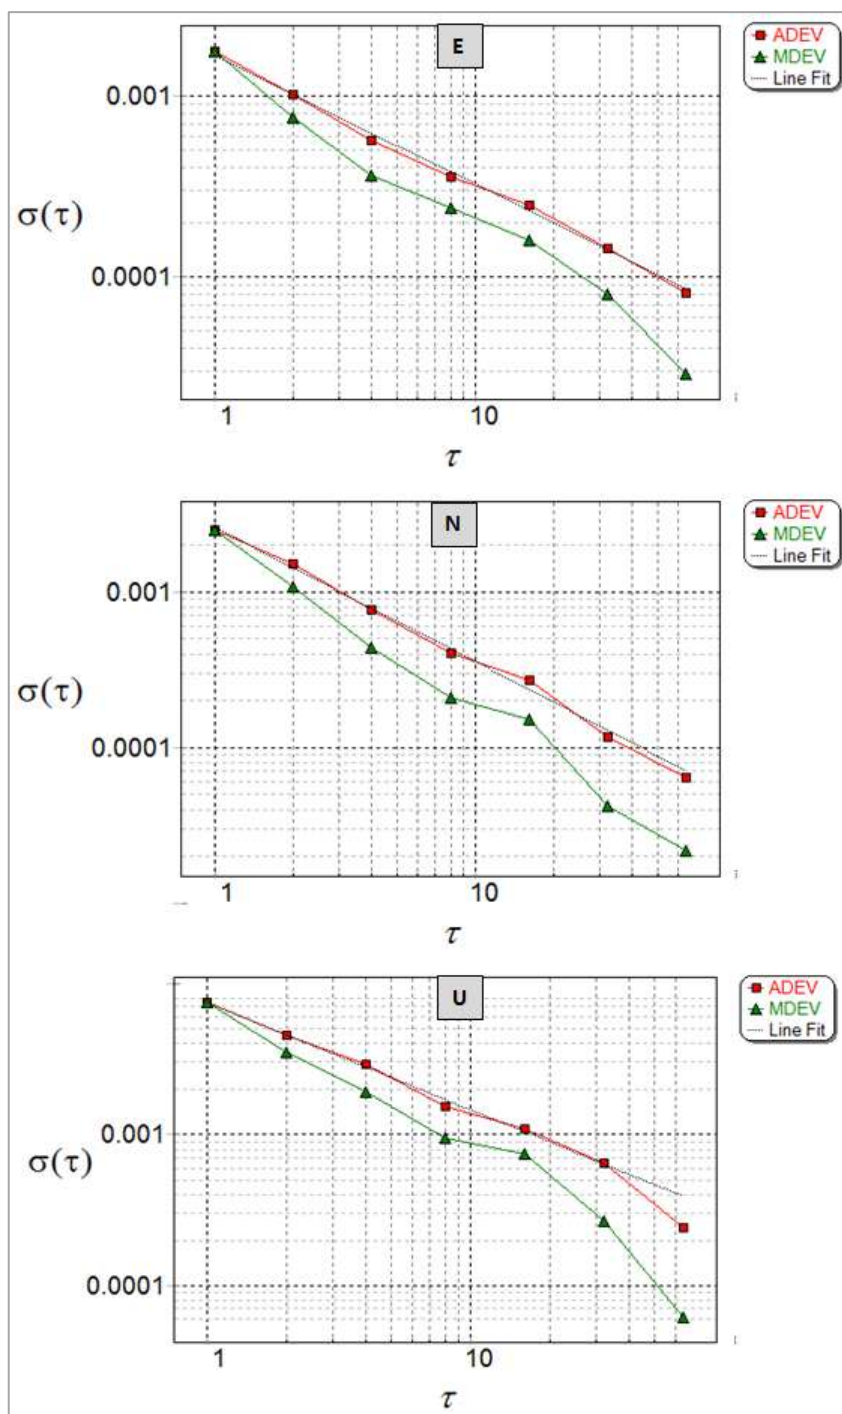


Figura 6.52: Gráfico log-log do ADEV e MDEV para as séries temporais da estação POAL (SIRGAS-CON)

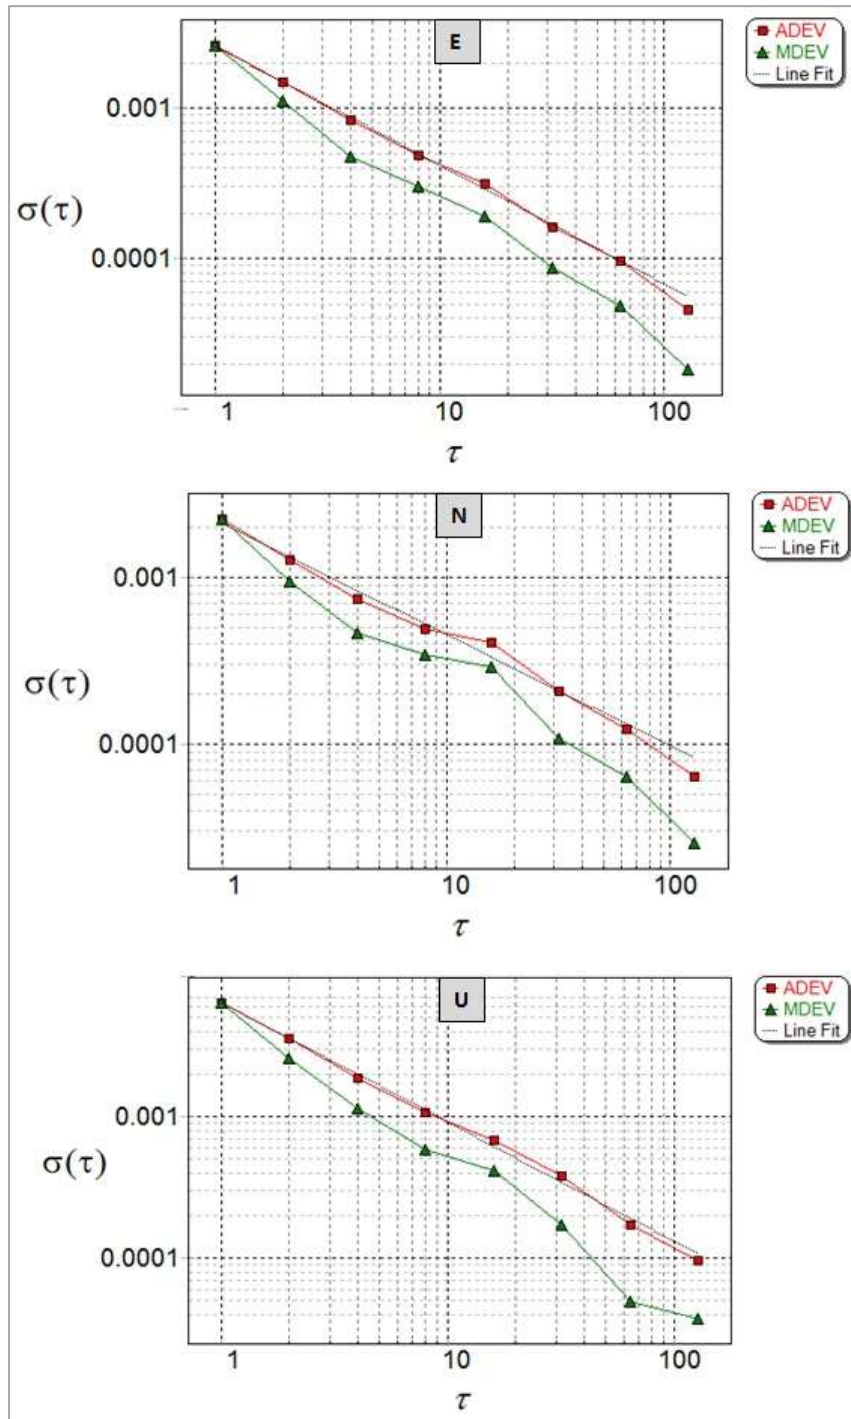


Figura 6.53: Gráfico log-log do ADEV e MDEV para as séries temporais da estação PPTE (SIRGAS-CON)

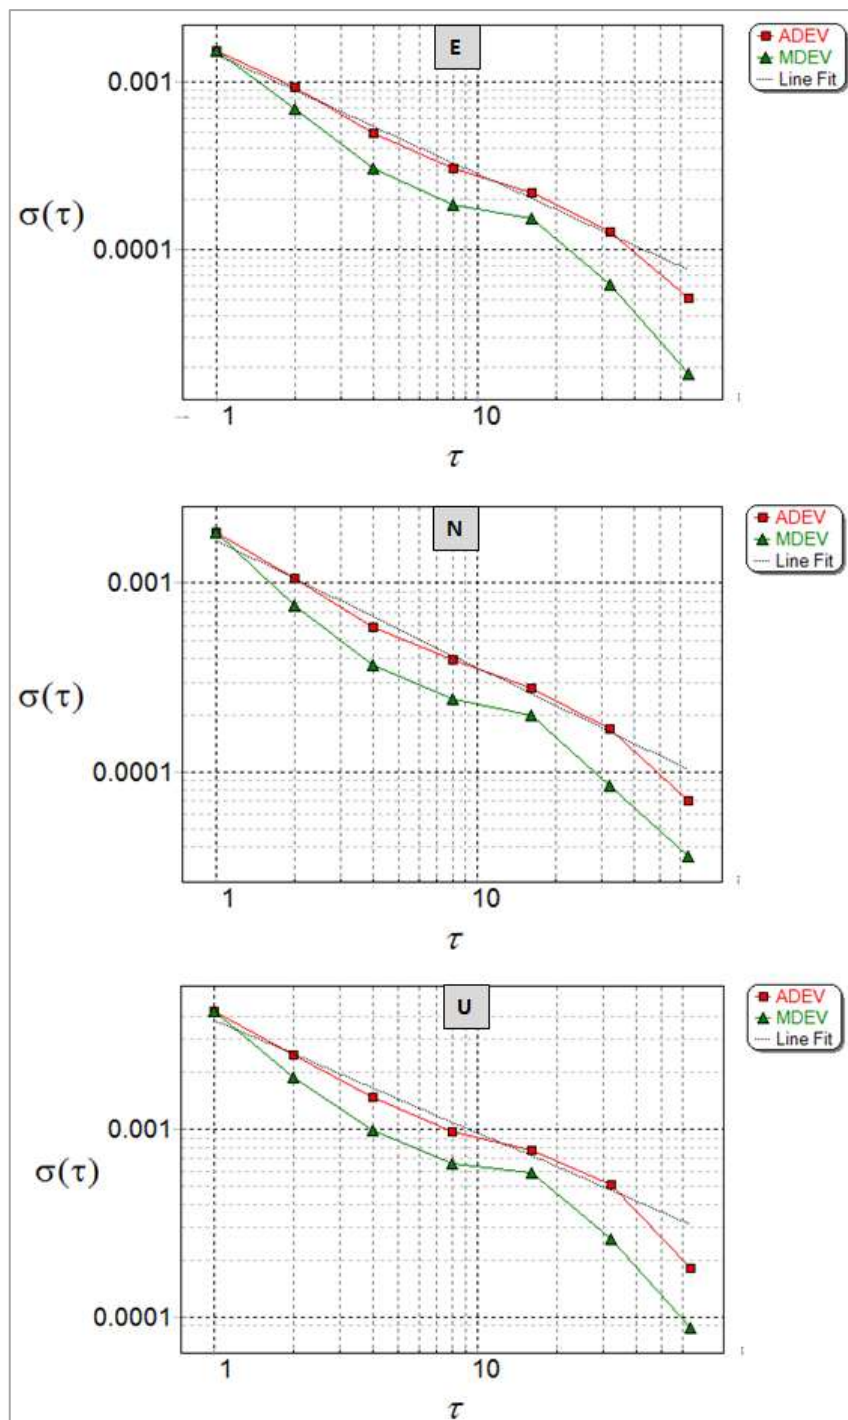
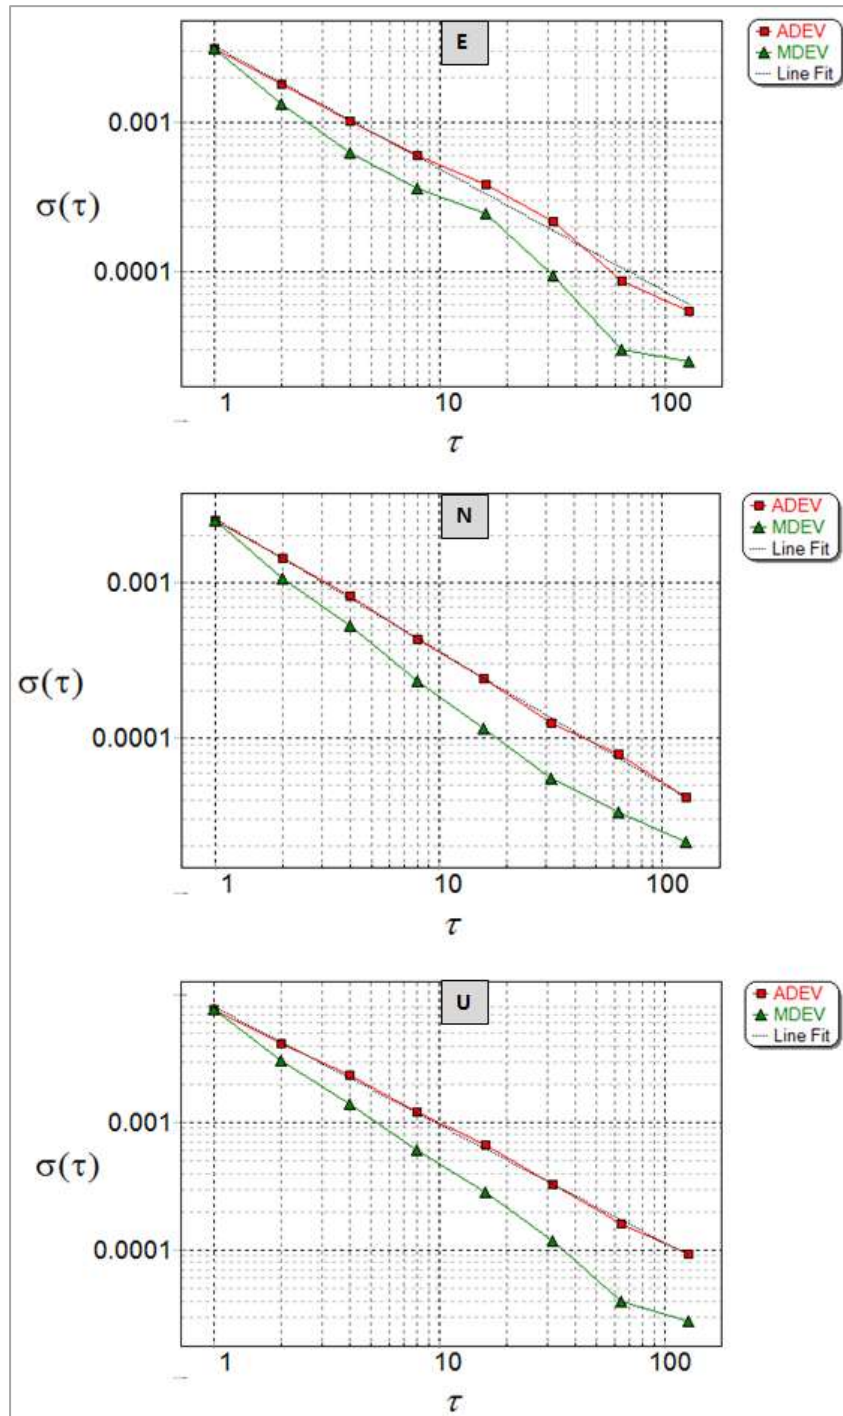


Figura 6.54: Gráfico log-log do ADEV e MDEV para as séries temporais da estação RECF (SIRGAS-CON)



De acordo com o ângulo (β) de inclinação da reta ajustada para cada gráfico de log-log do desvio-padrão de Allan (Figura 6.50 a Figura 6.54) e da Tabela 4.2, podem-se identificar os seguintes tipos de ruído em cada uma das séries como mostra a Tabela 6.7.

Tabela 6.7: Caracterização de ruídos a partir do ângulo de inclinação do gráfico de log-log do desvio-padrão de Allan (Estações SIRGAS-CON)

Estação	E		N		U	
	β	Tipo de ruído	β	Tipo de ruído	β	Tipo de ruído
BRAZ	-0,816	Super rosa ou super branco	-	Super rosa ou super branco	-	Ruído branco
MAPA	-0,712	Ruído branco	0,772	Super rosa ou super branco	0,616	Ruído branco
POAL	-0,790	Super rosa ou super branco	-	Super rosa ou super branco	-	Ruído branco
POTE	-0,713	Ruído branco	0,865	Ruído branco	0,846	Super flicker ou super white
RECF	-0,822	Super rosa ou super branco	0,667	Ruído branco	-	Ruído branco
			0,676	Super rosa ou super branco	0,602	Super rosa ou super branco
			-		-	
			0,850		0,925	

Ao analisar a Tabela 6.6 e a Tabela 6.7, verifica-se que para algumas séries a identificação do tipo de ruído foi diferente ao analisar a inclinação da reta da PSD e a do ADEV, principalmente nas componentes E e U . Normalmente há uma relação entre os gráficos de log da PSD e os gráficos de log do ADEV, no entanto isso não ocorreu para as séries temporais analisadas. Isso pode decorrer do fato que as séries temporais de coordenadas é composta por mais de um tipo de ruídos. Pode-se verificar, visualmente, que ao comparar os gráficos log-log de MDEV com a Figura 4.7, principalmente com relação às séries da componente U , que há mais dum ruído, por exemplo, ruído branco e ruído rosa, com prevalência do ruído branco.

6.2.2 Estimativa das componentes de variância a partir do MMQ e identificação do modelo estocástico das séries temporais

A estimativa de componentes de variância foi realizada de acordo com a seção 4.2.3 e o teste estatístico w utilizado na identificação do modelo estocástico foi baseado na seção 4.2.4, sendo os algoritmos desenvolvidos no software MatLab.

Os valores estimados das componentes de variância para as séries temporais de coordenadas E , N e U , bem como a estatística \underline{w} (Equação 4.58) para cada uma das estações SIRGAS-CON e JPL são apresentados nas tabelas a seguir.

Tabela 6.8: Estimativa de componentes de variância e teste w das séries temporais do SIRGAS-CON

Estação	Série temporal	Componentes de variância			Teste estatístico w	
		σ_w^2	σ_f^2	σ_{rw}^2	$Q_y = \sigma_w^2 I + \sigma_f^2 Q_f$	$Q_y = \sigma_w^2 I + \sigma_{rw}^2 Q_{rw}$
BRAZ	E	3,7021E-06	1,4737E-05	-9,6528E-04	27,5026	18,0980
	N	3,6268E-06	1,8049E-05	-6,5941E-04	28,0736	18,4737
	U	5,3120E-05	3,2153E-04	-2,3351E-02	1,9167	1,2613
MAPA	E	4,6618E-06	2,2882E-05	-3,4854E-04	47,3840	28,5912
	N	5,2749E-06	1,8380E-05	-6,1641E-04	41,8766	25,2680
	U	9,9058E-05	4,7120E-04	-2,6669E-02	2,2299	1,3455
POAL	E	6,3426E-06	2,4780E-05	2,8893E-03	209,2421	223,1697
	N	1,0554E-05	5,8480E-05	-3,0622E-03	125,7443	134,1141
	U	3,4462E-05	1,1976E-04	1,1640E-03	38,5106	41,0740
PPTE	E	3,3973E-06	1,5931E-05	-4,4045E-04	47,1489	43,3851
	N	6,1296E-06	3,1966E-05	-8,4200E-04	26,1325	24,0463
	U	3,9906E-05	2,1843E-04	4,0631E-03	4,0139	3,6935
RECF	E	8,3706E-06	2,9376E-05	5,8895E-03	211,9776	273,1452
	N	4,1147E-06	1,1427E-05	7,4535E-04	431,2311	555,6659
	U	3,5772E-05	8,3973E-05	-4,3745E-03	49,6031	63,9164

Tabela 6.9: Estimativa de componentes de variância e teste w das séries temporais do JPL

Estação	Série temporal	Componentes de variância			Teste estatístico w	
		σ_w^2	σ_f^2	σ_{rw}^2	$Q_y = \sigma_w^2 I + \sigma_f^2 Q_f$	$Q_y = \sigma_w^2 I + \sigma_{rw}^2 Q_{rw}$
BRAZ	E	4,5403E-06	6,4270E-06	-6,0429E-04	126,3582	107,9103
	N	4,5806E-06	6,7145E-06	8,4798E-04	79,0635	22,1342
	U	4,9700E-05	8,6127E-05	1,1227E-01	240,8872	109,5682
BRFT	E	3,7352E-06	4,8562E-06	1,1595E-03	73,8023	23,0474
	N	4,8743E-06	9,9975E-06	3,7106E-02	56,5548	17,6613
	U	3,4048E-05	3,1086E-05	2,9508E-02	8,0963	2,5284
CHPI	E	3,5347E-06	4,3744E-06	1,2815E-03	156,8511	133,5651
	N	4,1188E-06	6,6893E-06	5,8722E-03	134,6082	114,6243
	U	3,9922E-05	5,3592E-05	2,4335E-02	13,8878	11,8260
SAVO	E	1,5370E-05	6,1249E-06	-9,1385E-05	13,5889	5,6380
	N	5,4335E-06	3,7738E-06	3,6877E-04	38,4388	15,9480
	U	5,6266E-05	2,9643E-05	1,6989E-02	3,7119	1,5401

Considerando que a estatística w tabelada⁵ é 1,64, verifica-se a partir da Tabela 6.8 e da Tabela 6.9 que as estatísticas \underline{w} calculadas são maiores que esse valor, indicando que séries temporais são compostas não somente de ruído branco, mas também por outros tipos de ruídos. A identificação de qual o modelo estocástico é mais adequado

⁵ $w_{tab} \sim N_{\alpha/2}(0,1)$. Nessa tese adotou-se $\alpha = 5\%$.

para modelar a série (composto de ruído branco e ruído rosa ou ruído branco e caminho aleatório) é dada pela maior estatística entre esses dois modelos. Assim, verifica-se que apenas para as estações POAL e RECF do SIRGAS-CON o modelo mais provável é em função do ruído branco e caminho aleatório e para todas as outras séries é o modelo em função do ruído branco e do ruído rosa. No entanto, é importante verificar o sinal (+ ou -) do valor de cada componente de variância. Quando o sinal da componente de variância é negativo significa o modelo de ruído relacionado a este ruído não é apropriado ao modelo e deve ser excluído do modelo estocástico. Então, no caso da série temporal da componente N da estação POAL e da série temporal da componente U da estação RECF a componente de variância relacionado ao caminho aleatório não deve ser utilizado no modelo estocástico.

As componentes de variância estimadas para cada uma das séries temporais realizadas nessa seção bem como a identificação do modelo estocástico mais adequado podem ser utilizadas na construção de modelos funcionais que melhor se adapte a cada série.

A estimativa do modelo funcional de séries temporais é realizada baseada na Equação 4.25 e pode ser realizada a modificação do modelo funcional ou do modelo estocástico para identificar o modelo que melhor se adequa a cada série. Experimentos relacionados a essa abordagem serão apresentados na seção 6.2.3.

6.2.3 Estimativa do modelo funcional das séries temporais de coordenadas GNSS

A estimativa do modelo funcional utilizando a regressão linear pelo MMQ ponderado é realizada para tornar os dados estacionários. Nesse caso, o modelo funcional (Equação 4.25) é ponderado pelas precisões (σ) de cada componente da série (precisões diferentes), conforme o modelo abaixo:

$$\frac{E\{y(t)\}}{\sigma_i} = \frac{y_0}{\sigma_i} + r \frac{t}{\sigma_i} + \sum_{k=1}^q a_k \frac{\cos(\varpi_k t)}{\sigma_i} + b_k \frac{\text{sen}(\varpi_k t)}{\sigma_i}, \quad i = 1, 2, \dots, n \quad (6.1)$$

Nessa etapa, foram realizados experimentos, modificando o modelo funcional através da quantidade de funções harmônicas e/ou acrescentando o termo quadrático na Equação 4.25 (seção 6.2.3.1) e também modificando o modelo estocástico (seção 6.2.3.2). Os resultados com modificação do modelo funcional é descrito na próxima seção.

