

UNESP

Faculdade de Engenharia do Campus de Guaratinguetá

LUCIANO EUSTÁQUIO CHAVES

**MODELOS COMPUTACIONAIS *FUZZY* E *NEURO-FUZZY*
PARA AVALIAREM OS EFEITOS DA POLUIÇÃO DO AR**

GUARATINGUETÁ

2013

LUCIANO EUSTÁQUIO CHAVES

**MODELOS COMPUTACIONAIS *FUZZY* E *NEURO-FUZZY*
PARA AVALIAREM OS EFEITOS DA POLUIÇÃO DO AR**

Tese apresentada à Faculdade de Engenharia do
Campus de Guaratinguetá, Universidade Estadual
Paulista, para a qualificação do título de Doutor
em Engenharia Mecânica na área de Projetos.

Orientador: Prof. Dr. Luiz Fernando Costa
Nascimento.

Co-orientadora: Profa. Dra. Paloma Maria Silva
Rocha Rizol.

GUARATINGUETÁ

2013

LUCIANO EUSTÁQUIO CHAVES

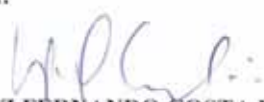
ESTA TESE FOI JULGADA ADEQUADA PARA A OBTENÇÃO DO TÍTULO DE
"DOUTOR EM ENGENHARIA MECÂNICA"

PROGRAMA: ENGENHARIA MECÂNICA
ÁREA: PROJETOS

APROVADA EM SUA FORMA FINAL PELO PROGRAMA DE PÓS-GRADUAÇÃO

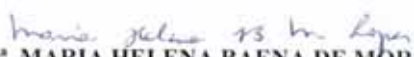

Prof. Dr. Edson Cocchieri Botelho
Coordenador

BANCA EXAMINADORA:


Prof. Dr. LUIZ FERNANDO COSTA NASCIMENTO
Orientador / UNESP-FEG


Prof. Dr. LEONARDO MESQUITA
UNESP-FEG


Prof. Dr. ANDREA PAULA PENELUPPI DE MEDEIROS
UNITAU


Prof. Dr. MARIA HELENA BAENA DE MORAES LOPES
F.E. UNICAMP


Prof. Dr. MARCOS ARBEX
FMUSP

Julho de 2013

DADOS CURRICULARES

LUCIANO EUSTÁQUIO CHAVES

NASCIMENTO:	23/01/1973 – Sete Lagoas / MG
FILIAÇÃO	Nery Chaves Neide Eustáquio da Silva
1996/1999	Curso de Graduação em Fisioterapia Universidade Católica de Petrópolis- UCP
2000/2001	Curso de Especialização em Fisioterapia Respiratória, Irmandade de Misericórdia Santa Casa de São Paulo-SP.
2004/2004	Especialização em Fisioterapia Respiratória e Terapia Intensiva, Associação Brasileira de Fisioterapia Respiratória e Terapia Intensiva- Assobrafir.
2006/2008	Curso de Pós-Graduação Stricto Sensu em Engenharia Mecânica, nível Mestrado com área de concentração em Engenharia Biomédica, na Faculdade de Engenharia do Campus de Guaratinguetá da Universidade Estadual Paulista.
2009/2013	Curso de Pós-Graduação Stricto Sensu em Engenharia Mecânica, nível Doutorado com área de concentração em Engenharia Biomédica, na Faculdade de Engenharia do Campus de Guaratinguetá da Universidade Estadual Paulista.

Dedico com muito amor e carinho a minha esposa Alline e meus filhos Livia e Gabriel; aos meus pais Nery e Neide, irmãos Luciana, Lúcio Nery e Elen, amigos de todas as horas.

AGRADECIMENTOS

À Deus, pelo dom da vida e pela coragem para a luta, onde sou apenas um instrumento para que Ele utilize de Sua autoridade para demonstrar seu amor...

ao Departamento de Engenharia Mecânica da UNESP – FEG, em especial ao Prof. Dr. Luiz Fernando Costa Nascimento, por suas valiosas orientações;

à Profa. Dra. Paloma Maria Silva Rocha Rizol pela contribuição e esclarecimentos para o aprimoramento desta tese;

ao Prof. Dr. Leonardo Mesquita de forma muito especial pelas observações e sugestões.

à Profa. Dra. Andréa Paula Penellupi de Medeiros, Profa. Dra. Maria Helena Baena de Moraes Lopes e ao Prof. Dr. Marcos Abdo Arbex por doarem seu precioso tempo participando desta banca.

à secretária do Departamento de Engenharia Mecânica, Rosiléa Ribeiro de Matos, pelas informações fornecidas e atenção no seu atendimento;

aos funcionários da Seção de Pós-Graduação da FEG/UNESP, Regina Célia Galvão Faria Alves, Maria Cristina Silva de Oliva, Renata Pereira da Rocha Barbosa e Rodrigo José Nunes;

às funcionárias da biblioteca da FEG/UNESP, em especial a Ana Maria Ramos Antunes, por sua contribuição no levantamento bibliográfico.

aos amigos, em especial ao Dr. Vinícius Ferreira de Souza, demais colegas, aos meus familiares e a todos que direta ou indiretamente contribuíram para que essa tese fosse realizada.

“Sonhar o sonho impossível,
Sofrer a angústia implacável,
Pisar onde os bravos não ousam,
Reparar o mal irreparável,
Amar um amor casto à distância,
Enfrentar o inimigo invencível,
Tentar quando as forças se esvaem,
Alcançar a estrela inatingível:
Essa continua sendo a minha busca”.

Dom Quixote

CHAVES, L. E. **Modelos computacionais *Fuzzy* e *Neuro-Fuzzy* para avaliarem os efeitos da poluição do ar**. 2013. 112f. Tese (Doutorado em Engenharia Mecânica) - Faculdade de Engenharia do Campus de Guaratinguetá, Universidade Estadual Paulista, Guaratinguetá, 2013.

RESUMO

O presente estudo teve por objetivo verificar a associação entre a exposição aos poluentes do ar e o número de internações hospitalares por asma e pneumonia. Para a verificação foi proposto desenvolver e validar modelos *fuzzy* (Mamdani) e *neuro-fuzzy* (Sugeno) e comparar qual dos modelos apresenta uma melhor eficácia para a predição de internações. A metodologia utilizada foi dividida em três módulos: limpeza e elaboração de dados, elaboração do modelo *fuzzy* (Mamdani) e elaboração do modelo *neuro-fuzzy* (Sugeno). Foram coletados dados reais de internações do DATASUS, os quais foram utilizados como saída do modelo. Os dados de entradas foram os poluentes do ar material particulado (MP₁₀), dióxido de enxofre (SO₂), ozônio (O₃) e a temperatura aparente (Tap). As saídas geradas pelos modelos foram comparadas e correlacionadas com os dados reais de internações através do Coeficiente de Correlação de Pearson. Para o estudo o nível de significância estatístico adotado foi $\alpha = 5\%$. A acurácia dos modelos foi realizada utilizando a Curva ROC. Neste estudo foi possível desenvolver e validar os modelos. O modelo *neuro-fuzzy* apresentou melhor correlação do que o modelo *fuzzy*; porém a acurácia foi melhor para o modelo *fuzzy*.

Palavras-Chave: Poluição atmosférica. Lógica *fuzzy*. *Neuro-fuzzy*. Doenças respiratórias.

CHAVES, L. E. **Computational models *Fuzzy* and *Neuro-Fuzzy* to assess the effects of air pollution**. 2013. 112f. Thesis (Doctorate in Mechanical Engineering)-Faculdade de Engenharia do Campus de Guaratinguetá, Universidade Estadual Paulista, Guaratinguetá, 2013.

ABSTRACT

This study aimed at investigating the association between exposure to air pollutants and the number of hospital admissions for asthma and pneumonia. For such verification it was proposed to develop and validate the Mamdani *fuzzy* and neuro-*fuzzy* (Sugeno) models and compare which of the two provides better efficacy in predicting hospitalization. The methodology was divided into three modules: data cleaning and preparation, elaboration of the *fuzzy* model (Mamdani) and elaboration of the neuro-*fuzzy* model (Sugeno). Data were collected from DATASUS actual admissions, which were used as the models output. The input data were air pollutants particulate matter (PM₁₀), sulfur dioxide (SO₂), ozone (O₃) and the apparent temperature (Tap). The outputs generated by the models were compared and correlated with the actual data of admissions through the Pearson Correlation Coefficient. In this study the level of statistical significance adopted was $\alpha = 5\%$. The accuracy of the models was performed using the ROC curve. In this study it was possible to develop and validate the models. The neuro-*fuzzy* model showed better correlation than the *fuzzy* model, but the accuracy was better for the *fuzzy* model.

Key-words: Atmospheric pollution. *Fuzzy* logic. Neuro-*fuzzy*. Respiratory diseases.

LISTA DE FIGURAS

Figura 1 – Áreas relacionadas com IA.....	21
Figura 2 – Gráficos comparativo da lógica clássica com a lógica <i>fuzzy</i>	24
Figura 3 – Representação dos conjuntos <i>fuzzy</i> . (a) Conjunto A, (b) Conjunto B, (c) Conjuntos $A \wedge B$ e $A \vee B$	26
Figura 4 – Funções de pertinência <i>fuzzy</i>	27
Figura 5 – Etapas de um sistema <i>fuzzy</i>	28
Figura 6 – Modelo Mamdani.....	29
Figura 7 – Modelo Takagi-Sugeno	29
Figura 8 – Comparativo do neurônio biológico com o matemático	31
Figura 9 – Rede de alimentação direta (<i>forwardfeed</i>).....	33
Figura 10 – Algoritmo <i>Back-Propagation</i> para rede neural de três camadas	35
Figura 11 – Exemplo de modelo de rede neural.....	35
Figura 12 – Arquitetura de um sistema neuro- <i>fuzzy</i>	40
Figura 13 – Estrutura do ANFIS.....	44
Figura 14 – Mecanismo de inferência.....	45
Figura 15 - Mapa do município de São José dos Campos	62
Figura 16 - Valores médios MP_{10} (CETESB) do ano de 2007.....	63
Figura 17 - Caminho para obter planilha DATASUS.....	64
Figura 18 - Arquivo para baixar planilhas DATASUS.....	64
Figura 19 - Arquivos para <i>downloads</i> para obter planilha DATASUS	65
Figura 20 - Planilha fornecida pelo DATASUS	65
Figura 21 - Planilha obtida do DATASUS.....	66
Figura 22 - Planilha para gerar número de internações	66
Figura 23 - Planilha desenvolvida no programa Excel	67
Figura 24 – Sistema de inferência <i>fuzzy</i> Mamdani com quatro entradas e uma saída	69
Figura 25 – Número de internações (muito baixo, baixo, médio, alto e muito alto).....	69
Figura 26 – Conjunto <i>fuzzy</i> para MP_{10} (BOA e REG: regular)	70
Figura 27 – Conjunto <i>fuzzy</i> para O_3 (BOA e INAD: inadequado)	71
Figura 28 – Conjunto <i>fuzzy</i> para SO_2 (BOA e INAD: inadequado)	71
Figura 29 – Conjunto <i>fuzzy</i> para Tap (INAD: inadequado e BOA)	72
Figura 30 – Regras <i>fuzzy</i> editadas no programa Matlab	73

Figura 31 – Janela <i>rule viewer</i> gerada pelo Matlab	74
Figura 32 – Janela inicial do ANFIS.....	76
Figura 33 – Conjuntos de dados para treinamento	76
Figura 34 – Dados a serem treinados (janela ANFIS)	77
Figura 35 – Geração FIS, janela do <i>toolbox</i> para gerar funções de pertinência	77
Figura 36 – Treinamento	78
Figura 37 – Testando agora (<i>test now</i>).....	79
Figura 38 – Janela de treinamento	79
Figura 39 - Checagem	80
Figura 40 – Estrutura do ANFIS.....	80
Figura 41 – Estrutura do modelo <i>fuzzy</i> Mamdani	83
Figura 42 – Gráficos da Curva ROC para MP ₁₀ : A)Lag0, B)Lag1 e C)Lag2.....	85
Figura 43 - Gráficos da Curva ROC para O ₃ : A)Lag0, B)Lag1 e C)Lag2.....	86
Figura 44 - Gráficos da Curva ROC para SO ₂ : A)Lag0, B)Lag1 e C)Lag2	87
Figura 45 – Tela de regras capturada do Matlab	88
Figura 46 – Tela capturada do Matlab com algumas regras.....	88
Figura 47 – Gráfico de superfície do número de interações relativo ao MP10 x Tap	89
Figura 48 – Gráficos de análises- a) NInter x MP ₁₀ e b) NInter x MP ₁₀	89
Figura 49 – Planilha com dados de entrada e saída para gerar modelos neuro- <i>fuzzy</i>	90
Figura 50 - Gráficos da Curva ROC para MP ₁₀ : A)Lag0, B)Lag1 e C)Lag2.....	92
Figura 51 - Gráficos da Curva ROC para O ₃ : A)Lag0, B)Lag1 e C)Lag2.....	93
Figura 52 - Gráficos da Curva ROC para SO ₂ : A)Lag0, B)Lag1 e C)Lag2	94
Figura 53 – Tela capturada do Matlab	95
Figura 54 – Tela capturada do Matlab	95
Figura 55 – Gráfico de superfície do número de interações relativo ao MP ₁₀ x SO ₂	96

LISTA DE SIGLAS

AI	– <i>Artificial Intelligence</i>
ANFIS	– <i>Adaptive Neuro-Fuzzy Inference System</i>
DPOC	– Doença Pulmonar Obstrutiva Crônica
EPA	– <i>Environmental Protection Agency</i>
FEV1	– <i>Forced expiratory volume in 1 second</i>
FIS	– <i>Fuzzy Inference System</i>
FMC	– Fumaça
FVC	– <i>Forced vital capacity</i>
IAM	– Inteligência Artificial Médica
IC	– Inteligência Computacional
LSE	– <i>Least Square Estimation</i>
MF	– <i>Membership function</i>
MP ₁₀	– Partículas inaláveis
MPS	– Material Particulado em Suspensão
OMS	– Organização Mundial de Saúde
PTS	– Partículas Totais em Suspensão
RNA	– Rede Neural Artificial
SD	– <i>Methods descendants</i>
SIH-SUS	– Sistema de Informações Hospitalares do Sistema Único de Saúde
SIM	– Sistema de Informações
SUS	– Sistema Único de Saúde
UR	– Umidade relativa do ar

LISTA DE SÍMBOLOS

CO	– Monóxido de carbono
NO ₂	– Óxido nítrico
NO _x	– Óxidos de nitrogênio
O ₂	– Oxigênio
O ₃	– Ozônio troposférico
SO ₂	– Dióxido de enxofre
SO ₃	– Trióxido de enxofre
T°	– Temperatura
μm	– Micrometro

LISTA DE TABELAS

Tabela 1 - Comparação entre redes neurais artificiais e sistemas de inferência <i>fuzzy</i>	38
Tabela 2 - Fontes emissoras de poluentes e efeitos à saúde.....	53
Tabela 3 - Dados de entradas e suas respectivas variações.....	68
Tabela 4 - Classificação da variável de saída.....	69
Tabela 5 - Classificação quanto ao nível de material particulado no ambiente.....	70
Tabela 6 - Classificação quanto ao nível de ozônio.....	70
Tabela 7 - Classificação quanto ao nível de dióxido de enxofre.....	71
Tabela 8 - Classificação quanto à temperatura aparente.....	72
Tabela 9 - Regras geradas por especialista para o modelo <i>fuzzy</i>	72
Tabela 10 - Valores das médias, desvio padrão, mínimos e máximos das variáveis: material particulado (MP ₁₀), ozônio (O ₃), dióxido de enxofre (SO ₂), temperatura aparente (Tap), segundo tipo de saída número de internações (NINTER), São José dos Campos-2007.....	81
Tabela 11- Valores da Curva ROC para Lag0, Lag1 e Lag2 dos poluenes MP ₁₀ , O ₃ e SO ₂ ...	84
Tabela 12- Parâmetros e resultados do modelo neuro- <i>fuzzy</i>	90
Tabela 13- Correlações entre dados reais e dados dos modelos.....	91
Tabela 14- Valores da Curva ROC para Lag0, Lag1 e Lag2 dos poluenes MP ₁₀ , O ₃ e SO ₂ ..	91

SUMÁRIO

1	INTRODUÇÃO	16
1.1	Objetivos	17
1.2	Estrutura do estudo	18
2	INTELIGÊNCIA ARTIFICIAL E INTELIGÊNCIA COMPUTACIONAL	19
2.1	Evolução da inteligência artificial	20
2.2	Inteligência computacional	21
2.3	Lógica <i>fuzzy</i>	22
2.3.1	Teoria da lógica <i>fuzzy</i>	23
2.3.2	Teoria dos conjuntos <i>fuzzy</i>	24
2.3.3	Função de pertinência <i>fuzzy</i>	26
2.3.4	Sistemas de inferência <i>fuzzy</i>	27
2.4	Rede neural artificial (RNA)	30
2.4.1	Redes neurais biológicas	30
2.4.2	Redes neurais artificiais (RNA`s)	31
2.4.2.1	Estruturas das redes neurais artificiais	33
2.4.2.2	Aprendizado das redes neurais artificiais	33
2.4.2.3	Algoritmo <i>back-propagation</i>	34
2.5	Redes neurais artificiais e sistema de inferência <i>fuzzy</i>	37
2.6	Sistemas neuro- <i>fuzzy</i>	38
2.7	Características dos sistemas neuro- <i>fuzzy</i>	39
2.8	Aprendizagem dos sistemas neuro- <i>fuzzy</i>	41
2.9	Vantagens dos sistemas neuro- <i>fuzzy</i>	41
3	ARQUITETURA DO MODELO DO SISTEMA DE INFERÊNCIA NEURO- FUZZY ADAPTATIVO-ANFIS	43
4	POLUIÇÃO ATMOSFÉRICA	48
4.1	Poluentes	48
4.1.1	Material particulado (MP ₁₀)	50
4.1.2	Ozônio (O ₃)	51
4.1.3	Dióxido de enxofre (SO ₂)	52
4.2	Efeitos da poluição atmosférica sobre a saúde	54
5	DOENÇAS RESPIRATÓRIAS	57
6	VARIÁVEIS CLIMÁTICAS	59
6.1	Umidade relativa do ar e temperatura do ar	59
6.2	Temperatura aparente	60
7	MATERIAIS E MÉTODOS	62
7.1	Modelo <i>fuzzy</i>	68
7.1.1	Material particulado	70
7.1.2	Ozônio	70
7.1.3	Dióxido de enxofre	71
7.1.4	Temperatura aparente	72
7.2	Modelo neuro- <i>fuzzy</i>	75
7.2.1	ANFIS	75
8	RESULTADOS E DISCUSSÃO	81
9	CONCLUSÃO	98

REFERÊNCIAS BIBLIOGRÁFICAS.....	99
ANEXO A – NOVOS PADRÕES PRIMÁRIOS E SECUNDÁRIOS – OMS – 2012.....	108
ANEXO B – PADRÕES PRIMÁRIOS E SECUNDÁRIOS - CETESB	109
ANEXO C – FÓRMULA PARA CALCULAR A TEMPERATURA APARENTE	110
ANEXO D – ROTINA DDEINIT DE O MATLAB PARA GERAR SAÍDA NUMÉRICA.....	111
ANEXO E – SIMULAÇÕES DO MODELO NEURO-<i>FUZZY</i>	112

1 INTRODUÇÃO

A Inteligência Artificial Médica (IAM), também chamada Inteligência Artificial em Medicina, preocupa-se com o desenvolvimento de programas de inteligência cada vez mais avançados para auxiliar os profissionais da área. Nos últimos anos, com o advento de novos recursos computacionais, são crescentes as áreas de aplicações destes programas como, por exemplo, o auxílio a diagnósticos médicos, reconhecimento e análise de imagens, modelos preditivos, entre outros mais.

Estudos envolvendo poluição e doenças do sistema respiratório têm grande expressão na literatura nacional e internacional.

Visando prever a interação entre poluentes, variáveis climáticas e número de internações por doenças respiratórias, pode-se utilizar a modelagem computacional. Um dos métodos é conhecido como Sistemas Especialistas Inteligentes, que são capazes de solucionar problemas a partir de uma base de dados. Um exemplo desses sistemas é a associação da lógica *fuzzy* e redes neurais artificiais. Daí o interesse da presente tese pela lógica *fuzzy* e *neuro-fuzzy* aplicadas para modelar internações hospitalares por pneumonia e asma.

Com o estado atual do desenvolvimento urbano e o recrudescimento das doenças respiratórias, redundando no aumento significativo das internações baseadas em problemas respiratórios, faz-se necessário a apresentação de modelo capaz de analisar de forma eficiente a relação poluição atmosférica, variação climática e o número de internações, de modo a identificar a problemática e propiciar uma melhora no seu quadro de decisões.

As doenças do sistema respiratório são responsáveis por grande morbidade e mortalidade e conseqüentemente gera um grande custo à saúde pública. A verificação da associação entre internação hospitalar por pneumonia e asma; e a concentração de certos poluentes pode ser uma ferramenta útil na definição de ações preventivas e políticas públicas, visando o controle e monitoramento de emissões atmosféricas.

Ainda de acordo com Motta e Mendes (1995), políticas sobre a prevenção da poluição atmosférica deveriam ter prioridade, dado que estariam antevendo uma relação entre a poluição e a incidência da morbidade e mortalidade na população, auxiliando também, no que diz respeito de tomada de decisões quanto ao grau de risco que a população sofre, tais como: gasto com tratamentos médicos e internações hospitalares, perda de dias de trabalho, redução da produtividade, morte prematura, entre outros.

Na literatura internacional são encontrados diferentes estudos, ainda que em número pequeno, aplicando sistema neuro-*fuzzy* na previsão de poluentes, como são descritos em Yildirin e Bayramoglu (2006) que realizaram estudo de um modelo neuro-*fuzzy* para previsão de níveis diários de poluição na cidade de Zonguldak-Turquia. Noori *et al.* (2010) realizaram uma análise para previsão da concentração de monóxido de carbono (CO) utilizando redes neurais artificiais e modelos ANFIS em Teerã-Irã. Jain e Khare (2010) realizaram um estudo com modelo neuro-*fuzzy* para previsão da concentração de CO em um cruzamento de estradas em Delhi- Índia. Ashish e Rashmi (2011) também utilizaram o ANFIS para a previsão da poluição diária do ar na cidade de Delhi- Índia. Lei e Wan (2012) aplicaram técnicas de aprendizagem ANFIS para a previsão do índice de poluição do ar em Macau-China; e Savic (2013) utilizou modelo ANFIS para a previsão da concentração de dióxido de enxofre (SO₂) em área urbana de Bor- Sérvia.

O restrito número de estudos com informações no que se referem à relação poluição atmosférico (AMÂNCIO, 2012; NASCIMENTO, 2006) e algumas doenças respiratórias (pneumonia e asma), não utilizando a teoria da lógica *fuzzy* e sistemas híbridos, na cidade de São José dos Campos, Vale do Paraíba-SP, instigaram a verificação dessa relação. A investigação pode ser promissora e buscará analisar os modelos propostos com base em dados reais coletados da cidade, escolhida como paradigma devido a seu tamanho e densidade demográfica proporcionais ao crescimento das últimas décadas.

1.1 Objetivos

Essa tese tem por objetivo verificar a associação entre a exposição aos poluentes atmosféricos, variáveis climáticas e o número de internações hospitalares por pneumonia e asma.

Deste modo, pretende-se desenvolver e validar um modelo de sistema de inferência *fuzzy* Mamdani para a predição do número de internações hospitalares por pneumonia e asma segundo exposição aos poluentes atmosféricos e variáveis climáticas.

O próximo passo é utilizar o sistema neuro-*fuzzy* ANFIS para obter um sistema de inferência *fuzzy* do tipo Sugeno para predição do número de internações hospitalares por pneumonia e asma. Em seguida este modelo será validado e comparado com o sistema de inferência *fuzzy* desenvolvido anteriormente.

1.2 Estrutura da tese

Para alcançar os objetivos desse trabalho, foi realizada a estrutura em nove capítulos. O primeiro capítulo contém a introdução sobre o tema, a motivação e os objetivos do trabalho.

O segundo capítulo contém as definições e a base teórica sobre a Inteligência Artificial (IA) e Computacional (IC). Sendo também realizada uma breve revisão sobre a lógica *fuzzy*, rede neural artificial e sistemas neuro-*fuzzy*.

Em seguida, o terceiro capítulo descreve a arquitetura do sistema neuro-*fuzzy* ANFIS.

O quarto capítulo trata sobre o assunto poluição atmosférica, descrevendo sobre os poluentes utilizados no estudo, sendo eles o material particulado, o ozônio e o dióxido de enxofre.

O quinto capítulo aborda sobre doenças de afetam o sistema respiratório relacionadas com a poluição atmosférica.

O sexto capítulo refere-se às variáveis climáticas: umidade relativa do ar e temperatura do ar; bem como a temperatura aparente.

O sétimo capítulo contém o método para desenvolver os modelos *fuzzy* do tipo Mamdani e neuro-*fuzzy* ANFIS.

No oitavo capítulo são apresentados os resultados e a discussão do trabalho.

Por fim, no nono capítulo apresenta-se a conclusão do trabalho.

2 INTELIGÊNCIA ARTIFICIAL E COMPUTACIONAL

Segundo Fernandes (1997) a Inteligência Artificial – IA é uma das ciências mais recentes, com início nos meados da década de 60 e em plena evolução até os dias atuais.

Atualmente, vem-se utilizando as redes neurais artificiais (RNAs), lógica *fuzzy* e uma variedade de métodos de aprendizagem, com a utilização de recursos computacionais, cada vez mais avançados, para auxílio na tomada de decisão, previsão, controle, dentre outros.

Nesse sentido, importa ressaltar que, tem havido um crescente interesse especificamente sobre os chamados sistemas de inferência *fuzzy* e sistema neuro-*fuzzy* (JANG, 1993; LIN *et al.*, 1995; JANG *et al.*, 1997; REZENDE, 2005; NEGNEVITSKY, 2005; CALDEIRA *et al.*, 2007).

A rigor, qualquer sistema que associa os paradigmas de sistemas de inferência *fuzzy* e as redes neurais artificiais poderia ser chamado de “neuro-*fuzzy*”, como, por exemplo, a utilização de um controlador *fuzzy* para alterar o aprendizado de uma rede neural artificial (SANDRI; CORREA, 1999).

Contudo, o termo é utilizado para um tipo específico de sistema que engloba os dois paradigmas. Nestes sistemas, os termos e regras de um sistema de inferência *fuzzy* são aprendidos mediante a apresentação de pares de entrada e a saída desejada (SANDRI; CORREA, 1999).

Esclareça-se que, tais pares apresentam dois comportamentos distintos, dependendo de estarem numa fase de aprendizado onde eles têm comportamento de uma rede neural artificial ou numa fase de processamento, em que eles se comportam como um sistema de inferência *fuzzy* (SANDRI; CORREA, 1999).

Modelos utilizando redes neurais artificiais e sistemas baseados em regras *fuzzy* têm surgido como uma alternativa aos modelos tradicionais em auxílio na área médica (CASTANHO, 2007), este é o motivo do interesse desta área para elaboração deste trabalho.

2.1 Evolução da inteligência artificial

O estudo da inteligência teve início há mais de 2.000 anos, começando com filósofos que procuravam entender como eram realizados os processos de visão, aprendizado, lembranças e raciocínio (MONARD; BARANAUSKAS, 2000).

Desde então, várias tentativas para mecanizar a inteligência foram efetuadas, sendo que muitas dessas tentativas precedem as idéias dos computadores digitais e das tecnologias mais avançadas.

Foi somente no pós-guerra, na década 50 que se originou a área de Inteligência Artificial (IA), quando pesquisadores da área da computação começaram a utilizar computadores no desenvolvimento de programas simbólicos com o objetivo de resolver problemas mais complexos (MONARD; BARANAUSKAS, 2000).

O termo Inteligência Artificial, foi usado pela primeira vez na década dos anos 50 e nada mais é do que uma tentativa de formalizar o eterno sonho da criação de um “cérebro eletrônico” (OSÓRIO, 1999). Nos últimos anos o cinema também abordou sobre o tema com os filmes Robocop, IA-Inteligência Artificial, Matrix, Eu robô, dentre outros, nos quais os temas associam o corpo humano e os computadores.

Caldeira, *et al.*(2007) definem a IA como o ramo da computação preocupada com a automação de comportamento inteligente, ao passo que, Winston (1992) entende IA como o estudo da computação que torna possível perceber, raciocinar e agir, concluindo que, IA é o estudo das idéias que permitem aos computadores serem inteligentes.

Para Rezende (2005) IA é a capacidade da ciência da computação voltada à execução das funções que são desempenhadas pelo seres humanos, isto é, imitar a inteligência na compreensão da linguagem e da visão, aprendizado, raciocínio lógico, resolução de problemas simples ou complexos, dentre outros.

Pode-se concluir então que, IA é um ramo da área da ciência da computação cujo interesse é fazer os computadores pensarem ou comportarem de forma inteligente (MONARD; BARANAUSKAS, 2000). A IA está interligada as mais diversas áreas como: psicologia, linguística, filosofia, biologia, matemática, engenharia, entre outras áreas científicas, sendo uma área extensa de aplicações, conforme mostrado na Figura 1.



Figura 1 – Áreas relacionadas com IA (adaptado de MONARD; BARANAUSKAS, 2000).

A IA envolve o conceito de explorar um comportamento inteligente que possui características bem definidas. Algumas destas características estão em aprender e aplicar o conhecimento adquirido com a experiência, aplicar o conhecimento adquirido de forma empírica, tratar situações complexas, resolver problemas mesmo quando há falta de informações, adquirirem a capacidade de raciocínio e pensamento, alcançar a capacidade de reação correta nas mais diversas situações, interpretar imagens, processar e manipular símbolos, ser criativo e imaginativo e utilizar-se da heurística e normas práticas advindas da experiência (MOURA *et al.*, 2005).

2.2 Inteligência Computacional – IC

A IC é a área da Ciência da Computação que compreende sistemas computacionais, que simulem características associadas, quando presentes no comportamento e raciocínio humano, a inteligência (SCHWALBERT, 2007).

Os primeiros modelos de IC são os algoritmos genéticos, a programação evolutiva, a lógica *fuzzy*, os sistemas baseados em conhecimento, o raciocínio baseado em casos, a programação genética e as redes neurais artificiais (CALDEIRA, 2007).

Para Carvalho *et al.*, (2006), o universo das pesquisas possui uma tendência a ser alterado muito rápido no tempo atual devido ser a realidade dinâmica. Os métodos e as

técnicas também evoluem muito rápido, contribuindo, assim para o surgimento de novos padrões de pesquisa.

