

**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA
FLUMINENSE**

**PROGRAMA DE PÓS-GRADUAÇÃO EM SISTEMAS APLICADOS À
ENGENHARIA E GESTÃO**

Alessandra Ribeiro Silva

**ESTUDO DA APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS EM
UNIDADE MICROCONTROLADA PARA MONITORAMENTO E
PREVISÃO DA QUALIDADE DO AR**

Campos dos Goytacazes/ RJ

2018

**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA
FLUMINENSE**

**PROGRAMA DE PÓS-GRADUAÇÃO EM SISTEMAS APLICADOS À
ENGENHARIA E GESTÃO**

ALESSANDRA RIBEIRO SILVA

**ESTUDO DA APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS EM UNIDADE
MICROCONTROLADA PARA MONITORAMENTO E PREVISÃO DA QUALIDADE DO
AR**

**Renato Gomes Sobral Barcellos
(Orientador)**

**Rogério Atem de Carvalho
(Co-orientador)**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação do Instituto Federal de Educação, Ciência e Tecnologia Fluminense, no Curso de Mestrado Profissional em Sistemas Aplicados à Engenharia e Gestão (MPSAEG), como parte dos requisitos necessários à obtenção do título de Mestre em Sistemas Aplicados à Engenharia e Gestão.

Campos dos Goytacazes/ RJ

2018

Biblioteca Anton Dakitsch
CIP - Catalogação na Publicação

S586e Silva, Alessandra Ribeiro
Estudo da aplicação de redes neurais artificiais em unidade microcontrolada para monitoramento e previsão da qualidade do ar / Alessandra Ribeiro Silva - 2018.
186 f.: il. color.

Orientador: Renato Gomes Sobral Barcellos
Coorientador: Rogério Atem de Carvalho

Dissertação (mestrado) -- Instituto Federal de Educação, Ciência e Tecnologia Fluminense, Campus Campos Centro, Curso de Mestrado Profissional em Sistemas Aplicados à Engenharia e Gestão, Campos dos Goytacazes, RJ, 2018.
Referências: f. 107 a 111.

1. Arduino. 2. Índice de qualidade do ar. 3. Monitoramento ambiental. 4. Poluentes atmosféricos. 5. Redes neurais artificiais. I. Barcellos, Renato Gomes Sobral, orient. II. Carvalho, Rogério Atem de, coorient. III. Título.

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA
FLUMINENSE

PROGRAMA DE PÓS-GRADUAÇÃO EM SISTEMAS APLICADOS À
ENGENHARIA E GESTÃO

Alessandra Ribeiro Silva

ESTUDO DA APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS EM UNIDADE
MICROCONTROLADA PARA MONITORAMENTO E PREVISÃO DA QUALIDADE DO
AR

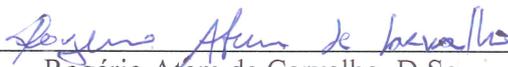
Dissertação de Mestrado apresentada ao Programa de Pós-Graduação do Instituto Federal de Educação, Ciência e Tecnologia Fluminense, no Curso de Mestrado Profissional em Sistemas Aplicados à Engenharia e Gestão (MPSAEG), como parte dos requisitos necessários à obtenção do título de Mestre em Sistemas Aplicados à Engenharia e Gestão.

Aprovada em 23 de maio de 2018.

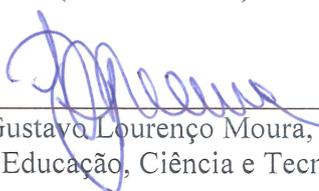
Banca Examinadora:



Renato Gomes Sobral Barcellos, D.Sc.
Instituto Federal de Educação, Ciência e Tecnologia Fluminense
(Orientador)



Rogério Atem de Carvalho, D.Sc.
Instituto Federal de Educação, Ciência e Tecnologia Fluminense
(Co-orientador)



Luiz Gustavo Lourenço Moura, D.Sc.
Instituto Federal de Educação, Ciência e Tecnologia Fluminense



William da Silva Vianna, D.Sc.
Instituto Federal de Educação, Ciência e Tecnologia Fluminense

“Para se ter sucesso, é necessário amar de verdade o que se faz. Caso contrário, levando em conta apenas o lado racional, você simplesmente desiste. É o que acontece com a maioria das pessoas”.

Steve Jobs

AGRADECIMENTOS

Agradeço, primeiramente, a Deus, pela vida.

Aos meus pais Josane Maria de Azevedo Ribeiro Silva e Luiz Carlos da Silva, pela confiança e apoio incondicional no meu crescimento pessoal e intelectual. E por todo o incentivo ao longo dos anos.

Ao meu irmão Raphael Ribeiro Silva, por todo o apoio proporcionado e pela força que transmitiu para que eu chegasse até aqui.

À Anna Luiza Ribeiro Soares Carvalho, à Izabela Ribeiro Soares e ao Daniel da Silva, que sempre estiveram presentes, me incentivando a alavancar o sucesso.

Aos professores Renato Gomes Sobral Barcellos e Rogério Atem de Carvalho, pela orientação e apoio em todos os momentos.

À equipe do Polo de Inovação do IFF, pela assistência durante o período de coleta dos dados experimentais.

Aos professores Luiz Carlos Ferreira Garcez e William da Silva Vianna, pelas dicas que contribuíram para a realização deste trabalho.

E aos meus amigos e colegas, pelos grandes momentos compartilhados.

RESUMO

A poluição atmosférica provocada pela presença de gases poluentes (químicos e particulado) no ar é uma das principais fontes geradoras de degradações do meio ambiente e de efeitos na saúde humana. No Brasil foram determinados indicadores da qualidade do ar, representados pelos principais gases poluentes, sendo eles: partículas inaláveis, dióxido de enxofre, dióxido de nitrogênio, monóxido de carbono e ozônio (INSTITUTO ESTADUAL DO AMBIENTE; GERÊNCIA DE QUALIDADE DO AR, 2016). O monitoramento desses indicadores auxilia no controle de situações emergenciais, através da aplicação de metodologias para a medição em escalas temporais e espaciais. Entretanto os métodos mais usuais apresentam limitações, como custo elevado e alta complexidade, que influenciam nas decisões quanto ao seu uso. A falta de um banco de dados das emissões atmosféricas também dificulta na avaliação das principais fontes poluidoras do ar. Neste contexto, aliar o monitoramento da qualidade do ar, em tempo real, com pequenas estações móveis ampliam significativamente a obtenção de dados em locais que periodicamente apresentam comprometimento da qualidade. A utilização deste tipo de equipamento, através de sistemas inteligentes, possibilita medições por meio de plataformas menos complexas e mais acessíveis. Este trabalho propõe o desenvolvimento de um sistema protótipo de sensoriamento ambiental, para o monitoramento do Índice de Qualidade do Ar (IQAr), em tempo real, e predição das concentrações de material particulado ($2,5 \mu\text{m}$), ozônio e monóxido de carbono, através de uma unidade microcontrolada e da aplicação da metodologia de redes neurais artificiais (RNA). O desenvolvimento do sistema considerou sensores, módulos e componentes sensíveis aos elementos, conectados a uma placa de Arduino Mega 2560, programada pelo *software* Arduino (IDE). Os dados experimentais foram coletados em Polo de Inovação do IFF e adotados para o treinamento das RNA através do *software* Statistica, para a predição das concentrações de cada gás, em relação as suas concentrações iniciais e as condições meteorológicas (pressão, temperatura e umidade). A definição das melhores redes treinadas e da viabilidade de uso considerou os parâmetros e dados estatísticos de cada uma. A implementação do modelo neural no sistema protótipo foi então realizada através da inclusão desses parâmetros no código de programação do microcontrolador. Por fim, considerou-se o protótipo como adequado aos objetivos do trabalho, sendo que a escolha quanto ao seu uso deve considerar o foco da aplicação.

Palavras-chave: Arduino; Índice de qualidade do ar; Monitoramento ambiental; Poluentes atmosféricos; Redes neurais artificiais.

ABSTRACT

Air pollution caused by the presence of gaseous (chemical and particulate) gases in the air is one of the main sources of environmental degradation and effects on human health. In Brazil, air quality indicators, represented by the main pollutants, were identified, being them: inhalable particles, sulfur dioxide, nitrogen dioxide, carbon monoxide and ozone (INSTITUTO ESTADUAL DO AMBIENTE; GERÊNCIA DE QUALIDADE DO AR, 2016). The monitoring of these indicators assists in the control of emergency situations, through the application of methodologies for the measurement in temporal and spatial scales. However, the most usual methods have limitations, such as high cost and high complexity, that influence in the decisions regarding their use. The lack of a database of atmospheric emissions also makes it difficult to assess the main sources of air pollution. In this context, combining real-time air quality monitoring with small mobile stations significantly increases data collection in locations that periodically exhibit quality impairment. The use of this type of equipment, through intelligent systems, enables measurements through less complex and more accessible platforms. This work proposes the development of a prototype system, of environmental sensing, for the monitoring of the Air Quality Index (AQI), in real time, and prediction of concentrations of particulate matter ($2.5 \mu\text{m}$), ozone and carbon monoxide, through a microcontrolled unit and the application of the artificial neural networks (ANN) methodology. The development of the system considered sensors, modules and components sensible to the elements, connected to an Arduino Mega 2560 board, programmed by Arduino software (IDE). The experimental data were collected at IFF's Innovation Hub and were used for the ANN training, through the Statistica software, to predict the concentrations of each gas in relation to its initial concentrations and the meteorological conditions (pressure, temperature and humidity). The definition of the best trained networks and the feasibility of use considered the parameters and statistical data of each one. The implementation of the neural model in the prototype system was then accomplished by including these parameters in the programming code of the microcontroller. Finally, the prototype was considered as adequate to the objectives of the work, and the choice as to its use should consider the focus of the application.

Keywords: Arduino; Air quality index; Environmental monitoring; Atmospheric pollutants; Artificial neural networks.

LISTA DE ABREVIACES

BCD	<i>binary-coded decimal</i> ;
C.O.	funo de ativao da camada oculta da rede neural artificial;
C.S.	funo de ativao da camada de sada da rede neural artificial;
classe_final	classificao da qualidade do ar, calculada pelo sistema;
CO_new	concentrao prevista de monxido de carbono (ppm);
CO_ppm	concentrao medida de monxido de carbono (ppm);
CO_ppm_norm	valor normalizado da concentrao de monxido de carbono;
CONAMA	Conselho Nacional de Meio Ambiente;
E2PROM	<i>electrically-erasable programmable read-only memory</i> ;
EPA	<i>Environmental Protection Agency</i> ;
Gear	Gerncia de Qualidade do Ar;
h_dht	umidade relativa medida pelo sensor DHT-11 (%);
IBAMA	Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais;
I ² C	<i>inter-integrated circuit</i> ;
IDE	<i>integrated development environment</i> ;
indice_CO	ndice de qualidade do monxido de carbono no ar;
indice_MP	ndice de qualidade do material particulado no ar;
indice_O3	ndice de qualidade do oznio no ar;
INEA	Instituto Estadual do Ambiente;
IoT	<i>internet of things</i> ;
IQAr	ndice de qualidade do ar;
IQAr_final	ndice de qualidade do ar (geral), calculado pelo sistema;
MAA	mdia aritmtica anual;
MCU	microcontrolador;
MEMS	<i>micro-electro-mechanical-systems</i> ;
MGA	mdia geomtrica anual;
MISO	<i>master input, slave output</i> ;
MLP	<i>multilayer perceptron</i> ;
MOSI	<i>master output, slave input</i> ;

MP	material particulado;
MP_new	concentração prevista de material particulado ($\mu\text{g}/\text{m}^3$);
MP_ugcm	concentração medida de material particulado ($\mu\text{g}/\text{m}^3$);
MP_ugcm_norm	valor normalizado da concentração de material particulado;
MP _{2,5}	material particulado inferior à 2,5 μm ;
MP ₁₀	material particulado inferior à 10 μm ;
O3_new	concentração prevista de ozônio ($\mu\text{g}/\text{m}^3$);
O3_ugcm	concentração medida de ozônio ($\mu\text{g}/\text{m}^3$);
O3_ugcm_norm	valor normalizado da concentração de ozônio;
p_bmp	pressão medida pelo sensor BMP085 (Pa);
p_mmHg	pressão em unidade mmHg;
ppm	partes por milhão;
ppb	partes por bilhão;
PSI	<i>pollutant standard index</i> ;
PTS	partículas totais em suspensão;
RBF	<i>radial bases function</i> ;
RNA	rede neural artificial;
RTC	<i>real-time clock</i> ;
RXD	pino de recepção serial;
SANN	<i>Statistica Automated Neural Network</i> ;
SCK	<i>serial clock</i> ;
SPI	<i>serial peripheral interface</i> ;
SS	<i>slave select</i> ;
T	temperatura ($^{\circ}\text{C}$);
t_bmp	temperatura medida pelo sensor BMP085 ($^{\circ}\text{C}$);
t_dht	temperatura medida pelo sensor DHT-11 ($^{\circ}\text{C}$);
t_kelvin	temperatura em unidade Kelvin;
TXD	pino de transmissão serial;
UR	umidade relativa (%).

LISTA DE SÍMBOLOS

a_i	sinal de entrada do jésimo neurônio;
b_j	sinal de saída do jésimo neurônio;
$C_{\text{particulado}}$	concentração final de material particulado;
d	densidade das partículas;
E	erro quadrático;
f_c	fator de correção atribuído ao cálculo do material particulado;
i	entrada da sinapse no neurônio;
j	neurônio em análise;
L	leitura analógica do sensor;
$m_{\text{particulado}}$	massa de cada partícula;
r	raio das partículas;
R	constante universal dos gases;
R_L	resistência de carga do sensor;
R_o	resistência do sensor em condição de ausência do gás medido;
R_s	resistência do sensor;
w_{ji}	peso da conexão de entrada i no neurônio j ;
x_j	total de ativação do jésimo neurônio.

LISTA DE SÍMBOLOS GREGOS

η_j	constante linear de proporcionalidade do neurônio j ;
θ_j	parâmetro externo “ <i>bias</i> ”;
π	constante Pi.

LISTA DE FIGURAS

Figura 1 - Processo de exposição dos agentes receptores.	7
Figura 2 - Curva de sensibilidade do sensor MQ-131 a diferentes gases.....	17
Figura 3 - Curva de sensibilidade do sensor MICS-5524 a diferentes gases.	18
Figura 4 - Componentes presentes no sensor PPD42.....	19
Figura 5 - Esquema representativo da medição do sensor PPD42.	20
Figura 6 – Curvas características de sensibilidade do pino P1 do sensor PPD42.	20
Figura 7 - Esquema de funcionamento do sensor DHT-11.....	21
Figura 8 - Exemplo do envio de dados pelo sensor DHT-11.....	22
Figura 9 - Modelo de RNA multicamadas.....	25
Figura 10 - Estrutura do $j^{\text{ésimo}}$ neurônio.	25
Figura 11 - Esquema de funcionamento do treinamento com os subconjuntos de dados para treinamento e para teste.	28
Figura 12 - Vista aérea da localização do Polo de Inovação do IFF.....	34
Figura 13 - Estrutura da RNA estudada.....	36
Figura 14 - Esquema desenvolvido para protótipo.....	40
Figura 15 - Circuito eletrônico do protótipo.....	41
Figura 16 – Gráfico de $\log(\text{concentração do gás})$ versus $\log(R_S/R_O)$	49
Figura 17 – Página <i>web</i> desenvolvida para envio dos dados.....	51
Figura 18 - Concentrações de (a) material particulado, (b) ozônio e (c) monóxido de carbono, ao longo do teste de exposição à fumaça do cigarro.	53
Figura 19 – Valores obtidos para o índice de qualidade do ar, ao longo do teste de exposição à fumaça do cigarro.	54
Figura 20 - Gráficos de (a) histograma e (b) dispersão dos dados, coletados para t_{dht} em C-01.	56
Figura 21 - Gráficos de (a) histograma e (b) dispersão dos dados, coletados para h_{dht} em C-01.....	57
Figura 22 - Gráficos de (a) histograma e (b) dispersão dos dados, coletados para MP_{ugcm} em C-01.....	58
Figura 23 - Gráficos de (a) histograma e (b) dispersão dos dados, coletados para CO_{ppm} em C-01.....	59

Figura 24 - Gráficos de (a) histograma e (b) dispersão dos dados, coletados para IQAr em C-01.	60
Figura 25 - Gráficos de (a) histograma e (b) dispersão dos dados, coletados para t_bmp em C-02.	62
Figura 26 - Gráficos de (a) histograma e (b) dispersão dos dados, coletados para t_dht em C-02.	63
Figura 27 - Gráficos de (a) histograma e (b) dispersão dos dados, coletados para h_dht em C-02.	64
Figura 28 - Gráficos de (a) histograma e (b) dispersão dos dados, coletados para p_bmp em C-02.	65
Figura 29 - Gráficos de (a) histograma e (b) dispersão dos dados, coletados para MP_ugcm em C-02.	66
Figura 30 - Gráficos de (a) histograma e (b) dispersão dos dados, coletados para O3_ugcm em C-02.	67
Figura 31 - Gráficos de (a) histograma e (b) dispersão dos dados, coletados para CO_ppm em C-02.	68
Figura 32 - Gráficos de (a) histograma e (b) dispersão dos dados, coletados para IQAr em C-02.	69
Figura 33 – Comparativo entre os valores obtidos de temperatura no estudo e dados históricos.	70
Figura 34 – Comparativo entre os valores obtidos de O ₃ no estudo e o Boletim do RJ.	72
Figura 35 – Comparativo entre os valores obtidos de CO no estudo e o Boletim RJ.	73
Figura 36 – Esquema de entrada e saída utilizado no treinamento da RNA para predição de material particulado.	74
Figura 37 – Histograma de distribuição dos resíduos, para o treinamento de material particulado.	78
Figura 38 – Dispersão dos dados preditos pela RNA em relação aos dados observados, para o treinamento de material particulado.	79
Figura 39 - Comparação da sequência de dados preditos pela RNA e os observados, em relação à variável MP_new, considerando o subconjunto de treinamento.	80
Figura 40 - Comparação da sequência de dados preditos pela RNA e os observados, em relação à variável MP_new, considerando os subconjuntos de teste e validação.	81
Figura 41 - Esquema de entrada e saída utilizado no treinamento da RNA para predição de ozônio.	83

Figura 42 - Histograma de distribuição dos resíduos para o treinamento de ozônio.....	86
Figura 43 - Dispersão dos dados preditos pela RNA em relação aos dados observados, para o treinamento de ozônio.	87
Figura 44 - Dispersão dos dados preditos pela RNA em relação aos dados observados, para o treinamento de ozônio, sem 8 pontos.	88
Figura 45 - Comparação da sequência de dados preditos pela RNA e os observados, em relação à variável O3_new, considerando o subconjunto de treinamento.	89
Figura 46 - Comparação da sequência de dados preditos pela RNA e os observados, em relação à variável O3_new, considerando os subconjuntos de teste e validação.	90
Figura 47 - Esquema de entrada e saída utilizado no treinamento da RNA para predição de monóxido de carbono.	91
Figura 48 - Histograma de distribuição dos resíduos para o treinamento de monóxido de carbono.	95
Figura 49 - Dispersão dos dados preditos pela RNA em relação aos dados observados, para o treinamento de monóxido de carbono.	96
Figura 50 - Dispersão dos dados preditos pela RNA em relação aos dados observados, para o treinamento de monóxido de carbono, considerando escala mais específica.....	97
Figura 51 - Comparação da sequência de dados preditos pela RNA e os observados, em relação à variável CO_new, considerando o subconjunto de treinamento.	98
Figura 52 - Comparação da sequência de dados preditos pela RNA e os observados, em relação à variável CO_new, considerando os subconjuntos de teste e validação.	99
Figura A.1 – Esquema do sensor MQ-131.	112
Figura A.2 – Esquema do sensor MICS-5524.	113
Figura A.3 – Esquema do sensor PPD42, representado em unidade de mm.	114
Figura A.4 – Esquema do sensor DHT-11, representado em unidade de mm.	115
Figura A.5 – Esquema do sensor BMP085, representado em unidade de mm, nas vistas: (a) superior; (b) superior, com tampa; (c) lateral, com tampa.	117
Figura A.6 – Esquema do RTC DS1307.....	117

LISTA DE QUADROS

Quadro 1 - Padrões de qualidade do ar nos Estados Unidos da América.....	8
Quadro 2 - Padrões nacionais de qualidade do ar, segundo Resolução CONAMA N° 003/1990.	9
Quadro 3 - Faixas de classificação do índice de qualidade do ar, correlacionados com os efeitos à saúde.	11
Quadro 4 - Métodos adotados pelo INEA para detecção dos gases poluentes atmosféricos no Estado do Rio de Janeiro.	15
Quadro 5 - Condições adotadas para os treinamentos das RNA.	35
Quadro A.1 – Especificações técnicas do sensor MQ-131.....	112
Quadro A.2 – Especificações técnicas do sensor MICS-5524.....	113
Quadro A.3 – Especificações técnicas do sensor PPD42.	114
Quadro A.4 – Especificações técnicas do sensor DHT-11.....	115
Quadro A.5 – Especificações técnicas do sensor BMP085.	116
Quadro A.6 – Especificações técnicas do RTC DS1307.	117
Quadro C.1 – Pesos de cada conexão da rede MLP 5-70-1, desenvolvida para predição de MP_new (continua).	120
Quadro C.2 – “Bias” de cada conexão da rede MLP 5-70-1, desenvolvida para predição de MP_new (continua).	127
Quadro D.1 - Pesos de cada conexão da rede MLP 5-86-1, desenvolvida para predição de O3_new (continua).	129
Quadro D.2 - “Bias” de cada conexão da rede MLP 5-86-1, desenvolvida para predição de O3_new (continua).	137
Quadro E.1 - Pesos de cada conexão da rede MLP 5-62-1, desenvolvida para predição de CO_new (continua).	139
Quadro E.2 - “Bias” de cada conexão da rede MLP 5-62-1, desenvolvida para predição de CO_new.	145

LISTA DE TABELAS

Tabela 1 - Faixas de classificação do índice de qualidade do ar, em função das concentrações dos gases poluentes.....	10
Tabela 2 - Faixas de concentrações dos gases adotadas para a classificação da qualidade do ar.	30
Tabela 3 - Relação do consumo de corrente dos componentes utilizados.....	39
Tabela 4 - Pontos das curvas de sensibilidade dos sensores de gás.....	48
Tabela 5 - Parâmetros estatísticos da coleta de dados C-01.	55
Tabela 6 - Parâmetros estatísticos da coleta de dados C-02.	61
Tabela 7 - Comparativo entre os parâmetros estatísticos das temperaturas obtidas no estudo e em dados históricos.	71
Tabela 8 - Dez melhores redes treinadas para a predição de material particulado, a cada 5 minutos.	75
Tabela 9 - Dez melhores redes treinadas para a predição de material particulado, a cada 10 minutos.	76
Tabela 10 - Dez melhores redes treinadas para a predição de material particulado, a cada 30 minutos.	77
Tabela 11 - Comparação dos desempenhos das RNA selecionadas para o material particulado, em cada treinamento.	77
Tabela 12 - Parâmetros estatísticos das melhores redes obtidas nos treinamentos 1, 2 e 3, de material particulado.	82
Tabela 13 - Análise de sensibilidade das RNA treinadas para o material particulado.....	82
Tabela 14 - Dez melhores redes treinadas para a predição de ozônio, a cada 5 minutos.	84
Tabela 15 - Dez melhores redes treinadas para a predição de ozônio, a cada 10 minutos.	84
Tabela 16 - Performances e erros das dez melhores redes treinadas para a predição de ozônio, a cada 30 minutos.	85
Tabela 17 - Comparação dos desempenhos das RNA selecionadas para o ozônio, em cada treinamento.	85
Tabela 18 - Parâmetros estatísticos das melhores redes obtidas nos treinamentos 1, 2 e 3, de ozônio.	90
Tabela 19 - Análise de sensibilidade das RNA treinadas para o ozônio.....	91

Tabela 20 - Dez melhores redes treinadas para a predição de monóxido de carbono, a cada 5 minutos.	92
Tabela 21 - Dez melhores redes treinadas para a predição de monóxido de carbono, a cada 10 minutos.	93
Tabela 22 - Dez melhores redes treinadas para a predição de monóxido de carbono, a cada 30 minutos.	94
Tabela 23 - Comparação dos desempenhos das RNA selecionadas para o monóxido de carbono, em cada treinamento.	94
Tabela 24 - Parâmetros estatísticos das melhores redes obtidas nos treinamentos 1, 2 e 3, de monóxido de carbono.	99
Tabela 25 - Análise de sensibilidade das RNA treinadas para o monóxido de carbono.	100
Tabela 26 - Redes neurais artificiais consideradas na implementação dos modelos de predição das concentrações dos poluentes.	100
Tabela 27 - Parâmetros para normalização dos dados das variáveis.	101

LISTA DE CÓDIGOS

Código 1 - Trecho do código de programação adotado para a calibração do módulo RTC DS1307.....	31
Código 2 - Trecho do código de programação desenvolvido para a calibração do sensor MQ-131.....	43
Código 3 - Trecho do código de programação desenvolvido para o monitoramento da qualidade do ar – inclusão das bibliotecas.....	45
Código 4 - Trecho do código de programação desenvolvido para o monitoramento da qualidade do ar – ranges para o cálculo de IQAr.....	46
Código 5 - Trecho do código de programação desenvolvido para o monitoramento da qualidade do ar – conexão com rede WiFi.....	46
Código 6 - Trecho do código de programação desenvolvido para o monitoramento da qualidade do ar – função <i>loop()</i>	47
Código 7 - Trecho do código de programação desenvolvido para o monitoramento da qualidade do ar – função <i>getParticulate()</i>	48
Código 8 - Trecho do código de programação desenvolvido para o monitoramento da qualidade do ar – dados das curvas de calibração dos sensores de gás.....	49
Código 9 - Trecho do código de programação desenvolvido para o monitoramento da qualidade do ar – cálculos para obtenção das concentrações de O ₃ e CO.....	50
Código 10 - Trecho do código de programação desenvolvido para o monitoramento da qualidade do ar – cálculos para obtenção da concentração de ozônio em µg/m ³	50
Código 11 - Trecho do código de programação desenvolvido para o monitoramento da qualidade do ar – cálculos para obtenção dos índices de qualidade do ar.....	50
Código B.1 - Código fonte para calibração do sensor MQ-131, em condição de ar limpo....	118
Código F.1 - Código fonte final para o monitoramento da qualidade do ar e predição das concentrações dos poluentes por modelos neurais.....	146

SUMÁRIO

1	INTRODUÇÃO.....	1
1.1	Contextualização.....	1
1.2	Objetivos.....	2
1.2.1	Objetivo Geral	2
1.2.2	Objetivos Específicos	2
1.3	Justificativa	2
1.4	Organização do Texto.....	4
2	REVISÃO BIBLIOGRÁFICA.....	6
2.1	Poluição	6
2.1.1	Poluição Atmosférica	6
2.1.2	Indicadores da Poluição Atmosférica	7
2.1.2.1	Partículas Inaláveis.....	11
2.1.2.2	Dióxido de Enxofre	12
2.1.2.3	Dióxido de Nitrogênio.....	12
2.1.2.4	Ozônio	13
2.1.2.5	Monóxido de Carbono.....	13
2.2	Métodos de Medição dos Poluentes Atmosféricos	14
2.3	Método Alternativo para Medição: Principais Elementos	16
2.3.1	Sistemas de Aquisição de Dados e Microcontroladores.....	16
2.3.2	Sensores, Módulos e Demais Componentes.....	16
2.3.2.1	Sensor de Ozônio	17
2.3.2.2	Sensor de Monóxido de Carbono.....	18
2.3.2.3	Sensor de Material Particulado	18
2.3.2.4	Sensor de Temperatura e Umidade Relativa	21
2.3.2.5	Sensor de Pressão Barométrica e Temperatura	22

2.3.2.6	Módulo de Relógio e Calendário	22
2.4	Métodos para a Previsão da Qualidade do Ar.....	23
2.4.1	Rede Neural Artificial	24
2.4.2	Modelagem da RNA.....	24
3	MATERIAL E MÉTODOS.....	29
3.1	Descrição do Objeto em Estudo.....	29
3.1.1	Gases Químicos	29
3.1.2	Sensores e Módulos	30
3.1.3	Plataforma de Prototipagem	30
3.2	Programação do Arduino	31
3.3	Coleta de Dados	32
3.3.1	Análise da Resposta dos Sensores de Gás.....	33
3.3.2	Coleta dos Dados Experimentais de um Ambiente	33
3.4	Treinamento da RNA.....	35
3.5	Implementação do Algoritmo Neural	38
4	RESULTADOS E DISCUSSÃO	39
4.1	Desenvolvimento do Protótipo	39
4.2	Programação do Arduino	42
4.2.1	Calibração.....	42
4.2.1.1	Módulo de Relógio e Calendário	42
4.2.1.2	Sensores de Gás.....	42
4.2.2	Desenvolvimento de Código para Classificação da Qualidade do Ar.....	45
4.3	Resposta dos Sensores de Gás	52
4.4	Obtenção dos Dados Experimentais	54
4.4.1	Valores Obtidos	54
4.4.2	Comparativos com Dados na Literatura	70
4.5	Treinamento da RNA.....	73

4.5.1	Treinamento para Material Particulado	74
4.5.1.1	Análise de Desempenho	75
4.5.1.2	Dados Preditos pela RNA <i>versus</i> Dados Observados	78
4.5.1.3	Comparação entre os Dados Experimentais e os Dados Preditos	79
4.5.1.4	Análise dos Dados Estatísticos.....	81
4.5.1.5	Análise de Sensibilidade	82
4.5.2	Treinamento para Ozônio	83
4.5.2.1	Análise de Desempenho	83
4.5.2.2	Dados Preditos pela RNA <i>versus</i> Dados Observados	86
4.5.2.3	Comparação entre os Dados Experimentais e os Dados Preditos	88
4.5.2.4	Análise dos Dados Estatísticos.....	90
4.5.2.5	Análise de Sensibilidade	91
4.5.3	Treinamento para Monóxido de Carbono.....	91
4.5.3.1	Análise de Desempenho	92
4.5.3.2	Dados Preditos pela RNA <i>versus</i> Dados Observados	95
4.5.3.3	Comparação entre os Dados Experimentais e os Dados Preditos	97
4.5.3.4	Análise dos Dados Estatísticos.....	99
4.5.3.5	Análise de Sensibilidade	100
4.6	Implementação do Algoritmo Neural na Programação e Avaliação Final	100
5	CONSIDERAÇÕES FINAIS	103
5.1	Perspectivas e Sugestões para Trabalhos Futuros.....	106
	REFERÊNCIAS BIBLIOGRÁFICAS	107
	Apêndice A.....	112
	Apêndice B	118
	Apêndice C	120
	Apêndice D.....	129
	Apêndice E	139

Apêndice F..... 146

1 INTRODUÇÃO

No presente capítulo se pleiteia a necessidade de monitoramento das emissões de gases poluentes na atmosfera e são discutidas as principais limitações de uso das técnicas normalmente adotadas, dentre elas o custo elevado. Sendo assim, dá-se ênfase no estudo de técnicas alternativas, que partem do pressuposto de sistemas inteligentes, com o uso de plataformas mais acessíveis (como a placa de Arduino) e predição de dados através de modelo de redes neurais artificiais, conforme descrito nas próximas seções.

1.1 Contextualização

A poluição atmosférica é um problema amplamente discutido na literatura, sendo classificada como uma das principais fontes geradoras de degradações do meio ambiente e da saúde humana. Os efeitos são diversos, podendo gerar chuva ácida, aumentar o efeito estufa, diminuir a camada de ozônio e causar efeitos na saúde da população, que variam entre problemas respiratórios, intoxicações e câncer (DOS SANTOS; MARTINS, 2002).

Devida tamanha problemática, cada país passou a determinar indicadores da qualidade do ar, representados pelos principais gases poluentes identificados, de forma a monitorar os mesmos e assim classificar a qualidade do ambiente. Para isso foram definidas regulamentações que listam os métodos que devem ser adotados na identificação dos componentes (BRASIL, 1990; FUNDAÇÃO ESTADUAL DE ENGENHARIA DO MEIO AMBIENTE, 2007; UNITED STATES ENVIRONMENTAL PROTECTION AGENCY, 2017).

No Brasil se observa uma carência por informações da emissão de gases na atmosfera, principalmente quanto aos gases resultantes de atividades industriais. Isto ocorre porque não existe um banco de dados nacional que contemple as indústrias potencialmente poluidoras, com a localização e os dados dos poluentes. Verifica-se então que o monitoramento dessas emissões apresenta limitações que impactam no controle dessas variáveis, tais como: custo elevado, grande diversidade de poluentes a serem medidos e complexidade de algumas medições (LISBOA; PAGE; GUY, 2009; SOR et al., 2008).

Tendo em vista os limites e barreiras dos métodos usualmente utilizados para a medição dos poluentes atmosféricos, pesquisas estudam a adoção de unidades microcontroladas para o monitoramento das concentrações de gases. Também são avaliadas a associação dessas unidades com modelos neurais, para a predição das concentrações futuras. Essa união visa a

identificação de tendências alarmantes, o que possibilita o controle de tal condição de forma rápida e eficaz (GUNAWAN et al., 2018; LACAVA, 2002; MARAJ et al., 2017).

Sendo assim, este trabalho propõe o desenvolvimento de um sistema protótipo de sensoriamento ambiental, para monitoramento da qualidade do ar em tempo real, considerando uma unidade microcontrolada em conjunto com a técnica de redes neurais artificiais para a predição das concentrações de três gases poluentes atmosféricos.

1.2 Objetivos

1.2.1 Objetivo Geral

O presente trabalho tem como objetivo desenvolver um sistema microcontrolado para monitoramento da qualidade do ar com a utilização de sensores de material particulado MP_{2,5}, ozônio e monóxido de carbono, associado a predição por redes neurais artificiais.

1.2.2 Objetivos Específicos

Para a consolidação do objetivo geral, faz-se necessário realizar os seguintes objetivos específicos, como etapas pertinentes ao estudo:

- Identificar os métodos adotados para monitoramento da qualidade do ar, com foco no Estado do Rio de Janeiro;
- Desenvolver sistema protótipo para medição das concentrações de três gases poluentes atmosféricos e monitoramento da qualidade do ar;
- Realizar coleta de dados experimentais em Polo de Inovação do IFF;
- Aplicar a metodologia de treinamento de redes neurais artificiais para a representação do cenário em estudo;
- Implementar o algoritmo neural desenvolvido no sistema protótipo.

1.3 Justificativa

Segundo estudos realizados pelo World Resources Institute (2017), no ano de 2013 o Brasil se encontrava em 8º lugar no *ranking* de países mais poluentes, quanto à emissão de

gases de efeito estufa. Neste âmbito, o país representava mais de 2% das emissões globais de dióxido de carbono, divididos nos setores de energia, agricultura, indústrias e resíduos. Os demais países em destaque na lista de poluentes foram a China, os Estados Unidos da América, a União Europeia e a Índia.

Em linha, o levantamento de dados realizado pela Fundação Estadual de Engenharia do Meio Ambiente (2007), notificou que no Estado do Rio de Janeiro os setores industriais que mais emitiram gases poluentes na atmosfera no ano de 2004 foram a petroquímica, a indústria de geração e a ceramista, que juntas representaram 88,6% das emissões avaliadas. Entretanto, estudos apontam que não existe atualização quanto ao inventário das fontes móveis, para o diagnóstico e definição das políticas públicas. Isso ocorre devido à uma carência de informações de porte nacional, gerada pelas limitações com relação ao monitoramento das emissões (INSTITUTO ESTADUAL DO AMBIENTE; GERÊNCIA DE QUALIDADE DO AR, 2016; SOR et al., 2008).

Na literatura são abordados diferentes métodos para o monitoramento dos índices de poluição. Devido à complexidade e aos altos custos por parte de algumas metodologias, seu uso pode se tornar inviável. Ressalta-se que, além destas barreiras, em determinadas aplicações e locais de estudo existem restrições físicas que dificultam o acesso e inviabilizam o uso de métodos analíticos, por exemplo, que avaliam a partir de amostras coletadas (LACAVA, 2002; LISBOA; PAGE; GUY, 2009).

Tendo em vista que as emissões de gases poluentes na atmosfera atuam diretamente nos padrões de qualidade do ar, podendo gerar danos pessoais, materiais e ambientais, o seu monitoramento é de vital importância para detectar rapidamente níveis elevados dos gases, tais como ocorre em situações de vazamentos (BRASIL, 1990; DOS SANTOS; MARTINS, 2002).

Neste contexto, existe a demanda por sistemas alternativos de avaliação da qualidade do ar. Estudos recentes ponderam a aplicação de unidades microcontroladas, como as placas de Arduino, devido à autonomia tecnológica proporcionada pelo *hardware* e *software* livres. Os demais benefícios observados para estas unidades são: baixos custos, plataforma de fácil acesso, domínio da tecnologia e baixa complexidade (PINTO; BARCELLOS, 2015).

Outros estudos apontam como vantagem o uso de modelos matemáticos, em conjunto à unidade microcontrolada, para a predição de dados e avaliação da influência de determinados fatores, que causam a dependência entre variáveis (GUALTIERI et al., 2017; RAHMAN; PANCHENKO; SAFAROV, 2017). Deve-se destacar, como exemplo, a aplicação da metodologia de redes neurais artificiais (RNA), uma vez que esta possui alta capacidade de generalização, o que viabiliza o seu uso em aplicações não lineares ou com dados ruidosos. Este

modelo pode ser associado a sistemas de controle, de forma a habilitar uma rápida correção de situações emergentes antes mesmo de chegarem a um patamar de alarme (BAUGHMAN; LIU, 1995; HAYKIN, 2001).

Para Lacava (2002) a definição de novas estratégias de controle da poluição atmosférica é apontada como um dos esforços mais recentes para o monitoramento da qualidade do ar. A associação entre monitoramento e controle das emissões auxilia no planejamento e definição de estratégias, diferente das metodologias antigas, que tratavam apenas do monitoramento dos gases e geração de dados.

1.4 Organização do Texto

Neste Capítulo 1 são apresentados os conceitos introdutórios do estudo e sua contextualização. Para isso, são discutidas as principais justificativas acerca da escolha do tema, os objetivos e a linha estrutural do trabalho.

A abordagem do Capítulo 2 focará na revisão bibliográfica, na qual serão apresentados os conceitos e métodos acerca do monitoramento de indicadores de poluição atmosférica, descritos na literatura, com proposta de aplicação de plataformas alternativas de baixo custo e maior acessibilidade. Ao longo do capítulo também serão abordados os conceitos e aplicações das ferramentas utilizadas, com foco na plataforma de prototipagem (estruturada com sensores) e na metodologia de redes neurais artificiais.

No Capítulo 3 serão descritos os materiais e métodos adotados no estudo, considerando os elementos necessários para o desenvolvimento do protótipo (gases estudados e os sensores, componentes e plataforma de prototipagem utilizados), a metodologia para a programação da placa, através do *software* Arduino (IDE), a coleta de dados experimentais em Polo de Inovação do IFF e o treinamento de RNA, através do *software* Statistica® (TIBCO, versão 13.3).

Logo, no Capítulo 4, serão apresentados e discutidos os resultados do estudo realizado, destinado ao desenvolvimento de sistema protótipo inteligente, para a medição e classificação da qualidade do ar, em tempo real, e predição das concentrações de três gases poluentes atmosféricos, ao longo do tempo.

Finalmente, no Capítulo 5, serão apresentadas as principais considerações dos resultados obtidos e indicadas as recomendações para futuros trabalhos.

No Apêndice, serão dispostos os detalhes técnicos dos sensores e módulos utilizados, os códigos de programação desenvolvidos no estudo e os parâmetros (pesos e “*bias*”) das redes neurais artificiais finais, desenvolvidas para cada poluente.

2 REVISÃO BIBLIOGRÁFICA

Neste capítulo são discutidos os conceitos de poluição atmosférica e as problemáticas decorrentes da presença dos gases poluentes no ar. Tendo em vista que os padrões de qualidade do ar são avaliados através do monitoramento de indicadores de poluição e que os métodos adotados apresentam barreiras e limitações de uso, aponta-se, como alternativa, o uso de unidade microcontrolada associada a metodologia de redes neurais artificiais. Na sequência, uma revisão desse sistema é descrita, abrangendo as suas principais características, com foco nos componentes utilizados no estudo.

2.1 Poluição

O termo poluição é definido pela legislação brasileira, através da Lei Nº 6.938, de 31 de agosto de 1981, como uma alteração adversa das condições ambientais, provinda de atividades que afetem, direta ou indiretamente, a saúde, segurança e bem-estar da população, os recursos ambientais, as atividades sociais e econômicas, as condições estéticas do meio ambiente, dentre outros (BRASIL, 1981).

Os tipos de poluição existentes são denominados conforme o elemento atingido, tendo destaque para a hídrica, a atmosférica, a do solo, a sonora, a visual e a radioativa. Neste contexto, a poluição atmosférica gera bastante preocupação, visto que as emissões de gases poluentes afetam diretamente na qualidade do ar, podendo resultar em problemas na saúde da população, geração de chuva ácida, efeito estufa e diminuição da camada de ozônio (DOS SANTOS; MARTINS, 2002).

2.1.1 Poluição Atmosférica

A poluição atmosférica representa o tipo de poluição que afeta a composição química e física do ar, devido ao desequilíbrio dos seus elementos constitutivos ou pela presença de algum elemento estranho, que ocasione prejuízos ao bem-estar público, aos materiais e ao meio ambiente (DOS SANTOS; MARTINS, 2002).

As principais fontes desse tipo de emissão são representadas por três grandes classes: estacionárias, móveis e naturais. As fontes estacionárias representam as emissões decorrentes das atividades, de diferentes graus e impactos, realizadas nas áreas urbanas, como por exemplo,

dos mesmos e de seus efeitos adversos ao meio ambiente (BRASIL, 1990; FUNDAÇÃO ESTADUAL DE ENGENHARIA DO MEIO AMBIENTE, 2007).

Os gases poluentes atmosféricos representam qualquer forma de matéria ou energia que apresente características em desacordo com níveis pré-estabelecidos, podendo estar dispostos nas fases de gás ou partículas. A classificação considera a origem da emissão destes: quando ocorre de forma direta pela sua fonte diz-se que o poluente é primário, por outro lado, caso o poluente seja resultado de uma reação química ocorrida na atmosfera, classifica-o como secundário (BRASIL, 1990; FUNDAÇÃO ESTADUAL DE ENGENHARIA DO MEIO AMBIENTE, 2007).

Nos Estados Unidos da América, o *Clean Air Act*, foi estabelecido para controlar a poluição atmosférica. Nela, fica estabelecida que a Agência de Proteção Ambiental Americana (EPA, do inglês *Environmental Protection Agency*) é responsável por avaliar os principais gases poluentes atmosféricos e determinar os padrões de qualidade do ar. Este processo deverá ocorrer de forma periódica. O Quadro 1 apresenta os padrões atuais dos poluentes listados, com as concentrações em ppm (partes por milhão), ppb (partes por bilhão) e $\mu\text{g}/\text{m}^3$.

Quadro 1 - Padrões de qualidade do ar nos Estados Unidos da América.

Poluente	Padrão	Tempo Médio	Nível	Formato
Monóxido de carbono (CO)	Primário	1 hora	35 ppm	Não deve ser excedido mais de uma vez por ano.
		8 horas	9 ppm	
Chumbo (Pb)	Primário e secundário	Média de 3 meses de rolamento	0,15 $\mu\text{g}/\text{m}^3$	Não deve ser excedido.
Dióxido de nitrogênio (NO ₂)	Primário	1 hora	100 ppb	98º percentil de concentrações máximas diárias de 1 hora, com média de 3 anos.
	Primário e secundário	1 ano	53 ppb	Média anual.
Ozônio (O ₃)	Primário e secundário	8 horas	0,07 ppm	Concentração máxima anual diária de 8 horas, a média, em três anos.
Material Particulado 2,5 μm (MP _{2,5})	Primário	1 ano	12 $\mu\text{g}/\text{m}^3$	Média anual, em média, em três anos.
	Secundário	1 ano	15 $\mu\text{g}/\text{m}^3$	Média anual, em média, em três anos.
	Primário e secundário	24 horas	35 $\mu\text{g}/\text{m}^3$	98º percentil, com média de 3 anos.
Material Particulado 10 μm (MP ₁₀)	Primário e secundário	24 horas	150 $\mu\text{g}/\text{m}^3$	Não exceder mais de uma vez por ano, em média, durante três anos.
Dióxido de enxofre (SO ₂)	Primário	1 hora	75 ppb	99º percentil de concentrações máximas diárias de 1 hora, com média de 3 anos.
	Secundário	3 horas	0,5 ppm	Não deve ser excedido mais de uma vez por ano.

Fonte: Adaptado de United States Environmental Protection Agency (2017).

Os níveis dos poluentes são apresentados conforme dois tipos de padrões. No padrão primário são consideradas as concentrações dos poluentes, que, caso ultrapassadas, podem afetar à saúde da população. Os padrões secundários representam os valores mínimos das concentrações que causam efeitos adversos e visam a proteção do bem-estar da população, dos animais, das colheitas, da vegetação e dos edifícios (BRASIL, 1990; UNITED STATES ENVIRONMENTAL PROTECTION AGENCY, 2017).

Com relação ao Brasil os padrões de qualidade do ar foram estabelecidos pela Resolução N° 003/1990, descrita pelo Conselho Nacional do Meio Ambiente (CONAMA), a partir da listagem descrita no Quadro 2. Nela são apontados os poluentes e às respectivas concentrações que caso sejam ultrapassadas poderão afetar no bem-estar da população, como também causar danos à fauna, flora, materiais e meio ambiente (BRASIL, 1990).

Esses valores além de estarem correlacionados com o tipo de padrão, também são descritos com relação ao tempo de amostragem. A avaliação dos dados de concentração dos poluentes é dividida quanto aos resultados da exposição em curto período (1, 8 ou 24 horas – tempo que não deve ser excedido mais que uma vez ao ano) e em longo período (MAA - média aritmética anual; e, MGA – média geométrica anual) (BRASIL, 1990).

Quadro 2 - Padrões nacionais de qualidade do ar, segundo Resolução CONAMA N° 003/1990.

Poluente	Tempo de Amostragem	Padrão Primário ($\mu\text{g}/\text{m}^3$)	Padrão Secundário ($\mu\text{g}/\text{m}^3$)
Partículas totais em suspensão (PTS)	24 horas	240	150
	MGA	80	60
Fumaça	24 horas	150	100
	MAA	60	40
Partículas inaláveis	24 horas	150	150
	MAA	50	50
Dióxido de enxofre (SO_2)	24 horas	365	100
	MAA	80	40
Monóxido de carbono (CO)	1 hora	40.000	40.000
	8 horas	10.000	10.000
Ozônio (O_3)	1 hora	160	160
Dióxido de nitrogênio (NO_2)	1 hora	320	190
	MAA	100	100

Fonte: Adaptado de Brasil (1990).

Ressalta-se que as Resoluções CONAMA Nº 005/1989 e Nº 003/1990 apontam que a gestão do monitoramento da qualidade do ar compete aos Estados, que são responsáveis pela criação e implementação de programas para controle da poluição do ar, em linha com os padrões nacionais definidos. Neste ponto, caso o Estado julgue necessário a adoção de limites mais rígidos de emissão dos poluentes, poderão ser fixados padrões de níveis estaduais (BRASIL, 1989, 1990).

Com relação à divulgação dos dados obtidos para cada poluente, adota-se a ferramenta matemática IQAr (Índice de Qualidade do Ar), fundamentada na metodologia concebida pelo PSI (*Pollutant Standard Index*, ou índice padrão de poluentes), desenvolvida pela EPA. O índice é calculado para cada poluente, a partir de uma função linear segmentada, para no final classificar a qualidade do ar considerando o índice mais elevado, conforme Tabela 1 (FUNDAÇÃO ESTADUAL DE ENGENHARIA DO MEIO AMBIENTE, 2007).

Tabela 1 - Faixas de classificação do índice de qualidade do ar, em função das concentrações dos gases poluentes.

Qualidade	Índice	MP ₁₀ (µg/m ³)	O ₃ (µg/m ³)	CO (ppm)	NO ₂ (µg/m ³)	SO ₂ (µg/m ³)
Boa	0 – 50	0 – 50	0 – 80	0 – 4,5	0 – 100	0 – 80
Regular	51 – 100	50 – 150	80 – 160	4,5 - 9	100 – 320	80 – 365
Inadequada	101 – 199	150 – 250	160 – 200	9 – 15	320 – 1130	365 – 800
Má	200 – 299	250 – 420	200 – 800	15 – 30	1130 – 2260	800 – 1600
Péssima	> 299	> 420	> 800	> 30	> 2260	> 1600

Fonte: Adaptado de Instituto Estadual do Ambiente e Gerência de Qualidade do Ar (2016).

Esses valores são determinados a partir da associação com os efeitos à saúde, conforme Quadro 3.

Quadro 3 - Faixas de classificação do índice de qualidade do ar, correlacionados com os efeitos à saúde.

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

Fonte: Instituto Estadual do Ambiente e Gerência de Qualidade do Ar (2016).

Considerando os indicadores de poluição atmosférica adotados pelo último relatório da qualidade do ar do Estado do Rio de Janeiro, elaborado pelo Instituto Estadual do Ambiente (INEA) e pela Gerência de Qualidade do Ar (Gear) (2016), as próximas seções apresentam um resumo desses itens.

2.1.2.1 Partículas Inaláveis

As partículas inaláveis são constituídas de uma mistura heterogênea de partículas, presentes nos estados sólido e líquido, e com diferentes tamanhos e composições químicas (BROOK et al., 2004). Derivam de diversos fatores, incluindo atividades antropogênicas (emissões resultantes da: a) queima de combustíveis fósseis e de biomassa vegetal; b) agricultura – gases de amônia; e, c) obras de construção, demolição e pavimentação de vias) e reações atmosféricas entre outros gases poluentes (BRASIL, 2017; DICKEY, 2000).

O conjunto mais amplo desse tipo de poluente é denominado de partículas totais em suspensão (PTS), que considera as partículas inferiores a 100 µm. Tendo em vista que a preocupação toxicológica está diretamente relacionada ao diâmetro das partículas, alterou-se o foco de atenção das PTS para o conjunto de materiais particulados (MP). Isto porque, o MP é constituído de partículas que podem penetrar facilmente no trato respiratório, podendo resultar nos seguintes efeitos na saúde da população: problemas respiratórios, inflamação no pulmão, câncer e morte (BRASIL, 2017; BROOK et al., 2004; CURTIS et al., 2006).

Deve-se frisar que o principal destaque no estudo dos materiais particulados está relacionado às partículas inferiores a 10 μm (MP_{10}) ou a 2,5 μm ($\text{MP}_{2,5}$) (CURTIS et al., 2006).

2.1.2.2 Dióxido de Enxofre

O dióxido de enxofre (SO_2) é um gás tóxico, incolor e de odor característico. É um dos principais componentes atmosféricos de enxofre, devido à sua alta reatividade química. Suas fontes de emissão derivam das atividades de fontes naturais, como erupções vulcânicas, e de fontes antropogênicas, como, queima de combustíveis contendo enxofre e fundição dos minérios metálicos. Uma vez exposto à atmosfera, o gás se desloca pelo ar, podendo sofrer reações químicas de conversão para ácido sulfúrico (H_2SO_4), trióxido de enxofre (SO_3) e sulfatos (SO_4^{2-}). Caso reaja com a água da atmosfera poderá, também, formar chuva ácida (CURTIS et al., 2006; GODISH, 2004; POHL; LICCIONE; IANNUCCI, 1998).

Dentre os efeitos causados por esse poluente, o Ministério do Meio Ambiente do Brasil destaca problemas respiratórios e formação de material particulado secundário. Caso a exposição ao gás ocorra em níveis elevados, poderá resultar em fatalidade. Os episódios mais críticos normalmente estão associados à formação de partículas de sulfatos (BRASIL, 2017; BROOK et al., 2004; POHL; LICCIONE; IANNUCCI, 1998).

2.1.2.3 Dióxido de Nitrogênio

O dióxido de nitrogênio (NO_2) é um gás tóxico, corrosivo, com odor característico e de alta ação oxidante. Apresenta coloração que varia entre amarelo e marrom, dependo da sua concentração na atmosfera. Similar ao componente anterior, o dióxido de nitrogênio é emitido através de ações resultantes de fontes naturais, como vulcanismo, ações bacterianas e descargas elétricas, e de fontes antropogênicas, como combustão industrial e veicular. Ressalta-se que a oxidação de fertilizantes industriais também agrega nessas emissões (CURTIS et al., 2006; GODISH, 2004).

Brasil (2017), Brook et al. (2004) e Godish (2004) alertam que esse é um dos componentes críticos formados pelo nitrogênio, no qual concentram os estudos de toxicologia e epidemiologia, visto que as suas moléculas são precursoras para muitas reações atmosféricas importantes, tais como a formação de ozônio troposférico. Desta forma, a sua presença no ar

acarreta em efeitos sobre a saúde humana (problemas respiratórios, pulmonares e alergênicos) e sobre o meio ambiente (formação de chuva ácida).

2.1.2.4 Ozônio

O ozônio (O_3) é um gás com odor característico e tonalidade entre incolor e azulado. Esse gás é um constituinte natural formado na camada de estratosfera, com a importante função de bloquear a luz ultravioleta nociva do sol, através do processo de absorção. Quando esse componente está presente na camada de troposfera (camada inferior da atmosfera), constitui em um poluente tóxico para os seres humanos, com elevada ação oxidante (BROOK et al., 2004; CURTIS et al., 2006).

O ozônio troposférico resulta a partir de diferentes processos, como relâmpagos e reações químicas complexas, decorrentes da queima de combustíveis fósseis. Estas reações ocorrem pelo envolvimento de óxidos de nitrogênio e compostos orgânicos voláteis na presença de radiação solar (BRASIL, 2017).

Nessa linha, Godish (2004), afirma que as principais preocupações referentes a este gás podem ser divididas em duas, sendo a primeira relacionada à estratosfera (esgotamento) e a segunda à troposfera (concentrações elevadas no ar, acarretando em doenças pulmonares e cardiovasculares, podendo reduzir a expectativa de vida) (BRASIL, 2017).

2.1.2.5 Monóxido de Carbono

O monóxido de carbono (CO) é um gás incolor, inodoro e insípido, resultante da combustão incompleta de combustíveis, que ocorre quando não existe oxigênio suficiente para realizar a reação completa. Suas principais fontes são processos de combustão de veículos automotores, aquecimento, geração de energia e queima de biomassa (BROOK et al., 2004; CURTIS et al., 2006).

Os efeitos que este gás tem sobre a saúde humana estão relacionados com a sua alta afinidade com a hemoglobina, que acarreta na diminuição da capacidade de transporte do oxigênio do sangue. A exposição dos seres humanos a baixos níveis de CO resulta em dores de cabeça, fadiga e sintomas gripais, enquanto que as altas concentrações podem gerar quadros de asfixia e morte (BRASIL, 2017; DICKEY, 2000).

Apesar deste poluente ser tóxico, sua presença no ar é considerada, muitas das vezes, apenas como um indicativo de poluição atmosférica, não sendo julgada a sua toxicidade direta (BRASIL, 2017; BROOK et al., 2004).

2.2 Métodos de Medição dos Poluentes Atmosféricos

A metodologia para monitoramento dos índices de poluição está atrelada à medição dos poluentes atmosféricos, em escalas temporais e espaciais. Para isto, após a determinação dos gases a serem medidos, são escolhidos os equipamentos de medição, considerando os aspectos a serem avaliados, as suas metodologias empregadas, os respectivos custos e a performance de operação (LACAVA, 2002).

No Brasil, os Estados devem adotar a Resolução N° 003/1990, descrita pelo CONAMA, que apresenta uma relação dos métodos a serem utilizados para a amostragem e análise das concentrações dos poluentes atmosféricos. Nela estão descritos métodos como: amostrador de grandes volumes; refletância; separação inercial e infravermelho não dispersivo. Os métodos, no entanto, poderão ser substituídos por métodos equivalentes, quando aprovados pelo Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais, IBAMA (BRASIL, 1990).

Como exemplo, o INEA realiza o monitoramento da qualidade do ar no Estado do Rio de Janeiro através de duas redes: automática e semiautomática. Na rede automática são realizadas medições contínuas (horárias) das concentrações dos gases poluentes dispersos no ar (dióxido de nitrogênio, monóxido de carbono, dióxido de enxofre, ozônio, hidrocarbonetos, compostos orgânicos voláteis e material particulado – PTS e MP₁₀) e dos parâmetros meteorológicos (direção e velocidade do vento, temperatura, umidade, radiação solar, pressão atmosférica e precipitação). Na rede semiautomática são monitoradas as concentrações de material particulado (PTS, MP_{2,5} e MP₁₀), por 24 horas ininterruptas, a cada 6 dias (INSTITUTO ESTADUAL DO AMBIENTE; GERÊNCIA DE QUALIDADE DO AR, 2016).

O Quadro 4 apresenta os métodos adotados em cada rede, para a medição dos parâmetros relativos aos gases poluentes atmosféricos.

Quadro 4 - Métodos adotados pelo INEA para detecção dos gases poluentes atmosféricos no Estado do Rio de Janeiro.

Rede	Poluente	Método
Rede automática	PTS	Absorção de raios beta
	MP ₁₀	Absorção de raios beta
	SO ₂	Fluorescência de pulso (ultravioleta)
	NO _x	Quimiluminescência
	CO	Infravermelho não dispersivo (GFC)
	O ₃	Fotometria de ultravioleta
	Hidrocarbonetos	Ionização de chama
Rede semiautomática	PTS	Amostrador de grandes volumes (MF606; NBR 9547)
	MP ₁₀	Amostrador de grandes volumes (NBR 13412)
	MP _{2,5}	Amostrador de grandes volumes

Fonte: Instituto Estadual do Ambiente e Gerência de Qualidade do Ar (2016).

No geral, os equipamentos mais utilizados na literatura são ordenados nos seguintes grupos de classificação: amostradores ativos, amostradores passivos, analisadores automáticos e sensores remotos. Desse conjunto, os dois últimos apresentam melhores resultados, visto que possibilitam a medição de diferentes gases, em longos períodos, com alta eficiência. Porém, devido à complexidade dessas metodologias, seu uso torna-se inviável em determinadas aplicações (LACAVA, 2002).

Como alternativa, estudos avaliam o uso de unidades microcontroladas para o monitoramento da qualidade do ar, quanto à viabilidade de aplicação de plataformas mais simples e de menor custo, com possibilidade de medições em tempo real. Gunawan et al. (2018), por exemplo, desenvolveram um sistema para a medição da qualidade do ar utilizando quatro sensores conectados a uma placa de Arduino Uno, para a medição de CO, O₂ (oxigênio), MP₁₀ e MP_{2,5}. O sistema, que se mostrou confiável e eficiente, foi proposto pelos autores como uma alternativa ao método adotado pelo Departamento de Meio Ambiente da Malásia, e como uma forma de medição das partículas de 2,5 µm.

De forma similar, Maraj et al. (2017) avaliaram a implementação de uma plataforma composta por um sensor eletroquímico ligado a uma placa de Arduino Uno, na medição em tempo real da qualidade do ar em Prishtina, Kosovo, com relação ao material particulado. Como considerações, os autores enfatizaram que o investimento em sistemas como o estudado (de baixo custo) possibilitam a geração de uma grande quantidade de dados experimentais, que

podem ser utilizados como insumos nas análises de aquecimento global e relação das concentrações dos poluentes com o número de doenças.

Dado que o escopo deste trabalho finda o desenvolvimento de uma plataforma microcontrolada, as próximas seções têm como objetivo abordar os conceitos acerca desta área, detalhando os elementos utilizados no estudo.

2.3 Método Alternativo para Medição: Principais Elementos

Nessa seção serão discutidos os elementos disponíveis no mercado que possibilitam a medição das características ambientais atreladas à qualidade do ar.

2.3.1 Sistemas de Aquisição de Dados e Microcontroladores

Sistemas de aquisição são dispositivos que permitem as leituras e coletas de dados, a partir dos elementos de *hardware* associados aos sistemas de *software*. Esses dispositivos normalmente são formados por circuitos eletrônicos complexos, compostos por microcontroladores, que viabilizam o monitoramento contínuo de variáveis a partir de uma estrutura encapsulada em um único *chip*. Devido a tal fator, seu uso é extenso em processos de controle, visto que reduzem os custos de automação e proporcionam maior flexibilidade. As plataformas de maior destaque são: placas de Arduino e Raspberry Pi (DA SILVA; CHOQUE, 2016; VIEIRA; ANDRADE; FIGUEIREDO, 2016).

O uso da placa de Arduino é amplamente difundido na literatura, devido aos benefícios como baixo custo, disponibilidade de uso em diferentes sistemas operacionais, ambiente de programação simples e claro e código aberto. O seu funcionamento ocorre a partir da comunicação entre sensores e diferentes componentes (DI JUSTO; GERTZ, 2013; JAVED, 2017). Para isso, todos os comandos e informações necessárias para configurar a placa são descritos a partir de codificação pelo *software* Arduino (IDE, do inglês *Integrated Development Environment*, ou, ambiente de desenvolvimento), em linguagem compatível (C++ modificada).

2.3.2 Sensores, Módulos e Demais Componentes

Nesta seção são descritos os principais aspectos referentes aos sensores, módulos e demais componentes necessários para a medição das concentrações dos gases poluentes

atmosféricos, das condições ambientais e para auxílio das análises. Os detalhes com relação às especificações técnicas dos mesmos estão descritos no Apêndice A.

2.3.2.1 Sensor de Ozônio

O sensor MQ-131 permite a detecção de ozônio no ar. Seu princípio de funcionamento considera o uso de um material semiconductor (óxido de estanho), que assegura a sensibilidade do sensor, visto que em condições de ar limpo (condição de ausência do gás medido) este material apresenta baixa condutividade e, por outro lado, quando é exposto ao ozônio, sua condutividade aumenta (INTERNATIONAL FREQUENCY SENSOR ASSOCIATION (IFSA), 2009).

Quando este sensor é conectado a uma plataforma de prototipagem, como o Arduino, as suas leituras são feitas pela porta analógica a qual estiver conectada, recebendo valores entre 0 e 1023, correspondentes à 0V e 5V, respectivamente. Assim, é possível obter a concentração de ozônio (em ppb) a partir da correlação da variável R_s/R_0 calculada (razão entre a resistência do sensor medida e a resistência do sensor em ar limpo) com a curva de sensibilidade, descrita na Figura 2 (INTERNATIONAL FREQUENCY SENSOR ASSOCIATION (IFSA), 2009).

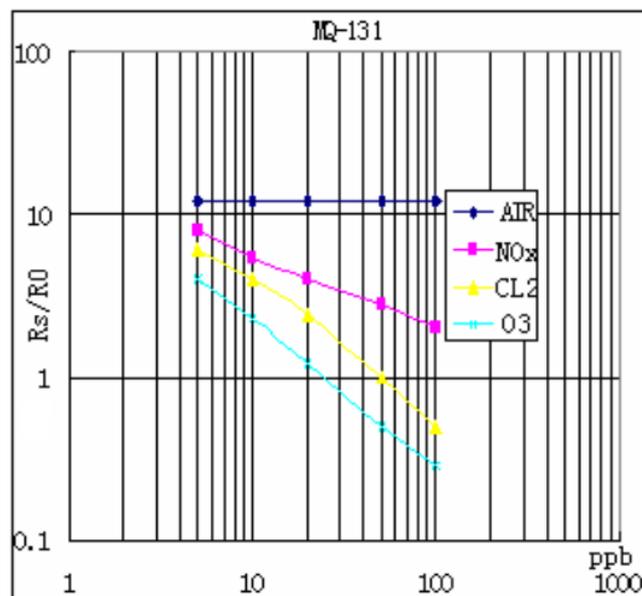


Figura 2 - Curva de sensibilidade do sensor MQ-131 a diferentes gases.

Fonte: Adaptado de Hanwei Electronics Co, LTD (2009) e International Frequency Sensor Association (IFSA) (2009).

2.3.2.2 Sensor de Monóxido de Carbono

O sensor MICS-5524, por outro lado, representa um sistema Micro eletromecânico (MEMS, do inglês *Micro-Electro-Mechanical-Systems*), projetado para detectar vazamentos de monóxido de carbono e gás natural (SGX SENSORTECH, 2016).

A obtenção da concentração de monóxido de carbono (em ppm) é similar a lógica adotada para o sensor MQ-131. Para isso, deve-se calcular a razão R_s/R_0 do sensor e correlacionar com a curva de sensibilidade descrita na Figura 3 (SGX SENSORTECH, 2016).

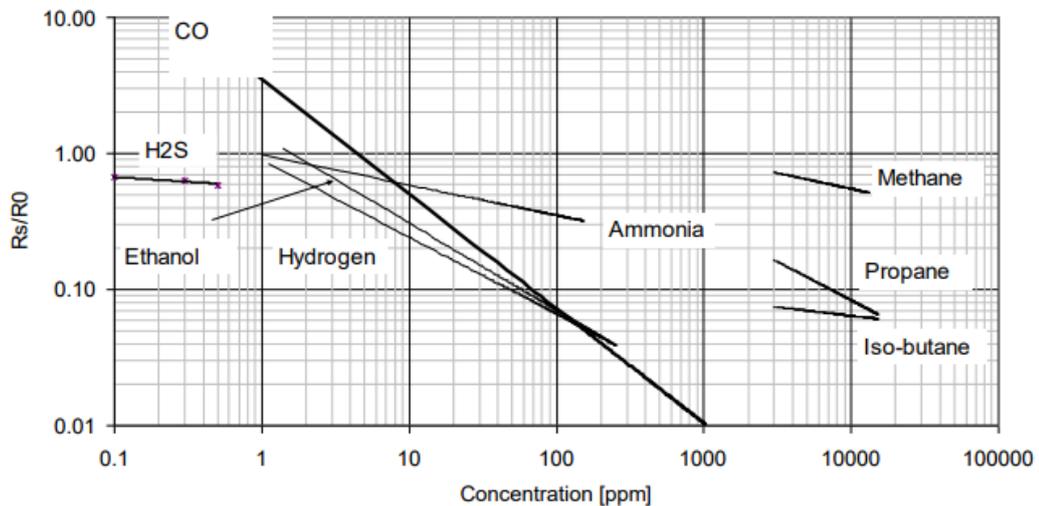


Figura 3 - Curva de sensibilidade do sensor MICS-5524 a diferentes gases.

Fonte: SGX Sensortech (2016).

2.3.2.3 Sensor de Material Particulado

O sensor PPD42, desenvolvido pela Shinyei Technology CO., LTD., é utilizado para determinar a concentração de material particulado a partir da detecção das partículas transportadas pelo ar, por método de dispersão da luz (SHINYEI TECHNOLOGY, 2018).

A forma na qual o sensor opera está diretamente relacionada aos componentes presentes em sua estrutura (conforme o revestimento superior representado na Figura 4).

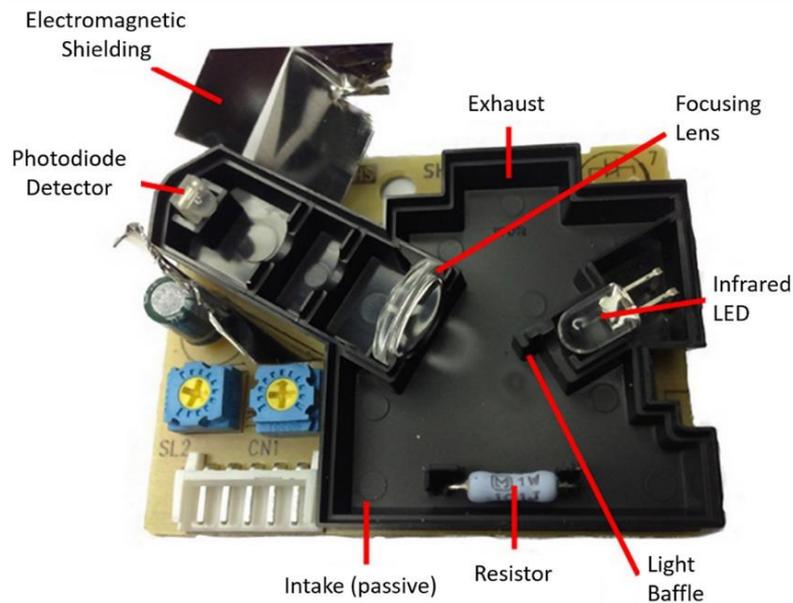


Figura 4 - Componentes presentes no sensor PPD42.

