



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA QUÍMICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA



Modelagem e Previsão da Qualidade do Ar na Cidade de Uberlândia - MG

Taisa Shimosakai de Lira



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA QUÍMICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA



Modelagem e Previsão da Qualidade do Ar na Cidade de Uberlândia - MG

Taisa Shimosakai de Lira

Tese de Doutorado submetida ao Programa de Pós-Graduação em Engenharia Química da Universidade Federal de Uberlândia como parte dos requisitos necessários para a obtenção do título de Doutor em Engenharia Química.

Prof. Dr. Adilson José de Assis
Orientador

Prof. Dr. Marcos Antônio de Souza Barrozo
Co-orientador

Uberlândia - MG
2009

Dados Internacionais de Catalogação na Publicação (CIP)

L768m Lira, Taisa Shimosakai de, 1979-
Modelagem e previsão da qualidade do ar na cidade de Uberlândia -
MG / Taisa Shimosakai de Lira. - 2009.
152 f. : il.

Orientador: Adilson José de Assis.
Co-orientador: Antônio de Souza Barrozo.

Tese (doutorado) – Universidade Federal de Uberlândia, Programa
de Pós-Graduação em Engenharia Química.
Inclui bibliografia.

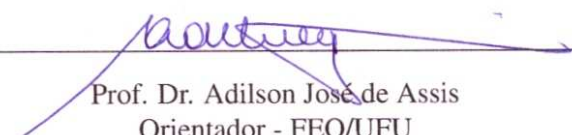
1. Ar - Qualidade - Uberlândia - Teses. 2. Modelos lineares (Estatística) - Teses. 3. Saúde pública - Teses. I. Assis, Adilson José de. II. Barrozo, Marcos Antônio de Souza. III. Universidade Federal de Uberlândia. Programa de Pós-Graduação em Engenharia Química. III. Título.

CDU: 504.064 (815.12 * UDI)

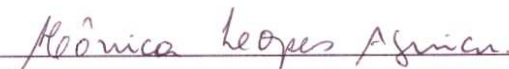
Modelagem e Previsão da Qualidade do Ar na Cidade de Uberlândia - MG

Tese de Doutorado de *Taisa Shimosakai de Lira* submetida ao Programa de Pós-Graduação em Engenharia Química da Universidade Federal de Uberlândia como parte dos requisitos necessários para a obtenção do título de Doutor em Engenharia Química em 02 de março de 2009.


BANCA EXAMINADORA



Prof. Dr. Adilson José de Assis
Orientador - FEQ/UFU



Prof. Dra. Mônica Lopes Aguiar
DEQ/UFSCAR



Prof. Dr. Edson Tomaz
FEQ/UNICAMP



Prof. Dr. Washington Luiz Assunção
IG/UFU



Prof. Dr. Humberto Molinar Henrique
FEQ/UFU

DEDICATÓRIA

Aos meus pais, que me propiciaram uma vida digna onde eu pudesse crescer acreditando que tudo é possível, desde que sejamos honestos, íntegros de caráter e tendo a convicção de que desistir nunca seja uma ação contínua em nossas vidas.

Ao Thiago, por todo apoio, amor e compreensão e pelas muitas horas de atenção e carinho que não pude lhe dedicar.

Aos meus queridos irmãos pelo apoio e carinho oferecidos em todos os momentos de minha vida.

AGRADECIMENTOS

Aos Professores Adilson José de Assis e Marcos Antônio de Souza Barrozo pela valiosa orientação, incentivo, confiança e amizade, essenciais para a concretização deste trabalho.

Aos Professores Washington Luiz Assunção, Humberto Molinar Henrique e Ednaldo Carvalho Guimarães pelos esclarecimentos e sugestões no decorrer deste trabalho.

À Secretaria de Trânsito e Transporte da Prefeitura de Uberlândia, Estação Climatológica da Universidade Federal de Uberlândia e direção do Hospital das Clínicas de Uberlândia pelo fornecimento de dados utilizados neste trabalho.

Ao Euclides Antônio Pereira de Lima pelas instruções e apoio quanto a operação e calibração dos equipamentos.

Aos alunos de iniciação científica pelo suporte nas amostragens.

À todos os professores e funcionários da FEQ/UFU pelo apoio.

À CAPES - Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, pela concessão de bolsa de estudo.

À todos aqueles que de alguma forma contribuíram para a realização deste trabalho.

RESUMO

O expressivo crescimento populacional da cidade de Uberlândia-MG, nas últimas quatro décadas, de forma desordenada e sem planejamento, pode causar sérios problemas na qualidade de vida da população. Um dos pontos mais preocupantes é a qualidade do ar atmosférico. O principal objetivo deste trabalho foi desenvolver modelos empíricos para previsão da concentração de MP_{10} no centro da cidade de Uberlândia-MG. Vários modelos lineares, tais como ARX, ARMAX, erro na saída e Box-Jenkins, bem como modelos baseados em redes neurais foram avaliados. Os modelos usaram variáveis meteorológicas e fluxo de veículos como dados de entrada e, como saída prevista pelo modelo, tem-se a concentração de MP_{10} com horizonte de predição de três dias à frente. Os resultados mostraram que boas estimativas podem ser obtidas, com exceção do modelo linear erro na saída. As melhores estimativas da concentração de MP_{10} foram obtidas pelo modelo linear Box-Jenkins. Os modelos propostos podem ser usados, entre outros propósitos, pelo Governo público local como uma ferramenta para ativar ações de emergência durante períodos de estagnação atmosférica, quando os níveis de MP_{10} na atmosfera possam representar risco à saúde pública. Também foi objetivo deste trabalho verificar a relação existente entre a concentração de MP_{10} e doenças respiratórias em Uberlândia. Entretanto, com as metodologias utilizadas e os dados disponíveis, não foi possível confirmar essa relação.

Palavras-chave: *qualidade do ar; modelos lineares; redes neurais; material particulado; saúde pública.*

ABSTRACT

The expressive population growth of the Uberlândia city, in the last four decades, in a disordered way and without planning, has caused serious problems in population life quality. One of the most concerning points it is the atmospheric air quality. The main aim of this work was to develop empiric models to predict the PM_{10} concentration in downtown of Uberlândia-MG. Several linear models, such as AARX, ARMAX, output error and Box-Jenkins, as well as models based on neural networks were evaluated. The models used meteorological variables and vehicles flow as input data. As output predicted by the models, the PM_{10} concentration is obtained with 3-day horizon. The results showed that good estimates can be obtained by the models, unless for the output-error model. The best estimates of the PM_{10} concentration were obtained by the Box-Jenkins linear model. The proposed models can be used, among other purposes, for the local public government, as a tool to activate emergency actions during periods of atmospheric stagnation, when PM_{10} levels in atmosphere can represent risk to public health. The aim of this work was also to verify the relationship between the $PM_{(10)}$ concentration and respiratory diseases in Uberlândia. However, with methodologies used and available data, it was not possible to confirm this relationship.

Keywords: *air quality; linear models; neural networks; particulate matter; public health.*

LISTA DE FIGURAS

1.1	Evolução da população de Uberlândia-MG.	1
2.1	Camadas da atmosfera segundo o critério de temperatura média do ar.	6
2.2	Emissões relativas de poluentes por tipo de fonte na RMSP em 2006.	11
2.3	Esquema de uma distribuição granulométrica típica para o material particulado.	28
3.1	Amostradores de grandes volumes: AGV-MP ₁₀ à esquerda e AGV-PTS à direita.	34
3.2	Localização da estação de monitoramento de MP.	35
3.3	Esquema do AGV - MP ₁₀	36
3.4	Detalhes do cabeçote desmontado: (a) cobertura contra chuva e tela contra insetos, (b) parte inferior da câmara de impactação (dezesseis bocais de saída), (c) placa de impactação e (d) entrada da câmara de impactação (nove bocais aceleradores).	37
4.1	Modelo de um neurônio artificial.	43
4.2	Modelo baseado em um <i>perceptron</i> multicamadas.	46
4.3	Fluxo de processamento do algoritmo <i>backpropagation</i>	47
4.4	Exemplo de mínimos locais e platôs em uma superfície de erro.	50
4.5	Influência do termo <i>momentum</i>	50
5.1	Localização da Estação Climatológica da Universidade Federal de Uberlândia.	57
5.2	Temperatura média mensal: (a) 2003, (b) 2004, (c) 2005, (d) 2006 e (e) 2007.	58
5.3	Precipitação média mensal: (a) 2003, (b) 2004, (c) 2005, (d) 2006 e (e) 2007.	59
5.4	Umidade relativa média mensal: (a) 2003, (b) 2004, (c) 2005, (d) 2006 e (e) 2007.	60
5.5	Nebulosidade média mensal: (a) 2003, (b) 2004, (c) 2005, (d) 2006 e (e) 2007.	61

5.6	Insolação média mensal: (a) 2003, (b) 2004, (c) 2005, (d) 2006 e (e) 2007.	62
5.7	Velocidade e direção do vento média mensal: (a) 2003, (b) 2004, (c) 2005, (d) 2006 e (e) 2007.	63
5.8	Fluxo médio mensal de veículos: (a) 2003, (b) 2004, (c) 2005, (d) 2006 e (e) 2007. . .	64
5.9	Fluxo médio de veículos por dia da semana: (a) 2003, (b) 2004, (c) 2005, (d) 2006 e (e) 2007.	65
5.10	<i>Box-plots</i> da concentração de MP_{10} de 2003 a 2007.	66
5.11	Concentração média diária de MP_{10} de 2003 a 2007.	67
5.12	Concentração média de MP_{10} por dia da semana: (a) 2003, (b) 2004, (c) 2005, (d) 2006 e (e) 2007.	68
5.13	Dispersão da concentração de MP_{10} em função de variáveis meteorológicas e de fluxo de veículos.	71
5.14	Modelo preliminar utilizando redes neurais: (a) concentrações de MP_{10} observada e predita na fase de validação e (b) simulação um passo à frente (linha) e valores observados (pontos).	73
5.15	Concentrações de MP_{10} observadas e previstas na fase de validação: (a) ARX, (b) ARMAX, (c) OE, (d) BJ e (e) RNA.	76
5.16	Histogramas dos erros de previsão da concentração de MP_{10} na fase de validação: (a) ARX, (b) ARMAX, (c) OE, (d) BJ, and (e) RNA.	77
5.17	Simulação um passo à frente (linha) e valores observados (pontos): (a) ARX, (b) ARMAX, (c) OE, (d) BJ, and (e) RNA.	78
5.18	Concentrações de MP_{10} observadas e previstas na fase de validação: (a) Scilab e (b) Matlab.	80
5.19	Simulação um passo à frente (linha) e valores observados (pontos): (a) Scilab e (b) Matlab.	81
5.20	Modelo Box-Jenkins (prestd + pca): (a) valores observados e preditos, (b) histograma dos resíduos e (c) simulação um passo à frente (linha) e valores observados (pontos). .	83
5.21	Modelo Box-Jenkins (prestd + pca): (a), (b), (c), (d) e (e) funções de correlações cruzada entre o vetor de resíduos e as variáveis de entrada; (f) função de autocorrelação do vetor de resíduos.	85

5.22	Comparação do número total mensal de internações por doenças respiratórias e concentrações médias mensais de MP_{10} para crianças menores de quatro anos, em relação aos anos de (a) 2003, (b) 2004, (c) 2005 e (d) 2006.	88
5.23	Comparação do número total mensal de internações por doenças respiratórias e concentrações médias mensais de MP_{10} para idosos maiores de 70 anos, em relação aos anos de (a) 2003, (b) 2004, (c) 2005 e (d) 2006.	89
5.24	Dispersão da concentração de MP_{10} em função das classes da CID-10 (de 165 a 172) para doenças do aparelho respiratório.	92
5.25	Dispersão da concentração de MP_{10} em função das classes da CID-10 (de 173 a 179, com exceção de 178) para doenças do aparelho respiratório.	93
B.1	Simulações de modelos preliminares utilizando redes neurais com 4 neurônios.	112
B.2	Simulações de modelos preliminares utilizando redes neurais com 5 neurônios.	113
B.3	Simulações de modelos preliminares utilizando redes neurais com 6 neurônios.	114
B.4	Seleção da ordem do modelo ARX utilizando dados normalizados no intervalo [-1; 1].	115
B.5	Simulações do modelo ARX [1, 1, 1] utilizando dados normalizados no intervalo [-1; 1].	116
B.6	Funções de autocorrelação e correlação cruzada do modelo ARX [1, 1, 1] utilizando dados normalizados no intervalo [-1; 1].	117
B.7	Seleção da ordem do modelo ARX utilizando dados normalizados com média = 0 e variância = 1.	118
B.8	Simulações do modelo ARX [1, 1, 1] utilizando dados normalizados com média = 0 e variância = 1.	119
B.9	Funções de autocorrelação e correlação cruzada do modelo ARX [1, 1, 1] utilizando dados normalizados com média = 0 e variância = 1.	120
B.10	Seleção da ordem do modelo ARX utilizando dados normalizados com média = 0 e variância = 1 e análise de componentes principais.	121
B.11	Simulações do modelo ARX [1, 1, 1] utilizando dados normalizados com média = 0 e variância = 1 e análise de componentes principais.	122
B.12	Funções de autocorrelação e correlação cruzada do modelo ARX [1, 1, 1] utilizando dados normalizados com média = 0 e variância = 1 e análise de componentes principais.	123
B.13	Seleção da ordem do modelo ARMAX utilizando dados normalizados no intervalo [-1; 1].	124

B.14 Simulações do modelo ARMAX [1, 1, 1, 1] utilizando dados normalizados no intervalo [-1; 1].	125
B.15 Funções de autocorrelação e correlação cruzada do modelo ARMAX [1, 1, 1, 1] utilizando dados normalizados no intervalo [-1; 1].	126
B.16 Seleção da ordem do modelo ARMAX utilizando dados normalizados com média = 0 e variância = 1.	127
B.17 Simulações do modelo ARMAX [6, 1, 1, 1] utilizando dados normalizados com média = 0 e variância = 1.	128
B.18 Funções de autocorrelação e correlação cruzada do modelo ARMAX [6, 1, 1, 1] utilizando dados normalizados com média = 0 e variância = 1.	129
B.19 Seleção da ordem dos modelos: modelo ARMAX utilizando dados normalizados com média = 0 e variância = 1 e análise de componentes principais.	130
B.20 Simulações do modelo ARMAX [1, 1, 1, 1] utilizando dados normalizados com média = 0 e variância = 1 e análise de componentes principais.	131
B.21 Funções de autocorrelação e correlação cruzada do modelo ARMAX [1, 1, 1, 1] utilizando dados normalizados com média = 0 e variância = 1 e análise de componentes principais.	132
B.22 Seleção da ordem do modelo OE utilizando dados normalizados no intervalo [-1; 1]. . .	133
B.23 Simulações do modelo OE [1, 1, 1] utilizando dados normalizados no intervalo [-1; 1].	134
B.24 Funções de autocorrelação e correlação cruzada do modelo OE [1, 1, 1] utilizando dados normalizados no intervalo [-1; 1].	135
B.25 Seleção da ordem do modelo OE utilizando dados normalizados com média = 0 e variância = 1.	136
B.26 Simulações do modelo OE [1, 1, 1] utilizando dados normalizados com média = 0 e variância = 1.	137
B.27 Funções de autocorrelação e correlação cruzada do modelo OE [1, 1, 1] utilizando dados normalizados com média = 0 e variância = 1.	138
B.28 Seleção da ordem do modelo OE utilizando dados normalizados com média = 0 e variância = 1 e análise de componentes principais.	139
B.29 Simulações do modelo OE [1, 1, 1] utilizando dados normalizados com média = 0 e variância = 1 e análise de componentes principais.	140

B.30 Funções de autocorrelação e correlação cruzada do modelo OE [1, 1, 1] utilizando dados normalizados com média = 0 e variância = 1 e análise de componentes principais.	141
B.31 Seleção da ordem do modelo BJ utilizando dados normalizados no intervalo [-1; 1]. . .	142
B.32 Simulações do modelo BJ [1, 1, 1, 1, 1] utilizando dados normalizados no intervalo [-1; 1].	143
B.33 Funções de autocorrelação e correlação cruzada do modelo BJ [1, 1, 1, 1, 1] utilizando dados normalizados no intervalo [-1; 1].	144
B.34 Seleção da ordem do modelo BJ utilizando dados normalizados com média = 0 e variância = 1.	145
B.35 Simulações do modelo BJ [1, 6, 5, 1, 1] utilizando dados normalizados com média = 0 e variância = 1.	146
B.36 Funções de autocorrelação e correlação cruzada do modelo BJ [1, 6, 5, 1, 1] utilizando dados normalizados com média = 0 e variância = 1.	147
B.37 Seleção da ordem do modelo BJ utilizando dados normalizados com média = 0 e variância = 1 e análise de componentes principais.	148
B.38 Dispersão das classes da CID-10 (de 165 a 172) em função da temperatura.	149
B.39 Dispersão das classes da CID-10 (de 173 a 179, com exceção de 178) em função da temperatura.	150
B.40 Dispersão das classes da CID-10 (de 165 a 172) em função da umidade relativa. . . .	151
B.41 Dispersão das classes da CID-10 (de 173 a 179, com exceção de 178) em função da umidade relativa.	152

LISTA DE TABELAS

2.1	Comparação do ar puro e da atmosfera poluída.	8
2.2	Contribuição relativa das fontes de poluição do ar na RMSP em 2006.	11
2.3	Classes de estabilidade atmosférica de Pasquill-Gifford.	13
2.4	Padrões nacionais de qualidade do ar.	23
2.5	Critérios para episódios críticos de poluição do ar.	24
2.6	Padrões de qualidade do ar adotados pela US-EPA.	24
2.7	Valores de referência recomendados pela OMS.	25
2.8	Estrutura do índice de qualidade do ar utilizado pela CETESB.	26
2.9	Efeitos sobre a saúde associados aos índices de qualidade do ar utilizado pela CETESB.	26
3.1	Vantagens e desvantagens dos equipamentos de medição da poluição do ar.	32
4.1	Funções de ativação.	45
5.1	Coeficientes de correlação de Pearson com os respectivos p-valores para os dados utilizados nos modelos de previsão.	69
5.2	Indicadores de desempenho para RNA e modelos lineares.	74
5.3	Indicadores de desempenho das RNAs em Scilab e em Matlab.	79
5.4	Indicadores de desempenho para os modelos lineares.	82
5.5	Distribuição das internações hospitalares e respectivos coeficientes de prevalência por doenças respiratórias na rede pública, da população residente em Uberlândia-MG, por faixa etária, em 2003.	86

5.6	Distribuição das internações hospitalares e respectivos coeficientes de prevalência por doenças respiratórias na rede pública, da população residente em Uberlândia-MG, por faixa etária, em 2004.	86
5.7	Distribuição das internações hospitalares e respectivos coeficientes de prevalência por doenças respiratórias na rede pública, da população residente em Uberlândia-MG, por faixa etária, em 2005.	87
5.8	Distribuição das internações hospitalares e respectivos coeficientes de prevalência por doenças respiratórias na rede pública, da população residente em Uberlândia-MG, por faixa etária, em 2006.	87
5.9	Lista de doenças do aparelho respiratório segundo a décima Revisão da Classificação Internacional de Doenças (CID-10).	90
5.10	Coeficientes de correlação de Pearson com os respectivos p-valores para os dados de atendimentos por doenças do aparelho respiratório.	90
A.1	Temperatura (°C): médias mensais e anuais de 2003 a 2007.	106
A.2	Precipitação (mm): médias mensais e totais anuais de 2003 a 2007.	106
A.3	Umidade relativa (%): médias mensais e anuais de 2003 a 2007.	107
A.4	Nebulosidade (%): médias mensais e anuais de 2003 a 2007.	107
A.5	Insolação (horas): médias mensais e totais anuais de 2003 a 2007.	108
A.6	Velocidade (m/s) e direção (graus, 0 para N) do vento: médias mensais e anuais de 2003 a 2007.	108
A.7	Fluxo de veículos: médias mensais e anuais de 2003 a 2007.	109
A.8	Fluxo de veículos: médias por dia da semana de 2003 a 2007.	109
A.9	Concentração de MP ₁₀ (μg/m ³): médias por dia da semana de 2003 a 2007.	110
A.10	Concentração de MP ₁₀ (μg/m ³): médias mensais e anuais de 2003 a 2007.	110

LISTA DE ABREVIATURAS E SIGLAS

ABNT - Associação Brasileira de Normas Técnicas

AGV - Amostradores de grande volume

AIC - Critério de informação de Akaike

ARMAX - Modelo auto-regressivo com média móvel e entradas exógenas

ARX - Modelo auto-regressivo com entradas exógenas

BIC - Critério de informação de Bayes

BJ - Modelo Box-Jenkins

CETESB - Companhia de Tecnologia de Saneamento Ambiental

CFCs - Clorofluorcarbonos

CH₄ - Metano

CO - Monóxido de carbono

CONAMA - Conselho Nacional de Meio Ambiente

FPE - Erro final de predição

GEE - Gases do efeito estufa

H₂S - Sulfeto de hidrogênio

H₂SO₄ - Ácido sulfúrico

HC - Hidrocarbonetos

HNO₃ - Ácido nítrico

IBAMA - Instituto Brasileiro de Meio Ambiente

N₂O - Óxido nitroso

MLP - Multilayer perceptron

MP - Material particulado

MP₁₀ - Material particulado com diâmetro menor que 10 μm

MP_{2,5} - Material particulado com diâmetro menor que 2,5 μm

NO₂ - Dióxido de nitrogênio

NO_x - Óxidos de nitrogênio

O₃ - Ozônio

O₂ - Oxigênio molecular

OE - Modelo erro na saída

PAN - Nitrato de peroxiacetil

Pb - Chumbo

PTS - Partículas totais em suspensão

RMSP - Região Metropolitana de São Paulo

RNA - Redes neurais artificiais

SO₂ - Dióxido de enxofre

SO_x - Óxidos de enxofre

US-EPA - United States - Environmental Protection Agency

WHO - World Health Organization

SUMÁRIO

Resumo	xi
Abstract	xii
Lista de Figuras	xv
Lista de Tabelas	xxi
Lista de Abreviaturas e Siglas	xxiii
Sumário	xxv
1 Introdução	1
2 Poluição atmosférica e meio ambiente	5
2.1 Introdução	5
2.2 Atmosfera terrestre	6
2.3 Fontes de poluição atmosférica	8
2.4 Dispersão e remoção de poluentes na atmosfera	10
2.4.1 Dispersão de poluentes	10
2.4.2 Remoção de poluentes	14
2.5 Efeitos da poluição atmosférica	14
2.5.1 Efeitos sobre as plantas	15
2.5.2 Efeitos sobre os materiais	16
2.5.3 Efeitos sobre o meio ambiente	16

2.5.4	Efeitos sobre a saúde humana	18
2.6	Padrões e índice de qualidade do ar	22
2.7	Material Particulado	27
2.7.1	Classificação	27
2.7.2	Tamanho da partícula	27
2.7.3	Composição química	29
3	Monitoramento da qualidade do ar	31
3.1	Introdução	31
3.2	Equipamentos de medição de poluentes	31
3.3	Monitoramento da qualidade do ar em Uberlândia	33
3.3.1	Local do monitoramento	33
3.3.2	Equipamento de amostragem	34
3.3.3	Operação de amostragem	37
3.3.4	Cálculo da concentração de MP ₁₀	38
4	Modelagem matemática da qualidade do ar	41
4.1	Introdução	41
4.2	Redes neurais artificiais	42
4.2.1	Neurônio artificial	43
4.2.2	Funções de ativação	44
4.2.3	Rede <i>perceptron</i> multicamadas	45
4.2.4	Algoritmo <i>backpropagation</i>	47
4.2.5	Processamento temporal	51
4.3	Modelos lineares	51
4.4	Indicadores de desempenho	53
4.4.1	Seleção da estrutura dos modelos	53
4.4.2	Desempenho dos modelos	53
5	Resultados e discussão	55
5.1	Caracterização geral das variáveis dos modelos	55
5.1.1	Variáveis meteorológicas	55
5.1.2	Fluxo de veículos	64

5.1.3	Concentração de MP_{10}	66
5.1.4	Análises de correlação entre as variáveis	68
5.2	Previsão da qualidade do ar	70
5.2.1	Estudo preliminar utilizando redes neurais	70
5.2.2	Redes neurais e modelos lineares: comparação	73
5.2.3	Redes neurais em Scilab	75
5.2.4	Modelos lineares: de 2003 a 2007	80
5.3	Relação entre MP_{10} e doenças respiratórias	84
5.3.1	Dados mensais por faixa etária	84
5.3.2	Dados diários por tipo de doença	89
6	Conclusões e sugestões para trabalhos futuros	95
6.1	Conclusões	95
6.2	Sugestões para trabalhos futuros	97
	Referências Bibliográficas	99
A	Tabelas	105
A.1	Dados meteorológicos	106
A.2	Dados de fluxo de veículos	109
A.3	Dados de concentração de MP_{10}	110
B	Gráficos	111
B.1	Simulações de modelos preliminares utilizando redes neurais	112
B.2	Seleção da estrutura e simulações dos modelos lineares	115
B.3	Dispersão das classes da CID-10 em função da temperatura e da umidade relativa .	149

INTRODUÇÃO

A partir de 1970, Uberlândia teve um intenso e contínuo crescimento populacional, passando de 126.112 habitantes para 608.369 habitantes em 2007, como mostra a Figura 1.1. Atualmente Uberlândia é a terceira cidade de Minas Gerais em população, atrás apenas de Belo Horizonte e Contagem. O expressivo crescimento populacional de Uberlândia, de forma desordenada e sem planejamento, pode causar sérios problemas na qualidade de vida da população. Um dos pontos mais preocupantes é a qualidade do ar atmosférico.

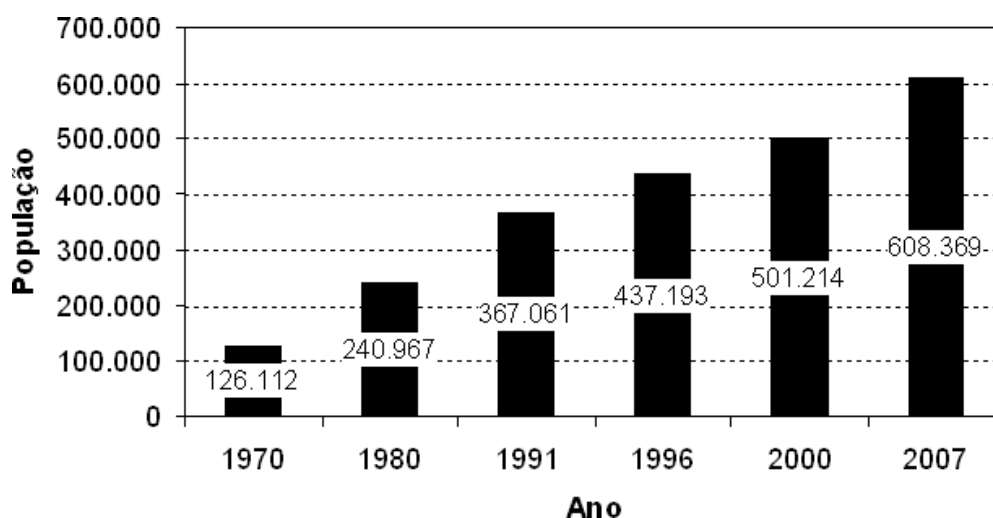


Figura 1.1: Evolução da população de Uberlândia-MG.

Fonte: IBGE (2008).

A poluição atmosférica sempre fez parte da vida humana. Nossos ancestrais já conviviam com a poluição natural de queimadas, erupções vulcânicas e decomposição da matéria orgânica. Mais tarde, a intensificação das atividades antropogênicas contribuiu ainda mais para a poluição atmosférica. Com a expansão da urbanização, as fontes de poluição multiplicaram-se e concentraram-se. O crescimento da frota motorizada agravou ainda mais o problema, mesmo em áreas não industrializadas.

A poluição do ar tem sido um tema extensivamente pesquisado nas duas últimas décadas e atualmente caracteriza-se como um fator de grande importância na busca da preservação do meio ambiente e na implementação de um desenvolvimento sustentável. A avaliação da qualidade do ar não envolve somente o monitoramento da qualidade do ar, mas também a identificação das principais fontes que causam a poluição medida, estudos de tendência, estimativas de poluição em áreas não monitoradas, e até mesmo a previsão de impacto na qualidade do ar de fontes ainda não instaladas.

Na Faculdade de Engenharia Química da Universidade Federal de Uberlândia (FEQ/UFU), os trabalhos relativos à avaliação da qualidade do ar foram iniciados com a escolha do local de monitoramento do material particulado (BARBOSA et al., 2002) e, em seguida, a análise do comportamento temporal do material particulado e sua caracterização química elementar (LIMA, 2007). Este estudo visa continuar esta linha de pesquisa.

As partículas em suspensão no ar podem ter diversos diâmetros aerodinâmicos¹(0-100 μm), sendo aquelas com diâmetro menor do que 10 μm (MP_{10}) muito danosas para a saúde humana. A exposição às altas concentrações dessas partículas está fortemente associada a graves problemas de saúde, principalmente dos sistemas respiratório e cardiovascular, conforme estudos da área de saúde pública (NASCIMENTO et al., 2006; MARTINS et al., 2006; MEDEIROS; GOUVEIA, 2005; BAKONYIA et al., 2004; MARTINS et al., 2002).

A concentração de um poluente no ar é o resultado final de processos complexos, sujeitos a vários fatores, que compreendem não só a emissão pelas fontes, como também suas interações físicas (diluição) e químicas (reações) na atmosfera. Normalmente, a própria atmosfera é capaz de dispersar os poluentes, misturando-os eficientemente a um grande volume de ar, o que contribui

¹Diâmetro aerodinâmico é definido como o diâmetro da esfera de densidade unitária que possua a mesma velocidade que a partícula em questão.

para que a poluição se mantenha em níveis aceitáveis. A capacidade de dispersão varia muito com a topografia e com as condições meteorológicas. O conhecimento prévio dos níveis dos poluentes na atmosfera de uma região pode ser útil para 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.

Modelos baseados em redes neurais têm sido utilizados para a previsão da concentração de uma gama de poluentes atmosféricos, apresentando, em muitos casos, boa concordância com os dados experimentais (JIANG et al., 2004; SLINI et al., 2006; KUKKONEN et al., 2003; PEREZ; REYES, 2002; GRIVAS; CHALOULAKOU, 2006; ORDIERES et al., 2005; JIANG et al., 2004, 2004; AGIRRE-BASURKO et al., 2006; KOLEHMAINEN et al., 2001; KUKKONEN et al., 2003; AGIRRE-BASURKO et al., 2006; GUARDANI et al., 1999). Os modelos lineares são usados, neste trabalho, como uma novidade, uma vez que não foram encontrados na literatura outros trabalhos que utilizassem esses modelos para a previsão da concentração de poluentes atmosféricos.

As vantagens do uso desses modelos são que eles não requerem informações muito exaustivas sobre poluentes atmosféricos, mecanismos de reação, parâmetros meteorológicos ou fluxo de veículos e têm a habilidade de permitir relações não lineares entre as variáveis de entrada e de saída. Esses fatos e a qualidade dos resultados que eles provêem são as razões que os fazem mais atraentes que outros modelos.

O principal objetivo deste trabalho foi desenvolver modelos empíricos capazes de prever a concentração de MP_{10} no centro da cidade de Uberlândia-MG. Vários modelos lineares, tais como ARX, ARMAX, erro na saída e Box-Jenkins, bem como modelos baseados em redes neurais foram avaliados. Os modelos usaram variáveis meteorológicas e fluxo de veículos como dados de entrada e, como saída prevista pelo modelo, tem-se a concentração de MP_{10} com horizonte de predição de três dias à frente.

A carência de informações no que se refere à relação entre poluição atmosférica e doenças respiratórias na cidade de Uberlândia instigou esta verificação. Assim, este estudo teve também como objetivo verificar a relação existente entre a concentração de MP_{10} e o número de atendimentos por doenças do aparelho respiratório.

Uma abordagem inicial do problema da poluição atmosférica é feita no Capítulo segundo. Fala-se primeiramente sobre a atmosfera e sua composição natural. Em seguida, discorre-se a respeito das fontes de poluição, da dispersão/remoção de poluentes na atmosfera e dos efeitos da poluição, principalmente na saúde humana. Esse capítulo aborda também os padrões e índices de qualidade do ar e faz uma caracterização geral do material particulado: classificação, tamanho da partícula e composição química.

No Capítulo terceiro, aborda-se o monitoramento da qualidade do ar. Primeiramente, é feita uma breve revisão sobre os equipamentos de medição; logo depois, fala-se sobre o monitoramento da qualidade do ar em Uberlândia: local do monitoramento, equipamento utilizado, operação de amostragem e como é feito o cálculo da concentração de MP_{10} .

O Capítulo quarto apresenta os modelos matemáticos utilizados na predição da qualidade do ar em Uberlândia. Inicialmente é feita uma revisão a respeito das redes neurais artificiais. Discorre-se sobre o neurônio artificial, as diferentes funções de ativação e as diversas arquiteturas de rede, além dos processos de aprendizagem. São também apresentadas as redes *perceptron* multicamadas, bem como o algoritmo de aprendizado utilizado para treinar tais redes, o algoritmo *backpropagation*. Em seguida é realizada uma breve revisão acerca de modelos lineares utilizados, a saber: ARX, ARMAX, Box-Jenkins e erro na saída. E, por fim, são apresentados os indicadores de desempenho usados para avaliar tais modelos.

O Capítulo quinto traz, inicialmente, uma caracterização geral das variáveis utilizadas: meteorológicas, fluxo de veículos e concentração de MP_{10} , além de análises de correlação entre tais variáveis. Em seguida, são reportados diversos estudos e comparações dos modelos propostos. Finalmente, é analisada a relação existente entre o número de atendimentos diários por doenças respiratórias e a concentração de MP_{10} do mesmo período. As conclusões e as sugestões para trabalhos futuros são apresentadas no capítulo sexto.

POLUIÇÃO ATMOSFÉRICA E MEIO AMBIENTE

2.1 Introdução

Conforme a Resolução CONAMA n° 3 de 28/06/1990, considera-se poluente atmosférico

[...] qualquer forma de matéria ou energia com intensidade e em quantidade, concentração, tempo ou características em desacordo com os níveis estabelecidos, e que tornem ou possam tornar o ar impróprio, nocivo ou ofensivo à saúde, inconveniente ao bem-estar público, danoso aos materiais, à fauna e à flora ou prejudicial à segurança, ao uso e gozo da propriedade e às atividades normais da comunidade (CONAMA, 1990).

Quando se determina a concentração de um poluente na atmosfera, mede-se o grau de exposição dos receptores (seres humanos, outros animais, plantas e materiais) como resultado final do processo de lançamento desse poluente na atmosfera, a partir de suas fontes de emissão e de suas interações na atmosfera, dos pontos de vista físico (dispersão) e químico (reações químicas).

2.2 Atmosfera terrestre

A atmosfera é o conjunto de gases, vapor d'água e partículas que envolvem a superfície da Terra. Diversas tentativas foram feitas, no sentido de dividi-la em camadas aproximadamente homogêneas, no que concerne às suas propriedades físicas, o que tornaria mais fácil seu estudo. O critério aceito atualmente fundamenta-se na variação da temperatura do ar com a altitude, dada pela interação de seus componentes com a entrada de energia proveniente do Sol e a saída de energia proveniente da Terra. De conformidade com esse critério, a atmosfera é dividida em quatro camadas aproximadamente homogêneas: troposfera, estratosfera, mesosfera e termosfera, separadas por três zonas de transição: tropopausa, estratopausa e mesopausa, conforme demonstra a Figura 2.1 (VAREJÃO-SILVA, 2005).

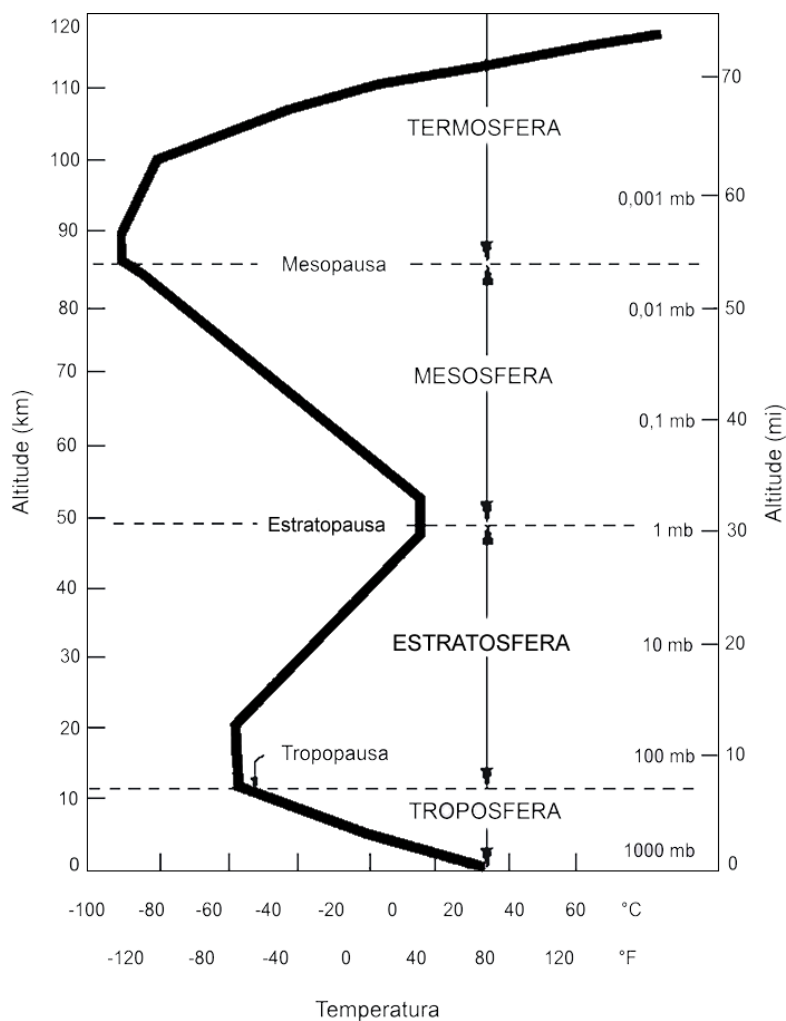


Figura 2.1: Camadas da atmosfera segundo o critério de temperatura média do ar.

Fonte: Ahrens (2001), adaptado.

A troposfera é a camada que está em contato direto com a superfície terrestre. Atinge uma altitude média de doze quilômetros, dependendo da latitude e da estação do ano. Na troposfera, concentra-se cerca de 75% da massa total da atmosfera e quase todo o seu vapor d'água. A temperatura do ar na troposfera decresce com a altitude à taxa de $6,5^{\circ}\text{C}/\text{km}$. Devido ao intenso movimento de energia térmica e às significativas diferenças de temperatura, a troposfera é a camada mais instável da atmosfera, na qual ocorrem os fenômenos meteorológicos (SEINFELD; PANDIS, 1998; VAREJÃO-SILVA, 2005).

A camada seguinte, a estratosfera, estende-se aproximadamente até 50 km de altitude. De um modo geral, observa-se uma zona aproximadamente isotérmica, correspondendo aos seus primeiros vinte quilômetros. A partir daí, a temperatura do ar aumenta com a altitude, devido à absorção de radiação ultravioleta solar pelo ozônio. Ao contrário da troposfera, a estratosfera é uma zona relativamente estável, fornecendo vantagens para vôos de longa-distância (SEINFELD; PANDIS, 1998; VAREJÃO-SILVA, 2005).

A mesosfera, camada da atmosfera imediatamente acima da estratosfera, estende-se dos 50 aos 80 km de altitude, aproximadamente. A temperatura do ar diminui com a altura até atingir aproximadamente -95°C , sendo este o ponto mais frio da atmosfera (SEINFELD; PANDIS, 1998; VAREJÃO-SILVA, 2005).

A quarta camada, denominada termosfera, se estende de uma altitude de aproximadamente 80 km até a faixa de 500 a 1.000 km (o limite superior não é bem definido). É caracterizada por um aumento da temperatura média do ar em relação à altitude devido à absorção de radiações de pequeno comprimento de onda pelos átomos de oxigênio e nitrogênio que, como consequência, são ionizados pela perda de elétrons. Por esse motivo, a termosfera é também chamada de ionosfera (SEINFELD; PANDIS, 1998; VAREJÃO-SILVA, 2005).

Na análise da composição do ar é conveniente suprimir o vapor d'água, exatamente porque sua concentração varia bastante no espaço e também no tempo, alterando as proporções dos demais constituintes. A atmosfera próxima à superfície da Terra (até cerca de 25 km) é constituída, principalmente, de gases como o nitrogênio (78,08%), o oxigênio (20,95%), o argônio (0,93%) e o dióxido de carbono (0,037%). Outros gases também participam de sua composição, mas em pequenas concentrações e, algumas vezes, em quantidades altamente variáveis, tais como: neônio,

hélio, metano, hidrogênio, xenônio e o ozônio, entre outros, que somados representam menos de 0,003% da composição total (SEINFELD; PANDIS, 1998; VAREJÃO-SILVA, 2005).

Em uma área urbana, além dos componentes naturais presentes, são lançados na atmosfera gases e partículas, poluentes ou não, que, sob diferentes condições meteorológicas de pressão, temperatura, umidade e radiação solar, sofrem reações formando poluentes adicionais aos já emitidos, que contribuem para o agravamento da poluição. A Tabela 2.1 compara a concentração média de poluentes no ar considerado limpo e na atmosfera poluída.

Tabela 2.1: Comparação do ar puro e da atmosfera poluída.

Componente	Ar puro	Atmosfera poluída
Material particulado	10-20 $\mu\text{g}/\text{m}^3$	260-3.200 $\mu\text{g}/\text{m}^3$
Dióxido de enxofre	0,001-0,01 ppm	0,02-3,2 ppm
Dióxido de carbono	300-330 ppm	350-700 ppm
Monóxido de carbono	1 ppm	2-300 ppm
Óxidos de nitrogênio	0,001-0,01 ppm	0,30-3,5 ppm
Hidrocarbonetos totais	1 ppm	1-20 ppm
Oxidantes totais	0,01 ppm	0,01-1,0 ppm

Fonte: Schnelle e Brown (2002).

2.3 Fontes de poluição atmosférica

As fontes de poluição atmosférica são entendidas como qualquer processo natural ou antropogênico que possa liberar ou emitir matéria ou energia para a atmosfera, tornando-a contaminada ou poluída.

As emissões naturais provêm de erupções vulcânicas que lançam partículas e gases para a atmosfera, como sulfeto de hidrogênio (H_2S), dióxido de enxofre (SO_2) e metano (CH_4); decomposição de vegetais e animais; ação do vento, causando ressuspensão de poeira do solo e de areia; ação biológica de microrganismos no solo; formação de metano principalmente nos pântanos; aerossóis marinhos; descargas elétricas na atmosfera, dando origem ao ozônio; incêndios florestais naturais que lançam grandes quantidades de material particulado (fumaça e cinzas), dióxido de carbono (CO_2), monóxido de carbono (CO), hidrocarbonetos (HC) e óxidos de nitrogênio (NO_x) (BOUBEL et al., 1994).

Entre as fontes antropogênicas estão os diversos processos e operações industriais; a queima de combustível na indústria e para fins de transporte nos veículos a gasolina, a álcool, a diesel ou a qualquer outro tipo de combustível e para aquecimento em geral e cozimento de alimentos; queimadas; queima de lixo ao ar livre; incineração de lixo; limpeza de roupas a seco; poeiras provocadas pela movimentação de veículos, principalmente em vias sem pavimentação; poeiras provenientes de demolições na construção civil e de movimentações de terra em geral; comercialização e armazenamento de produtos voláteis como gasolina e solventes; equipamentos de refrigeração e ar condicionado e embalagens tipo “aerossol”; pintura em geral; estações de tratamento de esgotos domésticos e industriais e aterros de resíduos (BOUBEL et al., 1994).

Dentre as diversas fontes antropogênicas, os veículos automotores e os processos industriais destacam-se como as principais fontes de poluição atmosférica, principalmente nos grandes centros urbanos. As fontes veiculares são as de mais difícil controle, devido à sua grande dispersão. Os processos industriais podem apresentar grande relevância e resultar em maior impacto ambiental localizado, porém, pode-se prevenir ou controlar tais fontes com mais facilidade e eficácia do que as emissões dos veículos automotores.

Cada fonte industrial de poluição atmosférica apresenta características específicas, pois a quantidade e o tipo de poluente emitido dependem de vários fatores, entre os quais podem ser citados: as matérias-primas e combustíveis utilizados no processo, os produtos fabricados, o próprio processo e suas operações, a eficiência do processo e as medidas de controle adotadas (DERÍSIO, 1992).

Num veículo automotor, tem-se a emissão de gases e partículas pelo tubo de escapamento, vapores através do sistema de alimentação de combustível, gases e vapores pelo respiro do cárter e de partículas originadas do desgaste de pneus e freios. As emissões desses poluentes variam em função de um número elevado de fatores, dentre esses se destacam (COSTA, 2002):

- as características da frota: composição, ano/modelo;
- o tipo e composição do combustível, poluente e tecnologia de alimentação;
- as características do sistema de tráfego local;
- a densidade do fluxo de tráfego;

- o modo de operação/velocidade de tráfego;
- a regulação e manutenção;
- o traçado da via.

Outro tipo de emissão, que está diretamente associado com o uso de veículos, é a emissão de vapores de combustíveis, que ocorre por ocasião do abastecimento do veículo, devido à saída para a atmosfera dos vapores formados no tanque de combustível.

Em termos nacionais, a Região Metropolitana de São Paulo (RMSP) é uma área prioritária para o controle da poluição atmosférica, já que apresenta uma forte degradação da qualidade do ar, condição comum à maior parte dos grandes centros urbanos. Por outro lado, também em termos nacionais, a RMSP é a região com melhor monitoramento da poluição atmosférica, monitoramento esse que é efetuado pela Companhia de Tecnologia de Saneamento Ambiental (CETESB). Segundo CETESB (2007), os poluentes presentes na atmosfera da RMSP estão relacionados, principalmente, à grande emissão proveniente dos veículos automotores leves e pesados e secundariamente pelas emissões originadas em processos industriais.

A contribuição relativa de cada fonte de poluição do ar na RMSP está apresentada na Tabela 2.2 e pode ser mais facilmente visualizada na Figura 2.2. Observa-se que os veículos automotores são as principais fontes de monóxido de carbono (CO), hidrocarbonetos totais (HC) e óxidos de nitrogênio (NO_x). Para os óxidos de enxofre (SO_x), as indústrias e os veículos são importantes fontes e no caso das partículas inaláveis (MP₁₀) contribuem ainda outros fatores como a ressuspensão de partículas do solo e a formação de aerossóis secundários (CETESB, 2007).

2.4 Dispersão e remoção de poluentes na atmosfera

2.4.1 Dispersão de poluentes

A interação entre as fontes de poluição e as condições atmosféricas define a qualidade do ar em uma região. As condições atmosféricas determinam as características de dispersão dos poluentes, favorecem ou não reações entre substâncias presentes na atmosfera e promovem a remoção dos

Tabela 2.2: Contribuição relativa das fontes de poluição do ar na RMSP em 2006.

Fonte de emissão		Poluentes (%)				
		CO	HC	NO _x	SO _x	MP ₁₀
Tubo de escapamento de veículos	Gasolina C	43,48	18,40	13,16	19,47	9,90
	Álcool	12,59	5,76	3,77	-	-
	Diesel	24,53	15,75	77,79	13,74	28,28
	Táxi	0,12	0,27	0,61	-	-
	Motocicleta e similares	16,74	9,11	0,61	1,53	1,82
Cárter e evaporativa	Gasolina C	-	32,91	-	-	-
	Álcool	-	4,35	-	-	-
	Motocicleta e similares	-	6,57	-	-	-
Operação de transferência de combustível	Gasolina C	-	3,32	-	-	-
	Álcool	-	0,32	-	-	-
Operação de processo industrial (1990)		2,54	3,24	4,06	65,27	10,00
Ressuspensão de partículas		-	-	-	-	25,00
Aerossóis secundários		-	-	-	-	25,00
Total		100	100	100	100	100

Fonte: CETESB (2007).

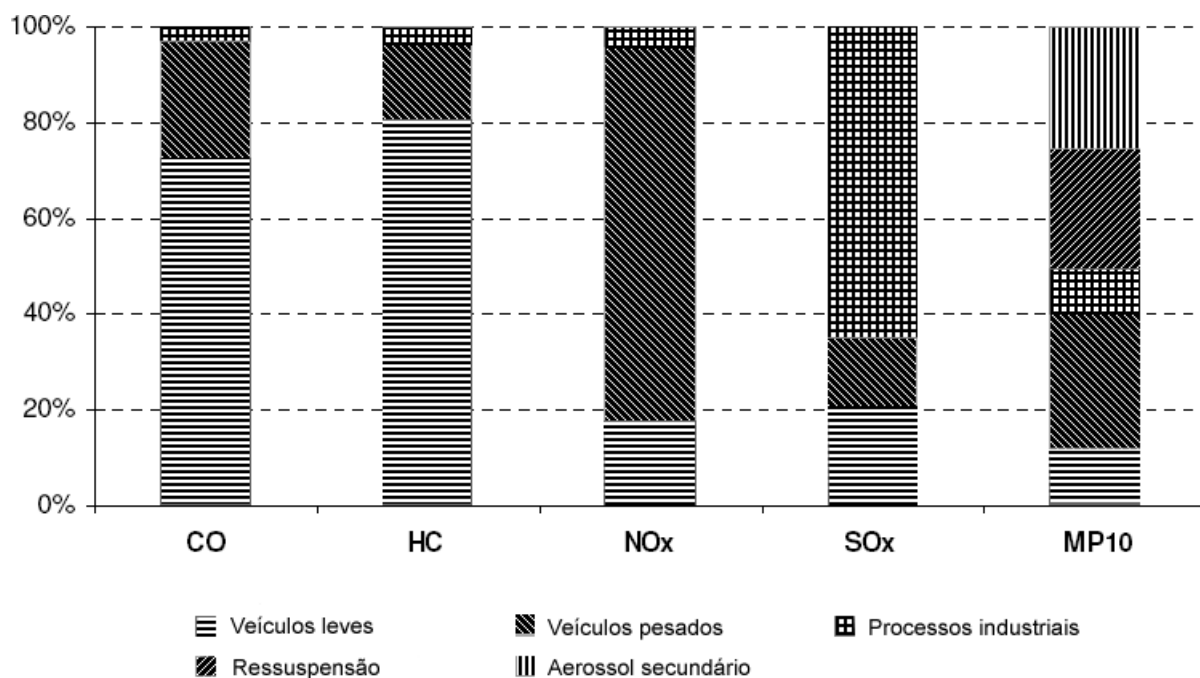


Figura 2.2: Emissões relativas de poluentes por tipo de fonte na RMSP em 2006.

Fonte: CETESB (2007).

poluentes. Condições meteorológicas distintas, mas com idênticas emissões de poluentes, poderão resultar em concentrações atmosféricas completamente diferentes.

Os ventos são os principais responsáveis pela dispersão de poluentes atmosféricos. À medida que a velocidade do vento aumenta, o volume de ar em movimento em torno de uma fonte também cresce. Se a taxa de emissão de um poluente é relativamente constante, o aumento da velocidade do vento diminui a concentração do poluente na atmosfera. Em situações de calmaria, ocorre estagnação do ar, que proporciona um aumento nas concentrações dos poluentes (LIU; LIPTAK, 1999).

A dispersão de poluentes também é afetada pela variação da direção do vento. Se a direção do vento é relativamente constante, uma mesma área é exposta continuamente a altos níveis de poluição. Se, por outro lado, a direção do vento é constantemente alterada, os poluentes são dispersos em uma área maior e as concentrações de qualquer área exposta são menores (LIU; LIPTAK, 1999).

O fluxo do vento próximo à superfície terrestre sofre perturbações devido à presença de obstáculos, tais como edifícios e construções em geral. Estas alterações no fluxo do vento influenciam a distribuição dos poluentes próximos aos obstáculos (ÁLVARES JR. et al., 2002).

As brisas marítima e terrestre são fenômenos meteorológicos muito importantes para a dispersão de poluentes, sobretudo nas regiões mais próximas do litoral. As brisas marítima e terrestre ocorrem devido às diferentes capacidades de aquecimento e retenção de calor entre as superfícies do mar e da terra. Durante os dias ensolarados, a superfície terrestre aquece mais rapidamente que o mar adjacente e provoca movimento ascendente do ar acima da terra e o movimento horizontal do ar em baixos níveis da atmosfera do mar para a terra. Durante a noite, a superfície terrestre esfria mais rapidamente que o mar, ocasionando uma inversão na circulação do ar (VAREJÃO-SILVA, 2005).

Os ventos de origem em vale e montanha ocorrem por mecanismo semelhante ao das brisas. Durante o dia, a superfície da encosta da montanha aquece mais rapidamente que o ar na mesma altura sobre o vale adjacente, provocando a movimentação do ar do vale para a montanha, ao passo que no período noturno, a superfície da encosta da montanha esfria mais rapidamente, promovendo a circulação inversa do ar, da montanha para o vale (VAREJÃO-SILVA, 2005).

O movimento vertical do ar depende do perfil vertical da temperatura do ar. Na troposfera, a temperatura do ar decresce com a altitude, o que proporciona o desenvolvimento de correntes verticais ascendentes. Estas correntes verticais favorecem a dispersão de poluentes atmosféricos (LIU;

LIPTAK, 1999; WARK; WARNER, 1981). Entretanto, processos naturais podem alterar esse gradiente térmico negativo, reduzindo-o ou aumentando-o, chegando até mesmo a invertê-lo, em geral por poucas horas, o que ocasiona um fenômeno prejudicial à dispersão dos poluentes denominado de inversão térmica. Esse fenômeno pode ocorrer em qualquer época do ano, entretanto é mais frequente nas noites frias de inverno e persiste, normalmente, até por volta de dez ou onze horas da manhã. Na inversão térmica, a camada da atmosfera onde os poluentes ficam restritos é chamada camada de mistura ou de estagnação. No Brasil, a altura média mensal dessa camada de mistura é 500 metros e no período do inverno ela atinge os menores valores.

O grau de estabilidade atmosférica influencia o movimento vertical do ar e, conseqüentemente, a dispersão de poluentes nesta direção. O sistema de classificação de Pasquill-Gifford (Tabela 2.3) é, provavelmente, o esquema mais usado para classificar a estabilidade atmosférica baseando-se em condições meteorológicas (ÁLVARES JR. et al., 2002). Esta classificação depende da velocidade do vento, juntamente com a radiação solar durante o dia ou a fração de cobertura de nuvens durante a noite. As classes são: A - extremamente instável; B - moderadamente instável; C - levemente instável; D - neutra; E - levemente estável; F - moderadamente estável.

Tabela 2.3: Classes de estabilidade atmosférica de Pasquill-Gifford.

Velocidade do vento (m/s)	Dia - Insolação			Noite - Nebulosidade	
	Forte ¹	Moderada ²	Fraca ³	$\geq 4/8$	$\leq 3/8$
<2	A	A - B	B	-	-
2 - 3	A - B	B	C	E	F
3 - 5	B	B - C	C	D	D
5 - 6	C	C - D	D	D	D
>6	C	D	D	D	D

Fonte: Álvares Jr. et al. (2002).

¹ $I > 700 \text{ Wm}^{-2}$.

² $350 \leq I \leq 700 \text{ Wm}^{-2}$.

³ $I < 350 \text{ Wm}^{-2}$.

Os fluxos de ar na atmosfera estão sujeitos a movimentos irregulares tridimensionais denominados turbulência. De modo geral, a turbulência atmosférica é determinada pela velocidade dos ventos e pelo perfil vertical de temperatura. A movimentação na direção vertical é atribuída à turbulência térmica resultante de parcelas de ar aquecido que ascende da superfície terrestre, sendo substituídas pelo ar mais frio em sentido descendente. A movimentação dos poluentes na

direção horizontal é determinada pela turbulência mecânica provocada pelos ventos, associados às características topográficas da região (LIU; LIPTAK, 1999; WARK; WARNER, 1981).

Normalmente, ambos os tipos de turbulência acontecem em qualquer condição atmosférica, embora às vezes um deles prevaleça. A turbulência térmica é dominante em dias ensolarados e com ventos fracos, quando o gradiente de temperatura é altamente negativo. Apesar de a turbulência mecânica ocorrer sob uma variedade de condições atmosféricas, ela é dominante em noites com ventos fortes e estabilidade atmosférica neutra (LIU; LIPTAK, 1999; WARK; WARNER, 1981).

2.4.2 Remoção de poluentes

Os principais processos de remoção de poluentes são decorrentes da deposição seca, da deposição úmida e de reações químicas. A deposição seca ocorre com a sedimentação ou impactação de partículas e também com absorção ou adsorção de gases em superfícies, tais como solo, vegetação, corpos d'água, entre outros (LIU; LIPTAK, 1999; WEINER; MATTHEWS, 2003).

A deposição úmida é o principal processo de remoção de poluentes da atmosfera. Existem dois mecanismos de deposição úmida. No primeiro, partículas muito pequenas tornam-se núcleos de condensação para formação de gotículas de água, que caem na forma de chuva. No segundo, ocorre o carreamento de partículas e/ou gases pela água da chuva (LIU; LIPTAK, 1999; WEINER; MATTHEWS, 2003).

As reações químicas alteram a concentração de poluentes, pois produzem outros compostos e/ou radicais livres. Como exemplo, pode-se citar os óxidos de nitrogênio e os hidrocarbonetos que, sob a ação da radiação solar, podem reagir fotoquimicamente produzindo os oxidantes fotoquímicos, em especial, o ozônio (LIU; LIPTAK, 1999).

2.5 Efeitos da poluição atmosférica

A presente abordagem dos efeitos da poluição atmosférica limita-se aos efeitos que podem ser identificados e quantificados e não abrange os aspectos psicológicos, sociológicos, políticos e morais relacionados à contaminação ambiental. Os efeitos da poluição atmosférica caracterizam-se

tanto pela alteração de condições consideradas normais, como pelo aumento de problemas preexistentes. Os efeitos dos poluentes atmosféricos variam em função do tempo de exposição e de suas concentrações. De maneira geral, os efeitos podem ser classificados como: (a) agudos - de caráter temporário, relacionada a exposição a altas concentrações de poluentes e os efeitos são imediatos; e (b) crônicos - de caráter permanente, relacionada a exposição a baixas concentrações de poluentes e os efeitos são a longo prazo.

A poluição atmosférica tem vários efeitos prejudiciais, diretos ou indiretos, sobre as plantas, os materiais, o meio ambiente e a saúde de seres humanos e dos animais. Esses efeitos causam perdas econômicas pelo aumento da ocorrência de algumas doenças (aumentando o consumo de medicamentos), diminuem a produção agrícola, aceleram a taxa de corrosão dos metais, aumentam o custo de sua proteção e diminuem o tempo de vida dos edifícios, construções e monumentos históricos, entre outros (LIU; LIPTAK, 1999).

2.5.1 Efeitos sobre as plantas

As plantas podem ser afetadas pelos poluentes atmosféricos por meio dos seguintes mecanismos (DERÍSIO, 1992): redução da penetração da luz por sedimentação de partículas nas folhas ou por interferência de partículas em suspensão na atmosfera; deposição de poluentes no solo, por sedimentação ou por carreamento pelas chuvas, permitindo a penetração de poluentes pelas raízes e alterando as condições do solo; e penetração de poluentes pelos estômatos¹ das plantas.

Qualquer que seja a forma pela qual a planta tenha sido afetada, os efeitos podem ser visíveis ou não. Os efeitos visíveis podem ser agrupados da seguinte forma: colapso e necrose do tecido foliar; perda de clorofila em regiões específicas da folha, resultando em alterações da cor normal das mesmas; e alterações no crescimento e produção das plantas.

¹Os estômatos são pequenos poros na superfície das plantas, geralmente nas folhas e nestas em geral na parte inferior, onde ocorre, em quase sua totalidade, a troca de gases (O_2 - CO_2).

2.5.2 Efeitos sobre os materiais

O principal efeito da poluição atmosférica sobre os metais é a corrosão, com eventual perda de material da superfície e alterações nas propriedades elétricas do metal. A corrosão é causada, principalmente, por gases ácidos, em especial o SO_2 . Dentre os metais, os ferrosos são mais susceptíveis à corrosão por poluentes atmosféricos (BOUBEL et al., 1994).

O ataque aos materiais de construção não metálicos ocorre principalmente pela ação do SO_2 , que reage com os carbonatos na presença de umidade, formando sulfatos, mais solúveis, causando deterioração do material. O CO_2 , na presença de umidade, forma o ácido carbônico que converte a pedra calcária em bicarbonato, que é solúvel em água e pode ser lixiviado pela chuva (BOUBEL et al., 1994).

Os tecidos são danificados pela poluição atmosférica não só pela deposição de MP, que aumenta a frequência de lavagens, desbotando e reduzindo a sua vida útil, mas também pela redução da sua resistência quando expostos a gases ácidos, SO_2 principalmente, e oxidantes fotoquímicos (O_3 , PAN e NO_x). Os corantes usados para tingir os tecidos também estão sujeitos a descoloração quando expostos a NO_2 e O_3 (BOUBEL et al., 1994).

O SO_2 afeta couro e papel e provoca significativa deterioração e enfraquecimento. Esse poluente é absorvido e convertido a H_2SO_4 , que ataca a estrutura desses materiais tornando-os frágeis. Nas tintas, o MP e o H_2S causam escurecimento, descoloração e sujeira, que resultam em aumento na frequência de pintura. A borracha natural também é afetada por poluentes atmosféricos, em especial pelo O_3 , que ataca a dupla ligação $\text{C}=\text{C}$ e ocasiona enfraquecimento e perda de elasticidade do material (BOUBEL et al., 1994).

2.5.3 Efeitos sobre o meio ambiente

Os efeitos da poluição do ar sobre o meio ambiente são caracterizados, em escala global, pela redução da camada de ozônio e pelo efeito estufa.

A camada de ozônio é uma camada de ar com alta concentração de O_3 , localizada de 20 a 30 km acima da superfície da Terra, na estratosfera. Ela concentra em torno de 90% do O_3 da

atmosfera e age como um filtro natural que protege o planeta dos níveis indesejáveis de radiação ultravioleta provenientes do Sol. Algumas das consequências da diminuição da concentração de O_3 nessa camada são: danos ao homem - catarata, câncer de pele, queimaduras; e danos à Natureza - à vegetação e agricultura, diminuindo a capacidade de fotossíntese e crescimento das plantas (KIPERSTOK et al., 2002).

A teoria atualmente aceita é a de que o O_3 da estratosfera estaria sendo eliminado em grande parte pelo cloro presente nas substâncias denominadas clorofluorcarbonos (CFCs). Estas substâncias são muito estáveis quimicamente e permanecem na atmosfera por dezenas de anos, o que permite serem carregadas para a estratosfera pelas correntes naturais da atmosfera, onde sofrem quebra da molécula pela radiação solar, liberam radical cloro, altamente reativo, provocam um desequilíbrio na reação natural de formação/destruição do O_3 e favorecem a reação de destruição. Substâncias coadjuvantes nesse processo seriam algumas outras contendo cloro, como o metilclorofórmio e o tetracloreto de carbono, e halons (ÁLVARES JR. et al., 2002).

Os CFCs são utilizados como gás refrigerante em sistemas de refrigeração (geladeiras, freezers, balcões, câmaras frigoríficas etc.) e em sistemas de ar condicionado. Outros usos incluem a produção de espumas, onde agem como agente expensor, e na limpeza de componentes eletrônicos. O metilclorofórmio é também usado como solvente, na limpeza de componentes eletrônicos. O tetracloreto de carbono é usado quase em sua totalidade como matéria-prima para produção de CFCs. Os halons são utilizados em extintores de incêndios (ÁLVARES JR. et al., 2002).

O Protocolo de Montreal, estabelecido em 1987, impôs aos países signatários a progressiva redução da produção e do consumo dessas substâncias, até sua total eliminação de uso. Essas substâncias passaram a ser conhecidas como ODS - "*Ozone Depleting substance*" (SDO em português). O Protocolo determina, ainda, restrições ao comércio dessas substâncias e recomenda o desenvolvimento de tecnologias alternativas que reduzam ou eliminem os riscos à Camada de Ozônio. O Brasil, a partir de 1990, é signatário desse Protocolo de Montreal (ÁLVARES JR. et al., 2002).

O efeito estufa está relacionado ao aumento de temperatura da Terra, provocado pela maior retenção de radiação infravermelha por ela refletida, em função do aumento da concentração de determinados gases que têm essa propriedade, tais como o CO_2 , CH_4 , N_2O e CFCs - chamados

gases do efeito estufa (GEE). A maioria dos GEE é proveniente da queima de combustíveis fósseis (carvão, petróleo e derivados), florestas e pastagens.

