

**UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO
PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA**

Antonio Luiz Schalata Pacheco

**DESENVOLVIMENTO DE SISTEMAS NEURAIIS ARTIFICIAIS
APLICADOS AO CONTROLE DE QUALIDADE DE
COMPRESSORES EM LINHA DE PRODUÇÃO**

Tese submetida ao Programa de Pós-Graduação em Engenharia Mecânica da Universidade Federal de Santa Catarina para a obtenção do Grau de Doutor em Engenharia Mecânica.

Orientador: Prof. Carlos Alberto Flesch, Dr. Eng.

Coorientador: Cesar Alberto Penz, Dr. Eng.

Florianópolis
2015

Ficha de identificação da obra elaborada pelo autor,
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Pacheco, Antonio Luiz Schalata

Desenvolvimento de sistemas neurais artificiais aplicados ao controle de qualidade de compressores em linha de produção / Antonio Luiz Schalata Pacheco; orientador, Carlos Alberto Flesch; coorientador, Cesar Alberto Penz. - Florianópolis, SC, 2015.

228 p.

Tese (doutorado) - Universidade Federal de Santa Catarina, Centro Tecnológico. Programa de Pós-Graduação em Engenharia Mecânica.

Inclui referências

1. Engenharia Mecânica. 2. Compressores - ensaios de desempenho e de mínima tensão de partida. 3. Teste de capacidade de elevação de pressão. 4. Redes neurais artificiais. 5. Avaliação de incertezas em inferências. I. Flesch, Carlos Alberto. II. Penz, Cesar Alberto. III. Universidade Federal de Santa Catarina. Programa de Pós-Graduação em Engenharia Mecânica. IV. Título.

Antonio Luiz Schalata Pacheco

**DESENVOLVIMENTO DE SISTEMAS NEURAIIS ARTIFICIAIS
APLICADOS AO CONTROLE DE QUALIDADE DE
COMPRESSORES EM LINHA DE PRODUÇÃO**

Esta Tese foi julgada adequada para obtenção do Título de “Doutor em Engenharia Mecânica” e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia Mecânica.

Florianópolis, 14 de setembro de 2015.

Prof. Armando Albertazzi Gonçalves Jr., Dr. Eng.
Coordenador do Programa de Pós-Graduação em Engenharia Mecânica

Prof. Carlos Alberto Flesch, Dr. Eng. (Orientador)
Universidade Federal de Santa Catarina

Cesar Alberto Penz, Dr. Eng. (Coorientador)
Universidade Federal de Santa Catarina

Banca Examinadora:

Prof. Carlos Alberto Flesch, Dr. Eng. (Presidente)
Universidade Federal de Santa Catarina

Prof. Herman Augusto Lepikson, Dr. Eng. (Relator)
Universidade Federal da Bahia

Prof. Marco Aurélio de Oliveira, Dr. Eng.
Sociedade Educacional de Santa Catarina

Prof. Arnaldo José Perin, Dr. Ing.
Universidade Federal de Santa Catarina

Prof. Marco Antonio Martins Cavaco, Ph. D.
Universidade Federal de Santa Catarina

Prof.^a Silvia Modesto Nassar, Dr. Eng.
Universidade Federal de Santa Catarina

Ofereço este trabalho a Deus;
aos meus pais, Antônio e Luiza; à minha esposa Dirivete;
aos meus filhos, Antonio Luiz, Alice e Luiz Felipe;
e aos meus irmãos, Ezequiel Felipe, Luiz Antonio e Maria Luiza.
Sem eles, o brilho de qualquer conquista estaria ofuscado.
Dedico, também, à memória de três grandes incentivadores,
Ezequiel Pacheco de Souza, Felipe Schlata e William Glenn Whitley.

AGRADECIMENTOS

Aos meus pais, Antônio e Luiza, meus primeiros mestres e maiores incentivadores. Amigos incondicionais e eternos nos quais espelhei a construção do meu caráter e minha conduta.

À minha esposa, Dirivete, pela amizade, carinho, dedicação e por compartilhar do apreço pela educação. Ao lado de todo homem que se aventura crescer, tem que existir uma grande mulher.

Aos meus filhos, Antonio Luiz, Alice e Luiz Felipe. Espero ter sido um exemplo de determinação para poder, futuramente, ser perdoado pelos momentos que não pude estar junto deles. Ao primeiro, agradecimento especial pelo auxílio com parcela considerável das figuras.

Ao meu orientador, Carlos Alberto Flesch, pelo companheirismo, profissionalismo e pela confiança com que me agregou ao seu grupo de trabalho. A liberdade com que permitiu conduzir minhas atividades sempre foi fundamental para meu crescimento profissional.

Ao meu coorientador, Cesar Alberto Penz, pela amizade, pelas discussões intermináveis e, sobretudo, pela postura crítica inabalável.

Aos membros do grupo de trabalho, Julio, Miguel, Rodolfo e Rodrigo, pela amizade, pelas conversas e práticas enriquecedoras, e por vários outros motivos inarráveis. Obrigado, também, a todos os alunos que fazem jus às oportunidades concedidas, pelo agradável convívio.

Ao PosMEC e Labmetro, por abrirem suas portas aos acadêmicos de outras áreas e pelo comprometimento de seus docentes, em especial ao Armando, e pela competência dos profissionais de suas secretarias, Maria Goreti, Marieta e Rosana.

Aos integrantes da banca, Arnaldo, Herman, Marco Antônio, Marco Aurélio e Silvia, pela disponibilidade, revisão esmerada deste trabalho e responsabilidade com que conduziram suas sugestões.

À Whirlpool – unidade Embraco – pela parceria; em especial ao Cláudio, Deandro, Felipe e Maykon, pelo profissionalismo com que a conduzem. Obrigado, ainda, aos especialistas das diversas áreas consultadas, pelo atendimento e transparência das informações.

Ao pessoal do Inep, professores, alunos e servidores, especialmente ao Luiz Marcellus, pelo incentivo e companheirismo nesses longos anos.

À Secretaria de Educação do Estado de Santa Catarina, pela bolsa concedida por meio do programa FUMDES, e ao CNPq, pelo suporte financeiro em outra etapa do projeto.

RESUMO

Dois mecanismos importantes para controle da qualidade de produção de compressores herméticos para refrigeração são os ensaios de desempenho e de mínima tensão de partida. Por demandarem muito tempo, ambos são restritos a laboratórios, não sendo viável aplicação direta em linhas de produção. Ensaios de desempenho requerem mais de 4 horas para serem realizados e de partida necessitam de tempos médios de 50 minutos. Devido ao tempo e custos envolvidos, a avaliação de todo um lote produzido é tipicamente realizada por meio dos ensaios de uma pequena amostra, em condições laboratoriais. O controle da qualidade de cada peça é restrito aos testes compatíveis com o tempo de ciclo da linha de produção. A empresa líder mundial na produção de compressores avalia a capacidade de cada unidade produzida em elevar a pressão de ar interna de um volume de valor conhecido, em testes que demandam menos de 7 s. Em estudo de caso, constatou-se a hipótese que desses testes de linha resultam parâmetros correlacionados aos obtidos nos ensaios de desempenho e de partida. Os níveis de correlação permitiram a realização de inferência dos parâmetros de laboratório a partir dos dados de linha de produção, o que se conseguiu com uso de ferramentas baseadas em redes neurais artificiais. Parcela significativa dos resultados das inferências distou menos de 1% dos valores fornecidos pelos ensaios de laboratório. A garantia da confiabilidade é um dos entraves mais expressivos para o emprego de redes neurais em atividades metrológicas. A avaliação de incerteza calcada nos preceitos metrológicos vigentes deve levar em conta as contribuições das incertezas de medição das variáveis de entrada e das incertezas do processo de treinamento. Com esse intuito, aperfeiçoou-se técnica disponibilizada em publicações recentes, que combina a reamostragem *bootstrap*, tipicamente utilizada para fornecer intervalos de confiança em redes neurais, com o método de Monte Carlo, frequentemente empregado na avaliação da incerteza de medição. A integração desses métodos representa evolução no estado da arte, por consubstanciar-se em abordagem adequada à avaliação da incerteza da saída de ferramentas baseada em redes neurais, conferindo confiabilidade às inferências obtidas em estudo de caso. Os níveis de incerteza estimados resultaram compatíveis com a incerteza de medição das grandezas envolvidas, em todas as frentes investigadas. As ferramentas propostas se mostraram adequáveis à rotina da linha de produção. O tempo médio para obtenção de cada resultado ficou próximo a 7 s, possibilitando que parâmetros típicos de ensaios de desempenho e de mínima tensão de partida possam ser obtidos para 100% dos compressores produzidos.

Palavras-chave: ensaios de desempenho de compressores; ensaios de mínima tensão de partida de motores; teste de capacidade de elevação de pressão; redes neurais artificiais; avaliação de incertezas em inferências.

ABSTRACT

Two important ways to control the production quality of hermetic refrigeration compressors are the performance test and the minimum starting voltage test. Both tests demand too much time, and, therefore, they are restricted to laboratories and not feasible to be applied directly on production lines. Performance tests require longer than four hours to be carried out and starting voltage tests require an average of fifty minutes. Due to the time and cost involved in the evaluation of a whole production batch, typically, a small sample of the production batch is tested under laboratory conditions. The quality control of each piece is restricted to tests which durations are suitable to the production line time cycle. The hermetic compressor world leader company evaluates the capacity of each unit to increase the air pressure in a fixed volume vessel, these tests demand less than seven seconds. Study cases generated the hypothesis that production line tests have parameters that are correlated with those obtained in laboratory performance and minimum starting voltage tests. The correlation levels allowed the inference of laboratory parameters using data from the production line, what has been achieved with tools based on artificial neural networks. A significant portion of the inferences presented errors of less than 1% when compared with laboratory tests. The reliability assurance is one of the most significant barriers when artificial neural networks are used in metrological activities. The uncertainty evaluation based on the current metrological precepts should consider the contributions of the measurement uncertainties related to input variables and to the training process. Therefore, a technique presented in recent publications was improved; such technique combined the bootstrap resampling approach, typically used to provide confidence intervals on neural networks, with the Monte Carlo method, often used in the evaluation of measurement uncertainty. The proposed improvement represents the state of the art since it consolidated the uncertainty evaluation of artificial neural network results obtained on the study cases, ensuring reliability to the inferences. The estimated uncertainty levels shown compatible results compared with the measurement uncertainty related to all investigated quantities. The proposed tools proved to be suitable for the production line. The average time to obtain each result was about seven seconds, allowing the performance test parameters and minimum starting voltage to be obtained for all the produced compressors.

Keywords: performance testing of compressors; minimum starting voltage tests for induction motors; pressure increase capacity test; artificial neural networks; evaluation of uncertainties in inferences.

LISTA DE TABELAS

Tabela 1 – Consumo final de energia elétrica na carga residencial.....	41
Tabela 2 – Panoramas de incerteza de medição.....	45
Tabela 3 – Combinação de métodos permitidos pela norma <i>ISO 917</i>	55
Tabela 4 – Limites máximos de variação estabelecidos pela norma <i>ISO 917</i>	60
Tabela 5 – Limites máximos de variação estabelecidos por especialistas.....	60
Tabela 6 – Funções de ativação totalmente diferenciáveis.....	74
Tabela 7 – Fontes de erros que podem ser significativas no treinamento e uso de RNA.....	95
Tabela 8 – Erros considerados pelo método <i>ensemble</i> gerado pelo <i>bagging</i>	100
Tabela 9 – Erros considerados na avaliação das incertezas pelo <i>Guia</i>	106
Tabela 10 – Erros considerados pelo método MMC- <i>bagging</i> hibridizado.....	111
Tabela 11 – Valor médio de resultados do teste de capacidade no lote 70B-03.....	122
Tabela 12 – Quantidade de resultados disponíveis por parâmetro, modelo de compressor e estação de teste de capacidade de elevação.....	124
Tabela 13 – Correlações lineares para o agrupamento R134a/ 60 Hz para dados tomados com temperatura de carcaça superior aos 37 °C.....	128
Tabela 14 – Correlações lineares para o agrupamento 100-R134-60-R para dados tomados com temperatura de carcaça superior aos 37 °C.....	130
Tabela 15 – Incertezas para <i>COP</i> , consumo linha e capacidade de elevação.....	130
Tabela 16 – Correlações lineares para o agrupamento 115-127 V para dados tomados com temperatura de carcaça maiores que 37 °C.....	135
Tabela 17 – Resultados de testes de capacidade de elevação realizados durante intervalo de resfriamento de cinco peças do modelo 100B.....	142
Tabela 18 – Estrutura das redes <i>MLP</i> empregadas.....	153

Tabela 19 – Quantidade de resultados disponíveis por parâmetro e modelo de compressor	155
Tabela 20 – Valores de laboratório para elementos dos conjuntos de testes	160
Tabela 21 – Comparação dos resultados das inferências para <i>COP</i> com valores dados em laboratório	163
Tabela 22 – Comparação dos resultados das inferências para consumo com valores dados em laboratório	174
Tabela 23 – Comparação dos resultados das inferências para MTP com valores dados em laboratório	179
Tabela 24 – Características do compressor de modelo 70A	207
Tabela 25 – Características do compressor de modelo 70B	207
Tabela 26 – Características do compressor de modelo 70C	207
Tabela 27 – Características do compressor de modelo 70D	208
Tabela 28 – Características do compressor de modelo 80A	208
Tabela 29 – Características do compressor de modelo 80B	208
Tabela 30 – Características do compressor de modelo 80C	208
Tabela 31 – Características do compressor de modelo 80D	209
Tabela 32 – Características do compressor de modelo 80E	209
Tabela 33 – Características do compressor de modelo 80F	209
Tabela 34 – Características do compressor de modelo 80G	209
Tabela 35 – Características do compressor de modelo 90A	210
Tabela 36 – Características do compressor de modelo 100A	210
Tabela 37 – Características do compressor de modelo 100B	210
Tabela 38 – Características do compressor de modelo 100C	210
Tabela 39 – Correlações lineares para os agrupamentos R600a/ 60 Hz e R134a/ 50 Hz para dados tomados com temperatura de carcaça superior aos 37 °C	214
Tabela 40 – Correlações lineares entre <i>COP-Col</i> e <i>COP-Cel</i> para dados tomados com temperatura de carcaça superior aos 37 °C	218

LISTA DE FIGURAS

Figura 1 – Circuito de refrigeração para o método A.....	56
Figura 2 – Diagrama simplificado do calorímetro de fluido secundário.....	57
Figura 3 – Medição de fluxo de massa na linha de sucção do compressor.....	58
Figura 4 – Diagrama simplificado de bancada de ensaio de desempenho.....	59
Figura 5 – Diagrama esquemático da bancada de partida e tombamento disponível do Labmetro.....	68
Figura 6 – Neurônio biológico (a) e neurônio de McCulloch e Pitts (b).....	73
Figura 7 – Diagrama em blocos da aprendizagem supervisionada.....	76
Figura 8 – Diagrama em blocos da aprendizagem não supervisionada.....	76
Figura 9 – Rede <i>perceptron</i> multicamadas <i>m-n-o</i>	79
Figura 10 – Convergência e divergência do algoritmo de retropropagação.....	81
Figura 11 – Projeções da função $z(x, y)$	86
Figura 12 – Mapa topológico (a) unidimensional e (b) bidimensional.....	87
Figura 13 – Erro de otimização (a) e erro por incompletude do conjunto de treinamento (b).....	93
Figura 14 – <i>Ensemble</i> baseado em média aritmética simples.....	97
Figura 15 – Aplicação da técnica <i>bagging</i> ao treinamento supervisionado de elementos de um <i>ensemble</i>	99
Figura 16 – Rede <i>MLP</i> 2-2-1.....	103
Figura 17 – Aplicação do método de Monte Carlo para propagar as <i>PDF</i> através de uma rede neural.....	105
Figura 18 – Etapa de treinamento do primeiro elemento do selecionado proposto no <i>MMC-bagging</i>	109
Figura 19 – Etapa de uso do método <i>MMC-bagging</i> hibridizado.....	110
Figura 20 – Comportamento da capacidade de refrigeração nas bancadas de desempenho de compressores.....	114
Figura 21 – Perfil típico de pressões de descarga para os ciclos do painel de teste de capacidade de elevação.....	117
Figura 22 – Compressor sob teste de capacidade de elevação de pressão.....	117
Figura 23 – Curvas de pressão e consumo linha sobre o compressor em teste.....	118

Figura 24 – Influência da temperatura no consumo linha – compressor modelo 100B	120
Figura 25 – Influência da temperatura na capacidade de elevação de pressão – compressor modelo 100B	120
Figura 26 – Valores de temperatura da carcaça obtidos nas estações A e B para o lote 70B-03	122
Figura 27 – Consumo (C_o) <i>versus</i> Capacidade de elevação de pressão (C_{el}) para todos os casos disponíveis	127
Figura 28 – COP <i>versus</i> Consumo linha (C_{ol}) para todos os dados disponíveis	129
Figura 29 – Efeito das incertezas de obtenção do consumo linha e COP	131
Figura 30 – Simulação de correlação entre COP e consumo linha frente aos efeitos de 10% (a) e 100% (b) das incertezas características - grupo 7-R1-6-P	132
Figura 31 – COP <i>versus</i> Consumo linha (C_{ol}) para os agrupamentos 8-R6-6-P e 10-R1-6-R	133
Figura 32 – Mínima tensão de partida <i>versus</i> Consumo linha	134
Figura 33 – Comparação dos valores de MTP para ensaios de partida equalizada dos modelos 70B e 80E com diferentes níveis de pressão	136
Figura 34 – Problema de caracterização da função consumo em domínio dado por consumo linha e capacidade de elevação de pressão – grupo R600a/ 60 Hz	138
Figura 35 – Domínio definido pelas variáveis C_{el} , C_{ol} e Mod	139
Figura 36 – Matriz de acumulação do mapa de Kohonen 12x12	140
Figura 37 – Estratégia para compensação indireta do efeito da temperatura – compressor 100B-1	143
Figura 38 – Simulação com dados hipotéticos e modelo irreal altamente linearizado do COP	144
Figura 39 – Inferências de COP considerando 100% da IM de laboratório e 1% das IM das variáveis de linha	146
Figura 40 – Inferência de COP considerando 100% da IM de laboratório e 100% das IM das variáveis de linha	147
Figura 41 – Região R decorrente da SMCt para o ponto (2100, 105) do domínio da função modelada	147
Figura 42 – Restrições para formação dos conjuntos de treinamento e testes	157
Figura 43 – Domínios de ativação para a função tangente hiperbólica $\varphi(u)$	158

Figura 44 – Inferências de <i>COP</i> para peças dos modelos 70A, 70B, 70C, 70D, 80A, 80B, 80C e 80D – 1000 RNA e 1000 SMCu.....	164
Figura 45 – Inferências de <i>COP</i> para peças dos modelos 80E, 80F, 80G, 100A, 100B e 100C – 1000 RNA e 1000 SMCu.....	165
Figura 46 – Influência do número de redes do <i>ensemble</i> na Inf do <i>COP</i> e no tempo de processamento dos dados considerando 1000 SMCu.....	166
Figura 47 – Influência do número de SMCu na Inf do <i>COP</i> e no tempo de processamento dos dados considerando 350 RNA.....	167
Figura 48 – Comparação entre diferentes configurações para inferências de <i>COP</i> - modelos 70A, 70B, 70C, 70D, 80A, 80B, 80C e 80D.....	168
Figura 49 – Comparação entre diferentes configurações para inferências de <i>COP</i> - modelos 80E, 80F, 80G, 100A, 100B e 100C.....	168
Figura 50 – Equivalência entre domínio de operação e domínio de definição das redes <i>MLP</i> (lote 100B-1 – estação A).....	169
Figura 51 – Inferência dos valores de <i>COP</i> para compressores do lote 100B-1 (estação A).....	170
Figura 52 – Inferência dos valores de <i>COP</i> para compressores do lote 100B-1 (estação A).....	171
Figura 53 – Inferência dos valores de <i>COP</i> para lote de 6328 peças do modelo 70A.....	172
Figura 54 – Inferência dos valores de <i>COP</i> para lote de 1416 peças do modelo 80B.....	173
Figura 55 – Inferência dos valores de <i>COP</i> para lote de 1380 peças do modelo 100A.....	173
Figura 56 – Inferências de consumo para peças dos modelos 70A, 70B, 70C, 70D, 80A, 80B, 80C e 80D.....	176
Figura 57 – Inferências de consumo para peças dos modelos 80E, 80F, 80G, 100A, 100B e 100C.....	176
Figura 58 – Inferência dos valores de consumo para lote de 768 peças do modelo 70C.....	177
Figura 59 – Inferência dos valores de consumo para lote de 1416 peças do modelo 80B.....	178
Figura 60 – Inferência dos valores de consumo para lote de 1380 peças do modelo 100A.....	178

Figura 61 – Inferências de MTP para peças dos modelos 70A, 70B, 70C, 70D, 80A, 80C, 80D, 80E, 80F, 100A, 100B e 100C.....	180
Figura 62 – Inferência dos valores de MTP para lote de 4147 peças do modelo 70A.....	181
Figura 63 – Inferência dos valores de MTP para lote de 1416 peças do modelo 80B.....	181
Figura 64 – Inferência dos valores de MTP para lote de 1380 peças do modelo 100A.....	182
Figura 65 – Influência da temperatura no consumo linha e capacidade de elevação de pressão - compressores de modelo 70B, 80B e 100A.....	211
Figura 66 – Valores de temperatura da carcaça obtidos nas estações A e B para o lote 70D-04.....	212
Figura 67 – Valores de temperatura da carcaça obtidos nas estações A e B para o lote 80C-02.....	212
Figura 68 – Diagramas de dispersão do consumo <i>versus</i> resultados dos testes de linha de produção – avaliação global das informações.....	213
Figura 69 – Diagramas de dispersão do consumo <i>versus</i> resultados dos testes de linha de produção – avaliação do agrupamento dado por refrigerante R134a e frequência de 60 Hz com temperatura de carcaça menor que 37 °C.....	214
Figura 70 – Diagramas de dispersão do <i>COP versus</i> resultados dos testes de linha de produção – avaliação global das informações.....	217
Figura 71 – Simulação de correlação entre <i>COP</i> e consumo linha frente aos efeitos de 10% (a) e 100% das incertezas características – grupo 8-R1-6-P.....	218
Figura 72 – Diagramas de dispersão do MTP <i>versus</i> resultados dos testes de linha de produção – avaliação global das informações.....	221
Figura 73 – Histogramas de frequência da propagação de 1000 SMCu sobre 50 (a), 200 (b), 350 (c), 500 (d), 750 (e) e 1000 (f) RNA.....	225
Figura 74 – Dados disponíveis para o modelo 70A.....	227

LISTA DE ABREVIATURAS E SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
ARLM	Análise de Regressão Linear Múltipla
ART	Adaptive Resonance Theory
ASHRAE	<i>American Society of Heating, Refrigerating and Air-Conditioning Engineers</i>
<i>Bagging</i>	<i>Bootstrap aggregating</i>
Cel	Capacidade de elevação de pressão
Co	Consumo – potência elétrica consumida obtida em ensaio de desempenho
Col	Consumo linha – potência elétrica consumida obtida em teste de capacidade de elevação de pressão
<i>COP</i>	<i>Coefficient of Performance</i>
<i>CSIR</i>	<i>Capacitive Start – Inductive Run</i>
<i>DIN</i>	<i>Deutsches Institut für Normung</i>
EDES	Amostra para Ensaio de Desempenho
EInf	<i>Ensemble de Inferência</i>
EIIInf	<i>Ensemble de Incerteza da Inferência</i>
EMTP	Amostra para Ensaio de Mínima Tensão de Partida
<i>GUM</i>	<i>Guide to the Expression of Uncertainty in Measurement</i>
IA	Inteligência Artificial
IBGE	Instituto Brasileiro de Geografia e Estatística
<i>IEA</i>	<i>International Energy Agency</i>
IC	Intervalo de Confiança
IInf	Incerteza da Inferência
IM	Incerteza de Medição
INMETRO	Instituto Nacional de Metrologia
<i>ISO</i>	<i>International Organization for Standardization</i>
<i>JCGM</i>	<i>Joint Committee for Guides in Metrology</i>
Labmetro	Laboratório de Metrologia e Automatização
LM	Levenberg-Marquardt
<i>LST</i>	<i>Low Starting Torque</i>
MFC	Montagem Final de Compressores
<i>MLP</i>	<i>Multilayer Perceptron</i>
MMC	Método de Monte Carlo
Mod	Modelo do compressor
MTP	Mínima Tensão de Partida
<i>nctool</i>	<i>Neural Network Clustering Tool</i>
<i>nntool</i>	<i>Neural Network Toolbox</i>

P	Potência consumida
<i>PDF</i>	<i>Probability Density Function</i>
PMC	Pré-Montagem de Compressores
Procel	Programa Nacional de Conservação de Energia Elétrica
<i>RAM</i>	<i>Random Access Memory</i>
<i>RBF</i>	<i>Radial Basis Function</i>
Rf	Ruído de Funcionamento
RNA	Rede Neural Artificial
Rp	Ruído de Parada
<i>RSCR</i>	<i>Resistive Start – Capacitive Run</i>
<i>RSIR</i>	<i>Resistive Start – Inductive Run</i>
SI	Sistema Internacional de Unidades
SICC	Sistema de Injeção de Corrente Contínua
SMC	Simulação de Monte Carlo
SMCt	Simulação de Monte Carlo para conjunto de treinamento
SMCu	Simulação de Monte Carlo para dados de uso de RNA
<i>SOM</i>	<i>Self-Organizing Map</i>
Ter	Temperatura da carcaça
UFSC	Universidade Federal de Santa Catarina

LISTA DE SÍMBOLOS

\mathbf{b}	vetor de bias
c	calor específico do fluido de trabalho
d	distância lateral entre neurônios do mapa de Kohonen
\mathbf{d}	vetores de saída da amostra
f	função que descreve mapeamento não linear
\mathcal{f}	função que aproxima mapeamento não linear
F	função vetorial realizada pela rede <i>MLP</i>
F_l	fator de perda
G	função vetorial da camada de saída da rede <i>MLP</i>
h	função da vizinhança topológica
h_{f1}	entalpia específica do refrigerante líquido na pressão correspondente à descarga do compressor
h_{f2}	entalpia do líquido entrando no calorímetro
h_{g1}	entalpia específica do refrigerante entrando no compressor nas condições básicas específicas de ensaio
h_{g2}	entalpia do gás saturado saindo do calorímetro
i	neurônio vencedor em processo competitivo
I	corrente elétrica
\mathbf{I}	matriz identidade
\mathbf{J}	matriz Jacobiana
l	quantidade de neurônios do mapa de Kohonen
q_{mf}	fluxo de massa de refrigerante
q_{ml}	vazão mássica do fluido
m	termo de <i>momentum</i>
N	tamanho da amostra
r	coeficiente linear de Pearson da amostra
R^2	coeficiente de determinação
s	desvio padrão da amostra
t_{n-1}	coeficiente <i>t</i> -student para $n-1$ graus de liberdade
T_1	temperatura ambiente
T_2	temperatura interna ao calorímetro
T_a	temperatura ambiente
T_g	temperatura interna ao calorímetro
\mathcal{J}	conjunto de amostras
U	incerteza expandida (do inglês <i>expanded uncertainty</i>)
V_{ga}	volume específico do fluido refrigerante (gás) entrando no compressor, durante o ensaio de desempenho

V_{gl}	volume específico do refrigerante entrando no compressor estabelecido anteriormente ao ensaio de desempenho
x	vetores de entrada da amostra
W	matriz de pesos sinápticos
z	valor da distribuição normal padrão
z	vetor de réplicas <i>bootstrap</i>
α	nível de confiança
β	coeficiente de regressão
γ	parâmetro real que define o centro da função gaussiana
ε	número real muito pequeno
ε	vetor de erro do mapeamento não linear
η	parâmetro da taxa de aprendizagem
λ	peso da camada de saída da rede <i>MLP</i>
μ	coeficiente de combinação
ξ	descreve os possíveis valores da variável aleatória x
ρ	coeficiente linear de Pearson da população
θ	vetor de parâmetros livres da rede <i>MLP</i>
σ	parâmetro real que denota a largura da função gaussiana
Σ	combinador linear
φ	função de ativação de neurônio da rede <i>MLP</i>
Φ	transformação não linear
ϕ_0	capacidade de refrigeração do compressor
ϕ_h	calor cedido pelo fluido de trabalho
ϕ_i	calor cedido pela fonte externa
ζ	parâmetro real associado ao nível de inclinação das funções logística e tangente hiperbólica
∇e	gradiente da função erro

SUMÁRIO

1.	INTRODUÇÃO	41
1.1.	CONTEXTUALIZAÇÃO	41
1.2.	OBJETIVOS	48
1.2.1.	Objetivo geral da tese	48
1.2.2.	Objetivos específicos da tese	49
1.3.	INOVAÇÕES CONCRETIZADAS	49
1.4.	ESTRUTURA DO DOCUMENTO	50
2.	ENSAIOS PARA CONTROLE DA QUALIDADE DE COMPRESSORES HERMÉTICOS	51
2.1.	INTRODUÇÃO	51
2.2.	ENSAIO DE DESEMPENHO DE COMPRESSORES	52
2.2.1.	Métodos de ensaios segundo a norma <i>ISO 917</i>	54
2.2.2.	Bancada de ensaios de desempenho de compressores	59
2.2.3.	Uso dos parâmetros de ensaio de desempenho no controle da qualidade da produção de compressores herméticos	62
2.2.4.	Modelo de previsão da capacidade de refrigeração	63
2.3.	ENSAIOS DE MÍNIMA TENSÃO DE PARTIDA	63
2.3.1.	Método para ensaio de mínima tensão de partida	64
2.3.2.	Bancada para ensaio de mínima tensão de partida	66
2.3.3.	Uso da mínima tensão de partida no controle da qualidade da produção de compressores herméticos	68
2.4.	CONSIDERAÇÕES	69
3.	REDES NEURAIS ARTIFICIAIS PARA APROXIMAÇÃO DE FUNÇÕES NÃO LINEARES	71
3.1.	INTRODUÇÃO	71
3.2.	REDES NEURAIS ARTIFICIAIS	72
3.2.1.	Modelo matemático do neurônio biológico	72
3.2.2.	Processos de aprendizagem	75
3.2.3.	Arquiteturas de redes neurais	77
3.3.	REDES <i>PERCEPTRON</i> MULTICAMADAS	79
3.3.1.	Algoritmo de retropropagação de erro	80
3.3.2.	Algoritmo de Levenberg-Marquardt	82
3.4.	CAPACIDADE DE GENERALIZAÇÃO	83

3.5.	REDES <i>MLP</i> E A TAREFA DA APROXIMAÇÃO DE FUNÇÕES NÃO LINEARES	85
3.6.	REDES AUTO-ORGANIZÁVEIS DE KOHONEN	87
3.7.	CONSIDERAÇÕES	89
4.	INCERTEZA DA INFERÊNCIA EM MODELOS NEURAIIS	91
4.1.	INTRODUÇÃO	91
4.2.	CONFIABILIDADE DE REDES NEURAIIS ARTIFICIAIS	92
4.3.	ABORDAGEM POR MÚLTIPLAS REDES	95
4.3.1.	<i>Ensemble</i> - compensação parcial de erros aleatórios	96
4.3.2.	<i>Bootstrap</i> - representação da incerteza do processo de aprendizagem	98
4.4.	AVALIAÇÃO DAS INCERTEZAS PELO <i>GUIA</i>	101
4.4.1.	Método clássico ou de propagação de incertezas	101
4.4.2.	Método de Monte Carlo ou de propagação de distribuições	104
4.5.	MÉTODO MMC- <i>BAGGING</i> HIBRIDIZADO	106
4.6.	CONSIDERAÇÕES	111
5.	PROPOSTA DE FERRAMENTAS NEURAIIS PARA CONTROLE DA QUALIDADE DE COMPRESSORES	113
5.1.	INTRODUÇÃO	113
5.2.	TESTE DE CAPACIDADE DE ELEVAÇÃO DE PRESSÃO	115
5.3.	MEDIÇÃO DA TEMPERATURA DA CARÇAÇA	119
5.4.	ANÁLISE DAS RELAÇÕES ENTRE OS RESULTADOS DE TESTES DE LINHA E DE ENSAIOS DE LABORATÓRIO	123
5.4.1.	Caracterização do conjunto de informações disponíveis	123
5.4.2.	Ferramentas estatísticas para análise das informações	125
5.4.3.	Correlação linear entre consumo e dados de linha	126
5.4.4.	Correlação linear entre <i>COP</i> e dados de linha	128
5.4.5.	Correlação linear entre mínima tensão de partida e dados de linha	133
5.5.	DEFINIÇÃO DAS VARIÁVEIS INDEPENDENTES	136
5.5.1.	Definição da variável qualitativa	137
5.5.2.	Avaliação da separação das informações por modelo	139
5.6.	PROPOSTA DE FERRAMENTAS NEURAIIS APLICÁVEIS	141
5.6.1.	Compensação indireta dos efeitos da temperatura	141

5.6.2.	Aplicabilidade do método MMC- <i>bagging</i> hibridizado.....	143
5.6.3.	Caracterização das ferramentas neurais.....	148
5.7.	CONSIDERAÇÕES.....	149
6.	ESTUDOS DE CASO	151
6.1.	INTRODUÇÃO.....	151
6.2.	ASPECTOS DA IMPLEMENTAÇÃO DAS FERRAMENTAS NEURAIAS.....	152
6.2.1.	Características das redes <i>MLP</i> empregadas.....	153
6.2.2.	Caracterização dos dados de resfriamento.....	155
6.2.3.	Seleção dos conjuntos de treinamento e teste.....	156
6.2.4.	Pré-processamento dos dados.....	157
6.3.	RESULTADOS DOS ESTUDOS DE CASO.....	159
6.3.1.	<i>COP</i>	162
6.3.2.	Consumo.....	174
6.3.3.	Mínima tensão de partida.....	179
6.4.	CONSIDERAÇÕES.....	182
7.	CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS.....	185
7.1.	CONCLUSÕES.....	185
7.1.1.	Sobre a revisão bibliográfica.....	185
7.1.2.	Sobre a realização das inferências.....	186
7.1.3.	Sobre a avaliação da incerteza das inferências.....	187
7.1.4.	Sobre os resultados experimentais.....	187
7.1.5.	Sobre as inovações concretizadas.....	188
7.2.	SUGESTÕES PARA TRABALHOS FUTUROS.....	189
7.2.1.	Sobre o aperfeiçoamento do método.....	189
7.2.2.	Sobre a proposta de aplicação na pré-montagem de compressores.....	190
	REFERÊNCIAS	193
	APÊNDICE A	
	CARACTERIZAÇÃO DOS COMPRESSORES HERMÉTICOS DE REFRIGERAÇÃO EMPREGADOS.....	207

APÊNDICE B AVALIAÇÃO DA POTÊNCIA ELÉTRICA CONSUMIDA E CAPACIDADE DE ELEVAÇÃO DE PRESSÃO DURANTE O RESFRIAMENTO DE COMPRESSORES	211
---	------------

APÊNDICE C DIAGRAMAS DE DISPERSÃO DE CONSUMO <i>VERSUS</i> RESULTADOS DE TESTES DE LINHA DE PRODUÇÃO	213
---	------------

APÊNDICE D RESULTADO DA ANÁLISE DE REGRESSÃO DO CONSUMO <i>VERSUS</i> RESULTADOS DE TESTES DE LINHA DE PRODUÇÃO	215
--	------------

APÊNDICE E DIAGRAMAS DE DISPERSÃO DE <i>COP</i> <i>VERSUS</i> RESULTADOS DE TESTES DE LINHA DE PRODUÇÃO	217
--	------------

APÊNDICE F RESULTADO DA ANÁLISE DE REGRESSÃO DO <i>COP</i> <i>VERSUS</i> RESULTADOS DE TESTES DE LINHA DE PRODUÇÃO	219
---	------------

APÊNDICE G DIAGRAMAS DE DISPERSÃO DE MTP <i>VERSUS</i> RESULTADOS DE TESTES DE LINHA DE PRODUÇÃO	221
---	------------

APÊNDICE H RESULTADO DA ANÁLISE DE REGRESSÃO DA MTP <i>VERSUS</i> RESULTADOS DE TESTES DE LINHA DE PRODUÇÃO	223
--	------------

APÊNDICE I RESULTADOS DE DIFERENTES CONFIGURAÇÕES DE <i>ENSEMBLE</i> PARA INCERTEZA DA INFERÊNCIA DE <i>COP</i> ..	225
---	------------

APÊNDICE J INDICATIVO DE DIFERENÇA SISTEMÁTICA ENTRE RESULTADOS DE <i>COP</i> PARA BANCADAS DE DESEMPENHO DISTINTAS	227
--	------------

1. INTRODUÇÃO

1.1. CONTEXTUALIZAÇÃO

O conjunto dos aparelhos de refrigeração e conforto térmico é imprescindível para satisfação de necessidades básicas atuais e praticamente toda unidade residencial¹ com acesso à rede elétrica possui pelo menos um de seus elementos. O grau de importância desses sistemas termodinâmicos pode ser caracterizado pelo volume altamente significativo da energia elétrica que consomem.

Na tabela 1 está registrada a participação de refrigeradores, *freezers* e aparelhos de condicionamento ambiental no consumo médio domiciliar, para todas as regiões brasileiras, em 2005. Os dados são da última avaliação disponível da Eletrobrás (PROCEL/ELETROBRÁS, 2007), para um ano em que o consumo do setor representou 22% de um total de 375193 MWh.

Tabela 1 – Consumo final de energia elétrica na carga residencial.

Região	Refrigerador	<i>Freezer</i>	Condicionamento ambiental
Centro-oeste	24%	4%	18%
Nordeste	29%	5%	27%
Norte	25%	4%	40%
Sudeste	22%	5%	11%
Sul	16%	7%	32%

Fonte: Adaptada de PROCEL/ELETROBRÁS (2007).

A expansão demográfica e o consequente aumento de unidades residenciais, bem como a necessidade de substituição de aparelhos, têm sido fatores responsáveis por manterem aquecida a demanda por esses bens de consumo duráveis, mesmo quando o mercado se manteve retraído em diversos outros setores (PACHECO, 2007). Entretanto, preocupações ambientais e legislativas, decorrentes das projeções de aumento de consumo, demandam grandes esforços da indústria de refrigeração no sentido de melhorar a eficiência dos aparelhos²

¹ Estatísticas do Instituto Brasileiro de Geografia e Estatística (IBGE) indicam que 97,3% dos domicílios brasileiros possuem refrigeradores (IBGE, 2013).

² Com o objetivo de estimular a fabricação e comercialização de produtos mais eficientes, foi instituído em 1983 o Selo Procel de Economia de Energia, que indica ao consumidor, no ato da compra, os equipamentos que apresentam melhores níveis de eficiência energética, dentro de cada categoria (ELETROBRÁS, 2010).

residenciais (LEIGHTON, 2011) – aspecto que tem sido cada vez mais considerado na compra de novas unidades (CARDOSO, 2008).

