

UNIVERSIDADE FEDERAL DE SANTA CATARINA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AMBIENTAL
DEPARTAMENTO DE ENGENHARIA SANITÁRIA E AMBIENTAL

MARA TEREZINHA MARIOTTI

**ANÁLISE ARIMA DE DADOS METEO-
OCEANOGRÁFICOS**

Dissertação apresentada à
Universidade Federal de Santa
Catarina para obtenção do título de
Mestre em Engenharia Ambiental
Orientador: Davide Franco, Dr.

Florianópolis
Santa Catarina
Maio 2003

MARIOTTI, M. T.

ANÁLISE ARIMA DE DADOS METEO-OCEANOGRÁFICOS

Florianópolis, 19/05/2003

x, 79 p., 29,7 cm, figuras em cores, (PPGEA/UFSC, M.Sc., Engenharia Ambiental, 2003).

Dissertação – Universidade Federal de Santa Catarina

1. Modelos ARIMA

2. Maré Meteorológica

3. Modelos Estatísticos de Previsão

I. PPGEA/UFSC

II. Título (série)

ÍNDICE

	LISTA DE FIGURAS	iv
	LISTA DE TABELAS	viii
	RESUMO	ix
	ABSTRACT	x
I.	INTRODUÇÃO	01
1.1	Descrição da Região de Estudo	05
1.2	Característica das Séries Temporais	10
II.	A MARÉ METEOROLÓGICA	15
III.	METODOLOGIA DE ANÁLISE	24
3.1	Processos Estocásticos e Estacionaridade	24
3.2	Funções Autocovariância, Autocorrelação e Autocorrelação Parcial	27
3.3	Ruído Branco	29
3.4	Estimação	30
3.5	Processos Autorregressivo e Média Móvel	31
3.6	Modelos Para Séries Temporais Não Estacionárias	35
3.7	Identificação do Modelo	38
IV.	ANÁLISE DAS SÉRIES	39
4.1	Os primeiros modelos	48
4.2	Análise no Matlab®	57
V.	CONCLUSÕES	75
	REFERÊNCIAS	77

LISTA DE FIGURAS

Figura 1.1:	Localização das estações de coleta dos dados oceanográficos e meteorológicos em São Francisco do Sul-SC, em 1996.	7
Figura 1.2:	Circulação atmosférica no sul do Brasil e sua alteração devido a entrada de frentes frias: (A) situação normal; (B) geração da frente fria; (C) invasão da frente fria; (D) ciclogênese da frente fria (DHN, 1994, apud Truccolo, 1998).....	8
Figura 2.1:	Escalas temporal e espacial vertical das variações do nível do mar. Supramaré (a), alta frequência (b) e baixa frequência (c, d).	19
Figura 4.1:	Séries reamostradas a cada seis horas da temperatura do ar, pressão atmosférica, vento meridional e nível do mar de São Francisco do Sul-SC, do período de 14 de julho a 15 de dezembro de 1996	40
Figura 4.2:	Médias calculadas a cada 30 dados das séries reamostradas a cada 6 horas das variáveis nível do mar, pressão atmosférica, temperatura do ar e vento meridional.....	41
Figura 4.3:	Teste de Box e Cox para verificar a estacionariedade da variância das séries temperatura do ar, pressão atmosférica, vento meridional e nível do mar.....	42
Figura 4.4:	Correlograma da função autocorrelação das séries (A) temperatura do ar e (B) pressão atmosférica.....	43
Figura 4.5:	Correlograma da função autocorrelação das séries (A) vento meridional e (B) nível do mar.....	44
Figura 4.6:	Funções autocorrelação e autocorrelação parcial da série temporal relativa à temperatura do ar local em São Francisco do Sul-SC, 1996.....	45
Figura 4.7:	Funções autocorrelação e autocorrelação parcial da série temporal relativa à pressão atmosférica em São Francisco do	46

Sul-SC, 1996.....

Figura 4.8:	Funções autocorrelação e autocorrelação parcial da série temporal relativa ao vento meridional em São Francisco do Sul-SC, 1996	47
Figura 4.9:	Funções autocorrelação e autocorrelação parcial da série temporal relativa ao nível do mar local em São Francisco do Sul-SC, 1996.....	47
Figura 4.1.1:	Gráfico das funções de autocorrelação (ACF) e autocorrelação parcial (PACF) do resíduo do modelo ARIMA (1,1,1) aplicado sobre a série da temperatura do ar.....	49
Figura 4.1.2:	Gráficos do normal probability plot e histograma do resíduo do modelo ARIMA(1,0,1) aplicado a série da temperatura do ar.....	50
Figura 4.1.3:	Gráfico das funções de autocorrelação (ACF) e autocorrelação parcial (PACF) do resíduo do modelo ARIMA (1,1,1) aplicado sobre a série da pressão atmosférica.....	51
Figura 4.1.4:	Gráficos do normal probability plot e histograma do resíduo do modelo ARIMA(1,1,1) aplicado a série da pressão atmosférica.....	52
Figura 4.1.5:	Gráfico das funções de autocorrelação (fac) e autocorrelação parcial (facp) do resíduo do modelo ARIMA (1,0,1) aplicado sobre a série do vento meridional.....	53
Figura 4.1.6:	Gráficos do normal probability plot e histograma do resíduo do modelo ARIMA(1,0,1) aplicado a série do vento meridional.....	54
Figura 4.1.7:	Gráfico das funções de autocorrelação (fac) e autocorrelação parcial (facp) do resíduo do modelo ARIMA (1,1,1) aplicado sobre a série do nível do mar.....	56
Figura 4.1.1:	Gráficos do normal probability plot e histograma do resíduo do modelo ARIMA(1,1,1) aplicado a série do nível do mar.....	56
Figura 4.2.1:	Funções autocorrelação e autocorrelação parcial do resíduo	59

do modelo AR(2) aplicado à série da temperatura do ar local em São Francisco do Sul-SC, 1996

Figura 4.2.2:	Funções autocorrelação e autocorrelação parcial do resíduo do modelo AR(4) aplicado à série da temperatura do ar local em São Francisco do Sul-SC, 1996.	59
Figura 4.2.3:	Funções autocorrelação e autocorrelação parcial do resíduo do modelo AR(2) aplicado à série da pressão atmosférica em São Francisco do Sul-SC, 1996.....	61
Figura 4.2.4:	Funções autocorrelação e autocorrelação parcial do resíduo do modelo AR(4) aplicado à série da pressão atmosférica em São Francisco do Sul-SC, 1996.....	61
Figura 4.2.5:	Figura 4.2.5: Funções autocorrelação e autocorrelação parcial do resíduo do modelo AR(2) aplicado à série do vento meridional local em São Francisco do Sul-SC, 1996.....	63
Figura 4.2.6:	Funções autocorrelação e autocorrelação parcial do resíduo do modelo AR(4) aplicado à série do vento meridional local em São Francisco do Sul-SC, 1996.....	63
Figura 4.2.7:	Funções autocorrelação e autocorrelação parcial do resíduo do modelo AR(2) aplicado à série do nível do mar local em São Francisco do Sul-SC, 1996.....	65
Figura 4.2.8:	Funções autocorrelação e autocorrelação parcial do resíduo do modelo AR(3) aplicado à série do nível do mar local em São Francisco do Sul-SC, 1996.....	65
Figura 4.2.9:	Funções autocorrelação e autocorrelação parcial do resíduo do modelo AR(4) aplicado à série do nível do mar local em São Francisco do Sul-SC, 1996.....	66
Figura 4.2.10:	Comparação entre ACF e espectro do modelo AR(4) e a série observada da série da temperatura do ar.	67
Figura 4.2.11:	Análise dos modos temporais do modelo AR(4) para a série da temperatura do ar.	68
Figura 4.2.12:	Comparação entre ACF e espectro do modelo AR(4) e a série observada da série da pressão atmosférica.	69

Figura	Análise dos modos temporais do modelo AR(4) para a série	
4.2.13:	da pressão atmosférica.	70
Figura	Comparação entre ACF e espectro do modelo AR(4) e a série	
4.2.14:	observada da série do vento longitudinal.	71
Figura	Análise dos modos temporais do modelo AR(4) para a série	
4.2.15:	do vento meridional.	72
Figura	Comparação entre ACF e espectro do modelo AR(4) e a série	
4.2.16:	observada da série do nível do mar.	73
Figura	Análise dos modos temporais do modelo AR(4) para a série	
4.2.17:	do nível do mar.	74

LISTA DE TABELAS

Tabela 4.1.1	Modelos desenvolvidos à partir dos dados reamostrados a cada 6 horas da série da temperatura do ar.....	48
Tabela 4.1.2	Modelos desenvolvidos à partir dos dados reamostrados a cada 6 horas da série da pressão atmosférica.....	51
Tabela 4.1.3	Modelos desenvolvidos à partir dos dados reamostrados a cada 6 horas da série do vento meridional.....	53
Tabela 4.1.4	Modelos desenvolvidos à partir dos dados reamostrados a cada 6 horas da série do nível do mar.....	55
Tabela 4.1.5	Estatísticas das séries analisadas e dos resíduos após a aplicação dos modelos.	57
Tabela 4.2.1	Modelos AR construídos para a série da temperatura do ar à partir da rotina AR do módulo Ident do Matlab.....	58
Tabela 4.2.2	Modelos AR construídos para a série da pressão atmosférica à partir da rotina AR do módulo Ident do Matlab	60
Tabela 4.2.3	Modelos AR construídos para a série do vento meridional à partir da rotina AR do módulo Ident do Matlab.....	62
Tabela 4.2.4	Modelos AR construídos para a série do vento meridional à partir da rotina AR do módulo Ident do Matlab.	64

RESUMO

Um estudo do mecanismo gerador das componentes meteorológicas que afetam o nível do mar é proposto através da utilização de modelos ARIMA (autorregressive integrated moving average). Séries temporais da temperatura do ar, pressão atmosférica, da componente meridional do vento e do nível do mar foram aquiritadas em São Francisco do Sul-SC, no período de 14 de julho a 15 de dezembro de 1996, e reamostradas a cada seis horas para melhor avaliar as componentes de baixa frequência. As séries se mostraram não estacionárias na média, impondo a necessidade de integração. Não foi possível identificar uma não estacionaridade da variância devido ao comprimento insuficiente dos registros utilizados. Nos modelos de ordem 2 a estrutura de recorrência entre dois sistemas frontais é reconhecida através do modo associado aos dois pólos do polinômio. Os modelos AR(4) de todas as variáveis consideradas conseguem reconstruir também a evolução do sistema in situ, de período aproximado de 2,5 dias, por meio da segunda dupla de pólos. Modelos autorregressivos de ordem superior poderiam melhorar a identificação e a reconstrução desses ciclos, mas não conseguem convergir devido a não estacionaridade. Apesar disso, modelos de baixa ordem, com dois parâmetros apenas, conseguem fazer previsões aceitáveis até 24 horas, o que demonstra as possibilidades da metodologia.

ABSTRACT

A study of the mechanism that generates the meteorological components that affect the sea level is proposed by using ARIMA models (autorregressive integrated moving average). Air temperature, atmospheric pressure, southward wind and sea level component were measured at São Francisco do Sul – SC, between July 14 and December 18, 1996, and resampled at every 6 hours for better evaluation of the low frequency components. The series showed to have a non-stationary mean, enforcing the need for integration. It was not possible to identify a non-stationary variance due to the insufficient size of the data utilized. At the second order models the appealing structure of two frontal systems is recognized by the mode associated to the two polynomial pole. AR(4) models of all considered variables are also able to reconstruct the system evolution in situ, of an approximate period of 2,5 days, by means a second pair of poles. Superior order autoregressive models could improve the identification and reconstruction of these cycles, but they can't converge due to the non-stationarity. Nevertheless, low order models with only two parameters are able to do acceptable forecasting up to 24 hours, which demonstrates the possibilities of the methodology.

CAPÍTULO 1

INTRODUÇÃO

Em fevereiro de 2002 uma elevação anormal do nível do mar provocou inundação em Balneário Camboriu-SC , invadindo quiosques e restaurantes da orla e alagando a avenida Atlântica. Antes desta outras ocorrências deste tipo são lembradas no litoral de Santa Catarina, como a de Florianópolis no natal de 1998, quando as águas de uma forte precipitação, represadas pelo nível anormalmente alto do mar, provocaram inundação nas margens da Lagoa da Conceição, fazendo com que os moradores passassem o dia de natal com água dentro de suas casas, especialmente os moradores do Canto da Lagoa. Matinhos, no litoral paranaense, é outro local onde as invasões do mar vez por outra surpreendem os moradores, inundando casas e avenidas e destruindo quiosques à beira-mar.

Existem registros de grandes catástrofes provocadas por esses fenômenos em outros locais do planeta. Na história mais recente podemos citar os casos ocorridos no Mar do Norte em 1953, quando o nível do mar local teve uma elevação de 3 m acima do normal, matando 1.800 pessoas na Holanda e 300 na Inglaterra (Brown, 1989; Heemink, 1986; Pugh, 1987), e na Baía de Bengala, onde em 1970 morreram 250.000 pessoas e em 1985, 20.000. (Brown, 1989; Pugh, 1987).

Embora sem provocar alterações tão significativas como nesses casos, fenômenos como estes não são incomuns no litoral sul do Brasil e acontecem com maior intensidade com periodicidade de uma a duas vezes por ano, causando prejuízos às populações litorâneas.

O fenômeno inverso também pode ocorrer, quando se verificam sub elevações do nível, ou seja, níveis mais baixos que os esperados, acarretando problemas principalmente em portos, impedindo a movimentação de embarcações de maior calado.

Esse tipo de fenômeno afeta uma grande parte da população do planeta, uma vez que cerca de 70% dela vive em regiões litorâneas, o que faz com que as atividades humanas nessas áreas se desenvolvam. Transporte de pessoas e de cargas, pesca, aquacultura e turismo são algumas dessas atividades. Novos esportes náuticos surgem todos os dias com novas tecnologias e equipamentos que utilizam, além dos motores, a energia do oceano e do vento. As atividades portuárias e pesqueiras necessitam de informação e previsões das condições meteorológicas, climáticas e oceanográficas para evitar acidentes e prejuízos.

Em Santa Catarina as pesquisas e o desenvolvimento da aquacultura buscam não só uma alternativa para a pesca artesanal, como também um incremento do consumo de peixes e moluscos. Intensifica-se assim o surgimento de cultivos que produzem alimentos muito apreciados

especialmente para as comunidades litorâneas e seus visitantes. Além disso, as áreas litorâneas são a cada ano mais visitadas por turistas que buscam descanso, lazer, veraneio e esportes nas praias tão numerosas e especialmente belas de sua costa, sendo o turismo uma de suas atividades econômicas mais importantes.

As políticas de gerenciamento costeiro necessitam equilibrar todas essas atividades, promovendo o desenvolvimento sustentável com manejo ambiental, protegendo praias, dunas, restingas e manguezais. Estes ecossistemas costeiros são ambientes de transição entre o oceano e o continente e estão em constante transformação em decorrência, principalmente, das mudanças climáticas e da dinâmica dos oceanos - particularmente da interação oceano-atmosfera. Essa interação provoca variações no nível e na temperatura do mar costeiro.

No litoral de Santa Catarina, em particular, as concentrações urbanas, as atividades portuárias, o turismo e a aquicultura são fatores preponderantes nas políticas de gerenciamento costeiro. Esses fatores também são influenciados diretamente pelas sobre ou sub elevações do nível do mar, sendo as atividades deles decorrentes prejudicadas pela ocorrência de situações diferentes das normais.

O movimento regular e previsível das marés, determinado por componentes astronômicas, mais especificamente pela posição relativa entre a

Terra e a Lua e a Terra e o Sol, é modificado em maior ou menor extensão por fatores irregulares sendo os principais a pressão atmosférica e a ação do vento sobre a superfície do oceano (Pugh, 1987, Gill, 1982). A variação da pressão atmosférica e a troca de energia entre a atmosfera e o oceano através da atuação do vento, resultam em oscilações da ordem de dias do registro do nível do mar, denominadas marés meteorológicas (Gill, 1982). A troca de energia entre a atmosfera e os oceanos acontece em todas as escalas temporais, desde a geração de ondas de vento de curto período até a suavização dos extremos climáticos pela transferência de calor dos pólos e pela inércia térmica dos oceanos (Pugh, 1987).

A importância relativa dos fatores astronômicos e meteorológicos depende da época do ano e da batimetria do local. Distúrbios meteorológicos são maiores no inverno, e tem efeito maior quando agem em águas rasas. O nível total pode aumentar provocando inundações costeiras quando as marés meteorológicas altas coincidem com as marés astronômicas altas de sizígia (Pugh, 1987).

Este trabalho tem por objetivo analisar as componentes meteorológicas de períodos de aproximadamente 3 a 15 dias que afetam o nível do mar local no litoral Norte de Santa Catarina, dando continuidade a análise feita por Truccolo (1998). Para isso serão necessários os seguintes passos:

- análise estatística das séries temporais relativas a temperatura do ar, pressão atmosférica, intensidade e direção do vento meridional e nível do mar;
- aplicação da metodologia ARIMA desenvolvida por Box e Jenkins (1970) desenvolvendo modelos que descrevam o mecanismo gerador das séries;
- construção de modelos de previsão.

1.1 Descrição da região de estudo

A obtenção das séries temporais utilizadas neste estudo se deveu a convênio firmado entre a PETROBRÁS S/A e as Universidades UFSC, UFRGS, UFPR E FURG para o projeto “Estudos Ambientais em Áreas Oceânicas e Costeiras no Sul do País”. Foram coletados, de julho a dezembro de 1996 registros de marés, correntes, medições de ondas e dados meteorológicos em São Francisco do Sul ($26^{\circ}13'09''S$ e $48^{\circ}29'05''W$), litoral norte de Santa Catarina. A localização das estações de coleta é mostrada na Figura 1.1.

A plataforma continental sul é relativamente larga, caracterizada por isóbaras alinhadas paralelamente à costa e com orientação da linha de costa de 45° em relação ao norte. Localmente, a plataforma continental ao largo de São Francisco do Sul apresenta uma orientação de aproximadamente 20° em relação ao norte.

A circulação atmosférica regional e sua alteração em função da evolução de frentes frias é caracterizada pela atuação do sistema semi-fixo de alta pressão denominado Anticiclone do Atlântico Sul (Figura 1.2A). A situação normal é o domínio do sistema semi-fixo com ventos de NE, juntamente com o efeito local da brisa marinha. Periodicamente, o sistema é perturbado pela passagem de frentes frias originadas pelo Anticiclone Móvel Polar (Figura 1.2B), que migram sobre a região de sudoeste para nordeste (DHN, 1994, *apud* Truccolo, 1998). Estas frentes frias estão associadas ao escoamento ondulatório de grande escala, intensificando-se ou dissipando-se sobre o continente de acordo com as características atmosféricas (Nimer, 1989, *apud* Truccolo, 1998).

Fig. 1.1 Localização das estações de coleta dos dados oceanográficos e meteorológicos em São Francisco do Sul-SC, em 1996.

A progressão do Anticiclone Móvel Polar sobre a porção sul da América do Sul origina uma frente que divide as massas de ar tropical marítima do Anticiclone do Atlântico Sul e a massa de ar frio. Durante os meses de inverno a massa polar é suficientemente forte para levar a frente até o Rio da Prata e, em conseqüência, a massa tropical se retrai e ocorre uma alteração geral na

circulação (Figura 1.2C). Os sistemas de frentes frias atuam com maiores intensidades no sul do Brasil devido a sua proximidade às zonas de geração.