Os sistemas envolvendo técnicas tradicionais de inteligência artificial aplicados no domínio da matemática, física, química, biologia, astronomia, entre outras, estão sendo associados aos chamados sistemas que utilizam Inteligência Computacional (IC), referenciados na literatura científica como *Soft Computing*. (CARVALHO *et. al.*, 2006). O uso da IC, como visto, não se restringe somente a área da ciência exata. Seu alcance vai além das fronteiras e pode auxiliar na modelagem de questões encontradas nas mais variadas área do conhecimento (CALDEIRA, 2007).

Através de técnicas inspiradas na natureza a IC adquire o poder de imitar o comportamento da inteligência humana, tais como o aprendizado, a percepção e o raciocínio, (CARVALHO *et. al.*, 2006).

Segundo Zadeh (2006), as características básicas desses sistemas estão na representação inexata do conhecimento, o qual seria impossível de representar através das técnicas tradicionais de IA. No centro da IC, estão a Lógica *Fuzzy*, Redes Neurais Artificiais, Neurocomputação, Computação Evolucionária, Computação Probabilística, Computação Caótica e Aprendizagem de Máquina, áreas que utilizam os princípios da IA.

Para Brusaferrro (2006), a modelagem, de modo geral, visa encontrar o melhor modelo com o menor erro. Já a previsão visa estimar valores futuros baseados no modelo, podendo lançar mão das técnicas estatísticas tradicionais ou dos métodos recentes da IC. A diferença está na modelagem dos dados. A técnica tradicional busca encontrar uma equação para o modelo, enquanto os modelos de IC usam redes para o aprendizado da função.

O conjunto de técnicas e modelos de IC representa o que há de mais inovador na área de modelamento e previsão, porém não é a solução para todos os problemas, tratando simplesmente de uma poderosa ferramenta que obtém soluções, simples e eficientes, para problemas de difícil manejo por técnicas convencionais (CALDEIRA, 2007).

2.3 Lógica *Fuzzy*

Neste tópico, sobre a lógica *fuzzy*, são abordados somente os conceitos de suma importância usada neste trabalho, podendo a teoria completa ser examinada em outras referências como KLIR, 1995a; MASSAD *et al.*, 2008; CALDEIRA *et al.*, 2007; REZENDE, 2005; NEGNEVITSKY, 2005, ORTEGA, 2001.

Uma vez que os textos em livros, artigos, tutoriais disponibilizados na literatura é bem extenso e diversificado o conteúdo aqui exposto constitui a medida exata para a compreensão do sistema de inferência *fuzzy* e neuro-*fuzzy* (ANFIS) proposto para a realização do trabalho.

2.3.1 Teoria da lógica *fuzzy*

A teoria dos conjuntos *fuzzy* foi apresentada em 1964 por Lotfi A. Zadeh, professor no Departamento de Engenharia Elétrica e Ciências da Computação da Universidade da Califórnia em Berkeley, quando trabalhava com problemas de classificações de conjuntos que não possuíam fronteiras bem definidas (ZADEH, 1965; KLIR, 1995b; SANDRI; CORREA, 1999; ORTEGA, 2001).

O termo em inglês “*fuzzy*” traduzido, tem o significado como algo vago, indefinido, incerto. Mas traduzido para o português os termos mais utilizados na área de inteligência artificial são nebuloso ou difuso (REZENDE, 2005).

A teoria dos conjuntos *fuzzy* permaneceu incompreendida por muito tempo. As primeiras aplicações com sucesso foram na área de controle. Em meados dos anos 80, Mamdani a utilizou para projetar controladores *fuzzy*. A partir daí houve um grande progresso da área, em especial com muitas aplicações reportadas dos países orientais principalmente do Japão (BAUCHSPIESS, 2008).

A lógica *fuzzy* (ZADEH, 1965) pode ser a base para geração de técnicas poderosas para a solução de problemas complexos, com uma vasta área de aplicação, em especial, nas áreas de controle, previsão e tomada de decisão, pois pode representar informações vagas e de limites imprecisos.

Diferente da lógica clássica, onde uma proposição lógica possui dois extremos: o “completamente verdadeiro” ou o “completamente falso”, na lógica *fuzzy* uma proposição pode assumir um número de valores infinito de pertinência que varia de zero a um, o que a torna parcialmente verdadeira ou parcialmente falsa, sendo o valor zero usado para representar a não pertinência completa e o valor um a completa pertinência. Isso permite que a lógica *fuzzy* descreva um determinado fato com mais detalhe e modo gradual, reduzindo assim a perda de informações, que conseqüentemente estará o mais coerente possível com a realidade em questão (MALUTTA, 2004).

Através de uma determinada regra, que varia para qual fim a lógica *fuzzy* é utilizada, os dados coletados caracterizados como incertos são analisados de acordo com a regra

implementada e aproximados por números para possibilitar a interpretação de computadores (MALUTTA, 2004).

Como exemplo, para lógica clássica um indivíduo de 1,79 m tem a mesma estatura baixa que um indivíduo de 1,40 m, por outro lado, um indivíduo de 1,81 m é tão alto quanto um de 2,00 m. Já para a lógica *fuzzy* existem graus de pertinência para um indivíduo de estatura alta entre 1,70 m e 1,90 m, Figura 2.




Figura 2 – Gráficos comparativos da lógica clássica com a lógica *fuzzy* (adaptado de NEGNEVITSKY, 2002).

Os sistemas inteligentes com base na lógica *fuzzy* são sistemas capazes de trabalhar com informações vagas, transformando-as em uma linguagem matemática de fácil aplicação computacional (FERREIRA, 2010).

Assim, a eficácia da lógica *fuzzy* provém da sua habilidade em inferir conclusões e gerar respostas baseadas em informações vagas, ambíguas, incompletas ou imprecisas (DASH *et. al*, 2000); neste sentido, os sistemas de inferência *fuzzy* têm habilidade de raciocinar de forma parecida com os humanos, encontrando aplicações nas mais diversas áreas do conhecimento, como, por exemplo, computação, engenharia, saúde, administração, entre outras.

2.3.2 Teoria dos conjuntos *fuzzy*

A teoria dos conjuntos *fuzzy* veio agregar-se a lógica binária (0-1; verdadeiro-falso) da teoria dos conjuntos clássica, traduzida na Álgebra de Boole, por uma lógica em que o grau de verdade de uma afirmação pode assumir uma gama contínua de valores entre zero e um.

Uma das grandes vantagens da utilização da teoria dos conjuntos *fuzzy* é a sua capacidade de poder representar expressões linguísticas qualitativas como, por exemplo, afirmar que um determinado critério é “baixo, médio ou alto”, em vez de se exprimir esta grandeza na forma de um número real (ANTÓNIO, 2004).

O conceito fundamental na definição de um conjunto *fuzzy* é a sua “função de pertinência”. Na teoria clássica dos conjuntos, dado um universo e um conjunto ‘A’ nele definido, estabelece-se uma relação de pertinência relativamente a cada elemento x nesse universo, tal que dois casos se dão: ou x pertence a ‘A’ ou x não pertence a ‘A’. Dito de outro modo poderia definir uma função de pertinência, tal que: $\mu_A : A \rightarrow \{0,1\}$, conforme equação (1):

$$\mu_A(x) = \begin{cases} 0 \Rightarrow x \notin A \\ 1 \Rightarrow x \in A \end{cases} \quad (1)$$

Ou seja, todos os elementos que pertençam a ‘A’ têm valor de pertinência um e todos os outros têm valor de pertinência zero, que é o mesmo que dizer que se aceita apenas um valor binário de verdade.

Na teoria dos conjuntos *fuzzy* μ assume valores entre $[0, 1]$ aceita que o valor de pertinência que pode ser representado por um número real qualquer no intervalo entre $[0, 1]$.

Um conjunto *fuzzy* A em X , coleção de objetos, é definido como sendo o conjunto de pares ordenados, conforme equação (2):

$$A = \{(x, \mu_A(x)) | x \in X\} \quad (2)$$

Sendo, $\mu_A(x)$ o valor a função de pertinência do conjunto *fuzzy* ‘A’ correspondente ao elemento x .

Os operadores na lógica *fuzzy* são as *t*-normas e *t*-conormas, dos quais os operadores mínimo (\wedge), máximo (\vee) e *not* (\neg) são apenas um caso particular. São conhecidos como operadores de relação. Na lógica *fuzzy* eles são usados para definir o grau máximo e mínimo de pertinência dos conjuntos (CARPENTER, 1992) Assim, tem-se a equação (3):

$$\begin{aligned} A \wedge B &= \min(A,B) \\ A \vee B &= \max(A,B) \end{aligned} \quad (3)$$

$$\neg A = 1 - A$$

Sendo:

\wedge : operador que representa a interseção dos dois conjuntos ($A \cap B$);

\vee : operador que representa a união dos dois conjuntos ($A \cup B$)

\neg : operador que representa o complemento de um conjunto (A).

Na Figura 3, são apresentadas as operações de união e interseção realizada entre dois conjuntos *fuzzy*.




Figura 3 – Representação dos conjuntos *fuzzy*. (a) Conjunto A, (b) Conjunto B, (c) Conjuntos $A \wedge B$ e $A \vee B$ (Adaptado de MALANGE, 2010).

2.3.3 Funções de pertinência *fuzzy*

As funções de pertinência *fuzzy* podem ser definidas como sendo uma representação gráfica (diferentes formas) da magnitude de participação de cada entrada e resposta de saída, dependendo do conceito que se deseja representar e do contexto aplicado. Ela associa um peso para cada valor de entrada processada, definindo, assim, uma superposição funcional entre as entradas e determinando uma resposta para a saída (CALDEIRA, 2007; MALANGE, 2010).

É uma função que mapeia a relação de cada entrada com a variável *fuzzy*, como exemplo: existe uma função de pertinência para a variável *fuzzy* indivíduo baixo que relaciona a estatura (entrada) com um valor de zero a um. Essa função pode ser linear (triangular, trapezoidal) ou não linear (gaussiana, sino, sigmóide) em função da complexidade do problema e podendo ser também usadas de acordo com a preferência, experiência do especialista, além de depender das características do fenômeno (CALDEIRA, 2007).

O grau de pertinência é determinado pela projeção vertical do parâmetro de entrada do eixo horizontal no limite mais alto da função de pertinência, o qual tem valores compreendidos entre zero e um (MALANGE, 2010), como mostrado a seguir, Figura 4.




Figura 4 – Funções de pertinência *fuzzy* (Adaptado de Malange, 2010).

Observa-se que estaturas de até 1,40 m apresentam grau de pertinência igual a um no conjunto (μ_A); o grau de pertinência nesse conjunto decresce a medida que a estatura aumenta.

O grau de pertinência define a quantidade ou intensidade, entre zero e um, que um determinado valor de entrada pertence aquele conjunto, exemplo: 1,80 m podem representar grau de pertinência 0,10 na função de pertinência *fuzzy* “indivíduo baixo” e 0,80 na função de pertinência *fuzzy* “indivíduo alto”.

2.3.4 Sistemas de Inferência *Fuzzy* (SIF)

Define-se sistema de inferência *fuzzy* como sendo o processo pelo qual se obtém as saídas do sistema, pela avaliação do relacionamento das entradas com os antecedentes das regras, ativando os consequentes. Assim, um conjunto *fuzzy* é transformado em um número real (CALDEIRAS, 2007).

Problemas complexos, normalmente, exigem soluções complexas que necessitam de tempo e esforço proporcional ao grau de complexidade. Os SIF empregam soluções simples para resolver estes tipos de problemas, pois, em vez de modelar um processo através do uso de relações complicadas entre as variáveis, o SIF leva em conta a modelagem do processo por meio do uso de um conjunto simples de vários tipos de regras de bom senso (LOESCH; SARI, 1996).

O SIF apresenta uma estrutura com base em um conjunto de regras *fuzzy* incluindo as seguintes fases principais: fuzificador, elaboração das bases de regras *fuzzy*, método de inferência e defuzificador, como pode ser observado a seguir, Figura 5.

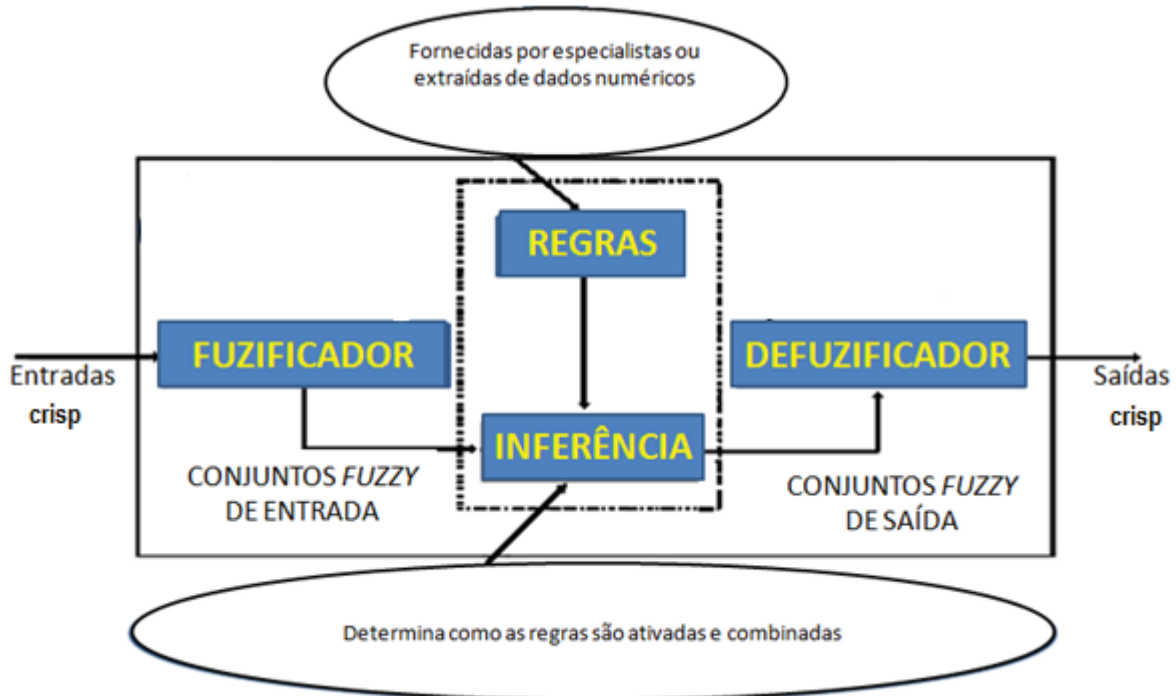


Figura 5 – Etapas de um sistema *fuzzy*. (Adaptado de CALDEIRA, et al., 2007).

A figura ilustra a arquitetura típica de um sistema de inferência *fuzzy* que é normalmente composto por blocos. No bloco fuzificador ocorre uma conversão de dados precisos (não-*fuzzy* ou *crisp*) pelos conjuntos *fuzzy* de entrada. A fuzificação é um mapeamento do domínio da variável *crisp* de entrada para o domínio *fuzzy*, representando a atribuição de valores linguísticos (baixo, médio e alto), definidas por funções de pertinência às variáveis de entrada.

A máquina de inferência, onde se efetua o processamento *fuzzy* propriamente dito é baseada em operadores da lógica *fuzzy*; a base de regras consiste em processar a aplicação de uma regra do tipo, SE-ENTÃO, constituída de proposições, envolvendo termos de variáveis linguísticas.

O defuzificador transforma o conceito linguístico, obtido pelo procedimento de inferência, em um valor numérico bem definido, o qual é utilizado como a saída efetiva do controlador *fuzzy*.

Existem dois métodos de inferência *fuzzy* mais usados e os quais serão usados neste trabalho, são eles:

Os SIF do tipo Mamdani, utiliza conjuntos *fuzzy* no antecedente e no consequente das regras, sendo a saída final representada por um conjunto *fuzzy* resultante da agregação da saída. A regra de Mamdani: Se x é A_1 E y é B_1 então z é C_1 , Figura 6.




Figura 6: Modelo Mamdani (adaptado de JANG, 1997).

O processo de defuzificação visa obter um resultado não-*fuzzy* na saída do sistema de inferência e podendo ser feito pelo método do centróide, mínimo, máximo, entre outros (CALDEIRA, 2007).

No sistema de inferência do tipo Sugeno, uma regra típica desse modelo é: Se x é A e y é B então $z = f(x, y)$, onde A_1 e B_1 são conjuntos *fuzzy* e f uma função real de x e y , Figura 7.




Figura 7: Modelo Takagi-Sugeno (adaptado de JANG, 1997).

O método de inferência proposto por Sugeno utiliza função exponencial.

2.4 Rede Neural Artificial (RNA)

Para que haja um melhor entendimento de uma Rede Neural Artificial, faz-se necessário a descrição, em resumo, do que é uma Rede Neural Biológica.

2.4.1 Redes Neurais Biológicas

O cérebro humano é formado por células chamadas neurônio e são atribuídas ao neurônio inúmeras funções de um organismo (pensamento, emoção e cognição, execução das funções sensório-motoras e autônomas). Cada neurônio compartilha várias características com outras células, mas possui capacidades singulares para receber, processar e transmitir sinais eletroquímicos ao longo das fibras nervosas, que compreendem o sistema de comunicação cerebral. A célula nervosa é vista como uma unidade de processamento analógica independente, capaz de estabelecer a comunicação com o sistema nervoso central (MOURA *et al.*, 2005).

Os neurônios são interconectados por intermédio dos dendritos (receptores de estímulos) e terminações dos axônios (condutores de impulsos), formando uma cadeia de aproximadamente 100 bilhões de células. Tais conexões são chamadas de sinapse e são realizadas para transmitir os impulsos de um neurônio para outro e juntos formam uma rede neural (MOURA *et al.*, 2005).

Uma rede neural biológica tem capacidade de aprendizado devido ao reforço ou enfraquecimento das sinapses. Os aprendizados são realizados através das repetições de um determinado estímulo de entrada. Quanto maior a estimulação neural maior é a percepção de que este é um fato relevante, passando assim, a dar uma maior ênfase para tal. Isto faz com que, a cada acontecimento de uma mesma situação, o sistema nervoso já tenha a informação solidificada (MOURA *et al.*, 2005).

Na Figura 8, mostra-se a semelhança entre o neurônio biológico e o neurônio matemático de McCulloch, Pitts (1943) onde existem sinais de entrada (dendritos), um somatório e uma função de ativação (corpo) e uma saída (sinapses do axônio) (PEREIRA; RODRIGUES, 1998).




Figura 8 – Comparativo do neurônio biológico com o neurônio matemático (Adaptado de Jacintho, 2010).

Pode-se notar que os principais componentes de um neurônio biológico são: os dendritos, que são estruturas responsáveis por receber os estímulos enviados por outros neurônios; o corpo do neurônio (soma), que é responsável por coletar e combinar informações vindas de outros neurônios; e por fim, o axônio, que é responsável pela condução dos impulsos a outras células do corpo humano.

Já em relação ao neurônio matemático é constituído de: W , que representa o vetor de pesos; e X o vetor de entradas; Σ representa a soma ponderada das entradas; e f a função de ativação. A saída será $f[(W_1.X_1) + (W_2.X_2) + (W_3.X_3)]$ para o exemplo apresentado na Figura 8.

2.4.2 Redes Neurais Artificiais – RNA

Segundo Lin e Cunningham III (1995), as RNAs são uma geração computacional promissora no que diz respeito ao processamento de informações, as quais demonstram capacidade de aprendizado, reaprendizado e generalização a partir de um banco de dados ou padrões de treinamento.

Loesch e Sari (1996) informam que as RNAs podem ser desenvolvidas em um tempo razoável e realizar tarefas de forma mais eficiente que outras tecnologias convencionais. Quando associadas em uma implementação de *hardware*, as RNAs exibem alta tolerância a falhas no sistema e fornecem dados que estimam o processamento em paralelo.

A rede neural artificial é um processador distribuído, massivamente paralelo, com uma tendência natural para armazenar conhecimento através da experiência e torná-lo acessível para uso (HAYKIN, 2001). Assemelha-se ao cérebro em dois aspectos:

1. O conhecimento é adquirido pela rede através de um processo de aprendizagem.
2. A intensidade das ligações entre neurônios, conhecidas por pesos sinápticos, é utilizada para armazenar conhecimento.

Para Nishida (1998), com o intuito de simular o aprendizado humano, pesos são designados às conexões sinápticas entre neurônios artificiais, e representam o conhecimento armazenado em uma RNA. Por meio de um processo de aprendizagem, ou treinamento, os pesos sinápticos são ajustados e tornam a rede artificial apta a decidir com maior ou menor eficiência.

Os neurônios artificiais são formados por sinais de habilitações e que são validados através de pesos. Os sinais de habilitação são sinais lógicos que informam ao neurônio se ele deve ou não considerar esta informação. Caso o neurônio considere a informação, será necessário levar em conta o peso atribuído à mesma, pois este pode representar se essa é uma informação muito ou pouco relevante. Caso ela seja muito relevante, de grande importância, o dado será conhecido como dado estimulante. Porém, se o dado não for muito relevante, ou seja, de pouca importância, ficará conhecido como dado inibidor (MOURA *et al.*, 2005).

A rede neural artificial calcula o somatório do produto dos valores de cada entrada pelo seu respectivo peso. Após esse cálculo ele compara o resultado com um valor predeterminado, que será considerado como um critério para ativar ou não a saída (MOURA *et al.*, 2005).

Segundo Baleeiro (2007), quando as execuções acontecem e o resultado do coeficiente de erro é diferente de zero, que é o resultado de uma situação perfeita, o sistema se auto-corrige, alterando os pesos para de cada dado de entrada, tornando-a mais ou menos relevante. Dessa forma o erro sempre tenderá a ser igual a zero. Isso é o que se chama de plasticidade neural (capacidade de reorganização).

Em síntese, plasticidade neural é a capacidade de alterar esses pesos e, como os neurônios biológicos, reforçar ou enfraquecer as ligações sinápticas, modificando sua interconexão (BALEEIRO, 2007).

A computação neural aplica alguns princípios e propriedades do funcionamento do cérebro em sistemas computacionais, tais como: aprendizagem, generalização e abstração de informações irrelevantes. O conhecimento adquirido pelo processo de treinamento de uma rede neural é usado posteriormente (BALEEIRO, 2007).

Percebe-se então que uma rede neural é constituída por um conjunto de elementos (neurônios), interligados e comunicados entre si pelo envio de sinais. A partir desses princípios, a RNA busca imitar os princípios organizacionais do cérebro humano, com isso demonstrando habilidade de aprendizagem e generalização (BALEEIRO, 2007).

Os neurônios artificiais são os elementos básicos de processamento da RNA, são estruturas lógicas que tem o objetivo de imitar o funcionamento de um neurônio biológico, fazendo com que a rede aja analisando os resultados obtidos (CALDEIRA, 2007).

Para aplicar as redes neurais à resolução de um problema qualquer, em geral, são necessárias três fases: treinamento da rede, teste e validação.

A seguir, serão descritas as principais classificações das redes neurais artificiais (RNA's) pela forma da arquitetura e pela forma de aprendizado (HAYKIN, 2001), que são aplicadas a este trabalho.

2.4.2.1 Estruturas das RNA's

Este tipo de classificação depende de como os neurônios estão conectados e como recebem as informações. Podem ser descritos três tipos: alimentação direta, recorrente e competitiva. A estrutura de alimentação direta, interesse para este trabalho, será descrita em seguida.

- Alimentação direta (*Forwardfeed*): neste caso os neurônios estão dispostos em camadas e o sinal propaga em uma só direção. Não há comunicação entre neurônios de uma mesma camada, conforme visto a seguir, Figura 9:




Figura 9 – Rede de alimentação direta (*forwardfeed*) (Adaptado de Jacinhto, 2010).

2.4.2.2 Aprendizado das RNA's

Outro tipo de classificação das redes neurais artificiais pode ser descrito pela forma como a rede é treinada (tipo de aprendizado). Há três mecanismos mais utilizados para o aprendizado de uma RNA: método de aprendizado supervisionado, método de aprendizado não supervisionado; e o aprendizado por reforço. Em seguida serão descritos esses mecanismos de aprendizado.

O primeiro método de aprendizado é o supervisionado, onde são fornecidos integralmente os resultados desejados através de um conjunto de entradas e saídas. Neste caso o comportamento de saída já é conhecido e a rede é levada a reproduzir as saídas desejadas. A maioria das aplicações utiliza o aprendizado supervisionado. Os parâmetros da rede são ajustados através da propagação do erro resultante da comparação entre as respostas desejadas e as respostas fornecidas pela rede (KARTALOPOULOS, 1996).

O segundo é o aprendizado não-supervisionado, quando a própria rede é capaz de ajustar o seu funcionamento extraindo regularidades e padrões existentes nos estímulos de entrada. Elas são úteis nos problemas em que as entradas variam com o tempo de forma conhecida. Em outras palavras, a rede abstrai correlações entre os estímulos de modo a obter as respostas desejadas. Na aprendizagem não-supervisionada, descrita em (KARTALOPOULOS, 1996), não se conhece a saída da rede, os padrões de entrada são apresentados à rede que os organiza em categorias, de acordo com as características comuns entre eles, por exemplo, padrões de uma mesma categoria possuem características semelhantes, enquanto padrões de grupos diferentes possuem aspectos que os diferenciam dos outros grupos.

O terceiro método é o aprendizado por reforço, quando é dado apenas um parâmetro externo de comparação para saber se estão agindo corretamente ou erroneamente. Ele basicamente mapeia situações em ações para maximizar uma recompensa. A aprendizagem competitiva (KARTALOPOULOS, 1996) representa outra forma de aprendizagem supervisionada, a diferença está na arquitetura e no funcionamento. A camada de saída possui muitos neurônios e, a cada padrão de entrada apresentado, os neurônios da camada de saída competem entre si para produzir a saída mais próxima da saída desejada. O neurônio vencedor torna-se o dominante para esta entrada.

2.4.2.3 Algoritmo *Back-Propagation*

O algoritmo *back-propagation* foi desenvolvido por Paul Werbos em 1974, sendo um algoritmo amplamente empregado no treinamento de redes neurais artificiais por ser um processo muito preciso e rápido. Na primeira etapa do processo são definidas as entradas e as saídas da rede, determina-se um valor para a taxa de aprendizado, um critério de parada do treinamento, e também qual a metodologia para o ajuste dos pesos e seus valores iniciais e por fim, na etapa final, escolhe-se uma função não linear (HAYKIN, 2001).

O *back-propagation* funciona baseado na propagação retrógrada do erro para os níveis anteriores da rede, de acordo com o grau de participação que cada neurônio teve no nível posterior (HAYKIN, 2001).

A seguir, vê-se um exemplo de treinamento *back-propagation* para uma RNA de três camadas, Figura 10.

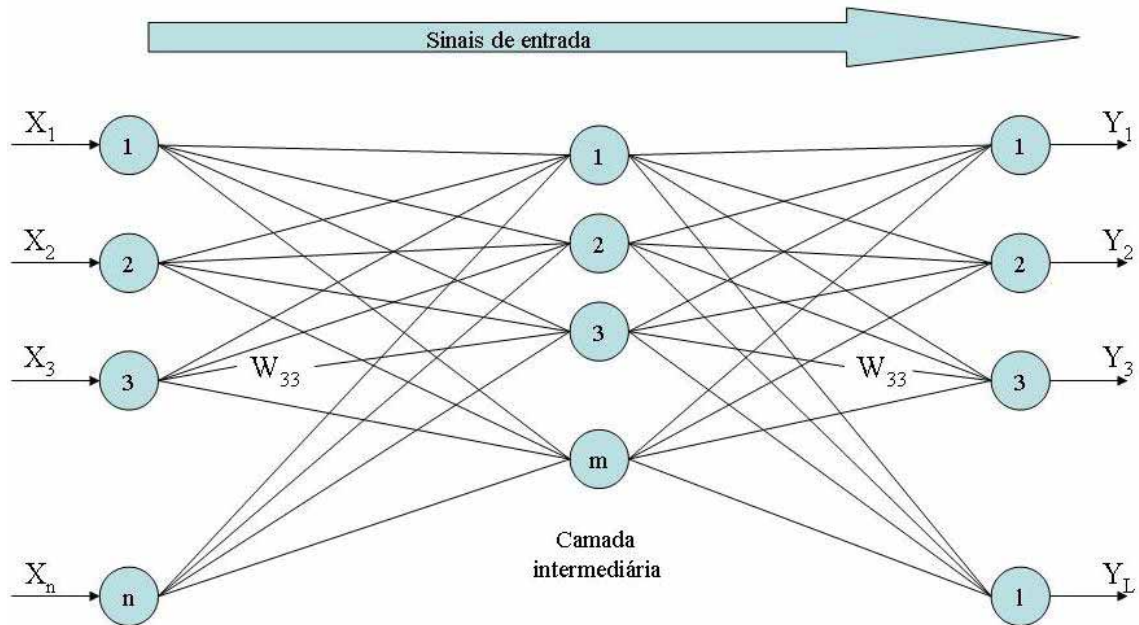


Figura 10: Algoritmo *Back-propagation* para rede neural de três camadas (NINOMIYA, 2008)

Ao modelar-se um problema com redes neurais artificiais, o número de camadas, a quantidade de neurônios por camada e a função de ativação podem variar. A Figura 11, a seguir, ilustra também o mecanismo de *Back-propagation*.

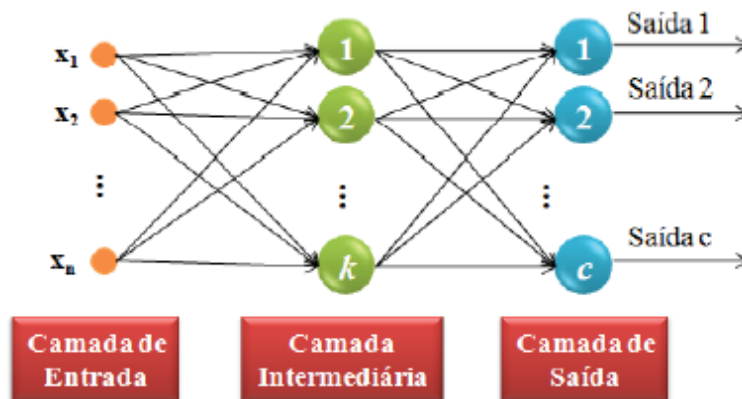


Figura 11 – Exemplo de modelo de rede neural, adaptado de Jacintho (2010).

Cada neurônio é uma unidade básica de processamento. A arquitetura da rede é estruturada de tal forma que os neurônios estão interconectados. O algoritmo de treinamento define como será realizado o processo de aprendizagem da rede, ou seja, após um conjunto de padrões de entrada ser apresentado à rede, uma nova informação é obtida e modificações são realizadas nos parâmetros da rede, a fim de que o modelo represente o conhecimento sobre o conjunto de dados apresentado, de maneira que respostas adequadas sejam fornecidas pela rede para a solução do problema (HAYKIN, 2001).

Algumas das mais conhecidas arquiteturas de redes neurais artificiais são: *Perceptron*; *Perceptron* multicamada (*Multi Layer Perceptron-MLP*); Rede com Funções de Base Radial (*Radial Based Function-RBF*); *Kohonen*; *Hopfield*; ADALINE e MADALINE e Máquinas de Boltzmann entre outras.

A seguir serão descritas as três primeiras arquiteturas citadas acima.

