

**UTILIZAÇÃO DA TÉCNICA DA ANÁLISE DA ÁRVORE DE FALHAS PARA
A DETERMINAÇÃO DO ALGORITMO HEURÍSTICO GENERALIZADO DE
DIAGNÓSTICO DE FALHAS EM MOTORES DIESEL**

Raimundo Nonato da Costa Coelho

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Engenharia de Recursos Naturais da Amazônia (PRODERNA), ITEC, da Universidade Federal do Pará, como parte dos requisitos necessários à obtenção do título de Doutor em Engenharia de Recursos Naturais.

Orientadores:

Professor Dr. Emanuel Negrão Macedo.

Professor Dr. João Nazareno Nonato Quaresma.

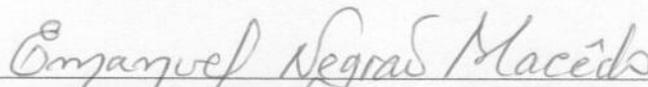
Belém
Junho de 2017

**UTILIZAÇÃO DA TÉCNICA DA ANÁLISE DA ÁRVORE DE FALHAS PARA A
DETERMINAÇÃO DO ALGORITMO HEURÍSTICO GENERALIZADO DE
DIAGNÓSTICO DE FALHAS EM MOTORES DIESEL**

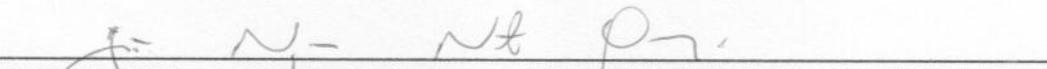
Raimundo Nonato da Costa Coelho

PROPOSTA DE TESE SUBMETIDA AO CORPO DOCENTE DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE RECURSOS NATURAIS DA AMAZÔNIA - PRODERNA/ITEC/UFPA COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA OBTENÇÃO DO GRAU DE DOUTOR EM ENGENHARIA DE RECURSOS NATURAIS.

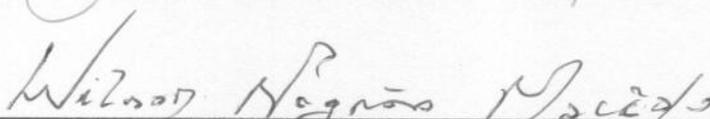
Aprovada por:



Prof. Dr. Emanuel Negrão Macêdo (PRODERNA/ITEC/UFPA - ORIENTADOR)



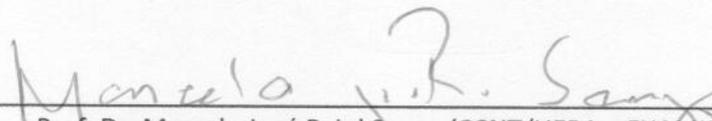
Prof. Dr. João Nazareno Nonato Quaresma (PRODERNA/ITEC/UFPA – CO-ORIENTADOR)



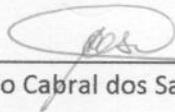
Prof. Dr. Wilson Negrão Macêdo (PPGEE/ITEC/UFPA - EXAMINADOR)



Prof. Dr. Marcos André Barros Galhardo (GDAE/ITEC/UFPA – EXAMINADOR)



Prof. Dr. Marcelo José Raiol Souza (CCNT/UEPA – EXAMINADOR)



Prof. Dr. Carlos Antônio Cabral dos Santos (DTM/UFPA – EXAMINADOR)

**Dados Internacionais de Catalogação na Publicação (CIP)
Sistemas de Biblioteca da UFPA**

Coelho, Raimundo Nonato da Costa, 1962-

Utilização da técnica da análise da árvore de falhas para a determinação do algoritmo heurístico generalizado de diagnóstico de falhas em motores diesel/ Raimundo Nonato da Costa Coelho.- 2017.

Orientador: Emanuel Negrão Macedo,
Coorientador: João Nazareno Nonato Quaresma

Tese (Doutorado) - Universidade Federal do Pará.
Instituto de Tecnologia. Programa de Pós-Graduação em
Engenharia de Recursos Naturais da Amazônia, Belém, 2017.

1. Motor diesel 2. Processo de combustão 3. Árvores
(Teoria dos grafos) 4. Confiabilidade (Engenharia) I.
Título

CDD 23.ed.621.436

DEDICATÓRIA

Ao meu gurizinho, Caio.

AGRADECIMENTOS

Aos Professores e amigos Emanuel Negrão Macêdo e João Nazareno Nonato Quaresma pela orientação, ajuda, incentivo e colaboração para o desenvolvimento e conclusão deste trabalho. Gratidão eterna.

À CAPES pela ajuda financeira fundamental.

Ao Professor Marcos Galhardo do PPGEE-ITEC/UFPA pela orientação decisiva para a conclusão do trabalho.

Aos Professores Wilson Negrão Macêdo (PPGEE-ITEC/UFPA), Marcelo José Raiol Souza (CCNT/UEPA), Edilson Marques Magalhães (PPGEP-ITEC/UFPA) e Kleber Bittencourt Oliveira (PPGEP-ITEC/UFPA) pelas contribuições para a conclusão do trabalho.

Resumo da Tese apresentada ao PRODERNA/UFPA como parte dos requisitos necessários para a obtenção do grau de Doutor em Engenharia de Recursos Naturais (D.Eng.)

UTILIZAÇÃO DA TÉCNICA DA ANÁLISE DA ÁRVORE DE FALHAS PARA A
DETERMINAÇÃO DO ALGORITMO HEURÍSTICO GENERALIZADO DE
DIAGNÓSTICO DE FALHAS EM MOTORES DIESEL

Raimundo Nonato da Costa Coelho

Junho/2017

Orientadores: Emanuel Negrão Macêdo

João Nazareno Nonato Quaresma

Área de Concentração: Transformação de Recursos Naturais

O presente trabalho utiliza a técnica da Análise da Árvore de Falhas (AAF) para a determinação do algoritmo heurístico generalizado de diagnóstico de falhas em motores diesel. O sistema físico (motor e seus subsistemas) é transformado em um diagrama lógico estruturado (a árvore de falhas) onde são dispostas as várias combinações de falhas nos elementos ou itens do sistema componentes do motor que possam resultar em evento indesejável. Um conjunto de regras de diagnóstico de falhas é construído baseado, puramente, na termodinâmica do processo de combustão no motor. É buscado o entendimento das interações dinâmicas entre causas e efeitos de falhas que proporcione a indicação da trajetória de cada uma até a sua causa raiz. Com a ajuda de uma Rede Neural Artificial (RNA) adequadamente estabelecida, são feitas inferências sobre o conjunto de regras de diagnóstico para fornecer a condição operacional do motor submetido a diferentes condições de ensaio e os resultados são apresentados na forma de tabelas e gráficos, seguindo a discussão e conclusão.

Abstract of Thesis presented to PRODERNA/UFPA as a partial fulfillment of the requirements for the degree of Doctor of Natural Resources Engineering (D.Eng.)

USE OF THE FAULT TREE ANALYSIS TECHNICAL FOR DETERMINING THE
GENERALIZED HEURISTIC ALGORITHM OF FAULT DIAGNOSTIC IN DIESEL
ENGINES

Raimundo Nonato da Costa Coelho

June/2017

Advisors: Emanuel Negrão Macêdo

João Nazareno Nonato Quaresma

Research Area: Transformation of Natural Resources

The present work uses the Fault Tree Analysis (AAF) technique to determine the generalized heuristic fault diagnosis algorithm in diesel engines. The physical system (motor and its subsystems) is transformed into a structured logic diagram (the fault tree) where the various combinations of failures in the elements or items of the system are components of the motor that may result in an undesirable event. A set of fault diagnosis rules is built purely on the thermodynamics of the combustion process in the engine. It is sought the understanding of the dynamic interactions between causes and effects of failures that provides the indication of the trajectory of each until its root cause. With the help of a properly established Artificial Neural Network (ANN), inferences are made about the set of diagnostic rules to provide the operational condition of the motor under different test conditions and the results are presented in the form of tables and graphs, following the discussion and conclusion.

LISTA DE ILUSTRAÇÕES

Figura 2.1	Esquema universal para a monitoração da condição e diagnóstico de falhas em um sistema mecânico. Fonte: adaptado de Twiddle (2001).....	45
Figura 3.1	O ciclo de operação de um motor diesel de quatro tempos. Fonte: adaptado de Heyhood (1988).....	63
Figura 3.2	Efeito da razão ar/combustível sobre a potência de um motor Diesel. Fonte: adaptado de Ganesan (1999).....	66
Figura 3.3	Desintegração do jato de combustível. Fonte: adaptado de Ganesan (1999).....	67
Figura 3.4	Identificação dos estágios da combustão no diagrama $p \times \theta$. Fonte: adaptado de Martins (2006).....	69
Figura 3.5	A detonação (batida) do motor diesel. Fonte: adaptado de Martins (2006).....	72
Figura 3.6	Efeito da regulagem de injeção de combustível sobre o diagrama $p \times \theta$. Fonte: adaptado de Adams (1949).....	76
Figura 3.7	Efeito da razão de compressão do motor sobre o diagrama $p \times \theta$. Fonte: adaptado de Adams (1949).....	77
Figura 3.8	Efeito das características físico-químicas do combustível sobre o diagrama $p \times \theta$. Fonte: adaptado de Adams (1949).....	78
Figura 3.9	Efeito da pressão do ar de admissão sobre o diagrama $p \times \theta$. Fonte: adaptado de Adams (1949).....	79
Figura 3.10	Efeito da pressão do ar de admissão que sofreu super carregamento sobre o diagrama $p \times \theta$. Fonte: adaptado de Adams (1949).....	80
Figura 3.11	Efeito da carga (quantidade de combustível injetado) no cilindro. Fonte: adaptado de Adams (1949).....	83
Figura 3.12	Efeito da taxa de elevação de pressão no segundo estágio sobre o pico de pressão de combustão. Fonte: adaptado de Ganesan (1999).....	85
Figura 3.13	Representação gráfica de um neurônio. Fonte: Dreyfus (2005).....	92
Figura 3.14	Perceptron de múltiplas camadas. Fonte: Dreyfus (2005).....	94
Figura 3.15	Rede neural com n entradas, uma camada de N_c neurônios escondidos e N_o neurônios de saída. Fonte: Dreyfus(2005).....	94

Figura 3.16	Esquema de treinamento de uma rede neural. Fonte: adaptado de Demuth (1998).....	96
Figura 4.1	Método gráfico para determinação da TEP_{comb} . Fonte: adaptado de Ganesan (1999).....	103
Figura 4.2	Diagrama indicado de pressão de injeção $PI \times \theta$. Fonte: adaptado de Warkman (1983).....	106
Figura 4.3	Sistema de admissão de ar/gás de descarga. Fonte: própria do autor....	108
Figura 4.4	Representação esquemática do motor diesel e seus subsistemas. Fonte: própria do autor.....	113
Figura 4.5	Composição do sistema por blocos. Fonte: própria do autor.....	114
Figura 4.6	Composição do bloco 10. Fonte: própria do autor.....	114
Figura 4.7	Composição do bloco 20. Fonte: própria do autor.....	115
Figura 4.8	Composição do bloco 30. Fonte: própria do autor.....	115
Figura 4.9	Composição do bloco 40. Fonte: própria do autor.....	115
Figura 4.10	Sistema decomposto em blocos. Fonte: própria do autor.....	116
Figura 4.11	Representação do sistema através de seus componentes. Fonte: própria do autor.....	119
Figura 4.12	Árvore de falhas do sistema. Fonte: própria do autor.....	123
Figura 5.1	Topologia da RNA.....	132
Figura 5.2	Histograma de erros dos subconjuntos de dados.....	134
Figura 5.3	Matriz de confusão de classificação de falhas para o subconjunto de treinamento.....	135
Figura 5.4	Matriz de confusão de classificação de falhas para o subconjunto de validação.....	136
Figura 5.5	Matriz de confusão de classificação de falhas para o subconjunto de teste.....	137
Figura 5.6	Matriz de confusão de classificação de falhas para o conjunto total de amostras.....	138
Figura 5.7	Característica de Operação do Receptor para os subconjuntos de treinamento, validação, teste e para o conjunto total de amostras de dados.....	139

Figura 5.8	Resultados do teste de simulação $\text{sim}(\text{netDiagDiesel}, \text{inputs}(:, 134))$	141
Figura 5.9	Resultados do teste de simulação $\text{sim}(\text{netDiagDiesel}, \text{inputs}(:, 14))$	143
Figura 6.1	Diagrama indicado de combustão $p \times \theta$ do cilindro 1 do motor testado para condição de operação MD3. Fonte: MIP Calculator NK-100.....	145
Figura 6.2	Diagrama indicado de injeção $PI \times \theta$ do cilindro 1 do motor testado para condição de operação MD3. Fonte: MIP Calculator NK-100.....	146
Figura 6.3	Resultados da RNA para condição de operação MD3 simulada no motor diesel.....	148
Figura 6.4	Diagrama indicado de combustão $p \times \theta$ do cilindro 1 do motor testado para condição de operação MD5. Fonte: MIP Calculator NK-100.....	150
Figura 6.5	Diagrama indicado de injeção $PI \times \theta$ do cilindro 1 do motor testado para condição de operação MD5. Fonte: MIP Calculator NK-100.....	151
Figura 6.6	Resultados da RNA para condição de operação MD3 simulada no motor diesel.....	153
Figura 6.7	Diagrama indicado de combustão $p \times \theta$ do cilindro 1 do motor testado para condição de operação MD10. Fonte: MIP Calculator NK-100.....	154
Figura 6.8	Diagrama indicado de injeção $PI \times \theta$ do cilindro 1 do motor testado para condição de operação MD10. Fonte: MIP Calculator NK-100.....	155
Figura 6.9	Resultados da RNA para condição de operação MD10 simulada no motor diesel.....	157
Figura 6.10	Diagrama indicado de combustão $p \times \theta$ do cilindro 3 do motor testado para condição de operação MD12. Fonte: MIP Calculator NK-100.....	158
Figura 6.11	Diagrama indicado de injeção $PI \times \theta$ do cilindro 3 do motor testado para condição de operação MD12. Fonte: MIP Calculator NK-100.....	160
Figura 6.12	Resultados da RNA para condição de operação MD12 simulada no motor diesel.....	161
Figura I.1	Esquema típico de turbo compressão de ar de admissão com resfriamento intermediário. Fonte: própria do autor.....	177
Figura II.1	Fluxo do refrigerante em um sistema desprovido de purga de ar. (A) termostato fechado e (B) termostato aberto. Fonte: adaptado de Dempsey (2008)..	178
Figura II.2	Fluxo do refrigerante em um sistema com auto-purga. (A) Termostato fechado e (B) Termostato aberto. Fonte: adaptado de Dempsey (2008).....	179

- Figura II.3** Aplicação marítima usando um trocador de calor resfriado por água do mar e tanque de expansão. Fonte: adaptado de Dempsey (2008).....180
- Figura II.4** Aplicação marítima com um resfriador de quilha. Fonte: adaptado de Dempsey (2008).....181
- Figura II.5** Um radiador, um resfriador e a jaqueta de água constituem o circuito de resfriamento básico. Fonte: adaptado de Dempsey (2008).....181
- Figura III.1** Um sistema de bomba em linha usados nos motores marítimos Lehman baseado em modelo Ford. Fonte: adaptado de Dempsey (2008).....183
- Figura III.2** Montagem do êmbolo, cilindro e cremalheira. A “ranhura helicoidal” usualmente é chamada de hélice. Fonte: adaptado de Dempsey (2008).....184
- Figura III.3** Ação do êmbolo de começo constante e término variável com o combustível excedente saindo pela porta de admissão. Fonte: adaptado de Dempsey (2008).....185

LISTA DE TABELAS

Tabela 3.1	Operadores fundamentais da FTA. Fonte: Limnios (2007).....	88
Tabela 3.2	Eventos na FTA. Fonte: Limnios (2007).....	89
Tabela 3.3	Triângulos de transferência na FTA. Fonte: Limnios (2007).....	89
Tabela 4.1	Regra de diagnóstico para o modo de falha MD1. Fonte: própria do autor.....	126
Tabela 4.2	Regra de diagnóstico para o modo de falha MD2. Fonte: própria do autor.....	126
Tabela 4.3	Regra de diagnóstico para o modo de falha MD3. Fonte: própria do autor.....	126
Tabela 4.4	Regra de diagnóstico para o modo de falha MD4. Fonte: própria do autor.....	126
Tabela 4.5	Regra de diagnóstico para o modo de falha MD5. Fonte: própria do autor.....	126
Tabela 4.6	Regra de diagnóstico para o modo de falha MD6. Fonte: própria do autor.....	127
Tabela 4.7	Regra de diagnóstico para o modo de falha MD7. Fonte: própria do autor.....	127
Tabela 4.8	Regra de diagnóstico para o modo de falha MD8. Fonte: própria do autor.....	127
Tabela 4.9	Regra de diagnóstico para o modo de falha MD9. Fonte: própria do autor.....	127
Tabela 4.10	Regra de diagnóstico para o modo de falha MD10. Fonte: própria do autor.....	127
Tabela 4.11	Regra de diagnóstico para o modo de falha MD11. Fonte: própria do autor.....	128
Tabela 4.12	Regra de diagnóstico para o modo de falha MD12. Fonte: própria do autor.....	128
Tabela 4.13	Matriz de diagnósticos. Fonte: própria do autor.....	129
Tabela 5.1	Detalhes dos parâmetros da rede desenvolvida na plataforma MATLAB. Fonte: própria do autor.....	132

Tabela 5.2	Desempenho individual dos subconjuntos de dados. Fonte: própria do autor.....	133
Tabela 5.3	Resultados do teste <code>sim(netDiagDiesel,inputs(:,134))</code> . Fonte: própria do autor.....	140
Tabela 5.4	Resultados do teste <code>sim(netDiagDiesel,inputs(:,14))</code> . Fonte: própria do autor.....	141
Tabela 6.1	Dados técnicos do motor testado. Fonte: NEW SULZER DIESEL, 1990.....	144
Tabela 6.2	Valores dos parâmetros operacionais, medidos ou derivados de outros, para a condição de operação MD3. Fonte: própria do autor.....	147
Tabela 6.3	Resultados da simulação da RNA para condição de operação MD3 simulada no motor diesel. Fonte: própria do autor.....	147
Tabela 6.4	Valores dos parâmetros operacionais, medidos ou derivados de outros, para a condição de operação MD5. Fonte: própria do autor.....	152
Tabela 6.5	Resultados da simulação da RNA para condição de operação MD5 simulada no motor diesel. Fonte: própria do autor.....	152
Tabela 6.6	Valores dos parâmetros operacionais, medidos ou derivados de outros, para a condição de operação MD10. Fonte: própria do autor.....	156
Tabela 6.7	Resultados da simulação da RNA para condição de operação MD10 simulada no motor diesel. Fonte: própria do autor.....	156
Tabela 6.8	Valores dos parâmetros operacionais, medidos ou derivados de outros, para a condição de operação MD12. Fonte: própria do autor.....	160
Tabela 6.9	Resultados da simulação da RNA para condição de operação MD12 simulada no motor diesel. Fonte: própria do autor.....	160
Tabela A.1	Valores limite dos dados de entrada da RNA. Fonte: própria do autor.....	186
Tabela B.1	Vetores alvo (valores desejados) da RNA. Fonte: própria do autor.....	187

LISTA DE ABREVIATURAS

- p – pressão no cilindro
 V – volume do cilindro
 V_v – volume varrido pelo pistão no interior do cilindro
 V_{cc} – volume da câmara de combustão
 V_t – volume total do cilindro
 θ – ângulo de rotação do eixo de manivelas
 $imep$ – pressão média efetiva indicada
 L – comprimento da biela
 r – raio da manivela
PMI – Ponto Morto Inferior
PMS – Ponto Morto Superior
 C – curso do pistão
 D – diâmetro do cilindro
 n – número de cilindros
 ε – razão de compressão do motor
 p_{me} – pressão média efetiva
 $imep$ – pressão média efetiva indicada
 A – área correspondente ao volume varrido pelo pistão no diagrama indicado $p \times V$.
RNA – Rede Neural Artificial
UCM – Unidade de Controle do Motor
SMA – Sistema de Monitoração da Condição
AAF – Análise da Árvore de Falhas
PMC – Perceptron de Múltiplas Camadas
IC – índice (ou número) de cetanas
 m – quantidade de combustível consumido
 t – unidade de tempo
 A – fator de frequência (independente da temperatura)
 E – energia de ativação (J/mol)
 K – constante universal dos gases (J/mol.K)
 T – temperatura absoluta (K)

P_{max} – pressão máxima de combustão
 TEP_{comb} – taxa máxima de elevação de pressão
 P_{comp} – pressão de compressão
 $\theta_{P_{max}}$ – ângulo da manivela na pressão máxima de combustão
 δT_{cil} – diferencial de temperatura no cilindro
 T_{desc} – temperatura de descarga do cilindro
 T_{adm} – temperatura do ar de admissão
 TS_{agua} – temperatura final da água refrigerante
 TE_{agua} – temperatura inicial da água refrigerante
 PI_{max} – pressão máxima de injeção
 PI_{aber} – pressão de abertura da válvula de injeção
 $\theta_{PI_{aber}}$ – ângulo da manivela na pressão de abertura da válvula de injeção
 Δ_{inj} – período de injeção de combustível
 $T_{pré-aq}$ – temperatura de pré-aquecimento do combustível
 T_{adm} – temperatura do ar de admissão
 P_{adm} – pressão do ar de admissão
 PE_{tc} – pressão na entrada do turbocompressor
 δP_{ic} – queda de pressão no intercooler
 PE_{ic} – pressão na entrada do intercooler
 P_{amb} – pressão do ar ambiente
 T_{amb} – temperatura do ar ambiente
CCAI – Índice de Aromaticidade do Carbono Calculado
 D – densidade do óleo combustível à 15,6 °C
 V – viscosidade do óleo combustível à 50 °C
 ID – índice diesel
 PA – ponto de anilina do diesel
 API – gravidade API
 g_e – gravidade específica à 60 °F

SUMÁRIO

1. INTRODUÇÃO.....	20
2. REVISÃO DA LITERATURA.....	26
2.1. A Monitoração da Condição e o Diagnóstico de Falhas em Sistemas Mecânicos.....	26
2.2. Sistemas de Monitoração da Combustão e Diagnóstico de Falhas em Motores Diesel.....	29
3. REFERENCIAL TEÓRICO.....	38
3.1. Princípios de Operação do Motor.....	38
3.2. Características do Processo de Combustão.....	43
3.3. Estágios da Combustão.....	45
3.3.1. Atraso da Ignição (1-2).....	45
3.3.2. Combustão Rápida (2-3).....	47
3.3.3. Combustão Uniforme (3-4).....	48
3.3.4. Combustão Atrasada (4 em diante).....	49
3.4. Fatores que Influenciam a Combustão no Motor Diesel.....	49
3.4.1. Regulagem de Injeção de Combustível.....	50
3.4.2. Razão de Compressão.....	51
3.4.3. Características Físico-químicas do Combustível.....	51
3.4.4. Pressão do Ar de Admissão.....	52
3.4.5. Temperatura do Ar de Admissão.....	54
3.4.6. Pressão de Injeção de Combustível.....	54
3.4.7. Carga (Quantidade de Combustível Injetado).....	55
3.4.8. Viscosidade do Combustível.....	56
3.4.9. Taxa de Elevação da Pressão no Segundo Estágio da Combustão (TEP _{comb}).....	56
3.5. AAF (Análise da Árvore de Falhas).....	57
3.6. RNA(Rede Neural Artificial).....	62
3.6.1. Algoritmo de Treinamento <i>Backpropagation</i>	66
3.6.2. Classificação (Discriminação).....	68

4. METODOLOGIA APLICADA PARA O DESENVOLVIMENTO DA PESQUISA	70
4.1. Determinação dos Parâmetros Operacionais	70
4.1.1. Parâmetros do Fluido de Trabalho na Unidade de Cilindro	70
4.1.1.1. P_{max} (Pressão Máxima de Combustão)	70
4.1.1.2. P_{comp} (Pressão de Compressão no Cilindro)	71
4.1.1.3. TE_{comb} (Taxa de Elevação da Pressão de Combustão)	71
4.1.1.4. δT_{cil} (Diferencial de Temperatura no Cilindro)	72
4.1.1.5. TS_{agua} (Temperatura Final da Água Refrigerante)	72
4.1.1.6. TE_{agua} (Temperatura Inicial da Água Refrigerante)	72
4.1.2. Parâmetros da Injeção de Combustível	73
4.1.2.1. PI_{max} (Pressão Máxima de Injeção)	74
4.1.2.2. PI_{aber} (Pressão de Abertura da Válvula de Injeção)	106
4.1.2.3. $\theta_{PI_{aber}}$ (Ângulo da Manivela na Pressão de Abertura da Válvula de Injeção)	74
4.1.2.4. Δt_{inj} (Período de Injeção de Combustível)	75
4.1.2.5. $T_{pré-aq}$ (Temperatura de Pré-aquecimento do Combustível)	75
4.1.3. Parâmetros da Admissão de Ar / Descarga de Produtos da Combustão	75
4.1.3.1. T_{adm} (Temperatura do Ar de Admissão)	76
4.1.3.2. P_{adm} (Pressão do Ar de Admissão)	76
4.1.3.3. PE_{tc} (Pressão na Entrada do Turbo compressor)	76
4.1.3.4. δP_{ic} (Queda de Pressão no <i>Intercooler</i>)	76
4.1.4. Parâmetros de Normalização	77
4.1.4.1. P_{amb} (Pressão do Ar Ambiente)	77
4.1.4.2. T_{amb} (Temperatura do Ar Ambiente)	77
4.1.4.3. CCAI (Índice de Aromaticidade do Carbono Calculado)	77
4.1.4.4. ID (Índice diesel)	78
4.2. A Construção da Árvore de Diagnóstico de Falhas pela Técnica da Análise da Árvore de Falhas (AAF)	78
4.2.1. A Definição do Sistema	78
4.2.2. Análise Preliminar	80
4.2.2.1. Decomposição do Sistema	80
4.2.2.2. Identificação dos Componentes	81

4.2.2.3. Definição dos Modos de Falha dos Componentes.....	82
4.2.2.4. Reconstituição do Sistema Pelos Seus Componentes.....	84
4.2.3. Especificações.....	84
4.2.3.1. Fases.....	84
4.2.3.2. Condições de Contorno.....	84
4.2.3.3. Hipótese Específica.....	84
4.2.3.4. Condições Iniciais.....	84
4.2.3.5. Construção.....	84
4.3. A Definição da Heurística para o Diagnóstico de Falhas em Motores Diesel.....	88
5. CLASSIFICAÇÃO DAS FALHAS.....	93
5.1. A Definição do Problema.....	93
5.2. Treinamento, Validação e Teste da Rede Neural Artificial (RNA).....	94
6. RESULTADOS DA UTILIZAÇÃO DA RNA E DISCUSSÕES.....	105
6.1. Estudo de Caso: Condição de Operação Simulada para MD3.....	105
6.2. Estudo de Caso: Condição de Operação Simulada para MD5.....	110
6.3. Estudo de Caso: Condição de Operação Simulada para MD10.....	113
6.4. Estudo de Caso: Condição de Operação Simulada para MD12.....	117
7. CONCLUSÕES E RECOMENDAÇÕES.....	122
REFERÊNCIAS.....	125
ANEXO I – Sistema de Alimentação de Ar de Admissão.....	132
ANEXO II – Sistema de Resfriamento Líquido do Motor.....	134
ANEXO III – Sistema de Injeção de Combustível – Bomba de Impulso.....	138
APÊNDICE A – Tabela com os valores limites dos dados de entrada da RNA	141

APÊNDICE B – Matriz com os vetores alvo (valores desejados) da RNA.....	142
APÊNDICE C – Matriz com os vetores de entrada da RNA.....	143
APÊNDICE D – Algoritmo da RNA desenvolvida.....	156

1. INTRODUÇÃO

A principal dificuldade em se realizar diagnóstico de falhas em motores de ignição por compressão (ICO), ou motores diesel, reside no fato de que estas falhas possuem um comportamento transiente e não linear decorrente da complexidade da estrutura do motor. Além do mais, há o agravante das falhas terem a propensão de causar danos dissimulados. Estas circunstâncias inconvenientes geram incertezas na determinação da causa geradora das falhas, mas podem ser superadas caso haja condição de se fazer a apresentação de possíveis interações entre eventos de falha e disfunções, que nada mais são do que sintomas, e destes com os componentes degradados do motor. A demonstração destas interações proporciona o estabelecimento de leis específicas que governam os eventos prestes a acontecer, ou seja, as causas das falhas que possam resultar em panes em componentes do motor. Estas leis específicas são chamadas de algoritmos de falhas.

Um motor diesel é composto por itens, que, segundo a definição de Anônimo (1994), são “quaisquer partes, componentes, dispositivos, subsistemas, unidades funcionais, equipamentos ou sistemas que possam ser considerados individualmente”. Cada um destes possui uma função ou combinação de funções necessárias para prover um determinado serviço. Quando há desvio em qualquer característica que impeça-o de exercer a sua função requerida, diz-se que o item possui defeito. O término da capacidade de desempenhar a sua função requerida indica que o item está operando em modo de falha. Após a ocorrência da falha, o item entra em pane, caracterizada pela incapacidade permanente de desempenhar a sua função requerida sob condições específicas de operação. Observa-se, portanto, que falha é um evento, enquanto que pane é um estado. Este trabalho considera como item tanto um componente individual, quanto o próprio motor e seus subsistemas, cuja função requerida é a geração de energia mecânica útil (trabalho ou potência).

Existem diversas maneiras de se detectar operação em modo de falha de motores diesel: leituras de temperaturas, pressões, ruídos, odores etc. Entretanto, a simples constatação da condição de operação em modo de falha garante apenas que “alguma coisa está errada” com o motor e que é necessário tomar providências para que o mesmo não entre em pane. A interpretação do comportamento anormal ou inesperado é chamada de diagnóstico e, a partir deste, pode-se determinar a causa geradora da falha, sua natureza e como corrigi-la. A união da detecção com a interpretação deu origem aos Sistemas de

Monitoração da Condição e Diagnóstico de Falhas (SMCDF), cuja finalidade principal é impedir que a falha se transforme em pane, o que traria consequências extremamente sérias em sistemas como o motor diesel em termos de fatalidades humanas, impactos ambientais e perdas econômicas.

De acordo com Gertler (1998), um SMCDF, para sistemas em geral, executa as seguintes tarefas:

- Detecção de falha, isto é, a indicação de falhas presentes no sistema monitorado.
- Isolamento de falha, ou a determinação do tipo, local e momento da detecção de uma falha (ou componente defeituoso). Ocorre depois da detecção de falha.
- Identificação de falha, ou seja, é a determinação da magnitude e do comportamento variável no tempo de uma falha. Vem em seguida ao isolamento.

Porém, o autor, juntamente com Patan (2008), ressalta que, enquanto a detecção é uma necessidade absoluta e o isolamento quase igualmente importante em qualquer sistema prático, a identificação de falha, embora útil, não justifica os esforços extras necessários para determiná-la. Por causa disto, os autores (Gertler, 1998 e Patan, 2008) afirmam que a maioria dos sistemas práticos contém apenas os estágios de detecção e isolamento de falhas, sendo que, em muitos casos, se utiliza apenas “diagnóstico” como sinônimo de “isolamento”. Em motores diesel, o aumento progressivo na severidade sempre proporciona uma fácil detecção da sua condição de operação em modo de falha. Entretanto, a identificação e o seu isolamento envolvem o conhecimento das influências recíprocas de falhas diferentes e destas com os componentes degradados do motor.

A medida que se vai aumentando o volume do conhecimento sobre as influências recíprocas, vai se tornando mais fácil descobrir toda a trajetória da falha até a sua causa raiz. Isto proporciona melhorias no planejamento e execução de manutenção, uma vez que os diagnósticos de falha ficam mais precisos, gerando uma redução no tempo de reparo, além de indicar as falhas que impedem a capacidade do motor diesel de satisfazer aos rigorosos padrões de emissões exigidos pela legislação ambiental. Isto tudo disponibilizado pelo emprego de uma técnica adequada de identificação e isolamento para o diagnóstico de falhas, cujos benefícios oriundos são evidenciados pela possibilidade de se determinar as causas físicas que influenciam os eventos definidores da condição de operação em modo de falha do motor, chamados de sintomas.

Este trabalho se propõe a utilizar eventos ou parâmetros operacionais característicos do processo de combustão para fazer o acompanhamento e avaliação do rendimento do ciclo de operação dos motores diesel. É o que ocorre desde que estes foram inventados pelo engenheiro alemão Rudolf Diesel no século XIX, posto que a eficácia no desempenho da função de produzir potência mecânica pelo ciclo de operação de um motor diesel é diretamente proporcional à eficácia com que o motor executa o seu processo de combustão (MARTINS, 2006). Todavia, aqui, os parâmetros operacionais servirão de qualificadores e quantificadores tanto do desempenho global do motor, quanto de eventos de falha individuais e servirão de sintomas para o algoritmo de falhas. Visa-se criar uma base de conhecimentos que apresente as interações entre eventos de falha, revelados por parâmetros operacionais, e possibilite a realização de diagnóstico de falhas em motores diesel. A motivação básica é proporcionar disponibilidade e confiabilidade contínua na mais alta eficiência de desempenho do ciclo de operação de um motor diesel realizando adequadamente a Monitoração da Condição e Diagnóstico de Falhas (MCDF), tanto de forma manual quanto automatizada.

O objetivo geral deste trabalho é desenvolver um entendimento das interações dinâmicas entre causas e efeitos de falhas, mostrando a trajetória de cada uma até a sua causa-raiz. Para tal, utiliza-se a técnica da Análise da Árvore de Falhas (AAF), que é uma metodologia dedutiva que apresenta sistematicamente, etapa por etapa, a interação entre todos os eventos de falha causadores de um evento indesejável. Em outras palavras, a AAF transforma um sistema físico, no caso o motor e seus subsistemas, em um diagrama lógico estruturado, a árvore de falhas, onde são dispostas as várias combinações de falhas nos elementos componentes do sistema (componentes do motor) que possam resultar em um evento indesejável. Isto proporciona um entendimento das interações dinâmicas entre causas e efeitos de falhas, mostrando a trajetória de cada uma até a sua causa raiz.

Mais especificamente, objetiva-se:

- Rever a prática e a aplicação passada e atual dos sistemas de monitoração da condição e diagnóstico de falhas na área de aplicação de motores diesel;
- Estabelecer, baseado puramente na termodinâmica do processo de combustão, os parâmetros operacionais que indiquem o desempenho do motor;

- Tendo como base os parâmetros operacionais que indicam o desempenho do motor, construir um conjunto de regras de diagnóstico de falhas a partir da AAF para servir de base de conhecimento para a máquina de inferência adotada;
- Construir um algoritmo de Rede Neural Artificial (RNA) para fazer inferências sobre o conjunto de regras de diagnóstico e fornecer a condição operacional do motor e detectar uma falha antes que ela se desenvolva para um nível mais severo. Uma revisão em pesquisas anteriores neste campo mostrou que a arquitetura de RNA mais adequada para sistemas não-lineares é a Perceptron de Múltiplas Camada (PMC). A precisão de uma RNA depende fundamentalmente da quantidade de dados disponíveis que, no caso deste trabalho, são os parâmetros operacionais capazes de detectar e avaliar a condição do motor e possíveis falhas.

A opção por RNA para fazer inferências sobre a base de conhecimentos a ser gerada se dá, principalmente, pelas limitações que os métodos computacionais tradicionais apresentam devido à sua natureza sequencial própria, além do baixo nível de êxito obtido no problema da MCDF em motores diesel. Isto deu espaço para a consideração de alternativas, como as RNA's, cuja natureza básica é de modelo matemático de processamento de informação que fornece um método de representação de relações bastante diferente dos computadores com programas armazenados. Suas vantagens sobre as outras técnicas, tais como os métodos numéricos, são o processamento paralelo e compacto usando funções simples, sua adaptabilidade e sua capacidade de aprender e ser treinada.

As RNA's são algoritmos que podem modelar o comportamento de complicados processos não lineares sem precisar de formulação explícita das relações físicas do problema em questão. Em outras palavras, precisam apenas de exemplos do assunto pertinente que se está tratando. Em geral, são treinadas para resolver problemas de difícil solução para computadores convencionais ou seres humanos, realizando funções complexas em vários campos de aplicação, incluindo classificação, reconhecimento de padrão, identificação, voz, visão e sistemas de controle.

Nos SMCDF são empregadas como classificadoras para analisar dados do motor diesel na condição de motor novo (dados-padrão) a fim de associá-los com certas condições de falha ou, até mesmo, condições de operação normal. Neste tipo de abordagem, o treinamento da classificadora com dados apropriados gera um

armazenamento de informação sobre o sistema que pode ser considerado como base de conhecimento. Em uma RNA classificadora primária, isto é, aquela usada para a análise de dados primários ou brutos, a base de conhecimento e o algoritmo de raciocínio estão contidos dentro da mesma estrutura. Este tipo de sistema “caixa preta” geralmente é eficiente na aprendizagem por dados, ao passo que sistemas baseados em princípios são melhores em modelagem.

A contribuição principal desta pesquisa, que a diferencia de outros trabalhos desenvolvidos, é a construção de um conjunto de regras de diagnóstico de falhas utilizando como sintomas os parâmetros operacionais que refletem as propriedades termodinâmicas do ciclo de operação do motor diesel.

A partir do emprego da técnica da AAF se consegue transformar um sistema físico – o motor e seus subsistemas – em um diagrama lógico estruturado – a árvore de falhas – onde são dispostas as várias combinações de falhas nos elementos do sistema, ou itens componentes do motor, que possam resultar em um evento indesejável.

A técnica também proporciona a construção de um conjunto de regras de diagnóstico de falhas bem mais discretizados, identificando a trajetória da falha e a localização do item defeituoso no sistema. Além disso, por ser baseado puramente na termodinâmica do processo de combustão no motor, o conjunto de regras de diagnóstico pode servir de base de conhecimento para qualquer metodologia de diagnóstico adotada. Também, pela própria estrutura da árvore de falhas, pode processar falhas múltiplas ou mutuamente comuns e realizar uma análise quantitativa da probabilidade de ocorrência de falhas e estudos de confiabilidade.

Visando uma fácil compreensão, a tese foi construída da seguinte forma:

O Capítulo 1 introduz o contexto, assim como a motivação, objetivos e contribuição da pesquisa.

O Capítulo 2 apresenta a revisão da literatura e a discussão sobre pesquisas anteriores no campo da monitoração da condição e diagnóstico de falhas do motor diesel. Isto proporciona ao leitor uma classificação dos diferentes métodos usados para construir os sistemas de monitoração da condição e diagnóstico de falhas desde os anos de 1970 até as técnicas recentes disponíveis.

O Capítulo 3 mostra os princípios teóricos mais relevantes do processo de combustão do motor diesel e da AAF de forma que possam ser aplicados apropriadamente

para a construção de regras de diagnóstico e monitoração de desempenho. As limitações e as razões para a seleção de RNA para o algoritmo proposto são resumidas no final do capítulo.

No Capítulo 4 são descritos em detalhes os parâmetros operacionais que indicam o desempenho do motor diesel e a construção da árvore de falhas. Também explica como foi feita a determinação do conjunto de regras de diagnóstico.

O Capítulo 5 mostra o princípio pelo qual a topologia da RNA foi selecionada e como ela satisfaz à complexidade e não-linearidade do motor diesel. Além disto, também foi incluída uma descrição detalhada da técnica usada para treinar a RNA para a detecção e o diagnóstico de falha. São avaliadas as etapas de treinamento, validação e teste.

Utilizando resultados experimentais do motor, o Capítulo 6 mostra quatro estudos de caso realizando as discussões pertinentes.

Um resumo dos resultados do presente trabalho é feito no Capítulo 7, juntamente com sugestões para trabalhos futuros.

As especificações técnicas para o sistema de alimentação de ar de admissão de um motor diesel são apresentadas no Anexo I e do resfriamento do motor no Anexo II. O Anexo III apresenta o sistema de injeção de combustível considerado neste trabalho.

No Apêndice A está a tabela com os valores de operação padrões do motor.

No Apêndice B encontra-se a tabela com os vetores alvo (valores desejados) da RNA.

No Apêndice C está a matriz com os vetores de entrada da RNA.

O Apêndice D contém o algoritmo da RNA.

2. REVISÃO DA LITERATURA

O objetivo deste capítulo é apresentar as fontes bibliográficas que expõem uma revisão dos princípios teóricos e dos estudos experimentais que produziram resultados mais relevantes para o entendimento e aplicação de um SMCDF em motores diesel. Tais estudos são analisados de forma que possam ser aplicados apropriadamente na construção de um conjunto de regras de diagnóstico que envolva o conhecimento das interações dinâmicas entre os diferentes eventos de falhas e destes com os itens ou componentes que causam a pane do motor, produzindo com isto um resultado mais eficiente e preciso no diagnóstico.

2.1. A Monitoração da Condição e o Diagnóstico de Falhas (MCDF) em Sistemas Mecânicos

Um sistema universal para a monitoração da condição de operação e diagnóstico de falhas em sistemas mecânicos é constituído por uma base de conhecimento, um algoritmo de raciocínio e a aquisição de dados característicos do processo do sistema. Segundo Twiddle (2001), a sua execução resume-se em analisar os dados adquiridos, relacionando-os à informação contida na base de conhecimento, utilizando para isto um algoritmo de raciocínio adequado. A saída do algoritmo revela a condição inferida do sistema (ver Figura 7).

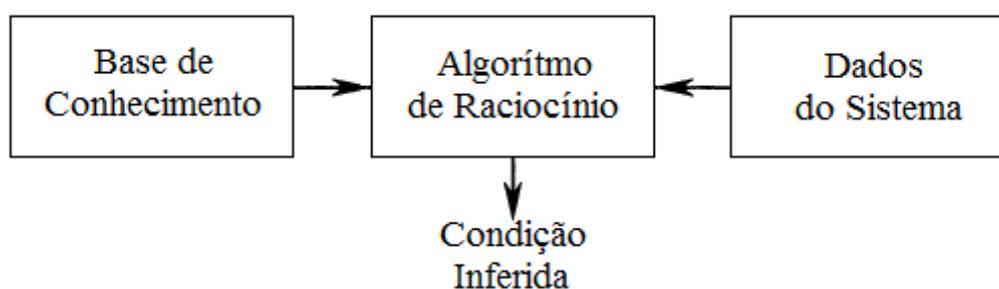


Figura 2.1 – Esquema universal para a monitoração da condição e diagnóstico de falhas em um sistema mecânico. Fonte: adaptado de Twiddle (2001).

A base de conhecimento é, na realidade, um conjunto de instruções que define o relacionamento ou dependência existente entre fatos e atributos inerentes ao sistema. Os

dados do sistema são os fatos mostrados como parâmetros operacionais. No algoritmo de raciocínio são feitas as inferências para se determinar a condição de operação do sistema.

Patan (2008) observa que o algoritmo de raciocínio decide quando uma parte específica do conhecimento capturado na base de conhecimento deve ser usada para a resolução de um problema. Segundo o autor, isto dá ao sistema de monitoração da condição e diagnóstico de falhas a capacidade de determinar, de maneira lógica, a condição de operação pelo registro de informações, identificações e indicações de anomalias no comportamento do sistema físico. Esta incumbência de determinar o possível estado de funcionamento de um sistema físico é chamada de monitoração da condição, que se completa com o diagnóstico de falhas, definido como a determinação do tipo, dimensão, localização e momento de detecção da falha pela estimativa dos sintomas.

O diagnóstico de falhas sucede à detecção e inclui identificação e isolamento de falha. A fase de detecção é onde se decide se ocorreu ou não a falha. Já o isolamento informa a localização, o que requer que a falha seja separada ou conhecida distintamente e, por fim, a identificação, que abrange a determinação da dimensão e do momento de ocorrência da falha. Contudo, segundo Isermann (2011), a fase de identificação aparece raramente, sendo incorporada na fase de isolamento e isto faz com que, na prática, o processo de diagnóstico inclua apenas duas fases: a detecção e o isolamento da falha. Em outras palavras, um sistema de monitoração da condição e diagnóstico de falhas pode ser visto como uma sequência que envolve os processos de aquisição dos sintomas e de determinação do diagnóstico propriamente dito.

Os métodos mais tradicionais de detecção e isolamento de falhas são baseados em técnicas de processamento de sinais, que não consideram as inter-relações dinâmicas entre os sinais medidos do sistema, resultando na geração de numerosos alarmes falsos (SOBHANI-TEHRANI e KHORASANI, 2009). Para superar esta inconveniência e detectar e isolar confiavelmente falhas (isto é, componentes defeituosos) em um sistema, torna-se necessário utilizar algum tipo de redundância, empregada basicamente para efetuar checagens consistentes entre múltiplas medições mutuamente relacionadas no sistema. Segundo Sobhani-Tehrani e Khorasani (2009), nestes tipos de método, a redundância é obtida com o emprego de hardware extra, sendo chamada tanto de redundância de hardware quanto de redundância física/paralela e, mesmo tendo alta performance e seja bastante confiável, o método importa em equipamento extra e custo

maior de manutenção, necessitando, também, de espaço para o hardware extra, que pode ter muita importância em algumas aplicações. Além disto, é impraticável e não confiável em aplicações onde a duplicação de um componente específico é extremamente difícil.

Com a vantagem de não necessitar de cópias adicionais de hardware, nos anos de 1970 surgiram métodos que produzem redundância por um modelo analítico (ou matemático) do componente ou do processo total monitorado e são conhecidos como sistemas de diagnóstico de falhas baseados em modelos.

