Universidade de São Paulo
Escola de Engenharia de São Carlos
Programa de Pós-Graduação em Engenharia Hidráulica e Saneamento

Elaine Schornobay Lui

Previsão de material particulado a curto e médio prazos com o uso de redes neurais artificiais

VERSÃO CORRIGIDA

São Carlos
2016

ELAINE SCHORNOBAY LUI

Previsão de material particulado a curto e médio prazos com o uso de redes neurais artificiais

Tese apresentada à Escola de Engenharia de São Carlos, da Universidade de São Paulo, como parte dos requisitos para obtenção do título de Doutora em Ciências: Engenharia Hidráulica e Saneamento.

Orientador: Prof. Dr. Nivaldo Aparecido Corrêa

Co-orientador: Prof. Dr. Werner Siegfried Hanisch

VERSÃO CORRIGIDA

São Carlos

2016

AUTORIZO A REPRODUÇÃO TOTAL OU PARCIAL DESTE TRABALHO, POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

Schornobay Lui, Elaine
Sp Previsão de material particulado a curto e médio prazo com o uso de redes neurais artificiais / Elaine Schornobay Lui; orientador Nivaldo Aparecido Corrêa; coorientador Werner Siegfried Hanisch. São Carlos, 2016.

Tese (Doutorado) - Programa de Pós-Graduação e Área de Concentração em Hidráulica e Saneamento -- Escola de Engenharia de São Carlos da Universidade de São Paulo, 2016.

1. material particulado. 2. redes neurais. 3. variáveis climáticas. 4. poluição do ar. I. Título.

FOLHA DE JULGAMENTO

Candidata: Bacharel **ELAINE SCHORNOBAY LUI**.

Título da tese: "Previsão de material particulado a curto e médio prazo com o uso de redes neurais artificiais ".

Data da defesa: 18/11/2016.

Comissão Julgadora:	**Resultado:**
Prof. Dr. **Nivaldo Aparecido Corrêa** **(Orientador)** (Escola de Engenharia de São Carlos/EESC)	Aprovada
Profa. Dra. **Mônica Lopes Aguiar** (Universidade Federal de São Carlos/UFSCar)	Aprovado
Prof. Dr. **Waldir Nagel Schirmer** (Universidade Estadual do Centro-Oeste/UNIOESTE)	Aprovada
Profa. Dra. **Simone Andréa Pozza** (Universidade Estadual de Campinas/UNICAMP)	Aprovada
Prof. Dr. **Erich Kellner** (Universidade Federal de São Carlos/UFSCar)	APROVADO

Coordenadora do Programa de Pós-Graduação em Engenharia Hidráulica e Saneamento:
Profa. Associada **Maria Bernadete A. Varesche Silva**

Presidente da Comissão de Pós-Graduação:
Prof. Associado **Luis Fernando Costa Alberto**

Dedicatória

Ao meu Pai.

AGRADECIMENTOS

À Fundação de Amparo a Pesquisa do Estado de São Paulo (FAPESP) pelo apoio financeiro, Projeto FAPESP 14928-2.

Ao meu orientador, Prof. Nivaldo por todo apoio na realização do projeto.

Ao meu co-orientador, Prof. Werner, pela colaboração no desenvolvimento da pesquisa.

À Profª Mônica Lopes Aguiar da UFSCar, que acompanhou meu trabalho na pós-graduação desde o início do mestrado. Além de disponibilizar o equipamento AGV-MP_{10}, essencial para esta pesquisa.

À Profª Simone Andrea Pozza e todo o pessoal do grupo de poluição atmosférica da Unicamp-Limeira, pelo apoio e orientações nas coletas.

Ao Rafael Belo da Silva, que me auxiliou com a programação das redes neurais, muito obrigada!

Ao Prof. Orlando Moreira Filho, da biologia da UFSCar, que gentilmente cedeu o carro e motorista do laboratório para que o transporte do AGV-MP_{10} para manutenção fosse possível.

Ao amigo Eduardo Carlos Alexandrina, com quem dividi todo o trabalho de coleta de dados e as dúvidas e acertos da pesquisa, muito obrigada!

Aos amigos de São Carlos, do PPG-SHS-USP e PPGEQ-UFSCar, especialmente Narumi Abe, Lucas Marcon, Poty, Filipe, Carol, Andressa e Tatiane. A todos os demais amigos e colegas que fizeram parte da minha trajetória em São Carlos.

Em especial a toda a minha família, meu pai Eugênio, que nos deixou a poucos dias e a quem esse título era motivo de muito orgulho. À minha mãe Tereza, meu irmão Eliton,

meu esposo Roberto e minha filha Maria Tereza, que nas idas e vindas estiveram ao meu lado com apoio incondicional.

RESUMO

SCHORNOBAY-LUI, E. **Previsão de material particulado a curto e médio prazo com o uso de redes neurais artificiais.** 2016. 146 f. Tese (Doutorado) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2016.

A preocupação com a qualidade do ar é crescente. Nos últimos anos, as emissões industriais e veiculares acarretam em muitos casos, especialmente em áreas urbanas, condições inadequadas para a saúde da população. Diversos estudos relacionam aumento em internações hospitalares, especialmente por problemas respiratórios, durante episódios de altas concentrações de material particulado. O objetivo deste estudo foi coletar dados diários de concentração de MP_{10} e compará-los com uma série de dados de quase 10 anos de coleta disponíveis para a cidade de São Carlos-SP. Além disso, ambas as séries de dados foram utilizadas para criar modelos de previsão da concentração de material particulado utilizando como ferramenta as redes neurais artificiais. O local escolhido para aquisição dos dados foi a Praça Voluntários da Pátria, no centro de São Carlos, em função da grande circulação de pessoas e veículos. As duas séries de dados foram coletadas com um equipamento amostrador de grande volume (AGV-MP_{10}). A série 1 (1997-2006) foi obtida para caracterizar o MP de São Carlos. As coletas eram realizadas alternando-se os dias na semana. Para a série 2 (2014-2015) foram realizadas coletas diárias, com o mesmo equipamento e no mesmo local de amostragem da série 1. Para a criação dos modelos de previsão foram utilizados dados do Banco de Dados Meteorológicos para Ensino e Pesquisa (BDMEP) do Instituto Nacional de Meteorologia (INMET), de temperatura (ºC), umidade relativa (%), velocidade do vento (m/s) e o acumulado de precipitação (mm). Os modelos foram desenvolvidos no *softwareMatLab*, utilizando duas arquiteturas de redes neurais, uma do tipo MLP (*Multilayer Percetron*) e outra do tipo NARX (*nonlinear autoregressive network with exogenous inputs*). Comparando os dados de MP_{10} da série 1 e da série 2, foi observado que houve uma redução nos índices de concentração de MP_{10} ao longo do tempo. Isto se deve à implantação de leis mais rigorosas e o desenvolvimento de tecnologias menos poluentes. Em relação aos modelos de previsão, para os dados da série 1, a utilização do modelo para previsão de médias mensais de concentração de MP_{10} foi mais eficiente do que o modelo para previsão de médias diárias, ambos tiveram como neurônios de entrada apenas variáveis climáticas, compostas de médias diárias e médias mensais, respectivamente. Para a previsão da série 2, o modelo utilizando a rede neural NARX, que utilizou como neurônios de entrada as variáveis

climáticas e o MP_{10} do dia anterior, apresentou o maior erro absoluto médio (7,13), no entanto, o modelo NARX apresentou a convergência mais rápida. O menor erro absoluto (6,00) foi obtido pelo modelo em que foi utilizada a rede do tipo MLP, que apresentava como neurônios de entrada as médias diárias das variáveis climáticas e da concentração de MP_{10} do dia anterior. A rede MLP também foi utilizada para criação de um modelo em que apenas as variáveis climáticas eram utilizadas, para este modelo foi encontrado o valor de 6,52 como erro absoluto. A apresentação do dado de concentração de MP_{10} do dia anterior torna o desempenho dos modelos de previsão mais eficiente.

Palavras-chave: material particulado, variáveis climáticas, redes neurais.

ABSTRACT

SCHORNOBAY-LUI, E. **Prediction of short and medium term particulate matter with the use of artificial neural network.** 2016. 146 f. Tese (Doutorado) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2016.

Concern about air quality is growing. In recent years, industrial and vehicular emissions have in many cases, especially in urban areas, resulted in inadequate conditions for the health of the population. Several studies have reported an increase in hospital admissions, especially due to respiratory problems, during episodes of high concentrations of particulate matter. The objective of this study was to collect daily PM_{10} concentration data and compare them with a series of data of almost 10 years of collection available for the city of São Carlos-SP. In addition, both sets of data were used to create forecasting models of the concentration of particulate material using artificial neural networks as a tool. The place chosen for data collect was Praça Voluntários da Pátria, in the center of São Carlos, due to the great circulation of people and vehicles. The two data series were collected with a high volume air sampler. The series 1 (1997-2006) was obtained to characterize the PM of São Carlos. The collections were carried out alternating the days in the week. For the series 2 (2014-2015) daily collections were carried out with the same equipment and in the same sampling site of the series 1. For the creation of the forecast models we used data from the Banco de Dados Meteorológicos para Ensino e Pesquisa (BDMEP) do do Instituto Nacional de Meteorologia (INMET), de temperature (ºC), relative humidity (%), wind speed (m/s) and precipitation (mm). The models were developed in the MatLab software, using two neural network architectures, one of the MLP (Multilayer Percetron) type and another of the NARX (nonlinear autoregressive network with exogenous inputs) type. Comparing PM_{10} data from series 1 and series 2, it was observed that there was a reduction in PM_{10} concentration indices over time. This is due to the implementation of stricter laws and the development of cleaner technologies. In relation to the prediction models, for the data of the series 1, the use of the model to predict monthly means of concentration of PM_{10} was more efficient than the model for prediction of daily means, both had as input neurons only climatic variables, daily averages and monthly averages, respectively. For the prediction of series 2, the model using the NARX neural network, which used as input neurons the climatic variables and PM_{10} of the previous day, presented the highest mean absolute error (7,13), however, the NARX model presented the better convergence. The lowest absolute error (6.00) was obtained by the model in which the

MLP type network was used, which presented as input neurons the daily averages of the climatic variables and PM_{10} concentration of the previous day. The MLP network was also used to create a model in which only the climatic variables were used, for this model was found the value of 6.52 as absolute error. Presenting an PM_{10} concentration data from the previous day improves the performance of forecast models.

Palavras-chave: particulate matter, climatic variables, neural network.

LISTA DE FIGURAS

Figura 1: Concentrações médias mensais de MP_{10} na cidade de São Carlos. 34
Figura 2: AGV-MP_{10} instalado na Praça Voluntários da Pátria no centro da cidade de São Carlos, SP. 43
Figura 3: Esquema do funcionamento do equipamento AGV-MP_{10}. 44
Figura 4: Esquema da rede neural MLP para previsão do MP_{10} diário da série 1. 48
Figura 5: Esquema da rede neural MLP para previsão do MP_{10} mensal da série 1. 49
Figura 6: Esquema da rede neural MLP-1 para previsão do MP_{10} diário da série 2. 49
Figura 7: Esquema da rede neural MLP-2 para previsão do MP_{10} mensal da série 2 com entrada de MP. 50
Figura 8: Desenho esquemático da rede MLP utilizada para previsão da concentração diária de MP_{10} da série 2. 50
Figura 9: *Tollbox* do *MatLab* utilizada para previsão do MP_{10} da série 2 com a rede neural do tipo NARX. 52
Figura 10: *Tollbox* do *MatLab* utilizada para previsão do MP_{10} da série 2 com a rede neural do tipo NARX, número de neurônios e atrasadores. 53
Figura 11: Diagrama fornecido pelo *MatLab* da rede neural NARX para previsão do MP_{10} da série 2. 53
Figura 12: Gráfico em *boxplot* da concentração de MP_{10} por dia da semana da série 1. 56
Figura 13: Concentrações de MP_{10} obtidas entre 16/04/2014 e 21/04/2015. 58
Figura 14: Gráfico em *boxplot* mensal da série 2. 60
Figura 15: Médias mensais da concentração de MP_{10} para o mês de Janeiro. 62
Figura 16: Médias mensais da concentração de MP_{10} para o mês de Fevereiro. 62
Figura 17: Médias mensais da concentração de MP_{10} para o mês de Março. 62
Figura 18: Médias mensais da concentração de MP_{10} para o mês de Abril. 63
Figura 19: Médias mensais da concentração de MP_{10} para o mês de Maio. 63
Figura 20: Médias mensais da concentração de MP_{10} para o mês de Junho. 63
Figura 21: Médias mensais da concentração de MP_{10} para o mês de Julho. 64
Figura 22: Médias mensais da concentração de MP_{10} para o mês de Agosto. 64
Figura 23: Médias mensais da concentração de MP_{10} para o mês de Setembro. 64
Figura 24: Médias mensais da concentração de MP_{10} para o mês de Outubro. 65

Figura 25: Médias mensais da concentração de MP_{10} para o mês de Novembro. 65
Figura 26: Médias mensais da concentração de MP_{10} para o mês de Dezembro. 65
Figura 27: Comparação entre os valores medidos e previstos de MP_{10} pela rede MLP-diária para a série 1. 68
Figura 28: Comparação entre os valores medidos e previstos da concentração de MP_{10} obtidos pela rede MLP-mensal para a série 1. 69
Figura 29: Gráficos de regressão das fases de treinamento (a), validação (b), teste (c) e de todos os dados (d) da rede MLP-diária do MP_{10} da série 1. 70
Figura 30: Gráficos de regressão das fases de treinamento (a), validação (b), teste (c) e de todos os dados (d) da rede MLP-mensal do MP_{10} da série 1. 70
Figura 31: Gráfico do desempenho da rede neural MLP-diária para previsão da concentração de MP_{10} da série 1. 71
Figura 32: Gráfico do desempenho da rede neural MLP-mensal para previsão da concentração de MP_{10} da série 1. 72
Figura 33: Comparação entre os valores medidos e previstos de MP_{10} pela rede MLP-1 para a série 2. 74
Figura 34: Comparação entre os valores medidos e previstos de MP_{10} pela rede MLP-2 para a série 2. 75
Figura 35: Gráficos das respostas da rede NARX de previsão do MP_{10} da série 2. 76
Figura 36: Gráficos de regressão das fases de treinamento (a), validação (b), teste (c) e de todos os dados (d) da rede MLP-1 de previsão do MP_{10} da série 2. 77
Figura 37: Gráficos de regressão das fases de treinamento (a), validação (b), teste (c) e de todos os dados (d) da rede MLP-2 de previsão do MP_{10} da série 2. 78
Figura 38: Gráficos de regressão das fases de treinamento (a), validação (b), teste (c) e de todos os dados (d) da rede NARX para previsão do MP_{10} da série 2. 78
Figura 39: Gráfico do desempenho da etapa de validação da rede MLP-1 para previsão da concentração de MP_{10} da série 2. 79
Figura 40: Gráfico do desempenho da etapa de validação da rede MLP-2 para previsão da concentração de MP_{10} da série 2. 80
Figura 41: Gráfico do desempenho da rede neural do tipo NARX para previsão da concentração de MP_{10} da série 2. 81

LISTA DE TABELAS

Tabela 1: Resumo dos modelos de previsão da concentração de MP_{10}. 47

Tabela 2: Número de amostragens por dia da semana da série 1. 55

Tabela 3: Valores comparativos de erro médio absoluto entre MLP-mensal e MLP-diária usando a série 1. 66

Tabela 4: Valores comparativos de erro absoluto dos modelos de previsão da série 2 de dados. 81

LISTA DE SIGLAS

ABNT	Associação brasileira de normas técnicas
AGV-MP_{10}	Amostrador de grandes volumes para MP_{10}
ARIMA	*Autoregressive integrated moving average*
BDMEP	Banco de dados meteorológicos para ensino e pesquisa
CETESB	Companhia ambiental do Estado de São Paulo
CMAQ	Community modeling and analysis system
CONAMA	Conselho Nacional do Meio Ambiente
FAPESP	Fundação de apoio a pesquisa do Estado de São Paulo
INMET	Instituto Nacional de Meteorologia
MLP	Multi-layer perceptron
MP	Material particulado
$MP_{2,5}$	Material particulado com diâmetro aerodinâmico inferior a 2,5 μ
MP_{10}	Material particulado com diâmetro aerodinâmico inferior a 10 μ
MLR	*Multiple Linear Regression*
NARX	*Nonlinear autoregressive network with exogenous inputs*
NBR	Norma brasileira
OMS	Organização mundial da saúde
PPGEQ	Programa de Pós-graduação em Engenharia Química
PROCONVE	Programa de controle da poluição do ar por veículos automotores
SARIMA	Variável sazonal do ARIMA
RNA	Rede neural artificial
UFSCar	Universidade Federal de São Carlos
US-EPA	*United States Environmental Protection Agency*

Sumário

1. INTRODUÇÃO 23
2. OBJETIVOS 27
   2.1. Objetivos específicos 27
3. REVISÃO BIBLIOGRÁFICA 29
   3.1 Estudos de MP na cidade de São Carlos 32
   3.2 Modelagem matemática de séries históricas de material particulado 35
   3.3 Modelagem com redes neurais 37
4. MATERIAIS E MÉTODOS 41
   4.1 Materiais 41
   4.2 Metodologia 41
   4.2.1 Manutenção do equipamento AGV-MP_{10} e adequação do local de coleta. 42
   4.2.2 Operação e coleta dos dados 43
      4.2.2.1 Coleta de dados da série 2 43
      4.2.2.2 Dados de variáveis climáticas 46
   4.2.3 Modelos de previsão 46
5. RESULTADOS E DISCUSSÃO 55
   5.1 Análise da coleta de dados de material particulado da Praça Voluntários da Pátria em São Carlos, SP. 55
   5.2 Discussões dos modelos de previsão por redes neurais artificiais 66
      5.2.1 Modelo de redes neurais para a série 1 de dados para previsão diária e mensal de MP_{10} 66
      5.2.2 Modelo de redes neurais para a série 2 de dados para previsão diária e mensal de MP_{10} 73
6. CONCLUSÃO 85
7. SUGESTÕES PARA TRABALHOS FUTUROS 87
8. REFERÊNCIAS BIBLIOGRÁFICAS 89

APÊNDICE A – Cálculo de concentração (correção vazão) 97
APÊNDICE B – Calibração do equipamento AGV-MP_{10} 99
APÊNDICE C – Rede Neural MLP 103
APÊNDICE D – Rede Neural NARX 107
APÊNDICEE – Dados série 1 111
APÊNDICE F – Dados série 2 133
APÊNDICE G – Médias Mensais 145

1. INTRODUÇÃO

O crescimento das aglomerações urbanas nas últimas décadas tem criado condições adversas à qualidade de vida nas áreas urbanas. Um dos sistemas que mais tem sofrido com essa degradação é o ar. Os avanços industriais e o aumento exorbitante da frota veicular são os principais fatores responsáveis pela má qualidade do ar nos centros urbanos (BASCOM, 1996).

A diminuição da qualidade do ar causa danos aos materiais, à fauna, flora, condições de visibilidade e também agride de muitas maneiras à saúde da população. É sabido, de algum tempo, a relação existente entre o aumento dos casos de internação e mesmo mortes por complicações cardiorrespiratórias nos episódios em que há o aumento da concentração dos poluentes. Além disso, as partículas e gases são constituídos de componentes químicos que podem ser tóxicos à saúde e ter potencial cancerígeno (MARTINS, DIAS E GONÇALVES, 2009).

Têm-se dados especial atenção às partículas finas, com menos de 10 μm de diâmetro, que por possuírem menores dimensões atingem o trato respiratório, e as partículas menores que 2,5 μm que podem chegar até os alvéolos pulmonares. Como agravante, diferentemente das partículas maiores que logo se depositam no solo com a ação da gravidade, estas podem permanecer suspensas por um tempo muito maior e viajar dezenas de quilômetros (MARQUES, 2000).

A quantificação dos poluentes pode ser realizada de duas maneiras, realizando-se amostragens diretamente na fonte ou nos chamados receptores. Quando a quantificação é realizada nos receptores, é interessante porque se está avaliando a soma de todas as fontes após dispersão e reações químicas, tendo-se dessa forma uma ideia melhor da exposição.

No entanto, essa forma de avaliação é onerosa e tem um custo muito alto. Por conta disso, há algum tempo já se tem utilizado modelos matemáticos com o intuito de fazer previsões dessas concentrações. Além da diminuição do custo com coletas e análise química do material, com a utilização da modelagem é possível à criação de cenários, sendo uma ferramenta muito valiosa para programas de gestão (PEREZ E REYS, 2006).

Uma das mais recentes ferramentas para previsão da concentração de poluentes são as redes neurais artificiais (RNA). Diferentemente dos modelos convencionais utilizados para previsão, que necessitam do entendimento e da disponibilidade de vários parâmetros, as redes neurais artificiais são baseadas no entendimento da relação entre as variáveis de entrada e as variáveis de saída do modelo. Assim, a modelagem das RNAs se dá por meio de exemplos e treinamento supervisionado, sem a necessidade de conhecer complexos processos físicos que atuam na dispersão dos poluentes. Estas características das redes neurais as tornam uma poderosa ferramenta, mas também pode levar a falsos resultados. Outra desvantagem é que os modelos quase sempre são feitos em locais com grande poluição como em cidades do Chile, Europa e Ásia. A eficiência das redes neurais para previsão em cidades com concentrações baixas de material particulado ainda deve ser verificada.

Os trabalhos que utilizam redes neurais para previsão de MP existentes exigem que se conheça previamente a quantidade de material particulado no mês ou do dia anterior ao que se deseja prever. Porém, por meio de observações recentes é possível verificar que o material particulado segue padrões temporais que podem ser determinísticos, pois são altamente dependentes das variáveis climáticas, geradas tanto por fenômenos físicos quanto comportamentais. Outra observação importante, retirada da literatura, é o crescimento ou diminuição do MP ao longo do tempo, por causa do

crescimento urbano e rural e devido a novas leis ambientais, como o que regula a queima da cana-de-açúcar, por exemplo, e o PROCONVE (Programa de controle da poluição do ar por veículos automotores) (SANTOS, CARVALHO e REBOITA, 2016; PROCONVE, 1986; Decreto Estadual 59119 de 23/04/2013). O conhecimento dessas informações é relevante para o treinamento das redes neurais e ainda não são utilizadas de maneira eficiente nos trabalhos atuais. Apesar do proposto neste trabalho ser realizar coletas contínuas, é sabido que um ano é um tempo curto de amostragem, visto que esse período pode ser atípico, mais seco ou mais úmido que o comum. Espera-se que as RNAs possam reconhecer padrões sazonais ao longo de um ano, e também tendências de crescimento ou diminuição do material particulado ao longo dos anos. A quantidade de lançamento pelas fontes emissoras é mais influenciada por razões sazonais do que devido a variações econômicas, e após o aumento ou diminuição em determinado momento, tendem a permanecer do mesmo modo a partir daquele instante, como, por exemplo, após a abertura ou fechamento de uma nova fábrica. A criação de um modelo de previsão que não depende de uma entrada de material particulado se justifica porque será possível conhecer melhor os processos envolvidos na dispersão de material particulado (SINGH *et al.*, 2012).

Este trabalho teve como objetivo ampliar o histórico de dados de material particulado para a cidade de São Carlos, SP. Para isso, foram realizadas coletas diárias de material particulado (MP_{10}), diariamente, pelo período de um ano (2014-2015). Os dados de MP_{10} foram utilizados em modelos de previsão com redes neurais artificiais.

2. OBJETIVOS

Os objetivos deste estudo foram avaliar as características do material particulado (MP_{10}) da cidade de São Carlos–SP e criar modelos de previsão da concentração de MP_{10} utilizando como ferramenta as redes neurais artificiais. Foram realizadas coletas diárias durante os anos de 2014 e 2015 com a finalidade de comparar com dados históricos disponíveis de dez anos de estudo do MP na cidade (1997-2006).

2.1. Objetivos específicos

- Avaliar a evolução da concentração de MP_{10} comparando as duas séries de dados históricos.
- Criar modelos de previsão da concentração de MP_{10}.
- Comparar a eficiência de cinco modelos de previsão para o MP_{10}.
- Verificar o desempenho dos modelos de previsão utilizando o dado de concentração de MP_{10} do dia anterior como um neurônio de entrada.

3. REVISÃO BIBLIOGRÁFICA

O crescimento da população urbana e dos níveis de industrialização tem ocasionado aumento nas emissões atmosféricas. Por conta disso, a concentração de gases e partículas poluentes excede as concentrações naturalmente encontradas na atmosfera. A emissão, seja por fontes fixas, móveis e ou geradas por meio de reações químicas, tem tornado a atmosfera urbana inadequada à saúde humana. Segundo Saldiva *et al.* (1992), o material particulado inalável encontrado nessa atmosfera, juntamente com os gases poluentes presentes, são tóxicos à saúde e tem potencial cancerígeno. As partículas mais finas podem ultrapassar as defesas respiratórias causando respostas inflamatórias. Se existir um revestimento químico da partícula com nitratos, sulfatos ou metais, pode ocorrer um dano oxidativo local e ou um dano carcinogênico (BASCOM, 1996). Além disso, os estudos mostram que esses materiais particulados influenciam no meio ambiente. Os aerossóis interferem nas propriedades radioativas da atmosfera, podendo alterar as condições climáticas locais porque atuam como núcleos de condensação (SEINFELD, 1998).

O material particulado que apresenta os maiores efeitos à saúde humana são as partículas menores que 10 μm de diâmetro. O conhecimento do diâmetro da partícula tem importância, pois pode ser usado como indicador da fonte emissora. Sabe-se também, que a deposição no trato respiratório é dependente do tamanho da partícula (MARQUES, 2000). As partículas de maiores dimensões são menos prejudiciais à saúde, sendo retidas nas vias aéreas superiores e também se depositam no solo em poucas horas, em função da ação da gravidade. O mesmo não ocorre com as partículas de menores dimensões, que são pequenas o suficiente para permanecerem em suspensão na atmosfera, movendo-se juntamente com o gás e, na prática, não se depositam no solo, permanecendo na atmosfera por horas ou até dias, podendo viajar por distâncias

consideráveis a partir da fonte (SEINFELD, 1998). Wang *et al.* (2013) coletaram amostras de material particulado (MP_{10}) em 113 cidades da China, cruzando com dados de mortalidade específica da população. Como resultado, foi encontrada uma melhoria na expectativa de vida, pois a mortalidade associada ao material particulado caiu de 2,13 anos em 2003 para 1,3 anos em 2010, sendo que as concentrações passaram de 125,3 µg/m³ para 88,3 µg/m³, para os mesmos períodos.

Em 1997 a US-EPA (United States Environmental ProtectionAgency), baseada em evidências de que as partículas com menores diâmetros aerodinâmicos são mais patogênicas, propôs a inclusão de um novo padrão de qualidade do ar, separando o MP_{10} em duas frações:

- $MP_{2,5}$: partículas com diâmetro aerodinâmico menor que 2,5 µm (partículas superfinas)
- MP_{10}: partículas com diâmetro aerodinâmico menor que 10 µm (partículas finas).

No Brasil, somente em 2013 a CETESB (Companhia Ambiental do Estado de São Paulo) criou padrão para o $MP_{2,5}$, por meio do Decreto Estadual 59119 de 23/04/2013 (SÃO PAULO, 2013), estabelecendo o limite de 60 µg/m³ e objetivando ao final de três estágios atingir o mesmo padrão proposto pela OMS (Organização Mundial da Saúde), de 25 µg/m³ para a média de 24 h. A legislação federal em vigor é a Resolução CONAMA 03/1990, que estabelece como limite de concentração de MP_{10}, para média de 24 horas, 150 µg/m³. Não há padrão federal para o $MP_{2,5}$.

Os níveis de poluição em áreas rurais e urbanas diferem em consequência de diferentes fontes e densidades de emissões. A fim de desenvolver estratégias de mitigação de material particulado é necessário determinar sua origem e de seus componentes, bem como a redução das emissões em áreas urbanas (MUES *et al.*, 2013).

Centros urbanos geralmente reúnem uma grande frota veicular, além de atividades industriais, o que torna a poluição antropogênica significativamente maior do que a natural nestes locais (WATSON e CHOW, 2001). Os veículos apresentam participação significativa na emissão particulada, sendo responsáveis por emissões de metais agregados ao material particulado, além de gases como CO_2, CO, SO_2 e NO_X (STERNBECK, SJODIN E ANDRÉASSON, 2002). Pikridas*et al.* (2013) em trabalho realizado em Patras, na Grécia, estimou que a emissão veicular correspondeu a 12% do MP_{10} nesse local. Castanho e Artaxo (2001) identificaram como principais fontes de $MP_{2,5}$ atmosférico na região metropolitana de São Paulo: veículos, ressuspensão de partículas do solo, combustão e óleo combustível, além de sulfatos e emissões industriais.

CETESB (2000) identificou em Araraquara-SP como maiores fontes de aerossol: tráfego de veículos, emissões industriais e componentes típicos de queimadas. No mesmo local, foi observado que o $MP_{2,5}$ representa 45% da massa do MP_{10}. Este dado inspira cuidados com a qualidade do ar em cidades de médio porte do interior paulista, pois praticamente metade do material particulado respirável pertence à fração fina e, portanto, a mais patogênica do MP. No mesmo relatório, foi constatado que em Campinas-SP as partículas inaláveis finas representam 60% das partículas respiráveis, indicando que em locais nos quais as fontes veiculares são preponderantes, as partículas finas são responsáveis por grande parte do MP respirável. O relatório de avaliação da qualidade do ar da CETESB do ano de 2014 reforça os dados dos anos anteriores. Na região metropolitana de São Paulo, a relação $MP_{10}/MP_{2,5}$ é de 0,6. Nas estações que monitoram as cidades de São José do Rio Preto, Piracicaba e Santos a relação $MP_{10}/MP_{2,5}$ é 0,4, mostrando nessas cidades condições locais diferentes das encontradas na região metropolitana. O mesmo relatório afirma que em estudos realizados pela

CETESB, a maior parte das partículas inaláveis finas ($MP_{2,5}$) da região metropolitana de São Paulo tem origem veicular. No entanto, a emissão de material particulado de fontes veiculares no estado de São Paulo apresentou uma redução de 8400 toneladas no ano de 2006 para 4800 no ano de 2014. Essa diminuição é decorrente das novas tecnologias e leis mais rigorosas para fabricação de veículos com índices menores de poluição atmosférica.

3.1 Estudos de MP na cidade de São Carlos

O Programa de Pós-Graduação de Engenharia Química da Universidade Federal de São Carlos (UFSCar) possui um grupo de pesquisa na área de Controle Ambiental, que há vários anos tem estudado o material particulado no município de São Carlos. Durante os primeiros estudos, foram definidos 5 pontos de amostragem para coleta de material particulado. Posteriormente, estes pontos foram reduzidos para apenas um ponto de monitoramento localizado no centro da cidade. Este ponto foi considerado de interesse, porque é onde havia a maior densidade de pessoas, grande fluxo de veículos e média semelhante aos outros pontos monitorados (CELLI, 1999).

Entre setembro de 1997 e setembro de 1998 foi constatado que os valores encontrados para o MP_{10} não ultrapassavam os valores estabelecidos na legislação ambiental brasileira RESOLUÇÃO CONAMA 03/1990 (média anual: 50 μg/m³, média diária: 150 μg/m³), excetuando os meses de Julho e Agosto, coincidindo com o período da queima da cana-de-açúcar na região. Durante o monitoramento, verificou-se que existe uma tendência periódica na concentração do MP, apresentando médias menores no verão, maiores no inverno e médias semelhantes durante as outras estações. Bruno (2005) analisou as concentrações de material particulado respirável (MP_{10}) e suas frações fina ($MP_{2,5-10}$) e super fina ($MP_{2,5}$) com as amostragens realizadas entre 1997 e

2004. O ano foi dividido em duas estações: seca (abril a outubro) e a chuvosa (novembro a março). A estação chuvosa coincide com o verão, nessa época ocorre à lavagem dos poluentes pela chuva e as temperaturas são mais elevadas, propiciando uma maior dispersão dos poluentes pela chuva e as temperaturas são mais elevadas, propiciando uma maior dispersão dos poluentes, pois as altas temperaturas na superfície favorecem o não aparecimento da inversão térmica. A Figura 1 apresenta as médias mensais de concentração de MP_{10} no período de setembro de 1997 a junho de 2004. É possível verificar que os valores apresentam concentração maior no inverno e menor no verão, entretanto o estudo não levou em consideração a sinergia entre as diversas variáveis climáticas. Segundo Bruno (2005), além do clima influenciar diretamente na dispersão do MP, também possui fator determinante no comportamento das atividades antropogênicas, como queimadas, por exemplo. Além da influência do clima na variação da concentração do MP, sabe-se que existe um aumento ocasionado por causa do crescimento urbano e rural. Marques (2000) verificou um grande crescimento no MP_{10} durante o período de 1997 a junho de 2000, embora a média encontrada não tenha atingido os limites da legislação. O aumento foi atribuído à elevação nos níveis de emissão de CO_2, no entanto, não foi verificada a origem do CO_2.

Pozza (2005) realizou um estudo para identificação das fontes de material particulado da cidade de São Carlos. Foram realizadas análises para determinar fontes consideradas as mais características para a região. Trabalhos anteriores como Marques (2000) e Pozza *et al.* (2004), indicaram as seguintes fontes: solo, emissão veicular, ressuspensão do solo pela ação veicular e queimadas, que foram confirmados no trabalho de Pozza (2005).

Figura 1: Concentrações médias mensais de MP_{10} na cidade de São Carlos.