Fonte: Heimbinder (2013).

A resistência (*resistor*) fornece um aquecimento que direciona o fluxo de ar (composto de partículas) para o interior da carcaça do sensor. O feixe de luz infravermelha do LED (*infrared LED*) é focado com as lentes (*focusing lens*) do detector (*photodiode detector*) no centro, que caracterizará o ponto de detecção. Assim, no momento da leitura, o detector irá avaliar as partículas que passaram no ponto de detecção, gerando um sinal da dispersão da luz, que será convertido em sinal de pulso (MARAJ et al., 2017).

Basicamente, a detecção deste sensor é feita a partir contagem do tempo de ocupação do pulso Lo (LPO, saída digital), através do esquema representado na Figura 5, e posterior correlação com curva de sensibilidade do sensor, para determinação da concentração do MP. Isto é possível uma vez que a saída do pulso corresponde à concentração por unidade de volume de partículas (SHINYEI, 2010; SHINYEI TECHNOLOGY, 2018).

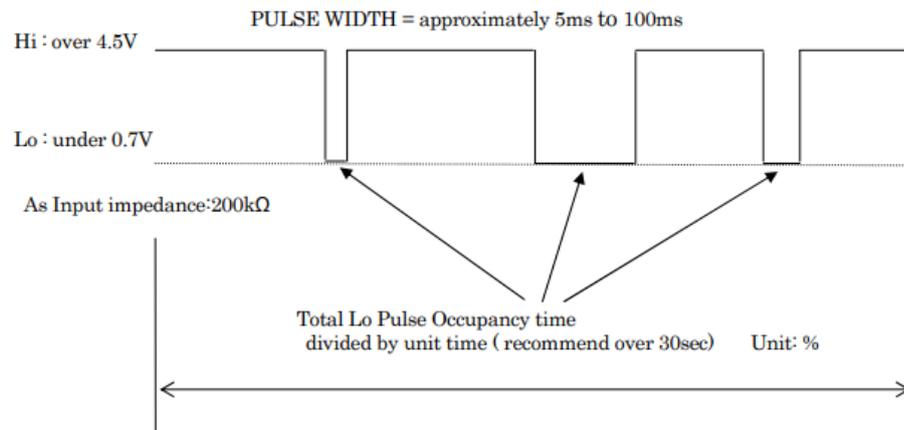


Figura 5 - Esquema representativo da medição do sensor PPD42.

Fonte: Shinyei Technology (2013).

A Figura 6 apresenta as curvas características de saída do sensor (mínima, máxima e média), considerando partículas com diâmetro maior que 1 μm (detectadas pelo pino P1), quando exposto à fumaça do cigarro.

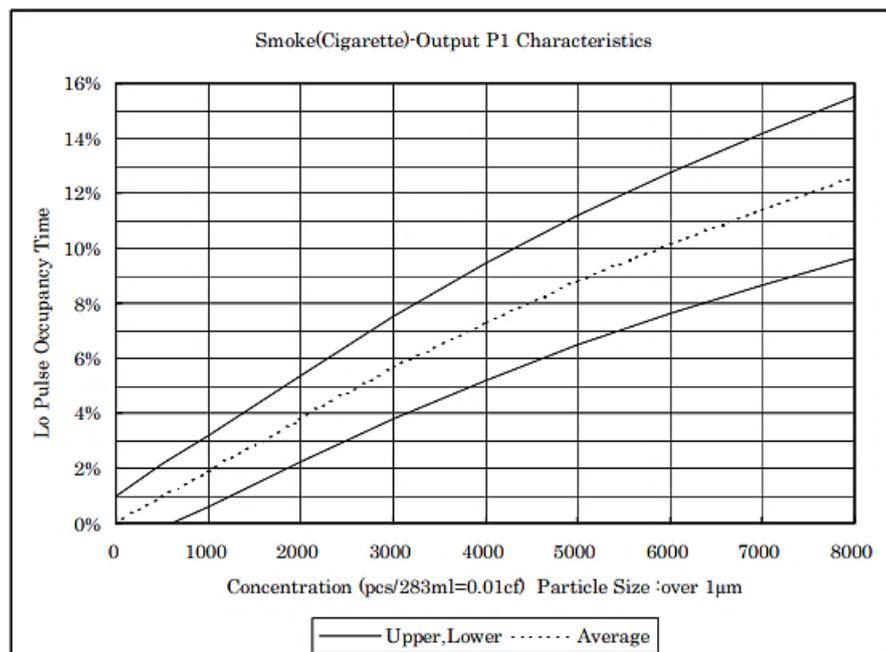


Figura 6 – Curvas características de sensibilidade do pino P1 do sensor PPD42.

Fonte: Shinyei Technology (2013).

2.3.2.4 Sensor de Temperatura e Umidade Relativa

O sensor DHT-11 permite a medição de temperatura (T) e umidade relativa (UR), a partir de uma saída de sinal digital calibrada. Seu uso é amplamente difundido na literatura, devido às seguintes vantagens: estabilidade a longo prazo, resposta rápida, capacidade anti-interferência e baixo custo (AOSONG, 2013; D-ROBOTICS UK, 2010).

A leitura do DHT-11 é realizada quando este sensor está conectado à um microcontrolador (MCU). Quando o MCU envia um sinal de partida, o sensor sai do modo de baixo consumo de energia para o modo operacional, realiza um processo de comunicação com o MCU, transmite um sinal de 40 bits com os dados medidos de temperatura e umidade relativa e volta para o modo de baixo consumo (D-ROBOTICS UK, 2010, p.). A Figura 7 apresenta o esquema dessas etapas, onde “Host signal” e “Slave signal” representam os sinais do MCU e do DHT-11, respectivamente.

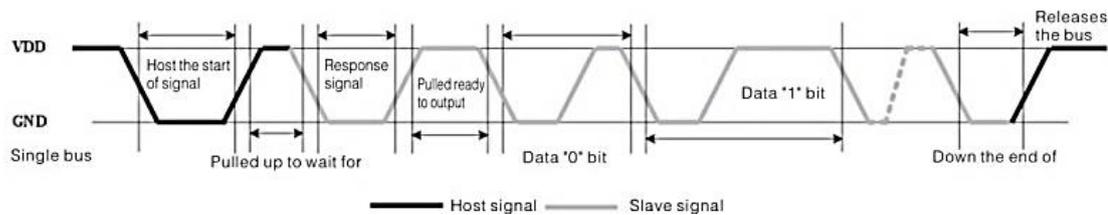


Figura 7 - Esquema de funcionamento do sensor DHT-11.

Fonte: Aosong (2013).

O processo de comunicação é feito por uma interface serial, com barramento único e duas vias (*Single-Wire Two-Way*). Os dados enviados pelo sensor consistem em partes integrais e decimais e atendem o seguinte formato: Parte integral dos dados de UR (8 bits) + Parte decimal dos dados de UR (8 bits) + Parte integral dos dados de T (8 bits) + Parte decimal dos dados de T (8 bits) + Soma de verificação (8 bits) (D-ROBOTICS UK, 2010, p.). A Figura 8 demonstra um exemplo de interpretação dos dados transmitidos pelo DHT-11.

Example 1: 40 data is received:				
<u>0011 0101</u>	<u>0000 0000</u>	<u>0001 1000</u>	<u>0000 0000</u>	<u>0100 1101</u>
High humidity 8	Low humidity 8	High temp. 8	Low temp. 8	Parity bit
Calculate:				
0011 0101+0000 0000+0001 1000+0000 0000= 0100 1101				
Received data is correct:				
Humidity: 0011 0101=35H=53%RH				
Temperature: 0001 1000=18H=24°C				

Figura 8 - Exemplo do envio de dados pelo sensor DHT-11.

Fonte: Aosong (2013).

2.3.2.5 Sensor de Pressão Barométrica e Temperatura

O sensor BMP085, desenvolvido pela Bosch, permite a leitura de pressão barométrica e de temperatura, com alta precisão e baixa potência de uso. Sua tecnologia se baseia no princípio piezo-resistivo e apresenta alta precisão e estabilidade a longo prazo (BOSCH SENSORTEC, 2008).

Quando conectado à um microcontrolador é possível obter os dados de pressão e de temperatura através de um circuito inter-integrado (I²C, do inglês *Inter-Integrated Circuit*), no qual as informações são compensadas com dados de calibração armazenados individualmente em uma memória descrita como E2PROM (do inglês *Electrically-Erasable Programmable Read-Only Memory*), em 176 bits (BOSCH SENSORTEC, 2009).

2.3.2.6 Módulo de Relógio e Calendário

O RTC DS1307 (do inglês *Real-Time Clock*), é um relógio e calendário de codificação binária completa (BCD, do inglês *Binary-coded decimal*). Seu uso possibilita o fornecimento dos seguintes parâmetros: segundos, minutos, horas, dia, mês e ano. Segundo Dallas Semiconductor (2001) este módulo também opera sem fornecimento de energia, devido à um circuito integrado que altera para uma bateria quando houver falha no fornecimento.

2.4 Métodos para a Previsão da Qualidade do Ar

As unidades microcontroladas podem ser utilizadas em conjunto com outros métodos, para obter além das medições uma correlação entre diferentes variáveis. Este ponto foi abordado por Gualtieri et al. (2017), que utilizaram uma plataforma integrada de monitoramento, composta por uma unidade de monitoramento da qualidade do ar (referentes aos gases CO, NO₂ e CO₂) em conjunto com um dispositivo para monitoramento de tráfego e uma infraestrutura de dados espaciais (um *GeoDatabase* central, um mecanismo GIS e uma interface *web*) para avaliar a influência do tráfego rodoviário local e das condições meteorológicas nas concentrações dos gases poluentes. Neste estudo, a avaliação foi feita através da aplicação dos métodos de regressão linear e rede neural artificial (RNA), que resultou na identificação de uma maior influência com relação aos parâmetros meteorológicos.

Neste ponto, destaca-se que o uso de redes neurais artificiais tem crescido nas aplicações na literatura, visto que possibilita aproximar funções complexas, nas quais não se tem um conhecimento detalhado do estudo, sendo esta uma propriedade comum nos modelos não-paramétricos. Para isso faz-se necessário apresentar um conjunto de dados de entrada/ saída, relativamente grande, para que a rede seja treinada e possa estabelecer o padrão de dependência entre essas variáveis. Isto possibilita então a predição dos dados de saída de uma determinada variável a partir dos dados de entrada das variáveis nas quais ela depende (BAUGHMAN; LIU, 1995; HAYKIN, 2001).

A avaliação da capacidade preditiva da RNA foi discutida no estudo desenvolvido por Rahman, Panchenko e Safarov (2017), com foco na previsão dos índices de poluição do ar da cidade Sterlitamak, localizada na Rússia. Foram desenvolvidos dois modelos neurais para a previsão temporal (das concentrações dos gases poluentes nas próximas 24 horas) e espacial (do índice de poluição do ar em diferentes pontos da cidade). Os treinamentos das redes consideraram dados meteorológicos, condições do ambiente e resultados de análises amostrais de toxicidade. Também foi elaborada uma implementação de *software* com o pacote de RNA do *software* Matlab, com o intuito de realizar os cálculos práticos de previsão. Visto que em ambos os casos a precisão foi superior a 70%, os modelos se mostraram satisfatórios. Os autores ressaltaram a importância do alinhamento destes estudos com uma gestão ambiental competente, de forma a alcançar melhores resultados.

Visto que a técnica de RNA foi utilizada nesse estudo, as próximas seções descrevem os principais conceitos e as informações necessárias para a modelagem da rede.

2.4.1 Rede Neural Artificial

As redes neurais artificiais foram desenvolvidas considerando as funções biológicas. Neste contexto, o neurônio artificial visa simular o neurônio biológico, que é responsável pelo processamento das funções e movimentações do organismo (HAYKIN, 2001).

Segundo Haykin (2001) e Benitez, Castro e Requena (1997), a RNA é estruturada a partir de unidades de processamento (neurônios) maciços, paralelamente distribuídos na rede, que serão responsáveis pela aprendizagem da mesma. O processamento interno ocorre de forma independente da natureza fenomenológica do processo a ser abordado (modelo “caixa preta”), modelando a forma na qual o cérebro humano trabalha.

Os benefícios que essa técnica proporciona estão relacionados a forma na qual a RNA atua em um processo, após a apresentação de dados característicos do mesmo. Devido à sua habilidade de aprendizado, ela pode ser utilizada em processos não lineares ou com dados ruidosos, incompletos ou inconsistentes (BAUGHMAN; LIU, 1995; HAYKIN, 2001).

Porém, a grande dificuldade de utilização de uma RNA ocorre devido à necessidade de um conjunto relativamente grande de dados de entrada/ saída do processo para seu treinamento, que nem sempre estão disponíveis ou passíveis de obtenção. Dessa forma, as limitações pertinentes à essa técnica se relacionam com os longos tempos de treinamento, a necessidade de grande quantidade de dados coletados e a falta de garantia de resultados ótimos (BAUGHMAN; LIU, 1995).

2.4.2 Modelagem da RNA

A estrutura de uma RNA consiste em camadas de neurônios conectadas entre si. Segundo Baughman e Liu (1995), a estrutura mais comumente utilizada apresenta uma camada de entrada, uma camada escondida (ou oculta) e uma camada de saída, interligadas através de uma conexão *feedforward*, conforme modelo representado pela Figura 9.

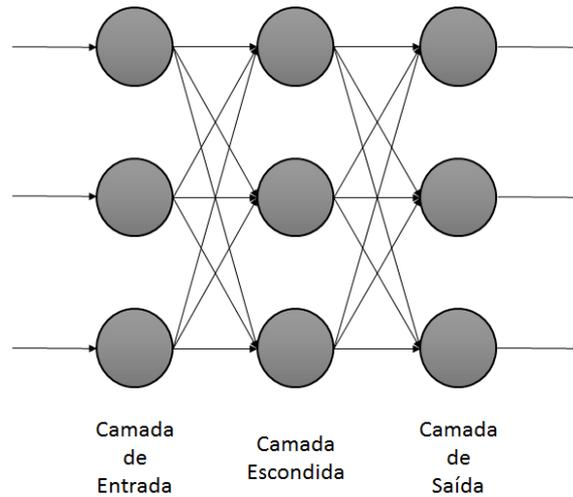


Figura 9 - Modelo de RNA multicamadas.

Nesta estrutura, a camada de entrada é responsável por receber as informações externas e enviar as mesmas para a camada escondida. Esta camada será responsável por todo processamento realizado, através da análise e resolução do problema, sem a disponibilização dos passos. Por fim, a informação final é repassada à camada de saída, que enviará o resultado ao meio externo. Ressalta-se que a conexão *feedforward* visa treinar a RNA para determinar os valores de saída através dos sinais de entrada (BAUGHMAN; LIU, 1995).

Para que a modelagem seja realizada, é necessário avaliar a estrutura individual do neurônio. Para isso, os principais componentes do neurônio artificial são: entradas, saídas, pesos, “*bias*” e funções de ativação (HAYKIN, 2001). A Figura 10 apresenta a estrutura do $j^{\text{ésimo}}$ neurônio, com esses componentes.

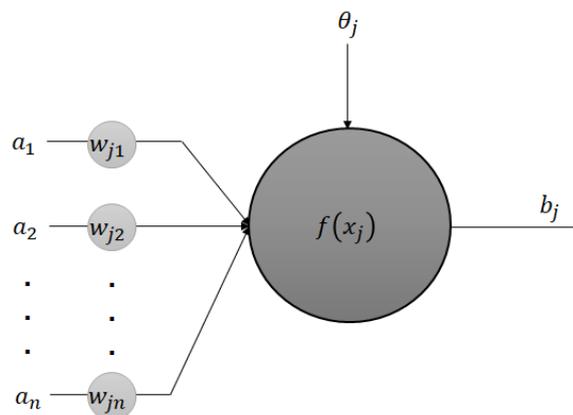


Figura 10 - Estrutura do $j^{\text{ésimo}}$ neurônio.

Neste modelo, a_i representa os sinais de entrada, w_{ji} os pesos individuais de cada entrada, θ_j um parâmetro externo (“bias”), x_j o total de ativação de um neurônio, $f(x_j)$ a função de ativação e b_j os sinais de saída, considerando-se i como a entrada da sinapse no neurônio j . Basicamente, as entradas são multiplicadas pelos seus respectivos pesos e somadas aos “bias”, cujo efeito é de aumentar ou diminuir a entrada líquida da função de ativação. Ao final, após a realização da função de ativação, obtêm-se o valor da saída deste neurônio.

Em termos matemáticos, o total de ativação do neurônio é descrito pela Equação (1), enquanto que a Equação (2) descreve a função de transferência (função de ativação).

$$\text{Total de ativação} = x_j = \sum_{i=1}^n (w_{ji} \cdot a_i) + \theta_j \quad (1)$$

$$f(x_j) = f(w_{ji} \cdot a_i + \theta_j) = f\left(\sum_{i=1}^n (w_{ji} \cdot a_i) + \theta_j\right) \quad (2)$$

Com relação à forma de $f(x_j)$, podem ser utilizadas diferentes funções, tais como, identidade, logística, tangente hiperbólica, exponencial e seno (BAUGHMAN; LIU, 1995). A escolha dependerá dos dados analisados e do *software* utilizado para o treinamento da rede.

Após os estudos realizados com o neurônio artificial isolado, devem ser determinados outros parâmetros da rede, a fim de realizar o treinamento da mesma. Abaixo seguem alguns desses itens (BAUGHMAN; LIU, 1995; DE SOUZA JR., 1993; HAYKIN, 2001):

1. Tipos de RNA: os principais tipos de RNA utilizados na literatura são os *Perceptrons* de Múltiplas Camadas (MLP, do inglês *Multilayer Perceptron*) e as Redes de Função de Base Radial (RBF, do inglês *Radial Basis Function*). O MLP é o mais utilizado, pois apresenta alta capacidade de generalização, sendo aplicado em situações nas quais a conexão entre as redes é a *feedforward*, com algoritmo *backpropagation* (descrito abaixo, no item 4). A RBF, por outro lado, realiza a projeção da RNA a partir da aproximação no ajuste de curva em um espaço de alta dimensionalidade, o que resulta, geralmente, em erros menores e convergência mais rápida que as redes MLP.
2. Conjunto de dados: esta etapa ocorre antes do treinamento e consiste em separar os dados coletados em subconjuntos para treinamento, para teste e para

validação, através de proporção estipulada. Dependendo do *software* poderá ser definida a proporção de dados para cada subconjunto.

3. Tipo de Aprendizado: consiste em estabelecer o processo de aprendizagem das redes neurais artificiais, através da classificação entre o relacionamento da RNA com o ambiente. Neste contexto, são adotados dois tipos de aprendizado: o supervisionado e o não-supervisionado. No primeiro, existe um “professor” na estrutura da rede, que será responsável por correlacionar os dados de saída da RNA com a saída desejada (resultado previamente conhecido) e assim, realizar os ajustes necessários nos pesos entre os neurônios, para minimizar os erros, até um critério aceitável. Por outro lado, no aprendizado não-supervisionado não existe uma saída conhecida para comparação e assim o ajuste dos pesos ocorre através de classificações dos padrões de entrada.

4. Algoritmo de Treinamento: tendo em vista que o tipo de rede MLP e o aprendizado supervisionado são os mais utilizados na literatura, o principal algoritmo de treinamento destes é o *backpropagation*, que realiza os ajustes dos pesos e “*bias*” através da retropropagação do erro encontrado para cada interação. Neste caso, o treinamento da rede corresponde em minimizar a função objetivo não linear, que dá o erro entre as saídas preditas pela rede e as saídas alvos. Os ajustes dos pesos são realizados considerando a Equação (3), onde Δw_{ij} é a variação do peso para a conexão i do neurônio j , η_j é a constante linear de proporcionalidade do neurônio (normalmente $0 < \eta_j \ll 1$), a_i consiste na entrada i e E é o erro quadrático (quadrado da diferença entre as saídas preditas e as saídas alvos).

$$\Delta w_{ij} = \eta_j \cdot a_i \cdot E \quad (3)$$

5. Fase de Teste: esta fase ocorre após o treinamento e tem como objetivo verificar a performance da RNA estabelecida. Para isso, são apresentados os subconjuntos de dados separados para teste e avaliados os resultados da rede treinada, através de duas etapas. Na primeira (recordação) são apresentados os dados de entrada, cujas saídas são conhecidas pela rede, enquanto que na segunda (generalização),

são enviados dados de entrada, cujas saídas são conhecidas pelo observador, porém desconhecidas pela rede, a fim de avaliar os erros obtidos entre os valores preditos *versus* os valores observados. Ressalta-se que o cálculo dos erros de treinamento e de teste podem ser utilizados como critério de parada do treinamento, conforme representado pela Figura 11.

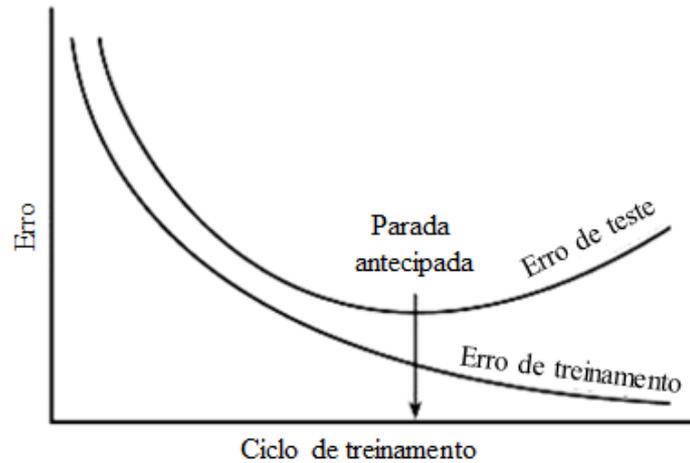


Figura 11 - Esquema de funcionamento do treinamento com os subconjuntos de dados para treinamento e para teste.

Fonte: Adaptado de Baughman e Liu (1995).

3 MATERIAL E MÉTODOS

Neste capítulo são apresentados os materiais e métodos utilizados para desenvolver o sistema protótipo de monitoramento da qualidade do ar e predição das concentrações de três gases poluentes atmosféricos. Para isso, são descritos os gases estudados, os sensores utilizados e a plataforma de prototipagem adotada para a montagem da estrutura. Em seguida, é apresentada a metodologia da coleta de dados, do treinamento das redes neurais artificiais e da inclusão do modelo neural no sistema em estudo.

3.1 Descrição do Objeto em Estudo

O objeto em estudo consiste em um sistema protótipo para monitoramento e predição das concentrações de gases poluentes atmosféricos, através de uma unidade microcontrolada. Dessa forma, as próximas seções descrevem os principais elementos avaliados, desde a escolha dos gases medidos até a estrutura do sistema, que correlacionou um arranjo de sensores com uma ferramenta inteligente para predição dos dados.

3.1.1 Gases Químicos

Neste trabalho considerou-se o estudo de três indicadores de poluição atmosférica, da relação adotada pelo último relatório da qualidade do ar do Estado do Rio de Janeiro (INSTITUTO ESTADUAL DO AMBIENTE; GERÊNCIA DE QUALIDADE DO AR, 2016): material particulado ($MP_{2,5}$), ozônio e monóxido de carbono.

A partir da medição desses gases, buscou-se o desenvolvimento de um sistema capaz de avaliar a qualidade do ar através dos índices determinados pela Resolução N° 003/1990 do CONAMA, atribuindo as seguintes classificações (BRASIL, 1990): boa, regular, inadequada, má e péssima.

Para os cálculos dos índices dos poluentes considerou-se as faixas adotadas pela Environmental Protection Agency (2013), para o material particulado ($MP_{2,5}$), e pelo Boletim de Qualidade do Ar do município do Rio de Janeiro, disponível em <http://jeap.rio.rj.gov.br/je-metinfosmac/boletim>, para o ozônio e o monóxido de carbono. A Tabela 2 apresenta os valores considerados.

Tabela 2 - Faixas de concentrações dos gases adotadas para a classificação da qualidade do ar.

Classificação	MP 2,5 ($\mu\text{g}/\text{m}^3$)	O₃ ($\mu\text{g}/\text{m}^3$)	CO (ppm)
Boa	0,0 – 12,0	0,0 – 80,0	0,0 – 4,0
Regular	12,0 – 35,4	80,0 – 160,0	4,0 – 9,0
Inadequada	35,4 – 150,4	160,0 – 200,0	9,0 – 15,0
Má	150,4 – 250,4	200,0 – 800,0	15,0 – 30,0
Péssima	> 250,4	> 800,0	> 30,0

3.1.2 Sensores e Módulos

A escolha dos sensores considerou as variáveis em estudo, suas faixas e a relação custo-benefício, com o intuito de desenvolver uma plataforma de baixo custo, capaz de medir a qualidade do ar. Os sensores utilizados para a medição das concentrações dos gases estudados e das condições ambientais/ meteorológicas foram:

- MQ-131, para medição de ozônio;
- MICS-5524, para medição de monóxido de carbono;
- PPD42, para medição de material particulado (MP_{2,5});
- DHT-11, para leitura da temperatura e da umidade relativa do ambiente;
- BMP085, para leitura da pressão e da temperatura do ambiente.

Ressalta-se que foram incluídos também os seguintes módulos e componentes:

- 1 elemento RTC DS1307, para a leitura dos dados de data e hora;
- 1 módulo ESP8266, modelo ESP-01, para envio dos dados em plataforma Web;
- 1 módulo de cartão Micro SD, para permitir a leitura e a escrita dos valores gerados pelos sensores em um cartão de memória Micro SD;
- Lâmpadas LED para facilitar a detecção (visual) de falhas dos elementos.

3.1.3 Plataforma de Prototipagem

Para auxiliar na construção e automatização do protótipo, os sensores e módulos listados na seção anterior foram conectados a uma placa de Arduino MEGA 2560. A escolha pela placa foi realizada considerando os seguintes fatores: número de componentes a serem ligados na

placa, custo, viabilidade de uso, memória disponível para a programação dos elementos e características quanto ao estudo.

Inicialmente, calculou-se a corrente máxima necessária para o sistema a partir do consumo de cada elemento. Assim, verificou-se a necessidade de implementação de uma fonte externa de alimentação. O arranjo da plataforma foi estruturado então através da comunicação dos sensores, módulos, componentes e fonte externa com a placa de Arduino, com o auxílio de 1 placa de ensaio (*protoboard*) e cabos *jumper*.

3.2 Programação do Arduino

Após a montagem da estrutura do sistema, realizou-se a programação do Arduino Mega 2560 no *software* Arduino (IDE), em linguagem compatível.

Primeiramente foram determinados os parâmetros de calibração dos sensores de gás. Como não houve acesso a concentrações conhecidas dos gases estudados, as calibrações consideraram as informações descritas em seus respectivos *Datasheets* e as curvas de sensibilidade apresentadas no Capítulo 2. Neste ponto, desenvolveu-se um código de programação capaz de realizar a calibração do sensor MQ-131, a partir da coleta de dados em local isento de ozônio.

Destaca-se que para o sensor PPD42, foi necessário adotar premissas adicionais para obter as concentrações de material particulado nas unidades desejadas. No Capítulo 4 serão apresentadas e discutidas tais considerações.

Outra programação de calibração adotada foi a referente ao módulo RTC DS1307, com o intuito de obter leituras calibradas de data e hora. Para isso, considerou-se a programação desenvolvida por Arduino e Cia (2013). No Código 1 segue o trecho adotado, que utiliza a biblioteca *Wire.h*, disponível em <https://github.com/esp8266/Arduino/tree/master/libraries/Wire>.

Código 1 - Trecho do código de programação adotado para a calibração do módulo RTC DS1307.

```

1. void SeleccionaDateeHora() //Calibração da data e da hora no DS1307
2. {
3.   byte segundos = 00; //Valores de 0 a 59
4.   byte minutos = 31; //Valores de 0 a 59
5.   byte horas = 15; //Valores de 0 a 23
6.   byte diadasemana = 5; //Valores de 0 a 6 (considerando domingo=0, segunda=1...)

```

```

7.  byte diadomes = 15;           //Valores de 1 a 31
8.  byte mes = 12;               //Valores de 1 a 12
9.  byte ano = 17;               //Valores de 0 a 99
10.
11. Wire.beginTransmission(DS1307_ADDRESS);
12. Wire.write(zero);
13.
14. Wire.write(ConverteParaBCD(segundos));
15. Wire.write(ConverteParaBCD(minutos));
16. Wire.write(ConverteParaBCD(horas));
17. Wire.write(ConverteParaBCD(diadasemana));
18. Wire.write(ConverteParaBCD(diadomes));
19. Wire.write(ConverteParaBCD(mes));
20. Wire.write(ConverteParaBCD(ano));
21. Wire.write(zero);
22. Wire.endTransmission();
23. }
24.
25. byte ConverteParaBCD(byte val) //Converte o número de decimal para BCD
26. {
27.   return ( (val/10*16) + (val%10) );
28. }
29.
30. byte ConverteparaDecimal(byte val) //Converte de BCD para decimal
31. {
32.   return ( (val/16*10) + (val%16) );
33. }

```

Fonte: Adaptado de Arduino e Cia (2013).

A partir das definições dos parâmetros dos elementos utilizados, montou-se um código de programação de qualidade do ar para obter as leituras dos sensores de gás, converter nas concentrações em unidades desejadas e comparar com os padrões definidos, para determinar a classificação do ar. Também foram incluídas as leituras das condições do ambiente (pressão, temperatura e umidade) e as informações de data e hora. As leituras obtidas pelos elementos foram programadas para apresentação no *Monitor Serial* do Arduino (IDE) e em *Web Page* e gravação no cartão Micro SD.

3.3 Coleta de Dados

Após a finalização desta programação foi possível realizar as coletas de dados, que se dividiram em duas etapas. Na primeira, buscou-se avaliar a resposta dos sensores de gás, enquanto que na segunda foi realizada a coleta de dados de um ambiente pré-determinado, com o intuito de adotar este banco de dados no treinamento das redes neurais artificiais.

3.3.1 Análise da Resposta dos Sensores de Gás

Para averiguar a capacidade de resposta dos sensores de gás, fez-se um teste de exposição dos elementos à fumaça de cigarro. A escolha deste teste considerou os estudos de Alves (2016) e Cançado et al. (2006) que apontam a presença de monóxido de carbono e ozônio, nas emissões do cigarro (a ocorrência do ozônio é de forma indireta, através de reações químicas). Também é prevista a presença de materiais particulados nessa emissão, visto que o sensor PPD42 é calibrado, pelo fabricante, para tal condição (SHINYEI, 2010).

Para isso foi adotada a experiência de Thenório (2013) para o armazenamento da fumaça em uma garrafa plástica, considerando as seguintes etapas:

- Fez-se dois pequenos furos, sendo um na tampa da garrafa e outro na parte lateral inferior desta;
- Fechou-se o furo lateral com uma fita adesiva;
- Encheu-se a garrafa com água, encaixando o cigarro no furo da tampa;
- Acendeu-se o cigarro e destampou o furo da lateral para a saída da água;
- Fechou-se os furos com fita adesiva quando o cigarro apagou.

Em seguida o protótipo foi inserido em uma caixa com uma abertura lateral para conexão da garrafa com a fumaça e outra pequena abertura no topo (localizada no lado oposto), que permitisse o fluxo do ar em baixa vazão. Logo, avaliou-se a resposta dos sensores ao longo do tempo, para tal condição.

3.3.2 Coleta dos Dados Experimentais de um Ambiente

Após o desenvolvimento do sistema sensorial e da análise de resposta dos sensores, buscou-se realizar a coleta de dados experimentais de um ambiente, para avaliar a aplicação de um modelo neural na predição de dados futuros. Sendo assim, instalou-se o protótipo no Polo de Inovação do Instituto Federal de Educação, Ciência e Tecnologia Fluminense (IFF), localizado no município de Campos dos Goytacazes/RJ.

A escolha do local considerou a localização deste polo (representado na Figura 12), que fica situado em frente a rodovia BR 356, próxima ao Rio Paraíba do Sul e a uma cerâmica (Cerâmica Indiana – no topo à direita). Todos esses fatores foram classificados como possíveis interferentes na qualidade do ar do campus, o que gerou o interesse na avaliação.



Figura 12 - Vista aérea da localização do Polo de Inovação do IFF.

Fonte: Google (2018).

A fim de obter dados representativos do local, realizou-se a coleta de dados de todos os sensores, módulos e elementos do protótipo. Sendo assim, as variáveis consideradas foram:

- t_bmp: temperatura medida pelo sensor BMP085, em graus Celsius ($^{\circ}\text{C}$);
- p_bmp: pressão medida pelo sensor BMP085, em Pascal (Pa);
- t_dht: temperatura medida pelo sensor DHT-11, em $^{\circ}\text{C}$;
- h_dht: umidade relativa medida pelo sensor DHT-11, em porcentagem (%);
- MP_ugcm: concentração de material particulado, em $\mu\text{g}/\text{m}^3$;
- O3_ugcm: concentração de ozônio, em $\mu\text{g}/\text{m}^3$;
- CO_ppm: concentração de monóxido de carbono, em ppm;
- indice_MP: índice do material particulado, segundo parâmetros do IQAr;
- indice_O3: índice do ozônio, segundo parâmetros do IQAr;
- indice_CO: índice do monóxido de carbono, segundo parâmetros do IQAr;
- IQAr_final: índice de qualidade do ar (geral);
- classe_final: classificação da qualidade do ar, segundo parâmetros do IQAr.

Inicialmente, a coleta de dados foi feita em 12 dias. Entretanto, visto que o sensor BMP085 não obteve leituras durante este período, foi inserida uma lâmpada LED para acusar a falha do sensor e realizada uma nova coleta de dados, ao longo de 20 dias. O tempo de coleta, em ambos os cenários, foi realizado a cada 30 segundos, considerando o tempo mínimo para leitura dos dados do sensor PPD42.

Como todos os elementos foram energizados ao início da primeira coleta de dados, diz-se que na segunda coleta os fatores de pré-aquecimento já haviam sido respeitados.

Assim, ao final da segunda coleta, foram obtidos 56.272 dados individuais para as variáveis t_bmp , p_bmp , t_dht , h_dht , MP_ugcm , $O3_ugcm$, CO_ppm , $indice_MP$, $indice_O3$, $indice_CO$, $IQAr_final$ e $classe_final$.

Desse conjunto, considerou-se as análises de 19 dias para o treinamento da RNA, uma vez que apresentavam os dados coletados para todas as horas dos dias. Isso correspondeu a 53.478 dados, para cada variável.

3.4 Treinamento da RNA

Como o objeto de análise do trabalho se relaciona às concentrações dos gases poluentes atmosféricos, estudou-se através de RNA a correlação das condições ambientais e de concentração dos gases iniciais com as concentrações finais, decorridos um tempo estipulado.

Adotou-se três tempos para avaliação da capacidade preditiva da rede (5, 10 e 30 minutos). Assim, definiu-se as variáveis MP_new , $O3_new$ e CO_new , correspondentes aos respectivos valores de concentração dos gases, após o tempo estipulado. Por exemplo, quando avaliado o tempo de 5 minutos, os valores de MP_new utilizados no treinamento da rede foram correspondentes aos valores de MP_ugcm quando decorridos 5 minutos da situação analisada. O Quadro 5 apresenta as condições adotadas neste estudo para o treinamento das RNA, consideradas para cada gás.

Quadro 5 - Condições adotadas para os treinamentos das RNA.

Variável de Saída	Treinamento	Tempo para Predição
MP_new $O3_new$ CO_new	Treinamento 1	5 minutos
	Treinamento 2	10 minutos
	Treinamento 3	30 minutos

Os treinamentos das redes neurais artificiais foram efetuados no pacote *STATISTICA AUTOMATED NEURAL NETWORK* (SANN), do *software* Statistica® (versão 13.3) da TIBCO Software Inc. (2017). A Figura 13 apresenta a estrutura considerada para os treinamentos dos gases estudados.

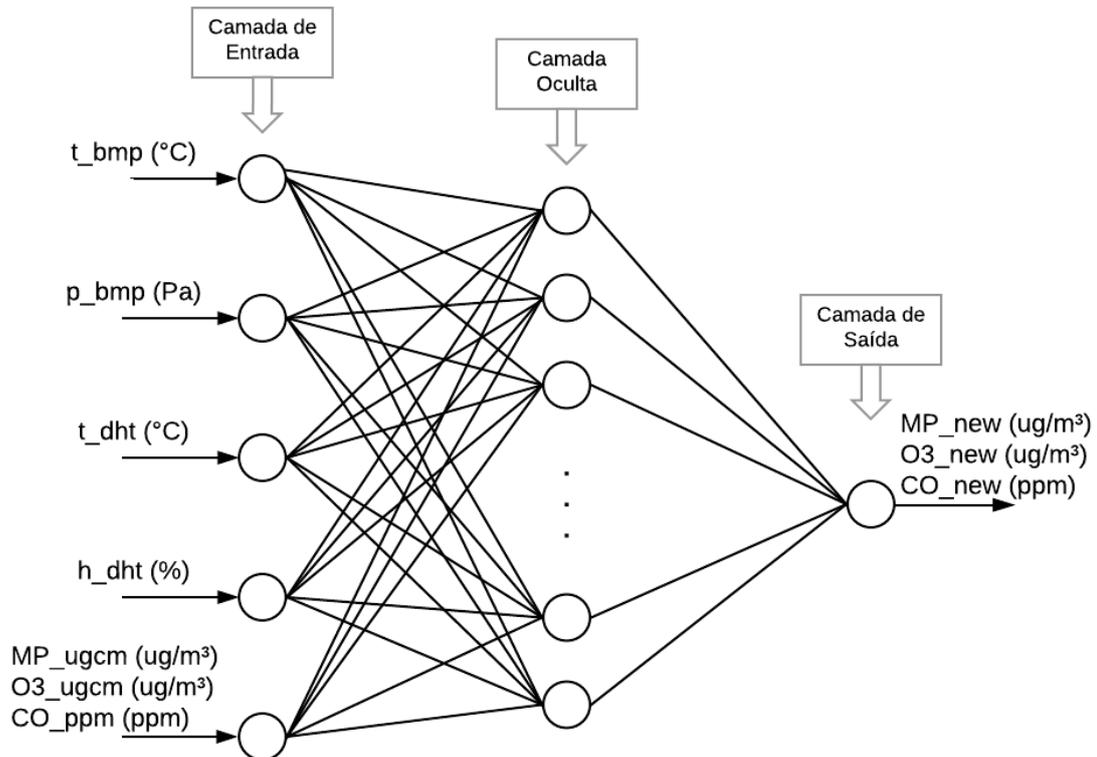


Figura 13 - Estrutura da RNA estudada.

O algoritmo de aprendizado foi o supervisionado, realizado através do método de regressão para a avaliação dos padrões de entrada e saída, uma vez que este representa o método mais utilizado na previsão de variáveis contínuas, com um conjunto de entradas (STATSOFT SOUTH AMERICA, 2015).

Para cada cenário foram realizados diversos treinamentos no *software*, a fim de obter as melhores redes de cada poluente, sendo que em cada, foram treinadas 100 redes, considerando as arquiteturas disponíveis pelo *software* (MLP e RBF).

Para as funções de ativação aplicadas nas camadas escondida e de saída também foram estabelecidas todas as disponíveis pelo programa (identidade, logística, tangente hiperbólica, exponencial e seno).

Com relação ao número de neurônios na camada oculta, aumentou-se as faixas de valores pré-estabelecidas pelo *software* para as duas arquiteturas, considerando de 1 a 100 neurônios.

A partir da estrutura desenvolvida, a próxima etapa consistiu na separação dos dados em três subconjuntos: treinamento, teste e validação, através da inserção da proporção de 14:3:3 (70%:15%:15%). Essa proporção constitui a condição padrão apresentada pela versão 13.3 do programa Statistica, empregada neste trabalho. Segundo De Souza Jr. (1993) e Baughman e Liu (1995) essa separação é necessária para evitar o fenômeno de *overfitting* (sobre-treinamento), que ocorre quando a RNA perde a capacidade de generalização de novos dados.

Neste ponto vale salientar que não foi realizado tratamento estatístico dos dados coletados para o treinamento da RNA, com o intuito de avaliar a capacidade preditiva da rede na presença de dados com ruídos, isto é, se a RNA foi capaz de identificar as situações com dados diferentes dos padrões (representados por picos de leitura) como sendo ruídos, para não modelá-los.

O critério de parada dos treinamentos se relacionou ao cálculo dos erros de treinamento e de teste, conforme abordado anteriormente (na seção 2.4.2). Caso os erros diminuíssem o treinamento prosseguiria e caso aumentassem existiria o indicativo de *overfitting*. Os treinamentos foram finalizados quando os erros não se alteraram. Neste ponto vale frisar que todo o processo de treinamento (e parada) foi efetuado pelo *software* de forma automática, sendo que os seus passos não foram informados.

A avaliação dos desempenhos das RNA ocorreu a partir dos seguintes estudos estatísticos, proporcionados pelo pacote SANN do *software*: valores dos pesos e “*bias*” de cada conexão, dados estatísticos, análise de sensibilidade, gráficos de resíduos e dados preditos pela rede x dados experimentais.

Destaca-se que na análise de sensibilidade é realizada a avaliação da contribuição de cada variável de entrada na rede desenvolvida. Para isso, calcula-se a razão dos erros globais da rede (entre o calculado para o valor médio dos dados antecedentes e o calculado para o valor real do dado), no qual se define como o número de *RATIO* (BOARETO MENDES, 2005).

Dessa forma, diz-se que a variável de entrada possui maior contribuição quanto maior for o valor calculado do *RATIO*; por outro lado, caso o número seja pequeno (menor ou igual a 1) Baughman e Liu (1995) indicam que existe a possibilidade de que a rede apresente melhor performance caso essa variável seja retirada da camada de entrada.

3.5 Implementação do Algoritmo Neural

Após o treinamento e determinação das melhores RNA obtidas para cada poluente, incluiu-se os parâmetros de pesos e “*bias*” dessas redes na programação de qualidade do ar, através de matrizes e vetores, com o intuito de realizar a previsão das concentrações dos gases a partir de operações matemáticas desses conjuntos. Os cálculos consideraram a modelagem apresentada no Capítulo 2 (seção 2.4.2) para o neurônio individual.

4 RESULTADOS E DISCUSSÃO

Neste capítulo são apresentados os resultados obtidos no emprego da metodologia destinada ao desenvolvimento de um protótipo para medição da qualidade do ar e previsão das concentrações de três gases poluentes atmosféricos. De início, descreve-se as etapas necessárias para a montagem do sistema e programação do Arduino. Na sequência, apresentam-se os resultados das coletas de dados, dos treinamentos das redes neurais artificiais e da implementação das melhores redes na programação do sistema.

4.1 Desenvolvimento do Protótipo

Para realizar o desenvolvimento do protótipo, fez-se inicialmente o cálculo do consumo de corrente dos componentes utilizados no estudo. Para isso, mediu-se as correntes através de Multímetro ligado em série, comparando com os valores descritos nos respectivos *Datasheets*. Na Tabela 3 constam os maiores valores identificados, considerados no cálculo do valor total de corrente necessária.

Tabela 3 - Relação do consumo de corrente dos componentes utilizados.

Componente	Máxima Corrente Necessária (mA)
BMP085	1
DHT-11	20
ESP8266/ ESP-01	215
Micro SD Card	5
MICS-5524	35
MQ-131	120
PPD42	90
RTC DS1307	10
TOTAL	496

Visto que a corrente contínua por pino I/O do Arduino Mega 2560 entrega até 20 mA, verificou-se a necessidade de uma fonte externa para alimentação dos demais componentes, que fosse capaz de fornecer, aproximadamente 1A.

Em seguida, desenvolveu-se o esquema representado na Figura 14, através do *software* Fritzing, disponível em <http://fritzing.org/home/>, com o circuito proposto para o sistema. Nela são descritas todas as ligações entre os componentes eletrônicos, considerando o circuito montado em *protoboard* e barramento terra comum (*common ground*) de todos os componentes.

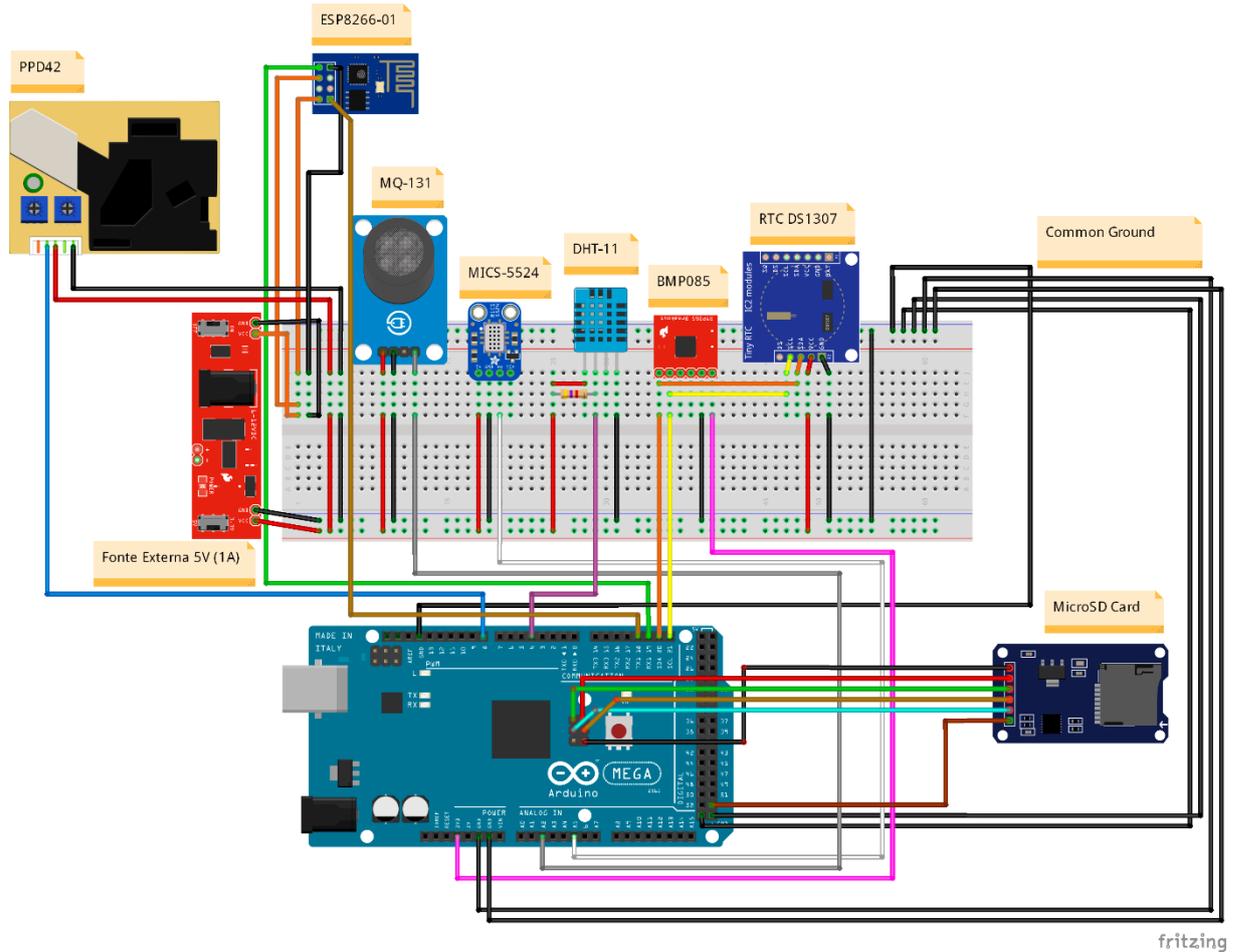


Figura 14 - Esquema desenvolvido para protótipo.

O circuito eletrônico está representado na Figura 15.

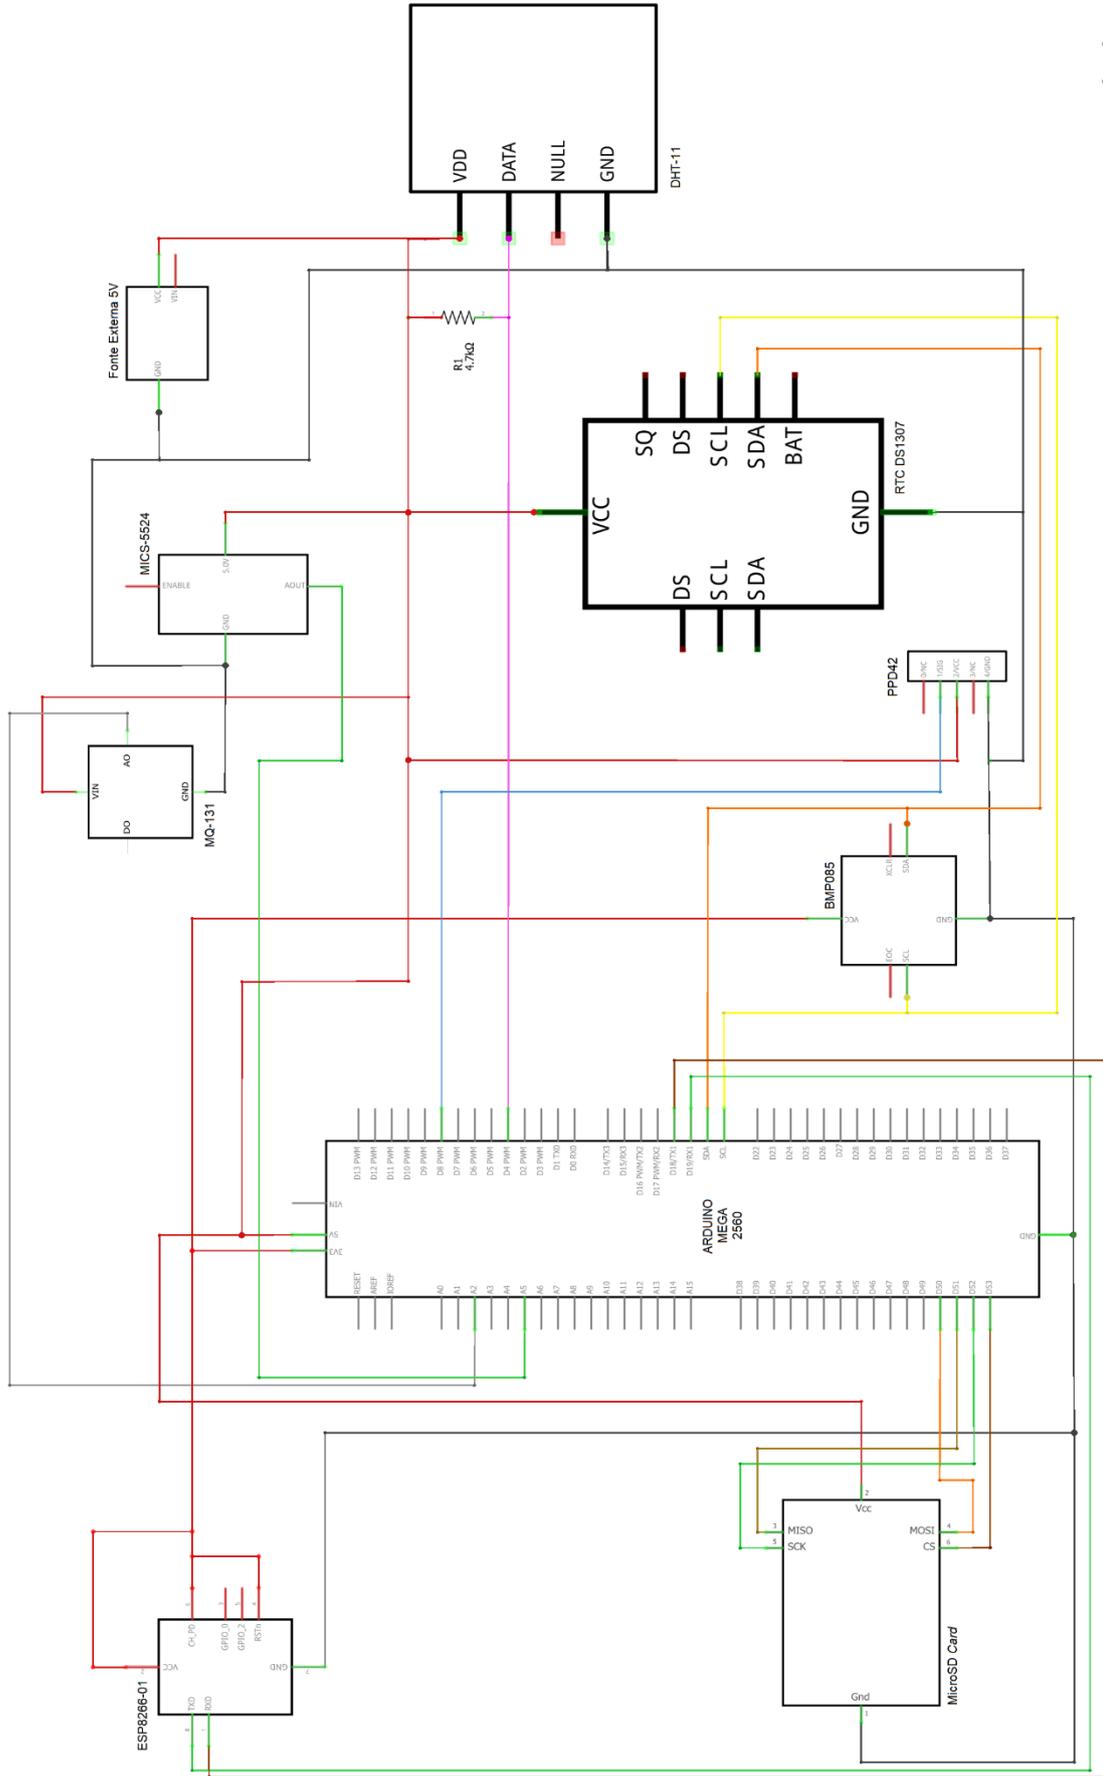


Figura 15 - Circuito eletrônico do protótipo.

4.2 Programação do Arduino

Após a montagem da estrutura do protótipo, realizou-se a programação do microcontrolador pelo *software* Arduino (IDE), conforme abordado anteriormente. Para isso, adotou-se duas etapas para programação: calibração dos elementos e desenvolvimento do código para leitura dos componentes e classificação da qualidade do ar. Tais resultados são discutidos nas próximas seções.

4.2.1 Calibração

Esta seção descreve as programações e os dados utilizados para as calibrações do módulo de relógio e calendário e dos sensores de gás.

4.2.1.1 Módulo de Relógio e Calendário

Conforme discutido no Capítulo 3, a calibração do módulo RTC DS1307 considerou a programação desenvolvida por Arduino e Cia (2013). Nela, preencheu-se os dados de segundos, minutos, horas, dia da semana, dia do mês, mês e ano, referentes ao momento da calibração.

4.2.1.2 Sensores de Gás

Para realizar a calibração adequada dos sensores gás (MQ-131, MICS-5524 e PPD42) é aconselhável realizar medições de concentrações conhecidas dos gases medidos. Uma alternativa é realizar medições pontuais e comparar com valores medidos por detectores já calibrados.

Entretanto, tendo em vista que não houve acesso a tais elementos, os dados de calibração adotados no estudo, para esses sensores, foram considerados a partir das informações descritas em seus respectivos *Datasheets*.

Neste contexto, os sensores MQ-131 e MICS-5524 apresentam lógicas similares. A partir da leitura analógica obtida (L) e da resistência de carga de cada sensor (R_L), obtêm-se os valores de resistência dos sensores (R_S), através da Equação (4).

$$R_S = R_L \cdot \left(\frac{1023 - L}{L} \right) \quad (4)$$

Sendo assim, é possível obter as concentrações dos gases medidos, nas unidades desejadas, a partir das curvas de sensibilidade descritas no Capítulo 2 (Figura 2, para o sensor MQ-131 e Figura 3, para o sensor MICS-5524). Isto é possível através da correlação entre a curva e a razão entre o R_S calculado e a resistência do sensor em condição de ausência do gás medido (R_O).

Segundo SGX Sensortech (2016) e E2V (2009), o valor de R_O do MICS-5524 está entre 100 k Ω e 1500 k Ω , enquanto que o valor de R_L deve ser maior que 820 Ω (sendo aconselhável 100 k Ω). Logo, os respectivos valores adotados neste estudo foram 800 k Ω e 100 k Ω .

Com relação ao sensor MQ-131, adotou-se o *Datasheet* de Hanwei Electronics CO., LTD. (2009). Nele, o valor de R_L é de 20 k Ω , não sendo disponibilizado o valor de R_O . Para isso, foi desenvolvida uma programação para leitura do sinal analógico do sensor, a cada segundo, através do *software* Arduino IDE. A partir desses dados, calculou-se a média dos sinais a cada hora e o valor correspondente de R_S . Em seguida, dividiu-se o valor de R_S por MQ131_ratio_clean_air_factor, que corresponde a razão (R_S/R_O) em ar limpo (igual a 18,60, segundo *Datasheet*). Assim, com a razão calculada, obteve-se o valor correspondente de ozônio, em ppb, através da curva de calibração e considerou-se o menor valor como sendo a condição de ar limpo (local com ausência de O_3).

As medições foram feitas ao longo dos dias 18/12/2017 e 21/12/2017 e, ao final dos cálculos, obteve-se o valor de R_O igual a 34,0 k Ω , sendo este o considerado na programação final do protótipo.

Como auxílio para estudos futuros, foi desenvolvida uma programação de calibração do sensor, descrita no Apêndice B, que realiza todos os cálculos anteriores para determinar o valor de R_O a partir da média aritmética dos valores de R_S obtidos para 1000 amostras, quando medidas em condição de ar limpo. No Código 2 segue o trecho de cálculo desta programação, no qual se baseia nos conceitos utilizados por Sandbox Electronics (2014) para a calibração do sensor MQ-2.

Código 2 - Trecho do código de programação desenvolvido para a calibração do sensor MQ-131.

1. //Etapa para cálculo do R_S :
2. `float MQResistanceCalculation(int raw_adc, int sensor_id){`

```

3.  if (sensor_id == MQ131) {
4.    return ( ((float)MQ131_RL*(1023-raw_adc)/raw_adc));
5.  }
6.  return 0;
7.  }
8.
9.  //Etapa para a calibração do sensor (cálculo do Ro):
10. float MQCalibration(int mq_pin, int sensor_id){
11.  int i;
12.  float val=0;
13.
14.  for (i=0;i<calibration_sample_times;i++) {
15.    val += MQResistanceCalculation(analogRead(mq_pin), sensor_id);
16.    delay(calibration_sample_interval);
17.  }
18.
19.  val = (val/calibration_sample_times);    //Cálculo do valor médio
20.
21.  if (sensor_id == MQ131) {
22.    val = val/MQ131_ratio_clean_air_factor;
23.  }
24.  return val;
25. }

```

Em relação à calibração do sensor PPD42, para se obter a concentração de material particulado no ar foi necessário adotar as seguintes premissas (ARLING; O'CONNOR; MERECIECA, 2010; MUKHERJEE et al., 2017):

- Todas as partículas são esféricas e de 2,5 μm ($\text{MP}_{2,5}$);
- O raio (r) das partículas é igual a 0,44 μm ;
- A densidade (d) das partículas é igual a $1,65 \times 10^{12} \mu\text{g}/\text{m}^3$;
- A constante Pi (π) é igual a 3,14159;
- O fator de correção f_c é igual a 3.531,47 $[(0,01.\text{ft}^3)/\text{m}^3]$.

Isto foi necessário, pois as medições realizadas pelo sensor, quanto ao tempo de ocupação do mínimo impulso, são proporcionais às concentrações de material particulado em $\text{pcs}/0,01\text{ft}^3$, conforme a curva de sensibilidade apresentada no Capítulo 2 (Figura 6).

Neste caso, as premissas visam à conversão dos dados para a unidade avaliada na qualidade do ar ($\mu\text{g}/\text{m}^3$). Primeiramente, calcula-se a massa de cada partícula ($m_{\text{particulado}}/\text{pcs}$), pela Equação (5), para que a concentração final ($C_{\text{particulado}}$) possa ser obtida pela Equação (6).

$$\frac{m_{\text{particulado}}}{\text{pcs}} = d \cdot V = d \cdot \frac{4}{3} \cdot \pi \cdot r^3 \quad (5)$$

$$C_{particulado} = \left(\frac{pcs}{0,01 \cdot ft^3} \right) \cdot f_c \cdot \left(\frac{m_{particulado}}{pcs} \right) \quad (6)$$

Ressalta-se que nessas condições a massa de cada partícula é de $5,89 \times 10^{-7} \mu\text{g}/\text{pcs}$.

4.2.2 Desenvolvimento de Código para Classificação da Qualidade do Ar

Para a escrita da programação de classificação da qualidade do ar, adotou-se a função “*setup()*” do Arduino (IDE) para a definição das entradas, inicialização dos componentes e configuração das comunicações seriais. A função “*loop()*” apresentou a sequência de ações a serem repetidas a cada 30 segundos (tempo estipulado ponderando o *delay* necessário para o sensor PPD42).

O *loop* considerou as seguintes etapas:

1. Medição dos dados de data e hora, pelo módulo RTC DS1307;
2. Leitura da pressão e da temperatura, pelo sensor BMP085;
3. Leitura da temperatura e da umidade relativa, pelo sensor DHT-11;
4. Leitura da concentração de material particulado, pelo sensor PPD42;
5. Leitura da concentração de ozônio, pelo sensor MQ-131;
6. Leitura da concentração de monóxido de carbono, pelo sensor MICS-5524;
7. Cálculo dos índices de qualidade de cada gás e do índice geral do ar (IQAr);
8. Gravação dos dados obtidos em cartão Micro SD;
9. Envio dos dados obtidos para o computador, via comunicação serial;
10. Envio dos dados obtidos para plataforma *Web*, pelo módulo ESP8266, via comunicação serial Tx-Rx.

A primeira parte da programação inclui as bibliotecas adotadas como auxílio nas programações dos sensores DHT-11 e BMP085 e dos módulos RTC DS1307 e Micro SD *Card*. O Código 3 apresenta o trecho da programação referente a essa inclusão.

Código 3 - Trecho do código de programação desenvolvido para o monitoramento da qualidade do ar – inclusão das bibliotecas.

```

2.
3. #include <SPI.h>           //Disponível na plataforma do Arduino (IDE)
4. #include <SD.h>           //Disponível na plataforma do Arduino (IDE)
5.
6. #include <Wire.h>         //Disponível na plataforma do Arduino (IDE)
7. #include <Adafruit_BMP085.h> //Disponível em: https://github.com/adafruit/Adafruit-BMP085-Library.
Acesso em: 20/12/2017.
8.
9. #include <SoftwareSerial.h> //Disponível na plataforma do Arduino (IDE)

```

Em seguida, são descritas as informações necessárias para a leitura dos componentes (pinos e conexões) e cálculos de cada variável. Também são informados os ranges dos índices de qualidade dos gases e do IQAr, conforme trecho representado no Código 4.

Código 4 - Trecho do código de programação desenvolvido para o monitoramento da qualidade do ar – ranges para o cálculo de IQAr.

```

1. //Valores de I da tabela de IQAr:
2.
3. float const lf_b = 50.0;           //Valor final para a classe "boa"
4. float const li_r = 51.0;           //Valor inicial para a classe "regular"
5. float const lf_r = 100.0;          //Valor final para a classe "regular"
6. float const li_i = 101.0;          //Valor inicial para a classe "inadequada"
7. float const lf_i = 199.0;          //Valor final para a classe "inadequada"
8. float const li_m = 200.0;          //Valor inicial para a classe "má"
9. float const lf_m = 299.0;          //Valor final para a classe "má"
10.
11. //Valores de C da tabela de IQAr (ranges dos gases):
12. float MP_ranges[4] = {12.0,35.4,150.4,250.4}; //Range de MP 2,5, em µg/m3 (segundo EPA)
13. float O3_ranges[4] = {80.0,160.0,200.0,800.0}; // Range de O3, em µg/m3 (segundo Boletim do RJ)
14. float CO_ranges[4] = {4.0,9.0,15.0,30.0}; // Range de CO, em ppm (segundo Boletim do RJ)

```

Na função *setup()* então são inicializados os componentes ESP8266, DHT-11, BMP085 e Micro SD Card. Uma vez que o sensor BMP085 não realizou as leituras na primeira coleta de dados, foi implementada uma lâmpada LED, que detectasse o erro deste componente (caso o sensor não se inicializasse, a luz do LED acenderia).

A conexão do módulo ESP8266 com a rede WiFi foi feita através do trecho disponível no Código 5.

Código 5 - Trecho do código de programação desenvolvido para o monitoramento da qualidade do ar – conexão com rede WiFi.

```

1. sendData("AT+RST\r\n", 2000, DEBUG);
2.

```

```

3. //Conecta a rede wireless:
4. sendData("AT+CWJAP=\"NOME_DA_REDE\", \"SENHA\"\\r\\n\", 2000, DEBUG);
5. delay(3000);
6. sendData("AT+CWMODE=1\\r\\n\", 1000, DEBUG);
7.
8. //Mostra o endereço IP:
9. sendData("AT+CIFSR\\r\\n\", 1000, DEBUG);
10.
11. //Configura para múltiplas conexões:
12. sendData("AT+CIPMUX=1\\r\\n\", 1000, DEBUG);
13.
14. //Inicia o web server na porta 80:
15. sendData("AT+CIPSERVER=1,80\\r\\n\", 1000, DEBUG);

```

Fonte: Adaptado de Thomsen (2015).

Neste ponto também foi inicializada a contagem do tempo, a fim de que, na função *loop()*, fossem realizadas medidas quando decorridos 30 segundos.

Na função *loop()*, foram declaradas funções de programação para cada elemento, como forma de auxiliar na obtenção das leituras (analógicas/ digitais) e realização de todos os cálculos necessários. No Código 6 segue o trecho desta programação.

Código 6 - Trecho do código de programação desenvolvido para o monitoramento da qualidade do ar – função *loop()*.

```

1. LeituraWiFi(); // Loop para envio dos dados em plataforma Web (ESP8266)
2.
3. if ((millis()-starttime) > samplertime_ms) // Condição a ser realizada quando decorrer o tempo estipulado
4. {
5.   Mostrarelogio(); // Loop para leitura da data e da hora (RTC DS1307)
6.   getPressureTemperature(); // Loop para medição da pressão e temperatura (BMP085)
7.   getTemperatureHumidity(); // Loop para medição da temperatura e umidade (DHT-11)
8.   getParticulate(); // Loop para leitura do material particulado (PPD42)
9.   getGas(); // Loop para medição dos gases (MQ-131 e MICS-5524)
10.  getIndex(); // Loop para avaliação dos índices IQAr dos gases e do geral
11.  LeituraSD(); // Loop para gravação dos dados no cartão SD
12. }

```

Quando decorridos o tempo estipulados para a coleta de dados, a programação segue para a medição dos dados de data e hora, através da função *Mostrarelogio()*. Na sequência, são obtidos os dados do sensor BMP085, pela função *getPressureTemperature()*. A função *getTemperatureHumidity()* considera os dados do sensor DHT-11.

Com relação às concentrações dos gases poluentes, inicia-se com a função *getParticulate()*, que calcula a concentração do material particulado, em $\mu\text{g}/\text{m}^3$. Para isto, adotou-se o conceito utilizado por Seeed Studio (2015) e as premissas assumidas nesse estudo.

No Código 7 segue o trecho que se refere à obtenção dos dados do sensor PPD42 e os cálculos para conversão na unidade desejada.

Código 7 - Trecho do código de programação desenvolvido para o monitoramento da qualidade do ar – função *getParticulate()*.

```

1. ratio = lowpulseoccupancy / (samptime_ms * 10.0);
2.
3. //Cálculo para obtenção da concentração de particulado, em pcs/0,01ft³, considerando a curva do Datasheet,
segundo Seed Studio (2015):
4. concentration = (1.1 * pow(ratio,3.0)) - (3.8 * pow(ratio,2.0)) + (520.0 * ratio) + 0.62;
5.
6. //Cálculo para obtenção da concentração de particulado, em ug/m³:
7. MP_ugcm = concentration * fc * massaPM25;

```

A função *getGas()* é utilizada para calcular as concentrações dos gases ozônio (em $\mu\text{g}/\text{m}^3$) e monóxido de carbono (em ppm). Para se obter as equações de conversão das leituras dos sensores em concentrações dos gases foram utilizados os pontos das curvas de sensibilidade descritas no Capítulo 2 para os sensores MICS-5524 (Figura 3) e MQ-131 (Figura 2). Esses dados e os respectivos valores de seus logaritmos (base 10) estão descritos na Tabela 4. Destaca-se que a curva de calibração do ozônio correlaciona os dados em ppb, fazendo-se necessária uma segunda etapa de conversão.

Tabela 4 - Pontos das curvas de sensibilidade dos sensores de gás.