De acordo com Sobhani-Tehrani e Khorasani (2009), nestes métodos, a relação matemática imposta pelo modelo analítico do sistema, entre a mesma variável do sistema com valores diferentes, serve como ponto de referência para o diagnóstico de falhas. Mais especificamente, sempre que medições realizadas no sistema estiverem violando estas relações, conclui-se pela presença de uma falha (ou componente defeituoso) no sistema.

Para Sobhani-Tehrani e Khorasani (2009), a violação das relações analíticas após a ocorrência de uma falha se reflete em um conjunto de sinais conhecidos como resíduos, que num contexto ideal igualam-se a zero no caso de sistema em condições de operação “saudáveis” e desviam-se de zero quando em modo de falha. Contudo, devido à presença de ruídos e perturbações nas medições, os sistemas podem ser considerados “saudáveis” com os valores dos sinais situando-se na vizinhança de zero e em modo de falha quando excedem um valor inicial, o *threshold*, da fronteira de zero.

Sobhani-Tehrani e Khorasani (2009) afirmam que devido a estes fatos o diagnóstico de falhas baseado em redundância analítica pode ser definido como a detecção e identificação de falhas em um sistema através da estimativa do valor e da análise de sinais residuais. A geração de resíduos visa gerar sinais residuais usando medições de entrada/saída disponíveis do sistema monitorado. É, em essência, um procedimento para extrair sintomas de falhas a partir de medições efetuadas no sistema. No estágio de estimativa residual, examinam-se os resíduos gerados da assinatura de falha e a presença desta é determinada pela aplicação de uma regra de decisão, que pode ser simplesmente um teste de valor mínimo de sinal (*threshold*) sobre o valor instantâneo ou médio dos resíduos ou pode consistir de métodos estatísticos mais complexos.

Para Twiddle (2001), os SMCDF propostos para sistemas mecânicos se diferenciam apenas nas técnicas aplicadas para a construção dos componentes do esquema universal. A estrutura de armazenamento de conhecimento utiliza modelos,

árvore de falhas, limites de dados, espectros de sinais, etc. As regras dos algoritmos de raciocínio são estabelecidas por lógica fuzzy ou booleana e heurísticas. A obtenção dos resultados é feita por diferentes especificações de dados. As bases de conhecimento são geradas a partir da experiência em reconhecimento de falhas de engenheiros e técnicos de manutenção, dos relatórios de manutenção e reparos ou de outras informações existentes, tais como árvore de falhas, manuais de manutenção, etc. Outros sistemas se desenvolvem a partir de dados do processo adquiridos em ensaios.

Como o principal objetivo dos SMCDF em sistemas mecânicos é a determinação do local e do momento da ocorrência de possíveis falhas baseado em dados acessíveis e no conhecimento do comportamento do processo de diagnóstico, estes tornam-se extremamente dependentes da base de conhecimento. Isto quer dizer que para lograr êxito na tarefa de diagnosticar falhas (detectar, localizar, isolar), é imprescindível que o conhecimento armazenado mostre causas e efeitos de possíveis falhas de maneira discretizada por características do processo do sistema fáceis de obter, mensurar e relacionar.

A forma mais primitiva de (MCDF) é a planilha de registro dos vários parâmetros operacionais do sistema. Outra concepção primitiva é a que usa o raciocínio do especialista em manutenção, que construiu uma base de conhecimento através de experiência e aprendizagem estruturada a partir de livros, manuais, etc., para inferir falhas baseado na informação obtida via visão, audição, olfato, etc.

A partir do desenvolvimento e grande disponibilidade de transdutores robustos e razoavelmente baratos e de sistemas computacionais capazes de armazenar e processar uma grande quantidade de dados, com competência de reconhecer padrões complexos que podem representar deterioração ou perigo real, estes tipos de monitoração primitiva sofreram mudanças radicais, que superaram as suas muitas limitações. Estas mudanças resultaram em métodos automatizados de inferência de dados sintomáticos para o diagnóstico de falhas.

2.2. Sistemas de Monitoração da Combustão e Diagnóstico de Falhas (SMCDF) em Motores Diesel

Por serem sistemas mecânicos, os motores diesel são vulneráveis à falhas, disfunções e, de forma geral, modos inesperados de comportamento que ocorrem devido

à desgates e panes inerentes à sua operação. Por causa desta característica nada favorável, existe uma necessidade contínua por sistemas de monitoração confiáveis e universais baseados em estratégias de diagnóstico de falhas adequadas e eficazes. Além de evitar as perdas econômicas com a substituição indevida de componentes não danificados, podem ser empregados para indicar falhas que prejudiquem a capacidade do sistema de satisfazer aos rigorosos padrões estipulados pela legislação ambiental.

O comportamento transiente, não-linear é, historicamente, difícil de verificar devido à complexidade tanto da instrumentação necessária, quanto da estrutura dessas máquinas. A técnica geral usada para realizar a monitoração da combustão e o diagnóstico de falhas é obter os parâmetros operacionais e depois compará-los aos dados fornecidos pelos fabricantes ou por testes de bancada em motores que acabaram de sofrer um processo de recondicionamento ou por modelos matemáticos do motor e tirar conclusões. A maioria das metodologias apresentadas nos trabalhos que têm relevância para a monitoração da combustão e diagnóstico de falhas define falha no sentido lato, não envolvendo o conhecimento das interações dinâmicas entre falhas diferentes e destas com os defeitos localizados nos componentes do motor.

Publicados inicialmente para descrever o desenvolvimento dos sistemas de instrumentação para a monitoração dos motores diesel, trabalhos como os de Langballe *et al.* (1975), Fredriksen (1976) e Terano (1976) mostraram a possibilidade e vantagem de se monitorar o processo e os componentes diretamente por meio de sensores especiais para fornecer uma monitoração da combustão mais eficiente do que aquela baseada em informações derivadas de medições físicas indiretas. O desenvolvimento destes sistemas de monitoração envolveu a pesquisa de detalhes no mecanismo de falhas em motores diesel e como eles se comportam em um largo campo de condições de operação e longo período de tempo.

A partir daí surgiram os métodos estatísticos como mecanismo de inferência sobre as bases de conhecimento. Estas eram compostas por parâmetros operacionais de referência expressos sob a forma de curvas, denominadas de curvas de referência, com valores apresentados em função dos chamados parâmetros de carga (rotação e potência do motor). Em trabalhos como o de Holtrop e Menner (1978), análise de resíduos das medições efetuadas era feita pelo método da imposição de limites de *thresholds* sobre a variação de sinal para detectar o desvio do sinal normal. Vincent e Turnbull (1986)

utilizaram o método estatístico conhecido como variáveis pseudodiscretas, que atualizava os limites das variáveis operacionais monitoradas do motor, para fazer a análise residual.

Warkman (1983), mesmo empregando a metodologia de análise estatística, inovou apresentando um trabalho em que foi incluída a monitoração do sistema de injeção do motor, fundamental para o processo de combustão.

Apesar de haverem métodos estatísticos mais complexos, há muita restrição na sua aplicação, pois é quase impossível correlacionar apropriadamente a condição real do motor àquelas obtidas em testes e, mesmo que isto seja conseguido, é muito difícil detectar a causa real de uma falha no motor. Além disto, se obtém pouca informação acerca da regulagem do motor, que é extremamente importante, pois um baixo desempenho não necessariamente pode ser causado por um componente do motor.

Lakshminarayanan e Aghav (2009) apontam as vantagens de se utilizar modelos matemáticos de operação de um motor diesel para a realização da análise de resíduos:

- Realização de estudos paramétricos sobre cada variável;
- Análise de extenso campo de condições de contorno;
- Separação dos subprocessos;
- Disponibilização dos resultados com informações detalhadas; e
- Economia de custo e tempo.

O trabalho pioneiro de Whitehouse e Sareen (1974) apresentou um modelo termodinâmico zerodimensional que prevê a taxa de liberação de calor através de submodelos empíricos, utilizando equações matemáticas simples, uma vez que a câmara de combustão, considerada zerodimensional, impediu uma modelagem detalhada de subprocessos físicos e químicos, fortemente afetados pela distribuição de temperatura e composição espacial não decomposta.

Trabalhos posteriores de Bracco *et al.* (1976), Diwakar (1981), Gosman (1985), Baker e Assanis (1994), Reitz e Rutland (1995) e Ogawa *et al.* (1997) apresentaram modelos CFD (Dinâmica dos Fluidos Computacional, em inglês) multidimensionais, baseados em soluções resolvidas localmente de conservação de massa, energia, quantidade de movimento para a mistura combustível-ar no cilindro do motor, incluindo submodelos detalhados para *spray* e fenômenos da combustão. Segundo Lakshminarayanan e Aghav (2009), os modelos CFD são de imensa utilidade para avaliar

o mecanismo de *spray* diesel, mas são muito difíceis de compreender durante a simulação completa de um motor diesel, além de ter um alto custo computacional.

Por serem mais práticos para se descrever a combustão, tornando mais realista a avaliação da influência dos parâmetros construtivos sobre as variáveis de operação do motor diesel (STIESCH, 2003), os modelos fenomenológicos foram utilizados com foco no desempenho e transferência de calor sobre os componentes do motor (ASSANIS e HEYWOOD, 1986), ou na pressão de combustão (CONNOLLY e YAGLE, 1994), ou nos efeitos do transdutor de pressão sobre o diagrama de pressão no cilindro (HOUNTALAS e ANESTIS, 1998), ou nos efeitos dos parâmetros termodinâmicos sobre o processo de combustão no motor (RAKOPOULOS e GIAKOUMIS, 1998) ou nas estimativas das propriedades termodinâmicas do gás para diagnóstico (LAPUERTA *et al.*, 1999).

Um dos primeiros métodos propostos criados para monitorar o desempenho do motor diesel em tempo real, baseado na termodinâmica e na modelagem do motor, foi proposto por Shamsolmaali e Banisoleiman (1994). Embora este modelo de sistema de monitoração tenha procurado diagnosticar falhas, a formação detalhada do caminho entre causas e falha não foi possível.

Outro trabalho original desenvolvido para a monitoração do desempenho e o diagnóstico de falhas foi proposto por Hountalas e Kouremenos (1999). O método é totalmente automático, baseado na termodinâmica, na modelagem fenomenológica do motor e de seus subsistemas e no processamento de dados medidos no motor. O modelo de simulação fornece o comportamento do motor no estado de referência e depois é usado para a determinação das modificações exigidas para prever a condição real do motor. Várias constantes são usadas para representar principalmente parâmetros geométricos do motor e de seus subsistemas, sendo que o procedimento de diagnóstico é baseado na determinação do valor dessas constantes no estado real do motor e na comparação com seus valores determinados em uma condição de motor novo.

Embora este seja, provavelmente, um dos principais trabalhos de pesquisa sobre a monitoração e o diagnóstico de falhas em motores diesel, sua aplicação é limitada devido à dificuldade de relacionar a causa da falha ao componente do motor, ou seja, descrever a trajetória percorrida pela falha até a sua causa-raiz. Estas limitações são decorrentes da dificuldade de se analisar falhas múltiplas e independentes, uma vez que

os seus efeitos combinados podem ocultar os sintomas característicos de algumas delas. Além do mais, há a possibilidade de um choque de efeitos, no qual o desenvolvimento de uma falha pode resultar no mau funcionamento de outras partes do sistema, complicando, assim, o processo de diagnósticos.

Outros trabalhos importantes, mas sem a mesma relevância, foram os de Hountalas (2000), que simula falhas para prever o desempenho do motor, e o de Lawrence e Kortekaas (2001), criado para fins didáticos de apresentação do ciclo de operação e do sistema de resfriamento do motor.

A necessidade de se realizar análises de causas e efeitos de falhas simples ou múltiplas em motores diesel fez com que alguns pesquisadores lançassem mão de métodos de identificação de riscos associados à sua operação. O resultado destes métodos consiste de uma lista de fontes potenciais de perigo, ou seja, os iniciadores de acidentes (falhas de componentes, desvio de processos, eventos externos, erros do operador) que tem probabilidade de ocorrência diferente de zero e potencial para consequências significativas (ZIO, 2007). Em geral, estes métodos consistem de uma análise qualitativa do sistema e de suas funções dentro de uma estrutura sistemática de procedimentos.

A primeira tentativa de se organizar regras de diagnóstico e fazer a sua distribuição em uma matriz de diagnósticos de falhas através de métodos de identificação de riscos associados à operação foi feita por Fagerland *et al.* (1979) e posteriormente por Tenekedjiev *et al.* (1996) que utilizaram a AMEF (Análise de Modos e Efeitos de Falhas), que é uma técnica qualitativa e de natureza indutiva que visa identificar os modos de falha dos componentes do motor.

Apesar de ser de fácil aplicação, a AMEF é bastante restrita, pois considera apenas os efeitos de falhas simples, que são circunstâncias em que um componente do sistema está se comportando anormalmente e pode ser localizado sem grandes dificuldades. Em geral, na AMEF não existe indicação de risco associado com falhas de causas múltiplas ou comuns. Para a análise ser coerente, são atribuídos os mesmos modos de falha, com a mesma qualificação de probabilidade, para componentes similares.

Devido a esta inaptidão, passou-se a utilizar a Análise da Árvore de Falhas (AAF), cuja metodologia para o estudo dos fatores que causam um evento indesejável revê sistematicamente todos os modos de falhas dos componentes do sistema e seus efeitos sobre outros componentes, bem como determina os componentes cujas falhas têm efeito

crítico sobre a operação do sistema (ZIO, 2007). A AAF é uma técnica dedutiva que transforma o sistema físico, no caso o motor diesel e seus subsistemas, em um diagrama lógico estruturado (a árvore de falhas), onde são dispostas as várias combinações de falhas dos elementos do sistema que possam resultar em um evento indesejável (evento topo).

O primeiro trabalho propondo a AAF como ferramenta de organização das regras de diagnóstico para um motor diesel foi publicado por Perakis e Inözu (1990). Em seguida, Shansolmaali e Banisoleiman (1994) também utilizaram a AAF ao introduzirem os requisitos para um ambiente de desenvolvimento de programas de computador em tempo real, destacando a deficiência de uma ferramenta em particular (MUSE), para o desenvolvimento de uma aplicação da monitoração condição operacional de um motor diesel.

Coelho (1999), utilizando a técnica da AAF, organizou um conjunto de regras de diagnóstico de falhas em motor diesel que serviu de base de conhecimento para um sistema especialista.

Combinando as vantagens do processamento distribuído e habilidade de auto-aprendizagem das Redes Neurais Artificiais (RNA's) e das características diretas, lógicas e claras do diagnóstico por AAF, Yingying Wang *et al.* (2012) discutem técnicas de diagnóstico e fazem uma análise específica de falhas em uma caixa de controle de um sistema de controle e fornecem o modelo de sistema especialista de diagnóstico de falhas.

Através da AAF, Belizário e Souza (2013) estudaram a probabilidade de ocorrência da combustão fora de estequiometria em um motor adaptado para operar com um kit diesel-gás (*dual fuel*). Para realizar a análise, foi necessário dividir o motor em subsistemas, mostrando sua árvore funcional, e integrar o kit diesel-gás neste sistema e observou-se o surgimento de novos modos de falha com grande ocorrência e severidade.

Nyan Win Aung *et al.* (2014) fizeram uma AAF qualitativa do sistema de resfriamento de um motor diesel marítimo a bordo de um navio e utilizaram a probabilidade Fuzzy para determinar a probabilidade de falha dos eventos básicos desta AAF visando evitar superestimativas e subestimativas e dar resultados mais confiáveis e razoáveis na análise quantitativa do sistema.

Laskowski (2015) modelou a estrutura de confiabilidade de um motor diesel marítimo utilizando Diagrama de Confiabilidade e AAF. Apresentou também maneira de criar modelos de sistemas com o emprego de AAF. A árvore principal descreve a

análise da estrutura de confiabilidade do motor e as subárvores modelam eixo de manivelas, eixo de cames, cilindros e turbocompressor, conduzindo uma análise de confiabilidade qualitativa da árvore, determinando as séries de corte (*cut sets*) do sistema.

Naik e Singh (2016) discutem os benefícios e limitações do uso de AAF's, aplicando a técnica em um motor diesel monocilíndrico vertical. A análise de falhas concentrou-se no bloco do motor, mais especificamente no cabeçote e nas válvulas do cilindro. Dividiram as causas de pane em técnicas, como exemplo um filtro de combustível danificado, um motor diesel que operou com gasolina no passado ou a alteração na razão de compressão etc., e fatores humanos, tais como furos adicionais feitos, nenhuma limpeza e reparos por longo tempo etc.

A utilização de RNA's no campo da MCDF de motores diesel cobre várias áreas. Yusaf *et al.* (2010) usaram a modelagem por RNA para prever a potência no eixo, o torque, o consumo específico e as emissões de descarga de um motor diesel monocilíndrico quatro-tempos, modificado para operar com uma combinação entre CNG (Gás Natural Comprimido) e diesel.

Jian-Da Wu *et al.* (2010) propõem um sistema de reconhecimento de falha baseado na pressão do coletor de admissão do motor usando GRNN (Rede Neural de Regressão Generalizada) e RBF (Rede de Função Radial) e compara os efeitos da utilização da utilização de ambas.

Porteiro *et al.* (2011) apresentam um sistema de diagnóstico de falhas Multirede Neural para fornecer a estimativa de potência e identificação de oito tipos diferentes de falhas. Utilizaram sensores de temperatura e sinais de vibração para obter os dados que serviram de entrada para treinar uma RNA de três níveis projetada para estimar a carga do motor, sua condição de operação (normal e falha) e identificar a causa da falha.

Uzun (2012) usou dados de rotação, carga e ângulo da manivela de um motor diesel para treinar e testar um modelo de RNA para realizar estudos paramétricos sobre o consumo específico do motor.

Bolan Liu *et al.* (2013) apresentam uma RNA *backpropagation* para identificar falha na ignição de um motor diesel turbocarregado de acordo com parâmetros de operação do motor selecionados por AAF.

Uzun (2014) desenvolveu, configurou e testou um modelo de RNA como método mais rápido, seguro e robusto de determinar os efeitos do processo de resfriamento intermediário da massa de ar de admissão sobre o desempenho de um motor diesel.

Tayarani-Bathaie *et al.* (2014) apresentam um esquema de detecção e isolamento de falhas baseado em uma RNA. O esquema de detecção e isolamento de falha consiste de múltiplas RNA's dinâmicas ou bancos de filtros paralelos que correspondem aos vários modos de operação da condição do motor em modo falha ou "saudável". O diagnóstico de falhas é feito com o uso dos resíduos gerados pelas medições.

Roy *et al.* (2014) desenvolveram um modelo de RNA para prever consumo específico de combustível, eficiência térmica, níveis de CO₂, NO_x e particulado utilizando como parâmetros de entrada para a rede a carga, pressão de injeção de combustível, EGR (Recirculação do Gás de Descarga) e combustível injetado por ciclo em um motor diesel.

A pesquisa na literatura técnica pertinente à monitoração da condição e diagnóstico de falhas em motores diesel mostra que há uma base bem estabelecida de metodologias no campo da detecção de falhas, porém, no que tange o isolamento de falhas, há uma lacuna que necessita ser preenchida para a indicação confiável de causas e efeitos de falhas em motores diesel.

Neste trabalho pretende-se preencher essa lacuna dando uma contribuição para a resolução do problema da falta de discretização no isolamento de falhas. Para isto, se propõe a construção de um conjunto de regras de diagnóstico (algoritmo heurístico) baseado em um modelo de árvore de falhas cujas premissas são parâmetros operacionais mensuráveis obtidos por diagramas indicados de pressão de combustão e pressão de injeção e por medições diretas em pontos do motor e de seus subsistemas e que refletem as propriedades termodinâmicas básicas do processo de combustão do motor.

Os trabalhos relevantes sobre a detecção e isolamento de falhas em motores diesel utilizam a técnica da AAF apenas para a realização de estudos de confiabilidade baseados na estatística de falhas cujos eventos são qualitativos, não havendo um entendimento das interações dinâmicas entre causas e efeitos de falhas, mostrando a trajetória de cada uma até a sua causa-raiz.

Com o emprego da técnica da AAF consegue-se transformar um sistema físico (o motor e seus subsistemas) em um diagrama lógico estruturado (a árvore de falhas) e com isto se dispõe das várias combinações de falhas nos elementos do sistema, ou itens

componentes do motor, que possam resultar em um evento indesejável. A técnica também proporciona a construção de um conjunto de regras de diagnóstico de falhas bem mais discretizados, identificando a trajetória da falha e a localização do item defeituoso no sistema. Além disso, por ser baseado puramente na termodinâmica do processo de combustão no motor, o conjunto de regras de diagnóstico pode servir de base de conhecimento para qualquer metodologia de diagnóstico adotada. Também, pela própria estrutura da árvore de falhas, pode processar falhas múltiplas ou mutuamente comuns e realizar uma análise quantitativa da probabilidade de ocorrência de falhas e estudos de confiabilidade.

3. REFERENCIAL TEÓRICO

Neste capítulo são apresentadas as bases teóricas necessárias para a extração dos parâmetros operacionais que possibilitem a mensuração da condição de operação de um motor diesel.

3.1. Princípios de Operação do Motor

Apesar de passar por evolução contínua desde os tempos de sua invenção no século XIX, o motor diesel mantém os princípios básicos de operação:

- O volume varrido é criado por um pistão evoluindo dentro de um cilindro;
- O movimento do pistão é controlado por um sistema biela-manivela;
- A energia é fornecida ao motor por meio de um combustível líquido;
- Fornece energia ao exterior através de um eixo girante.

Por ser uma máquina térmica, o motor diesel queima combustível e produz trabalho para ser fonte de potência tanto para locomoção de veículos como para a geração de energia elétrica. O trabalho produzido, apresentado como torque, é a transformação da energia térmica resultante da energia química do combustível liberada pela combustão da mistura ar-combustível. A trajetória da transferência de trabalho em meio físico pode ser resumida da seguinte forma: inicialmente a energia térmica liberada pela combustão da mistura ar-combustível é transferida ao fluido de trabalho e causa um aumento na pressão dentro do cilindro que irá atuar sobre a coroa do pistão para forçá-lo para baixo e se propagar pelo pino do pistão para a biela que imprime um movimento circular na manivela. Portanto, há transformação de movimento linear alternativo do pistão dentro do cilindro em movimento rotativo no eixo de manivelas.

Quando o pistão desce do PMS (Ponto Morto Superior) até o PMI (Ponto Morto Inferior) ele “varre” um volume correspondente a um cilindro cuja base é a sua seção transversal e a altura é o curso do pistão, chamado de volume varrido ou cilindrada (V_v). A soma dos volumes varridos de todos os cilindros chama-se de cilindrada do motor (V). Se um motor tiver um número n de cilindros de diâmetro D e curso C , a sua cilindrada será (HEYHOOD, 1988):

$$V = \frac{n \cdot C \cdot D^2 \cdot \pi}{4} \quad (01)$$

Quando o pistão se encontra no PMS, existe um espaço morto por cima da cabeça do pistão. É nesse volume que se inicia a combustão, sendo por isso denominado de volume da câmara de combustão (V_{cc}). Se dividirmos o volume total (V_t), por cima da cabeça do pistão quando este está no PMI pelo valor de quando está no PMS, obtemos a razão de compressão (ε) do motor, dada por (HEYHOOD, 1988):

$$\varepsilon = \frac{V_t}{V_{cc}} = \frac{V_p + V_{cc}}{V_{cc}} \quad (02)$$

Rudolf Diesel (1858-1913) concebeu este tipo de motor com princípio de funcionamento baseado no ciclo teórico a pressão constante (ciclo Diesel). Apesar disto, a realidade da progressão das propriedades dos gases dentro do cilindro de um motor real é significativamente diferente da análise teórica do ciclo, pois no ciclo real o fluido de trabalho (mistura combustível-comburente), ao passar através do motor, submete-se a uma série de transformações químicas e físicas (compressão, expansão, combustão, transferência de calor através das paredes, etc.).

Em resumo, o motor diesel real é um sistema aberto que admite ar fresco nas condições ambientes e expelle gases queimados a alta temperatura, enquanto que no ciclo teórico o processo de descarga é substituído por um processo de transferência de calor para um reservatório térmico a baixa temperatura, que regenera os gases para as propriedades iniciais do ciclo.

No caso de motores de quatro-tempos, o ciclo real obedece a uma sequência rígida de eventos que ocorrem através de duas revoluções completas do eixo de manivelas, definidos a seguir, conforme mostra a Figura 9:

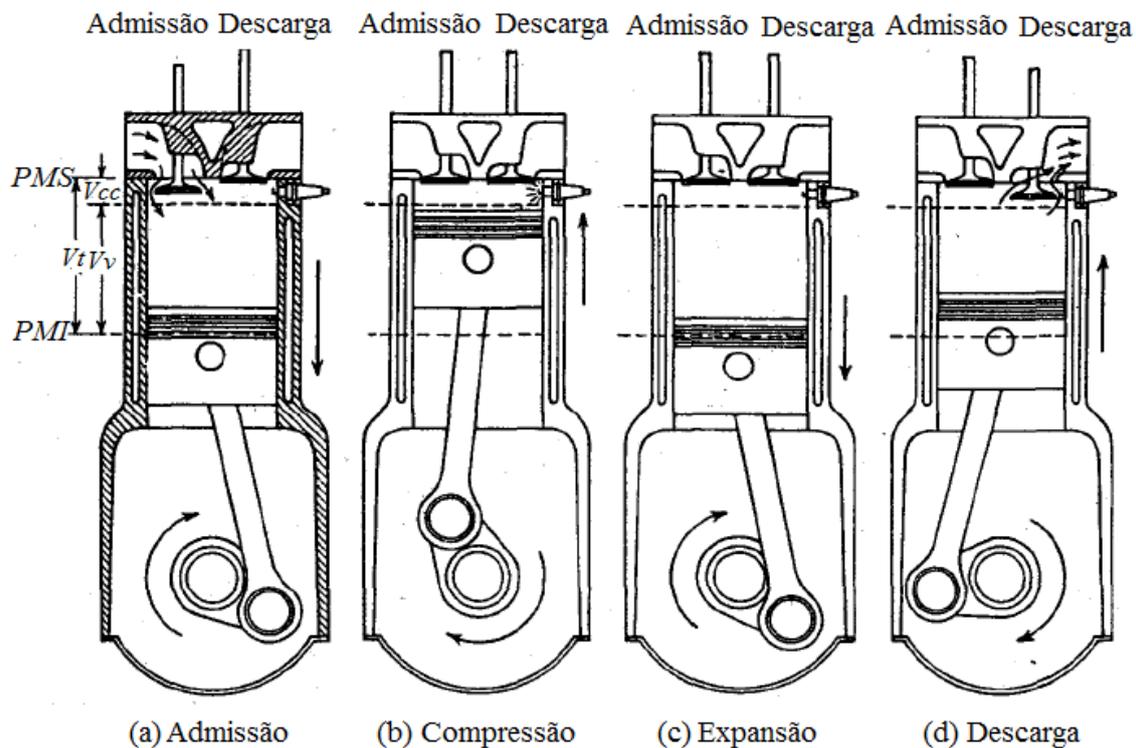


Figura 3.1 – O ciclo de operação de um motor diesel de quatro tempos. Fonte: adaptado de Heywood (1988).

- Admissão, onde a válvula de admissão abre e o pistão desloca-se para o PMI, induzindo uma carga de ar para o interior do cilindro.
- Compressão, onde tanto a válvula de admissão, quanto a válvula de descarga estão fechadas e o pistão desloca-se para o PMS. Assim que o pistão aproxima-se do PMS, isto é, quando estiver próximo do final do curso, o combustível é injetado, ocorrendo ignição.
- Expansão, também conhecido como curso de potência ou de trabalho, onde a combustão propaga-se pela carga da mistura ar-combustível, elevando a pressão e a temperatura e forçando o pistão para baixo. No final deste curso a válvula de descarga abre, acontecendo a expansão irreversível dos gases de descarga.
- Descarga, onde a válvula de descarga permanece aberta e, com o deslocamento do pistão para cima, os gases remanescentes são expelidos do cilindro. No final deste curso, quando a válvula de descarga fechar, ainda sobrar algum gás residual no cilindro, que se diluirá na próxima carga de ar.

Esta concepção de ciclo permitiu a resolução de inconveniências como a necessidade de se utilizar combustível de qualidade especial, restringindo esta somente à facilidade de autoignição (ou desempenho em relação à autoignição), medida pelo seu Índice (ou Número) de Cetanas (IC). Outras inconveniências superadas foram a limitação do valor máximo da taxa de compressão e a obrigação de se colocar a mistura combustível-comburente sempre dentro de limites apertados (com restrição à entrada de ar).

O motor diesel também é conhecido como motor de ignição por compressão por não possuir sistema externo de preparação de mistura nem sistema de ignição. Recebe apenas ar durante o curso de admissão e que passa pelo processo de compressão. Devido à alta razão de compressão empregada (da ordem de 12 até 24, segundo Martins (2006)), a temperatura do ar no final do tempo de compressão (antes do PMS) é suficientemente alta e superior à do ponto de ignição do combustível que começa a ser injetado para gerar a autoignição deste, após um período de atraso. A injeção do combustível prossegue por parte da descida do pistão e, à medida que o combustível encontra ar, vai ocorrendo combustão até que todo o combustível seja consumido.

Como o ar se encontra a elevada pressão, torna-se necessário que o combustível seja injetado com pressão ainda maior e para que isto ocorra é indispensável o uso de um sistema de injeção a alta pressão que comprima e forneça combustível a cada cilindro em intensidade e quantidade exatas a fim de permitir uma combustão suave. Estas últimas particularidades geram outra característica bastante importante que é a extensão da injeção de combustível e, por conseguinte, do período de combustão no curso de potência.

O escoamento dos gases através do cilindro é controlado pelas válvulas de admissão e de descarga, acionadas, assim como o sistema de injeção de combustível, por um mecanismo que opera com a rotação igual à metade da rotação do motor. Uma parte da potência do curso de expansão é armazenada no volante do motor para fornecer energia aos outros três cursos.

Por fim, uma particularidade bastante importante deste tipo de motor é que não há limitação para o ar de admissão, pois o tipo de combustão não necessita de mistura próxima da estequiométrica e a variação da carga no motor é feita apenas pela injeção de mais ou menos combustível por ciclo, permanecendo constante a quantidade de ar admitido. Em outras palavras, o pedal do acelerador é ligado somente à bomba injetora

de combustível. Quando há mudança na carga, a quantidade de combustível injetado muda, o que altera a razão ar/combustível. Assim, o motor trabalha com uma razão ar/combustível menor em altas cargas, quando é injetada uma quantidade maior de combustível por ciclo.

Quando o motor diesel opera com razão ar/combustível mais pobre, a análise termodinâmica do ciclo indica uma maior eficiência térmica, porém reduzida pressão média efetiva e potência. Por causa disto, em determinada potência, maior será o tamanho do motor quando operar próximo da condição estequiométrica e mais rica será a razão ar/combustível em certas regiões dentro da câmara, o que faz com que algumas “gotículas” do combustível não obtenham o oxigênio necessário à combustão, gerando o aparecimento de fumaça negra perceptível na descarga.

Segundo Ganesan (1999), evita-se esta inconveniência, projetando o motor diesel para operar com um excesso de ar entre 15% e 40%, de acordo com a sua aplicação. A Figura 10 apresenta a curva de potência de um motor diesel operando com velocidade constante. A área sombreada indica, aproximadamente, a região das razões ar/combustível em que ocorre a fumaça negra visível.

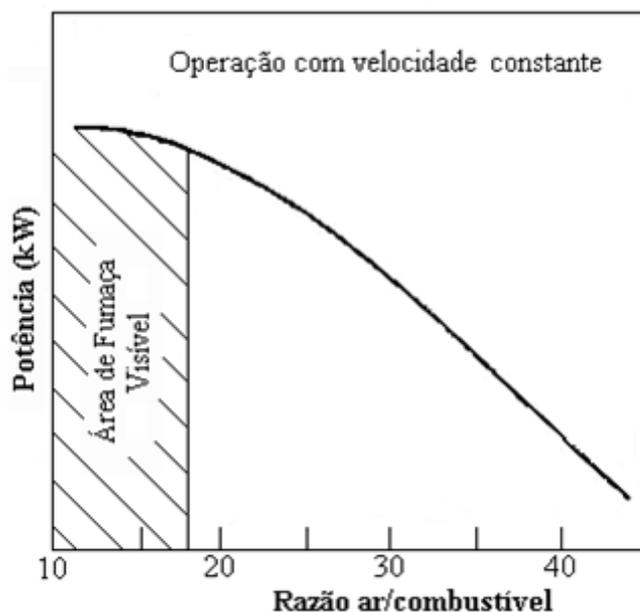


Figura 3.2 - Efeito da razão ar/combustível sobre a potência de um motor Diesel. Fonte: adaptado de Ganesan (1999).

3.2. Características do Processo de Combustão

A combustão espontânea, ou autoignição, da mistura combustível-comburente dentro do cilindro é a principal característica do motor diesel. Ela ocorre quando o combustível é injetado no ar fresco comprimido (em alta razão de compressão) e com temperatura superior ao do ponto de ignição do combustível, próximo ao final do tempo de compressão (antes do PMS), após um atraso.

O combustível é injetado no ar altamente comprimido e aquecido e se desintegra em um núcleo de combustível envolvido por um *spray* formado de ar e partículas vaporizadas de combustível como se fosse um envelope. A turbulência do ar na câmara de combustão, que passa através do jato, separa as partículas de combustível do núcleo, conforme mostra a representação esquemática na Figura 11. A oxidação tem início quando o *spray* (envelope) da mistura ar-combustível alcança as condições ideais de combustibilidade determinadas pela razão ar/combustível e pela temperatura de autoignição do combustível.

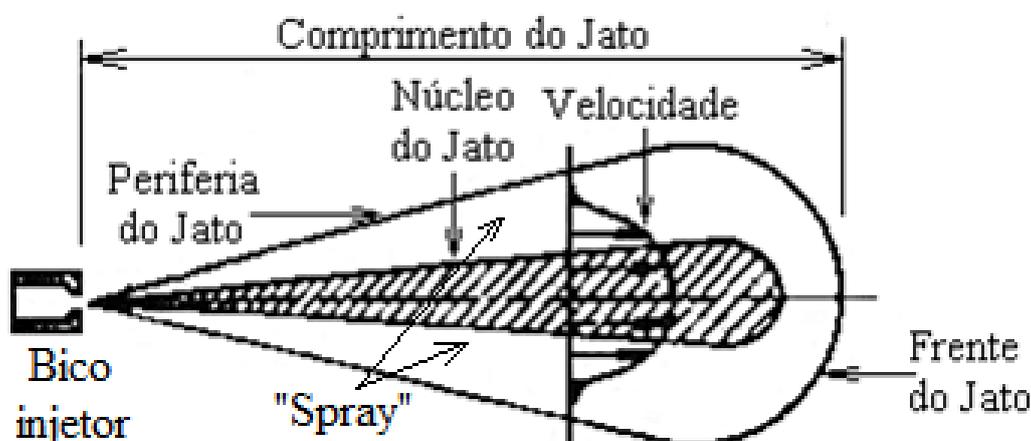


Figura 3.3 – Desintegração do jato de combustível. Fonte: adaptado de Ganesan (1999).

Entretanto, para que sejam vaporizadas, é necessário que as partículas de combustível absorvam o calor latente de vaporização do próprio ar, por difusão ou convecção, no exato momento da injeção do combustível. Em consequência, há a redução

imediate na temperatura da fina camada de ar que envolve o jato, sendo necessário algum tempo para que a temperatura volte a subir pela retirada de calor do ar em sua vizinhança.

Assim, a combustão ocorre, desde o seu início, com o núcleo do jato de combustível ainda líquido e relativamente frio, envolvido por uma camada de vapor, inflamando-se rapidamente à medida que for obtendo oxigênio até a sua total oxidação. Conclui-se que sempre haverá certo período de atraso entre o início da injeção e a ocorrência da ignição, chamado de atraso da ignição.

Uma particularidade da preparação da mistura combustível-comburente para a combustão é a sua heterogeneidade, pois a injeção não distribui as “gotículas” de combustível uniformemente através do espaço da câmara de combustão. Ou seja, haverá sempre diferentes misturas combustível-comburente em diferentes pontos da câmara de combustão.

Idealmente, o *spray* de combustível deveria misturar-se com a totalidade da massa de comburente (o ar), o que implicaria haver “gotículas” com diferentes penetrações e dirigidas para diferentes zonas da câmara. Estes requisitos não são possíveis de preencher globalmente, sendo a combustão penalizada. Como não é possível utilizar a totalidade do ar, a combustão é realizada sempre em excesso de ar e este, junto com o combustível, deve possuir movimento ordenado e controlado (turbulência), para que um fluxo contínuo de ar fresco seja trazido a cada “gotícula” em combustão e os produtos da combustão sejam levados. Este excesso também é necessário para auxiliar a quebra do jato de combustível e para misturar partes queimadas e não queimadas da mistura combustível-comburente.

Para Ganesan (1999), esta particularidade evidencia o maior problema na combustão no motor diesel que é conseguir suficiente mistura entre o *spray* de combustível e o ar, pois a taxa de mistura controla a taxa de combustão. Motores com cilindros muito largos – um motor de navio pode ter cilindros com diâmetro muito superior a um metro – rodam a velocidades muito lentas, pois o combustível tem de “viajar” do bico injetor até os cantos mais remotos da câmara de combustão à “procura” de ar. Este tipo de motor requer grandes penetrações do combustível, tendo de se realizar a injeção a pressões muito elevadas.

3.3. Estágios da Combustão

A combustão no motor diesel desenvolve-se em vários estágios por causa do seu tipo de preparação de mistura e inflamação, e estes podem ser mais bem identificados no diagrama indicado $p \times \theta$, conforme mostra a Figura 12.

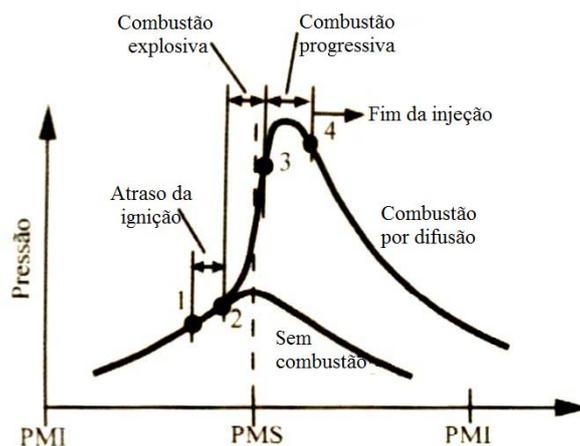


Figura 3.4 – Identificação dos estágios da combustão no diagrama $p \times \theta$. Fonte: adaptado de Martins (2006).

3.3.1. ATRASO DA IGNIÇÃO (1-2)

Quando o combustível é injetado, é necessário que se espere que este se evapore, misture com o ar circundante e reaja. Todo este processo leva certo período de tempo e por esta razão é denominado de atraso, sendo que somente depois deste lapso de tempo é que começará a verdadeira combustão da mistura.

Segundo Martins (2006), antes da combustão, a mistura combustível-comburente passa por uma reação de oxidação que tem início no momento em que começa a injeção, quando é necessário que o comburente (ar) esteja a uma pressão compreendida entre 35 e 60 bar e temperatura acima de 450 °C, e prossegue nas “gotículas” de combustível injetadas neste ar que se aquecem e vaporizam e o vapor na vizinhança das gotículas aquece-se mais uma vez e mistura-se com o ar que consegue, por difusão ou convecção, chegar até ele. Deste modo têm início lentas reações de oxidação, que mais uma vez aumentarão a temperatura do meio e, conseqüentemente, a taxa de reação até chegar à combustão.

A velocidade de reação é dada pela equação geral da teoria cinética dos gases, do tipo Arrhenius, que mostra que a taxa de combustão aumenta significativamente com a elevação da temperatura (MARTINS, 2006):

$$\frac{dm}{dt} = A \exp\left(\frac{E}{RT}\right) \quad (03)$$

onde

m – quantidade de combustível consumido

t – unidade de tempo

A – fator de frequência (independente da temperatura)

E – energia de ativação (J/mol)

K – constante universal do gases (J/mol.K)

T – temperatura absoluta (K)

O atraso da ignição, medido em graus do ângulo de rotação do eixo de manivelas, é decomposto em atraso físico (transferência de calor, vaporização das “gotículas” e mistura) e atraso químico (reações químicas de oxidação lenta).

- O Atraso físico é dependente da atomização do *spray* e da taxa de aquecimento e de vaporização das “gotículas”, parâmetros que variam com a velocidade de injeção e com o diâmetro das “gotículas” que, por sua vez, são dependentes de sua velocidade. Assim, injeções em alta velocidade diminuem o atraso físico, pois reduzem o tamanho das gotículas e melhoram as características de transferência de calor e massa.
- O atraso químico está vinculado à equação (03) e ao IC do combustível. Como é dependente da temperatura do meio e em alta temperatura as reações químicas tornam-se mais rápidas, o seu período é mais curto que o do atraso físico.

Como ocorre durante a injeção de combustível, o atraso da ignição não pode ser longo, pois do contrário, quando a combustão iniciar, haverá muita massa de combustível que queimará simultaneamente causando um violento aumento na taxa de aumento de pressão, por conseguinte, vibração e ruído no motor, fenômeno conhecido como “batida” ou “detonação”, conforme mostra a Figura 13.

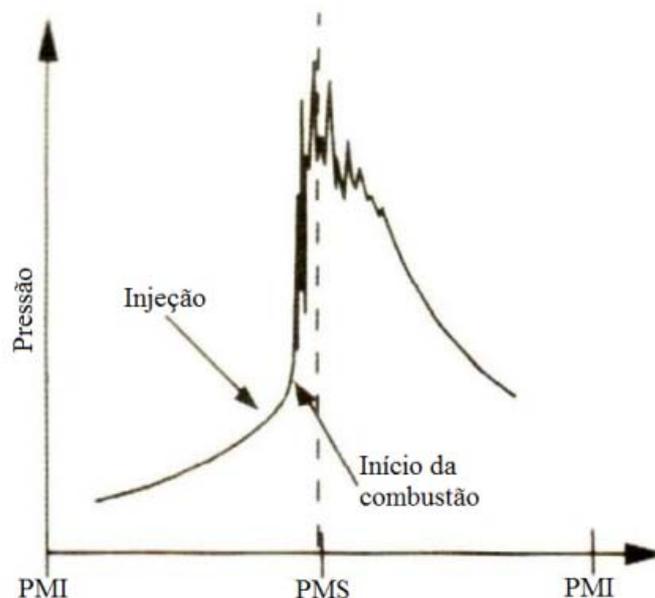


Figura 3.5 – A detonação (batida) do motor diesel. Fonte: adaptado de Martins (2006).

Portanto, a redução do período de atraso da ignição é primordial para um funcionamento “suave” do motor diesel e para tal, é necessário atuar sobre a pulverização do combustível e turbulência do ar. Quanto mais fino o *spray*, mais fácil será a sua vaporização (transferência de massa), transferência de calor e mistura com o ar, pois a área superficial (por unidade de massa ou volume) de um *spray* é inversamente proporcional ao diâmetro médio das suas “gotículas”.

3.3.2. COMBUSTÃO RÁPIDA (2-3)

A combustão inicia no ponto 2 da Figura 12, propagando-se por todo o espaço da câmara de combustão. O combustível acumulado no cilindro durante o período de atraso da ignição se inflama e queima rapidamente aumentando bruscamente a pressão e a temperatura no cilindro. A pressão alcançada durante este período dependerá da duração do período de atraso da ignição, ou seja, quanto mais longo o atraso, maior e mais rápido será o aumento da pressão, uma vez que mais combustível se fará presente no cilindro antes que a velocidade da combustão se estabilize (MARTINS, 2006).

Nesta fase não é fácil controlar a combustão, pois o seu controle é cinético, devendo recair sobre os parâmetros iniciais. Assim, a taxa de aumento de pressão pode ser controlada pela variação da vazão a injetar antes desta fase, do avanço do início da

injeção e do tipo de injetor e pressão de injeção. A forma da câmara de combustão também é muito importante, assim como as propriedades do combustível, mas, obviamente, não é possível modificá-las.

Como é a fase em que se atingem as maiores temperaturas do ciclo, há a produção de gases poluentes, como o NO_x , e também a emissão de particulados.

3.3.3. COMBUSTÃO UNIFORME (3-4)

A combustão prossegue a partir da “explosão” inicial, à medida que o combustível é injetado no ar com temperatura elevada, o que reduz o atraso da ignição. De acordo com Martins (2006), o controle da velocidade da combustão (ou taxa de liberação de calor) nesta fase é difusivo, já que as “gotículas” entram em combustão à medida que se difundem pelo espaço da câmara e tornam a mistura combustível-comburente (ar) disponível para combustão. Para que ocorra esta difusividade, é necessário que o combustível se espalhe por toda a câmara ou que o ar (altamente turbulento) passe pelo *spray* de combustível.

No primeiro caso é necessário haver injeção em diferentes direções e com “gotículas” de diferentes tamanhos. Desta maneira elas terão energia cinética diferente (mesma velocidade de injeção, mas massa diferente), originando penetrações diferentes. As “gotículas” maiores não perderão facilmente a sua velocidade e continuarão o seu trajeto durante mais tempo por possuírem mais massa para vaporizar e queimar. Deve-se projetar o sistema de injeção para que as “gotículas” maiores acabem o seu trajeto próximo das paredes do cilindro ou do pistão. As “gotículas” menores consumirão o ar perto do bico injetor.