É difícil prever a escala e os efeitos do aquecimento global provocados pelo efeito estufa e há debates e estudos científicos ainda em andamento. Uma das consequências mais graves do efeito estufa é o derretimento das camadas de gelo polar, o que já vem sendo detectado. Caso esse problema se agrave, o nível do oceano pode subir cerca de um metro, inundando regiões densamente povoadas próximas aos deltas dos rios e fazendo desaparecer as ilhas e terrenos costeiros de baixa altitude. Outro problema seria o superaquecimento da região equatorial e a alteração das zonas climáticas em seus limites de latitude, o que provocaria desertificação e afetaria áreas produtoras de alimentos IPCC (2007).

A principal iniciativa internacional para tentar minimizar o problema do efeito estufa é o Protocolo de Kyoto, um tratado assinado em 1997 que estabelece metas de redução na emissão dos GEE. Além da redução das emissões de GEE, o Protocolo de Kyoto estabelece outras medidas, como o estímulo à substituição do uso dos derivados de petróleo pelo da energia elétrica e do gás natural (ÁLVARES JR. et al., 2002).

O Protocolo de Kyoto propõe um cronograma pelo qual os países-membros, principalmente os desenvolvidos, são obrigados a reduzir a emissão de GEE em, pelo menos, 5,2% em relação aos níveis de 1990 no período entre 2008 e 2012. As metas de redução não são homogêneas a todos os países, estabelecendo-se níveis diferenciados para os 38 países que mais emitem GEE. Países em franco desenvolvimento (como Brasil, México, Argentina e Índia) não receberam metas de redução, pelo menos momentaneamente (ÁLVARES JR. et al., 2002).

2.5.4 Efeitos sobre a saúde humana

O impacto da poluição atmosférica sobre o bem-estar humano tem sido a principal motivação para o seu estudo e controle. A poluição atmosférica tem afetado a saúde da população, mesmo quando seus níveis encontram-se aquém do que determina a legislação vigente (MARTINS et al., 2001).

Alguns episódios graves de poluição atmosférica ocorridos na Inglaterra e nos Estados Unidos despertaram a conscientização da população para os efeitos na saúde produzidos pelos poluentes gerados pela queima de combustíveis.

O primeiro episódio documentado na História ocorreu em 1930, no vale de Meuse, Bélgica, uma região com grande concentração de indústrias. Nos cinco primeiros dias de dezembro daquele ano, condições meteorológicas desfavoráveis, como ausência de ventos, impediram a dispersão dos poluentes, que permaneceram estacionados sobre a região. Durante esse período, foi registrado um aumento da incidência de doenças respiratórias e um excesso de mortes (60 óbitos) até dois dias após o início do episódio (BOUBEL et al., 1994).

Em 1948, em Donora, Estados Unidos, uma pequena cidade de 14.000 habitantes, dominada por siderúrgicas e fábricas de produtos químicos, ocorreu um episódio de inversão térmica que impediu a dispersão dos poluentes, formando uma névoa densa que cobriu a cidade por seis dias. Durante esse período, estudos mostraram que, aproximadamente, metade da população apresentou sintomas de doenças cardiorrespiratórias e 20 pessoas morreram. Dez anos após o incidente, os indivíduos residentes em Donora que apresentaram patologia aguda durante o episódio mostraram ter uma taxa de morbidade maior que a média da população em geral (BOUBEL et al., 1994).

Em dezembro de 1952, em Londres, ocorreu o mais clássico e grave episódio dos efeitos deletérios da poluição do ar. Entre cinco e nove de dezembro, uma grande onda de frio levou a população a utilizar uma grande quantidade de carvão e esse fato, associado a uma inversão térmica que impediu a dispersão dos poluentes, produziu uma densa névoa, composta principalmente por material particulado e enxofre. A névoa permaneceu estacionada na cidade, próxima ao solo, por três dias, ocasionando um aumento de 4.000 mortes em relação à média de óbitos em períodos semelhantes. O sistema hospitalar londrino, considerado um dos mais eficientes do planeta, entrou em colapso. As estatísticas indicaram que a grande maioria dos indivíduos que morreram apresentava história prévia de bronquite crônica, enfisema, ou patologia cardiovascular (BOUBEL et al., 1994).

Esses episódios agudos, apesar de dramáticos, chamaram a atenção da população, dos pesquisadores e das autoridades no sentido de estabelecer medidas de proteção à população em relação à poluição do ar. Diversos estudos têm sido realizados, principalmente nas duas últimas déca-

das, objetivando demonstrar a associação existente entre variações de concentração de poluentes atmosféricos e aumento de incidência de doenças respiratórias e cardiovasculares.

As crianças e os idosos são os dois grupos etários mais suscetíveis aos efeitos da poluição atmosférica. Muitos estudos, tanto no Brasil quanto no exterior, mostram uma associação positiva entre mortalidade e morbidade (internações) por problemas respiratórios em crianças. Já entre os idosos, a poluição atmosférica tem sido associada a aumentos de morbidade e de mortalidade, por doenças tanto respiratórias quanto cardiovasculares. A seguir, citam-se alguns desses estudos realizados no Brasil.

Nascimento et al. (2006) usaram dados diários do número de internações por pneumonia na cidade de São José dos Campos-SP, dados diários de poluentes (SO_2 , O_3 e MP_{10}) e de temperatura e umidade relativa. Para estimar a associação entre as internações por pneumonia e a poluição atmosférica, utilizaram modelos aditivos generalizados de regressão de Poisson. Foram estimados os acréscimos das internações por pneumonia para o intervalo interquartil para cada um dos poluentes estudados, com um intervalo de confiança de 95%. Os três poluentes apresentaram efeitos defasados nas internações por pneumonia, iniciada três a quatro dias após a exposição e decaindo rapidamente. Na estimativa de efeito acumulado de oito dias, observou-se, ao longo desse período, que, para aumentos de $24,7 \mu\text{g}/\text{m}^3$ na concentração média de MP_{10} , houve um acréscimo de 9,8% nas internações.

Martins et al. (2006) investigaram a estrutura de defasagem entre exposição à poluição do ar (níveis diários de CO , MP_{10} , SO_2 , O_3 e NO_2) e internações hospitalares por doenças cardiovasculares em idosos (com mais de 64 anos), na cidade de São Paulo-SP, entre 1996 e 2001. Foram utilizados modelos aditivos generalizados de regressão de Poisson para estimar os efeitos dos poluentes no dia da exposição e até vinte dias após, controlando-se para sazonalidades de longa e curta durações, feriados e fatores meteorológicos. Variações interquartis de MP_{10} ($26,21 \mu\text{g}/\text{m}^3$) e SO_2 ($10,73 \mu\text{g}/\text{m}^3$) foram associados com aumentos de 3,17% (IC 95%: 2,09-4,25) nas admissões por insuficiência cardíaca congestiva e de 0,89% (IC 95%: 0,18-1,61) para admissões por todas as doenças cardiovasculares no dia da exposição, respectivamente. Os efeitos foram predominantemente agudos e maiores para o gênero feminino.

Medeiros e Gouveia (2005) analisaram todos os partos de mães residentes no Município de São Paulo nos anos de 1998 a 2000. Estimaram as prevalências de baixo peso ao nascer conforme características do recém-nascido, da mãe e do parto. Para avaliação do efeito da poluição do ar, foram excluídos os prematuros, os gemelares e analisados somente os nascimentos das áreas mais centrais da cidade, totalizando uma amostra de 311.735 nascimentos. Os poluentes analisados foram O_3 , SO_2 , NO_2 , MP_{10} e CO . O efeito da exposição materna à poluição do ar no peso ao nascer foi avaliado por meio de regressão linear e logística. Do total analisado, 4,6% dos recém-nascidos apresentaram menos de 2.500 g ao nascer. A exposição materna ao CO , MP_{10} e NO_2 durante o primeiro trimestre de gestação mostrou associação estatisticamente significativa com a diminuição no peso do recém-nascido.

Bakonyia et al. (2004) fizeram uso de dados diários de atendimentos por doenças respiratórias para crianças em unidades de saúde no Sistema Único de Saúde (SUS) no município de Curitiba-PR. Para verificar a relação existente entre doenças respiratórias e níveis diários de MP_{10} , fumaça, NO_2 e O_3 , utilizaram o modelo aditivo generalizado de regressão de Poisson. A análise foi ajustada para sazonalidade de longa duração (número de dias transcorridos), sazonalidade de curta duração (dias da semana), temperatura mínima e umidade média. O nível de significância de 5% foi adotado em todas as análises. Todos os poluentes investigados apresentaram efeitos sobre as doenças respiratórias de crianças. Um aumento de $40,4 \mu g/m^3$ na média móvel de três dias de fumaça esteve associado a um aumento de 4,5% (IC 95%: 1,5-7,6) nas consultas por doenças respiratórias de crianças.

Martins et al. (2002) utilizaram dados diários de atendimentos por pneumonia e gripe para idosos em pronto-socorro médico de um hospital-escola de referência no Município de São Paulo-SP. Os níveis diários de CO , O_3 , SO_2 , NO_2 e MP_{10} foram obtidos na CETESB, e os dados diários de temperatura e umidade relativa do ar foram obtidos no Instituto Astronômico e Geofísico da USP. Para verificar a relação existente entre pneumonia e gripe e poluição atmosférica, foi utilizado o modelo aditivo generalizado de regressão de Poisson, tendo como variável dependente o número diário de atendimentos por pneumonia e gripe e como variáveis independentes as concentrações médias diárias dos poluentes atmosféricos. Pôde-se observar que um aumento interquartil (25%-75%) para o O_3 ($38,80 \mu g/m^3$) e SO_2 ($15,05 \mu g/m^3$) levaram a um acréscimo de 8,07% e 14,51%, respectivamente, no número de atendimentos por pneumonia e gripe em idosos.

2.6 Padrões e índice de qualidade do ar

Em muitos países, assim como no Brasil, os padrões de qualidade do ar definem legalmente o limite máximo aceitável para um determinado período de tempo, da concentração de um poluente na atmosfera. Os padrões de qualidade do ar podem, também, definir métodos de medição, métodos de análise, metodologias de controle de qualidade dos dados etc. Além disso, um determinado poluente pode ter mais de um padrão para períodos de exposição (amostragem) distintos.

O estabelecimento dos padrões de qualidade do ar é apenas uma parte da estratégia legal de gestão da poluição do ar de um determinado país ou estado. Outros aspectos, como o estabelecimento de estratégias de controle, padrões de emissão de fontes poluidoras, aplicação de penalidades etc., também podem ter um importante papel.

Os padrões nacionais de qualidade do ar foram estabelecidos pelo IBAMA - Instituto Brasileiro de Meio Ambiente e aprovados pelo CONAMA - Conselho Nacional de Meio Ambiente, por meio da Resolução CONAMA 03/90. Essa Resolução define padrões de qualidade do ar como aquelas concentrações de poluentes atmosféricos que, ultrapassadas, poderão afetar a saúde, a segurança e o bem-estar da população, bem como ocasionar danos à flora e à fauna, aos materiais e ao meio ambiente em geral.

A Resolução CONAMA 03/90 estabelece dois tipos de padrões de qualidade do ar: em primeiro lugar, os padrões primários de qualidade do ar, que são as concentrações de poluentes que, ultrapassadas, poderão afetar a saúde da população. Podem ser entendidos como níveis máximos toleráveis de concentração de poluentes atmosféricos, constituindo-se em metas de curto e médio prazo. E, em segundo lugar, os padrões secundários de qualidade do ar, que são as concentrações de poluentes atmosféricos abaixo das quais se prevê o 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.

O objetivo do estabelecimento de padrões secundários é criar um mecanismo legal para políticas de prevenção da degradação da qualidade do ar. Devem ser aplicados às áreas de preservação, tais como: parques nacionais, áreas de proteção ambiental etc. Não se aplicam, pelo menos em

curto prazo, a áreas de desenvolvimento, onde devem ser aplicados os padrões primários. Os poluentes e seus padrões de qualidade do ar, bem como o tempo de amostragem e os métodos de medição, fixados pela Resolução CONAMA 03/90, são apresentados na Tabela 2.4.

Tabela 2.4: Padrões nacionais de qualidade do ar.

Poluente	Tempo de amostragem	Padrão primário ($\mu\text{g}/\text{m}^3$)	Padrão secundário ($\mu\text{g}/\text{m}^3$)	Método de medição
PTS	24 horas ¹	240	150	Amostrador de grandes volumes
	MGA ²	80	60	
MP ₁₀	24 horas ¹	150	150	Separação Inercial/Filtração
	MAA ³	50	50	
Fumaça	24 horas ¹	150	100	Refletância
	MAA ³	60	40	
SO ₂	24 horas ¹	365	100	Pararosanilina
	MAA ³	80	40	
CO	1 hora ¹	40.000 (35 ppm)	40.000 (35 ppm)	Infravermelho não dispersivo
	8 horas ¹	10.000 (9 ppm)	10.000 (9 ppm)	
NO ₂	1 hora ¹	320	190	Quimiluminescência
	MAA ³	100	100	
O ₃	1 hora ¹	160	160	Quimiluminescência

Fonte: CONAMA (1990).

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

² Média geométrica anual.

³ Média aritmética anual.

Todos os valores dos padrões de qualidade do ar são médias baseadas no período de amostragem. No caso dos métodos de medição, a Resolução CONAMA 03/90 estabelece os métodos citados como métodos de referência, podendo ser utilizados métodos equivalentes, desde que aprovados pelo IBAMA. A Resolução CONAMA 03/90 estabelece, ainda, níveis de qualidade do ar para a elaboração do Plano de Emergência para Episódios Críticos de Poluição do Ar, visando a providências dos Governos dos Estados e dos Municípios, assim como de entidades privadas e da comunidade geral, com o objetivo de prevenir grave e iminente risco à saúde da população. Episódio crítico de poluição do ar é definido na mesma Resolução, como sendo a presença de altas concentrações de poluentes na atmosfera em curto período de tempo, resultante da ocorrência de condições meteorológicas desfavoráveis à sua dispersão. A Tabela 2.5 apresenta os níveis de qualidade do ar definidos na Resolução CONAMA 03/90.

Como exemplo de exigências legais em termos de qualidade do ar praticadas fora do Brasil, ilustram-se, na Tabela 2.6, os padrões de qualidade do ar adotados pela US-EPA (*United States*

Tabela 2.5: Critérios para episódios críticos de poluição do ar.

Parâmetros	Atenção	Alerta	Emergência
PTS ($\mu\text{g}/\text{m}^3$) - 24 horas	375	625	875
MP ₁₀ ($\mu\text{g}/\text{m}^3$) - 24 horas	250	420	500
Fumaça ($\mu\text{g}/\text{m}^3$) - 24 horas	250	420	500
SO ₂ ($\mu\text{g}/\text{m}^3$) - 24 horas	800	1.600	2.100
CO (ppm) - 8 horas	15	30	40
NO ₂ ($\mu\text{g}/\text{m}^3$) - 1 hora	1.130	2.260	3.000
O ₃ ($\mu\text{g}/\text{m}^3$) - 1 hora	400 ¹	800	1.000
SO ₂ X PTS ($\mu\text{g}/\text{m}^3$) - 24 horas	65.000	261.000	393.000

Fonte: CONAMA (1990).

¹ No estado de São Paulo, o nível de atenção é declarado com base na Legislação Estadual, que é mais restritiva (200 $\mu\text{g}/\text{m}^3$).

- *Environmental Protection Agency*). Os valores dos padrões secundários de qualidade do ar são os mesmos do padrão primário, com exceção do dióxido de enxofre (SO₂) que é de 0,5 ppm ou 1.300 $\mu\text{g}/\text{m}^3$, para um tempo de amostragem de três horas, e o monóxido de carbono (CO) que não possui padrão secundário.

Tabela 2.6: Padrões de qualidade do ar adotados pela US-EPA.

Poluente	Tempo de amostragem	Padrão primário	Método de medição
MP ₁₀	24 horas	150 $\mu\text{g}/\text{m}^3$	Separação Inercial/Filtração
MP _{2,5}	24 horas MAA ²	35 $\mu\text{g}/\text{m}^3$ 15 $\mu\text{g}/\text{m}^3$	Separação Inercial/Filtração
SO ₂	24 horas ¹ MAA ²	0,14 ppm 0,03 ppm	Pararrosanílina
CO	1 hora ¹ 8 horas ¹	40.000 $\mu\text{g}/\text{m}^3$ (35 ppm) 10.000 $\mu\text{g}/\text{m}^3$ (9 ppm)	Infravermelho não dispersivo
NO ₂	MAA ²	100 $\mu\text{g}/\text{m}^3$	Quimiluminescência
O ₃	1 hora 8 horas	0,12 ppm 0,075 ppm	Quimiluminescência
Pb	MAT ³	1,5 $\mu\text{g}/\text{m}^3$	Absorção atômica

Fonte: US-EPA (2006).

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

² Média aritmética anual.

³ Média aritmética trimestral.

Em 1997, pela primeira vez, a US-EPA estabeleceu padrões de qualidade do ar para a fração fina do MP₁₀, denominada MP_{2,5} (material particulado com diâmetro menor que 2,5 μm) pela primeira vez. A inclusão desse padrão foi baseada em estudos científicos na área da saúde que

mostraram que a fração fina ($MP_{2,5}$) é mais danosa que a fração grossa (MP_{10}). Em 2006, US-EPA diminuiu o padrão 24 horas de $65 \mu\text{g}/\text{m}^3$ para $35 \mu\text{g}/\text{m}^3$ (US-EPA, 2006). Convém ressaltar que o padrão de qualidade do ar adotado no Brasil não faz referência ao $MP_{2,5}$.

A Tabela 2.7 traz os valores de referência atualmente recomendados pela WHO (*World Health Organization*). Esses valores não são padrões legais de qualidade do ar, têm o objetivo de prover uma base de informações de proteção à saúde pública e servem de orientação para o estabelecimento de padrões de qualidade do ar. Tais valores de referência podem e devem considerar não somente os aspectos de saúde e meio ambiente, mas também os aspectos sociais.

Tabela 2.7: Valores de referência recomendados pela OMS.

Poluente	Tempo de amostragem	Concentração ($\mu\text{g}/\text{m}^3$)
SO ₂	24 horas	365
	MAA ¹	80
NO ₂	1 hora	320
	MAA ¹	100
MP ₁₀	24 horas	150
	MAA ¹	50
O ₃	1 hora	160

Fonte: WHO (2006).

¹ Média aritmética anual.

O índice de qualidade do ar é uma ferramenta desenvolvida para simplificar o processo de divulgação da qualidade do ar. Essa ferramenta foi criada nos Estados Unidos e é atualmente utilizada em diversos países. No Brasil, o estado de São Paulo é pioneiro na utilização de um índice de qualidade do ar, que tem sido utilizado desde 1981 pela CETESB (Companhia de Tecnologia de Saneamento Ambiental).

O índice de qualidade do ar utilizado pela CETESB contempla os mesmos poluentes definidos na Resolução CONAMA 03/90, e atribui a cada um deles uma qualidade do ar, que varia com base nos valores de concentração estabelecidos nos critérios para a ocorrência de episódios críticos definidos nessa mesma resolução. A Tabela 2.8 apresenta a estrutura do índice utilizado pela CETESB e a qualidade do ar associada.

Para efeito de facilidade na divulgação, foi associada uma cor para cada classificação da qualidade do ar: Boa (verde), Regular (amarelo), Inadequada (laranja), Má (vermelho) e Péssima

Tabela 2.8: Estrutura do índice de qualidade do ar utilizado pela CETESB.

Qualidade	Índice	PTS ($\mu\text{g}/\text{m}^3$)	MP ₁₀ ($\mu\text{g}/\text{m}^3$)	Fumaça ($\mu\text{g}/\text{m}^3$)	SO ₂ ($\mu\text{g}/\text{m}^3$)	CO (ppm)	NO ₂ ($\mu\text{g}/\text{m}^3$)	O ₃ ($\mu\text{g}/\text{m}^3$)
Boa	0-50	0-80	0-50	0-60	0-80	0-4,5	0-100	0-80
Regular	51-100	80-240	50-150	60-150	80-365	4,5-9	100-320	80-160
Inadequada	101-199	240-375	150-250	150-25	365-800	9-15	320-1130	160-200
Má	200-299	375-625	250-420	250-42	800-160	15-30	1130-2260	200-800
Péssima	>299	>625	>420	>420	>1600	>30	>2260	>800

Fonte: CETESB (2007).

(roxo). A divulgação da qualidade do ar para o público geral, no caso da CETESB, é feita por estação de amostragem. É utilizado o índice mais elevado dos poluentes medidos em cada estação. Portanto, a qualidade do ar de uma estação é determinada pelo pior caso. Essa qualificação do ar está associada a efeitos sobre a saúde, independentemente do poluente em questão, conforme Tabela 2.9.

Tabela 2.9: Efeitos sobre a saúde associados aos índices de qualidade do ar utilizado pela CETESB.

Qualidade	Índice	Significado
Boa	0-50	Praticamente não há riscos à saúde.
Regular	51-100	Pessoas de grupos sensíveis (crianças, idosos e pessoas com doenças respiratórias e cardíacas) podem apresentar sintomas como tosse seca e cansaço. A população em geral não é afetada.
Inadequada	101-199	Toda a população pode apresentar sintomas como tosse seca, cansaço, ardor nos olhos, nariz e garganta. Pessoas de grupos sensíveis (crianças, idosos e pessoas com doenças respiratórias e cardíacas) podem apresentar efeitos mais sérios na saúde.
Má	200-299	Toda a população pode apresentar agravamento dos sintomas como tosse seca, cansaço, ardor nos olhos, nariz e garganta e ainda apresentar falta de ar e respiração ofegante. Efeitos ainda mais graves à saúde de grupos sensíveis (crianças, idosos e pessoas com doenças respiratórias e cardíacas).
Péssima	>299	Toda a população pode apresentar sérios riscos de manifestações de doenças respiratórias e cardiovasculares. Aumento de mortes prematuras em pessoas de grupos sensíveis.

Fonte: CETESB (2007).

2.7 Material Particulado

O material particulado (MP) é um termo genérico para uma grande classe de substâncias químicas existentes na atmosfera na forma de partículas. Fisicamente, apresenta-se como partículas sólidas ou líquidas, e em suspensão num meio gasoso são definidas como aerossóis (SEINFELD; PANDIS, 1998).

2.7.1 Classificação

O MP pode ser classificado segundo o método de formação em quatro classes (HINDS, 1999): a primeira é a das **poeiras**, partículas sólidas formadas geralmente por processos de desintegração mecânica; a segunda é a dos **fumos**, partículas sólidas formadas por condensação de vapores ou gases originados da combustão; a terceira é a das **fumaças**, partículas sólidas ou líquidas, formadas na combustão incompleta; e a quarta é a das **névoas**, partículas líquidas produzidas mecanicamente (*spray*).

Baseado em sua origem, o MP também pode ser dividido em dois grupos: primário e secundário. As partículas primárias são produzidas por meio de processos químicos e físicos diretamente das fontes de poluição, enquanto as partículas secundárias são formadas na atmosfera como resultado de reações químicas envolvendo gases preexistentes (HINDS, 1999).

2.7.2 Tamanho da partícula

O tamanho das partículas é um dos parâmetros mais importantes para a caracterização do comportamento do material particulado. Partículas comportam-se distintamente em diferentes faixas de tamanho, sendo também regidas por diferentes leis físicas. O tamanho da partícula é frequentemente expresso em termos de seu diâmetro aerodinâmico, definido como o diâmetro da esfera de densidade unitária que possua a mesma velocidade terminal que a partícula em questão (HINDS, 1999).

As partículas suspensas na atmosfera possuem diâmetro aerodinâmico entre 0,005 μm e 100 μm . Partículas com diâmetro menor de 2,5 μm são comumente chamadas de “finas” e as maiores

de $2,5 \mu\text{m}$ de “grossas”. A Figura 2.3 mostra uma representação esquemática de uma distribuição granulométrica típica para o material particulado, com indicação das frações fina e grossa. Partículas finas e grossas têm, em geral, diferentes origens, composições químicas e propriedades óticas; são removidas da atmosfera por diferentes processos e depositam-se no trato respiratório de formas distintas (SEINFELD; PANDIS, 1998).

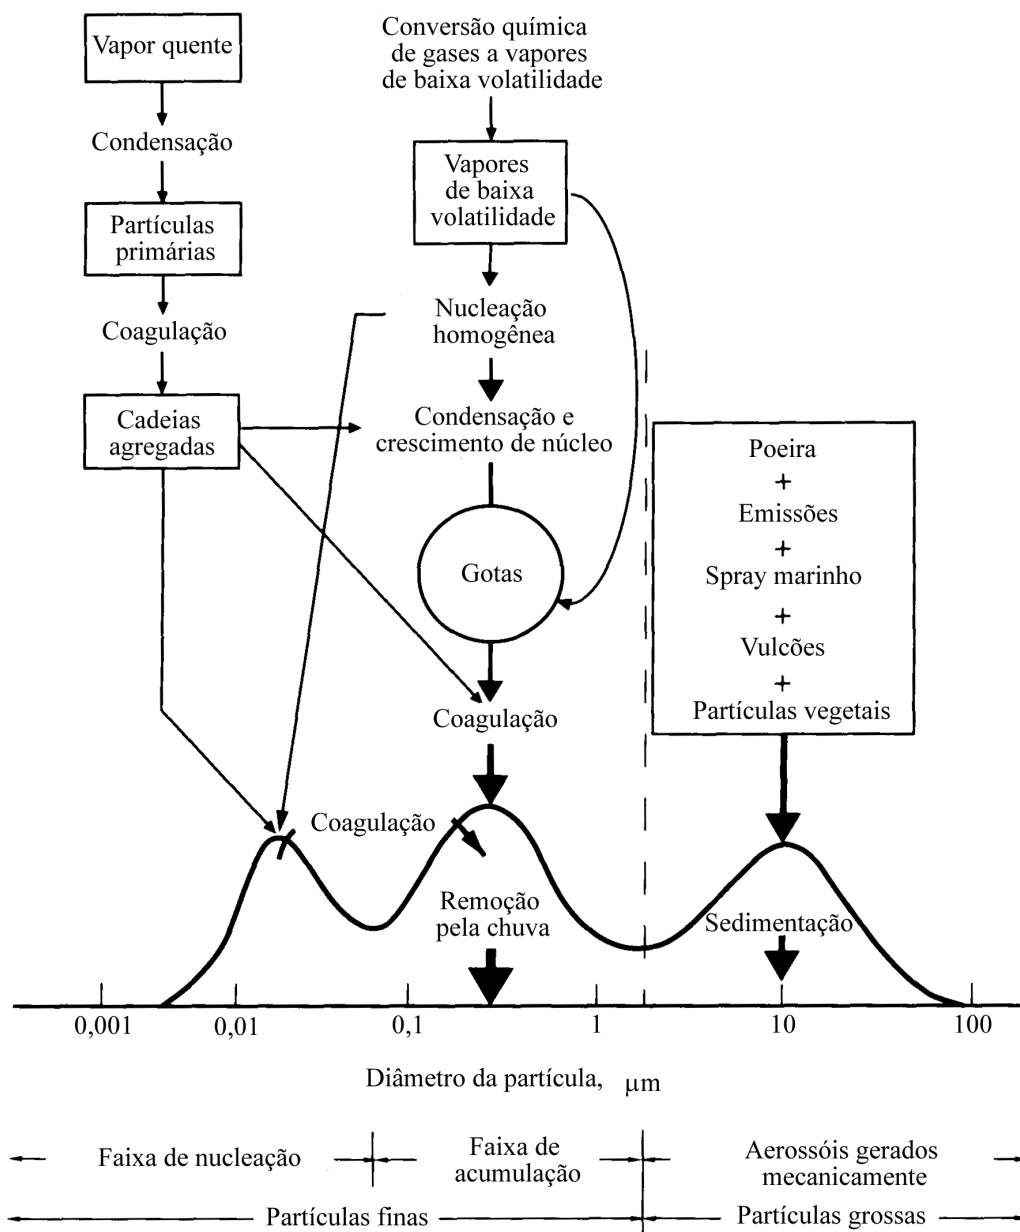


Figura 2.3: Esquema de uma distribuição granulométrica típica para o material particulado.

Fonte: Seinfeld e Pandis (1998).

Partículas maiores que $10 \mu\text{m}$ são retidas no nariz e nasofaringe. Partículas menores que $10 \mu\text{m}$ de diâmetro (MP_{10}) são retidas nas vias aéreas superiores, na região traqueobrônquica. Partículas

menores que $2,5 \mu\text{m}$ de diâmetro ($\text{MP}_{2,5}$) depositam-se no bronquíolo terminal. Nos alvéolos, ocorre a deposição de partículas bem menores, com 1 a $2 \mu\text{m}$ de diâmetro (HEINSOHN; KABEL, 1999; BOUBEL et al., 1994).

2.7.3 Composição química

Em função de sua composição química, o material particulado pode provocar efeitos nocivos a um indivíduo, devido à sua exposição a substâncias tóxicas. O material particulado apresenta uma considerável variabilidade de elementos em sua composição, chegando a ser constituído por centenas de substâncias químicas diferentes. As frações fina e grossa do material particulado possuem diferenças marcantes em sua composição química. Em geral, a fração grossa é básica e a fração fina é ácida (MANAHAN, 2000).

As partículas finas são preferencialmente emitidas por processos de combustão, indústrias e veículos, ou são formadas na atmosfera por reações químicas (partículas secundárias). Além do carbono na sua forma elementar, a fração fina apresenta, em sua composição, íons sulfatos, nitratos e amoníacos, compostos orgânicos e metais como chumbo, mercúrio, cádmio, vanádio e cromo (MANAHAN, 2000).

As partículas grossas são, geralmente, constituídas por fragmentos primários, produzidos a partir de processos mecânicos como ressuspensão do solo e erosão, ou são compostas por sal marinho, cinzas de combustão e emissões biogênicas naturais, com predominância de compostos orgânicos como o pólen, esporos, e fragmentos de plantas, insetos etc. Os principais elementos que compõem as partículas grossas são silício, alumínio, ferro e cálcio, entre outros (MANAHAN, 2000).

Segundo um estudo realizado por Lima (2007), os principais elementos químicos que compõem o MP_{10} no centro da cidade de Uberlândia são alumínio (Al), cálcio (Ca), ferro (Fe), zinco (Zn), potássio (K) e enxofre (S). A presença dos elementos químicos K, Al, Ca e Fe pode estar associada à ressuspensão do solo e o elemento S pode ser relacionado à queima de combustíveis fósseis, comum na região estudada.

MONITORAMENTO DA QUALIDADE DO AR

3.1 Introdução

A qualidade do ar de uma cidade pode ser monitorada em função de qualquer poluente legalmente regulamentado (SO_2 , NO_2 , CO , O_3 , PTS ou MP_{10}). A qualidade do ar em Uberlândia é monitorada em função da concentração de material particulado (PTS e MP_{10}) na região central da cidade.

3.2 Equipamentos de medição de poluentes

Os equipamentos de medição devem ser capazes de garantir que os dados gerados possam ser comparados com os padrões legais de qualidade do ar. A escolha dos equipamentos de medição deve levar em consideração, ainda, os recursos necessários para a aquisição, operação e manutenção dos equipamentos.

Os equipamentos que medem a poluição do ar podem ser divididos em quatro tipos, dependendo da metodologia empregada: amostradores passivos, amostradores ativos, analisadores auto-

máticos e sensores remotos. Esses quatro tipos mais comuns de equipamentos cobrem uma faixa muito grande em termos de custos e desempenho. As principais vantagens e desvantagens no uso de cada um dos tipos de equipamentos de amostragem são resumidas na Tabela 3.1.

Tabela 3.1: Vantagens e desvantagens dos equipamentos de medição da poluição do ar.

Equipamento	Vantagens	Desvantagens
Amostradores passivos	Custo muito baixo; muito simples de operar; não depende de energia elétrica; pode ser utilizado em grande número; muito útil para mapeamento espacial.	Inexistente para alguns poluentes; em geral, fornecem médias mensais ou semanais; trabalho intenso de desenvolvimento e análise; processamento lento de dados.
Amostradores ativos	Baixo custo; fácil operação; dados confiáveis; banco de dados histórico.	Fornecem médias diárias; trabalho intenso de coleta e análise em laboratório.
Analísadores automáticos	Alta eficiência; dados horários; informações <i>online</i> .	Complexos; alto custo; exigem especialização; alto custo de manutenção.
Sensores remotos	Dados integrados espacialmente; útil para medições próximas à fonte; medidas multi-componentes.	Muito complexos e caros; Difícil operar, calibrar e validar; não prontamente comparáveis com medidas pontuais; interferência das condições atmosféricas.

Fonte: WHO (2000).

Os amostradores passivos consistem em um corpo cilíndrico com uma extremidade aberta, protegida do vento por uma membrana, ou algo equivalente, para minimizar a interferência de partículas e difusão turbulenta; e outra fechada, para evitar transporte convectivo. Após o espaço de difusão, próximo a extremidade fechada, encontra-se um filtro com material absorvente, específico para cada poluente, que, posteriormente, é analisado em laboratório.

Nos amostradores ativos, certo volume de ar é sugado por uma bomba e passa através de um meio coletor químico ou físico por um determinado período de tempo (tipicamente, 24 horas para os poluentes em que o padrão legal é de 24 horas). A coleta pode ser feita por processo de absorção, adsorção, impactação, filtração, difusão, reação ou por uma combinação de dois ou mais desses processos. Posteriormente, as amostras são analisadas em laboratório para determinação da concentração do poluente de interesse. Os amostradores ativos mais utilizados são para medir SO_2 e MP, embora existam muitos métodos utilizados também para medir NO_2 , O_3 e Pb. O uso desse tipo de equipamento para o monitoramento de gases tem sido reduzido, com a substituição principalmente por analisadores automáticos. Os amostradores ativos para medição de MP podem ainda serem divididos em amostradores de grande volume (AGV), médio volume (AMV) e pe-

queno volume (APV), que variam basicamente em termos do volume de ar amostrado, e não em tamanho da partícula amostrada.

Os analisadores automáticos fornecem medidas com frequência de tempo relativamente alta. A amostra é analisada *on-line* e em tempo real por métodos eletroóticos (fluorescência no ultravioleta, quimiluminescência, absorção no infravermelho, absorção no ultravioleta etc.). As medidas obtidas pelos analisadores automáticos possuem alto grau de precisão, mas exigem um trabalho rigoroso de operação, manutenção e controle de qualidade dos dados gerados.

Os sensores remotos fornecem informações de concentração de poluentes em tempo real, por meio de técnicas de espectroscopia, sem a necessidade de contato direto com os elementos poluidores. São dispositivos capazes de detectar a radiação eletromagnética (microondas, infravermelho ou ultravioleta) proveniente de um poluente, transformá-la em um sinal elétrico e registrá-lo, de tal forma que esse possa ser armazenado ou transmitido em tempo real (PAYAN et al., 2005).

Além do monitoramento realizado por equipamentos, há, ainda, um método menos comum de avaliação da qualidade do ar utilizando bioindicadores. O biomonitoramento é um método experimental indireto de se verificar a existência de poluentes numa certa área, utilizando-se de organismos vivos, que respondem ao estresse a que se encontram submetidos por modificações nos ciclos vitais ou pela acumulação de poluentes (CARNEIRO, 2004).

3.3 Monitoramento da qualidade do ar em Uberlândia

3.3.1 Local do monitoramento

Segundo a US-EPA, o número mínimo de estações de monitoramento de MP_{10} é determinado em função do número de habitantes da cidade e da concentração atual do poluente (40 CFR, Parte 58, Apêndice D, Tabela D-4, revisado em 01/07/2003). De acordo com esse critério, o número mínimo de estações de monitoramento de MP_{10} para Uberlândia é 1 a 2 (população de 500.000-1.000.000 e concentração ambiente menor que 80% do padrão legal para o MP_{10}).

A escolha do local de amostragem foi baseada em um estudo prévio (BARBOSA et al., 2002) em que foram avaliadas cinco localidades: setor industrial (dois locais), estação climatológica da Uni-

versidade Federal de Uberlândia, centro da cidade e zona rural. Os resultados do referido estudo mostraram que as maiores concentrações de PTS foram obtidas no setor industrial e no centro da cidade, e que esse último possuía um nível de concentração de PTS estatisticamente equivalente ao do setor industrial. Considerando esses resultados, a intensa movimentação de veículos e de pedestres no centro da cidade e a existência de apenas um AGV-PTS e um AGV-MP₁₀, além da disponibilidade de energia elétrica e proteção contra vandalismo, ambos os equipamentos foram instalados no terminal rodoviário central em 2003 e permanecem nesse local até os dias atuais. A Figura 3.2 mostra a localização da estação de monitoramento de MP.

3.3.2 Equipamento de amostragem

O equipamento utilizado neste trabalho é um amostrador de grande volume (AGV) Andersen 1200 para partículas menores que 10 μm (AGV-MP₁₀), mostrado à esquerda na Figura 3.1. Apesar de a estação de monitoramento também possuir um AGV-PTS e um APV-MP_{2,5} (amostrador de pequenos volumes para partículas menores que 2,5 μm , instalado em julho de 2006), eles não foram objetos de estudo deste trabalho.



Figura 3.1: Amostradores de grandes volumes: AGV-MP₁₀ à esquerda e AGV-PTS à direita.

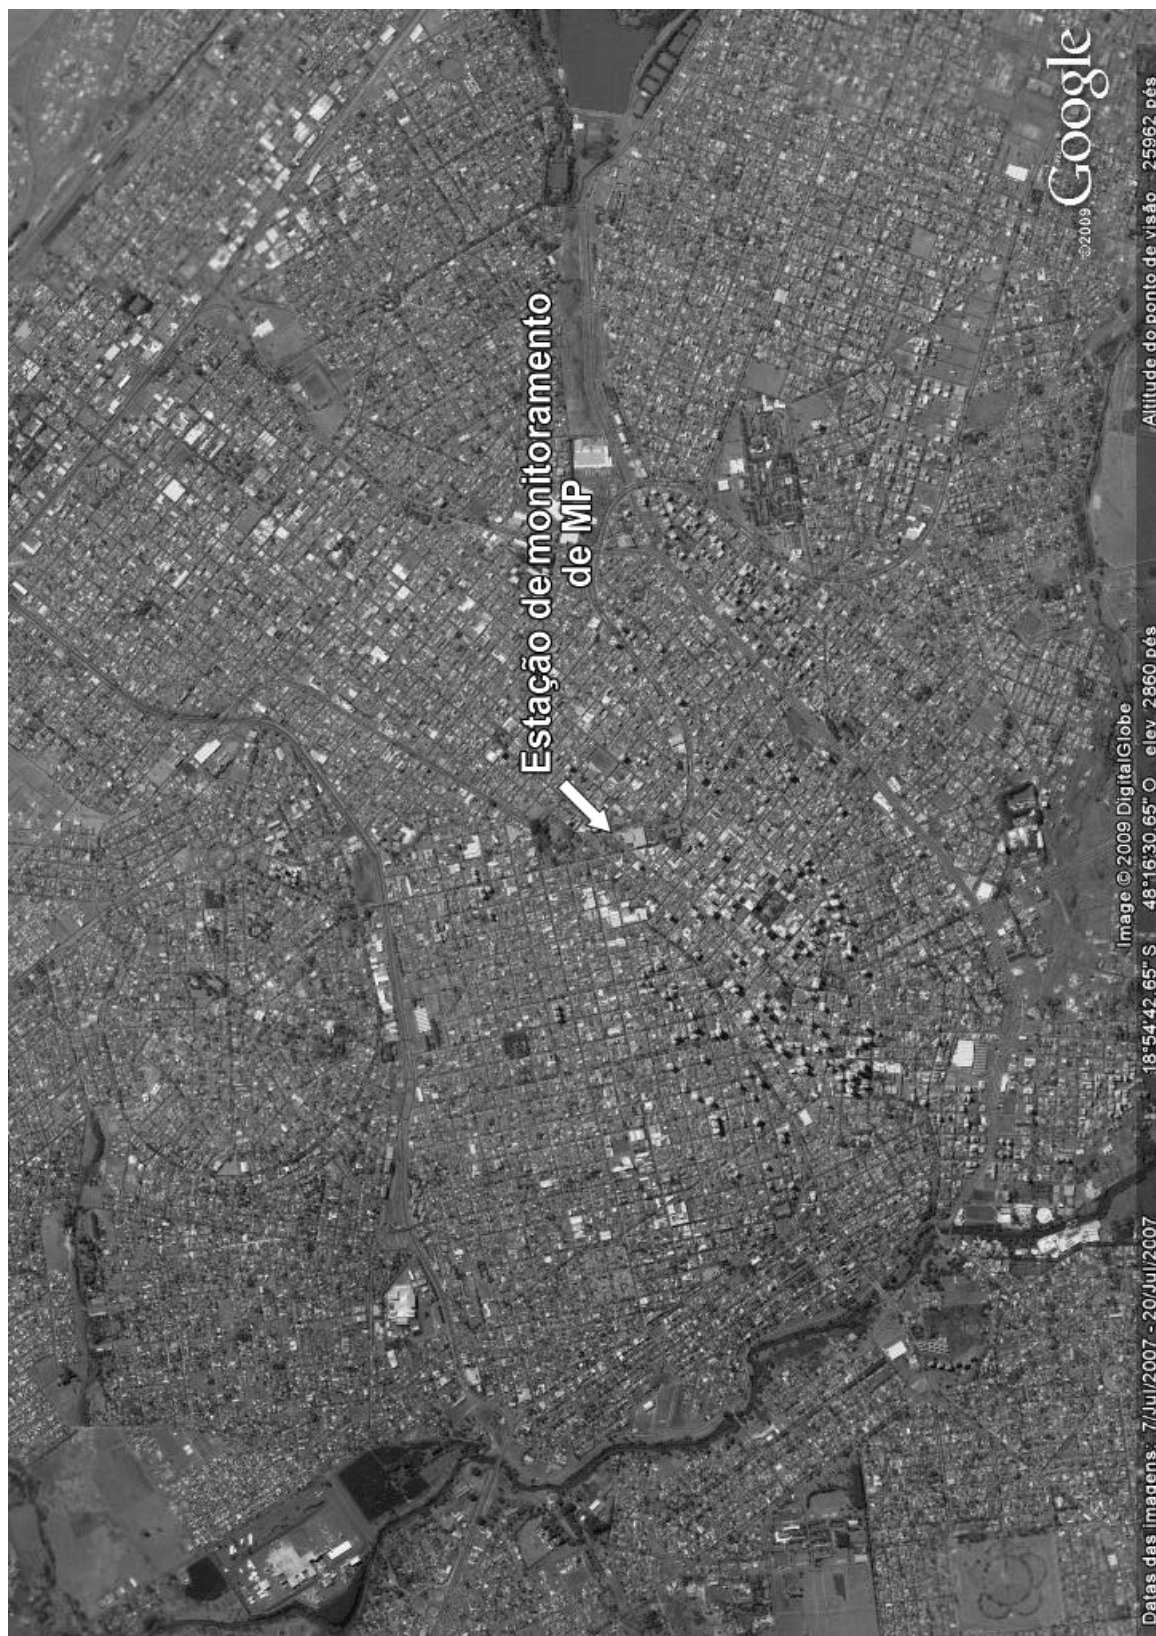


Figura 3.2: Localização da estação de monitoramento de MP.

O amostrador AGV-MP₁₀ é composto por um motor-aspirador a vazão constante e dotado de um cabeçote com separador inercial de um estágio. A Figura 3.3 mostra um esquema funcional do AGV-MP₁₀. O ar entra pelo cabeçote, que possui a região de entrada de 360°, de forma que a amostragem seja feita independentemente da direção do vento. O escoamento é acelerado por nove bocais que projetam o ar para a câmara de impactação inercial. Nesse local, o material particulado com diâmetro aerodinâmico superior a 10 μm é retido em uma placa untada com graxa de silicone. Com a primeira separação executada, o ar segue por dezesseis bocais de saída até encontrar o filtro posicionado na base do cabeçote, onde o MP₁₀ é retido. A Figura 3.4 mostra uma série de detalhes do cabeçote desmontado.

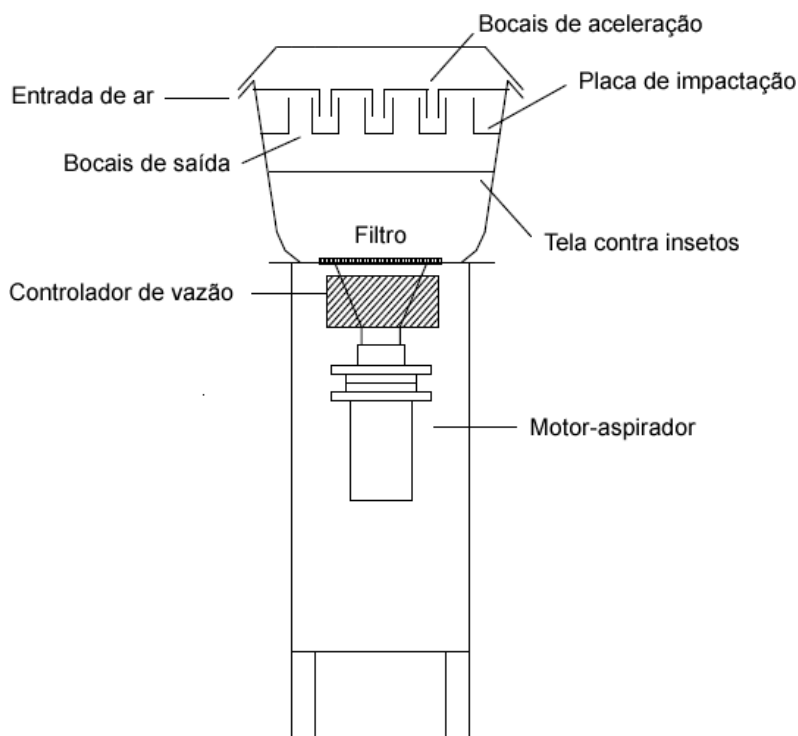


Figura 3.3: Esquema do AGV - MP₁₀.

A vazão de operação deve ser constante e igual a $1,13 \text{ m}^3/\text{min} \pm 10\%$, o que garante o diâmetro de corte de $10 \mu\text{m} \pm 0,5 \mu\text{m}$. De acordo com o manual do equipamento (ENERGÉTICA, 1999), para assegurar medidas precisas da concentração de MP₁₀, é necessário calibrar o amostrador: (a) pelo menos duas vezes ao ano; (b) após a troca de escovas ou motor; (c) após deslocamento do equipamento para outro local; ou (d) quando a vazão de operação estiver fora da faixa aceitável.

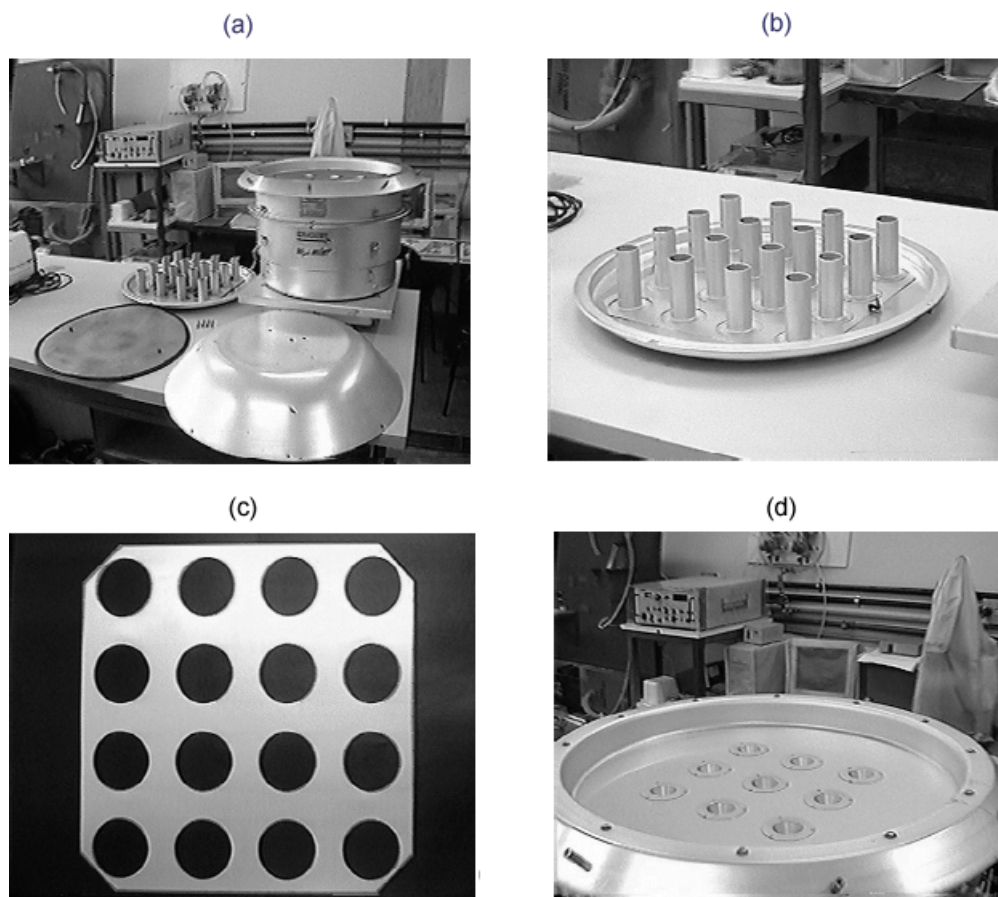


Figura 3.4: Detalhes do cabeçote desmontado: (a) cobertura contra chuva e tela contra insetos, (b) parte inferior da câmara de impactação (dezesesseis bocais de saída), (c) placa de impactação e (d) entrada da câmara de impactação (nove bocais aceleradores).

As operações de calibração e manutenção do AGV-MP₁₀ são realizadas conforme os procedimentos descritos no manual do equipamento (ENERGÉTICA, 1999) e na norma NBR 13412 (ABNT, 1995).

3.3.3 Operação de amostragem

As amostragens de MP₁₀ são realizadas em períodos de 24 horas, a cada três dias, de acordo com a norma NBR 13412 estabelecida pela ABNT (1995). Antes da amostragem, o filtro é numerado próximo à borda e fica por, no mínimo, 24 horas em um recipiente contendo sílica gel para equilíbrio de umidade. Após esse período, o filtro é pesado em uma balança analítica de precisão 0,1 mg, que fica dentro de uma câmara de pesagem. A massa inicial do filtro é anotada juntamente

com seu número de identificação. Os filtros são de fibra de vidro de dimensões 20,3 x 25,4 cm, e com eficiência de coleta de 99% para 0,3 μm .

No início da amostragem, o filtro e a carta gráfica são colocados no equipamento. A carta gráfica tem a função apenas de registrar eventuais anormalidades durante a operação de amostragem e, por esse motivo, é conhecida como registrador contínuo de eventos. Anota-se em um formulário o número de identificação do filtro, a leitura inicial do horâmetro, o nome do operador, a data e a hora inicial da amostragem. Liga-se o equipamento e, após cinco minutos de funcionamento (tempo suficiente para atingir equilíbrio térmico), anota-se também a pressão diferencial inicial através do filtro.

Alguns minutos antes de completar 24 horas de amostragem, a pressão diferencial final através do filtro é medida e anotada no formulário. Completadas as 24 horas, desliga-se o equipamento e anota-se no formulário a data e hora final da amostragem e a leitura final do horâmetro. O filtro e a carta gráfica são retirados do equipamento. A carta gráfica é anexada ao formulário. O filtro volta para o recipiente contendo sílica gel por, no mínimo, 24 horas e é, então, pesado novamente. Todos os filtros amostrados são guardados separadamente em sacos plásticos.

3.3.4 Cálculo da concentração de MP_{10}

A concentração do MP_{10} (expressa em $\mu\text{g}/\text{m}^3$ padrão) é determinada pela razão entre a massa de material particulado retida no filtro e o volume padrão total de ar amostrado (Equação 3.1).

$$\text{Conc. } \text{MP}_{10} = (10^6) \frac{(M_f - M_i)}{V_p} \quad (3.1)$$

sendo:

M_f - massa do filtro depois da amostragem, g;

M_i - massa do filtro antes da amostragem, g;

V_p - volume padrão total do ar amostrado, m^3 ;

10^6 - fator de conversão, $\mu\text{g}/\text{g}$.

O volume padrão total de ar amostrado, por sua vez, é dado pela Equação 3.2.

$$V_p = \bar{Q}_p t \quad (3.2)$$

em que \bar{Q}_p é vazão volumétrica padrão média (em m³/min) e t é o tempo total da amostragem (em min). A correção da vazão volumétrica média do período amostrado é uma exigência da norma NBR 13412 (ABNT, 1995).

As vazões volumétricas padrão (\bar{Q}_p) e real (\bar{Q}_a) são dadas pelas Equações 3.3 e 3.4, respectivamente.

$$\bar{Q}_p = \bar{Q}_a \left(\frac{P_m}{760 \text{ mmHg}} \right) \left(\frac{298 \text{ K}}{T_m} \right) \quad (3.3)$$

$$\bar{Q}_a = \frac{1}{a_2} \left(\frac{\bar{P}_o}{P_m} - b_2 \right) \sqrt{T_m} \quad (3.4)$$

sendo:

\bar{P}_o - pressão de estagnação absoluta média durante o período de amostragem, mmHg;

P_m - pressão ambiente média durante o período de amostragem, mmHg;

T_m - temperatura ambiente média durante o período de amostragem, K;

a_2 - inclinação da relação de calibração do amostrador;

b_2 - intersecção da relação de calibração do amostrador.

A pressão de estagnação absoluta média durante o período de amostragem (\bar{P}_o) é dada por:

$$\bar{P}_o = P_m - \overline{dH}_f \quad (3.5)$$

em que \overline{dH}_f é a média aritmética das pressões diferenciais através do filtro do início e do fim da amostragem.

MODELAGEM MATEMÁTICA DA QUALIDADE DO AR

4.1 Introdução

Modelagem matemática é a área do conhecimento que estuda meios de desenvolver e implementar modelos matemáticos de sistemas reais. Existem várias técnicas de modelagem e, neste trabalho, foi utilizada a modelagem do tipo caixa-preta. Uma das características da modelagem caixa-preta, também conhecida como modelagem empírica, é que pouco ou nenhum conhecimento prévio do sistema é necessário. O que se pretende descrever com tais modelos são as relações de causa e efeito entre as variáveis de entrada e de saída. De maneira geral, os modelos caixa-preta são obtidos com maior facilidade. Entretanto, o sucesso de tais modelos depende fortemente da qualidade dos dados usados. Pode-se dizer que bons modelos caixa-preta só são possíveis, se os dados utilizados contiverem toda a informação a respeito do sistema que se deseja modelar.

Este capítulo faz uma breve revisão acerca de dois tipos de modelos caixa-preta: redes neurais artificiais e modelos lineares. As redes neurais têm sido utilizadas para a previsão da concentração de uma gama de poluentes atmosféricos, tais como MP_{10} (JIANG et al., 2004; SLINI et al., 2006;

KUKKONEN et al., 2003; PEREZ; REYES, 2002; GRIVAS; CHALOULAKOU, 2006), $MP_{2,5}$ (ORDIERES et al., 2005) SO_2 (JIANG et al., 2004), NO_2 (JIANG et al., 2004; AGIRRE-BASURKO et al., 2006; KOLEHMAINEN et al., 2001; KUKKONEN et al., 2003) e O_3 (AGIRRE-BASURKO et al., 2006; GUARDANI et al., 1999), em várias cidades do mundo, apresentando, em muitos casos, boa concordância com os dados experimentais. Os modelos lineares são usados, neste trabalho, como uma novidade, uma vez que não foram encontrados na literatura outros trabalhos que utilizassem esses modelos para a previsão da concentração de poluentes atmosféricos.

4.2 Redes neurais artificiais

A Rede Neural Artificial (RNA) pode ser definida, segundo Alekxander e Morton (1990), como um processador paralelamente distribuído constituído de unidades de processamento simples, que tem a propensão natural de armazenar conhecimento experimental e posteriormente torná-lo disponível para o uso. Uma RNA assemelha-se ao cérebro em dois aspectos: o conhecimento é adquirido pela rede por meio de um processo de aprendizagem; e forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

A capacidade de aprender a partir de exemplos e de generalizar a informação aprendida é, sem dúvida, o atrativo principal da solução de problemas por intermédio de RNAs. A generalização, que está associada à capacidade da rede aprender com base em um conjunto reduzido de exemplos e, posteriormente, dar respostas coerentes para dados não conhecidos, é uma demonstração de que a capacidade das RNAs vai muito além do que simplesmente mapear relações entre variáveis de entrada e saída. As RNAs são capazes de extrair informações não apresentadas de forma explícita por meio dos exemplos. Não obstante, as RNAs são capazes de atuar como aproximadoras universais de funções multivariáveis com custo computacional que cresce apenas linearmente com o número de variáveis.

4.2.1 Neurônio artificial

O modelo matemático de um neurônio artificial foi idealizado pelos pesquisadores McCulloch e Pitts (MCCULLOCH; PITTS, 1943) a partir do neurônio biológico. O neurônio artificial é uma unidade de processamento matematicamente simples, que recebe uma ou mais entradas e as transforma em saída. A Figura 4.1 mostra um esquema de um neurônio artificial.

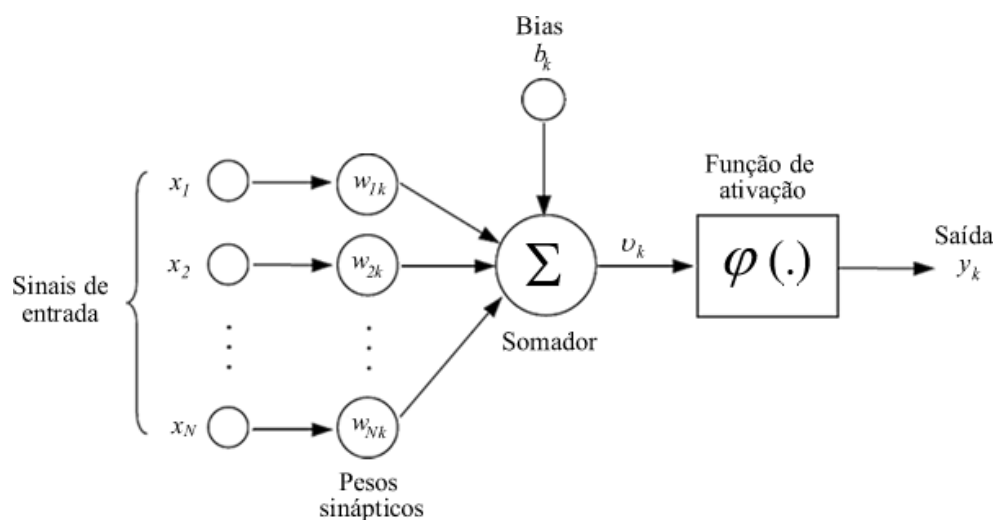


Figura 4.1: Modelo de um neurônio artificial.

Fonte: Haykin (1994), adaptado.

Com base na Figura 4.1, é possível distinguir alguns elementos considerados importantes na estrutura de um neurônio:

1. as sinapses, que são caracterizadas por um peso w . O papel do peso w_{jk} é multiplicar o sinal x_j na entrada da sinapse j , conectada a um neurônio k . O peso w_{jk} é positivo se a sinapse associada é excitatória e negativo se a sinapse associada é inibitória;
2. um combinador linear, que soma os sinais de entradas, ponderados pelos seus pesos respectivos;
3. uma função de ativação, que restringe a amplitude do sinal de saída do neurônio a um intervalo fechado, geralmente $[0,1]$ ou $[-1,1]$;

Em termos matemáticos, podemos descrever um neurônio k com as seguintes equações:

$$u_k = \sum_{j=1}^N w_{jk} x_j \quad (4.1)$$

$$\nu_k = b_k + u_k \quad (4.2)$$

$$y_k = \varphi(\nu_k) \quad (4.3)$$

sendo x_1, x_2, \dots, x_N os sinais de entrada, $w_{1k}, w_{2k}, \dots, w_{Nk}$ os pesos sinápticos, u_k a saída do combinador linear devido aos sinais de entrada, b_k o *bias* que tem o papel de aumentar ou diminuir a entrada da função de ativação, ν_k o potencial de ativação do neurônio k , φ a função de ativação e y_k o sinal de saída do neurônio.

4.2.2 Funções de ativação

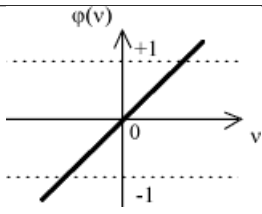
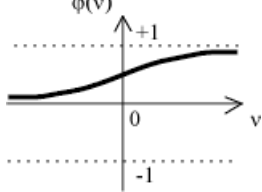
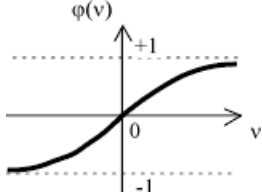
A função de ativação, $\varphi(\cdot)$, define a saída do neurônio em termos do nível de atividade do mesmo. Dentre as principais funções de ativação estão:

1. Função linear - não é limitada. Neurônios com essa função de ativação podem ser utilizados como aproximadores lineares;
2. Função logística sigmoideal - assume um intervalo contínuo de valores entre 0 e +1. É a função geralmente adotada em redes neurais em virtude de ser contínua, estritamente crescente¹, não linear e facilmente diferenciável em qualquer ponto;
3. Função tangente hiperbólica - possui as mesmas características da função logística sigmoideal, entretanto, se estende de -1 a +1, possibilitando que as saídas sejam simétricas.

A Tabela 4.1 apresenta as expressões matemáticas das funções de ativação listadas anteriormente e seus respectivos gráficos, demonstrando o seu comportamento.

¹Uma função é dita estritamente crescente se $x < y \Rightarrow f(x) < f(y)$.

Tabela 4.1: Funções de ativação.

Função	Equação	Gráfico
Função linear	$\varphi(\nu) = \nu$	
Função logística sigmoideal	$\varphi(\nu) = \frac{1}{1 + \exp(-a\nu)}$	
Função tangente hiperbólica	$\varphi(\nu) = \tanh\left(\frac{\nu}{2}\right) = \frac{1 - \exp(-\nu)}{1 + \exp(-\nu)}$	

4.2.3 Rede *perceptron* multicamadas

A rede *perceptron* multicamadas, ou MLP (*multilayer perceptron*), consiste de uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída (Figura 4.2). Excluindo a camada de entrada, todas as outras camadas são constituídas por neurônios. O sinal de entrada se propaga para frente através da rede camada por camada, ou seja, é uma rede do tipo *feedforward*.

A saída de um *perceptron* multicamadas pode ser expressa pela Equação 4.4 como segue:

$$y_k^s = \varphi_k^s \left[b_k^s + \sum_{i=1}^M w_{ik}^s \varphi_i^o \left(b_i^o + \sum_{j=1}^N w_{ji}^o x_j \right) \right] \quad (4.4)$$

na qual o denota o elemento da camada oculta e s indica o elemento da camada de saída; w_{ji}^o é o peso que conecta o neurônio j da camada de entrada com o neurônio i da camada oculta; w_{ik}^s é o peso que conecta o neurônio i da camada oculta com o neurônio k da camada de saída; φ_i^o é a função de transferência do neurônio i da camada oculta; φ_k^s é a função de transferência do neurônio k da camada de saída; b_i^o é o bias do neurônio i da camada oculta; b_k^s é o bias do neurônio k da camada de saída; y_k^s é a saída do neurônio k da camada de saída e x_j é a entrada do neurônio j da camada de entrada.

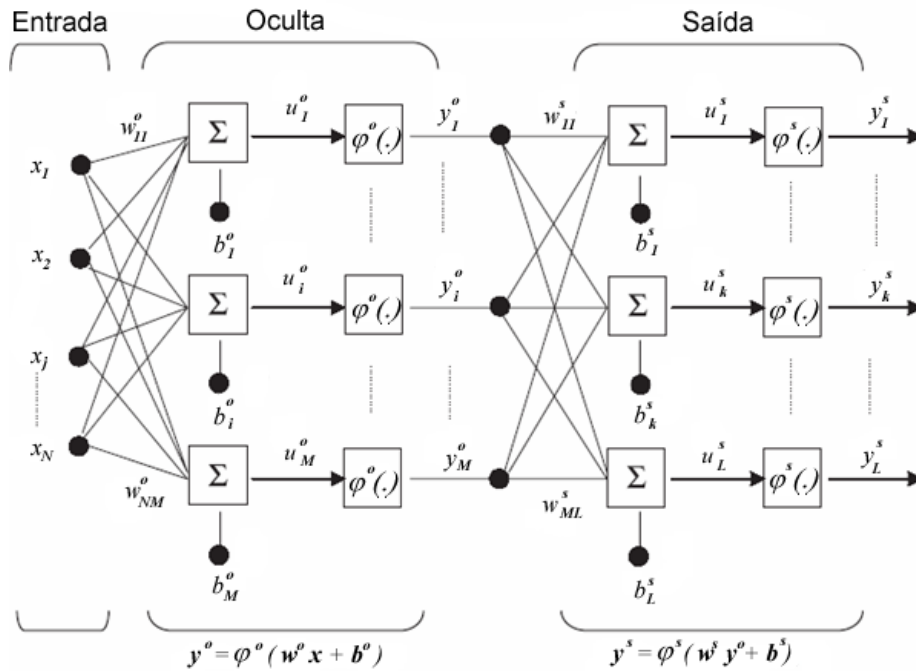


Figura 4.2: Modelo baseado em um *perceptron* multicamadas.