6.2.3.1 Modificação do modelo funcional

A estimativa do modelo funcional das séries temporais foi realizada primeiramente utilizando $q = 10$, ou seja, dez sinais periódicos, na Equação 6.1. Em seguida, baseado no resultado dessa estimativa, foi realizado um novo ajustamento considerando apenas as variáveis significativas a um nível de significância de 5%. Posteriormente, foi realizado um novo processamento considerando na Equação 6.1 apenas os sinais anuais e semianuais, ou seja, dois sinais periódicos ($q = 2$). Todos os processamentos foram realizados no software R.

As Tabelas 6.10, 6.11 e 6.12 mostram as estatísticas advindas dos ajustamentos das séries temporais (estimativa do modelo funcional) da estação BRAZ (JPL) utilizando dez sinais periódicos.

Tabela 6.10: Resumo de estatísticas da estimativa do modelo funcional (10 harmônicos esféricos) da componente E da estação BRAZ (JPL)

Coefficientes	Estimativa	Desvio-padrão	Valor de t	Probabilidade(> t)
xts	8.267e+00	1.705e-02	484.872	< 2e-16 ***
xs	-4.145e-03	8.494e-06	-488.009	< 2e-16 ***
x1_p	3.888e-04	4.327e-05	8.985	< 2e-16 ***
x11_p	-1.096e-03	4.382e-05	-25.015	< 2e-16 ***
x2_p	-1.418e-04	4.368e-05	-3.245	0.00118 **
x12_p	-7.721e-05	4.342e-05	-1.778	0.07541 .
x3_p	3.532e-04	4.402e-05	8.023	1.33e-15 ***
x13_p	1.054e-04	4.307e-05	2.446	0.01448 *
x4_p	1.277e-04	4.341e-05	2.942	0.00328 **
x14_p	-3.134e-05	4.370e-05	-0.717	0.47334
x5_p	1.037e-05	4.367e-05	0.237	0.81233
x15_p	-8.410e-05	4.341e-05	-1.938	0.05275 .
x6_p	1.005e-05	4.355e-05	0.231	0.81742
x16_p	9.068e-06	4.350e-05	0.208	0.83489
x7_p	1.667e-05	4.342e-05	0.384	0.70102
x17_p	5.430e-06	4.362e-05	0.124	0.90095
x8_p	-3.380e-05	4.363e-05	-0.775	0.43852
x18_p	3.385e-06	4.339e-05	0.078	0.93782
x9_p	7.951e-05	4.348e-05	1.829	0.06751
x19_p	1.743e-05	4.354e-05	0.400	0.68891
x10_p	5.845e-05	4.332e-05	1.349	0.17737
x20_p	4.767e-05	4.345e-05	1.097	0.27267

Tabela 6.11: Resumo de estatísticas da estimativa do modelo funcional (10 harmônicos esféricos) da componente N da estação BRAZ (JPL)

Coeficientes	Estimativa	Desvio-padrão	Valor de t	Probabilidade(> t)
x _{ts}	-2.50E+01	1.71E-02	-1458.164	< 2e-16 ***
x _s	1.25E-02	8.52E-06	1467.332	< 2e-16 ***
x _{1_p}	9.16E-04	4.34E-05	21.083	< 2e-16 ***
x _{11_p}	5.96E-04	4.41E-05	13.518	< 2e-16 ***
x _{2_p}	-4.36E-04	4.39E-05	-9.94	< 2e-16 ***
x _{12_p}	5.42E-05	4.36E-05	1.242	0.21423
x _{3_p}	-2.06E-05	4.42E-05	-0.465	0.64174
x _{13_p}	1.04E-05	4.33E-05	0.241	0.80954
x _{4_p}	-2.62E-05	4.37E-05	-0.599	0.54895
x _{14_p}	-3.88E-05	4.39E-05	-0.885	0.37612
x _{5_p}	-6.61E-05	4.39E-05	-1.507	0.13189
x _{15_p}	-1.22E-04	4.36E-05	-2.798	0.00517 **
x _{6_p}	2.38E-05	4.38E-05	0.542	0.58761
x _{16_p}	9.23E-05	4.37E-05	2.114	0.03460 *
x _{7_p}	-4.55E-05	4.36E-05	-1.042	0.29741
x _{17_p}	1.52E-04	4.39E-05	3.468	0.00053 ***
x _{8_p}	1.04E-05	4.39E-05	0.238	0.81217
x _{18_p}	-1.18E-05	4.36E-05	-0.271	0.78666
x _{9_p}	-1.97E-04	4.37E-05	-4.507	6.76e-06 ***
x _{19_p}	3.25E-05	4.37E-05	0.743	0.45727
x _{10_p}	3.45E-05	4.35E-05	0.791	0.42876
x _{20_p}	9.46E-05	4.36E-05	2.169	0.03018 *

Tabela 6.12: Resumo de estatísticas da estimativa do modelo funcional (10 harmônicos esféricos) da componente U da estação BRAZ (JPL)

Coeficientes	Estimativa	Desvio-padrão	Valor de t	Probabilidade(> t)
x _{ts}	1.70E+00	5.27E-02	32.344	< 2e-16 ***
x _s	-8.61E-04	2.62E-05	-32.809	< 2e-16 ***
x _{1_p}	3.09E-03	1.34E-04	23.122	< 2e-16 ***
x _{11_p}	-8.26E-03	1.36E-04	-60.868	< 2e-16 ***
x _{2_p}	-9.39E-04	1.35E-04	-6.948	4.28e-12 ***
x _{12_p}	-1.71E-03	1.34E-04	-12.691	< 2e-16 ***
x _{3_p}	-3.55E-04	1.36E-04	-2.604	0.00925 **
x _{13_p}	5.37E-04	1.33E-04	4.028	5.74e-05 ***
x _{4_p}	-7.16E-05	1.34E-04	-0.533	0.59434
x _{14_p}	-1.50E-04	1.35E-04	-1.112	0.26622
x _{5_p}	1.05E-04	1.35E-04	0.778	0.43657
x _{15_p}	-3.02E-04	1.34E-04	-2.25	0.02451 *
x _{6_p}	1.74E-04	1.35E-04	1.293	0.19613
x _{16_p}	-5.08E-05	1.35E-04	-0.377	0.70594
x _{7_p}	-1.38E-04	1.34E-04	-1.028	0.30412
x _{17_p}	-1.38E-04	1.35E-04	-1.021	0.30746
x _{8_p}	-1.25E-05	1.35E-04	-0.092	0.9265
x _{18_p}	1.05E-05	1.34E-04	0.079	0.93739
x _{9_p}	7.66E-06	1.35E-04	0.057	0.95458
x _{19_p}	1.63E-04	1.35E-04	1.21	0.2264
x _{10_p}	-1.51E-04	1.34E-04	-1.127	0.25968
x _{20_p}	1.42E-04	1.34E-04	1.055	0.29166

Nas tabelas 6.10, 6.11 e 6.12, os coeficientes da Equação 6.1 são representados da seguinte forma:

$$x_{ts} = 1/\sigma_i; x_s = t/\sigma_i$$

$$x1_p = \cos(\varpi_k t)/\sigma_i; x11_p = \sin(\varpi_k t)/\sigma_i; \dots, x10_p = \cos(\varpi_k t)/\sigma_i; x20_p = \sin(\varpi_k t)/\sigma_i$$

Nos experimentos realizados, os valores de ϖ_k foram baseados nas funções senoidais, ou seja, $\varpi_k = 2\pi k$. No entanto, os valores de ϖ_k podem ser identificados através de análise do periodograma ou através de wavelets.

Os modelos funcionais estimados para o caso da estação BRAZ são mostrados na Tabela 6.13.

Tabela 6.13: Modelos funcionais estimados da estação BRAZ (JPL)

Série temporal	Modelo funcional
E	$\hat{y}(t) = 8,267 - 4,145 \times 10^{-3}t + 3,888 \times 10^{-4} \cos(\varpi_1 t) - 1,096 \times 10^{-3} \sin(\varpi_1 t),$ $-1,418 \times 10^{-4} \cos(\varpi_2 t) - 7,721 \times 10^{-5} \sin(\varpi_2 t), \dots,$ $+ 5,845 \times 10^{-5} \cos(\varpi_{10} t) + 4,767 \times 10^{-5} \sin(\varpi_{20} t)$
N	$\hat{y}(t) = -25,00 + 1,25 \times 10^{-2}t + 9,16 \times 10^{-4} \cos(\varpi_1 t) + 5,96 \times 10^{-4} \sin(\varpi_1 t),$ $-4,36 \times 10^{-4} \cos(\varpi_2 t) + 5,42 \times 10^{-5} \sin(\varpi_2 t), \dots,$ $+ 3,45 \times 10^{-5} \cos(\varpi_{10} t) + 9,46 \times 10^{-5} \sin(\varpi_{20} t)$
U	$\hat{y}(t) = 1,70 - 8,61 \times 10^{-4}t + 3,09 \times 10^{-3} \cos(\varpi_1 t) - 8,26 \times 10^{-3} \sin(\varpi_1 t),$ $-9,39 \times 10^{-4} \cos(\varpi_2 t) - 1,71 \times 10^{-3} \sin(\varpi_2 t), \dots,$ $- 1,51 \times 10^{-4} \cos(\varpi_{10} t) + 1,42 \times 10^{-4} \sin(\varpi_{20} t)$

As variáveis mais representativas (variáveis explicativas significativas) do modelo são escolhidas de acordo com o nível de significância adotado. Por exemplo, as variáveis representativas podem ser escolhidas de acordo com os seguintes códigos:

“***” indica que a variável é representativa a um nível de significância de 0,1%;

“**” indica que a variável é representativa um nível de significância de 1%;

“*” indica que a variável é representativa um nível de significância de 5%;

“.” indica que a variável é representativa um nível de significância de 10%.

Nesta tese, foram escolhidas como variáveis (incógnitas) representativas do modelo funcional da série temporal aquelas com um nível de significância menor do que 5%, ou seja, indicadas com “*”, “**” e “***”. Por exemplo, a partir da Tabela 6.10 para a série temporal da componente E as variáveis representativas são as relacionadas aos seguintes coeficientes: x_{ts} , x_s , $x1_p$, $x11_p$, $x2_p$, $x3_p$, $x13_p$ e x_{4p} . Baseado nesses resultados as

séries temporais são reprocessadas considerando apenas essas variáveis. Sendo assim as séries temporais foram processadas considerando os modelos funcionais da Tabela 6.14:

Tabela 6.14: Modelagens funcionais das séries temporais de coordenadas GNSS

Modelo funcional	Descrição
Mod_func_1	Estimativa considerando a tendência linear e 10 termos trigonométricos, ou seja, $q=10$.
Mod_func_2	Estimativa considerando a tendência linear e as variáveis representativas do modelo funcional.
Mod_func_3	Estimativa considerando a tendência linear e 2 termos trigonométricos, ou seja, $q=2$ (termos anuais e semianuais).

A Figura 6.55, a Figura 6.56 e a Figura 6.57 mostram as séries temporais (E , N e U) da estação BRAZ (JPL) e os modelos funcionais ajustados considerando a Mod_func_1 e a Mod_func_3.

Figura 6.55: Séries temporais (E) e modelos ajustados (Mod_func_1 e Mod_func_3) da estação BRAZ (JPL)




Figura 6.56: Séries temporais (N) e modelos ajustados (Mod_func_1 e Mod_func_3) da estação BRAZ (JPL)





Figura 6.57: Séries temporais (U) e modelos ajustados (Mod_func_1 e Mod_func_3) da estação BRAZ (JPL)



Ao analisar graficamente as Figuras 6.55 a 6.57 verifica-se que ambos os modelos funcionais Mod_func_1 e Mod_func_3 representaram bem as séries temporais da estação BRAZ (JPL).

Uma possível análise de comparação entre modelos funcionais com diferentes números de parâmetros é através da estatística *R-square* ajustado⁶ (R^2 ajustado), o qual é calculado a partir da expressão (CRYER; CHAN, 2008; R CORE TEAM, 2012):


$$R^2_{ajustado} = 1 - \frac{\sum_{i=1}^n v_i^2 (n-1)}{\sum_{i=1}^n (y_i - \bar{y})^2 (n-u)}, \quad (6.2)$$

em que, n é o número de dados da série y e u é número de parâmetros (coeficientes) e v é o vetor de resíduos.

A Figura 6.58 mostra, graficamente, os valores de R^2 ajustado, em porcentagem, obtidos em cada uma das estimativas dos modelos funcionais das séries temporais.

⁶ É o quadrado do coeficiente de correlação amostral entre a série observada e o modelo ajustado. Também pode ser interpretado como a fração da variação na série que é explicada pelo modelo estimado (CRYER; CHAN, 2008; R CORE TEAM, 2012).

Figura 6.58: Valores de R^2 nas estimativas dos modelos funcionais das séries temporais (E, N e U)



Ao analisar a Figura 6.58, verifica-se que os valores de R^2 ajustado atingiram valores acima de 90% e de 99%, respectivamente, para as séries temporais das componentes E e N das estações pertencentes ao SIRGAS-CON e ao JPL, independente do modelo funcional adotado, o que significa que a modelagem funcional adotada é adequada para a série temporal. Já com relação às séries temporais da componente U apenas as séries das estações BRAZ e CHPI do JPL atingiram valores de R^2 ajustado maiores que 90% e para o restante das outras estações os valores de R^2 ajustado ficaram abaixo dos 80%, indicando que para as séries temporais da componente U os modelos funcionais estimados não são adequados. Ao analisar também a Figura 6.55, verifica-se que a série da componente U tem uma maior variabilidade nos dados, o que proporciona uma maior dificuldade na estimativa da modelagem funcional.

Um fato interessante a ser destacado é com relação à estação BRAZ, cujas séries temporais são diárias (JPL) e semanais (SIRGAS.). Ao comparar os valores de R^2 ajustado advindos das estimativas dos modelos funcionais, verifica-se que ao utilizar as séries temporais diárias de todas as componentes, esses atingiram valores acima 90%. Isso significa que ao utilizar um número maior de dados o modelo funcional estimado se adapta melhor à série, principalmente quando se tem uma maior variabilidade nos dados, como é o caso da série temporal da componente U da estação BRAZ.

Com relação aos três diferentes modelos funcionais utilizados, pode-se verificar a partir da Figura 6.58 que no caso das séries temporais das componentes E e N para praticamente todas as estações os valores de R^2 ajustado são praticamente os mesmos, o que indica que se pode estimar um modelo funcional com menos parâmetros (incógnitas), ou seja, menos termos trigonométricos (Mod_func_2 e Mod_func_3) que o modelo se adaptará bem à série temporal. Já para as séries temporais da componente U , as séries temporais relacionadas às estações do JPL tiveram os valores de R^2 ajustado praticamente os mesmos e para as estações do SIRGAS-CON os valores foram menores quando se utilizou menos termos trigonométricos (Mod_func_2 e Mod_func_3). Novamente, quando se tem um número de observações maior o modelo funcional estimado se adapta melhor à série.

É interessante verificar o comportamento de cada uma das séries temporais das estações. A Figura 6.59 até a Figura 6.66 apresentam as séries temporais das outras estações do JPL e também das estações SIRGAS-CON e os modelos funcionais estimados considerando o Mod_func_3.

Figura 6.59: Séries temporais (E, N e U) e modelos ajustados (Mod_func_3) da estação BRFT (JPL)

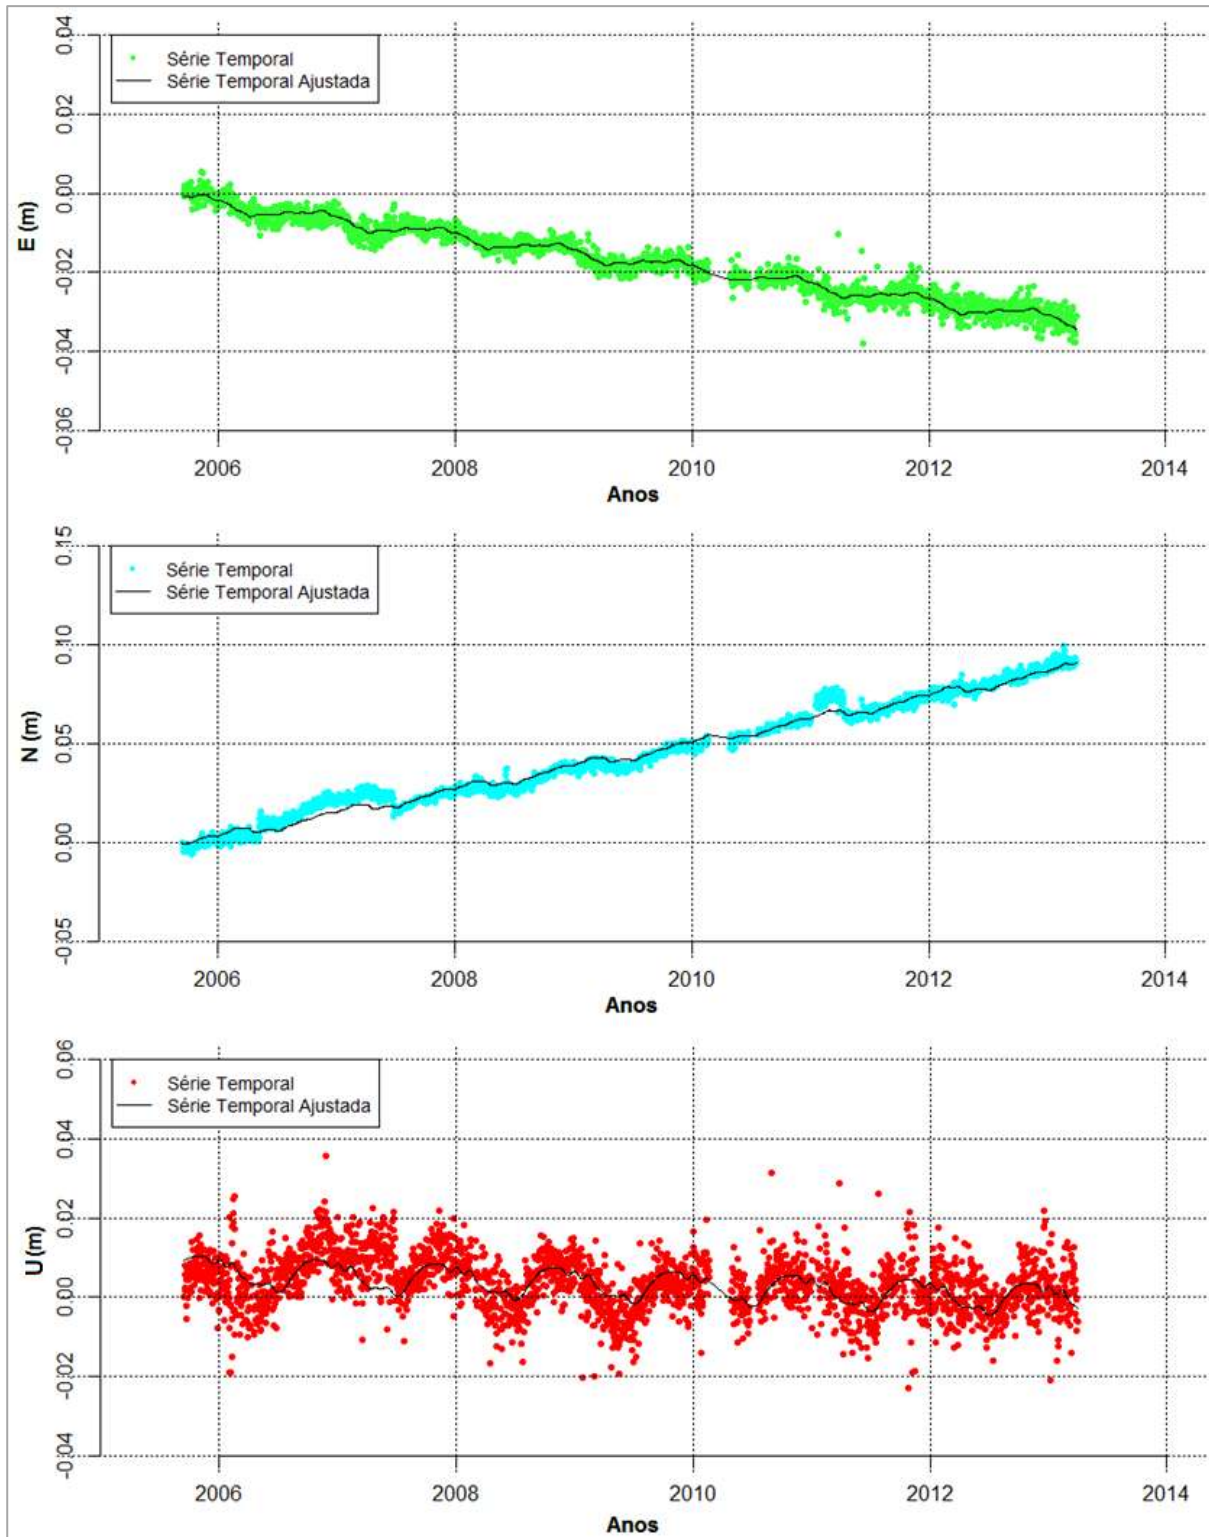


Figura 6.60: Séries temporais (E, N e U) e modelos ajustados (Mod_func_3) da estação CHPI (JPL)