Sensor MICS-5524				Sensor MQ-131			
Concentração de CO (ppm)	R_s/R_o	log (CO)	log (R_s/R_o)	Concentração de O3 (ppb)	R_s/R_o	log (O3)	log (R_s/R_o)
1	3,60	0,00	0,56	5	5,50	0,70	0,74
10	0,50	1,00	- 0,30	10	4,50	1,00	0,65
100	0,07	2,00	- 1,15	20	2,00	1,30	0,30
1000	0,01	3,00	- 1,96	50	0,75	1,70	- 0,12

Com os dados de logaritmo da concentração do gás e do logaritmo de R_s/R_o , montou-se o gráfico representado na Figura 16, que apresenta as linhas de tendência das curvas dos sensores.

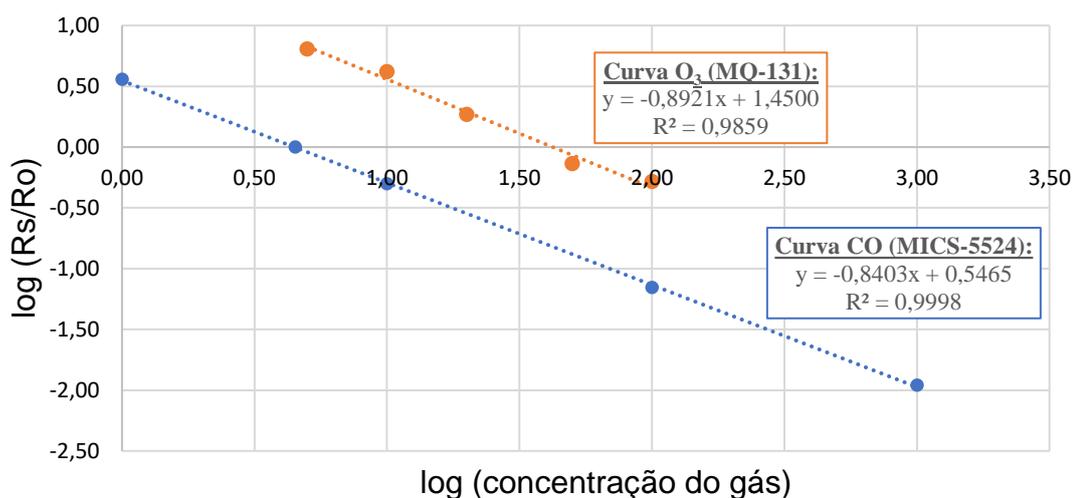


Figura 16 – Gráfico de log (concentração do gás) versus log (Rs/Ro).

É importante ressaltar que em ambos os casos, os valores de R^2 são próximos de 1,0. Montgomery e Runger (2016) definem R^2 como o coeficiente de determinação, amplamente utilizado para avaliar a adequação de modelos de regressão. Neste caso, diz-se que as curvas O_3 e CO explicam, respectivamente, 98,59% e 99,98% da variabilidade dos dados, o que indica uma boa correlação.

No Código 8 segue o trecho da programação que inclui os dados das curvas de calibração desses sensores, onde “x1” é primeiro valor do logaritmo da concentração do gás, “y1” é o primeiro valor do logaritmo de R_S/R_O e “a” é o coeficiente angular da reta característica do gás.

Código 8 - Trecho do código de programação desenvolvido para o monitoramento da qualidade do ar – dados das curvas de calibração dos sensores de gás.

```

1. // Curvas dos gases, considerando a estrutura (y = a.x + b), representada como curva = {x1;y1;a};
2. float O3_curve[3] = {0.6990,0.8062,-0.8921};
3. float CO_curve[3] = {0.00,0.5563,-0.8403};

```

O trecho que no qual são lidas as medidas dos sensores MQ-131 e MICS-5524 e convertidas nas concentrações dos gases está representado no Código 9. Nas funções *MQRead()* e *MQGetGasPercentage()* são obtidos, respectivamente, os valores de R_S dos sensores e as concentrações dos gases, calculadas através da equações características.

Código 9 - Trecho do código de programação desenvolvido para o monitoramento da qualidade do ar – cálculos para obtenção das concentrações de O₃ e CO.

```
1. float O3_ppb = MQGetGasPercentage(MQRead(MQ131_pin,MQ131)/MQ131_Ro, MQ131);
2. CO_ppm = MQGetGasPercentage(MQRead(MICS5524_pin,MICS5524)/MICS5524_Ro, MICS5524);
```

A segunda etapa de conversão da concentração de ozônio, de ppb para $\mu\text{g}/\text{m}^3$, considerou os cálculos discutidos pelo Centro Canadense de Saúde e Segurança no Trabalho (CANADIAN CENTRE FOR OCCUPATIONAL HEALTH & SAFETY, 2016). Para isso adotou-se as seguintes considerações:

- t_kelvin: média das temperaturas obtidas pelos sensores BMP085 e DHT-11, em Kelvin;
- p_mmHg: pressão medida pelo sensor BMP085, em mmHg;
- Massa molar do ozônio igual a 47,997 g/mol;
- Constante universal dos gases (R) igual a 62,3637 (mmHg.L)/(mol.K).

O Código 10 apresenta o trecho do cálculo final do ozônio.

Código 10 - Trecho do código de programação desenvolvido para o monitoramento da qualidade do ar – cálculos para obtenção da concentração de ozônio em $\mu\text{g}/\text{m}^3$.

```
1. float t_kelvin = 273.15 + ((t_bmp + t_dht)/2.0); // Conversão da temperatura de °C para K
2. float p_mmHg = p_bmp/133.322; // Conversão da pressão de Pa para mmHg
3.
4. O3_ugcm = (p_mmHg * 47.997 * O3_ppb)/(62.3637 * t_kelvin); // Cálculo do O3 em ug/m3
```

A função *getIndex()* calcula os índices individuais dos gases, através da função *IndiceCalculation()*, verifica o maior valor e determina o IQAr geral (conforme Código 11). A classificação da qualidade do ar considera então o valor do IQAr e as faixas já estabelecidas.

Código 11 - Trecho do código de programação desenvolvido para o monitoramento da qualidade do ar – cálculos para obtenção dos índices de qualidade do ar.

```
1. //Obtenção dos índices dos gases e do IQAr:
2. indice_MP = IndiceCalculation(MP_ugcm,MP_gas) ;
3. indice_O3 = IndiceCalculation(O3_ugcm,O3_gas) ;
4. indice_CO = IndiceCalculation(CO_ppm,CO_gas) ;
5.
6.
```

```

7. //Etapa para escolha do maior índice calculado:
8. IQAr_final = max(indice_CO, max(indice_MP, indice_O3));
9.
10.   if (IQAr_final <= If_b){
11.     classe_final = "Boa";
12.   } else if (IQAr_final >= Ii_r && IQAr_final <= If_r){
13.     classe_final = "Regular";
14.   } else if (IQAr_final >= Ii_i && IQAr_final <= If_i){
15.     classe_final = "Inadequada";
16.   } else if (IQAr_final >= Ii_m && IQAr_final <= If_m){
17.     classe_final = "Ma";
18.   } else if (IQAr_final > If_m){
19.     classe_final = "Pessima";
20.   }

```

As demais funções presentes no *loop()* são responsáveis pelo envio dos dados para o *Monitor Serial* do Arduino (IDE), plataforma *Web* e cartão *Micro SD* (para gravação). Vale ressaltar que a programação da página *web* considerou trechos da programação desenvolvida por Thomsen (2015) e a linguagem HTML, resultando no *display* exemplificado na Figura 17.

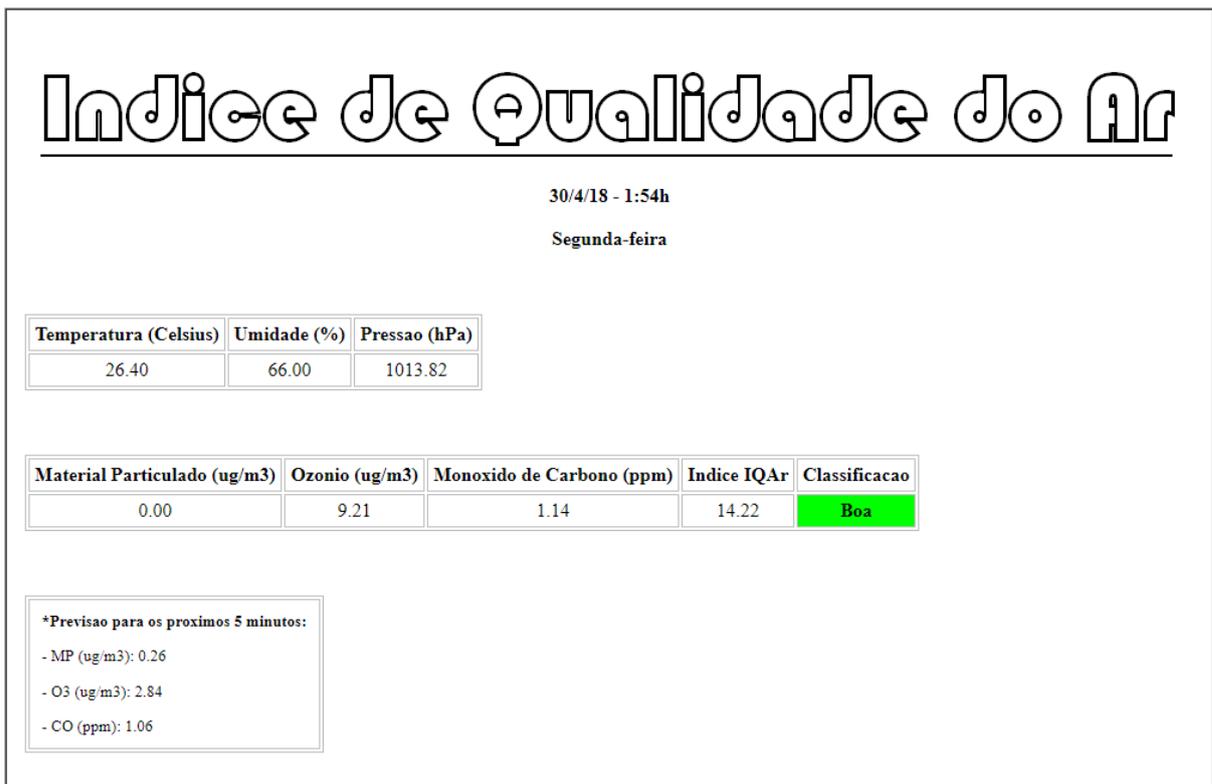


Figura 17 – Página *web* desenvolvida para envio dos dados.

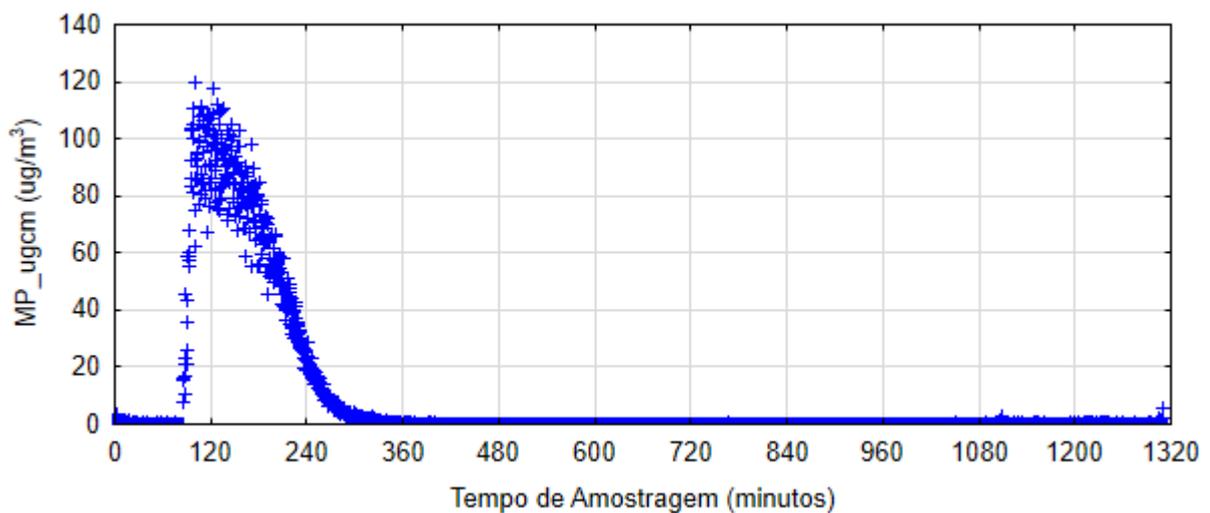
4.3 Resposta dos Sensores de Gás

Após a montagem da estrutura e da programação dos elementos, avaliou-se a resposta dos sensores de gás à exposição de fumaça de cigarro. Para isso, fez-se o uso de uma garrafa plástica para capturar e armazenar essa fumaça e, em seguida, conectou-se a mesma a uma caixa que dispunha todos os elementos do sistema protótipo em seu interior.

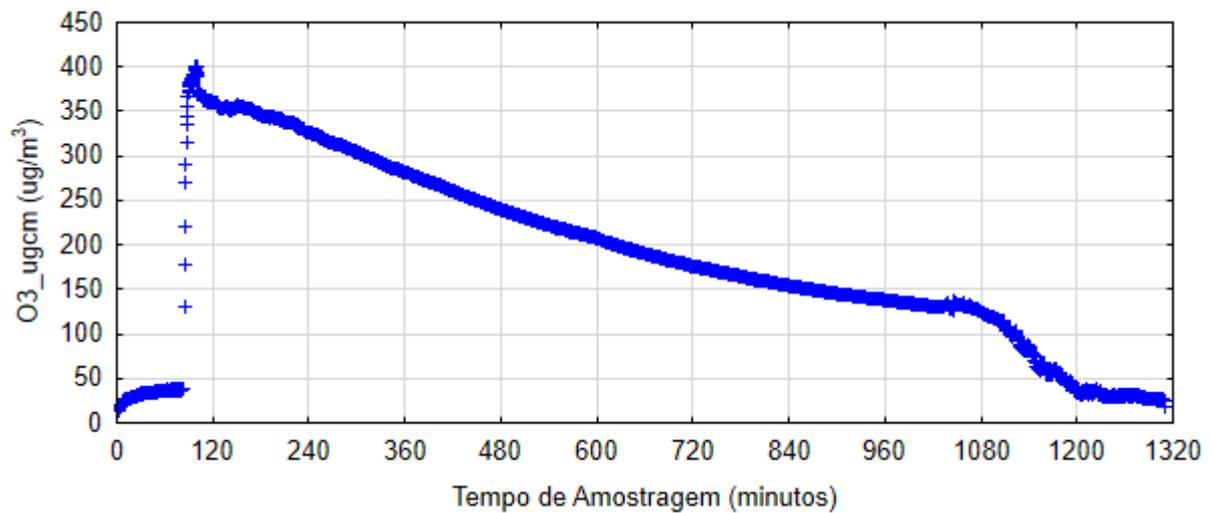
O ambiente apresentava uma pequena abertura na parte superior da parede oposta à entrada do gás, de forma a obrigar a passagem deste pelos elementos sensoriais e auxiliar na avaliação da disposição das concentrações dos gases poluentes ao longo do tempo. Ressalta-se que o protótipo foi energizado um dia antes desta análise, de forma a pré-aquecer os elementos.

O resultado das respostas dos sensores está representado na Figura 18, conforme as concentrações de material particulado, ozônio e monóxido de carbono (“a”, “b” e “c”, respectivamente).

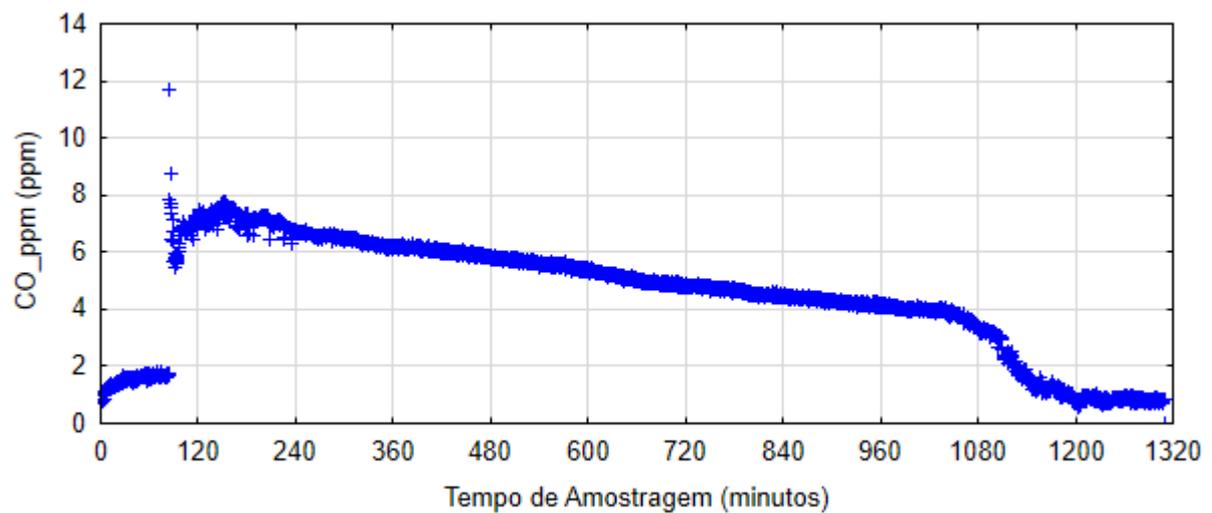
No momento da exposição à fumaça do cigarro (no minuto 84) as concentrações medidas pelos sensores apresentaram elevações significativas em um curto espaço de tempo, com diminuições gradativas ao longo do tempo - o material particulado retornou à condição inicial em aproximadamente 240 minutos (4 horas), enquanto que os demais (ozônio e monóxido de carbono) retornaram após aproximadamente 1080 minutos (18 horas).



(a)



(b)



(c)

Figura 18 - Concentrações de (a) material particulado, (b) ozônio e (c) monóxido de carbono, ao longo do teste de exposição à fumaça do cigarro.

De forma similar, a Figura 19 apresenta a disposição das medições do índice de qualidade do ar ao longo do experimento, considerando as diferentes classificações do IQAr. Nota-se que no momento da exposição à fumaça do cigarro a qualidade do ar que era classificada como “boa” passou rapidamente para a descrição de “má”. Isto ocorreu como contribuição de todos os sensores.

Também se destaca que a qualidade do ar somente retornou à classificação de “boa” após um longo período (de aproximadamente 18 horas), principalmente por causa do sensor MQ-131, que detectou altas concentrações de ozônio no ambiente.

Apesar da concentração de monóxido de carbono retornar à condição inicial após este longo período, a classe relativa ao seu índice passou para “boa” após aproximadamente 15 horas.

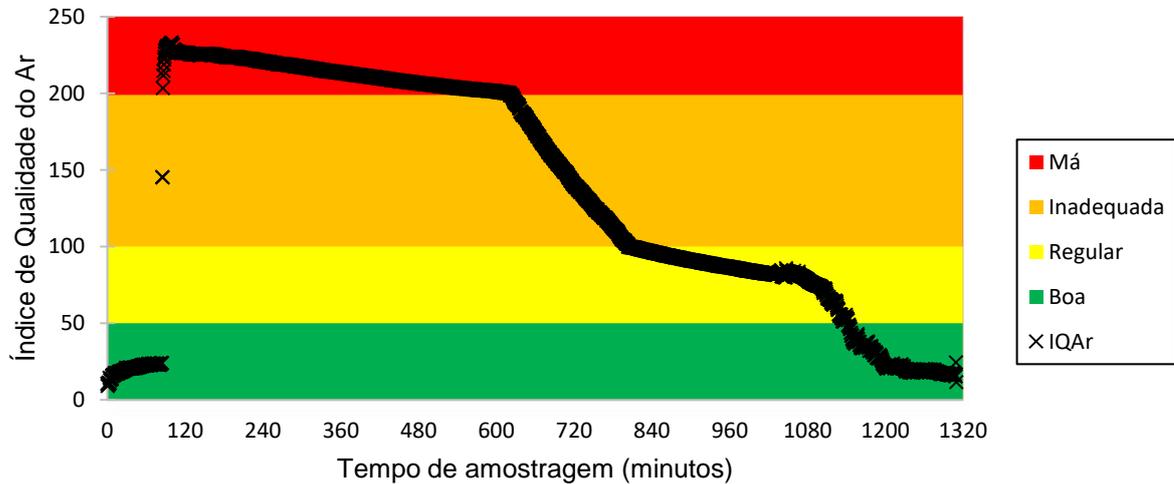


Figura 19 – Valores obtidos para o índice de qualidade do ar, ao longo do teste de exposição à fumaça do cigarro.

Nesse contexto foi possível constatar que os sensores apresentaram sensibilidade aos gases presentes na fumaça do cigarro, isto é, foram capazes de detectar os gases estudados, nas condições avaliadas. Dessa forma, considerou-se como satisfatória a resposta dos mesmos.

4.4 Obtenção dos Dados Experimentais

Esta seção descreve os resultados acerca das coletas de dados realizadas no Polo de Inovação do IFF e as comparações com dados disponíveis em plataformas de acesso livre.

4.4.1 Valores Obtidos

A coleta de dados foi realizada no Polo de Inovação do Instituto Federal de Educação, Ciência, e Tecnologia Fluminense, localizado no município de Campos dos Goytacazes/RJ, durante os dias 04 de janeiro e 05 de fevereiro, de 2018.

Conforme abordado anteriormente, durante a obtenção dos dados na primeira quinzena de janeiro, o sensor BMP085 não realizou leituras. Desta forma, a coleta foi separada em dois períodos:

- C-01: Entre os dias 04/01/2018 e 16/01/2018, no qual não houve medições das variáveis t_{bmp} e p_{bmp} , e, conseqüentemente, os valores obtidos para O_3_{ugcm} e $Indice_{O_3}$ também foram desconsiderados pelas suas dependências nos cálculos;
- C-02: Entre os dias 16/01/2018 e 05/02/2018, no qual todas as variáveis foram medidas.

A Tabela 5 apresenta os parâmetros estatísticos da coleta C-01, considerando os valores mínimos e máximos obtidos para cada variável e as respectivas média, mediana, moda e desvio padrão.

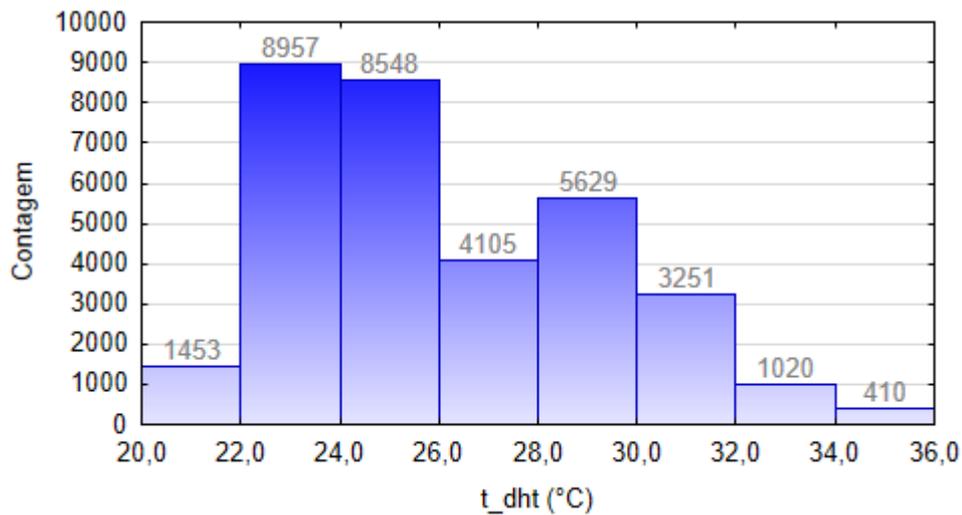
Partindo da premissa adotada por Montgomery e Runger (2016), que destacam que o desvio padrão deve ser pelo menos uma ordem de grandeza menor que a sua média, os parâmetros estatísticos das variáveis t_{dht} e $IQAr$ foram adequados. As demais variáveis apresentaram desvios um pouco acima do proposto.

Tabela 5 - Parâmetros estatísticos da coleta de dados C-01.

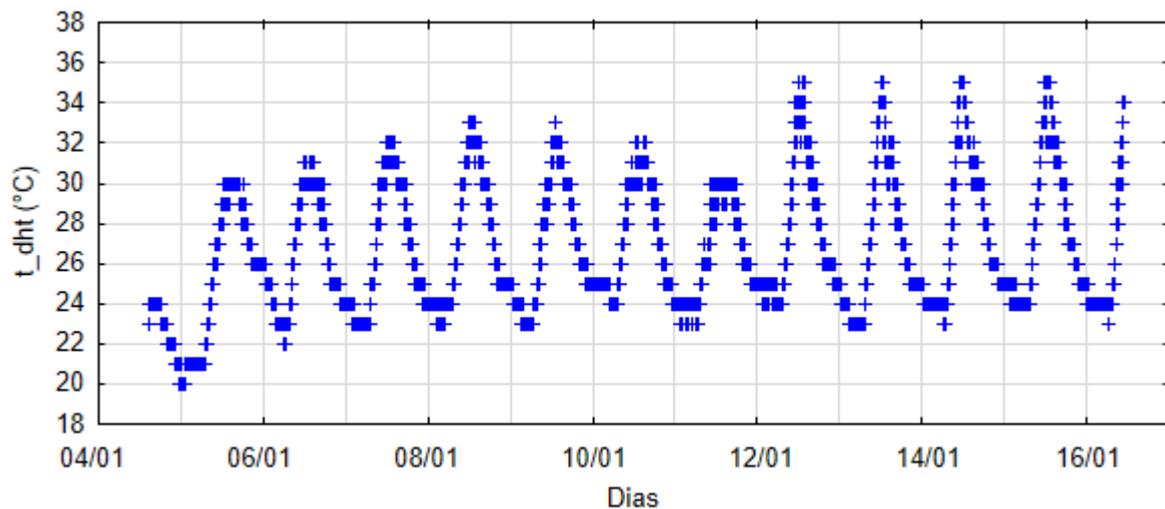
Variáveis	Mínimo	Máximo	Média	Mediana	Moda	Desvio Padrão
t_{bmp} (°C)	N/A	N/A	N/A	N/A	N/A	N/A
t_{dht} (°C)	20,0	35,0	26,7	26,0	24,0	3,2
h_{dht} (%)	56,0	95,0	81,6	89,0	93,0	12,3
p_{bmp} (Pa)	N/A	N/A	N/A	N/A	N/A	N/A
MP_{ugcm} ($\mu\text{g}/\text{m}^3$)	0,0	19,9	0,9	0,6	0,0	1,1
O_3_{ugcm} ($\mu\text{g}/\text{m}^3$)	N/A	N/A	N/A	N/A	N/A	N/A
CO_{ppm} (ppm)	0,4	1,6	0,8	0,8	0,8	0,1
$IQAr$	5,6	67,6	10,4	10,3	10,9	2,7

A seguir serão apresentados e discutidos os gráficos estatísticos obtidos para cada variável, considerando o conjunto de dados da amostra coletada em C-01. As análises serão resumidas aos gráficos de histograma e dispersão dos dados ao longo dos dias.

A Figura 20 destaca os gráficos referentes a variável t_{dht} . Verifica-se pelo histograma que o comportamento da distribuição é bimodal, com valores entre 20,0 e 35,0°C, mais concentrados na faixa de 22,0 e 24,0°C. É possível notar também um padrão entre as temperaturas lidas através do gráfico de dispersão: o começo de cada dia é caracterizado por uma baixa de temperatura até parte da manhã, que se altera ao longo do dia para uma alta na temperatura de até aproximadamente 36,0°C. No turno da tarde até o final do dia é representado pela diminuição desta variável até 20,0°C. As leituras foram gradativas e não apresentaram picos repentinos.



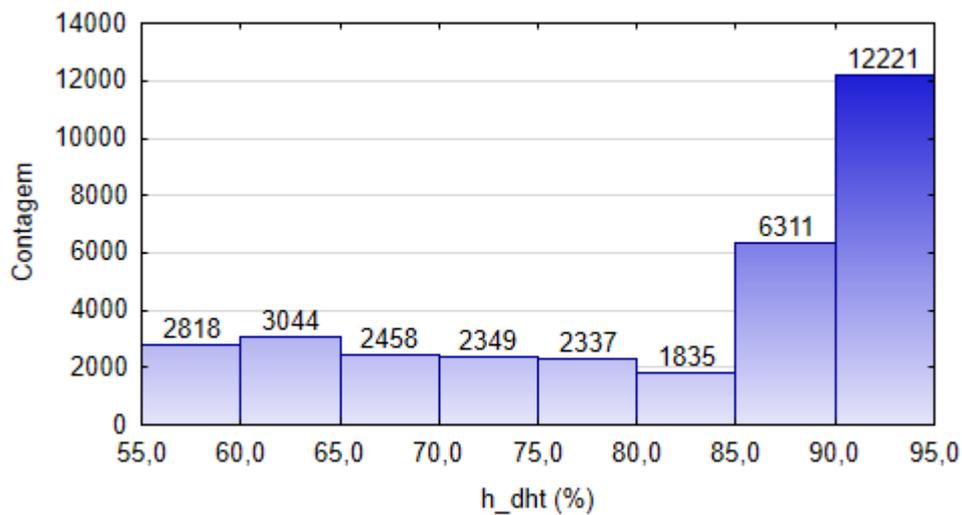
(a)



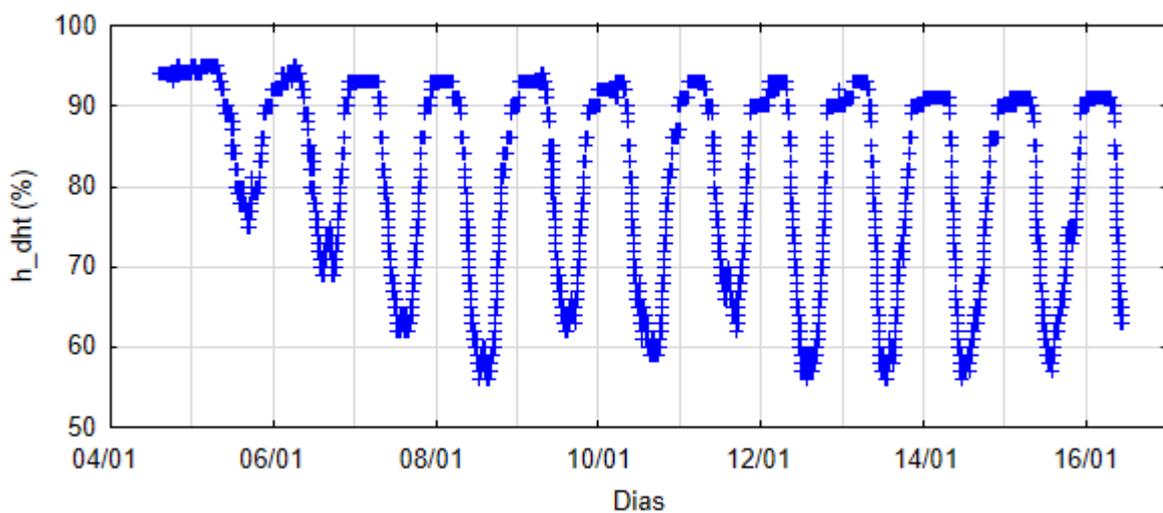
(b)

Figura 20 - Gráficos de (a) histograma e (b) dispersão dos dados, coletados para t_{dht} em C-01.

Quanto a variável h_dht os gráficos estão representados na Figura 21. O comportamento da distribuição é assimétrico à esquerda, com valores entre 56,0 e 95,0%, mais concentrados na faixa de 90,0 a 95,0%, com $média < mediada < moda$. Ao contrário da variável anterior, nota-se que durante a madrugada a umidade aumenta até uns 95,0%, em seguida diminui pelo período da manhã, atingindo pontos de até 55,0% de umidade relativa. Durante a tarde e a noite a umidade volta a subir. Com isso, verifica-se que a umidade do local é inversamente proporcional à temperatura. As leituras também foram gradativas, sem picos repentinos.



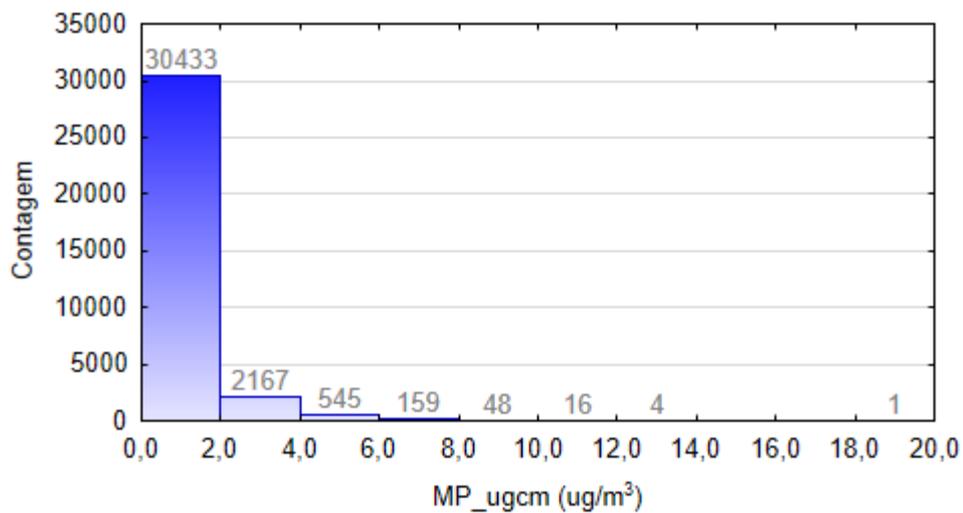
(a)



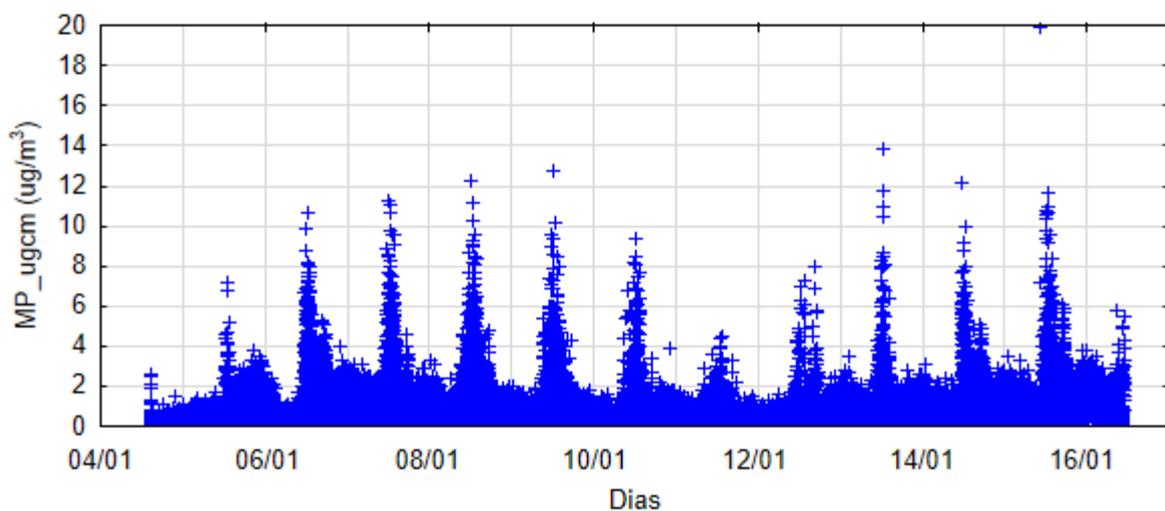
(b)

Figura 21 - Gráficos de (a) histograma e (b) dispersão dos dados, coletados para h_dht em C-01.

Os gráficos da variável MP_ugcm estão descritos na Figura 22, cujo comportamento da distribuição é assimétrico à direita, com valores entre 0,0 e 19,9 $\mu\text{g}/\text{m}^3$, mais concentrados na faixa de 0,0 e 2,0 $\mu\text{g}/\text{m}^3$, com moda < mediana < média. A coleta foi representada por uma grande dispersão dos dados, uma vez que o sensor PPD42 realiza as leituras pela contagem das partículas que atravessam o seu interior no momento da coleta, resultando em medições não contínuas. Verifica-se também um padrão, no qual as medidas do poluente aumentaram por volta das 12h de cada dia. Esta elevação pode estar associada a um aumento do tráfego local e/ou das atividades produtivas da região (como por exemplo, da cerâmica localizada próxima ao Polo de Inovação do IFF) e como influência dos ventos (direção e velocidade).



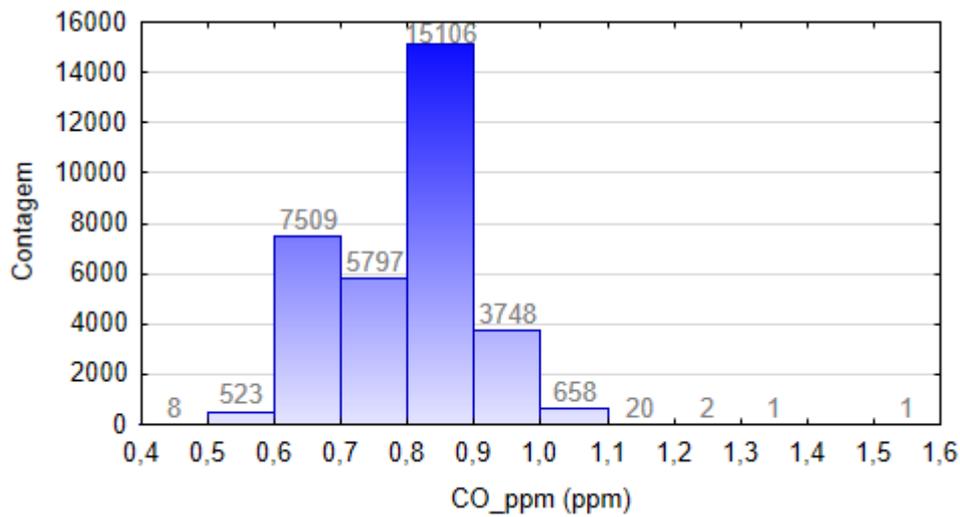
(a)



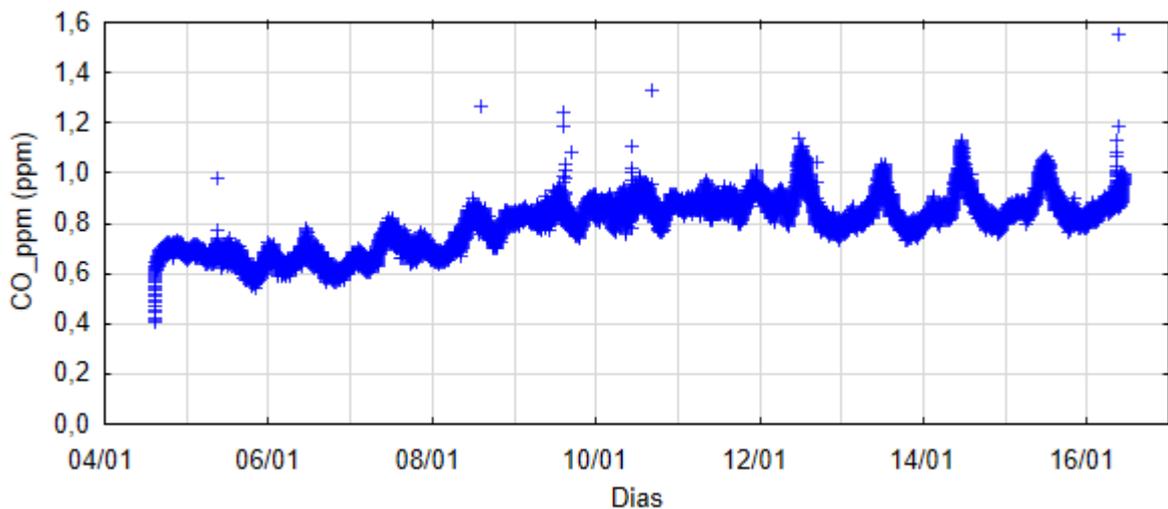
(b)

Figura 22 - Gráficos de (a) histograma e (b) dispersão dos dados, coletados para MP_ugcm em C-01.

Os gráficos referentes à variável CO_ppm estão representados na Figura 23. Nota-se que o comportamento é simétrico, com moda, mediana e média próximas. Os valores variam entre 0,4 e 1,6 ppm, mais concentrados na faixa de 0,8 e 0,9 ppm. Considerando o gráfico de dispersão, verifica-se que as faixas diárias das leituras aumentaram gradativamente ao longo do tempo de coleta, com poucos picos repentinos, onde os valores mais altos foram identificados por volta das 12h de cada dia. Similar à análise anterior, percebe-se que a concentração de poluentes no ar do Polo de Inovação do IFF é maior na metade do dia, o que instiga a conclusão da alteração de fatores externos neste período.



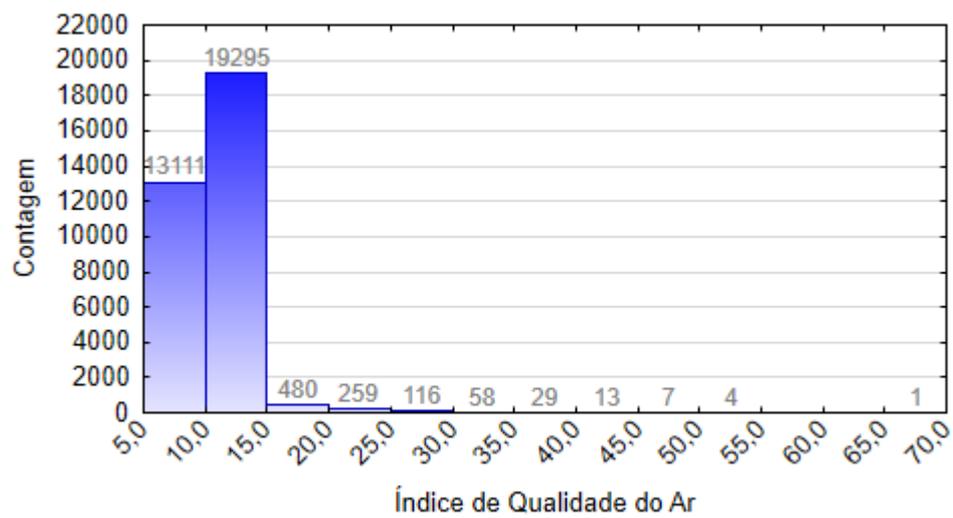
(a)



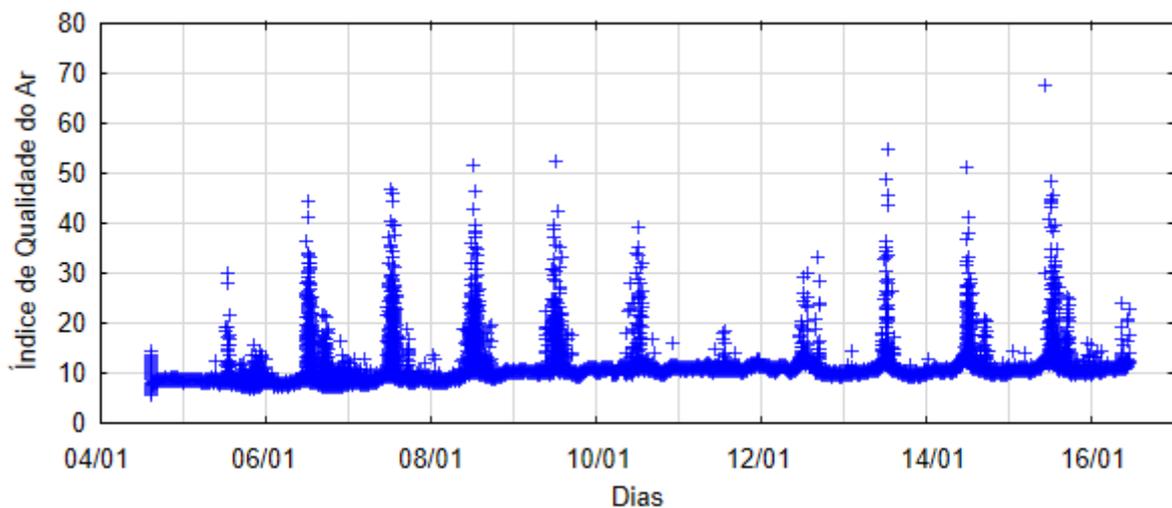
(b)

Figura 23 - Gráficos de (a) histograma e (b) dispersão dos dados, coletados para CO_ppm em C-01.

Quanto à última variável coletada (IQAR - Índice de Qualidade do Ar), os gráficos estão descritos na Figura 24. O comportamento da distribuição é assimétrico à direita, com mediana < média < moda e valores compreendidos entre 5,6 e 67,6, mais concentrados na faixa de 10,0 e 15,0. Considerando as faixas de classificação do IQAr, nota-se que desse conjunto a classe de qualidade do ar mais representativa foi a “Boa”. Também esteve presente a classe “Regular”. Com relação à distribuição dos dados, representada pelo gráfico de dispersão, verifica-se um padrão no qual os maiores valores diários ocorreram por volta da metade do dia. Este ponto se alinha com as avaliações de dispersão das concentrações dos poluentes no local.



(a)



(b)

Figura 24 - Gráficos de (a) histograma e (b) dispersão dos dados, coletados para IQAr em C-01.

Em relação à coleta C-02, os parâmetros estatísticos de mínimo, máximo, média, mediana, moda e desvio padrão, calculados para cada variável, estão dispostos na Tabela 6. Conforme as premissas de Montgomery e Runger (2016), as variáveis t_{bmp} , t_{dht} e p_{bmp} foram classificadas como adequadas, devido aos baixos valores de desvio padrão, correlacionados com as respectivas médias. As demais variáveis apresentaram desvios um pouco acima do proposto, sendo que os desvios de MP_{ugcm} e CO_{ppm} foram consideráveis.

Tabela 6 - Parâmetros estatísticos da coleta de dados C-02.

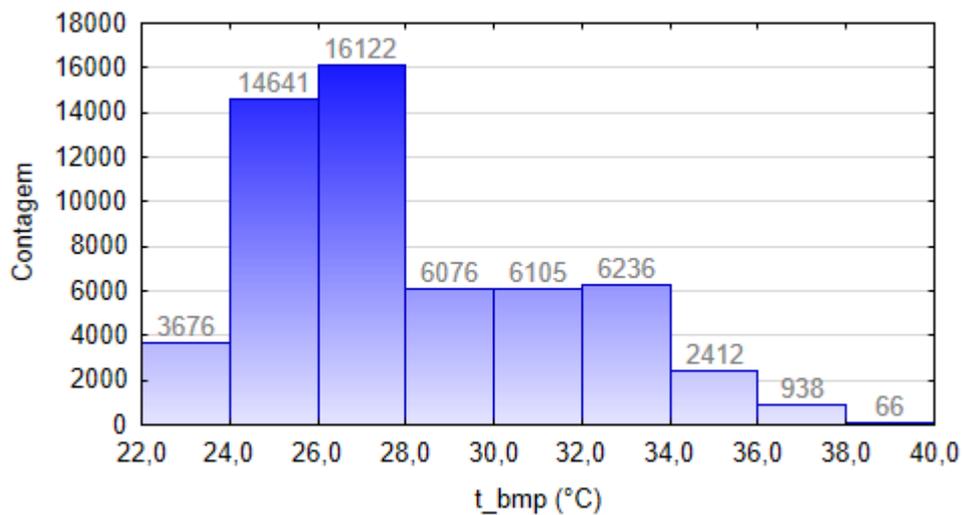
Variáveis	Mínimo	Máximo	Média	Mediana	Moda	Desvio Padrão
t_{bmp} (°C)	22,3	38,5	28,1	26,9	26,5	3,4
t_{dht} (°C)	20,0	37,0	27,0	26,0	25,0	3,8
h_{dht} (%)	34,0	95,0	75,4	80,0	91,0	15,8
p_{bmp} (Pa)	100.150,0	101.364,0	100.877,4	100.895,0	100.844,0	228,4
MP_{ugcm} ($\mu\text{g}/\text{m}^3$)	0,0	24,1	0,9	0,6	0,0	1,2
O_3_{ugcm} ($\mu\text{g}/\text{m}^3$)	1,7	114,6	4,7	4,3	3,9	2,1
CO_{ppm} (ppm)	0,0	10,0	0,3	0,1	0,0	0,4
IQAr	1,1	116,8	6,9	4,9	2,9	5,1

A seguir serão apresentados e discutidos os gráficos estatísticos (histograma e dispersão dos dados ao longo dos dias) obtidos para cada variável, considerando o conjunto de dados da amostra coletada em C-02.

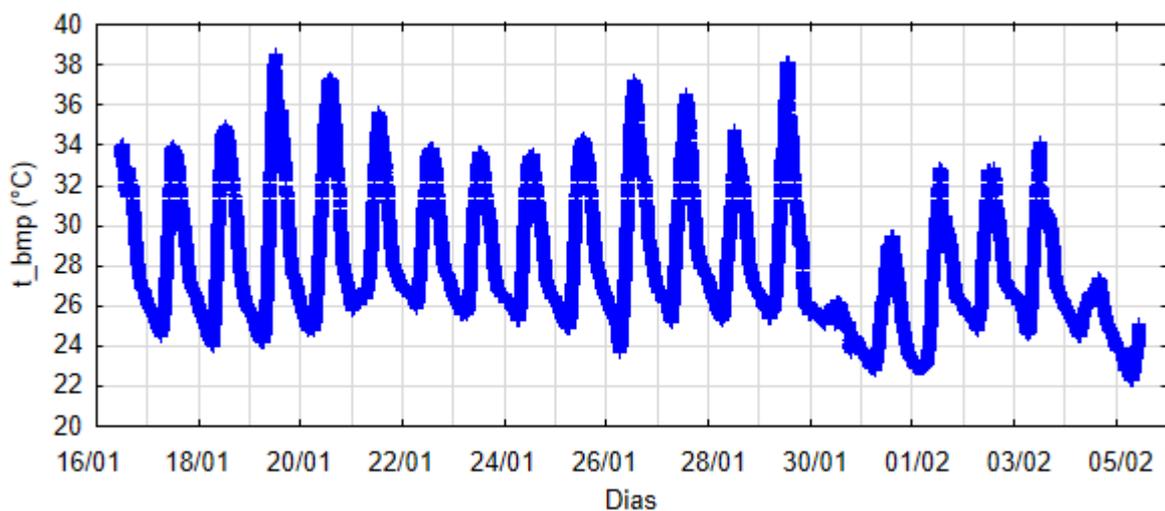
A primeira variável em análise é t_{bmp} , cujos gráficos estão representados na Figura 25. Segundo o histograma é possível identificar que o comportamento da distribuição dos dados é assimétrico à direita, com moda < mediana < média. Os valores estão dispostos entre 22,3 e 38,5°C, mais concentrados na faixa de 26,0 e 28,0°C. A sequência de dados obtida para a temperatura, realizadas pelo sensor BMP085, apresentam como características leituras gradativas e ausência de picos repentinos.

O padrão identificado anteriormente, na análise de t_{dht} em C-01, também pode ser visto na distribuição dos dados de t_{bmp} em C-02, isto é, quando o dia se inicia a temperatura cai até o turno da manhã. Em seguida, a temperatura se eleva até aproximadamente 12h de cada dia, quando atinge o pico mais elevado e torna a diminuir.

Nota-se que durante o dia 30/01 as leituras desta variável se diferiram do padrão identificado, o que pode ter ocorrido devido a fatores externos, como chuvas, que também influenciaram na diminuição das faixas de temperatura diária (mínimo e máximo) após este dia.



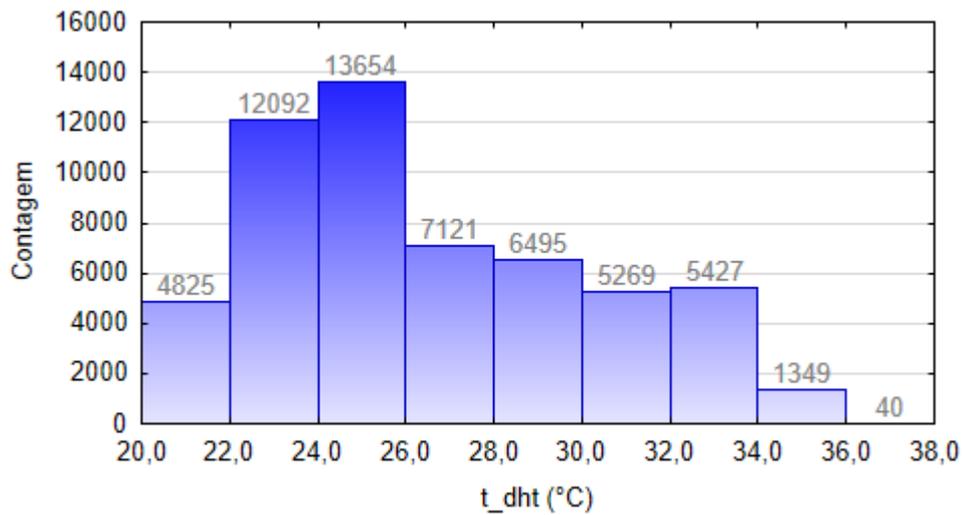
(a)



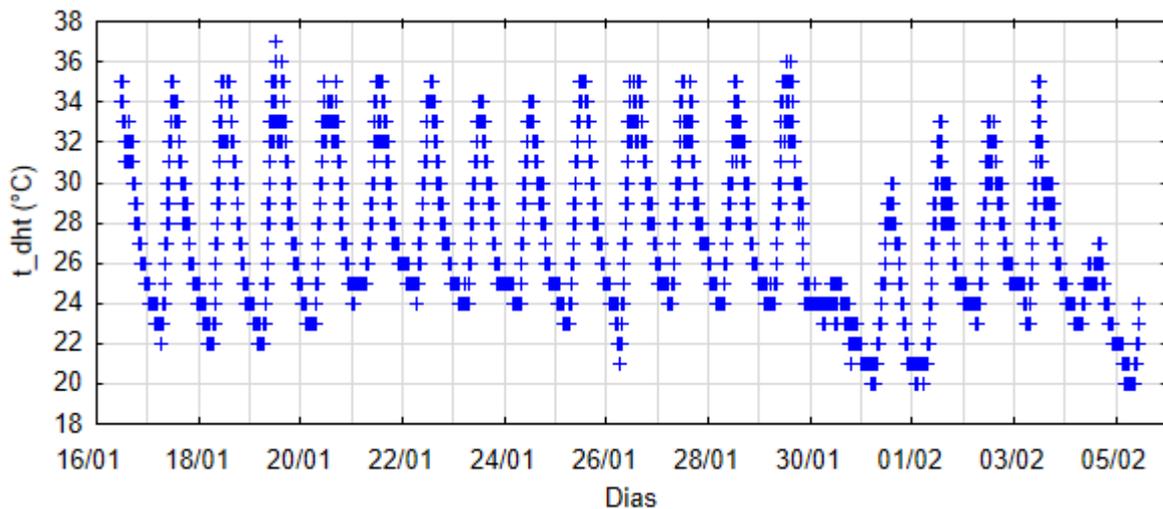
(b)

Figura 25 - Gráficos de (a) histograma e (b) dispersão dos dados, coletados para t_{bmp} em C-02.

Para fins de comparação com a análise anterior, a Figura 26 apresenta os gráficos estatísticos da variável t_{dht} , que obtiveram os valores de temperatura ao longo dos dias, através do sensor DHT-11. Conforme o histograma, o comportamento da distribuição é assimétrico à direita, com $\text{moda} < \text{mediana} < \text{média}$ (similar à variável t_{bmp}). Os valores estão dispostos entre 20,0 e 37,0°C, sendo que a maior concentração ocorre na faixa de 24,0 a 26,0°C. Com relação ao gráfico de dispersão, nota-se que os valores obtidos pelos sensores BMP085 e DHT-11 foram próximos e destacaram o mesmo padrão para o local. Visto que as leituras de t_{dht} não continham casas decimais, a disposição dos dados tem um maior espaçamento.



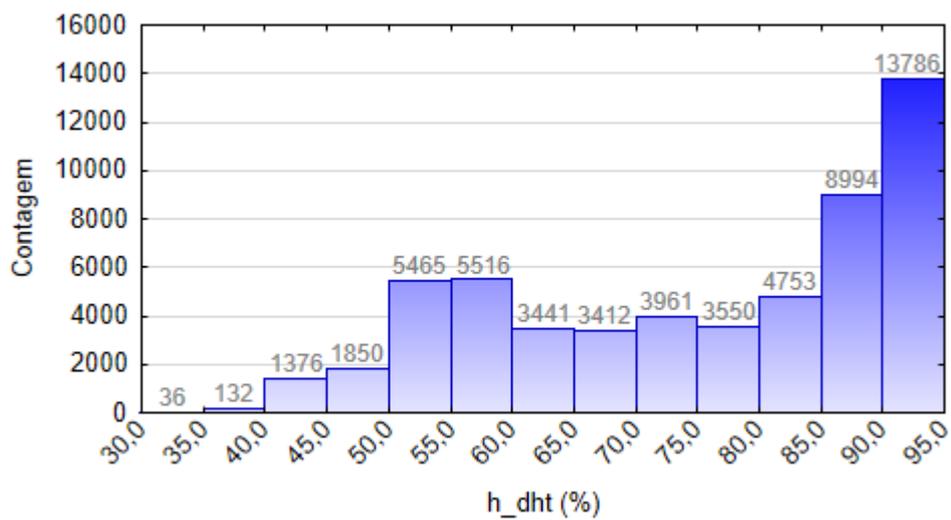
(a)



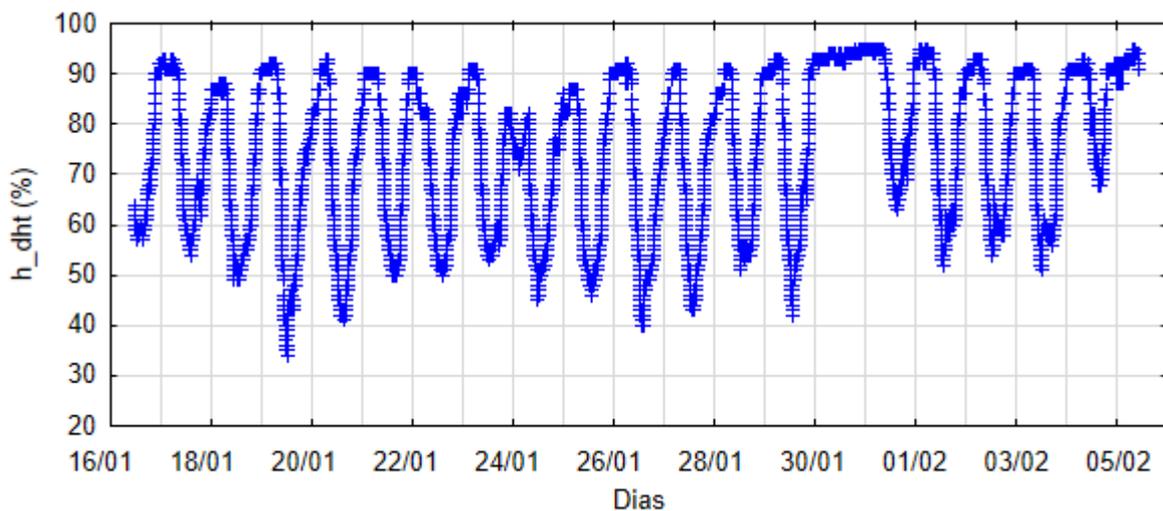
(b)

Figura 26 - Gráficos de (a) histograma e (b) dispersão dos dados, coletados para t_{dht} em C-02.

Os gráficos estatísticos de h_dht estão representados na Figura 27. O comportamento da distribuição é deslocado à esquerda, com $média < mediada < moda$, similar à avaliação realizada para esta variável em C-01. Os dados estão dispostos entre 34,0 e 95,0%, mais concentrados na faixa de 90,0 a 95,0%. O padrão verificado para esta variável considera um aumento da umidade durante a madrugada, em pequenas variações, que se altera ao longo do dia, com variações mais intensas de diminuição até aproximadamente 12h e aumento depois. Vale ressaltar que no dia 30/01 o padrão se alterou, marcando altos percentuais de umidade relativa do ar. Este ponto corrobora as discussões anteriores, pois indica a possibilidade de ocorrência de chuvas no local.



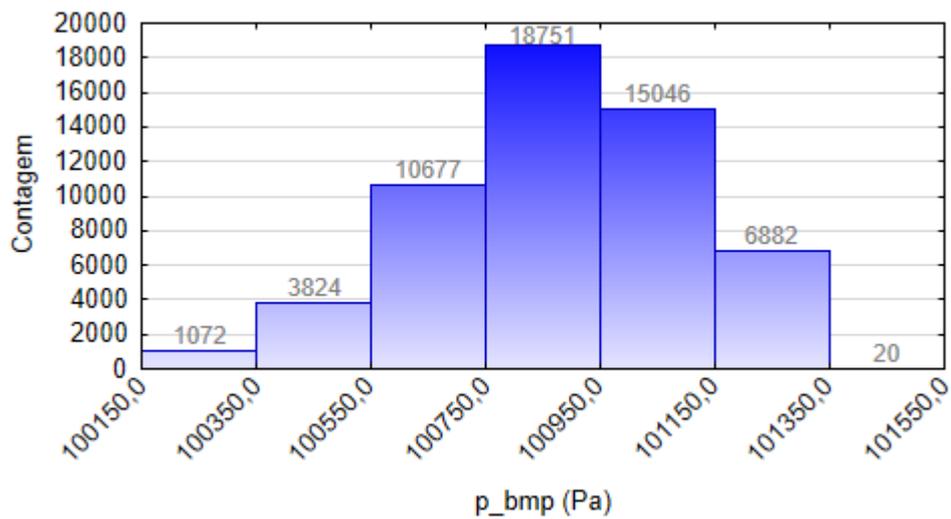
(a)



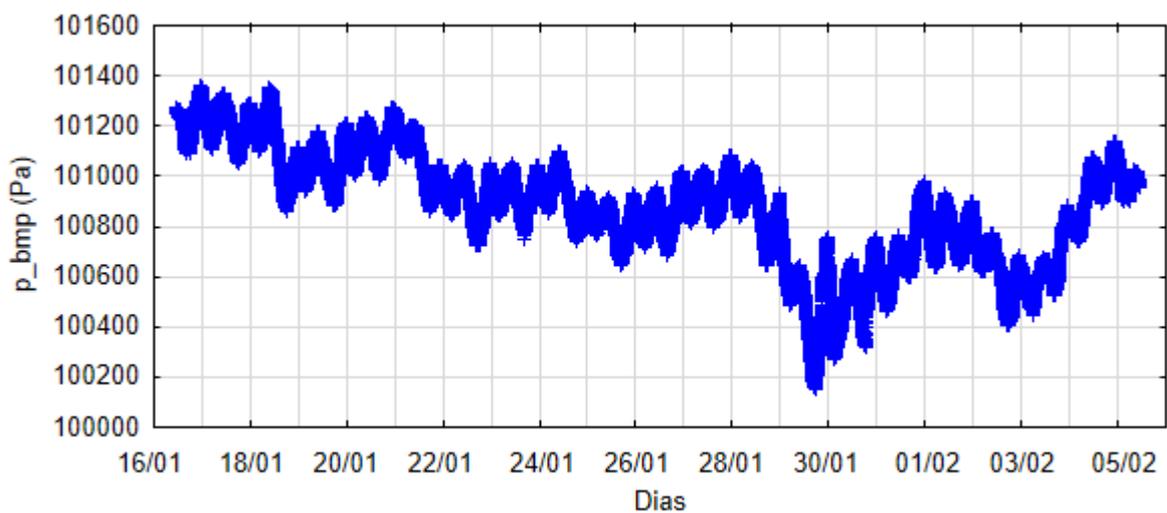
(b)

Figura 27 - Gráficos de (a) histograma e (b) dispersão dos dados, coletados para h_dht em C-02.

A variável p_{bmp} está representada pelos gráficos dispostos na Figura 28. O comportamento da distribuição é simétrico, com moda < média < mediana. Os valores se concentram entre 100.150,0 e 101.364,0 Pa, mais concentrados na faixa de 100.750,0 e 100.950,0 Pa. As leituras foram gradativas e não apresentaram picos repentinos. Apesar das faixas de pressão ao longo da coleta C-02 não serem constantes, considerando o gráfico de dispersão, nota-se que o padrão diário considera um aumento da variável até a metade do dia, seguida por uma diminuição pela tarde e noite.



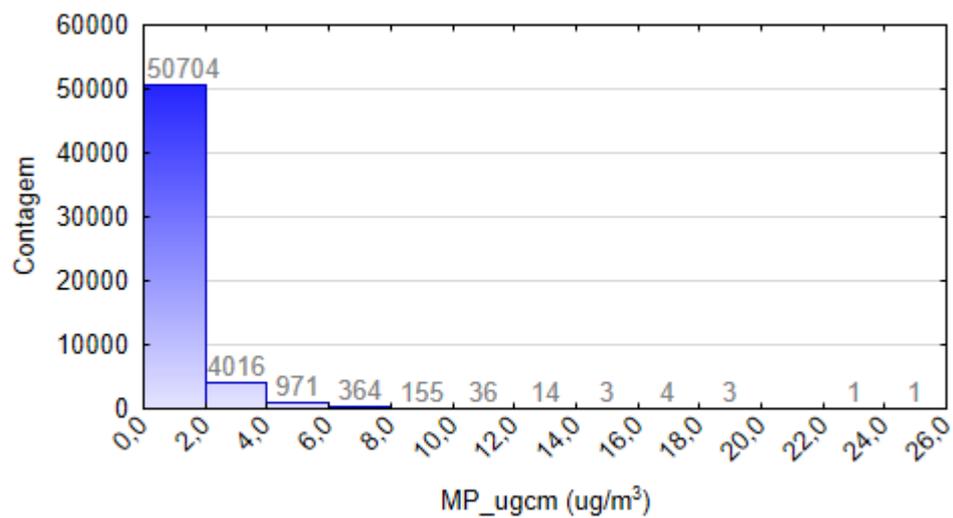
(a)



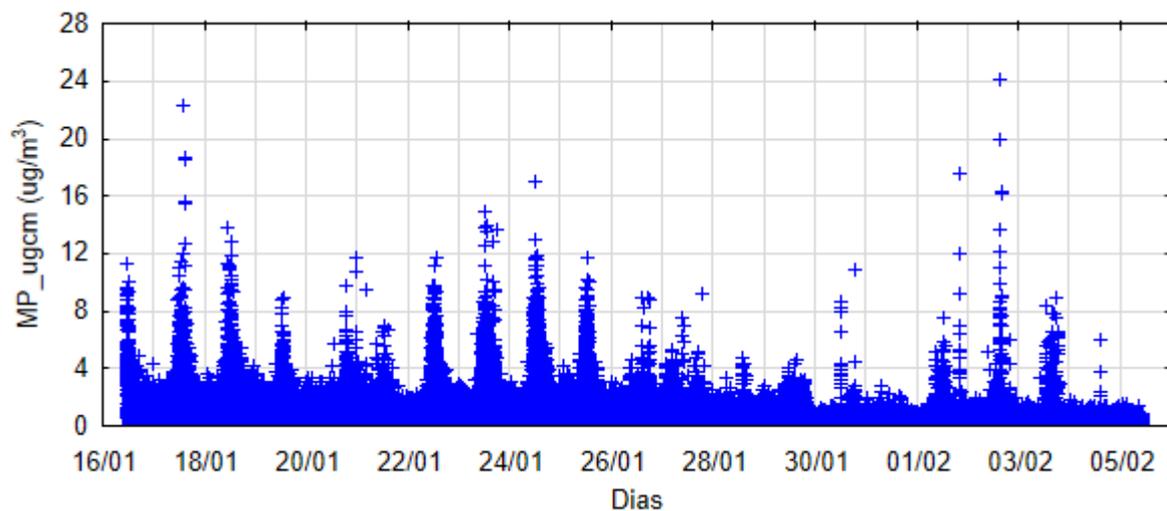
(b)

Figura 28 - Gráficos de (a) histograma e (b) dispersão dos dados, coletados para p_{bmp} em C-02.