A busca por aparelhos mais eficientes requer ampla análise de todos os elementos constituintes dos sistemas de refrigeração, como se pode constatar em publicações das últimas décadas (RADEMACHER; KIM, 1996; TIWARI; GUPTA, 2011), aí incluídos os compressores herméticos.

Os compressores herméticos são responsáveis por transferir a energia necessária para que ocorra a troca de calor com o meio externo, em sistemas de pequeno porte, pela transferência de fluido da região de baixa para a de alta pressão. Conseqüentemente, as melhorias pretendidas estão fortemente relacionadas com o aumento da eficiência dos compressores empregados (PACHECO, 2007). Corroborando essa argumentação o fato de os compressores atuais, produzidos por empresa com posição de destaque nesse segmento, consumirem hoje metade da energia consumida pelos compressores de duas décadas atrás, equivalentes em capacidade de refrigeração (EMBRACO, 2014).

O aumento da eficiência dos compressores normalmente decorre do somatório de pequenos ganhos que devem ser monitorados tanto em nível de desenvolvimento quanto no âmbito da produção. O coeficiente de performance (*COP – Coefficient of Performance*) é um parâmetro globalmente empregado para medir o nível de eficiência de compressores herméticos. Seu valor é obtido pela razão entre a capacidade de refrigeração, que pode ser definida como a taxa de eliminação de calor do espaço refrigerado, e a potência elétrica ativa consumida pelo compressor. Tais parâmetros são tipicamente obtidos em ensaios de desempenho (ARENCIBIA; TRICIO, 2014).

O *COP* é uma boa medida da eficiência energética, mas outros parâmetros podem ser considerados na avaliação da qualidade do compressor, como a mínima tensão de partida (MTP), que é o menor nível de tensão necessário para partida e funcionamento do mesmo, em determinada condição de operação. Tais condições podem ser severas, especialmente quando decorrem das relações com clientes de mercados com características atípicas, como aqueles sujeitos a condições precárias de fornecimento de energia elétrica, com interrupções frequentes e magnitudes de tensão muito aquém das nominais. Nesses casos, pode ser exigida partida do compressor com baixos níveis de tensão de alimentação aliados a cargas muito elevadas. Para dar garantias ao cliente de que o compressor pode partir e operar em tais condições, o fabricante precisa identificar o valor da MTP, o que normalmente é feito por meio do ensaio de mínima tensão de partida.

Ensaaios com abrangência global, como os de desempenho, devem ser realizados em bases comuns e com níveis de incerteza adequados, permitindo a comparação entre modelos equivalentes de diferentes fabricantes. A desejada padronização de tais procedimentos pode ser alcançada com a observação de normas relacionadas, entre elas: *ANSI/ASHRAE 23* (ANSI/ASHRAE, 2005); *DIN EN 13771-1* (DIN, 2008) e *ISO 917* (ISO, 1989).

Ensaaios mais específicos, como os de MTP, seguem apenas procedimentos operacionais internos dos fabricantes, elaborados em função das especificidades da aplicação (EMBRACO, 2012).

Para atender requisitos de norma ou procedimento operacional, ambos os ensaios são realizados em condições laboratoriais e demandam a utilização de bancadas específicas, capazes de estabelecer diferentes condições de operação, em procedimentos que requerem o uso de óleo lubrificante e gás refrigerante para os quais o compressor foi projetado. Outra característica comum aos ensaios é o longo tempo necessário para suas execuções.

Um ensaio de desempenho demanda normalmente mais de quatro horas para ser realizado (SCUSSEL, 2006). Os parâmetros de interesse são estimados a partir de medições tomadas na última hora de ensaio, intervalo de tempo em que um determinado grupo de grandezas é considerável estável (regime permanente). O intervalo de tempo requerido para a estabilização é denominado regime transitório, e é superior a três horas (POLETTI, 2006; SCUSSEL, 2006; FLESCH, 2006).

Um ensaio de partida demanda, em média, 50 minutos para a execução. Desse tempo, em média, 40 minutos são empregados no pré-aquecimento³ do compressor sob ensaio, cuja temperatura é monitorada de forma indireta, por meio da medição da resistência elétrica dos enrolamentos do motor associado (ABNT, 2002).

Os ensaios de desempenho e MTP são realizados em protótipos, em lotes-piloto e no controle da qualidade da produção, o que demanda número expressivo de horas de ensaio em empresas com elevado fluxo produtivo, também dedicadas à pesquisa e ao desenvolvimento. Apenas para exemplificar, a Embraco – maior fabricante mundial de compressores – possui atualmente 24 bancadas, operando em três

³ Nos ensaios de partida podem ser obtidos valores de MTP tanto para o caso em que a temperatura do enrolamento do motor associado esteja próxima da ambiente (partida a frio) quanto nas condições em que ela esteja próxima dos limites de operação do compressor (simulações de partida a quente). Nestes casos, faz-se necessário pré-aquecer o compressor sob ensaio. Vale destacar que no âmbito deste trabalho foram considerados apenas resultados de simulações de partida a quente.

turnos, para realizar ensaios de desempenho. Ainda assim, a avaliação da produção fica limitada a pequenos conjuntos de peças, amostras dos lotes encaminhados aos clientes.

A quantidade de ensaios requerida é função das características metrológicas das bancadas, visto que o número de peças necessárias para validação de ganhos é proporcional à incerteza da medição praticada (PENZ, 2011). Por outro lado, o aumento desejável da capacidade de realização de ensaios é limitado por vários fatores, como:

- custos de aquisição e operação – cada nova bancada de desempenho representaria um gasto inicial de centenas de milhares de dólares, além das despesas decorrentes do uso;
- baixo nível de automação dos equipamentos atuais – requerendo intervenção de operadores experientes.

Para melhorar os níveis de incerteza envolvidos e reduzir o tempo de ensaio, visando aumento da produtividade das bancadas, a Embraco estabeleceu parceria com o Labmetro – Laboratório de Metrologia e Automatização da Universidade Federal de Santa Catarina. Para o desenvolvimento das pesquisas, a empresa disponibilizou ao Labmetro uma bancada de ensaios de desempenho e outra onde são realizados ensaios de MTP.

Dentre os trabalhos realizados na bancada de ensaios de desempenho se destacaram:

- Poletto (2006) deu início ao aprimoramento da bancada de ensaios, aumentando o nível de automação e propondo mecanismos para redução das incertezas de medição;
- Barbosa (2006) desenvolveu sistema de medição de grandezas elétricas – tensão, corrente e potência – visando redução das incertezas associadas;
- Scussel (2006) atuou na eliminação de limitações que comprometiam a estabilidade do ensaio durante o regime permanente e propôs redução do intervalo transitório por meio de técnicas de aquecimento forçado do compressor;
- Flesch (2006, 2010) desenvolveu técnicas avançadas de controle e automação para aumentar a confiabilidade e reduzir o tempo de ensaio;
- Silveira (2010) validou uma das propostas de Scussel (2006), desenvolvendo o SICC (Sistema de Injeção de Corrente Contínua), capaz de forçar o aquecimento do compressor, por meio da inserção de nível significativo de componente contínua à alimentação do compressor.

A incorporação das estratégias relacionadas permitiu redução média do tempo total de ensaio de desempenho em 52% (passando de 286 minutos para 138 minutos), sobretudo em decorrência da diminuição do regime transitório. É válido destacar que a arquitetura proposta já está sendo absorvida pelo mercado e existem algumas bancadas capazes de realizar os ensaios com tempo médio de 2,5 horas. Com auxílio da tabela 2 também se podem notar as reduções significativas dos níveis de incerteza de medição dos parâmetros de desempenho, para três condições de ensaios⁴.

Tabela 2 – Panoramas de incerteza de medição.

Condição de ensaio [°C]	Capacidade de refrigeração		Potência elétrica ativa consumida		Coeficiente de performance	
	Antes	Depois	Antes	Depois	Antes	Depois
(-5 e +45)	1,5%	0,6%	0,7%	0,2%	2,2%	0,8%
(-23,3 e +54,4)	2,2%	0,7%	1,0%	0,4%	3,2%	1,1%
(-35 e +65)	4,4%	0,8%	1,6%	0,4%	5,9%	1,2%

Fonte: Adaptada de PENZ (2011).

Com relação aos trabalhos desenvolvidos na bancada para ensaios de MTP se destacaram:

- Costa (2010) incorporou inúmeras soluções visando à automação dos ensaios;
- Schlickmann (2012) estabeleceu estratégias objetivando diminuir a incerteza na medição da temperatura interna ao compressor, por meio de recursos para obtenção não invasiva do valor da resistência do enrolamento, com baixa incerteza;
- Thomazini (2013) aprimorou a bancada, incorporando a ela o SICC (Sistema de Injeção de Corrente Contínua), desenvolvido por Silveira (2010), para diminuir o tempo de pré-aquecimento do compressor.

Por meio da integração do SICC, Thomazini (2013) conseguiu reduzir até 58% no tempo médio de pré-aquecimento das peças avaliadas na época, indicando possível aumento substancial da produtividade da bancada de ensaios.

⁴ As condições de ensaios são definidas na prática por especialistas, diante dos requisitos de mercado de compressores. A condição de *check-point*, por exemplo, requer a avaliação do compressor com temperaturas de evaporação e condensação em -23,3 °C e +54,4 °C, respectivamente. Tais valores definem as pressões absolutas de sucção e de descarga respectivamente em 1,148 bar e em 14,698 bar e temperatura de sucção em 32,2 °C, para fluido R134a.

Além dos trabalhos relacionados, também tem sido avaliado o uso de recursos computacionais, para diminuir de maneira ainda mais incisiva os tempos envolvidos. Sob esse enfoque foram realizados vários trabalhos que revelaram o potencial de uso de ferramentas de inteligência artificial (IA) para realização de inferências e prognósticos⁵ em ensaios de desempenho. Destacam-se, dentre eles:

- Henklein (2006) empregou abordagem neuro-nebulosa (neuro-*fuzzy*) para obtenção de prognósticos, a partir de informações do intervalo de estabilização, de capacidade de refrigeração e potência elétrica ativa consumida, em classes previamente estabelecidas;
- Steinbach (2008) adotou abordagem em redes neurais para inferir sobre o instante de entrada em regime permanente e, a partir de informações associadas a esse momento, obter prognóstico de capacidade de refrigeração, potência elétrica ativa consumida e *COP*;
- Casella (2008) usou redes *fuzzy*-bayesianas para inferir sobre a entrada em regime permanente da capacidade de refrigeração e, a partir dela, avaliar a estabilidade do ensaio (entrada em regime permanente);
- Lima (2010) contribuiu para a validação das estratégias anteriores, implantando um conjunto de ferramentas de IA em bancada de ensaios de empresa parceira. Tais ferramentas permitiam a identificação do instante da entrada em regime permanente, a partir do transitório, e prognóstico de capacidade de refrigeração, potência elétrica ativa consumida e *COP*, a partir das informações desse instante;
- Penz (2011) propôs procedimentos e métodos para prover confiabilidade ao uso de ferramentas de IA para inferência e prognóstico de condições de regime, a partir de dados de transitório.

A aplicação das ferramentas de IA tornou possível obter parâmetros de desempenho em tempo médio de 54 minutos, com significativo nível de confiança. Um caso mais específico foi o

⁵ Assim como em Penz (2011) e Coral (2014), neste trabalho se diferenciam os termos prognóstico e inferência, apoiados nas definições de Houaiss (2002): prognóstico – suposição, baseada em dados da realidade, sobre o que deve acontecer no futuro; inferência – operação intelectual por meio da qual se afirma a verdade de uma proposição em decorrência de sua ligação com outras já reconhecidas como verdadeiras.

prognóstico de capacidade de refrigeração, onde 95,6% dos ensaios válidos apresentaram resultado em faixa de $\pm 2\%$ em relação aos valores finais de ensaio relacionados ao método tradicional (PENZ, 2011).

Trabalho iniciado recentemente objetiva identificar valores de MTP a partir da alimentação do compressor com rampa de tensão (ZANOL, 2015). Os primeiros resultados apontam para viabilidade de uso de tal estratégia. Apesar de atualmente não prever a diminuição do tempo destinado ao aquecimento do compressor, o uso dessa estratégia poderia diminuir o tempo de ensaio, propriamente dito, de 10 minutos para menos de 1 minuto.

Os avanços nas duas frentes de trabalho são significativos e sinalizam para grandes ganhos de produtividade, em instalação massiva dos recursos em bancadas de empresas. Entretanto, ainda assim não resolveriam o problema da adequação ao controle da produção de cada peça, especialmente em plantas com elevado fluxo.

Ainda que cientes do risco de colocarem no mercado produtos com testes pouco representativos, empresas com elevado fluxo de produção são impulsionadas a submeterem cada unidade produzida a testes mais rápidos, implicando incapacidade de investigação de aspectos quantitativos, visando, sobretudo, avaliação de aspectos mais imediatos de segurança e operacionalidade. Devido ao tempo destinado aos testes, normalmente pequeno, ensaios potencialmente mais capazes são realizados apenas em pequenas amostras da produção.

A avaliação por amostragem de lotes implica riscos significativos de produtos não conformes e decorrente desperdício de recursos naturais, como: consumo desnecessário de matéria-prima e energia nas fábricas; transporte de produtos defeituosos. Quando identificados apenas nos clientes, prejudicam a imagem da empresa e podem gerar pesadas multas contratuais.

Atualmente, na empresa parceira, os testes de capacidade de elevação de pressão, que acontecem no meio e no final das linhas de produção, são os únicos instantes em que o motor de cada compressor produzido é acionado, antes de ser enviado para o cliente.

Como se trata de um teste no qual é avaliado o funcionamento do compressor como um todo, necessariamente se avalia a capacidade do motor elétrico associado partir. Entretanto, tal partida ocorre em uma condição particular, muito provavelmente distinta daquelas consideradas nos ensaios de MTP. Portanto, não existe, atualmente, qualquer mecanismo que associe resultados dos testes de linha de produção com os ensaios de partida, realizados em laboratório.

Assim como não fornecem dados empregados para obtenção dos valores de MTP, os resultados dos ensaios de elevação também não apresentam, de forma direta, informações aparentemente relevantes para determinação da capacidade de refrigeração do compressor, potência elétrica ativa consumida ou do *COP*, que são os parâmetros avaliados nos ensaios de desempenho, em condições laboratoriais.

Resultados apresentados por Coral (2014) mostraram ser possível estabelecer bons níveis de correlação entre dados de teste de capacidade de elevação com valores de capacidade de refrigeração, obtidos em ensaios de laboratório. Devido ao significativo nível apresentado pelas correlações, ele estabeleceu, com uso de redes neurais artificiais, modelo de inferência da capacidade de refrigeração, com método para estimativa da incerteza associada, metrologicamente mais adequado que os até então disponíveis na literatura. O tempo médio para obtenção de cada resultado ficou próximo a 7 s, possibilitando integração da solução a plantas com pequenos tempos de ciclo.

Face aos excelentes resultados obtidos por Coral (2014), identificou-se a oportunidade de implementar junto aos testes de capacidade de elevação, meios para que se torne possível a obtenção de inferência de potência elétrica ativa consumida, *COP* e mínima tensão de partida na fase de produção. Tais recursos possibilitariam a avaliação de cada compressor durante a etapa de fabricação, o que permitiria a empresa atuar no processo de modo mais eficiente e também ter conhecimento dos parâmetros de desempenho de todo um lote de compressores sem que fosse necessário esperar pelos resultados fornecidos pelos laboratórios. Dessa forma, as bancadas poderiam ser destinadas exclusivamente aos ensaios em protótipos e em lotes-piloto.

Consulta à literatura técnica e científica não revelou o tratamento desses casos em abordagens semelhantes a esta, logo, os resultados pretendidos representarão significativo avanço no estado da arte. Adicionalmente, tais resultados deverão trazer benefícios diretos para todas as empresas do setor, especialmente aquelas com elevadíssimos volumes de produção.

1.2. OBJETIVOS

1.2.1. Objetivo geral da tese

O objetivo geral deste trabalho de doutorado é estabelecer métodos que permitam obter estimativas de potência elétrica ativa consumida, *COP* e mínima tensão de partida em compressores

herméticos de refrigeração, em tempo muito reduzido e com níveis de incerteza conhecidos, integráveis ao controle da qualidade junto à linha de produção, em plantas com elevado fluxo produtivo.

1.2.2. Objetivos específicos da tese

- identificar o estado da arte em métodos de ensaios para determinação de potência elétrica ativa consumida, *COP* e mínima tensão de partida em compressores herméticos de refrigeração;
- investigar a potencialidade de testes tipicamente empregados no controle da qualidade da produção de compressores em plantas com elevado fluxo;
- avaliar os níveis de correlação entre resultados de laboratório – potência elétrica ativa consumida, *COP* e mínima tensão de partida – e informações provenientes de testes de linha;
- identificar tipos de redes neurais artificiais úteis à tarefa de mapeamento entre dados típicos de testes de linha e resultados de laboratório;
- investigar o estado da arte em determinação de intervalos de confiança na aplicação de redes neurais artificiais;
- estabelecer modelos baseados em redes neurais artificiais capazes de realizar inferências sobre consumo, *COP* e mínima tensão de partida, com níveis de incerteza conhecidos, a partir de dados previamente obtidos em laboratório e linha de produção;
- realizar estudos de caso, com aplicações em vários lotes de produção de compressores, para verificar a adequação dos modelos propostos e validar os conceitos envolvidos.

1.3. INOVAÇÕES CONCRETIZADAS

Os resultados decorrentes do trabalho propiciaram avanços no estado da arte, gerando perspectivas favoráveis de integração dos modelos estabelecidos aos procedimentos de controle da qualidade em plantas com elevado fluxo de produção de compressores, proporcionando maior aproveitamento das informações obtidas em testes atuais.

De maneira inédita, o trabalho de tese proporcionou a medição dos valores de consumo, *COP* e mínima tensão de partida em compressores herméticos, por meio de inferências realizadas em linha de produção, com tempo muito reduzido e níveis de incerteza conhecidos, em 100% das peças produzidas, sem a necessidade de utilização de sistemas de refrigeração ou interferência de fatores humanos no processo.

1.4. ESTRUTURA DO DOCUMENTO

Este documento está dividido em sete capítulos.

No capítulo 2, discorre-se sobre o estado da arte em ensaios para obtenção de parâmetros úteis à avaliação de compressores herméticos. Entre outros aspectos, destacam-se as limitações de integração dos procedimentos ao controle da qualidade de linhas de produção.

No capítulo 3, investigam-se recursos de inteligência artificial aplicáveis aos problemas de aproximação de funções não lineares. São apresentadas ferramentas de redes neurais artificiais e seus respectivos algoritmos de aprendizagem.

No capítulo 4, caracteriza-se o estado da arte em estimativa de intervalos de confiança para saídas de modelos baseados em redes neurais artificiais. Os métodos apresentados consideram erros decorrentes do processo de medição e do processo de aprendizagem.

No capítulo 5, avaliam-se os níveis de correlação entre resultados de ensaios realizados em laboratório e testes típicos de linhas de produção de compressores. São discutidas as propostas do trabalho de tese e a forma de encaminhamento da solução, por meio de modelo baseado em redes neurais artificiais.

No capítulo 6, detalha-se separadamente cada um dos três estudos de caso – potência elétrica ativa consumida, *COP* e mínima tensão de partida – associados à proposta de encaminhamento. São apresentados aspectos relevantes das estratégias empregadas, bem como resultados práticos obtidos para cada uma das frentes de trabalho.

No capítulo 7, são feitas considerações sobre a conclusão do trabalho, confrontando os resultados obtidos com os objetivos propostos. Além de salientar os ganhos decorrentes, destacam-se, oportunamente, pontos que necessitam de abordagens complementares.

2. ENSAIOS PARA CONTROLE DA QUALIDADE DE COMPRESSORES HERMÉTICOS

2.1. INTRODUÇÃO

Conforme exposto na seção anterior (1.1), a sociedade atual depende de sistemas de refrigeração que operem com alta performance, tanto pela indispensabilidade de ambientes climatizados quanto pela necessidade de economia de energia. Essa relação gera grande expectativa de que cada novo aparelho produzido somente seja disponibilizado ao mercado quando determinadas características tenham sido avaliadas, como: desempenho; segurança operacional; durabilidade; eficiência energética. Tais aspectos são propagados, pelos produtores desses sistemas termodinâmicos, a toda a cadeia de fornecedores, dentre eles os fabricantes de compressores herméticos.

Grande esforço tem sido despendido pelas empresas do setor, com auxílio da comunidade científica, no desenvolvimento de mecanismos de apoio ao controle da qualidade de compressores. Em âmbito global, os **ensaios de desempenho** são os tipicamente mais empregados para a avaliação de eficiência, e consistem nas medições da capacidade de geração de fluxo de massa de fluido refrigerante, sob determinadas condições de operação, e na potência elétrica ativa consumida para a execução dessa tarefa (ARENCIBIA; TRICIO, 2014). Procedimentos mais específicos, como os **ensaios de mínima tensão de partida**, permitem avaliar o menor valor de tensão de alimentação necessário para que o motor seja capaz de partir e se manter em operação, sob determinadas condições de carga (THOMAZINI, 2013). De modo geral, o valor da mínima tensão de partida é útil para garantir o funcionamento do compressor em condições de subtensão.

Ensaio mais amplamente empregados são abalizados por normas, que impõem condições de contorno para que os procedimentos adotados sejam equivalentes, permitindo a comparação de informações, garantindo repetibilidade e reprodutibilidade (SCUSSEL, 2006). Ensaio mais específicos, entretanto, seguem apenas as recomendações técnicas de determinados fabricantes (COSTA, 2010).

Nas demais seções deste capítulo são abordados vários aspectos relevantes dos procedimentos acima destacados, como: caracterização dos parâmetros de interesse; diferentes métodos de aplicação e mecanismos de padronização; esforços da comunidade científica para diminuição do tempo de execução e aumento da confiabilidade

metrológica; avaliação da aplicabilidade ao controle da qualidade em plantas com elevados volumes de produção.

2.2. ENSAIO DE DESEMPENHO DE COMPRESSORES

Os ensaios de desempenho permitem analisar a eficiência de compressores por flexibilizarem a obtenção dos seguintes parâmetros (ISO, 1989):

- capacidade de refrigeração do compressor (ϕ_0) – expressada em watt no SI⁶ – é quantificada pelo produto da vazão mássica de refrigerante, que flui através do compressor, pela diferença entre a entalpia específica do refrigerante, medida na entrada (sucção) do compressor, e a entalpia específica de líquido saturado, correspondente à pressão de saída (descarga), como representado pela equação (1),

$$\phi_0 = q_{mf} \frac{V_{ga}}{V_{gl}} (h_{g1} - h_{f1}), \quad (1)$$

onde:

ϕ_0	é a capacidade de refrigeração do compressor	[W];
q_{mf}	é o fluxo de massa de refrigerante	[kg/s];
V_{ga}	é o volume específico do fluido refrigerante (gás) entrando no compressor, durante o ensaio	[m ³ /kg];
V_{gl}	é o volume específico do refrigerante entrando no compressor estabelecido anteriormente ao ensaio	[m ³ /kg];
h_{g1}	é a entalpia específica do refrigerante entrando no compressor nas condições básicas específicas de ensaio	[kJ/kg];
h_{f1}	é a entalpia específica do refrigerante líquido na pressão correspondente à descarga do compressor	[kJ/kg].

- potência elétrica ativa consumida (P) – doravante denominado consumo (Co) – é definido como a potência

⁶ SI – Sistema Internacional de Unidades – adotado neste trabalho – é um documento que emergiu da necessidade de um sistema prático mundialmente aceito, que evoluiu de forma contínua para refletir as melhores práticas de medição (INMETRO, 2012).

elétrica drenada por todo o elemento compressor, aí compreendidos os aparatos auxiliares que representam impedâncias adicionais, como os dispositivos de partida, capacitores de funcionamento e conversores eletrônicos. A unidade de medida do consumo é watt;

- coeficiente de performance (*COP* – *Coefficient of Performance*) – é o quociente entre a capacidade de refrigeração e o consumo, que resulta adimensional, e pode ser caracterizado pela equação (2),

$$COP = \frac{\phi_0}{C_o}, \quad (2)$$

onde:

<i>COP</i>	é o coeficiente de performance	[W/W];
ϕ_0	é a capacidade de refrigeração do compressor	[W];
<i>C_o</i>	é o consumo	[W].

Segundo Poletto (2006), o *COP* expressa a eficiência do compressor na base de entalpia exigida pelo experimento.

Os ensaios de desempenho são realizados em compressores em desenvolvimento e no controle da qualidade de produção. Quando aplicados na avaliação de produtos em desenvolvimento, onde eventualmente se faz necessário monitorar ganhos muito pequenos, existe grande preocupação em estabelecer limites máximos para as incertezas de medição dos parâmetros envolvidos. Embora, na prática, utilizem-se valores maiores, as incertezas de medição também são importantes no controle da qualidade ligada à produção. Nesse caso, quanto menores forem as incertezas dos ensaios para obtenção das características de interesse dos compressores, maior a confiança em aceitar ou rejeitar um determinado lote. Preocupação adicional é garantir que sejam equivalentes as medições feitas por fabricantes em qualquer parte do globo, visto que não existe consenso na adoção de um único procedimento para determinação dos parâmetros de desempenho. Essa garantia só é alcançada na existência de rastreabilidade das medições e equivalência entre os procedimentos empregados nos ensaios, o que se torna possível com a observação de condições de contorno, definidas em norma (POLETTO, 2006).

As normas lançam bases comuns para os ensaios, no intuito de padronizar os diferentes métodos empregados, possibilitar a reprodução dos ensaios em diferentes locais e permitir a confrontação dos resultados obtidos entre fabricantes distintos (SCUSSEL, 2006).

Existem várias normas aplicáveis aos ensaios de desempenho de compressores herméticos, todas muito similares e com requisitos básicos para tais ensaios (PENZ, 2011).

Por se tratar de publicação técnica com destacada aceitação internacional e pelo conteúdo consolidado no meio industrial, particularmente pela empresa parceira no desenvolvimento deste trabalho de tese, nas próximas seções são abordados aspectos relacionados a métodos preconizados pela *ISO 917 – Testing of refrigerant compressors*. A observação de tais métodos deve permitir a obtenção de resultados com níveis de incerteza que possibilitem a análise da adequação de um compressor a qualquer condição de operação requerida em um sistema de refrigeração (ISO, 1989).

2.2.1. Métodos de ensaios segundo a norma ISO 917

A norma apresenta nove diferentes métodos para os ensaios de desempenho, todos aplicáveis a compressores alternativos herméticos de simples estágio e deslocamento positivo (ISO, 1989):

- Método A – calorímetro⁷ de fluido secundário;
- Método B – calorímetro inundado;
- Método C – calorímetro a seco;
- Método D1 – medição do fluxo de massa na fase gasosa (linha de sucção);
- Método D2 – medição do fluxo de massa na fase gasosa (linha de descarga);
- Método F – medição do fluxo de massa na fase líquida;
- Método G – condensador resfriado a água;
- Método J – resfriamento parcial do vapor de refrigerante
- Método K – calorímetro na linha de descarga.

Por meio dos métodos D1, D2 e F se mede diretamente a vazão mássica. Os demais utilizam medidores de pressão, temperatura e transferência de energia associados, para possibilitar o cálculo do fluxo de massa a partir do balanço de energia em parte do sistema de

⁷ Na definição clássica, calorímetro é um ambiente, ou volume, dedicado à quantificação das trocas térmicas entre elementos fixos em seu interior ou daqueles que cruzam a fronteira do sistema (HANSEN, 2003).

refrigeração. Os valores das entalpias requeridas para satisfação das equações características podem ser obtidos em tabela de propriedades termodinâmicas, conhecidas as temperaturas e pressões de sucção e de descarga, obtidas em pontos indicados pela norma (ISO, 1989).

Alguns dos métodos relacionados precisam operar segundo um ciclo completo de refrigeração por compressão de vapor – com mudança de fase –, para outros tais circuitos são desnecessários – ciclos quentes ou ciclos a vapor –, o que se justifica pelo fato de estarem buscando resultados de desempenho do compressor e não do circuito de refrigeração, tornando este apenas um meio para obtenção daquele (CORAL, 2014). Em todos os casos existe a necessidade de empregar fluido refrigerante e óleo de funcionamento para os quais os compressores foram projetados (ISO, 1989).

A escolha do método a ser empregado é função da capacidade do compressor, dentre outras variáveis. Os métodos de medição direta são mais eficientes em compressores de maior capacidade, onde o fluxo de massa é maior. Para os compressores de menor capacidade, os métodos de obtenção indireta são os mais indicados (CORAL, 2014). Entretanto, a norma orienta que sejam obtidos dois valores de vazão mássica, em medições simultâneas e métodos distintos⁸. A validade do ensaio dependerá da comparação entre os valores obtidos (ISO, 1989). Tais métodos, denominados X (primário) e Y, devem ser escolhidos dentre as possíveis combinações sugeridas na tabela 3.

Tabela 3 – Combinação de métodos permitidos pela norma ISO 917.

Métodos para o ensaio X	Métodos para o ensaio Y	
	Permitidos	Recomendados
A	D1, D2, F, G, K	F, G, K
B	D1, D2, F, G, K	F, G, K
C	D1, D2, F, G, K	F, G, K
D1	A, B, C, D2, F, G, J, K	F, G, J, K
D2	A, B, C, D1, F, J	F, J
F	A, B, C, D1, D2, J, K	D1, D2, J, K
G	A, B, C, D1, F, J	D1, J
K	A, B, C, D1, F, J	D1, J

Fonte: Adaptada de ISO (1989).


⁸ Essa é uma especificidade da ISO 917. A norma ASHRAE 23 permite que os métodos empregados no ensaio sejam os mesmos, desde que operem de maneira independente (ANSI/ASHRAE, 2005).

Nas seções seguintes (2.2.1.1 e 2.2.1.2) são abordados dois dos métodos relacionados, que correspondem à primeira combinação permitida na tabela 3, $X = A$ e $Y = D1$. Vale destacar que esses são procedimentos adotados pela empresa parceira, a partir dos quais foram obtidos os parâmetros empregados nos estudos de caso apresentados no capítulo 6 desta tese.

2.2.1.1. Método A – Calorímetro de fluido secundário

Neste método o compressor a ser avaliado é acoplado a um sistema, de forma que seja caracterizado um ciclo de compressão de vapor de gás refrigerante (figura 1) – nesse caso, fluido primário.

Figura 1 – Circuito de refrigeração para o método A.



Legenda: f – fluido refrigerante em fase líquida;
 g – fluido refrigerante em fase gasosa;
 1 – variáveis lidas próximo ao compressor;
 2 – variáveis lidas próximo ao calorímetro.


Fonte: Adaptada de ISO (1989).

A pressão de descarga é controlada por válvula localizada depois do compressor e a pressão de sucção por outra junto à entrada do calorímetro, cumprindo o papel de válvula de expansão. A evaporação do fluido primário ocorre no interior do calorímetro (figura 2), dentro de uma serpentina ou câmara, que o separa do fluido secundário (ISO, 1989).

O evaporador se encontra suspenso na parte superior de um vaso de pressão hermético e termicamente isolado. Na base desse vaso está

localizado o conjunto aquecedor, envolto pelo fluido secundário na fase líquida. O calor pode ser cedido por conjunto de resistências elétricas ou dutos que conduzam fluido de trabalho aquecido (ISO, 1989).

Figura 2 – Diagrama simplificado do calorímetro de fluido secundário.



Fonte: Adaptada de Coral (2014).

Para viabilizar a medição se faz necessário estabilizar as pressões e temperaturas em torno do calorímetro, onde a temperatura interna deve ser mantida constante. As perdas do calorímetro devem ser conhecidas para que sejam compensadas durante os cálculos. O fluxo de massa, nessas condições, pode ser estimado a partir da equação (3),

$$q_{mf} = \frac{\phi_i + F_l (T_a - T_g)}{h_{g2} - h_{f2}}, \quad (3)$$

onde:

q_{mf}	é o fluxo de massa de refrigerante	[kg/s];
ϕ_i	é o calor cedido pela fonte externa	[kJ];
F_l	é o fator de perda	[kJ/K];
T_a	é a temperatura ambiente	[K];
T_g	é a temperatura interna ao calorímetro	[K];
h_{g2}	é a entalpia do gás saturado saindo do calorímetro	[kJ/kg];
h_{f2}	é a entalpia do líquido entrando no calorímetro	[kJ/kg].

Quando o aquecimento é produzido a partir de um conjunto de resistências, a quantidade de calor cedido é dada pela potência dissipada nos resistores. Quando usado aquecimento por circulação de líquidos, esse parâmetro é calculado por (4),

$$\phi_h = c (T_1 - T_2) q_{ml}, \quad (4)$$

onde:

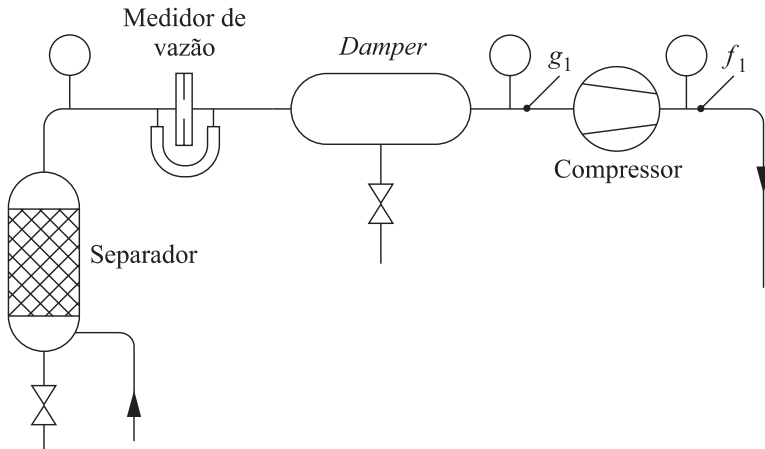
ϕ_h	é o calor cedido pelo fluido de trabalho	[kJ];
----------	--	-------

c	é o calor específico do fluido de trabalho	[Jkg ⁻¹ K ⁻¹];
T_1	é a temperatura ambiente	[K];
T_2	é a temperatura interna ao calorímetro	[K];
q_m	é a vazão mássica do fluido	[kg/s].

2.2.1.2. Método D1 – Medição do fluxo de massa na fase gasosa

Neste método é empregado dispositivo específico para medição instantânea do fluxo de massa, inserido próximo à sucção do compressor, sem necessidade de balanço de energia. A configuração proposta, ilustrada pela figura 3, permite que o ensaio seja realizado sem que ocorra mudança de fase do fluido refrigerante, podendo se manter sempre no estado de vapor. Entretanto, segundo Poletto (2006), nada impede que essa configuração seja inserida em circuito tradicional de refrigeração.

Figura 3 – Medição de fluxo de massa na linha de sucção do compressor.



Legenda: f – fluido refrigerante em fase líquida;
 g – fluido refrigerante em fase gasosa;
 1 – variáveis lidas próximo ao compressor.

Fonte: Adaptada de ISO (1989).

O circuito deve conter dispositivos capazes de controlar a temperatura e a pressão para os valores estipulados por norma. Também se faz necessário garantir a não formação de líquido no interior do medidor de vazão, bem como evitar sua contaminação por óleo proveniente do compressor, para não influenciar a medição, o que se consegue com uso de aquecedores e separador de óleo. A proximidade

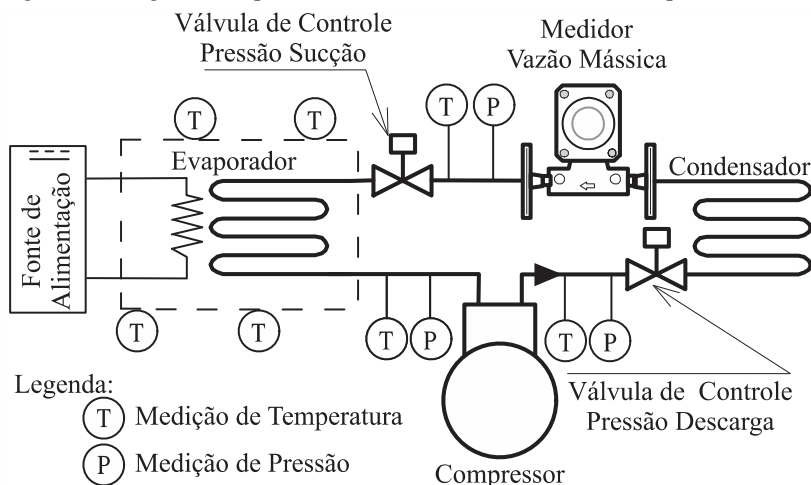
do medidor de vazão mássica ao compressor pode ainda afetar a medição da vazão, por provocar pulsação indesejada de fluxo no interior do medidor. Para diminuí-la, pode-se inserir um *dampner* no circuito (SCUSSEL, 2006).

A caracterização dos parâmetros de desempenho requer inúmeros meios que possibilitem a aplicação dos métodos relacionados e permitam estabelecer diferentes pontos de operação (*set points*) para os compressores sob ensaio. A implementação física desses recursos é comumente denominada bancada de ensaios de desempenho de compressores.

2.2.2. Bancada de ensaios de desempenho de compressores

De maneira geral, para atender requisitos da norma *ISO 917*, uma bancada de ensaio de desempenho deve reunir trocadores de calor, válvulas de controle de pressão de descarga, válvula de controle de pressão de sucção, transdutores de pressão, transdutores de temperatura, medidor de vazão mássica, além de outros aparatos auxiliares, dispostos em modo semelhante ao ilustrado pelo diagrama simplificado da figura 4.

Figura 4 – Diagrama simplificado de bancada de ensaio de desempenho.



Fonte: PENZ (2011).

A realização de ensaio nesses equipamentos, em conformidade com a *ISO 917*, requer que o compressor sob ensaio opere continuamente até que as oscilações de um determinado grupo de

variáveis fiquem restritas a uma faixa de valores estabelecida e que as curvas de tendência não caracterizem convergência para além desses limites. Alguns desses intervalos de valores são impostos pela norma *ISO 917* (tabela 4) e outros por especialistas em compressores e ensaios de desempenho (tabela 5).

Tabela 4 – Limites máximos de variação estabelecidos pela norma *ISO 917*.

Grandeza	Limites de variação
Pressões	$\pm 1\%$ do valor de referência
Temperaturas	$\pm 3\%$ do valor de referência
Valor eficaz da tensão de alimentação do compressor	$\pm 3\%$ do valor nominal
Frequência da tensão de alimentação	$\pm 1\%$ do valor nominal
Potência fornecida aos resistores para os métodos de calorímetro	$\pm 1\%$ do valor médio da última hora de ensaio
Fluxo de massa para os métodos de medição direta	$\pm 1\%$ do valor médio da última hora de ensaio

Fonte: Adaptado de *ISO 917* (ISO, 1989).

Tabela 5 – Limites máximos de variação estabelecidos por especialistas.

Grandeza	Limites de operação
Capacidade de refrigeração	$\pm 2\%$ do valor médio da última hora de ensaio
Potência elétrica ativa consumida pelo compressor	$\pm 2\%$ do valor médio da última hora de ensaio
Temperatura externa da carcaça do compressor	$\pm 1\%$ do valor médio da última hora de ensaio

Fonte: Adaptado de Coral (2014).