No segundo caso, como a turbulência do ar é muito elevada, este passa em alta velocidade em frente ao bico injetor, o que possibilita a redução na pressão de injeção, pois a turbulência se encarrega da preparação da mistura.

Esta fase de combustão ocorre praticamente à pressão constante, para o que é necessário controlar a taxa de injeção de combustível e a forma, atomização e penetração do *spray*. A pressão no cilindro atinge o pico imediatamente após o PMS e próximo da metade do período, podendo ou não ter um segundo pico (comumente menor) e vai diminuir assim que começar o processo de expansão.

Uma boa combustão exige a maior quantidade possível de oxigênio disponível em contato com o *spray* antes que o combustível seja arrefecido pelas paredes ou sobreaquecido pelos gases da combustão. A taxa de liberação de calor é máxima durante os períodos de combustão rápida e uniforme.

3.3.4. COMBUSTÃO ATRASADA (4 EM DIANTE)

Este tipo de combustão surge após a interrupção da injeção e é fundamental para a emissão de particulados. É uma fase relativamente longa, onde a liberação de calor continua em uma velocidade bem inferior no curso de expansão, dando suavidade ao perfil da pressão. Entretanto, há uma flutuação de pressão, pois, como a temperatura dos gases não baixa muito, são queimados as últimas porções de combustível e os resíduos da combustão anterior.

Para Martins (2006), o ideal neste período, é que haja na câmara regiões de elevada temperatura e alguma turbulência para que o ar ainda não usado possa chegar aonde é necessário. Se o rendimento da combustão não for elevado, o calor desenvolvido não é utilizado para a produção de trabalho e a temperatura dos gases se eleva para valores em que se produz fumaça, NO_x e outros poluentes.

A velocidade da combustão nesta fase vai depender da velocidade de difusão e do nível de turbulência responsável pela mistura do combustível não queimado e parcialmente queimado com o ar.

3.4. Fatores que Influenciam a Combustão no Motor Diesel

Devido à alta complexidade de seu processo de combustão causada pelo grande número de fatores envolvidos, é difícil monitorar com segurança o desempenho do motor diesel. Adams (1949), no entanto, avalia os efeitos das alterações nos fatores característicos da operação do motor, sobretudo sobre a P_{max} (Pressão Máxima de Combustão) alcançada no terceiro estágio da combustão e sobre θ (Ângulo de Rotação do Eixo de Manivelas) em que esta ocorre, mostrados em diagramas indicados $p \times \theta$, em determinadas condições de carga. Com isto, surge a oportunidade de se tirar conclusões acerca, por exemplo, do consumo de combustível e dos níveis de depósitos e desgastes

no cilindro, além de outros tipos de falhas. Os mais importantes fatores e os seus efeitos são descritos a seguir.

3.4.1. REGULAGEM DE INJEÇÃO DE COMBUSTÍVEL

O efeito da regulagem de injeção de combustível é mostrado na Figura 14, onde três diagramas $p \times \theta$ com regulagem padrão, avançada e retardada da mesma quantidade de combustível injetado por ciclo estão sobrepostos. A regulagem avançada é evidenciada pela alta P_{max} , enquanto que a regulagem retardada se evidencia pela baixa P_{max} , aumento no consumo de combustível e fumaça na descarga.

Segundo Ganesan (1999), no começo do processo de injeção, se θ for grande, a pressão e a temperatura terão valores mais baixos, aumentando o período de atraso da ignição. Como consequências diretas deste fato está o aumento da TEP_{comb} (Taxa Máxima de Elevação de Pressão) e da P_{max} , pois quanto mais longo o atraso, maior e mais rápido é o aumento da pressão de combustão.

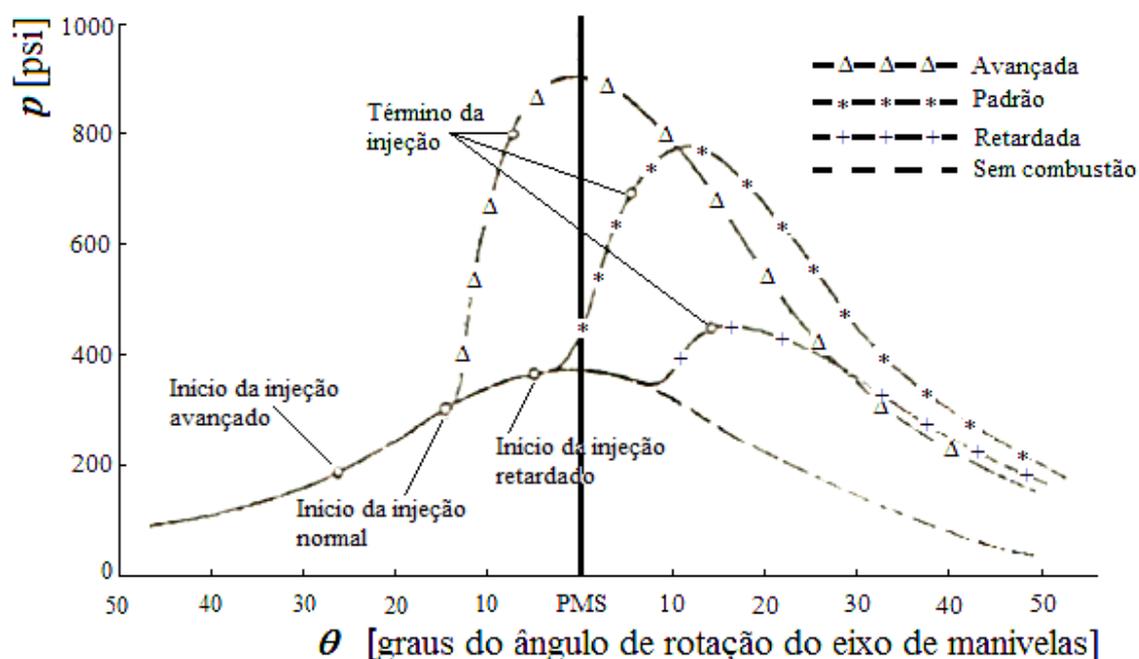


Figura 3.6 – Efeito da regulagem de injeção de combustível sobre o diagrama $p \times \theta$.
Fonte: adaptado de Adams (1949).

3.4.2. RAZÃO DE COMPRESSÃO

A razão de compressão não tem um efeito acentuado no pico de pressão de combustão, como pode observar-se na Figura 15. Segundo Adams (1949), o aumento da razão de compressão, com o conseqüente aumento da P_{comp} (Pressão de Compressão), poderia elevar a P_{max} , porém, com a diminuição do atraso da ignição e da TEP_{comb} , a tendência é baixar a P_{max} . Além disto, o aumento na razão de compressão diminui o tempo em que o combustível alcança a sua temperatura de autoignição encurtando o atraso da ignição e diminuindo a P_{max} .

Portanto, o efeito mais significativo da razão de compressão é mesmo a alteração na P_{comp} .

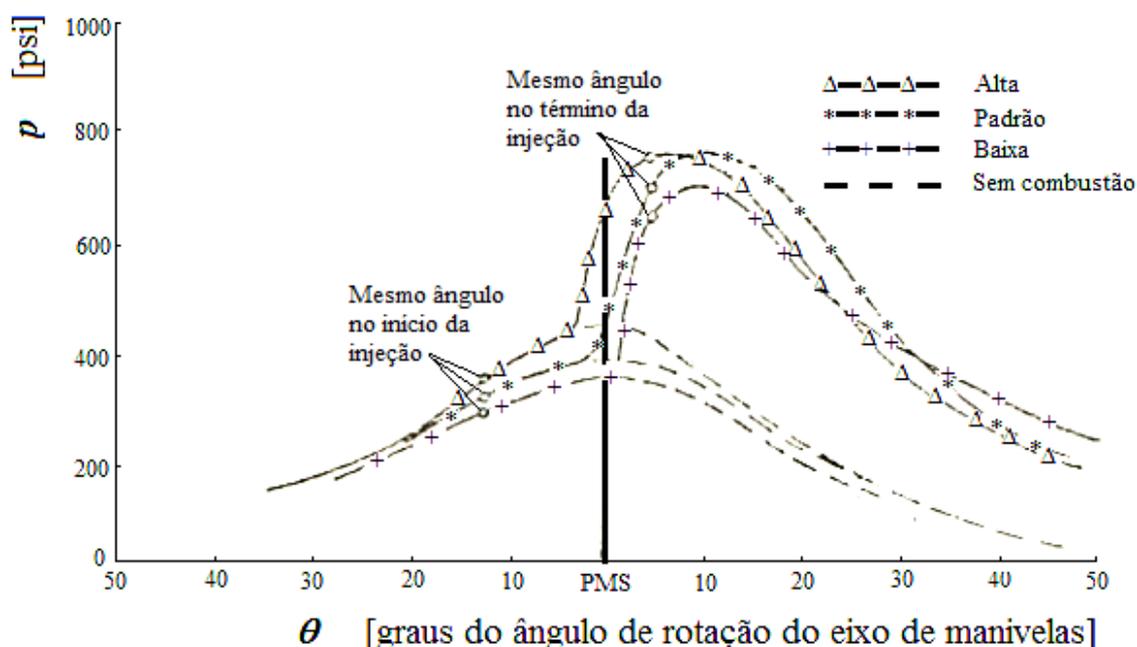


Figura 3.7 – Efeito da razão de compressão do motor sobre o diagrama $p \times \theta$. Fonte: adaptado de Adams (1949).

3.4.3. CARACTERÍSTICAS FÍSICO-QUÍMICAS DO COMBUSTÍVEL

Segundo Adams (1949), a única característica do combustível que afeta apreciavelmente o diagrama indicado é a qualidade de ignição, usualmente expressa pelo IC. Observa-se pela Figura 16 que existe pouca diferença na aparência dos diagramas $p \times \theta$ com IC entre 50 (normal) e 70 (alto), mas o combustível com IC igual a 30 (baixo)

dá um diagrama decididamente “anormal”, como evidenciado pela baixa TEP_{comp} . Com a utilização de combustíveis com qualidade de ignição ainda mais baixa, é provável a ocorrência de falha de ignição.

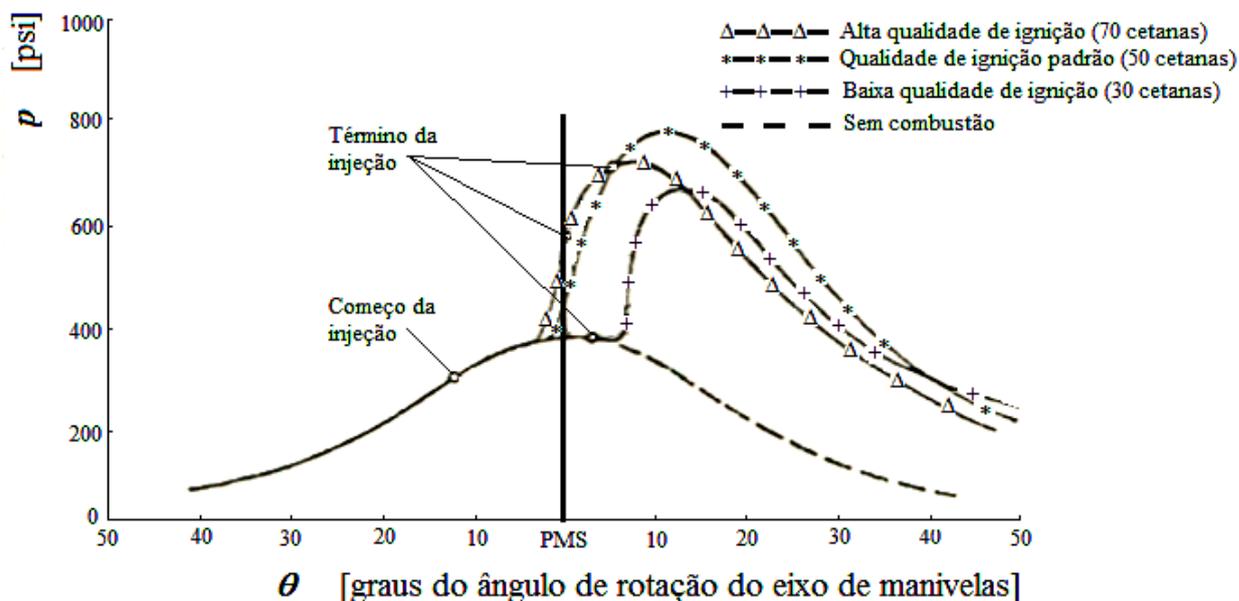


Figura 3.8 – Efeito das características físico-químicas do combustível sobre o diagrama $p \times \theta$. Fonte: adaptado de Adams (1949).

3.4.4. PRESSÃO DO AR DE ADMISSÃO

Quando a pressão do ar de admissão for maior do que a atmosférica, a P_{comp} será maior na mesma proporção e a P_{max} será correspondentemente maior. Pela Figura 17, observa-se que o diagrama $p \times \theta$ mais elevado representa alta pressão do ar de admissão correspondente à super carregamento e o diagrama mais baixo representa baixa pressão do ar de admissão, correspondente a estrangulamento no ar de admissão. Neste caso, Adams (1949) afirma que o motor “fumaria” a plena carga porque a reduzida quantidade de ar seria incapaz de queimar a quantidade normal de combustível, o que geraria a necessidade de reduzir a carga.

Nos testes realizados para a obtenção dos diagramas, a carga – quantidade de combustível injetado – foi sempre ajustada no máximo que ainda daria descarga limpa e a regulagem de injeção foi mantida fixa. O resultado mostrou que a P_{max} foi consideravelmente maior com super carregamento do que com admissão atmosférica.

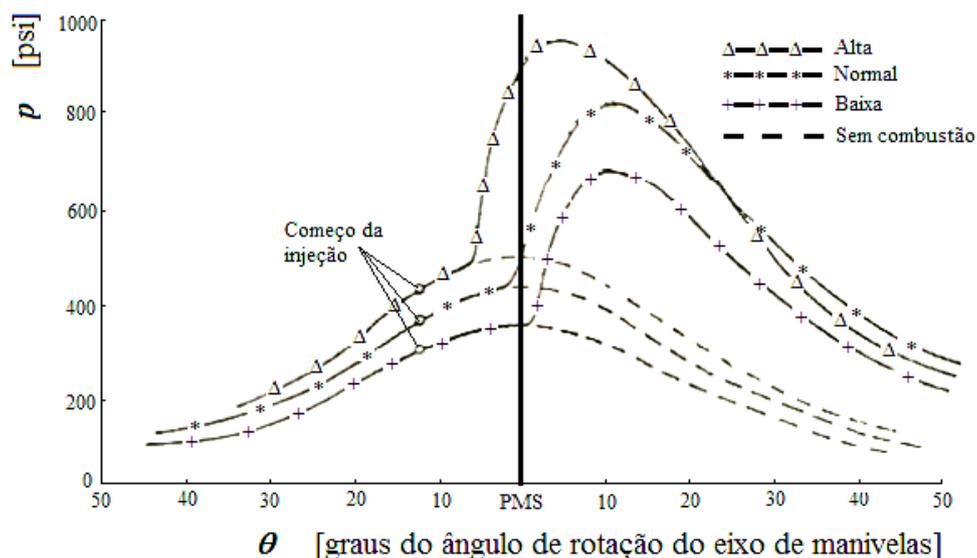


Figura 3.9 – Efeito da pressão do ar de admissão sobre o diagrama $p \times \theta$. Fonte: adaptado de Adams (1949).

Por outro lado, quando um motor opera sob super carregamento, pode-se obter vantagem do encurtamento do atraso da ignição pelo retardamento da regulagem de injeção. Pela Figura 18, observa-se que a regulagem de injeção foi ajustada para que a ignição ocorresse a 2° antes do PMS para produzir um melhor desempenho do motor. O resultado é que o aumento na pressão de combustão nem de longe se parece com o de regulagem fixa (Fig. 17) que na verdade é muito avançada em condições de super carregamento. Quando um motor é projetado para super carregamento ele funciona uma etapa além pela redução da razão de compressão até ter substancialmente as mesmas pressões de combustão e de compressão do motor naturalmente aspirado.

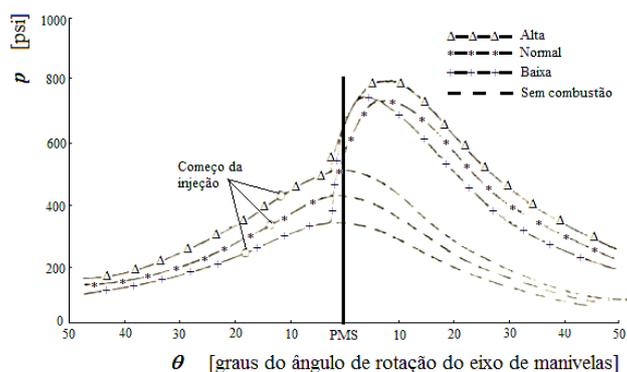


Figura 3.10 – Efeito da pressão do ar de admissão que sofreu super carregamento sobre o diagrama $p \times \theta$. Fonte: adaptado de Adams (1949).

Segundo Adams (1949), a redução na pressão do ar de admissão resulta em ignição atrasada, podendo-se visualizar a perda de potência na Figura 17. Avançando a regulagem como mostrado na Figura 18, o motor começaria um funcionamento anormal manifestado pela elevação de pressão excessivamente íngreme, mas ainda estaria deficiente em potência. Obstrução em trechos da admissão, filtro de ar ou coletor do ar de admissão, juntamente com a regulagem incorreta das válvulas de admissão, causariam perda de carga de ar, cujo efeito seria similar ao de estrangulamento deliberado. Para Adams (1949), apenas a eliminação da causa remediaria o defeito.

3.4.5. TEMPERATURA DO AR DE ADMISSÃO

De acordo com Heyhood (1988), a temperatura de autoignição do combustível é inversamente proporcional à razão de compressão e, portanto, da P_{comp} . Devido a isto, pode-se afirmar que o aumento na P_{comp} diminui o atraso da ignição e, também, a TEP_{comb} , resultando em baixa P_{max} .

Sabe-se que a densidade dos gases depende da pressão e da temperatura a que são submetidos. Porém, um pré-aquecimento no ar de admissão de um motor diesel para aumentar a temperatura no momento da ignição do combustível não é desejável porque reduziria a densidade do ar de admissão e haveria a necessidade de aumentar o nível da pressão de compressão para alcançar a temperatura de autoignição do combustível, acarretando aumento no atraso da ignição.

Assim sendo, uma diminuição na temperatura do ar de admissão aumenta a sua densidade, diminuindo o nível da P_{comp} e, portanto, do atraso da ignição.

3.4.6. PRESSÃO DE INJEÇÃO DE COMBUSTÍVEL

Segundo Ganesan (1999), a alta pressão de injeção de combustível aumenta o grau de pulverização do combustível líquido e reduz o atraso da ignição devido à sua maior razão superfície/volume. Além do mais, com menores “gotículas” de combustível, a área agregada de combustão aumenta após a ignição, resultando em maior aumento de pressão durante o segundo estágio da combustão.

A explicação para isto é que as “gotículas” de combustível com menores dimensões têm pouca penetração no ar presente no cilindro de onde têm de obter oxigênio

após a pulverização. Com menor dimensão, as gotículas têm menor quantidade de movimento e velocidade, o que reduz o fator de utilização do ar, já que a penetração do *spray* de combustível será mais curta, porém terão mais facilidade de deslocamento no volume da câmara de combustão pela turbulência gerada pela própria geometria desta.

Por outro lado, a baixa pressão de injeção gera maior dimensão nas “gotículas” de combustível, levando a baixa pressão de combustão durante o segundo estágio e, provavelmente, funcionamento anormal do motor.

3.4.7. CARGA (QUANTIDADE DE COMBUSTÍVEL INJETADO)

A Figura 19 apresenta três diagramas $p \times \theta$ sobrepostos que diferem apenas na regulagem da haste de controle da bomba de injeção de combustível. Devido à diferença na quantidade de combustível injetado, um cilindro carregará mais e outro menos que sua cota de combustível. Para igualar a carga, as cremalheiras de controle da quantidade de combustível a ser injetado precisam ser ajustadas. Observa-se que a P_{max} aumenta inexpressivamente quando a carga é aumentada de normal para pesada. Segundo Adams (1949), em qualquer motor, um aumento de carga pode causar ou não um aumento no pico de pressão de combustão podendo até, paradoxalmente, causar um decréscimo.

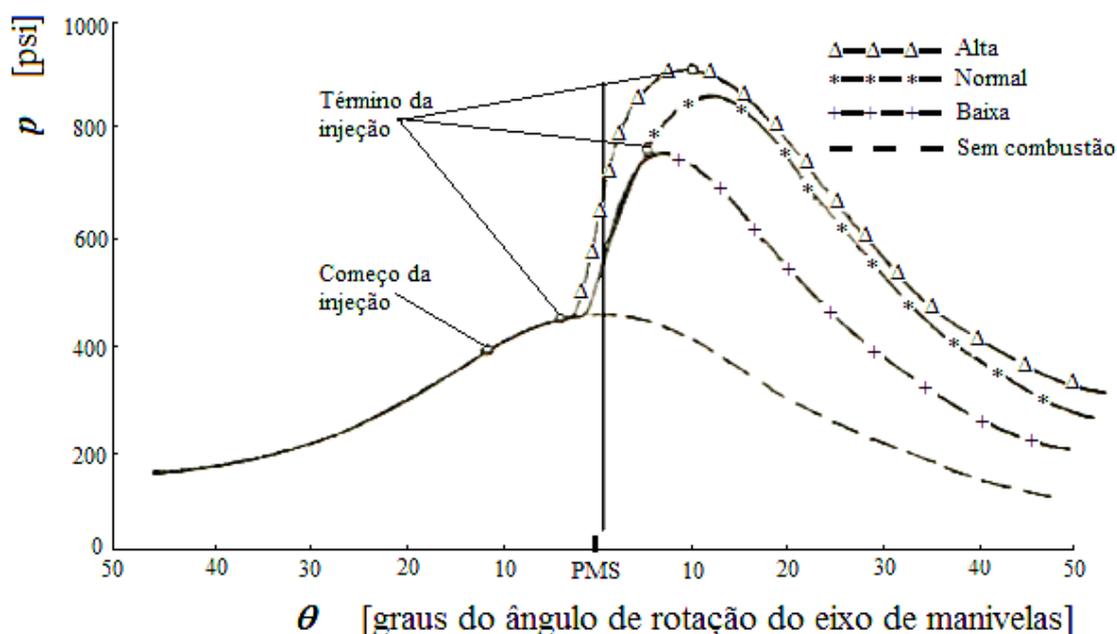


Figura 3.11 – Efeito da carga (quantidade de combustível injetado) no cilindro. Fonte: adaptado de Adams (1949).

Sabe-se que a variação na quantidade de combustível liberado no período de injeção afeta o pico de pressão, muito embora o atraso da ignição não seja afetado diretamente por esta variação devido à existência de uma grande faixa de razões ar/combustível presentes no cilindro. Contudo, em altas cargas (grandes quantidades de combustível), as paredes do cilindro tendem a ter temperaturas mais altas, o que faz com que o ar perca menos calor durante a compressão, diminuindo o período de atraso da ignição.

É usual que maiores quantidades de combustível sejam injetadas pelo prolongamento do período de injeção, ao invés de se aumentar a taxa de combustível injetado. Assim, em alta carga, a quantidade de combustível injetada no cilindro durante o atraso da ignição é reduzida por causa do reduzido período de atraso. Devido a isto, a taxa de aumento médio da pressão de combustão e a pressão no segundo estágio podem reduzir-se. O restante do combustível injetado durante o terceiro estágio da combustão aumentará o pico de pressão. Por outro lado, em baixa carga, se a quantidade de combustível for suficientemente reduzida a fim de cessar a injeção antes do fim do período de atraso, o pico de pressão reduzirá grandemente.

3.4.8. VISCOSIDADE DO COMBUSTÍVEL

Ganesan (1999) afirma que o atraso físico da ignição depende da viscosidade do combustível, uma vez que, para combustíveis leves, o atraso físico é pequeno, ao passo que, para combustíveis mais viscosos, ele torna-se mais longo devido à deficiência na sua vaporização. Com base neste fato, podemos afirmar que quanto maior a viscosidade do combustível maior o atraso da ignição e, portanto, maior o pico de pressão de combustão.

3.4.9. TAXA DE ELEVAÇÃO DA PRESSÃO NO SEGUNDO ESTÁGIO DA COMBUSTÃO

A Figura 20 mostra três diagramas $p \times \theta$ sobrepostos com diferentes taxas de elevação da pressão no segundo estágio da combustão. A TEP_{comb} na câmara de combustão de um motor diesel exerce uma influência considerável sobre o valor da P_{max} , sobre a potência produzida e sobre a suavidade com que as forças são transmitidas ao pistão. A sua magnitude é dependente, principalmente, da velocidade da combustão da

mistura no cilindro, ou seja, do atraso da ignição. Em resumo, quanto maior for o atraso da ignição, maior será a TEP_{comb} durante o segundo estágio e, conseqüentemente, do pico de pressão.

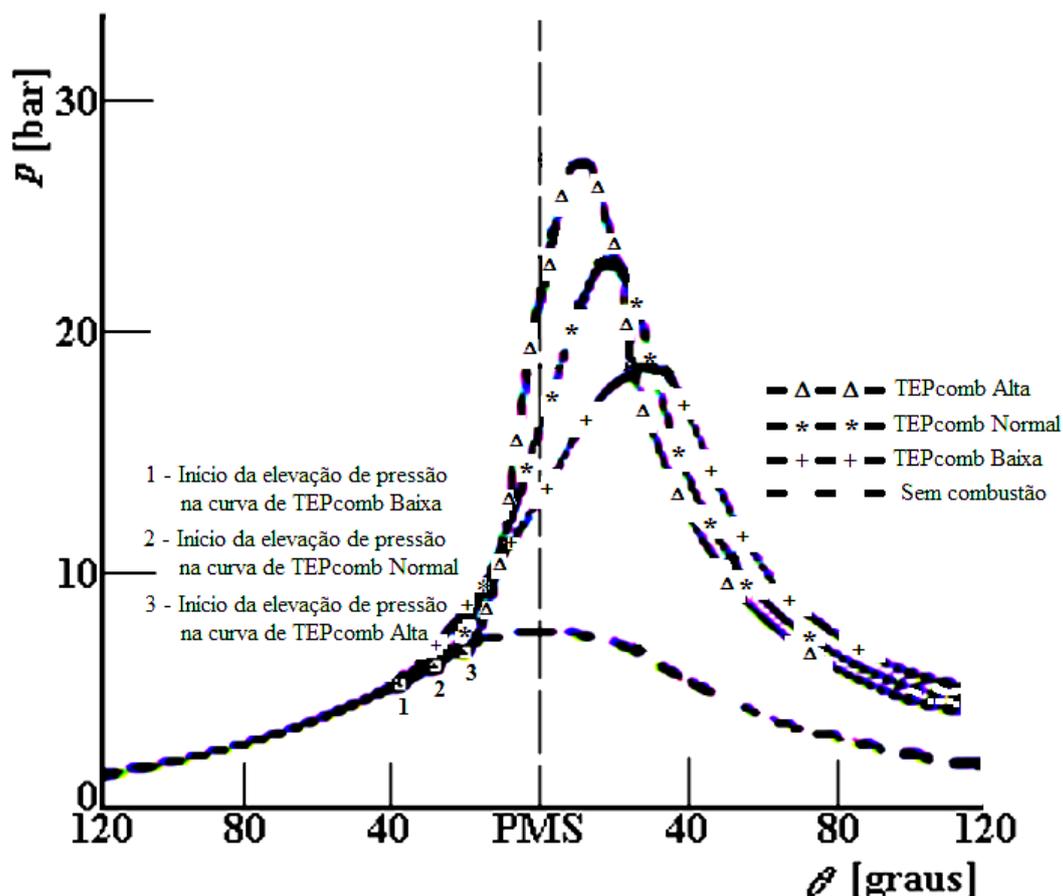


Figura 3.12 – Efeito da taxa de elevação de pressão no segundo estágio sobre o pico de pressão de combustão. Fonte: adaptado de Ganesan (1999).

3.5. AAF (Análise da Árvore de Falhas)

No presente trabalho, apresenta-se a importância de se analisar os possíveis mecanismos de falha em um sistema complexo, de multicomponentes como é o motor diesel. Mostram-se, ainda, as causas iniciais e a combinação de eventos de falha que podem resultar em uma falha específica. Define-se aqui um evento de falha como sendo o estado em que se encontram, em dado momento, os parâmetros operacionais do motor diesel e seus subsistemas. A maneira utilizada para apresentar as causas iniciais e a combinação de eventos é a técnica da AAF, que imprime relações lógicas simples

(interseção, união, etc.) entre os eventos e reproduz metodicamente uma estrutura lógica que representa o motor diesel e todos os seus subsistemas.

Segundo Zio (2007), a AAF é uma técnica, ou metodologia dedutiva e sistemática, que permite o desenvolvimento de relações causais que resultam em um determinado evento de falha indesejável. É dedutiva porque inicia por um evento de falha definido, revelando suas causas em ordem inversa para baixo até chegar às falhas primárias independentes.

Focando-se inicialmente em um modo de falha individual do sistema, a AAF pode ser fonte de informações qualitativas sobre um evento de falha e qual as consequências resultantes deste, além de permitir a identificação dos componentes protagonistas para a determinação da falha definida. Além disto, o evento pode ser decomposto em termos quantitativos para estabelecer a probabilidade dos eventos a que diz respeito, começando pelo conhecimento da probabilidade de ocorrência dos eventos primários que podem causá-lo. Contudo, apesar da importância do conhecimento desta probabilidade, neste trabalho, o objetivo central da AAF é mostrar a trajetória da falha até a sua causa-raiz, indicando a combinação entre falhas de itens componentes, erros operacionais ou outras falhas causadoras do evento indesejável, com o cuidado de dedicar atenção especial com as interações entre componentes, particularmente no caso das falhas de modo comum.

A construção da árvore de falhas não é uma tarefa simples, uma vez que exige conhecimento profundo do sistema em estudo. Isto requer um conhecimento horizontal de sistemas complexos e aqui há uma sobreposição de diversas disciplinas, como física, química, eletrônica, engenharia de controle automático, ciência da computação, etc. Também é necessário o conhecimento vertical, visto que a fidelidade da representação do evento indesejável, definido em nível de sistema pela árvore de falhas, depende da definição precisa das ligações lógicas existentes entre os diferentes componentes do sistema e de seus modos de falha (LIMNIOS, 2007).

A construção da árvore sempre começa pela definição do evento indesejável, chamado de evento topo, e cada evento seguinte será estabelecido pela sua contribuição para a ocorrência deste. Estes eventos contribuintes são definidos como eventos intermediários de falha, necessários e suficientes para causar diretamente a ocorrência do evento topo, ou outro evento intermediário, e conectados a este por portas lógicas. Segundo Limnios (2007), na decomposição de um evento intermediário, é imperativo que

todas as suas causas sejam definidas antes de iniciar a sua análise. Cada entrada de operador deve possuir texto próprio e não deve ter dois operadores com conexão direta entre eles.

Os eventos intermediários têm pelo menos quatro possibilidades de ocorrência (ZIO, 2007):

- Sistema sem alimentação;
- Falha primária no sistema (em operação nas especificações de projeto, aleatória devido ao envelhecimento ou fadiga);
- Falha secundária no sistema (devido às tensões, presentes ou passadas, causadas por itens componentes próximos ou pelo ambiente: por exemplo, falha de causa comum, escoamento excessivo, causas externas como terremotos); e
- Falha humana ou de controle em operação ou instalação do sistema.

A falha secundária se caracteriza principalmente pelo funcionamento anormal do sistema. O seu caráter aleatório é fruto de fatores de operação, que abrangem amplitude, frequência e duração, e de variáveis do meio em que se insere o sistema, que são de natureza térmica, mecânica, elétrica, química, magnética e eletromagnética.

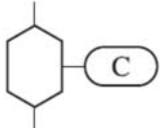
Uma vez estabelecidos os eventos intermediários contribuintes diretos para a ocorrência do evento topo, estes devem ser investigados com vistas a sua viabilidade de decomposição em eventos mais elementares pelas seguintes perguntas (ZIO, 2007):

- Este evento é uma falha primária?
- Este evento pode ser decomposto em outras causas de falha primárias?

Se a resposta para a primeira pergunta for positiva, o evento é um evento primário de falha e o ramo correspondente da árvore é finalizado. Caso contrário, deve-se investigar o evento, decompô-lo, identificá-lo e conectá-lo via portas lógicas, nível por nível, até chegar ao nível dos eventos primários de falha, onde, por uma série de razões, não podem mais ser decompostos.

A Tabelas 2, a Tabela 3 e a Tabela 4 apresentam os símbolos empregados para a representação de eventos e suas relações em uma árvore de falhas.

Tabela 3.1 – Operadores fundamentais da AAF.

Símbolo gráfico	Nome	Significado
	OU	A saída é gerada se ao menos uma das entradas existir.
	E	A saída é gerada se todas as entradas existirem.
	SE	A saída é gerada se a entrada existir e se a condição C for comprovada.

Fonte: Limnios (2007).

Tabela 3.2 – Eventos na AAF.

Símbolo gráfico	Significado
	Retângulo Evento topo ou intermediário.
	Círculo Evento básico primário.
	Losango Evento básico não primário.
	Duplo losango Evento considerado básico na etapa em curso, sendo analisado posteriormente.
	Casa Evento considerado normal.

Fonte: Limnios (2007).

Tabela 3.3 – Triângulos de transferência na AAF.

Símbolo gráfico	Significado
	Transferência idêntica O trecho da árvore que deve prosseguir não é mostrado por ser idêntico ao trecho sinalizado pelo símbolo de identificação de transferência abaixo.
	Transferência similar O trecho da árvore que deve prosseguir não é mostrado por ser similar ao trecho sinalizado pelo símbolo de identificação de transferência abaixo.
	Identificação de transferência Indica uma subárvore idêntica ou similar que não será mostrada no prosseguimento.

Fonte: Limnios (2007).

Na configuração gráfica da árvore de falhas aparecem dois tipos de portas lógicas: a porta OU, usada para mostrar que o evento de saída ocorre quando um ou mais eventos de entrada ocorrem, e a porta E, usada para mostrar que o evento de saída ocorre se e somente se ocorrerem todos os eventos de entrada. Ambas podem ter vários eventos como entrada. Além destas, há também um caso especial da porta E, chamada de porta SE, na qual a saída é causada por uma única entrada, porém, tendo que satisfazer uma condição qualificadora antes que a entrada possa produzir a saída. Por convenção, esta porta é indicada por um hexágono e a condição, situada à sua direita, por uma elipse. Deste modo, a saída acontece apenas se a entrada ocorrer sob as condições especificadas dentro da elipse.

As saídas das portas indicadas por retângulos, ou são eventos topo ou são eventos intermediários. Os eventos de falha primários, ou de entrada das portas, que aparecem na extremidade inferior da árvore de falhas são divididos em eventos básicos, não desenvolvidos e externos. Os eventos básicos, representados por um círculo, são os eventos de iniciação que não requerem desenvolvimento adicional e indicam que a resolução apropriada da árvore de falhas foi alcançada. Os eventos não desenvolvidos, indicados por um losango, referem-se a eventos de falha específicos, embora sem serem desenvolvidos posteriormente, ou porque suas consequências são desprezíveis ou porque faltam informações relevantes ao evento. Por outro lado, os eventos externos, expressos por uma figura em forma de casa, indicam um evento de ocorrência normalmente esperada e, portanto, não representam uma falha em si. Quando se quer tornar a

representação de uma árvore de falhas mais compacta, utilizam-se os triângulos de transferência que evitam a repetição de trechos idênticos ou similares da árvore (LIMNIOS, 2007).

Todos os eventos de falha têm que ser cuidadosamente descritos (o quê, onde e quando) dentro de seus respectivos símbolos gráficos. Segundo Limnios (2007), para que a análise seja consistente é necessária a definição segura de três fases: a análise preliminar, as especificações e a construção propriamente dita.

A análise preliminar envolve a decomposição do sistema por critérios como tecnologia, manutenção, dados de estudos realizados, entre outros; a identificação dos itens, que envolve a identificação de todos os componentes representados no último nível de decomposição do sistema; a definição dos modos de falha dos itens; a reconstituição do sistema através de seus itens componentes.

As especificações levam em conta as fases, que são os diferentes modos de operação do sistema; as condições de contorno, que dizem respeito às interações do sistema com o meio; as hipóteses específicas, que são as convenções sobre o sistema em si; e as condições iniciais referentes às hipóteses associadas ao começo da fase em estudo.

A construção em si, começa pela definição do evento indesejável sem ambiguidade e de maneira coerente com as especificações. Além disto, é necessário definir a resolução dos eventos, que é a decomposição em eventos-causa desde o indesejável, passando pelos intermediários. A construção acaba quando todos os eventos-causa não decompostos forem modos de falha dos itens componentes ou do meio.

Com a árvore completa, será realizada a avaliação qualitativa e, conseqüentemente, a determinação das regras de diagnóstico com base nas *cutsets* (Séries de Corte) mínimas, que são conjuntos de eventos cuja ocorrência simultânea assegura a ocorrência do evento topo.

3.6. RNA (Rede Neural Artificial)

Segundo Braga *et al.* (2007), uma rede de neurônios artificiais, ou RNA, é um sistema paralelo distribuído composto por unidades de processamento simples (dois ou mais neurônios artificiais) que calculam, em geral, funções não-lineares e possuem três características principais: a arquitetura, o algoritmo de treinamento ou aprendizado e a função de ativação.

Estas unidades de processamento – os neurônios artificiais – são definidas por Dreyfus (2005) como uma função limitada, parametrizada e não linear, cujas variáveis são chamadas de entradas e o seu valor é a sua saída. A Figura 21 mostra a representação gráfica de um neurônio artificial inspirado na célula biológica.

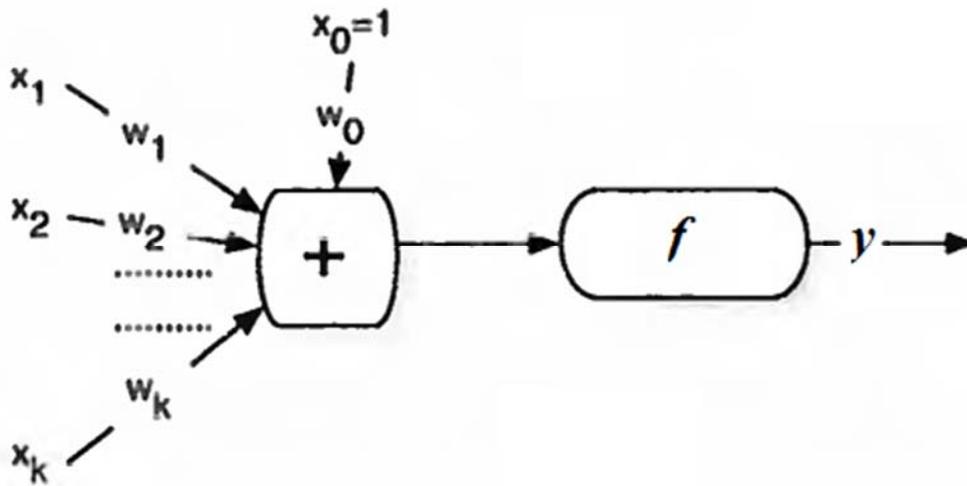


Figura 3.13 – Representação gráfica de um neurônio. Fonte: Dreyfus (2005).

A saída y é a função limitada não linear dada por

$$y = f(x_1, x_2, \dots, x_n; w_1, w_2, \dots, w_p) \quad (04)$$

onde $\{x_i\}$ são as variáveis e os $\{w_j\}$ são os parâmetros (ou pesos) do neurônio.

Um modo de parametrizar-se a função f é atribuir-se os parâmetros às entradas dos neurônios; a saída do neurônio é uma combinação não linear (chamada de potencial linear) das entradas dadas pelo vetor $x = [1, x_1, \dots, x_k]$, ponderada pelos pesos (ou pesos sinápticos) dados pelo vetor $w = [w_0, w_1, \dots, w_k]$. O potencial v mais frequentemente usado é uma soma ponderada das entradas, com um termo constante adicional w_0 chamado viés (“bias”)

$$v = w_0 + \sum_{i=1}^{n-1} w_i x_i \quad (05)$$

A função f é chamada de função de ativação, sendo recomendável que seja sigmoide (em forma de s), tal como a função tangente hiperbólica ou a função inversa da tangente.

Neste trabalho, objetiva-se implementar um sistema de classificação de falhas a partir de padrões definidos pelos parâmetros operacionais de motores diesel. Muitos problemas de classificação podem ser vistos como problemas de regressão não linear e, de acordo com Dreyfus (2005), as RNA's unidirecionais (*feedforward*) são os classificadores mais eficientes, explicando-se a preferência pela utilização da rede MLP (Perceptron de Múltiplas Camadas).

A arquitetura da MLP apresenta uma camada de entrada, uma camada de saída e uma ou mais camadas escondidas, conforme Figura 22. Este arranjo em camadas se dá pelo fato de que as saídas dos neurônios de uma camada são usadas como entradas para os neurônios da próxima camada. O número de neurônios nas camadas de entrada e de saída é dado pelo problema a ser resolvido, ao passo que o número de camadas escondidas e de neurônios em cada camada é definido pelo projetista da RNA.

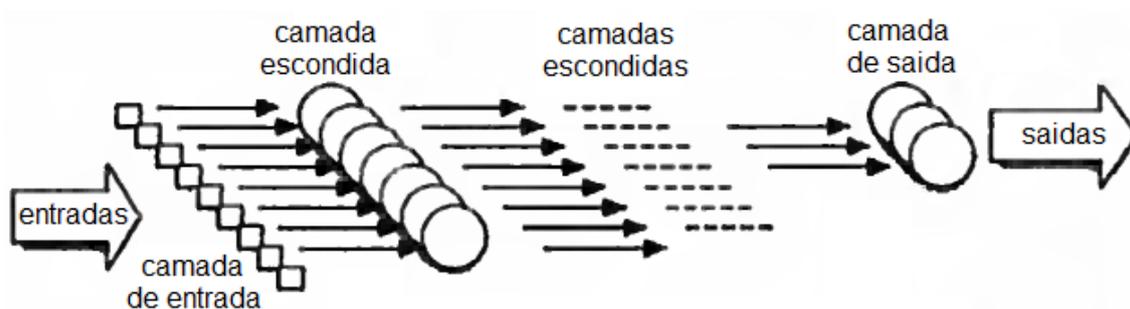


Figura 3.14 – Perceptron de múltiplas camadas. Fonte: Dreyfus (2005).

A arquitetura de uma RNA diz respeito ao padrão de conexões entre as suas unidades e entre as suas classes principais estão a unidirecional e a recorrente (*feedback*). A rede unidirecional é definida por Dreyfus (2005) como uma função não linear de suas entradas, que, por sua vez, é a composição das funções de seus neurônios. A Figura 23 mostra uma RNA unidirecional representada graficamente como um conjunto de neurônios conectados, onde a informação flui no sentido para frente, das entradas para as saídas e os vértices são os neurônios e as arestas são as conexões.

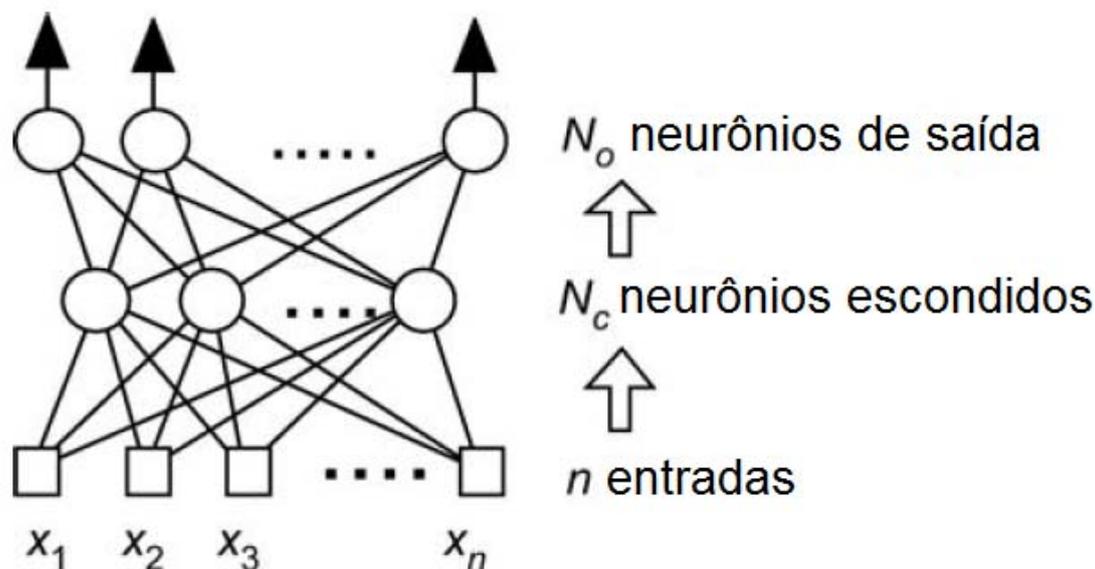


Figura 3.15 – Rede neural com n entradas, uma camada de N_c neurônios escondidos e N_o neurônios de saída. Fonte: Dreyfus(2005).

Observa-se que o gráfico da rede é acíclico: nenhuma trajetória, seguindo as conexões, pode dirigir-se para trás do ponto de partida. Os neurônios que realizam o cálculo final, cujas saídas são as saídas da rede, são chamados de neurônios de saída; os outros neurônios, que realizam cálculos intermediários, são chamados de neurônios escondidos.