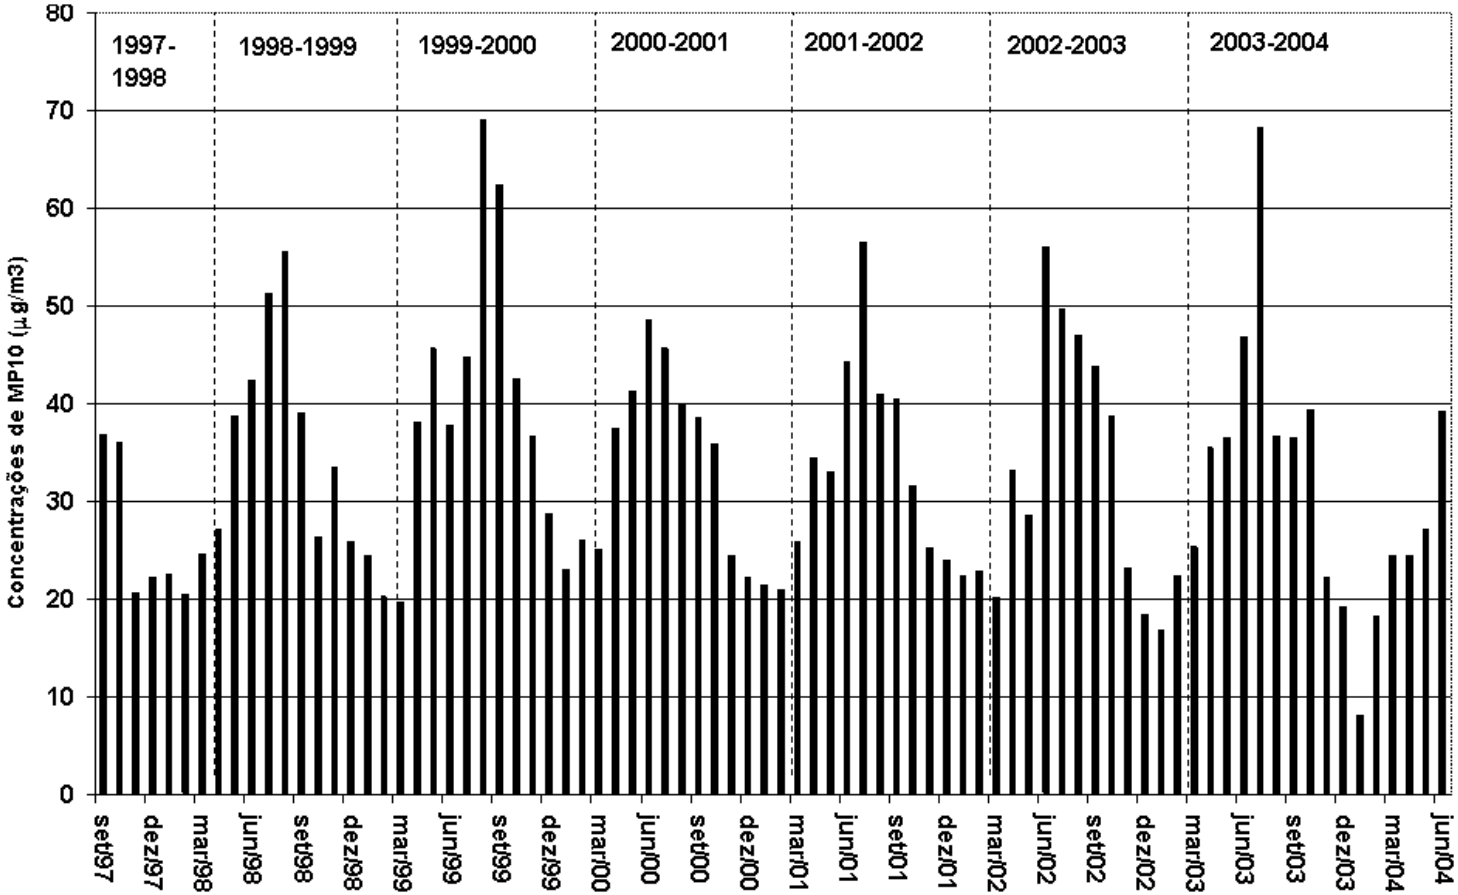

(Fonte: BRUNO, 2005)

Pozza (2009) estudou as características temporais de material particulado (MP) respirável suspensos na atmosfera de São Carlos (MP_{10}, $MP_{2,5-10}$ e $MP_{2,5}$) por meio da modelagem estatística. Foram utilizados modelos de séries médias móveis integradas autoregressivas (ARIMA) e sua variante sazonal (SARIMA) sobre os dados coletados por estudos da concentração de material particulado, no período compreendido entre 1997-2006. Os modelos SARIMA e Holt-Winters utilizados nos três conjuntos de dados mostraram-se praticáveis e reproduziram satisfatoriamente o histórico das concentrações de MP nos períodos investigados. No entanto, o modelo SARIMA apresentou melhores resultados, mesmo com os erros obtidos para validação dos modelos, todos apresentaram valores menores do que os obtidos com Holt-Winters.

3.2 Modelagem matemática de séries históricas de material particulado

Nos últimos anos, modelos de previsão de material particulado têm sido propostos como uma ferramenta de ajuda para a gestão da qualidade do ar em diversas cidades em todo o mundo (PEREZ e REYS, 2006). Muitos modelos determinísticos existem para avaliar e predizer a dispersão de poluentes em áreas urbanas, mas a maioria deles é de natureza causal e, portanto, falham para predizer concentrações extremas (JAKEMAN, SIMPSON e TAYLOR, 1998). Como resultado, esses modelos não são adequados para planejamentos e regulagens. Os modelos estatísticos, que são não-causais e baseados na captura de dados históricos, na tendência estatística dos poluentes e na retrospectiva da concentração dos poluentes não parecem a dos modelos determinísticos. Assim, eles predizem concentrações extremas com uma razoável exatidão (ZENNETTI, 1990). Além disso, os modelos de dispersão exigem detalhes de informação sobre as fontes de poluição e as condições meteorológicas, que na maioria das vezes não são obtidos

(COLLETT e ODUYEMI, 1997). Muitos deles têm de ser assumidos ou simplesmente ignorados devido à dificuldade de disponibilidade.

Para superar essas dificuldades, modelos estatísticos foram utilizados para facilitar a predição da concentração de poluentes (POLYDORAS, ANAGNOSTOPOULOS E BERGELES, 1998; ZIOMAS *et al.*, 1995; FINZI e TEBALDI, 1982; COMRIE, 1997). Médias móveis integradas autoregressivas (ARIMA), séries temporais Box-Jenkis e modelos de regressão multilinear (MLR) foram largamente utilizados para predição da qualidade do ar em áreas urbanas, mas elas apresentavam uma exatidão variável por causa da representação linear de sistemas não lineares. Quando a combinação dos modelos ARIMA e MLR foi utilizada, apresentaram resultados melhores na predição da concentração de MP_{10} do que os modelos usados independentemente. (GOYAL, CHAN e JAISWAL, 2006).

Perez, Trier e Reyes (2000) implementaram redes neurais artificiais, modelos lineares e modelos de persistência com a finalidade de fazer previsões horárias de valores de $MP_{2,5}$ para o próximo dia em Santiago, Chile. Ordieres*et al.* (2005) utilizaram três tipologias de redes neurais, comparando-as com dois modelos, um linear e um modelo de persistência com o objetivo de prever as médias diárias de $MP_{2,5}$ em El Paso (USA) e Ciudade Juarez (Méico). Uma rede neural e um modelo linear foram projetados a fim de prever a média móvel de 24 h de MP_{10} em Santiago, os modelos foram baseados nas concentrações medidas para uma estação de monitoramento de MP_{10} e em dados observados e preditos para as variáveis meteorológicas (PEREZ e REYES, 2002). O desempenho de modelos de regressão múltipla linear e redes neurais para previsão da média diária de MP_{10} em Atenas foi analisada por (CHALOULAKOU *et al.*, 20015). Muitos modelos de redes neurais e modelos lineares foram usados em Helsinski a fim de prever a média de 1h de MP_{10} (KUKKONEN *et al.*, 2003). O

perceptron de multicamadas usando um novo algoritmo de treinamento foi utilizado a fim de prever a média móvel de 24 h de MP_{10} em Shangai e outras cidades na China (JIANG *et al.*, 2004). Corani (2005) comparou o desempenho de várias redes neurais e modelos lineares localmente treinados para previsão da média diária de MP_{10} em Milão.

Perez e Reys (2006) desenvolveram um modelo integrado de redes neurais artificiais para previsão da média máxima de 24 h da concentração de MP_{10} do dia seguinte e compararam os resultados com um modelo de regressão linear. Os resultados, da maioria desses estudos, mostraram que os modelos construídos com redes neurais são mais eficientes do que os modelos lineares para previsão da concentração de material particulado. Eles mostraram também a importância da escolha das variáveis de entrada, em geral, os dados de entrada são valores de concentração de material particulado medidos em estações e variáveis meteorológicas locais de relevância (PEREZ e REYS, 2006).

É suposto que a modelagem para previsão da concentração de MP pode ser mais difícil do que a previsão de poluentes de gases comuns por causa da complexidade dos processos, que controlam a formação, transporte e remoção do aerossol da atmosfera. Por causa disso, para as redes neurais artificiais é esperado que produzam bons resultados de predição, dado sua capacidade para capturar características não lineares (GRIVAS e CHALOULAKOU, 2006).

3.3 Modelagem com redes neurais

Redes neurais artificiais têm demonstrado ser eficientes em propósitos gerais como aproximação para padrões de reconhecimento, classificação, agrupamento e predição. Pesquisadores têm aplicado métodos de RNA para uma ampla variedade de campos (RUMELHART, HINTONT e WILLIAMS, 1986).

Uma das maiores áreas de aplicações das redes neurais é a previsão (SHARDA, 1994). Muitas características distintas fazem das redes neurais artificiais valiosas e atrativas para a tarefa de previsão. Ao contrário dos métodos baseados em modelos tradicionais, as RNAs são métodos auto-adaptativos, seu aprendizado ocorre por exemplos e captura sutil das relações funcionais entre os dados, mesmo os que não são claramente entendidos ou ocultos. Assim, as RNAs são adequadas para problemas em que as soluções requerem um conhecimento que é difícil especificar, mas que há dados ou observações suficientes (ZHANG *et al.*, 1998).

As redes neurais podem generalizar, depois de aprenderem com os dados apresentados para elas. As RNAs podem inferir corretamente partes invisíveis da população mesmo se os dados contiverem ruído de informação. Como a predição do futuro é realizada (com partes invisíveis) para o exemplo do comportamento passado, a previsão é uma área de aplicação ideal para as RNAs (ZHANG *et al.*, 1998). Além disso, as RNAs são aproximações funcionais universais. Tem sido mostrado que as redes podem aproximar qualquer função contínua de qualquer exatidão desejada (MAXWELL e WHITE, 1989, HORNIK, 1991; HORNIK, 1993). As RNAs têm formas mais gerais e flexíveis do que os métodos estatísticos tradicionais podem efetivamente lidar. Qualquer modelo tradicional assume que não existe qualquer relação básica entre as entradas (os valores passados da série temporal e outras variáveis relevantes) e as saídas (os valores futuros). Frequentemente, os modelos de previsão estatísticos tradicionais têm limitações em estimar esta função (básica, oculta) em função da complexidade do sistema real. As RNAs podem ser boas alternativas para identificar estas funções.

Finalmente, as RNAs são não lineares. Previsões têm sido de longa data dominadas por estatísticas lineares. As aproximações tradicionais da previsão de séries

temporais como Box-Jenkis ou método ARIMA, assumem que as séries temporais em estudo são generalizadas para processos lineares. Modelos lineares têm as vantagens de que eles podem ser entendidos e analisados com bons detalhes, e são fáceis de serem explicados e implementados. No entanto, eles podem ser totalmente inapropriados para mecanismos básicos não lineares. De fato, no mundo real os sistemas são frequentemente não lineares. Na última década alguns modelos não lineares foram desenvolvidos, no entanto, esses modelos apresentam ainda uma limitação explícita na relação da série temporal com hipóteses sem conhecimento das leis (básicas, ocultas). De fato, a formulação de modelos não lineares para um conjunto de dados particulares é uma tarefa muito difícil desde que haja também padrões não lineares possíveis e modelos não lineares préviamente especificados que podem não ser generalizados suficientemente para a captura de todas as características importantes (ZHANG *et al.*, 1998).

Singh *et al.* (2012) concluíram em seu trabalho que o uso de RNA é uma excelente ferramenta para previsão da qualidade do ar. Nesse estudo foram desenvolvidos vários modelos baseados em aproximações lineares (mínimos quadrados parciais) e não- lineares (regressão polinomial multivariada e redes neurais artificiais) para previsão da qualidade do ar. O modelo de mínimos quadrados parciais foi o que obteve o menor desempenho, seguido pela regressão polinomial multivariada. Para a rede neural foram desenvolvidos três modelos, MLP (perceptron de multicamadas), RBF (função de base radial) e GRNN (rede neural de regressão generalizada). As três apresentaram resultados excelentes, sendo capazes de capturar o complexo de não linearidades dos dados e apresentarem excelente capacidade de generalização e previsão. No entanto, a GRNN apresentou desempenho relativamente melhor do que as outras duas. Nejadkoorki e Baroutian (2012) criaram um modelo para prever a média

diária de MP_{10} do dia seguinte. Além do modelo apresentar bons resultados outra conclusão do trabalho é que o modelo de RNA desenvolvido para cada local de monitoramento pode compensar a falta de dados em seus vizinhos.

Um modelo baseado em redes neurais foi desenvolvido para previsão da qualidade do ar em Roma, Milão e Napoli. Comparando este modelo com o que era utilizado até então, o modelo CMAQ (CommunityMulti-scale Air Quality) da USEPA, a utilização da rede neural se mostrou melhor para prever concentrações altas e moderadas. Além disso, o tempo de cálculo dos dois modelos é bem diferente, enquanto o modelo tradicional demora 5 horas, o modelo baseado na rede neural leva em torno de 10 minutos. Segundo os autores, levando em consideração o melhor desempenho e a rapidez, as redes neurais são recomendadas como competidores superiores para modelos fotoquímicos para previsões práticas de qualidade do ar (FERNANDO *et al.*, 2012). Russo, Raischel e Lind (2013) utilizaram um método para derivar variáveis estocásticas acopladas que posteriormente foram utilizadas como entrada para uma rede neural, conseguindo diminuir consideravelmente a quantidade de dados necessários para a formação dos modelos de RNA. No contexto de estudos atmosféricos, a redução da quantidade de dados de entrada otimizando a RNA sem perda da precisão, permite a evolução rápida. Assim esse estudo pode ser muito útil como primeiro passo para melhorar os sistemas de alarme, tornando-os mais eficientes na predição de períodos de níveis inferiores da qualidade do ar.

4. MATERIAIS E MÉTODOS

O desenvolvimento deste trabalho foi realizado em duas etapas. A primeira etapa consistiu na realização da coleta dos dados e a segunda etapa foi à criação dos modelos de previsão com redes neurais. O trabalho foi todo desenvolvido na cidade de São Carlos, interior do Estado de São Paulo, desde a coleta de dados até o posterior tratamento de modelagem. As etapas são descritas a seguir.

4.1 Materiais

- Amostrador de grande volume para diâmetro aerodinâmico de até 10 µm (AGV-MP_{10}) da marca *Graseby-Andersen*.
- Filtros de fibra de vidro, com dimensões de 25,4 cm x 20,32 cm, da marca Energética.
- Carta gráfica para controle da vazão, da marca Energética.
- Balança modelo AY220 da marca *Shimadzu*, com precisão de 0,01 mg.
- Calibrador padrão para AGV-MP_{10}
- *Software MatLab R2010b©*.

4.2 Metodologia

As concentrações de material particulado (MP_{10}) utilizadas contemplam duas séries de dados, que ao longo do texto foram denominadas série 1 e série 2. Ambas as coletas ocorreram na Praça Voluntária da Pátria, no centro da cidade de São Carlos, utilizando o mesmo equipamento, um Amostrador de Grande Volume (AGV-MP_{10}).

- Série 1: coletas realizadas entre os anos de 1997 e 2006. Os dados foram cedidos pelo grupo de pesquisa em Controle Ambiental do Programa de Pós-graduação em Engenharia Química da Universidade Federal de São Carlos. Foram utilizados os dados do Anexo 3 da Tese de Doutorado de Pozza (2009). A série original é

composta por 683 dados, sendo que para a previsão diária foram utilizados 582 deles. Para os dias em que havia pelo menos uma informação climática faltante e para o mês de agosto de 2011 que repetiram a mesma concentração, todos esses dados de coleta foram removidos.

- Série 2: coletas diárias realizadas entre os anos de 2014 e 2015. Os dados coletados como parte experimental deste trabalho e é composto por uma série histórica de 343 dados.

4.2.1 Manutenção do equipamento AGV-MP_{10} e adequação do local de coleta.

O equipamento AGV-MP_{10} pertence à Universidade Federal de São Carlos (UFSCar). É um equipamento de funcionamento manual e, apesar de ser importado, atualmente existe no Brasil uma empresa que fabrica e presta assistência técnica, a Energética, estabelecida na cidade do Rio de Janeiro. Antes de realizar os novos ensaios, a manutenção do equipamento teve de ser feita com recursos do fomento. O transporte oneroso do AGV-MP_{10}, devido às suas dimensões, teve de ser feito, além de se despender de tempo necessário para o conserto e testes de calibração.

Para a campanha de coleta de dados da série 2 foram utilizados o mesmo equipamento e o mesmo ponto de monitoramento dos dados da série 1. Como o ponto de coleta ficou sem utilização durante muitos anos, foi necessária a reconstrução do local para alocar o equipamento e garantir a segurança. A autorização para instalação do equipamento no centro da cidade foi concedida pelo órgão responsável da Prefeitura Municipal de São Carlos, a Secretaria de Habitação, bem como a cessão e a instalação do ponto de eletricidade. As obras para garantia da segurança foram realizadas por serviço contratado e o equipamento AGV-MP_{10} foi instalado. Os recursos necessários foram concedidos pelo Programa de Pós-Graduação em Engenharia Química da

UFSCar e pela reserva técnica da FAPESP (Projeto 2012/14928-2 – Bolsa de Doutorado). A Figura 2 apresenta o equipamento instalado no local de coleta.

Figura 2: AGV-MP_{10} instalado na Praça Voluntários da Pátria no centro da cidade de São Carlos, SP.

4.2.2 Operação e coleta dos dados

Durante a realização das coletas foram considerados os parâmetros determinados pela Resolução CONAMA nº 03 de 28 de junho de 1990 (BRASIL, 1990), somente para amostragem de MP_{10}, já que essa Resolução abrange outros poluentes atmosféricos. Também foram utilizadas as normas ABNT NBR 13.412/1995 (ABNT, 1995) e ABNT NBR 9.547/1997 (ABNT, 1997), que tratam da operação do AGV-MP_{10} e da coleta dos dados, respectivamente.

4.2.2.1 Coleta de dados da série 2

O funcionamento do AGV-MP_{10} consiste em succionar uma determinada vazão de ar, que passa por um filtro, no qual o material particulado é acumulado. A geometria do equipamento faz com que as partículas com menos de 10 µm de diâmetro sejam direcionadas para o local onde o filtro é instalado. A determinação da concentração é feita por gravimetria, sendo a massa acumulada no filtro determinada por pesagem em

balança de precisão. Além disso, para determinação da concentração também é necessário medir a vazão de ar amostrado. O equipamento fornece a leitura da vazão succionada, que deve ser corrigida para as condições padrão (25 ºC e 760 mmHg). Todos os cálculos que envolveram a correção da vazão estão apresentados no Apêndice A. A Figura 3 apresenta um esquema do funcionamento do equipamento AGV-MP_{10}.

Figura 3: Esquema do funcionamento do equipamento AGV-MP_{10}.

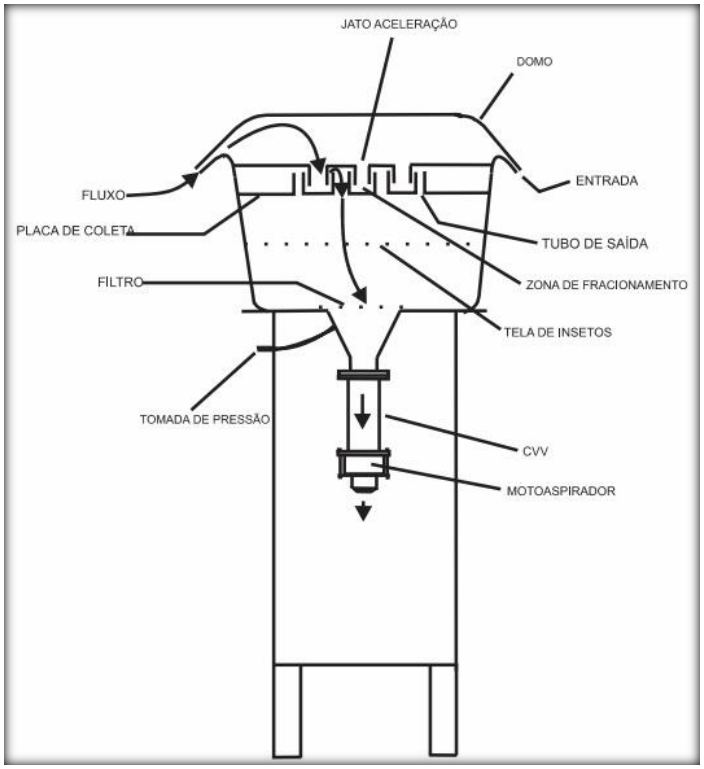

(Fonte: ENERGÉTICA, 2016)

De acordo com as normas, as coletas devem ser realizadas por um período de 24 horas, iniciando 00 hora e com término às 23h59min. Além disso, elas estabelecem a realização de coletas a cada seis dias, para caracterização do material particulado, compreendendo todos os dias da semana. Neste trabalho, no entanto, as coletas foram realizadas diariamente, com o objetivo de avaliar os níveis de concentração do material particulado ao longo dos dias e servir de histórico de dados para basear o modelo de previsão de MP_{10} do dia seguinte por redes neurais artificiais. A decisão da coleta diária foi baseada em estudos como o de Lira (2009), em que a autora realizou a previsão do

MP_{10} com uma rede neural do tipo *MultiLayerPerceptron* (MLP) com algoritmo de treinamento *backpropagation* e não encontrou bons resultados. A autora atribuiu os resultados a forma de coleta dos dados, ou mais especificamente, a falta de frequência de coleta, exatamente como os dados disponíveis da série 1, mas que foram muito importantes para o entendimento de vários processos relacionados ao material particulado de São Carlos. Pelo monitoramento diário é possível determinar perfis de poluentes durante diferentes dias da semana, mês e estação do ano, entre outros.

Para viabilizar as coletas diárias, algumas mudanças foram necessárias, o período de amostragem foi reduzido de 24h para 23h30min, sendo o intervalo de 30min necessário para troca do filtro e da carta gráfica, utilizada para verificação da vazão ao longo do tempo de amostragem. Além disso, os horários de início e término das coletas foram alterados, as trocas dos filtros e da carta gráfica eram realizadas diariamente entre 6h10min e 6h40min. Assim, a coleta do dia 16/04/2014, por exemplo, se iniciou às 6h40min do dia 16/04/2014 e terminou às 6h10min do dia 17/04/2014. Foi assumido que nesse intervalo, entre 00 hora e 6h10min, a interferência na concentração do material particulado não era significativa, já que a movimentação no local de coleta era reduzida. Os filtros eram pesados em triplicata, antes e após cada coleta, para determinação da massa de material particulado acumulado em cada dia de coleta. Para assegurar a confiabilidade das pesagens, os filtros ficavam previamente em um dessecador para estabilização da umidade. O transporte dos filtros a campo era realizado utilizando suportes de filtro adequados.

Para o bom funcionamento do AGV-MP_{10} era necessário realizar a troca das duas escovas de grafite, que servem como condutores elétricos para o coletor do induzido e também como uma espécie de lubrificante para o eixo do rotor. Essa troca era realizada a cada 25 coletas, sendo que a cada 100 coletas era necessário realizar a

troca do próprio motor. Sempre que ocorria a troca de escovas ou a troca do motor era necessário realizar a calibração do equipamento, que consistia em medir a vazão que passa por diferentes placas, onde o número de orifícos é variado, assim dois parâmetros (a e b) que eram necessários para calcular a vazão padrão eram encontrados, o Apêndice B apresenta os detalhes dos cálculos da calibração.

4.2.2.2 Dados de variáveis climáticas

O INMET (Instituto Nacional de Meteorologia) possui estações de monitoramento de parâmetros meteorológicos em várias cidades do país. No site do INMET é possível acessar dados de 90 dias anteriores e os dados mais antigos, todas as séries que o instituto possui são armazenadas em um banco de dados, o BDMEP (Banco de Dados Meteorológicos para Ensino e Pesquisa). Para este trabalho, foram retirados do BDMEP dados da cidade de São Carlos, que possui uma estação meteorológica do INMET, Estação 83726. Foram utilizadas médias diárias e mensais de temperatura (ºC), umidade relativa (%) e velocidade do vento (m/s), além do acumulado de precipitação (mm) diário e mensal. Os dados foram retirados do endereço: http://www.inmet.gov.br/projetos/rede/pesquisa.

Para a série 1 foram levantados todos os dias em que havia o dado de concentração de material particulado (MP_{10}) e retirados do BDMEP os dados de variáveis climáticas do dia anterior. Além disso, as médias mensais e o acumulado de precipitação do mês também foram utilizados para a série 1 de dados. Na série 2, como a coleta ocorreu diariamente, foram levantados dados de todos os dias as médias das variáveis climáticas.

4.2.3 Modelos de previsão

Para criação dos modelos foi escolhido o *software MatLab R2010b©*, em função da existência de arquiteturas de redes neurais presentes nas funções do programa. Foram

criados cinco modelos de previsão. A Tabela 1 apresenta um resumo dos modelos de previsão criados utilizando as redes neurais artificiais.

Tabela 1: Resumo dos modelos de previsão da concentração de MP_{10}.

Nomenclatura utilizada	**Dados**	**Arquitetura**	**Entradas**	**Saída**
MLP-diária	Série 1 (1997-2005)	Perceptron de múltiplas camadas	Médias diárias das variáveis climáticas	Concentração média diária do próximo dia de MP_{10}
MLP-mensal			Médias mensais das variáveis climáticas	Concentração mensal de MP_{10}
MLP-1	Série 2 (2014-2015)	Perceptron de múltiplas camadas	Médias diárias das variáveis climáticas	Concentração média diária do próximo dia de MP_{10}
MLP-2			Médias diárias das variáveis climáticas e concentração de MP_{10}	
NARX		Auto regressiva com entradas exógenas	Médias diárias das variáveis climáticas e concentração de MP_{10}	

Inicialmente, foram utilizados os dados de MP_{10} da série 1. Foi criada uma rede neural do tipo MLP (*Multi Layer Perceptron*) ou Perceptron de Multicamadas, sem retroalimentação e utilizando como algoritmo de treinamento o *backprogation*. A rede neural do tipo MLP foi escolhida pela sua extensa utilização na literatura. Para executar a rede, os dados precisaram ser divididos para as fases de treinamento, validação e teste, sendo que a divisão ocorreu da seguinte forma:

- Treinamento -70%
- Validação - 15%
- Teste - 15%

A escolha dos dados para cada fase ocorreu de maneira aleatória durante o processo de execução da rede. Para definição da arquitetura da rede neural foram variados os seguintes parâmetros:

- Número de camadas ocultas
- Número de neurônios nas camadas ocultas
- Funções de ativação nas camadas ocultas
- Função de ativação na camada de saída

Foi definida uma rede com 2 camadas ocultas e 10 neurônios em cada camada oculta. Como funções de ativação foram utilizadas a função do tipo sigmóide nas duas camadas ocultas e a função do tipo linear na camada de saída da rede. A inicialização dos pesos ocorreu de maneira aleatória e como critério de parada foi utilizado o erro igual à zero ou após 150 verificações do erro da validação. Foi estabelecido um máximo de 2000 ciclos ou épocas. Com a arquitetura definida foi realizada a previsão da série 1, utilizando como dados de entrada as variáveis climáticas, temperatura (ºC), velocidade do vento (m/s), precipitação acumulada (mm) e umidade relativa do ar (%), e como saída a concentração de MP_{10}. Duas redes foram criadas, uma para a previsão mensal e outra para a previsão diária do MP_{10} da série 1. A rede para previsão diária utilizou médias dos dados climáticos de um dia e realizou a previsão da concentração média do MP_{10} do dia seguinte. A rede utilizada para a previsão mensal utilizou as médias mensais das variáveis climáticas, considerando apenas os dias em que houve coleta de material particulado, para previsão da concentração do MP_{10} do próprio mês. As Figuras 4 e 5 apresentam o desenho esquemático das redes para previsão da série 1.

Figura 4: Esquema da rede neural MLP para previsão do MP_{10} diário da série 1.

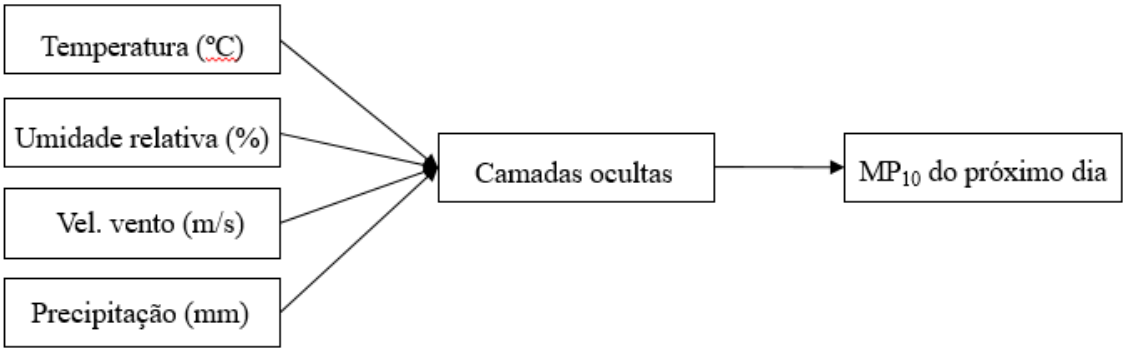

Figura 5: Esquema da rede neural MLP para previsão do MP_{10} mensal da série 1.

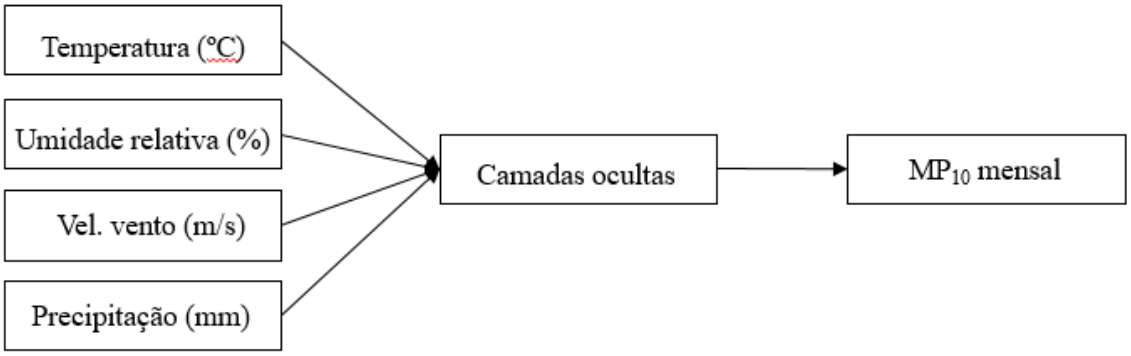

A mesma arquitetura de rede neural definida para a série 1 foi utilizada para previsão do MP_{10} da série 2, onde foi realizada a previsão diária do material particulado do próximo dia. No entanto, os dados de entrada da rede foram modificados, uma rede foi executada tendo como entradas somente as variáveis climáticas, denominada MLP-1 e uma segunda rede teve como entradas as variáveis climáticas e a concentração de MP_{10} do dia anterior, denominada MLP-2. As Figuras 6 e 7 apresentam os esquemas dessas redes. A utilização do dado de concentração de material particulado como um dos neurônios de entrada foi possível devido à frequência de realização das coletas serem diárias.

Figura 6: Esquema da rede neural MLP-1 para previsão do MP_{10} diário da série 2.

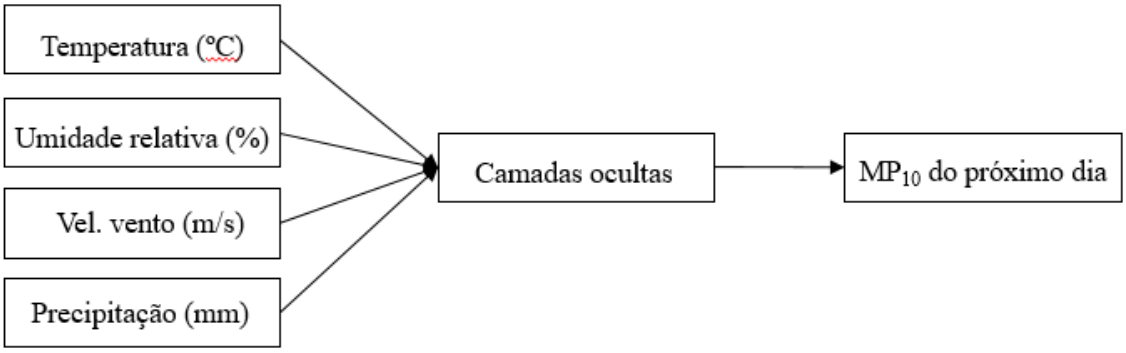

Figura 7: Esquema da rede neural MLP-2 para previsão do MP_{10} mensal da série 2 com entrada de MP.