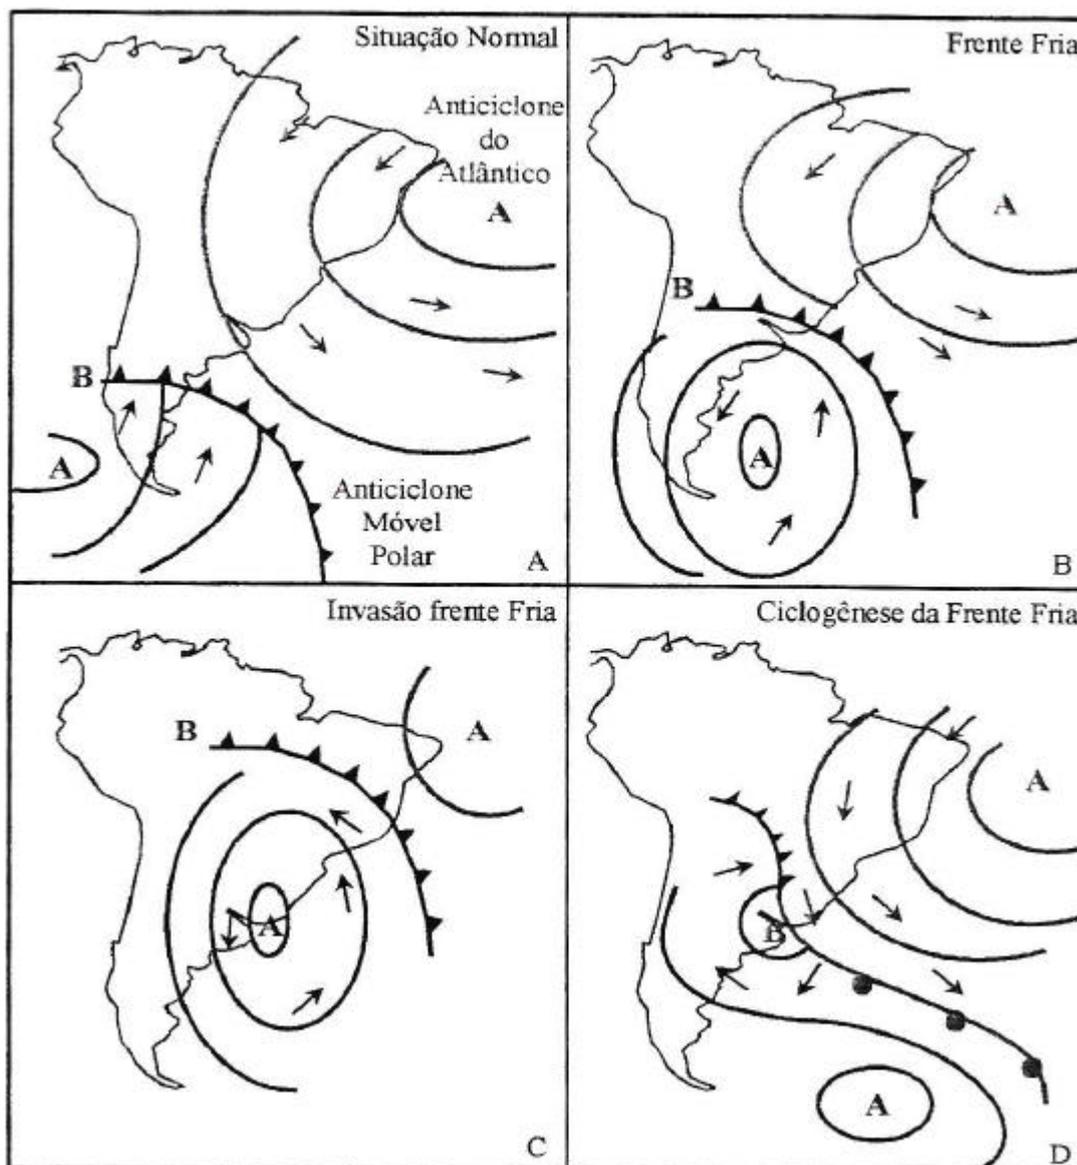


Fig. 1.2 Circulação atmosférica no sul do Brasil e sua alteração devido a entrada de frentes frias: (A) situação normal; (B) geração da frente fria; (C) invasão da frente fria; (D) ciclogênese da frente fria (DHN, 1994, apud Truccolo, 1998)

O Anticiclone Polar pode progredir sobre o Brasil e fundir-se rapidamente com o Anticiclone do Atlântico. No entanto, nem sempre a frente

progredir para o norte, podendo estacionar nas regiões sul e sudeste. Neste caso, ela ondula e gera depressões atmosféricas que se deslocam em direção ao oceano (Figura 1.2D).

A passagem de uma frente fria produz variações bruscas da pressão e da temperatura do ar, ocasionando também uma modificação da magnitude e direção do vento. Algumas características da propagação destes distúrbios são: (1) com a aproximação da frente fria, a velocidade média do vento é de 5 ms^{-1} no setor quente da frente, apresentando uma rotação anti-horária de nordeste para noroeste; (2) durante a permanência da frente, logo após a pressão atmosférica chegar ao seu valor mínimo, o vento passa a soprar do quadrante sul com uma velocidade média de 8 ms^{-1} no setor frio; (3) aproximadamente 1 dia após a passagem da frente o vento volta a soprar de nordeste, com retorno do Anticiclone do Atlântico Sul; (4) a duração média de uma frente fria é de 2 a 3 dias, com intervalo de tempo consecutivo entre as frentes de 6 a 11 dias, e a velocidade média de propagação é de 500 Km dia^{-1} (Stech & Lorenzetti, 1992, *apud* Truccolo, 1998).

Segundo Rodrigues (2003) em média 3 a 4 frentes frias atingem Santa Catarina em todos os meses do ano, com um número ligeiramente maior de sistemas nos meses de primavera. O intervalo médio entre duas passagens frontais é de 8 dias, sendo que mais de 50% dos sistemas atingem o litoral catarinense em um intervalo de 3 a 8 dias. Nos meses de primavera, além disso, ocorre uma frequência frontal relativamente maior e uma menor

variabilidade do número de sistemas quando comparados aos demais meses do ano.

Ainda segundo Rodrigues (2003), frentes frias seguidas de vento sudeste, situação típica de verão, geram um aumento do nível do mar relativamente pequeno. Uma condição de pós-frontal com ventos de sudoeste e de sul, típica de inverno, favorece o empilhamento de água na costa Sul do Brasil graças ao efeito de Ekman. Os casos mais significativos de maré meteorológica positiva em São Francisco do Sul no período deste estudo foram verificados em uma condição favorável à formação de pista de vento sul.

1.2 Características das séries temporais

Os registros do nível do mar para São Francisco do Sul foram obtidos através de um marégrafo de pressão marca Aanderaa, modelo WLR7, com sistema digital de medições e instalado no pier da PETROBRAS a 2,74 m de profundidade em relação ao zero do IBGE. Os registros de pressão hidrostática foram obtidos com intervalo amostral de 30 minutos e convertidos em valores de nível horário médio subtraindo a pressão atmosférica do local por Truccolo (1998).

As séries temporais de meteorologia local para o período de julho a dezembro, foram monitoradas através de uma estação meteorológica automática marca Campbell, modelo CM6, instalada a 10 m de altura no alto de

um posto de salva vidas e com intervalo amostral horário. A direção do vento foi corrigida com valor de 17° , resultante da declinação magnética.

As informações sobre os deslocamentos de sistemas atmosféricos ciclônicos que se propagam sobre a região sul foram obtidas de cartas sinópticas de pressão atmosférica superficial, elaboradas pela Diretoria de Hidrografia e Navegação (DHN) do Ministério da Marinha do Brasil.

Após a aquisição e tratamento preliminar dos registros maregráficos e meteorológicos, foram obtidas séries temporais horárias (hora local, GMT-3) do nível do mar, da pressão atmosférica, da direção e velocidade do vento e da temperatura do ar para o período de 14 de julho a 15 de dezembro de 1996.

O primeiro trabalho utilizando as séries de São Francisco do Sul, publicado por Truccolo (1998), apresenta os seguintes resultados preliminares:

- As variações do nível do mar observadas oscilam em torno de um valor médio de 117,19 cm, com desvio padrão de 37,15 cm. Os valores extremos do nível do mar foram observados durante os meses de inverno: o valor máximo de 277,4 cm ocorreu no dia 21 de julho e o valor mínimo de 26,2 cm se deu em agosto.
- A pressão atmosférica média foi de 1017,4 mbar, com desvio padrão de 5,7 mbar. Alcança um valor mínimo de 1001,0 mbar em setembro e máximo de 1031,0 mbar em julho.

- A evolução temporal do vento mostra inversões da direção devido a passagem de frentes frias no local sendo três direções de maior concentração:
 - 1) de direção norte-nordeste, mais expressiva, com intensidade entre 2 e 4 m s⁻¹, que corresponde a atuação do Anticiclone do Atlântico Sul;
 - 2) de direção oeste e leste, com intensidades de aproximadamente 2 ms⁻¹, correspondendo às brisas marinha e terral, ortogonais à linha de costa;
 - 3) de direção sudeste, alcançando intensidades maiores, em torno de 6 a 8 ms⁻¹, correspondendo aos ventos associados à passagem de frentes frias.

Oscilações com periodicidades menores que 40 horas foram removidas das séries por Truccolo (1998) utilizando um filtro passa-baixo quadrático Lanczos, que garante que períodos maiores que 55 horas não sejam afetados e permitindo assim a identificação da componente meteorológica relacionada à variações entre 3 e 15 dias.

Da análise das componentes astronômicas dos registros de marés verificou-se que, segundo a classificação de Pugh (1987), a região pode ser caracterizada por micro-marés, a maré astronômica apresentando uma altura média de 70 cm, atingindo 105 cm durante a sizígia e 21 cm durante a quadratura (Truccolo, 1998).

O Número de forma encontrado para São Francisco do Sul é igual a 0,32, o que representa um regime de maré do tipo misto, predominantemente semidiurno com desigualdades de alturas para as preamares e baixa-mares consecutivas (Truccolo & Melo F^o, 1997).

A variância dos constituintes harmônicos identificados representa 74% da variância total do nível observado, da maré meteorológica 24% e a porção de longo período menos de 2%. Oscilações do nível do mar maiores de 50 cm são observadas em 19,4% do período analisado, sendo que 6,4% são devido à componente meteorológica. Considerando-se oscilações maiores que 80 cm, a maré astronômica é responsável por 0,2% dos casos e a maré meteorológica por 2%. Este valor representa em um ano a ocorrência de pelo menos 1 semana de marés maiores que 80 cm devidas à componente meteorológica, e menos de 1 dia devido somente a maré astronômica. (Truccolo, 1998).

Utilizando o filtro passa-baixo Lanczos, com a remoção de oscilações de até 40 horas das séries, Truccolo (1998) conseguiu identificar a componente meteorológica como componente de baixa frequência. Na decomposição do nível do mar nas três faixas de frequência, as oscilações de alta frequência representam 77%, as de baixa frequência 22% e tendência 2%. Com relação às séries climáticas, a pressão atmosférica tem 3,5% da variância na faixa de alta frequência, 68% na faixa meteorológica e 28,5% representa a tendência.

O vento sendo uma variável vetorial pode ser representado pelas suas componentes ortogonais x e y . Foram definidos como positivos ventos de Oeste na direção x e ventos de Sul ao longo do eixo y . A componente y apresenta-se mais energética estando associada aos ventos do quadrante Sul de maior intensidade, sendo que a maior variabilidade reside na faixa meteorológica (54%). A componente diária relacionada aos ventos do quadrante Norte é responsável por 41% da variância. A componente x mostra 44% da variância relacionada aos fenômenos diários, e dominância na faixa meteorológica (47%), provavelmente devido à componente horizontal dos ventos de Sudoeste e Nordeste. O incremento da importância da tendência (9%) pode indicar uma possível sazonalidade na componente horizontal dos ventos.

Este trabalho apresentará, no capítulo 2 definições sobre a maré meteorológica e os trabalhos mais recentes de análise de dados meteorológicos, no capítulo 3 uma descrição da metodologia utilizada, no capítulo 4 os resultados obtidos na análise das séries temporais e, finalmente, no capítulo 5 as conclusões e sugestões para trabalhos futuros.

CAPÍTULO 2

A MARÉ METEOROLÓGICA

Embora os registros de observação de marés datem de muitos séculos, as pesquisas científicas modernas relacionadas ao assunto começaram com três teorias. Galileu Galilei (1564-1642), propôs que a rotação da terra, anualmente em torno do sol e diariamente sobre seu próprio eixo induz os movimentos do mar, os quais são modificados pelos contornos do fundo do mar provocando as marés. René Descartes (1596-1650) afirmava que o espaço é preenchido por matéria ou éter invisíveis, e que a lua, em sua trajetória em torno da terra, comprime esse éter o qual transmite pressão sobre o oceano, formando as marés. Foi de Kepler (1571-1630) a idéia original de que a lua exerce atração gravitacional sobre água do oceano provocando uma elevação do nível no local onde essa força atua. A atração pela lua seria balanceada pela atração da terra sobre a água, impedindo assim o seu escoamento para a lua (Pugh, 1987).

O maior avanço na compreensão científica da geração de marés, porém, se deve a Isaac Newton (1642-1727). Newton conseguiu aplicar sua formulação da lei de atração gravitacional, de que dois corpos se atraem com uma força proporcional ao produto de suas massas e inversamente proporcional ao quadrado da distância entre eles, para mostrar a razão da ocorrência de duas marés a cada trânsito lunar (Pugh, 1987; Thurman, 1997).

A teoria da maré de equilíbrio de Newton evoluiu e as forças geradoras de marés são atualmente conhecidas em várias escalas temporais.

Pode-se definir maré como movimentos periódicos da água dos oceanos, que são diretamente relacionados em amplitude e fase com algumas forças geofísicas periódicas. A função forçante geofísica dominante é a variação do campo gravitacional na superfície da terra, causada pelos movimentos regulares dos sistemas lua-terra e terra-sol. Movimentos provocados por essas forças não chamados *maré astronômica* (Pugh, 1987).

A magnitude das forças geradoras das marés pode ser precisamente formulada, embora a resposta do oceano a essas forças seja modificada pelo efeito permanente da topografia e pelo efeito passageiro dos processos climáticos (Brown, 1989). O modelo regular e previsível das marés é modificado, em maior ou menor extensão, por esses fatores irregulares, sendo os principais a pressão atmosférica e o vento atuando na superfície do mar. Esses fenômenos podem provocar mudanças consideráveis na altura de uma determinada maré e no tempo de sua ocorrência (Pugh, 1987; Brown, 1989).

As marés observadas na maioria dos oceanos têm altura de cerca de 0-1m (amplitude de 0-0,5m), mas existem consideráveis variações. As marés espalham-se por oceanos cercados de plataformas continentais onde são observadas alturas muito mais significativas. As razões para essas complicadas respostas dos oceanos podem ser resumidas por (Pugh, 1987):

- 1) Movimentos da água na superfície da terra obedecem às leis físicas representadas pelas equações hidrodinâmicas da continuidade e do momentum, ou seja, eles se propagam como ondas longas. Qualquer propagação de uma onda de leste para oeste ao redor da terra seria impedida pelas fronteiras norte-sul dos continentes. As únicas latitudes onde o movimento circumpolar não é impedido são em volta do continente Antártico e na bacia do Ártico.
- 2) Ondas longas viajam a uma velocidade dada por $(\text{profundidade da água} \times \text{aceleração da gravidade})^{1/2}$. Mesmo na ausência de barreiras, seria impossível a Maré de Equilíbrio acompanhar a trajetória da lua, porque os oceanos são muito rasos. Tomando uma profundidade média de 4.000m a velocidade da onda seria de 198 ms^{-1} , enquanto que no equador um ponto sublunar viaja em direção a oeste numa velocidade de 450 ms^{-1} .
- 3) As várias bacias oceânicas têm seu próprio modo natural de oscilação que influencia suas respostas as forças geradoras de marés.
- 4) Os movimentos da água são afetados pela rotação da terra. Os efeitos da rotação da terra nos movimentos da água estão representados nas equações hidrodinâmicas pela aceleração de Coriolis. A solução das equações mostra que certas formas modificadas do movimento da água são possíveis, a mais importante das quais tem a forma descrita pelas ondas de Kelvin.
- 5) A crosta terrestre responde elasticamente às forças de maré e essa resposta é descrita em termos dos "Love numbers". Embora a resposta

da terra sólida às forças diretas de marés seja bem descrita globalmente por estes termos, existem efeitos locais devidos à depressões em áreas de águas rasas provocadas pelo carregamento da maré.

Variações com escalas de tempo de segundos (ondas geradas pelo vento), horas (ondas geradas pela maré astronômica), dias (ondas geradas por influências meteorológicas), meses (meandros e vórtices das correntes oceânicas), anual (variações sazonais nos processos de interação oceano-atmosfera, nível estérico do mar, ondas geradas pela maré astronômica), interanual (alterações climáticas geradas por processos globais do tipo El Niño) exercem influência com diferentes intensidades sobre o comportamento dos oceanos (Miranda, 2002).

Essas escalas de tempo estão associadas a amplitudes de variação do nível relativo do mar entre centímetros a vários metros, como ilustra esquematicamente a Figura 2.1. Pode-se observar na figura que a influência da maré astronômica é, em geral, dominante tanto em intensidade quanto em frequência (Figura 2.1b). Essas oscilações com escala de tempo de horas têm altura predominante e períodos de ocorrência predominante semidiurno (12,4 h) ou diurno (25,0 h), correspondendo a frequências de uma ou duas oscilações por dia e costuma-se classificá-las de oscilações de *freqüência de maré* ou *alta freqüência*. As variações com escala de tempo de segundos (Figura 2.1a) e dias, semanas, meses ou anos (Figura 2.1c, Figura 2.1d) são de *freqüências supramaré* (freqüência superior a 1 e 2 ciclos por dia) e *baixa*

freqüência ou *submaré* (oscilações com freqüência inferior à freqüência de maré), respectivamente (Miranda, 2002; Franco, 1988).

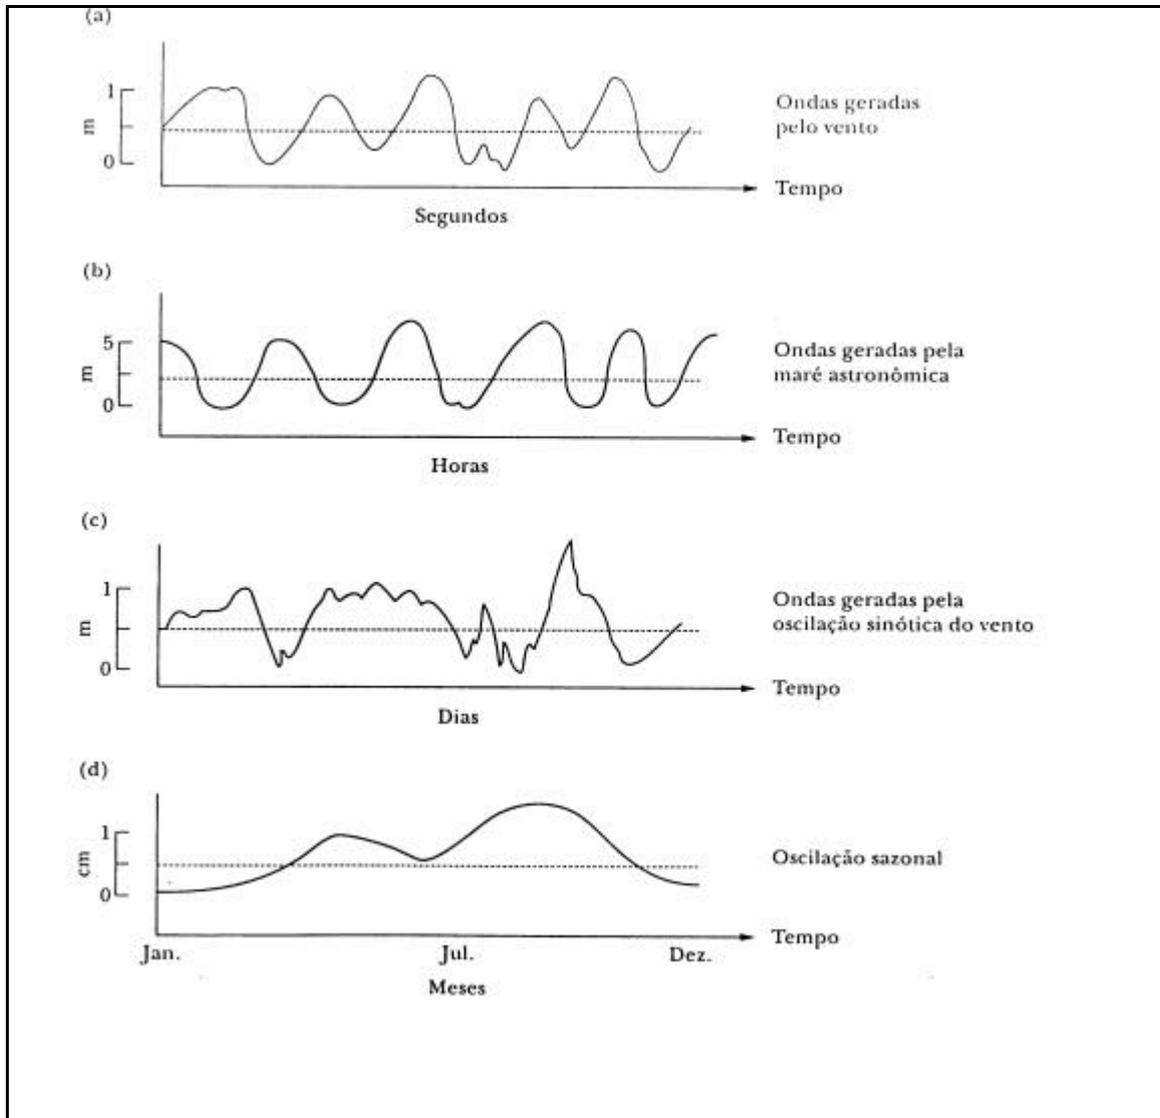


Figura 2.1 Escalas temporal e espacial vertical das variações do nível do mar. Supramaré (a), alta freqüência (b) e baixa freqüência (c, d).