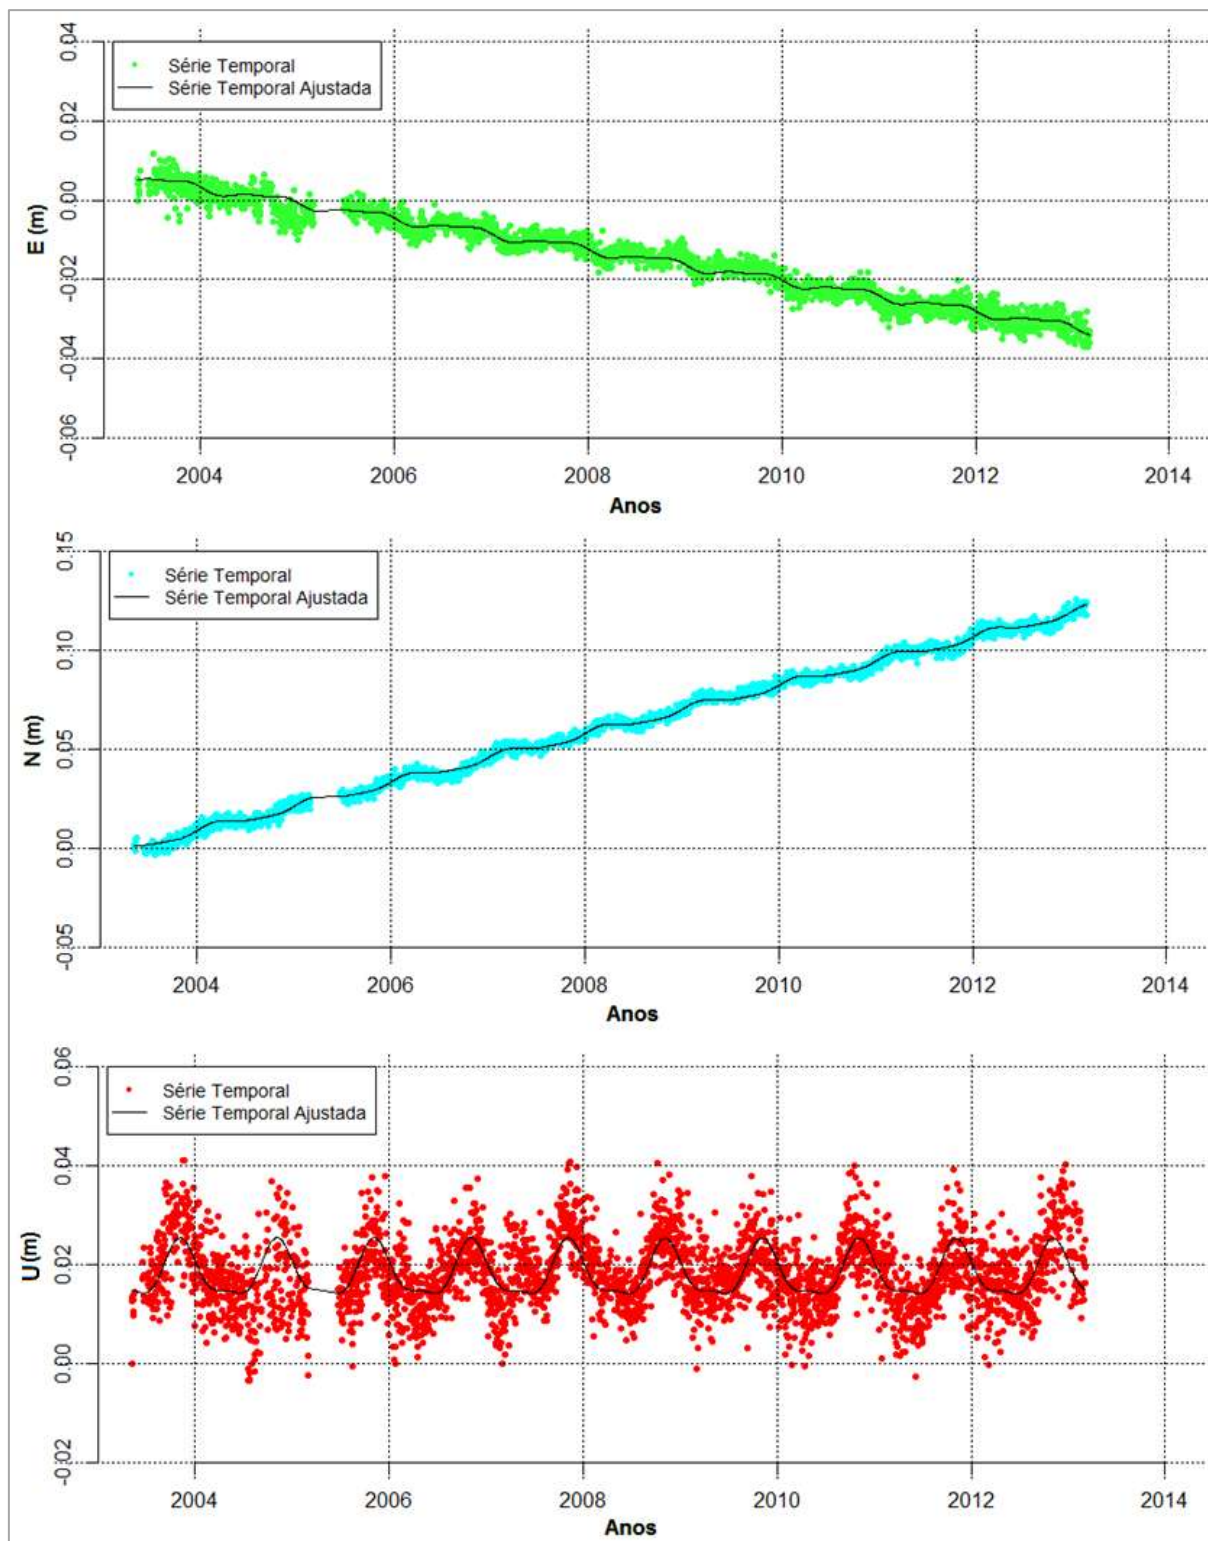


Figura 6.61: Séries temporais (E, N e U) e modelos ajustados (Mod_func_3) da estação SAVO (JPL)




Figura 6.62: Séries temporais (E, N e U) e modelos ajustados (Mod_func_3) da estação BRAZ (SIRGAS-CON)




Figura 6.63: Séries temporais (E, N e U) e modelos ajustados (Mod_func_3) da estação MAPA (SIRGAS-CON)




Figura 6.64: Séries temporais (E, N e U) e modelos ajustados (Mod_func_3) da estação POAL (SIRGAS-CON)

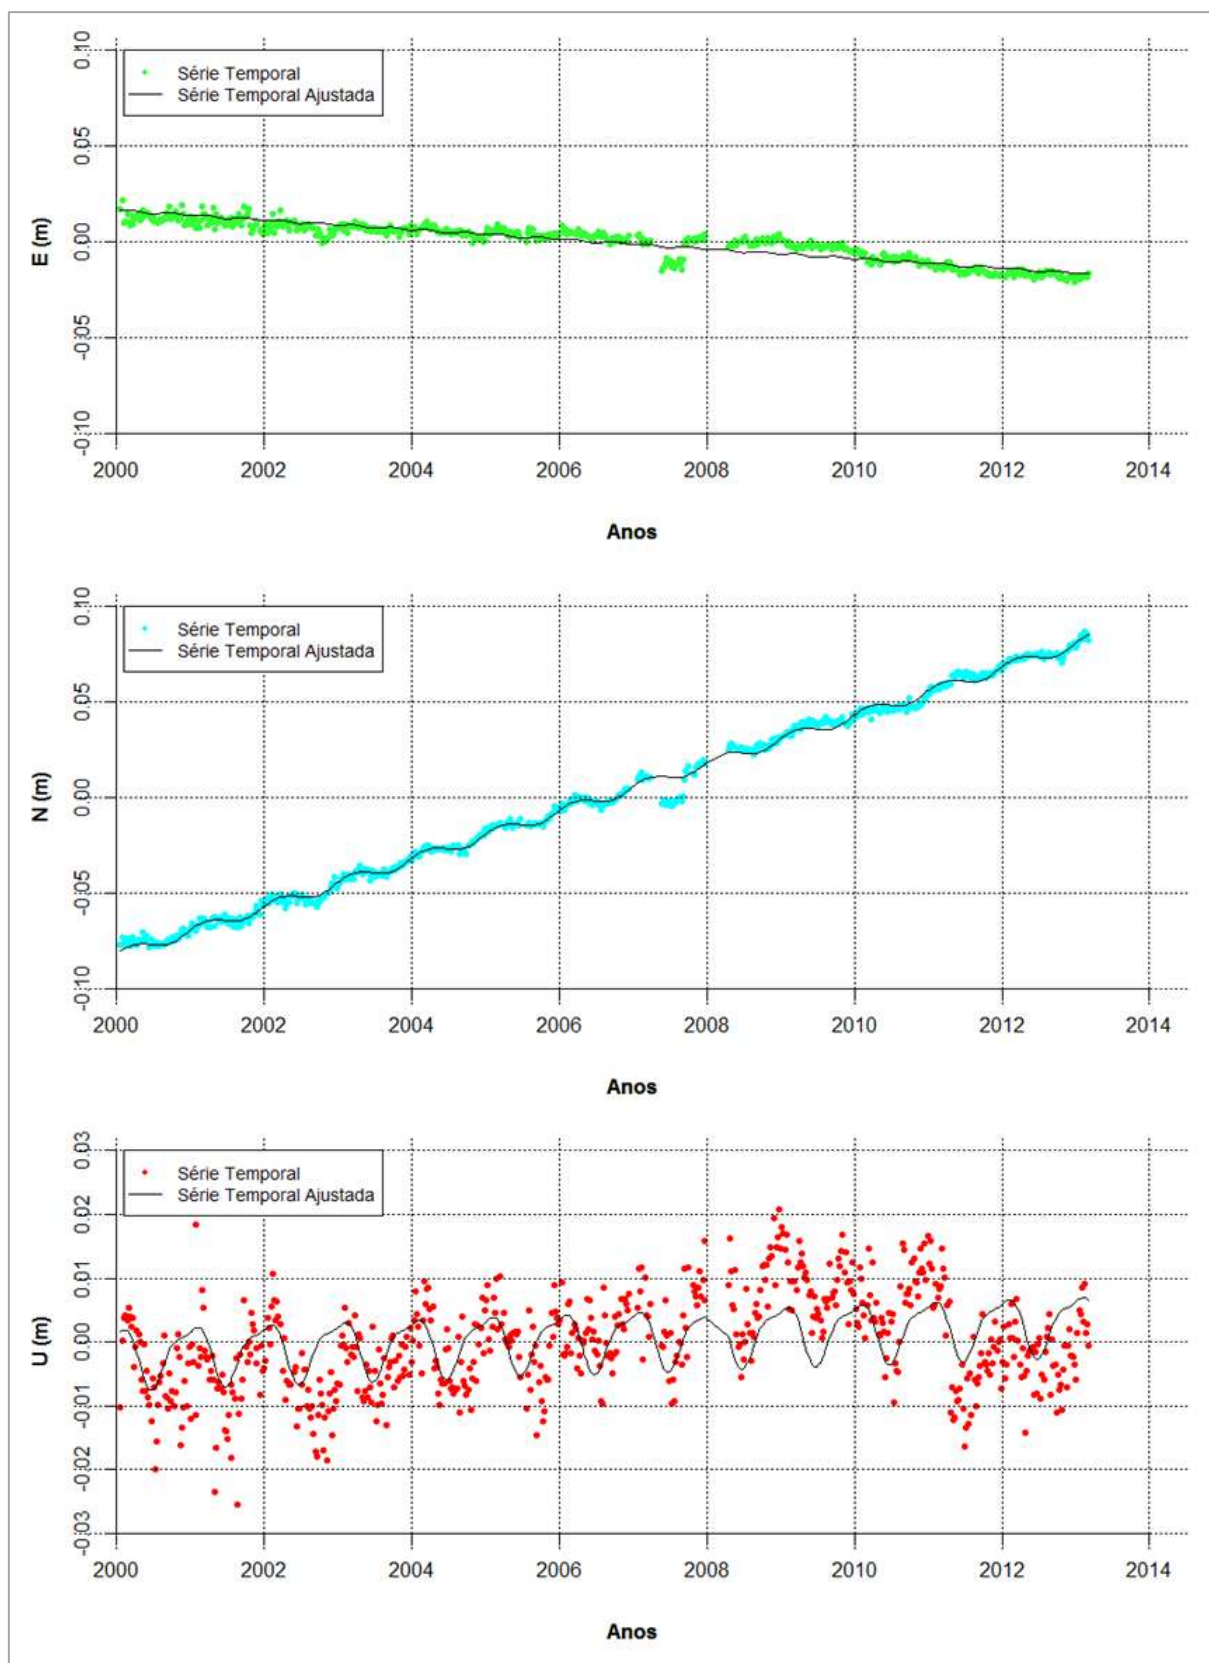


Figura 6.65: Séries temporais (E, N e U) e modelos ajustados (Mod_func_3) da estação PPTe (SIRGAS-CON)

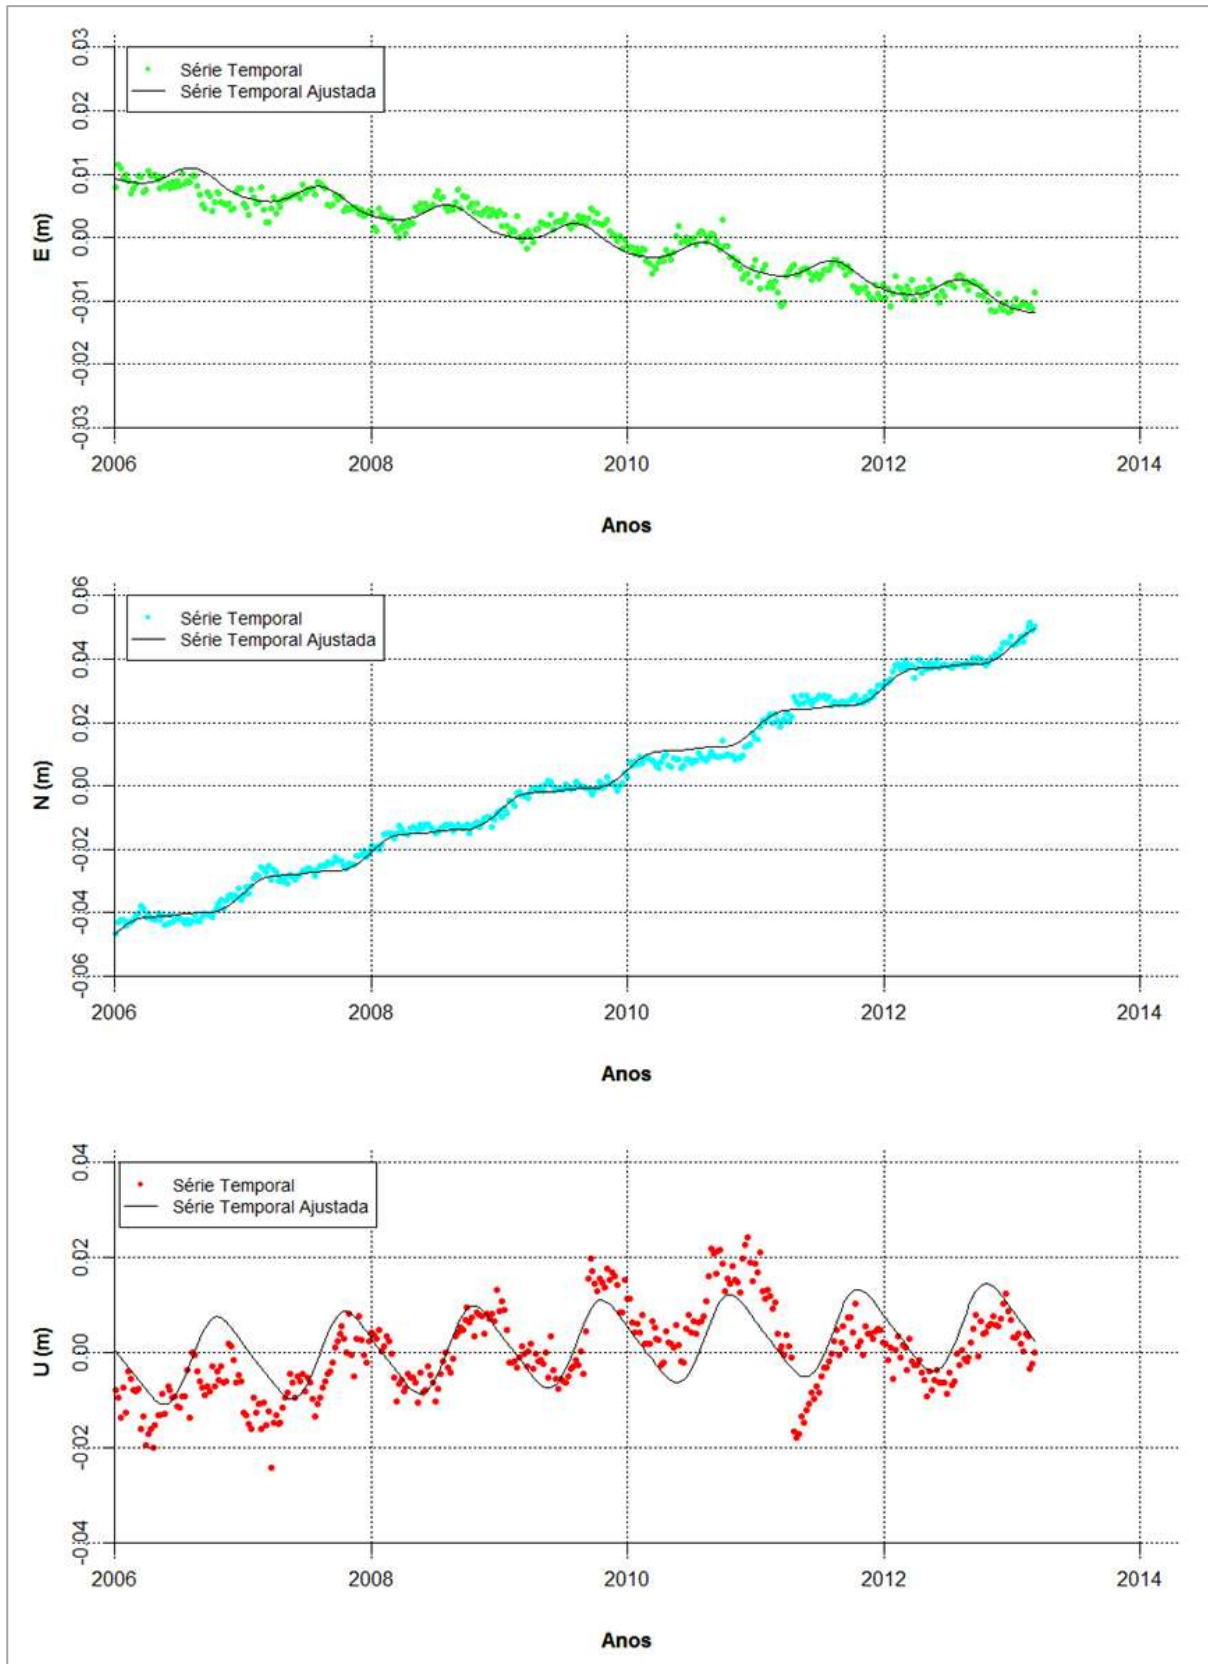



Figura 6.66: Séries temporais (E, N e U) e modelos ajustados (Mod_func_3) da estação RECF (SIRGAS-CON)



Da Figura 6.59 até a Figura 6.66 pode-se verificar que nas séries temporais da componente U de todas as estações do SIRGAS-CON é bem perceptível um “deslocamento” nas séries no início de 2011. É interessante verificar que este “deslocamento” coincide com a data em que houve a mudança de IGS05 para IGS08. Ao comparar a estação BRAZ do SIRGAS-CON com a do JPL, verifica-se que nessa última o “deslocamento” não é tão perceptivo visualmente. Lembrando que as séries temporais do SIRGAS-CON são soluções semanais (média das soluções diárias da semana) e a do JPL serem diárias. É importante dizer que o interessante seria comparar as séries temporais de soluções diárias com soluções semanais que fossem advindas do mesmo processamento.


Na Figura 6.59 referente à série temporal da componente N da estação BRFT (JPL) verifica-se que há dois “deslocamentos” nas séries, no início de 2005 e no início de 2011. Verifica-se também “deslocamentos” nas séries temporais das estações do SIRGAS-CON, principalmente nas séries da componente, também no início de 2011. Com relação a esses “deslocamentos” investigações devem ser realizadas.

Ao analisar as séries temporais das coordenadas U de todas as estações, verifica-se também que seu comportamento acompanha uma função quadrática. Sendo assim, esse termo foi incluindo nos modelos funcionais das séries temporais da componente U de todas as estações, como pode ser visto na equação a seguir:

$$\frac{E\{y(t)\}}{\sigma_i} = \frac{y_0}{\sigma_i} + r \frac{t}{\sigma_i} + z \frac{t^2}{\sigma_i} + \sum_{k=1}^q a_k \frac{\cos(\omega_k t)}{\sigma_i} + b_k \frac{\text{sen}(\omega_k t)}{\sigma_i}. \quad (6.3)$$

Utilizando-se esse novo modelo funcional, foram realizados dois experimentos para as séries temporais da componente U de todas as estações. No primeiro os modelos foram estimados considerando o Mod_func_3 e no segundo considerando este modelo funcional acrescentando o termo quadrático da Equação 6.3, sendo esse experimento denominado Mod_func_3_quad. A Figura 6.67 mostra graficamente os valores de R^2 ajustado para cada uma das estações utilizando as duas modelagens:

Figura 6.67: Valores de R^2 ajustado nas estimativas dos modelos funcionais das séries temporais com e sem a inclusão do termo quadrático



A partir da Figura 6.67, verifica-se para as estações BRAZ, MAPA, POAL e PYTE pertencentes ao SIRGAS-CON, a melhoria em R^2 ajustado ao utilizar o termo quadrático na modelagem funcional foi significativa e para o restante das estações os valores de R^2 ajustado mantiveram-se praticamente os mesmos. As Figuras 6.68 a 6.72 mostram as séries temporais da componente U ajustadas dessas estações.

Figura 6.68: Séries temporais (U) da estação BRAZ (SIRGAS-CON) e modelos ajustados (Mod_func_3 e Mod_func_3_quad)

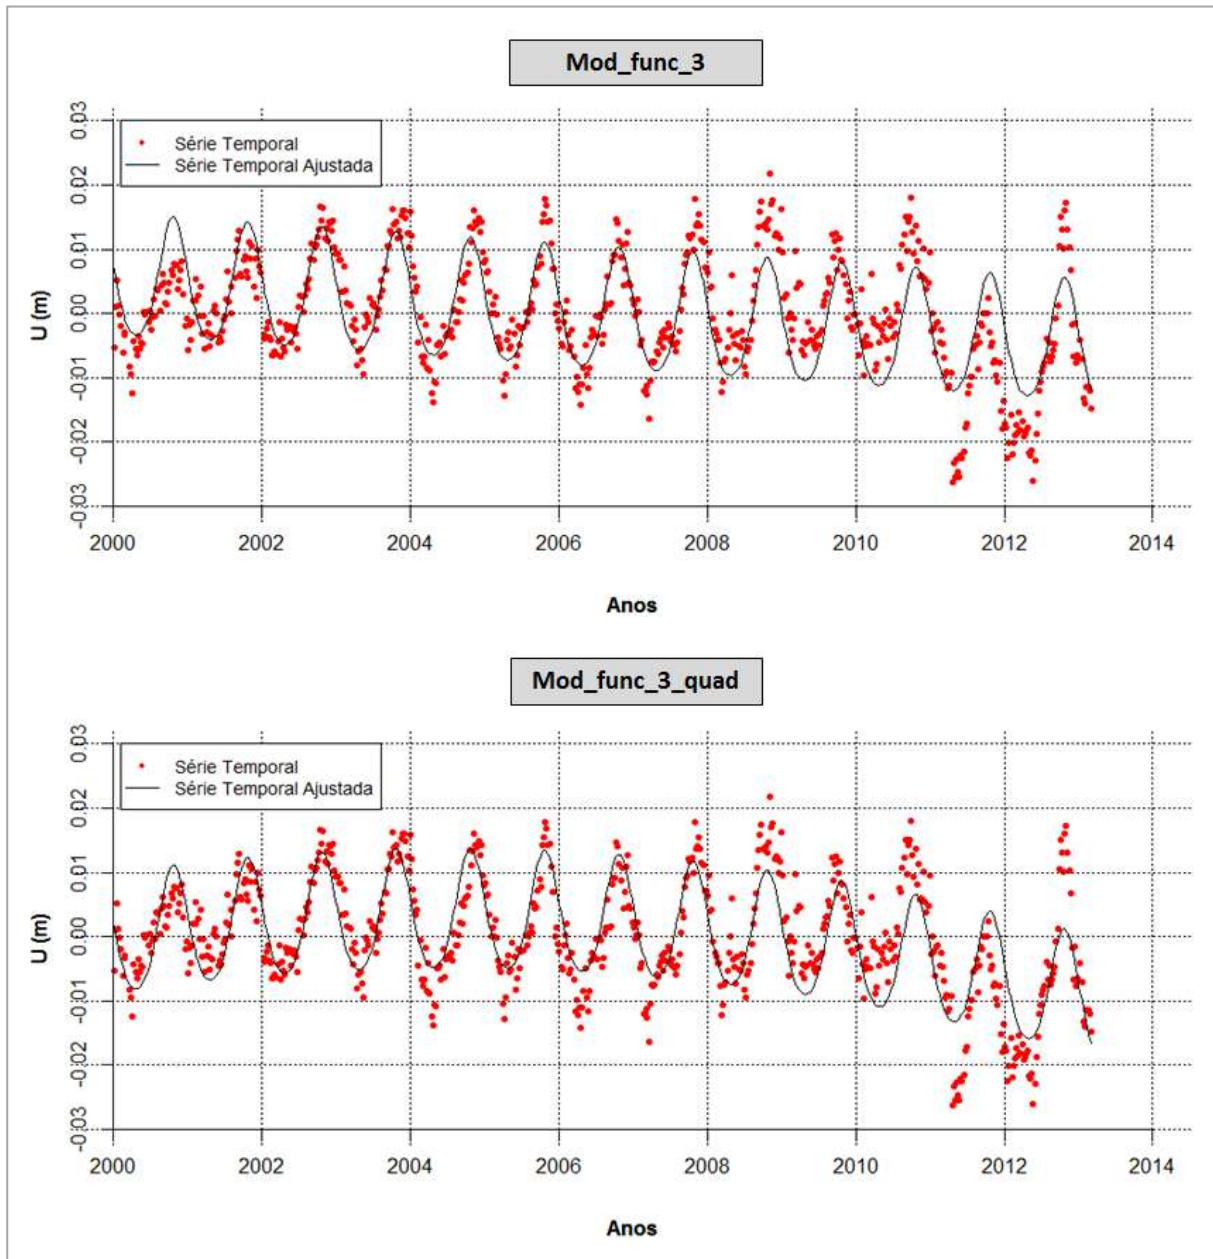


Figura 6.69: Séries temporais (U) da estação MAPA (SIRGAS-CON) e modelos ajustados (Mod_func_3 e Mod_func_3_quad)