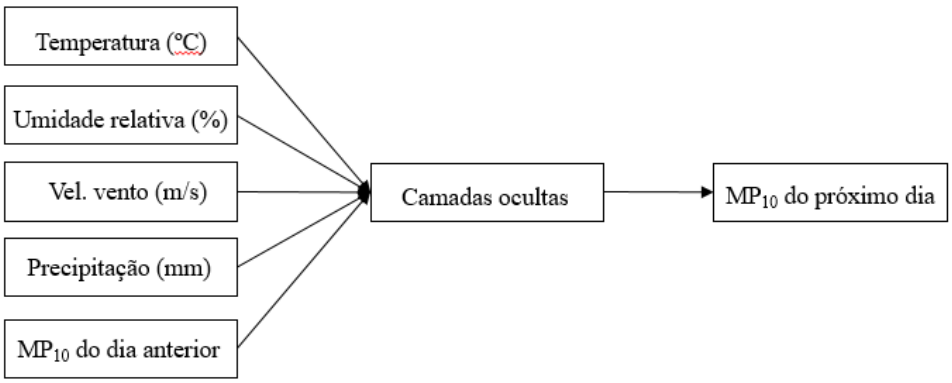

A Figura 8 apresenta o desenho esquemático da rede neural *perceptron* de multicamadas (MLP), utilizada para previsão diária de material particulado da série 2. Como entradas da rede são utilizadas as variáveis climáticas e contração do MP_{10} do dia anterior para previsão do MP_{10} do próximo dia. Todos os neurônios se conectam e, dessa forma, durante a etapa de treinamento os pesos sinápticos vão convergindo para o melhor resultado da rede, considerando os valores de concentrações apresentadas como saída desejada.

Figura 8: Desenho esquemático da rede MLP utilizada para previsão da concentração diária de MP_{10} da série 2.

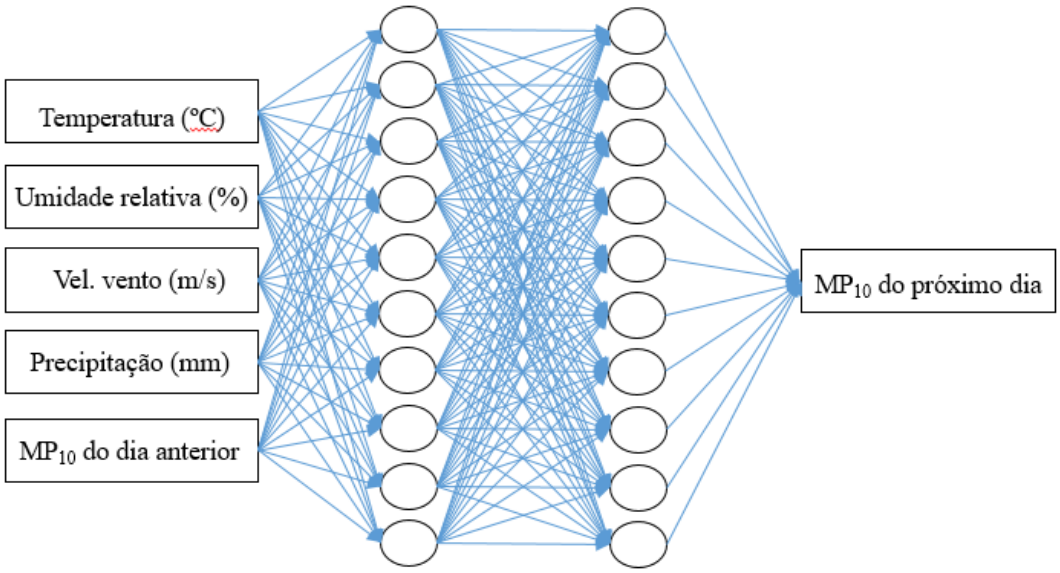

Os dados de entrada e saída da rede foram normalizados (-1 até 1), utilizando a função *mapminmax* do *MatLab*. O Apêndice C apresenta o código utilizado para execução dessa rede. O mesmo código foi utilizado para as execuções da série 1 mensal e diária e para a série 2 tendo como neurônios de entrada apenas as variáveis climáticas, somente foram alterados os dados de *inputs* (entradas) e *targets* (saída) da rede.

Outra arquitetura de rede neural foi utilizada para os dados da série 2, a rede neural do tipo NARX (rede neural auto regressiva com entradas exógenas). Essa arquitetura foi selecionada buscando-se uma comparação com os resultados da MLP, em função do mapeamento dos dados que ocorre de maneira diferente. A rede NARX é uma derivação da MLP, aplicada em estudos de séries temporais, que funciona como uma rede recorrente, ou seja, possui retroalimentação, além disso, a rede NARX possui "atrasadores" na camada de entrada (HAYKIN, 2001).

Foi definido a utilização dessa arquitetura somente para a série 2, em função da disponibilidade dos dados de concentração de material particulado como entrada da rede. Os dados utilizados na rede NARX foram normalizados, conforme a Equação 1.

$$y = \left[\frac{(y_{máx} - y_{mín})(x - x_{mín})}{x_{máx} - x_{mín}}\right] + y_{mín} \qquad \text{Equação (1)}$$

Em que, para os dados deste trabalho:

y= dado normalizado

$y_{máx}$ = 0,9

$y_{máx}$ = 0,1

$x_{máx}$ = valor máximo do dado a ser normalizado

$x_{mín}$ = valor mímino do dado a ser normalizado

x = dado a ser normalizado

Para execução dessa rede foi utilizada a *Toolbox Neural Network* do *MatLab*, que possibilita a criação, treinamento e visualização das redes neurais. Essa ferramenta facilita a utilização das arquiteturas de redes neurais e permite alterações como o número de neurônios na camada oculta ou o número de atrasadores no caso da rede NARX, além da variação na divisão dos dados para treinamento, validação e teste.

Na janela do *MatLab* mostrada na Figura 9 foram inseridos os dados de entrada da rede (*inputs*) e a saída desejada (*targets*). Os dados precisaram estar na forma de linha de matriz. Na próxima janela (Figura 10) foram definidos parâmetros da rede, como número de neurônios na camada oculta (10) e número de atrasadores (2). A Figura 11 apresenta o diagrama da rede NARX utilizada para previsão do MP_{10} diário da série 2, com 5 neurônios de entrada, função sigmoidal na camada oculta e função linear na camada de saída.

Figura 9: *Tollbox* do *MatLab* utilizada para previsão do MP_{10} da série 2 com a rede neural do tipo NARX.

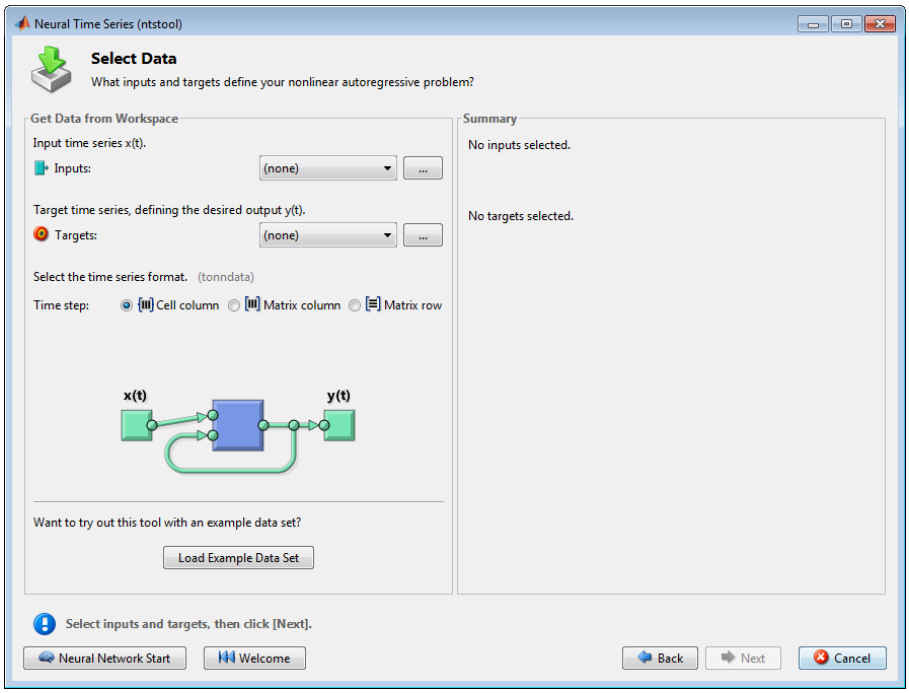

Figura 10: *Tollbox* do *MatLab* utilizada para previsão do MP_{10} da série 2 com a rede neural do tipo NARX, número de neurônios e atrasadores.

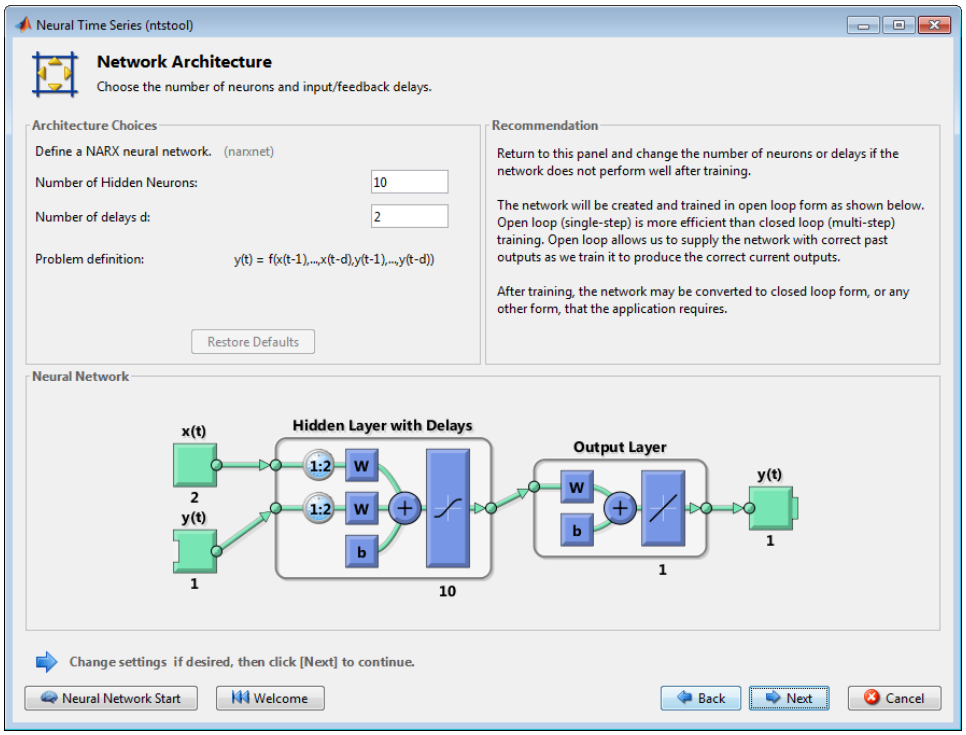

Figura 11: Diagrama fornecido pelo *MatLab* da rede neural NARX para previsão do MP_{10} da série 2.

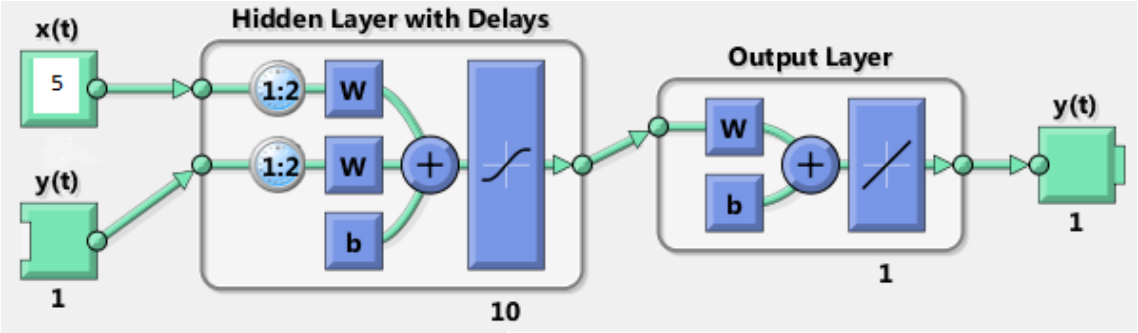

A rede NARX utiliza como algoritmo de treinamento o Levenberg-Marquardt, como critérios de para foram utilizados o erro igual a zero e após 150 verificações do erro de validação. Após a execução com a *Toolbox*, foi gerado o *script* somente para facilitar o processo de guardar as figuras geradas durante o processo de execução da rede, mas que também poderia ter sido utilizado para modificações nos parâmetros da rede NARX, o Apêndice D apresenta o código utilizado para execução dessa rede.

5. RESULTADOS E DISCUSSÃO

Os resultados são apresentados divididos entre a análise dos valores de concentração do material particulado e as simulações realizadas com as redes neurais.

5.1 Análise da coleta de dados de material particulado da Praça Voluntários da Pátria em São Carlos, SP.

Inicialmente, foi realizado um levantamento de todos os dias em que havia dados de concentração de material particulado da série 1 e acrescentados os dados climáticos do dia anterior, já que para a criação do modelo o objetivo foi realizar a previsão do dia seguinte. No Apêndice E estão apresentados todos os dados da série 1 de concentração de MP_{10} e dados climáticos utilizados para geração dos resultados, além disso, foram acrescentados os dias da semana em que ocorreram as coletas de MP_{10}. A Tabela 2 apresenta o número de coletas de MP_{10} realizadas em cada dia da semana. Como o objetivo na época foi caracterizar o material particulado, não havia uma frequência estabelecida para realização das coletas. É possível observar a diferença no número de coletas em cada dia, a segunda-feira apresenta 220 dados e o domingo apresenta apenas 6 coletas realizadas, sendo os dias com o maior e o menor número de amostragens, respectivamente.

Tabela 2: Número de amostragens por dia da semana da série 1.

	Domingo	Segunda	Terça	Quarta	Quinta	Sexta	Sábado
Número de amostras de MP_{10}	6	220	100	144	152	42	19

A Figura 12 apresenta o gráfico em *boxplot* que resume os dados de MP_{10} da série 1por dia semana, sendo possível analisar os valores máximos, médios e mínimos para cada dia. O domingo apresenta uma média elevada, a maior média diária, apesar de ser um dia sem grande movimentação no centro da cidade, porque os comércios

estavam fechados. No entanto, de acordo com os dados presentes no Apêndice E, é possível observar que as seis coletas realizadas no domingo ocorreram entre os meses de abril e setembro, portanto, caracterizam apenas a concentração de MP_{10} da estação seca, quando os níveis de material particulado são mais elevados em função da menor incidência de precipitação.

Figura 12: Gráfico em *boxplot* da concentração de MP_{10} por dia da semana da série 1.

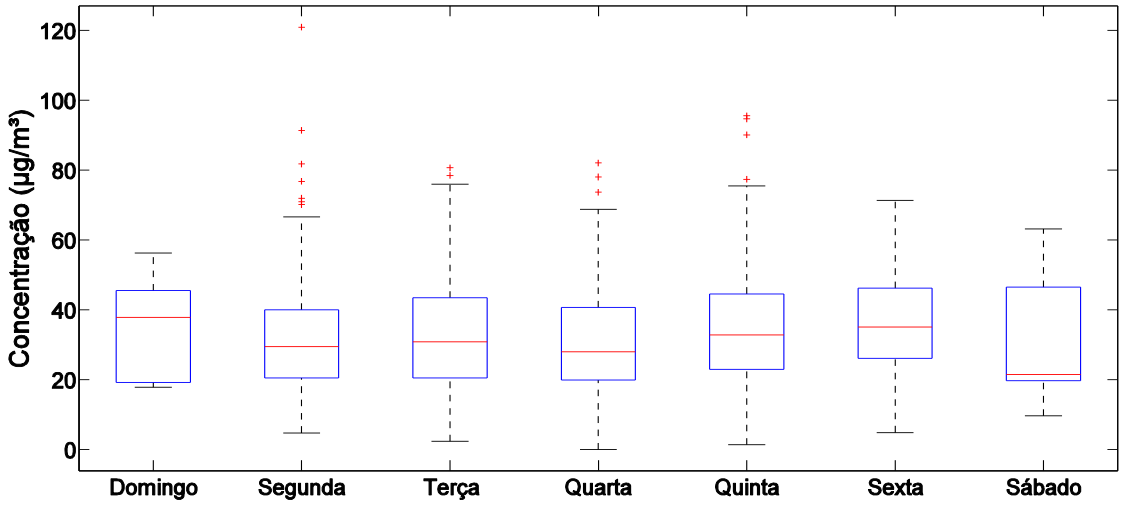

Em relação aos demais dias da semana, a sexta-feira apresenta a maior média, possivelmente por causa da maior movimentação neste dia no comércio local. O sábado possui a menor média diária, pois, em São Carlos o comércio durante aos sábados fica aberto somente até às 12h, sendo este provavelmente um dos motivos do menor índice de material particulado quando comparado aos outros dias da semana, além do número de amostragens ser de apenas 19 em todo o período considerado na série 1, que engloba os anos de 1997 a 2005.

Os resultados apresentados para a série 2 são constituídos de dados diários de concentração de material particulado, coletados para este trabalho durante o período de um ano, entre abril/2014 e abril/2015. Os dados de concentração de material particulado MP_{10} também foram utilizados para uma dissertação do Programa de Pós-Graduação da

Engenharia Química, da Universidade Federal de São Carlos (PPGEQ-USFCar), que analisou as características químicas do MP_{10} de São Carlos (ALEXANDRINA, 2015).

A Figura 13 apresenta os valores de concentração de MP_{10} obtidos para a série 2. As amostragens tiveram início no dia 16/04/2014 e término no dia 21/04/2015, sendo coletados dados diários de material particulado. Com exceção do mês de janeiro, quando o equipamento AGV-MP_{10} apresentou falhas no registro realizado pela carta gráfica, que garante a confiabilidade da vazão medida. Assim, durante este mês aconteceram apenas 4 coletas.

Os valores obtidos para a série 2 corroboram com os dados coletados anteriormente em São Carlos (série 1) apresentando diferenças na concentração de material particulado entre a estação seca e a estação chuvosa. Durante o período chuvoso o material particulado é lavado da atmosfera, assim, para este período os níveis de concentração são menores. Além disso, o período de chuvas coincide com o verão que, em função das temperaturas elevadas, aumenta a dispersão dos poluentes. Ao contrário, no período seco, que coincide com a época do inverno, além da menor incidência de precipitação, na região ocorrem queimadas nas plantações de cana-de-açúcar, aumentando os valores de concentração de material particulado (CELLI, 2003; MARQUES, 2000, BRUNO, 2005; POZZA, 2009).

A Figura 14 apresenta o gráfico em *boxplot* dos meses de coleta da série 2. O maior valor de concentração de material particulado foi encontrado no mês de outubro e ultrapassa 90 µg/m³. A OMS (Organização Mundial da Saúde) sugere como limite de exposição ao MP_{10} o valor máximo de 50 µg/m³, sendo que, nos meses de abril, maio, junho, julho, agosto, setembro e outubro esse valor é ultrapassado.

Figura 13: Concentrações de diárias de MP_{10} obtidas entre 16/04/2014 e 21/04/2015.

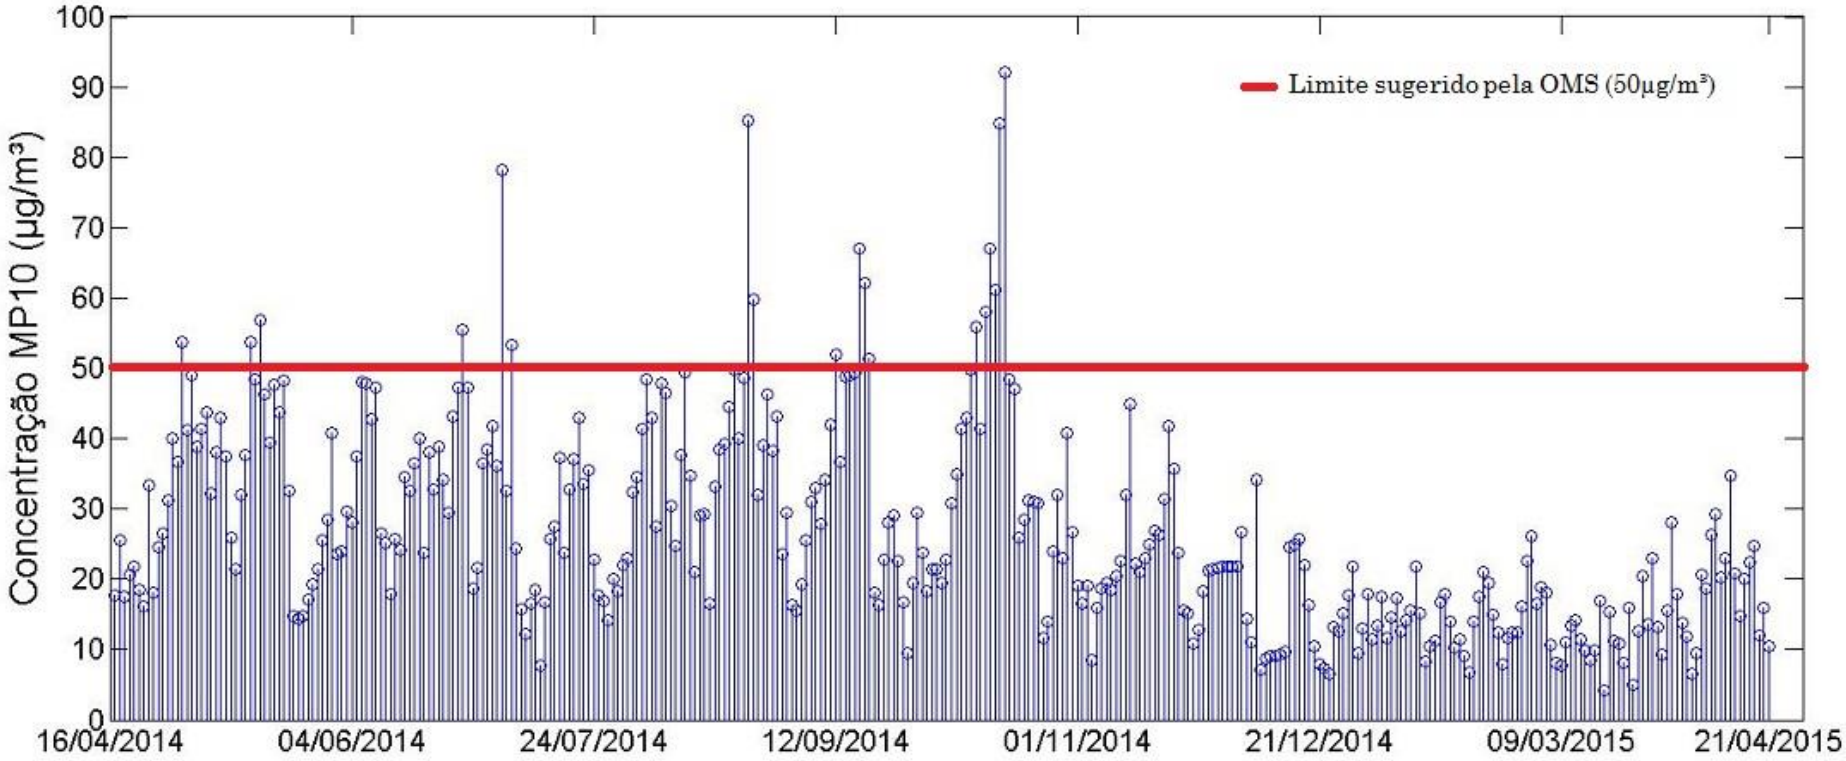

Durante o mês de outubro, em que foi verificado o maior valor médio diário de concentração do material particulado, foi possível observar visualmente a presença de fuligem, proveniente de queimadas na região, sugerindo ser a causa da alta concentração encontrada neste mês. A Resolução CONAMA 03/1990 (BRASIL, 1990) determina como limite diário o valor de 150µg/m³. Em nenhum dia de amostragem esse valor foi ultrapassado, no entanto, sabe-se que essa Resolução está ultrapassada e atualmente está passando por revisão, mas os novos índices ainda não foram apresentados. Como São Carlos é uma cidade que pertence ao estado de São Paulo, está sujeita às normas da Companhia Ambiental do Estado de São Paulo (CETESB), que estabelece, por meio do Decreto Estadual 59.113/2013, o valor de concentração de 24 horas de 120 µg/m³ (SÃO PAULO, 2013). Este Decreto Estadual propõe metas intermediárias até que se alcance um valor padrão final de concentração de MP_{10} de 50 µg/m³, o mesmo valor sugerido pela OMS.

Estudos anteriores, realizados em São Carlos, dividiram os meses de abril a setembro em estação seca, e os meses de outubro a março em estação chuvosa. É possível verificar que o período seco para o ano de 2014 se estendeu até o mês de outubro, sendo observado que o mês de novembro apresentou uma média menor e mais próxima da média dos outros meses do período chuvoso (Figura 14). Uma hipótese é de que os períodos possam ter sofrido um pequeno deslocamento ao longo dos últimos anos, apesar de que as coletas anteriores cessaram no ano de 2005. Uma década é um período curto para observar uma mudança desse patamar. Outra hipótese, mais razoável, é a de que em função de fatores climáticos mais abrangentes, até globais, o ano de 2014 foi um ano mais seco que o esperado. Foram observados apenas 21 dias com precipitação durante os meses de abril a setembro, segundo dados do INMET (INMET,

2014). De qualquer forma, são necessários dados de vários anos para apontar algo concreto em qualquer uma das hipóteses.

Figura 14: Gráfico em *boxplot* mensal da série 2.

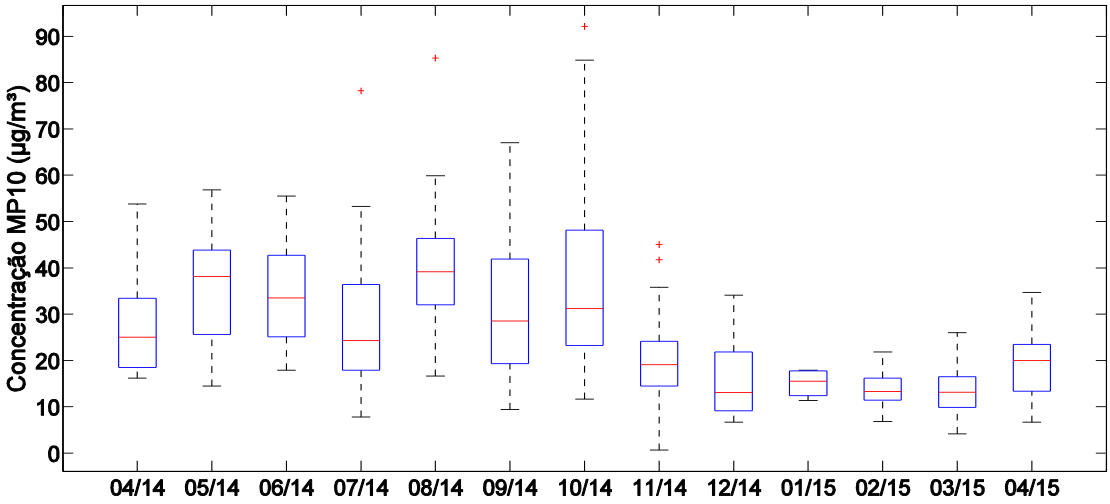

Comparando a Figura 12 (série 1) com a Figura 14 (série2) é interessante verificar que na primeira foram alcançados níveis de MP_{10} em torno de 120 µg/m³, enquanto que para a série 2 o maior valor foi um pouco acima de 90 µg/m³. As variações nos níveis de material particulado na atmosfera são decorrentes do incremento das fontes poluidoras ou quando as leis se tornam mais rigorosas. Neste caso, a região onde a cidade de São Carlos está situada tem o plantio da cana-de-açúcar como uma das atividades agropecuárias mais intensas, e para a colheita manual é prática a realização de queimadas para facilitar o trabalho do corte. O estado de São Paulo possui a Lei nº 11.241 de 2.002 (SÃO PAULO, 2002) que dispõe sobre a redução das queimadas na cana-de-açúcar. De acordo com essa legislação está prevista a redução em 100% da queima em áreas mecanizáveis, sendo previstas metas intermediárias, redução de 50% no ano de 2011 e de 80% no ano de 2.016. Esta legislação deve ser responsável pela diminuição dos índices de MP_{10} de São Carlos, mas é necessário um período maior de tempo de coleta de dados para este cenário se confirmar, já que a série 2 é composta por

apenas um ano de coletas, enquanto a série 1, apesar de não serem dados diários, é composta por quase 10 anos de coleta de dados.

As Figuras 15 a 26apresentam os gráficos para comparação das médias mensais ao longo dos anos de coleta. Foram agrupados os dados da série 1 (1997-2005) e da série 2 (2014-2015), valores das médias no Apêndice G. Com exceção dos meses de outubro (2014) e maio (2015), Figuras 24 e 19, respectivamente, os outros meses da série 2 estão entre as menores médias dos anos em que há dados disponíveis. O mês de outubro de 2014 tem a terceira maior média, apresentando valor médio mensal menor apenas que os anos de 1999 e 2002. O mês de maio apresenta a quarta maior média, sendo que os anos de 1998, 1999 e 2000 possuem médias mensais superiores. No ano de 2015 (série 2), os meses de janeiro (Figura 15), março (Figura 17) e abril (Figura 18) apresentam as menores médias mensais em relação aos outros anos. E, além disso, cinco meses da série 2 apresentam o segundo menor valor de média mensal, sendo fevereiro de 2015 (Figura 16), que possui somente uma média superior ao ano de 2004 e os meses de junho (Figura 20), julho (Figura 21), setembro (Figura 23) e dezembro de 2014 (Figura 26), que apresentam médias maiores que os anos de 2005, 2004, 2005 e 2003, respectivamente. Restando os meses de agosto e novembro da série 2, que apresentam a terceira menor média mensal (Figuras 22 e 25). Esses dados apontam para uma tendência de queda nos níveis de material particulado quando comparadas a série 1 e a série 2 de dados de MP_{10} para a cidade de São Carlos.

Figura 15: Médias mensais da concentração de MP_{10} para o mês de Janeiro.

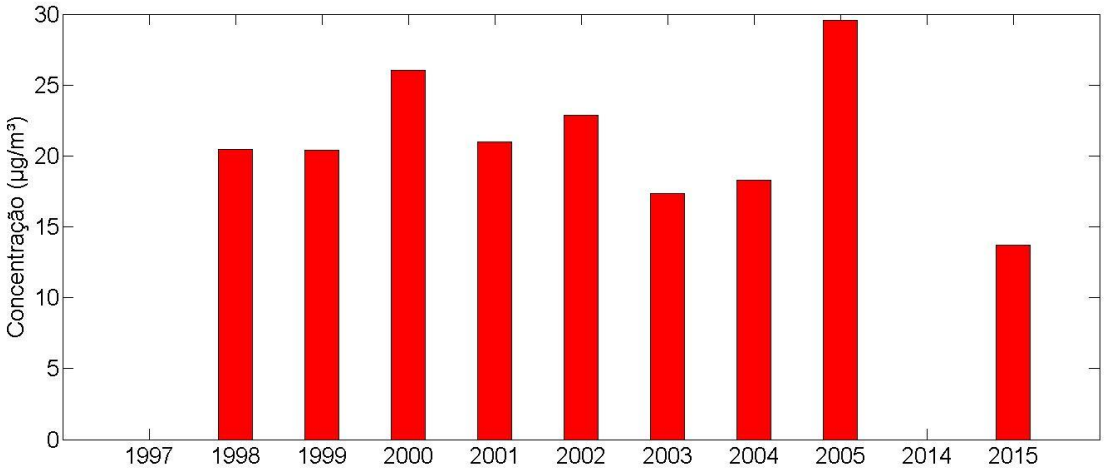

Figura 16: Médias mensais da concentração de MP_{10} para o mês de Fevereiro.

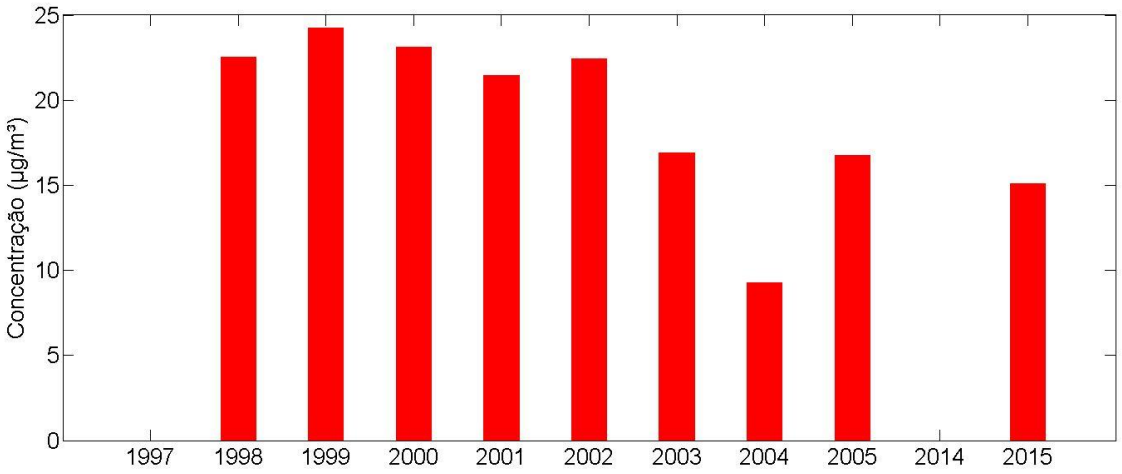

Figura 17: Médias mensais da concentração de MP_{10} para o mês de Março.