Em baixas freqüências ocorrem, de forma aleatória e com períodos de dias a semanas, ondas de plataforma continental. Essas ondas topográficas são geradas pelas oscilações em escala sinótica da componente do vento paralelo à costa. Na mesma faixa de períodos, o nível do mar pode responder

em fase aos componentes do vento (principalmente paralelos à costa) e às oscilações de pressão atmosférica associadas à tempestades. O mar costeiro responde na forma de um barômetro invertido a essas últimas oscilações, a superfície do mar elevando-se cerca de um centímetro por milibar de decréscimo de pressão atmosférica (Gill, 1982; Miranda, 2002).

Maré Meteorológica

Qualquer seqüência de medições do nível do mar tem uma componente astronômica e uma não astronômica, que permanece após ter sido removida a componente regular através de análise. Essa componente não regular é chamada de *residual*, *residual meteorológico* ou *maré meteorológica* (Pugh, 1987). Fisicamente a atmosfera atua sobre a superfície do mar de duas maneiras distintas. Mudanças na pressão atmosférica produzem mudanças nas forças que agem verticalmente na superfície do oceano e são sentidas imediatamente em todas as profundidades. Além disso, forças devido à tensão do vento são geradas na superfície do mar e paralelas a ela, e a extensão em que elas são sentidas em profundidades abaixo da superfície é determinada pela duração de sua atuação e pela estratificação da densidade da coluna de água, que determina a transferência de momento para baixo. Os efeitos da pressão e do vento nesses fenômenos dificilmente podem ser identificados separadamente (Pugh, 1987).

Os efeitos de tempestades tropicais e extratropicais têm diferentes características e atuação. As primeiras são usualmente pequenas e muito intensas e são geradas no oceano onde se movem de forma relativamente não previsível até encontrar a costa, onde provocam aumento do nível do mar. As tempestades extratropicais se estendem por centenas de quilômetros em torno da região central de baixa pressão atmosférica e geralmente se movem lentamente, afetando grandes áreas costeiras por períodos que podem se estender a vários dias. Os efeitos da pressão e do vento podem ser igualmente importantes, embora para tempestades tropicais a tensão do vento é usualmente dominante (Pugh, 1987).

Muitas possíveis respostas físicas podem ser modeladas pela solução analítica das equações hidrodinâmicas, mas uma descrição mais completa dos complicados efeitos locais é alcançada por técnicas de modelagem numérica.

Marés meteorológicas positivas e negativas podem ser geradas pela mesma tempestade em diferentes estágios de propagação (Pugh, 1987).

Maré Alta é o nível máximo alcançado durante um ciclo. A maré alta pode ser maior ou menor que o nível esperado em função de efeitos meteorológicos. Da mesma forma, *maré baixa* é o nível mínimo alcançado durante um ciclo e também pode ter níveis diferentes dos esperados em função de efeitos meteorológicos. A diferença entre a maré alta e a maré baixa seguinte é chamada de altura, que é duas vezes a *amplitude*.

A representação geral do nível observado do mar que varia no tempo pode ser escrita:

$$\mathbf{X}(t) = \mathbf{S}_0(t) + \mathbf{T}(t) + \mathbf{Z}(t) \quad (2.1)$$

onde $\mathbf{S}_0(t)$ são as lentas mudanças no tempo do nível médio do mar, $\mathbf{T}(t)$ é a parte da maré astronômica e $\mathbf{Z}(t)$ é a componente da maré meteorológica.

Mudanças no nível médio do mar somente são evidentes em longas séries de medições, e essas mudanças são muito pequenas comparadas com as mudanças diárias de nível provocadas pelo movimento das marés. Mudanças de longo termo têm tipicamente um ou dois decímetros por século.

A importância relativa dos movimentos da maré astronômica e da maré meteorológica depende do período do ano e da batimetria do local. Perturbações meteorológicas são maiores no inverno e têm maior efeito em águas rasas. O nível total pode subir para grandes inundações costeiras quando uma tempestade coincide com uma maré de sizígia (Lamb, 1980; Murty, 1984; Wood, 1986; apud Pugh, 1987).

O residual meteorológico pode ser definido re-arranjando a equação 2.1

$$\mathbf{Z}(t) = \mathbf{X}(t) - \mathbf{S}_0(t) - \mathbf{T}(t) \quad (2.2)$$

como a diferença entre os níveis observado e previsto.

Os autores mencionados a seguir registraram a influência das componentes meteorológicas no nível do mar em estudos de caso no Sul-Sudeste do Brasil.

Marone e Camargo (1994) associaram uma forte elevação do nível do mar no litoral paranaense em 1993 à passagem de uma frente fria seguida de um ciclone extratropical deslocando-se perto da costa.

Castro e Lee (1995) associaram flutuações do nível do mar a flutuações de pressão atmosférica e vento nas regiões sul-sudeste do Brasil.

Encontramos poucas publicações de autores que utilizaram a metodologia estatística ARIMA (Autoregressive Integrated Moving Average) para a previsão de variáveis meteorológicas ou oceanográficas. A seguir mencionamos dois artigos relacionados ao assunto.

A metodologia ARIMA (Box e Jenkins, 1970) foi utilizada por Vaziri (1997) para a previsão no nível do Mar Cáspio e considerada eficiente para previsões de curto período.

Broersen (2002) sugere a aplicação com eficiência das ferramentas computacionais automáticas do Matlab, em especial o módulo ARMASA, para estimar modelos ARMA.

CAPÍTULO 3

METODOLOGIA DE ANÁLISE

A metodologia utilizada no presente trabalho é a implementação dos modelos ARIMA para séries temporais desenvolvida por Box e Jenkins (1976), que passamos a descrever neste capítulo.

O objetivo de se estudar uma série temporal é principalmente entender e descrever seu mecanismo gerador e prever valores futuros. A natureza intrínseca de uma série temporal é que suas observações são dependentes ou correlacionadas no tempo, e a ordem das observações é, portanto, importante.

3.1 Processos Estocásticos e Estacionaridade

Um processo estocástico é uma família de variáveis aleatórias indexadas no tempo $Z(\omega, t)$, onde ω pertence ao espaço amostral e t pertence a um conjunto ordenado de índices, que nesta discussão será o conjunto dos números inteiros, e t sendo tempo múltiplo da taxa de amostragem, para um t fixo, $Z(\omega, t)$ é uma variável aleatória. Para um dado ω , $Z(\omega, t)$, como função de t , é chamada função amostral ou realização. Uma série temporal é um subconjunto de uma realização de um determinado processo estocástico. Por simplicidade, escreveremos daqui para frente Z_t ao invés de $Z(\omega, t)$.

Considerando um conjunto finito de variáveis aleatórias $\{Z_{t1}, Z_{t2}, \dots, Z_{tn}\}$ de um processo estocástico $\{Z(\omega, t): t = 0, \pm 1, \pm 2, \dots\}$, a função distribuição n-dimensional é definida por

$$F(z_{t1}, \dots, z_{tn}) = p\{\omega: z(\omega, t_1) \leq z_{t1}, \dots, z(\omega, t_n) \leq z_{tn}\}. \quad (3.1.1)$$

Um processo é estacionário de primeira ordem se sua função distribuição unidimensional não varia no tempo, ou seja, se $F(z_t) = F(z_{t_1+k})$ para qualquer inteiros t_1, k e $t_1 + k$; estacionário de segunda ordem se $F(z_{t1}, z_{t2}) = F(z_{t1+k}, z_{t2+k})$ para quaisquer inteiros $t_1, t_2, k, t_1 + k$ e $t_2 + k$; e estacionário de enésima ordem se

$$F(z_{t1}, \dots, z_{tn}) = F(z_{t1+k}, \dots, z_{tn+k}) \quad (3.1.2)$$

para qualquer n-upla (t_1, \dots, t_n) e k inteiros.

Um processo é definido como *estritamente estacionário*, ou *fortemente estacionário*, se (3.2) é verdadeira para qualquer n . Se (3.2) é verdadeira para todo $n = m$, é também verdadeira para todo $n < m$, pois a função distribuição de emésima ordem determina todas as funções distribuição de ordens mais baixas. Portanto, uma estacionaridade de ordem elevada implica em uma estacionaridade de baixa ordem.

Além disso, algumas outras definições importantes para um dado processo $\{Z(t): t = 0, \pm 1, \pm 2, \dots\}$. A função média do processo definida por

$$\mu_t = E(Z_t), \quad (3.1.3)$$

a função variância definida por

$$s_t^2 = E(Z_t - \mu_t)^2, \quad (3.1.4)$$

a função covariância entre Z_{t_1} e Z_{t_2}

$$\gamma(t_1, t_2) = E(Z_{t_1} - \mu_{t_1})(Z_{t_2} - \mu_{t_2}), \quad (3.1.5)$$

e a função correlação entre Z_{t_1} e Z_{t_2}

$$r(t_1, t_2) = \frac{g(t_1, t_2)}{\sqrt{s_{t_1}^2} \sqrt{s_{t_2}^2}}. \quad (3.1.6)$$

Para um processo *estritamente estacionário*, desde que sua função distribuição é a mesma para todo t , a função média $\mu_t = \mu$ é constante, desde que $E(|Z_t|) < \infty$. Do mesmo modo, se $E(Z_t^2) < \infty$, então $s_t^2 = s^2$ para todo t , e, portanto, também constante. Além disso, desde que $F(z_1, z_2) = F(z_{1+k}, z_{2+k})$ para quaisquer t_1, t_2 e k , temos

$$\gamma(t_1, t_2) = \gamma(t_1 + k, t_2 + k)$$

e

$$\rho(t_1, t_2) = \rho(t_1 + k, t_2 + k).$$

Tomando $t_1 = t - k$ e $t_2 = t$ obtemos

$$\gamma(t_1, t_2) = \gamma(t - k, t) = \gamma(t_1, t_2) = \gamma(t, t + k) = \gamma_k \quad (3.1.7)$$

e

$$\rho(t_1, t_2) = \rho(t - k, t) = \rho(t_1, t_2) = \rho(t, t + k) = \rho_k. \quad (3.1.8)$$

Portanto, para um processo *estritamente estacionário* com os dois primeiros momentos finitos, a covariância e a correlação entre Z_t e Z_{t+k} depende somente da diferença no tempo k .

Um processo é definido como *fracamente estacionário* se todos seus momentos conjuntos superiores de ordem n existem e não variam no tempo, ou seja, são independentes da origem no tempo. Conseqüentemente, um processo fracamente estacionário de segunda ordem terá média e variância constantes, com covariância e correlação sendo funções somente da diferença no tempo. Segue das definições que um processo *estritamente estacionário* com os dois primeiros momentos finitos é também um processo *fracamente estacionário* de segunda ordem. Usaremos neste trabalho o termo *estacionário* para referir-nos a todo processo estacionário de segunda ordem.

Um processo estocástico é dito ser um processo Normal ou Gaussiano se sua distribuição conjunta de probabilidade é normal. Como uma distribuição Normal é caracterizada unicamente pelos dois primeiros momentos, *estacionaridade estrita* ou *estacionaridade fraca* são equivalentes para um processo Gaussiano. Assumiremos os processos estudados neste trabalho como Gaussianos.

3.2 Funções Autocovariância, Autocorrelação e Autocorrelação Parcial

Num processo estacionário Z_t temos a média e a variância – que são constantes – e a covariância como funções somente da diferença do tempo $|t - s|$. Então, neste caso, podemos escrever a covariância entre Z_t e Z_{t+k} como

$$\gamma_k = \text{Cov}(Z_t, Z_{t+k}) = E(Z_t - \mu)(Z_{t+k} - \mu), \quad (3.2.1)$$

e a correlação entre Z_t e Z_{t+k} como

$$\mathbf{r}_k = \frac{\text{Cov}(Z_t, Z_{t+k})}{\sqrt{\text{Var}(Z_t)}\sqrt{\text{Var}(Z_{t+k})}} = \frac{\mathbf{g}_k}{\mathbf{g}_0}. \quad (3.2.2)$$

Como função de k , γ_k é chamada de função autocovariância e ρ_k é chamada de função autocorrelação (ACF) em análise de séries temporais, uma vez que elas representam a covariância e a correlação entre Z_t e Z_{t+k} para o mesmo processo, separado apenas por k intervalos de tempo.

Para um processo estacionário a função autocovariância $\tilde{\alpha}_k$ e a função autocorrelação $\tilde{\rho}_k$ têm as seguintes propriedades:

1. $\tilde{\alpha}_0 = \text{Var}(Z_t)$; $\tilde{\rho}_0 = 1$.
2. $|\tilde{\alpha}_k| \leq \tilde{\alpha}_0$; $|\tilde{\rho}_k| \leq 1$.
3. $\tilde{\alpha}_{-k} = \tilde{\alpha}_k$ e $\tilde{\rho}_{-k} = \tilde{\rho}_k$ para todo k , ou seja, $\tilde{\alpha}_k$ e $\tilde{\rho}_k$ são funções pares e, portanto, simétricas em torno da origem no tempo, $k = 0$. Isso resulta do fato que a diferença temporal entre Z_t e Z_{t+k} e Z_{t-k} é a mesma. O gráfico da função autocorrelação é construído somente para os valores positivos e é chamado de correlograma.

Como complemento para a autocorrelação entre Z_t e Z_{t+k} , pode ser necessário investigar a correlação entre Z_t e Z_{t+k} depois que a dependência linear mútua entre as variáveis $Z_{t+1}, Z_{t+2}, \dots, Z_{t+k-1}$ tenha sido removida. A função

$$\mathbf{f}_{kk} = \frac{\text{Cov}[(Z_t - \hat{Z}_t), (Z_{t+k} - \hat{Z}_{t+k})]}{\sqrt{\text{Var}(Z_t - \hat{Z}_t)}\sqrt{\text{Var}(Z_{t+k} - \hat{Z}_{t+k})}}, \quad (3.2.3)$$

onde \hat{Z}_t e \hat{Z}_{t+k} são, respectivamente, a melhor estimativa linear de Z_t e Z_{t+k} , é chamada de função autocorrelação parcial (PACF) de Z_t .

3.3 Ruído Branco

Um processo $\{a_t\}$ é chamado de ruído branco se uma seqüência de variáveis aleatórias não correlacionadas de uma determinada distribuição com média constante $E(a_t) = \mu_a$ usualmente zero, variância constante e $\text{Var}(a_t) = \mathbf{s}_a^2$ e $\mathbf{g}_k = \text{Cov}(a_t, a_{t+k}) = 0$ para todo $k \neq 0$. Por definição, segue imediatamente que um processo de ruído branco é estacionário com função autocovariância

$$\mathbf{g}_k = \begin{cases} \mathbf{s}_a^2 & k = 0 \\ 0 & k \neq 0, \end{cases} \quad (3.3.1)$$

função autocorrelação

$$\mathbf{r}_k = \begin{cases} 1 & k = 0 \\ 0 & k \neq 0, \end{cases} \quad (3.3.2)$$

e função autocorrelação parcial

$$\mathbf{f}_{kk} = \begin{cases} 1 & k = 0 \\ 0 & k \neq 0, \end{cases} \quad (3.3.3)$$

e o fenômeno básico do ruído branco é que suas ACF e PACF são identicamente iguais a zero.

Um processo de ruído branco é Gaussiano se sua distribuição conjunta de probabilidade é normal. Neste trabalho nos referiremos sempre a um processo de ruído branco Gaussiano média zero.

3.4 Estimação

Uma série temporal estacionária e Gaussiana é completamente caracterizada por suas funções média (μ), variância (σ^2), autocorrelação (ρ_k) e autocorrelação parcial (ϕ_{kk}). Os valores exatos desses parâmetros podem ser calculados se o conjunto de todas as possíveis realizações (população) for conhecido. Caso contrário, podem ser estimados se múltiplas realizações independentes são avaliadas. Entretanto, na maior parte das vezes apenas uma realização é conhecida, o que torna impossível calcular a média populacional. Porém, se o processo for ergódico, uma alternativa natural é substituir a média populacional pela média temporal.

Então, com somente uma realização, um estimador natural para a média $\mu = E(Z_t)$ de um processo estacionário é a média temporal de n observações

$$\bar{Z} = \frac{1}{n} \sum_{t=1}^n Z_t. \quad (3.4.1)$$

Da mesma forma, com apenas uma realização, os estimadores da função autocovariância γ_k , utilizando a média temporal, são

$$\hat{\mathbf{g}} = \frac{1}{n} \sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z}), \quad (3.4.2)$$

ou

$$\hat{\mathbf{g}} = \frac{1}{n-k} \sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z}). \quad (3.4.3)$$

o estimador da função autocorrelação amostral é

$$\hat{\mathbf{r}}_k = \frac{\hat{\mathbf{g}}_k}{\hat{\mathbf{g}}_0} = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2}, \quad (3.4.4)$$

e da função autocorrelação parcial

$$\hat{\mathbf{f}}_{k+1,k+1} = \frac{\hat{\mathbf{r}}_{k+1} - \sum_{j=1}^k \hat{\mathbf{f}}_{kj} \hat{\mathbf{r}}_{k+1-j}}{1 - \sum_{j=1}^k \hat{\mathbf{f}}_{kj} \hat{\mathbf{r}}_j}. \quad (3.4.5)$$

3.5 Processos Autorregressivo e Média Móvel

Discutiremos duas maneiras usuais de expressar um processo de séries temporais. A primeira é uma representação autorregressiva (AR), na qual regredimos o valor de Z no tempo t em seus próprios valores passados mais uma componente aleatória, fazendo

$$\dot{Z}_t = \mathbf{p}_1 \dot{Z}_{t-1} + \mathbf{p}_2 \dot{Z}_{t-2} + \dots + a_t \quad (3.5.1)$$

ou, de forma compacta

$$\mathbf{p}(B) \dot{Z}_t = a_t \quad (3.5.2)$$

onde $\mathbf{p}(B) = 1 - \sum_{j=1}^{\infty} \mathbf{p}_j B^j$, e $1 + \sum_{j=1}^{\infty} |\mathbf{p}_j| < \infty$. Um processo é inversível se pode ser descrito desta forma.

Para um processo linear $Z_t = \psi(B)a_t$ ser inversível de modo a poder ser escrito em termos da representação AR, as raízes de $\psi(B) = 0$ como função de

B devem estar fora do círculo unitário. Para um processo $\mathbf{p}(B)\dot{Z}_t = a_t$ ser estacionário, deve ser possível reescrevê-lo como uma representação MA, ou seja,

$$Z_t = \frac{1}{\mathbf{p}(B)} a_t = \mathbf{y}(B)a_t, \quad (3.5.3)$$

tal que a condição $\sum_{j=0}^{\infty} \mathbf{y}_j^2 < \infty$ seja satisfeita. Para isso, a condição necessária é que as raízes de $\pi(B) = 0$ encontrem-se todas fora do círculo unitário.

A segunda forma de representar um processo que utilizaremos é escrever Z_t como uma combinação linear de uma seqüência de variáveis aleatórias não correlacionadas,

$$Z_t = \mathbf{m} a_t + \mathbf{y}_1 a_{t-1} + \mathbf{y}_2 a_{t-2} + \dots = \mathbf{m} + \sum_{j=0}^{\infty} \mathbf{y}_j a_{t-j}, \quad (3.5.4)$$

onde $\psi_0 = 1$, $\{a_t\}$ é um processo ruído branco com média zero e $\sum_{j=0}^{\infty} \mathbf{y}_j^2 < \infty$.

Utilizando um operador de retrocesso $B^j x_t = x_{t-j}$, podemos escrever de forma compacta:

$$\dot{Z}_t = \mathbf{y}(B)a_t, \quad (3.5.5)$$

onde $\dot{Z}_t = Z_t - \mathbf{m}$ e $\mathbf{y}(B) = \sum_{j=0}^{\infty} \mathbf{y}_j B^j$. A condição requerida para o processo ser estacionário é $\sum_{j=0}^{\infty} \mathbf{y}_j^2 < \infty$, ou seja, que seja infinito limitado.

A forma acima é chamada uma representação média móvel (MA) de um processo, ou representação de Wold.

As representações AR e MA dispostas acima possuem um infinito número de parâmetros impossíveis de serem estimados de um número finito de observações. Para modelar um fenômeno, construímos modelos com número finito de parâmetros.

Em uma representação AR de um processo, se somente um número finito de parâmetros são não nulos e $\pi_p = 0$ para $k > p$, o processo resultante é chamado de autorregressivo de ordem p , AR(p), e escrito como

$$\dot{Z}_t - \mathbf{f}_1 \dot{Z}_{t-1} - \dots - \mathbf{f}_p \dot{Z}_{t-p} = a_t, \quad (3.5.6)$$

ou

$$(1 - \mathbf{f}_1 B - \mathbf{f}_2 B^2 - \dots - \mathbf{f}_p B^p) \dot{Z}_t = a_t \quad (3.5.7)$$

A ACF de um processo AR(p) estacionário decresce como uma mistura de decaimento exponencial e/ou senóides amortecidas dependendo das raízes de $\phi_p(B) = 0$. Senóides amortecidas aparecem se algumas raízes forem complexas. A PACF desaparece depois de p passos temporais. Essas propriedades são úteis para a identificação do modelo.