Figura 6.70: Séries temporais (U) da estação POAL (SIRGAS-CON) e modelos ajustados (Mod_func_3 e Mod_func_3_quad)




Figura 6.71: Séries temporais (U) da estação PPTe (SIRGAS-CON) e modelos ajustados (Mod_func_3 e Mod_func_3_quad)


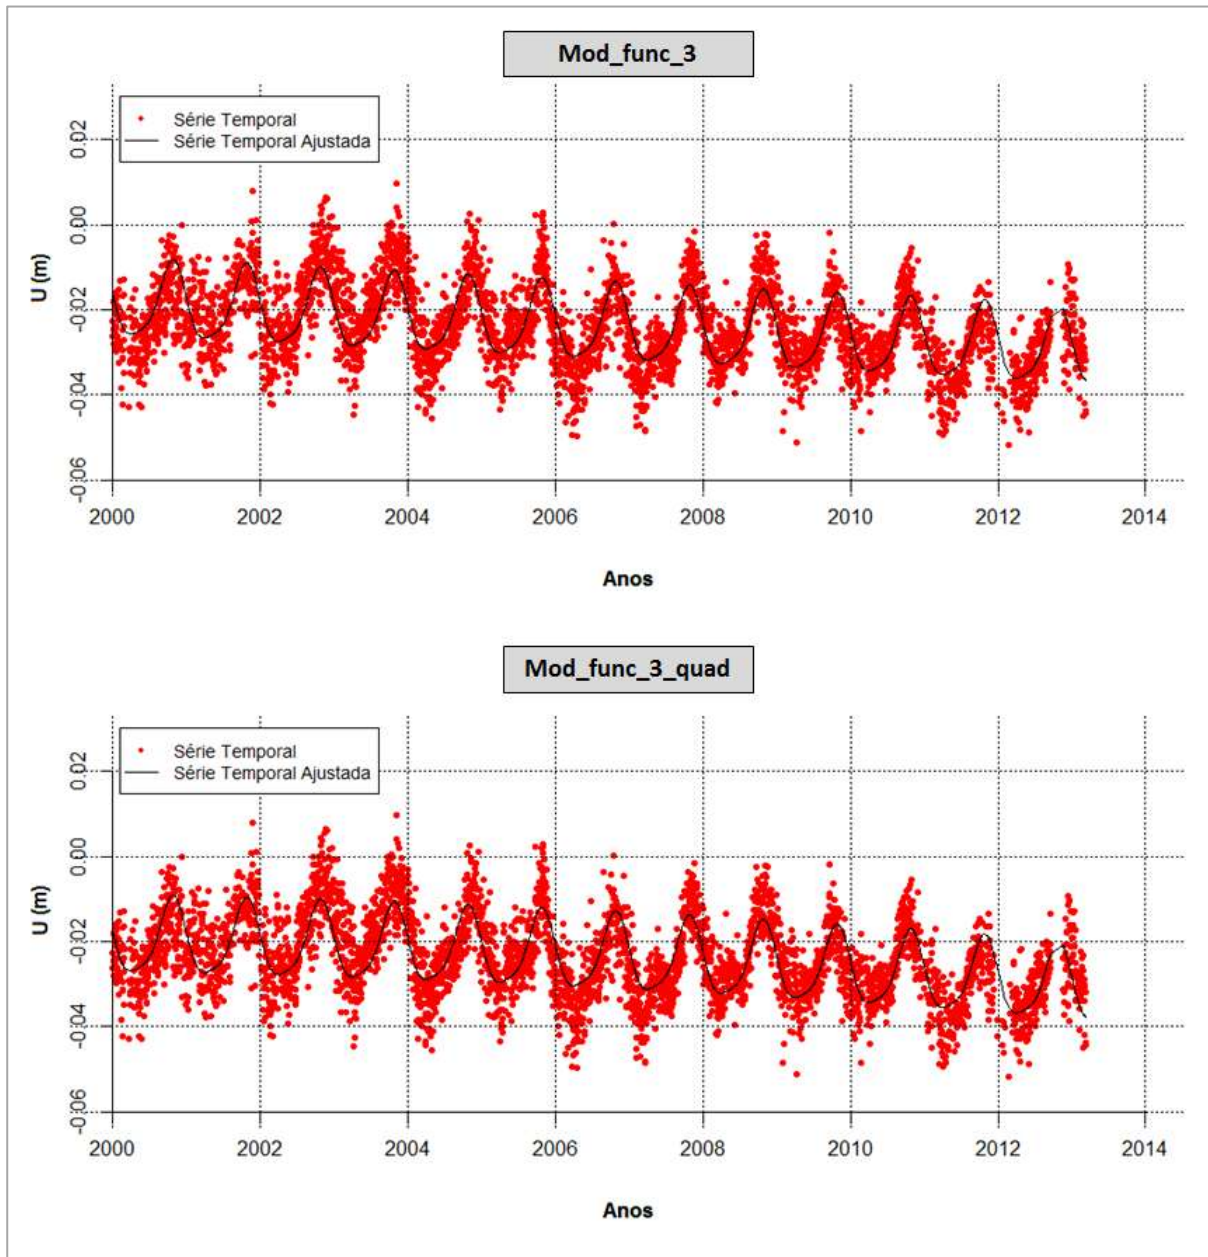


Figura 6.72: Séries temporais (U) da estação BRAZ (JPL) e modelos ajustados (Mod_func_3 e Mod_func_3_quad)



A partir da Figura 6.68 até a Figura 6.72, verifica-se que ao considerar o modelo funcional utilizando o termo quadrático (Mod_func_3_quad), os modelos funcionais estimados foram mais adequados às séries temporais do que sem a utilização desse termo.

Outra forma de analisar as séries temporais é através da função de autocorrelação dos resíduos do modelo estimado. As Figuras 6.73 a 6.81 apresentam os gráficos de autocorrelação para as séries temporais das estações SIRGAS-CON e JPL utilizando o modelo funcional Mod_func_3. As linhas tracejadas em azul representam o intervalo do erro padrão das autocorrelações amostrais, o qual é calculado por $\pm 2/\sqrt{n}$ sendo que n é o número de amostras).

Figura 6.73: Autocorrelação das séries temporais ajustadas (Mod_func_3) da estação BRAZ (SIRGAS-CON)

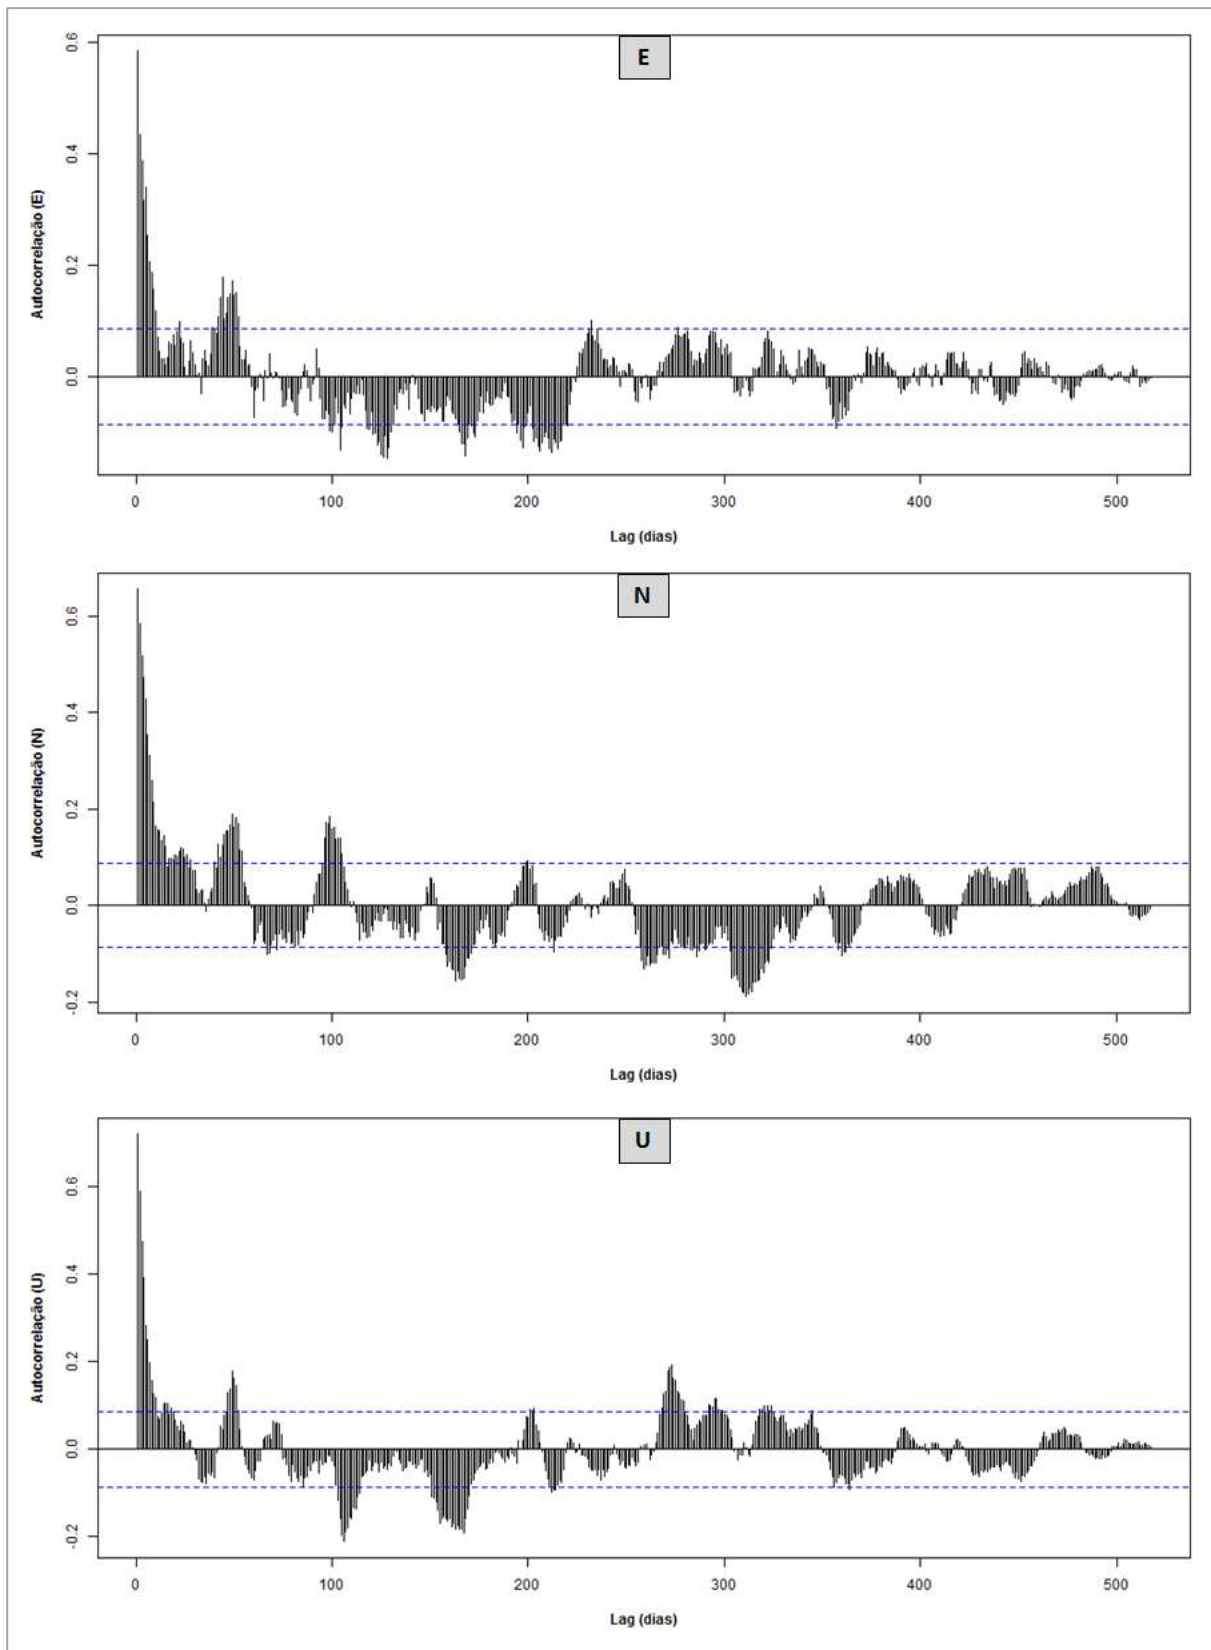


Figura 6.74: Autocorrelação das séries temporais ajustadas (Mod_func_3) da estação MAPA (SIRGAS-CON)




Figura 6.75: Autocorrelação das séries temporais (E, N e U) ajustadas (Mod_func_3) da estação POAL (SIRGAS-CON)

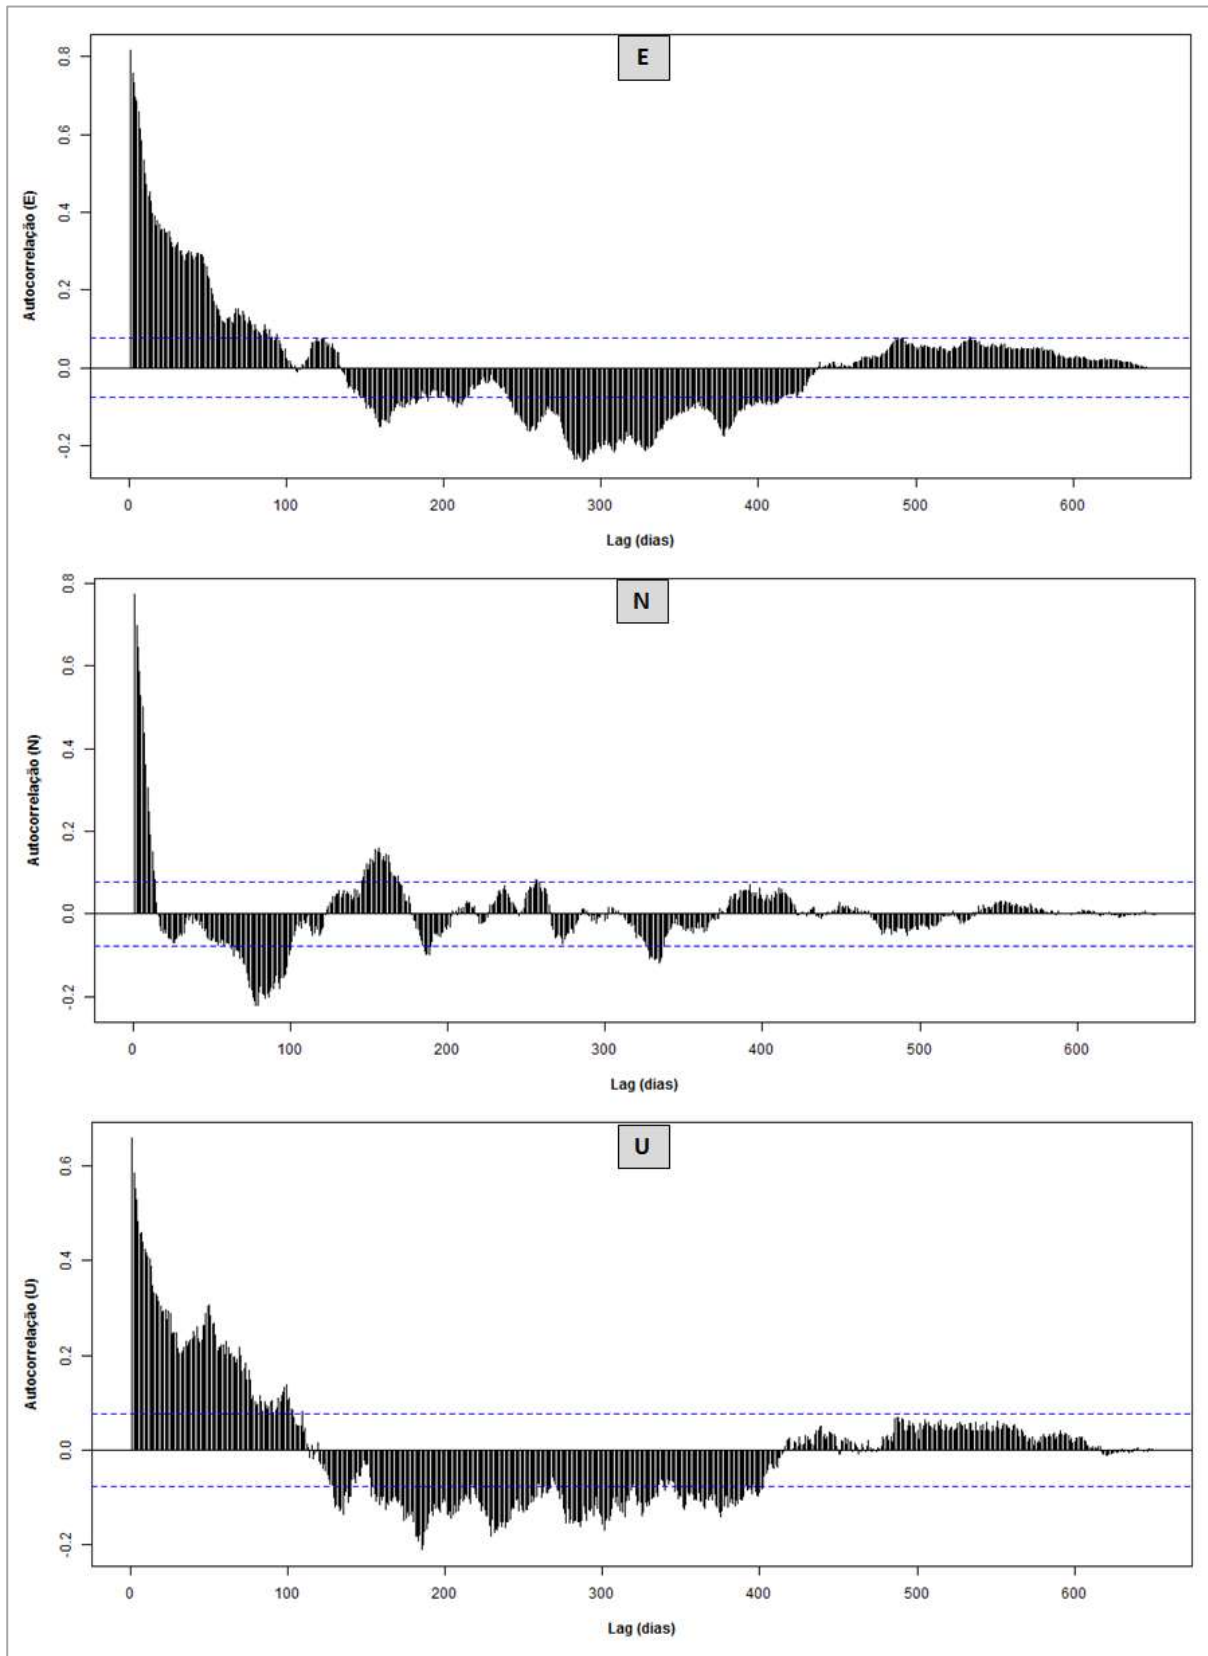


Figura 6.76: Autocorrelação das séries temporais (E, N e U) ajustadas (Mod_func_3) da estação PPTE (SIRGAS-CON)

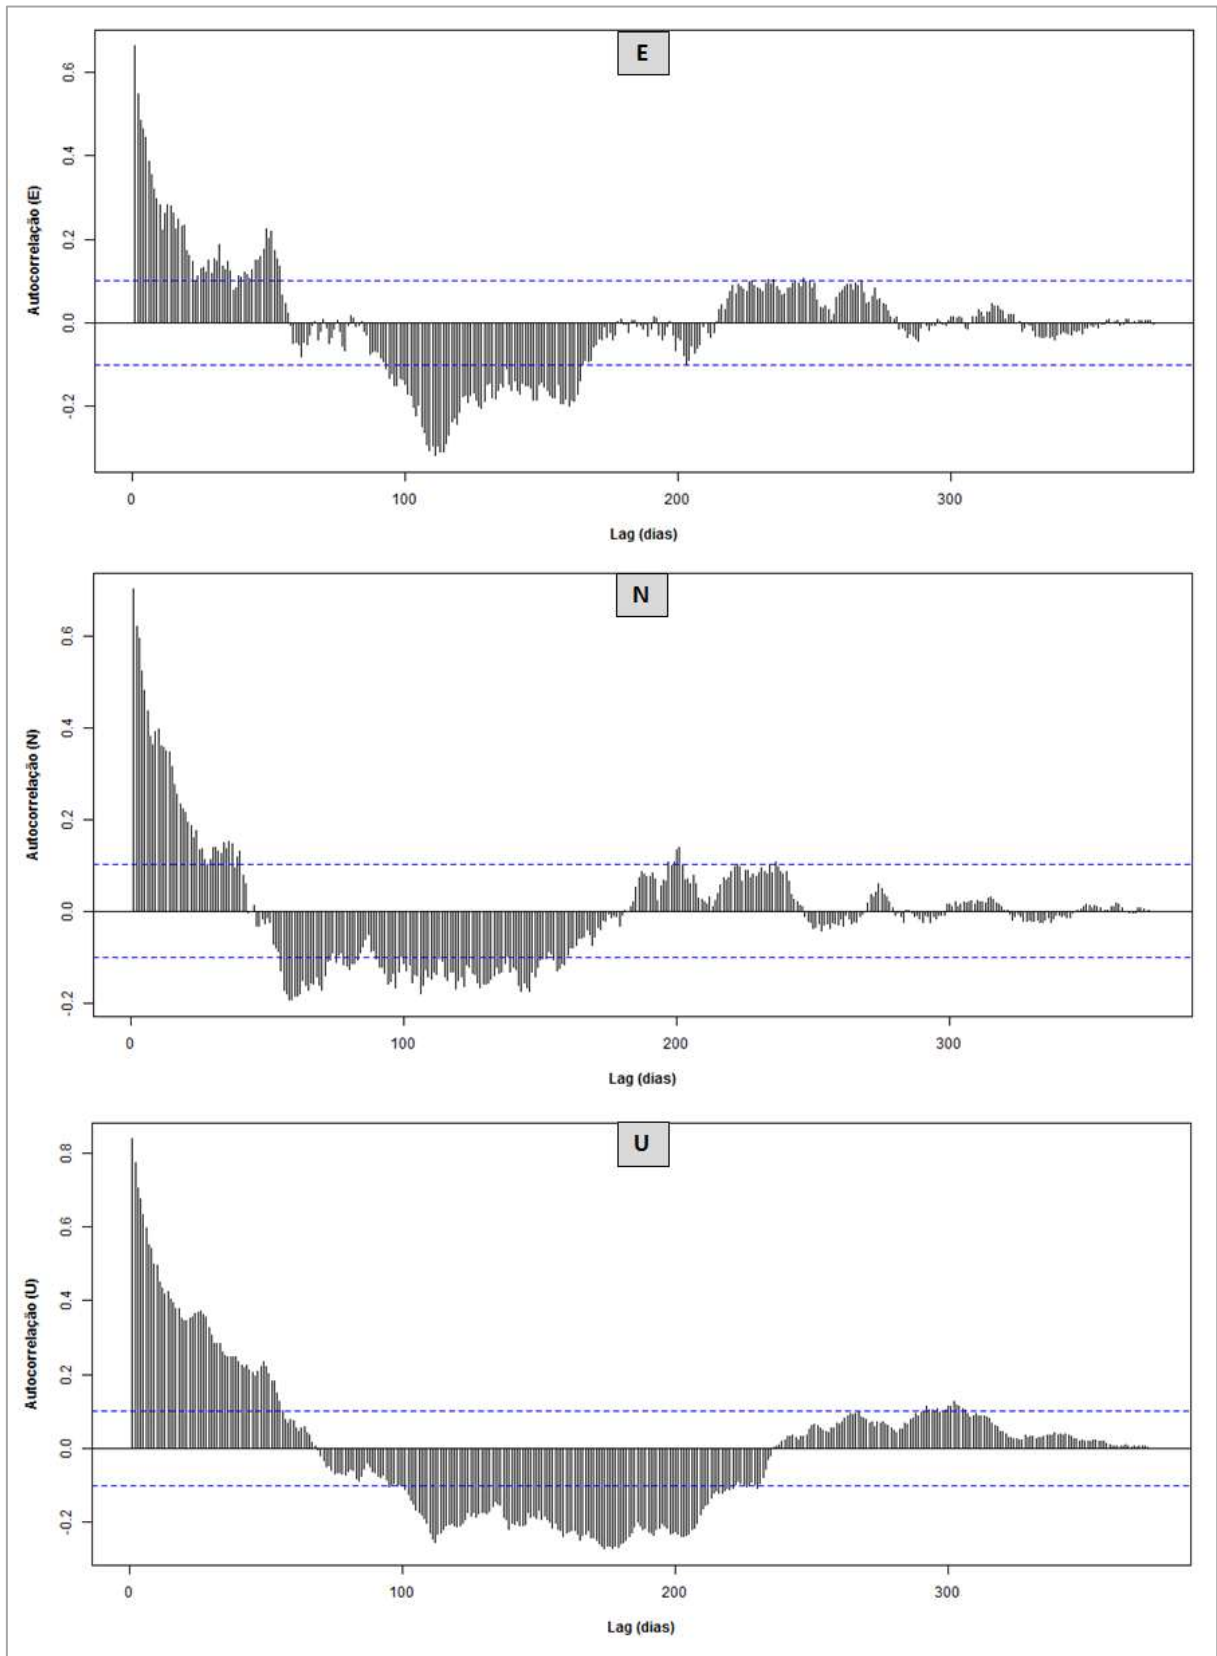


Figura 6.77: Autocorrelação das séries temporais (E, N e U) ajustadas (Mod_func_3) da estação RECF (SIRGAS-CON)