Fonte: Agirre-Basurko et al. (2006), adaptado.

Segundo (CYBENKO, 1989), uma rede com uma camada intermediária pode implementar qualquer função contínua e a utilização de duas camadas intermediárias permite a aproximação de qualquer função matemática (CYBENKO, 1988). Deve ser observado, contudo, que, em alguns casos, a utilização de duas ou mais camadas intermediárias pode facilitar o treinamento da rede. A utilização de um grande número de camadas intermediárias não é recomendada, pois cada vez que o erro medido durante o treinamento é propagado para a camada anterior, ele se torna menos útil ou preciso. A única camada que tem uma noção precisa do erro cometido pela rede é a de saída. Dentre as intermediárias, a última recebe apenas uma estimativa sobre o erro. A penúltima, uma estimativa da estimativa e assim por diante.

Com relação ao número de neurônios nas camadas intermediárias, esse é em geral definido empiricamente e depende fortemente da distribuição dos padrões de treinamento e validação da rede. Devem-se ter dois cuidados: primeiro, não utilizar unidades demais, que podem levar a rede a memorizar os padrões de treinamento em vez de extrair as características gerais que permitirão a generalização ou o reconhecimento de padrões não vistos durante o treinamento, problema chamado de *overfitting*; e segundo, não usar um número muito pequeno, que pode forçar a rede a

gastar tempo em excesso tentando encontrar uma representação ótima, ou seja, a rede não converge durante seu treinamento, problema que é chamado de *underfitting*.

4.2.4 Algoritmo *backpropagation*

O algoritmo *backpropagation* (RUMELHART; MCCLELLAND, 1986) é considerado o mais popular, no que se refere ao aprendizado de redes MLPs. Essa popularidade resulta, sobretudo, de sua relativa simplicidade de implementação e de sua eficiência. O algoritmo *backpropagation* utiliza pares (entrada, saída desejada) para ajustar os pesos da rede por meio da regra de correção de erro. O treinamento ocorre em duas fases nas quais cada fase percorre a rede em um sentido. Essas duas fases são chamadas de *forward* e *backward*. A fase *forward* é utilizada para definir a saída da rede para um dado padrão de entrada. Já a fase *backward* utiliza a saída desejada e a saída fornecida pela rede para atualizar os pesos de suas conexões. A Figura 4.3 ilustra estas duas fases.

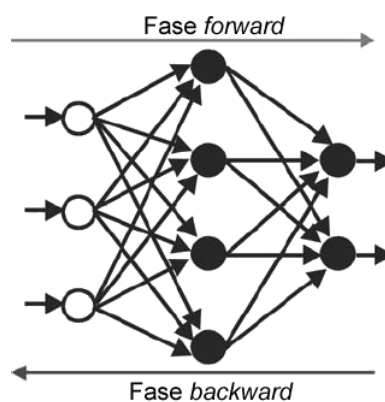


Figura 4.3: Fluxo de processamento do algoritmo *backpropagation*.

Fonte: Henrique (2005).

A fase *forward* envolve os seguintes passos:

1. A entrada é apresentada à primeira camada da rede, a camada C^0 ;
2. Calcula-se a saída de cada neurônio da próxima camada C^i ($i > 0$) a partir da saída da camada anterior C^{i-1} . Estas saídas servirão como entrada para a camada C^{i+1} ;
3. O passo 2 repete-se até a última camada;

4. As saídas produzidas pelos neurônios da última camada são comparadas com as saídas desejadas.

A fase *backward* envolve as etapas listadas a seguir:

1. Os erros de cada neurônio da camada de saída são calculados;
2. Os pesos de cada neurônio da camada de saída são ajustados de forma a reduzir seus erros;
3. Em seguida, o erro de cada neurônio das camadas intermediárias C^i é calculado, utilizando os erros dos neurônios da camada seguinte C^{i+1} conectados a ele, e ponderados pelos pesos das conexões entre eles;
4. O passo 3 repete-se até a primeira camada.

O algoritmo *backpropagation*, que faz uso dessas duas fases é apresentado a seguir:

1. Inicializar pesos e parâmetros;
2. Para cada padrão de treinamento:
 - a) Calculam-se as saídas da rede através da fase *forward*;
 - b) Comparam-se as saídas produzidas com as saídas desejadas;
 - c) Atualizam-se os pesos dos neurônios através da fase *backward*.
3. Após a rede ser apresentada a todos os padrões, uma nova iteração é iniciada voltando-se ao item 2;
4. As iterações continuam até que o erro seja mínimo ou que um número máximo de iterações seja alcançado.

O sinal de erro na saída do neurônio k , na iteração n , é definido por:

$$e_k(n) = d_k(n) - y_k(n) \quad (4.5)$$

na qual d_k é a saída desejada para o neurônio k e y_k é dado pela Equação (4.3).

Embora o erro total E seja definido pela soma dos erros dos neurônios da camada de saída para todos os padrões contidos no conjunto de treinamento, será considerado, sem perda de generalidade, que a minimização do erro para cada padrão individualmente levará a minimização do erro total. Assim, o erro passa a ser definido por:

$$E(n) = \frac{1}{2} \sum_{k=1}^L e_k^2(n) \quad (4.6)$$

O algoritmo *backpropagation* aplica uma correção $\Delta w_{jk}(n)$ ao peso sináptico $w_{jk}(n)$, que é definida pela regra delta (WIDROW; HOFF Jr., 1960) por:

$$\Delta w_{jk}(n) = -\eta \frac{\partial E(n)}{\partial w_{jk}(n)} \quad (4.7)$$

ou

$$w_{jk}(n+1) = w_{jk}(n) - \eta \frac{\partial E(n)}{\partial w_{jk}(n)} \quad (4.8)$$

sendo η denominado de taxa de aprendizagem. O uso do sinal negativo na Equação 4.7 indica a descida do gradiente no espaço dos pesos (isto é, busca uma direção para a mudança de pesos que reduza o valor de $E(n)$). Quanto menor for η , mais suaves serão as variações dos pesos sinápticos da rede, de uma iteração para outra. Por outro lado, se η for grande, para acelerar a taxa de aprendizagem, as grandes modificações nos pesos sinápticos podem tornar a rede instável.

Para melhor compreensão do processo de aprendizado, pode-se supor, por exemplo, que cada combinação de pesos e *bias* corresponda a um ponto na superfície de solução. Considerando-se que a altura de um ponto é diretamente proporcional ao erro associado a esse ponto, a solução está, portanto, nos pontos mais baixos da superfície. O algoritmo *backpropagation* procura minimizar o erro obtido pela rede ajustando pesos e *bias* para que eles correspondam às coordenadas dos pontos mais baixos da superfície do erro.

O gradiente de uma função está na direção e sentido em que a função tem taxa de variação máxima. Isso garante que a rede caminha na superfície na direção que vai reduzir mais o erro obtido. Para superfícies simples, esse método certamente encontra a solução com erro mínimo. Para superfícies mais complexas, tal garantia não mais existe, podendo levar o algoritmo a convergir para mínimos locais. O algoritmo *backpropagation* fornece uma aproximação da trajetória no espaço de pesos calculado pelo método do gradiente descendente. Esses pontos ou áreas podem incluir platôs, mínimos locais ou arestas. A Figura 4.4 ilustra mínimos locais e platôs.

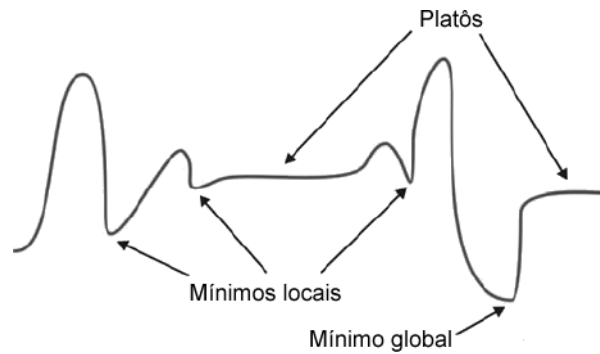


Figura 4.4: Exemplo de mínimos locais e platôs em uma superfície de erro.

Fonte: Henrique (2005).

Entre as várias técnicas utilizadas para acelerar o processo de treinamento e evitar mínimos locais, a adição do termo *momentum* (RUMELHART; MCCLELLAND, 1986) é uma das mais frequentes. Sua grande utilização é influenciada por ser ela uma técnica simples e efetiva. Com a adição do *momentum* (α), Δw_{ij} passa a ser dado por:

$$w_{jk}(n+1) = w_{jk}(n) - \eta \frac{\partial E(n)}{\partial w_{jk}(n)} + \alpha[w_{ji}(n) - w_{ji}(n-1)] \quad (4.9)$$

Evidências práticas mostram que a inclusão do termo *momentum* na fórmula de ajuste dos pesos aumenta a velocidade de aprendizado reduzindo o perigo de instabilidade. O termo *momentum* pode acelerar o treinamento em regiões muito planas da superfície de erro, os chamados platôs. Além disso, ele suprime a oscilação de pesos em vales e ravinas. A Figura 4.5 ilustra o efeito da utilização do termo de *momentum* no caminho seguido pela rede durante seu aprendizado.

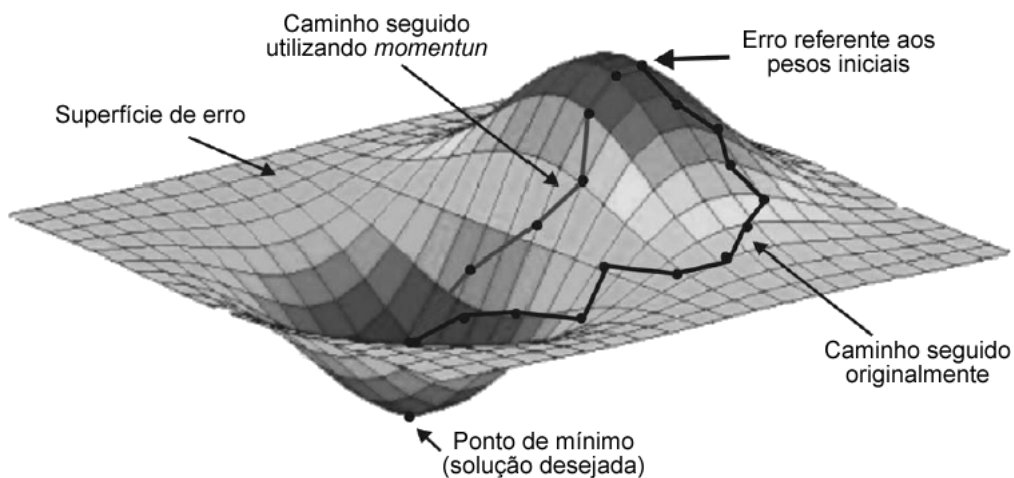


Figura 4.5: Influência do termo *momentum*.

Fonte: Henrique (2005).

4.2.5 Processamento temporal

Muitos algoritmos de treinamento de RNAs não são capazes de implementar mapeamentos dinâmicos como, por exemplo, o algoritmo *backpropagation*, que pode implementar apenas mapeamentos estáticos. Para que uma RNA seja dinâmica, é preciso que possua memória (ELMAN, 1990) cujo papel principal da memória é transformar uma rede estática em uma rede dinâmica. Ao incorporar memória na estrutura de uma rede estática, tal como uma MLP, a saída da rede torna-se uma função do tempo. Nesse sentido, consegue-se uma representação de um sistema dinâmico não linear porque a rede estática provê a não linearidade e a memória provê o comportamento temporal.

Existem basicamente duas maneiras de prover memória a uma RNA: introduzir atraso no tempo e utilizar redes recorrentes. Introduzir atraso no tempo como a técnica TDNN (*Time Delay Neural Network*) (LANG; HINTON, 1988) é a forma usual de fazer uma rede neural aprender padrões temporais. Nesse caso, o sistema dinâmico não linear na forma discreta é dado por:

$$y(t+1) = f[y(t), y(t-1), \dots, y(t-n_y), u(t), u(t-1), \dots, u(t-n_u)] \quad (4.10)$$

na qual n_y e n_u são os atrasos das saídas e entradas, respectivamente.

Nessa representação, a principal vantagem está associada à simplicidade do treinamento, pois pode-se usar, por exemplo, o algoritmo *backpropagation*. Entretanto, deve-se ter o cuidado para não ocorrer *overfitting*, pois o número de entradas da rede aumenta com n_y e n_u , o que aumenta muito a dimensão da rede.

4.3 Modelos lineares

Os modelos lineares pertencem a uma classe de modelos freqüentemente utilizada na área de controle de processos industriais, que são capazes de estabelecer relações de causa e efeito entre variáveis de entrada e saída, conforme a Equação 4.11 (LJUNG, 1999; AGUIRRE, 2004).

$$A(q)y(t) = \frac{B(q)}{F(q)}u(t-nk) + \frac{C(q)}{D(q)}e(t) \quad (4.11)$$

sendo $u(t)$ e $y(t)$ os vetores de entrada e saída, respectivamente, nk o atraso no tempo e $e(t)$ um ruído branco. Os polinômios A , B , C , D e F são dados por:

$$\begin{aligned} A(q) &= 1 + a_1 q^{-1} + \dots + a_{n_a} q^{-n_a} \\ B(q) &= b_1 q^{-1} + \dots + b_{n_b} q^{-n_b} \\ C(q) &= 1 + c_1 q^{-1} + \dots + c_{n_c} q^{-n_c} \\ D(q) &= 1 + d_1 q^{-1} + \dots + d_{n_d} q^{-n_d} \\ F(q) &= 1 + f_1 q^{-1} + \dots + f_{n_f} q^{-n_f} \end{aligned} \quad (4.12)$$

sendo n_a , n_b , n_c , n_d , e n_f as ordens dos polinômios e q^{-1} o operador de atraso, de forma que

$$q^{-1}y(t) = y(t-1) \quad (4.13)$$

A partir do modelo geral dado pela Equação 4.11, podem-se obter 32 modelos diferentes, dependendo de quais dos cinco polinômios sejam utilizados (LJUNG, 1999). Contudo, neste trabalho, apenas quatro modelos são usados, a saber:

1. **ARX** - o modelo auto-regressivo com entradas exógenas (ARX do Inglês *autoregressive with exogenous inputs*) pode ser obtido tomando-se $C(q) = D(q) = F(q) = 1$.

$$A(q)y(t) = B(q)u(t - nk) + e(t) \quad (4.14)$$

2. **ARMAX** - o modelo auto-regressivo com média móvel e entradas exógenas (ARMAX do Inglês *autoregressive moving average with exogenous inputs*) pode ser obtido tomando-se $D(q) = F(q) = 1$.

$$A(q)y(t) = B(q)u(t - nk) + C(q)e(t) \quad (4.15)$$

3. **Erro na saída** - o modelo erro na saída (OE) pode ser obtido tomando-se $A(q) = C(q) = D(q) = 1$.

$$y(t) = \frac{B(q)}{F(q)}u(t - nk) + e(t) \quad (4.16)$$

4. **Box-Jenkins** - o modelo Box-Jenkins (BJ) pode ser obtido tomando-se $A(q) = 1$.

$$y(t) = \frac{B(q)}{F(q)}u(t - nk) + \frac{C(q)}{D(q)}e(t) \quad (4.17)$$

4.4 Indicadores de desempenho

4.4.1 Seleção da estrutura dos modelos

Na seleção da estrutura dos modelos da Seção 5.2.4 (ordens dos polinômios/número de neurônios e os atrasos no tempo na seção), foram utilizados os seguintes índices: critério de informação de Akaike (AIC), erro final de predição (FPE) e critério de informação de Bayes (BIC), definidos nas Equações 4.18, 4.19 e 4.20. Esses critérios quantificam a diminuição da variância dos resíduos resultantes da inclusão de um termo (aumento do número de parâmetros), e ao mesmo tempo, penaliza a inclusão de cada termo.

$$AIC(n_\theta) = N \ln[\sigma_{\text{erro}}^2(n_\theta)] + 2n_\theta \quad (4.18)$$

$$BIC(n_\theta) = N \ln[\sigma_{\text{erro}}^2(n_\theta)] + n_\theta \ln N \quad (4.19)$$

$$FPE(n_\theta) = N \ln[\sigma_{\text{erro}}^2(n_\theta)] + N \ln \left[\frac{N + n_\theta}{N - n_\theta} \right] \quad (4.20)$$

sendo N o número de dados, $\sigma_{\text{erro}}^2(n_\theta)$ a variância do erro de modelagem (erro de predição um passo à frente ou resíduos) e n_θ o número de parâmetros do modelo.

Esses índices, normalmente, atingem um mínimo para um determinado número de parâmetros no modelo. Do ponto de vista do critério usado, esse número de parâmetros é ótimo. Todavia, tal critério é fundamentalmente estatístico e não garante, necessariamente, que o modelo com o número “ótimo” de termos seja um modelo válido (AGUIRRE, 2004).

4.4.2 Desempenho dos modelos

Para comparar o desempenho dos modelos, foram utilizados três indicadores estatísticos. Um deles é a raiz quadrada do erro médio quadrático (*RMSE*), calculado de acordo com a Equação 4.21, que mede os desvios entre os valores observados e preditos pelos modelos. Quanto menor esse índice, mais próximos estarão os valores preditos dos observados.

$$RMSE = \left[\frac{1}{N} \sum_{i=1}^N (P_i - O_i)^2 \right]^{\frac{1}{2}} \quad (4.21)$$

na qual N é o número de observações, O_i é o valor observado e P_i é o valor predito.

O coeficiente de determinação (R^2), definido pela Equação 4.22, informa quanto da variabilidade da variável observada é explicada pelo modelo. Apesar de suas deficiências em algumas situações (WILLMOTT, 1982), essa medida foi usada a fim de comparar os resultados deste trabalho com outros estudos.

$$R^2 = \frac{\sum_{i=1}^N (P_i - \bar{O})^2}{\sum_{i=1}^N (O_i - \bar{O})^2} \quad (4.22)$$

na qual \bar{O} é a média dos valores observados.

Uma medida relativa de erro denominada índice de concordância (d) foi calculada de acordo com Equação 4.23. Essa é uma medida adimensional limitada ao intervalo 0-1, em que o valor 1 representa o completo ajuste do modelo, enquanto o valor 0 indica o oposto.

$$d = 1 - \frac{\sum_{i=1}^N (P_i - O_i)^2}{\sum_{i=1}^N (|P_i| + |O_i|)^2} \quad (4.23)$$

sendo $P'_i = P_i - \bar{O}$ e $O'_i = O_i - \bar{O}$.

RESULTADOS E DISCUSSÃO

5.1 Caracterização geral das variáveis dos modelos

5.1.1 Variáveis meteorológicas

O nível de concentração de MP_{10} suspenso na atmosfera está fortemente relacionado com as condições meteorológicas. A dinâmica das massas de ar é, sem dúvida, o fator decisivo das condições meteorológicas de um local. Evidentemente, outros fatores são também importantes, a saber: latitude, altitude, forma e disposição do relevo, vegetação e outros.

A cidade de Uberlândia localiza-se na região do Triângulo Mineiro, no Estado de Minas Gerais, na intersecção das coordenadas geográficas $18^{\circ} 55' 23''$ de latitude Sul e $48^{\circ} 17' 19''$ de longitude Oeste de *Greenwich*, ocupando uma área de 219 km^2 dentro de um município de 4.115 km^2 (SILVA; ASSUNCAO, 2004). O município de Uberlândia está situado no domínio dos Planaltos e Chapadas da Bacia Sedimentar do Paraná, recoberto pelo cerrado, apresentando extensas áreas com superfícies aplainadas, levemente onduladas, e com altitude média de 865 m (MENDES, 2001).

O clima da região do Triângulo Mineiro, segundo a classificação climática de Köppen, é do tipo Aw, ou seja, possui inverno seco e verão chuvoso. A dinâmica atmosférica em Uberlândia está sob o controle principalmente dos sistemas intertropicais, cuja participação no transcorrer do ano é superior a 50%, completada com a atuação dos sistemas polares, cuja participação é pouco superior a 25%. As atuações desses sistemas de circulação ocasionam sobre Uberlândia a formação de um clima tropical alternadamente seco e úmido (SILVA; ASSUNCAO, 2004).

Dada a posição geográfica da cidade de Uberlândia, normalmente ela é atingida por massas de ar oriundas do sul (Frente Polar Antártica e Massa Polar), do leste (ondas de leste) e do oeste (Linhas de Instabilidade Tropical). Também sofre influência das Zonas de Convergência do Atlântico Sul (ZCAS), que são responsáveis pelas chuvas intensas e prolongadas. A Frente Polar Antártica influencia a ZCAS, canalizando a umidade da Amazônia para a região sudeste. Desse modo, a sazonalidade existente entre os períodos chuvosos e quentes, frios e secos, durante o ano, se deve à alternância de atuação dessas massas, que impõem à cidade de Uberlândia uma característica climática tida como tropical alternadamente úmida e seca. Uma análise mais aprofundada sobre a dinâmica climática na cidade de Uberlândia foi realizada por Mendes (2001).

Neste trabalho foram utilizados dados meteorológicos do período de 2003 a 2007 obtidos junto à Estação Climatológica da Universidade Federal de Uberlândia (altura do anemômetro: 12 metros). A estação localiza-se a aproximadamente dois quilômetros de distância do local de amostragem de MP₁₀ (Figura 5.1). Os dados referentes à temperatura (°C), precipitação (mm), umidade relativa (%), nebulosidade (%), direção do vento (graus, 0 para norte) e velocidade do vento (m/s) são coletados diariamente, em três horários predeterminados, a saber: 9, 15 e 21 horas (horário de Brasília). Já os dados de insolação (h) referem-se ao acumulado do dia e são coletados diariamente no período da noite (às 21h). A variável insolação foi usada em substituição a variável radiação, uma vez que os dados utilizados neste trabalho são de uma estação manual que não possui dados de radiação. Embora a Estação Climatológica da Universidade Federal de Uberlândia possua uma estação automática desde 2006, optou-se por utilizar dados da estação manual por essa possuir dados a partir de 2003.



Figura 5.1: Localização da Estação Climatológica da Universidade Federal de Uberlândia.

Tanto no desenvolvimento dos modelos quanto na análise das variáveis apresentada a seguir, foram calculadas médias diárias para a temperatura, umidade relativa, nebulosidade, direção e velocidade do vento. No caso da precipitação somaram-se os valores dos dois últimos períodos do dia anterior e o primeiro do dia em questão, obtendo-se um valor total diário. No Apêndice A.1 estão as médias mensais, anuais e do período de todas as variáveis meteorológicas analisadas.

A temperatura média no período de 2003 a 2007 foi de $23,7^{\circ}\text{C}$. No ano de 2007, registrou-se a maior média anual ($24,2^{\circ}\text{C}$) e, em 2004, a menor média anual ($23,4^{\circ}\text{C}$). A temperatura média desse período é superior à média encontrada em um estudo sobre o clima da cidade de Uberlândia realizado por Silva e Assuncao (2004), que consideraram o período de 1981 a 2003. No trabalho citado a temperatura média do período foi de $22,3^{\circ}\text{C}$. A Figura 5.2 exhibe as temperaturas médias mensais do período abordado. Os meses de setembro e outubro foram os mais quentes, com temperatura média igual ou superior a $25,1^{\circ}\text{C}$. Por outro lado, os meses mais frios foram junho e julho, com temperatura média inferior a $21,4^{\circ}\text{C}$.

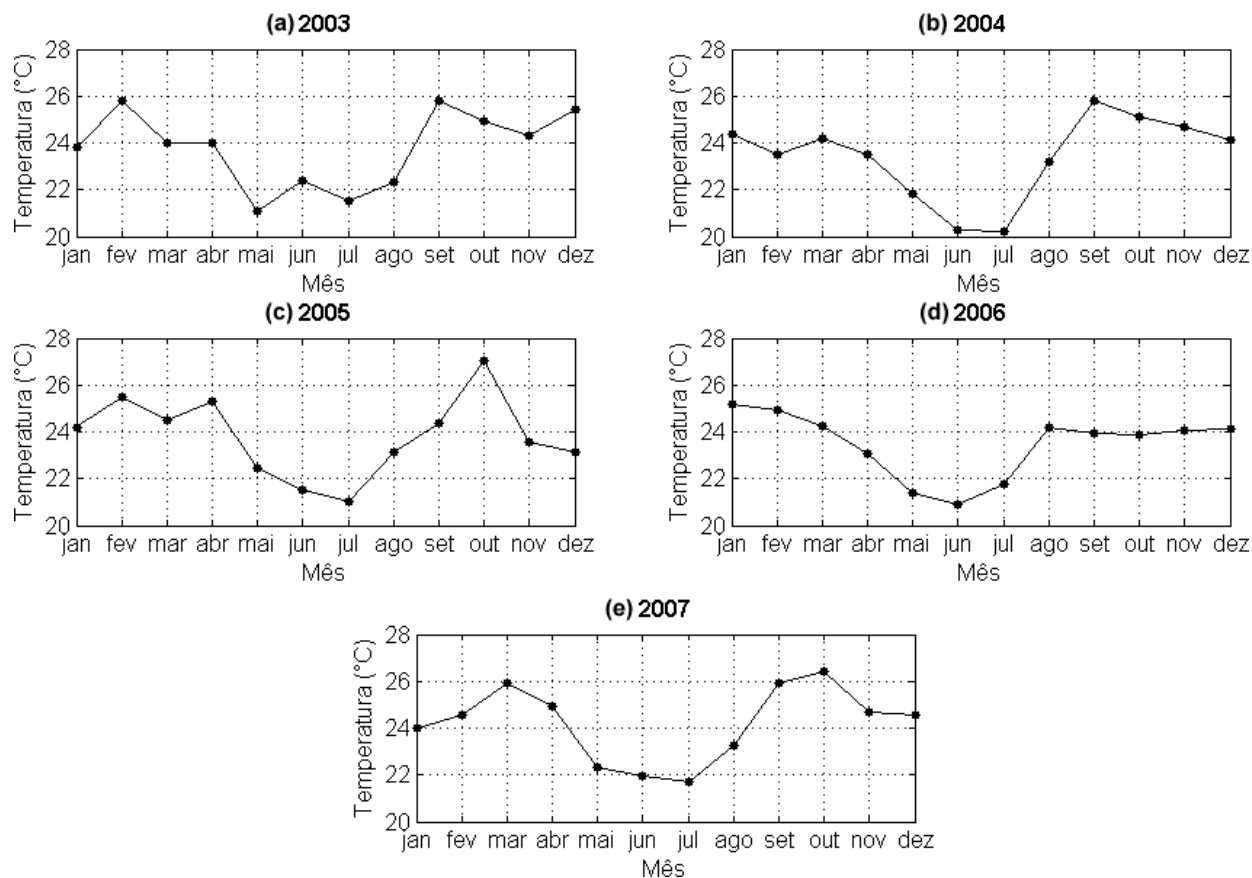


Figura 5.2: Temperatura média mensal: (a) 2003, (b) 2004, (c) 2005, (d) 2006 e (e) 2007.

Fonte: Estação Climatológica da Universidade Federal de Uberlândia (2008).

A análise dos dados de precipitação demonstra nitidamente um período chuvoso e outro seco, como mostra a Figura 5.3. As chuvas concentraram-se de outubro a março (período chuvoso), representando 84% do total da precipitação anual, e os meses de maio a setembro (período seco) representam os outros 16%. O mês com maior precipitação total média foi janeiro (382 mm), seguido por dezembro (320 mm). Os meses com menores médias foram julho e agosto, com 13 mm e 7 mm, respectivamente. A precipitação total média do período de 2003 a 2007 foi de 1.709 mm. Esse valor é maior do que a precipitação total média encontrada por Silva e Assuncao (2004), que foi de 1.584 mm. Todavia, esse aumento na média do período foi devido principalmente à precipitação total do ano de 2006 (2.090 mm). As precipitações totais médias dos anos de 2004, 2005 e 2007 ficaram próximas da média encontrada por Silva e Assuncao (2004). Observa-se também um período seco mais prolongado em 2007, comparado aos demais anos.

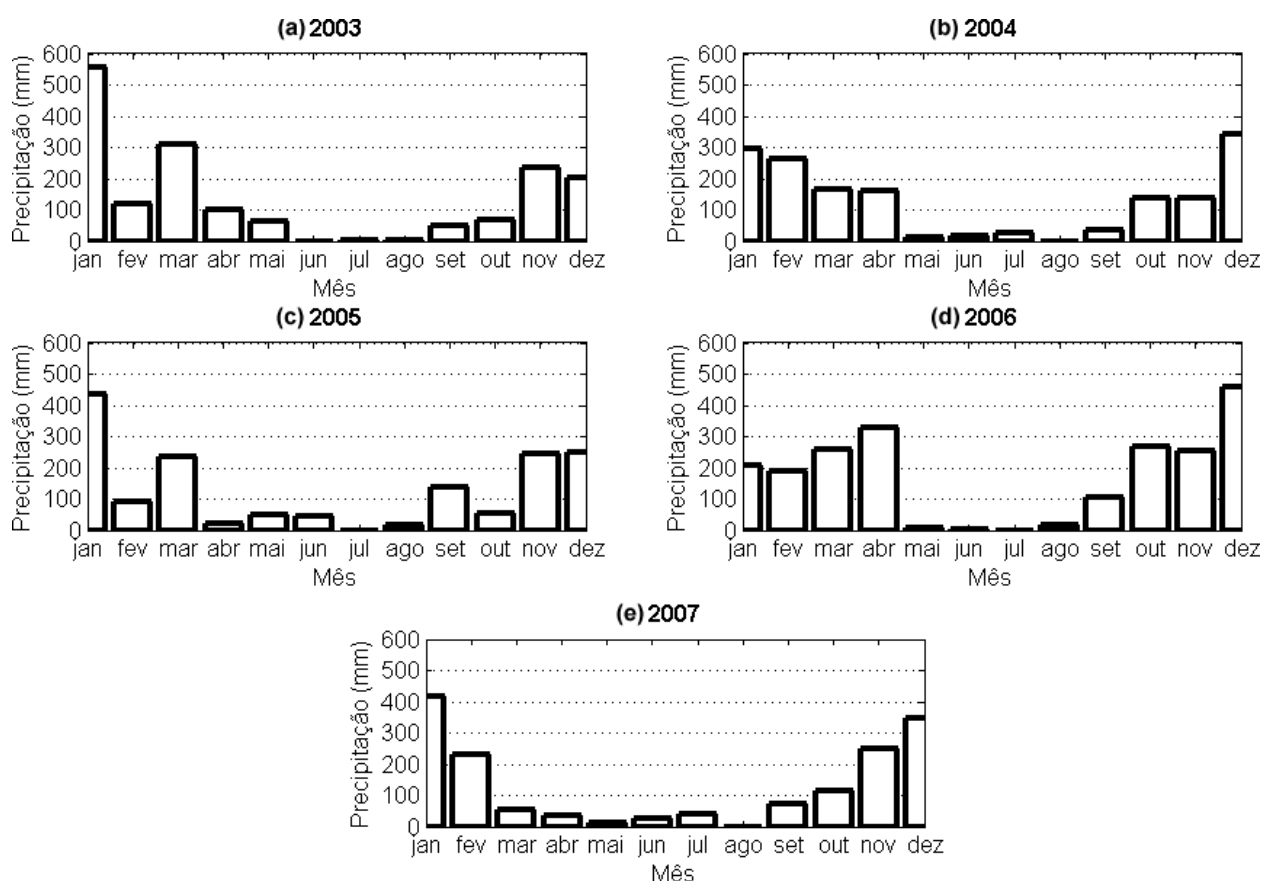


Figura 5.3: Precipitação média mensal: (a) 2003, (b) 2004, (c) 2005, (d) 2006 e (e) 2007.

Fonte: Estação Climatológica da Universidade Federal de Uberlândia (2008).

A apreciação dos dados referentes à umidade relativa do ar demonstrou que os maiores índices foram alcançados no período chuvoso, conforme mostra a Figura 5.4, com destaque para os meses

de janeiro e dezembro que registraram uma umidade relativa média superior a 77%. Em contraste, os meses de agosto e setembro apresentaram menores valores de umidade relativa média (51% e 52%, respectivamente). A média anual da umidade relativa apresentou pouca variação, sendo a menor em 2007 (65%) e a maior em 2005 (68%). Em 2007, como consequência de um período sem chuvas mais prolongado, houve também um período maior com baixos índices de umidade relativa. A umidade relativa média no período foi de 67%, valor esse menor do que o encontrado Silva e Assuncao (2004) que foi de 71%. Essa diminuição na umidade relativa pode estar associada ao aumento da temperatura no mesmo período. É importante destacar que, nessa análise da umidade relativa, são utilizadas médias mensais e que na cidade de Uberlândia são frequentemente registrados índices inferiores a 30%, principalmente nos meses junho, julho e agosto no período da tarde.

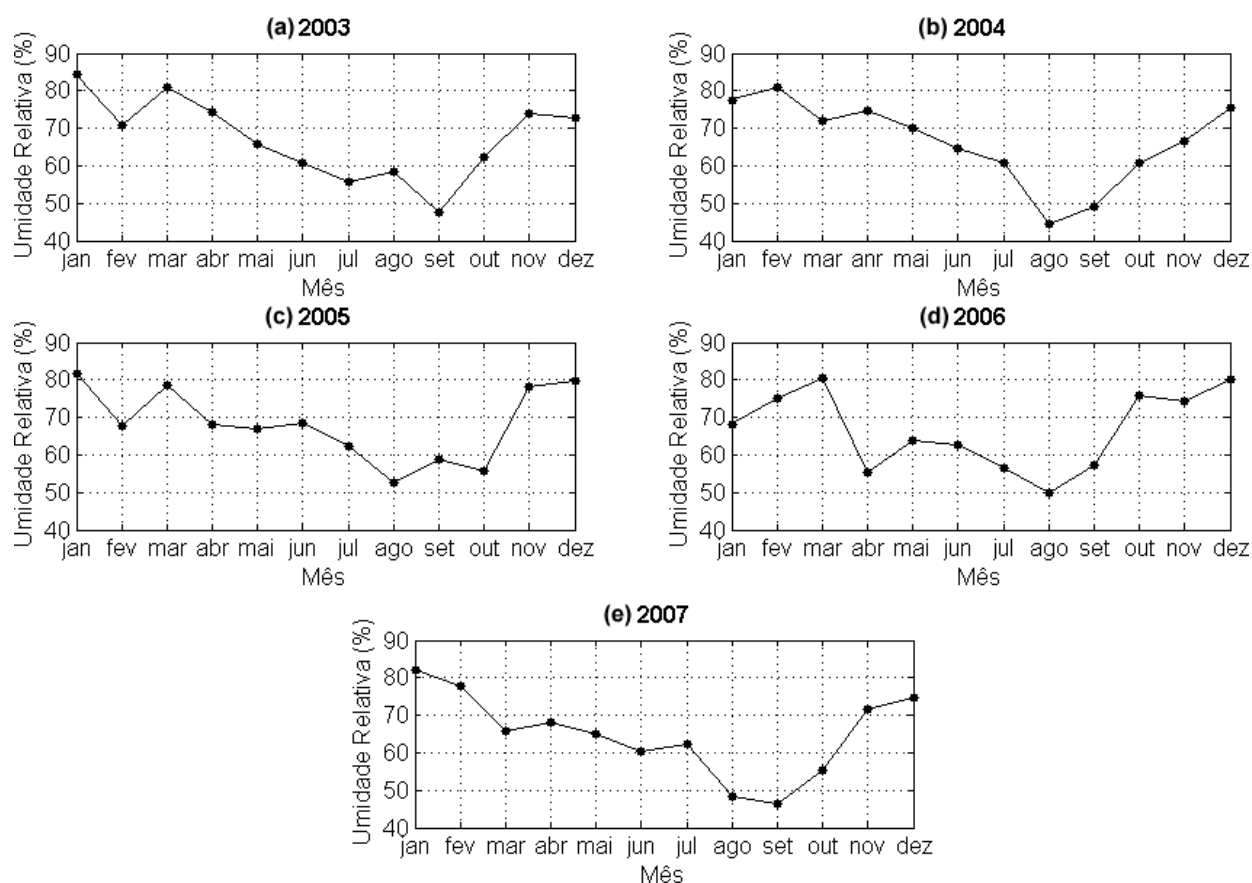


Figura 5.4: Umidade relativa média mensal: (a) 2003, (b) 2004, (c) 2005, (d) 2006 e (e) 2007.

Fonte: Estação Climatológica da Universidade Federal de Uberlândia (2008).

A Figura 5.5 mostra as nebulosidades médias mensais do período de 2003 a 2007. A nebulosidade média do período foi 48%. O ano de maior nebulosidade foi 2005 com 53% e o de menor

nebulosidade foi 2007 com 39%. Esses resultados são próximos aos encontrados por Silva e Assuncao (2004). As maiores médias mensais ocorreram nos meses de dezembro (69%) e janeiro (75%). A menor nebulosidade média ocorreu no mês de agosto (22%), com destaque para agosto de 2007 (8%), mesmo ano em que foi registrada a maior temperatura média do período analisado. Segundo Silva e Assuncao (2004), a baixa nebulosidade contribui para acentuar a incidência de radiação solar, responsável por aumentar a temperatura no período do inverno.

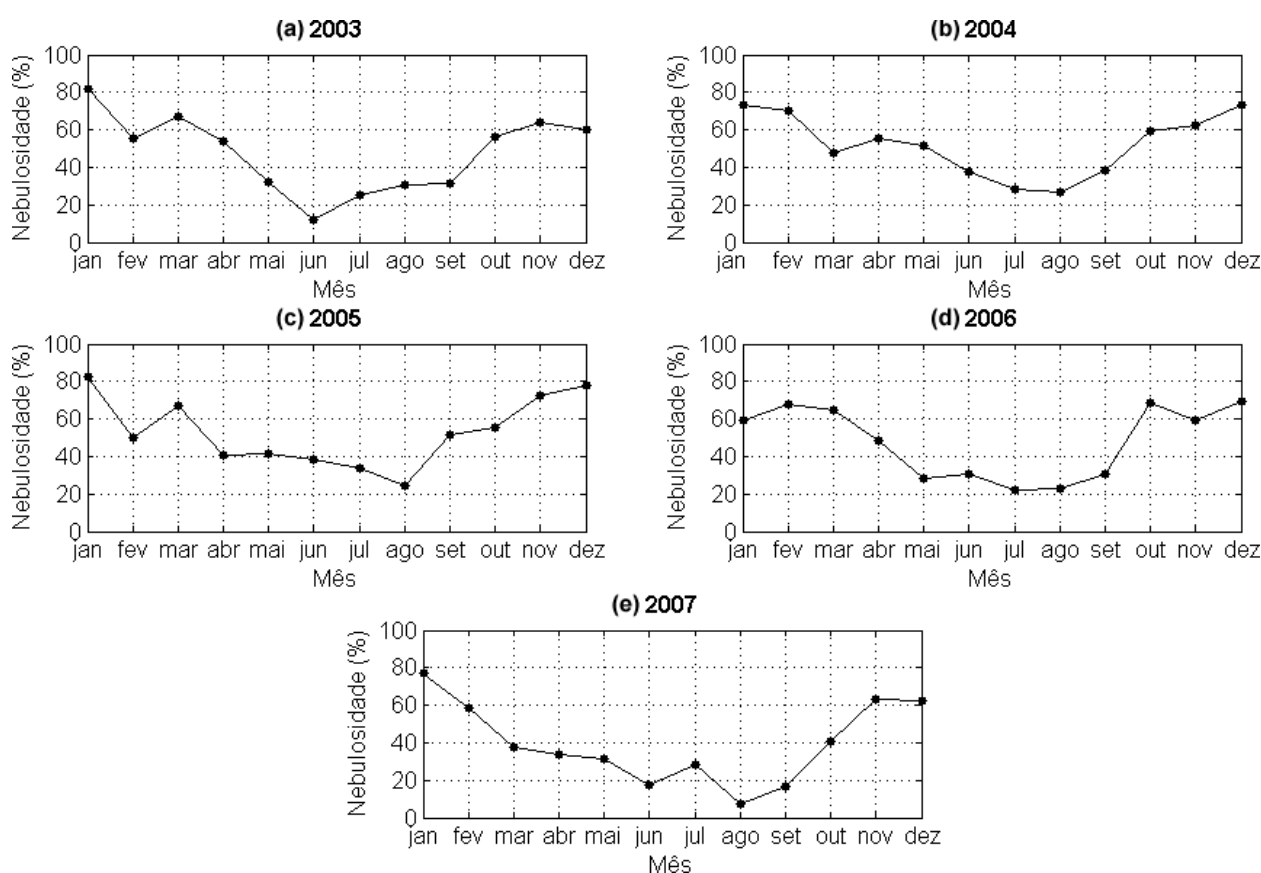


Figura 5.5: Nebulosidade média mensal: (a) 2003, (b) 2004, (c) 2005, (d) 2006 e (e) 2007.

Fonte: Estação Climatológica da Universidade Federal de Uberlândia (2008).

A insolação média do período estudado foi de 2.567 horas, que é maior do que a média encontrada por Silva e Assuncao (2004). A Figura 5.6 mostra a insolação acumulada por mês. As maiores médias mensais registradas ocorreram nos meses de julho (267h) e agosto (281h), e as menores nos meses de janeiro (145h) e dezembro (167h). A maior insolação total anual foi em 2007 com 2.765 horas, devido à menor nebulosidade ocorrida nesse mesmo ano. E a menor insolação total anual foi em 2004 com 2.484 horas. De acordo com Silva e Assuncao (2004), a insolação

é maior no período seco, quando o tempo se apresenta claro e estável, ocorrendo uma diminuição no período chuvoso, quando o tempo permanece por vários dias instável e nublado.

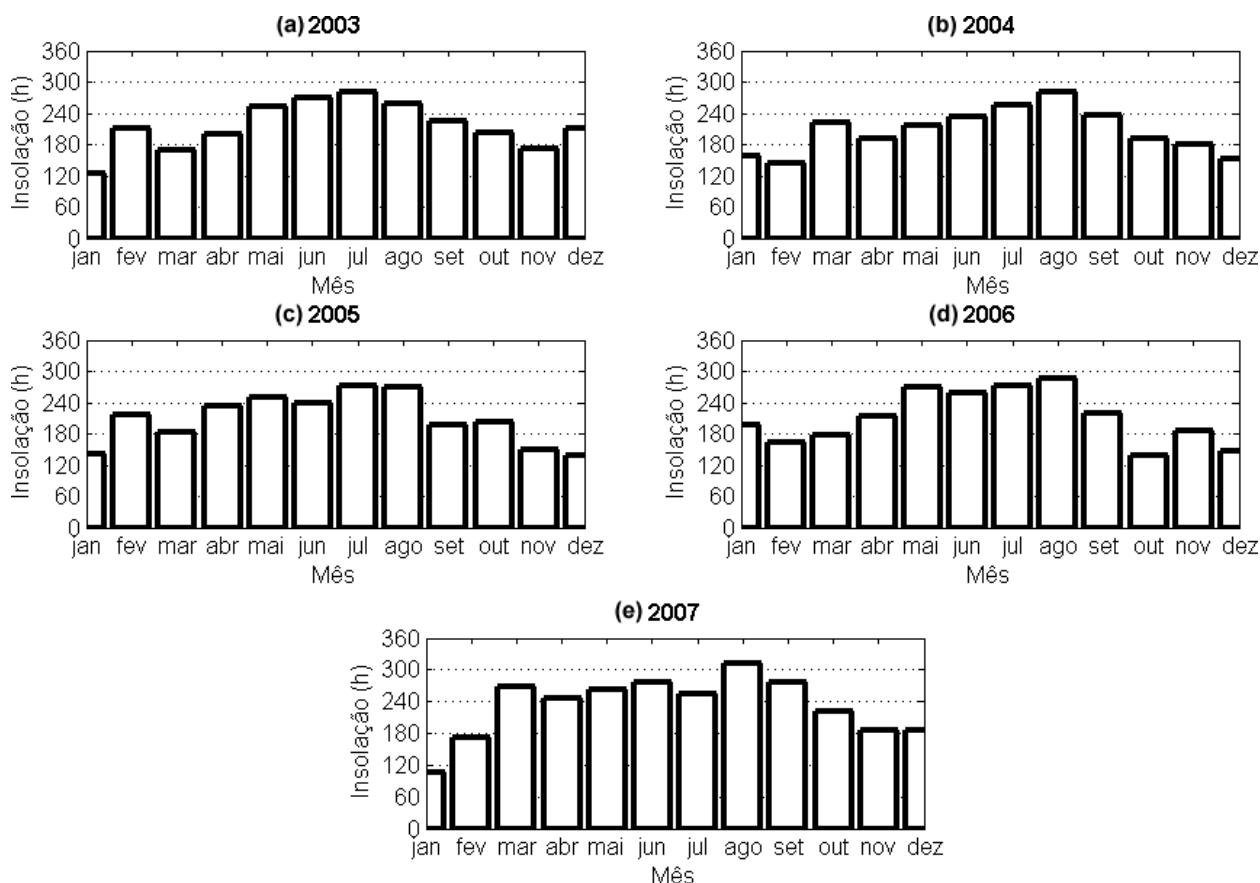


Figura 5.6: Insolação média mensal: (a) 2003, (b) 2004, (c) 2005, (d) 2006 e (e) 2007.

Fonte: Estação Climatológica da Universidade Federal de Uberlândia (2008).

A Figura 5.7 mostra as rosas-dos-ventos das médias mensais do período de 2003 a 2007. Nota-se uma predominância de vento NE (nordeste) e ENE (leste-nordeste), com velocidade na faixa 2-3 m/s. O fato de a velocidade do vento ser baixa é prejudicial à dispersão de poluentes, contudo isso também significa que haverá um menor arraste de material particulado, principalmente nos períodos sem chuva. A característica do vento local com direção predominante é igualmente prejudicial à dispersão de poluentes, pois uma mesma área próxima à fonte emissora é exposta continuamente a poluição. Por outro lado, o centro da cidade de Uberlândia (local do monitoramento do MP₁₀) é pouco afetado pelas emissões originadas no setor industrial, localizado ao norte da cidade.

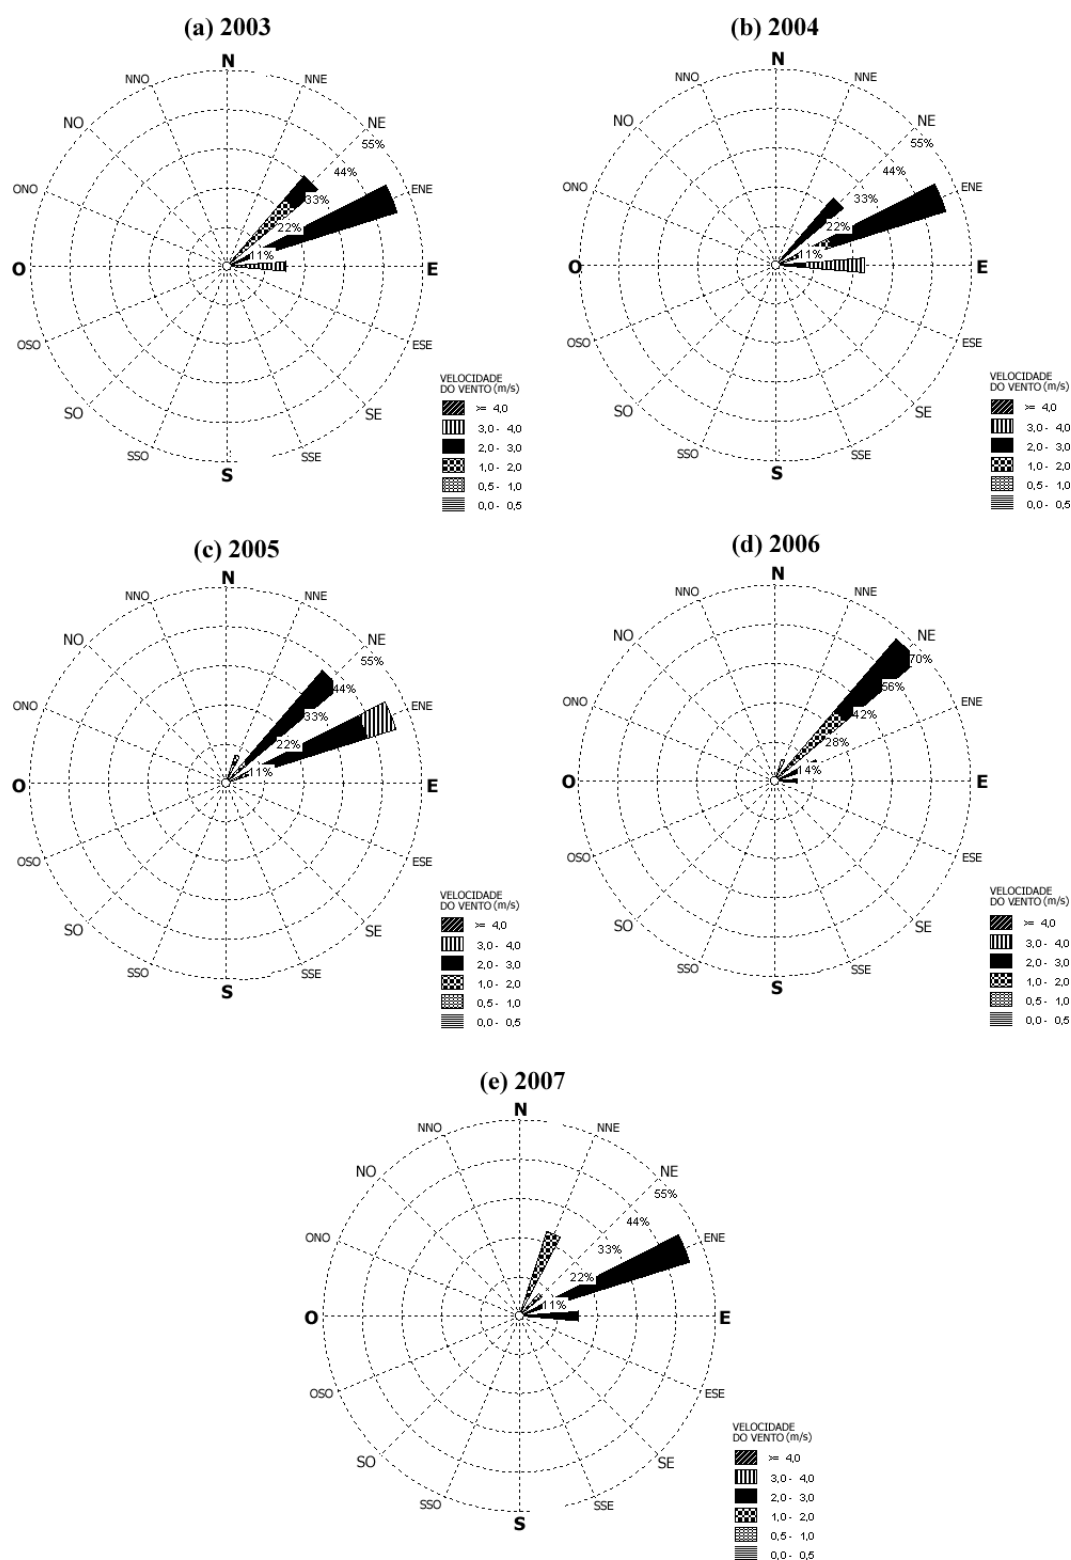


Figura 5.7: Velocidade e direção do vento média mensal: (a) 2003, (b) 2004, (c) 2005, (d) 2006 e (e) 2007.

Fonte: Estação Climatológica da Universidade Federal de Uberlândia (2008).

5.1.2 Fluxo de veículos

Considerando que o local de amostragem de MP_{10} é caracterizado por um intenso fluxo de veículos, foram utilizados, neste trabalho, dados de fluxo diário de veículos próximo a esse local. Tais dados foram concedidos pela Secretaria de Trânsito e Transportes (SETRAN) da Prefeitura de Uberlândia. O monitoramento do fluxo de veículos é realizado por um detector automático instalado no pavimento da Avenida João Pinheiro, esquina com a Avenida João Naves de Ávila. Esse equipamento monitora o fluxo de veículos 24 horas por dia, o ano todo.

Com o propósito de melhor visualizar as variações do fluxo diário de veículos, foram calculadas as médias mensais e por dia da semana. As Tabelas com estas médias estão no Apêndice A.2. A Figura 5.8 apresenta as médias do fluxo diário de veículos por mês do período de 2003 a 2007.

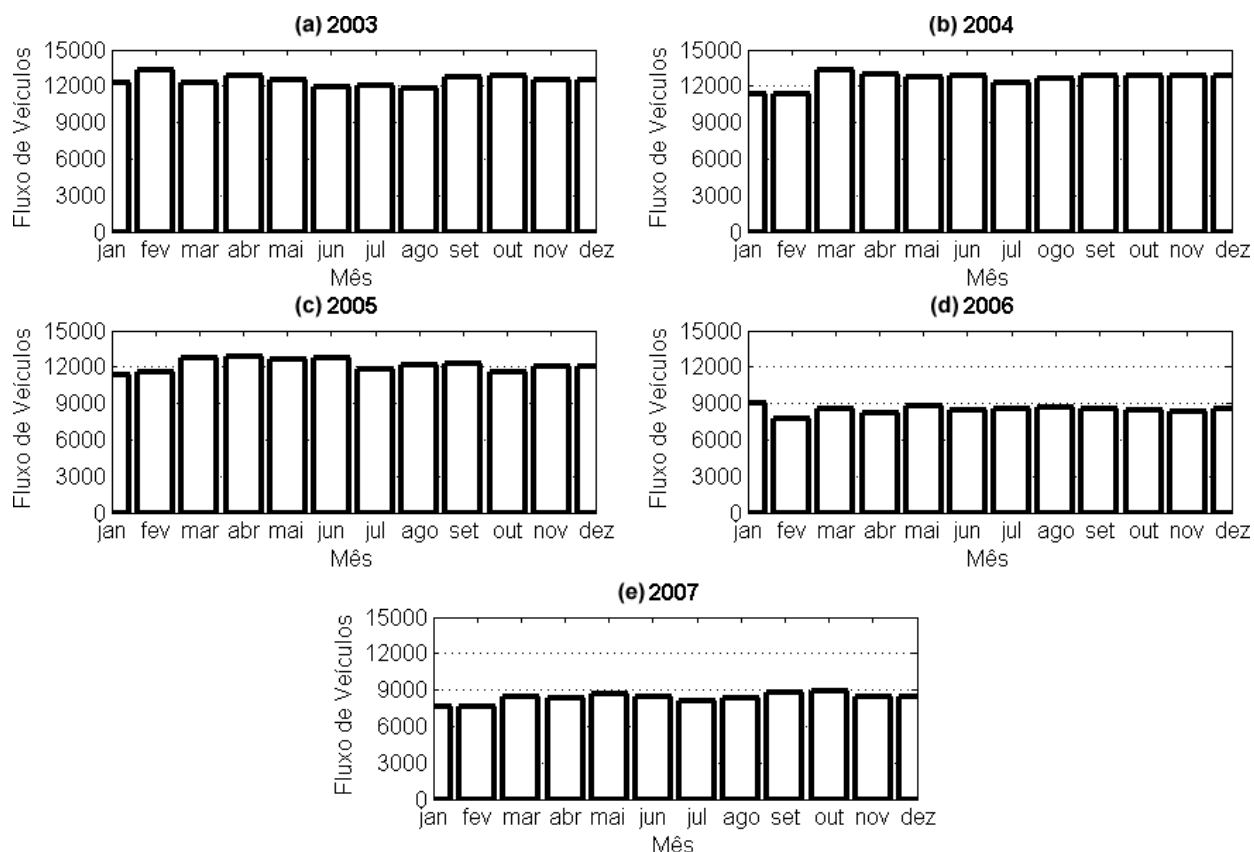


Figura 5.8: Fluxo médio mensal de veículos: (a) 2003, (b) 2004, (c) 2005, (d) 2006 e (e) 2007.

Fonte: Secretaria de Trânsito e Transportes da Prefeitura de Uberlândia (2008).

Observa-se, de forma geral, uma pequena redução no fluxo de veículos nos meses de janeiro e fevereiro (período de férias escolares), com exceção de 2003, e nenhuma tendência visível nos

outros meses. Verifica-se também uma queda no fluxo de aproximadamente 30% a partir de 2006. Essa queda no fluxo de veículos ocorreu devido a ações da SETRAN para reorganizar e melhorar o trânsito no centro da cidade.

Já a Figura 5.9 mostra as médias do fluxo diário de veículos por dia da semana. Nota-se que o fluxo de veículos na via sofre reduções significativas aos domingos e sábados, mantendo-se relativamente constante nos demais dias da semana.

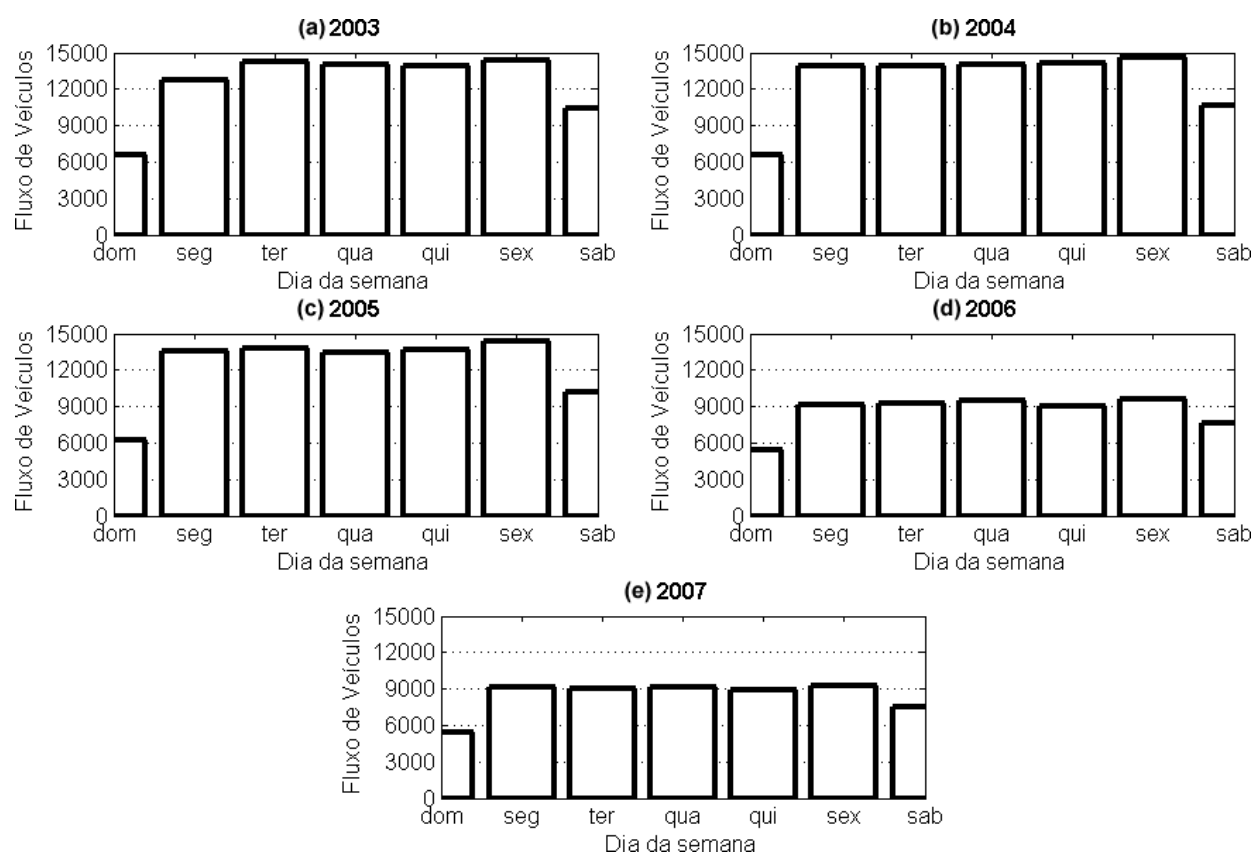


Figura 5.9: Fluxo médio de veículos por dia da semana: (a) 2003, (b) 2004, (c) 2005, (d) 2006 e (e) 2007.

Fonte: Secretaria de Trânsito e Transportes da Prefeitura de Uberlândia (2008).

É importante ressaltar que esses dados não são do cruzamento como um todo, correspondem ao fluxo diário de uma das vias do cruzamento, da Avenida João Pinheiro. De acordo com um estudo realizado por Silva (2007), o fluxo na Avenida João Pinheiro corresponde a cerca de 48% do fluxo total do cruzamento. Silva (2007) também observou que o fluxo de veículos no cruzamento é maior em dois períodos, sendo o primeiro por volta das 12h e o segundo por volta das 18h; a maior proporção de veículos corresponde àqueles de motor ciclo Otto (61,0%), seguidos pelos veículos

de motor ciclo Diesel (21,9%) e pelas motocicletas (17,1%); e aproximadamente 2/3 dos veículos de motores de ciclo Otto utilizam gasolina.

5.1.3 Concentração de MP_{10}

Os dados de concentração de MP_{10} são obtidos pela Faculdade de Engenharia Química da Universidade Federal de Uberlândia (FEQ/UFU) desde 11 de março de 2003; o autor deste trabalho conduz as amostragens desde 01 de julho de 2007. Os dados utilizados neste trabalho são do período de 11 de março de 2003 a 31 de dezembro de 2007.

De um total de 357 dados de concentração de MP_{10} , verificou-se que sete eram *outliers*. Os mesmos foram identificados estatisticamente utilizando o *software* R. As possíveis causas dos *outliers* foram: limpeza do gramado entorno do equipamento durante a amostragem; erro de leitura da pressão através do filtro; erro na pesagem do filtro; queimadas próximas ao local de monitoramento durante a amostragem etc. A Figura 5.10 mostra os *box-plots* das concentrações de MP_{10} , com e sem os *outliers*, do período abordado. Os valores *outliers* foram excluídos do banco de dados.

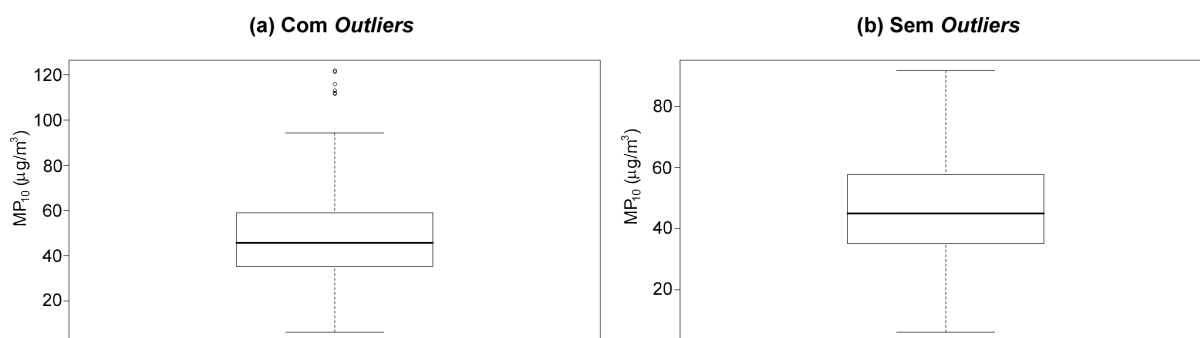


Figura 5.10: *Box-plots* da concentração de MP_{10} de 2003 a 2007.

Em etapas iniciais deste trabalho a identificação de *outliers* foi executada de maneira diferente do que a apresentada aqui. A identificação de *outliers* foi realizada por meio de análises de regressão linear múltipla utilizando dados meteorológicos. O número de valores *outliers* era muito maior, o que diminuía a variabilidade dos dados.

A Figura 5.11 mostra as concentrações médias de MP_{10} obtidas em períodos de 24 horas. De modo geral, as maiores concentrações de MP_{10} foram obtidas no período do inverno quando as condições meteorológicas são desfavoráveis à remoção e dispersão de poluentes da atmosfera.