A Figura 29 destaca os gráficos referentes à variável MP_ugcm, cujo comportamento da distribuição é assimétrico à direita, com moda < mediana < média (similar aos dados obtidos para esta variável em C-01) e valores entre 0,0 e 24,1 $\mu\text{g}/\text{m}^3$, mais concentrados na faixa de 0,0 e 2,0 $\mu\text{g}/\text{m}^3$. As leituras apresentaram grande dispersão dos dados, com picos significativos. Nota-se que os maiores valores deste poluente foram obtidos na metade dos dias, o que enaltece a existência de fatores externos que influenciem diretamente no aumento da concentração de material particulado neste período do dia. Acredita-se que um aumento do tráfego e das atividades produtivas da região estejam atreladas a esses fatores.



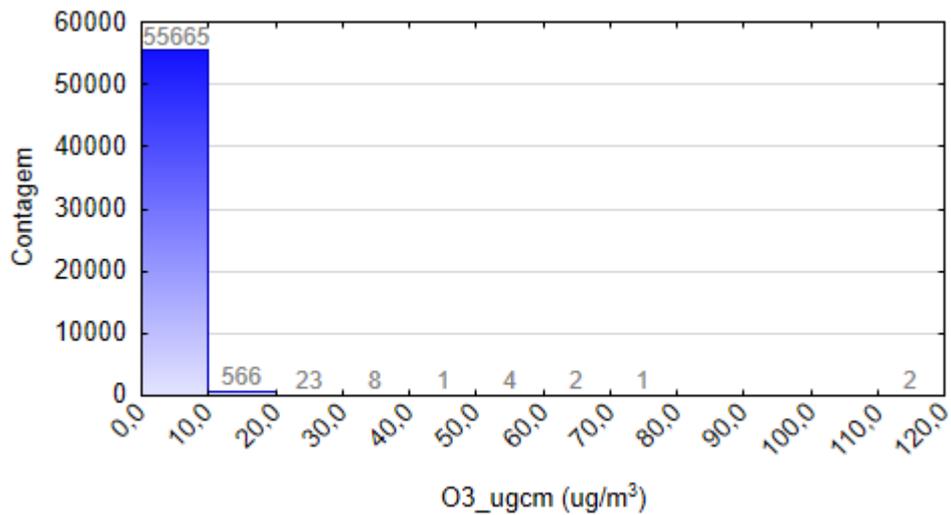
(a)



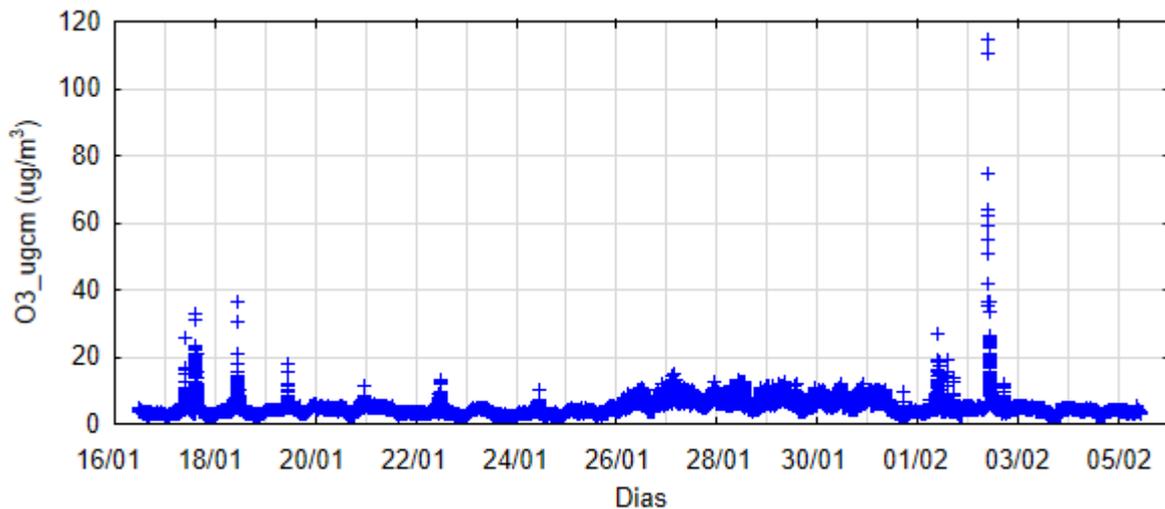
(b)

Figura 29 - Gráficos de (a) histograma e (b) dispersão dos dados, coletados para MP_ugcm em C-02.

Com relação à variável O3_ugcm, os gráficos estatísticos estão representados na Figura 30. O comportamento da distribuição é assimétrico à direita, com moda < mediana < média. Os dados estão dispostos entre 1,7 e 114,6 $\mu\text{g}/\text{m}^3$, mais concentrados na faixa de 0,0 e 10,0 $\mu\text{g}/\text{m}^3$. Apesar das leituras apresentarem picos repentinos, a distribuição dos dados ocorre de forma gradativa. No geral, nota-se que as concentrações diárias do poluente são baixas, sendo que os valores mais elevados são característicos na metade do dia, cujos índices de radiação solar são mais elevados e contribuem no processo de formação do ozônio. Apesar deste ser um poluente secundário, as fontes de emissão discutidas para MP_ugcm também podem estar associadas.



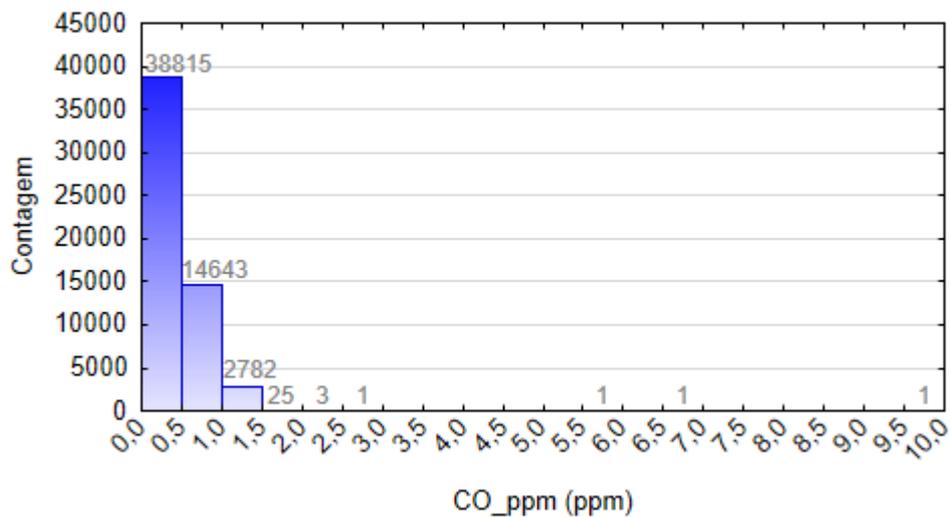
(a)



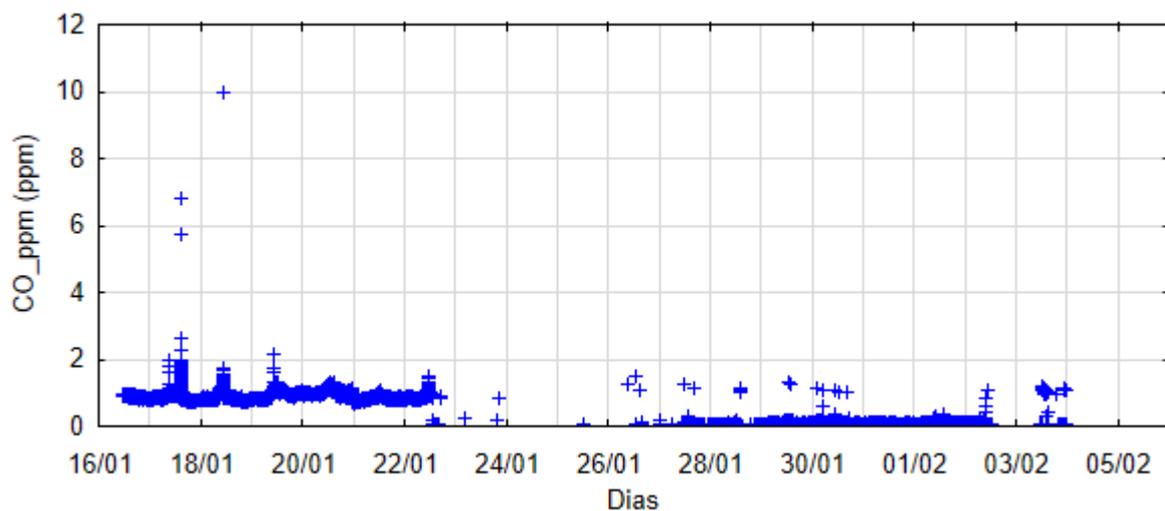
(b)

Figura 30 - Gráficos de (a) histograma e (b) dispersão dos dados, coletados para O3_ugcm em C-02.

A Figura 31 apresenta os gráficos característicos da variável CO_ppm, cujo comportamento da distribuição é assimétrico à direita, com moda < mediana < média e valores compreendidos entre 0,0 e 10,0 ppm, mais concentrados na faixa de 0,0 e 0,5 ppm. De forma similar às análises dos demais poluentes (material particulado e ozônio), verifica-se que as concentrações de monóxido de carbono são baixas, no geral, com os maiores valores diários obtidos por volta de 12h, com alguns picos de leitura. A presença deste poluente pode estar associada ao tráfego local, pelas atividades da cerâmica e/ ou pelo fumo.



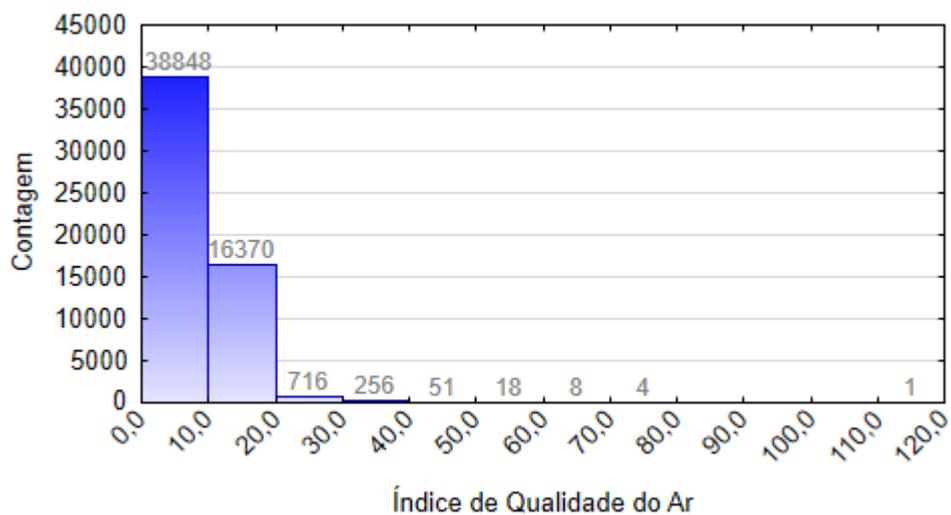
(a)



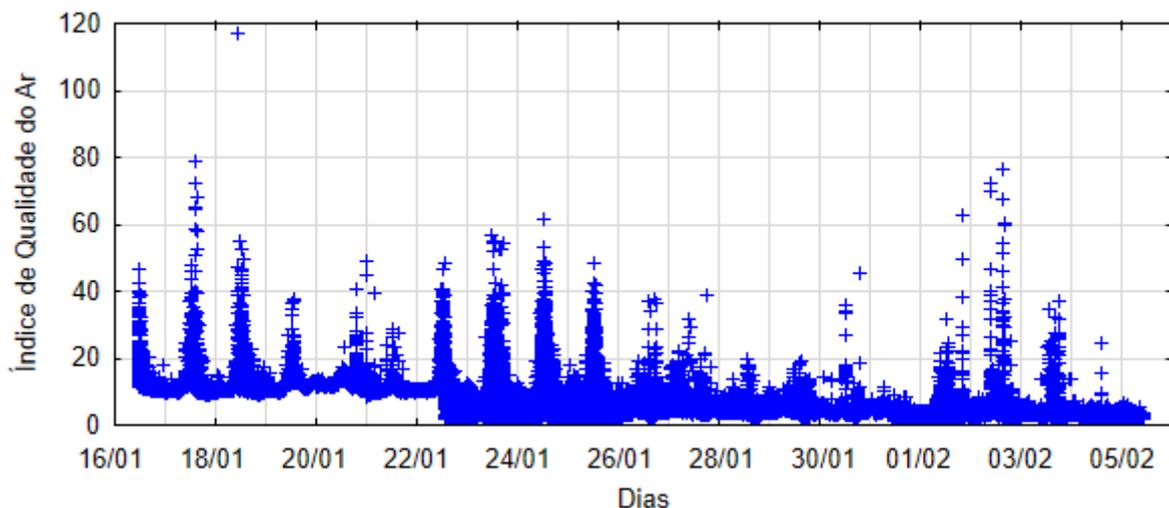
(b)

Figura 31 - Gráficos de (a) histograma e (b) dispersão dos dados, coletados para CO_ppm em C-02.

Por fim, a Figura 32 apresenta os gráficos do Índice de Qualidade do Ar, em C-02. O comportamento da distribuição é assimétrico à direita, com moda < mediana < média. Os valores estão compreendidos entre 1,1 e 116,8, mais concentrados na faixa de 0,0 e 10,0. A classificação da qualidade do ar que se destacou nesse conjunto foi a “Boa” (mais de 99% dos dados analisados). As classes “Regular” e “Inadequada” também estiveram presentes. Considerando o gráfico de dispersão dos dados, nota-se que os maiores valores diários desta variável ocorrem por volta da metade do dia, o que causa a ocorrência de picos. Estas elevações estão atreladas aos comportamentos dos poluentes no local, com maior influência do MP_{ugm}.



(a)



(b)

Figura 32 - Gráficos de (a) histograma e (b) dispersão dos dados, coletados para IQAr em C-02.

4.4.2 Comparativos com Dados na Literatura

Com o intuito de avaliar os valores obtidos durante as coletas dos dados, foram feitas comparações com estudos e dados disponíveis, em plataformas de acesso livre.

De início, comparou-se as temperaturas medidas pelos sensores BMP085 e DHT-11, com dados históricos de temperatura máxima e mínima, disponibilizados em <https://www.accuweather.com/pt/br/brazil-weather>. A Figura 33 apresenta esta comparação, que considerou a média dos valores obtidos no dia. Nota-se que ambos os sensores detectaram temperaturas dentro da faixa de mínimo e máximo, do AccuWeather.

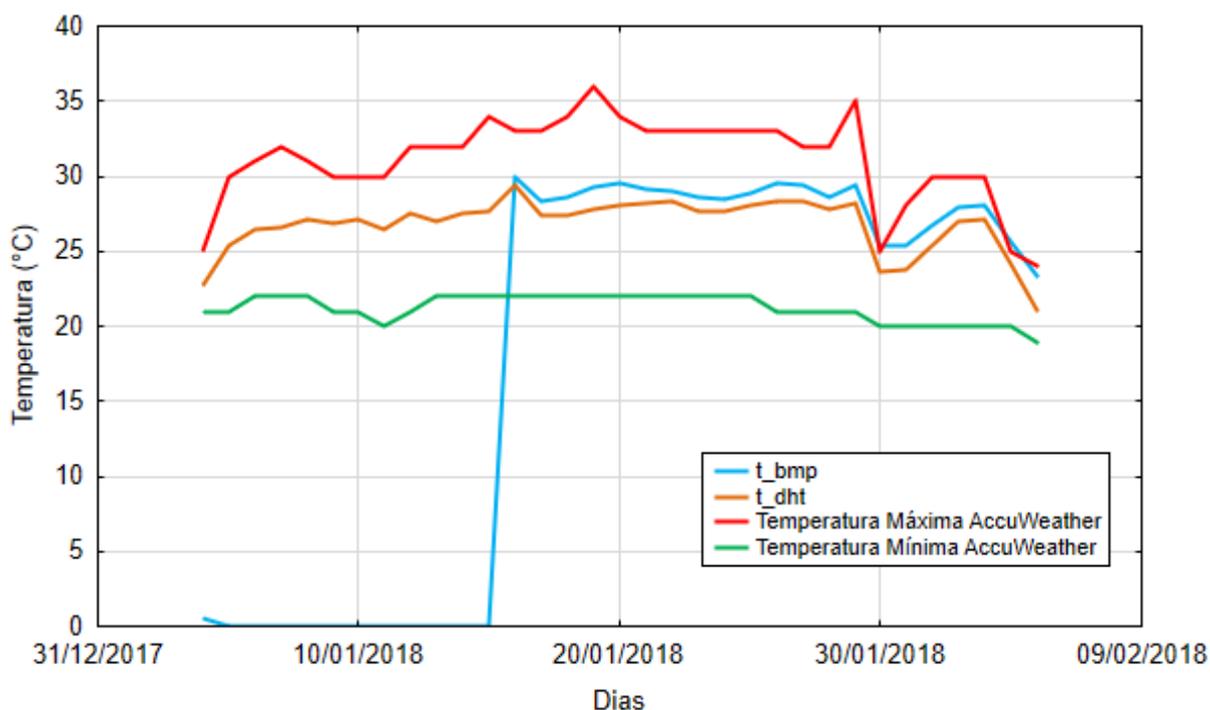


Figura 33 – Comparativo entre os valores obtidos de temperatura no estudo e dados históricos.

Considerando a média dos valores obtidos por dia, em C-02, a Tabela 7 destaca os parâmetros estatísticos de cada meio e os erros relativos percentuais dos sensores, em relação ao AccuWeather. Partindo da premissa adotada por Montgomery e Runger (2016), diz-se que os parâmetros estatísticos foram adequados para a análise. Os baixos erros percentuais também foram satisfatórios quanto à comparação dos sensores com os dados históricos, sendo que a temperatura medida pelo sensor DHT-11 foi a que melhor se adequou.

Tabela 7 - Comparativo entre os parâmetros estatísticos das temperaturas obtidas no estudo e em dados históricos.

Meio de Medição	Mínimo (°C)	Máximo (°C)	Média (°C)	D.P. (°C)	Erro Relativo (%)
AccuWeather	21,50	29,00	26,24	± 2,11	-
t_bmp	23,31	29,94	28,05	± 1,76	6,90
t_dht	21,09	29,40	26,89	± 2,06	2,49

Com relação às concentrações dos gases, foi realizada a comparação com os dados do Boletim de Qualidade do Ar, do Município do Rio de Janeiro, disponibilizados pela Secretaria de Conservação e Meio Ambiente, através do site <http://jeap.rio.rj.gov.br/je-metinfosmac/boletim>.

Este Boletim se baseia nos dados que afetam a qualidade do ar, sendo realizadas as medidas das concentrações de dióxido de enxofre, monóxido de carbono, material particulado (MP₁₀), ozônio e dióxido de nitrogênio, em nove pontos da cidade.

Primeiramente, não foi possível comparar o material particulado, visto que os dados disponíveis no Boletim eram para MP₁₀, enquanto que, neste estudo, os dados foram obtidos para MP_{2,5}.

Em relação às medidas de ozônio, o Boletim considera a média máxima de 1h. Para comparar as concentrações deste gás, foram calculadas as médias de O₃, por hora, e identificados os valores máximos dos dias. Na Figura 34 estão dispostos os valores obtidos no estudo e em três bairros do Rio de Janeiro (Centro, Copacabana e Tijuca).

Verifica-se que as concentrações de ozônio obtidas no estudo foram inferiores às demais. Neste ponto, alguns estudos discutem que o processo de formação do ozônio ocorre principalmente em áreas urbanas, devido a distribuição espacial dos prédios, das indústrias e dos veículos. Altos índices de radiação solar também contribuem para o aumento das concentrações de ozônio na superfície dos centros urbanos (COSTA, 2015; DUTRA; FIORAVANTE; FERREIRA, 2009). Esses fatores podem estar associados aos valores elevados obtidos nos bairros do Rio de Janeiro. Com relação ao Polo de Inovação do IFF, apesar de normalmente o local apresentar fluxo elevado de veículos, o distanciamento entre os prédios e a influência dos ventos podem ter contribuído para as baixas concentrações do poluente.

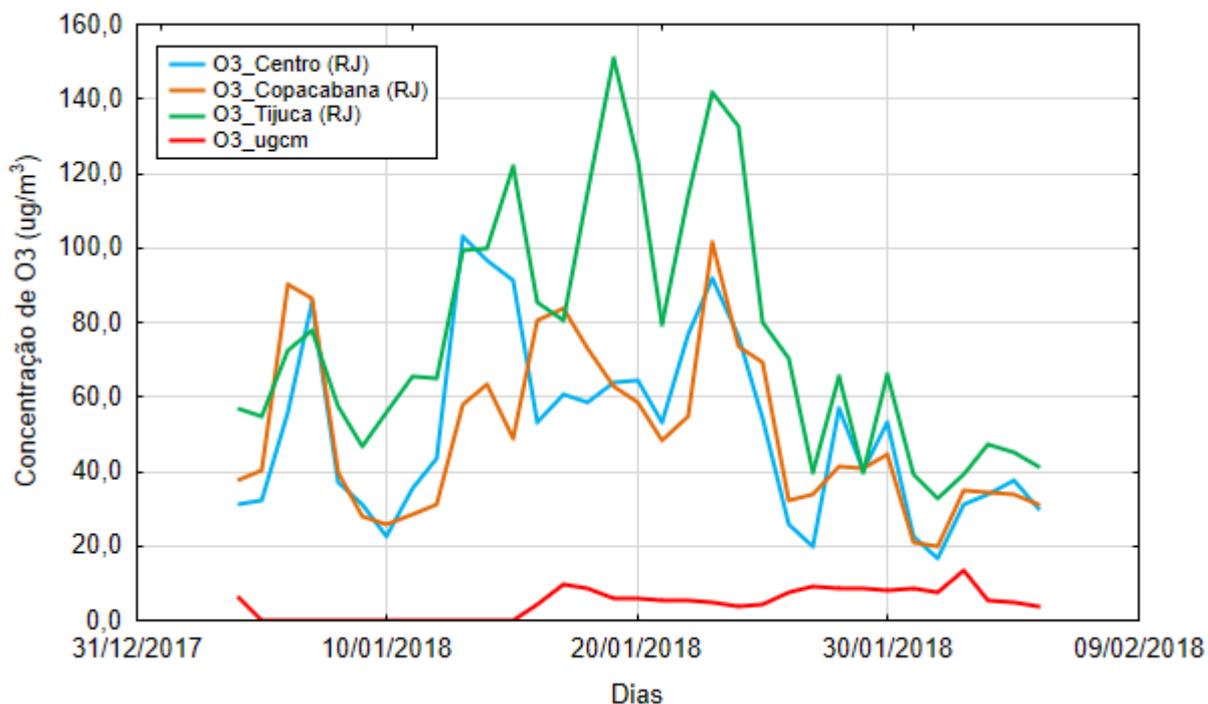


Figura 34 – Comparativo entre os valores obtidos de O₃ no estudo e o Boletim do RJ.

Quanto ao monóxido de carbono, visto que o Boletim apresenta a média máxima de 8h, foram calculadas as médias de CO obtidas no estudo, a cada 8h, e assim, comparou-se a maior média do dia, com os dados dos três bairros do Rio de Janeiro adotados na análise anterior. A Figura 35 apresenta este comparativo, no qual foi possível constatar que os valores obtidos para o poluente, em todas as situações, estiveram situados na classe “Boa”.

Neste ponto vale observar que as concentrações do poluente no Polo de Inovação do IFF se mantiveram superiores às concentrações obtidas no Rio de Janeiro até o dia 21/01/2018. No dia 22 deste mês, entretanto, verifica-se uma queda abrupta das concentrações que, apesar de se elevarem nos próximos dias, se mantiveram próximas a 0,2 ppm, sendo inferior às medidas do Rio de Janeiro.

Tais fenômenos estão associados a localização das estações de monitoramento: os valores mais elevados no Polo podem ser característicos de maiores fluxos do tráfego, visto que a rodovia em frente é caminho para cidades praianas e o período normalmente é marcado por bastante procura (férias escolares) e/ ou devido a um possível aumento das atividades desenvolvidas na cerâmica próxima, resultando em maiores emissões de gases. Em relação à diminuição das concentrações, é possível que tenha ocorrido um aumento da velocidade dos ventos, pela proximidade com o Rio Paraíba do Sul, acarretando na dispersão do poluente.

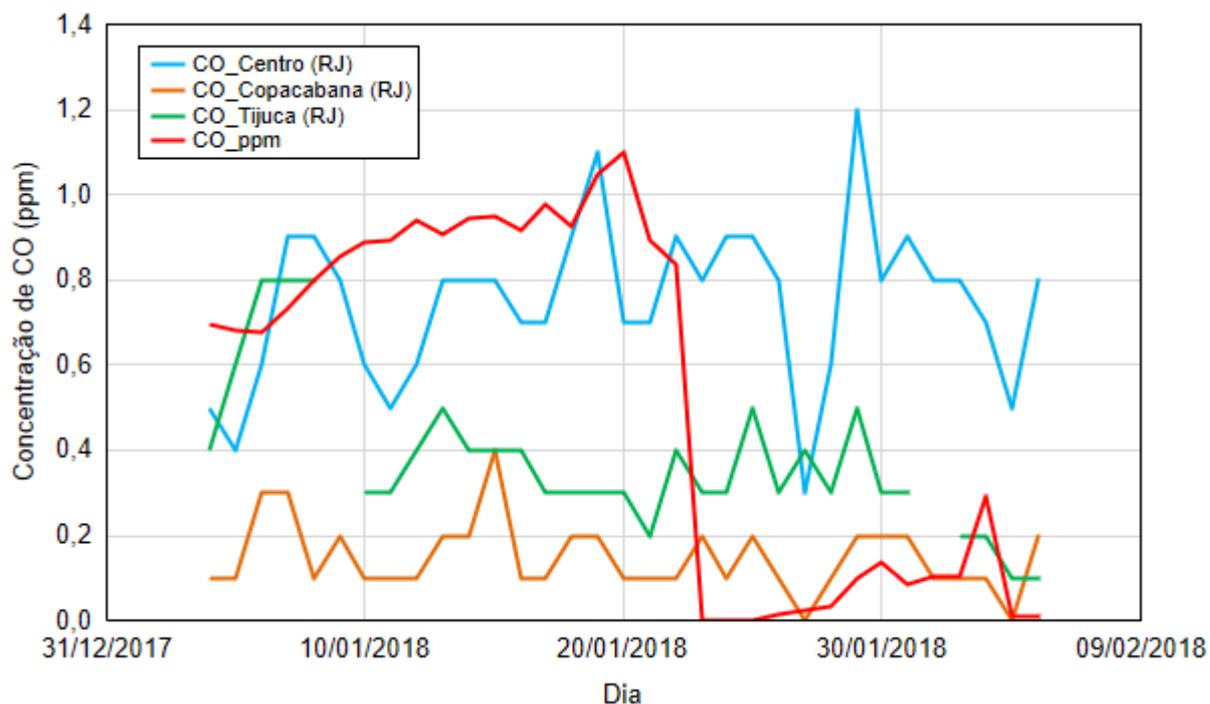


Figura 35 – Comparativo entre os valores obtidos de CO no estudo e o Boletim RJ.

Desta forma, considerou-se que os dados coletados no estudo foram satisfatórios para o monitoramento das condições ambientais do Polo de Inovação do IFF, localizado no município de Campos dos Goytacazes, durante o período de análise.

Visto que em C-02 foram realizadas as coletas de dados de todas as variáveis, utilizou-se este banco de dados no treinamento das redes neurais artificiais, considerando os dias em que todas as horas foram medidas (de 17/01/2018 a 04/02/2018). A próxima seção discute os resultados desta análise.

4.5 Treinamento da RNA

Conforme descrito anteriormente, os treinamentos das redes neurais artificiais foram realizados através do programa TIBCO Statistica® (versão 13.3).

Os treinamentos buscaram avaliar a capacidade de predição das concentrações de três gases poluentes atmosféricos, decorridos um tempo estipulado, a partir das medições das condições ambientais e das concentrações iniciais dos gases medidos.

As redes estruturadas apresentam 5 neurônios na camada de entrada e 1 neurônio na camada de saída, correspondentes às variáveis do sistema. Através do treinamento foi determinado o número de neurônios nas respectivas camadas escondidas (ou ocultas) e estimados os pesos e “*bias*” das conexões.

Dessa forma, foram considerados três esquemas, para a predição das concentrações de material particulado (MP_new), ozônio (O3_new) e monóxido de carbono (CO_new), separadamente. Para cada variável foram realizados treinamentos para a previsão dos dados em 5, 10 e 30 minutos. Nas próximas seções serão apresentadas as redes desenvolvidas nos treinamentos de cada variável e adotadas técnicas estatísticas com o intuito de avaliar a capacidade preditiva das mesmas.

4.5.1 Treinamento para Material Particulado

Na Figura 36 estão esquematizadas as variáveis de entrada e de saída, consideradas no treinamento da RNA para predição das concentrações de material particulado.

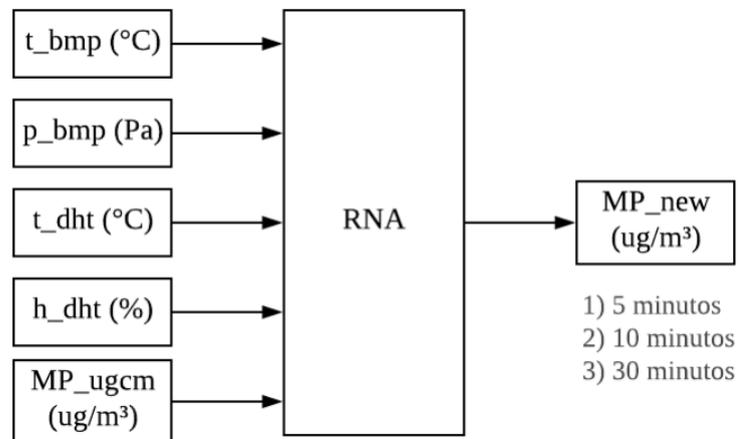


Figura 36 – Esquema de entrada e saída utilizado no treinamento da RNA para predição de material particulado.

Tendo em vista que foram realizados três treinamentos (para predição dos valores em 5, 10 e 30 minutos), serão apresentados e discutidos os resultados de cada treinamento individual, e comparados os resultados das melhores redes obtidas em cada treinamento, considerando suas análises de desempenho.

4.5.1.1 Análise de Desempenho

Ao final do treinamento 1 (5 minutos) foram retidas as dez melhores redes apresentadas na Tabela 8, onde C.O. e C.S. se referem às funções de ativação das camadas oculta e de saída, respectivamente. As performances e os erros de treinamento, teste e validação também estão descritos. É possível verificar que a melhor rede foi a segunda (MLP 5-70-1), com 5 neurônios na camada de entrada, 70 neurônios na camada oculta e 1 neurônio na camada de saída. Isto ocorreu porque seu erro de teste apresentou o menor valor em relação aos demais e os valores de performance de treinamento, de teste e de validação foram maiores.

Verifica-se também que, as funções de ativação utilizadas na melhor rede foram: tangente hiperbólica (Tanh.), para a camada oculta, e exponencial (Exp.), para a camada de saída. Essas funções se destacaram nas demais redes, junto com a função logística (Logíst.).

Tabela 8 - Dez melhores redes treinadas para a predição de material particulado, a cada 5 minutos.

Nº	RNA	Função		Performance			Erro		
		C.O.	C.S.	Trein.	Teste	Valid.	Trein.	Teste	Valid.
1	MLP 5-94-1	Logíst.	Exp.	0,6271	0,6109	0,6142	0,4166	0,4309	0,4201
2	MLP 5-70-1	Tanh.	Exp.	0,6596	0,6365	0,6226	0,3879	0,4097	0,4144
3	MLP 5-73-1	Logíst.	Logíst.	0,6520	0,6287	0,6292	0,3948	0,4166	0,4080
4	MLP 5-60-1	Tanh.	Logíst.	0,6532	0,6254	0,6250	0,3937	0,4189	0,4116
5	MLP 5-60-1	Logíst.	Logíst.	0,6417	0,6262	0,6179	0,4039	0,4178	0,4172
6	MLP 5-57-1	Logíst.	Exp.	0,6367	0,6228	0,6146	0,4083	0,4207	0,4200
7	MLP 5-48-1	Tanh.	Exp.	0,6331	0,6141	0,6132	0,4113	0,4284	0,4210
8	MLP 5-92-1	Logíst.	Logíst.	0,6371	0,6159	0,6137	0,4079	0,4268	0,4208
9	MLP 5-85-1	Logíst.	Exp.	0,6278	0,6186	0,6152	0,4161	0,4243	0,4194
10	MLP 5-78-1	Logíst.	Exp.	0,6309	0,6221	0,6153	0,4133	0,4212	0,4194

A análise que correlaciona os subconjuntos dos dados é importante, visto que as melhores performances de treinamento podem não indicar fielmente os melhores resultados, quando expostos a uma quantidade de ruídos nos dados iniciais. Portanto, o tutorial do Statistica 13.3 aponta que numa análise final deve-se levar em consideração tanto os dados de desempenhos da rede treinada, quanto os de generalização, relacionados às amostras que não

foram utilizadas no treinamento (teste e de validação, com enfoque no primeiro). Dessa forma, adotou-se as premissas desta análise para a avaliação das demais redes obtidas no estudo.

É importante destacar que, das 100 redes treinadas, apenas a arquitetura MLP esteve representada nas melhores redes, o que demonstra um padrão do sistema. Este ponto está em concordância com Haykin (2001) quando este descreve que, normalmente, em problemas de regressão são utilizadas a arquitetura MLP, enquanto que os problemas de classificação adotam a RBF.

O treinamento 2 (10 minutos) apresentou resultados semelhantes ao primeiro, retendo as dez redes descritas na Tabela 9. Pode-se verificar que neste treinamento a melhor rede foi a quinta (MLP 5-100-1), com 5 neurônios na camada de entrada, 100 neurônios na camada oculta e 1 neurônio na camada de saída. As funções de ativação utilizadas foram: tangente hiperbólica, para a camada oculta, e logística, para a camada de saída.

Tabela 9 - Dez melhores redes treinadas para a predição de material particulado, a cada 10 minutos.

Nº	RNA	Função		Performance			Erro		
		C.O.	C.S.	Trein.	Teste	Valid.	Trein.	Teste	Valid.
1	MLP 5-64-1	Tanh.	Exp.	0,6538	0,5938	0,6173	0,3835	0,5039	0,4118
2	MLP 5-24-1	Tanh.	Exp.	0,6544	0,5963	0,6143	0,3828	0,5012	0,4138
3	MLP 5-96-1	Logíst.	Exp.	0,6696	0,6031	0,6163	0,3694	0,4952	0,4139
4	MLP 5-55-1	Tanh.	Tanh.	0,6444	0,5884	0,6191	0,3915	0,5084	0,4095
5	MLP 5-100-1	Tanh.	Logíst.	0,6767	0,6142	0,6256	0,3631	0,4846	0,4057
6	MLP 5-98-1	Tanh.	Logíst.	0,6709	0,6088	0,6224	0,3684	0,4897	0,4086
7	MLP 5-91-1	Logíst.	Logíst.	0,6617	0,6054	0,6228	0,3765	0,4928	0,4072
8	MLP 5-54-1	Logíst.	Exp.	0,6574	0,5956	0,6119	0,3803	0,5020	0,4168
9	MLP 5-90-1	Tanh.	Logíst.	0,6663	0,6016	0,6230	0,3724	0,4966	0,4074
10	MLP 5-52-1	Tanh.	Exp.	0,6528	0,5963	0,6114	0,3844	0,5012	0,4165

Em relação ao treinamento 3 (30 minutos), a Tabela 10 apresenta as dez melhores redes retidas, na qual a nona (MLP 5-56-1) obteve melhores resultados para a performance e erro de teste. Esta rede contém 5 neurônios na camada de entrada, 56 neurônios na camada oculta e 1 neurônio na camada de saída. A função de ativação logística foi utilizada para as duas camadas.

Tabela 10 - Dez melhores redes treinadas para a predição de material particulado, a cada 30 minutos.

Nº	RNA	Função		Performance			Erro		
		C.O.	C.S.	Trein.	Teste	Valid.	Trein.	Teste	Valid.
1	MLP 5-23-1	Tanh.	Logíst.	0,6421	0,5908	0,6327	0,3947	0,5078	0,3912
2	MLP 5-54-1	Tanh.	Logíst.	0,6572	0,6009	0,6539	0,3815	0,4987	0,3734
3	MLP 5-56-1	Tanh.	Logíst.	0,6587	0,6037	0,6521	0,3803	0,4961	0,3750
4	MLP 5-62-1	Tanh.	Logíst.	0,6520	0,5890	0,6420	0,3862	0,5103	0,3835
5	MLP 5-46-1	Tanh.	Exp.	0,6568	0,5959	0,6409	0,3819	0,5036	0,3845
6	MLP 5-21-1	Tanh.	Exp.	0,6426	0,5837	0,6348	0,3943	0,5151	0,3895
7	MLP 5-50-1	Tanh.	Exp.	0,6595	0,5979	0,6463	0,3795	0,5018	0,3799
8	MLP 5-53-1	Tanh.	Exp.	0,6600	0,5965	0,6490	0,3791	0,5033	0,3776
9	MLP 5-56-1	Logíst.	Logíst.	0,6522	0,6072	0,6468	0,3859	0,4926	0,3794
10	MLP 5-23-1	Tanh.	Logíst.	0,6400	0,5855	0,6363	0,3965	0,5131	0,3883

Sendo assim, a Tabela 11 compara as melhores redes obtidas em cada treinamento (1, 2 e 3, referentes à predição dos valores em 5, 10 e 30 minutos, respectivamente), as quais são provenientes das análises acima. Comparando as melhores redes neurais artificiais obtidas em cada treinamento, nota-se que o treinamento 1 apresentou o melhor desempenho em relação às demais, visto que seu erro de teste foi o menor. Os parâmetros de pesos e “bias” desta rede estão descritos no Apêndice C. Quanto às performances, os valores dos três treinamentos apresentaram valores próximos.

Tabela 11 - Comparação dos desempenhos das RNA selecionadas para o material particulado, em cada treinamento.

Treinamento	RNA	Performance			Erro		
		Trein.	Teste	Valid.	Trein.	Teste	Valid.
1 (5 min)	MLP 5-70-1	0,6596	0,6365	0,6226	0,3879	0,4097	0,4144
2 (10 min)	MLP 5-100-1	0,6767	0,6142	0,6256	0,3631	0,4846	0,4057
3 (30 min)	MLP 5-56-1	0,6522	0,6072	0,6468	0,3859	0,4926	0,3794

Essa análise possibilitou identificar que, quanto maior o tempo para a predição de valores das concentrações de material particulado, maiores serão os erros de teste das redes, isto é, menor será a capacidade de generalização das redes neurais artificiais.

Nesta linha, as demais análises estatísticas consideraram a melhor rede neural artificial desenvolvida para o material particulado.

4.5.1.2 Dados Preditos pela RNA *versus* Dados Observados

Considerando a RNA obtida no treinamento 1 (MLP 5-70-1), inicializou-se as análises estatísticas pela avaliação da distribuição de frequências dos resíduos da rede, considerando o subconjunto utilizado para o treinamento, através do histograma representado na Figura 37. Os resíduos foram calculados pela diferença entre os valores observados (reais) e os valores preditos pela RNA. Verifica-se pelo histograma que o comportamento da distribuição é assimétrico à direita, com valores entre -7,0 e 19,0 $\mu\text{g}/\text{m}^3$, mais concentrados na faixa de -3,0 e -1,0 $\mu\text{g}/\text{m}^3$, o que indica que na maioria dos casos a rede previu valores maiores em relação aos reais, com diferença de até 3,0 $\mu\text{g}/\text{m}^3$. Quanto aos erros relativos dessas previsões, os valores estiveram mais concentrados entre 0,0 e 50,0%. Entretanto, verificou-se a grande ocorrência de percentuais muito elevados, com diferenças expressivas em relação aos valores reais. A distribuição assimétrica do histograma também indica uma quantidade maior de ruídos.

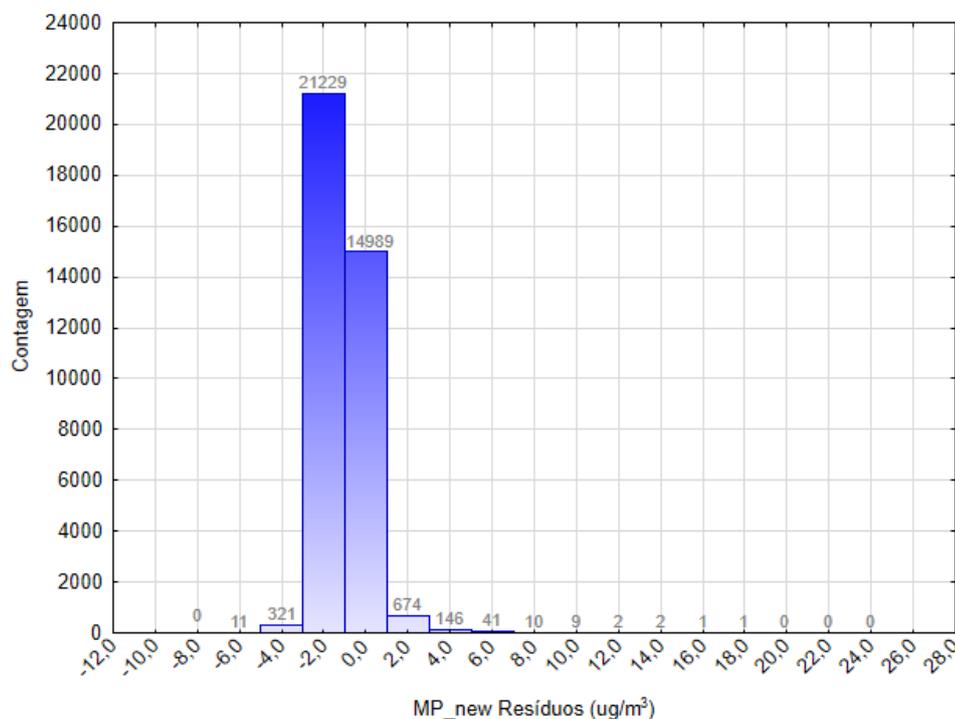


Figura 37 – Histograma de distribuição dos resíduos, para o treinamento de material particulado.

Em seguida gerou-se o gráfico descrito na Figura 38 com a dispersão dos valores preditos pela rede em relação aos valores observados (reais), cuja curva obteve R^2 igual a 0,4351. Nota-se que há uma dispersão considerável dos pontos ao longo da linha de ajuste, o que influenciou no baixo valor de R^2 . Pode-se concluir que neste caso a RNA apresentou baixa correlação com os dados reais.

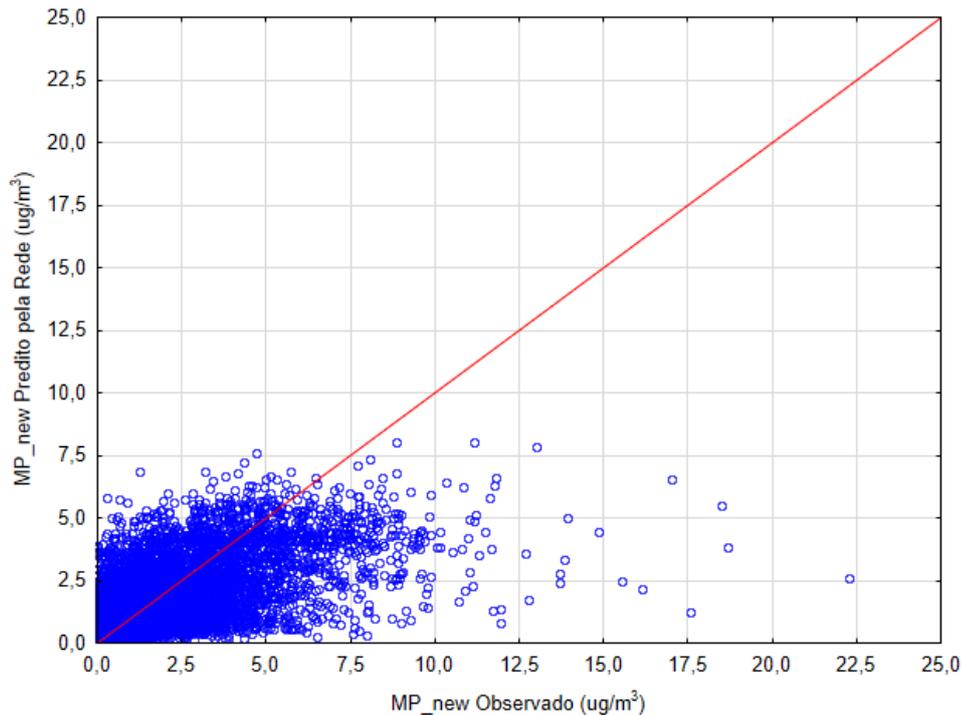


Figura 38 – Dispersão dos dados preditos pela RNA em relação aos dados observados, para o treinamento de material particulado.

A baixa adequação do modelo neural é justificável tendo em vista a forma na qual o sensor PPD42 opera. Conforme abordado anteriormente, este sensor realiza medições pontuais, através da contagem de partículas que atravessaram a sua carcaça durante o momento da coleta. Com isso, os resultados obtidos em sua medição não são contínuos e apresentam picos consideráveis, que influenciaram no treinamento da RNA.

4.5.1.3 Comparação entre os Dados Experimentais e os Dados Preditos

A Figura 39 apresenta a comparação entre os valores preditos pela RNA do treinamento 1 com os valores observados (reais), considerando a sequência dos dados do subconjunto

utilizado para o treinamento das redes. Quando a concentração do poluente foi inferior a $2,5 \mu\text{g}/\text{m}^3$ houve uma proximidade dos dados comparados, com pequenos desvios. Entretanto, quando o sensor detectou picos da concentração do poluente, o valor predito pela RNA apresentou uma grande dispersão da realidade, com baixa capacidade preditiva em tais situações. Este último ponto, apesar de parecer um problema, é uma vantagem do modelo, pois a rede foi capaz de identificar esses pontos como ruídos e assim evitou modelá-los como verdadeiros sinais (conforme tutorial do Statistica 13.3).

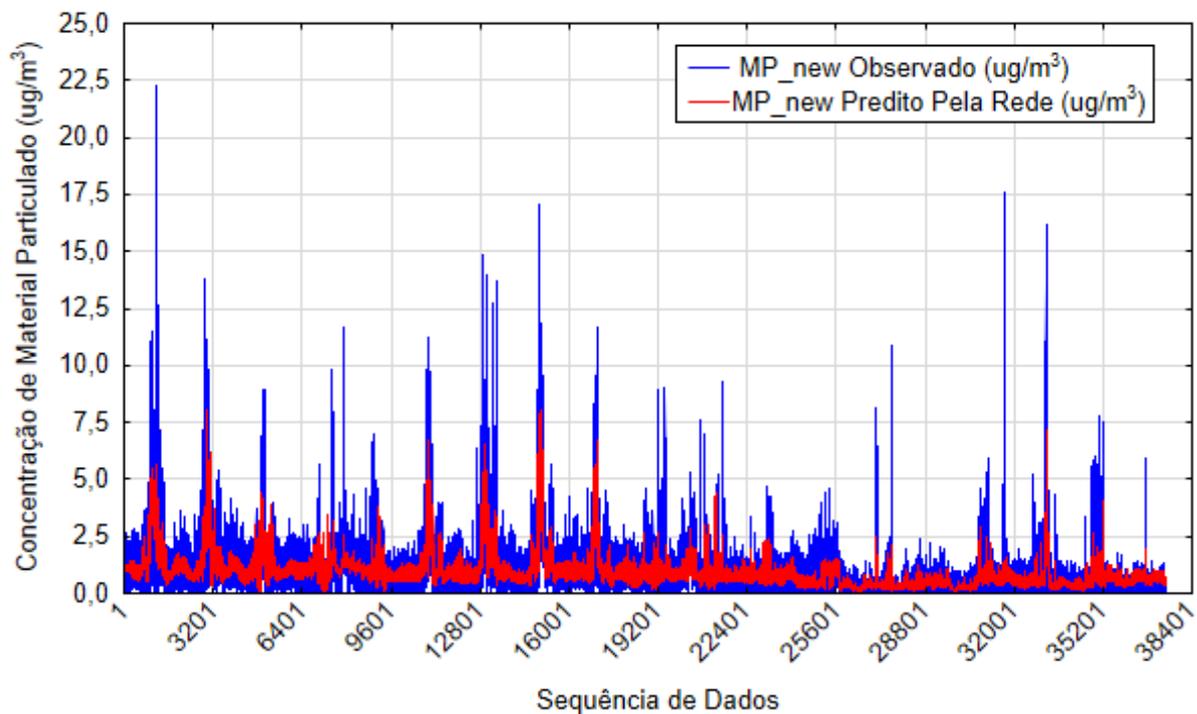


Figura 39 - Comparação da sequência de dados preditos pela RNA e os observados, em relação à variável MP_{new}, considerando o subconjunto de treinamento.

Estes pontos também foram verificados na Figura 40, que considerou os dados utilizados nos subconjuntos para teste e para validação da rede.

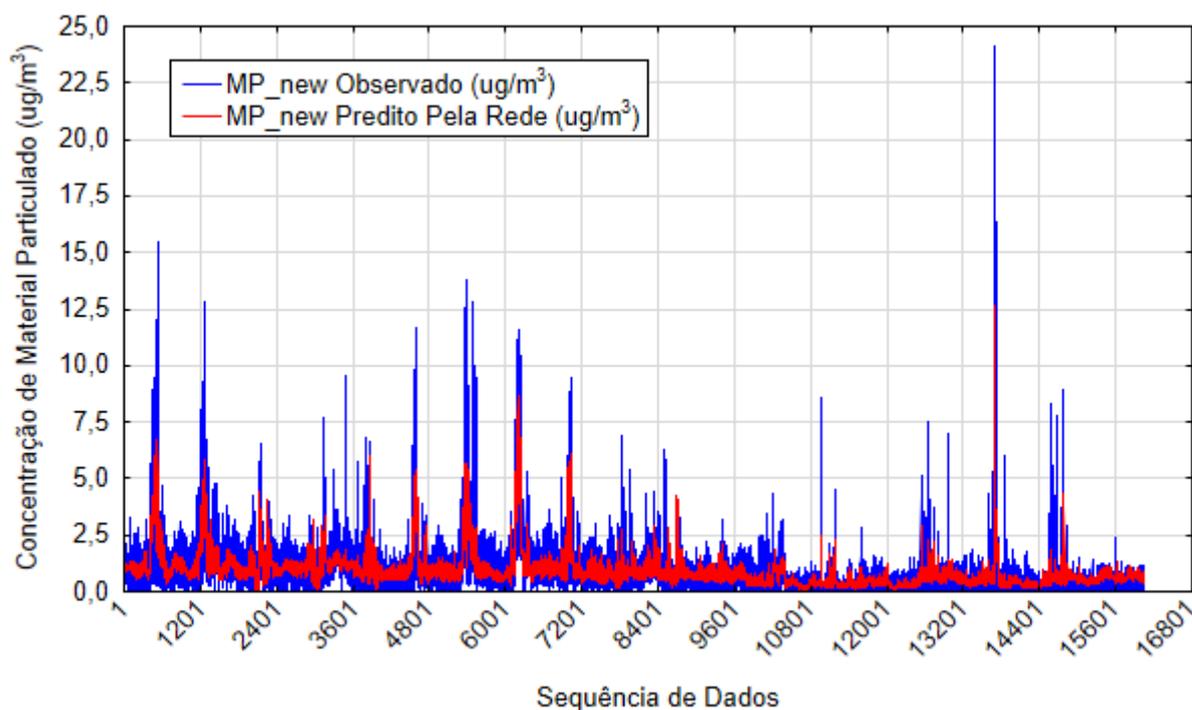


Figura 40 - Comparação da sequência de dados preditos pela RNA e os observados, em relação à variável MP_new, considerando os subconjuntos de teste e validação.

Fonte: Elaboração própria.

Considerando todas as análises realizadas anteriormente, confere-se que os valores preditos pela RNA têm baixa correlação com os dados observados, o que resultou numa rede com baixa capacidade preditiva para a variável MP_new, a partir das variáveis estabelecidas como entrada. O principal motivador está na natureza dos dados, visto que o sensor obteve muitas leituras ruidosas (com grande quantidade de picos).

Assim, o uso deste modelo deverá ser avaliado conforme o foco da aplicação, isto é, caso seja necessária uma precisão dos valores preditos, deverão ser adotados outros métodos ou métodos auxiliares.

4.5.1.4 Análise dos Dados Estatísticos

Os resultados estatísticos das melhores redes (atribuídas aos treinamentos 1, 2 e 3), para a predição de material particulado, estão destacados na Tabela 12. Considerando a premissa de avaliação da relação entre a média e o desvio padrão, adotada por Montgomery e Runger (2016), os parâmetros estatísticos das RNA obtidas para a predição da variável MP_new

apresentam desvios consideráveis, uma vez que os desvios padrão calculados foram superiores às médias dos dados. As análises anteriores também atestaram tal afirmativa.

Tabela 12 - Parâmetros estatísticos das melhores redes obtidas nos treinamentos 1, 2 e 3, de material particulado.

Parâmetros Estatísticos	MP_new (ug/m ³)		
	MLP 5-70-1	MLP 5-100-1	MLP 5-56-1
Média dos dados	0,9559	0,9525	0,9524
Desvio padrão dos dados	1,1718	1,1572	1,1589

4.5.1.5 Análise de Sensibilidade

Por fim analisou-se a importância relativa das variáveis utilizadas nas camadas de entrada das redes neurais artificiais desenvolvidas para o material particulado, através da análise de sensibilidade, que avalia o número de *RATIO* calculado para cada uma.

Considerando os dados Tabela 13 é possível notar que a temperatura medida pelo sensor BMP085 (variável *t_bmp*) apresentou maior contribuição nas três redes destacadas. Em contrapartida, a concentração de material particulado (variável *MP_ugcm*) contribuiu pouco na previsão de *MP_new*, nos três treinamentos.

Este último ponto corrobora a discussão acerca da forma na qual o sensor PPD42 opera, o que afeta no desenvolvimento de um modelo preditivo de alta precisão, devido à dificuldade do reconhecimento e da caracterização do sistema.

Tabela 13 - Análise de sensibilidade das RNA treinadas para o material particulado.

Treinamento	RNA	<i>t_bmp</i>	<i>p_bmp</i>	<i>t_dht</i>	<i>h_dht</i>	<i>MP_ugcm</i>
1 (5 min)	MLP 5-70-1	20,94	1,40	4,20	2,13	1,31
2 (10 min)	MLP 5-100-1	3,43	1,46	2,25	2,76	1,29
3 (30 min)	MLP 5-56-1	5,82	1,35	3,30	2,21	1,24

4.5.2 Treinamento para Ozônio

Após o treinamento de material particulado, realizou-se o treinamento para predição das concentrações de ozônio. A nova RNA considerou o esquema da Figura 41 quanto às variáveis de entrada e de saída.

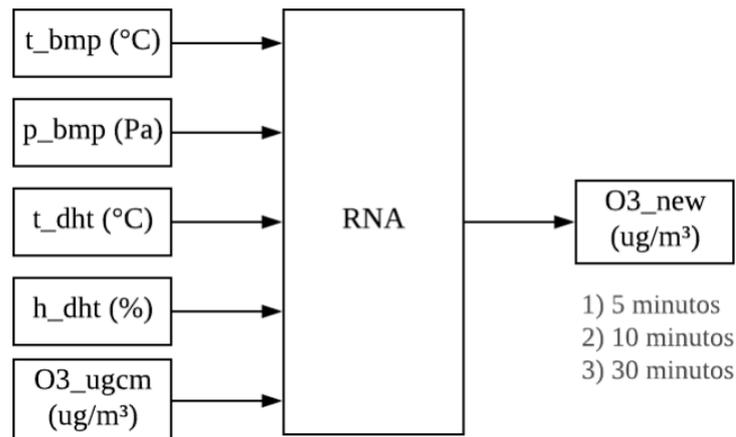


Figura 41 - Esquema de entrada e saída utilizado no treinamento da RNA para predição de ozônio.

Neste ponto também foram realizados três treinamentos (para predição dos valores em 5, 10 e 30 minutos), cujos resultados serão apresentados e discutidos, individualmente, nas próximas seções.

4.5.2.1 Análise de Desempenho

Ao final do treinamento 1 (5 minutos), foram retidas as dez melhores redes apresentadas na Tabela 14. Nesta seção foi possível identificar uma simultaneidade quanto à arquitetura das redes (MLP) e à função de ativação das camadas escondida e de saída (exponencial). Verifica-se então que a primeira rede (MLP 5-86-1) foi a melhor treinada para o cenário em análise, pois apresentou o menor erro de teste. Esta rede é composta de 5 neurônios na camada de entrada, 86 neurônios na camada oculta e 1 neurônio na camada de saída. As performances desta rede apresentaram resultados similares aos resultados das demais.

Tabela 14 - Dez melhores redes treinadas para a predição de ozônio, a cada 5 minutos.

Nº	RNA	Função		Performance			Erro		
		C.O.	C.S.	Trein.	Teste	Valid.	Trein.	Teste	Valid.
1	MLP 5-86-1	Exp.	Exp.	0,8103	0,9245	0,8698	0,8338	0,2356	0,4708
2	MLP 5-90-1	Exp.	Exp.	0,8108	0,9233	0,8699	0,8318	0,2392	0,4705
3	MLP 5-90-1	Exp.	Exp.	0,8107	0,9235	0,8690	0,8320	0,2384	0,4735
4	MLP 5-47-1	Exp.	Exp.	0,8105	0,9240	0,8695	0,8331	0,2372	0,4720
5	MLP 5-83-1	Exp.	Exp.	0,8107	0,9240	0,8697	0,8322	0,2370	0,4713
6	MLP 5-71-1	Exp.	Exp.	0,8106	0,9238	0,8690	0,8326	0,2377	0,4738
7	MLP 5-68-1	Exp.	Exp.	0,8104	0,9241	0,8693	0,8334	0,2366	0,4726
8	MLP 5-77-1	Exp.	Exp.	0,8099	0,9232	0,8691	0,8354	0,2393	0,4730
9	MLP 5-40-1	Exp.	Exp.	0,8105	0,9232	0,8690	0,8331	0,2396	0,4738
10	MLP 5-37-1	Exp.	Exp.	0,8100	0,9234	0,8690	0,8348	0,2390	0,4736

Quanto ao treinamento 2 (10 minutos), a Tabela 15 apresenta as dez melhores redes retidas. Neste ponto a sétima rede (MLP 5-52-1) foi a melhor, com o menor valor de erro de teste. Suas performances (de treinamento, teste e validação) também foram superiores às demais. Essa rede é composta de 5 neurônios na camada de entrada, 52 neurônios na camada oculta e 1 neurônio na camada de saída. As funções de ativação utilizadas foram: tangente hiperbólica para a camada oculta e exponencial para a camada de saída.

Tabela 15 - Dez melhores redes treinadas para a predição de ozônio, a cada 10 minutos.

Nº	RNA	Função		Performance			Erro		
		C.O.	C.S.	Trein.	Teste	Valid.	Trein.	Teste	Valid.
1	MLP 5-73-1	Tanh.	Logíst.	0,8375	0,8862	0,6632	0,6317	0,3620	1,8613
2	MLP 5-77-1	Tanh.	Logíst.	0,8372	0,8837	0,6651	0,6328	0,3702	1,8521
3	MLP 5-74-1	Tanh.	Exp.	0,8369	0,8876	0,6639	0,6337	0,3577	1,8576
4	MLP 5-60-1	Tanh.	Exp.	0,8373	0,8877	0,6648	0,6325	0,3582	1,8532
5	MLP 5-57-1	Tanh.	Exp.	0,8347	0,8815	0,6632	0,6416	0,3763	1,8603
6	MLP 5-74-1	Tanh.	Logíst.	0,8360	0,8838	0,6637	0,6369	0,3693	1,8583
7	MLP 5-52-1	Tanh.	Exp.	0,8400	0,8907	0,6687	0,6226	0,3486	1,8368
8	MLP 5-76-1	Tanh.	Logíst.	0,8375	0,8849	0,6652	0,6318	0,3662	1,8521
9	MLP 5-68-1	Tanh.	Exp.	0,8374	0,8875	0,6665	0,6322	0,3584	1,8466
10	MLP 5-75-1	Tanh.	Logíst.	0,8367	0,8826	0,6642	0,6346	0,3731	1,8564

Em relação ao treinamento 3 (30 minutos) a Tabela 16 retrata as dez melhores redes retidas e suas performances e erros. A melhor rede deste treinamento foi a décima (MLP 5-63-1), com 5 neurônios na camada de entrada, 63 neurônios na camada oculta e 1 neurônio na camada de saída. As funções de ativação utilizadas foram: tangente hiperbólica para a camada oculta e exponencial para a camada de saída.

Tabela 16 - Performances e erros das dez melhores redes treinadas para a predição de ozônio, a cada 30 minutos.

Nº	RNA	Função		Performance			Erro		
		C.O.	C.S.	Trein.	Teste	Valid.	Trein.	Teste	Valid.
1	MLP 5-75-1	Tanh.	Logíst.	0,8732	0,8517	0,9000	0,5019	0,8382	0,3813
2	MLP 5-66-1	Tanh.	Logíst.	0,9110	0,8883	0,9073	0,3594	0,6474	0,3523
3	MLP 5-67-1	Logíst.	Exp.	0,8928	0,9001	0,9008	0,4299	0,6155	0,3813
4	MLP 5-69-1	Logíst.	Logíst.	0,8941	0,8961	0,9050	0,4244	0,5985	0,3671
5	MLP 5-80-1	Logíst.	Logíst.	0,8831	0,8681	0,8995	0,4666	0,7488	0,3863
6	MLP 5-71-1	Tanh.	Exp.	0,9097	0,8862	0,9142	0,3642	0,6531	0,3271
7	MLP 5-63-1	Logíst.	Exp.	0,9045	0,9163	0,9106	0,3846	0,4887	0,3429
8	MLP 5-71-1	Tanh.	Logíst.	0,8872	0,8789	0,9012	0,4497	0,6913	0,3794
9	MLP 5-80-1	Logíst.	Exp.	0,9104	0,8938	0,9108	0,3621	0,6103	0,3402
10	MLP 5-63-1	Tanh.	Exp.	0,9014	0,9237	0,9014	0,3975	0,4520	0,3756

Com o intuito de resumir as análises dos treinamentos de ozônio, a Tabela 17 apresenta uma comparação das melhores redes obtidas em cada treinamento (1, 2 e 3). Desse conjunto a melhor rede foi a obtida no treinamento 1, devido ao menor erro de teste e maiores performances de teste e validação. Os parâmetros de pesos e “*bias*” desta rede estão descritos no Apêndice D.

Tabela 17 - Comparação dos desempenhos das RNA selecionadas para o ozônio, em cada treinamento.

Treinamento	RNA	Performance			Erro		
		Trein.	Teste	Valid.	Trein.	Teste	Valid.
5 min	MLP 5-86-1	0,8103	0,9245	0,8698	0,8338	0,2356	0,4708
10 min	MLP 5-52-1	0,8400	0,8907	0,6687	0,6226	0,3486	1,8368
30 min	MLP 5-63-1	0,9014	0,9237	0,9014	0,3975	0,4520	0,3756

Os resultados adquiridos nessa análise possibilitaram chegar em conclusões similares às obtidas para o material particulado: quanto maior o tempo estipulado para a RNA prever a concentração do gás, menor será a sua capacidade de generalização e maiores serão os erros.

4.5.2.2 Dados Preditos pela RNA *versus* Dados Observados

Considerando a RNA obtida no treinamento 1 (MLP 5-86-1) desenvolveu-se o histograma representado na Figura 42 para avaliar a distribuição de frequências dos resíduos desta rede, considerando o subconjunto utilizado para o treinamento. Verifica-se que o comportamento da distribuição é assimétrico à direita, com valores entre -15,0 e 105,0 $\mu\text{g}/\text{m}^3$, mais concentrados na faixa de -15,0 e -5,0 $\mu\text{g}/\text{m}^3$. Apesar de na maioria dos casos a RNA ter previsto valores maiores em relação aos reais (com diferença de até 15,0 $\mu\text{g}/\text{m}^3$, com erros relativos mais concentrados entre 0,0 e 5,0%,) e da assimetria, nota-se que a distribuição desta rede foi melhor do que a distribuição atribuída ao material particulado (discutido na seção 4.5.1.2), visto que a quantidade de resíduos à direita apresentou menor frequência de ocorrência.

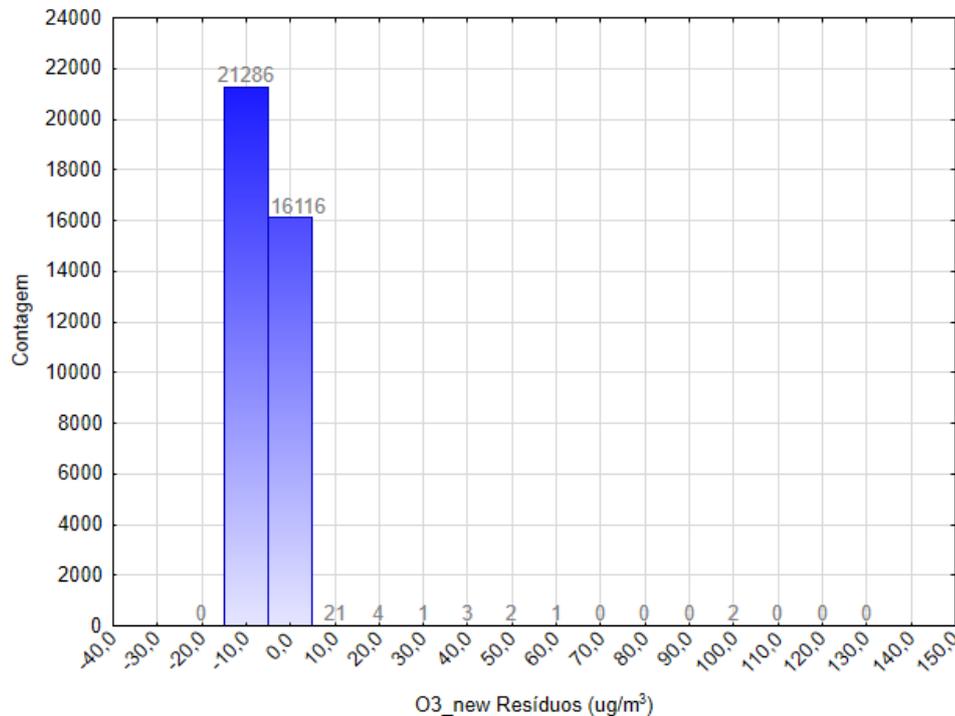


Figura 42 - Histograma de distribuição dos resíduos para o treinamento de ozônio.

A dispersão dos valores preditos pela rede em relação aos valores observados (reais) é retratada na Figura 43, na qual apresentou o coeficiente de determinação R^2 igual a 0,6566. Ainda que este valor seja baixo, o modelo foi capaz de explicar mais de 60% da variabilidade dos dados. É possível que o tempo de amostragem tenha sido insuficiente para que a rede pudesse modelar o sistema, refletindo no valor limítrofe de R^2 .

Os pontos que se distanciaram da linha de ajuste foram menos frequentes e representaram os picos de leitura do sensor. A rede então identificou os mesmos como ruídos e não os modelou como verdadeiros sinais. Esta característica pode ser apontada como uma vantagem quando o sensor detecta picos na concentração do poluente.

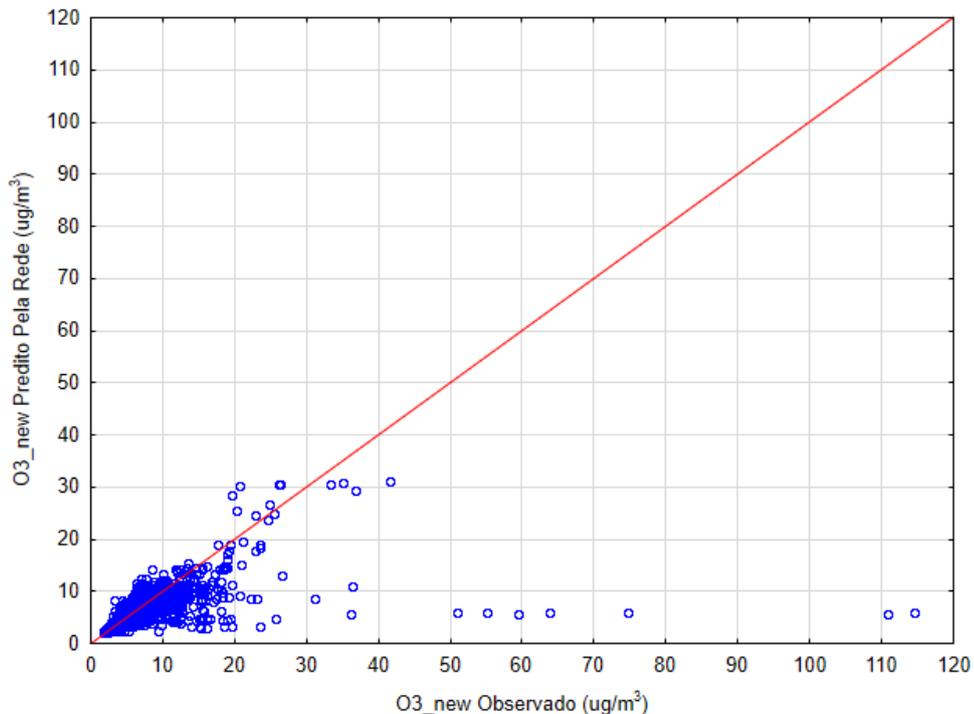


Figura 43 - Dispersão dos dados preditos pela RNA em relação aos dados observados, para o treinamento de ozônio.

