

**UNIVERSIDADE FEDERAL DE SÃO CARLOS**  
**CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA**

***CARACTERÍSTICAS TEMPORAIS DA CONCENTRAÇÃO DE  
MATERIAL PARTICULADO NA ATMOSFERA DA CIDADE DE SÃO  
CARLOS - SP***

ORIENTADOR: PROF. DR. JOSÉ RENATO COURY

SIMONE ANDRÉA POZZA

TESE DE DOUTORADO

**UNIVERSIDADE FEDERAL DE SÃO CARLOS**  
**CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA**

***CARACTERÍSTICAS TEMPORAIS DA CONCENTRAÇÃO DE  
MATERIAL PARTICULADO NA ATMOSFERA DA CIDADE DE SÃO  
CARLOS - SP***

SIMONE ANDRÉA POZZA

ORIENTADOR: PROF. DR. JOSÉ RENATO COURY

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Engenharia Química da Universidade Federal de São Carlos como parte dos requisitos necessários à obtenção do título de Doutor em Engenharia Química, área de Pesquisa e Desenvolvimento de Processos Químicos.

SÃO CARLOS – SP

2009

**Ficha catalográfica elaborada pelo DePT da  
Biblioteca Comunitária/UFSCar**

P893ct

Pozza, Simone Andréa.

Características temporais da concentração de material particulado na atmosfera da cidade de São Carlos - SP / Simone Andréa Pozza. -- São Carlos : UFSCar, 2009. 141 f.

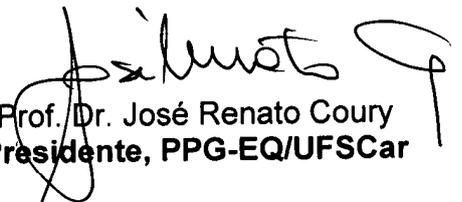
Tese (Doutorado) -- Universidade Federal de São Carlos, 2009.

1. Ar - poluição. 2. Análise de séries temporais. 3. Material particulado. 4. São Carlos (SP). I. Título.

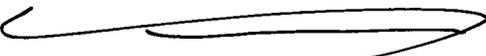
CDD: 660.294515 (20<sup>a</sup>)

MEMBROS DA BANCA EXAMINADORA DA TESE DE DOUTORADO DE **SIMONE ANDRÉA POZZA**, APRESENTADA AO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA DA UNIVERSIDADE FEDERAL DE SÃO CARLOS EM 19 DE MARÇO DE 2009.

BANCA EXAMINADORA:



Prof. Dr. José Renato Coury  
Presidente, PPG-EQ/UFSCar



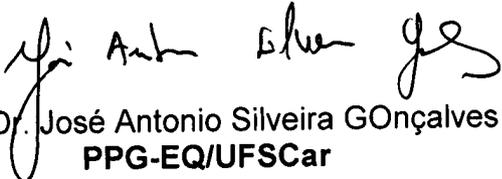
Prof. Dr. Virgílio Franco do Nascimento Filho  
CENA/USP



Prof. Dr. Marcelino Luiz Gimenes  
PPG-EQ/UEM



Prof. Dr. Wiclef Dymurgo Marra Júnior  
EESC-USP



Prof. Dr. José Antonio Silveira Gonçalves  
PPG-EQ/UFSCar

“As dificuldades são como as montanhas.  
Elas só se aplainam quando avançamos sobre elas.”

[Provérbio japonês](#)

## **Agradecimentos**

Deus, família e amigos!!!! Todos de crucial importância em diversas e diferentes fases deste processo.

Ao Prof. Dr. José Renato (Zezão) pela orientação. Foi um “quase pai” em diversos momentos.

Aos integrantes do nosso grupo de pesquisa que me auxiliaram com companheirismo para a conclusão deste trabalho: Ricardo, colega valioso em meu mestrado e início de doutorado; Tati, a melhor aluna de IC que poderia existir, além de uma grande amiga e Ed, pela competência no desenvolvimento das rotinas utilizadas nos modelos deste trabalho.

Ao Oscar (técnico) e Juliana Milanez (técnica e amiga) pelas inúmeras contribuições.

À Estatística (e grande amiga) Dalila Moraes, pelas contribuições iniciais.

Ao coleguismo de Edinalda, Karina Basan, Juliana Steffens, Marina e Vádila, que sempre foram solícitas, em importantes e grandes decisões e dúvidas.

Aos demais colegas do Laboratório de Controle Ambiental I, sem citar nomes, mas a todos que por aqui passaram desde 2003, quando iniciei meu mestrado.

Aos grandes amigos destes últimos anos, minha quase família, meus “quase irmãos”: Néstor, Paty e Ti.

Ao amigo Lincoln, que esteve presente em diversos momentos, tentando sempre me animar, dando força para superar as fases difíceis.

Aos amigos de ontem, hoje e sempre que mesmo a distância (PR, RS, SC, MG, RJ, DF, GO, MA, etc.) mantêm contato e estiveram presentes por telefone ou via e-mail.

D. Adélia e D. Maria Helena, pelo carinho e hospitalidade em São Carlos.

Ao casal Michele (teacher) e Cleber, novos amigos que pretendo cultivar por longo tempo.

A todos os professores, funcionários e alunos do DEQ/UFSCar por sua assistência.

Ao pessoal da UFU, em nome do professor Marcos Barrozo e dos colegas Euclides e Taísa, pelas trocas de informações.

Ao CNPq e FAPESP pelo suporte financeiro.

À Prefeitura de São Carlos, pela forma prestativa ao ceder-nos dados de saúde e transporte quando solicitados.

A todos que me ajudaram a concluir esta etapa da vida.

## SUMÁRIO

LISTA DE FIGURAS .....	iii
LISTA DE TABELAS .....	v
LISTA DE TABELAS .....	v
NOMENCLATURA.....	vi
RESUMO .....	viii
ABSTRACT .....	ix
CAPÍTULO 1 INTRODUÇÃO .....	1
1.1 Considerações Gerais .....	1
1.2 Objetivos.....	3
1.3 Estrutura do trabalho .....	4
CAPÍTULO 2 REVISÃO BIBLIOGRÁFICA .....	5
2.1 Aerossóis atmosféricos e material particulado (MP).....	5
2.2 Padrões de Qualidade do Ar e Legislação Ambiental .....	6
2.3 Danos Devido a Poluição do Ar .....	13
2.3.1 Materiais .....	13
2.3.2 Propriedades da natureza .....	13
2.3.3 Saúde .....	14
2.4 Monitoramento do Material Particulado .....	16
2.5 Análise Estatística .....	18
2.5.1 Box Plot.....	18
2.5.2 Séries Temporais .....	19
2.5.2.8 Séries Temporais Aplicadas a Problemas Ambientais .....	32
CAPÍTULO 3 PROCEDIMENTO EXPERIMENTAL .....	35
3.1 Área de Estudo .....	35
3.1.1 O Estado de São Paulo .....	35
3.1.2 A Cidade de São Carlos.....	35
3.1.3 Sazonalidade e Climatologia .....	36
3.1.4 Área da Coleta .....	37
3.2 Amostragem .....	41
3.2.1 Amostrador de Grandes Volumes (AGV) MP <sub>10</sub> .....	42
3.2.2 Amostrador Dicotômico .....	44
3.2.3 Campanha realizada.....	46
3.2.4 A plataforma “R”.....	46
CAPÍTULO 4 TRATAMENTO PRELIMINAR DOS DADOS.....	48
4.1 Dados do AVG MP <sub>10</sub> .....	49
4.2 Dados do Amostrador Dicotômico .....	51
4.2.1 Fração MP <sub>2,5</sub> .....	51
4.2.2 FraçãoMP <sub>10-2,5</sub> .....	53
CAPÍTULO 5 MODELAGEM E DISCUSSÃO DOS RESULTADOS.....	56
5.1 Dados do AVG MP <sub>10</sub> .....	57
5.2 Dados do Amostrador Dicotômico .....	62
5.2.1 Fração MP <sub>2,5</sub> .....	63
5.2.2 FraçãoMP <sub>10-2,5</sub> .....	66
5.3 Discussão dos Resultados.....	72
CAPÍTULO 6 CONCLUSÕES E RECOMENDAÇÕES .....	74
6.1 Conclusões.....	74
6.2 Sugestões para Trabalhos Futuros .....	75
REFERÊNCIAS BIBLIOGRÁFICAS .....	77

ANEXOS .....	84
Anexo 1 .....	85
Trabalhos publicados pelo grupo de pesquisa sobre o tema “Poluição Atmosférica e Monitoramento de Qualidade do Ar” .....	85
Anexo 2 .....	90
Interface do Tinn-R e do R .....	90
Anexo 3 .....	91
Dados coletas com amostrador AGV para concentração de $MP_{10}$ .....	91
Anexo 4 .....	97
Dados coletas com amostrador Dicotômico para concentração de $MP_{2,5}$ .....	97
Anexo 5 .....	99
Dados coletas com amostrador Dicotômico para concentração de $MP_{10-2,5}$ .....	99
Anexo 6 .....	101
Mean Absolute Percentage Error (MAPE) .....	101
Root Mean Square Deviation .....	101
Anexo 7 .....	102
Resultados dos 10 modelos com menor valor de AIC para a série de dados do $MP_{10}$ ..	102
Anexo 8 .....	115
Resultados dos 10 modelos com menor valor de AIC para a série de dados do $MP_{2,5}$ ..	115
Anexo 9 .....	129
Resultados dos 10 modelos com menor valor de AIC para a série de dados do $MP_{10-2,5}$ ..	129

## LISTA DE FIGURAS

Figura 1 - Distribuição bimodal do MP, adaptado de Celli (1999).....	10
Figura 2 - Aparelho respiratório humano (adaptado de Hinds, 1999).....	16
Figura 3 – Gráfico explicativo do Box-Plot .....	19
Figura 4 - Localização do município de São Carlos no Estado de São Paulo e no Brasil.....	36
Figura 5 - Relevo elevado da área de São Carlos (Oliveira, 1996).....	38
Figura 6 – Densidade populacional do município de São Carlos (Oliveira, 1996).....	39
Figura 7 – Mapa do município de São Carlos destacando a localização da estação de coleta.	40
Figura 8 - Localização da estação de coleta e monitoramento.....	41
Figura 9 - Estação amostradora no centro da cidade de São Carlos.....	41
Figura 10 - Amostrador de Grandes Volumes AGV MP <sub>10</sub> .....	42
Figura 11 - Cabeçote de separação do AGV MP <sub>10</sub> com detalhe dos 9 bocais (a) e detalhe do filtro sujo no equipamento (b) .....	43
Figura 12 - Filtros para amostragem em dicotômico antes (a) e após a coleta de MP <sub>10-2,5</sub> (b) e MP <sub>2,5</sub> (c).....	44
Figura 13 - Foto do amostrador dicotômico na estação de monitoramento (a) e com detalhe do painel de controle de pressão e vazão (b) .....	45
Figura 14 - Esquema de funcionamento do amostrador dicotômico .....	45
Figura 15 - Dados de monitoramento de MP <sub>10</sub> realizado com AGV MP <sub>10</sub> .....	49
Figura 16 - Box-plot para a série MP <sub>10</sub> .....	50
Figura 17 - Série temporal e valores usados para a validação do modelo da série MP <sub>10</sub> .....	50
Figura 18 - Dados de monitoramento de MP <sub>2,5</sub> realizado com Amostrador Dicotômico.....	51
Figura 19 - Box-plot para a série MP <sub>2,5</sub> .....	52
Figura 20 - Série temporal e valores usados para a validação do modelo da série MP <sub>2,5</sub> .....	53
Figura 21 - Dados de monitoramento de MP <sub>10-2,5</sub> realizado com Amostrador Dicotômico .....	53
Figura 22 - Box-plot para a série MP <sub>10-2,5</sub> .....	54
Figura 23 - Série temporal e valores usados para a validação do modelo da série MP <sub>10-2,5</sub> .....	55
Figura 24 – Teste de estacionariedade da série MP <sub>10</sub> . Funções de autocorrelação –FAC (a) da série transformada e suas diferenças de ordem 1 (b) e de ordem 2 (c).....	57
Figura 25 - Teste de normalidade da série MP <sub>10</sub> .....	58
Figura 26 - Teste de Ljung-Box (a) e resíduos (b) para o modelo M3.....	60
Figura 27 – Funções de autocorrelação (FAC) e autocorrelação parcial (FACP) para o modelo M3.....	61
Figura 28 - Teste de normalidade do modelo M3 .....	61
Figura 29 - Valores preditos pelo modelo M3.....	62
Figura 30 – Teste de estacionariedade da série MP <sub>2,5</sub> . Funções de autocorrelação –FAC (a) da série transformada e suas diferenças de ordem 1 (b), de ordem 2 (c) e de ordem 3 (d)...	63
Figura 31 - Teste de normalidade da série MP <sub>2,5</sub> .....	63
Figura 32 - Teste de Ljung-Box e resíduos para o modelo M1 .....	65
Figura 33 - Teste de Ljung-Box e resíduos para o modelo M3.....	65
Figura 34 – Funções de autocorrelação (FAC) e autocorrelação parcial (FACP) para o modelo M1.....	66
Figura 35 - Teste de normalidade do modelo M1 .....	66
Figura 36 – Teste de estacionariedade da série MP <sub>10-2,5</sub> . Funções de autocorrelação –FAC (a) da série transformada e suas diferenças de ordem 1 (b) e de ordem 2 (c).....	67
Figura 37 - Teste de normalidade da série MP <sub>10-2,5</sub> .....	67
Figura 38 - Teste de Ljung-Box e resíduos para o modelo M1.....	69
Figura 39 - Teste de Ljung-Box e resíduos para o modelo M8.....	69

Figura 40 – Funções de autocorrelação (FAC) e autocorrelação parcial (FACP) para o modelo M1.....	70
Figura 41 - Teste de normalidade do modelo M1 .....	70
Figura 42 - Modelo, previsão e respectivos intervalos de confiança para $MP_{2,5}$ .....	71
Figura 43 - Modelo, previsão e respectivos intervalos de confiança para $MP_{10-2,5}$ .....	72

## LISTA DE TABELAS

Tabela 1 – Padrões nacionais de qualidade do ar (Resolução CONAMA N° 03/90).....	8
Tabela 2 – Comparação entre padrões internacionais de MP <sub>10</sub> . Adaptada de CELLI (1999)..	12
Tabela 3 – Comparação entre a fração fina e a fração grossa do MP (Pozza, 2005) .....	12
Tabela 4 - Comparação dos modelos obtidos com menor AIC.....	59
Tabela 5 - Análise estatística dos parâmetros dos modelos.....	59
Tabela 6 - Comparação com Holt-Winters.....	62
Tabela 7 - Comparação dos modelos obtidos com menor AIC para dados da série MP <sub>2,5</sub> .....	64
Tabela 8 - Análise estatística dos parâmetros dos modelos.....	64
Tabela 9 - Comparação dos modelos obtidos com menor AIC para dados da série MP <sub>10-2,5</sub> ...	67
Tabela 10 - Análise estatística dos parâmetros dos modelos.....	68
Tabela 11 - Comparação com Holt-Winters.....	71
Tabela 12 - Comparação dos modelos obtidos com menor AIC.....	102
Tabela 13 - Análise estatística dos parâmetros dos modelos da série MP <sub>10</sub> .....	102
Tabela 14 – Valores dos erros calculados para os 10 modelos com menor AIC para dados da série MP <sub>10</sub> .....	103
Tabela 15 - Comparação dos modelos obtidos com menor AIC para dados da série MP <sub>2,5</sub> ..	115
Tabela 16 - Análise estatística dos parâmetros dos modelos.....	115
Tabela 17 - Valores dos erros calculados para os 10 modelos com menor AIC para dados da série MP <sub>2,5</sub> .....	117
Tabela 18 - Comparação dos modelos obtidos com menor AIC para dados da série MP <sub>10-2,5</sub> .....	129
Tabela 19 - Análise estatística dos parâmetros dos modelos.....	129
Tabela 20 - Valores dos erros calculados para os 10 modelos com menor AIC para dados da série MP <sub>10-2,5</sub> .....	130

**NOMENCLATURA**

<b>ABNT</b>	Associação Brasileira de Normas Técnicas
<b>AGV/MP10</b>	Amostrador de grandes volumes - partículas com diâmetro aerodinâmico menor ou igual a 10 $\mu\text{m}$
<b>AIC</b>	Akaike Information Criterion - Critério de Informação de Akaike
<b>AR (p)</b>	Modelo auto-regressivo
<b>ARIMA (p,d,q)</b>	Modelo auto-regressivo integrado
<b>ARMA (p,q)</b>	Modelo auto-regressivo de média móvel
<b>at</b>	Ruído branco
<b>B</b>	Constante que define o modelo
<b><math>B</math> e <math>B^S</math></b>	Operadores de retrocesso
<b>CETESB</b>	Companhia Estadual de Tecnologia e Saneamento Ambiental (órgão de proteção ambiental do Estado de São Paulo)
<b>CID</b>	Código Internacional de Doenças
<b>CONAMA</b>	Conselho Nacional do Meio Ambiente
<b>d</b>	Número de diferenças não sazonais
<b>D</b>	Número de diferenças sazonais
<b>DEQ/UFSCar</b>	Departamento de Engenharia Química/Universidade Federal de São Carlos
<b>FAC</b>	Função de auto correlação
<b>FACP</b>	Função de auto correlação parcial
<b>FEEMA</b>	Fundação Estadual de Engenharia de Meio Ambiente -RJ
<b>IBAMA</b>	Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis
<b>IBGE</b>	Instituto Brasileiro de Geografia e Estatística
<b><math>I_t</math></b>	Índice Sazonal no tempo “t” para Holt-Winters
<b><math>L_t</math></b>	Nível no tempo “t” para Holt-Winters
<b>OMS</b>	Organização Mundial de Saúde
<b>MAA</b>	Média Aritmética Anual
<b>MAG</b>	Modelos Aditivos Generalizados
<b>MA (q)</b>	Médias móveis de ordem “q”
<b>MAPE</b>	Mean Absolute Percentage Error
<b>MGA</b>	Média Geométrica Anual

<b>MLG</b>	Modelos Lineares Generalizados
<b>MP</b>	Material Particulado
<b>MP<sub>10</sub></b>	Material Particulado com diâmetro aerodinâmico igual a 10 µm ou menor
<b>MP<sub>10-2,5</sub></b>	Material Particulado com diâmetro aerodinâmico entre 2,5 µm e 10 µm
<b>MP<sub>2,5</sub></b>	Material Particulado com diâmetro aerodinâmico igual a 2,5 µm ou menor
<b>PTS</b>	Partículas Totais em Suspensão
<b>R</b>	Número de períodos previstos para Holt-Winters
<b>S</b>	Período sazonal da série
<b>SARIMA (P,D,Q)</b>	Modelo auto-regressivo integrado sazonal
<b>SISNAMA</b>	Sistema Nacional do Meio Ambiente
<b>SPSS</b>	Statistical Package for the Social Sciences
<b>t</b>	Índice do tempo
<b>T<sub>t</sub></b>	Tendência no tempo “t” para Holt-Winters
<b>USEPA</b>	United States Environmental Protection Agency (órgão de proteção ambiental dos Estados Unidos)
<b>Z<sub>t</sub></b>	Observações da série
<b>Y</b>	Notação de valores de séries temporais
<b>W<sub>t</sub></b>	D’ésima diferença da variável de interesse z <sub>t</sub> ;

### **Símbolos Gregos**

$\gamma(t_1, t_2)$	Autocovariância
$\varepsilon_t$	“ruído branco” ou erro aleatório ( $\varepsilon_t \sim N(0,1)$ )
$\theta(B)$	Operador de médias móveis
$\Theta(B^S)$	Operador de médias móveis sazonal
$\sigma^2$	Variância
$\varphi(B)$	Operador auto-regressivo
$\Phi(B^S)$	Operador auto-regressivo sazonal
$\mu_t$	Média

## RESUMO

A cidade de São Carlos, uma cidade de porte médio do estado de São Paulo, pode ser considerada como representativa da região sudeste brasileira, com atividades agrícolas praticamente equivalente às atividades industriais. Dentro desse perfil, possui uma série de fontes de poluição atmosférica, que incluem uma frota considerável de veículos automotores, queimadas agrícolas e emissões industriais diversas. A evolução temporal desta poluição ambiental tem sido motivo de preocupação, uma vez que pode causar danos à saúde humana e ao meio ambiente. O presente trabalho estudou estas características temporais, especificamente para o caso de material particulado (MP) em suspensão na atmosfera, a partir de dados experimentais e através de modelos estatísticos. Foram coletadas e analisadas as concentrações de  $MP_{10}$ ,  $MP_{2,5}$  e  $MP_{10-2,5}$  na cidade de São Carlos. O período de estudos compreende os dados de 1997 a 2006 para o  $MP_{10}$  e de 2001 a 2006 para  $MP_{2,5}$  e  $MP_{10-2,5}$ . Foram usadas médias mensais para a obtenção dos modelos e os 30 (trinta) ou 6 (seis) dados finais foram usados para a validação da previsão. A seleção do melhor modelo foi feita buscando o menor valor de AIC (Critério de Informação de Akaike), por meio da variação sucessiva dos parâmetros. Dos 10 modelos com menor valor de AIC, foram escolhidos o de menor valor e outros com um menor número de parâmetros. Na análise estatística, ocorreu a eliminação de modelos que não atenderam aos requisitos de testes de Shapiro-Wilk (normalidade) e de estacionariedade. Nos três casos, a comparação com Holt-Winters confirma que os modelos SARIMA representaram melhor os conjuntos de dados estudados. O modelo encontrado para a série de dados de  $MP_{10}$  foi o  $SARIMA(1,0,0) \times (1,0,1)_6$ . No segundo caso, a concentração de  $MP_{2,5}$  o melhor modelo encontrado foi o  $SARIMA(2,1,3) \times (1,0,1)_6$ . No terceiro caso, a concentração de  $MP_{10-2,5}$ , o modelo encontrado foi o  $SARIMA(2,0,2) \times (1,0,0)_6$ .

## ***Time Characteristics of the Atmospheric Particulate Matter Concentration in the City of São Carlos - SP***

### **ABSTRACT**

The city of São Carlos, of medium size of São Paulo State, can be considered as representative of the Brazilian Southeast area, with agricultural activities practically equivalent to the industrial ones. As part of that profile, it possesses a series of sources of atmospheric pollution that include a considerable fleet of vehicles, agricultural burns and several industrial emissions. The time evolution of this environmental pollution has been reason of concern, once it can cause damages to the human health and to the environment. The present work studied these time characteristics, specifically for the case of particulate matter (PM) suspended in the atmosphere, from experimental data and through statistical models. The concentrations of  $PM_{10}$ ,  $PM_{2.5}$  and  $PM_{10-2.5}$  in the city of São Carlos were collected and analyzed. The period of study comprises the years from 1997 to 2006 for  $PM_{10}$  and from 2001 to 2006 for  $PM_{2.5}$  and  $PM_{10-2.5}$ . Monthly averages were used for obtaining the models and the 30 (thirty) or 6 (six) final data were used for the validation of the forecast. The selection of the best model was made considering the smallest value of AIC (Akaike Information Criterion), through the successive variation of the parameters. Of the 10 models with smaller value of AIC, was chosen the one of smaller value and other with a smaller number of parameters. In the statistical analysis, the models that did not comply with the requirements of the Shapiro-Wilk tests (normality) and of steadiness were eliminated. In the three cases the model SARIMA represented the groups of studied data better, when compared with the Holt-Winters correlation. The model found for the series of data of  $PM_{10}$ , was the  $SARIMA(1,0,0) \times (1,0,1)_6$ . In the second case, the concentration of  $PM_{2.5}$  the best model was the  $SARIMA(2,1,3) \times (1,0,1)_6$ . In the third case, the concentration of  $PM_{10-2.5}$ , the best model was the  $SARIMA(2,0,2) \times (1,0,0)_6$ .

## **CAPÍTULO 1 INTRODUÇÃO**

### **1.1 Considerações Gerais**

O aumento populacional e da atividade humana, em áreas urbanas de países em desenvolvimento têm provocado situações de impacto ambiental que englobam problemas sociais, habitacionais, econômicos, de saneamento básico e de poluição das águas, solo e ar (Brasseur *et al.*, 1999).

A poluição do ar provavelmente acompanha a humanidade desde tempos remotos. No entanto, passou a ser sentida de forma acentuada quando as pessoas começaram a viver em assentamentos urbanos de grande densidade demográfica, em consequência da Revolução Industrial, a partir de quando o carvão mineral começou a ser utilizado como fonte de energia (Phillippi *et al.*, 2004). Também é um dos impactos ambientais mais significativos e seus efeitos afetam de diversas formas a saúde humana, os ecossistemas e os materiais. Este impacto é decorrente das altas concentrações de poluentes gasosos e particulados, que são quantitativamente medidas em estações de monitoramento.

O problema da concentração de poluentes na área urbana não está ligado apenas à sua produção, isto é, à utilização de veículos ou emissão industrial, mas também à sua dispersão e remoção, a primeira delas causada pela movimentação das massas de ar e a segunda realizada por chuvas, deposição seca, fotólise e outros tipos de reações químicas (Freitas, 2003). As reações químicas na atmosfera podem transformar os poluentes primários em poluentes secundários. Também se verifica que o clima tem grande influência na dispersão dos poluentes gasosos ou particulados presentes no ar, assim como a geometria das edificações também têm um papel a desempenhar. Entre os fatores climáticos diretamente relacionados com a dispersão, os mais significativos são o perfil vertical de temperatura e a velocidade e direção dos ventos.

Apesar de um número imenso de episódios de poluição atmosférica, desde a década de 30, identificados principalmente na Europa, somente nos anos 90 surgiu uma consciência ambiental mundial, com a participação de governantes, grupos ambientalistas, população em geral, de que certas medidas eram necessárias, dentre elas: diminuição da produção de lixo e uso racional de recursos e desenvolvimento de produtos que não agredissem o meio ambiente (Miranda, 2001).

Dentre os poluentes atmosféricos, o material particulado em suspensão possui importância significativa, devido à complexa composição química e suas propriedades físicas.

Material Particulado é o termo genérico usado para a mistura de partículas sólidas ou líquidas em suspensão no ar atmosférico. De acordo com a origem, as partículas em suspensão são classificadas como primárias e secundárias. As partículas primárias se originam da ressuspensão de poeira e na combustão nos veículos, e as secundárias são formadas a partir de gases da combustão, que reagem com o vapor de água na atmosfera (EPA, 2006). Em relação às fontes emissoras não naturais, os veículos apresentam participação significativa na emissão de material particulado. Citando os dados de 2007 da Região Metropolitana de São Paulo (CETESB, 2008), os veículos leves tiveram participação de 12% e os veículos pesados 28%.

O conhecimento do diâmetro da partícula tem importância por este ser um indicativo da fonte emissora, além de se relacionar com o local da deposição no trato respiratório (Marques, 2000). As partículas têm diâmetros de 0,001 a 500  $\mu\text{m}$ , sendo a maior parte situada no intervalo de 0,1 a 10  $\mu\text{m}$ . As partículas de maiores dimensões são menos prejudiciais à saúde, já que se depositam no solo em poucas horas, em função da ação da gravidade. O mesmo não ocorre com as partículas com menores dimensões, que são pequenas o suficiente para permanecerem em suspensão na atmosfera, movendo-se juntamente com o gás e, na prática, não se depositam no solo, permanecendo na atmosfera por horas ou até dias, podendo viajar por distâncias consideráveis a partir da fonte (Carvalho e Lacava, 2003).

Alguns estudos indicam que as partículas com diâmetros maiores que 10  $\mu\text{m}$  ficam retidas no aparelho respiratório superior (nariz, faringe, laringe e traquéia). Porém, partículas menores podem alcançar o pulmão e sedimentar nos alvéolos e na região traqueobronquial (Hinds, 1999).

Além dos problemas relacionados à saúde, o material particulado prejudica o meio ambiente ao modificar os balanços químicos e de nutrientes em corpos d'água, podendo também causar erosão e manchas em estruturas e monumentos. Conforme Cappiello (2002), o material particulado é a causa principal da redução da visibilidade em muitas partes dos EUA, alterando os níveis de radiação solar que atingem o solo. Em função dessa redução na radiação solar, as partículas alteram a temperatura do solo e influenciam negativamente o crescimento das plantas (Carvalho e Lacava, 2003).

Modelos estatísticos são muito utilizados e de muita importância no que se refere aos estudos sobre poluição, seja atmosférica ou não. A utilização de modelos matemáticos e técnicas estatísticas aliadas às ferramentas computacionais possibilitam um entendimento de muitos fenômenos com os quais nos deparamos no dia a dia (Guimarães, 2006).

Os processos ambientais, incluindo a poluição atmosférica, que são o foco principal nessa pesquisa, são causados por uma infinidade de outros processos desconhecidos e interdependentes, tornando a modelagem dos mesmos uma tarefa difícil. Favoravelmente na natureza, em geral, não ocorrem mudanças abruptas. Processos ambientais são, em sua maioria, contínuos no tempo e no espaço variando, portanto de forma suave em ambas as dimensões. A distribuição espaço temporal desses processos pode ser atribuída a uma combinação de outros processos humanos e naturais (também contínuos), que operam em diferentes escalas espaciais e temporais.

A cidade de São Carlos possui uma estação de monitoramento na região central que vem coletando a concentração de material particulado desde 1997, o que permitiu a obtenção de série temporal com as concentrações desse poluente. Uma série temporal é um conjunto de observações de uma determinada variável aleatória gerada seqüencialmente ao longo do tempo (Morettin e Tolo, 2006). A análise estatística por séries temporais permite descrever o comportamento geral dos dados e também possibilita a realização de previsões de comportamentos futuros (Ehlers, 2005). Séries temporais de material particulado têm sido usadas para verificar a relação de sua concentração com doenças respiratórias (Oliveira *et al.*, 2003; Conceição *et al.*, 2001; Dominici *et al.*, 2002) e para a previsão da tendência da concentração (Lima *et al.*, 2006). Estimar a tendência de uma série temporal de dados ambientais possibilita a tomada de decisões quanto à emissão de poluentes antes que as concentrações limite sejam atingidas, ou então ajudam na decisão sobre a criação e ampliação de redes de monitoramento (Stock e Watson, 1988).

Vários métodos de previsão de séries temporais estão disponíveis, como o de médias móveis (MA), regressão linear com o tempo, suavização exponencial de Holt-Winters e os modelos ARIMA. Os modelos ARIMA, robustos do ponto de vista conceitual e estatístico, proporcionam previsões probabilísticas, apresentando certa facilidade de implantação. Esses modelos apresentam diversas vantagens em relação a outros modelos, como alisamento exponencial e redes neurais, em particular em sua capacidade de previsão e a grande quantidade de informações sobre mudanças relacionadas ao tempo (Mishra e Desai, 2005).

## 1.2 Objetivos

Este estudo teve como objetivo estudar as características temporais da concentração de Material Particulado (MP) respirável suspensos na atmosfera de São Carlos-SP (MP<sub>10</sub> MP<sub>10-2,5</sub> e MP<sub>2,5</sub>), através da modelagem estatística. Para isso, foram usados modelos de séries

temporais ARIMA sobre os dados coletados por estudos da concentração de material particulado atmosférico, no período entre 1997 e 2006.

A partir disto verificou-se:

- a capacidade de predição destes modelos;
- a qualidade dos modelos;
- o comportamento dos dados previstos, se seguem os padrões aceitos pela Legislação vigente para a qualidade do ar respirável.

### **1.3 Estrutura do trabalho**

O trabalho está dividido em cinco capítulos, além dessa Introdução.

O CAPÍTULO 2 traz uma revisão da literatura existente sobre a poluição atmosférica, definições de MP e suas frações. Aborda ainda os efeitos gerais da poluição do ar na saúde humana e meio ambiente em geral. Apresenta a Legislação Ambiental pertinente (mundial, nacional e estadual). Na parte final, relata as principais definições e detalhamentos a respeito das séries temporais e seus modelos, assim como trabalhos anteriores acerca do tema.

O CAPÍTULO 3 apresenta a metodologia desenvolvida nesta pesquisa, justificando a adoção das variáveis de trabalho, as condições em que foram obtidas e os métodos utilizados para sua obtenção. Descreve a fase de coleta de dados na área central da cidade de São Carlos.

O CAPÍTULO 4 apresenta o tratamento preliminar dos dados relativos às informações coletadas na estação de monitoramento.

O CAPÍTULO 5 apresenta e discute os resultados da modelagem estatística dos dados anteriormente tratados para cada fração do MP, bem como a discussão dos mesmos.

O CAPÍTULO 6 resume as principais conclusões e apresenta recomendações para trabalhos futuros.

## CAPÍTULO 2 REVISÃO BIBLIOGRÁFICA

### 2.1 Aerossóis atmosféricos e material particulado (MP)

As partículas microscópicas que flutuam no ar têm diversas origens: ressuspensão de solo, emissões de indústrias, partículas fotoquimicamente formadas, partículas salinas formadas de ‘sprays’ oceânicos, nuvens atmosféricas de gotículas de água ou gelo, etc. Elas variam consideravelmente nas suas habilidades em afetar não somente visibilidade e clima, mas também nossa saúde e qualidade de vida. Estes todos são exemplos de aerossóis (Hinds, 1999).

Aerossóis são suspensões de pequenas partículas sólidas ou líquidas em gases (Hinds, 1999). Eles são formados pela conversão de gases a partículas ou por desintegração de líquido ou sólido. Eles podem também resultar da ressuspensão de material empoeirado ou dissolução de aglomerados (Friedlander, 2000). Podem ser subdivididos de acordo com a forma física das partículas e seus métodos de geração (Hinds, 1999). Consideraremos material particulado (MP), somente os sólidos em suspensão.

A ciência dos aerossóis iniciou-se com as experiências de Tyndall em 1869 e pela teoria do espalhamento da luz de Rayleigh em 1871. O estudo sobre a mecânica das partículas iniciou-se com Aitken em 1884 e os primeiros trabalhos sobre nucleação foram feitos por Wilson em 1897. A compreensão das interações foi desenvolvida tanto nos estudos de propriedades físicas e químicas dos aerossóis, quanto no desenvolvimento de modelos que descrevem seu comportamento macroscópico. Atualmente o estudo de aerossóis encontra-se bastante avançado não apenas por razões científico-acadêmicas, mas, sobretudo, pela importância do papel deste sistema físico na poluição do ar (Andrade, 1986).

A origem destas partículas pode ser natural (ressuspensão de poeira do solo, “spray” marinho) ou antropogênica, que é proveniente de atividades humanas, com as fontes fixas (industriais e agrícolas) e as fontes automotoras móveis (combustão de gasolina e diesel).

Além de algumas implicações na visibilidade e no clima, os aerossóis têm impactos significativos na saúde. Os efeitos adversos da poluição na saúde são mais notados em crianças, idosos e em pessoas que sofrem de doenças respiratórias e cardiovasculares. Nestas pessoas, os poluentes levam a um agravamento nas doenças de base, promovendo infecções mais graves como bronquites, pneumonia, asma, câncer, chegando até a morte (Seinfeld, 1986; Castanho, 1999; Braga *et al.*, 2002).

O diâmetro da partícula é frequentemente expresso em termos de seu diâmetro aerodinâmico, que pode ser definido como o diâmetro de densidade unitária que possua a mesma velocidade de sedimentação que a partícula estudada (Friedlander, 2000). As partículas grandes com diâmetro superior a 100  $\mu\text{m}$  não permanecem por muito tempo em suspensão e tende a se precipitar rapidamente, um exemplo são as gotas de chuva (Arbex, 2001). De outro modo, as partículas suspensas na atmosfera que possuem diâmetro aerodinâmico menor que 100  $\mu\text{m}$ , denominadas inaláveis, se caracterizam pelo fato de que boa parte desta fração fica no trato respiratório superior. As partículas de maior importância para os aspectos físico-químicos da atmosfera e para a saúde humana são as de diâmetro compreendido entre 0,002  $\mu\text{m}$  a 10  $\mu\text{m}$ . Aquelas consideradas respiráveis ( $\text{MP}_{10}$ ) possuem diâmetro aerodinâmico menor que 11,6  $\mu\text{m}$  (absorvidos no trato torácico). As menores que 4,25  $\mu\text{m}$  em sua grande maioria de origem antropogênica, alcançam o pulmão (ACCGIH – American Conference of Governmental Industrial Hygienists, Apud Celli, 1999).

Dados de concentração de várias cidades nos Estados Unidos indicam que a poeira ressuspena é o maior componente da fração  $\text{MP}_{10}$  indicado pela grande quantidade de alumínio e silício presenteem todas as cidades amostradas. A fração  $\text{MP}_{10}$  é muito menos ativa quimicamente com relação à fração  $\text{MP}_{2,5}$  (Friedlander, 2000).

Para atingir esses objetivos, torna-se necessária à fixação de padrões de qualidade do ar. Em virtude da necessidade de limites para emissão de poluentes, algumas leis para a qualidade do ar vêm sendo implantadas em níveis mundial, nacional e regional, tornando-se progressivamente mais restritivas (CETESB, 2008).

## **2.2 Padrões de Qualidade do Ar e Legislação Ambiental**

As primeiras preocupações legais no Brasil foram consolidadas a partir da década de 80. A Lei n° 6938, de 31 de agosto de 1981, que dispõe sobre a Política Nacional do Meio Ambiente e o Sistema Nacional de Meio Ambiente (SISNAMA), estabeleceu os princípios e objetivos dessa Política e considerou o meio ambiente como “patrimônio público a ser necessariamente assegurado e protegido, tendo em vista o uso coletivo”. Com fundamento nos dispositivos desta Lei, o Conselho Nacional do Meio Ambiente (CONAMA), por ela criada, passou a editar normas administrativas relativas à proteção ambiental.

Através da Portaria Normativa n° 348 de 14/03/90 o IBAMA (Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis) estabeleceu os padrões nacionais de

qualidade do ar e os respectivos métodos de referência, ampliando o número de parâmetros anteriormente regulamentados através da Portaria GM 0231 de 27/04/76.

Os padrões estabelecidos através dessa portaria foram submetidos ao CONAMA em 28/06/90 e transformados na Resolução CONAMA nº03/90. Esta resolução estabelece padrões de qualidade atmosférica e amplia o número de poluentes atmosféricos passíveis de monitoramento e controle.

O CONAMA, na já referida Resolução 03/90, artigo 1, define poluente atmosférico como qualquer forma de matéria ou energia, com intensidade, em quantidade ou concentração, tempo ou característica em desacordo com os níveis estabelecidos, e que possam tornar o ar:

- impróprio, nocivo ou ofensivo à saúde;
- inconveniente ao bem estar público;
- danoso aos materiais, fauna e flora.

São estabelecidos dois tipos de padrões de qualidade do ar: os primários e os secundários (CETESB, 1989).

São padrões primários de qualidade do ar as concentrações de poluentes que, ultrapassadas, poderão afetar a saúde da população. Podem ser entendidos como níveis máximos toleráveis de concentrações de poluentes atmosféricos, constituindo-se em metas de curto e médio prazo.

São padrões secundários de qualidade do ar as concentrações de poluentes atmosféricos abaixo das quais se prevê um mínimo efeito adverso sobre o bem estar da população, assim como o mínimo dano à fauna e à flora, aos materiais e ao meio ambiente em geral. Podem ser entendidos como níveis desejados de concentração de poluentes, constituindo-se em meta de longo prazo.

A Legislação Estadual (DE 8468 de 08/09/76) também estabelece padrões de qualidade do ar e critérios para episódios agudos de poluição do ar, mas abrange um número menor de parâmetros. Os parâmetros fumaça, partículas inaláveis e dióxido de nitrogênio não têm padrões e critérios estabelecidos na Legislação Estadual. Os parâmetros comuns às legislações federal e estadual têm os mesmos padrões e critérios.

Os padrões regulamentados são os seguintes: partículas totais em suspensão, fumaça, partículas inaláveis, dióxido de enxofre, monóxido de carbono, ozônio e dióxido de

nitrogênio. Os padrões de qualidade do ar fixados na Resolução CONAMA nº 03/90 são apresentados na Tabela 1. Estes padrões foram estabelecidos levando-se em consideração os efeitos adversos à saúde da população, dificuldade de visibilidade entre outros.

Tabela 1 – Padrões nacionais de qualidade do ar (Resolução CONAMA Nº 03/90)

POLUENTE	TEMPO DE AMOSTRAGEM	PADRÃO PRIMÁRIO ( $\mu\text{g}/\text{m}^3$ )	PADRÃO SECUNDÁRIO ( $\mu\text{g}/\text{m}^3$ )	MÉTODO DE MEDIÇÃO
Partículas totais em suspensão	24 horas <sup>1</sup> MGA <sup>2</sup>	240 80	150 60	Amostrador de grandes volumes
Partículas inaláveis	24 horas <sup>1</sup> MAA <sup>3</sup>	150 50	150 50	Separação inercial/filtração
Fumaça	24 horas <sup>1</sup> MAA <sup>3</sup>	150 60	100 40	Refletância
Dióxido de enxofre	24 horas <sup>1</sup> MAA <sup>3</sup>	365 80	100 40	Pararosalina
Dióxido de nitrogênio	1 hora <sup>1</sup> MAA <sup>3</sup>	320 100	190 100	Quimiluminescência
Monóxido de carbono	1 hora <sup>1</sup> 8 horas <sup>1</sup>	40.000/35ppm 10.000/9ppm	40.000/35ppm 10.000/9ppm	Infravermelho não dispersivo
Ozônio	1 hora <sup>1</sup>	160	160	Quimiluminescência

1-Não deve ser excedido mais que uma vez ao ano

2-Média geométrica anual

3-Média aritmética anual

O modo usual de classificação do material particulado suspenso na atmosfera refere-se ao seu tamanho, normalmente dividindo-o em frações. Considerando que as partículas são usualmente não esféricas, existe um grande número de definições de tamanho. Na área ambiental, a definição de tamanho mais utilizada é o diâmetro aerodinâmico. Uma partícula com diâmetro aerodinâmico de 10  $\mu\text{m}$  move-se num gás de modo análogo a uma esfera de densidade unitária ( $1 \text{ g}/\text{cm}^3$ ) desse mesmo diâmetro. O material particulado atmosférico tem seu tamanho normalmente situado na faixa de 1 nm a 100  $\mu\text{m}$ . Essas dimensões abrangem tamanhos da ordem molecular até tamanhos em que a partícula deposita-se rapidamente pela ação da gravidade. Do ponto de vista de exposição humana, a faixa de tamanho entre 10 e 0,1  $\mu\text{m}$  é a mais estudada. Isso porque somente partículas menores que 10  $\mu\text{m}$  são pequenas suficiente para penetrar no sistema respiratório (fração torácica) e são potencialmente prejudiciais à saúde. Dessa fração, as partículas com diâmetro menor que 2,5  $\mu\text{m}$  (fração respirável) podem atingir os alvéolos pulmonares e afetam especialmente os idosos e recém nascidos. A partir dessas constatações, a legislação definiu as frações de material particulado atmosférico de importância ambiental.

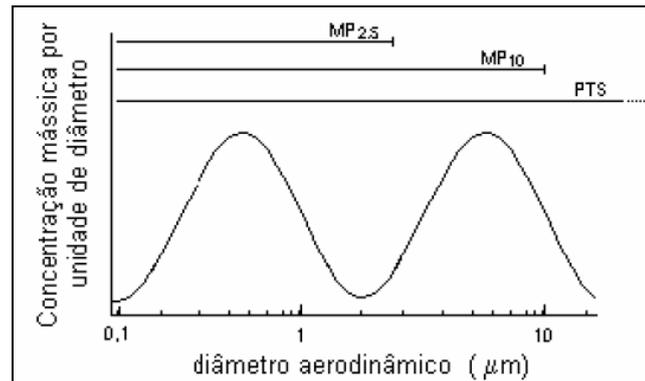
O primeiro padrão de qualidade do ar referente às partículas totais em suspensão (PTS) foi criado em 1971 nos Estados Unidos. Somente em 1987 a agência americana de

proteção do meio ambiente (USEPA - United States Environmental Protection Agency) promulgou o padrão para material particulado inalável (que podem alcançar as regiões mais baixas do trato respiratório), o padrão  $MP_{10}$ .

A notação  $MP_{10}$ , usualmente definida pela USEPA (2009), é usada para descrever partículas com de diâmetro aerodinâmico igual ou menor que 10  $\mu\text{m}$ . Da mesma forma,  $MP_{2,5}$  aplica-se a partículas com de diâmetro aerodinâmico igual ou menor que 2,5  $\mu\text{m}$ . A fração  $MP_{10-2,5}$  refere-se à diferença entre  $MP_{10}$  e  $MP_{2,5}$ , ou seja, inclui apenas a fração mais grossa do  $MP_{10}$ .

Os efeitos principais referentes à exposição do  $MP_{10}$  com relação à saúde humana são: danos ao tecido do pulmão, câncer e morte prematura. As crianças, idosos e pessoas com doenças pulmonares ou asma crônica são mais sensíveis aos efeitos destas partículas. Os estudos mais atuais sugeriram que as partículas finas (menores que 2,5  $\mu\text{m}$  de diâmetro) podem causar efeitos de saúde adversos mais sérios. Em consequência disso a USEPA ajustou um novo padrão, o  $MP_{2,5}$  (EPA, 2009). A Figura 1 apresenta uma comparação entre estas frações (PTS,  $MP_{10}$  e  $MP_{2,5}$ ), ilustrando os tamanho as quais as partículas se referem. Ainda nesta figura se apresenta um esquema idealizado de distribuição bimodal de material particulado suspenso em atmosferas urbanas, em função do diâmetro aerodinâmico e da concentração mássica por unidade de diâmetro (Celli, 1999). Também é apresentado o padrão  $MP_{2,5}$  (partículas com diâmetro aerodinâmico de 2,5  $\mu\text{m}$  ou menores), salientando a necessidade da implantação de um padrão para esta fração no Brasil, já que quando nos referimos a problemas ambientais ele é mais patogênico (Bruno, 2005).

A distribuição do tamanho das partículas é ditada pelo processo que gera o aerossol. As partículas inaláveis grossas resultam de processos mecânicos, operações de moagem e ressuspensão de poeira. Materiais geológicos tendem a dominar essa moda. As partículas inaláveis finas são, geralmente, emitidas por atividades como: combustão industrial e residencial, exaustão de veículos automotores, etc. Elas também se formam na atmosfera a partir de reações químicas de gases como  $SO_2$ ,  $NO_x$  e compostos orgânicos voláteis que são emitidos, principalmente, em atividades de combustão.



**Figura 1** - Distribuição bimodal do MP, adaptado de Celli (1999).

As partículas pertencentes à moda grossa possuem baixas concentrações e tamanhos maiores. Em função dessas condições, estas partículas primárias normalmente não coagulam entre si, mas outras espécies podem se misturar a elas por meio de troca de massa com a fase gasosa. Em função de seu tamanho, estas partículas grossas são rapidamente removidas pelo processo de lavagem atmosférica através da precipitação. Sua composição química reflete a sua origem, predominando os compostos inorgânicos como poeira e sal marinho. A maioria das partículas biológicas como esporos e pólen também tendem a se encontrar na moda grossa (Ynoue, 2004). As partículas inaláveis finas penetram mais profundamente no trato respiratório, sendo que as partículas menores que  $0,5 \mu\text{m}$  podem se depositar nos alvéolos pulmonares.

Pode-se verificar algumas equivalências entre os padrões nacionais (IBAMA) e USEPA (United Environmental Protection Agency) na

Tabela 2. No Brasil ainda não existe um padrão estabelecido para o  $MP_{2,5}$ . Para fins de estudo utiliza-se o padrão proposto pela USEPA, que define a concentração máxima permitida em medições de 24 horas de  $65 \mu\text{g}/\text{m}^3$  e a média anual de  $15 \mu\text{g}/\text{m}^3$ . Em 2008, a USEPA apresentou novos padrões, mas ainda não os consideramos neste trabalho.

Tabela 2 – Comparação entre padrões internacionais de MP<sub>10</sub>. Adaptada de CELLI (1999).

Instituição	Descrição	Critério de Medição	Concentração (µg/m <sup>3</sup> )
CONAMA 03/1990 (Brasil)	Padrão primário MP <sub>10</sub>	Média anual <sup>f</sup>	50
	Padrão primário MP <sub>10</sub>	Média 24 horas <sup>g</sup>	150
	Padrão secundário MP <sub>10</sub>	Média anual <sup>f</sup>	50
	Padrão secundário MP <sub>10</sub>	Média 24 horas <sup>g</sup>	150
OMS	Padrão secundário MP <sub>10</sub>	Média 24 horas	50
Especialistas em poluição do ar <sup>a</sup>	Padrão secundário MP <sub>10</sub>	Média 24 horas	50
USEPA	Padrão primário MP <sub>10</sub>	Média anual <sup>b</sup>	50
	Padrão primário MP <sub>10</sub>	Média 24 horas <sup>c</sup>	150
	Padrão primário MP <sub>2,5</sub>	Média anual <sup>d</sup>	15
	Padrão primário MP <sub>2,5</sub>	Média 24 horas <sup>e</sup>	65

a - *UK Expert Panel on Air Quality Guidelines*: grupo de médicos especialistas em poluição do ar que recomenda padrões de qualidade do ar para o governo do Reino Unido.

b - o padrão é cumprido se a média tri-anual das médias aritméticas anuais das amostras de 24 horas não o exceder.

c - o padrão é cumprido se 99% das médias de 24 horas num período de três anos não o excedam, em cada ponto de monitoramento.

d - a média tri-anual das concentrações de 24 horas não pode exceder o padrão.

e - 98% das médias de 24 horas de um período de três anos não podem exceder o padrão.

f - média aritmética das concentrações de 24 horas.

g - não deve ser excedido mais de uma vez por ano.

A Tabela 3, apresentada a seguir, ilustra as principais diferenças entre a fração fina e a grossa do MP.

Tabela 3 – Comparação entre a fração fina e a fração grossa do MP (Pozza, 2005)

	Fração Fina	Fração Grossa
Formado de:	Gases e gotículas	Sólidos grossos
Formado por:	Reações químicas ou vaporização. Nucleação, condensação de núcleos, coagulação. Evaporação de gotículas nas quais os gases dissolvem e reagem.	Quebras mecânicas (moagem, abrasão de superfícies, etc.), ressuspensão de poeira.
Composto de:	Sulfatos, nitratos, amônia, carbono elementar, compostos orgânicos (ex: aromáticos) e metais (Pb, Cd, V, Ni, Cu, Zn, Mn).	Poeira ressuspensa (do solo, de ruas). Cinzas de combustão. Óxidos de elementos da crosta (Si, Al, Ti, Fe), CaCO <sub>3</sub> , NaCl, pólen, esporos de fungos, fragmentos de plantas e animais.
Solubilidade:	Muito solúvel, higroscópico e deliquescente.	Pouco solúvel e não higroscópico.
Fontes:	Combustão de carvão, óleos, madeira, combustíveis de automóveis. Transformações atmosféricas de NO <sub>x</sub> , SO <sub>x</sub> , e compostos orgânicos. Processos de alta temperatura, fundições e moinhos de aço.	Ressuspensão de poeira industrial e de solo espalhadas em ruas e estradas. Suspensão de atividades modificadoras do solo (mineração, agricultura, rodovias não pavimentadas). Fontes biológicas. Construção e demolição. Combustão incompleta de carvão de óleos. “spray” marinho.
Tempo de meia vida na atmosfera	Dias, até semanas.	Minutos a horas.
Distância de dispersão	Centenas a milhares de quilômetros.	Menos de um a dezenas de quilômetros.