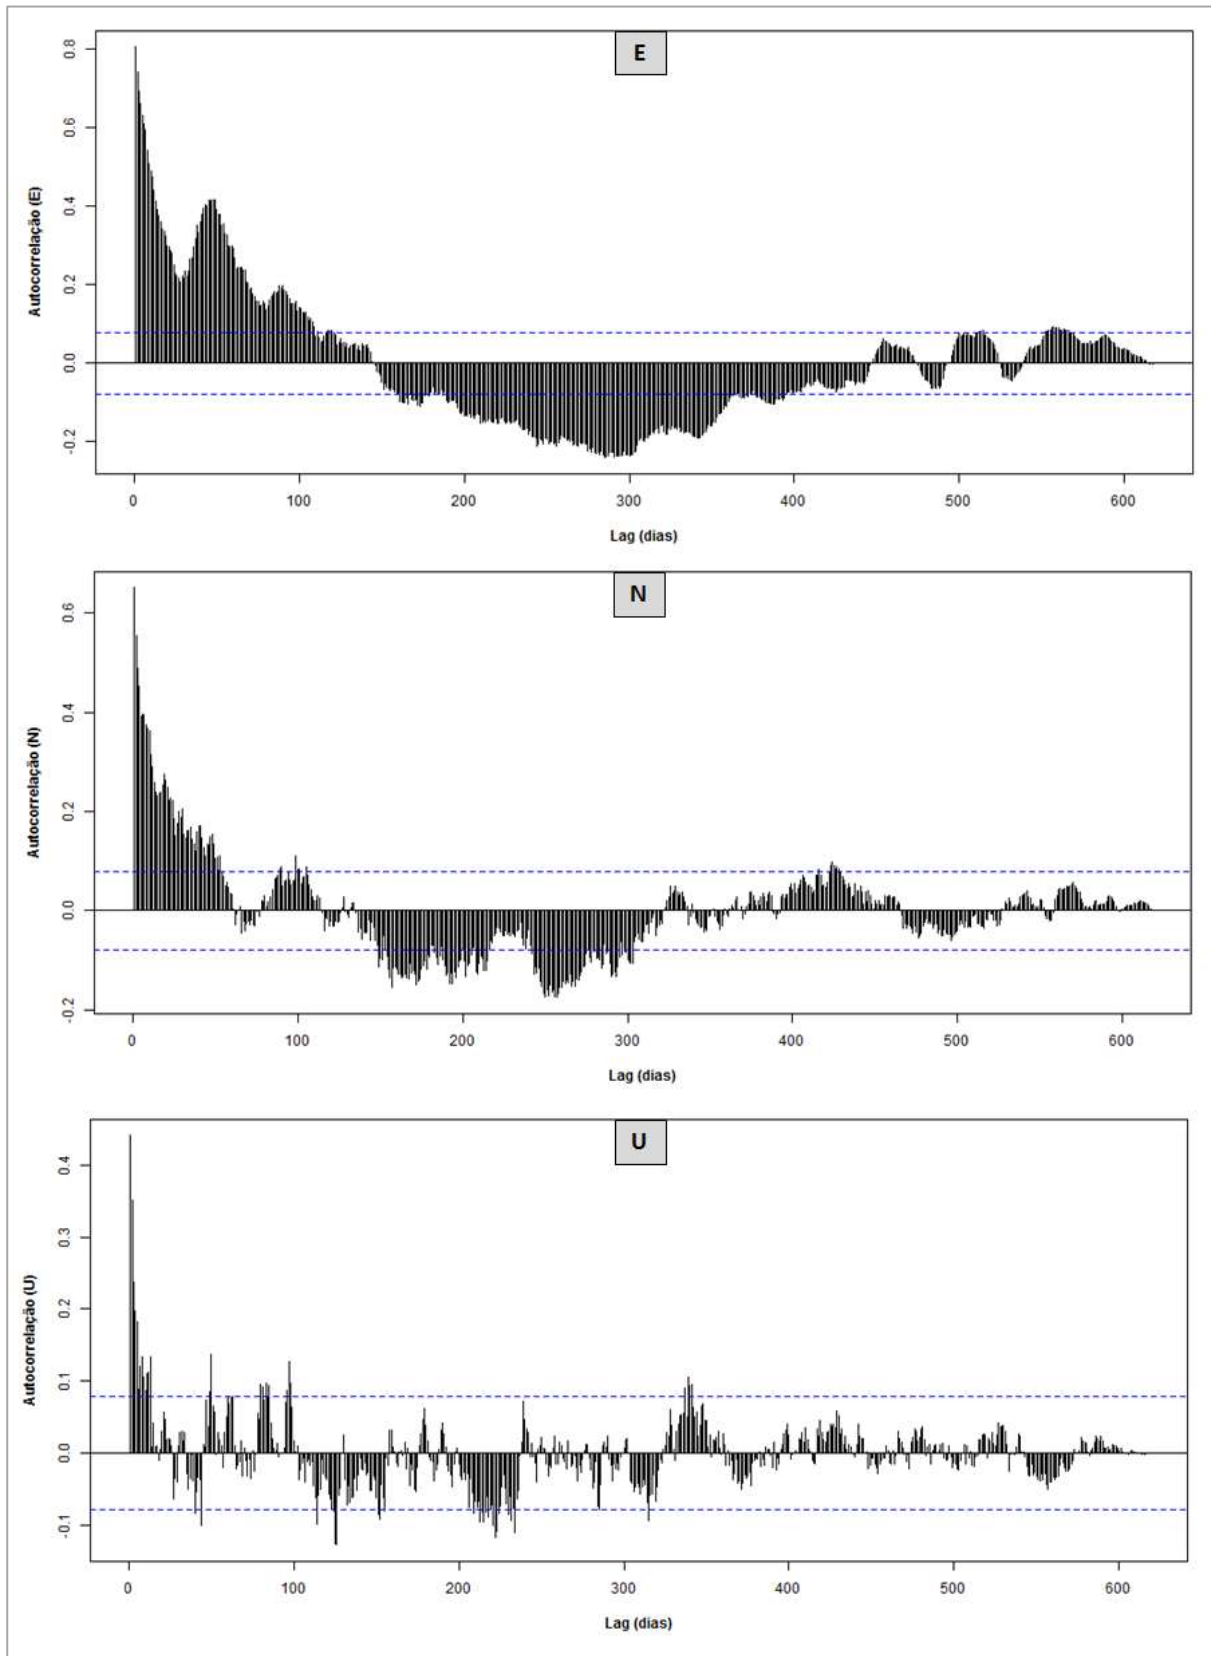


Figura 6.78: Autocorrelação das séries temporais (E, N e U) ajustadas (Mod_func_3) da estação BRAZ (JPL)

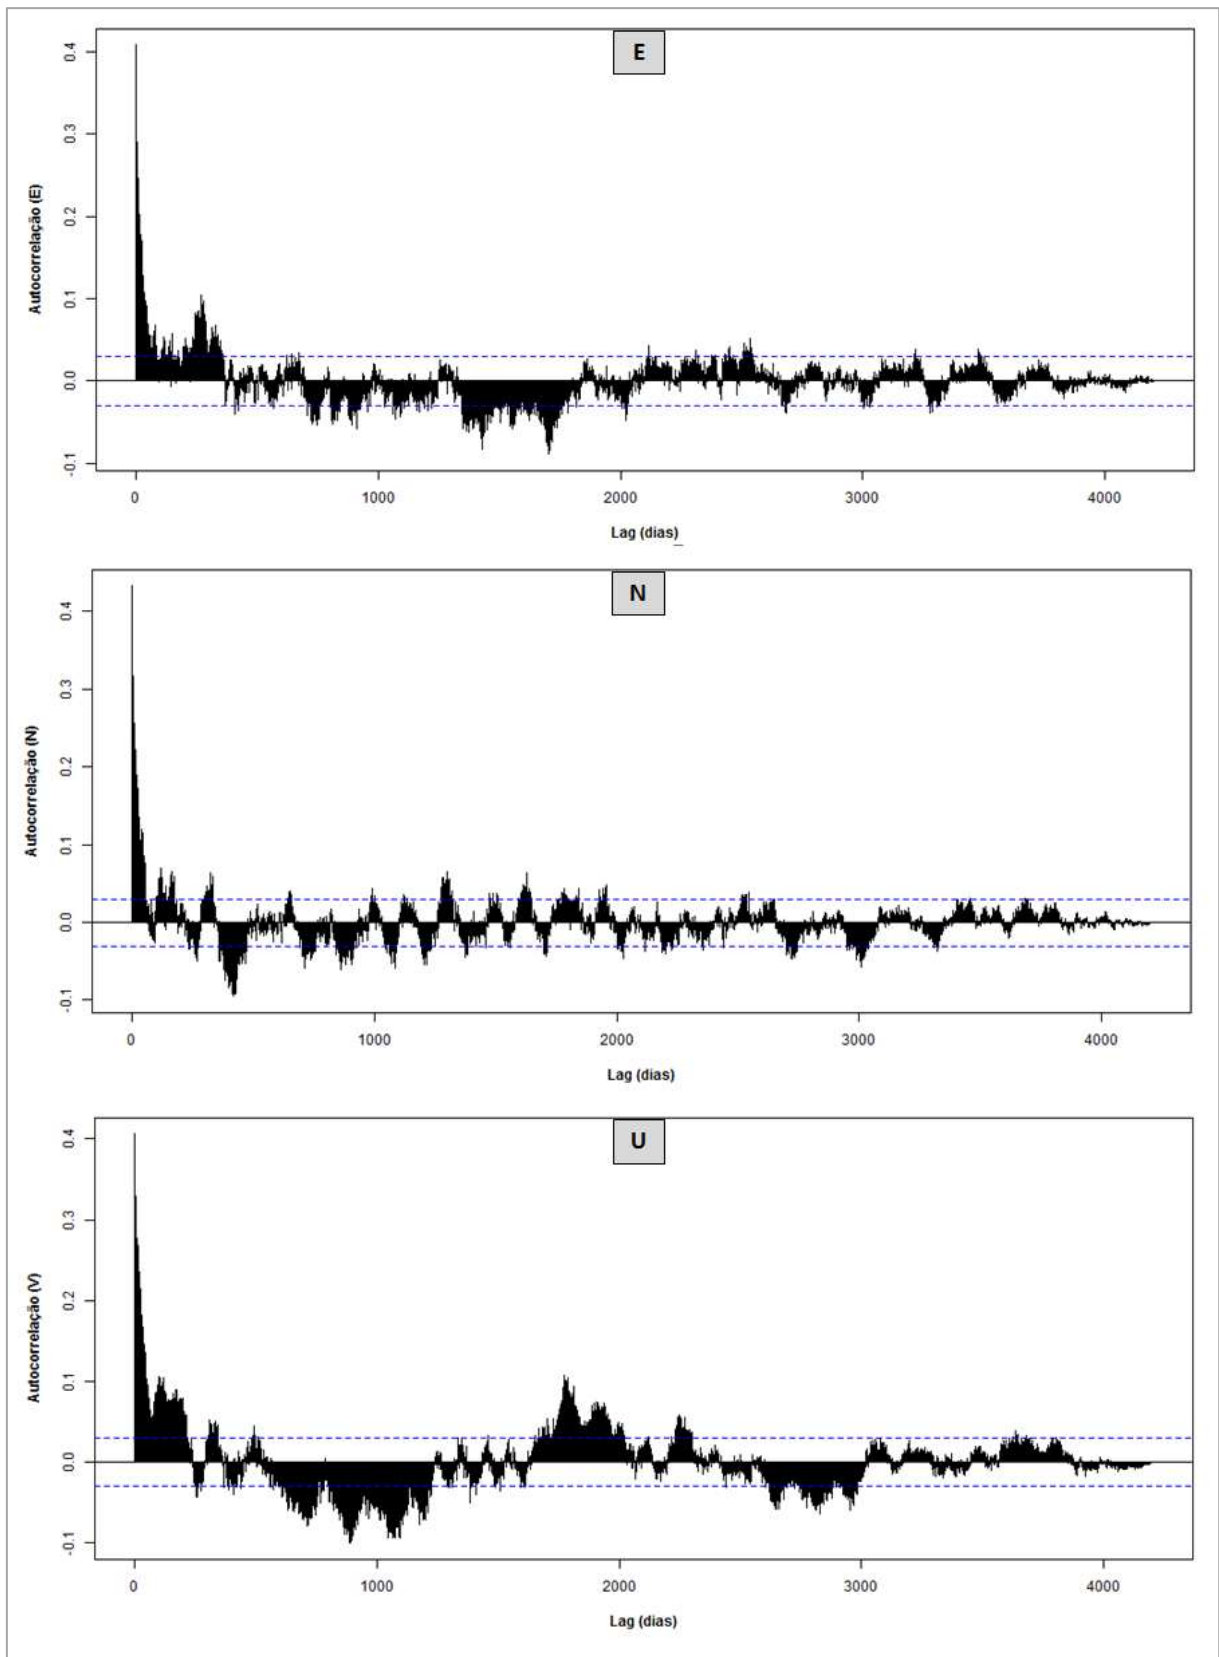


Figura 6.79: Autocorrelação das séries temporais (E, N e U) ajustadas (Mod_func_3) da estação BRFT (JPL)

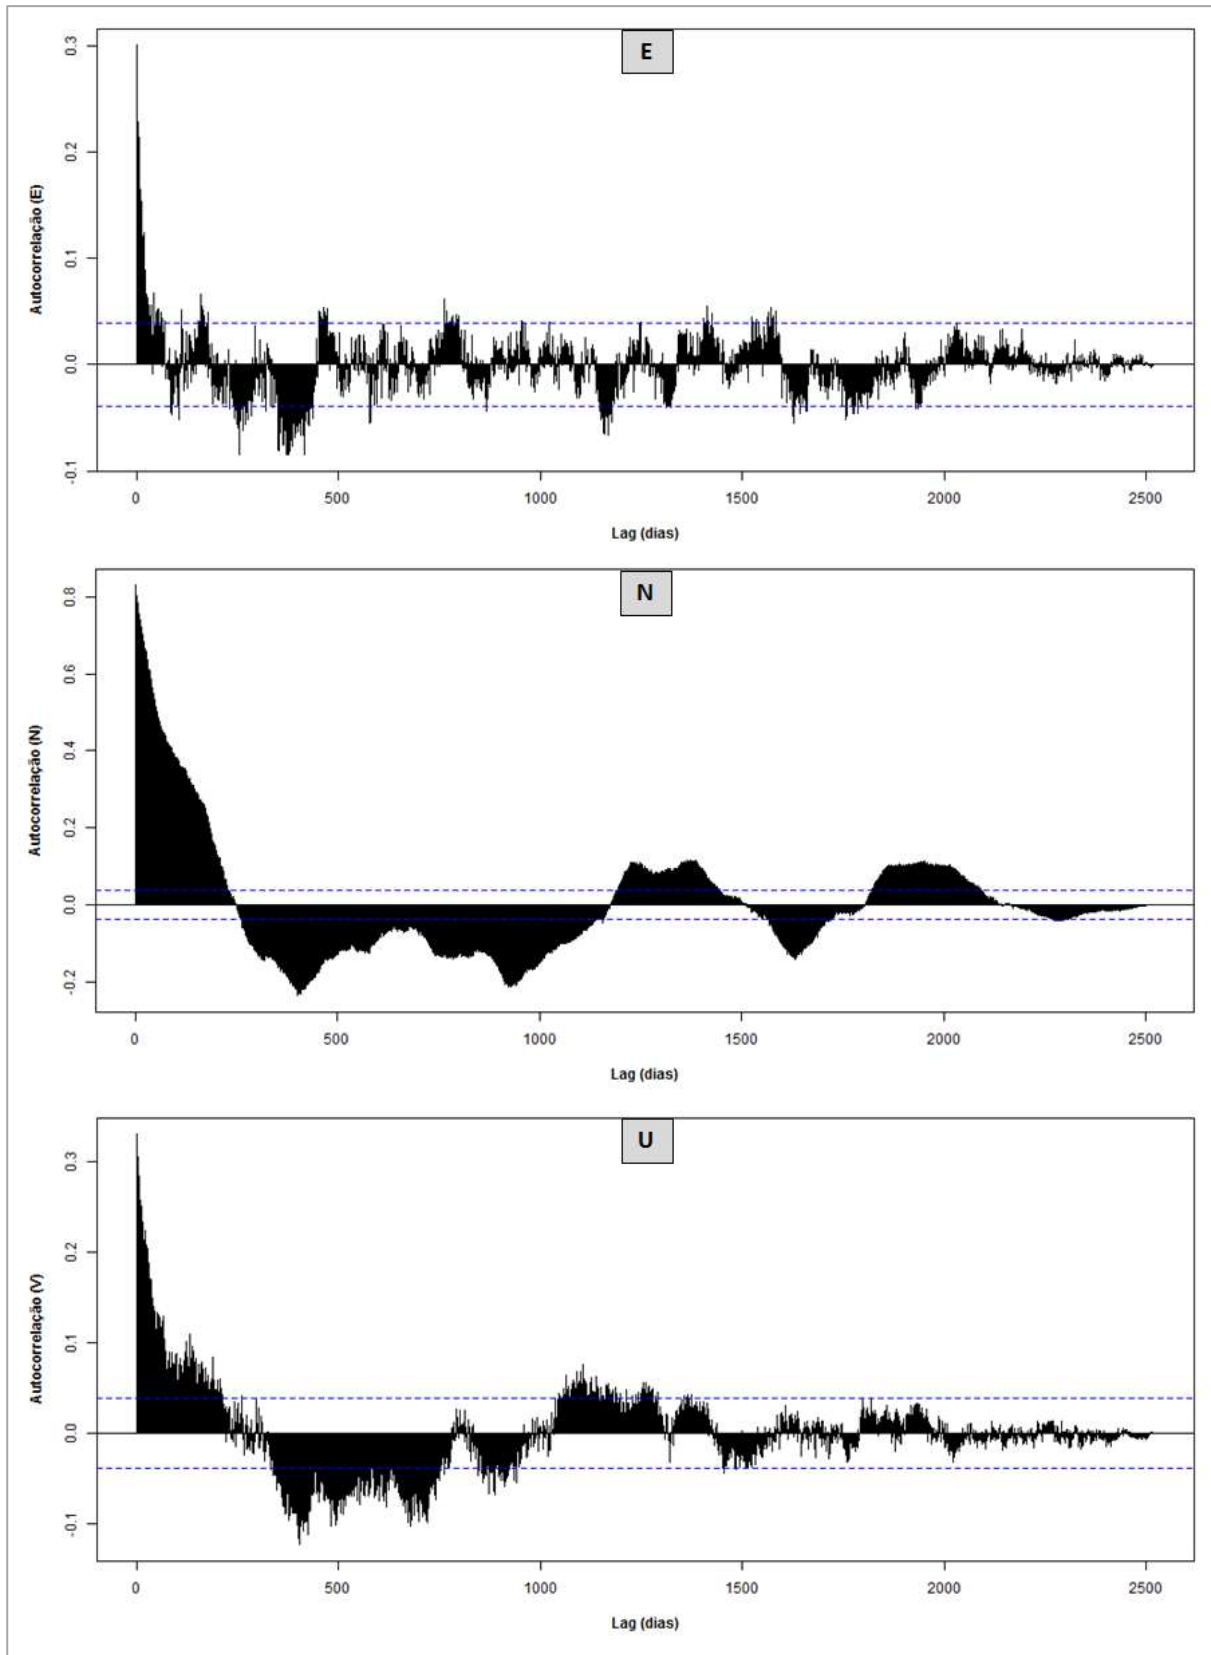


Figura 6.80: Autocorrelação das séries temporais (E, N e U) ajustadas (Mod_func_3) da estação CHPI (JPL)