A caracterização do instante em que as variáveis relacionadas estejam todas estabilizadas divide o tempo de ensaio em dois intervalos, cronologicamente definidos como regimes transitório e permanente.

Segundo Scussel (2006), além do tempo demandado para a estabilização das grandezas, que pode ser superior a três horas, em condições típicas, o compressor deve ser monitorado por mais uma hora em regime permanente. Neste intervalo são necessárias pelo menos quatro medidas⁹ das variáveis de interesse, espaçadas de vinte minutos (ISO, 1989).

⁹ Na prática esse número é maior, pois existe a necessidade de observações das variáveis ao longo do tempo.

Todas as exigências apresentadas tornam o ensaio muito lento, situação que pode ser agravada quando nas bancadas são empregados: níveis inadequados de automação; técnicas de controle que não tratam apropriadamente o atraso na resposta dos sistemas térmicos; sistemas e procedimentos de medição metrologicamente defasados (FLESCH; NORMEY-RICO, 2010; PENZ, 2011).

A partir de uma bancada típica disponível em laboratório, obtida no âmbito da parceria discutida em 1.1, pesquisadores do Labmetro estabeleceram nova arquitetura que permite obter resultados mais confiáveis e em tempo significativamente menor.

O aprimoramento da bancada (POLETTI, 2006), a realização de processos de medição no estado da arte em metrologia (BARBOSA, 2006) e a utilização de modernas técnicas de controle e automação (FLESCH, 2006; PETROVICIC, 2007; FLESCH; NORMEY-RICO, 2010), bem como a implementação de estratégias de aceleração de regime transitório (SCUSSEL, 2006; SILVEIRA, 2010), contribuíram para que o tempo médio de ensaio fosse reduzido em 52%. A diminuição de tempo proporcionada, apesar de significativa, ainda era insuficiente para atender algumas eventuais aplicações, como o controle da qualidade de produto em escala mais ampla.

A necessidade de obtenção de parâmetros de desempenho em tempos ainda menores e a aparente otimização da bancada em termos de hardware exigiram redirecionamento das pesquisas, para buscas de resultados a partir das próprias informações de etapas do ensaio. Sob esse enfoque, ferramentas de inteligência artificial (IA) se mostraram muito úteis, tanto na identificação de entrada em regime permanente quanto na obtenção de parâmetros de desempenho (HENKLEIN, 2006; STEINBACH, 2008; CASELLA, 2008; LIMA, 2010). Em paralelo a esses trabalhos, Penz (2011) estabeleceu métodos e procedimentos para prover confiabilidade ao uso dos recursos por eles desenvolvidos.

Como consequência das pesquisas com enfoque em IA, tornou-se possível obter parâmetros de desempenho, com significativa confiança, em tempo médio de 54 minutos (PENZ, 2011) – redução drástica mas ainda insuficiente para adequação a uma inspeção 100%.

Todas as informações apresentadas são imprescindíveis para compreensão da real dimensão do problema em adequar o ensaio de desempenho ao controle da qualidade em empresas com elevado fluxo de produção. Caracterizadas as limitações, faz-se necessário descrever como esse problema é contornado na prática, ou seja, como os parâmetros de interesse são efetivamente empregados para o controle da qualidade de produção.

2.2.3. Uso dos parâmetros de ensaio de desempenho no controle da qualidade da produção de compressores herméticos

As bancadas de desempenho permitem estabelecer várias condições termodinâmicas para o ensaio, definidas como representativas de condições de aplicação. A variação da condição de operação compreende a combinação de diferentes valores de grandezas, como as pressões absolutas de descarga e de sucção e a temperatura de sucção.

Os métodos apresentados pela *ISO 917* são gerais para todas as condições de operação. Algumas dessas condições são definidas em normas relacionadas, como a *DIN EN 12900* (DIN, 2006). Entretanto, diante de requisitos mais específicos do mercado de compressores herméticos para refrigeração, outras condições de operação são definidas por especialistas, na prática.

Uma das condições tipicamente empregadas, conhecida como condição de *check-point*, requer a avaliação do compressor com temperaturas de evaporação e condensação em $-23,3\text{ °C}$ e $+54,4\text{ °C}$, respectivamente. Esses valores definem as pressões absolutas de sucção e de descarga respectivamente em 1,148 bar e 14,698 bar e temperatura de sucção em $32,20\text{ °C}$, para fluido refrigerante R134a. Para outros fluidos a pressão pode ser diferente, por isso fixa-se a condição de operação por temperatura e não por pressão. A condição de *check-point* também é observada pela empresa que deu suporte a este trabalho, quando os ensaios são empregados para controle da qualidade do produto. É válido destacar que em tal empresa o tempo de ciclo é de apenas sete segundos.

Devido às limitações apresentadas, a avaliação de desempenho de todo um lote é realizada a partir de uma pequena amostra, escolhida aleatoriamente entre compressores que estejam em condições de serem enviados aos clientes. No decorrer deste trabalho, o termo EDES (Amostra para Ensaio de Desempenho) será empregado para denominar tal amostra, tipicamente composta por cinco peças, submetida ao ensaio em condição de *check-point*.

O critério empregado para aceitação ou rejeição de um lote consiste em avaliar se a média dos resultados de EDES se enquadra em faixas ($\pm 5\%$) de valores definidas em torno das especificações técnicas de consumo, *COP* e capacidade de refrigeração para o produto.

A avaliação por amostragem (ainda que representativas), em momento posterior à produção de todo o lote, tem alguns riscos inerentes. Peças não conformes, identificadas antes da remessa do lote, geram rejeitos. Quando identificadas apenas no cliente, prejudicam a

imagem da empresa e podem incorrer em pesadas multas contratuais. Tais fatores corroboram a necessidade da inspeção por peça produzida, em procedimentos rápidos.

2.2.4. Modelo de previsão da capacidade de refrigeração

Em trabalho mais recente, Coral (2014) validou a tese de que a capacidade de um compressor deslocar massa de ar para o interior de um recipiente fechado, em um determinado intervalo de tempo, pode ser correlacionada com um dos parâmetros de desempenho: capacidade de refrigeração. Motivado pelo significativo nível apresentado pelas correlações e pelo potencial mostrado pelas ferramentas de inteligência artificial, destacadas em seu grupo de trabalho no Labmetro (HENKLEIN, 2006; STEINBACH, 2008; CASELLA, 2008; LIMA, 2010; PENZ, 2011) e em publicações correlatas (DENCKER, 2002; ERTUNC; HOSUZ, 2005; YANG *et al*, 2005; MIDANY; BAZ; ADBELWAHED, 2013), ele estabeleceu ferramenta de inferência da capacidade de refrigeração. Tal ferramenta, baseada em redes neurais artificiais, usava recursos para estimativa da incerteza associada, metrologicamente mais adequados que os até então disponíveis na literatura.

A utilização do painel de testes de capacidade de elevação (apresentado com detalhes em 5.2), inserido no início e final das linhas de montagens da empresa parceira neste trabalho, permitiu a ele realizar aplicação da ferramenta em estudo de caso (CORAL, 2014; CORAL *et al*, 2015). Como resultado, obteve indicações confiáveis da capacidade de refrigeração para cada uma das peças produzidas naquela linha de produção, observando o *lead time*¹⁰ característico da empresa (7 s).

2.3. ENSAIOS DE MÍNIMA TENSÃO DE PARTIDA

Os ensaios de partida permitem avaliar a mínima tensão de alimentação necessária para que o motor, sujeito a condições de carga elevada, seja capaz de entrar em funcionamento e se manter em operação, mesmo após a desativação do enrolamento de partida. Em se tratando de compressores, o torque exigido do motor elétrico associado

¹⁰ *Lead time* é um termo utilizado na indústria e que é traduzido como sendo o período entre a programação e o acabamento de um produto (MICHAELIS, 2011). No âmbito deste trabalho, *lead time* é o tempo decorrido entre a produção de dois compressores consecutivos, em uma mesma linha de produção.

depende fundamentalmente das pressões estabelecidas nos seus terminais de sucção e de descarga.

Os ensaios de partida podem ser realizados em protótipos, em lotes-piloto e em modelos de compressores já estabelecidos e se configuram em ensaios de partida equalizada e diferencial. Em ambos os casos, emula-se a queda e restabelecimento do fornecimento de energia elétrica¹¹ para compressores empregados em sistemas de refrigeração (COSTA, 2010; THOMAZINI, 2013).

No ensaio de partida equalizada, a queda emulada é mais prolongada, permitindo que as pressões de sucção (saída do evaporador) e de descarga (entrada do condensador) se equalizem em valor relativamente alto. Nessa condição, o motor do compressor deverá ser religado com torque de carga elevado. No ensaio de partida diferencial, a interrupção reproduzida é momentânea e o motor do compressor deve religar em condições muito próximas daquela que estava antes da queda, quando o sistema se encontrava em regime. Haverá um grande diferencial de pressão no compressor, podendo configurar torque de carga muito alto, e ele deverá ser capaz de partir em tal condição (COSTA, 2010; THOMAZINI, 2013).

A identificação dos valores de Mínima Tensão de Partida (MTP) é imprescindível para avaliação da adequação do compressor a determinadas demandas, mesmo que elas sejam atípicas (COSTA, 2010; THOMAZINI, 2013). Os procedimentos para determinação desses valores seguem orientações internas ao fabricante, visando eventuais reproduções de resultados e permitindo comparação das informações levantadas.

2.3.1. Método para ensaio de mínima tensão de partida

Segundo Schlickmann (2012), o torque fornecido pelo motor é afetado inversamente pela temperatura do seu enrolamento, o que se deve às propriedades dos materiais empregados em seus elementos condutores. Admite-se que o aumento da temperatura eleva a resistividade de tais materiais, e que a resistência elétrica deles é diretamente proporcional à sua resistividade (PACHECO, 2007). O aumento da resistência, componente real da impedância elétrica do

¹¹ Nesses ensaios também são simuladas, da mesma forma, interrupções decorrentes da atuação do protetor térmico, que ocorre quando a corrente de alimentação aumenta excessivamente, e dos ciclos do termostato, que atua quando a temperatura desejada no interior do refrigerador é atingida (COSTA, 2010).

motor, limita a corrente que circula pelo seu enrolamento e, conseqüentemente, a capacidade de proporcionar torque (SCHLICKMANN, 2012). Logo, é imprescindível padronizar as faixas de temperatura dentro das quais os ensaios de mínima tensão de partida ocorram, visto que o ensaio é relacionado ao torque¹² que o motor consegue fornecer (THOMAZINI, 2013).

Nos ensaios que simulam partidas a quente, os enrolamentos devem ser pré-aquecidos para (105 ± 4) °C. Tais valores devem ser observados antes, durante e depois do ensaio, para garantir que os procedimentos tenham sido realizados dentro da faixa especificada (padronização e repetibilidade). Adicionalmente, a observação desses limites também garante a integridade da peça, visto que o motor não pode exceder 130 °C em operação (EMBRACO, 2013). É válido destacar que a temperatura é medida de maneira indireta, por meio do método da variação da resistência elétrica do enrolamento (ABNT, 2002).

A execução do ensaio de partida requer primeiramente a definição do menor valor de tensão de alimentação a ser empregado. É válido destacar que a mínima tensão de partida é sempre superior à mínima tensão de operação. Isso ocorre porque, quando em operação, o compressor tem a inércia do movimento rotativo ao seu favor, associado à lubrificação presente nos mancais e no pistão (COSTA, 2010).

Quando aplicado a novos produtos ou protótipos (que nunca passaram por esse ensaio), a mínima tensão de operação é aquela onde ocorre o tombamento do compressor, que nesse contexto é caracterizado pela parada do motor elétrico por excesso de solicitação no eixo. Em suma, essa relação se justifica porque, para uma mesma condição de carga, o compressor pode se manter em operação com uma tensão de alimentação insuficiente para permitir sua partida (COSTA, 2010).

Quando aplicado ao controle da qualidade, a tensão inicial de ensaio já é conhecida. Conseqüentemente, para avaliação de produto basta configurar as pressões de sucção e de descarga do dispositivo sob ensaio. Após a energização do compressor com o valor de tensão definido, deve-se verificar que ele seja capaz de partir, por meio do monitoramento da frequência rotacional. Em caso afirmativo, deve-se diminuir a tensão de alimentação e realizar nova tentativa. Em caso negativo, eleva-se a tensão de alimentação e repete-se o processo, até

¹² Para evitar variações indesejadas do torque, faz-se necessário observar alguns procedimentos preliminares, como: realização de vácuo no compressor, para assegurar a inexistência de contaminantes; correção da impedância da fonte de alimentação da bancada de partida (EMBRACO, 2012).

que o compressor seja capaz de partir e manter-se em operação por certo intervalo de tempo. Deve-se variar a tensão da fonte em 1 V para compressores com tensão nominal de 115 V. Para aqueles alimentados nominalmente em 220 V, deve-se variar 2 V a cada nova tentativa de partida (COSTA, 2010; EMBRACO, 2012; THOMAZINI, 2013).

Verificando-se que o compressor é capaz de partir e se manter em operação com um determinado valor de tensão, reduz-se tal valor para confirmar que, de fato, ele não é capaz de partir e operar com valor ligeiramente inferior. Esse procedimento é repetido até que o mesmo valor de MTP seja obtido em um determinado número de tentativas. É válido destacar que não podem ser realizados mais do que três tentativas consecutivas sem que o compressor seja colocado em operação com tensão nominal (EMBRACO, 2012).

Os ensaios de partida equalizada e diferencial são semelhantes, no entanto, o último requer mais habilidade do operador, o que contribui para que o ensaio seja ainda mais demorado. Existem várias dificuldades adicionais; a maior delas é manter as pressões de sucção e de descarga nos pontos desejados. Segundo relatos dos operadores das bancadas, a posição de parada do pistão do compressor, no momento em que ele foi desligado, pode permitir vazamento de gás da descarga para a sucção. Nesse caso se faz necessário retornar o fluido para o circuito auxiliar e reiniciar o procedimento de ajuste das pressões. As pressões também precisam ser reajustadas quando o compressor consegue partir, mas não é capaz de se manter em operação pelo tempo mínimo estabelecido (COSTA, 2010).

Para conseguir maior controle sobre todas as condições relacionadas, os ensaios de mínima tensão de partida são realizados em condições laboratoriais, em bancadas específicas, por operadores muito experientes – pois o dinamismo com que as pressões são configuradas exige deles habilidade extrema (COSTA, 2010, SCHLICKMANN, 2012).

2.3.2. Bancada para ensaio de mínima tensão de partida

Os procedimentos para o ensaio de mínima tensão de partida são realizados em bancada que também permite realizar os ensaios de tombamento, composta, entre outros elementos, por:

- conjunto de válvulas que permite regular a vazão de fluido refrigerante em um circuito cuja finalidade é permitir que pressões diferentes sejam impostas à sucção e à descarga de um compressor sob ensaio;

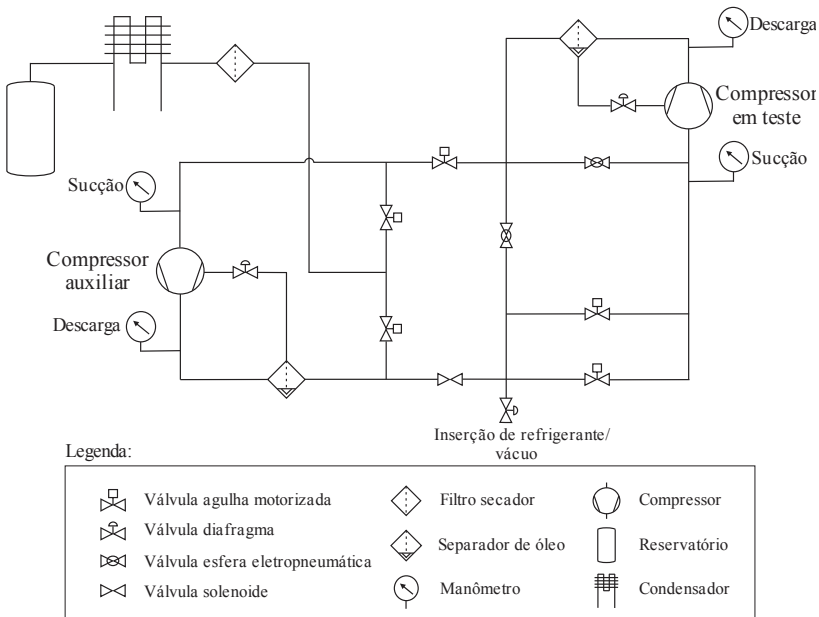
- compressor auxiliar de elevada capacidade para gerar pressões mais altas;
- reservatório para manutenção do fluido refrigerante utilizado nos ensaios;
- manômetros utilizados para medição das pressões de sucção e descarga;
- variador de tensão (varivolt) para permitir aplicação de diferentes tensões de alimentação ao motor;
- chaves auxiliares para comutação dos enrolamentos principal e auxiliar, uma vez que o compressor é ensaiado sem dispositivos de partida específicos;
- resistores de baixo coeficiente de temperatura para compor e padronizar o sistema de proteção;
- terminais para inserção de eventuais capacitores de partida e funcionamento.

As bancadas atualmente empregadas têm baixo nível de automação (COSTA, 2010, SCHLICKMANN, 2012), resultando em procedimentos demorados (em média 50 minutos). Segundo informações de operadores e especialistas da empresa parceira, parcela muito expressiva desse tempo (em média 40 minutos) é dedicada ao pré-aquecimento do compressor, pois pode ser necessário repeti-lo mais de uma vez durante o ensaio. Vale destacar que, para maior uniformidade de condições, a obtenção dos valores de MTP é comumente feita após os ensaios de desempenho, que, por si só, demandam mais de quatro horas para execução (SCUSSEL, 2006).

O Labmetro dispõe de uma bancada de partida e tombamento (figura 5 – página seguinte), recebida no âmbito da parceria discutida anteriormente (1.1), na qual foram incorporadas inúmeras soluções visando aumento da produtividade da bancada, minimização da influência dos operadores e obtenção de resultados com incertezas menores, alta repetibilidade e reprodutibilidade (COSTA, 2010; SCHLICKMANN, 2012; THOMAZINI, 2013).

O maior ganho decorrente das ações de Costa (2010), Schlickmann (2012) e Thomazini (2013) está relacionado com a significativa diminuição do tempo de aquecimento do enrolamento das peças, que diminuiria consideravelmente o tempo de ensaio, em eventual aplicação. Entretanto, tal concepção ainda é muito incipiente e não foi implementada na empresa, inviabilizando maiores comparações com modelos empregados atualmente.

Figura 5 – Diagrama esquemático da bancada de partida e tombamento disponível do Labmetro.



Fonte: Adaptado de Costa (2010).

2.3.3. Uso da mínima tensão de partida no controle da qualidade da produção de compressores herméticos

Apesar de ser um ensaio mais específico, não aplicado para avaliação de todos os lotes produzidos, o tempo de execução do ensaio (em média 50 minutos) é muito superior ao tempo de ciclo de empresas de elevado fluxo de produção (que pode ser de poucos segundos), limitando esse procedimento a pequena amostra dos lotes, como no caso dos ensaios de desempenho. Tal amostra, denominada neste trabalho por Amostra para Ensaio de Mínima Tensão de Partida (EMTP), é composta por no máximo três peças, escolhidas entre os cinco elementos da Amostra para Ensaio de Desempenho (EDES).

Como a demanda dos ensaios de MTP geralmente é muito específica, pode ocorrer grande variedade de resultados de EMTP, porém, com histórico pouco representativo para cada perfil de pressões empregado.

A decisão sobre um lote produzido depende da comparação entre o valor médio da EMTP e um valor percentual (90%) da tensão nominal de alimentação: caso aquele seja maior que este, rejeita-se o lote. Dito de outra forma, o mínimo que o compressor tem que cumprir do ponto de vista de partida e operação é 10% de subtensão.

2.4. CONSIDERAÇÕES

O presente capítulo resultou de investigação na literatura técnica e científica, além de inúmeros contatos com especialistas do setor de produção de compressores, para maior compreensão e melhor representação de todo o amplo espectro das características associadas à abordagem.

Foram apontados diversos aspectos relacionados aos ensaios de compressores herméticos para refrigeração, atualmente empregados para determinação de consumo, *COP* e mínima tensão de partida; onde se identificou que métodos ora adotados requerem estabelecimento de ciclos de refrigeração controlados em bancadas específicas e requerem grandes intervalos de tempo para execução.

Enfatizaram-se vários esforços no sentido de diminuir o tempo desses procedimentos e melhorar os níveis de incerteza associados, visando aumento de produtividade das bancadas atuais. Oportunamente, identificou-se estratégia, baseada em redes neurais artificiais, que permite obter previsões confiáveis de capacidade de refrigeração, em inferências a partir de testes rápidos, tipicamente empregados em 100% da produção de compressores.

A solução identificada vai ao encontro dos objetivos deste trabalho: estabelecimento de métodos que permitam obter estimativas de consumo, *COP* e mínima tensão de partida em compressores herméticos de refrigeração, em tempo muito reduzido e com níveis de incerteza conhecidos.

No capítulo que segue são investigadas ferramentas de inteligência artificial potencialmente úteis para comporem sistemas de controle de qualidade integráveis à linha de produção, em plantas com elevado fluxo produtivo.

3. REDES NEURAIS ARTIFICIAIS PARA APROXIMAÇÃO DE FUNÇÕES NÃO LINEARES

3.1. INTRODUÇÃO

A inteligência artificial (IA)¹³ é uma ciência relativamente jovem, mas traz consigo extensa bagagem herdada de outras disciplinas, como a matemática, psicologia, linguística e ciências da computação. Todo o arcabouço agregado contribuiu para que sua difusão ocorresse rapidamente por meio de diversas tecnologias, com amplo espectro de aplicabilidade (HAYKIN, 2001). Tal característica fica evidenciada quando algum desses aspectos é preponderante à tarefa subjacente: não é possível desenvolver um modelo matemático para o problema que aproxime suficientemente o comportamento real do sistema; a complexidade e o tamanho do problema são tais que uma solução completa não poderia ser estabelecida em tempo razoável (RICH; KNIGHT, 2001).

A habilidade em resolver problemas complexos, geralmente intratáveis com uso de outros recursos, estabeleceu as redes neurais artificiais (RNA) como a principal ferramenta¹⁴ no campo da IA, com aplicabilidade nas mais diversas áreas das engenharias e ciências (HAYKIN, 2001; SWIDER; BROWNE; BANSAL, 2001; ARCAKLIOĞLU; ÇAVUŞOĞLU; ERIŞEN, 2004; ERTUNC; HOSOZ, 2005; GHOBADIAN *et al*, 2009; SINGARAM, 2011; RUSSEL; NORVIG, 2013).

Nos capítulos anteriores foram apontados vários exemplos de propostas de aplicações de RNA ao controle de qualidade de compressores (DENCKER, 2002; YANG *et al*, 2005; HENKLEIN, 2006; STEINBACH, 2008; CASELLA, 2008; LIMA, 2010; PENZ, 2011), aí incluídas ferramentas de avaliação em plantas de elevado fluxo produtivo (CORAL, 2014; CORAL *et al* 2015). Neste caso, as redes neurais foram empregadas para mapear relacionamento funcional não linear entre grandezas de interesse, que é um processo de difícil modelagem por técnicas convencionais.

¹³ A inteligência artificial tem inúmeras definições, não necessariamente afins. Para este trabalho, convencionou-se defini-la a partir de Nilsson (1998), como a ciência que tem como um de seus objetivos de longo prazo o desenvolvimento de artefatos que possam raciocinar, perceber, aprender, comunicar e agir em ambientes complexos, assim como os seres humanos podem, ou possivelmente até melhor do que eles.

¹⁴ Não é objetivo deste trabalho apresentar outras diferentes ferramentas de IA, como: lógica difusa; sistemas especialistas; algoritmos genéticos, raciocínio baseado em casos; redes bayesianas.

No presente capítulo são resumidamente caracterizadas as RNA, apenas como forma de introduzir ferramentas úteis à realização da tarefa de aproximação de funções não lineares, característica também associada aos problemas que este trabalho se propõe resolver.

3.2. REDES NEURAIS ARTIFICIAIS

As RNA são técnicas computacionais que apresentam modelos matemáticos inspirados na organização cerebral de seres inteligentes, que são estruturas de processamento de informações altamente complexas, não lineares e paralelas (ADAMOWICZ; SAMPAIO, BARBOSA, 2002). As RNA possuem a capacidade de aquisição de conhecimento e podem ser definidas como um processador maciçamente paralelamente distribuído, constituído de unidades de processamento simples, caracterizadas por neurônios artificiais, que têm a propensão natural para armazenar conhecimento experimental, por meio da força de conexão entre eles, e disponibilizá-lo para uso (HAYKIN, 2001)¹⁵.

A habilidade de uma RNA em resolver problemas depende, fundamentalmente, do modelo de neurônio utilizado, da forma de aprendizado e da sua estrutura ou arquitetura (LOESCH; SARI, 1996).

3.2.1. Modelo matemático do neurônio biológico

Alguns autores descrevem uma série de modelos de neurônios, associando cada um deles a um tipo de RNA desenvolvida ao longo da história (CICHOCKI; UNBENHAUEN, 1993). O modelo mais bem aceito foi proposto por McCulloch e Pitts (1943), o qual implementa de maneira simplificada os componentes e o funcionamento de um neurônio biológico (figura 6a), englobando suas principais características de paralelismo e alta conectividade, e continua inspirando modelos de neurônios artificiais mais atuais.

Na representação de McCulloch e Pitts¹⁶, ilustrada pela figura 6(b), tem-se que:


- os **sinais de entrada** $\{x_1, x_2, \dots, x_n\}$ são aqueles oriundos do meio externo, usualmente normalizados, e que

¹⁵ O livro *Redes Neurais – Princípios e Práticas* (HAYKIN, 2001) fornece uma fundamentação teórica bastante abrangente das redes neurais e será usado extensivamente como referência neste capítulo.

¹⁶ Esse neurônio é referido na literatura como o modelo de McCulloch-Pitts, em reconhecimento ao trabalho pioneiro dos dois cientistas (HAYKIN, 2001).

- representam os valores assumidos pelas variáveis de uma aplicação específica. São análogos aos impulsos elétricos externos captados pelos dendritos do neurônio biológico;
- os **pesos sinápticos** $\{w_{k1}, w_{k2}, \dots, w_{kn}\}$ são valores para ponderar as variáveis de entrada, permitindo quantificar as suas relevâncias em relação à funcionalidade do respectivo neurônio – um sinal x_j na entrada da sinapse j conectada ao neurônio k é multiplicada pelo peso sináptico w_{kj} –. São equivalentes às ponderações exercidas pelas junções sinápticas do modelo biológico;
 - o **combinador linear** $\{\Sigma\}$ agrega os sinais de entrada ponderados a fim de produzir um valor de potencial de ativação;
 - a **saída do neurônio** $\{u_k\}$ resulta da combinação linear das ponderações aos sinais de entrada;
 - o **limiar de ativação** $\{b_k\}$ é uma variável que especifica qual será o patamar apropriado para que o resultado produzido pelo combinador linear possa gerar um valor de disparo em relação à saída do neurônio;
 - o **potencial de ativação ou campo local induzido** $\{v_k\}$ é o resultado da aplicação do limiar de ativação à saída do combinador linear. Geralmente, se $u_k \geq b_k$ então o neurônio produz um sinal excitatório, caso contrário, será inibitório;
 - a **função de ativação** $\{\varphi(\cdot)\}$ limita a saída do neurônio em um intervalo de valores razoáveis a serem assumidos pela própria imagem funcional;
 - o **sinal de saída** $\{y_k\}$ consiste do valor final produzido pelo neurônio.

Figura 6 – Neurônio biológico (a) e neurônio de McCulloch e Pitts (b).



As expressões em (5) sintetizam o resultado produzido pelo neurônio artificial representado pela figura 6(b):

$$y_k = \varphi(v_k) = \varphi\left(\sum_{j=1}^n w_{kj}x_j + b_k\right). \quad (5)$$

As funções de ativação tipicamente utilizadas podem ser divididas em dois grupos principais: funções parcialmente diferenciáveis – degrau (*heavyside*); degrau bipolar (função sinal) e rampa simétrica – e funções totalmente diferenciáveis. Estas, por serem usualmente empregadas nas ferramentas de interesse, estão relacionadas na tabela 6.

Tabela 6 – Funções de ativação totalmente diferenciáveis.

Funções totalmente diferenciáveis	
Função linear	$g(u) = u$
Função logística	$g(u) = 1 / (1 + e^{-\zeta u})$
Função tangente hiperbólica	$g(u) = (1 - e^{-\zeta u}) / (1 + e^{-\zeta u})$
Função gaussiana	$g(u) = e^{-(u-\gamma)^2 / (2\sigma^2)}$

onde: ζ é um parâmetro real associado ao nível de inclinação das funções logística e tangente hiperbólica;
 γ é um parâmetro real que define o centro da função gaussiana;
 σ é um parâmetro real que denota a largura da função gaussiana.

Fonte: Autor.

A grande vantagem no uso de RNA para solução de problemas complexos, como aproximação de funções não lineares, decorre de algumas propriedades e capacidades úteis (HAYKIN, 2001). Dentre elas:

- aprendizagem – habilidade da RNA de aprender o mapeamento desejado entre entradas e saídas conhecidas, por meio de processo iterativo de ajustes em seus parâmetros livres (pesos sinápticos e limiares);
- generalização – capacidade da RNA de apresentar saída adequada para entrada ausente do processo de aprendizagem;
- não linearidade – característica que decorre do uso de neurônios não lineares, importante para modelagem da maioria dos sistemas físicos;
- adaptabilidade – capacidade das RNA em adaptar seus pesos sinápticos à modificações no ambiente – uma rede

treinada para operar sob determinadas condições pode ser retreinada para absorver alterações em tais condições.

3.2.2. Processos de aprendizagem

A aprendizagem, no contexto em que as RNA se inserem, é um processo iterativo necessário para sintonizar os pesos sinápticos e limiares dos neurônios, o treinamento. O objetivo do treinamento é a obtenção de um conjunto desejado de saída a partir de um conjunto de entrada; este, formado por amostras tão representativas quanto possíveis do sistema sob mapeamento. Em outras palavras, segundo Basheer e Hajmeer (2000), a aprendizagem é um processo de atualização da representação interna do sistema em resposta a um estímulo externo, podendo desempenhar uma tarefa específica.

O conjunto total de amostras do sistema é dividido em dois subconjuntos, compostos aleatoriamente, treinamento e teste. Dependendo do tamanho das amostras, 60% a 90% delas podem ser designadas ao primeiro subconjunto, que é efetivamente empregado no processo de aprendizagem. O subconjunto de teste, por sua vez, será utilizado para verificar se as respostas das redes treinadas estão em níveis aceitáveis, visto que seus elementos são desconhecidos para elas (HAYKIN, 2001).

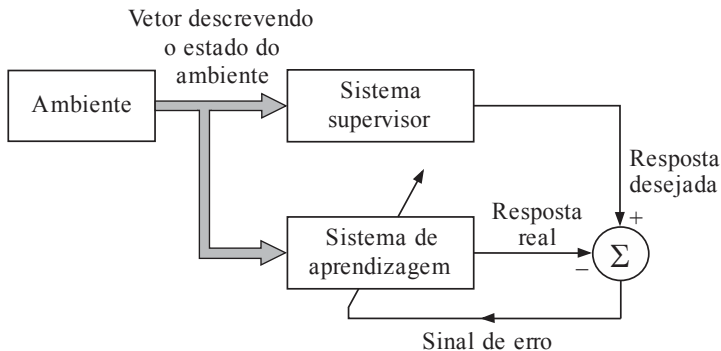
A teoria de aprendizado necessita endereçar três características práticas fundamentais associadas com o aprendizado a partir das amostras (HAYKIN, 2001):

- a **capacidade** se refere a quantos padrões podem ser armazenados e quais funções e limites de decisão uma RNA pode formar (HAYKIN, 2001);
- a **complexidade das amostras** determina o número de padrões de treinamento necessários para treinar a RNA de modo a garantir uma generalização válida (WELSTEAD, 1994);
- a **complexidade computacional** refere-se ao tempo requerido para que um algoritmo de aprendizado chegue a uma solução a partir dos padrões de treinamento (JAIN; MAO, 1994).

Existe certo consenso na literatura em classificar os tipos de aprendizado em três grupos distintos: supervisionado, não supervisionado e híbrido; este, caracterizado pela utilização, em um mesmo treinamento, dos outros dois diferentes tipos.

No aprendizado supervisionado (figura 7) – ou treinamento associativo – o conjunto de treinamento consiste de amostras que são pares de vetores de entrada e de saída. O vetor de entrada de cada amostra é aplicado e um sistema supervisor indica à rede um comportamento bom ou ruim, que vai depender da “similaridade” entre a resposta e o vetor de saída da amostra. Uma medida de similaridade usada com frequência é baseada no conceito de distância euclidiana. O erro é propagado através da rede e os parâmetros livres, pesos sinápticos e limiares, são ajustados de acordo com a diferença observada nas respostas (HAYKIN, 2001).


Figura 7 – Diagrama em blocos da aprendizagem supervisionada.



Fonte: Adaptado de Haykin (2001).

O processo de aprendizado não supervisionado (figura 8) – ou auto-organizado – é mais autônomo, não possui agente externo e as amostras são exclusivamente vetores de entrada, consequentemente, o aprendizado não requer uma resposta correta associada a cada padrão de entrada ou conjunto de treinamento. “Esse tipo de aprendizado explora a estrutura não aparente entre os dados, ou correlação de padrões entre os dados, e organiza os padrões em categorias a partir dessas correlações” (HECKMANN, 1999, p. 21).

Figura 8 – Diagrama em blocos da aprendizagem não supervisionada.



Fonte: Adaptado de Haykin (2001).

Nesse tipo de aprendizagem, o processo extrai propriedades estocásticas do conjunto de treinamento e agrupa vetores similares em

classes (HAYKIN, 2001). Geralmente, os algoritmos auto-organizados usam estratégias de aprendizagem competitiva.

Em ambos os casos, durante o processo de aprendizagem os exemplos do conjunto de treinamento podem ser apresentados à rede em lote (*batch* ou *off-line*), ou padrão-por-padrão (*on-line*). Nesse contexto, o termo época é usado para caracterizar o conjunto de iterações requerido para apresentação de todos os padrões à rede (HAYKIN, 2001).

O aprendizado é função da aplicação a que se destina a RNA e tais aspectos estão intimamente ligados à sua estrutura (arquitetura).

3.2.3. Arquiteturas de redes neurais

A forma como os neurônios artificiais estão arranjados uns em relação aos outros, define a arquitetura da rede. A estruturação desses arranjos se dá por meio das conexões sinápticas dos neurônios (HAYKIN, 2001).

Uma RNA pode ser dividida em três partes: uma camada de entrada, responsável pelo recebimento das informações; camadas ocultas (intermediárias ou escondidas), incumbidas de extrair características associadas ao processo ou sistema a ser inferido; e a camada de saída, a qual cabe a produção e apresentação dos resultados da rede. Considerando a disposição de seus neurônios, bem como as formas de interligação entre eles, podem-se dividir as principais arquiteturas de redes em três grupos: redes *feedforward* de camada simples; redes *feedforward* de camadas múltiplas; redes recorrentes (HAYKIN, 2001).

3.2.3.1. Arquitetura *feedforward* de camada simples

Essas redes são compostas de camada de entrada com unidades sensoriais – também denominadas falsos neurônios, por não realizarem qualquer processo computacional – e uma única camada de neurônios, que é a própria camada de saída. Nessa estrutura, cada elemento da camada de entrada é exclusivamente conectado a cada neurônio da camada de saída e o fluxo de informações é unidirecional, da entrada para a saída. Essas redes são tipicamente empregadas em classificação de padrões linearmente separáveis e são representadas geralmente pelos *perceptrons*¹⁷ (HAYKIN, 2001).

¹⁷ O *perceptron* é a forma mais simples de uma RNA. O neurônio da figura 6(b), com função de ativação degrau ou degrau bipolar, é um exemplo de *perceptron* de n entradas.

3.2.3.2. Arquitetura *feedforward* de camadas múltiplas

Além da estrutura da rede de camada simples, essas RNA possuem uma ou mais camadas escondidas de neurônios. Tais camadas adicionam um poder maior em relação às anteriores, pois os neurônios ocultos são responsáveis por capturarem a não linearidade dos dados. São empregadas em problemas que envolvem a aproximação de funções, classificação de padrões, identificação de sistemas, robótica, e controle de processos (HAYKIN, 2001).

Nesta arquitetura o fluxo de informações também é unidirecional e não existem ligações entre neurônios da mesma camada. As classes mais populares dessas redes são o *perceptron* multicamadas, do inglês *multilayer perceptron (MLP)*, e as redes de funções de base radial, do inglês *radial basis function (RBF)*. Sendo que as *RBF* possuem, geralmente, apenas uma camada escondida (HAYKIN, 2001).

3.2.3.3. Arquitetura recorrente ou realimentada

Essa estrutura de rede se distingue das RNA *feedforward* por possuírem pelo menos um laço de realimentação. Tal característica, qualifica-as para o processamento dinâmico de informações, com aplicações em séries temporais, otimização e identificação de sistemas de controle. O treinamento competitivo, subjacente a algumas dessas estruturas, possibilita seu uso em extração de características de parâmetros, comum em problemas de agrupamentos – *clustering* – e reconhecimentos de padrões (HAYKIN, 2001).


Entre os principais tipos de RNA com essa arquitetura estão as redes de Hopfield, as redes auto-organizáveis de Kohonen, as redes competitivas e as redes *ART*.

Conforme depreende das considerações anteriores, RNA são ferramentas de IA aplicáveis a diversas classes de problemas, dentre elas a aproximação de funções não lineares. Nesse caso, as redes *perceptron* multicamadas (*MLP*) e as redes de função de base radial (*RBF*) são as ferramentas tipicamente empregáveis. Segundo Haykin (2001), sempre existe uma *RBF* capaz de imitar um *MLP* específico, precisamente. Entretanto, “[...] para a aproximação de um mapeamento de entrada-saída não linear, o *MLP* requer um número menor de parâmetros que a *RBF* para o mesmo grau de precisão” (HAYKIN, 2001, p. 323). Por esse motivo, neste trabalho de tese, optou-se por avaliar o emprego do *MLP* como ferramenta para aproximação de funções não lineares.

3.3. REDES *PERCEPTRON* MULTICAMADAS

As redes *perceptron* multicamadas, do inglês *multilayer perceptron (MLP)*, são redes caracterizadas por um conjunto de unidades sensoriais (falsos neurônios), que constituem a camada de entrada, uma ou mais camadas ocultas de neurônios e uma camada de saída de neurônios. A figura 9 ilustra um *MLP m-n-o*, com m unidades sensoriais, n neurônios na camada oculta e o neurônios na camada de saída. O sinal de entrada se propaga em direção à saída, por isso são caracterizadas como redes alimentadas adiante (HAYKIN, 2001).