O treinamento é o procedimento algorítmico pelo qual os parâmetros dos neurônios da rede são estimados, de forma que a RNA cumpra, tão precisamente quanto possível, a tarefa que lhe foi imputada. Dentro do contexto deste trabalho, considera-se o treinamento supervisionado, pois é o caso em que a função que a rede deve implementar é conhecida em alguns ou em todos os pontos. Neste presente caso, um “professor” fornece os “exemplos” dos valores das entradas e dos correspondentes valores da saída para que a RNA calcule a função não linear desconhecida analiticamente, conhecendo-se apenas o número de valores numéricos da função (DREYFUS, 2005).

Da mesma forma como ocorre na natureza, as conexões entre os componentes definem a função da rede, que, de modo geral, são ajustadas, ou treinadas, para que uma entrada em particular resulte em uma saída específica. Pelo esquema mostrado na Figura 24, pode-se observar que a rede é ajustada com base na comparação entre a saída e o objetivo desejado (alvo) até que a saída da rede iguale-se ao alvo. Geralmente, são

necessários muitos pares de entradas/alvos para treinar uma rede (DEMUTH & BEALE, 1998).

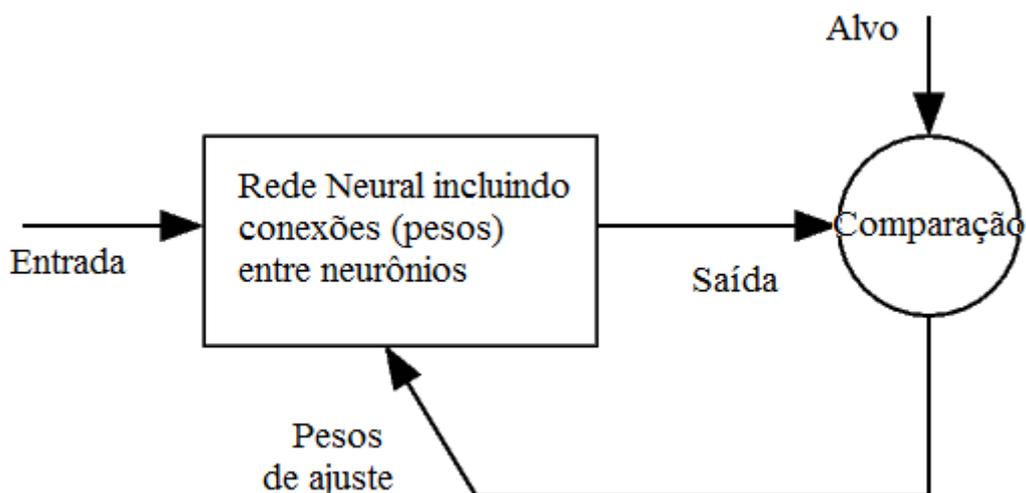


Figura 3.16 – Esquema de treinamento de uma rede neural. Fonte: adaptado de Demuth & Beale (1998).

Para criar a RNA com algoritmo de treinamento BP (*backpropagation*), utilizou-se a ferramenta para reconhecimento de padrão do software Matlab R2010b. O objetivo é investigar os efeitos de diferentes pressões, ângulos e temperaturas sobre a condição operacional de um motor diesel.

3.6.1. ALGORITMO DE TREINAMENTO *BACKPROPAGATION*

Para Haykin (1994), o processo de treinamento de uma RNA consiste basicamente em apresentar pares entrada-saída à rede, calcular as saídas da rede em função das entradas, calcular o erro entre a saída desejada e a saída calculada e alterar os valores sinápticos por algum tipo de algoritmo. À medida que os pares entrada-saída vão sendo apresentados e os pesos das sinapses atualizados, o MSE (Erro Médio Quadrático) da saída da RNA tende a diminuir.

Neste trabalho opta-se pelo algoritmo de treinamento BP que realiza a retro propagação dos erros calculados das saídas em direção às entradas, com o erro calculado na saída de um neurônio sendo multiplicado pela derivada da função de ativação deste e propagado para a sua entrada. Este valor é, então, enviado para todos os neurônios da

camada anterior – pesado pelas respectivas sinapses – utilizando o método do gradiente descendente para corrigir os valores sinápticos.

Pelo método do gradiente descendente se faz o cálculo do gradiente da função objetivo (MSE) a se minimizar e atualiza-se o valor das sinapses somando-se a ele o valor do gradiente com o sinal invertido. O gradiente, neste caso, é a derivada parcial da função MSE em relação à sinapse. Este processo faz com que o erro médio quadrático do problema caminhe sempre no sentido contrário de seu máximo crescimento.

Porém, a performance deste algoritmo é bastante sensível ao valor da taxa de aprendizagem. De acordo com Demuth & Beale (1998), quando esta é fixada com um valor muito alto, o algoritmo pode oscilar e tornar-se instável. Por outro lado, quando a taxa de aprendizagem é muito pequena, o algoritmo levará muito tempo até a convergência. De fato, não é nada fácil fixar um valor ótimo para a taxa de aprendizagem antes da realização do treinamento, uma vez que o algoritmo move-se através da superfície de performance.

Para resolver este problema da performance do algoritmo, Demuth & Beale (1998) apontam que a taxa de aprendizagem seja alterada durante o processo de treinamento utilizando o algoritmo com taxa de aprendizagem adaptativa para deixar a medida do passo de aprendizagem o mais extenso possível, deixando estável a aprendizagem.

No procedimento com uma taxa de aprendizagem adaptativa, a saída da rede inicial e o erro são calculados, assim como novos pesos e vieses em cada época utilizando a taxa de aprendizagem corrente. Sucessivamente, novas saídas e erros são calculados. Quando o novo erro excede o erro anterior acima de um valor predefinido, os novos pesos e vieses são descartados e a taxa de aprendizagem é diminuída, deixando, todavia, os novos pesos, etc. Quando o novo erro for menor do que o erro anterior, a taxa de aprendizagem é aumentada.

Optou-se, também, em realizar o treinamento da rede por época, onde todo o conjunto de treinamento utilizado é apresentado à rede e só após as sinapses são atualizadas. Isto é realizado somando-se os gradientes calculados para cada par entrada-saída até o último par do conjunto de treinamento. Quando todos os pares passarem pelo processo diz-se que ocorreu uma época. Este tipo de treinamento é mais rápido que por Regra Delta, pois a quantidade de operações a realizar é bem menor.

Em resumo, a equação básica do Algoritmo BP é dada por

$$w_{k+1} = w_k - \alpha_k \nabla_k(F_o) \quad (06)$$

onde w_{k+1} é o vetor de pesos sinápticos no instante $k+1$, w_k é o vetor de pesos sinápticos no instante k ; α_k é uma constante chamada passo de treinamento e $\nabla_k(F_o)$ é o vetor gradiente da função objetivo.

O passo de treinamento é uma constante que controla a velocidade de convergência do algoritmo, ou seja, a rapidez com que os valores sinápticos levam o MSE para um mínimo local ou global na superfície de erro do problema. Haykin (1994) dá ênfase ao fato de que, para pequenos valores de α , a atualização das sinapses é mais lenta, fazendo com que se percorra com maior precisão a superfície de erro do problema. Para valores altos de α , apesar da convergência ocorrer de maneira mais rápida, pode acontecer oscilações no treinamento, podendo às vezes até impossibilitar a convergência para um mínimo local ou global.

3.6.2. CLASSIFICAÇÃO (OU DISCRIMINAÇÃO)

A classificação (ou discriminação) é a tarefa de atribuir itens a uma classe (ou categoria) entre várias classes predefinidas. Um algoritmo que efetue automaticamente uma classificação é chamado de classificador.

Embora na linguagem estatística a classificação seja definida como o agrupamento de dados similares (semelhantes) em classes não predefinidas, Dreyfus (2005) afirma que tal tarefa de agrupamento pode ser efetuada perfeitamente por uma RNA com aprendizagem não supervisionada para classes predefinidas.

Os classificadores são largamente aplicados no reconhecimento de padrões. Em geral, um padrão pode ser qualquer item descrito por um conjunto de descritores numéricos. No caso deste trabalho, as classes predefinidas são os modos de falha (ou a condição de operação normal) de um motor diesel descritas pelo conjunto dos valores dos parâmetros operacionais do motor. Espera-se neste caso que o classificador contribua com a resolução do problema respondendo a seguinte pergunta: o conjunto de valores dos parâmetros operacionais do motor definem um modo de falha MD0, ou MD1, ou MD2, etc?

Portanto, resolver um problema de classificação é determinar uma aplicação do conjunto de padrões dentro do conjunto de classes. Em resumo, o problema de classificação abordado neste trabalho é:

- Conjunto de 20 padrões;
- 20 variáveis (ou características) que descrevem os padrões e são importantes para a tarefa de classificação. Estas variáveis compõem o conjunto de descritores de um determinado padrão que faz a “representação” do padrão; e
- Conjunto de 13 classes para as quais os padrões são atribuídos.

4. METODOLOGIA APLICADA PARA O DESENVOLVIMENTO DA PESQUISA

Nesta seção apresentamos a definição dos parâmetros operacionais utilizados para a realização da monitoração da condição e a utilização da técnica da AAF para modelar o comportamento do processo da combustão visando a construção do algoritmo heurístico de falhas em um motor diesel.

4.1. Determinação dos Parâmetros Operacionais

Anônimo (1994) define parâmetro operacional como um parâmetro normalizado, medido ou calculado, que expressa a condição operacional (desempenho) do motor diesel ou de um de seus subsistemas componentes. O processo de normalização dos parâmetros operacionais é feito para torná-los independentes das condições ambientes (temperatura e pressão) e das características físico-químicas do combustível, principalmente as suas propriedades de ignição.

Neste trabalho, a monitoração da combustão é feita baseada na avaliação dos resíduos gerados pelas medições das grandezas dos parâmetros operacionais comparadas a padrões destes. Os parâmetros operacionais indicam o quadro real do processo de combustão no motor diesel e seus subsistemas componentes e, conseqüentemente, do seu desempenho. Além disto, servem de premissas para o conjunto heurístico de falhas, levando ao isolamento e localização destas.

O sistema térmico motor diesel foi dividido em três subsistemas e as descrições dos parâmetros operacionais serão feitas conforme estes.

4.1.1. PARÂMETROS DO FLUIDO DE TRABALHO NA UNIDADE DE CILINDRO

São os parâmetros relacionados aos fenômenos físico-químicos que o fluido de trabalho sofre durante o processo de combustão no interior do cilindro do motor Diesel.

4.1.1.1. P_{max} (Pressão Máxima de Combustão)

Expressa o valor máximo da pressão de combustão que ocorre no cilindro durante um ciclo de operação do motor diesel, normalmente quando o pistão está

próximo ao PMS. O seu valor é influenciado direta ou indiretamente por todos os demais parâmetros operacionais, sendo por isso considerado o mais importante parâmetro operacional na monitoração da combustão dos motores Diesel (ADAMS, 1949). Sua medida é tomada diretamente no diagrama indicado $p \times \theta$.

4.1.1.2. P_{comp} (Pressão de Compressão no Cilindro)

É a pressão máxima que ocorreria na ausência de combustão no cilindro. A medida da sua grandeza depende da densidade do ar de admissão e das condições dos anéis de segmento e da superfície interna da camisa do cilindro e é tomada diretamente nos diagrama indicado $p \times \theta$.

4.1.1.3. TEP_{comb} (Taxa de Elevação da Pressão de Combustão)

Expressa a velocidade com que a pressão se eleva desde o ponto em que começa a ignição da mistura combustível-comburente até o ponto de pressão máxima na curva de combustão do diagrama indicado $p \times \theta$, sendo, portanto, dependente do período de atraso da ignição. Segundo Ganesan (1999), a taxa de elevação da pressão de combustão é igual à inclinação da reta definida pelos pontos de pressão máxima de combustão e pressão de compressão, dada pela tangente do ângulo α do triângulo 123 mostrado na Figura 25.

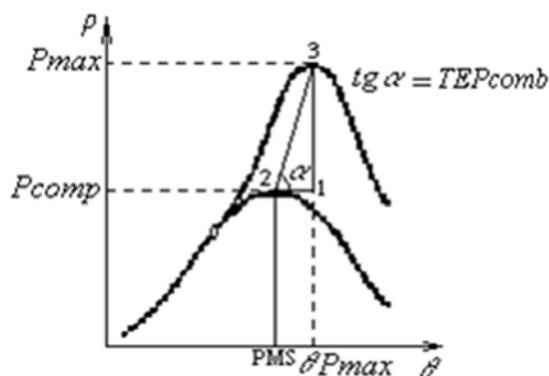


Figura 4.1 – Método gráfico para determinação da TEP_{comb} . Fonte: adaptado de Ganesan (1999).

Deste modo, podemos calcular a taxa de elevação de pressão de combustão pela seguinte equação:

$$TEP_{comb} = \frac{P_{max} - P_{comp}}{\theta P_{max}} \quad (07)$$

sendo que θP_{max} (Ângulo da Manivela na Pressão Máxima de Combustão) é o ângulo de rotação do eixo de manivelas, dado em graus em relação ao PMS, em que ocorre a P_{max} . Este parâmetro é obtido no diagrama indicado $p \times \theta$.

4.1.1.4. δT_{cil} (Diferencial de Temperatura no Cilindro)

Expressa a carga térmica a que é submetido o cilindro durante o processo de combustão. A medida de sua magnitude é calculada pela seguinte equação

$$\delta T_{cil} = T_{desc} - T_{adm} \quad (08)$$

sendo que T_{desc} (Temperatura de Descarga do Cilindro) é a temperatura obtida por medição direta na descarga do cilindro e T_{adm} (Temperatura do Ar de Admissão) é a temperatura do ar obtida por medição direta no coletor do ar de admissão.

4.1.1.5. TS_{agua} (Temperatura Final da Água Refrigerante)

Expressa a temperatura da água obtida por medição direta na entrada do trocador de calor (saída do motor).

4.1.1.6. TE_{agua} (Temperatura Inicial da Água Refrigerante)

Expressa a temperatura da água obtida por medição direta na saída do trocador de calor (entrada do motor).

4.1.2. PARÂMETROS DA INJEÇÃO DE COMBUSTÍVEL

Segundo Martins (2006), o sistema de injeção de combustível é o principal responsável pelo bom ou mau desempenho do motor diesel, ou seja, a potência, a economia de combustível etc., são bastante dependentes da sua eficácia, uma vez que é ele que desempenha a importante tarefa de iniciar e controlar o processo de combustão no motor. Para isto é necessário cumprir as seguintes exigências:

- Formação da mistura ar-combustível o mais homogêneo possível;
- Medição precisa do combustível injetado por ciclo;
- Correta regulagem de injeção do combustível no ciclo para que seja obtida a máxima potência e assim assegurar economia de combustível e combustão limpa;
- Controle apropriado da taxa de injeção para que o desejado padrão de liberação de calor seja obtido durante a combustão;
- Atomização apropriada do combustível em pequenas partículas;
- Distribuição uniforme das “gotículas” de combustível por toda a câmara de combustão;
- Fornecer quantidades iguais de combustível para todos os cilindros, no caso de motores multicilíndricos;
- Não atrasar durante o começo e o final da injeção para evitar o gotejamento.

Neste trabalho a monitoração do processo de injeção é feita pelo diagrama que relaciona a variação da pressão de injeção, desde a bomba injetora até o bico injetor, ao ângulo de rotação do eixo de manivelas. O registro que fornece os parâmetros operacionais do processo, desde o tanque até o bico injetor, é o diagrama $PI \times \theta$ mostrado na Figura 26.

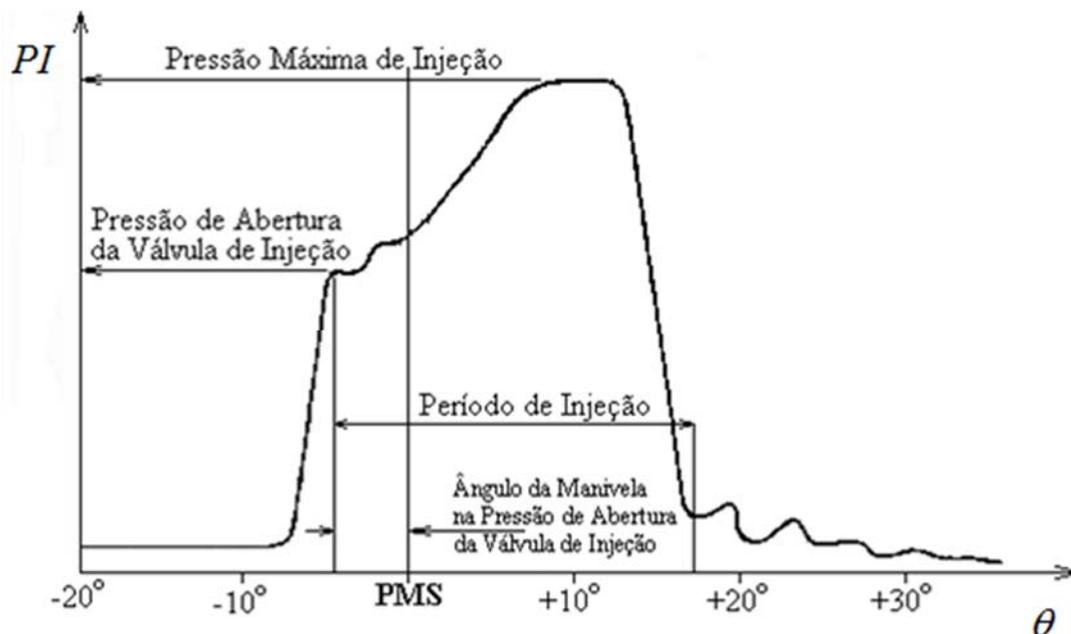


Figura 4.2 – Diagrama indicado de pressão de injeção $PI \times \theta$. Fonte: adaptado de Warkman (1983).

4.1.2.1. PI_{max} (Pressão Máxima de Injeção)

Equivale ao valor máximo de pressão de recalque da bomba injetora durante o processo de injeção de combustível. É influenciado pela condição operacional da bomba injetora. O valor de sua grandeza é obtido diretamente no diagrama $PI \times \theta$.

4.1.2.2. PI_{aber} (Pressão de Abertura da Válvula de Injeção)

Indica a pressão de injeção do combustível no momento em que a injeção inicia, isto é, quando a agulha do bico injetor eleva-se de sua sede. É influenciada pela condição da mola da válvula injetora. O valor de sua grandeza é obtido diretamente no diagrama $PI \times \theta$.

4.1.2.3. $\theta_{PI_{aber}}$ (Ângulo da Manivela na Pressão de Abertura da Válvula de Injeção)

Registra a posição angular do eixo de manivelas na pressão de abertura da válvula de injeção, medido em relação ao PMS, identificando, com isto, o início do processo de injeção. É afetado pela pressão de abertura da válvula de injeção e pela

regulagem de injeção, sendo que o valor da sua grandeza é obtido diretamente no diagrama $PI \times \theta$.

4.1.2.4. Δ_{inj} (Período de Injeção de Combustível)

Expressa a duração do processo de injeção, medido em graus de rotação do eixo de manivelas. É o intervalo do ciclo de combustão em que a válvula de injeção permanece aberta injetando combustível no cilindro. É influenciado pela carga no cilindro e pelo valor do índice da bomba injetora. O valor de sua grandeza também é obtido diretamente no diagrama $PI \times \theta$.

4.1.2.5. $T_{pré-aq}$ (Temperatura de Pré-aquecimento do Combustível)

É a temperatura do combustível medida diretamente na saída do pré-aquecedor de combustível. Este parâmetro influencia diretamente a viscosidade do combustível.

4.1.3. PARÂMETROS DA ADMISSÃO DE AR / DESCARGA DE PRODUTOS DA COMBUSTÃO

A função principal do sistema de admissão de ar/descarga de produtos da combustão é induzir o máximo de massa de ar para o cilindro e fazer o descarte dos produtos da combustão. É constituído de filtro de ar, turbo compressor e um resfriador intermediário da carga de ar de admissão (*intercooler*), que utiliza água como elemento refrigerante, situado entre o compressor e o coletor do ar de admissão. Os parâmetros operacionais inerentes ao processo de admissão de ar e também à descarga dos produtos da combustão são obtidos por medição direta em pontos específicos do sistema, como mostra a representação esquemática na Figura 27.

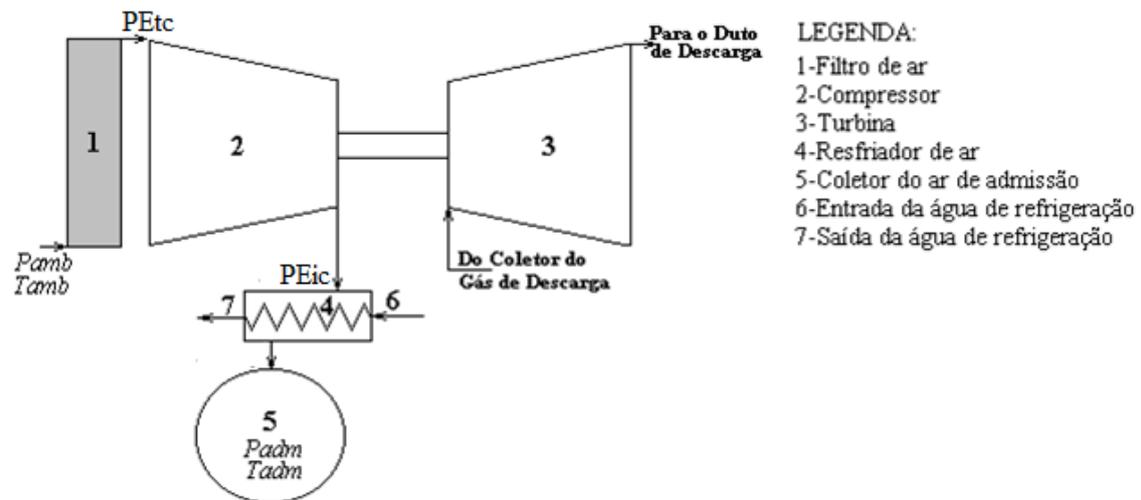


Figura 4.3 – Sistema de admissão de ar/gás de descarga. Fonte: própria do autor.

4.1.3.1. Tadm (Temperatura do Ar de Admissão)

É a temperatura medida diretamente no coletor do ar de admissão do motor diesel. O valor da medida da sua grandeza é influenciado diretamente pela condição operacional do resfriador intermediário de ar.

4.1.3.2. Padm (Pressão do Ar de Admissão)

É a pressão medida diretamente no coletor do ar de admissão do motor. O valor da medida da sua grandeza pode ser influenciado pela condição operacional do resfriador intermediário de ar e do filtro de ar.

4.1.3.3. PEtc (Pressão na Entrada do Turbo Compressor)

Expressa a queda de pressão do ar através do filtro, silenciador e duto do turbo compressor.

4.1.3.4. δP_{ic} (Queda de Pressão no *Intercooler*)

Expressa a condição operacional do resfriador de ar pela seguinte equação:

$$\delta P_{ic} = PE_{ic} - P_{adm} \quad (09)$$

sendo que PEic (Pressão na Entrada do *Intercooler*) é o valor da grandeza da pressão do ar medida diretamente na entrada do resfriador intermediário de ar.

4.1.4. PARÂMETROS DE NORMALIZAÇÃO

Antes de usar os parâmetros operacionais no sistema de diagnóstico temos de torná-los independentes das variações das condições ambientes e das características físico-químicas do combustível (principalmente suas especificações quanto à qualidade de ignição). Para isto, Anônimo (1994) recomenda que os parâmetros descritos a seguir tenham de ser estabelecidos antes da tomada das medidas dos parâmetros operacionais, tanto os que servirão de padrão quanto os que forem tomados em condição de serviço (condição instantânea).

4.1.4.1. Pamb (Pressão do Ar Ambiente)

É a pressão do ar medida, preferencialmente, na sala de máquinas.

4.1.4.2. Tamb (Temperatura do Ar Ambiente)

É a temperatura do ar medida, preferencialmente, na sala de máquinas.

4.1.4.3. CCAI (Índice de Aromaticidade do Carbono Calculado)

Expressa a relação direta entre a aromaticidade do carbono e o atraso da ignição do combustível como uma função da densidade e viscosidade do combustível. Quanto maior o valor do CCAI em uma escala de 800 a 930, mais baixa é a qualidade de ignição (CLARK, 1988):

$$CCAI = D - 81 - 141 \log[\log(V + 0,85)] \quad (10)$$

sendo que D (Densidade do óleo combustível à 15,6 °C) é a densidade, em kg/m³, fornecida pela refinaria e V (Viscosidade do óleo combustível à 50 °C) é a viscosidade, em cSt, fornecida pela refinaria.

4.1.4.4. ID (Índice diesel)

Expressa a qualidade de ignição do óleo diesel, baseada no ponto de anilina e na gravidade API, pela seguinte fórmula:

$$ID = PA \left(\frac{API}{100} \right) \quad (11)$$

sendo que PA (Ponto de Anilina do Diesel) é a mais baixa temperatura sobre a qual volumes iguais de diesel e anilina tornam-se homogêneos e API (Gravidade API) é expressa pela equação:

$$API = \left(\frac{141,5}{g_e} \right) - 131,5 \quad (12)$$

onde g_e é a gravidade específica à 60 °F.

4.2. A Construção da Árvore de Diagnóstico de Falhas pela Técnica da Análise da Árvore de Falhas (AAF)

Esta seção apresenta o método de construção da árvore de falhas que representa as relações entre causas e efeitos de falha no motor diesel.

4.2.1. A DEFINIÇÃO DO SISTEMA

De modo geral, um sistema pode ser definido como um ambiente que gera um produto final pela interação entre os seus elementos discretos (LEWIS, 1996). Neste trabalho, a análise considera como sistema um motor diesel com alimentação de ar feita por turbo compressor, refrigeração por água, com sistema de injeção de combustível com bomba injetora em linha e ciclo de operação de quatro-tempos estendendo-se através de duas revoluções completas do virabrequim (720° de ângulo da manivela) dividido em quatro cursos distintos do pistão: admissão, compressão, expansão e descarga. O princípio de operação do sistema de alimentação de ar é mostrado no

Anexo I, do sistema de refrigeração é mostrado no Anexo II e o do sistema de injeção é mostrado no Anexo III.

Na realidade, o sistema é dividido em três subsistemas: unidade de cilindro, injeção de combustível e admissão de ar/descarga dos produtos da combustão, conforme mostra a representação esquemática na Figura 28. O projeto prevê o escoamento simultâneo do combustível e do ar, respectivamente, do ponto 1 e do ponto 2 até a área consumidora 3 e o escoamento dos gases queimados, produtos da combustão no cilindro, do ponto 3 até a área 4. Os componentes do sistema são identificados a seguir:

TQ – tanque de combustível

PAq – pré-aquecedor de combustível

F1 – filtro de combustível

B0 – bomba injetora

B1 – bico injetor

F2 – filtro de ar

CP – compressor

T – turbina

RCA – resfriador intermediário da carga de ar (*intercooler*)

C1 – coletor de admissão

C2 – coletor de descarga

Cc – câmara de combustão (engloba as válvulas de admissão (VA) e descarga (VD), coroa do pistão, anéis de segmento, camisa do cilindro, cabeçote do motor e sistema de arrefecimento) e os dutos contíguos para o transporte dos fluidos de trabalho.

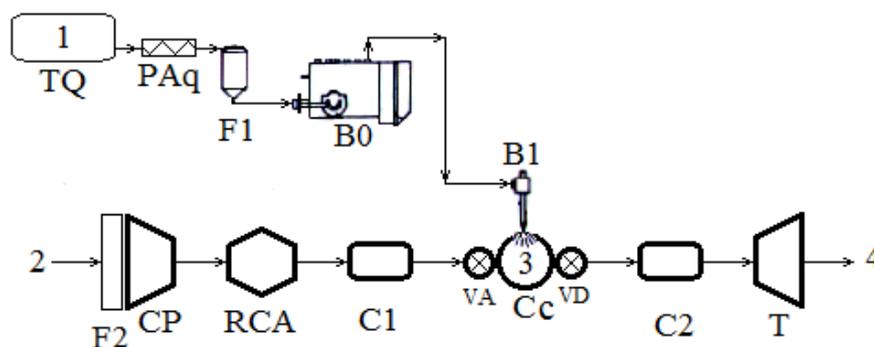


Figura 4.4 – Representação esquemática do motor diesel e seus subsistemas. Fonte: própria do autor.

4.2.2. ANÁLISE PRELIMINAR

Nesta seção se faz a decomposição física do sistema usando critérios como tecnologia, manutenção e dados sobre o estudo em desenvolvimento. Também é feita a identificação e definição dos modos de falha dos componentes e, por fim, a reconstituição do sistema por meio dos componentes.

4.2.2.1. Decomposição do Sistema

– Nível 1:

A composição do sistema é feita, essencialmente, por quatro blocos, conforme a Figura 29.

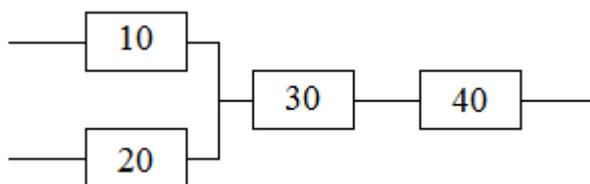


Figura 4.5 – Composição do sistema por blocos. Fonte: própria do autor.

– Nível 2:

O bloco 10 contém o tanque de combustível, o pré-aquecedor de combustível, o filtro de combustível, a bomba injetora, o bico injetor e quatro dutos adjacentes, representados esquematicamente na Figura 30.

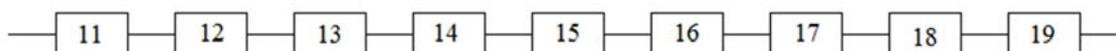


Figura 4.6 – Composição do bloco 10. Fonte: própria do autor.

O bloco 20 contém o filtro de ar, o compressor, o resfriador da carga de ar, o coletor do ar de admissão e cinco dutos adjacentes, representados esquematicamente na Figura 31.



Figura 4.7 – Composição do bloco 20. Fonte: própria do autor.

O bloco 30 contém a válvula de admissão, a válvula de descarga, a câmara de combustão e quatro dutos adjacentes, representados esquematicamente na Figura 32.

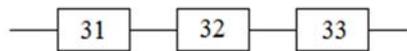


Figura 4.8 – Composição do bloco 30. Fonte: própria do autor.

O bloco 40 contém um coletor de descarga, a turbina e três dutos adjacentes, representados esquematicamente na Figura 33.



Figura 4.9 – Composição do bloco 40. Fonte: própria do autor.

E o sistema completo é apresentado a seguir, na Figura 34.

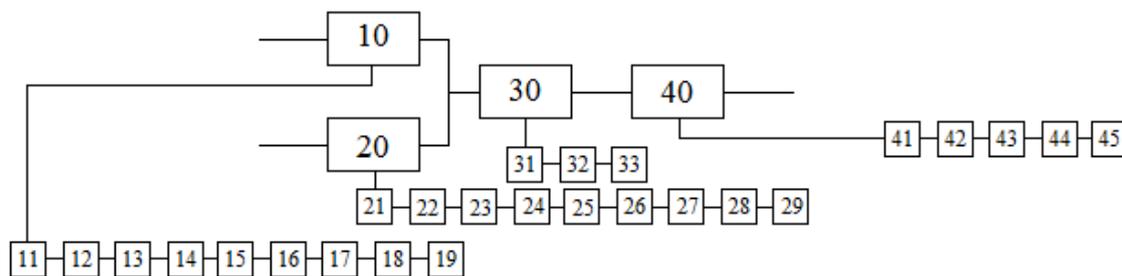


Figura 4.10 – Sistema decomposto em blocos. Fonte: própria do autor.

4.2.2.2. Identificação dos Componentes

- 11 – Tanque de combustível.
- 13 – Pré-aquecedor de combustível.
- 15 – Filtro de combustível.

- 17 – Bomba injetora.
- 19 – Bico injetor.
- 12, 14, 16, 18 – Duto de escoamento de combustível a alta pressão.
- 22 – Filtro, silenciador e duto de passagem do ar no turbo compressor.
- 24 – Compressor.
- 26 – *Intercooler*.
- 28 – Coletor do ar de admissão.
- 21, 23, 25, 27, 29 – Duto de escoamento do ar de admissão.
- 31 – Válvula de admissão da carga de ar.
- 32 – Câmara de combustão.
- 33 – Válvula de descarga dos produtos da combustão.
- 42 – Coletor dos produtos da combustão.
- 44 – Turbina.
- 41, 43, 45 – Duto de escoamento dos produtos da combustão.

4.2.2.3. Definição dos Modos de Falha dos Componentes

As falhas que ocorrem no sistema motor Diesel apresentado neste trabalho são classificadas como primárias, secundárias e de controle, conforme a definição de Lewis (1996). As falhas primárias ocorrem em ambiente e carregamento designados para o item componente, sendo causadas com maior frequência por projetos, fabricação ou construção defeituosa e por isso estão relacionadas a desgastes, ao contrário das falhas secundárias que acontecem de modo aleatório e são caracterizadas por taxas de falha constantes.

Um componente pode operar corretamente quando tiver uma falha de controle, porém no tempo ou função errada. Por causa disto, é necessário que se faça uma análise além da falha do componente com vistas à determinação da fonte de controle errôneo.

As falhas a serem diagnosticadas são descritas a seguir:

- Tanque de combustível (11)

MD1: Combustível com baixo número de cetanas devido à contaminação.

- Pré-aquecedor de combustível (13)

MD2: Falha no pré-aquecedor gerando alta viscosidade no combustível.

- Filtro de combustível (15)
 - MD3: Obstrução no escoamento.

- Bomba injetora (17)
 - MD4: A regulagem do início da injeção de combustível está muito avançada.
 - MD5: A regulagem do início da injeção de combustível está muito atrasada.

- Bico injetor (19)
 - MD6: Defeito na mola e/ou travamento da agulha.

- Filtro, silenciador e duto de passagem do ar no turbo compressor (22)
 - MD7: Obstrução no escoamento do ar.

- Compressor (24)
 - MD8: Defeito no compressor e/ou turbina.

- *Intercooler* (26)
 - MD9: Obstrução no escoamento do ar.

- Câmara de combustão (32)
 - MD10: Falha no trocador de calor (radiador).
 - MD11: Carbonização excessiva no cilindro.
 - MD12: Vazamento pela válvula de admissão da carga de ar e/ou válvula de descarga dos produtos da combustão, ou devido à desgaste dos anéis de segmento e/ou camisa do cilindro.

- Turbina (44)
 - MD8: Defeito no compressor e/ou turbina.

4.2.2.4. Reconstituição do Sistema Pelos Seus Componentes

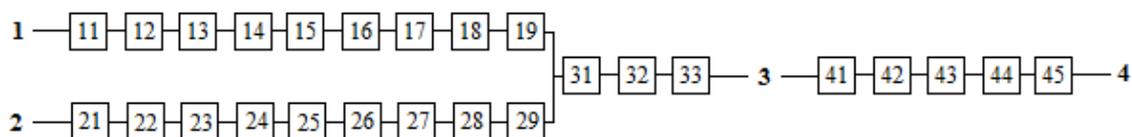


Figura 4.11 – Representação do sistema através de seus componentes. Fonte: própria do autor.

4.2.3. ESPECIFICAÇÕES

4.2.3.1. Fases

Em operação normal na seguinte condição de carga: 90%.

4.2.3.2. Condições de Contorno

- Disponibilidade de combustível no ponto 1.
- Disponibilidade de ar atmosférico no ponto 2.
- Nenhuma outra interação relativa ao ambiente será considerada, isto é, não se levará em conta nenhuma causa externa causadora de falha.

4.2.3.3. Hipótese Específica

Os dutos de escoamento do combustível, do ar de admissão e dos produtos da combustão não serão levados em conta no presente trabalho.

4.2.3.4. Condições Iniciais

O sistema funciona normalmente sem carga no começo da fase de operação, sendo que esta é gradualmente elevada.

4.2.3.5. Construção

O evento topo é definido como GRANDE DIFERENCIAL DE TEMPERATURA NO CILINDRO (δT_{cil}), ou seja, o evento “motor não dá partida” não

está incluído nas especificações dadas. A escolha deveu-se porque é o parâmetro operacional que abrange o maior número de falhas possível.

Segundo Dempsey (2008), um dos eventos contribuintes para esta ocorrência, possivelmente, é a carbonização excessiva no cilindro (MD11), fato atestado por Alho e Belchior (1998) em um trabalho que contou com a participação do autor. Também é possível que esteja ocorrendo uma ALTA temperatura na descarga dos produtos da combustão, fato deduzido a partir da Equação (08).

Este grande diferencial de temperatura no cilindro também pode ser causado por uma ALTA temperatura inicial da água refrigerante (TE_{agua}) que, quando associado à ocorrência simultânea de temperatura final da água refrigerante (TS_{agua}) NORMAL, indica que está havendo uma falha no trocador de calor (radiador) (MD10) devido, possivelmente, às incrustações nas aletas de passagem do ar.

Outra possibilidade de contribuição para a ocorrência de alta temperatura na descarga dos produtos da combustão é uma ALTA pressão máxima de combustão (P_{max}), decorrente do princípio termodinâmico que diz que quanto maior a pressão, maior a temperatura e vice-versa (SONNTAG *et al.*, 2003). Esta contribuição pode ser decorrente de um LONGO período de injeção de combustível (Δt_{inj}) que, quando associado a um GRANDE ângulo da manivela na pressão máxima de combustão, indica que há uma regulagem do início de injeção de combustível muito atrasada (MD5).

Por outro lado, a alta pressão máxima de combustão também pode ser causada por uma ALTA taxa de elevação da pressão de combustão (TEP_{comb}) decorrente de longo atraso da ignição. Este pode ocorrer devido o combustível estar com baixo número de cetanas, possivelmente por ter sido contaminado (MD1). Também pode ocorrer devido à dificuldade de se reduzir a grande dimensão das gotículas de combustível pela alta viscosidade do combustível (MD2) resultante de uma BAIXA temperatura de pré-aquecimento do combustível ($T_{\text{pre-aq}}$).

Outra possibilidade de ocorrência de uma alta taxa de elevação da pressão de combustão é quando há uma BAIXA pressão máxima de injeção (PI_{max}). Possibilidades de ocorrência deste evento intermediário são:

— Obstrução no escoamento pelo filtro de combustível (MD3);

- GRANDE ângulo da manivela na pressão de abertura da válvula de injeção ($\theta_{PI_{aber}}$), devido à regulação do início da injeção de combustível estar muito avançada (MD4);
- BAIXA pressão de abertura da válvula de injeção (PI_{aber}) possivelmente por defeito na mola e/ou travamento da agulha do bico injetor (MD6).

O período de atraso da ignição pode ser estendido e, conseqüentemente, a taxa de elevação de pressão vai aumentar (GANESAN, 1999), com a possibilidade de uma BAIXA pressão de compressão no cilindro (P_{comp}), oriunda de vazamento pela válvula de admissão da carga de ar e/ou válvula de descarga, ou então por desgaste nos anéis de segmento ou camisa do cilindro (MD12).

Outra possibilidade é a ocorrência de uma baixa concentração de oxigênio que causa uma BAIXA pressão do ar de admissão (P_{adm}). Esta pode ser causada tanto por uma BAIXA pressão na entrada do *intercooler* (PE_{ic}), quanto pela ALTA queda de pressão no *intercooler* (δP_{ic}) em razão de uma obstrução no escoamento do ar que passa pelo *intercooler* (MD9). As razões para uma baixa pressão na entrada do *intercooler* podem ser atribuídas a um defeito no compressor e/ou turbina (MD8), assim como a uma BAIXA pressão na entrada do turbo compressor (PE_{tc}) oriunda de obstrução no escoamento do ar pelo filtro, silenciador e duto de passagem do ar no turbo compressor (MD7).

A árvore de falhas é apresentada na Figura 36 a seguir, onde os números dentro dos círculos representam os modos de falha na operação do motor.

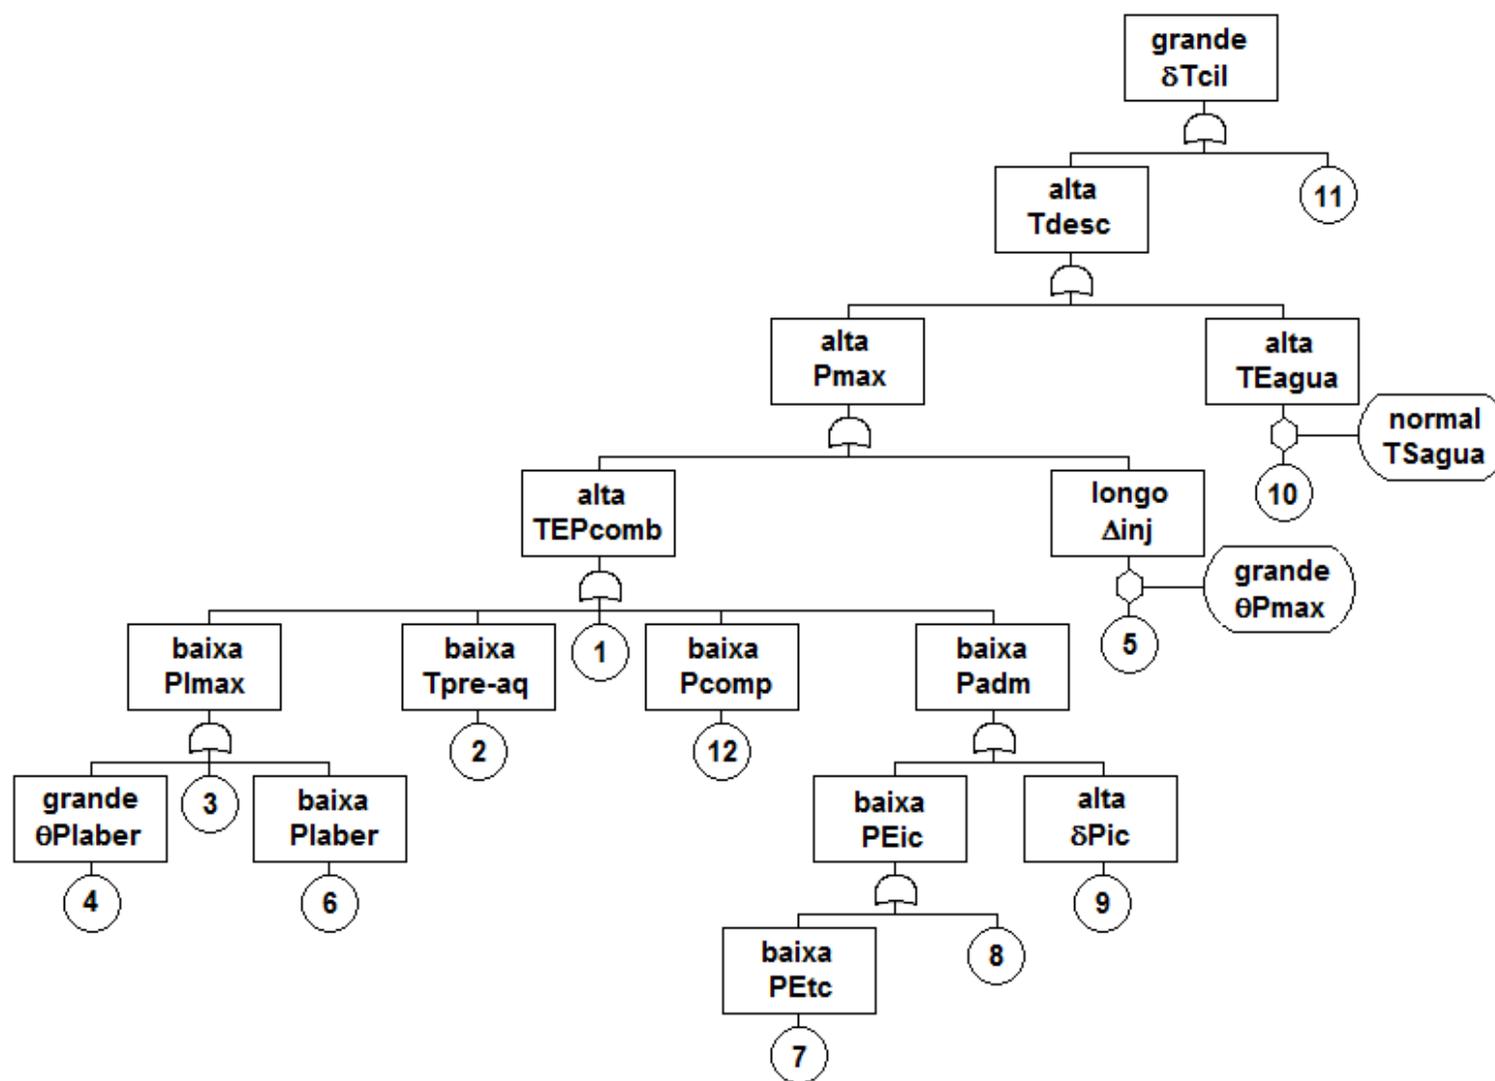


Figura 4.12 – Árvore de falhas do sistema. Fonte: própria do autor.

4.3. A Definição da Heurística para o Diagnóstico de Falhas em Motores Diesel

Segundo Lewis (1996), um conjunto de informações representa conhecimento quando se consegue definir o relacionamento ou a dependência mútua que existe entre os fatos ou atributos que fazem parte do mesmo. No presente trabalho, a heurística de diagnóstico de falhas em motores diesel é um conjunto bem definido de premissas e conclusões. As premissas são representadas pelo relacionamento e dependência entre os eventos de falha caracterizados pelas propriedades termodinâmicas do processo de combustão do motor, definidas parâmetros operacionais, e as conclusões são a localização das falhas nos seus componentes. A heurística de diagnóstico de falhas é fundamentada nas séries de corte mínimas, estabelecidas pela AAF, que expressam a função de estrutura (ou de ligação) coerente (ou logicamente consistente).