## **2.3 Danos Devido a Poluição do Ar**

Poluir não significa necessariamente produzir substâncias estranhas e altamente venenosas e introduzi-las na atmosfera (embora por vezes isto seja feito), nem mesmo produzir substâncias naturais em maior quantidade do que a própria natureza já o faz. Poluir é introduzir na atmosfera substâncias em maior taxa do que a natureza pode reciclar, e fazê-lo em locais e em momentos inadequados.

Existem diversos aspectos que devem ser considerados no estudo dos danos ou efeitos da poluição do ar, os principais são: saúde, materiais, propriedades da atmosfera, vegetação e economia (Derísio, 1992).

### **2.3.1 Materiais**

Alguns fenômenos podem ser identificados no processo de danos da poluição do ar sobre materiais, pode-se destacar: abrasão, deposição e remoção, ataque químico direto e indireto e corrosão eletroquímica. Além destes fenômenos, ressaltam-se alguns fatores que influenciam os danos a materiais por atmosferas poluídas: umidade relativa, temperatura, luz solar, velocidade do ar, a posição no espaço do material. Exemplificando, pode-se mencionar que não havendo umidade praticamente não haverá corrosão eletroquímica, mesmo em atmosfera muito poluída. Para vários metais existe uma umidade atmosférica crítica, que quando excedida, produz abrupto aumento na velocidade de corrosão (Lima, 2007).

### **2.3.2 Propriedades da natureza**

A deterioração da visibilidade é a primeira indicação da existência da poluição do ar para um cidadão comum. A visibilidade urbana pode ser afetada principalmente pelos seguintes fatores meteorológicos: altura da inversão e velocidade dos ventos e elevadas condições de umidade que propiciam aumento no tamanho de partículas higroscópicas o que resulta em redução da visibilidade.

A redução de visibilidade ocorre devido à presença de partículas sólidas e líquidas suspensas na atmosfera, que absorvem e dispersam a luz. Este problema está relacionado com o tamanho, concentração e características físicas das partículas poluentes presentes.

Levantamentos climatológicos em áreas urbanas mostram que as neblinas nas cidades são mais freqüentes e persistentes nas áreas circunvizinhas devido à poluição do ar. Mas a quantidade de radiação recebida por uma cidade com poluição é menor do que para uma área

sem poluição, sendo os comprimentos de onda mais curtos mais afetados que os mais longos (Lora, 2002).

Deve-se saber que a camada da atmosfera mais importante para o transporte e dispersão dos poluentes é a chamada “camada limite planetária”, uma faixa de cerca de 1 km de altura a partir da superfície do solo onde a topografia, o perfil de temperatura e a distribuição de pressão têm efeito direto na velocidade dos ventos e no nível de turbulência. Estes, por sua vez, determinam o grau de manutenção ou dispersão de um contaminante lançado na atmosfera em um determinado local (Seinfeld e Pandis, 1998).

### 2.3.3 Saúde

Estudos em diversos países têm relatado associação entre poluição atmosférica e vários indicadores de morbidade e mortalidade, mesmo quando as concentrações de poluentes estão abaixo dos limites padronizados internacionalmente (Daumas, 2002). A maioria dos estudos está focada em estatística descritiva ou simples testes de significância. Barnett e Thurkman (1995) realizaram intensa pesquisa bibliográfica e descrevem que 65% dos testes realizados em dados ambientais são simples testes de significância, 25% do tratamento de dados são realizados com Análise Multivariada de Dados, e apenas 10% do tratamento de dados são realizados com outras ferramentas matemáticas, como testes de tendências temporais.

Os efeitos da poluição do ar sobre a saúde podem provocar: doença aguda ou morte; doença crônica, encurtamento da vida, ou dano ao crescimento; alteração de importantes funções fisiológicas, tais como ventilação do pulmão, transporte de oxigênio pela hemoglobina, adaptação ao escuro, ou outras funções do sistema nervoso; sintomas adversos, tal como irritações sensoriais, que na ausência de uma causa óbvia, como a poluição do ar, pode levar uma pessoa a procurar um médico; desconforto, odor, prejuízo de visibilidade ou outros efeitos da poluição do ar suficientes para levar indivíduos a trocar de residência ou local de emprego (Freitas, 2003).

Alguns autores, como Braga *et al.* (2002) concluíram alguns fatores relevantes no tocante à influência da poluição atmosférica na saúde humana:

- o material particulado inalável é apontado como o poluente mais freqüentemente relacionado com danos à saúde;

- a mortalidade por patologias do sistema respiratório apresenta uma forte associação com a poluição atmosférica; sendo mais vulneráveis as crianças, idosos e pessoas que apresentam doenças respiratórias crônicas;
- as concentrações de poluentes atmosféricos encontradas em grandes cidades acarretam infecções agudas e crônicas no trato respiratório, mesmo em concentrações abaixo do padrão de qualidade do ar;
- notadamente os níveis de poluição acima dos padrões de qualidade do ar apresentam problemas, mas pode ocorrer efeitos mórbidos em concentrações abaixo dos padrões.

Desde o ponto da deposição respiratória, o sistema respiratório pode ser dividido em três regiões. Estas regiões diferem na estrutura, modelos de fluxos, função, tempo de retenção e sensibilidade às partículas depositadas. A primeira inclui nariz, boca, faringe e laringe. O ar inalado é morno e úmido nesta região. A segunda região inclui vias aéreas da traquéia até o bronquíolo terminal. Esta região se parece com uma árvore invertida, com um tronco, a traquéia subdivide-se em ramos menores. A terceira região inclui o bronquíolo terminal e a região pulmonar ou alveolar, onde ocorre a troca de gases (Hinds, 1999). Estas regiões podem ser vistas na Figura 2.

Sabe-se que as partículas mais finas são patogenicamente mais perigosas do que as mais grossas. De acordo com Baird (2002) a razão das partículas menores serem mais prejudiciais à saúde do que as maiores são:

- as partículas grossas, quando inaladas, são filtradas de modo eficiente pelo nariz e pela garganta e geralmente não são transportadas até os pulmões. Ao contrário, as partículas finas (usualmente inaladas) chegam até os pulmões e, uma vez ali, podem ser adsorvidas nas superfícies das células e, em razão disso, causar danos à saúde;
- como as partículas grossas sedimentam rapidamente, a exposição humana a essas partículas por inalação é reduzida;
- a área superficial por unidade de massa para as partículas grandes é menor que para as pequenas, e assim, quando comparamos uma mesma massa, a capacidade das partículas maiores em transportar moléculas adsorvidas até os órgãos do sistema respiratório, onde podem catalisar reações químicas e biológicas, é menor.

Outro fator a ser considerado é que as partículas com menores dimensões são pequenas o suficiente para permanecerem em suspensão na atmosfera, movendo-se como moléculas de gás e, na prática, não se depositam no solo, permanecendo na atmosfera por

horas ou até dias, podendo viajar por distâncias consideráveis a partir da fonte (Carvalho e Lacava, 2003).

O aparelho respiratório humano, mostrado na Figura 2 sofre com a inalação de poluentes presentes no ar atmosférico, das mais variadas formas, devido á sua complexidade e sensibilidade.

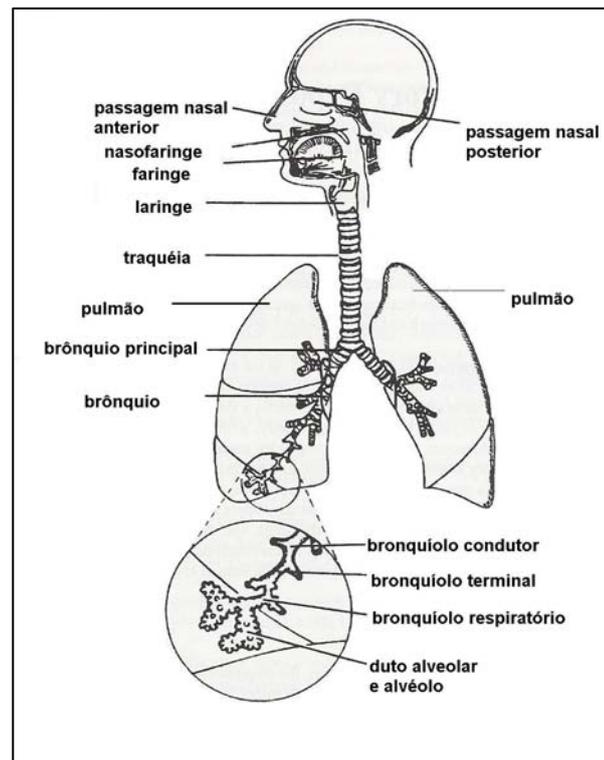


Figura 2 - Aparelho respiratório humano (adaptado de Hinds, 1999)

## 2.4 Monitoramento do Material Particulado

O monitoramento atmosférico é uma das várias formas de avaliação da qualidade do ar de uma determinada região, onde se deve observar cuidadosamente os métodos analíticos e equipamentos de forma que produzam resultados apropriados aos propósitos aos quais se destinam, levando-se em conta, também, a quantidade de estações de amostragem, bem como, a frequência das mesmas (Amorim, 2004).

Os principais objetivos do monitoramento da qualidade do ar são:

- fornecer dados para ativar ações de emergência durante períodos de estagnação atmosférica, quando os níveis de poluentes na atmosfera possam representar risco à saúde pública;

- avaliar a qualidade do ar à luz de limites estabelecidos para proteger a saúde e o bem estar das pessoas;
- acompanhar as tendências e mudanças na qualidade do ar devidas às alterações nas emissões dos poluentes

Vários métodos têm sido propostos para o cálculo do número adequado de estações de amostragem e se localizarem numa dada região e a frequência com que as amostras devem ser coletadas (Derísio, 1992).

Com relação à frequência de amostragem e também o período da mesma, a USEPA fixou um valor mínimo para alguns parâmetros importantes (Lima, 2007). De acordo com a metodologia adotada, a amostragem de material particulado pode ser realizada através da determinação do material particulado, em conformidade com a legislação vigente e a identificação das propriedades físico-químicas (Hinds, 1999).

As informações a serem obtidas quando se realiza uma amostragem de partículas na atmosfera devem ser a concentração mássica, o tamanho e a composição elementar das partículas.

A estação de amostragem deve ser instalada num determinado local visando avaliar a qualidade do ar de uma área ou região. A escolha do local adequado para a estação de amostragem, além de contemplar as características de distribuição dos poluentes, objetos do estudo, deve levar em consideração a segurança, a proteção dos equipamentos contra intempéries, vandalismo e a disponibilidade de recursos como, por exemplo, a energia elétrica.

Segundo Derísio (1992) algumas das recomendações para a localização e implantação de estações de amostragem de poluentes atmosféricos são:

- prioridade para as áreas mais poluídas;
- prioridade para as áreas mais povoadas;
- instalações de estações nos locais de entrada de ar para a região (a direção predominante dos ventos é importante neste caso);
- todas as estações devem estar na mesma altura do solo (altura respirável);
- evitar proximidade de obstáculos tais como prédios etc.
- evitar proximidade de chaminés.

## 2.5 Análise Estatística

### 2.5.1 Box Plot

É chamado *box plot*, a representação gráfica da análise exploratória de dados que mostra o intervalo dos 50% de valores centrais, a mediana, a amplitude e os valores anômalos ou aberrantes. Esta técnica fornece informações sobre a dispersão da medida, podendo-se detectar com precisão a presença de pontos extremos e valores de *outliers*.

A representação de um *box plot* é um retângulo alinhado verticalmente com duas semi-retas, uma em cada um dos lados do retângulo. A altura do retângulo é definida pelo valor do primeiro quartil (Q1), o qual representa 25% de todos dados, organizados em ordem crescente. O valor que está na posição que representa 75% de todos os dados é o Q3. O valor compreendido entre Q1-Q3 representa 50% de todos os dados. Os dados situados entre o Q3 e o final da semi-reta (cauda) acima do retângulo (limite superior - LS), determinam o conjunto de valores máximos dos dados sem os valores extremos, ou seja, o alcance. Já os dados que estão entre Q1 e a cauda inferior (limite inferior – LI) representa os valores mínimos do conjunto de dados. Os pontos situados acima do limite superior ou abaixo do limite inferior são considerados pontos extremos ou *outliers* (Morettin e Bussab, 2002).

As caudas que aparecem no diagrama *box plot* são calculadas da seguinte maneira:

$$LS = Q3 + (1,5) * (Q3 - Q1) \quad (2.1)$$

$$LI = Q1 - (1,5) * (Q3 - Q1) \quad (2.2)$$

A posição central é dada pela mediana e a dispersão por Q3-Q1. As posições relativas de Q1, Q2 e Q3 dão uma noção da assimetria da distribuição, ou seja, quanto mais central estiver Q2, mais simétrico será o conjunto de dados analisados. Maiores detalhes podem ser observados na Figura 3.

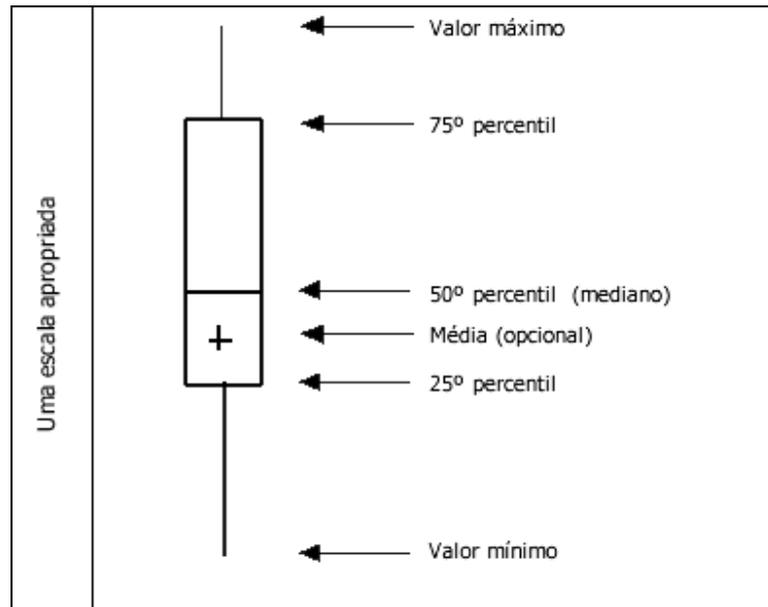


Figura 3 – Gráfico explicativo do Box-Plot

### 2.5.2 Séries Temporais

Uma série temporal é um conjunto de observações feitas sequencialmente em tempos determinados, comumente em intervalos iguais. A característica mais importante deste tipo de dados é que as observações vizinhas são dependentes e estamos interessados em modelar e analisar esta dependência. Enquanto em modelos de regressão, por exemplo, a ordem das observações é irrelevante para a análise, em séries temporais a ordem dos dados é crucial. Vale notar também que o tempo pode ser substituído por outra variável como espaço, profundidade, etc. (Ehlers, 2005). De uma maneira um pouco mais formal, dizemos que uma série temporal é uma realização de um processo estocástico (Barros, 2004).

A dependência serial entre os valores da série é um aspecto essencial, pois nos permite gerar previsões de valores futuros da série. Estas previsões seriam puro “chute” se não houvesse dependência serial. Também, diferentes séries possuem diferentes “graus” de previsibilidade; por exemplo, é frequentemente mais fácil prever uma série de temperaturas médias mensais do que a taxa mensal de inflação. Logo, não se pode garantir que a previsão encontrada por este ou aquele método será “sempre boa”, tudo depende das características da série que está sendo estudada. No entanto, um aspecto deve ser levado em conta ao fazermos previsões de séries temporais: o nível de incerteza aumenta com o horizonte de previsão – quanto mais longe no futuro, maior é a incerteza associada à previsão. Isto é intuitivamente razoável, é sempre mais difícil prever o futuro distante, e a nossa previsão estará cercada de incertezas (Barros, 2004).

Uma medida do “acerto” das nossas previsões é o erro de previsão  $k$ -passos à frente, definido a seguir.

O erro de previsão  $k$  passos no instante  $t$  (onde  $k$  é um inteiro maior ou igual a um) é definido como a diferença entre o valor real da série no instante  $t$  e a previsão deste valor feita  $k$  instantes antes ( $\hat{Z}_{t-k}$ ), isto é:

$$e_k(t) = Z_t - \hat{Z}_{t-k}(k) \quad (2.3)$$

Um caso particular importante é o erro de previsão um passo à frente, dado por:

$$e_1(t) = Z_t - \hat{Z}_{t-1}(1) \quad (2.4)$$

Um “bom” modelo de previsão produz previsões com erro pequeno, e assim é interessante acompanhar quantidades como a soma dos quadrados dos erros de previsão, ou a soma dos valores absolutos dos erros de previsão.

Matematicamente, uma série temporal é definida pelos valores  $Y_1, Y_2, \dots$  de uma variável  $Y$  (temperatura, valor de fechamento de uma ação etc.), nos tempos  $t_1, t_2, \dots$ . Portanto,  $Y$  é uma função de  $t$  simbolizada por  $Y = F(t)$  (Spiegel, 1969).

Uma série temporal é dita ser *contínua* quando as observações são feitas continuamente no tempo ou *discreta* quando as observações são feitas em tempos específicos, geralmente equiespaçados. Note que estes termos não se referem à variável observada, esta pode assumir valores discretos ou contínuos. Por outro lado, séries temporais discretas podem surgir de várias formas. Séries contínuas podem ser *discretizadas*, i.e. seus valores são registrados a certos intervalos de tempo (Ehlers, 2005).

Para Morettin e Tolo (2006), o estudo de séries temporais tem por filosofia a idéia básica de que o passado é o melhor elemento para estimar o futuro. Nesse sentido, entende-se por previsão a tentativa de prever o comportamento de um sistema em um instante  $t+h$  com base nas informações até o momento  $t$ .

Em algumas situações, o objetivo pode ser fazer previsões de valores futuros enquanto em outras a estrutura da série ou sua relação com outras séries pode ser o interesse principal. De um modo geral, os principais objetivos em se estudar séries temporais podem ser os seguintes:

- modelar o fenômeno estudado;

- obter conclusões estatísticas da série;
- avaliar a adequação do modelo para previsões.

### **2.5.2.1 Etapas Fundamentais na Análise das Séries Temporais**

1. Coletar os dados das séries temporais, fazendo todo o esforço para assegurar que os dados são fidedignos. Na coleta dos dados deve-se ter sempre em mente a finalidade eventual da análise das séries temporais.

2. Representar graficamente a série temporal, assinalando-se qualitativamente a presença da tendência a longo prazo e as variações cíclicas e por estações.

3. Construir a curva ou a reta da tendência a longo prazo e obter valores adequados da tendência, mediante o emprego de um dos métodos.

4. Se há variações por estações, obter um índice por estação e ajustar os dados àquelas variações, isto é, desestacionalizar os dados.

5. Ajustar os dados desestacionalizados à tendência. Os dados resultantes contêm (teoricamente) apenas as variações cíclicas e irregulares.

6. Representar graficamente as variações cíclicas obtidas na etapa 5, anotando quaisquer periodicidades (ou periodicidades aproximadas) que possam ocorrer.

7. Mediante a combinação dos resultados das etapas de 1 a 6, e utilizando qualquer outra informação disponível, fazer uma previsão (se for desejada) e, se possível, discutir as fontes de erro e a grandeza deste.

Os modelos utilizados para descrever séries temporais são processos estocásticos, isto é, processos controlados por leis probabilísticas. Antes de tudo é necessário fazer uma ressalva: nas aplicações práticas, os tipos de modelos para séries temporais, para os quais existem procedimentos ótimos de estimação, são em número limitado e estão longe de serem os melhores. Contudo eles fornecem uma primeira aproximação à análise do fenômeno físico do qual provêm os dados (Morettin e Tolo, 2006).

### **2.5.2.2 Representação Gráfica de uma Série Temporal**

Uma série temporal é representada por meio da construção de um gráfico de  $y$  em função de  $t$ . Estes tipos de gráficos são chamados, na estatística descritiva, de gráficos de dispersão e mostram, de uma maneira geral, o comportamento dos dados ao longo do tempo.

Informações básicas como a presença ou ausência de tendência e sazonalidade, podem ser extraídas deste tipo de gráfico.

### 2.5.2.3 Movimentos Característicos das Séries Temporais

O gráfico de uma série temporal é descrito por um ponto que se move com o decorrer do tempo, de alguma forma análoga à trajetória de uma partícula material que se desloca sob a influência de forças físicas. O movimento pode ser provocado, em vez de forças físicas, por uma combinação de forças econômicas, sociológicas, psicológicas e outras (Spiegel, 1969).

Experiências realizadas com muitos exemplos de séries temporais revelaram certos *movimentos* ou *variações características*, alguns dos quais, ou todos, estão presentes em graus diversos. A análise desses movimentos é de grande valor em vários casos, um dos quais é o problema da *previsão* de movimentos futuros.

Os movimentos característicos das séries temporais podem ser classificados em quatro tipos principais, freqüentemente denominados *componentes* de uma série temporal (Morettin e Toloj, 2006):

**1. Os movimentos a longo prazo ou seculares (tendência da série):** referem-se à direção geral, segundo a qual parece que o gráfico ou série temporal se desenvolve, em um longo intervalo de tempo.

**2. Variações cíclicas:** referem-se às oscilações em longo prazo ou aos desvios em torno da reta ou da curva de tendência. Esses *ciclos*, como são freqüentemente denominados, podem ser ou não *periódicos*, isto é, podem ou não seguir exatamente padrões análogos, depois de intervalos de tempos iguais.

**3. Variações por estações (variações sazonais):** referem-se a padrões idênticos, ou quase, que uma série temporal parece obedecer durante os mesmos meses dos anos sucessivos.

**4. Movimentos irregulares ou aleatórios (variações irregulares):** referem-se aos deslocamentos esporádicos das séries temporais, provocados por eventos casuais, como enchentes, greves, eleições etc. embora, ordinariamente, se admita que esses eventos produzem variações somente durante curto período, é concebível que elas sejam tão intensas que acarretem novos movimentos cíclicos ou de outra natureza.

Vale ressaltar que uma série temporal pode apresentar, simultaneamente, mais de uma componente e não raro encontramos séries que apresentam as componentes de tendência, variação cíclica e sazonal e de movimento irregular.

#### 2.5.2.4 Decomposição Clássica

Muitas das propriedades observadas em uma série temporal  $X_t$  podem ser captadas assumindo-se a seguinte forma de decomposição

$$X_t = T_t + C_t + R_t \quad (2.5)$$

onde  $T_t$  é uma componente de tendência,  $C_t$  é uma componente cíclica ou sazonal e  $R_t$  é uma componente aleatória ou ruído (a parte não explicada, que espera-se ser puramente aleatória). A componente cíclica se repete a cada intervalo fixo  $s$ , i.e.

$$\dots = C_{t-2s} = C_{t-s} = C_t = C_{t+s} = C_{t+2s} = \dots \quad (2.6)$$

Assim, variações periódicas podem ser captadas por esta componente.

#### 2.5.2.5 Séries com Tendência

A tendência de uma série indica o seu comportamento “de longo prazo”, isto é, se ela sobe, desce, ou permanece estável, e qual a velocidade destas mudanças. Nos casos mais comuns trabalha-se com tendência constante, linear ou quadrática.

Não existe uma definição precisa de tendência, e diferentes autores usam este termo de diferentes formas. Podemos pensar em tendência como uma mudança de longo prazo no nível médio da série. A dificuldade aqui é definir longo prazo.

A forma mais simples de tendência é

$$X_t = \alpha + \beta t + \varepsilon_t \quad (2.7)$$

onde  $\alpha$  e  $\beta$  são constantes a serem estimadas e  $\varepsilon_t$  denota um erro aleatório com média zero. O nível médio da série no tempo  $t$  é dado por  $m_t = \alpha + \beta t$  que é algumas vezes chamado de *termo de tendência*. Porém alguns autores preferem chamar a inclinação  $\beta$  de tendência, ou seja, a mudança no nível da série por unidade de tempo já que  $\beta = m_t - m_{t-1}$  (Ehlers, 2005).

Seja qual for a curva utilizada, a função ajustada fornece uma medida da tendência da série, enquanto os resíduos (diferença entre valores observados e valores ajustados) fornecem uma estimativa de flutuações locais.

### Filtragem

Outro procedimento para analisar séries com tendência é através de *filtros lineares*. A filtragem é utilizada para procurar ou eliminar tendências. Um filtro linear converte uma série  $\{x_t\}$  em outra  $\{y_t\}$  através da seguinte operação linear

$$y_t = \sum_{j=-q}^s a_j x_{t+j} \quad (2.8)$$

onde  $\{a_j\}$  é um conjunto de pesos. Além disso, como deseja-se estimar a média local os pesos devem ser tais que  $\sum_{j=-q}^s a_j = 1$ , garantindo assim que  $\min\{x_t\} < y_t < \max\{x_t\}$ . Neste caso a operação é chamada de média móvel.

Médias móveis são em geral simétricas com  $s = q$  e  $a_{-r} = a_r$ . Por exemplo, se  $s = q = 2$  temos que

$$y_t = a_2 x_{t-2} + a_1 x_{t-1} + a_0 x_t + a_1 x_{t+1} + a_2 x_{t+2} \quad (2.9)$$

O caso mais simples é quando todos os pesos  $a_j$  têm o mesmo valor devido à restrição de soma 1 segue que  $a_j = \frac{1}{(2q+1)}$ , para  $j = -q, \dots, q$ . Neste caso, o valor suavizado de  $x_t$  é dado por

$$y_t = \frac{1}{(2q+1)} * \sum_{j=-q}^q x_{t+j} \quad (2.10)$$

### Diferenciação

Um tipo especial de filtro, muito útil para remover uma componente de tendência, consiste em *diferenciar* a série até que ela se torne estacionária. Para dados não sazonais, a primeira diferenciação é em geral suficiente para induzir estacionariedade aproximada. A nova série  $y_2, \dots, y_n$  é formada a partir da série original  $x_1, \dots, x_n$  como

$$y_t = x_t - x_{t-1} = \nabla x_t \quad (2.11)$$

### 2.5.2.6 Séries Sazonais

Séries sazonais ocorrem com enorme frequência na prática. Por exemplo, séries de temperatura média mensal e séries de consumo de energia elétrica são claramente sazonais, e exibem características que se repetem ano a ano sempre no mesmo mês (ou semana, ou trimestre, ...). A sazonalidade pode ser modelada de duas formas: através de fatores sazonais ou através de funções trigonométricas. Aqui estaremos interessados apenas na modelagem através de fatores sazonais.

Seja  $S$  o período sazonal, por exemplo,  $S = 12$  no caso de dados mensais,  $S = 4$  no caso de observações trimestrais. Existem dois tipos de modelos para sazonalidade: modelos aditivos e multiplicativos. Nos modelos aditivos, o padrão sazonal não se altera a medida que o nível da série muda. Ao contrário, nos modelos multiplicativos, a sazonalidade da série é afetada pelo nível da mesma.

Uma forma bastante simples de eliminar o efeito sazonal é simplesmente tomar médias sazonais. Por exemplo, em dados mensais com sazonalidade anual, as médias anuais estarão livres do efeito sazonal. Embora este procedimento esteja correto, muitos dados serão desconsiderados e ao invés disto pode-se recorrer mais uma vez às médias móveis.

### 2.5.2.7 Modelos para Séries Temporais

Ao modelar uma série temporal, desejamos:

- capturar “toda” a estrutura de dependência existente na série;
- logo, nos resíduos não deve “sobrar” estrutura, pois ela já foi capturada pelo modelo. Nota: o resíduo é apenas a diferença entre o valor real e o ajustado por um modelo qualquer. Por exemplo, seja  $Z_t$  o valor real da série no instante  $t$ , e  $\hat{Z}_t$  seu valor ajustado pelo modelo. Então, o resíduo no instante  $t$  é apenas  $Z_t - \hat{Z}_t$ ;
- em particular, se o modelo é bom, os resíduos não devem apresentar correlação serial (isto é, correlação entre os resíduos em diferentes instantes de tempo);
- explicar o comportamento da série com o menor número de parâmetros (parcimônia).

Matematicamente um processo estocástico pode ser definido como uma coleção de variáveis aleatórias ordenadas no tempo e definidas em um conjunto de pontos  $T$ , que pode ser contínuo ou discreto. Iremos denotar a variável aleatória no tempo  $t$  por  $X(t)$  no caso contínuo (usualmente  $-\infty < t < +\infty$ ), e por  $X_t$  no caso discreto (usualmente  $t = 0, \pm 1, \pm 2, \dots$ ). O

conjunto de possíveis valores do processo é chamado de *espaço de estados* que pode ser discreto (por exemplo, o número de chamadas que chegam a uma central telefônica a cada 2 horas) ou contínuo (por exemplo, a temperatura do ar em uma localidade observada em intervalos de 1 hora).

Em análise de séries temporais a situação é bem diferente da maioria dos problemas estatísticos. Embora seja possível variar o tamanho da série observada, usualmente será impossível fazer mais do que uma observação em cada tempo.

Assim, tem-se apenas uma realização do processo estocástico e uma única observação da variável aleatória no tempo  $t$  denotada por  $x(t)$  no caso contínuo e  $x_t$ , para  $t = 1, \dots, N$  no caso discreto.

Uma maneira de descrever um processo estocástico é através da distribuição de probabilidade conjunta de  $X(t_1), \dots, X(t_k)$  para qualquer conjunto de tempos  $t_1, \dots, t_k$  e qualquer valor de  $k$ . Esta é uma tarefa extremamente complicada e na prática costuma-se descrever um processo estocástico através das funções média, variância e autocovariância. Estas funções são definidas a seguir para o caso contínuo sendo que definições similares se aplicam ao caso discreto.

$$\text{Média: } \mu(t) = E[X(t)] \quad (2.12)$$

$$\text{Variância: } \sigma^2(t) = \text{Var}[X(t)] \quad (2.13)$$

$$\text{Autocovariância: } \gamma(t_1, t_2) = E[X(t_1) - \mu(t_1)] * [X(t_2) - \mu(t_2)] \quad (2.14)$$

Nota-se que a função de variância é um caso especial da função de autocovariância quando  $t_1 = t_2$ . Momentos de ordem mais alta do processo também podem ser definidos, mas são raramente utilizados na prática e as funções  $\mu(t)$  e  $\gamma(t_1, t_2)$  são em geral suficientes.

Qualquer que seja a classificação que façamos para modelos de séries temporais, podemos considerar um número muito grande de modelos diferentes para descrever o comportamento de uma série particular. A construção destes modelos depende de vários fatores, tais como o comportamento do fenômeno ou o conhecimento a priori que temos de sua natureza e do objetivo de análise (Morettin e Toloi, 2006). Na prática, depende, também, da existência de métodos apropriados de estimação e da disponibilidade de programas (“softwares”) adequados.

Há, basicamente, dois enfoques usados na análise de séries temporais. Em ambos, o objetivo é construir modelos para as séries, com propósitos determinados (Morettin e Tolo, 2006). No primeiro enfoque, a análise é feita no *domínio temporal* e os modelos propostos são *modelos paramétricos* (com um número finito de parâmetros). No segundo, a análise é conduzida no *domínio de frequências* e os modelos propostos são *modelos não paramétricos* (com um número infinito de parâmetros). Dentro dos modelos paramétricos temos os modelos ARMA (modelos auto-regressivos e de médias móveis) e ARIMA (modelos auto-regressivos integrados e de médias móveis). No domínio das frequências temos a análise espectral que tem recebido muita atenção sobre tudo em ciências físicas e engenharia, a função de autocovariância (ou autocorrelação) e sua transformada de Fourier, o espectro.

### Processos de Média Moveis (MA)

Seja  $\{\varepsilon_t\}$  um processo discreto puramente aleatório com média zero e variância  $\sigma_\varepsilon^2$ . Um processo  $\{X_t\}$  é chamado de processo de médias móveis de ordem  $q$ , ou MA( $q$ ), se

$$X_t = \varepsilon_t + \beta_1 \varepsilon_{t-1} + \dots + \beta_q \varepsilon_{t-q} \quad (2.15)$$

A equação (2.15) pode ser rearranjada, aplicando-se operador de retardo, denotado por  $B$ , resultando em

$$\theta(B) = (1 - \theta_1 B^1 - \theta_2 B^2 - \dots - \theta_q B^q) \quad (2.16)$$

onde  $\theta(B)$  é um polinômio de ordem  $q$  em  $B$ .

### Processos Auto-regressivos (AR)

Suponha que  $\{\varepsilon_t\}$  seja um processo puramente aleatório com média zero e variância  $\sigma_\varepsilon^2$ . Um processo  $\{X_t\}$  é chamado de processo auto-regressivo de ordem  $p$ , ou AR( $p$ ), se

$$X_t = \alpha_1 X_{t-1} + \dots + \alpha_p X_{t-p} + \varepsilon_t \quad (2.17)$$

Nota-se a similaridade com um modelo de regressão múltipla, onde os valores passados de  $X_t$  fazem o papel das regressoras. Assim, processos AR podem ser usados como modelos se for razoável assumir que o valor atual de uma série temporal depende do seu passado imediato mais um erro aleatório.

A equação acima pode ser rearranjada, aplicando-se operador de retardo, denotado por  $B$ , resultando em

$$\varphi(B) = (1 - \varphi_1 B^1 - \varphi_2 B^2 - \dots - \varphi_p B^p) \quad (2.18)$$

onde  $\varphi(B)$  é um polinômio de ordem  $p$  em  $B$ .

### Modelos Mistos ARMA

Combinando-se os modelos AR e MA pode-se obter uma representação adequada com um número menor de parâmetros. Processos auto-regressivos de médias móveis (ARMA) formam uma classe de modelos muito úteis e parcimoniosos para descrever dados de séries temporais. O modelo ARMA( $p, q$ ) é dado por

$$X_t = \alpha_1 X_{t-1} + \dots + \alpha_p X_{t-p} + \varepsilon_t + \beta_1 \varepsilon_{t-1} + \dots + \beta_q \varepsilon_{t-q} \quad (2.19)$$

Média Móvel                      Auto-regressivo

onde  $\{\varepsilon_t\}$  é um processo puramente aleatório com média zero e variância  $\sigma_\varepsilon^2$ . Nota-se que, modelos AR ou MA podem ser obtidos como casos especiais quando  $p = 0$  ou  $q = 0$ .

### Principais elementos e estimação dos parâmetros nos modelos AR ( $p$ ), MA ( $q$ ) e ARMA ( $p, q$ )

A estratégia para a construção do modelo se baseia em um ciclo iterativo, no qual a escolha da estrutura do modelo é baseada nos próprios dados. Os estágios desse ciclo são:

- a) Especificação: considera-se uma classe geral de modelos para análise;
- b) Identificação: com base na análise de autocorrelações e autocorrelações parciais se identifica um modelo;
- c) Estimação: é a fase na qual são estimados os parâmetros do modelo identificado;
- d) Verificação: através de uma análise de resíduos se verifica o modelo ajustado para se saber se este é adequado para os fins em vista.

Caso o modelo não seja adequado, o ciclo é repetido, voltando-se à fase de identificação. A fase crítica do procedimento acima é a identificação. É possível que vários pesquisadores identifiquem modelos diferentes para a mesma série temporal.

Vários métodos alternativos de identificação têm sido sugeridos na literatura.

Os modelos ARMA são apropriados para descrever séries que se desenvolvem no tempo ao redor de uma média constante. Provavelmente as séries encontradas na prática

nunca serão estacionárias, com exceção talvez para as diversas formas de “ruídos”, subjacentes a certos fenômenos físicos (Morettin & Toloi, 1981).

### Modelos de Box e Jenkins

Uma metodologia bastante utilizada na análise de modelos paramétricos é conhecida como abordagem de Box e Jenkins (1970). Tal método consiste em ajustar modelos auto-regressivos integrados de médias móveis, ARIMA  $(p,d,q)$ , (também chamados de modelos ARMA integrados) a um conjunto de dados.

Em geral, os modelos postulados são *parcimoniosos*, pois contém um número pequeno de parâmetros e as previsões obtidas são bastante precisas, comparando-se favoravelmente com os demais métodos de previsão.

### As equações ARIMA e SARIMA

São modelos mais sofisticados, que usam as correlações entre as observações em diversos instantes (Barros, 2004).

Os modelos ARIMA foram difundidos por Box *et al.* (1994) e representam uma generalização dos diversos métodos de análise de séries temporais. O modelo ARIMA geral é AR de ordem  $p$  e MA de ordem  $q$ , operando na  $d$ -ésima diferença da série temporal  $Z_t$ . Assim, a classe de modelos ARIMA é classificada por três parâmetros  $(p,d,q)$ . Os modelos ARIMA são robustos do ponto de vista conceitual e estatístico, proporcionam previsões probabilísticas e são de fácil implementação (desde que se tenha o recurso computacional adequado). Estes modelos representam uma generalização dos diversos métodos de análise de séries temporais. Na presença de sazonalidade nos dados, deve-se incorporar as componentes sazonais no modelo ARIMA $(p,d,q)$ , obtendo assim o modelo SARIMA $(p,d,q) \times (P,D,Q)_s$ .

De uma forma sumária, um modelo SARIMA $(p,d,q) \times (P,D,Q)_s$  pode ser apresentada como segue:

$$\varphi(B)\Phi(B^S)W_t = \theta(B)\Theta(B^S)\varepsilon_t \quad (2.20)$$

onde

$t$ , índice do tempo;

$W_t$ ,  $d$ 'ésima diferença da variável de interesse  $z_t$ ;

$\varphi(B)$ , operador auto-regressivo:  $\varphi(B) = (1 - \varphi_1 B^1 - \varphi_2 B^2 - \dots - \varphi_p B^p)$ ;

$\Phi(B^S)$ , operador auto-regressivo sazonal:  $\Phi(B^S) = (1 - \Phi_s B^S - \dots - \Phi_p B^{ps})$ ;

$\theta(B)$ , operador de médias móveis:  $\theta(B) = (1 - \theta_1 B^1 - \theta_2 B^2 - \dots - \theta_q B^q)$ ;

$\Theta(B^S)$ , operador de médias móveis sazonal:  $\Theta(B^S) = (1 - \Theta_s B^S - \dots - \Theta_Q B^{Qs})$ ;

$B$  e  $B^S$ , operadores de retrocesso:  $B_{z_t - z_{t-p}}$  e  $B^S_{z_t - z_{t-p}}$ ;

$\varepsilon_t$ , “ruído branco” ou erro aleatório ( $\varepsilon_t \sim N(0,1)$ );

Intuitivamente, pode-se afirmar que os modelos ARIMA representam as séries temporais como uma ponderação dos próprios valores e/ou erros passados da série.

A identificação de um modelo ARIMA corresponde à determinação do nível de diferenciação (d), a partir do qual a série se torna estacionária; da ordem (máxima) dos termos auto-regressivos (p) e da ordem (máxima) dos termos médias móveis (q).

A verificação de validação e adequação do modelo é efetuada em duas dimensões inter-relacionadas: o exame do grau de ajustamento (ou aderência) do modelo, realizado comparando-se os dados experimentais com os obtidos via modelo e a verificação dos erros dos parâmetros obtidos com o modelo. Validado o modelo, pode-se então estimar a tendência dos dados experimentais.

### Holt-Winters

As técnicas de amortecimento exponencial podem ser estendidas para modelar séries que apresentam tendência e sazonalidade.

Um dos modelos mais utilizados na prática é o modelo de amortecimento exponencial de Holt-Winters. Este procedimento é capaz de modelar séries sazonais e gera, na maioria dos casos, boas previsões, a um custo computacional bastante baixo. O modelo de Holt-Winters utiliza a idéias de amortecimento das informações passadas três vezes para:

- estimar o nível da séries;
- estimar a taxa de crescimento da séries;
- estimar os fatores sazonais.

Em cada um dos passos indicados emprega-se uma constante de amortecimento diferente.

O método de alisamento exponencial de Holt-Winters é uma das melhores técnicas de previsão conhecidas que permitem que o teste padrão sazonal se adapte ao tempo excedente

(Lawton, 1998). É um método onde a observação começa dos dados mais antigos, dando relativamente mais peso às observações recentes na previsão (ITL, 2009). De acordo com Gardner (2006), os métodos de alisamento exponencial são melhores para uma classe geral de modelos, sendo mais abrangentes do que os modelos ARIMA.

O procedimento de alisamento exponencial pode ser generalizado para séries que contenham tendência e variação sazonal. Suponha por exemplo que as observações sejam mensais e sejam  $L_t$ ,  $T_t$  e  $I_t$  o nível, a tendência e o índice sazonal no tempo  $t$ , respectivamente. Assim,  $T_t$  é o aumento ou redução esperada por mês no nível atual da série (Ehlers, 2005).

Suponha que no tempo  $t$  os termos  $(L_1; T_1; I_1); \dots; (L_{t-1}; T_{t-1}; I_{t-1})$  sejam conhecidos. Então, após observar  $x_t$  os termos  $L_t$ ,  $T_t$  e  $I_t$  são atualizados via alisamento exponencial. Se a variação sazonal for multiplicativa, isto é, com amplitudes que tendem a crescer ao longo do tempo, as equações de atualização na forma de recorrência são dadas por

$$L_t = \alpha(x_t / I_{t-12}) + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (2.21)$$

$$T_t = \gamma(L_t - L_{t-1}) + (1 - \gamma)T_{t-1} \quad (2.22)$$

$$I_t = \delta(x_t / L_t) + (1 - \delta)I_{t-12} \quad (2.23)$$

E as previsões  $k$  períodos à frente são dadas por

$$\hat{x}_t(k) = (L_t + kT_t)I_{t-12+k}, \quad k = 1, 2, \dots \quad (2.24)$$

Os parâmetros de alisamento  $\alpha$ ,  $\gamma$  e  $\delta$  são em geral escolhidos no intervalo  $(0,1)$  e podem ser estimados minimizando-se a soma de quadrados dos erros de previsão com na seção anterior. Aqui vale também o comentário sobre valores próximos aos extremos devido à soma de quadrados variar pouco nesta região. Além disso, eles não dependem da escala das observações, mas sim das propriedades temporais do nível, tendência e sazonalidade da série. Valem os mesmo comentários sobre estes valores refletindo a influência das observações passadas nas previsões de cada componente.

Para modelar adequadamente a sazonalidade, é necessário pelo menos 3 anos de dados mensais e 4 anos de dados trimestrais, para o método de Holt-Winters (Barros, 2004).

### **Crítérios de Informação**

Em muitas aplicações vários modelos podem ser julgados adequados em termos do comportamento dos resíduos. Uma forma de “discriminar” entre estes modelos competidores é utilizar os chamados critérios de informação que levam em conta não apenas a qualidade do

ajuste, mas também penalizam a inclusão de parâmetros extras. Assim, um modelo com mais parâmetros pode ter um ajuste melhor mas não necessariamente será preferível em termos de critério de informação. A regra básica consiste em selecionar o modelo cujo critério de informação calculado seja mínimo (Ehlers, 2005).

A regra mais utilizada em séries temporais é o chamado critério de informação de Akaike, denotado por AIC.

Existem outros critérios de informação que são basicamente modificações do AIC na forma de penalizar a inclusão de parâmetros extras. O mais famoso deles é o critério de informação Bayesiano (BIC).

Estas medidas não têm nenhum significado quando olhadas individualmente, isto é, considerando-se um único modelo. Assim, tanto o AIC quanto o BIC podem assumir valores quaisquer, inclusive valores negativos. Vale lembrar também que ao usar tais critérios para comparar modelos a estimação precisa ser feita no mesmo período amostral de modo que os modelos sejam comparáveis. Se a inclusão de termos adicionais no modelo não melhorar sensivelmente o ajuste, então o AIC e o BIC (e qualquer outro critério) serão maiores.

Para este trabalho utilizamos o critério de AIC.

#### **2.5.2.8 Séries Temporais Aplicadas a Problemas Ambientais**

Algumas pesquisas ambientais realizam análise temporal de dados para verificar previsões e comportamentos futuros das variáveis analisadas. Em alguns casos, após a análise de séries temporais, foram utilizados análises de regressão para comparar duas ou mais variáveis.

O avanço das técnicas estatísticas tem viabilizado o estudo dos efeitos da poluição do ar sobre a saúde mesmo quando os níveis de poluentes ambientais são muito menores do que aqueles considerados nocivos (Junger, 2004). Modelos de séries temporais têm desempenhado um papel relevante para o desenvolvimento destes estudos. Estudos recentes apresentam séries temporais relacionando a poluição do ar e seus efeitos sobre a saúde humana (Eftim e Dominici, 2005; Pope e Dockery, 2006), fazendo uso de vários tipos de modelagens.

Craggs e Davison (1987) observaram a dependência do fluoreto presente no ar e do ar particulado. Os modelos da série de tempo foram obtidos. A grande quantidade de variação inexplicada pelos modelos foi devido à influência dos fatores ambientais e meteorológicos não incluídos nos modelos, e à variação aleatória devido ao cotidiano.

Em 1999, Castanho apresentou séries temporais das concentrações de material particulado inalável, representado pela soma de particulado fino e grosso. Ainda em 1999, Zeghnoun *et al.* realizaram estudo para verificar a poluição do ar na cidade de Le Havre. Foi realizado o cruzamento de vendas diárias de medicamentos para doenças respiratórias com concentrações diárias do ar, de SO<sub>2</sub>, NO<sub>2</sub> e fumaça negra ajustando-se ao modelo de regressão de Poisson para tendências temporais, variações sazonais, influências epidêmicas e temperatura.

Em 2001, podemos citar dois trabalhos que utilizaram o modelo de Regressão de Poisson. Goldeberg *et al.* utilizaram uma série de tempo para investigar a associação entre a mortalidade diária de cardíacos e concentrações diárias das partículas e de poluentes gasosos na atmosfera de Montreal, Quebec, durante o período 1984-1993. Arbex adotou o modelo de regressão para assegurar a validade dos resultados obtidos através do Coeficiente de Correlação de Pearson. Os aprimoramentos metodológicos nos estudos de séries temporais possibilitaram indicar a presença de relação causa e efeito entre os poluentes do ar e a saúde humana.

O modelo SARIMA foi utilizado em algumas séries, algumas vezes combinado a outros modelos: ao modelo de dinâmica linear (DLM) (Nobre *et al.*, 2001) e associado ao modelo de regressão linear múltipla (Goyal *et al.*, 2006). Em outros estudos o SARIMA foi aplicado sozinho: Tseng e Tseng (2002); Mishra e Desai (2005) utilizaram estes modelos para sistemas de fontes de água; Ghosh *et al.* (2007) para previsões de emissões veiculares; Modarres (2007) para séries temporais hidrológicas, ambos sem a necessidade de complementação de outros modelos.

Um monitoramento na Noruega realizado em uma floresta por Kvaalen *et al.* (2002), durante 14 anos, utilizou a análise de série de tempo para mostrar a verificação da influência da deposição de ácido na água e no solo.

Puliafito *et al.* (2003) apresentaram um modelo para determinar a qualidade do ar nas áreas urbanas da cidade de Mendonça na Argentina, que usa um sistema de informação geográfico. Este sistema permitiu a integração, a manipulação, a análise e a simulação de dados espacial e temporal da concentração de poluição ambiental.

Estudo realizado no período 1980-1996 em Toronto, Canadá por Rainham e Smoyer-Tomic (2003) relacionou dados de poluentes do ar e variáveis cronológicas na relação entre umidade e, a temperatura no verão e um índice de umidade e mortalidade acidental. Modelos

log-linear com Poisson foram usados para estimar a relação diária entre umidade e mortalidade e relatar por tendências de variáveis de tempo, dia da semana e poluição do ar.

Em muitas comunidades são realizados estudos de séries temporais sobre o efeito da poluição de ar na mortalidade. Roberts (2004) investigou a interação entre a poluição diária de ar e a temperatura média diária no Condado de Cook, em Ilínois e no Condado de Allegheny, Pensilvânia, usando dados de 1987 a 1994. Os resultados deste estudo sugeriram que em estudos de série de tempo relacionando mortalidade e poluição de ar existiria uma possibilidade de se considerar uma interação entre a poluição diária de ar e a temperatura diária média. Foi utilizada a Regressão de Poisson.

O método não-paramétrico de Poisson foi usado na pesquisa realizada por Pitard *et al.* (2004) para avaliar o efeito da poluição de ar em asmáticos (no aparelho broncodilatador) e nas vendas de medicamentos para doenças respiratórias na cidade de Rouen (França). Utilizou-se na pesquisa a base de dados de planos de saúde da União Regional Superior da Normandia e da qualidade do ar monitorado. A análise das séries temporais foi executada por dois anos (julho 1998/junho 2000).

O'Neill *et al.* (2004) realizaram estudo na Cidade do México, usando uma análise de séries temporais, para investigar se havia associação entre a mortalidade diária e o ozônio ambiental e se diferiam por condições sociais, da idade e da região da residência. A regressão de Poisson modelou a associação entre a mortalidade e níveis diários do ozônio (no dia de morte e no dia precedente), o nível e a idade sócio-econômica, e controlou tendências de temperatura e de tempo.

Em uma análise de séries temporais epidemiológicas, realizada por Junger (2004), o que se pretendeu foi estimar o efeito de uma ou mais co-variáveis que representam uma exposição sobre a variável resposta que corresponde a um desfecho de saúde. A metodologia padrão utilizada nas análises de séries temporais em estudos epidemiológicos sobre os efeitos da poluição do ar na saúde são os modelos aditivos generalizados. Neste trabalho, foi introduzida uma nova classe de modelos para séries temporais de dados de contagem, os modelos Poisson-gama semi-paramétricos.

Hosseinpoor *et al.* (2005) estudou os efeitos da poluição de ar na saúde em diferentes partes do mundo. Este foi um estudo retrospectivo que utilizou séries temporais. As variáveis do estudo incluem os níveis da poluição do ar de dióxido de nitrogênio (NO<sub>2</sub>), de monóxido

de carbono (CO), de ozônio (O<sub>3</sub>), de dióxido de enxofre (SO<sub>2</sub>), e de material particulado. Foi utilizada a Regressão de Poisson.

Análise de séries temporais usando a Regressão de Poisson para dados de MP<sub>10</sub> e SO<sub>2</sub>, foi realizada para verificar os riscos de nascimentos prematuros quando as gestantes do EUA ficavam por longos períodos expostas às concentrações dos mesmos (Sagiv *et al.*, 2005).

Nickerson e Madsen (2005) apresentaram dados de monitoramento de precipitação que ocorreram desde 1978 em um local de amostragem na Universidade Central da Flórida. A concentração mensal de volume médio depositado e deposição de H<sup>+</sup>, NH<sub>4</sub><sup>+</sup>, Ca<sup>2+</sup>, Mg<sup>2+</sup>, NO<sub>3</sub><sup>-</sup>, Cl<sup>-</sup> e SO<sub>4</sub><sup>2-</sup> úmidos foram avaliados por um modelo não-linear da regressão (NLR) que considera dados de 10 anos (1978 a 1987) e dados de 20 anos (1978 a 1997). Os modelos integrados auto-regressivos ARIMA com tendência linear foram considerados como uma alternativa aos modelos de NLR para estes dados.

Estudos foram desenvolvidos para séries que relacionavam, em diversos países, mortalidade (Yorifuji *et al.*, 2005; Martin e Roberts, 2006; Forastiere *et al.*, 2007) e incidências de doenças pulmonares (Peng *et al.*, 2006), em locais com maior concentração de MP, bem como as influências de pluviosidade e fatores meteorológicos (Johansson *et al.*, 2006).

Em 2005, Skjelkvale *et al.* utilizaram uma Regressão Linear Simples no monitoramento de águas e poluição de ar em uma base regional, comparando o grau e a extensão geográfica do impacto da poluição atmosférica na acidificação nas águas de superfície. As tendências regionais foram calculadas para 12 regiões geográficas na Europa e na América do Norte, compreendendo 189 locais das águas de superfície. De 1990 a 2001 as concentrações de sulfato diminuíram em muitos casos com exceção de uma das regiões investigadas.