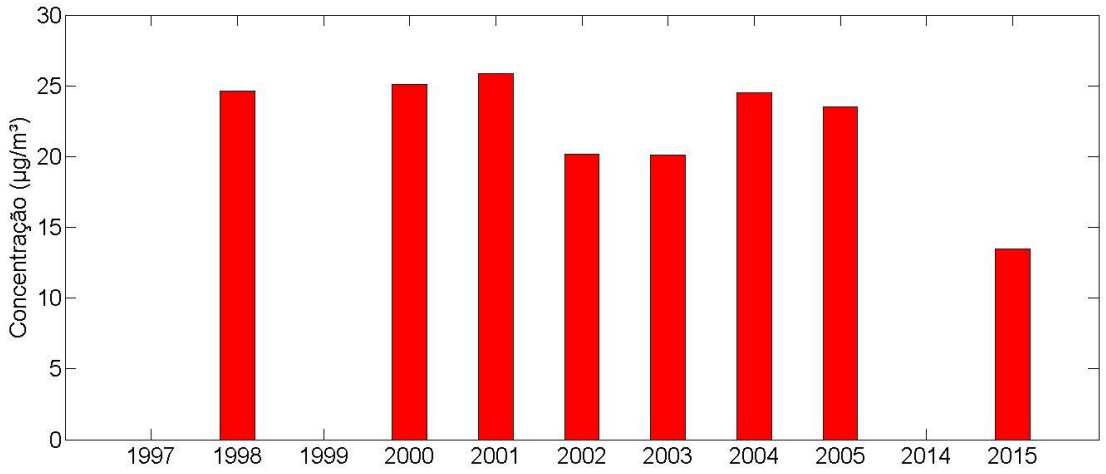

Figura 18: Médias mensais da concentração de MP_{10} para o mês de Abril.

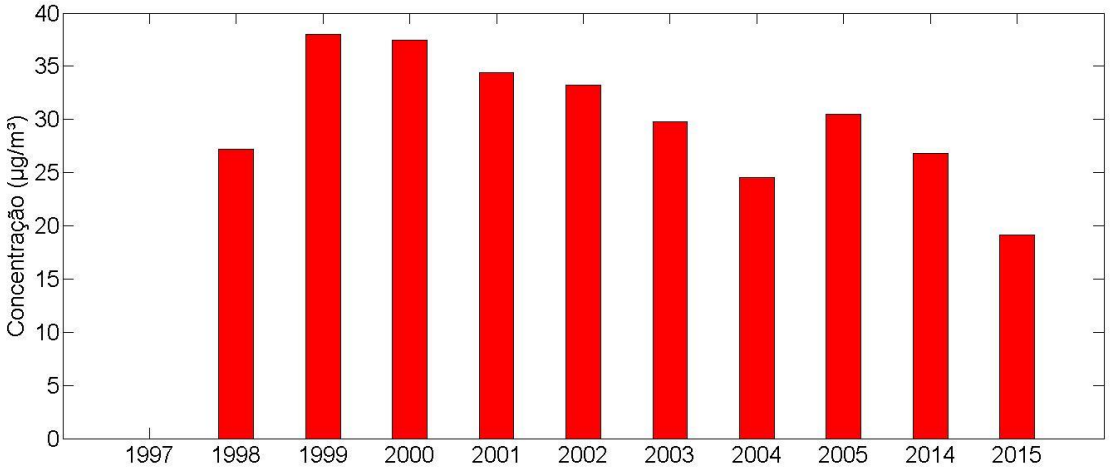

Figura 19: Médias mensais da concentração de MP_{10} para o mês de Maio.

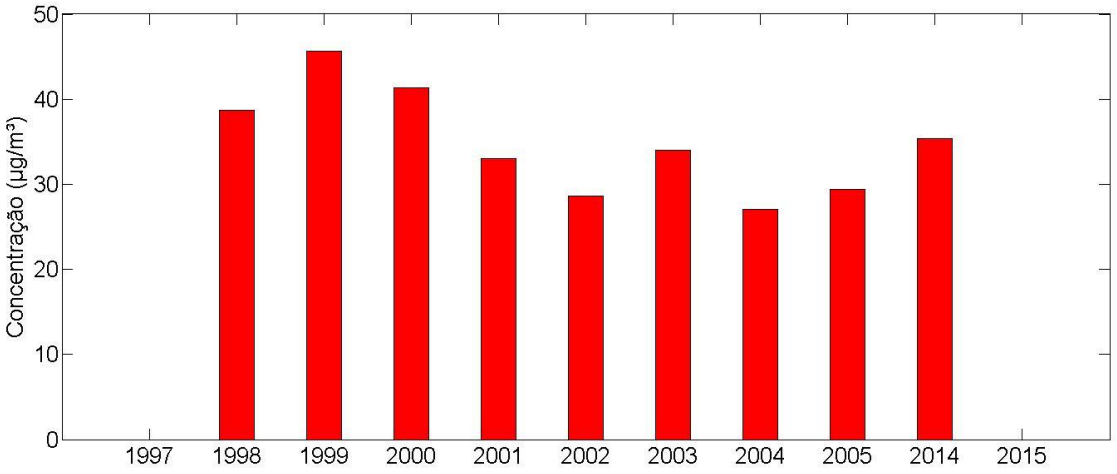

Figura 20: Médias mensais da concentração de MP_{10} para o mês de Junho.

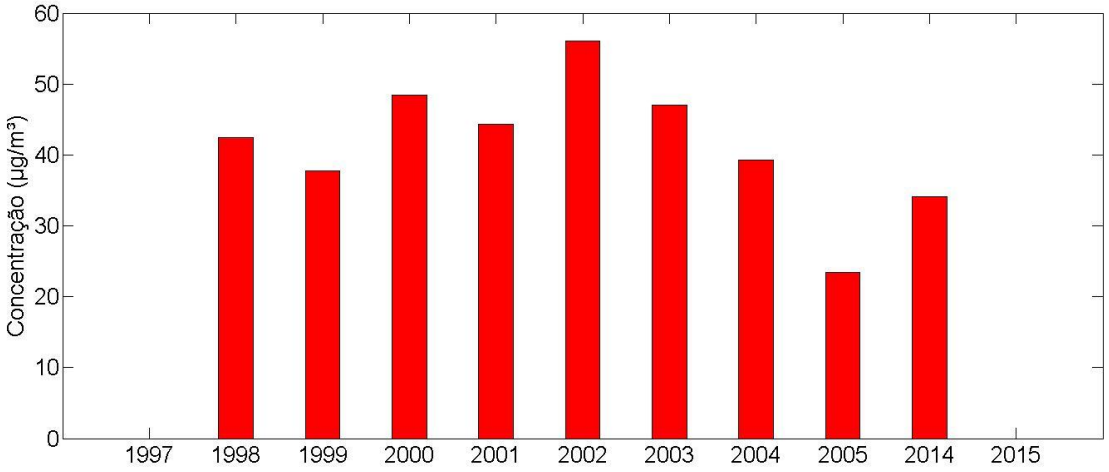

Figura 21: Médias mensais da concentração de MP_{10} para o mês de Julho.

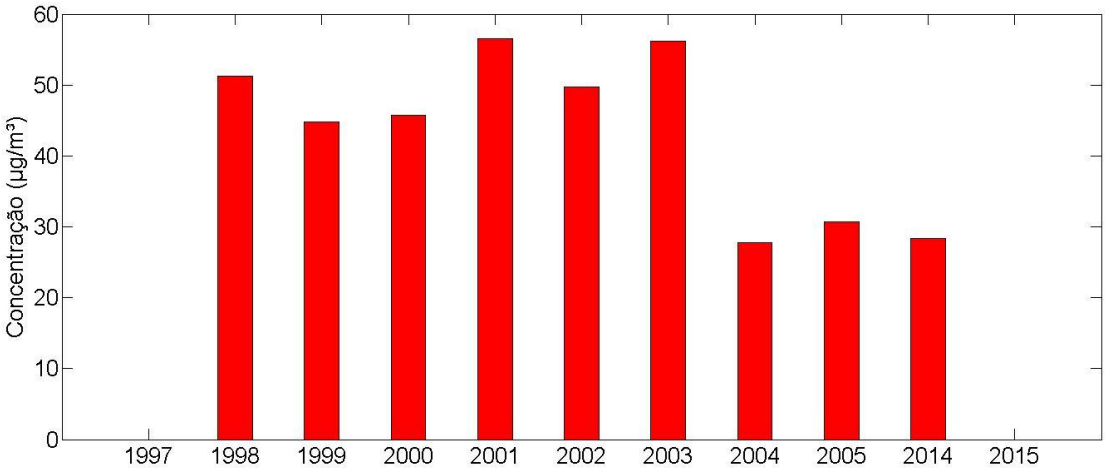

Figura 22: Médias mensais da concentração de MP_{10} para o mês de Agosto.

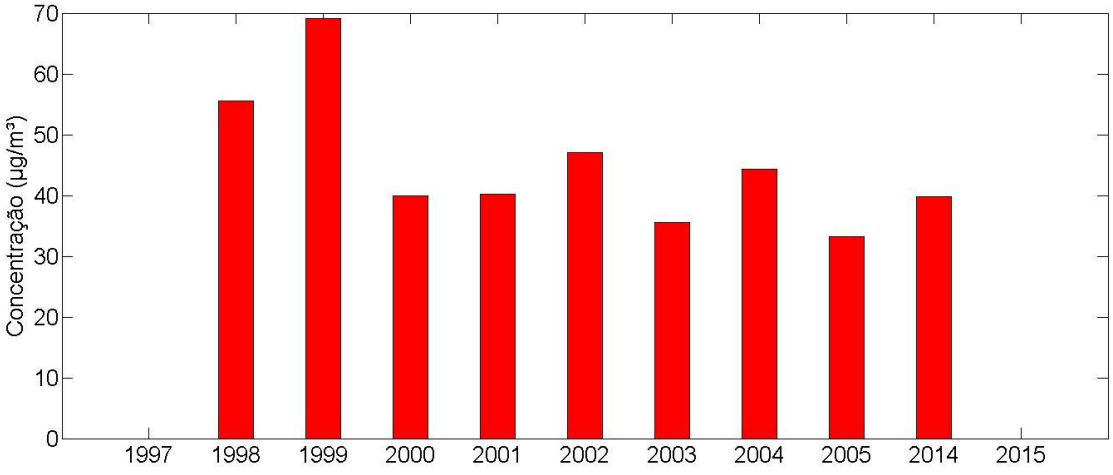

Figura 23: Médias mensais da concentração de MP_{10} para o mês de Setembro.

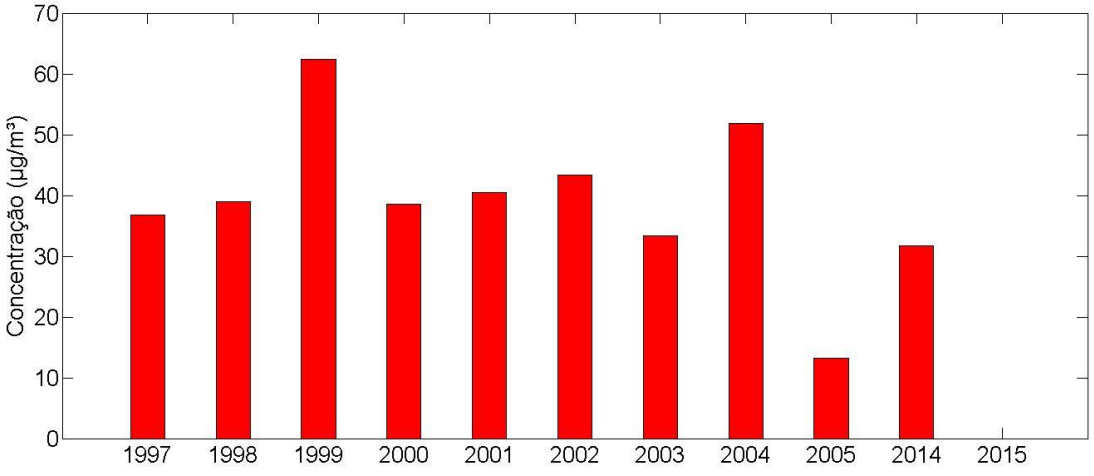

Figura 24: Médias mensais da concentração de MP_{10} para o mês de Outubro.

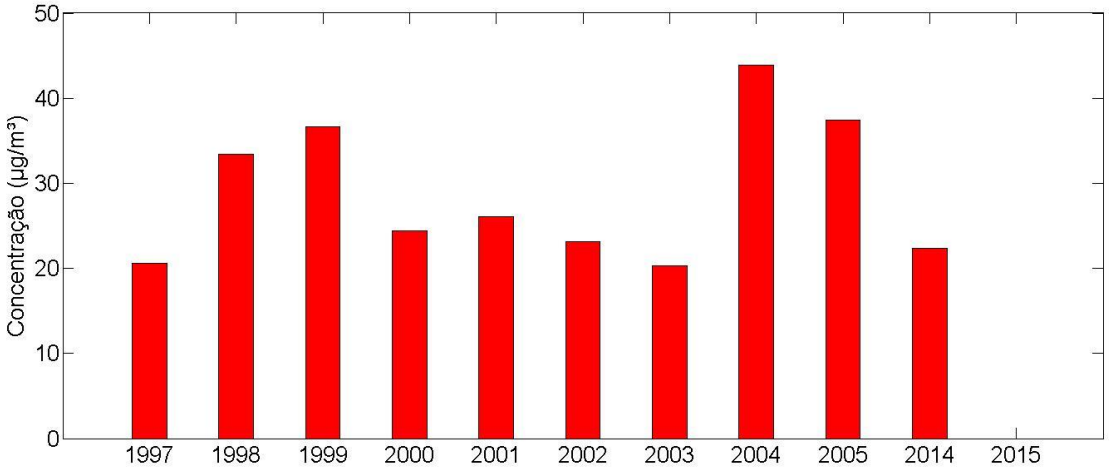

Figura 25: Médias mensais da concentração de MP_{10} para o mês de Novembro.

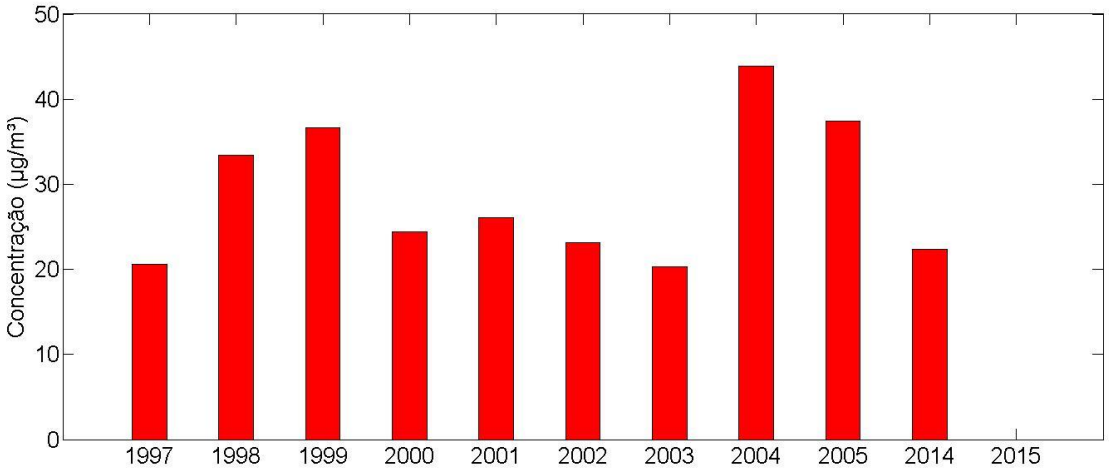

Figura 26: Médias mensais da concentração de MP_{10} para o mês de Dezembro.

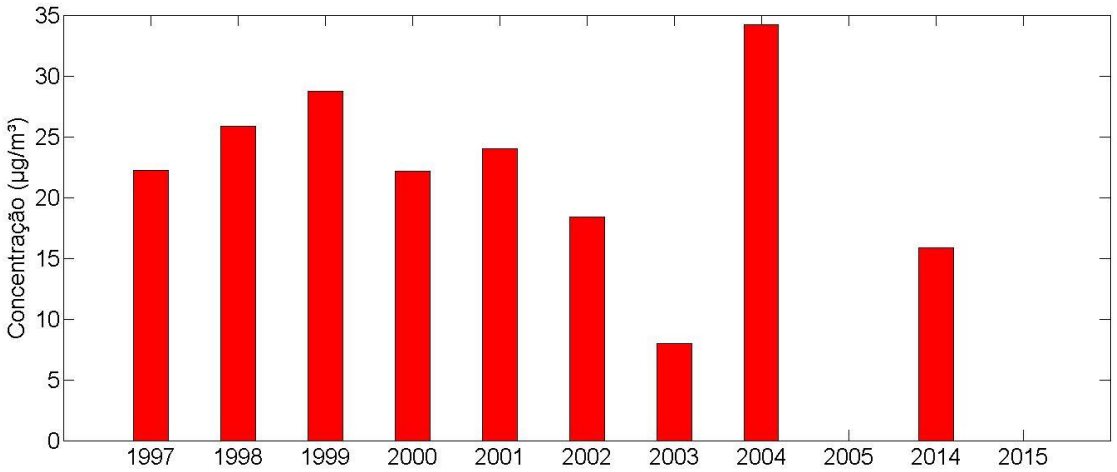

5.2 Discussões dos modelos de previsão por redes neurais artificiais

Nesta seção serão apresentados os resultados obtidos para previsão da concentração de MP_{10} utilizando as redes neurais artificiais. Foram criados 5 (cinco) modelos de previsão.

5.2.1 Modelo de redes neurais para a série 1 de dados para previsão diária e mensal de MP_{10}

Em posse dos dados de concentração de material particulado e dos dados climáticos de temperatura (ºC), umidade relativa do ar (%), velocidade do vento (mm) e acumulado de precipitação (mm), seguiu-se com a inserção dos mesmos nos algoritmos de redes neurais, usando-se o *MatLab*. Os algoritmos são compostos em fases de treino, validação e teste. Os modelos MLP foram testados para previsão de média diária e média mensal para o conjunto de dados da série 1.

A Tabela 3 apresenta os valores de erro médio absoluto para previsão diária e mensal da série 1, com os valores inteiros de MP_{10} e não normalizados. A MLP-mensal apresentou um valor de erro menor. Como o valor utilizado para a previsão mensal é um valor médio de concentração de MP_{10}, ou seja, não ocorrem os valores extremos, a eficiência da rede é maior em relação à previsão dos valores diários. Além disso, quando é realizada a previsão diária não são consideradas as tendências dos fatores climáticos, apenas o dado do dia que está sendo previsto o MP.

Tabela 3: Valores comparativos de erro médio absoluto entre MLP-mensal e MLP-diária usando a série 1.

	MLP-mensal	MLP-diária
Erro médio absoluto	5,1405	9,2158

As Figuras 27 e 28 apresentam os gráficos dos valores de MP_{10} diários previstos e medidos para a série 1. As concentrações encontradas pela previsão da rede neural (linha azul) seguem o padrão dos dados medidos (linha verde).

As Figuras 29 e 30 apresentam gráficos de regressão comparando os valores medidos e previstos das redes MLP-diária e MLP-mensal, respectivamente, para a série 1, das fases de treinamento, validação, teste e do conjunto total de dados. Comparando os gráficos de regressão da MLP-diária (Figura 29) e da MLP-mensal (Figura 30) foi observado que a MLP-mensal apresenta valores de R mais próximos de 1, ou seja, o desvio entre os dados medidos e previstos é menor. Como foi citado anteriormente, a utilização de dados de médias mensais pela rede neural MLP-mensal possibilita um desempenho melhor na previsão da concentração de MP_{10}.

Os modelos de rede neural apresentam apenas resultados médios, não sendo eficiente para os valores extremos, muito altos ou muito baixos. Como esses dados não foram coletados diariamente, não é possível identificar, quando aparece um valor de concentração elevado, que se trata de uma tendência gradativa ao longo dos dias por falta de precipitação, por exemplo, ou se foi um valor que pode ser considerado como um *outlier*, um erro de medição. A mesma tendência é observada na Figura 28, de previsão mensal do MP_{10}, entretanto, como são utilizados os valores de média do mês o ajuste entre os valores previstos e medidos é mais adequado. De modo geral, tanto para a média diária como mensal, a qualidade da trajetória do modelo MLP apresentou-se além de satisfatória para essa primeira série de dados (série 1), ou seja, é viável sua aplicação.

Figura 27: Comparação entre os valores medidos e previstos de MP_{10} pela rede MLP-diária para a série 1.

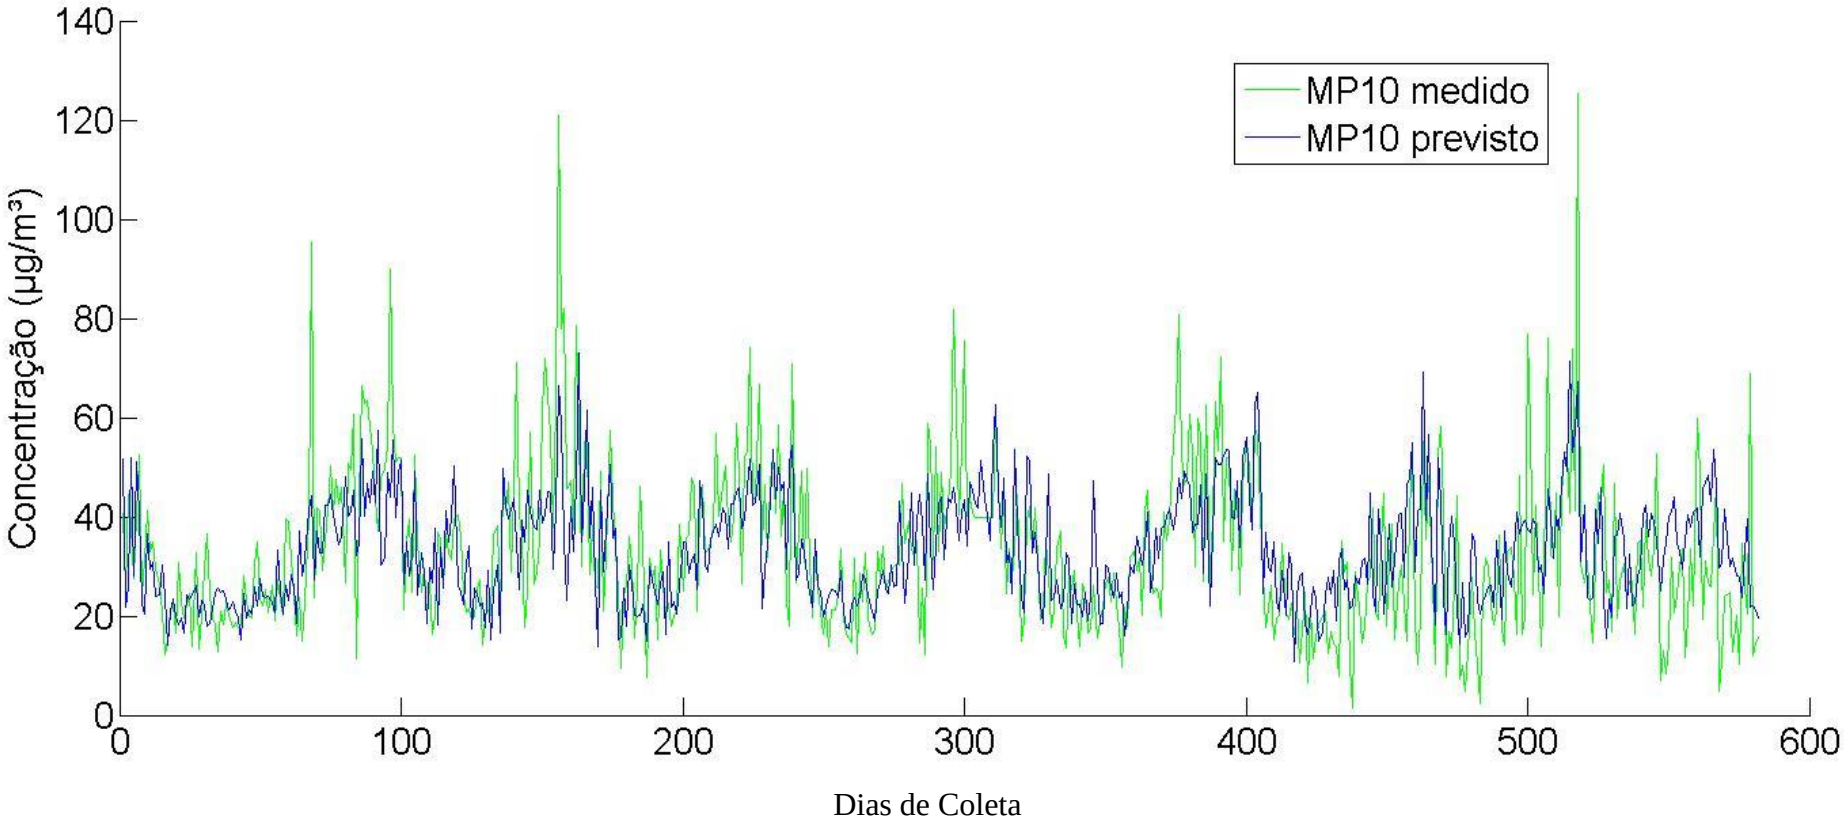

Figura 28: Comparação entre os valores medidos e previstos da concentração de MP_{10} obtidos pela rede MLP-mensal para a série 1.

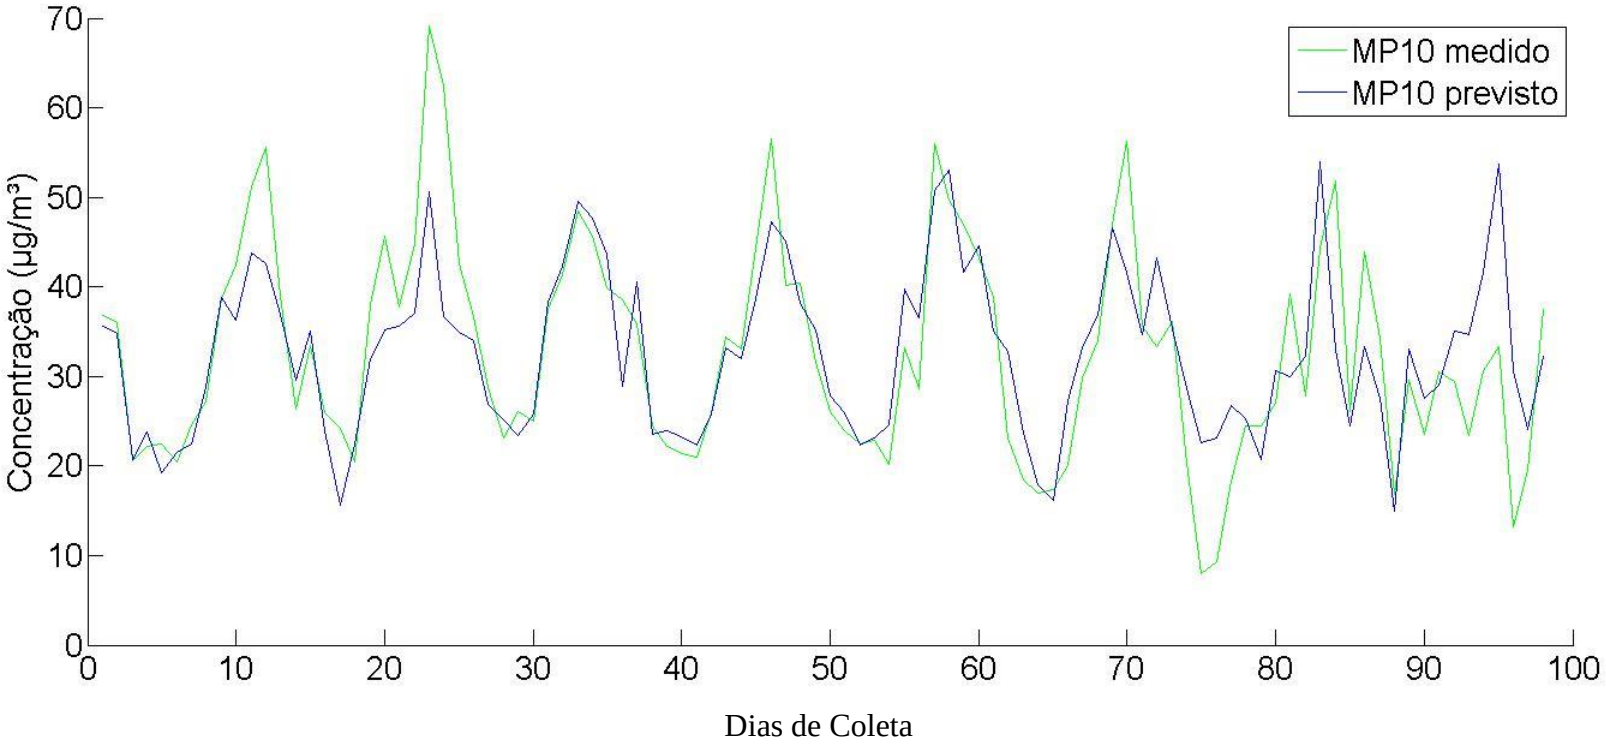

Figura 29: Gráficos de regressão das fases de treinamento (a), validação (b), teste (c) e de todos os dados (d) da rede MLP-diária do MP_{10} da série 1.

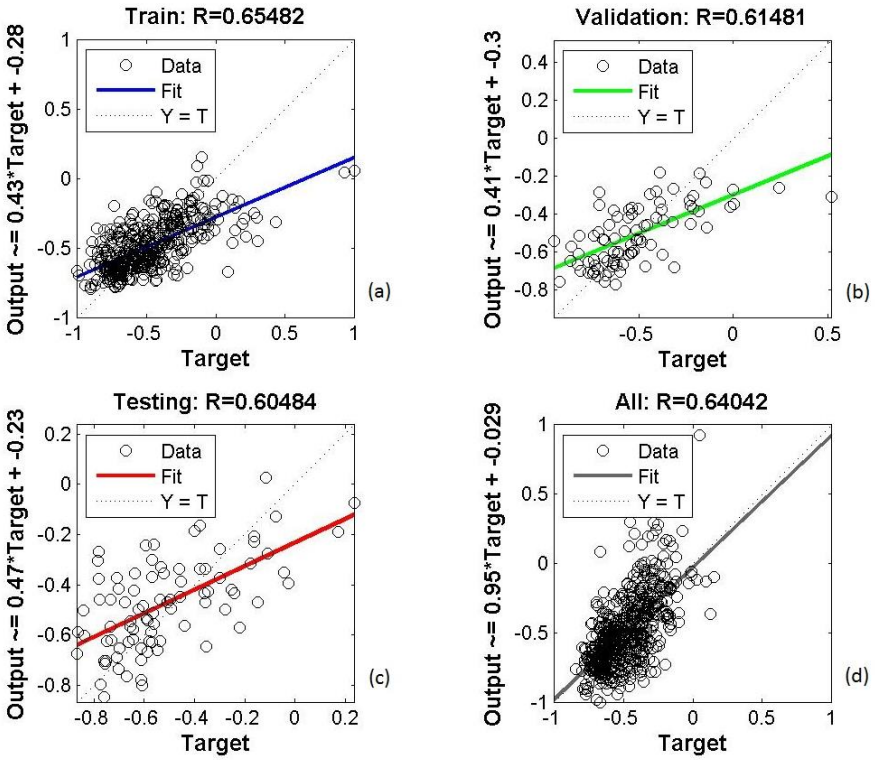

Figura 30: Gráficos de regressão das fases de treinamento (a), validação (b), teste (c) e de todos os dados (d) da rede MLP-mensal do MP_{10} da série 1.