Figura 9 – Rede *perceptron* multicamadas *m-n-o*.



$W^{(i)}$ são as matrizes de pesos das i -ésimas camadas;
 $b^{(i)}$ são os vetores de limiares das i -ésimas camadas.

Fonte: Autor.

As redes *MLP* representam uma generalização do *perceptron* de camada única, caracterizando uma ferramenta aplicável a problemas não lineares, que é uma limitação da estrutura elementar. Para tanto, comumente se aplica uma transformação não linear Φ aos dados de entrada, projetando-os em um espaço onde sejam linearmente tratáveis (HAYKIN, 2001).

Formalmente, uma rede *MLP* é uma função $F : \mathbb{R}^D \rightarrow \mathbb{R}^L$, onde D é a dimensão do vetor de entrada x e L é a dimensão do vetor de saída $F(x)$. Uma rede de camada oculta única, como o *MLP m-n-o* da figura 9, pode ser expressa, em notação matricial, pela equação (6),

$$F(x) = G\left(b^{(2)} + W^{(2)}\left(\Phi\left(b^{(1)} + W^{(1)}x\right)\right)\right), \quad (6)$$

onde:

- F é a função vetorial realizada pela rede;
- \mathbf{x} é o vetor de entradas;
- G é a função vetorial de ativação da camada de saída;
- $\mathbf{b}^{(i)}$ são os vetores de limiares das i -ésimas camadas;
- $\mathbf{W}^{(i)}$ são as matrizes de pesos das i -ésimas camadas;
- φ é a função de ativação da camada oculta.

Nesse sentido, o vetor $\Phi(\mathbf{x}) = \varphi(\mathbf{b}^{(1)} + \mathbf{W}^{(1)}\mathbf{x})$ constitui a camada escondida e o vetor $o(\mathbf{x}) = G(\mathbf{b}^{(2)} + \mathbf{W}^{(2)}h(\mathbf{x}))$ a camada de saída.

No exemplo, o vetor $\Phi(\mathbf{x})$ impõe a não linearidade ao modelo. A função de ativação normalmente empregada para tanto é sigmoïdal. Haykin (2001) destaca que geralmente o aprendizado é mais rápido – requer menor número de iterações – quando a função utilizada for antissimétrica – função tangente hiperbólica – do que quando for não simétrica – função logística –. Para a camada de saída, podem ser usadas funções lineares.

O conhecimento adquirido por uma rede está contido no seu vetor de parâmetros livres θ , que pode ser compreendido como uma concatenação de \mathbf{W} e \mathbf{b} . O vetor θ é estabelecido inicialmente de forma aleatória e a tarefa do método de aprendizado é estabelecer o seu ajuste. Segundo Haykin (2001, p. 76), “um conjunto preestabelecido de regras bem definidas para a solução de um problema de aprendizagem é denominado um algoritmo de aprendizagem”.

Existem vários algoritmos para aprendizagem das redes *MLP*, entretanto, por se tratar de uma RNA com treinamento supervisionado, todos devem considerar a atualização de parâmetros livres com vistas à minimização de uma função de erro global, mediante erro máximo admissível. Nesse âmbito, considera-se que o algoritmo empregado tenha convergido quando a variação do erro global, decorrente do ajuste de tais parâmetros, seja muito pequena, entre uma e outra época de treinamento (SILVA; SPATTI; FLAUZINO, 2010). A diferença entre tais algoritmos está justamente na forma como ajustam o peso das conexões sinápticas, objetivando alcançar a convergência.

3.3.1. Algoritmo de retropropagação de erro

Segundo Heckmann (1999), foi o desenvolvimento do algoritmo de aprendizado por retropropagação de erro – do inglês *back-propagation*, como abreviatura de *backward propagation of errors* –, veiculado por Rumelhart *et al* (1986), que tornou as redes *MLP* as mais populares entre pesquisadores e usuários de RNA.

O algoritmo, também conhecido como regra Delta generalizada (WIDROW; HOFF, 1960), é um método gradiente descendente que busca minimizar a função de erro médio quadrático estabelecida para a rede (CICHOCKI; UNBENHAUEN, 1993). Esse algoritmo consiste de dois passos, um da camada de entrada para a de saída – propagação – e outro, em sentido contrário – retropropagação – (HAYKIN, 2001).

Na propagação, os valores oriundos das unidades sensoriais são aplicados aos neurônios ocultos e suas saídas são aplicadas como entradas aos neurônios da camada final, obtendo a resposta da rede. Durante esse passo os pesos sinápticos e limiares da rede são todos mantidos constantes (HAYKIN, 2001).

Na retropropagação os parâmetros livres são ajustados a partir do cálculo do erro realizado na camada de saída. Os pesos sinápticos e os limiares são modificados proporcionalmente ao oposto do gradiente do erro médio quadrático (HAYKIN, 2001), como representado em (7),

$$\theta_{i+1} = \theta_i - \eta \nabla e_i, \quad (7)$$

onde:


θ é o vetor de parâmetros livres na iteração i ;

η é a taxa de aprendizagem definida pelo projetista;

∇e_i é o gradiente do erro médio quadrático na iteração i .

Mesmo sendo amplamente empregado em redes *MLP*, o algoritmo de retropropagação possui problemas de convergência, que pode ser lenta, prematura, ou sequer nem ocorrer (SILVA; SPATTI; FLAUZINO, 2010). Os aspectos de convergência ou divergência podem estar intimamente ligados ao valor da taxa de aprendizagem η , como ilustrado na figura 10.

Figura 10 – Convergência e divergência do algoritmo de retropropagação.



Fonte: Adaptado de Yu e Wilamowsky (2011).

Valores de η muito pequenos podem deixar o treinamento naturalmente muito lento, pois são dados passos muito pequenos em

oposição ao gradiente do erro. Adicionalmente, como o algoritmo leva em consideração a inclinação da superfície do erro, a aleatoriedade da matriz de pesos iniciais, somada a pequenos valores de η , também pode levar o algoritmo a estacionar em mínimos locais, nas regiões com muitos vales, caracterizando a convergência prematura. Por outro lado, valores de η muito grandes podem inviabilizar a convergência, devido aos grandes saltos do modelo, provocando oscilações em torno dos pontos de mínimo (SILVA; SPATTI; FLAUZINO, 2010).

Uma das soluções para o problema da convergência do algoritmo é a adição do termo de *momentum* (POLYAK, 1964) na atualização dos parâmetros livres, fruto de uma ponderação entre o passo atual e os calculados anteriormente, como mostrado na equação (8),

$$\boldsymbol{\theta}_{i+1} = \boldsymbol{\theta}_i - \eta \nabla e_i + m(\boldsymbol{\theta}_i - \boldsymbol{\theta}_{i-1}), \quad (8)$$

onde m é o termo de *momentum*.

A convergência lenta limita a aplicação do algoritmo em problemas que requeiram rapidez no processo de ajuste. Uma das soluções com convergência rápida e estável para a minimização do erro em problemas de RNA é fornecida pelo algoritmo de Levenberg-Marquardt (YU; WILAMOWSKY, 2011).

3.3.2. Algoritmo de Levenberg-Marquardt

O algoritmo de Levenberg-Marquardt (LM) foi desenvolvido de forma independente por Levenberg (1944) e por Marquardt (1963), para prover soluções numéricas a problemas de minimização de funções não lineares. No âmbito das RNA, o algoritmo LM é empregado visando convergência rápida e estável para a minimização da função de erro em problemas pequenos e médios (YU; WILAMOWSKY, 2011). Segundo Hagan e Menhaj (1994), por meio dessa abordagem se consegue conduzir o treinamento de redes *MLP* na ordem de 10 a 100 vezes mais rápido que o algoritmo de retropropagação de erro, em problemas de até poucas centenas de pesos.

O algoritmo LM é um método gradiente de segunda ordem. A solução proposta por ele estabelece um compromisso entre o algoritmo de gradiente descendente e o método iterativo de Gauss-Newton (OSBORNE, 1992; BJÖRK, 1996). O método de Gauss-Newton avalia a superfície de erro por meio de derivadas de segunda ordem e é mais efetivo quando tal superfície tem a forma quadrática. Em superfícies

complexas ele pode divergir, nesse caso, o método gradiente descendente é mais efetivo (YU; WILAMOWSKY, 2011).

A regra de atualização de parâmetros livres pode ser representada pelas relações em (9),

$$\theta_{i+1} = \theta_i - \left(J_i^T J_i + \mu \mathbf{I} \right)^{-1} J_i e_i = \theta_i - \left(J_i^T J_i + \mu \mathbf{I} \right)^{-1} \nabla e_i, \quad (9)$$

onde:

θ é o vetor de parâmetros livres na iteração i ;

J é a matriz Jacobiana na iteração i ;

μ é o coeficiente de combinação;

I é a matriz identidade;

e_i é o vetor de erros na iteração i ;

∇e_i é o gradiente de erro na iteração i .

O coeficiente de combinação é adaptativo, evoluindo durante o processo de aprendizagem. Tal coeficiente é quem determina qual dos dois métodos será preponderante no ajuste, como depende da equação (9). Quando a superfície de erro for complexa, o coeficiente de combinação deverá ser muito grande – nesse caso $\eta = 1/\mu$ –, fazendo prevalecer o método do gradiente descendente. Quando a superfície se aproximar de uma forma quadrática, o valor de μ deverá se tornar muito pequeno – próximo de zero –, diminuindo a influência do gradiente descendente e fazendo prevalecer o algoritmo de Gauss-Newton (YU; WILAMOWSKY, 2011).

Assim como no caso anterior, a atualização dos parâmetros livres ocorre na fase de retropropagação.

Ainda que se empreguem algoritmos de aprendizagem adequados, a minimização da função de erro não é garantia de que a rede se torne capaz de fornecer saídas convenientes para entradas distintas daquelas usadas no treinamento. Tal capacidade se manifesta em projetos que considerem vários aspectos adicionais.

3.4. CAPACIDADE DE GENERALIZAÇÃO

A generalização é a capacidade da rede, devidamente treinada, responder de maneira adequada a entradas desconhecidas, considerando o seu domínio de treinamento. Entretanto, essa capacidade não decorre inerentemente da aplicação de algoritmo de treinamento apropriado. Além da complexidade física do problema abordado, o tamanho do

conjunto de treinamento e a representatividade estatística dos dados, bem como a escolha apropriada da topologia da estrutura escolhida, são alguns dos aspectos preponderantes no desempenho da rede, quando aplicada a novos dados (HAYKIN, 2001).

Cada problema requer determinado número de amostras para representá-lo de maneira mais adequada, e geralmente não existem regras específicas para a escolha apropriada do tamanho do conjunto de treinamento (SILVA; SPATTI; FLAUZINO, 2010).

A definição da quantidade de neurônios por camada e a determinação do número de camadas ocultas, que sejam condizentes com a complexidade do problema, é outro grande desafio do projetista da rede, pois esses parâmetros influenciam diretamente a sua capacidade de generalização (SILVA; SPATTI; FLAUZINO, 2010).

O aumento indiscriminado do número de neurônios e de camadas ocultas eleva a complexidade do modelo neural. Se tal complexidade é muito superior a do problema, a rede pode ficar demasiadamente ajustada aos dados de treinamento, pela circunstância de memorização excessiva – *overfitting* –, podendo resultar em baixa capacidade de generalização. Por outro lado, se a complexidade do problema é superior a do modelo, este pode não ser capaz de representá-lo, caracterizando o fenômeno de subajuste – *underfitting* – (HAYKIN, 2001). Assim, o processo de especificação da topologia de uma rede deve levar em consideração esse compromisso: superar o *underfitting* e evitar o *overfitting*. Em muitos casos, isso só se consegue na prática, por meio de simulações (SILVA; SPATTI; FLAUZINO, 2010).

Apesar da complexidade inerente ao problema de aproximação de funções não lineares, existe resultado na literatura (CYBENKO, 1989) que aponta para sua solução geral com uso de RNA. Por meio do Teorema da Aproximação Universal¹⁸ (KOLMOGOROV, 1957), Cybenko (1989) mostrou que um *MLP* de única camada oculta é suficiente para aproximar qualquer função contínua no espaço das funções reais.

Apesar de ser um “teorema de existência”, ele não permite afirmar que a camada oculta é uma solução ótima, no sentido de tempo de aprendizagem, facilidade de implementação, ou generalização. Entretanto, possibilita admitir a solução e aponta para a mínima topologia necessária para sua obtenção (SILVA; SPATTI; FLAUZINO, 2010). Segundo Haykin (2001), sem o resultado dado por esse teorema,

¹⁸ O Teorema da Aproximação Universal fornece justificativa matemática para a aproximação de uma função contínua arbitrária, como oposição à representação exata (KOLMOGOROV, 1957).

poder-se-ia estar procurando por uma solução inexistente. Essa faculdade se deve às semelhanças entre o problema de aproximação e o processo de aprendizagem do *MLP*.

3.5. REDES *MLP* E A TAREFA DA APROXIMAÇÃO DE FUNÇÕES NÃO LINEARES

Segundo Haykin (2001), a caracterização de um problema de aproximação requer, inicialmente, que se considere um mapeamento de entrada-saída, descrito por uma relação funcional $\mathbf{d} = f(\mathbf{x})$, onde \mathbf{x} é o vetor de entrada, \mathbf{d} é o vetor de saída e $f(\cdot)$ é a suposta função vetorial desconhecida.

A representação do conhecimento sobre $f(\cdot)$ é dada por um conjunto de exemplos rotulados¹⁹, como representado em (10),

$$\mathcal{J} = \{(\mathbf{x}_i, \mathbf{d}_i)\}_{i=1}^N, \quad (10)$$

onde:

- \mathcal{J} é o conjunto da amostra;
- \mathbf{x}_i são as i -ésimas entradas da amostra;
- \mathbf{d}_i são as i -ésimas saídas da amostra;
- N é o tamanho da amostra.

No âmbito da IA, então, o problema se caracteriza em projetar uma rede que se aproxime suficientemente da função desconhecida $f(\cdot)$, por uma função $\hat{f}(\cdot)$ que descreva o mapeamento, de forma a satisfazer a desigualdade em (11),

$$\|\hat{f}(\mathbf{x}) - f(\mathbf{x})\| \leq \varepsilon, \text{ para todo } \mathbf{x}, \quad (11)$$

onde cada ε é um número positivo pequeno (HAYKIN, 2001).

Colocado dessa forma, pode-se compreender o problema de ajuste de curva como a aprendizagem supervisionada (SHEFERD, 1997), ou seja, “a própria rede *MLP* pode ser considerada simplesmente como um mapeamento não linear de entrada-saída” (HAYKIN, 2001, p. 232). Essa é a forma mais intuitiva de compreender o resultado mostrado por Cybenko (1989).

Considerando um único neurônio na camada de saída do *MLP*, representado matricialmente em (6), que realize combinação linear das funções de ativação sigmoidais implementadas na camada oculta, poder-

¹⁹ Nesse contexto, exemplos rotulados são aqueles para os quais cada sinal de entrada é associado a uma resposta desejada correspondente (HAYKIN, 2001).

se-ia reescrever $F(x)$ como solução geral de problemas de aproximação de funções não lineares,

$$F(x) = \sum_{i=1}^m \lambda_i \varphi \left(\sum_{j=1}^n w_{ij}^{(1)} x_j - b_i \right), \quad (12)$$


onde $\lambda_i = w_{1j}^{(2)}$ (SILVA; SPATTI; FLAUZINO, 2010).

O teorema subjacente pressupõe a disponibilidade de uma camada oculta de tamanho ilimitado e da função contínua a ser aproximada, condições que são violadas na maioria das aplicações. O uso de duas camadas ocultas, por exemplo, é muito comum, pois torna o processo mais gerenciável, possibilitando aos neurônios da primeira e segunda camada extrair características locais e globais do sistema, respectivamente (HAYKIN, 2001).

Como o problema parte da premissa de que o mapeamento entrada-saída é descrito por uma função $f(\cdot)$, faz-se necessário garantir a representação do problema em um domínio capaz de caracterizar tal comportamento funcional. Do contrário, além do esforço adicional decorrente de topologias mal dimensionadas, pode-se incorrer em aproximações precárias.

Por definição, uma função é uma lei segundo a qual a cada elemento do domínio corresponde um único elemento do conjunto imagem. Como exemplo, as relações ilustradas nos planos yOx e zOx , da figura 11, não caracterizariam funções. Entretanto, elas podem ser caracterizadas por meio das relações entre as três variáveis identificadas, como $z(x, y)$.

Figura 11 – Projeções da função $z(x, y)$.



Fonte: Autor.

Verificar essa condição em dimensões mais elevadas é uma tarefa difícil, geralmente. Entretanto, existem tipos de RNA que podem facilitá-la, como as redes de Kohonen. Tais ferramentas permitem

reduzir a dimensão arbitrária de um espaço para um plano, preservando as relações espaciais originais, de acordo com propriedades que o algoritmo subjacente “considerar” relevantes (KASKI; KOHONEN, 1995).


3.6. REDES AUTO-ORGANIZÁVEIS DE KOHONEN

Parcela considerável das estruturas de RNA necessita de padrões de entrada e de saída para que possam ser treinadas. Os ajustes dos parâmetros livres dependem das apresentações sucessivas dessas amostras de treinamento. Em certas aplicações, só se dispõe do conjunto de padrões de entrada, entretanto, constituído de amostras com informações relevantes sobre o comportamento do sistema de onde foram extraídas. As RNA usadas em problemas assim organizam-se por meio de métodos de treinamento competitivo, os quais detectam similaridade, regularidade e correlações entre padrões de entrada, agrupando-os em classes – *clusters* (SILVA; SPATTI; FLAUZINO, 2010).

As estruturas mais difundidas, nesse contexto, são os mapas auto-organizáveis (*Self-Organizing Map – SOM*), propostos por Tuevo Kohonen (1982, 1984). Esses mapas têm como principal objetivo transformar um sinal incidente de dimensão arbitrária em um mapa discreto de apenas uma ou duas dimensões, preservando nele as características espaciais do espaço original (HAYKIN, 2001).

A rede de Kohonen se utiliza de duas camadas, entrada e mapa de características – grade pós-sináptica –, associados, respectivamente, às unidades sensoriais e aos neurônios de entrada e de saída. Cada unidade sensorial da camada de entrada está ligada com todos os neurônios da grade (figura 12); nesta, os neurônios mais próximos estão interligados (HAYKIN, 2001).

Figura 12 – Mapa topológico (a) unidimensional e (b) bidimensional.



Fonte: Autor.

A *SOM* é aplicada à compressão de dados, uma vez que informações de alta dimensionalidade são mapeadas em um espectro de dimensão inferior. São usadas também na “clusterização” de dados, quando nada é conhecido sobre eles (BASHEER; HAJMEER, 2000).

Haykin (2001) identifica três processos essenciais inerentes ao algoritmo de formação da *SOM*:

- competição – determinação do neurônio vencedor;
- cooperação – identificação da vizinhança;
- adaptação sináptica – atualização dos pesos.

No primeiro processo, os neurônios da grade competem entre si para se tornarem ativos, mediante um estímulo apresentado na camada de entrada. Para tanto, pressupõe-se o estabelecimento de pesos iniciais aleatórios. Existindo um neurônio vencedor, que melhor represente a informação recebida, ele terá seu vetor de pesos sinápticos reajustado para responder ainda melhor ao estímulo inicial (HAYKIN, 2001).

Como decorre das conexões sinápticas que os vetores de entrada \mathbf{x} e os vetores de pesos sinápticos \mathbf{w}_j de cada j -ésimo elemento da grade terão sempre a mesma dimensão, então o neurônio vencedor $i(\mathbf{x})$ pode ser representado pela menor distância euclidiana entre os vetores \mathbf{x} e \mathbf{w}_j (LIPPMANN, 1987; HAYKIN, 2001), como em (13),

$$i(\mathbf{x}) = \arg \min_j \{ \|\mathbf{x} - \mathbf{w}_j\| \}, \quad j = 1, 2, \dots, l, \quad (13)$$

onde:

- $i(\mathbf{x})$ é o neurônio vencedor;
- \mathbf{x} é o vetor de entrada;
- \mathbf{w}_j é o vetor de pesos sinápticos do neurônio j ;
- l é a quantidade de neurônios da grade.

Diferente das redes competitivas simples, baseadas no esquema vencedor leva tudo (*winner take all*), durante o processo de treinamento o neurônio vencedor ajusta o seu peso e o dos considerados neurônios cooperativos, estabelecidos pela vizinhança topológica. Tal vizinhança é normalmente definida por uma função gaussiana, como em (14),

$$h_{j,i(\mathbf{x})} = e^{-d_{ji}^2/2\sigma^2}, \quad (14)$$

onde:

- $h_{j,i(\mathbf{x})}$ é a vizinhança topológica;
- $d_{j,i}$ é a distância lateral entre o neurônio vencedor i e o neurônio cooperado j ;

σ denota a largura da função gaussiana (função de vizinhança).

Definida a vizinhança, pode-se ajustar o peso dos neurônios aí contidos por meio de (15),

$$\Delta \mathbf{w}_j = \eta h_{j,i(x)}(\mathbf{x} - \mathbf{w}_j), \quad (15)$$

onde:

$\mathbf{w}_j(n)$ é a variação do vetor de pesos do neurônio j ;

η é a taxa de aprendizagem (HAYKIN, 2001).

Tanto a taxa de aprendizagem η quanto a largura da função de vizinhança σ devem decair exponencialmente em função do número de iterações, ou seja, na medida em que a rede se especializa. No limite, isso garante o ajuste fino dos neurônios no centro dos *clusters* e que a vizinhança englobe apenas o neurônio vencedor (HAYKIN, 2001).

3.7. CONSIDERAÇÕES

No capítulo anterior, discorreu-se sobre vários aspectos relacionados aos ensaios para obtenção dos valores de consumo, *COP* e mínima tensão de partida, parâmetros normalmente empregados para avaliação de compressores herméticos para refrigeração. Focou-se a análise na adequabilidade desses procedimentos ao controle da qualidade em plantas de elevado fluxo, o que não se mostrou viável em aplicações diretas, apesar de todos os esforços identificados para diminuição dos tempos dos ensaios. Entretanto, em decorrência de trabalhos correlatos, considerou-se a possibilidade de inferir esses parâmetros a partir de testes rápidos, tipicamente realizados na linha de produção, em 100% dos compressores produzidos.

O primeiro problema subjacente à proposta de solução é o de aproximação das funções não lineares, que regem os processos associados. Para tanto, no presente capítulo se investigaram recursos de inteligência artificial aplicáveis. Na abordagem foram resumidamente caracterizadas redes neurais artificiais, destacando ferramentas usualmente empregadas como “aproximadoras” e seus respectivos algoritmos de aprendizagem.

O presente capítulo, assim como o anterior, foi amparado por investigação na literatura científica. Tal tarefa também subsidiará o capítulo seguinte, onde será caracterizado o estado da arte em estimativa de intervalos de confiança para saídas de modelos baseados nas redes

neurais adotadas, que é o segundo problema associado à proposta de solução.

4. INCERTEZA DA INFERÊNCIA EM MODELOS NEURAIS

4.1. INTRODUÇÃO

Ao treinar uma rede neural artificial (RNA) não se objetiva unicamente obter representação apropriada para determinado conjunto de treinamento, mas estabelecer ferramenta capaz de modelar as relações intrínsecas ao ambiente por ele representado. No caso das redes neurais *perceptron* multicamadas (*MLP*), usadas na aproximação de mapeamentos não lineares, o processo de aprendizagem visa estabelecer função que seja capaz de aproximar os dados de treinamento e fornecer respostas adequadas, durante o uso, para entradas não conhecidas. Para tanto, tais entradas devem estar compreendidas na mesma região em que a rede *MLP* foi treinada, ou seja, no domínio de definição da função estabelecida (SILVA; SPATTI; FLAUZINO, 2010).

Geralmente, o erro obtido no conjunto de teste é a medida disponível para avaliar a capacidade de generalização do *MLP* treinado. As respostas da função modelada aos elementos do conjunto de teste, pertencentes ao domínio de definição, possibilitam avaliar condições de *underfitting* e *overfitting*, provendo alguma capacidade de análise das topologias empregadas, como número de camadas e número de neurônios por camada. Entretanto, tais respostas, não permitem exprimir diretamente o grau de confiabilidade dos resultados a serem fornecidos para as demais regiões do domínio de definição (HE; LI, 2011), apesar de muitas vezes serem usadas com esse intuito (PENZ, 2011).

Em aplicações em sistemas industriais, a expressão da dúvida é imprescindível (YANG *et al*, 2000), sob pena de contestação metrológica dos resultados; sobretudo quando a rede é vista como integrante de um sistema de medição (PENZ, 2011).

Em publicações que foram elementos motivadores da proposta deste trabalho de tese, Coral (2014) e Coral *et al* (2015) estabeleceram ferramenta de inferência de capacidade de refrigeração, aplicável ao controle da qualidade de produção de compressores herméticos. Tal ferramenta, baseada em redes neurais artificiais do tipo *MLP*, usa recursos para estimativa da incerteza associada, metrologicamente mais adequados que os demais métodos até então disponíveis na literatura. Tais recursos também vão ao encontro das necessidades deste trabalho, e serão avaliados como meios para prover confiabilidade aos resultados dele decorrentes.

No presente capítulo será caracterizado o estado da arte na estimativa de intervalos de confiança para saídas de modelos baseados

em RNA. Entre outros aspectos, são apresentados resumidamente os métodos que consubstanciaram a ferramenta desenvolvida por Coral (2014) e Coral *et al* (2015), apenas como forma de evidenciar o caráter limitado de suas aplicações de modo individualizado. O objetivo principal é destacar o quanto tais métodos se tornam abrangentes, quando usados em conjunto. Na composição de um sistema híbrido eles são capazes de considerar erros decorrentes do processo de treinamento da rede e da etapa de uso, abordagem não encontrada nas fontes disponíveis.

4.2. CONFIABILIDADE DE REDES NEURAIAS ARTIFICIAIS

Quando os modelos neurais são empregados, é desejável que sejam estabelecidas formas para quantificar a incerteza associada às suas saídas. Nesse âmbito, o intervalo de confiança tem sido considerado como uma medida da incerteza, uma vez que corresponde a uma faixa de saída do modelo, onde o valor da grandeza possa realmente estar, com certa probabilidade (CHRYSSOLOURIS; LEE; RAMSEY, 1996).

Muitos trabalhos foram desenvolvidos nas últimas décadas, visando estimar intervalos de confiança (IC) para modelos neurais (LEONARD; KRAMER; UNGAR, 1992, CHRYSSOLOURIS; LEE; RAMSEY, 1996; HWANG; DIN, 1997; VEAUX *et al*, 1998). Como não existe uma teoria global sobre o assunto, a análise focada na solução de problemas particulares tem sido a abordagem dominante (PENZ, 2011). Consequentemente, muitas das técnicas relacionadas são específicas das redes para as quais foram desenvolvidas e não são diretamente aplicáveis aos diversos tipos de arquiteturas, com diferentes topologias e conexões (OLIVEIRA; MONTINI; BERGMANN, 2007).

Algumas dessas publicações (CHRYSSOLOURIS; LEE; RAMSEY, 1996; HWANG; DIN, 1997; VEAUX *et al*, 1998) são citadas seguidamente, ainda hoje. Entretanto, no início desse milênio, Yang *et al* (2000) já apontavam para suas limitações. Segundo eles, nas propostas os autores assumiam condições que raramente seriam satisfeitas na prática, e elas só teriam validade quando: a quantidade de informações para o conjunto de treinamento fosse suficientemente grande (HWANG; DIN, 1997); os erros dos modelos fossem independentes e com distribuição normal e média nula (CHRYSSOLOURIS; LEE; RAMSEY, 1996); o treinamento convergisse sempre da mesma forma (VEAUX *et al*, 1998).

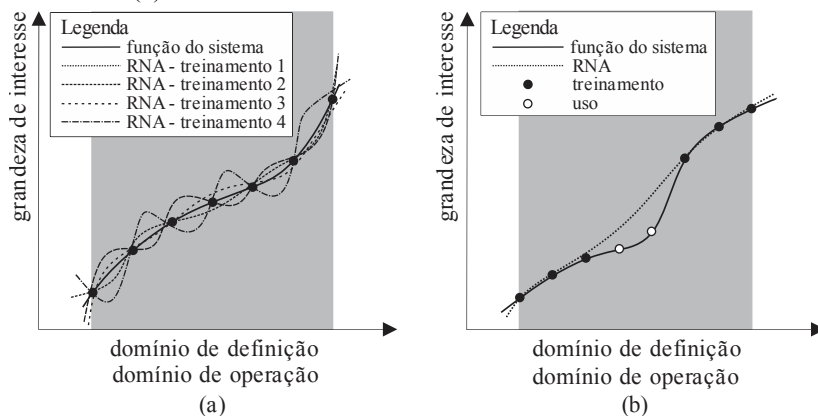
Na grande maioria das publicações disponíveis, a análise dos IC recai comumente sobre dois grupos: imprecisões dos dados de

treinamento; limitações intrínsecas à ferramenta neural (PAPADOPOULOS; EDWARDS, MURRAY, 2000; HAYKIN, 2001).

Na visão dos autores supracitados, mesmo com a escolha de uma solução apropriada²⁰ à complexidade do problema, dois aspectos ainda podem ser determinantes nas limitações da ferramenta neural: processo de otimização; incompletude do conjunto de treinamento. A compreensão dos seus efeitos, em separado, requer algumas considerações adicionais, visto que na prática são pouco dissociáveis.

Mesmo que os dados de treinamento sejam isentos de erros e representem bem o sistema sob mapeamento, não se pode garantir que o algoritmo de aprendizagem convirja para um ponto de mínimo global da função de erro. A natureza aleatória com que os parâmetros livres são estabelecidos e ajustados pode conduzir a resultados diferentes, para um mesmo conjunto de treinamento. O erro decorrente do processo de otimização é preponderantemente aleatório, como sugere a figura 13(a). Na imagem estão representadas respostas distintas de uma mesma RNA, que podem ser obtidas a cada processo de aprendizagem, em comparação com a função que descreve o sistema modelado.

Figura 13 – Erro de otimização (a) e erro por incompletude do conjunto de treinamento (b).



Fonte: Autor.

De modo geral, dificilmente se conseguem amostras suficientes para representar de maneira completa a região de definição da rede, e a maneira como ela responderá à incompletude de seu domínio é incerta.

²⁰ Nessa abordagem, considera-se que o modelo neural empregado seja adequado à complexidade do problema e a exatidão requerida. Não é objetivo deste trabalho lidar eventuais parcelas sistemáticas de erro inseridas por modelos inapropriados.

Dessa forma, mesmo que se atinja o mínimo global, não se pode assegurar que se tenha obtido a melhor solução. O erro associado é predominantemente sistemático, como se pode intuir da figura 13(b).

O conjunto de treinamento é tipicamente impreciso. Os erros podem ser atribuídos a diversas fontes, dentre elas aquelas provenientes das medições dos dados, necessárias para extraí-los dos sistemas físicos. Em um problema de aproximação, por exemplo, a memorização excessiva de dados ruidosos afasta consideravelmente a função modelada da aplicação real (HAYKIN, 2001; PAPADOPOULOS; EDWARDS, MURRAY, 2000; 2001).

As abordagens tipicamente empregadas para considerar esses dois aspectos – limitações do modelo neural e imprecisões dos dados de treinamento – são limitadas. Uma análise mais consistente, que pretenda estar alinhada aos preceitos metrológicos vigentes, deve considerar outros aspectos relevantes (CORAL, 2014; CORAL *et al*, 2015).

Dados de medição contêm parcelas sistemáticas²¹ e aleatórias de erro (ALBERTAZZI; SOUZA, 2008; BIPM, 2008a); porém, segundo Coral (2014) e Coral *et al* (2015), os métodos para caracterização do IC de RNA consideram exclusivamente a componente aleatória. As parcelas sistemáticas podem ser reduzidas a um mínimo aceitável, o que nem sempre é realizado. Nesses casos, seus efeitos também devem ser considerados na análise da incerteza das respostas das redes.

As características metrológicas dos sistemas de medição usados para obtenção dos dados do conjunto de treinamento podem não corresponder às daqueles empregados no uso das redes. Desse modo, uma avaliação mais criteriosa deve levar em conta a influência das incertezas de ambos os conjuntos de dados. Tal condição só foi identificada nas abordagens de Coral (2014) e Coral *et al* (2015).

A tabela 7 resume as fontes de erros que podem ser significativas no desenvolvimento e uso de uma RNA, conforme argumentações desta seção. A divisão sugerida para as fontes, entre dados de medições e etapa de aprendizagem, objetiva facilitar a identificação de estratégias capazes de considerar os erros decorrentes. Assim, a tabela 7 deverá ser útil para abalizar a capacidade dos métodos, apresentados nas seções seguintes (4.3 a 4.5), em expressar incertezas de modelos neurais.

É sempre válido destacar que essa abordagem é procedente, tão somente, quando o domínio de uso da rede estiver contido na região em que ela foi treinada (SILVA; SPATTI; FLAUZINO, 2010).

²¹ Considera-se que medições realizadas com esse objetivo estejam sempre livres de erros grosseiros, por esse motivo elas não são consideradas nesta abordagem.

Tabela 7 – Fontes de erros que podem ser significativas no treinamento e uso de RNA.

	erro aleatório	erro sistemático não compensado
dados de medições		
treinamento da RNA		
exemplos de entrada	sim	sim
exemplos de saída	sim	sim
uso da RNA		
dados de entrada	sim	sim
aprendizagem		
processo de otimização	sim	não
incompletude do conjunto de treinamento	não	sim

Fonte: Adaptada de Coral (2014).

4.3. ABORDAGEM POR MÚLTIPLAS REDES

O desempenho de uma RNA é fortemente dependente das limitações da ferramenta neural empregada. Como visto na seção anterior, devido às características inerentes ao processo de aprendizagem, as respostas da rede podem apresentar efeitos aleatórios, como aqueles ilustrados na figura 13(a).

No âmbito da metrologia, considera-se que o erro aleatório pode ser minimizado, embora não possa ser totalmente compensado. Para diminuí-lo, recomenda-se aumentar o número de observações da grandeza de interesse (BIPM, 2008a). De modo semelhante, os efeitos aleatórios das respostas das redes podem ser minimizados, a partir da consideração de um número maior de respostas, suficientemente distintas²², para o mesmo problema (WOLPERT, 1992).

Como no análogo procedimento metrológico (BIPM, 2008a), a consideração de um número maior de observações deve representar melhor o resultado que uma observação única, o que pode conferir maior robustez ao resultado. Adicionalmente, a variabilidade

²² No âmbito deste trabalho, as respostas de diferentes redes treinadas com o mesmo objetivo são ditas “suficientemente distintas”, quando a proximidade delas caracterizar efeito aleatório.

característica da série de observações pode ser considerada uma medida da incerteza do valor médio, devida aos efeitos aleatórios.

Depois de treinadas, as RNA do tipo *MLP*, por exemplo, são estanques, visto que seus parâmetros permanecem fixos durante o uso. Dessa forma, a partir de um mesmo conjunto de entrada não se consegue obter resultados diferentes na saída. Logo, a aplicação dessa estratégia, no caso das RNA, requer o uso de outro recurso, que possibilite obter as respostas com grau de distinção necessário. Tal recurso pode ser intuído da própria natureza do problema de aleatoriedade.

Retomando a situação ilustrada pela figura 13(a), observa-se que uma rede treinada a partir do mesmo conjunto de dados pode produzir resposta distinta a cada processo de aprendizagem (HAYKIN, 2001). Estabelecer uma ferramenta composta por redes desse tipo pode, então, considerar o efeito aleatório gerado pelo treinamento, e a combinação das suas respostas possibilita minimizar tal efeito (TIBSHIRANI, 1994). A abordagem por múltiplas redes também possibilita estimar intervalos de confiança que levem em conta os efeitos aleatórios dos dados de treinamento e do processo de otimização, além de considerar a incompletude do conjunto de treinamento, na etapa de aprendizagem (PAPADOPOULOS; EDWARDS, MURRAY, 2001).

4.3.1. Ensemble - compensação parcial de erros aleatórios

A ideia de obter melhor desempenho final a partir da combinação de redes não é recente, como sugerem os trabalhos de Ablow e Kaylor (1965), Nilsson (1965) e Bastes e Granger (1968). Entretanto, Barbosa (2009) comenta que foi apenas a partir da penúltima década do século passado que a pesquisa nessa área se intensificou, como retrato da evolução computacional, onde cita os trabalhos de Hansem e Salamon (1990), Schapire (1990), Jacobs *et al* (1991), Wolpert (1992), Perrone e Cooper (1993), Drucker *et al* (1994) e Sharkey e Sharkey (1997).

Mais recentemente, Penz (2011) desenvolveu estratégia baseada em combinados de redes, onde destacou várias referências mais atuais (EDWARDS *et al*, 2002; HU; HWANG, 2002; GRANITTO; VERDES; CECCATTO, 2005; ZIO, 2006; FORTUNA *et al*, 2007; YU; XI, 2009; WU; YU, 2009; TRICHAKIS; NIKOLOS; KARATZAS, 2011), que confirmam a continuidade do interesse dos pesquisadores sobre o assunto.


Segundo Haykin (2001), a combinação de redes constituídas com objetivos comuns constitui uma máquina de comitê, que funde o conhecimento adquirido em cada um deles para chegar a uma solução global supostamente superior àquela alcançável por qualquer um deles

em separado. Bishop (1995) mostrou que a performance do comitê pode ser melhor que a melhor performance individual de qualquer uma das redes constituintes. Tal efeito decorre da compensação parcial de erros, proveniente da combinação individual das saídas das redes que compõem o comitê (TIBSHIRANI, 1994).

O comitê de redes neurais treinadas com o mesmo objetivo pode ser denominado *ensemble*. Nesse sentido, cada elemento do *ensemble* é capaz de realizar sozinho a tarefa do comitê (HANSEN, SALAMON, 1990). Um *ensemble* é uma estrutura estática, onde as respostas dos diferentes modelos são combinadas por um mecanismo que não envolve o sinal de entrada (HAYKIN, 2001). No *ensemble*, as saídas das diferentes redes constituintes são combinadas linearmente para produzir a saída global – razão pela qual a estrutura também pode ser denominada média de *ensemble* (HAYKIN, 2001).

Apesar da inerente desvantagem de considerar que todas as saídas de seus k elementos são igualmente importantes (LIMA, 2004), a média aritmética simples (figura 14) é o método de combinação mais empregado quando os *ensembles* são formados por redes aproximadoras de funções (AHMAD; ZHANG, 2002).

Figura 14 – *Ensemble* baseado em média aritmética simples.



Fonte: Autor.

No *ensemble* as redes são treinadas com o mesmo objetivo, mas deve existir certa diversidade entre elas para que possam produzir resultados suficientemente diferentes, que, quando combinados, tragam

algum ganho, em relação ao comportamento individual. Segundo Sharkey (1999), a diversidade em um *ensemble* pode ser alcançada por meio de quatro diferentes formas: variação dos pesos iniciais; variação da topologia; variação do algoritmo de aprendizagem; variação do conjunto de treinamento.