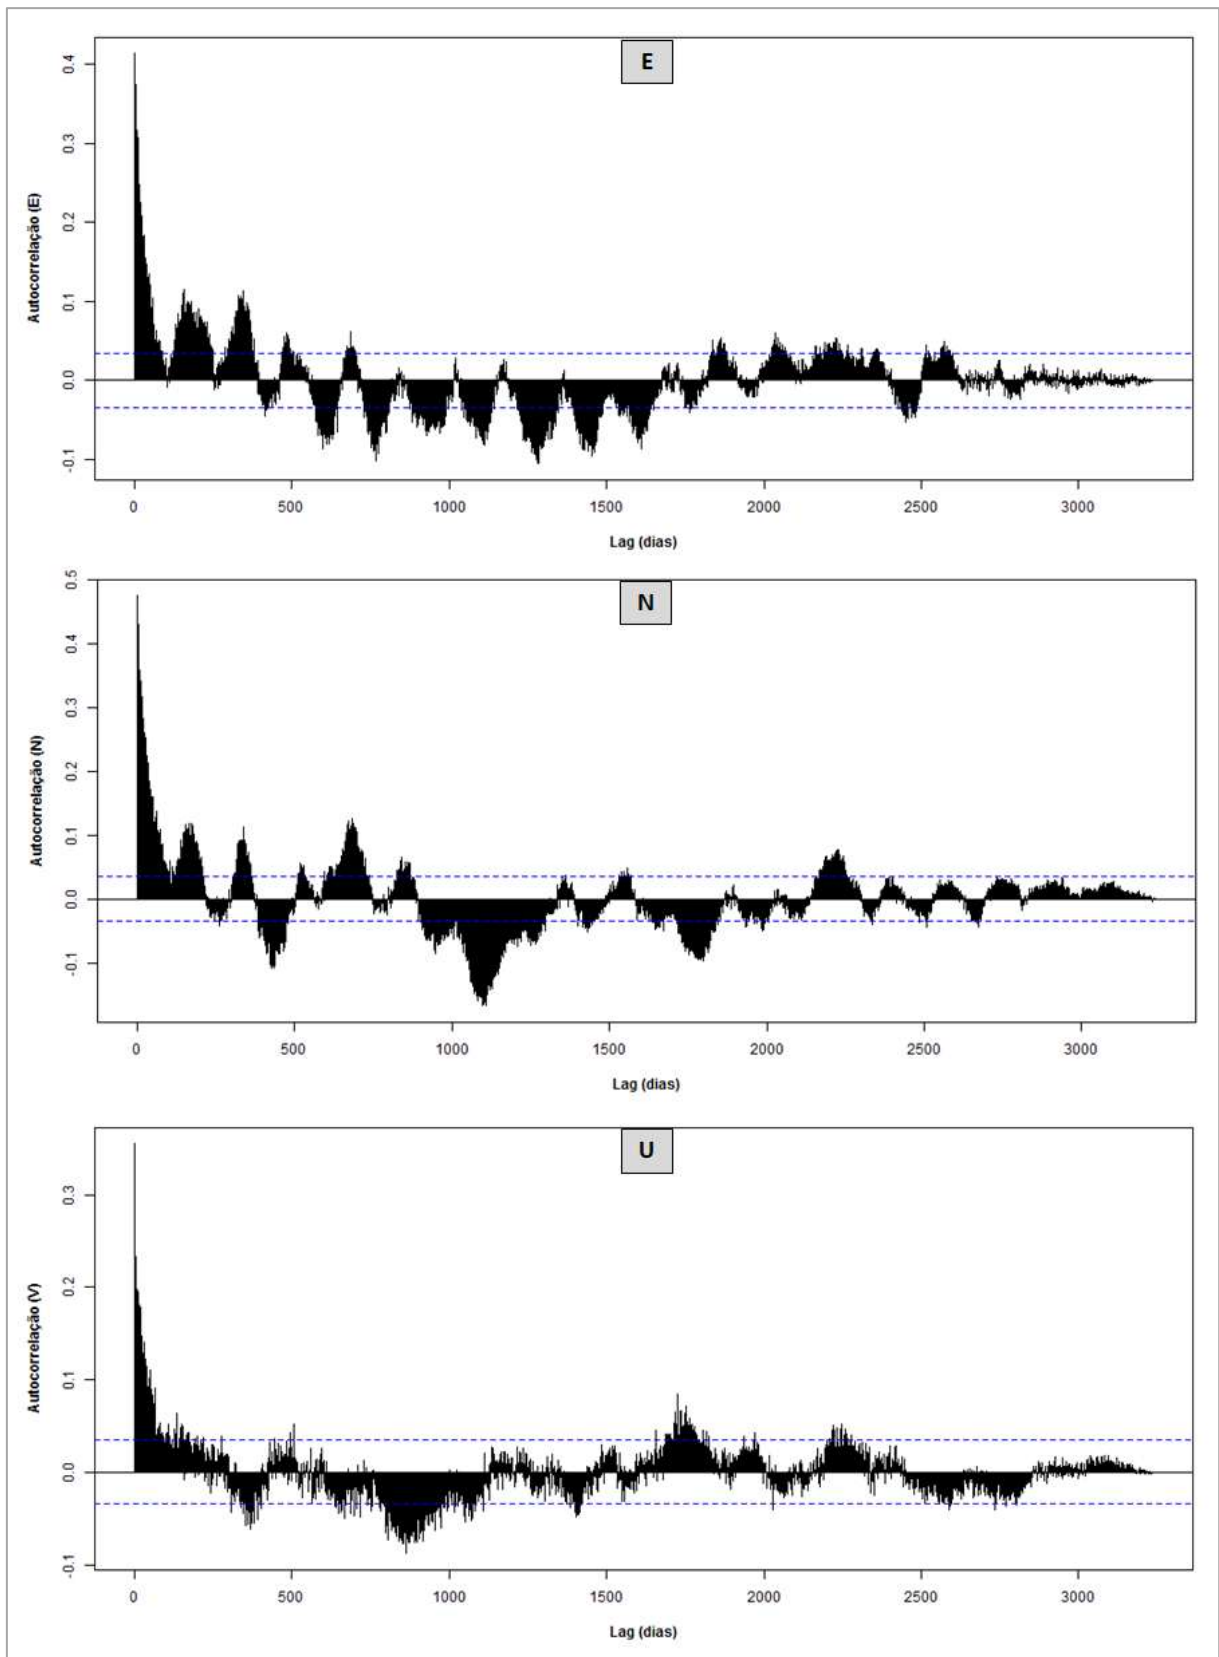
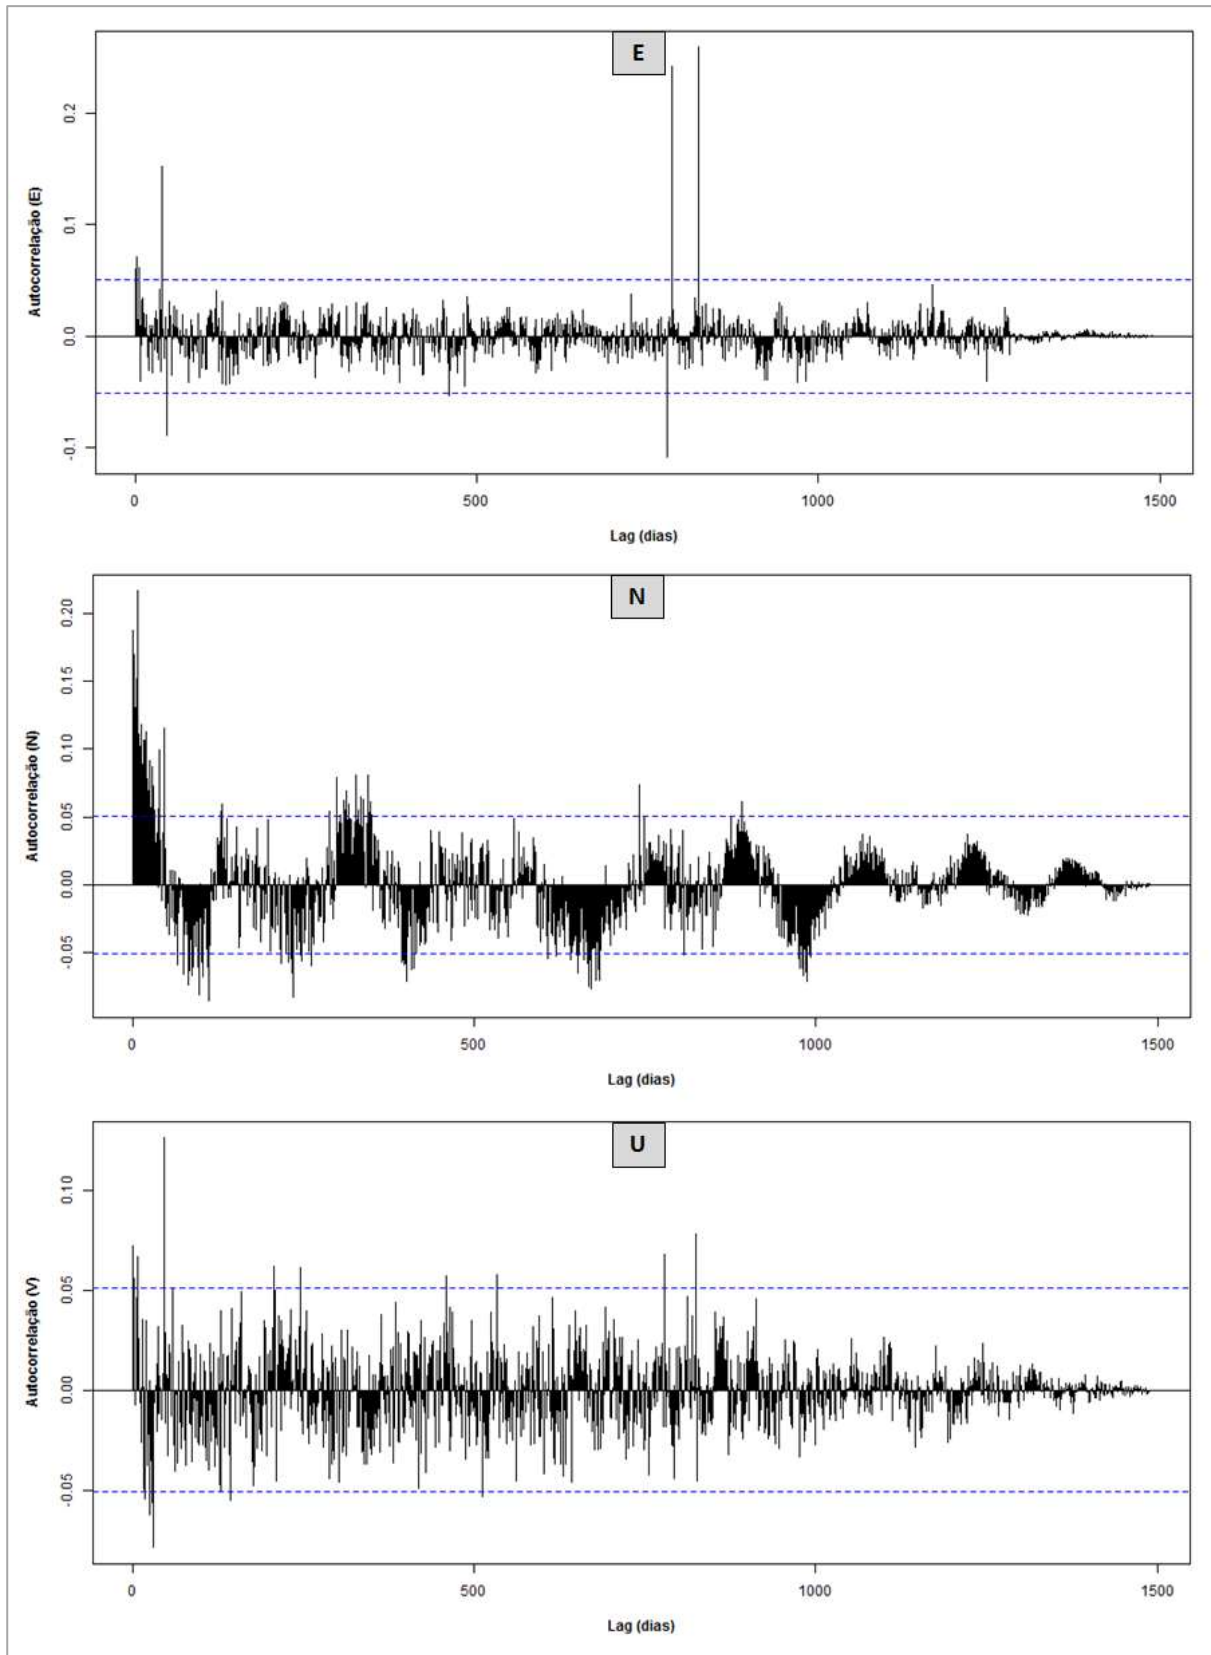


Figura 6.81: Autocorrelação das séries temporais (E, N e U) ajustadas (Mod_func_3) da estação SAVO (JPL)



Ao analisar os valores de autocorrelação das séries temporais (Figuras 6.73 a 6.81) verifica-se que a maioria dos valores está fora do intervalo do erro padrão (linha tracejada) e isto significa que se pode inferir que a componente estocástica da série não é ruído branco (*white noise*), ou seja, as séries temporais são também compostas de outros ruídos. A caracterização das componentes desses ruídos pode ser feita a partir da variância de Allan ou a partir da estimativa das mesmas pelo MMQ. A segunda opção permite a caracterização de mais de um tipo de ruído e também a identificação de um modelo estocástico que melhor se ajuste à série temporal, conforme mostrado na seção 6.2.2. Sendo assim, foram realizados novos experimentos considerando diferentes modelos estocásticos, os quais são apresentados na seção 6.2.3.2.

6.2.3.2 Modificação do modelo estocástico

Considerando que as séries temporais de coordenadas GNSS contém ruídos do tipo branco (*white noise*), rosa (*flicker noise*) e caminho aleatório (*random walk*), foi realizada então a identificação desses ruídos na série, algo que pode ser feita, por exemplo, através da análise de variância de Allan (seção 4.1.1) ou através da estimativa de componentes de variância a partir do MMQ (seção 4.2.3).

Na estimativa de componentes de variância a partir do MMQ, a caracterização dos ruídos se dá a partir da estimativa de cada variância do ruído (seção 4.2.3). Baseado nessa caracterização é possível selecionar o modelo estocástico mais adequado para a série temporal (seção 4.2.4). Sendo assim, as séries temporais da seção 6.2.3.1 foram processadas novamente utilizando o modelo funcional Mod_func_3 para as componentes E e N e o Mod_func_3_quad para a componente U das séries temporais. Em ambos os casos foram considerados três diferentes modelos estocásticos (seção 6.2.2) de acordo com a Tabela 6.15:

Tabela 6.15: Modelos estocásticos das séries temporais de coordenadas GNSS

Modelo estocástico	Descrição
Modelo padrão	$\Sigma_{L_b} = \Sigma_0$
Modelo padrão + ruído branco	$\Sigma_{L_b} = \Sigma_0 + \sigma_w^2 I$
Modelo padrão + ruído branco + ruído colorido	$\Sigma_{L_b} = \Sigma_0 + \sigma_w^2 I + \sigma_f^2 Q_f$ ou $Q_y = \Sigma_0 + \sigma_w^2 I + \sigma_{rw}^2 Q_{rw}$.

Nesta tese, a matriz Σ_{L_b} foi utilizada na forma diagonal, desprezando as correlações. Além disso, a matriz Σ_0 foi adotada considerando na diagonal as variâncias advindas das séries temporais, no caso da estimativa das componentes de variância e na identificação do modelo estocástico essa matriz foi adotada com nula. O terceiro modelo foi utilizado nas séries temporais seguindo a identificação do modelo estocástico obtido na seção 6.2.2, na qual apenas para as estações POAL e RECF do SIRGAS-CON foram identificados com o modelo que considera ruído branco e caminho aleatório ($\Sigma_{L_b} = \Sigma_0 + \sigma_w^2 I + \sigma_{rw}^2 Q_{rw}$), sendo as restantes identificadas com o modelo que considera ruído branco e ruído ($\Sigma_{L_b} = \Sigma_0 + \sigma_w^2 I + \sigma_f^2 Q_f$). Vale lembrar que as séries temporais da componente N da estação POAL e da componente U da estação RECF, embora o modelo estocástico tenha sido identificado como uma composição de ruído branco e caminho aleatório, sendo que o caminho aleatório não pode ser considerado no modelo estocástico, haja vista não ser apropriado ao modelo (veja seção 6.2.2).

A Figura 6.82 mostra os valores de R^2 ajustado para cada uma das séries temporais das componentes E , N e U das estações utilizando o modelo funcional Mod_func_3 e a Figura 6.83 mostra os valores de R^2 ajustado para as séries temporais da componente U utilizando o modelo funcional Mod_func_3_quad. Em ambos os casos, são utilizados os três modelos estocásticos. É importante dizer que as séries temporais BRAZ (SIRGAS-CON e JPL), com asterisco (*) nas figuras, foram reamostradas para 10 anos de dados (2000 a 2009) devido a limitações computacionais na estimativa das componentes de variância.

Figura 6.82: Valores de R^2 ajustado das séries temporais ajustadas utilizando Mod_func_3 e com diferentes modelos estocásticos





Figura 6.83: Valores de R^2 ajustado das séries temporais da componente U ajustadas utilizando Mod_func_3_quad e com diferentes modelos estocásticos



Pode-se verificar a partir da Figura 6.82 que para as séries temporais da componente N do JPL (dados diários) os valores de R^2 ajustado são praticamente os mesmos. Já com relação às séries temporais da componente E do SIRGAS-CON e as séries temporais das componentes U (SIRGAS-CON e JPL) tanto utilizando o modelo funcional Mod_func_3 (Figura 6.82) quanto o modelo Mod_func_3_quad (Figura 6.83), os valores de R^2 ajustado foram menores ao se realizar a modificação do modelo estocástico, significando que a taxa de sucesso que explica a variabilidade dos dados da série temporal foi menor ao modificar a modelagem estocástica.

É interessante verificar, nesse caso, outro tipo de medida para o bom ajuste do modelo. Um tipo de medida é a raiz do erro padrão médio também chamado de erro padrão do modelo (EPM) ou erro padrão da regressão, o qual é dado por (CRYER; CHAN, 2008):


$$EPM = \sqrt{\frac{1}{gl} \sum_{t=1}^n (y(t) - \hat{y}(t))^2}, \quad (6.4)$$

em que, gl é o número de graus de liberdade.

Quanto mais próximo de zero estiver o valor de EMP melhor é ajuste do modelo e este será mais útil para a predição dos dados.

A Figura 6.84 mostra os valores do EPM para as séries temporais utilizando o modelo funcional Mod_func_3 e os três diferentes modelos estocásticos.

Figura 6.84: Desvio-padrão dos resíduos das séries temporais ajustadas utilizando o modelo funcional "Mod_func_3" e os três modelos estocásticos



Ao analisar a Figura 6.84 verifica-se que para todas as séries temporais do SIRGAS-CON (dados semanais) ao utilizar a modelagem estocástica padrão, os valores do EPM são muito grandes em relação ao EPM dos outros tipos de modelagem estocástica, o que significa que esses modelos funcionais estimados não são úteis para a predição dos dados.

A Figura 6.85 mostra uma comparação entre os modelos estocásticos “Modelo padrão + ruído branco” e “Modelo padrão + ruído branco + ruído colorido” utilizando o modelo funcional Mod_func_3 e, a Figura 6.86 apresenta a mesma comparação para as séries temporais da componente U utilizando o modelo funcional Mod_func_3_quad.

Figura 6.85: EPM das séries temporais ajustadas utilizando o Mod_func_3 e os modelos estocásticos “Modelo padrão + ruído branco” e “Modelo padrão + ruído branco + ruído colorido”





Figura 6.86: EPM das séries temporais ajustadas utilizando o Mod_func_3_quad e os modelos estocásticos “Modelo padrão + ruído branco” e “Modelo padrão + ruído branco + ruído colorido”



A partir da Figura 6.85 e da Figura 6.86 verifica-se que ao aplicar a modelagem estocástica considerando ruído branco e ruído colorido (ruído rosa ou caminho aleatório) os valores de EPM ficaram bem mais próximos de zero do que ao utilizar o modelo considerando apenas ruído branco. Pode-se verificar também que os menores valores são para as séries temporais diárias (JPL).

Pode-se concluir após essas análises que embora o valor de R^2 ajustado praticamente não tenha tido melhorias quando se modificou o modelo estocástico, os valores de EPM foram bem menores indicando que ao aplicar uma modelagem estocástica mais adequada o modelo funcional estimado será mais adequado para a predição de dados.

6.2.4 Análise dos experimentos

A análise de variância de Allan das séries temporais de coordenadas GNSS realizada na seção 6.2.1, fornece uma indicação dos possíveis erros contidos nas séries. Já na seção 6.2.2 é possível a identificação e a quantização das variâncias relacionadas aos ruídos contidos nas séries. Além disso, permite um controle de qualidade, podendo através deste, identificar um modelo estocástico mais adequado a cada série temporal considerando a influência dos ruídos do tipo ruído branco, ruído rosa e caminho aleatório.

Diante dos resultados obtidos na seção 6.2.3.1, tem-se que os modelos funcionais que se adaptam às séries temporais das componentes E e N podem ser estimados em função de uma tendência linear e apenas dois termos trigonométricos (Mod_func_3). Já com relação às séries temporais da componente U , os modelos funcionais podem ser estimados em função de uma tendência linear, de um termo quadrático e apenas dois termos trigonométricos (Mod_func_3_quad), o que se adaptará bem a essas séries temporais.

Verifica-se também, a partir da seção 6.2.3.2 que a adoção de uma modelagem estocástica adequada contribui num melhor ajuste do modelo funcional, sendo este mais útil na predição de dados.

Sendo assim, para que os modelos funcionais estimados possam ser utilizados para predições das coordenadas GNSS, são construídos os modelos funcionais e respectivos modelos estocásticos para cada uma das estações do SIRGA-CON e JPL utilizadas nesta tese, os quais são apresentados na Tabela 6.16 e na Tabela 6.17, sendo os valores de $\varpi_1 = 2\pi$ e $\varpi_2 = 4\pi$.

Tabela 6.16: Modelos funcionais estimados para as séries temporais do SIRGAS-CON

Estação	Série temporal	Modelo funcional estimado	Modelo estocástico utilizado
BRAZ	E	$L_a(t) = 7,607 - 3,791 \times 10^{-3}t$ $+4,805 \times 10^{-4} \cos(\varpi_1 t) - 1,115 \times 10^{-3} \text{sen}(\varpi_1 t)$ $-2,320 \times 10^{-4} \cos(\varpi_2 t) + 2,043 \times 10^{-4} \text{sen}(\varpi_2 t)$	$\Sigma_{L_b} = \Sigma_0 + \sigma_w^2 I + \sigma_f^2 Q_f$
	N	$L_a(t) = -25,83 + 1,287 \times 10^{-2}t$ $+1,200 \times 10^{-3} \cos(\varpi_1 t) + 1,449 \times 10^{-3} \text{sen}(\varpi_1 t)$ $-2,826 \times 10^{-4} \cos(\varpi_2 t) - 1,285 \times 10^{-4} \text{sen}(\varpi_2 t)$	$\Sigma_{L_b} = \Sigma_0 + \sigma_w^2 I + \sigma_f^2 Q_f$
	U	$L_a(t) = 1,201 \times 10^2 - 1,197 \times 10^{-1}t + 2,929 \times 10^{-3}t^2$ $+3,870 \times 10^{-3} \cos(\varpi_1 t) - 7,784 \times 10^{-3} \text{sen}(\varpi_1 t)$ $-2,617 \times 10^{-4} \cos(\varpi_2 t) - 1,510 \times 10^{-3} \text{sen}(\varpi_2 t)$	$\Sigma_{L_b} = \Sigma_0 + \sigma_w^2 I + \sigma_f^2 Q_f$
MAPA	E	$L_a(t) = 8,832 - 4,395 \times 10^{-3}t$ $+2,145 \times 10^{-4} \cos(\varpi_1 t) - 1,487 \times 10^{-3} \text{sen}(\varpi_1 t)$ $+1,870 \times 10^{-4} \cos(\varpi_2 t) + 1,009 \times 10^{-3} \text{sen}(\varpi_2 t)$	$\Sigma_{L_b} = \Sigma_0 + \sigma_w^2 I + \sigma_f^2 Q_f$
	N	$L_a(t) = -27,07 + 1,347 \times 10^{-2}t$ $+4,802 \times 10^{-4} \cos(\varpi_1 t) - 1,116 \times 10^{-3} \text{sen}(\varpi_1 t)$ $-4,780 \times 10^{-4} \cos(\varpi_2 t) + 5,213 \times 10^{-4} \text{sen}(\varpi_2 t)$	$\Sigma_{L_b} = \Sigma_0 + \sigma_w^2 I + \sigma_f^2 Q_f$
	U	$L_a(t) = -2,662 \times 10^3 + 2,649t - 6,590 \times 10^{-4}t^2$ $+8,502 \times 10^{-3} \cos(\varpi_1 t) - 4,966 \times 10^{-3} \text{sen}(\varpi_1 t)$ $-9,369 \times 10^{-4} \cos(\varpi_2 t) + 8,253 \times 10^{-4} \text{sen}(\varpi_2 t)$	$\Sigma_{L_b} = \Sigma_0 + \sigma_w^2 I + \sigma_f^2 Q_f$
POAL	E	$L_a(t) = 4,676 - 2,330 \times 10^{-3}t$ $+2,799 \times 10^{-4} \cos(\varpi_1 t) + 8,029 \times 10^{-5} \text{sen}(\varpi_1 t)$ $-4,982 \times 10^{-4} \cos(\varpi_2 t) + 4,883 \times 10^{-5} \text{sen}(\varpi_2 t)$	$\Sigma_{L_b} = \Sigma_0 + \sigma_w^2 I + \sigma_{rw}^2 Q_{rw}$
	N	$L_a(t) = -25,12 + 1,252 \times 10^{-2}t$ $+1,055 \times 10^{-3} \cos(\varpi_1 t) + 2,777 \times 10^{-3} \text{sen}(\varpi_1 t)$ $+3,476 \times 10^{-5} \cos(\varpi_2 t) - 8,243 \times 10^{-5} \text{sen}(\varpi_2 t)$	$\Sigma_{L_b} = \Sigma_0 + \sigma_w^2 I$
	U	$L_a(t) = -6,337 \times 10^2 + 6,309 \times 10^{-1}t - 1,570 \times 10^{-4}t^2$ $+3,847 \times 10^{-3} \cos(\varpi_1 t) + 2,206 \times 10^{-3} \text{sen}(\varpi_1 t)$ $-9,009 \times 10^{-4} \cos(\varpi_2 t) + 7,743 \times 10^{-4} \text{sen}(\varpi_2 t)$	$\Sigma_{L_b} = \Sigma_0 + \sigma_w^2 I + \sigma_{rw}^2 Q_{rw}$
PPTE	E	$L_a(t) = 5,736 - 2,854 \times 10^{-3}t$ $-1,258 \times 10^{-3} \cos(\varpi_1 t) - 1,113 \times 10^{-3} \text{sen}(\varpi_1 t)$ $+2,679 \times 10^{-4} \cos(\varpi_2 t) + 1,727 \times 10^{-4} \text{sen}(\varpi_2 t)$	$\Sigma_{L_b} = \Sigma_0 + \sigma_w^2 I + \sigma_f^2 Q_f$
	N	$L_a(t) = -26,16 + 1,302 \times 10^{-2}t$ $+1,177 \times 10^{-4} \cos(\varpi_1 t) + 2,448 \times 10^{-3} \text{sen}(\varpi_1 t)$ $-1,521 \times 10^{-5} \cos(\varpi_2 t) + 7,284 \times 10^{-4} \text{sen}(\varpi_2 t)$	$\Sigma_{L_b} = \Sigma_0 + \sigma_w^2 I + \sigma_f^2 Q_f$
	U	$L_a(t) = -3,783 \times 10^3 + 3,763t - 9,359 \times 10^{-4}t^2$ $+4,738 \times 10^{-3} \cos(\varpi_1 t) - 5,242 \times 10^{-3} \text{sen}(\varpi_1 t)$ $-2,212 \times 10^{-4} \cos(\varpi_2 t) - 6,905 \times 10^{-6} \text{sen}(\varpi_2 t)$	$\Sigma_{L_b} = \Sigma_0 + \sigma_w^2 I + \sigma_f^2 Q_f$
RECF	E	$L_a(t) = 5,933 - 2,957 \times 10^{-3}t$ $-2,064 \times 10^{-3} \cos(\varpi_1 t) - 4,299 \times 10^{-4} \text{sen}(\varpi_1 t)$ $+5,365 \times 10^{-4} \cos(\varpi_2 t) + 5,895 \times 10^{-4} \text{sen}(\varpi_2 t)$	$\Sigma_{L_b} = \Sigma_0 + \sigma_w^2 I + \sigma_{rw}^2 Q_{rw}$
	N	$L_a(t) = -25,15 + 1,253 \times 10^{-2}t$ $+2,602 \times 10^{-4} \cos(\varpi_1 t) + 4,056 \times 10^{-4} \text{sen}(\varpi_1 t)$ $-1,364 \times 10^{-4} \cos(\varpi_2 t) - 7,242 \times 10^{-4} \text{sen}(\varpi_2 t)$	$\Sigma_{L_b} = \Sigma_0 + \sigma_w^2 I + \sigma_{rw}^2 Q_{rw}$
	U	$L_a(t) = 4,259 - 2,139 \times 10^{-3}t + 2,538 \times 10^{-6}t^2$ $+2,093 \times 10^{-3} \cos(\varpi_1 t) + 5,354 \times 10^{-4} \text{sen}(\varpi_1 t)$ $+8,289 \times 10^{-4} \cos(\varpi_2 t) - 2,850 \times 10^{-4} \text{sen}(\varpi_2 t)$	$\Sigma_{L_b} = \Sigma_0 + \sigma_w^2 I$