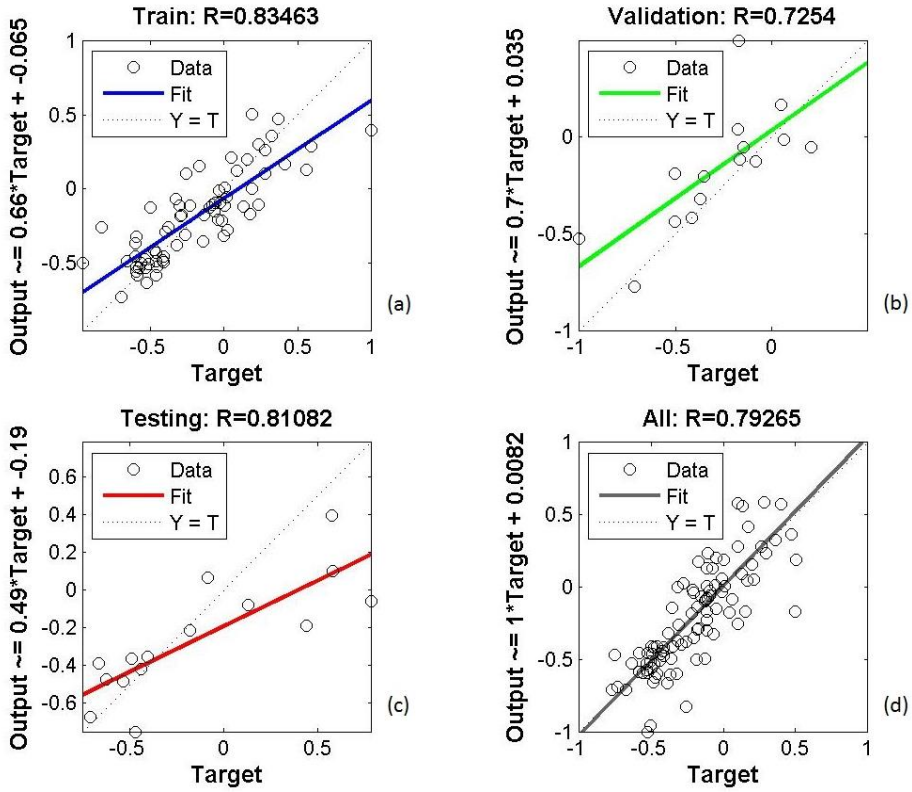

As Figuras 31 e 32 apresentam os gráficos dos resultados de desempenho das redes MLP-diário e MLP-mensal, respectivamente, para a série 1. Na previsão diária o melhor resultado de validação ocorreu com erro de 0,039148 no ciclo 112 e para a previsão mensal o melhor resultado da validação ocorreu com erro de 0,063612 no ciclo ou época 35, denomina-se época uma apresentação de todos os pares (entrada e saída) do conjunto de treinamento no processo de aprendizado.

Em relação ao desempenho da etapa de validação, conforme observado nas Figuras 31 (diária) e Figura 32 (mensal), o erro encontrado na previsão diária foi menor, no entanto, a rede utilizada para a previsão mensal convergiu mais rapidamente, no ciclo 35, exigindo um menor esforço computacional, enquanto a MLP-diária no ciclo 112.

Figura 31: Gráfico do desempenho da rede neural MLP-diária para previsão da concentração de MP_{10} da série 1.

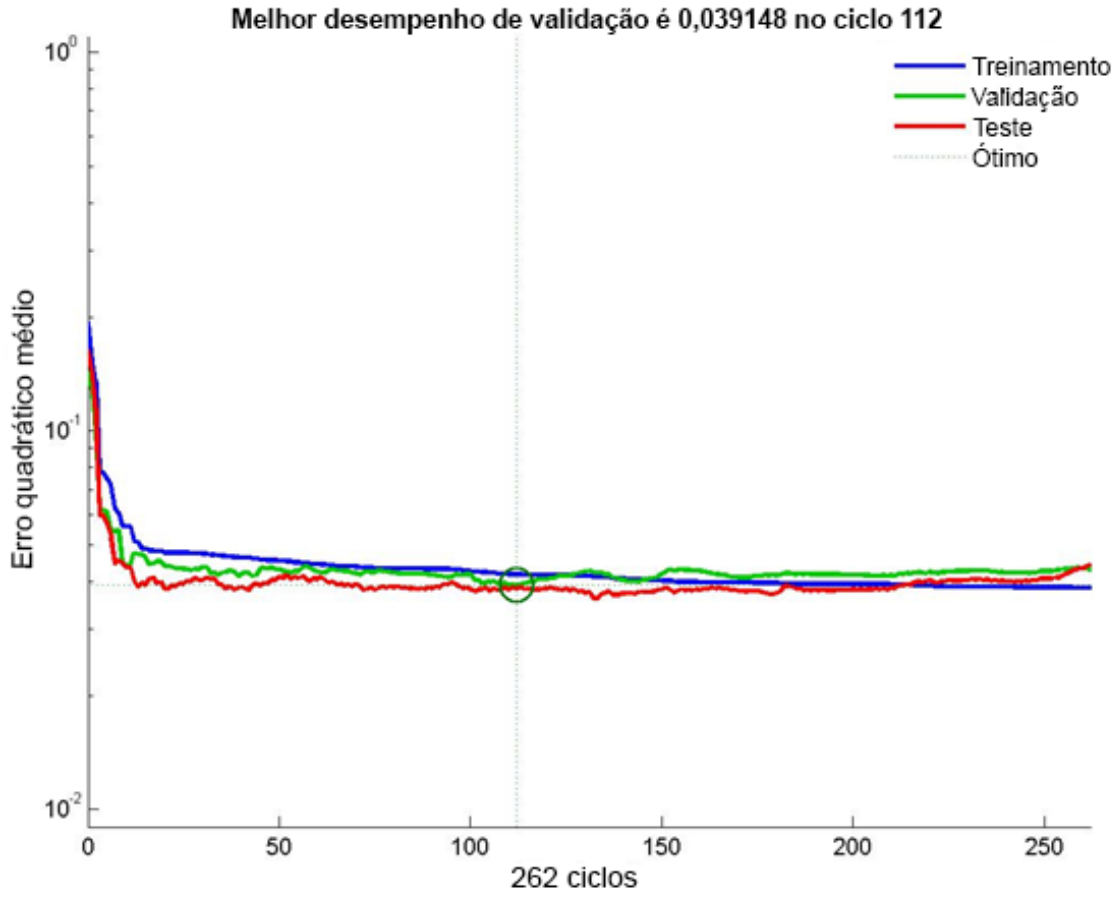

Figura 32: Gráfico do desempenho da rede neural MLP-mensal para previsão da concentração de MP_{10} da série 1.

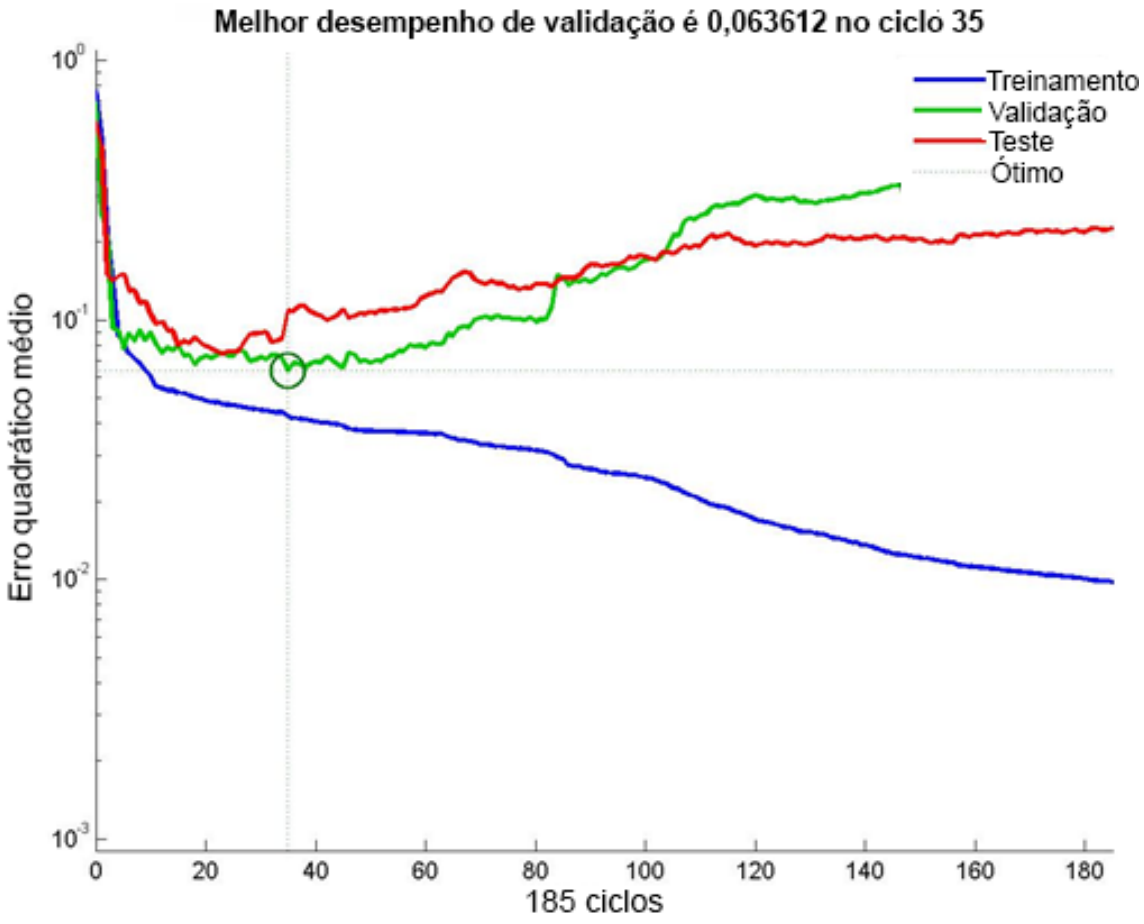

A MLP-mensal (Figura 32) apresenta uma piora do desempenho após o ciclo 35. Provavelmente a rede neural decorou os dados de treinamento. Neste caso, seria necessário encerrar o treinamento antecipadamente ou utilizar outras estratégias para melhorar o desempenho da rede, diminuindo o erro. Comparando com o desempenho da MLP-diária (Figura 31) é possível observar que, para os dados diários, isto não ocorre de maneira tão evidente, possivelmente por apresentar um número de dados disponíveis maior em relação ao número de médias mensais. No entanto, a rede MLP-mensal realizou de maneira mais eficiente a previsão da concentração do MP_{10} mensal, portanto, como foi citado anteriormente, por se tratar de dados de médias mensais, a rede conseguiu apresentar um desvio menor entre os dados medidos e previstos. Assim,

o conjunto de dados de entrada é primordial para o desempenho e eficiência da previsão da rede neural.

5.2.2 Modelo de redes neurais para a série 2 de dados para previsão diária e mensal de MP_{10}

Nesta seção serão apresentados os resultados da previsão de MP_{10} realizados para a série 2 de dados. Foram utilizadas três modelos de previsão, o primeiro utilizou uma rede neural MLP (perceptron de múltiplas camadas), apresentando como dados de entrada somente as variáveis climáticas dia anterior e como saída a previsão da concentração diária de MP_{10}, denominada MLP-1. A segunda teve como entradas a concentração de MP_{10} e os dados climáticos do dia anterior e como saída a previsão da concentração diária de MP_{10}, denominada de MLP-2. E ainda, foi utilizada a rede neural NARX (rede neural auto regressiva com entradas exógenas), apresentando como dados de entrada as variáveis climáticas e a concentração de MP_{10} do dia anterior e como saída a previsão da concentração diária de MP_{10}.

As Figuras 33 e 34 apresentam os resultados da previsão do MP_{10} pelas redes MLP-1 e MLP-2, respectivamente. A previsão realizada pela MLP-2, que possui como dado de entrada a concentração de MP_{10} do dia anterior, representa de maneira mais eficiente o conjunto de dados medidos de MP_{10}. A Figura 35 apresenta os resultados da previsão obtidos pela rede NARX. O ajuste dos dados de previsão foi mais eficiente na rede NARX, que os obtidos pela MLP-1 e MLP-2. Os dados de entrada da rede NARX foram normalizados conforme a Equação 1, antes da entrada na rede e como foi utilizado a *Toolbox Neural Network* do *MatLab* a saída da rede é apresentada com os valores normalizados de concentração variando de 0,1 a 0,9. A rede neural MLP-1 teve o resultado menos eficiente em comparação com as outras duas arquiteturas, os resultados da previsão de concentração de MP_{10} dessa arquitetura apresentaram apenas

concentrações medianas, não mostrando os valores de concentração extremos do conjunto de dados da série 2.

Figura 33: Comparação entre os valores medidos e previstos de MP_{10} pela rede MLP-1 para a série 2.

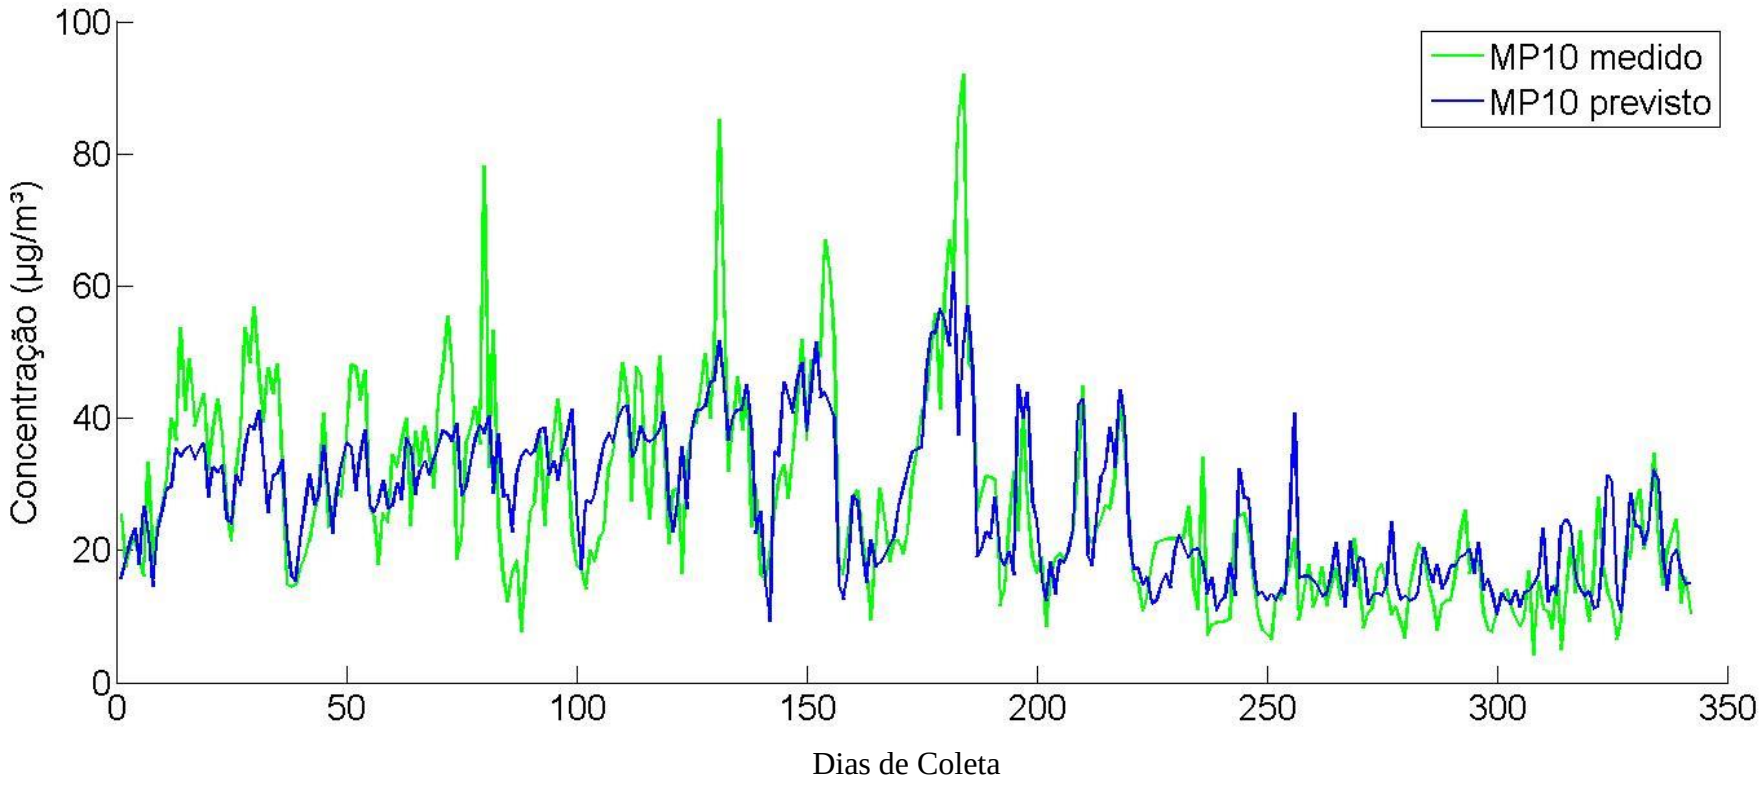

Figura 34: Comparação entre os valores medidos e previstos de MP_{10} pela rede MLP-2 para a série 2.

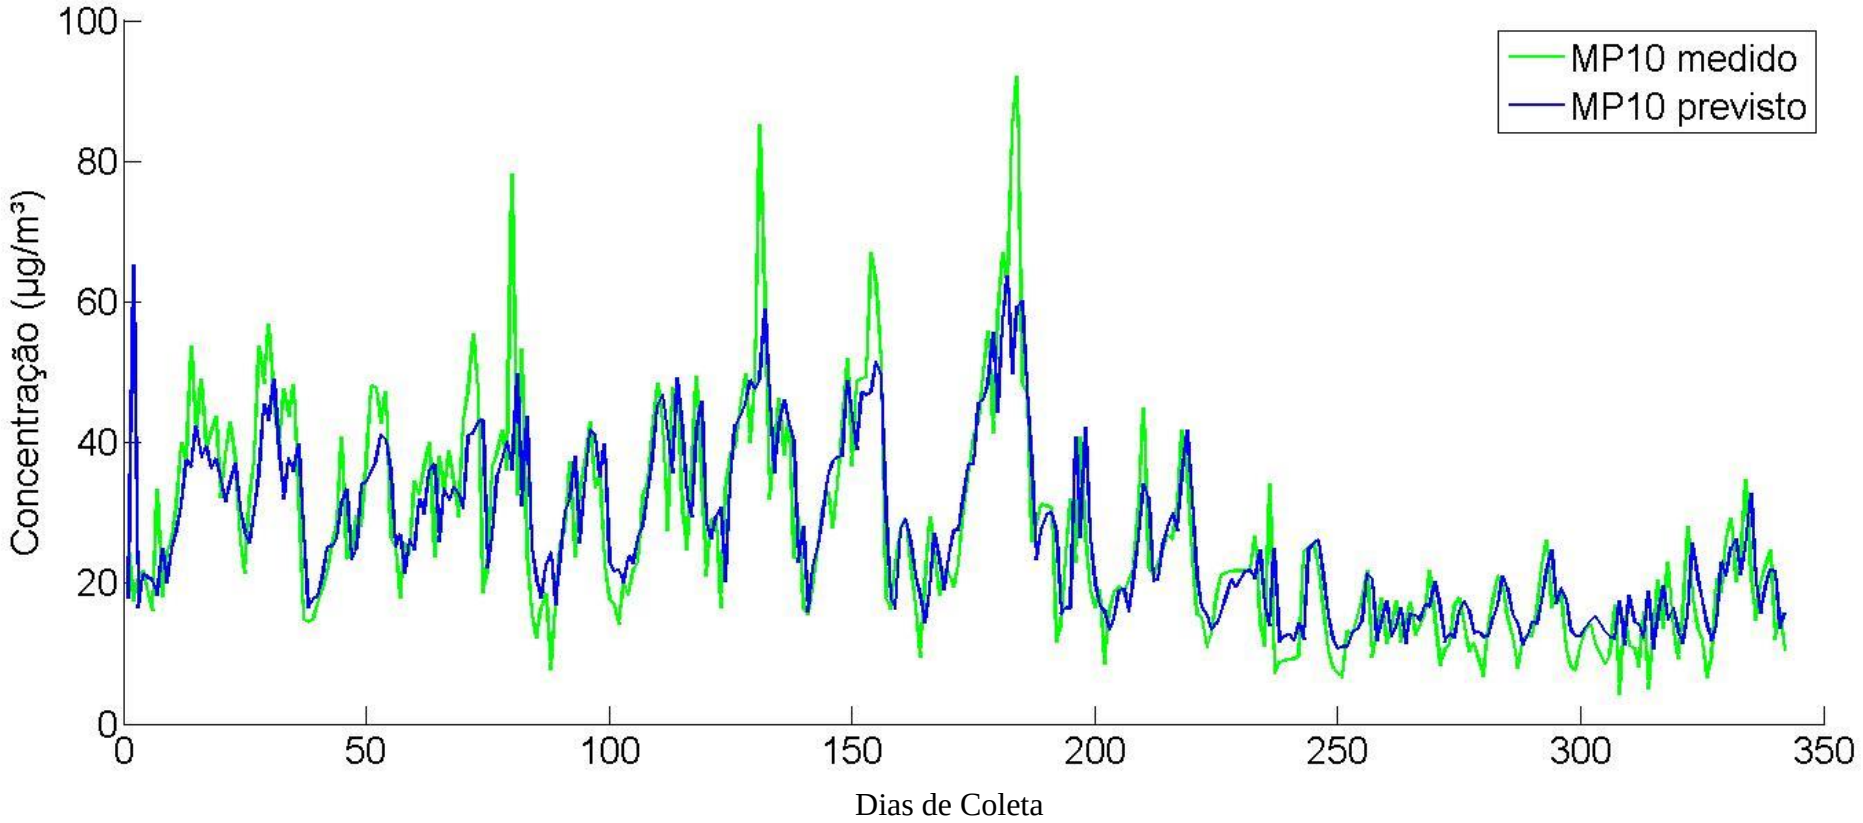

Figura 35: Gráficos das respostas da rede NARX de previsão do MP_{10} da série 2.

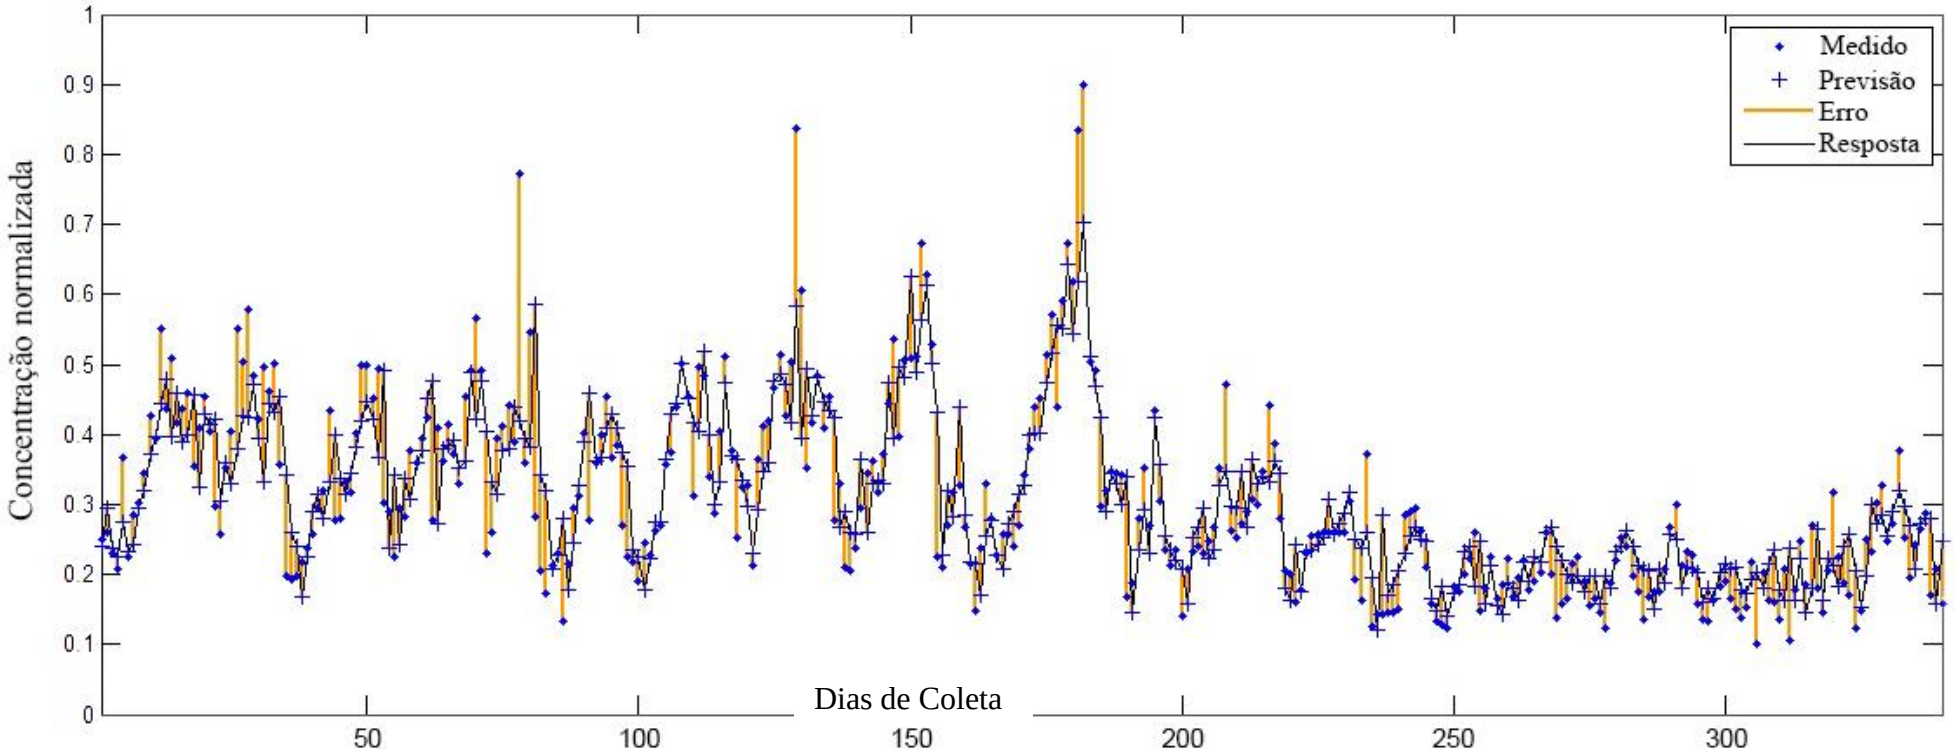

As Figuras 36, 37 e 38 apresentam gráficos de regressão comparando os valores medidos e previstos das redes MLP-1, MLP-2 e NARX, respectivamente, para o conjunto de dados da série 2, das fases de treinamento, validação, teste e do conjunto total de dados.

Figura 36: Gráficos de regressão das fases de treinamento (a), validação (b), teste (c) e de todos os dados (d) da rede MLP-1 de previsão do MP_{10} da série 2.

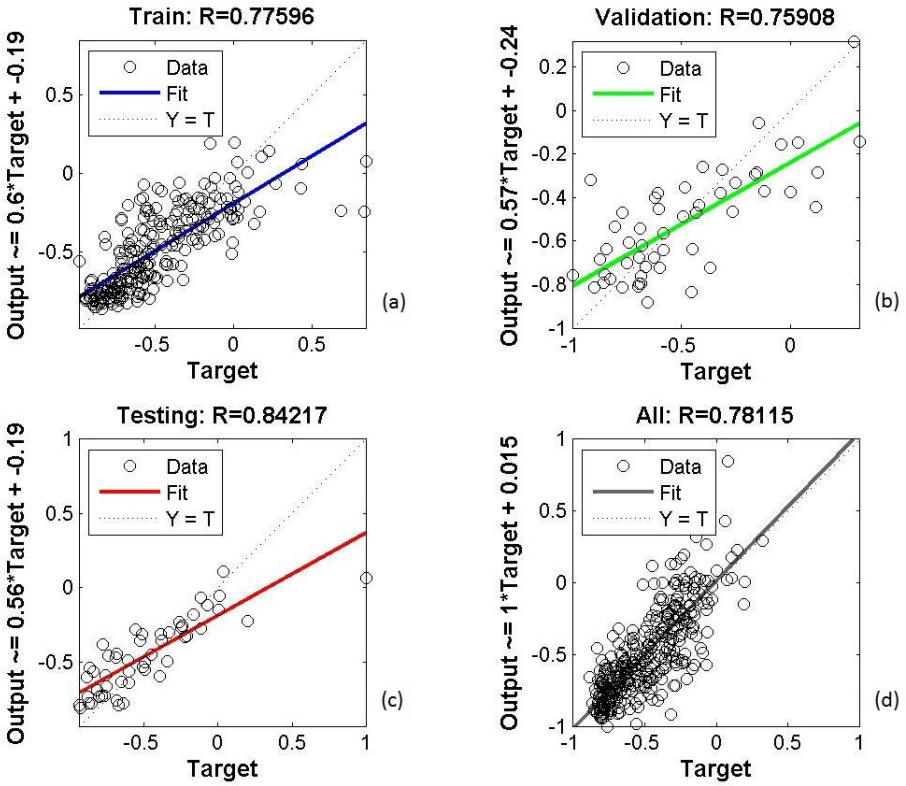

Comparando os gráficos de regressão da MLP-1 (Figura 36) e da MLP-2 (Figura 37) e da rede NARX (Figura 38) foi observado que a MLP-2 apresenta para a etapa de teste uma melhor eficiência, ou seja, o desvio entre os dados medidos e previstos é menor. No entanto, para as etapas de treinamento, validação e para o conjunto total de dados a rede NARX apresentou os melhores resuldados, corroborando com a necessidade da concentração do MP_{10} do dia anterior como dado de entrada ser importante para o aprendizado e generalização da rede, apesar da etapa de teste da NARX apresentar o resultado menos eficiente que as redes MLP.

Figura 37: Gráficos de regressão das fases de treinamento (a), validação (b), teste (c) e de todos os dados (d) da rede MLP-2 de previsão do MP_{10} da série 2.

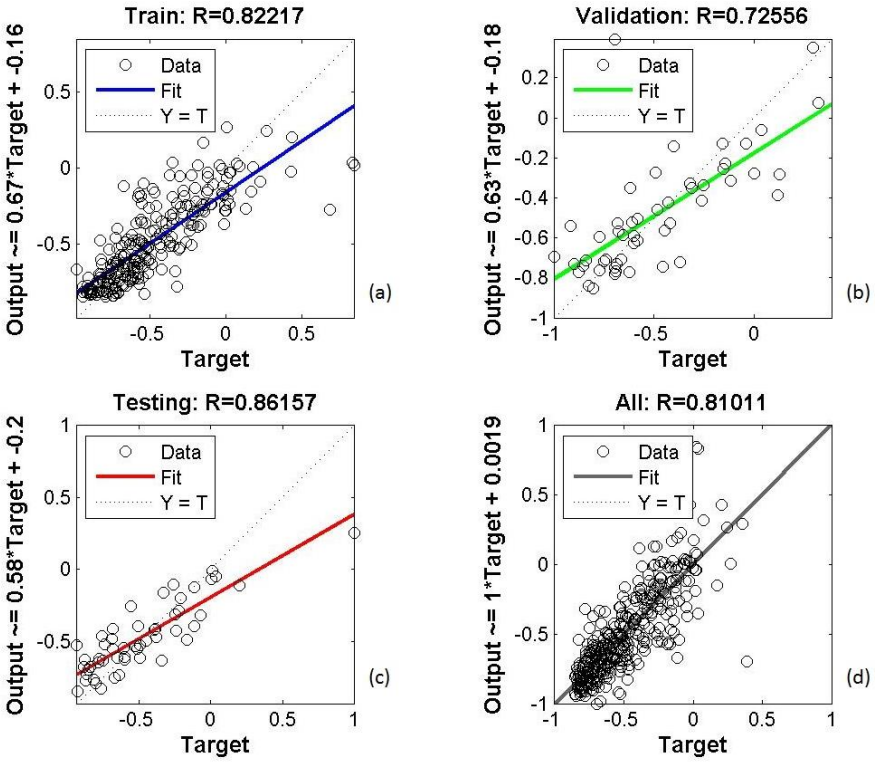

Figura 38: Gráficos de regressão das fases de treinamento (a), validação (b), teste (c) e de todos os dados (d) da rede NARX para previsão do MP_{10} da série 2.

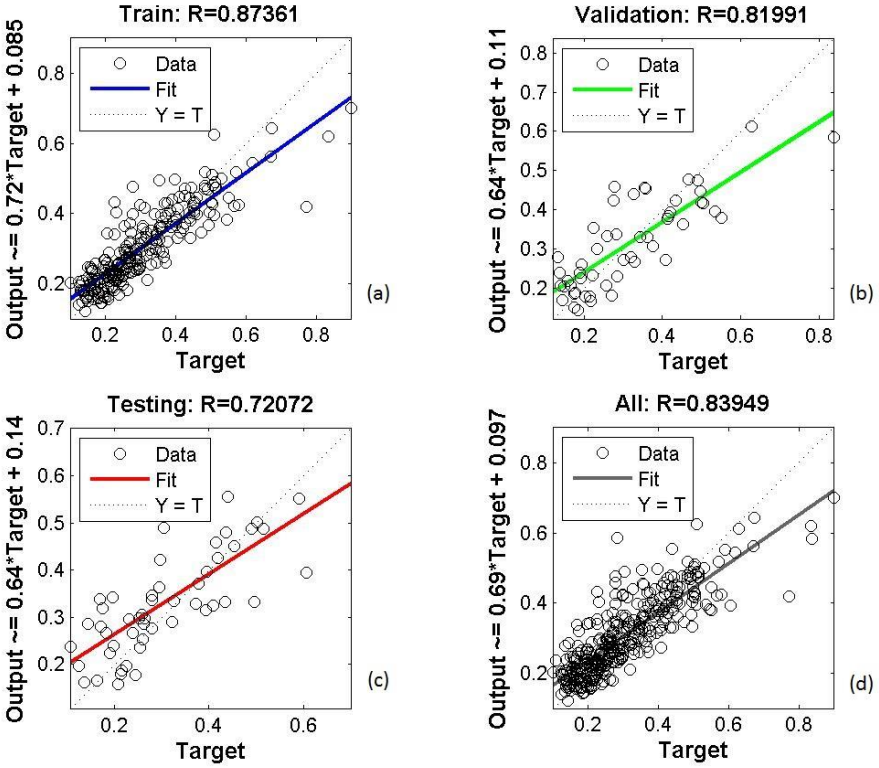

A divisão dos dados para treinamento, validação e teste ocorre de maneira aleatória durante a etapa de execução da rede neural. Por conta disso, a cada nova execução os resultados apresentam pequena variação, seguindo o mesmo padrão, mas com modificação dos valores. Como os dados da série 2 utilizados para as redes MLP-1, MLP-2 e NARX são compostos de apenas um ano de coleta, apesar de serem coletas diárias, a variação dos resultados pode ser mais representativa, devido a diferenciação entre as estações seca e chuvosa em São Carlos. Se, durante o processo de divisão dos dados, o treinamento apresentar, por exemplo, uma quantidade maior de dados de uma das estações, seca ou chuvosa, os dados da outra estação serão utilizados para as fases de validação e teste da rede neural. Para uma maior eficiência no processo de generalização da rede neural é importante à continuação da coleta de dados.