Do mesmo modo, numa representação MA, se somente um número finito de pesos ψ são não nulos e $\psi_k = 0$ para $k > q$, o processo resultante é chamado de média móvel de ordem q , MA(q), dado por

$$\dot{Z}_t = a_t - \mathbf{q}_1 a_{t-1} - \dots - \mathbf{q}_q a_{t-q}, \quad (3.5.8)$$

ou

$$\dot{Z}_t = (1 - \mathbf{q}_1 B - \mathbf{q}_2 B^2 - \dots - \mathbf{q}_q B^q) a_t. \quad (3.5.9)$$

A ACF de um processo MA(q) é cortada depois de q passos temporais, e a PACF decresce como uma mistura de decaimento exponencial e/ou senóides amortecidas dependendo das raízes de $\theta_q(B) = 0$. A função autocorrelação parcial mostrará senóides amortecidas se algumas de suas raízes forem complexas.

O modelo misto autorregressivo média móvel ARMA(p,q) de um processo estacionário e inversível pode ser escrito como:

$$\dot{Z}_t - \mathbf{f}_1 \dot{Z}_{t-1} - \dots - \mathbf{f}_p \dot{Z}_{t-p} = a_t - \mathbf{q}_1 a_{t-1} - \dots - \mathbf{q}_q a_{t-q}. \quad (3.5.10)$$

ou, de forma compacta

$$\mathbf{f}_p(B) \dot{Z}_t = \mathbf{q}_q(B) a_t, \quad (3.5.11)$$

onde,

$$\mathbf{f}_p(B) = 1 - \mathbf{f}_1 B - \dots - \mathbf{f}_p B^p,$$

e

$$\mathbf{q}_q(B) = 1 - \mathbf{q}_1 B - \dots - \mathbf{q}_q B^q.$$

Escrevendo em forma fracionária, temos:

$$\dot{Z}_t = \frac{\mathbf{q}_q(B)}{\mathbf{f}_p(B)} a_t. \quad (3.5.12)$$

Um processo ARMA estacionário e inversível pode ser escrito como uma representação autorregressiva pura, ou seja,

$$\mathbf{p}(B)\dot{Z}_t = a_t, \quad (3.5.13)$$

onde

$$\mathbf{p}(B) = \frac{\mathbf{f}(B)}{\mathbf{q}(B)} = (1 - \mathbf{p}_1 B - \mathbf{p}_2 B^2 - \dots) \quad (3.5.14)$$

A ACF de um modelo ARMA(p, q) decrescerá depois de q passos temporais exatamente como no processo AR(p). Porém as primeiras q autocorrelações dependem de ambos os parâmetros, autorregressivos e médias móveis. A PACF será uma mistura de decaimento exponencial e senóides amortecidas dependendo das raízes de $\phi(B) = 0$ e de $\theta(B) = 0$.

3.6 Modelos para séries temporais não estacionárias

As séries temporais podem ser não estacionárias na média ou na variância. Um processo estacionário na média não é necessariamente estacionário na variância e na autocovariância. Quando a série não é estacionária na variância, o problema nem sempre pode ser resolvido por diferenciação. Utiliza-se então a transformação de potência, desenvolvida por Box e Cox (1964), para estabilizar a variância:

$$T(Z_t) = Z_t^{(\lambda)} = \frac{Z_t^\lambda - 1}{\lambda}. \quad (3.6.1)$$

λ é chamado de parâmetro de transformação, e alguns dos valores mais comuns que pode assumir e as transformações a eles associadas são:

VALORES DE I	TRANSFORMAÇÃO
- 1,0	$\frac{1}{Z}$
- 0,5	$\frac{1}{\sqrt{Z_t}}$
0,0	$\ln Z_t$
0,5	$\sqrt{Z_t}$
1,0	Z_t (sem transformação)

A transformação deve ser realizada antes de qualquer outra operação como a diferenciação.

Diferenciação pode ser utilizada em modelos estocásticos com tendência na média para tornar a série temporal estacionária, quando diferentes partes dessa série se comportam de forma similar, exceto por diferenças em níveis médios locais. Este tipo de não estacionaridade é chamado de não estacionaridade homogênea. Em termos dos modelos ARMA, o processo é não estacionário se algumas raízes do polinômio AR estão dentro do círculo unitário. Entretanto, pela natureza da homogeneidade, o comportamento local desse tipo de séries é independente do nível.

Então, considerando $\Psi(B)$ um operador autorregressivo que pode representar a série localmente, temos

$$\Psi(B)(Z_t + C) = \Psi(B)Z_t \quad (3.6.2)$$

que deve valer para qualquer constante C. Isso implica que $\Psi(B)$ pode ser escrito na forma

$$\Psi(B) = \phi(B)(1-B)^d, \quad (3.6.3)$$

para $d > 0$, onde $\phi(B)$ é um operador autorregressivo estacionário. Então se a série $\{Z_t\}$ não é estacionária, a série resultante de sua d'ésima diferenciação $\{(1 - B)^d Z_t\}$ é estacionária para algum inteiro $d \geq 1$. Se após a d'ésima diferenciação a série se reduz a ruído branco, teremos

$$(1 - B)^d Z_t = a_t \quad (3.6.4)$$

ou

$$Z_t = Z_{t-1} + a_t. \quad (3.6.5)$$

Um processo estacionário resultante de uma adequada diferenciação pode já ser ruído branco ou, mais geralmente, segue o processo geral ARMA(p,q) e pode ser escrito como

$$\mathbf{f}_p(B)(1-B)^d Z_t = \mathbf{q}_0 + \mathbf{q}_q(B)a_t. \quad (3.6.6)$$

Quando $d = 0$ o processo original é estacionário e o parâmetro \mathbf{q}_0 é relacionado com a média do processo, ou seja, $\mathbf{q}_0 = \mathbf{m}(1 - \mathbf{f}_1 - \dots - \mathbf{f}_p)$. Quando $d \geq 1$, \mathbf{q}_0 é chamado de termo de tendência determinística e é freqüentemente omitido do modelo.

O modelo resultante de não estacionaridade homogênea é chamado de modelo Média Móvel Integrado Autorregressivo de ordem (p,d,q) e denotado por modelo ARIMA(p,d,q).

Séries temporais que contém fenômenos sazonais também podem ser modeladas por modelos ARIMA sazonais multiplicativos

$$\Phi_p(B^S)\mathbf{f}_p(B)(1-B)^d(1-B^S)^D\dot{Z}_t = \mathbf{q}_q(B)\Theta_q(B^S)a_t \quad (3.6.7)$$

onde

$$\dot{Z}_t = \begin{cases} Z_t - \mathbf{m} & \text{se } d = D = 0 \\ Z_t, & \text{demais casos} \end{cases}$$

e dizemos que $\phi_p(B)$ e $\theta_q(B)$ são os fatores (ou polinômios) autorregressivos e médias móveis regulares, e $\Phi_p(B^S)$ e $\Theta_q(B^S)$ são os fatores (ou polinômios) autorregressivos e médias móveis sazonais.

3.7 Identificação do Modelo

A identificação do modelo deve seguir os seguintes passos (Wei, 1990):

1. Fazer o gráfico da série e verificar a existência de tendência, sazonalidade, dados discrepantes, variância não constante ou outros fenômenos não normais ou não estacionários e escolher as transformações adequadas para estabilizar a série. A transformação da variância deve ser efetuada antes de qualquer outra.
2. Computar e examinar a ACF e a PACF amostrais da série original para confirmar os graus de diferenciação necessários. Se a ACF decai lentamente e a PACF é cortada depois de 1 passo temporal, isso indica que a diferenciação é necessária. Deve-se então tentar diferenciação de ordem 1 ou maior. Em casos limites, recomenda-se a diferenciação.
3. Computar e examinar a ACF e PACF amostrais da série transformada e/ou diferenciada para identificar a ordem de p e q .

CAPÍTULO 4

ANÁLISE DAS SÉRIES

Como relatado em 3.7, a fase preliminar de análise das séries temporais envolve a inspeção visual de seus gráficos temporais para ajudar na identificação de possíveis tendências na média, não estacionaridade da variância ou sazonalidade, com o intuito de verificar a necessidade de diferenciação ou transformações, ou ainda denunciar a existência de picos discrepantes nas séries.

Uma vez que o objetivo deste trabalho é a análise das componentes de baixa frequência, decidiu-se por uma reamostragem das séries a cada seis horas, retirando assim as variações de curto período. A Figura 4.1 mostra o gráfico das séries.

Na figura 4.1 podem ser notadas tendências na média mais ou menos significativas para todas as variáveis consideradas, e relacionadas à variações anuais das forçantes meteorológicas.

Essas tendências podem ser evidenciadas considerando-se os valores promediados no tempo. Na figura 4.2 os valores são semanais e em todos os gráficos é evidente uma tendência linear crescente na temperatura do ar e decrescente nas demais séries.

As figuras 4.1 e 4.2 não evidenciam ciclicidades nos dados, mas é imediato identificar um período anormal no nível do mar logo no começo do registro. Esse período anormal implicaria na construção de um modelo mais complexo, com um número maior de parâmetros para explicar essa anormalidade. Em vista disso, se preferiu perder alguns dados eliminando esse pico inicial e ganhando com isso a possibilidade de construir um modelo que se adapte melhor à maioria dos dados.

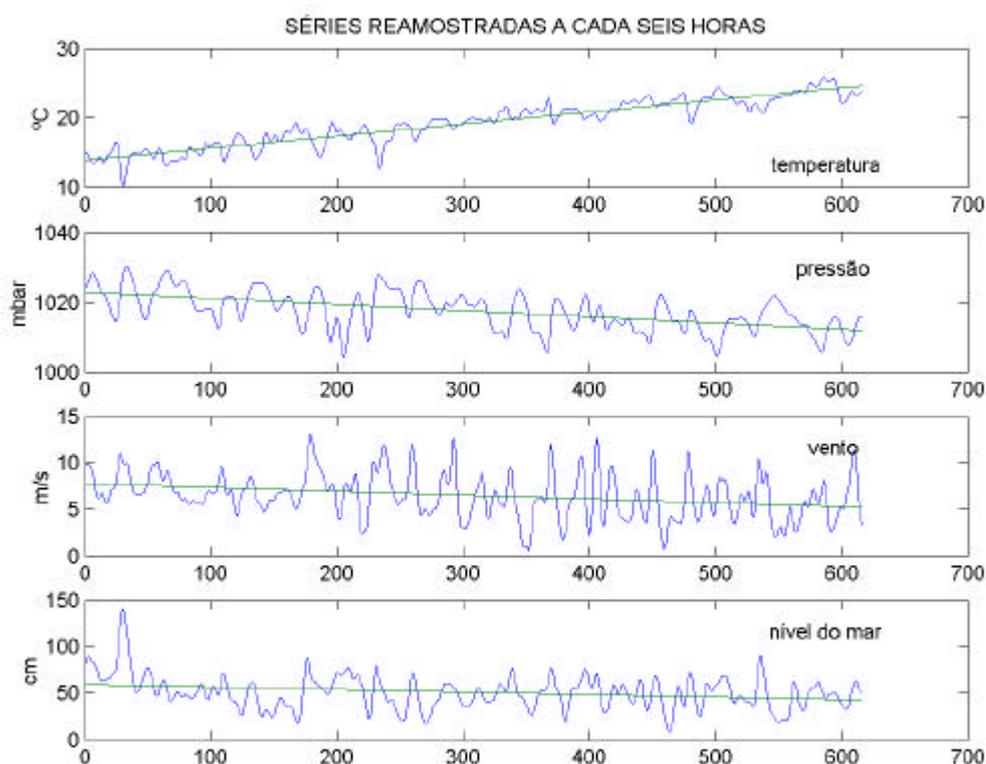


Figura 4.1 Séries reamostradas a cada seis horas da temperatura do ar, pressão atmosférica, vento meridional e nível do mar de São Francisco do Sul-SC, do período de 14 de julho a 15 de dezembro de 1996

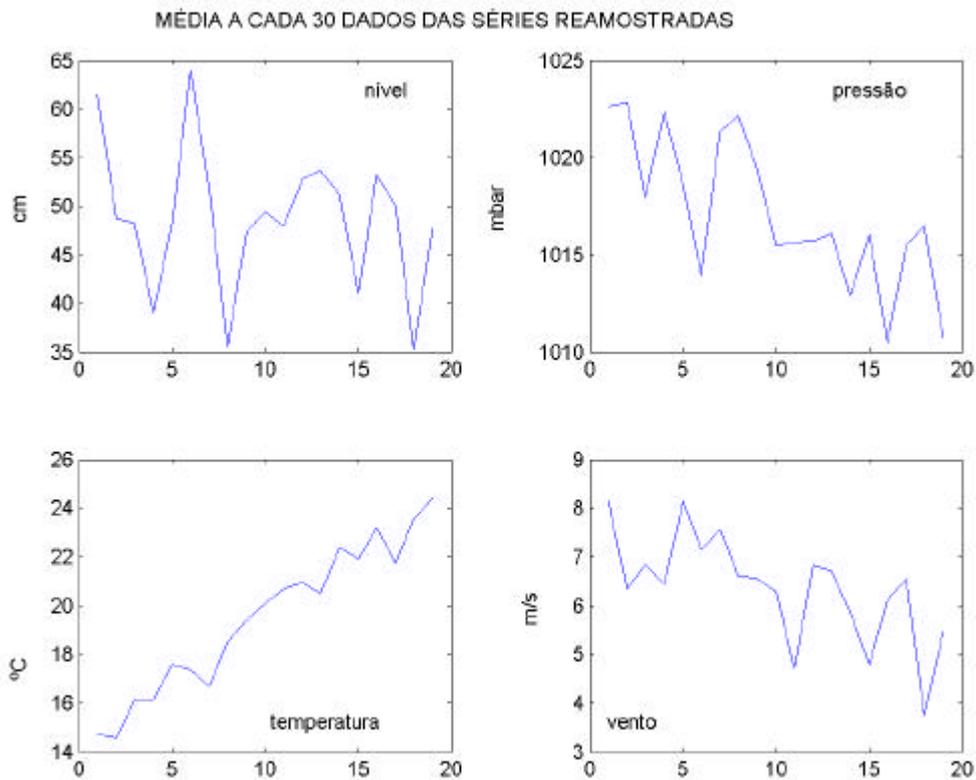


Figura 4.2 Médias calculadas a cada 30 dados das séries reamostradas a cada 6 horas das variáveis nível do mar, pressão atmosférica, temperatura do ar e vento meridional.

A estacionaridade da variância foi avaliada aplicando-se às séries a transformação de Box e Cox (1964) para diferentes valores de λ . A transformação que garanta a máxima log-verossimilhança sob a hipótese de gaussianidade dos dados indica o valor adequado para λ . A transformação é realmente necessária quando existe um aumento significativo da log-probabilidade com relação à série original, ou seja, quando o máximo é bem definido.

A análise dos gráficos da Figura 4.3 aponta um λ ótimo em todos os casos, não comportando em nenhuma das séries uma melhoria significativa.

Existe uma quase estacionariedade na variância em todas as séries temporais, que não precisam, portanto, ser transformadas.

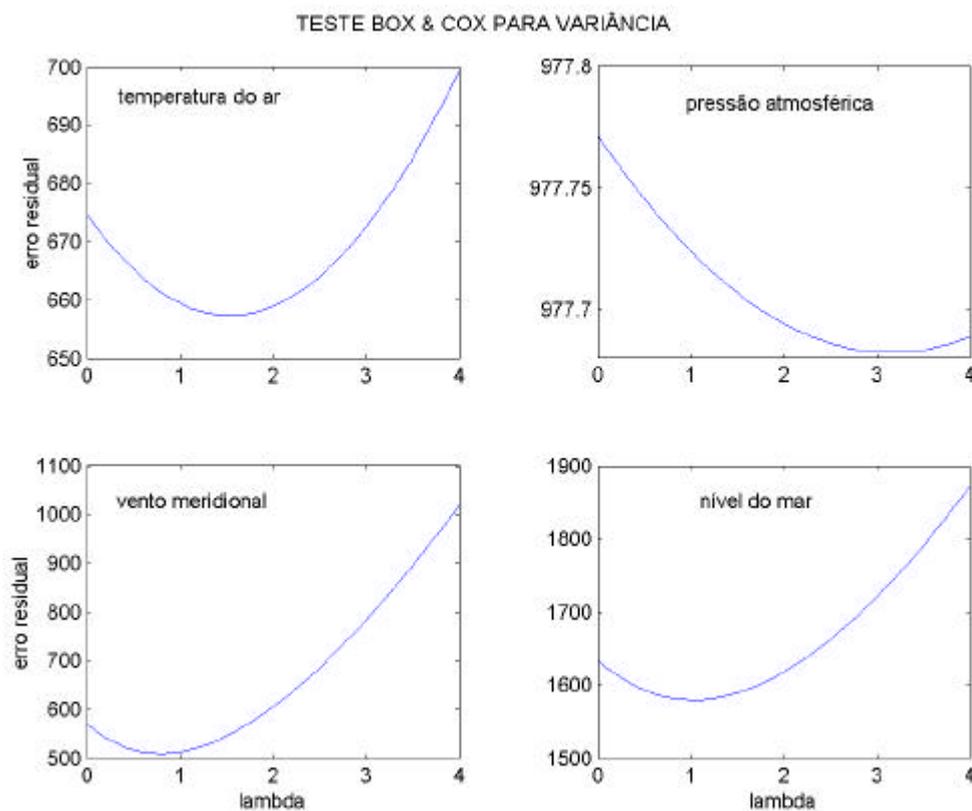


Figura 4.3 Teste de Box e Cox para verificar a estacionariedade da variância das séries temperatura do ar, pressão atmosférica, vento meridional e nível do mar.

A existência de tendência nos dados da variável temperatura do ar (Fig. 4.4) implica em valores da ACF muito elevados por vários passos temporais sucessivos, decaindo muito lentamente. Como vimos no capítulo 3, podemos retirar essa tendência fazendo uma diferenciação.

Com relação ao correlograma da série da pressão atmosférica (Figura 4.4) pode-se perceber um decaimento lento da acf, ao mesmo tempo

em que todos os valores são positivos, não deixando dúvidas quanto a necessidade de diferenciação neste caso.

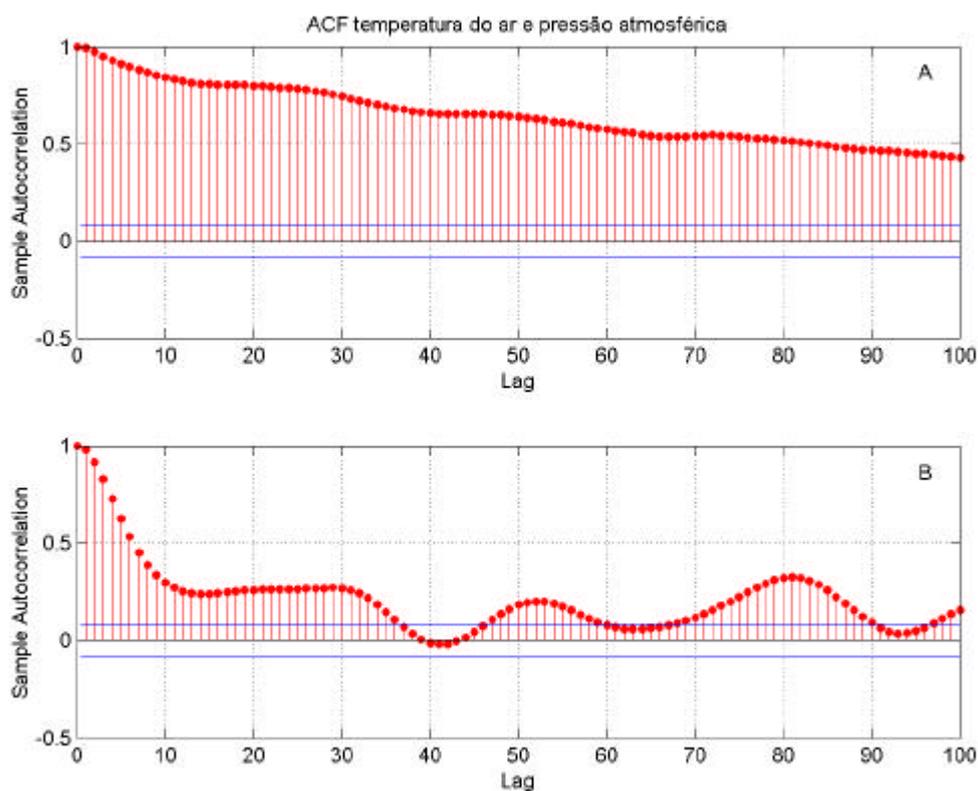


Figura 4.4 Correlograma da função autocorrelação das séries (A) temperatura do ar e (B) pressão atmosférica.