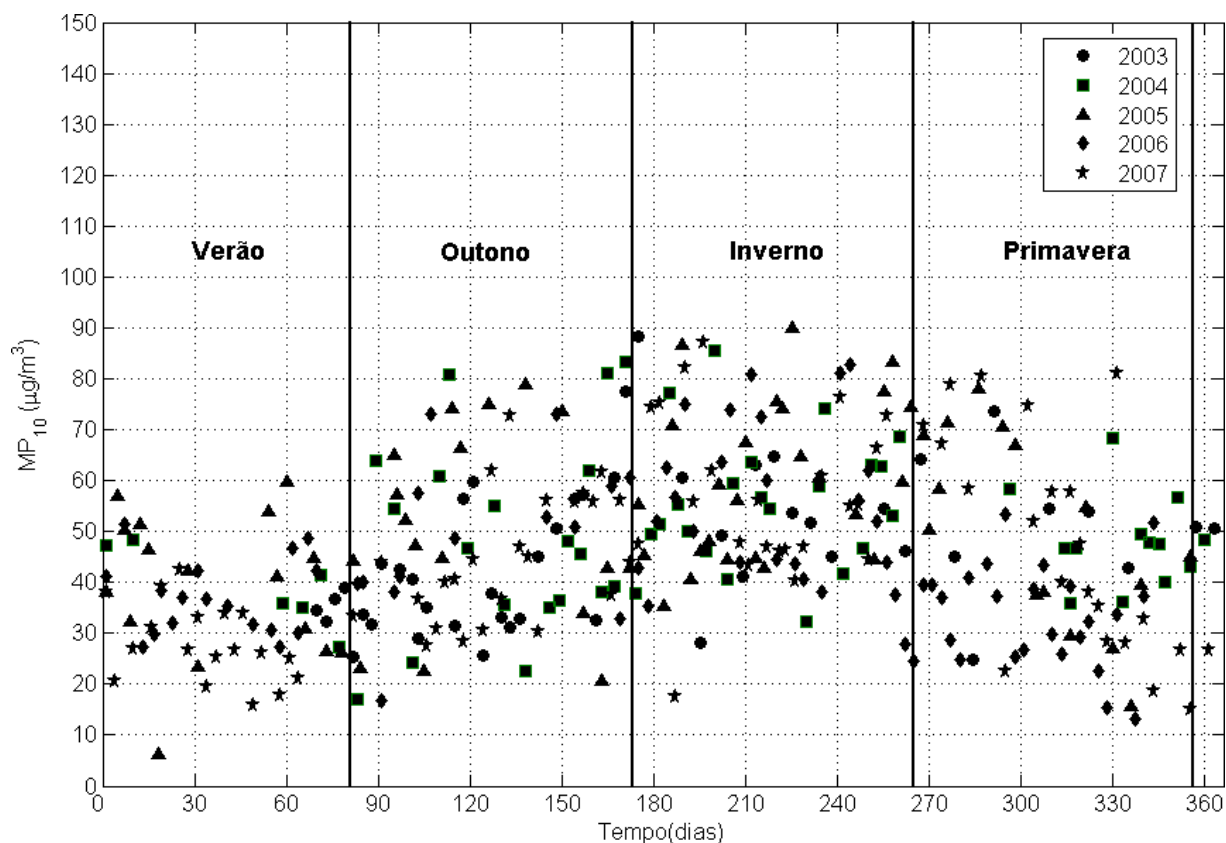


Figura 5.11: Concentração média diária de MP_{10} de 2003 a 2007.

As concentrações médias anuais de MP_{10} foram 47,8, 50,1, 51,5, 44,9 e 44,3 $\mu\text{g}/\text{m}^3$, respectivamente, para os anos de 2003, 2004, 2005, 2006, e 2007. Houve um aumento progressivo nas médias anuais de 2003 a 2005, e em 2004 e 2005 o padrão primário para MP_{10} ($50 \mu\text{g}/\text{m}^3$) foi ultrapassado. Em 2006, ocorreu uma redução significativa na média anual, e essa redução coincide com a redução no fluxo de veículos próximo ao local de amostragem de MP_{10} . Em 2007, mesmo com condições atmosféricas desfavoráveis, houve uma redução na concentração média de MP_{10} . Ou seja, a redução do fluxo de veículos no local de amostragem foi decisiva para o menor valor da concentração média anual de MP_{10} .

As concentrações médias anuais, mensais e por dia da semana de MP_{10} encontram-se no Apêndice A.3. A Figura 5.12 apresenta as concentrações médias de MP_{10} por dia da semana. As con-

centrações de MP_{10} são, em geral, menores nos domingos e sábados, coincidindo com os dias em que há menor fluxo de veículos próximo ao local de amostragem de MP_{10} .

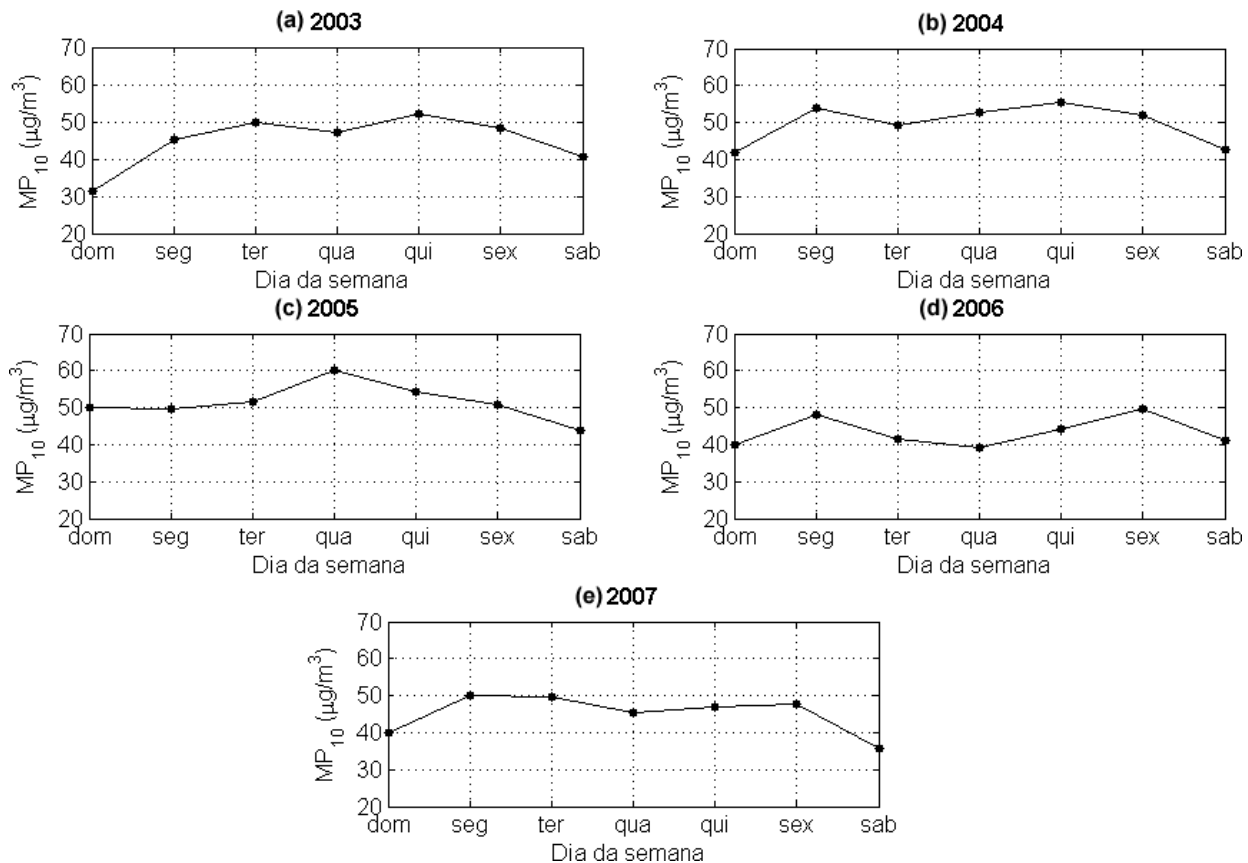


Figura 5.12: Concentração média de MP_{10} por dia da semana: (a) 2003, (b) 2004, (c) 2005, (d) 2006 e (e) 2007.

5.1.4 Análises de correlação entre as variáveis

A fim de investigar as relações entre a concentração de MP_{10} e as demais variáveis disponíveis para a construção dos modelos de previsão, foram calculados coeficientes de correlação. As variáveis meteorológicas analisadas nesta etapa são as mesmas apresentadas anteriormente, ou seja: temperatura (T), umidade relativa (UR), precipitação (Pr), direção do vento (Dv)¹, velocidade do vento (Vv), nebulosidade (Neb) e insolação (Ins). Além das variáveis meteorológicas, foi analisado também o fluxo total diário de veículos (Fv).

¹A variável direção do vento foi redefinida usando uma função seno.

O coeficiente de correlação varia de -1 a +1, dependendo do grau da relação entre as variáveis e da forma com que se relacionam (direta ou inversamente). Os coeficientes de correlação apresentam significância estatística se p-valor for menor que 0,05. Na Tabela 5.1, estão os coeficientes de correlação de Pearson com os respectivos p-valores das variáveis analisadas. Os coeficientes de correlação que apresentaram significância estatística estão em negrito.

Tabela 5.1: Coeficientes de correlação de Pearson com os respectivos p-valores para os dados utilizados nos modelos de previsão.*

	MP ₁₀	T	UR	Pr	Vv	Dv	Neb	Ins	Fv
MP ₁₀	1,000 (0,000)	0,084 (0,116)	-0,268 (0,000)	-0,494 (0,000)	-0,018 (0,743)	-0,013 (0,812)	-0,361 (0,000)	0,296 (0,000)	0,197 (0,000)
T	0,084 (0,116)	1,000 (0,000)	-0,029 (0,591)	-0,242 (0,005)	-0,146 (0,006)	-0,049 (0,365)	-0,038 (0,478)	0,174 (0,001)	-0,071 (0,188)
UR	-0,268 (0,000)	-0,029 (0,591)	1,000 (0,000)	0,394 (0,000)	-0,037 (0,493)	-0,052 (0,331)	0,358 (0,000)	-0,374 (0,000)	0,044 (0,414)
Pr	-0,494 (0,000)	-0,242 (0,005)	0,394 (0,000)	1,000 (0,000)	-0,136 (0,011)	0,049 (0,359)	0,731 (0,000)	-0,738 (0,000)	-0,012 (0,829)
Vv	-0,018 (0,743)	-0,146 (0,006)	-0,037 (0,493)	-0,136 (0,011)	1,000 (0,000)	0,030 (0,574)	-0,030 (0,578)	0,046 (0,394)	0,021 (0,693)
Dv	-0,013 (0,812)	-0,049 (0,365)	-0,052 (0,331)	0,049 (0,359)	0,030 (0,574)	1,000 (0,000)	-0,050 (0,352)	0,124 (0,021)	-0,005 (0,925)
Neb	-0,361 (0,000)	-0,038 (0,478)	0,358 (0,000)	0,731 (0,000)	-0,030 (0,578)	-0,050 (0,352)	1,000 (0,000)	-0,800 (0,000)	0,030 (0,574)
Ins	0,296 (0,000)	0,174 (0,001)	-0,374 (0,000)	-0,738 (0,000)	0,046 (0,394)	0,124 (0,021)	-0,800 (0,000)	1,000 (0,000)	-0,012 (0,818)
Fv	0,197 (0,000)	-0,071 (0,188)	0,044 (0,414)	-0,012 (0,829)	0,021 (0,693)	-0,005 (0,925)	0,030 (0,574)	-0,012 (0,818)	1,000 (0,000)

* Valores na parte superior são os coeficientes de correlação e os valores entre parênteses são p-valores.

A concentração de MP₁₀ apresenta correlação inversa com umidade relativa, precipitação e nebulosidade; correlação direta com insolação e fluxo de veículos; e não correlação com temperatura, velocidade do vento e direção do vento. As variáveis em ordem decrescente de intensidade de correlação são precipitação, nebulosidade, insolação, umidade relativa e fluxo de veículos. Observam-se também que algumas variáveis meteorológicas são correlacionadas entre si, como, por exemplo, nebulosidade e insolação; umidade relativa e precipitação etc. Mesmo apresentado significância estatística, todas as correlações identificadas são consideradas fracas. Embora a Tabela 5.1 não mostre isso claramente, pois essas variáveis atuam em sentidos opostos, as condições meteorológicas (precipitação e umidade relativa) favoreceram a elevação da concentração de MP₁₀.

e o fluxo de veículos sua diminuição. Existe ainda uma outra variável que poderia entrar nessa análise que seria a interação entre as variáveis.

Gráficos de dispersão também permitem identificar se há relações entre as variáveis. A Figura 5.13 exibe os gráficos de dispersão das variáveis analisadas. Verifica-se em todos os gráficos uma nuvem dispersa de pontos, sem tendência visível.

É importante ressaltar que o coeficiente de correlação mede a intensidade da relação linear entre as variáveis. Mesmo não havendo correlações, ou sendo elas fracas, pode haver relações não lineares fortes entre as variáveis estudadas. Assim, apesar dos resultados obtidos aqui, todas as variáveis analisadas foram utilizadas nos modelos de previsão a seguir.

5.2 Previsão da qualidade do ar

5.2.1 Estudo preliminar utilizando redes neurais

Esta etapa do trabalho utilizou dados de concentração de MP_{10} (com *outliers*) e variáveis meteorológicas dos anos de 2003, 2004 e 2005. As variáveis meteorológicas utilizadas foram: temperatura, umidade relativa, velocidade do vento e precipitação.

Um procedimento recomendado ao utilizar RNAs é a normalização dos dados. A depender do tipo de função de ativação utilizada na camada de saída da RNA, esse procedimento torna-se necessário. O *software* Matlab oferece duas formas de normalização dos dados: no intervalo $[-1; 1]$ e com média = 0 e variância = 1. Assim, os dados foram normalizados de tal modo a apresentarem média = 0 e variância = 1 e submetidos à análise de componentes principais. Optou-se por esse tipo de normalização, pois a função do Matlab para análise de componentes principais exige que os dados estejam normalizados dessa forma. Apenas os componentes principais que contribuíram com mais de 10% para a variância dos dados foram utilizados.

A análise de componentes principais é uma técnica estatística indicada para conjuntos de medidas correlacionadas linearmente, o que permite reduzi-las a poucas variáveis. Consiste em reescrever as variáveis originais em novas variáveis, denominadas componentes principais, por meio de uma transformação de coordenadas. Cada componente principal é uma combinação linear de

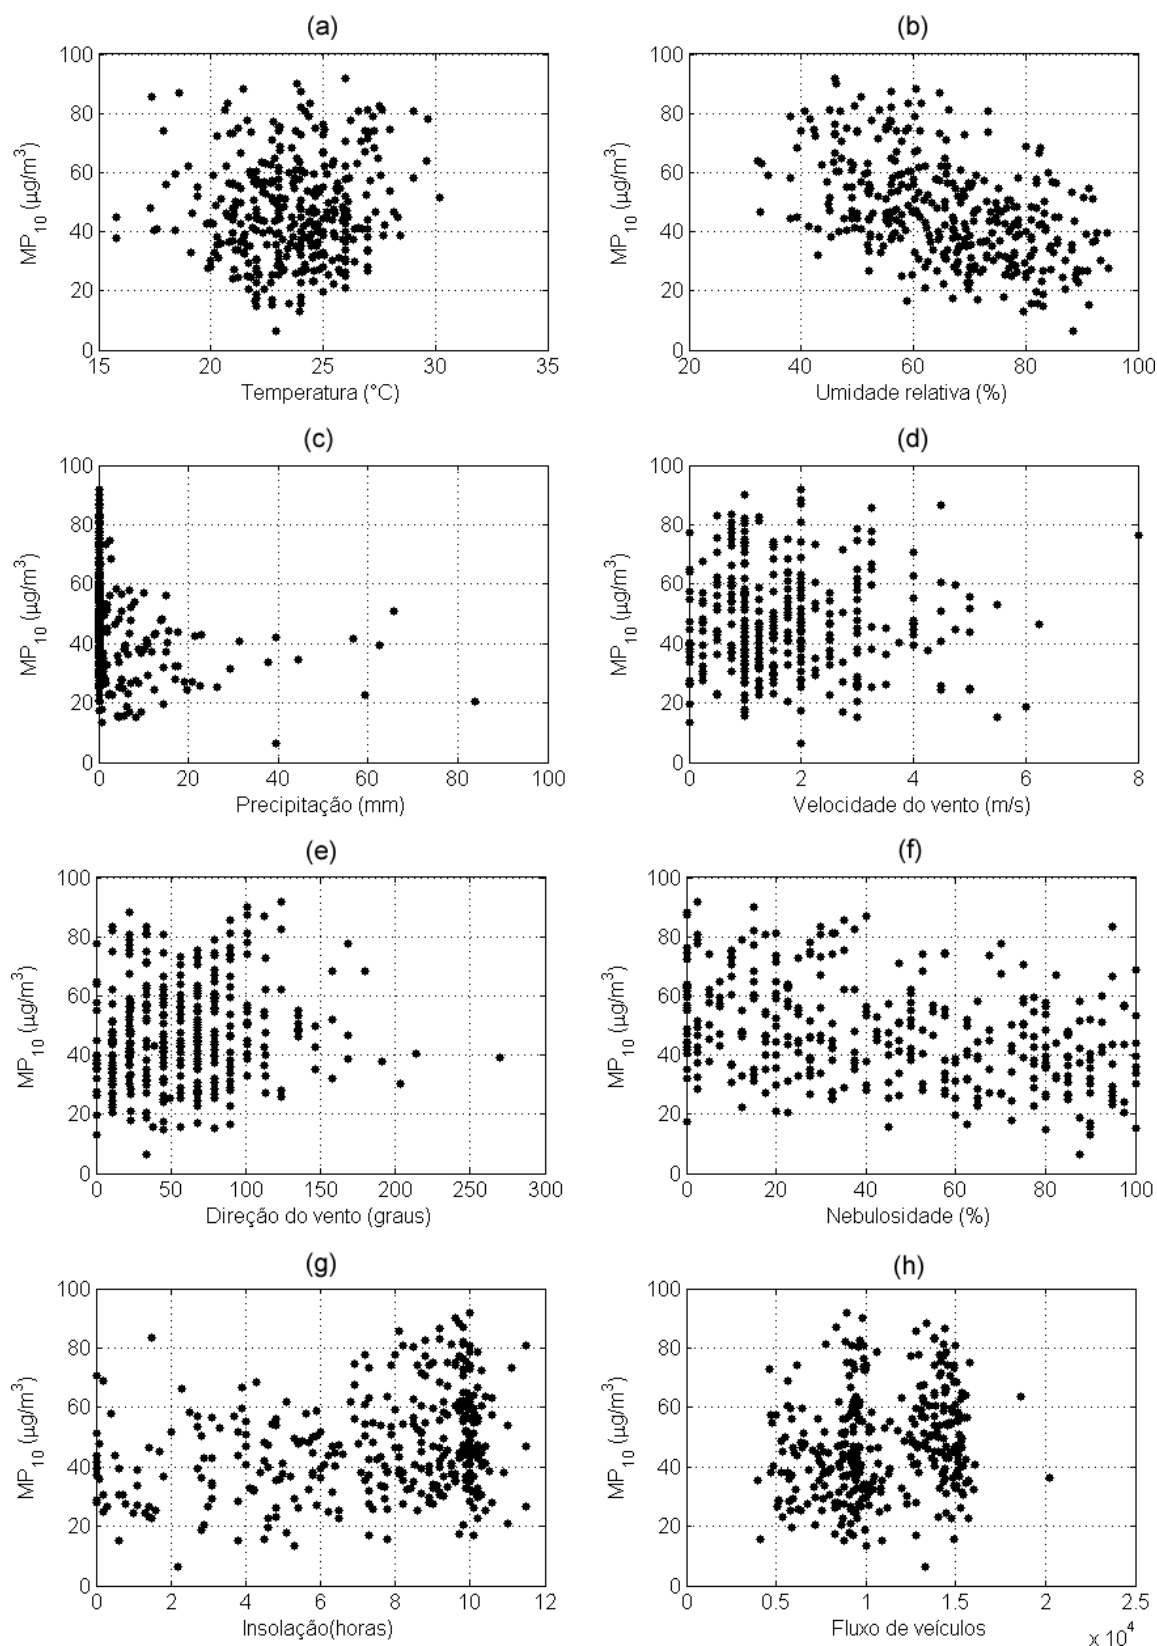


Figura 5.13: Dispersão da concentração de MP_{10} em função de variáveis meteorológicas e de fluxo de veículos.

todas as variáveis originais (MANLY, 1994). Duas são as características das novas variáveis que as tornam mais efetivas que as originais para a análise do conjunto das amostras. A primeira característica é que os componentes principais são ortogonais entre si. Desse modo, cada componente principal traz uma informação estatística diferente das outras. A segunda característica importante é decorrente do processo matemático-estatístico de geração de cada componente que maximiza a informação estatística para cada uma das coordenadas criadas. As variáveis originais têm a mesma importância estatística, enquanto as componentes principais têm importância estatística decrescente, ou seja, as primeiras componentes principais são tão mais importantes que podemos até desprezar as demais (DILLON; GOLDSTEIN, 1984).

E por fim, os dados (total = 172) foram divididos da seguinte forma: 2/3 consecutivos para treinamento e 1/3 restante para validação.

O modelo foi desenvolvido no *software* Matlab com o auxílio do *Neural Network Toolbox*. A RNA adotada foi do tipo *perceptron* multicamadas com atraso no tempo, associada ao algoritmo de treinamento *Levenberg-Marquardt backpropagation*. Utilizou-se uma camada oculta cuja função de ativação foi a tangente hiperbólica. Já para a camada de saída, foi utilizada a função linear. O número de neurônios na camada oculta e o número de atrasos no tempo foram variados de 4 a 6 e de 1 a 3, respectivamente, na busca da estrutura que produzisse o melhor resultado. Esses valores foram limitados, para evitar que o número de parâmetros da RNA fosse superior ao número de dados.

Outro procedimento recomendado ao utilizar RNAs é treinar cada estrutura várias vezes. Isso é feito para evitar distorções nos resíduos devido a inicialização aleatória dos pesos dos neurônios durante a fase de treinamento. Cada vez que a RNA é treinada, encontra-se um erro mínimo, que pode ser local ou global. Treina-se a RNA várias vezes, na tentativa de encontrar o erro mínimo global.

Para avaliar a *performance* das RNAs foi utilizado o indicador de desempenho *RMSE* (Equação 4.21). A comparação do desempenho dos modelos foi realizada com base nos valores de concentração de MP_{10} preditos e observados na fase de validação. O melhor resultado foi obtido pela RNA com estrutura de cinco neurônios e um atraso no tempo. A Figura 5.14-a apresenta a comparação dos valores preditos e observados na fase de validação. Nesse tipo de gráfico, o caso

perfeito seria aquele representado por uma reta que passa pela origem. Verifica-se que os pontos ficaram muito dispersos. O desempenho do modelo não foi satisfatório, pois não houve um bom ajuste do modelo aos dados. A Figura 5.14-b mostra a simulação um passo à frente do modelo obtido. As simulações das RNAs com outras estruturas avaliadas estão no Apêndice B.1.

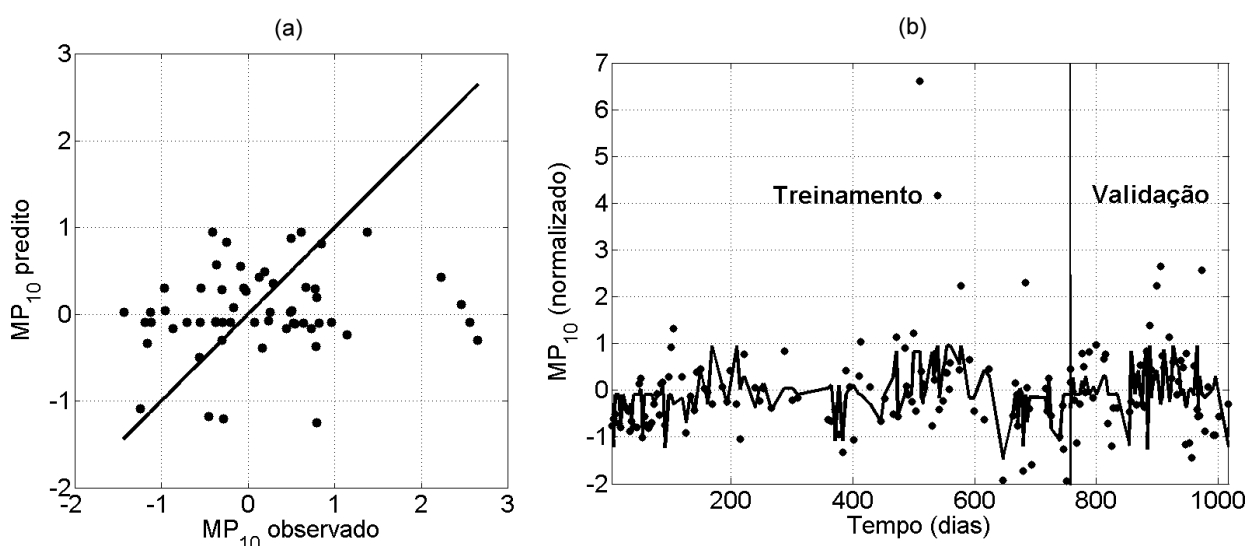


Figura 5.14: Modelo preliminar utilizando redes neurais: (a) concentrações de MP_{10} observada e predita na fase de validação e (b) simulação um passo à frente (linha) e valores observados (pontos).

Essa etapa do estudo foi essencial para mostrar que ao se utilizar RNAs com processamento temporal é necessário que os dados informados tenham a mesma frequência de amostragem. Essa observação estende-se, também, aos modelos lineares. O banco de dados aqui utilizado possui algumas falhas, isto é, em alguns dias no período de amostragem não foi possível determinar a concentração de MP_{10} e isto prejudicou o desempenho do modelo.

5.2.2 Redes neurais e modelos lineares: comparação

Para comparar o desempenho da RNA e dos modelos lineares, foram utilizados dados de concentração de MP_{10} e variáveis meteorológicas dos anos de 2003, 2004 e 2005. Nesta etapa do trabalho, a identificação de *outliers* foi realizada por meio de análises de regressão múltipla (nível de significância: $p < 0,05$), utilizando dados meteorológicos. Temperatura, umidade relativa, precipitação, velocidade do vento, direção do vento e insolação, além do dia da semana, explicaram 64% da variância da concentração de MP_{10} . As variáveis direção do vento e dia da semana foram

redefinidas usando funções seno e cosseno. Segundo Kolehmainen et al. (2001), isto permite que os algoritmos das RNAs trabalhem corretamente apesar das discontinuidades nos sinais cíclicos originais.

Para solucionar o problema de falhas no banco de dados, estimaram-se por meio de interpolações² as concentrações de MP_{10} dos dias em que a amostragem não foi executada ou daquelas retiradas por serem *outliers* e, desta forma, a sequência de dados foi completada. Os dados (total = 341) já normalizados (média = 0 e desvio padrão = 1) foram divididos como segue: 2/3 consecutivos para treinamento/estimação e 1/3 restante para validação.

O *software* Matlab foi novamente utilizado. Os modelos lineares foram ajustados usando o *System Identification toolbox*. O algoritmo *Levenberg-Marquardt backpropagation* foi usado para treinar a RNA do tipo *perceptron* multicamadas com atraso no tempo (*Neural Network toolbox*). As funções de transferência utilizadas foram tangente hiperbólica e linear para as camadas oculta (uma camada) e de saída, respectivamente. O número de neurônios na camada oculta da RNA e as ordens dos polinômios dos modelos lineares, além do atraso no tempo para ambos os modelos, foram variados e a melhor estrutura de modelo foi definida como aquela que rendeu menor *RMSE*.

Para avaliar a performance dos modelos, foram utilizados os indicadores de desempenho *RMSE*, R^2 e d (Equações 4.21, 4.22 e 4.23). Os desempenhos dos modelos foram comparados com base nas concentrações de MP_{10} preditas e observadas na fase de validação. Os resultados da melhor estrutura obtida para cada modelo estão na Tabela 5.2. Observa-se que os modelos lineares, com exceção do modelo erro na saída, foram melhores que a RNA, e que o modelo Box-Jenkins forneceu os melhores resultados de acordo com todos os indicadores de desempenho.

Tabela 5.2: Indicadores de desempenho para RNA e modelos lineares.

	ARX [4, 1, 1]	ARMAX [3, 1, 1, 1]	OE [1, 2, 4]	BJ [2, 2, 3, 4, 3]	RNA [1, 2]
<i>RMSE</i>	0,5078	0,5044	0,6495	0,4039	0,5424
d	0,9320	0,9318	0,8795	0,9629	0,9140
R^2	0,7799	0,7842	0,6394	0,8120	0,7591

Observa-se que altos valores de R^2 e d foram obtidos. O R^2 excedeu 0,75 pela maioria dos modelos, e todos os modelos renderam d entre 0,87 e 0,96. Esses resultados foram comparados

²Os valores foram interpolados usando a função “interp1” do *software* Matlab.

com os obtidos em outros estudos de previsão de concentrações horárias de NO_2 e O_3 (AGIRRE-BASURKO et al., 2006; KOLEHMAINEN et al., 2001), e também de concentrações diárias de MP_{10} (GRIVAS; CHALOULAKOU, 2006). Os valores R^2 e d do melhor modelo deste estudo foram 0,81 e 0,96, respectivamente, enquanto que Grivas e Chaloulakou (2006) reportaram 0,60 e 0,86.

A Figura 5.15 exibe gráficos que comparam valores observados e preditos pelos modelos na fase de validação. Já a Figura 5.16 apresenta os histogramas dos resíduos dos modelos avaliados na fase de validação. Um bom modelo deve ter distribuição normal dos resíduos, ou seja, o histograma dos resíduos deve ser simétrico, ter a forma de “sino”. Para visualizar a *performance* dos modelos lineares e da RNA, foram comparados os valores observados e as simulações um passo à frente, como ilustra a Figura 5.17. O gráfico mostra um bom ajuste dos modelos aos dados observados, tanto da fase de estimação/treinamento quanto na fase de validação.

5.2.3 Redes neurais em Scilab

O objetivo deste estudo foi mostrar que é possível desenvolver uma RNA em Scilab com facilidade. Foram utilizados dados de concentração de MP_{10} , meteorológicos e de fluxo de veículos do período de 2003 a 2007. A identificação de *outliers* nos dados de concentração de MP_{10} foi realizada da mesma forma que a da seção anterior (Seção 5.2.2). Foram estimadas por meio de interpolações³ as concentrações de MP_{10} dos dias em que a amostragem não foi executada ou daquelas retiradas por serem *outliers*. As variáveis meteorológicas consideradas foram: temperatura, umidade relativa, precipitação, velocidade do vento, direção do vento e insolação. A variável direção do vento foi redefinida usando uma função seno.

O *Neural Network Toolbox 0.4.2* (disponível em: www.scilab.org) foi desenvolvido para o *software* Scilab 2.6, mas pode ser utilizado no Scilab 4.0. Para isso, é necessário adicionar “*endfunction*” no final de cada arquivo *./macro/ann/*.sci*. Alguns dos recursos disponíveis nessa versão são: RNA *feedforward* multicamadas; número ilimitado de camadas; número ilimitado de neurônios por camada separadamente; a função de ativação é definida pelo usuário (padrão é a logística); algoritmo *backpropagation* padrão, algoritmo *backpropagation* com momento, entre outros algoritmos de treinamento.

³Os valores foram interpolados usando a função “*interp1*” do *software* Matlab.

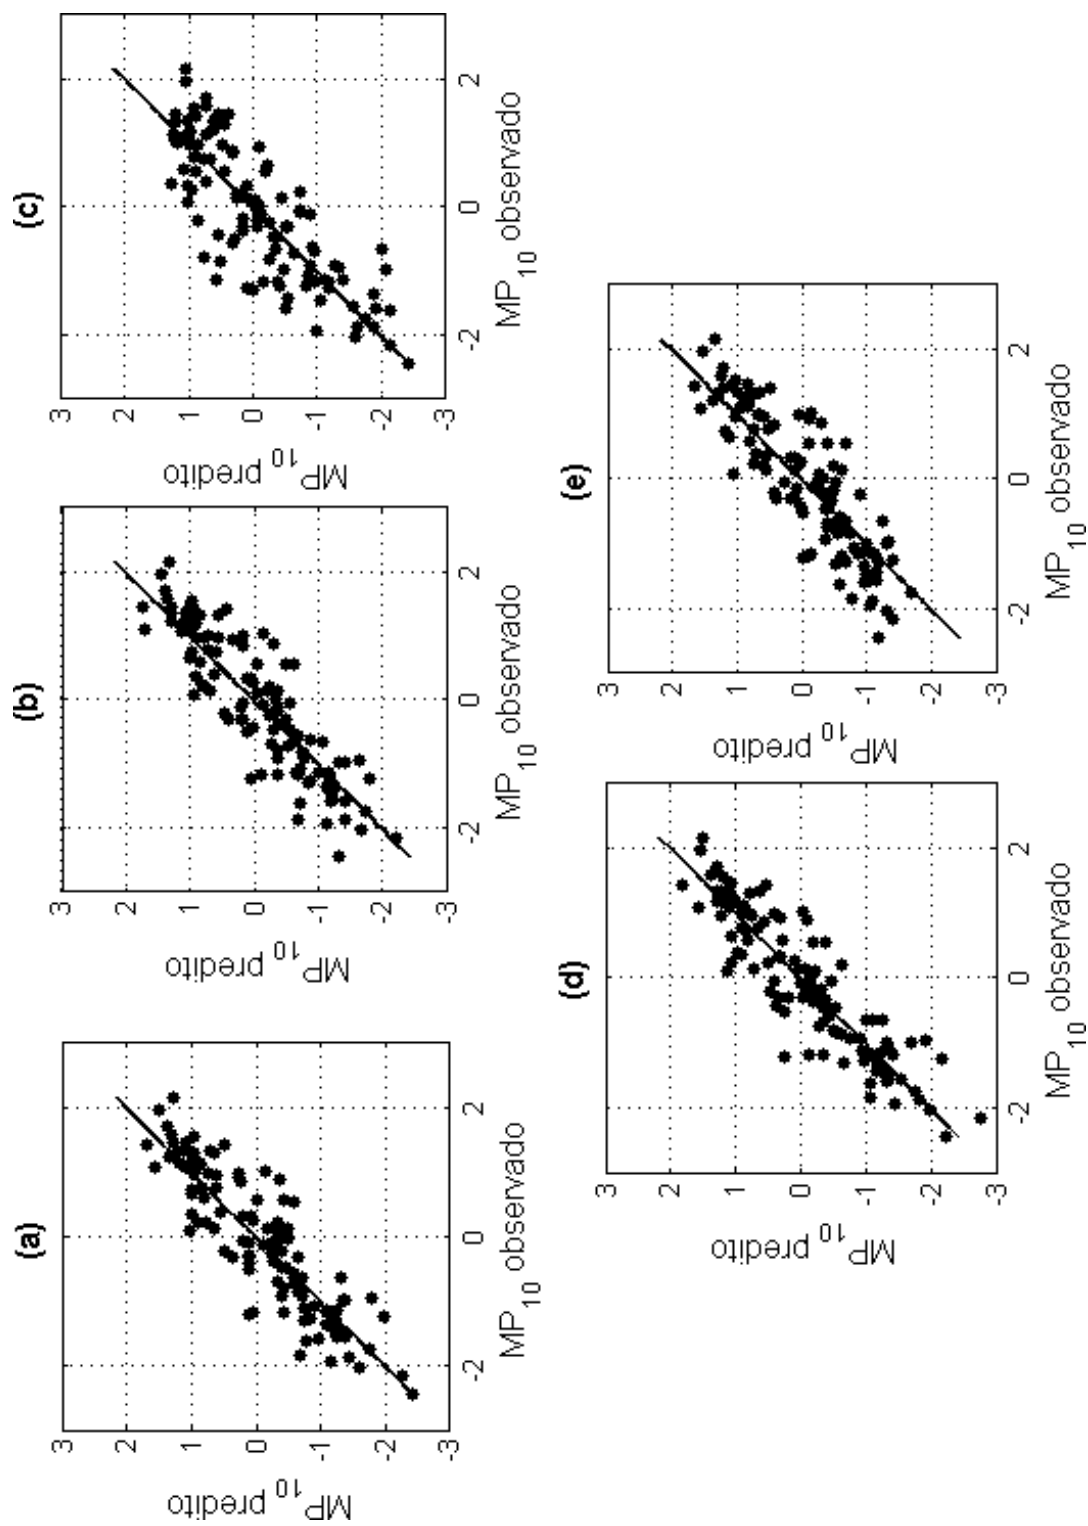


Figura 5.15: Concentrações de MP_{10} observadas e preditas na fase de validação: (a) ARX, (b) ARMAX, (c) OE, (d) BJ e (e) RNA.

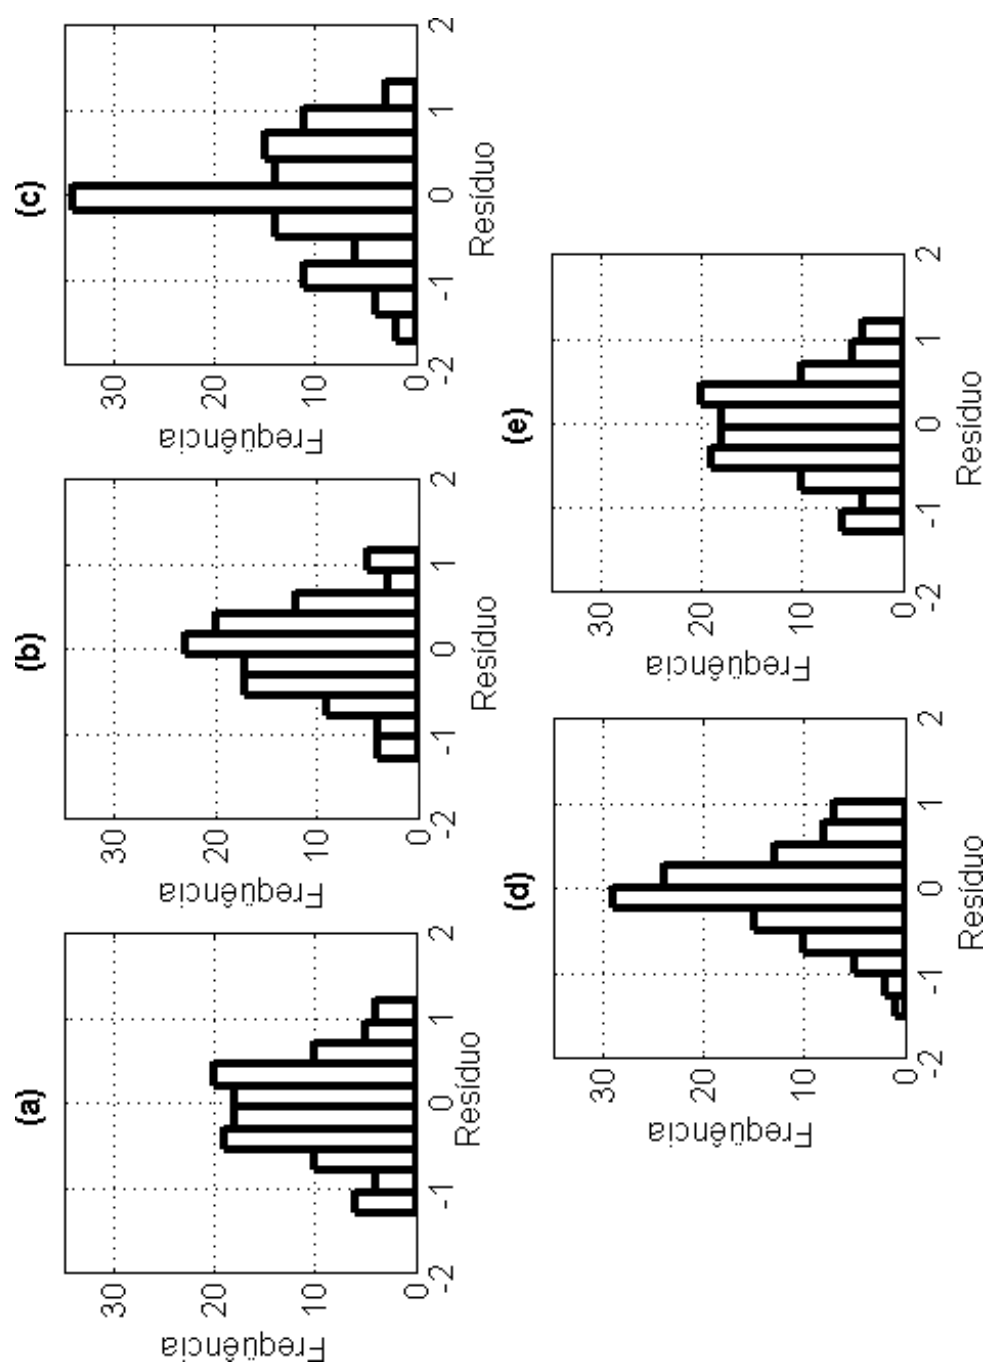


Figura 5.16: Histogramas dos erros de previsão da concentração de MP_{10} na fase de validação: (a) ARX, (b) ARMAX, (c) OE, (d) BJ, and (e) RNA.

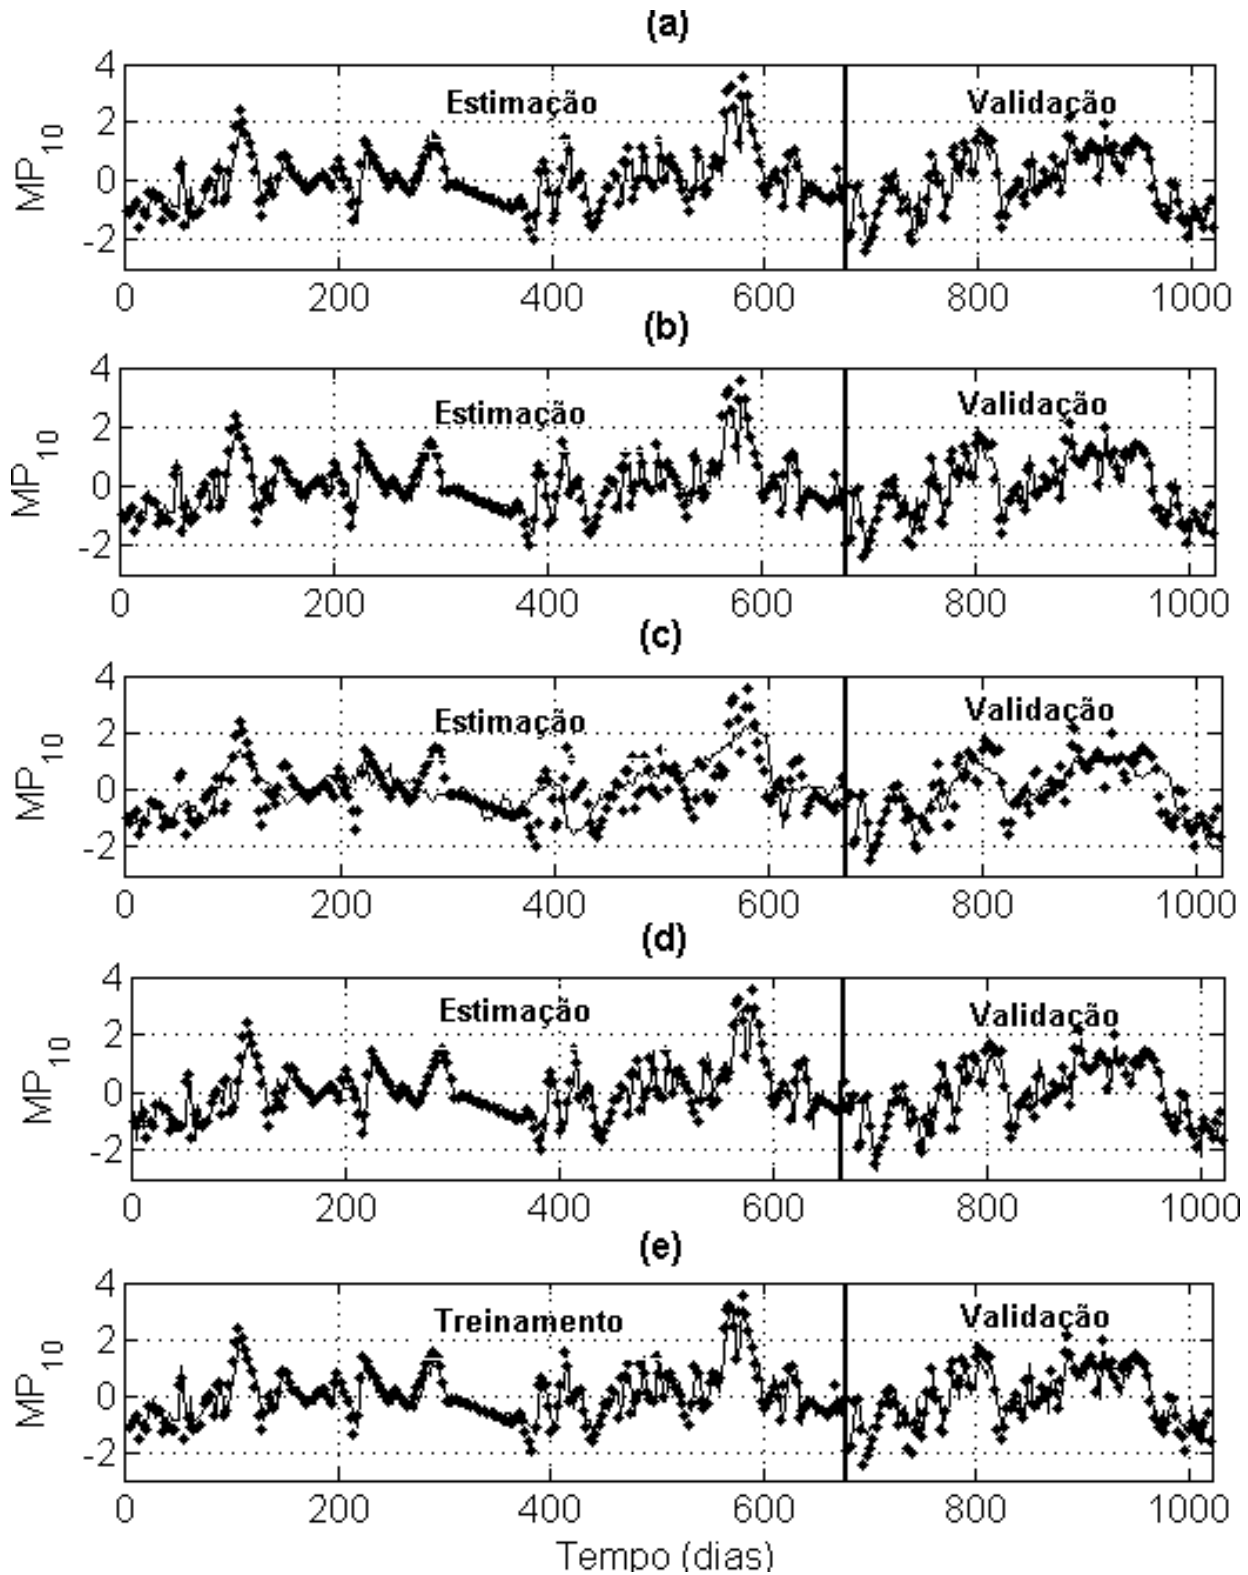


Figura 5.17: Simulação um passo à frente (linha) e valores observados (pontos): (a) ARX, (b) ARMAX, (c) OE, (d) BJ, and (e) RNA.

A RNA desenvolvida em Scilab foi do tipo *perceptron* multicamadas associada ao algoritmo de treinamento *backpropagation* padrão. O *Neural Network Toolbox 0.4.2* para Scilab permite utilizar apenas um tipo de função de ativação em todas as camadas (ocultas e de saída). Assim, para prover características não lineares ao modelo de previsão, adotou-se a função da ativação tangente hiperbólica, que é limitada em $[-1; 1]$. Logo, o conjunto de dados (total = 582) foi normalizado no intervalo $[-1; 1]$, e então dividido da seguinte maneira: 2/3 consecutivos para treinamento e 1/3 restante para validação. Paralelamente, foi desenvolvida uma RNA no *software* Matlab tão similar quanto possível a RNA em Scilab.

O número de neurônios da camada oculta (uma camada) foi variado de 1 a 30 e a melhor estrutura das RNAs foi definida como aquela que rendeu menor *RMSE*. O número ótimo de neurônios encontrado foi 6 para RNA em Scilab e 20 para RNA em Matlab. Essa diferença grande no número de neurônios ocorreu devido à inicialização aleatória dos pesos dos neurônios durante a fase de treinamento, que levou a mínimos locais diferentes. O mesmo poderia ter acontecido para RNAs desenvolvidas em um mesmo *software*.

Para avaliar o desempenho dos modelos três indicadores de desempenho mencionados anteriormente foram usados: *RMSE*, R^2 e d (Equações 4.21, 4.22 e 4.23). O desempenho dos modelos foi comparado com base nos valores preditos e observados na fase de validação. Os resultados estão resumidos na Tabela 5.3 que mostra que ambos os modelos renderam bons resultados.

Tabela 5.3: Indicadores de desempenho das RNAs em Scilab e em Matlab.

	Scilab	Matlab
<i>RMSE</i>	0,1883	0,2182
R^2	0,7511	0,9005
d	0,9269	0,9089

A Figura 5.18 exibe os gráficos dos valores observados e preditos pelos modelos na fase de validação. De acordo com esses gráficos e com os resultados da Tabela 5.3, a RNA em Scilab obteve predições tão boas quanto as obtidas pela RNA em Matlab. A Figura 5.19 mostra um bom ajuste entre as concentrações de MP_{10} observadas e preditas pelos modelos nas fases de treinamento e validação.

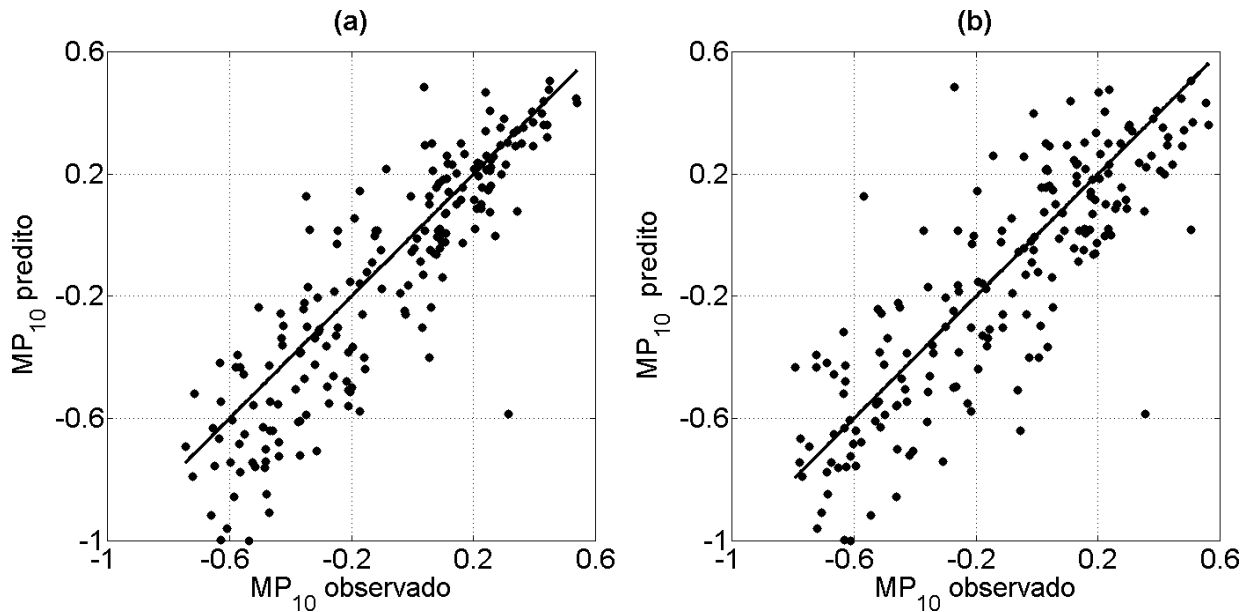


Figura 5.18: Concentrações de MP_{10} observadas e previstas na fase de validação: (a) Scilab e (b) Matlab.

Mesmo com um número menor de neurônios na camada oculta, o esforço computacional na fase de treinamento da RNA em Scilab foi um pouco maior. Entretanto, o *software* Scilab é livre e isso o faz mais atraente que o Matlab. O *Neural Network Toolbox 0.4.2* é uma ferramenta fácil usar e apesar de não ser popular entre estudantes e pesquisadores, é bastante útil para resolver alguns problemas de predição.

5.2.4 Modelos lineares: de 2003 a 2007

Dados de concentração de MP_{10} , meteorológicos e de fluxo de veículos do período de 2003 a 2007 foram usados neste estudo. As variáveis meteorológicas consideradas foram: temperatura, umidade relativa, precipitação, direção do vento, velocidade do vento, nebulosidade e insolação. Os dados de concentração de MP_{10} receberam o mesmo tratamento dado anteriormente, a saber: retirada de *outliers* e interpolações. Todavia, neste estudo os *outliers* retirados são os mesmo apresentados na Seção 5.1.3.

Antes de fornecer os dados aos modelos de previsão, eles foram transformados de três modos: **Mnmx** - normalização no intervalo $[-1; 1]$; **Prestd** - normalização com média = 0 e variância = 1; **Prestd + pca** - normalização com média = 0 e variância = 1 e análise de componentes principais.

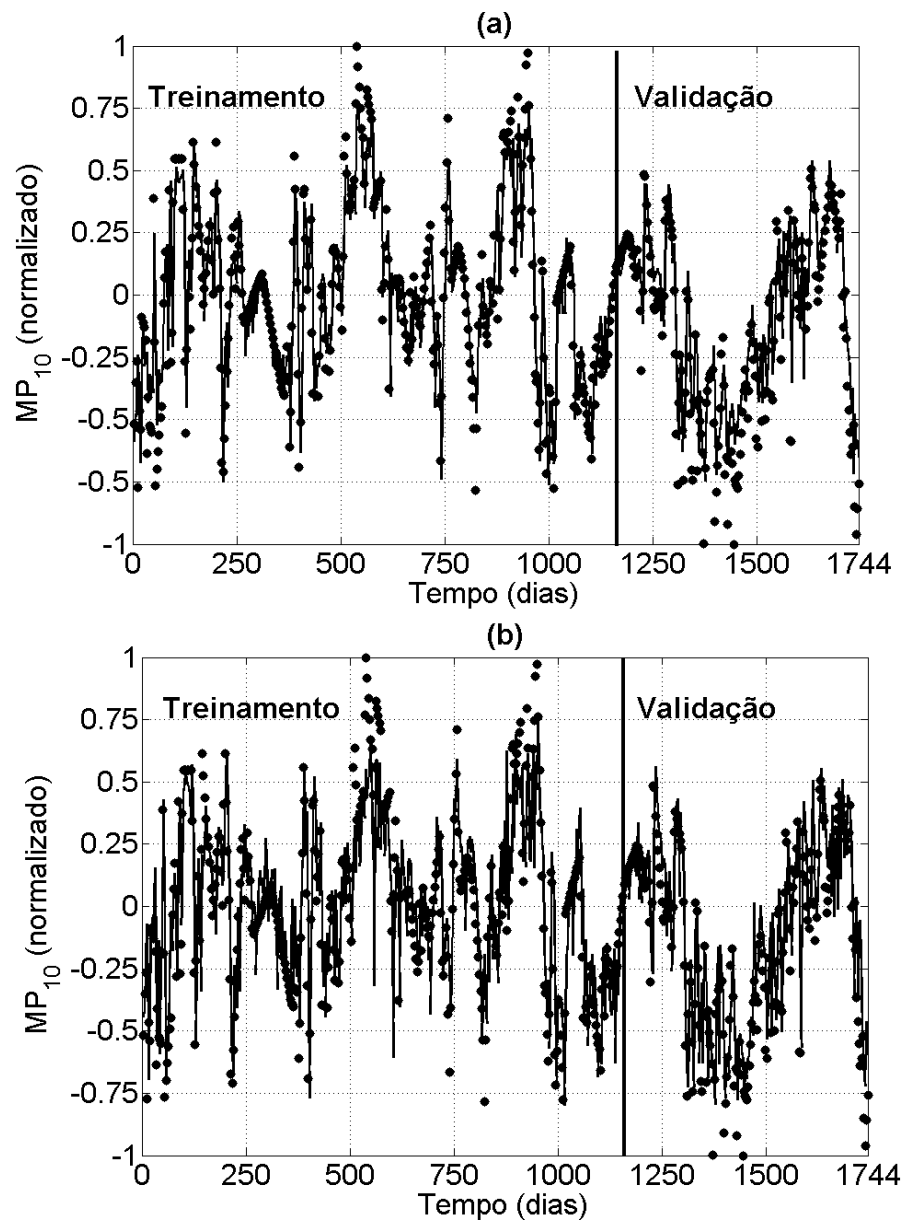


Figura 5.19: Simulação um passo à frente (linha) e valores observados (pontos): (a) Scilab e (b) Matlab.

Em seguida, os dados (total = 585) foram divididos em dois subconjuntos: 2/3 consecutivos para estimação e 1/3 restante para validação.

O *software* Matlab foi utilizado mais uma vez no desenvolvimento dos modelos lineares, que foram ajustados usando o *System Identification toolbox*. As ordens dos polinômios e os atrasos no tempo foram determinados utilizando os seguintes índices: critério de informação de Akaike (AIC), erro final de predição (FPE) e critério de informação de Bayes (BIC), definidos nas Equações

ções 4.18, 4.19 e 4.20. Os gráficos desses índices em função das ordens dos polinômios e dos atrasos no tempo estão no Apêndice B.2.

Para avaliar o desempenho dos modelos três indicadores de desempenho mencionados anteriormente, foram usados: $RMSE$, R^2 e d (Equações 4.21, 4.22 e 4.23). A comparação do desempenho dos modelos foi realizada com base nos valores de concentração de MP_{10} preditos e observados na fase de validação. Os resultados estão na Tabela 5.4.

Tabela 5.4: Indicadores de desempenho para os modelos lineares.

	ARX			ARMAX		
	$RMSE$	d	R^2	$RMSE$	d	R^2
mnmx	0,2308	0,9056	0,7250	0,2355	0,9060	0,8009
prestd	0,5948	0,9066	0,7236	0,5889	0,9112	0,7709
prestd+pca	0,6021	0,9044	0,7286	0,6135	0,9050	0,8028
	OE			BJ		
	$RMSE$	d	R^2	$RMSE$	d	R^2
mnmx	0,2886	0,8345	0,6162	0,2297	0,9138	0,8615
prestd	0,7483	0,8483	0,7577	0,6211	0,9079	0,9056
prestd+pca	0,7318	0,8253	0,4940	0,5947	0,9142	0,8646

Observa-se que os modelos que fizeram uso de dados normalizados no intervalo $[-1; 1]$ obtiveram os menores valores de $RMSE$, pois esse é um índice absoluto. Assim, comparações com base no $RMSE$ só podem ser realizadas entre os modelos que utilizaram o mesmo tipo de transformação de dados. Com exceção do modelo erro na saída, todos os outros modelos proveram bons resultados, e o modelo Box-Jenkins $[1, 1, 1, 1, 1]$ (prestd + pca) forneceu o melhor resultado segundo d , que é um índice relativo. Nota-se também que os valores de índices de desempenho apresentados em uma seção anterior (Tabela 5.2) são melhores do que os obtidos aqui. Isso porque a variabilidade dos dados de concentração de MP_{10} utilizados aqui é maior devido à menor quantidade de *outliers* retirados. Além disso, o banco de dados aqui utilizado é maior.

As Figuras 5.20-a, 5.20-b e 5.20-c exibem, respectivamente, os valores observados e preditos e o histograma dos resíduos na fase de validação e a simulação um passo à frente do modelo Box-Jenkins (prestd + pca). Os gráficos dos outros modelos estão no Apêndice B.2. O tempo de amostragem dos dados é de três dias, de forma que a predição de um passo à frente corresponde a prever a concentração de MP_{10} que dista três dias da última amostragem.

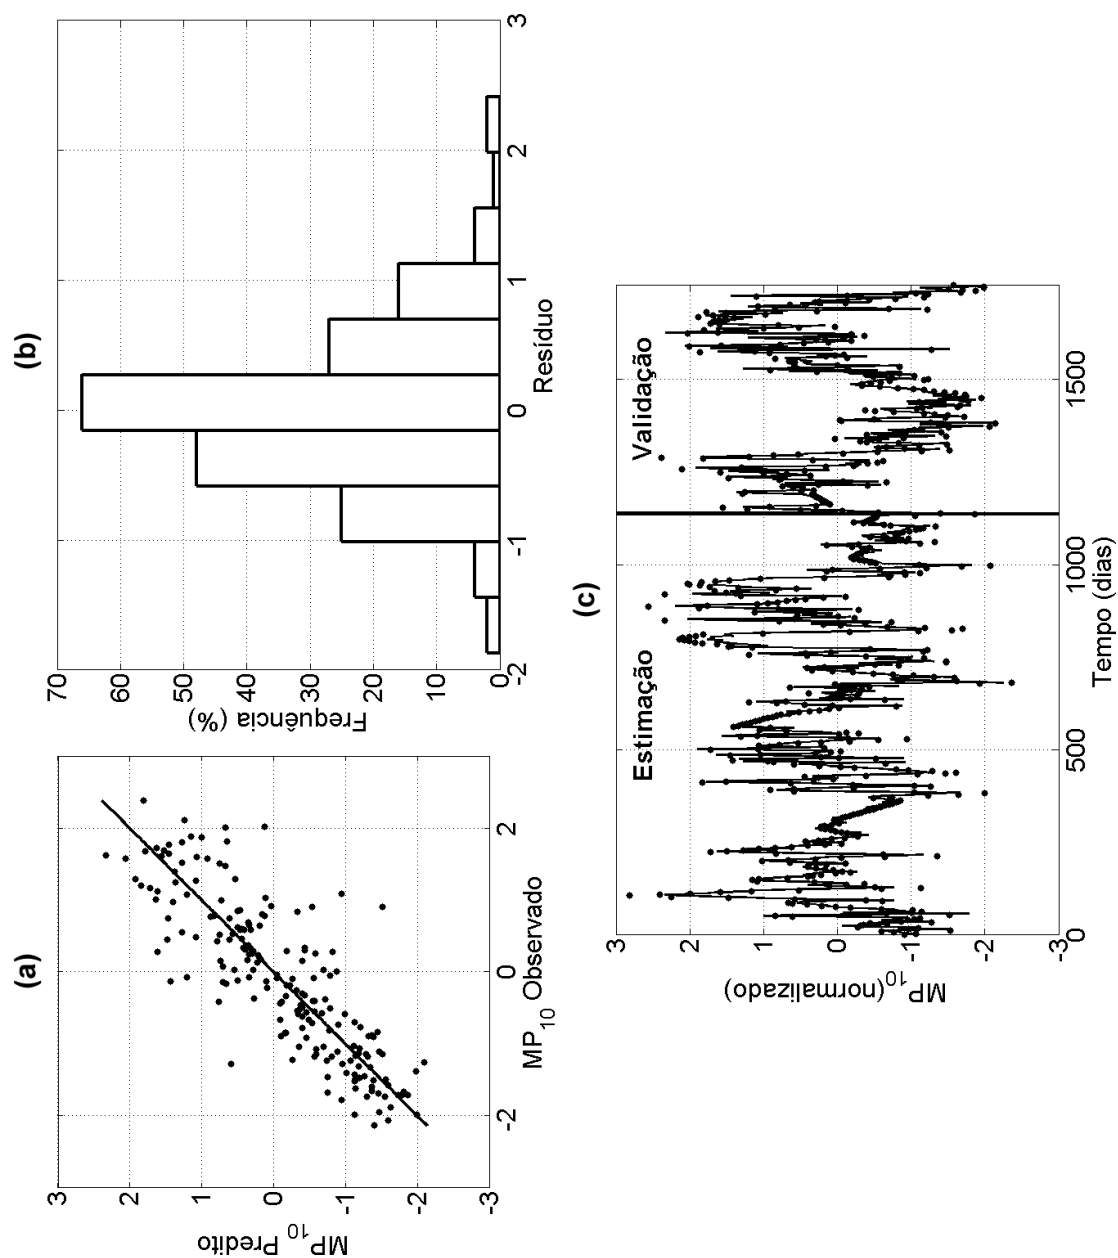


Figura 5.20: Modelo Box-Jenkins (prest + pca): (a) valores observados e preditos, (b) histograma dos resíduos e (c) simulação um passo à frente (linha) e valores observados (pontos).