As Figuras 39, 40 e 41apresentam os gráficos de desempenho durante a etapa de validação, para os modelos da MLP-1, MLP-2 e NARX, respectivamente, para os dados da série 2.

Figura 39: Gráfico do desempenho da etapa de validação da rede MLP-1 para previsão da concentração de MP_{10} da série 2.

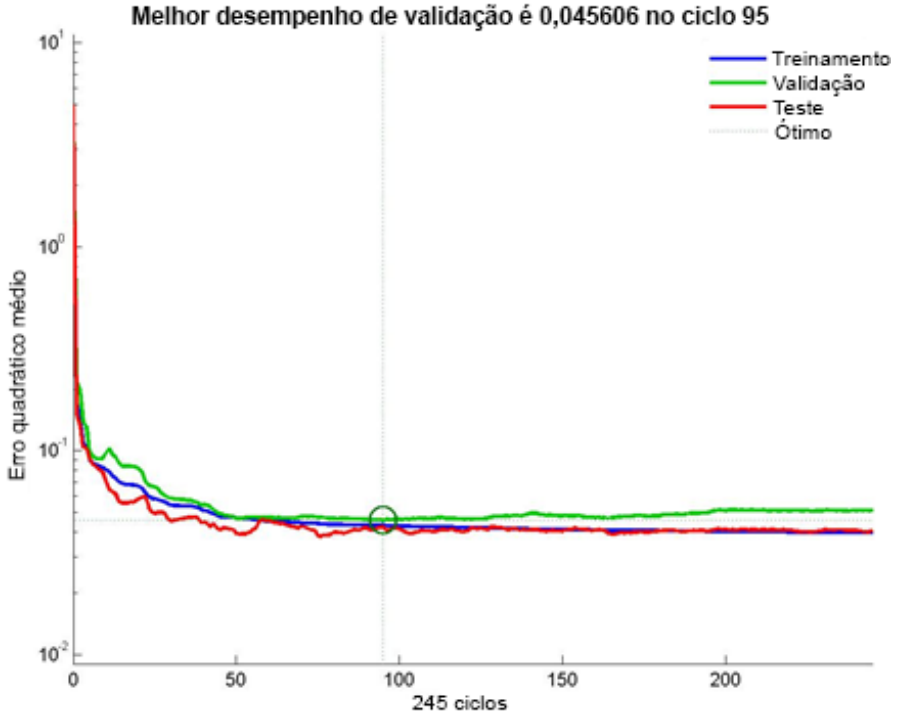

Figura 40: Gráfico do desempenho da etapa de validação da rede MLP-2 para previsão da concentração de MP_{10} da série 2.

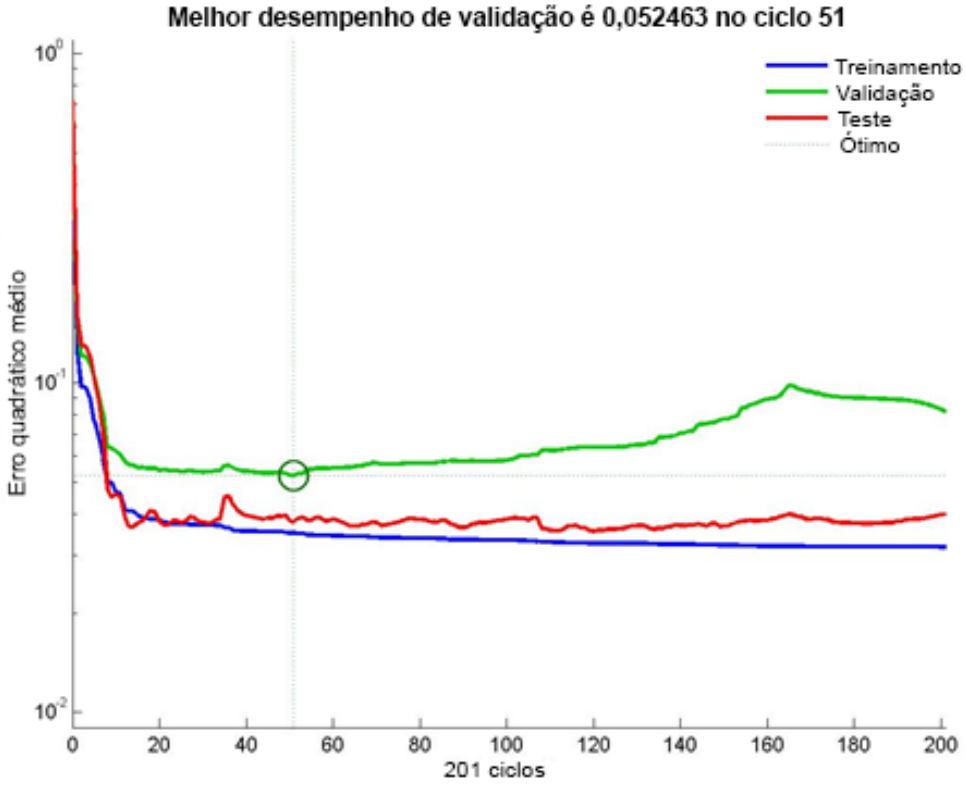

A Figura 39 apresenta o menor erro de validação com convergência na iteração 95 referente aos dados da série 2, atuais para o modelo MLP-1 que não possui a entrada de MP-10 do dia anterior. A Figura 40 apresenta o menor erro de validação na iteração 51, para e rede neural MLP-2, que possui a concentração do MP_{10} do dia anterior como neurônio de entrada. E a rede neural NARX (Figura41) apresenta o menor erro de validação na iteração 12, portanto, a NARX apresenta a convergência mais rápida, além do erro ser de 0,007, enquanto os modelos MLP-1 e MLP-2 apresentam erros de 0,046 0,052, respectivamente.

Figura 41: Gráfico do desempenho da rede neural do tipo NARX para previsão da concentração de MP_{10} da série 2.

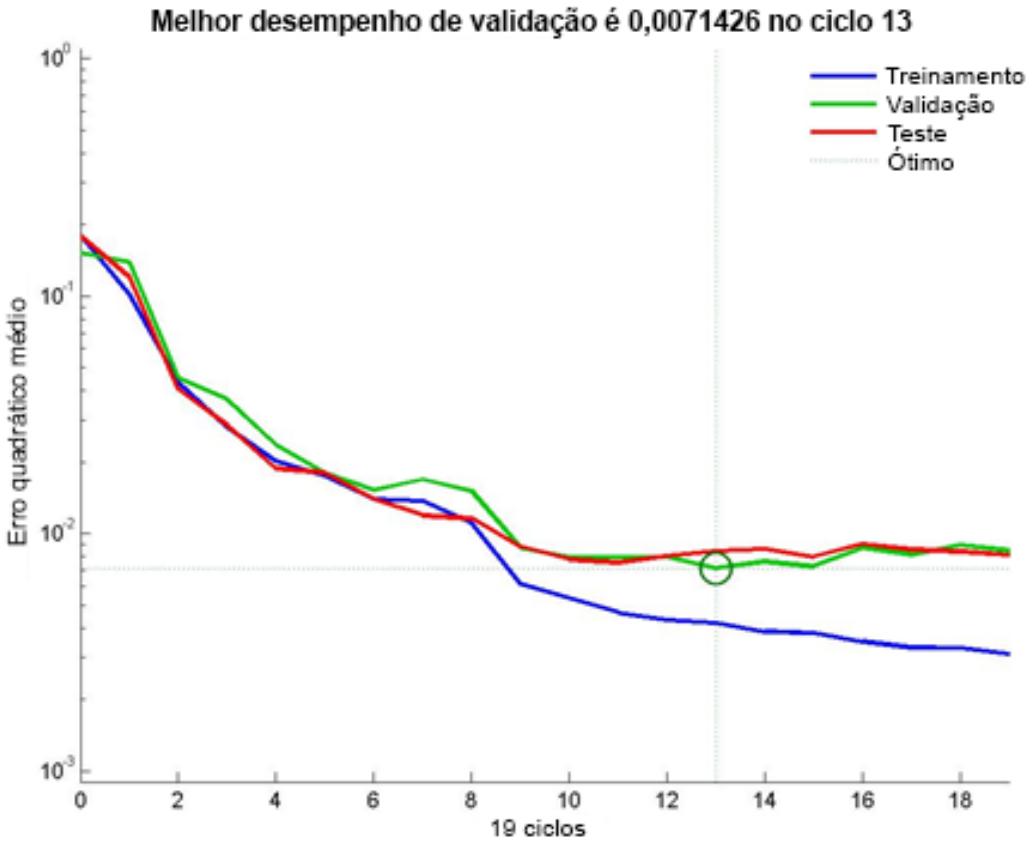

O melhor desempenho foi conseguido com a rede NARX, apresentando os menores valores de erro e o menor empenho computacional, sendo alcançado o melhor valor no ciclo 13. Comparando os modelos MLP-1 e MLP-2, o segundo apresentou resultados melhores quando comparado ao primeiro, mostrando neste caso, também, a importância de apresentar o dado de concentração de MP_{10} como um neurônio de entrada da rede para obtenção de melhores resultados.

A Tabela 4 apresenta os valores médios de erro absoluto da concentração de MP_{10} para os modelos de previsão criados para a série 2 de dados.

Tabela 4: Valores comparativos de erro absoluto dos modelos de previsão da série 2 de dados.

	MLP-1	MLP-2	NARX
Erro médio absoluto	6,52	6	7,13

A rede neural MLP-2 apresenta o menor valor de erro absoluto médio (6) para previsão da concentração de MP_{10}, enquanto o modelo utilizando a rede NARX apresenta o valor mais elevado de erro absoluto (7,13). A rede NARX apresenta uma convergência mais rápida, com os menores desvios de previsão na validação, sendo está estrutura a mais indicada para o presente estudo de caso.

6. CONCLUSÃO

Neste trabalho, foram coletados dados diários de material particulado (MP_{10}) pelo período de um ano e comparados com dados históricos disponíveis para a cidade de São Carlos-SP. Comparando os dados disponíveis para a série 1 (1997-2005) e da série 2 (2014-2015) foi verificado decréscimo dos valores de concentração do MP_{10} ao longo do tempo. Novas tecnologias, menos poluentes nas indústrias e veículos e as leis ambientais mais rígidas são, provavelmente, os fatores desencadeantes para este fato.

A legislação federal, Resolução CONAMA 03/1190, não teve seu limite diário ultrapassado durante a coleta de dados da série 2, que é de 150 µg/m³. No entanto, a Organização Mundial da Saúde (OMS) estabelece como limite máximo a média diária de 50 µg/m³, valor que foi ultrapassado em 18 dias de coleta, todos no período seco, que corresponde a época do inverno.

Para os dados da série 1 foram criados dois modelos de previsão, MLP-diária e MLP-mensal, ambos apresentando como neurônios de entrada dados climáticos e como saída a concentração de MP_{10}. O modelo MLP-mensal apresentou resultados mais eficientes de previsão, como foram utilizados valores médios mensais dos dados na rede é mais fácil prever do que os picos de máximo ou mínimo de médias diárias. O erro médio absoluto da MLP-mensal foi de 5,1, enquanto da MLP-diária de 9,2. Apesar da série 1 apresentar um conjunto de dez anos de dados de material particulado, o monitoramento não era contínuo, o que influência na eficiência do modelo de previsão.

Para o conjunto de dados da série 2,as redes MLP-2 e NARX, que apresentam como um neurônio de entrada a concentração de material particulado (MP_{10}) do dia anterior, apresentaram resultados mais eficientes que a MLP-1 que apresenta como dados de entrada apenas as variáveis climáticas. Sendo que o modelo que utiliza a rede neural do tipo NARX apresenta os resultados mais eficientes.

7. SUGESTÕES PARA TRABALHOS FUTUROS

Continuação da coleta de dados de material particulado para avaliações mais efetivas da sua evolução ao longo do tempo.

Associação dos níveis de concentração de material particulado com atendimentos hospitalares de doenças respiratórias.

Análise detalhada para determinação das variáveis climáticas que tem maior interferência na concentração de material particulado.

Colocar uma ou mais entradas na rede referente a concentração MP_{10} da mesma data, mas de um período (ano ou anos) anterior, uma vez que espera-se uma repetição aproximadamente cíclica dos fenômenos climáticos locais e da dspersão do material particulado.

8. REFERÊNCIAS BIBLIOGRÁFICAS

[ABNT] Associação Brasileira de Normas Técnicas, 1995. Material particulado em suspensão na atmosfera – Determinação da concentração de partículas inaláveis pelo método do amostrados de grande volume acoplado a um separador inercial de partículas – Método de ensaio – NBR 13412. Rio de Janeiro: ABNT.

[ABNT] Associação Brasileira de Normas Técnicas, 1997. Material particulado em suspensão no ar ambiente – Determinação da concentração total pelo método do amostrador de grande volume – NBR 9547. Rio de Janeiro: ABNT.

ALEXANDRINA, E. C. *Caracterização e composição química do material particulado grosso (MP_{10}) no centro da cidade de São Carlos (SP)*. Dissertação (Mestrado) – Universidade Federal de São Carlos, 2015.

BASCOM, R. Health effects of outdoor air pollution. *American Journal of Respiratory and Critical Care Medicina*, v. 153, n. 1, p. 3-50, 1996.

BASCOM, L. R. Material particulado atmosférico na cidade de São Carlos-SP: quantificação e identificação de fontes Tese (Doutorado) – Universidade Federal de São Carlos, 2005.

BRASIL. Ministério do Meio Ambiente, Conselho Nacional de Meio Ambiente, CONAMA. **Resolução CONAMA nº 03**, de 28 de junho de 1990. – In: Resoluções, 1990.

CASTANHO, A; ARTAXO, P. Wintertime and summertime São Paulo aerosol source apportionment study. *Atmospheric Environment*. Elsevier, v. 35, n. 29, p. 4889-4902, 2001.

CELLI, C. E. *Monitoramento do material particulado respirável suspenso na atmosfera no centro da cidade de São Carlos-SP*. Dissertação (Mestrado) – Universidade Federal de São Carlos, 1999.

CETESB. *Comparaçao entre os períodos de safra e entressafa de cana-de-açúcar*.[S.l.], 2000.

CHALOULAKOU, A. et al. Particulate matter and black smoke concentration levels in central Athens, Greece. *Environment International*, Elsevier, v. 31, n. 5, p. 651-659, 2005.

COLLETT, R. S.; ODUYEMI, K. Air quality modelling: a technical review of mathematical approaches. *Meteorological Applications*, Wiley Online Library, v. 4, n. 3, p. 235-246, 1997.

COMRIE, A. Comparing neural network and regression models for ozone forecasting. *Journal of the Air and Waste Management Association*, v.47, n. 6, p. 653-663, 1997.

CORANI, G. Air quality prediction in Milan: feed-forward neural networks, pruned neural networks and lazy learning. *Ecological Modeling*, Elsevier, v. 185, n. 2-4, p. 513-529, 2005.

FERNANDO, H. et al. Forecasting PM_{10} in metropolitan areas: efficacy of neural networks. *Environmental Pollution*, Elsevier, v. 163, p. 62-67, 2012.

FINZI, G.; TEBALDI, G. A mathematical model for air pollution forecast and alarm in na urban area. *Atmospheric Environment (1967)*, Elsevier, v. 16, n. 9, p. 2055-2059, 1982.

GOYAL, P.; CHAN, A.; JAISWAL, N. Statistical models for the prediction of respirable suspended particulate matter in urban cities. *Atmospheric Environment*, Elsevier, v. 40, n. 11, p. 2068-2077, 2006.

GRIVAS, G.;CHALOULAKOU, A. Artificial neural network models for prediction of PM_{10} hourly concentrations, in the greater area os Athens, Greece. *Atmospheric Environment*, Elsevier, v. 40, n. 7, p. 1216-1229, 2006.

HAYKIN, S. Redes neurais: princípios e aplicações. Segunda edição. Porto Alegre, 2001.

HORNIK, K. Approximation capabilities of multilayer feedforward networks. *Neural Networks*, Elsevier, v. 4, n. 2, p. 251-257, 1991.

HORNIK, K. Some new results on neural network approximation. *Neural Networks*, Elsevier, v. 6, n. 8, p. 1069-1072, 1993.

JAKEMAN, A.; SIMPSON, R.; TAYLOR, J. Modeling distributions of air pollutant concentrations: th hybrid deterministic-statistical distribution approach. Atmospheric Environment (1967), Elsevier, v. 38, n. 40, p. 7055-7064, 2004.

JIANG, D. et al. Progress in developing na ANN model for air pollution index forecast. *Atmospheric Environment*, ELsevier, v. 38, n. 40, p. 7055-7064, 2004.

KOLEHMAINEN, M.; MARTIKAINEN, H.; RUUSKANEN, J. Neural networks and periodic components used in air quality forecasting. *Atmospheric Environment*, Elsevier, v. 35, n. 5, p. 815-825, 2001.

KUKKONEN, J. et al. Extensive evaluation of neural network models for the prediction of NO_2 and PM_{10} concentrations, compared with a deterministic modeling system and measurements in central Helsinki. *Atmospheric Environment*, Elsevier, v. 37, n. 32, p. 4539-4550, 2003.

LIRA, T.S. de. *Modelagem e previsão da qualidade do ar na cidade de Uberlândia-MG*. Tese (Doutorado) – Universidade Federal de Uberlândia, 2009.

MARQUES, K. A. Caracterização do material particulado suspenso na atmosfera da cidade de São Carlos. Dissertação (Mestrado) – Universidade Federal de São Carlos, 2000.

MARTINS, J.; DIAS, M.; GONÇALVEZ, F. Impact of biomass burning aerosols on precipitation in the Amazon: a modeling case study. *Journal Geophys Research*, v. 114, p. D02207.

MAXWELL, K. H..; WHIT, H. Multilayer feedforward networks are universal approximators, *Neural Networks*, Elsevier, v. 2, n. 5, p. 359-366, 1989.

MUES, A. et al. Difference in particulate matter concentratons between urban and rural regions under current and changing climate conditions. *Atmospheric Environment*, Elsevier, 2013.

NEJADKOORKI, F.; BAROUTIAN, S. Forecasting extreme PM_{10} concentrations using artificial neural networks. *International Journal of Environment Research*, v. 6, n.1, p. 277-284, 2012.

ORDIERES, J. et al. Neural network prediction model for fine particulate matter ($PM_{2,5}$) on the US-Mexico border in El Paso (Texas) and Ciudad Juarez (Chihuahua). *Environmental Modelling and Software*, Elsevier, v. 20, n. 5, p. 547-559, 2005.

PEREZ, P. Combined model for PM_{10} forecasting in a large city. *Atmospheric Environment*, Elsevier, v. 60, p. 27-276, 2012.

PEREZ, P.; REYES, J. Prediction of maximum of 24 h PM_{10} cncentrations 30 h in advance in Santiago, Chile. *Atmospheric Environment*, Elevier, v. 36, n. 28, p. 4555-4561, 2002.

PEREZ, P.; REYES, J. An integrated neural network model for PM_{10} forecasting. *Atmospheric Environment*, Elsevier, v. 40, n. 16, p. 2845-2851, 2006.

PEREZ, P.; TRIER, A.; REYES, J. Prediction of $PM_{2,5}$ concentrations several hours in advance using neural networks in Santiago, Chile. Atmospheric Environment, Elsevier, v. 34, n. 8, p. 1189-1196, 2000.

PIKRIDAS, M. et al. Characterization of the origin of fine particulate matter in a medium size urban area in the Mediterranean. *Atmospheric Environment*, Elsevier, 2013.

POLYDORAS, G.; ANAGNOSTOPOULOS, J.; BERGELES, G. Air quality predictions: dispersion model vs box-jenkins stochastic models. Na implementation and comparison for Athens, Greece. Applied Thermal Engineering, Elsevier, v. 18, n. 11, p. 1037-1048, 1998.

POZZA, S. A. *Identificação das fontes de poluição atmosférica na cidade de São Carlos-SP*. Dissertação (Mestrado) – Universidade Federal de São Carlos, 2005.

POZZA, S. A. *Características temporais da concentração de material particulado na atmosfera da cidade de São Carlos-SP*. Tese (Doutorado) – Universidade Federal de São Carlos, 2009.

POZZA, S. A. et al. Identificação de possíveis fontes de oluição atmosférica na cidade de São Carlos. In: *Anais do 9º Simpósio Internacional da Qualidade Ambiental*. Porto Alegre: [s.n.], 2004.

RUMELHART, D.; HINTONT, G.; WILLIAMS, R. Learning representations by back-propagaing errors. *Nature*, London, v. 323, n. 6088, p. 533-536, 1986.

RUSSO, A.; RAISCHEL, F.; LIND, P. G. Air quality prediction using optimal neural networks with stochastic variables. *Atmospheric Environment*, Elsevier, 2013.

SALDIVA, P. et al. Respiratory alteration due to urban air pollution: na experimental study in rats. *Environment Research*, Elsevier, v. 57, n. 1, p. 19-33, 1992.

SÃO PAULO. Decreto nº 59113, de 23 de abril de 2013. Estabelece novos padrões de qualidade do ar e dá providências correlatas.

SANTOS, T. C.; CARVALHO, V. S. D.; REBOITA, M. S. Avalição da influência das condições meteorológicas em dias com altas concentraçãoes de material particulado na

Região Metropolitana do Rio de Janeiro. *Engenharia Sanitária e Ambiental*, v. 21, n. 2. 2016.

SHARDA, R. Neural networks for the MS/OR analyst: an application bibliography. Interfaces, *JSTOR*, p. 116–130, 1994.

SINGH, K. P. et al. Linear and nonlinear modeling approaches for urban air quality prediction. *Science of the Total Environment*, Elsevier, v. 426, p. 244–255, 2012.

STERNBECK, J.; SJÖDIN, A.; ANDRÉASSON, K. Metal emissions from road traffic andthe influence of resuspension–results from two tunnel studies. *Atmospheric Environmen*t, Elsevier, v. 36, n. 30, p. 4735–4744, 2002.

USEPA. PM2:5 NAAQS Implementation. [S.l.], 1997.

WANG, C. et al. Estimation of the effects of ambient air pollution on life expectancy of urbanresidents in china. *Atmospheric Environment*, Elsevier, v. 80, p. 347–351, 2013.

WATSON, J.; CHOW, J. Source characterization of major emission sources in the Imperialand Mexicali valleys along the US/Mexico border. *The Science of the Total Environment*,Elsevier, v. 276, n. 1-3, p. 33–47, 2001.

YI, J.; PRYBUTOK, V. R. A neural network model forecasting for prediction of daily maximumozone concentration in an industrialized urban area. *Environmental Pollution*, Elsevier,v. 92, n. 3, p. 349–357, 1996.

ZENNETTI, P. Air pollution modeling–Theories, Computational Methods and Available

Software. [S.l.]: *Computational Mechanics Publications*, 1990.

ZHANG, G.; PATUWO, B. E. et al. Forecasting with artificial neural networks::: The state ofthe art. *International Journal of Forecasting*, Elsevier, v. 14, n. 1, p. 35–62, 1998.

ZIOMAS, I. et al. Forecasting peak pollutant levels from meteorological variables. *AtmosphericEnvironment*, Elsevier, v. 29, n. 24, p. 3703–3711, 1995.

APÊNDICE A – Cálculo de concentração (correção vazão)

O volume de ar amostrado, corrigido para condições padrão (25°C e 760 mmHg), foi determinado a partir da vazão medida e do tempo de amostragem.

$$C_{MP_{10}} = (10^6)\frac{M_1}{V_P} \qquad \text{Equação A1}$$

Em que:

C_{MP10} = concentração (µg/m³)

M_1 = massa acumulada (g)

V_P = volume amostrado em unidade padrão (m³)

10^6 = fator de conversão (µg/g)

Em que V_p é dado pela expressão

$$V_P = Q_P * (t) \qquad \text{Equação A2}$$

Em que:

V_p = volume total amostrado em unidade padrão (m³)

Q_p = vazão média corrigida para condições padrão (m³/min)

t = tempo de amostragem (min)

Q_p foi obtida pela seguinte equação

$$Q_R = Q_P\left(\frac{P_B}{P_P}\right)\left(\frac{T_P}{T_M}\right) \qquad \text{Equação A3}$$

Em que:

Q_p = vazão volumétrica padrão (m³/min)

Q_R = vazão volumétrica real (m³/min)

P_B = pressão barométrica média (mmHg)

T_M = temperatura média (K)

P_P = pressão padrão (760 mmHg)

T_P = temperatura padrão (298 K)

O AGV é projetado para trabalhar a uma vazão controlada em torno de 1.13 m³/min em condições reais de temperatura e pressão. Teoricamente, a vazão pode variar na faixa de 1.02 a 1.24 m³/min.. No entanto, para garantia da qualidade, essa faixa é reduzida para 1.05 a 1.21 m³/min.

$$P_0 = P_{atm} - dH_F \qquad \text{Equação A4}$$

Em que:

P_0 = pressão de estagnação (abaixo do filtro) (cmH_2O)

P_{atm} = pressão atmosférica (cmH_2O)

dH_F = pressão diferencial lida no manômetro (cmH_2O)

$$Q_R = \frac{1}{a_2}\left[\left(\frac{P_0}{P_B} - b_2\right)\sqrt{T_m}\right] \qquad \text{Equação A5}$$

a_2 e b_2 são parâmetros obtidos na calibração

APÊNDICE B – Calibração do equipamento AGV-MP_{10}

A calibração foi realizada com a cabeça do AGV aberta. Foi necessário remover a moldura de aperto da porta filtro e instalar a placa adaptada do CPV (calibrador padrão de vazão). A calibração foi realizada sem filtro, foram instaladas as placas de resistência sobre a sede circular da placa adaptadora e montado o copo de orifício sobre a placa de resistência.

O manômetro de calibração foi conectado à tomada de pressão do copo de orifício. Após esses procedimentos e a instalação de uma carta no registrador o aparelho foi ligado por pelo menos 5 min para obter o equilíbrio térmico. Então foram realizadas as leituras nos dois manômetros, pressão diferencial no "filtro" (dH_F) lida no manômetro de 800 mm e pressão diferencial do calibrador (dH_C) lida no manômetro de 400 mm. Os valores foram anotados na planilha de cálculo e os procedimentos repetidos para cada placa.

Conversão do valor de dH_F lido em cmH_2O para mmHg:

$$mmHg = \frac{cmH_2O}{1{,}36} \qquad \text{Equação B1}$$

Cálculo da pressão de estagnação (P_0):

$$P_0 = P_2 - dH_F \qquad \text{Equação B2}$$

Em que:

P_0 = pressão de estagnação (mmHg)

P_2 = pressão ambiente (mmHg)

Cálculo da taxa de pressão de estagnação

$$\frac{P_0}{P_2} = \left(1 - \frac{dH_F}{P_2}\right)$$ Equação B3

Cálculo da vazão real Q_R (CPV):

$$Q_R(CPV) = \frac{1}{a_1}\left[\sqrt{dH_c \frac{T_2}{P_2}} - b_1\right]$$ Equação B4

Cálculo da reta de calibração:

$$\frac{P_0}{P_2} = a_2\left[\frac{Q_R(CPV)}{\sqrt{T_2}}\right] + b_2$$ Equação B5

Em que:

a_2 = inclinação da relação de calibração, a ser obtida na regressão linear

b_2 = intercepto da relação de calibração, a ser obtido por regressão linear

$$X = \frac{Q_R(CPV)}{\sqrt{T_2}}$$ Equação B6

$$Y = \frac{P_0}{P_2}$$ Equação B7

$$Y = a_2 X + b_2$$ Equação B8

Onde a inclinação é dada por:

$$a = \frac{\sum_{i=1}^{n} XY - X\sum_{i=1}^{n} Y}{\sum_{i=1}^{n} X^2 - X\sum_{i=1}^{n} X}$$ Equação B9

E o intercepto é dado por:

$$b = Y - aX$$ Equação B10

APÊNDICE C – Rede Neural MLP

```
[numbers, strings] = xlsread('dados_bdmep.xlsx','dados');

inputs = numbers(1:342,:);
outputs = numbers(2:343,5);

inputs = inputs';
outputs = outputs';
%A entrada da rede precisa de dados mapeados de -1 até 1
%A funçaomapminmax(dados,intervalominimo,intervalomaximo) faz isso
%As variaveismapedinputs e mapedoutputs são os dados finais mapeados
de
%-1 até 1, e as variaveismapinp e mapout são os parametros usados pra
%realizar o mapeamento, eles serão necessários depois para desmapear a
%resposta da rede
[mapedinputs,mapinp]=mapminmax(inputs,-1,1);
[mapedoutputs,mapout]=mapminmax(outputs,-1,1);


error = 0; % erro (criterio de parada)
spread = 1;     % desvio padrao
maxneuron = 15; % numero maximo de neuronios
df = 40; % numero de neuronios p/ add entre os displays

%net = newrb(inputs,outputs,error,spread,maxneuron,df);  %
definindorede neural rbf

%-------------------------------------------------------------------
----
%--------------------------------Parametros de Rede-----------------
---
%-------------------------------------------------------------------
---


%Redes muito grandes podem memorizar o dataset
net = newff(mapedinputs,mapedoutputs, [10 10]); %altera número de
neurônios na camada oculta

net.layers{1}.transferFcn = 'tansig';  %altera a função das camadas
(tansig, logsig, purelin)
net.layers{2}.transferFcn = 'tansig';
%net.layers{3}.transferFcn = 'tansig';
net = init(net); % inicializa os pesos e os bias
net.trainFcn = 'trainscg';
%net.divideFcn = 'dividerand';
net.divideFcn = 'divideint';
net.divideParam.trainRatio = 0.70;
net.divideParam.testRatio = 0.15;
net.divideParam.valRatio = 0.15;
net.trainParam.epochs = 2000;

%---------------------Validationchecks aumentado-------------------
% Maximo de falhas antes de regredir a rede para o ponto de melhor
% performance de teste
%-------------------------------------------------------------------
net.trainParam.max_fail=150;
```

```
%Treinamento
[net,tr] = train(net, mapedinputs, mapedoutputs);


%Simulando Rede
Sout=sim(net,mapedinputs);
%Desmapeando Resposta da Rede
[DeMapedResponse,PS]=mapminmax('reverse',Sout,mapout);
Error=abs(outputs-DeMapedResponse);
MediaErroAbs=mean(Error);

disp('Erro Absoluto Médio');
MediaErroAbs

%Plotando Resposta
figure(1)
plot(Error,'r')
title('Serie Temporal Do Erro Absoluto')
figname = 'erro_absoluto_mlp_mp';
saveas(gcf, figname, 'fig');
saveas(gcf, figname, 'jpg');

figure(2)
hold on
plot(outputs,'g')
plot(DeMapedResponse,'b')
title('Verde (Resposta Desejada), Azul (Resposta da Rede)')
hold off
figname = 'resposta_mlp_mp';
saveas(gcf, figname, 'fig');
saveas(gcf, figname, 'jpg');


AllOutputs = net(mapedinputs);
trOut = AllOutputs(tr.trainInd);
vOut = AllOutputs(tr.valInd);
tsOut = AllOutputs(tr.testInd);
trTarg = mapedoutputs(tr.trainInd);
vTarg = mapedoutputs(tr.valInd);
tsTarg = mapedoutputs(tr.testInd);

figure(3)
plotperform (tr)
figname = 'perform';
saveas(gcf, figname, 'fig');
saveas(gcf, figname, 'jpg');

figure(4)
plotregression(trTarg,trOut,'Train',vTarg,vOut,'Validation',tsTarg,tsO
ut,'Testing',AllOutputs,mapedoutputs,'All')
figname = 'regression_mlp_mp';
saveas(gcf, figname, 'fig');
saveas(gcf, figname, 'jpg');

view(net);
%figure, plotperform(tr)
figure(5), plotperform(tr)
figname = 'performance_mlp_mp';
saveas(gcf, figname, 'fig');
```

```
saveas(gcf, figname, 'jpg');

%figure, plottrainstate(tr)
figure(6), plottrainstate(tr)
figname = 'trainstate_mlp_mp';
saveas(gcf, figname, 'fig');
saveas(gcf, figname, 'jpg');

%figure, ploterrhist(errors)
figure(7), ploterrhist(errors)
figname = 'errors_mlp_mp';
saveas(gcf, figname, 'fig');
saveas(gcf, figname, 'jpg');
```