Nesta linha foi desenvolvido um novo gráfico de dispersão, desconsiderando os valores mais dispersos, de forma a avaliar a disposição dos demais. A retirada considerou os pontos nos quais o eixo x (O3_new Observado) foi superior a $50 \mu\text{g}/\text{m}^3$ enquanto que os respectivos valores no eixo y (O3_new Predito Pela Rede) foram inferiores a $10 \mu\text{g}/\text{m}^3$. Retirou-se então 8 pontos, resultando no gráfico representado na Figura 44, com coeficiente de determinação R^2 igual a 0,8424.

Apesar de existirem pontos afastados da linha de 45°, a grande maioria dos dados se distribuiu próxima a linha de ajuste. Logo, quando comparado este treinamento com o treinamento 1 do material particulado, nota-se que a RNA treinada para prever a variável O3_new apresentou maior correlação dos dados do que a da variável MP_new.

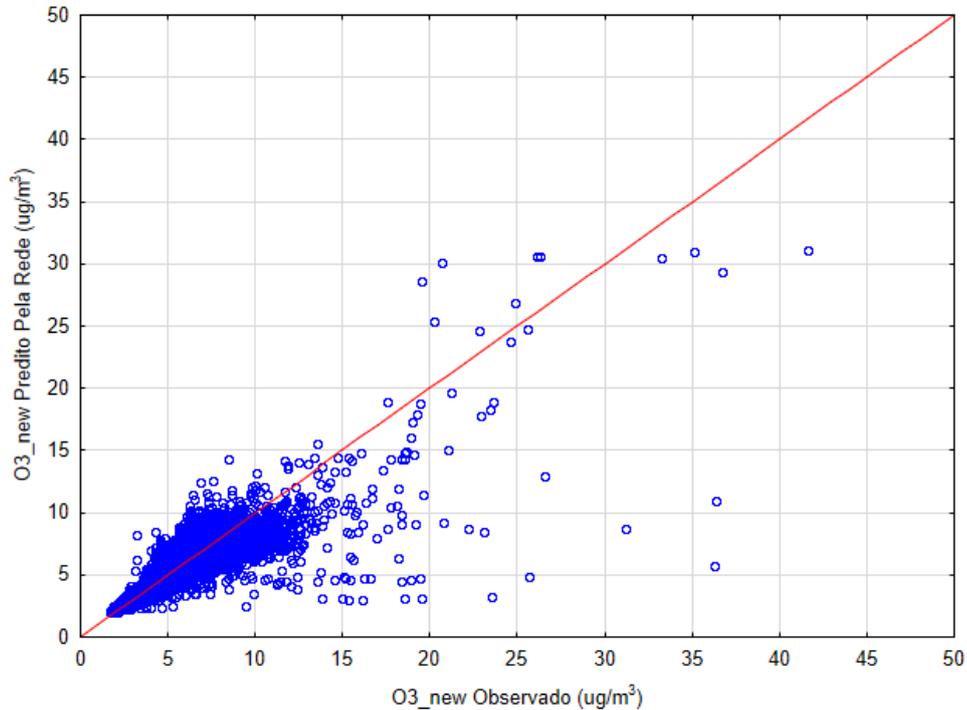


Figura 44 - Dispersão dos dados preditos pela RNA em relação aos dados observados, para o treinamento de ozônio, sem 8 pontos.

4.5.2.3 Comparação entre os Dados Experimentais e os Dados Preditos

A comparação entre os valores preditos pela RNA (do treinamento 1) com os valores observados (reais), considerando a sequência dos dados utilizada no subconjunto de treinamento, está representada na Figura 45. Nesta análise pode-se constatar a mesma comparação discutida na análise acima (dispersão dos dados): o modelo neural desenvolvido apresentou uma maior correlação dos dados para o ozônio quando comparado com a RNA treinada para o material particulado.

A alta frequência da proximidade dos dados preditos pela rede quanto aos valores observados, na sequência dos dados, retrata uma boa capacidade de representação do sistema.

Novamente, diz-se que os desvios representam picos de leituras do sensor e que a rede foi capaz de identificar essas situações, para diminuir a influência dos ruídos no modelo final.

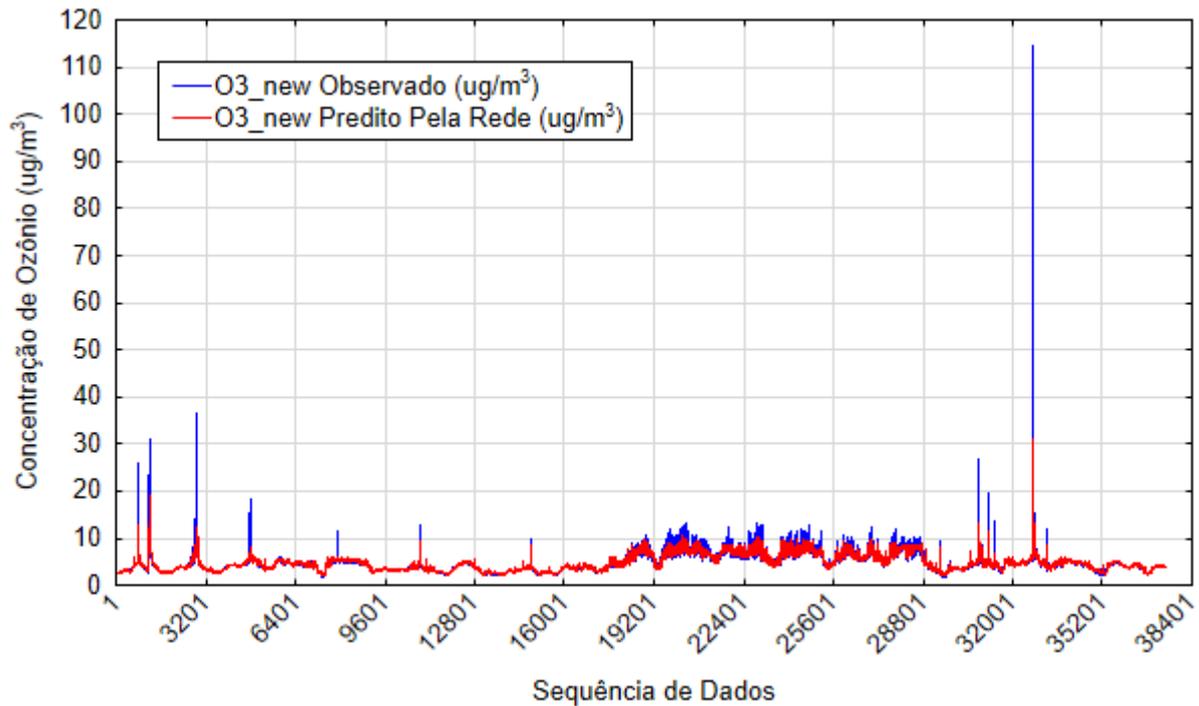


Figura 45 - Comparação da sequência de dados preditos pela RNA e os observados, em relação à variável O3_new, considerando o subconjunto de treinamento.

Tais avaliações também foram percebidas na Figura 46, que adotou os dados dos subconjuntos de teste e de validação.

Apesar de existirem oscilações e desvios em alguns pontos (normalmente associados aos picos), o ajuste da resposta da RNA em relação aos dados reais, que não foram utilizados para o treinamento da rede, pode ser considerado bom, com uma alta capacidade preditiva para a variável O3_new a partir das variáveis estabelecidas como entrada.

Sendo assim o modelo foi considerado satisfatório. De forma similar às discussões dos resultados obtidos para o material particulado, a aplicação do modelo desenvolvido para o ozônio dependerá da precisão exigida para os valores, o que indicará se há a necessidade de implementação de métodos alternativos ou auxiliares.

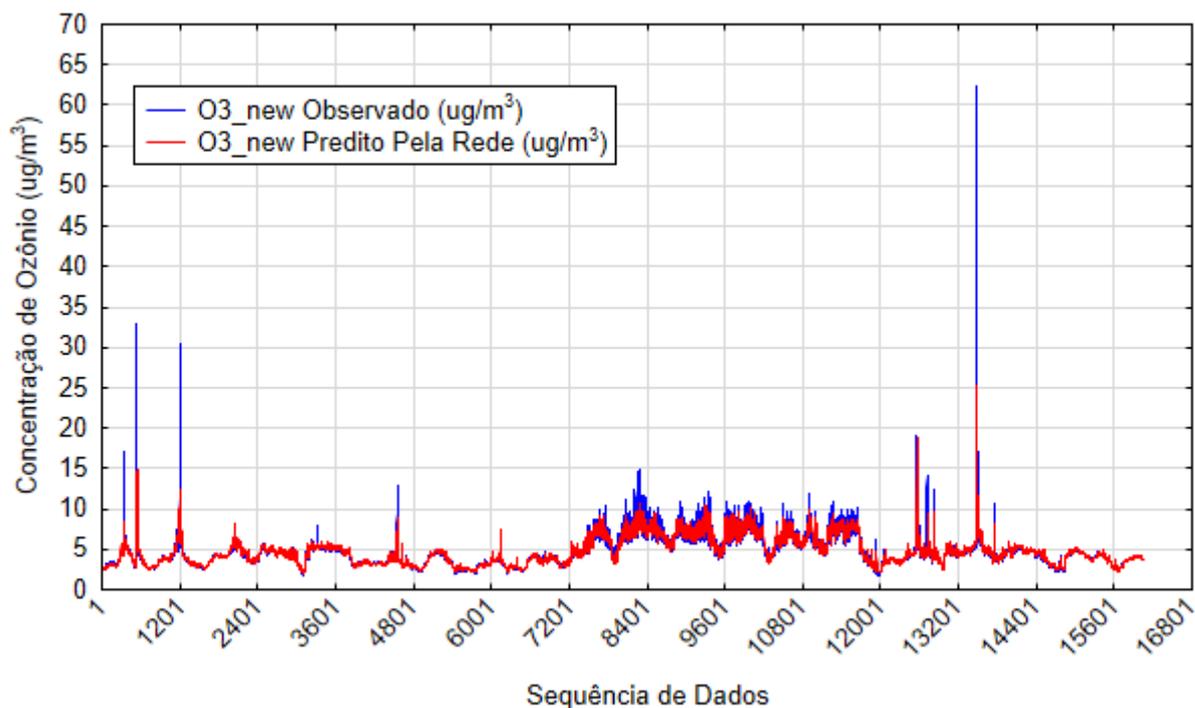


Figura 46 - Comparação da sequência de dados preditos pela RNA e os observados, em relação à variável O3_new, considerando os subconjuntos de teste e validação.

4.5.2.4 Análise dos Dados Estatísticos

Os resultados estatísticos das melhores redes (atribuídas aos treinamentos 1, 2 e 3) para a predição de ozônio estão destacados na Tabela 18. Nas três redes os valores de desvio padrão foram próximos à metade dos valores da média. Partindo da premissa adotada por Montgomery e Runger (2016), verifica-se que os dados utilizados no treinamento da rede MLP 5-86-1 apresentam desvios acima do proposto. Entretanto, constatou-se através das outras análises estatísticas que a rede neural artificial atende às características estudadas.

Tabela 18 - Parâmetros estatísticos das melhores redes obtidas nos treinamentos 1, 2 e 3, de ozônio.

Parâmetros Estatísticos	O3_new (ug/m ³)		
	MLP 5-86-1	MLP 5-52-1	MLP 5-63-1
Média dos dados	4,7788	4,7692	4,7663
Desvio padrão dos dados	2,2036	2,0569	2,0544

4.5.2.5 Análise de Sensibilidade

A Tabela 19 apresenta o resultado da última análise acerca das RNA treinadas para o ozônio, quanto à sensibilidade das variáveis de entrada, a partir dos valores calculados de *RATIO* para cada uma. Nota-se que a variável *t_bmp* apresentou maior contribuição nas três redes destacadas. Quanto à variável de menor contribuição, não houve uma simultaneidade: nos treinamentos 1 e 3 a variável *p_bmp* foi a que menos contribuiu nas redes, enquanto que no treinamento 2 este posto foi conferido à variável *O3_ugcm*.

Tabela 19 - Análise de sensibilidade das RNA treinadas para o ozônio.

Treinamento	RNA	<i>t_bmp</i>	<i>p_bmp</i>	<i>t_dht</i>	<i>h_dht</i>	<i>O3_ugcm</i>
1 (5 min)	MLP 5-86-1	315,07	1,03	1,19	1,20	2,81
2 (10 min)	MLP 5-52-1	380,45	2,99	2,30	2,35	3,24
3 (30 min)	MLP 5-63-1	3,39E+15	3,33	24,17	7,28	4,41

4.5.3 Treinamento para Monóxido de Carbono

A última análise buscou treinar redes neurais artificiais para prever as concentrações de monóxido de carbono, conforme o esquema estruturado na Figura 47.

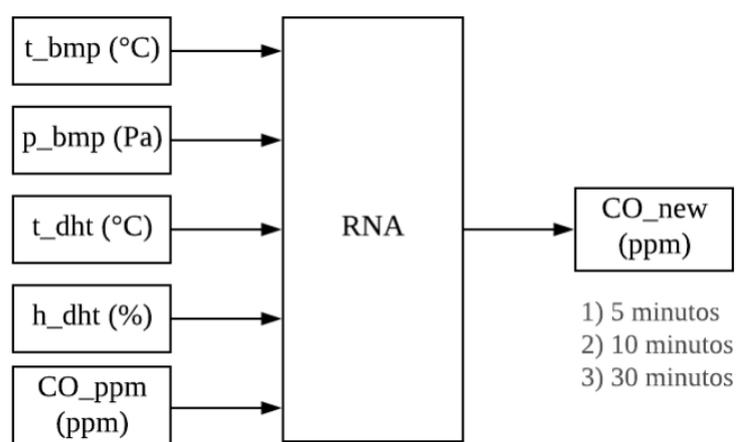


Figura 47 - Esquema de entrada e saída utilizado no treinamento da RNA para previsão de monóxido de carbono.

Também foram realizados três treinamentos, considerando a previsão quando decorridos 5, 10 e 30 minutos. Os resultados individuais são apresentados e discutidos nas próximas seções.

4.5.3.1 Análise de Desempenho

O treinamento 1 (5 minutos) reteve as dez melhores redes apresentadas na Tabela 20. A sexta rede (MLP 5-62-1) apresentou o melhor resultado, com as maiores performances (de treinamento, teste e validação) e o menor erro de teste. Vale observar que os erros dos três subconjuntos se caracterizaram na terceira casa decimal, enquanto que as performances foram próximas a unidade. Esses dois aspectos indicam um bom ajuste do modelo.

A rede MLP 5-62-1 é constituída de 5 neurônios na camada de entrada, 62 neurônios na camada oculta e 1 neurônio na camada de saída. A função logística esteve presente em ambas as camadas analisadas (oculta e de saída).

Tabela 20 - Dez melhores redes treinadas para a predição de monóxido de carbono, a cada 5 minutos.

Nº	RNA	Função		Performance			Erro		
		C.O.	C.S.	Trein.	Teste	Valid.	Trein.	Teste	Valid.
1	MLP 5-77-1	Logíst.	Seno	0,9819	0,9901	0,9768	0,0029	0,0016	0,0038
2	MLP 5-44-1	Tanh.	Seno	0,9820	0,9902	0,9769	0,0029	0,0016	0,0037
3	MLP 5-89-1	Tanh.	Tanh.	0,9822	0,9904	0,9772	0,0029	0,0015	0,0037
4	MLP 5-71-1	Tanh.	Exp.	0,9821	0,9904	0,9771	0,0029	0,0015	0,0037
5	MLP 5-71-1	Tanh.	Tanh.	0,9823	0,9904	0,9773	0,0029	0,0015	0,0037
6	MLP 5-62-1	Logíst.	Logíst.	0,9840	0,9914	0,9777	0,0026	0,0014	0,0036
7	MLP 5-58-1	Logíst.	Logíst.	0,9820	0,9896	0,9773	0,0029	0,0017	0,0037
8	MLP 5-40-1	Tanh.	Logíst.	0,9839	0,9907	0,9776	0,0026	0,0015	0,0036
9	MLP 5-78-1	Logíst.	Tanh.	0,9819	0,9902	0,9769	0,0029	0,0015	0,0038
10	MLP 5-62-1	Tanh.	Tanh.	0,9820	0,9902	0,9769	0,0029	0,0016	0,0037

Neste ponto, a arquitetura MLP foi singular na representação das redes. As funções de ativação tangente hiperbólica, logística e exponencial também foram predominantes, sendo que as duas primeiras redes consideraram também a função seno.

Com relação ao treinamento 2 (10 minutos) a Tabela 21 apresenta as dez melhores redes retidas e seus respectivos dados de performance e de erro. A melhor rede foi a sétima (MLP 5-77-1), na qual obteve menor erro de teste e maiores performances de treinamento e teste. Sua estrutura é composta por 5 neurônios na camada de entrada, 77 neurônios na camada oculta e 1 neurônio na camada de saída. As funções de ativação foram: logística, para a camada oculta, e exponencial, para a camada de saída.

Tabela 21 - Dez melhores redes treinadas para a predição de monóxido de carbono, a cada 10 minutos.

Nº	RNA	Função		Performance			Erro		
		C.O.	C.S.	Trein.	Teste	Valid.	Trein.	Teste	Valid.
1	MLP 5-34-1	Logíst.	Logíst.	0,9823	0,9795	0,9889	0,0029	0,0033	0,0018
2	MLP 5-30-1	Tanh.	Tanh.	0,9807	0,9788	0,9876	0,0032	0,0035	0,0020
3	MLP 5-46-1	Logíst.	Seno	0,9807	0,9790	0,9876	0,0031	0,0034	0,0019
4	MLP 5-16-1	Logíst.	Logíst.	0,9821	0,9797	0,9891	0,0029	0,0033	0,0017
5	MLP 5-27-1	Logíst.	Tanh.	0,9806	0,9788	0,9876	0,0032	0,0035	0,0020
6	MLP 5-34-1	Logíst.	Exp.	0,9819	0,9790	0,9885	0,0030	0,0034	0,0018
7	MLP 5-77-1	Logíst.	Exp.	0,9826	0,9801	0,9893	0,0028	0,0032	0,0017
8	MLP 5-61-1	Tanh.	Seno	0,9811	0,9792	0,9876	0,0031	0,0034	0,0020
9	MLP 5-37-1	Logíst.	Exp.	0,9824	0,9799	0,9894	0,0029	0,0033	0,0017
10	MLP 5-93-1	Tanh.	Logíst.	0,9825	0,9800	0,9896	0,0028	0,0033	0,0016

Por fim, o treinamento 3 (30 minutos) reteve as dez melhores redes dispostas na Tabela 22. A melhor RNA desse conjunto foi a quarta (MLP 5-72-1), com 5 neurônios na camada de entrada, 72 neurônios na camada oculta e 1 neurônio na camada de saída. A escolha resultou do menor erro de teste.

De forma similar ao treinamento anterior, a função de ativação logística foi adotada para a camada oculta e a função exponencial para a camada de saída.

Tabela 22 - Dez melhores redes treinadas para a predição de monóxido de carbono, a cada 30 minutos.

Nº	RNA	Função		Performance			Erro		
		C.O.	C.S.	Trein.	Teste	Valid.	Trein.	Teste	Valid.
1	MLP 5-96-1	Logíst.	Exp.	0,9770	0,9861	0,9897	0,0038	0,0022	0,0016
2	MLP 5-83-1	Logíst.	Logíst.	0,9796	0,9886	0,9914	0,0033	0,0018	0,0013
3	MLP 5-75-1	Logíst.	Logíst.	0,9787	0,9883	0,9909	0,0035	0,0019	0,0015
4	MLP 5-72-1	Logíst.	Exp.	0,9795	0,9889	0,9918	0,0034	0,0017	0,0013
5	MLP 5-99-1	Logíst.	Logíst.	0,9795	0,9887	0,9918	0,0034	0,0018	0,0013
6	MLP 5-26-1	Logíst.	Exp.	0,9787	0,9884	0,9909	0,0035	0,0019	0,0014
7	MLP 5-81-1	Logíst.	Exp.	0,9790	0,9881	0,9910	0,0035	0,0019	0,0014
8	MLP 5-65-1	Logíst.	Exp.	0,9788	0,9882	0,9910	0,0035	0,0019	0,0014
9	MLP 5-46-1	Tanh.	Logíst.	0,9775	0,9858	0,9898	0,0037	0,0023	0,0016
10	MLP 5-97-1	Logíst.	Exp.	0,9786	0,9878	0,9908	0,0035	0,0020	0,0015

Dessa forma, a Tabela 23 apresenta um resumo das melhores redes obtidas nos treinamentos 1, 2 e 3.

Comparando os dados, verifica-se que a melhor rede foi a produzida a partir do treinamento 1. Os parâmetros de pesos e “*bias*” desta rede estão descritos no Apêndice E. Diferente dos resultados comparativos das demais variáveis (material particulado e ozônio), a rede obtida no treinamento 3 apresentou melhor capacidade de generalização que a rede adquirida no treinamento 2. Este foi um exemplo no qual, apesar da performance de treinamento ter sido maior em 2 (em relação a 3), seu erro de teste foi quase o dobro que o erro em 3.

Tabela 23 - Comparação dos desempenhos das RNA selecionadas para o monóxido de carbono, em cada treinamento.

Treinamento	RNA	Performance			Erro		
		Trein.	Teste	Valid.	Trein.	Teste	Valid.
5 min	MLP 5-62-1	0,9840	0,9914	0,9777	0,0026	0,0014	0,0036
10 min	MLP 5-77-1	0,9826	0,9801	0,9893	0,0028	0,0032	0,0017
30 min	MLP 5-72-1	0,9795	0,9889	0,9918	0,0034	0,0017	0,0013

4.5.3.2 Dados Preditos pela RNA *versus* Dados Observados

A partir da RNA obtida no treinamento 1 (MLP 5-62-1), montou-se o histograma da distribuição de frequências dos resíduos, disposto na Figura 48. Essa distribuição apresentou comportamento assimétrico à direita, com valores entre -2,5 e 8,5 ppm, mais concentrados na faixa de -1,5 e -0,5 ppm. Apesar do deslocamento do gráfico, nota-se que foram muito baixas as frequências de ocorrência dos desvios acima de 1,0 ppm, assim pode-se indicar que a distribuição se aproxima da normal (simétrica), que constitui em um modelo razoável de discernimento acerca da população.

Vale destacar que na maioria dos casos a RNA previu valores com diferença de até 1,5 ppm acima dos reais, com erros relativos mais concentrados entre 0,0 e 5,0%, o que indica uma boa correlação dos dados. Este ponto se alinha à observação discutida na análise anterior, visto que as redes treinadas obtiveram erros com valores baixos para os três subconjuntos de dados. Assim, pode-se afirmar que das três variáveis analisadas para o treinamento de RNA, o CO obteve a melhor distribuição da rede, com uma quantidade consideravelmente menor de resíduos, quando comparada com a rede do material particulado, por exemplo.

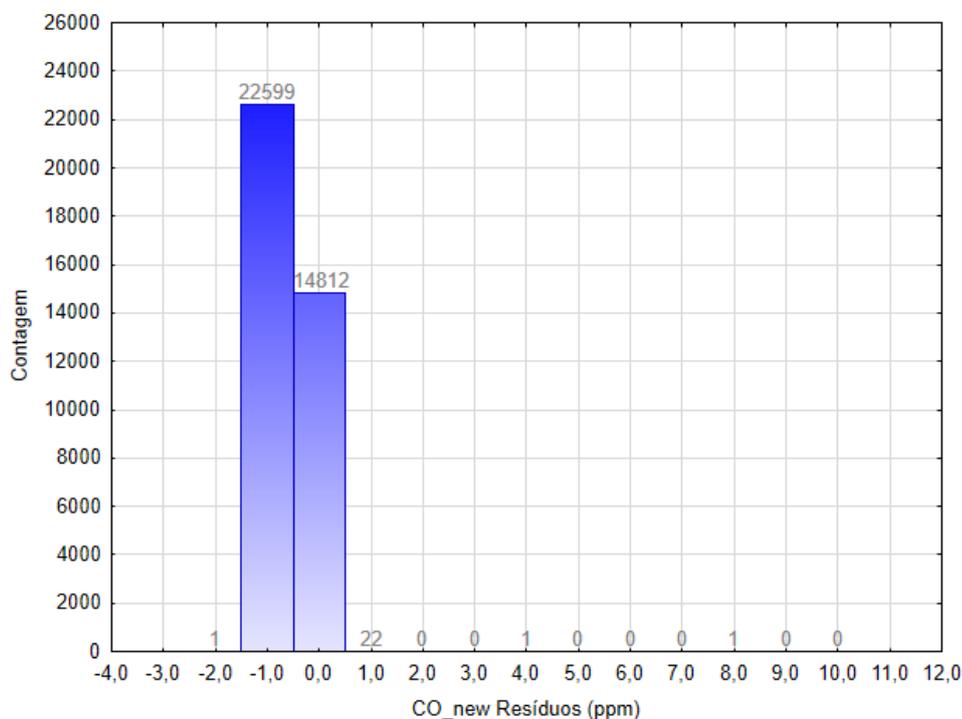


Figura 48 - Histograma de distribuição dos resíduos para o treinamento de monóxido de carbono.

A dispersão dos valores preditos pela rede quanto aos valores observados (reais) está representada na Figura 49, cujo coeficiente de determinação R^2 foi igual a 0,9682. A aproximação do coeficiente na unidade indica uma boa representação do modelo, que foi capaz de explicar mais de 96% da variabilidade dos dados.

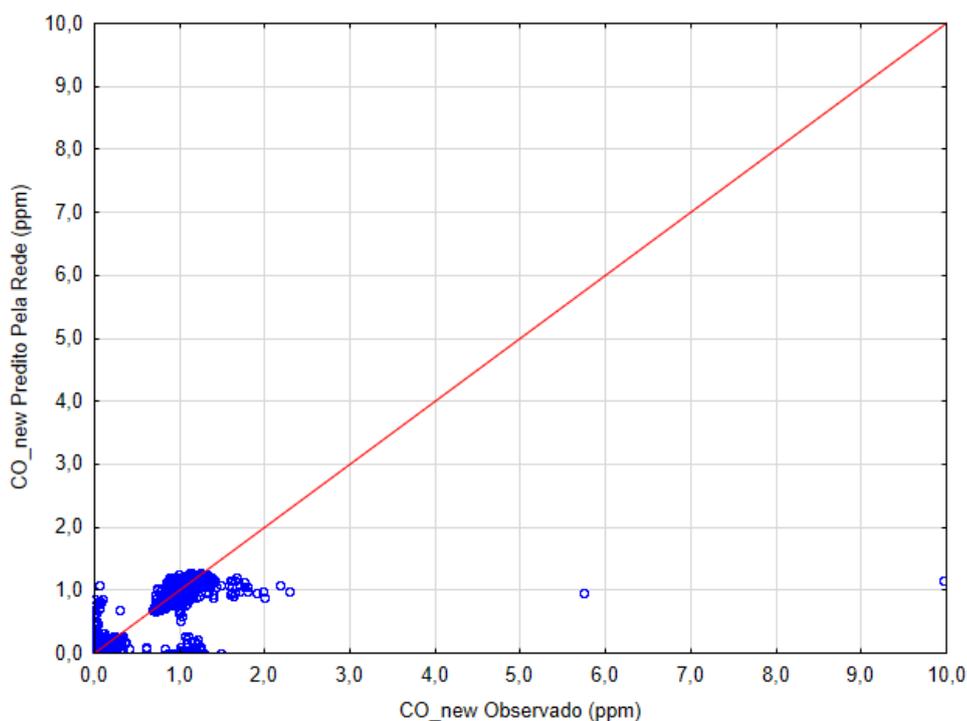


Figura 49 - Dispersão dos dados preditos pela RNA em relação aos dados observados, para o treinamento de monóxido de carbono.

Uma vez que dados estiveram concentrados em até 3 ppm de CO_{new} (observado e predito pela rede), mudou-se a escala do gráfico anterior para este conjunto de pontos, a fim de auxiliar na avaliação da dispersão dos valores. Isto foi possível pois apenas 2 dos 37.436 conjuntos de dados estiveram fora dessa faixa. A Figura 50 apresenta o novo gráfico.

Ainda que exista uma quantidade significativa de pontos afastados da linha de 45°, a grande maioria dos dados se distribuiu próxima a linha de ajuste e os demais apresentaram variações inferiores à 2,0 ppm do gás poluente, classificados pela rede como resíduos.

Nesse contexto, comparando os gráficos da Figura 49 e Figura 50 com os resultados das dispersões das redes treinadas para as demais variáveis (MP_{2,5} e O₃), pode-se verificar também a melhor distribuição da rede desenvolvida para previsão da variável CO_{new}, reflexo do alto coeficiente de determinação.

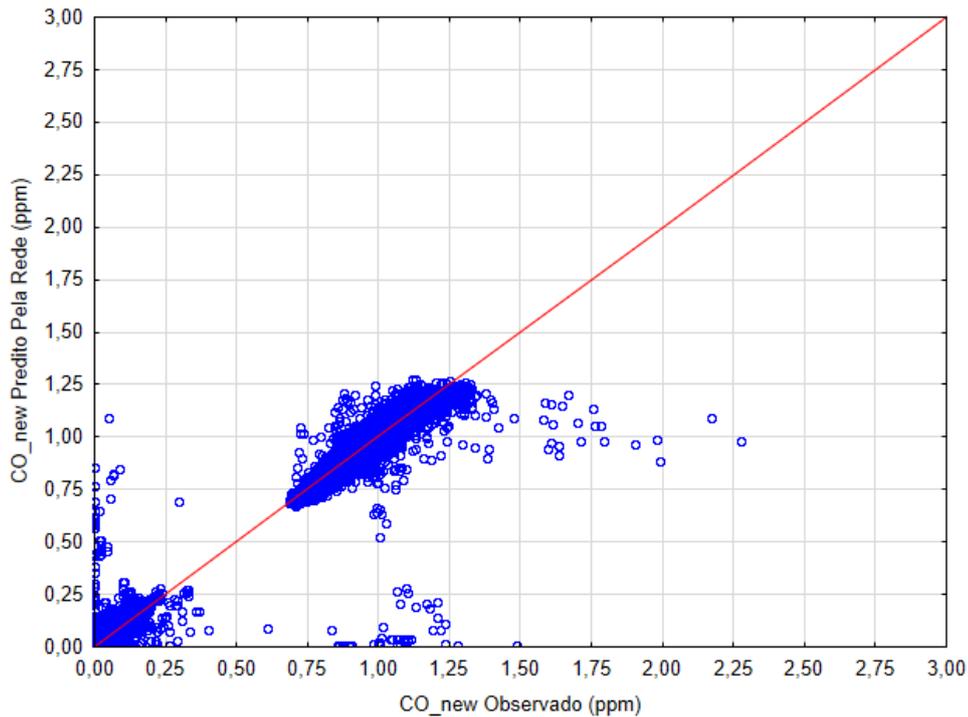


Figura 50 - Dispersão dos dados preditos pela RNA em relação aos dados observados, para o treinamento de monóxido de carbono, considerando escala mais específica.

4.5.3.3 Comparação entre os Dados Experimentais e os Dados Preditos

A Figura 51 apresenta a comparação entre os valores preditos pela RNA desenvolvida no treinamento 1 e os valores observados (reais), considerando a sequência dos dados adotada no subconjunto de treinamento. A alta frequência observada da proximidade dos dados preditos pela rede, quanto aos valores observados, indica uma boa capacidade de representação do sistema.

Neste ponto é importante destacar que rede foi capaz de identificar os valores ruidosos, representados pelos picos de leitura do sensor, diminuindo a influência destes no modelo final. Isto resultou nas diferenças significativas de predição dos picos de concentração resultantes de súbitas variações.

Visto que os desvios foram pontuais, verifica-se novamente a melhor adequação deste modelo em relação aos modelos das demais variáveis ($MP_{2,5}$ e O_3).

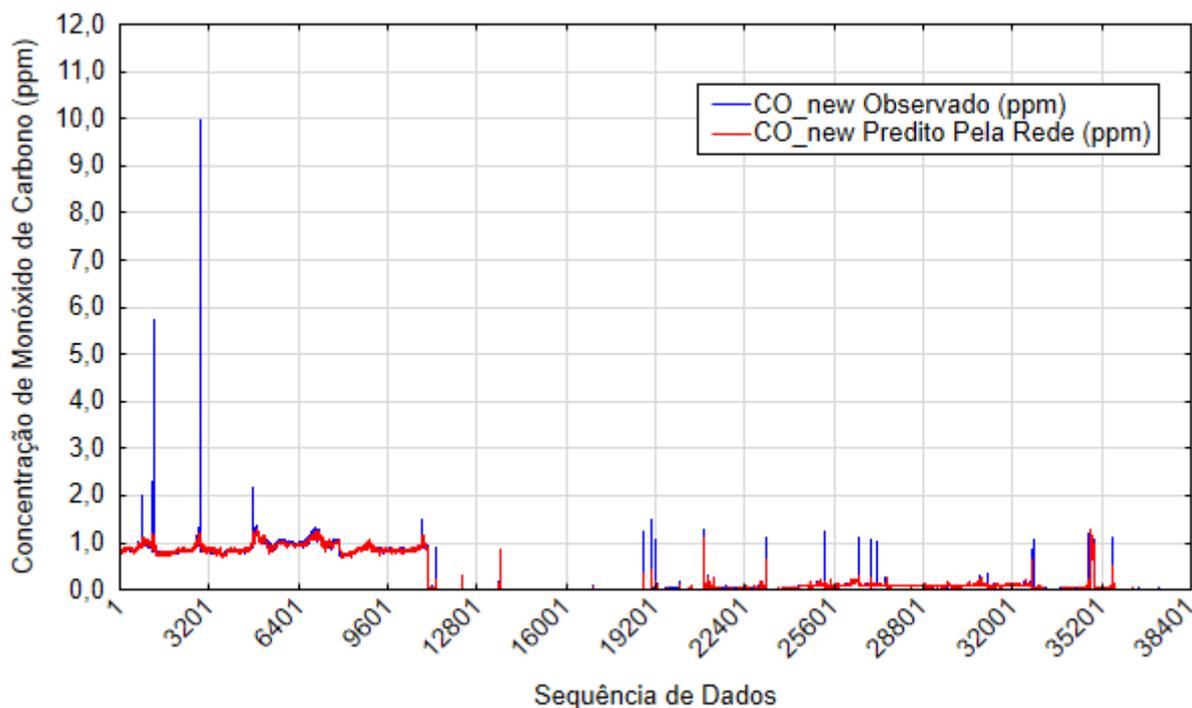


Figura 51 - Comparação da sequência de dados preditos pela RNA e os observados, em relação à variável CO_new, considerando o subconjunto de treinamento.

De forma similar, a Figura 52 apresenta essa comparação considerando os subconjuntos utilizados para teste e para validação. As conclusões acerca deste gráfico são semelhantes ao anterior: a rede apresentou uma boa capacidade preditiva de dados novos (que não foram utilizados em seu treinamento) em sua grande maioria, com pouca influência dos desvios no modelo final.

Sendo assim, diz-se que o modelo desenvolvido para o monóxido de carbono foi satisfatório e que a RNA treinada apresentou uma alta capacidade preditiva para a variável CO_new, a partir das variáveis adotadas como entrada. Similar às discussões das outras variáveis, o uso deste modelo dependerá do ambiente no qual for inserido e da precisão exigida. Este fator deve ser bem analisado, visto que além desde gás ser um poluente do ar, sua estrutura é tóxica.

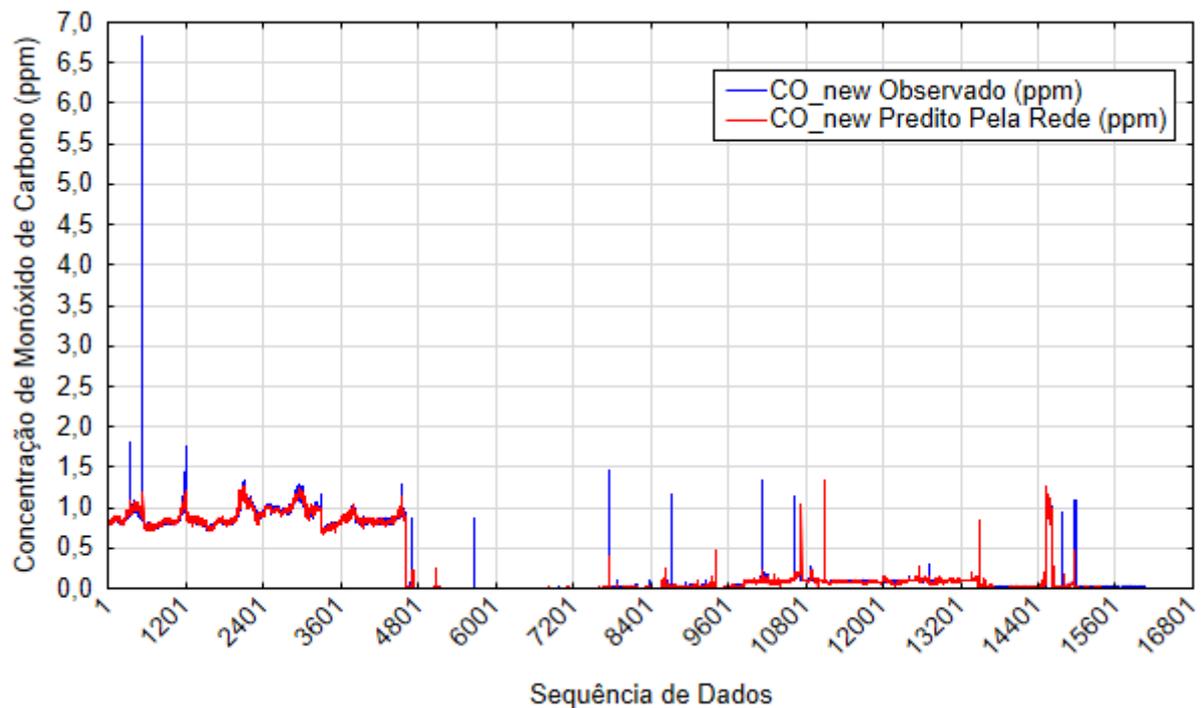


Figura 52 - Comparação da sequência de dados preditos pela RNA e os observados, em relação à variável CO_new, considerando os subconjuntos de teste e validação.

4.5.3.4 Análise dos Dados Estatísticos

A Tabela 24 contém os resultados estatísticos das melhores redes atribuídas nos treinamentos 1, 2 e 3 para a predição de monóxido de carbono. Apesar dos bons resultados vistos até o momento, os desvios das redes foram superiores ao proposto por Montgomery e Runger (2016). Este ponto corrobora a afirmativa de que o uso do modelo dependerá da aplicação.

Tabela 24 - Parâmetros estatísticos das melhores redes obtidas nos treinamentos 1, 2 e 3, de monóxido de carbono.

Parâmetros Estatísticos	CO_new (ppm)		
	MLP 5-62-1	MLP 5-77-1	MLP 5-72-1
Média dos dados	0,2968	0,2965	0,2960
Desvio padrão dos dados	0,4058	0,4058	0,4068

4.5.3.5 Análise de Sensibilidade

A última análise das redes neurais artificiais desenvolvidas para o monóxido de carbono resultou na Tabela 25, que destaca os valores calculados de *RATIO* para cada variável presente nas respectivas camadas de entrada. Desse conjunto não houve simultaneidade das variáveis de maior contribuição nos três treinamentos: em 1 e em 2 a variável CO_ppm foi a que melhor contribuiu para as redes, enquanto que no treinamento 3 foi a h_dht. Com relação à variável de menor contribuição a t_dht foi a que se destacou.

Tabela 25 - Análise de sensibilidade das RNA treinadas para o monóxido de carbono.

Treinamento	RNA	t_bmp	p_bmp	t_dht	h_dht	CO_ppm
1 (5 min)	MLP 5-62-1	1,90	6,53	1,52	5,76	87,31
2 (10 min)	MLP 5-77-1	1,95	11,01	1,53	3,34	32,04
3 (30 min)	MLP 5-72-1	43,71	13,95	8,51	11760,97	32,76

4.6 Implementação do Algoritmo Neural na Programação e Avaliação Final

Para a implementação dos modelos neurais no protótipo desenvolvido neste estudo foram consideradas as melhores redes obtidas para cada variável. Uma vez que os melhores resultados das três variáveis ocorreram nos respectivos treinamentos 1, adotou-se o tempo de 5 minutos para a predição dos poluentes e considerou-se as redes descritas na Tabela 26.

Tabela 26 - Redes neurais artificiais consideradas na implementação dos modelos de predição das concentrações dos poluentes.

Treinamento	RNA	Função de Ativação	
		C.O.	C.S.
Material particulado	MLP 5-70-1	Tangente hiperbólica	Exponencial
Ozônio	MLP 5-86-1	Exponencial	Exponencial
Monóxido de carbono	MLP 5-62-1	Logística	Logística

Para considerar os cálculos realizados pelas redes foram agrupados os pesos e “*bias*” das conexões em matrizes e vetores. As lógicas descritas a seguir foram adotadas para as três

variáveis de saída (gases poluentes a serem preditos), onde “_MP”, “_O3” e “_CO” são índices que se referem, respectivamente, ao material particulado, ozônio e monóxido de carbono. O índice “_Gas” foi utilizado para se referir aos três.

Inicialmente se considerou que os valores das variáveis presentes nas camadas de entrada e de saída devem ser normalizados para a realização dos cálculos previstos nos modelos neurais. Neste ponto vale destacar que durante o treinamento das RNA o programa Statistica realizou automaticamente a normalização dos dados de entrada, de forma que os valores mínimos e máximos de cada uma fossem associados a valores dentro da faixa de 0 a 1. Essa interpolação também foi realizada ao final, de forma contrária, para que os valores obtidos na camada de saída fossem associados à concentração do gás. Logo, a Tabela 27 apresenta as informações necessárias para o cálculo de normalização das variáveis, considerando a equação linear $y = a \cdot x + b$, adotada pelo *software* durante o treinamento das redes.

Tabela 27 - Parâmetros para normalização dos dados das variáveis.

Variável y	Variável x	Coefficiente angular (a)	Coefficiente linear (b)
t_{bmp_norm}	t_{bmp}	$6,3694 \times 10^{-2}$	- 1,4522
p_{bmp_norm}	p_{bmp}	$8,3195 \times 10^{-4}$	- 83,3195
t_{dht_norm}	t_{dht}	$5,8824 \times 10^{-2}$	- 1,1765
h_{dht_norm}	h_{dht}	$1,6393 \times 10^{-2}$	- $5,5738 \times 10^{-1}$
MP_{ugcm_norm}	MP_{ugcm}	$5,0280 \times 10^{-2}$	- $6,5363 \times 10^{-5}$
$O3_{ugcm_norm}$	$O3_{ugcm}$	$8,8546 \times 10^{-3}$	- $1,4769 \times 10^{-2}$
CO_{ppm_norm}	CO_{ppm}	$1,0030 \times 10^{-1}$	0,0000
MP_{new_norm}	MP_{new}	$4,4891 \times 10^{-2}$	- $5,8358 \times 10^{-5}$
$O3_{new_norm}$	$O3_{new}$	$8,8550 \times 10^{-3}$	- $1,4821 \times 10^{-2}$
CO_{new_norm}	CO_{new}	$1,0030 \times 10^{-1}$	0,0000

Assim definiu-se a matriz A como as variáveis normalizadas da camada de entrada da rede. As Equações (7), (8) e (9) apresentam as matrizes que foram determinadas para o material particulado, ozônio e monóxido de carbono, respectivamente.

$$A_{MP} = [t_{bmp_norm} \quad p_{bmp_norm} \quad t_{dht_norm} \quad h_{dht_norm} \quad MP_{ugcm_norm}] \quad (7)$$

$$A_{O3} = [t_{bmp_norm} \quad p_{bmp_norm} \quad t_{dht_norm} \quad h_{dht_norm} \quad O3_{ugcm_norm}] \quad (8)$$

$$A_{CO} = [t_{bmp_norm} \quad p_{bmp_norm} \quad t_{dht_norm} \quad h_{dht_norm} \quad CO_{ppm_norm}] \quad (9)$$

Em seguida ordenou-se os pesos das conexões entre as camadas de entrada e oculta através da matriz B_Gas . O número de linhas desta matriz foi igual a 5 (referentes ao número de variáveis na camada de entrada) e o número de colunas foi igual a “ O_Gas ”, que indica a ordem necessária para cada gás (igual ao número de neurônios na camada oculta). Dessa forma multiplicou-se as matrizes A_Gas e B_Gas , resultando na nova matriz A_B_Gas , com 1 linha e “ O_Gas ” colunas (podendo ser rotulada como um vetor). Deve-se atentar que os valores deste vetor correspondem a equações matemáticas, que são realizadas ao longo da programação, quando as leituras das variáveis de entrada da rede são atualizadas.

Os demais vetores considerados para o cálculo da RNA foram: $Bias_1_Gas$, com os valores dos “*bias*” de cada neurônio na camada oculta, e C_Gas , com os pesos das conexões entre as camadas oculta e de saída. Em ambos, o número de colunas foi igual a “ O_Gas ”.

Visto que as camadas de saída das três RNA apresentavam apenas um neurônio (referente ao gás estudado), definiu-se $Bias_2_Gas$ como o valor de “*bias*” desse neurônio.

Essas definições foram então inseridas no código de programação desenvolvido para o monitoramento da qualidade do ar. Para o cálculo das previsões, desenvolveu-se a função “*getPredictionLoop()*” e a inseriu nas etapas da função “*loop()*”.

A função normaliza os valores das variáveis presentes na camada de entrada da rede e calcula os valores do vetor A_B_Gas . Na sequência calcula os novos dados dos gases através das funções *CalculatePrediction()* e *PredictionMath()*, que descrevem o *loop* necessário, conforme a variável selecionada. A estrutura do cálculo considerou a modelagem do neurônio individual, apresentada no Capítulo 2 (seção 2.4.2), através da realização das seguintes etapas:

1. Operação de soma dos vetores A_B_Gas e $Bias_1_Gas$ e aplicação da função de transferência da camada oculta, resultando no novo vetor D ;
2. Operação de multiplicação dos dados dos vetores D e C_Gas e soma de todos os componentes, resultando no novo vetor E (que possui 1 coluna);
3. Soma dos valores E e $Bias_2_Gas$ e aplicação da função de transferência da camada de saída, resultando na variável F (MP_new_norm , $O3_new_norm$ e CO_new_norm , respectivamente);
4. Normalização da variável presente na camada de saída, retornando o valor da concentração do poluente (MP_new , $O3_new$ e CO_new , respectivamente).

O código fonte final deste trabalho, com a programação do monitoramento da qualidade do ar e previsão das concentrações dos poluentes, está descrito no Apêndice F.

5 CONSIDERAÇÕES FINAIS

A qualidade do ar influencia no bem-estar da população e no meio ambiente. Caso os índices de poluentes atmosféricos estejam acima de valores pré-estabelecidos poderão acarretar em problemas de diferentes proporções. O seu monitoramento é um fator de grande importância que proporciona a identificação das fontes emissoras e na rápida tomada de decisão quanto ao controle de situações emergentes, caso as leituras sejam obtidas em tempo real.

No Brasil, regulamentos descrevem os principais métodos que devem ser utilizados na medição das concentrações dos poluentes atmosféricos presentes no ar. No Estado do Rio de Janeiro, por exemplo, são utilizados métodos equivalentes, conforme dados na literatura. Entretanto, esses métodos possuem limitações, como custo elevado.

A fim de propor um método alternativo para o monitoramento da qualidade do ar, através de uma plataforma de baixo custo e fácil acesso, desenvolveu-se um sistema protótipo a partir de uma unidade microcontrolada associada à metodologia de redes neurais artificiais, para o monitoramento a partir das concentrações de três poluentes atmosféricos (material particulado 2,5 μm , ozônio e monóxido de carbono), em tempo real, e predição das concentrações dos gases. A estrutura considerou sensores, módulos e componentes sensíveis às variáveis estudadas, conectadas a uma placa de Arduino Mega 2560.

Para a avaliação das respostas dos sensores de gás, foi realizado um teste de exposição dos elementos à fumaça do cigarro, no qual pôde-se constatar que os sensores apresentaram sensibilidade aos gases presentes neste cenário. No momento do contato, os sensores PPD42, MQ-131 e MICS-5524 apresentaram leituras com elevações significativas das concentrações de material particulado, ozônio e monóxido de carbono, respectivamente. As diminuições das leituras ocorreram de forma gradativa, sendo que a concentração de ozônio foi a que precisou de um tempo maior para retornar à condição inicial. O comportamento do índice de qualidade do ar foi similar aos demais gases, apresentando maior influência pelo ozônio.

Em seguida, realizou-se a coleta dos dados experimentais no Polo de Inovação do IFF, obtendo as leituras dos gases poluentes e das condições ambientais de meteorologia (temperatura, umidade e pressão). Foi possível verificar os seguintes padrões do local (no período analisado):

- A temperatura diária apresenta um comportamento característico, no qual os valores são baixos durante a madrugada, aumentam no período da manhã (até às 12h) e diminuem durante a tarde e noite. Verificou-se no período em análise que a faixa desta variável foi de 20,0 a 40,0°C, considerando as medidas dos dois

sensores utilizados (BMP085 e DHT-11), cujos parâmetros estatísticos foram adequados em relação aos dados históricos disponíveis em plataforma de livre acesso;

- A umidade relativa do ar apresentou comportamento inverso ao da temperatura: os valores aumentaram durante a madrugada, diminuíram no período da manhã (até às 12h) e aumentaram ao longo da tarde e da noite. Durante o tempo da coleta, verificou-se que a faixa desta variável foi de 30,0 a 95,0%, com valores mais concentrados no range de 90,0 a 95,0%;
- As leituras de pressão do ambiente, obtidas pelo sensor BMP085, não foram constantes, apresentando altas e baixas nos valores ao longo do período de coleta. Entretanto, nota-se que o padrão diário desta variável é representado por um aumento dos valores até a metade do dia e diminuição durante os períodos da tarde e da noite. Suas leituras se concentraram na faixa de 100.750,0 e 100.950,0 Pa;
- Com relação aos poluentes atmosféricos, verificou-se uma maior dispersão dos dados para o material particulado, o que pode estar associado a forma na qual o sensor PPD42 opera, o que refletiu em medições não contínuas. As demais variáveis apresentaram valores com alterações gradativas, com picos eventuais;
- No geral, as concentrações diárias dos poluentes atmosféricos apresentaram valores mais elevados por volta da metade do dia (12h), o que pode ser influência de um fluxo mais elevado no tráfego local e/ ou das atividades desenvolvidas pela cerâmica localizada próxima à instalação em análise. A proximidade do polo com o Rio Paraíba do Sul também pode ter contribuído com os aumentos e diminuições dos valores em curto espaço de tempo, devido à influência dos ventos (direção e velocidade). Neste ponto vale destacar que o ozônio é um poluente secundário e que a sua formação ocorre através de reações químicas entre óxidos de nitrogênio e luz solar. Visto que o período de 12h apresenta alto índice de radiação solar, este fator também pode ter contribuído no aumento das concentrações desse poluente;
- Como consequência do item anterior, os índices de qualidade do ar (IQA_r) diários apresentaram os maiores valores na metade do dia, resultantes do aumento das concentrações dos gases poluentes. A distribuição dos dados se

concentrou em maior frequência na classe “Boa”, também sendo verificadas as classes “Regular” e “Inadequada”.

A partir dos dados coletados, avaliou-se a implementação da metodologia de redes neurais artificiais na representação da qualidade do ar no local estudado. O treinamento das redes considerou como entrada as variáveis ambientais e da concentração inicial do poluente, enquanto que a saída representou a contração final deste gás, após decorridos um tempo estipulado. Avaliou-se então a capacidade preditiva das RNA considerando os tempos de 5, 10 e 30 minutos, para os três gases analisados. Com base nos parâmetros e dados estatísticos de cada rede treinada, verificou-se os seguintes pontos:

- Os melhores desempenhos foram identificados nas redes treinadas para predição em 5 minutos;
- O modelo neural obtido para a predição do material particulado apresentou baixa adequação aos valores lidos pelo sensor PPD42, visto que as leituras não foram contínuas e continham picos consideráveis;
- Com relação ao modelo obtido para a predição do ozônio, verificou-se uma adequação melhor, capaz de explicar mais de 60,0% da variabilidade dos dados;
- O modelo desenvolvido para a predição de monóxido de carbono apresentou a melhor capacidade preditiva, capaz de explicar mais de 96,0% da variabilidade dos dados;
- As redes neurais artificiais desenvolvidas para as três variáveis foram capazes de identificar os picos de leitura dos sensores e classificar esses valores como ruídos. Assim, durante os treinamentos as redes optaram por não modelar os picos como verdadeiros sinais, diminuindo a influência destes nos modelos finais. Este fator é classificado como uma vantagem do modelo neural.

Dessa forma, inseriu-se o algoritmo neural das melhores redes obtidas na programação desenvolvida para o monitoramento da qualidade do ar, resultando em um sistema capaz de obter os dados reais das concentrações dos poluentes atmosféricos e prever os valores. Os resultados obtidos pela metodologia de inteligência artificial foram considerados como adequados à amostra de dados da unidade microcontrolada, sendo que a escolha quanto ao uso destes modelos deve considerar o foco da aplicação.

5.1 Perspectivas e Sugestões para Trabalhos Futuros

Inicialmente sugere-se calibrar os sensores de gás (PPD42, MQ-131 e MICS-5524) a partir da exposição do protótipo a concentrações conhecidas dos gases, ou, a partir da correlação com sensores e equipamentos já calibrados. Neste último, o protótipo e o equipamento calibrado deverão estar situados no mesmo ambiente, para que a comparação seja eficaz.

Em concordância, propõe-se obter novos conjuntos de dados experimentais, em um espaço de tempo maior do que o adotado neste estudo, a fim de obter redes neurais artificiais treinadas para os sensores calibrados, e, ou, para validar as redes já desenvolvidas.

Os novos treinamentos podem ser realizados em diferentes *softwares*, como o MATLAB e o SCILAB, que fornecem pacotes para a modelagem de sistemas não lineares complexos, de forma a comparar os resultados de cada um.

Sugere-se, também, replicar o sistema protótipo para instalação em diferentes polos da Instituição, com o intuito de desenvolver uma rede de sensores, que visa o estudo de Internet das Coisas (IoT, do inglês *Internet of Things*). Os dados poderão estar disponibilizados em banco de dados, na plataforma *Web*.

Por fim, propõe-se integrar o sistema a uma plataforma de gestão humanitária, para atuar como uma alternativa de monitoramento de dados ambientais, em prol da defesa civil.

REFERÊNCIAS BIBLIOGRÁFICAS

- ALVES, V. B. **A influência da densidade do filtro de cigarros nos teores da fumaça**. Porto Alegre: Universidade Federal do Rio Grande do Sul, 2016.
- AOSONG. **Temperature and humidity module DHT11 product manual**, 24 set. 2013. Disponível em: <<https://akizukidenshi.com/download/ds/aosong/DHT11.pdf>>. Acesso em: 30 nov. 2017.
- ARDUINO E CIA. **Real time clock (RTC) DS1307**, 20 abr. 2013. Disponível em: <<http://www.arduinoecia.com.br/2013/04/real-time-clock-rtc-ds1307.html>>. Acesso em: 28 nov. 2017.
- ARLING, J.; O'CONNOR, K.; MERCIECA, M. **Air quality sensor network for Philadelphia - data validation**, 5 jun. 2010. Disponível em: <<http://www.fijnstofmeter.com/documentatie/Data-Validation.pdf>>. Acesso em: 20 out. 2017.
- BAUGHMAN, D. R.; LIU, Y. A. **Neural Networks in Bioprocessing and Chemical Engineering**. San Diego: Academic Press, 1995.
- BENITEZ, J. M.; CASTRO, J. L.; REQUENA, I. Are artificial neural networks black boxes? **IEEE Transactions on Neural Networks**, v. 8, n. 5, p. 1156–1164, set. 1997.
- BOARETO MENDES, Á. J. **Modelagem híbrido-neuronal da produção de lipase por Candida rugosa**. Tese de Mestrado—Rio de Janeiro: Universidade Federal do Rio de Janeiro, 2005.
- BOSCH SENSORTEC. **BMP085 digital, barometric pressure sensor**, 29 mar. 2008. Disponível em: <https://www.sparkfun.com/datasheets/Components/General/BMP085_Flyer_Rev.0.2_March2008.pdf>. Acesso em: 29 nov. 2017.
- BOSCH SENSORTEC. **BMP085 digital pressure sensor data sheet**, 15 out. 2009. Disponível em: <<https://www.sparkfun.com/datasheets/Components/General/BST-BMP085-DS000-05.pdf>>. Acesso em: 29 nov. 2017.
- BRASIL. Lei Nº 6.938, de 31 de agosto de 1981. Dispõe sobre a Política Nacional do Meio Ambiente, seus fins e mecanismos de formulação e aplicação, e dá outras providências. Diário Oficial da República Federativa do Brasil, Brasília, DF. 9 fev. 1981.
- BRASIL. Ministério do Meio Ambiente. **Resolução CONAMA Nº 005/1989**. 15 jun. 1989, p. 14713–14714.
- BRASIL. Ministério do Meio Ambiente. **Resolução CONAMA Nº 003/1990**. Dispõe sobre padrões de qualidade do ar, previstos no PRONAR. 28 jun. 1990, Sec. 1, p. 15937–15939.
- BRASIL. Ministério do Meio Ambiente. **Poluentes atmosféricos**. 2017.
- BROOK, R. D. et al. Air pollution and cardiovascular disease: a statement for healthcare professionals from the expert panel on population and prevention science of the american heart association. **Circulation**, v. 109, n. 21, p. 2655–2671, 1 jun. 2004.

CANADIAN CENTRE FOR OCCUPATIONAL HEALTH & SAFETY. **Converting occupational exposure limits from mg/m³ to ppmCCOHS**, 1 nov. 2016. Disponível em: <<https://www.ccohs.ca/oshanswers/chemicals/convert.html>>. Acesso em: 12 nov. 2017.

CANÇADO, J. E. D. et al. Repercussões clínicas da exposição à poluição atmosférica. 2006.

COSTA, P. DOS S. **Concentração do ozônio em dois sítios experimentais da região metropolitana de Manaus: Medidas em superfície e estimativas remotas**. Manaus: Instituto Nacional de Pesquisas da Amazônia; Universidade do Estado do Amazonas, nov. 2015.

CURTIS, L. et al. Adverse health effects of outdoor air pollutants. **Environment International**, v. 32, n. 6, p. 815–830, ago. 2006.

DA SILVA, W. L.; CHOQUE, N. M. S. Desenvolvimento de sistemas de aquisição de dados usando a placa Arduino Uno e o software Ni-Labview. **Desafios - Revista Interdisciplinar da Universidade Federal do Tocantins**, v. 3, n. especial, p. 118–125, 2016.

DALLAS SEMICONDUCTOR. **DS1307 - 64 x 8 serial real-time clock**, 1 out. 2001. Disponível em: <<https://www.sparkfun.com/datasheets/Components/DS1307.pdf>>. Acesso em: 16 dez. 2017

DE SOUZA JR., M. B. **Redes neuronais multicamadas aplicadas a modelagem e controle de processos químicos**. Tese de Doutorado—Rio de Janeiro: Universidade Federal do Rio de Janeiro, 1993.

DI JUSTO, P.; GERTZ, E. **Atmospheric monitoring with arduino: keeping an eye on the environment above you**. First edition ed. Farnham: O'Reilly, 2013.

DICKEY, J. H. Selected topics related to occupational exposures Part VII. Air pollution: overview of sources and health effects. **Disease-a-Month**, v. 46, n. 9, p. 566–589, set. 2000.

DOS SANTOS, A. S. R.; MARTINS, R. DE F. Poluição: considerações ambientais e jurídicas. **Revista Direito e Humanidades**, v. 5, p. 97–102, 2002.

D-ROBOTICS UK. **DHT11 humidity & temperature sensor**, 30 jul. 2010. Disponível em: <<http://www.micropik.com/PDF/dht11.pdf>>. Acesso em: 30 nov. 2017.

DUTRA, E. G.; FIORAVANTE, E. F.; FERREIRA, F. D. **Emissão veicular e o ozônio troposférico na região metropolitana de Belo Horizonte, Minas Gerais, Brasil**. In: 9º CONGRESO IBEROAMERICANO DE INGENIERÍA MECÁNICA - CIBIM. Las Palmas de Gran Canaria: 2009. Disponível em: <http://www.feam.br/images/stories/rafael/cibim_9_las_palmas-emissao_veiculares_-_oznio_29-aspectos_medio_ambientales.pdf>. Acesso em: 20 mar. 2018.

E2V. **MiCS application note 4 - using MiCS sensors for alcohol detection**, jun. 2009. Disponível em: <<http://pub.ucpros.com/download/AN4-Using-MiCS-Sensors-for-Alcohol-Detection.pdf?osCsid=umgpoh8v8hnjaopvlervgne0q1>>. Acesso em: 28 nov. 2017.

ENVIRONMENTAL PROTECTION AGENCY (EPA). **Federal Register - National ambient air quality standards for particulate matter**, v. 78, n. 10, 15 jan. 2013.

FUNDAÇÃO ESTADUAL DE ENGENHARIA DO MEIO AMBIENTE. **Relatório anual de qualidade do ar - 2007**. Rio de Janeiro: Divisão de Qualidade do Ar - Departamento de Planejamento Ambiental, 2007. Disponível em: <http://www.inea.rj.gov.br/cs/groups/public/@inter_dimfis_gear/documents/document/zwff/mde3/~edisp/inea_017063.pdf>. Acesso em: 21 abr. 2017.

GODISH, T. **Air quality**. 4. ed. Boca Raton: Lewis Publishers, 2004.

GOOGLE. **Google Earth-Maps**. Disponível em: <<https://www.google.com.br/maps/place/Polo+de+Inova%C3%A7%C3%A3o+Campos+Dos+Goytacazes/@-21.7401171,-41.2075539,4672m/data=!3m1!1e3!4m5!3m4!1s0x0:0x57a3e903a92ce0b7!8m2!3d-21.7401171!4d-41.2075539>>. Acesso em: 3 abr. 2018.

GUALTIERI, G. et al. An integrated low-cost road traffic and air pollution monitoring platform to assess vehicles' air quality impact in urban areas. **Transportation Research Procedia**, v. 27, p. 609–616, 2017.

GUNAWAN, T. S. et al. Design and implementation of portable outdoor air quality measurement system using Arduino. **International Journal of Electrical and Computer Engineering (IJECE)**, n. 1, p. 280–290, fev. 2018.

HANWEI ELECTRONICS CO., LTD. **Technical data MQ-131 gas sensor**, 30 nov. 2009. Disponível em: <<http://www.sensorica.ru/pdf/MQ-131.pdf>>. Acesso em: 28 nov. 2017.

HAYKIN, S. **Redes neurais: princípios e prática**. 2. ed. Porto Alegre: Bookman, 2001.

HEIMBINDER, M. **Make your own aircasting particle monitor** Taking Space, 5 out. 2013. Disponível em: <<http://www.takingspace.org/make-your-own-aircasting-particle-monitor/>>. Acesso em: 25 fev. 2018.

INSTITUTO ESTADUAL DO AMBIENTE; DIRETORIA DE INFORMAÇÃO E MONITORAMENTO AMBIENTAL. **Relatório anual da qualidade do ar do Estado do Rio de Janeiro - 2009**. Rio de Janeiro: Gerência de Qualidade do Ar, 2009. Disponível em: <http://www.inea.rj.gov.br/cs/groups/public/@inter_dimfis_gear/documents/document/zwff/mde3/~edisp/inea_017061.pdf>. Acesso em: 11 abr. 2017.

INSTITUTO ESTADUAL DO AMBIENTE; GERÊNCIA DE QUALIDADE DO AR. **Relatório da qualidade do ar do Estado do Rio de Janeiro - ano base 2015**. Rio de Janeiro: Gerência de Qualidade do Ar, 2016. Disponível em: <http://www.inea.rj.gov.br/cs/groups/public/@inter_dimfis_gear/documents/document/zwew/mtmx/~edisp/inea0131852.pdf>. Acesso em: 21 abr. 2017.

INTERNATIONAL FREQUENCY SENSOR ASSOCIATION (IFSA). **MQ131 semiconductor sensor for ozone**, 6 jan. 2009. Disponível em: <<http://www.sensorsportal.com/DOWNLOADS/MQ131.pdf>>. Acesso em: 28 nov. 2017.

JAVED, A. **Criando projetos com Arduino para a internet das coisas**. 1. ed. São Paulo: Novatec, 2017.

LACAVAL, C. I. V. Avaliação da qualidade do ar. In: **Emissões atmosféricas**. Brasília: SENAI-Depto Nacional, 2002. v. 1p. 131–180.

LISBOA, H. DE M.; PAGE, T.; GUY, C. Gestão de odores: fundamentos do nariz eletrônico. **Engenharia Sanitária e Ambiental**, v. 14, n. 1, p. 9–18, jan. 2009.

MARAJ, A. et al. **Sensing platform development for air quality measurements and analysis**. Institute of Electrical and Electronics Engineers Inc. (IEEE), set. 2017. Disponível em: <<http://ieeexplore.ieee.org/document/8088233/>>. Acesso em: 25 mar. 2018.

MONTGOMERY, D. C.; RUNGER, G. C. **Estatística aplicada e probabilidade para engenheiros**. Tradução Verônica Calado. 6. ed. Rio de Janeiro: LTC, 2016.

MUKHERJEE, A. et al. Assessing the utility of low-cost particulate matter sensors over a 12-week period in the cuyama valley of California. **Sensors**, v. 17, n. 8, 5 ago. 2017.

PINTO, K. G. M.; BARCELLOS, R. G. S. Desenvolvimento de sistemas microcontrolados embarcados em plataforma Arduino para equipamentos de monitoramento para estudos hidrogeoquímicos. **Bolsista de Valor: Revista de Divulgação do Projeto Universidade Petrobras/IFFluminense**, v. 4, p. 13–17, 2015.

POHL, H.; LICCIONE, J.; IANNUCCI, A. **Toxicological profile for sulfur dioxide**. U.S. Department of health and human services, Public Health Service, Agency for Toxic Substances and Disease Registry, dez. 1998. Disponível em: <<https://www.atsdr.cdc.gov/toxprofiles/tp116.pdf>>. Acesso em: 20 mar. 2017.

RAHMAN, P. A.; PANCHENKO, A. A.; SAFAROV, A. M. Using neural networks for prediction of air pollution index in industrial city. **IOP Conference Series: Earth and Environmental Science**, v. 87, n. 4, out. 2017.

SANDBOX ELECTRONICS. **MQ-2 Smoke/LPG/CO Gas Sensor Module**, 2014. Disponível em: <<http://sandboxelectronics.com/?p=165>>. Acesso em: 29 mar. 2017.

SEED STUDIO. **Grove - dust sensor user manual**, 23 set. 2015. Disponível em: <http://www.mouser.com/ds/2/744/Seeed_101020012-838657.pdf>. Acesso em: 21 out. 2017.

SGX SENSORTECH. **The MiCS-5524 is a compact MOS sensor**, 29 mar. 2016. Disponível em: <<https://cdn-shop.adafruit.com/product-files/3199/MiCS-5524.pdf>>. Acesso em: 28 nov. 2017.

SHINYEI. **Specification sheet of PPD42NS**, mar. 2010. Disponível em: <<http://wiki.timelab.org/images/f/f9/PPD42NS.pdf>>. Acesso em: 20 out. 2017.