- *Perceptron*

Segundo Haykin (2001) o *perceptron* é a forma mais simples de uma rede neural artificial utilizada para classificar padrões linearmente separáveis. É uma rede de apenas uma camada cujos pesos e erros podem ser treinados para que se tenha um vetor esperado dado um vetor de entrada. O aprendizado usa as mudanças dos pesos e as *bias* (viés) dado um vetor de entrada e o erro, que é a diferença entre a resposta da rede e o vetor de saída desejado (CALDEIRAS, 2007).

- *Perceptron múltiplas camadas (MLP)*

São redes alimentadas adiante que possuem uma camada de entrada, uma ou mais camadas ocultas de nós computacionais e neurônios e uma camada saída. O aprendizado de uma rede neural MLP é de forma supervisionada com um algoritmo de retropropagação de erro (*back propagation*), baseado na regra de aprendizagem por correção de erro, que consiste basicamente de dois passos, um para frente e outro para trás (HAYKIN, 2001).

O passo para frente é chamado de propagação, os valores provindos dos neurônios de entrada são aplicados aos neurônios ocultos e posteriormente suas saídas são aplicadas como entradas aos neurônios da camada, obtendo a resposta da rede. Durante este passo os pesos sinápticos da rede são todos fixos (HAYKIN, 2001).

Já o passo para trás é realizado para ajustar os pesos sinápticos, por meio do cálculo do erro realizado na camada de saída, os pesos sinápticos entre as camadas antecessoras são ajustados de acordo com uma regra de correção de erro (HAYKIN, 2001).

- *Redes com Funções de Base Radial (RBF)*

São redes que combinam várias definições da teoria de aproximação de funções, *clustering*, tornando bastante adequadas aplicações em situações práticas. São utilizadas para a aproximação de funções multivariáveis, bem como em reconhecimento de padrões. As RBF's representam a informação de forma localizada, o que facilita a interpretação dos parâmetros de cada uma das funções que compõem a rede (CALDEIRA, 2007).

Segundo Caldeira (2007) ainda é possível aproveitar a arquitetura final de uma RBF para a construção de sistemas *fuzzy* com funcionalidade igual a da rede recém-treinada.

2.5 Redes Neurais Artificiais e Sistemas de Inferência *Fuzzy*

A teoria de conjuntos *fuzzy* tem sido agregada aos sistemas de redes neurais artificiais, propondo os sistemas neuro-*fuzzy*, aumentando, assim, a capacidade de aprendizado através de interface com dados numéricos. Informações incertas, qualitativas, capacidade de aprendizado e formulação de estratégias de tomadas de decisão, são características dos seres humanos e por isso são referidos como “sistemas inteligentes”, em consequência do fato de imitarem a inteligência humana (MALANGE, 2010).

Os sistemas neuro-*fuzzy* têm atraído interesse da comunidade científica nestes últimos anos, pois estes sistemas têm demonstrado um melhor desempenho em diferentes aplicações quando comparadas separadamente (CALDEIRA, 2007).

Um sistema de inferência *fuzzy* é capaz de utilizar o conhecimento especialista, armazenando informação na base de regras associada ao sistema e realizando o raciocínio aproximado para inferir o valor da saída correspondente. Para construir um sistema de inferência *fuzzy* – FIS, é necessário definir o número de conjuntos *fuzzy* que constituem as partições dos universos de discurso, os operadores lógicos e a base de conhecimento (CALDEIRA, 2007).

As redes neurais artificiais se mostram deficientes para representar o conhecimento de forma explícita em sua estrutura, pois estes sistemas não são capazes de definir automaticamente as regras utilizadas para as tomadas de decisões (FULLÉR, 1995). Por outro lado, os FIS valem-se amplamente de suas características com relação à manipulação de termos linguísticos. A Tabela 1 apresenta uma comparação entre as redes neurais artificiais e os sistemas de inferência *fuzzy*.

Tabela 1 - Comparação entre redes neurais artificiais e sistemas de inferência *fuzzy*

Redes Neurais Artificiais	Sistemas de Inferência <i>Fuzzy</i>
Conhecimento a priori não utilizado	Conhecimento a priori pode ser incorporado
Capacidade de aprendizado	Utiliza o conhecimento lingüístico
Caixa preta	De fácil interpretação (regras <i>SE – ENTÃO</i>)
Algoritmos de aprendizado complexos	Fácil interpretação e implementação
Dificuldade para extração de conhecimento	Conhecimento disponível

Fonte: Adaptado de Ramos (1999).

2.6 Sistemas neuro- *fuzzy*

Um sistema neuro-*fuzzy* pode ser definido como sendo um sistema de inferência *fuzzy* que é treinado por uma RNA. Este tipo de sistema é o resultado da união destes dois modelos. Com isto, tem-se a capacidade das RNA em reconhecimento e classificação, sem esquecer a robustez e habilidade de generalização (RAMOS, 1999).

Por outro lado, têm-se os sistemas *fuzzy* que, através da suas regras e conjuntos *fuzzy*, facilita o entendimento do problema, porque modela o ambiente por meio de uma linguagem próxima da usada pelos especialistas. Por exemplo, os sistemas *fuzzy* têm demonstrado ser bastante consistentes e confiáveis, quando aplicados a sistemas de controle e problemas de classificação (FULLÉR, 1995).

Considerando as características destes dois importantes sistemas tem procurado unir os potenciais. Estes sistemas podem incorporar conhecimentos empíricos e ter seus parâmetros adaptados através de algoritmos eficientes para cada caso (REZENDE, 2005).

O objetivo desta integração é minimizar as deficiências que cada sistema apresenta, tentando construir um novo sistema que busca unir as melhores qualidades dos dois sistemas (FULLÉR, 1995).

Sistemas neuro-*fuzzy* podem ser utilizados em tarefas de reconhecimento de padrões, interpolação de funções, previsão e controle (FULLÉR, 1995).

Um importante aspecto que torna possível esta integração é que as redes neurais artificiais e os sistemas de inferência *fuzzy* são aproximadores universais. Portanto, o sistema neuro- *fuzzy* mantém esta característica fundamental para o desenvolvimento das aplicações (RAMOS, 1999).

Os sistemas neuro-*fuzzy* adquirem da rede neural artificial sua capacidade de aprendizagem, generalização, classificação, robustez, adaptação e agrupamento de dados. As redes neurais sempre foram vistas como uma caixa preta, em que, não é possível obter o conhecimento sobre as decisões da rede no processo de treinamento (CALDEIRA, 2007).

Os sistemas neuro-*fuzzy* quebram este conceito de caixa preta das redes neurais, porque o comportamento deste modelo pode ser entendido através da observação das variáveis linguísticas, das funções de pertinência, dos relacionamentos entrada-saída e das próprias regras *fuzzy*, as quais podem explicar facilmente o funcionamento do sistema, devido a simplicidade e proximidade com a linguagem humana (RAMOS, 1999).

As redes neurais artificiais, com sua capacidade de aprendizagem e adaptação, diminuem a deficiência dos sistemas de inferência *fuzzy* em aprender novas regras, ou até mesmo remover as desnecessárias. Num ambiente impreciso e ambíguo, definir regras e funções de pertinência para um sistema inferência *fuzzy* não é uma atividade fácil, muitos erros durante a fase de fuzificação (KARTALOPOULOS, 1996) podem ser cometidos, comprometendo o pleno funcionamento destes sistemas. As redes neurais artificiais podem oferecer a um sistema *fuzzy* a habilidade de obter novas regras automaticamente, sem a presença do especialista, e remover aquelas com grau de importância ou peso, muito pequeno.

2.7 Características dos Sistemas Neuro-Fuzzy

Estes modelos de sistemas integram redes neurais artificiais e sistemas de inferência *fuzzy*, criando uma arquitetura homogênea, no qual o sistema de inferência *fuzzy* realiza o aprendizado usando algum tipo de algoritmo de treinamento baseado nos modelos de redes neurais artificiais (CALDEIRA, 2007).

A principal vantagem deste sistema é a consistência da arquitetura que evita problemas de comunicação entre os dois modelos, pois os sistemas estão completamente integrados. Desta forma, as regras, as variáveis de entrada e as variáveis de saída são representadas pelos neurônios e os pesos representam os conjuntos *fuzzy* (RAMOS, 1999).

Os sistemas híbridos que combinam lógica *fuzzy*, redes neurais, algoritmos genéticos e sistemas especialistas proporcionam os métodos mais eficientes para resolver uma grande variedade de problemas. Cada uma dessas técnicas tem propriedades computacionais particulares (por exemplo, habilidade de aprender, explanação das decisões) que as faz ótimas para certos problemas particulares e não para outros. Por exemplo, quando as redes neurais artificiais são boas em reconhecimento de padrões, não são boas em explicar como alcançam suas decisões, que é bem realizado pela lógica *fuzzy* (RODRÍGUEZ, 2003).

Já os sistemas de inferência *fuzzy*, podem raciocinar com informações imprecisas, são bons em explicar decisões, por outro lado, não podem gerar de modo automático as regras que

se usam para realizar aquelas decisões. Estas limitações foram à motivação principal para a criação dos sistemas híbridos inteligentes onde duas ou mais técnicas são associadas de modo que supere as limitações de cada uma das técnicas individualmente (RODRÍGUEZ, 2003).

A utilização dos sistemas híbridos vem crescendo bem rápido com aplicações sucedidas em muitas áreas, como exemplos, controle de processos, engenharia, negócios e finanças, apoio a diagnóstico médico, em modelo de previsão e a simulação (RODRÍGUEZ, 2003).

Segundo Ramos (1999) os sistemas neuro-*fuzzy* também podem ser vistas como redes *multilayer feedforward* de três camadas, como se pode verificar na Figura 12.

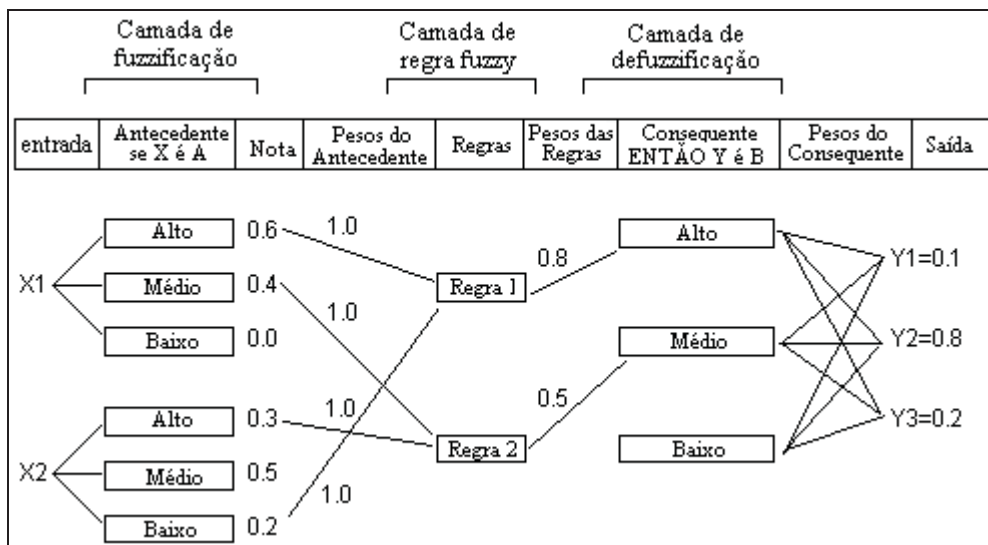


Figura12 – Arquitetura de um sistema neuro-*fuzzy* (www.din.uem.br/ia/intelige/neurofuzzy/).

A primeira camada (fuzzificação) representa as variáveis de entrada, ou seja, o termo antecedente da regra. A segunda camada (intermediária) representa as regras *fuzzy* e a terceira camada (defuzzificação) representa as variáveis de saída, ou seja, o termo consequente da regra. A arquitetura do sistema neuro-*fuzzy* utilizado neste trabalho será descrita com mais detalhes no próximo capítulo.

O algoritmo de aprendizagem ajusta os pesos das conexões, podendo criar ou remover regras. As mudanças na rede, durante o processo de treinamento pode ser conhecido com base na estrutura do sistema de inferência *fuzzy*, o que remove a idéia de caixa preta associada às RNA. Portanto, pode-se obter o conhecimento resultante do processo de treinamento que está estruturado em forma de regras *fuzzy* (RAMOS, 1999).

Sistemas neuro-*fuzzy* podem aprender no modo supervisionado, desde que se conheça a saída esperada (RAMOS, 1999).

Num sistema neuro-*fuzzy*, são empregadas as operações *t*-normas ou *t*-conormas, da aritmética *fuzzy* (FULLÉR, 1995), ao invés das operações de multiplicação e adição.

Mais detalhes sobre sistemas híbridos podem ser encontrados em FULLÉR, 1995; IYODA, 2000; CALDEIRA, 2007.

2.8 Aprendizagem de Sistemas Neuro-Fuzzy

O processo de aprendizagem necessita de uma partição inicial para cada variável. O dado treinado é processado e os *clusters*, que cobrem as áreas onde o dado está localizado, são adicionados à base de regras do classificador. No ciclo seguinte, apenas as melhores regras são mantidas, reduzindo a quantidade de regras do sistema (RAMOS, 1999).

Após a criação da base de regras, as funções de pertinência são ajustadas através de alguma heurística. Para cada regra, um erro é computado e este será usado para modificar as funções de pertinência que tiveram influência na ativação da regra (NAUCK, 1997).

Para melhorar a capacidade de aprendizagem do sistema, podem ser introduzidos novos conceitos (NAUCK, 1997), tais como: retreinar a base de regras, eliminarem regras e variáveis. O retreinamento da base deve acontecer quando o erro não puder ser mais reduzido, então se necessita reinicializar a criação das regras. As regras correntes serão comparadas com as novas.

A eliminação de regras serve para reduzir a base, pois as regras com baixo desempenho ou que cobrem dados de outra regra são removidas.

A eliminação de variáveis deve ser realizada quando as variáveis nunca atingirem nem o grau de pertinência mínimo de todas as variáveis do antecedente da regra. Se isto acontecer, a variável deve ser excluída deste antecedente (RAMOS, 1999).

2.9 Vantagens dos Sistemas Neuro-Fuzzy

Diferentemente das redes neurais artificiais convencionais, os sistemas neuro-fuzzy, usando técnicas como o aprendizado neuro-fuzzy descritas em Nauck (1997) que podem extrair regras da base de dados, sem qualquer interferência humana. Estas bases de regras fuzzy são usadas para gerar os classificadores fuzzy e são requisitadas em processos de suporte à decisão.

Outra vantagem sobre as redes neurais é o fato dos sistemas neuro-fuzzy terem seu funcionamento completamente compreensível devido a regras estarem próximas da linguagem

natural. Os sistemas neuro-*fuzzy* não possuem a característica de caixa preta, que causou tantas discussões entre os pesquisadores. Todas as decisões tomadas podem ser analisadas e entendidas (RAMOS, 1999).

Os sistemas neuro- *fuzzy* apresentam as características importantes como classificação e agrupamento em *clusters*. Também são usadas em várias aplicações que envolvem previsão (FULLÉR, 1995). Por meio das regras *fuzzy*, podem-se obter o relacionamento entre a entrada e a saída.

Os sistemas neuro-*fuzzy* possuem as características fundamentais requisitadas para desenvolver um sistema de mineração de dados (NAUCK, 1997). Estes sistemas podem ser usados em sistemas de previsão, análise de risco, ou qualquer sistema de suporte à tomada de decisão (FULLÉR, 1995).

Segundo Osório (1999) os principais sistemas neuro-*fuzzy* citados na literatura sobre este tipo de métodos híbridos são: *Fuzzy*ARTMAP, FUN, *Fuzzy* COPE, NEFCON NEFCLASS- NEFPROX, FUNEGEN e ANFIS.

A seguir, apresenta-se o método neuro-*fuzzy* ANFIS baseado em sistema de inferência *fuzzy* tipo Takagi-Sugeno que faz parte deste trabalho.

3 ARQUITETURA DO MODELO DO SISTEMA DE INFERÊNCIA NEURO-FUZZY ADAPTATIVO – ANFIS

O Sistema de Inferência Neuro-Fuzzy Adaptativo (*Adaptive Neuro-Fuzzy Inference System* - ANFIS) é uma rede neural proposta por Jang (1993), cuja idéia básica é de implementar um sistema de inferência *fuzzy* por meio de uma arquitetura paralela distribuída, neste caso, a de uma RNA, de tal forma que os algoritmos de aprendizado possam ser usados para ajustar este sistema de inferência *fuzzy* (TEIXEIRA *et al.*, 2007).

Os parâmetros associados com as funções de pertinência são ajustados via um algoritmo de aprendizado. O ajuste destes parâmetros é efetuado utilizando o algoritmo *back-propagation* ou uma combinação deste com um algoritmo do tipo mínimos quadrados (*Least Squares*). Esta estrutura programa sistemas do tipo Takagi-Sugeno (TAKAGI; SUGENO, 1985), com funções lineares ou constantes nos consequentes das regras que formam o sistema, tendo estas regras pesos unitários (HUAMANI, 2003).

Dado um conjunto de padrões entrada-saída, o ANFIS constrói um sistema de inferência neural e *fuzzy* equivalente (HUAMANI, 2003).

O sistema ANFIS apresenta então sua característica típica, necessitando de um processo de fuzificação dos dados de entrada, porém não precisando fazer o processo inverso no final, sendo a saída calculada diretamente.

O treinamento compõe-se de duas etapas. A primeira envolvendo o algoritmo LSE (*Least Square Estimation*) sobre os parâmetros do consequente para cada regra (os parâmetros do consequente permanecem fixos nesta etapa). Na segunda etapa, utiliza-se o algoritmo *back-propagation* sobre os parâmetros do precedente da regra (aqui, os parâmetros do consequente permanecem fixos) (AZEVEDO *et al.*, 2000).

O uso de funções de pertinência contínuas permite obter expressões contínuas para a descida de gradiente, necessária ao algoritmo *back-propagation*. Este ciclo é executado então para um número de interações pré-fixadas.

Um número excessivo de épocas de treinamento pode levar a uma deformação das funções de pertinência. O uso de restrições sobre a faixa de valores possíveis dos parâmetros do precedente pode ser útil de forma a evitar tal efeito e permitir uma interpretação lingüística aceitável das entradas.

A Figura 13 mostra o sistema neuro-*fuzzy* equivalente e a Figura 14, ilustra o mecanismo de inferência associado ao modelo. Este sistema possui duas entradas x , y , uma saída f e duas regras da forma:

$$\text{Regra 1 : SE } (x \text{ é } A_1) \text{ E } (y \text{ é } B_1) \text{ ENTÃO } f_1 = p_1x + q_1y + r_1 \quad (4)$$

$$\text{Regra 2 : SE } (x \text{ é } A_2) \text{ E } (y \text{ é } B_2) \text{ ENTÃO } f_2 = p_2x + q_2y + r_2 \quad (5)$$

Considerando o exemplo ilustrado, a saída da camada 1 é composta pelos graus de pertinência do padrão de entrada (x , y) com relação aos subconjuntos *fuzzy* que formam a partição de x e y , respectivamente.

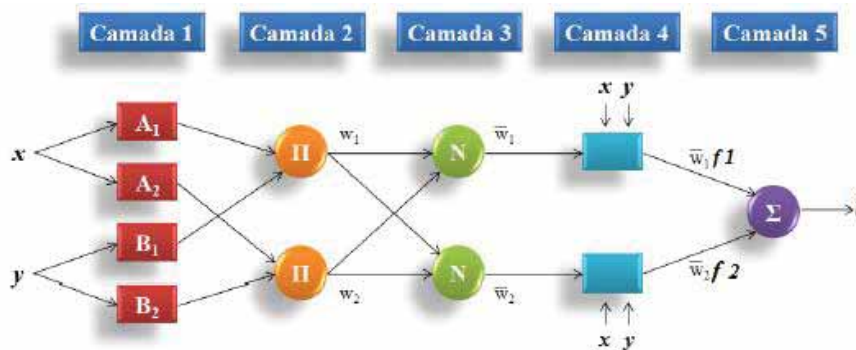


Figura 13 – Estrutura do ANFIS (adaptado de Jacintho, 2010).

A **primeira camada** é composta pelo o grau de pertinência do padrão de entrada (x , y). Nesta camada calcula-se o grau de pertinência com que as entradas precisas satisfazem os termos lingüísticos associados a estes nós. A dinâmica do treinamento determina a evolução dos vários parâmetros.

Na **segunda camada**, cada nó corresponde a uma regra, nesta calcula-se o grau de ativação de cada regra, ou seja, com que grau o conseqüente da regra está sendo atendido. Os neurônios desta camada executam a operação de t-norma (geralmente produto). Trata-se de camada com elemento estático.

A segunda camada calcula o grau de ativação de cada regra. No caso do exemplo ilustrado na Figura 14 e considerando a t-norma como o produto algébrico (neurônio Π), tem-se:




Figura 14 – Mecanismo de inferência ANFIS (adaptado de JANG, 1997).

Sendo que qualquer outro tipo de operador t-norma pode ser utilizado na implementação do neurônio II.

A **terceira camada** também é estática, sendo responsável pelo cálculo do grau de ativação normalizado das variáveis partes consequentes do sistema TSK subjacente.

Na terceira camada, os graus de relevância de cada regra são normalizados via neurônios N, isto é:

$$\bar{w}_i = \frac{w_i}{w_1 + w_2} \quad i = 1, 2 \quad (6)$$

Na **quarta camada** as saídas do neurônio são calculadas pelo produto entre os níveis de disparo normalizados e o valor da regras do consequente da regra em si. Seus parâmetros correspondem aos coeficientes das expressões afins.

As funções de ativação dos neurônios que formam a quarta camada são definidas como:

$$z_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_i + q_i y + r_i) \quad (7)$$

Sendo p_i , q_i , r_i os parâmetros associados aos consequentes das regras.

A camada 5 calcula a saída precisa. É fixa e responsável pela soma de sinais de entradas locais e respectiva propagação para a saída.

A saída f do sistema neuro-*fuzzy* é calculada da seguinte maneira:

$$f = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (8)$$

Estas variáveis ajustáveis são os parâmetros associados aos antecedentes das regras.

O processo de treinamento é composto de duas etapas. Na primeira etapa (*forward*), os parâmetros dos antecedentes são fixos e os parâmetros dos conseqüentes são determinados via algoritmo dos mínimos quadrados. Na segunda etapa (*backward*), os sinais de erro são retropropagados e os parâmetros dos antecedentes são atualizados via o método do gradiente descendente (retropropagação). Maiores detalhes podem ser encontrados em (JANG, 1997).

3.1 Aprendizado do modelo ANFIS

Se um conjunto de treinamento (conjunto clássico) é apresentado na camada de entrada do sistema, então os parâmetros do sistema neuro-*fuzzy* que determinam a forma da função de pertinência, podem ser ajustados usando métodos de otimização de tipo descendente (RODRÍGUEZ, 2003).

A regra de aprendizado híbrido combina a descida a mais métodos descendentes (SD) e o método de mínimos quadrados para atualizar os parâmetros no ANFIS. Para que a aprendizagem híbrida seja aplicada em grupo, cada época é composta de um passo *forward* e de um passo *backward*. No passo *forward*, os parâmetros das funções de pertinência são inicializados e um vetor de entrada-saída é apresentado, calculam-se as saídas do nó para cada camada da rede, então os parâmetros θ são calculados usando o método de mínimos quadrados (RODRÍGUEZ, 2003).

Depois de identificar os parâmetros, o erro é calculado como a diferença entre a saída da rede e a saída desejada apresentada nos pares de treinamento. No passo *backward*, os sinais do erro são propagados desde a saída na direção das entradas; o vetor gradiente é acumulado para cada dado de treinamento. No final do passo *backward* para todos os dados de treinamento, os parâmetros na camada 1 (os parâmetros das funções de pertinência) são atualizados pelo método descendente.

Isto significa que a taxa de aprendizagem é variável e ajusta-se automaticamente. (RODRÍGUEZ, 2003).

Dentre os sistemas ditos neuro-*fuzzy*, pode-se destacar os sistemas que criam regras a partir de observações anteriores, especialmente usados na previsão de séries como o ANFIS.

O método ANFIS aplica inferência *fuzzy* ao sistema. As funções de pertinência são escolhidas automaticamente através de aprendizado neuro-adaptativo.

Um algoritmo constrói um “sistema *fuzzy* de inferência” (FIS) cujas funções de pertinência são sintonizadas (*tuned*) usando algoritmo de retropropagação (*back propagation*) sozinho ou combinado com o método dos mínimos quadrados. Com isso, o sistema aprende com os dados do modelo.

Seguem abaixo os passos para uso do método ANFIS (BRUSAFERRO, 2006):

- Coletar dados de entrada e saída;
- Usar o algoritmo ANFIS para treinar a FIS;
- Usar dados de entrada conhecidos no modelo FIS treinado;
- Verificar o erro entre as saídas conhecidas e a saída do modelo;
- Deve-se tomar cuidado com o “*model-overfitting*” (sobreajuste ou ajuste excessivo dos exemplos de treino, ou seja, aprendem-se inclusive os ruídos e os erros. Ocorre freqüentemente quando temos muitas variáveis e poucos dados);
- Dados para o treinamento devem representar bem o modelo.

Limitações do modelo:

- Deve ser usado como um Sugeno de primeira ordem, ou seja, as regras são do tipo função linear (no de ordem zero elas são constantes);
- Tem saída simples do tipo linear ou constante;
- Não pode haver compartilhamento de regras;
- Tem peso unitário para cada regra (BRUSAFERRO, 2006).

A aplicação do sistema ANFIS está em recursos disponíveis na *Fuzzy Logic Toolbox* do programa computacional Matlab. O uso do *Toolbox* será demonstrado no capítulo de materiais e métodos dessa tese.

4 POLUIÇÃO ATMOSFÉRICA

4.1 Poluentes

A poluição atmosférica é uma das questões ambientais mais críticas no planeta devido ao seu impacto sobre a saúde humana, principalmente em grandes áreas urbanas. Desde que surgiram os primeiros ancestrais do homem no planeta Terra, há aproximadamente um milhão de anos, estes têm atuado de forma transformadora e predatória sobre a natureza. A partir da descoberta do fogo, aproximadamente 800 mil anos antes de Cristo, o Homem passou a contribuir de forma desordenada (inconsciente) para a deterioração da qualidade do ar, e hoje mais do que nunca, vem sofrendo com as consequências desse ato (BRAGA *et al.*, 1999).

Estes processos não foram acompanhados de análises que pudessem avaliar o impacto da poluição sobre o meio ambiente, a toxicidade dos resíduos produzidos e os prováveis danos à saúde (CANÇADO *et al.*, 2006).

De fato, a rápida urbanização, o crescimento demográfico, a queima de biomassa, a industrialização e um número crescente de veículos automotores são hoje as principais causas da poluição atmosférica; o crescimento econômico de centros urbanos tem causado o aumento da poluição atmosférica particularmente por monóxido de carbono (CO), óxidos de nitrogênio (NOx), dióxido de enxofre (SO₂), ozônio (O₃), hidrocarbonos (HC) e material particulado (MP) dentre outros, em associação com as variações climáticas como a umidade relativa do ar (UR), ventos, chuvas (precipitações) e a temperatura do ar (T°).

Poluente atmosférico é definido como qualquer substância no ar cuja concentração possa ser prejudicial à saúde dos seres humanos, fauna, a flora e até mesmo aos mais diversos tipos de materiais. Os poluentes incluem quase todas as composições naturais ou artificiais de matéria em suspensão no ar que pode ser transportada pelo mesmo. Apresentam-se na forma de partículas sólidas, líquidas, gases, ou combinadas. São constatados mais de 100 contaminantes do ar, sendo divididos nas seguintes categorias: sólidos, compostos sulfúricos, químicos orgânicos voláteis, compostos nitrogenados, compostos oxigenados, compostos radioativos e odores (CETESB, 2012).

Segundo Cançado *et al.* (2006), poluição atmosférica pode ser definida como a presença de substâncias estranhas na atmosfera, resultantes da atividade humana ou de processos naturais, em concentrações suficientes para interferir direta ou indiretamente na saúde, segurança e bem estar dos seres vivos.

Considera-se poluente qualquer substância presente no ar e que pela sua concentração possa torná-lo impróprio, nocivo ou ofensivo à saúde, inconveniente ao bem estar público, danoso aos materiais à fauna e à flora ou prejudicial à segurança, ao uso e ao gozo da propriedade e às atividades normais da comunidade (CONAMA, 1990).

Mesmo mantida as emissões de poluentes do ar sobre controle, a qualidade do ar é diretamente influenciada pela distribuição e intensidade das emissões de poluentes atmosféricos e podem sofrer alterações em função das variáveis climáticas (umidade relativa do ar, temperatura, pressão e chuva) ao longo do dia.

As fontes naturais de poluição do ar são a queima acidental de biomassa (qualquer material derivado de plantas ou animais), ações biológicas em pântanos e erupções vulcânicas, as quais podem ser consideradas as mais antigas fontes de contaminação do ar (CANÇADO *et al.*, 2006) e as antropogênicas (fontes móveis – veículos; fontes fixas – fábricas, termoeletricas).

A partir da Revolução Industrial a antropogênica ficou mais evidente, surgiram novas fontes de poluição do ar devido à queima de combustíveis fósseis nos motores a combustão e nas indústrias siderúrgicas. Recentemente, somaram-se as fontes emissoras de poluente os veículos automotivos com uma frota cada vez maior e também dos produtos químicos (ARBEX *et al.*, 2004).

Poluentes podem ser classificados em primários e secundários. Os poluentes primários são emitidos diretamente pelas fontes emissoras para a atmosfera, e os secundários são resultantes de reações químicas (fotoquímica) entre os poluentes primários e componentes normais da atmosfera (CETESB, 2012).

Os principais poluentes primários monitorados no Brasil e pelas principais agências ambientais em todo o mundo são óxidos de nitrogênio (NO_2 ou NO_x), compostos orgânicos voláteis (COVs), monóxido de carbono (CO) e dióxido de enxofre (SO_2). Um exemplo de poluente secundário é o ozônio (O_3), formado a partir da reação química induzida pela oxidação fotoquímica dos COVs e o NO_2 na presença de raios ultravioleta provenientes da luz solar (ARBEX *et al.*, 2012).

A Organização Mundial da Saúde (OMS) lista seis poluentes atmosféricos clássicos, sendo eles indicadores da qualidade do ar, é composto por: monóxido de carbono (CO), chumbo (Pb), dióxido de nitrogênio (NO_2), Material Particulado (MP) que inclui a poeira, fumos, neblinas e fumaça, dióxido de enxofre (SO_2) e ozônio (O_3) (WHO, 1999). Os novos parâmetros da OMS para o MP_{10} e $\text{MP}_{2.5}$ são demonstrados no ANEXO A.