APÊNDICE D – Rede Neural NARX

```
% Solve an Autoregression Problem with External Input with a NARX
Neural Network
% Script generated by NTSTOOL%
% This script assumes these variables are defined:
%
%   in - input time series.
%   out - feedback time series.

load in;
load out;

inputSeries = tonndata(in,false,false);
targetSeries = tonndata(out,false,false);

% Create a Nonlinear Autoregressive Network with External Input
inputDelays = 1:2;
feedbackDelays = 1:2;
hiddenLayerSize = 10;
net = narxnet(inputDelays,feedbackDelays,hiddenLayerSize);

% Choose Input and Feedback Pre/Post-Processing Functions
% Settings for feedback input are automatically applied to feedback
output
% For a list of all processing functions type: help nnprocess
% Customize input parameters at: net.inputs{i}.processParam
% Customize output parameters at: net.outputs{i}.processParam
net.inputs{1}.processFcns = {'removeconstantrows','mapminmax'};
net.inputs{2}.processFcns = {'removeconstantrows','mapminmax'};

% Prepare the Data for Training and Simulation
% The function PREPARETS prepares timeseries data for a particular
network,
% shifting time by the minimum amount to fill input states and layer
states.
% Using PREPARETS allows you to keep your original time series data
unchanged, while
% easily customizing it for networks with differing numbers of delays,
with
% open loop or closed loop feedback modes.
[inputs,inputStates,layerStates,targets] =
preparets(net,inputSeries,{},targetSeries);

% Setup Division of Data for Training, Validation, Testing
% The function DIVIDERAND randomly assigns target values to training,
% validation and test sets during training.
% For a list of all data division functions type: help nndivide
net.divideFcn = 'dividerand';  % Divide data randomly
% The property DIVIDEMODE set to TIMESTEP means that targets are
divided
% into training, validation and test sets according to timesteps.
% For a list of data division modes type: help
nntype_data_division_mode
net.divideMode = 'value';  % Divide up every value
net.divideParam.trainRatio = 70/100;
net.divideParam.valRatio = 15/100;
net.divideParam.testRatio = 15/100;
```

```
% Choose a Training Function
% For a list of all training functions type: help nntrain
% Customize training parameters at: net.trainParam
net.trainFcn = 'trainlm';  % Levenberg-Marquardt

% Choose a Performance Function
% For a list of all performance functions type: help nnperformance
% Customize performance parameters at: net.performParam
net.performFcn = 'mse';  % Mean squared error

% Choose Plot Functions
% For a list of all plot functions type: help nnplot
% Customize plot parameters at: net.plotParam
net.plotFcns = {'plotperform','plottrainstate','plotresponse', ...
'ploterrcorr', 'plotinerrcorr'};

% Train the Network
% net.trainParam.max_fail=150;
[net,tr] = train(net,inputs,targets,inputStates,layerStates);


% Test the Network
outputs = net(inputs,inputStates,layerStates);
errors = gsubtract(targets,outputs);
performance = perform(net,targets,outputs)

% Recalculate Training, Validation and Test Performance
trainTargets = gmultiply(targets,tr.trainMask);
valTargets = gmultiply(targets,tr.valMask);
testTargets = gmultiply(targets,tr.testMask);
trainPerformance = perform(net,trainTargets,outputs)
valPerformance = perform(net,valTargets,outputs)
testPerformance = perform(net,testTargets,outputs)

% View the Network
view(net)

% Plots
% Uncomment these lines to enable various plots.
figure(2), plotperform(tr)
figname = 'perform_narx';
saveas(gcf, figname, 'fig');
saveas(gcf, figname, 'jpg');

figure(3), plottrainstate(tr)
figname = 'trainstate_narx';
saveas(gcf, figname, 'fig');
saveas(gcf, figname, 'jpg');

figure(4)
plotregression(trainTargets,outputs,'Train',valTargets,outputs,'Valida
tion',testTargets,outputs,'Testing',targets,outputs,'All')
figname = 'regression_narx';
saveas(gcf, figname, 'fig');
saveas(gcf, figname, 'jpg');

figure(5), plotresponse(targets,outputs)
figname = 'response_narx';
saveas(gcf, figname, 'fig');
```

```
saveas(gcf, figname, 'jpg');

figure(6), ploterrcorr(errors)
figname = 'errors_narx';
saveas(gcf, figname, 'fig');
saveas(gcf, figname, 'jpg');

figure(7), plotinerrcorr(inputs,errors)
figname = 'errorinput_narx';
saveas(gcf, figname, 'fig');
saveas(gcf, figname, 'jpg');

% Closed Loop Network
% Use this network to do multi-step prediction.
% The function CLOSELOOP replaces the feedback input with a direct
% connection from the outout layer.
netc = closeloop(net);
netc.name = [net.name ' - Closed Loop'];
view(netc)
[xc,xic,aic,tc] = preparets(netc,inputSeries,{},targetSeries);
yc = netc(xc,xic,aic);
closedLoopPerformance = perform(netc,tc,yc)


% Early Prediction Network
% For some applications it helps to get the prediction a timestep
early.
% The original network returns predicted y(t+1) at the same time it is
given y(t+1).
% For some applications such as decision making, it would help to have
predicted
% y(t+1) once y(t) is available, but before the actual y(t+1) occurs.
% The network can be made to return its output a timestep early by
removing one delay
% so that its minimal tap delay is now 0 instead of 1.  The new
network returns the
% same outputs as the original network, but outputs are shifted left
one timestep.
nets = removedelay(net);
nets.name = [net.name ' - Predict One Step Ahead'];
view(nets)
[xs,xis,ais,ts] = preparets(nets,inputSeries,{},targetSeries);
ys = nets(xs,xis,ais);
earlyPredictPerformance = perform(nets,ts,ys)

figure(1),view(net)
figname = 'view_narx';
saveas(gcf, figname, 'fig');
saveas(gcf, figname, 'jpg');
```

APÊNDICEE – Dados série 1

	Concentração (µg/m³)	Precipitação (mm)	Temperatura (°C)	Umidade Relativa (%)	Velocidade do Vento (m/s)
23/09/1997	40,58	0	20,58	55	2,60
25/09/1997	25,17	2,4	20,88	91	2,03
30/09/1997	44,63	0	22,8	76	4,76
04/10/1997	38,62	0	22,42	53	4,03
08/10/1997	27,66	0	21,34	71,75	4,90
09/10/1997	40,05	0	23,2	54	4,46
14/10/1997	52,41	0	25,88	50,5	2,53
16/10/1997	24,31	8,2	20,46	90,5	2,96
21/10/1997	31,33	11,6	21,12	88	2,56
23/10/1997	41,14	0	19,7	69,75	3,83
28/10/1997	33,07	0	23,2	65,75	1,43
29/10/1997	35,01	0	24,96	61	2,20
04/11/1997	29,82	0	24,58	70,75	1,46
06/11/1997	26,46	0,6	22,42	82,75	2,46
11/11/1997	20,74	0	26,82	54,5	1,33
13/11/1997	12,11	0	24,02	79	2,63
17/11/1997	15,34	38,9	20,68	92,5	4,03
19/11/1997	21,16	16,1	20,38	79,5	2,36
25/11/1997	22,38	1,2	22,84	84	2,53
27/11/1997	16,64	2,6	20,86	96,25	1,70
02/12/1997	30,9	18,3	21	88,25	2,66
04/12/1997	22,8	6,6	19,82	95,5	1,76
09/12/1997	19,7	22,1	22,1	85,75	2,43
11/12/1997	22,3	0	22,92	81	2,50
15/12/1997	24,43	3,8	22,06	83,75	3,46
18/12/1997	13,81	0	21,74	79,25	4,03
23/12/1997	32,83	0	25,68	69,75	2,90
25/12/1997	13,21	17	24,76	78	3,36

	Concentração (µg/m³)	Precipitação (mm)	Temperatura (°C)	Umidade Relativa (%)	Velocidade do Vento (m/s)
30/12/1997	20,2	0	24,2	73	1,26
01/01/1998	29,38	0	24,66	75,75	1,50
06/01/1998	36,55	37	26,14	68,25	1,80
08/01/1998	24,3	16,5	20,42	89,75	2,36
13/01/1998	19,7	11,8	22,94	82,5	3,43
15/01/1998	18,3	0	24,54	72,5	2,03
20/01/1998	12,64	2,6	22,92	76,75	3,36
22/01/1998	21,06	1,1	23,66	72	1,73
27/01/1998	18,23	0	25,84	71	2,53
29/01/1998	22,55	76	23,58	83,25	1,63
03/02/1998	20,17	0,8	24,44	80	1,46
05/02/1998	17,69	8,2	25,32	71	2,80
10/02/1998	18,7	0,8	24,3	89,5	3,30
12/02/1998	17,64	22,7	19,1	87,25	3,46
16/02/1998	18,31	50,6	19,44	89,5	3,00
18/02/1998	28,19	0	22,84	79,25	2,10
24/02/1998	23,2	4,9	23,12	91,5	1,73
26/02/1998	19,9	6,6	22,14	91,75	3,20
03/03/1998	19,46	9,8	22,56	84	0,60
05/03/1998	30,3	8,6	22,8	72,75	3,30
10/03/1998	35,02	8,6	24,78	69	2,13
12/03/1998	23,52	0	25,14	67,75	2,86
17/03/1998	22,17	0	21,9	79	4,26
19/03/1998	25,4	0	22,1	85,25	2,93
24/03/1998	20,8	0	24,44	75,5	2,03
25/03/1998	26,04	0	22,64	86,5	2,36
31/03/1998	18,98	16	22,92	77,5	0,87
02/04/1998	27,13	0	19,42	74,75	3,73
07/04/1998	23,45	0	19,32	88,25	2,13

	Concentração (µg/m³)	Precipitação (mm)	Temperatura (°C)	Umidade Relativa (%)	Velocidade do Vento (m/s)
09/04/1998	20,21	12,2	20,86	87,5	0,93
14/04/1998	39,63	0	23,58	72	2,03
16/04/1998	38,96	0	23,84	80,5	2,00
21/04/1998	31,71	0	21,28	73,25	1,30
23/04/1998	24,15	0	23,4	71,5	1,80
28/04/1998	15,93	32,8	19	95	1,80
30/04/1998	23,65	8,7	14,2	81,5	2,83
05/05/1998	14,85	14,6	16,82	82,75	1,63
07/05/1998	22,81	0	16,36	73,25	4,30
12/05/1998	40,08	0	17	73,5	1,83
14/05/1998	95,54	0	18,74	66,25	1,36
19/05/1998	23,77	0	18,58	74,5	6,76
21/05/1998	41,89	0	19,38	71	1,66
26/05/1998	41,32	0	20,08	73	1,00
28/05/1998	29,06	0	16,68	87,25	2,66
02/06/1998	35,3	0	14,92	76	1,66
04/06/1998	41,56	0	15,38	79	1,36
09/06/1998	50,23	0	14,14	71,5	1,33
11/06/1998	41,08	0	18,84	69,5	1,66
16/06/1998	47,65	0	15,24	73,75	3,00
18/06/1998	42,71	0	19,18	71,5	4,00
23/06/1998	45,92	0	17,98	79	0,67
25/06/1998	26,63	0	12,82	76,5	1,00
30/06/1998	50,75	0	17,56	73,75	1,66
02/07/1998	49,38	0	17	73,75	2,00
07/07/1998	60,63	0	16	78	0,67
09/07/1998	11,24	0,3	15,72	90,25	2,33
10/07/1998	43,5	0	12,12	75,75	6,33
14/07/1998	66,32	0	14,12	67,75	0,67

	Concentração (µg/m³)	Precipitação (mm)	Temperatura (°C)	Umidade Relativa (%)	Velocidade do Vento (m/s)
17/07/1998	62,99	0	14,9	58	1,66
21/07/1998	63,36	0	20,26	60,5	2,33
23/07/1998	58,16	0	20,42	62,5	1,50
28/07/1998	53,27	0	19,34	57,75	2,60
30/07/1998	43,37	0	16,9	72	1,63
04/08/1998	37	0	21,94	50,25	0,60
11/08/1998	48,11	0	20,14	75	1,36
13/08/1998	49,75	0	22,52	67,75	2,20
18/08/1998	54,4	0	20,26	58,5	2,56
20/08/1998	90,11	0,2	22,78	55,75	2,20
25/08/1998	58,71	0	21,62	50,75	2,63
27/08/1998	51,08	0	18,02	74,5	2,90
01/09/1998	51,8	0	19,02	49,25	3,26
03/09/1998	51,82	0	20,16	54,25	3,30
08/09/1998	21,18	1,8	19,08	84,5	1,96
10/09/1998	35,3	0,2	19,12	72	3,90
15/09/1998	39,5	0	21,76	77	3,03
22/09/1998	24,9	0	16,78	65,75	5,00
24/09/1998	52,59	0	21,14	55,75	2,10
29/09/1998	35,03	1,8	18,6	94,25	2,93
01/10/1998	24,91	0	19,38	78	3,30
06/10/1998	29,76	13,4	22,36	69	4,00
08/10/1998	20,27	25	20,08	88,75	1,70
13/10/1998	27,13	0,5	22,18	71,5	3,96
15/10/1998	16,3	0	21,92	74	4,63
20/10/1998	20,2	0	21,2	65,5	2,13
28/10/1998	36,92	25,6	20,82	82,25	1,93
29/10/1998	35,5	0	22,6	66,5	3,90
03/11/1998	25,65	0	19,04	85,75	1,56

	Concentração (µg/m³)	Precipitação (mm)	Temperatura (°C)	Umidade Relativa (%)	Velocidade do Vento (m/s)
05/11/1998	36,6	0	22,02	61,5	3,83
09/11/1998	32,68	2,6	23,26	59,5	2,13
16/11/1998	31,44	0	22,94	61	4,13
23/11/1998	39,58	0	21,52	55,5	2,66
25/11/1998	40,28	0	23,54	75,25	2,90
07/12/1998	36,1	0	23,58	77	3,76
14/12/1998	24,37	0	24,64	80,75	1,86
21/12/1998	20,64	0	24,82	62	2,40
28/12/1998	21,57	0	22,9	65,75	3,63
04/01/1999	19,04	77,4	21,8	91,25	3,70
11/01/1999	20,23	0	23,08	77,5	2,93
18/01/1999	25,63	0	24,8	72,5	2,03
25/01/1999	27,28	7	24,04	79	2,66
01/02/1999	14,22	0	22,76	85	3,36
08/02/1999	19,94	41,6	21,24	85,25	2,10
15/02/1999	21,33	0	24,7	63	1,93
22/02/1999	20,1	39,4	20,38	88,25	2,80
05/04/1999	36,33	0	23,76	77,25	2,83
12/04/1999	38,32	0	20,24	76	1,96
14/04/1999	21,32	31	22,34	80	2,20
21/04/1999	46,2	0	21,58	56,25	3,40
26/04/1999	41,32	0	18,44	65,25	3,56
03/05/1999	46,98	0	19,82	68	2,13
10/05/1999	28,95	0	17,68	72,75	2,60
17/05/1999	45,12	0	15,82	71	1,63
24/05/1999	71	0	14,34	74	2,66
31/05/1999	40,32	0	11,82	73,25	2,30
07/06/1999	36,31	0	16,26	76,25	3,16
14/06/1999	17,8	0	15,56	87	2,13

	Concentração (µg/m³)	Precipitação (mm)	Temperatura (°C)	Umidade Relativa (%)	Velocidade do Vento (m/s)
21/06/1999	25,27	0	14,54	74,5	1,30
28/06/1999	57,18	0	17,42	72,75	3,06
05/07/1999	26,55	0	14,7	83,75	2,53
12/07/1999	28,9	0	15,52	70,25	3,03
19/07/1999	35,28	0	20,1	63,25	2,86
21/07/1999	61,84	0	19,1	70,75	2,03
26/07/1999	71,98	0	18,54	72,25	2,73
02/08/1999	64,46	0	18,28	65	2,50
04/08/1999	56,66	0	17,64	60,75	2,13
16/08/1999	38,01	0	11,94	59,25	3,43
18/08/1999	63,71	0	17,44	63	3,43
30/08/1999	120,95	0	22,58	41,25	3,13
01/09/1999	78,07	0	21,06	44	3,23
08/09/1999	82,06	0	24,9	56,25	2,20
15/09/1999	45,62	3,4	18,34	96	2,60
20/09/1999	47,28	8,9	20,98	61,25	3,56
22/09/1999	37,52	0	17,22	64,5	4,96
28/09/1999	78,47	0	21,14	55,75	5,80
30/09/1999	57,27	0	22,48	26,25	4,10
04/10/1999	30,09	0	14,5	74,75	2,96
06/10/1999	55,26	0	20,18	61,5	2,23
16/10/1999	54,54	1,8	26,7	46,75	4,93
20/10/1999	28,24	0	20,68	70,5	2,66
01/11/1999	38,15	0	20	61,5	2,20
08/11/1999	26,12	0	22,12	75	3,86
10/11/1999	25,67	54,9	14,66	80,5	2,53
18/11/1999	49,15	0	21,02	60	3,66
20/11/1999	21,06	0	20,84	78,5	3,23
22/11/1999	32,11	0	21,22	67,25	3,30

	Concentração (µg/m³)	Precipitação (mm)	Temperatura (°C)	Umidade Relativa (%)	Velocidade do Vento (m/s)
24/11/1999	57,36	1,7	22,7	54	3,80
30/11/1999	43,47	0	22,9	64,25	3,66
16/12/1999	32,8	0,6	21,4	65,75	2,60
27/12/1999	25,4	28,4	22,92	87	2,50
07/01/2000	9,46	32	21,38	89,75	3,96
10/01/2000	24,38	0	24,06	70,5	1,80
13/01/2000	26,24	11,6	23,74	84,75	1,70
21/01/2000	36,07	0	23,88	67	2,83
24/01/2000	30,67	0	23,9	73,75	3,60
26/01/2000	15,49	12,6	19,98	93,25	2,73
02/02/2000	25,51	14,8	22,68	85,75	3,20
04/02/2000	46,21	4	22,28	89,5	1,73
08/02/2000	34,46	0,2	21,2	93,75	2,53
09/02/2000	7,44	39	21,38	95	4,76
18/02/2000	31,7	6	19,98	74,25	2,43
21/02/2000	27,41	0	22,68	73,5	2,13
24/02/2000	30,08	0	23,74	77,25	2,40
29/02/2000	15,26	0,2	23,58	82,75	4,33
02/03/2000	33,34	0	23,6	73,25	2,56
09/03/2000	26,04	0	21,6	74,25	2,13
11/03/2000	20,76	43,2	20,94	89,75	2,40
14/03/2000	22,72	0	22,8	65,25	3,36
16/03/2000	18,04	1,2	22,24	87	1,83
21/03/2000	20,17	0	22,96	81,5	3,96
28/03/2000	21,09	8,5	20,6	89,25	5,20
30/03/2000	38,4	0	20,86	83	2,60
03/04/2000	25,17	0	19,6	74,75	2,50
06/04/2000	35,76	0	21,18	70,5	2,96
10/04/2000	36,34	0	23,02	71,75	2,66

	Concentração (µg/m³)	Precipitação (mm)	Temperatura (°C)	Umidade Relativa (%)	Velocidade do Vento (m/s)
14/04/2000	47,88	0	22,36	69,75	2,63
17/04/2000	46,18	0	20,88	70,5	1,70
19/04/2000	21,02	0	21,36	82,5	2,36
25/04/2000	40,94	0	19,34	61,75	2,96
27/04/2000	46,45	0	19,7	65	2,03
01/05/2000	32,76	0	20,82	75	2,16
04/05/2000	33,35	0	21,42	75,75	2,40
09/05/2000	35,06	0	18,6	75	1,50
11/05/2000	38,05	0	16,08	61,75	4,63
15/05/2000	56,85	0	18	74,75	3,33
18/05/2000	40,03	0	12,94	76,25	1,86
22/05/2000	46,16	0	16,7	72	2,36
25/05/2000	50,2	0	16,16	69,25	2,53
29/05/2000	39,28	0	12,96	61	1,83
05/06/2000	34,85	0	17,8	71	1,33
07/06/2000	39,87	0	16,58	70,25	2,00
12/06/2000	58,8	0	18,36	60	3,33
15/06/2000	48,58	0	19,36	62,25	1,90
21/06/2000	26,53	2,5	12,38	86,5	2,13
23/06/2000	52,16	0	14,54	56,75	4,23
26/06/2000	53,15	0	18,74	60,25	3,26
29/06/2000	74	0	20,42	54,75	2,46
05/07/2000	43,32	0	17,12	70,25	2,90
07/07/2000	43,93	0	18,4	64,25	3,53
10/07/2000	66,62	0	20,18	55,75	2,13
17/07/2000	34,5	0	5,76	63,25	2,86
21/07/2000	46,31	0	14	61,5	2,46
24/07/2000	31,88	5,2	11,06	80,5	1,96
26/07/2000	46,65	0	17,32	66,75	2,16

	Concentração (µg/m³)	Precipitação (mm)	Temperatura (°C)	Umidade Relativa (%)	Velocidade do Vento (m/s)
31/07/2000	52,61	0	19,88	47,25	2,20
02/08/2000	40,8	0	17,54	67,75	2,06
08/08/2000	58,49	0	20,2	57,5	2,86
10/08/2000	35,95	0	19,1	64,25	3,16
14/08/2000	45,87	0	18,24	53,75	2,03
18/08/2000	22,77	11,8	17,8	78,5	1,50
22/08/2000	17,99	0	19,52	49,25	3,00
25/08/2000	70,92	0	22,44	49	1,40
29/08/2000	26,84	19,4	14,46	90,5	3,86
01/09/2000	37,7	2,3	20,28	80	3,06
04/09/2000	49,29	0	14,6	78,5	3,26
10/09/2000	30,93	0	20,5	74,75	3,03
12/09/2000	49,8	0	21,34	78,25	2,63
14/09/2000	30,98	4,6	21,24	83	3,16
04/12/2000	19,56	0	22,78	90,25	2,90
07/12/2000	32,01	0	22,72	64,75	4,06
20/12/2000	25,68	0	22,4	76	4,00
22/12/2000	21,08	2,9	22,74	75,5	2,30
27/12/2000	16,3	14,2	22,74	82,5	2,76
29/12/2000	21,09	4,4	22,5	87,75	2,80
04/01/2001	13,82	0	22,04	80,25	1,70
06/01/2001	21,26	0	24,4	73	2,30
08/01/2001	21,26	0	24,24	73,25	2,16
15/01/2001	24,34	3	22,54	80	2,23
17/01/2001	33,64	0	24,32	67,5	2,96
29/01/2001	19,44	3,8	23,4	80,25	1,46
31/01/2001	16,4	19,5	22,84	82,5	1,50
06/02/2001	15,56	20,1	22,94	80	2,40
08/02/2001	14,75	0	23,92	85	2,66

	Concentração (µg/m³)	Precipitação (mm)	Temperatura (°C)	Umidade Relativa (%)	Velocidade do Vento (m/s)
15/02/2001	31,72	0	22,66	84,25	2,73
17/02/2001	12,5	0,2	22,52	89,75	2,13
23/02/2001	28,5	0	24,62	69,75	1,26
26/02/2001	22,86	2	24,06	68	2,83
01/03/2001	32,78	0	23,1	68,75	1,53
05/03/2001	19,4	0,7	22,24	83,25	2,93
07/03/2001	16,26	2,6	21,52	94,25	3,43
12/03/2001	17,49	12,9	23	79,25	2,03
15/03/2001	32,89	0	24,6	71,25	1,96
19/03/2001	27,84	0	22,64	74,75	2,23
23/03/2001	34,09	0	23,94	68,5	2,96
27/03/2001	25,23	1	22,98	77,5	3,10
29/03/2001	27	2	22,2	78,25	2,03
04/04/2001	29,25	0	23,08	68	2,36
07/04/2001	29,97	0	23,94	74	2,50
11/04/2001	30,68	0	24,2	73,5	3,50
14/04/2001	30,29	0	20,3	64,5	2,56
19/04/2001	46,8	0	20,6	71,25	2,10
23/04/2001	34,79	3,8	22,42	78,25	1,70
27/04/2001	38,98	0	21,7	68,5	4,20
30/04/2001	33,5	0	21,16	60,75	2,56
02/05/2001	31,85	0	22,92	70	3,53
07/05/2001	35,24	0	16,28	65,75	3,03
09/05/2001	14,75	0	17,88	66	2,06
14/05/2001	25,53	0,4	15,8	80,25	2,16
16/05/2001	12,09	1,7	15,86	96,25	2,56
21/05/2001	58,76	0	17,78	64,75	1,16
24/05/2001	54,7	0	18,42	76,5	3,70
29/05/2001	31,4	0	19,44	86,25	1,90

	Concentração (µg/m³)	Precipitação (mm)	Temperatura (°C)	Umidade Relativa (%)	Velocidade do Vento (m/s)
07/06/2001	54,17	0	20,18	73	2,36
11/06/2001	33,09	0	19,22	66	1,66
15/06/2001	48,94	0	17,8	67	2,76
18/06/2001	37,78	0	15,4	92,5	2,36
25/06/2001	42,82	0	19,44	65,75	2,40
30/06/2001	49,14	0	16,78	69	2,06
02/07/2001	81,77	0	17,78	66	1,46
04/07/2001	60,62	0	17	65,75	3,06
13/07/2001	40,53	0	14,06	75,25	2,40
17/07/2001	53,29	0	17,1	57,25	2,90
19/07/2001	75,45	0	18,8	68	2,93
24/07/2001	40,18	0	17,28	82,5	2,23
31/07/2001	43,83	0	18,82	61,5	2,73
03/08/2001	41	0	18,62	58,75	3,46
13/08/2001	40	0	16,96	61,5	2,13
17/08/2001	40	0	17,26	54	3,20
20/08/2001	40	0	21,02	53,75	1,80
22/08/2001	40	0	19,64	65	2,30
27/08/2001	40	0	20,72	66,5	3,23
30/08/2001	40	0	21,46	66,5	1,96
03/09/2001	40	0	21,26	53,5	3,10
10/09/2001	59,81	0	24,1	46,25	4,06
13/09/2001	46,09	0	22,24	64,5	5,90
18/09/2001	33,65	0	15,78	52,75	3,33
20/09/2001	45,31	0	19,88	52	4,06
26/09/2001	24,5	0	20,64	75,25	2,23
28/09/2001	33,65	0,2	21,14	71,5	3,60
01/10/2001	27,46	5,2	20,7	83,75	3,80
04/10/2001	33,53	0	20,38	51,25	1,80

	Concentração (µg/m³)	Precipitação (mm)	Temperatura (°C)	Umidade Relativa (%)	Velocidade do Vento (m/s)
15/10/2001	44,44	0	21,84	61,75	1,56
20/10/2001	15	12,4	19,72	77,75	1,76
22/10/2001	19,24	25,1	18,78	86	4,13
25/10/2001	39,27	0	22,44	51	2,13
29/10/2001	42,16	0	23,44	50	2,46
01/11/2001	32,92	0	23,98	60,25	1,70
07/11/2001	41,85	0	24	59	2,63
08/11/2001	31,75	0	23,52	66,25	2,73
17/11/2001	19,41	0	22,48	82,75	1,50
24/11/2001	21,55	41,8	23,76	72	4,13
26/11/2001	35,21	0	23,84	62	1,80
03/12/2001	28,56	0	21,06	58	2,76
07/12/2001	17,74	2,5	22,6	83,25	2,43
10/12/2001	21,32	5,4	22,08	78	2,20
12/12/2001	33,64	0,2	23,44	73,25	2,90
18/12/2001	37,12	0	22,96	81,75	1,23
20/12/2001	15,97	0,8	22,94	81,75	3,83
26/12/2001	13,63	0	22,14	68,75	2,56
03/01/2002	28,48	0	23,9	61,5	1,53
09/01/2002	25,45	59,7	21,56	74,75	2,56
11/01/2002	29,13	0	21,7	79,75	3,16
15/01/2002	20,01	9,7	21,68	85,5	3,96
19/01/2002	13,76	0	21,32	89,25	3,43
21/01/2002	26,42	13,5	23,24	76,5	2,30
23/01/2002	24,46	1,5	22,76	80	2,86
28/01/2002	16,53	5,8	22,72	87,25	0,83
31/01/2002	17,44	3,8	23,78	82,75	4,80
04/02/2002	26,22	0	21,28	59	3,13
06/02/2002	15,48	0	22,16	75,5	1,96

	Concentração (µg/m³)	Precipitação (mm)	Temperatura (°C)	Umidade Relativa (%)	Velocidade do Vento (m/s)
11/02/2002	19,03	51,5	23,16	77,75	2,26
14/02/2002	21,76	21	19,28	92,5	3,13
18/02/2002	26,82	0	22,04	71,25	2,30
25/02/2002	27,91	0	22,88	67,25	1,73
04/03/2002	22,88	1,5	23,16	71,75	1,86
08/03/2002	28,63	0	25,1	76,25	2,23
13/03/2002	22,73	0	24,94	62	1,66
17/03/2002	17,8	5,4	24,34	75,25	2,86
23/03/2002	9,62	0	22,04	79	3,86
25/03/2002	21,84	24,6	22,54	85,25	2,20
27/03/2002	17,85	0	22,34	88,75	1,40
01/04/2002	31,97	0	23,6	66,75	2,40
04/04/2002	33,08	0	23,3	71,25	3,40
08/04/2002	29,07	0	21,98	64,75	2,22
10/04/2002	31,59	0	22,08	66	1,83
17/04/2002	20,22	0	23,26	67,75	2,46
24/04/2002	41,26	0	21,86	65,5	1,66
29/04/2002	45,34	0	23,4	55,75	1,10
03/05/2002	29,4	2	21,14	83,25	2,40
06/05/2002	24,58	0,1	20,98	78,75	2,46
13/05/2002	25,51	0	20,5	68,25	2,26
16/05/2002	24,7	0	19,64	75,5	1,66
22/05/2002	19,93	0,5	16,28	81	2,30
27/05/2002	40,9	0	15,88	64,25	2,43
29/05/2002	35,27	0	16,48	73,5	3,10
03/06/2002	39,48	0	18,18	70,5	2,03
10/06/2002	54,86	0	20,18	68	1,40
13/06/2002	62,34	0	19,94	66,25	2,13
18/06/2002	80,69	0	19,18	60	2,93

	Concentração (µg/m³)	Precipitação (mm)	Temperatura (°C)	Umidade Relativa (%)	Velocidade do Vento (m/s)
24/06/2002	52,49	0	18,12	66,75	3,13
27/06/2002	46,31	0	19,86	58,75	2,83
04/07/2002	47,9	0	19,58	60,25	1,50
06/07/2002	60,68	0	18,46	62,25	2,80
08/07/2002	52,77	0,3	9,4	86	1,46
11/07/2002	30,07	0	16,28	79,75	1,73
15/07/2002	59,92	0	16,08	55,75	3,46
19/07/2002	56,68	0	18,08	63,5	1,66
22/07/2002	27,04	1,5	16,54	91,5	0,87
24/07/2002	62,61	0	19,06	56,25	2,88
01/08/2002	26,1	16,4	17,86	92,75	1,20
05/08/2002	40,68	0	22,12	65	2,66
10/08/2002	63,22	0	21,6	52,25	1,80
12/08/2002	53,26	0	20,92	54,75	1,50
15/08/2002	72,13	0	20,9	55,5	3,53
19/08/2002	35,01	0	20,52	53	2,20
21/08/2002	51,98	0	20,4	51,25	2,16
26/08/2002	51,71	0	20,16	50,75	2,23
29/08/2002	29,2	0	18,88	72	2,83
15/09/2002	45,55	0,7	21,88	61,5	2,20
19/09/2002	44,87	0	24,18	49,25	1,43
23/09/2002	24,19	2,5	16,54	85	2,76
27/09/2002	46,34	0	21,24	53	2,03
30/09/2002	55,52	0	23,26	50,25	4,06
03/10/2002	49,78	0	23,32	55,25	2,56
07/10/2002	38,04	0	25,14	53	1,73
10/10/2002	58,04	0	26,66	42,75	4,03
13/10/2002	56,24	0	27,96	33,25	2,20
21/10/2002	40,64	0	27,88	39,5	2,46

	Concentração (µg/m³)	Precipitação (mm)	Temperatura (°C)	Umidade Relativa (%)	Velocidade do Vento (m/s)
25/10/2002	28,28	0,4	23,94	72	1,60
28/10/2002	17,73	0	24,18	59,5	3,03
31/10/2002	21,44	0	22,64	71	2,70
04/11/2002	26,16	0	22,66	72,75	3,20
14/11/2002	15,13	0	22,72	65,5	3,56
18/11/2002	19,62	3	23,22	82,75	3,60
25/11/2002	20,18	8,2	24,48	71,25	1,70
28/11/2002	34,57	0	25,02	68	3,76
02/12/2002	20,55	10,1	23,42	80,25	2,23
09/12/2002	19,23	20,9	21,6	75	6,10
10/12/2002	22,48	0	22,3	72,25	3,33
16/12/2002	16,33	113,4	19,44	92,5	1,53
23/12/2002	22,55	0	24,12	78	4,00
26/12/2002	10,51	2,7	21,82	71,5	2,00
30/12/2002	17,31	0,5	24,9	61,5	0,97
03/01/2003	24,79	25,4	23,7	77	3,66
06/01/2003	6,5	33,8	24,22	72,5	2,43
13/01/2003	20,93	12,3	21,9	84,5	2,86
16/01/2003	11,48	0	22,8	77,75	2,90
20/01/2003	16,11	0	23,2	82,75	2,46
23/01/2003	18,29	29,9	21,56	91,5	2,93
29/01/2003	20,2	22	21,24	89,5	2,33
01/02/2003	20,97	6,2	23,98	66,75	1,86
03/02/2003	12,34	0	25,28	63	1,86
06/02/2003	16,97	0	23,36	78,25	2,30
10/02/2003	14,45	0	26,06	59,25	1,96
19/02/2003	13,94	49,5	23,68	75,5	1,96
25/02/2003	7,77	0	25,08	60	2,13
27/02/2003	35,08	0	25,52	58,25	2,76