Tabela 6.17: Modelos funcionais estimados para as séries temporais do JPL

Estação	Série temporal	Modelo funcional estimado	Modelo estocástico utilizado
BRAZ	E	$L_a(t) = 8,199 - 4,111 \times 10^{-3}t$ $+1,658 \times 10^{-4} \cos(\varpi_1 t) - 1,009 \times 10^{-3} \text{sen}(\varpi_1 t)$ $-1,296 \times 10^{-4} \cos(\varpi_2 t) - 2,617 \times 10^{-5} \text{sen}(\varpi_2 t)$	$\Sigma_{L_b} = \Sigma_0 + \sigma_w^2 I + \sigma_f^2 Q_f$
	N	$L_a(t) = -25,14 + 1,260 \times 10^{-2}t$ $+1,099 \times 10^{-3} \cos(\varpi_1 t) + 7,466 \times 10^{-4} \text{sen}(\varpi_1 t)$ $-6,736 \times 10^{-4} \cos(\varpi_2 t) - 2,024 \times 10^{-4} \text{sen}(\varpi_2 t)$	$\Sigma_{L_b} = \Sigma_0 + \sigma_w^2 I + \sigma_f^2 Q_f$
	U	$L_a(t) = -3,277 \times 10^2 + 3,277 \times 10^{-1}t - 8,190 \times 10^{-5}t^2$ $+3,129 \times 10^{-3} \cos(\varpi_1 t) - 8,369 \times 10^{-3} \text{sen}(\varpi_1 t)$ $-6,472 \times 10^{-4} \cos(\varpi_2 t) - 2,131 \times 10^{-3} \text{sen}(\varpi_2 t)$	$\Sigma_{L_b} = \Sigma_0 + \sigma_w^2 I + \sigma_f^2 Q_f$
BRFT	E	$L_a(t) = 8,277 - 4,1281 \times 10^{-3}t$ $+7,119 \times 10^{-4} \cos(\varpi_1 t) - 1,233 \times 10^{-3} \text{sen}(\varpi_1 t)$ $+3,405 \times 10^{-4} \cos(\varpi_2 t) - 7,037 \times 10^{-5} \text{sen}(\varpi_2 t)$	$\Sigma_{L_b} = \Sigma_0 + \sigma_w^2 I + \sigma_f^2 Q_f$
	N	$L_a(t) = -23,85 + 1,189 \times 10^{-2}t$ $+1,832 \times 10^{-3} \cos(\varpi_1 t) + 5,429 \times 10^{-4} \text{sen}(\varpi_1 t)$ $-6,202 \times 10^{-4} \cos(\varpi_2 t) + 3,040 \times 10^{-4} \text{sen}(\varpi_2 t)$	$\Sigma_{L_b} = \Sigma_0 + \sigma_w^2 I + \sigma_f^2 Q_f$
	U	$L_a(t) = -61,11 + 6,176 \times 10^{-2}t - 1,560 \times 10^{-5}t^2$ $+2,935 \times 10^{-3} \cos(\varpi_1 t) - 2,036 \times 10^{-3} \text{sen}(\varpi_1 t)$ $-9,012 \times 10^{-4} \cos(\varpi_2 t) - 1,053 \times 10^{-4} \text{sen}(\varpi_2 t)$	$\Sigma_{L_b} = \Sigma_0 + \sigma_w^2 I + \sigma_f^2 Q_f$
CHPI	E	$L_a(t) = 7,794 - 3,888 \times 10^{-3}t$ $-9,751 \times 10^{-5} \cos(\varpi_1 t) - 9,185 \times 10^{-4} \text{sen}(\varpi_1 t)$ $+1,943 \times 10^{-4} \cos(\varpi_2 t) - 3,076 \times 10^{-4} \text{sen}(\varpi_2 t)$	$\Sigma_{L_b} = \Sigma_0 + \sigma_w^2 I + \sigma_f^2 Q_f$
	N	$L_a(t) = -24,48 + 1,222 \times 10^{-2}t$ $+5,984 \times 10^{-4} \cos(\varpi_1 t) + 1,871 \times 10^{-3} \text{sen}(\varpi_1 t)$ $-2,289 \times 10^{-4} \cos(\varpi_2 t) + 4,154 \times 10^{-4} \text{sen}(\varpi_2 t)$	$\Sigma_{L_b} = \Sigma_0 + \sigma_w^2 I + \sigma_f^2 Q_f$
	U	$L_a(t) = -51,86 + 5,163 \times 10^{-2}t - 1,285 \times 10^{-5}t^2$ $+3,180 \times 10^{-3} \cos(\varpi_1 t) - 4,201 \times 10^{-3} \text{sen}(\varpi_1 t)$ $-7,919 \times 10^{-4} \cos(\varpi_2 t) - 1,594 \times 10^{-3} \text{sen}(\varpi_2 t)$	$\Sigma_{L_b} = \Sigma_0 + \sigma_w^2 I + \sigma_f^2 Q_f$
SAVO	E	$L_a(t) = 8,967 - 4,464 \times 10^{-3}t$ $+2,404 \times 10^{-4} \cos(\varpi_1 t) - 1,381 \times 10^{-3} \text{sen}(\varpi_1 t)$ $-7,586 \times 10^{-5} \cos(\varpi_2 t) - 2,042 \times 10^{-4} \text{sen}(\varpi_2 t)$	$\Sigma_{L_b} = \Sigma_0 + \sigma_w^2 I + \sigma_f^2 Q_f$
	N	$L_a(t) = -24,58 + 1,224 \times 10^{-2}t$ $-2,976 \times 10^{-4} \cos(\varpi_1 t) - 1,997 \times 10^{-4} \text{sen}(\varpi_1 t)$ $-7,054 \times 10^{-5} \cos(\varpi_2 t) + 7,342 \times 10^{-4} \text{sen}(\varpi_2 t)$	$\Sigma_{L_b} = \Sigma_0 + \sigma_w^2 I + \sigma_f^2 Q_f$
	U	$L_a(t) = 5,516 \times 10^2 - 5,486 \times 10^{-1}t + 1,364 \times 10^{-4}t^2$ $+3,994 \times 10^{-4} \cos(\varpi_1 t) - 5,809 \times 10^{-4} \text{sen}(\varpi_1 t)$ $-1,026 \times 10^{-3} \cos(\varpi_2 t) - 4,714 \times 10^{-4} \text{sen}(\varpi_2 t)$	$\Sigma_{L_b} = \Sigma_0 + \sigma_w^2 I + \sigma_f^2 Q_f$

7 CONCLUSÕES E CONSIDERAÇÕES FINAIS

Nesta tese foram realizadas investigações e implementações da modelagem estocástica para observações GNSS no processamento de dados, bem como pesquisas e implementações relacionadas à análise, modelagem funcional e estocástica das séries temporais de coordenadas GNSS.

Com relação a modelagem estocástica em função de cintilação ionosférica, foram realizados diversos experimentos visando encontrar uma modelagem estocástica que melhor mitigasse os efeitos de cintilação ionosférica na região brasileira. Para tanto foram utilizados dados GNSS de estações pertencentes à rede CIGALA/CALIBRA. Os receptores GNSS dessas estações coletam dados a uma taxa de 50 Hz e permitem a geração de arquivos de observações GNSS no formato RINEX e também de arquivos de índices de cintilação (ISMR) que fornecem parâmetros necessários para a obtenção de variâncias das observações GNSS em função dos efeitos de cintilação ionosférica (seção 3.2.3). Os experimentos envolveram a análise dos resultados dos processamentos de dados GNSS aplicando diferentes modelagens estocásticas:

- 1) Em função apenas das variâncias das observações, denominado Mod_Padrão
- 2) Em função das variâncias das observações e também dos ângulos de elevação dos satélites, denominado Mod_Elev;
- 3) Em função dos efeitos de cintilação ionosférica, denominado Mod_Cint;
- 4) Em função das variâncias das observações, dos ângulos de elevação dos satélites e também dos efeitos de cintilação, denominado Mod_Elev_Cint.

Na seção 6.1 os resultados relacionados à estação PALM apontaram que para períodos em que a cintilação é fraca os resultados atingem melhorias de até aproximadamente 30% ao aplicar o Mod_Elev_Cint ao invés do Mod_Padrão (durante todo o período do processamento). Em períodos de moderada cintilação, as melhorias atingiram a ordem de 50% utilizando o Mod_Cint em relação ao Mod_Padrão (durante todo o período do processamento).

Já para a estação PRU1, em períodos de fraca cintilação houve melhorias durante todo o período de aproximadamente 20% ao utilizar o Mod_Cint ao invés do Mod_Padrão. Porém, em períodos de forte cintilação (20/10/2012) não houve melhorias de nenhum dos três modelos em relação ao Mod_Padrão. Sendo observado ainda, que nesse

dia, entre as 0h e 4h, ocorreram muitas perdas de ciclos e detecção de possíveis erros grosseiros pelo método DIA

Conclui-se, portanto, que em regiões que os dados estão sob fraca e moderada cintilação ionosférica a utilização de uma modelagem estocástica mais adequada no processamento de dados GNSS proporciona resultados mais confiáveis e realísticos. Já quando se tem dados sob forte cintilação ionosférica são necessárias mais investigações.

Com relação à análise de séries temporais dos dados GNSS, foi realizada nesta tese, a caracterização dos ruídos contidos nas mesmas a partir da análise de variância de Allan e também a partir da estimativa das componentes dos ruídos das séries através do MMQ. No primeiro caso, a caracterização dos ruídos é feita através do ângulo de inclinação das variâncias de Allan obtidas das séries temporais, sendo caracterizado assim apenas um tipo de ruído na série. No entanto, ao realizar a análise gráfica das variâncias de Allan, verifica-se que as séries temporais contêm mais de um tipo de ruído. No caso da estimativa das componentes dos ruídos das séries através do MMQ, considera-se que as séries temporais de coordenadas GNSS contêm ruídos do tipo ruído branco (*white noise*), ruído rosa (*flicker noise*) e caminho aleatório (*random walk*), sendo então estimada as componentes de variância desses ruídos. A partir da estimativa dessas componentes é possível adotar um modelo estocástico que melhor se ajuste à modelagem funcional da série temporal, visando uma melhor representatividade da mesma. Com uma modelagem funcional que melhor se adapte às séries temporais das coordenadas GNSS é possível realizar a predição de novas coordenadas GNSS.

Assim, nesta tese, foram realizadas análise das séries temporais de coordenadas GNSS para estações do SIRGAS-CON (BRAZ, MAPA, POAL, PPTTE e RECF) e do JPL (BRAZ, BRFT, CHPI e SAVO). As primeiras são séries temporais com soluções semanais e a segundas são soluções diárias. Os períodos das séries foram de no mínimo 5 anos e no máximo de 12 anos. Primeiramente, foi realizada a análise de variância de Allan para cada uma das séries temporais (seção 6.2.1). Verificou-se ao final que as séries temporais são compostas por diferentes tipos de ruídos (ruído branco, ruído rosa e caminho aleatório). Em seguida foi realizada a estimativa das componentes de variâncias dos ruídos das séries temporais a partir do MMQ (seção 6.2.2). Nesse caso, após a estimativa das componentes de variância, verificou-se que, para a maioria das séries temporais (E , N e U) das estações, o modelo estocástico identificado (que melhor se adapta às séries temporais) é aquele composto de ruído branco e ruído rosa. Apenas as estações POAL e RECF tiveram o modelo estocástico identificado diferente das outras: modelo em função do ruído branco e caminho aleatório para as componentes E e U da estação POAL e para as

componentes E e N da estação RECF e, modelo em função do ruído branco para a componente N da estação POAL e para a componente U da estação RECF.

Posteriormente, foi realizada a identificação de modelos funcionais que melhor representassem as séries temporais de coordenadas GNSS (seção 6.2.3). Essa tarefa correspondeu a duas etapas: identificação dos modelos através da modificação do modelo funcional (relacionada ao número de parâmetros do modelo) (seção 6.2.3.1) e identificação através da modificação do modelo estocástico (seção 6.2.3.2).

Na primeira etapa, foram estimados modelos funcionais considerando diferentes números de parâmetros:

- 1) Tendência linear mais 10 termos trigonométricos (Mod_func_1);
- 2) Somente as variáveis representativas obtidos da estimativa do modelo anterior (Mod_func_2);
- 3) Tendência linear mais 2 termos trigonométricos (efeitos anuais e semianuais) (Mod_func_3).

Os experimentos mostraram que a utilização do modelo funcional estimado seguindo a terceira estratégia é bem representativo das séries temporais de coordenadas GNSS, principalmente, para as séries das componentes E e N . Com relação às séries da componente U , verificou-se que o modelo que melhor se adapta deve ser acrescido de um termo quadrático (denominado de Mod_func_3_quad).

A próxima etapa consistiu em estimar modelos funcionais levando em consideração os diferentes tipos de ruídos que são contidos nas séries temporais. Para tanto, os modelos funcionais a serem estimados foram escritos em função da tendência linear mais 2 termos trigonométricos, e especificamente para a componente, foi estimado também o modelo considerando o termo quadrático. Em ambos os casos, foram implementados diferentes modelos estocásticos:

- 1) Modelo em função das variâncias das coordenadas (Modelo padrão);
- 2) Modelo em função das variâncias das coordenadas e da componente de variância ruído branco estimada na seção 6.2.3.1 (Modelo padrão + ruído branco);
- 3) Modelo em função das variâncias das coordenadas e das componentes de variância ruído branco e ruído colorido (ruído rosa ou caminho

aleatório) estimadas na seção 6.2.3.2 (Modelo padrão + ruído branco + ruído colorido).

Verificou-se que a adoção de uma modelagem estocástica adequada, a qual considera os diferentes tipos de ruídos nas séries temporais de coordenadas GNSS, é mais realístico e confiável, contribuindo assim numa melhor representação do modelo funcional das séries.

A teoria e metodologia desenvolvida nesta tese para a construção de modelos funcionais que sejam representativos das séries temporais de coordenadas GNSS, pode ser utilizada para qualquer outro tipo de séries temporais dentro do contexto das Ciências Geodésicas e áreas afins. Como exemplo, pode-se citar o monitoramento de estações GNSS, movimento de placas tectônicas, meteorologia (através da análise da atmosfera), etc.

8 RECOMENDAÇÕES E TRABALHOS FUTUROS

Neste trabalho foi investigada a modelagem estocástica dos dados GNSS considerando três diferentes estratégias no processamento: padrão, em função da elevação dos satélites e em função dos efeitos de cintilação ionosférica. Foram utilizados para os experimentos somente dados GPS. Recomenda-se para trabalhos futuros a modelagem estocástica dos sinais GNSS, considerando os efeitos de cintilação ionosférica envolvidos com as portadoras L1 e L2 e com os sinais modernizados (código L2C e portadora L5) do GPS, bem como os sinais dos sistemas GLONASS e GALILEO.

Com relação à análise de séries temporais, foram realizados experimentos visando a identificação de um modelo funcional (seção 6.2.3) que melhor se ajusta à série temporal. Para tanto, foi realizada identificação de ruídos através da estimativa de componentes de variância (seção 6.2.3.2), a partir das quais foram construídos e identificados modelos estocásticos para serem utilizados na identificação do modelo funcional das séries. Com relação à utilização dos modelos estocásticos (construção da matriz Σ_{L_b}) na identificação dos modelos funcionais das séries, nesta tese, foi utilizada apenas a parte diagonal das matrizes de variância das observações (Σ_{L_b}) composta pelos ruídos. Investigações para a utilização dessa matriz completa são recomendadas.

Um assunto de grande relevância na área de Ciências Geodésicas e que também se recomenda para trabalhos futuros está relacionado à análise multivariada das séries temporais. Nesta tese, foi realizada uma introdução à teoria e também alguns experimentos. É importante destacar que a partir da análise multivariada das séries temporais é possível fazer uma análise “espacial” dos dados numa determinada região, através, por exemplo, das análises de correlações entre as estações GNSS da região brasileira. Baseado nisso e em mais investigações no contexto de estimativa de componentes de variância de ruído para séries temporais de coordenadas multivariadas, é possível a construção de modelos funcionais que melhor representem essas séries levando em consideração a correlação existente entre as diferentes estações e também os ruídos contidos nessas séries. Isso permitirá que se crie um campo que represente os elementos que compõem as séries temporais na região brasileira, o que contribuirá para diversos tipos de análises geodinâmicas e posicionamento de alta acurácia (mm) dentro do âmbito das Ciências Geodésicas e áreas afins.

REFERÊNCIAS

ALLAN, D. W.; BARNES, J. A modified "Allan variance" with increased oscillator characterization ability. **Proceedings**. 35th Ann. Freq. Control Symposium, Ft. Monmouth, 1981.

AMIRI-SIMKOOEI, A. R. **Least-squares variance component estimation theory and GPS applications**. 2007. 208p. Ph.D. Thesis. Delft: Netherlands Geodetic Commission, 2007.

AMIRI-SIMKOOEI, A. R. Noise in multivariate GPS position time series. **Journal of Geodesy**. 2008. DOI: 10.1007/s00190-008-0251-8.

AMIRI-SIMKOOEI, A. R.; TIBERIUS, C. C. J. M.; TEUNISSEN, P. J. G. Assessment of noise in GPS coordinate time series: methodology and results. **Journal of Geophysical Research**. vol. 112. 2008.

AQUINO, M; MONICO, J. F. G.; DODSON, A; MARQUES, H. A.; Mitigating the effects of ionospheric scintillations on position estimates, invited presentation to the **3rd European Space Weather Week**, Online Proceedings, Brussels, 13-17 November, 2006.

AQUINO, M.; ANDREOTTI, M.; DODSON, A.; STRANGWAYS, H. On the use of ionospheric scintillation indices as input to receiver tracking models. **Advances in Space Research**. v. 40, Issue 3, 2007, pp. 426-435. doi:10.1016/j.asr.2007.05.035.

AQUINO, M.; MONICO, J. F. G.; DODSON, A.; MARQUES, H. A.; DE FRANCESCHI, G.; ALFONSI, L., ROMANO, V.; ANDREOTTI, M., 2009. Improving the GNSS Positioning Stochastic Model in the Presence of Ionospheric Scintillation. **Journal of Geodesy**, DOI 10.1007/s00190-009-0313-6, 83(10), 953-966.

BASSIRI, S.; HAJJ, G. A. Higher-order ionospheric effects on the global positioning systems observables and means of modeling them, **Manuscr. Geod.**, 18, 280– 289, 1993.

BLEWITT, G. GPS data processing methodology. In: TEUNISSEN, P. J. G.; KLEUSBERG, A. **GPS for geodesy**. 2. ed. New York: Springer-Verlag, 1998. Cap. 6, p. 231-270.

BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. **Time Series Analysis**: forecasting and control, 4th ed. 2008, 784p.

BROWN, R. G.; HWANG, P. Y. C. **Introduction to random signals and applied Kalman filtering**. 2. ed. USA: John Wiley & Sons, Inc., 1992. 502p.

CAMARGO P. O. **Controle de qualidade aplicado ao filtro de Kalman**. 1992. 94 f. Dissertação (Mestrado em Ciências Geodésicas) – Setor de Tecnologia, Universidade Federal do Paraná, Curitiba.

CAMARGO, P. O. **Modelo regional da ionosfera para uso em receptores de uma frequência**. 1999. 191 f. Tese (Doutorado em Ciências Geodésicas) – Setor de Ciências da Terra, Universidade Federal do Paraná, Curitiba.

- CARVALHO, A. G. **Influência da modelagem dos componentes de *bias* instabilidade dos sensores inerciais no desempenho do navegador integrado SNI/GPS**. 2011. 146f. Dissertação (Mestrado em Ciências em Engenharia Elétrica) - Instituto Militar de Engenharia, Rio de Janeiro. 2011.
- CHATFIELD, C. **The analysis of time series: an introduction**. 3rd ed. London: Chapman and Hall Ltd, 1984. 286p.
- CIRAOLO, L.; AZPILICUETA, F.; BRUNINI, C.; MEZA, A.; RADICELLA, S. M. Calibration errors on experimental slant total electron content (TEC) determined with GPS. **Journal of Geodesy**. v. 81, n. 2, p. 111-120, fev. 2007.
- CONKER, R. S.; EL-ARINI, B.; HEGARTY, C. J.; HSIAO, T. Modeling the effects of ionospheric scintillation on GPS/Satellite-Based augmentation system availability. **Radio Science**. vol. 37, n. 0, 2002.
- CRYER, J. D.; CHAN, K. **Time Series Analysis: with Applications in R**. 2nd ed. New York: Springer, 2008, 491p.
- DAVIES, K. **Ionospheric radio**. England: Short Run Press LTd., 1990, 580p.
- DE FRANCESCHI, G., ALFONSI, L., ROMANO, V. ISACCO: an Italian project to monitor the high latitudes ionosphere by means of GPS receivers. **GPS Solutions**, pp. 263-267, 2006, DOI 10.1007/s10291-006-0036-6.
- DE PAULA, E. R.; KANTOR, I. J.; REZENDE, L. F. C.; MUELLA, M. T. H.; CAMPOS, A. A. N.; SMORIGO, P. F.; NETO, A. C. **Characteristics of the low latitude ionospheric irregularities and their effects over GPS signal**. Ionospheric scintillation: Scientific Aspects Space Weather and Services. Nottingham, 2008. Disponível em: <http://www.nottingham.ac.uk/iessg/public/2008_iono_workshop/De_Paula.pdf>. Acesso em: jun. de 2008.
- EL-SHEIMY, N.; HOU, H.; NIU, X. Analysis and modeling of inertial sensors using Allan variance. **IEEE Transactions on Instrumentation and Measurement**. v. 57, n. 1, 2008.
- ELMAS, Z. G.; AQUINO, M.; DODSON, A. Using ionospheric scintillation indices to estimate GPS receiver tracking performance. **EGU General Assembly 2010**, 2010.
- FONSECA JÚNIOR, E. S. **O sistema GPS como ferramenta para a avaliação ionosférica no Brasil**. 2002. 176p. Tese (Doutorado) – Departamento de Engenharia de Transportes, Escola Politécnica da Universidade de São Paulo, São Paulo.
- GAMBIS, D. Allan variance in Earth rotation time series analysis. **Advances in Space Research**, 2002, v.30, n.2, p. 207-212.
- GELB, A.; KASPER JR., J. F.; NASH JR., R. A.; PRICE, C. F.; SUTHERLAND JR., A. A. **Applied optimal estimation**. Cambridge, Massachusetts: The M.I.T. Press, 1974. 374p.
- GEMAEL, C. **Introdução ao ajustamento de observações**. Curitiba: UFPR, 1994. 319p.
- GOAD, C. Surveying with the Global Positioning System. In: PARKINSON, B. W.; SPILKER JR., J. J. **Global Positioning System: Theory and applications**. Washington: American Institute of Aeronautics and Astronautics, 1996. v. 2, Cap. 18, p.501-517.