SHINYEI TECHNOLOGY. **Product specifications PPD42NJ**, 19 mar. 2013. Disponível em: <https://publiclab.org/system/images/photos/000/010/161/original/Spec_PPD42NJ_Eng_SPP13001V00_20130319.pdf>. Acesso em: 20 out. 2017.

SHINYEI TECHNOLOGY. **PPD42NJ particle sensor unit**, 2018. Disponível em: <http://www.shinyei.co.jp/stc/eng/optical/main_ppd42.html>. Acesso em: 7 jan. 2018.

SOR, J. L. et al. (EDS.). **Relatório piloto com aplicação da metodologia IPPS ao Estado do Rio de Janeiro: uma estimativa do potencial de poluição industrial do ar**. Rio de Janeiro: Ministério do Planejamento, Orçamento e Gestão, Instituto Brasileiro de Geografia e Estatística--IBGE, Diretoria de Geociências, Coordenação de Recursos Naturais e Estudos Ambientais, 2008.

STATSOFT SOUTH AMERICA. **Redes Neurais**. Materiais de Curso de Redes Neurais Artificiais, 2015.

THENÓRIO, I. **Conheça o veneno do cigarro - Manual do mundo**, dez. 2013. Disponível em: <<http://www.manualdomundo.com.br/2013/12/conheca-o-veneno-do-cigarro-2/>>. Acesso em: 5 fev. 2018.

THOMSEN, A. **Tutorial módulo Wireless ESP8266 com arduino - FilipeFlop**, 23 jun. 2015. Disponível em: <<https://www.filipeflop.com/blog/esp8266-arduino-tutorial/>>. Acesso em: 15 nov. 2017.

TIBCO SOFTWARE INC. **Statistica (data analysis software system), version 13**, 2017. Disponível em: <<http://statistica.io>>. Acesso em: 2 fev. 2018.

UNITED STATES ENVIRONMENTAL PROTECTION AGENCY. **NAAQS Table**, 2017. Disponível em: <<https://www.epa.gov/criteria-air-pollutants/naaqs-table>>. Acesso em: 9 abr. 2017.

VIEIRA, J. C. S.; ANDRADE, V. C. V.; FIGUEIREDO, R. T. **Controle de temperatura do secador com incidência solar indireta utilizando microcontrolador de baixo custo**. A prática interdisciplinar alimentando a Ciência. **Anais**. In: 18ª SEMANA DE PESQUISA DA UNIVERSIDADE TIRADENTES. Aracaju: out. 2016. Disponível em: <<https://eventos.set.edu.br/index.php/sempeq/article/view/3959>>. Acesso em: 30 abr. 2018.

WORLD RESOURCES INSTITUTE. **CAIT climate data explorer**, 2017. Disponível em: <<http://cait.wri.org>>. Acesso em: 10 abr. 2017.

APÊNDICE A

Especificações técnicas e esquemas dos sensores e módulos

As especificações técnicas e os esquemas estruturais dos sensores e módulos utilizados neste estudo estão representadas respectivamente nos: Quadro A.1 e Figura A.1 para o MQ-131; Quadro A.2 e Figura A.2 para o MICS-5524; Quadro A.3 na Figura A.3 para o PPD42; Quadro A.4 e Figura A.4 para o DHT-11; Quadro A.5 e Figura A.5 para o BMP085; e, Quadro A.6 e Figura A.6 para o RTC DS1307.

Quadro A.1 – Especificações técnicas do sensor MQ-131.

Range da Concentração do Gás Detectado	Ozônio (O ₃)	10 a 2000 ppb	
Condições de Trabalho	Tensão do circuito	V _C	5V ± 0,1
	Tensão de aquecimento	V _H	6V ± 0,1
	Resistência de carga	R _L	Variável
	Resistência do aquecedor	R _H	31Ω ± 5%
	Consumo de aquecimento	P _H	< 1100 mw
Condições Ambientais	Temperatura de uso	T _{ao}	-10 a 50°C
	Temperatura de armazenamento	T _{as}	-20 a 70°C
	Umidade relativa	RH	Menos de 95%UR
Características de Sensibilidade	Resistência do sensor	R _S	100 a 200 KΩ (50 ppb O ₃)
	Taxa de inclinação da concentração	α O ₃ (100ppb/50ppb)	≤ 0,65
Condição de Detecção Padrão	Temperatura	20°C ± 2°C (V _c : 5V ± 0,1)	
	Umidade	65% ± 5% (V _h : 6V ± 0,1)	
Tempo de Pré-aquecimento	Acima de 24 horas		

Fonte: Adaptado de Hanwei Electronics Co, LTD (2009).

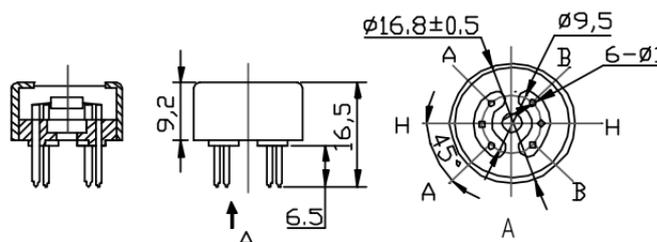


Figura A.1 – Esquema do sensor MQ-131.

Fonte: Hanwei Electronics Co, LTD (2009).

Quadro A.2 – Especificações técnicas do sensor MICS-5524.

Range das Concentrações dos Gases Detectados	Monóxido de Carbono (CO)	1 a 1000 ppm	
	Etanol (C ₂ H ₆ OH)	10 a 500 ppm	
	Hidrogênio (H ₂)	1 a 1000 ppm	
	Amônia (NH ₃)	1 a 500 ppm	
	Metano (CH ₄)	1000 ppm	
Características do Sensor	Resistência do sensor no ar ¹	R ₀	100 a 1500 Ω
	Faixa típica de detecção de CO	FS	1 a 100 ppm
	Fator de Sensibilidade ²	S ₆₀	1,2 a 50
Parâmetros	Potência de aquecimento	P _H	71 a 81 mW
	Tensão/ Corrente de aquecimento	V _H / I _H	-
	Resistência de aquecimento na potência nominal	R _H	66 a 82 Ω
Avaliação	Dissipação máxima de energia do aquecedor	P _H	88 mW
	Dissipação de potência máxima da camada sensitiva	P _S	8 mW
	Fornecimento de tensão/ corrente de aquecimento	V _C	4,9 a 5,1 V
	Faixa de umidade relativa	RH	5 a 95 %UR
	Temperatura ambiente para operação	T _{amb}	-30 a 85°C
	Faixa de temperatura para armazenamento	T _{sto}	-40 a 120°C
	Faixa de umidade para armazenamento	RH _{sto}	5 a 95 %UR
<p>¹A resistência do sensor no ar (R₀) é medida sob condições ambientais controladas, isto é, ar sintético à 23°C ± 5°C e 50 %UR ± 10 %UR (teste de amostragem).</p> <p>²O fator de sensibilidade é definido como R_S no ar dividido por R_S a 60 ppm de CO. As condições do teste são 23°C ± 5°C e 50 %UR ± 10 %UR (teste de amostragem).</p>			

Fonte: Adaptado de SGX Sensortech (2016).

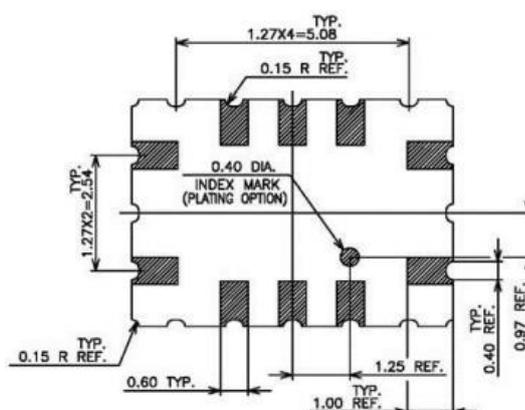


Figura A.2 – Esquema do sensor MICS-5524.

Fonte: SGX Sensortech (2016).

Quadro A.3 – Especificações técnicas do sensor PPD42.

Modelo	PPD42NJ
Tamanho de partícula detectável	Aproximadamente 1 μm (mínimo)
Faixa de concentração detectável	0 a 28000 pcs/L (0 a 8000 pcs/0,01 CF = 283 mL)
Tensão de alimentação	DC 5V \pm 10%
Faixa de temperatura para operação	0 a 45°C
Faixa de umidade para operação	95% UR ou menos
Consumo de energia	90 mA
Temperatura de armazenamento	-30 a 60°C
Tempo para estabilização	1 minuto após ligada a energia
Método de saída	Lógica negativa, Saída digital Hi: acima de 4,5V e Lo: abaixo de 0,7V (impedância de entrada: 200 k Ω)

Fonte: Adaptado de Shinyei Technology (2013).

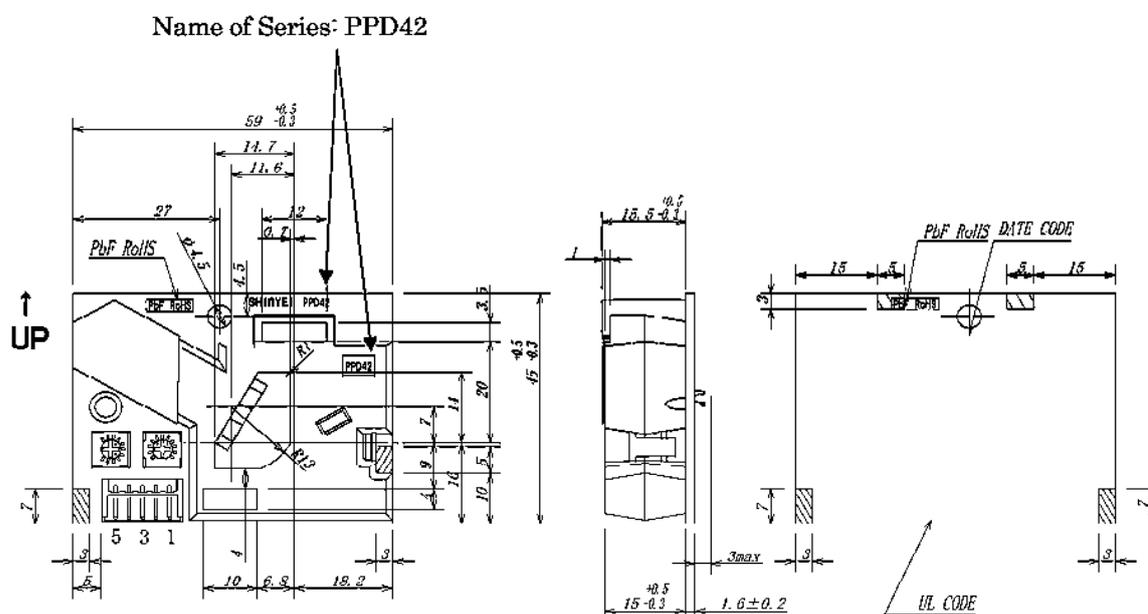


Figura A.3 – Esquema do sensor PPD42, representado em unidade de mm.

Fonte: Shinyei Technology (2013).

Quadro A.4 – Especificações técnicas do sensor DHT-11.

Range das Medições	Temperatura	0 a 50°C ($\pm 2^\circ\text{C}$)	
	Umidade	20 a 90% UR ($\pm 5\%$ UR)	
Características Elétricas	Tensão de alimentação	3 a 5,5V	
	Corrente de entrada	Medindo	0,5 a 2,5 mA
		Média	0,2 a 1 mA
		Standby	100 a 150 μA
Condições de Armazenamento	Temperatura de armazenamento	10 a 40°C	
	Umidade de armazenamento	< 60% UR	

Fonte: Adaptado de D-Robotics UK (2010).

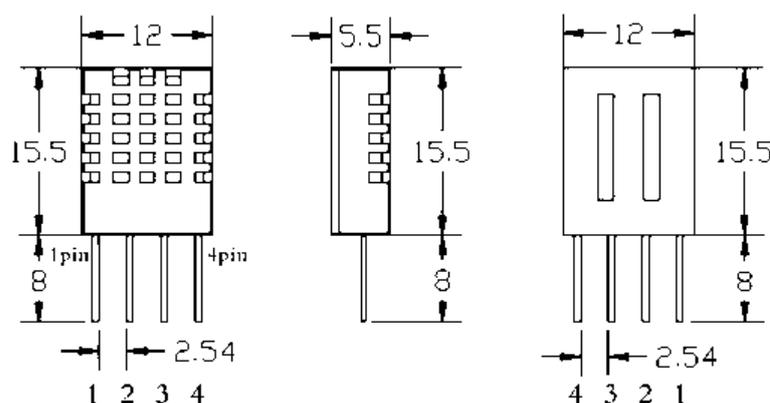


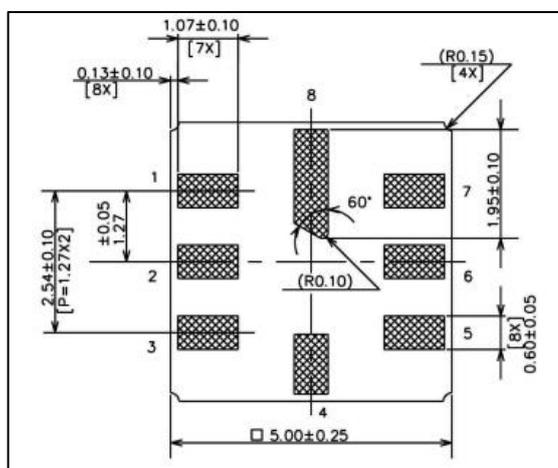
Figura A.4 – Esquema do sensor DHT-11, representado em unidade de mm.

Fonte: Aosong (2013).

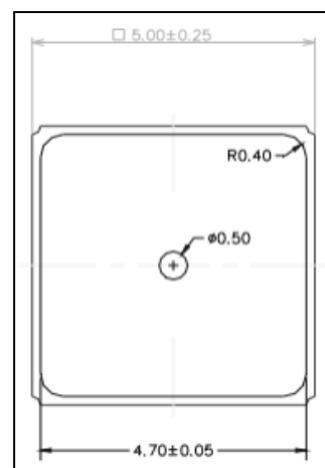
Quadro A.5 – Especificações técnicas do sensor BMP085.

Range das Medições	Pressão		300 a 1100 hPa
Precisão das Medidas	Pressão absoluta ($V_{DD} = 3,3V$)	700 a 1100 hPa 0 a 65°C	$\pm 1,0$ hPa (típico)
		300 a 700 hPa 0 a 65°C	$\pm 1,0$ hPa (típico)
		300 a 1100 hPa -20 a 0°C	$\pm 1,5$ hPa (típico)
	Pressão relativa ($V_{DD} = 3,3V$)	700 a 1100 hPa 25°C	$\pm 0,2$ hPa (típico)
		0 a 65°C (pressão constante)	$\pm 0,5$ hPa (típico)
	Temperatura ($V_{DD} = 3,3V$)	25°C	$\pm 0,5^\circ C$ (típico)
0 a 65°C		$\pm 1,0^\circ C$ (típico)	
Características Elétricas	Tensão de Alimentação	V_{DDA}	1,8 a 3,6V
		V_{DDD}	1,62 a 3,6V
	Temperatura de operação	T_A	- 40 a 85°C
	Corrente de alimentação (1 amostra/segundo a 25°C)	Modo de baixa energia	3 μA (típico)
		Modo padrão	5 μA (típico)
		Modo de alta resolução	7 μA (típico)
		Modo de resolução muito alta	12 μA (típico)
	Corrente de pico	Durante a conversão	650 μA (típico)
Corrente de <i>Standby</i>	25°C	0,1 μA (típico)	
Condição de Armazenamento	Temperatura de armazenamento		- 40 a 85°C

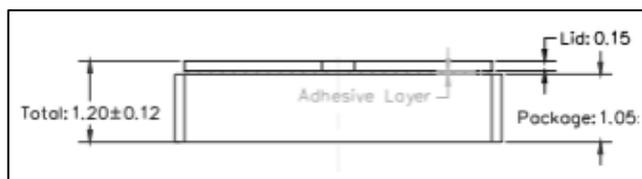
Fonte: Adaptado de Bosch Sensortec (2009).



(a)



(b)



(c)

Figura A.5 – Esquema do sensor BMP085, representado em unidade de mm, nas vistas: (a) superior; (b) superior, com tampa; (c) lateral, com tampa.

Fonte: Bosch Sensortec (2009).

Quadro A.6 – Especificações técnicas do RTC DS1307.

Características Elétricas	Tensão de Alimentação	4,5 a 5,5V
	<i>Input Leakage (SCL)</i>	1 μ A
	<i>I/O Leakage (SDA & SQW/OUT)</i>	1 μ A
	<i>Active Supply Current</i>	1,5 mA
	<i>Standby Current</i>	200 μ A
Condições de Armazenamento	Temperatura de armazenamento	-55 a 125°C

Fonte: Adaptado de Dallas Semiconductor (2001).

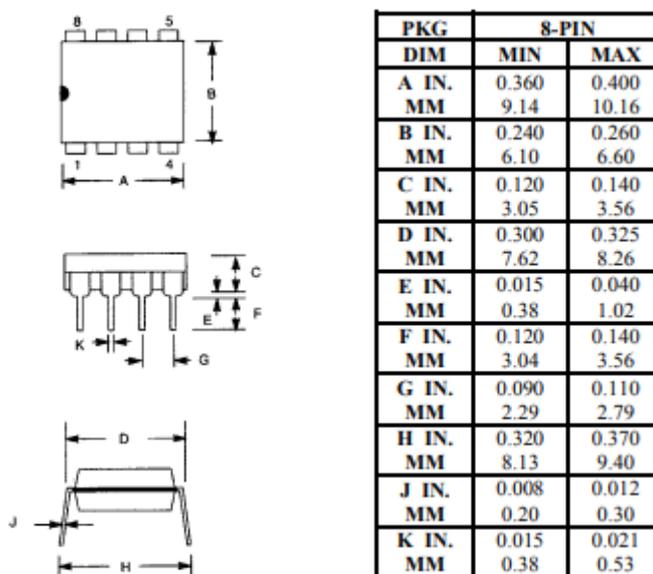


Figura A.6 – Esquema do RTC DS1307.

Fonte: Dallas Semiconductor (2001).

APÊNDICE B

Código fonte para calibração do sensor MQ-131

O Código B.1 apresenta o código de programação desenvolvido para a obtenção do valor de R_0 calibrado para o sensor MQ-131, que deverá ser utilizado quando o sensor estiver exposto a sua condição de ar limpo (ausência de ozônio). Esta programação considera um *loop* para a realização dos cálculos, logo, caso se deseje adotar a mesma para a calibração de mais de um sensor, serão necessários pequenos ajustes, a partir do uso de índices para diferenciação de cada elemento (“*sensor_id*”).

Código B.1 - Código fonte para calibração do sensor MQ-131, em condição de ar limpo.

```

1. #define MQ131_pin (A2)
2. #define MQ131_RL (20.0) //Valor de RL (load resistance) em kilo ohms
3. #define MQ131_ratio_clean_air_factor (18.6) //Valor de (Rs/Ro) do sensor em ar limpo
4. #define MQ131 (0) //sensor_id
5.
6. #define calibration_sample_times (1000) //Quantidade de amostras
7. #define calibration_sample_interval (1000) //Tempo entre as coletas (1 segundo)
8.
9. float MQ131_Ro = 10.0; //Considerando que o Ro é inicializado em 10 kilo ohms
10.
11. void setup(){
12.   Serial.begin(9600);
13.
14.   Serial.print("Calibrando sensor MQ-131...");
15.   MQ131_Ro = MQCalibration(MQ131_pin, MQ131); //Loop para calibração do sensor
16.   Serial.println("Calibração finalizada.\n");
17.
18.   Serial.print("Sensor MQ-131: ");
19.   Serial.print("Ro (kohm) = ");
20.   Serial.println(MQ131_Ro);
21. }
22.
23. void loop(){
24. }
25.
26. //Etapas para cálculo do Rs:
27. float MQResistanceCalculation(int raw_adc, int sensor_id){
28.   if (sensor_id == MQ131) {
29.     return ((float)MQ131_RL*(1023-raw_adc)/raw_adc);
30.   }
31.   return 0;
32. }
33.
34. //Etapas para a calibração do sensor (cálculo do Ro):
35. float MQCalibration(int mq_pin, int sensor_id){
36.   int i;

```

```
37. float val=0;
38.
39. for (i=0;i<calibration_sample_times;i++) {
40.   val += MQResistanceCalculation(analogRead(mq_pin), sensor_id);
41.   delay(calibration_sample_interval);
42. }
43.
44. val = val/calibration_sample_times;           //Cálculo do valor médio
45.
46. if (sensor_id == MQ131) {
47.   val = val/MQ131_ratio_clean_air_factor;
48. }
49. return val;
50. }
```

APÊNDICE C

Parâmetros da RNA final para MP_new

O Quadro C.1 e o Quadro C.2 apresentam, respectivamente, os pesos e os “*bias*” de cada conexão da melhor rede obtida para a predição do material particulado (MLP 5-70-1).

Quadro C.1 – Pesos de cada conexão da rede MLP 5-70-1, desenvolvida para predição de MP_new (continua).

MLP 5-70-1	Pesos	MLP 5-70-1	Pesos
t_bmp_norm - neurônio oculto 1	2,7614	p_bmp_norm - neurônio oculto 6	-5,0190
p_bmp_norm - neurônio oculto 1	-2,5613	t_dht_norm - neurônio oculto 6	5,3069
t_dht_norm - neurônio oculto 1	0,2483	h_dht_norm - neurônio oculto 6	9,9368
h_dht_norm - neurônio oculto 1	-3,9659	MP_ugcm_norm - neurônio oculto 6	-3,0877
MP_ugcm_norm - neurônio oculto 1	0,1997	t_bmp_norm - neurônio oculto 7	17,3693
t_bmp_norm - neurônio oculto 2	0,0873	p_bmp_norm - neurônio oculto 7	-0,1440
p_bmp_norm - neurônio oculto 2	0,1491	t_dht_norm - neurônio oculto 7	5,4023
t_dht_norm - neurônio oculto 2	1,0070	h_dht_norm - neurônio oculto 7	21,8564
h_dht_norm - neurônio oculto 2	-0,3225	MP_ugcm_norm - neurônio oculto 7	-22,0370
MP_ugcm_norm - neurônio oculto 2	-2,4554	t_bmp_norm - neurônio oculto 8	-6,1917
t_bmp_norm - neurônio oculto 3	7,1358	p_bmp_norm - neurônio oculto 8	-4,3610
p_bmp_norm - neurônio oculto 3	10,4303	t_dht_norm - neurônio oculto 8	3,7362
t_dht_norm - neurônio oculto 3	0,8493	h_dht_norm - neurônio oculto 8	13,9621
h_dht_norm - neurônio oculto 3	-4,8631	MP_ugcm_norm - neurônio oculto 8	-1,8556
MP_ugcm_norm - neurônio oculto 3	6,2963	t_bmp_norm - neurônio oculto 9	-12,5315
t_bmp_norm - neurônio oculto 4	-3,4410	p_bmp_norm - neurônio oculto 9	-1,9210
p_bmp_norm - neurônio oculto 4	2,7549	t_dht_norm - neurônio oculto 9	8,8955
t_dht_norm - neurônio oculto 4	-0,1536	h_dht_norm - neurônio oculto 9	2,5591
h_dht_norm - neurônio oculto 4	-1,1038	MP_ugcm_norm - neurônio oculto 9	1,6991
MP_ugcm_norm - neurônio oculto 4	1,8763	t_bmp_norm - neurônio oculto 10	-4,2671
t_bmp_norm - neurônio oculto 5	-2,4576	p_bmp_norm - neurônio oculto 10	4,3400
p_bmp_norm - neurônio oculto 5	-1,4154	t_dht_norm - neurônio oculto 10	-1,8147
t_dht_norm - neurônio oculto 5	0,3028	h_dht_norm - neurônio oculto 10	-3,5497
h_dht_norm - neurônio oculto 5	0,2537	MP_ugcm_norm - neurônio oculto 10	0,7043
MP_ugcm_norm - neurônio oculto 5	-1,3576	t_bmp_norm - neurônio oculto 11	0,7562
t_bmp_norm - neurônio oculto 6	23,6072	p_bmp_norm - neurônio oculto 11	1,2046

Quadro C.1. Continuação

MLP 5-70-1	Pesos	MLP 5-70-1	Pesos
t_dht_norm - neurônio oculto 11	-1,0194	p_bmp_norm - neurônio oculto 18	3,4368
h_dht_norm - neurônio oculto 11	-2,1991	t_dht_norm - neurônio oculto 18	-2,7211
MP_ugcm_norm - neurônio oculto 11	-0,9220	h_dht_norm - neurônio oculto 18	-2,4359
t_bmp_norm - neurônio oculto 12	8,7607	MP_ugcm_norm - neurônio oculto 18	-1,5774
p_bmp_norm - neurônio oculto 12	-30,3812	t_bmp_norm - neurônio oculto 19	1,9506
t_dht_norm - neurônio oculto 12	20,2397	p_bmp_norm - neurônio oculto 19	3,5825
h_dht_norm - neurônio oculto 12	-6,1037	t_dht_norm - neurônio oculto 19	-12,9796
MP_ugcm_norm - neurônio oculto 12	1,8845	h_dht_norm - neurônio oculto 19	11,5809
t_bmp_norm - neurônio oculto 13	-3,3616	MP_ugcm_norm - neurônio oculto 19	6,2841
p_bmp_norm - neurônio oculto 13	3,3429	t_bmp_norm - neurônio oculto 20	1,6222
t_dht_norm - neurônio oculto 13	-1,9273	p_bmp_norm - neurônio oculto 20	4,8082
h_dht_norm - neurônio oculto 13	3,3370	t_dht_norm - neurônio oculto 20	-4,9300
MP_ugcm_norm - neurônio oculto 13	4,6510	h_dht_norm - neurônio oculto 20	-23,7448
t_bmp_norm - neurônio oculto 14	-2,2482	MP_ugcm_norm - neurônio oculto 20	3,0791
p_bmp_norm - neurônio oculto 14	-1,6676	t_bmp_norm - neurônio oculto 21	-2,7223
t_dht_norm - neurônio oculto 14	0,0506	p_bmp_norm - neurônio oculto 21	0,9922
h_dht_norm - neurônio oculto 14	-1,2753	t_dht_norm - neurônio oculto 21	0,0863
MP_ugcm_norm - neurônio oculto 14	3,0544	h_dht_norm - neurônio oculto 21	0,1034
t_bmp_norm - neurônio oculto 15	0,0189	MP_ugcm_norm - neurônio oculto 21	-2,1578
p_bmp_norm - neurônio oculto 15	1,3455	t_bmp_norm - neurônio oculto 22	0,0876
t_dht_norm - neurônio oculto 15	-4,0605	p_bmp_norm - neurônio oculto 22	1,2018
h_dht_norm - neurônio oculto 15	-6,8034	t_dht_norm - neurônio oculto 22	-0,8707
MP_ugcm_norm - neurônio oculto 15	7,3610	h_dht_norm - neurônio oculto 22	-3,0040
t_bmp_norm - neurônio oculto 16	2,8933	MP_ugcm_norm - neurônio oculto 22	-0,3055
p_bmp_norm - neurônio oculto 16	-3,0516	t_bmp_norm - neurônio oculto 23	-7,3334
t_dht_norm - neurônio oculto 16	8,1863	p_bmp_norm - neurônio oculto 23	-3,0848
h_dht_norm - neurônio oculto 16	19,6571	t_dht_norm - neurônio oculto 23	-6,6942
MP_ugcm_norm - neurônio oculto 16	2,5880	h_dht_norm - neurônio oculto 23	-3,2353
t_bmp_norm - neurônio oculto 17	4,8884	MP_ugcm_norm - neurônio oculto 23	4,2320
p_bmp_norm - neurônio oculto 17	-2,0438	t_bmp_norm - neurônio oculto 24	4,4576
t_dht_norm - neurônio oculto 17	-0,6423	p_bmp_norm - neurônio oculto 24	2,0167
h_dht_norm - neurônio oculto 17	-4,6279	t_dht_norm - neurônio oculto 24	-0,5273
MP_ugcm_norm - neurônio oculto 17	-5,1478	h_dht_norm - neurônio oculto 24	3,6037
t_bmp_norm - neurônio oculto 18	-4,0110	MP_ugcm_norm - neurônio oculto 24	1,3128

Quadro C.1. Continuação

MLP 5-70-1	Pesos	MLP 5-70-1	Pesos
t_bmp_norm - neurônio oculto 25	6,6840	MP_ugcm_norm - neurônio oculto 31	-0,9397
p_bmp_norm - neurônio oculto 25	-2,7687	t_bmp_norm - neurônio oculto 32	-2,2125
t_dht_norm - neurônio oculto 25	4,0770	p_bmp_norm - neurônio oculto 32	0,5634
h_dht_norm - neurônio oculto 25	-2,5000	t_dht_norm - neurônio oculto 32	-2,8489
MP_ugcm_norm - neurônio oculto 25	-4,0851	h_dht_norm - neurônio oculto 32	0,9450
t_bmp_norm - neurônio oculto 26	-0,0399	MP_ugcm_norm - neurônio oculto 32	0,2973
p_bmp_norm - neurônio oculto 26	3,8634	t_bmp_norm - neurônio oculto 33	-0,4344
t_dht_norm - neurônio oculto 26	0,1064	p_bmp_norm - neurônio oculto 33	-2,2509
h_dht_norm - neurônio oculto 26	-0,5365	t_dht_norm - neurônio oculto 33	-3,1623
MP_ugcm_norm - neurônio oculto 26	-7,9816	h_dht_norm - neurônio oculto 33	-4,3789
t_bmp_norm - neurônio oculto 27	0,6368	MP_ugcm_norm - neurônio oculto 33	-8,8181
p_bmp_norm - neurônio oculto 27	-1,2629	t_bmp_norm - neurônio oculto 34	-1,1548
t_dht_norm - neurônio oculto 27	0,6666	p_bmp_norm - neurônio oculto 34	0,9610
h_dht_norm - neurônio oculto 27	4,2465	t_dht_norm - neurônio oculto 34	-0,6551
MP_ugcm_norm - neurônio oculto 27	-2,6666	h_dht_norm - neurônio oculto 34	0,7410
t_bmp_norm - neurônio oculto 28	-3,3323	MP_ugcm_norm - neurônio oculto 34	3,4777
p_bmp_norm - neurônio oculto 28	4,5382	t_bmp_norm - neurônio oculto 35	3,1005
t_dht_norm - neurônio oculto 28	-2,9966	p_bmp_norm - neurônio oculto 35	-3,6682
h_dht_norm - neurônio oculto 28	1,9251	t_dht_norm - neurônio oculto 35	1,8960
MP_ugcm_norm - neurônio oculto 28	-2,3255	h_dht_norm - neurônio oculto 35	-0,8210
t_bmp_norm - neurônio oculto 29	-0,1874	MP_ugcm_norm - neurônio oculto 35	5,9864
p_bmp_norm - neurônio oculto 29	-1,2101	t_bmp_norm - neurônio oculto 36	-2,0381
t_dht_norm - neurônio oculto 29	0,9763	p_bmp_norm - neurônio oculto 36	-2,1730
h_dht_norm - neurônio oculto 29	1,0559	t_dht_norm - neurônio oculto 36	-1,4720
MP_ugcm_norm - neurônio oculto 29	-0,4776	h_dht_norm - neurônio oculto 36	-2,6304
t_bmp_norm - neurônio oculto 30	-0,1751	MP_ugcm_norm - neurônio oculto 36	0,8190
p_bmp_norm - neurônio oculto 30	-0,5939	t_bmp_norm - neurônio oculto 37	1,5472
t_dht_norm - neurônio oculto 30	0,1958	p_bmp_norm - neurônio oculto 37	-3,0056
h_dht_norm - neurônio oculto 30	0,1697	t_dht_norm - neurônio oculto 37	-0,5576
MP_ugcm_norm - neurônio oculto 30	0,6060	h_dht_norm - neurônio oculto 37	-1,2493
t_bmp_norm - neurônio oculto 31	1,8089	MP_ugcm_norm - neurônio oculto 37	-3,0302
p_bmp_norm - neurônio oculto 31	-1,6994	t_bmp_norm - neurônio oculto 38	5,8870
t_dht_norm - neurônio oculto 31	1,4603	p_bmp_norm - neurônio oculto 38	-10,6789
h_dht_norm - neurônio oculto 31	-1,5378	t_dht_norm - neurônio oculto 38	-24,1008

Quadro C.1. Continuação

MLP 5-70-1	Pesos
h_dht_norm - neurônio oculto 38	-4,1355
MP_ugcm_norm - neurônio oculto 38	-4,2220
t_bmp_norm - neurônio oculto 39	-0,7470
p_bmp_norm - neurônio oculto 39	1,7782
t_dht_norm - neurônio oculto 39	0,7866
h_dht_norm - neurônio oculto 39	2,4451
MP_ugcm_norm - neurônio oculto 39	-2,0436
t_bmp_norm - neurônio oculto 40	-1,8820
p_bmp_norm - neurônio oculto 40	1,8504
t_dht_norm - neurônio oculto 40	-4,9104
h_dht_norm - neurônio oculto 40	-7,0344
MP_ugcm_norm - neurônio oculto 40	-5,9092
t_bmp_norm - neurônio oculto 41	-0,1882
p_bmp_norm - neurônio oculto 41	-9,5129
t_dht_norm - neurônio oculto 41	0,7348
h_dht_norm - neurônio oculto 41	-5,4231
MP_ugcm_norm - neurônio oculto 41	-10,5432
t_bmp_norm - neurônio oculto 42	4,3263
p_bmp_norm - neurônio oculto 42	-8,4738
t_dht_norm - neurônio oculto 42	2,5716
h_dht_norm - neurônio oculto 42	-2,5049
MP_ugcm_norm - neurônio oculto 42	1,1010
t_bmp_norm - neurônio oculto 43	-1,1054
p_bmp_norm - neurônio oculto 43	2,5403
t_dht_norm - neurônio oculto 43	0,1906
h_dht_norm - neurônio oculto 43	2,4986
MP_ugcm_norm - neurônio oculto 43	-1,7134
t_bmp_norm - neurônio oculto 44	-0,3567
p_bmp_norm - neurônio oculto 44	-0,6534
t_dht_norm - neurônio oculto 44	-2,1838
h_dht_norm - neurônio oculto 44	-1,4697
MP_ugcm_norm - neurônio oculto 44	-0,7487
t_bmp_norm - neurônio oculto 45	4,7895
p_bmp_norm - neurônio oculto 45	-4,5542

MLP 5-70-1	Pesos
t_dht_norm - neurônio oculto 45	2,3471
h_dht_norm - neurônio oculto 45	-1,5375
MP_ugcm_norm - neurônio oculto 45	-7,1611
t_bmp_norm - neurônio oculto 46	-1,1591
p_bmp_norm - neurônio oculto 46	0,6970
t_dht_norm - neurônio oculto 46	0,9378
h_dht_norm - neurônio oculto 46	-3,1519
MP_ugcm_norm - neurônio oculto 46	-1,3608
t_bmp_norm - neurônio oculto 47	0,6621
p_bmp_norm - neurônio oculto 47	2,1128
t_dht_norm - neurônio oculto 47	-0,5503
h_dht_norm - neurônio oculto 47	4,8652
MP_ugcm_norm - neurônio oculto 47	4,7255
t_bmp_norm - neurônio oculto 48	2,7674
p_bmp_norm - neurônio oculto 48	-1,3541
t_dht_norm - neurônio oculto 48	-2,0033
h_dht_norm - neurônio oculto 48	-2,9644
MP_ugcm_norm - neurônio oculto 48	1,7699
t_bmp_norm - neurônio oculto 49	-7,8533
p_bmp_norm - neurônio oculto 49	1,5989
t_dht_norm - neurônio oculto 49	0,7140
h_dht_norm - neurônio oculto 49	5,3951
MP_ugcm_norm - neurônio oculto 49	1,5745
t_bmp_norm - neurônio oculto 50	-0,8715
p_bmp_norm - neurônio oculto 50	1,7172
t_dht_norm - neurônio oculto 50	-2,3868
h_dht_norm - neurônio oculto 50	0,2312
MP_ugcm_norm - neurônio oculto 50	-0,6488
t_bmp_norm - neurônio oculto 51	32,6666
p_bmp_norm - neurônio oculto 51	-27,2301
t_dht_norm - neurônio oculto 51	-17,3581
h_dht_norm - neurônio oculto 51	-4,5205
MP_ugcm_norm - neurônio oculto 51	6,7166
t_bmp_norm - neurônio oculto 52	-3,8098

Quadro C.1. Continuação

MLP 5-70-1	Pesos	MLP 5-70-1	Pesos
p_bmp_norm - neurônio oculto 52	0,3239	t_bmp_norm - neurônio oculto 59	2,5651
t_dht_norm - neurônio oculto 52	1,1195	p_bmp_norm - neurônio oculto 59	-3,0103
h_dht_norm - neurônio oculto 52	-0,3846	t_dht_norm - neurônio oculto 59	1,3983
MP_ugcm_norm - neurônio oculto 52	-0,3230	h_dht_norm - neurônio oculto 59	4,8606
t_bmp_norm - neurônio oculto 53	2,9055	MP_ugcm_norm - neurônio oculto 59	-2,2314
p_bmp_norm - neurônio oculto 53	-2,2344	t_bmp_norm - neurônio oculto 60	-2,4326
t_dht_norm - neurônio oculto 53	1,1355	p_bmp_norm - neurônio oculto 60	2,8249
h_dht_norm - neurônio oculto 53	-2,6765	t_dht_norm - neurônio oculto 60	-2,2555
MP_ugcm_norm - neurônio oculto 53	-6,8419	h_dht_norm - neurônio oculto 60	-1,5862
t_bmp_norm - neurônio oculto 54	0,0908	MP_ugcm_norm - neurônio oculto 60	0,7001
p_bmp_norm - neurônio oculto 54	-1,1399	t_bmp_norm - neurônio oculto 61	-3,9745
t_dht_norm - neurônio oculto 54	-0,7685	p_bmp_norm - neurônio oculto 61	1,7215
h_dht_norm - neurônio oculto 54	-2,4667	t_dht_norm - neurônio oculto 61	1,4692
MP_ugcm_norm - neurônio oculto 54	1,4650	h_dht_norm - neurônio oculto 61	-0,1082
t_bmp_norm - neurônio oculto 55	-0,9479	MP_ugcm_norm - neurônio oculto 61	0,3240
p_bmp_norm - neurônio oculto 55	1,6250	t_bmp_norm - neurônio oculto 62	1,6608
t_dht_norm - neurônio oculto 55	-0,7090	p_bmp_norm - neurônio oculto 62	5,1811
h_dht_norm - neurônio oculto 55	8,3240	t_dht_norm - neurônio oculto 62	2,7217
MP_ugcm_norm - neurônio oculto 55	0,8051	h_dht_norm - neurônio oculto 62	6,3791
t_bmp_norm - neurônio oculto 56	6,3115	MP_ugcm_norm - neurônio oculto 62	2,5264
p_bmp_norm - neurônio oculto 56	2,9018	t_bmp_norm - neurônio oculto 63	-0,7580
t_dht_norm - neurônio oculto 56	11,6616	p_bmp_norm - neurônio oculto 63	-10,4093
h_dht_norm - neurônio oculto 56	3,3825	t_dht_norm - neurônio oculto 63	6,1157
MP_ugcm_norm - neurônio oculto 56	1,6441	h_dht_norm - neurônio oculto 63	3,9477
t_bmp_norm - neurônio oculto 57	2,6618	MP_ugcm_norm - neurônio oculto 63	-0,7024
p_bmp_norm - neurônio oculto 57	0,1626	t_bmp_norm - neurônio oculto 64	3,6180
t_dht_norm - neurônio oculto 57	-1,6008	p_bmp_norm - neurônio oculto 64	-0,7631
h_dht_norm - neurônio oculto 57	0,1596	t_dht_norm - neurônio oculto 64	-0,3827
MP_ugcm_norm - neurônio oculto 57	6,5929	h_dht_norm - neurônio oculto 64	4,2022
t_bmp_norm - neurônio oculto 58	-0,1776	MP_ugcm_norm - neurônio oculto 64	2,3307
p_bmp_norm - neurônio oculto 58	-0,0205	t_bmp_norm - neurônio oculto 65	3,5732
t_dht_norm - neurônio oculto 58	0,0115	p_bmp_norm - neurônio oculto 65	0,2491
h_dht_norm - neurônio oculto 58	-0,8423	t_dht_norm - neurônio oculto 65	1,8520
MP_ugcm_norm - neurônio oculto 58	-0,2090	h_dht_norm - neurônio oculto 65	0,0936

Quadro C.1. Continuação

MLP 5-70-1	Pesos	MLP 5-70-1	Pesos
MP_ugcm_norm - neurônio oculto 65	-1,4014	neurônio oculto 9 - MP_new	1,4517
t_bmp_norm - neurônio oculto 66	0,1469	neurônio oculto 10 - MP_new	4,0511
p_bmp_norm - neurônio oculto 66	-9,0896	neurônio oculto 11 - MP_new	-1,7023
t_dht_norm - neurônio oculto 66	-10,3398	neurônio oculto 12 - MP_new	0,7720
h_dht_norm - neurônio oculto 66	0,5966	neurônio oculto 13 - MP_new	-1,8679
MP_ugcm_norm - neurônio oculto 66	5,0208	neurônio oculto 14 - MP_new	2,8567
t_bmp_norm - neurônio oculto 67	-4,5289	neurônio oculto 15 - MP_new	-0,4619
p_bmp_norm - neurônio oculto 67	-4,1132	neurônio oculto 16 - MP_new	3,6471
t_dht_norm - neurônio oculto 67	3,4369	neurônio oculto 17 - MP_new	2,4096
h_dht_norm - neurônio oculto 67	-2,0258	neurônio oculto 18 - MP_new	-1,0204
MP_ugcm_norm - neurônio oculto 67	-1,6281	neurônio oculto 19 - MP_new	-5,1803
t_bmp_norm - neurônio oculto 68	-0,0177	neurônio oculto 20 - MP_new	-1,3151
p_bmp_norm - neurônio oculto 68	-0,7760	neurônio oculto 21 - MP_new	0,5184
t_dht_norm - neurônio oculto 68	0,7012	neurônio oculto 22 - MP_new	-1,2155
h_dht_norm - neurônio oculto 68	2,5400	neurônio oculto 23 - MP_new	-1,4281
MP_ugcm_norm - neurônio oculto 68	1,3825	neurônio oculto 24 - MP_new	-2,5566
t_bmp_norm - neurônio oculto 69	-1,0904	neurônio oculto 25 - MP_new	1,3360
p_bmp_norm - neurônio oculto 69	-1,8772	neurônio oculto 26 - MP_new	3,8076
t_dht_norm - neurônio oculto 69	-0,3917	neurônio oculto 27 - MP_new	-2,0212
h_dht_norm - neurônio oculto 69	0,6568	neurônio oculto 28 - MP_new	1,5220
MP_ugcm_norm - neurônio oculto 69	0,2972	neurônio oculto 29 - MP_new	-0,0291
t_bmp_norm - neurônio oculto 70	1,4073	neurônio oculto 30 - MP_new	0,7943
p_bmp_norm - neurônio oculto 70	-3,5164	neurônio oculto 31 - MP_new	1,1292
t_dht_norm - neurônio oculto 70	-4,9333	neurônio oculto 32 - MP_new	0,0067
h_dht_norm - neurônio oculto 70	3,4057	neurônio oculto 33 - MP_new	4,8481
MP_ugcm_norm - neurônio oculto 70	1,2201	neurônio oculto 34 - MP_new	0,8630
neurônio oculto 1 - MP_new	-1,9645	neurônio oculto 35 - MP_new	1,3045
neurônio oculto 2 - MP_new	2,3353	neurônio oculto 36 - MP_new	5,1893
neurônio oculto 3 - MP_new	-0,1163	neurônio oculto 37 - MP_new	2,9422
neurônio oculto 4 - MP_new	-2,8909	neurônio oculto 38 - MP_new	-0,4679
neurônio oculto 5 - MP_new	0,5284	neurônio oculto 39 - MP_new	0,9288
neurônio oculto 6 - MP_new	0,5977	neurônio oculto 40 - MP_new	-3,2768
neurônio oculto 7 - MP_new	-0,3578	neurônio oculto 41 - MP_new	-0,6206
neurônio oculto 8 - MP_new	-1,5841	neurônio oculto 42 - MP_new	1,1538

Quadro C.1. Continuação

MLP 5-70-1	Pesos
neurônio oculto 43 - MP_new	0,7785
neurônio oculto 44 - MP_new	-0,9235
neurônio oculto 45 - MP_new	1,3883
neurônio oculto 46 - MP_new	-2,6736
neurônio oculto 47 - MP_new	3,8122
neurônio oculto 48 - MP_new	-3,3744
neurônio oculto 49 - MP_new	-1,3857
neurônio oculto 50 - MP_new	-2,3417
neurônio oculto 51 - MP_new	-0,2974
neurônio oculto 52 - MP_new	-3,0841
neurônio oculto 53 - MP_new	2,3424
neurônio oculto 54 - MP_new	-0,8319
neurônio oculto 55 - MP_new	2,0029
neurônio oculto 56 - MP_new	-1,0039
neurônio oculto 57 - MP_new	4,9636
neurônio oculto 58 - MP_new	1,0525
neurônio oculto 59 - MP_new	-2,1636
neurônio oculto 60 - MP_new	5,4742
neurônio oculto 61 - MP_new	-1,5957
neurônio oculto 62 - MP_new	4,1555
neurônio oculto 63 - MP_new	0,9429
neurônio oculto 64 - MP_new	-0,2428
neurônio oculto 65 - MP_new	-1,4163
neurônio oculto 66 - MP_new	0,7516
neurônio oculto 67 - MP_new	-1,5077
neurônio oculto 68 - MP_new	0,1593
neurônio oculto 69 - MP_new	1,2592
neurônio oculto 70 - MP_new	5,0855

Quadro C.2 – “Bias” de cada conexão da rede MLP 5-70-1, desenvolvida para predição de MP_new (continua).

MLP 5-70-1	"Bias"	MLP 5-70-1	"Bias"
“bias” de entrada - neurônio oculto 1	-4,2815	“bias” de entrada - neurônio oculto 34	0,4047
“bias” de entrada - neurônio oculto 2	-3,5280	“bias” de entrada - neurônio oculto 35	0,7538
“bias” de entrada - neurônio oculto 3	-6,3390	“bias” de entrada - neurônio oculto 36	-2,8890
“bias” de entrada - neurônio oculto 4	-0,3100	“bias” de entrada - neurônio oculto 37	-0,9973
“bias” de entrada - neurônio oculto 5	-4,6114	“bias” de entrada - neurônio oculto 38	23,3140
“bias” de entrada - neurônio oculto 6	-17,1414	“bias” de entrada - neurônio oculto 39	1,8080
“bias” de entrada - neurônio oculto 7	-22,0618	“bias” de entrada - neurônio oculto 40	-4,0961
“bias” de entrada - neurônio oculto 8	-0,5323	“bias” de entrada - neurônio oculto 41	7,5341
“bias” de entrada - neurônio oculto 9	2,4104	“bias” de entrada - neurônio oculto 42	1,4830
“bias” de entrada - neurônio oculto 10	1,7253	“bias” de entrada - neurônio oculto 43	0,6187
“bias” de entrada - neurônio oculto 11	-0,4837	“bias” de entrada - neurônio oculto 44	-0,0956
“bias” de entrada - neurônio oculto 12	-4,7322	“bias” de entrada - neurônio oculto 45	0,8155
“bias” de entrada - neurônio oculto 13	-3,2495	“bias” de entrada - neurônio oculto 46	-0,1419
“bias” de entrada - neurônio oculto 14	-1,2376	“bias” de entrada - neurônio oculto 47	2,0884
“bias” de entrada - neurônio oculto 15	5,3190	“bias” de entrada - neurônio oculto 48	3,0588
“bias” de entrada - neurônio oculto 16	-8,6320	“bias” de entrada - neurônio oculto 49	1,6538
“bias” de entrada - neurônio oculto 17	-1,0054	“bias” de entrada - neurônio oculto 50	0,6822
“bias” de entrada - neurônio oculto 18	2,1030	“bias” de entrada - neurônio oculto 51	8,0414
“bias” de entrada - neurônio oculto 19	8,3458	“bias” de entrada - neurônio oculto 52	-3,3964
“bias” de entrada - neurônio oculto 20	7,0181	“bias” de entrada - neurônio oculto 53	0,0496
“bias” de entrada - neurônio oculto 21	-0,3971	“bias” de entrada - neurônio oculto 54	-0,6639
“bias” de entrada - neurônio oculto 22	1,1745	“bias” de entrada - neurônio oculto 55	-2,6288
“bias” de entrada - neurônio oculto 23	3,8607	“bias” de entrada - neurônio oculto 56	-14,4868
“bias” de entrada - neurônio oculto 24	8,7128	“bias” de entrada - neurônio oculto 57	0,3633
“bias” de entrada - neurônio oculto 25	3,0787	“bias” de entrada - neurônio oculto 58	1,9125
“bias” de entrada - neurônio oculto 26	-4,6362	“bias” de entrada - neurônio oculto 59	-1,5308
“bias” de entrada - neurônio oculto 27	-4,7062	“bias” de entrada - neurônio oculto 60	2,3398
“bias” de entrada - neurônio oculto 28	-1,4330	“bias” de entrada - neurônio oculto 61	-0,6981
“bias” de entrada - neurônio oculto 29	0,8949	“bias” de entrada - neurônio oculto 62	-4,8047
“bias” de entrada - neurônio oculto 30	-1,8027	“bias” de entrada - neurônio oculto 63	1,5666
“bias” de entrada - neurônio oculto 31	-1,3828	“bias” de entrada - neurônio oculto 64	4,1047
“bias” de entrada - neurônio oculto 32	1,3632	“bias” de entrada - neurônio oculto 65	-1,4959
“bias” de entrada - neurônio oculto 33	-5,9896	“bias” de entrada - neurônio oculto 66	14,5414

Quadro C.2. Continuação

MLP 5-70-1	"Bias"
"bias" de entrada - neurônio oculto 67	4,3111
"bias" de entrada - neurônio oculto 68	-0,0992
"bias" de entrada - neurônio oculto 69	2,9795
"bias" de entrada - neurônio oculto 70	-2,7179
"bias" oculto - MP_new	-2,9651

APÊNDICE D
Parâmetros da RNA final para O3_new

O Quadro D.1 e o Quadro D.2 apresentam, respectivamente, os pesos e os “*bias*” de cada conexão da melhor rede obtida para a predição do ozônio (MLP 5-86-1).

Quadro D.1 - Pesos de cada conexão da rede MLP 5-86-1, desenvolvida para predição de O3_new (continua).

MLP 5-86-1	Pesos	MLP 5-86-1	Pesos
t_bmp_norm - neurônio oculto 1	-1,4215	p_bmp_norm - neurônio oculto 6	0,8391
p_bmp_norm - neurônio oculto 1	1,4756	t_dht_norm - neurônio oculto 6	0,0481
t_dht_norm - neurônio oculto 1	-0,0221	h_dht_norm - neurônio oculto 6	-1,3268
h_dht_norm - neurônio oculto 1	-0,4115	O3_ugcm_norm - neurônio oculto 6	-1,2538
O3_ugcm_norm - neurônio oculto 1	-2,6824	t_bmp_norm - neurônio oculto 7	-0,8047
t_bmp_norm - neurônio oculto 2	-1,4958	p_bmp_norm - neurônio oculto 7	-1,4969
p_bmp_norm - neurônio oculto 2	2,8533	t_dht_norm - neurônio oculto 7	1,0573
t_dht_norm - neurônio oculto 2	-0,2276	h_dht_norm - neurônio oculto 7	-1,8331
h_dht_norm - neurônio oculto 2	-1,0408	O3_ugcm_norm - neurônio oculto 7	-4,1731
O3_ugcm_norm - neurônio oculto 2	-11,6522	t_bmp_norm - neurônio oculto 8	-1,7853
t_bmp_norm - neurônio oculto 3	-2,7719	p_bmp_norm - neurônio oculto 8	2,3546
p_bmp_norm - neurônio oculto 3	1,0835	t_dht_norm - neurônio oculto 8	-0,2516
t_dht_norm - neurônio oculto 3	-1,1117	h_dht_norm - neurônio oculto 8	-1,4488
h_dht_norm - neurônio oculto 3	-2,4275	O3_ugcm_norm - neurônio oculto 8	-11,4839
O3_ugcm_norm - neurônio oculto 3	-12,7080	t_bmp_norm - neurônio oculto 9	-2,1869
t_bmp_norm - neurônio oculto 4	-0,7097	p_bmp_norm - neurônio oculto 9	3,3594
p_bmp_norm - neurônio oculto 4	0,9018	t_dht_norm - neurônio oculto 9	-0,1638
t_dht_norm - neurônio oculto 4	-1,9411	h_dht_norm - neurônio oculto 9	-1,2052
h_dht_norm - neurônio oculto 4	-0,2040	O3_ugcm_norm - neurônio oculto 9	-3,3105
O3_ugcm_norm - neurônio oculto 4	-8,8039	t_bmp_norm - neurônio oculto 10	-0,7968
t_bmp_norm - neurônio oculto 5	0,6515	p_bmp_norm - neurônio oculto 10	0,5960
p_bmp_norm - neurônio oculto 5	2,0989	t_dht_norm - neurônio oculto 10	0,1772
t_dht_norm - neurônio oculto 5	-2,2291	h_dht_norm - neurônio oculto 10	0,0999
h_dht_norm - neurônio oculto 5	-1,5876	O3_ugcm_norm - neurônio oculto 10	-5,1216
O3_ugcm_norm - neurônio oculto 5	-21,3053	t_bmp_norm - neurônio oculto 11	-1,7381
t_bmp_norm - neurônio oculto 6	-0,7718	p_bmp_norm - neurônio oculto 11	1,2889

Quadro D.1. Continuação

MLP 5-86-1	Pesos	MLP 5-86-1	Pesos
t_dht_norm - neurônio oculto 11	-0,2680	p_bmp_norm - neurônio oculto 18	1,3581
h_dht_norm - neurônio oculto 11	-1,8746	t_dht_norm - neurônio oculto 18	-0,2069
O3_ugcm_norm - neurônio oculto 11	-5,9507	h_dht_norm - neurônio oculto 18	-0,5607
t_bmp_norm - neurônio oculto 12	-3,5050	O3_ugcm_norm - neurônio oculto 18	-36,4397
p_bmp_norm - neurônio oculto 12	0,0142	t_bmp_norm - neurônio oculto 19	0,6854
t_dht_norm - neurônio oculto 12	0,1601	p_bmp_norm - neurônio oculto 19	2,7269
h_dht_norm - neurônio oculto 12	-1,4727	t_dht_norm - neurônio oculto 19	-0,3782
O3_ugcm_norm - neurônio oculto 12	-32,3713	h_dht_norm - neurônio oculto 19	-1,0445
t_bmp_norm - neurônio oculto 13	-0,9751	O3_ugcm_norm - neurônio oculto 19	-2,7725
p_bmp_norm - neurônio oculto 13	1,4124	t_bmp_norm - neurônio oculto 20	-0,1892
t_dht_norm - neurônio oculto 13	0,0629	p_bmp_norm - neurônio oculto 20	1,7983
h_dht_norm - neurônio oculto 13	-0,9460	t_dht_norm - neurônio oculto 20	-0,2634
O3_ugcm_norm - neurônio oculto 13	-2,5730	h_dht_norm - neurônio oculto 20	-2,8236
t_bmp_norm - neurônio oculto 14	-1,1593	O3_ugcm_norm - neurônio oculto 20	-7,7700
p_bmp_norm - neurônio oculto 14	1,0284	t_bmp_norm - neurônio oculto 21	-1,7169
t_dht_norm - neurônio oculto 14	-0,3025	p_bmp_norm - neurônio oculto 21	0,5251
h_dht_norm - neurônio oculto 14	-2,5895	t_dht_norm - neurônio oculto 21	-1,2543
O3_ugcm_norm - neurônio oculto 14	-17,9606	h_dht_norm - neurônio oculto 21	-1,8638
t_bmp_norm - neurônio oculto 15	-0,8193	O3_ugcm_norm - neurônio oculto 21	-3,4360
p_bmp_norm - neurônio oculto 15	0,8198	t_bmp_norm - neurônio oculto 22	-1,5829
t_dht_norm - neurônio oculto 15	0,3092	p_bmp_norm - neurônio oculto 22	4,2952
h_dht_norm - neurônio oculto 15	-1,4345	t_dht_norm - neurônio oculto 22	2,2709
O3_ugcm_norm - neurônio oculto 15	-2,9084	h_dht_norm - neurônio oculto 22	-5,1960
t_bmp_norm - neurônio oculto 16	0,4365	O3_ugcm_norm - neurônio oculto 22	-10,8100
p_bmp_norm - neurônio oculto 16	0,2239	t_bmp_norm - neurônio oculto 23	0,1506
t_dht_norm - neurônio oculto 16	2,0384	p_bmp_norm - neurônio oculto 23	0,1392
h_dht_norm - neurônio oculto 16	-2,4371	t_dht_norm - neurônio oculto 23	2,3898
O3_ugcm_norm - neurônio oculto 16	-0,1043	h_dht_norm - neurônio oculto 23	-2,5315
t_bmp_norm - neurônio oculto 17	-0,9948	O3_ugcm_norm - neurônio oculto 23	1,2334
p_bmp_norm - neurônio oculto 17	1,0172	t_bmp_norm - neurônio oculto 24	-0,3280
t_dht_norm - neurônio oculto 17	-0,1937	p_bmp_norm - neurônio oculto 24	0,8407
h_dht_norm - neurônio oculto 17	-1,0712	t_dht_norm - neurônio oculto 24	1,0475
O3_ugcm_norm - neurônio oculto 17	-2,7067	h_dht_norm - neurônio oculto 24	-2,2415
t_bmp_norm - neurônio oculto 18	-1,5622	O3_ugcm_norm - neurônio oculto 24	-1,3676

Quadro D.1. Continuação

MLP 5-86-1	Pesos	MLP 5-86-1	Pesos
t_bmp_norm - neurônio oculto 25	0,3404	O3_ugcm_norm - neurônio oculto 31	-4,9929
p_bmp_norm - neurônio oculto 25	2,9054	t_bmp_norm - neurônio oculto 32	-0,4369
t_dht_norm - neurônio oculto 25	-0,6609	p_bmp_norm - neurônio oculto 32	-1,4383
h_dht_norm - neurônio oculto 25	-2,4938	t_dht_norm - neurônio oculto 32	-2,5279
O3_ugcm_norm - neurônio oculto 25	-8,6858	h_dht_norm - neurônio oculto 32	0,1060
t_bmp_norm - neurônio oculto 26	-1,8988	O3_ugcm_norm - neurônio oculto 32	-11,6500
p_bmp_norm - neurônio oculto 26	2,3182	t_bmp_norm - neurônio oculto 33	0,2414
t_dht_norm - neurônio oculto 26	0,2505	p_bmp_norm - neurônio oculto 33	2,9577
h_dht_norm - neurônio oculto 26	-2,7740	t_dht_norm - neurônio oculto 33	-0,9142
O3_ugcm_norm - neurônio oculto 26	-6,8250	h_dht_norm - neurônio oculto 33	-1,9704
t_bmp_norm - neurônio oculto 27	1,1231	O3_ugcm_norm - neurônio oculto 33	-14,8590
p_bmp_norm - neurônio oculto 27	-0,5374	t_bmp_norm - neurônio oculto 34	-0,9240
t_dht_norm - neurônio oculto 27	-3,0231	p_bmp_norm - neurônio oculto 34	2,3679
h_dht_norm - neurônio oculto 27	-2,9499	t_dht_norm - neurônio oculto 34	0,1025
O3_ugcm_norm - neurônio oculto 27	-21,6868	h_dht_norm - neurônio oculto 34	-2,0366
t_bmp_norm - neurônio oculto 28	-0,7855	O3_ugcm_norm - neurônio oculto 34	-9,6318
p_bmp_norm - neurônio oculto 28	1,3602	t_bmp_norm - neurônio oculto 35	-2,6185
t_dht_norm - neurônio oculto 28	0,2622	p_bmp_norm - neurônio oculto 35	3,4852
h_dht_norm - neurônio oculto 28	-0,8296	t_dht_norm - neurônio oculto 35	0,0448
O3_ugcm_norm - neurônio oculto 28	-2,6505	h_dht_norm - neurônio oculto 35	-1,1225
t_bmp_norm - neurônio oculto 29	1,0339	O3_ugcm_norm - neurônio oculto 35	-22,6808
p_bmp_norm - neurônio oculto 29	1,4956	t_bmp_norm - neurônio oculto 36	-0,8406
t_dht_norm - neurônio oculto 29	-3,3729	p_bmp_norm - neurônio oculto 36	1,2158
h_dht_norm - neurônio oculto 29	-2,0456	t_dht_norm - neurônio oculto 36	-0,0412
O3_ugcm_norm - neurônio oculto 29	-22,3089	h_dht_norm - neurônio oculto 36	-1,6926
t_bmp_norm - neurônio oculto 30	-2,3700	O3_ugcm_norm - neurônio oculto 36	-7,2491
p_bmp_norm - neurônio oculto 30	2,1899	t_bmp_norm - neurônio oculto 37	-1,2220
t_dht_norm - neurônio oculto 30	0,1732	p_bmp_norm - neurônio oculto 37	0,5495
h_dht_norm - neurônio oculto 30	-2,0769	t_dht_norm - neurônio oculto 37	0,5234
O3_ugcm_norm - neurônio oculto 30	-4,7192	h_dht_norm - neurônio oculto 37	-1,1817
t_bmp_norm - neurônio oculto 31	-0,2280	O3_ugcm_norm - neurônio oculto 37	-0,0770
p_bmp_norm - neurônio oculto 31	0,8370	t_bmp_norm - neurônio oculto 38	-0,7764
t_dht_norm - neurônio oculto 31	0,2901	p_bmp_norm - neurônio oculto 38	1,5333
h_dht_norm - neurônio oculto 31	-1,9444	t_dht_norm - neurônio oculto 38	0,3927

Quadro D.1. Continuação

MLP 5-86-1	Pesos	MLP 5-86-1	Pesos
h_dht_norm - neurônio oculto 38	-2,1209	t_dht_norm - neurônio oculto 45	0,3753
O3_ugcm_norm - neurônio oculto 38	-0,7961	h_dht_norm - neurônio oculto 45	-3,0553
t_bmp_norm - neurônio oculto 39	-1,0641	O3_ugcm_norm - neurônio oculto 45	2,5965
p_bmp_norm - neurônio oculto 39	1,4702	t_bmp_norm - neurônio oculto 46	-2,9418
t_dht_norm - neurônio oculto 39	-0,2314	p_bmp_norm - neurônio oculto 46	0,9546
h_dht_norm - neurônio oculto 39	-0,8505	t_dht_norm - neurônio oculto 46	-0,3139
O3_ugcm_norm - neurônio oculto 39	-3,0932	h_dht_norm - neurônio oculto 46	-2,7940
t_bmp_norm - neurônio oculto 40	0,8882	O3_ugcm_norm - neurônio oculto 46	-17,1108
p_bmp_norm - neurônio oculto 40	3,8543	t_bmp_norm - neurônio oculto 47	-1,5683
t_dht_norm - neurônio oculto 40	-0,0927	p_bmp_norm - neurônio oculto 47	2,2441
h_dht_norm - neurônio oculto 40	-3,7719	t_dht_norm - neurônio oculto 47	-2,0559
O3_ugcm_norm - neurônio oculto 40	-17,1763	h_dht_norm - neurônio oculto 47	-1,4253
t_bmp_norm - neurônio oculto 41	-1,2161	O3_ugcm_norm - neurônio oculto 47	-34,6039
p_bmp_norm - neurônio oculto 41	0,0287	t_bmp_norm - neurônio oculto 48	-0,6149
t_dht_norm - neurônio oculto 41	-2,6112	p_bmp_norm - neurônio oculto 48	0,6447
h_dht_norm - neurônio oculto 41	0,5742	t_dht_norm - neurônio oculto 48	0,0433
O3_ugcm_norm - neurônio oculto 41	-10,8865	h_dht_norm - neurônio oculto 48	-1,3221
t_bmp_norm - neurônio oculto 42	-0,2026	O3_ugcm_norm - neurônio oculto 48	-2,5889
p_bmp_norm - neurônio oculto 42	2,7649	t_bmp_norm - neurônio oculto 49	-1,2505
t_dht_norm - neurônio oculto 42	0,1146	p_bmp_norm - neurônio oculto 49	1,9751
h_dht_norm - neurônio oculto 42	-2,5115	t_dht_norm - neurônio oculto 49	0,5606
O3_ugcm_norm - neurônio oculto 42	-8,4363	h_dht_norm - neurônio oculto 49	-1,6568
t_bmp_norm - neurônio oculto 43	0,4255	O3_ugcm_norm - neurônio oculto 49	-4,5533
p_bmp_norm - neurônio oculto 43	0,1556	t_bmp_norm - neurônio oculto 50	-2,8841
t_dht_norm - neurônio oculto 43	0,4334	p_bmp_norm - neurônio oculto 50	0,9217
h_dht_norm - neurônio oculto 43	-2,8087	t_dht_norm - neurônio oculto 50	-1,7910
O3_ugcm_norm - neurônio oculto 43	-0,1999	h_dht_norm - neurônio oculto 50	-1,9173
t_bmp_norm - neurônio oculto 44	-1,6034	O3_ugcm_norm - neurônio oculto 50	-8,6425
p_bmp_norm - neurônio oculto 44	1,0306	t_bmp_norm - neurônio oculto 51	-1,5963
t_dht_norm - neurônio oculto 44	-1,1828	p_bmp_norm - neurônio oculto 51	0,1173
h_dht_norm - neurônio oculto 44	-3,1483	t_dht_norm - neurônio oculto 51	-5,7718
O3_ugcm_norm - neurônio oculto 44	-4,2579	h_dht_norm - neurônio oculto 51	1,7095
t_bmp_norm - neurônio oculto 45	-0,3512	O3_ugcm_norm - neurônio oculto 51	-18,3754
p_bmp_norm - neurônio oculto 45	3,2682	t_bmp_norm - neurônio oculto 52	-1,9132

Quadro D.1. Continuação

MLP 5-86-1	Pesos	MLP 5-86-1	Pesos
p_bmp_norm - neurônio oculto 52	-1,0302	t_bmp_norm - neurônio oculto 59	0,1735
t_dht_norm - neurônio oculto 52	0,9920	p_bmp_norm - neurônio oculto 59	1,5658
h_dht_norm - neurônio oculto 52	-4,9640	t_dht_norm - neurônio oculto 59	2,4791
O3_ugcm_norm - neurônio oculto 52	-16,8415	h_dht_norm - neurônio oculto 59	-3,8496
t_bmp_norm - neurônio oculto 53	-0,2955	O3_ugcm_norm - neurônio oculto 59	0,9436
p_bmp_norm - neurônio oculto 53	2,2699	t_bmp_norm - neurônio oculto 60	-0,8936
t_dht_norm - neurônio oculto 53	-0,0981	p_bmp_norm - neurônio oculto 60	2,0059
h_dht_norm - neurônio oculto 53	-1,5879	t_dht_norm - neurônio oculto 60	0,1705
O3_ugcm_norm - neurônio oculto 53	-2,5813	h_dht_norm - neurônio oculto 60	-2,4047
t_bmp_norm - neurônio oculto 54	-3,2262	O3_ugcm_norm - neurônio oculto 60	-5,7997
p_bmp_norm - neurônio oculto 54	0,8496	t_bmp_norm - neurônio oculto 61	-2,9743
t_dht_norm - neurônio oculto 54	0,1111	p_bmp_norm - neurônio oculto 61	1,3910
h_dht_norm - neurônio oculto 54	-3,8825	t_dht_norm - neurônio oculto 61	-0,5832
O3_ugcm_norm - neurônio oculto 54	-20,4329	h_dht_norm - neurônio oculto 61	-1,8720
t_bmp_norm - neurônio oculto 55	-0,7502	O3_ugcm_norm - neurônio oculto 61	-12,0205
p_bmp_norm - neurônio oculto 55	1,9569	t_bmp_norm - neurônio oculto 62	-0,6771
t_dht_norm - neurônio oculto 55	0,1024	p_bmp_norm - neurônio oculto 62	0,0993
h_dht_norm - neurônio oculto 55	-2,1243	t_dht_norm - neurônio oculto 62	1,5241
O3_ugcm_norm - neurônio oculto 55	-4,2998	h_dht_norm - neurônio oculto 62	-2,3662
t_bmp_norm - neurônio oculto 56	-1,1167	O3_ugcm_norm - neurônio oculto 62	-36,2057
p_bmp_norm - neurônio oculto 56	1,6747	t_bmp_norm - neurônio oculto 63	-1,0693
t_dht_norm - neurônio oculto 56	-0,3401	p_bmp_norm - neurônio oculto 63	1,4660
h_dht_norm - neurônio oculto 56	-1,7959	t_dht_norm - neurônio oculto 63	-0,4464
O3_ugcm_norm - neurônio oculto 56	-2,8878	h_dht_norm - neurônio oculto 63	-1,9113
t_bmp_norm - neurônio oculto 57	-1,4795	O3_ugcm_norm - neurônio oculto 63	-3,7190
p_bmp_norm - neurônio oculto 57	1,2185	t_bmp_norm - neurônio oculto 64	-3,6445
t_dht_norm - neurônio oculto 57	0,2065	p_bmp_norm - neurônio oculto 64	1,9608
h_dht_norm - neurônio oculto 57	-2,0256	t_dht_norm - neurônio oculto 64	-1,4367
O3_ugcm_norm - neurônio oculto 57	-5,3383	h_dht_norm - neurônio oculto 64	-2,4276
t_bmp_norm - neurônio oculto 58	-1,4781	O3_ugcm_norm - neurônio oculto 64	-18,9304
p_bmp_norm - neurônio oculto 58	1,0218	t_bmp_norm - neurônio oculto 65	-0,7350
t_dht_norm - neurônio oculto 58	-1,0033	p_bmp_norm - neurônio oculto 65	1,0722
h_dht_norm - neurônio oculto 58	-1,9103	t_dht_norm - neurônio oculto 65	-0,6477
O3_ugcm_norm - neurônio oculto 58	-3,2467	h_dht_norm - neurônio oculto 65	-1,7433