	Concentração (µg/m³)	Precipitação (mm)	Temperatura (°C)	Umidade Relativa (%)	Velocidade do Vento (m/s)
03/03/2003	28,94	0	23	78,25	2,46
07/03/2003	30,74	4,8	23,72	67,25	2,57
10/03/2003	9,65	2,5	20,56	94,75	2,22
13/03/2003	1,41	8,3	22,64	79	2,40
17/03/2003	28,87	0	22,22	76	5,40
18/03/2003	21,8	0	21,02	81	3,42
24/03/2003	14,79	0	22,14	71,25	3,25
25/03/2003	17,74	0	21,72	71	2,40
27/03/2003	27,06	0	20,54	83,75	2,51
02/04/2003	28,1	0	23,34	53,75	2,13
07/04/2003	41,69	5,3	19,46	82,5	1,36
10/04/2003	20,68	0	20,44	90,75	1,13
13/04/2003	19,23	0	17	59,5	2,40
16/04/2003	34,38	0	20,7	71,25	3,42
20/04/2003	44,68	23,6	20,78	83	4,28
25/04/2003	17,82	0	22,14	70,5	1,20
28/04/2003	31,69	0	22,02	61,75	1,03
02/05/2003	38,58	0	20,7	84,5	2,55
07/05/2003	15,15	0	12,62	75	4,37
10/05/2003	27	0	16,22	77	2,05
13/05/2003	30,3	0	17,86	73	3,15
16/05/2003	22,5	0	19,6	80	1,40
19/08/2003	15,06	0	18,36	40,25	2,90
03/09/2003	40,59	0	18,76	53	2,83
08/09/2003	53,58	0	22,26	49	1,93
11/09/2003	18,9	5	13,66	78,5	4,36
15/09/2003	10,33	0	20,86	62,5	1,36
17/09/2003	19,49	3,9	18,32	64	4,10
22/09/2003	55,14	0	24,74	37,75	2,36

	Concentração (µg/m³)	Precipitação (mm)	Temperatura (°C)	Umidade Relativa (%)	Velocidade do Vento (m/s)
29/09/2003	35,39	0	21,84	62,75	4,06
01/10/2003	48,29	0	22,52	49,5	2,93
06/10/2003	34,54	0	24,72	57,75	2,20
08/10/2003	10,34	27,4	19,8	85,75	3,90
16/10/2003	52,44	0	19,52	44,75	2,53
20/10/2003	58,21	0	24,46	54,75	3,40
22/10/2003	41,41	1,3	21,5	80	1,26
28/10/2003	7,77	3,5	19,24	90	5,50
03/11/2003	16,84	0	16,94	63,75	4,86
05/11/2003	13,46	0	18,92	70	3,43
14/11/2003	26,1	0,9	22,22	67,25	3,43
24/11/2003	44,2	11,7	21,38	89	3,13
01/12/2003	7,28	33,8	21,46	96	2,90
06/01/2004	9,94	0	23,94	71,5	2,46
09/01/2004	4,86	33,1	20,58	96,5	2,26
28/01/2004	13,07	23,7	21,92	85,25	3,10
09/02/2004	27,82	0	20,78	63,25	4,60
11/02/2004	16,76	0	23,1	64,5	3,40
16/02/2004	10,22	7,2	23,16	77,25	2,73
02/03/2004	2,35	4,8	23,22	82	1,55
04/03/2004	25,39	6,9	21,66	84	2,70
05/04/2004	31,61	1,4	21,58	84,25	2,46
12/04/2004	29,9	0	22,24	79,5	2,86
20/04/2004	21,96	0	21,12	82,5	2,86
21/04/2004	18,09	0	22,06	84,5	1,43
28/04/2004	21,03	0	18,64	76,75	2,26
04/05/2004	36,18	0	22,14	72,75	2,10
06/05/2004	17,52	14,4	18,66	93,75	2,10
17/05/2004	14,15	0	13,06	79	1,93

	Concentração (µg/m³)	Precipitação (mm)	Temperatura (°C)	Umidade Relativa (%)	Velocidade do Vento (m/s)
20/05/2004	32,94	3,3	16,56	88,75	1,73
24/05/2004	33,77	0,3	20,12	86,25	3,00
26/05/2004	27,86	13,7	11,92	90,25	3,03
08/06/2004	16,19	0	15,08	75,75	1,90
14/06/2004	48,49	0	15,28	86,25	2,56
16/06/2004	16,19	0	15,36	82,25	2,10
23/06/2004	19,93	0	15,8	72	2,83
28/06/2004	76,8	0	18,64	74,25	3,40
30/06/2004	58,08	0	17,58	77,25	1,63
05/07/2004	24,25	0	19,12	69,25	1,70
07/07/2004	42,27	0	17,98	68,75	3,83
14/07/2004	28,54	0	18,52	74,25	4,36
21/07/2004	13,89	0	13,36	65,5	3,46
26/07/2004	30,07	0	11,6	68,5	2,23
03/08/2004	75,99	0	18,48	63,75	2,20
05/08/2004	32,14	0	16,14	55,5	4,06
09/08/2004	31,77	0	13,66	52,25	2,56
11/08/2004	44,89	0	17,02	50,75	2,76
16/08/2004	19,94	0	15,68	62,5	2,16
18/08/2004	44,31	0	17,92	53	1,86
25/08/2004	52,72	0	20,88	53,5	2,70
30/08/2004	52,93	0	18,98	43,5	2,96
01/09/2004	40,81	0	22,8	36	3,80
15/09/2004	73,7	0	20,72	52,5	2,26
21/09/2004	41,17	0	24,38	45,5	2,76
23/09/2004	125,43	0	24,54	41,75	3,40
04/10/2004	30,63	4,3	17,98	79,5	1,80
06/10/2004	26,65	0	17,42	61,75	3,30
13/10/2004	31,22	4,3	21,58	84,5	2,80

	Concentração (µg/m³)	Precipitação (mm)	Temperatura (°C)	Umidade Relativa (%)	Velocidade do Vento (m/s)
18/10/2004	22,22	9,1	21,62	74,25	1,50
25/10/2004	14,65	0,7	20,46	88,25	2,23
28/10/2004	31,01	0	18,06	64	3,70
10/11/2004	44,76	0	24,62	58,75	2,53
25/11/2004	43,06	0	23	56,5	3,60
03/12/2004	50,53	0,8	20,14	88,25	2,00
09/12/2004	24,91	29,6	21,38	86,75	2,70
15/12/2004	27,25	0	22,4	78,25	1,36
31/01/2005	16,78	18,1	23,42	68,5	2,30
10/02/2005	46,58	0	21,74	64,5	1,86
14/02/2005	19,67	0	23,58	61,25	2,93
21/02/2005	27,04	0	22,98	56,75	1,53
23/02/2005	30,6	0	24,56	56	1,53
28/02/2005	24,03	7,8	22,9	86,75	3,33
02/03/2005	27,1	0	21,48	71,75	3,13
21/03/2005	27,1	0	21,78	90,75	2,06
23/03/2005	16,35	0,3	23,82	81	1,86
13/04/2005	34,54	0	23,76	69,25	2,30
18/04/2005	35,21	4	21,76	72,75	5,00
27/04/2005	21,82	0	17,2	75	2,43
05/05/2005	39,39	0	16,94	66,5	2,60
09/05/2005	31,54	0	19,86	71,5	2,10
11/05/2005	28,05	0	19,9	68	2,56
16/05/2005	33,82	0	20,04	67	1,70
19/05/2005	52,85	0	20,62	68,5	1,63
23/05/2005	6,99	7,8	17,94	90,25	2,93
30/05/2005	12,98	0,1	17,38	86,5	2,86
01/06/2005	8,47	0	19,52	75,25	3,13
06/06/2005	14,95	0	17,78	73,25	1,93

	Concentração (µg/m³)	Precipitação (mm)	Temperatura (°C)	Umidade Relativa (%)	Velocidade do Vento (m/s)
13/06/2005	31,96	0	17,7	73	2,30
16/06/2005	20,58	0	17,76	67	2,86
21/06/2005	24,13	3,8	15,14	87,5	1,36
28/06/2005	30,19	0	17,6	83	2,26
30/06/2005	33,5	0	19,64	81,5	2,60
06/07/2005	11,77	0	17,02	82	2,20
11/07/2005	19,47	0	16,1	70,75	2,70
13/07/2005	33,67	0	16,26	60,5	2,86
20/07/2005	22,13	2	14,86	83	1,20
21/07/2005	59,79	0	17,82	71,25	2,30
25/07/2005	48,68	3,4	14,82	92,5	3,10
28/07/2005	19,4	0	18,76	64	2,40
01/08/2005	31,12	0	17,64	60,5	1,63
04/08/2005	26,69	0	18,06	57,5	1,63
09/08/2005	25,82	0	16,62	73,5	1,43
11/08/2005	36,5	0	16,1	55	1,10
18/08/2005	46,22	0	21,14	59,25	2,46
19/09/2005	4,75	0	22,08	71,75	2,20
26/09/2005	10,84	13,6	16,18	90,25	0,33
29/09/2005	23,94	0	19,12	66	3,66
03/10/2005	24,38	0	22,32	65	4,26
10/10/2005	24,82	0,3	25,66	57,75	1,26
19/10/2005	12,8	0,1	17,86	84	2,36
24/10/2005	20,26	2,2	23,92	65	2,00
31/10/2005	10,26	2,6	18,98	81,5	1,90
07/11/2005	34,59	14	22,08	73,75	3,13
14/11/2005	25,89	0	21,6	69,75	2,50
21/11/2005	20,46	0	21,38	63,25	4,00
30/11/2005	68,79	1,3	20,64	93,25	3,33

	Concentração (µg/m³)	Precipitação (mm)	Temperatura (°C)	Umidade Relativa (%)	Velocidade do Vento (m/s)
05/12/2005	12	0	22,38	89,25	2,03
30/01/2006	14,69	3,9	21,42	88,5	1,90
15/02/2006	15,88	10,2	22,9	80,5	1,76

APÊNDICE F – Dados série 2

	Precipitação (mm)	Temperatura (°C)	Umidade Relativa (%)	Velocidade do Vento (m/s)	Concentração (μg/m³)
16/04/2014	3,8	21,5	82,25	1,00	17,69
17/04/2014	0	22,2	76,375	1,00	25,53
18/04/2014	0	22,9	70,5	0,33	17,53
19/04/2014	0	23,58	65,75	0,67	20,60
20/04/2014	0	23,22	73	1,33	21,80
21/04/2014	0	23,02	63,75	1,00	18,46
22/04/2014	0	20,12	86	1,67	16,15
23/04/2014	20,6	20,26	80,75	1,00	33,44
24/04/2014	0,5	19,76	80,75	1,33	18,04
25/04/2014	0	20,08	72,25	1,67	24,59
26/04/2014	0	18,32	70	1,67	26,43
27/04/2014	0	17,16	67	2,00	31,17
28/04/2014	0	17,98	63,25	1,00	40,00
29/04/2014	0	17,32	61,25	1,33	36,66
30/04/2014	0	19,9	58,25	1,67	53,77
01/05/2014	0	20,06	61,5	1,03	41,12
02/05/2014	0	20,13	67,25	0,34	49,03
03/05/2014	0	20,2	65,25	0,34	38,86
04/05/2014	0	19,38	65,5	0,34	41,29
05/05/2014	0	20,1	71	1,03	43,73
06/05/2014	0	20,92	63,75	1,03	32,24
07/05/2014	0	20,2	66,25	1,03	38,09
08/05/2014	0	20,44	66	0,69	42,98
09/05/2014	0	20,64	71,75	2,06	37,55
10/05/2014	0	17,18	70,5	3,09	25,88
11/05/2014	0	17,88	65,5	1,71	21,49
12/05/2014	0	18,1	71,75	1,37	31,91

	Precipitação (mm)	Temperatura (°C)	Umidade Relativa (%)	Velocidade do Vento (m/s)	Concentração (µg/m³)
13/05/2014	0	18,78	67	0,34	37,73
14/05/2014	0	19,82	57,75	0,69	53,80
15/05/2014	0	18,98	61	0,34	48,48
16/05/2014	0	20,78	53	0,69	56,85
17/05/2014	0	20,23	64,5	1,03	46,33
18/05/2014	0	19,68	76	0,69	39,52
19/05/2014	0	20,4	66,5	1,03	47,65
20/05/2014	0	19,16	70,5	0,69	43,83
21/05/2014	0	20,5	61,5	1,37	48,27
22/05/2014	0	21,14	76	1,37	32,53
23/05/2014	38,8	18,78	96	1,03	14,81
24/05/2014	5,8	17,78	94,25	0,69	14,46
25/05/2014	0,2	18,76	88,5	1,03	14,81
26/05/2014	0	16,72	86	0,69	17,19
27/05/2014	0	14,04	75,75	0,34	19,28
28/05/2014	0	14,68	80,5	2,40	21,38
29/05/2014	0	16,24	80,5	1,37	25,58
30/05/2014	0	17,14	64,5	0,51	28,43
31/05/2014	0	17,88	73,5	1,37	40,82
01/06/2014	0	17,04	90	0,33	23,56
02/06/2014	3	16,3	81,25	0,33	23,94
03/06/2014	0	14,78	65,25	0,00	29,67
04/06/2014	0	17,7	53,75	0,67	28,05
05/06/2014	0	21,26	62,75	0,37	37,41
06/06/2014	0	20,88	70	0,33	48,03
07/06/2014	0	22,24	62	0,33	47,92
08/06/2014	0	21,84	57,75	0,67	42,69
09/06/2014	0	21,08	69,5	1,00	47,33
10/06/2014	0	18,78	81,25	1,67	26,53

	Precipitação (mm)	Temperatura (°C)	Umidade Relativa (%)	Velocidade do Vento (m/s)	Concentração (µg/m³)
11/06/2014	0	18,98	65,5	2,33	25,14
12/06/2014	0	19,8	68,75	1,00	17,92
13/06/2014	0	19,14	70,25	2,33	25,70
14/06/2014	0	19,74	73,25	1,33	24,15
15/06/2014	0	20,46	67,5	1,00	34,56
16/06/2014	0	20,02	72,75	0,67	32,61
17/06/2014	0	19,98	63,25	0,33	36,57
18/06/2014	0	19,46	64,5	0,67	39,94
19/06/2014	0	16,12	77,75	1,67	23,76
20/06/2014	0	16,76	74,5	0,67	38,12
21/06/2014	0	15,72	76,75	0,00	32,84
22/06/2014	0	17,66	72,25	1,00	38,78
23/06/2014	0	18,02	71	0,33	34,09
24/06/2014	0	18,34	69	0,00	29,40
25/06/2014	0	18,66	61	0,33	43,10
26/06/2014	0	19,18	63,25	0,33	47,16
27/06/2014	0	20,02	62,5	0,67	55,53
28/06/2014	0	20,62	57,5	0,67	47,21
29/06/2014	0	16,12	83,75	0,67	18,60
30/06/2014	0	13,92	75,5	1,00	21,65
01/07/2014	0	15,82	68,75	0,69	36,54
02/07/2014	0	19,32	60,25	1,03	38,52
03/07/2014	0	20,98	56,25	1,03	41,79
04/07/2014	0	20,86	58,25	1,03	36,08
05/07/2014	0	20,54	53,5	1,03	78,20
06/07/2014	0	19,12	66	2,06	32,64
07/07/2014	0	19,4	60,75	0,69	53,30
08/07/2014	0	17,4	79,25	1,03	24,29
09/07/2014	0,1	17,66	77,75	1,03	15,77

	Precipitação (mm)	Temperatura (°C)	Umidade Relativa (%)	Velocidade do Vento (m/s)	Concentração (µg/m³)
10/07/2014	8,2	17,3	82,5	1,37	12,32
11/07/2014	0	16,22	73,75	1,03	16,63
12/07/2014	0	17,14	65,5	1,03	18,56
13/07/2014	0	17,18	66,25	0,69	7,77
14/07/2014	0	16,9	62,75	1,03	16,73
15/07/2014	0	16,64	63,75	0,69	25,69
16/07/2014	0	18,4	59,25	0,34	27,44
17/07/2014	0	19,34	58,25	0,69	37,23
18/07/2014	0	17,84	73,75	0,69	23,71
19/07/2014	0	15,26	71,25	0,34	32,82
20/07/2014	0	16,52	50,75	1,03	37,06
21/07/2014	0	17,08	59	1,03	42,96
22/07/2014	0	19,58	57	1,37	33,60
23/07/2014	0	20,34	46	1,71	35,42
24/07/2014	0	17,82	87,5	3,09	22,82
25/07/2014	20,3	12,1	92	1,03	17,80
26/07/2014	0	13,92	93,25	1,03	16,99
27/07/2014	0,3	15,28	89,25	1,03	14,14
28/07/2014	0	16,94	75	1,71	20,01
29/07/2014	0	18	69,5	1,03	18,24
30/07/2014	0	17,52	67	0,34	22,07
31/07/2014	0	18,06	61,25	0,34	22,92
01/08/2014	0	18,66	68	0,00	32,33
02/08/2014	0	19,52	57,25	0,00	34,45
03/08/2014	0	20,78	49	0,34	41,40
04/08/2014	0	21,18	51,25	0,69	48,35
05/08/2014	0	17,26	57	1,37	42,98
06/08/2014	0	18,28	46,75	1,03	27,48
07/08/2014	0	19,28	47,75	0,69	47,80

	Precipitação (mm)	Temperatura (°C)	Umidade Relativa (%)	Velocidade do Vento (m/s)	Concentração (µg/m³)
08/08/2014	0	18,28	59,25	1,03	46,39
09/08/2014	0	19,38	61,25	1,03	30,39
10/08/2014	0	18,52	59,25	1,03	24,81
11/08/2014	0	18,96	49,5	1,03	37,63
12/08/2014	0	20,88	53	0,86	49,36
13/08/2014	0	17,64	79,25	2,74	34,69
14/08/2014	1,3	13,36	75,25	3,09	20,94
15/08/2014	0	19,08	63,75	2,40	28,99
16/08/2014	0	20,72	60,75	1,03	29,22
17/08/2014	0	18,7	79,25	1,71	16,60
18/08/2014	0,3	20,58	59	0,69	33,12
19/08/2014	0	20,36	48	1,03	38,52
20/08/2014	0	20,36	47	1,03	39,30
21/08/2014	0	20,68	49	1,03	44,54
22/08/2014	0	22,52	46,5	1,03	49,79
23/08/2014	0	22,76	39,5	0,69	39,97
24/08/2014	0	22,7	40	2,06	48,60
25/08/2014	0	22,56	42,5	0,69	85,30
26/08/2014	0	23,06	57,25	0,69	59,88
27/08/2014	0	20,42	55,75	0,34	31,93
28/08/2014	0	20,42	49,5	0,86	39,12
29/08/2014	0	20,48	49,75	1,03	46,32
30/08/2014	0	22,96	46,25	0,69	38,20
31/08/2014	0	21,96	55,5	1,37	43,21
01/09/2014	0,3	19,4	82,25	1,03	23,59
02/09/2014	2	23,52	61,25	1,37	29,50
03/09/2014	35,8	21,04	72,5	2,40	16,25
04/09/2014	0	16,86	69	5,14	15,62
05/09/2014	0	18,58	57,75	1,71	19,32

	Precipitação (mm)	Temperatura (°C)	Umidade Relativa (%)	Velocidade do Vento (m/s)	Concentração (µg/m³)
06/09/2014	0	19,64	52,25	2,40	25,63
07/09/2014	0	21,9	44,5	2,40	31,05
08/09/2014	0	22,32	49,75	0,69	32,90
09/09/2014	0	20,7	40,75	0,69	27,96
10/09/2014	0	22,64	46,75	1,37	34,06
11/09/2014	0	23,94	39	0,69	41,88
12/09/2014	0	24,7	46	3,09	52,00
13/09/2014	0	22,08	46,5	2,06	36,74
14/09/2014	0	24,04	43	2,06	48,74
15/09/2014	0	24,52	50	0,69	49,11
16/09/2014	0	23,24	49,5	0,86	49,35
17/09/2014	0	23,12	52,25	0,51	67,02
18/09/2014	0	24,16	52,75	0,69	62,22
19/09/2014	0	22,26	84,25	0,69	51,33
20/09/2014	24,8	18,98	95	1,03	18,05
21/09/2014	35,5	20,46	75,5	1,03	16,27
22/09/2014	0	18,46	54,5	2,74	22,74
23/09/2014	0	22,22	52,25	3,09	28,00
24/09/2014	0	22,14	64	4,46	29,11
25/09/2014	5,5	20,68	82,5	0,69	22,57
26/09/2014	3,6	21	84,25	2,40	16,81
27/09/2014	7,1	20,46	90,25	1,71	9,42
28/09/2014	1,9	23,52	70,25	1,71	19,41
29/09/2014	0	24,9	62,75	1,37	29,41
30/09/2014	0	23	70,5	0,34	23,83
01/10/2014	0	24,6	62,75	1,00	18,26
02/10/2014	0	18,48	72	2,33	21,46
03/10/2014	0	17,36	56,5	2,33	21,39
04/10/2014	0	17,3	52,75	1,67	19,56

	Precipitação (mm)	Temperatura (°C)	Umidade Relativa (%)	Velocidade do Vento (m/s)	Concentração (µg/m³)
05/10/2014	0	18,16	46,75	1,00	22,88
06/10/2014	0	18,88	45,5	2,00	30,78
07/10/2014	0	19,54	50,5	2,33	34,89
08/10/2014	0	21,86	41,25	1,67	41,38
09/10/2014	0	23,84	40,75	1,67	42,95
10/10/2014	0	25,1	42,75	1,67	49,71
11/10/2014	0	26,58	38,25	1,00	55,95
12/10/2014	0	26,2	41,75	1,33	41,49
13/10/2014	0	26,92	40,5	0,33	58,11
14/10/2014	0	29,04	31,75	0,67	67,10
15/10/2014	0	27,1	51	0,67	61,06
16/10/2014	0	28,74	42,25	0,33	84,88
17/10/2014	0	28,96	39	0,67	92,12
18/10/2014	0	26,88	46	0,67	48,45
19/10/2014	0	24,82	64,5	1,00	47,10
20/10/2014	2,7	21,9	75,25	1,67	25,90
21/10/2014	0	19,64	68	3,00	28,46
22/10/2014	0	21,52	60,25	3,00	31,21
23/10/2014	0	23,34	61,75	1,00	30,99
24/10/2014	0	23,92	66,5	1,67	30,77
25/10/2014	1,2	19,48	94	1,00	11,64
26/10/2014	0,8	20,92	88,5	1,67	13,90
27/10/2014	53,6	22,82	52,5	1,00	24,04
28/10/2014	0	22,5	40,25	0,67	31,95
29/10/2014	0	23,76	52,75	1,00	22,96
30/10/2014	0	26,2	48,25	0,67	40,85
31/10/2014	0	25,88	56,5	1,00	26,79
01/11/2014	0	25,42	60,25	0,67	19,08
02/11/2014	0	24,04	72,5	1,00	16,63

	Precipitação (mm)	Temperatura (°C)	Umidade Relativa (%)	Velocidade do Vento (m/s)	Concentração (µg/m³)
03/11/2014	10	24,42	81,25	0,50	19,11
04/11/2014	22	21,48	90	2,33	8,52
05/11/2014	36,6	22,6	83,25	1,67	16,04
06/11/2014	0	24,12	69,25	0,33	18,71
07/11/2014	1,2	23,66	70,75	0,33	19,48
08/11/2014	44,8	22,08	77,5	0,33	18,47
09/11/2014	0	23,62	64,5	1,03	20,49
10/11/2014	0	23,06	51	1,33	22,52
11/11/2014	0	24,04	49	1,67	31,95
12/11/2014	0	22,44	74,25	1,33	45,00
13/11/2014	2,2	23,46	73,25	2,33	22,15
14/11/2014	13,8	20,14	76,75	3,67	21,06
15/11/2014	0	20,26	63	1,67	23,00
16/11/2014	0	20,98	54,75	2,33	24,91
17/11/2014	0	21,28	56,75	1,00	26,83
18/11/2014	0	22,74	61,25	0,67	26,25
19/11/2014	0	23,98	49	0,67	31,45
20/11/2014	0	24,4	53,25	0,33	41,72
21/11/2014	0	24,8	63	0,67	35,79
22/11/2014	0,8	23,02	79,25	1,67	23,87
23/11/2014	0	23,26	73,25	0,33	15,65
24/11/2014	0,7	23	85	1,00	15,09
25/11/2014	12,3	22,5	85	1,67	10,88
26/11/2014	18,4	21,48	93,75	0,67	12,80
27/11/2014	11,6	23,4	88,5	0,67	18,38
28/11/2014	19,6	22,72	76,75	1,00	21,19
29/11/2014	0	22,62	77	0,67	21,52
30/11/2014	1,8	20,22	97	0,67	21,69
01/12/2014	4,7	21,54	79,75	2,00	21,77

	Precipitação (mm)	Temperatura (°C)	Umidade Relativa (%)	Velocidade do Vento (m/s)	Concentração (µg/m³)
02/12/2014	0	21,22	77,25	2,33	21,82
03/12/2014	0	22,46	72	0,67	21,84
04/12/2014	0	22,6	78	2,00	21,86
05/12/2014	0	21,54	71	3,00	26,65
06/12/2014	0	22,46	70,5	2,33	14,40
07/12/2014	0	23,02	74,25	1,67	11,08
08/12/2014	3	22,18	87	0,67	34,09
09/12/2014	5,6	21,7	77,75	0,67	7,09
10/12/2014	8	21,2	92	0,33	8,80
11/12/2014	5,4	21,08	86,75	0,33	9,01
12/12/2014	18,8	22,18	85,25	0,33	9,11
13/12/2014	63,4	19,88	98,25	0,33	9,22
14/12/2014	22,6	22,78	85	0,67	9,63
15/12/2014	6,4	22,12	58,75	1,37	24,47
16/12/2014	0	23,74	63,25	0,33	24,99
17/12/2014	0	24,3	62	0,33	25,70
18/12/2014	0	25,84	65,25	0,34	21,95
19/12/2014	0	24,86	75,25	1,00	16,32
20/12/2014	28,4	23,22	79	1,00	10,47
21/12/2014	0	23,3	92,75	0,33	7,93
22/12/2014	13,8	22,88	87	1,00	7,29
23/12/2014	36,7	23,24	94,5	0,33	6,65
24/12/2014	31,4	23,64	78,75	0,67	13,19
25/12/2014	0	24,04	78,25	0,67	12,54
26/12/2014	9	25,52	62,25	0,33	15,15
27/12/2014	0	26,38	50	0,67	17,75
28/12/2014	0	24,72	70,25	0,33	21,84
29/12/2014	5,6	23,76	72,25	1,33	9,53
30/12/2014	0	23,62	77,75	2,33	13,05

	Precipitação (mm)	Temperatura (°C)	Umidade Relativa (%)	Velocidade do Vento (m/s)	Concentração (µg/m³)
28/01/2015	0	24,52	70,25	1,00	17,92
29/01/2015	8	23,6	75	0,33	11,37
30/01/2015	0	24,32	78	0,67	13,48
31/01/2015	0	24,22	77,5	0,67	17,53
01/02/2015	12	24,94	69,5	1,00	11,66
02/02/2015	11	22,44	84	3,00	14,61
03/02/2015	33,8	22,68	78,75	0,67	17,37
04/02/2015	12,6	20,88	91	0,67	12,71
05/02/2015	3,7	20,7	87	2,33	14,16
06/02/2015	7,1	21,24	82,75	1,00	15,55
07/02/2015	0	22,34	82,5	2,33	21,86
08/02/2015	0	22,48	79,75	1,67	15,09
09/02/2015	3,8	22,16	87,5	0,33	8,31
10/02/2015	2,4	22,68	86	0,67	10,56
11/02/2015	11,5	23,5	78,25	0,67	11,32
12/02/2015	0	24,66	75,25	0,67	16,82
13/02/2015	0	24,14	73,5	1,00	17,96
14/02/2015	0	25,14	61	0,67	14,08
15/02/2015	0	22,58	78,75	0,33	10,19
16/02/2015	5,1	22,78	81,25	0,33	11,50
17/02/2015	0	21,92	88,5	0,33	9,15
18/02/2015	24,3	20,28	92,5	0,33	6,79
19/02/2015	13,6	21,42	89,75	1,00	13,93
20/02/2015	3,3	22,92	79,75	0,67	17,50
21/02/2015	0	25,2	63,5	0,67	21,07
22/02/2015	0	24,84	66	1,00	19,50
23/02/2015	0	24,3	71	2,50	15,05
24/02/2015	0	24,56	64,75	1,67	12,50
25/02/2015	30,2	22,86	78	1,00	7,96

	Precipitação (mm)	Temperatura (°C)	Umidade Relativa (%)	Velocidade do Vento (m/s)	Concentração (µg/m³)
26/02/2015	14,5	23,72	74,75	1,33	11,73
27/02/2015	6,4	22,5	86,75	2,00	12,48
28/02/2015	11	22,75	77,75	2,00	12,47
01/03/2015	0	23	68,75	2,40	16,05
02/03/2015	0	23,04	70,75	1,71	22,67
03/03/2015	0	24,68	65	0,69	26,04
04/03/2015	0	24,02	71	0,69	16,62
05/03/2015	0	24,22	68	0,00	18,88
06/03/2015	0	23,3	78,25	0,34	18,15
07/03/2015	0	22,64	83,5	1,03	10,60
08/03/2015	3,4	21,2	91,25	0,69	8,10
09/03/2015	13	20,48	95,5	0,34	7,70
10/03/2015	8,2	21,68	91,25	1,03	11,07
11/03/2015	2,8	22,06	86	0,34	13,31
12/03/2015	9,6	21,24	90,5	0,69	14,12
13/03/2015	3	21,48	86,5	0,69	11,50
14/03/2015	1,5	20,66	93,75	0,00	9,82
15/03/2015	5,3	21,52	84	0,69	8,45
16/03/2015	5,8	22,54	79,5	0,00	9,92
17/03/2015	8,2	21,02	82	1,03	17,02
18/03/2015	0	20,12	91,75	0,69	4,18
19/03/2015	5,4	19,68	75,25	1,03	15,42
20/03/2015	4,5	19,9	93	0,34	11,19
21/03/2015	0	20,44	87	0,00	10,84
22/03/2015	15,5	20,98	84,25	0,34	8,11
23/03/2015	0	20,32	77,875	1,54	16,03
24/03/2015	0	21,94	71,5	0,00	4,90
25/03/2015	0	23,26	67,5	0,34	12,67
26/03/2015	0	23,58	73,75	0,34	20,45

	Precipitação (mm)	Temperatura (°C)	Umidade Relativa (%)	Velocidade do Vento (m/s)	Concentração (µg/m³)
27/03/2015	0	22,86	79,5	0,34	13,61
28/03/2015	72,6	22,38	86	0,00	22,93
29/03/2015	14,7	23,68	81,25	1,03	13,14
30/03/2015	0	22,99	93	0,00	9,31
31/03/2015	4	22,3	85,25	0,00	15,63
01/04/2015	0	22,9	72,75	0,34	28,16
02/04/2015	0	22,54	61,25	1,03	17,87
03/04/2015	0	22,56	63,25	0,69	13,89
04/04/2015	0	21,5	87,5	0,00	11,92
05/04/2015	15	20,62	93,25	0,34	6,65
06/04/2015	16,7	20,94	82,25	2,40	9,59
07/04/2015	0	18,28	76,75	0,69	20,63
08/04/2015	0	20,78	70,75	2,40	18,77
09/04/2015	0	20,9	74,25	1,37	26,41
10/04/2015	0	21,16	76,5	0,69	29,27
11/04/2015	0	21,44	72	1,37	20,28
12/04/2015	0	22,22	61,25	1,03	23,07
13/04/2015	0	22,24	62,75	1,00	34,66
14/04/2015	0	22,76	75	1,67	20,89
15/04/2015	1,7	21,36	91,75	0,67	14,76
16/04/2015	0	22,18	80,25	1,67	19,98
17/04/2015	0	22,96	70,25	1,00	22,39
18/04/2015	0	23,08	77,125	3,00	24,80
19/04/2015	0	23,2	84	1,00	11,95
20/04/2015	2,4	24	76	1,33	15,93
21/04/2015	0	23,82	79,25	2,33	10,54

APÊNDICE G – Médias Mensais

	Janeiro	Fevereiro	Março	Abril	Maio	Junho	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro
1997	-	-	-	-	-	-	-	-	36,79	35,96	20,58	22,24
1998	22,52	20,48	24,63	27,2	38,67	42,43	51,22	55,59	39,02	26,37	33,42	25,89
1999	24,25	20,39	-	38,03	45,68	37,7	44,79	69,08	62,46	42,61	36,63	28,75
2000	23,11	26,05	25,07	37,47	41,3	48,49	45,73	39,95	38,57	35,93	24,42	22,17
2001	21,45	20,98	25,89	34,4	33,04	44,32	56,52	40,14	40,43	31,59	26,1	24
2002	22,41	22,87	20,19	33,22	28,61	56,02	49,71	47,03	43,3	38,77	23,13	18,42
2003	16,9	17,36	20,11	29,78	34	47,04	56,21	35,6	33,35	36,14	20,34	8
2004	9,29	18,27	24,5	24,52	27,07	39,28	27,8	44,37	51,89	26,06	43,91	34,23
2005	16,78	29,58	23,52	30,52	29,37	23,39	30,7	33,27	13,17	19,25	37,43	-
2014	-	-	-	26,79	35,35	34,07	28,39	39,73	31,66	38,03	22,34	15,84
2015	15,07	13,71	13,5	19,16	-	-	-	-	-	-	-	-