## **CAPÍTULO 3 PROCEDIMENTO EXPERIMENTAL**

### **3.1 Área de Estudo**

#### **3.1.1 O Estado de São Paulo**

Localizado na Região Sudeste do Brasil, o Estado de São Paulo possui área aproximadamente de 249.000 km<sup>2</sup>, que correspondem a 2,9% do território nacional. O Estado de São Paulo é a unidade da Federação de maior ocupação territorial, maior contingente populacional (em torno de 37 milhões de habitantes), maior desenvolvimento econômico (agrícola, industrial e serviço), maior frota automotiva e, como consequência, apresenta grande alteração na qualidade do ar (CETESB, 2003).

Com relação à poluição atmosférica, destaca-se a Região Metropolitana de São Paulo (RMSP) e a área de Cubatão que possuem, respectivamente, alta emissão de poluentes de origem veicular e industrial. No interior do Estado de São Paulo, em geral, a situação é diferente e as necessidades estão relacionadas ao acompanhamento da qualidade do ar a longo prazo. Todavia, municípios densamente povoados, áreas próximas de grandes centros urbanos e/ou industriais, regiões próximas de outras fontes poluidoras, como por exemplo, queimadas de palha de cana-de-açúcar, merecem atenção especial e têm sido motivo de novas investigações.

#### **3.1.2 A Cidade de São Carlos**

Fundada em 1857, durante o período de expansão da cultura do café, São Carlos possui área de aproximadamente 1.132 km<sup>2</sup> e localiza-se próxima ao centro geográfico do estado de São Paulo. A área urbana corresponde a 6% da área total (67,25 km<sup>2</sup>), e a área urbana ocupada é de 33 km<sup>2</sup>.

Localizada (**Figura 4**) no centro geográfico do Estado de São Paulo (22°S; 48°W), a cidade de São Carlos possui características especiais que a tornam um local de destaque sob vários aspectos. O clima ameno, com temperatura média anual de 19,6 °C, somado às altitudes médias entre 800 e 1.000 metros, faz de São Carlos um local muito agradável, com inúmeras cachoeiras, curiosas formações geológicas e belíssimas paisagens.

É uma cidade de tamanho médio, se destaca entre as cidades médias brasileiras pelo vigor acadêmico, tecnológico e industrial. No setor industrial concentra grande volume de atividades, com mais de 1.600 empresas que produzem de bens de consumo a aplicações

meccânicas, sendo um dos munic pios a abrigar um “citygate” do gasoduto Brasil-Bol via. Os setores de agroind stria s o bem desenvolvidos, tanto na pecu ria (cintur o do leite) como na sucro-alcooleira, regi o destacada no cultivo de cana-de-a car. Segundo dados do IBGE (2009), S o Carlos possuem 213.314 habitantes, sendo 95,1% na  rea urbana. Possui intensa atividade industrial nas  reas mec nica, t xtil e cer mica e com expans o crescente da agroind stria, como a produ o de  lcool, papel e alimentos. Assim, pode ser considerada como representativa da parte do sudeste do pa s, que inclui cidades como Ribeir o Preto, Piracicaba, S o Jos  do Rio Preto etc., onde a atividade industrial rural   equivalente   urbana, justificando-se a import ncia do monitoramento da qualidade atmosf rica e a escolha de S o Carlos como epicentro das pesquisas (Marques, 2000).



Figura 4 - Localiza o do munic pio de S o Carlos no Estado de S o Paulo e no Brasil.

### 3.1.3 Sazonalidade e Climatologia

O clima de S o Carlos ([www.saocarlos.sp.gov.br](http://www.saocarlos.sp.gov.br))   temperado de altitude, apresenta ver o chuvoso e inverno seco, com precipita o m dia de 1.512 mm/ano e umidade relativa do ar m dia de 76% no ver o e 54% no inverno. A cidade apresenta como dados de altitude:

- m dia: 856 metros
- m nima: 520 metros
- m xima: 1000 metros

O clima da cidade de S o Carlos baseado na classifica o de Kl ppen   **Cwa**. Onde o grupo **C** determina climas mesot rmicos  midos, com o m s mais frio com m dia inferior a 18 C, mas superior a 3 C. **Cw** indica clima mesot rmico com inverno seco. Os sub- ndices **a** e **b** indicam neste grupo, se o m s mais quente tem m dia de temperatura superior ou inferior

a 22°C, respectivamente. Para o Brasil **Cwa** também indica climas com chuvas de verão (Enciclopédia Mirador Internacional, 1983).

Pela classificação de Strahler, a cidade de São Carlos encontra-se numa zona interfacial entre clima controlado por massa de ar equatoriais e tropicais (A<sub>3</sub>) (sub-índice 3 – clima tropical alternadamente úmido e seco), e de chuvas controladas por massas de ar tropicais e polares, que se estendem do sul do estado de São Paulo até o Rio Grande do Sul (Enciclopédia Mirador Internacional, op. cit.).

Existem flutuações climáticas, porém suas causas não são amplamente conhecidas, embora haja algumas hipóteses tais como: processos dos equinócios; variação na radiação solar, teor de CO<sub>2</sub> na atmosfera (efeito estufa) alternância nos períodos de circulação atmosférica zonal rápida e lenta, alternância de fases secas e úmidas em regiões intertropicais. Em algumas destas flutuações periódicas são dadas denominações especiais tais como El Niño, La Niña.

Verificou-se através de muitos artigos internacionais, que as estações do ano eram bem definidas em outros países, o que não acontece na região de nosso estudo. A região de São Carlos possui características peculiares, sendo possível separar as estações do ano em duas: Estação Seca (abril a setembro), a qual apresenta menor incidência de chuvas, e Estação Chuvosa (outubro a março), com maior incidência de chuvas; tais critérios foram utilizados neste trabalho. Essa divisão foi realizada para facilitar o tratamento de dados.

### **3.1.4 Área da Coleta**

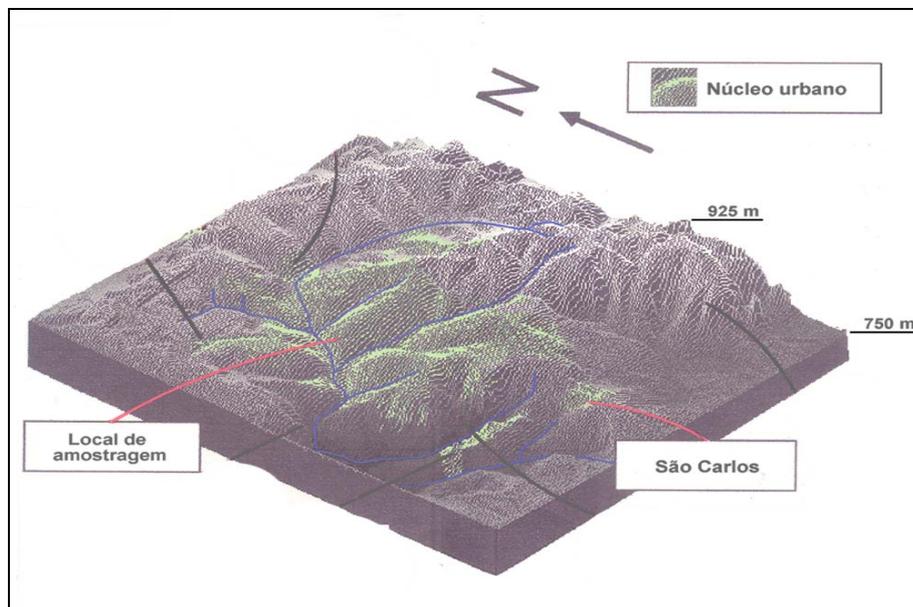
Segundo estudos preliminares realizados na cidade de São Carlos – SP, durante 1997-1998 (Celli, 1999; Marques 2000), que levava em conta à análise do MP total, determinou-se que dos cinco pontos de amostragem, três possuíam médias anuais próximas, sendo que dos outros dois, um localizado em zona estritamente industrial possuía uma média muito superior, e a outra localizada na zona rural possuía uma média anual menor para particulado total suspenso (PTS). Outros estudos relativos ao mesmo tema e pesquisados pelo nosso grupo podem ser consultados através das informações contidas no Anexo 1.

Na região onde se localiza a estação de monitoramento (Praça Voluntários da Pátria) foi realizado um estudo do fluxo de pessoas e veículos. Neste estudo determinou-se que aproximadamente 15.000 pedestres circulavam diariamente nesta região central, dando um pico de fluxo entre as 14h e 17h.

Quanto ao fluxo de automóveis, aproximadamente 30.000 veículos transitavam diariamente nessa região, com um pico por volta das 12h. Assim, devido à combinação de intenso fluxo de veículos e pedestres, estando estes, portanto, suscetíveis à influência do ar local, Celli (1999) decidiu fazer o monitoramento semanal da qualidade do ar, instalando o equipamento na Praça Voluntários da Pátria, ao lado da Avenida São Carlos. As coletas tiveram início em 1997 para o amostrador de grandes volumes e em 2001 para o amostrador dicotômico.

Uma das características a serem consideradas na escolha do melhor local para a locação da estação de monitoramento foi o relevo da cidade, e sua predominância de ventos. A Figura 5 ilustra o relevo, apresentando alta altitude na região central.

Outro fator de crucial importância na decisão foi a densidade populacional da região onde esta estação de monitoramento fosse instalada. Diversos estudos preliminares acusaram a região central como a melhor representatividade neste quesito, confirmado pelo que observa-se na **Figura 6**.



**Figura 5 - Relevo elevado da área de São Carlos (Oliveira, 1996)**

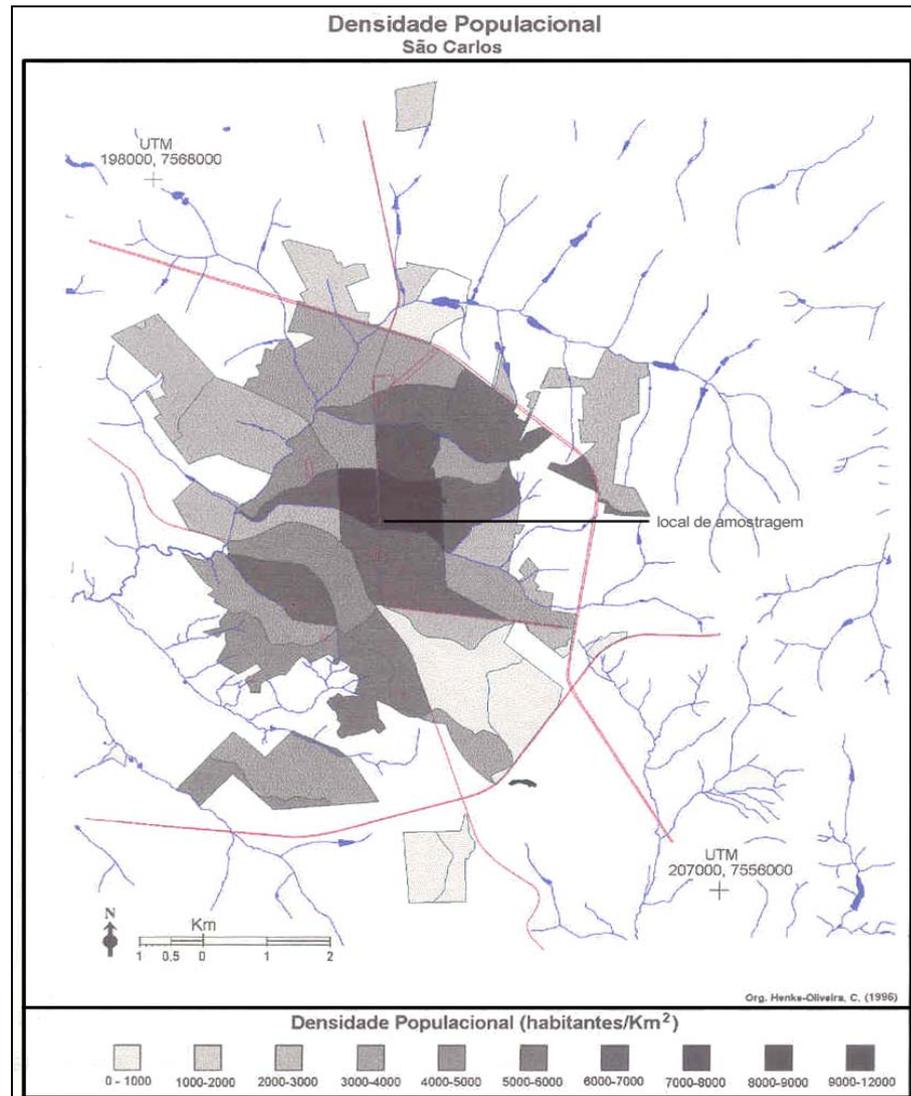


Figura 6 – Densidade populacional do município de São Carlos (Oliveira, 1996)

O mapa da cidade de São Carlos pode ser observado na Figura 7, destacando a Praça Voluntária da Pátria, na região central, onde foi implantada a estação de monitoramento.

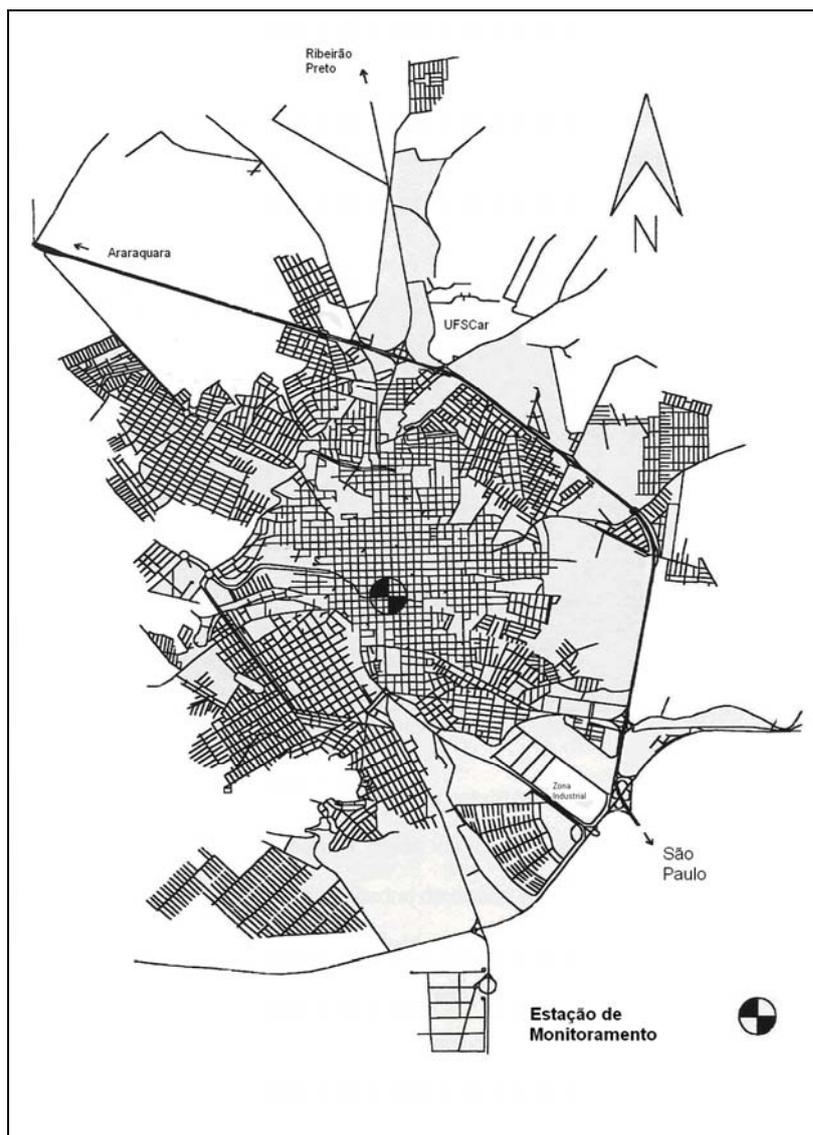


Figura 7 – Mapa do município de São Carlos destacando a localização da estação de coleta

Cabe observar que a Avenida São Carlos tem um ponto de ônibus (Figura 9) na Praça Voluntários da Pátria, muito próximo da estação de monitoramento (Figura 8). Somado a isso, existem dois semáforos: um antes da praça e outro logo após o ponto de ônibus apresentando, nesse trecho da avenida, um greide significativo. Isso faz com que as emissões de material particulado no local sejam maiores, já que os ônibus estão funcionando em modo de maior consumo de combustível (mistura rica).

Um fator relevante é que até o ano de 2004 existiam muitos vendedores ambulantes na Praça, nos arredores da estação amostradora. Estes ambulantes comercializavam diversos artigos, inclusive alimentos que eram fritos na hora, causando vários tipos de emissão. Em 2005, após a construção do camelódromo, eles mudaram-se para o outro lado do rio,

diminuindo consideravelmente a circulação de pedestres naquele local. Outra emissão que deve ser considerada é a proveniente de pólen das plantas e árvores presentes na praça.



Figura 8 - Localização da estação de coleta e monitoramento.



Figura 9 - Estação amostradora no centro da cidade de São Carlos

### 3.2 Amostragem

A determinação do material particulado (MP) em suspensão pode ser considerada como um processo de duas fases. Primeiramente, o ar ambiente carregado de particulados é amostrado através de amostradores específicos que possuem um apropriado orifício de entrada por onde o fluxo de ar passa, depositando o MP sobre um filtro. Em seguida, realiza-se a análise do material coletado. O conceito de método de amostragem se torna um tanto genérico se levarmos em consideração apenas a configuração do orifício de entrada do equipamento e o fluxo de ar amostrado. Programas de monitoramentos específicos são

caracterizados pela escolha prévia do método de amostragem em associação com o subsequente método de análise a ser utilizado (Almeida, 1999).

Foram realizadas amostragens para avaliar o monitoramento da qualidade do ar (na estação amostradora, localizada no centro da cidade de São Carlos) semanalmente. A metodologia consiste na amostragem do material particulado em filtros em um amostrador dicotômico e um amostrador de grandes volumes (AGV) MP<sub>10</sub>. Após a coleta de dados de concentração de MP, os dados seguiram para análise de séries temporais, através da plataforma “R”.

As amostragens de monitoramento aconteceram em dias da semana, aleatoriamente, uma ou duas vezes por semana, por períodos de 24 horas.

### 3.2.1 Amostrador de Grandes Volumes (AGV) MP<sub>10</sub>

A coleta de MP<sub>10</sub> em suspensão na atmosfera foi feita utilizando-se um AGV MP<sub>10</sub>, modelo HV1200/MFC da marca Graseby-GMW, mostrado na Figura 10.

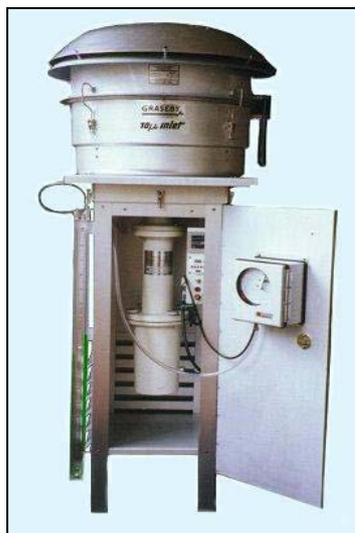


Figura 10 - Amostrador de Grandes Volumes AGV MP<sub>10</sub>

O equipamento possui uma bomba de sucção à vazão constante, a qual é controlada por um medidor de vazão do tipo Venturi e um cabeçote dotado de um separador inercial. O ar entra pelo cabeçote perfazendo 360° de forma que a amostragem seja feita independente da direção do vento (vide Figura 11) e a geometria de entrada da cabeça de separação favorece apenas a coleta de partículas com diâmetro aerodinâmico igual ou inferior a 10 $\mu$ m. O ar é então acelerado por nove bocais e é projetado para a câmara de impactação inercial, onde o

material que possui diâmetro maior que  $10\mu\text{m}$  fica retido numa placa untada com graxa de silicone.

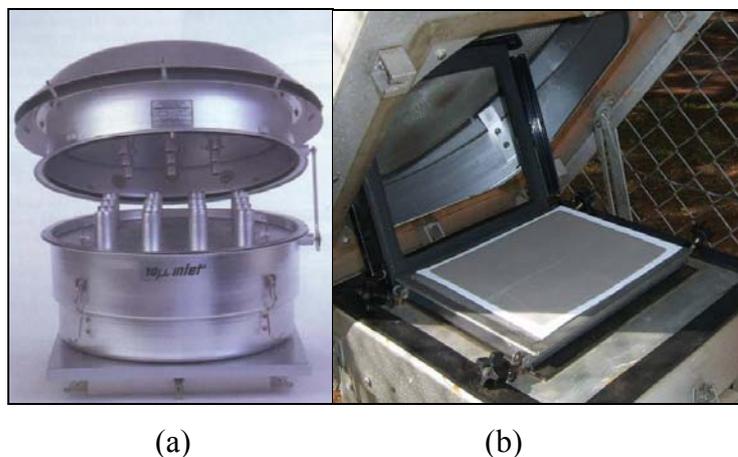


Figura 11 - Cabeçote de separação do AGV MP<sub>10</sub> com detalhe dos 9 bocais (a) e detalhe do filtro sujo no equipamento (b)

O MP é coletado num filtro de fibra de vidro de dimensões 20x25 cm que possui eficiência de 99% para partículas maiores do que  $0,3\ \mu\text{m}$  de tamanho.

O AGV MP<sub>10</sub> succiona uma certa quantidade de ar ambiente através de um filtro, instalado dentro da camisa de abrigo, durante um período de amostragem de 24 horas (nominais). A vazão imprimida pelo aparelho, em torno de  $1,13\ \text{m}^3/\text{min}$ , e a geometria de entrada da cabeça de separação favorecem apenas a coleta de partículas com diâmetro aerodinâmico  $\leq 10\ \mu\text{m}$ . A duração de amostragem é controlada por um programador de tempo (timer com exatidão de pelo menos  $\pm 15$  minutos em 24 horas).

O filtro é pesado (após equilibrada a umidade em dessecador e estufa) antes e após a coleta para se determinar o ganho líquido em peso (massa). O volume amostrado é corrigido para condições padrão ( $25\ ^\circ\text{C}$ ,  $760\ \text{mm Hg}$ ), determinado a partir da vazão medida e o tempo de amostragem.

Este método é o mais apropriado para amostragem de material particulado total e respirável em suspensão. É referência para a legislação brasileira, norte americana, e atende às normas de outras instituições como a ABNT (Associação Brasileira de Normas Técnicas), CETESB (Companhia de Tecnologia de Saneamento Ambiental – SP) e FEEMA (Fundação Estadual de Engenharia de Meio Ambiente –RJ) (Celli, 1999).

### 3.2.2 Amostrador Dicotômico

O amostrador dicotômico é um impactador virtual que separa aerodinamicamente partículas em frações de tamanho correspondente a moda fina e grossa da distribuição normal de tamanho das partículas do ar ambiente. O equipamento utilizado em nossa amostragem é da marca Andersen Modelo AS 241.

O dicotômico possui uma bomba de sucção, que suga o ar através de um *in let* (região de entrada, admissão), perfazendo 360°, coletando o ar por qualquer direção.

O MP é retido em filtros de teflon com diâmetro de 37 mm e diâmetro de poro de 2  $\mu\text{m}$ , da marca Pall.

A Figura 12 ilustra dois filtros após a amostragem, nas frações  $\text{MP}_{10-2,5}$  e  $\text{MP}_{2,5}$ , respectivamente.

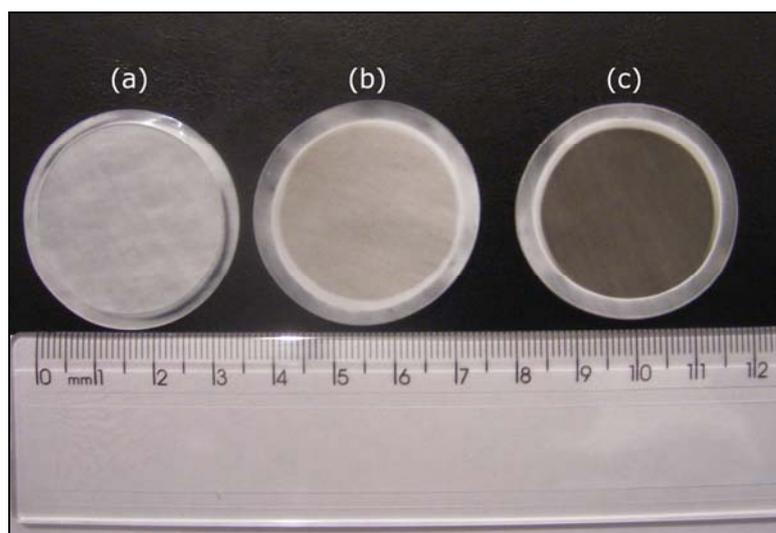


Figura 12 - Filtros para amostragem em dicotômico antes (a) e após a coleta de  $\text{MP}_{10-2,5}$  (b) e  $\text{MP}_{2,5}$  (c).

A Figura 13 mostra fotografias desse equipamento que é considerado como método de referência da USEPA. Nesta figura (b) nota-se em primeiro plano o *container* das bombas de vácuo e dos manômetros, e em segundo plano a armação de amostragem. Na parte superior da armação nota-se a entrada para a amostragem, que possui um impactador inercial que separa o  $\text{MP}_{10-2,5}$  do  $\text{MP}_{2,5}$ .



a) (b)

Figura 13 - Foto do amostrador dicotômico na estação de monitoramento (a) e com detalhe do painel de controle de pressão e vazão (b)

Após o fracionamento inicial, o escoamento ar-partículas é impelido a um impactador virtual, onde é subdividido em duas correntes, uma com diâmetro de corte médio de  $2,5 \mu\text{m}$  (chamadas de partículas finas) e a outra com a fração grossa (do particulado respirável  $\text{MP}_{10}$ ). Cada uma destas correntes segue para um meio filtrante onde o MP é retido. A Figura 14 mostra um esquema de funcionamento do dicotômico.

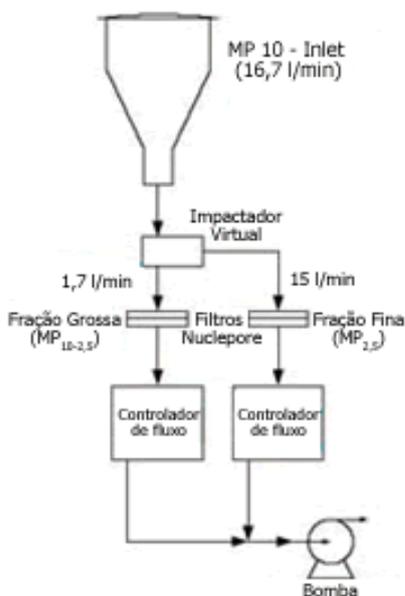


Figura 14 - Esquema de funcionamento do amostrador dicotômico

A concentração de MP é medida após a pesagem dos filtros em balança micro analítica, e é calculada utilizando-se a expressão:

$$MP(\mu\text{g} / \text{m}^3) = \frac{m_f - m_i}{V * \Delta t} \quad (3.1)$$

onde:

$m_f$ : massa do filtro depois da amostragem

$m_i$ : massa do filtro antes da amostragem

V: vazão de entrada do ar no coletor

$\Delta t$ : tempo de amostragem

### 3.2.3 Campanha realizada

Foram realizadas amostragens para monitorar a qualidade do ar (na estação amostradora, localizada no centro da cidade de São Carlos) semanalmente. A metodologia consiste na amostragem com a coleta de MP em filtros apropriados para cada tipo de amostrador para a obtenção da concentração de MP. As amostragens de monitoramento aconteceram em dias úteis, aleatoriamente, uma ou duas vezes por semana, por períodos de 24 horas.

Para a análise de concentração de  $MP_{10}$  utilizaram-se dados obtidos no período de setembro de 1997 a fevereiro de 2006. Para o  $MP_{2,5}$  e  $MP_{10-2,5}$  foram utilizados dados obtidos entre junho de 2001 e fevereiro de 2006.

### 3.2.4 A plataforma “R”

As análises estatísticas foram realizadas com versão 2.8.0 da plataforma R (R Development Core Team, 2008), um dialeto da linguagem matemática orientada a objetos S, distribuída gratuitamente sob os termos da licença GNU GPL (*General Public License*) e também o editor Tinn-R V.1.19.4.7. Para trabalhar com os dados da série temporal, é preciso fazer o tratamento dos dados, em seguida, é feita a identificação do melhor modelo ARIMA que se ajuste à série transformada, e por fim, é feita a validação do modelo comparando com valores observados. A interface do Tinn-R e do R podem ser vistas no Anexo 2.

A grande vantagem do R é tratar-se de um pacote de livre acesso, distribuído sob Licença Pública Geral, podendo ser livremente copiado e distribuído entre usuários. R é um conjunto integrado de programas para manipulação de dados, cálculo e gráficos. Entre outras características permite:

- manipulação e armazenamento efetivo de dados;
- operadores para cálculo sobre variáveis indexadas e cálculo matricial;

- uma vasta, coerente e integrada coleção de ferramentas para análise de dados;
- capacidades gráficas para análise exploratória de dados, que permitem a visualização direta ou para impressão;
- uma linguagem de programação bem desenvolvida, simples e eficiente, que inclui estruturas cíclicas, funções recursivas, e capacidade de entrada e saída de dados.

O R é uma linguagem ambiente para computação estatística e gráfica, fornecendo uma grande variedade de técnicas estatísticas (modelagem linear e não linear, testes estatísticos de agrupamento, análises de séries temporais etc...). O termo “ambiente” caracteriza R como um sistema completamente planejado e coerente, e não apenas como um conjunto ampliado de ferramentas muito específicas e inflexíveis, como é frequentemente o caso de outros programas de análise de dados.

R é em grande parte um veículo para o desenvolvimento de novos métodos interativos de análise de dados. Como tal é muito dinâmico e as diferentes versões nem sempre são compatíveis com as anteriores. Se alguns usuários preferem as alterações pelos novos métodos e tecnologias que acompanham as novas versões, outros pelo contrário, ficam desiludidos porque seus códigos-fonte deixaram de funcionar. Embora R possa ser entendido como se tratando de uma linguagem de programação, os programas escritos em R devem considerar-se essencialmente efêmeros.

## CAPÍTULO 4 TRATAMENTO PRELIMINAR DOS DADOS

A abordagem sistemática pela qual se responde à questão de se ter dados correlacionados no tempo é chamada de *Análise de Séries Temporais*.

O primeiro passo na investigação de uma série temporal deve sempre ser um cuidadoso escrutínio dos dados registrados em um gráfico ao longo do tempo. Isso sugere o método de análise, assim como um resumo estatístico geral dos dados observados.

Devido à grande quantidade de dados e também um intervalo não equidistante dos dados de coleta, em alguns casos, para a modelagem utilizou-se as médias mensais de dados coletados semanalmente. Os dados originais para série dos equipamentos AGV ( $MP_{10}$ ) e dicotômico  $MP_{2,5}$  e  $MP_{10-2,5}$ ) podem ser encontrados nos Anexos 3,4 e 5 respectivamente.

Antes de se obter o modelo é necessário fazer o tratamento dos dados das séries. As análises estatísticas foram realizadas meio da plataforma R (R Development Core Team, 2008). O primeiro passo é a localização de valores espúrios, ou seja, valores irreais de cada série. Esta análise foi feita verificando a presença de *outliers* e valores extremos por meio dos gráficos *box-plot*. As observações consideradas *outliers* e valores extremos foram excluídas das séries antes do processamento das séries temporais. Como estes valores retirados levam a valores ausentes, em alguns casos, novos valores foram obtidos pelo método de *median of nearby values*, através do software SPSS (Statistical Package for the Social Sciences). Existem vários métodos de se obter valores ausentes, como mostra Gnauck (2004), e a escolha deste método foi feita pela comparação com outros métodos como interpolação linear, tendência linear, média da série etc., buscando qual era o mais adequado para a série analisada.

Os dados de uma série temporal precisam apresentar intervalos de tempo igualmente espaçados. Como os dados obtidos nas séries não têm intervalos equidistantes de amostragem, foram obtidas médias mensais. As séries temporais obtidas por este processo foram então divididas em duas partes. A primeira, para a obtenção do modelo, e a segunda, para a validação da previsão do modelo obtido. Foram adotados os últimos valores de cada série para a validação, dependendo do tamanho da série, tem-se os últimos 6 (seis) ou últimos 30 (trinta) valores.

Após a retirada dos *outliers* e valores extremos, as séries foram decompostas para identificar a presença de sazonalidade e tendência. Se confirmadas tendência e sazonalidade, a

série pode ser explicada e realizar previsões pelo modelo SARIMA ou ARIMA sazonal (Morettin e Toloí, 2006).

#### 4.1 Dados do AVG MP<sub>10</sub>

Os dados coletados na amostragem de MP<sub>10</sub> pelo equipamento AGV MP<sub>10</sub> foram de MP<sub>10</sub> coletados entre setembro de 1997 e fevereiro de 2006, como ilustrado no gráfico da Figura 15. Pela legislação ambiental, o limite máximo de concentração de MP<sub>10</sub>, numa amostragem de 24h é de 150 µg/m<sup>3</sup>, na figura observa-se que os dados monitorados não extrapolaram este limite. Pode-se observar uma nítida sazonalidade de concentração, com picos nos períodos de inverno (baixa pluviosidade).

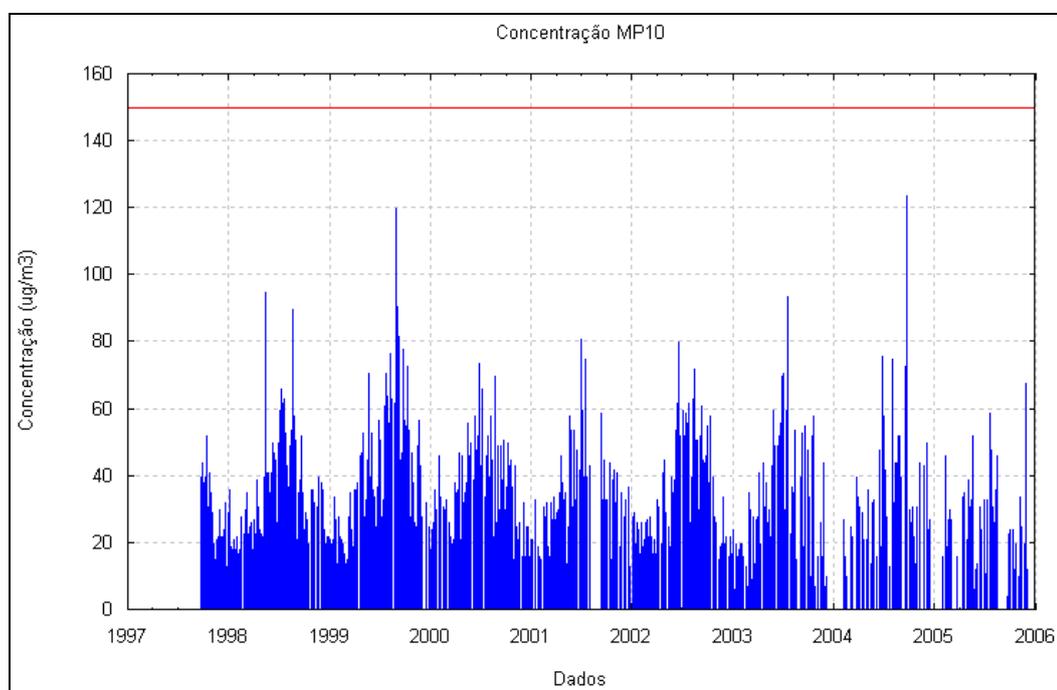


Figura 15 - Dados de monitoramento de MP<sub>10</sub> realizado com AGV MP<sub>10</sub>

Após observação de todos os valores, aplicou-se o Box-Plot para a identificação de outliers e valores extremos, como observado na Figura 16.

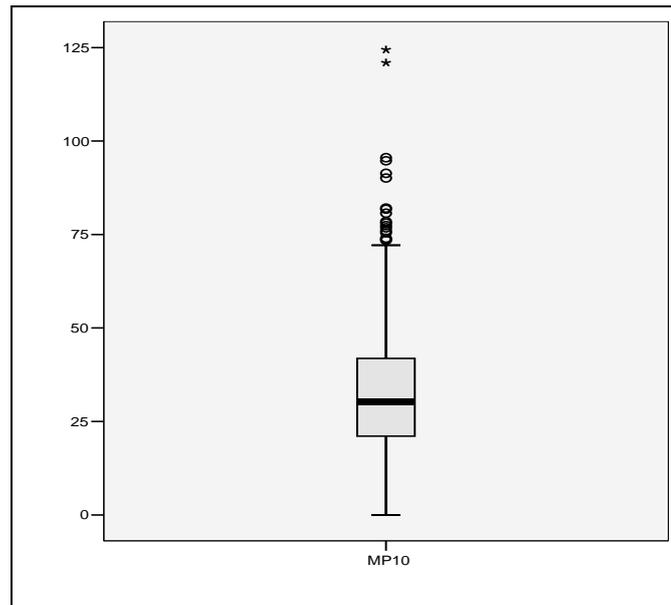


Figura 16 - Box-plot para a série  $MP_{10}$

A etapa seguinte compreendeu a eliminação de valores extremos e *outliers* e sua substituição dos valores ausentes.

A série temporal obtida por este processo foi dividida em duas partes. A primeira, para a obtenção do modelo, e a segunda, para a validação da previsão do modelo obtido. Foram adotados os últimos 30 valores da série para a validação, como mostrado na Figura 17, que apresenta dados de médias mensais a partir de setembro de 1997. Dentre estes 30 valores, é possível observar que alguns pontos apresentam baixos valores de concentração em relação a todos os valores usados para a modelagem, o que pode aumentar os erros finais na validação. A série destinada à modelagem foi então transformada com a aplicação do logaritmo, o que leva à obtenção de um modelo mais simples.

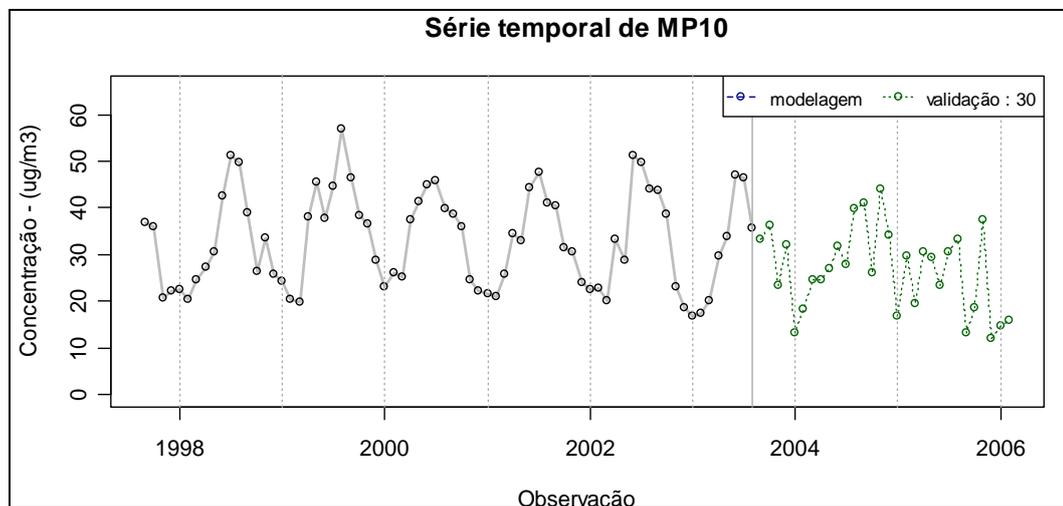


Figura 17 - Série temporal e valores usados para a validação do modelo da série  $MP_{10}$

## 4.2 Dados do Amostrador Dicotômico

O equipamento dicotômico coleta partículas nas frações  $MP_{2,5}$  e  $MP_{10-2,5}$ . As coletas foram realizadas no período de 2001 a 2006.

### 4.2.1 Fração $MP_{2,5}$

Os dados coletados na amostragem estão ilustrados no gráfico da Figura 18. Pela legislação ambiental (USEPA), o limite máximo de concentração de  $MP_{2,5}$ , numa amostragem de 24h é de  $65 \mu\text{g}/\text{m}^3$ . Pela Figura 18 observa-se que os dados monitorados não extrapolaram este limite, com exceção de um dado do mês de julho de 2005, o qual consideramos um ponto espúrio.

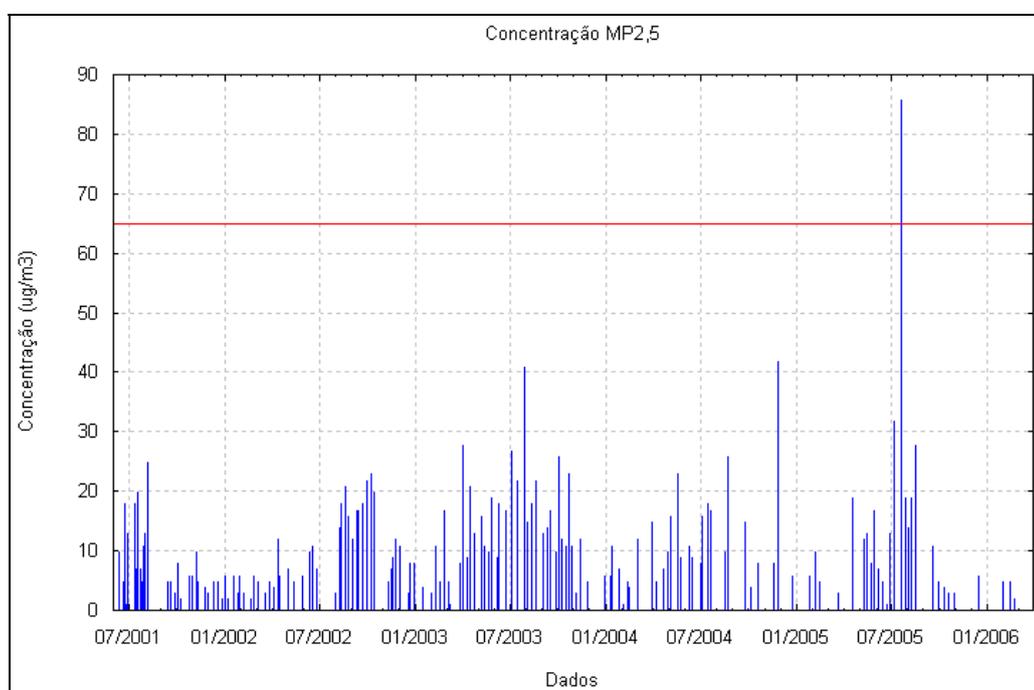


Figura 18 - Dados de monitoramento de  $MP_{2,5}$  realizado com Amostrador Dicotômico

Antes de se obter o modelo é necessário fazer o tratamento dos dados da série de  $MP_{2,5}$ . Tomando-se os mesmos procedimentos da série anterior. Após observação de todos os valores, aplicou-se o Box-Plot para a identificação de outliers e valores extremos, como observado na Figura 19.

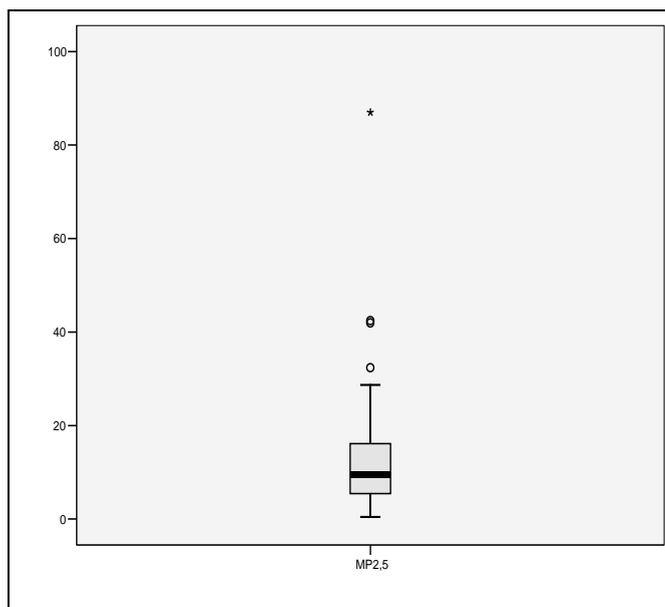


Figura 19 - Box-plot para a série  $MP_{2,5}$

A etapa seguinte compreendeu a eliminação de valores extremos e *outliers* e sua substituição dos valores ausentes.

Como os dados obtidos não têm intervalos equidistantes de amostragem, foram obtidas médias mensais. A série temporal obtida por este processo foi então dividida em duas partes. A primeira, para a obtenção do modelo, e a segunda, para a validação da previsão do modelo obtido. Foram adotados os últimos 6 valores da série para a validação, como mostrado na Figura 20. Dentre estes 6 valores, observar-se que alguns pontos que apresentam baixos valores de concentração em relação a todos os valores usados para a modelagem, resultando num aumento dos erros finais na validação. A série destinada à modelagem foi então transformada com a aplicação do logaritmo, o que leva à obtenção de um modelo mais simples. Também verifica-se que série de dados do  $MP_{2,5}$ , obtidos experimentalmente através do monitoramento da qualidade do ar, apresenta um comportamento sazonal.

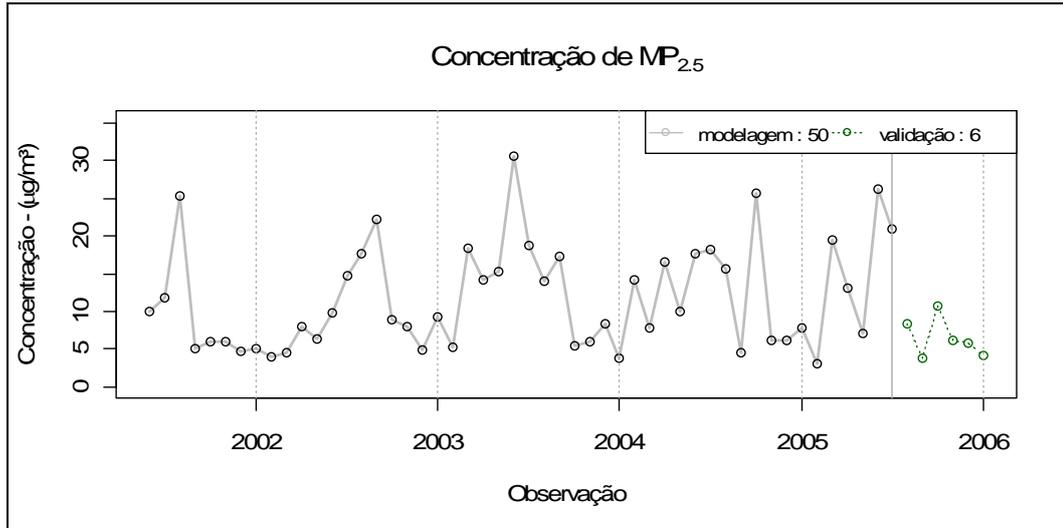


Figura 20 - Série temporal e valores usados para a validação do modelo da série MP<sub>2,5</sub>

#### 4.2.2 Fração MP<sub>10-2,5</sub>

Os dados coletados na amostragem desta fração estão ilustrados no gráfico da Figura 21. Esta fração de material particulado não tem especificação na legislação quanto aos limites máximos de concentração tolerável, entretanto pode se observar que os valores não ultrapassaram o limite para todo o MP<sub>10</sub> (150 µg/m<sup>3</sup> em amostragem de 24h).

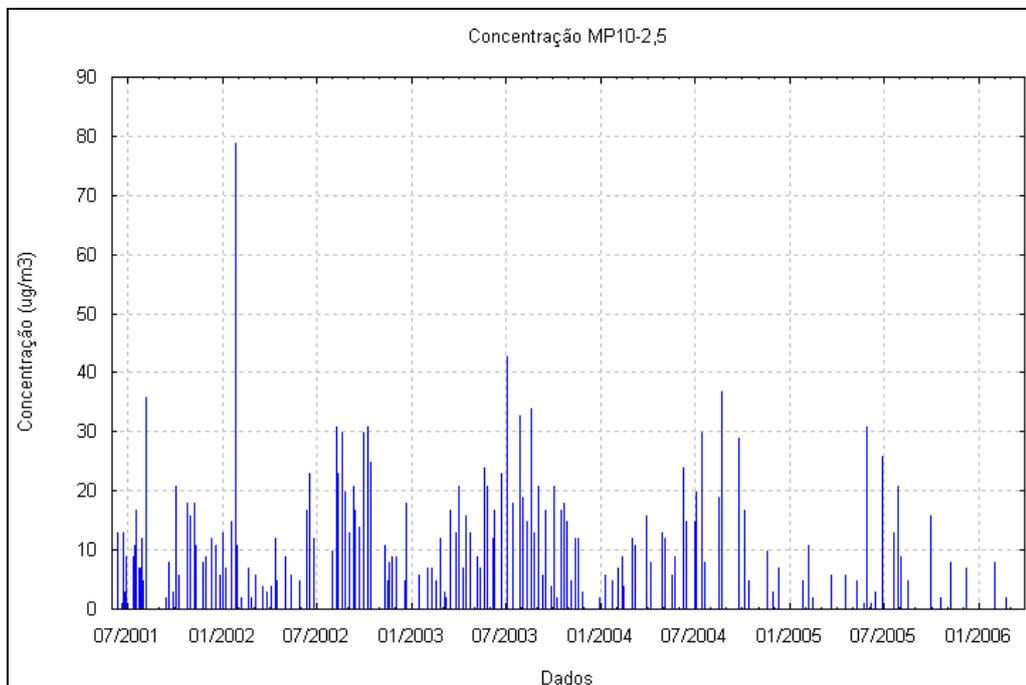


Figura 21 - Dados de monitoramento de MP<sub>10-2,5</sub> realizado com Amostrador Dicotômico

Antes de se obter o modelo é necessário fazer o tratamento dos dados da série de  $MP_{10-2,5}$ . Tomando-se os mesmos procedimentos da série anterior. Após observação de todos os valores, aplicou-se o Box-Plot para a identificação de outliers e valores extremos, como observado na Figura 22.

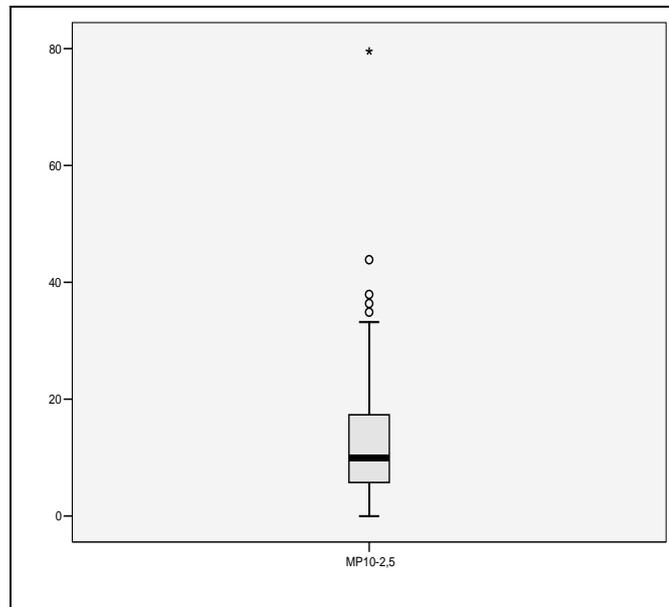


Figura 22 - Box-plot para a série  $MP_{10-2,5}$

A etapa seguinte compreendeu a eliminação de valores extremos e *outliers* e sua substituição dos valores ausentes.