De acordo com a Cetesb (2012), os padrões de qualidade do ar podem ser divididos em primários e secundários. São padrões primários de qualidade do ar as concentrações de poluentes que, ultrapassadas, poderão afetar a saúde da população. Podem ser entendidos como níveis máximos aceitáveis de concentração de poluentes atmosféricos, constituindo-se em metas de curto e médio prazo. São padrões secundários de qualidade do ar as concentrações de poluentes atmosféricos abaixo das quais se prevê o mínimo efeito adverso sobre o bem estar da população, assim como o mínimo dano à fauna e à flora, aos materiais e ao meio ambiente em geral. Os parâmetros primários e secundários de acordo com a CETESB estão demonstrados no ANEXO B.

A seguir será realizada uma breve descrição sobre os poluentes: material particulado (MP_{10}), ozônio (O_3) e o dióxido de enxofre (SO_2), utilizados no trabalho.

4.1.1 Material Particulado – MP_{10}

O material particulado (MP) é um conjunto de poluentes constituído de poeiras, fumaças e todo o tipo de material sólido e líquido que se mantém suspenso na atmosfera por causa de seu pequeno tamanho. Esse poluente é resultado da queima incompleta de combustíveis e de seus aditivos, de processos industriais, do desgaste de pneus e freios, além da queima de biomassa (SALES; MARTINS, 2005).

De acordo com a CETESB o material particulado pode ser classificado de acordo com o diâmetro aerodinâmico como:

Partículas Totais em Suspensão – PTS – podem ser definidas de maneira simplificada como aquelas cujo diâmetro aerodinâmico é menor que $50\mu m$. Uma parte destas partículas é inalável e pode causar problemas à saúde, outra parte pode afetar desfavoravelmente a qualidade de vida da população, interferindo nas condições estéticas do ambiente e prejudicando as atividades normais da comunidade.

Fumaça – FMC – está associada ao material particulado suspenso na atmosfera proveniente dos processos de combustão. O método de determinação da fumaça é baseado na medida de refletância da luz que incide na poeira (coletada em um filtro), o que confere a este parâmetro a característica de estar diretamente relacionado ao teor de fuligem na atmosfera.

Partículas Inaláveis – MP_{10} – podem ser definidas de maneira simplificada como aquelas cujo diâmetro aerodinâmico é menor que $10\mu m$.

Partículas Inaláveis Finas – (MP_{2,5}) – Podem ser definidas como aquelas cujo diâmetro aerodinâmico é menor que 2,5µm. Existem também as partículas ultrafinas com diâmetro de 0,1 micra com capacidade de transpor a barreira alvéolo capilar e atingir a circulação sistêmica.

O material particulado pode-se formar na atmosfera a partir de gases como dióxido de enxofre (SO₂), óxidos de nitrogênio (NO_x), compostos orgânicos voláteis (COVs), que são emitidos principalmente em atividades de combustão, transformando-se em partículas como resultado de reações químicas no ar, poeiras minerais transportadas pelo vento, podendo conter endotoxinas e partículas biológicas com alergênicos associados (CETESB, 2013).

Ainda, como fontes naturais de material particulado, podem ser apontadas os vulcões, aerossóis marinhos e a ação do vento sobre o solo. Fontes antropogênicas criadas a partir da intervenção humana sobre a natureza podem ser observadas em processos industriais (por exemplo, o processo de extração de brita, realizado por pedreiras) tráfego rodoviário e a combustão fóssil.

Normalmente, o ar atmosférico contém partículas em suspensão que variam de 0,1 µm a 10µm de diâmetro. Partículas maiores que 10µm são efetivamente filtradas pelo nariz e pela nasofaringe, onde essas grandes partículas ficam depositadas e podem ser vistas em expectoração e/ou saliva. Partículas menores que 10µm de diâmetro (MP₁₀) ficam retidas nas vias aéreas superiores e podem ser depositadas na árvore traqueobrônquica. As partículas menores que 2,5µm (MP_{2,5}) depositam-se no brônquio terminal e nos alvéolos (CASTRO *et al.*, 2009).

Atualmente, existem parâmetros reguladores para o MP₁₀ e segundo a CETESB seu valor de referência é classificado como bom (em níveis aceitáveis), quando atinge até 50 µg/m³ em 24 horas.

O tamanho das partículas está diretamente associado ao seu potencial para causar problemas à saúde, sendo que quanto menores as partículas, maiores os efeitos provocados.

O material particulado pode também reduzir a visibilidade na atmosfera e é considerado um dos poluentes atmosféricos mais críticos.

4.1.2 Ozônio – O₃

O Ozônio é um gás incolor, inodoro em concentrações ambiental, relativamente insolúvel em água e não é emitido diretamente na atmosfera. É também o principal

componente da névoa fotoquímica, o *Smog*. É considerado um importante oxidante fotoquímico sendo bastante irritante (CETESB, 2011).

“Oxidantes fotoquímicos” é a denominação que se dá à mistura de poluentes secundários formados pelas reações entre os óxidos de nitrogênio (NO_x) e compostos orgânicos voláteis (VOCs), na presença de luz solar, sendo estes últimos liberados na queima incompleta e evaporação de combustíveis e solventes. O principal produto desta reação é o ozônio, por isso mesmo utilizado como parâmetro indicador da presença de oxidantes fotoquímicos na atmosfera. Tais poluentes formam a chamada névoa fotoquímica ou “*smog* fotoquímico”, que possui este nome porque causa na atmosfera diminuição de visibilidade (CETESB, 2013).

Forma-se no ar em resultado de reações fotoquímicas que envolvem, também, os óxidos de azoto emitidos para o ar em resultado de combustões a temperaturas elevadas. Neste processo também são libertados para o ar ambiente ácido nítrico, formaldeído e oxidantes orgânicos. Os seus níveis são mais elevados no verão e no período da tarde (GOMES, 2002).

Este é o ozônio troposférico, encontrado na faixa de ar próxima da superfície terrestre, onde respiramos que é tóxico. O ozônio presente na estratosfera (entre 25 e 30 km de altitude), forma uma camada protetora (conhecida como camada de ozônio) com importante função de proteger a Terra, como um filtro, dos raios ultravioletas emitidos pelo sol (CETESB, 2012).

Os níveis têm aumentado progressivamente desde o início do século XX. Diversos estudos epidemiológicos revelam um aumento dos sintomas respiratórios e alterações na função respiratória mesmo após exposições de curta duração (GOMES, 2002).

Segundo a CETESB, seu valor de referência é classificado como bom (em níveis aceitáveis), quando atinge até 80 µg/m³ em 1 hora.

4.1.3 Dióxido de Enxofre – SO₂

O SO₂ é um gás não inflamável, sem cor, com odor forte e irritante aos olhos. Ele reage com uma variedade enorme de partículas, é solúvel em água e pode ser oxidado. Este gás é produzido por fontes antropogênicas como refinarias de petróleo, veículos a diesel, fornos e metalurgia e fabricação de papel e por fontes naturais como a atividade vulcânica (principal fonte de emissão natural). A queima de combustíveis fósseis é fonte de emissão do SO₂ (CETESB, 2013).

As principais características do SO_2 lançado para a atmosfera, após o processo de oxidação é que ele pode ser transformado em trióxido de enxofre (SO_3). O SO_3 reage com a umidade do ar dando origem ao ácido sulfúrico (H_2SO_4) e respectivos sais, sendo assim, um dos principais formadores de chuvas ácidas.

O SO_2 é mais denso do que o ar e quando está na mesma temperatura do ar tende a ocupar locais mais baixos, sendo responsável pela redução da visibilidade na atmosfera.

Os danos do SO_2 à saúde humana podem ser aumentados na presença de material particulado e outros poluentes em concentrações altas; e com uma maior morbidade e mortalidade por doenças respiratórias, particularmente a asma brônquica e a bronquite crônica (GOMES, 2002).

Atualmente, segundo a CETESB seu valor de referência é classificado como bom (em níveis aceitáveis), quando atinge até $80 \mu\text{g}/\text{m}^3$ em 24 horas (CETESB, 2012).

A tabela 2 apresenta as fontes emissoras e os efeitos sobre a saúde dos poluentes MP, O_3 e SO_2 .

Tabela 2– Fontes emissoras de poluentes e efeitos à saúde (adaptado de CETESB, 2012).

Poluentes Monitorados	Fontes de Emissão	Efeitos à Saúde
Material Particulado (MP)	Combustão incompleta originada da indústria, motores à combustão, queimadas e poeiras diversas.	Interfere no sistema respiratório, pode afetar os pulmões e todo o organismo.
Dióxido de Enxofre (SO_2)	Queima de combustíveis fósseis que contenham enxofre, como óleo combustível, carvão mineral e óleo diesel.	Ação irritante nas vias respiratórias, o que provoca tosse e até falta de ar. Agravando os sintomas da asma e da bronquite crônica. Afeta, ainda, outros órgãos sensoriais.
Ozônio (O_3)	Não é um poluente emitido diretamente pelas fontes, mas formado na atmosfera através da reação entre os compostos orgânicos voláteis e óxidos de nitrogênio em presença de luz solar.	Irritação nos olhos e nas vias respiratórias, agravando doenças pré-existentes, como asma e bronquite, reduzindo as funções pulmonares.

4.2 Efeitos da poluição atmosférica sobre a saúde

A poluição do ar provoca doenças respiratórias (asma, bronquite e enfisema pulmonar) e desconforto físico (irritação dos olhos, nariz e garganta, dor de cabeça, sensação de cansaço, tosse), agrava doenças cardiorrespiratórias e contribui para o desenvolvimento de câncer pulmonar. Esses problemas de saúde relacionados à poluição atmosférica por vários estudos epidemiológicos e toxicológicos, até mesmo reconhecidos pela OMS têm alto custo social, com gastos no tratamento de saúde, perda de horas de trabalho, redução da produtividade e até mesmo com relação a morte prematura (SALES; MARTINS, 2005).

Estudos têm demonstrado em grandes cidades como São Paulo, Rio de Janeiro, Belo Horizonte, Curitiba e Salvador, que variações nos os níveis de poluição têm relações danosas à saúde da população. Ainda nesse sentido Motta, Mendes (1995), relacionaram os custos com a saúde e a poluição do ar no Brasil. Já foram detectadas associações entre níveis diários de poluentes atmosféricos e mortes em idosos; (SALDIVA *et al.*, 1995; BASCON *et al.*, 1996; GOUVEIA; FLETCHER, 2000a;) internações por doenças respiratórias (GOUVEIA, FLETCHER, 2000b; SALDIVA 2008; SALDANHA, 2005; AMÂNCIO, NASCIMENTO, 2012a) internações e mortes por doenças cardiovasculares (GOUVEIA *et al.*, 2003; LIN *et al.*, 2003, FERNANDES *et al.*, 2010; AMÂNCIO, NASCIMENTO, 2012a) e, ainda, mortes fetais tardias (PEREIRA *et al.*, 1998) e baixo peso ao nascer (NASCIMENTO; MOREIRA, 2009).

Atualmente, o problema se estende além dos grandes centros urbanos e também afetam cidades de médio e pequeno porte (BAKONYI *et al.*, 2004; SALES; MARTINS, 2005; NASCIMENTO *et al.*, 2006; BRAGA *et al.*, 2007; NICODEMOS *et al.*, 2009; BUENO, 2010; CARMO *et al.*, 2010).

Segundo Braga *et al.* (2007) além das emissões industriais e veiculares, que são características dos grandes centros urbanos, existem em cidades menores outras fontes de emissão de poluentes que podem colocar em risco a saúde dos seus habitantes, tais como a queima de biomassa, que tem se mostrado uma importante fonte de poluentes do ar. Tanto as queimadas acidentais de florestas quanto aquelas realizadas deliberadamente (queima da cana de açúcar, para a formação de pastagem, entre outras) promovem danos consideráveis à saúde das populações expostas.

O material particulado (MP) é considerado como um dos maiores causadores de efeitos nocivos a saúde humana dentre os poluentes presentes no ar e agregado a ele poderão estar associados outros poluentes tais como metais e hidrocarbonetos (considerados carcinogênicos), sendo então, o MP o transportador mais eficiente de poluentes atmosféricos

para o interior do organismo humano e por isso tem recebido atenção especial nos estudos relacionados à poluição atmosférica (GIODA; GIODA, 2006).

Quanto menor o diâmetro das partículas, mais nocivas elas podem se tornar. A poeira e a fumaça podem provocar irritação ocular, nasal, do trato respiratório e pulmonar e até bronquite, asma e mesmo a morte. O MP 2,5 devido ao seu tamanho diminuto atinge os alvéolos pulmonares que se constituem na região mais profunda do sistema respiratório onde ocorrem as trocas gasosas, provocando dificuldades respiratórias, podendo também originar doenças respiratórias crônicas, como a pneumoconiose (doença pulmonar causada por inalação de poeira); e contribuindo para um aumento da mortalidade e morbidade (GIODA; GIODA, 2006)

Entre as partículas inaláveis, as mais grossas ficam retidas, por ação da gravidade, na parte superior do sistema respiratório, desencadeando rinites e sinusites (SALES; MARTINS, 2005).

De acordo com a Agência de Proteção Ambiental dos Estados Unidos (EPA), os MP₁₀ constituem um risco acrescido para a asma.

As partículas finas e ultrafinas estão relacionadas principalmente com a morbidade em idoso por doenças cardiovasculares e nas crianças por doenças respiratórias (SILVA, 2010).

Em altas concentrações o ozônio é um gás tóxico que pode desenvolver lesões irreversíveis a via respiratória e ao parênquima pulmonar. O O₃ pode provocar irritações nos olhos, nariz e garganta, seguindo-se tosse e dor de cabeça. A sua ação pode ser percebida, mesmo para concentrações baixas e para exposições de curta duração, principalmente em crianças (WHO, 2005).

Segundo O'Connor *et al.*(2008), a exposição ao O₃ leva a um maior número de internações hospitalares por doenças respiratórias em indivíduos com doenças respiratórias pré-existentes. A exposição prolongada provoca sintomas de bronquite e acentuação da queda anual do Volume Expiratório Forçado no 1 segundo (FEV₁) que caracteriza a obstrução das vias aéreas inferiores (BASCUM *et al.*, 1996).

A inalação de O₃ em estudos experimentais predispôs dor retroesternal durante a fase de inspiração e uma redução do Volume Expirado Forçado no primeiro segundo (FEV₁) e na Capacidade Vital Forçada (FVC), efeitos que aumentam com a atividade física. O ozônio provoca um aumento da resposta à metacolina (substância que induz ao broncoespasmo) e à exposição a alergênicos (BASCUM *et al.*, 1996), causando ainda, alterações celulares e bioquímicas, que provoca um aumento de neutrófilos nas vias aéreas (GOMES, 2002).

Outros efeitos possíveis da exposição ao O_3 são as lesões celulares e diminuição da permeabilidade celular. Sendo o O_3 pouco solúvel, penetra profundamente nas vias aéreas periféricas, sendo o processo inflamatório das vias aéreas parece ser mais marcante nos pacientes asmáticos do que na população saudável (GOMES, 2002).

O dióxido de enxofre é irritante para as mucosas dos olhos e do sistema respiratório podendo ter efeitos agudos e crônicos na saúde dos indivíduos expostos, reportados predominantemente ao aparelho respiratório. Tem efeitos tóxicos aumentado em pacientes com doenças respiratórias prévias e cardiovasculares pré-existentes. A exposição em longo prazo provoca um aumento da tosse e expectoração; e tem também efeito broncoconstritor (broncoespasmo) em pacientes asmáticos levando a diminuição do fluxo aéreo (CETESB, 2012).

O SO_2 uma vez inalado dissolve-se na camada de muco que reveste o epitélio das vias aéreas e transformam-se em ácido sulfúrico, sulfitos, bissulfitos e sulfatos. Estes produtos tal como o SO_2 interferem com as pontes de dissulfitos, mas o mecanismo ainda não está bem esclarecido. Há liberação de mediadores da inflamação que induzem hipersecreção de muco e estimulação das terminações nervosas aumentando os episódios de tosse. A exposição prolongada pode causar alterações obstrutivas das vias aéreas semelhantes às da bronquite crônica (CETESB, 2012).

Sozinho provoca irritação no sistema respiratório, e convertido em partículas pode ser conduzido as vias aéreas inferiores, podendo causar danos ao parênquima pulmonar. Mesmo em níveis tolerados pelas agências de controle, o SO_2 tem sido associado ao aumento de morbidade cardiovascular em pessoas idosas (CETESB, 2012).

5 DOENÇAS RESPIRATÓRIAS

O sistema respiratório, por sua exposição direta com o meio externo e pelas funções, de condução do ar e da troca gasosa, que desempenha, está particularmente exposto às agressões do ambiente e é frequentemente local de alterações de maior ou menor intensidade e gravidade (GOMES, 2002).

Doenças das vias respiratórias altas e baixas podem ser doenças infecciosas (resfriado comum e pneumonias) ou não infecciosas (rinite alérgica e asma). Em estudos de campo, entretanto, nem sempre é possível distinguir a origem infecciosa ou não infecciosa da doença respiratória (BENÍCIO *et al.*, 2000).

Segundo Galvão e Santos (2009) definem pneumonia como uma infecção aguda do parênquima pulmonar com uma inflamação do espaço alveolar, que pode comprometer a troca gasosa. Comumente, esta inflamação resulta da invasão principalmente de bactérias, vírus ou fungos, embora também possa resultar de uma lesão química.

Segundo as Diretrizes da Sociedade Brasileira de Pneumologia e Tisiologia para o Manejo da Asma (2012), asma é uma doença inflamatória crônica, caracterizada por hiperresponsividade brônquica e por limitação variável ao fluxo aéreo, reversível espontaneamente ou com tratamento, manifestando-se clinicamente por episódios recorrentes de sibilância, dispnéia, aperto no peito e tosse. Resulta de uma interação entre genética, exposição ambiental a alérgenos e irritantes, e outros fatores específicos que levam ao desenvolvimento e manutenção dos sintomas.

A poluição do ar causa uma resposta inflamatória no aparelho respiratório induzida pela ação de substâncias oxidantes, as quais acarretam aumento da produção, da acidez, da viscosidade e da consistência do muco produzido pelas vias aéreas, levando, conseqüentemente, à diminuição da resposta e/ou eficácia do sistema mucociliar (GOMES, 2002).

A literatura biomédica está repleta de estudos sobre os efeitos agudos da poluição do ar sobre a saúde. A maior ênfase é dada a dois desfechos: mortalidade e admissões hospitalares (CANÇADO *et al.*, 2006).

As doenças respiratórias constituem importante causa de adoecimento e morte em adultos e crianças no mundo (TOYOSHIMA *et al.*, 2005). Segundo dados da Organização Mundial de Saúde (OMS- 2012), calculam que nos dias atuais exista cerca de 235 milhões de

pacientes com asma. Ainda segundo a OMS as mortes por asma aumentarão entorno de 20% nos próximos 10 anos caso não se tomam medidas urgentes.

No Brasil, as doenças respiratórias agudas e crônicas também ocupam posição de destaque. Em 2007, foram registradas mais de 700 mil internações por pneumonia e em 2011 foram registradas aproximadamente 160 mil internações por asma (BRASIL, 2011).

A asma, a bronquite crônica e o câncer do pulmão são as doenças do aparelho respiratório, que têm relações mais estreitas com a poluição atmosférica. Assiste-se a um aumento da prevalência da asma em todo o Mundo (WHO, 1995), principalmente nos países industrializados, um aumento da bronquite crônica nos fumadores e nos não fumadores e são em número crescente os trabalhos que demonstram a correlação entre o aumento da prevalência destas patologias e a poluição atmosférica (WHO, 2001).

Durante a respiração a inalação dos poluentes do ar produz diversos efeitos biológicos sobre o corpo humano. As partículas inaladas podem depositar-se nas vias aéreas e interferir com os mecanismos fisiológicos de limpeza do pulmão ou depositar-se no parênquima pulmonar e eventualmente contribuir para o desenvolvimento da Doença Pulmonar Obstrutiva Brônquica (DPOC), ou câncer do pulmão se a exposição se mantiver durante anos. O pulmão pode ainda servir de porta de entrada para a circulação sistêmica e serem atingidos vários órgãos (GOMES, 2002).

Entretanto, apesar da importância epidemiológica das doenças respiratórias em nosso contexto, informações mais precisas sobre sua frequência, distribuição e tendências de evolução recente ainda são escassas no Brasil, principalmente para morbidade, uma vez que para mortalidade dispomos de um Sistema de Informações – SIM, já bastante consolidado (TOYOSHIMA *et al.*, 2005).

A poluição do ar, mesmo com valores abaixo do nível permitido pelos órgãos responsáveis CONAMA, CETESB, EPA, WHO; tem afetado de forma significativa a vida dos seres vivos (PEREIRA *et al.*, 1998; SALDIVA *et al.*, 1995).

As faixas etárias mais atingidas são as crianças com idade abaixo de 2 anos (imaturidade pulmonar) e os idosos (envelhecimento fisiológico do pulmão), grupos bastante suscetíveis aos efeitos deletérios da poluição do ar (BAKONYI *et al.*, 2004).

Embora o mecanismo biológico específico ainda esteja em estudo, diversos autores sustentam que o efeito deletério da poluição atmosférica na saúde da população é causal (MARTINS *et al.*, 2002).

Em um estudo de revisão realizado por Arbex *et al.* (2012), tem-se um excelente material relacionando poluição do ar e o sistema respiratório.

6 VARIÁVEIS CLIMÁTICAS

As variáveis climáticas; temperatura do ar, umidade relativa do ar, precipitação, pressão atmosférica e ventos, são componentes ambientais que influenciam diretamente e indiretamente na saúde humana, pois o ser humano está permanentemente em contato com o meio ambiente atmosférico pelo intermédio de trocas térmicas, hídricas e gasosas (PITTON; DOMINGOS, 2004; MENDONÇA, 2000).

Segundo Braga, Zanobetti e Schwartz (2002), os parâmetros meteorológicos que mais afetam as pessoas são a temperatura do ar, a umidade do ar, a velocidade do vento e a radiação solar, porém, as condições extremas de calor e frio têm se mostrado de maior significância em termos de morbidade e mortalidade humana. As grandes variações de temperatura, tanto no verão, como no inverno, são causadoras de mortes devido a problemas respiratórios.

Segundo Stocco *et al.* (2010), algumas doenças podem ser induzidas pelo clima em épocas diferentes e demonstram em suas incidências correlações íntimas com as condições climáticas e com a estação do ano, afetando a resistência do corpo humano, influenciando o crescimento, a propagação e a difusão de alguns organismos patogênicos ou de seus hospedeiros.

Em condições favoráveis de altas temperaturas e baixa umidade o tempo de permanência dos poluentes na atmosfera fica aumentado, podendo ser transportados a longas distâncias. Estes poluentes associados às condições climáticas podem afetar a saúde de populações distantes das fontes geradoras de poluição (OPAS, 2008).

6.1 Umidade Relativa do Ar (UR) e Temperatura do ar (T°)

As alterações de temperatura, umidade e o regime de chuvas podem aumentar os efeitos das doenças respiratórias, assim como alterar as condições de exposição aos poluentes atmosféricos. Dada a evidência da relação entre alguns efeitos na saúde devido às variações climáticas e aos níveis de poluição atmosférica, tais como os episódios de inversão térmica, aumento dos níveis de poluição e o aumento de problemas respiratórios, parecem inevitáveis que as mudanças climáticas de longo prazo possam exercer efeitos à saúde humana a nível global (OPAS, 2008).

Isto se verifica em relação à asma, alergias, infecções bronco-pulmonares e infecções das vias aéreas superiores (sinusite), principalmente nos grupos mais suscetíveis, que incluem as crianças menores de 5 anos e indivíduos maiores de 65 anos de idade (BARCELLOS *et al.*, 2009).

As doenças infecciosas são mais rapidamente difundidas entre a população durante a estação fria, devido, principalmente, ao agrupamento de pessoas em ambientes fechados, uma vez que na estação quente as pessoas realizam mais atividades externas (STOCCO *et al.*, 2010).

Mudanças climáticas bruscas ajudam a piorar a qualidade do ar respirado, sobretudo quando a massa de ar frio dificulta a corrente de ventos e faz precipitar o material particulado da atmosfera nas grandes cidades. Com isso, há aumento significativo para os casos de pneumonia, asma e bronquiolite (PEREIRA, 1995).

A análise da umidade relativa do ar (UR) é essencial em determinada região, visto que esta variável meteorológica pode causar danos principalmente a saúde de uma comunidade. O uso de estimativas da UR pode ser de grande utilidade para precauções no que se refere a cuidados da saúde humana.

Segundo Barcelos *et al.* (2009) os problemas mais comuns observados devido à baixa umidade relativa do ar são as complicações alérgicas e respiratórias; devido o ressecamento das mucosas, sangramento pelo nariz, ressecamento da pele, irritação dos olhos.

Os efeitos das mudanças climáticas podem ser potencializados, dependendo das características físicas e químicas dos poluentes e das características climáticas como temperatura, umidade e precipitação (BARCELOS *et al.*, 2009).

As alterações de temperatura, umidade e o regime de chuvas podem aumentar os efeitos das doenças respiratórias, assim como alterar as condições de exposição aos poluentes atmosféricos (BARCELOS *et al.*, 2009).

Dada a evidência da relação entre alguns efeitos na saúde devido às variações climáticas e aos níveis de poluição atmosférica, tais como os episódios de inversão térmica, aumento dos níveis de poluição e o aumento de problemas respiratórios, parecem inevitáveis que as mudanças climáticas de longo prazo possam exercer efeitos à saúde humana a nível global (BARCELOS *et al.*, 2009).

Em áreas urbanas alguns efeitos da exposição a poluentes atmosféricos são potencializados quando ocorrem alterações climáticas, principalmente as inversões térmicas (BARCELOS *et al.*, 2009).

O aumento da temperatura também está associado ao incremento de partículas alergênicas produzidas pelas plantas, aumentando o número de casos de pessoas com respostas alérgicas e asmáticas (ZAMORANO *et al.*, 2003).

Segundo Arbex *et al.* (2004) é sabido que a umidade relativa do ar e temperatura afeta a qualidade do ar e como consequência afeta também, a saúde humana.

No período seco, quando a temperatura do ar atinge valores muito altos e umidade relativa do ar muito baixa, sugerem-se cuidados com a saúde, haja vista que a umidade relativa do ar muito baixa pode causar problemas respiratórios, ressecamento de pele, sangramento do nariz, irritação dos olhos, dentre outros, sem mencionar o aumento do risco de incêndios (FERNANDES, 2010).

Ainda segundo Fernandes (2010) os efeitos dos poluentes acima citados, sofrem influência diretas de outros fatores, como a ação do vento, da umidade e temperatura.

6.2 Temperatura Aparente (Tap)

Segundo Barnett (2010), a temperatura aparente pode ser quantificada através de um índice relacionado à temperatura do ar e da umidade relativa do ar e tem como objetivo combinar os efeitos do calor e frio no corpo humano.

A temperatura aparente se difere da temperatura ambiente real por levar em conta a umidade relativa. Para calcular a temperatura aparente neste trabalho foi utilizada a fórmula descrita por Barnett (2010) ANEXO C.

Quando há baixa umidade relativa, a temperatura aparente pode ser menor do que a temperatura ambiente, pois, o suor evapora para esfriar o corpo. A evaporação do suor da pele no ser humano é o mecanismo natural que o corpo possui para regular a própria temperatura. Porém, quando o ar está muito úmido o processo é diminuído ou dificultado. Como resultado, em dias quentes e úmidos as pessoas têm sensações térmicas mais desagradáveis e, assim, surge sinais de fadiga no corpo.

A temperatura aparente fornece valores absolutos independentes da localização das coletas de dados.

7 MATERIAIS E MÉTODOS

Este trabalho foi realizado no município de São José dos Campos- SP, cidade de médio porte do interior do Estado de São Paulo que possui importante parque industrial. Situa-se nas coordenadas $23^{\circ} 10' S$ e $45^{\circ} 52' O$, no Alto Vale do Paraíba paulista, a 600 m acima do nível do mar. Tem clima úmido e tropical de altitude, localiza-se entre São Paulo e Rio de Janeiro – as duas maiores cidades do Brasil – e é cortada pela Rodovia Presidente Dutra, uma das mais importantes rodovias do país e que tem tráfego intenso. Em 2010, sua população era estimada em torno de 630 mil habitantes, conforme apresentado na Figura 15.




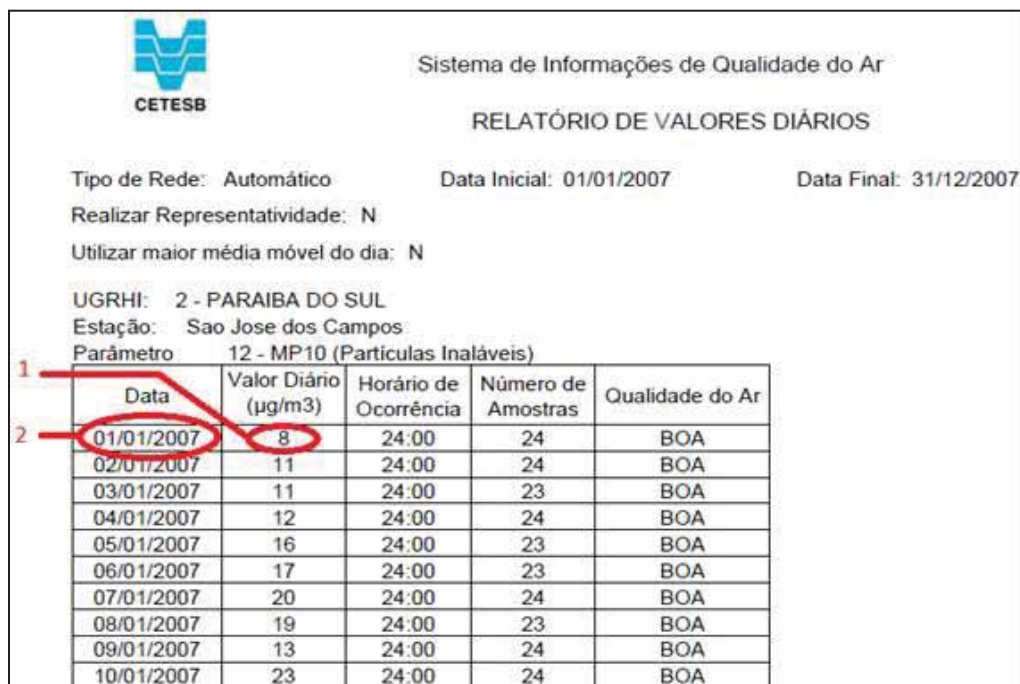
Figura 15 - Mapa do município de São José dos Campos (<http://maps.google.com.br>. 1:5Km).

A seguir, será apresentado o método para a realização deste trabalho, o qual será dividido em 3 módulos, sendo eles: limpeza e elaboração do banco de dados; elaboração e validação do modelo *fuzzy* (Mamdani) e elaboração e validação do modelo neuro-*fuzzy* (Sugeno).