De acordo com Zio (2007), as séries de corte são definidas, fisicamente, como um conjunto de eventos cuja indicação individual de falha assegura a falha do sistema como um todo. Já uma série de corte mínima é uma série de corte que não possui outra série de corte como subconjunto. Fisicamente, é definida como uma série de corte irreduzível, isto é, quando se repara um elemento do conjunto, repara-se o sistema como um todo. Devido a isto, quando se remove um elemento de uma série de corte mínima, o conjunto gerado após a remoção do elemento já não é mais uma série de corte mínima.

Uma função de estrutura coerente incorpora todas as séries de corte mínimas, que são as relações causais entre os eventos que levam ao evento topo. É uma função booleana das variáveis booleanas que descrevem as condições dos n eventos de falhas no motor diesel e seus componentes, indicados como X_1, X_2, \dots, X_n . Representando o evento topo da árvore de falhas pela variável indicadora X_T , obtém-se a função de ligação recíproca baseada na lógica da álgebra booleana e que proporciona uma análise qualitativa da árvore, ou seja,

$$X_T = \Phi(X_1, X_2, \dots, X_n) \quad (14)$$

Uma vez identificadas as séries de corte, a função de estrutura do sistema pode ser expressa como a união dos conjuntos de corte e esta constitui uma forma única e irreduzível da função estrutura coerente do sistema. Segundo Zio (2007), a partir desta

análise pode-se construir uma árvore de falhas equivalente para qualquer sistema apenas com um portão OU no primeiro nível, abaixo do evento topo, que combine todas as séries de corte mínimas, cada uma, por seu turno, representada por um portão E que intercepta todos os eventos que compreendem a série de corte mínima em questão.

Pela árvore de falhas mostrada na Figura 36, observa-se que existem 12 (doze) séries de corte mínimas. A partir de cada uma destas séries são construídas as regras de diagnóstico, onde as premissas são definidas pelo evento topo e pelos eventos intermediários e as conclusões são dadas pelos eventos básicos primários. Por exemplo, reportando-nos ao modo de falha 7 (MD7), temos como premissas a ocorrência simultânea de grande δT_{cil} , alta T_{desc} , alta P_{max} , alta TEP_{comb} , baixa P_{adm} , baixa PE_{ic} e baixa PE_{tc} e como conclusão a falha MD7. Deste modo organizamos as regras de diagnóstico de falhas nas tabelas a seguir.

Tabela 4.1 – Regra de diagnóstico para o modo de falha MD1.

Premissas	Conclusões
GRANDE δT_{cil} ALTA T_{desc} ALTA P_{max} ALTA TEP_{comb}	Combustível com baixo número de cetanas devido à contaminação.

Fonte: própria do autor.

Tabela 4.2 – Regra de diagnóstico para o modo de falha MD2.

Premissas	Conclusões
GRANDE δT_{cil} ALTA T_{desc} ALTA P_{max} ALTA TEP_{comb} BAIXA T_{pre-aq}	Falha no pré-aquecedor gerando alta viscosidade no combustível.

Fonte: própria do autor.

Tabela 4.3 – Regra de diagnóstico para o modo de falha MD3.

Premissas	Conclusões
GRANDE δT_{cil} ALTA T_{desc} ALTA P_{max} ALTA TEP_{comb} BAIXA PI_{max}	Obstrução no escoamento pelo filtro de combustível.

Fonte: própria do autor.

Tabela 4.4 – Regra de diagnóstico para o modo de falha MD4.

Premissas	Conclusões
GRANDE δT_{cil} ALTA T_{desc} ALTA P_{max} ALTA TEP_{comb} BAIXA PI_{max} GRANDE $\theta_{PI_{aber}}$	A regulagem do início da injeção de combustível está muito avançada.

Fonte: própria do autor.

Tabela 4.5 – Regra de diagnóstico para o modo de falha MD5.

Premissas	Conclusões
GRANDE δT_{cil} ALTA T_{desc} ALTA P_{max} LONGO Δt_{inj} GRANDE $\theta_{P_{max}}$	A regulagem do início da injeção de combustível está muito atrasada.

Fonte: própria do autor.

Tabela 4.6 – Regra de diagnóstico para o modo de falha MD6.

Premissas	Conclusões
GRANDE δT_{cil} ALTA T_{desc} ALTA P_{max} ALTA TEP_{comb} BAIXA PI_{max} BAIXA PI_{aber}	Defeito na mola e/ou travamento da agulha do bico injetor.

Fonte: própria do autor.

Tabela 4.7 – Regra de diagnóstico para o modo de falha MD7.

Premissas	Conclusões
GRANDE δT_{cil} ALTA T_{desc} ALTA P_{max} ALTA TEP_{comb} BAIXA P_{adm} BAIXA PE_{ic} BAIXA PE_{tc}	Obstrução no escoamento pelo filtro, silenciador e duto de passagem de ar no turbocompressor.

Fonte: própria do autor.

Tabela 4.8 – Regra de diagnóstico para o modo de falha MD8.

Premissas	Conclusões
GRANDE δT_{cil} ALTA T_{desc} ALTA P_{max} ALTA TEP_{comb} BAIXA P_{adm} BAIXA PE_{ic}	Defeito no compressor e/ou turbina.

Fonte: própria do autor.

Tabela 4.9 – Regra de diagnóstico para o modo de falha MD9.

Premissas	Conclusões
GRANDE δT_{cil} ALTA T_{desc} ALTA P_{max} ALTA TEP_{comb} BAIXA P_{adm} ALTA δP_{ic}	Obstrução no escoamento do ar pelo intercooler.

Fonte: própria do autor.

Tabela 4.10 – Regra de diagnóstico para o modo de falha MD10.

Premissas	Conclusões
GRANDE δT_{cil} ALTA T_{desc} BAIXA TS_{agua} NORMAL TE_{agua}	Falha no trocador de calor (radiador).

Fonte: própria do autor.

Tabela 4.11 – Regra de diagnóstico para o modo de falha MD11.

Premissas	Conclusões
GRANDE δT_{cil}	Carbonização excessiva na câmara de combustão do cilindro.

Fonte: própria do autor.

Tabela 4.12 – Regra de diagnóstico para o modo de falha MD12.

Premissas	Conclusões
GRANDE δT_{cil} ALTA T_{desc} ALTA T_{desc} ALTA P_{max} ALTA TEP_{comb} BAIXA P_{comp}	Vazamento pela válvula de admissão da carga de ar e/ou válvula de descarga dos produtos da combustão, ou devido à desgaste dos anéis de segmento ou camisa do cilindro.

Fonte: própria do autor.

Privilegiando a prática, é normal que as informações geradas pela técnica da AAF, ou seja, as regras de diagnóstico sejam organizadas em forma de matrizes de diagnóstico, onde os modos de falha são listados em uma direção e os parâmetros operacionais representativos do processo termodinâmico de combustão no motor em outra. Com esta estrutura, cada modo de falha possui seu respectivo vetor de estado, o qual descreve o comportamento de cada parâmetro operacional com relação às anormalidades especificadas (Tabela 17).

Tabela 4.13 – Matriz de diagnósticos.

Modos de Falha	P _{max}	P _{comp}	θP _{max}	TEP _{comb}	T _{desc}	T _{adm}	δT _{cil}	TS _{agua}	TE _{agua}	δT _{agua}	P _{lmax}	P _{l_{ab}er}	θP _{l_{ab}er}	Δ _{inj}	T _{pre-aq}	P _{adm}	P _{amb}	PE _{tc}	PE _{ic}	δP _{ic}
MD0	N	N	N	N	N	N	N	N	N	N	N	N	N	N	N	N	N	N	N	N
MD1	A	N	N	A	A	N	G	N	N	N	N	N	N	N	N	N	N	N	N	N
MD2	A	N	N	A	A	N	G	N	N	N	N	N	N	N	B	N	N	N	N	N
MD3	A	N	N	A	A	N	G	N	N	N	B	N	N	N	N	N	N	N	N	N
MD4	A	N	N	A	A	N	G	N	N	N	B	N	G	N	N	N	N	N	N	N
MD5	A	N	G	N	A	N	G	N	N	N	N	N	N	L	N	N	N	N	N	N
MD6	A	N	N	A	A	N	G	N	N	N	B	B	N	N	N	N	N	N	N	N
MD7	A	N	N	A	A	N	G	N	N	N	N	N	N	N	N	B	N	B	B	N
MD8	A	N	N	A	A	N	G	N	N	N	N	N	N	N	N	B	N	N	B	N
MD9	A	N	N	A	A	N	G	N	N	N	N	N	N	N	N	B	N	N	N	A
MD10	N	N	N	N	A	N	G	N	A	B	N	N	N	N	N	N	N	N	N	N
MD11	N	N	N	N	N	N	G	N	N	N	N	N	N	N	N	N	N	N	N	N
MD12	A	B	N	A	A	N	G	N	N	N	N	N	N	N	N	N	N	N	N	N

Fonte: própria do autor.

N – Normal; A – Alta; B – Baixa; L – Longo; Grande – G.

5. CLASSIFICAÇÃO DAS FALHAS

Esta seção mostra a utilização de uma RNA para detectar a condição de operação de um motor diesel. O objetivo é construir um classificador que possa distinguir entre condição de operação normal e condição de operação em modo de 12 (doze) possíveis falhas, a partir de eventos ocorridos em propriedades termodinâmicas características do processo de combustão do motor. Inclui a definição do problema, treinamento, validação e teste da RNA.

5.1. A Definição do Problema

Este trabalho propõe um método para a revelação da condição de operação de um motor diesel como normal ou em modo de falha baseada em 20 (vinte) parâmetros operacionais que refletem propriedades termodinâmicas do processo de combustão que ocorre durante o ciclo de operação do motor. Trata-se da resolução de um típico problema de classificação de falhas por reconhecimento de padrões em que o número de características é muito maior do que o número de observações. Neste tipo de problema não se pode realizar uma classificação correta a partir de uma só característica. É necessário, portanto, criar um classificador que aprenda de forma adequada a ponderar características múltiplas e, ao mesmo tempo, fazer um mapeamento generalizado que não seja superestimado.

O conjunto de dados consiste de 195 (cento e noventa e cinco) vetores de entrada, com 20 (vinte) elementos cada, dispostos como colunas em uma matriz e 195 (cento e noventa e cinco) vetores alvos (valores desejados), com 13 (treze) elementos cada, que indicam as classes de falha ou de condição normal que os vetores de entrada determinam.

Cada coluna da matriz de vetores de entrada da rede representa uma condição de operação do motor. Há 15 (quinze) colunas que representam a condição de operação normal e 15 (quinze) colunas representantes de cada uma das 12 (doze) condições de operação em modo de falha que perfazem um total de 195 (cento e noventa e cinco) colunas. Cada linha desta matriz de vetores de entrada representa a medida de um parâmetro operacional que reflete uma propriedade termodinâmica. Através dos valores de alarme fornecidos por New Sulzer Diesel (1990), determinaram-se os valores dos

parâmetros operacionais em condição de operação normal do motor contidos na Tabela 31 do anexo A. É de se ressaltar que os valores-limite (thresholds) que definem a condição de normal, alta (longo, grande) e baixa (curto) dos parâmetros são estabelecidos pelas sociedades classificadoras¹, conforme WARKMAN (1983) e NEW SULZER DIESEL (1990), através do desvio relativo fixado em $\pm 2\%$.

Cada coluna da matriz de vetores alvo (valores desejados) representa uma classe de modo de falha (condição operacional) a que os vetores da matriz de entrada serão atribuídos. Para definir o problema em que as 20 (vinte) entradas devam ser classificadas em 13 (treze) classes diferentes, em cada vetor alvo um elemento é 1 (sucesso) e os outros são 0 (insucesso), conforme mostra a Tabela 32 do anexo B. Os vetores da matriz de entrada de dados são mostrados no anexo C.

5.2. Treinamento, Validação e Teste da Rede Neural Artificial (RNA)

A topologia da RNA é composta de uma camada de entrada, uma camada escondida e uma camada de saída. O número de entradas do sistema determina o número de neurônios na camada de entrada da rede e seu número de saídas determina o número de neurônios na camada de saída. Assim, a camada de entrada da rede tem 20 (vinte) neurônios e a camada de saída tem 13 (treze) neurônios ao passo que 55 (cinquenta e cinco) neurônios foram usados na camada escondida, conforme mostra a Figura 37.

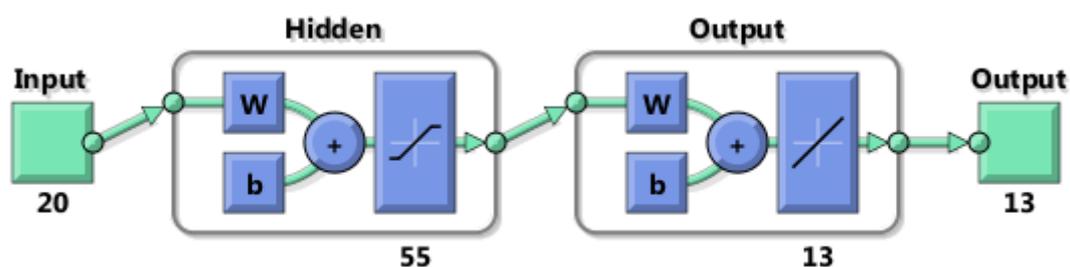


Figura 5.1 – Topologia da RNA.

Na plataforma MATLAB (ANÔNIMO, 2010), foi desenvolvido o algoritmo que

¹IACS, Nippon K.K., RINA, Polish Register, Russian Register, American Bureau, Bureau Veritas, Det Norske Veritas, German Lloyd, Lloyds Register, Ppls. Rep. of China Reg.

modela uma RNA para servir de classificadora de falhas por reconhecimento de padrão. O algoritmo é mostrado no anexo D, enquanto que os detalhes dos parâmetros do modelo são exibidos na Tabela 18.

Tabela 5.1 – Detalhes dos parâmetros da rede desenvolvida na plataforma MATLAB.

Função de criação da rede	patternnet (RNA de reconhecimento de padrão)
Dados	Subconjunto de treinamento: 80% do conjunto de dados selecionados aleatoriamente Subconjunto de validação: 5% do conjunto de dados selecionados aleatoriamente Subconjunto de teste: 15% do conjunto de dados selecionados aleatoriamente
Função de ativação (transferência)	Camada escondida: Transferência linear de saturação simétrica. Camada de saída: Transferência linear
Algoritmo de treinamento	trainscg (<i>Backpropagation</i> gradiente conjugado em escala)
Critério da função de perda	mse (Erro médio quadrático)
Critério de parada	Parar o treinamento da rede quando o erro de validação começar a aumentar em até 6 (seis) repetições.

Após o erro no subconjunto de validação aumentar durante 6 (seis) iterações consecutivas o treinamento foi encerrado e o melhor desempenho de validação serviu como ponto de verificação de desempenho para os outros dois subconjuntos (treinamento e teste). Os resultados com os desempenhos dos três subconjuntos são apresentados na Tabela 19.

Tabela 5.2 – Desempenho individual dos subconjuntos de dados.

	Desempenho
Treinamento	0,0142
Validação	0,1051
Teste	0,0742

A rede teve um desempenho global com valor = 0,0278. Este, juntamente com

os dados do desempenho individual, configura um desempenho satisfatório da rede que pode ser creditado às seguintes razões:

- O erro médio quadrático é pequeno;
- O erro do conjunto de teste e o erro do conjunto de validação têm características similares devido à menor quantidade de amostras;
- Não ocorreu nenhum *overfitting* importante na interação onde ocorreu o melhor desempenho de validação.

A Figura 38 fornece uma verificação adicional do desempenho da rede através do histograma de erros, que mostra que a maioria dos erros situa-se entre -0,3 e 0,3 e que não há pontos de dados com erros significativamente diferentes da maioria, conhecidos como *outliers*. Isto indica um desempenho satisfatório da rede, sem a necessidade de treiná-la novamente com novos dados mais próximos aos *outliers*, uma vez que não há extrapolação para estes.

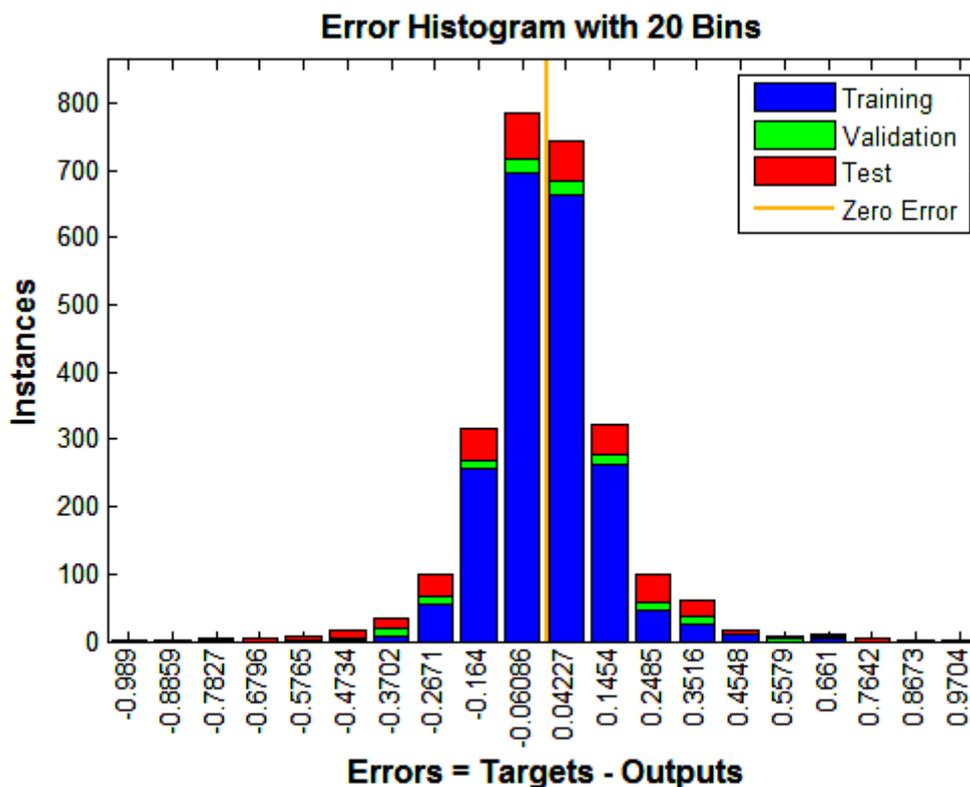


Figura 5.2 – Histograma de erros dos subconjuntos de dados.

As matrizes de confusão apresentam os vários tipos de erro que ocorreram na

rede treinada final através dos subconjuntos de treinamento, validação, teste e para os 3 (três) dados combinados. As células da diagonal principal mostram o número de casos que foram corretamente classificados e as células fora da diagonal principal mostram o número de casos classificados incorretamente. A célula no canto inferior direito da matriz mostra o percentual total de casos corretamente classificados (em verde) e o percentual total de casos incorretamente classificados (em vermelho). Os resultados apresentam um muito bom reconhecimento.

O primeiro caso é o da classificação de falhas do subconjunto de treinamento com 156 (cento e cinquenta e seis) elementos, que corresponde a 80% do total de amostras. Foram classificados corretamente todas as amostras (100%), conforme mostra a Figura 39.

Training Confusion Matrix

Output Class	1	14 9.0%	0 0.0%	100% 0.0%											
	2	0 0.0%	11 7.1%	0 0.0%	100% 0.0%										
	3	0 0.0%	0 0.0%	15 9.6%	0 0.0%	100% 0.0%									
	4	0 0.0%	0 0.0%	0 0.0%	9 5.8%	0 0.0%	100% 0.0%								
	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	13 8.3%	0 0.0%	100% 0.0%							
	6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	12 7.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%	
	7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	12 7.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%	
	8	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	13 8.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%	
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	12 7.7%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%	
	10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	13 8.3%	0 0.0%	0 0.0%	100% 0.0%	
	11	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	12 7.7%	0 0.0%	100% 0.0%	
	12	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	11 7.1%	0 0.0%	100% 0.0%
	13	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	9 5.8%	100% 0.0%
		100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	
		1	2	3	4	5	6	7	8	9	10	11	12	13	
		Target Class													

Figura 5.3 – Matriz de confusão de classificação de falhas para o subconjunto de treinamento.

A segunda matriz de classificação é a que utiliza os dados para a validação da rede, com 10 (dez) amostras correspondentes a, aproximadamente, 5% do total. Neste caso foram classificados como corretos 7 (sete) modos de falha correspondentes a 70%, enquanto que 3 (três) modos de falha, correspondentes a 30% foram classificados como incorretos, conforme mostra a Figura 40. Apesar das classificações não estarem razoavelmente satisfatórias, não se pode levá-las em conta, neste caso, porque o subconjunto de validação não tem uma influência direta no treinamento da rede, servindo apenas ao critério de encerramento do treinamento.

Validation Confusion Matrix

1	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	NaN%
2	0 0.0%	1 10.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100%
3	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	NaN%
4	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	NaN%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 10.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100%
6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 10.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100%
7	0 0.0%	0 0.0%	0 0.0%	1 10.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0.0%
8	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 10.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100%
9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	NaN%
10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	NaN%
11	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2 20.0%	0 0.0%	0 0.0%	100%
12	0 0.0%	1 10.0%	0 0.0%	0 0.0%	0 0.0%	1 10.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0.0%
13	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 10.0%	100%
	NaN%	50.0%	NaN%	0.0%	100%	50.0%	NaN%	100%	NaN%	NaN%	100%	NaN%	100%	70.0%
	NaN%	50.0%	NaN%	100%	0.0%	50.0%	NaN%	0.0%	NaN%	NaN%	0.0%	NaN%	0.0%	30.0%
	1	2	3	4	5	6	7	8	9	10	11	12	13	

Target Class

Figura 5.4 – Matriz de confusão de classificação de falhas para o subconjunto de validação.

A matriz de confusão de classificação de falhas para o subconjunto de teste fornece uma medida completamente independente da precisão da rede. No presente caso, observamos uma boa precisão na classificação de falhas, uma vez que 22 (vinte e dois), cerca de 75,9% dos modos de falha, foram classificados corretamente, enquanto que apenas 7 (sete) casos, aproximadamente 24,1%, foram desclassificados, conforme mostra a Figura 41.

Test Confusion Matrix

Output Class	1	1 3.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 3.4%	0 0.0%	50.0%	
	2	0 0.0%	2 6.9%	0 0.0%	2 6.9%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 3.4%	0 0.0%	40.0%
	3	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	NaN%
	4	0 0.0%	0 0.0%	0 0.0%	2 6.9%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100%
	5	0 0.0%	0 0.0%	0 0.0%	1 3.4%	1 3.4%	0 0.0%	0 0.0%	0 0.0%	1 3.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	33.3%
	6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 3.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100%
	7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	3 10.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 3.4%	0 0.0%	75.0%
	8	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 3.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100%
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2 6.9%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100%
	10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2 6.9%	0 0.0%	0 0.0%	0 0.0%	100%
	11	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 3.4%	0 0.0%	0 0.0%	100%
	12	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 3.4%	0 0.0%	100%
	13	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	5 17.2%	100%
		100%	100%	NaN%	40.0%	100%	100%	100%	66.7%	100%	100%	25.0%	100%	75.9%	
		0.0%	0.0%	NaN%	50.0%	0.0%	0.0%	0.0%	33.3%	0.0%	0.0%	75.0%	0.0%	24.1%	
		1	2	3	4	5	6	7	8	9	10	11	12	13	
		Target Class													

Figura 5.5 – Matriz de confusão de classificação de falhas para o subconjunto de teste.

As matrizes de confusão fornecem um quadro abrangente do desempenho de classificação de falhas da classificadora, através dos subconjuntos dos 3 (três) dados

combinados, como mostra a Figura 42.

All Confusion Matrix

Output Class	1	15 7.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.5%	0 0.0%	93.8% 6.3%	
	2	0 0.0%	14 7.2%	0 0.0%	2 1.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.5%	0 0.0%	82.4% 17.6%	
	3	0 0.0%	0 0.0%	15 7.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%	
	4	0 0.0%	0 0.0%	0 0.0%	11 5.6%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%	
	5	0 0.0%	0 0.0%	0 0.0%	1 0.5%	15 7.7%	0 0.0%	0 0.0%	0 0.0%	1 0.5%	0 0.0%	0 0.0%	0 0.0%	88.2% 11.8%	
	6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	14 7.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%	
	7	0 0.0%	0 0.0%	0 0.0%	1 0.5%	0 0.0%	0 0.0%	15 7.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.5%	88.2% 11.8%	
	8	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	15 7.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%	
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	14 7.2%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%	
	10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	15 7.7%	0 0.0%	0 0.0%	100% 0.0%	
	11	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	15 7.7%	0 0.0%	100% 0.0%	
	12	0 0.0%	1 0.5%	0 0.0%	0 0.0%	0 0.0%	1 0.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	12 6.2%	85.7% 14.3%	
	13	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	15 7.7%	100% 0.0%
		100% 0.0%	93.3% 6.7%	100% 0.0%	73.3% 26.7%	100% 0.0%	93.3% 6.7%	100% 0.0%	100% 0.0%	93.3% 6.7%	100% 0.0%	100% 0.0%	80.0% 20.0%	100% 0.0%	94.9% 5.1%
		1	2	3	4	5	6	7	8	9	10	11	12	13	
		Target Class													

Figura 5.6 – Matriz de confusão de classificação de falhas para o conjunto total de amostras.

Como o ideal é que possua a soma da sua diagonal principal igual ao número de amostras, podemos observar pela figura que, após o treinamento, a RNA apresentou ótimo reconhecimento (classificação) de falhas, uma vez que de um total de 195 (cento e noventa e cinco) vetores de modos de condição de operação que compõem a matriz de entrada da rede, 185 (cento e oitenta e cinco), correspondentes a 94,9%, foram classificados corretamente, enquanto que apenas 10 (dez), que correspondem a 5,1% do

total, foram incorretamente classificados.

A Figura 43 mostra o resultado da análise da sensibilidade da RNA classificadora de falhas em função da especificidade de cada classe de condição de operação do motor, ou seja, a taxa de verdadeiro positivo (sensibilidade) versus a taxa de falso negativo (especificidade) para diferentes “thresholds” da saída da classificadora.

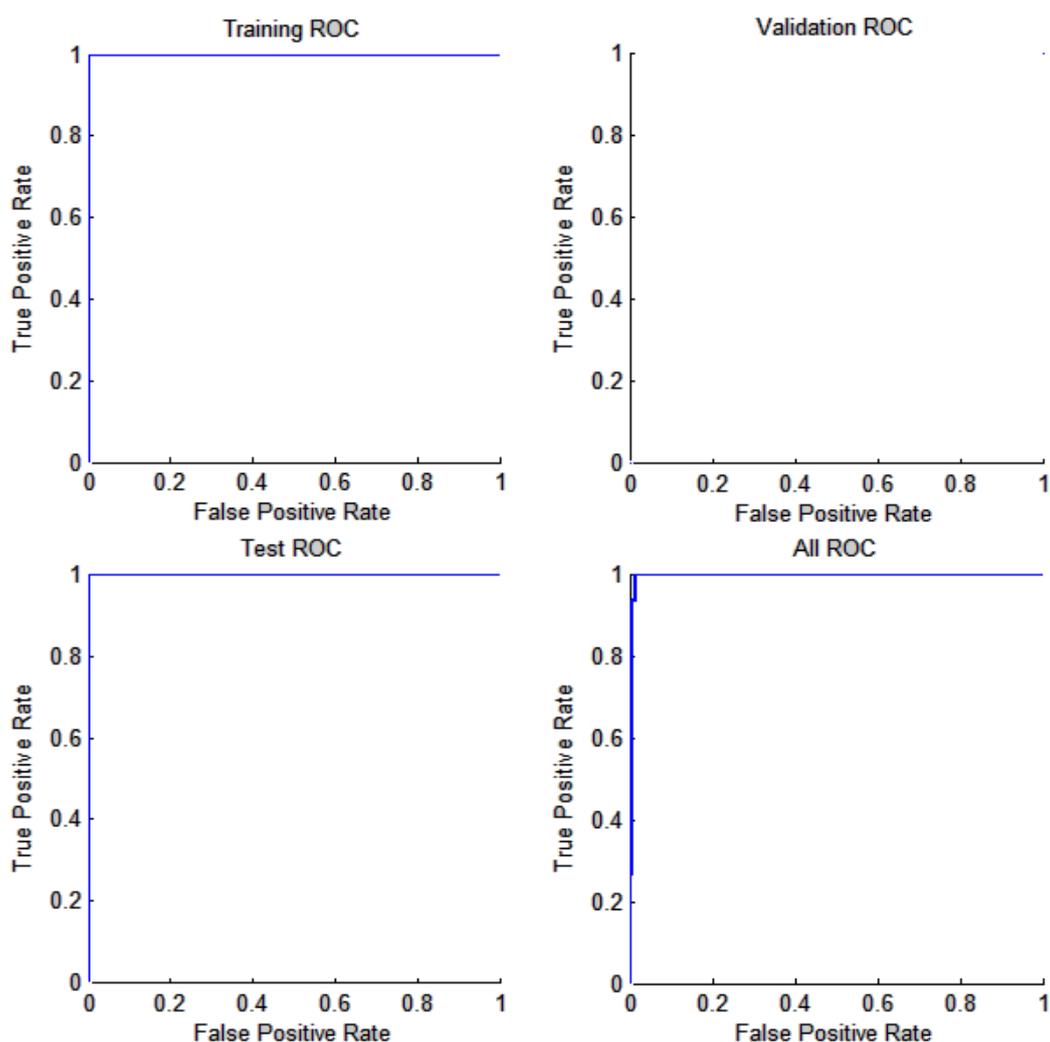


Figura 5.7 – Característica de Operação do Receptor para os subconjuntos de treinamento, validação, teste e para o conjunto total de amostras de dados.

Estas curvas são criadas pelas funções ROC (Características de Operação do Receptor) que aplicam, para cada classe de condição de operação, um valor limite do intervalo $[0, 1]$ às saídas. Desse modo, são calculados dois valores para cada limite: o

valor 1 é a razão verdadeiro positivo, que é o número de saídas maior ou igual ao limite dividido pelo número de alvos (valores desejados); o valor 0 é a razão falso positivo, que, neste caso, é o número de saídas menores do que o limite dividido pelo número de alvos (valores desejados).

As curvas ROC dão a medida da qualidade das RNA's classificadoras e mostram as suas capacidades de distinguir, entre as várias amostras de dados, aquelas que se adequam às suas devidas classes. Um desempenho perfeito da RNA é o que apresenta os pontos situados no canto superior esquerdo, indicando 100% de sensibilidade e 100% de especificidade. Isto mostra que a aplicação da função ROC sobre os subconjuntos de treinamento, teste e para o conjunto total de amostras de dados da RNA classificadora proposta neste trabalho indica que o desempenho da rede foi muito bom, conforme pudemos observar na Figura 43. A ausência da curva para os dados de validação deve-se ao fato, já mencionado, de que a função deste subconjunto é de, apenas, servir ao critério de parada de treinamento da RNA.

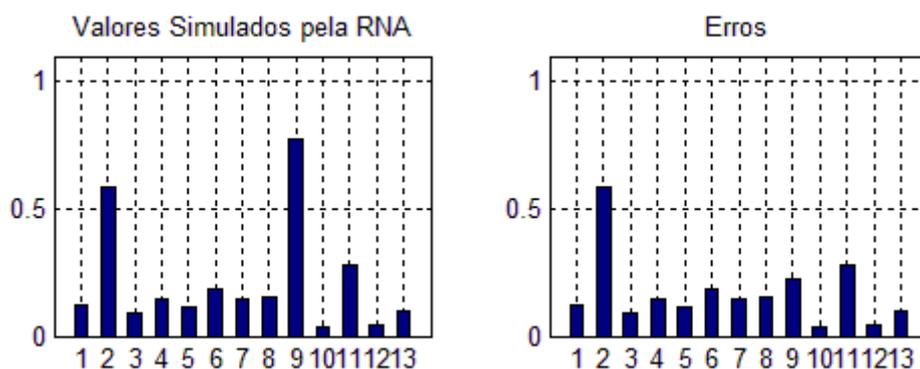
Como a resposta da rede desenvolvida neste trabalho mostrou-se bastante satisfatória, foram realizados testes com valores aleatórios escolhidos entre os que constam nos dados de entrada da RNA classificadora. Os testes utilizam a função 'sim' que é a função de simulação de redes neurais do Matlab. A sintaxe utilizada na janela de comando para testar a ocorrência da condição de operação é a seguinte:

```
>> sim(netDiagDiesel,inputs(:,134))
```

Os resultados são apresentados na Tabela 20. Os sinais negativos que aparecem em alguns valores da tabela são devidos ao domínio das funções de transferência que varia entre -1 e 1. A Figura 44 apresenta os gráficos com os resultados.

Tabela 5.3 – Resultados do teste $\text{sim}(\text{netDiagDiesel}, \text{inputs}(:,134))$.

Simulado	Erro
-0,1247	0,1247
0,5837	-0,5837
-0,0917	0,0917
-0,1477	0,1477
-0,1176	0,1176
0,1861	-0,1861
0,1418	-0,1418
0,1530	-0,1530
0,7760	0,2240
-0,0359	0,0359
-0,2819	0,2819
-0,0431	0,0431
-0,0959	0,0959

**Figura 5.8** – Resultados do teste de simulação $\text{sim}(\text{netDiagDiesel}, \text{inputs}(:,134))$.

Observa-se, pelos resultados apresentados, que há uma única ocorrência de “outlier” que, por ter valor acima de 0,5, faz parte de um conjunto de dados quase insignificante, como pode ser atestado pela Figura 38. Podemos concluir, então, que a probabilidade de nova ocorrência deste “outlier” é bastante pequena. Os outros erros possuem grandezas que os colocam na condição de normalidade e, com isto, podemos afirmar que o teste indica operação em condição MD8.

Outro teste foi realizado utilizando a seguinte sintaxe na janela de comando do Matlab:

```
>> sim(netDiagDiesel,inputs(:,14))
```

Os resultados obtidos mostraram, mais uma vez, a boa precisão da rede, conforme mostram a Tabela 21 e a Figura 45.

Tabela 5.4 – Resultados do teste `sim(netDiagDiesel,inputs(:,14))`.

Simulado	Erro
0,8696	0,1304
0,1557	-0,1557
0,0497	-0,0497
-0,0590	0,0590
-0,0048	0,0048
0,0363	-0,0363
0,0145	-0,0145
0,0521	-0,0521
0,0738	-0,0738
-0,1702	0,1702
-0,0965	0,0965
-0,0298	0,0298
-0,0473	0,0473

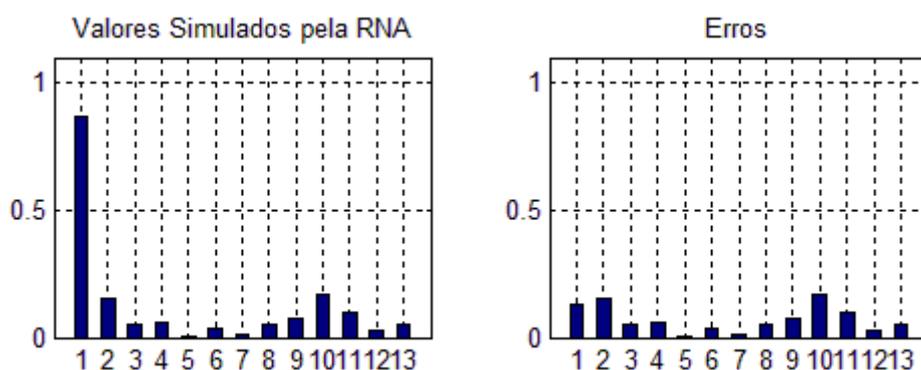


Figura 5.9 – Resultados do teste de simulação `sim(netDiagDiesel,inputs(:,14))`.

Os erros oriundos da simulação da RNA, neste caso, apresentaram valores insignificantes, o que proporciona uma grande precisão na afirmação de que a condição de operação é normal (MD0).

6. RESULTADOS DA UTILIZAÇÃO DA RNA E DISCUSSÕES

Com a rede neural apresentando um resultado bastante satisfatório após o seu treinamento, validação e teste, é possível a sua utilização com dados de entrada reais. Estes dados foram obtidos a partir de uma simulação de falhas em uma instalação experimental que contou com um motor diesel componente de um grupo diesel-gerador de um navio mercante instrumentado com sistema de aquisição de dados de combustão e injeção de combustível MIP Calculator NK-100 da Autronica AS, termopares e manômetros fixados em pontos específicos da instalação, conforme foi mostrado na seção 3.1 (Determinação dos Parâmetros Operacionais).

Os ensaios foram realizados com o motor operando em 90% de carga, conforme preconizam as sociedades classificadoras anteriormente mencionadas. Os valores dos parâmetros operacionais medidos e registrados, diretamente ou derivados de outros, compõem a matriz de dados de entrada para a utilização da rede e que vão servir para a realização de estudos de caso. As especificações técnicas do motor diesel estão resumidas na Tabela 22.

Tabela 6.1 – Dados técnicos do motor testado.

Marca e Modelo	Sulzer ZA40S
Tipo de Motor	Diesel com turbocompressor e intercooler, quatro-tempos.
Número de Cilindros	9
Diâmetro/Curso	400/560 [mm/mm]
Potência do Motor	720 kW/cilindro
Rotação	510 rpm

Fonte: New Sulzer Diesel, 1990.

6.1. Estudo de Caso: Condição de Operação Simulada para MD3

A condição de operação MD3 diz respeito a uma possível obstrução no filtro do sistema de injeção de combustível. Para reproduzir esta condição, o filtro de óleo do sistema de injeção de combustível do motor foi substituído por um que já apresentava sintomas de obstrução. A Figura 46 mostra o resultado do teste realizado no cilindro 1 do motor para combustão.

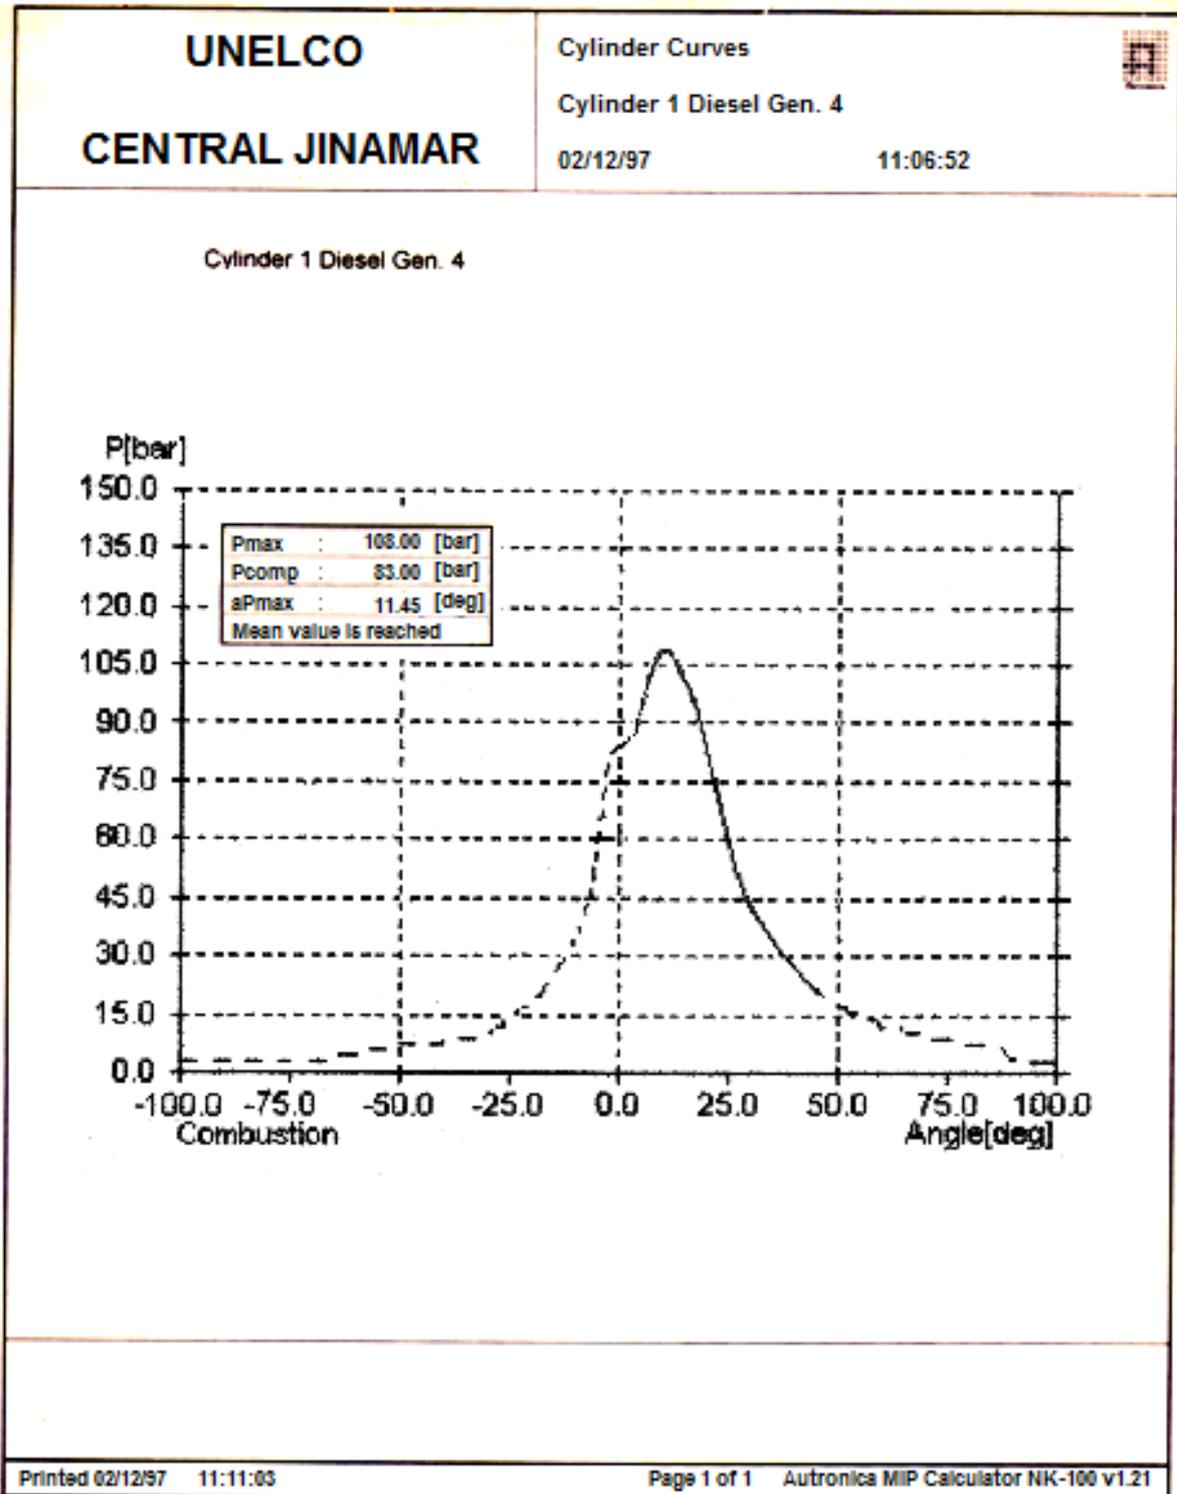


Figura 6.1 – Diagrama indicado de combustão $p \times \theta$ do cilindro 1 do motor testado para condição de operação MD3. Fonte: MIP Calculator NK-100.

A Figura 47 mostra o resultado do teste realizado no cilindro 1 do motor para o sistema de injeção de combustível.