A série temporal obtida por este processo foi então dividida em duas partes. A primeira, para a obtenção do modelo, e a segunda, para a validação da previsão do modelo obtido. Foram adotados os últimos 6 valores da série para a validação, como mostrado na Figura 23. Dentre estes 6 valores, é possível observar que alguns pontos apresentam baixos valores de concentração em relação a todos os valores usados para a modelagem, o que pode aumentar os erros finais na validação.

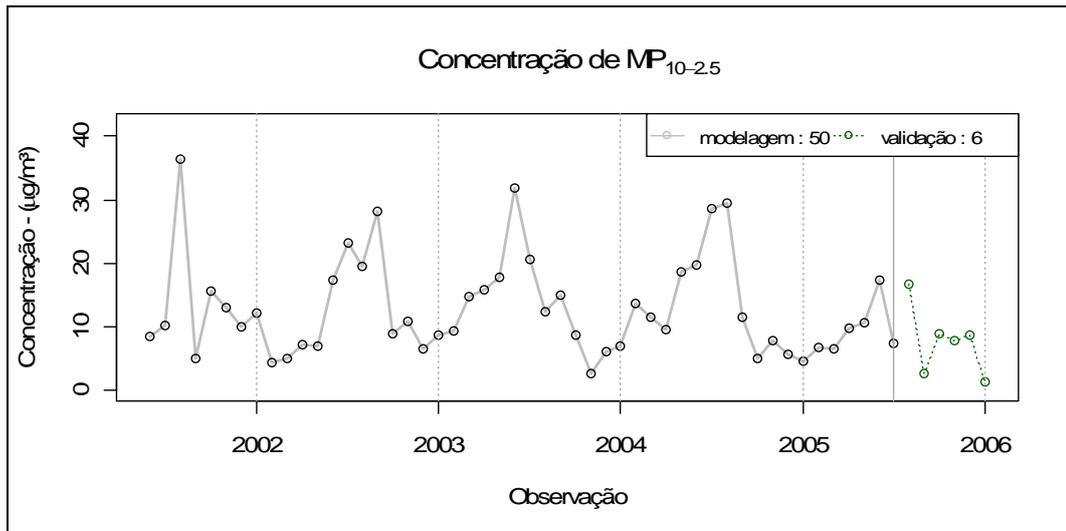


Figura 23 - Série temporal e valores usados para a validação do modelo da série MP<sub>10-2.5</sub>

## CAPÍTULO 5 MODELAGEM E DISCUSSÃO DOS RESULTADOS

Para a identificação dos modelos adequados foram feitos vários testes preliminares e depois a validação e comparação dos mesmos.

As primeiras modelagens foram realizadas considerando os modelos auto-regressivos (AR de ordem  $p$ ), médias móveis (MA de ordem  $q$ ) e auto-regressivo com médias móveis (ARMA de ordem  $p, q$ ). Observando-se os resultados verificou-se que os resíduos destes modelos não apresentavam ruído branco, portanto não identificavam toda a informação dos dados. Além disso, foi observada a presença de sazonalidade. Sendo assim, o modelo SARIMA  $(p,d,q) \times (P,D,Q)_s$  foi o modelo apropriado para estes casos. Os modelos SARIMA foram comparados com o Método de suavização exponencial de Holt-Winters.

O processo de seleção do melhor modelo SARIMA foi feito usando como medida para o ajuste o valor do menor valor do critério de informação de Akaike (AIC). A busca pelo menor AIC se deve ao fato de que o modelo com o menor valor geralmente apresenta resíduos similares a ruído branco (Makridakis *et al.*, 2003 *apud* Mishra e Desai, 2005). Segundo Morettin e Toloí (2006), devem-se buscar modelos com poucos parâmetros, e no caso de modelos para a previsão, escolhe-se um grupo de modelos para verificar qual apresenta o melhor desempenho na predição. Assim, por meio da variação sucessiva dos parâmetros  $(p,q)$  e  $(P,Q)$  do modelo ARIMA sazonal, foram obtidos 10 modelos com os menores valores de AIC.

Dentre estes dez modelos, realizaram-se análises estatísticas dos parâmetros, escolhendo para previsão o modelo com menor número de parâmetros significativos. O desempenho do modelo escolhido foi verificado usando os dados dos últimos meses de cada série para a validação analisando os valores de MAPE (Mean Absolute Percentage Error), RMSE (Root Means Square Error) e RMSE percentual, detalhamento destes podem ser encontrados no Anexo 6. Dependendo do tamanho da série foi estipulado um número determinado de meses para validação dos resultados.

Para análise dos resíduos, foram traçados gráficos de Ljung-Box e QQ plot Normal. Se o ajuste do modelo estiver adequado espera-se que seus resíduos apresentem distribuição normal e não haja correlação com o tempo. Evidência de correlação ao longo do tempo nos resíduos é uma indicação de que uma ou mais características da série não foram adequadamente descritas pelo modelo.

## 5.1 Dados do AVG MP<sub>10</sub>

### *Identificação do modelo*

A escolha do modelo univariado compreende duas etapas: a análise da estacionariedade e normalidade da série e a estrutura da correlação temporal (Mishra e Desai, 2005). Na primeira etapa, determina-se o nível de diferenciação ( $d$  e  $D$ ) necessário para tornar a série estacionária e atingir a normalidade. Neste trabalho, foram adotados os testes de Dickey-Fuller (estacionariedade) e de Shapiro-Wilk (normalidade).

A Figura 24 apresenta as representações gráficas das funções de autocorrelação (FAC) da série transformada e suas diferenças de ordem 1 e 2. O comportamento da FAC da série, aparentemente, não indica a necessidade de diferenças para torná-la estacionária, pois os lags são significativos até a ordem 2.

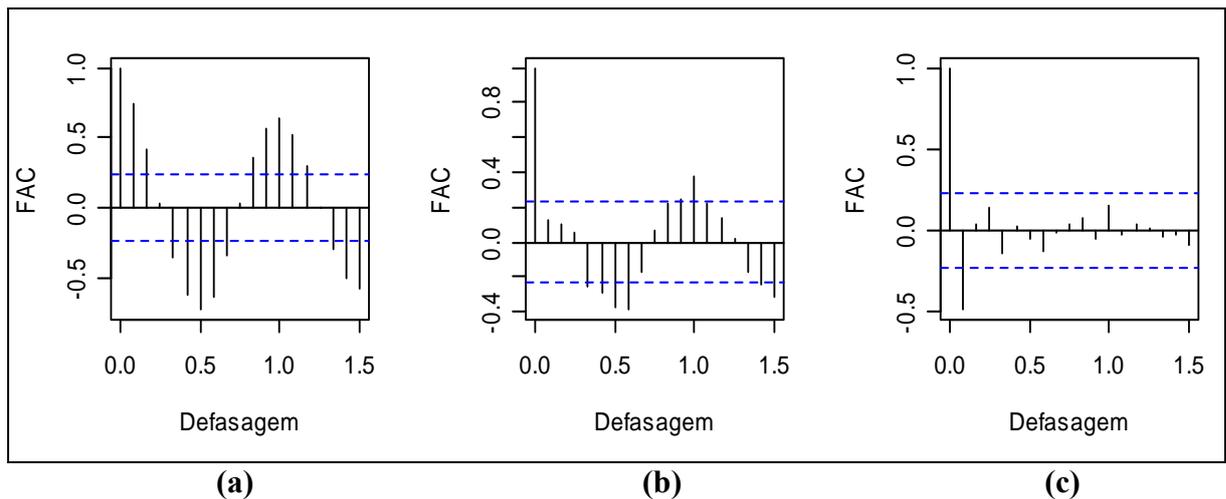


Figura 24 – Teste de estacionariedade da série MP<sub>10</sub>. Funções de autocorrelação –FAC (a) da série transformada e suas diferenças de ordem 1 (b) e de ordem 2 (c)

Ao analisar a normalidade da série pelo teste de Shapiro-Wilk ( $p > 0,05$ ), mostrado na Figura 25, pode-se observar que a série original não apresenta normalidade ( $p = 0,009$ ), sendo necessário a aplicação de diferenciação para torná-la estacionária ( $p = 0,267$ ).

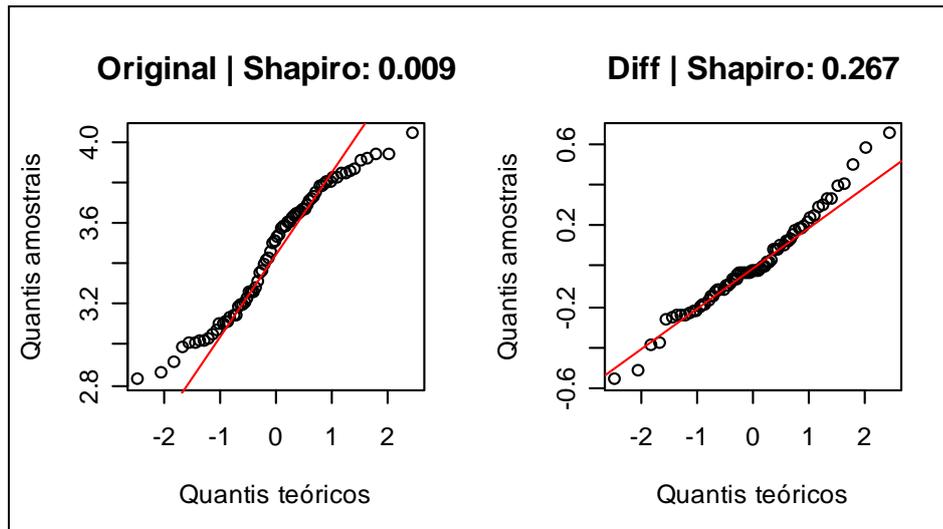


Figura 25 - Teste de normalidade da série  $MP_{10}$

Para determinar a estrutura da correlação temporal da série transformada são analisadas as funções de autocorrelação (FAC) e autocorrelação parcial (FACP) e, a partir desta informação, determinar a forma geral do modelo a ser ajustado. No entanto, segundo Ong *et al.* (2005), quando a série temporal tem os efeitos autoregressivos (AR) e médias móveis (MA), os gráficos de FAC e FACP não apresentam de forma clara as defasagens a serem identificadas o que, segundo Ehlers (2005), envolve algum grau de arbitrariedade na interpretação destas funções. Como alternativa, podem ser usados algoritmos, como feito em Ong *et al.* (2005) ou então usar uma busca seqüencial dos modelos que apresentem os menores valores do critério de informação de Akaike (AIC – Akaike Information Criterion) ao variar os parâmetros do modelo dentro de um certo intervalo.

A busca pelo menor AIC se deve ao fato de que o modelo com o menor valor geralmente apresenta resíduos similares a ruído branco (Makridakis *et al.*, 2003 *apud* Mishra e Desai, 2005). Apesar de este método consumir certo tempo de processamento, dependendo do intervalo de variação adotado para cada parâmetro, não é um valor significativo em máquinas com processadores atuais. Por meio da variação sucessiva dos parâmetros ( $p,q$ ) e ( $P,Q$ ) do modelo ARIMA, foram obtidos os modelos com os menores valores de AIC, mostrados os 10 menores na Tabela 4. Detalhamento da análise pode ser encontrado no Anexo 7.

Tabela 4 - Comparação dos modelos obtidos com menor AIC

	Modelo	AIC	Parâmetros
M1	arima (2,0,2)×(1,0,0)6	-56,37248	5
M2	arima (2,1,3)×(0,0,0)6	-56,06557	6
M3	arima (1,0,0)×(1,0,1)6	-50,44648	3
M4	arima (0,0,1)×(1,0,1)6	-49,88188	3
M5	arima (1,0,1)×(1,0,1)6	-48,75357	4
M6	arima (2,0,0)×(1,0,1)6	-48,55726	4
M7	arima (0,0,2)×(1,0,1)6	-47,98307	4
M8	arima (0,0,3)×(1,0,1)6	-47,54608	5
M9	arima (2,0,3)×(1,0,1)6	-47,54444	7
M10	arima (1,0,2)×(1,0,1)6	-47,20685	5

O modelo com menor AIC, chamado M1, apresenta um grande número de parâmetros. Segundo Morettin e Tolo (2006), devem-se buscar modelos com poucos parâmetros, e no caso de modelos para a previsão, escolhe-se um grupo de modelos para verificar qual apresenta o melhor desempenho na predição. Desta forma, foram selecionados seis modelos, M1, M3, M4, M5, M6 e M7. Escolhidos por apresentarem um menor número de parâmetros. Para estes modelos, foi feita a análise estatísticas dos parâmetros (Tabela 5) para verificar se todos são significativos. Observa-se que os modelos M1, M4, M5, M6 e M7 apresentaram problemas com parâmetros, sendo estes modelos eliminados da seleção.

Tabela 5 - Análise estatística dos parâmetros dos modelos

Modelo	Parâmetros	Variáveis		
		Valor	Erro padrão	$p < 0,05$
M1	$\varphi_1$	1,7335	0,0031	0,00000
	$\varphi_2$	-0,9995	0,010	0,00000
	$\theta_1$	-1,6981	0,0955	0,00000
	$\theta_2$	0,9997	0,1082	0,00000
	$\Phi_1$	<b>0,0606</b>	<b>0,1272</b>	<b>0,31701</b>
	Intercepto	3,4535	0,0197	0,00000
M3	$\varphi_1$	0,3237	0,1239	0,00448
	$\Phi_1$	-0,9979	0,0089	0,00000
	$\Theta_1$	0,9049	0,1930	0,00000
	Intercepto	3,4510	0,0238	0,00000
M4	$\theta_1$	<b>0,3093</b>	<b>0,1234</b>	<b>0,00610</b>
	$\Phi_1$	-0,9992	0,0062	0,00000
	$\Theta_1$	0,9372	0,2376	0,00004
	Intercepto	3,4515	0,0212	0,00000
M5	$\varphi_1$	<b>0,5712</b>	<b>0,3705</b>	<b>0,066160</b>
	$\theta_1$	<b>-0,2897</b>	<b>0,4595</b>	<b>0,26418</b>
	$\Phi_1$	-0,9971	0,0088	0,00000
	$\Theta_1$	0,8852	0,1712	0,00000
	Intercepto	3,4503	0,0263	0,00000

Continuação da Tabela 5

<b>M6</b>	$\varphi_1$	<b>0,3102</b>	<b>0,1292</b>	<b>0,00820</b>
	$\varphi_2$	<b>0,0408</b>	<b>0,1223</b>	<b>0,36946</b>
	$\Phi_1$	-0,9974	0,0093	0,00000
	$\Theta_1$	0,8953	0,1835	0,00000
	Intercepto	3,4508	0,00247	0,00000
<b>M7</b>	$\theta_1$	<b>0,3098</b>	<b>0,1296</b>	<b>0,00842</b>
	$\theta_2$	<b>0,0394</b>	<b>0,1247</b>	<b>0,37589</b>
	$\Phi_1$	-0,9988	0,0077	0,00000
	$\Theta_1$	0,9262	0,2369	0,00005
	Intercepto	3,4514	0,0218	0,00000

Em um bom modelo de previsão, os resíduos do modelo ajustado devem apresentar ruído branco e distribuição normal. A evidência de correlação ao longo do tempo nos resíduos indica que uma ou mais características da série não foram adequadamente descritas pelo modelo. Para verificar se há correlação nos resíduos no modelo M3 e se este apresenta ruído branco, foi traçado o gráfico do teste de Ljung-Box ( $p > 0,05$ ). A Figura 26 mostra que no modelo M3 não há correlação. Os resíduos encontram-se distribuídos aleatoriamente em torno de zero, confirmando ser um processo de ruído branco.

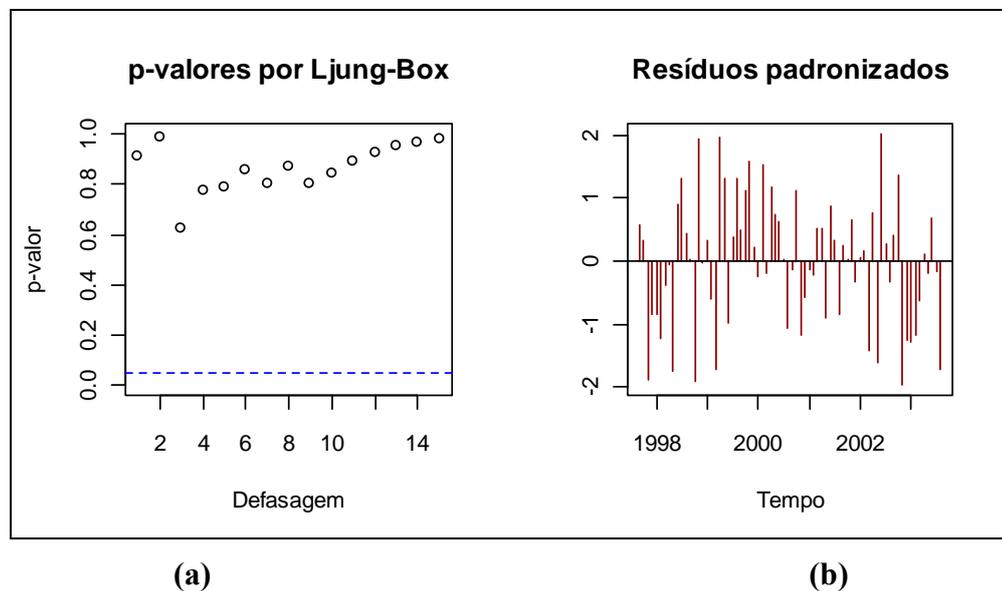


Figura 26 - Teste de Ljung-Box (a) e resíduos (b) para o modelo M3.

Outra característica a ser analisada para um bom modelo é FAC e FACP, os quais são apresentados na Figura 27. O gráfico de FAC mostra que apenas o primeiro lag é significativo, o que confirma a independência de resíduos e estes se distribuem aleatoriamente

em torno de zero (0). O gráfico FACP mostra que todos os lags não são significativos identificando um processo de ruído branco.

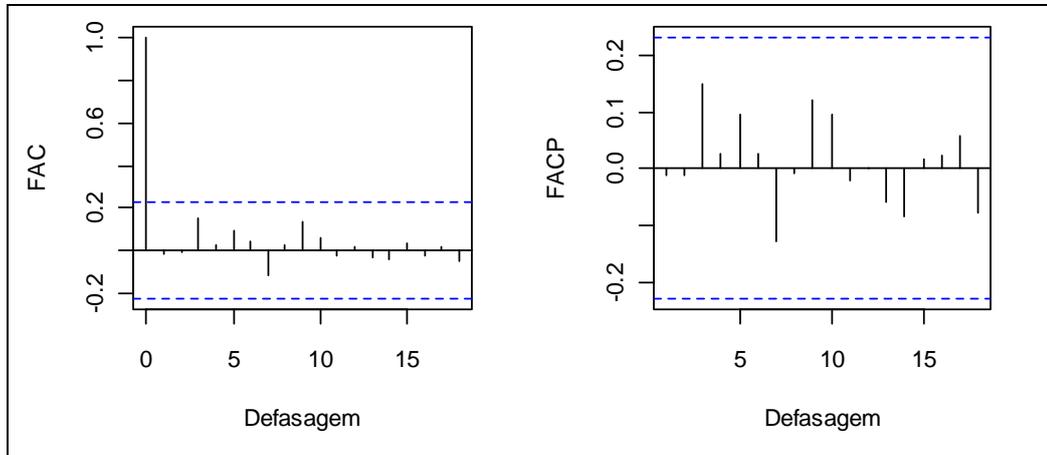


Figura 27 – Funções de autocorrelação (FAC) e autocorrelação parcial (FACP) para o modelo M3

Para verificar se os resíduos do modelo M3 apresentavam distribuição normal, foram traçados o histograma e o QQ-plot com teste de Shapiro-Wilk ( $p > 0,05$ ), mostrados na Figura 28, onde se pode verificar que os resíduos apresentam normalidade.

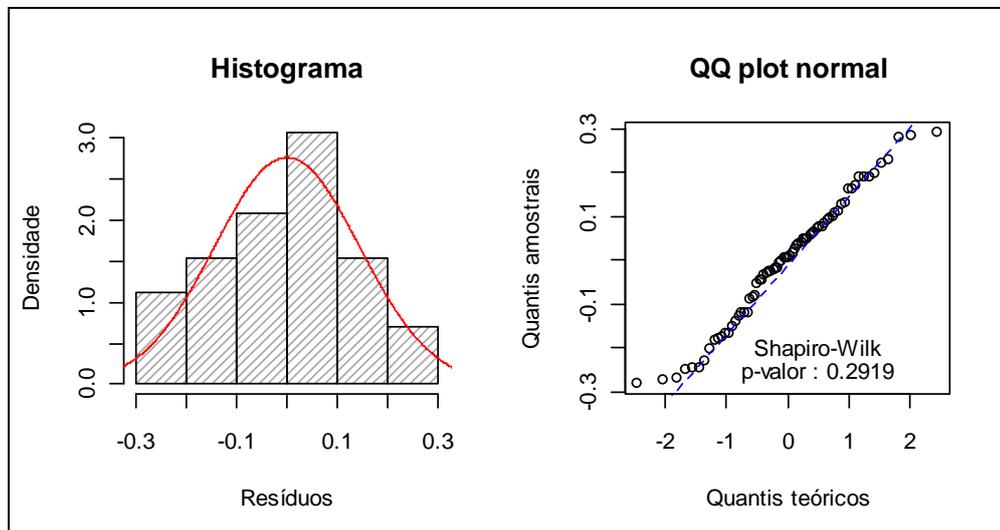


Figura 28 - Teste de normalidade do modelo M3

### **Validação e previsão**

O desempenho do modelo SARIMA(1,0,0)×(1,0,1)<sub>6</sub> ou M3 foi verificado comparando os dados dos últimos 30 valores observados da série com os valores previstos pelo modelo. Para isto, foram considerados os valores de MAPE, RMSE e RMSE percentual, que foram

comparados com o modelo de alisamento exponencial de Holt-Winters, mostrados na Tabela 6.

Tabela 6 - Comparação com Holt-Winters

	MAPE	RMSE	RMSE%
ARIMA M3	0,41	10,96	0,57
Holt-Winters	0,53	15,43	0,72

Os dados da tabela acima mostram que os valores obtidos com o modelo M3 são mais próximos aos valores observados, representando melhor a série analisada do que o modelo de Holt-Winters. A Figura 29 mostra os valores preditos pelo modelo com os valores observados e os intervalos de confiança. Pode-se notar que o modelo representou bem a série, apresentando maiores concentrações nos meses de inverno e menores concentrações nos meses de verão. Ainda na Figura 29, é possível ver que o modelo ficou distante dos baixos valores de concentração (início de 2004 e de 2006), estes baixos valores podem ser resultado da mudança dos vendedores ambulantes, o que resultou numa diminuição no fluxo de pessoas e também na quantidade de emissões.

Foram utilizados 30 valores para validação, um número considerado ideal seriam 12 pontos para previsão, pois quanto maior menor a confiança no modelo, por este motivo os valores finais observados estão mais afastados dos valores previstos pelo modelo estudado.

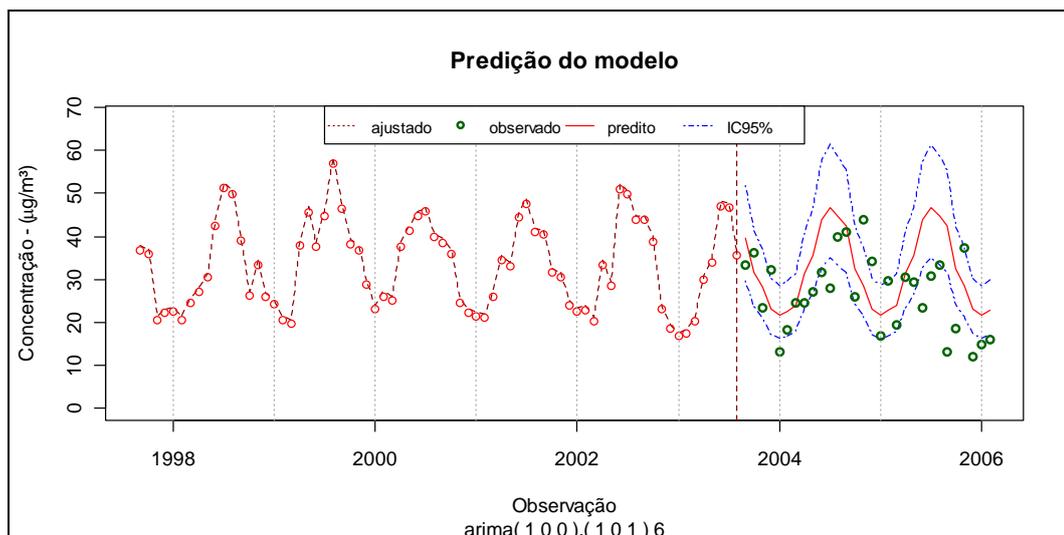


Figura 29 - Valores preditos pelo modelo M3

## 5.2 Dados do Amostrador Dicotômico

Para os dados do equipamento dicotômico também foram escolhidos os dez modelos com menor AIC e menor número de parâmetros, como realizado para os dados do AGV MP<sub>10</sub>.

após esta análise preliminar escolheu-se o modelo que atendesse além deste critério, os testes de normalidade e resíduos, além da verificação da significância dos parâmetros. Os detalhes dos 10 modelos com menor valor de AIC para cada série de dados estão apresentados nos Anexos 8 e 9.

### 5.2.1 Fração $MP_{2,5}$

#### *Identificação do modelo*

A Figura 30 apresenta as representações gráficas das funções de autocorrelação (FAC) da série transformada e suas diferenças de ordem 1, 2 e 3. O comportamento da FAC da série, aparentemente, indica a necessidade de diferenças para torná-la estacionária.

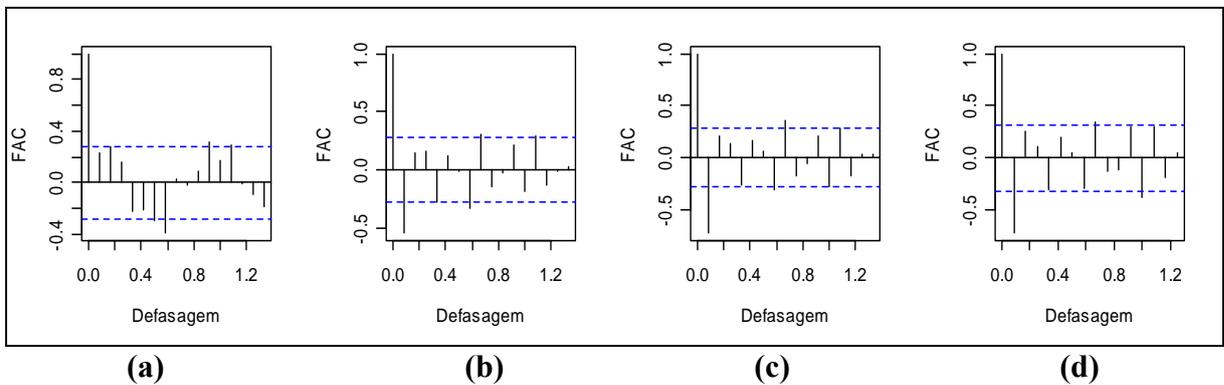


Figura 30 – Teste de estacionariedade da série  $MP_{2,5}$ . Funções de autocorrelação –FAC (a) da série transformada e suas diferenças de ordem 1 (b), de ordem 2 (c) e de ordem 3 (d)

Ao analisar a normalidade da série pelo teste de Shapiro-Wilk ( $p > 0,05$ ), mostrado na Figura 31, pode-se observar que a série original não apresenta normalidade ( $p = 0,083$ ), sendo necessário a aplicação de diferenciação para torná-la estacionária ( $p = 0,568$ ).

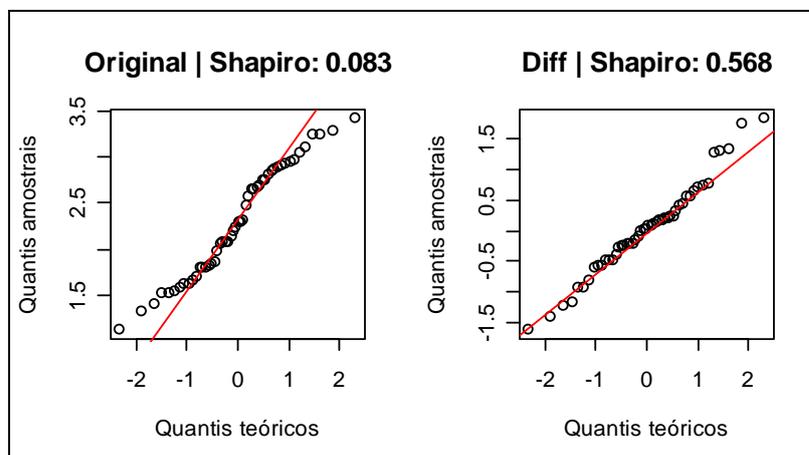


Figura 31 - Teste de normalidade da série  $MP_{2,5}$

Por meio da variação sucessiva dos parâmetros  $(p,q)$  e  $(P,Q)$  do modelo ARIMA, foram obtidos os modelos com os menores valores de AIC, mostrados os 10 menores na Tabela 7. Detalhamento da análise pode ser encontrado no Anexo 8.

Tabela 7 - Comparação dos modelos obtidos com menor AIC para dados da série  $MP_{2,5}$

	Modelo	AIC	Parâmetros
M1	arima (2,1,3)×(1,0,1) <sub>6</sub>	84,14907	8
M2	arima (0,0,3)×(1,0,1) <sub>6</sub>	84,34229	5
M3	arima (0,0,2)×(1,0,1) <sub>6</sub>	85,18649	4
M4	arima (1,0,2)×(1,0,1) <sub>6</sub>	85,51312	5
M5	arima (2,0,3)×(0,0,0) <sub>6</sub>	85,65818	5
M6	arima (2,0,2)×(1,0,1) <sub>6</sub>	86,23122	6
M7	arima (0,0,3)×(1,0,0) <sub>6</sub>	86,33125	4
M8	arima (1,0,3)×(1,0,1) <sub>6</sub>	86,34090	6
M9	arima (2,1,3)×(1,0,0) <sub>6</sub>	86,48810	7
M10	arima (0,0,3)×(0,0,1) <sub>6</sub>	86,70969	4

O modelo com menor AIC, chamado M1, apresenta um grande número de parâmetros. Foram selecionados quatro modelos, M1, M3, M7 e M10. Estes modelos foram escolhidos por apresentarem um menor número de parâmetros e menor AIC. Para estes modelos, foi realizada a análise estatísticas dos parâmetros (Tabela 8) para verificar se todos são significativos. Observa-se que os modelos M7 e M10 apresentaram problemas com parâmetros, sendo estes modelos eliminados da seleção.

Tabela 8 - Análise estatística dos parâmetros dos modelos

Modelo	Parâmetros	Variáveis		
		Valor	Erro padrão	$p < 0,05$
M1	$\varphi_1$	1,6499	0,0604	0,00000
	$\varphi_2$	-0,9558	0,0646	0,00000
	$\theta_1$	-1,4460	0,1671	0,00000
	$\theta_2$	0,756	0,1762	0,00000
	Intercepto	2,3612	0,0734	0,00000
M3	$\varphi_1$	0,3237	0,1239	0,00448
	$\Phi_1$	-0,9979	0,0089	0,00000
	$\Theta_1$	0,9049	0,1930	0,00000
	Intercepto	3,4510	0,0238	0,00000
M7	$\theta_1$	<b>-0,0108</b>	<b>0,1406</b>	<b>0,46947</b>
	$\theta_2$	0,3814	0,1233	0,00099
	$\theta_3$	0,3166	0,1579	0,02247
	$\Phi_1$	-0,3290	0,1738	0,02917
	Intercepto	2,301	0,091	0,00000
M10	$\theta_1$	<b>0,0238</b>	<b>0,1307</b>	<b>0,42787</b>
	$\theta_2$	0,3773	0,1197	0,00081
	$\theta_3$	0,3448	0,1468	0,00941
	$\Theta_1$	-0,3070	0,1783	0,04255
	Intercepto	2,3070	0,0891	0,00000

A evidência de correlação ao longo do tempo nos resíduos indica que uma ou mais características da série não foram adequadamente descritas pelo modelo. Para verificar se há correlação nos resíduos nos modelos M1 e M3 e se estes apresentam ruído branco, foram traçados os gráficos do teste de Ljung-Box ( $p > 0,05$ ). A Figura 32 mostra que no modelo M1 não há correlação. Já, através da Figura 33 verifica-se que no modelo M3 há correlação, sendo este eliminado. Esta correlação é observada através do gráfico de Ljung-Box, onde os p valores devem ser maiores que 0,05.

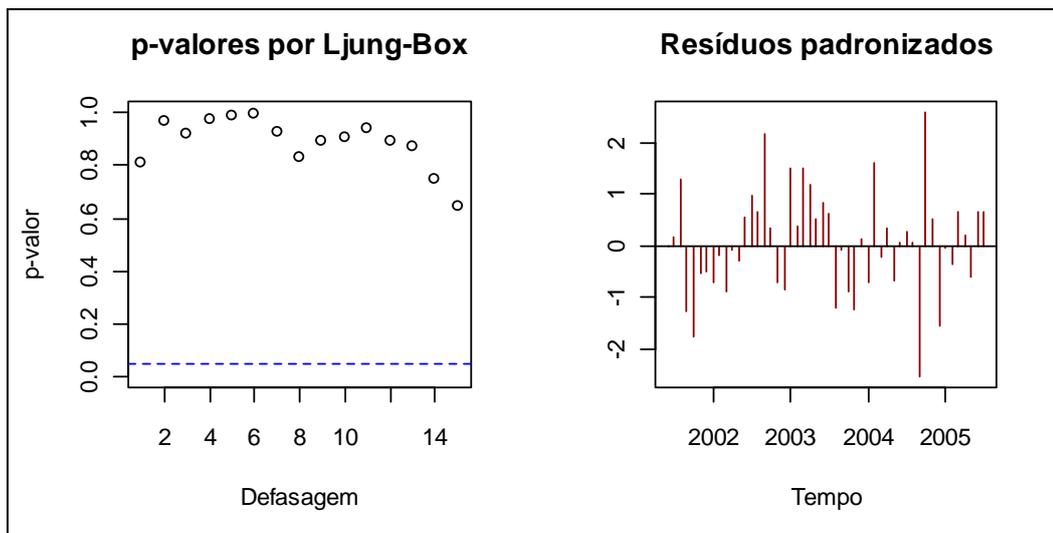


Figura 32 - Teste de Ljung-Box e resíduos para o modelo M1.

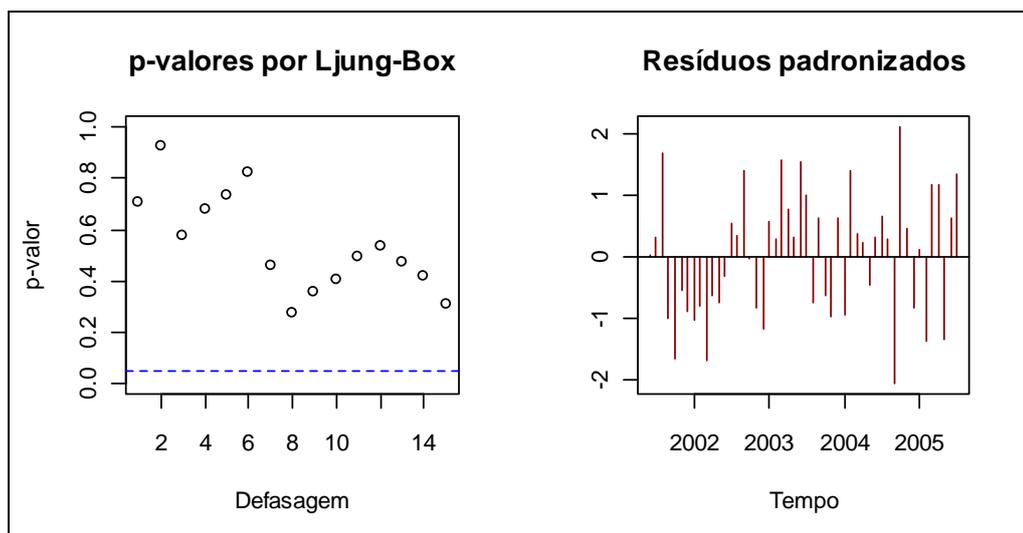


Figura 33 - Teste de Ljung-Box e resíduos para o modelo M3.

Outra característica a ser analisada para um bom modelo é FAC e FACP, os quais são apresentados na Figura 34. Estes gráficos confirmam independência de resíduos e ruído branco no modelo M1.

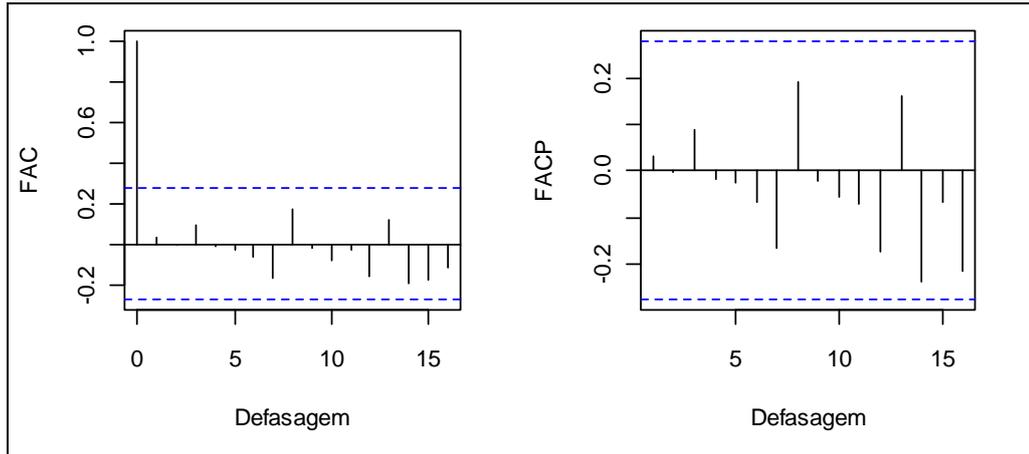


Figura 34 – Funções de autocorrelação (FAC) e autocorrelação parcial (FACP) para o modelo M1

Para verificar se os resíduos do modelo M1 apresentavam distribuição normal, foram traçados o histograma e o QQ-plot com teste de Shapiro-Wilk ( $p > 0,05$ ), mostrados na Figura 35, onde se pode verificar que os resíduos apresentam normalidade.

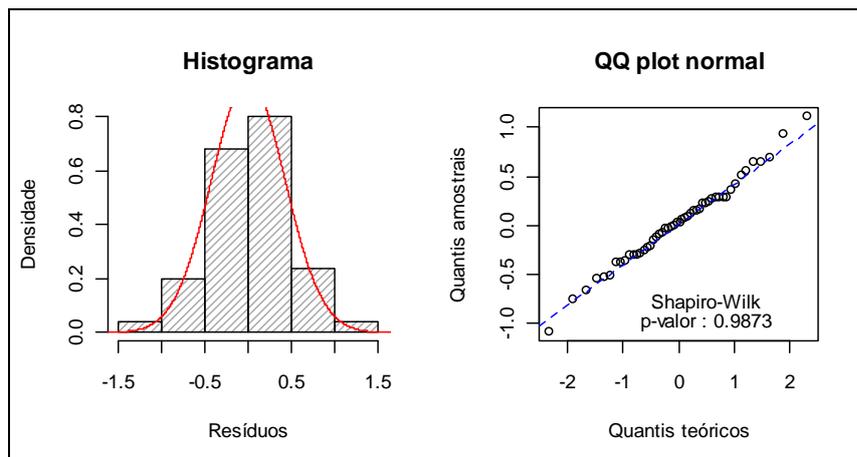


Figura 35 - Teste de normalidade do modelo M1

### 5.2.2 FraçãoMP<sub>10-2,5</sub>

A Figura 36 apresenta as representações gráficas das funções de autocorrelação (FAC) da série transformada e suas diferenças de ordem 1, e 2. O comportamento da FAC da série, aparentemente, não indica a necessidade de diferenças para torná-la estacionária.

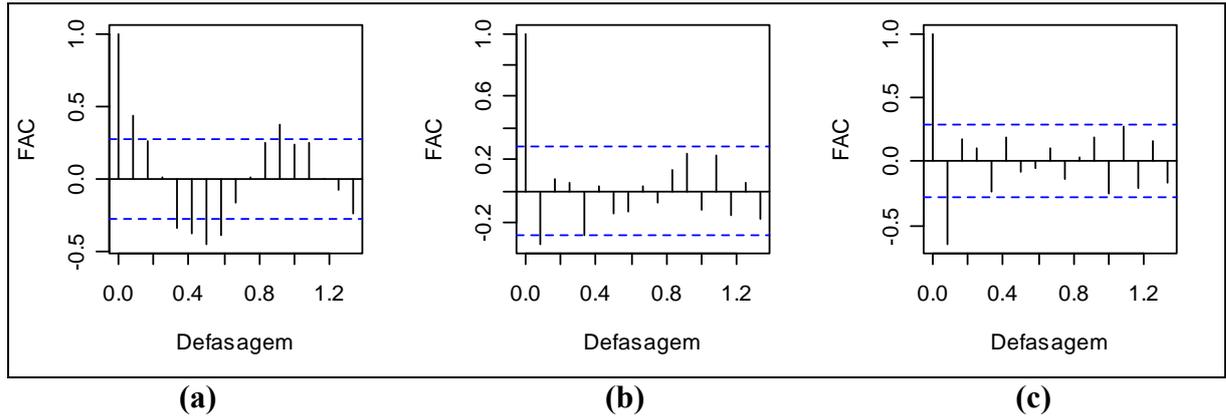


Figura 36 – Teste de estacionariedade da série  $MP_{10-2,5}$ . Funções de autocorrelação –FAC (a) da série transformada e suas diferenças de ordem 1 (b) e de ordem 2 (c)

Ao analisar a normalidade da série pelo teste de Shapiro-Wilk ( $p > 0,05$ ), mostrado na Figura 37, pode-se observar que a série original já apresenta normalidade ( $p = 0,9$ ), não sendo necessário a aplicação de diferenciação para torná-la estacionária.

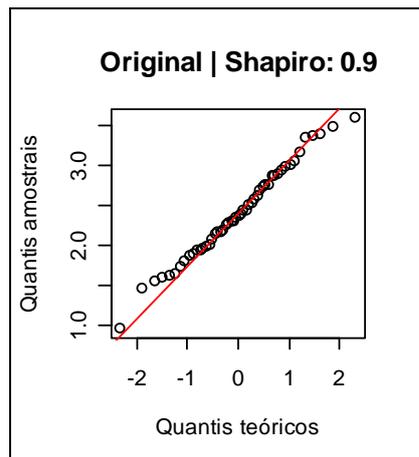


Figura 37 - Teste de normalidade da série  $MP_{10-2,5}$

Por meio da variação sucessiva dos parâmetros  $(p, q)$  e  $(P, Q)$  do modelo ARIMA, foram obtidos os modelos com os menores valores de AIC, mostrados os 10 menores na Tabela 9. Detalhamento da análise pode ser encontrado no Anexo 9.

Tabela 9 - Comparação dos modelos obtidos com menor AIC para dados da série  $MP_{10-2,5}$

	Modelo	AIC	Parâmetros
M1	arima (2,0,2)×(0,0,0) <sub>6</sub>	77,08133	4
M2	arima (2,0,2)×(1,0,0) <sub>6</sub>	78,75297	5
M3	arima (2,0,3)×(0,0,1) <sub>6</sub>	79,03707	6
M4	arima (2,0,2)×(0,0,1) <sub>6</sub>	79,23380	5
M5	arima (2,0,3)×(1,0,0) <sub>6</sub>	79,23550	6
M6	arima (1,0,3)×(0,0,1) <sub>6</sub>	79,68164	5
M7	arima (1,0,0)×(0,0,1) <sub>6</sub>	79,77015	2
M8	arima (1,0,0)×(1,0,0) <sub>6</sub>	79,88796	2
M9	arima (1,0,3)×(1,0,0) <sub>6</sub>	79,89975	5
M10	arima (0,0,1)×(0,0,1) <sub>6</sub>	80,39325	2

O modelo com menor AIC, chamado M1, apresenta um grande número de parâmetros. Foram selecionados outros três modelos, M7, M8 e M10. Estes modelos foram escolhidos por apresentarem um menor número de parâmetros. Para estes modelos, foi realizada a análise estatística dos parâmetros (Tabela 10) para verificar se todos são significativos. Observa-se que os modelos M7 e M10 apresentaram problemas com parâmetros, sendo estes modelos eliminados da seleção.

Tabela 10 - Análise estatística dos parâmetros dos modelos

Modelo	Parâmetros	Variáveis		
		Valor	Erro padrão	$p < 0,05$
M1	$\varphi_1$	1,6499	0,0604	0,00000
	$\varphi_2$	-0,9558	0,0646	0,00000
	$\theta_1$	-1,4460	0,1671	0,00000
	$\theta_2$	0,756	0,1762	0,00000
	Intercepto	2,3612	0,0734	0,00000
<b>M7</b>	$\varphi_1$	<b>0,3304</b>	<b>0,1359</b>	<b>0,00752</b>
	$\Theta_1$	-0,3973	0,1527	0,00463
	Intercepto	2,3911	0,0678	0,00000
M8	$\varphi_1$	02791	0,1500	0,03139
	$\Phi_1$	-0,3842	0,1516	0,00563
	Intercepto	2,3809	0,0716	0,00000
<b>M10</b>	$\theta_1$	<b>0,3058</b>	<b>0,1358</b>	<b>0,01218</b>
	$\Theta_1$	-0,4416	0,1480	0,00142
	Intercepto	2,3955	0,0565	0,00000

A evidência de correlação ao longo do tempo nos resíduos indica que uma ou mais características da série não foram adequadamente descritas pelo modelo. Para verificar se há correlação nos resíduos nos modelos M1 e M8 e se estes apresentam ruído branco, foram traçados os gráficos do teste de Ljung-Box ( $p > 0,05$ ). A Figura 38 mostra que no modelo M1 não há correlação, o que não ocorre com o modelo M8, mostrado na Figura 39.

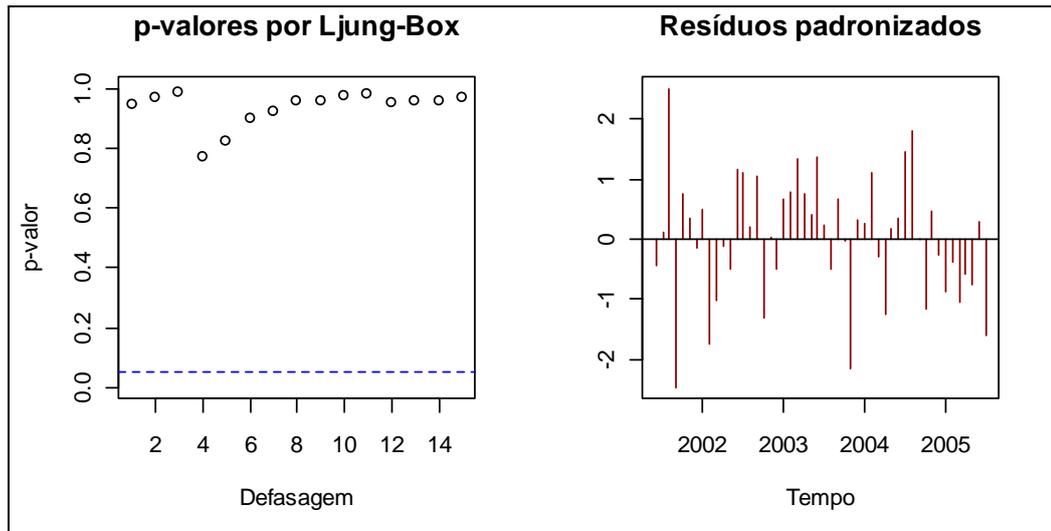


Figura 38 - Teste de Ljung-Box e resíduos para o modelo M1.

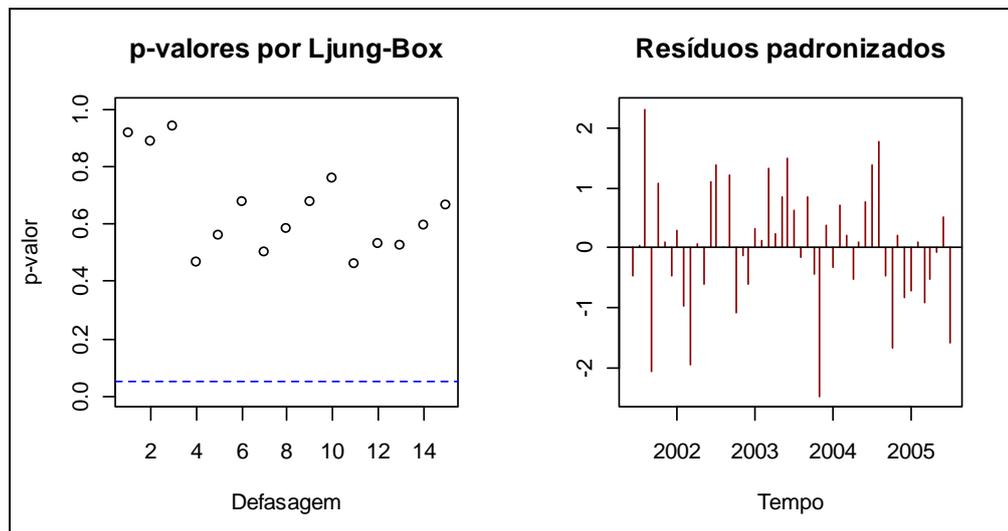


Figura 39 - Teste de Ljung-Box e resíduos para o modelo M8.

Outra característica a ser analisada para um bom modelo é FAC e FACP, os quais são apresentados na Figura 40. Estes gráficos confirmam independência de resíduos e ruído branco no modelo M1.

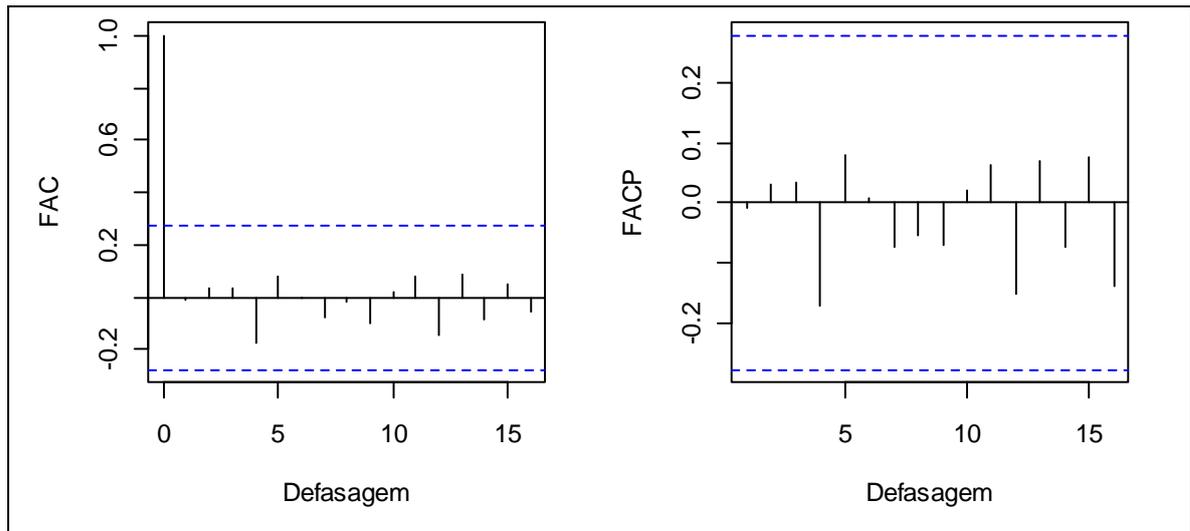


Figura 40 – Funções de autocorrelação (FAC) e autocorrelação parcial (FACP) para o modelo M1

Para verificar se os resíduos do modelo M1 apresentavam distribuição normal, foram traçados o histograma e o QQ-plot com teste de Shapiro-Wilk ( $p > 0,05$ ), mostrados na Figura 41, onde se pode verificar que os resíduos apresentam normalidade.