A decisão quanto a diferenciar ou não a série da variável vento meridional não é tão simples. O decaimento da acf não é muito significativo (Figura 4.5), mas o gráfico das médias semanais da série demonstrava

tendência para baixo (Figura 4.2) Por isso a série será diferenciada, mas também serão feitos testes com modelos sem diferenças.

A análise do correlograma da função autocorrelação da série nível do mar (Figura 4.5) indica que o decaimento da ACF não é muito acentuado e deixa dúvida quanto à necessidade de diferenciação. Em situações duvidosas é aconselhável a diferenciação, pois os danos para o modelo são menores quando se diferencia uma série sem necessidade do que quando não se diferencia quando necessário (Wei, 1989). Também neste caso serão avaliados modelos com a série diferenciada e sem diferenciação.

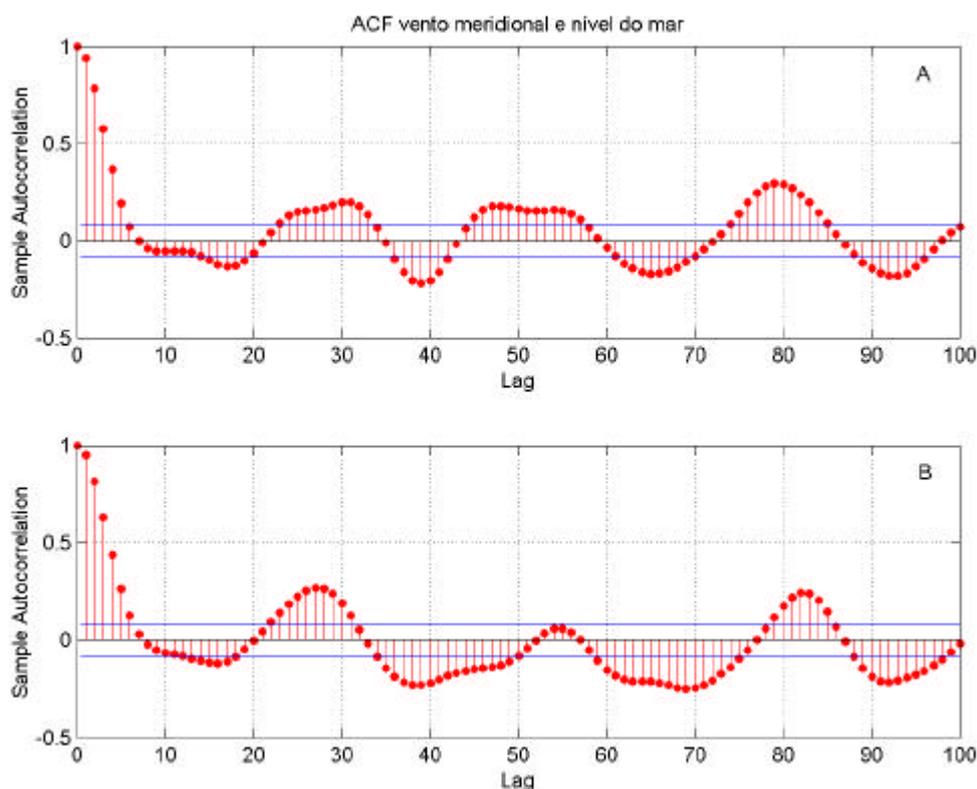


Figura 4.5 Correlograma da função autocorrelação das séries (A) vento meridional e (B) nível do mar.

Seguindo ainda os passos para análise sugeridos por Wei (1994), após terem sido diferenciadas todas as séries para promover a estacionarização da média, foram computadas as funções de autocorrelação (ACF) e autocorrelação parcial (PACF) das séries diferenciadas com o intuito de diagnosticar sazonalidade e determinar modelos ARIMA gerais que permitam a compreensão de suas componentes geradoras. A análise das ACF da série da temperatura do ar (Fig. 4.6) mostra que seus extremos locais positivos não acontecem com nenhuma periodicidade aparente, o mesmo acontecendo com a PACF. Essa análise preliminar parece indicar que não existe nenhum efeito significativo de sazonalidade nestas funções.

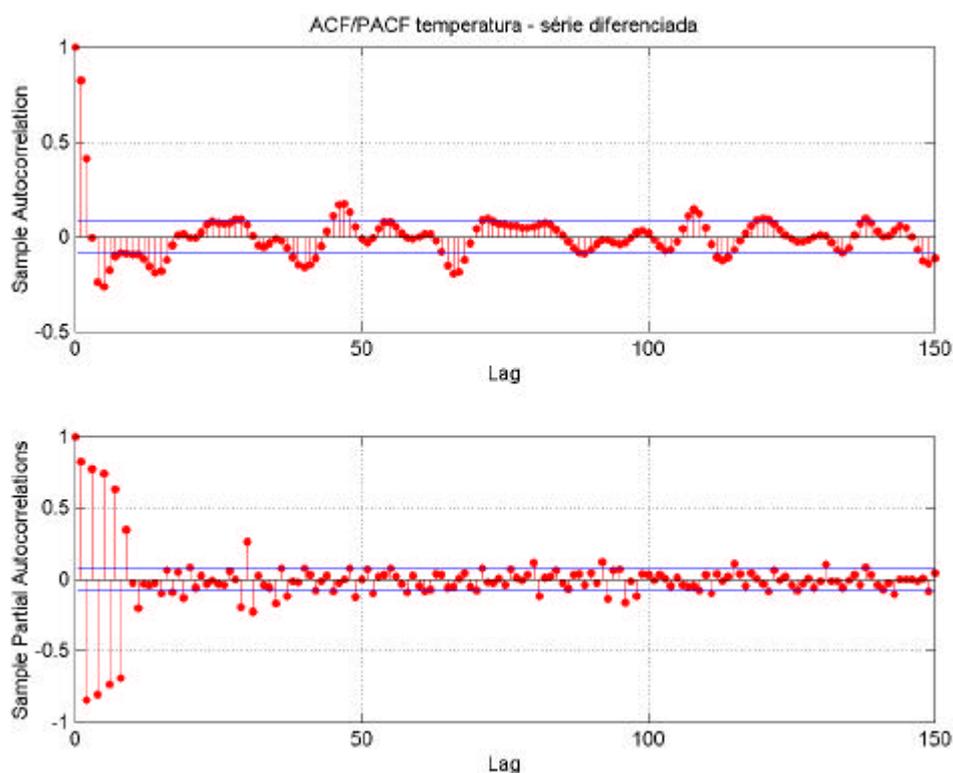


Figura 4.6 Funções autocorrelação e autocorrelação parcial da série temporal relativa à temperatura do ar local em São Francisco do Sul-SC, 1996.

A mesma verificação foi feita para as ACF e PACF da série da pressão atmosférica (Fig. 4.7), e seu gráfico não mostra sazonalidade significativa, ou seja, os máximos e mínimos locais das funções não acontecem com periodicidade aparente.

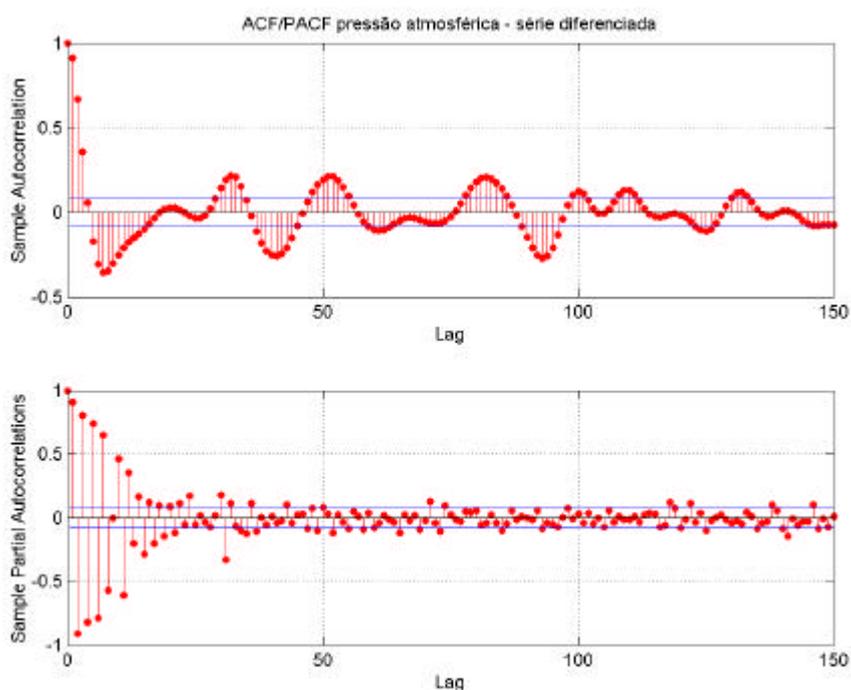


Figura 4.7 Funções autocorrelação e autocorrelação parcial da série temporal relativa à pressão atmosférica em São Francisco do Sul-SC, 1996.

Análise semelhante feita para as ACF e PACF das séries do vento meridional (Fig. 4.8) e do nível do mar (Fig. 4.9) apontou os mesmos resultados das anteriores, ou seja, não existência de sazonalidade aparente nas séries.

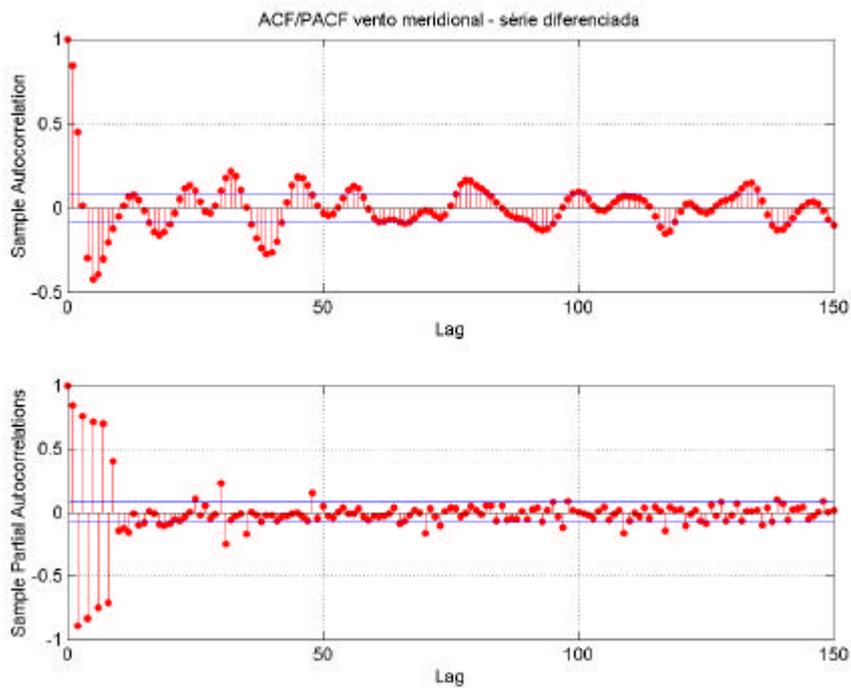


Figura 4.8 Funções autocorrelação e autocorrelação parcial da série temporal relativa ao vento meridional em São Francisco do Sul-SC, 1996.

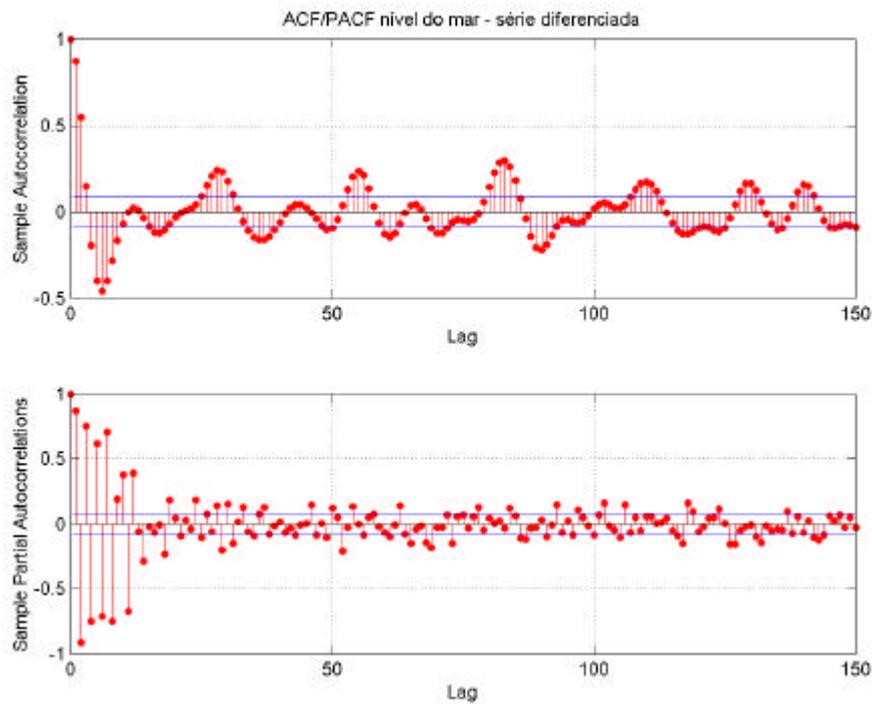


Figura 4.9 Funções autocorrelação e autocorrelação parcial da série temporal relativa ao nível do mar local em São Francisco do Sul-SC, 1996.

4.1 Os Primeiros Modelos

A busca dos primeiros modelos foi efetuada utilizando um pacote estatístico, o Statistica. Após inúmeras tentativas chegou-se a alguns modelos relativamente "enxutos", que explicam razoavelmente bem a variância das séries reduzindo satisfatoriamente a soma de quadrados. Vamos então para a análise para cada uma das séries.

Temperatura do ar

O correlograma da ACF e da PACF da série da temperatura do ar (Fig. 4.1.1) apontam para um modelo ARIMA de ordem baixa ou um AR de ordem 4 ou maior. Algumas tentativas foram executadas com base nesta indicação buscando associar parcimônia na quantidade de parâmetros com variância explicada. Os resultados estão na Tabela 4.1.1.

Tabela 4.1.1 Modelos desenvolvidos à partir dos dados reamostrados a cada 6 horas da série da temperatura do ar.

MODELO	SOMA DE QUADRADOS INICIAL	SOMA DE QUADRADOS FINAL	PORCENTAGEM DA VARIÂNCIA EXPLICADA
ARIMA (1,1,0)	60,169	19,204	68,08%
ARIMA (0,1,1)	60,169	17,303	71,24%
ARIMA (1,1,1)	60,169	6,4336	89,31%
ARIMA (1,1,1) (1,0,0) ₅	60,169	5,9156	90,17%
ARIMA (1,1,1) (0,0,1) ₅	60,169	5,7808	90,4%

Observando a Tabela 4.1.1 vemos que o modelo que explica melhor a variância com um mínimo de parâmetros é o ARMA (1,1,1), pouca diferença havendo entre este e os dois últimos em termos de variância explicada.

Ao analisarmos os gráficos da ACF e da PACF (Figura 4.1.2) notamos que a correlação entre os valores do resíduo do modelo ARIMA(1,1,1) aplicado a série da temperatura do ar apresenta valores significativos.

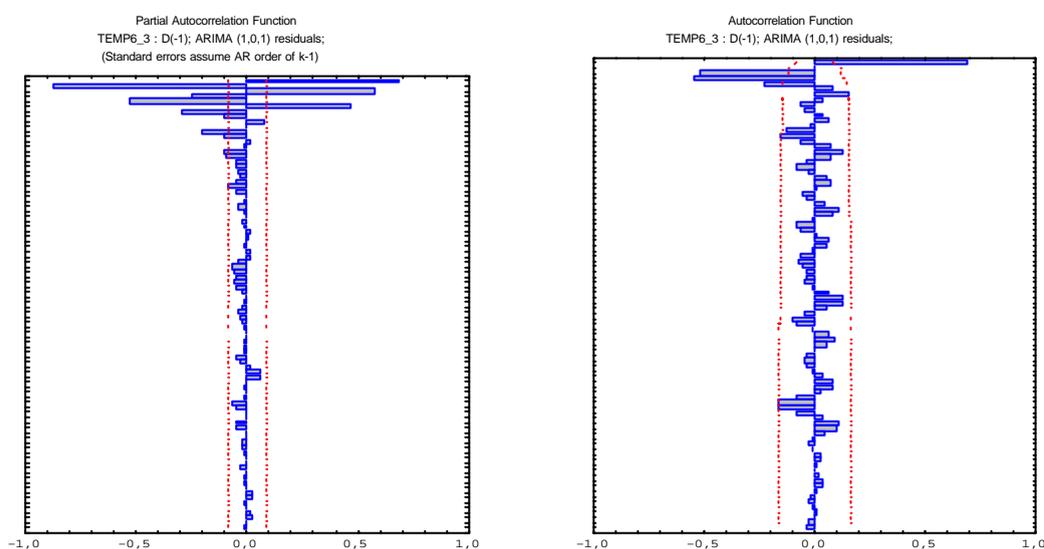


Figura 4.1.1 Gráfico das funções de autocorrelação (ACF) e autocorrelação parcial (PACF) do resíduo do modelo ARIMA (1,1,1) aplicado sobre a série da temperatura do ar.

Com relação à normalidade, observamos que, exceto por alguns valores discrepantes, aparentemente o resíduo do modelo aplicado à série da temperatura do ar pode ser aproximado por uma curva normal.

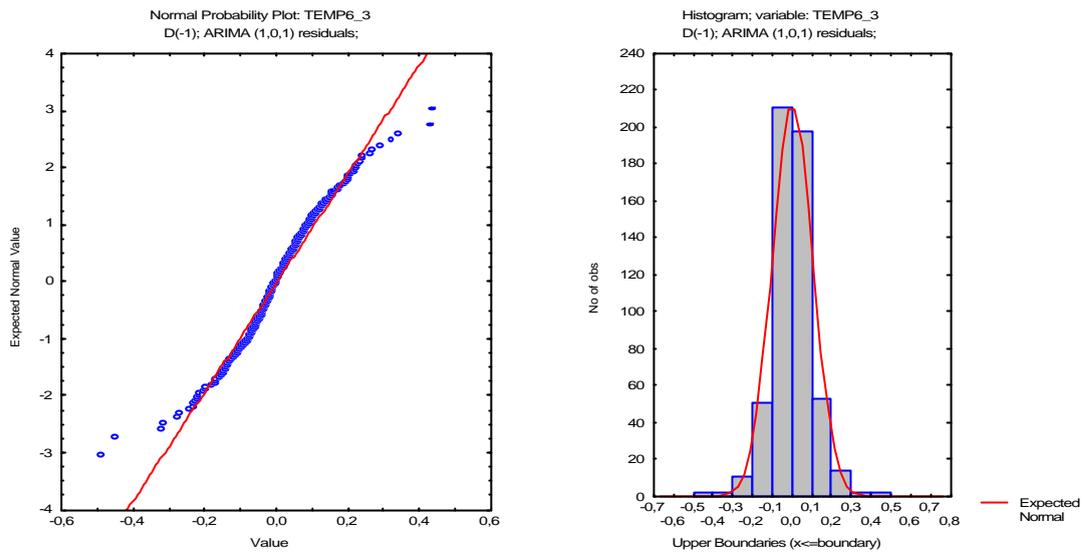


Figura 4.1.2 Gráficos do normal probability plot e histograma do resíduo do modelo ARIMA(1,0,1) aplicado a série da temperatura do ar.

Pressão Atmosférica

Os modelos que reduziram significativamente a soma dos quadrados da série da pressão atmosférica (Tabela 4.1.2) não são muito diferentes dos da temperatura do ar, porém explicam um percentual maior da variância da série original.

O modelo que melhor agrega parcimônia e variância explicada é o ARIMA (1,1,1), que representa aproximadamente 94% da variância da série reamostrada a cada 6 horas. A análise dos gráficos da ACF e PACF do resíduo (Figura 4.1.3) mostra que ainda resta bastante correlação entre os valores

Tabela 4.1.2 Modelos desenvolvidos à partir dos dados reamostrados a cada 6 horas da série da pressão atmosférica

MODELO	SOMA DE QUADRADOS INICIAL	SOMA DE QUADRADOS FINAL	PORCENTAGEM DA VARIÂNCIA EXPLICADA
ARIMA (1,1,0)	682,81	118,4	82,66%
ARIMA (0,1,1)	682,81	188,58	72,38%
ARIMA (1,1,1)	682,81	40,169	94,12%
ARIMA (1,1,1) (1,0,0) ₅	682,81	29,147	95,73%
ARIMA (1,1,1) (0,0,1) ₅	682,81	24,997	96,34%

Figura 4.1.3 Gráfico das funções de autocorrelação (ACF) e autocorrelação parcial (PACF) do resíduo do modelo ARIMA (1,1,1) aplicado sobre a série da pressão atmosférica

A análise quanto à normalidade do resíduo também não apresenta um resultado muito satisfatório. Tanto o histograma quanto o normal probability plot (Figura 4.1.4) mostram que o resíduo não é muito bem aproximado pela curva normal.