Trata-se de um estudo do tipo ecológico de séries temporais utilizando as ferramentas da lógica *fuzzy* para desenvolver os modelos computacionais. Para a realização do trabalho foram coletados dados reais das internações por pneumonia e asma brônquica (CID10: J 12-18 e J45) em indivíduos de todas as idades residentes na cidade de São José dos Campos, no período de 01/01/2007 a 31/12/2007. Esses dados foram obtidos do Departamento de Informações e Informática do Sistema Único de Saúde - DATASUS. Também foram coletados os dados reais dos níveis dos poluentes ambientais: material particulado (MP₁₀), dióxido de enxofre (SO₂) e ozônio (O₃), em suas médias diárias, obtidos da Companhia de Tecnologia de Saneamento Ambiental - CETESB, que conta com uma estação medidora no município de São José dos Campos.

A técnica utilizada pela CETESB para dosar o MP₁₀ é o monitor beta; para o SO₂, a coulometria; e para o O₃, a quimiluminescência, tendo sido quantificados em µg/m³. Os dados de temperatura e umidade foram obtidos da Fundação de Ciência, Aplicações e Tecnologias Espaciais – FUNCATE no mesmo período de 2007 e utilizados para calcular a temperatura aparente (Tap) de acordo com Barnett (2010).

A fase inicial do método proposto para desenvolver os modelos preocupou com a seleção e organização do banco de dados com as variáveis de entrada e saída. Os dados referentes aos poluentes e variáveis climáticas, de entrada, foram extraídos das tabelas fornecidas pela Cetesb e Funcate, Figura 16.



Sistema de Informações de Qualidade do Ar
RELATÓRIO DE VALORES DIÁRIOS

Tipo de Rede: Automático Data Inicial: 01/01/2007 Data Final: 31/12/2007
 Realizar Representatividade: N
 Utilizar maior média móvel do dia: N

UGRHI: 2 - PARAIBA DO SUL
 Estação: Sao Jose dos Campos
 Parâmetro: 12 - MP10 (Partículas Inaláveis)

Data	Valor Diário (µg/m3)	Horário de Ocorrência	Número de Amostras	Qualidade do Ar
01/01/2007	8	24:00	24	BOA
02/01/2007	11	24:00	24	BOA
03/01/2007	11	24:00	23	BOA
04/01/2007	12	24:00	24	BOA
05/01/2007	16	24:00	23	BOA
06/01/2007	17	24:00	23	BOA
07/01/2007	20	24:00	24	BOA
08/01/2007	19	24:00	23	BOA
09/01/2007	13	24:00	24	BOA
10/01/2007	23	24:00	24	BOA

Figura 16 - Valores médios MP₁₀ (CETESB), do ano de 2007(próprio autor).

No círculo número 1, visto na figura 16, tem-se o valor do MP₁₀ (a mesma seleção foi realizada para o O₃, SO₂, Tap) e no número 2 a data das medidas dos mesmos. Esses valores fazem parte das quatro primeiras colunas de uma planilha desenvolvida no programa Excel.

Os dados referentes às internações diárias por pneumonia e/ou asma foram obtidos através da seguinte rotina: www2.datasus.gov.br/DATASUS/index.php, clicar: 1- em informações de saúde, 2- serviços, 3- transferência de arquivos, 4- SIHSUS reduzida, Figura 17.

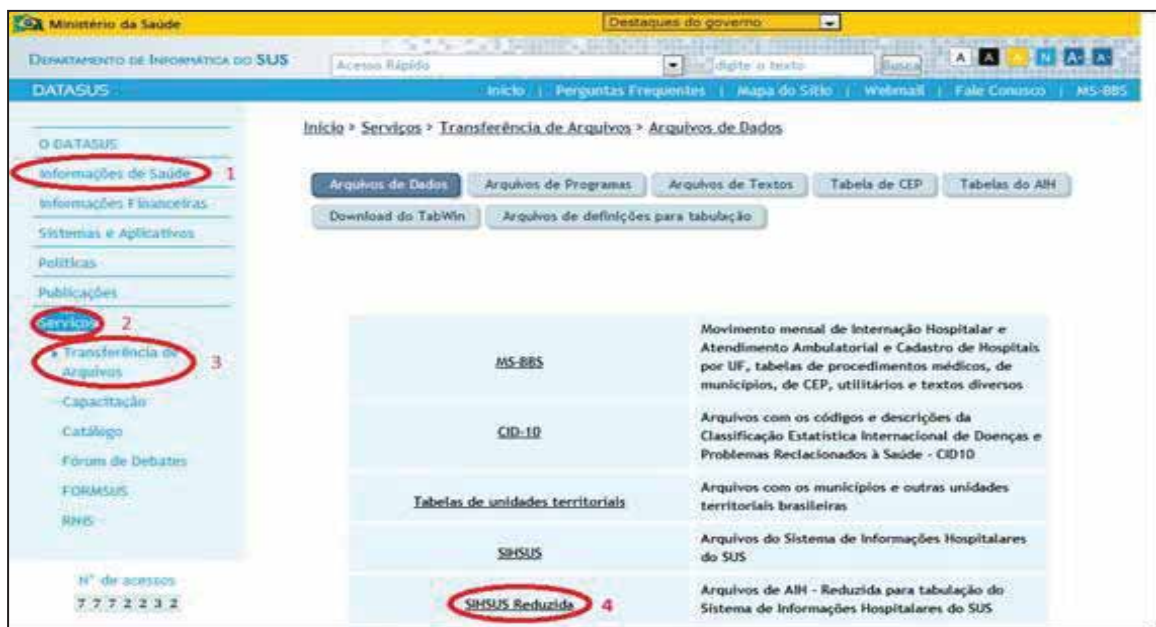


Figura 17 - Caminho para obter planilha DATASUS (próprio autor).

Em seguida selecionou-se: UF (SP), informou-se o mês (todos), informou-se o ano (2007) e o tipo de arquivo (RD), Figura 18.

Selecione, no quadro abaixo, o arquivo que deseja baixar.

Consulta

Selecione a UF:

Informe o Mês:

Informe o ano:

Informe o tipo de arquivo :

Figura 18 - Arquivo para baixar planilhas DATASUS (próprio autor).

Em seguida aparecerão os *links* dos arquivos para *downloads*, Figura 19.

SIHSUS Reduzida		
Arquivos para Downloads		
Mes/Ano	Arquivo	Data Últ. Atualização
1/07	rdsp0701.dbc(download)	-
2/07	rdsp0702.dbc(download)	-
3/07	rdsp0703.dbc(download)	-
4/07	rdsp0704.dbc(download)	-
5/07	rdsp0705.dbc(download)	-
6/07	rdsp0706.dbc(download)	-
7/07	rdsp0707.dbc(download)	-
8/07	rdsp0708.dbc(download)	-
9/07	rdsp0709.dbc(download)	-
10/07	rdsp0710.dbc(download)	-
11/07	rdsp0711.dbc(download)	-
12/07	rdsp0712.dbc(download)	-

Figura 19 - Arquivos para downloads para obter planilha DATASUS (próprio autor).

A planilha DATASUS possui 75 colunas das quais se observa as mais importantes (circuladas e enumeradas) para selecionar as internações: 1- ano da internação, 2- o mês e 3- o código do município (São José dos Campos-SP), Figura 20.

	A	1 B	2 C	D	E	F	G	H	3 I	J	K
1	UF_ZI	ANO_CMF	MES_CMF	ESPEC	CGC_HOS	N_AIH	IDENT	CEP	MUNIC_R	NASC	SEXO
2	354990	2007	01	03	77777002	350612687	1	12220000	354990	19880707	3
3	354990	2007	01	07	77777000	350710197	1	12220000	354990	19970520	3
4	354990	2007	02	03	46643466	35061293	1	12212020	354990	19200121	1
5	354990	2007	02	03	46643466	35061293	1	12249000	354990	19220720	1
6	354990	2007	02	03	77777000	350612687	1	12220000	354990	19800127	1
7	354990	2007	06	03	46643466	350711217	1	12223280	354990	19281109	3
8	354990	2007	07	03	77777000	35071121	1	12220330	354990	19401227	1
9	354990	2007	01	01	77777000	350710197	1	12220000	354990	19900508	1
10	354990	2007	01	07	77777000	35061293	1	12220000	354990	20061114	1
11	354990	2007	02	03	77777002	35061293	1	12220000	354990	19660407	1
12	354990	2007	02	03	46643466	35061293	1	12220280	354990	19580101	1
13	354990	2007	01	01	60194990	350710197	1	12225040	354990	20010904	3
14	354990	2007	01	03	77777002	350612687	1	12220000	354990	19300320	1
15	354990	2007	01	03	77777002	35061293	1	12220000	354990	19430611	1

Figura 20 - Planilha fornecida pelo DATASUS (próprio autor).

As colunas ainda foram selecionadas de acordo com: 4- a data de internação e 5- pelo CID 10 (J12-18 e J45) os quais são de pneumonia e asma, respectivamente, Figura 21.

	AI	AJ	AK	AI	AM	AN	AO	AP	AQ	AR	AS	AT	AU	AV	AW	AX
1	VAL_TOT	VAL_UTI	US_TOT	DT_INTE	DT_SAID	DIAG_PRI	DIAG_SE	COBRAN	NATURE	GESTAO	RUBRICA	IND_VDR	IND_M	COD_IDA	IDADE	DIAS_PEF
2	162,01	0	76,78	20070101	20070105	J36	E86	12	50	1	410010	0	354990	4		18
3	310	0	146,92	20070101	20070103	J450		12	50	1	410010	0	354990	4		9
4	319,74	0	156,74	20070101	20070105	J180		39	40	1	410010	0	354990	4		86
5	319,73	0	156,73	20070101	20070107	J180		53	40	1	410010	0	354990	4		84
6	319,74	0	156,74	20070101	20070108	J152		39	50	1	410010	0	354990	4		26
7	325,74	0	174,19	20070101	20070103	J181		12	40	1	410010	0	354990	4		78
8	319,74	0	163,13	20070101	20070602	J180		12	40	1	410010	0	354990	4		66
9	204,36	0	96,85	20070102	20070102	J350		12	50	1	410010	0	354990	4		16
10	201,88	0	95,68	20070102	20070109	J219		12	50	1	410010	0	354990	3		2
11	456,14	0	223,6	20070102	20070117	J188		12	50	1	410010	0	354990	4		40
12	319,74	0	156,74	20070102	20070104	J180		12	40	1	410010	0	354990	4		49
13	244,78	0	116,01	20070103	20070103	J353		12	61	1	410010	0	354990	4		5
14	319,74	0	151,54	20070103	20070105	J188		12	50	1	410010	0	354990	4		76
15	319,74	0	151,54	20070103	20070112	J188	E86	12	50	1	410010	0	354990	4		63

Figura 21 - Planilha obtida do DATASUS. (próprio autor).

Após selecionar: 6- data de internação, 7- CID 10 para pneumonia e asma, 8- foram contados os números de internações para pacientes com pneumonia e asma, dia a dia, referente ao ano de 2007, Figura 22. O número de internações foi colocado na sexta coluna da planilha final. Este procedimento foi realizado para cada dia do ano, onde pode ser visto que no dia primeiro de janeiro de 2007 ocorreram 6 internações, no dia dois de janeiro ocorreram duas internações e assim sucessivamente.

	A	B	C
1	20070101	J152	6
2	20070101	J180	
3	20070101	J180	
4	20070101	J180	
5	20070101	J181	
6	20070101	J450	
7	20070102	J180	2
8	20070102	J188	
9	20070103	J188	3
10	20070103	J188	
11	20070103	J188	
12	20070104	J180	5
13	20070104	J188	
14	20070104	J188	
15	20070104	J188	
16	20070104	J188	

Figura 22 - Planilha para gerar número de internações (próprio autor).

Por fim, foi obtido o banco de dados final que será utilizado para realizar este trabalho.

A planilha é composta pelos seguintes dados de entrada: 1- Material particulado (MP₁₀); 2- Ozônio (O₃); 3- Dióxido de enxofre (SO₂); 4-Temperatura aparente (Tap); e 5- como saída o número de internações por doenças respiratórias (pneumonia e asma) na cidade de São José dos Campos.

Este banco de dados foi composto de 345 dados (ano de 2007) e foi elaborado com o auxílio do programa Excel, conforme apresentado na Figura 23.

	1	2	3	4	5
	A	B	C	D	E
1	8	43	1.0	17.21	6
2	11	47	0.9	18.39	2
3	11	42	0.9	19.11	3
4	17	40	1.1	18.88	0
5	20	49	1.0	19.53	1
6	19	93	1.0	19.47	3
7	13	103	1.0	18.83	3
8	23	119	2.0	17.93	3
9	18	111	2.0	16.37	4
10	27	94	2.0	17.52	4
11	17	31	2.0	19.57	1
12	21	68	2.0	18.05	0
13	15	53	1.0	17.73	3
14	20	96	4.0	15.04	1
15	18	60	2.0	17.70	2
16	24	30	1.0	18.94	2
17	23	54	2.0	18.37	3
18	29	119	2.0	19.51	6
19	17	48	1.0	18.38	0
20	10	106	3.0	16.94	1

Figura 23 - Planilha desenvolvida no programa Excel (próprio autor).

Esta planilha foi utilizada duas vezes neste trabalho: primeiro foi utilizada para validar o modelo *fuzzy* (Mamdani) elaborado no *toolbox fuzzy* do Matlab. O Matlab possui uma rotina (*ddeinit*) que permite gerar uma saída numérica para o modelo *fuzzy* elaborado. Com esta rotina é possível comparar os valores obtidos do banco de dados real com os resultados obtidos do modelo; desta forma, é possível avaliar o SIF *fuzzy* Mamdani realizando a correlação entre os dados obtidos no banco de dados real e os dados obtidos no modelo *fuzzy*. Quanto maior a correlação, melhor a acurácia do modelo *fuzzy* elaborado.

Na segunda, a planilha foi utilizada para realizar o treinamento do sistema neuro-*fuzzy* ANFIS. Este treinamento foi realizado utilizando o *toolbox neuro-fuzzy* do Matlab. Para isso, a planilha foi dividida em duas partes: a metade dos dados foi utilizada para elaborar o treinamento do sistema e a segunda metade dos dados foi utilizada para realizar o teste (25% dos dados) e a validação dos dados treinados (25% dados) do modelo.

O sistema neuro-*fuzzy* ANFIS gera automaticamente o SIF *fuzzy* Sugeno. Posteriormente, este SIF foi comparado com o SIF *fuzzy* Mamdani elaborado anteriormente.

A seguir, será apresentado os modelos elaborados.

7.1 Modelo Fuzzy

A seguir, são apresentados os dados de entrada e saída utilizados para elaborar o modelo *fuzzy*. A proposta é apresentar um método que permita estimar os números de internações por pneumonia e asma utilizando o sistema de inferência *fuzzy* do tipo Mamdani.

As variáveis de entrada para o modelo *fuzzy* são: material particulado (MP_{10}), ozônio (O_3), dióxido de enxofre (SO_2), temperatura (Tap). O universo de discurso para cada variável de entrada foi selecionado da planilha (vide Figura 23).

A Tabela 3 apresenta a classificação das variáveis de entrada obtida na base de dados com valor mínimo e máximo (universo de discurso):

Tabela 3 - Dados de entradas e suas respectivas variações

Variável de entrada	Variação
MP_{10} ($\mu\text{g}/\text{m}^3$)	8,0 - 68,0
O_3 ($\mu\text{g}/\text{m}^3$)	17,0 - 209,0
SO_2 ($\mu\text{g}/\text{m}^3$)	0,9 - 27,0
Tap ($^{\circ}\text{C}$)	5,7 - 20,2

O modelo foi desenvolvido usando o método de inferência proposta por Mamdani, Figura 24; e foi implementado usando o *software* computacional do *toolbox fuzzy* Matlab 7.1.

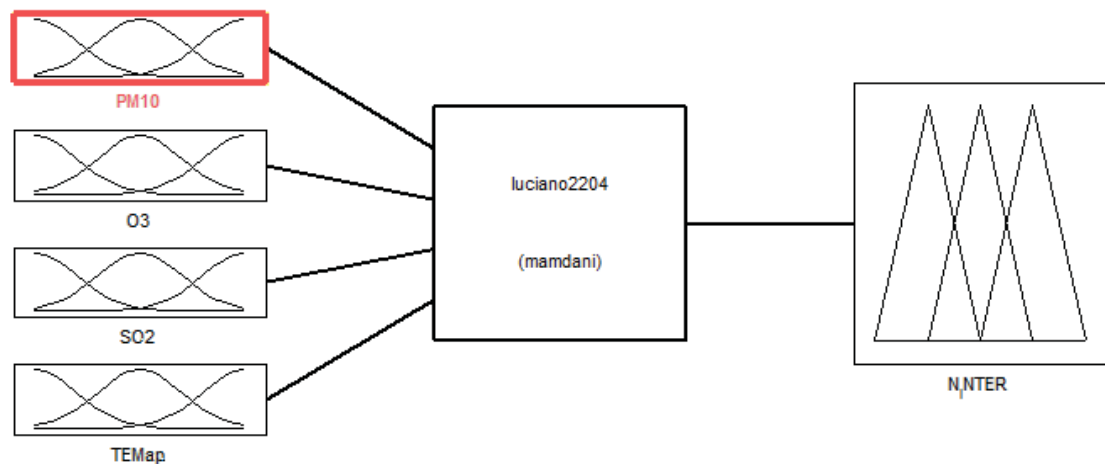


Figura 24 - Sistema de inferência *fuzzy* Mamdani com quatro entradas e uma saída (próprio autor).

A variável de saída representa o número de internações de pacientes com as doenças respiratórias pneumonia e asma, essa variável de saída apresenta uma variação de zero a 16 pacientes, apresentadas na Tabela 4. Na lógica *fuzzy* é possível trabalhar com variáveis lingüísticas. Neste trabalho foi realizada a seguinte classificação para a saída: muito baixo, baixo, médio, alto e muito alto.

Tabela 4 - Classificação da variável de saída

Intervalo	Classificação
[0; 1]	Muito baixo
[2; 4]	Baixo
[5; 7]	Médio
[8; 10]	Alto
[11; 16]	Muito alto

A saída representa a variável número de internações sendo fornecida com cinco funções de pertinência, Figura 25: muito baixo, baixo, médio, alto, muito alto.

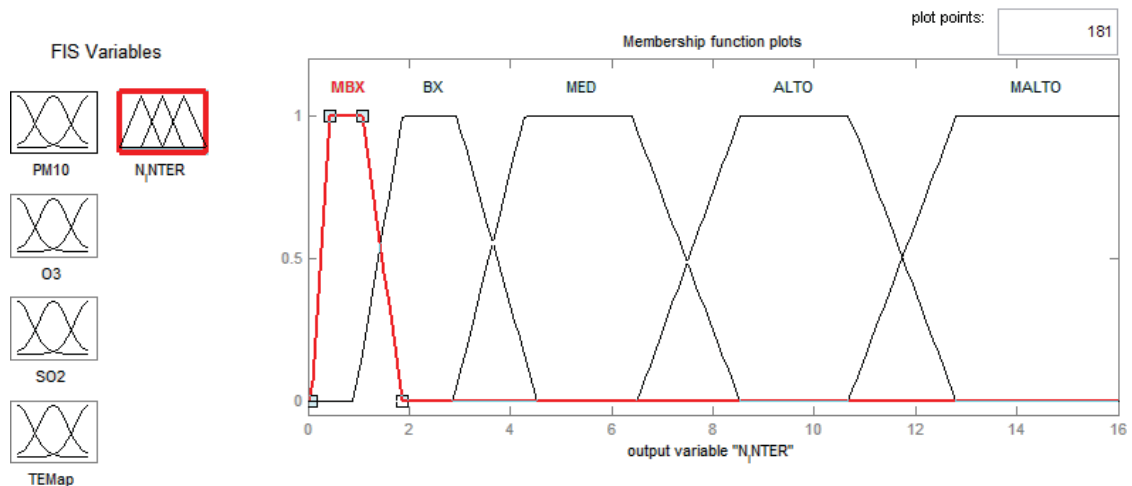


Figura 25 - Número de internações (MBX: muito baixo, BX: baixo, MED: médio, alto e MALTO: muito alto (próprio autor).

Segundo Caldeira *et.al.* (2007), a função de pertinência é bastante subjetiva. Quando uma função é especificada para um mesmo conceito, esta pode apresentar resultados variados quando definida por especialistas diferentes. A função de pertinência define o quanto um elemento pertence a um conjunto e também representa os limites de cada um destes conjuntos *fuzzy*. As funções de pertinência mais utilizadas são as triangulares e as trapezoidais. Neste trabalho foi realizado com as funções de pertinência do tipo trapezoidal.

A classificação de cada variável de entrada foi feita com base nos valores máximos e mínimos dos dados. Cada universo de discurso possui duas funções de pertinência do tipo trapezoidal e suas variações realizadas no primeiro quartil.

7.1.1 Material Particulado (MP₁₀)

Tabela 5 - Classificação quanto ao nível de material particulado no ambiente

Intervalo	Classificação
[8,22]	BOA
[23,68]	REGULAR

O modelo foi desenvolvido da opinião um especialista que elaborou as seguintes funções de pertinência:

Dois funções de pertinência *fuzzy* para a variável MP₁₀, Figura 26: boa e regular.

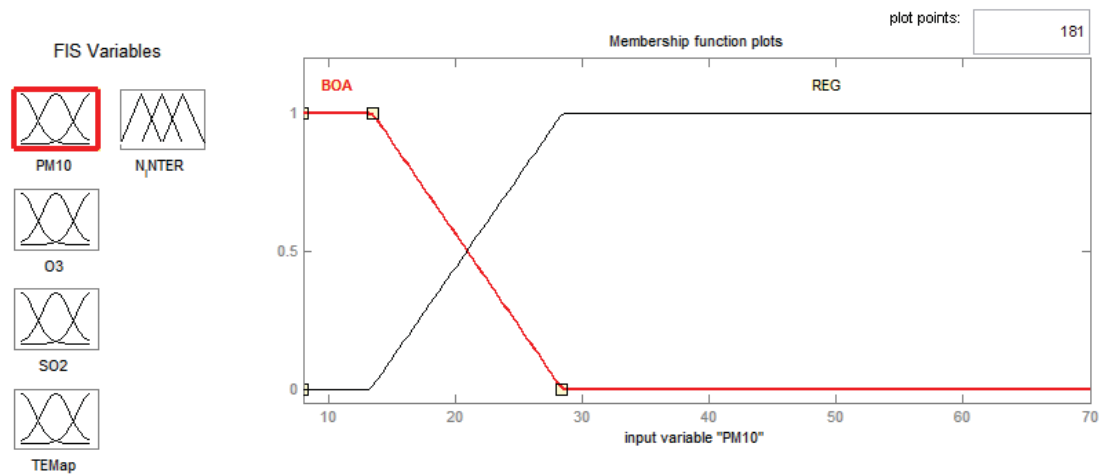


Figura 26 - Conjunto *fuzzy* para MP₁₀ (µg/m³) (BOA e REG: regular) (próprio autor).

Observa-se que o universo de discurso varia de 8 a 68 µg/m³ (valor mínimo e máximo, Tabela 3, página 68) e a transição das funções em torno de 22 µg/m³ (valor de transição do MP₁₀ prejudicial à saúde, Tabela 5).

7.1.2 Ozônio (O₃)

Tabela 6 - Classificação quanto ao nível de ozônio

Intervalo	Classificação
[17, 99]	BOA
[100, 209]	INADEQUADO

Dois funções de pertinência *fuzzy* são definidas para variável O₃ conforme apresentado na Figura 27: boa e inadequado.

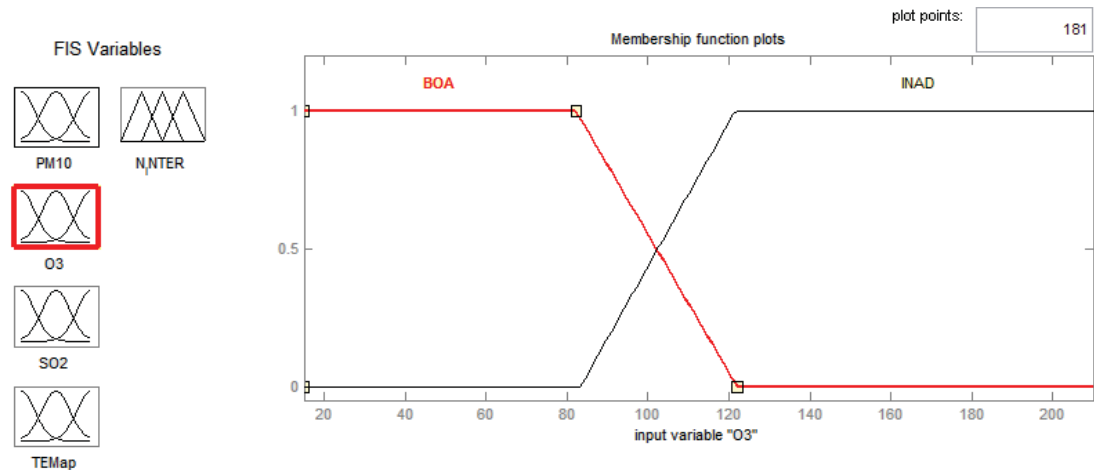


Figura 27 - Conjunto *fuzzy* para O_3 ($\mu\text{g}/\text{m}^3$) (BOA E INAD: inadequado) (próprio autor).

Observa-se que o universo de discurso varia de 17 a 209 $\mu\text{g}/\text{m}^3$ (valor mínimo e máximo, Tabela 3, página 68) e a transição das funções em torno de 100 $\mu\text{g}/\text{m}^3$ (valor de transição do O_3 prejudicial à saúde, Tabela 6).

7.1.3 Dióxido de Enxofre (SO_2)

Tabela 7 - Classificação quanto ao nível de dióxido de enxofre

Intervalo	Classificação
[0,9; 2,5]	BOA
[2,6; 27]	INADEQUADO

Duas funções de pertinência *fuzzy* para a variável SO_2 , Figura 28: boa e inadequado.

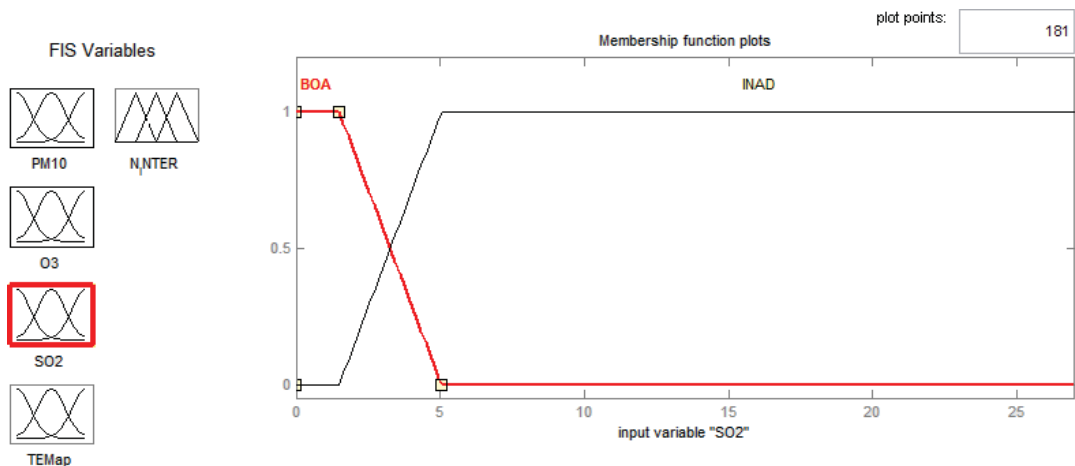


Figura 28 - Conjunto *fuzzy* para SO_2 ($\mu\text{g}/\text{m}^3$) (BOA E INAD: inadequado) (próprio autor).

Nota-se que o universo de discurso varia de 0,9 a 27 $\mu\text{g}/\text{m}^3$ (valor mínimo e máximo, Tabela 3, página 68) e a transição das funções em torno de 2,5 $\mu\text{g}/\text{m}^3$ (valor de transição do SO_2 prejudicial à saúde, Tabela 7).

7.1.4 Temperatura Aparente (Tap)

Tabela 8 - Classificação quanto à temperatura aparente

Intervalo	Classificação
[5,7; 17]	INADEQUADA
[18; 20,2]	BOA

Duas funções de pertinência *fuzzy* para a variável Tap, Figura 29: inadequada e boa.




Figura 29 - Conjunto *fuzzy* para Tap (INAD: inadequada e BOA) (próprio autor).

Nota-se que o universo de discurso varia de 5,7 a 20,2 °C (valor mínimo e máximo, Tabela 3, página 68) e a transição das funções em torno de 18 °C (valor de transição do Tap prejudicial à saúde, Tabela 8).

Base de regras *fuzzy*

Na Tabela 9 são apresentadas as 16 regras (2^4 – duas funções de pertinência para as quatro entradas).

Tabela 9- Regras geradas por especialista para o modelo *fuzzy*

Regras	MP ₁₀	O ₃	SO ₂	Tap	N° INT	Peso
1	BOA	BOA	BOA	BOA	MBX	1
2	BOA	BOA	BOA	INAD	BX	1
3	BOA	BOA	INAD	BOA	BX	1
4	BOA	BOA	INAD	INAD	MED	1
5	BOA	INAD	BOA	BOA	BX	1
6	BOA	INAD	BOA	INAD	MED	1

7	BOA	INAD	INAD	BOA	MED	1
8	BOA	INAD	INAD	INAD	ALTO	1
9	REG	BOA	BOA	BOA	BX	1
10	REG	BOA	BOA	INAD	ALTO	1
11	REG	BOA	INAD	BOA	MED	1
12	REG	BOA	INAD	INAD	MALTO	1
13	REG	INAD	BOA	BOA	ALTO	1
14	REG	INAD	BOA	INAD	MALTO	1
15	REG	INAD	INAD	BOA	ALTO	1
16	REG	INAD	INAD	INAD	MALTO	1

Ao se combinarem todas as possíveis entradas, construindo 16 regras, foi possível observar que todas são plausíveis e por isso todas as regras possuem peso um.

A Figura 30 apresenta a base de regras editada no *toolbox fuzzy* do Matlab.