Normalmente, a diversidade do *ensemble* é obtida por meio de técnicas de modificação do conjunto de treinamento. Segundo Barbosa (2009), uma das técnicas que tem uso mais difundido, também aplicável aos selecionados de *MLP*, é o *bagging* (acrônimo de *bootstrap aggregating*).

4.3.2. Bootstrap - representação da incerteza do processo de aprendizagem

Segundo Ferreira (2012), a metodologia *bootstrap* surgiu como alternativa para análise de situações em que inferências estatísticas são realizadas a partir de amostras não suficientemente grandes.

A metodologia foi desenvolvida por Efron (1979) e consiste em considerar que a população em estudo pode ser representada por uma determinada amostra, desde que ela seja representativa. Essa condição permite que a partir dessa amostra original se obtenham novas amostras, selecionadas aleatoriamente e com reposição. Tais amostras resultantes são denominadas réplicas *bootstrap* e, na prática, representam diferentes situações experimentais.

Formalmente, as réplicas *bootstrap* de um conjunto de amostras de tamanho M , $A = \{A_1, A_2, A_3, \dots, A_m\}$, são subconjuntos também de tamanho M , $Z(k) = \{Z_{1,k}, Z_{2,k}, Z_{3,k}, \dots, Z_{m,k}\}$, criados por seleção aleatória, não viciada e com reposição, realizada no conjunto original A , onde B é o número total de réplicas geradas e $k = \{1, 2, \dots, B\}$.

Para cada réplica *bootstrap* é calculada uma estimativa para a estatística de interesse. O conjunto das estimativas *bootstrap* obtidas dá origem à distribuição *bootstrap*, que tem a forma e dispersão aproximada da distribuição amostral. A partir dos resultados podem ser obtidas estimativas da população, possibilitando construir intervalos de confiança fiáveis (GONZÁLEZ-MANTEIGA, SÁNCHEZ, URROZ, 1994). Para o cálculo das estimativas de *bootstrap*, cem réplicas geralmente são suficientes²³ ($B = 100$). Entretanto, para determinar a distribuição por

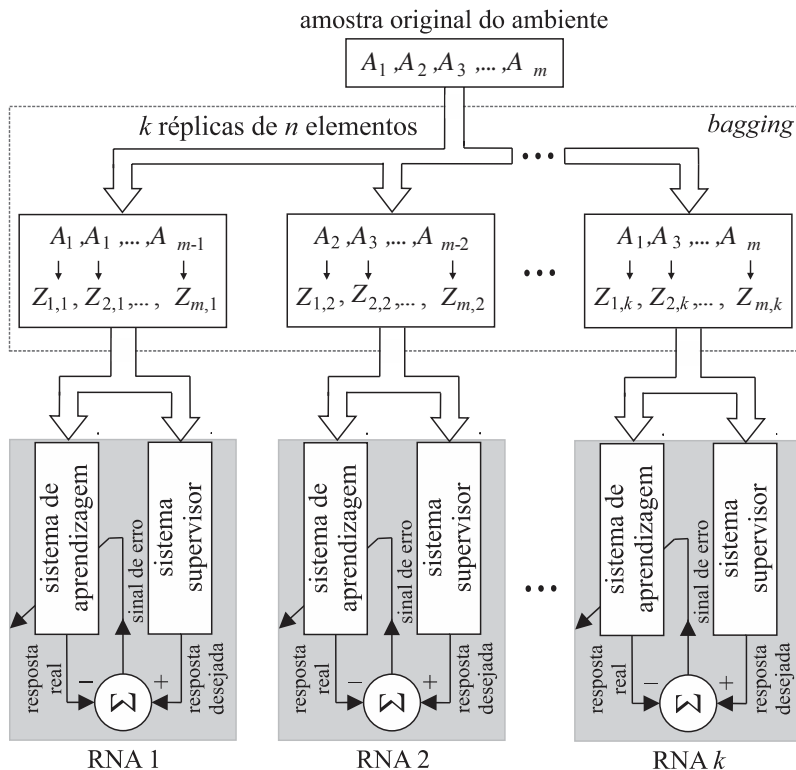
²³ O número de reamostragens pode ser estabelecido como função da variação do desvio padrão para a estimativa do parâmetro de interesse, calculado para as reamostras à medida que estas são realizadas (MONTGOMERY; PECK; VINING, 2001).

amostragem com qualidade assegurada, devem ser consideradas pelo menos mil réplicas ($B \geq 1000$) da amostra original (EFRON, TIBSHIRANI, 1986; 1993).

Devido à generalidade da metodologia, o *bootstrap* também é útil na solução de problemas complexos, e tem vasta aplicação em diversas áreas. O seu uso no âmbito das redes neurais, como técnica para gerar diversidade em um *ensemble*, foi veiculado por Breiman (1996). Nesse caso, o *bagging*, ou *bootstrap aggregating*, é uma estratégia baseada na reamostragem dos padrões de treinamento – amostras representativas do processo a ser modelado – de modo a se obter diferentes subconjuntos de treinamento para cada membro do *ensemble*.

Assim, um *ensemble* gerado pelo *bagging* é uma ferramenta de componentes treinados a partir de versões *bootstrap* do conjunto original de dados de treinamento, conforme ilustrado pela figura 15.

Figura 15 – Aplicação da técnica *bagging* ao treinamento supervisionado de elementos de um *ensemble*.



Fonte: Autor.

A resposta obtida pela combinação linear das saídas das diferentes redes constituintes do *ensemble*, gerado a partir das réplicas *bootstrap*, tem qualidade superior à solução individual dos seus componentes – propriedade característica das máquinas de comitê (BISHOP, 1995). Da variabilidade em torno dessa solução, obtém-se a variância, que possibilita estimar o IC associado. Parcela dessa variância decorre da propriedade do selecionado de trazer consigo os efeitos da aleatoriedade do processo de otimização.

Os conjuntos de treinamento gerados são aleatórios. Como a seleção é com reposição, a grande maioria deles deve conter dados repetidos. Repetir alguns significa não incorporar outros. De certa forma, então, inúmeras redes do selecionado estarão lidando com “incompletudes” em relação ao conjunto original. Segundo Coral (2014) e Coral *et al* (2015), a aleatoriedade da seleção também pode inserir no *ensemble* a variabilidade inerente aos dados do conjunto de treinamento original. Essas duas características também influenciam a variância.

Decorre das observações sobre a variância que os intervalos de confiança estimáveis podem levar em conta os efeitos aleatórios dos dados de treinamento e do processo de otimização, além de considerar a incompletude do conjunto de treinamento (PAPADOPOULOS; EDWARDS, MURRAY, 2000; 2001), como sintetizado na tabela 8.

Tabela 8 – Erros considerados pelo método *ensemble* gerado pelo *bagging*.

	erro aleatório	erro sistemático não compensado
dados de medições		
treinamento da RNA		
exemplos de entrada	considera	não considera
exemplos de saída	considera	não considera
uso da RNA		
dados de entrada	não considera	não considera
aprendizagem		
processo de otimização	considera	não se aplica
incompletude do conjunto de treinamento	não se aplica	considera

Fonte: Coral (2014).

Como a diversificação do *ensemble*, nesse caso, decorre da variação do conjunto de treinamento, tomado como réplicas do conjunto original, não existe possibilidade de considerar o erro sistemático não

compensado dos dados. Da mesma forma, não se identificou qualquer referência à empregabilidade desse método durante o uso das RNA.

Na seção seguinte, avaliam-se métodos capazes de considerar erros relacionados à utilização dos modelos neurais.

4.4. AVALIAÇÃO DAS INCERTEZAS PELO *GUIA*

O Guia para Expressão de Incerteza de Medição, do inglês *Guide to the Expression of Uncertainty in Measurement* (GUM) – comumente denominado apenas como *Guia* – é resultado de um esforço da comunidade metrológica internacional para estabelecer regras gerais para avaliação e expressão de incerteza de medição (IM). Nesse contexto foram propostos dois métodos, um analítico e outro numérico, ambos apoiados na propagação de parâmetros estatísticos das grandezas de entrada, através do modelo matemático associado à medição. O primeiro, dado pelo documento *JCGM 100* (BIPM, 2008a), baseia-se na propagação das incertezas, e é realizável por meio de manipulações algébricas. O segundo, amparado pelo documento *JCGM 101* (BIPM, 2008b), fundamenta-se na propagação das distribuições de probabilidades, e é efetuado por meio de simulações numéricas.

As redes *perceptron* multicamadas (*MLP*) investigadas no capítulo anterior, quando empregadas como ferramentas aproximadoras, são funções matemáticas com parâmetros bem definidos. Nesse aspecto, quando usadas para inferir o valor de uma grandeza, elas mesmas podem ser interpretadas como modelos matemáticos da medição, estando sujeitas às avaliações de incerteza propostas, tanto pelo método analítico clássico (BIPM, 2008a) quanto pelo método numérico (BIPM, 2008b).

A representação da medição por meio de modelo matemático adequado é de importância crítica para a aplicação dos métodos propostos nessa abordagem. O *Guia* assume que tal representação é possível até o grau imposto pela exatidão requerida na medição. Adicionalmente, orienta que o modelo matemático estabelecido deve ser revisado sempre que os dados observados mostrarem que ele está incompleto (BIPM, 2008a). Da mesma forma, estendê-la às RNA pressupõe escolha de arquiteturas apropriadas e reavaliação periódica, sempre que for possível submetê-las a exemplos rotulados atuais.

4.4.1. Método clássico ou de propagação de incertezas

Na maioria das vezes em que não é medido de forma direta, o mensurando y é obtido a partir de outras grandezas x_1, x_2, \dots, x_n , por uma

relação funcional $y = f(x_1, x_2, \dots, x_n)$. A incerteza de y , quando estimada pela combinação das incertezas padrão das entradas x_1, x_2, \dots, x_n , é denominada incerteza padrão combinada $u_c(y)$, que pode ser formalmente representada por (16) (BIPM, 2008a),

$$u_c(y) = \sqrt{\sum_{i=1}^n \left(\frac{\partial f}{\partial x_i} \right)^2 u_{x_i}^2}, \quad (16)$$

onde:

$u_c(y)$ é a incerteza padrão combinada do mensurando y ;

u_{x_i} é a incerteza padrão da grandeza de entrada x_i ;

$\frac{\partial f}{\partial x_i}$ é o coeficiente de sensibilidade da grandeza x_i .

Quando se faz possível atender as condições de aplicabilidade do Teorema Central do Limite²⁴, pode-se assumir que a distribuição da grandeza de saída tenha o formato de uma curva normal, com $u_c(y)$ denotando o seu desvio padrão. Na prática, deve-se expressar a incerteza de y com probabilidade de abrangência maior que a representada por $u_c(y)$, que é de 68,2%. Tipicamente a IM é apresentada com 95%, o que pode ser obtido por meio de (17),

$$U_{95\%} = k u_c(y), \quad (17)$$

onde:

$U_{95\%}$ é a incerteza expandida para uma probabilidade de 95%;

k é o fator de abrangência da distribuição de probabilidade *t-student*²⁵.


Exemplos de aplicação do método clássico às redes neurais podem ser encontrados em Zhu *et al* (2005), para funções de base radial, e em Gusman (2011), para redes *perceptron* multicamadas.

Em Gusman (2011), considera-se um mapeamento entrada-saída realizado por um *MLP* 2-2-1, ou seja, com duas unidades sensoriais, dois neurônios em camada oculta única e uma só saída, com funções de ativação diferenciáveis, conforme ilustrado pela figura 16.

²⁴ O Teorema Central do Limite é aplicável em alguns problemas práticos, desde que sejam observadas certas condições, como a existência de um número significativo de grandezas de influência não correlacionadas (DONATELLI, KONRATH, 2005).

²⁵ O fator de abrangência k é função do número efetivo de graus de liberdade de $u_c(y)$ e pode ser obtido da chamada fórmula de Welch-Satterthwaite (BIPM, 2008a).

Figura 16 – Rede MLP 2-2-1.



Fonte: Adaptado de Gusman (2011).

Em consonância com a equação (6), apresentada na seção 3.3, o mapeamento considerado pode ser descrito por (18),

$$y = f(x_1, x_2) = \varphi(b_1^{(2)} + w_{1,1}^{(2)}\varphi(b_1^{(1)} + w_{1,1}^{(1)}x_1 + w_{1,2}^{(1)}x_2) + w_{1,2}^{(2)}\varphi(b_2^{(1)} + w_{2,1}^{(1)}x_1 + w_{2,2}^{(1)}x_2)) \quad (18)$$

onde:

- y é a saída da rede;
- f é a função realizada pela rede;
- x_i é a i -ésima entrada da rede;
- φ é a função de ativação não linear diferenciável;
- $b_j^{(k)}$ é o bias da k -ésima camada;
- $w_{j,i}^{(k)}$ é o peso da sinapse j - i na k -ésima camada.

Como se pode observar na equação (16), a estimativa da incerteza padrão combinada de y requer o cômputo dos coeficientes de sensibilidade das grandezas de entrada x_1 e x_2 , que podem ser obtidos, respectivamente, pelas equações (19) e (20):

$$\frac{\partial(x_1, x_2)}{\partial x_1} = \varphi'(x_1) \left(w_{1,1}^{(2)} \varphi'(x_1) w_{1,1}^{(1)} + w_{1,2}^{(2)} \varphi'(x_1) w_{2,1}^{(1)} \right); \quad (19)$$

$$\frac{\partial(x_1, x_2)}{\partial x_2} = \varphi'(x_2) \left(w_{1,1}^{(2)} \varphi'(x_2) w_{1,2}^{(1)} + w_{1,2}^{(2)} \varphi'(x_2) w_{2,2}^{(1)} \right). \quad (20)$$

Os coeficientes de sensibilidade decorrem das derivadas parciais da grandeza de saída em relação a cada uma variável de entrada, e podem resultar em expressões muito longas, mesmo para estruturas simplificadas, como o *MLP 2-2-1* considerado no exemplo. Na prática, redes neurais não são modelos matemáticos tradicionais e o tamanho que podem assumir, diante de problemas mais complexos, pode inviabilizar a aplicação da metodologia analítica sugerida pelo *Guia* (GUSMAN, 2011). Ademais, as condições para a aplicação do Teorema Central do Limite também são bastante restritivas e o uso desse método pode resultar em incertezas pouco realistas (DONATELLI, KONRATH, 2005). Nesse caso, o próprio *Guia* recomenda que a avaliação seja feita por meio de método numérico (BIPM, 2008b).

4.4.2. Método de Monte Carlo ou de propagação de distribuições

O método sugerido em *JCGM 101* (BIPM, 2008b) possibilita avaliar a distribuição das respostas do modelo matemático sob análise, por meio da combinação de um número adequado de amostras aleatórias das grandezas de entrada, respeitando as suas distribuições.

O método pressupõe, como no caso anterior, que o mensurando seja obtido por meio de uma relação funcional $y = f(x_1, x_2, \dots, x_n)$, e que as funções de distribuição de probabilidade das grandezas x_1, x_2, \dots, x_n sejam conhecidas.

Por considerar que todos os possíveis valores que cada uma das grandezas de entrada pode assumir, sob determinada distribuição, são igualmente válidos, o método também considera válidas todas as estimativas decorrentes para o mensurando (BIPM, 2008b). De modo formal, tais estimativas podem ser expressas por (21),

$$y_i = f(x_{1,i}, x_{2,i}, \dots, x_{n,i}) = f(g_{x_1}(\xi_1), g_{x_2}(\xi_2), \dots, g_{x_n}(\xi_n)), \quad (21)$$

onde:

- y_i é o valor da i -ésima estimativa de y ;
- $x_{k,i}$ é a i -ésima amostra da k -ésima grandeza;
- g_{x_k} é o valor da função densidade de probabilidade da k -ésima grandeza;;
- ξ_k denota todos os possíveis valores da k -ésima grandeza x .


Dessa forma, obtém-se um vetor de saída $\mathbf{y} = (y_1, y_2, \dots, y_m)$, de tamanho M , a partir do qual se pode aproximar uma função de

distribuição acumulada. A qualidade da aproximação decorre fortemente do tamanho de y e é decisiva na obtenção dos parâmetros estatísticos de interesse, como média e desvio padrão, e IM associada (DONATELLI, KONRATH, 2005). Segundo o *Guia* (BIPM, 2008b), boas aproximações são geralmente obtidas a partir de um milhão de simulações ($M = 10^6$).

A tarefa numérica para extrair as amostras aleatórias, das distribuições de probabilidade das grandezas consideradas, é comumente denominada simulação de Monte Carlo (SMC)²⁶. Resumidamente, nesse método, as SMC propagam as *PDF* das grandezas de entrada pelo modelo matemático da medição, gerando uma distribuição que descreve os valores do mensurando e a incerteza associada (BIPM, 2008b).

Assim como o método clássico propaga as incertezas, o método de Monte Carlo (MMC) pode ser empregado para propagar as distribuições das entradas para a saída da RNA, como ilustrado na figura 17. A cada SMC é gerado um conjunto de valores aleatórios para as entradas da RNA, com base nas *PDF* de cada grandeza considerada. Ao final do processo, obtém-se a *PDF* associada ao vetor y , de onde se pode obter a estimativa de y e sua incerteza (CORAL, 2014; CORAL *et al*, 2015). Mesmo sem fazer qualquer referência ao *Guia* ou ao documento *JCGM 101* (BIPM, 2008b), outros autores, como Colorado *et al* (2011) e Ablameyko *et al* (2003), divulgaram resultados de trabalhos onde empregaram SMC para estimar a dúvida na saída de uma RNA.

Figura 17 – Aplicação do método de Monte Carlo para propagar as *PDF* através de uma rede neural.



Fonte: Adaptado de Coral (2014).

²⁶ Os matemáticos Neumann e Ulam são considerados os principais autores da técnica de SMC, em trabalhos que remontam à metade do século passado (ECKHARDT, 1987).

De maneira geral, além de dispensar os cálculos de derivadas parciais e ser aplicável sob outras condições que limitam o uso do método clássico, o MMC tem a grande vantagem adicional de possibilitar avaliação mais adequada da incerteza expandida, mesmo que a distribuição que representa os possíveis valores do mensurando não seja uma normal (DONATELLI, KONRATH, 2005; BIPM, 2008b).

Apesar de permitir maior flexibilização no cômputo da incerteza, em relação ao método clássico, o MMC também apresenta algumas desvantagens, como o altíssimo número de iterações, que podem dificultar, ou até inviabilizar, sua aplicação em alguns casos. No âmbito deste trabalho, o aspecto limitante é comum ao método clássico: ambos não permitem considerar outras fontes de erro capazes de influenciar no resultado da rede, conforme destacado na tabela 9.

Tabela 9 – Erros considerados na avaliação das incertezas pelo *Guia*.

	erro aleatório	erro sistemático não compensado
dados de medições		
treinamento da RNA		
exemplos de entrada	não considera	não considera
exemplos de saída	não considera	não considera
uso da RNA		
dados de entrada	considera	considera
aprendizagem		
processo de otimização	não considera	não se aplica
incompletude do conjunto de treinamento	não se aplica	não considera

Fonte: Coral (2014).

Nesta seção (4.4) e na anterior (4.3), apresentam-se métodos aplicáveis à avaliação da incerteza em modelos neurais, e destacam-se suas limitações em uso individualizado. Na sequência, mostra-se o ganho decorrente do uso combinado desses métodos, em ferramenta que se convencionou chamar de método MMC-*bagging* hibridizado.

4.5. MÉTODO MMC-BAGGING HIBRIDIZADO

Na seção 4.2, discorreu-se sobre fontes de erros que podem ser significativas no desenvolvimento e uso de redes neurais artificiais. Os erros decorrentes das fontes consideradas – imprecisões dos dados e

limitações do modelo neural – possuem componentes aleatórios e sistemáticos que devem ser considerados em avaliações de incerteza, especialmente naqueles que pretendam estar alinhados aos preceitos metroológicos vigentes.

Além do método proposto por Coral (2014) e Coral *et al* (2015), não se encontrou na literatura outro meio, metrologicamente mais confiável, que permitisse considerar todos os erros conjuntamente, na definição da dúvida relacionada aos resultados das RNA.

Um *ensemble*, gerado a partir de réplicas *bootstrap*, tem boa abrangência em relação aos efeitos das fontes apontadas na tabela 7, como se pode observar na tabela 8. Por meio desse método, pode-se considerar a incompletude do conjunto de treinamento, bem como a contaminação de seus elementos por erros aleatórios. As características gerais do *ensemble* levam em conta, adicionalmente, os efeitos do processo de otimização. Entretanto, além de não considerar os efeitos sistemáticos não compensados dos dados de treinamento, o método não é aplicável aos dados de entrada, durante o uso da rede.

O método de Monte Carlo, assim como o método clássico, considera apenas os componentes aleatórios e sistemáticos dos erros de medição dos dados empregados no uso das RNA. Apesar de ser amparado pelo *Guia*, o que assegura confiabilidade metroológica ao método, não se identificou referência à sua aplicação direta às outras fontes, também capazes de influenciar nos resultado das redes.

O uso concomitante dos dois métodos, da forma como foram concebidos e tipicamente empregados, ainda não contemplaria os erros sistemáticos não compensados, dos dados de treinamento.

O modelo de avaliação da incerteza proposto por Coral (2014) e Coral *et al* (2015), aqui denominado método MMC-*bagging* hibridizado, leva em conta os dois métodos anteriores, ampliando a aplicação do MMC, estendendo-a aos dados de treinamento. Dessa forma, torna-se possível considerar também os efeitos sistemáticos não compensados desses dados, na estimativa da incerteza.

Tanto os dados de treinamento quanto os dados submetidos à rede durante o uso são geralmente obtidos do ambiente a partir de medições. Logo, a mesma justificativa, do ponto de vista da metrologia, que assegura o uso do MMC na etapa de uso, deve amparar sua aplicação na etapa de aprendizagem das redes neurais (CORAL, 2014).

Pressupõe-se, como em 4.4.2, que as funções de distribuição de probabilidade (*PDF*) das grandezas de entrada $\{x_1, x_2, \dots, x_n\}$ sejam conhecidas. Adicionalmente, como se trata de um conjunto de treinamento, composto de exemplos rotulados, também se faz necessário

conhecer a *PDF* da grandeza de saída (admitindo-se, para o exemplo, *ensemble* constituído de redes de saída única).

Considerando-se que a representação do processo seja dada por um conjunto de amostras $A = \{A_1, A_2, \dots, A_m\}$, onde cada elemento é um exemplo rotulado $A_q = \{x_{1,q}, x_{2,q}, \dots, x_{n,q}, y_q\}$, $q = (1, 2, \dots, m)$, admite-se que cada conjunto decorrente da simulação de Monte Carlo²⁷ (SMCt), $SMCt(A_q) = \{g_{x_{1,q}}(\xi_1), g_{x_{2,q}}(\xi_2), \dots, g_{x_{n,q}}(\xi_n), g_{y_q}(\xi)\}$, seja tão válido quanto o conjunto A_q que lhe deu origem. Partindo-se desse pressuposto, pode-se admitir que cada conjunto de treinamento simulado $SMCt_j(A) = \{SMCt_j(A_1), SMCt_j(A_2), \dots, SMCt_j(A_m)\}$, $j = (1, 2, \dots, k)$, também seja tão válido quanto o conjunto original A (CORAL, 2014).

Para possibilitar melhor interpretação da figura 18, que ilustra a etapa de aprendizado para o primeiro elemento do selecionado proposto por Coral (2014), denotam-se por $g_{x_{i,q-j}}(\xi_i)$ e $g_{y_{q-j}}(\xi_q)$ os elementos resultantes das j -ésimas SMCt, aplicadas ao q -ésimo exemplo rotulado do conjunto de amostras A , associado as *PDF* da i -ésima grandeza de entrada x e da q -ésima grandeza de saída y , respectivamente.

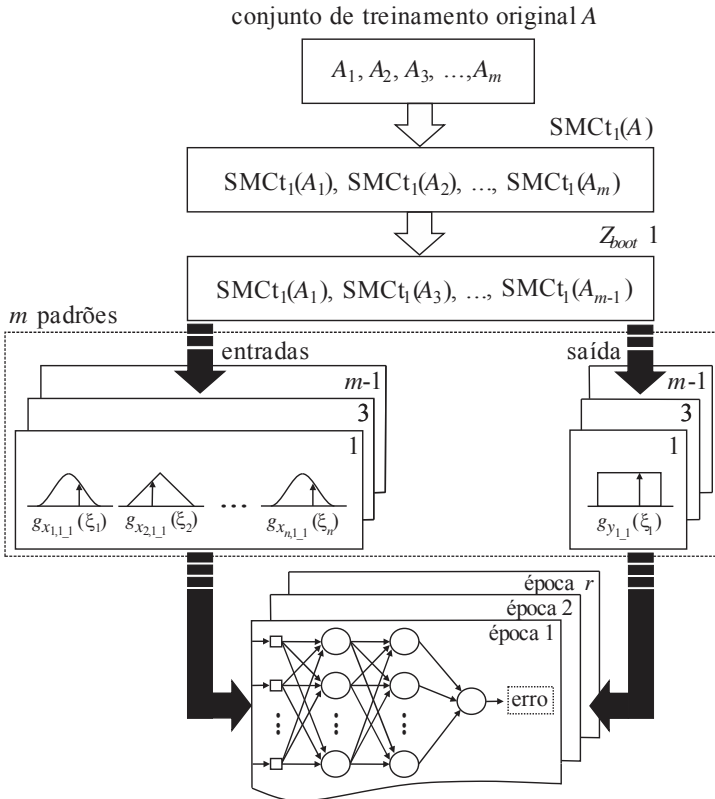
A preparação dos dados para o treinamento de cada elemento constituinte do MMC-*bagging* consiste em gerar um conjunto $SMCt(A)$ e empregar a metodologia *bootstrap* sobre ele, que deve resultar em conjunto Z_{boot} , com o mesmo número de elementos do conjunto original A . A partir de Z_{boot} , treina-se a rede preestabelecida. O processo deve ser repetido k vezes, resultando em uma estrutura com k RNA.

Como visto em 4.3.2, boas aproximações são obtidas pelo *bagging*, a partir de mil réplicas *bootstrap* ($k \geq 10^3$). Entretanto, o *Guia* (BIPM, 2008b) recomenda que sejam feitas um milhão de SMC para efetividade do MMC ($k \geq 10^6$), o que demandaria grande esforço computacional durante o treinamento. A solução para esse problema é uma vantagem adicional do método proposto. Os autores (CORAL, 2014; CORAL *et al*, 2015) consideraram que um número satisfatório de simulações poderia ser alcançado, dividindo sua obtenção em duas etapas do processo: treinamento (SMCt); uso (SMCu). Como os dados empregados nas duas fases são semelhantes, além das k SMCt, admite-se fazer p simulações de Monte Carlo (SMCu) sobre cada conjunto de

²⁷ Para facilitar o entendimento, a partir desta seção serão denotadas por SMCt e SMCu as simulações de Monte Carlo associadas ao treinamento e ao uso das redes neurais, respectivamente.

entrada $\{x_1, x_2, \dots, x_n\}$, durante o uso da rede, como ilustrado na figura 19.

Figura 18 – Etapa de treinamento do primeiro elemento do selecionado proposto no MMC-*bagging*.




Fonte: Autor.

Dessa forma, o MMC-*bagging* hibridizado considera k SMCt (e réplicas *bootstrap* decorrentes) para o treinamento das k redes constituintes, processando p SMCu durante o uso, envolvendo um total de $k.p$ SMC. Fazendo k e $k.p$ próximos de 10^3 e 10^6 , respectivamente, atendem-se os requisitos dos métodos integrantes. Essa solução possibilita diminuir substancialmente o tempo de processamento da aplicação (CORAL, 2014; CORAL *et al*, 2015).

Ao final do processo, obtêm-se p saídas Y_1, Y_2, \dots, Y_p , com k resultados cada, como ilustrado na figura 19. A distribuição resultante da combinação dessas saídas, Y_{pk} , possibilita estimar a grandeza de

interesse, com maior precisão, e a sua incerteza, com maior confiabilidade (CORAL, 2014).

Figura 19 – Etapa de uso do método MMC-*bagging* hibridizado.



Fonte: Adaptado de Coral (2014).

Conforme se resume na tabela 10, o método proposto por Coral (2014) e Coral *et al* (2015) leva em conta todos os erros identificados na seção 4.2. A amostragem com reposição do *bagging* (e *ensemble* associado) permite considerar os erros devidos à incompletude do conjunto de treinamento e ao processo de otimização. De modo complementar, as SMCT propagam as distribuições do conjunto de treinamento, permitindo considerar os erros aleatórios e sistemáticos não

compensados dos seus dados. Da mesma forma, as SMCu permitem considerar tais erros de medição durante a aplicação das redes.

Tabela 10 – Erros considerados pelo método MMC-*bagging* hibridizado.

	erro aleatório	erro sistemático não compensado
dados de medições		
treinamento da RNA		
exemplos de entrada	considera	considera
exemplos de saída	considera	considera
uso da RNA		
dados de entrada	considera	considera
aprendizagem		
processo de otimização	considera	não se aplica
incompletude do conjunto de treinamento	não se aplica	considera

Fonte: Coral (2014).

Em sua tese de doutorado, Coral (2014) realizou vários experimentos que mostram as limitações dos métodos, quando utilizados separadamente, e a sua eficácia, quando usados da forma apresentada nesta seção. Vale destacar, entretanto, que a viabilidade da proposta requer o conhecimento da IM de cada dado utilizado, bem como da sua respectiva *PDF*.

4.6. CONSIDERAÇÕES

O capítulo anterior está pautado em referencial teórico sobre recursos de inteligência artificial aplicáveis ao problema de aproximação de funções não lineares, que permeia a proposta de solução apresentada no âmbito deste trabalho de tese. Além de uma breve caracterização das RNA, destacaram-se ferramentas usualmente empregadas como “aproximadoras”, bem como algoritmos de aprendizagem compatíveis com as aplicações.

O capítulo atual decorreu da necessidade de identificar método metrologicamente embasado para estimar a incerteza da medição associada à saída de redes *MLP*, requisito essencial para aplicação de RNA em processos metroológicos. A literatura analisada durante o desenvolvimento deste trabalho permitiu caracterizar o estado da arte em estimativa de intervalos de confiança para saídas de modelos baseados nas redes *MLP*, consideradas na proposição deste trabalho.

É válido destacar, novamente, que os resultados apontados neste capítulo são válidos apenas para condição de uso que envolva escolha apropriada de topologia de rede, bem como domínio de operação que esteja contido na região de definição das RNA envolvidas.

No capítulo seguinte, avaliam-se os níveis de correlação entre resultados de ensaios realizados em laboratório e testes típicos de linhas de produção de compressores. São discutidas as propostas do trabalho de tese e é apresentada a forma de encaminhamento da solução.

5. PROPOSTA DE FERRAMENTAS NEURAIIS PARA CONTROLE DA QUALIDADE DE COMPRESSORES

5.1. INTRODUÇÃO

Dois mecanismos importantes para controle da qualidade de compressores são os ensaios de desempenho (2.2) e o de mínima tensão de partida (2.3). Entretanto, ambos não têm aplicações diretas em linhas de produção com elevado fluxo produtivo, devido ao custo envolvido e longo tempo demandado para a realização. Normalmente são feitos em condições laboratoriais, para pequenas amostras dos lotes de produção.

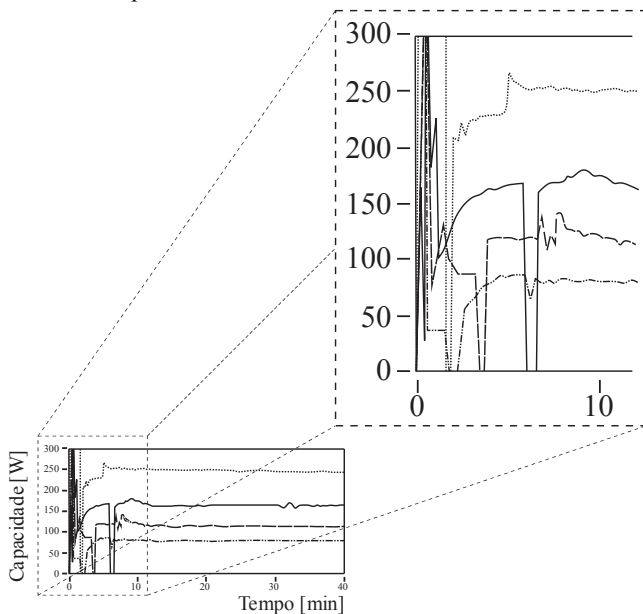
Os ensaios de desempenho demandam normalmente mais de quatro horas para serem realizados, função do longo intervalo de tempo necessário para a estabilização de um determinado número de grandezas, que pode ser superior a três horas. Os ensaios de mínima tensão de partida (MTP) abordados neste trabalho requerem, em média, cinquenta minutos para sua execução, devidos, principalmente, ao intervalo de tempo de pré-aquecimento dos enrolamentos do motor elétrico associado, que pode representar 80% do tempo total de ensaio para alguns modelos de compressores.

A aplicação de ferramentas de inteligência artificial viabilizou a obtenção de parâmetros de desempenho em tempos médios de uma hora (PENZ, 2011). Da mesma forma, resultados obtidos por Zanol (2015) apontam para possível diminuição do tempo necessário para obtenção dos valores de mínima tensão de partida, de dez minutos para menos de um minuto. Os tempos alcançados, entretanto, ainda são muito superiores ao tempo de ciclo de empresas que trabalham com elevado volume de produção, que pode ser de poucos segundos, como colocado em 2.2.4.

Ainda que Zanol (2015) tenha encaminhado solução que prevê significativa redução no tempo de obtenção dos valores de MTP, sua proposta não considera o tempo de aquecimento inicial das bobinas.

Inferir consumo, capacidade de refrigeração e *COP* a partir dos primeiros segundos do ensaio de desempenho é ainda um grande desafio. Como decorre das observações de autores que propuseram ações nesse sentido (HENKLEIN, 2006; STEINBACH, 2008; LIMA, 2010; PENZ, 2011; CORAL, 2014), os minutos iniciais são caracterizados por forte instabilidade das grandezas de interesse. Na figura 20, pode-se observar o comportamento inicial indefinido da capacidade de refrigeração, para quatro compressores submetidos a ensaios de desempenho, em bancadas de laboratório.

Figura 20 – Comportamento da capacidade de refrigeração nas bancadas de desempenho de compressores.



Fonte: CORAL (2014).

Além da grande dificuldade em diminuir ainda mais os tempos de ensaio, propriamente ditos, existem outros fatores que inviabilizam a aplicação direta dos métodos, apresentados em 2.2 e 2.3, ao controle da qualidade da produção de compressores, especialmente em plantas com elevado volume de produção. Os procedimentos subjacentes aos métodos normalmente empregados requerem o uso de óleo lubrificante e gás refrigerante para os quais os compressores em avaliação foram projetados. Esses dois fatores são bastante limitantes, uma vez que o custo envolvido na reciclagem do fluido refrigerante é alto e nem todos os compressores podem ter contato com óleo de funcionamento durante a produção, por força de cláusulas contratuais.

Atualmente, na empresa que disponibilizou informações para este trabalho, os testes de capacidade de elevação de pressão são os únicos instantes em que o funcionamento do compressor é avaliado como um todo, entretanto, em condições particulares, distintas daquelas realizadas nos ensaios de laboratório. Portanto, não existe ainda qualquer mecanismo que associe seus resultados com os parâmetros de interesse – consumo, *COP* e *MTP* – obtidos nos ensaios de desempenho e mínima

tensão de partida. Assim como não evidenciam diretamente tais parâmetros, também não apresentam, de maneira explícita, informações relevantes para determinação da capacidade de refrigeração, que é outro parâmetro avaliado nos ensaio de desempenho.

Coral (2014) mostrou ser possível estabelecer bons níveis de correlação entre dados de teste de capacidade de elevação de pressão com valores de capacidade de refrigeração. Função de tais níveis estabeleceu ferramenta, baseada em redes neurais artificiais, capaz de realizar inferência da capacidade de refrigeração, com método para estimativa da incerteza associada (4.5) apoiado em preceitos metrologicos vigentes. Face aos resultados publicados por ele, estabeleceram-se as seguintes pressuposições para este trabalho de tese:

- existe correlação entre dados de testes de capacidade de elevação de pressão e consumo (C_o);
- existe correlação entre dados de testes de capacidade de elevação de pressão e COP ;
- existe correlação entre dados de testes de capacidade de elevação de pressão e MTP.

Oportunamente, o autor do presente trabalho propôs implementar junto aos testes de capacidade de elevação, meios para que se torne possível a obtenção de inferência de consumo, COP e MTP na fase de produção. Tais recursos, somados aos resultados de Coral (2014) e Coral *et al* (2015), possibilitarão a avaliação de 100% dos compressores durante a fabricação, permitindo à empresa atuar no processo de modo mais eficiente e também conhecer os parâmetros de desempenho de um lote de compressores sem a necessidade de esperar pelos resultados de laboratórios.

Neste capítulo é apresentado o ensaio de capacidade de elevação de pressão e são caracterizados os parâmetros monitorados durante sua realização. São avaliados os níveis de correlação existentes entre tais parâmetros e os de interesse (consumo, COP e MTP), comumente obtidos em ensaios de laboratório. Adicionalmente, é discutido o encaminhamento das soluções propostas, para as três frentes de trabalho, e são esboçadas as ferramentas neurais subjacentes a elas.

5.2. TESTE DE CAPACIDADE DE ELEVAÇÃO DE PRESSÃO

As linhas de produção de compressores da empresa parceira contam com painéis automatizados, onde atualmente são feitos os testes de capacidade de elevação de pressão. Tais testes atendem ao *lead time*

da empresa e atuam basicamente como ferramenta de classificação: aprovando peças em conformidade com seu funcionamento mecânico e elétrico e, conseqüentemente, reprovando peças não conformes (geralmente com erros grosseiros de montagem). Para a aprovação de uma peça são avaliados: consumo linha²⁸ (potência elétrica consumida pelo compressor), em uma condição bem especificada de pressão na descarga; capacidade de elevação da pressão em um volume conhecido; ruído gerado durante o funcionamento e ruído de parada.

A avaliação da peça em teste depende dos resultados dos 100 compressores de mesmo modelo testados anteriormente no painel. Tanto para a potência elétrica consumida quanto para a capacidade de elevação, processa-se, a cada novo teste, a mediana e o desvio padrão dos dados do histórico, devendo os valores dos parâmetros do compressor avaliado ficar enquadrados em intervalo determinado por três desvios padrões²⁹, conforme informado por especialistas da linha de produção. De modo geral, as peças somente são descartadas após a confirmação dos resultados desfavoráveis em novo ciclo de medições.


O teste de capacidade de elevação de pressão realizado no final das linhas de montagem é denominado MFC (montagem final de compressores). Nessa etapa do processo, o compressor já está pronto para ser embalado. Vale destacar que, para atender ao *lead time* da empresa considerada nesse estudo, em cada um desses pontos realizam-se simultaneamente dois testes de capacidade de elevação de pressão, em estações denominadas A e B, que possuem instrumentações independentes.