Quadro D.1. Continuação

MLP 5-86-1	Pesos	MLP 5-86-1	Pesos
O3_ugcm_norm - neurônio oculto 65	-2,6471	h_dht_norm - neurônio oculto 72	-1,0913
t_bmp_norm - neurônio oculto 66	-0,6830	O3_ugcm_norm - neurônio oculto 72	-3,2675
p_bmp_norm - neurônio oculto 66	2,1534	t_bmp_norm - neurônio oculto 73	-1,9344
t_dht_norm - neurônio oculto 66	-0,3001	p_bmp_norm - neurônio oculto 73	1,3434
h_dht_norm - neurônio oculto 66	-1,9959	t_dht_norm - neurônio oculto 73	-0,7808
O3_ugcm_norm - neurônio oculto 66	-7,0096	h_dht_norm - neurônio oculto 73	-1,7804
t_bmp_norm - neurônio oculto 67	-1,5620	O3_ugcm_norm - neurônio oculto 73	-5,9619
p_bmp_norm - neurônio oculto 67	2,0601	t_bmp_norm - neurônio oculto 74	-3,1262
t_dht_norm - neurônio oculto 67	0,3019	p_bmp_norm - neurônio oculto 74	1,1859
h_dht_norm - neurônio oculto 67	-2,3086	t_dht_norm - neurônio oculto 74	-1,3843
O3_ugcm_norm - neurônio oculto 67	-1,1576	h_dht_norm - neurônio oculto 74	-2,1245
t_bmp_norm - neurônio oculto 68	0,2869	O3_ugcm_norm - neurônio oculto 74	-10,7657
p_bmp_norm - neurônio oculto 68	1,7408	t_bmp_norm - neurônio oculto 75	-0,0428
t_dht_norm - neurônio oculto 68	0,3633	p_bmp_norm - neurônio oculto 75	1,0768
h_dht_norm - neurônio oculto 68	-0,7009	t_dht_norm - neurônio oculto 75	1,6172
O3_ugcm_norm - neurônio oculto 68	-0,8531	h_dht_norm - neurônio oculto 75	-2,6892
t_bmp_norm - neurônio oculto 69	-1,9037	O3_ugcm_norm - neurônio oculto 75	0,2514
p_bmp_norm - neurônio oculto 69	1,8876	t_bmp_norm - neurônio oculto 76	0,7231
t_dht_norm - neurônio oculto 69	0,4348	p_bmp_norm - neurônio oculto 76	0,7380
h_dht_norm - neurônio oculto 69	-2,7698	t_dht_norm - neurônio oculto 76	1,6160
O3_ugcm_norm - neurônio oculto 69	-9,9833	h_dht_norm - neurônio oculto 76	-3,5487
t_bmp_norm - neurônio oculto 70	-1,4910	O3_ugcm_norm - neurônio oculto 76	-5,4096
p_bmp_norm - neurônio oculto 70	1,7367	t_bmp_norm - neurônio oculto 77	-2,2080
t_dht_norm - neurônio oculto 70	-0,7383	p_bmp_norm - neurônio oculto 77	6,2734
h_dht_norm - neurônio oculto 70	-1,3266	t_dht_norm - neurônio oculto 77	-0,1999
O3_ugcm_norm - neurônio oculto 70	-3,7207	h_dht_norm - neurônio oculto 77	-3,1911
t_bmp_norm - neurônio oculto 71	-0,5010	O3_ugcm_norm - neurônio oculto 77	-18,4471
p_bmp_norm - neurônio oculto 71	1,7024	t_bmp_norm - neurônio oculto 78	-1,0330
t_dht_norm - neurônio oculto 71	-0,1207	p_bmp_norm - neurônio oculto 78	0,4599
h_dht_norm - neurônio oculto 71	-2,0153	t_dht_norm - neurônio oculto 78	2,2428
O3_ugcm_norm - neurônio oculto 71	-0,8380	h_dht_norm - neurônio oculto 78	-2,7094
t_bmp_norm - neurônio oculto 72	-0,6836	O3_ugcm_norm - neurônio oculto 78	-11,6477
p_bmp_norm - neurônio oculto 72	1,6507	t_bmp_norm - neurônio oculto 79	-0,7379
t_dht_norm - neurônio oculto 72	0,1260	p_bmp_norm - neurônio oculto 79	1,1227

Quadro D.1. Continuação

MLP 5-86-1	Pesos	MLP 5-86-1	Pesos
t_dht_norm - neurônio oculto 79	-0,0367	p_bmp_norm - neurônio oculto 86	0,6487
h_dht_norm - neurônio oculto 79	-1,6993	t_dht_norm - neurônio oculto 86	0,7087
O3_ugcm_norm - neurônio oculto 79	-1,5917	h_dht_norm - neurônio oculto 86	-3,0818
t_bmp_norm - neurônio oculto 80	0,2790	O3_ugcm_norm - neurônio oculto 86	-4,7108
p_bmp_norm - neurônio oculto 80	1,7854	neurônio oculto 1 - O3_new	-0,0486
t_dht_norm - neurônio oculto 80	0,9545	neurônio oculto 2 - O3_new	0,3513
h_dht_norm - neurônio oculto 80	-2,3854	neurônio oculto 3 - O3_new	1,3866
O3_ugcm_norm - neurônio oculto 80	0,1375	neurônio oculto 4 - O3_new	-1,5775
t_bmp_norm - neurônio oculto 81	-1,1740	neurônio oculto 5 - O3_new	2,2248
p_bmp_norm - neurônio oculto 81	3,7046	neurônio oculto 6 - O3_new	0,7327
t_dht_norm - neurônio oculto 81	-0,8438	neurônio oculto 7 - O3_new	-1,7112
h_dht_norm - neurônio oculto 81	-1,2276	neurônio oculto 8 - O3_new	0,4911
O3_ugcm_norm - neurônio oculto 81	-2,9025	neurônio oculto 9 - O3_new	-0,0143
t_bmp_norm - neurônio oculto 82	-0,2746	neurônio oculto 10 - O3_new	-0,8750
p_bmp_norm - neurônio oculto 82	2,7547	neurônio oculto 11 - O3_new	-1,9782
t_dht_norm - neurônio oculto 82	0,3964	neurônio oculto 12 - O3_new	-1,8184
h_dht_norm - neurônio oculto 82	-3,0402	neurônio oculto 13 - O3_new	-0,1003
O3_ugcm_norm - neurônio oculto 82	-5,4648	neurônio oculto 14 - O3_new	2,7133
t_bmp_norm - neurônio oculto 83	-0,5649	neurônio oculto 15 - O3_new	0,2261
p_bmp_norm - neurônio oculto 83	1,4297	neurônio oculto 16 - O3_new	0,3365
t_dht_norm - neurônio oculto 83	-0,0412	neurônio oculto 17 - O3_new	0,6687
h_dht_norm - neurônio oculto 83	-0,5729	neurônio oculto 18 - O3_new	-2,3201
O3_ugcm_norm - neurônio oculto 83	-3,9835	neurônio oculto 19 - O3_new	-0,3435
t_bmp_norm - neurônio oculto 84	-1,4687	neurônio oculto 20 - O3_new	-0,6026
p_bmp_norm - neurônio oculto 84	1,5748	neurônio oculto 21 - O3_new	-0,3839
t_dht_norm - neurônio oculto 84	1,1350	neurônio oculto 22 - O3_new	0,2217
h_dht_norm - neurônio oculto 84	-1,4926	neurônio oculto 23 - O3_new	0,6475
O3_ugcm_norm - neurônio oculto 84	-6,3499	neurônio oculto 24 - O3_new	-0,3274
t_bmp_norm - neurônio oculto 85	-4,3802	neurônio oculto 25 - O3_new	-0,9130
p_bmp_norm - neurônio oculto 85	1,0738	neurônio oculto 26 - O3_new	-0,9449
t_dht_norm - neurônio oculto 85	-1,0210	neurônio oculto 27 - O3_new	0,9969
h_dht_norm - neurônio oculto 85	-2,5416	neurônio oculto 28 - O3_new	-0,1494
O3_ugcm_norm - neurônio oculto 85	-19,6248	neurônio oculto 29 - O3_new	3,0164
t_bmp_norm - neurônio oculto 86	-1,5897	neurônio oculto 30 - O3_new	-1,2718

Quadro D.1. Continuação

MLP 5-86-1	Pesos	MLP 5-86-1	Pesos
neurônio oculto 31 - O3_new	-0,7786	neurônio oculto 65 - O3_new	-0,0366
neurônio oculto 32 - O3_new	-1,5029	neurônio oculto 66 - O3_new	1,7034
neurônio oculto 33 - O3_new	-0,2892	neurônio oculto 67 - O3_new	-0,3620
neurônio oculto 34 - O3_new	1,2702	neurônio oculto 68 - O3_new	-0,7780
neurônio oculto 35 - O3_new	0,6653	neurônio oculto 69 - O3_new	0,7042
neurônio oculto 36 - O3_new	-1,3415	neurônio oculto 70 - O3_new	-0,6677
neurônio oculto 37 - O3_new	1,2140	neurônio oculto 71 - O3_new	0,3985
neurônio oculto 38 - O3_new	0,3539	neurônio oculto 72 - O3_new	0,3812
neurônio oculto 39 - O3_new	0,5574	neurônio oculto 73 - O3_new	-0,0761
neurônio oculto 40 - O3_new	-1,4752	neurônio oculto 74 - O3_new	0,1230
neurônio oculto 41 - O3_new	-0,8651	neurônio oculto 75 - O3_new	-0,3872
neurônio oculto 42 - O3_new	-0,9405	neurônio oculto 76 - O3_new	1,0423
neurônio oculto 43 - O3_new	-1,1507	neurônio oculto 77 - O3_new	0,3675
neurônio oculto 44 - O3_new	-1,9055	neurônio oculto 78 - O3_new	0,3019
neurônio oculto 45 - O3_new	-0,0405	neurônio oculto 79 - O3_new	0,9884
neurônio oculto 46 - O3_new	2,2646	neurônio oculto 80 - O3_new	1,0078
neurônio oculto 47 - O3_new	-2,2877	neurônio oculto 81 - O3_new	-0,5449
neurônio oculto 48 - O3_new	0,1468	neurônio oculto 82 - O3_new	0,9899
neurônio oculto 49 - O3_new	0,1823	neurônio oculto 83 - O3_new	0,4799
neurônio oculto 50 - O3_new	-1,1044	neurônio oculto 84 - O3_new	-1,8260
neurônio oculto 51 - O3_new	2,0381	neurônio oculto 85 - O3_new	2,4831
neurônio oculto 52 - O3_new	0,5109	neurônio oculto 86 - O3_new	0,1528
neurônio oculto 53 - O3_new	0,8210		
neurônio oculto 54 - O3_new	3,2083		
neurônio oculto 55 - O3_new	1,3263		
neurônio oculto 56 - O3_new	-0,4991		
neurônio oculto 57 - O3_new	-1,9477		
neurônio oculto 58 - O3_new	-0,8054		
neurônio oculto 59 - O3_new	-0,5680		
neurônio oculto 60 - O3_new	-0,5263		
neurônio oculto 61 - O3_new	-0,2452		
neurônio oculto 62 - O3_new	-2,1243		
neurônio oculto 63 - O3_new	-0,4195		
neurônio oculto 64 - O3_new	0,4344		

Quadro D.2 - “Bias” de cada conexão da rede MLP 5-86-1, desenvolvida para predição de O3_new (continua).

MLP 5-86-1	"Bias"	MLP 5-86-1	"Bias"
“bias” de entrada - neurônio oculto 1	1,2009	“bias” de entrada - neurônio oculto 34	-0,3778
“bias” de entrada - neurônio oculto 2	0,8499	“bias” de entrada - neurônio oculto 35	0,2772
“bias” de entrada - neurônio oculto 3	0,6508	“bias” de entrada - neurônio oculto 36	-0,1696
“bias” de entrada - neurônio oculto 4	-1,4014	“bias” de entrada - neurônio oculto 37	1,2447
“bias” de entrada - neurônio oculto 5	-1,1453	“bias” de entrada - neurônio oculto 38	0,5279
“bias” de entrada - neurônio oculto 6	1,0880	“bias” de entrada - neurônio oculto 39	0,0165
“bias” de entrada - neurônio oculto 7	-0,8227	“bias” de entrada - neurônio oculto 40	-1,6814
“bias” de entrada - neurônio oculto 8	0,8282	“bias” de entrada - neurônio oculto 41	-1,7769
“bias” de entrada - neurônio oculto 9	0,8923	“bias” de entrada - neurônio oculto 42	-0,0992
“bias” de entrada - neurônio oculto 10	-0,2010	“bias” de entrada - neurônio oculto 43	0,9257
“bias” de entrada - neurônio oculto 11	0,0696	“bias” de entrada - neurônio oculto 44	2,0009
“bias” de entrada - neurônio oculto 12	0,4575	“bias” de entrada - neurônio oculto 45	-1,6916
“bias” de entrada - neurônio oculto 13	1,6540	“bias” de entrada - neurônio oculto 46	1,3445
“bias” de entrada - neurônio oculto 14	1,2048	“bias” de entrada - neurônio oculto 47	0,0864
“bias” de entrada - neurônio oculto 15	0,3934	“bias” de entrada - neurônio oculto 48	-0,4186
“bias” de entrada - neurônio oculto 16	-1,2559	“bias” de entrada - neurônio oculto 49	0,1494
“bias” de entrada - neurônio oculto 17	1,0972	“bias” de entrada - neurônio oculto 50	1,5716
“bias” de entrada - neurônio oculto 18	0,8122	“bias” de entrada - neurônio oculto 51	-1,9074
“bias” de entrada - neurônio oculto 19	-0,5097	“bias” de entrada - neurônio oculto 52	-0,6392
“bias” de entrada - neurônio oculto 20	1,4128	“bias” de entrada - neurônio oculto 53	1,1200
“bias” de entrada - neurônio oculto 21	0,6180	“bias” de entrada - neurônio oculto 54	1,0615
“bias” de entrada - neurônio oculto 22	-0,1513	“bias” de entrada - neurônio oculto 55	-0,0186
“bias” de entrada - neurônio oculto 23	-1,0784	“bias” de entrada - neurônio oculto 56	-0,7247
“bias” de entrada - neurônio oculto 24	0,5916	“bias” de entrada - neurônio oculto 57	0,5659
“bias” de entrada - neurônio oculto 25	-0,9538	“bias” de entrada - neurônio oculto 58	1,1945
“bias” de entrada - neurônio oculto 26	1,1063	“bias” de entrada - neurônio oculto 59	-0,1091
“bias” de entrada - neurônio oculto 27	-2,1121	“bias” de entrada - neurônio oculto 60	1,1317
“bias” de entrada - neurônio oculto 28	1,7197	“bias” de entrada - neurônio oculto 61	1,8762
“bias” de entrada - neurônio oculto 29	-0,5433	“bias” de entrada - neurônio oculto 62	0,0889
“bias” de entrada - neurônio oculto 30	0,7900	“bias” de entrada - neurônio oculto 63	1,5057
“bias” de entrada - neurônio oculto 31	0,9611	“bias” de entrada - neurônio oculto 64	2,4508
“bias” de entrada - neurônio oculto 32	-1,8053	“bias” de entrada - neurônio oculto 65	0,7944
“bias” de entrada - neurônio oculto 33	-0,8525	“bias” de entrada - neurônio oculto 66	-0,1965

Quadro D.2. Continuação

MLP 5-86-1	"Bias"
"bias" de entrada - neurônio oculto 67	-0,0595
"bias" de entrada - neurônio oculto 68	0,3884
"bias" de entrada - neurônio oculto 69	-0,0300
"bias" de entrada - neurônio oculto 70	-0,8733
"bias" de entrada - neurônio oculto 71	0,5894
"bias" de entrada - neurônio oculto 72	1,0607
"bias" de entrada - neurônio oculto 73	0,5154
"bias" de entrada - neurônio oculto 74	1,1226
"bias" de entrada - neurônio oculto 75	0,0649
"bias" de entrada - neurônio oculto 76	0,2996
"bias" de entrada - neurônio oculto 77	-3,6390
"bias" de entrada - neurônio oculto 78	0,3372
"bias" de entrada - neurônio oculto 79	1,1162
"bias" de entrada - neurônio oculto 80	0,0909
"bias" de entrada - neurônio oculto 81	0,0383
"bias" de entrada - neurônio oculto 82	0,1461
"bias" de entrada - neurônio oculto 83	1,2768
"bias" de entrada - neurônio oculto 84	0,4580
"bias" de entrada - neurônio oculto 85	1,2683
"bias" de entrada - neurônio oculto 86	0,1672
"bias" oculto - O3_new	-3,2104

APÊNDICE E

Parâmetros da RNA final para CO_new

O Quadro E.1 e o Quadro E.2 apresentam, respectivamente, os pesos e os “*bias*” de cada conexão da melhor rede obtida para a predição do monóxido de carbono (MLP 5-62-1).

Quadro E.1 - Pesos de cada conexão da rede MLP 5-62-1, desenvolvida para predição de CO_new (continua).

MLP 5-62-1	Pesos	MLP 5-62-1	Pesos
t_bmp_norm - neurônio oculto 1	-4,8199	p_bmp_norm - neurônio oculto 6	-27,0691
p_bmp_norm - neurônio oculto 1	-11,7958	t_dht_norm - neurônio oculto 6	-3,3414
t_dht_norm - neurônio oculto 1	0,2639	h_dht_norm - neurônio oculto 6	9,3350
h_dht_norm - neurônio oculto 1	3,3472	CO_ppm_norm - neurônio oculto 6	21,9158
CO_ppm_norm - neurônio oculto 1	-46,2638	t_bmp_norm - neurônio oculto 7	-6,1815
t_bmp_norm - neurônio oculto 2	-3,7996	p_bmp_norm - neurônio oculto 7	-8,3613
p_bmp_norm - neurônio oculto 2	-26,0665	t_dht_norm - neurônio oculto 7	-3,1408
t_dht_norm - neurônio oculto 2	-2,4989	h_dht_norm - neurônio oculto 7	1,8408
h_dht_norm - neurônio oculto 2	16,8433	CO_ppm_norm - neurônio oculto 7	-37,2586
CO_ppm_norm - neurônio oculto 2	3,0958	t_bmp_norm - neurônio oculto 8	-2,7707
t_bmp_norm - neurônio oculto 3	-3,5729	p_bmp_norm - neurônio oculto 8	-16,0590
p_bmp_norm - neurônio oculto 3	-28,6448	t_dht_norm - neurônio oculto 8	-0,2365
t_dht_norm - neurônio oculto 3	-2,0775	h_dht_norm - neurônio oculto 8	0,6343
h_dht_norm - neurônio oculto 3	10,6868	CO_ppm_norm - neurônio oculto 8	-58,3670
CO_ppm_norm - neurônio oculto 3	0,8548	t_bmp_norm - neurônio oculto 9	-6,1173
t_bmp_norm - neurônio oculto 4	-3,8810	p_bmp_norm - neurônio oculto 9	-8,4044
p_bmp_norm - neurônio oculto 4	-22,5337	t_dht_norm - neurônio oculto 9	-2,6089
t_dht_norm - neurônio oculto 4	0,6662	h_dht_norm - neurônio oculto 9	-0,9407
h_dht_norm - neurônio oculto 4	8,1793	CO_ppm_norm - neurônio oculto 9	-52,5238
CO_ppm_norm - neurônio oculto 4	-13,1817	t_bmp_norm - neurônio oculto 10	-7,0751
t_bmp_norm - neurônio oculto 5	4,9598	p_bmp_norm - neurônio oculto 10	-33,2875
p_bmp_norm - neurônio oculto 5	-8,8929	t_dht_norm - neurônio oculto 10	-4,5975
t_dht_norm - neurônio oculto 5	-0,3945	h_dht_norm - neurônio oculto 10	12,6206
h_dht_norm - neurônio oculto 5	4,3642	CO_ppm_norm - neurônio oculto 10	6,0376
CO_ppm_norm - neurônio oculto 5	-45,1238	t_bmp_norm - neurônio oculto 11	-2,5081
t_bmp_norm - neurônio oculto 6	-5,7308	p_bmp_norm - neurônio oculto 11	-17,0437

Quadro E.1. Continuação

MLP 5-62-1	Pesos	MLP 5-62-1	Pesos
t_dht_norm - neurônio oculto 11	-2,1609	p_bmp_norm - neurônio oculto 18	-21,2147
h_dht_norm - neurônio oculto 11	4,7562	t_dht_norm - neurônio oculto 18	-2,9321
CO_ppm_norm - neurônio oculto 11	-19,8531	h_dht_norm - neurônio oculto 18	2,4125
t_bmp_norm - neurônio oculto 12	-9,0745	CO_ppm_norm - neurônio oculto 18	-24,1477
p_bmp_norm - neurônio oculto 12	-30,4150	t_bmp_norm - neurônio oculto 19	-4,4727
t_dht_norm - neurônio oculto 12	-4,0936	p_bmp_norm - neurônio oculto 19	-20,8444
h_dht_norm - neurônio oculto 12	8,7029	t_dht_norm - neurônio oculto 19	-2,5351
CO_ppm_norm - neurônio oculto 12	7,1422	h_dht_norm - neurônio oculto 19	7,1282
t_bmp_norm - neurônio oculto 13	3,5651	CO_ppm_norm - neurônio oculto 19	-22,0757
p_bmp_norm - neurônio oculto 13	-33,5383	t_bmp_norm - neurônio oculto 20	-4,9335
t_dht_norm - neurônio oculto 13	3,2181	p_bmp_norm - neurônio oculto 20	-15,5865
h_dht_norm - neurônio oculto 13	8,3688	t_dht_norm - neurônio oculto 20	-0,1407
CO_ppm_norm - neurônio oculto 13	6,3839	h_dht_norm - neurônio oculto 20	1,7223
t_bmp_norm - neurônio oculto 14	-10,2789	CO_ppm_norm - neurônio oculto 20	-61,4113
p_bmp_norm - neurônio oculto 14	-11,3846	t_bmp_norm - neurônio oculto 21	-3,3668
t_dht_norm - neurônio oculto 14	-5,8721	p_bmp_norm - neurônio oculto 21	-19,3726
h_dht_norm - neurônio oculto 14	-4,0837	t_dht_norm - neurônio oculto 21	-0,9656
CO_ppm_norm - neurônio oculto 14	-36,4998	h_dht_norm - neurônio oculto 21	2,2825
t_bmp_norm - neurônio oculto 15	-9,5838	CO_ppm_norm - neurônio oculto 21	-35,9504
p_bmp_norm - neurônio oculto 15	-33,8054	t_bmp_norm - neurônio oculto 22	-3,7935
t_dht_norm - neurônio oculto 15	-7,3276	p_bmp_norm - neurônio oculto 22	-23,0244
h_dht_norm - neurônio oculto 15	8,9200	t_dht_norm - neurônio oculto 22	3,9754
CO_ppm_norm - neurônio oculto 15	17,6439	h_dht_norm - neurônio oculto 22	7,3761
t_bmp_norm - neurônio oculto 16	-7,5458	CO_ppm_norm - neurônio oculto 22	12,4938
p_bmp_norm - neurônio oculto 16	-9,2644	t_bmp_norm - neurônio oculto 23	-9,3233
t_dht_norm - neurônio oculto 16	-3,9182	p_bmp_norm - neurônio oculto 23	-29,2783
h_dht_norm - neurônio oculto 16	2,2240	t_dht_norm - neurônio oculto 23	-8,5756
CO_ppm_norm - neurônio oculto 16	-44,4503	h_dht_norm - neurônio oculto 23	6,9316
t_bmp_norm - neurônio oculto 17	-5,4542	CO_ppm_norm - neurônio oculto 23	5,5761
p_bmp_norm - neurônio oculto 17	-17,2507	t_bmp_norm - neurônio oculto 24	-4,3474
t_dht_norm - neurônio oculto 17	-2,5222	p_bmp_norm - neurônio oculto 24	-28,7642
h_dht_norm - neurônio oculto 17	3,8931	t_dht_norm - neurônio oculto 24	-2,8818
CO_ppm_norm - neurônio oculto 17	-34,0034	h_dht_norm - neurônio oculto 24	10,2093
t_bmp_norm - neurônio oculto 18	-3,8671	CO_ppm_norm - neurônio oculto 24	2,8361

Quadro E.1. Continuação

MLP 5-62-1	Pesos	MLP 5-62-1	Pesos
t_bmp_norm - neurônio oculto 25	-3,3524	CO_ppm_norm - neurônio oculto 31	-24,2273
p_bmp_norm - neurônio oculto 25	-10,8363	t_bmp_norm - neurônio oculto 32	-4,7277
t_dht_norm - neurônio oculto 25	-4,5408	p_bmp_norm - neurônio oculto 32	-26,0776
h_dht_norm - neurônio oculto 25	0,6492	t_dht_norm - neurônio oculto 32	-3,4661
CO_ppm_norm - neurônio oculto 25	-68,5212	h_dht_norm - neurônio oculto 32	10,3659
t_bmp_norm - neurônio oculto 26	-2,7961	CO_ppm_norm - neurônio oculto 32	-6,7148
p_bmp_norm - neurônio oculto 26	-27,3077	t_bmp_norm - neurônio oculto 33	-4,4108
t_dht_norm - neurônio oculto 26	1,7413	p_bmp_norm - neurônio oculto 33	-17,9273
h_dht_norm - neurônio oculto 26	10,1047	t_dht_norm - neurônio oculto 33	-2,2362
CO_ppm_norm - neurônio oculto 26	-4,0499	h_dht_norm - neurônio oculto 33	5,6038
t_bmp_norm - neurônio oculto 27	2,8810	CO_ppm_norm - neurônio oculto 33	-26,2866
p_bmp_norm - neurônio oculto 27	-3,1838	t_bmp_norm - neurônio oculto 34	-1,4292
t_dht_norm - neurônio oculto 27	-0,6609	p_bmp_norm - neurônio oculto 34	-12,8903
h_dht_norm - neurônio oculto 27	1,3984	t_dht_norm - neurônio oculto 34	3,2604
CO_ppm_norm - neurônio oculto 27	-53,3634	h_dht_norm - neurônio oculto 34	8,6198
t_bmp_norm - neurônio oculto 28	-4,6864	CO_ppm_norm - neurônio oculto 34	-32,9882
p_bmp_norm - neurônio oculto 28	-27,0276	t_bmp_norm - neurônio oculto 35	-8,0988
t_dht_norm - neurônio oculto 28	-4,6176	p_bmp_norm - neurônio oculto 35	-15,2831
h_dht_norm - neurônio oculto 28	9,1370	t_dht_norm - neurônio oculto 35	-5,1700
CO_ppm_norm - neurônio oculto 28	-8,1450	h_dht_norm - neurônio oculto 35	1,4697
t_bmp_norm - neurônio oculto 29	-15,2334	CO_ppm_norm - neurônio oculto 35	-18,2521
p_bmp_norm - neurônio oculto 29	-31,3393	t_bmp_norm - neurônio oculto 36	-8,9364
t_dht_norm - neurônio oculto 29	-15,0420	p_bmp_norm - neurônio oculto 36	-11,9791
h_dht_norm - neurônio oculto 29	8,5170	t_dht_norm - neurônio oculto 36	-6,6406
CO_ppm_norm - neurônio oculto 29	6,5157	h_dht_norm - neurônio oculto 36	4,5828
t_bmp_norm - neurônio oculto 30	-11,1295	CO_ppm_norm - neurônio oculto 36	-28,4131
p_bmp_norm - neurônio oculto 30	-8,1566	t_bmp_norm - neurônio oculto 37	-7,0736
t_dht_norm - neurônio oculto 30	-5,9639	p_bmp_norm - neurônio oculto 37	-14,2223
h_dht_norm - neurônio oculto 30	-1,2587	t_dht_norm - neurônio oculto 37	-4,7230
CO_ppm_norm - neurônio oculto 30	-43,2089	h_dht_norm - neurônio oculto 37	6,1241
t_bmp_norm - neurônio oculto 31	-4,7253	CO_ppm_norm - neurônio oculto 37	-25,5389
p_bmp_norm - neurônio oculto 31	-17,5797	t_bmp_norm - neurônio oculto 38	-0,2819
t_dht_norm - neurônio oculto 31	-3,0923	p_bmp_norm - neurônio oculto 38	-5,8959
h_dht_norm - neurônio oculto 31	7,4144	t_dht_norm - neurônio oculto 38	6,2015

Quadro E.1. Continuação

MLP 5-62-1	Pesos	MLP 5-62-1	Pesos
h_dht_norm - neurônio oculto 38	-2,0927	t_dht_norm - neurônio oculto 45	2,4546
CO_ppm_norm - neurônio oculto 38	-23,7316	h_dht_norm - neurônio oculto 45	10,7266
t_bmp_norm - neurônio oculto 39	-1,4473	CO_ppm_norm - neurônio oculto 45	-9,2452
p_bmp_norm - neurônio oculto 39	-24,7734	t_bmp_norm - neurônio oculto 46	-4,0517
t_dht_norm - neurônio oculto 39	-0,9610	p_bmp_norm - neurônio oculto 46	-20,9631
h_dht_norm - neurônio oculto 39	7,6778	t_dht_norm - neurônio oculto 46	-3,7498
CO_ppm_norm - neurônio oculto 39	-2,4694	h_dht_norm - neurônio oculto 46	8,3379
t_bmp_norm - neurônio oculto 40	-3,6502	CO_ppm_norm - neurônio oculto 46	-11,9650
p_bmp_norm - neurônio oculto 40	-22,1900	t_bmp_norm - neurônio oculto 47	1,1139
t_dht_norm - neurônio oculto 40	-2,3870	p_bmp_norm - neurônio oculto 47	-22,7948
h_dht_norm - neurônio oculto 40	9,4504	t_dht_norm - neurônio oculto 47	11,3436
CO_ppm_norm - neurônio oculto 40	-9,3928	h_dht_norm - neurônio oculto 47	7,0412
t_bmp_norm - neurônio oculto 41	3,0303	CO_ppm_norm - neurônio oculto 47	-63,9867
p_bmp_norm - neurônio oculto 41	-24,8118	t_bmp_norm - neurônio oculto 48	-3,2057
t_dht_norm - neurônio oculto 41	-1,2721	p_bmp_norm - neurônio oculto 48	-13,8137
h_dht_norm - neurônio oculto 41	6,7558	t_dht_norm - neurônio oculto 48	-3,5956
CO_ppm_norm - neurônio oculto 41	-13,4615	h_dht_norm - neurônio oculto 48	6,2642
t_bmp_norm - neurônio oculto 42	-7,2043	CO_ppm_norm - neurônio oculto 48	-70,3356
p_bmp_norm - neurônio oculto 42	-25,4202	t_bmp_norm - neurônio oculto 49	-4,7340
t_dht_norm - neurônio oculto 42	-3,6492	p_bmp_norm - neurônio oculto 49	-24,2801
h_dht_norm - neurônio oculto 42	7,0279	t_dht_norm - neurônio oculto 49	-3,5334
CO_ppm_norm - neurônio oculto 42	3,1435	h_dht_norm - neurônio oculto 49	7,8880
t_bmp_norm - neurônio oculto 43	-4,5491	CO_ppm_norm - neurônio oculto 49	-8,2364
p_bmp_norm - neurônio oculto 43	-18,3829	t_bmp_norm - neurônio oculto 50	-13,2775
t_dht_norm - neurônio oculto 43	-3,6160	p_bmp_norm - neurônio oculto 50	-34,4075
h_dht_norm - neurônio oculto 43	6,3478	t_dht_norm - neurônio oculto 50	-16,4561
CO_ppm_norm - neurônio oculto 43	-20,2163	h_dht_norm - neurônio oculto 50	3,8273
t_bmp_norm - neurônio oculto 44	-7,0397	CO_ppm_norm - neurônio oculto 50	17,4247
p_bmp_norm - neurônio oculto 44	-31,2054	t_bmp_norm - neurônio oculto 51	0,1887
t_dht_norm - neurônio oculto 44	-5,4784	p_bmp_norm - neurônio oculto 51	-11,7443
h_dht_norm - neurônio oculto 44	10,4422	t_dht_norm - neurônio oculto 51	-3,4238
CO_ppm_norm - neurônio oculto 44	14,5141	h_dht_norm - neurônio oculto 51	5,7958
t_bmp_norm - neurônio oculto 45	-4,1385	CO_ppm_norm - neurônio oculto 51	-41,4938
p_bmp_norm - neurônio oculto 45	-30,7076	t_bmp_norm - neurônio oculto 52	-3,4650

Quadro E.1. Continuação

MLP 5-62-1	Pesos	MLP 5-62-1	Pesos
p_bmp_norm - neurônio oculto 52	-20,5514	t_bmp_norm - neurônio oculto 59	-3,4696
t_dht_norm - neurônio oculto 52	-0,7403	p_bmp_norm - neurônio oculto 59	-22,0338
h_dht_norm - neurônio oculto 52	1,7131	t_dht_norm - neurônio oculto 59	-2,8741
CO_ppm_norm - neurônio oculto 52	-35,6747	h_dht_norm - neurônio oculto 59	10,0226
t_bmp_norm - neurônio oculto 53	-4,3680	CO_ppm_norm - neurônio oculto 59	-10,6057
p_bmp_norm - neurônio oculto 53	-36,3170	t_bmp_norm - neurônio oculto 60	-9,3813
t_dht_norm - neurônio oculto 53	4,6290	p_bmp_norm - neurônio oculto 60	-28,6277
h_dht_norm - neurônio oculto 53	12,3051	t_dht_norm - neurônio oculto 60	-0,3866
CO_ppm_norm - neurônio oculto 53	-2,2021	h_dht_norm - neurônio oculto 60	11,6085
t_bmp_norm - neurônio oculto 54	-6,4978	CO_ppm_norm - neurônio oculto 60	5,0552
p_bmp_norm - neurônio oculto 54	-24,5520	t_bmp_norm - neurônio oculto 61	-0,7011
t_dht_norm - neurônio oculto 54	-5,4150	p_bmp_norm - neurônio oculto 61	1,3082
h_dht_norm - neurônio oculto 54	8,2087	t_dht_norm - neurônio oculto 61	-0,5071
CO_ppm_norm - neurônio oculto 54	-14,4604	h_dht_norm - neurônio oculto 61	-1,5740
t_bmp_norm - neurônio oculto 55	-2,7389	CO_ppm_norm - neurônio oculto 61	-125,7515
p_bmp_norm - neurônio oculto 55	-24,9921	t_bmp_norm - neurônio oculto 62	-4,4707
t_dht_norm - neurônio oculto 55	1,4727	p_bmp_norm - neurônio oculto 62	-24,1691
h_dht_norm - neurônio oculto 55	6,3173	t_dht_norm - neurônio oculto 62	-2,4103
CO_ppm_norm - neurônio oculto 55	-11,7364	h_dht_norm - neurônio oculto 62	11,3288
t_bmp_norm - neurônio oculto 56	-5,6506	CO_ppm_norm - neurônio oculto 62	-12,0220
p_bmp_norm - neurônio oculto 56	-17,9304	neurônio oculto 1 - CO_new	0,3651
t_dht_norm - neurônio oculto 56	-3,5174	neurônio oculto 2 - CO_new	-0,0518
h_dht_norm - neurônio oculto 56	4,2647	neurônio oculto 3 - CO_new	-0,8799
CO_ppm_norm - neurônio oculto 56	-22,3134	neurônio oculto 4 - CO_new	6,0964
t_bmp_norm - neurônio oculto 57	-3,5039	neurônio oculto 5 - CO_new	1,6099
p_bmp_norm - neurônio oculto 57	-19,3933	neurônio oculto 6 - CO_new	-17,9303
t_dht_norm - neurônio oculto 57	-2,9825	neurônio oculto 7 - CO_new	-2,0447
h_dht_norm - neurônio oculto 57	7,9231	neurônio oculto 8 - CO_new	-8,2656
CO_ppm_norm - neurônio oculto 57	-15,4797	neurônio oculto 9 - CO_new	-6,9747
t_bmp_norm - neurônio oculto 58	-3,9131	neurônio oculto 10 - CO_new	0,0358
p_bmp_norm - neurônio oculto 58	-18,3429	neurônio oculto 11 - CO_new	9,1727
t_dht_norm - neurônio oculto 58	-2,8952	neurônio oculto 12 - CO_new	-7,2632
h_dht_norm - neurônio oculto 58	6,4531	neurônio oculto 13 - CO_new	-4,4398
CO_ppm_norm - neurônio oculto 58	-18,6886	neurônio oculto 14 - CO_new	13,7628

Quadro E.1. Continuação

MLP 5-62-1	Pesos	MLP 5-62-1	Pesos
neurônio oculto 15 - CO_new	-11,5561	neurônio oculto 49 - CO_new	3,3006
neurônio oculto 16 - CO_new	6,3589	neurônio oculto 50 - CO_new	7,1720
neurônio oculto 17 - CO_new	1,0911	neurônio oculto 51 - CO_new	-5,9216
neurônio oculto 18 - CO_new	9,5493	neurônio oculto 52 - CO_new	3,6945
neurônio oculto 19 - CO_new	5,1057	neurônio oculto 53 - CO_new	7,7583
neurônio oculto 20 - CO_new	-8,0876	neurônio oculto 54 - CO_new	0,6060
neurônio oculto 21 - CO_new	4,5421	neurônio oculto 55 - CO_new	4,9935
neurônio oculto 22 - CO_new	-11,2301	neurônio oculto 56 - CO_new	13,9392
neurônio oculto 23 - CO_new	-1,7077	neurônio oculto 57 - CO_new	3,8381
neurônio oculto 24 - CO_new	-0,5303	neurônio oculto 58 - CO_new	5,4423
neurônio oculto 25 - CO_new	-9,8169	neurônio oculto 59 - CO_new	2,5372
neurônio oculto 26 - CO_new	-6,8273	neurônio oculto 60 - CO_new	-2,7764
neurônio oculto 27 - CO_new	-3,1671	neurônio oculto 61 - CO_new	-35,4445
neurônio oculto 28 - CO_new	6,6340	neurônio oculto 62 - CO_new	3,2447
neurônio oculto 29 - CO_new	5,3643		
neurônio oculto 30 - CO_new	5,5735		
neurônio oculto 31 - CO_new	3,4979		
neurônio oculto 32 - CO_new	4,1277		
neurônio oculto 33 - CO_new	6,1891		
neurônio oculto 34 - CO_new	-0,1101		
neurônio oculto 35 - CO_new	7,8702		
neurônio oculto 36 - CO_new	5,2681		
neurônio oculto 37 - CO_new	2,9975		
neurônio oculto 38 - CO_new	0,3005		
neurônio oculto 39 - CO_new	-1,3421		
neurônio oculto 40 - CO_new	3,0749		
neurônio oculto 41 - CO_new	3,8756		
neurônio oculto 42 - CO_new	-7,8580		
neurônio oculto 43 - CO_new	1,6511		
neurônio oculto 44 - CO_new	-7,8857		
neurônio oculto 45 - CO_new	8,1496		
neurônio oculto 46 - CO_new	2,4799		
neurônio oculto 47 - CO_new	-0,2662		
neurônio oculto 48 - CO_new	-21,0424		

Quadro E.2 - “Bias” de cada conexão da rede MLP 5-62-1, desenvolvida para predição de CO_new.

MLP 5-62-1	"Bias"	MLP 5-62-1	"Bias"
“bias” de entrada - neurônio oculto 1	6,5858	“bias” de entrada - neurônio oculto 34	17,1130
“bias” de entrada - neurônio oculto 2	9,5504	“bias” de entrada - neurônio oculto 35	2,7722
“bias” de entrada - neurônio oculto 3	5,3567	“bias” de entrada - neurônio oculto 36	-3,6550
“bias” de entrada - neurônio oculto 4	2,8340	“bias” de entrada - neurônio oculto 37	-0,9126
“bias” de entrada - neurônio oculto 5	5,2588	“bias” de entrada - neurônio oculto 38	4,2417
“bias” de entrada - neurônio oculto 6	3,1837	“bias” de entrada - neurônio oculto 39	5,8400
“bias” de entrada - neurônio oculto 7	0,1868	“bias” de entrada - neurônio oculto 40	2,4335
“bias” de entrada - neurônio oculto 8	3,1653	“bias” de entrada - neurônio oculto 41	10,0408
“bias” de entrada - neurônio oculto 9	-0,2420	bias de entrada - neurônio oculto 42	7,4051
“bias” de entrada - neurônio oculto 10	2,5713	“bias” de entrada - neurônio oculto 43	2,6111
“bias” de entrada - neurônio oculto 11	-0,3965	“bias” de entrada - neurônio oculto 44	0,8425
“bias” de entrada - neurônio oculto 12	0,2646	“bias” de entrada - neurônio oculto 45	6,5730
“bias” de entrada - neurônio oculto 13	10,4935	“bias” de entrada - neurônio oculto 46	2,3526
“bias” de entrada - neurônio oculto 14	-10,5784	“bias” de entrada - neurônio oculto 47	13,2102
“bias” de entrada - neurônio oculto 15	-0,8287	“bias” de entrada - neurônio oculto 48	2,0567
“bias” de entrada - neurônio oculto 16	5,0559	“bias” de entrada - neurônio oculto 49	5,3205
“bias” de entrada - neurônio oculto 17	4,1402	“bias” de entrada - neurônio oculto 50	-12,2792
“bias” de entrada - neurônio oculto 18	0,2402	“bias” de entrada - neurônio oculto 51	4,0462
“bias” de entrada - neurônio oculto 19	3,2874	“bias” de entrada - neurônio oculto 52	3,4878
“bias” de entrada - neurônio oculto 20	2,1374	“bias” de entrada - neurônio oculto 53	10,8205
“bias” de entrada - neurônio oculto 21	2,4956	“bias” de entrada - neurônio oculto 54	4,1848
“bias” de entrada - neurônio oculto 22	3,5261	“bias” de entrada - neurônio oculto 55	5,5520
“bias” de entrada - neurônio oculto 23	-3,0427	“bias” de entrada - neurônio oculto 56	0,2350
“bias” de entrada - neurônio oculto 24	4,4426	“bias” de entrada - neurônio oculto 57	1,8503
“bias” de entrada - neurônio oculto 25	2,8579	“bias” de entrada - neurônio oculto 58	-0,0139
“bias” de entrada - neurônio oculto 26	7,8767	“bias” de entrada - neurônio oculto 59	3,3068
“bias” de entrada - neurônio oculto 27	3,9541	“bias” de entrada - neurônio oculto 60	8,0516
“bias” de entrada - neurônio oculto 28	3,3702	“bias” de entrada - neurônio oculto 61	-1,7278
“bias” de entrada - neurônio oculto 29	-5,9693	“bias” de entrada - neurônio oculto 62	6,8163
“bias” de entrada - neurônio oculto 30	-6,9694	“bias” oculto - CO_new	-1,9906
“bias” de entrada - neurônio oculto 31	2,2685		
“bias” de entrada - neurônio oculto 32	3,0566		
“bias” de entrada - neurônio oculto 33	0,8606		

APÊNDICE F

Código fonte final (com RNA)

O Código F.1 apresenta o código final desenvolvido no estudo, que possibilita o monitoramento da qualidade do ar e previsão das concentrações dos poluentes atmosféricos para os próximos 5 minutos, considerando modelos neurais.

Código F.1 - Código fonte final para o monitoramento da qualidade do ar e previsão das concentrações dos poluentes por modelos neurais.

```

1. //Bibliotecas:
2. #include <DHT.h>
3. #include <SPI.h>
4. #include <SD.h>
5. #include <Wire.h>
6. #include <Adafruit_BMP085.h>
7. #include <SoftwareSerial.h>
8.
9. //Setup dos componentes:
10. Adafruit_BMP085 bmp;
11.
12. #define DHTPIN 4 //Pino conectado ao sensor DHT-11
13. #define DHTTYPE DHT11
14. DHT dht(DHTPIN, DHTTYPE);
15.
16. #define DS1307_ADDRESS 0x68 //Relógio RTC DS1307
17. byte zero = 0x00;
18.
19. #define esp8266 Serial1 //Módulo de WiFi - ESP8266
20. #define DEBUG true
21.
22. const int chipSelect = 53; //Pino por ativar o cartão SD
23.
24. //Variáveis para os cálculos do sensor de material particulado (PPD42):
25. int PPD42_pin = 8; //Pino referente à medição de MP(2,5)
26. unsigned long duration;
27. unsigned long starttime;
28. unsigned long samptime_ms = 30000; //Tempo de medição de 30 segundos
29. unsigned long lowpulseoccupancy = 0;
30. float ratio = 0;
31. float concentration = 0;
32.
33. //Valores necessários para a conversão dos dados do MP para ug/m³:
34. double pi = 3.14159;
35. double fc = 3531.5; //Fator de correção [0,01 ft³/m³]
36. double massaPM25;
37.
38. //Definição dos pinos ligados aos sensores:
39. int MQ131_pin = A2; //Pino referente à medição de O3
40. int MICS5524_pin = A5; //Pino referente à medição de CO (MICS-5524)

```

```

41.
42. //Valores de RL (load resistance), em kilo ohms, segundo Datasheet dos sensores:
43. #define MQ131_RL (20.0)
44. #define MICS5524_RL (100.0)
45.
46. // Curvas dos gases, considerando a estrutura (y = a.x + b), representada como curva = {x1;y1;a):
47. float O3_curve[3] = {0.6990,0.8062,-0.8921};
48. float CO_curve[3] = {0.00,0.5563,-0.8403};
49.
50. //Dados de calibração dos sensores:
51. float const MQ131_Ro = 34.0; //Ro obtido pelo programa de calibração em ar
52. float const MICS5524_Ro = 800.0; //Ro médio segundo Datasheet
53.
54. //Outros dados para obtenção das concentrações dos gases:
55. #define MQ131 (0)
56. #define MICS5524 (1)
57. #define read_sample_interval (50)
58. #define read_sample_times (50)
59.
60. //Variáveis lidas:
61. int diadomes;
62. int mes;
63. int ano;
64. int horas;
65. int minutos;
66. int segundos;
67. float t_bmp;
68. float p_bmp;
69. float t_dht;
70. float h_dht;
71. float MP_ugcm;
72. float O3_ugcm;
73. float CO_ppm;
74. float indice_MP;
75. float indice_O3;
76. float indice_CO;
77. float IQAr_final;
78. char *diadasemana_print;
79. char *classe_final;
80.
81. //IEDs conectados ao Cartão SD:
82. int GreenPin = 13;
83. int WellowPin = 12;
84. int RedPin = 11;
85.
86. //Valores de I da tabela de IQAr:
87. float const lf_b = 50.0; //Valor final para a classe "boa"
88. float const li_r = 51.0; //Valor inicial para a classe "regular"
89. float const lf_r = 100.0; //Valor final para a classe "regular"
90. float const li_i = 101.0; //Valor inicial para a classe "inadequada"
91. float const lf_i = 199.0; //Valor final para a classe "inadequada"
92. float const li_m = 200.0; //Valor inicial para a classe "má"
93. float const lf_m = 299.0; //Valor final para a classe "má"
94.
95. //Valores de C da tabela de IQAr (ranges dos gases):
96. float MP_ranges[4] = {12.0,35.4,150.4,250.4}; //Range dos dados em ug/m³ (considerando a tabela da EPA
para PM2,5) - https://www.gpo.gov/fdsys/pkg/FR-2013-01-15/pdf/2012-30946.pdf

```

```

97. float O3_ranges[4] = {80.0,160.0,200.0,800.0}; //Range dos dados em ug/m³ - http://jeap.rio.rj.gov.br/je-metinfosmac/boletim
98. float CO_ranges[4] = {4.0,9.0,15.0,30.0}; //Range dos dados em PPM - http://jeap.rio.rj.gov.br/je-metinfosmac/boletim
99.
100.//Outros dados para obtenção do IQAr:
101.#define MP_gas (0)
102.#define O3_gas (1)
103.#define CO_gas (2)
104.
105.//Variáveis que serão calculadas:
106. float MP_new;
107. float O3_new;
108. float CO_new;
109.
110.//Ordem das matrizes (de acordo com o número de neurônios na camada de saída de cada rede):
111. #define O_MP (70) //Ordem para material particulado
112. #define O_O3 (86) //Ordem para ozônio
113. #define O_CO (62) //Ordem para monóxido de carbono
114.
115.//Função de ativação:
116. #define th (0) //Tangente hiperbólica
117. #define ex (1) //Exponencial
118. #define lo (2) //Logística
119.
120.//Matrizes para material particulado:
121. float Bias_1_MP[O_MP] = {-4.281502384956830,-3.527962697237340,-6.339016024328330,-0.310049997265898,-4.611371317881870,-17.141396311143900,-22.061778076826700,-0.532325680944216,2.410404640734030,1.725346974886150,-0.483656755698856,-4.732229761605390,-3.249531239280580,-1.237552505054260,5.318993010708190,-8.632016919443030,-1.005437993317210,2.103008379275760,8.345806625991400,7.018137989258770,-0.397113260341193,1.174535017795120,3.860740588141820,8.712780285292250,3.078698985379270,-4.636235730108100,-4.706178556635190,-1.432963891937560,0.894862934114613,-1.802696509414760,-1.382784893284490,1.363171401401030,-5.989580886457370,0.404729051985092,0.753834680340692,-2.888960226282840,-0.997263919009571,23.313986136442100,1.808043266962350,-4.096116315279360,7.534064221292130,1.483032182778150,0.618733634556763,-0.095638990684147,0.815509071436850,-0.141884148280026,2.088393401216130,3.058783348732080,1.653840909482350,0.682183649869931,8.041389045696680,-3.396413756279650,0.049550450395174,-0.663933942347309,-2.628779174119810,-14.486785303516400,0.363306467474281,1.912499013242590,-1.530763462761110,2.339794290122630,-0.698133160557883,-4.804703319972280,1.566634630591600,4.104741150491410,-1.495931649845720,14.541372556995400,4.311082706508750,-0.099189308109932,2.979508439371310,-2.717863245707280};
122. float C_MP[O_MP] = {-1.964549111182920,2.335346760946220,-0.116263744407200,-2.890904203461960,0.528365700182735,0.597731894772113,-0.357762933424238,-1.584100735782980,1.451731279524300,4.051110819644710,-1.702295758102240,0.771972798107774,-1.867862484224100,2.856681243826660,-0.461919329710449,3.647094628208900,2.409579548899720,-1.020405874736030,-5.180342661466340,-1.315075954229040,0.518448295581439,-1.215483872534870,-1.428134552710620,-2.556577051869970,1.335957492507350,3.807635397631440,-2.021210751990890,1.521967910948820,-0.029062976492905,0.794278264024285,1.129245238121030,0.006740341490370,4.848132226651590,0.863038783210331,1.304523010670340,5.189314285243500,2.942159535545070,-0.467865147060979,0.928837153419628,-3.276773813916510,-0.620624717678443,1.153843247244010,0.778515860747528,-0.923453322542234,1.388256711560460,-2.673571427992870,3.812187758261110,-3.374399749650070,-1.385706072277090,-2.341715133046840,-0.297387028444108,-3.084147865933880,2.342414277786560,-0.831891798426864,2.002875702208110,-1.003881201920660,4.963599241700210,1.052495990786250,-2.163628613059200,5.474190472180060,-

```

```

1.595726228617250,4.155461686806640,0.942943777349880,-0.242827700506053,-
1.416292389097280,0.751601196026573,-
1.507691559946060,0.159312941310601,1.259245432803490,5.085479361382450};
123. float Bias_2_MP = -2.965072798118910;
124.
125.//Matrizes para ozônio:
126. float      Bias_1_O3[O_O3]      =      {1.200852812903060,0.849891822449557,0.650849364992540,-
1.401414355601900,-1.145290027168860,1.088019051432750,-
0.822708992079689,0.828244030532552,0.892252320251561,-
0.201034962415791,0.069570032204367,0.457492015190903,1.653979438674410,1.204821372020530,0.393374
305242690,-1.255903320887810,1.097249747750850,0.812204338907984,-
0.509736560195408,1.412767166854250,0.617972899560781,-0.151265147976510,-
1.078394730274310,0.591616900436701,-0.953825923382013,1.106298019922400,-
2.112120040105060,1.719749986128240,-0.543280447558801,0.789998318918094,0.961094641730764,-
1.805290382615910,-0.852471796437242,-0.377816281688751,0.277248942540432,-
0.169558072050674,1.244723597377270,0.527918467579554,0.016516117454937,-1.681353952813760,-
1.776943875616470,-0.099166612055556,0.925680211367092,2.000911710887020,-
1.691603162517940,1.344489655216520,0.086435918771871,-
0.418602381951901,0.149369063224924,1.571565414799030,-1.907417164914950,-
0.639224250501482,1.120000144381290,1.061539754912580,-0.018636209944585,-
0.724700835662125,0.565903742357709,1.194540471869060,-
0.109078669727147,1.131669711380100,1.876181564311770,0.088880031954006,1.505678268483940,2.450791
909748260,0.794444533758321,-0.196468775579590,-0.059538849684954,0.388405406059545,-
0.029990501238783,-
0.873334442899074,0.589383683319000,1.060664308163030,0.515405913955854,1.122572118896760,0.064927
357419683,0.299643616673691,-
3.639018336434450,0.337229364548855,1.116235184922680,0.090892166310313,0.038277521844864,0.146122
708953163,1.276828220768780,0.457992377316445,1.268338994804400,0.167206736025036};
127. float      C_O3[O_O3]      =      {-0.048559259318960,0.351261078413935,1.386647275498870,-
1.577462179669640,2.224810364006090,0.732659076921369,-1.711162588600980,0.491073368065635,-
0.014347570296354,-0.874960742768417,-1.978151968134750,-1.818445549857070,-
0.100297822214682,2.713284774018540,0.226076936606344,0.336513856112468,0.668662545744055,-
2.320109793758570,-0.343502970564259,-0.602586897856645,-
0.383874185468653,0.221667700670700,0.647458780075589,-0.327386177438178,-0.913020389560852,-
0.944882675684481,0.996897924100898,-0.149422926343201,3.016395646839160,-1.271804878826600,-
0.778633977001618,-1.502924859235030,-0.289161587526329,1.270216511951950,0.665272662029704,-
1.341485779646650,1.214047569600160,0.353914160365838,0.557442426124778,-1.475240841708000,-
0.865124452442082,-0.940486512562783,-1.150723579489280,-1.905536482840530,-
0.040460887744556,2.264648075906930,-2.287744967504550,0.146843027010219,0.182340822065163,-
1.104424883362830,2.038073160681510,0.510898451055039,0.821045710600343,3.208330735251390,1.326323
178953230,-0.499082385794415,-1.947702688293860,-0.805399893887488,-0.568026055467614,-
0.526303150676258,-0.245186704648440,-2.124285440758950,-0.419467682251513,0.434394457595280,-
0.036619586320614,1.703397158998030,-0.362045341912216,-0.778041432804618,0.704198552332412,-
0.667701879740334,0.398522591229656,0.381184784082984,-0.076124933268949,0.123003679145174,-
0.387181552789105,1.042256853753810,0.367547226528468,0.301861123413390,0.988419457712685,1.007838
519576800,-0.544900433085010,0.989941975943477,0.479914377358204,-
1.825959069755030,2.483123349279690,0.152799980657164};
128. float Bias_2_O3 = -3.210407468343700;
129.
130.//Matrizes para monóxido de carbono:
131. float      Bias_1_CO[O_CO]      =      {6.585753145804130,9.550437288425800,5.356651132132280,2.834003520000370,5.258773836495700,3.18365
5610851470,0.186833123118066,3.165342629354490,-0.242000039066414,2.571340042920970,-
0.396473873334792,0.264555951984640,10.493467341795300,-10.578394302895200,-
0.828718489862649,5.055942356299470,4.140213355898890,0.240216457288182,3.287428651774980,2.137386
446905000,2.495639791231570,3.526096147560780,-
3.042728811245760,4.442627681575820,2.857948990203370,7.876672578365170,3.954084630499540,3.370249

```

```

171647350,-5.969312819884760,-
6.969370490732090,2.268460939794490,3.056574106029060,0.860570871642585,17.112991995119200,2.77219
0316662480,-3.655038296052910,-
0.912605686736198,4.241715148199720,5.839978178963710,2.433519397264840,10.040767315718700,7.40510
1774666240,2.611143879153810,0.842513840329648,6.572962396064530,2.352613534602470,13.21020531417
0700,2.056745465294400,5.320547546122990,-
12.279241591416900,4.046189706852930,3.487787087635040,10.820544519318000,4.184831543153170,5.5520
17422942980,0.235016925822070,1.850289537282040,-
0.013930857033243,3.306840434503240,8.051558623027780,-1.727807008097150,6.816325112433430};
132. float          C_CO[O_CO]          =          {0.365062733494462,-0.051773304384241,-
0.879920239952957,6.096350536241650,1.609890007633490,-17.930327070113500,-2.044659368044860,-
8.265630719709780,-6.974687427478920,0.035790110383237,9.172719111734420,-7.263167772398600,-
4.439831845229800,13.762776735182100,-
11.556108438892400,6.358894651758710,1.091108852605750,9.549260964485440,5.105706291057060,-
8.087579034539750,4.542107288715080,-11.230077099933900,-1.707710453415920,-0.530310867368403,-
9.816881926343620,-6.827274406536250,-
3.167136463781310,6.633976738626470,5.364325184483480,5.573460719429640,3.497893974998690,4.127715
730072460,6.189106669050170,-
0.110062595559606,7.870167439567980,5.268129531217020,2.997473511856870,0.300463251821552,-
1.342066086270360,3.074868551148520,3.875602134545780,-7.857975658425740,1.651080397735900,-
7.885739296628620,8.149633726921330,2.479858834704440,-0.266195438600728,-
21.042401138725800,3.300553748363040,7.172043824573640,-
5.921608546574530,3.694549541963630,7.758281060521380,0.606021518606147,4.993515448195200,13.93919
8155834600,3.838061847805090,5.442336153101820,2.537225779351110,-2.776422095088400,-
35.444529342169800,3.244671858931460};
133. float Bias_2_CO = -1.990565113058040;
134.
135. void setup(){
136.   Serial.begin(9600);
137.   esp8266.begin(115200);
138.
139.   pinMode(MQ131_pin,INPUT);
140.   pinMode(MICS5524_pin,INPUT);
141.   pinMode(8,INPUT);
142.   pinMode(GreenPin, OUTPUT);
143.   pinMode(WellowPin, OUTPUT);
144.   pinMode(RedPin, OUTPUT);
145.   digitalWrite(RedPin, LOW);
146.
147.   dht.begin();
148.   Wire.begin();
149.   if (!bmp.begin()){
150.     Serial.println("Erro BMP");
151.     digitalWrite(RedPin, HIGH);
152.   } else {
153.   }
154.
155.   sendData("AT+RST\r\n", 2000, DEBUG);
156.
157. //Conecta a rede wireless:
158.   sendData("AT+CWJAP=\"NOME_DA_REDE\", \"SENHA\"\r\n", 2000, DEBUG);
159.   delay(3000);
160.   sendData("AT+CWMODE=1\r\n", 1000, DEBUG);
161.
162. //Mostra o endereço IP:
163.   sendData("AT+CIFSR\r\n", 1000, DEBUG);
164.