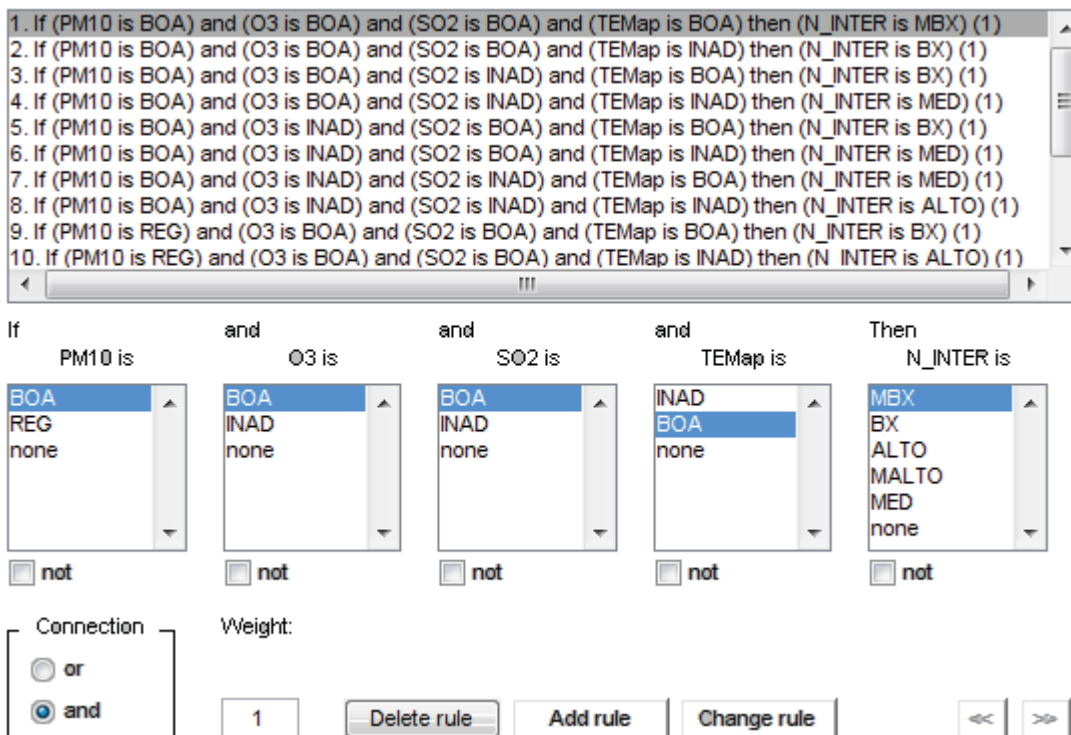


Figura 30 - Regras *fuzzy* editadas no programa Matlab (próprio autor).

Rule viewer do toolbox Matlab

A Figura 31 apresenta a janela do *rule viewer* do *toolbox* do Matlab, a partir desta pode-se observar que com média concentração de poluentes, boa temperatura aparente, tem-se um número médio, aproximado seis de interações.

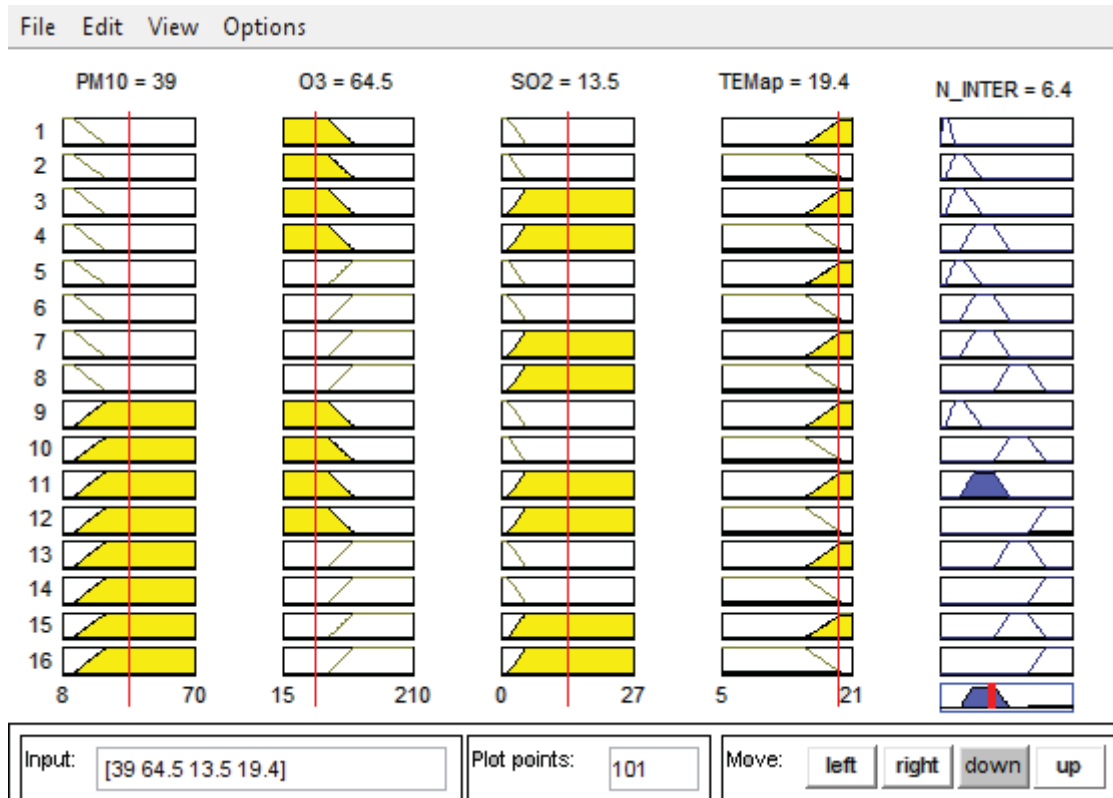


Figura 31 - Janela *rule viewer* gerada pelo matlab (próprio autor).

O *rule viewer* é utilizado para validar o modelo, pois apresenta o resultado do mesmo.

Outra forma de validar o modelo é por meio da rotina *ddeinit* (ANEXO D), desta forma, pode-se comparar o resultado real com o obtido pelo modelo.

Esta rotina gera todos os resultados dados pelo modelo a partir dos dados de entrada. Desta forma, pode-se validar o modelo *fuzzy*.

A acurácia do modelo *fuzzy* foi estudada pela área sob a Curva ROC. Neste trabalho consideraram-se defasagens (lags) de até dois dias, tendo em vista, que os efeitos de exposição aos poluentes podem se manifestar no mesmo dia da exposição ou nos dias subsequentes.

As saídas geradas pelo modelo foram comparadas e correlacionadas com os dados reais de interação utilizando o coeficiente de correlação de Pearson ($p > 0,01$).

7.2 Modelo Neuro-fuzzy

A seguir, é apresentado o modelo obtido por meio do sistema neuro-fuzzy ANFIS.

Para a construção do modelo neuro-fuzzy, como ferramenta para implementação será usado o programa computacional Matlab no módulo denominado Toolbox ANFIS, que consiste em uma implementação do método proposto por Roger Jang (JANG, 1993).

Para criar o conjunto de treinamento do sistema ANFIS foram utilizados os dados reais diários referentes às concentrações dos poluentes: material particulado (MP_{10}), ozônio (O_3) e dióxido de enxofre (SO_2) e da variável climática: temperatura aparente (T_{ap}) para as entradas. Os dados diários das internações por pneumonia e asma, para a saída, são referente ao período de 01 de janeiro a 31 de dezembro de 2007. Estes dados foram fornecidos pelo Departamento de Informações e informática do Sistema Único de Saúde (DATASUS) obtido do portal DATASUS. Vide planilha na Figura 23, página 66.

Os dados foram divididos da seguinte forma: 50% para realizar o treinamento do sistema, 25% para testar e 25% para validar o modelo neuro-fuzzy. Estes dados foram selecionados aleatoriamente.

As saídas geradas pelo modelo neuro-fuzzy foram correlacionadas com os dados reais de internações utilizando o coeficiente de Pearson ($p > 0,01$)

A seguir, será apresentado como funciona o *toolbox* ANFIS do Matlab.

7.2.1 ANFIS: *Toolbox* do Matlab

O *toolbox* ANFIS do Matlab é obtido por meio do comando *anfisedit*. A Figura 32, a seguir, exibe a tela inicial do *toolbox* ANFIS. Os principais comandos estão em destaque, circulos e enumerados de um a seis. Em seguida será comentado o que cada comando realiza ao ser acionado (MATLAB, 2012).

1 - **Load Data** - Carrega os dados do modelo. Devem-se inserir os dados de treinamento (*Training*), dados de teste (*Testing*), e dados de verificação (*Checking*). É disponibilizado um conjunto de dados de demonstração (*Demo*) para fins didáticos. Os dados podem ser importados direto do disco rígido (*disk*) ou da área de trabalho do Matlab (*work*).

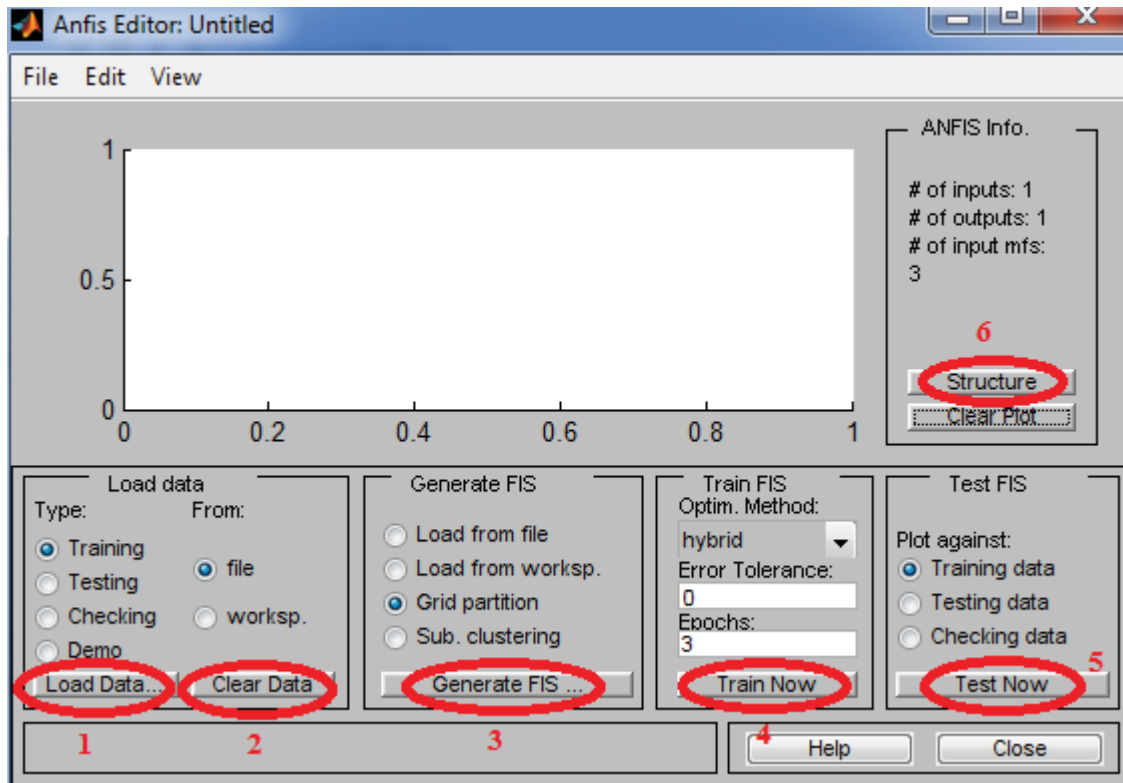


Figura 32 - Janela inicial do ANFIS (próprio autor).

A Figura 33, mostra como carregar a tabela de dados para treinamento com colunas de entrada e saída, respectivamente.

Import	Name ▲	Size	1	2	3	4	5	
<input checked="" type="checkbox"/>	Treino	187x5	1	8	43	1	17.2146	6
			2	11	47	0.9410	18.3867	2
			3	11	42	0.8594	19.1096	3
			4	17	40	1.1486	18.8754	0
			5	20	49	1	19.5287	1
			6	19	93	1	19.4736	3
			7	13	103	1	18.8330	3
			8	23	119	2	17.9325	3
			9	18	111	2	16.3735	4
			10	27	94	2	17.5176	4
			11	17	31	2	19.5726	1
			12	21	68	2	18.0464	0

Figura 33 - Conjunto de dados para treinamento (próprio autor).

As quatro primeiras colunas estão relacionadas com os dados de entradas do modelo e a quinta coluna com os dados da saída.

Janela com os dados que foram treinados são apresentados na Figura 34.

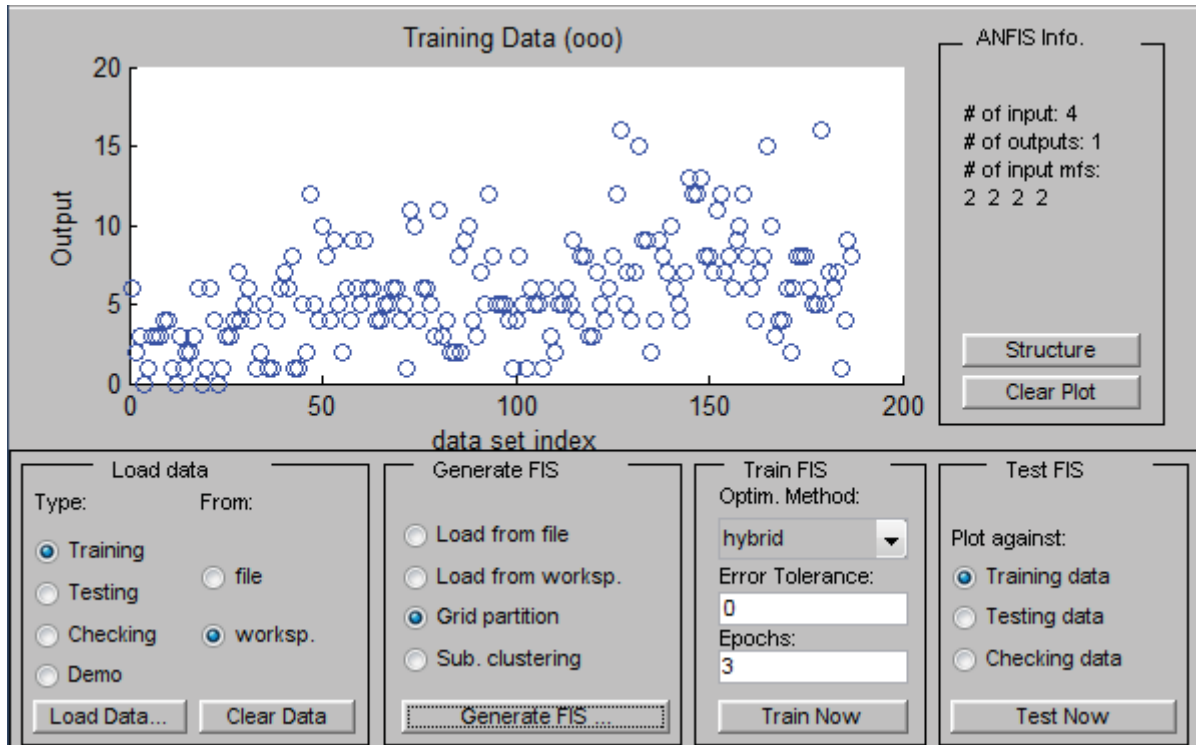


Figura34 - Dados a serem treinados (janela ANFIS) (próprio autor).

2 - **Clear Data** – Este comando apaga os dados carregados. Os subconjuntos para o ANFIS serão constituídos da seguinte forma em percentual do total de dados: 50% para o conjunto de treinamento, 25% para o conjunto de teste e 25% para o conjunto de verificação.

3 - **Generate FIS** - Este comando cria ou importa o sistema de inferência *fuzzy* (.fis), onde são configuradas as funções de pertinência com relação ao número de funções, ao tipo e característica da função de saída constante ou linear, como pode ser visto na Figura 35.

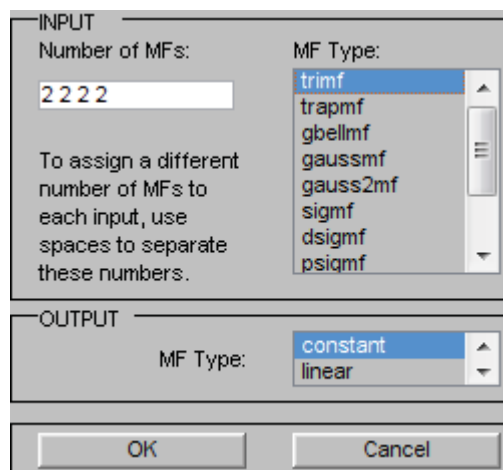


Figura 35 – Geração do FIS, janela do *toolbox* para gerar funções de pertinência (próprio autor).

Nesse trabalho foi escolhido o método *Grid Partition*, com duas funções de pertinência para a primeira variável MP_{10} , duas funções de pertinência para a segunda variável O_3 , duas funções de pertinência para a terceira variável SO_2 , duas funções de pertinência para a quarta variável (Tap); e a variável de saída, número de internações por pneumonia e asma (constante).

Os valores dos números das funções de pertinências vão variando de acordo com o treinamento e verificação para o menor erro do modelo. A tabela apresentado no ANEXO E mostra todas as simulações realizadas neste trabalho.

4 - **Train Now** - Neste item, são definidos os parâmetros de treinamento: tolerância a erro (*Error Tolerance*), número de épocas (*Epochs*) e algoritmo de treinamento híbrido ou *back-propagation* (*Optim. Method*), Figura 36.




Figura 36 – Treinamento FIS (próprio autor).

Como parâmetro para o treinamento, foi escolhido o método de treinamento híbrido, que consiste pela combinação do método de *back-propagation* e o dos mínimos quadrados, sendo o primeiro associado às estimativas dos parâmetros das funções de pertinência de entrada, e o segundo, associado às estimativas dos parâmetros de saída das funções de pertinência.

Outros parâmetros que foram usados são: tolerância de erro mais próximo a zero e o número inicial de épocas igual a 30. O número de épocas pode aumentar ou diminuir de acordo com o sistema a ser implementado. Lembrando que sempre se deve tomar cuidado com o supertreinamento (*Overfitting*).

5 - **Test Now** - A base de dados é colocado a prova com a saída do sistema que foi treinado, Figura 37. Na janela de teste é apresentado o erro apresentado pelo modelo e as saídas reais e a gerada pelo modelo.

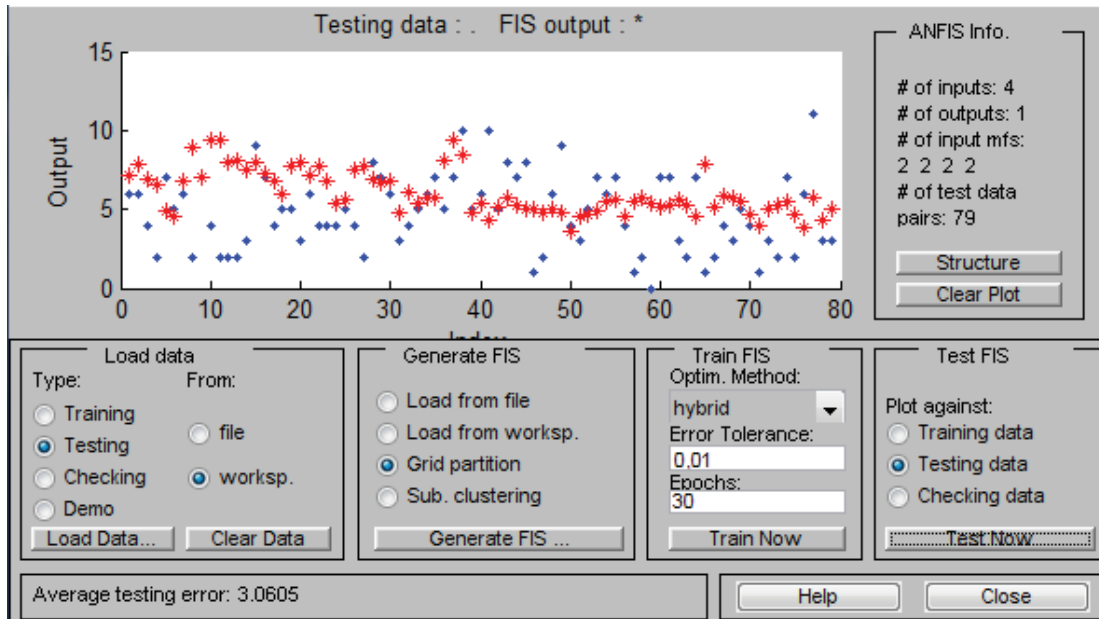


Figura 37 - Testando agora (*test now*) janela *toolbox* ANFIS para teste do sistema (próprio autor).

A Figura 38 apresenta quão próximo ou distante o sistema está do resultado e também apresenta o erro obtido pelo modelo (2.691).

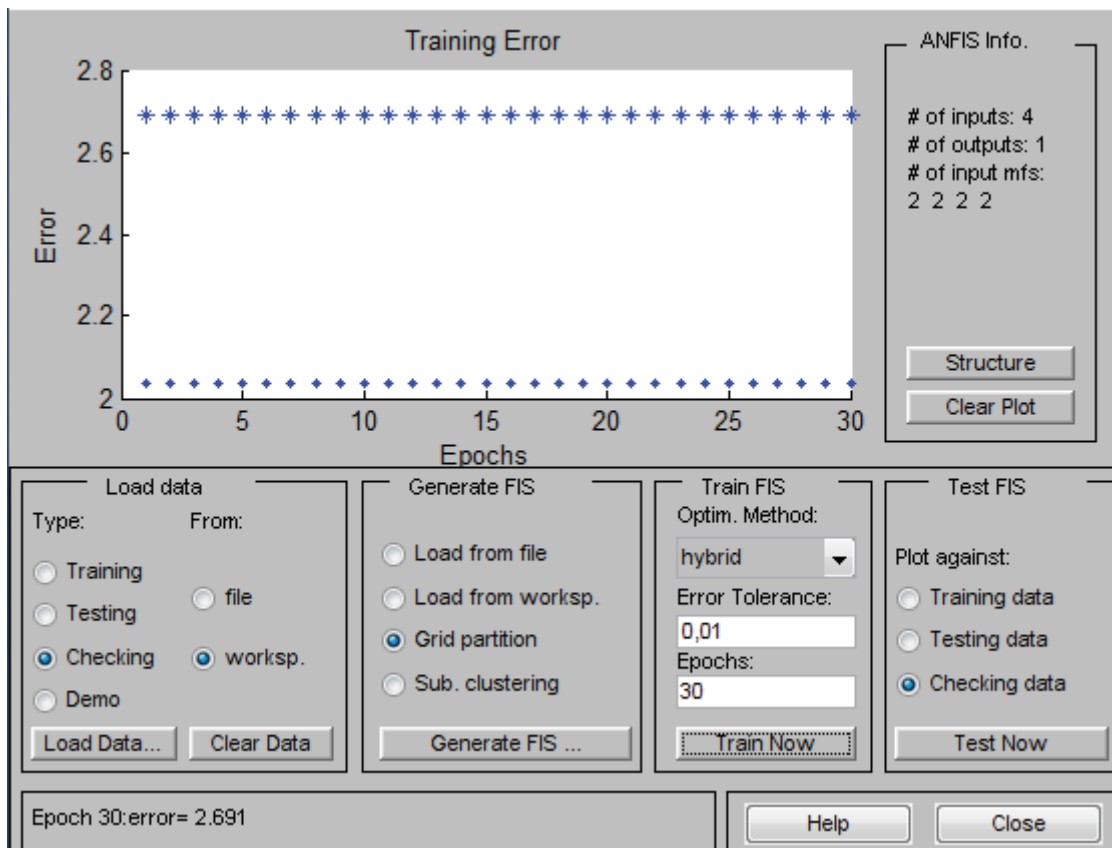


Figura 38 – Janela de treinamento (próprio autor).

O próximo passo será inserir os dados para checagem (check) do modelo, Figura 39.

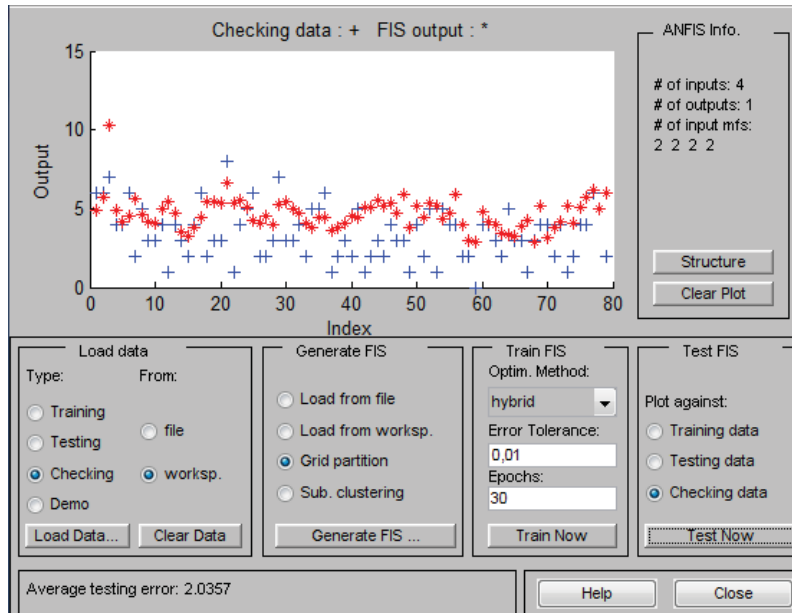


Figura 39 – Checagem (próprio autor).

A ferramenta de checagem pode-se verificar mais uma vez se o modelo gerado pelo ANFIS está bom, ou seja, apresentando um erro baixo e nenhum dado incoerente.

6 - **Structure** – Nesta janela é possível visualizar a arquitetura da rede gerada pelo ANFIS, Figura 40.

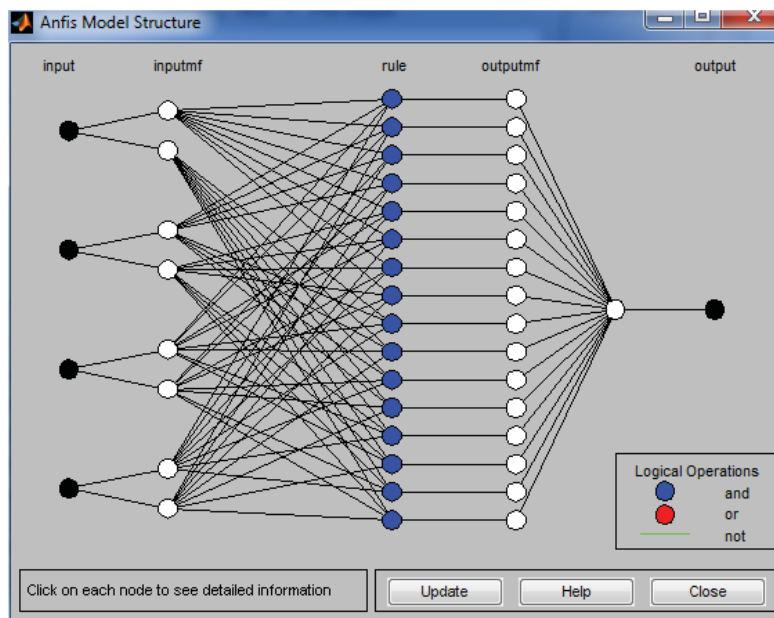


Figura 40 – Estrutura ANFIS (Próprio Autor).

Este sistema possui quatro entradas, a camada um apresenta duas funções de pertinência para cada uma das entradas; na camada três tem-se a agregação das 16 regras (4^2); e por último, uma saída.

8 RESULTADOS E DISCUSSÃO

Este é o primeiro estudo a ser realizado em uma cidade de médio porte como São José dos Campos e no estado de São Paulo a utilizar a técnica de modelagem *fuzzy* e *neuro-fuzzy* para previsão do número de internações por algumas doenças respiratórias (pneumonia e asma) com relação à exposição aos poluentes do ar.

Trata-se da construção de um modelo computacional, utilizando-se das ferramentas da lógica *fuzzy*, para estimar o número de internações por asma e pneumonia relacionadas aos poluentes do ar.

Os dados reais diários de internações por asma e pneumonia, foram considerados como variável de saída dos modelos; e durante o período de estudo foi registrado o total de 1710 (correspondendo a 6,6% de todas as internações) internações na cidade de São José dos Campos.

Os valores mínimos e máximos dos poluentes, temperatura aparente e número de internações foram utilizados como universo de discurso para a elaboração do modelo *fuzzy*.

A análise descritiva das variáveis consideradas neste estudo encontra-se na Tabela 10..

Tabela 10 - Valores das médias, desvio padrão, mínimos e máximos das variáveis: material particulado (MP₁₀), ozônio (O₃), dióxido de enxofre (SO₂), temperatura aparente (Tap), segundo tipo de saída número de internações (NINTER), São José dos Campos-2007.

	Média	dp	Mínimo	Máximo
MP ₁₀ (µg/m ³)	16,0	11,3	8,0	68,0
O ₃ (µg/m ³)	91,0	67,9	17,0	209,0
SO ₂ (µg/m ³)	3,8	3,3	0,9	27,0
Tap (°C)	17,9	0,9	5,7	20,2
NINTER	4,9	2,9	0,0	16,0

O número de internações variou entre zero e 16 internações por dia, com média de 4,9 internações e desvio padrão de 2,9.

O valor médio da concentração MP₁₀ ficou em 16 µg/m³ apresentando nível máximo em 68 µg/m³, nível bem menor do que o padrão de qualidade do ar preconizado pelo CONAMA, que é de 150 µg/m³. Porém, segundo a CETESB (2012) que descreve sobre a qualidade do ar e efeito à saúde, índices entre 51 e 100 µg/m³ de material particulado é classificado como

regular e pode causar sintomas como tosse seca e cansaço em indivíduos com doenças respiratórias.

Segundo estudo realizado por Arbex (2004), o material particulado pode levar a irritação das vias aéreas, inflamação, aumento da reatividade brônquica, diminuição da atividade muco ciliar e tendo como conseqüências aumento nas crises asmáticas e das infecções respiratórias.

Em pesquisa realizada por Gouveia (2006) na cidade de São Paulo-SP, observou-se que com o aumento em $10 \mu\text{g}/\text{m}^3$ na concentração do material particulado gerou-se um aumento de aproximadamente 5% no número de internações por asma em crianças. Da mesma forma Nascimento et. al (2006), observaram a associação entre a concentração de poluentes do ar e o aumento na morbidade em crianças por problemas respiratórios na cidade de São José dos Campos - SP.

A concentração média do O_3 ficou em $91 \mu\text{g}/\text{m}^3$ e a máxima de $209 \mu\text{g}/\text{m}^3$ durante o período de 2007, esse valor ficou muito próximo ao valor encontrado no estudo de Amâncio (2012) com uma média de $74,3 \mu\text{g}/\text{m}^3$. O O_3 ultrapassou por 12 dias os valores de níveis aceitáveis pelo CONAMA que é de $160 \mu\text{g}/\text{m}^3$. No relatório da CETESB (2012), os níveis valores inadequados do O_3 situado entre $180\text{-}200 \mu\text{g}/\text{m}^3$ e pode causar em crianças com doença respiratória agravos aos sintomas da asma e na população em geral sintomas como ardor no nariz, garganta e olhos bem como tosse seca e cansaço. O O_3 teve um crescimento significativo no último ano no município de São José dos Campos conforme último relatório da CETESB (2012).

Na cidade de São Paulo-SP, as internações hospitalares diárias em crianças por sintomas respiratórios aumentaram em 5% e especificamente por pneumonias foram acrescidas em 8% para aumento dos níveis de O_3 (GOUVEIA, 2000).

Para o SO_2 a concentração máxima foi de $27 \mu\text{g}/\text{m}^3$ e apresentou uma média de em $3,8 \mu\text{g}/\text{m}^3$, valor que não difere muito do que encontrado em pesquisa realizado na mesma cidade com dados coletados entre 2004 e 2005 (AMÂNCIO, 2012).