O teste de capacidade de elevação, propriamente dito, consiste na imposição de ciclos de distintas pressões (figura 21) aplicadas a um volume conhecido, conectado ao terminal de descarga do compressor. Por meio das diferentes pressões dadas pelo funcionamento do compressor e por uma rede de ar comprimido adjacente a esse volume, diferentes parâmetros são avaliados para determinar se a peça foi fabricada dentro das condições esperadas. Trata-se, portanto, de um teste no qual os componentes que constituem o compressor são ensaiados em conjunto a fim de avaliar rapidamente o funcionamento do produto.

²⁸ O termo “consumo linha” (Col) também será usado para denotar a potência elétrica consumida, obtida no teste de capacidade de elevação. Esse recurso deve ser útil para distingui-lo do “consumo” (Co), obtido em laboratório, no ensaio de desempenho.

²⁹ O número de desvios padrões (tipicamente 3) é definido pelo analista responsável pela produção.


Figura 21 – Perfil típico de pressões de descarga para os ciclos do painel de teste de capacidade de elevação.



Fonte: Autor.

Na figura 22, apresenta-se a representação esquemática do circuito utilizado em painel de teste da linha de produção.

Figura 22 – Compressor sob teste de capacidade de elevação de pressão.



Fonte: Adaptado de Coral (2014).

Na configuração ilustrada (figura 22), uma linha de ar comprimido com volume conhecido e estável é acoplada ao terminal de descarga do compressor. A linha acoplada funciona como um vaso de pressão quando selada e a entrada externa de ar possui duas funções elementares:

- manter a pressão constante em 2 bar durante as medições da potência elétrica consumida pelo compressor (consumo linha – Col) e do ruído associado ao seu funcionamento (Rf), as quais são realizadas simultaneamente em 1,5 s;
- elevar a pressão na linha de descarga até um valor predefinido (7 bar) e logo após selá-la, para que se possa

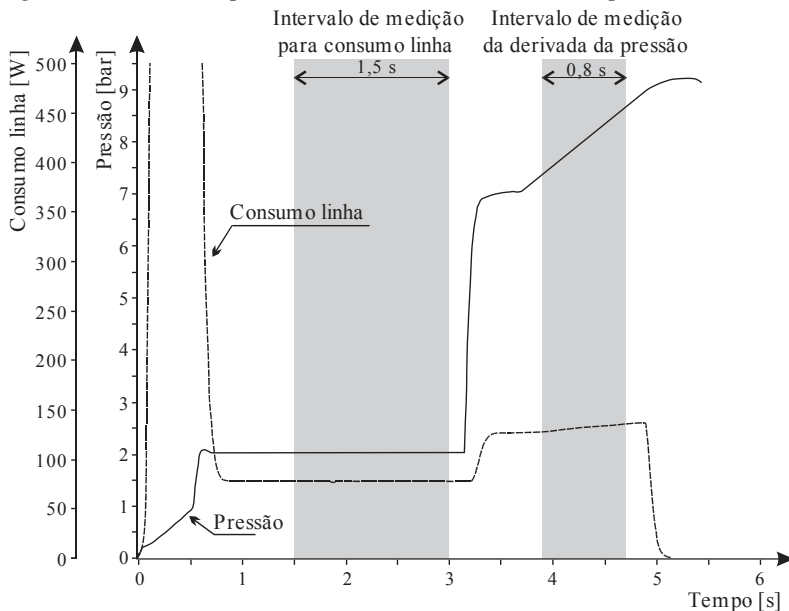
medir a capacidade do compressor sob teste de elevar a pressão sobre o volume conhecido, em intervalo de 0,8 s.

A taxa da elevação da pressão em função do tempo caracteriza a capacidade de elevação de pressão. Para sua determinação são adquiridos 400 valores de pressão durante intervalo de 0,8 s. Por meio do método dos mínimos quadrados se obtém o coeficiente angular da reta associada a esses pontos, que é o valor da capacidade de elevação (CORAL, 2014). O ruído de parada (R_p) é obtido no intervalo de tempo posterior, de 1,5 s.

A pressurização preestabelecida em 7 bar na linha de descarga permite ao compressor em teste operar a partir de pressões mais elevadas, sem ter que realizar trabalho para chegar até elas. Do contrário, o teste exigiria mais tempo do que os atuais 7 segundos necessários para sua execução.

A figura 23 apresenta a resposta de uma peça testada em uma das linhas de produção e seus diferentes ciclos de pressão impostos na descarga do compressor, destacando o comportamento estável e bem definido das curvas em momentos de aquisição de dados de potência elétrica consumida e pressão.

Figura 23 – Curvas de pressão e consumo linha sobre o compressor em teste.



Fonte: Adaptado de Coral (2014).

Durante o teste, além de medir os parâmetros de consumo linha, capacidade de elevação de pressão, ruído de funcionamento e ruído de parada, nas estações de medição também é monitorada a temperatura da carcaça do compressor.

5.3. MEDIÇÃO DA TEMPERATURA DA CARÇAÇA


Os resultados de testes de capacidade de elevação de pressão considerados neste trabalho são decorrentes dos painéis MFC, situados no final de uma das linhas de montagem. No estágio anterior à aplicação dos testes, os compressores são submetidos ao processo de secagem da pintura, em estufa, onde a temperatura da carcaça atinge cerca de 50 °C. Em condições normais de fluxo da linha, os compressores chegam aos painéis MFC um pouco mais resfriados, com temperatura da carcaça próxima aos 46 °C. Entretanto, podem ocorrer interrupções na etapa de montagem final que aumentem consideravelmente o tempo para que os compressores cheguem até aos painéis. Nesses casos, o resfriamento pode ser bem maior, pois a temperatura da carcaça tende a convergir à temperatura da linha de montagem final, climatizada em 21 °C.

Mesmo não sendo um parâmetro empregado diretamente na classificação dos compressores em teste, o valor da temperatura da carcaça (T_{cr}) é um indicativo da temperatura do enrolamento do motor elétrico de indução associado. Tal grandeza tem influência significativa nos resultados de capacidade de elevação de pressão e potência elétrica consumida pelo compressor, por alterar a resistência elétrica dos condutores desse enrolamento.

A forte influência da temperatura foi confirmada em vários testes adicionais, realizados durante o resfriamento natural de alguns modelos de compressores, no ambiente da linha de montagem final. Os comportamentos identificados para o consumo linha e a capacidade de elevação de pressão estão aqui representados pelas figuras 24 e 25. Tais resultados são provenientes de três unidades do modelo 100B, caracterizado na tabela 37 do Apêndice A (página), e correspondem a ciclos de medições³⁰ tomados durante 260 minutos de resfriamento. Resultados semelhantes, para outros modelos de compressores, podem ser observados na figura 65 do Apêndice B (página 211).


³⁰ As curvas tracejadas das figuras 24 e 25 são polinômios de grau 2 e 1, respectivamente, ajustados por mínimos quadrados aos resultados dos testes de capacidade de elevação, com objetivo meramente ilustrativo.

Figura 24 – Influência da temperatura no consumo linha – compressor modelo 100B.



Fonte: Autor.

Figura 25 – Influência da temperatura na capacidade de elevação de pressão – compressor modelo 100B.



Fonte: Autor.

Alterações expressivas resultantes podem levar à rejeição desnecessária de compressores conformes, especialmente quando nos limites de aceitação predominar informações tomadas em temperaturas mais altas, já que Col e Cel aumentam com a diminuição da temperatura. Para evitar o ônus desse tipo de descarte, o controle de qualidade de produção prevê a compensação do efeito da temperatura nos parâmetros de interesse, o que pode ser alcançado a partir dos valores da temperatura da carcaça.

Como a eventual compensação dos resultados de cada estação estaria baseada no histórico de medições recentes, não existe maior rigor metrológico para garantia dos valores obtidos de temperatura da carcaça.


Para o monitoramento da grandeza é empregado, no caso específico dessa empresa, termômetro infravermelho. Segundo Barron (2014), existem inúmeros fatores que podem afetar a medição de temperatura com esses instrumentos – como tipo, forma, cor e brilho da superfície – e que são comuns erros sistemáticos de até ± 10 °C, dependendo da emissividade das superfícies avaliadas. O ambiente fabril favorece muito esse tipo de efeito e vários resultados de medições de lotes de produção de compressores o confirmam.

Como destacado na seção anterior, em cada ponto de teste da linha de produção considerada, os compressores são alocados às estações A e B, onde as medições ocorrem quase concomitantemente, espaçadas de pouquíssimos segundos (menos que 7 s, em condições de pleno funcionamento). Dessa forma, grandes grupos, formados por compressores que tenham sido produzidos em condições semelhantes, deveriam apresentar valores médios idênticos para a temperatura da carcaça. Entretanto, isso é pouco perceptível entre os resultados disponíveis de lotes de produção. A diferença observada entre tais valores médios pode ser considerada como bom indicativo da composição dada pela soma dos erros sistemáticos dos termômetros infravermelhos das estações A e B.

Na figura 26, ilustram-se as medições de temperatura da carcaça, obtidas por ambas as estações, para um lote de 3644 compressores de modelo 70B – caracterizado na tabela 25 do Apêndice A (página 207). Como se pode observar, existe diferença muito expressiva, que se mantém ao longo do tempo total de produção, entre os resultados de temperatura dados pelas duas estações. Para os demais parâmetros influenciáveis pela variação da temperatura, essa diferença é pouco relevante, como se pode observar na tabela 11. Da proximidade entre suas médias, pode-se intuir que as diferenças entre as médias de temperatura da carcaça decorrem exclusivamente dos instrumentos

utilizados. Nas figuras 66 e 67 do Apêndice B (página 212) constam diagramas semelhantes, que mostram a variação da magnitude dessa diferença para outros lotes, função de ajustes na instrumentação empregada.

Figura 26 – Valores de temperatura da carcaça obtidos nas estações A e B para o lote 70B-03.



Fonte: Autor.

Tabela 11 – Valor médio de resultados do teste de capacidade no lote 70B-03.

Parâmetro avaliado	Estação A	Estação B
Capacidade de elevação de pressão [mbar/s]	1263,59	1274,95
Consumo linha [W]	74,68	75,17
Temperatura [°C]	40,36	27,90

Fonte: Autor.

Conforme se podem constatar na seção seguinte (tabela 12 da página 124), os dados disponíveis para esse trabalho de tese são provenientes das duas estações de teste de capacidade de elevação de pressão. Como são informações tomadas em histórico de banco de dados, não houve oportunidade de implementar medição auxiliar que permitisse identificar os erros sistemáticos associados aos valores de temperatura obtidos, para posterior compensação. Entretanto, como os dados de consumo linha e capacidade de elevação de pressão carregam os efeitos dessa grandeza, faz-se necessário considerá-la criteriosamente em abordagens que seguem (5.4 e 5.6).

5.4. ANÁLISE DAS RELAÇÕES ENTRE OS RESULTADOS DE TESTES DE LINHA E DE ENSAIOS DE LABORATÓRIO

Ao longo desta seção, pressupõe-se que do conjunto de variáveis decorrentes dos testes de capacidade de elevação, Cel, Col, Tcr, Rf e Rp, possam-se extrair subconjuntos inerentemente relacionados a cada um dos parâmetros de interesse, Co, COP, MTP, tipicamente obtidos em ensaios de laboratório. A identificação de tais subconjuntos, bem como a forma e a força da relação que possuem com os parâmetros de interesse, é alvo de investigação ao longo desta seção. Preliminarmente, são apontadas características relevantes do conjunto de informações disponíveis e brevemente apresentadas as ferramentas estatísticas empregadas para avaliação das relações.

5.4.1. Caracterização do conjunto de informações disponíveis

Os resultados considerados para a análise das pressupostas relações decorrem de 237 peças tomadas para avaliação da qualidade de 55 lotes de compressores produzidos entre 2013 e 2014. A escolha das amostras para os testes de laboratório se faz de forma aleatória e geralmente considera compressores provenientes de ambas as estações de teste, razão pela qual existe razoável proporção entre os resultados delas decorrentes, como se pode observar na tabela 12. Os 15 modelos de compressores relacionados estão caracterizados, quanto às informações necessárias para entendimento deste trabalho, nas tabelas do Apêndice A (páginas 207 a 210).

Como mencionado em 2.3.2, para maior uniformidade de condições, a obtenção dos valores de MTP é comumente feita após os ensaios de desempenho. Entretanto, cada amostra para ensaio de MTP (EMTP) é apenas parte da amostra para ensaio de desempenho (EDES), o que justifica as diferentes quantidades de informações resultantes.

Os resultados das EDES são todos oriundos de ensaios na condição de *check-point*, com temperatura de evaporação em $-23,3\text{ }^{\circ}\text{C}$ e de condensação em $+54,4\text{ }^{\circ}\text{C}$. Os resultados das EMTP, entretanto, por estarem alinhados com aplicações específicas dos lotes, resultaram de ensaios em diferentes níveis de pressões equalizadas. Cada modelo relacionado na tabela 12, entretanto, é oriundo de um mesmo nível de pressão. Vale destacar que antes dos ensaios todas as amostras de EDES são submetidas a processo de preparação com características semelhantes.

Tabela 12 – Quantidade de resultados disponíveis por parâmetro, modelo de compressor e estação de teste de capacidade de elevação.

Modelo do compressor	Consumo e <i>COP</i>		MTP	
	Estação A	Estação B	Estação A	Estação B
70A	4	11	4	7
70B	11	16	3	4
70C	4	13	3	5
70D	5	7	4	4
80A	10	3	7	2
80B	3	6	1	4
80C	7	2	5	2
80D	8	9	4	6
80E	6	9	2	1
80F	5	8	3	3
80G	5	9	2	3
90A	1	4	1	2
100A	11	10	11	7
100B	19	12	8	5
100C	9	10	3	6
Peças por estação	108	129	61	61
Total geral	237		122	

Fonte: Autor.

Embora sejam todas produzidas para o mesmo tipo de aplicação e fabricadas em uma mesma linha de montagem, provêm de modelos distintos, que representam boa parcela da diversidade produzida, sobre os seguintes aspectos (EMBRACO, 2013):

- capacidade nominal (décima parte do valor característico obtido, em btu/h, na condição de *check-point*, descrita em 2.2.3) – 70; 80; 90; 100;
- refrigerante – R134a (tetrafluoreetano); R600a (isobutano);
- alimentação (tensão/frequência) – 115-127 V/ 60 Hz; 220 V/ 50 Hz; 220 V/ 60 Hz; 220 V/ 50-60 Hz; 220-240 V/ 50 Hz; 220-240 V/ 50-60 Hz;
- equipamentos elétricos associados ao motor de indução – relé eletromecânico; relé *PTC* (*Positive Temperature Coefficient*) e capacitor de funcionamento opcional (PACHECO, 2007).

A análise estatística por modelo de compressor foi prejudicada pela pequena quantidade de informação disponível para parcela considerável deles, especialmente para MTP. Assim, toda análise partiu da avaliação global, considerando todas as informações relacionadas a cada um dos parâmetros de interesse.

5.4.2. Ferramentas estatísticas para análise das informações

Em alguns casos, a análise visual de um diagrama de dispersão permite intuir acerca da relação entre variáveis, duas a duas. Entretanto, de modo geral, faz-se necessário empregar técnicas estatísticas para explorar a natureza dessa relação. Nesse sentido, a regressão linear múltipla é um método de análise que tem sido amplamente empregado em problemas nos quais se presume que uma variável, dita dependente, possa estar relacionada com outras variáveis, consideradas independentes (MONTGOMERY, RUNGER, 2003; HIGGINS, 2005).

A análise de regressão pode ser empregada em abordagens preditivas e explicativas, ambas resultantes da observação de exemplos rotulados. Na preditiva, o objetivo da análise de regressão é prever as mudanças na variável dependente em resposta às perturbações que ocorram nas variáveis independentes. Na explicativa, o objetivo é indicar, mas não provar, uma possível relação de causa e efeito entre as variáveis, independentes e dependente (MONTGOMERY, RUNGER, 2003). No âmbito deste capítulo, tal método de análise será empregado para fornecer indicativo da influência dos resultados de teste de capacidade de elevação nos dados obtidos em laboratório.

Para avaliar a relação entre uma variável aleatória dependente Y e p variáveis independentes x_1, x_2, \dots, x_p , necessita-se dispor de um conjunto representativo de observações de tais variáveis, $\{x_{1,i}, x_{2,i}, \dots, x_{p,i}, \dots, y_i\}$, $i = 1, 2, \dots, N$, de onde se admite que cada elemento pode ser modelado matematicamente como (22),

$$y_i = \beta_0 + \beta_1 x_{1,i} + \beta_2 x_{2,i} + \dots + \beta_p x_{p,i} + \varepsilon_i, \quad (22)$$

onde:

- y_i é a i -ésima variável aleatória dependente;
- β_j é o j -ésimo coeficiente de regressão, $j = 0, 1, \dots, p$;
- x_k é a k -ésima variável (não aleatória) independente, $k = 1, 2, \dots, p$;
- ε_i é o i -ésimo erro de aproximação do modelo.

A análise de regressão linear múltipla (ARLM) permite considerar, adicionalmente, nos modelos subjacentes o eventual efeito da interação entre as variáveis independentes originais. Por exemplo, para um conjunto de p variáveis poderia ser considerada a influência de um termo $p+1$, dado por $\beta_{p+1} x_{p+1} = \beta_{1,2} x_1 x_2$, ou $\beta_{p+1} x_{p+1} = \beta_{1,1} x_1^2$, no comportamento da variável supostamente dependente. Tal análise, entretanto, requer algum conhecimento prévio sobre o comportamento

das grandezas, por conta do excessivo número de possíveis combinações decorrentes (MONTGOMERY, RUNGER, 2003).

Uma estatística comumente empregada para avaliação dos resultados obtidos em abordagem explicativa da ARLM é o chamado coeficiente de determinação (R^2). O valor de R^2 é usado para denotar o percentual de variação da variável dependente que pode ser explicado pelo conjunto das variáveis independentes avaliadas (HIGGINS, 2005).

Para medir a força da relação estatística entre as variáveis identificadas na ARLM, pode-se empregar o coeficiente de correlação (r) linear da amostra. Tal coeficiente indica o grau de correlação entre duas variáveis e pode apresentar valores entre -1 e +1, sendo que os extremos indicam uma perfeita correlação linear e o zero indica que não dependem linearmente uma da outra (MONTGOMERY, RUNGER, 2003). O coeficiente r é um estimador do coeficiente de correlação linear da população (ρ). O intervalo aproximado de confiança de $100(1-\alpha)\%$ para ρ pode ser obtido por meio de (23),

$$\operatorname{tg} h\left(\operatorname{arc} \operatorname{tg} h(r) - \frac{z_{\alpha/2}}{\sqrt{N-3}}\right) \leq \rho \leq \operatorname{tg} h\left(\operatorname{arc} \operatorname{tg} h(r) + \frac{z_{\alpha/2}}{\sqrt{N-3}}\right), \quad (23)$$

onde:

- r é o coeficiente de correlação linear da amostra;
- z é o valor da distribuição normal padrão com área à direita igual a $\alpha/2$;
- N é o tamanho da amostra;
- ρ é o coeficiente de correlação linear da população.

De maneira geral, os procedimentos estatísticos foram realizados com o software Minitab³¹ (MINITAB, 2015). A apresentação conjunta do valor p ³² possibilita avaliar a confiabilidade das correlações obtidas.

5.4.3. Correlação linear entre consumo e dados de linha


Para a análise das relações entre os resultados dos testes de linha e valores de consumo (Co), obtidos em laboratório, consideraram-se inicialmente todas as 237 informações disponíveis, que, nesse caso, são dadas por valores das variáveis Cel , Col , Tcr , Rf e Rp e do parâmetro Co .

³¹ Minitab versão 17.2.1.0 com licença temporária para uso acadêmico.

³² O valor p é relacionado ao teste de hipótese $H_0: \rho = 0$ versus $H_1: \rho \neq 0$. Em testes de hipóteses com valores de p inferiores a 0,05 (alfa típico) a hipótese nula H_0 pode ser descartada e assumida a alternativa H_1 (MONTGOMERY, RUNGER, 2003).

A ARLM resultou em coeficiente de determinação R^2 de 0,135, revelando que somente 13,5% da variação do consumo (C_o) pode ser explicada pelo comportamento das cinco variáveis de linha consideradas. Entretanto, puderam-se intuir melhores relações para algumas variáveis específicas, a partir dos diagramas de dispersão originados (figura 27 e figura 68 do Apêndice C – página 213). Nas imagens estão destacados agrupamentos dados pela frequência da tensão de alimentação e pelo fluido refrigerante. A dispersão apresentada por grupo sugere dependência linear entre consumo e capacidade de elevação de pressão (figura 27) e entre consumo e consumo linha (figura 68a).

Figura 27 – Consumo (C_o) versus Capacidade de elevação de pressão (C_{el}) para todos os casos disponíveis.



Fonte: Autor.

Uma nova ARLM foi realizada, considerando apenas o grupo definido por refrigerante R134a e frequência de 60 Hz, que é significativamente maior, com 150 dados. Da ARLM resultou R^2 de 0,958, corroborando as relações intuídas da análise visual e revelando influência da temperatura, como se pode observar na transcrição dos resultados para o Apêndice D (páginas 215 e 216). Os grandes valores de resíduo relacionados são decorrentes das informações de peças testadas com temperaturas de carcaça menores que 37 °C, razão pela qual se optou por desconsiderá-las na análise de correlação subsequente, que levou em conta apenas as 124 informações restantes desse

agrupamento. É válido destacar que existe grande dúvida acerca dos resultados dessa grandeza, devida ao efeito sistemático destacado em 5.3, logo, não existe garantia de que as informações consideradas decorram de testes realizados com temperaturas de carcaça maiores que 37 °C.

Dado a existência de quantidade semelhante de informações provenientes de ambas as estações, optou-se por considerá-las separadamente para avaliação adicional da correlação entre as variáveis, como ilustram os diagramas de dispersão da figura 69 (Apêndice C – página 214). Os resultados obtidos mostram que os erros sistemáticos da medição da temperatura da carcaça restringem a dependência linear do consumo apenas às variáveis capacidade de elevação de pressão e consumo linha. Os valores de correlação linear obtidos para os pares de variáveis Co-Cel, Co-Tcr e Co-Col estão relacionados na tabela 13.

Tabela 13 – Correlações lineares para o agrupamento R134a/ 60 Hz para dados tomados com temperatura de carcaça superior aos 37 °C.

Variáveis	Coeficiente de correlação (r)			Valor p
	Estação A	Estação B	Est. A e B	Est. A e B
Co-Cel	+0,969	+0,981	+0,976	0,000
Co-Tcr	+0,258	-0,302	-0,167	0,064
Co-Col	+0,983	+0,987	+0,985	0,000
Nº de peças	63	61	124	

Fonte: Autor.

Cálculos adicionais mostram que existe correlação significativa dessas grandezas para a população de compressores. O coeficiente de correlação linear da população ρ ficou entre 0,955 e 0,987 para a capacidade de elevação de pressão e consumo e entre 0,972 e 0,992 para consumo e consumo linha, caracterizando níveis fortes³³ de correlação direta entre as variáveis avaliadas, visto que é sempre muito alta a probabilidade de ρ ser superior a 0,8 (DEVORE, 2006). Resultados para os outros dois agrupamentos podem ser observados na tabela 39 do Apêndice C (página 214).

5.4.4. Correlação linear entre *COP* e dados de linha


Como no caso anterior, para a análise das relações entre os resultados dos testes de linha e valores de *COP*, obtidos em laboratório, consideraram-se todas as 237 informações disponíveis, que, nesse caso,

³³ Considera-se forte a correlação linear para valor de $|\rho|$ superior a 0,8 (DEVORE, 2006).

são formadas por valores das variáveis Cel, Col, Tcr, Rf e Rp e do parâmetro *COP*.

Para o conjunto total, a ARLM mostrou que apenas 9,47% da variação do *COP* pode ser justificada pelo comportamento das cinco variáveis de linha consideradas. Entretanto, a representação planificada das relações (figura 28 e figura 70 do Apêndice E – página 217), destacando os agrupamentos definidos pela capacidade nominal dos compressores, fluido refrigerante, frequência da tensão de alimentação e equipamento elétrico associado ao motor, sugere que exista alguma dependência linear entre as variáveis. Tal relação pode ser mais bem intuída a partir dos diagramas *COP versus* Col (figura 28) e *COP versus* Cel (figura 70a), especialmente para o grupo com maior quantidade de informações, denominado 10-R1-6-R, que possui 52 peças.

Figura 28 – *COP versus* Consumo linha (Col) para todos os dados disponíveis.



Legenda:

	<p>R: relé eletromecânico P: relé <i>PTC</i> 5: 50 Hz 6: 50-60 Hz; 60 Hz 1: R134a 6: R600a 7: 700 btu/h 8: 800 btu/h 9: 900 btu/h 10: 1000 btu/h</p>	<p>☆ 7-R1-6-P ☆ 7-R6-6-R + 8-R1-5-R ○ 8-R1-6-R □ 8-R1-5-P ◇ 8-R6-6-P ▽ 9-R1-6-R + 10-R1-5-P * 10-R1-6-R</p>
--	---	---

Fonte: Autor.

O grupo 10-R1-6-R possui 5 informações de linha obtidas em peças com temperatura de carcaça menor que de 37 °C. Esses dados, assim como a variável temperatura da carcaça, foram suprimidos em nova ARLM, transcrita para o Apêndice F (página 219), da qual resultou R^2 de 0,699.

Os resultados da análise indicam que apenas o consumo linha é significativamente influente no comportamento do *COP*. Na avaliação da correlação linear considerou-se também o par de variáveis *COP-Cel*. Os resultados obtidos estão relacionados na tabela 14.

Tabela 14 – Correlações lineares para o agrupamento 100-R134-60-R para dados tomados com temperatura de carcaça superior aos 37 °C.

Variáveis	Coefficiente de correlação (r)	Valor p
<i>COP-Cel</i>	-0,683	0,000
<i>COP-Col</i>	-0,809	0,000

Fonte: Autor.

O intervalo, com 95% de confiança, para o coeficiente de correlação linear da população ρ ficou entre -0,821 e -0,469 para *COP* e capacidade de elevação de pressão e entre -0,896 e -0,663 para *COP* e consumo linha, indicando que tais variáveis possuem correlação inversa moderada e moderada a forte, respectivamente (DEVORE, 2006).

Os demais agrupamentos possuem número menor de informações para as temperaturas de carcaça acima de 37 °C. Para esses casos, a análise de correlação resultou em valores pouco expressivos, como se pode constatar na tabela 40 do Apêndice E (página 218). Atribuem-se tais resultados à influência conjunta da incerteza de medição (IM) das variáveis consideradas (tabela 15) e limitação do tamanho da amostra. Para justificar tal afirmação, avalia-se a influência das IM do consumo linha e *COP* no cômputo da correlação, para o agrupamento com o segundo maior número de informações, 7-R1-6-P. As características das incertezas foram fornecidas por especialistas da empresa e podem ser confirmadas nos trabalhos de Poletto (2006) e Coral (2014).

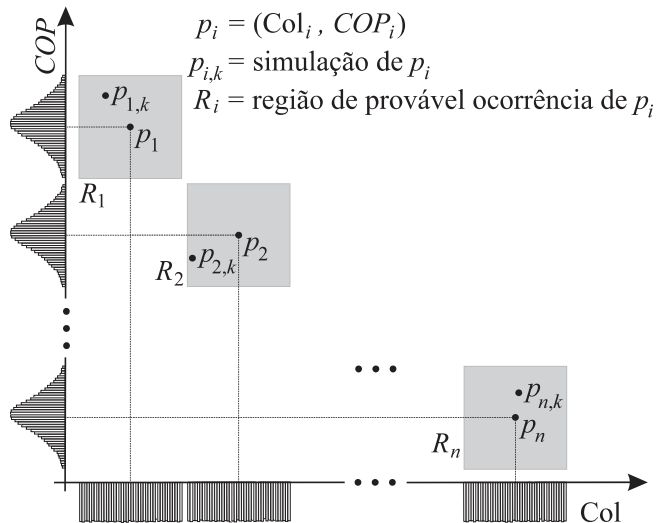
Tabela 15 – Incertezas para *COP*, consumo linha e capacidade de elevação.

Variável	IM	PDF
<i>COP</i>	3,2%	normal
Consumo linha	± 6 W	retangular
Capacidade de elevação de pressão	± 150 mbar/s	retangular

Fonte: Autor.

Na figura 29 se ilustram pontos p_i empregados na avaliação de correlação, onde as coordenadas (Col_i, COP_i) são aquelas definidas a partir dos valores medidos de Col e COP . Devido à incerteza associada à medição dos dados, considera-se que tais pontos possam ocupar qualquer outro lugar $p_{i,k}$ dentro das regiões R_i , ali representadas. Como o comportamento se aplica a todos os pontos originais do agrupamento, admite-se que qualquer uma das possíveis configurações decorrentes seria igualmente válida à maneira como eles estão dispostos originalmente. Assim, simular a correlação linear r em cada uma das possíveis configurações resultantes é uma maneira razoável de avaliar a influência da incerteza de medição das grandezas, dado o tamanho da amostra, no computo dessa relação. Os efeitos decorrentes devem ser maiores nos demais agrupamentos, que possuem ainda menos dados.

Figura 29 – Efeito das incertezas de obtenção do consumo linha e COP .



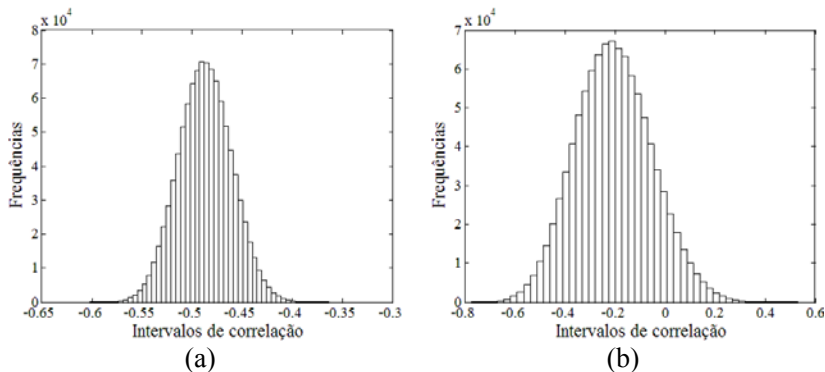
Fonte: Autor.

Para melhor caracterizar as PDF das incertezas envolvidas foi considerada a simulação de um milhão de casos (BIPM, 2008b). Para cada uma das configurações geradas, calculou-se o valor do coeficiente r , com distribuições resultantes ilustradas pela figura 30.

Nas simulações foram empregados diferentes níveis de incerteza, para observar seus efeitos. A figura 30a decorre das simulações com apenas 10% dos valores nominais das incertezas. Observa-se que a distribuição tem centro próximo ao valor do coeficiente obtido para o par original de variáveis (tabela 40 do Apêndice E – página 218), que é

de -0,495, com pequena dispersão. Para os valores típicos de incerteza (figura 30b), entretanto, resulta maior dispersão de r , com centro mais afastado da estatística original.

Figura 30 – Simulação de correlação entre COP e consumo linha frente aos efeitos de 10% (a) e 100% (b) das incertezas características - grupo 7-R1-6-P.



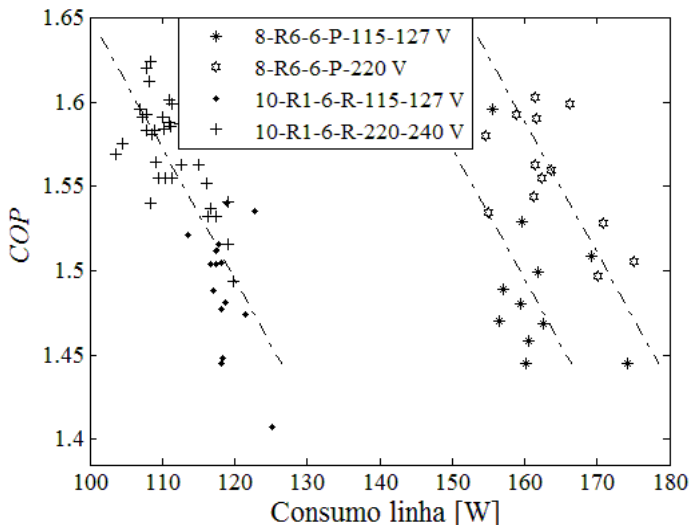
Fonte: Autor.

Os resultados indicam que podem ocorrer até 9,7% de valores positivos para a correlação, justificáveis pela ordem de grandeza do coeficiente angular da reta ajustada à análise de correlação original, que é de 10^{-4} . A figura 71 do Apêndice E (página 218) ilustra resultado semelhante para grupo menos numeroso (8-R1-6-P).

Alguns dos agrupamentos avaliados podem ser separados em dois subagrupamentos, levando em conta a tensão nominal de alimentação dos modelos de compressores integrantes. Nesses casos é possível observar que os maiores valores médios de COP são obtidos dos modelos de maior tensão. Tal comportamento, ilustrado pela figura 31, é característico de compressores semelhantes aos empregados neste trabalho de tese, segundo especialistas da empresa.

Em alguns agrupamentos, como o 10-R1-6-R, ilustrado na figura 31, a dispersão dos pontos sugere alinhamento dos subgrupos 10-R1-6-R-115-127 V e 10-R1-6-R-220-240 V ao longo de um mesmo segmento de reta (linha tracejada). Na mesma ilustração, entretanto, isso não é tão fácil de inferir a partir dos subgrupos 8-R6-6-P-115-127 V e 8-R6-6-P-220 V, e a separação dos dados por níveis de tensão nominal fica mais evidenciada. Esse aspecto também deve ser considerado para justificar os baixos níveis de correlação resultantes, que estão apresentados na tabela 40 (Apêndice E – página 218).

Figura 31 – COP versus Consumo linha (Col) para os agrupamentos 8-R6-6-P e 10-R1-6-R.



Fonte: Autor.

Os agrupamentos ilustrados na figura 28 (página 129) estão definidos pela capacidade nominal dos compressores, fluido refrigerante, frequência da tensão de alimentação e equipamento elétrico associado ao motor. Levando em conta nessa separação, adicionalmente, valores nominais de tensão, equivaleria a considerar cada um dos 15 modelos relacionados na tabela 12 (página 124), individualmente. O número de dados úteis à identificação de relações, entretanto, seria bem menor que aquele lá relacionado, devido à necessidade de desconsiderar peças com temperaturas de carcaça supostamente menores que 37 °C.

Pelo exposto, considera-se que análise mais aprofundada das relações do caso COP tenha sido prejudicada pelo pequeno número de informações disponível para a maioria dos modelos.

5.4.5. Correlação linear entre mínima tensão de partida e dados de linha


De maneira distinta aos casos avaliados em 5.4.3 e 5.4.4, para a análise das relações entre os dados de testes de linha e os valores de MTP se dispunha de apenas 122 observações. Tais informações – dadas por valores das variáveis C_{el} , C_{ol} , T_{cr} , R_f e R_p e do parâmetro MTP – estão distribuídas entre os 15 modelos considerados, o que resulta em

representação pouco expressiva para alguns deles, como se pode constatar na tabela 12 (página 124).

As informações de MTP estão naturalmente separadas pelos valores nominais de tensão de alimentação, conforme ilustram a figura 32 e a figura 72 do Apêndice G (página 221). Para os modelos alimentados em 115-127 V, os valores de MTP variam entre 78,5 V e 98,5 V. Para os de maior tensão (220 V e 220-240 V), esses valores estão compreendidos entre 117 V e 193 V. Conseqüentemente, nesse caso, a análise de regressão foi dirigida diretamente para tais agrupamentos, onde foram consideradas apenas às informações de peças testadas com temperatura de carcaça superior aos 37 °C, que resultou em 46 peças para o grupo de menor tensão e 49 peças para o de maior tensão nominal.

A ARLM resultou em coeficiente de determinação R^2 de 0,871, considerando todas as variáveis do agrupamento 115-127 V. Nesse caso, revelaram-se significativos o consumo linha e o ruído de parada. Bons resultados também foram obtidos na análise de subgrupos de variáveis, como o Cel-Col-Rp, com R^2 de 0,870, conforme se pode observar nos dados transcritos para o Apêndice H (páginas 223 e 224).

Figura 32 – Mínima tensão de partida *versus* Consumo linha.



Fonte: Autor.

Os valores de correlação linear obtidos para os pares de variáveis MTP-Cel, MTP-Col e MTP-Rp estão relacionados na tabela 16. Os resultados mostram que a correlação para o terceiro par de variáveis é

fraca. O coeficiente linear ρ para a população ficou entre 0,802 e 0,938 para a Cel e MTP e entre 0,823 e 0,945 para MTP e Col, caracterizando níveis fortes de correlação direta entre as variáveis avaliadas, visto que é alta a probabilidade de ρ ser superior a 0,8 (DEVORE, 2006).

Tabela 16 – Correlações lineares para o agrupamento 115-127 V para dados tomados com temperatura de carcaça maiores que 37 °C.

Variáveis	Coeficiente de correlação (r)	Valor p
MTP-Cel	0,888	0,000
MTP-Col	0,900	0,000
MTP-Rp	0,455	0,001

Fonte: Autor.

Para o agrupamento de maior tensão, a ARLM resultou em R^2 de 0,153, expressando pequena influência da variável consumo linha no comportamento da MTP. O coeficiente r entre tais variáveis é de apenas 0,307, com 0,032 de valor p, indicando nível de correlação muito inferior ao obtido para o agrupamento de menor tensão.

A maior contribuição para os resultados pouco expressivos de correlação não provém dos fatores relacionados ao final de 5.4.4 (incerteza e tamanho da amostra), mas das diferentes relações entre as pressões empregadas nos ensaios de partida equalizada e aquelas estabelecidas no teste de capacidade de elevação.


Em ensaios adicionais, dos quais decorrem resultados como aqueles representados na figura 33, verificou-se que peças de mesmo modelo exigem maiores níveis de tensão para partirem sob condições de carga mais elevadas. Desses ensaios, infere-se que a MTP é diretamente proporcional ao valor da pressão empregada no ensaio de partida equalizada.

Nos ensaios de capacidade de elevação, todos os lotes de determinado modelo são submetidos ao mesmo perfil de pressão, independentemente da especificidade da aplicação a que se destinam seus compressores. Consequentemente, variações nos níveis de pressão dos ensaios de partida devem afetar as eventuais correlações existentes entre os valores de MTP resultantes e as variáveis de linha.

Não foi possível constatar tal influência no agrupamento de maior tensão, por falta de resultados de MTP obtidos em pressões mais favoráveis. Entretanto, verificou-se o efeito da substituição dos resultados representados na figura 33, no cômputo da correlação para o agrupamento ao qual pertencem (menor tensão), mantendo inalterados os valores dos outros quatro modelos que o compõem. Considerar as pressões de 6 bar e 4 bar para os modelos 70B e 80E, respectivamente,

fez alterar o valor de r do par MTP-Col de 0,900 (tabela 16) para 0,691 e de 0,888 para 0,694 para MTP-Cel.