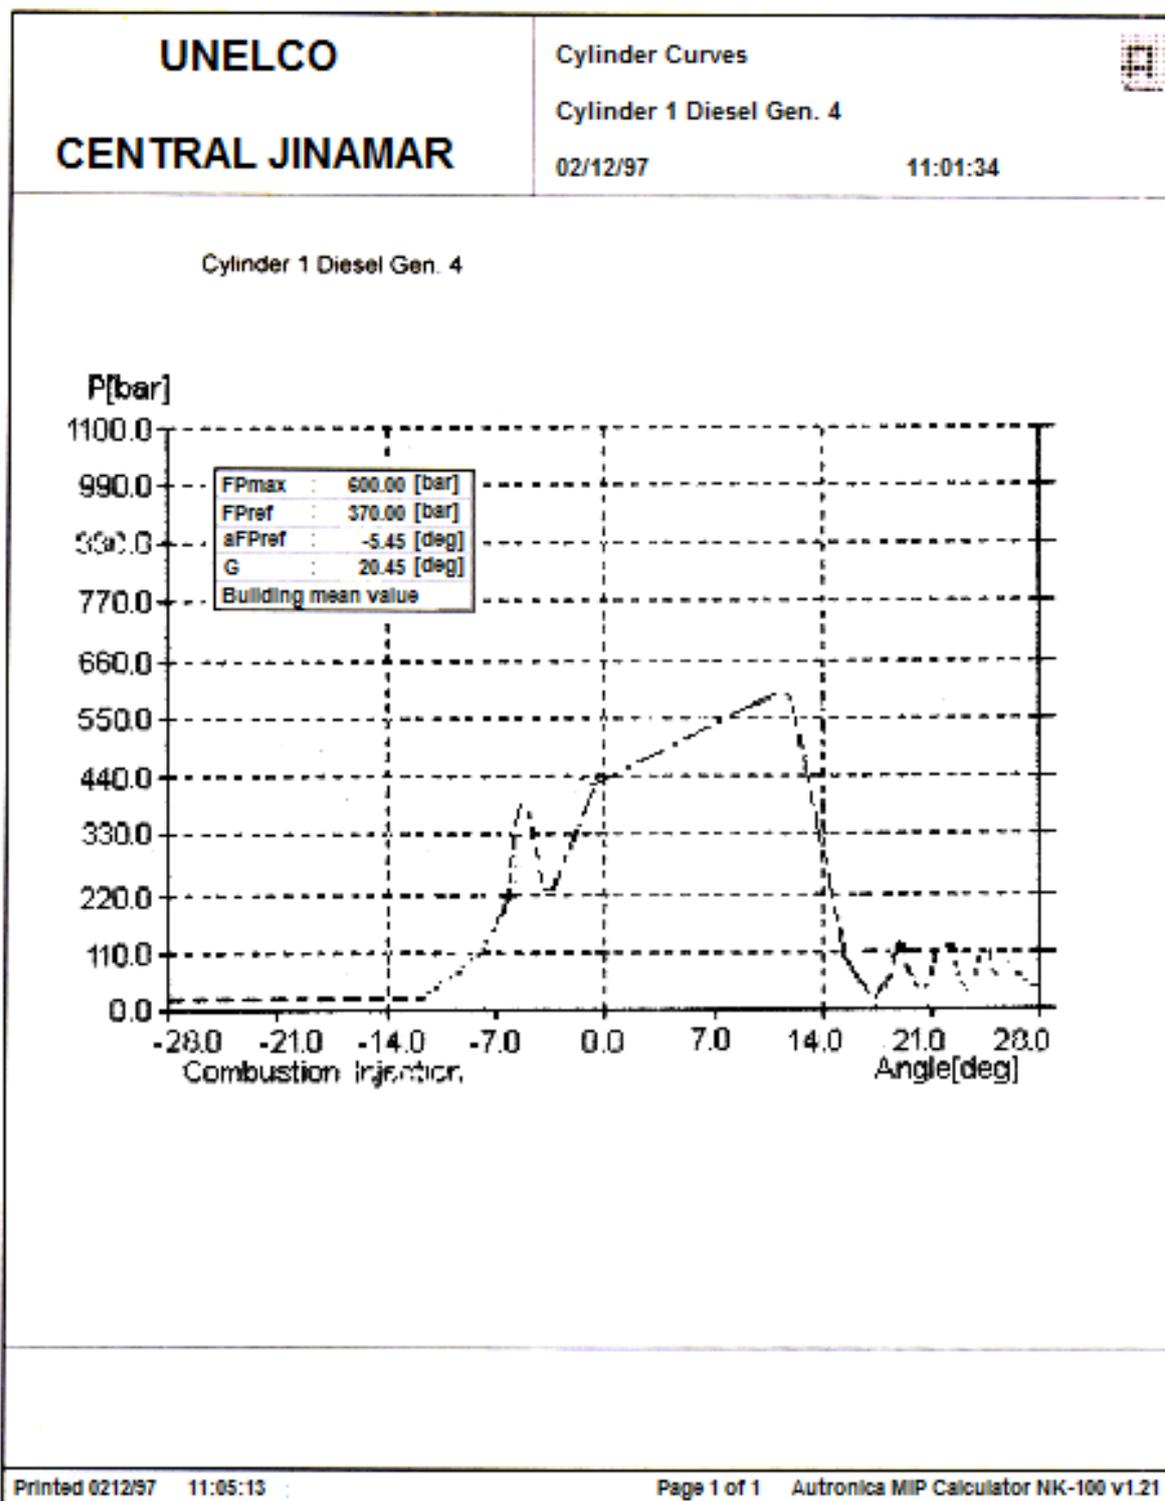


Figura 6.2 – Diagrama indicado de injeção $PI \times \theta$ do cilindro 1 do motor testado para condição de operação MD3. Fonte: MIP Calculator NK-100.

A matriz de dados de entrada que alimentará a RNA para a realização da simulação é composta pelos parâmetros obtidos pelo sistema de aquisição de dados

montado no motor, mostrados nas figuras 46 e 47, e seus derivados. Também compõem a matriz de dados de entrada os parâmetros obtidos por instrumentação específica para aquisição de dados de temperatura e pressão, além dos parâmetros derivados destes. A Tabela 23 contém os valores dos 20 (vinte) parâmetros operacionais obtidos que compõem a matriz de dados de entrada da RNA e que será utilizada para a simulação da condição de operação MD3 do motor em teste. Os resultados da simulação na RNA são mostrados na Tabela 24 e na Figura 48 em forma de gráfico de barras.

Tabela 6.2 – Valores dos parâmetros operacionais, medidos ou derivados de outros, para a condição de operação MD3.

Tdesc	549,000	TSagua	83,000	Tpre-aq	113,000
Tadm	40,000	TEagua	65,000	Pamb	1,000
δT_{cil}	509,000	δT_{agua}	18,000	Padm	6,380
Pmax	108,000	PImax	600,000	PEtc	0,990
Pcomp	83,000	PIaber	370,000	PEic	6,410
θP_{max}	11,450	θPI_{aber}	-5,450	δP_{ic}	0,030
TEPcomb	2,183	Δinj	20,450		

Fonte: própria do autor.

Tabela 6.3 – Resultados da simulação da RNA para condição de operação MD3 simulada no motor diesel.

Resultados Esperados	Resultados Simulados	Erros
0	0,3768	-0,3768
0	-0,5311	0,5311
0	0,5283	-0,5283
1	0,9996	0,0004
0	0,5382	-0,5382
0	-0,1585	0,1585
0	-0,1299	0,1299
0	-0,0683	0,0683
0	0,0359	-0,0359
0	-0,4241	0,4241
0	0,5223	-0,5223
0	-0,2328	0,2328
0	-0,0794	0,0794

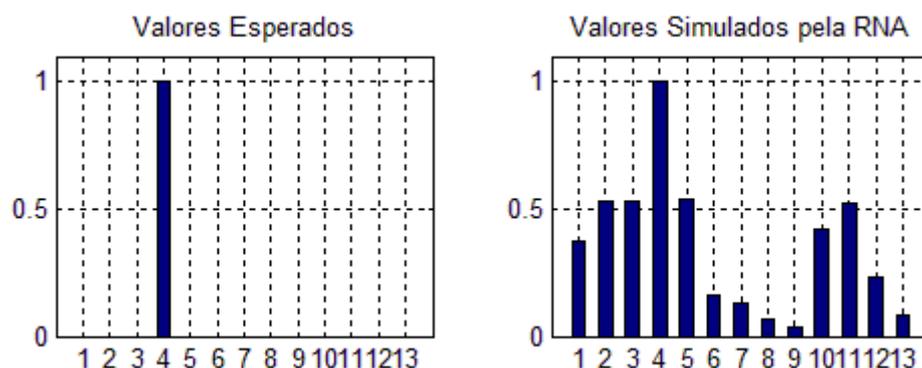


Figura 6.3 – Resultados da RNA para condição de operação MD3 simulada no motor diesel.

Antes da análise, é necessário ressaltar que os valores negativos que aparecem na Tabela 24 são devidos ao domínio das funções de transferência da RNA que é igual a $[-1,1]$. Numa condição ideal, cada gráfico de valores esperados reproduz um diagnóstico ideal, com uma coordenada da abscissa de valor igual a 1 (sucesso) e as outras doze coordenadas de valor igual a 0 (insucesso). Assim sendo, a coordenada que possui o valor igual a 1 (sucesso) é a definidora do diagnóstico, por exemplo, valor 1 para a coordenada 1 indica a condição de operação MD0, valor 1 para a coordenada 2 indica a condição de operação MD1, etc.

A condição de operação MD3 apresenta a coordenada 4 com valor igual a 1 (sucesso) enquanto que as outras coordenadas possuem valor igual a 0 (insucesso) no seu gráfico correspondente de valores esperados mostrado na Figura 48. A partir da matriz com os dados de entrada (Tab. 23) alimentados, a RNA inferiu que o modo de operação do motor é o MD3, conforme mostra o gráfico com os valores simulados pela rede na Figura 48, com o valor da coordenada 4 sendo igual a 0,9996, um erro mínimo de 0,0004 em relação ao valor esperado. Por outro lado, a simulação apresenta alguns valores discrepantes (erro acima de 0,5). Atribui-se a razão para estas ocorrências à falta de uma matriz com dados de entrada fisicamente mais realistas no processo de treinamento da rede. Isto significa que as amostras de dados utilizados para o treinamento da rede não estavam completamente correlacionadas umas com as outras (ruído branco), o que ocasiona o surgimento de erros quando se utiliza dados reais, como foi o caso da simulação executada.

Sabe-se que um modelo de classificação perfeito deve possuir valores próximos

aos valores esperados. No entanto, mesmo com erros de valores significativos, estes estão muito defasados em relação ao valor que define a classe de condição de operação (igual a 1). Portanto, há uma grande facilidade de se distinguir a condição de operação MD3 e, portanto, realizar diagnóstico, quando comparada com os resultados esperados mostrados na Figura 48.

6.2. Estudo de Caso: Condição de Operação MD5

A condição de operação MD5 diz respeito a um possível atraso demasiado na regulagem do início da injeção de combustível. Esta condição foi reproduzida com a diminuição do débito de combustível na bomba injetora na linha que fornece combustível para o cilindro 1. A Figura 49 mostra o resultado do teste realizado no cilindro 1 do motor para combustão.

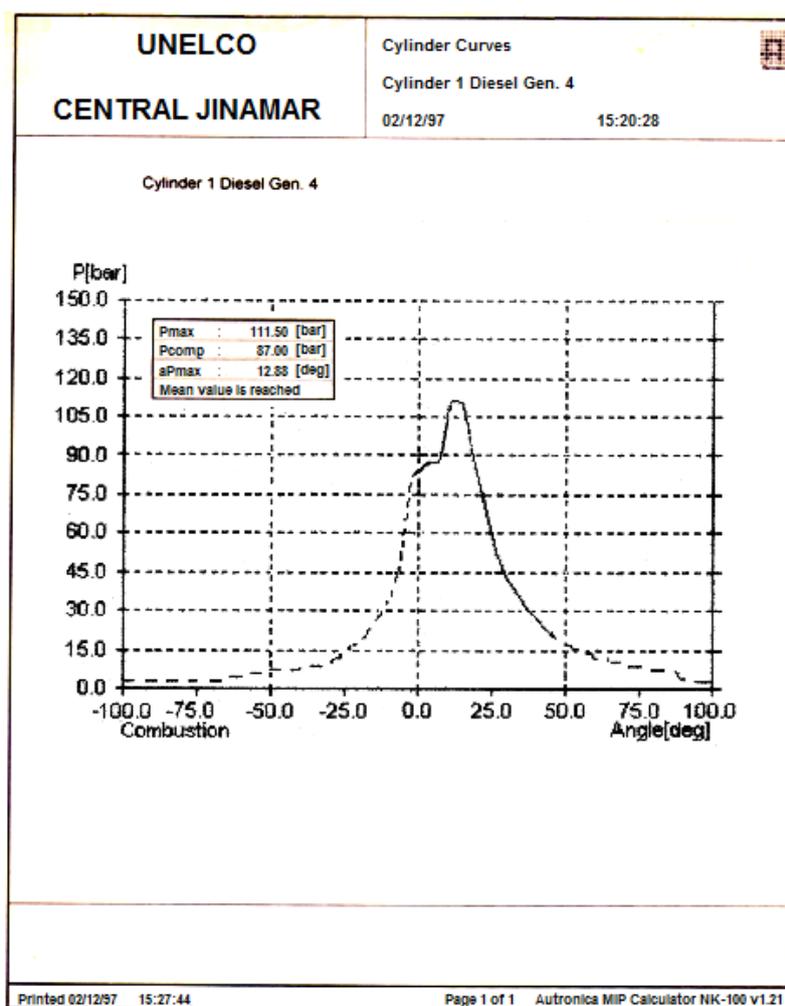


Figura 6.4 – Diagrama indicado de combustão $p \times \theta$ do cilindro 1 do motor testado para condição de operação MD5. Fonte: MIP Calculator NK-100.

A Figura 50 mostra o resultado do teste realizado no cilindro 1 do motor para o sistema de injeção de combustível.

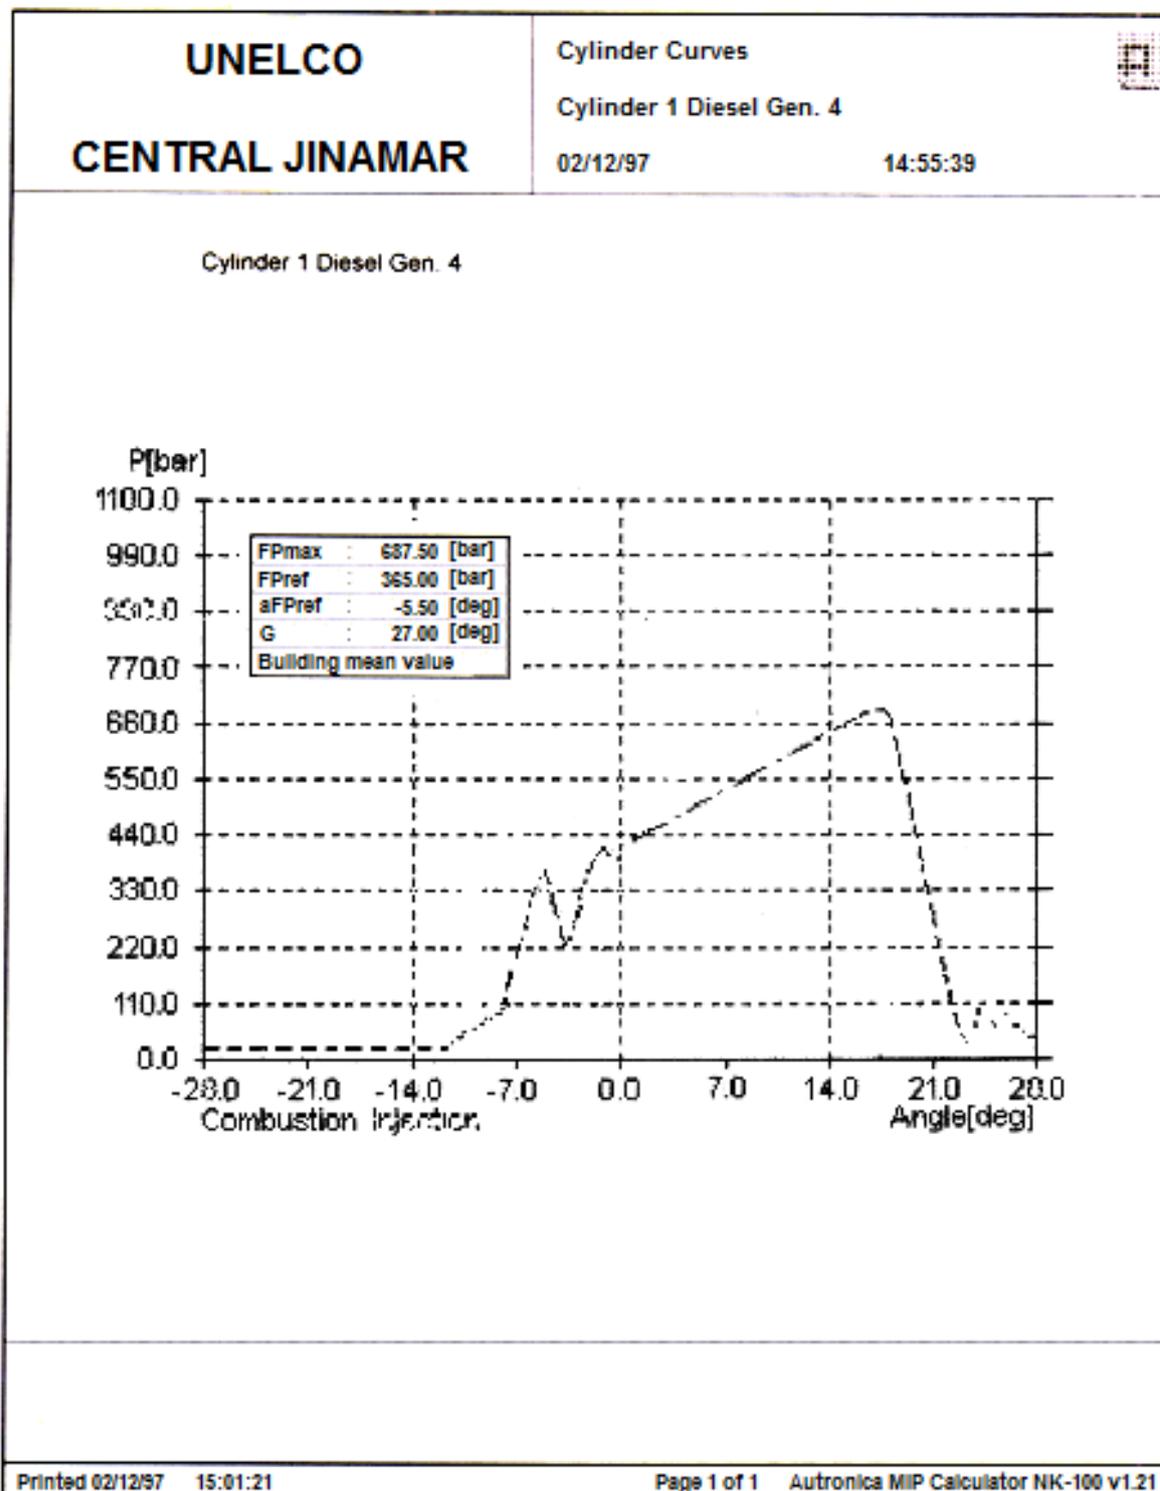


Figura 6.5 – Diagrama indicado de injeção $PI \times \theta$ do cilindro 1 do motor testado para condição de operação MD5. Fonte: MIP Calculator NK-100.

A matriz de dados de entrada que alimentará a RNA para a realização da simulação é composta pelos parâmetros obtidos pelo sistema de aquisição de dados montado no motor, mostrados nas figuras 49 e 50, e seus derivados. Também compõem a matriz de dados de entrada os parâmetros obtidos por instrumentação específica para aquisição de dados de temperatura e pressão, além dos parâmetros derivados destes. A Tabela 25 contém os valores dos 20 (vinte) parâmetros operacionais obtidos que compõem a matriz de dados de entrada da RNA e que será utilizada para a simulação da condição de operação MD5 do motor em teste. Os resultados da simulação na RNA são mostrados na Tabela 26 e na Figura 51 em forma de gráfico de barras.

Tabela 6.4 – Valores dos parâmetros operacionais, medidos ou derivados de outros, para a condição de operação MD5.

Tdesc	550,000	TSagua	92,000	Tpre-aq	115,000
Tadm	40,000	TEagua	61,000	Pamb	1,000
δT_{cil}	510,000	δT_{agua}	31,000	Padm	6,500
Pmax	111,500	PImax	687,500	PEtc	0,990
Pcomp	87,000	PIaber	365,000	PEic	6,520
θP_{max}	12,880	θP_{Iaber}	-5,500	δP_{ic}	0,020
TEPcomb	1,902	Δinj	27,000		

Tabela 6.5 – Resultados da simulação da RNA para condição de operação MD5 simulada no motor diesel.

Resultados Esperados	Resultados Simulados	Erros
0	-0,0002	0,0002
0	-0,7374	0,7374
0	0,9006	-0,9006
0	-0,3341	0,3341
0	-0,2420	0,2420
1	2,2593	-1,2593
0	-0,2748	0,2748
0	0,2727	-0,2727
0	0,8379	-0,8379
0	-0,4523	0,4523
0	-0,3891	0,3891
0	-1,6319	1,6319
0	0,3688	-0,3688

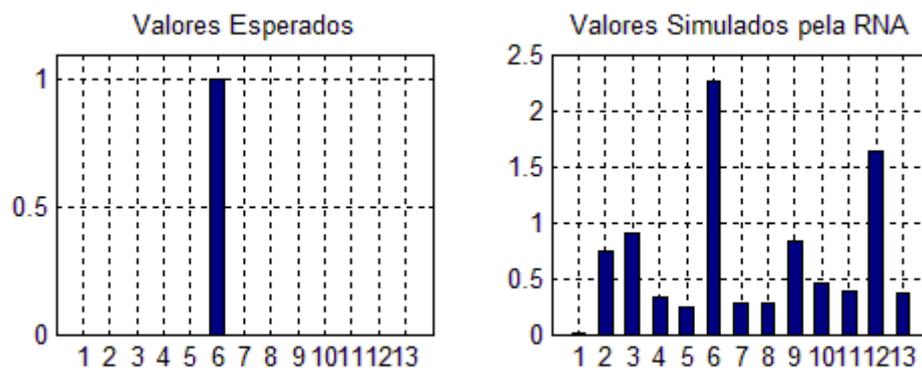


Figura 6.6 – Resultados da RNA para condição de operação MD3 simulada no motor diesel.

A condição de operação MD5 apresenta a coordenada 6 com valor igual a 1 (sucesso) enquanto que as outras coordenadas possuem valor igual a 0 (insucesso) no seu gráfico correspondente de valores esperados mostrado na Figura 51. A partir da matriz com os dados de entrada (Tab. 25) alimentados, a RNA inferiu que o modo de operação do motor é o MD5, conforme mostra o gráfico com os valores simulados pela rede na Figura 51, com o valor da coordenada 6 sendo igual a 2,2593, um erro bastante expressivo de 1,2593 em relação ao valor esperado. Há outros valores discrepantes como no caso das coordenadas 12, 3, 9 e 2, com erros de 1,6319, 0,9006, 0,8379 e 0,7374. É, de fato, uma anomalia devida à falta de uma matriz com dados de entrada fisicamente mais realistas no processo de treinamento da rede, porém, ao mesmo tempo, mostra que o desempenho da RNA é bastante satisfatório, pois a mesma consegue extrapolar os outros valores para se adequarem ao que foi alcançado pelo valor da coordenada 6. Isto faz com que o resultado seja bastante equivalente aos valores esperados, satisfazendo ao algoritmo de falhas proposto para a condição de operação MD5. Portanto, há uma grande facilidade de se distinguir a condição de operação MD5 quando comparada com os resultados esperados, conforme mostra a Figura 51.

6.3. Estudo de Caso: Condição de Operação MD10

A condição de operação MD10 diz respeito a uma possível falha na regulagem do início da injeção de combustível, fazendo com que este início se atrase muito. Esta condição foi reproduzida com o aumento do débito de combustível na bomba injetora na

linha que fornece combustível para o cilindro 1. A Figura 52 mostra o resultado do teste realizado no cilindro 1 do motor para combustão.

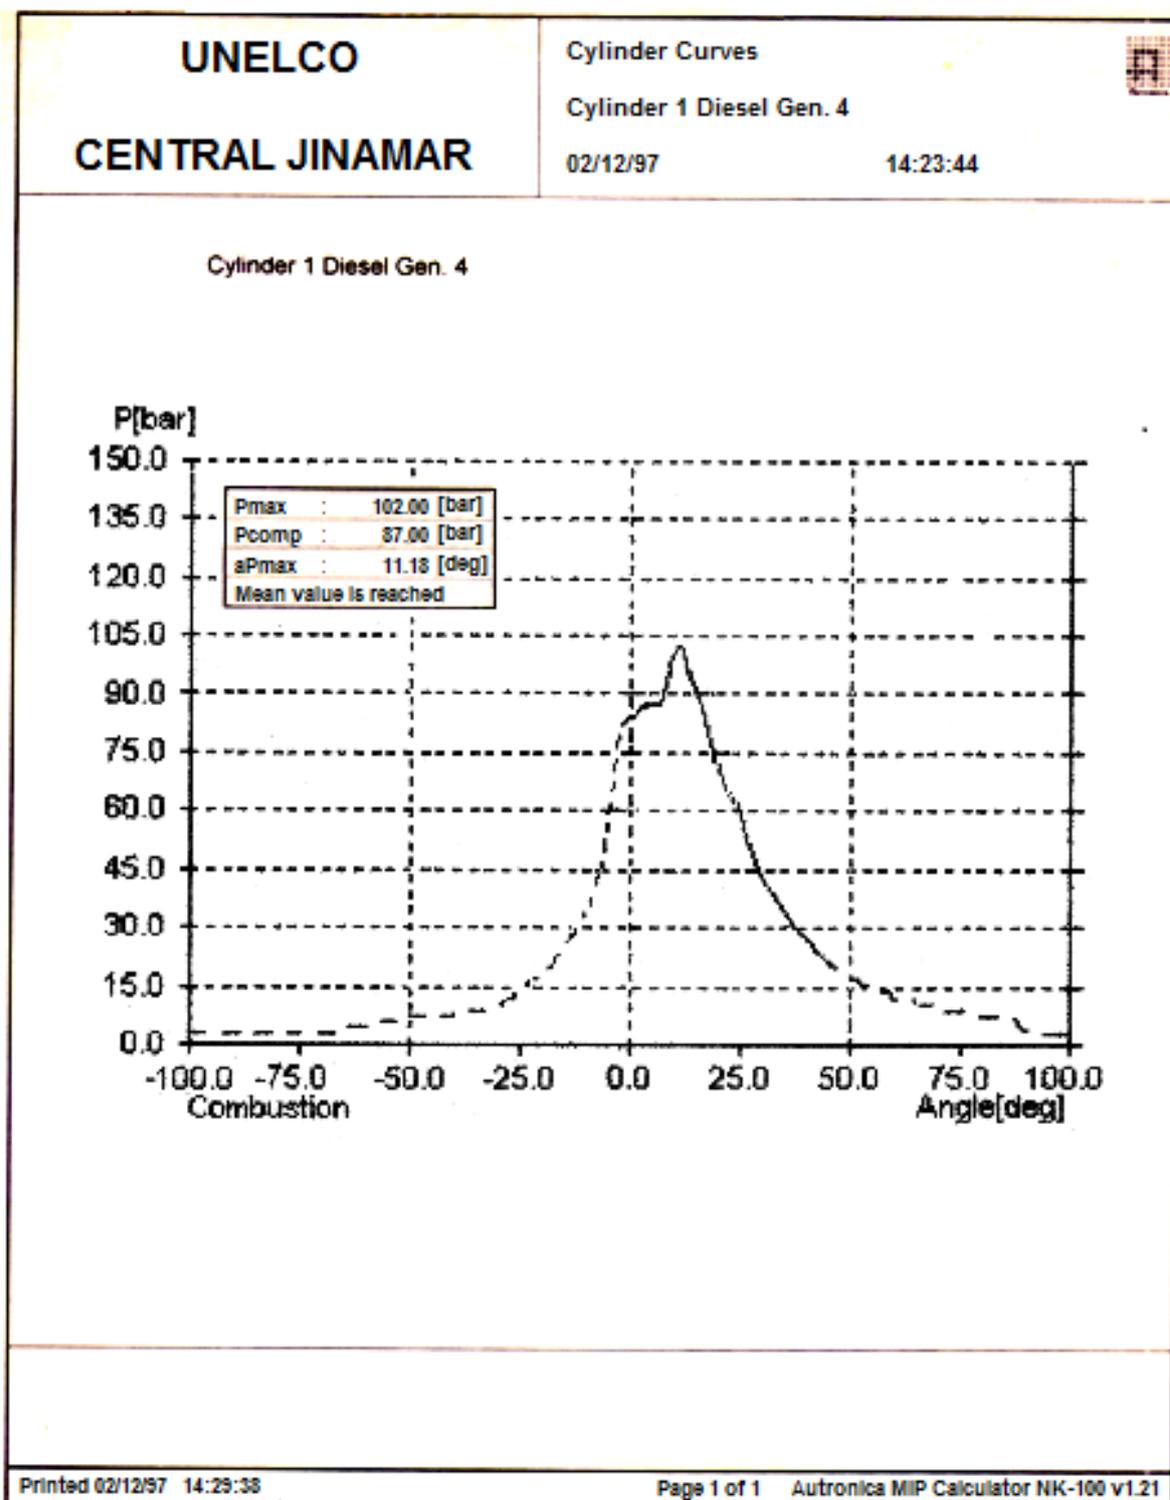


Figura 6.7 – Diagrama indicado de combustão $p \times \theta$ do cilindro 1 do motor testado para condição de operação MD10. Fonte: MIP Calculator NK-100.

A Figura 53 mostra o resultado do teste realizado no cilindro 1 do motor para o sistema de injeção de combustível.

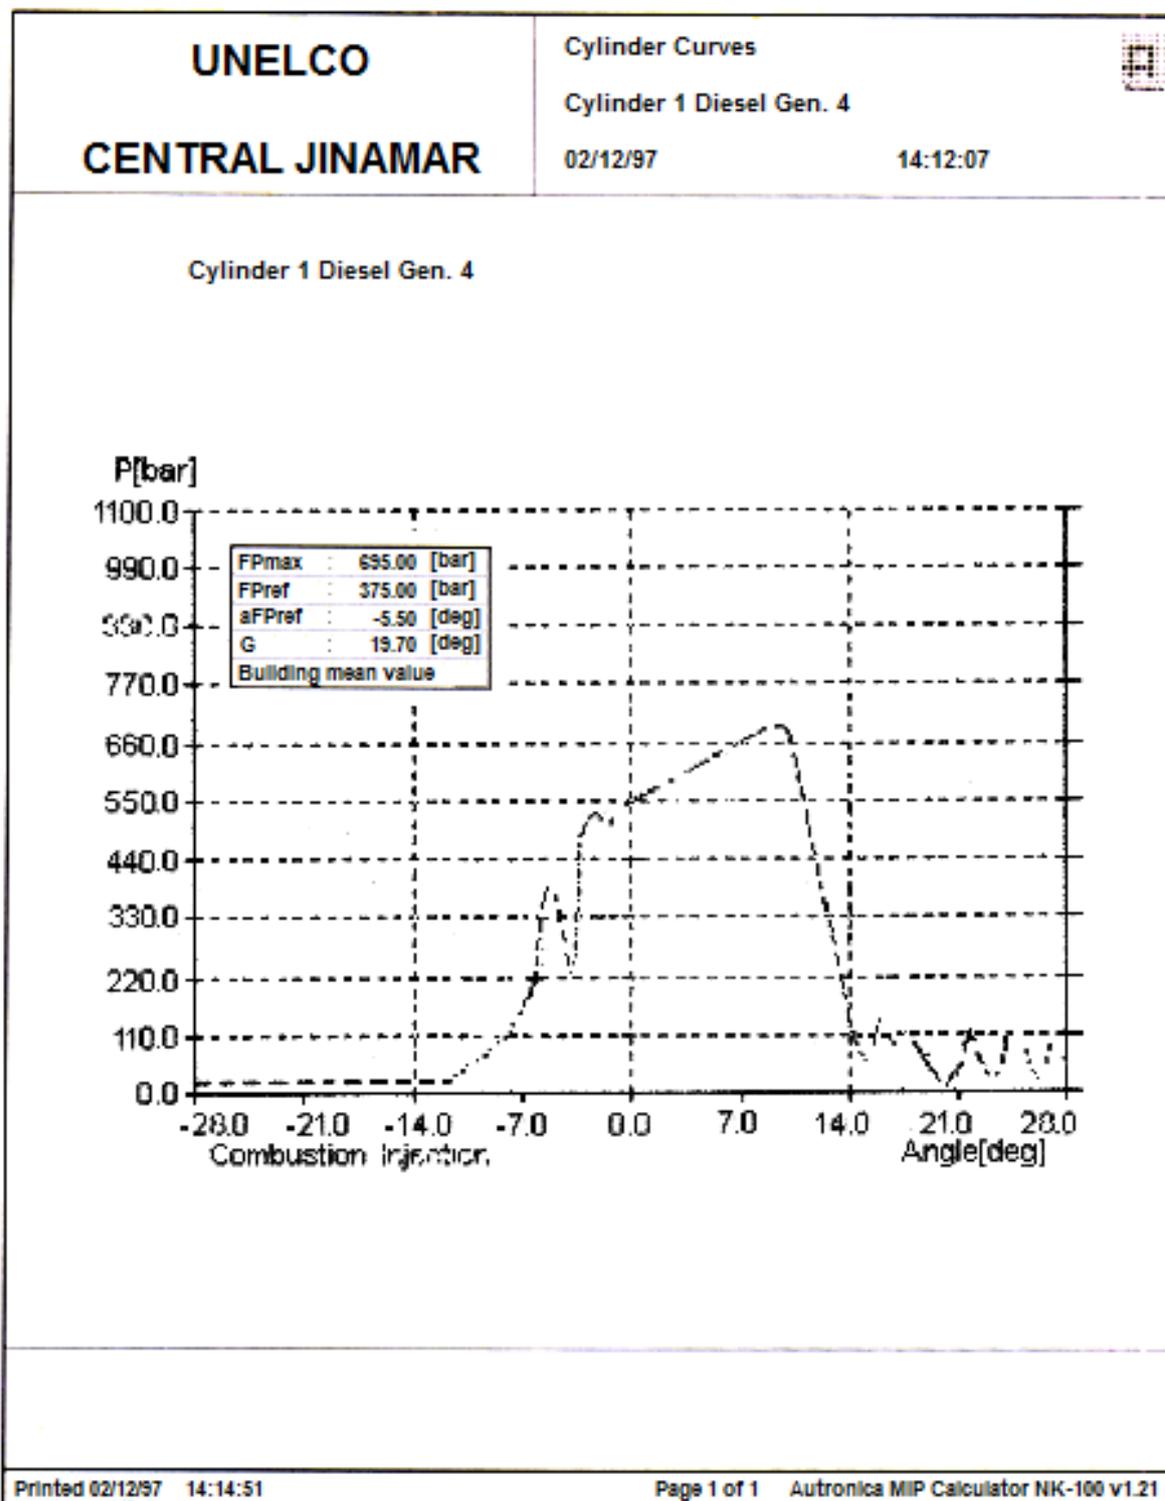


Figura 6.8 – Diagrama indicado de injeção $PI \times \theta$ do cilindro 1 do motor testado para condição de operação MD10. Fonte: MIP Calculator NK-100.

A matriz de dados de entrada que alimentará a RNA para a realização da simulação é composta pelos parâmetros obtidos pelo sistema de aquisição de dados montado no motor, mostrados nas figuras 52 e 53, e seus derivados. Também compõem a matriz de dados de entrada os parâmetros obtidos por instrumentação específica para aquisição de dados de temperatura e pressão, além dos parâmetros derivados destes. A Tabela 27 contém os valores dos 20 (vinte) parâmetros operacionais obtidos que compõem a matriz de dados de entrada da RNA e que será utilizada para a simulação da condição de operação MD10 do motor em teste. Os resultados da simulação na RNA são mostrados na Tabela 28 e na Figura 54 em forma de gráfico de barras.

Tabela 6.6 – Valores dos parâmetros operacionais, medidos ou derivados de outros, para a condição de operação MD10.

Tdesc	605,000	TSagua	85,000	Tpre-aq	115,000
Tadm	46,000	TEagua	78,000	Pamb	1,000
δT_{cil}	559,000	δT_{agua}	7,000	Padm	6,500
Pmax	102,000	PImax	695,000	PEtc	0,990
Pcomp	87,000	PIaber	375,000	PEic	6,520
θP_{max}	11,180	θP_{Iaber}	-5,500	δP_{ic}	0,020
TEPcomb	1,342	Δ_{inj}	19,700		

Tabela 6.7 – Resultados da simulação da RNA para condição de operação MD10 simulada no motor diesel.

Resultados Esperados	Resultados Simulados	Erros
0	0,1422	-0,1422
0	-0,0178	0,0178
0	0,1383	-0,1383
0	0,1026	-0,1026
0	-0,2256	0,2256
0	0,3257	-0,3257
0	-0,2448	0,2448
0	0,0014	-0,0014
0	0,0414	-0,0414
0	0,1981	-0,1981
1	0,6963	0,3037
0	0,0823	-0,0823
0	-0,1979	0,1979

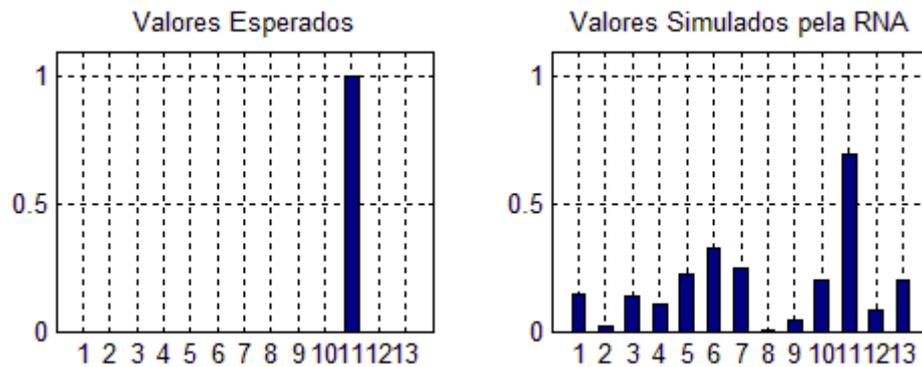


Figura 6.9 – Resultados da RNA para condição de operação MD10 simulada no motor diesel.

A condição de operação MD10 apresenta a coordenada 11 com valor igual a 1 (sucesso) enquanto que as outras coordenadas possuem valor igual a 0 (insucesso) no seu gráfico correspondente de valores esperados mostrado na Figura 54. A partir da matriz com os dados de entrada (Tab. 27) alimentados, a RNA inferiu que o modo de operação do motor é o MD10, conforme mostra o gráfico com os valores simulados pela rede na Figura 54, com o valor da coordenada 11 sendo igual a 0,6963, um erro de 0,3037 em relação ao valor esperado. O valor mais discrepante, igual a 0,3237, situa-se na coordenada 6 e isto faz-nos considerar uma condição de normalidade nos dados simulados.

Assim sendo, com o resultado bastante equivalente ao dos valores esperados, podemos afirmar que o algoritmo de falhas proposto satisfaz a condição de operação MD10. E por isso há uma grande facilidade de se distinguir a condição de operação MD10 quando comparada com os resultados esperados, conforme mostra a Figura 54.

6.4. Estudo de Caso: Condição de Operação MD12

A condição de operação MD12 diz respeito a uma possível perda de compressão na câmara de combustão do cilindro causada por desgaste na camisa do cilindro ou anéis de segmentos gastos. Esta condição foi reproduzida com a utilização de anéis de segmento já com adiantado estado de desgaste no pistão do cilindro 3. A Figura 55 mostra o resultado do teste realizado no cilindro 1 do motor para combustão.

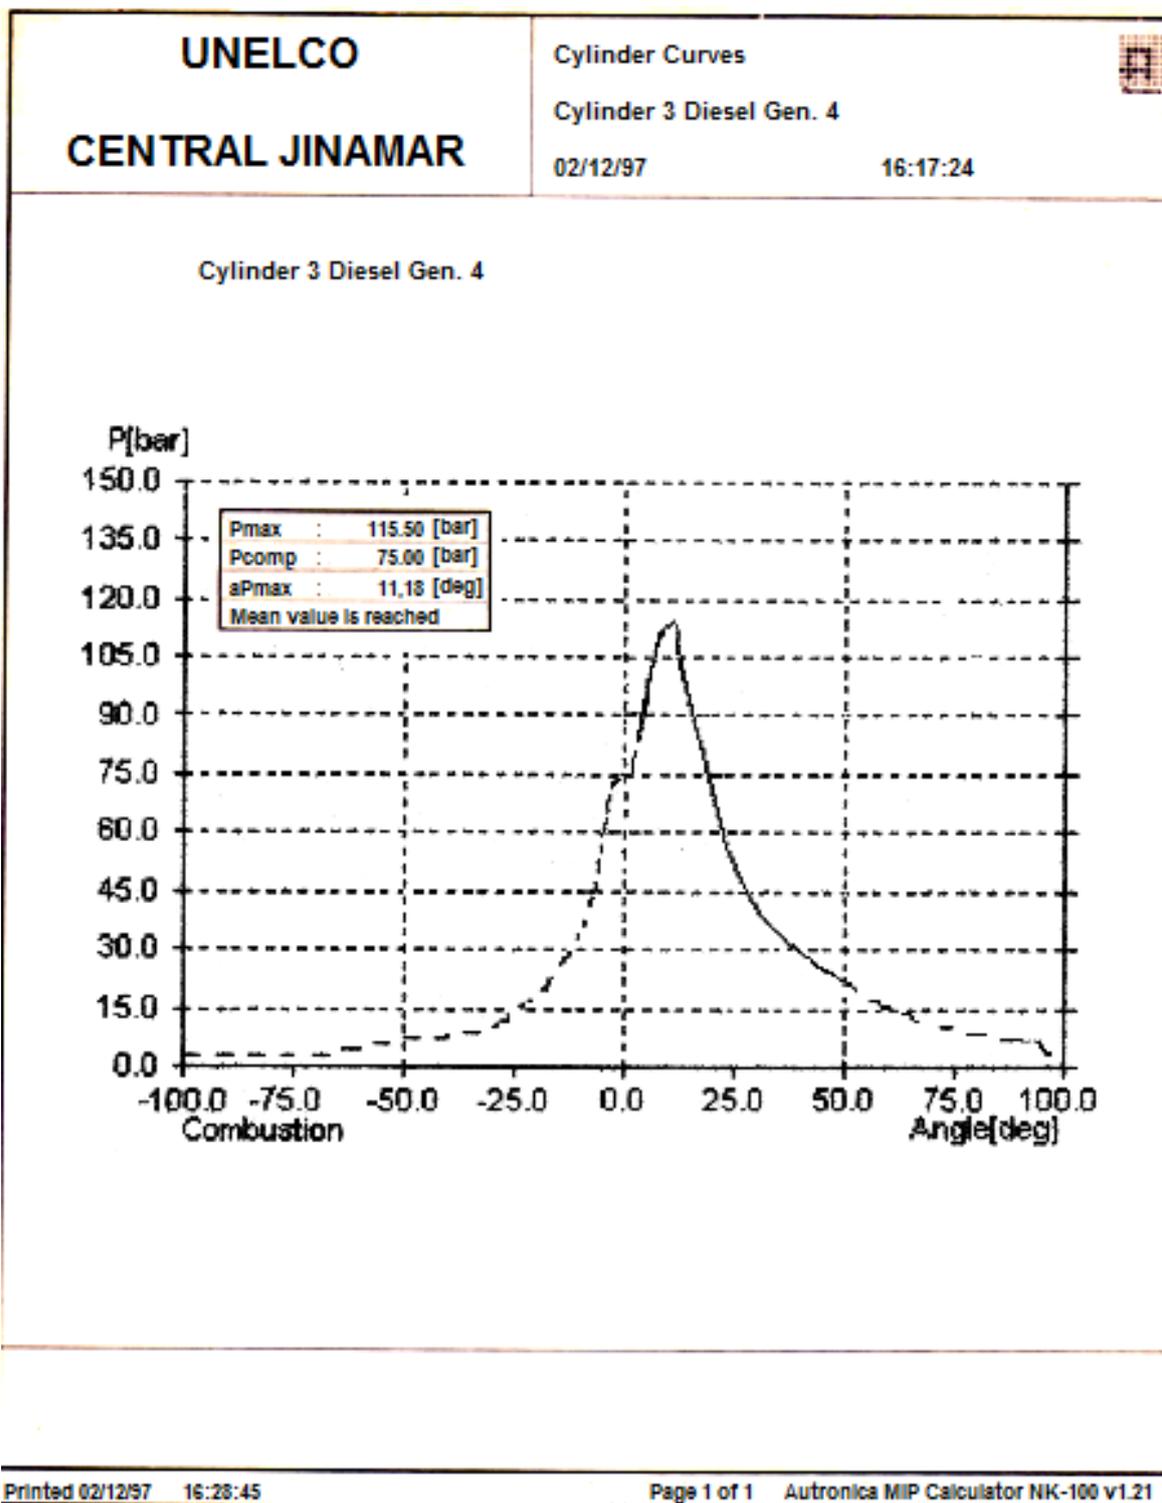


Figura 6.10 – Diagrama indicado de combustão $p \times \theta$ do cilindro 3 do motor testado para condição de operação MD12. Fonte: MIP Calculator NK-100.

A Figura 56 mostra o resultado do teste realizado no cilindro 3 do motor para o sistema de injeção de combustível.