As concentrações médias encontradas no presente estudo estão dentro dos valores toleráveis pela OMS, que aceita nível de exposição máxima de até $20 \mu\text{g}/\text{m}^3$ durante 24 horas.

Em pesquisa conduzida no município de São Paulo, encontrou-se uma média de SO_2 de $17,71 \mu\text{g}/\text{m}^3$, o que difere do valor encontrado nesse estudo (GOUVEIA, 2006). Essa diferença pode ser explicada pela maior emissão desse poluente em São Paulo, devido à maior frota de veículos, uma das principais fontes desse poluente.

Mesmo em concentrações consideradas seguras pelos principais órgãos controladores, os poluentes podem causar efeitos adversos à saúde humana, principalmente sobre os sistemas cardiovasculares e respiratórios.

Modelo *Fuzzy*

O modelo *fuzzy* baseado no processo de inferência de Mamdani foi desenvolvido utilizando duas funções de pertinência para cada uma das entradas material particulado (MP_{10}), ozônio (O_3), dióxido de enxofre (SO_2) e temperatura aparente (Tap) e cinco funções de pertinência para a saída número de internações (NINTER), sendo gerada a seguinte estrutura apresentada na Figura 41.

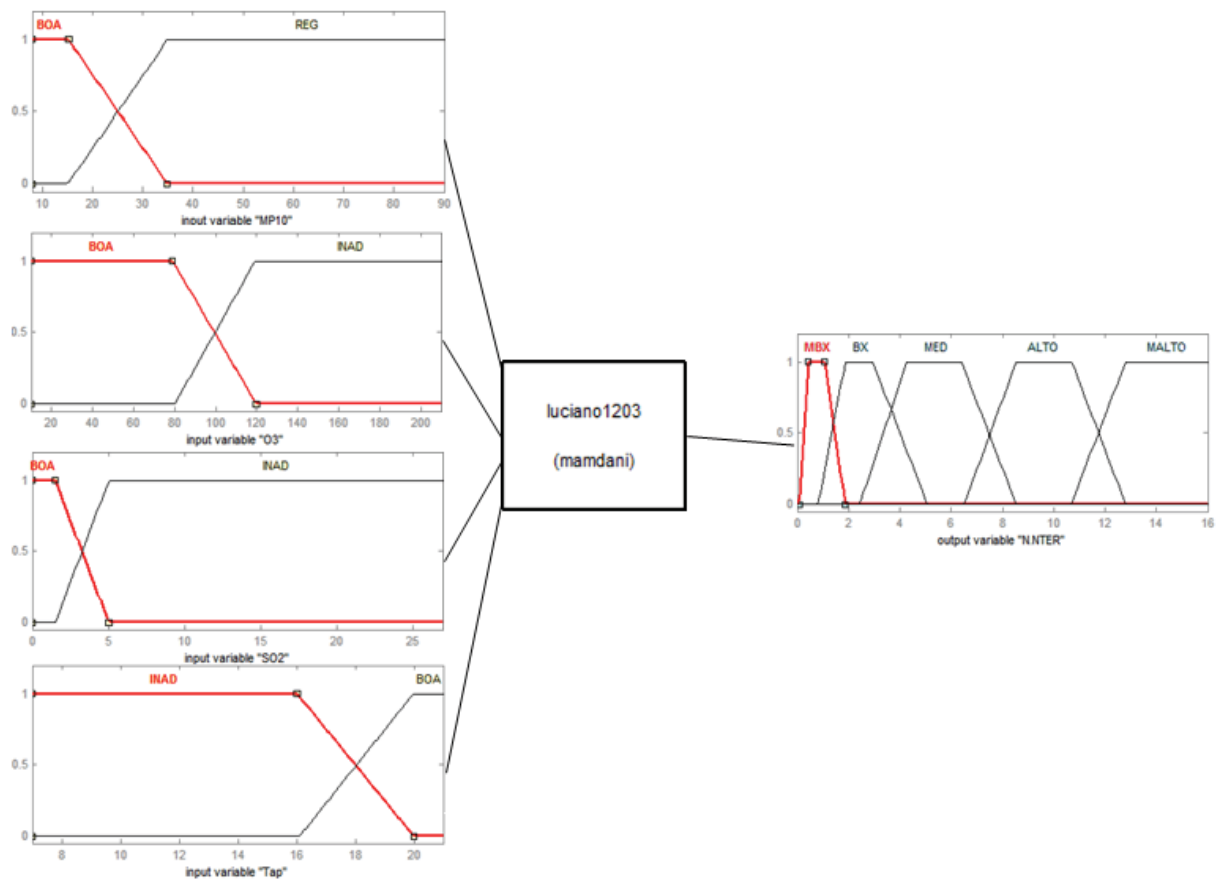


Figura 41: Estrutura do modelo *fuzzy* Mamdani (Próprio Autor).

Para realizar a comparação da saída do modelo *fuzzy* proposto com a saída real, foi realizada uma rotina (ddeinit), que gera uma saída numérica para o modelo *fuzzy*. Gerada a saída pode-se então, realizar a correlação entre o modelo e os dados reais de saída.

Os coeficientes de correlação de *Pearson* foram significantes entre os valores reais e preditos $r = 0,38$ ($p < 0,01$). O modelo *fuzzy* mostrou um nível satisfatório ao relacionar poluentes e o número de internações quando comparado com as saídas reais; este valor pode indicar um modelo adequado ao número reduzido de dados, apenas um ano.

Um valor ótimo para correlação seria próximo de 1,00. Porém para a área biológica este valor é dificilmente alcançado e considera-se bom um valor próximo de 0,60 (FARAWAY, apud TADANO, 2012).

Segundo Tadano (2012) pode-se ainda supor que para o caso específico de estudos do efeito dos poluentes do ar sobre a saúde, o valor da correlação excelente não atinja 0,60.

Devido à falta de estudos nesta área com modelos *fuzzy*, não é possível realizar comparações e obter uma conclusão mais precisa.

A área sob a Curva ROC foi significativa ($p < 0,05$) para o lag 0, lag 1 e lag 2 e estão mostradas na Tabela 11, a seguir.

Tabela 11 - Valores para Curva ROC para Lag 0, Lag 1 e Lag 2 dos poluentes MP₁₀, O₃ e SO₂.


	Lag 0	Lag 1	Lag 2
MP ₁₀	0,92 (0,88-0,96)	0,75(0,64-0,85)	0,73(0,60-0,81)
O ₃	0,87 (0,82-0,92)	0,64 (0,52-0,76)	0,62(0,51-0,73)
SO ₂	0,95 (0,92-0,97)	0,73 (0,63-0,82)	0,79 (0,72-0,87)

Em estudos epidemiológicos é comum encontrar uma relação entre níveis de poluentes do ar de um dia com os efeitos na saúde do dia seguinte, de dois dias depois ou até mesmo após uma semana. Geralmente os pesquisadores ajustam o modelo para diferentes arranjos do mesmo banco de dados com defasagens (lags). Em estudos de séries temporais, defasagens de um a sete dias são aplicadas com certa frequência (BAKONYI, 2004; MARTINS, 2004).


Na análise das defasagens, verifica-se um efeito sempre positivo que se torna estatisticamente significativo nos lag 0, 1 e 2; demonstrando o efeito agudo que os níveis de poluentes têm sobre a saúde dos expostos.

As Figuras 42, 43 e 44 mostram as Curvas ROC para os poluentes MP₁₀, O₃ e SO₂ respectivamente; e para lags 0 (A), 1 (B) e 2 (C).

A) 0,92 (0,88-0,96)



B) 0,75 (0,64-0,85)



C) 0,71(0,60-0,81)






Figura 42- Gráficos da Curva ROC para MP_{10} : A) Lag 0, B) Lag 1 e C) Lag 2 (Próprio Autor).

A) 0,87 (0,82-0,92)



B) 0,64 (0,52-0,76)



C) 0,62(0,51-0,73)






Figura 43- Gráficos da Curva ROC para O₃: A) Lag 0, B) Lag 1 e C)Lag 2(Próprio Autor).

A) 0,95 (0,92-0,97)



B) 0,73 (0,63-0,82)



C) 0,79 (0,72-0,87)




Figura 44- Gráficos da Curva ROC para SO₂: A) Lag 0, B) Lag 1 e C) Lag 2(Próprio Autor).

O *rule viewer* também pode ser utilizado para validar o modelo, pois apresenta o resultado do mesmo como pode ser observado a seguir. Podem-se variar as entradas e, em seguida, observar o sistema de reajustar e calcular a nova saída.

Em algumas situações particulares, como no caso demonstrado na Figura 45, considerando a variável MP_{10} de $55\mu\text{g}/\text{m}^3$, O_3 de $112\mu\text{g}/\text{m}^3$, SO_2 de $8\mu\text{g}/\text{m}^3$ e a Tap de 11°C ; o modelo previu 13,8 de interações. Para as mesmas variáveis o número de interações reais foi de 12.




Figura45: Tela de regras capturada do Matlab (Próprio Autor)

Já com o MP_{10} de $8\mu\text{g}/\text{m}^3$, O_3 de $34\mu\text{g}/\text{m}^3$, SO_2 de $1\mu\text{g}/\text{m}^3$ e a Tap de $11,6^\circ\text{C}$, o número de interações foi 2,7 e para o número de interações reais de 3, Figura 46.




Figura46: Tela capturada do Matlab com algumas regras (Próprio Autor).

O *software* Matlab também fornece, baseado no modelo *fuzzy* proposto, gráficos de superfície nos 3 eixos, sendo o eixo z representando a variável de saída número de interações e os eixos x, y representando as variáveis de entrada: MP_{10} , O_3 , SO_2 e Tap.

Como exemplo, o gráfico de superfície do número de interações, MP_{10} e Tap é visualizado na Figura 47, onde pode ser notado que quanto maior o nível do MP_{10} e menor a Tap, maior é o número de interação estimado pelo modelo.

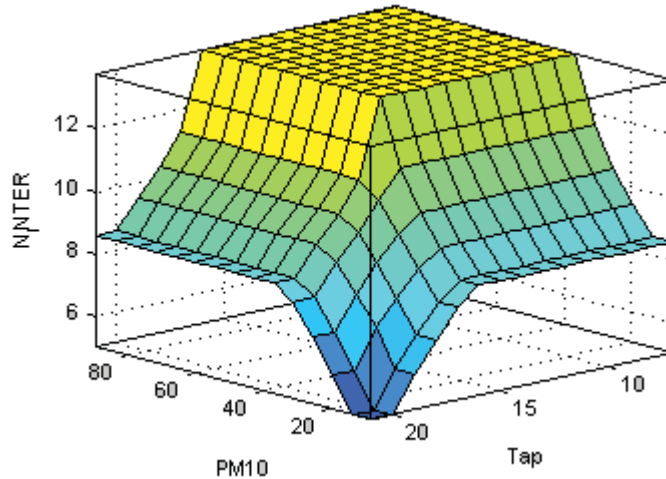


Figura 47- Gráfico de superfície do número de interações relativo ao MP_{10} x Tap (Próprio Autor)

As análises com duas variáveis, entrada versus saída, são demonstrados a seguir, Figura 48.




Figura 48- Gráficos de Análises- a) N_{inter} x MP_{10} e b) N_{inter} x MP_{10} (Próprio Autor)

No gráfico (a) pode ser notado que o número de interações é maior com um maior material particulado $40 \mu\text{g}/\text{m}^3$, com valores para ozônio $110 \mu\text{g}/\text{m}^3$, dióxido de enxofre $13,5 \mu\text{g}/\text{m}^3$ e temperatura aparente 14°C , enquanto que no gráfico (b) o número de interações é menor com um ozônio $40 \mu\text{g}/\text{m}^3$, dióxido de enxofre $1,5 \mu\text{g}/\text{m}^3$ e temperatura aparente 20°C .

Modelo Neuro-Fuzzy

Para a criação do modelo neuro-fuzzy foram coletados, para a saída do modelo, dados reais da base de dados do DATASUS para o número de interações de pacientes com asma e pneumonia na cidade de São José dos Campos- SP, ano de 2007.

Os dados de entrada coletados foram concentrações dos seguintes poluentes: MP₁₀ (material particulado), Ozônio (O₃), Dióxido de Enxofre (SO₂) e a temperatura aparente (Tap). Parte da planilha utilizada para gerar os modelos neuro-*fuzzy* pode ser vista a seguir, Figura 49.

1	MP10	O3	SO2	Tap	N° Inter
2	8	43	1.0	17.21	6
3	11	47	0.9	18.39	2
4	11	42	0.9	19.11	3
5	17	40	1.1	18.88	0
6	20	49	1.0	19.53	1
7	19	93	1.0	19.47	3
8	13	103	1.0	18.83	3
9	23	119	2.0	17.93	3
10	18	111	2.0	16.37	4
11	27	94	2.0	17.52	4
12	17	31	2.0	19.57	1
13	21	68	2.0	18.05	0
14	15	53	1.0	17.73	3
15	20	96	4.0	15.04	1

Figura 49- Planilha com dados de entrada e saída para gerar modelos neuro-*fuzzy* (Próprio Autor).

Durante o período de estudo, os dados referentes a 345 dias do ano de 2007 foram incluídos para desenvolver o modelo, sendo utilizados 50% dos dados para treinamento, 25% para teste e 25% para checagem do modelo.

Após várias simulações, ANEXO E, obteve-se os melhores resultados para o modelo neuro-*fuzzy* quanto ao número de funções de pertinência (N MF), tipo da função de pertinência (MF), saída constante, híbrido, erro igual a 0,01 e número de épocas (N épocas) usadas para treinar o modelo, Tabela 12.

O número ideal de épocas é aquele em que a função erro tem seu ponto mínimo, mas não pode ser muito alto para evitar o *overfitting* ou supertreinamento. Neste caso, o modelo iria responder perfeitamente (erro aproximadamente igual a zero) para os dados de treinamento, mas para os dados de checagem e teste iria apresentar um erro muito grande.

Tabela 12: Parâmetros e resultados do modelo neuro-*fuzzy*.

N MF	MF	N épocas	Erro treino	Erro teste	Erro chec
2222	Bell	1.240	2.5364	3.3371	2.1332
3222	Bell	1.240	2.4440	3.7738	2.9264
2223	Bell	780	2.4462	3.1615	2.2245

Na primeira coluna tem-se o número de funções de pertinência para as variáveis MP₁₀, O₃, SO₂ e Tap, respectivamente. Na segunda coluna, o tipo das funções de pertinência, em forma de sino (Bell). Na terceira coluna, tem-se o número de épocas utilizado para obter o menor erro. Nas quarta, quinta e sexta colunas estão os erros dos dados de treinamento, do teste e da checagem, respectivamente. O menor erro indica a melhor opção de funções de pertinência.

A melhor correlação entre os dados reais e os dados do modelo foi de 0,44 para o modelo com duas funções de pertinência para o MP₁₀, duas para o O₃, duas para o SO₂ e duas para a Tap; e tipo de função sino, como pode ser visto a seguir na Tabela 13.

Tabela 13- Correlações entre dados reais e dados dos modelos

Funções de pertinência	Tipo de função	Correlação
MF 2222	trimf	0.35
	trapmf	0.28
	gbellmf	0.44
	gaussmf	0.36
MF 3222	trimf	0.34
	trapmf	0.22
	gbellmf	0.36
	gaussmf	0.32
MF 2223	trimf	0.28
	trapmf	0.28
	gbellmf	0.37
	gaussmf	0.43

Na tabela observam-se os resultados das correlações entre os dados reais e os dados gerados pelos modelos neuro-*fuzzy* para a previsão do número de internações.


A área sob a Curva ROC foi significativa ($p < 0,05$) somente para a lag 2 do MP₁₀ e lag 0 do O₃, as lags estão mostradas na Tabela 14, a seguir.

Tabela 14 - Valores para Curva ROC para Lag 0, Lag 1 e Lag 2 dos poluentes MP₁₀, O₃ e SO₂.


	Lag 0	Lag 1	Lag 2
MP ₁₀	0,56 (0,42-0,70)	0,53 (0,39-0,67)	0,64(0,51-0,78)
O ₃	0,69 (0,54-0,84)	0,56 (0,41-0,70)	0,52(0,39-0,66)
SO ₂	0,53 (0,38-0,67)	0,50 (0,35-0,63)	0,56 (0,40-0,73)

As figuras 50, 51 e 52 mostram as Curvas ROC para os poluentes MP_{10} , O_3 e SO_2 respectivamente; e para os lags 0, 1 e 2.

A) 0,56 (0,42-0,70)



B) 0,53 (0,39-0,67)



C) 0,64(0,51-0,78)






Figura 50- Gráficos da Curva ROC para MP_{10} : A) Lag 0, B) Lag 1 e C) Lag 2 (Próprio Autor).

A) 0,69 (0,54-0,84)



B) 0,56 (0,41-0,70)



C) 0,52(0,39-0,66)






Figura 51- Gráficos da Curva ROC para O₃: A) Lag 0, B) Lag 1 e C) Lag 2 (Próprio Autor).

A) 0,53 (0,38-0,67)



B) 0,50 (0,35-0,63)



C) 0,56 (0,40-0,73)




Figura 52- Gráficos da Curva ROC para SO₂: A) Lag 0, B) Lag 1 e C) Lag 2 (Próprio Autor).

O modelo apresentou uma boa acurácia somente para o lag2 do MP₁₀ e lag0 do O₃.

Como exemplo usando o *rule viewer*, no caso mostrado na Figura 53, considerando a variável MP_{10} de $53\mu\text{g}/\text{m}^3$, O_3 de $112\mu\text{g}/\text{m}^3$, SO_2 de $8\mu\text{g}/\text{m}^3$ e a Tap de 11°C ; o modelo previu número de 10,7 interações. Para os dados reais houve 12 interações.

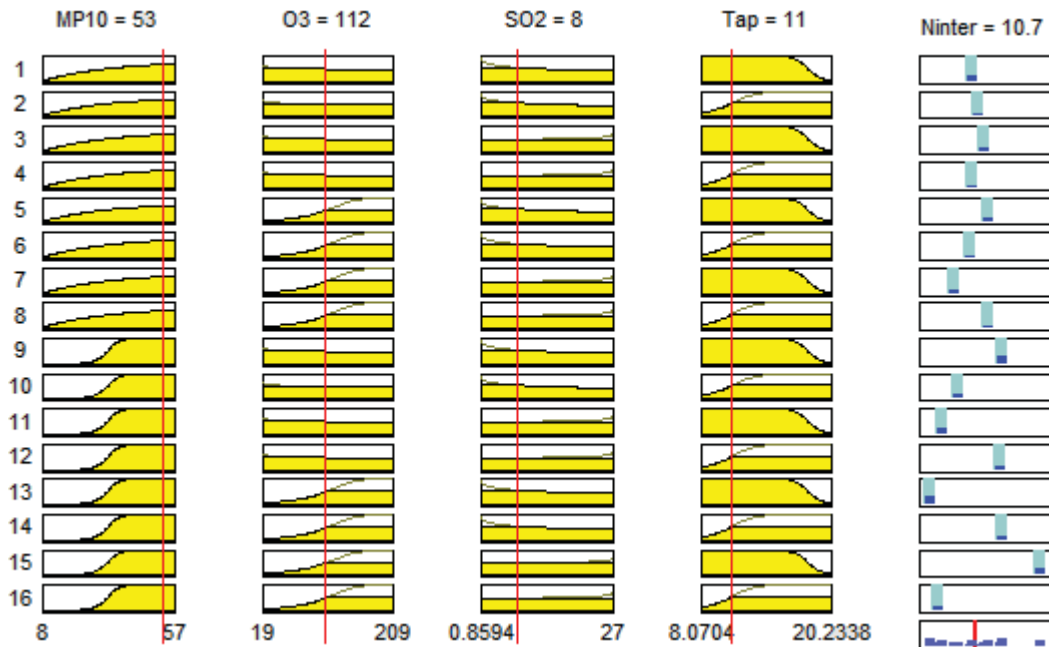


Figura 53: Tela capturada do Matlab

Outro exemplo, Figura 54, considerando as variáveis MP_{10} de $8\mu\text{g}/\text{m}^3$, O_3 de $34\mu\text{g}/\text{m}^3$, SO_2 de $1\mu\text{g}/\text{m}^3$ e a Tap de $11,6^\circ\text{C}$; o modelo previu 4,55 de interações. Para os dados reais o número de interações foi de 3.

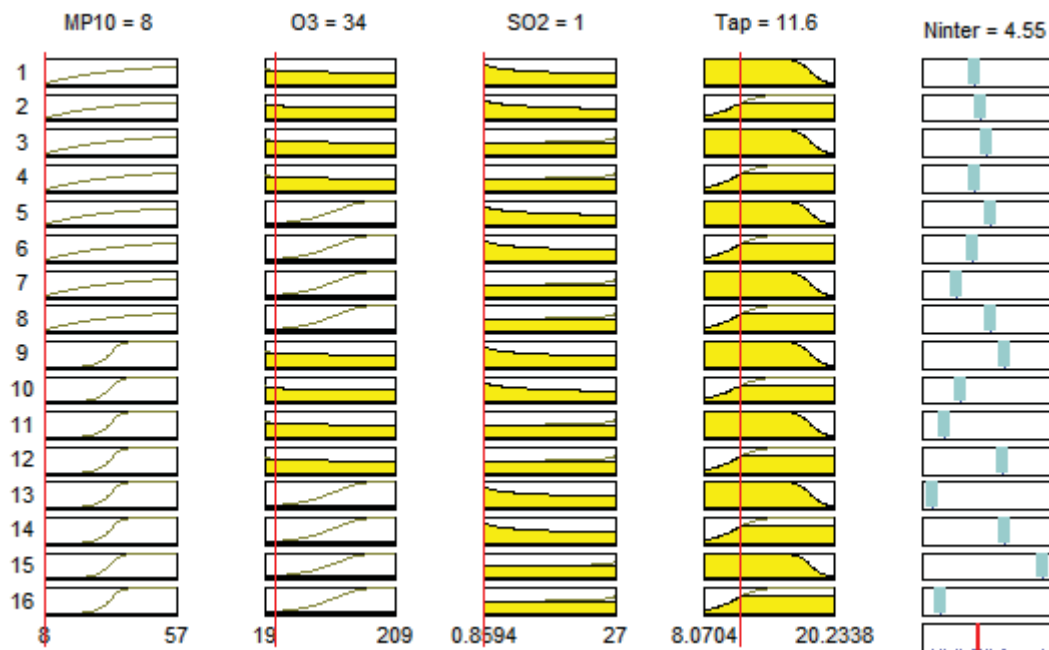


Figura 54: Tela capturada do Matlab (Próprio Autor)

O Matlab gera gráficos de superfície nos 3 eixos, sendo o eixo z representando a variável de saída número de internações (NINTER) e os eixos x, y representando as variáveis de entrada: MP₁₀ e Tap, é mostrado na Figura 55, onde pode ser notado que quanto maior o MP₁₀ e menor a Tap, maior é o número de internação estimado pelo modelo.




Figura 55- Gráfico de superfície do número de internações relativo ao MP₁₀ x SO₂ (Próprio Autor).

Este trabalho se diferencia de outros que estimam os riscos ou chances de risco que ocorram internações por exposição aos poluentes do ar utilizando regressão logística, estudos retrospectivos ou regressão de Poisson (BUENO *et al.*, 2010; AMÂNCIO; NASCIMENTO, 2012). Ao contrário das regressões, os modelos *fuzzy* e *neuro-fuzzy* são capazes de realizar a previsão do número de internações.

Os resultados do estudo apontam que os modelos têm grande capacidade em prever fenômenos complexos e não lineares.

A teoria e aplicações dos conjuntos *fuzzy* tornou-se uma ferramenta importante para a investigação médica com grande avanço do conhecimento. A aplicação da teoria de conjuntos *fuzzy* na medicina é uma nova área de pesquisa. No entanto, esta abordagem tem proporcionado resultados promissores em várias aplicações médica, propondo uma mudança de paradigma na ciência da saúde (ORTEGA, 2001).

A vantagem de previsão das internações aqui apresentado está em que após ser construído com o auxílio de um especialista, ele pode ser utilizado com base em dados reais para as simulações, não necessitando da opinião de mais especialistas.

O modelo pode ser implementado em sistemas de saúde pública e pode servir como um importante instrumento para a prevenção e tomadas de decisões quanto às variações do nível de poluentes. Uma previsão acurada é crítica para os melhoramentos na área de poluentes e

internações na saúde pública. Utilizar um bom índice de previsão permite identificar os potenciais pacientes relacionando ao desfecho das internações, assim como poderá, no futuro, ajudarem a equipe de saúde no tratamento. Modelos de previsão envolvendo poluentes e número de internações pode ser uma ferramenta muito eficaz no planejamento para a gestão da tomada de decisões adequadas na saúde pública.

Os modelos propostos neste trabalho representam uma modesta contribuição para este cenário de mudança, uma vez que os resultados mostram que a teoria dos conjuntos *fuzzy* pode ser uma ferramenta poderosa, para além da já existente.

O desenvolvimento de modelos utilizando a teoria *fuzzy* sobre o impacto da poluição atmosférica na saúde pode ser vista como um avanço tecnológico.

Os modelos *fuzzy* e *neuro-fuzzy* são de baixo custo financeiro, tornando-os, assim, possível de implantação e pode ser apresentado em um programa computacional específico para esta finalidade.

9 CONCLUSÃO

O presente trabalho foi desenvolvido no sentido de utilizar novas técnicas de abordagem em relação aos poluentes do ar e efeitos sobre a saúde.

Os resultados obtidos em relação aos modelos apresentados (*fuzzy* e *neuro-fuzzy*) no capítulo anterior permitem responder à questão inicial sobre a possibilidade de se construírem modelos capazes de realizar previsões sobre internações hospitalares por asma e pneumonia.

Tanto o modelo *fuzzy* (Mamdani) quanto o modelo *neuro-fuzzy* (Sugeno) mostraram resultados satisfatórios em relação à previsão de internações hospitalares por asma e pneumonia, relacionadas aos poluentes do ar.

Conclui-se que foi verificada a associação entre os poluentes do ar e o número de internações.

Foi possível desenvolver e validar os modelos *fuzzy* e *neuro-fuzzy*.

Realizando uma análise comparativa entre os modelos é possível observar que o modelo *neuro-fuzzy* foi capaz de generalizar com uma precisão maior em comparação com o modelo *fuzzy*. Apesar de apresentar uma melhor correlação do que o modelo *fuzzy*; o modelo *neuro-fuzzy* apresentou uma pior acurácia.

Com os modelos propostos neste estudo é possível que profissionais da área da saúde possam verificar em menor tempo a relação entre exposição aos poluentes e internações; e como consequência menor tempo e custo final para tomada de decisões.

REFERÊNCIAS

- AMANCIO, C.T.; NASCIMENTO, L.F.C.. Asma e poluentes ambientais: um estudo de séries temporais. **Rev Assoc Med Bras**, 58(3):302-307. 2012a.
- AMANCIO, C.T.; NASCIMENTO, L.F.C.. Association of sulfur dioxide exposure with circulatory system deaths in a medium-sized city in Brazil. **Braz J Med Biol Res**, Ribeirão Preto, v. 45, n. 11, nov. 2012b.
- ANTÔNIO, L.F.M. **Modelo baseado em inferência difusa para a análise de risco na operação de sistemas de energia**. 83 p. Graduação. (Licenciatura em Engenharia Eletrotécnica e de Computadores), Faculdade de Engenharia da Universidade do Porto, Porto: FEUP, 2004.
- ARBEX, M.A.; CANÇADO, J.E.D.; PEREIRA, L.A.A; BRAGA,A.L.F.; SALDIVA, P.H.N. Queima de Biomassa e efeitos sobre a saúde. **J. Bras. Pneumol**. 30 (2): 158-175. 2004.
- ARBEX, M.A.; SANTOS, U. P.; MARTINS, L. C.; SALDIVA, P.H.N.; PEREIRA, L.A.A; BRAGA,A.L.F. A poluição do ar e o sistema respiratório. **J Bras Pneumol**. 38 (5): 643-655. 2012.
- ASHISH, M.; RASHMI, B.. Prediction of daily air pollution using wavelet decomposition and Adaptive- Network-based *fuzzy* inference system. **International Journal of Environmental Sciences**. 2:1, 2011.
- AZEVEDO, F. A.; BRASIL, F. M.; OLIVEIRA, R. C. L. **Redes Neurais com Aplicações em Controle e em Sistemas Especialistas**. Florianópolis: Visual Books, 2000.
- BAKONYI, S.M.C.; DANNI-POLIVEIRA, I.M.; MARTINS, L.C.; BRAGA, A.L.F. Poluição atmosférica e doenças respiratória em crianças na cidade de Curitiba, PR. **Rev. Saúde Pública** 2004;38;(5):695-700, 2004.
- BALEEIRO, G.B.; **Modelagem Neuro-Fuzzy na estimativa de volume de *Eucalyptus sp.*** 51 p. (Monografia). Graduação em Ciência da Computação, Lavras: Universidade Federal de Lavras, 2007.
- BARCELLOS, C., MONTEIRO, A.M.V.; CORVALÁN, C.; GURGEL, H.C.; CARVALHO, M.S.; ARTAXO, Paulo; HACON, S.; RAGONI, V. Mudanças climáticas e ambientais e as doenças infecciosas: cenários e incertezas para o Brasil. **Epidemiol. Serv. Saúde**, Brasília, 18(3):285-304, jul-set 2009.
- BARNETT, A.G.; TONG, S.; CLEMENTS, A.C.A. What measure of temperature is the best predictor of mortality? **Environmental Research**. 110: 604–611, 2010.

BASCON, R.; BROMBREG, P. A.; COSTA, D. A.; DEVLIN, R.; DOCKERY, D. W.; FRAMPTON, M. W. *et al.* Health effects of outdoor air pollution. **Am J Respir Crit Care Med.** n. 153, p. 3-50. 1996.

BAUCHSPIESS, A. **Introdução aos Sistemas Inteligentes Aplicações em Engenharia de Redes Neurais Artificiais, Lógica Fuzzy e Sistemas Neuro-Fuzzy.** Engenharia Elétrica da Universidade de Brasília. Disponível em> [HTTP://www.ene.unb.br/adolfo/Isi](http://www.ene.unb.br/adolfo/Isi), Março de 2008. Acesso em 12 de set. 2012.

BENÍCIO, M.H.D'A.; CARDOSO, M.R.A.; GOUVEIA, N.C.; MONTEIRO, C.A. Tendência secular da doença respiratória na infância na cidade de São Paulo (1984-1996). **Rev. Saúde Pública** 2000; 34(6 Supl.):91-101. Disponível no site: www.fsp.usp.br/rsp. Acesso em: 23 ago. 2012.

BRAGA, A. L. F.; CONCEIÇÃO, G. M. S.; PEREIRA, L. A. A.; KISHI, H. S.; PEREIRA, J. C. R.; ANDRADE, M. F. *et al.* Air pollution and pediatric hospital admissions in São Paulo, Brazil. **J Environ Med.** n. 1, p. 95-102, 1999.