As Figuras 5.21-a, 5.21-b, 5.21-c, 5.21-d e 5.21-e mostram as funções de correlação cruzada (AGUIRRE, 2004) entre o vetor de resíduos e as cinco variáveis de entradas resultantes da análise de componentes principais. As linhas pontilhadas delimitam o intervalo de confiança de 99%. Verifica-se que as funções de correlação cruzada das cinco variáveis de entrada estão dentro do intervalo de confiança para qualquer valor de atraso. Tem-se então que o vetor de resíduos do modelo não depende das variáveis de entrada usadas para obter o modelo. A implicação desse resultado é que as predições um passo à frente do modelo terão características semelhantes, se calculadas para outro conjunto de dados.

A Figura 5.21-f mostra a função de autocorrelação do vetor de resíduos do modelo Box-Jenkins. Observa-se que a função de autocorrelação é nula para todos os valores de atraso maiores ou iguais a um. Isto significa que os resíduos do modelo são aleatórios, ou seja, não há informação útil nos resíduos e o modelo explicou tudo que era possível explicar. Os gráficos das funções de autocorrelação e correlação cruzada para os outros modelos analisados estão no Apêndice B.2.

5.3 Relação entre MP_{10} e doenças respiratórias

5.3.1 Dados mensais por faixa etária

Esta investigação teve como proposta dimensionar as internações hospitalares decorrentes de doenças do aparelho respiratório ocorridas na rede pública na cidade de Uberlândia-MG. Os dados relativos às internações mensais por faixa etária foram obtidos via internet junto ao Departamento de Informática do Sistema Único de Saúde - DATASUS do Ministério da Saúde.

Pode-se observar nas Tabelas 5.5, 5.6, 5.7 e 5.8 a distribuição das internações hospitalares por distúrbios respiratórios e os coeficientes de prevalência⁴, segundo a faixa etária, ocorridas nos anos de 2003 a 2006.

⁴Prevalência representa a proporção da população que apresenta uma dada doença. Na área da saúde a prevalência ajuda o profissional a conhecer a probabilidade - ou risco - de um indivíduo sofrer de determinada doença.

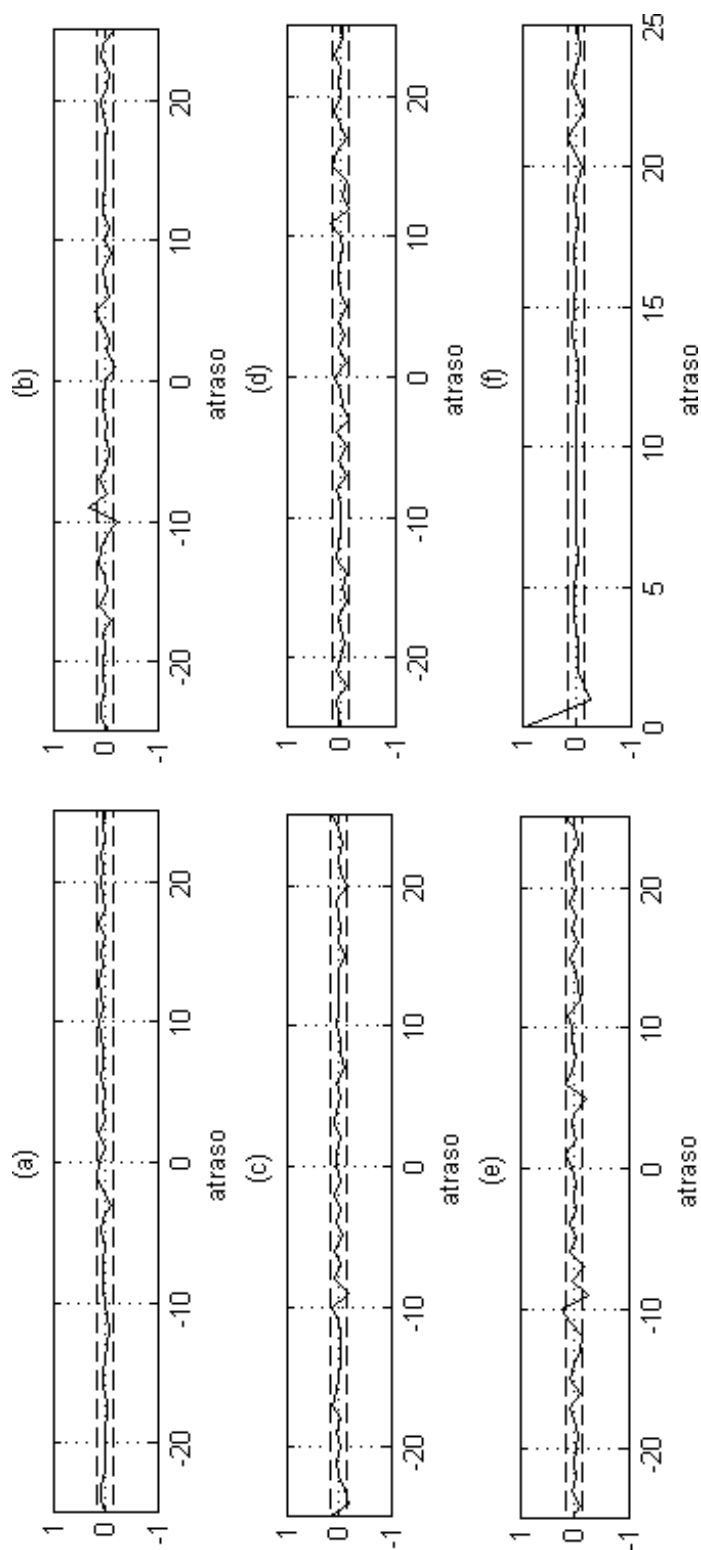


Figura 5.21: Modelo Box-Jenkins (prest + pca): (a), (b), (c), (d) e (e) funções de correlações cruzada entre o vetor de resíduos e as variáveis de entrada; (f) função de autocorrelação do vetor de resíduos.

Tabela 5.5: Distribuição das internações hospitalares e respectivos coeficientes de prevalência por doenças respiratórias na rede pública, da população residente em Uberlândia-MG, por faixa etária, em 2003.

Faixa etária	População total do município	Total de internações hospitalares por doenças respiratórias	Prevalência (x 1000)
Menor 1 ano	8.503	664	78,1
1 a 4 anos	36.153	873	24,1
5 a 9 anos	47.172	226	4,8
10 a 14 anos	49.903	75	1,5
15 a 19 anos	53.908	38	0,7
20 a 29 anos	104.973	109	1,0
30 a 39 anos	91.756	98	1,1
40 a 49 anos	69.589	135	1,9
50 a 59 anos	39.913	137	3,4
60 a 69 anos	24.152	170	7,0
70 a 79 ano	12.063	165	13,7
80 e mais	4.455	168	37,7
Total	542.540	2.858	5,3

Tabela 5.6: Distribuição das internações hospitalares e respectivos coeficientes de prevalência por doenças respiratórias na rede pública, da população residente em Uberlândia-MG, por faixa etária, em 2004.

Faixa etária	População total do município	Total de internações hospitalares por doenças respiratórias	Prevalência (x 1000)
Menor 1 ano	8.707	644	74,0
1 a 4 anos	37.024	904	24,4
5 a 9 anos	48.308	317	6,6
10 a 14 anos	51.106	149	2,9
15 a 19 anos	55.207	88	1,6
20 a 29 anos	107.500	247	2,3
30 a 39 anos	93.965	185	2,0
40 a 49 anos	71.264	207	2,9
50 a 59 anos	40.875	185	4,5
60 a 69 anos	24.733	220	8,9
70 a 79 ano	12.354	203	16,4
80 e mais	4.563	156	34,2
Total	555.606	3.505	6,3

Tabela 5.7: Distribuição das internações hospitalares e respectivos coeficientes de prevalência por doenças respiratórias na rede pública, da população residente em Uberlândia-MG, por faixa etária, em 2005.

Faixa etária	População total do município	Total de internações hospitalares por doenças respiratórias	Prevalência (x 1000)
Menor 1 ano	9.172	551	60,0
1 a 4 anos	38.999	805	20,6
5 a 9 anos	50.886	339	6,7
10 a 14 anos	53.833	146	2,7
15 a 19 anos	58.154	124	2,1
20 a 29 anos	113.239	322	2,8
30 a 39 anos	98.981	220	2,2
40 a 49 anos	75.068	206	2,7
50 a 59 anos	43.056	208	4,8
60 a 69 anos	26.054	215	8,2
70 a 79 ano	13.012	176	13,5
80 e mais	4.806	131	27,3
Total	585.260	3.443	5,9

Tabela 5.8: Distribuição das internações hospitalares e respectivos coeficientes de prevalência por doenças respiratórias na rede pública, da população residente em Uberlândia-MG, por faixa etária, em 2006.

Faixa etária	População total do município	Total de internações hospitalares por doenças respiratórias	Prevalência (x 1000)
Menor 1 ano	9.409	716	76,1
1 a 4 anos	40.007	1.125	28,1
5 a 9 anos	52.199	442	8,5
10 a 14 anos	55.222	160	2,9
15 a 19 anos	59.654	103	1,7
20 a 29 anos	116.161	317	2,7
30 a 39 anos	101.537	262	2,6
40 a 49 anos	77.006	255	3,3
50 a 59 anos	44.168	205	4,6
60 a 69 anos	26.726	210	7,9
70 a 79 ano	13.348	168	12,6
80 e mais	4.930	137	27,8
Total	600.367	4.102	6,8

Em todos os anos analisados, o predomínio nas hospitalizações ocorreu na faixa etária infantil correspondente até quatro anos de idade, com percentagens próximas de 45% em relação ao total dos pacientes internados. Observa-se, também, que, apesar de representar uma pequena parcela do total da população, aproximadamente 7,5%, os idosos maiores de 70 anos tiveram altos valores de prevalência, ficando atrás apenas da faixa etária infantil até quatro anos.

As Figuras 5.22 e 5.23 comparam o número total mensal de internações por doenças respiratórias e concentrações médias mensais de MP_{10} do mesmo período. Apesar de existir, não foi possível identificar visualmente, a partir dos dados disponíveis, relações entre a concentração de MP_{10} e o número de internações por problemas respiratórios, tanto para crianças menores de quatro anos, quanto para idosos maiores de 70 anos. Dividir o problema por tipo de doença ou por região do sistema respiratório pode favorecer futuras comparações. Espera-se também que com a utilização de métodos estatísticos, essa relação possa ser estabelecida.

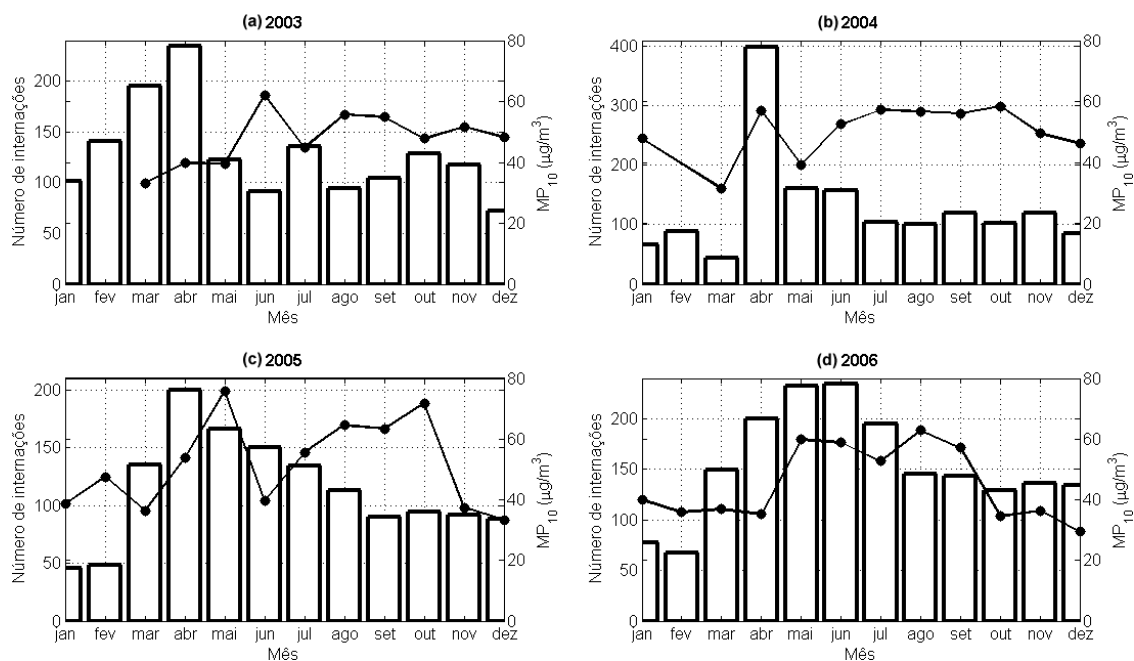


Figura 5.22: Comparação do número total mensal de internações por doenças respiratórias e concentrações médias mensais de MP_{10} para crianças menores de quatro anos, em relação aos anos de (a) 2003, (b) 2004, (c) 2005 e (d) 2006.

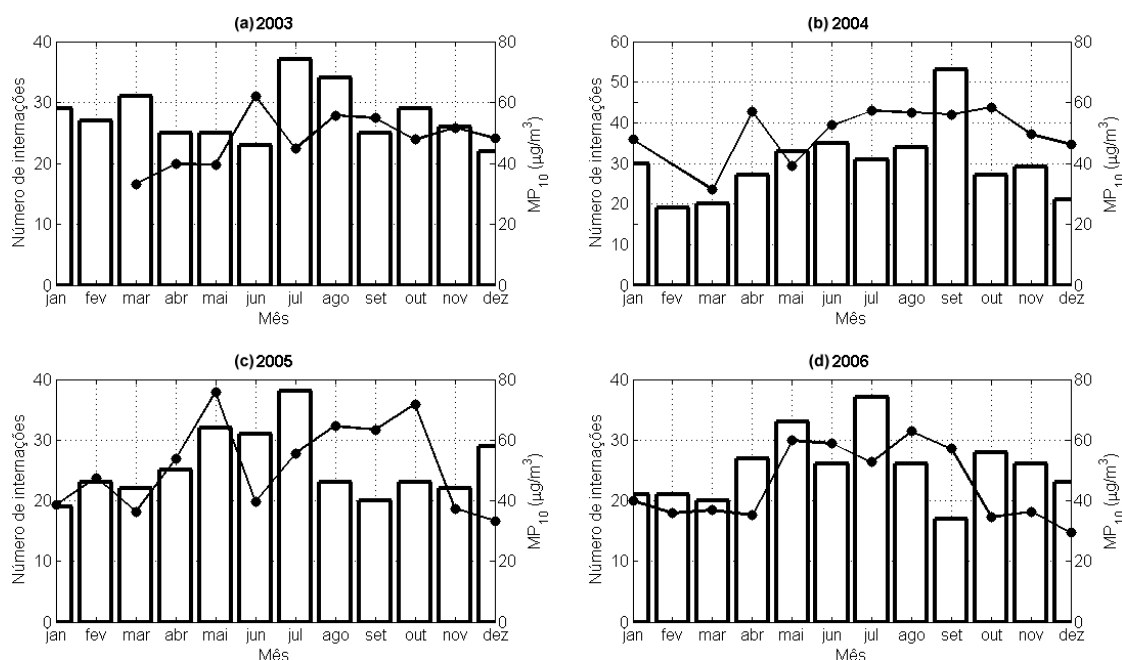


Figura 5.23: Comparação do número total mensal de internações por doenças respiratórias e concentrações médias mensais de MP_{10} para idosos maiores de 70 anos, em relação aos anos de (a) 2003, (b) 2004, (c) 2005 e (d) 2006.

5.3.2 Dados diários por tipo de doença

Os dados de número de atendimentos diários por doenças do aparelho respiratório foram obtidos junto a direção do Hospital das Clínicas de Uberlândia. Esses dados são do mesmo período dos dados de concentração de MP_{10} , isto é, de 11 de março de 2003 a 31 de dezembro de 2007. Os atendimentos são classificados segundo causa básica no Capítulo X - Doenças do Aparelho Respiratório da décima Revisão da Classificação Internacional de Doenças (CID-10), como mostra a Tabela 5.9.

Para verificar a relação entre o número de atendimentos hospitalares decorrentes de doenças do aparelho respiratório e a concentração de MP_{10} do mesmo dia foram calculados coeficientes de correlação para cada classe da CID-10. Segundo Dockery e Pope III (1994), ao se avaliar esse tipo de relação, deve-se levar em consideração também variáveis meteorológicas como temperatura e umidade relativa. Assim, também foram calculados os coeficientes de correlação para estas variáveis. Na Tabela 5.10, estão os coeficientes de correlação de Pearson com os respectivos p-valores das variáveis analisadas. Os coeficientes de correlação que apresentaram significância estatística estão em negrito.

Tabela 5.9: Lista de doenças do aparelho respiratório segundo a décima Revisão da Classificação Internacional de Doenças (CID-10).

Código	Descrição
165	Faringite aguda e amigdalite aguda
166	Laringite e traqueíte agudas
167	Outras infecções agudas das vias aéreas superiores
168	Influenza (gripe)
169	Pneumonia
170	Bronquite aguda e bronquiolite aguda
171	Sinusite crônica
172	Outras doenças do nariz e dos seios paranasais
173	Doenças crônicas das amígdalas e das adenóides
174	Outras doenças do trato respiratório superior
175	Bronquite, enfisema e outras doenças pulmonares obstrutivas crônicas
176	Asma
177	Bronquiectasia
178	Pneumoconiose
179	Outras doenças do aparelho respiratório

Tabela 5.10: Coeficientes de correlação de Pearson com os respectivos p-valores para os dados de atendimentos por doenças do aparelho respiratório¹.

Código	MP_{10}		Temperatura		Umidade relativa	
165	-0,002	(0,977)	0,024	(0,653)	-0,033	(0,536)
166	0,063	(0,238)	-0,054	(0,313)	-0,065	(0,225)
167	0,147	(0,006)	-0,215	(0,049)	-0,062	(0,251)
168	-0,033	(0,539)	-0,149	(0,005)	-0,009	(0,867)
169	0,176	(0,001)	-0,131	(0,014)	-0,119	(0,025)
170	-0,040	(0,457)	-0,036	(0,505)	0,058	(0,283)
171	0,036	(0,504)	-0,170	(0,001)	-0,102	(0,056)
172	-0,031	(0,569)	-0,026	(0,630)	-0,007	(0,901)
173	-0,022	(0,685)	0,030	(0,573)	0,097	(0,069)
174	-0,051	(0,344)	0,027	(0,621)	-0,038	(0,474)
175	0,094	(0,079)	-0,145	(0,007)	-0,038	(0,482)
176	-0,008	(0,884)	-0,086	(0,110)	0,049	(0,363)
177	-0,071	(0,183)	-0,007	(0,899)	0,034	(0,531)
178 ²	-	-	-	-	-	-
179	0,044	(0,414)	-0,109	(0,042)	0,045	(0,399)

¹ Valores à esquerda são os coeficientes de correlação e os valores à direita, entre parênteses, são p-valores.² Não houve registro no período analisado.

Observa-se que a concentração de MP₁₀ apresentou correlação direta com outras infecções agudas das vias aéreas superiores (cód. 167) e com a pneumonia (cód. 169). A temperatura manifestou correlação inversa com um número maior de classes, a saber: outras infecções agudas das vias aéreas superiores (cód. 167), influenza (cód. 168), pneumonia (cód. 169), sinusite crônica (cód. 171) e bronquite, enfisema e outras doenças pulmonares obstrutivas crônicas (cód. 175). E a umidade relativa mostrou correlação inversa apenas com a pneumonia (cód. 169). No entanto, todas estas correlações são consideradas fracas. E como já foi dito, o coeficiente de correlação mede a intensidade da relação linear entre as variáveis. Mesmo não havendo correlações, ou elas sendo fracas, pode haver relações não lineares fortes entre as variáveis estudadas.

Na tentativa de identificar algum tipo de relação entre a concentração de MP₁₀ e o número de atendimentos hospitalares decorrentes de doenças do aparelho respiratório, foram construídos gráficos de dispersão das variáveis analisadas (Figuras 5.24 e 5.25). Verifica-se em todos os gráficos uma nuvem dispersa de pontos, sem tendência visível. Os gráficos de dispersão para a temperatura e umidade relativa estão no Apêndice B.3.

De acordo com Schwartz (1999), em um estudo dessa relação, caso exista, deve-se considerar que as causas nem sempre se dão no mesmo dia em que ocorre o atendimento, ou seja, o número de atendimentos ocorridos num determinado dia pode ser consequência das condições meteorológicas ou de poluição atmosférica de vários dias anteriores. Assim, recomenda-se um estudo mais aprofundado dessas relações considerando esse tempo de defasagem.

Cabe ressaltar, ainda, que essas informações referem-se somente aos atendimentos do Hospital das Clínicas de Uberlândia, que é uma unidade hospitalar que pertence à Universidade Federal de Uberlândia e que é referência na região do Triângulo Mineiro. Mas não está incluída nesta investigação uma considerável parcela da população que fez uso de postos de saúde municipais e hospitais particulares no mesmo período do estudo.

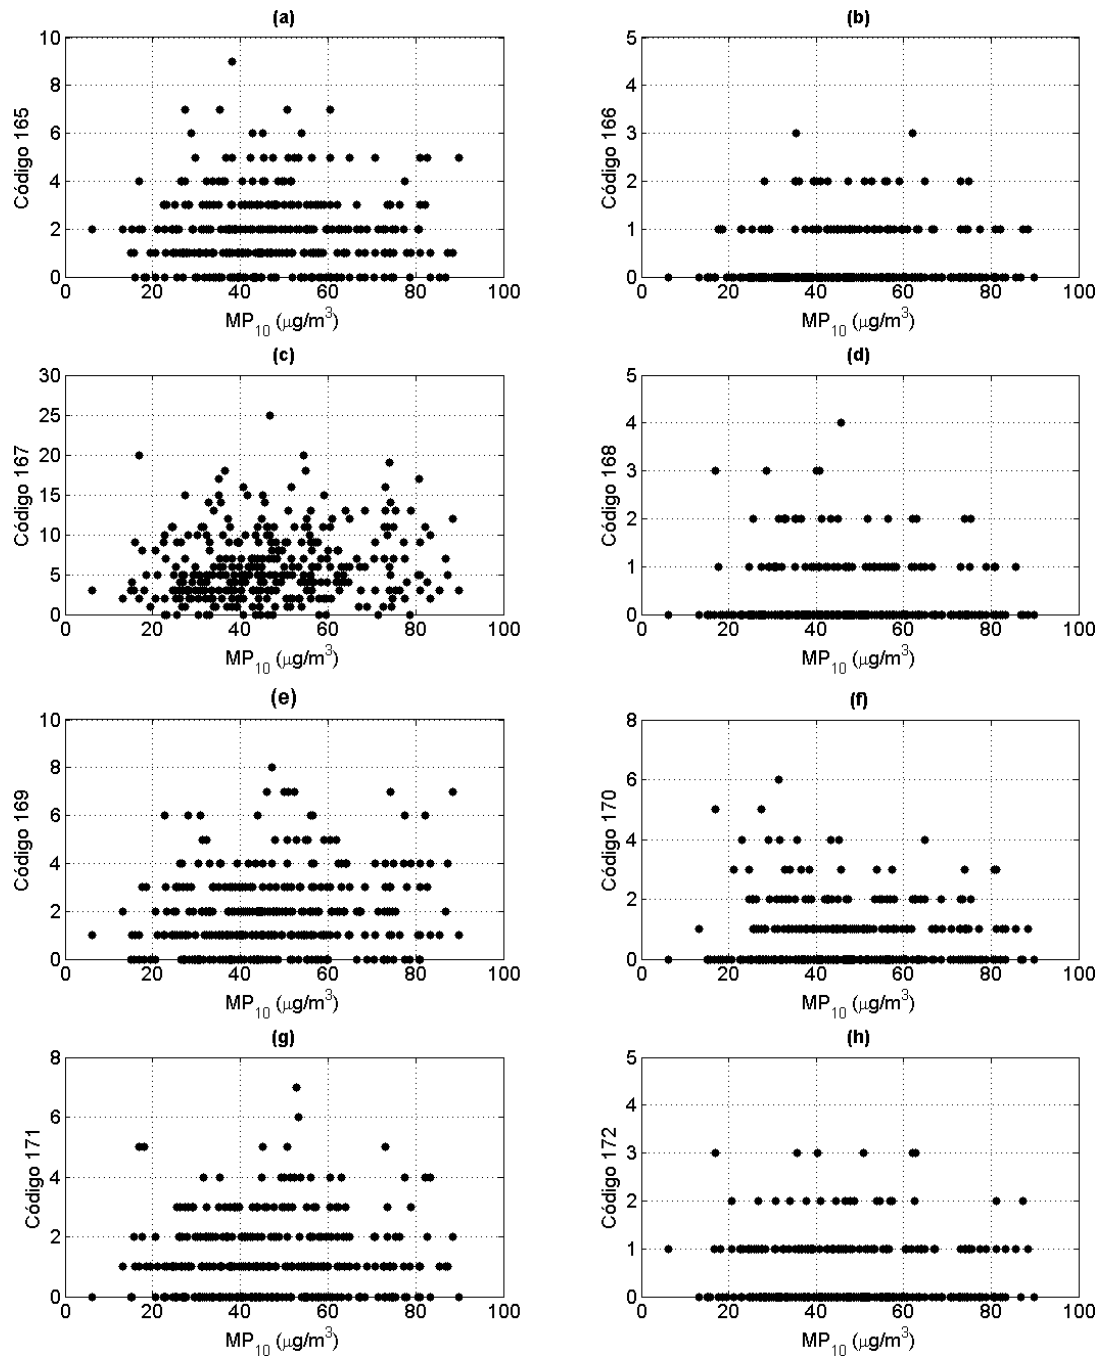


Figura 5.24: Dispersão da concentração de MP_{10} em função das classes da CID-10 (de 165 a 172) para doenças do aparelho respiratório.

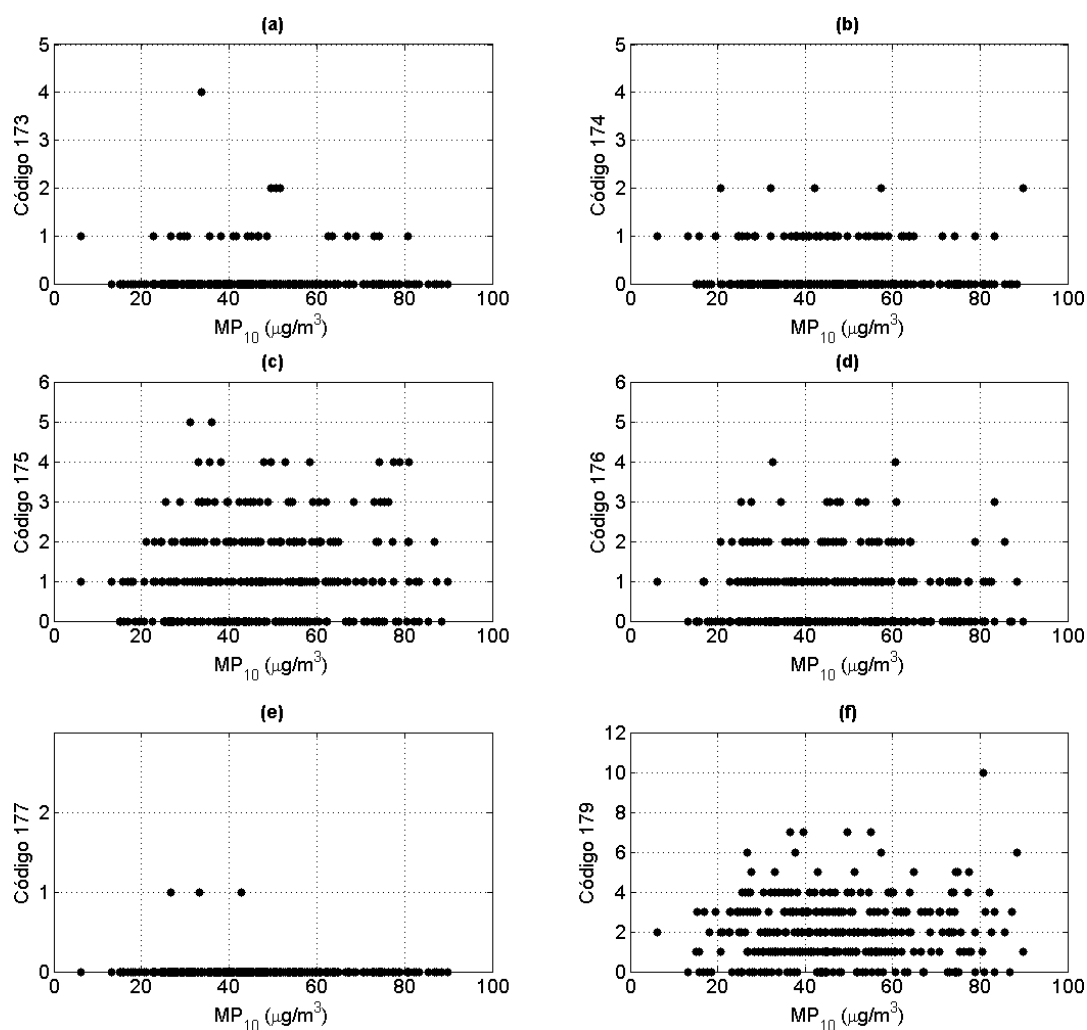


Figura 5.25: Dispersão da concentração de MP_{10} em função das classes da CID-10 (de 173 a 179, com exceção de 178) para doenças do aparelho respiratório.

CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS

6.1 Conclusões

De modo geral, as maiores concentrações de MP_{10} foram obtidas no período do inverno, quando as condições atmosféricas são desfavoráveis à dispersão e remoção de poluentes, e as menores concentrações de MP_{10} foram obtidas aos sábados e domingos, quando o fluxo de veículos é menor.

Em 2007, mesmo com condições meteorológicas desfavoráveis (período seco mais prolongado), houve uma redução na concentração média de MP_{10} . Ou seja, a redução do fluxo de veículos no local de amostragem foi decisiva para o menor valor da concentração média de MP_{10} .

Apesar de as correlações lineares entre a concentração de MP_{10} e as variáveis meteorológicas e fluxo de veículos serem fracas ou não existirem, todas as variáveis analisadas foram utilizadas nos modelos de previsão, pois pode haver relações não lineares fortes entre as mesmas.

Foi mostrado que, ao se utilizar RNAs com processamento temporal, é necessário que os dados informados tenham a mesma frequência de amostragem, pois, do contrário, o desempenho do modelo é prejudicado. Essa observação estende-se também aos modelos lineares.

Na predição da qualidade do ar na cidade de Uberlândia, cinco modelos empíricos foram avaliados, um baseado em redes neurais e quatro modelos lineares, a saber: ARX, ARMAX, erro na saída e Box-Jenkins. Os modelos usaram variáveis meteorológicas e fluxo de veículos como dados de entrada. Como saída prevista pelo modelo, a concentração de MP_{10} é obtida com horizonte de predição de três dias à frente. Os resultados mostraram que boas estimativas podem ser obtidas pelos modelos, com exceção do modelo linear erro na saída.

Foi mostrado que é possível desenvolver uma RNA em Scilab com facilidade. A RNA em Scilab obteve predições tão boas quanto as obtidas pela RNA em Matlab, apesar do esforço de treinamento um pouco maior da RNA em Scilab.

As melhores estimativas da concentração de MP_{10} foram obtidas pelo modelo linear Box-Jenkins. A análise de resíduos desse modelo indicou que os parâmetros do mesmo foram estimados corretamente, ou seja, o modelo explicou tudo que era possível explicar, e que o mesmo pode ser usado para outro conjunto de dados sem perda de qualidade.

Os modelos propostos podem ser usados, entre outros propósitos, pelo Governo público local como uma ferramenta para ativar ações de emergência durante períodos de estagnação atmosférica, quando os níveis de MP_{10} na atmosfera possam representar risco à saúde pública. Até mesmo municípios com baixo orçamento podem usar as capacidades de predição oferecidas pelo *Neural Network Toolbox 0.4.2*, pois o Scilab não tem nenhum custo de aquisição e nem qualquer taxa de licenciamento anual.

Verificou-se que o predomínio nas internações hospitalares em Uberlândia decorrentes de doenças do aparelho respiratório ocorreu na faixa etária infantil correspondente até quatro anos de idade. Entretanto, não foi possível confirmar, com as metodologias utilizadas e os dados disponíveis, relações entre a concentração de MP_{10} e o número de atendimentos por problemas respiratórios em Uberlândia.

6.2 Sugestões para trabalhos futuros

- Continuar o monitoramento do material particulado em Uberlândia. Isto é fundamental para avaliar os impactos de um crescimento expressivo do número de usinas de açúcar e álcool esperado na região;
- Utilizar dados de outra cidade para avaliar os modelos desenvolvidos. Por exemplo, os dados horários que são obtidos pela CETESB desde 2003;
- Considerar outros parâmetros meteorológicos, como estabilidade atmosférica e turbulência, no desenvolvimento dos modelos;
- Avaliar a inserção da previsão do tempo com entrada para os modelos desenvolvidos;
- Adaptar para Uberlândia os modelos de emissão veicular (Mobile 6) e de dispersão (Caline 3) desenvolvidos para a US-EPA, cujos códigos em Fortran estão disponíveis para *download* gratuito no site: <http://www.weblakes.com/lakeepa.html>;
- Fazer um inventário de emissões veiculares para Uberlândia pelo método CETESB. Para isto é necessário obter dados da frota da cidade por ano de fabricação do veículo e por tipo de combustível utilizado;
- Utilizar modelos estatísticos, como por exemplo, o modelo aditivo generalizado de regressão de Poisson, para avaliar a associação entre poluição atmosférica, em termos de MP_{10} , e doenças respiratórias na cidade de Uberlândia.

REFERÊNCIAS BIBLIOGRÁFICAS

ABNT. *Material suspenso na atmosfera - Determinação da concentração de partículas inaláveis pelo método do amostrador de grande volume acoplado a um separador inercial de partículas*. Rio de Janeiro, junho 1995.

AGIRRE-BASURKO, E.; IBARRA-BERASTEGI, G.; MADARIAGA, I. Regression and multilayer perceptron-based models to forecast hourly O₃ and NO₂ levels in the Bilbao area. *Environmental Modelling & Software*, v. 21, p. 430–446, 2006.

AGUIRRE, L. A. *Introdução à identificação de sistemas: técnicas lineares e não lineares aplicadas a sistemas reais*. Belo Horizonte: Editora UFMG, 2004.

AHRENS, C. D. *Essentials of meteorology an invitation to the atmosphere*. 3. ed. Canada: Thomas Learning Inc., 2001.

ALEKXANDER, I.; MORTON, H. *An Introduction to Neural Computing*. London: Chapman and Hall, 1990.

ÁLVARES JR., O. M.; LACAVA, C. I. V.; FERNANDES, P. S. *Emissões atmosféricas*. Brasília: SENAI/DN, 2002.

BAKONYIA, S. M. C. et al. Poluição atmosférica e doenças respiratórias em crianças na cidade de Curitiba, PR. *Revista de Saúde Pública*, v. 38, p. 695–700, 2004.

BARBOSA, E. A. et al. A study about the quality of the atmospheric air of the Uberlandia city in Brazil. In: *15th International Congress of Chemical and Process Engineering*. Praga: [s.n.], 2002.

- BOUBEL, R. et al. *Fundamentals of air pollution*. 3. ed. San Diego, CA: Academic Press, 1994.
- CARNEIRO, R. M. A. *Bioindicadores vegetais de poluição atmosférica: uma contribuição para a saúde da comunidade*. Dissertação (Mestrado) — Universidade de São Paulo, 2004.
- CETESB. *Relatório de qualidade do ar no estado de São Paulo 2006*. São Paulo, 2007.
- CONAMA. *Resolução CONAMA nº 03, de 28 de junho de 1990*. 1990.
- COSTA, E. S. *Efeitos da poluição do ar relacionados com o crescimento da área urbanizada e do número de veículos automotores no Distrito Federal*. Dissertação (Mestrado) — Universidade Católica de Brasília, 2002.
- CYBENKO, G. *Continuous valued networks with two hidden layers are sufficient*. Department of Computer Science, Tufts University, 1988.
- CYBENKO, G. Approximations by superpositions of a sigmoidal function. *Math. Control Signal Systems*, v. 2, p. 303–314, 1989.
- DERÍSIO, J. *Introdução ao controle de poluição ambiental*. São Paulo: Cetesb, 1992.
- DILLON, W. R.; GOLDSTEIN, M. *Multivariate analysis methods and applications*. New York: John Wiley & Sons, 1984.
- DOCKERY, D. W.; Pope III, C. Acute respiratory effects of particulate air pollution. *Annual Review Public Health*, v. 15, p. 107–132, 1994.
- ELMAN, J. L. Finding structure in time. *Cognitive Science*, v. 14, p. 179–211, 1990.
- ENERGÉTICA. *AGV MP10: Manual de operação*. Rio de Janeiro, 1999.
- GRIVAS, G.; CHALOULAKOU, A. Artificial neural network models for prediction of PM10 hourly concentrations, in the greater area of Athens, Greece. *Atmospheric Environment*, v. 40, p. 1216–1229, 2006.
- GUARDANI, R. et al. Study of atmospheric ozone formation by means of a neural network-based model. *Journal of the Air and Waste Management Association*, v. 49, p. 316–323, 1999.
- HAYKIN, S. *Neural Networks: A Comprehensive Foundation*. New York: Macmillan College Publishing Company, Inc., 1994.

HEINSOHN, R.; KABEL, R. L. *Sources and control of air pollution*. Upper Saddle River: Prentice Hall, 1999.

HENRIQUE, H. M. *Redes neurais: teoria e aplicações*. 2005.

HINDS, W. *Aerosol technology: properties, behavior and measurement of airborne particles*. New York: John Wiley & Sons, 1999.

IPCC. *Climate change 2001: impacts, adaptations and vulnerability, summary for policymakers*. Cambridge: Intergovernmental Panel on Climate Change, Cambridge University Press, 2007. 1-17 p.

JIANG, D. et al. Progress in developing an ann model for air pollution index forecast. *Atmospheric Environment*, v. 38, p. 7055–7064, 2004.

KIPERSTOK, A. et al. *Prevenção da poluição*. Brasília: SENAI/DN, 2002.

KOLEHMAINEN, M.; MARTIKAINEN, H.; RUUSKANEN, J. Neural networks and periodic components used in air quality forecasting. *Atmospheric Environment*, v. 35, p. 815–825, 2001.

KUKKONEN, J. et al. Extensive evaluation of neural network models for the prediction of NO₂ and PM₁₀ concentrations, compared with a deterministic modelling system and measurements in central Helsinki. *Atmospheric Environment*, v. 37, p. 4539–4550, 2003.

LANG, K. J.; HINTON, G. E. *Development of the time-delay neural networks architecture for speech recognition*. [S.l.], 1988.

LIMA, E. A. P. *Um estudo sobre a qualidade do ar de Uberlândia: material particulado em suspensão*. Tese (Doutorado) — Universidade Federal de Uberlândia, 2007.

LIU, D. H. F.; LIPTAK, B. G. *Environmental engineers' handbook*. Boca Raton: CRC Press LLC, 1999.

LJUNG, L. *System identification: theory for the user*. Upper Saddle River: PTR Prentice-Hall, 1999.

MANAHAN, S. E. *Environmental chemistry*. 7. ed. New York: CRC Press LLC, 2000.

MANLY, B. F. J. *Multivariate statistical methods: a primer*. London: Chapman & Hall, 1994.

- MARTINS, L. et al. Poluição atmosférica e atendimentos por pneumonia e gripe em São Paulo, Brasil. *Revista de Saúde Pública*, v. 36, p. 88–94, 2002.
- MARTINS, L. et al. Relação entre poluição atmosférica e atendimentos por infecção de vias aéreas superiores no município de São Paulo: avaliação do rodízio de veículos. *Revista Brasileira de Epidemiologia*, v. 4, p. 220–229, 2001.
- MARTINS, L. C. et al. Efeitos da poluição do ar nas doenças cardiovasculares: estruturas de defasagem. *Revista de Saúde Pública*, v. 40, p. 677–683, 2006.
- MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, v. 5, p. 115–133, 1943.
- MEDEIROS, A.; GOUVEIA, N. Relação entre baixo peso ao nascer e a poluição do ar no município de São Paulo. *Revista Saúde Pública*, v. 39, p. 965–972, 2005.
- MENDES, P. C. *A gênese espacial das chuvas na cidade de Uberlândia – MG*. Dissertação (Mestrado) — Universidade Federal de Uberlândia, Uberlândia, 2001.
- NASCIMENTO, L. F. C. et al. Efeitos da poluição atmosférica na saúde infantil em São José dos Campos, SP. *Revista de Saúde Pública*, v. 40, p. 77–82, 2006.
- ORDIERES, J. B. et al. Neural network prediction model for fine particulate matter (pm2.5) on the US-Mexico border in el paso (texas) and Ciudad Juárez (Chihuahua). *Environmental Modelling & Software*, v. 20, p. 547–559, 2005.
- PAYAN, S. et al. A review of remote sensing techniques and related spectroscopy problems. *Comptes Rendus Physique*, v. 6, p. 825–835, 2005.
- PEREZ, P.; REYES, J. Prediction of maximum of 24-h average of PM10 concentrations 30 h in advance in Santiago, Chile. *Atmospheric Environment*, v. 36, p. 4555–4561, 2002.
- RUMELHART, D. E.; MCCLELLAND, J. *Parallel distributed processing: explorations in the microstructure of cognition*. Cambridge: MIT Press, 1986.
- SCHNELLE, K. B.; BROWN, C. A. *Air pollution control technology handbook*. Boca Raton: CRC Press, 2002.

SCHWARTZ, J. Air pollution and daily mortality in Birmingham, Alabama. *American Journal of Epidemiology*, v. 137, p. 1136–1147, 1999.

SEINFELD, J. H.; PANDIS, S. N. *Atmospheric chemistry and physics - from air pollution to climate change*. New York: John Wiley & Sons, 1998.

SILVA, E. M.; ASSUNCAO, W. L. O clima na cidade de Uberlândia. *Sociedade & Natureza*, v. 16, n. 30, p. 91–107, 2004.

SILVA, M. G. *Análise da qualidade do ar com base no fluxo de veículos e variáveis climáticas: o caso da cidade de Uberlândia - MG*. Dissertação (Mestrado) — Universidade Federal de Uberlândia, 2007.

SLINI, T. et al. PM10 forecasting for Thessaloniki, Greece. *Environmental Modelling & Software*, v. 21, p. 559–565, 2006.

US-EPA. *National Ambient Air Quality Standards*. Washington, 2006.

VAREJÃO-SILVA, M. A. *Meteorologia e climatologia*. Recife: Versão digital 1, 2005. 516 p.

WARK, K.; WARNER, C. F. *Air pollution: Its origin and control*. New York: Happer & Row, 1981.

WEINER, R. E.; MATTHEWS, R. A. *Environmental engineering*. Boston: Butterworth-Heinemann, 2003.

WHO. *Guidelines for air quality*. Geneva, 2000.

WHO. *Air quality guidelines: global update 2005*. Copenhagen, 2006.

WIDROW, B.; HOFF Jr., M. Adaptive switching circuits. In: *IRE WESCON Convention Record*. [S.l.: s.n.], 1960. p. 96–104.

WILLMOTT, C. J. Some comments on the evaluation of model performance. *Bulletin American Meteorological Society*, v. 63, p. 1309–1313, 1982.

APÊNDICE



TABELAS

A.1 Dados meteorológicos

Tabela A.1: Temperatura (°C): médias mensais e anuais de 2003 a 2007.

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez	média
2003	23,8	25,8	24,0	24,0	21,1	22,4	21,5	22,3	25,8	24,9	24,3	25,4	23,8
2004	24,4	23,5	24,2	23,5	21,8	20,3	20,2	23,2	25,8	25,1	24,7	24,1	23,4
2005	24,2	25,5	24,5	25,3	22,5	21,5	21,0	23,1	24,3	27,1	23,6	23,1	23,8
2006	25,2	24,9	24,2	23,0	21,4	20,9	21,8	24,2	23,9	23,9	24,1	24,1	23,5
2007	24,0	24,5	25,9	24,9	22,3	22,0	21,7	23,3	25,9	26,4	24,7	24,6	24,2
média	24,3	24,9	24,6	24,1	21,8	21,4	21,3	23,2	25,1	25,5	24,3	24,3	23,7

Tabela A.2: Precipitação (mm): médias mensais e totais anuais de 2003 a 2007.

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez	total
2003	556	119	310	98	62	0	1	3	48	67	234	203	1.702
2004	295	265	166	161	10	14	24	0	37	138	139	343	1.592
2005	434	90	236	22	47	44	0	17	138	55	245	247	1.574
2006	208	190	258	327	6	2	0	16	104	266	253	460	2.090
2007	415	230	55	33	12	26	38	0	74	114	249	344	1.588
média	382	179	205	128	27	17	13	7	80	128	224	320	1.709

Tabela A.3: Umidade relativa (%): médias mensais e anuais de 2003 a 2007.

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez	média
2003	84	71	81	74	66	61	56	59	48	62	74	73	67
2004	78	81	72	75	70	65	61	45	49	61	67	75	66
2005	82	68	79	68	67	69	62	53	59	56	78	80	68
2006	68	75	81	55	64	63	57	50	57	76	75	80	67
2007	82	78	66	68	65	60	62	48	47	55	72	75	65
média	79	74	76	68	66	63	60	51	52	62	73	77	67

Tabela A.4: Nebulosidade (%): médias mensais e anuais de 2003 a 2007.

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez	média
2003	82	55	67	54	32	12	26	30	32	56	64	60	47
2004	73	70	48	56	52	37	28	27	38	60	63	73	52
2005	82	50	67	41	41	38	34	24	52	56	73	78	53
2006	59	68	65	48	28	31	22	23	30	69	59	69	48
2007	77	58	38	33	32	17	28	8	16	41	63	62	39
média	75	60	57	46	37	27	28	22	34	56	64	69	48

Tabela A.5: Insolação (horas): médias mensais e totais anuais de 2003 a 2007.

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez	total
2003	125	211	168	199	253	270	280	258	225	203	173	210	2.573
2004	157	144	221	191	216	232	256	280	263	191	180	153	2.484
2005	141	217	183	232	249	237	271	269	196	203	150	138	2.486
2006	197	163	179	214	270	259	272	285	219	137	187	148	2.528
2007	107	172	269	246	264	276	254	313	275	220	184	186	2.765
média	145	181	204	216	250	255	267	281	236	191	175	167	2.567

Tabela A.6: Velocidade (m/s) e direção (graus, 0 para N) do vento: médias mensais e anuais de 2003 a 2007.

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez	média
2003	velocidade	2	1	1	2	2	1	2	3	3	2	2	2
	direção	67	43	53	55	78	40	62	94	88	77	74	60
2004	velocidade	2	2	1	2	1	2	2	2	3	3	2	2
	direção	54	75	66	55	62	65	60	89	95	82	57	44
2005	velocidade	2	1	1	1	2	2	2	2	3	2	2	2
	direção	44	57	33	38	53	53	65	63	70	62	62	51
2006	velocidade	2	1	1	1	1	2	1	2	2	2	2	2
	direção	38	50	41	31	41	44	41	36	88	45	67	57
2007	velocidade	1	1	1	1	2	2	2	2	2	2	2	2
	direção	52	31	27	33	85	67	77	75	69	59	83	77
média	velocidade	2	1	1	1	2	2	2	2	3	2	2	2
	direção	51	51	44	42	64	54	61	71	82	65	69	58

A.2 Dados de fluxo de veículos

Tabela A.7: Fluxo de veículos: médias mensais e anuais de 2003 a 2007.

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez	média
2003	12.305	13.266	12.315	12.792	12.457	11.953	11.992	11.772	12.768	12.833	12.496	12.529	12.457
2004	11.306	11.346	13.292	12.963	12.688	12.817	12.242	12.571	12.876	12.813	12.804	12.838	12.546
2005	11.391	11.611	12.747	12.800	12.656	12.745	11.818	12.131	12.251	11.554	12.016	12.053	12.148
2006	9.055	7.774	8.592	8.253	8.737	8.480	8.501	8.644	8.509	8.419	8.309	8.508	8.482
2007	7.652	7.651	8.442	8.297	8.697	8.426	8.049	8.274	8.781	8.850	8.432	8.459	8.334
média	10.342	10.330	11.078	11.021	11.047	10.884	10.520	10.678	11.037	10.894	10.811	10.877	10.793

Tabela A.8: Fluxo de veículos: médias por dia da semana de 2003 a 2007.

	dom	seg	ter	qua	qui	sex	sab
2003	6.532	12.751	14.265	13.992	13.853	14.339	10.428
2004	6.598	13.951	13.851	13.993	14.141	14.647	10.661
2005	6.208	13.543	13.803	13.393	13.616	14.353	10.206
2006	5.429	9.186	9.202	9.438	9.012	9.599	7.634
2007	5.377	9.084	8.976	9.150	8.929	9.286	7.480
média	6.029	11.703	12.019	11.993	11.910	12.445	9.282

A.3 Dados de concentração de MP₁₀

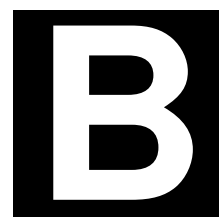
Tabela A.9: Concentração de MP₁₀ ($\mu\text{g}/\text{m}^3$): médias por dia da semana de 2003 a 2007.

	Dom	Seg	Ter	Qua	Qui	Sex	Sab
2003	31,3	45,4	49,9	47,0	52,1	48,4	40,7
2004	41,8	54,1	49,3	52,6	55,6	51,9	42,7
2005	49,9	49,8	51,6	60,1	54,1	51,0	44,0
2006	40,0	48,0	41,4	39,1	44,3	49,7	41,2
2007	39,8	50,0	49,7	45,3	46,9	47,6	35,5
Média	40,5	49,4	48,4	48,8	50,6	49,7	40,8

Tabela A.10: Concentração de MP₁₀ ($\mu\text{g}/\text{m}^3$): médias mensais e anuais de 2003 a 2007.

	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Média
2003	-	-	33,3	39,8	39,5	62,1	44,8	55,7	54,9	47,8	51,7	48,1	47,8
2004	47,8	-	31,4	56,9	39,0	52,4	57,3	56,7	56,0	58,4	49,5	46,2	50,1
2005	38,6	47,5	36,4	53,7	75,8	39,6	55,5	64,6	63,4	71,7	37,4	33,4	51,5
2006	40,0	35,9	36,8	35,2	59,8	58,9	52,7	62,8	57,1	34,5	36,3	29,4	44,9
2007	32,2	25,9	26,6	35,5	47,3	54,5	58,9	52,5	60,8	63,7	48,7	24,7	44,3
Média	39,6	36,4	32,9	44,2	52,3	53,5	53,8	58,5	58,4	55,2	44,7	36,4	47,2

APÊNDICE



GRÁFICOS

B.1 Simulações de modelos preliminares utilizando redes neurais

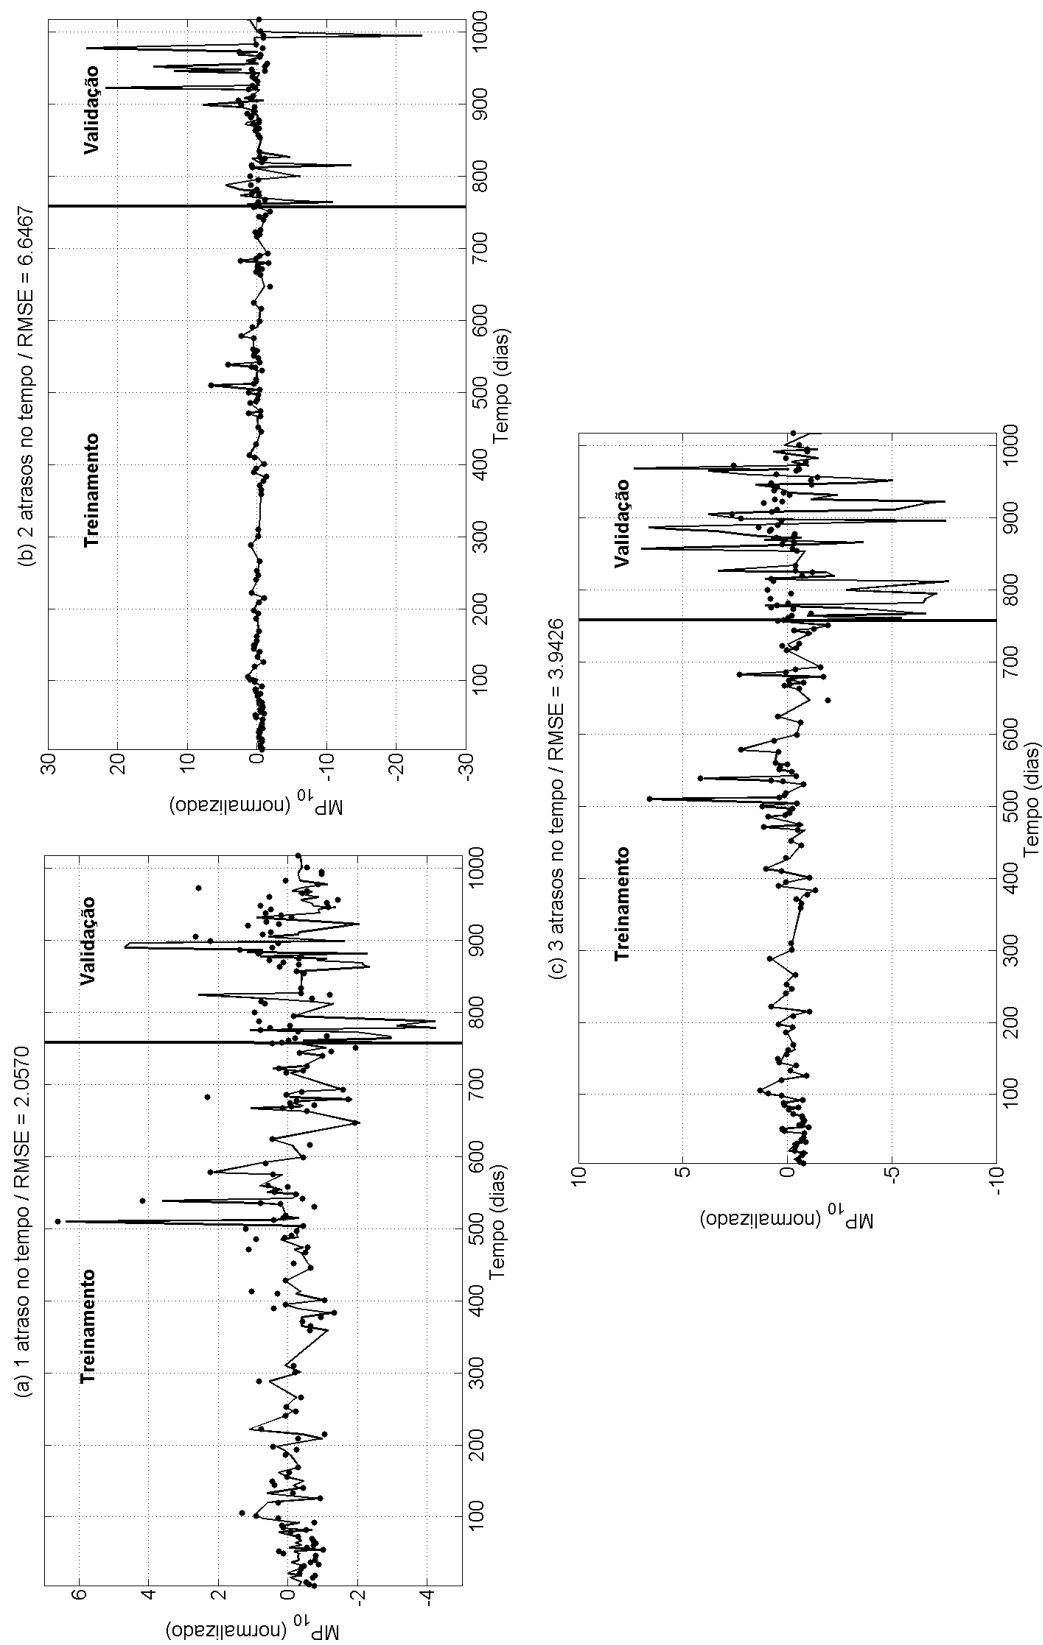


Figura B.1: Simulações de modelos preliminares utilizando redes neurais com 4 neurônios.

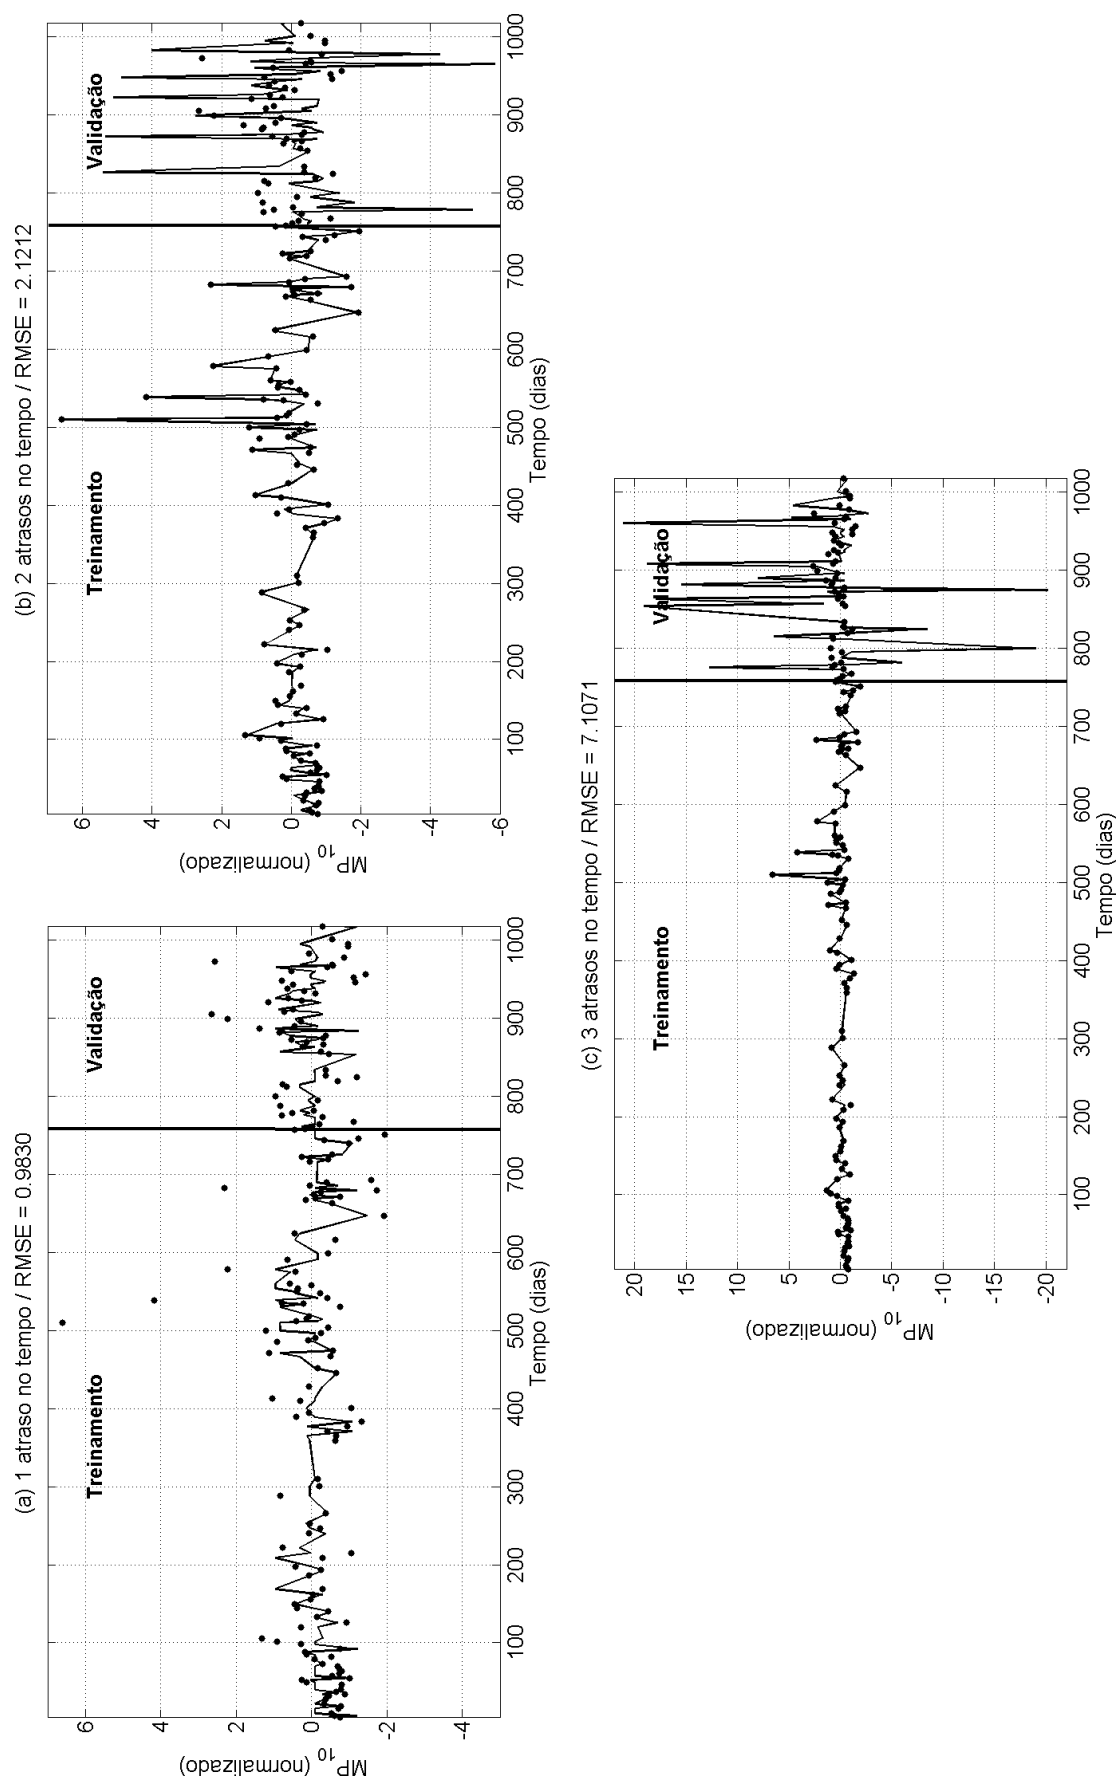


Figura B.2: Simulações de modelos preliminares utilizando redes neurais com 5 neurônios.