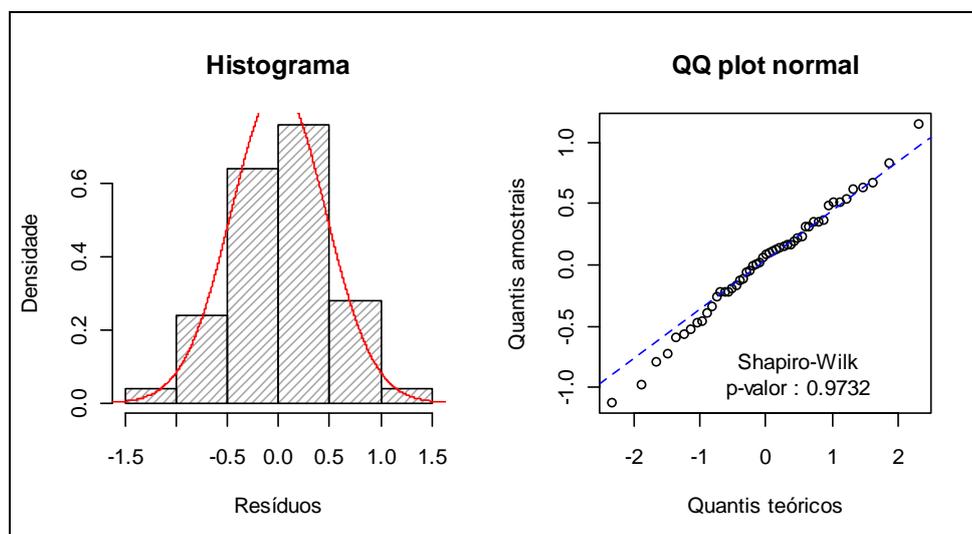


Figura 41 - Teste de normalidade do modelo M1

### Validação e previsão

O desempenho dos modelos  $SARIMA(2,1,3) \times (1,0,1)_6$  ou M1 (série  $MP_{2,5}$ ) e  $SARIMA(2,0,2) \times (1,0,0)_6$  ou M1 (série  $MP_{10-2,5}$ ) foram verificados comparando os dados dos últimos 6 valores observados da série com os valores previstos pelos modelos. A validação foi feita considerando os valores de MAPE, RMSE e RMSE percentual, que foram comparados aos valores de Holt-Winters, como mostrado na Tabela 11. A O modelo da série  $MP_{10-2,5}$

apresentou valores maiores para MAPE e RMSE percentual do que o modelo da série MP<sub>2,5</sub>.

Tabela 11 - Comparação com Holt-Winters

		MAPE	RMSE	RMSE%
MP <sub>2,5</sub>	ARIMA	0,86	5,57	1,12
	Holt-Winters	2,39	15,70	3,17
MP <sub>10-2,5</sub>	ARIMA	1,83	5,24	3,23
	Holt-Winters	3,66	14,83	5,93

Os dados da tabela acima mostram que os valores obtidos com o modelos para ambas as séries são mais próximos aos valores observados, representando melhor a série analisada do que o modelo de Holt-Winters. A Figura 42 e a Figura 43 mostram as séries de MP<sub>2,5</sub> e MP<sub>10-2,5</sub>, respectivamente, com os valores preditos em cada modelo SARIMA, os intervalos de confiança e os valores observados. No caso dos valores preditos do modelo MP<sub>2,5</sub>, pode-se verificar que eles ficam dentro do intervalo de confiança, exceto o segundo ponto e apresentam valores distantes em relação aos observados, principalmente no caso do segundo ponto. Na verificação do modelo MP<sub>10-2,5</sub> é um modelo que apresentou melhor resultado na análise de resíduos e de Ljung-Box, apesar de possuir uma quantidade maior de parâmetros.

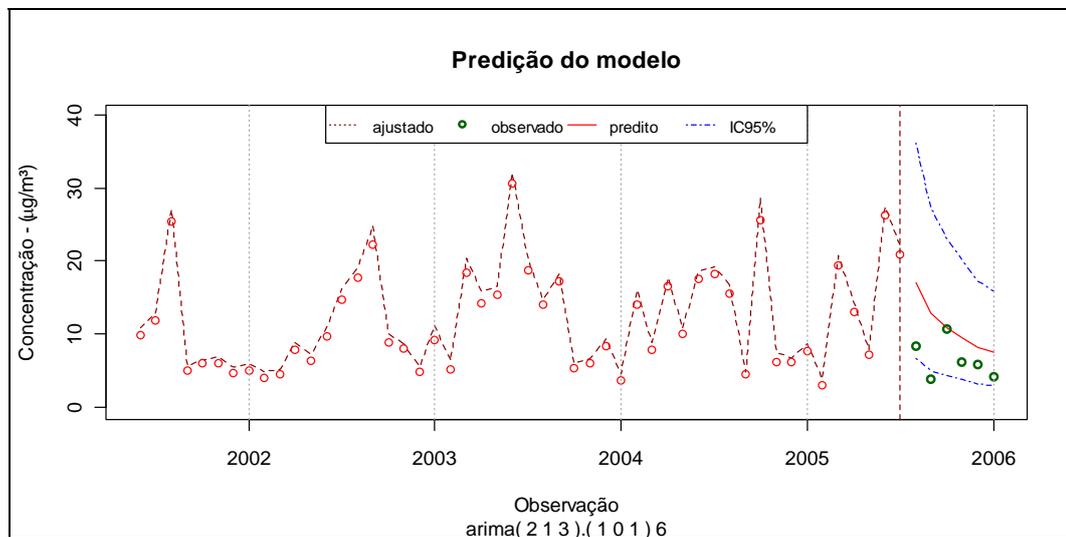


Figura 42 - Modelo, previsão e respectivos intervalos de confiança para MP<sub>2,5</sub>

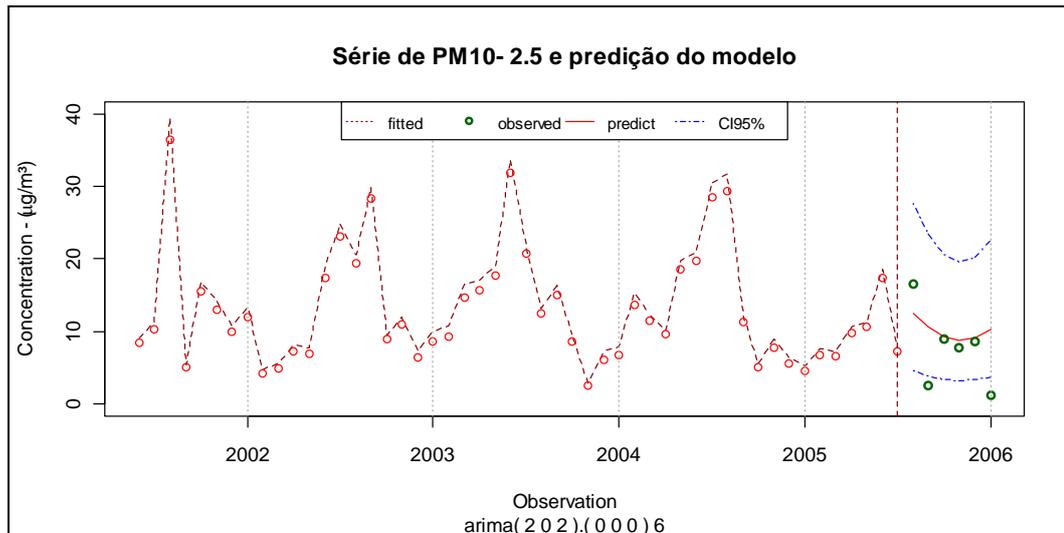


Figura 43 - Modelo, previsão e respectivos intervalos de confiança para  $MP_{10-2,5}$

### 5.3 Discussão dos Resultados

Os modelos SARIMA e Holt-Winters foram usados nas análises de séries temporais nas concentrações dos três conjuntos de dados. Ambos os métodos mostraram ser praticáveis e puderam reproduzir satisfatoriamente o histórico das concentrações de MP nos períodos investigados, incluindo eventos sazonais e locais. Resultado disso é que, ambos podem ser usados em estudos similares para outros locais ou eventos. De outro modo, se a melhor aproximação for a opção desejada, o SARIMA será, provavelmente a escolha preferida. Os erros obtidos para validação em todos os modelos apresentaram valores menores do que os obtidos com Holt-Winters.

O principal parâmetro a ser considerado na avaliação do modelo que melhor representa o conjunto de dados é o RMSE%, quanto menor o valor deste, mais representativo o modelo. Assim, o modelo para o  $MP_{10}$  apresentou RMSE% menores que os demais, provavelmente devido a um número maior de valores (30) utilizados na validação. Isto pode ser confirmado pela análise de resíduos. Em ambos os casos, os valores preditos se apresentam bem próximos dos valores observados, reproduzindo a variação sazonal das séries.

A metodologia de variação sucessiva de parâmetros é relativamente rápida e a escolha foi através do menor valor para AIC. Entretanto a análise estatística de parâmetros e de resíduos não devem ser rejeitadas, pois mesmo um menor valor de AIC, o modelo ainda assim pode não apresentar parâmetros significativos.

A adoção da plataforma R é adequada devido ao fato das rotinas serem modulares, adaptando-se aos modelos, permitindo fácil adequação em qualquer altura da série.

## CAPÍTULO 6 CONCLUSÕES E RECOMENDAÇÕES

### 6.1 Conclusões

Neste trabalho, as séries temporais de  $MP_{10}$ ,  $MP_{2,5}$  e  $MP_{10-2,5}$  da cidade de São Carlos foram analisadas por meio dos modelos ARIMA sazonais e Holt-Winters, usando um pacote estatístico de livre acesso.

As equações ARIMA e SARIMA são de fácil utilização, e podem ser consideradas como uma boa ferramenta para análise de tendências em concentrações de material particulado respirável.

Para os três conjuntos de dados apresentados foram feitas tentativas de modelagens AR, MA, ARIMA e SARIMA.

Os modelos encontrados podem não ser os mais adequados, pois cada série de dados requer análises específicas para verificação do método mais adequado e uma mesma série pode apresentar diversos modelos, principalmente após a inserção de novos dados.

Como já comentado por Daumas (2002), é provável que o efeito de alguns dias de poluição atmosférica elevada seja maior do que aquele ocasionado por um único dia de exposição. A ausência de medidas diárias não permitiu, entretanto, que essa hipótese fosse explorada.

A metodologia adotada de variação sucessiva dos parâmetros se mostrou rápida, e os modelos ajustados que foram escolhidos entre 10 modelos com menores valores do critério de informação de Akaike. No entanto, não se deve descartar a análise estatística dos parâmetros do modelo nem a análise de resíduos, pois mesmo com um menor valor de AIC, o modelo ainda pode apresentar parâmetros não significativos ou então correlação com resíduos ao longo do tempo. A adoção da plataforma R se mostrou acertada, já que, além de ser de livre acesso, tem uma base de usuários ampla, facilitando a troca de informações. Somado a isso, as rotinas elaboradas para a obtenção dos modelos foram feitas de forma modular, permitindo a fácil adaptação a qualquer série temporal.

No primeiro caso, a concentração de  $MP_{10}$ , obtida pelo amostrador AGV MP10, é representada pelo modelo SARIMA(1,0,0)×(1,0,1)<sub>6</sub> com  $\varphi_1 = 0,3237$ ;  $\Phi_1 = -0,9979$ ;  $\Theta_1 = 0,9049$ .

No segundo caso, a concentração de  $MP_{2,5}$ , obtida pelo amostrador dicotômico, é representada pelo modelo SARIMA(2,1,3)×(1,0,1)<sub>6</sub> com  $\varphi_1 = -0,7859$ ;  $\varphi_2 = -0,7518$ ;  $\theta_1 = -0,2193$ ;  $\theta_2 = 0,5097$ ;  $\theta_3 = -0,8184$ ;  $\Phi_1 = -0,9768$ ;  $\Theta_1 = 0,7929$ .

No terceiro caso, a concentração de  $MP_{10-2,5}$ , obtida pelo amostrador dicotômico, é representada pelo modelo SARIMA(2,0,2)×(1,0,0)<sub>6</sub> com  $\varphi_1 = 1,6499$ ;  $\varphi_2 = -0,9563$ ;  $\theta_1 = -1,446$ ;  $\theta_2 = 0,756$ .

Nos três casos, a comparação com o método de suavização exponencial de Holt-Winters confirma que os modelos SARIMA representaram melhor os conjuntos de dados estudados.

Vale salientar que modelos de séries temporais possuem previsões para um curto período de tempo (até 12 observações futuras é um número de previsões confiável). Para uma previsão mais longa, no entanto, é necessário o acréscimo de novas observações e de uma nova modelagem. Com uma série com maior número de observações, os erros de ajuste do modelo e predição tendem a diminuir, produzindo resultados mais confiáveis. Tem-se a alternativa também de adotar métodos mais refinados para obter valores ausentes e, assim, trabalhar com valores diários de concentração, em vez das médias mensais.

É importante ressaltar que a análise realizada não leva em consideração alterações que podem ocorrer tanto nas fontes poluidoras, como nas variações meteorológicas entre os meses e estações do ano.

As variações sazonais de concentração podem ser devido a diferentes fatores. Um deles é a própria diferença meteorológica entre os meses e estações do ano. A maior frequência de chuvas no período de verão promove a redução das concentrações devido a processos de deposição. Ventos e instabilidades atmosféricas propiciam a dispersão dos poluentes. No verão a formação da Camada Limite Noturna ocorre a altas altitudes não promovendo o acúmulo de poluentes como ocorre no inverno.

## 6.2 Sugestões para Trabalhos Futuros

- Coleta de dados com períodos equispaçados de quatro dias, para um melhor modelo, dos dois equipamentos nas mesmas datas e períodos, para ambas as frações de MP;
- fazer novos modelos e comparar com os modelos aqui apresentados;
- verificar as possíveis previsões futuras para os meses posteriores às coletas;

- fazer análises (modelos) para as séries de concentrações dos modelos químicos detectados no MP coletado;
- verificar se a cidade de São Carlos apresenta um modelo adequado para cada fração de MP.

Uma consequência da adoção do R é a possibilidade de se trabalhar com modelos aditivos generalizados (MAG) e modelos lineares generalizados (MLG), para a obtenção da correlação entre a série de  $MP_{10}$  e séries de dados meteorológicas e de incidências de doenças respiratórias (CID10), complementando o estudo para a cidade.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ALMEIDA, I.T., 1999, **A poluição atmosférica por material particulado a céu aberto**. Dissertação de Mestrado. São Paulo, 194p.
- AMORIM, W. B., 2004, **Monitoramento da concentração e caracterização de material particulado suspenso na atmosfera**. Campinas, SP. Tese de Doutorado. 165 p.
- ANDRADE, M. F., 1986, **Propriedades da matéria particulada inalável do aerosol atmosférico de São Paulo**. Dissertação de Mestrado. São Paulo. Instituto de Física da Universidade de São Paulo.
- ARBEX, M. A., 2001, **Avaliação dos efeitos do material particulado proveniente da queima da plantação de cana de açúcar sobre a morbidade respiratória na população de Araraquara – SP**. Tese de doutorado. Faculdade de Medicina da Universidade de São Paulo, 188p.
- BAIRD, C., 2002, **Química ambiental**, 2ª edição, Porto Alegre: Bookman. 622p.
- BARNETT, V., TURKMAN, K. F., 1995, **Pollution assessment and control**. Wiley 8.
- BARROS, M., 2004, **Processos estocásticos**. Papel virtual. Capítulo 5, disponível em [http://www.mbarros.com/sitebuildercontent/sitebuilderfiles/Livro\\_Processos\\_Cap\\_5\\_parte.pdf](http://www.mbarros.com/sitebuildercontent/sitebuilderfiles/Livro_Processos_Cap_5_parte.pdf)>, acesso em fev/2009, 432p.
- BOX , G. E., JENKINS, G. M., 1970, **Time series analysis: Forecasting and control**. San Francisco: Holden-Day (Revised edition, 1976)
- BOX , G. E., JENKINS, G. M., REINSEL, G., 1994, **Time series analysis: Forecasting and control**. Third edition. Englewood Cliffs: Prentice Hall.
- BRAGA, A., PEREIRA, L. A., SALDIVA, P. H. N., 2002, **Poluição atmosférica e seus efeitos na saúde humana**. Trabalho apresentado no evento de sustentabilidade na geração e uso de energia, UNICAMP, 18 a 20 de fevereiro de 2002.
- BRASSEUR, G. P., ORLANDO, J. J., TYNDALL; G., 1999, **Atmospheric chemistry and global change**. Editora Oxford University.
- BRUNO, R. L., 2005, **Material particulado atmosférico na cidade de São Carlos- SP: quantificação e identificação de fontes**. Tese de Doutorado em Engenharia Química, DEQ/UFSCar. 187p.
- CARVALHO, J. A. e LACAVA, P. T., 2003. **Emissões em processos de combustão**, Editora UNESP, São Paulo, v.1, 135p.

- CASTANHO, A. D. A., 1999, **A determinação quantitativa de fontes de material particulado na atmosfera da cidade de São Paulo**. Dissertação de Mestrado. Instituto de Física da Universidade de São Paulo. 105p.
- CELLI, C. E., 1999, **Monitoramento do material particulado respirável suspenso na atmosfera no centro da cidade de São Carlos - SP**. Dissertação de Mestrado. São Carlos. UFSCar/DEQ.
- CETESB – Companhia de Tecnologia e Saneamento Ambiental, 1989, **Estudo de caracterização de aerossóis da grande São Paulo – Modelo receptor – ECA/GSP**. n.3 – v.1 a 5 - 83p.
- CETESB – Companhia de Tecnologia e Saneamento Ambiental, 2003, **Relatório de qualidade do ar no Estado de São Paulo 2002**. 126p.
- CETESB – Companhia de Tecnologia e Saneamento Ambiental, 2008, **Relatório de qualidade do ar no Estado de São Paulo 2007**. 284p.
- CONCEIÇÃO, G. M S.; SALDIVA, P. H. N. e SINGER, J. M., 2001, **Modelos MLG e MAG para análise da associação entre poluição atmosférica e marcadores de morbi-mortalidade: uma introdução baseada em dados da cidade de São Paulo**. Rev. Bras. epidemiol., v. 4 n. 3, São Paulo, nov. 2001.
- CRAGGS, C., DAVISON, A. W., 1987, **Autocorrelation and univariate time series modelling for grass fluoride and airborne fluoride concentrations**. Environmental Pollution 43, p. 115-128.
- DAUMAS, R. P., 2002, **Poluição do ar e mortalidade em idosos no município do Rio de Janeiro: análise de série temporal**. Dissertação de mestrado. Instituto de Medicina Social da Universidade do estado do Rio de Janeiro.
- DERISIO, J. C., 1992, **Introdução ao controle de poluição ambiental**. São Paulo, CETESB.
- DOMINICI, F.; McDERMOTT, A.; ZEGER, S. L. e SAMET, J. M., 2002, **On the use of generalized additive models in time-series studies of air pollution and health**. American Journal of Epidemiology, v. 156, n. 3, ago.
- EFTIM, S., DOMINICI, F., 2005, **Multisite time-series studies versus cohort studies: methods, findings, and policy implications**. Journal of Toxicology and Environmental Health-Part-A-Current Issues 68 (13-14), p. 1191-1205.
- EHLERS, R. S., 2005, **Análise de séries temporais**. Departamento de Estatística da Universidade Federal do Paraná. Disponível em: <[www.est.ufpr.br/~ehlers](http://www.est.ufpr.br/~ehlers)>, acesso em jan/2009. 53p.

- ENCICLOPÉDIA MIRADOR INTERNACIONAL, 1983, Encyclopedia Britannica do Barsil Publicações Ltda, São Paulo, v. 6, p. 2556-2562.
- EPA – Environmental Protection Agency, 2009, **Glossary: P. terms of environment: glossary, abbreviations and acronyms.** Disponível em <<http://www.epa.gov/OCEPAterms/pterm.html>>, acesso em fev/2009.
- EPA – Environmental Protection Agency, 2006, 40 CFR Part 50. **National ambient air quality standards for particulate matter;** Final Rule, Part II. Disponível em <<http://www.epa.gov/air/criteria.html>>, acesso em jan/2009.
- EPA – Environmental Protection Agency, 2003, **National air quality and emissions trends report**, EPA 454/R-03-005.
- FOORASTIERE, F., STAFOGGIA, M., TASCIO, C., PICCIOTTO, S., AGABITI, N., CESARONI, G., PERUCCI, C. A., 2007, **Socioeconomic status, particulate air pollution, and daily mortality: differential exposure or differential susceptibility.** American Journal of Industrial Medicine v. 50 n. 3, p. 208-216.
- FREITAS, M. K., 2003, **Investigação da produção e dispersão de poluentes do ar no ambiente urbano: determinação empírica e modelagem em rede neural da concentração de CO.** Tese de Doutorado, EESC, USP- São Carlos.
- FRIEDLANDER, S. K., 2000, **Smoke, dust and haze: Fundamentals of aerosol dynamics.** 2nd Edition. Oxford University Press, 407p.
- GHOSH, B., BASU, B., O'MAHONY, M., 2007, **Bayesian time-series model for short-term traffic flow forecasting.** Journal of Transportation Engineering v. 133, p. 180-189.
- GNAUCK, A., 2004, **Interpolation and approximation of water quality time series and process identification.** Anal. Bioanal Chem, v. 380 p. 484-492.
- GOLDBERG, M. S., BURNETT, R. T., VALOIS, M-F., FLEGEL, K., BAILAR III, J. C., BROOK, J., VICENT, R., RADON, K., 2001, **Associations between ambient air pollution and daily mortality among persons with congestive heart failure.** Environmental Research v. 86, p. 12-25.
- GOYAL, P., CHAN, A. T., JAISWAL, N., 2006, **Statistical models for the prediction of respirable suspended particulate matter in urban cities.** Atmospheric Environment v. 40, p. 2068-2077.
- GUIMARÃES, E. C., 2006, **Séries temporais.** II Curso de pós graduação Latu Sensu em Estatística Aplicada. Universidade Federal de Uberlândia. 40p.

- HINDS, W. C., 1999, **Aerosol technology: properties, behavior and measurement airborne particles**. 2nd edition, John Wiley & Sons, Inc. 483p.
- HOSSEINPOOR, A. R., FOROUZANFAR, M. H., YUNESIAN, M., ASGHARI, F., NAIENI, K. H., FARHOOD, D., 2005, **Air pollution and hospitalization due to angina pectoris in Tehran, Iran: A time-series study**. Environmental Research v. 99, p. 126-131.
- IBGE. Instituto Brasileiro de Geografia e Estatística, 2009, **Censo 2006**. Disponível em <[www.ibge.gov.br/cidadesat](http://www.ibge.gov.br/cidadesat)>, acesso em jan/2009.
- ITL – Information Technology Laboratory, 2009, **Introduction to time series analysis**. Disponível em <http://www.itl.nist.gov/div898/handbook/pmc/section4/pmc4.htm>, acesso em jan/2009.
- JUNGER, W. L., 2004, **Modelo poisson-gama semi-paramétrico – Uma abordagem de penalização por rugosidade**. Dissertação de Mestrado. Departamento de Engenharia Elétrica da Universidade Católica do Rio de Janeiro. 82 p.
- KVAALEN, H., SOLBERG, S., CLARKE, N., TORP, T., AAMLID, D., 2002, **Time series study of concentrations of SO<sub>4</sub><sup>2-</sup> and H<sup>+</sup> in precipitation and soil waters in Norway**. Environmental Pollution v. 117, p. 215-224.
- LIMA, E. A. P., 2007, **Um estudo sobre a qualidade do ar em Uberlândia: Material particulado em suspensão**. Tese de Doutorado. Departamento de Engenharia Química da Universidade Federal de Uberlândia. 149 p.
- LIMA, E. A. P.; GUIMARÃES, E. C.; REIS, R. R.; SOUZA, C. G.; COURY, J. R.; BARROZO, M. A. S., 2006, **Estudo sobre a concentração de partículas no ar atmosférico de Uberlândia-MG por meio da técnica de séries temporais**. In: Anais do XXXII Congresso Brasileiro de Sistemas Particulados, Maringá, PR. Anais do XXXII ENEMP, 2006. v. 1. p. 1-9.
- LORA, E. E. S., 2002, **Prevenção e controle da poluição nos setores energético, industrial e de transporte**. 2. ed. Rio de Janeiro: Editora Interciência Ltda. 481p.
- MARQUES, K. A., 2000, **Caracterização do material particulado suspenso na atmosfera da cidade de São Carlos**. Dissertação de Mestrado em Engenharia Química – UFSCar/DEQ.
- MARTIN, M. A., ROBERTS, S., 2006, **Bootstrap model averaging in time series studies of particulate matter air pollution and mortality**. Journal of Exposure Science and Environmental Epidemiology v. 16 n. 3, p. 242-250.

- MIRANDA, R. M., 2001, **Caracterização físico-química e propriedades ópticas do aerossol urbano na Região Metropolitana de São Paulo**. Tese de Doutorado, IAG-USP.
- MISHRA, A. K., DESAI, V.R., 2005, **Drought forecasting using stochastic models**. Stochastic Environmental Research and Risk Assessment vol. v. 19, p. 326-3339.
- MORETTIN, P. A.; BUSSAB, W. O., 2002, **Estatística básica**. Saraiva, São Paulo, 5. ed. 526p.
- MORETTIN, P. A., TOLOI, C. M. C., 2006, **Análise de séries temporais**. 2ª. edição. Rio de Janeiro-RJ. 538p.
- NICKERSON, D. M., MADSEN, B. C., 2005, **Nonlinear regression and ARIMA models for precipitation chemistry in East Central Florida from 1978 to 1997**. Environmental Pollution v. 135, p. 71-379.
- NOBRE, F. F., MONTEIRO, A. B. S., TELLES, P. R., WILLIANSO, G. D., 2001, **Dynamic linear model and SARIMA: a comparison of their forecasting performance in epidemiology**. Statistics in Medicine v. 20 n. 20, p. 3051-3069.
- OLIVEIRA, C. H., 1996. **Planejamento ambiental na cidade de São Carlos (SP) com ênfase nas áreas públicas e áreas verdes: diagnóstico e propostas**. Dissertação de Mestrado do Programa de Pós-Graduação em Ecologia e Recursos Naturais – UFSCar. 181p.
- OLIVEIRA, L. G. A.; RIBEIRO, S. K. e SANTOS, M. P. S., 2003, **Análise do impacto da concentração de material particulado sobre a saúde pública: O caso da população idosa da cidade do Rio de Janeiro**. In: XVII Congresso de Pesquisa e Ensino em Transportes, Rio de Janeiro, RJ. Anais do XVII ANPET. Rio de Janeiro, RJ: Lagoa, 2003. v. 1, p. 410-419.
- O'NEILL, M. S., LOOMIS, D., BORJA-ABRTO, V. H., 2004, **Ozone, area social conditions, and mortality in Mexico City**. Environmental Research v. 94, p. 234-242.
- PENG, R. D., DOMINICI, F., LOUIS, T. A., 2006, **Model choice in time series studies of air pollution and mortality**. Journal of the Royal statistical Society Series A-Statistics v. 169, p. 179-198.
- PHILLIPI, A., ROMÉRO, M. A., BRUNA, G. C. (editores), 2004, **Curso de gestão ambiental**. Barueri-SP: Manole. 1041p.

- PITARD, A., ZEGHNOUN, A., COURSEAU, A., AMBERTY, J., DELMAS, V., FOSSARD, J-L, VILLET, H., 2004, **Short-term associations between air pollution and respiratory drug sales**. *Environmental Research* v. 95, p. 43-52.
- POPE, C. A., DOCKERY, D. W., 2006, **Health effects of fine particulate air pollution: Lines that connect**. *Journal of the Air & Waste Management Association* v. 56 n. 6, p. 709-742.
- POZZA, S. A., 2005, **Identificação das Fontes de Poluição Atmosférica na Cidade de São Carlos – SP**. Dissertação de Mestrado em Engenharia Química – UFSCar. 104p.
- PULIAFITO, E., GUEVARA, M., PULIAFITO, C., 2003, **Characterization of urban air quality using GIS as a management system**. *Environmental Pollution* v. 122, p. 105-117.
- R Development Core Team (2008). **R: A language and environment for statistical computing**. R Foundation for Statistical Computing, Vienna, Austria. ISBN 3-900051-07-0. Disponível em: <<http://www.r-project.org>>, Acesso em jan/2009.
- RAINHAM, D. G. C., SMOYER-TOMIC, K. E., 2003, **The role of air pollution in the relationship between a heat stress index and human mortality in Toronto**. *Environmental Research* v. 93, p. 9-19.
- ROBERTS, S., 2004, **Interactions between particulate air pollution and temperature in air pollution mortality time series studies**. *Environmental Research* 96, pp. 328-337.
- ROSSI, L. M. B., 1994, **Aplicação de diferentes métodos de análise para determinação de padrão espacial de espécies arbóreas da floresta tropical úmida de terra firme**. Dissertação de Mestrado. Instituto Nacional de Pesquisas da Amazônia. Fundação Universidade do Amazonas. 91 p.
- SAGIV, S. K., MENDOLA, P., LOOMIS, D., HERRING, A. H., NEAS, L. M., SAVITZ, D. A., POOLE, C., 2005, **A time series analysis of air pollution and preterm birth in Pennsylvania, 1997-2001**. *Environmental Health Perspectives* v. 113, n. 5, p. 602-606.
- SEINFELD, J.H., 1986, **Atmospheric chemistry and physics of air pollution**. John Wiley & Sons, NY.
- SEINFELD, J. H. e PANDIS, S. N., 1998, **Atmospheric Chemistry And Physics: From Air Pollution to Climate Change**. Ed. John Wiley & Sons, 1326p.
- SKJELKVALE, B. L., STODDARD, J. L., JEFFRIES, K. T., HOGASEN, T., BOWMAN, J., MANNIO, J., MONTHEIG, D. T., MOSELLO, R., ROGORA, M., RZYCHON, D., VESELY, J., WIETING, J., WILANER, A., WORSZTYNOWICZ, A., 2005,

- Regional scale evidence for improvements in surface water chemistry 1990–2001.**  
Environmental Pollution v. 137, p. 165-176.
- SPIEGEL, M. R., 1969, **Shaun's outline of theory and problems of statistics.** 580p.
- STOCK, J. H., WATSON, M. W., 1988, **Testing for common trends.** Journal of the American Statistical Association v. 83, p. 1097-1107.
- TSENG, F. M., TSENG, G. H., 2002, **A fuzzy seasonal ARIMA model for forecasting.** Fuzzy Sets and Systems v. 126 n. 3, p. 367-376.
- YNOUE, R. Y., 2004, **Modelagem numérica da formação, crescimento, e transporte das partículas inorgânicas secundárias constituintes do aerossol urbano na Região Metropolitana de São Paulo.** Tese de Doutorado, IAG – USP.
- YORIFUJI, T., YAMAMOTO, E., TSUDA, T., KAWAKAMI, N., 2005, **Health impact assessment of particulate matter in Tokyo, Japan.** Archives of Environmental & Occupational Health v. 60 n. 4, p. 179-185.
- ZEGHNOUN, A., BEAUDEAU, P., CARRAT, F., DELMAS, V., BOUDHABHAY, O., GAYON, F., GUINCÈTRE, D., CZERNICHOW, P., 1999, **Air Pollution and Respiratory Drug Sales in the City of Le Havre, France, 1993–1996.** Environmental Research v. 81, p. 224-230.

# **ANEXOS**

## Anexo 1

### **Trabalhos publicados pelo grupo de pesquisa sobre o tema “Poluição Atmosférica e Monitoramento de Qualidade do Ar”.**

*Trabalhos completos publicados (ou já aceitos para publicação) em periódicos:*

1) POZZA, S. A.; BRUNO, R L; TAZINASSI, M G ; GONÇALVES, J. A. S.; NASCIMENTO FILHO, V F.; BARROZO, M A S ; COURY, J. R. Sources of Particulate Matter: Emission Profile of Biomass Burning. International Journal of Environment and Pollution Vol. 36, No 1/2/3 pp 276-286, 2009.

2) LIMA, E. A. P.; GUIMARAES, E. C.; POZZA, S. A.; BARROZO, M. A. S.; COURY, J. R.. A Study of Atmospheric Particulate Matter in a City of the Central Region of Brazil Using Time Series Analysis. International Journal of Environment Engineering, 2009 (no prelo).

3) POZZA, S. A.; LIMA, E. P.; COMIM, T. T.; GIMENES, M. L.; COURY, J. R.. Time Series Analysis of PM2.5 and PM10-2.5 Mass Concentration in the City of São Carlos - Brazil. International Journal of Environment and Pollution, 2009 (no prelo).

4) BRUNO, R L; ALMEIDA, A F; NASCIMENTO FILHO, V. F; AGUIAR, M L.; GONÇALVES, J. A. S.; COURY, J. R . Atmospheric Particulate Matter in the City of São Carlos/SP-Brazil. International Journal of Environment and Pollution, v. 22, n. 4, p. 476-489, 2004.

5) CELLI, C. E.; MARQUES, K. A.; TEIXEIRA, D.; BACHIEGA, E.; MACHADO, A. P. G.; BRUNO, R L; CARVALHO, W. M.; AGUIAR, M L.; COURY, J. R.. Concentração de Material Particulado Suspenso na Atmosfera em São Carlos SP. Engenharia Sanitária e Ambiental, ABES, RJ, v. 8, n. 1, p. 6-12, 2003.

6) COURY, J.R.; MANOSSO, F.G.; MARQUES, K.A.; MACHADO, A.P.G. ; CELLI, C.E.; MULLER, E.B.; BRUNHEROTTO, F.F.; CARVALHO, W.M.; AGUIAR, M.L. . Assessment of Particulates in the Urban Atmosphere of São Carlos, Brazil. International Journal Environment and Pollution, UK, v. 17, n. 03, p. 220-242, 2002.

7) MARQUES, K. A.; CELLI, C. E.; PASSONI, J. H.; TEIXEIRA, D.; BACHIEGA, E.; VIDAL, E. S.; CARVALHO, W. M.; AGUIAR, M L.; COURY, J. R.. Assessment of Atmospheric Particulate Matter in São Carlos -SP, Brazil. Environment Management And Health, Northampton, UK, v. 12, n. 1, p. 17-25, 2001.

8) INNOCENTINI, M. D. M.; COURY, J. R. . Estudo do Desempenho de Três Monitoradores de Aerossóis, Na Faixa Respirável. Revista Brasileira de Saúde Ocupacional, v. 83, p. 35-50, 1994.

*Trabalhos completos publicados em anais de congressos*

1) POZZA, S. A.; LIMA, E. A. P.; COMIN, T T.; BARROZO, M A S; COURY, J. R.. Características Temporais da Emissão de Material Particulado à Atmosfera na Cidade de São

Carlos-SP. In: XVII Congresso Brasileiro de Engenharia Química, 2008, Recife. Anais do XVII COBEQ, 2008. v. Tr277. p. 1-8.

2) ITO, L. X. ; AGUIAR, M. L. . Monitoramento da qualidade do ar em ambientes internos de bibliotecas em São Paulo. In: XVI Congresso Brasileiro de Engenharia Química (XVI COBEQ), 2006, Santos. XVI Congresso Brasileiro de Engenharia Química (XVI COBEQ), 2006.

3) LIMA, E. A. P.; GUIMARAES, E. C. ; REIS, R. R.; SOUZA, C. G. ; COURY, J. R. ; BARROZO, M A S . Estudo Sobre a Concentração de Partículas no Ar Atmosférico de Uberlândia-MG Por Meio da Técnica de Séries Temporais. In: Anais do XXXII Congresso Brasileiro de Sistemas Particulados, 2007, Maringá. Anais do XXXII ENEMP, 2006. v. 1. p. 1-9.

4) POZZA, S. A.; BRUNO, R L; GONÇALVES, J. A. S.; COURY, J. R.. Vehicular Emission Source Profile for the City of São Carlos Brazil. In: CHISA 2006 - 17th International Congress of Chemical and Process Engineering, 2006, Praga. Proceedings of the CHISA 2006, 2006. v. 1. p. P5.67-13p.

5) POZZA, S. A.; BRUNO, R L; TREVISAN, J. E.; TAZINASSI, M. G.; GONÇALVES, J. A. S.; NASCIMENTO FILHO, V. F.; COURY, J. R.. Sources of Atmospheric Particulate Matter: The Emission Profile of a Sugar Cane Foliage Burning. In: 4th Mercosur Congress on Process Systems Engineering, 2005, Rio de Janeiro. Proceedings of the 4th Mercosur Congress on Process Systems Engineering, 2005. p. 10p.

6) BRUNO, R L.; POZZA, S. A.; SANTOS, F M.; TREVISAN, J. E.; TAZINASSI, M. G.; GONÇALVES, J. A. S.; COURY, J. R.. Perfis de Fontes Poluidoras Obtidos na Cidade de São Carlos - SP. In: XXXI ENEMP - Congresso Brasileiro de Sistemas Particulados, 2005, Uberlândia. Anais do XXXI ENEMP, 2004. v. Tr. L4. p. 8p..

7) POZZA, S. A.; BRUNO, R L.; SANTOS, F. M.; TREVISAN, J. E.; NASCIMENTO FILHO, V. F.; COURY, J. R.. Fontes de Poluição Atmosférica na Cidade de São Carlos SP. In: IV Simpósio Internacional de Qualidade Ambiental, 2004, Porto Alegre. Anais do IV Simpósio Internacional de Qualidade Ambiental, 2004. v. CDROM. p. 1-8.

8) BRUNO, R L.; POZZA, S. A.; SANTOS, F. M.; GONÇALVES, J. A. S.; COURY, J. R.. Identificação das Fontes de Poluição Atmosférica na Cidade de São Carlos - SP. In: XV Congresso Brasileiro de Engenharia Química, 2004, Curitiba (PR). Anais do XV COBEQ, 2004. v. 1. p. 8p.-T1805.

9) BRUNO, R. L.; ALMEIDA, A. F.; GONÇALVES, J. A. S.; NASCIMENTO FILHO, V. F.; COURY, J. R.. Caracterização de Material Particulado Suspenso na Atmosfera da Cidade de São Carlos e suas Possíveis Fontes. In: XXX Congresso Brasileiro de Sistemas Particulados, 2003, São Carlos SP. Anais do XXX Congresso Brasileiro de Sistemas Particulados, 2002. v. 1. p. 10p.

10) COURY, J. R. Poluição Atmosférica: Material Particulado. In: 1o. Fórum das Universidades Públicas Paulistas em Ciência e Tecnologia de Resíduos, 2003, São Pedro. 1o. Fórum das Universidades Públicas Paulistas em Ciência e Tecnologia de Resíduos, 2003. p. CDROM-10p..

- 11) COURY, J. R.. Particulate Matter in the Atmosphere - Assessment and Control. In: I International Workshop on Air Quality in Industrialized Urban Centers, 2002, Vitória - ES. Proceedings of the I International Workshop on Air Quality in Industrialized Urban Centers, 2002. v. 1. p. 64-87.
- 12) BRUNO, R L.; ALMEIDA, A F.; COURY, J. R.. Concentração de Material Particulado Fino, PM-10, e Super-Fino, PM-2,5, Presentes na Atmosfera na Cidade de São Carlos-SP. In: XXIX Congresso Brasileiro de Sistemas Particulados, 2001, São João del Rei (MG). Anais do XXIX Congresso Brasileiro de Sistemas Particulados, 2001. v. 1. p. 8p..
- 13) MARQUES, K. A.; CELLI, C. E.; PASSONI, J. H.; TEIXEIRA, D.; BACHIEGA, E.; VIDAL, E. S.; CARVALHO, W. M.; AGUIAR, M. L.; COURY, J. R.. Assessment of Particulate Matter and Carbon Concentrations in the Atmosphere of São Carlos-SP, Brazil. In: 5th International Symposium on Environmental Geotechnology and Global Sustainable Development, 2000, Belo Horizonte. Proceedigs of the 5th International Symposium on Environmental Geotechnology and Global Sustainable Development, 2000. v. 1. p. 1-10.
- 14) CELLI, C. E.; MARQUES, K. A.; MANOSSO, F. G.; MACHADO, A. P. G.; MULLER, E. B.; BRUNHEROTTO, F. F.; CARVALHO, W. M.; AGUIAR, M L.; COURY, J. R.. Monitoramento e Caracterização do Material Particulado Suspenso na Atmosfera da Cidade de São Carlos-SP. In: XXVI Congresso Brasileiro de Sistemas Particulados, 1999, Teresópolis (RJ). Anais do XXVI Congresso Brasileiro de Sistemas Particulados. Seropédica (RJ): UFFRJ, 1998. v. 2. p. 569-576.
- 15) MANOSSO, F. G.; MARQUES, K. A.; MACHADO, A. P. G.; CELLI, C. E.; AGUIAR, M L.; COURY, J. R.. Concentração de Material Particulado na Atmosfera da Cidade de São Carlos-SP. In: II Simpósio Internacional de Qualidade Ambiental, 1998, Porto Alegre (RS). Anais, 1998. v. 1. p. 535-544.
- 16) MARQUES, K. A.; MANOSSO, F. G.; MACHADO, A. P. G.; AGUIAR, M L.; COURY, J. R.. Monitoramento da Carga de Material Particulado Na Cidade de São Carlos (Sp): Resultados Preliminares. In: XXV Congresso Brasileiro de Sistemas Particulados, 1997. Anais do XXV ENEMP. São Carlos (SP). v. 1.
- 17) INNOCENTINI, M. D. M.; COURY, J. R.. Estudo do Desempenho de Três Monitoradores de Aerossóis Na Faixa Respirável. In: 10º Congresso Brasileiro de Engenharia Química, 1994. Anais. São Paulo (SP). p. 462-467.
- 18) COURY, J. R.; INNOCENTINI, M. D. M.. Monitoradores de Ar Na Faixa Respirável. In: XX Encontro sobre escoamento em Meios Porosos, 1992, São Carlos (SP). Anais do XX Encontro sobre escoamento em Meios Porosos. São Carlos - SP, 1992. v. 2. p. 347-357.
- 19) INNOCENTINI, M. D. M.; COURY, J. R.. Monitoradores de Aerossóis, na Faixa Respirável. In: XX Encontro Sobre Escoamento em Meios Porosos, 1992, São Carlos-SP. Anais do XX Encontro Sobre Escoamento em Meios Porosos, 1992.

*Trabalhos completos publicados em anais de congressos de I.C.*

1) COMIN, T. T.; POZZA, S. A.; COURY, J. R.. Identificação da contribuição das fontes de material particulado atmosférico de São Carlos através do Software CMB8. In: XIV Congresso de Iniciação Científica - UFSCar, 2006, São Carlos, SP. CD de resumos do XIV CIC - UFSCar, 2006, 2006.

2) COMIN, T. T.; COURY, J. R.; POZZA, S. A.. Principais fontes de material particulado atmosférico (MP10) em São Carlos - SP. 2007. (Apresentação de Trabalho/Congresso).

COMIN, T. T.; COURY, J. R.; POZZA, S. A. Identificação de fontes de material particulado atmosférico em São Carlos-SP no período 06/01 - 06/02. 2007. (Apresentação de Trabalho/Congresso).COMIN, T. T.; COURY, J. R.; POZZA, S. A.. Principais fontes de material particulado atmosférico (MP10) em São Carlos - SP. 2007. (Apresentação de Trabalho/Congresso).

5) COMIN, T. T.; COURY, J. R.; POZZA, S. A.. Principais fontes de material particulado atmosférico MP2,5 em São Carlos - SP. 2007. (Apresentação de Trabalho/Congresso).COMIN, T. T.; COURY, J. R.; POZZA, S. A.. Material particulado fino e grosso amostrados no período seco em São Carlos - SP. 2007. (Apresentação de Trabalho/Simpósio).

7) COMIN, T. T.; COURY, J. R.; POZZA, S. A.. Identificação da contribuição das fontes de material particulado atmosférico de São Carlos através do software CMB8. 2006. (Apresentação de Trabalho/Congresso).8) TAZINASSI, M. G.; TREVISAN, J. E.; BRUNO, R. L.; POZZA, S. A.; COURY, J. R.. Identificação de Fontes de Aerossóis Atmosféricos na Cidade de São Carlos - SP. In: 6º COBEQ-IC, 2005, Campinas SP. Anais de Resumos do 6º COBEQ-IC, 2005. v. 1. p. EA17.

9) SANTOS, F M.; BRUNO, R. L.; COURY, J. R.. Estudo da Emissão de Material Particulado MP10 e MP2,5 à Atmosfera na Cidade de São Carlos - SP. In: V COBEQ-IC, 2003, Seropédica. Anais do V COBEQ-IC, 2003. v. 1. p. MA193-MA199.

10) TEIXEIRA, D.; COURY, J. R.. Levantamento da Emissão de Material Particulado (MP10 e MP 2,5) à atmosfera na cidade de São Carlos S.P. In: 4º Congresso Brasileiro de Engenharia Química - Iniciação Científica - COBEQ-IC, 2001, Maringá-PR. Anais do 4º Congresso Brasileiro de Engenharia Química - Iniciação Científica, 2001.

11) MANOSSO, F. G.; COURY, J. R.. Levantamento da Emissão de Material Particulado no Campus da UFSCar. In: II Congresso Brasileiro de Engenharia Química - Iniciação Científica, 1997, Uberlândia (MG). Anais do Congresso Brasileiro de Engenharia Química - Iniciação Científica, 1997. v. 1. p. 155-158.

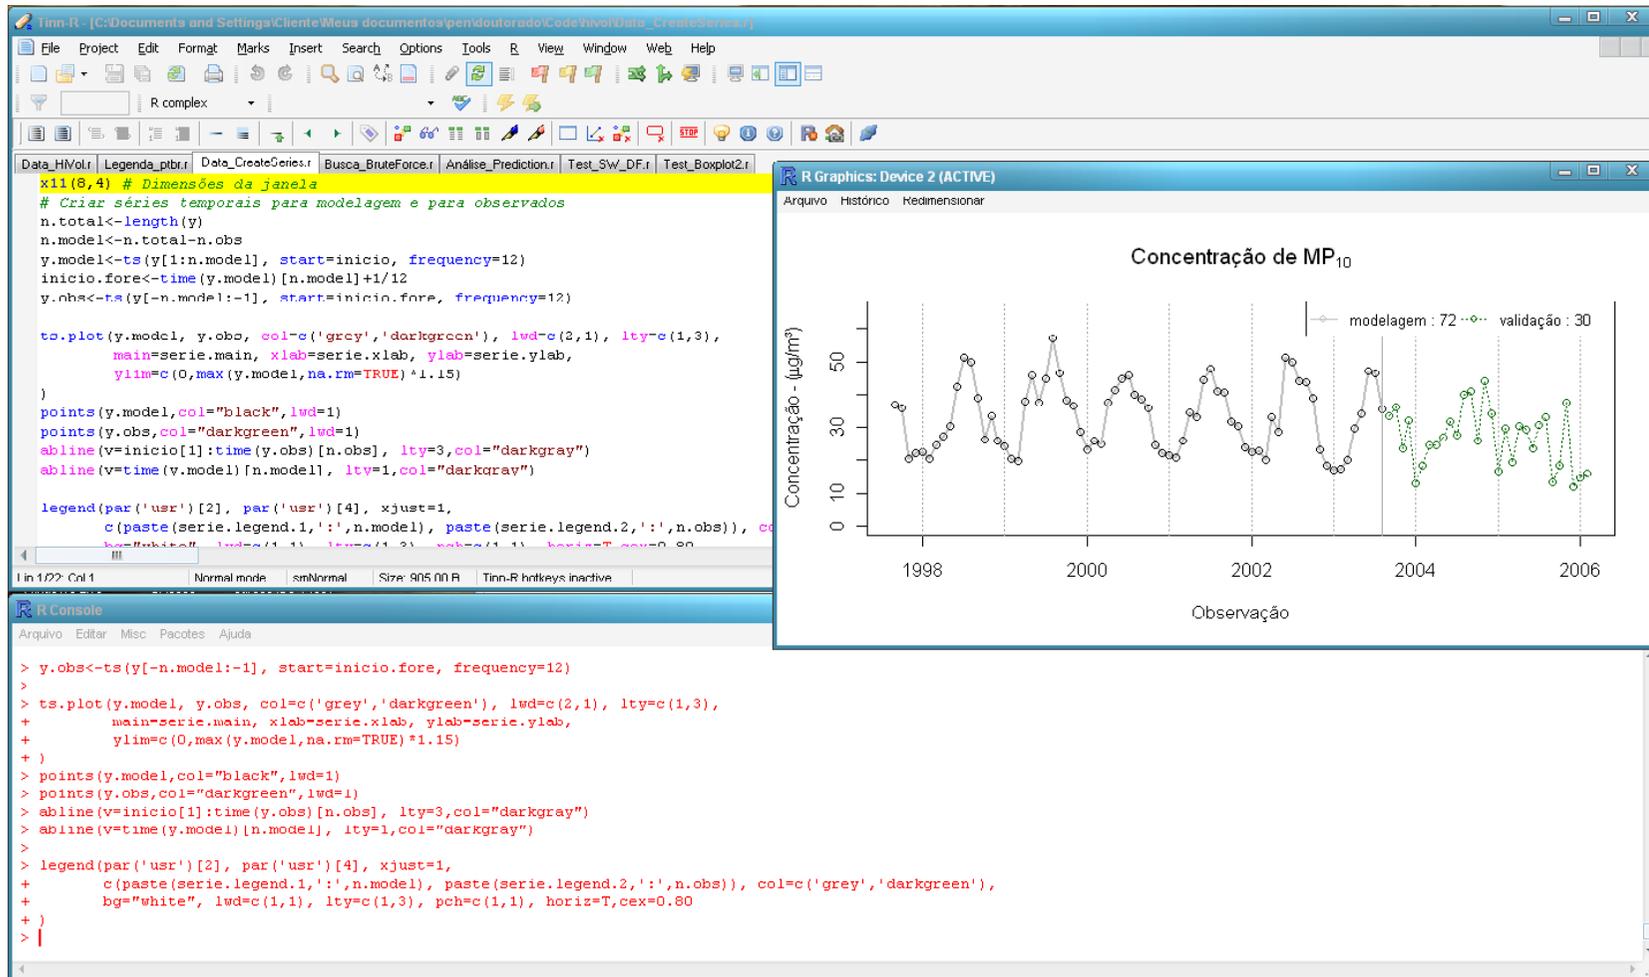
12) MANOSSO, F. G.; COURY, J. R.. Levantamento da Emissão de Material Particulado no Campus da UFSCar. In: 20 Congresso Brasileiro de Engenharia Química - Iniciação Científica - II COBEQ-IC, 1997, Uberlândia-MG. Anais do 2º Congresso Brasileiro de Engenharia Química - Iniciação Científica - II COBEQ-IC, 1997.