- GRODECKI, J. **Estimation of variance-covariance components for geodetic observations and implications on deformation trend analysis**. 1997. 243 pp, Department of Geodesy and Geomatics Engineering (Doutorado). Technical Report No. 186, University of New Brunswick, Fredericton, New Brunswick, Canada. 1997.
- HOU, H. **Modeling inertial sensors errors using Allan variance**.. 2004. 147 pp. Thesis. University of Calgary. 2004. Disponível em: <http://www.ucalgary.ca/engo_webdocs/NES/04.20201.HaiyingHou.pdf>. Acesso em: dez. 2013.
- JIN, S.; WANG J.; PARK P. An improvement of GPS height estimations: stochastic modeling. **Earth Planets Space**, 57, p. 253–259, 2005.
- KAPLAN, E. D. **Understanding GPS: principles and applications**. 2 ed. Boston: Artech House, Inc., 1996. 554p.
- KLOBUCHAR, J. A. Ionospheric effects on GPS. In: PARKINSON, B. W.; SPILKER JUNIOR, J. J. **Global Positioning System: theory and applications**. Washington, Dc: American Institute of Aeronautics and Astronautics, Inc, 1996. Cap. 12, p. 485-515.
- KNIGHT, M.; FINN, A. The effects of Ionospheric scintillations on GPS. **ION_GPS 1998**, Inst. of Navig., Nashville, Tenn., 15 – 18 Sep. 1998.
- LEANDRO, R. F.; SANTOS, M. C. Stochastic models for GPS positioning: an empirical approach. **GPS World**. fev. 2007. Disponível em: <<http://www.gpsworld.com/gpsworld/article/articleDetail.jsp?id=401144>>. Acesso em: 5 abr. 2007.
- LEICK, A. **GPS satellite surveying**. 2nd .ed. New York: John Wiley & Sons, 1995.560 p.
- LEICK, A. **GPS satellite surveying**. 3 .ed. New York: John Wiley & Sons, 2004.435 p.
- MAINI, A. K; AGRAWAL, V. **Satellite technology: principles and applications**. Hoboken, N.J.: John Wiley, 2007. 558p.
- MARQUES, H. A. **Influência da ionosfera no posicionamento GPS: estimativa dos resíduos no contexto de duplas diferenças e eliminação dos efeitos de 2ª e 3ª ordem**. 2008. 151f. Dissertação (Mestrado em Ciências Cartográficas) - Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista, Presidente Prudente. 2008.
- MARQUES, H. A.; MONICO, J. F. G.; AQUINO, M. RINEX_HO: Second and Third Order Ionospheric Corrections for RINEX Observation Files. **GPS Solutions**, 2011.
- MARQUES, H. A.; **PPP em tempo real com estimativa das correções dos relógios dos satélites no contexto de rede GNSS**. 2012. 212f. Tese (Doutorado em Ciências Cartográficas) - Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista, Presidente Prudente. 2012.
- MATSUOKA, M. T. **Influência de diferentes condições da ionosfera no posicionamento por ponto com GPS: Avaliação na região brasileira**. 2007. 263 f. Tese (Doutorado em Ciências Cartográficas) - Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista, Presidente Prudente.

MATSUOKA, M. T.; CAMARGO, P. O. Cálculo do TEC usando dados de receptores GPS de dupla frequência para a produção de mapas da ionosfera para a região brasileira. **Revista Brasileira de Cartografia**. Rio de Janeiro, n. 56/01, p. 14-27, jul. 2004.

MIKHAIL, E. M. **Observations and least squares**. New York: IEP, 1976.497 p.

MINITAB. MINITAB QUALITY COMPANION. 2005: **MINITAB**: Statistical software. Disponível em: <<http://www.minitab.com>>. Acesso em: 2011.

MONICO, J. F. G. **Ajustamento das observáveis GPS no contexto de posicionamento geodésico**, Tese de Livre Docência, - Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista, Presidente Prudente, 2005.

MONICO, J. F. G. **Posicionamento pelo GNSS: descrição, fundamentos e aplicações**. 2. ed São Paulo: Unesp, 2008. 476p.

MORETIN, P. A.; TOLOI, C. M. C. **Análise de séries temporais**. São Paulo: Edgard Blücher, 2004. 535p.

NIKOLAIDIS, R., **Observation of Geodetic and Seismic Deformation with the Global Positioning System**. Ph.D. Thesis, University of California, San Diego, 2002.

ODIJK D. **Fast precise GPS positioning in the presence of ionospheric delays**. 2002. 242 f. PhD dissertation, Faculty of Civil Engineering and Geosciences, Delft University of Technology, Delft.

PARKINSON, B. W.; SPILKER JR., J. J. **Global Positioning System: Theory and applications**. Washington: American Institute of Aeronautics and Astronautics, 1996.

PEREIRA, B. B.; PAIS, M. B. Z.; SALES, P. R. H. **Análise espectral de séries temporais: uma introdução para Engenharia, Economia e Estatística**. Rio de Janeiro: Arte Final Leasing Editorial; Eletrobrás S.A., 1986. 108p.

PRESS, W. H. Flicker noises in Astronomy and Elsewhere. **Comments Astrophys**. 1978. v.7, n.4, p. 103-119.

R CORE TEAM. **R: A language and environment for statistical computing**. R Foundation for Statistical Computing, Vienna, Austria. 2012. ISBN 3-900051-07-0. Disponível em: <<http://www.R-project.org/>>.

REZENDE, L. F. C. **Mineração de dados aplicada à análise e predição de cintilação ionosférica**. 2009. 176p. Dissertação (Mestrado em Computação Aplicada) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2009.

RODRIGUES, F. S. **Estudo das irregularidades ionosféricas equatoriais utilizando GPS**. 2003. 175p. Dissertação (Mestrado em Geodésia Espacial) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos.

ROSA, G. P. S. **Análise de séries temporais de coordenadas estimadas com GPS: uma proposta metodológica para eliminação dos efeitos sazonais**. 2008. 106f. Dissertação (Mestrado em Ciências Cartográficas) - Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista, Presidente Prudente. 2008.

- SANTANA, D. C. **Estudos da evolução temporal/espacial das derivas das depleções do plasma ionosférico por imagens digitais da aeroluminescência OI 630 nm noturna**. 2001. Dissertação (Mestrado em Geofísica Espacial) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 2000.
- SEARLE, S. R. An Overview of Variance Component Estimation. **Metrika**. 1995. v.42, p. 215-230.
- SEEBER, G. **Satellite geodesy: foundations, methods, and applications**. 2nd. ed. Berlin, New York: Walter de Gruyter, 2003. 589p.
- SILVA, H. A. **Avaliação de modelos estocásticos no posicionamento GNSS**. 2009. 108f. Dissertação (Mestrado em Ciências Cartográficas) - Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista, Presidente Prudente. 2009.
- SILVA, H. A.; CAMARGO, P. O.; MONICO, J. F. G; AQUINO, M.; MARQUES, H. A.; DE FRANCESCHI, G.; DODSON, A., 2010. Stochastic Modelling Considering Ionospheric Scintillation Effects on GNSS Relative and Point Positioning. **Advances in Space Research: Special Issue Space Weather Advances**, 45(9), 1113-1121.
- SKONE, S. GPS receiver tracking performance under ionospheric scintillations conditions. In: **IGS Network Workshop**, SoriaMoria, Oslo, Norway, 12-14 July, 2000. Disponível em: <<http://www.gdiv.statkart.no/igsworkshop/book/>>. Acesso em: jun. de 2008.
- SOUZA, E. M. **Efeito de multicaminho no GPS: detecção e atenuação usando wavelets**. 2004. 162f. Dissertação (Mestrado em Ciências Cartográficas) - Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista, Presidente Prudente. 2004.
- SOUZA, E. M. **Análise de wavelets para detecção e correção do multicaminho no posicionamento relativo GNSS estático e cinemático**. 2008. 171f. Tese (Doutorado em Ciências Cartográficas) - Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista, Presidente Prudente. 2008.
- STRANGWAYS, H. J. Determining scintillation effects on GPS receivers. **Radio Sci.** vol44, RS0A36, 2009. DOI:10.1029/2008RS004076.
- TEUNISSEN, P. J. G. Quality control and GPS. In: TEUNISSEN, P. J. G.; KLEUSBERG, A. **GPS for geodesy**. 2. ed. New York: Springer-Verlag, 1998. Cap. 7, p. 271-318.
- TEUNISSEN, P. J. G.; KLEUSBERG, A. **GPS for geodesy**. 2. ed. New York: Springer-Verlag, 1998.
- TEUNISSEN, P. J. G. **Testing theory: an introduction**. Netherlands: Delft University Press, 2000. 147 p.
- TEUNISSEN, P. J. G. **Dynamic data processing: recursive least-squares**. Netherlands: Delft University Press, 2001. 241 p.
- TEUNISSEN, P. J. G.; AMIRI-SIMKOOEI, A. R. (). Least-squares variance component estimation. **Journal of Geodesy**, v. 82(2), 2007, p. 65–82. DOI:10.1007/s00190-007-0157-x.

- TIWARI, R.; SKONE, S.; TIWARI, S.; STRANGWAYS, H. J. WMod Assisted PLL GPS Software Receiver for Mitigating Scintillation Affect in High Latitude Region. In: **General Assembly and Scientific Symposium**, 2011 XXXth URSI, 2011, pp. 1-4.
- VAN DIERENDONK, A. J. Measuring ionospheric scintillation effects from GPS signals. **ION 59th Annual Meeting**. Albuquerque, New Mexico, 11-13. June 2001, p. 391-396.
- WALLS, F. L.; FERRE-PIKAL, E. Frequency Standards, Characterization. *Wiley Encyclopedia of Electrical and Electronics Engineering*, v. 12, 1999, p. 767–775. Disponível em: <http://www.nist.gov/customcf/get_pdf.cfm?pub_id=105599>. Acesso em: dez. 2013.
- WANG, J. **Modelling and quality control for precise GPS and GLONASS satellite positioning**. 1999. 171 p. PhD Thesis. School of Spatial Sciences, Curtin University of Technology.
- WARD, P. Satellite signal acquisition and tracking. In: KAPLAN, E. D. **Understanding GPS principles and applications**. Boston: Artech House, 1996. Cap. 5, p. 119-208.
- WEI, W. W. S. **Time series analysis**: univariate and multivariate methods. Boston: Pearson Education: Addison-Wesley, 2006. 614p.
- WILLIAMS, S. D. P. The effect coloured noise on the uncertainties of rates estimated from geodetic time series. **Journal of Geodesy**. v. 76, 2003, p. 483-494. DOI: 10.1007/s00190-002-0283-4.
- WILLIAMS, S. D. P. Error analysis of continuous GPS position time series. **Journal of Geophysical Research**. v. 109, 2004, n. B03412. DOI: 10.1029/2003JB002741.
- WILLIAMS, S. D. P. CATS: GPS coordinate time series analysis software. **GPS Tool Box**. v. 12, 2008, p. 147-153. DOI: 10.1007/s10291-007-0086-4.
- ZHANG, J.; BOCK, Y.; JOHNSON, H; FANG, P.; WILLIAMS, S.; GENRICH, J.; WDOWINSKI, S.; BEHR, J. Southern California permanent GPS geodetic array: error analysis of daily position estimates and sites velocities. **Journal of Geophysical Research**. v. 102, 1997, n. B8, p. 18035-18055.

APÊNDICE A Algoritmo para remoção de outliers em séries temporais a partir do intervalo de predição

```

#instalar os pacotes:
#install.packages("TSA")
#install.packages("tseries")
#install.packages("MASS")
#install.packages("fftw")

# carregar os pacotes:
library(TSA)
library(tseries)
library(MASS)
library(fftw)

#Leitura do arquivo:
temp=read.table('D:/usuarios/Helo/TESE/Resultados/SERIES_TEMPORAIS/JPL_time_series/
R/REMOVE_OUTLIERS/BRAZ/BRAZ_2000a2013.tseries',header=F,dec=".")
temp
is.data.frame(temp)
temp$tmx
temax=temp$tmx
aux = data.matrix(temp)
m=nrow(aux) #total de linhas do arquivo (total de observações)

# criando vetores:
t = rep(0,m); E = rep(0,m); N = rep(0,m); V = rep(0,m);
SE = rep(0,m); SN = rep(0,m); SV = rep(0,m);
SEN = rep(0,m); SEV = rep(0,m); SNV = rep(0,m);
MJD = rep(0,m); ANO = rep(0,m); MES = rep(0,m); DIA = rep(0,m);
HH = rep(0,m); MM = rep(0,m); SS = rep(0,m);

# armazenando as variáveis em vetores:
for(i in 1:m)
{
  t[i] = aux[i,1]; E[i] = aux[i,2]; N[i] = aux[i,3]; V[i] = aux[i,4];
  SE[i] = aux[i,5]; SN[i] = aux[i,6]; SV[i] = aux[i,7];
  SEN[i] = aux[i,8]; SEV[i] = aux[i,9]; SNV[i] = aux[i,10];
  MJD[i] = aux[i,11]; ANO[i] = aux[i,12]; MES[i] = aux[i,13]; DIA[i] = aux[i,14];
  HH[i] = aux[i,15]; MM[i] = aux[i,16]; SS[i] = aux[i,17];
}

# REGRESSÃO LINEAR + 2 HARMONICOS ESFERICOS
# y = y0 + rt + a1*cos(w1)*t + b1*sin(w1)*t + a2*cos(w2)*t + b2*sin(w2)*t
#coeficientes harmônicos do modelo funcional da série temporal:
x1=cos(2*pi*t) #termo anual
x2=cos(2*pi*2*t) #termo anual
x11=sin(2*pi*t) #termo semianual
x12=sin(2*pi*2*t) #termo semianual

#----- COORDENADA E -----

#estimativa pelo MMQ ordinario
regressão_E = lm(E ~ t + x1 + x11 + x2 + x12);
saída_E<-summary(regressão_E)
resíduos_E<-regressão_E$resid
yst_E<-regressão_E$fitted.values
#Intervalo de Confiança
fy_E <-predict(regressão_E, interval="confidence", level=0.99)
ysa_E<-fy_E[,1] #y estimado=yst
linf_E<-fy_E[,2] # limite inferior do intervalo de 99% de confiança
lins_E<-fy_E[,3] # limite superior do intervalo de 99% de confiança
ordem_E<-order(ysa_E)

```

```

png(filename =
"D:/usuarios/Helo/TESE/Resultados/SERIES_TEMPORAIS/JPL_time_series/R/REMOVE_OUTLIER
S/BRAZ/BRAZ_2000a2013_remove_outlier_E.png",width=1000,height=500)
par(new='FALSE',cex=1.3)
plot(ysa_E,E,font.lab=2,xlab='E estimado (m)',ylab='E (m)',axes=F,ylim=c(-
0.2,0.01),xlim=c(-0.08,-0.02))
axis(1, at = seq(-0.08, -0.02, by = 0.01), pos = -0.2)
axis(2, at = seq(-0.2,0.01, by = 0.04), pos = -0.08)
abline(0,1,lty=2)
ordem_E<-order(ysa_E)
lines(ysa_E[ordem], linf_E[ordem])
lines(ysa_E[ordem], lins_E[ordem])
#Intervalo de Predição
fyp_E <-predict(regressão_E,interval="prediction", level=0.99) #t>23
ysa_E<-fyp_E[,1] #y estimado=yst
linfp_E<-fyp_E[,2] # limite inferior do intervalo de 99% de predição
linsp_E<-fyp_E[,3] # limite superior do intervalo de 99% de predição
ordem_E<-order(ysa_E)
lines(ysa_E[ordem_E], linfp_E[ordem_E],lty=5,col="red")
lines(ysa_E[ordem_E], linsp_E[ordem_E],lty=5,col="red")
title(main = "BRAZ (JPL)")
dev.off()

#----- COORDENADA N -----
#estimativa pelo MMQ ordinario
regressão_N = lm(N ~ t + x1 + x11 + x2 + x12);
saída_N<-summary(regressão_N)
resíduos_N<-regressão_N$resid
yst_N<-regressão_N$fitted.values
#Intervalo de Confiança
fy_N <-predict(regressão_N,interval="confidence", level=0.99)
ysa_N<-fy_N[,1] #y estimado=yst
linf_N<-fy_N[,2] # limite inferior do intervalo de 99% de confiança
lins_N<-fy_N[,3] # limite superior do intervalo de 99% de confiança
ordem_N<-order(ysa_N)
png(filename =
"D:/usuarios/Helo/TESE/Resultados/SERIES_TEMPORAIS/JPL_time_series/R/REMOVE_OUTLIER
S/BRAZ/BRAZ_2000a2013_remove_outlier_N.png",width=1000,height=500)
par(new='FALSE',cex=1.3)
plot(ysa_N,N,font.lab=2,xlab='N estimado (m)',ylab='N
(m)',axes=F,ylim=c(0.05,0.25),xlim=c(0.05,0.25))
axis(1, at = seq(0.05,0.25, by = 0.05), pos = 0.05)
axis(2, at = seq(0.05,0.25, by = 0.05), pos = 0.05)
abline(0,1,lty=2)
ordem_N<-order(ysa_N)
lines(ysa_N[ordem], linf_N[ordem])
lines(ysa_N[ordem], lins_N[ordem])
#Intervalo de Predição
fyp_N <-predict(regressão_N,interval="prediction", level=0.99) #t>23
ysa_N<-fyp_N[,1] #y estimado=yst
linfp_N<-fyp_N[,2] # limite inferior do intervalo de 99% de predição
linsp_N<-fyp_N[,3] # limite superior do intervalo de 99% de predição
ordem_N<-order(ysa_N)
lines(ysa_N[ordem_N], linfp_N[ordem_N],lty=5,col="red")
lines(ysa_N[ordem_N], linsp_N[ordem_N],lty=5,col="red")
title(main = "BRAZ (JPL)")
dev.off()

#----- COORDENADA V -----
#estimativa pelo MMQ ordinario
regressão_V = lm(V ~ t + x1 + x11 + x2 + x12);
saída_V<-summary(regressão_V)
resíduos_V<-regressão_V$resid
yst_V<-regressão_V$fitted.values
#Intervalo de Confiança

```

```

fy_V <-predict(regressão_V,interval="confidence", level=0.95)
ysa_V<-fy_V[,1]      #y estimado=yst
linf_V<-fy_V[,2]    # limite inferior do intervalo de 99% de confiança
lins_V<-fy_V[,3]    # limite superior do intervalo de 99% de confiança
ordem_V<-order(ysa_V)
png(filename =
"D:/usuarios/Helo/TESE/Resultados/SERIES_TEMPORAIS/JPL_time_series/R/REMOVE_OUTLIER
S/BRAZ/BRAZ_2000a2013_remove_outlier_V.png",width=1000,height=500)
par(new='FALSE',cex=1.3)
plot(ysa_V,font.lab=2,V,xlab='V estimado (m)',ylab='V (m)',axes=F,ylim=c(-
0.15,0.25),xlim=c(-0.04,-0.005))
axis(1, at = seq(-0.04,-0.005, by = 0.005), pos = -0.15)
axis(2, at = seq(-0.15,0.25, by = 0.1), pos = -0.04)
abline(0,1,lty=2)
ordem_V<-order(ysa_V)
lines(ysa_V[ordem_V], linf_V[ordem_V])
lines(ysa_V[ordem_V], lins_V[ordem_V])
#Intervalo de Predição
fyp_V <-predict(regressão_V,interval="prediction", level=0.99) #t>23
ysa_V<-fyp_V[,1]      #y estimado=yst
linfp_V<-fyp_V[,2]    # limite inferior do intervalo de 99% de predição
linsp_V<-fyp_V[,3]    # limite superior do intervalo de 99% de predição
ordem_V<-order(ysa_V)
lines(ysa_V[ordem_V], linfp_V[ordem_V],lty=5,col="red")
lines(ysa_V[ordem_V], linsp_V[ordem_V],lty=5,col="red")
title(main = "BRAZ (JPL)")
dev.off()

#===== REMOÇÃO DOS OUTLIERS =====

j=1; k=1;
outlier_E = rep(0,m); outlier_N = rep(0,m); outlier_V = rep(0,m);
t_new = rep(0,m); E_new = rep(0,m); N_new = rep(0,m); V_new = rep(0,m);
SE_new = rep(0,m); SN_new = rep(0,m); SU_new = rep(0,m);
SEN_new = rep(0,m); SEV_new = rep(0,m); SNV_new = rep(0,m);
MJD_new = rep(0,m); ANO_new = rep(0,m); MES_new = rep(0,m); DIA_new = rep(0,m);
HH_new = rep(0,m); MM_new = rep(0,m); SS_new = rep(0,m);

for(i in 1:m)
{
  if( (E[i]>=linsp_E[i] || E[i] <= linfp_E[i]) || (N[i]>=linsp_N[i] || N[i] <=
linfp_N[i]) || (V[i]>=linsp_V[i] || V[i] <= linfp_V[i]) )
  {
    outlier_E[j] = E[i]; outlier_N[j] = N[i]; outlier_V[j] = V[i];
    j=j+1;
  }
  else
  {
    t_new[k] = t[i]; E_new[k] = E[i]; N_new[k] = N[i]; V_new[k] = V[i];
    SE_new[k] = SE[i]; SN_new[k] = SN[i]; SU_new[k] = SV[i];
    SEN_new[k] = SEN[i]; SEV_new[k] = SEV[i]; SNV_new[k] = SNV[i];
    MJD_new[k] = MJD[i];
    ANO_new[k] = ANO[i]; MES_new[k] = MES[i]; DIA_new[k] = DIA[i];
    HH_new[k] = HH[i]; MM_new[k] = MM[i]; SS_new[k] = SS[i];
    k=k+1;
  }
}
}

E_temp = rep(0,j-1)
t_temp = rep(0,j-1)
j=1;

```

```
#salvando arquivo com as séries temporais sem os outliers:
Tfile <-
file("D:/usuarios/Helo/TESE/Resultados/SERIES_TEMPORAIS/JPL_time_series/R/REMOVE_OUTLIERS/BRAZ/JPL_BRAZ_2000a2013_new.txt", "w+")
c(isOpen(Tfile, "r"), isOpen(Tfile, "w")) # both TRUE
for(i in 1:m)
{
  if(t_new[i] !=0 )
  {
cat(t_new[i], "\t", E_new[i], "\t", N_new[i], "\t", V_new[i], "\t", SE_new[i], "\t", SN_new[i], "\t", SU_new[i], "\t", SEN_new[i], "\t", SEV_new[i], "\t", SNV_new[i], "\t", MJD_new[i], "\t", ANO_new[i], "\t", MES_new[i], "\t", DIA_new[i], "\t", HH_new[i], "\t", MM_new[i], "\t", SS_new[i], "\t", "\n", file=Tfile)
    E_temp[j]=E_new[i];
    t_temp[j]=t_new[i];
    j=j+1;
  }
}
close(Tfile)
```

APÊNDICE B Gráficos das series temporais do JPL com limite de predição (remoção de outliers)