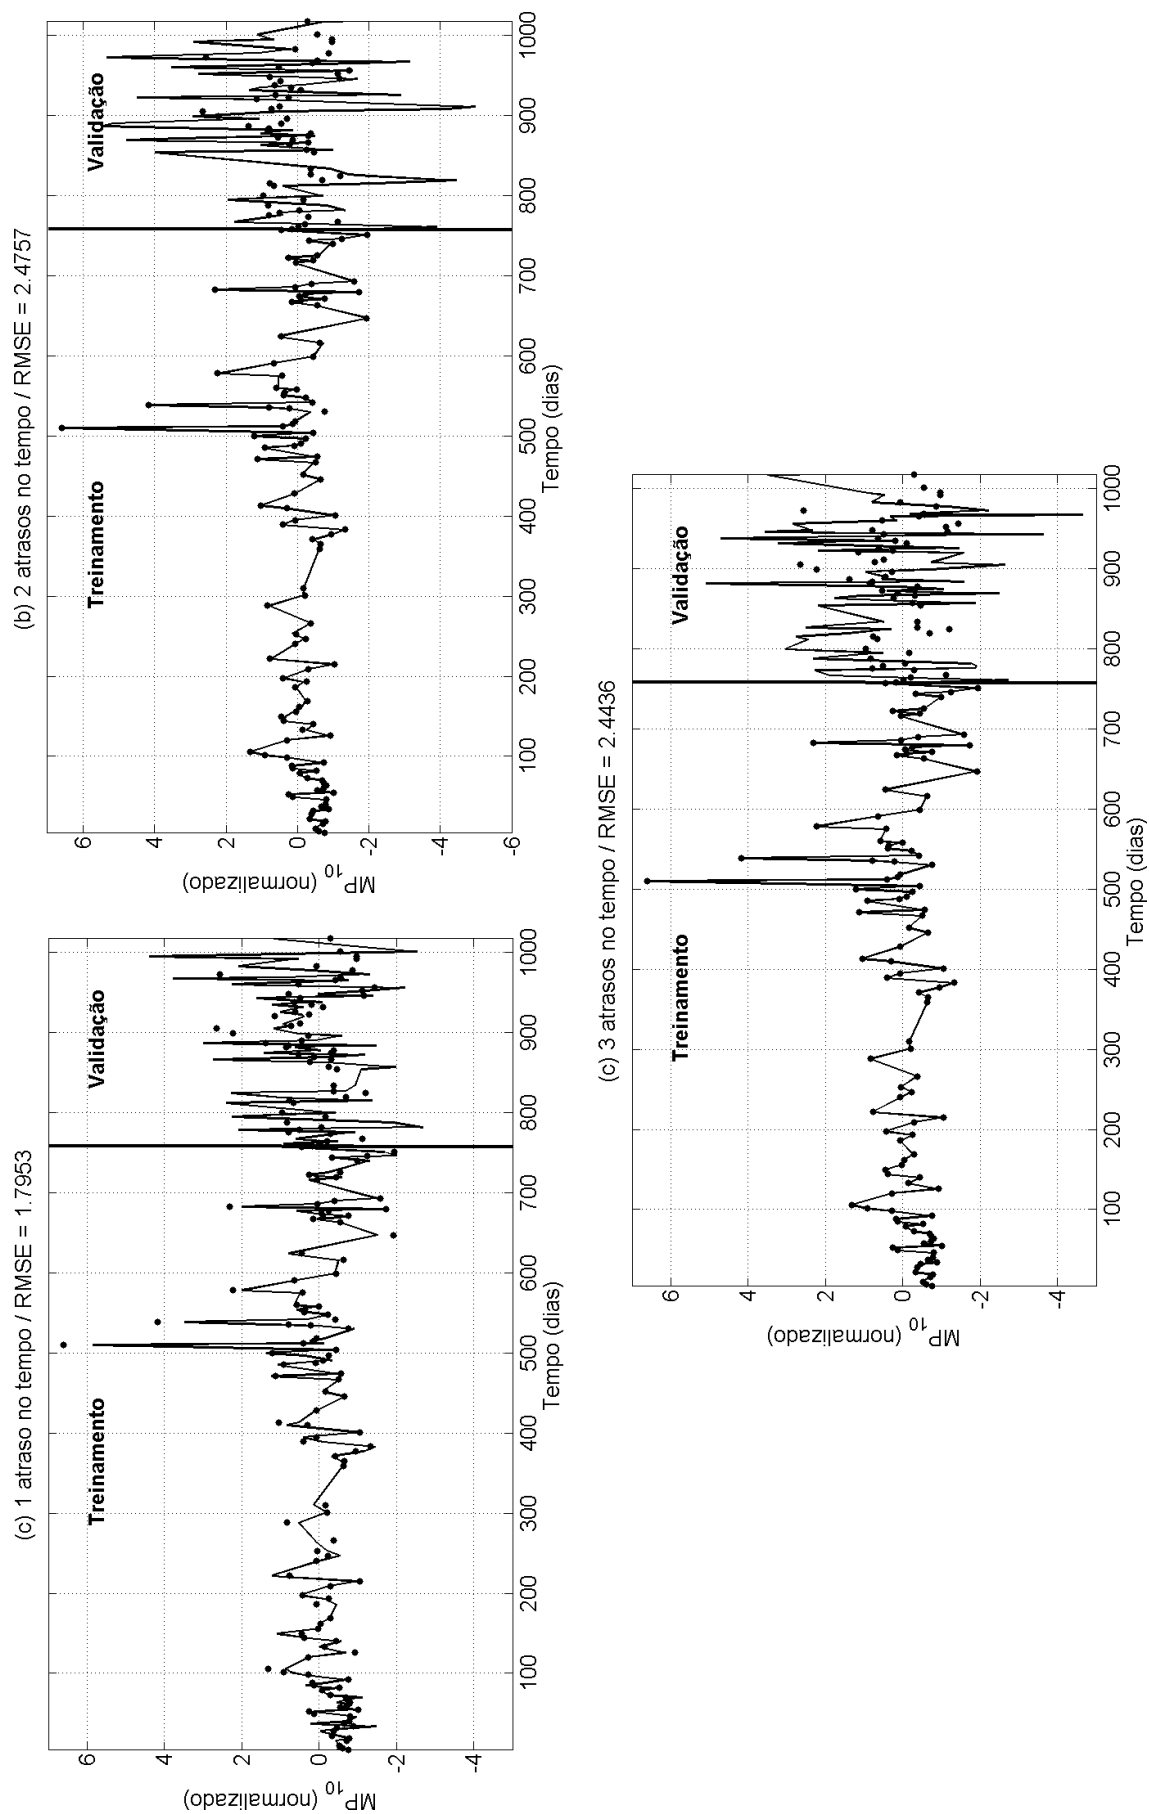


Figura B.3: Simulações de modelos preliminares utilizando redes neurais com 6 neurônios.

B.2 Seleção da estrutura e simulações dos modelos lineares

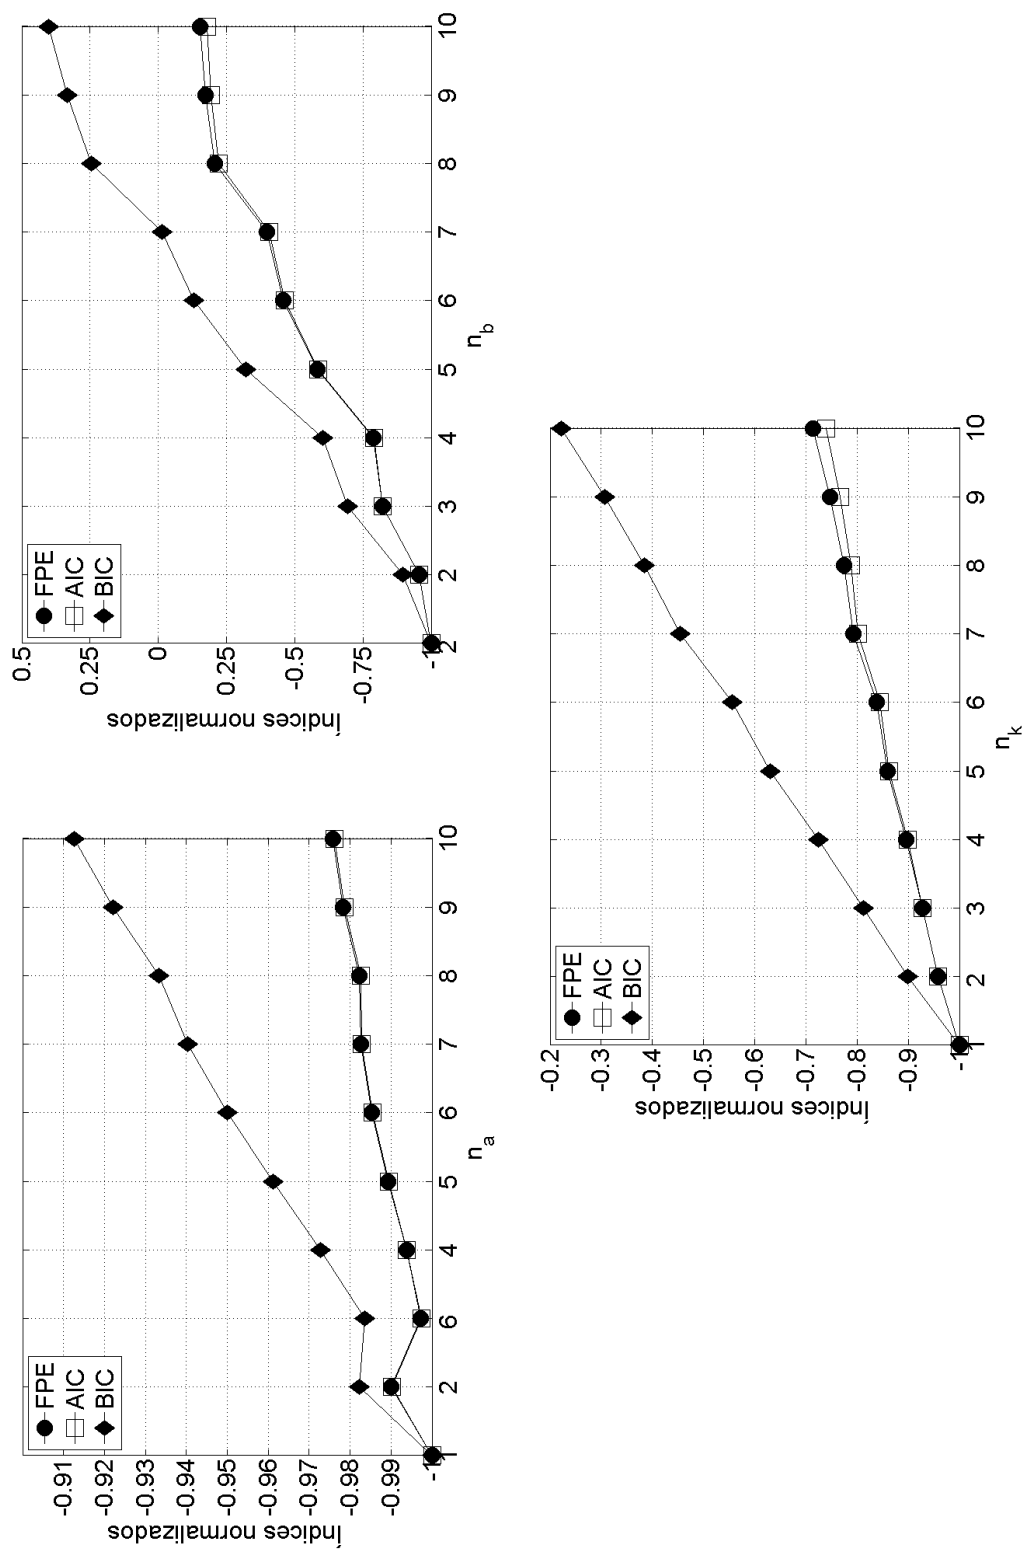


Figura B.4: Seleção da ordem do modelo ARX utilizando dados normalizados no intervalo $[-1; 1]$.

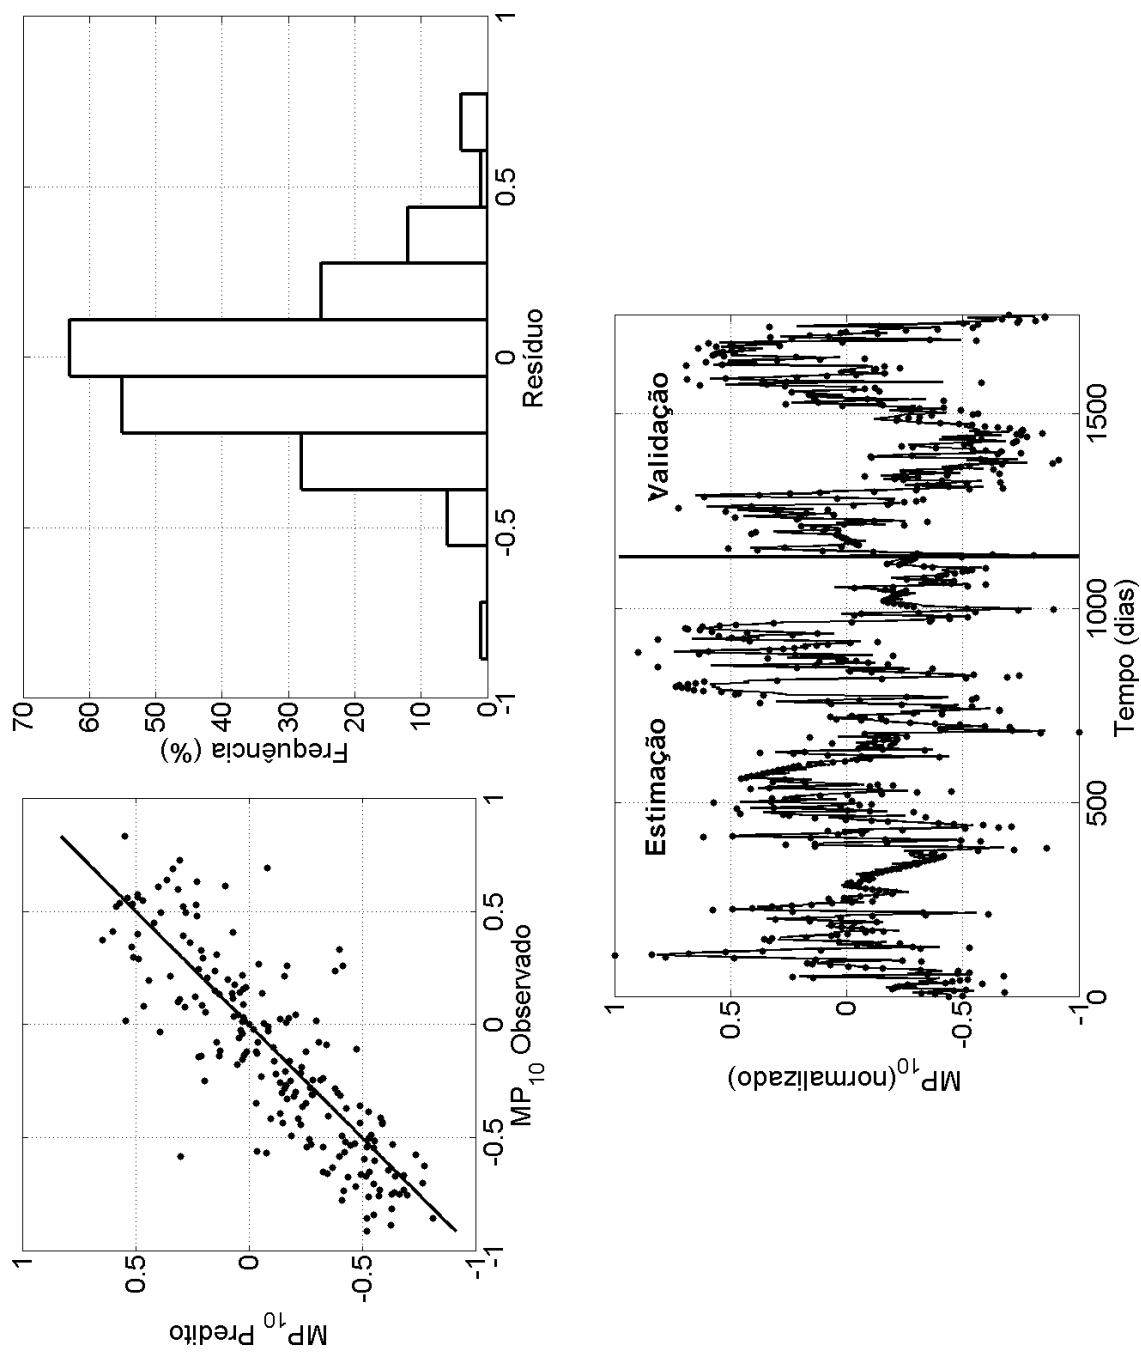


Figura B.5: Simulações do modelo ARX [1, 1, 1] utilizando dados normalizados no intervalo [-1; 1].

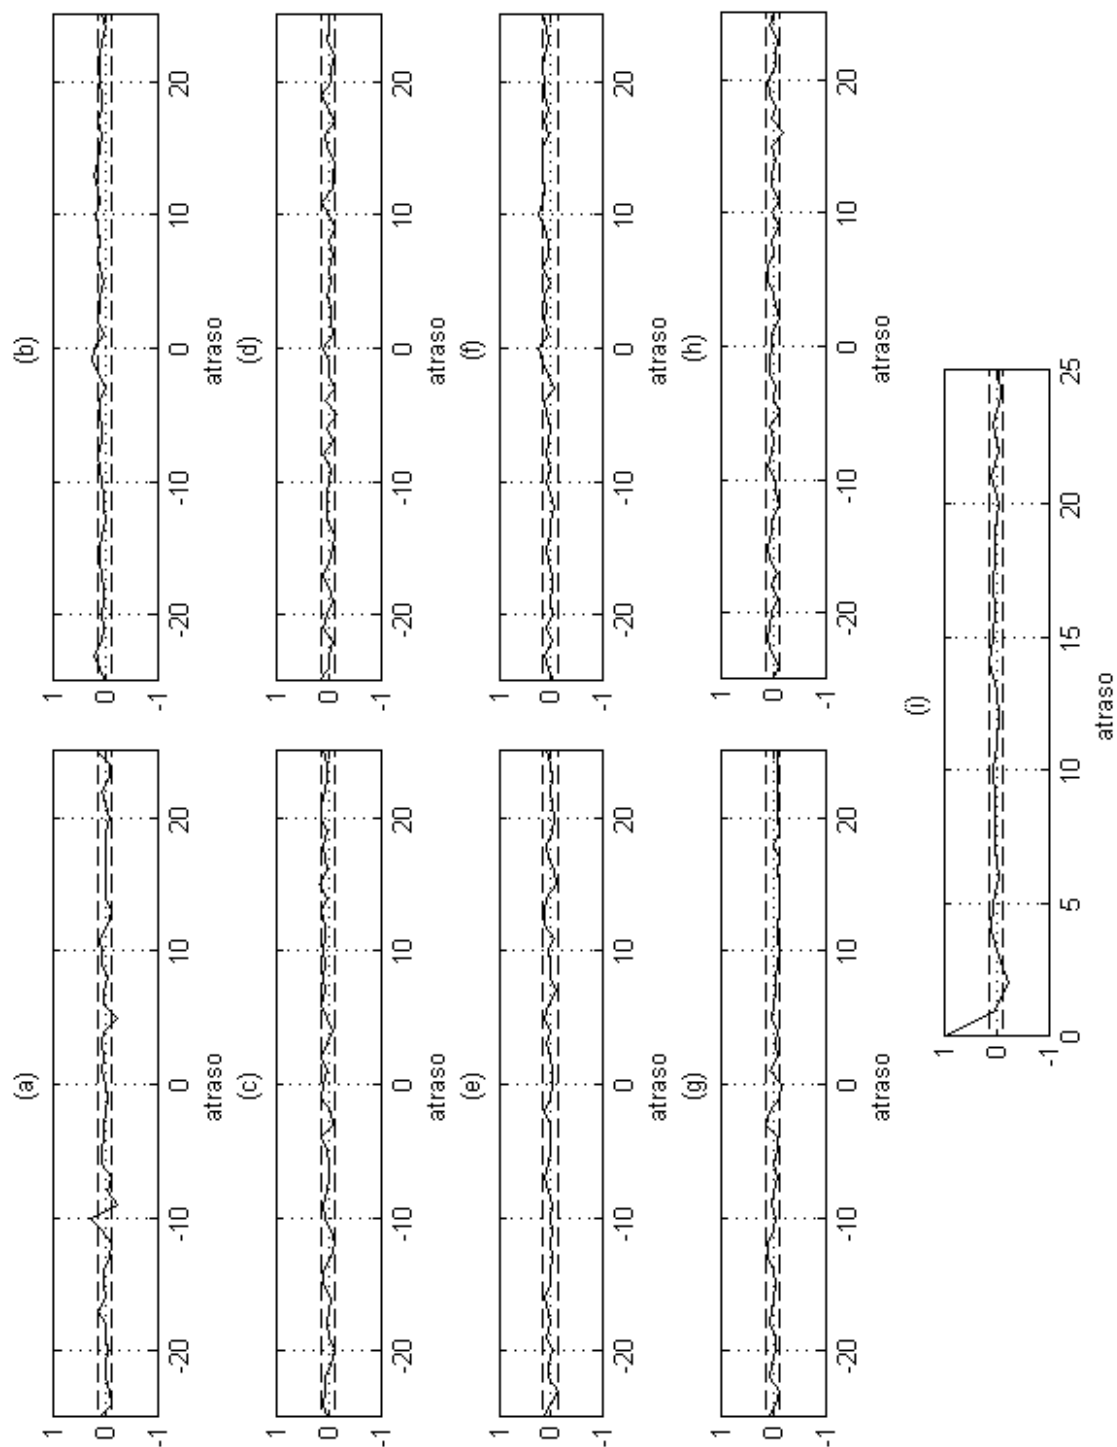


Figura B.6: Funções de autocorrelação e correlação cruzada do modelo ARX $[1, 1, 1]$ utilizando dados normalizados no intervalo $[-1; 1]$.

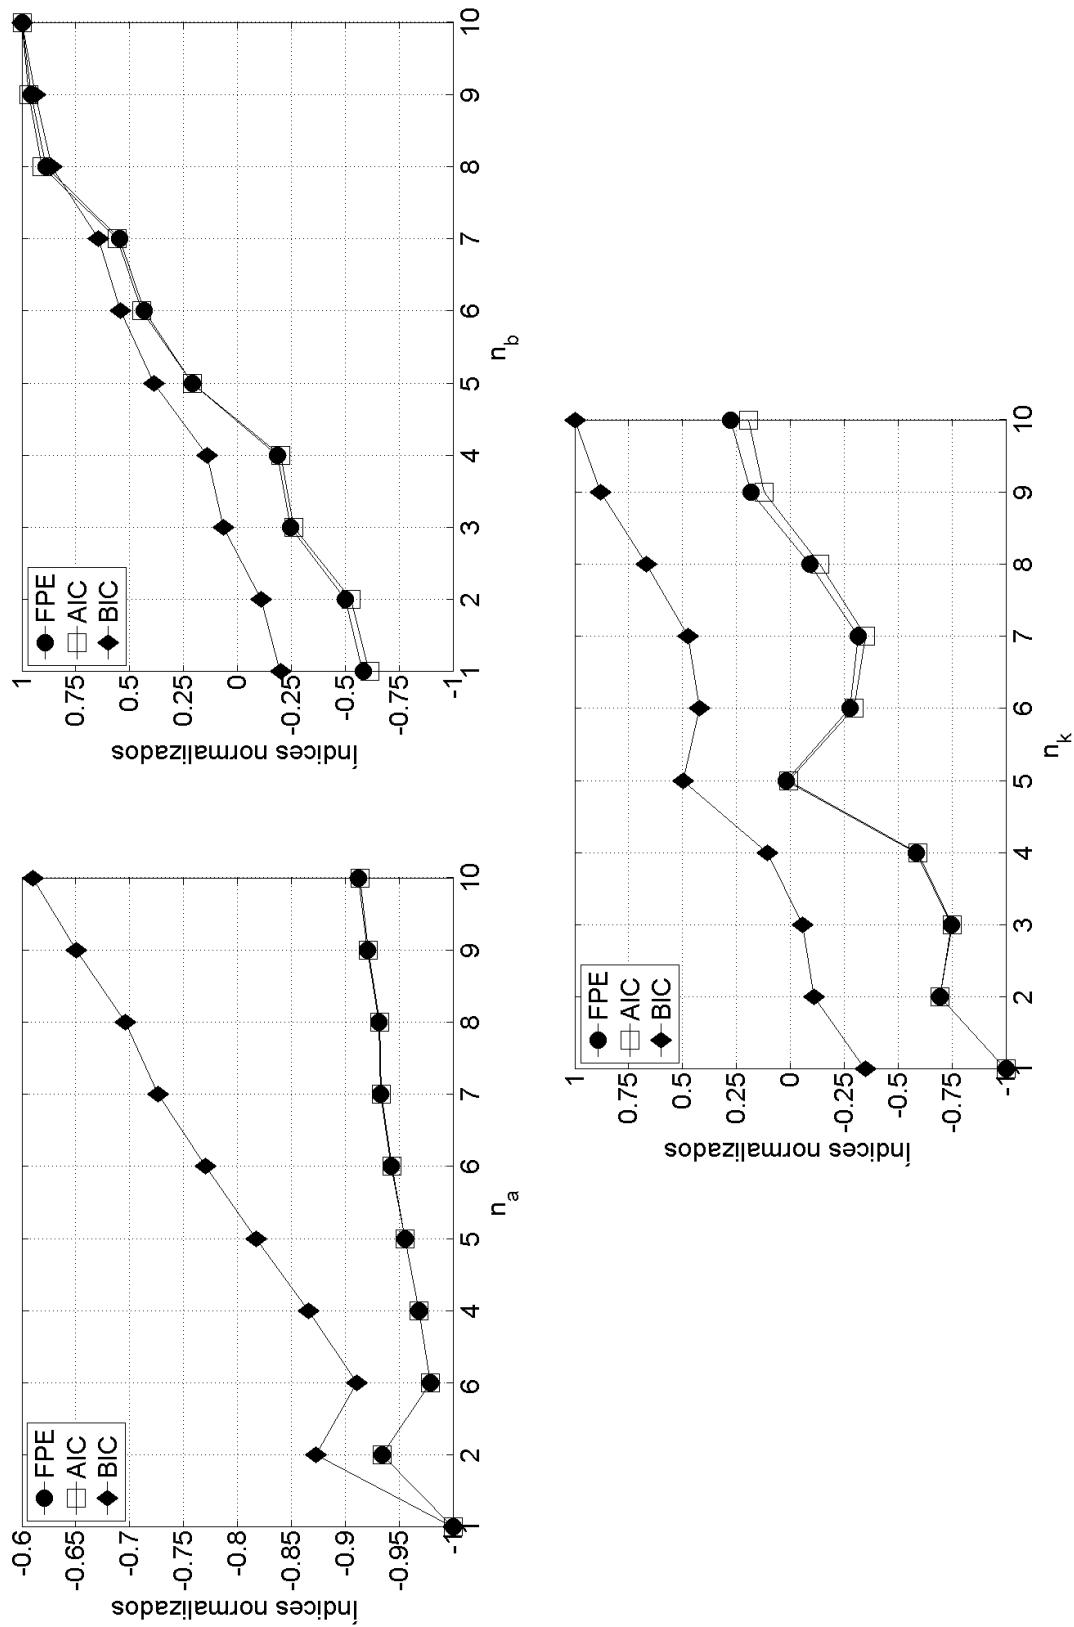


Figura B.7: Seleção da ordem do modelo ARX utilizando dados normalizados com média = 0 e variância = 1.

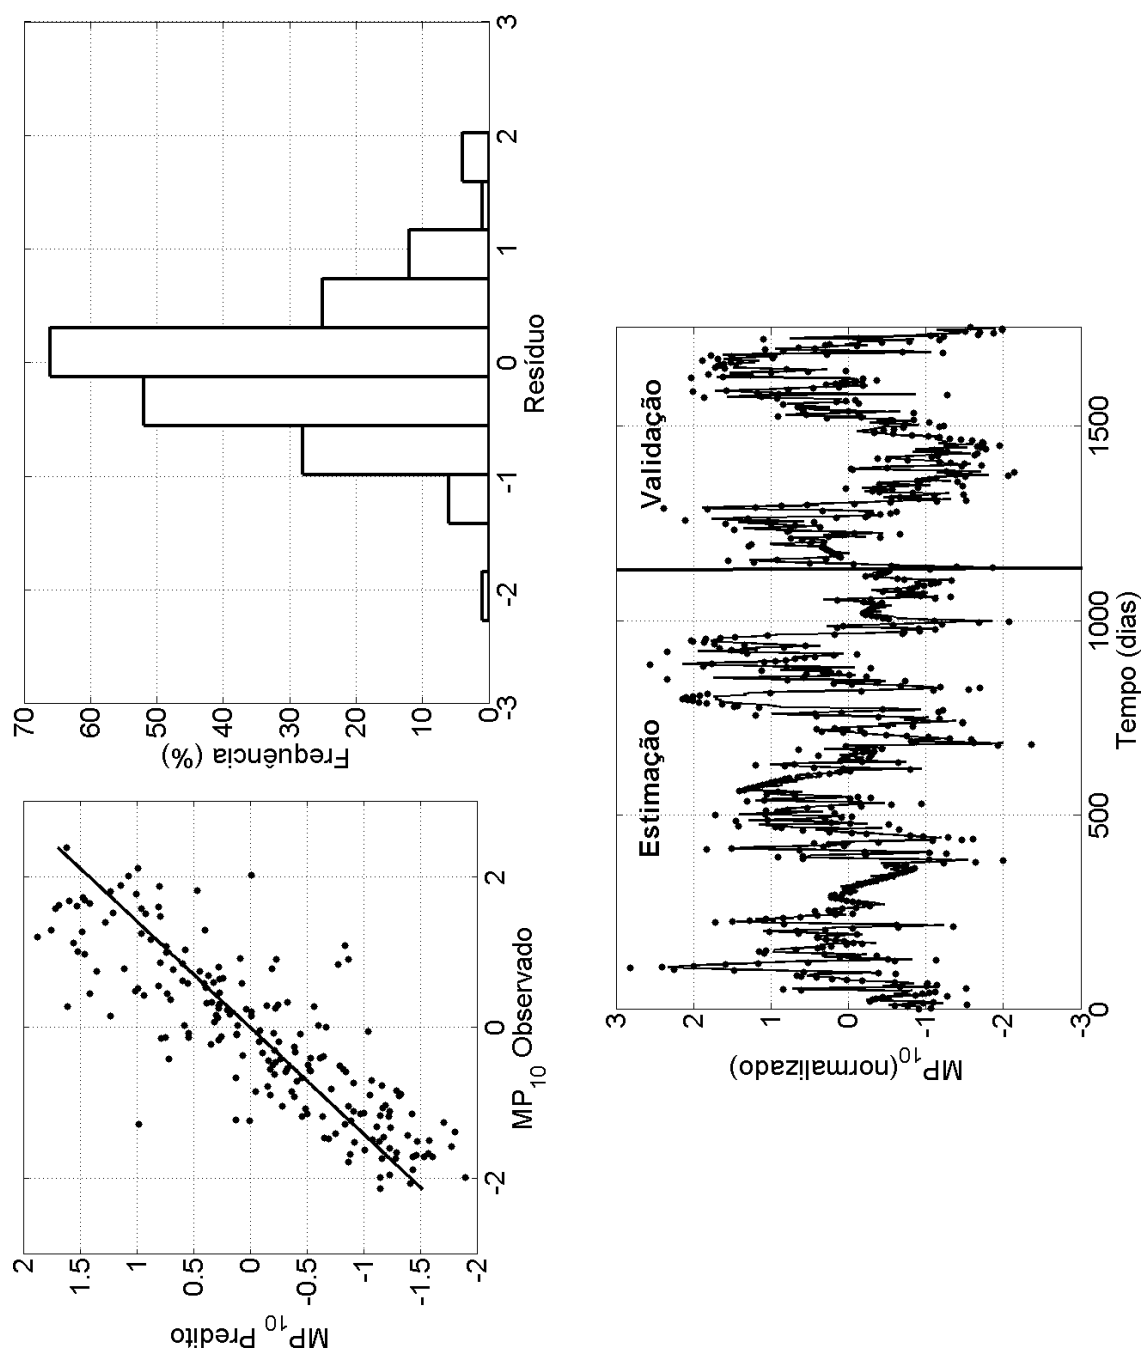


Figura B.8: Simulações do modelo ARX [1, 1, 1] utilizando dados normalizados com média = 0 e variância = 1.

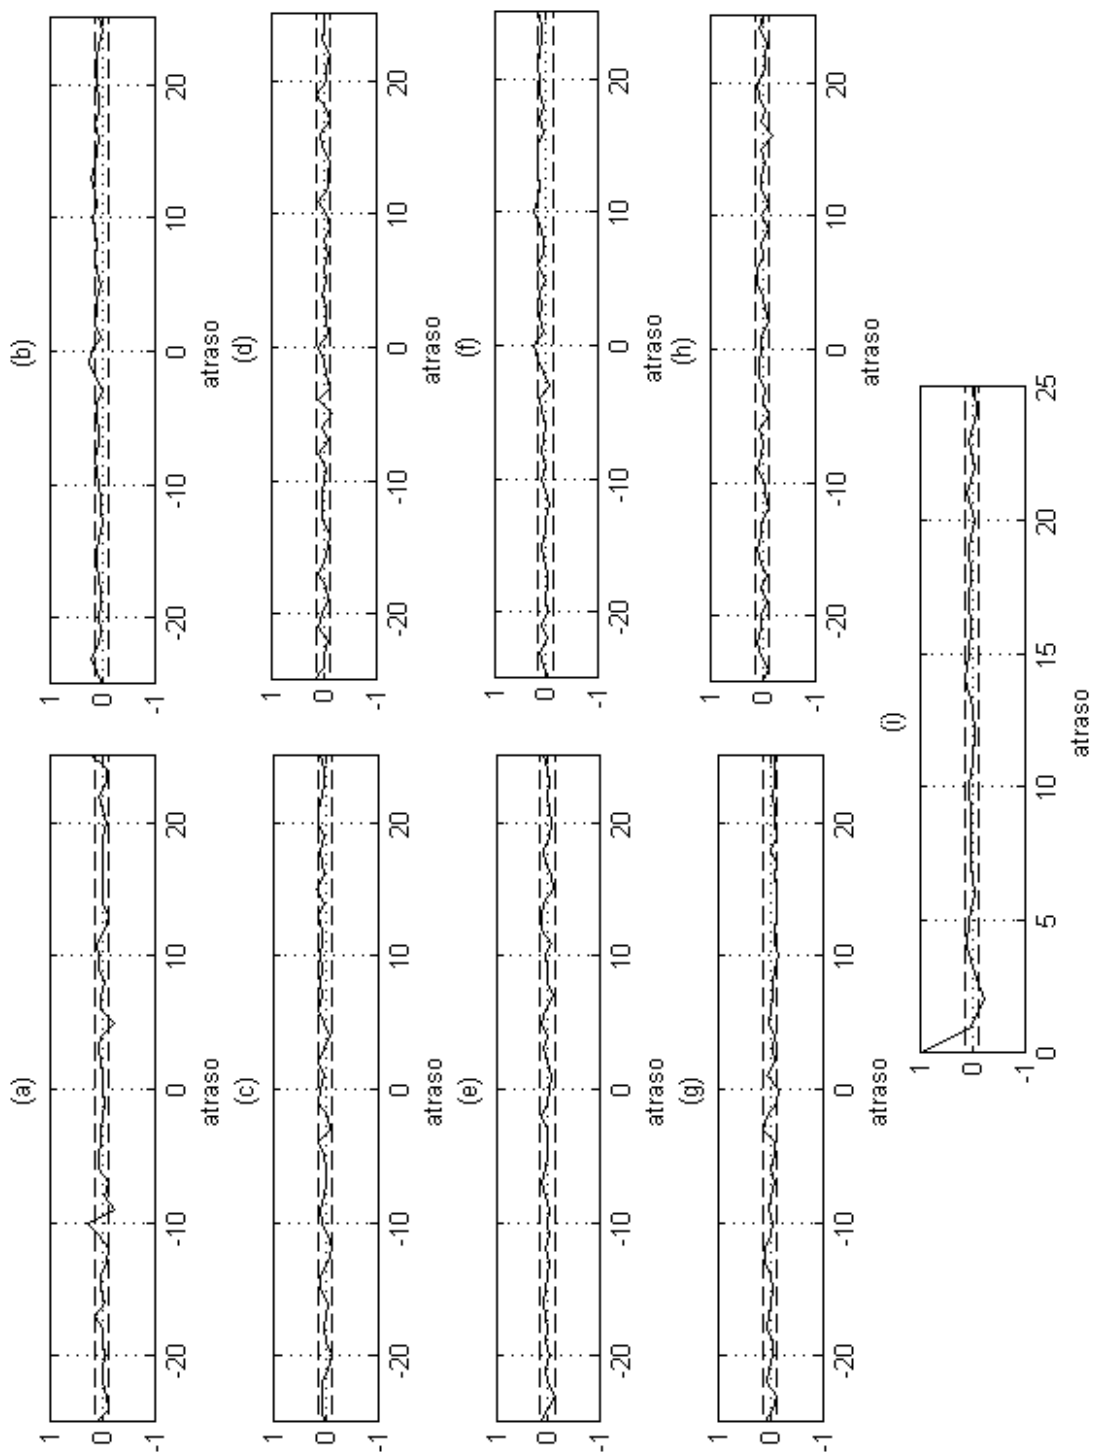


Figura B.9: Funções de autocorrelação e correlação cruzada do modelo ARX [1, 1, 1] utilizando dados normalizados com média = 0 e variância = 1.

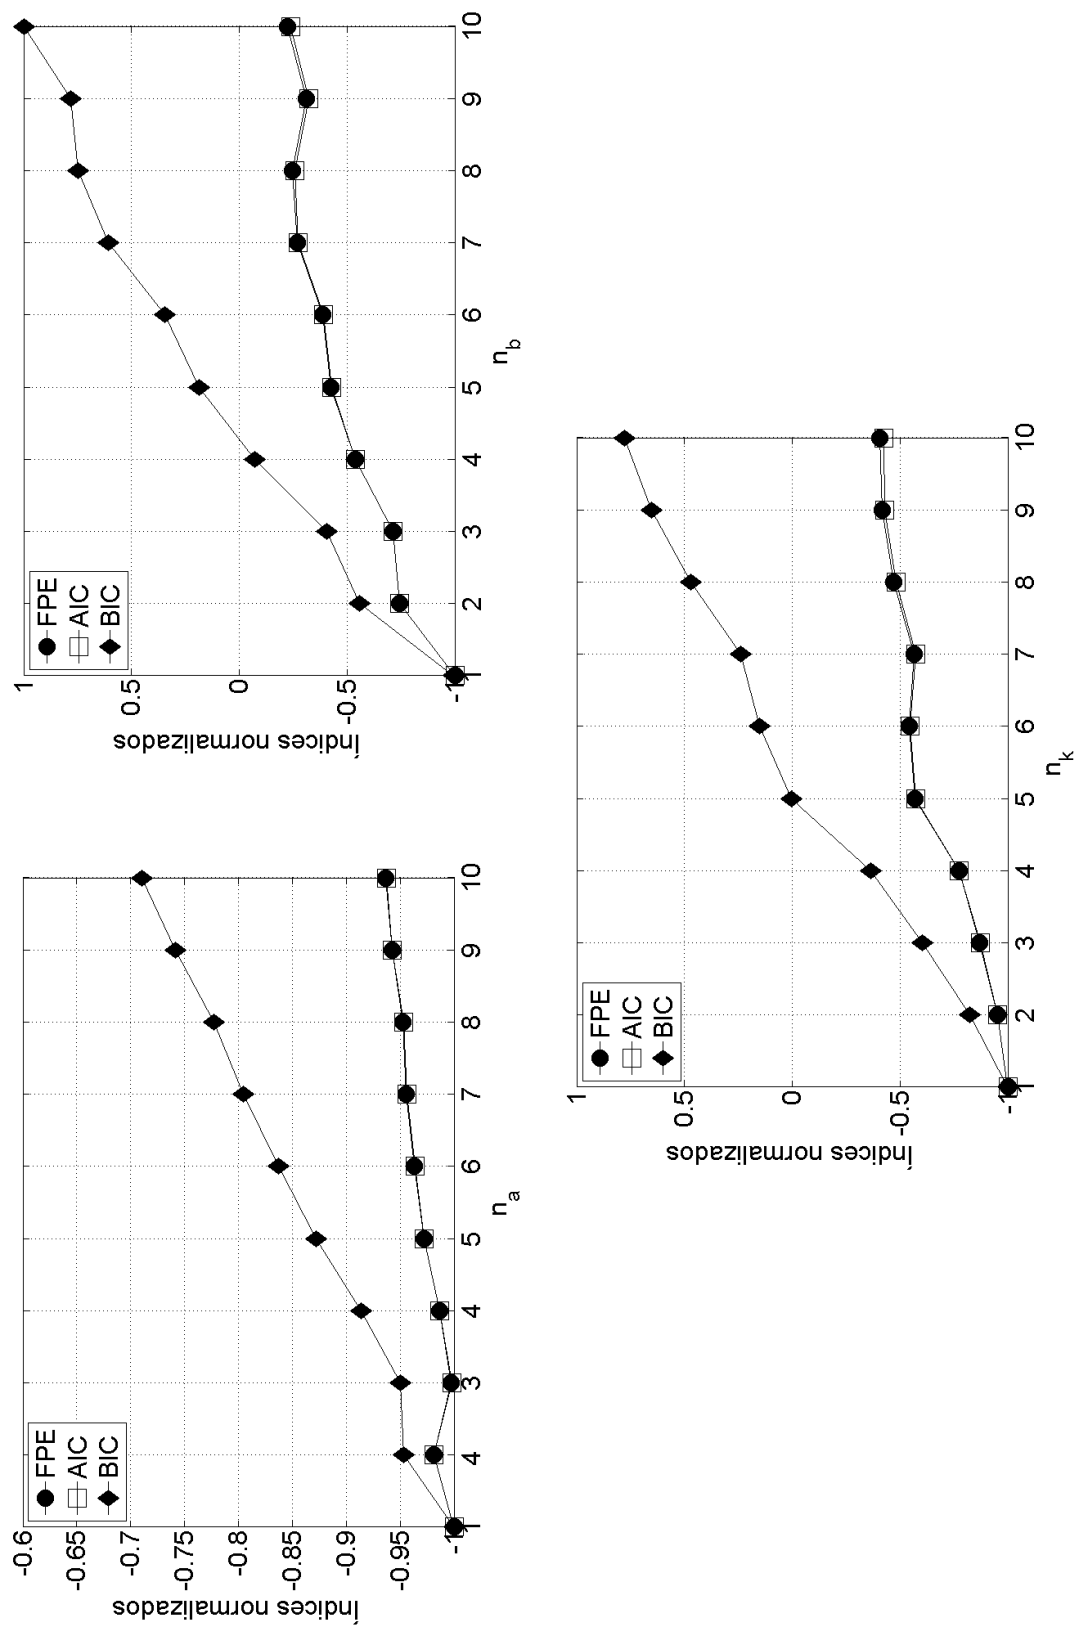


Figura B.10: Seleção da ordem do modelo ARX utilizando dados normalizados com média = 0 e variância = 1 e análise de componentes principais.

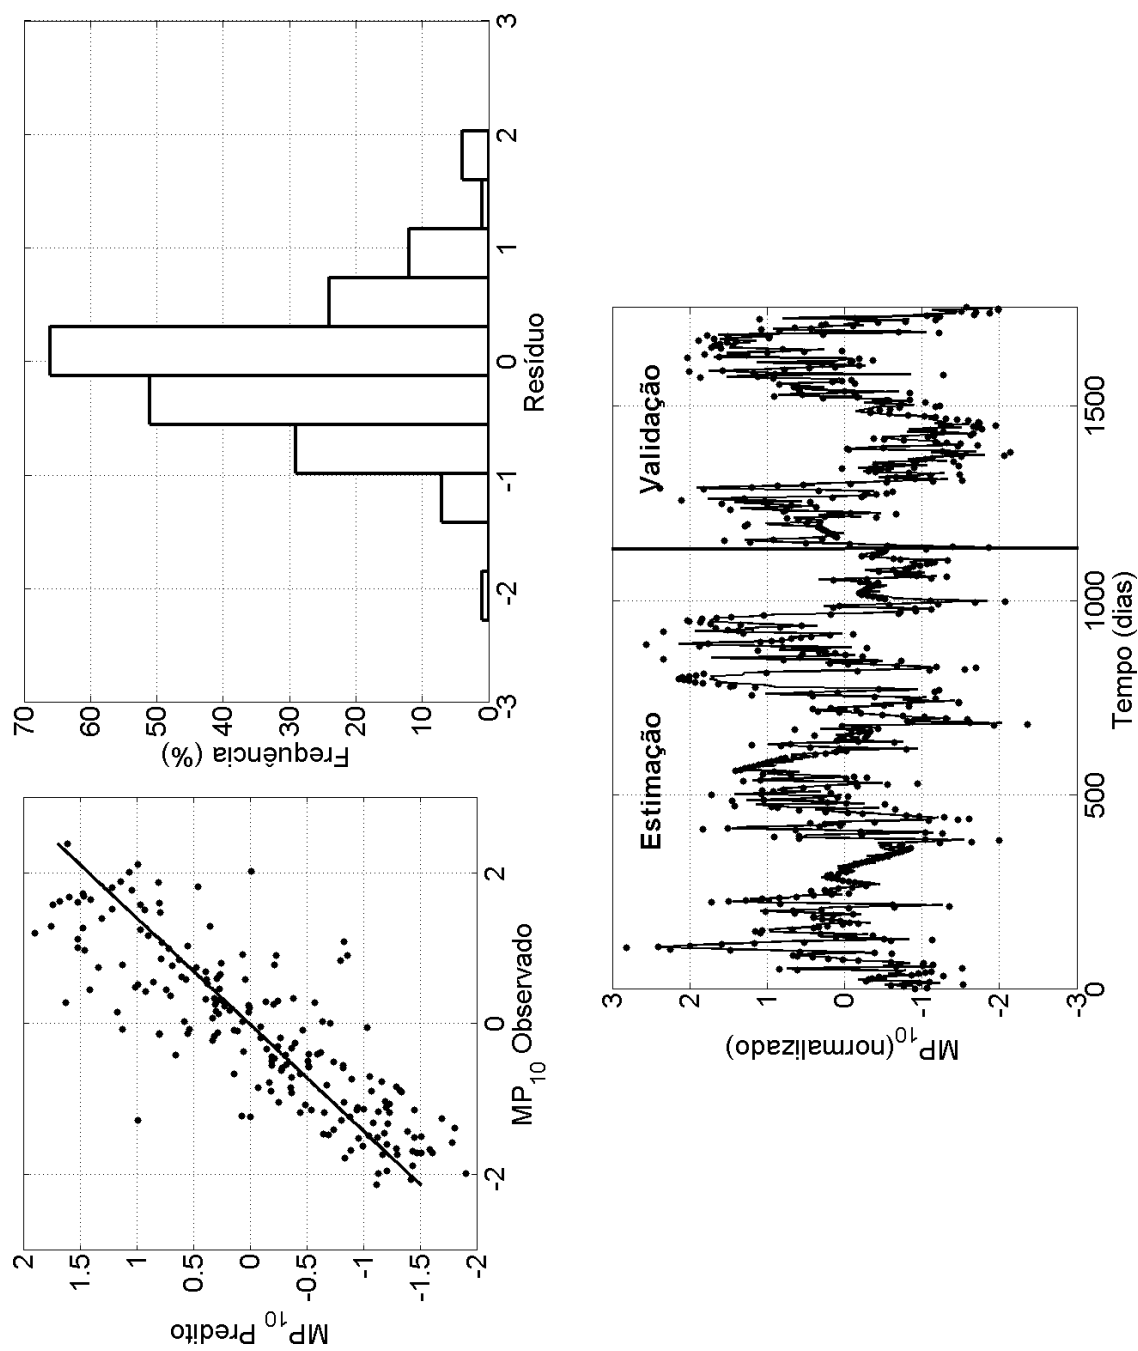


Figura B.11: Simulações do modelo ARX [1, 1, 1] utilizando dados normalizados com média = 0 e variância = 1 e análise de componentes principais.

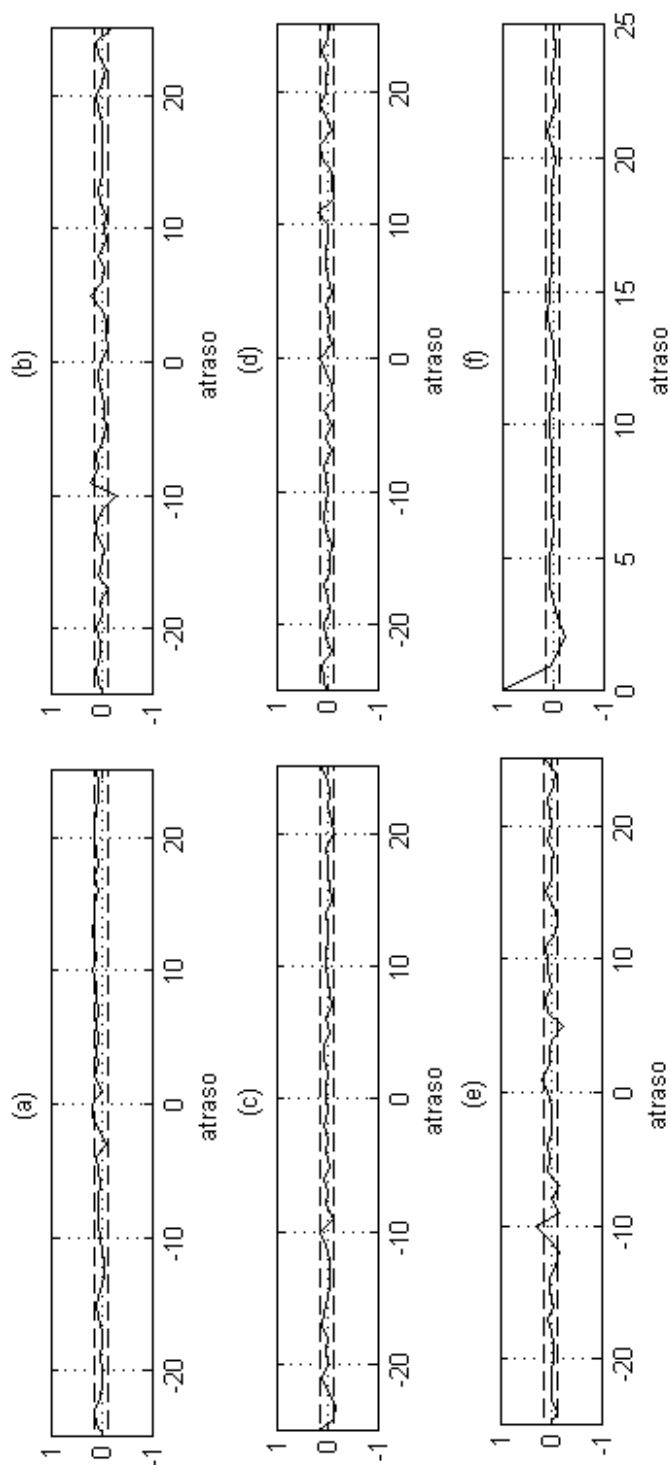


Figura B.12: Funções de autocorrelação e correlação cruzada do modelo ARX $[1, 1, 1]$ utilizando dados normalizados com média = 0 e variância = 1 e análise de componentes principais.

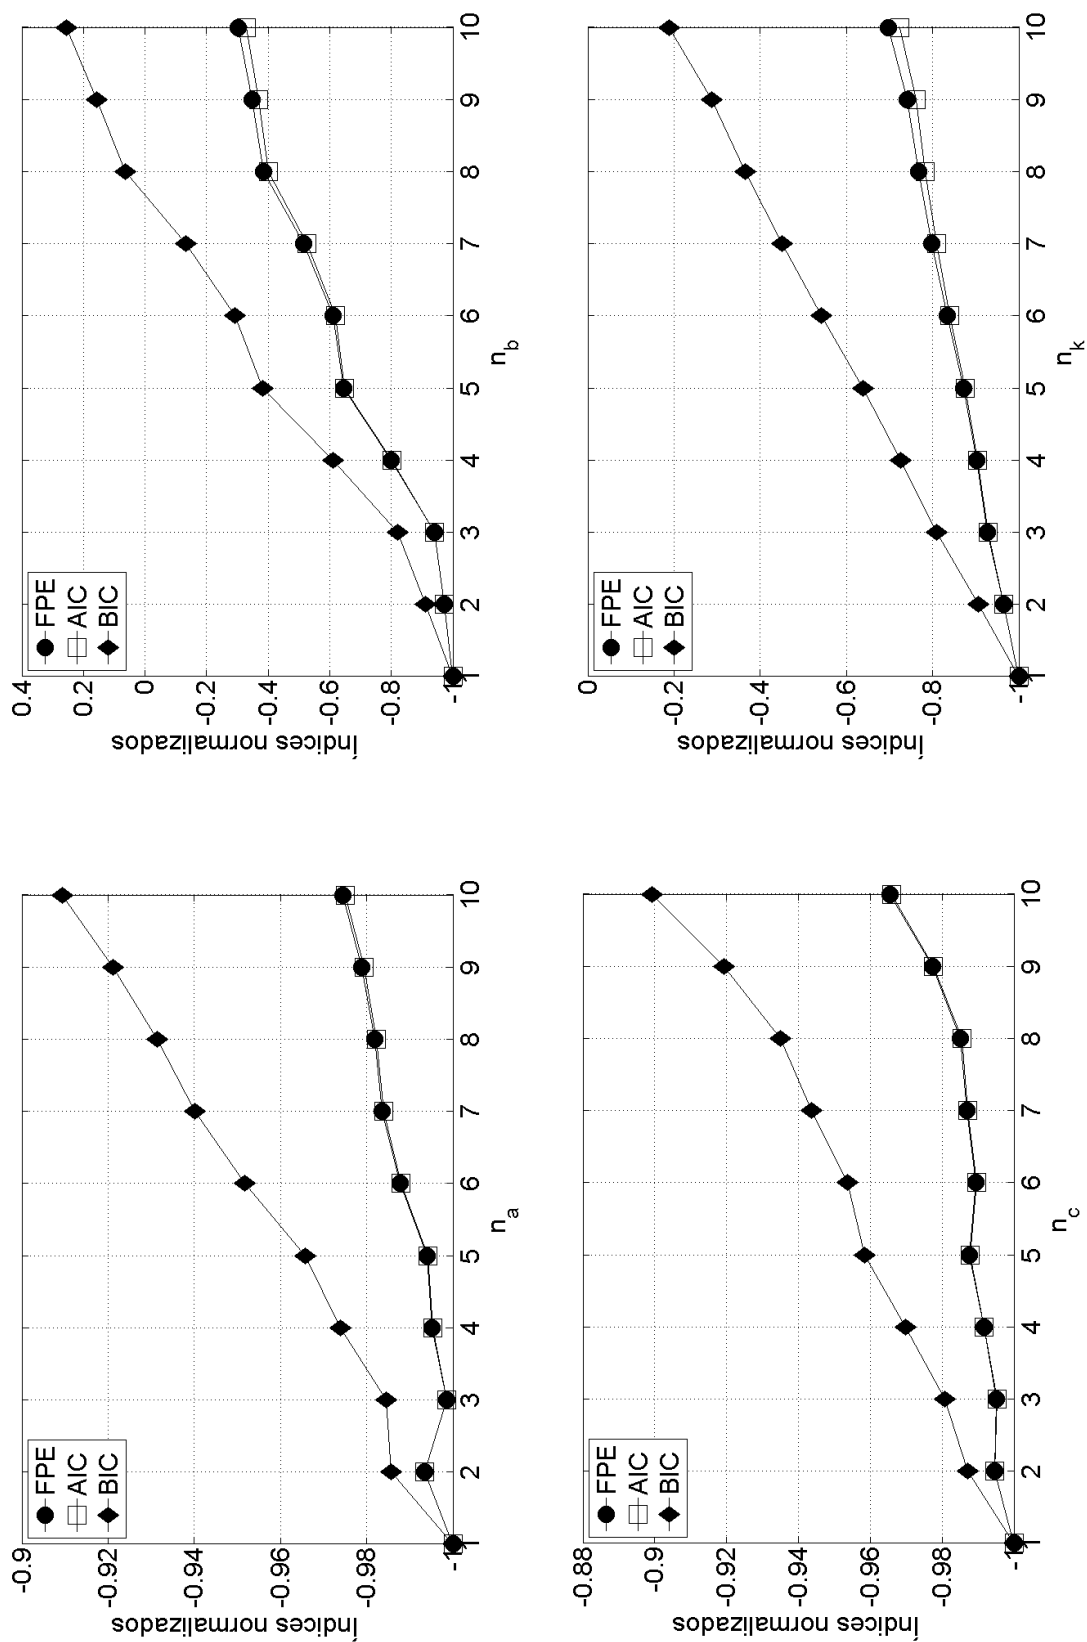


Figura B.13: Seleção da ordem do modelo ARMAX utilizando dados normalizados no intervalo $[-1; 1]$.

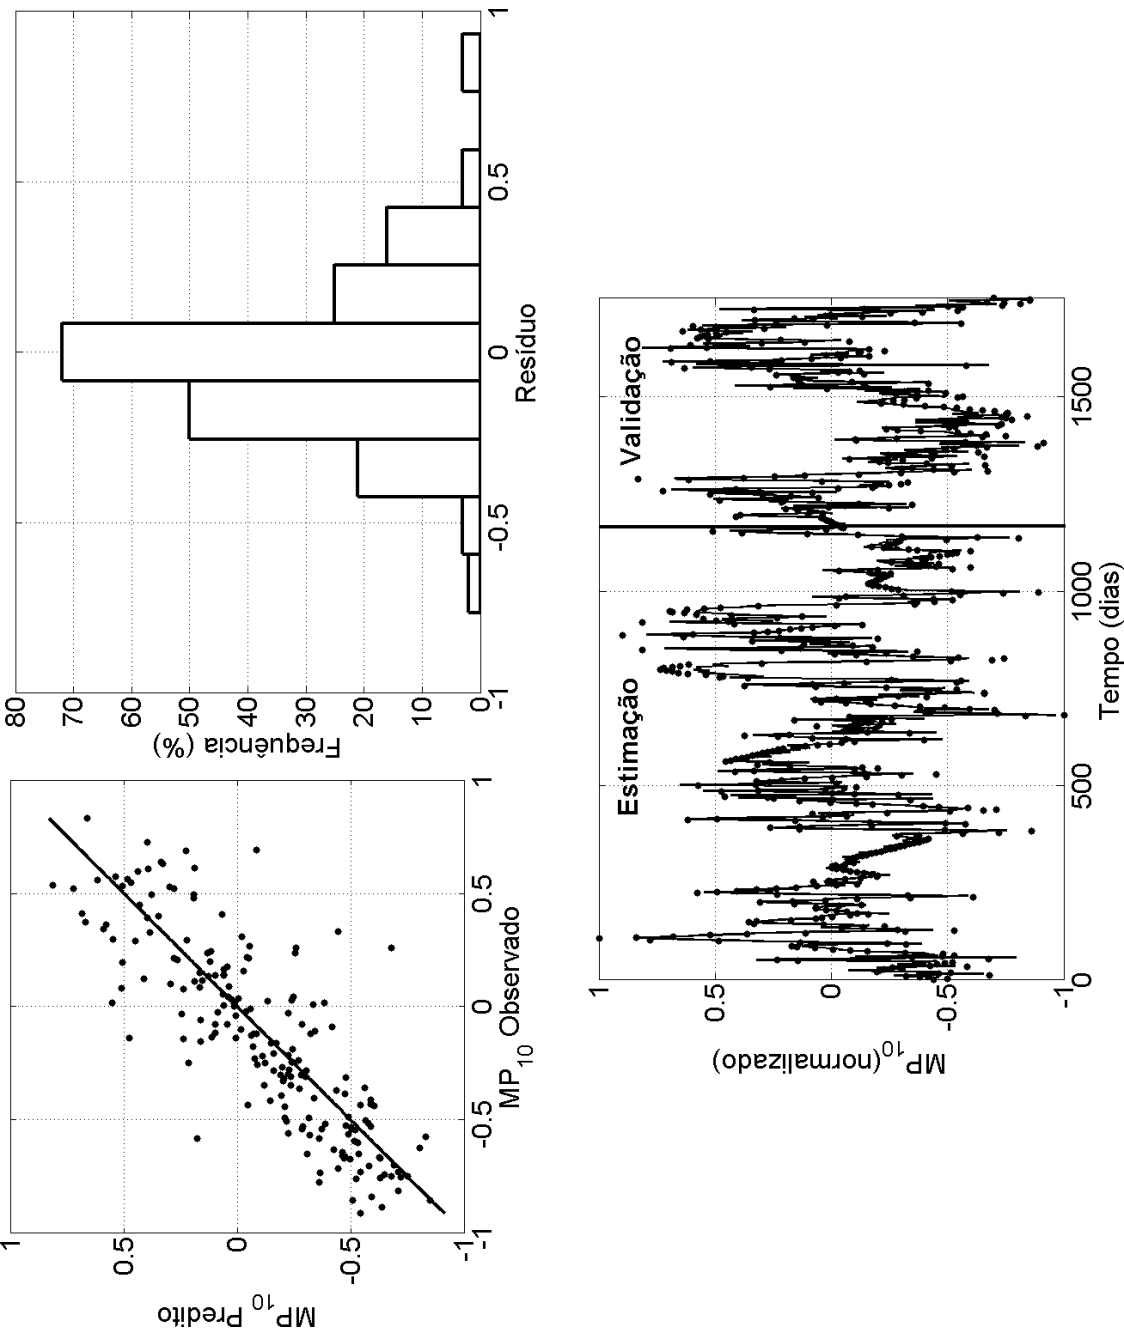


Figura B.14: Simulações do modelo ARMAX [1, 1, 1, 1] utilizando dados normalizados no intervalo [-1; 1].

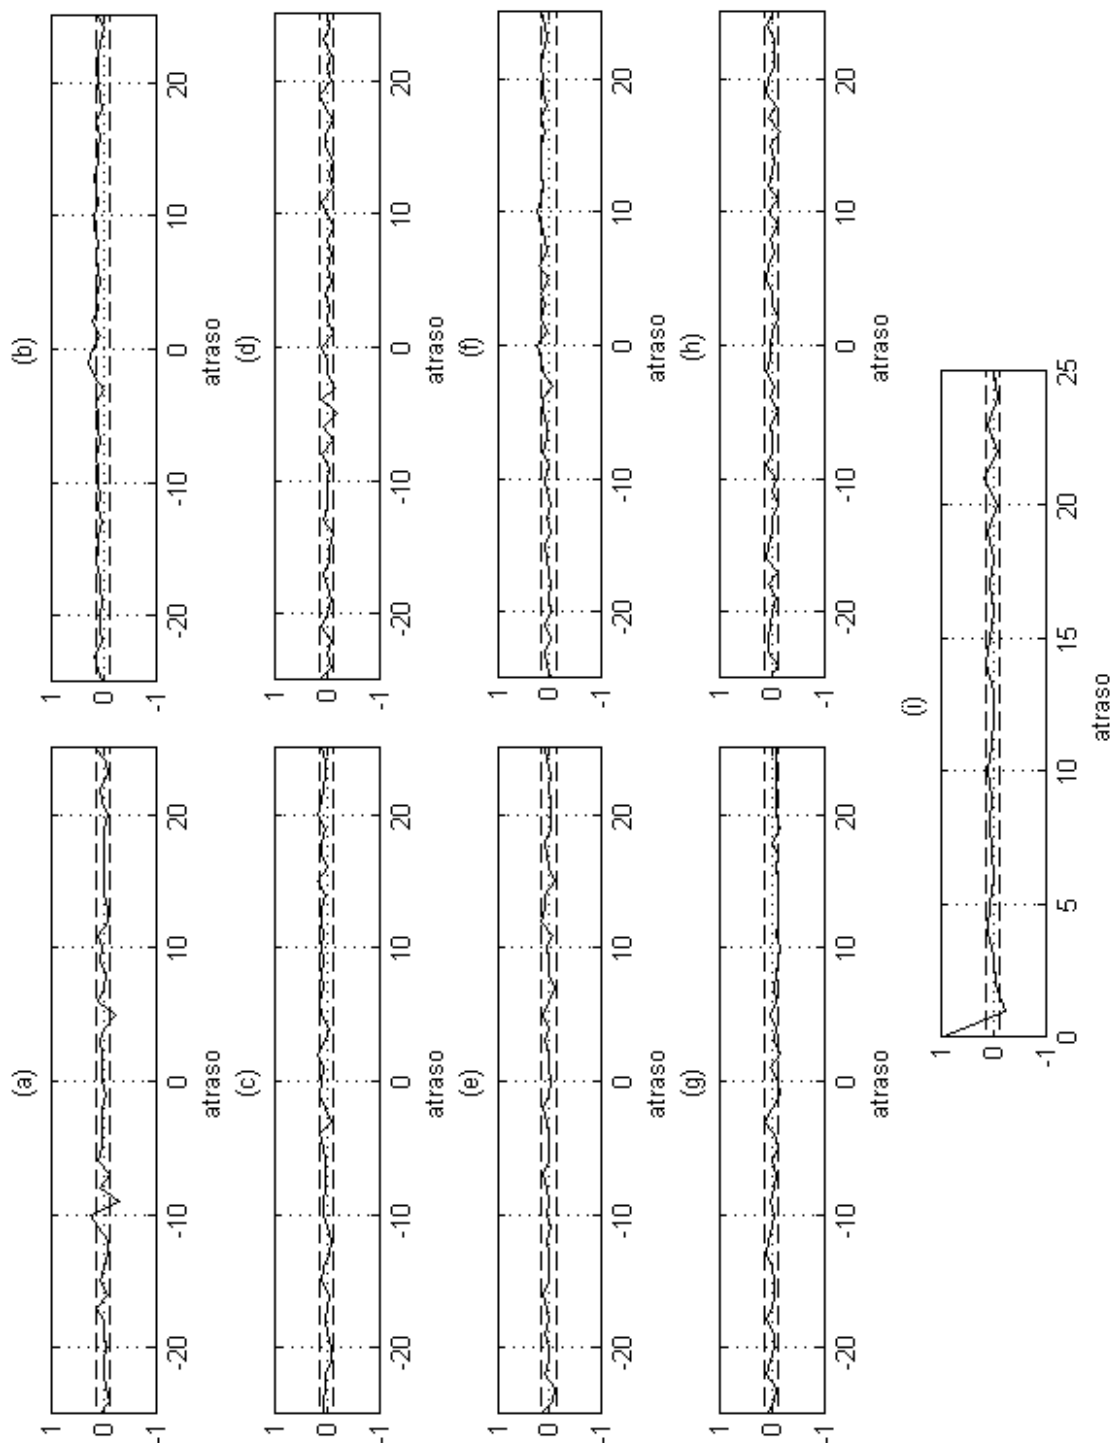


Figura B.15: Funções de autocorrelação e correlação cruzada do modelo ARMAX [1, 1, 1, 1] utilizando dados normalizados no intervalo [-1; 1].