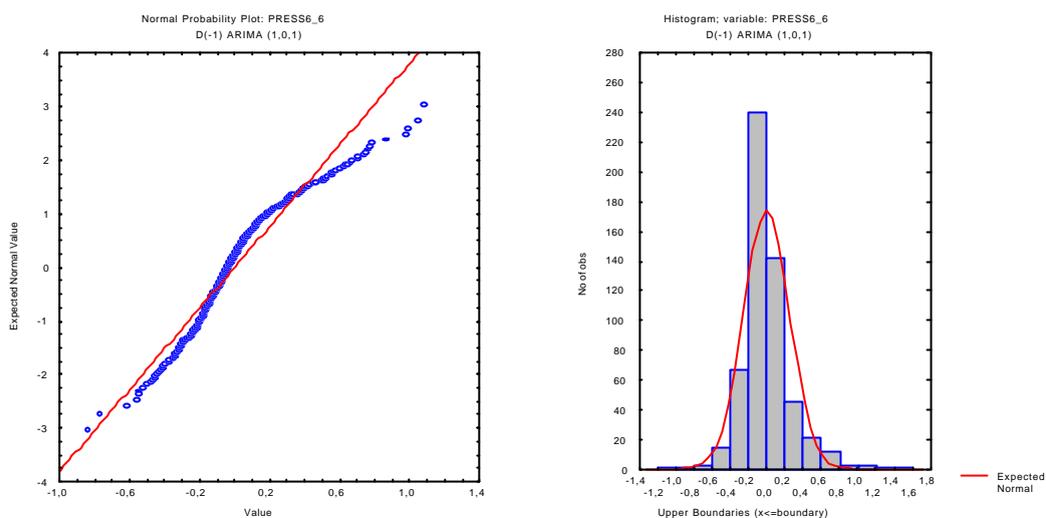


Figura 4.1.4 Gráficos do normal probability plot e histograma do resíduo do modelo ARIMA(1,1,1) aplicado a série da pressão atmosférica

Vento Meridional

A série do vento meridional reamostrada a cada 6 horas não apresentou bons resultados quando diferenciada. Os modelos com melhor comportamento (Tabela 4.1.3) foram obtidos utilizando o Statistica® sem tomar diferenças. A diferença entre o ARIMA (1,0,0) e ARIMA(1,0,1) foi pequena, porém consideramos que o segundo, por explicar melhor a variância - 99% - e ser o mesmo modelo aplicado às outras séries poderia facilitar o trabalho posterior.

Tabela 4.1.3 Modelos desenvolvidos à partir dos dados reamostrados a cada 6 horas da série do vento meridional

MODELO	SOMA DE QUADRADOS INICIAL	SOMA DE QUADRADOS FINAL	PORCENTAGEM DA VARIÂNCIA EXPLICADA
ARIMA (1,0,0)	27.096	460,15	98,3%
ARIMA (0,0,1)	27.096	7.314,4	73%

ARIMA (1,0,1)	27.096	278,02	98,97%
---------------	--------	--------	--------

Através da observação dos gráficos da ACF e PACF (Figura 4.1.5) podemos constatar que também no caso do vento meridional restou correlação entre os valores do resíduo.

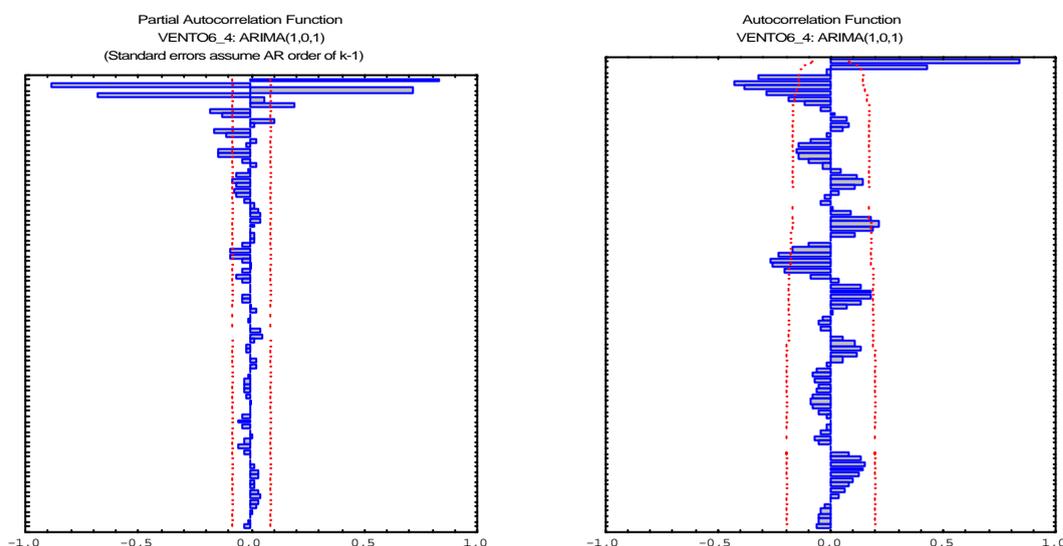


Figura 4.1.5 Gráfico das funções de autocorrelação (fac) e autocorrelação parcial (facp) do resíduo do modelo ARIMA (1,0,1) aplicado sobre a série do vento meridional.

Quanto a normalidade, o histograma e o normal probability plot (Figura 4.1.6) mostram que o resíduo pode ser satisfatoriamente aproximado por uma curva normal.

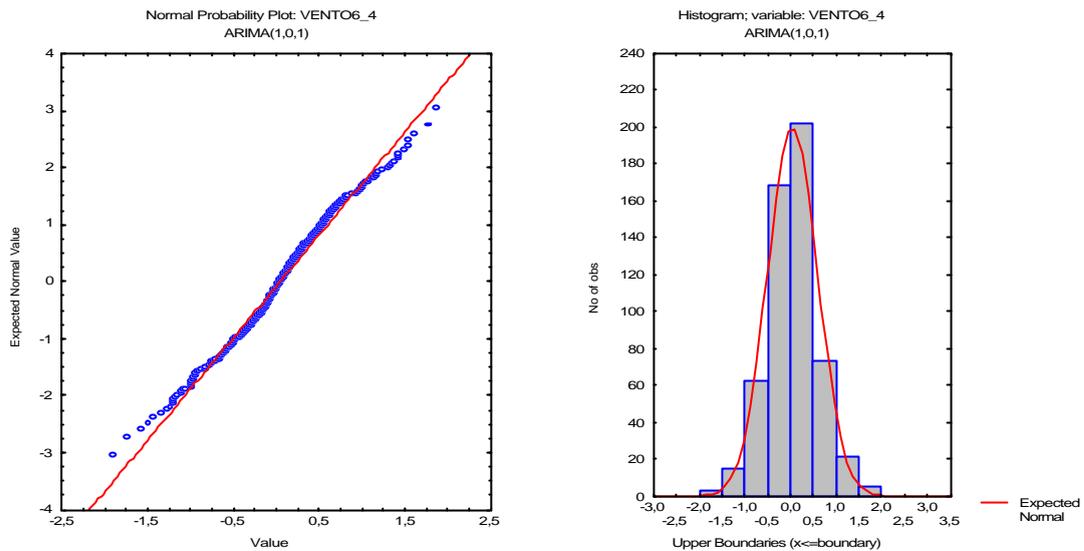


Figura 4.1.6 Gráficos do normal probability plot e histograma do resíduo do modelo ARIMA(1,0,1) aplicado a série do vento meridional.

Nível do Mar

A Tabela 4.1.4 a seguir mostra os primeiros resultados para a série do nível do mar. Verificamos que os modelos ARIMA(1,1,1) e ARIMA(1,1,1)(1,0,0)₅ explicam respectivamente 89,53% e 92,29% da variância da série.

Os modelos ARIMA(1,1,0) e ARIMA(0,1,1) explicam, respectivamente, 75,81% e 69,4% e são descartados em função dos resultados melhores dos dois outros.

Tabela 4.1.4 Modelos desenvolvidos à partir dos dados reamostrados a cada 6 horas da série do nível do mar

MODELO	SOMA DE QUADRADOS INICIAL	SOMA DE QUADRADOS FINAL	PORCENTAGEM DA VARIÂNCIA EXPLICADA
ARIMA (1,1,0)	12.811	3.098,9	75,81%
ARIMA (0,1,1)	12.811	3.919,7	69,4%
ARIMA (1,1,1)	12.811	1.340,4	89,53%
ARIMA(1,1,1)(1,0,0) ₅	12.811	987,74	92,29%

Dos modelos acima o ARIMA(1,1,1) é o melhor candidato por ser ao mesmo tempo parcimonioso e explicar aproximadamente 90% da variância da série do nível do mar. Analisando o resíduo, verificamos que ainda resta alguma covariância não explicada pelo modelo, mostrada pelos gráficos da ACF e da PACF (Figura 4.1.7). Ao mesmo tempo, o histograma e o normal probability plot (Figura 4.1.8) mostram que o resíduo pode ser razoavelmente aproximado pela curva normal .

Figura 4.1.7 Gráfico das funções de autocorrelação (fac) e autocorrelação parcial (facp) do resíduo do modelo ARIMA (1,1,1) aplicado sobre a série do nível do mar

Figura 4.1.8 Gráficos do normal probability plot e histograma do resíduo do modelo ARIMA(1,1,1) aplicado a série do nível do mar

Comparando as estatísticas das séries reamostradas a cada 6 horas com as dos modelos aplicados a essas séries (Tabela 4.1.5) podemos perceber que a variância é satisfatoriamente explicada. Porém, como pudemos perceber pelos gráficos a análise da normalidade dos resíduos nem sempre foi satisfatória.

Tabela 4.1.5 Estatísticas das séries analisadas e dos resíduos após a aplicação dos modelos.

Variáveis	Valid N	Média	Variância	Desv.Padr.
NIVEL	551	48,188	228,6831	15,12227
NIVEL D(-1)	551	-,006	22,1314	4,70440
NIVEL ARIMA (1,1,1)	551	,005	1,8540	1,36163
PRESSÃO	551	1016,784	27,7547	5,26828
PRESSÃO D(-1)	551	-,024	1,1823	1,08735
PRESSÃO ARIMA (1,1,1)	551	-,002	,0634	,25172
TEMP	551	19,839	8,8435	2,97381
TEMP_4 D(-1)	551	,019	,1037	,32205
TEMP_3 ARIMA (1,1,1)	551	,002	,0104	,10214
VENTO	551	6,292	5,9050	2,43002
VENTO ARIMA (1,0,1)	551	,044	,3020	,54950

4.2 ANÁLISE NO MATLAB®

Seguindo o conselho de Broersen (2002) de utilizar ferramentas computacionais automáticas para analisar séries temporais, e com intuito de encontrar um modelo AR mais adequado para previsão, passamos a utilizar o programa computacional Matlab.

As funções autocorrelação (ACF) e autocorrelação parcial (PACF) foram computadas utilizando as rotinas autocorr e parcorr do módulo Garch do Matlab. O cálculo dos parâmetros para a construção dos modelos AR foi feito através da rotina AR, do módulo Ident. O objetivo agora é procurar encontrar modelos AR, uma vez que os modelos mistos (ARIMA) tem utilização para previsão mais complexa.

À partir deste momento, a análise foi feita com as todas séries diferenciadas a passo um.

A análise dos correlogramas das ACF e PACF de todas as séries (Figs. 4.6 a 4.9) apontam para modelos AR de ordem 2 ou um 4. Foram então computados modelos de ordem 2 a 4 para todas as séries. A análise vem a seguir.

Temperatura do Ar

Os modelos de melhor resolução foram os de ordem 2 e 4, que explicam, respectivamente, 91,2 e 98,8% da variabilidade da série diferenciada, conforme mostra a Tabela 4.2.1. Porém a ACF e PACF dos resíduos dos modelos AR(2) (Fig. 4.2.1) e AR(4) (Fig. 4.2.2) mostram que ainda permanece uma forte correlação entre os valores. Embora essa correlação seja menor no modelo de ordem 4, ainda é significativa.

Tabela 4.2.1 Modelos AR construídos para a série da temperatura do ar à partir da rotina AR do módulo Ident do Matlab

MODELO	SOMA DE QUADRADOS INICIAL	SOMA DE QUADRADOS FINAL	PORCENTAGEM DA VARIÂNCIA EXPLICADA
AR(2)	60,1685	5,3217	91,2%
AR(4)	60,1685	0,7487	98,8%

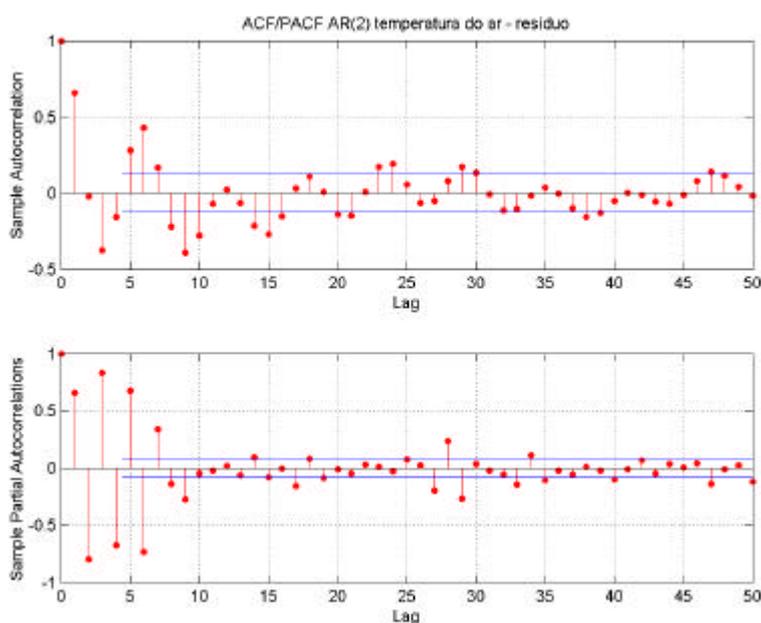


Figura 4.2.1 Funções autocorrelação e autocorrelação parcial do resíduo do

modelo AR(2) aplicado à série da temperatura do ar local em São Francisco do Sul-SC, 1996.

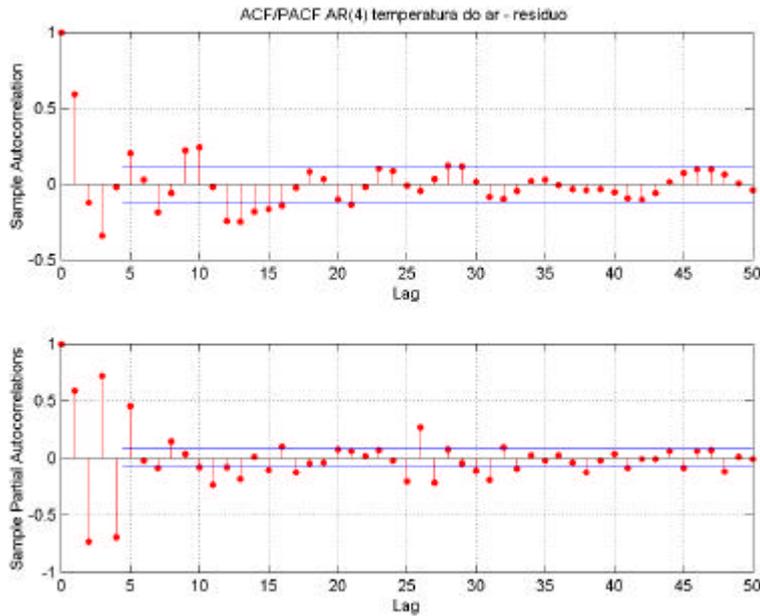


Figura 4.2.2 Funções autocorrelação e autocorrelação parcial do resíduo do modelo AR(4) aplicado à série da temperatura do ar local em São Francisco do Sul-SC, 1996.

Pressão Atmosférica

A análise da série da pressão atmosférica é semelhante a da temperatura do ar. Os modelos de melhor resolução foram os de ordem 2 e 4, que explicam, respectivamente, 97,3% e 99,7% da variabilidade da série diferenciada, conforme mostra a Tabela 4.7. Porém a ACF e PACF dos resíduos dos modelos AR(2) (Fig. 4.2.3) e AR(4) (Fig. 4.2.4) mostram que ainda permanece uma forte correlação entre os valores. Também neste caso, embora essa correlação seja menor no modelo de ordem 4, ainda é significativa.

Tabela 4.2.2: Modelos AR construídos para a série da pressão atmosférica à partir da rotina AR do módulo Ident do Matlab

MODELO	SOMA DE QUADRADOS INICIAL	SOMA DE QUADRADOS FINAL	PORCENTAGEM DA VARIÂNCIA EXPLICADA
AR(2)	682,8053	18,7516	97,3%
AR(4)	682,8053	2,1330	99,7%

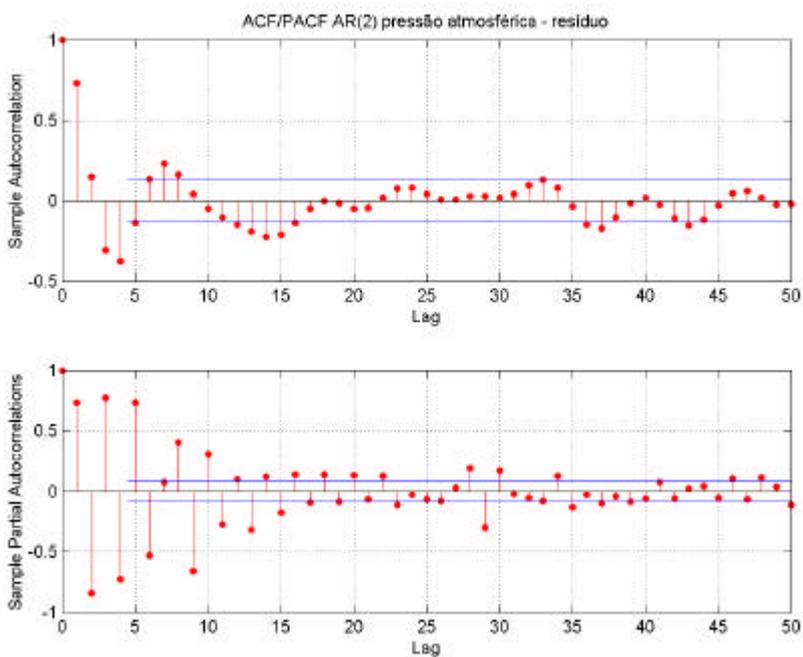


Figura 4.2.3 Funções autocorrelação e autocorrelação parcial do resíduo do modelo AR(2) aplicado à série da pressão atmosférica em São Francisco do Sul-SC, 1996.

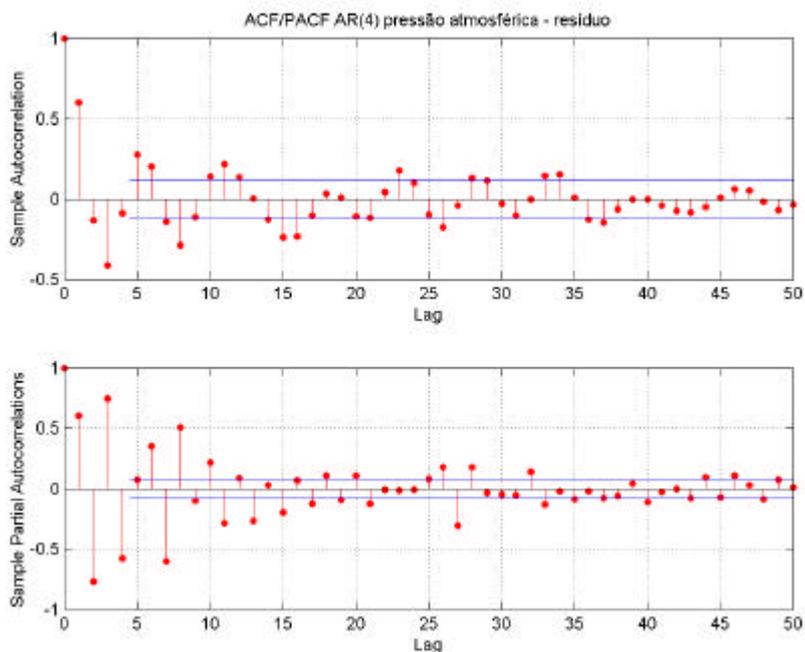


Figura 4.2.4 Funções autocorrelação e autocorrelação parcial do resíduo do modelo AR(4) aplicado à série da pressão atmosférica em São Francisco do Sul-SC, 1996.