Figura 33 – Comparação dos valores de MTP para ensaios de partida equalizada dos modelos 70B e 80E com diferentes níveis de pressão.



Fonte: Autor.

Maior quantidade de informações de MTP, obtidas a partir de outras pressões, poderia permitir a identificação de melhores níveis de correlação para o agrupamento de maior tensão. De maneira geral, um estudo mais aprofundado das possíveis relações existentes ficou prejudicado pelo pequeno volume de informações disponíveis para alguns modelos.

As análises realizadas neste item, e também em 5.4.3 e 5.4.4, confirmaram os pressupostos deste trabalho de tese: existe correlação entre resultados de testes dos painéis MFC, realizados em linha de produção, e cada um dos parâmetros de interesse, obtidos em laboratório. Tal confirmação vai ao encontro das propostas do autor do presente trabalho, de implementação de recursos junto aos painéis de testes MFC, que viabilizem a obtenção de inferência de consumo, *COP* e MTP na fase de produção de compressores.

5.5. DEFINIÇÃO DAS VARIÁVEIS INDEPENDENTES

Na abordagem subjacente às propostas deste trabalho de tese, considera-se a possibilidade de aproximar funções que descrevam os

parâmetros *COP*, consumo e MTP a partir de domínio definido pelas variáveis de linha significativamente correlacionadas a eles.

Em todos os casos investigados na seção 5.4, as relações estatísticas procuradas apenas emergiram de condições específicas. Para a MTP, considerou-se a separação das informações em agrupamentos dados pela tensão. Para o consumo, dividiram-se os dados de acordo com o fluido refrigerante e a frequência. Para o caso do *COP*, a análise só se tornou possível a partir de uma segmentação ainda maior das informações, definindo agrupamentos por capacidade nominal, fluido refrigerante, frequência da tensão de alimentação e equipamento elétrico associado ao motor. Neste caso, revelaram-se indícios da necessidade de separação adicional, que levasse em conta também a tensão de alimentação, como ilustrado na figura 31 (da página 133).

Das análises realizadas, evidenciou-se que a variável consumo linha possui expressivos níveis de relação estatística com cada um dos parâmetros de interesse. Também se obtiveram bons níveis de correlação para os pares de variáveis Co-Cel, MTP-Cel e *COP*-Cel.

Para a consecução dos objetivos propostos, faz-se necessário avaliar se o domínio formado exclusivamente pelas variáveis de linha identificadas, Cel e Col, permite caracterizar os comportamentos funcionais que descrevam os parâmetros de interesse.

A avaliação dos requisitos mínimos de domínio para a definição das funções buscadas, conforme colocado em 3.5, é realizada nos itens seguintes (5.5.1 e 5.5.2).

5.5.1. Definição da variável qualitativa


No agrupamento R600a/ 60 Hz (ilustrado anteriormente pela figura 27, da página 127), considerado em parte na figura 34, as informações dos compressores de modelo 80E e 80F se sobrepõem em regiões do plano gerado por Cel e Col. Entretanto, das regiões de sobreposição resulta, para cada modelo de compressor, um diferente patamar de consumo, com valor médio de 163,6 W para aquele associado ao 80E e 153,1 W para o que decorre do 80F.

O comportamento ilustrado, que também foi identificado nas informações de MTP, vai de encontro à definição de função, onde a cada elemento do domínio deve corresponder um único elemento da imagem.

Em avaliações semelhantes para o caso do *COP*, a caracterização da relação funcional no domínio dado por Cel e Col ficou prejudicada apenas para o agrupamento 8-R6-6-P, em razão da necessidade ilustrada

pela figura 31, de segmentação adicional pela tensão de alimentação nominal, o que reduziria a divisão aos agrupamentos de dados originais.

Figura 34 – Problema de caracterização da função consumo em domínio dado por consumo linha e capacidade de elevação de pressão – grupo R600a/ 60 Hz.




Fonte: Autor.

Tratar os modelos individualmente limitaria a capacidade de investigação deste trabalho, pois as amostras são pouco representativas para a maioria deles, especialmente para o caso da MTP. Entretanto, da definição de solução específica por modelo, sugerida na análise do *COP*, resultou proposta que permite tratá-los conjuntamente.

Optou-se por modelar, para cada um dos parâmetros de interesse (*Co*, *COP* e *MTP*), uma única relação funcional. Para permitir a caracterização de tais funções, estabeleceu-se domínio a partir das variáveis quantitativas já identificadas – *Col* e *Cel* – e da variável categórica *Mod*, que é uma representação numérica de variável qualitativa relacionada ao modelo do compressor. A consideração desse conjunto de variáveis deve prover o domínio de 15 regiões distintas, com intersecções nulas entre elas. Verificar essa condição em domínios com mais de duas dimensões (figura 35) é uma tarefa difícil, geralmente. Entretanto, ela pode ser facilitada com uso de uma rede neural artificial (RNA) apropriada, denominada mapa auto-organizável (ou rede) de Kohonen (KOHONEN, 2014), conforme apresentado em 3.6.

Figura 35 – Domínio definido pelas variáveis Cel, Col e Mod.



Fonte: Autor.

5.5.2. Avaliação da separação das informações por modelo

O mapa auto-organizável (*SOM*) é capaz de representar um conjunto de dados de dimensão mais elevada em uma imagem bidimensional ordenada. A redução da dimensionalidade possibilita a visualização de eventuais características comuns aos dados, no espaço de dimensão original (KOHONEN, 2014).

Todas as informações apresentadas às unidades sensoriais do *SOM* são representadas por algum neurônio do mapa de características. As distâncias entre tais neurônios refletem semelhanças no espaço original. Consequentemente, dados muito semelhantes podem ocupar os mesmos neurônios do mapa e neurônios vizinhos estão associados a grupos de informações com características comuns (KOHONEN, 2014).


Para avaliar se o domínio resultante possuía as características idealizadas, submetem-se todas as 237 informações disponíveis a um *SOM* 12x12 (configuração definida por experimentação). Vale destacar que devido ao tipo de treinamento envolvido, competitivo, os dados utilizados não continham informações de laboratório, possuindo apenas valores das variáveis Cel, Col e Mod.

O mapa foi definido a partir de um toolbox do Matlab³⁴ (MATHWORKS, 2014), o *nctool* (*Neural Network Clustering Tool*)³⁵. Para facilitar a visualização dos resultados, o software empregado disponibiliza uma matriz de acumulação (*SOM Sample Hits*). Após o treinamento, nessa matriz é representada a localização dos neurônios vencedores na grade sináptica predefinida, fornecendo indicações de características comuns no espaço de maior dimensão.

A matriz de acumulação obtida, ilustrada pela figura 36, mostra que a inserção da variável categórica (sujeitas às ponderações apropriadas) resultou na separação pretendida. Como nenhum neurônio da grade acumulou informação de mais de um modelo, infere-se que não haja qualquer intersecção indesejada de regiões no domínio original.

Como os problemas de consumo e *COP* deverão ser representados em mesmo domínio, e para MTP em um subconjunto dele, então a análise é suficiente para os três casos.

Figura 36 – Matriz de acumulação do mapa de Kohonen 12x12.



Fonte: Autor.

Na seção seguinte é definida a forma de encaminhamento da solução, a partir do conjunto de variáveis estabelecido.

³⁴ Matlab/Simulink versão 2014/A, licença acadêmica concurrent.

³⁵ O *nctool* fornece informações adicionais que possibilitam melhor entendimento das relações entre os agrupamentos originais e aqueles apresentados pelo mapa resultante, muito importantes na etapa de experimentação (MATHWORKS, 2014).

5.6. PROPOSTA DE FERRAMENTAS NEURAIIS APLICÁVEIS

A dependência linear identificada entre as variáveis observadas, como em 5.4.3, pode sugerir a aplicação de regressão linear para predição de valores dos parâmetros obtidos em laboratório. Entretanto, naquelas investigações o objetivo era apenas identificar a maneira como as variáveis se relacionam. Por tal motivo, consideraram-se somente informações onde a influência da temperatura era menos significativa, reduzindo o problema às suas características mais lineares. Vale destacar que se houvessem informações suficientes por modelo e fossem mantidos os níveis de correlação identificados, não se descartaria investigar a utilização da ARLM, com abordagem preditiva. No entanto, a escassez de dados é fator limitante e a abordagem por modelo reduziria a investigação a pouquíssimos casos.

Em 5.5.1 apresentou-se domínio ampliado com objetivo de tratar todos os modelos conjuntamente. A avaliação da estratégia, em 5.5.2, forneceu indicação de condições para o estabelecimento das relações funcionais necessárias às inferências. Entretanto, a representação do problema no domínio sugerido o torna mais complexo, do ponto de vista da modelagem pretendida. O grau de complexidade do problema aumenta na medida em que se faz necessário acrescentar a ele a influência da temperatura. Nesse sentido, o uso de ferramentas neurais para a aproximação das funções se torna uma opção mais atraente que a modelagem estatística clássica.

5.6.1. Compensação indireta dos efeitos da temperatura

Na seção 5.3 e no Apêndice B (página 211) foram apresentados resultados de ensaios adicionais que mostram a forte relação que a temperatura da carcaça (T_{cr}) possui com o consumo linha e com a capacidade de elevação de pressão, que são variáveis estatisticamente relacionadas com COP , consumo e mínima tensão de partida (MTP). Entretanto, em avaliações posteriores (5.4.3-5.4.5) não se observaram níveis satisfatórios de correlação linear entre T_{cr} e qualquer um dos parâmetros obtidos em ensaios de laboratório. Acredita-se que as relações investigadas tenham sido perdidas, em grande parte, pelos expressivos erros sistemáticos inerentes aos resultados de medição de temperatura.

Assim como não se mostrou adequada aos modelos de regressão, que são também ferramentas aproximadoras de função, a T_{cr} dificilmente se consubstanciaria como variável útil à outra forma de

modelagem estatística, nas condições em que atualmente é obtida. Entretanto, não prover a ferramenta de inferência, a ser empregada, de meios capazes de reconhecer sua influência, fatalmente fará incorrer em estimativas precárias, em determinadas faixas de temperatura.

Nos resultados de testes tomados em intervalos de resfriamento, como aqueles apresentados em 5.3, observou-se que existem fortes índices de correlação linear negativa entre capacidade de elevação da pressão e temperatura da carcaça. Da mesma forma, notou-se que para peças de um mesmo modelo, os coeficientes angulares e lineares das retas de regressão são semelhantes, o que caracteriza uniformidade de comportamento. Resultados obtidos para cinco peças do modelo 100B, relacionados na tabela 17, evidenciam tais características.

Tabela 17 – Resultados de testes de capacidade de elevação realizados durante intervalo de resfriamento de cinco peças do modelo 100B.

Peça	Coeficiente			Valor p	ΔT_{cr} [°C]
	angular [(mbar/s)/°C]	linear [mbar/s]	correlação (<i>r</i>)		
100B-1	-14	2763	-0,991	0,000	26,0 a 44,0
100B-2	-12	2751	-0,993	0,000	26,2 a 43,8
100B-3	-13	2731	-0,991	0,000	26,2 a 43,6
100B-4	-14	2733	-0,990	0,000	25,9 a 44,1
100B-5	-13	2746	-0,996	0,000	25,9 a 43,9

Fonte: Autor.


Ainda que consumo linha e capacidade de elevação de pressão não fossem variáveis dependentes, as relações entre Cel e Tcr permitiriam interpretá-las como decorrentes de uma transformação linear da relação entre o Col e Tcr (ilustrada na figura 24 da página 120), como pode ser observado para a peça 100B-1, na figura 37, que caracteriza comportamento típico do modelo.

A solução encontrada, diante das evidências apresentadas e dos recursos disponíveis, foi a da utilização da relação entre Col e Cel como forma de compensar indiretamente os efeitos da temperatura.

A estratégia consiste, inicialmente, em obter dados de testes dos painéis MFC para vários compressores de vários modelos, tomados durante intervalo de resfriamento. Da mesma forma, faz-se necessário submetê-los aos ensaios de laboratório para conhecer os valores de consumo, COP e MTP. Assim, aos valores dos parâmetros obtidos estariam associados diferentes pares de valores de Cel e Col, para diferentes temperaturas de carcaça, igualmente significativos. Posteriormente, seria necessário apresentar essas informações às redes

neurais, na etapa de treinamento. Implementada dessa forma, a estratégia permite considerar para a modelagem das funções todas as informações relacionadas na tabela 12 da página 124 (listagem dos dados disponíveis), bem como possibilitar um espectro maior de atuação para as ferramentas treinadas.

Figura 37 – Estratégia para compensação indireta do efeito da temperatura – compressor 100B-1.



Fonte: Autor.

5.6.2. Aplicabilidade do método MMC-*bagging* hibridizado

Os resultados apresentados ao longo deste capítulo indicaram a existência de relações funcionais capazes de descrever *COP*, consumo e MTP a partir de domínio derivado das variáveis *Col* e *Cel*, que são características de testes dos painéis MFC. Na seção 3.4, discorreu-se sobre a capacidade do *perceptron* multicamadas (*MLP*) em aproximar qualquer função contínua desconhecida. De modo geral, a aproximação de uma função é viabilizada a partir de um conjunto de exemplos rotulados, ou padrões de treinamento, $\{(x_i, d_i)\}$, onde $i = \{1, 2, \dots, N\}$, que represente o conhecimento sobre a função desconhecida. No âmbito deste trabalho, considerando os resultados de 5.5, as componentes do vetor x são valores das variáveis contínuas *Col* e *Cel* e representações numéricas de variável qualitativa, relacionada ao modelo do compressor,


e d pode assumir o valor do parâmetro de interesse a ser inferido, COP , consumo ou MTP.

Em 4.5, apresentaram-se as características do método MMC-*bagging* hibridizado, estabelecido com o intuito de melhorar a confiabilidade metrológica de inferências realizadas por meio de redes neurais, aí incluídas as *MLP*, que é um aspecto imprescindível em aplicações em sistemas industriais.

Em síntese, a amostragem com reposição do *bagging* permite considerar os erros devidos à incompletude do conjunto de treinamento e ao processo de otimização. Complementarmente, as simulações de Monte Carlo (SMC) envolvidas propagam as *PDF* do conjunto de treinamento (SMCt), levando em conta os erros aleatórios e sistemáticos não compensados dos seus dados, e permitem considerar tais erros de medição durante a aplicação das redes (SMCu).

Apesar de o método ter se mostrado útil em aplicações afins (CORAL, 2014; CORAL *et al*, 2015), identificaram-se limitações ao seu uso no contexto deste trabalho de tese, as quais são discutidas na sequência. Para apresentá-las, simulou-se o problema do COP , colocando-o em domínio definido pelas variáveis a ele correlacionadas, Col e Cel , observando intervalos de valores e relações típicas de determinados modelos de compressores, conforme ilustrado na figura 38.

Figura 38 – Simulação com dados hipotéticos e modelo irreal altamente linearizado do COP .



Fonte: Autor.

De uma das retas do plano onde se situavam os valores simulados de *COP* (figura 38), retiraram-se amostras para compor conjunto de treinamento (pontos coloridos em preto) e teste (pontos em vermelho). O conjunto de treinamento consistia de 20 pontos igualmente espaçados. Para o conjunto de teste, selecionaram-se os 19 pontos médios associados a cada par consecutivo do conjunto de treinamento.

O objetivo da atividade consistia em treinar redes *MLP*, capacitando-as a generalizar a partir da região amostrada para o treinamento, seu domínio de definição. Tais redes seriam empregadas em *ensemble* baseado em método *MMC-bagging*, para avaliar a capacidade do mesmo em gerar inferências e respectivas incertezas para o conjunto de teste, originário dessa mesma região.


A opção pelo mapeamento de função linear conhecida, a ausência de ruídos nos dados simulados, a uniformidade da distribuição dos pontos amostrados e a densidade do conjunto de treinamento, foram critérios considerados para minimizar a parcela de erro decorrente do processo de treinamento das mil redes *MLP* envolvidas.

Para a atividade, empregaram-se todos os recursos intrínsecos ao método *MMC-bagging*, levando-se em conta os valores e características das incertezas de medição (IM) das grandezas envolvidas, relacionadas na tabela 15 (da página 130). Durante o uso, cada uma das redes processava mil SMCu.

As simulações ocorreram em duas etapas distintas, onde se avaliou o desempenho da ferramenta neural frente a diferentes níveis de IM das variáveis de linha, observando os erros das inferências e a qualidade das incertezas estimadas. Em ambos os casos, levou-se em conta o valor nominal da IM do *COP*, que é 3,2%.

Na primeira simulação, tanto para o treinamento quanto no uso das redes, considerou-se apenas 1% dos valores nominais das IM de Col e Cel, o que correspondia a 0,06 W e 1,5 mbar, respectivamente. Os resultados obtidos nessas condições estão ilustrados na figura 39. Na imagem, cada símbolo colorido em vermelho representa um valor de *COP* do conjunto de teste, e a barra representa a sua IM. O símbolo subsequente, na cor azul, relaciona-se ao valor da inferência, para o dado representado pelo símbolo anterior (cor vermelha), e a barra azul à incerteza da inferência estimada correspondente. Como se pode intuir da figura, a ferramenta neural mostrou boa capacidade de generalização para toda a região considerada, entretanto, o método subjacente não assegurou a propagação razoável das IM envolvidas. Nas condições simuladas, esperava-se que as incertezas das inferências fossem no mínimo iguais à IM do *COP*.

Figura 39 – Inferências de *COP* considerando 100% da IM de laboratório e 1% das IM das variáveis de linha.




Fonte: Autor.

Para o segundo caso, considerou-se o valor nominal das incertezas de Col e Cel, 6 W e 150 mbar, respectivamente, com distribuições retangulares. As respostas obtidas com a aplicação do método estão ilustradas na figura 40, que possui os mesmos recursos gráficos da figura 39. Apesar de terem sido considerados níveis bem maiores de incerteza no treinamento e uso, em relação à primeira simulação, ainda assim não se obtiveram resultados sequer iguais à IM do *COP*. Para esse caso, adicionalmente, observou-se significativa queda na capacidade de generalização das redes envolvidas.

Parcela do efeito observado pode ser atribuída à interação entre as SMC dos vários pontos de treinamento, especialmente pela relação entre o intervalo de confiança das variáveis de linha e o tamanho do intervalo do domínio de definição da função modelada, o que justifica a ocorrência com maior intensidade na segunda simulação³⁶.

³⁶ Os dois efeitos observados nas simulações foram constatados posteriormente para parcela expressiva dos casos de *COP*, o que era esperado, pois as simulações reproduziram bem as características reais do problema.


Figura 40 – Inferência de COP considerando 100% da IM de laboratório e 100% das IM das variáveis de linha.



Fonte: Autor.

O efeito de tal interação pode ser mais bem compreendido a partir da figura 41, onde os pontos em preto são projeções dos valores simulados de COP (figura 38) no plano dado por Col e Cel , e R é a região da incerteza do ponto (2100, 105).

Figura 41 – Região R decorrente da SMCT para o ponto (2100, 105) do domínio da função modelada.



Fonte: Autor.

Propagar a IM das variáveis associadas ao ponto (2100, 105) da figura 41, por exemplo, significa considerar que ele possa estar em qualquer lugar da região R . Nesse caso, ele influenciaria diretamente o cômputo de qualquer outro ponto. De modo geral, esse processo pode colocar como equivalentes todos os pontos do conjunto de treinamento. Como a região central estaria sujeita a certa “simetria” desse efeito, então a inferência a partir daquela região seria pouco afetada, o que não aconteceria com pontos dos extremos do intervalo do domínio de definição, onde tal interação ocorreria apenas de maneira parcial.

Função dos efeitos observados nas simulações considerou-se necessário empregar ferramentas neurais distintas para realização de inferências e para obtenção das incertezas associadas. A caracterização de tais ferramentas será apresentada na sequência.

5.6.3. Caracterização das ferramentas neurais

Além de influenciar a realização das inferências, propriamente ditas, as estratégias subjacentes ao método *MMC-bagging* não asseguram a propagação adequada das distribuições de variáveis empregadas no treinamento. A solução proposta pelo autor do presente trabalho para esse problema adicional consiste em considerar dois diferentes *ensembles*, constituídos de redes *MLP* treinadas com o mesmo objetivo, capazes de fornecer, de forma independente, a inferência e sua incerteza.

O *Ensemble* de Inferência (*EInf*) será constituído com o intuito de estimar o valor do parâmetro de interesse. Para o treinamento serão empregados somente os valores medidos, sem considerar nenhuma informação de incerteza. A diversidade das redes constituintes será garantida por pequenas alterações do conjunto de treinamento, selecionado aleatoriamente, sem reposição, entre os dados disponíveis para cada modelo. A inferência resultará da média aritmética simples das saídas das redes, conferindo maior robustez aos resultados, função da minimização da aleatoriedade, típica do *ensemble*.

O *Ensemble* da Incerteza da Inferência (*EInf*), deverá ser estabelecido com base no método *MMC-bagging*, com solução que possibilite tratar os problemas identificados em 5.6.2, visando assegurar confiabilidade metrológica às inferências fornecidas pelo *EInf*.

A modificação a ser implementada consiste em não considerar a IM do parâmetro de laboratório (IM_{lab}) na etapa de treinamento. Dessa forma, a incerteza resultante do *EInf* (I_{EInf}) seria função da

aleatoriedade presente nas informações de laboratório, das IM das variáveis de linha (Col e Cel), e das incertezas associadas ao treinamento (incompletude e otimização). Assim, a incerteza da inferência (IInf) seria dada pela combinação de IM_{lab} com I_{EInf} , da forma como sugere a equação (24),

$$IInf = \pm \sqrt{IM_{lab}^2 + I_{EInf}^2}, \quad (24)$$

onde:

- IInf é a incerteza da inferência;
- IM_{lab} é a incerteza de medição do parâmetro de laboratório;
- I_{EInf} é a incerteza resultante do EInf.

O conjunto de treinamento deverá ser definido a partir dos dados relacionados na tabela 12 (página 124) e de resultados de testes de etapas de resfriamento, para consideração do efeito da temperatura, conforme discutido em 5.6.1.

Durante o uso do EInf, cada inferência será obtida depois de processadas p simulações de Monte Carlo (SMCu) pelas k redes constituintes. Devido às características das redes empregadas, a confiabilidade metrológica dos resultados será assegurada apenas às entradas oriundas de domínio de operação contido no domínio de definição da função aproximada pela rede.

5.7. CONSIDERAÇÕES

A investigação realizada nos capítulos anteriores revelou a complexidade para obtenção de parâmetros úteis à avaliação da qualidade da produção de compressores herméticos de refrigeração, mostrando as limitações de soluções típicas, destacando avanços que fornecem indicações da viabilidade de tratamento mais abrangente, com uso de ferramentas de inteligência artificial. Adicionalmente, avaliaram-se recursos potencialmente úteis para assegurar confiabilidade aos resultados obtidos com uso de tais ferramentas.

No presente capítulo, foram discutidas as propostas do trabalho de tese e a forma de encaminhamento da solução. Foi apresentado inicialmente o teste de capacidade de elevação de pressão, empregado como ferramenta de apoio ao controle da qualidade de produção de compressores em empresa com tempo de ciclo muito reduzido. Tais testes representam os poucos instantes em que o motor de cada compressor produzido é acionado, antes de ser enviado para o cliente. Por meio de análise de dados, constatou-se a hipótese da existência de

correlação entre variáveis características desses testes e parâmetros normalmente obtidos em ensaios de desempenho e de mínima tensão de partida. Com base nos níveis de correlação identificados, apresentou-se proposta do trabalho de tese, que consiste em realizar inferências dos parâmetros normalmente obtidos em laboratório a partir das variáveis resultantes dos ensaios de linha de produção. Para assegurar confiabilidade aos resultados daí resultantes, avaliou-se a capacidade de aplicação de método alinhado aos preceitos metroológicos vigentes.

No capítulo seguinte são apresentados três estudos de caso com o objetivo de mostrar a viabilidade de realização de inferência dos valores de consumo, *COP* e mínima tensão de partida a partir dos testes de painéis MFC. Oportunamente, são apresentados aspectos relevantes das estratégias empregadas, bem como resultados obtidos a partir de lotes de produção para cada uma das frentes de trabalho.

6. ESTUDOS DE CASO

6.1. INTRODUÇÃO

O presente trabalho de tese consiste no estabelecimento de ferramentas que permitam obter estimativas de consumo, *COP* e mínima tensão de partida para compressores herméticos de refrigeração.

A solução proposta pelo autor não utiliza os métodos tipicamente empregados para medição de tais parâmetros, que são demorados, dispendiosos, e se limitam apenas a pequenas amostras da produção, ainda que empregados para monitoramento da qualidade de lotes produzidos. Na proposta, as estimativas devem ser obtidas de inferências realizadas a partir de resultados de testes rápidos, que sejam efetivamente aplicados em 100% das peças produzidas, em procedimentos compatíveis com o tempo de ciclo de empresas com elevado fluxo de produção, permitindo controle mais efetivo da qualidade da produção.

Com o intuito de avaliar validade e viabilidade de implantação da solução estruturada anteriormente em 5.6.3, neste capítulo são analisados os resultados de três estudos de caso, desenvolvidos na Whirlpool S.A. – unidade Embraco, localizada no norte catarinense, na cidade de Joinville. A legitimidade de tais estudos como abordagem metodológica de pesquisa está calcada na forte representatividade da empresa no segmento produtivo em que se insere.

A empresa é líder mundial no mercado de compressores herméticos para refrigeração, comercializando seus produtos em mais de 80 países. Sua capacidade de produção instalada é de 30 milhões de compressores por ano, dos quais, 35 mil podem ser produzidos por dia na planta de Joinville (EMBRACO, 2011a). Considerando o atual número de linhas de produção da unidade, cada uma possui capacidade de produzir um compressor hermético a cada 7 segundos (*lead time*).

O elevadíssimo volume de produção da empresa limita o controle da qualidade de cada peça fabricada aos ensaios de capacidade de elevação de pressão (5.2), realizados em painéis disponíveis na linha de montagem final de compressores (MFC). Os ensaios de desempenho e de mínima tensão de partida (MTP) são realizados em condições laboratoriais para pequenas amostras dos lotes produzidos e demandam, respectivamente, tempos médios de 4,5 horas e de 50 minutos para realização por compressor.

Por meio dos resultados apresentados neste capítulo, deve-se avaliar a capacidade de realização de inferência dos valores de *COP*,

consumo e MTP a partir de dados obtidos nas linhas de produção, nesse caso provenientes dos painéis MFC. Oportunamente, no estudo de caso também deve ser verificada a compatibilidade dos níveis de incerteza das inferências fornecidas com a incerteza de medição das grandezas envolvidas.

Além de aspectos relacionados à qualidade das inferências obtidas e incertezas associadas, são destacadas características relevantes das estratégias subjacentes à solução, bem como resultados da aplicação das ferramentas a alguns lotes de produção, em cada um dos estudos de caso. Preliminarmente, são relatados aspectos práticos da implementação das ferramentas neurais, respaldando teoricamente, quando necessário, a escolha pelos recursos empregados.

6.2. ASPECTOS DA IMPLEMENTAÇÃO DAS FERRAMENTAS NEURAIAS

Como apresentado em 5.6.3, para cada um dos casos a serem avaliados, considerou-se necessário estabelecer duas ferramentas neurais distintas, o *Ensemble* de Inferência (*EInf*) e o *Ensemble* da Incerteza da Inferência (*EIIInf*). O *EInf* deve ser empregado com o intuito de estimar o valor do parâmetro de interesse propriamente dito, beneficiando-se da combinação das suas unidades integrantes para obter melhor desempenho final. O *EIIInf*, configurado com uma versão aperfeiçoada do método *MMC-bagging* hibridizado (4.5), deve assegurar confiabilidade metrológica às inferências fornecidas pelo *EInf*.

No total, para obter os resultados desejados dos parâmetros *COP*, consumo e MTP são necessários seis *ensembles*, respectivamente denominados: *EInf_{COP}* e *EIIInf_{COP}*; *EInf_{Co}* e *EIIInf_{Co}*; *EInf_{MTP}* e *EIIInf_{MTP}*. Em todos os casos, tais ferramentas são compostas por redes do tipo *perceptron* multicamadas (*MLP*). A escolha desse tipo de ferramenta, no contexto das redes neurais artificiais (RNA) decorre da sua capacidade em aproximar uma função qualquer com o mesmo grau de precisão e número menor de parâmetros que uma ferramenta similar, como a *RBF*, conforme colocado anteriormente em 3.2.3 (página 78).

A implementação das redes *MLP* requer a observação de aspectos práticos, específicos dos problemas a que se destinam. Nas seções seguintes (6.2.1 a 6.3.3) são abordados resumidamente alguns desses aspectos, como a definição das estruturas mais apropriadas, a seleção dos conjuntos de treinamento e teste entre os dados disponíveis, e o pré-processamento dos elementos desses conjuntos.

6.2.1. Características das redes *MLP* empregadas

Como colocado em 3.4, a especificação da estrutura de uma rede *MLP* depende da disposição espacial das amostras, além de vários outros fatores, geralmente difíceis de serem quantificados, como o grau de complexidade física do problema a ser mapeado e a qualidade do conjunto de treinamento disponível (SILVA; SPATTI; FLAUZINO, 2010).

Apesar de algumas heurísticas sugerirem certo compromisso entre o número de parâmetros livres e a quantidade de padrões disponíveis (HAYKIN, 2001), na prática, a estrutura da rede *MLP* é normalmente definida de maneira experimental, empiricamente. No presente estudo, obtiveram-se resultados satisfatórios com a estrutura de rede *MLP* caracterizada na tabela 18, em todos os elementos dos seis *ensembles* envolvidos. Vale destacar que a opção por tal configuração resultou de significativo número de simulações.

Tabela 18 – Estrutura das redes *MLP* empregadas.

Camada	Unidades sensoriais ou neurônios	Função de ativação
Entrada	3	–
1ª oculta	20	Tangente hiperbólica
2ª oculta	10	Tangente hiperbólica
3ª oculta	5	Tangente hiperbólica
Saída	1	Tangente hiperbólica

Fonte: Autor.

A escolha da tangente hiperbólica como função de ativação decorreu da necessidade de ajuste às não linearidades dos problemas e da sua característica intrínseca de antissimetria contribuir para melhorar o processo de convergência da rede durante a etapa de treinamento (HAYKIN, 2001), especialmente a partir da opção pela aplicação do algoritmo de aprendizagem de Levenberg-Marquardt.

Para as configurações testadas, invariavelmente o algoritmo de treinamento de retropropagação de erro se mostrou muito mais lento que o de Levenberg-Marquardt. Apesar de as análises experimentais mostrarem que o desempenho da rede treinada independia do algoritmo empregado e de o tempo de treinamento não ter influência direta na adequabilidade pretendida das ferramentas neurais à rotina da linha de produção, pois é um processo anterior à aplicação, optou-se pelo uso do Levenberg-Marquardt (LM). A escolha de tal algoritmo permitiu maior agilidade na etapa de experimentação. Apenas para exemplificar, mesmo

com uso do algoritmo LM, a formação de alguns *ensembles* demandou tempo de treinamento superior a oito horas³⁷.

O critério de parada do treinamento foi definido pela combinação de um conjunto de técnicas bem consolidadas: erro mínimo; número de épocas; validação cruzada. Dessa forma, o processo é interrompido quando qualquer um desses requisitos estiver satisfeito.

A técnica do erro mínimo consiste em observar o momento a partir do qual a função de erro considerada (erro médio quadrático) fica abaixo de um valor predefinido. O critério do número de épocas vincula essa etapa do processo a um número máximo de vezes em que o conjunto de treinamento deve ser apresentado à rede. Esta é complementar a anterior, particularmente útil quando o erro admissível é difícil de ser alcançado (SILVA; SPATTI; FLAUZINO, 2010). Na parada pela validação, compara-se, durante o treinamento, o erro médio quadrático para o conjunto de treinamento com o erro médio quadrático obtido para um conjunto de validação cruzada. Se este aumentar, entre épocas sucessivas, enquanto aquele diminuir, significa que o processo está tendendo à memorização e então deve ser parado (HAYKIN, 2001). Esta última técnica permite a identificação do momento em que a rede começa a perder a capacidade de generalização.

Tanto a parada pelo erro mínimo quanto a interrupção pelo número de épocas não são garantias de que conseguiu estabelecer o almejado compromisso entre o *underfitting* e o *overfitting*, discutido em 3.4. Um número excessivo de épocas pode fazer com que a rede perca sua capacidade de generalização, assim como um número muito pequeno, pode fazer com que ela não alcance o desempenho satisfatório. De igual forma, atingir o erro mínimo não é garantia de que o melhor desempenho tenha sido alcançado. Como o objetivo do treinamento é definir uma rede com boa capacidade de generalização, o uso da parada pela validação se torna particularmente útil (SILVA; SPATTI; FLAUZINO, 2010). Na prática, para a maioria absoluta das redes geradas, este critério foi geralmente atingido.

A seleção do conjunto de validação poderá ser mais bem compreendida a partir da seção 6.2.3, onde se vai discutir a seleção dos conjuntos de treinamento e teste. Tais conjuntos são definidos a partir da incorporação dos dados caracterizados na sequência aos empregados nas análises do capítulo anterior (tabela 12 da página 124).

³⁷ Para tais atividades foi empregado computador com processador Intel Core i5, com 8 Gbytes de memória RAM, sistema operacional Microsoft Windows 7 Professional, de 64 bits, e Matlab R2013a, para o processamento das RNA

6.2.2. Caracterização dos dados de resfriamento

Além dos dados da rotina de ensaios da empresa, relacionados na tabela 12 (página 124), consideraram-se para os estudos de caso informações de testes de capacidade de elevação de pressão efetuados durante a etapa de resfriamento de alguns modelos de compressores, gerados especificamente para este trabalho de tese. Como comentado em 5.6.1, essas peças também foram submetidas aos ensaios de laboratório para obtenção dos valores dos parâmetros típicos. Os resultados assim obtidos, listados na tabela 19, destinam-se à implementação da estratégia de compensação indireta dos efeitos da temperatura. Por meio de tal estratégia, devem-se prover as ferramentas neurais de informações que as capacitem a generalizar a partir de resultados de painéis MFC gerados em faixa mais ampla de temperatura de carcaça.

Tabela 19 – Quantidade de resultados disponíveis por parâmetro e modelo de compressor.

Modelo	Faixa de temperatura [°C]	Total de peças disponíveis		
		Consumo	<i>COP</i>	MTP
70B	44,5 a 25,1	8	8	2
80B	43,8 a 26,1	3	3	3
80E	45,6 a 24,0	6	6	–
100A	44,6 a 20,1	6	6	6
100B	42, 5 a 24,7	6	6	–

Fonte: Autor.

Para melhor caracterização dos resultados, não se empregaram técnicas para aceleração do resfriamento dos compressores. Procurou-se realizar medições a cada decaimento de 5 °C na temperatura da carcaça, entretanto, devido a fatores operacionais, como mudança de turno, associados ao longo tempo de resfriamento, isso nem sempre foi possível. Apenas para exemplificar, um compressor de modelo 100B leva um tempo médio de 4,7 horas para resfriar de 43 °C até 26 °C. Da mesma forma, não se conseguiu cobrir toda a faixa de interesse, para todos os modelos avaliados, que deveria ir até ao valor da temperatura ambiente da linha, que é de 21 °C. A faixa de temperatura observada para cada modelo também está identificada na tabela 19.

Vale salientar que apesar da especificidade desses ensaios, eles seguiram a mesma rotina das demais peças envolvidas no estudo de caso, que resultam de amostras de ensaio de desempenho (EDES), tendo sido submetidas a processo de preparação com características

semelhantes. O conjunto dos resultados considerados é oriundo de ensaios na condição de *check-point*, com temperatura de evaporação em $-23,3^{\circ}\text{C}$ e de condensação em $+54,4^{\circ}\text{C}$. Para os ensaios de desempenho foram empregadas 20 bancadas distintas, sendo que cada compressor foi submetido a apenas uma delas. Os resultados das amostras de ensaio de mínima tensão de partida decorrem de ensaios em diferentes níveis de pressões equalizadas. Para cada um dos modelos avaliados, entretanto, consideraram-se apenas resultados para um mesmo nível de pressão.

Na sequência é apresentado o critério adotado para a extração dos conjuntos de treinamento e teste a partir do conjunto total de dados considerados.


6.2.3. Seleção dos conjuntos de treinamento e teste

Quando a rede *MLP* é projetada para problemas de aproximação, ela não conhece o comportamento fora do seu domínio de definição (HAYKIN, 2001). A sua capacidade de generalização é normalmente avaliada apenas sobre informações que pertençam a esse domínio, de onde decorre sua característica “interpoladora”. Logo, os conjuntos de treinamento e teste devem ser definidos observando tal característica.

Um dos cuidados essenciais para a formação do conjunto de treinamento é assegurar que ele contenha todas as amostras que carregam valores mínimos e máximos de cada variável considerada. Para o conjunto de teste, sempre que possível, devem-se empregar os pontos internos à região de definição da *MLP*.

Como já foram discutidos em 5.5.1, os problemas relativos a este trabalho de tese foram definidos em domínio formado por duas variáveis contínuas, consumo linha (Col) e capacidade de elevação (Cel), e por uma variável qualitativa, relacionada ao modelo do compressor. Neste cenário, considera-se razoável adotar restrições à formação dos conjuntos de treinamento e teste a partir dos planos dados pelas variáveis Col e Cel. Em tais planos, para cada modelo resultam dispersões associadas a regiões poligonais, conforme ilustra a figura 42. Na ilustração está representada a amostra disponível para determinado modelo. Nesse caso, apenas os pontos *g* e *i* poderiam compor o conjunto de teste, visto que os pontos *a*, *b*, *c*, *d* e *e* são vértices da região de definição da função e os pontos *f* e *h* são pontos de máximo e mínimo do parâmetro de interesse, respectivamente, devendo ser considerados no conjunto de treinamento. Adicionalmente, a quantidade de elementos do conjunto de teste foi tomada proporcionalmente ao número de peças por modelo e limitada a cinco compressores por modelo.

Figura 42 – Restrições para formação dos conjuntos de treinamento e testes.



Fonte: Autor.

A seleção do conjunto de validação cruzada para o treinamento de uma rede *MLP* depende do objetivo do *ensemble* ao qual ela se destina. Para as redes do *EInf*, o conjunto de validação é formado pelos dados não selecionados no método *bagging*. Para os elementos do *EInf*, o conjunto de validação de cada rede corresponde a determinada quantidade dos dados internos ao seu domínio de definição, que não tenham sido empregados no conjunto de teste.


Durante o uso, também não se pode garantir a validade de resultados que não estejam compreendidos dentro da região de definição, como é exemplificado no decorrer do capítulo (6.3.1).

6.2.4. Pré-processamento dos dados

São vários os parâmetros que podem ser ajustados com o objetivo de melhorar o desempenho do processo de treinamento das redes *MLP* (HAGAN, DEMUTH, BEALE, 1996; REED, MARKS II, 1999; HAYKIN, 2001). Um dos aspectos imprescindíveis a serem observados, no entanto, é o pré-processamento dos conjuntos de dados das amostras, que inclui a normalização com respeito às faixas de variação (regiões dinâmicas) das funções de ativação empregadas nas camadas intermediárias e de saída.