```

```

165.//Configura para múltiplas conexões:
166. sendData("AT+CIPMUX=1\r\n", 1000, DEBUG);
167.
168.//Inicia o web server na porta 80:
169. sendData("AT+CIPSERVER=1,80\r\n", 1000, DEBUG);
170.
171.//Cálculo da massa das partículas, considerando que são PM2,5:
172. double raioPM25 = 0.44 * pow(10.0,-6.0);
173. double volumePM25 = (4.0/3.0) * pi * pow(raioPM25,3.0);
174. double densidade = 1.65 * pow(10.0,12.0);
175. massaPM25 = densidade * volumePM25;
176.
177.//Contagem do tempo:
178. starttime = millis();
179.
180.//Inicialização do cartão SD para gravar os dados:
181. while (!Serial){
182. }
183.
184. Serial.print("Inicializando cartao SD...");
185. if (!SD.begin(chipSelect)){
186.   Serial.println("Status do cartão SD: Falha na leitura (verificar conexões).");
187.   return;
188. }
189. Serial.println("Status do cartão SD: Ok.");
190. Serial.print("\n");
191.
192.
193. Serial.println("Data;Dia_Semana;Hora(h:min:s);Temperatura_BMP(°C);Pressão(Pa);Temperatura_DHT(°C);Umidade
(%) ;MP(ug/m3);O3(ug/m3);CO(ppm);Ind_MP;Ind_O3;Ind_CO;IQAr;Classificacao;MP_new(ug/m3);O3_new(ug/m3);
CO_new(ppm)");
193. delay(1000);
194.}
195.
196.void loop(){
197. digitalWrite(GreenPin, LOW);
198. digitalWrite(WellowPin, LOW);
199.
200. getParticulatePulse();
201.
202. LeituraWiFi(); //Loop para envio dos dados em plataforma Web (ESP8266)
203.
204. if ((millis()-starttime) > sampletime_ms) //Se o tempo de amostra for igual a 30 segundos
205. {
206.   Mostrarelogio(); //Loop para leitura da data e da hora (RTC DS1307)
207.   getPressureTemperature(); //Loop para medição da pressão e temperatura (BMP085)
208.   getTemperatureHumidity(); //Loop para medição da temperatura e umidade (DHT-11)
209.   getParticulate(); //Loop para leitura do material particulado (PPD42)
210.   getGas(); //Loop para medição dos gases (MQ-131 e MICS-5524)
211.   getIndex(); //Loop para avaliação dos índices IQAr dos gases e do geral
212.   getPredictionLoop(); //Loop para predição das concentrações dos gases (RNA)
213.   LeituraSD(); //Loop para gravação dos dados no cartão SD
214. }
215.}
216.
217.byte ConverteParaBCD(byte val){ //Converte o número de decimal para BCD
218. return ( (val/10*16) + (val%10) );

```

```

219.}
220.byte ConverteparaDecimal(byte val){           //Converte de BCD para decimal
221. return ( (val/16*10) + (val%16) );
222.}
223.
224.void getParticulatePulse(){
225. duration = pulseIn(PPD42_pin, LOW);
226. lowpulseoccupancy = lowpulseoccupancy + duration;
227.}
228.
229.void Mostrarelogio(){
230. Wire.beginTransmission(DS1307_ADDRESS);
231. Wire.write(zero);
232. Wire.endTransmission();
233. Wire.requestFrom(DS1307_ADDRESS, 7);
234. segundos = ConverteparaDecimal(Wire.read());
235. minutos = ConverteparaDecimal(Wire.read());
236. horas = ConverteparaDecimal(Wire.read() & 0b111111);
237. int diadasemana = ConverteparaDecimal(Wire.read());
238. diadomes = ConverteparaDecimal(Wire.read());
239. mes = ConverteparaDecimal(Wire.read());
240. ano = ConverteparaDecimal(Wire.read());
241.
242. if (diadasemana == 0){
243. diadasemana_print = "Domingo";
244. } else if (diadasemana == 1){
245. diadasemana_print = "Segunda-feira";
246. } else if (diadasemana == 2){
247. diadasemana_print = "Terca-feira";
248. } else if (diadasemana == 3){
249. diadasemana_print = "Quarta-feira";
250. } else if (diadasemana == 4){
251. diadasemana_print = "Quinta-feira";
252. } else if (diadasemana == 5){
253. diadasemana_print = "Sexta-feira";
254. } else if (diadasemana == 6){
255. diadasemana_print = "Sabado";
256. }
257.}
258.
259.void getPressureTemperature(){
260. t_bmp = bmp.readTemperature();
261. p_bmp = bmp.readPressure();
262.}
263.
264.void getTemperatureHumidity(){
265. t_dht = dht.readTemperature();
266. h_dht = dht.readHumidity();
267.
268. if (isnan(t_dht) || isnan(h_dht)){
269. Serial.print("Erro DHT");
270. } else {
271. digitalWrite(WellowPin, HIGH);
272. }
273.}
274.
275.void getParticulate(){

```

```

276. ratio = lowpulseoccupancy / (sampletime_ms * 10.0);
277.
278. //Cálculo para obtenção da concentração de particulado, em pcs/0,01ft³:
279. concentration = (1.1 * pow(ratio,3.0)) - (3.8 * pow(ratio,2.0)) + (520.0 * ratio) + 0.62;
280.
281. //Cálculo para obtenção da concentração de particulado, em ug/m³:
282. MP_ugcm = concentration * fc * massaPM25;
283.
284. lowpulseoccupancy = 0;
285. starttime = millis();
286. }
287.
288. void getGas(){
289. //Cálculos para obtenção da concentração de ozônio, em ug/m3:
290. float O3_ppb = MQGetGasPercentage(MQRead(MQ131_pin,MQ131)/MQ131_Ro, MQ131);
291. float t_kelvin = 273.15 + ((t_bmp + t_dht)/2.0);
292. float p_mmHg = p_bmp/133.322;
293. O3_ugcm = (p_mmHg * 47.997 * O3_ppb)/(62.3637 * t_kelvin);
294.
295. //Loop para obtenção da concentração de monóxido de carbono, em ppm:
296. CO_ppm = MQGetGasPercentage(MQRead(MICS5524_pin,MICS5524)/MICS5524_Ro, MICS5524);
297. }
298.
299. void getIndex(){
300. //Obtenção dos índices dos gases e do IQAr:
301. indice_MP = IndiceCalculation(MP_ugcm,MP_gas);
302. indice_O3 = IndiceCalculation(O3_ugcm,O3_gas);
303. indice_CO = IndiceCalculation(CO_ppm,CO_gas);
304.
305. //Etapa para escolha do maior índice calculado:
306. IQAr_final = max(indice_CO, max(indice_MP,indice_O3));
307.
308. if (IQAr_final <= If_b){
309. classe_final = "Boa";
310. } else if (IQAr_final >= li_r && IQAr_final <= If_r){
311. classe_final = "Regular";
312. } else if (IQAr_final >= li_i && IQAr_final <= If_i){
313. classe_final = "Inadequada";
314. } else if (IQAr_final >= li_m && IQAr_final <= If_m){
315. classe_final = "Ma";
316. } else if (IQAr_final > If_m){
317. classe_final = "Pessima";
318. }
319. }
320.
321. void getPredictionLoop(){
322. //Etapa inicial para normalização das entradas:
323. float t_bmp_norm = (t_bmp * 0.0636942675159236) - 1.4522299363;
324. float p_bmp_norm = (p_bmp * 0.000831946755407654) - 83.3194675540765;
325. float t_dht_norm = (t_dht * 0.0588235294117647) - 1.17647058823529;
326. float h_dht_norm = (h_dht * 0.0163934426229508) - 0.557377049180328;
327. float MP_ugcm_norm = (MP_ugcm * 0.0502795543220305) - 0.0000653634206186396;
328. float O3_ugcm_norm = (O3_ugcm * 0.00885455682057657) - 0.0147685153210397;
329. float CO_ppm_norm = CO_ppm * 0.100301908745323;
330.
331. //Obtenção das matrizes A (entradas) x B (pesos_hidden):

```

```

332. float A_B_MP[O_MP] = {(2.76144212315897 * t_bmp_norm) + (-2.56134783438582 * p_bmp_norm) +
(0.248281118719407 * t_dht_norm) + (-3.96590259574648 * h_dht_norm) + (0.199675373923218 *
MP_ugcm_norm),(0.087329328808874 * t_bmp_norm) + (0.149099196588317 * p_bmp_norm) +
(1.00695686172208 * t_dht_norm) + (-0.32253512549288 * h_dht_norm) + (-2.45538844575683 *
MP_ugcm_norm),(7.13581327738797 * t_bmp_norm) + (10.4303298891794 * p_bmp_norm) +
(0.849289510283288 * t_dht_norm) + (-4.8631453995377 * h_dht_norm) + (6.29625092764189 *
MP_ugcm_norm),(-3.44104405194992 * t_bmp_norm) + (2.75486384107755 * p_bmp_norm) + (-
0.153623247928622 * t_dht_norm) + (-1.1037892815725 * h_dht_norm) + (1.87629190990064 *
MP_ugcm_norm),(-2.45760137682981 * t_bmp_norm) + (-1.41540491036155 * p_bmp_norm) +
(0.302786400421099 * t_dht_norm) + (0.253721083449901 * h_dht_norm) + (-1.35757672929124 *
MP_ugcm_norm),(23.6071852038556 * t_bmp_norm) + (-5.01903972632331 * p_bmp_norm) + (5.30686632350352
* t_dht_norm) + (9.93679578010188 * h_dht_norm) + (-3.08773134529208 * MP_ugcm_norm),(17.3693204093993
* t_bmp_norm) + (-0.143988400843178 * p_bmp_norm) + (5.40226506057775 * t_dht_norm) + (21.8564105807283
* h_dht_norm) + (-22.0369528818482 * MP_ugcm_norm),(-6.19167279803789 * t_bmp_norm) + (-
4.36095258933581 * p_bmp_norm) + (3.7362236152498 * t_dht_norm) + (13.9621254295122 * h_dht_norm) + (-
1.85560865101088 * MP_ugcm_norm),(-12.5314829872224 * t_bmp_norm) + (-1.92095501005324 * p_bmp_norm)
+ (8.89547188182564 * t_dht_norm) + (2.55909570724738 * h_dht_norm) + (1.69913049093163 *
MP_ugcm_norm),(-4.26709758196162 * t_bmp_norm) + (4.33995919593143 * p_bmp_norm) + (-
1.81470525089757 * t_dht_norm) + (-3.54972651295178 * h_dht_norm) + (0.704306517999864 *
MP_ugcm_norm),(0.756234102624351 * t_bmp_norm) + (1.20455934184065 * p_bmp_norm) + (-
1.01941834319528 * t_dht_norm) + (-2.19906850649566 * h_dht_norm) + (-0.921962014084651 *
MP_ugcm_norm),(8.76073413567093 * t_bmp_norm) + (-30.3812457398983 * p_bmp_norm) + (20.2397383221613
* t_dht_norm) + (-6.10365207786473 * h_dht_norm) + (1.88449924795118 * MP_ugcm_norm),(-3.36164763369485
* t_bmp_norm) + (3.34285611354439 * p_bmp_norm) + (-1.9273006895515 * t_dht_norm) + (3.3369662465282 *
h_dht_norm) + (4.65100544974565 * MP_ugcm_norm),(-2.24815388576522 * t_bmp_norm) + (-1.66760611836361
* p_bmp_norm) + (0.0506305368516859 * t_dht_norm) + (-1.27525496717286 * h_dht_norm) +
(3.05436608213204 * MP_ugcm_norm),(0.0188800781882799 * t_bmp_norm) + (1.34546267330501 *
p_bmp_norm) + (-4.06049042816286 * t_dht_norm) + (-6.80336067849948 * h_dht_norm) + (7.3610307938349 *
MP_ugcm_norm),(2.89326197509257 * t_bmp_norm) + (-3.05159854212718 * p_bmp_norm) + (8.1862589676394
* t_dht_norm) + (19.657141554092 * h_dht_norm) + (2.58802093495457 * MP_ugcm_norm),(4.88838081254685 *
t_bmp_norm) + (-2.04384013378722 * p_bmp_norm) + (-0.64234829699612 * t_dht_norm) + (-4.62786402704371
* h_dht_norm) + (-5.1478447371984 * MP_ugcm_norm),(-4.01103797841475 * t_bmp_norm) + (3.43675636858888
* p_bmp_norm) + (-2.72106135817351 * t_dht_norm) + (-2.43593351238242 * h_dht_norm) + (-1.57735463718809
* MP_ugcm_norm),(1.95061141127211 * t_bmp_norm) + (3.58254563828925 * p_bmp_norm) + (-
12.9795697203699 * t_dht_norm) + (11.580850001938 * h_dht_norm) + (6.28409199254474 *
MP_ugcm_norm),(1.62223791559986 * t_bmp_norm) + (4.80824561132384 * p_bmp_norm) + (-4.92999073303057
* t_dht_norm) + (-23.7448267824947 * h_dht_norm) + (3.07909995606695 * MP_ugcm_norm),(-2.72227645845837
* t_bmp_norm) + (0.992202522139797 * p_bmp_norm) + (0.0862604186340618 * t_dht_norm) +
(0.103396153659287 * h_dht_norm) + (-2.1578164942691 * MP_ugcm_norm),(0.0875679105913756 *
t_bmp_norm) + (1.2018343299124 * p_bmp_norm) + (-0.870702576998595 * t_dht_norm) + (-3.00400157269866 *
h_dht_norm) + (-0.305539272456874 * MP_ugcm_norm),(-7.33342912172355 * t_bmp_norm) + (-
3.08476647094881 * p_bmp_norm) + (-6.69422074846916 * t_dht_norm) + (-3.23532530135147 * h_dht_norm) +
(4.23198984980941 * MP_ugcm_norm),(4.4575578694874 * t_bmp_norm) + (2.01668336184823 * p_bmp_norm)
+ (-0.527302572604014 * t_dht_norm) + (3.60369964838818 * h_dht_norm) + (1.31278688835818 *
MP_ugcm_norm),(6.683971075633 * t_bmp_norm) + (-2.76870656624281 * p_bmp_norm) + (4.07704422285062 *
t_dht_norm) + (-2.49995969342275 * h_dht_norm) + (-4.0850886238961 * MP_ugcm_norm),(-
0.0399389437023726 * t_bmp_norm) + (3.86344304398314 * p_bmp_norm) + (0.106415337712029 * t_dht_norm)
+ (-0.536477648453303 * h_dht_norm) + (-7.98158037206428 * MP_ugcm_norm),(0.636811516694509 *
t_bmp_norm) + (-1.26294329461055 * p_bmp_norm) + (0.666558482666316 * t_dht_norm) + (4.24646951668123
* h_dht_norm) + (-2.66656311087421 * MP_ugcm_norm),(-3.33230577760671 * t_bmp_norm) +
(4.53815003453824 * p_bmp_norm) + (-2.99657743211892 * t_dht_norm) + (1.92507543916123 * h_dht_norm) +
(-2.32548376760868 * MP_ugcm_norm),(-0.187445977323549 * t_bmp_norm) + (-1.21013086471829 *
p_bmp_norm) + (0.976329406805289 * t_dht_norm) + (1.05590839648187 * h_dht_norm) + (-0.477563553107521
* MP_ugcm_norm),(-0.17511533872069 * t_bmp_norm) + (-0.593882648642708 * p_bmp_norm) +
(0.195757855618632 * t_dht_norm) + (0.169667466117636 * h_dht_norm) + (0.605955919653234 *
MP_ugcm_norm),(1.80890059398726 * t_bmp_norm) + (-1.69935496698725 * p_bmp_norm) + (1.46026946070726
* t_dht_norm) + (-1.53780164177923 * h_dht_norm) + (-0.9397315394474 * MP_ugcm_norm),(-2.21252360817701

```

$$\begin{aligned}
& * t_bmp_norm) + (0.563414082818177 * p_bmp_norm) + (-2.84892726159638 * t_dht_norm) + \\
& (0.944982086039257 * h_dht_norm) + (0.297312641904124 * MP_ugcm_norm),(-0.434434171775472 * \\
& t_bmp_norm) + (-2.25091118692291 * p_bmp_norm) + (-3.16229517524559 * t_dht_norm) + (-4.3788723845115 * \\
& h_dht_norm) + (-8.81814414113031 * MP_ugcm_norm),(-1.15479391741946 * t_bmp_norm) + \\
& (0.960987013927506 * p_bmp_norm) + (-0.655065217448815 * t_dht_norm) + (0.741035804300598 * h_dht_norm) \\
& + (3.47774356697024 * MP_ugcm_norm),(3.10049789788762 * t_bmp_norm) + (-3.66815242657171 * \\
& p_bmp_norm) + (1.89603699314255 * t_dht_norm) + (-0.821029900610273 * h_dht_norm) + (5.98641181369451 * \\
& MP_ugcm_norm),(-2.03813275470245 * t_bmp_norm) + (-2.17297831409448 * p_bmp_norm) + (- \\
& 1.47198151093925 * t_dht_norm) + (-2.63043527117812 * h_dht_norm) + (0.818963328427516 * \\
& MP_ugcm_norm),(1.54722703571569 * t_bmp_norm) + (-3.00560167103004 * p_bmp_norm) + (- \\
& 0.557596214423762 * t_dht_norm) + (-1.24925685547642 * h_dht_norm) + (-3.03015211172067 * \\
& MP_ugcm_norm),(5.88700387091342 * t_bmp_norm) + (-10.6789026968223 * p_bmp_norm) + (- \\
& 24.1008025186196 * t_dht_norm) + (-4.13552215224703 * h_dht_norm) + (-4.22201036495943 * \\
& MP_ugcm_norm),(-0.747048455026878 * t_bmp_norm) + (1.77824014581472 * p_bmp_norm) + \\
& (0.786568632594004 * t_dht_norm) + (2.4451272247273 * h_dht_norm) + (-2.04362194833352 * \\
& MP_ugcm_norm),(-1.88201657687059 * t_bmp_norm) + (1.85040624685812 * p_bmp_norm) + (- \\
& 4.91042851629894 * t_dht_norm) + (-7.03444666368882 * h_dht_norm) + (-5.90923953018051 * \\
& MP_ugcm_norm),(-0.188248781596139 * t_bmp_norm) + (-9.51286279664038 * p_bmp_norm) + \\
& (0.734818451424194 * t_dht_norm) + (-5.42314414346708 * h_dht_norm) + (-10.5431925446524 * \\
& MP_ugcm_norm),(4.32631985017127 * t_bmp_norm) + (-8.47381962069942 * p_bmp_norm) + (2.57161090837086 \\
& * t_dht_norm) + (-2.50489243021928 * h_dht_norm) + (1.10096786323869 * MP_ugcm_norm),(-1.10535583890626 \\
& * t_bmp_norm) + (2.54032727065178 * p_bmp_norm) + (0.190640279505725 * t_dht_norm) + (2.49861898237974 \\
& * h_dht_norm) + (-1.71335003464006 * MP_ugcm_norm),(-0.356721727306164 * t_bmp_norm) + (- \\
& 0.653412832483745 * p_bmp_norm) + (-2.18379039179974 * t_dht_norm) + (-1.46965584015571 * h_dht_norm) + \\
& (-0.748659040614641 * MP_ugcm_norm),(4.78947092206799 * t_bmp_norm) + (-4.55420475622314 * \\
& p_bmp_norm) + (2.34708215485727 * t_dht_norm) + (-1.53750662821998 * h_dht_norm) + (-7.16114343346271 * \\
& MP_ugcm_norm),(-1.15907237994982 * t_bmp_norm) + (0.696993111540241 * p_bmp_norm) + \\
& (0.937820654613005 * t_dht_norm) + (-3.15191852337441 * h_dht_norm) + (-1.36076414707031 * \\
& MP_ugcm_norm),(0.662111832241906 * t_bmp_norm) + (2.11283277508986 * p_bmp_norm) + (- \\
& 0.550308293505812 * t_dht_norm) + (4.86520459569191 * h_dht_norm) + (4.72554509122301 * \\
& MP_ugcm_norm),(2.76739245458469 * t_bmp_norm) + (-1.35410499452926 * p_bmp_norm) + (- \\
& 2.00330086000305 * t_dht_norm) + (-2.96441304642546 * h_dht_norm) + (1.76987099229509 * \\
& MP_ugcm_norm),(-7.85332384909268 * t_bmp_norm) + (1.59888975906748 * p_bmp_norm) + (0.71396039041819 \\
& * t_dht_norm) + (5.39513609279411 * h_dht_norm) + (1.57451085720736 * MP_ugcm_norm),(- \\
& 0.871534899391181 * t_bmp_norm) + (1.71717876770829 * p_bmp_norm) + (-2.38682908488467 * t_dht_norm) + \\
& (0.231245093044372 * h_dht_norm) + (-0.64881866935507 * MP_ugcm_norm),(32.6666442753517 * t_bmp_norm) \\
& + (-27.2301423832975 * p_bmp_norm) + (-17.3580570810407 * t_dht_norm) + (-4.52052642456855 * h_dht_norm) \\
& + (6.71662631476044 * MP_ugcm_norm),(-3.80977890459828 * t_bmp_norm) + (0.323862125725884 * \\
& p_bmp_norm) + (1.11953722837843 * t_dht_norm) + (-0.384601139281878 * h_dht_norm) + (-0.323043440452622 \\
& * MP_ugcm_norm),(2.90550790240957 * t_bmp_norm) + (-2.23442964679007 * p_bmp_norm) + \\
& (1.13551190127836 * t_dht_norm) + (-2.67651570226886 * h_dht_norm) + (-6.84187648171214 * \\
& MP_ugcm_norm),(0.0908267063900264 * t_bmp_norm) + (-1.13991116054216 * p_bmp_norm) + (- \\
& 0.768535881080524 * t_dht_norm) + (-2.46667722572335 * h_dht_norm) + (1.46496855757462 * \\
& MP_ugcm_norm),(-0.947907452085942 * t_bmp_norm) + (1.624954350762 * p_bmp_norm) + (- \\
& 0.709009487770856 * t_dht_norm) + (8.32401789062229 * h_dht_norm) + (0.805073963317983 * \\
& MP_ugcm_norm),(6.3115376240795 * t_bmp_norm) + (2.90182657858356 * p_bmp_norm) + (11.6615562399825 \\
& * t_dht_norm) + (3.38252938909247 * h_dht_norm) + (1.64406025221962 * MP_ugcm_norm),(2.66184877272335 \\
& * t_bmp_norm) + (0.162626858766115 * p_bmp_norm) + (-1.60084319231792 * t_dht_norm) + \\
& (0.159572364719446 * h_dht_norm) + (6.59286909549703 * MP_ugcm_norm),(-0.177551884390731 * \\
& t_bmp_norm) + (-0.0204744638816123 * p_bmp_norm) + (0.0115181499097894 * t_dht_norm) + (- \\
& 0.842270451157782 * h_dht_norm) + (-0.209043682152949 * MP_ugcm_norm),(2.565077000446 * t_bmp_norm) \\
& + (-3.01028594483928 * p_bmp_norm) + (1.39832581271341 * t_dht_norm) + (4.86062888352864 * h_dht_norm) \\
& + (-2.23144369291568 * MP_ugcm_norm),(-2.4326066370408 * t_bmp_norm) + (2.82491173475526 * \\
& p_bmp_norm) + (-2.25554833191583 * t_dht_norm) + (-1.58620399172724 * h_dht_norm) + (0.70014627821557 * \\
& MP_ugcm_norm),(-3.97452087796967 * t_bmp_norm) + (1.72147313458763 * p_bmp_norm) + (1.46920871957189 \\
& * t_dht_norm) + (-0.108197725477409 * h_dht_norm) + (0.323965937488208 * \\
& MP_ugcm_norm),(1.66084994053966 * t_bmp_norm) + (5.1811408983387 * p_bmp_norm) + (2.72170879560217
\end{aligned}$$

```

* t_dht_norm) + (6.37908123944749 * h_dht_norm) + (2.52640057405719 * MP_ugcm_norm),(-
0.758031031813319 * t_bmp_norm) + (-10.4092595603833 * p_bmp_norm) + (6.11572165251015 * t_dht_norm) +
(3.94771903227893 * h_dht_norm) + (-0.702381231304299 * MP_ugcm_norm),(3.61795383731017 * t_bmp_norm)
+ (-0.763127778473636 * p_bmp_norm) + (-0.382749217282111 * t_dht_norm) + (4.20215874435882 *
h_dht_norm) + (2.3306649672199 * MP_ugcm_norm),(3.57320367812182 * t_bmp_norm) + (0.249053728697711
* p_bmp_norm) + (1.85200553435338 * t_dht_norm) + (0.0935901452429384 * h_dht_norm) + (-
1.40144611310858 * MP_ugcm_norm),(0.146902034637402 * t_bmp_norm) + (-9.0896403654138 * p_bmp_norm)
+ (-10.3398432474057 * t_dht_norm) + (0.596554607206899 * h_dht_norm) + (5.02078698783433 *
MP_ugcm_norm),(-4.52893593006094 * t_bmp_norm) + (-4.11322135198528 * p_bmp_norm) + (3.4369271613881
* t_dht_norm) + (-2.02584678940637 * h_dht_norm) + (-1.62808295597152 * MP_ugcm_norm),(-
0.0176811369566008 * t_bmp_norm) + (-0.776022836914618 * p_bmp_norm) + (0.701246096732258 *
t_dht_norm) + (2.54002979541233 * h_dht_norm) + (1.38245488331694 * MP_ugcm_norm),(-1.09039250814695 *
t_bmp_norm) + (-1.87719587502777 * p_bmp_norm) + (-0.391667010261167 * t_dht_norm) + (0.656820467968279
* h_dht_norm) + (0.297203593966067 * MP_ugcm_norm),(1.4073125896034 * t_bmp_norm) + (-
3.51635598392155 * p_bmp_norm) + (-4.93332632389979 * t_dht_norm) + (3.40565745821928 * h_dht_norm) +
(1.22014645850509 * MP_ugcm_norm));
333. float A_B_O3[O_O3] = {(-1.42149889321761 * t_bmp_norm) + (1.4756240056508 * p_bmp_norm) + (-
0.0221124774314943 * t_dht_norm) + (-0.41149817442984 * h_dht_norm) + (-2.68236757950032 *
O3_ugcm_norm),(-1.49582424019835 * t_bmp_norm) + (2.85333739470497 * p_bmp_norm) + (-
0.227606217599451 * t_dht_norm) + (-1.04076847796035 * h_dht_norm) + (-11.6521782275043 *
O3_ugcm_norm),(-2.77185600507932 * t_bmp_norm) + (1.0834927115574 * p_bmp_norm) + (-1.11169172944964
* t_dht_norm) + (-2.42749593428243 * h_dht_norm) + (-12.7080368220422 * O3_ugcm_norm),(-
0.709732449823228 * t_bmp_norm) + (0.901784701987251 * p_bmp_norm) + (-1.94107270613457 * t_dht_norm)
+ (-0.204022625870013 * h_dht_norm) + (-8.80387710627501 * O3_ugcm_norm),(0.651510577951406 *
t_bmp_norm) + (2.0989209782445 * p_bmp_norm) + (-2.22907253451644 * t_dht_norm) + (-1.58763261980677 *
h_dht_norm) + (-21.3053252919728 * O3_ugcm_norm),(-0.771771745381474 * t_bmp_norm) +
(0.839135702142401 * p_bmp_norm) + (0.0480726559852541 * t_dht_norm) + (-1.32678726890148 * h_dht_norm)
+ (-1.2538382789577 * O3_ugcm_norm),(-0.804744168661787 * t_bmp_norm) + (-1.49687556560114 *
p_bmp_norm) + (1.0573452118526 * t_dht_norm) + (-1.83308443222355 * h_dht_norm) + (-4.1730759802708 *
O3_ugcm_norm),(-1.78532938526457 * t_bmp_norm) + (2.35463594082307 * p_bmp_norm) + (-
0.251627396653432 * t_dht_norm) + (-1.44876849794035 * h_dht_norm) + (-11.4839177415072 *
O3_ugcm_norm),(-2.18691402752719 * t_bmp_norm) + (3.35944456752903 * p_bmp_norm) + (-
0.163783913557783 * t_dht_norm) + (-1.20519605024542 * h_dht_norm) + (-3.31051380801082 *
O3_ugcm_norm),(-0.796831035850672 * t_bmp_norm) + (0.595996873249706 * p_bmp_norm) +
(0.17723243921667 * t_dht_norm) + (0.099862764949389 * h_dht_norm) + (-5.12163075474792 *
O3_ugcm_norm),(-1.73808381886661 * t_bmp_norm) + (1.28890616021525 * p_bmp_norm) + (-
0.268047859126693 * t_dht_norm) + (-1.87457939770494 * h_dht_norm) + (-5.95072536766641 *
O3_ugcm_norm),(-3.50498619736816 * t_bmp_norm) + (0.0142383903397523 * p_bmp_norm) +
(0.160147991439586 * t_dht_norm) + (-1.47266045953614 * h_dht_norm) + (-32.3713188997591 *
O3_ugcm_norm),(-0.975065076456676 * t_bmp_norm) + (1.41242138098464 * p_bmp_norm) +
(0.0629459419270983 * t_dht_norm) + (-0.945983996382913 * h_dht_norm) + (-2.57301735764876 *
O3_ugcm_norm),(-1.15934481366668 * t_bmp_norm) + (1.02841571365657 * p_bmp_norm) + (-
0.302522362539313 * t_dht_norm) + (-2.58953117448733 * h_dht_norm) + (-17.9606368491275 *
O3_ugcm_norm),(-0.819319915208807 * t_bmp_norm) + (0.819838382924171 * p_bmp_norm) +
(0.309190008703165 * t_dht_norm) + (-1.43445717462097 * h_dht_norm) + (-2.90841270729226 *
O3_ugcm_norm),(0.436508882263143 * t_bmp_norm) + (0.223900304663875 * p_bmp_norm) + (2.0383509484884
* t_dht_norm) + (-2.43712681355888 * h_dht_norm) + (-0.104251828233442 * O3_ugcm_norm),(-
0.994817602027036 * t_bmp_norm) + (1.01722867369128 * p_bmp_norm) + (-0.193657798092502 * t_dht_norm)
+ (-1.07123059295297 * h_dht_norm) + (-2.70671304860324 * O3_ugcm_norm),(-1.56222002126478 *
t_bmp_norm) + (1.35805953503484 * p_bmp_norm) + (-0.206913999573582 * t_dht_norm) + (-0.560731909099015
* h_dht_norm) + (-36.4396529320477 * O3_ugcm_norm),(0.685446035312721 * t_bmp_norm) +
(2.72688578826219 * p_bmp_norm) + (-0.378230386392203 * t_dht_norm) + (-1.0445020323268 * h_dht_norm) +
(-2.77251147857278 * O3_ugcm_norm),(-0.189208048377352 * t_bmp_norm) + (1.79830848025713 *
p_bmp_norm) + (-0.263404675919203 * t_dht_norm) + (-2.82359857419573 * h_dht_norm) + (-7.77004074644282
* O3_ugcm_norm),(-1.71694727927202 * t_bmp_norm) + (0.525095345179554 * p_bmp_norm) + (-
1.25425902996951 * t_dht_norm) + (-1.86378979471655 * h_dht_norm) + (-3.43603038227993 *
O3_ugcm_norm),(-1.58287494651235 * t_bmp_norm) + (4.29521814812942 * p_bmp_norm) + (2.27094701569158

```

```

* t_dht_norm) + (-5.19600078571825 * h_dht_norm) + (-10.8099670710301 *
O3_ugcm_norm),(0.150562717117869 * t_bmp_norm) + (0.13916798706569 * p_bmp_norm) + (2.38976793168884
* t_dht_norm) + (-2.53153451478017 * h_dht_norm) + (1.2333725586354 * O3_ugcm_norm),(-0.328015646526036
* t_bmp_norm) + (0.840721504712359 * p_bmp_norm) + (1.04754667937684 * t_dht_norm) + (-2.24145597935921
* h_dht_norm) + (-1.36763831564903 * O3_ugcm_norm),(0.340401270733817 * t_bmp_norm) +
(2.90537212401413 * p_bmp_norm) + (-0.660947507406781 * t_dht_norm) + (-2.49380166535025 * h_dht_norm)
+ (-8.6858244965941 * O3_ugcm_norm),(-1.89877613664733 * t_bmp_norm) + (2.31820072080522 *
p_bmp_norm) + (0.250549379383373 * t_dht_norm) + (-2.77403367831614 * h_dht_norm) + (-6.82502281691518
* O3_ugcm_norm),(1.12314234612588 * t_bmp_norm) + (-0.537365534863273 * p_bmp_norm) + (-
3.02311635707515 * t_dht_norm) + (-2.94990118448784 * h_dht_norm) + (-21.6868423812746 *
O3_ugcm_norm),(-0.785528703931177 * t_bmp_norm) + (1.36018950836255 * p_bmp_norm) +
(0.262199129115383 * t_dht_norm) + (-0.829611526290659 * h_dht_norm) + (-2.65053547555392 *
O3_ugcm_norm),(1.0338865828993 * t_bmp_norm) + (1.49561479885586 * p_bmp_norm) + (-3.37292297422145
* t_dht_norm) + (-2.04564089925777 * h_dht_norm) + (-22.3089312250786 * O3_ugcm_norm),(-2.3699643957173
* t_bmp_norm) + (2.18987363312105 * p_bmp_norm) + (0.17319580360925 * t_dht_norm) + (-2.07685537022734
* h_dht_norm) + (-4.71919211555502 * O3_ugcm_norm),(-0.228046011477366 * t_bmp_norm) +
(0.836967323364177 * p_bmp_norm) + (0.290085971175531 * t_dht_norm) + (-1.94442844393624 * h_dht_norm)
+ (-4.99290645379622 * O3_ugcm_norm),(-0.436886833921732 * t_bmp_norm) + (-1.43834318308169 *
p_bmp_norm) + (-2.52792128288283 * t_dht_norm) + (0.106044120155987 * h_dht_norm) + (-11.6499766605793
* O3_ugcm_norm),(0.241387719576899 * t_bmp_norm) + (2.95767419997469 * p_bmp_norm) + (-
0.914223656894186 * t_dht_norm) + (-1.97037926256694 * h_dht_norm) + (-14.8590215553008 *
O3_ugcm_norm),(-0.923991242661048 * t_bmp_norm) + (2.36793573420187 * p_bmp_norm) + (0.1025081437023
* t_dht_norm) + (-2.03661651567086 * h_dht_norm) + (-9.63184878647346 * O3_ugcm_norm),(-
2.61853330105179 * t_bmp_norm) + (3.48517473551316 * p_bmp_norm) + (0.0447797586214189 * t_dht_norm)
+ (-1.12250825538706 * h_dht_norm) + (-22.6808214319933 * O3_ugcm_norm),(-0.840605099563018
* t_bmp_norm) + (1.21583136473 * p_bmp_norm) + (-0.0411698451777507 * t_dht_norm) + (-1.69261244027186
* h_dht_norm) + (-7.24911151153454 * O3_ugcm_norm),(-1.22203769016082 * t_bmp_norm) +
(0.549534163354143 * p_bmp_norm) + (0.523401155288352 * t_dht_norm) + (-1.18172505054157 * h_dht_norm)
+ (-0.0770425198291769 * O3_ugcm_norm),(-0.776352432887726 * t_bmp_norm) + (1.53328488829907 *
p_bmp_norm) + (0.392723770298279 * t_dht_norm) + (-2.12092959307815 * h_dht_norm) + (-0.79609008386041
* O3_ugcm_norm),(-1.06411057139979 * t_bmp_norm) + (1.47024004100015 * p_bmp_norm) + (-
0.231404649895528 * t_dht_norm) + (-0.850479275625466 * h_dht_norm) + (-3.09319659363111 *
O3_ugcm_norm),(0.888174715434781 * t_bmp_norm) + (3.85429447164792 * p_bmp_norm) + (-
0.0926793535238567 * t_dht_norm) + (-3.77186509303022 * h_dht_norm) + (-17.17634441445
* O3_ugcm_norm),(-1.21606965712465 * t_bmp_norm) + (0.0286955864145301 * p_bmp_norm) + (-
2.61123165647323 * t_dht_norm) + (0.574151109642627 * h_dht_norm) + (-10.8864614436337
* O3_ugcm_norm),(-0.20256257058734 * t_bmp_norm) + (2.76492887643547 * p_bmp_norm) +
(0.114590478346286 * t_dht_norm) + (-2.5114914130031 * h_dht_norm) + (-8.43626972246685
* O3_ugcm_norm),(0.425453572680879 * t_bmp_norm) + (0.155641391159226 * p_bmp_norm) +
(0.43337653944738 * t_dht_norm) + (-2.8086914874882 * h_dht_norm) + (-0.199868892305258
* O3_ugcm_norm),(-1.60344029465536 * t_bmp_norm) + (1.03056057814373 * p_bmp_norm) + (-
1.18283979984508 * t_dht_norm) + (-3.14832192663232 * h_dht_norm) + (-4.25785045179717
* O3_ugcm_norm),(-0.351202901577514 * t_bmp_norm) + (3.2682287924292 * p_bmp_norm) +
(0.375268335648105 * t_dht_norm) + (-3.0553297115842 * h_dht_norm) + (2.59651221783174
* O3_ugcm_norm),(-2.94180968635878 * t_bmp_norm) + (0.95461464026288 * p_bmp_norm) + (-
0.313927017429893 * t_dht_norm) + (-2.79399063177982 * h_dht_norm) + (-17.1108216481704
* O3_ugcm_norm),(-1.56826872051466 * t_bmp_norm) + (2.24407678645843 * p_bmp_norm) + (-
2.05594412556203 * t_dht_norm) + (-1.42531693675818 * h_dht_norm) + (-34.6039269367776
* O3_ugcm_norm),(-0.614942938636896 * t_bmp_norm) + (0.64467339891057 * p_bmp_norm) +
(0.0433373737488617 * t_dht_norm) + (-1.32206378234395 * h_dht_norm) + (-2.58885540427981
* O3_ugcm_norm),(-1.25051698392725 * t_bmp_norm) + (1.9750600965644 * p_bmp_norm) + (0.560558285914968
* t_dht_norm) + (-1.65677946716379 * h_dht_norm) + (-4.55332372974009 * O3_ugcm_norm),(-
2.88410009530687 * t_bmp_norm) + (0.921726596978406 * p_bmp_norm) + (-1.79097983140383 * t_dht_norm) +
(-1.91733315635796 * h_dht_norm) + (-8.64252688669078 * O3_ugcm_norm),(-1.59628780152423 * t_bmp_norm)
+ (0.117333356158884 * p_bmp_norm) + (-5.77182610727937 * t_dht_norm) + (1.70947174736783 * h_dht_norm)
+ (-18.3753817625098 * O3_ugcm_norm),(-1.91321520267264 * t_bmp_norm) + (-1.03019468231113
* p_bmp_norm) + (0.991970539085226 * t_dht_norm) + (-4.96397372163568 * h_dht_norm) + (-16.8415108370471

```

* O3_ugcm_norm),(-0.295516402457078 * t_bmp_norm) + (2.26988307611116 * p_bmp_norm) + (-0.098110782525536 * t_dht_norm) + (-1.58794487487825 * h_dht_norm) + (-2.58125828572569 * O3_ugcm_norm),(-3.22617586749164 * t_bmp_norm) + (0.849647446612687 * p_bmp_norm) + (0.111054355768808 * t_dht_norm) + (-3.88251441132153 * h_dht_norm) + (-20.4329009349835 * O3_ugcm_norm),(-0.75021690714126 * t_bmp_norm) + (1.95694887342128 * p_bmp_norm) + (0.102423256579174 * t_dht_norm) + (-2.12432778211434 * h_dht_norm) + (-4.2997687353234 * O3_ugcm_norm),(-1.11670747977249 * t_bmp_norm) + (1.67473192733809 * p_bmp_norm) + (-0.340127465982963 * t_dht_norm) + (-1.79592725936229 * h_dht_norm) + (-2.88778591740198 * O3_ugcm_norm),(-1.47945017999732 * t_bmp_norm) + (1.21854274225121 * p_bmp_norm) + (0.206525643828908 * t_dht_norm) + (-2.02558435967946 * h_dht_norm) + (-5.33834507203003 * O3_ugcm_norm),(-1.47806848027862 * t_bmp_norm) + (1.02179754221439 * p_bmp_norm) + (-1.00334523114472 * t_dht_norm) + (-1.91025262481532 * h_dht_norm) + (-3.24674901036005 * O3_ugcm_norm),(0.173460106774436 * t_bmp_norm) + (1.5657800395468 * p_bmp_norm) + (2.47911094328806 * t_dht_norm) + (-3.84958145858331 * h_dht_norm) + (0.943634717168996 * O3_ugcm_norm),(-0.893580819406087 * t_bmp_norm) + (2.0058822173602 * p_bmp_norm) + (0.170510790105749 * t_dht_norm) + (-2.40470654195494 * h_dht_norm) + (-5.79965479253869 * O3_ugcm_norm),(-2.97433001088052 * t_bmp_norm) + (1.39100097566581 * p_bmp_norm) + (-0.583219663643229 * t_dht_norm) + (-1.87199837992356 * h_dht_norm) + (-12.0204732062615 * O3_ugcm_norm),(-0.677109903376909 * t_bmp_norm) + (0.0993468651330498 * p_bmp_norm) + (1.5240745945493 * t_dht_norm) + (-2.36616319091351 * h_dht_norm) + (-36.2056772167541 * O3_ugcm_norm),(-1.06930767071 * t_bmp_norm) + (1.46599785200901 * p_bmp_norm) + (-0.446432420987656 * t_dht_norm) + (-1.91127189232376 * h_dht_norm) + (-3.71896023765051 * O3_ugcm_norm),(-3.6445211181401 * t_bmp_norm) + (1.96078243417294 * p_bmp_norm) + (-1.43673244402084 * t_dht_norm) + (-2.42764035106038 * h_dht_norm) + (-18.9303966159716 * O3_ugcm_norm),(-0.734976126546473 * t_bmp_norm) + (1.07216444706174 * p_bmp_norm) + (-0.647686420062531 * t_dht_norm) + (-1.74331387294239 * h_dht_norm) + (-2.64713888562304 * O3_ugcm_norm),(-0.682987891692585 * t_bmp_norm) + (2.15344572871164 * p_bmp_norm) + (-0.300098029886059 * t_dht_norm) + (-1.99585107400641 * h_dht_norm) + (-7.00962272083723 * O3_ugcm_norm),(-1.56200115948548 * t_bmp_norm) + (2.06010363501176 * p_bmp_norm) + (0.301922040857707 * t_dht_norm) + (-2.30863693751623 * h_dht_norm) + (-1.15760906804418 * O3_ugcm_norm),(-0.286872982233722 * t_bmp_norm) + (1.74075448611903 * p_bmp_norm) + (0.363331879523432 * t_dht_norm) + (-0.700889828516057 * h_dht_norm) + (-0.853075533993973 * O3_ugcm_norm),(-1.90371162148426 * t_bmp_norm) + (1.88755711249278 * p_bmp_norm) + (0.434825359249157 * t_dht_norm) + (-2.76981901820866 * h_dht_norm) + (-9.98326959355647 * O3_ugcm_norm),(-1.4910111006307 * t_bmp_norm) + (1.73669722506005 * p_bmp_norm) + (-0.738339831208518 * t_dht_norm) + (-1.32657372879183 * h_dht_norm) + (-3.72069376379171 * O3_ugcm_norm),(-0.500957830612854 * t_bmp_norm) + (1.70243897311432 * p_bmp_norm) + (0.120674111757538 * t_dht_norm) + (-2.01529680529288 * h_dht_norm) + (-0.837996218079767 * O3_ugcm_norm),(-0.683593501621679 * t_bmp_norm) + (1.65069791936283 * p_bmp_norm) + (0.12603647376648 * t_dht_norm) + (-1.09125784036402 * h_dht_norm) + (-3.26746230300989 * O3_ugcm_norm),(-1.93440277821506 * t_bmp_norm) + (1.34343140286397 * p_bmp_norm) + (0.780784874384666 * t_dht_norm) + (-1.78039048273192 * h_dht_norm) + (-5.96191069711033 * O3_ugcm_norm),(-3.12624412622136 * t_bmp_norm) + (1.18592679788806 * p_bmp_norm) + (-1.3842636025099 * t_dht_norm) + (-2.12452381071928 * h_dht_norm) + (-10.7657056995993 * O3_ugcm_norm),(-0.0428237228826453 * t_bmp_norm) + (1.07677476174956 * p_bmp_norm) + (1.61722925486998 * t_dht_norm) + (-2.68920682214428 * h_dht_norm) + (0.251406325220099 * O3_ugcm_norm),(0.723095602067637 * t_bmp_norm) + (0.738038488933803 * p_bmp_norm) + (1.61597407288965 * t_dht_norm) + (-3.54871805953833 * h_dht_norm) + (-5.40960865904606 * O3_ugcm_norm),(-2.20796302130776 * t_bmp_norm) + (6.27339122363747 * p_bmp_norm) + (-0.199947646495169 * t_dht_norm) + (-3.19112956533346 * h_dht_norm) + (-18.447059761116 * O3_ugcm_norm),(-1.03295419551595 * t_bmp_norm) + (0.459857404203019 * p_bmp_norm) + (2.24277596295965 * t_dht_norm) + (-2.70938845360034 * h_dht_norm) + (-11.6477226171028 * O3_ugcm_norm),(-0.737858035038381 * t_bmp_norm) + (1.12271636001003 * p_bmp_norm) + (-0.0366599522926255 * t_dht_norm) + (-1.69929507840065 * h_dht_norm) + (-1.59173816868629 * O3_ugcm_norm),(0.279022726776438 * t_bmp_norm) + (1.78535307219381 * p_bmp_norm) + (0.954498387231722 * t_dht_norm) + (-2.3853732347506 * h_dht_norm) + (0.137507172653852 * O3_ugcm_norm),(-1.17404508673591 * t_bmp_norm) + (3.70464548373019 * p_bmp_norm) + (-0.843811692715493 * t_dht_norm) + (-1.2275951764947 * h_dht_norm) + (-2.90249930887107 * O3_ugcm_norm),(-0.274633666441788 * t_bmp_norm) + (2.75472826301406 * p_bmp_norm) + (0.396444063238276 * t_dht_norm) + (-3.04024935166137 * h_dht_norm) + (-5.46477062662958 *

```

O3_ugcm_norm),(-0.564938600373829 * t_bmp_norm) + (1.42970090581459 * p_bmp_norm) + (-
0.0411556979971471 * t_dht_norm) + (-0.57293874668549 * h_dht_norm) + (-3.98351318353601 *
O3_ugcm_norm),(-1.4687309000663 * t_bmp_norm) + (1.57480342341963 * p_bmp_norm) + (1.13499758524005
* t_dht_norm) + (-1.49260613902243 * h_dht_norm) + (-6.34986731359228 * O3_ugcm_norm),(-
4.38018897654391 * t_bmp_norm) + (1.07378606964061 * p_bmp_norm) + (-1.02095105348069 * t_dht_norm) +
(-2.5416133447041 * h_dht_norm) + (-19.6248028026523 * O3_ugcm_norm),(-1.58972824347583 * t_bmp_norm)
+ (0.648730403238373 * p_bmp_norm) + (0.70872097200491 * t_dht_norm) + (-3.08183986329556 * h_dht_norm)
+ (-4.71077977076935 * O3_ugcm_norm));
334. float A_B_CO[O_CO] = {( -4.81993208235237 * t_bmp_norm) + (-11.7957589859291 * p_bmp_norm) +
(0.26385234553728 * t_dht_norm) + (3.34719003634355 * h_dht_norm) + (-46.2638281454142 * CO_ppm_norm),(-
3.79961150174138 * t_bmp_norm) + (-26.0665285645074 * p_bmp_norm) + (-2.49885750446647 * t_dht_norm) +
(16.8432960329689 * h_dht_norm) + (3.09576907587308 * CO_ppm_norm),(-3.57285330451043 * t_bmp_norm) +
(-28.6447945518593 * p_bmp_norm) + (-2.07748569984067 * t_dht_norm) + (10.6868099524529 * h_dht_norm) +
(0.854774492564317 * CO_ppm_norm),(-3.88099005461419 * t_bmp_norm) + (-22.5336804612949 *
p_bmp_norm) + (0.66620597469903 * t_dht_norm) + (8.17928129058789 * h_dht_norm) + (-13.1817452096824 *
CO_ppm_norm),(-4.95980092413715 * t_bmp_norm) + (-8.89291551624602 * p_bmp_norm) + (-
0.394463637941711 * t_dht_norm) + (4.36417995360163 * h_dht_norm) + (-45.1237863005801 *
CO_ppm_norm),(-5.73080243654968 * t_bmp_norm) + (-27.0690600525856 * p_bmp_norm) + (-3.3413848610255
* t_dht_norm) + (9.33496190118121 * h_dht_norm) + (21.9157751682004 * CO_ppm_norm),(-6.18148246306759
* t_bmp_norm) + (-8.3613238432215 * p_bmp_norm) + (-3.14083798988995 * t_dht_norm) + (1.84082907919884
* h_dht_norm) + (-37.2586297562489 * CO_ppm_norm),(-2.77070692267563 * t_bmp_norm) + (-
16.0590239132727 * p_bmp_norm) + (-0.236492335376253 * t_dht_norm) + (0.634324311966837 * h_dht_norm) +
(-58.3670219605121 * CO_ppm_norm),(-6.11725731388071 * t_bmp_norm) + (-8.40437311068588 *
p_bmp_norm) + (-2.60892370979517 * t_dht_norm) + (-0.94066944129334 * h_dht_norm) + (-52.5238293397437
* CO_ppm_norm),(-7.07511224018618 * t_bmp_norm) + (-33.2874939418528 * p_bmp_norm) + (-
4.59753583137504 * t_dht_norm) + (12.6206238910122 * h_dht_norm) + (6.03760358538326 * CO_ppm_norm),(-
2.50808053706551 * t_bmp_norm) + (-17.0436550104682 * p_bmp_norm) + (-2.16085198801706 * t_dht_norm) +
(4.75624341515023 * h_dht_norm) + (-19.8530986110681 * CO_ppm_norm),(-9.07450812072531 * t_bmp_norm)
+ (-30.4149759779519 * p_bmp_norm) + (-4.09358916428355 * t_dht_norm) + (8.70291710266399 * h_dht_norm)
+ (7.1422095035704 * CO_ppm_norm),(-3.56507511629741 * t_bmp_norm) + (-33.5382622048908 * p_bmp_norm)
+ (3.21807114921607 * t_dht_norm) + (8.36875521509299 * h_dht_norm) + (6.38390044464466 *
CO_ppm_norm),(-10.2789204680171 * t_bmp_norm) + (-11.3846101584007 * p_bmp_norm) + (-
5.87210082759455 * t_dht_norm) + (-4.08373491164314 * h_dht_norm) + (-36.4998306804086 * CO_ppm_norm),(-
9.5837718142276 * t_bmp_norm) + (-33.8054259079517 * p_bmp_norm) + (-7.32760919560147 * t_dht_norm) +
(8.92000785697646 * h_dht_norm) + (17.6438986833995 * CO_ppm_norm),(-7.54584107192919 * t_bmp_norm) +
(-9.2643876007903 * p_bmp_norm) + (-3.91817902956842 * t_dht_norm) + (2.22395346510051 * h_dht_norm) +
(-44.4502991017349 * CO_ppm_norm),(-5.45420073408046 * t_bmp_norm) + (-17.2507018099129 *
p_bmp_norm) + (-2.52222404044651 * t_dht_norm) + (3.89306999400192 * h_dht_norm) + (-34.0034423046034 *
CO_ppm_norm),(-3.86707953005304 * t_bmp_norm) + (-21.2147490303341 * p_bmp_norm) + (-2.9321238111709
* t_dht_norm) + (2.41254703286871 * h_dht_norm) + (-24.1477183530099 * CO_ppm_norm),(-4.47269796667745
* t_bmp_norm) + (-20.8444333068783 * p_bmp_norm) + (-2.53507471081234 * t_dht_norm) + (7.12815356078253
* h_dht_norm) + (-22.0756800255856 * CO_ppm_norm),(-4.93349475554172 * t_bmp_norm) + (-15.586496123556
* p_bmp_norm) + (-0.140692371695318 * t_dht_norm) + (1.72232626112791 * h_dht_norm) + (-61.4112921514164
* CO_ppm_norm),(-3.36683913492174 * t_bmp_norm) + (-19.3726449524241 * p_bmp_norm) + (-
0.96561832668918 * t_dht_norm) + (2.2825374253076 * h_dht_norm) + (-35.9504312412095 * CO_ppm_norm),(-
3.79350173486517 * t_bmp_norm) + (-23.0244326122293 * p_bmp_norm) + (3.97537080442138 * t_dht_norm) +
(7.37614703368476 * h_dht_norm) + (12.4937503333772 * CO_ppm_norm),(-9.32327188050256 * t_bmp_norm) +
(-29.2782863720486 * p_bmp_norm) + (-8.57559986274728 * t_dht_norm) + (6.93162972516852 * h_dht_norm) +
(5.57610050737958 * CO_ppm_norm),(-4.34737043100559 * t_bmp_norm) + (-28.7641974321605 * p_bmp_norm)
+ (-2.88181703192538 * t_dht_norm) + (10.2093117725538 * h_dht_norm) + (2.83605694330598 *
CO_ppm_norm),(-3.35241061349218 * t_bmp_norm) + (-10.8362925634092 * p_bmp_norm) + (-
4.54084489017097 * t_dht_norm) + (0.649201164146915 * h_dht_norm) + (-68.5211858026487 *
CO_ppm_norm),(-2.79610727254979 * t_bmp_norm) + (-27.3077469890334 * p_bmp_norm) + (1.74127384859157
* t_dht_norm) + (10.1046878600081 * h_dht_norm) + (-4.04994820183023 * CO_ppm_norm),(-2.88101181080323
* t_bmp_norm) + (-3.18383308721878 * p_bmp_norm) + (-0.660945500702586 * t_dht_norm) +
(1.39839265310461 * h_dht_norm) + (-53.3633997981824 * CO_ppm_norm),(-4.68642490855944 * t_bmp_norm)
+ (-27.0275550241801 * p_bmp_norm) + (-4.61757117182236 * t_dht_norm) + (9.13703728316776 * h_dht_norm)

```

+ (-8.14499710344588 * CO_ppm_norm),(-15.2333873782009 * t_bmp_norm) + (-31.3392800112079 * p_bmp_norm) + (-15.0420011226922 * t_dht_norm) + (8.51704005592893 * h_dht_norm) + (6.51572642621275 * CO_ppm_norm),(-11.1295271568987 * t_bmp_norm) + (-8.15656678063853 * p_bmp_norm) + (-5.96394472200149 * t_dht_norm) + (-1.25866492493119 * h_dht_norm) + (-43.2089254123943 * CO_ppm_norm),(-4.7253322361772 * t_bmp_norm) + (-17.5796716415603 * p_bmp_norm) + (-3.09229613683994 * t_dht_norm) + (7.41437634374741 * h_dht_norm) + (-24.2272533732168 * CO_ppm_norm),(-4.72768704774877 * t_bmp_norm) + (-26.0776327579176 * p_bmp_norm) + (-3.46612464301434 * t_dht_norm) + (10.3658666644588 * h_dht_norm) + (-6.71478751764498 * CO_ppm_norm),(-4.41081777265976 * t_bmp_norm) + (-17.92730069966 * p_bmp_norm) + (-2.23617085795537 * t_dht_norm) + (5.60383884889783 * h_dht_norm) + (-26.2866094875137 * CO_ppm_norm),(-1.4291545140545 * t_bmp_norm) + (-12.8902901312775 * p_bmp_norm) + (3.26036951373046 * t_dht_norm) + (8.61982292207763 * h_dht_norm) + (-32.9882119310567 * CO_ppm_norm),(-8.09883421680554 * t_bmp_norm) + (-15.2831390846557 * p_bmp_norm) + (-5.1700281121097 * t_dht_norm) + (1.46967876213992 * h_dht_norm) + (-18.2521034232611 * CO_ppm_norm),(-8.93635172707179 * t_bmp_norm) + (-11.9790900491102 * p_bmp_norm) + (-6.64057521899159 * t_dht_norm) + (4.58280497261343 * h_dht_norm) + (-28.4131108601685 * CO_ppm_norm),(-7.07362413314264 * t_bmp_norm) + (-14.222577258886 * p_bmp_norm) + (-4.72300126863448 * t_dht_norm) + (6.1240799830473 * h_dht_norm) + (-25.5388711101774 * CO_ppm_norm),(-0.281886919824893 * t_bmp_norm) + (-5.89586322560689 * p_bmp_norm) + (6.20148165110846 * t_dht_norm) + (-2.09272060361517 * h_dht_norm) + (-23.7315743558731 * CO_ppm_norm),(-1.4473066087615 * t_bmp_norm) + (-24.7733558305971 * p_bmp_norm) + (-0.960954140942039 * t_dht_norm) + (7.67776485457002 * h_dht_norm) + (-2.46943170530559 * CO_ppm_norm),(-3.65019614316276 * t_bmp_norm) + (-22.1899701326665 * p_bmp_norm) + (-2.38701997163509 * t_dht_norm) + (9.45037625777752 * h_dht_norm) + (-9.39279402025223 * CO_ppm_norm),(-3.03028713882444 * t_bmp_norm) + (-24.811825578851 * p_bmp_norm) + (-1.27209780203799 * t_dht_norm) + (6.75578011591019 * h_dht_norm) + (-13.461544259166 * CO_ppm_norm),(-7.2042763817137 * t_bmp_norm) + (-25.420174745006 * p_bmp_norm) + (-3.64923612579851 * t_dht_norm) + (7.02793299022015 * h_dht_norm) + (3.14347781417538 * CO_ppm_norm),(-4.54911383098841 * t_bmp_norm) + (-18.3828746994574 * p_bmp_norm) + (-3.61603965299977 * t_dht_norm) + (6.34776494401262 * h_dht_norm) + (-20.2163442097863 * CO_ppm_norm),(-7.03967745435615 * t_bmp_norm) + (-31.205410918828 * p_bmp_norm) + (-5.47840852039485 * t_dht_norm) + (10.4422392878998 * h_dht_norm) + (14.5141440037112 * CO_ppm_norm),(-4.13845110171098 * t_bmp_norm) + (-30.7076206952785 * p_bmp_norm) + (2.45462131449018 * t_dht_norm) + (10.7265695000586 * h_dht_norm) + (-9.24523445753201 * CO_ppm_norm),(-4.05166247693852 * t_bmp_norm) + (-20.9630729737828 * p_bmp_norm) + (-3.74980241342083 * t_dht_norm) + (8.33788950406961 * h_dht_norm) + (-11.9650249320956 * CO_ppm_norm),(-1.11392253850821 * t_bmp_norm) + (-22.7948037065799 * p_bmp_norm) + (11.3436463944145 * t_dht_norm) + (7.04118986383086 * h_dht_norm) + (-63.9867384764881 * CO_ppm_norm),(-3.20570156065381 * t_bmp_norm) + (-13.8136938179509 * p_bmp_norm) + (-3.5955565805673 * t_dht_norm) + (6.26424180795539 * h_dht_norm) + (-70.3355924022352 * CO_ppm_norm),(-4.73403387640569 * t_bmp_norm) + (-24.2801186901872 * p_bmp_norm) + (-3.53339636510151 * t_dht_norm) + (7.88803979067842 * h_dht_norm) + (-8.23639877224432 * CO_ppm_norm),(-13.2774827834831 * t_bmp_norm) + (-34.4075067674996 * p_bmp_norm) + (-16.4560601419027 * t_dht_norm) + (3.82728307527248 * h_dht_norm) + (17.4246702222847 * CO_ppm_norm),(-0.188741404839516 * t_bmp_norm) + (-11.74430088687 * p_bmp_norm) + (-3.42377788031867 * t_dht_norm) + (5.79579149793755 * h_dht_norm) + (-41.4937848125944 * CO_ppm_norm),(-3.46502710620722 * t_bmp_norm) + (-20.5514457806739 * p_bmp_norm) + (-0.740277636676443 * t_dht_norm) + (1.71305553694675 * h_dht_norm) + (-35.6747010883125 * CO_ppm_norm),(-4.36795348494648 * t_bmp_norm) + (-36.3170066087176 * p_bmp_norm) + (4.62904365979695 * t_dht_norm) + (12.3051469359968 * h_dht_norm) + (-2.20206933917998 * CO_ppm_norm),(-6.49780981813239 * t_bmp_norm) + (-24.5519712608648 * p_bmp_norm) + (-5.41495346924092 * t_dht_norm) + (8.20867239599922 * h_dht_norm) + (-14.4604359662871 * CO_ppm_norm),(-2.73885893927478 * t_bmp_norm) + (-24.9920632990855 * p_bmp_norm) + (1.47271974106436 * t_dht_norm) + (6.31731970126332 * h_dht_norm) + (-11.7364481317214 * CO_ppm_norm),(-5.65063774572126 * t_bmp_norm) + (-17.9304051794863 * p_bmp_norm) + (-3.51741585024215 * t_dht_norm) + (4.26469144182714 * h_dht_norm) + (-22.3134301670286 * CO_ppm_norm),(-3.50392255217846 * t_bmp_norm) + (-19.3932988899545 * p_bmp_norm) + (-2.98250586694297 * t_dht_norm) + (7.92305147339524 * h_dht_norm) + (-15.479671328562 * CO_ppm_norm),(-3.91308889722112 * t_bmp_norm) + (-18.3428695230923 * p_bmp_norm) + (-2.8952044033621 * t_dht_norm) + (6.45305001970601 * h_dht_norm) + (-18.6886481403111 * CO_ppm_norm),(-3.46958530440398 * t_bmp_norm) + (-22.0338364421914 * p_bmp_norm) + (-2.87410341891153 * t_dht_norm) + (10.022605454208 * h_dht_norm) + (-10.6056707432182 * CO_ppm_norm),(-9.38127605387389 * t_bmp_norm) + (-28.6277371364698 * p_bmp_norm) + (-0.386569580070251 * t_dht_norm) + (11.6084515565409 * h_dht_norm) + (5.05522228198485 *

```

CO_ppm_norm),(-0.701131086664875 * t_bmp_norm) + (1.3081692954347 * p_bmp_norm) + (-
0.507064449867734 * t_dht_norm) + (-1.57403765750532 * h_dht_norm) + (-125.751483053078 *
CO_ppm_norm),(-4.47066606755532 * t_bmp_norm) + (-24.1691009983053 * p_bmp_norm) + (-
2.41027075874804 * t_dht_norm) + (11.328841721615 * h_dht_norm) + (-12.0220322344972 * CO_ppm_norm));
335.
336.
337.//Funções para previsão das concentrações dos gases:
338. MP_new = CalculatePrediction(MP_gas, A_B_MP);
339. O3_new = CalculatePrediction(O3_gas, A_B_O3);
340. CO_new = CalculatePrediction(CO_gas, A_B_CO);
341.}
342.
343.void LeituraSerialMonitor(){
344. Serial.print(diadomes);
345. Serial.print("/");
346. Serial.print(mes);
347. Serial.print("/");
348. Serial.print(ano);
349. Serial.print(",");
350. Serial.print(diadasemana_print);
351. Serial.print(",");
352. Serial.print(horas);
353. Serial.print(":");
354. Serial.print(minutos);
355. Serial.print(":");
356. Serial.print(segundos);
357. Serial.print(",");
358. Serial.print(t_bmp);
359. Serial.print(",");
360. Serial.print(p_bmp);
361. Serial.print(",");
362. Serial.print(t_dht);
363. Serial.print(",");
364. Serial.print(h_dht);
365. Serial.print(",");
366. Serial.print(MP_ugcm,4);
367. Serial.print(",");
368. Serial.print(O3_ugcm,4);
369. Serial.print(",");
370. Serial.print(CO_ppm,4);
371. Serial.print(",");
372. Serial.print(indice_MP);
373. Serial.print(",");
374. Serial.print(indice_O3);
375. Serial.print(",");
376. Serial.print(indice_CO);
377. Serial.print(",");
378. Serial.print(IQAr_final);
379. Serial.print(",");
380. Serial.print(classe_final);
381. Serial.print (" ");
382. Serial.print (MP_new);
383. Serial.print (" ");
384. Serial.print (O3_new);
385. Serial.print (" ");
386. Serial.println (CO_new);
387.}

```

```

388.
389. void LeituraSD()
390. {
391.   File MySensorData = SD.open("DATALOG.txt", FILE_WRITE);      //Abrir DATALOG.txt no cartão SD
392.   if (MySensorData){                                           //Somente fará isso se o arquivo de dados abrir com sucesso
393.     digitalWrite(GreenPin, HIGH);
394.     MySensorData.print (diadomes);
395.     MySensorData.print ("/");
396.     MySensorData.print (mes);
397.     MySensorData.print ("/");
398.     MySensorData.print (ano);
399.     MySensorData.print (",");
400.     MySensorData.print (diadasemana_print);
401.     MySensorData.print (",");
402.     MySensorData.print (horas);
403.     MySensorData.print (",");
404.     MySensorData.print (minutos);
405.     MySensorData.print (",");
406.     MySensorData.print (segundos);
407.     MySensorData.print (",");
408.     MySensorData.print (t_bmp);
409.     MySensorData.print (",");
410.     MySensorData.print (p_bmp);
411.     MySensorData.print (",");
412.     MySensorData.print (t_dht);
413.     MySensorData.print (",");
414.     MySensorData.print (h_dht);
415.     MySensorData.print (",");
416.     MySensorData.print (MP_ugcm,4);
417.     MySensorData.print (",");
418.     MySensorData.print (O3_ugcm,4);
419.     MySensorData.print (",");
420.     MySensorData.print (CO_ppm,4);
421.     MySensorData.print (",");
422.     MySensorData.print (indice_MP);
423.     MySensorData.print (",");
424.     MySensorData.print (indice_O3);
425.     MySensorData.print(",");
426.     MySensorData.print (indice_CO);
427.     MySensorData.print (",");
428.     MySensorData.print (IQAr_final);
429.     MySensorData.print (",");
430.     MySensorData.print (classe_final);
431.     MySensorData.print (",");
432.     MySensorData.print (MP_new);
433.     MySensorData.print (",");
434.     MySensorData.print (O3_new);
435.     MySensorData.print (",");
436.     MySensorData.println (CO_new);
437.     MySensorData.close();                                     //Fechar o arquivo
438.
439.   LeituraSerialMonitor();
440. } else {
441.   Serial.println("Erro ao abrir o arquivo txt.");
442. }
443. }
444.

```

```

445.void LeituraWiFi()
446.{
447.//Verifica se o ESP8266 está enviando dados:
448.if (esp8266.available()){
449.if (esp8266.find("+IPD,")){
450.  delay(300);
451.  int connectionId = esp8266.read() - 48;
452.  String webpage = "<head><meta http-equiv=""refresh"" content=""3""></head>";
453.  webpage += "<center><table border=1 cellspacing=0 cellpadding=15>";
454.  webpage += "<tr><td><center>";
455.  webpage += "<img src=https://i.imgur.com/SIL17g3.png>";
456.  webpage += "<br>";
457.  webpage += "<b>";
458.  webpage += diadomes;
459.  webpage += "/";
460.  webpage += mes;
461.  webpage += "/";
462.  webpage += ano;
463.  webpage += " - ";
464.  webpage += horas;
465.  webpage += ".";
466.  webpage += minutos;
467.  webpage += "h";
468.  webpage += "<br><br>";
469.  webpage += diadasemana_print;
470.  webpage += "</center><br><br><br>";
471.  webpage += "<table border=1 cellspacing=2 cellpadding=4 bordercolor=#BEBEBE>";
472.  webpage += "<thead><tr><th><center>Temperatura (Celsius)</center></th>";
473.  webpage += "<th><center>Umidade (%)</center></th>";
474.  webpage += "<th><center>Pressao (hPa)</center></th></tr></thead>";
475.  webpage += "<tbody><tr><td><center>";
476.  webpage += (t_dht + t_bmp)/2.0;
477.  webpage += "</center></td>";
478.  webpage += "<td><center>";
479.  webpage += h_dht;
480.  webpage += "</center></td>";
481.  webpage += "<td><center>";
482.  webpage += p_bmp * 0.01;
483.  webpage += "</center></td>";
484.  webpage += "</tr></tbody></table><br><br><br>";
485.  webpage += "<table border=1 cellspacing=2 cellpadding=4 bordercolor=#BEBEBE>";
486.  webpage += "<thead><tr><th><center>Material Particulado (ug/m3)</center></th>";
487.  webpage += "<th><center>Ozonio (ug/m3)</center></th>";
488.  webpage += "<th><center>Monoxido de Carbono (ppm)</center></th>";
489.  webpage += "<th><center>Indice IQAr</center></th>";
490.  webpage += "<th><center>Classificacao</center></th></tr></thead>";
491.  webpage += "<tbody><tr><td><center>";
492.  webpage += MP_ugcm;
493.  webpage += "</center></td>";
494.  webpage += "<td><center>";
495.  webpage += O3_ugcm;
496.  webpage += "</center></td>";
497.  webpage += "<td><center>";
498.  webpage += CO_ppm;
499.  webpage += "</center></td>";
500.  webpage += "<td><center>";
501.  webpage += IQAr_final;

```

```

502. webpage += "</center></td>";
503. if (classe_final == "Boa"){
504.   webpage += "<td bgcolor=#00FF00><b><center>Boa";
505. } else if (classe_final == "Regular"){
506.   webpage += "<td bgcolor=#FFFF00><b><center>Regular";
507. } else if (classe_final == "Inadequada"){
508.   webpage += "<td bgcolor=#FF8C00><b><center>Inadequada";
509. } else if (classe_final == "Ma"){
510.   webpage += "<td bgcolor=#FF0000><b><center>Ma";
511. } else if (classe_final == "Pessima"){
512.   webpage += "<td bgcolor=#9400D3><b><center>Pessima";
513. }
514. webpage += "</center></b></td></tr></tbody></table><br><br><br>";
515. webpage += "<table border=1 cellspacing=2 cellpadding=10 bordercolor=#BEBEBE>";
516. webpage += "<tr><td>";
517. webpage += "<small><p><b>*Previsao para os proximos 5 minutos: </b></p></small>";
518. webpage += "<small><p>- MP (ug/m3): ";
519. webpage += MP_new;
520. webpage += "</p></small>";
521. webpage += "<small><p>- O3 (ug/m3): ";
522. webpage += O3_new;
523. webpage += "</p></small>";
524. webpage += "<small><p>- CO (ppm): ";
525. webpage += CO_new;
526. webpage += "</p></small>";
527. webpage += "</td></tr></table><br>";
528. webpage += "</td></tr></table></center>";
529.
530. String cipSend = "AT+CIPSEND=";
531. cipSend += connectionId;
532. cipSend += ",";
533. cipSend += webpage.length();
534. cipSend += "\r\n";
535.
536. sendData(cipSend, 1000, DEBUG);
537. sendData(webpage, 1000, DEBUG);
538.
539. String closeCommand = "AT+CIPCLOSE=";
540. closeCommand += connectionId;           //Acrescenta conexão ID
541. closeCommand += "\r\n";
542.
543. sendData(closeCommand, 3000, DEBUG);
544. }
545. }
546. }
547.
548. String sendData(String command, const int timeout, boolean debug)
549. {
550. //Envio dos comandos AT para o módulo ESP8266:
551. String response = "";
552. esp8266.print(command);
553. long int time = millis();
554. while ( (time + timeout) > millis()){
555.   while (esp8266.available()){
556.     char c = esp8266.read();           //Lê o próximo sinal
557.     response += c;
558.   }

```

```

559. }
560. if (debug){
561.   Serial.print(response);
562. }
563. return response;
564.}
565.
566.float MQResistanceCalculation(float raw_adc, int sensor_id){
567. if (sensor_id == MQ131) {
568.   return ( ((float)MQ131_RL*(1023.0-raw_adc)/raw_adc));
569. } else if (sensor_id == MICS5524) {
570.   return ( ((float)MICS5524_RL*(1023.0-raw_adc)/raw_adc));
571. }
572. return 0;
573.}
574.
575.float MQRead(float mq_pin, int sensor_id){
576. int i;
577. float rs=0;
578.
579. for (i=0;i<read_sample_times;i++) {
580.   rs += MQResistanceCalculation(analogRead(mq_pin), sensor_id);
581.   delay(read_sample_interval);
582. }
583. rs = rs/read_sample_times;
584. return rs;
585.}
586.
587.float MQGetGasPercentage(float rs_ro_ratio, int sensor_id){
588. if (sensor_id == MQ131) {
589.   return MQGetPercentage(rs_ro_ratio,O3_curve);
590. } else if (sensor_id == MICS5524) {
591.   return MQGetPercentage(rs_ro_ratio,CO_curve);
592. }
593. return 0;
594.}
595.
596.float MQGetPercentage(float rs_ro_ratio, float *pcurve){
597. return (pow(10.0,((log10(rs_ro_ratio)-pcurve[1])/pcurve[2]) + pcurve[0]]));
598.}
599.
600.float IndiceCalculation(float ppm,int gas_id){
601. if (gas_id == MP_gas){
602.   return IndiceCalculation(ppm,MP_ranges);
603. } else if (gas_id == O3_gas){
604.   return IndiceCalculation(ppm,O3_ranges);
605. } else if (gas_id == CO_gas){
606.   return IndiceCalculation(ppm,CO_ranges);
607. }
608.}
609.
610.float IndiceCalculation(float ppm, float *pcurve){
611. if (ppm <= pcurve[0]){
612.   return ((lf_b)/(pcurve[0]))*(ppm);
613. } else if ((ppm > pcurve[0]) && (ppm <= pcurve[1])){
614.   return (((lf_r - li_r)/(pcurve[1] - pcurve[0]))*(ppm - pcurve[0])) + li_r;
615. } else if ((ppm > pcurve[1]) && (ppm <= pcurve[2])){

```

```

616. return (((lf_i - li_i)/(pcurve[2] - pcurve[1]))*(ppm - pcurve[1]))+ li_i;
617. } else if ((ppm > pcurve[2]) && (ppm <= pcurve[3])){
618. return (((lf_m - li_m)/(pcurve[3] - pcurve[2]))*(ppm - pcurve[2]))+ li_m;
619. } else if (ppm > pcurve[3]){
620. return (ppm - pcurve[3])+ lf_m;
621. }
622.}
623.
624.float CalculatePrediction (int gas_id, float* Matrix_A_B){
625. if (gas_id == MP_gas){
626. return PredictionMath(Matrix_A_B, Bias_1_MP, C_MP, Bias_2_MP, th, ex, O_MP, MP_gas);
627. } else if (gas_id == O3_gas){
628. return PredictionMath(Matrix_A_B, Bias_1_O3, C_O3, Bias_2_O3, ex, ex, O_O3, O3_gas);
629. } else if (gas_id == CO_gas){
630. return PredictionMath(Matrix_A_B, Bias_1_CO, C_CO, Bias_2_CO, lo, lo, O_CO, CO_gas);
631. }
632. return 0;
633.}
634.
635.float PredictionMath(float* Matrix_A_B, float* Bias_hidden, float* Weigh_final, float Bias_final, int
function_hidden, int function_final, int O_gas, int gas_id){
636. float D[O_gas];
637. float E = 0;
638. float F;
639.
640. if (function_hidden == th){
641. for (int i = 0; i < O_gas; i++){
642. D[i] = tanh(Matrix_A_B[i] + Bias_hidden[i]);
643. E += (D[i] * Weigh_final[i]);
644. }
645. } else if (function_hidden == ex){
646. for (int i = 0; i < O_gas; i++){
647. D[i] = exp(Matrix_A_B[i] + Bias_hidden[i]);
648. E += (D[i] * Weigh_final[i]);
649. }
650. } else if (function_hidden == lo){
651. for (int i = 0; i < O_gas; i++){
652. D[i] = 1/(1 + (exp(-(Matrix_A_B[i] + Bias_hidden[i]))));
653. E += (D[i] * Weigh_final[i]);
654. }
655. }
656.
657. if (function_final == ex){
658. F = exp(E + Bias_final);
659. } else if (function_final == lo){
660. F = 1/(1 + (exp(-(E + Bias_final))));
661. }
662.
663. if (gas_id == MP_gas){
664. return ((F + 0.0000583577238692069)/0.0448905568224668);
665. } else if (gas_id == O3_gas){
666. return ((F + 0.0148206328853878)/0.00885501158235515);
667. } else if (gas_id == CO_gas){
668. return (F / 0.100301908745323);
669. }
670. return 0;
671.}

```