Vento Meridional

Da mesma forma que as anteriores, foram construídos através da série do vento meridional modelos AR de ordem 2 e 4. Os resultados também são semelhantes. O modelo de ordem 2 explica 94% da variância da série diferenciada (Tabela 4.2.3), porém os gráficos da ACF e PACF do resíduo (Fig. 4.2.5) ainda demonstram a existência de forte correlação entre os valores regredidos da série. Também neste caso o modelo de ordem 4, que explica 99,2% da variabilidade da série (Tabela 4.2.3), tem forte correlação entre os valores do resíduo, conforme mostra o gráfico da ACF e da PACF (Fig. 4.2.6).

Tabela 4.2.3: Modelos AR construídos para a série do vento meridional à partir da rotina AR do módulo Ident do Matlab

MODELO	SOMA DE QUADRADOS INICIAL	SOMA DE QUADRADOS FINAL	PORCENTAGEM DA VARIÂNCIA EXPLICADA
AR(2)	395,9271	23,5439	94%
AR(4)	395,9271	3,1275	99,2%

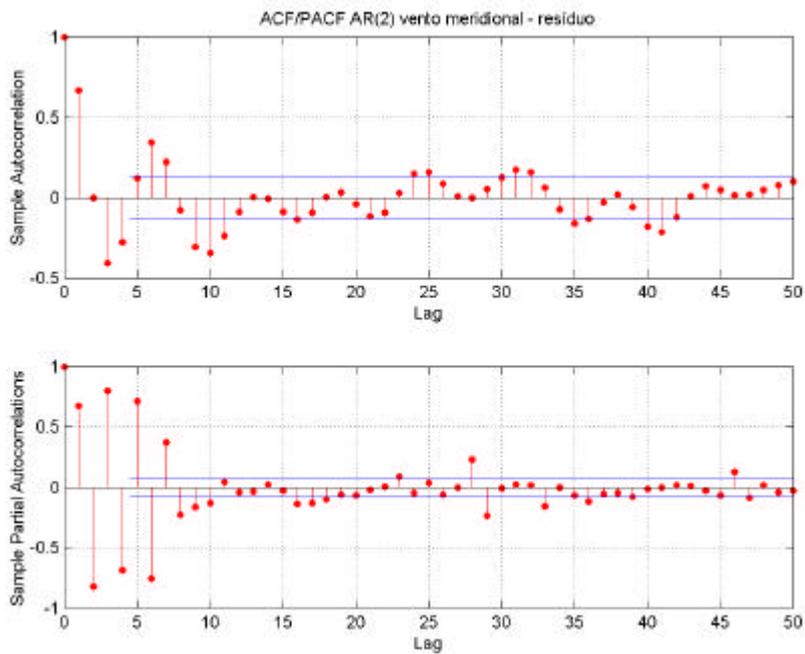


Figura 4.2.5 Funções autocorrelação e autocorrelação parcial do resíduo do modelo AR(2) aplicado à série do vento meridional local em São Francisco do Sul-SC, 1996.

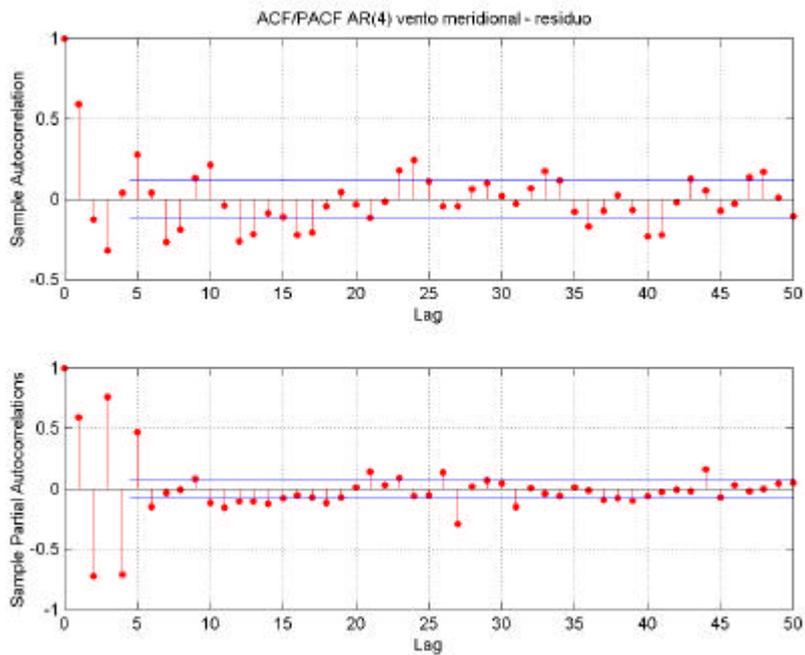


Figura 4.2.6 Funções autocorrelação e autocorrelação parcial do resíduo do modelo AR(4) aplicado à série do vento meridional local em São Francisco do Sul-SC, 1996.

Nível do mar

No caso da série do nível do mar, os modelos computados foram os de ordem 2, 3 e 4. Embora os modelos representem, respectivamente, 96,2%, 98,4% e 99,3% da variância da série diferenciada (Tabela 4.2.4), todos os resíduos apresentam correlação entre seus valores. O gráfico da ACF e da PACF dos modelos de ordem 2 (Fig. 4.2.7), 3 (Fig. 4.2.8) e 4 (Fig. 4.2.9) mostram que o modelo que apresenta menos correlação é o de ordem 3.

Tabela 4.2.4: Modelos AR construídos para a série do vento meridional à partir da rotina AR do módulo Ident do Matlab

MODELO	SOMA DE QUADRADOS INICIAL	SOMA DE QUADRADOS FINAL	PORCENTAGEM DA VARIÂNCIA NÃO EXPLICADA
AR(2)	$1,28 \times 10^4$	489,0767	96,2%
AR(3)	$1,28 \times 10^4$	209,6389	98,4%
AR(4)	$1,28 \times 10^4$	90,6681	99,3%

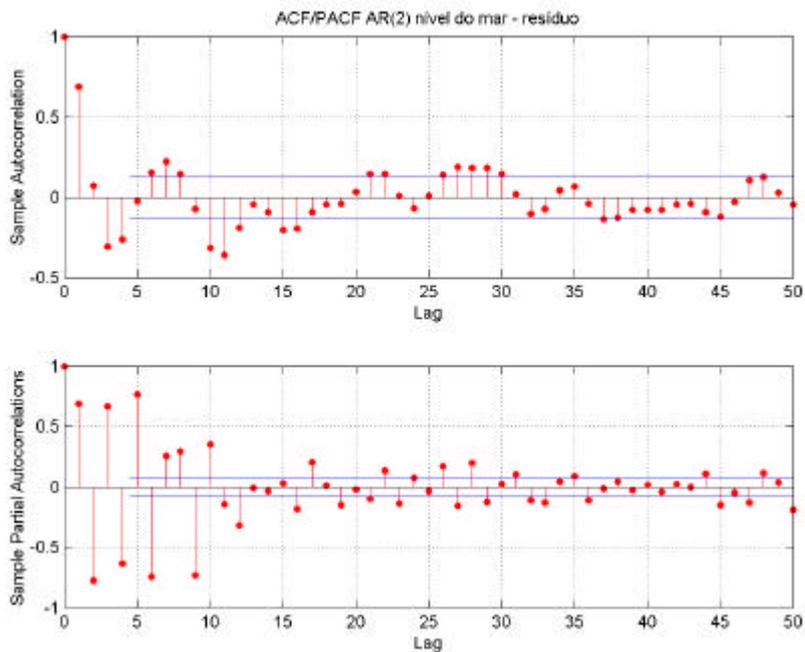


Figura 4.2.7 Funções autocorrelação e autocorrelação parcial do resíduo do modelo AR(2) aplicado à série do nível do mar local em São Francisco do Sul-SC, 1996.

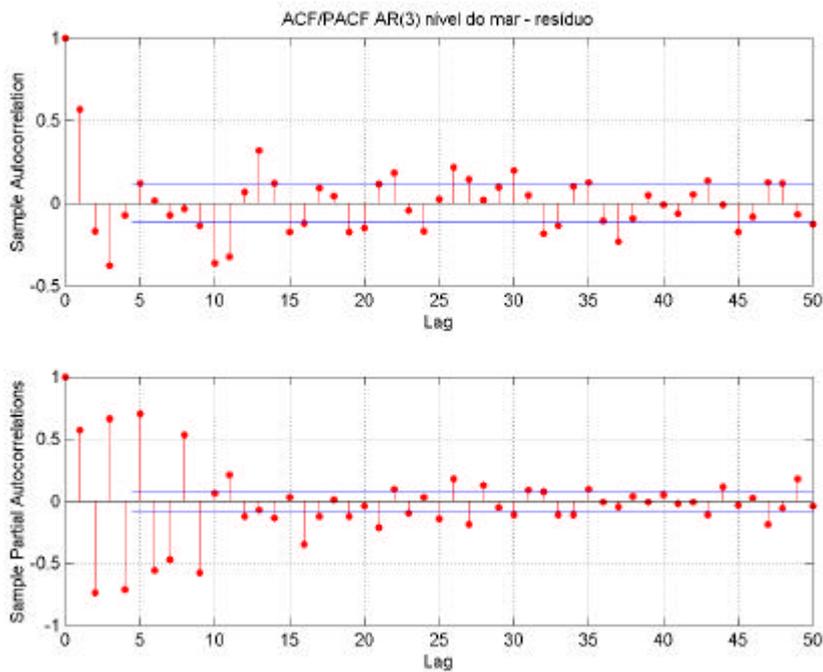


Figura 4.2.8 Funções autocorrelação e autocorrelação parcial do resíduo do modelo AR(3) aplicado à série do nível do mar local em São Francisco do Sul-SC, 1996.

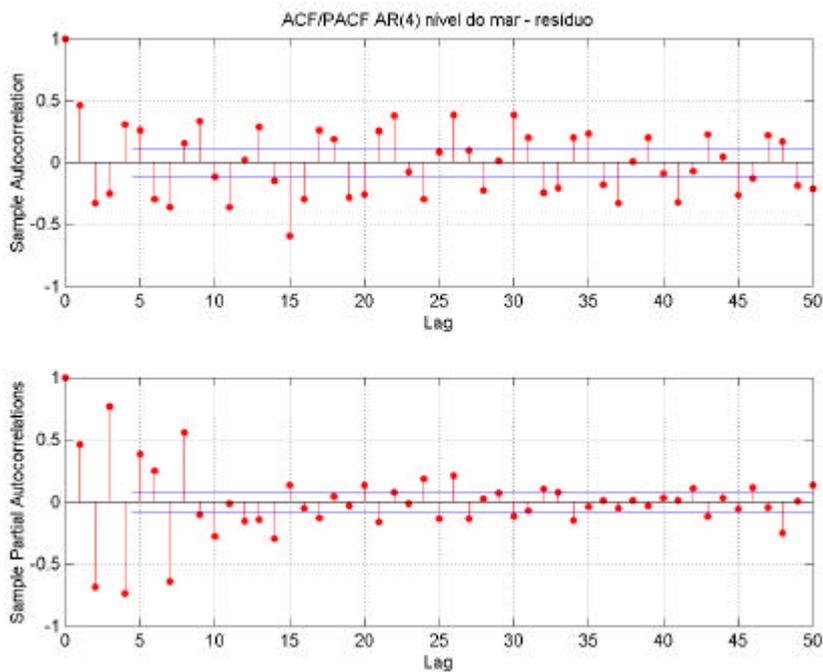


Figura 4.2.9 Funções autocorrelação e autocorrelação parcial do resíduo do modelo AR(4) aplicado à série do nível do mar local em São Francisco do Sul-SC, 1996.

Os parâmetros dos modelos

Os modelos escolhidos para representar todas as séries foram os autorregressivos de ordem 4, que descrevemos a seguir:

Temperatura do Ar

Calculados os parâmetros do modelo AR(4) da série da temperatura do ar, construímos o modelo:

$$(1 - B)Z_t = 2,809 Z_{t-1} - 3,67 Z_{t-2} + 2,535 Z_{t-3} - 0,81 Z_{t-4} + a_t$$

A análise da ACF do modelo AR(4) para a série da temperatura do ar (Fig. 4.2.10) mostra que o modelo consegue explicar bem os primeiros passos temporais, o que significa que pode ser utilizado para previsões de até 24 horas. Mostra também que, para previsões para janelas temporais maiores seria necessário um modelo de ordem superior.

Comparando com o espectro da série original (Fig. 4.2.10) observa-se que o modelo consegue captar parte da energia. Novamente vemos que para construir um modelo cujo espectro represente uma parte mais significativa da energia dos dados seria necessário um AR de ordem superior.

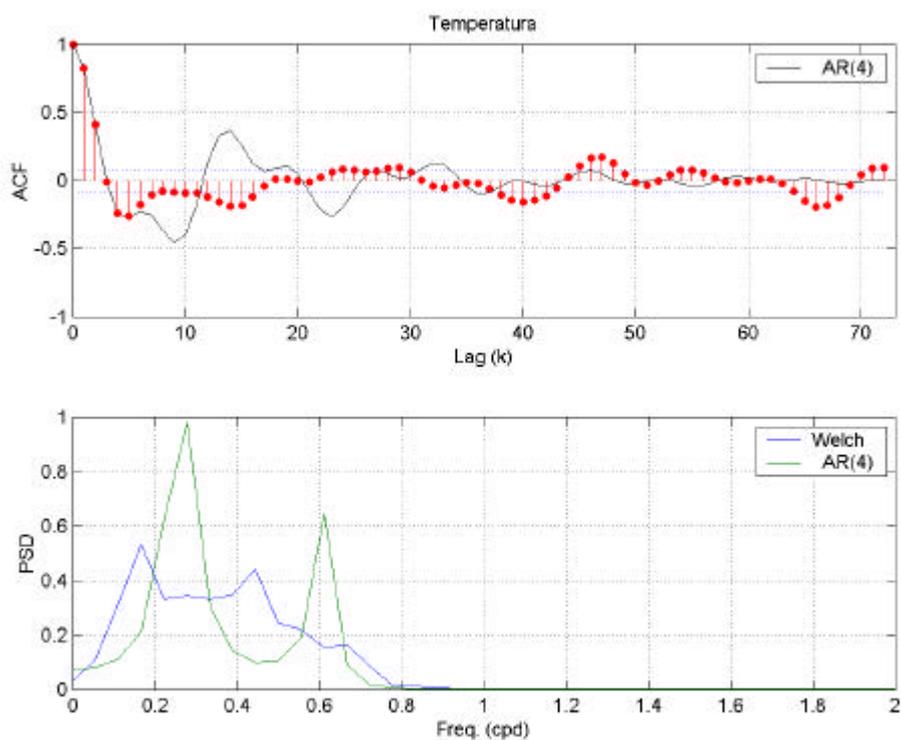


Figura 4.2.10 Comparação entre ACF e espectro do modelo AR(4) e a série observada da série da temperatura do ar.

Na observação dos gráficos que fazem a análise dos modos temporais do modelo AR(4) para a temperatura do ar (Fig. 4.2.11) percebemos que existe associação dos tempos em dias com a passagem dos sistemas frontais. Com uma série maior de dados (pelo menos um ano) os modelos representariam com muito mais eficiência essa associação.

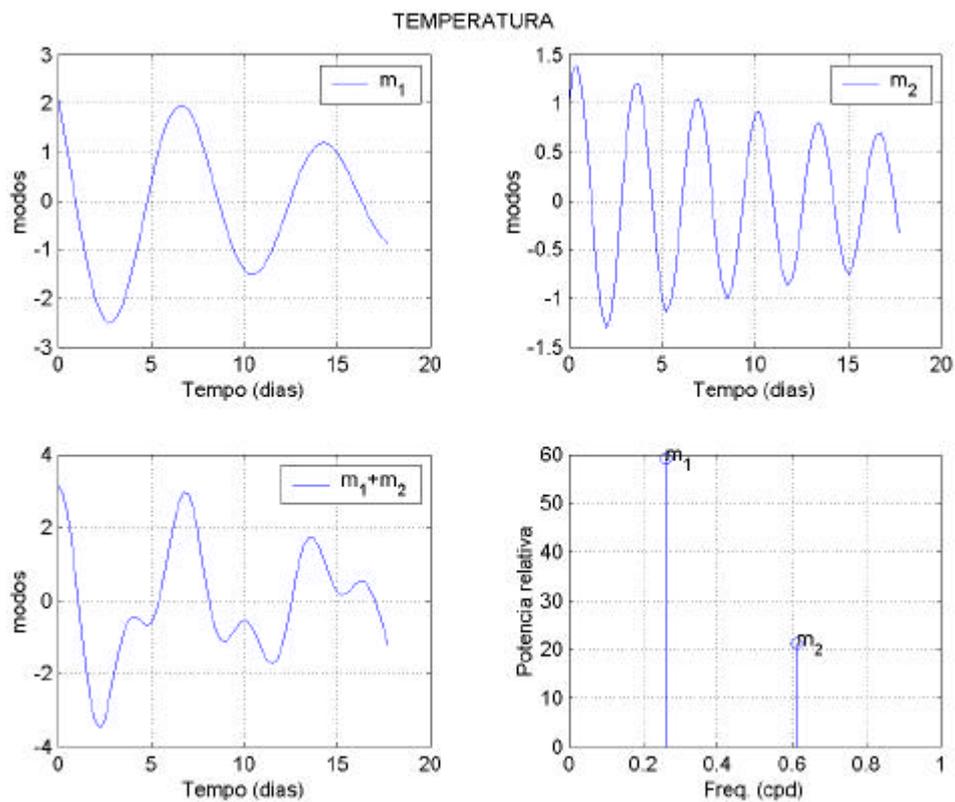


Figura 4.2.11 Análise dos modos temporais do modelo AR(4) para a série da temperatura do ar.

Pressão Atmosférica

Calculados os parâmetros do modelo AR(4) da série da pressão atmosférica, construímos o modelo:

$$(1 - B)Z_t = 3,142 Z_{t-1} - 4,226 Z_{t-2} + 2,845 Z_{t-3} - 0,823 Z_{t-4} + a_t$$

A ACF do modelo e a comparação com o espectro da série original vêm a seguir(Fig. 4.2.12):

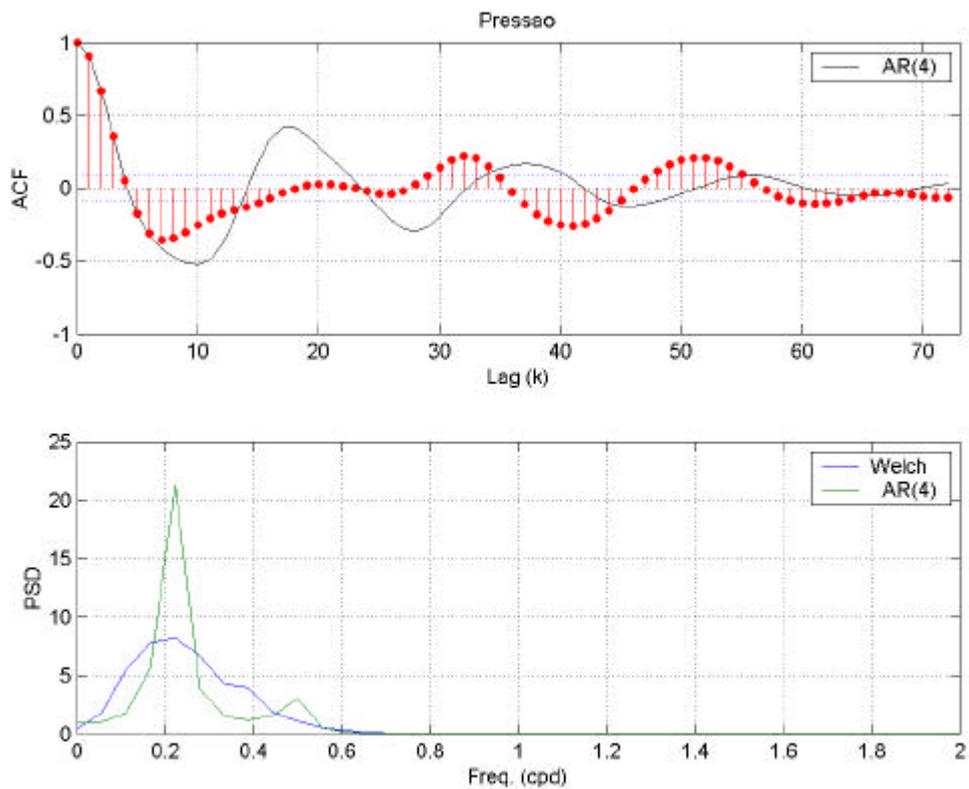


Figura 4.2.12 Comparação entre ACF e espectro do modelo AR(4) e a série observada da série da pressão atmosférica.

A análise da ACF do modelo AR(4) e a comparação com o espectro para a série da pressão atmosférica (Fig. 4.2.12) é muito semelhante com aquela feita para a temperatura do ar, ou seja, o modelo explica apenas os primeiros passos temporais e parte do espectro.