BRAGA, A.L.F.; PEREIRA, L.A.A.; PROCÓPIO, M; ANDRÉ, P.A.A.; SALDIVA; P.H.N. Association between air pollution and respiratory and cardiovascular diseases in Itabira, Minas Gerais State, Brazil, **Cad. Saúde Pública**, Rio de Janeiro, 23, Sup. 4:S570-S578, 2007.

BRAGA, A. L. F.; ZANOBETTI, A.; SCHWARTZ, J. The Effect of Weather on Respiratory and Cardiovascular Deaths in 12 U.S. Cities. **Environmental Health Perspectives.** v. 110, n. 9, p. 859-63, September 2002.

BRASIL. Ministério da Saúde. Departamento de Informática do SUS. DATASUS. Cadernos de Informação de Saúde. Disponível em: <http://tabnet.datasus.gov.br/cgi/tabcgi.exe?sih/cnv/nruf.def> Acesso em: 03 mar 2011.

BRUSAFERRO, Gustavo. **Previsão do mercado automotivo brasileiro usando modelos matemáticos e inteligência artificial.** 2006. 157f. Dissertação de Mestrado, São José dos Campos: Instituto Tecnológico de Aeronáutica, 2006.

BUENO, F. F.; Fonseca, A. R.; Braga, F. A.; Miranda, P. S. C. Qualidade do ar e internações por doenças respiratórias em crianças no município de Divinópolis, Estado de Minas Gerais. **Acta Scientiarum. Health Sciences.** v. 32, n. 2, p. 185-189, Maringá, 2010.

CALDEIRA, A.M.; MACHADO, M.A.S.; SOUZA, R.C.; TANSCHKEIT, R. OLIVEIRA JUNIOR, A.H (Coord.). 2007; **Inteligência computacional aplicada à administração, economia e engenharia em Matlab®.** São Paulo: Tomson Learning, 2007.

CANÇADO, J.E.D.; BRAGA, A.; PEREIRA, L.A.A.; ARBEX, M.A.; SALDIVA, P.H.N.; SANTOS, U.P. **Repercussões clínicas da exposição à poluição atmosférica.** J. Bras. Pneumol. 2006; 32(Supl 1):S5-S11.2006.

CARMO, C.N.; HACON, S.; LONGO, K.M. FREITAS, S.; IGNOTTI, E.; LEON, A.P.; ARTAXO, P. Associação entre material particulado de queimadas e doenças respiratórias na região sul da Amazônia brasileira. **Rev. Panam Salud Publica**. 2010;27(1):10-6.

CARPENTER, G. A.; GROSSBERG, S. A Self-organizing Neural Network for Supervised Learning, Recognition and Prediction: Can neural networks learn to recognize new objects without forgetting familiar ones? **IEEE Communications Magazine**. September, 1992.

CARVALHO, L. F.; NASSAR, S.M.; AZEVEDO, F. M.; CARVALHO, H. J. T.; RECH, C. M. Z.; MONTEIRO, L. L. **Metodologia de aprendizagem para Sistemas Neuro-difusos**. Iniciação Científica: PIBIC/UPF, 2006.

CASTANHO, M.J.P. **Sistema neuro-fuzzy para prognóstico de câncer de próstata**. *Biomatemática* 17 (2007), 11-20. IMECC-UNICAMP.

CASTRO, H. A.; GOUVEIA, N.; CEJUDO, J. A. E. Questões metodológicas para a investigação dos efeitos da poluição do ar na saúde. **Rev. Bras. Epidemiol.** v.6, n.2, 2003.

CASTRO, H. A.; CUNHA, M. F.; MENDONÇA, G. A. e S.; JUNGER, W. L., CUNHA-CRUZ, J.; LEON, A. P.. Efeitos da poluição do ar na função respiratória de escolares, Rio de Janeiro, RJ. **Revista de Saúde Pública**, 43(1), 26-34, 2009.

CETESB (Companhia de Tecnologia de Saneamento Ambiental). **Relatório de qualidade do ar no Estado de São Paulo**, 2012. São Paulo. Disponível em: <<http://www.cetesb.sp.gov.br>>. Acesso em: 31 de março de 2013.

CETESB (Companhia de Tecnologia de Saneamento Ambiental). Informações Básicas sobre Poluentes. <http://www.cetesb.sp.gov.br/ar/Informa??es-B?sicas/21-Poluentes#mp>. Acesso 23 junho 2013.

CONAMA- RESOLUÇÃO N.º 003 de 28 de junho de 1990 em <http://www.mma.gov.br/port/conama/res/res90/res0390.html> acesso em 01 julho 2013.

DASH, P.K.; MISHRA, S.; SALAMANA, M.M.A.; LIEW, A.C. **Classification of Power System Disturbances Using a Fuzzy Expert System and a Fourier Linear Combiner**. *IEEE Transaction on power delivery*, vol. 15. n.2. p. 472-47, april, 2000.

Diretrizes da Sociedade Brasileira de Pneumologia e Tisiologia para o Manejo da Asma. **J Bras Pneumol.** v.38, Suplemento 1, p.S1-S46 Abril. 2012.

FARAWAY, J.J. **Practical regression and anova using R**. 1999.

FERNANDES, J. S.; CARVALHO, A. M.; CAMPOS, D. J. F.; COSTA, L. O. BRASILEIRO FILHO, G. Poluição atmosférica e efeitos respiratórios, cardiovasculares e reprodutivos na saúde humana. **Rev. Med. Minas Gerais**. 20(1): 92-101. 2010.

FERNANDES, A. P. S. **Sistema Especialista Difuso de Apoio ao Aprendizado do Traumatismo Dento-Aveolar Utilizando Recursos Multimídia**. (Dissertação de mestrado) Florianópolis: Universidade Federal de Santa Catarina, 1997.

FERREIRA, L.; YANAGI JUNIOR, T.; LOPES, A.Z.; LACERDA, W.S. **Desenvolvimento de uma rede neuro-fuzzy para predição da temperatura retal de frangos de corte**. Departamento de Engenharia, Universidade Federal de Lavras (UFLA), MG, Brasil, 2010.

FULLÉR, R. **Neural Fuzzy Systems**. Abdo Akademi University, 1995.

GALVÃO, M. G. A.; SANTOS, M. A. R. Pneumonia na infância. *Pulmão RJ* 2009; Supl; 1:545-549, S45.2009.

GIODA, A.; GIODA, F. R.. A influência da qualidade do ar nas doenças respiratórias. **Health and Environment Journal**. v. 7, n. 1, jun. 2006.

GOMES, M. J. M. Ambiente e pulmão. **I. Pneumol.** 28(5) – set-out. 2002.

GOOGLE Mapas. <http://maps.google.com.br>. Acesso em 2 julho 2013.

GOUVEIA, N.; FLETCHER, T. Respiratory diseases in children and outdoor air pollution in São Paulo, Brazil: a time series analysis. **Occup Environ Med**, n. 57, p. 477-83, 2000b.

GOUVEIA, N.; FLETCHER, T. Time series analysis of air pollution and mortality: effects by cause, age and socioeconomic status. **J Epidemiol Comm Health**, n. 54, p. 750-5, 2000a.

GOUVEIA, N.; MENDONÇA, G. A.; LEON, A. P.; CORREIA, J. E.; JUNGER, W. L.; FREITAS, C. U. DAUMAS, R.P.; MARTINS, L.C.; GIUSSEPE, L.; CONCEIÇÃO, G.M.S.; MANERICH, A.; CUNHA-CRUZ, J. Poluição do ar e efeitos na saúde nas populações de duas grandes metrópoles brasileiras. **Epidemiol Serv Saúde**, n. 12,(1) p. 29-40, 2003.

HAYKIN, Simon. **Redes Neurais: Princípios e Prática**. 2 ed , Porto Alegre: Bookman, 2001.

HUAMANÍ, I.R.L. **Redes Neurais Fuzzy Aplicadas em Identificação e Controle de Sistemas**. (Dissertação) Faculdade de Engenharia Elétrica e de Computação da Universidade Estadual de Campinas, Departamento de Engenharia de Computação e Automação Industrial, 2003.

IYODA, E. M. **Inteligência Computacional no Projeto Automático de Redes Neurais Híbridas e Redes Neuro-fuzzy Heterogêneas**. 176 p. (Tese de Doutorado em Engenharia Elétrica) Faculdade de Engenharia Elétrica e de Computação. Departamento de Engenharia de Computação e Automação Industrial. Campinas: Universidade Estadual de Campinas, 2000.

JACINTHO, L. F. O. **Redes Neuro-Fuzzy: Um Estudo de Caso em Diagnóstico de Alzheimer**. 60f. (Monografia). Centro de Matemática, Computação e Cognição da Universidade Federal do ABC. 2010.

JAIN, S.; KHARE, M.. Adaptive neuro-*fuzzy* modeling for prediction of ambient CO concentration at urban intersections and roadways. **Air Qual Atmos Health**, 3:203–212, 2010.

JANG, J .S. R.; SUN, C. T.; MIZUTANI, E. **Neuro-*fuzzy* and soft computing: a computacional approach to learning and machine intelligence**. Upper Saddle River, NJ: Prentice Hall Inc. 1997.

JANG, J.S.R. **ANFIS: Adaptive-Network-Based *Fuzzy* Inference System**. Department of Electrical Engineering and Computer Science University of California, Berkeley, CA 94720. **IEEE Trans on Systems, Man and Cybernetics**, vol, 23,n. 23, pp. 665-685, May,1993.

KARTALOPOULOS, S. V. **Understanding neural network and *fuzzy* logic**. New York: IEEE, 1996.

KLIR, G. J.; BO, Y.. ***Fuzzy Sets and fuzzy Logic: theory and applications***. Prentice Hall. 1995a.

KLIR, G. J. *Fuzzy Logic: Unearthing its meaning and significance*. **IEEE Potentials**. p.10-15, oct./nov. 1995b.

LEI, K. S.; WAN, F.. Applying Ensemble Learning Techniques to ANFIS for Air Pollution Index Prediction in Macau. **Lecture Notes in Computer Science**. V 7367, pp 509-516, 2012.

LIN, C. A.; PEREIRA, L. A. A.; BRAGA, A. L. F.; CONCEIÇÃO, G. M. S.; KISHI, H. S.; MILANI, R. *et al.* Association between air pollution and ischemic cardiovascular emergency room visits. **Env Res** n. 92, p. 53-63, 2003.

LIN, Y.; CUNNINGHAM III, G. A. A new approach to *fuzzy*-neural modelling, **IEEE Transactions on *Fuzzy* Systems**, v. 3, n. 2, p. 190-198, 1995.

LOESCH, C.; SARI, S. T. ***Redes neurais artificiais: fundamentos e modelos***. Blumenau: FURB, 1996.

MALANGE, F.C.V. **Rede Neuro *Fuzzy* Wavelet para Detecção e Classificação de Anomalias de Tensão em Sistemas Elétricos de Potência**. 128 p (Tese de Doutorado). Universidade Estadual Paulista “Júlio de Mesquita Filho”. Campus de Ilha Solteira: SP, Abril, 2010.

MALUTTA, C. **Método de apoio à tomada de decisão sobre adequação de aterros sanitários utilizando a *Lógica Fuzzy***. 221 p. (Tese) Engenharia de Produção de Pós-Graduação em Engenharia de Produção da Universidade Federal de Santa Catarina. Florianópolis, 2004.

MARTINS, L.C.; LATORRE, M.R.D.O.; CARDOSO, M.R.A.; GONÇALVES, F.L.T.; SALDIVA, P.H.N.; BRAGA, A.L.F. Poluição atmosférica e atendimento por pneumonia e gripe em São Paulo, Brasil. **Rev. Saúde Pública**. 36(1): 88-94. 2002. Disponível em: www.fsp.usp.br/rsp. Acesso em 12 ago. 2012.

MASSAD, E.; ORTEGA, N. R. S.; BARROS, L. C.; STRUCHINER, C. J.. **Fuzzy Logic in Action: Applications in Epidemiology and Beyond. Applications in Epidemiology and Beyond (Studies in Fuzziness and Soft Computing)**. Springer; 1 edition, Feb, 2009.

MATLAB, **Fuzzy Logic Toolbox** R2012b, User's Guide, 2012.

MCCULLOCH, W. S.; PITTS, W. H. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, v. 5, p. 115-133, 1943.

MENDONÇA, F. **Aspectos da Interação clima-Ambiente-Saúde Humana: Da relação Sociedade-Natureza à (in) sustentabilidade ambiental**. R.RA'EGA, Curitiba: Editora da UFPR, n. 4, p. 85-99, 2000.

MONARD, M.C.; BARANAUSKAS, J.A.. **Aplicação de Inteligência Artificial: Uma Visão Geral**. Instituto de Ciências Matemáticas e de Computação de São Carlos. São Carlos: Universidade São Paulo, 2000.

MOTTA, R. S.; MENDES, A.P.F.; Custos de Saúde associados à poluição do ar no Brasil. **Pesq. Plan. Econ.**, Rio de Janeiro, v.25, n. 1, p.165-198, abr. 1995.

MOURA, A.O.; ANDRADE, D.S.; KIKUCHI, W.K. Inteligência Artificial Aplicada no Auxílio a Tomadas de Decisões na área de Saúde. **II Simpósio de excelência em Gestão e Tecnologia – SEGeT12005**. 2005.

NASCIMENTO, L. F. C.; MOREIRA, D. A. Are environmental pollutants risk factors for low birth weight? **Cad. Saúde Pública**, Rio de Janeiro, 25(x): 1-6. 2009.

NASCIMENTO, L. F. C.; PEREIRA, L. A.; BRAGA, A. L. F.; MÓDOLO, M. C.; CARVALHO, J. A. Efeitos da poluição atmosférica na saúde infantil em São José dos Campos, SP. **Rev. Saúde Pública**, n. 40, p. 77-82, 2006.

NAUCK, D.; KRUSE, R. Neuro-Fuzzy systems for function approximation. *Fuzzy Sets and Systems* 101 261-271, **Faculty of Computer Science**, Elsevier Science B.V. 1997.

NEGNEVITSKY, M. **Artificial Intelligence A Guide to Intelligent System**. Second Edition. Pearson Education Limited. 2005.

NICODEMOS, R.M.; LIRA, T.S.; BARROZO, M.A.S.; GUIMARÃES, E.C. Estudo da relação entre concentração em MP10 e Doenças Respiratórias na cidade de Uberlândia-MG, **VIII Congresso Brasileiro de Engenharia Química em Iniciação Científica**. 27 a 30 de julho de 2009, Uberlândia, Minas Gerais, Brasil.

NINOMIYA, M. P., **Utilização do sistema Neuro-Fuzzy (ANFIS) para estimação do peso ao nascer**. Relatório Bolsa PAE, UNESP - Guaratinguetá-SP, 2008.

NISHIDA, W. **Uma rede neural artificial para classificação de imagens multiespectrais de sensoriamento remoto**. Florianópolis, 1998. Dissertação (Mestrado em PPGEP) - Universidade Federal de Santa Catarina – UFSC.

NOORI, R.; HOSHYARIPOUR, G.; ASHRAFI, K.; ARAABI, B. N. Uncertainty analysis of developed ANN and ANFIS models in prediction of carbon monoxide daily concentration. **Atmospheric Environment**. 44; 476-482, 2010.

O'CONNOR, G. T.; NEAS, L.; VAUGHN, B.; KATTAN, M.; MITCHELL, H.; CRAIN, E. F.; EVANS III, R.; GRUCHALLA, R.; MORGAN, W.; STOUT, J.; ADAMS, G. K.; LIPPMANN, M. Acute respiratory health effects of air pollution on children with asthma in US inner cities. **U.S. Environmental Protection Agency Papers. Paper 12**. 2008.

OPAS, **Mudanças climáticas e ambientais e seus efeitos na saúde: cenários e incertezas para o Brasil**, 2008.

ORTEGA, N. R. S. **Aplicação da Teoria dos Conjuntos Fuzzy a Problemas de Biomedicina**. Tese (Doutorado) Universidade de São Paulo, Instituto de Física, SP: 2001. Disponível em: <http://www.ime.usp.br/~tonelli/verao-fuzzy/neli/principal.pdf>. Acesso em: 08/10/2012

OSÓRIO, F. **Redes Neurais – Aprendizado Artificial**. Forum de I.A. 1999.

PEREIRA, B. B.; RODRIGUES, C. V. Redes Neurais em Estatística. *In*: SIMPOSIO NACIONAL DE PROBABILIDADE E ESTATÍSTICA, 13º, 1998. **Anais...** [S.l.:s.n.] 1998.

PEREIRA, L. A. A.; LOOMIS, D.; CONCEIÇÃO, G. M. S.; BRAGA, A. L. F.; ARCAS, R. M.; KISHI, H. *et al.* Association between air pollution and intrauterine mortality in São Paulo, Brazil. **Environ Health Perspect**, n. 106, p. 325-9, 1998.

PITTON, S.E.C.P. ; DOMINGOS, A.E. Tempo e Doenças: Efeitos dos Parâmetros Climáticos nas crises Hipertensivas nos moradores de Santa Gertrudes-SP, *Estudos Geográficos*, Rio Claro, 2(1):75-86, junho-2004. Disponível em www.rc.unesp.br/igce/grad/geografia/revista.htm. Acesso em: 18 jul. 2012.

RAMOS, P.G. **Uma investigação das Redes Neuro-Fuzzy aplicadas à Mineração de Dados**. Universidade Federal de Pernambuco. Recife: Centro de Ciências Exatas e da Natureza. Departamento de Informática, 1999.

REZENDE, S.O. **Sistemas inteligentes: fundamentos e aplicações**. Baueri/SP: Manole, 2005.

RODRÍGUEZ. A. A. Z. **IA 353- Redes Neurais: Previsão de Demanda de Energia Elétrica usando Redes Neurais Adaptativas y Regras Nebulosas**. 27 p. (Relatório de Projeto)

Faculdade de Engenharia Elétrica e de Computação. Campinas: Universidade Estadual de Campinas, 2003.

SALDANHA, C. T.; SILVA, A. M. C. da.; BOTELHO, C. Variações climáticas e uso de serviços de saúde em crianças asmáticas menores de cinco anos de idade: um estudo ecológico. **J Bras Pneumol.** n. 31, p. 492-498, 2005.

SALDIVA, P. Nossos doentes pneumopatas e a poluição atmosférica. **J. Bras. Pneumol.** 2008;34(1): 1.

SALDIVA, P. H. N.; POPE, C. A.; SCHWARTZ, J.; DOCKERY, D. W.; LICHTENFELS, A. J.; SALGE, J. M. *et al.* Air pollution and mortality in elderly people: a time-series study in São Paulo, Brazil. **Archives of Environmental Health**, n. 50 (2), p. 159-63, 1995.

SALES, G.K.; MARTINS, L.A. Poluição Atmosférica e Doenças respiratórias em Juiz de Fora-MG. **Enciclopédia Bioesfera**, n. 01, 11p. 2005.

SANDRI, S.; CORREA, C. **Lógica Nebulosa.** V Escola de Redes, Promoção: Conselho Nacional de Redes Neurais. PP. C073-c090. São José dos Campos: ITA. 19 de jul. 1999.

SAVIC, M.; MIHAJLOVIC, I.; ŽIVKOVIC, Ž.. An ANFIS – Based Air Quality Model For Prediction of SO₂ Concentration in Urban Area. **Serbian Journal of Management.** 8 (1). 2013.

SCHWALBERT, M. A. **Metodologias de aprendizagem de máquina utilizando redes neurais artificiais.** 114 p. (TCC de Ciência da Computação) Instituto de Ciências Exatas e Geociências. Passo Fundo: Universidade de Passo Fundo, 2007.

SILVA, A. M. C.; MATTOS, I. E.; FREITAS, S. R.; LONGO, K. M.; HACON, S. S. Material particulado (PM 2.5) de queima de biomassa e doenças respiratórias no sul da Amazônia brasileira. **Rev. bras. epidemiol.**, São Paulo, v. 13, n. 2, jun. 2010 .

STOCCO, C. ; LEITE, M.L.; LABIAK, M.L.; VIRGENS FILHO, J.S.; NASCIMENTO, E. Influência de Variáveis Climáticas sobre a Incidência de Meningite e sua Distribuição Espacial no Município de Ponta Grossa-PR 2001-2005. **Saúde Soc. São Paulo**, v.19, n. 1, p.84-93, 2010.

STONE, V. Environmental air pollution. **Am J Respir Crit Care Med**, 162:S47, 2000.

TADANO, Y. S. **Simulação da dispersão dos poluentes atmosféricos para aplicação em análise de impacto.** 197p. (Tese de Doutorado). Campinas: Faculdade de Engenharia Mecânica da Universidade Estadual de Campinas, 2012.

TAKAGI, T.; SUGENO, M. *Fuzzy* identification of systems and its application to modeling and control. **IEEE Trans. On Systems, Man & Cybernetics**, n. 15, p. 116-132, 1985.

TEIXEIRA, R. A.; CORRÊA, M.V.; ASSIS, J.C.O. **Redes Neuro-Fuzzy**: Algoritmo de Treinamento e Aplicações. Principiu, Online: Iniciação Científica no Unileste-MG, Coronel Fabriciano, v.1, n.3, p.152-168. 2007.

TOYOSHIMA, M.T.K.; ITO, G.M.; GOUVEIA, N. Morbidade por doenças respiratórias em pacientes hospitalizados em São Paulo/SP. *Rev. Assoc. Med. Bras.*, 2005; 51(4):209-13.

WHO- WORLD HEALTH ORGANIZATION, N. H. L. B. I. **Global Initiative for Asthma**, 1995.

WHO - WORLD HEALTH ORGANIZATION. **Health Guidelines for Vegetation Fire Events**. ed. SCHWELA, D.H., GOLDAMMER, J.G., MORAWSKA, L.H., SIMPSON, O. Geneva, World Health Organization, 1999.

WHO- WORLD HEALTH ORGANIZATION, N. H. L. B. I. **Global Initiative for Obstructive Lung Disease**. Executive summary, 2001.

WHO- WORLD HEALTH ORGANIZATION. “Air Quality Guidelines Global Update 2005”. Report on a working group meeting, Bonn/Germany, 18-20 october .2005.

WINSTON, P. H. “**Artificial intelligence**”, Addison-Wesley, Massachusetts, third edition, 1992.

YILDIRIM, Y.; BAYRAMOGLU, M.. Adaptive neuro-*fuzzy* based modelling for prediction of air pollution daily levels in city of Zonguldak. **Chemosphere**. 63, 1575–1582, 2006.

ZADEH, L. A. Generalizes theory of uncertainty (CTU) – principal conceptions and ideas. **Computational Statistics & Data Analysis** 51 (2006) 16-46. 2006.

ZADEH, L. A. *Fuzzy Sets*. **Information Control**. v. 8, p. 338-353, 1965.


ZAMORANO, A.; MÁRQUEZ, S. ARÁNGUIZ, J.L.; BEDREGAL, P.; SÁNCHEZ, I. Relación entre bronquiolitis aguda com factores climaticos y contaminación ambiental. **Rev. Med. Chile**. 131:1117-1122. 2003.

www.din.uem.br/ia/intelige/neurofuzzy/. Acesso em 2 julho 2013.

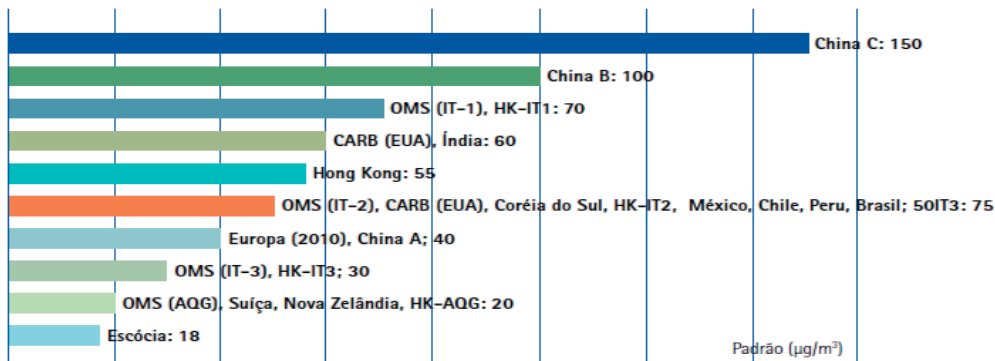
www.who.int/features/factfiles/asthma/asthma_facts/es/index.html. Acesso em 25 agosto 2013.

ANEXO A- NOVOS PADRÕES PRIMÁRIOS E SECUNDÁRIOS DA OMS-2012


– Padrões diários de qualidade do ar para MP₁₀ em diferentes países



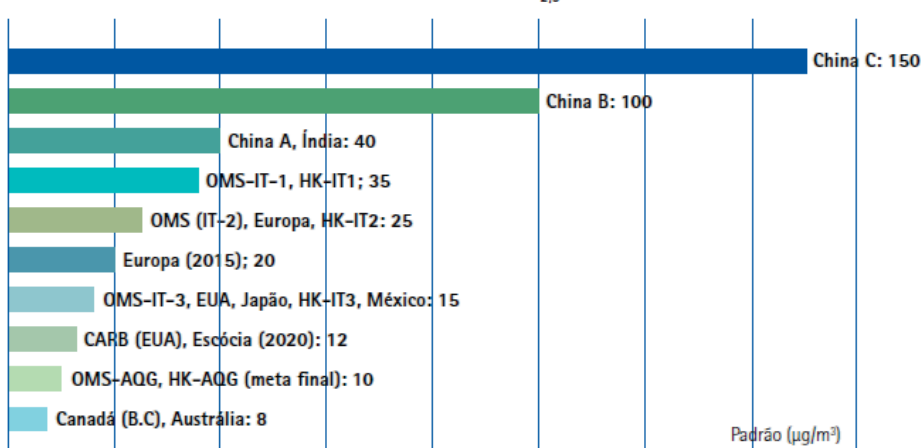
– Padrões anuais de qualidade do ar para MP₁₀ em diferentes países



– Padrões diários de qualidade do ar para MP_{2,5} em diferentes países



– Padrões anuais de qualidade do ar para MP_{2,5} em diferentes países



ANEXO B- PADÕES PRIMÁRIOS E SECUNDÁRIOS DO AR- CETESB

Poluente	Tempo de Amostragem	Padrão Primário µg/m ³	Padrão Secundário µg/m ³	Método de Medição
partículas totais em suspensão	24 horas ¹	240	150	amostrador de grandes volumes
	MGA ²	80	60	
partículas inaláveis	24 horas ¹	150	150	separação inercial/filtração
	MAA ³	50	50	
fumaça	24 horas ¹	150	100	refletância
	MAA ³	60	40	
dióxido de enxofre	24 horas ¹	365	100	pararosanilina
	MAA ³	80	40	
dióxido de nitrogênio	1 hora	320	190	quimiluminescência
	MAA ³	100	100	
monóxido de carbono	1 hora ¹	40.000	40.000	infravermelho não dispersivo
		35 ppm	35 ppm	
	8 horas ¹	10.000	10.000	
ozônio		9 ppm	9 ppm	quimiluminescência
	1 hora ¹	160	160	

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

2 - Média geométrica anual.

3 - Média aritmética anual.

ANEXO C- FÓRMULA PARA CALCULAR A TEMPERATURA APARENTE

Apparent temperature (deg F)

$$= -2.653 + 0.994 \times \text{mean temperature (deg F)} + 0.0153 \\ \times [\text{dew-point temperature (deg F)}]^2.$$

Dada a Temperatura T (°C) e a Umidade Relativa UR (%), é a seguinte a fórmula de cálculo do ponto de orvalho To (°C):

$$T_o = T - (14,55 + 0,114 \times T) \times [1 - (0,01 \times UR)] - \{(2,5 + 0,007 \times T) \times [1 - (0,01 \times UR)]\}^3 - (15,9 + 0,117 \times T) \times [1 - (0,01 \times UR)]^{14}$$

ANEXO D- ROTINA DDEINIT DO MATLAB PARA GERAR SAÍDA NUMÉRICA

```
>> myvariable=ddeinit('excel','C:\Users\Luciano\Desktop\Dados 1104\Planilha fuzzy final.xls:Plan1')

myvariable =

    4.7836e-299

>> mymatrix = ddereq(myvariable, 'l1c1:l345c4')

mymatrix =

    8.0000    43.0000    1.0000    17.2100
   11.0000    47.0000    0.9000    18.3900
   11.0000    42.0000    0.9000    19.1100
   17.0000    40.0000    1.1000    18.8800
   20.0000    49.0000    1.0000    19.5300
   19.0000    93.0000    1.0000    19.4700
   13.0000   103.0000    1.0000    18.8300
   23.0000   119.0000    2.0000    17.9300
   18.0000   111.0000    2.0000    16.3700

>> fismat = readfis('luciano2204')

fismat =

    name: 'luciano2204'
    type: 'mamdani'
 andMethod: 'min'
  orMethod: 'max'
defuzzMethod: 'centroid'
 impMethod: 'min'
aggMethod: 'max'
   input: [1x4 struct]
  output: [1x1 struct]
    rule: [1x16 struct]

>> output = evalfis(mymatrix,fismat)

output =

    2.4521
    2.0737
    1.6698
    5.1040
    3.5537
    5.9963
    3.4768
    8.8248
    7.5434
```

ANEXO E- SIMULAÇÕES DO MODELO NEURO-FUZZY

N° MF	Tipo MF	N Épocas	erro	teste	chec	correl
2222	trimf	570	2.6927	3.0605	2.0353	0.35
	trapmf	828	2.6713	3.3371	2.1332	0.28
	gbellmf	1240	2.5364	3.3725	2.1162	0.44
	gaussmf	4.704	2.5614	3.1766	3.0248	0.36
3222	trimf	2.134	2.4775	4.2812	3.7708	0.34
	trapmf	344	2.7124	4.1070	2.7095	0.22
	gbellmf	1.240	2.4440	3.7738	2.9264	0.36
	gaussmf	3.590	2.4429	4.6656	2.7219	0.32
2223	trimf	152	2.6042	3.4351	2.3259	0.28
	trapmf	522	2.5799	3.4867	2.1957	0.28
	gbellmf	780	2.4462	3.1615	2.2245	0.37
	gaussmf	369	2.4914	3.5417	2.4095	0.43
3332	trimf	1.972	2.5270	22.3735	24.2925	0.14
	trapmf	48	2.8981	87.4517	81.9314	0.10
	gbellmf	708	2.5227	26.6468	57.4557	0.15
	gaussmf	3.777	2.3971	10.7002	13.767	0.25
3333	trimf	335	2.5389	30.3070	18.1581	0.19
	trapmf	98	2.6734	8.2933	18.419	-0.02
	gbellmf	2.468	1.9881	63.5317	12.2535	0.10
	gaussmf	922	2.2663	44.5234	46.2084	0.02
4333	trimf	708	2.2881	55.7652	68.5957	0.23
	trapmf	6	2.5072	12.9372	7.4632	0.08
	gbellmf	1.868	1.6797	15.2566	14.5328	0.08
	gaussmf	860	2.0595	28.8641	19.1329	-0.07