*Defesas de Teses e Dissertações:*

- 1) POZZA, S.A., 2005, Identificação das fontes de Poluição atmosférica na cidade de São Carlos-SP, Dissertação de Mestrado, DEQ/UFSCar, 2005.
- 2) BRUNO, R.L., 2005, Material particulado atmosférico na cidade de São Carlos- SP: quantificação e identificação de fontes. Tese de Doutorado em Engenharia Química, DEQ/UFSCar, 2005.
- 3) MARQUES, K. A., 2000, Caracterização do material particulado suspenso na atmosfera da cidade de São Carlos. Dissertação de Mestrado em Engenharia Química – UFSCar/DEQ.
- 4) CELLI, C. E., 1999, Monitoramento do material particulado respirável suspenso na atmosfera no centro da cidade de São Carlos - SP. Dissertação de Mestrado. São Carlos. UFSCar/DEQ.

## Anexo 2

### Interface do Tinn-R e do R.



### Anexo 3

#### Dados coletas com amostrador AGV para concentração de MP<sub>10</sub>.

<u>Data</u>	<u>Conc.(ug/m3)</u>	<u>Data</u>	<u>Conc.(ug/m3)</u>	<u>Data</u>	<u>Conc.(ug/m3)</u>
23/9/1997	40,58	3/3/1998	19,46	4/8/1998	37,00
25/9/1997	25,17	5/3/1998	30,30	11/8/1998	48,11
30/9/1997	44,63	10/3/1998	35,02	13/8/1998	49,75
4/10/1997	38,62	12/3/1998	23,52	18/8/1998	54,40
8/10/1997	27,66	17/3/1998	22,17	20/8/1998	90,11
9/10/1997	40,05	19/3/1998	25,40	25/8/1998	58,71
14/10/1997	52,41	24/3/1998	20,80	27/8/1998	51,08
16/10/1997	24,31	25/3/1998	26,04	1/9/1998	51,80
21/10/1997	31,33	31/3/1998	18,98	3/9/1998	51,82
23/10/1997	41,14	2/4/1998	27,13	8/9/1998	21,18
28/10/1997	33,07	7/4/1998	23,45	10/9/1998	35,30
29/10/1997	35,01	9/4/1998	20,21	15/9/1998	39,50
4/11/1997	29,82	14/4/1998	39,63	22/9/1998	24,90
6/11/1997	26,46	16/4/1998	38,96	24/9/1998	52,59
11/11/1997	20,74	21/4/1998	31,71	29/9/1998	35,03
13/11/1997	12,11	23/4/1998	24,15	1/10/1998	24,91
17/11/1997	15,34	28/4/1998	15,93	6/10/1998	29,67
19/11/1997	21,16	30/4/1998	23,65	8/10/1998	20,27
25/11/1997	22,38	5/5/1998	14,85	13/10/1998	27,13
27/11/1997	16,64	7/5/1998	22,81	15/10/1998	16,30
2/12/1997	30,90	12/5/1998	40,08	20/10/1998	20,20
4/12/1997	22,80	14/5/1998	95,54	28/10/1998	36,92
9/12/1997	19,70	19/5/1998	23,77	29/10/1998	35,50
11/12/1997	22,30	21/5/1998	41,89	3/11/1998	25,65
15/12/1997	24,43	26/5/1998	41,32	5/11/1998	36,60
18/12/1997	13,81	28/5/1998	29,06	9/11/1998	32,68
23/12/1997	32,83	2/6/1998	35,30	16/11/1998	31,44
25/12/1997	13,21	4/6/1998	41,56	18/11/1998	27,71
30/12/1997	20,20	9/6/1998	50,23	23/11/1998	39,58
1/1/1998	29,38	11/6/1998	41,08	25/11/1998	40,28
6/1/1998	36,55	16/6/1998	47,65	2/12/1998	38,93
8/1/1998	24,30	18/6/1998	42,71	7/12/1998	36,10
13/1/1998	19,70	23/6/1998	45,92	9/12/1998	22,42
15/1/1998	18,30	25/6/1998	26,63	14/12/1998	24,37
20/1/1998	12,64	30/6/1998	50,75	16/12/1998	24,45
22/1/1998	21,06	2/7/1998	49,38	21/12/1998	20,64
27/1/1998	18,23	7/7/1998	60,63	23/12/1998	22,50
29/1/1998	22,55	9/7/1998	11,24	28/12/1998	21,57
3/2/1998	20,17	10/7/1998	43,50	30/12/1998	22,04
5/2/1998	17,69	14/7/1998	66,32	4/1/1999	19,04
10/2/1998	18,70	17/7/1998	62,99	6/1/1999	21,03
12/2/1998	17,64	21/7/1998	63,36	11/1/1999	20,23
16/2/1998	18,31	23/7/1998	58,16	13/1/1999	21,82
18/2/1998	28,19	28/7/1998	53,27	18/1/1999	25,63
24/2/1998	23,20	30/7/1998	43,37	20/1/1999	34,04
26/2/1998	19,90			25/1/1999	27,28
				27/1/1999	24,96

<u>Data</u>	<u>Conc.(ug/m3)</u>	<u>Data</u>	<u>Conc.(ug/m3)</u>	<u>Data</u>	<u>Conc.(ug/m3)</u>
1/2/1999	14,22	5/7/1999	26,55	5/1/2000	18,24
3/2/1999	28,27	7/7/1999	51,59	7/1/2000	9,46
8/2/1999	19,94	12/7/1999	28,90	10/1/2000	24,38
11/2/1999	22,73	14/7/1999	33,11	13/1/2000	26,24
15/2/1999	21,33	19/7/1999	35,28	19/1/2000	24,20
17/2/1999	18,88	21/7/1999	61,84	21/1/2000	36,07
22/2/1999	20,10	26/7/1999	71,98	24/1/2000	30,67
24/2/1999	17,66	29/7/1999	49,08	26/1/2000	15,49
1/3/1999	11,59	2/8/1999	64,46	2/2/2000	25,51
3/3/1999	14,29	4/8/1999	56,66	4/2/2000	46,21
8/3/1999	15,15	12/8/1999	77,39	8/2/2000	34,46
10/3/1999	14,60	16/8/1999	38,01	9/2/2000	7,44
15/3/1999	28,86	18/8/1999	63,71	16/2/2000	16,46
17/3/1999	35,72	26/8/1999	62,40	18/2/2000	31,70
22/3/1999	12,82	30/8/1999	120,95	21/2/2000	27,41
24/3/1999	24,68	1/9/1999	78,07	24/2/2000	30,08
29/3/1999	19,73	6/9/1999	91,36	29/2/2000	15,26
5/4/1999	36,33	8/9/1999	82,06	2/3/2000	33,34
7/4/1999	36,19	13/9/1999	44,46	9/3/2000	26,04
12/4/1999	38,32	15/9/1999	45,62	11/3/2000	20,76
14/4/1999	21,32	20/9/1999	47,28	14/3/2000	22,72
21/4/1999	46,20	22/9/1999	37,52	16/3/2000	18,04
23/4/1999	36,95	28/9/1999	78,47	21/3/2000	20,17
26/4/1999	41,32	30/9/1999	57,27	28/3/2000	21,09
28/4/1999	47,63	4/10/1999	30,09	30/3/2000	38,40
3/5/1999	46,98	6/10/1999	55,26	3/4/2000	25,17
5/5/1999	53,78	14/10/1999	73,46	6/4/2000	35,76
10/5/1999	28,95	16/10/1999	54,54	10/4/2000	36,34
12/5/1999	33,81	18/10/1999	29,84	14/4/2000	47,88
17/5/1999	45,12	20/10/1999	28,24	17/4/2000	46,18
19/5/1999	38,21	25/10/1999	47,16	19/4/2000	21,02
24/5/1999	71,00	27/10/1999	22,31	25/4/2000	40,94
26/5/1999	52,97	1/11/1999	38,15	27/4/2000	46,45
31/5/1999	40,32	8/11/1999	26,12	1/5/2000	32,76
2/6/1999	53,43	10/11/1999	25,67	4/5/2000	33,35
7/6/1999	36,31	18/11/1999	49,15	9/5/2000	35,06
9/6/1999	35,15	20/11/1999	21,06	11/5/2000	38,05
14/6/1999	17,80	22/11/1999	32,11	15/5/2000	56,85
16/6/1999	34,27	24/11/1999	57,36	18/5/2000	40,03
21/6/1999	25,27	30/11/1999	43,47	22/5/2000	46,16
23/6/1999	37,35	2/12/1999	28,06	25/5/2000	50,20
28/6/1999	57,18	16/12/1999	32,80	29/5/2000	39,28
30/6/1999	42,55	27/12/1999	25,40		

<u>Data</u>	<u>Conc.(ug/m3)</u>	<u>Data</u>	<u>Conc.(ug/m3)</u>	<u>Data</u>	<u>Conc.(ug/m3)</u>
5/6/2000	34,85	2/11/2000	43,17	2/5/2001	31,85
7/6/2000	39,87	6/11/2000	31,60	7/5/2001	35,24
12/6/2000	58,80	9/11/2000	25,35	9/5/2001	14,75
15/6/2000	48,58	13/11/2000	18,25	14/5/2001	25,53
21/6/2000	26,53	15/11/2000	21,17	16/5/2001	12,09
23/6/2000	52,16	20/11/2000	21,79	21/5/2001	58,76
26/6/2000	53,15	22/11/2000	26,37	24/5/2001	54,70
29/6/2000	74,00	28/11/2000	16,52	29/5/2001	31,40
5/7/2000	43,32	30/11/2000	15,60	7/6/2001	54,17
7/7/2000	43,93	4/12/2000	19,56	11/6/2001	33,09
10/7/2000	66,62	7/12/2000	32,01	15/6/2001	48,94
17/7/2000	34,50	13/12/2000	16,20	18/6/2001	37,78
21/7/2000	46,31	15/12/2000	25,45	25/6/2001	42,82
24/7/2000	31,88	20/12/2000	25,68	30/6/2001	49,14
26/7/2000	46,65	22/12/2000	21,08	2/7/2001	81,77
31/7/2000	52,61	27/12/2000	16,30	4/7/2001	60,62
2/8/2000	40,80	29/12/2000	21,09	13/7/2001	40,53
8/8/2000	58,49	6/1/2001	21,26	17/7/2001	53,29
10/8/2000	35,95	8/1/2001	21,26	19/7/2001	75,45
14/8/2000	45,87	15/1/2001	24,34	24/7/2001	40,18
18/8/2000	22,77	17/1/2001	33,64	31/7/2001	43,83
22/8/2000	17,99	29/1/2001	19,44	3/8/2001	41,00
25/8/2000	70,92	31/1/2001	16,40	13/8/2001	40,00
29/8/2000	26,84	6/2/2001	15,56	17/8/2001	40,00
1/9/2000	37,70	8/2/2001	14,75	20/8/2001	40,00
4/9/2000	49,29	15/2/2001	31,72	22/8/2001	40,00
10/9/2000	30,93	17/2/2001	12,50	27/8/2001	40,00
12/9/2000	49,80	23/2/2001	28,50	30/8/2001	40,00
14/9/2000	30,98	26/2/2001	22,86	3/9/2001	40,00
19/9/2000	39,08	4/1/2001	13,82	10/9/2001	59,81
23/9/2000	51,91	1/3/2001	32,78	13/9/2001	46,09
25/9/2000	27,15	5/3/2001	19,40	18/9/2001	33,65
27/9/2000	30,30	7/3/2001	16,26	20/9/2001	45,31
2/10/2000	37,81	12/3/2001	17,49	26/9/2001	24,50
6/10/2000	30,00	15/3/2001	32,89	28/9/2001	33,65
9/10/2000	38,28	19/3/2001	27,84	1/10/2001	27,46
10/10/2000	50,25	23/3/2001	34,09	4/10/2001	33,53
17/10/2000	43,36	27/3/2001	25,23	15/10/2001	44,44
19/10/2000	45,71	29/3/2001	27,00	20/10/2001	15,00
24/10/2000	25,06	4/4/2001	29,25	22/10/2001	19,24
26/10/2000	37,31	7/4/2001	29,97	25/10/2001	39,27
30/10/2000	15,63	11/4/2001	30,68	29/10/2001	42,16
		14/4/2001	30,29		
		16/4/2001	35,31		
		19/4/2001	46,80		
		23/4/2001	34,79		
		27/4/2001	38,98		
		30/4/2001	33,50		

<u>Data</u>	<u>Conc.(ug/m3)</u>	<u>Data</u>	<u>Conc.(ug/m3)</u>	<u>Data</u>	<u>Conc.(ug/m3)</u>
1/11/2001	32,92	3/5/2002	29,40	2/12/2002	20,55
7/11/2001	41,85	6/5/2002	24,58	9/12/2002	19,23
8/11/2001	31,75	13/5/2002	25,51	10/12/2002	22,48
17/11/2001	19,41	16/5/2002	24,70	16/12/2002	16,33
21/11/2001	0,00	22/5/2002	19,93	23/12/2002	22,55
24/11/2001	21,55	27/5/2002	40,90	26/12/2002	10,51
26/11/2001	35,21	29/5/2002	35,27	30/12/2002	17,31
3/12/2001	28,56	3/6/2002	39,48	3/1/2003	24,79
7/12/2001	17,74	10/6/2002	54,86	6/1/2003	6,50
10/12/2001	21,32	13/6/2002	62,34	13/1/2003	20,93
12/12/2001	33,64	18/6/2002	80,69	16/1/2003	11,48
18/12/2001	37,12	24/6/2002	52,49	20/1/2003	16,11
20/12/2001	15,97	27/6/2002	46,31	23/1/2003	18,29
26/12/2001	13,63	4/7/2002	47,90	29/1/2003	20,20
3/1/2002	28,48	6/7/2002	60,68	1/2/2003	20,97
9/1/2002	25,45	8/7/2002	52,77	3/2/2003	12,34
11/1/2002	29,13	11/7/2002	30,07	6/2/2003	16,97
15/1/2002	20,01	15/7/2002	59,92	10/2/2003	14,45
19/1/2002	13,76	19/7/2002	56,68	19/2/2003	13,94
21/1/2002	26,42	22/7/2002	27,04	25/2/2003	7,77
23/1/2002	24,46	24/7/2002	62,61	27/2/2003	35,08
28/1/2002	16,53	1/8/2002	26,10	3/3/2003	28,94
31/1/2002	17,44	5/8/2002	40,68	7/3/2003	30,74
4/2/2002	26,22	10/8/2002	63,22	10/3/2003	9,65
6/2/2002	15,48	12/8/2002	53,26	13/3/2003	1,41
11/2/2002	19,03	15/8/2002	72,13	17/3/2003	28,87
14/2/2002	21,76	19/8/2002	35,01	18/3/2003	21,80
18/2/2002	26,82	21/8/2002	51,98	24/3/2003	14,79
25/2/2002	27,91	26/8/2002	51,71	25/3/2003	17,74
4/3/2002	22,88	29/8/2002	29,20	27/3/2003	27,06
8/3/2002	28,63	15/9/2002	45,55	2/4/2003	28,10
13/3/2002	22,73	19/9/2002	44,87	7/4/2003	41,69
17/3/2002	17,80	23/9/2002	24,19	10/4/2003	20,68
23/3/2002	9,62	27/9/2002	46,34	13/4/2003	19,23
25/3/2002	21,84	30/9/2002	55,52	16/4/2003	34,38
27/3/2002	17,85	3/10/2002	49,78	20/4/2003	44,68
1/4/2002	31,97	7/10/2002	38,04	25/4/2003	17,82
4/4/2002	33,08	10/10/2002	58,04	28/4/2003	31,69
8/4/2002	29,07	13/10/2002	56,24	2/5/2003	38,58
10/4/2002	31,59	21/10/2002	40,64	7/5/2003	15,15
17/4/2002	20,22	25/10/2002	28,28	10/5/2003	27,00
24/4/2002	41,26	28/10/2002	17,73	13/5/2003	30,30
29/4/2002	45,34	31/10/2002	21,44	16/5/2003	22,50
		4/11/2002	26,16	22/5/2003	43,76
		14/11/2002	15,13	26/5/2003	60,72
		18/11/2002	19,62		
		25/11/2002	20,18		
		28/11/2002	34,57		

<u>Data</u>	<u>Conc.(ug/m3)</u>	<u>Data</u>	<u>Conc.(ug/m3)</u>	<u>Data</u>	<u>Conc.(ug/m3)</u>
2/6/2003	49,55	2/3/2004	2,35	4/10/2004	30,63
5/6/2003	42,44	4/3/2004	25,39	6/10/2004	26,65
11/6/2003	49,37	8/3/2004	22,22	13/10/2004	31,22
16/6/2003	52,12	24/3/2004	40,30	18/10/2004	22,22
23/6/2003	9,58	29/3/2004	34,32	25/10/2004	14,65
25/6/2003	56,06	31/3/2004	22,47	28/10/2004	31,01
30/6/2003	70,14	5/4/2004	31,61	10/11/2004	44,76
4/7/2003	71,37	12/4/2004	29,90	25/11/2004	43,06
7/7/2003	30,90	20/4/2004	21,96	3/12/2004	50,53
14/7/2003	60,56	21/4/2004	18,09	9/12/2004	24,91
17/7/2003	94,71	28/4/2004	21,03	15/12/2004	27,25
30/7/2003	23,52	4/5/2004	36,18	31/1/2005	16,78
4/8/2003	37,29	6/5/2004	17,52	10/2/2005	46,58
11/8/2003	35,26	17/5/2004	14,15	14/2/2005	19,67
12/8/2003	54,81	20/5/2004	32,94	21/2/2005	27,04
19/8/2003	15,06	24/5/2004	33,77	23/2/2005	30,60
3/9/2003	40,59	26/5/2004	27,86	28/2/2005	24,03
8/9/2003	53,58	8/6/2004	16,19	2/3/2005	27,10
11/9/2003	18,90	14/6/2004	48,49	21/3/2005	14,75
15/9/2003	10,33	16/6/2004	16,19	23/3/2005	16,35
17/9/2003	19,49	23/6/2004	19,93	13/4/2005	34,54
22/9/2003	55,14	28/6/2004	76,80	18/4/2005	35,21
29/9/2003	35,39	30/6/2004	58,08	27/4/2005	21,82
1/10/2003	48,29	5/7/2004	24,25	5/5/2005	39,39
6/10/2003	34,54	7/7/2004	42,27	9/5/2005	31,54
8/10/2003	10,34	14/7/2004	28,54	11/5/2005	28,05
16/10/2003	52,44	21/7/2004	13,89	16/5/2005	33,82
20/10/2003	58,21	26/7/2004	30,07	19/5/2005	52,85
22/10/2003	41,41	3/8/2004	75,99	23/5/2005	6,99
28/10/2003	7,77	5/8/2004	32,14	30/5/2005	12,98
3/11/2003	16,84	9/8/2004	31,77	1/6/2005	8,47
5/11/2003	13,46	11/8/2004	44,89	6/6/2005	14,95
14/11/2003	26,10	16/8/2004	19,94	13/6/2005	31,96
19/11/2003	16,87	18/8/2004	44,31	16/6/2005	20,58
24/11/2003	44,20	25/8/2004	52,72	21/6/2005	24,13
26/11/2003	4,54	30/8/2004	52,93	28/6/2005	30,19
1/12/2003	7,28	1/9/2004	40,81	30/6/2005	33,50
4/12/2003	6,35	15/9/2004	73,70	6/7/2005	11,77
8/12/2003	10,37	21/9/2004	41,17	11/7/2005	19,47
6/1/2004	9,94	23/9/2004	124,43	13/7/2005	33,67
9/1/2004	4,86			20/7/2005	22,13
28/1/2004	13,07			21/7/2005	59,79
9/2/2004	27,82			25/7/2005	48,68
11/2/2004	16,76			28/7/2005	19,40
16/2/2004	10,22				

<b>Data</b>	<b>Conc.(ug/m3)</b>
<b>1/8/2005</b>	31,12
<b>4/8/2005</b>	26,69
<b>9/8/2005</b>	25,82
<b>11/8/2005</b>	36,50
<b>18/8/2005</b>	46,22
<b>19/9/2005</b>	4,75
<b>26/9/2005</b>	10,84
<b>29/9/2005</b>	23,94
<b>3/10/2005</b>	24,38
<b>10/10/2005</b>	24,82
<b>19/10/2005</b>	12,80
<b>24/10/2005</b>	20,26
<b>31/10/2005</b>	10,26
<b>7/11/2005</b>	34,59
<b>14/11/2005</b>	25,89
<b>21/11/2005</b>	20,46
<b>30/11/2005</b>	68,79
<b>5/12/2005</b>	12,00
<b>30/1/2006</b>	14,69
<b>15/2/2006</b>	15,88

## Anexo 4

### Dados coletas com amostrador Dicotômico para concentração de MP<sub>2,5</sub>.

Data	Conc.(ug/m3)	Data	Conc.(ug/m3)	Data	Conc.(ug/m3)
14/6/2001	10,78	14/6/2002	10,84	5/8/2003	15,34
20/6/2001	5,30	18/6/2002	11,05	12/8/2003	18,01
23/6/2001	18,67	27/6/2002	7,41	21/8/2003	22,95
26/6/2001	1,88	1/8/2002	3,12	3/9/2003	13,51
29/6/2001	13,10	10/8/2002	14,43	11/9/2003	14,93
12/7/2001	18,10	12/8/2002	18,09	17/9/2003	17,67
16/7/2001	7,09	21/8/2002	21,46	27/9/2003	10,31
19/7/2001	20,60	26/8/2002	16,59	2/10/2003	26,95
24/7/2001	7,16	2/9/2002	12,10	8/10/2003	12,60
27/7/2001	5,42	10/9/2002	17,59	16/10/2003	11,77
30/7/2001	11,01	15/9/2002	17,80	22/10/2003	23,04
31/7/2001	13,44	23/9/2002	18,05	29/10/2003	11,81
7/8/2001	25,35	30/9/2002	23,00	5/11/2003	3,08
14/9/2001	5,57	10/10/2002	23,70	14/11/2003	12,23
20/9/2001	5,73	13/10/2002	20,67	19/11/2003	0,75
28/9/2001	3,85	11/11/2002	5,82	26/11/2003	5,57
4/10/2001	8,81	15/11/2002	7,44	29/12/2003	6,07
10/10/2001	2,94	18/11/2002	9,56	9/1/2004	6,28
25/10/2001	6,36	24/11/2002	12,56	14/1/2004	11,35
1/11/2001	6,45	2/12/2002	11,23	28/1/2004	7,49
7/11/2001	10,26	19/12/2002	3,74	4/2/2004	1,46
10/11/2001	5,89	23/12/2002	8,03	11/2/2004	5,03
23/11/2001	4,13	30/12/2002	8,98	16/2/2004	4,74
30/11/2001	3,65	16/1/2003	4,87	2/3/2004	12,52
11/12/2001	5,67	1/2/2003	3,62	31/3/2004	15,72
18/12/2001	5,47	10/2/2003	11,06	7/4/2004	5,95
26/12/2001	2,95	17/2/2003	5,41	21/4/2004	7,07
3/1/2002	6,80	25/2/2003	17,01	28/4/2004	10,73
7/1/2002	2,99	7/3/2003	5,11	4/5/2004	16,92
18/1/2002	6,16	10/3/2003	1,91	17/5/2004	23,25
26/1/2002	3,38	27/3/2003	8,65	24/5/2004	9,56
30/1/2002	6,07	2/4/2003	28,44	8/6/2004	11,77
6/2/2002	3,10	10/4/2003	9,86	16/6/2004	9,77
20/2/2002	2,62	16/4/2003	21,83	30/6/2004	8,69
27/2/2002	6,34	25/4/2003	13,72	21/7/2004	17,88
7/3/2002	5,02	7/5/2003	16,13	5/7/2004	16,76
20/3/2002	3,39	15/5/2003	11,10	14/7/2004	18,21
27/3/2002	5,32	22/5/2003	10,40	16/8/2004	10,02
6/4/2002	4,37	28/5/2003	19,54	23/8/2004	26,32
12/4/2002	12,81	6/6/2003	9,77	23/9/2004	15,64
16/4/2002	6,57	11/6/2003	18,67	6/10/2004	4,62
2/5/2002	7,35	23/6/2003	17,71	13/10/2004	1,00
13/5/2002	5,30	4/7/2003	27,78	18/10/2004	8,07
29/5/2002	6,57	17/7/2003	22,08	17/11/2004	8,77
		30/7/2003	41,96	25/11/2004	42,46
				30/11/2004	<b>0,50</b>

<b>Data</b>	<b>Conc.(ug/m3)</b>
<b>24/12/2004</b>	6,25
<b>26/1/2005</b>	6,20
<b>5/2/2005</b>	10,02
<b>14/2/2005</b>	5,45
<b>21/3/2005</b>	3,08
<b>18/4/2005</b>	19,42
<b>9/5/2005</b>	12,31
<b>16/5/2005</b>	13,60
<b>23/5/2005</b>	8,94
<b>30/5/2005</b>	17,59
<b>6/6/2005</b>	7,03
<b>15/6/2005</b>	5,95
<b>22/6/2005</b>	1,58
<b>28/6/2005</b>	13,93
<b>6/7/2005</b>	32,39
<b>20/7/2005</b>	86,99
<b>28/7/2005</b>	19,96
<b>4/8/2005</b>	14,55
<b>9/8/2005</b>	19,54
<b>18/8/2005</b>	28,69
<b>19/9/2005</b>	11,23
<b>29/9/2005</b>	5,41
<b>10/10/2005</b>	4,99
<b>19/10/2005</b>	3,33
<b>31/10/2005</b>	3,33
<b>7/11/2005</b>	0,50
<b>15/12/2005</b>	6,25
<b>31/1/2006</b>	5,82
<b>15/2/2006</b>	5,41
<b>21/2/2006</b>	2,91

## Anexo 5

### Dados coletas com amostrador Dicotômico para concentração de MP<sub>10-2,5</sub>.

Data	Conc.(ug/m3)	Data	Conc.(ug/m3)	Data	Conc.(ug/m3)
14/6/2001	13,7210	1/8/2002	10,1880	5/8/2003	19,1700
20/6/2001	1,5122	10/8/2002	31,7698	12/8/2003	15,3443
23/6/2001	13,8325	12/8/2002	23,6194	21/8/2003	34,8886
26/6/2001	3,0305	21/8/2002	30,0233	27/8/2003	13,2651
29/6/2001	9,6803	26/8/2002	20,3343	3/9/2003	21,0413
12/7/2001	9,0853	2/9/2002	13,4731	11/9/2003	6,7781
16/7/2001	11,0561	10/9/2002	21,2492	17/9/2003	17,3403
19/7/2001	17,9600	15/9/2002	17,3403	27/9/2003	4,5742
24/7/2001	7,8025	23/9/2002	14,0552	2/10/2003	21,7482
27/7/2001	7,3377	30/9/2002	30,9797	8/10/2003	2,5366
30/7/2001	12,4815	10/10/2002	31,2708	16/10/2003	17,6730
31/7/2001	5,8937	13/10/2002	25,2412	22/10/2003	18,2136
7/8/2001	36,3848	11/11/2002	11,2691	29/10/2003	15,0116
14/9/2001	2,5223	15/11/2002	5,8633	5/11/2003	5,7801
20/9/2001	8,9676	18/11/2002	8,8157	14/11/2003	12,5166
28/9/2001	3,6441	24/11/2002	9,5642	19/11/2003	12,3919
4/10/2001	21,5111	2/12/2002	9,2731	26/11/2003	3,6593
10/10/2001	6,2593	19/12/2002	5,3643	29/12/2003	2,5782
25/10/2001	18,8462	23/12/2002	18,0888	9/1/2004	6,3207
1/11/2001	16,7639	16/1/2003	6,4039	14/1/2004	0,0000
7/11/2001	18,8958	20/1/2003	0,0000	23/1/2004	5,7385
10/11/2001	11,0313	1/2/2003	7,9424	28/1/2004	0,0000
23/11/2001	8,8622	6/2/2003	0,0000	4/2/2004	7,3187
30/11/2001	9,2651	10/2/2003	7,9009	11/2/2004	9,0652
11/12/2001	12,0167	17/2/2003	5,6969	16/2/2004	4,0336
18/12/2001	11,1553	25/2/2003	12,6830	2/3/2004	12,1008
26/12/2001	6,4577	7/3/2003	3,8673	8/3/2004	11,9760
3/1/2002	13,1384	10/3/2003	2,6613	31/3/2004	16,8413
7/1/2002	7,6785	17/3/2003	17,6730	7/4/2004	8,9820
18/1/2002	15,9086	27/3/2003	13,1404	28/4/2004	13,8473
26/1/2002	79,5432	2/4/2003	21,1660	4/5/2004	12,8909
30/1/2002	11,3598	10/4/2003	7,7761	17/5/2004	6,5286
6/2/2002	2,5954	16/4/2003	16,5086	24/5/2004	9,1900
20/2/2002	7,7652	25/4/2003	13,1820	8/6/2004	24,9917
27/2/2002	2,5326	7/5/2003	9,3979	16/6/2004	15,0948
7/3/2002	6,6978	15/5/2003	7,8593	30/6/2004	15,7601
20/3/2002	4,5838	22/5/2003	24,2016	21/7/2004	8,5246
27/3/2002	3,4117	28/5/2003	21,3323	5/7/2004	20,0017
6/4/2002	4,3745	6/6/2003	12,5998	14/7/2004	30,7718
12/4/2002	12,1188	11/6/2003	17,4651	16/8/2004	19,0868
16/4/2002	5,0861	23/6/2003	23,3283	23/8/2004	37,9242
2/5/2002	9,0420	4/7/2003	43,8706	23/9/2004	29,3580
13/5/2002	6,6768	17/7/2003	18,6710	6/10/2004	17,1740
29/5/2002	5,0861	30/7/2003	33,1836	13/10/2004	5,6138
14/6/2002	17,1839			17/11/2004	10,2295
18/6/2002	23,0236			25/11/2004	0,9564
27/6/2002	12,0141			30/11/2004	3,9920

<b>Data</b>	<b>Conc.(ug/m3)</b>
<b>9/12/2004</b>	7,7878
<b>26/1/2005</b>	5,5306
<b>5/2/2005</b>	11,1444
<b>14/2/2005</b>	2,4534
<b>23/2/2005</b>	0,2495
<b>21/3/2005</b>	6,7781
<b>18/4/2005</b>	6,5702
<b>9/5/2005</b>	5,3227
<b>16/5/2005</b>	0,4990
<b>23/5/2005</b>	1,8713
<b>30/5/2005</b>	31,6035
<b>6/6/2005</b>	1,9544
<b>15/6/2005</b>	3,7841
<b>28/6/2005</b>	26,0313
<b>20/7/2005</b>	13,3067
<b>26/7/2005</b>	<b>0,0000</b>
<b>28/7/2005</b>	21,3739
<b>4/8/2005</b>	9,1484
<b>18/8/2005</b>	5,4059
<b>29/9/2005</b>	16,5644
<b>19/10/2005</b>	2,4950
<b>7/11/2005</b>	8,8720
<b>7/12/2005</b>	7,7878
<b>31/1/2006</b>	8,6269
<b>15/2/2006</b>	0,4158
<b>21/2/2006</b>	2,0792

## Anexo 6

### Mean Absolute Percentage Error (MAPE)

Disponível em: <[http://en.wikipedia.org/wiki/Mean\\_absolute\\_percentage\\_error](http://en.wikipedia.org/wiki/Mean_absolute_percentage_error)>, acesso em Fev/2009.

**Mean absolute percentage error** (também conhecido como **MAPE**) é medida de precisão em valor ajustados de uma série temporal na estatística, especificamente quando trata-se de tendências. Geralmente se manifesta como percentagem.

$$\text{MAPE} = \frac{1}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right|$$

A diferença entre o valor real  $A_t$  e o valor  $F_t$  da previsão, é dividida pelo valor real em outra vez. O valor absoluto deste cálculo é somado para cada tempo ajustado ou da previsão e dividido outra vez pelo número dos pontos ajustados  $n$ . Isto resulta em um erro percentual, então se pode comparar o erro das séries temporais ajustadas que diferem em nível.

### Root Mean Square Deviation

Disponível em: <[http://en.wikipedia.org/wiki/Root\\_mean\\_square\\_deviation](http://en.wikipedia.org/wiki/Root_mean_square_deviation)>, acesso em Fev/2009.

O **root mean square deviation** (RMSD) (também conhecido como **root mean square error** (RMSE)) é freqüentemente utilizado como uma medida das diferenças entre os valores preditos por um modelo ou um valor estimado e valores reais, onde a observação é feita a partir de moldes ou estimados. RMSD é uma boa medida de precisão. Estas diferenças individuais são também chamados de resíduos, bem como a RMSD serve para agregá-los em uma única medida de poder preditivo.

O RMSD de um estimador em relação ao parâmetro estimado  $\theta$  é definido como a raiz quadrada do erro médio:

$$\text{RMSD}(\hat{\theta}) = \sqrt{\text{MSE}(\hat{\theta})} = \sqrt{\text{E}((\hat{\theta} - \theta)^2)}.$$

## Anexo 7

### Resultados dos 10 modelos com menor valor de AIC para a série de dados do MP<sub>10</sub>.

Tabela 12 - Comparação dos modelos obtidos com menor AIC

	Modelo	AIC	Parâmetros
M1	arima (2,0,2)×(1,0,0) <sub>6</sub>	-56,37248	5
M2	arima (2,1,3)×(0,0,0) <sub>6</sub>	-56,06557	6
M3	arima (1,0,0)×(1,0,1) <sub>6</sub>	-50,44648	3
M4	arima (0,0,1)×(1,0,1) <sub>6</sub>	-49,88188	3
M5	arima (1,0,1)×(1,0,1) <sub>6</sub>	-48,75357	4
M6	arima (2,0,0)×(1,0,1) <sub>6</sub>	-48,55726	4
M7	arima (0,0,2)×(1,0,1) <sub>6</sub>	-47,98307	4
M8	arima (0,0,3)×(1,0,1) <sub>6</sub>	-47,54608	5
M9	arima (2,0,3)×(1,0,1) <sub>6</sub>	-47,54444	7
M10	arima (1,0,2)×(1,0,1) <sub>6</sub>	-47,20685	5

Valores dos parâmetros para os 10 modelos com menor valor de AIC para a série de dados do MP<sub>10</sub>.

Tabela 13 - Análise estatística dos parâmetros dos modelos da série MP<sub>10</sub>

Modelo	Parâmetros	Variáveis		
		Valor	Erro padrão	$p < 0,05$
M1	$\phi_1$	1,7335	0,0031	0,00000
	$\phi_2$	-0,9995	0,010	0,00000
	$\theta_1$	-1,6981	0,0955	0,00000
	$\theta_2$	0,9997	0,1082	0,00000
	$\Phi_1$	0,0606	0,1272	0,31701
	Intercepto	3,4535	0,0197	0,00000
M2	$\phi_1$	1,7293	0,0043	0,00000
	$\phi_2$	-0,9996	0,0016	0,000000
	$\theta_1$	-2,5045	0,1948	0,0000
	$\theta_2$	2,3145	0,3552	0,00000
	$\theta_3$	-0,760	0,174	0,00001
	Intercepto			
M3	$\phi_1$	0,3237	0,1239	0,00448
	$\Phi_1$	-0,9979	0,0089	0,00000
	$\Theta_1$	0,9049	0,1930	0,00000
	Intercepto	3,4510	0,0238	0,00000
M4	$\theta_1$	0,3093	0,1234	0,00610
	$\Phi_1$	-0,9992	0,0062	0,00000
	$\Theta_1$	0,9372	0,2376	0,00004
	Intercepto	3,4515	0,0212	0,00000
M5	$\phi_1$	0,5712	0,3705	0,066160
	$\theta_1$	-0,2897	0,4595	0,26418
	$\Phi_1$	-0,9971	0,0088	0,00000
	$\Theta_1$	0,8852	0,1712	0,00000
	Intercepto	3,4503	0,0263	0,00000

Continuação da Tabela 13.

M6	$\phi_1$	0,3102	0,1292	0,00820
	$\phi_2$	0,0408	0,1223	0,36946
	$\Phi_1$	-0,9974	0,0093	0,00000
	$\Theta_1$	0,8953	0,1835	0,00000
	Intercepto	3,4508	0,00247	0,00000
M7	$\theta_1$	0,3098	0,1296	0,00842
	$\theta_2$	0,0394	0,1247	0,37589
	$\Phi_1$	-0,9988	0,0077	0,00000
	$\Theta_1$	0,9262	0,2369	0,00005
	Intercepto	3,4514	0,0218	0,00000
M8	$\theta_1$	0,3059	0,1303	0,00947
	$\theta_2$	0,0758	0,1262	0,27394
	$\theta_3$	0,1366	0,1079	0,10283
	$\Phi_1$	-0,9985	0,0084	0,00000
	$\Theta_1$	0,9199	0,2254	0,00002
Intercepto	3,4508	0,0242	0,00000	
M9	$\phi_1$	1,0377	0,1688	0,00000
	$\phi_2$	-0,7257	0,1980	0,000012
	$\theta_1$	-0,7479	0,1886	0,00004
	$\theta_2$	0,5056	0,2163	0,00972
	$\theta_3$	0,3723	0,1390	0,00369
	$\Phi_1$	-0,9996	0,0035	0,00000
	$\Theta_1$	0,9624	0,1596	0,00000
	Intercepto	3,4489	0,0257	0,00000
M10	$\phi_1$	0,8430	0,2816	0,00138
	$\theta_1$	-0,5426	0,3197	0,04483
	$\theta_2$	-0,1523	0,1845	0,20444
	$\Phi_1$	-0,9977	0,0074	0,00000
	$\Theta_1$	0,8874	0,1766	0,00000
Intercepto	3,4468	0,0317	0,00000	

Valores de erros calculados para os 10 modelos com menor valor de AIC para a série de dados do MP<sub>10</sub>.

Tabela 14 – Valores dos erros calculados para os 10 modelos com menor AIC para dados da série MP<sub>10</sub>

	MAPE	RMSE	RMSE%
M1	0,4200952	11,49138	0,6088991
M2	0,3275844	9,897359	0,4500748
M3	0,4080315	10,96247	0,5758327
M4	0,4078156	10,95471	0,576142
M5	0,4085385	11,02	0,5766825
M6	0,4083701	10,98102	0,5761261
M7	0,4080801	10,95878	0,5761732
M8	0,4073440	10,95516	0,5756971
M9	0,4031358	10,74074	0,567772
M10	0,40017457	10,92295	0,579513

Resultados gerais dos 10 modelos com menor AIC.

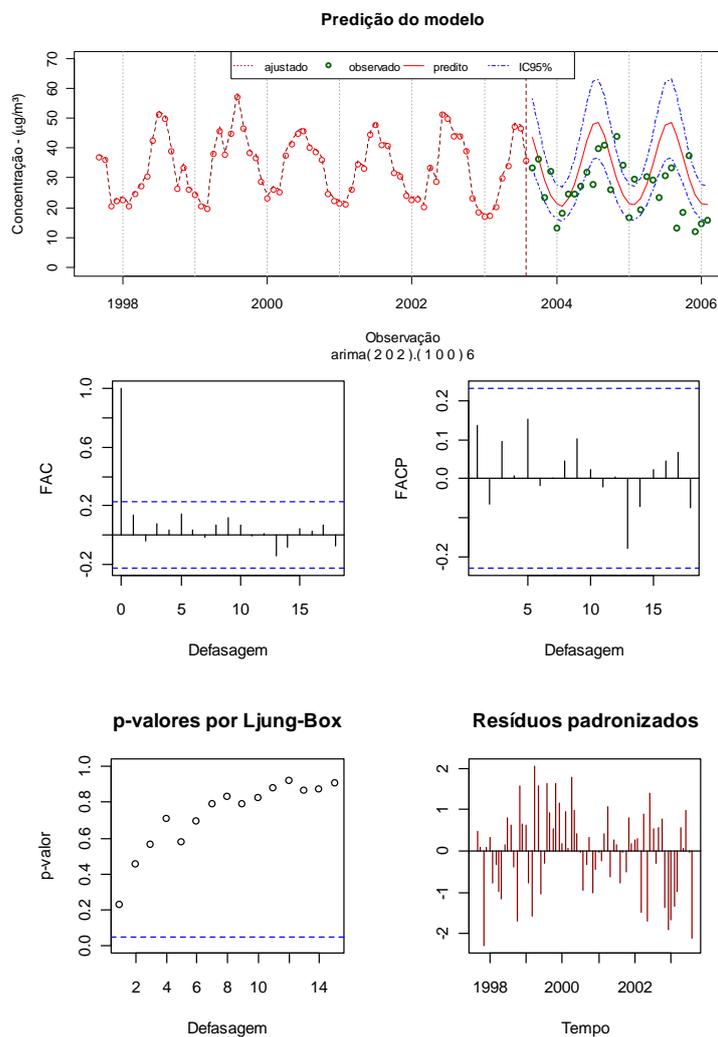
**[1] SARIMA (2 0 2)x(1 0 0) 6**

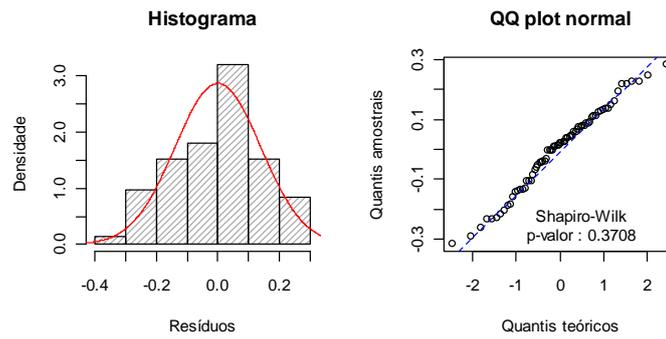
**Parâmetros:**

ar1	ar2	ma1	ma2	sar1	intercept
0.00000	0.00000	0.00000	0.00000	0.31701	0.00000

**Erros:**

MAPE	RMSE	RMSEp
0.4200952	11.49138	0.6088991





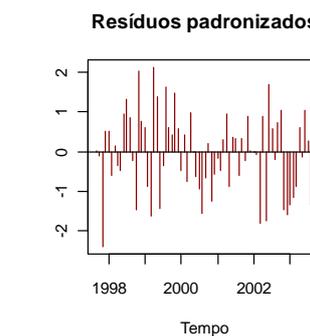
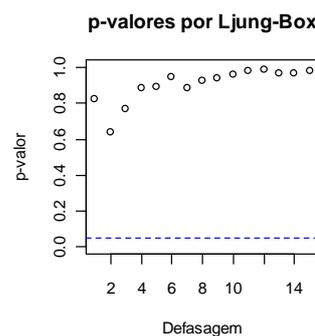
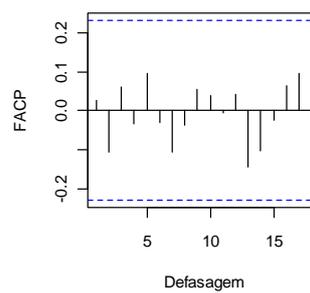
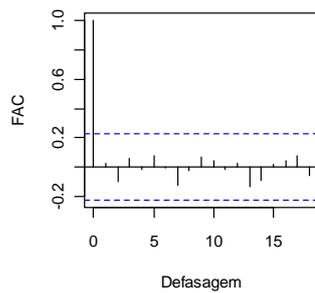
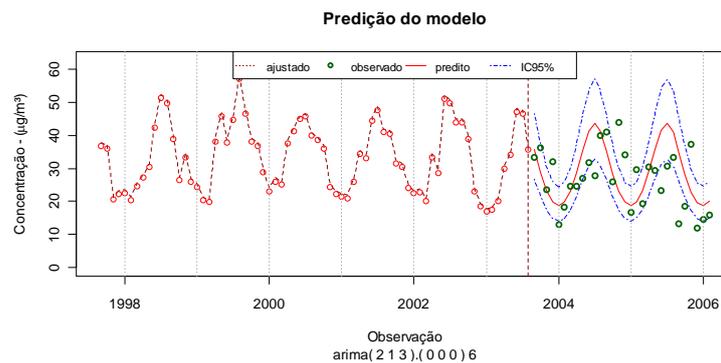
[2] SARIMA (2 1 3)x(0 0 0) 6

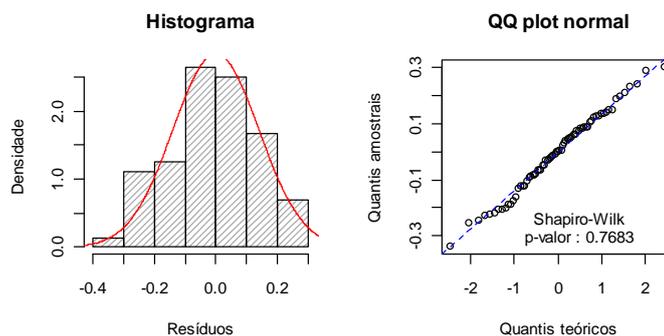
**Parâmetros:**

ar1 ar2 ma1 ma2 ma3  
0e+00 0e+00 0e+00 0e+00 1e-05

**Erros:**

MAPE RMSE RMSEp  
0.3275844 9.897359 0.4500748





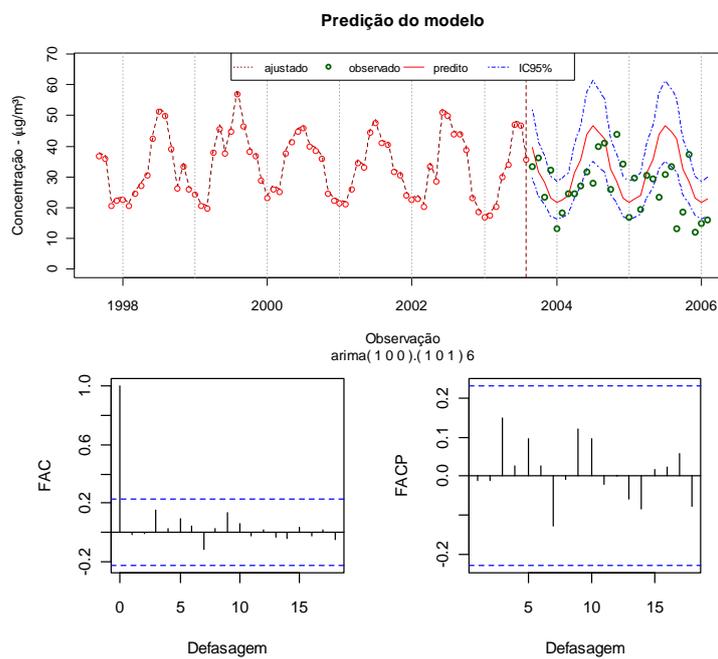
### [3] SARIMA (1 0 0)x(1 0 1) 6

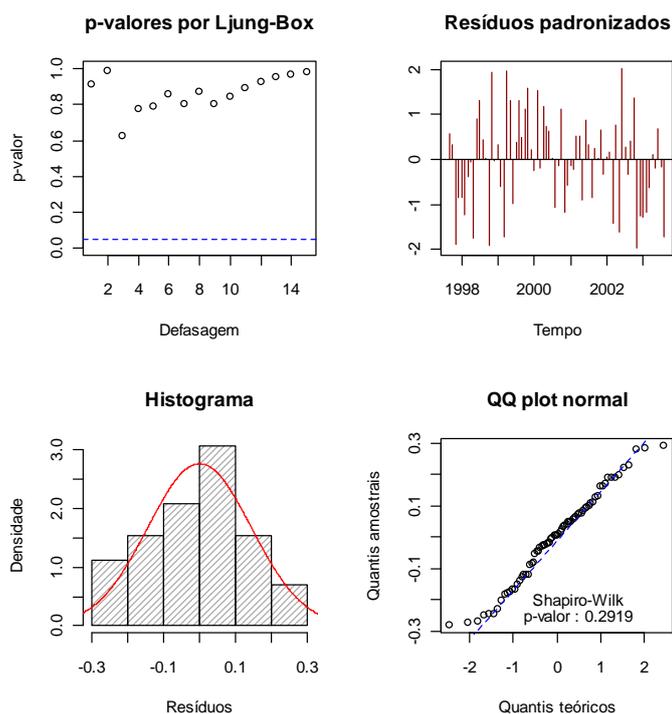
#### Parâmetros:

ar1 sar1 sma1 intercept  
 0.00448 0.00000 0.00000 0.00000

#### Erros:

MAPE RMSE RMSEp  
 0.4080315 10.96247 0.5758327





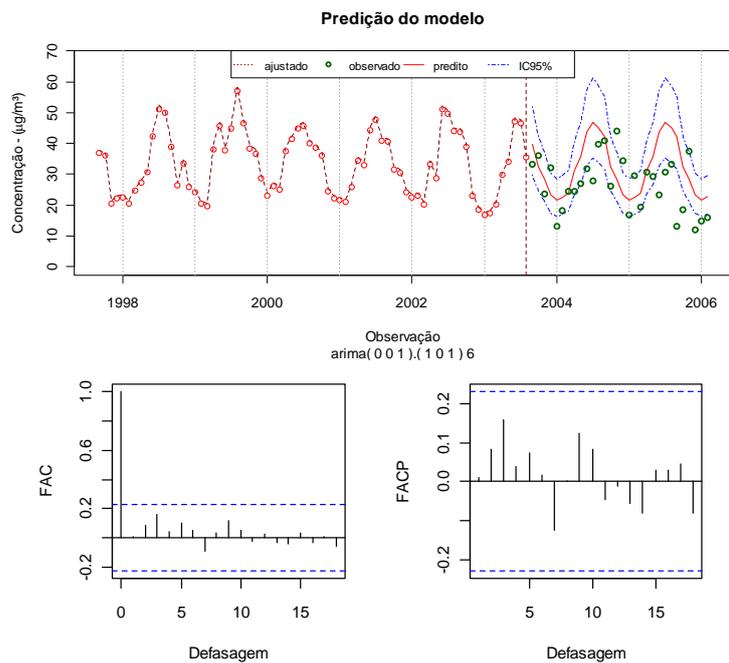
[4] SARIMA (0 0 1)x(1 0 1) 6

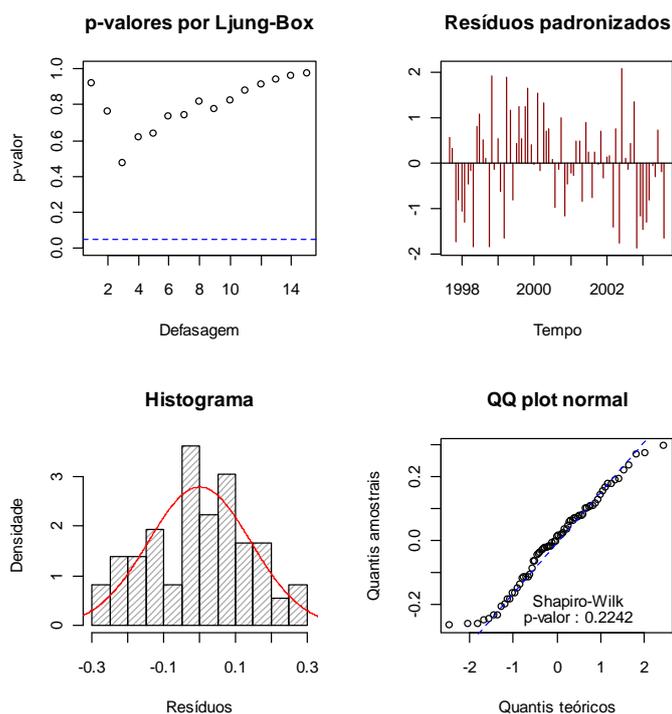
**Parâmetros:**

ma1 sar1 sma1 intercept  
 0.00610 0.00000 0.00004 0.00000

**Erros:**

MAPE RMSE RMSEp  
 0.4078156 10.95471 0.576142





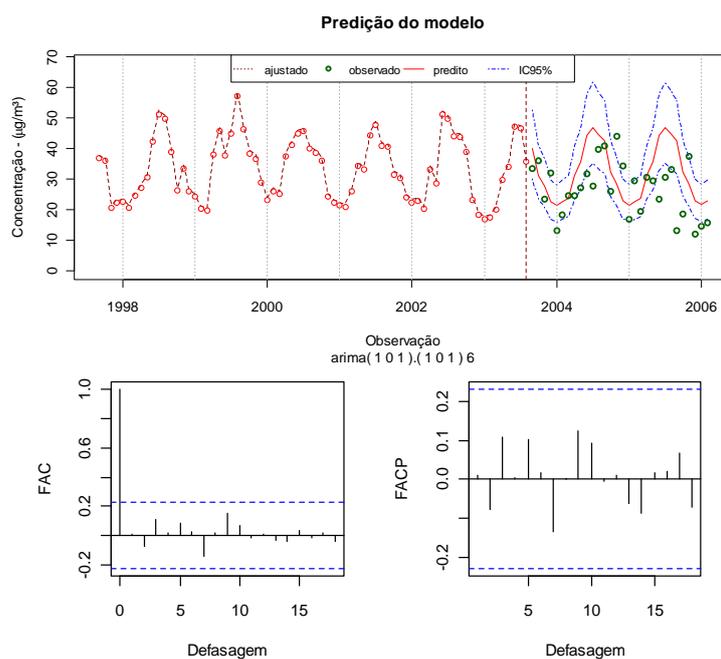
[5] SARIMA (1 0 1)x(1 0 1) 6

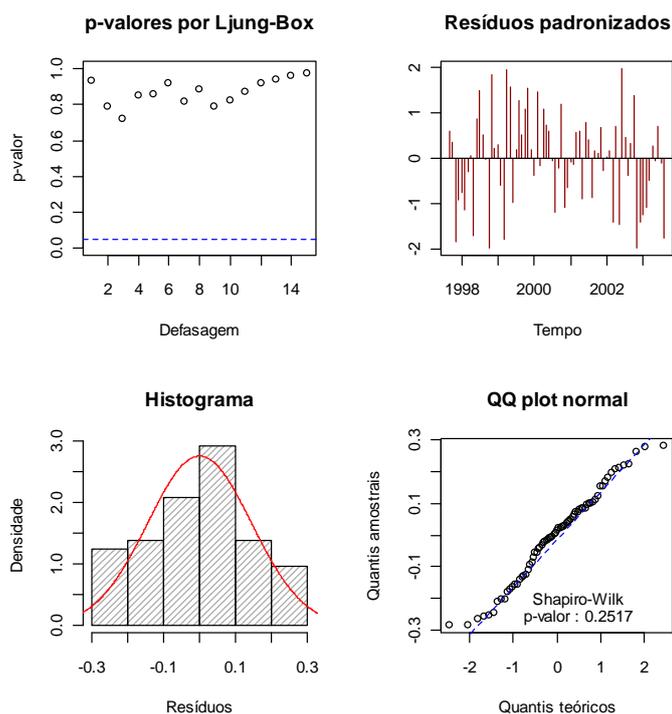
**Parâmetros:**

ar1    ma1    sar1    smal    intercept  
 0.06160   0.26418   0.00000   0.00000   0.00000