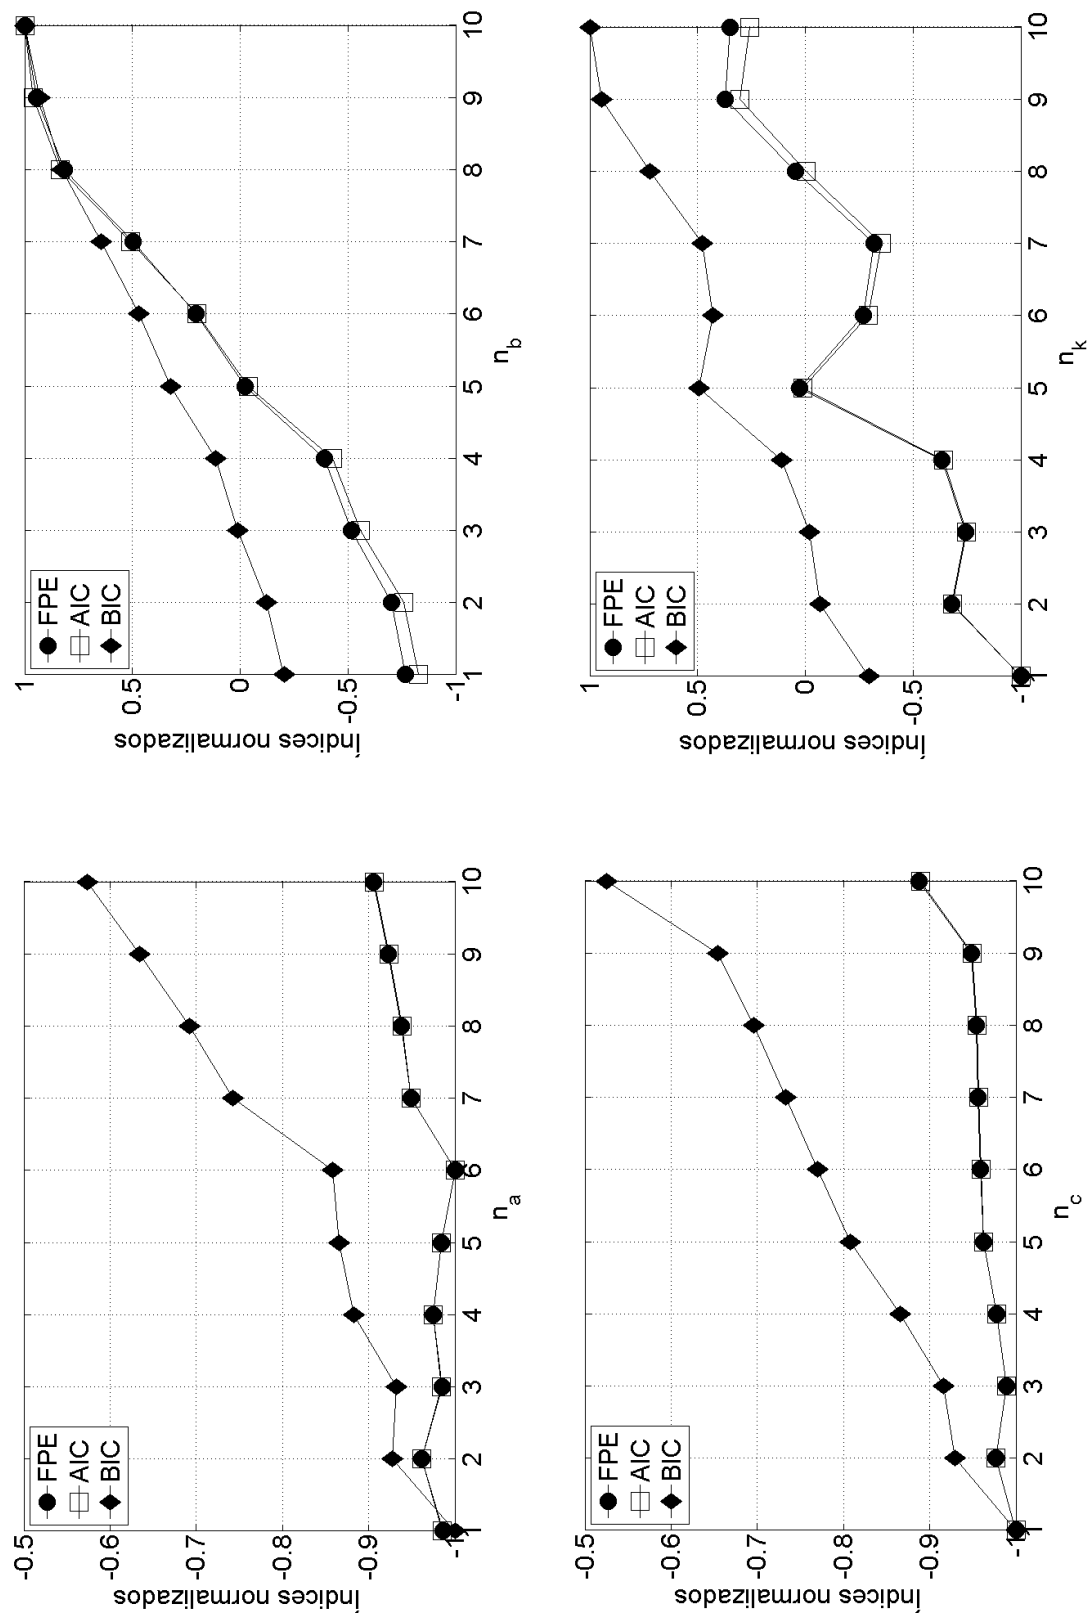


Figura B.16: Seleção da ordem do modelo ARMAX utilizando dados normalizados com média = 0 e variância = 1.

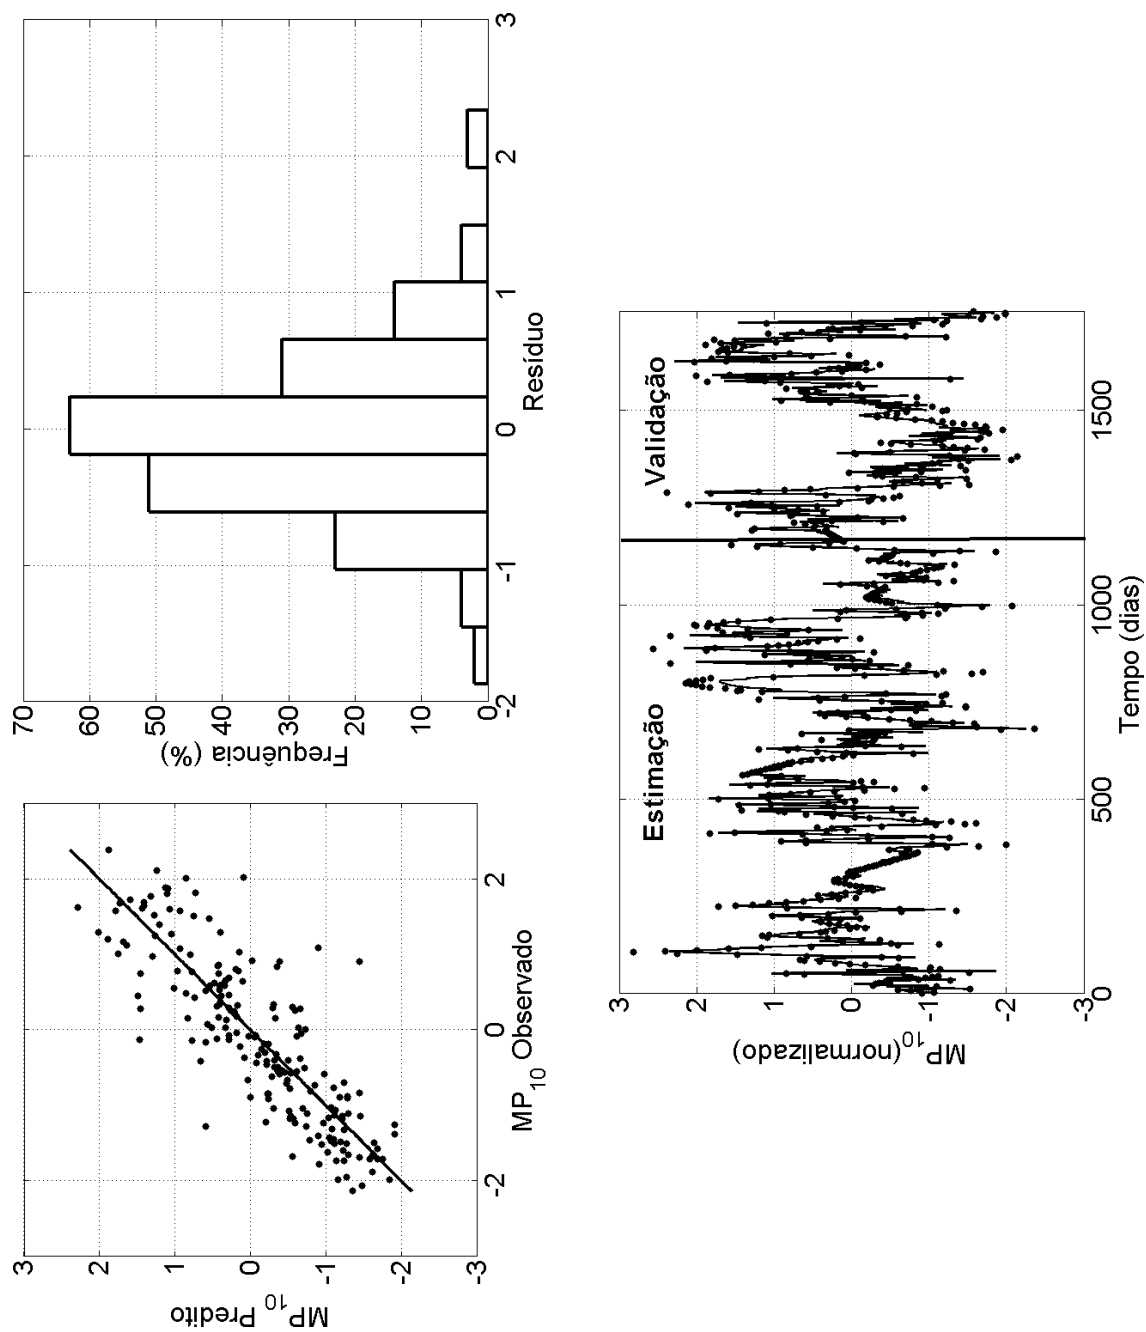


Figura B.17: Simulações do modelo ARMAX [6, 1, 1, 1] utilizando dados normalizados com média = 0 e variância = 1.

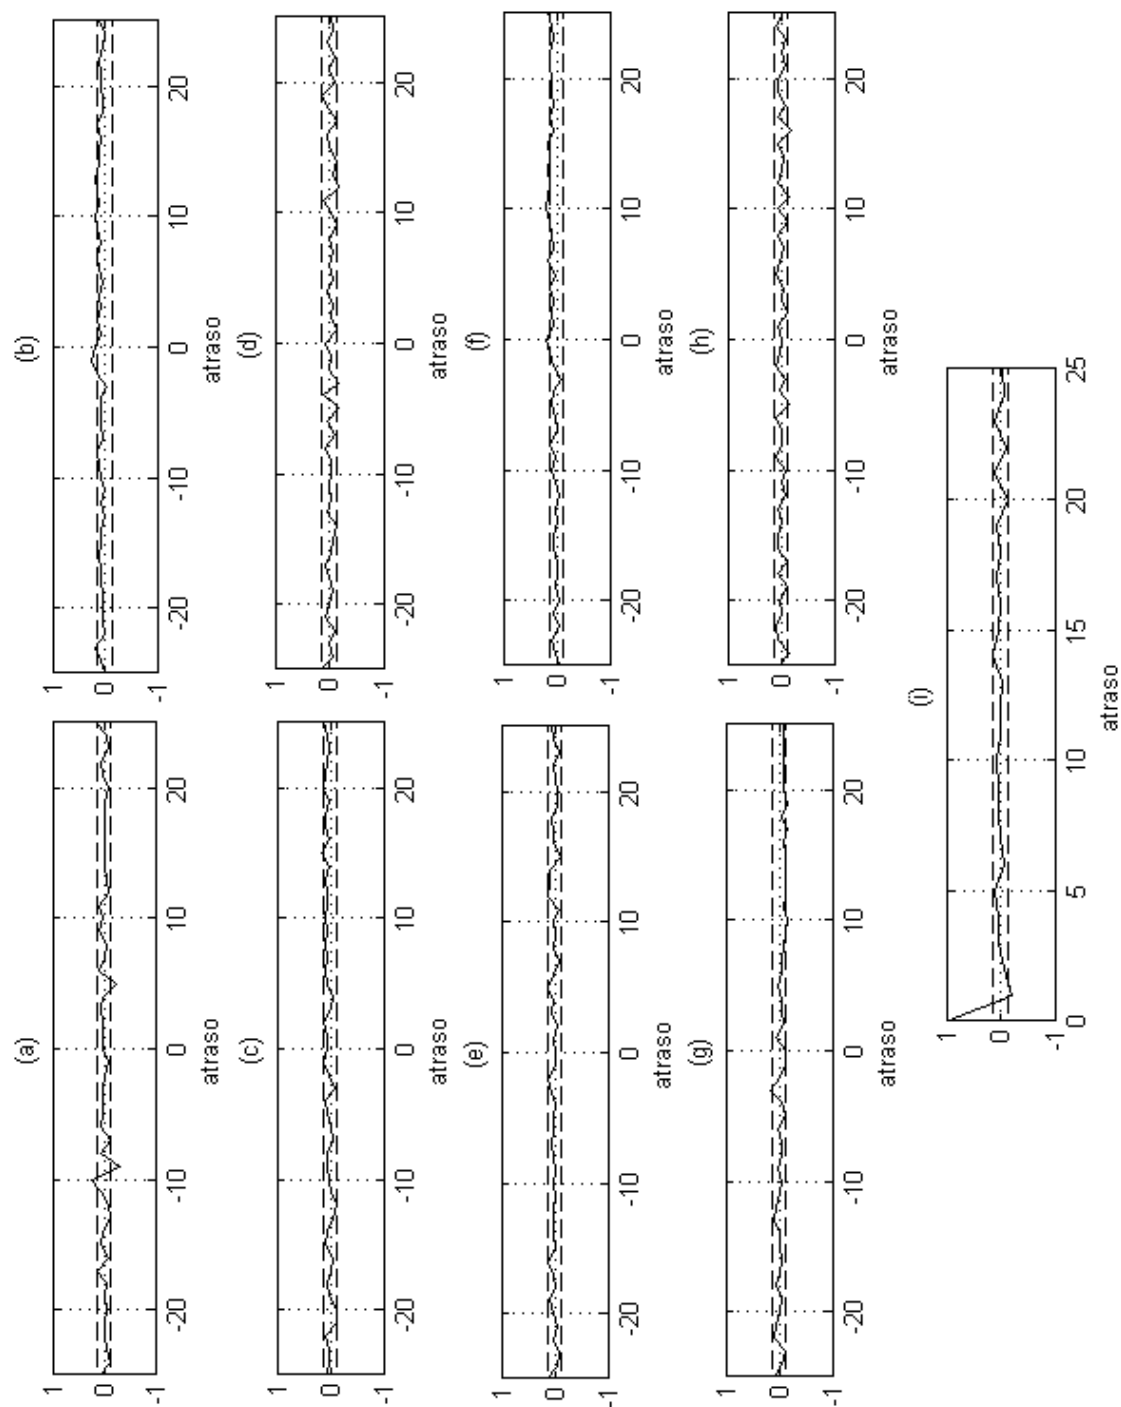


Figura B.18: Funções de autocorrelação e correlação cruzada do modelo ARMAX [6, 1, 1, 1] utilizando dados normalizados com média = 0 e variância = 1.

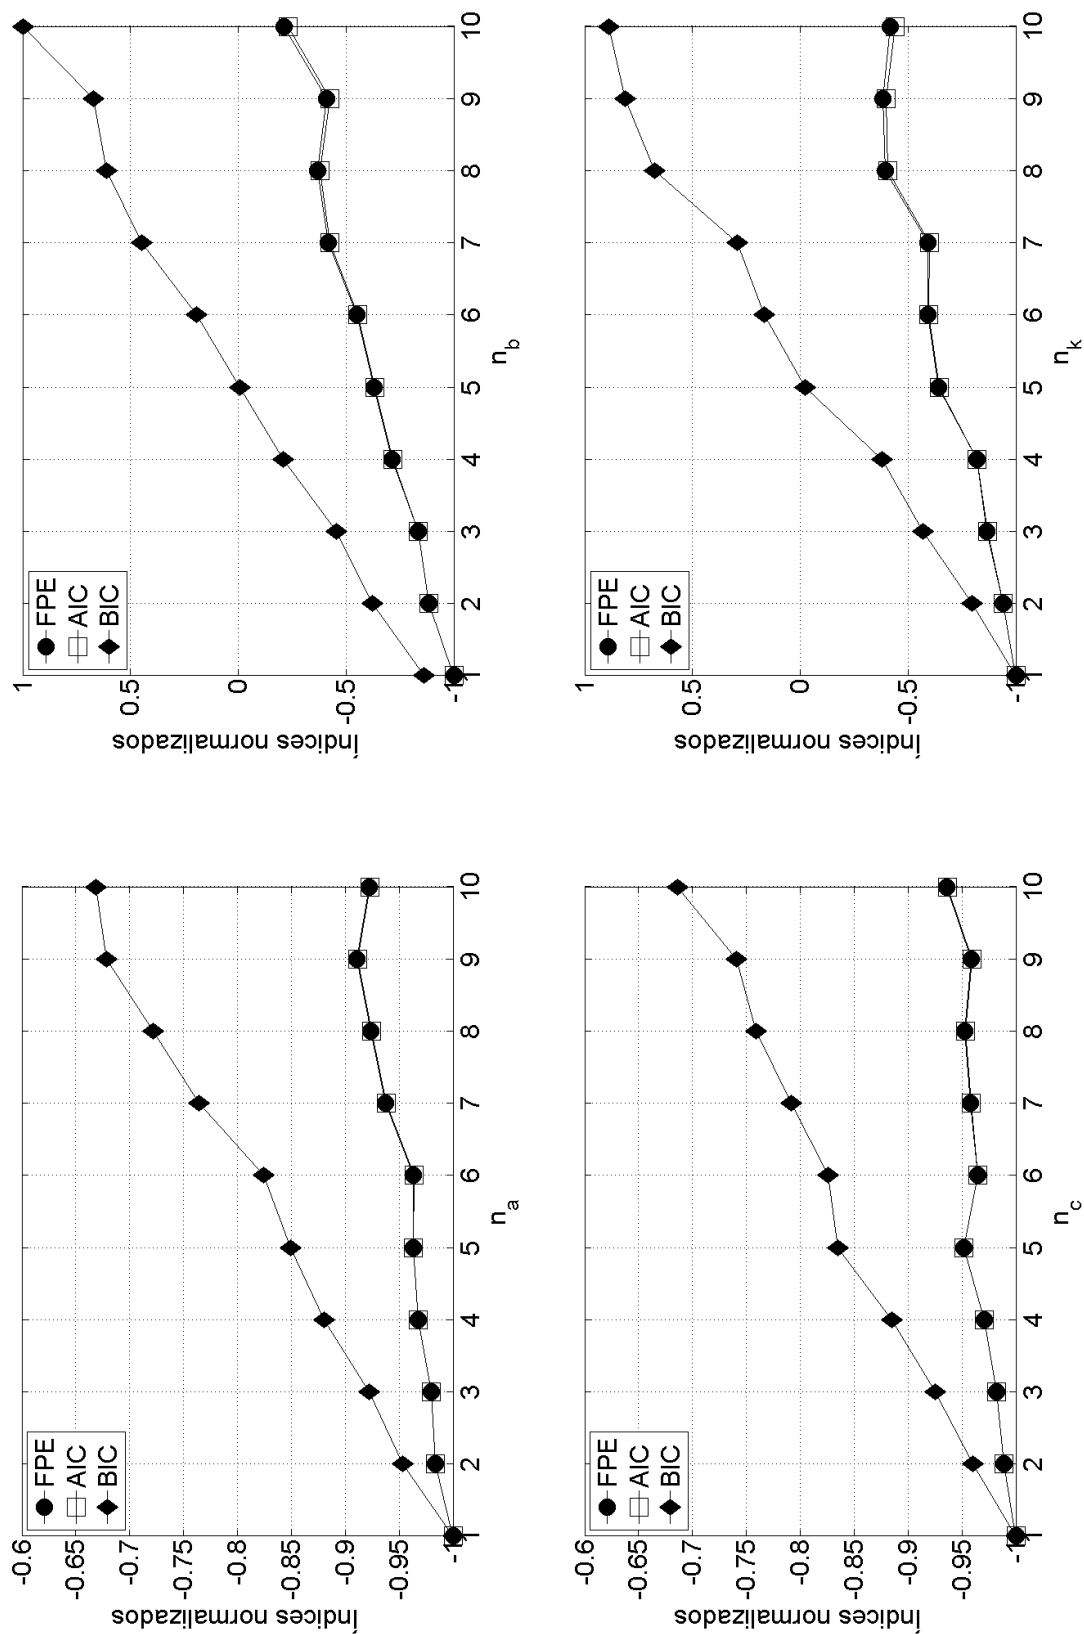


Figura B.19: Seleção da ordem dos modelos: modelo ARMAX utilizando dados normalizados com média = 0 e variância = 1 e análise de componentes principais.

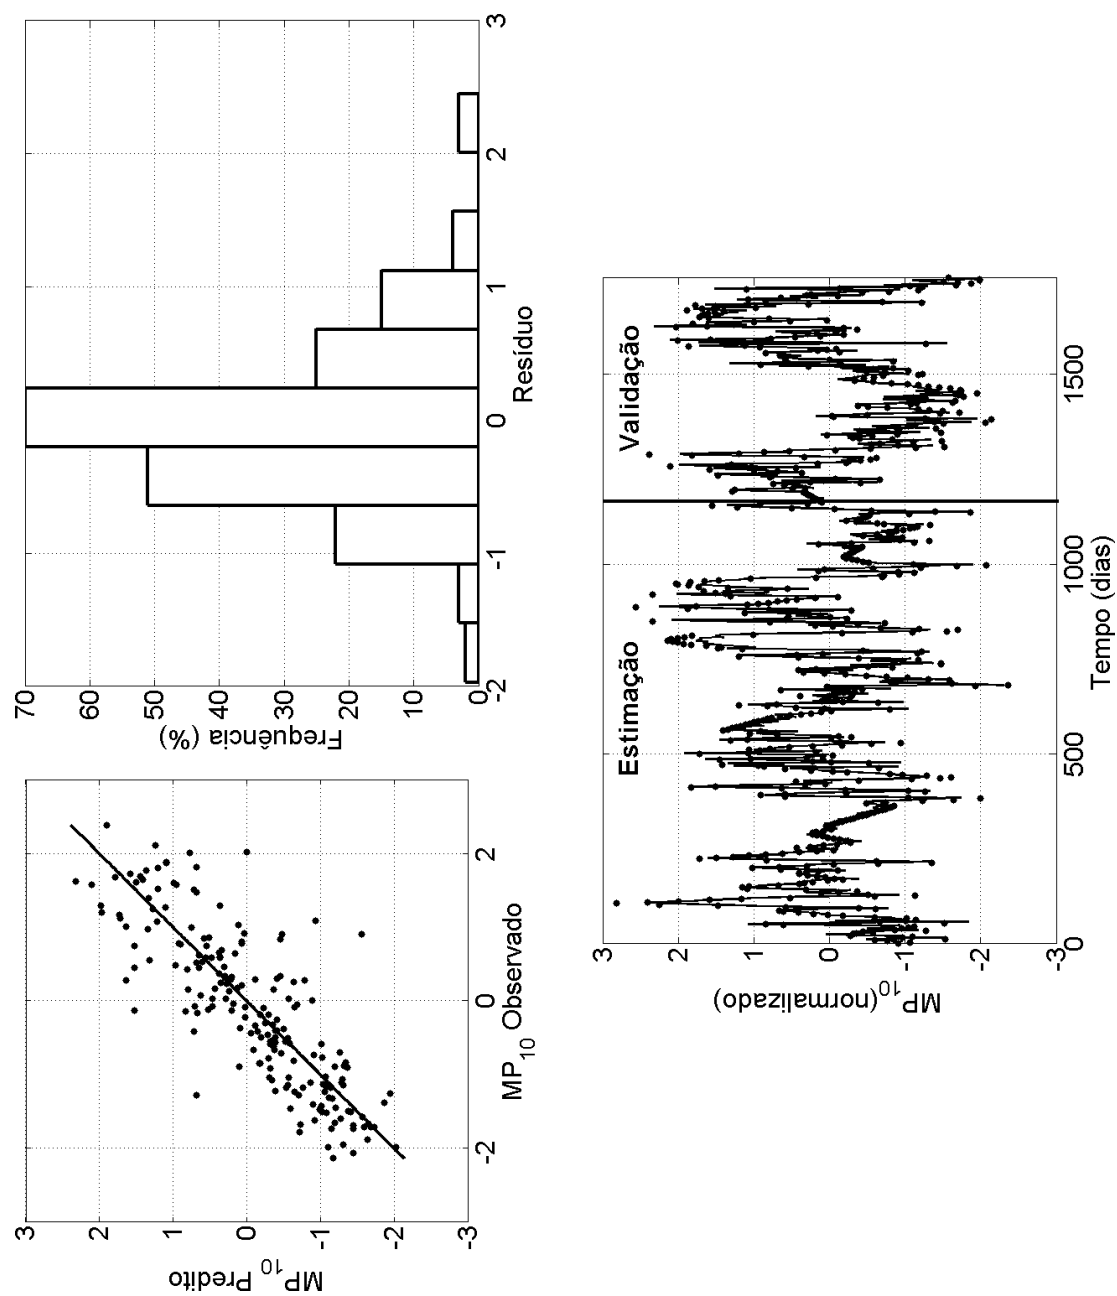


Figura B.20: Simulações do modelo ARMAX [1, 1, 1, 1] utilizando dados normalizados com média = 0 e variância = 1 e análise de componentes principais.

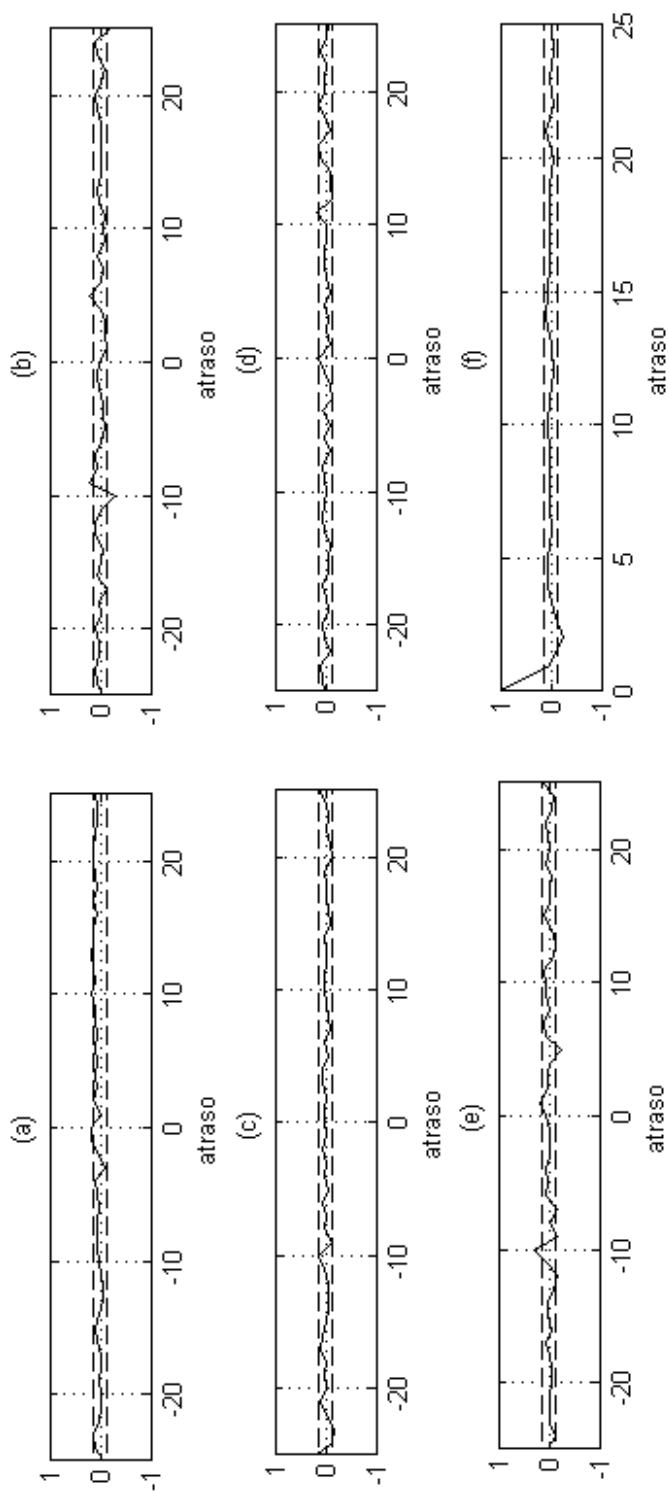


Figura B.21: Funções de autocorrelação e correlação cruzada do modelo ARMAX [1, 1, 1, 1] utilizando dados normalizados com média = 0 e variância = 1 e análise de componentes principais.

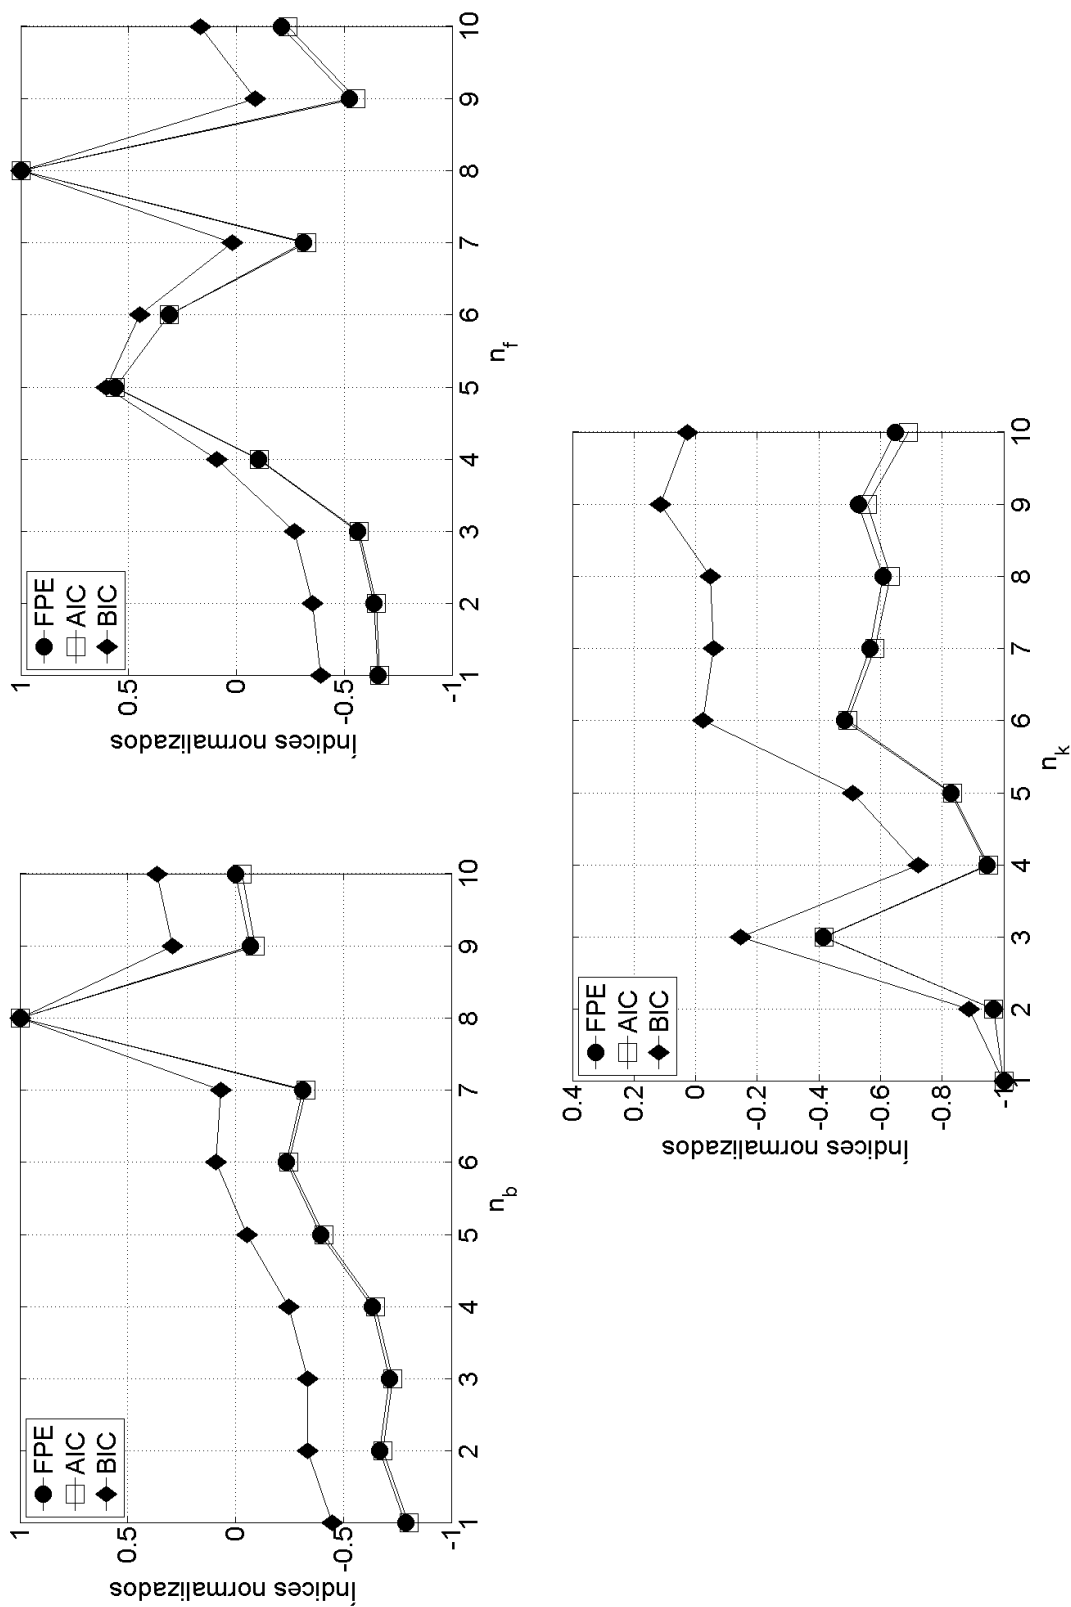


Figura B.22: Seleção da ordem do modelo OE utilizando dados normalizados no intervalo $[-1; 1]$.

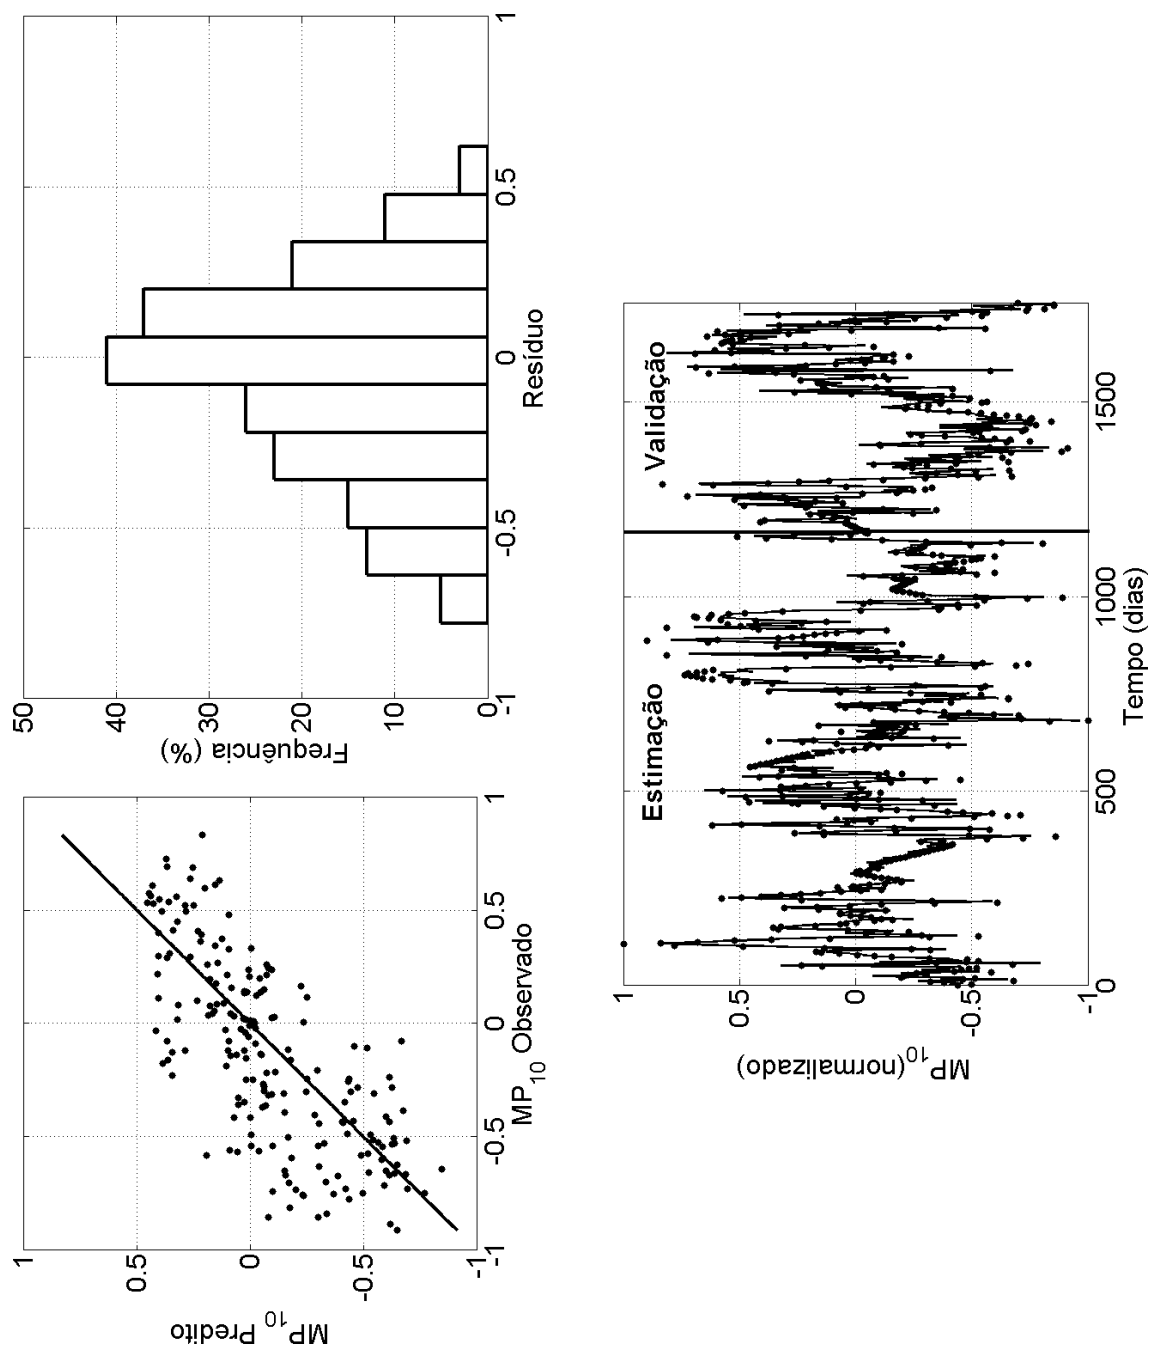


Figura B.23: Simulações do modelo OE [1, 1, 1] utilizando dados normalizados no intervalo [-1; 1].

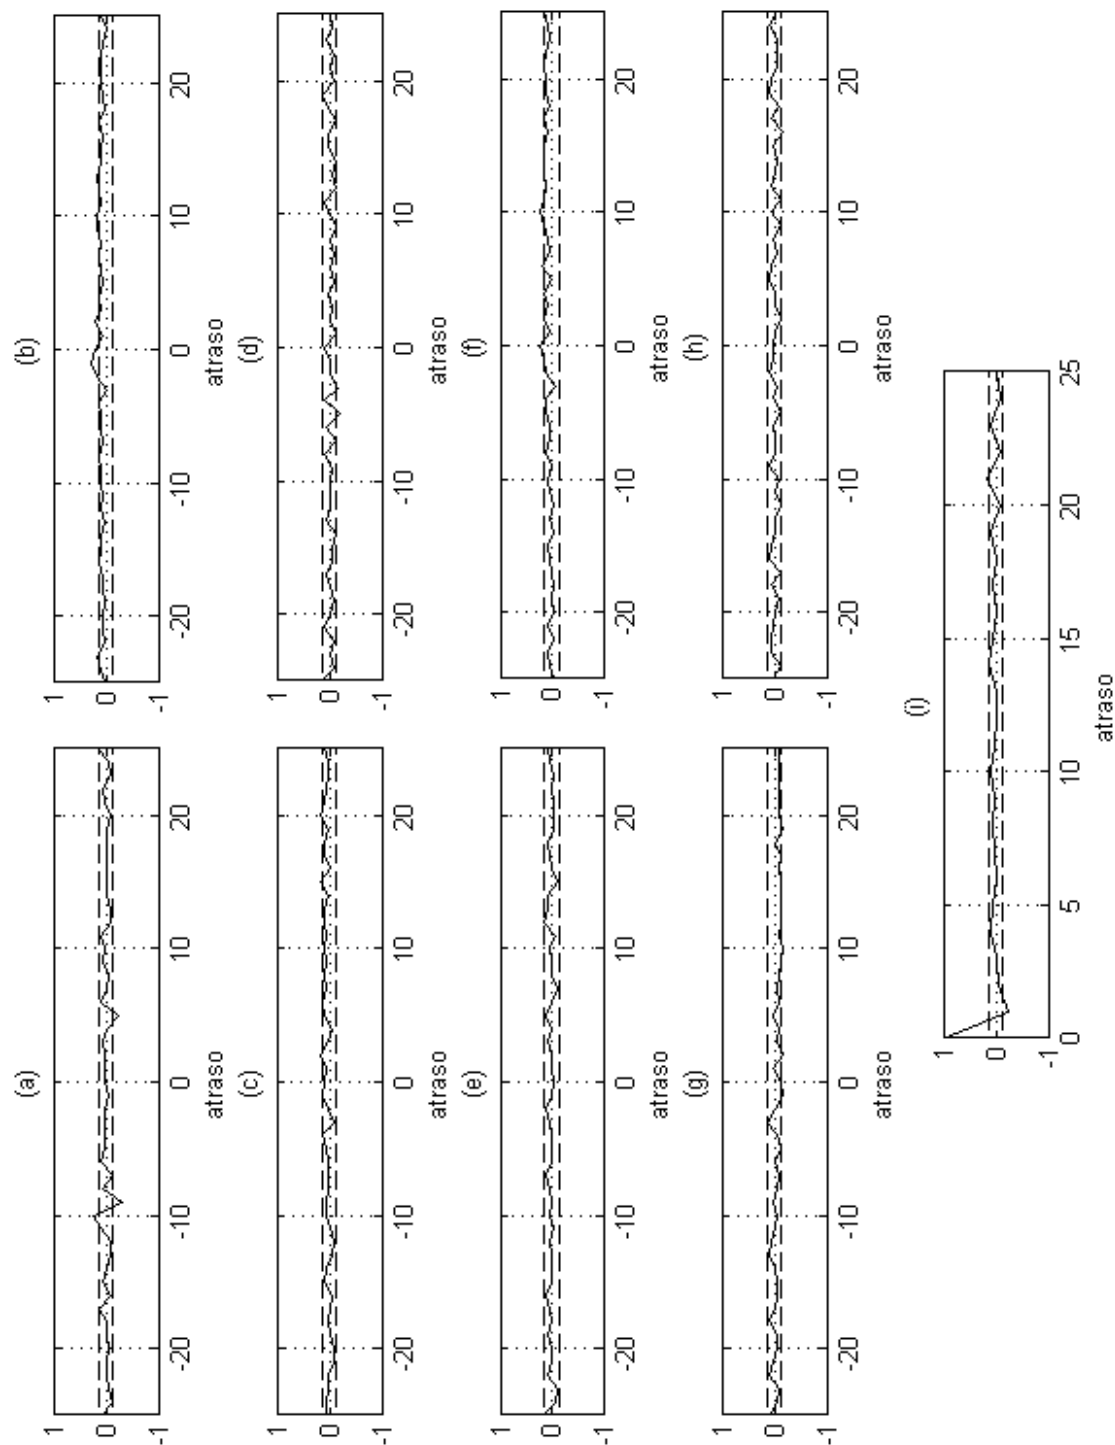


Figura B.24: Funções de autocorrelação e correlação cruzada do modelo OE [1, 1, 1] utilizando dados normalizados no intervalo [-1; 1].

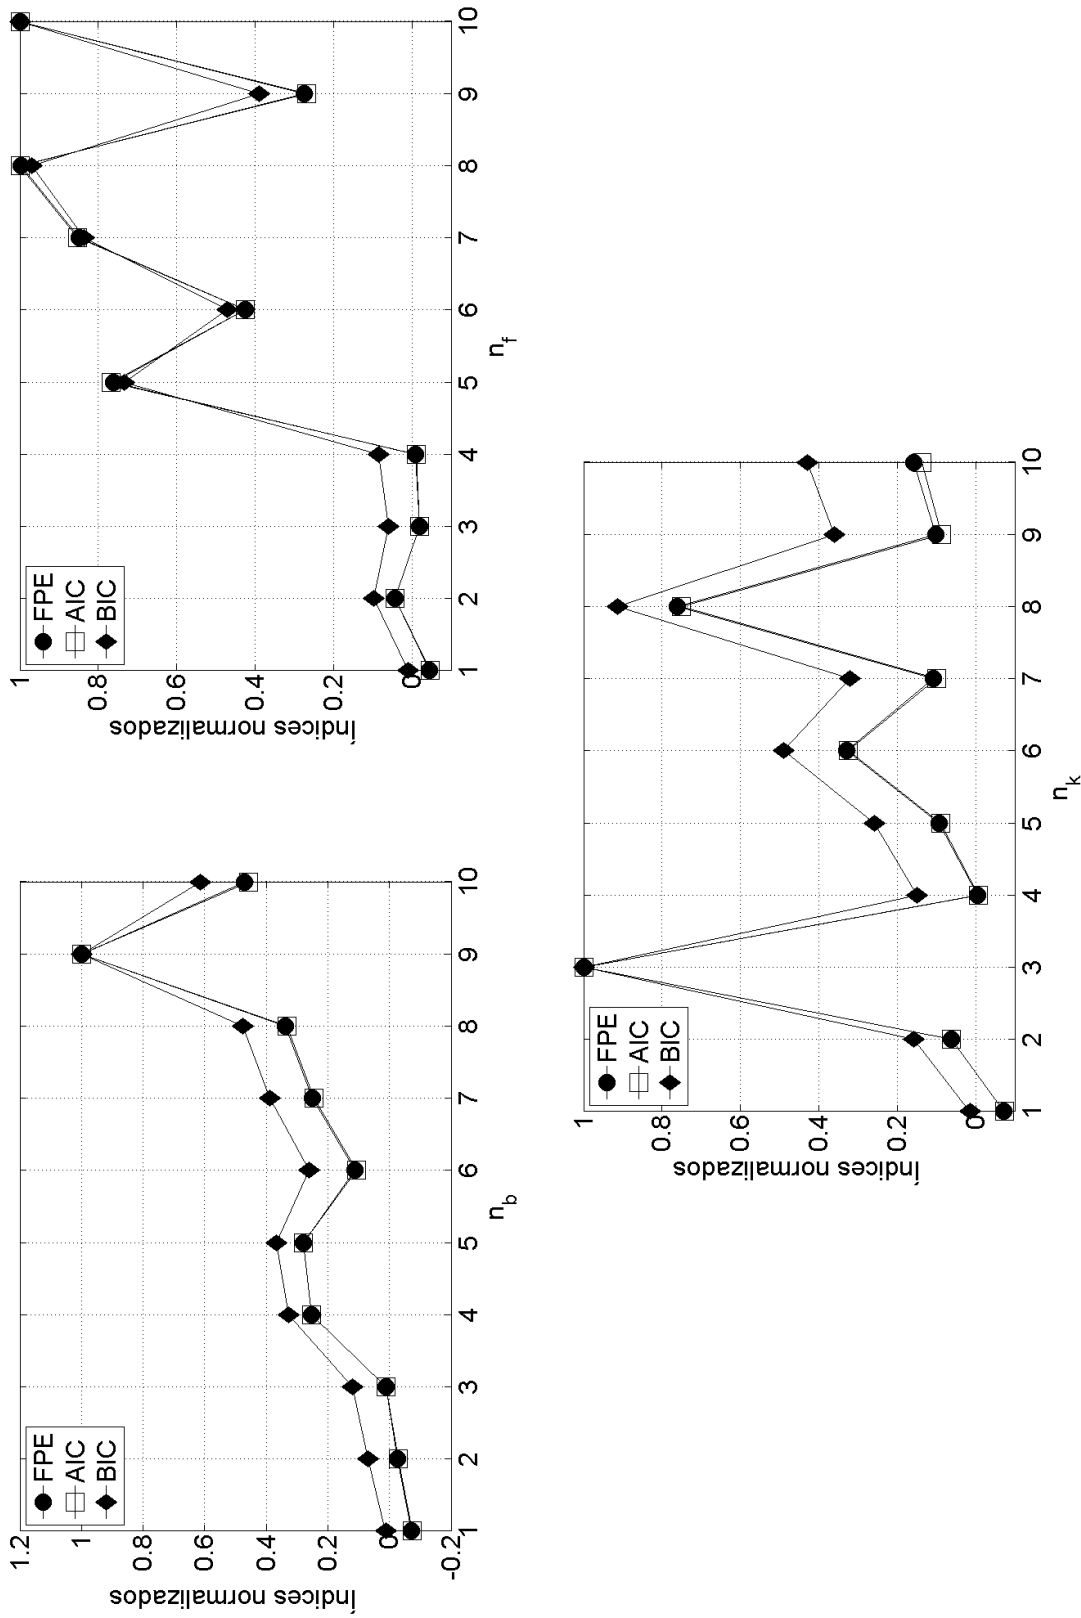


Figura B.25: Seleção da ordem do modelo OE utilizando dados normalizados com média = 0 e variância = 1.

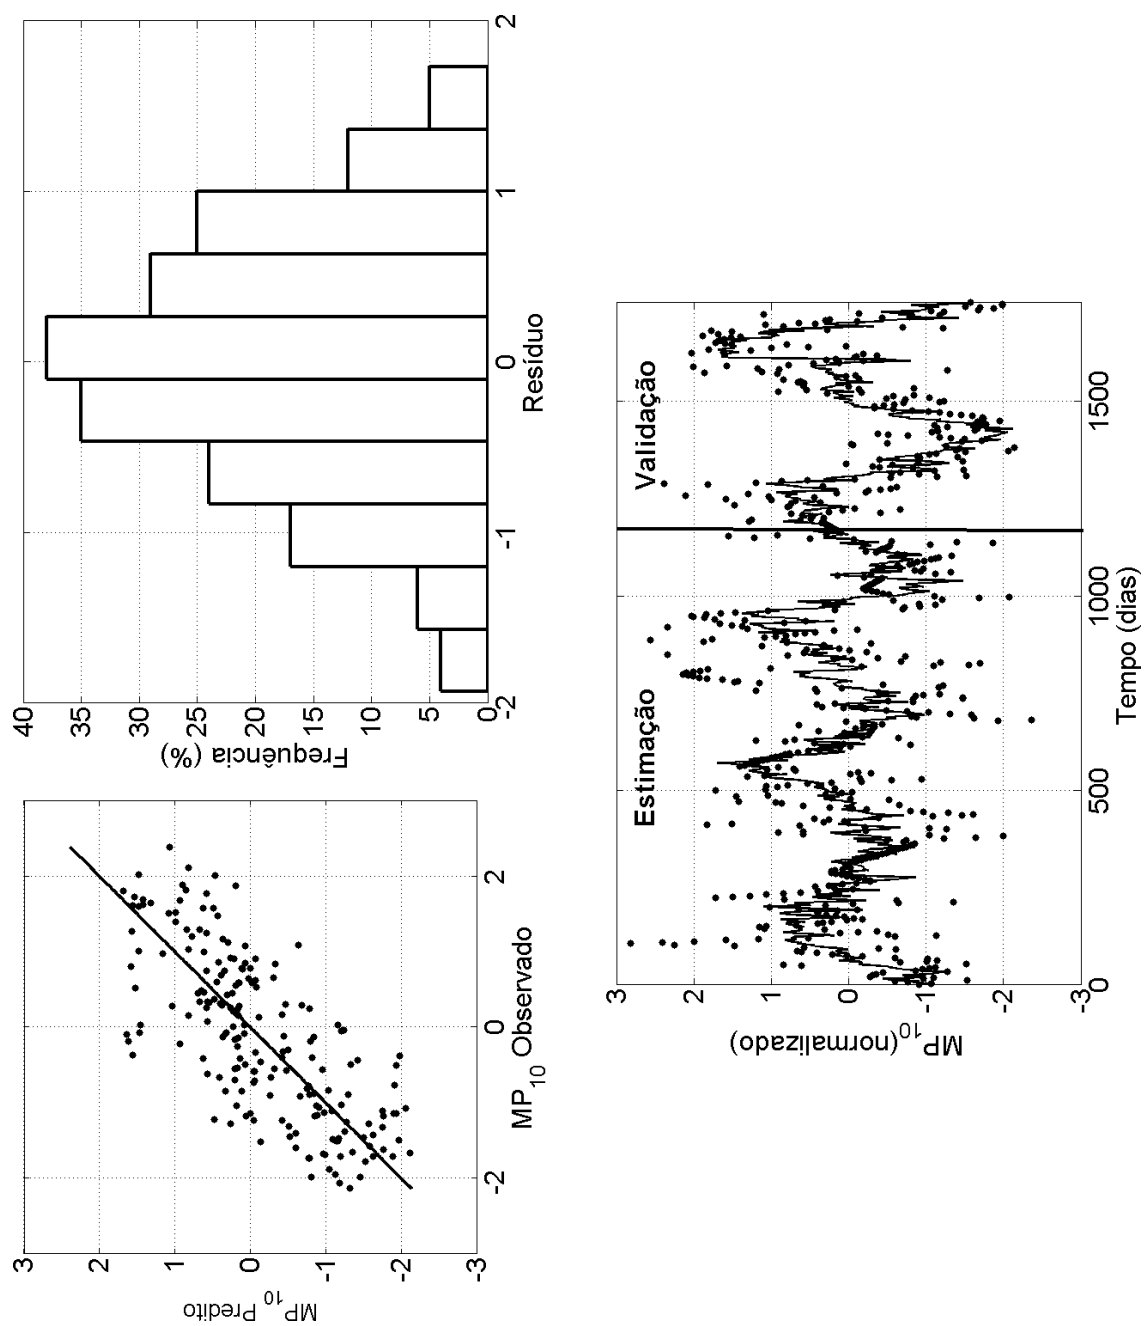


Figura B.26: Simulações do modelo OE [1, 1, 1] utilizando dados normalizados com média = 0 e variância = 1.

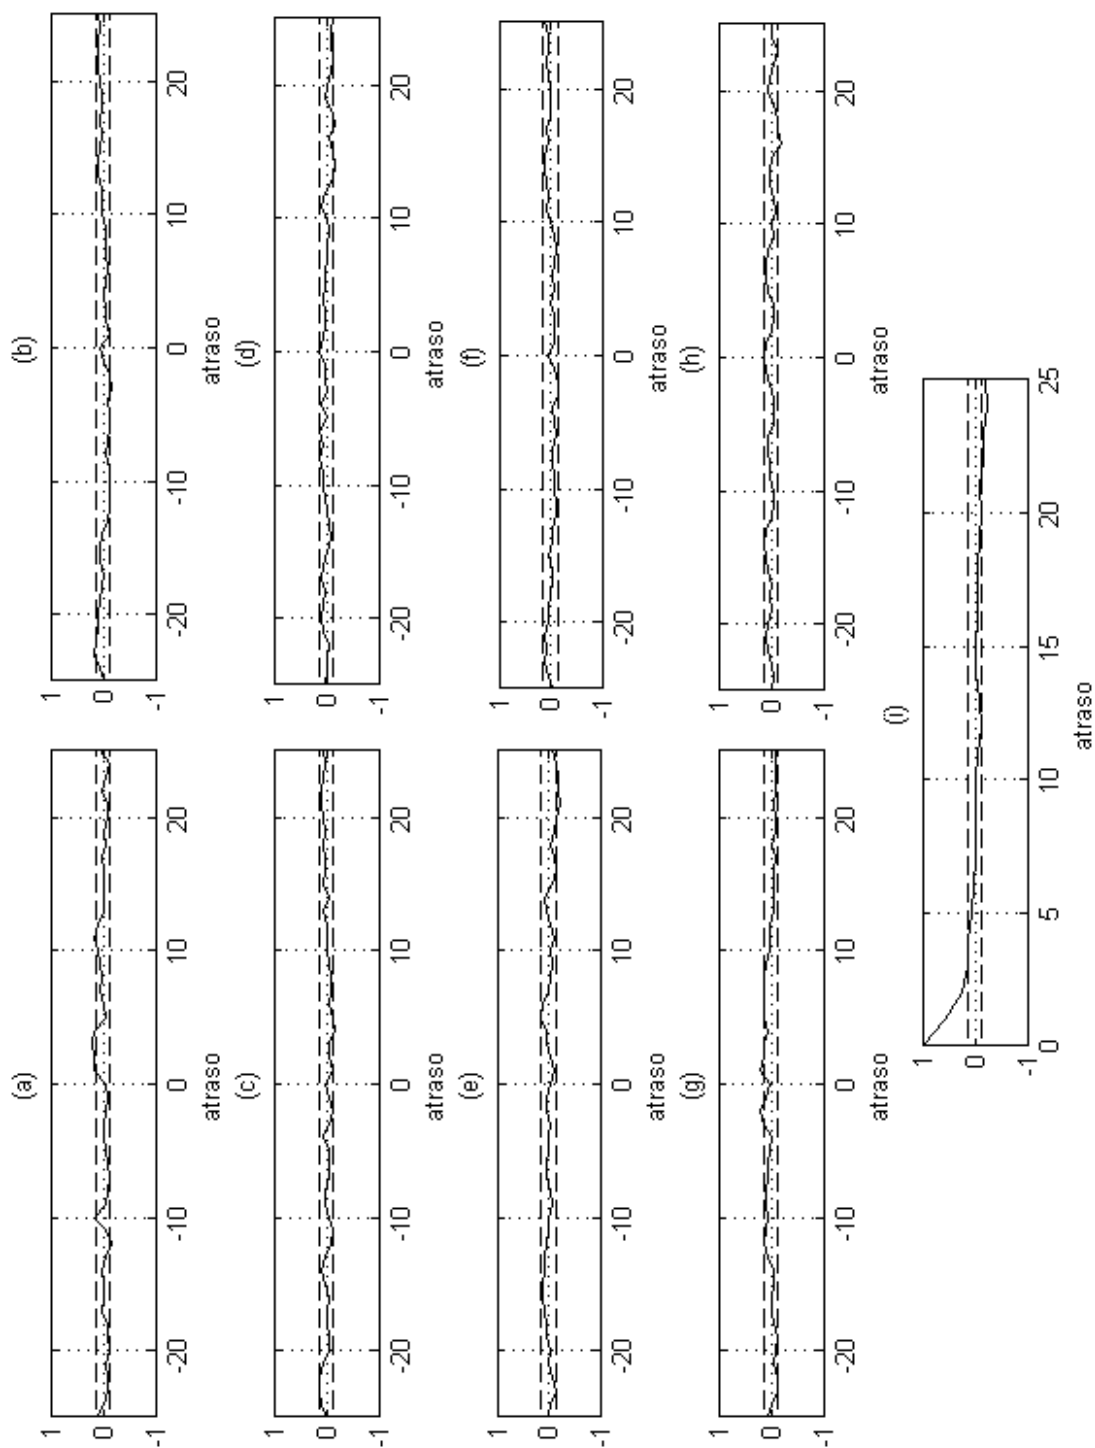


Figura B.27: Funções de autocorrelação e correlação cruzada do modelo OE $[1, 1, 1]$ utilizando dados normalizados com média = 0 e variância = 1.

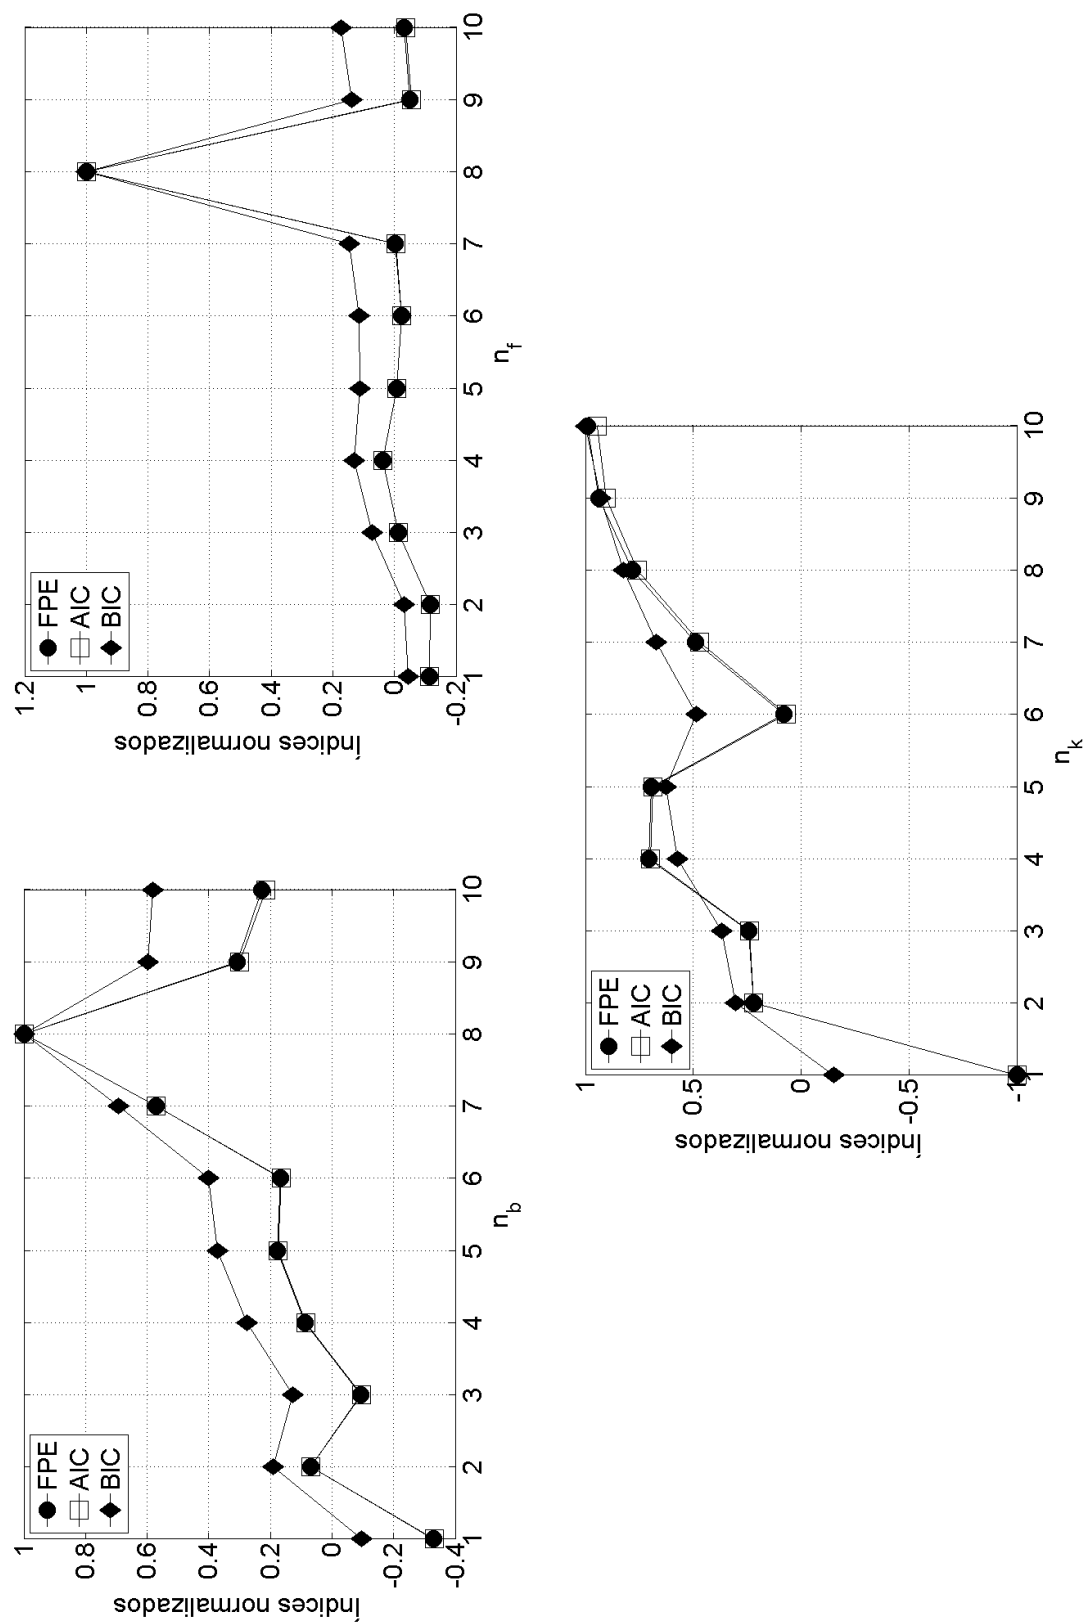


Figura B.28: Seleção da ordem do modelo OE utilizando dados normalizados com média = 0 e variância = 1 e análise de componentes principais.