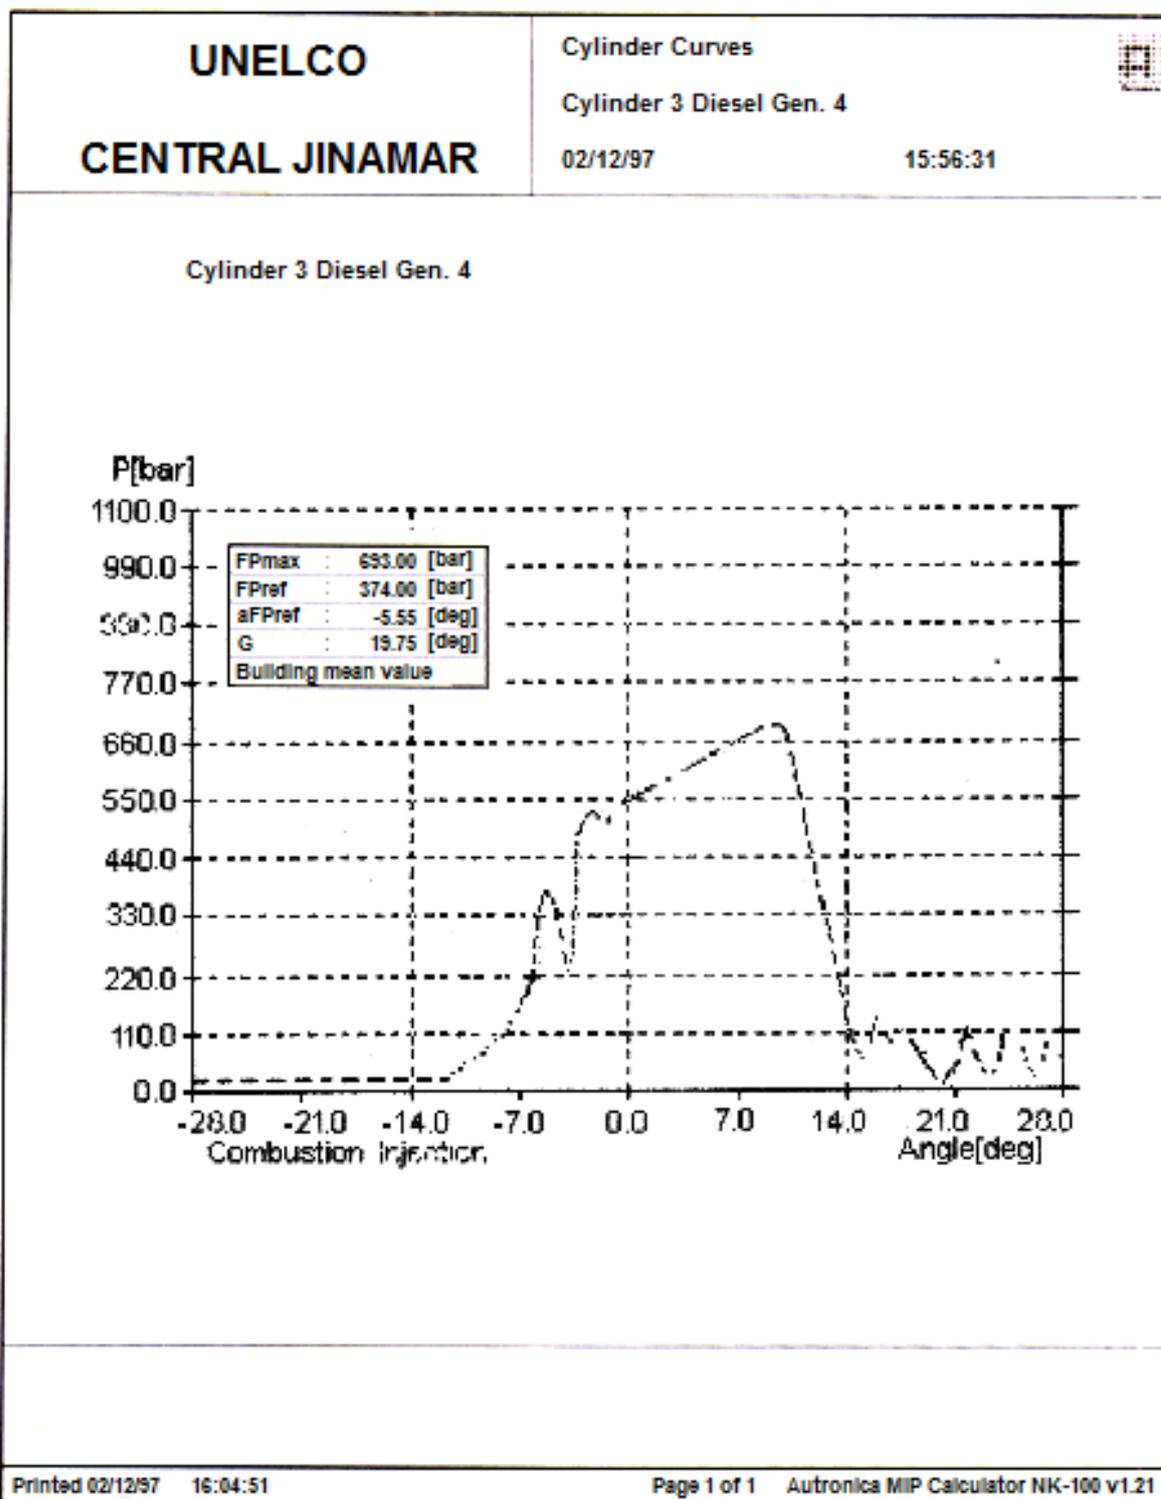


Figura 6.11 – Diagrama indicado de injeção $PI \times \theta$ do cilindro 3 do motor testado para condição de operação MD12. Fonte: MIP Calculator NK-100.

A matriz de dados de entrada que alimentará a RNA para a realização da

simulação é composta pelos parâmetros obtidos pelo sistema de aquisição de dados montado no motor, mostrados nas figuras 55 e 56, e seus derivados. Também compõem a matriz de dados de entrada os parâmetros obtidos por instrumentação específica para aquisição de dados de temperatura e pressão, além dos parâmetros derivados destes. A Tabela 29 contém os valores dos 20 (vinte) parâmetros operacionais obtidos que compõem a matriz de dados de entrada da RNA e que será utilizada para a simulação da condição de operação MD12 do motor em teste. Os resultados da simulação na RNA são mostrados na Tabela 30 e na Figura 57 em forma de gráfico de barras.

Tabela 6.8 – Valores dos parâmetros operacionais, medidos ou derivados de outros, para a condição de operação MD12.

Tdesc	590,000	TSagua	83,000	Tpre-aq	115,000
Tadm	43,000	TEagua	63,000	Pamb	1,000
δT_{cil}	547,000	δT_{agua}	20,000	Padm	6,530
Pmax	115,500	PImax	693,000	PEtc	0,990
Pcomp	75,000	PIaber	374,000	PEic	6,570
θP_{max}	11,180	θPI_{aber}	-5,550	δP_{ic}	0,040
TEPcomb	3,623	Δinj	19,750		

Tabela 6.9 – Resultados da simulação da RNA para condição de operação MD12 simulada no motor diesel.

Resultados Esperados	Resultados Simulados	Erros
0	0,2760	-0,2760
0	0,1553	-0,1553
0	-0,0276	0,0276
0	-0,3531	0,3531
0	-0,5464	0,5464
0	-0,3295	0,3295
0	-0,2191	-0,2191
0	0,3878	-0,3878
0	0,4515	-0,4515
0	-0,0752	0,0752
0	-0,2739	0,2739
0	-0,2510	0,2510
1	1,4026	-0,4026

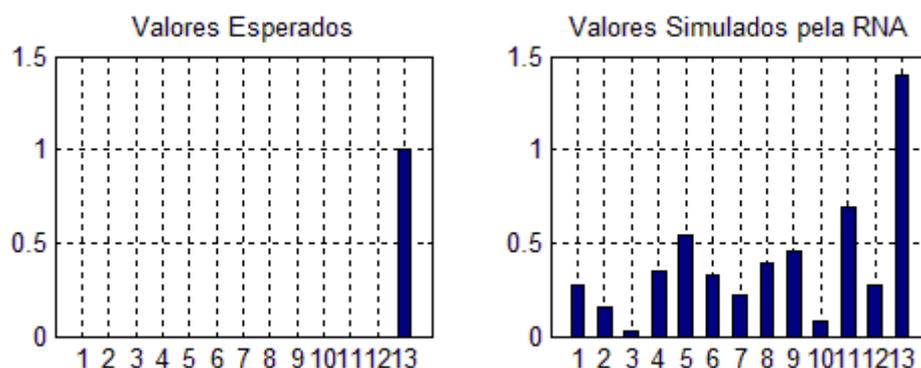


Figura 6.12 – Resultados da RNA para condição de operação MD12 simulada no motor diesel. Fonte: Anônimo (2010).

A condição de operação MD12 apresenta a coordenada 13 com valor igual a 1 (sucesso) enquanto que as outras coordenadas possuem valor igual a 0 (insucesso) no seu gráfico correspondente de valores esperados mostrado na Figura 57. A partir da matriz com os dados de entrada (Tab. 29) alimentados, a RNA inferiu que o modo de operação do motor é o MD12, conforme mostra o gráfico com os valores simulados pela rede na Figura 57, com o valor da coordenada 13 sendo igual a 1,4026 com, um erro de 0,4026 em relação ao valor esperado. Por outro lado, a simulação apresenta alguns valores discrepantes (erro acima de 0,5), proporcionais ao erro da coordenada definidora da condição de operação, atribuídos à falta de uma matriz com dados de entrada fisicamente mais realistas no processo de treinamento da rede posto que as amostras de dados utilizados para o treinamento da rede não estavam completamente correlacionadas umas com as outras (ruído branco).

Sabe-se que um modelo de classificação perfeito deve possuir valores próximos aos valores esperados. Contudo, os erros de alguns valores estes estão muito defasados em relação ao valor que define a classe de condição de operação (igual a 1). Portanto, há uma grande facilidade de se distinguir a condição de operação MD12 e, portanto, realizar diagnóstico, quando comparada com os resultados esperados mostrados na Figura 57, satisfazendo ao algoritmo de falhas proposto para a condição de operação MD12.

7. CONCLUSÕES E RECOMENDAÇÕES

Este trabalho focou no projeto, configuração e validação de um sistema capaz de diagnosticar a condição de operação de um motor diesel de qualquer tamanho usando uma abordagem de RNA. O objetivo geral da pesquisa foi alcançado através da satisfação de todos os objetivos específicos identificados no Capítulo Um. Além disso, a pesquisa constitui um trabalho original que também satisfaz as recomendações dadas em pesquisas anteriores. O trabalho realizado nesta pesquisa pode ser resumido da seguinte forma:

- Desenvolvimento de um modelo de simulação da condição de operação de um motor diesel utilizando a técnica da Análise da Árvore de Falhas (AAF). O modelo faz uso de correlações bem definidas de eventos baseados em propriedades puramente termodinâmicas do ciclo de operação do motor e que são facilmente mensuráveis.
- Construção de um conjunto de regras que sirva de base para o desenvolvimento de um algoritmo de diagnóstico a partir da árvore de falhas desenvolvida. As regras de diagnóstico têm por premissas o evento topo (indesejável) que dispara todo o processo de investigação de uma possível condição de operação em modo de falha, além de eventos intermediários definidos, também, por parâmetros operacionais que refletem propriedades termodinâmicas do ciclo de operação do motor diesel. A conclusão das regras são os defeitos localizados no motor.
- Treinamento, validação e teste de uma Rede Neural Artificial (RNA) que possibilite a realização de inferências sobre o algoritmo de diagnóstico desenvolvido. As amostras de dados da matriz de entrada da RNA foram definidas com base nos alarmes indicados pelo fabricante do motor para cada parâmetro operacional, levando em conta as normas das principais sociedades classificadoras do mundo.
- A RNA foi utilizada para fazer inferências sobre dados coletados em um programa de ensaios experimentais que abrange 4 (quatro) casos de falhas sintéticas introduzidas artificialmente no motor diesel para estabelecer seu efeito individual sobre os desempenhos dos vários parâmetros operacionais. O motor foi integrado com um sistema de aquisição de dados de combustão e injeção de combustível e sensores adicionais para ser usado como uma instalação de teste para medições

experimentais requeridas para o desenvolvimento dos parâmetros chaves para a avaliação da condição de operação do motor.

Podemos extrair as seguintes conclusões do presente trabalho:

- É inteiramente factível a construção de uma base de conhecimento apresentando as interações entre eventos de falha revelados por parâmetros operacionais que refletem eventos termodinâmicos básicos e realize o diagnóstico de falhas em motores diesel. Esta factibilidade só é possível com a utilização da técnica da análise da árvore de falhas (AAF) que permite que sejam observadas todas as interações entre os eventos de falhas e destes com os defeitos localizados no motor ou um de seus componentes.
- A inferência realizada pela RNA desenvolvida nesta tese mostrou-se bastante satisfatória com a utilização de dados reais obtidos nos testes de simulação de falhas no motor. Apesar dos erros de precisão ocorridos entre os dados esperados e os dados simulados pela rede, os diagnósticos oriundos da simulação da RNA não deixaram dúvidas sobre o tipo de falha que foi simulado nos testes experimentais. É preciso lembrar que a RNA desenvolvida é para o reconhecimento de padrões de condição de operação de motores diesel, portanto, leva-se em conta a configuração ou forma de cada diagnóstico inferido e, neste caso, a proporcionalidade entre a configuração ou forma dos resultados esperados e dos resultados simulados não deixou margem de dúvidas sobre qual diagnóstico se tratava, conforme se pode observar pelas figuras 48, 51, 54 e 57.

Considerando todas as observações e constatações realizadas ao longo deste estudo e buscando e aumentar a precisão dos diagnósticos da condição de operação do motor, sugere-se como proposta para novos trabalhos:

- Expandir a técnica apresentada, combinando-a com outras ferramentas de inferência como os sistemas especialistas e/ou lógica fuzzy para produzir um esquema de monitoração da saúde do motor mais abrangente, uma vez que as RNA's também têm a capacidade de fundir dados de outras técnicas de monitoração de performance associadas, como vibração e análise de óleo.
- Implementar um modelo matemático do ciclo de operação dos motores diesel em uma linguagem computacional a fim de que possa gerar amostras de dados mais precisas das diversas condições de operação do motor e utilizá-las como dados de entrada para a RNA e, com isto, tentar diminuir o erro de precisão entre os valores

esperados e os valores simulados. Isto envolve a simulação de defeitos em todas as faixas de operação para criar um banco de dados de falhas e, com isso, realizar uma avaliação quantitativa no algoritmo de diagnóstico de falhas.

REFERÊNCIAS

ADAMS, O.L., 1949, *Elements of Diesel Engineering*, 2nded., USA, The Norman W. Henley Publishing Co.

ALHO, A. L. P., BELCHIOR, C. R. P., 1998, Relatório de Avaliação do Estado de Funcionamento do Motor MEP-MAN do Laboratório de Máquinas do CIAGA. DEN-CT-UFRJ, Rio de Janeiro, 1998. Trabalho não publicado.

ANÔNIMO, 1994, *Operator's Handbook – PROF DIESEL PD 100*. Oslo, Norway, Autronica AS.

ASSANIS, D. N., HEYWOOD, J. B., 1986, “Development and Use of a Computer Simulation of the Turbocompounded Diesel System for Engine Performance and Component Heat Transfer Studies”, *SAE*, paper 860329, pp. 95-120.

BAKER, D. M., ASSANIS, D. N., 1994, “A Methodology for Coupled Thermodynamic and Heat Transfer Analysis of a Diesel Engine”, *Appl. Math. Modeling*, v. 18, pp. 590-601.

BELIZÁRIO, A. C., SOUZA, G. F. M., 2013, “Fault Tree Analysis For Non Stoichiometric Combustion of Diesel Gas Engine”. Proceedings of the 22nd Brazilian Congress of Mechanical Engineering, COBEM 2013, v.1, pp. 8044-8054, Ribeirão Preto, SP, Brazil, November 3-7.

BOLAN LIU *et al.*, 2013, “Misfire Detection of a Turbocharged Diesel Engine by Using Artificial Neural Networks”, *Applied Thermal Engineering*, v. 55, pp. 26-32.

BRACCO, F. V. *et al.*, 1976, “Two-Phase Two-Dimensional Unsteady Combustion in Internal Combustion Engines: Preliminary Theoretical-Experimental Results”, *SAE*, Paper 760114.

BRAGA, A. P., CARVALHO, A. C. P. L. F., LUDERMIR, T. B., 2007, *Redes Neurais Artificiais: Teoria e Aplicação*, 2^a ed., Brasil, LTC.

CLARK, G.H., 1988, *Industrial and Marine Fuels Reference Book*, London, Butterworth.

COELHO, R. N. C., 1999, *Análise de um Sistema de Monitoração e Diagnóstico da Combustão de Motores Diesel*. Dissertação de M.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.

CONNOLLY, F. T., YAGLE, A. E. 1994, "Modeling and Identification of the Combustion Pressure Process in Internal Combustion Engines", *Mechanical Systems and Signal Processing*, pp. 1-19.

DEMPSEY, P., 2008, *Troubleshooting and Repairing Diesel Engines*. 4rd ed., USA, The McGraw-Hill Companies.

DEMUTH, H., BEALE, M., 1998, *Neural Network Toolbox – For Use With MATLAB User's Guide*. Version 3.0, Chapter 5. The MathWorks, Inc.

DIWAKAR, R., 1981, "Multidimensional Modeling Applied to the Direct-Injection Stratified-Charge Engine, Calculation Versus Experiment", *SAE*, paper 810225.

DREYFUS, G., 2005, *Neural Networks Methodology and Applications*. Germany, Springer.

FAGERLAND, H., ROTH AUG, K., TOKLE, P., 1978, "Monitoring and Diagnosing Process Deviations in Marine Diesel Engines", *Ship Research Institute of Norway*, pp. 321-340.

FREDRIKSEN, P.S., 1976, "Advanced Condition Monitoring System Based on Microprocessor Components", *Ship Operation Automation*.

GANESAN, V., 1999, *Internal Combustion Engines*, 2nd ed., New Delhi, India, Tata McGraw-Hill.

GERTLER, J. J., 1998, *Fault Detection and Diagnosis in Engineering Systems*, New York, USA, Marcel Dekker, Inc.

GOSMAN, A. D., 1985, "Multidimensional Modeling of Cold Flows and Turbulence in Reciprocating Engines", *SAE*, paper 850344, pp. 137-153.

HAYKIN, S., 1994, *Neural Networks – A comprehensive foundation*, New York, USA, Simon, Macmillan College Publishing Company.

HEYWOOD, J.B., 1988, *Internal Combustion Engine Fundamentals*, Singapore, McGraw-Hill Book Co.

HOLTROP, J., MENNER, G. J., 1978, “A statistical Power Prediction Method”, *International Shipbuilding Progress*, v.25, paper 290.

HOUNTALAS, D. T., 2000, “Prediction of Marine Diesel Engine Performance under Fault Conditions”, *Applied Thermal Engineering*, v. 20, pp. 1753-1783.

HOUNTALAS, D. T., ANESTIS, A., 1998, “Effect of Pressure Transducer Position on Measured Cylinder Pressure Diagram of High Speed Diesel Engines”, *Energy Convers. Mgmt.*, v. 39, n. 7, pp. 589-607.

HOUNTALAS, D. T., KOUREMENOS, A. D., 1999, “Development and Application of a Fully Automatic Troubleshooting Method for a Large Marine Diesel Engines”, *Applied Thermal Engineering*, v. 19, pp. 299-324.

ISERMANN, R., 2011, *Model-Based Condition Monitoring: Actuators, Drives, Machinery, Plants, Sensors, and Fault-Tolerant Systems*. Berlin, Springer.

JIAN-DA WU, CHENG-KAI HUANG, YO-WEI CHANG *et al.*, 2010, “Fault diagnosis for internal combustion engines using intake manifold pressure and artificial neural network”, *Expert Systems with Applications*, v. 37, pp. 949-958.

KOUREMENOS, D. A., HOUNTALAS, D. T., 1997, “Diagnosis and Condition Monitoring of Medium-Speed Marine Diesel Engines”, *Tribo Test*, v. 4, n. 1.

LAKSHMINARAYANAN, P. A., AGHAV, Y. V., 2009, *Modelling Diesel Combustion*. New York, Springer.

LANGBALLE, M., TONNING, L., WIBROG, T., 1975, “Condition Monitoring of Diesel Engines”, *Norwegian Maritime Research*, v. 3, pp. 2-16.

LAPUERTA, M., ARMAS, O., HERNÁNDEZ, J. J., 1999, “Diagnosis of DI Diesel Combustion from In-Cylinder Pressure Signal by Estimation of Mean Thermodynamic Properties of the Gas”, *Applied Thermal Engineering*, v. 19, pp. 513-529.

LASKOWSKI, R., 2015, “Fault Tree Analysis as a Tool for Modelling the Marine Main Engine Reliability Structure”, *Scientific Journals of the Maritime University of Szczecin*, v. 41, n. 113, pp. 71-77.

LAWRENCE, N., KORTEKAAS, H. Y. P., 2001, “DECSIM – A PC-Based Diesel Engine Cycle and Cooling System Simulation Program”, *Mathematical and Computer Modeling*, v. 33, pp. 565-575.

LEWIS, E. E., 1996, *Introduction to Reliability Engineering*. 2nded., New York, USA, John Wiley & Sons, Inc.

LIMNIOS, N., 2007, *Fault Trees*. Great Britain and United States, ISTE Ltd.

MARTINS, J., 2006, *Motores de Combustão Interna*. 2^a ed., Porto, Publindústria.

NAIK, S., SINGH, A., 2016, “Fault Tree Analysis of Single Cylinder Vertical Diesel Engine”, *International Research Journal of Engineering and Technology (IRJET)*, v. 3, pp. 2278-2283.

NEW SULZER DIESEL, 1990, General Technical Data of ZA40S Marine Propulsion Diesel Engines. Wintertur, Switzerland.

NYAN WIN AUNG, WEI HAIJUN, SUN DI, 2014, “Fuzzy Fault Tree Analysis of the Marine Diesel Engine Jacket Water Cooling System”, *Information Technology Journal*, v. 13, n. 3, pp. 425-433.

OGAWA, H. *et al.*, 1997, “Three-Dimensional Computation of In-Cylinder Flow and Combustion Characteristics in Diesel Engines – Effect of Wall Impingement Models of Fuel Droplet Behavior on Combustion Characteristics”, *JSAE Review*, v. 18, pp. 95-99.

PATAN, K., 2008, Artificial Neural Network for the Modelling and Fault Diagnosis of Technical Process. Berlin, Springer.

PERAKIS, A., INÖZÜ, B., 1990, “Reliability Analysis of Great Lakes Marine Diesels: State of Art and Current Modeling”, *Marine Technology*, v. 27, n. 4.

PLINT, M., MARTYR, T., 1999, “Condition Monitoring”. In: Challen, B., Baranescu, R. (eds.), Diesel Engine Reference Book, 2nd ed., chapter 27, Oxford, UK, Butterworth-Heinemann.

PORTEIRO, J., COLLAZO, J., PATIÑO, D. *et al.* 2011, “Diesel engine condition monitoring using a multi-net neural network system with nonintrusive sensors”, *Applied Thermal Engineering*, v. 31, pp. 4097-4105.

RAKOPOULOS, C. D., GIAKOUMIS, E. G., 1998, “Simulation and Analysis of a Naturally Aspirated IDI Diesel Engine Under Transient Conditions Comprising the Effect of Various Dynamic and Thermodynamic Parameters”, *Energy Convers. Mgmt.*, v. 39, n. 5/6, pp. 465-484.

REITZ, R. D., RUTLAND, C. J., 1995, “Development and Testing of Diesel Engine CFD Models”, *Prog. Energy Combust. Sci.*, v. 21, pp. 173-196.

ROY, S., BANERJEE, R., BOSE, P. K., 2014, “Performance and Exhaust Emissions Prediction of a CRDI Assisted Single Cylinder Diesel Engine Coupled with EGR Using Artificial Neural Network”, *Applied Energy*, v. 119, pp. 330-340.

SHAMSOLMAALI, A., BANISOLEIMAN, K., 1994, “Real Time Diagnostic Techniques and Condition Monitoring Application”, *Trans. I Mar. E*, v. 103, pp. 357-363.

SOBHANI-TEHRANI, E., KHORASANI, K., 2009, *Fault Diagnosis of Nonlinear Systems Using a Hybrid Approach*. New York, USA, Springer.

SONNTAG, R. E., BORGNAKKE, C., VAN WILLEN, G. J., 2003, *Fundamentals of Thermodynamics*, 6th ed. USA, John Wiley & Sons, Inc.

STIESCH, G., 2003, *Modelling Engine Spray and Combustion Processes*. Springer.

STONE, R., 1999, *Introduction to Internal Combustion Engines*. 3rd ed., Great Britain, Society of Automotive Engineers.

TAYARANI-BATHAIE, S. S., VANINI, Z. N. S., KHORASANI, K., 2014, "Dynamic Neural Network-Based Fault Diagnosis of Gas Turbine Engines", *Neurocomputing*, v. 125, pp. 153-165.

TENEKEDJIEV, K., LYUBOMIR, A. NAUMOV, V., 1996, "Main Ship Engines and Auxiliary Power Devices Technical Diagnostics Using Pseudo-Discrete Features". *Proceedings of MARIND '96, 1st Intl Conf on Marine Industry; 2-7 June 1996, Vol 1*, p 263 [14 p, 6 ref, 5 tab, 7 fig], Varna, Bulgaria.

TERANO, T., 1976, "Trouble Diagnosis System of Marine Engine – Its System Analysis", *Ship Operation Automation*.

TWIDDLE, J. A., 2001, Fuzzy Systems in Real-Time Condition Monitoring and Fault Diagnosis With a Diesel Engine Case Study. Ph.D thesis, University of Leicester, USA.

UZUN, T., 2012, "A Parametric Study for Specific Fuel Consumption of an Intercooled Diesel Engine Using a Neural Network", *Fuel*, v. 93, pp. 189-199.

UZUN, T., 2014, "Air Mass Flow Estimation of Diesel Engines Using Neural Network", *Fuel*, v. 117, pp. 833-838.

VINCENT, M. R., TURNBULL, A. T., 1986, "Onboard Combustion Monitoring", *Trans. I. Mar. E.*, v. 98, paper 7.

WARKMAN, D. C., 1983, "BP's Performance-Monitoring System for Marine Diesel Engines", *Trans. I. Mar. E.*, v. 95, paper 40.

WATZENIG, D., SOMMER, M. S., STEINER, G., 2009, "Engine State Monitoring and Fault Diagnosis of Large Marine Diesel Engines", *Elektrotechnik & Informationstechnik*, v. 126, n. 5, pp. 173-179.

WHITEHOUSE, N. D., SAREEN, B. K., 1974, "Prediction of Heat Release in a Quiescent Chamber Diesel Engine Allowing for Fuel/Air Mixing", *SAE*, paper 740084.

YINGYING WANG, QIUJU LI, MING CHANG *et al.*, 2012, “Research on Fault Diagnosis Expert System Based on the Neural Network and the Fault Tree Technology”, *Procedia Engineering*, v. 31, pp. 1206-1210.

YUSAF, T. F. *et al*, 2010, “CNG-Diesel Engine Performance and Exhaust Emission Analysis with the Aid of Artificial Neural Network”, *Applied Energy*, v. 87, pp. 1661-1669.

ZIO, E., 2007, *An Introduction to the Basics of Reliability and Risk Analysis*. Singapore, World Scientific Publishing Co. Re. Ltd.

ANEXO I

SISTEMA DE ALIMENTAÇÃO DE AR DE ADMISSÃO

Segundo HEYHOOD [1], a potência máxima que um motor diesel pode liberar é limitada pela quantidade de combustível que pode ser queimado eficientemente dentro do cilindro do motor. A eficiência desta queima é limitada pela quantidade de ar que pode ser introduzido em cada cilindro a cada ciclo. Quando o ar induzido em um motor de dimensões fixas é comprimido até uma densidade superior à do ar ambiente, antes de entrar no cilindro, a potência máxima aumentará. Esta é a finalidade fundamental do super carregamento.

O termo super carregamento refere-se ao aumento da densidade do ar (ou mistura) pelo aumento de sua pressão antes de entrar no cilindro do motor. Entre os métodos utilizados para a realização deste aumento está o turbo carregamento, onde um turbo compressor – um compressor e uma turbina montados em um único eixo – é usado para elevar a densidade do ar de admissão (ou mistura). A energia disponível no fluxo da descarga do motor é usada para acionar a turbina que aciona o compressor que, por sua vez, aumenta a densidade do fluido de admissão antes deste entrar no cilindro do motor.

Para STONE [2], temperatura mais alta na admissão do motor aumenta a temperatura através do ciclo e, embora esta elevação de temperatura reduza o atraso da ignição, ela faz com que o carregamento térmico sobre o motor aumente.

A vantagem do resfriamento da carga leva à utilização de resfriadores intermediários. Obviamente que a vantagem de se utilizar um meio refrigerante (geralmente ar ou água) à temperatura ambiente, ao contrário do que acontece com a água de resfriamento do motor. A Figura 58 mostra um arranjo típico do turbo compressor mais comum.

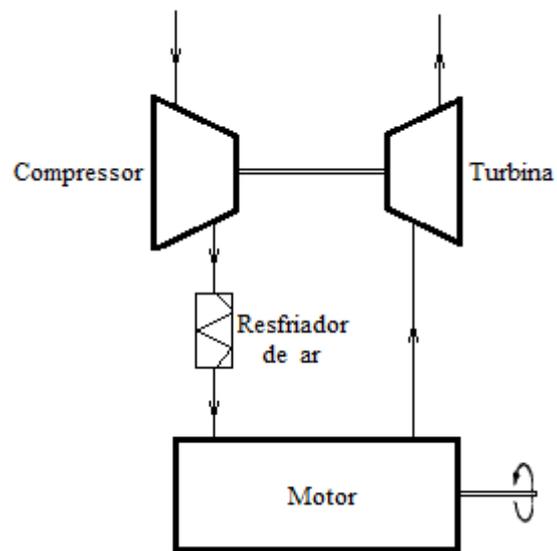


Figura 58 – Esquema típico de turbo compressão de ar de admissão com resfriamento intermediário. Fonte: Própria do autor.

ANEXO II

SISTEMA DE RESFRIAMENTO LÍQUIDO DO MOTOR

Os motores antigos eram resfriados por água armazenada em um reservatório alimentador localizado acima dos cilindros que era reabastecido à medida que a água fervia e evaporava-se. Hoje em dia são empregados sistemas fechados com radiador ou outra forma de trocador de calor, uma ou mais bombas de circulação e um termostato. A Figura 59 ilustra um sistema básico.

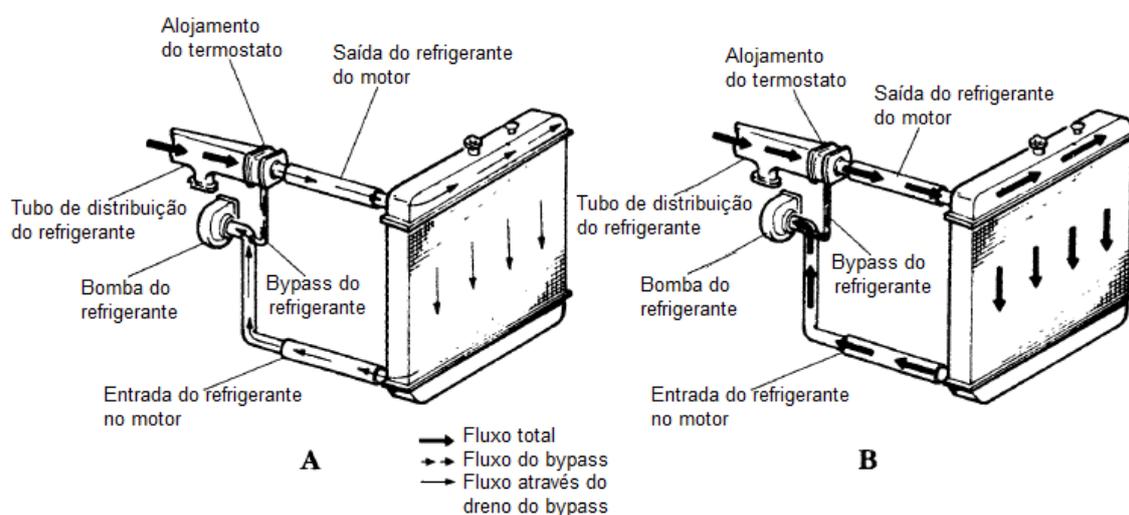


Figura 59 – Fluxo do refrigerante em um sistema desprovido de purga de ar. (A) termostato fechado e (B) termostato aberto. Fonte: adaptado de Dempsey (2008).

Segundo Dempsey (2008), quando o motor está frio, o termostato fecha para confinar a maior parte do refrigerante dentro da jaqueta de água do bloco do motor. Uma pequena fração do refrigerante escoava para o radiador através de um dreno interno no termostato. Como mostrado na Figura 59, o *bypass* é uma mangueira com pequeno diâmetro que liga a parte inferior do alojamento do termostato à bomba. Isto é necessário porque a circulação previne a localização de bolhas quentes na jaqueta de água. Quando a temperatura da água aumenta, o termostato abre. O fluxo sai da jaqueta de água através da mangueira superior e passa para o radiador, saindo pela mangueira inferior no sentido da bomba d'água.

A maioria dos sistemas de resfriamento inclui uma ou duas mangueiras adicionais cuja função é purgar o ar para o radiador ou tanque de expansão, como mostra a Figura 60.

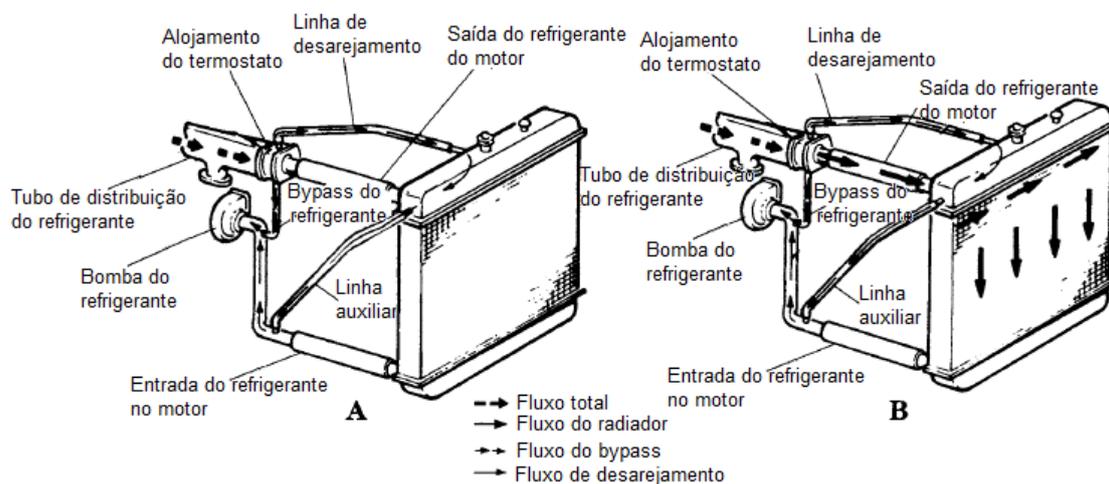


Figura 60 – Fluxo do refrigerante em um sistema com auto-purga. (A) Termostato fechado e (B) Termostato aberto. Fonte: adaptado de Dempsey (2008).

O sistema mostrado na Figura 60 emprega duas linhas que conduzem o refrigerante aerado até o cabeçote do radiador. O ar entra devido ao esguicho (como, por exemplo, quando o radiador é abastecido por balde), passa pelo selo de vedação da bomba d'água e segue caminho através de vazamentos na compressão e pela gaxeta do cabeçote. Além de reduzir a transferência de calor – o ar remove calor cerca de 3500 vezes menos eficientemente do que a água – o ar aumenta a tendência de perda de carga da bomba d'água devido à cavitação.

Os sistemas de resfriamento modernos usam tanques de expansão conectados ao ladrão da tampa do radiador e, nos motores estacionários, descarregam dentro da linha de retorno do radiador (DEMPSEY, 2008). Este tanque de expansão (ou oscilação) descarrega o ar e os gases de descarga confinados, coleta transbordamento (excesso) e fornece um meio conveniente de reuso do refrigerante. Quando for para descarregar gases, o tanque ser localizado acima do alojamento do termostato, que normalmente situa-se no ponto úmido mais alto sobre o bloco do motor.

A Figura 61 e a Figura 62 mostram dois sistemas marítimos de água fresca, um utilizando um trocador de calor resfriado por água do mar e o outro um resfriador de quilha. Os tanques de expansão são mostrados com clareza.

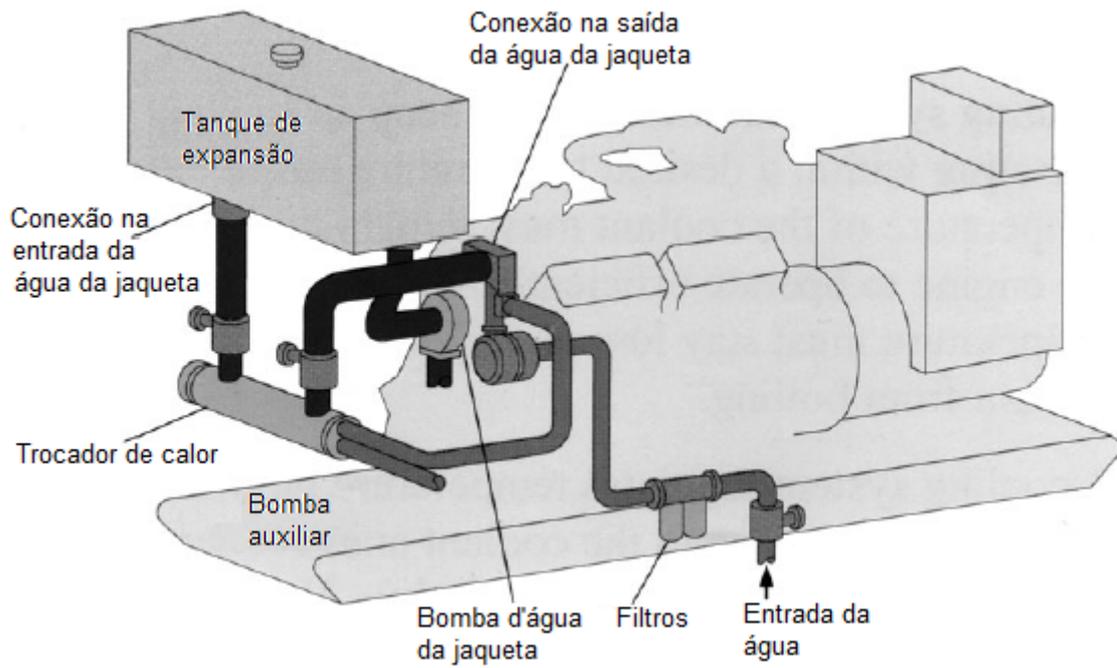


Figura 61 – Aplicação marítima usando um trocador de calor resfriado por água do mar e tanque de expansão. Fonte: adaptado de Dempsey (2008).

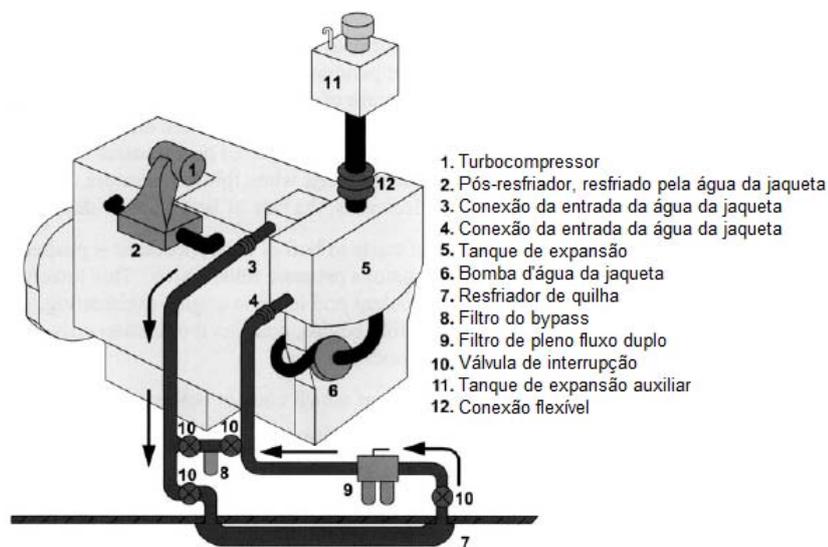


Figura 62 – Aplicação marítima com um resfriador de quilha. Fonte: adaptado de Dempsey (2008).

A prática padrão é distribuir o refrigerante às camisas dos cilindros através de uma tubulação externa, como ilustrado na Figura 63. Muitos motores possuem resfriadores a óleo em série com o circuito de resfriamento principal e múltiplos acessórios resfriados por líquido, tais como o pós-resfriador, o turbo compressor, o conversor de torque e freio de veículos apurados em paralelo.

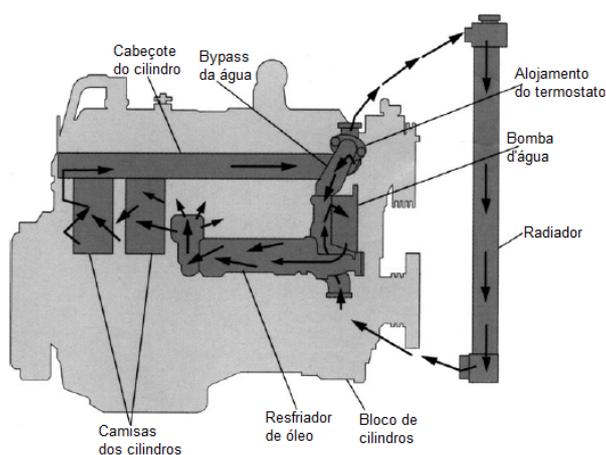


Figura 63 – Um radiador, um resfriador e a jaqueta de água constituem o circuito de resfriamento básico. Fonte: adaptado de Dempsey (2008).

ANEXO III

SISTEMA DE INJEÇÃO DE COMBUSTÍVEL – BOMBA DE IMPULSO

Segundo Dempsey (2008), os sistemas de injeção tiveram um desenvolvimento notável com o desenvolvimento da bomba em linha Bosch, usada hoje de forma quase idêntica à primeira produção iniciada em abril de 1927. As primeiras bombas eram casadas com injetores de agulha em aplicações de injeção indireta. Os injetores com multiorifícios para injeção direta surgiram em 1929 e, dois anos depois, a Bosch integrou governores centrífugos com as bombas, iniciando a era moderna dos motores diesel.

A bomba em linha consiste de uma linha de êmbolos individuais, um por cilindro do motor, operada pelo mesmo eixo de cames interno. Tubulação de alta pressão conecta cada êmbolo ao seu injetor. Os injetores acionados por mola funcionam como válvulas de ação direta que abrem automaticamente quando um valor limite de pressão é alcançado. A perda súbita de pressão na linha fez surgir o termo “bomba de impulso”, que, embora deselegante, é bastante descritivo.

A Figura 64 ilustra o “layout” do sistema de bomba de impulso com bomba em linha. Uma bomba de elevação, mostrada no canto inferior esquerdo do desenho, libera combustível para os filtros e, a partir destes, para a sucção da bomba em linha. Combustível em alta pressão deixa a bomba pelas linhas de cada injetor. Uma segunda linha construída para cada injetor recicla o combustível excedente de volta para o tanque. O sistema trabalha com três níveis de pressão: baixa pressão, da ordem de 30-50 psi, entre a bomba de elevação e a bomba injetora; pressão de alguns milhares de psi na tubulação do injetor; e pressão ligeiramente maior do que zero na linha de retorno.

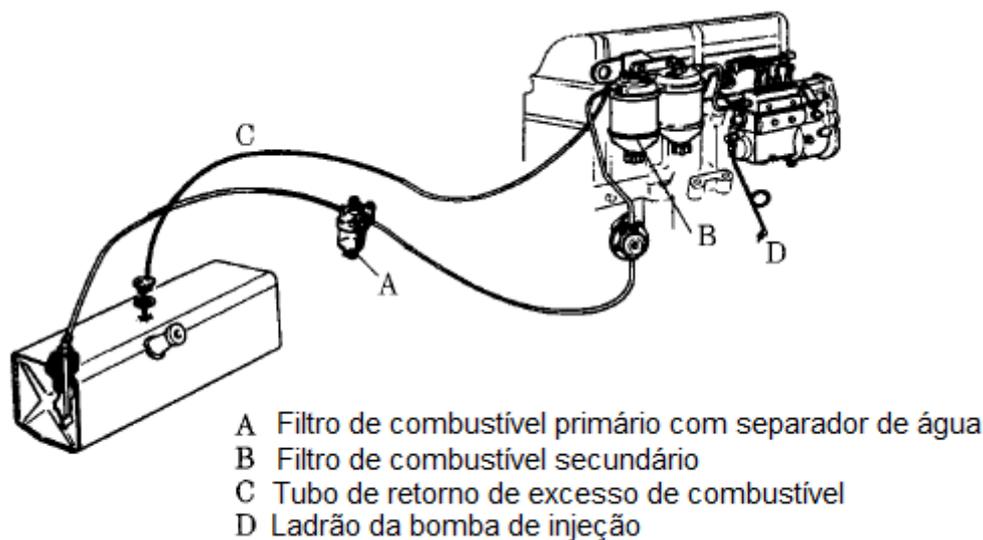


Figura 64 – Um sistema de bomba em linha usados nos motores marítimos Lehman baseado em modelo Ford. Fonte: adaptado de Dempsey (2008).

O desenho de uma bomba com um êmbolo na Figura 65 ajuda a esclarecer a relação entre a cremalheira, engrenagem (pinhão do êmbolo) de controle de combustível e o êmbolo. O combustível entra através da porta de admissão a direita e sai passando pela válvula de recalque no topo da unidade. O rasgo helicoidal cortado no diâmetro externo do êmbolo funciona em conjunto com a cremalheira para controlar a distribuição de combustível.

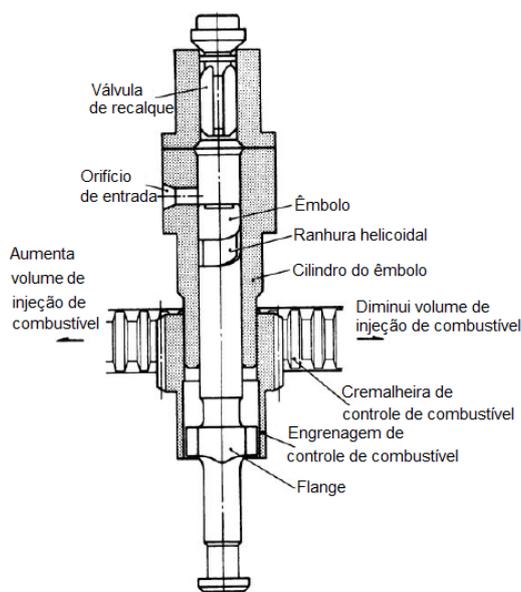


Figura 65 – Montagem do êmbolo, cilindro e cremalheira. A “ranhura helicoidal” usualmente é chamada de hélice. Fonte: adaptado de Dempsey (2008).