Na observação dos gráficos que fazem a análise dos modos temporais do modelo AR(4) para a pressão atmosférica (Fig. 4.2.13) percebemos que os resultados, também aqui, são muito semelhantes aos da temperatura, ou seja, existe associação dos tempos em dias com a passagem dos sistemas frontais.

Com uma série maior de dados (pelo menos um ano) os modelos representariam com muito mais eficiência essa associação.

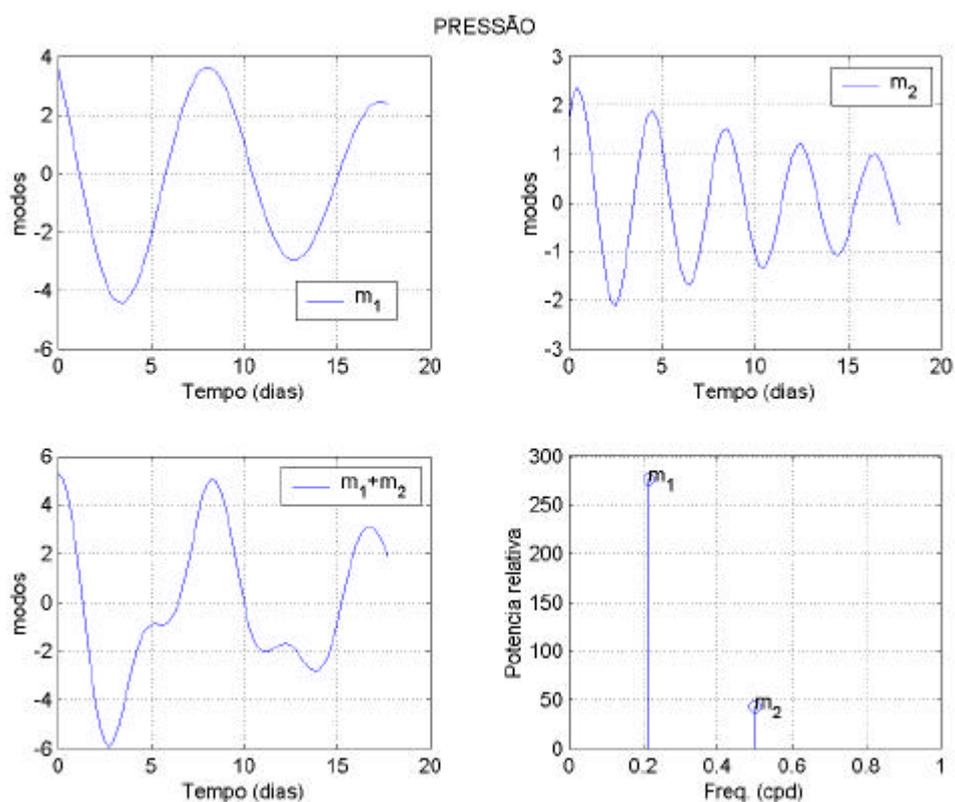


Figura 4.2.13 Análise dos modos temporais do modelo AR(4) para a série da pressão atmosférica..

Vento Meridional

Calculados os parâmetros do modelo AR(4) da série do vento meridional, construímos o modelo:

$$(1 - B)Z_t = 2,891 Z_{t-1} - 3,83 Z_{t-2} + 2,636 Z_{t-3} - 0,8313 Z_{t-4} + a_t$$

A Figura 4.2.14 mostra a comparação da ACF e do espectro do modelo AR(4) com a série original e os resultados são muito semelhantes aos das séries anteriores, ou seja, o modelo consegue explicar somente os primeiros passos temporais e apenas parte da energia espectral.

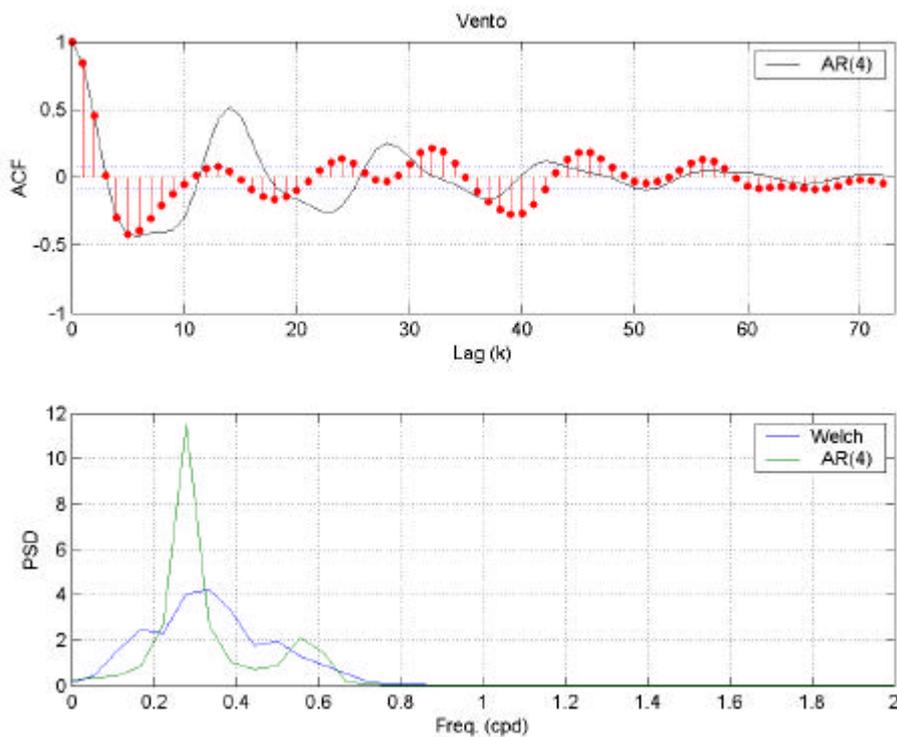


Figura 4.2.14 Comparação entre ACF e espectro do modelo AR(4) e a série observada da série do vento longitudinal.

Quanto aos gráficos que fazem a análise dos modos temporais do modelo AR(4) para o vento meridional (Fig. 4.2.15) percebemos que os resultados, também aqui, são muito semelhantes aos das outras séries, ou

seja, existe associação dos tempos em dias com a passagem dos sistemas frontais.

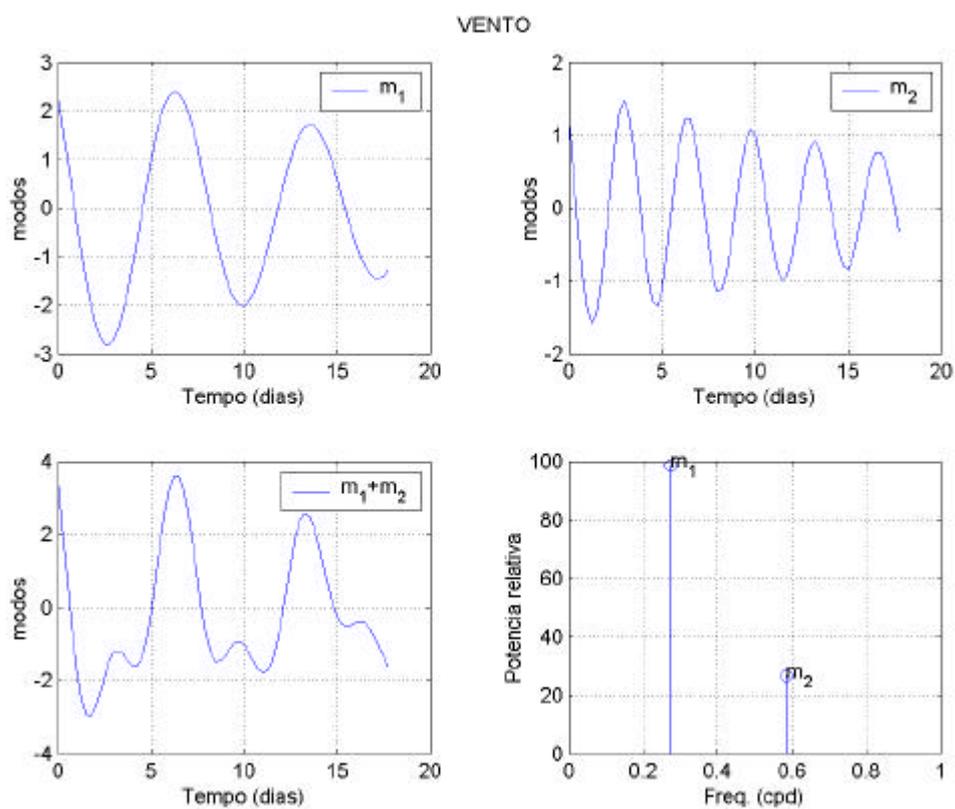


Figura 4.2.15 Análise dos modos temporais do modelo AR(4) para a série do vento meridional.

Nível do Mar

Calculados os parâmetros do modelo AR(4) para a série do nível do mar, construímos o modelo:

$$(1 - B)Z_t = 2,937 Z_{t-1} - 3,826 Z_{t-2} + 2,54 Z_{t-3} - 0,7531 Z_{t-4} + a_t$$

Os gráficos com a comparação entre a ACF do modelo AR(4) e o espectro com a série original da variável nível do mar também demonstram que o modelo consegue reproduzir somente os primeiros passos temporais e explicar somente parte do espectro da série original.

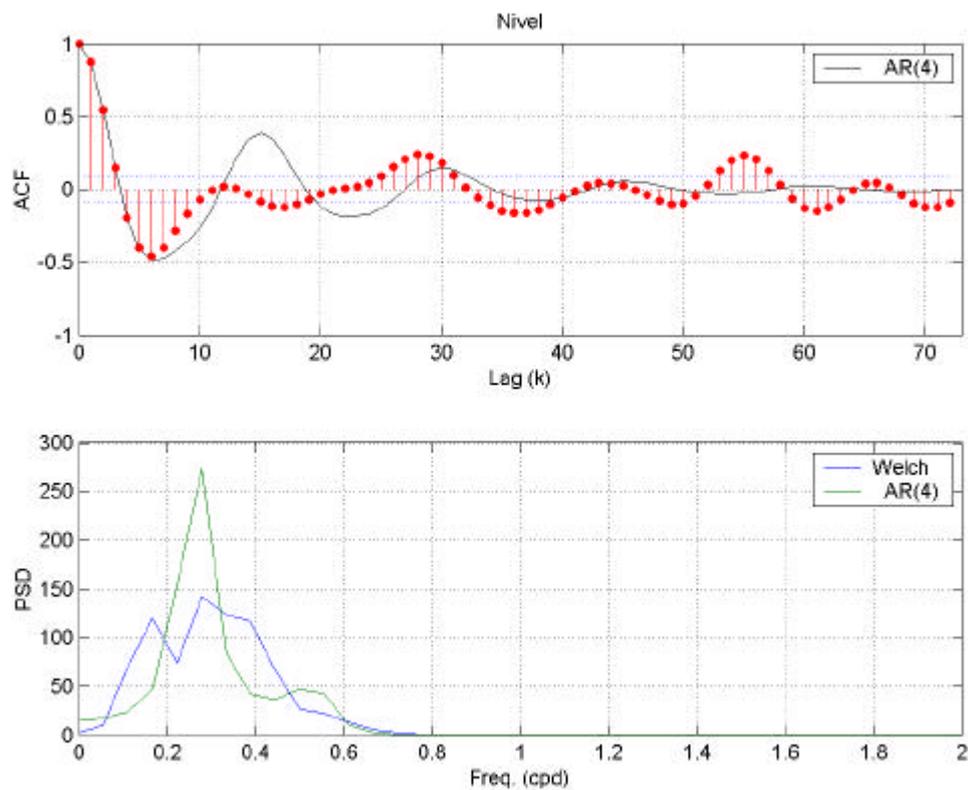


Figura 4.2.16 Comparação entre ACF e espectro do modelo AR(4) e a série observada da série do nível do mar.

Vemos a mesma associação dos modos temporais do modelo AR(4) para a série do nível do mar (Fig. 4.2.17) com a passagem de sistemas frontais.

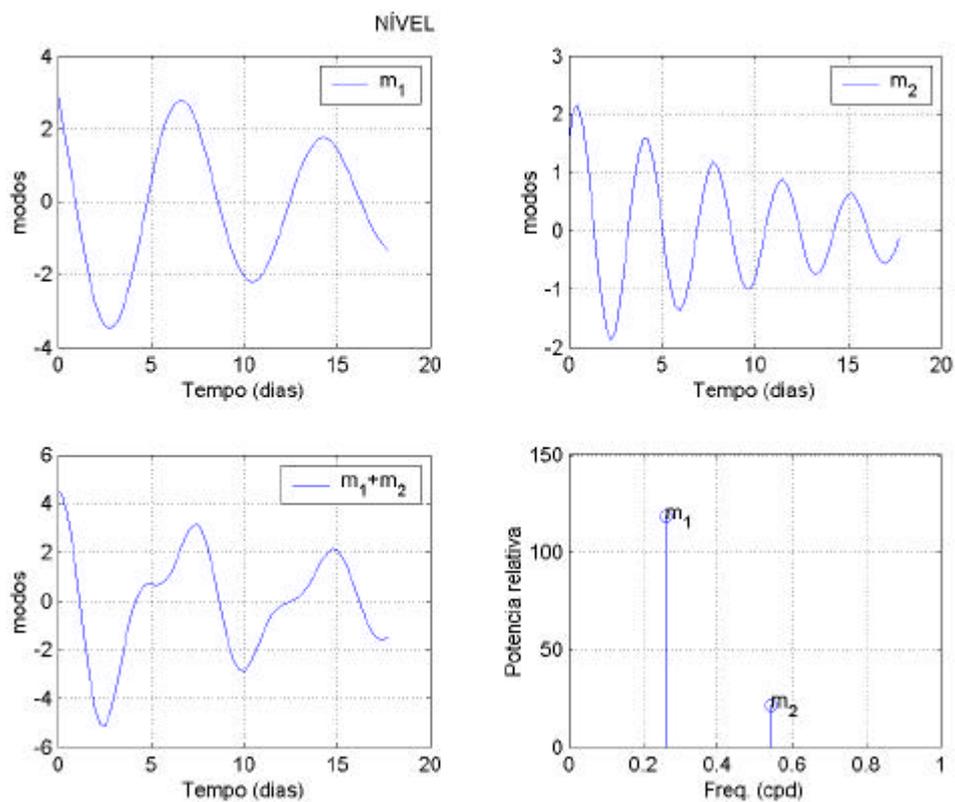


Figura 4.2.17 Análise dos modos temporais do modelo AR(4) para a série do nível do mar.

CAPÍTULO 5

CONCLUSÕES

Séries temporais da temperatura do ar, pressão atmosférica, da componente meridional do vento meridional e nível do mar aqisitadas em São Francisco do Sul-SC, no período de 14 de julho a 15 de dezembro de 1996, foram analisadas utilizando-se modelos ARIMA (autoregressive integrated moving average).

As séries horárias foram reamostradas a cada seis horas para facilitar a análise das componentes de baixa freqüência.

As séries se mostraram não estacionárias na média, impondo a necessidade de integração. É possível intuir uma não estacionaridade da variância que os modelos não conseguem reconhecer corretamente devido ao comprimento insuficiente dos registros utilizados. Isso pode ter como conseqüência a reconstrução imprecisa de componentes cíclicas.

Por exemplo, na ACF da série diferenciada do nível do mar (Fig. 4.9), ficam evidentes máximos a distância de 27 passos temporais, indicando um ciclo de 7,5 dias, que não foi reconhecido como tal por nenhum modelo.

Nos modelos de ordem 2 a estrutura de recorrência entre dois sistemas frontais é reconhecida através do modo associado aos dois pólos do polinômio.

Os modelos AR(4) de todas as variáveis consideradas conseguem reconstruir também a evolução do sistema in situ, de período aproximado de 2,5 dias, por meio da segunda dupla de pólos.

Modelos autorregressivos de ordem superior poderiam melhorar a identificação e a reconstrução desses ciclos, mas não conseguem convergir devido a não estacionaridade.

Apesar disso, modelos de baixa ordem, com dois parâmetros apenas, conseguem fazer previsões aceitáveis até 24 horas, o que demonstra as possibilidades da metodologia.

A sugestão para trabalhos futuros é a construção de modelos com uma quantidade mínima de um ano de dados. Com séries assim poderiam-se explicar melhor outras periodicidades que ficam “escondidas” com séries menores.

A não estacionaridade poderia, outrossim, ser enfrentada por meio de modelos quadráticos.

REFERÊNCIAS

- BOX, G. E. & JENKINS, G. M. Time series analysis - forecasting and control. Holden-Day, San Francisco, 553 p., 1970.
- BROERSEN, P. M. T. Automatic Spectral Analysis With Time Series Models. IEEE Transaction On Instrumentation and Measurement, Vol. 51, nº 2, pp. 211-216, 2002.
- BROWN, J., COLLING, A., PARK, D., PHILLIPS, J., ROTHERY, D., WRIGHT, J. Waves, tides and shallow-water processes. Pergamon Press and The Open University, Oxford. 187 p., 1989.
- CASTRO, B. M., LEE, T. N. Wind-forced sea level variability on the southeast brazilian shelf. Journal of Geophysical Research, Vol 100, nº C8, pp. 16.045-16.056. 1995.
- DHN. Roteiro Costa Sul: do Cabo Frio ao Arroio Chuí, Lagoas dos Patos e Mirim. Diretoria de Hidrografia e Navegação. 12ª Ed. Rio de Janeiro. 282 p., 1994.
- FRANCO, A. S. Tides – fundamentals, analysis and prediction. IPT – Instituto de Pesquisas Tecnológicas. 2º Edition. São Paulo. 232 p. 1988.
- GARRISON, T. Oceanography – an invitation to marine science. Wadsworth Publishing Company, Belmont. 3ª Edition, 552 p., 1999.
- GILL, A. E. Atmosphere-ocean dynamics. International Geophysics Series (Ed. By W. L. Donn), Vol. 30. Academic Press, New York. 662 p., 1982.

- HAMON, B. V. 1966. Continental shelf waves and the effects of atmospheric pressure and wind stress on sea level. *Journal of Geophysical Research*, vol 71, nº 12, pp. 2883-2893.
- HEEMINK, A. W. Storme surge prediction using Kalman filtering. Thesis Twente University of Technology, Rijkswaterstaat. 193 p., 1986.
- MAKRIDAKIS, S., WHEELWRIGHT, S. C., HYNDMAN, R. J. Forecasting - methods and applications. John Wiley & Sons, Inc, New York, 3ª Edition. 642 p. 1998.
- MARONE, E. & CAMARGO, R. 1994. Marés Meteorológicas no litoral do estado do Paraná: o evento de 18 de agosto de 1993. *Nerítica*, Vol 8 (1-2), pp. 73-85.
- MIRANDA, L. B., CASTRO, B. M., KJERFVE. B. Princípios de Oceanografia Física em Estuários. Editora da Universidade de São Paulo, 420p., 2002.
- NIMER, E. Climatologia do Brasil. IBGE. Rio de Janeiro. 421 p., 1989.
- PICKARD, G. L. & EMERY, W. J. Descriptive Physical Oceanograpy - an introduction. Pergamon Press, New York. 5º Edition. 320 p., 1990.
- PONTE, R. M. 1994. Understanding the relation betwen wind and pressure driven sea level variability. *Journal of Geophysical Research*, vol. 99, nº C4, pp. 8033-8039.
- PUGH, D. T. Tides, surges and mean sea-level. John Wiley & Sons, Chichester. 472 p., 1987.

- RODRIGUES, M. L. G. Uma climatologia de frentes frias no litoral de Santa Catarina. Dissertação de Mestrado. Universidade Federal de Santa Catarina, Florianópolis. 75 p., 2003.
- STECH, J. L. & LORENZETTI, J. A. The response of the South Brazil Bight to the passage of wintertime cold fronts. Jour. Of Geophys. Res., Vol 97, nº C6, pp. 9.507-9.520. 1992.
- TANG, Y. M., GRIMSHAW, R., SANDERSON, B., HOLLAND, G. A numerical study of storm surges and tides, with application to the North Queensland Coast. Journal of Physical Oceanography, vol. 26, pp. 2700-2711. 1996.
- THURMAN, H. V. Introductory Oceanography. Prentice Hall, New Jersey. 8ª Edition, 544 p., 1997.
- TRUCCOLO, E. C. Maré meteorológica e forçantes atmosféricas locais em São Francisco do Sul - SC. Dissertação de Mestrado. Universidade Federal de Santa Catarina, Florianópolis. 100 p., 1998.
- VAZIRI, M. Predicting Caspian sea surface water level by ANN and ARIMA models. Journal of Waterway, Port, Coastal, and Ocean Engineering. July/August, pp 158-162, 1997.
- WEI, W. W. S. Time Series Analysis - Univariate and Multivariate Methods. Addison-Wesley Publishing Company, New York. 478 p., 1994.