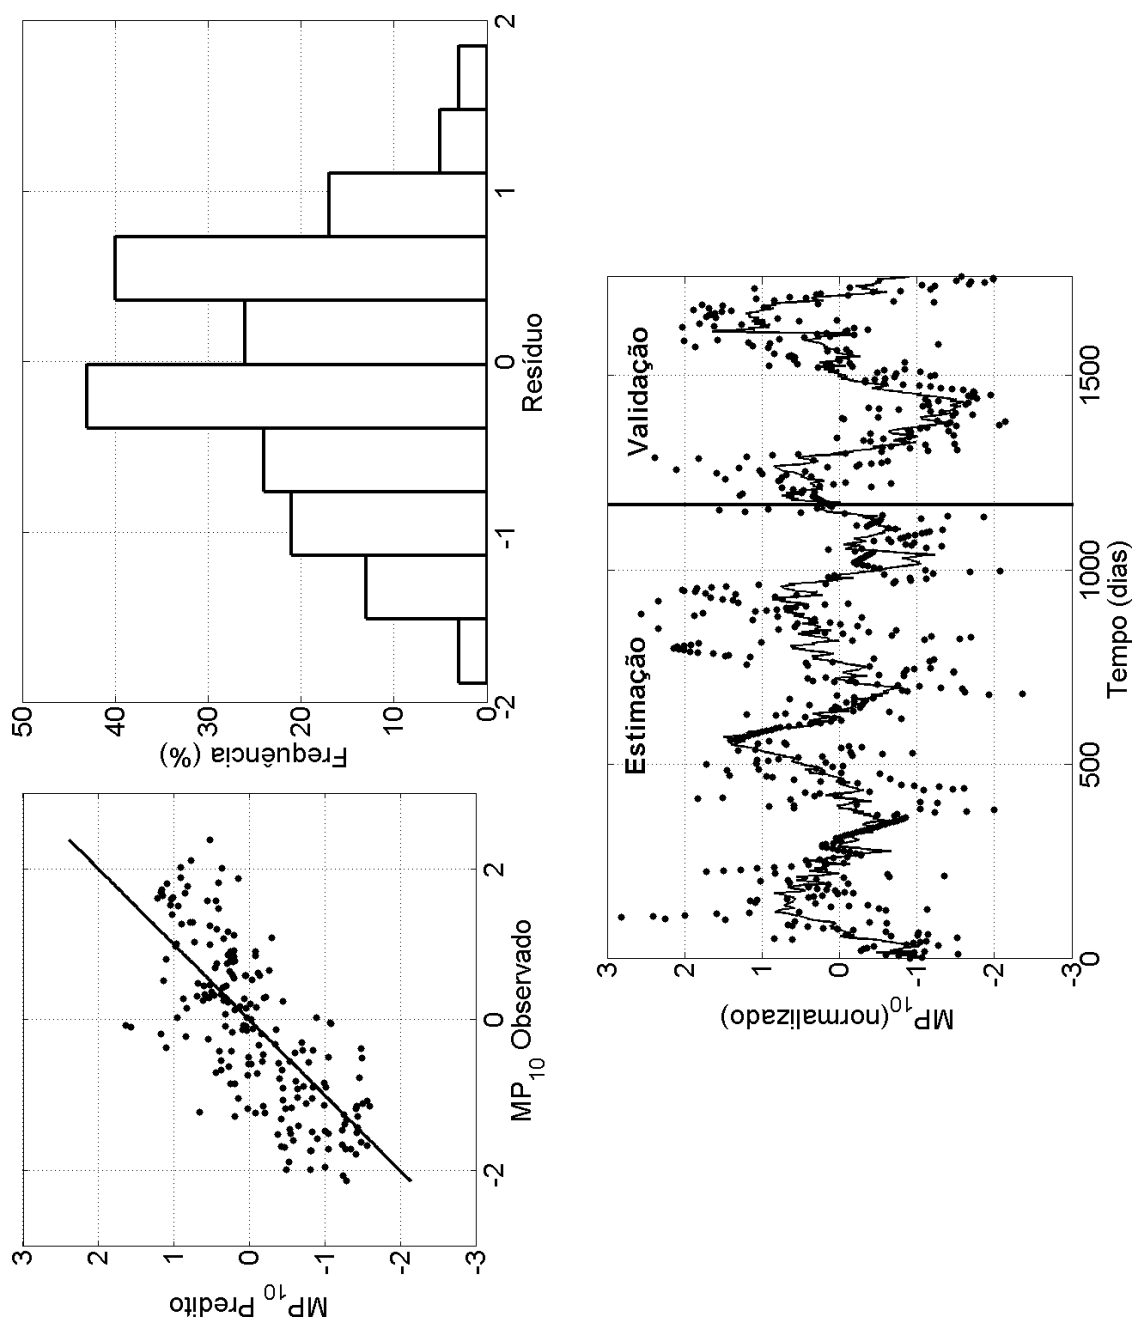


Figura B.29: Simulações do modelo OE [1, 1, 1] utilizando dados normalizados com média = 0 e variância = 1 e análise de componentes principais.

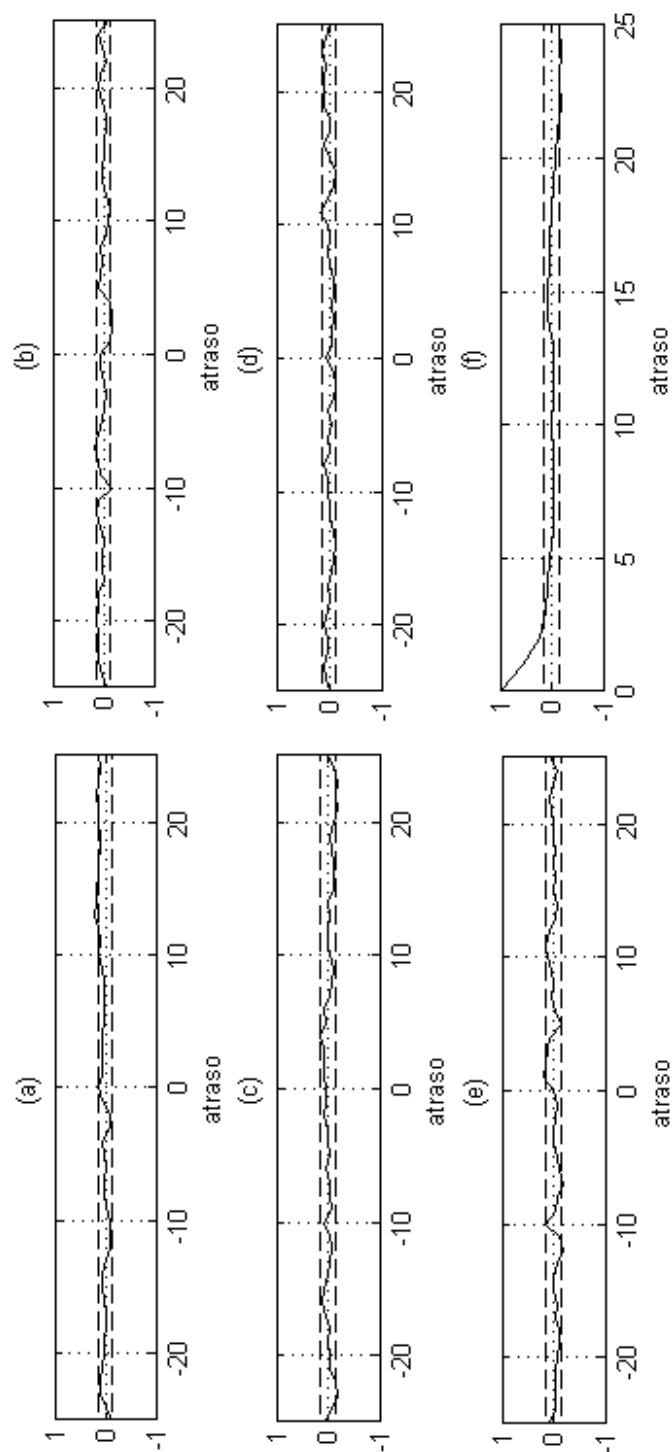


Figura B.30: Funções de autocorrelação e correlação cruzada do modelo OE $[1, 1, 1]$ utilizando dados normalizados com média = 0 e variância = 1 e análise de componentes principais.

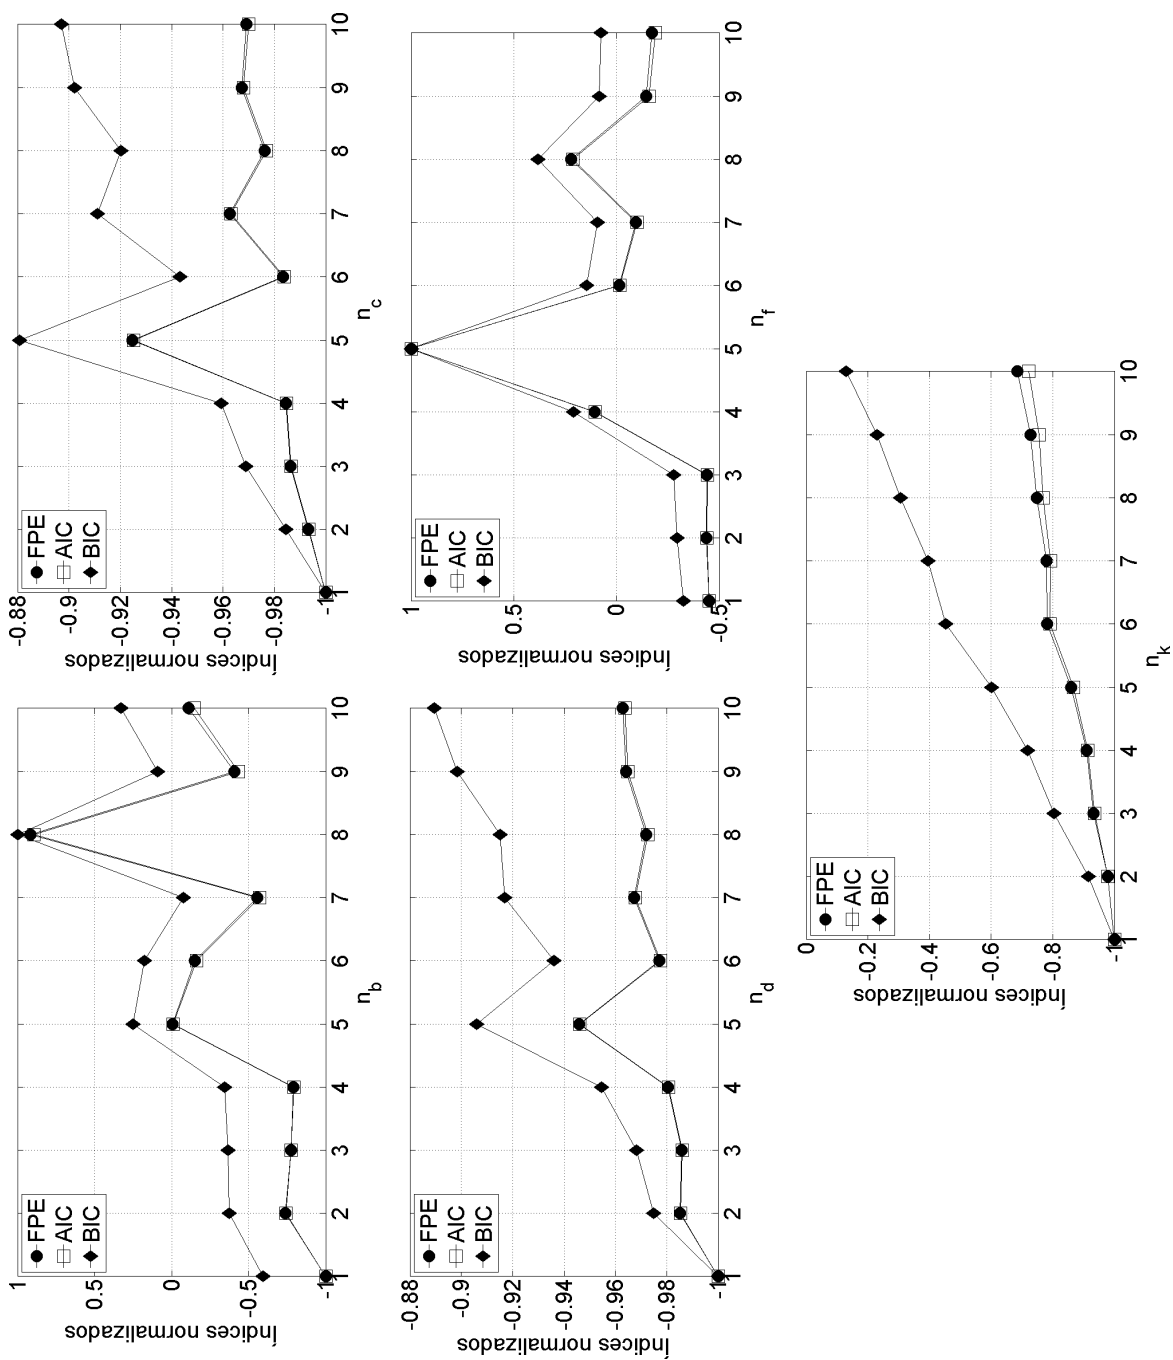


Figura B.31: Seleção da ordem do modelo BJ utilizando dados normalizados no intervalo $[-1; 1]$.

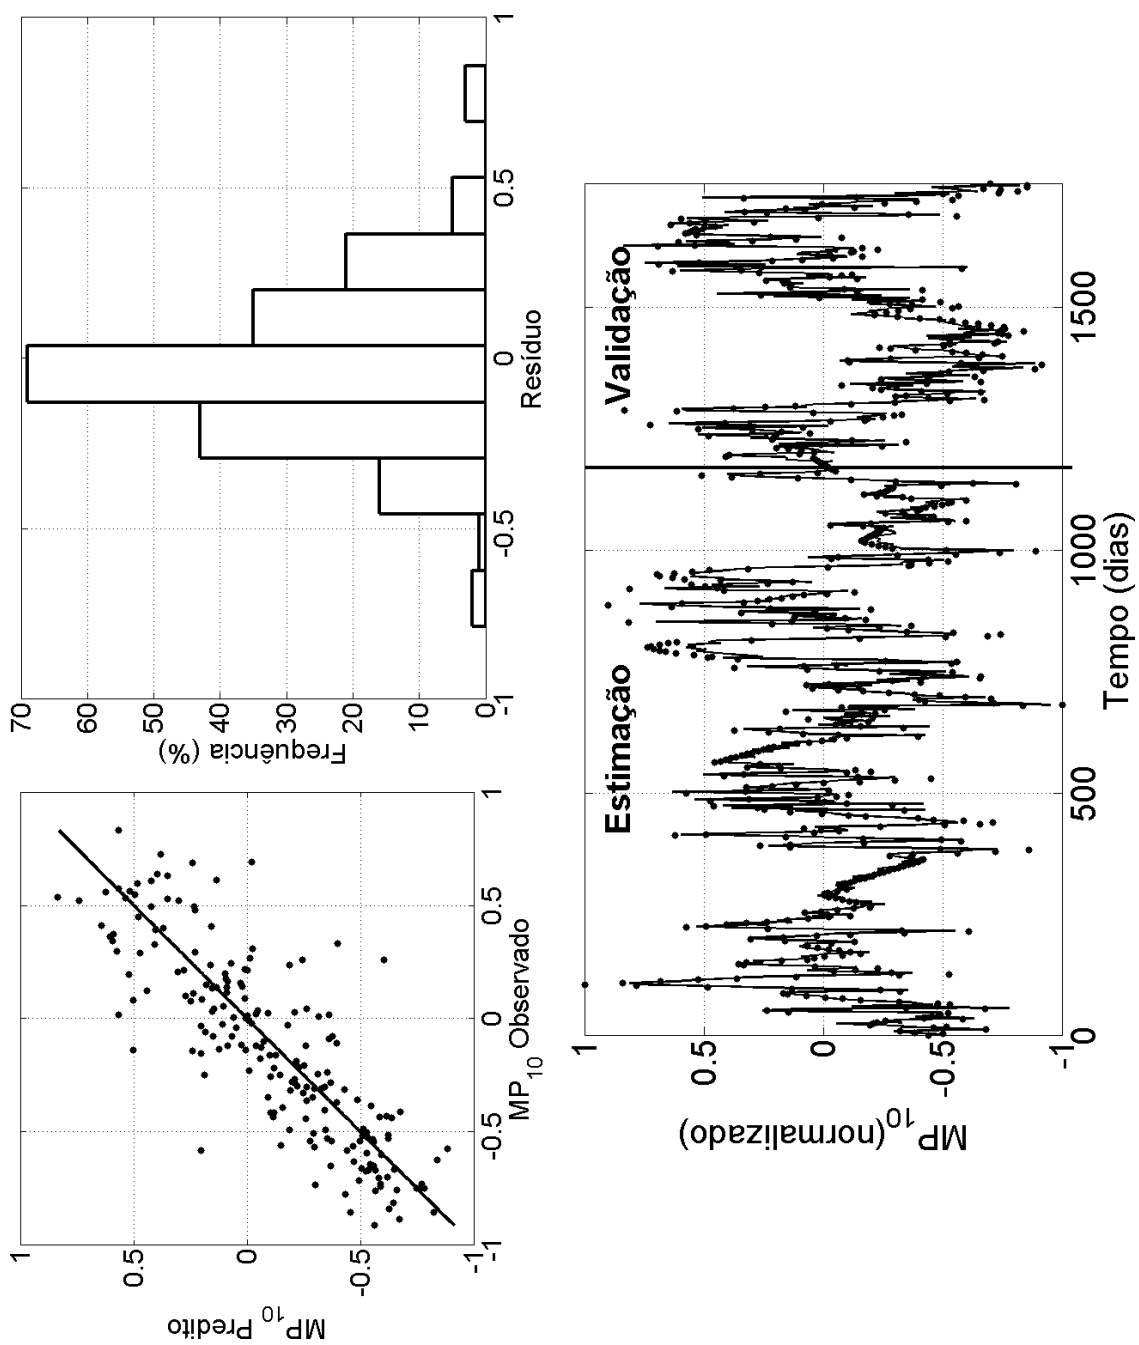


Figura B.32: Simulações do modelo BJ [1, 1, 1, 1, 1] utilizando dados normalizados no intervalo [-1; 1].

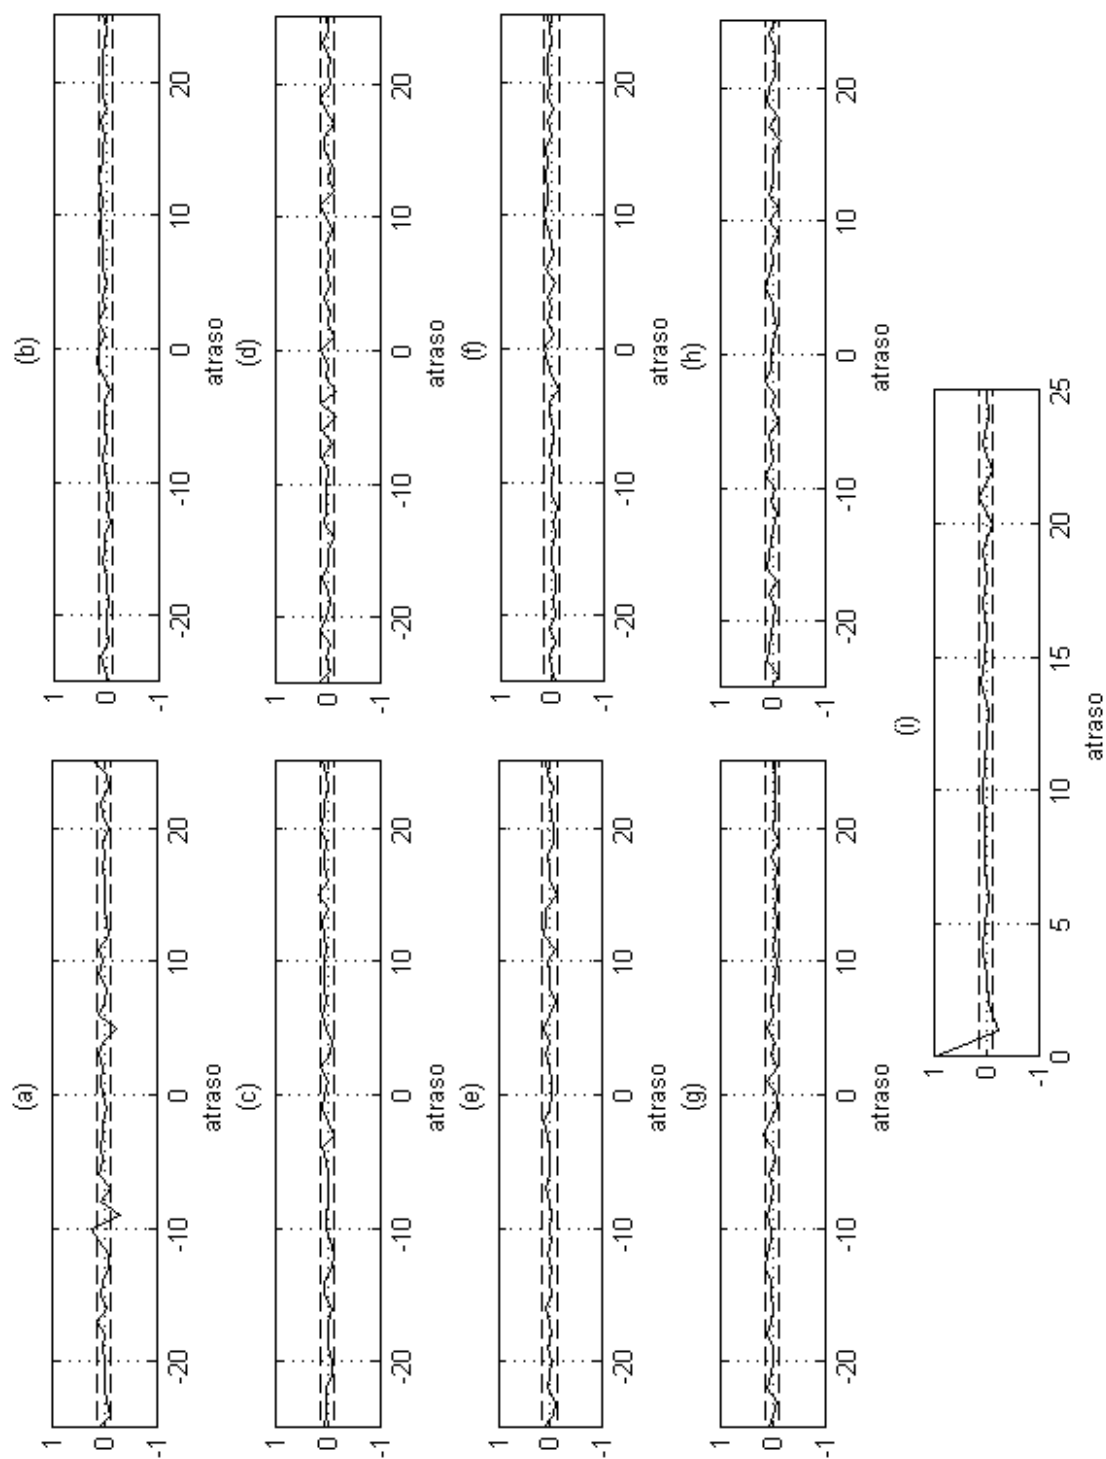


Figura B.33: Funções de autocorrelação e correlação cruzada do modelo BJ $[1, 1, 1, 1, 1]$ utilizando dados normalizados no intervalo $[-1; 1]$.

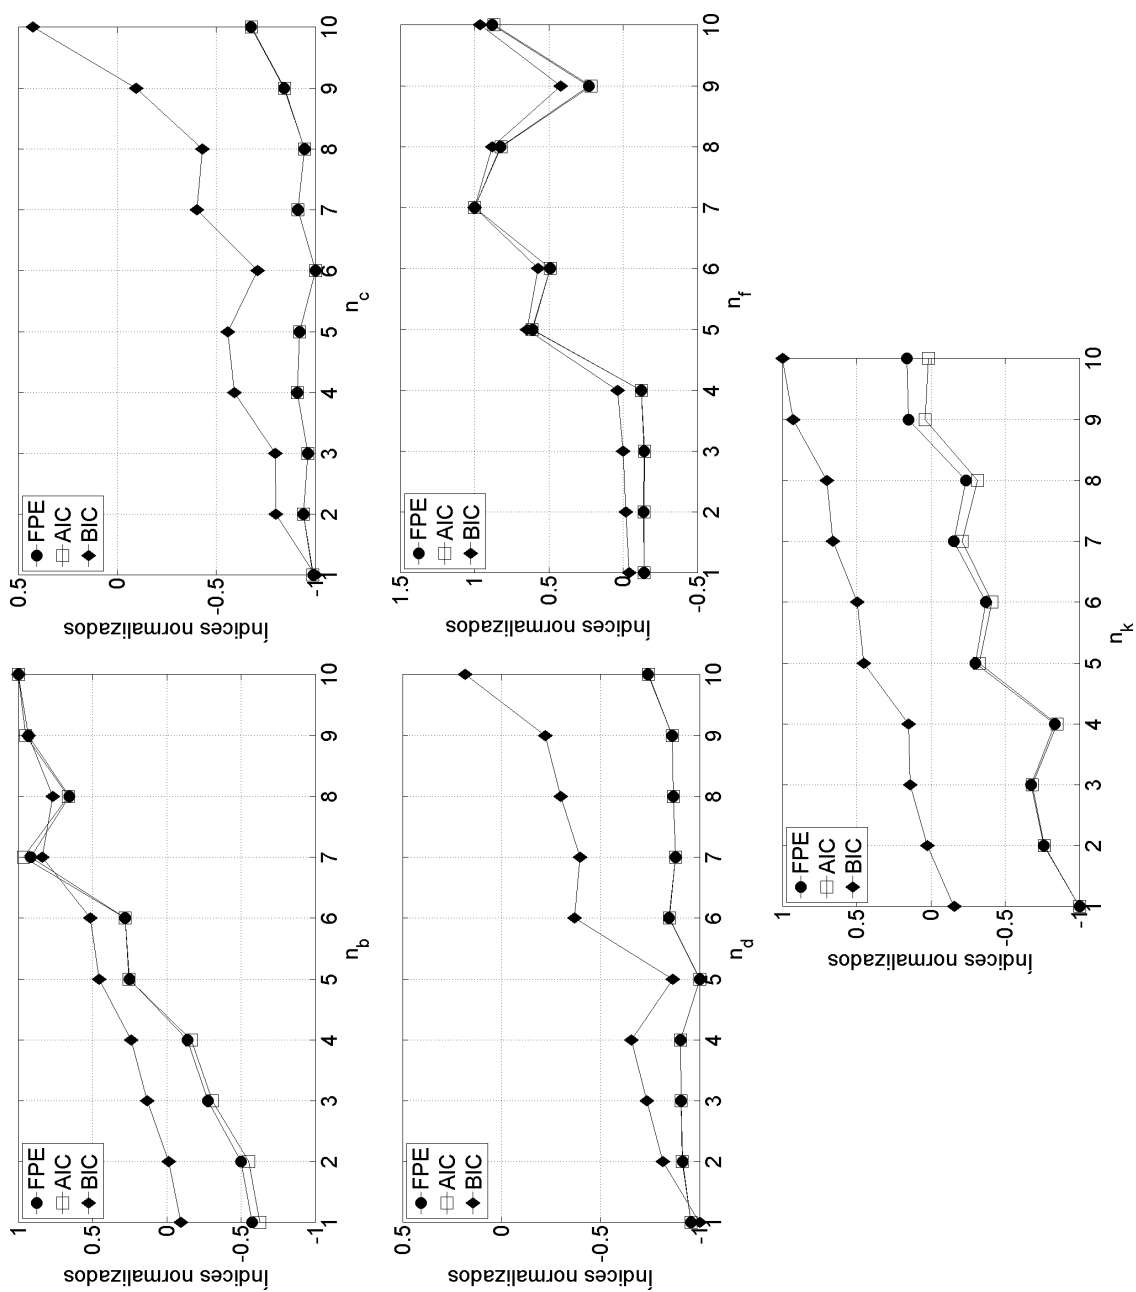


Figura B.34: Seleção da ordem do modelo BJ utilizando dados normalizados com média = 0 e variância = 1.

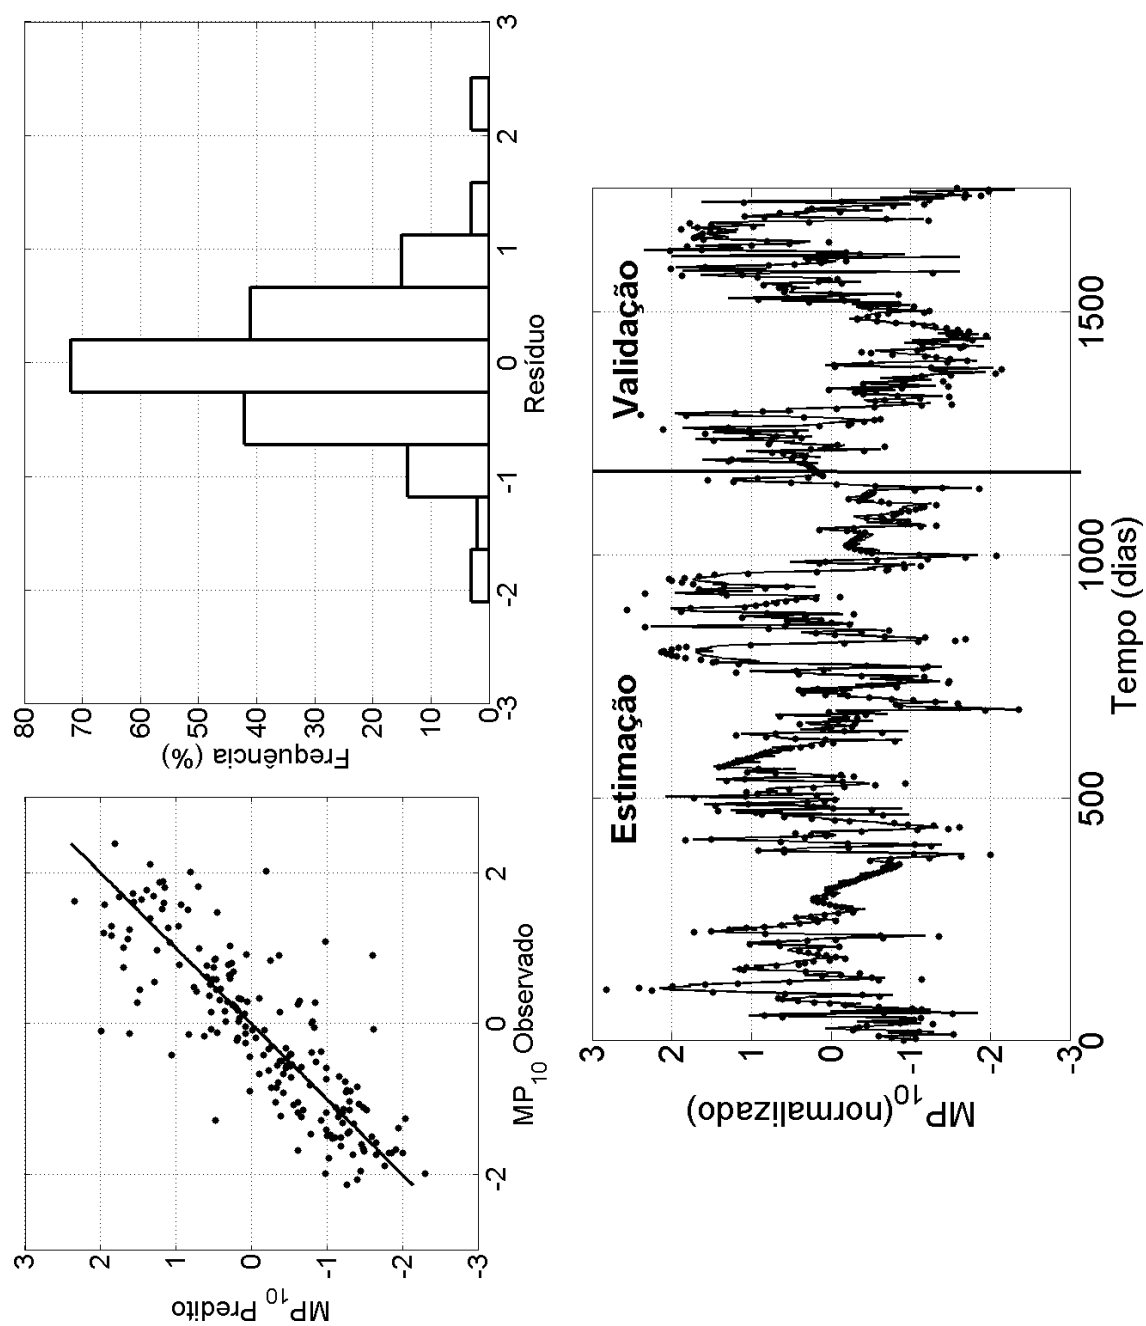


Figura B.35: Simulações do modelo BJ [1, 6, 5, 1, 1] utilizando dados normalizados com média = 0 e variância = 1.

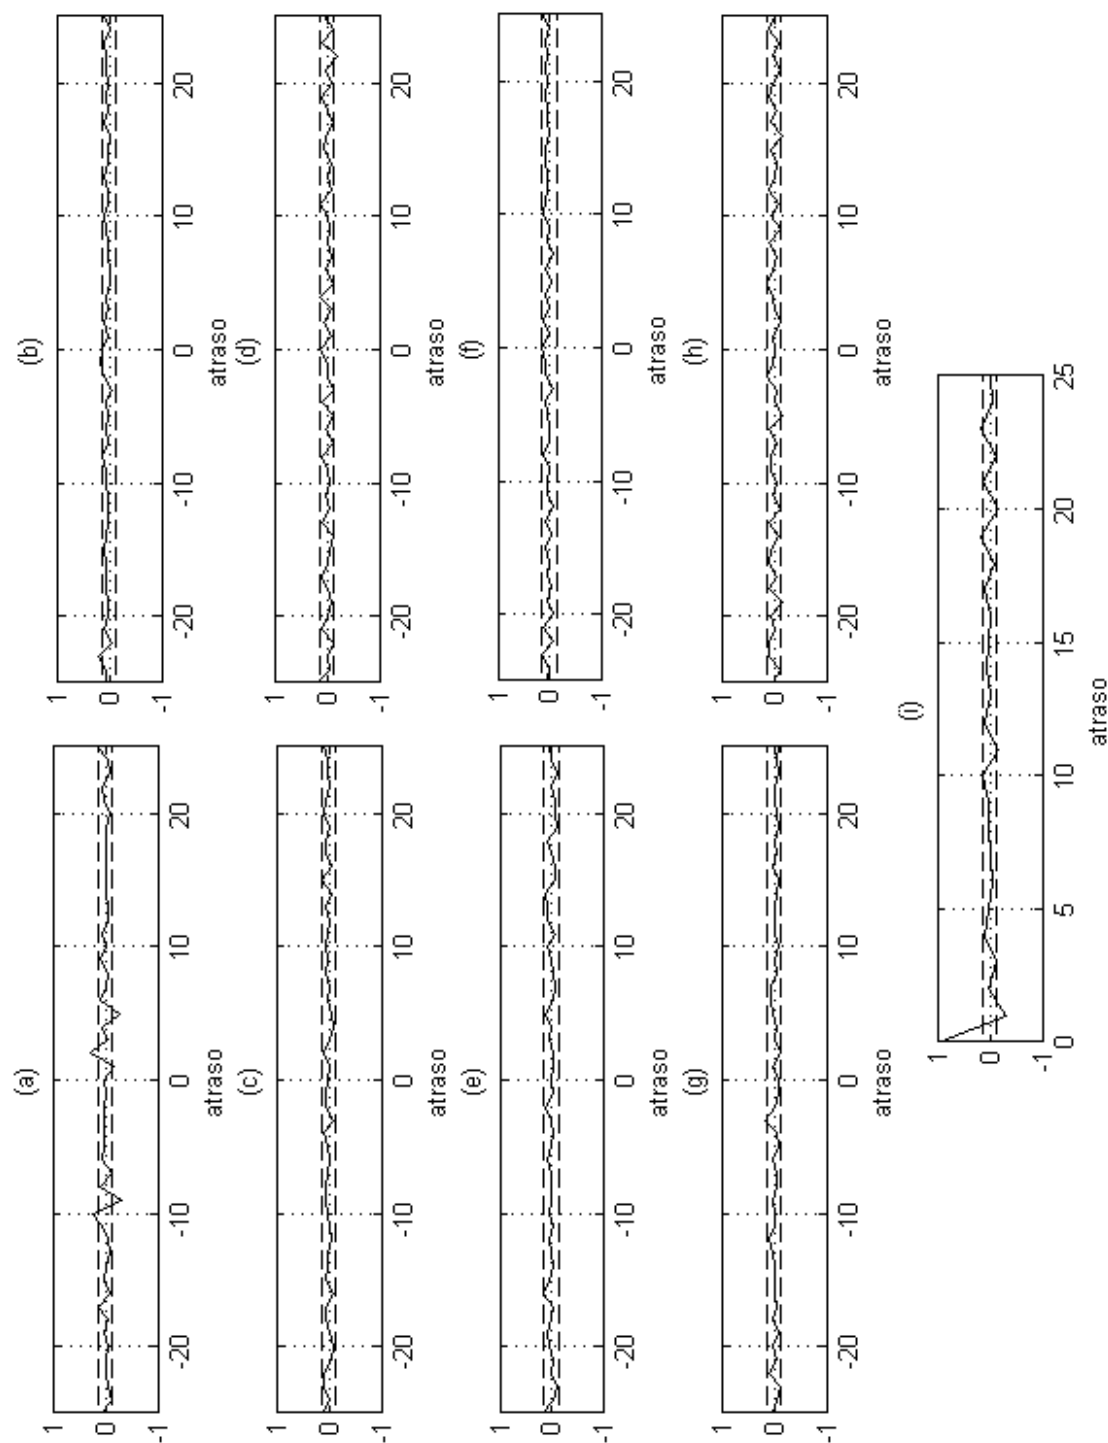


Figura B.36: Funções de autocorrelação e correlação cruzada do modelo BJ [1, 6, 5, 1, 1] utilizando dados normalizados com média = 0 e variância = 1.

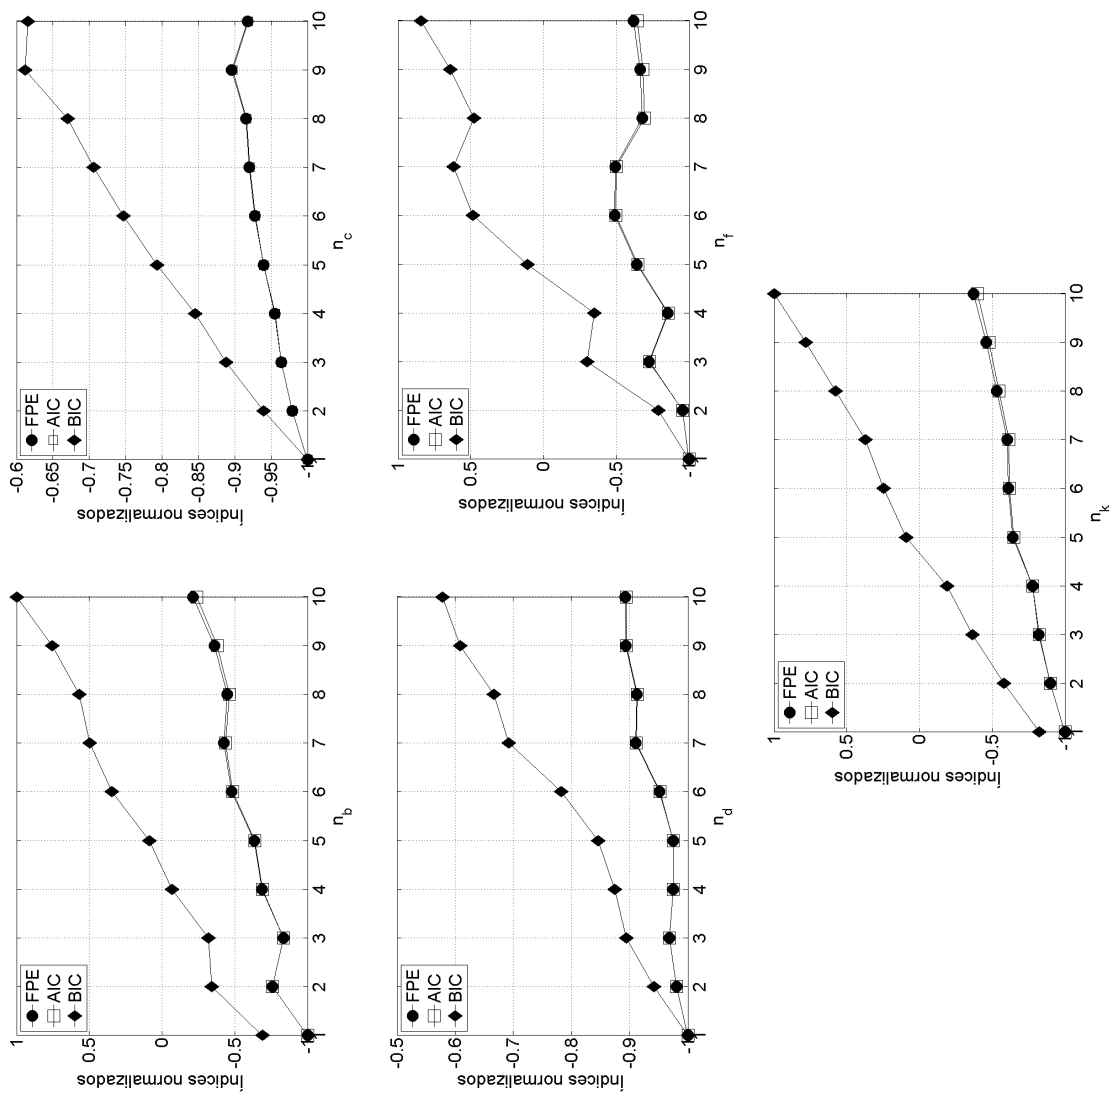


Figura B.37: Seleção da ordem do modelo BJ utilizando dados normalizados com média = 0 e variância = 1 e análise de componentes principais.

B.3 Dispersão das classes da CID-10 em função da temperatura e da umidade relativa

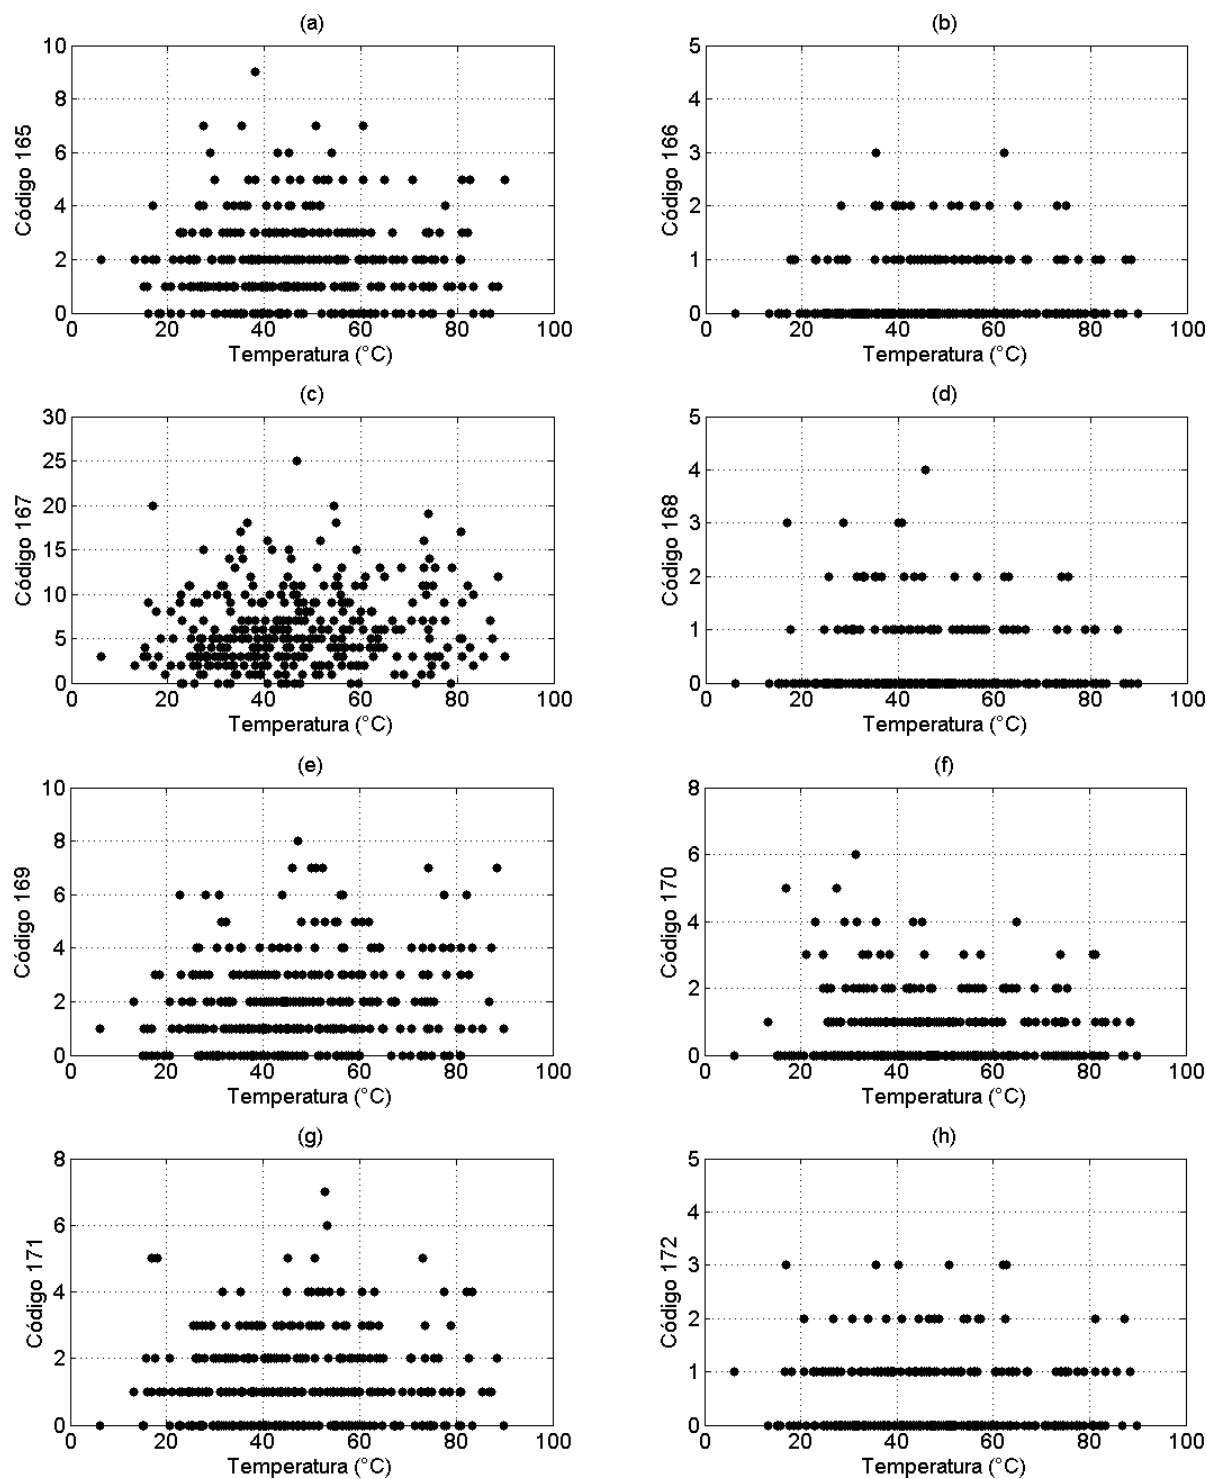


Figura B.38: Dispersão das classes da CID-10 (de 165 a 172) em função da temperatura.

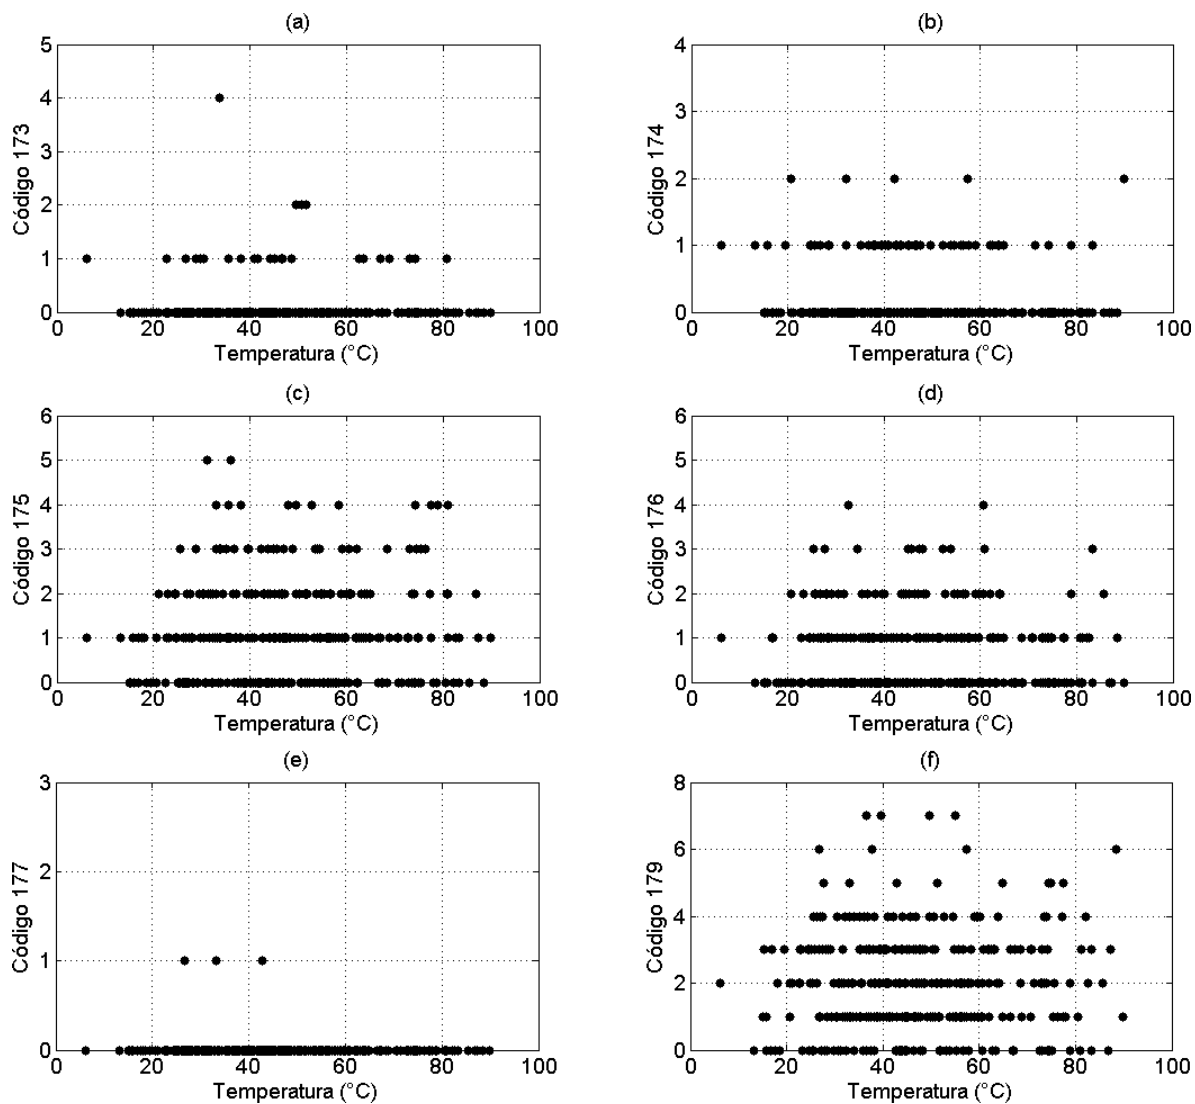


Figura B.39: Dispersão das classes da CID-10 (de 173 a 179, com exceção de 178) em função da temperatura.

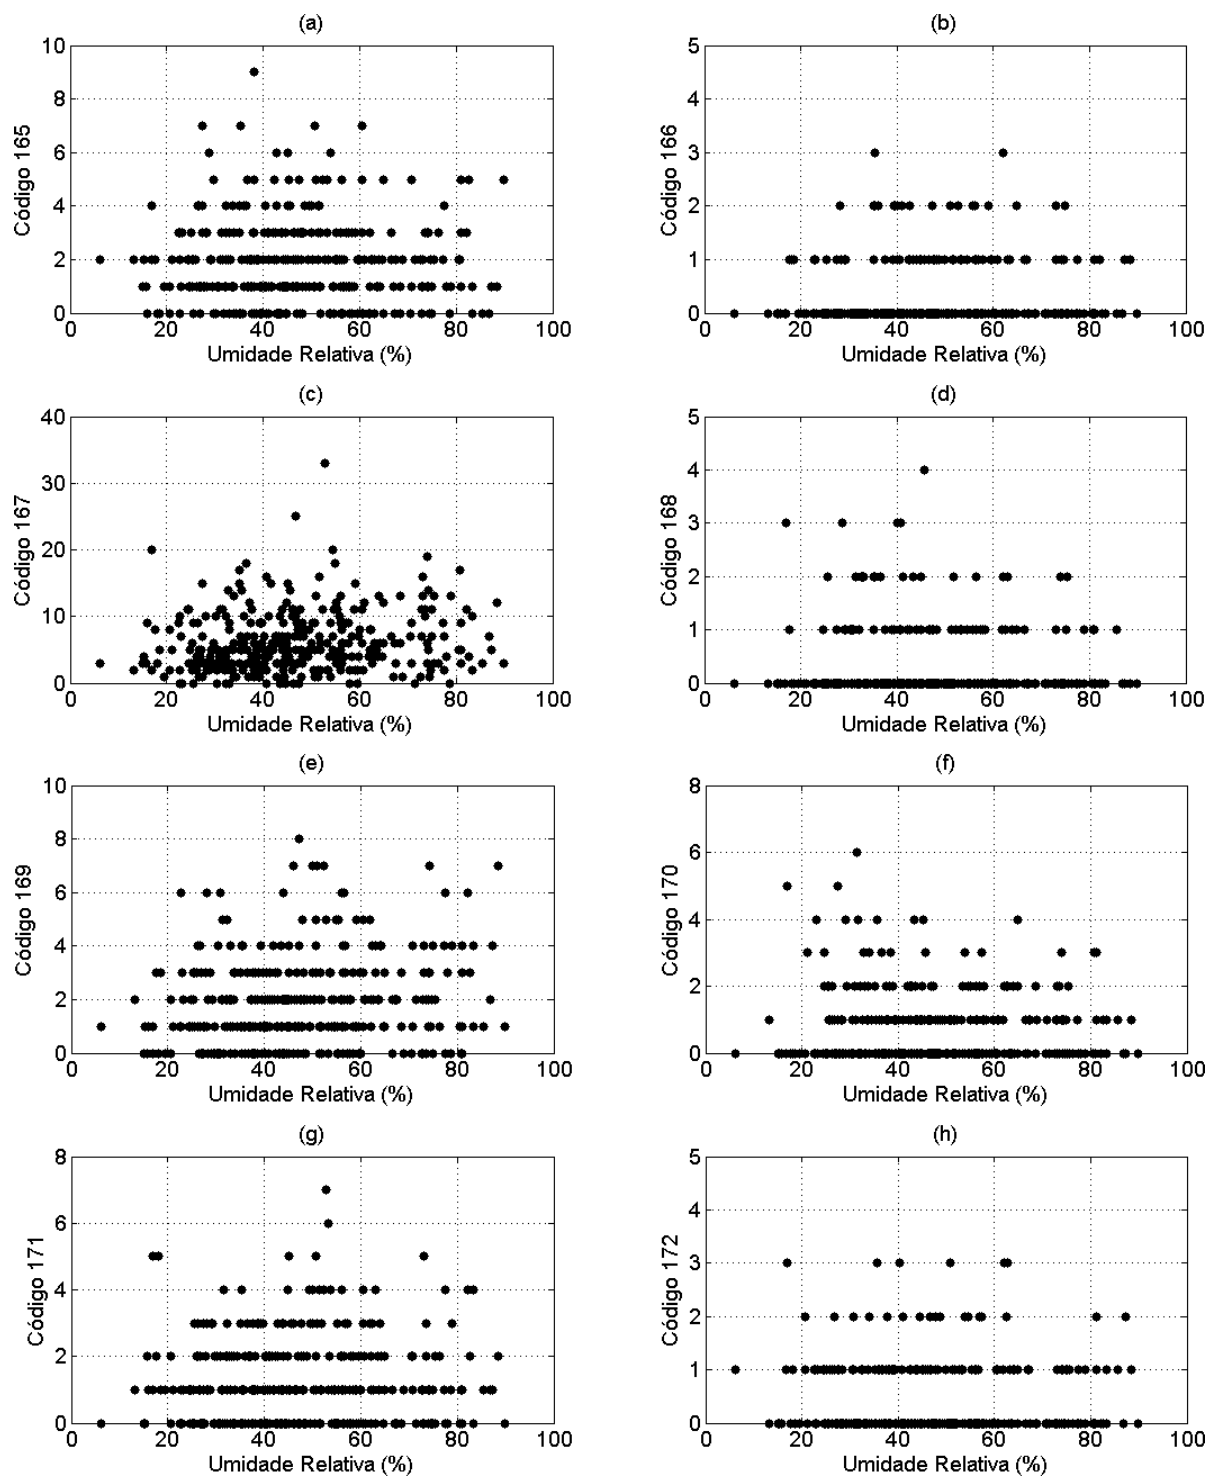


Figura B.40: Dispersão das classes da CID-10 (de 165 a 172) em função da umidade relativa.

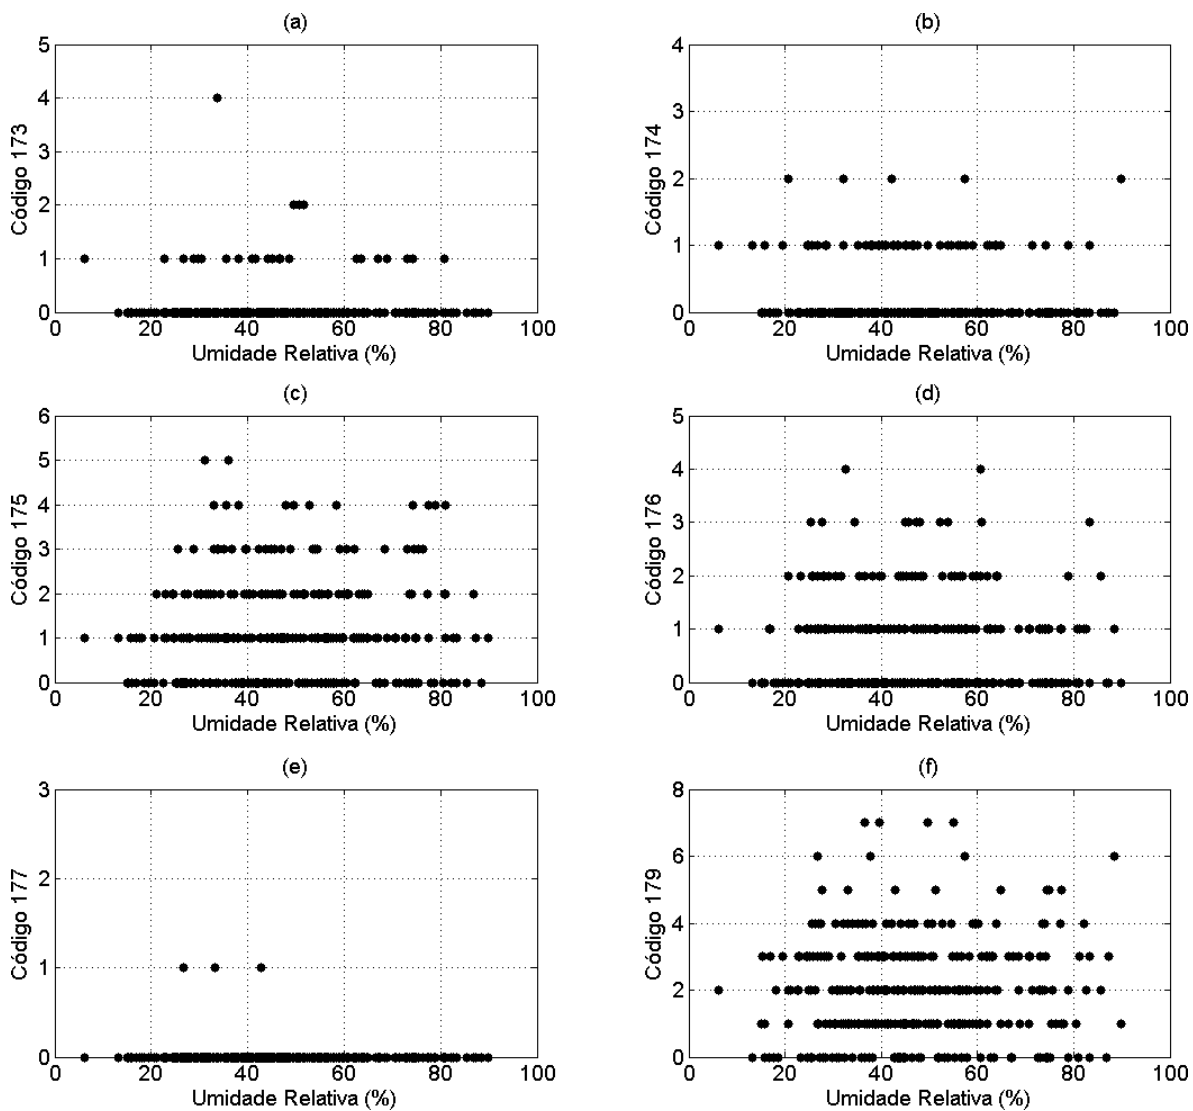


Figura B.41: Dispersão das classes da CID-10 (de 173 a 179, com exceção de 178) em função da umidade relativa.