**Erros:**

MAPE    RMSE    RMSEp  
 0.4085385   11.02   0.5766825





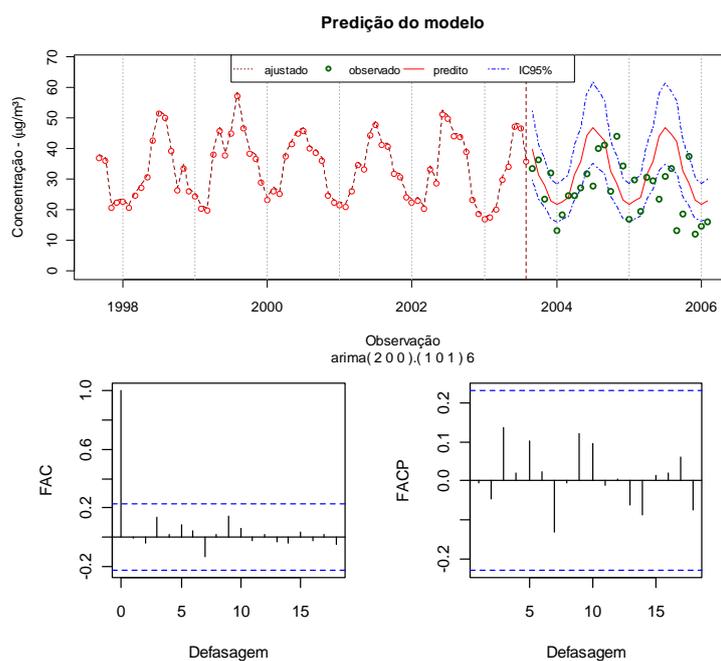
[6] SARIMA (2 0 0)x(1 0 1) 6

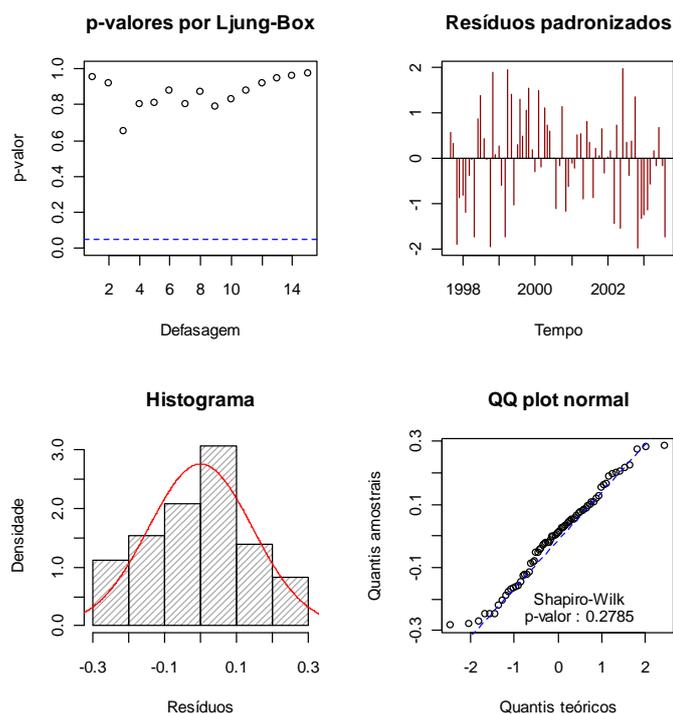
**Parâmetros:**

ar1	ar2	sar1	smal	intercept
0.00820	0.36946	0.00000	0.00000	0.00000

**Erros:**

MAPE	RMSE	RMSEp
0.4083701	10.98102	0.5761261





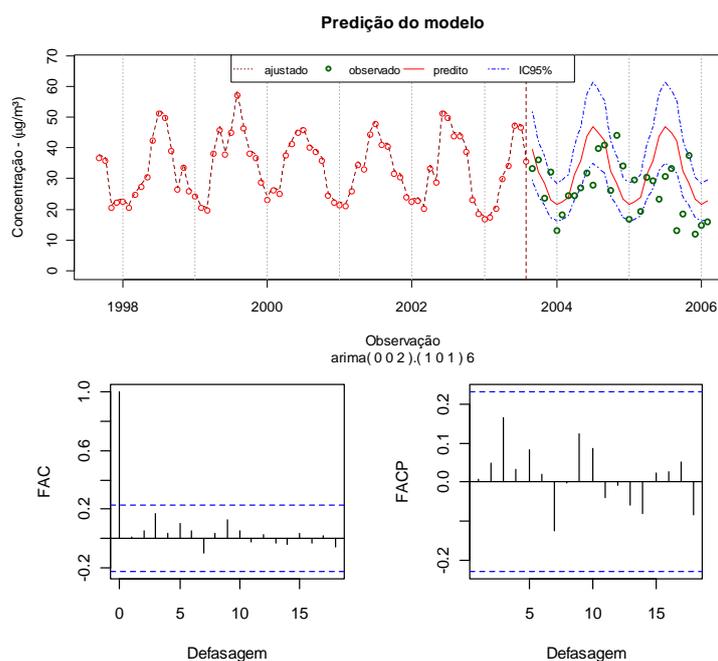
[7] SARIMA (0 0 2)x(1 0 1) 6

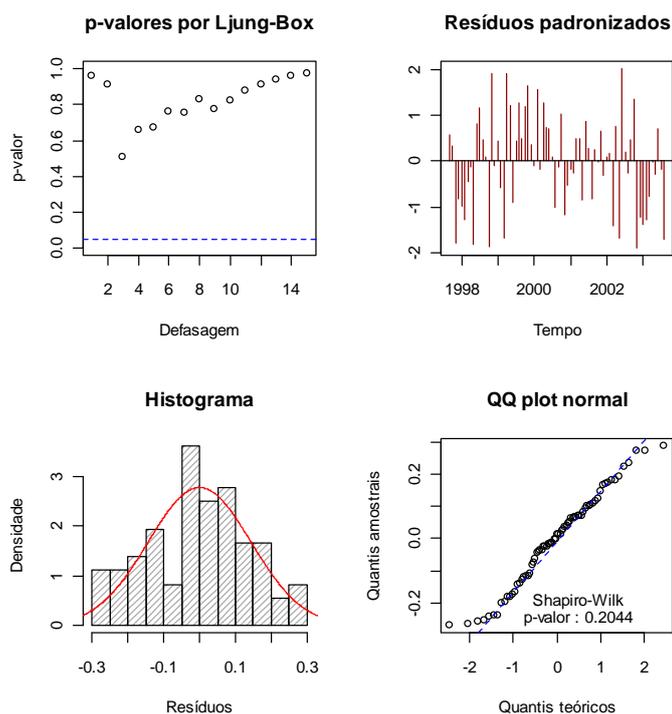
**Parâmetros:**

ma1	ma2	sar1	sma1	intercept
0.00842	0.37589	0.00000	0.00005	0.00000

**Erros:**

MAPE	RMSE	RMSEp
0.4080801	10.95878	0.5761732





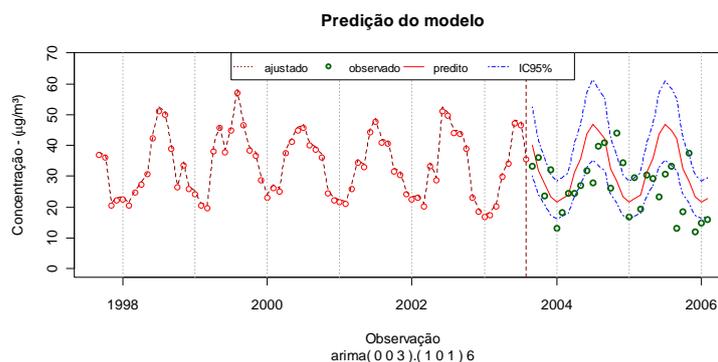
[8] SARIMA (0 0 3)x(1 0 1) 6

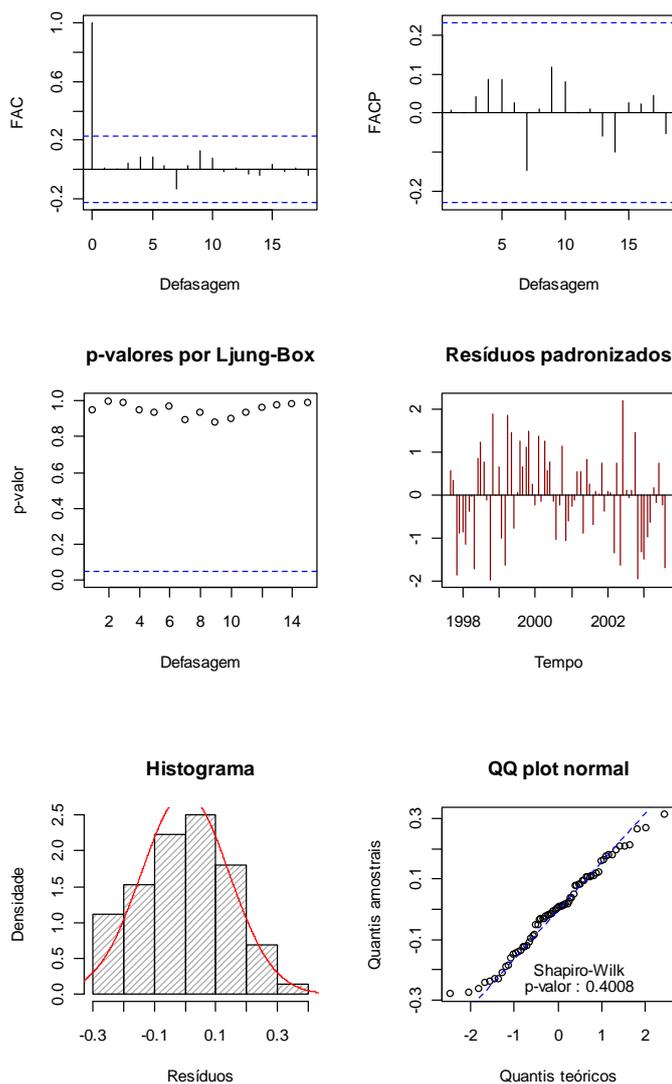
**Parâmetros:**

ma1	ma2	ma3	sar1	sma1	intercept
0.00947	0.27394	0.10283	0.00000	0.00002	0.00000

**Erros:**

MAPE	RMSE	RMSEp
0.4073440	10.95516	0.5756971





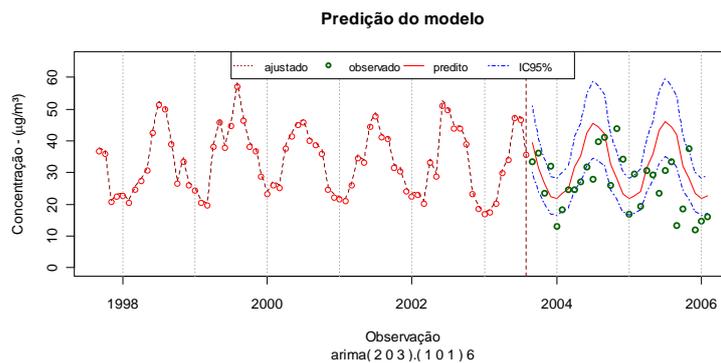
[9] SARIMA (2 0 3)x(1 0 1) 6

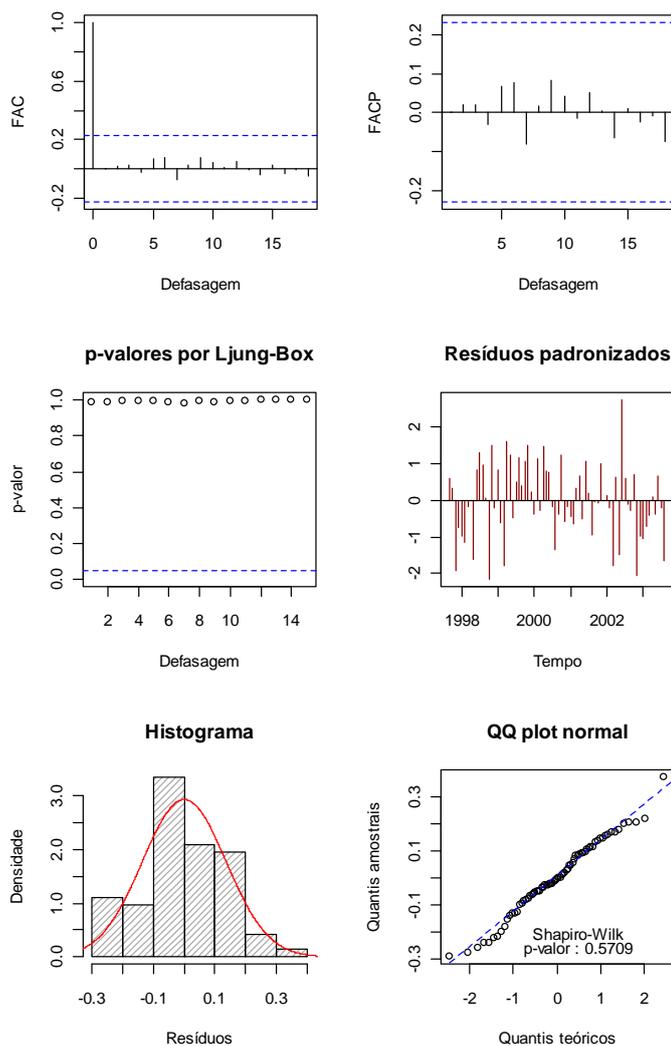
**Parâmetros:**

ar1	ar2	ma1	ma2	ma3	sar1	sma1	intercept
0.00000	0.00012	0.00004	0.00972	0.00369	0.00000	0.00000	0.00000

**Erros:**

MAPE	RMSE	RMSEp
0.4031358	10.74074	0.567772





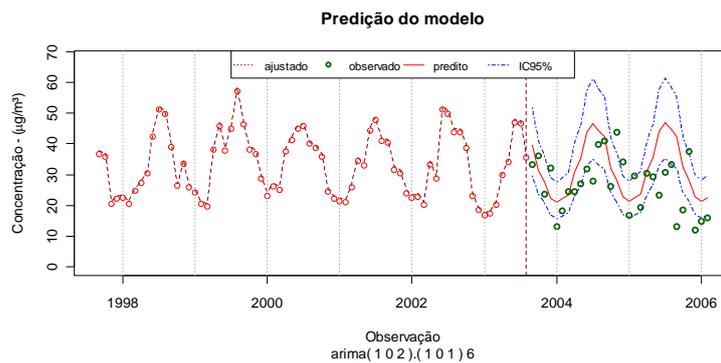
## [10] SARIMA (1 0 2)x(1 0 1) 6

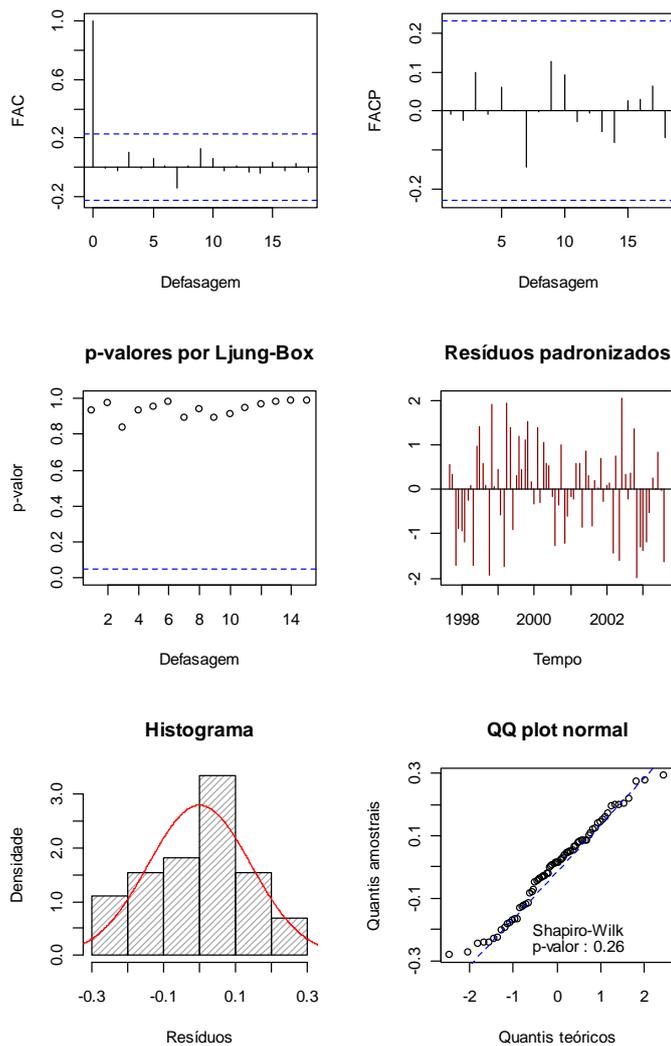
### Parâmetros:

ar1	ma1	ma2	sar1	smal	intercept
0.00138	0.04483	0.20444	0.00000	0.00000	0.00000

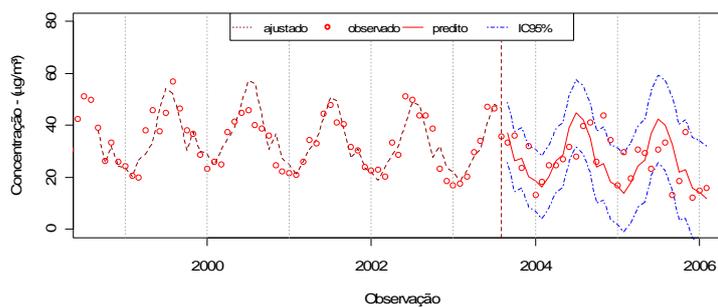
### Erros:

MAPE	RMSE	RMSEp
0.4017457	10.92295	0.5709513





**Holt-Winters**



**Erros:**

MAPE RMSE RMSEp  
 0.537243 15.42692 0.7200414

## Anexo 8

### Resultados dos 10 modelos com menor valor de AIC para a série de dados do MP<sub>2,5</sub>.

Tabela 15 - Comparação dos modelos obtidos com menor AIC para dados da série MP<sub>2,5</sub>

	Modelo	AIC	Parâmetros
M1	arima (2,1,3)×(1,0,1) <sub>6</sub>	84,14907	8
M2	arima (0,0,3)×(1,0,1) <sub>6</sub>	84,34229	5
M3	arima (0,0,2)×(1,0,1) <sub>6</sub>	85,18649	4
M4	arima (1,0,2)×(1,0,1) <sub>6</sub>	85,51312	5
M5	arima (2,0,3)×(0,0,0) <sub>6</sub>	85,65818	5
M6	arima (2,0,2)×(1,0,1) <sub>6</sub>	86,23122	6
M7	arima (0,0,3)×(1,0,0) <sub>6</sub>	86,33125	4
M8	arima (1,0,3)×(1,0,1) <sub>6</sub>	86,34090	6
M9	arima (2,1,3)×(1,0,0) <sub>6</sub>	86,48810	7
M10	arima (0,0,3)×(0,0,1) <sub>6</sub>	86,70969	4

Valores dos parâmetros para os 10 modelos com menor valor de AIC para a série de dados do MP<sub>2,5</sub>.

Tabela 16 - Análise estatística dos parâmetros dos modelos

Modelo	Parâmetros	Variáveis		
		Valor	Erro padrão	$p < 0,05$
M1	$\phi_1$	-0,7859	0,1629	0,00000
	$\phi_2$	-0,7518	0,1505	0,00000
	$\theta_1$	-0,2193	0,1592	0,08412
	$\theta_2$	0,5097	0,1183	0,00001
	$\theta_3$	-0,8184	0,1475	0,00000
	$\Phi_1$	-0,9768	0,0708	0,00000
	$\Theta_1$	0,7929	0,3380	0,00950
Intercepto				
M2	$\theta_1$	-0,0840	0,1381	0,27150
	$\theta_2$	0,2919	0,1377	0,01702
	$\theta_3$	0,3240	0,1623	0,02295
	$\Phi_1$	-0,9866	0,1016	0,00000
	$\Theta_1$	0,8903	0,4257	0,01825
Intercepto				
M3	$\theta_1$	-0,1415	0,1674	0,19889
	$\theta_2$	0,3572	0,1534	0,00993
	$\Phi_1$	-0,9734	0,1007	0,00000
	$\Theta_1$	0,8231	0,3568	0,01052
Intercepto				
M4	$\phi_1$	0,4340	0,2419	0,03640
	$\theta_1$	-0,5512	0,2240	0,00694
	$\theta_2$	0,4359	0,1647	0,00406
	$\Phi_1$	-0,9719	0,0996	0,00000
	$\Theta_1$	0,8251	0,3244	0,00549
Intercepto				
		2,2828	0,0949	0,00000

Continuação da Tabela 16.

M5	$\phi_1$	1,6016	0,1073	0,00000
	$\phi_2$	-0,8626	0,1026	0,00000
	$\theta_1$	-1,6044	0,1577	0,00000
	$\theta_2$	1,2048	0,2076	0,00000
	$\theta_3$	-0,3320	0,1597	0,01883
	Intercepto	2,2945	0,0733	0,00000
M6	$\phi_1$	0,6645	0,2358	0,00242
	$\phi_2$	-0,3915	0,2644	0,06939
	$\theta_1$	-0,7520	0,1531	0,00000
	$\theta_2$	0,7689	0,2019	0,00007
	$\Phi_1$	-0,9986	0,0193	0,00000
	$\Theta_1$	0,9661	0,2244	0,00001
	Intercepto	22,803	0,0871	0,00000
M7	$\theta_1$	-0,0108	0,1406	0,46947
	$\theta_2$	0,3814	0,1233	0,00099
	$\theta_3$	0,3166	0,1579	0,02247
	$\Phi_1$	-0,3290	0,1738	0,02917
	Intercepto	2,301	0,091	0,00000
M8	$\phi_1$	0,01057	0,4350	0,48562
	$\theta_1$	-0,0974	0,3964	0,40299
	$\theta_2$	0,2945	0,1583	0,03140
	$\theta_3$	0,3202	0,1957	0,05090
	$\Phi_1$	-0,9878	0,1048	0,00000
	$\Theta_1$	0,8956	0,4591	0,02554
	Intercepto	22,824	0,0944	0,00000
M9	$\phi_1$	-0,8327	0,1304	0,00000
	$\phi_2$	-0,7984	0,1229	0,00000
	$\theta_1$	-0,1525	0,1914	0,21282
	$\theta_2$	0,6072	0,1291	0,00000
	$\theta_3$	-0,7076	0,1713	0,00002
	$\Phi_1$	-0,6064	0,1331	0,00000
	Intercepto			
M10	$\theta_1$	0,0238	0,1307	0,42787
	$\theta_2$	0,3773	0,1197	0,00081
	$\theta_3$	0,3448	0,1468	0,00941
	$\Theta_1$	-0,3070	0,1783	0,04255
	Intercepto	2,3070	0,0891	0,00000

Valores de erros calculados para os 10 modelos com menor valor de AIC para a série de dados do  $MP_{2,5}$ .

Tabela 17 - Valores dos erros calculados para os 10 modelos com menor AIC para dados da série  $MP_{2,5}$

	MAPE	RMSE	RMSE%
M1	0,8564643	5,57213	1,12702
M2	0,7374078	4,769776	0,9991118
M3	0,7968595	5,473025	1,064004
M4	0,7970494	5,379142	1,054335
M5	0,9249735	5,943902	1,318381
M6	0,7357182	4,926749	0,9672644
M7	0,9458452	5,666342	1,126746
M8	0,7404108	4,795815	1,002859
M9	1,092516	6,549288	1,264341
M10	1,027831	6,049409	1,274704

Resultados gerais dos 10 modelos com menor AIC.

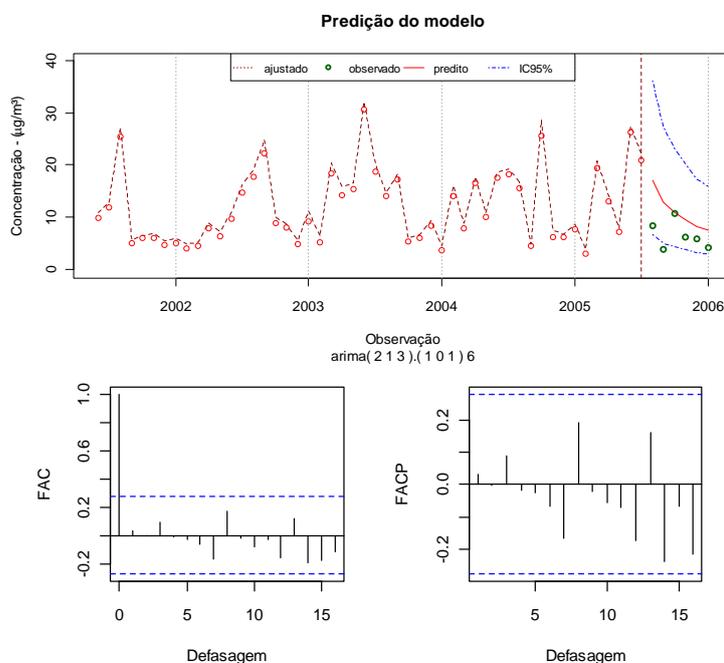
[1] SARIMA(2 1 3)x(1 0 1) 6

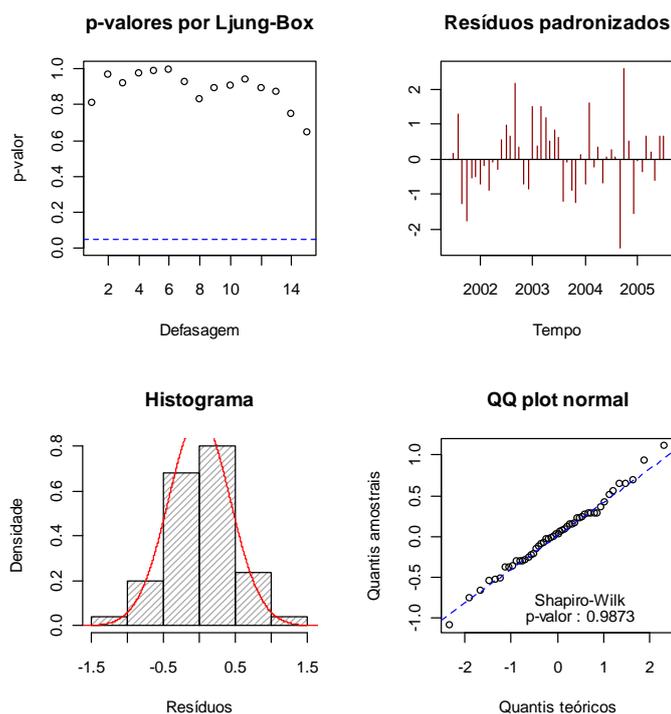
**Parâmetros:**

ar1      ar2      ma1      ma2      ma3      sar1      sma1  
 0.00000 0.00000 0.08412 0.00001 0.00000 0.00000 0.00950

**Erros:**

MAPE      RMSE      RMSEp  
 0.8564643    5.57213    1.12702





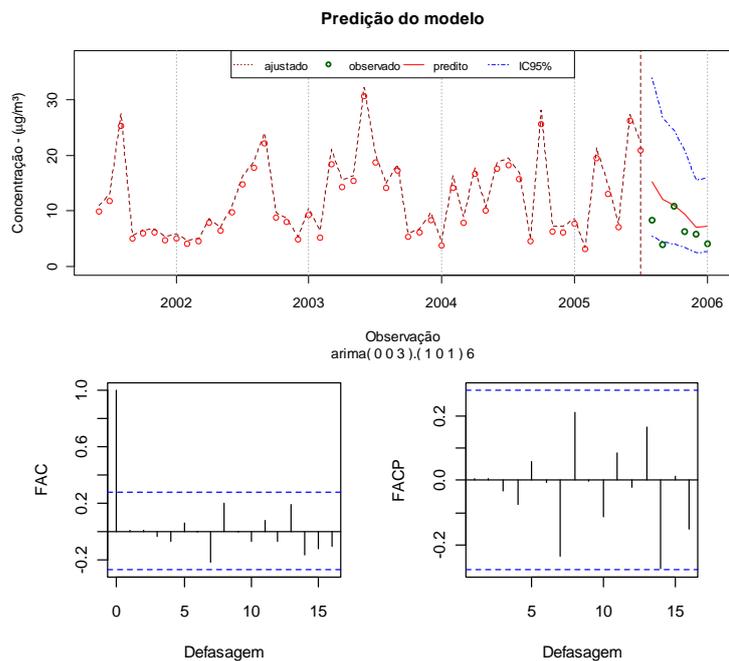
**[2] SARIMA(0 0 3)x(1 0 1) 6**

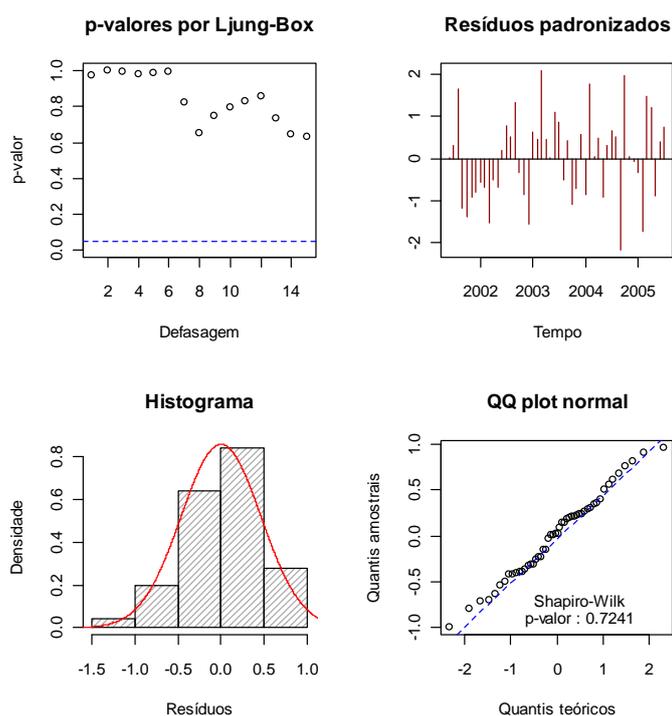
**Parâmetros:**

ma1	ma2	ma3	sar1	sma1	intercept
0.27150	0.01702	0.02295	0.00000	0.01825	0.00000

**Erros:**

MAPE	RMSE	RMSEp
0.7374078	4.769776	0.9991118





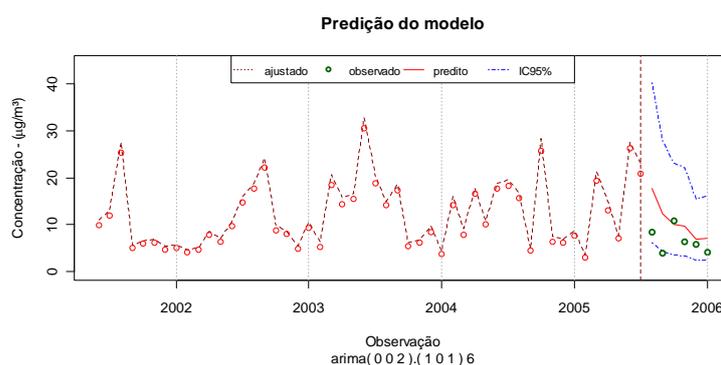
[3] SARIMA(0 0 2)x(1 0 1) 6

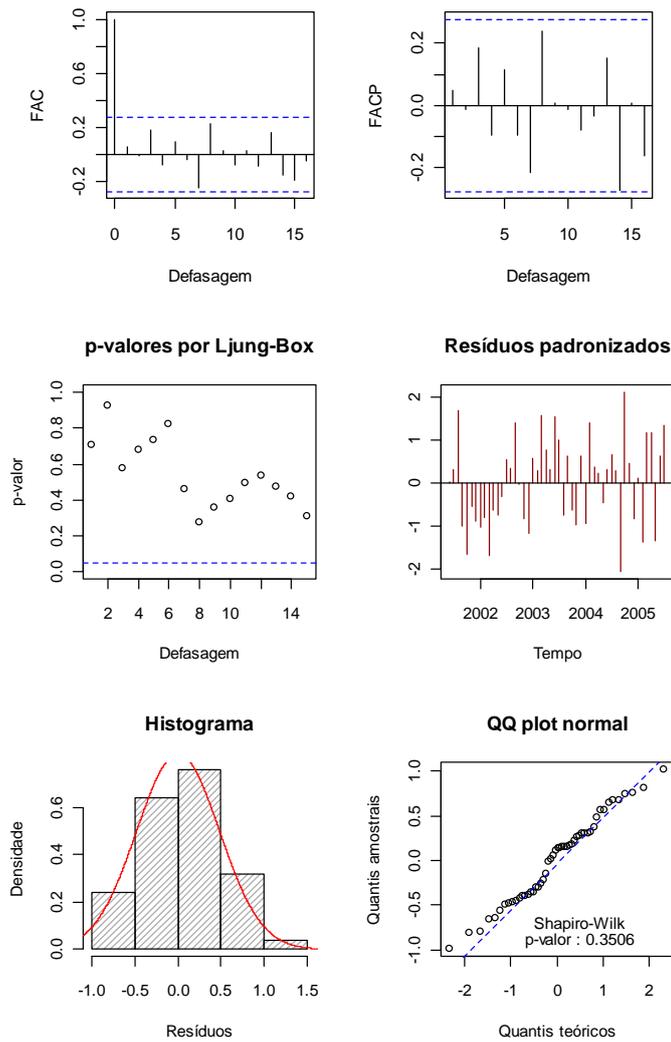
**Parâmetros:**

ma1	ma2	sar1	sma1	intercept
0.19889	0.00993	0.00000	0.01052	0.00000

**Erros:**

MAPE	RMSE	RMSEp
0.7968595	5.473025	1.064004





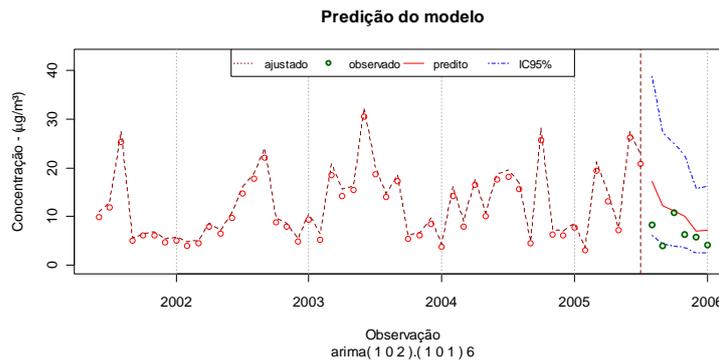
**[4] SARIMA(1 0 2)x(1 0 1) 6**

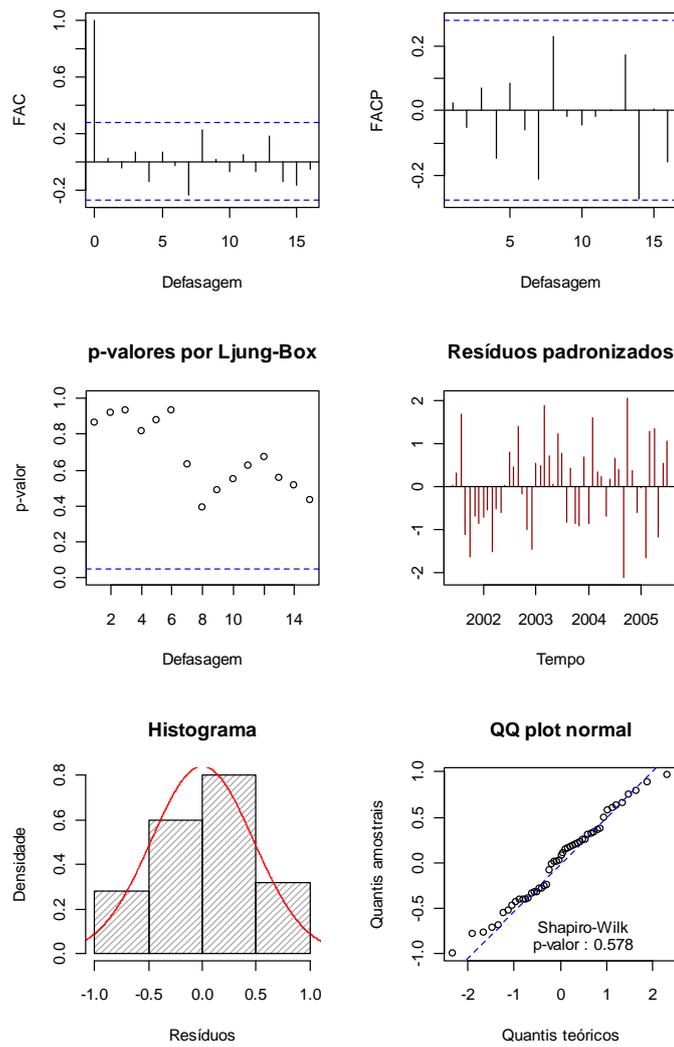
**Parâmetros:**

ar1	ma1	ma2	sar1	sma1	intercept
0.03640	0.00694	0.00406	0.00000	0.00549	0.00000

**Erros:**

MAPE	RMSE	RMSEp
0.7970494	5.379142	1.054335





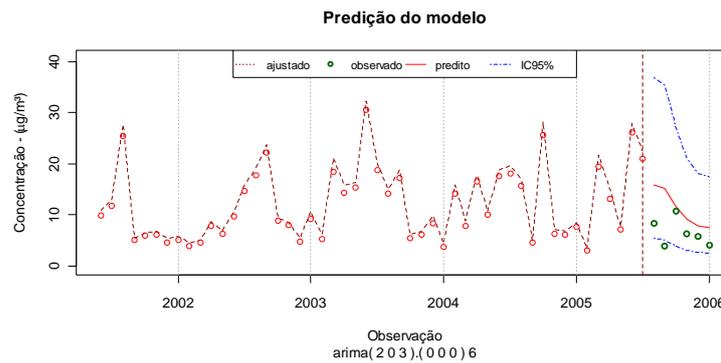
**[5] SARIMA(2 0 3)x(0 0 0)6**

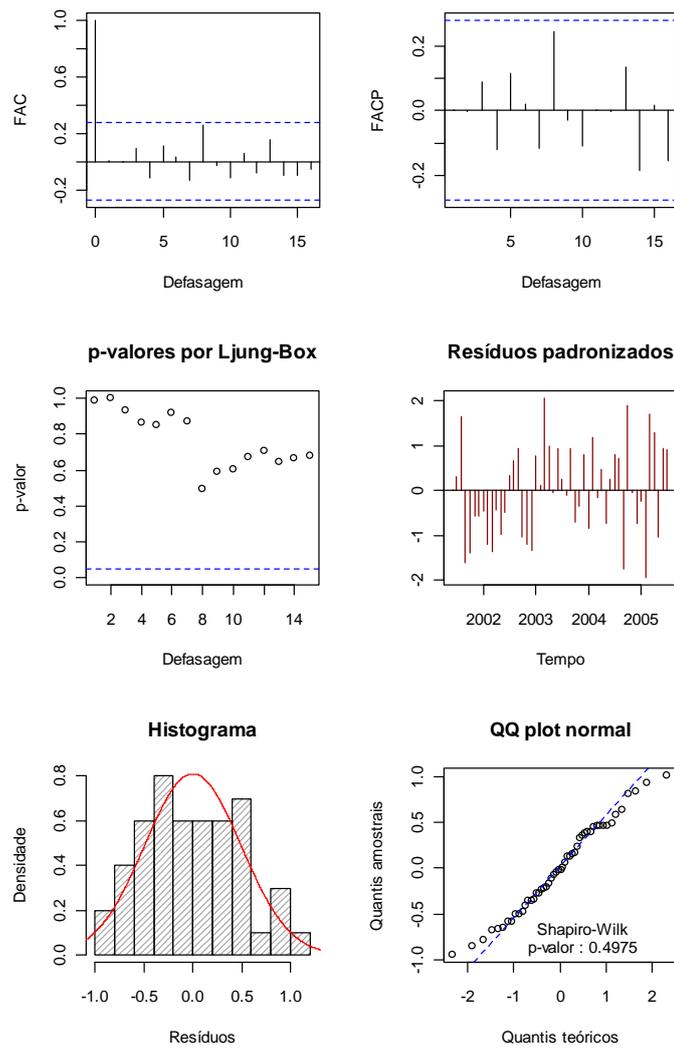
**Parâmetros:**

ar1	ar2	ma1	ma2	ma3	intercept
0.00000	0.00000	0.00000	0.00000	0.01883	0.00000

**Erros:**

MAPE	RMSE	RMSEp
0.9249735	5.943902	1.318381





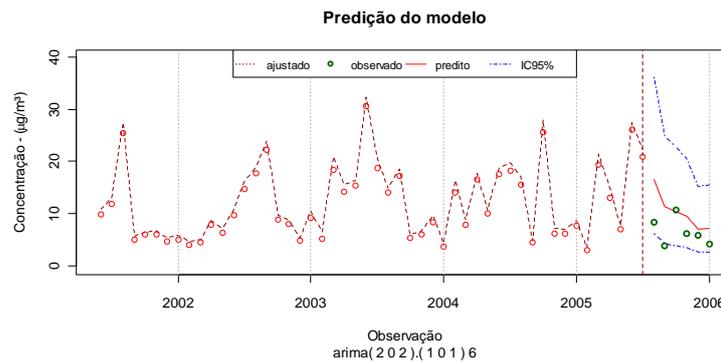
**[6] SARIMA(2 0 2)x(1 0 1) 6**

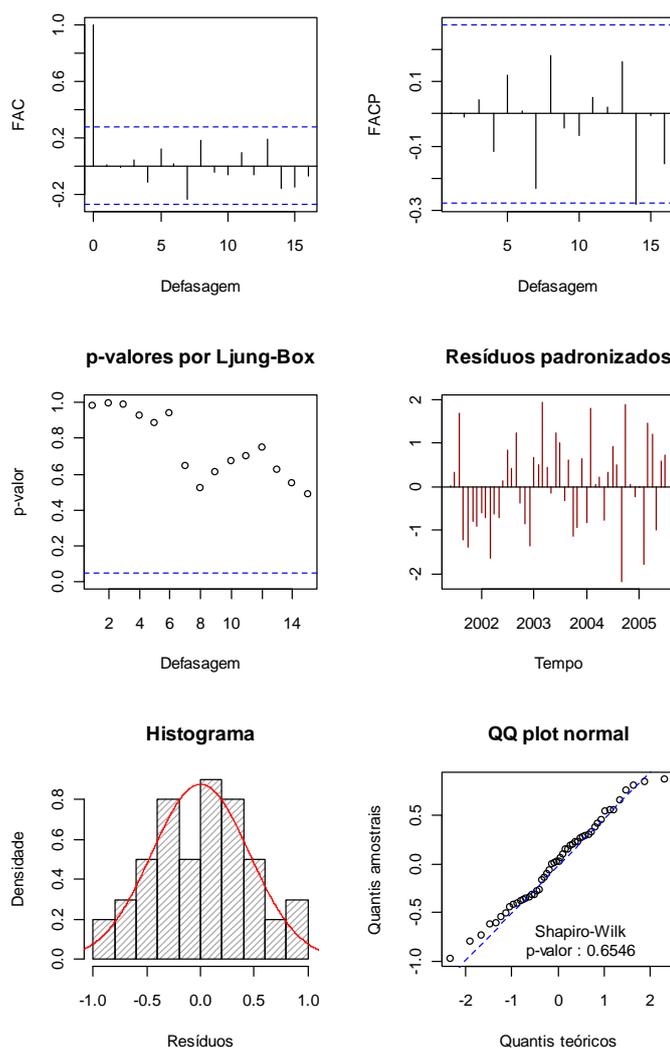
**Parâmetros:**

ar1 ar2 ma1 ma2 sar1 smal intercept  
 0.00242 0.06936 0.00000 0.00007 0.00000 0.00001 0.00000

**Erros:**

MAPE RMSE RMSEp  
 0.7357182 4.926749 0.9672644





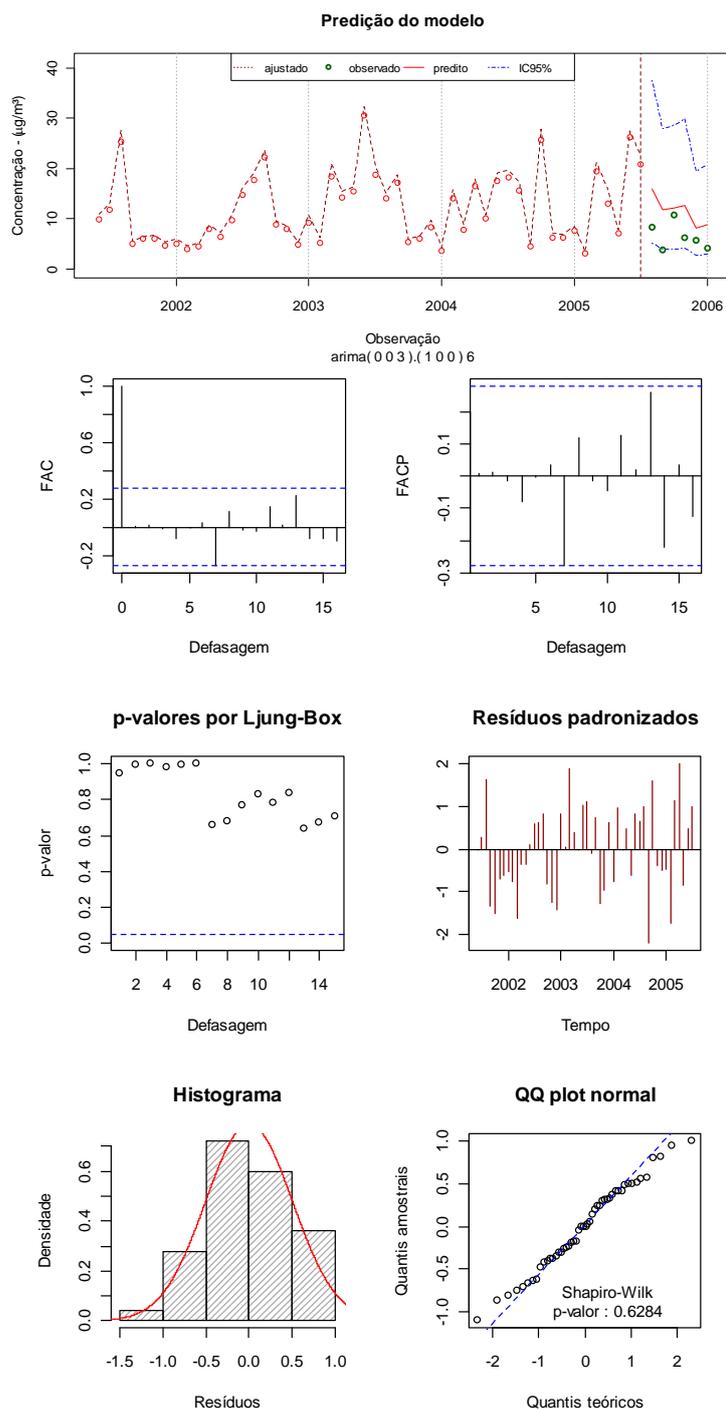
**[7] SARIMA(0 0 3)x(1 0 0) 6**

**Parâmetros:**

ma1	ma2	ma3	sar1	intercept
0.46947	0.00099	0.02247	0.02917	0.00000

**Erros:**

MAPE	RMSE	RMSEp
0.9458452	5.666342	1.126746



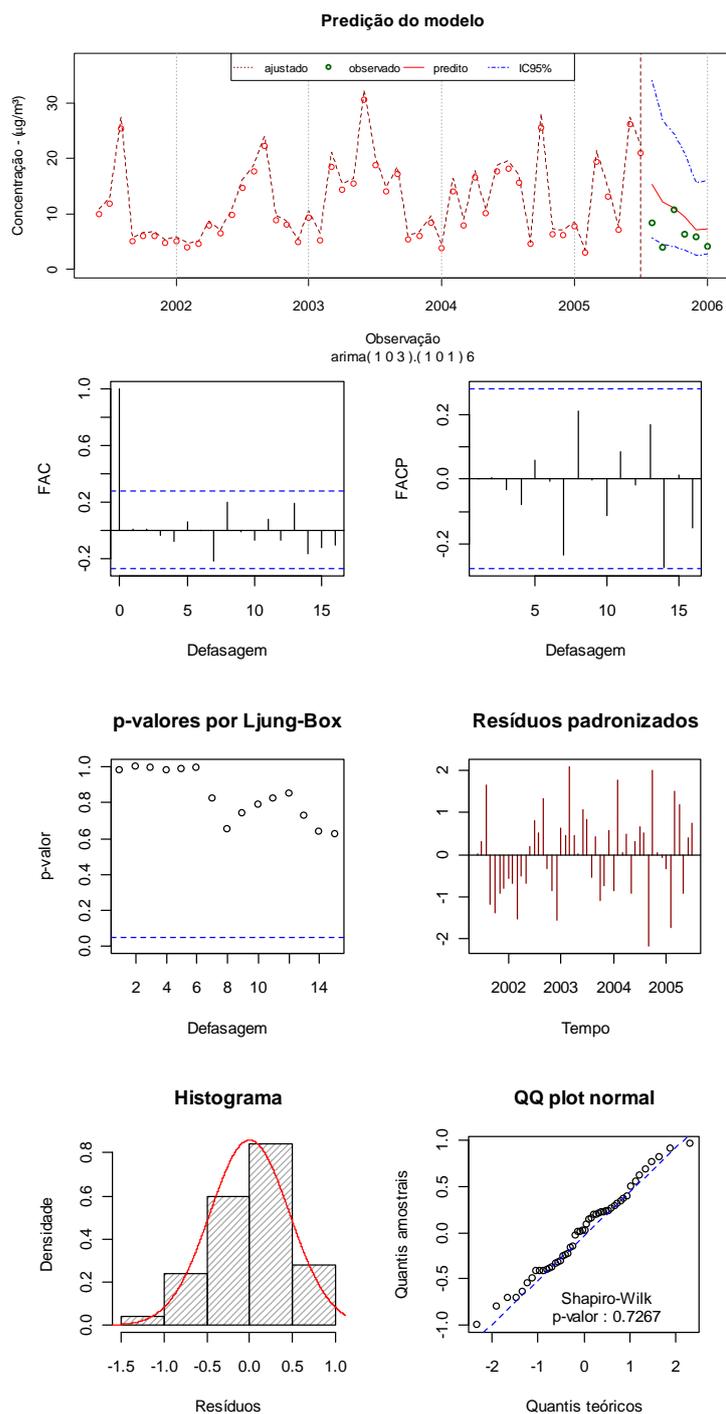
**[8] SARIMA(1 0 3)x(1 0 1) 6**

**Parâmetros:**

ar1	ma1	ma2	ma3	sar1	smal	intercept
0.48562	0.40299	0.03140	0.05090	0.00000	0.02554	0.00000