O processo de injeção de combustível é mostrado na Figura 66. Na parte mais baixa do curso, o êmbolo destampa a porta de admissão. O combustível entra na câmara de pressão acima do êmbolo. O êmbolo começa a subir, inicialmente empurrando o combustível de volta pela porta de admissão. Movimento de subida adicional encobre a porta de admissão. O êmbolo continua sua elevação, estabelecendo pressão sobre o combustível confinado acima. A válvula de recalque abre e alguns milissegundos depois o injetor descarrega. O combustível continua a ser descarregado até que o rasgo anular fresado ao longo da superfície do êmbolo destampe a porta de admissão. Neste ponto, a pressão é aliviada pela porta de admissão e a injeção cessa. Devido à forma do rasgo, o giro do êmbolo abre a porta de admissão em pressões mais adiantadas ou mais atrasadas no curso do êmbolo.

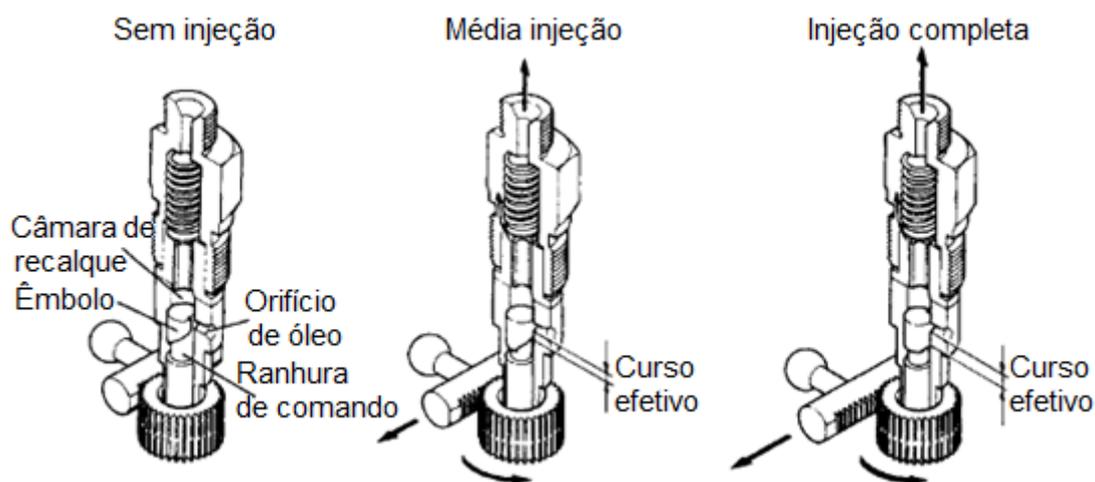


Figura 66 – Ação do êmbolo de começo constante e término variável com o combustível excedente saindo pela porta de admissão. Fonte: adaptado de Dempsey (2008).

APÊNDICE A

VALORES LIMITES DOS DADOS DE ENTRADA DA RNA

Tabela 31 – Valores limite dos dados de entrada da RNA.

	Pmax [bar]	Pcomp [bar]	θPmax [°CA]	TEPcomb [bar/°CA]	Tdesc [°C]	Tadm [°C]	δTcil [°C]	TSagua [°C]	TEagua [°C]	δTagua [°C]
máx	104	87	11,48	1,904	530	50	505	95	65	
mín	100	83	11,03	1,132		20	475	80		15
	PImax [bar]	PIaber [bar]	θPIaber [°CA]	Δinj [°CA]	Tpre.aq [°C]	Padm [bar]	Pamb [bar]	PEtc [bar]	PEic [bar]	δPic [bar]
máx	714	377	5,61	20,50	120	7,99	1		8,03	0,040
							1			
mín	686	363	5,39	19,70	108	6,00	1	0,990	6,01	

APÊNDICE C

MATRIZ DOS VETORES DE ENTRADA DA RNA

100,000	104,000	102,280	103,040	101,550	101,780	100,230	100,800
87,000	83,000	84,950	86,590	86,950	84,400	83,690	86,280
11,480	11,030	11,240	11,110	11,470	11,260	11,190	11,290
1,132	1,904	1,542	1,481	1,273	1,544	1,478	1,286
518,000	530,000	505,000	503,000	528,000	517,000	510,000	530,000
23,000	25,000	30,000	21,000	44,000	20,000	23,000	25,000
495,000	505,000	475,000	482,000	484,000	497,000	487,000	505,000
89,000	86,000	90,000	88,000	88,000	80,000	82,000	80,000
65,000	56,000	64,000	57,000	63,000	61,000	50,000	65,000
24,000	30,000	26,000	31,000	25,000	19,000	32,000	15,000
686,000	700,000	714,000	701,000	699,000	706,000	693,000	694,000
376,000	373,000	367,000	377,000	371,000	377,000	366,000	370,000
5,430	5,390	5,510	5,420	5,580	5,450	5,520	5,520
20,500	19,920	19,700	20,360	20,390	20,330	19,930	20,210
117,000	115,000	120,000	112,000	118,000	112,000	111,000	110,000
7,010	6,220	7,150	6,410	7,110	7,030	7,990	6,770
1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000
0,995	0,992	0,990	0,999	0,997	0,999	0,990	0,993
7,050	6,250	7,160	6,440	7,140	7,050	8,000	6,810
0,040	0,030	0,010	0,030	0,030	0,020	0,010	0,040
101,720	101,070	103,830	103,890	100,000	103,230	101,070	
86,000	83,820	85,350	83,010	83,540	87,000	83,490	
11,450	11,480	11,410	11,050	11,040	11,210	11,400	
1,373	1,503	1,620	1,890	1,491	1,448	1,542	
519,000	515,000	529,000	525,000	512,000	528,000	515,000	
39,000	38,000	39,000	50,000	32,000	43,000	33,000	
480,000	477,000	490,000	475,000	480,000	485,000	482,000	
83,000	95,000	91,000	93,000	86,000	84,000	94,000	
65,000	51,000	52,000	60,000	63,000	65,000	68,000	
18,000	44,000	39,000	33,000	23,000	19,000	26,000	
687,000	687,000	690,000	697,000	705,000	708,000	689,000	
377,000	374,000	365,000	363,000	368,000	373,000	364,000	
5,540	5,610	5,430	5,580	5,550	5,500	5,600	
20,460	19,790	19,850	20,330	20,120	20,190	20,470	
118,000	109,000	108,000	111,000	118,000	109,000	110,000	
6,900	7,360	6,800	6,030	6,000	7,680	7,820	
1,000	1,000	1,000	1,000	1,000	1,000	1,000	
0,991	0,996	0,998	0,992	0,995	0,991	0,993	
6,920	7,400	6,810	6,050	6,010	7,710	7,850	
0,020	0,040	0,010	0,020	0,010	0,030	0,030	

108,000	109,620	109,280	104,010	107,520	107,500	108,380	105,700
83,240	87,000	84,710	83,000	85,450	85,705	83,000	83,380
11,070	11,040	11,460	11,030	11,140	11,070	11,480	11,380
2,237	2,049	2,144	1,905	1,981	1,969	2,211	1,961
530,010	597,000	590,000	578,000	555,010	585,000	561,000	548,000
25,000	45,000	39,000	25,000	50,000	31,000	50,000	20,000
505,010	552,000	551,000	553,000	505,010	554,000	511,000	528,000
95,000	94,000	83,000	95,000	87,010	90,000	80,010	93,000
65,000	63,000	55,000	65,000	61,000	51,000	65,000	58,000
30,000	31,000	28,000	30,000	26,010	39,000	15,010	35,000
692,000	686,000	693,000	688,000	689,000	697,000	686,000	714,000
376,000	374,000	373,000	363,000	377,000	374,000	377,000	363,000
5,560	5,440	5,470	5,390	5,520	5,540	5,610	5,410
19,700	20,500	20,200	20,110	20,490	19,920	20,000	19,960
115,000	108,000	118,000	116,000	120,000	117,000	112,000	111,000
7,450	7,050	6,730	7,990	7,370	7,550	6,690	7,070
1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000
0,992	0,999	0,997	0,993	0,995	0,995	0,992	0,998
7,490	7,070	6,740	8,030	7,400	7,560	6,710	7,080
0,040	0,020	0,010	0,040	0,030	0,010	0,020	0,010
109,680	105,000	109,270	108,900	107,640	104,010	105,380	
87,000	83,500	86,700	87,000	86,090	83,000	84,080	
11,270	11,070	11,220	11,170	11,230	11,030	11,110	
2,012	1,942	2,012	1,961	1,919	1,905	1,917	
620,000	586,000	589,000	530,010	571,000	534,000	555,000	
49,000	26,000	37,000	20,000	42,000	22,000	25,000	
571,000	560,000	552,000	510,010	529,000	512,000	530,000	
80,000	81,000	82,000	92,000	91,000	83,000	88,000	
64,000	60,000	63,000	64,000	62,000	64,000	60,000	
16,000	21,000	19,000	28,000	29,000	19,000	28,000	
691,000	706,000	705,000	711,000	707,000	703,000	689,000	
368,000	373,000	366,000	370,000	375,000	371,000	375,000	
5,490	5,410	5,610	5,390	5,570	5,530	5,520	
20,100	20,220	19,990	20,010	20,380	20,230	20,360	
108,000	115,000	120,000	117,000	119,000	112,000	114,000	
6,000	6,530	6,950	7,080	7,530	7,140	6,940	
1,000	1,000	1,000	1,000	1,000	1,000	1,000	
0,994	0,998	0,999	0,991	0,996	0,991	0,993	
6,010	6,560	6,990	7,110	7,550	7,170	6,960	
0,010	0,030	0,040	0,030	0,020	0,030	0,020	

108,760	107,410	106,480	104,670	109,540	108,460	107,140	105,040
86,110	84,980	85,450	83,180	86,170	84,950	85,270	83,280
11,120	11,280	11,040	11,140	11,110	11,450	11,240	11,080
2,037	1,988	1,905	1,929	2,104	2,053	1,946	1,964
550,000	538,000	590,000	558,000	541,000	530,010	586,000	589,000
44,990	26,000	39,000	20,000	30,000	25,000	50,000	37,000
505,010	512,000	551,000	528,000	511,000	505,010	536,000	552,000
90,000	84,000	93,000	80,000	84,000	95,000	94,000	83,000
51,000	57,000	58,000	64,000	60,000	65,000	53,000	55,000
39,000	27,000	35,000	16,000	24,000	30,000	41,000	28,000
698,000	703,000	694,000	699,000	690,000	705,000	689,000	699,000
369,000	366,000	371,000	370,000	372,000	376,000	377,000	367,000
5,470	5,500	5,540	5,610	5,570	5,610	5,490	5,570
20,490	20,210	20,270	19,900	20,460	19,700	19,910	19,780
102,000	104,000	107,990	106,000	101,000	105,000	104,000	107,000
6,000	6,540	7,470	7,040	6,590	6,960	7,320	7,710
1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000
0,995	0,992	0,990	0,999	0,997	0,995	0,992	0,998
6,030	6,550	7,500	7,080	6,620	7,000	7,360	7,740
0,030	0,010	0,030	0,040	0,030	0,040	0,040	0,030
106,000	104,010	109,780	108,440	105,860	108,860	105,340	
84,100	83,000	86,940	83,300	84,040	84,000	84,230	
11,030	11,030	11,120	11,440	11,200	11,140	11,070	
1,985	1,905	2,054	2,198	1,948	2,232	1,907	
541,000	554,000	585,000	555,000	560,010	620,000	586,000	
27,000	48,990	31,000	20,000	50,000	49,000	26,000	
514,000	505,010	554,000	535,000	510,010	571,000	560,000	
81,000	86,000	95,000	94,000	83,000	81,000	86,000	
59,000	56,000	60,000	63,000	65,000	59,000	64,000	
22,000	30,000	35,000	31,000	18,000	22,000	22,000	
693,000	714,000	701,000	688,000	712,000	686,000	701,000	
374,000	363,000	375,000	373,000	377,000	376,000	375,000	
5,490	5,600	5,510	5,390	5,470	5,460	5,590	
19,850	20,500	20,090	20,250	20,100	19,940	19,840	
105,000	107,990	103,000	107,000	103,000	106,000	105,000	
6,380	6,000	7,090	7,600	7,190	6,020	6,690	
1,000	1,000	1,000	1,000	1,000	1,000	1,000	
0,994	0,998	0,998	0,992	0,995	0,991	0,993	
6,400	6,010	7,120	7,630	7,200	6,060	6,720	
0,020	0,010	0,030	0,030	0,010	0,040	0,030	

106,600	106,780	104,010	104,670	107,930	108,170	109,220	105,390
84,230	83,490	83,000	83,200	85,160	86,090	85,920	83,570
11,290	11,100	11,030	11,050	11,170	11,260	11,330	11,250
1,981	2,098	1,905	1,943	2,038	1,961	2,056	1,940
554,000	571,000	584,000	555,000	564,000	570,000	530,010	620,000
27,000	20,000	37,000	49,990	48,000	45,000	20,000	50,000
527,000	551,000	547,000	505,010	516,000	525,000	510,010	570,000
90,000	84,000	93,000	80,000	84,000	95,000	94,000	83,000
61,000	57,000	58,000	64,000	60,000	65,000	53,000	59,000
29,000	27,000	35,000	16,000	24,000	30,000	41,000	24,000
685,990	678,000	670,000	680,000	669,000	675,000	677,000	670,000
366,000	363,000	370,000	368,000	375,000	377,000	374,000	365,000
5,430	5,450	5,390	5,420	5,430	5,550	5,550	5,400
19,940	19,860	19,970	20,190	20,070	20,380	20,300	20,070
120,000	115,000	108,000	113,000	115,000	111,000	117,000	109,000
7,990	6,380	6,000	7,780	7,190	6,770	6,610	7,210
1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000
0,990	0,999	0,997	0,995	0,992	0,990	0,993	0,991
8,020	6,400	6,040	7,800	7,230	6,810	6,650	7,240
0,030	0,020	0,040	0,020	0,040	0,040	0,040	0,030
109,870	109,010	108,210	105,700	106,540	108,150	109,700	
87,000	84,400	85,950	84,270	83,590	86,040	85,720	
11,040	11,300	11,310	11,100	11,150	11,480	11,300	
2,072	2,178	1,968	1,931	2,058	1,926	2,122	
586,000	589,000	578,000	605,000	547,000	578,000	602,000	
26,000	37,000	40,000	43,000	41,990	20,000	50,000	
560,000	552,000	538,000	562,000	505,010	558,000	552,000	
81,000	86,000	95,000	94,000	83,000	81,000	86,000	
63,000	65,000	61,000	63,000	65,000	56,000	58,000	
18,000	21,000	34,000	31,000	18,000	25,000	28,000	
685,990	679,000	685,000	660,000	676,000	681,000	669,000	
363,000	370,000	368,000	367,000	377,000	364,000	363,000	
5,530	5,530	5,430	5,580	5,460	5,610	5,420	
20,280	20,080	20,500	20,000	20,250	20,120	19,700	
118,000	117,000	110,000	120,000	119,000	114,000	113,000	
7,100	7,610	6,490	6,310	7,330	6,190	6,000	
1,000	1,000	1,000	1,000	1,000	1,000	1,000	
0,996	0,998	0,994	0,998	0,998	0,992	0,995	
7,130	7,650	6,520	6,350	7,340	6,200	6,010	
0,030	0,040	0,030	0,040	0,010	0,010	0,010	

106,590	104,010	107,680	109,370	108,480	107,620	107,970	108,140
84,230	83,000	85,820	87,000	85,160	86,090	85,920	84,310
11,130	11,030	11,470	11,080	11,180	11,140	11,090	11,120
2,009	1,905	1,906	2,019	2,086	1,933	1,988	2,143
549,000	565,000	530,010	595,000	584,000	564,000	572,000	615,000
22,000	29,000	20,000	41,000	33,000	58,000	24,000	50,000
527,000	536,000	510,010	554,000	551,000	506,000	548,000	565,000
93,000	80,000	84,000	95,000	94,000	83,000	81,000	86,000
62,000	64,000	60,000	55,000	63,000	60,000	57,000	61,000
31,000	16,000	24,000	40,000	31,000	23,000	24,000	25,000
681,000	682,000	677,000	673,000	685,000	680,000	683,000	676,000
371,000	372,000	363,000	377,000	365,000	363,000	368,000	376,000
5,640	5,620	5,680	5,700	5,640	5,690	5,620	5,650
20,340	20,440	19,720	20,220	19,740	20,440	20,390	20,060
108,000	111,000	119,000	116,000	113,000	120,000	116,000	117,000
7,990	6,250	6,300	7,000	6,980	6,180	7,280	6,420
1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000
0,990	0,999	0,997	0,999	0,998	0,999	0,991	0,996
8,030	6,290	6,310	7,040	7,020	6,210	7,320	6,440
0,040	0,040	0,010	0,040	0,040	0,030	0,040	0,020
106,690	106,150	108,410	106,250	104,850	106,120	109,000	
83,690	84,400	85,950	84,270	83,590	83,040	85,720	
11,210	11,250	11,210	11,040	11,140	11,150	11,480	
2,052	1,933	2,004	1,991	1,908	2,070	2,028	
580,000	547,010	582,000	613,000	550,010	588,000	599,000	
35,000	42,000	31,000	39,000	45,000	46,000	41,000	
545,000	505,010	551,000	574,000	505,010	542,000	558,000	
83,000	81,000	86,000	95,000	94,000	90,000	84,000	
65,000	59,000	56,000	58,000	63,000	51,000	57,000	
18,000	22,000	30,000	37,000	31,000	39,000	27,000	
684,000	680,000	678,000	680,000	675,000	685,000	669,000	
367,000	369,000	371,000	375,000	377,000	371,000	364,000	
5,790	5,690	5,710	5,640	5,680	5,630	5,620	
20,450	20,420	20,200	19,730	19,960	19,780	20,120	
117,000	108,000	115,000	120,000	119,000	117,000	108,000	
6,760	7,680	7,990	6,000	7,710	6,830	6,660	
1,000	1,000	1,000	1,000	1,000	1,000	1,000	
0,992	0,998	0,994	0,998	0,996	0,998	0,994	
6,790	7,700	8,000	6,010	7,730	6,860	6,690	
0,030	0,020	0,010	0,010	0,020	0,030	0,030	

106,050	104,900	104,010	107,330	108,430	104,010	109,230	105,950
84,230	83,490	85,840	86,020	85,160	87,000	85,920	87,000
11,490	12,000	12,310	13,970	15,860	11,030	15,710	11,490
1,899	1,784	1,476	1,525	1,467	1,542	1,484	1,649
534,000	603,000	602,000	566,000	574,000	613,000	530,010	549,000
28,990	38,000	50,000	35,000	23,000	47,000	25,000	20,000
505,010	565,000	552,000	531,000	551,000	566,000	505,010	529,000
89,000	86,000	80,000	88,000	88,000	80,000	82,000	81,000
65,000	56,000	65,000	61,000	64,000	65,000	55,000	64,000
24,000	30,000	15,000	27,000	24,000	15,000	27,000	17,000
694,000	686,000	696,000	702,000	698,000	687,000	689,000	704,000
370,000	366,000	363,000	368,000	373,000	371,000	368,000	370,000
5,520	5,470	5,610	5,390	5,570	5,490	5,590	5,450
20,530	20,630	20,610	20,510	20,630	21,000	20,560	20,640
113,000	118,000	120,000	118,000	114,000	113,000	108,000	119,000
6,840	7,770	6,720	7,980	7,330	7,560	6,710	7,080
1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000
0,996	0,998	0,994	0,990	0,993	0,991	0,990	0,999
6,870	7,800	6,730	8,000	7,370	7,600	6,730	7,100
0,030	0,030	0,010	0,020	0,040	0,040	0,020	0,020
104,540	108,850	109,570	105,920	106,490	105,810	107,160	
86,900	84,400	85,950	84,270	83,590	86,040	85,720	
15,580	16,000	15,560	14,530	15,490	13,190	14,010	
1,132	1,528	1,518	1,490	1,478	1,499	1,530	
586,000	590,000	591,000	592,000	596,000	530,010	607,000	
33,000	38,000	40,000	34,000	50,000	20,000	45,000	
553,000	552,000	551,000	558,000	546,000	510,010	562,000	
83,000	95,000	91,000	93,000	86,000	84,000	94,000	
63,000	61,000	62,000	60,000	53,000	62,000	59,000	
20,000	34,000	29,000	33,000	33,000	22,000	35,000	
702,000	686,000	709,000	707,000	714,000	694,000	703,000	
367,000	363,000	365,000	377,000	375,000	364,000	377,000	
5,400	5,560	5,610	5,530	5,440	5,530	5,420	
20,510	27,000	20,580	20,640	23,000	22,000	20,550	
110,000	117,000	120,000	115,000	119,000	109,000	112,000	
6,990	6,500	6,940	7,070	7,130	7,170	6,240	
1,000	1,000	1,000	1,000	1,000	1,000	1,000	
0,997	0,992	0,999	0,997	0,990	0,993	0,991	
7,000	6,530	6,950	7,080	7,160	7,200	6,270	
0,010	0,030	0,010	0,010	0,030	0,030	0,030	

107,420	104,010	106,140	107,140	109,350	106,640	109,900	108,870
84,700	83,000	83,280	85,730	84,560	85,537	85,330	86,750
11,050	11,030	11,460	11,090	11,150	11,050	11,290	11,440
2,056	1,905	1,995	1,931	2,223	1,910	2,176	1,934
597,000	582,000	613,000	633,000	535,010	599,000	533,000	603,000
42,000	20,000	35,000	45,000	30,000	41,000	27,990	38,000
555,000	562,000	578,000	588,000	505,010	558,000	505,010	565,000
95,000	94,000	83,000	81,000	86,000	90,000	84,000	93,000
65,000	63,000	60,000	58,000	56,000	61,000	63,000	65,000
30,000	31,000	23,000	23,000	30,000	29,000	21,000	28,000
669,000	681,000	679,000	671,000	677,000	675,000	684,000	682,000
355,000	356,000	358,000	362,000	356,000	361,000	362,000	358,000
5,390	5,520	5,590	5,470	5,530	5,390	5,470	5,540
20,000	20,330	19,750	20,500	19,840	19,700	20,210	20,070
115,000	120,000	111,000	118,000	120,000	112,000	110,000	108,000
6,590	6,980	7,670	6,070	6,440	7,000	7,960	6,760
1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000
0,990	0,990	0,997	0,997	0,993	0,998	0,999	0,991
6,630	7,010	7,700	6,100	6,450	7,030	7,990	6,770
0,040	0,030	0,030	0,030	0,010	0,030	0,030	0,010
105,430	107,790	107,210	108,620	107,880	107,460	105,660	
83,140	84,010	85,370	86,690	85,340	86,310	83,150	
11,360	11,040	11,130	11,180	11,210	11,090	11,110	
1,962	2,154	1,962	1,962	2,011	1,907	2,026	
602,000	566,000	574,000	613,000	589,000	557,000	586,000	
50,000	26,000	20,000	47,000	38,000	50,000	33,000	
552,000	540,000	554,000	566,000	551,000	507,000	553,000	
80,000	84,000	82,000	92,000	91,000	83,000	88,000	
64,000	60,000	63,000	64,000	62,000	65,000	55,000	
16,000	24,000	19,000	28,000	29,000	18,000	33,000	
670,000	676,000	685,000	679,000	683,000	680,000	668,000	
355,000	356,000	361,000	359,000	351,000	362,000	350,000	
5,610	5,410	5,510	5,470	5,570	5,530	5,600	
20,370	20,480	19,770	20,290	20,280	19,850	20,430	
116,000	111,000	108,000	109,000	114,000	117,000	114,000	
6,880	7,320	6,760	7,500	6,250	7,660	6,660	
1,000	1,000	1,000	1,000	1,000	1,000	1,000	
0,995	0,995	0,992	0,994	0,999	0,996	0,993	
6,900	7,360	6,800	7,510	6,280	7,680	6,690	
0,020	0,040	0,040	0,010	0,030	0,020	0,030	

107,990	104,010	108,150	106,800	108,130	105,020	108,970	104,720
84,850	83,000	86,480	83,820	86,720	83,210	87,000	83,080
11,180	11,030	11,330	11,270	11,070	11,130	11,170	11,290
2,070	1,905	1,913	2,039	1,934	1,960	1,967	1,917
594,000	597,000	555,010	620,000	530,010	589,000	531,000	605,000
36,000	45,000	50,000	49,000	25,000	37,000	20,000	43,000
558,000	552,000	505,010	571,000	505,010	552,000	511,000	562,000
90,000	84,000	93,000	80,000	84,000	95,000	94,000	83,000
61,000	57,000	58,000	64,000	56,000	57,000	53,000	65,000
29,000	27,000	35,000	16,000	28,000	38,000	41,000	18,000
709,000	711,000	699,000	688,000	701,000	703,000	704,000	693,000
377,000	371,000	365,000	373,000	363,000	369,000	368,000	370,000
5,470	5,410	5,570	5,520	5,480	5,390	5,470	5,430
20,070	19,700	20,470	20,450	19,900	20,260	19,920	20,500
115,000	120,000	108,000	113,000	110,000	109,000	120,000	119,000
5,880	5,420	5,980	5,500	5,720	5,570	5,350	5,480
1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000
0,983	0,988	0,980	0,985	0,981	0,984	0,978	0,982
5,900	5,460	5,990	5,530	5,750	5,600	5,380	5,500
0,020	0,040	0,010	0,030	0,030	0,030	0,030	0,020
104,130	107,100	109,590	104,960	106,420	105,980	109,560	
83,050	84,000	85,870	83,000	84,700	84,040	85,660	
11,050	11,200	11,250	11,030	11,150	11,250	11,380	
1,908	2,063	2,108	1,991	1,948	1,950	2,100	
591,000	578,000	602,000	549,000	565,000	530,010	595,000	
28,000	28,000	50,000	33,000	39,000	20,000	41,000	
563,000	550,000	552,000	516,000	526,000	510,010	554,000	
81,000	86,000	95,000	94,000	83,000	81,000	86,000	
59,000	56,000	64,000	62,000	65,000	62,000	56,000	
22,000	30,000	31,000	32,000	18,000	19,000	30,000	
699,000	713,000	714,000	706,000	707,000	686,000	697,000	
370,000	365,000	369,000	363,000	366,000	370,000	377,000	
5,580	5,550	5,580	5,510	5,540	5,610	5,510	
20,150	20,440	19,910	19,840	20,340	20,400	19,740	
110,000	120,000	119,000	115,000	111,000	115,000	110,000	
5,930	5,800	5,630	5,380	5,840	5,550	5,790	
1,000	1,000	1,000	1,000	1,000	1,000	1,000	
0,980	0,979	0,977	0,989	0,986	0,980	0,979	
5,950	5,820	5,640	5,410	5,850	5,570	5,820	
0,020	0,020	0,010	0,030	0,010	0,020	0,030	

104,010	106,180	109,390	105,140	107,420	105,440	107,010	106,020
83,000	84,400	86,130	83,630	85,700	83,280	84,900	84,250
11,030	11,400	11,100	11,240	11,310	11,350	11,390	11,060
1,905	1,911	2,095	1,914	1,920	1,952	1,941	1,968
601,000	620,000	586,000	551,000	530,010	571,000	534,000	555,000
50,000	49,000	26,000	45,990	22,000	20,000	39,000	25,000
551,000	571,000	560,000	505,010	508,010	551,000	495,000	530,000
90,000	84,000	93,000	80,000	84,000	95,000	94,000	83,000
61,000	65,000	58,000	54,000	60,000	65,000	63,000	65,000
29,000	19,000	35,000	26,000	24,000	30,000	31,000	18,000
698,000	711,000	704,000	714,000	702,000	700,000	710,000	693,000
365,000	375,000	374,000	366,000	363,000	370,000	377,000	375,000
5,410	5,550	5,480	5,390	5,500	5,550	5,530	5,560
20,500	19,700	20,280	19,930	20,420	20,310	20,450	20,230
110,000	108,000	111,000	119,000	120,000	108,000	112,000	109,000
5,960	5,440	5,550	5,770	5,300	5,930	5,670	5,400
1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000
0,995	0,992	0,994	0,999	0,996	0,993	0,999	0,991
5,970	5,460	5,590	5,790	5,310	5,940	5,710	5,440
0,010	0,020	0,040	0,020	0,010	0,010	0,040	0,040
109,260	107,180	108,010	107,280	105,620	109,270	107,530	
84,920	84,010	86,360	83,830	84,170	86,270	83,780	
11,180	11,160	11,280	11,160	11,180	11,360	11,080	
2,177	2,076	1,919	2,101	1,919	2,025	2,144	
594,000	597,000	590,000	578,000	581,000	620,000	586,000	
36,000	45,000	39,000	50,000	30,000	49,000	26,000	
558,000	552,000	551,000	528,000	551,000	571,000	560,000	
81,000	86,000	95,000	94,000	83,000	81,000	86,000	
56,000	56,000	61,000	58,000	64,000	63,000	64,000	
25,000	30,000	34,000	36,000	19,000	18,000	22,000	
712,000	700,000	707,000	696,000	703,000	709,000	686,000	
369,000	376,000	371,000	364,000	374,000	372,000	367,000	
5,540	5,500	5,540	5,450	5,570	5,590	5,610	
19,720	20,220	20,290	20,380	20,400	20,370	19,990	
113,000	116,000	108,000	120,000	115,000	111,000	118,000	
5,590	5,660	5,910	5,840	5,390	5,510	5,860	
1,000	1,000	1,000	1,000	1,000	1,000	1,000	
0,995	0,992	0,994	0,992	0,991	0,993	0,997	
5,610	5,690	5,950	5,850	5,400	5,540	5,880	
0,020	0,030	0,040	0,010	0,010	0,030	0,020	

108,200	106,370	104,010	106,810	105,540	107,370	109,640	107,360
85,700	83,120	83,000	83,750	84,280	83,150	85,640	84,880
11,220	11,130	11,030	11,230	11,090	11,450	11,400	11,070
2,005	2,089	1,905	2,053	1,917	2,115	2,105	2,031
592,000	596,000	595,000	530,010	548,000	582,000	613,000	633,000
34,000	45,000	50,000	20,000	42,990	31,000	35,000	45,000
558,000	551,000	545,000	510,010	505,010	551,000	578,000	588,000
80,000	84,000	93,000	80,000	84,000	95,000	94,000	83,000
65,000	65,000	63,000	54,000	60,000	63,000	61,000	53,000
15,000	19,000	30,000	26,000	24,000	32,000	33,000	30,000
688,000	709,000	686,000	692,000	696,000	692,000	687,000	694,000
365,000	363,000	366,000	369,000	371,000	368,000	377,000	372,000
5,520	5,450	5,580	5,500	5,490	5,390	5,440	5,460
19,760	19,930	20,380	20,400	20,240	20,090	20,310	19,840
108,000	120,000	112,000	113,000	116,000	120,000	114,000	111,000
5,990	5,730	5,610	5,470	5,310	5,490	5,510	5,420
1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000
0,990	0,999	0,996	0,994	0,996	0,994	0,990	0,998
6,035	6,500	7,940	7,890	7,780	7,110	7,100	6,860
0,045	0,770	2,330	2,420	2,470	1,620	1,590	1,440
107,020	106,710	105,750	108,150	105,260	104,960	108,010	
83,420	85,010	83,030	85,750	83,030	83,480	86,040	
11,030	11,280	11,430	11,180	11,420	11,210	11,470	
2,140	1,924	1,988	2,004	1,947	1,916	1,915	
588,000	599,000	580,000	603,000	530,010	566,000	574,000	
21,000	41,000	29,000	38,000	25,000	35,000	23,000	
567,000	558,000	551,000	565,000	505,010	531,000	551,000	
81,000	86,000	95,000	94,000	83,000	81,000	86,000	
58,000	64,000	65,000	53,000	64,000	62,000	65,000	
23,000	22,000	30,000	41,000	19,000	19,000	21,000	
714,000	695,000	694,000	700,000	689,000	694,000	691,000	
372,000	375,000	365,000	366,000	368,000	370,000	371,000	
5,470	5,580	5,610	5,440	5,470	5,500	5,520	
19,700	20,120	19,860	19,850	20,270	20,500	19,800	
108,000	110,000	113,000	117,000	120,000	119,000	109,000	
5,340	5,650	5,990	5,770	5,970	5,969	5,570	
1,000	1,000	1,000	1,000	1,000	1,000	1,000	
0,991	0,995	0,993	0,992	0,994	0,992	0,991	
6,140	6,180	8,000	7,740	6,012	6,010	7,120	
0,800	0,530	2,010	1,970	0,042	0,041	1,550	

100,000	104,000	101,860	103,480	101,120	100,310	102,850	100,780
87,000	83,000	84,500	86,340	83,980	83,770	85,500	83,310
11,480	11,030	11,470	11,400	11,120	11,070	11,420	11,320
1,132	1,904	1,514	1,504	1,541	1,494	1,519	1,543
613,000	589,000	549,000	586,000	530,010	554,010	592,000	596,000
50,000	38,000	43,000	33,000	20,000	49,000	34,000	45,000
563,000	551,000	506,000	553,000	510,010	505,010	558,000	551,000
80,000	84,000	93,000	80,000	81,000	95,000	92,000	95,000
65,010	80,000	84,000	79,000	65,010	90,000	78,000	89,000
14,990	4,000	9,000	1,000	11,990	5,000	14,000	6,000
693,000	709,000	686,000	690,000	714,000	703,000	690,000	706,000
369,000	374,000	366,000	370,000	374,000	364,000	368,000	364,000
5,550	5,590	5,450	5,500	5,430	5,390	5,530	5,610
20,210	20,500	20,390	19,970	20,040	20,340	19,700	19,950
119,000	109,000	116,000	120,000	113,000	108,000	112,000	116,000
7,280	6,350	6,640	7,770	7,160	6,810	6,590	7,290
1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000
0,999	0,991	0,995	0,995	0,992	0,994	0,999	0,996
7,310	6,380	6,650	7,780	7,190	6,840	6,610	7,310
0,030	0,030	0,010	0,010	0,030	0,030	0,020	0,020
104,000	102,150	101,680	101,580	102,970	100,030	104,000	
83,000	85,000	84,670	84,550	85,330	86,967	87,000	
11,030	11,280	11,260	11,380	11,420	11,360	11,450	
1,904	1,520	1,511	1,496	1,545	1,150	1,485	
550,000	607,000	597,000	582,000	613,000	528,010	588,000	
44,990	45,000	42,000	31,000	35,000	21,000	30,000	
505,010	562,000	555,000	551,000	578,000	507,010	558,000	
80,000	86,000	90,000	85,000	84,000	80,000	89,000	
65,010	82,000	75,010	77,000	78,000	65,010	76,000	
14,990	4,000	14,990	8,000	6,000	14,990	13,000	
686,000	698,000	689,000	700,000	714,000	707,000	710,000	
374,000	371,000	364,000	372,000	366,000	363,000	375,000	
5,600	5,580	5,490	5,540	5,570	5,390	5,420	
20,150	20,480	20,250	20,280	19,830	20,010	20,220	
116,000	117,000	120,000	119,000	119,000	117,000	114,000	
7,060	6,850	7,930	6,350	7,340	6,150	6,020	
1,000	1,000	1,000	1,000	1,000	1,000	1,000	
0,993	0,992	0,994	0,992	0,991	0,993	0,997	
7,100	6,860	7,960	6,390	7,360	6,190	6,040	
0,040	0,010	0,030	0,040	0,020	0,040	0,020	

102,640	103,720	100,000	102,150	101,500	104,000	100,000	104,000
85,500	86,470	87,000	86,970	84,000	86,000	87,000	83,000
11,410	11,170	11,480	11,210	11,470	11,440	11,480	11,030
1,502	1,544	1,132	1,354	1,526	1,573	1,132	1,904
530,000	528,000	529,000	530,000	529,940	530,000	529,000	525,010
20,000	22,990	23,990	21,000	24,000	24,000	23,990	20,000
510,000	505,010	505,010	509,000	505,940	506,000	505,010	505,010
90,000	84,000	93,000	80,000	84,000	95,000	94,000	83,000
65,000	62,000	54,000	55,000	61,000	64,000	63,000	60,000
25,000	22,000	39,000	25,000	23,000	31,000	31,000	23,000
701,000	712,000	710,000	691,000	703,000	686,000	697,000	689,000
374,000	368,000	376,000	363,000	365,000	364,000	364,000	370,000
5,390	5,430	5,590	5,460	5,470	5,610	5,600	5,440
19,910	20,010	20,310	19,700	20,330	20,460	20,380	20,500
110,000	120,000	111,000	108,000	115,000	120,000	114,000	116,000
6,270	7,760	7,260	6,670	6,910	7,420	7,350	6,060
1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000
0,990	0,999	0,996	0,994	0,996	0,994	0,997	0,993
6,290	7,800	7,270	6,700	6,920	7,460	7,390	6,080
0,020	0,040	0,010	0,030	0,010	0,040	0,040	0,020
102,180	100,580	101,600	102,350	102,960	103,040	104,000	
85,170	83,790	84,010	85,690	86,080	83,000	83,000	
11,090	11,290	11,480	11,220	11,380	11,340	11,030	
1,534	1,487	1,532	1,485	1,483	1,767	1,904	
529,800	530,000	528,000	528,000	529,000	530,000	526,000	
24,000	23,000	20,000	22,990	24,500	21,000	20,000	
505,800	507,000	508,000	505,010	505,500	509,000	506,000	
81,000	86,000	95,000	94,000	83,000	81,000	86,000	
61,000	59,000	55,000	57,000	54,000	59,000	65,000	
20,000	27,000	40,000	37,000	29,000	22,000	21,000	
701,000	714,000	692,000	700,000	707,000	705,000	697,000	
372,000	370,000	370,000	369,000	365,000	377,000	373,000	
5,390	5,420	5,550	5,500	5,560	5,430	5,570	
20,390	19,870	20,480	20,340	20,370	20,420	20,080	
112,000	111,000	120,000	116,000	119,000	113,000	109,000	
6,120	6,200	7,730	7,930	7,720	6,130	7,830	
1,000	1,000	1,000	1,000	1,000	1,000	1,000	
0,998	0,992	0,994	0,992	0,991	0,993	0,995	
6,160	6,220	7,750	7,940	7,740	6,150	7,860	
0,040	0,020	0,020	0,010	0,020	0,020	0,030	

105,890	104,010	104,980	107,010	108,460	107,090	108,290	105,850
82,720	79,930	80,200	82,990	76,560	75,700	77,240	81,040
11,120	11,030	11,480	11,480	11,160	11,120	11,390	11,470
2,084	2,183	2,159	2,092	2,858	2,823	2,726	2,163
607,000	597,000	582,000	530,010	633,000	588,000	599,000	580,000
50,000	42,000	31,000	20,000	45,000	30,000	20,000	29,000
557,000	555,000	551,000	510,010	588,000	558,000	579,000	551,000
89,000	86,000	90,000	88,000	88,000	80,000	82,000	81,000
63,000	62,000	64,000	57,000	60,000	58,000	65,000	57,000
26,000	24,000	26,000	31,000	28,000	22,000	17,000	24,000
690,000	697,000	705,000	708,000	686,000	694,000	714,000	687,000
373,000	368,000	364,000	365,000	370,000	364,000	374,000	367,000
5,500	5,590	5,430	5,440	5,420	5,390	5,580	5,470
20,210	19,830	19,750	20,390	20,020	19,700	19,930	20,390
111,000	120,000	108,000	111,000	116,000	117,000	120,000	119,000
6,290	7,750	7,240	6,630	6,950	7,460	7,180	6,080
1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000
0,990	0,998	0,991	0,995	0,993	0,990	0,990	0,997
6,330	7,760	7,260	6,670	6,990	7,500	7,200	6,100
0,040	0,010	0,020	0,040	0,040	0,040	0,020	0,020
108,150	106,390	104,010	108,100	107,840	104,770	109,520	
79,460	82,380	82,770	81,960	75,180	82,690	78,550	
11,040	11,390	11,150	11,400	11,220	11,480	11,030	
2,599	2,108	1,905	2,293	2,911	1,923	2,808	
603,000	602,000	566,000	538,010	530,010	589,000	549,000	
38,000	50,000	35,000	33,000	20,000	38,000	21,000	
565,000	552,000	531,000	505,010	510,010	551,000	528,000	
83,000	95,000	91,000	93,000	86,000	84,000	94,000	
65,000	62,000	61,000	63,000	64,000	65,000	62,000	
18,000	33,000	30,000	30,000	22,000	19,000	32,000	
694,000	692,000	705,000	705,000	712,000	708,000	696,000	
363,000	368,000	369,000	368,000	377,000	375,000	372,000	
5,590	5,460	5,530	5,400	5,610	5,590	5,410	
20,440	19,770	20,460	20,500	20,260	20,000	20,320	
119,000	120,000	108,000	116,000	112,000	116,000	117,000	
6,170	6,260	7,750	6,950	7,660	6,150	7,800	
1,000	1,000	1,000	1,000	1,000	1,000	1,000	
0,997	0,993	0,998	0,995	0,992	0,994	0,999	
6,210	6,300	7,760	6,960	7,700	6,170	7,830	
0,040	0,040	0,010	0,010	0,040	0,020	0,030	

APÊNDICE D

ALGORITMO DA RNA DESENVOLVIDA

```

% Resolução de um problema de Classificação de Falhas por uma Rede Neural
% Artificial (RNA) FeedForward para Reconhecimento de Padrões.
%
% Este algoritmo assume que as seguintes variáveis estão definidas:
%
% dieselInputs = Dados de Entrada.
% dieselTargets = Dados de Saída (Valores Esperados).
%
inputs = DiagDieselInputs;
targets = DiagDieselTargets;
%
% Criação da Rede de Reconhecimento de
Padrão. hiddenLayerSize = 55;
net = patternnet(hiddenLayerSize);
%
% Seleção das funções de Transferência.
% Para listar todas as funções de Transferência digite: help nntransf.
net.layers{1}.transferFcn = 'satlins'; % Transferência linear de saturação
simétrica. net.layers{2}.transferFcn = 'purelin'; % Transferência linear.
%
% Seleção da função de Aprendizagem de Pesos e Bias.
% Para listar todas as funções de Aprendizagem digite: help nnlearn.
net.inputWeights{1,1}.learnFcn = 'learngd'; % Gradiente
descendente. net.layerWeights{1,1}.learnFcn = 'learngd'; %
Gradiente descendente. net.biases{1}.learnFcn = 'learngd'; %
Gradiente descendente.
%
% Seleção das funções de pré/pós-processamento dos dados
% de entrada e de saída.
% Para listar todas as funções de processamento digite: help
nnprocess. net.inputs{1}.processFcns =
{'removeconstantrows','mapminmax'}; net.outputs{2}.processFcns =
{'removeconstantrows','mapminmax'};
%
% Estabelecimento da divisão de dados para Treinamento, Validação e Teste.
% Para listar todas as funções de divisão de dados digite: help nndivision.
net.divideFcn = 'dividerand'; % Divide os valores desejados em 3 subconjuntos
usando net.divideMode = 'sample'; % Define o tamanho das amostras de dados
esperados que serão divididos quando a função divisão de dados for chamada.

net.divideParam.trainRatio = 80/100;

```

```

net.divideParam.valRatio = 5/100;
net.divideParam.testRatio = 15/100;
%
net.trainParam.epochs = 1000;% Número de épocas
net.trainParam.show = 15; % Visualização durante o
treinamento net.trainParam.goal = 1e-4;% Meta
%
% Seleção da função de Treinamento.
% Para listar todas as funções de Treinamento digite: help nntrain.
net.trainFcn = 'trainlm'; % Backpropagation Levenberg-
marquardt.
%
% Seleção da função de Desempenho.
% Para listar todas as funções de Desempenho digite: help
nnperformance. net.performFcn = 'mse'; % Erro Médio quadrático.
%
% Seleção das funções de Gráficos.
% Para listar todas as funções de Gráficos digite: help nnplot.
net.plotFcns = {'ploterrhist','plotperform','plotfit','plotroc'};
%
% Treinamento da Rede.
[net,tr] = train(net,inputs,targets);
%
% Teste da Rede.
outputs = net(inputs);
errors = gsubtract(targets,outputs);
performance = perform(net,targets,outputs);
%
% Reavaliação do Desempenho do Treinamento, Validação e Teste.
trainTargets = targets .* tr.trainMask{1};
valTargets = targets .* tr.valMask{1}; testTargets =
targets .* tr.testMask{1}; trainPerformance =
perform(net,trainTargets,outputs); valPerformance =
perform(net,valTargets,outputs); testPerformance =
perform(net,testTargets,outputs);
%
% Visualização da Rede.
view(net)
%
% Gráficos.
% Retire o símbolo (%) para habilitar a visualização dos vários gráficos.
figure, plotconfusion(trainTargets,outputs,'Training')
plottools('on')
figure, plotconfusion(valTargets,outputs,'Validation')
plottools('on')
figure, plotconfusion(testTargets,outputs,'Test')
plottools('on')
figure, plotconfusion(targets,outputs,'All')

```

```
plottools('on')  
figure, plotperform(tr)  
plottools('on')
```