**Erros:**

MAPE	RMSE	RMSEp
0.7404108	4.795815	1.002859



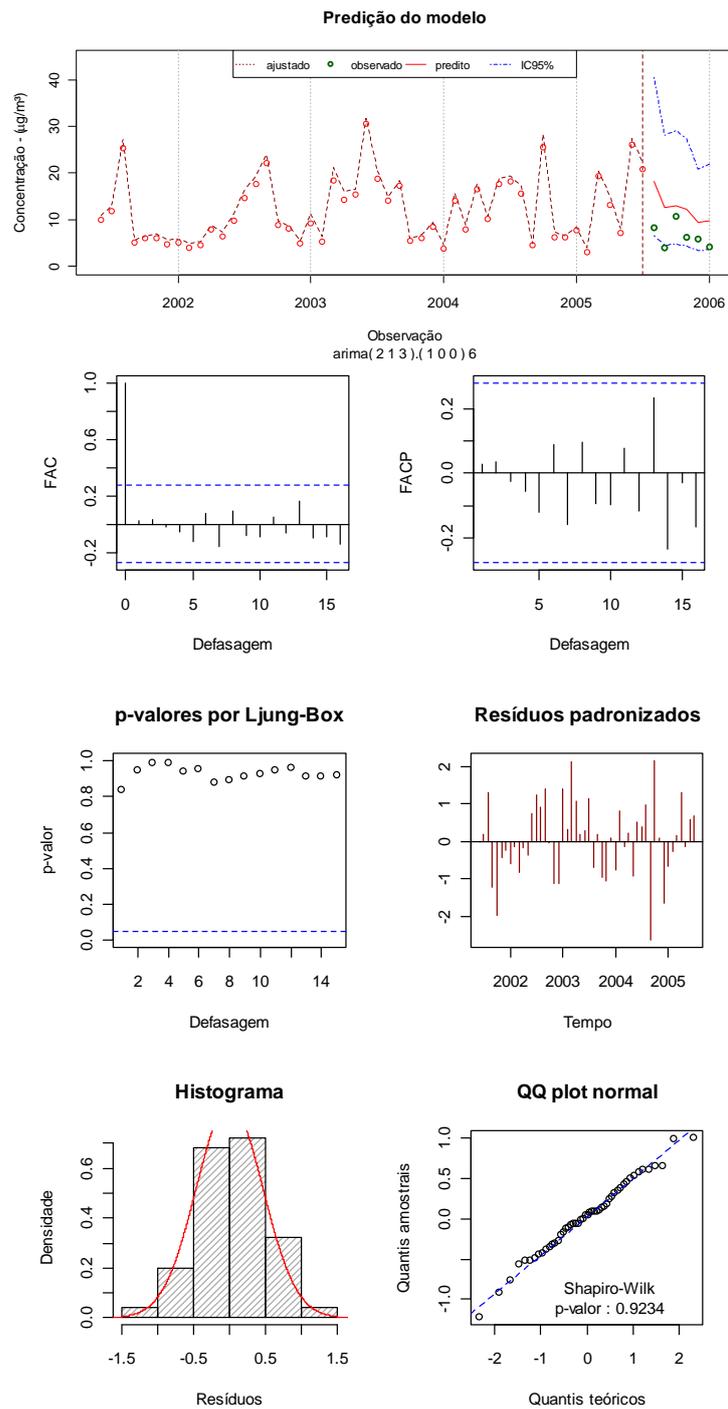
**[9] SARIMA(2 1 3)x(1 0 0) 6**

**Parâmetros:**

ar1 ar2 ma1 ma2 ma3 sar1  
0.00000 0.00000 0.21282 0.00000 0.00002 0.00000

**Erros:**

MAPE RMSE RMSEp  
1.092516 6.549288 1.264341



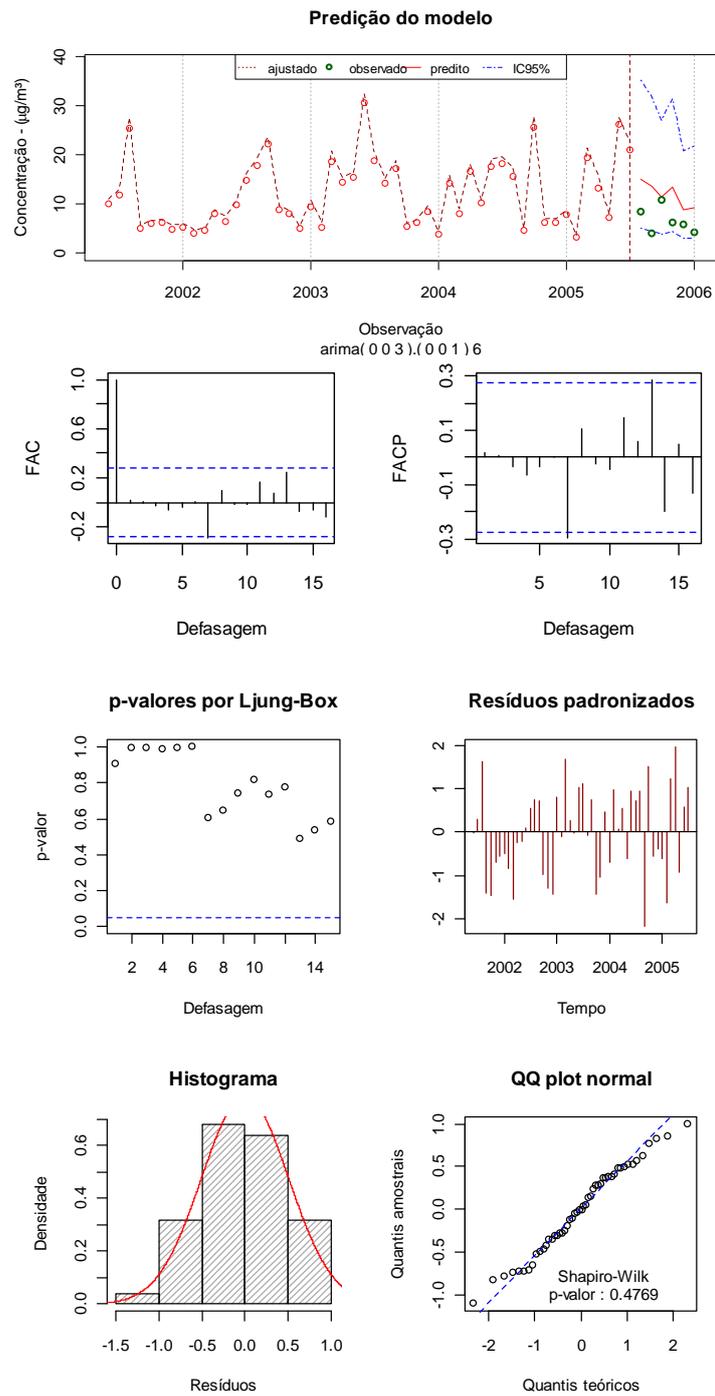
**[10] SARIMA(0 0 3)x(0 0 1) 6**

**Parâmetros:**

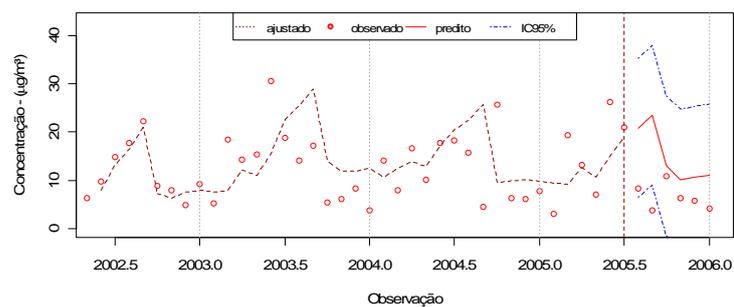
ma1	ma2	ma3	sma1	intercept
0.42787	0.00081	0.00941	0.04255	0.00000

**Erros:**

MAPE	RMSE	RMSEp
1.027831	6.049409	1.274704



## Holt-winters



**Erros:**

MAPE	RMSE	RMSEp
2.387148	15.70378	3.1723

## Anexo 9

### Resultados dos 10 modelos com menor valor de AIC para a série de dados do MP<sub>10-2,5</sub>.

Valores de erros calculados para os 10 modelos com menor valor de AIC para a série de dados do MP<sub>10-2,5</sub>.

Tabela 18 - Comparação dos modelos obtidos com menor AIC para dados da série MP<sub>10-2,5</sub>

	Modelo	AIC	Parâmetros
M1	arima (2,0,2)×(0,0,0) <sub>6</sub>	77,08133	4
M2	arima (2,0,2)×(1,0,0) <sub>6</sub>	78,75297	5
M3	arima (2,0,3)×(0,0,1) <sub>6</sub>	79,03707	6
M4	arima (2,0,2)×(0,0,1) <sub>6</sub>	79,23380	5
M5	arima (2,0,3)×(1,0,0) <sub>6</sub>	79,23550	6
M6	arima (1,0,3)×(0,0,1) <sub>6</sub>	79,68164	5
M7	arima (1,0,0)×(0,0,1) <sub>6</sub>	79,77015	2
M8	arima (1,0,0)×(1,0,0) <sub>6</sub>	79,88796	2
M9	arima (1,0,3)×(1,0,0) <sub>6</sub>	79,89975	5
M10	arima (0,0,1)×(0,0,1) <sub>6</sub>	80,39325	2

Valores dos parâmetros para os 10 modelos com menor valor de AIC para a série de dados do MP<sub>10-2,5</sub>.

Tabela 19 - Análise estatística dos parâmetros dos modelos

Modelo	Parâmetros	Variáveis		
		Valor	Erro padrão	$p < 0,05$
M1	$\phi_1$	1,6499	0,0604	0,00000
	$\phi_2$	-0,9558	0,0646	0,00000
	$\theta_1$	-1,4460	0,1671	0,00000
	$\theta_2$	0,756	0,1762	0,00000
	Intercepto	2,3612	0,0734	0,00000
M2	$\phi_1$	0,1717	0,1603	0,14204
	$\phi_2$	-0,5877	0,1346	0,00001
	$\theta_1$	-0,0133	0,0610	0,41394
	$\theta_2$	1,0000	0,0773	0,00000
	$\Phi_1$	-0,4585	0,1387	0,00047
	Intercepto	2,3794	0,0627	0,00000
M3	$\phi_1$	-0,2697	0,2630	0,15263
	$\phi_2$	-0,4906	0,1630	0,00131
	$\theta_1$	0,6446	0,2837	0,01153
	$\theta_2$	1,0243	0,1300	0,00000
	$\theta_3$	0,6044	0,2746	0,01388
	$\Theta_1$	-0,452	0,148	0,00113
	Intercepto	29,923	0,0692	0,00000
M4	$\phi_1$	0,2469	0,1574	0,05840
	$\phi_2$	-0,5848	0,1373	0,00001
	$\theta_1$	-0,0209	0,0316	0,36736
	$\theta_2$	1,0000	0,1051	0,00000
	$\Theta_1$	-0,4710	0,1499	0,00084
	Intercepto	2,3923	0,0555	0,00000

Continuação da Tabela 19.

M5	$\phi_1$	-0,2479	0,2840	0,19131
	$\phi_2$	-0,5284	0,1578	0,000041
	$\theta_1$	0,5387	0,3181	0,04516
	$\theta_2$	1,0179	0,0931	0,00000
	$\theta_3$	0,5031	0,3026	0,04820
	$\Phi_1$	-0,4256	0,1447	0,00164
	Intercepto	23,785	0,0768	0,00000
M6	$\phi_1$	-0,5312	0,1860	0,00214
	$\theta_1$	1,0120	0,1604	0,00000
	$\theta_2$	0,5824	0,2151	0,00339
	$\theta_3$	0,5705	0,2168	0,00425
	$\Theta_1$	-0,2805	0,1620	0,04168
	Intercepto	2,3804	0,0979	0,00000
M7	$\phi_1$	0,3304	0,1359	0,00752
	$\Theta_1$	-0,3973	0,1527	0,00463
	Intercepto	2,3911	0,0678	0,00000
M8	$\phi_1$	02791	0,1500	0,03139
	$\Phi_1$	-0,3842	0,1516	0,00563
	Intercepto	2,3809	0,0716	0,00000
M9	$\phi_1$	-0,5558	0,1882	0,00157
	$\theta_1$	1,0062	0,1598	0,00000
	$\theta_2$	0,5550	0,2195	0,00572
	$\theta_3$	0,5488	0,2170	0,00571
	$\Phi_1$	-0,2567	0,1551	0,04889
	Intercepto	2,3746	0,1026	0,00000
M10	$\theta_1$	0,3058	0,1358	0,01218
	$\Theta_1$	-0,4416	0,1480	0,00142
	Intercepto	2,3955	0,0565	0,00000

Valores de erros calculados para os 10 modelos com menor valor de AIC para a série de dados do MP<sub>10-2,5</sub>.

Tabela 20 - Valores dos erros calculados para os 10 modelos com menor AIC para dados da série MP<sub>10-2,5</sub>

	MAPE	RMSE	RMSE%
M1	1,825271	5,240481	3,233455
M2	2,408777	6,751750	4,147861
M3	2,673198	7,816016	4,489032
M4	2,759626	7,849844	4,755419
M5	2,356615	6,795829	4,001565
M6	2,710197	7,894061	4,729723
M7	3,003966	8,560346	5,080424
M8	2,730875	7,701727	4,637232
M9	2,571966	7,491315	4,469338
M10	3,202529	9,211370	5,346605

Resultados gerais dos 10 modelos com menor AIC.

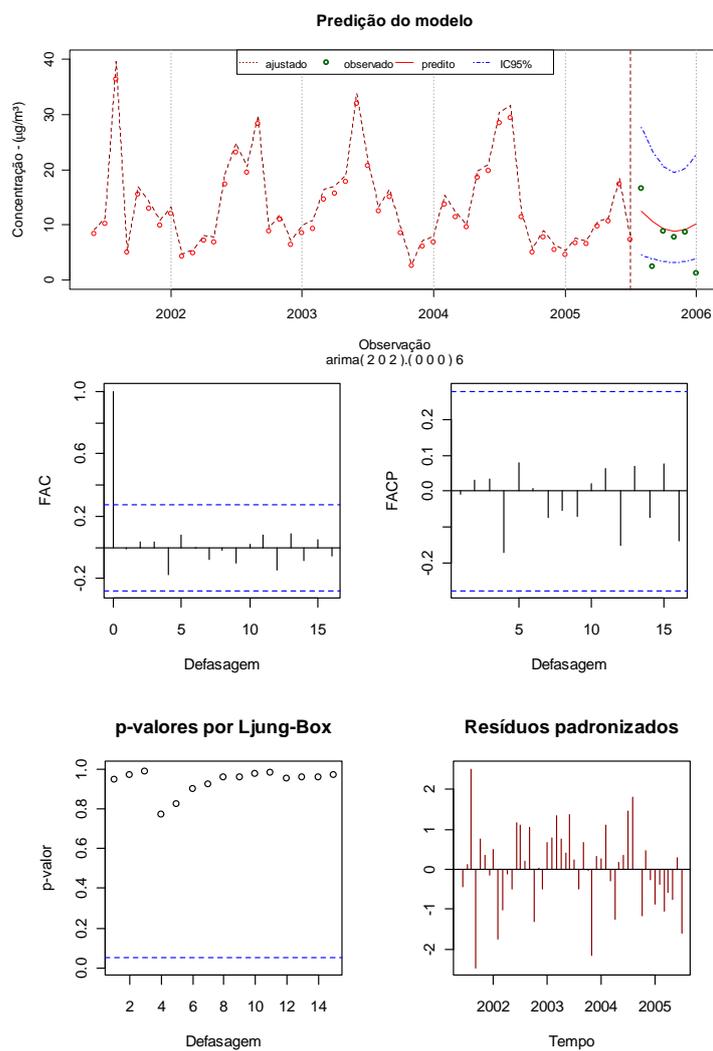
[1] SARIMA (2 0 2)x(0 0 0) 6

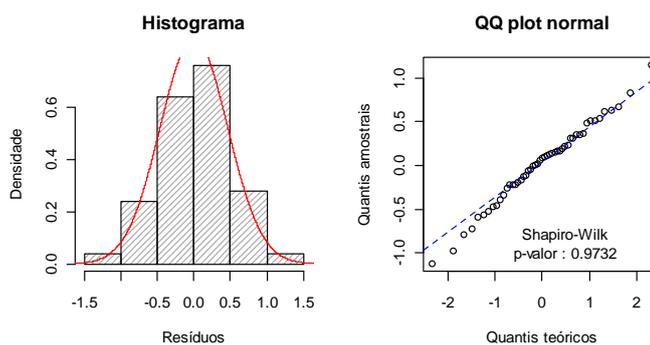
**Parâmetros:**

ar1	ar2	ma1	ma2	intercept
0	0	0	0	0

**Erros:**

MAPE	RMSE	RMSEp
1.825271	5.240481	3.233455





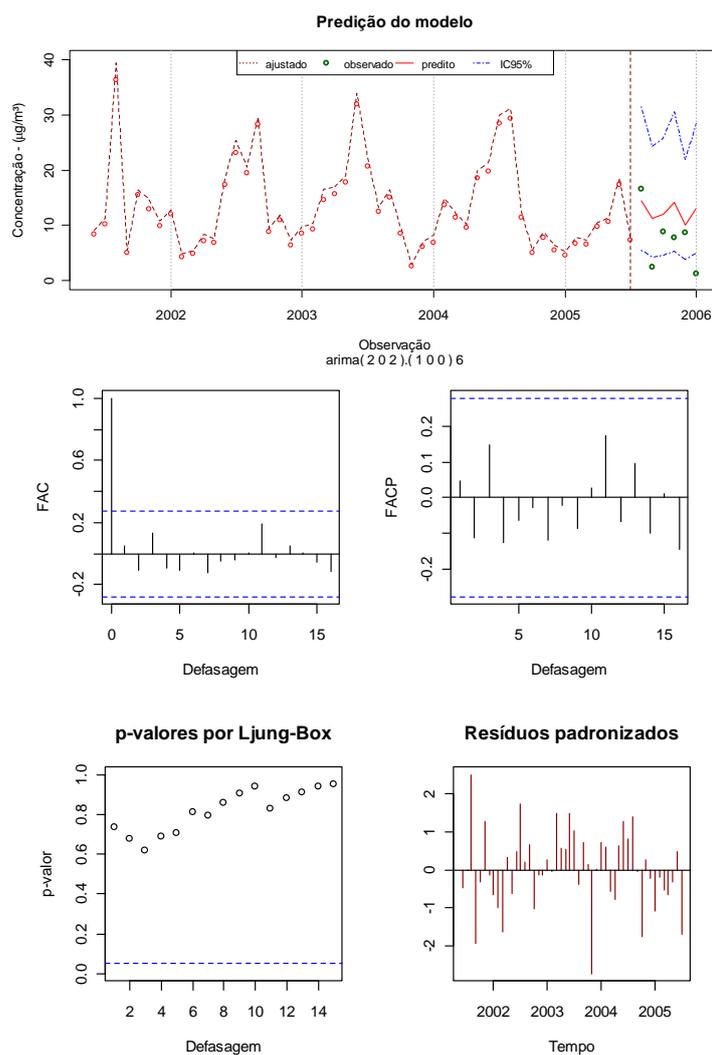
[2] SARIMA (2 0 2)x(1 0 0) 6

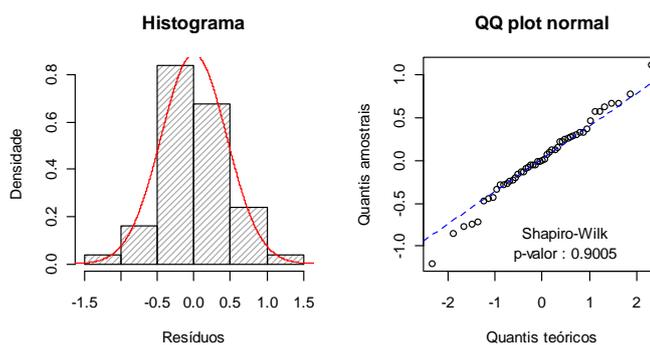
Parâmetros:

ar1	ar2	ma1	ma2	sar1	intercept
0.14204	0.00001	0.41394	0.00000	0.00047	0.00000

Erros:

MAPE	RMSE	RMSEp
2.408777	6.75175	4.147861





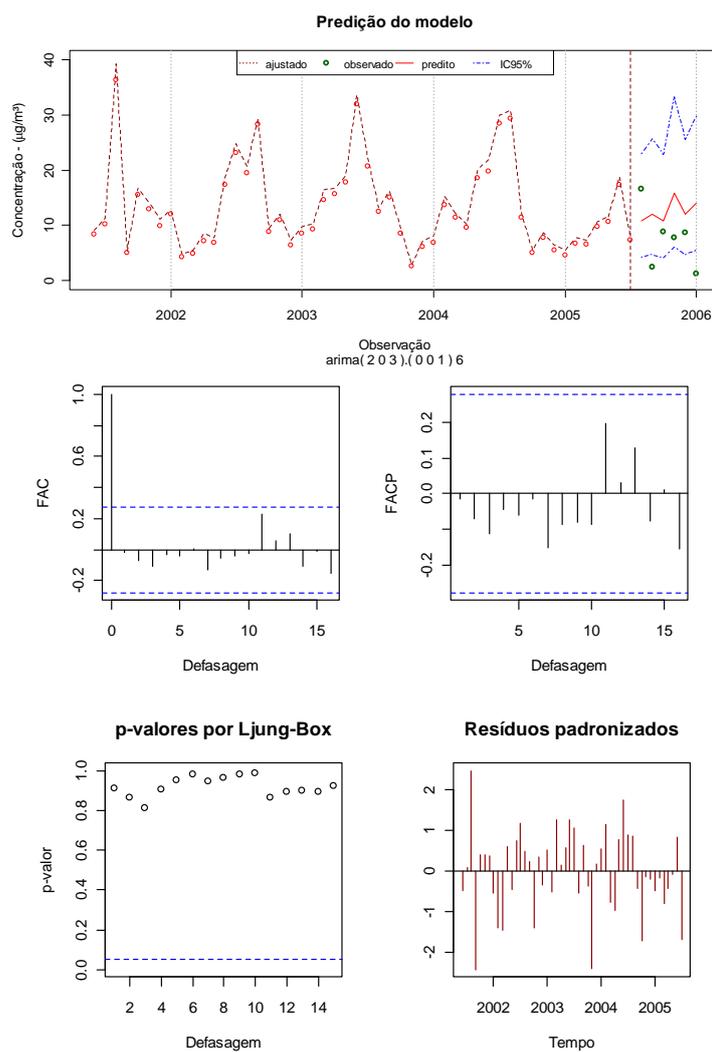
[3] SARIMA (2 0 3)x(0 0 1) 6

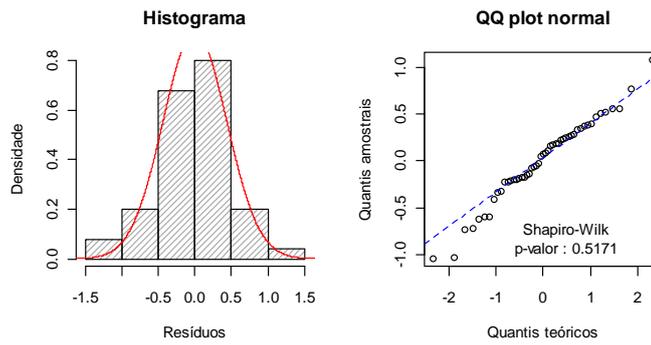
**Parâmetros:**

ar1	ar2	ma1	ma2	ma3	sma1	intercept
0.15263	0.00131	0.01153	0.00000	0.01388	0.00113	0.00000

**Erros:**

MAPE	RMSE	RMSEp
2.673198	7.816016	4.489032





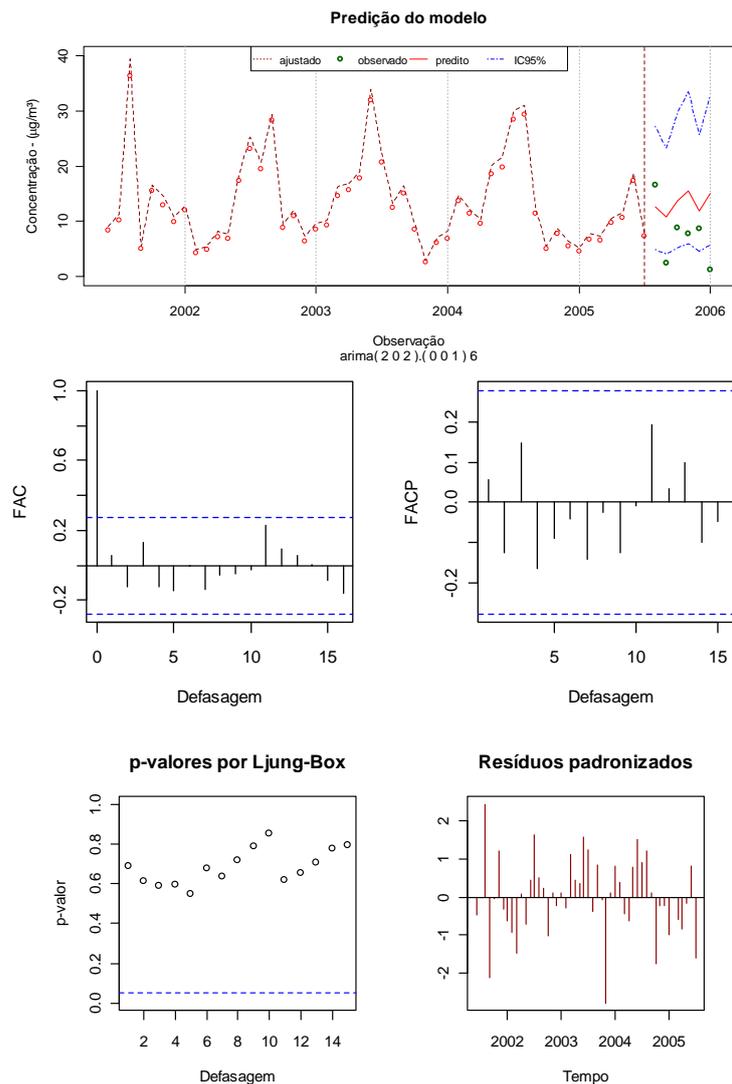
**[4] SARIMA ( 2 0 2 ) x ( 0 0 1 ) 6**

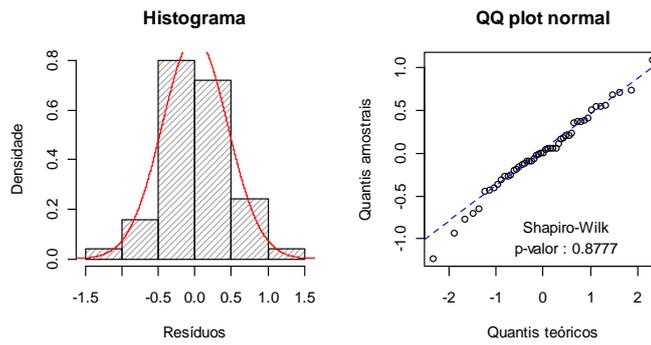
**Parâmetros:**

ar1 ar2 ma1 ma2 sma1 intercept  
0.05840 0.00001 0.36736 0.00000 0.00084 0.00000

**Erros:**

MAPE RMSE RMSEp  
2.759626 7.849844 4.755419





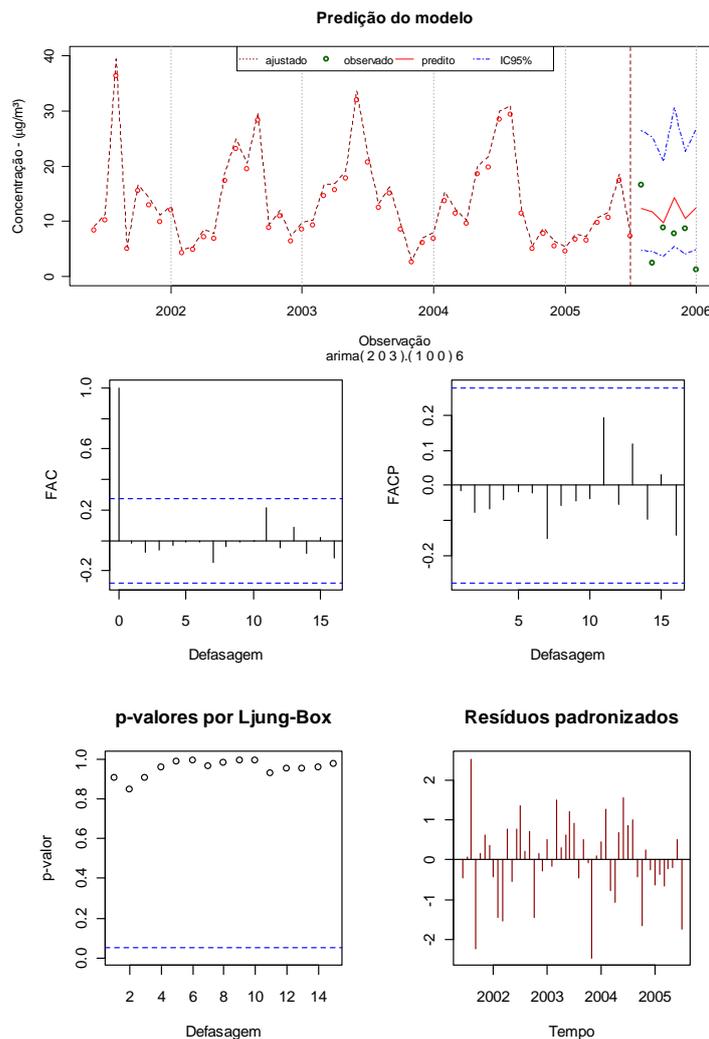
[5] SARIMA (2 0 3)x(1 0 0) 6

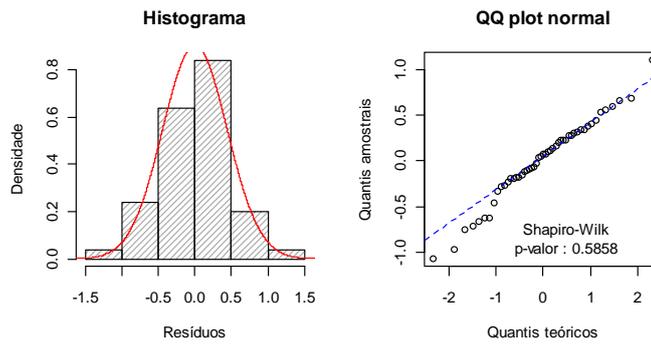
Parâmetros:

ar1 ar2 ma1 ma2 ma3 sar1 intercept  
 0.19131 0.00041 0.04516 0.00000 0.04820 0.00164 0.00000

Erros:

MAPE RMSE RMSEp  
 2.356615 6.795829 4.001565





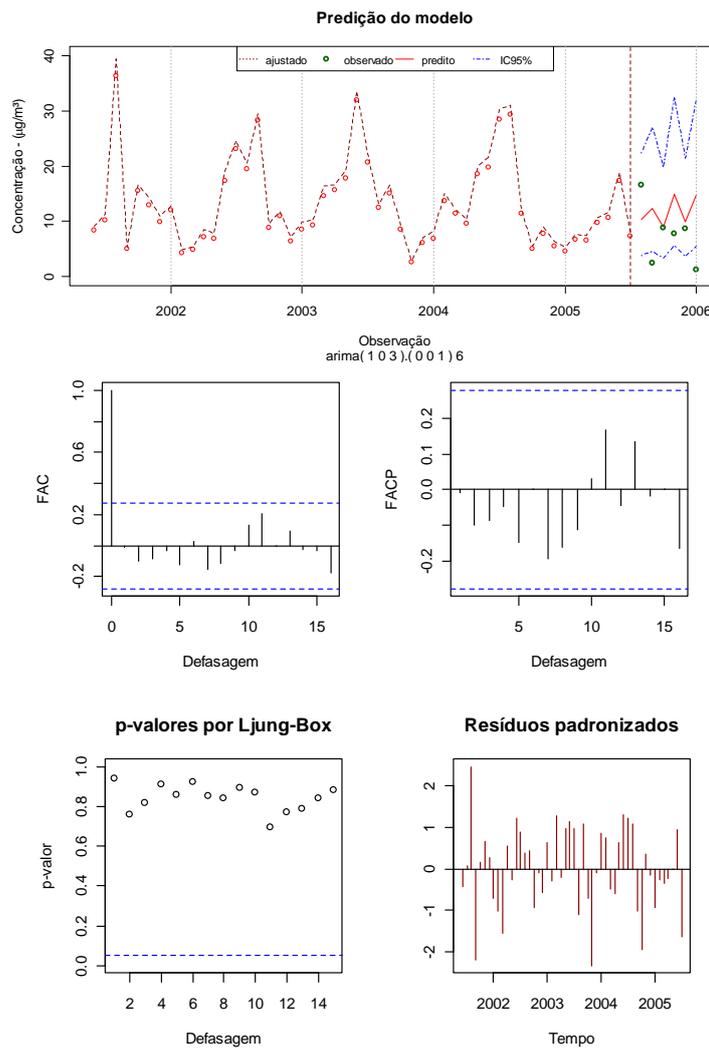
[6] SARIMA (1 0 3)x(0 0 1) 6

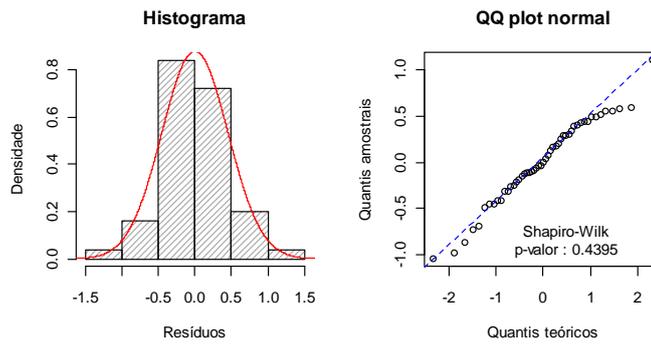
**Parâmetros:**

ar1	ma1	ma2	ma3	sma1	intercept
0.00214	0.00000	0.00339	0.00425	0.04168	0.00000

**Erros:**

MAPE	RMSE	RMSEp
2.710197	7.894061	4.729723





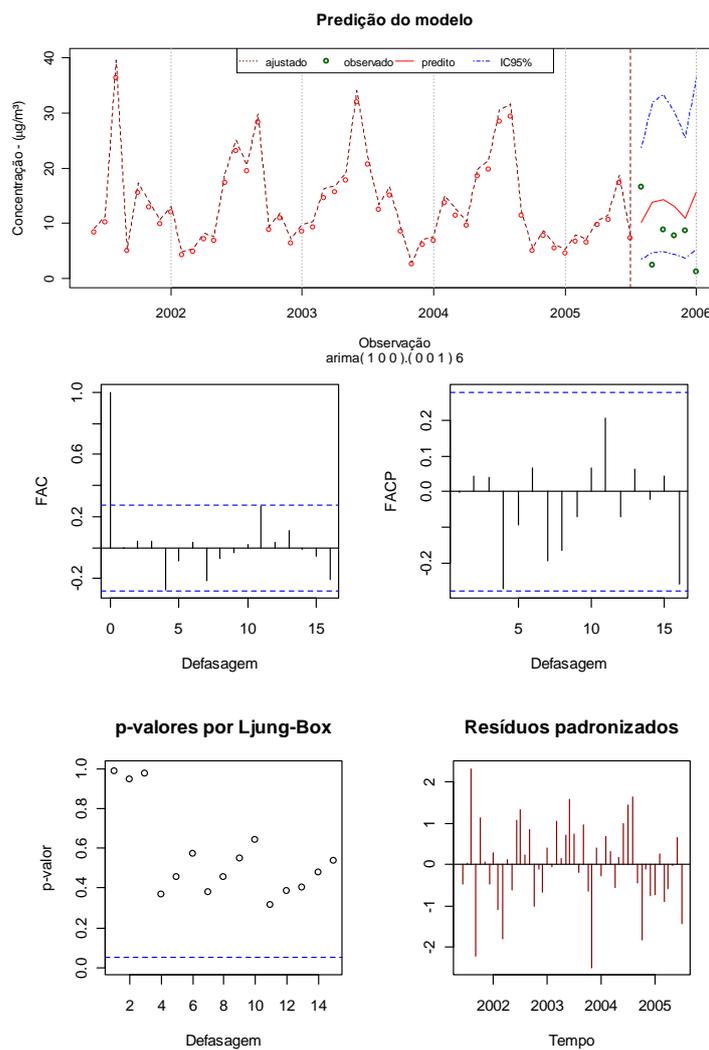
[7] SARIMA (1 0 0)x(0 0 1) 6

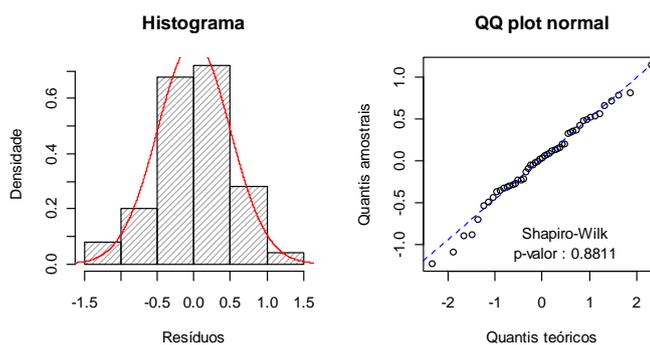
**Parâmetros:**

ar1 sma1 intercept  
0.00752 0.00463 0.00000

**Erros:**

MAPE RMSE RMSEp  
3.003966 8.560346 5.080424





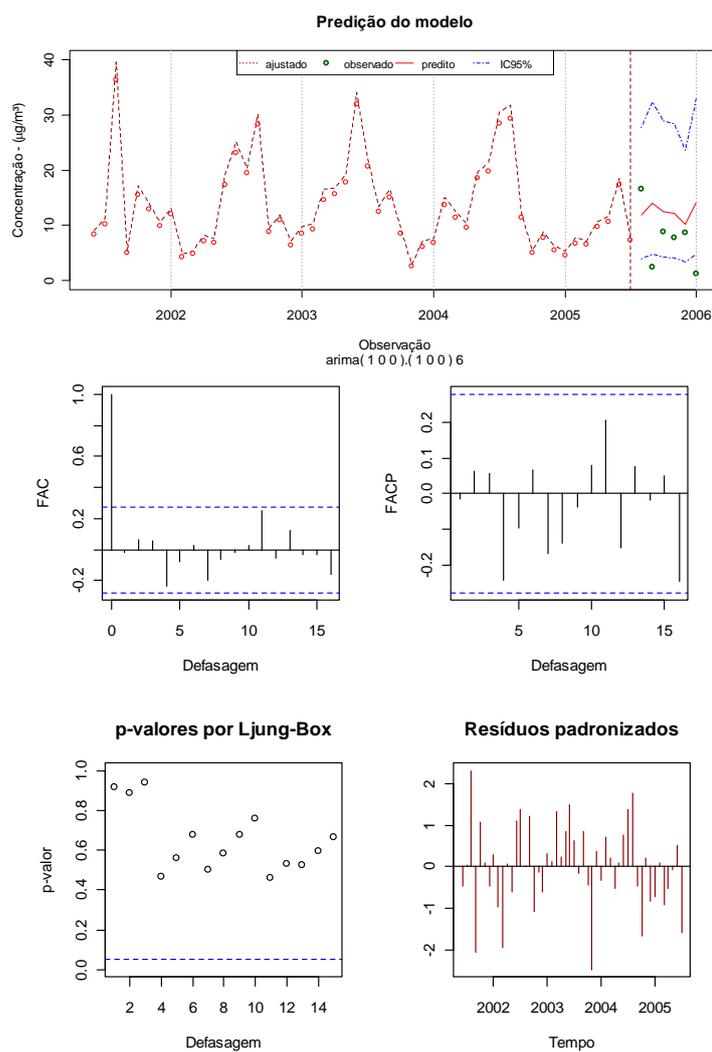
[8] SARIMA (1 0 0)x(1 0 0) 6

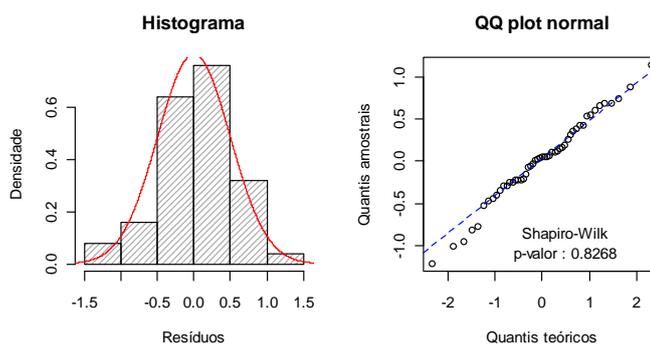
**Parâmetros:**

ar1 sar1 intercept  
0.03139 0.00563 0.00000

**Erros:**

MAPE RMSE RMSEp  
2.730875 7.701727 4.637232





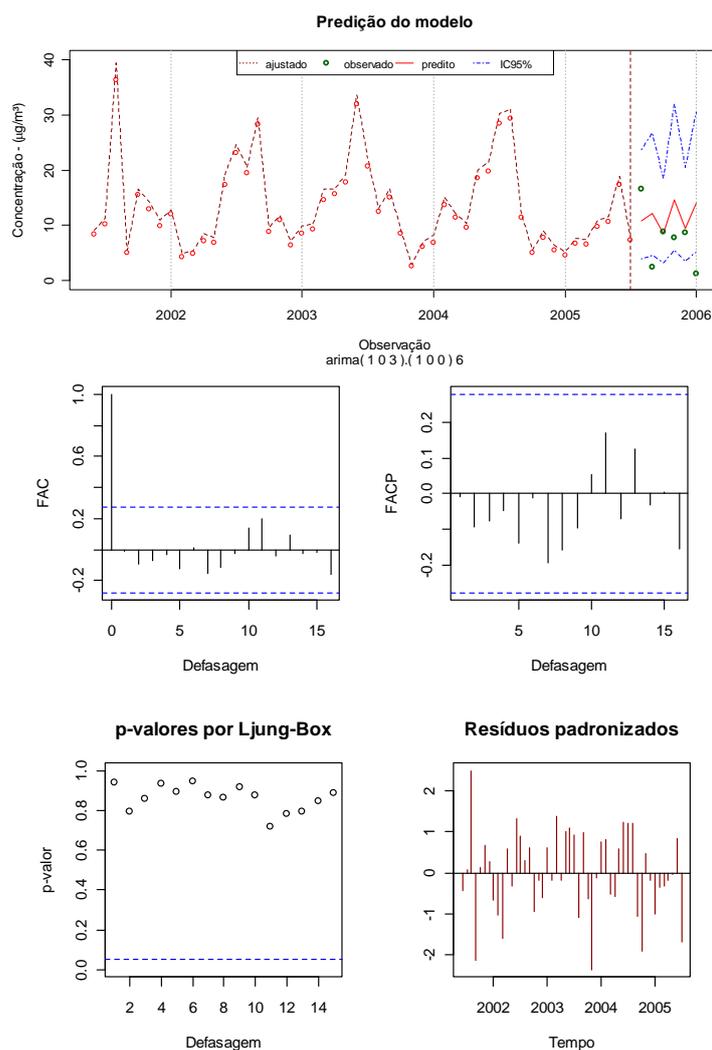
[9] SARIMA (1 0 3)x(1 0 0) 6

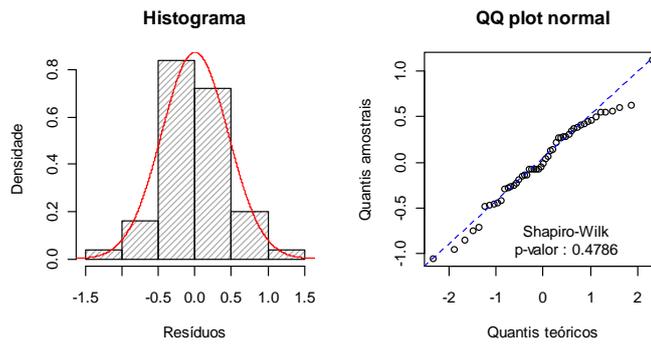
**Parâmetros:**

ar1 ma1 ma2 ma3 sar1 intercept  
 0.00157 0.00000 0.00572 0.00571 0.04889 0.00000

**Erros:**

MAPE RMSE RMSEp  
 2.571966 7.491315 4.469338





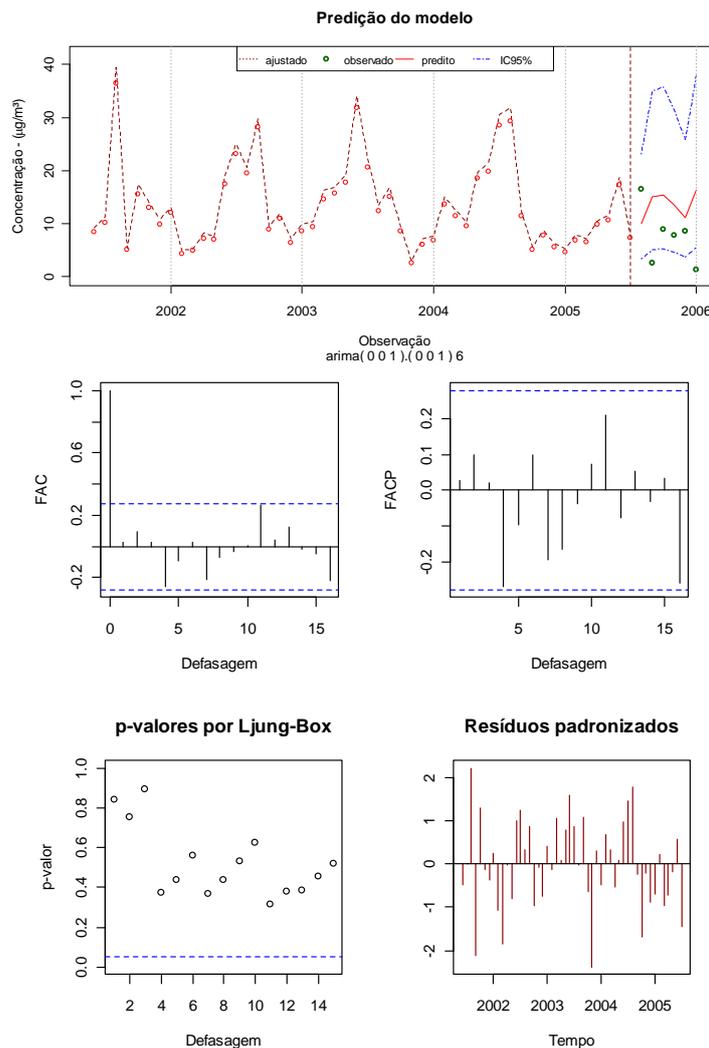
**[10] SARIMA (0 0 1)x(0 0 1) 6**

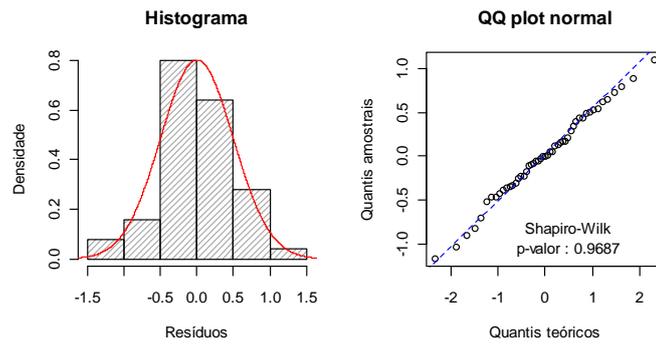
**Parâmetros:**

ma1 sma1 intercept  
0.01218 0.00142 0.00000

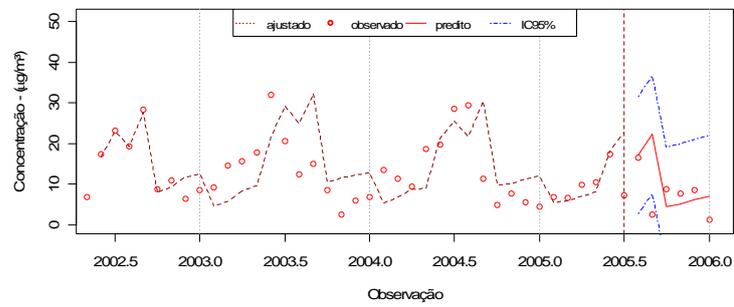
**Erros:**

MAPE RMSE RMSEp  
3.202529 9.21137 5.346605





## Holt-Winters



## Erros:

MAPE	RMSE	RMSEp
3.660241	14.83088	5.926271