Como se pode observar na figura 43, a função tangente hiperbólica é limitada por assíntotas horizontais. Assim, ela só apresenta variações significativas para conjuntos de informações pertencentes ao domínio $[u_{mín}, u_{máx}]$. Para evitar a saturação dos neurônios associados, devem-se adequar os conjuntos de valores, definidos inicialmente em intervalos quaisquer da forma $[x_{mín}, x_{máx}]$, proporcionalmente à região dinâmica da função.

Figura 43 – Domínios de ativação para a função tangente hiperbólica $\varphi(u)$.



Fonte: Autor.

Para a normalização dos dados, contou-se com uma das técnicas tipicamente empregadas nessa etapa do processo, baseada no princípio dos segmentos proporcionais (SILVA; SPATTI; FLAUZINO, 2010), também conhecido como teorema de Tales (BOYER; MERZBACH, 2012), que tem aplicação dada pela equação (25),

$$u = \frac{x - x_{mín}}{x_{máx} - x_{mín}}, \quad (25)$$

onde:

u é um valor pertencente à região dinâmica $[u_{mín}, u_{máx}]$;

x é um valor qualquer do conjunto de dados originais $[x_{mín}, x_{máx}]$.

Assim como às variáveis de entrada, faz-se necessário empregar técnicas semelhantes aos dados de saída, observando o intervalo $[\varphi(u_{mín}), \varphi(u_{máx})]$. É válido destacar que todas as variáveis de entrada e de saída devem ser normalizadas³⁸ individualmente, considerando todos os dados disponíveis, ou seja, treinamento e teste. Na etapa de uso da rede, devem ser executadas operações inversas, que façam os valores de saída retornar aos domínios reais da aplicação.

Em todas as etapas do processo de desenvolvimento foi empregado o *nntool* (*Neural Network Toolbox*), um *toolbox* do Matlab (MATHWORKS, 2014), que disponibiliza várias funções e aplicativos que permitem projetar, treinar, visualizar e simular as redes. Os resultados obtidos estão apresentados e discutidos na sequência.

³⁸ Uma propriedade particularmente útil da função tangente hiperbólica $\varphi(v) = \text{atanh}(bv)$ é que para valores adequados das constantes a (1,7159) e b (2/3) se obtém $\varphi(1) = 1$ e $\varphi(-1) = -1$ (HAYKIN, 2001).

6.3. RESULTADOS DOS ESTUDOS DE CASO

Os estudos de caso objetivam avaliar a solução apresentada no capítulo anterior. Na avaliação são observados aspectos relacionados à qualidade das inferências, razoabilidade dos níveis de incerteza estimados e adequabilidade da inserção das ferramentas desenvolvidas à rotina do controle da qualidade da produção de compressores.

A tabela 20 relaciona os valores dos parâmetros obtidos em laboratório para os ensaios de desempenho e de mínima tensão de partida, relativos aos compressores selecionados, a partir do grupo de dados especificado na tabela 12 (página 124), para compor o conjunto de teste. Por não terem sido apresentados às redes em nenhuma etapa do processo de treinamento, objetiva-se avaliar a capacidade de generalização dessas ferramentas, a partir de tal conjunto. Para tanto, as inferências de *COP*, consumo e MTP, realizadas a partir dos respectivos dados de linhas, devem possuir valores razoavelmente próximos aos registrados nas colunas 3, 4 e 5 da referida tabela, respectivamente. É válido lembrar que a IM considerada para o *COP* é de 3,2% do valor indicado na tabela. Da mesma forma, na empresa se considera que a IM do consumo corresponda a 0,9% das indicações. As IM da MTP, entretanto, não foram disponibilizadas para o estudo de caso.

Conforme foi colocado anteriormente, as amostras de EMTP são apenas parte da EDES, logo a quantidade de dados disponíveis é bem menor que para os demais parâmetros. Como comentado em 5.5.2, o problema de MTP deverá ser representado em um subconjunto do domínio de representação dos problemas de consumo e *COP*, logo, não existe qualquer garantia de que os pontos que definem os vértices sejam os mesmos para as duas regiões. Algumas vezes, dados escolhidos para o conjunto de teste de um parâmetro, para um determinado modelo, podem representar pontos de máximo ou de mínimo, quando avaliados para compor o conjunto de teste para outro parâmetro. Noutras vezes, elementos do conjunto de teste de um parâmetro podem representar vértices do conjunto de treinamento de outro parâmetro, especialmente no caso da MTP em relação ao consumo, ou *COP*. Por tais motivos, em poucos casos foi possível usar a mesma peça para testar o desempenho das diferentes ferramentas, conforme se pode constatar na tabela 20, onde se destacam em negrito os valores associados ao conjunto de teste de cada um dos parâmetros de interesse.

Tabela 20 – Valores de laboratório para elementos dos conjuntos de testes.

(continua)

Peça	Capacidade de refrigeração [W]	Consumo [W]	<i>COP</i>	MTP [V]
70A-1	205,08	134,41	1,526	94,50
70A-2	209,68	135,01	1,553	90,50
70A-3	209,12	137,47	1,521	–
70A-4	203,28	135,12	1,504	95,50
70A-5	206,46	135,04	1,529	–
70A-6	204,60	135,46	1,510	95,50
70B-1	195,90	132,18	1,482	92,50
70B-2	204,15	135,51	1,507	–
70B-3	204,54	135,82	1,507	–
70B-4	198,84	134,12	1,483	88,50
70B-5	206,56	135,28	1,527	–
70B-6	207,08	133,31	1,553	91,50
70B-7	203,13	133,05	1,527	90,50
70B-8	200,64	132,00	1,520	–
70B-9	201,55	132,95	1,516	87,50
70C-1	199,44	129,87	1,536	–
70C-2	196,40	128,81	1,525	–
70C-3	195,01	127,29	1,532	–
70C-4	190,75	125,21	1,523	179,00
70C-5	192,49	126,92	1,517	177,00
70D-1	204,48	136,55	1,497	–
70D-2	204,46	136,13	1,502	–
70D-3	205,20	138,50	1,482	177,00
70D-4	207,58	137,86	1,506	175,00
80A-1	182,69	129,40	1,412	153,00
80A-2	190,76	130,86	1,458	159,00
80B-1	234,46	156,47	1,498	–
80C-1	239,41	166,81	1,435	87,50
80C-2	229,19	163,26	1,404	83,50
80D-1	230,49	158,87	1,451	–
80D-2	231,27	160,65	1,440	167,00
80D-3	229,34	156,58	1,465	163,00
80D-4	231,97	158,56	1,463	–
80E-1	246,66	163,44	1,509	96,50
80E-2	238,54	163,59	1,458	93,50
80E-3	242,03	163,47	1,481	–
80E-4	241,20	165,44	1,468	–

Tabela 20 – Valores de laboratório para elementos dos conjuntos de testes.

Peça	Capacidade de refrigeração [W]	Consumo [W]	(conclusão)	
			<i>COP</i>	MTP [V]
80E-5	240,24	163,39	1,470	96,50
80E-6	241,72	161,20	1,499	98,50
80F-1	237,83	154,00	1,544	–
80F-2	236,00	151,76	1,555	–
80F-3	242,54	151,70	1,599	169,00
80F-4	240,12	153,63	1,563	–
80F-5	237,12	155,17	1,528	173,00
80G-1	228,91	149,71	1,529	143,00
80G-2	237,08	149,38	1,587	141,00
80G-3	234,67	151,80	1,546	139,00
80G-4	240,34	153,40	1,567	141,00
80G-5	236,13	153,44	1,539	–
80G-6	235,08	151,84	1,548	–
100A-1	296,90	199,53	1,488	90,50
100A-2	295,53	196,54	1,504	90,50
100A-3	304,98	201,70	1,512	91,50
100A-4	299,81	202,41	1,481	90,50
100A-5	302,63	197,55	1,532	90,50
100A-6	299,91	200,75	1,494	89,50
100A-7	301,60	198,93	1,516	91,50
100B-1	306,16	194,61	1,573	157,00
100B-2	306,66	192,35	1,594	155,00
100B-3	303,84	192,00	1,583	–
100B-4	298,92	189,10	1,581	149,00
100B-5	302,86	189,80	1,596	151,00
100B-6	297,06	189,93	1,564	159,00
100B-7	306,32	192,99	1,587	–
100C-1	248,03	156,14	1,589	175,00
100C-2	242,02	153,51	1,577	–
100C-3	245,01	155,14	1,579	155,00
100C-4	242,62	150,10	1,616	161,00
100C-5	247,49	154,89	1,598	165,00
100C-6	246,24	155,33	1,585	–

Fonte: Autor.

Além da aplicação aos dados do conjunto de teste, que possuem informações de linha e de laboratório, são avaliados lotes completos de compressores. Tais lotes são compostos por grande quantidade de peças

e para o controle da qualidade dos mesmos são avaliadas amostras em laboratório. Para avaliação das ferramentas neurais são comparados os resultados das inferências com a média das informações consideradas para as amostras para ensaio de desempenho (EDES) e para ensaio de mínima tensão de partida (EMTP), obtidas de tais lotes. Na análise é observada, também, a compatibilização entre o tempo de ciclo da linha de produção e o tempo de processamento das informações. Adicionalmente, é avaliada a efetividade da estratégia de compensação dos efeitos da temperatura, observáveis na etapa de resfriamento dos compressores, e verificado o comportamento das ferramentas neurais quando aplicadas em dados que decorram de regiões externas ao domínio de definição das redes *MLP* envolvidas.

Nas seções que seguem (6.3.1 a 6.3.3) são apresentados e discutidos os resultados para cada um dos parâmetros de interesse. Para o caso do *COP*, são brevemente relatadas algumas etapas da evolução do estudo, com o intuito de facilitar a avaliação da efetividade das estratégias empregadas.

6.3.1. COP

Vale salientar, inicialmente, que os valores de inferência do *COP*, bem como dos demais parâmetros de interesse, resultam das médias aritméticas simples dos valores gerados nas saídas dos *EInf*. Para estimar a *IInf* é empregada a equação (24) (página 149) às informações que decorrem das saídas do *EIInf*, conforme discutido em 5.6.3.

Para a análise inicial das inferências e respectivas incertezas de *COP* foram consideradas 1000 redes *MLP*, em ambos os *ensembles*. No caso do *EIInf*, as redes processaram 1000 *SMCu* durante o uso. Os resultados obtidos com a configuração inicial estão relacionados na tabela 21 e ilustrados pelas figuras 44 e 45. Na tabela, a segunda e terceira colunas registram os valores obtidos em ensaios de desempenho e em inferências a partir dos dados de linha, respectivamente. A diferença relativa entre esses dois valores é colocada na quarta coluna. A quinta coluna relaciona as *IInf* estimadas, exprimindo o intervalo de confiança para as inferências. Na sexta coluna, o intervalo de confiança está posto em forma percentual, facilitando a avaliação de sua razoabilidade, pela comparação com o valor da *IM* do *COP* (3,2%). Nas figuras 44 e 45, cada símbolo colorido em vermelho ilustra o valor do ensaio realizado em laboratório, e a barra representa a *IM*. O símbolo subsequente, na cor preta, relaciona-se ao valor da inferência, para a

peça representada pelo símbolo anterior (cor vermelha), e a barra preta à IInf correspondente.

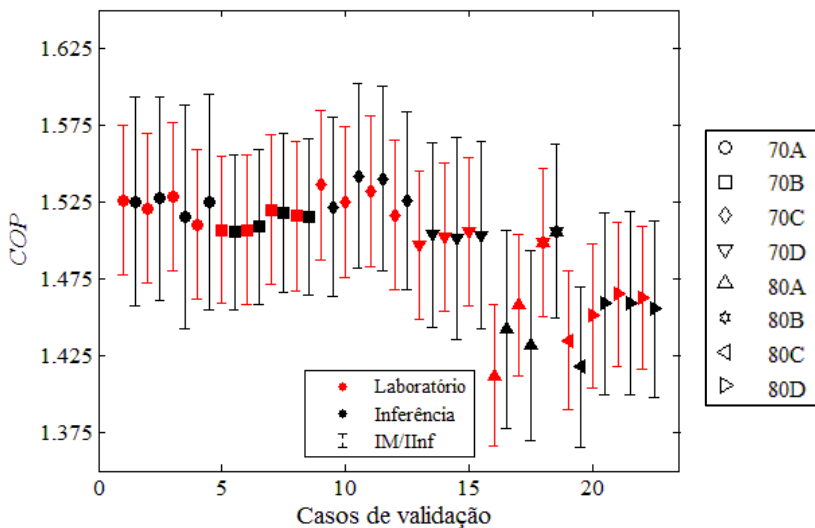
Tabela 21 – Comparação dos resultados das inferências para *COP* com valores dados em laboratório.

(continua)					
Peça	<i>COP</i> (laboratório)	<i>COP</i> (inferência)	Diferença %	IInf	IInf %
70A-1	1,526	1,525	-0,06	± 0,068	± 4,5
70A-3	1,521	1,527	+0,42	± 0,066	± 4,3
70A-5	1,529	1,515	-0,88	± 0,073	± 4,8
70A-6	1,510	1,525	+0,97	± 0,070	± 4,6
70B-2	1,507	1,505	-0,12	± 0,050	± 3,3
70B-3	1,507	1,509	+0,12	± 0,050	± 3,3
70B-8	1,520	1,518	-0,15	± 0,052	± 3,4
70B-9	1,516	1,515	-0,04	± 0,051	± 3,4
70C-1	1,536	1,522	-0,92	± 0,058	± 3,8
70C-2	1,525	1,542	+1,11	± 0,060	± 3,9
70C-3	1,532	1,540	+0,54	± 0,060	± 3,9
70C-5	1,517	1,526	+0,60	± 0,058	± 3,8
70D-1	1,497	1,504	+0,46	± 0,060	± 4,0
70D-2	1,502	1,501	-0,04	± 0,066	± 4,4
70D-4	1,506	1,503	-0,17	± 0,061	± 4,0
80A-1	1,412	1,442	+2,14	± 0,064	± 4,4
80A-2	1,458	1,432	-1,81	± 0,063	± 4,4
80B-1	1,498	1,506	+0,50	± 0,057	± 3,8
80C-1	1,435	1,418	-1,21	± 0,052	± 3,7
80D-1	1,451	1,459	+0,55	± 0,059	± 4,0
80D-3	1,465	1,459	-0,39	± 0,060	± 4,1
80D-4	1,463	1,455	-0,51	± 0,057	± 3,9
80E-3	1,481	1,482	+0,10	± 0,057	± 3,9
80E-4	1,468	1,475	+0,47	± 0,058	± 3,9
80E-5	1,470	1,491	+1,43	± 0,057	± 3,8
80E-6	1,499	1,476	1,52	± 0,057	± 3,9
80F-1	1,544	1,574	+1,91	± 0,063	± 4,0
80F-2	1,555	1,572	+1,09	± 0,065	± 4,1
80F-4	1,563	1,573	+0,66	± 0,064	± 4,1
80F-5	1,528	1,530	+0,13	± 0,083	± 5,4
80G-1	1,529	1,552	+1,52	± 0,061	± 3,9
80G-3	1,546	1,554	+0,49	± 0,060	± 3,8
80G-4	1,567	1,553	-0,89	± 0,062	± 4,0
80G-6	1,548	1,554	+0,36	± 0,060	± 3,8
100A-2	1,504	1,524	+1,36	± 0,060	± 3,9

Tabela 21 – Comparação dos resultados das inferências para *COP* com valores dados em laboratório.


Peça	(conclusão)				
	<i>COP</i> (laboratório)	<i>COP</i> (inferência)	Diferença %	IInf	IInf %
100A-3	1,512	1,517	+0,32	± 0,057	± 3,7
100A-5	1,532	1,530	-0,15	± 0,061	± 4,0
100A-6	1,494	1,509	+0,98	± 0,056	± 3,7
100A-7	1,516	1,513	-0,23	± 0,058	± 3,8
100B-3	1,583	1,574	-0,56	± 0,057	± 3,6
100B-4	1,581	1,577	-0,23	± 0,058	± 3,6
100B-5	1,596	1,578	-1,11	± 0,058	± 3,7
100B-6	1,564	1,576	+0,79	± 0,057	± 3,6
100B-7	1,587	1,569	-1,15	± 0,063	± 4,0
100C-1	1,589	1,584	-0,31	± 0,064	± 4,0
100C-2	1,577	1,592	+0,97	± 0,061	± 3,9
100C-3	1,579	1,592	+0,80	± 0,061	± 3,8
100C-5	1,598	1,591	-0,43	± 0,062	± 3,9
100C-6	1,585	1,600	+0,93	± 0,063	± 4,0

Fonte: Autor.

Figura 44 – Inferências de *COP* para peças dos modelos 70A, 70B, 70C, 70D, 80A, 80B, 80C e 80D – 1000 RNA e 1000 SMCu.

Fonte: Autor.

Figura 45 – Inferências de *COP* para peças dos modelos 80E, 80F, 80G, 100A, 100B e 100C – 1000 RNA e 1000 SMCu.



Fonte: Autor.

Os valores de inferência obtidos são muito próximos dos valores de *COP* medidos. A média do valor absoluto da diferença percentual é de apenas 0,7%, e em apenas um caso ela é superior a 2%. Da mesma forma, os valores de IInf estão muito próximos da IM consideradas, revelando desempenho satisfatório das ferramentas neurais envolvidas.

Um aspecto imprescindível à adequação da ferramenta proposta ao controle da qualidade da produção é que o tempo de processamento das informações para fornecimento do valor inferido e respectivo nível de incerteza não seja superior ao tempo de ciclo (7 s) da linha de produção adotada. Vale destacar que o tempo destinado ao treinamento, ainda que longo, não é considerado nessa avaliação, uma vez que ele é realizado em etapa anterior ao uso das ferramentas.

Para o tratamento de parcela significativa das informações apresentadas neste capítulo foi empregado computador com processador Intel Core i5, com 8 Gbytes de memória RAM, sistema operacional Microsoft Windows 7 Professional, de 64 bits, e Matlab R2013a, para o processamento das RNA. Como essa era a melhor das configurações disponíveis na etapa de realização das atividades, ela foi tomada como referência para a análise que segue. Com tal configuração, considerando que ambos os comitês empregados são formados por 1000 RNA e que aquele voltado à IInf envolve 1000 SMCu, o tempo médio necessário


para processamento da inferência do *COP* e respectiva *IInf* foi de 20 s, muito superior ao tempo de ciclo da linha.

O tempo médio requerido para realizar a inferência é muito pequeno: cerca de 10 ms. Conseqüentemente, a adequação da ferramenta ao controle da qualidade requer diminuição do tempo demandado pela etapa de cômputo da *IInf*, o que deve ser obtido sem prejuízo da qualidade dos níveis de incerteza a serem fornecidos.

Em estudos preliminares, observou-se que o tempo de processamento da *IInf* depende muito mais da quantidade de redes envolvidas no *ensemble* do que do número de SMCu processadas por elas. Da mesma forma, simulações evidenciaram que os ganhos de qualidade são pouco expressivos a partir de certa quantidade de redes.

Gráficos, como aquele do alto da figura 46, mostram que os níveis de *IInf* são pouco influenciados pela variação do número de RNA do *ensemble*: nos casos investigados, relativos ao conjunto de teste do *COP*, a variação observada foi menor que 0,15% do valor inferido (mantido fixo em 1000 o número de SMCu e variando a quantidade de redes, de 50 até 1000, com passo de 25). Na mesma figura, o gráfico da parte de baixo ilustra expressiva variação do tempo de processamento, função das alterações do número de redes do *ensemble*.

Figura 46 – Influência do número de redes do *ensemble* na *IInf* do *COP* e no tempo de processamento dos dados considerando 1000 SMCu.




Fonte: Autor.

Em avaliações adicionais, verificou-se que a variação do tempo de processamento é pouco expressiva, nesse contexto, mantendo-se fixo o número de redes e incrementando-se a quantidade de SMCu. Na figura

47, apresenta-se diagrama de variação da I_{Inf} em decorrência da mudança do número de SMCu, (mantido fixo em 350 o número de RNA e variando-se a quantidade de SMCu, de 50 até 1000, com passos de 25). Como se pode intuir da imagem, a alteração do tempo de processamento é menor que 0,5 s, considerando toda a faixa avaliada.

Figura 47 – Influência do número de SMCu na I_{Inf} do *COP* e no tempo de processamento dos dados considerando 350 RNA.




Fonte: Autor.

Como o uso de 400 RNA já demandaria mais que 7 s de processamento, mesmo para pequeno número de SMCu, e o objetivo era maximizar o produto de SMCu por RNA, optou-se por empregar 350 RNA e 1000 SMCu para computar a I_{Inf} . Os histogramas de frequência da figura 73, do Apêndice I (página 225), mostram que a partir de 200 redes se obtêm distribuições próximas de uma curva normal, na saída das redes que processam 1000 SMCu, corroborando a opção por tal configuração.


Os resultados destacados pelas barras de cor preta nas figuras 48 e 49 decorrem do uso da configuração adotada. Como se pode observar nas ilustrações, os níveis de incerteza se mantiveram praticamente inalterados para todos os elementos. De fato, para o pior caso, essa variação não foi superior a 1% em relação aos valores de I_{Inf} obtidos com 1000 RNA e 1000 SMCu, destacados em vermelho nessas imagens. Vale destacar que cada símbolo preenchido em vermelho e o subseqüente preto descrevem valores iguais, pois a configuração do E_{Inf} se manteve inalterada.

Figura 48 – Comparação entre diferentes configurações para inferências de *COP* – modelos 70A, 70B, 70C, 70D, 80A, 80B, 80C e 80D.



Fonte: Autor.

Figura 49 – Comparação entre diferentes configurações para inferências de *COP* – modelos 80E, 80F, 80G, 100A, 100B e 100C.




Fonte: Autor.

Em 6.2.3, comentou-se sobre a necessidade de garantir que durante o uso as variáveis de entrada estejam compreendidas dentro dos limites de definição da rede *MLP*, região para a qual ela é supostamente capaz de generalizar. Daí decorre a necessidade de conjunto de treinamento formado de amostras representativas do problema, para que o domínio de definição seja efetivamente muito semelhante ao domínio de operação. Na sequência, buscou-se ilustrar a representatividade das amostras de treinamento das redes, quando as mesmas são usadas para avaliar um lote de produção de compressores.

Na figura 50, contrastam-se os vértices da região poligonal empregada no treinamento do modelo 100B com dados de Cel e Col de todo um lote de produção. Os dados representados na cor vermelha são aqueles internos ao domínio de formação da rede. Os dados de cor preta representam pontos que a rede não conheceu durante o treinamento. Aqueles do lado direito da região poligonal têm características muito semelhantes aos pertencentes a ela, com variação apenas em Cel, no nível da sua incerteza. Entretanto, os que estão no lado superior direito do domínio de definição são decorrentes de peças testadas em instantes onde a temperatura de carcaça era inferior a 35 °C.

Figura 50 – Equivalência entre domínio de operação e domínio de definição das redes *MLP* (lote 100B-1 – estação A).




Fonte: Autor.

Para obter as inferências de *COP* desse lote, empregou-se inicialmente um *EInf* treinado especificamente sem informações de

resfriamento, composto por mil redes *MLP* com características idênticas às apresentadas na tabela 18. Da aplicação, obtiveram-se os resultados ilustrados na figura 51. Para avaliação do desempenho da ferramenta neural, considera-se que, para tal modelo, o valor característico do *COP* é 1,580, conforme tabela 37 (página 210 do Apêndice A), e para esse lote, em particular, a média dos valores da EDES resultou em 1,592.

Figura 51 – Inferência dos valores de *COP* para compressores do lote 100B-1 (estação A).



Fonte: Autor.

Como se pode observar, com auxílio do gráfico de temperatura da cargaça, o desempenho das redes só não resultou satisfatório para os compressores testados em temperaturas inferiores aos 35 °C. Para esses casos, os valores de *COP* ficaram muito aquém do valor típico e da média das informações obtidas nos ensaios de EDES.


Dos resultados da figura 51, evidencia-se o bom desempenho das redes para dados internos ao seu domínio de definição e aqueles com características semelhantes. Da mesma forma, destaca-se a necessidade de dotar o treinamento de recurso que permita capacitá-las a operar com informações tomadas em temperaturas mais baixas. A melhoria do desempenho das redes a partir da aplicação de tal recurso – estratégia da compensação indireta da temperatura (5.6.1) – é ilustrada na sequência, ainda com informações do lote 100B-1.

Como relacionado na tabela 19 (página 155), para o modelo 100B se dispunha de resultados de testes dos painéis MFC, tomados na

etapa de resfriamento, para seis compressores, além das respectivas informações de laboratório. Assim como os demais resultados dessa tabela, eles foram devidamente empregados no treinamento das redes dos respectivos *ensembles*.

As inferências obtidas para o lote 100B-1 estão ilustradas em azul na figura 52, em comparação com os resultados decorrentes das redes treinadas sem informações em temperaturas mais baixas, na cor preta, antes ilustrados na figura 51. A imagem indica a eficiência da incorporação das informações, o que foi confirmado por meio de várias simulações semelhantes, para outros modelos listados na tabela 19.

Figura 52 – Inferência dos valores de *COP* para compressores do lote 100B-1 (estação A).



Fonte: Autor.

Vale salientar que mesmo em situações como a apresentada no último exemplo, nas quais as dispersões indiquem significativas variações dos valores de *Col* e *Cel*, todos os resultados apresentados nas análises são relativos a compressores considerados bons, pelos critérios específicos dos testes de capacidade de elevação de pressão (5.2).

Assim como no caso do modelo 100B, também foram avaliados os resultados da aplicação das ferramentas neurais a vários outros lotes de compressores. As análises permitiram constatar a adequabilidade do tempo de processamento e do desempenho, indicados em relação ao conjunto de teste. Para o tempo, considerou-se o limite estabelecido pelo tempo de ciclo da empresa. Para o desempenho, compararam-se os resultados com as informações que decorrem da média aritmética simples das EDES e respectivos intervalos de confiança (IC_{LAB}). Tais intervalos são obtidos a partir da equação (26),

$$IC_{LAB} = \pm \left(t_{n-1, \alpha/2} \frac{s}{\sqrt{N}} \right), \quad (26)$$

onde:

IC_{LAB} é o intervalo de confiança dado à incerteza da EDES;

- $t_{n-1, \alpha/2}$ é o coeficiente *t*-student para $n-1$ graus de liberdade e $\alpha/2$ nível de confiança;
 s é o desvio padrão estimado para a amostra;
 N é o tamanho da amostra;
 α é o nível de confiança estabelecido para o IC_{LAB} .

O desvio padrão s , por sua vez, pode ser estimado a partir de (27),


$$s = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2}, \quad (27)$$

onde:

- s é o desvio padrão estimado para a amostra;
 N é o tamanho da amostra;
 x_i é o i -ésimo valor da amostra;
 \bar{x} é a média da amostra de tamanho N .


Para possibilitar algum entendimento da dinâmica da linha de produção investigada, nas imagens que seguem (figuras 53 a 55) os resultados estão ordenados pelo tempo em que cada peça foi submetida ao painel MFC, respeitando os intervalos de parada, comuns ao processo.

Figura 53 – Inferência dos valores de *COP* para lote de 6328 peças do modelo 70A.



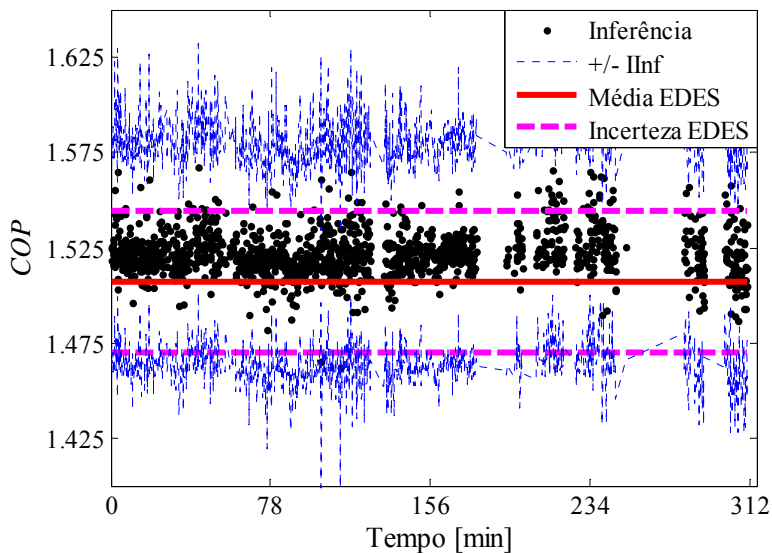
Fonte: Autor.

Figura 54 – Inferência dos valores de *COP* para lote de 1416 peças do modelo 80B.



Fonte: Autor.

Figura 55 – Inferência dos valores de *COP* para lote de 1380 peças do modelo 100A.



Fonte: Autor.

O tempo médio requerido para o processamento das informações ficou em 6,6 s, confirmando os valores obtidos em simulações anteriores, para o conjunto de teste. Da mesma forma, parte muito significativa dos resultados ficou dentro do IC_{LAB} , considerado pela empresa, confirmando o bom desempenho da ferramenta neural, com relação a esse parâmetro. Na sequência são apresentados resultados semelhantes para os parâmetros consumo e MTP.

6.3.2. Consumo

Os *ensembles* empregados neste estudo de caso possuem a mesma configuração daqueles usados no estudo de caso anterior: $EInf_{Co}$ – 1000 redes *MLP*; $EIIInf_{Co}$ – 350 redes *MLP* processando 1000 SMCu. Vale destacar que parcela considerável dos compressores usados para o treinamento das redes de *COP* foi empregada para o treinamento das redes de consumo, visto que compartilham pelo menos os vértices dos domínios de definição e os dados de resfriamento.

Os resultados obtidos com a aplicação de $EInf_{Co}$ e $EIIInf_{Co}$ aos 49 casos do conjunto de teste estão relacionados na tabela 22 e ilustrados pelas figuras 56 e 57, com recursos gráficos e estrutura idênticos aos das figuras 44 e 48, 45 e 49 e tabela 21, respectivamente.

Tabela 22 – Comparação dos resultados das inferências para consumo com valores dados em laboratório.

(continua)

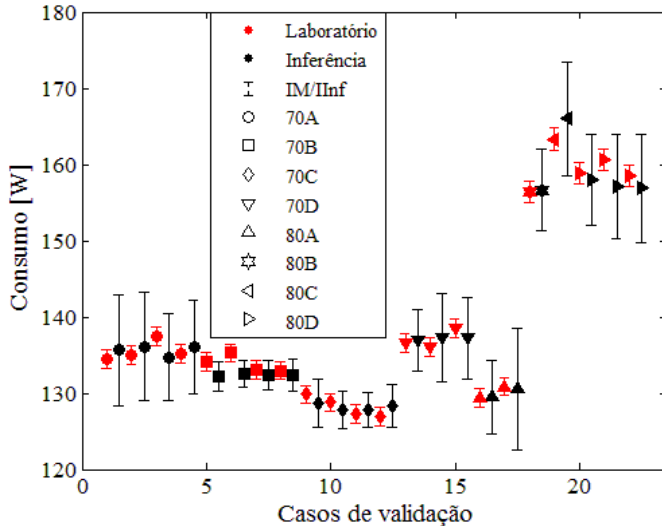
Peça	Consumo (laboratório) [W]	Consumo (inferência) [W]	Diferença %	IInf [W]	IInf %
70A-1	134,41	135,60	+0,88	± 7,31	± 5,4
70A-2	135,01	136,05	+0,77	± 7,11	± 5,2
70A-3	137,47	134,97	-1,82	± 5,70	± 4,2
70A-4	135,12	136,15	+0,77	± 6,16	± 4,5
70B-4	134,12	132,28	-1,38	± 1,93	± 1,5
70B-5	135,28	132,55	-2,01	± 1,75	± 1,3
70B-7	133,05	132,41	-0,49	± 1,89	± 1,4
70B-9	132,95	132,33	-0,47	± 2,15	± 1,6
70C-1	129,87	128,60	-0,97	± 3,14	± 2,4
70C-2	128,81	127,68	-0,87	± 2,46	± 1,9
70C-3	127,29	127,71	+0,33	± 2,34	± 1,8
70C-5	126,92	128,34	+1,12	± 2,82	± 2,2
70D-1	136,55	136,97	+0,31	± 4,04	± 2,9
70D-2	136,13	137,31	+0,87	± 5,83	± 4,2

Tabela 22 – Comparação dos resultados das inferências para consumo com valores dados em laboratório.

Peça	Consumo	Consumo	Diferença	(conclusão)	
	(laboratório)	(inferência)		IInf	IInf
	[W]	[W]	%	[W]	%
70D-3	138,50	137,31	-0,86	± 5,33	± 3,9
80A-1	129,40	129,47	+0,05	± 4,78	± 3,7
80A-2	130,86	130,57	-0,22	± 7,96	± 6,1
80B-1	156,47	156,71	+0,15	± 5,33	± 3,4
80C-2	163,26	166,15	+1,77	± 7,41	± 4,5
80D-1	158,87	157,89	-0,62	± 5,95	± 3,8
80D-2	160,65	157,25	-2,11	± 6,77	± 4,3
80D-4	158,56	157,00	-0,98	± 7,06	± 4,5
80E-1	163,44	164,96	+0,93	± 4,33	± 2,6
80E-2	163,59	163,81	+0,14	± 3,35	± 2,0
80E-3	163,47	163,89	+0,26	± 3,84	± 2,3
80E-4	165,44	164,46	-0,59	± 4,13	± 2,5
80F-1	154,00	151,78	-1,45	± 5,20	± 3,4
80F-3	151,70	154,57	+1,89	± 7,00	± 4,5
80F-4	153,63	152,11	-0,99	± 5,30	± 3,5
80F-5	155,17	156,06	+0,58	± 8,60	± 5,5
80G-2	149,38	152,28	+1,94	± 6,52	± 4,3
80G-3	151,80	151,53	-0,18	± 6,18	± 4,1
80G-4	153,40	150,97	-1,58	± 6,56	± 4,3
80G-5	153,44	150,38	-1,99	± 7,01	± 4,7
100A-2	196,54	197,02	+0,24	± 5,37	± 2,7
100A-3	201,70	198,21	-1,73	± 3,92	± 2,0
100A-4	202,41	198,39	-1,98	± 4,53	± 2,3
100A-6	200,75	199,51	-0,62	± 3,64	± 1,8
100A-7	198,93	198,88	-0,02	± 4,03	± 2,0
100B-3	192,00	190,94	-0,55	± 4,23	± 2,2
100B-4	189,10	191,22	+1,12	± 5,13	± 2,7
100B-5	189,80	189,79	-0,00	± 6,07	± 3,2
100B-6	189,93	191,61	+0,89	± 4,85	± 2,5
100B-7	192,99	194,59	+0,83	± 4,99	± 2,6
100C-1	156,14	154,54	-1,03	± 5,75	± 3,7
100C-2	153,51	153,81	+0,19	± 4,92	± 3,2
100C-3	155,14	153,91	-0,79	± 4,80	± 3,1
100C-5	154,89	153,94	-0,61	± 4,96	± 3,2
100C-6	155,33	153,20	-1,37	± 4,40	± 2,9

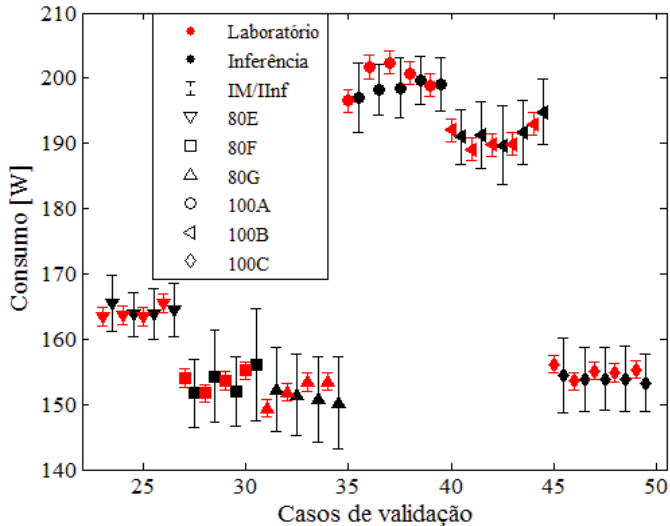
Fonte: Autor.

Figura 56 – Inferências de consumo para peças dos modelos 70A, 70B, 70C, 70D, 80A, 80B, 80C e 80D.



Fonte: Autor.

Figura 57 – Inferências de consumo para peças dos modelos 80E, 80F, 80G, 80G, 100A, 100B e 100C.




Fonte: Autor.

Os valores de inferência obtidos são muito próximos dos valores de consumo medidos em laboratório. A média do valor absoluto da diferença percentual é de apenas 0,9%. Individualmente, tal valor foi superior a 2% para somente dois casos. As IInf estimadas, entretanto, são geralmente muito maiores que as IM consideradas, visto que a média dos valores informados na sexta coluna da tabela 22 é 3,2%, enquanto a IM é 0,9%.

Para a maioria dos compressores do conjunto de teste, as incertezas atribuídas à ferramenta neural são preponderantes em relação às parcelas devidas aos dados de laboratório, no cômputo da IInf (5.6.3). Para outras peças, como aquelas do modelo 70B, a diferença entre os valores dessas parcelas é pequena. Particularmente, este modelo é o que possui maior representação no conjunto de treinamento, com 68 dados, visto que dos 8 casos dos testes de resfriamento (tabela 19) resultam 45 informações aplicáveis.

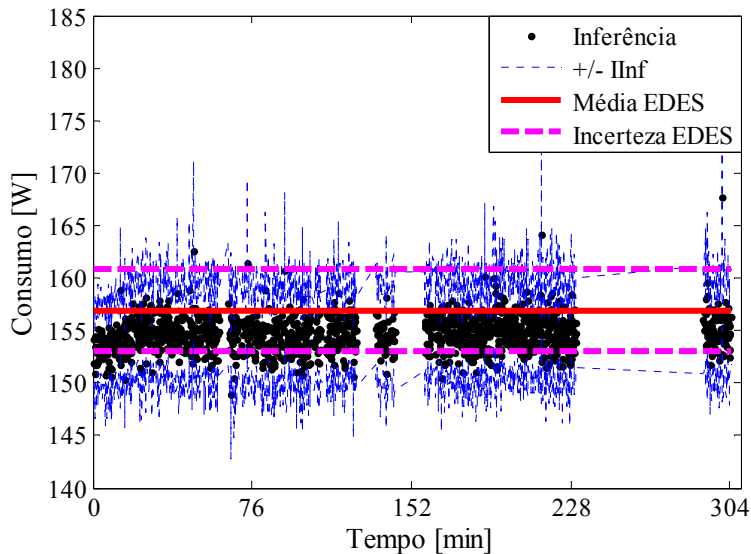
Na sequência são ilustrados (figuras 58 a 60) os resultados das avaliações sobre três lotes completos de compressores. Como no estudo de caso anterior, as respostas estão ordenadas pelo tempo em que cada peça foi submetida ao painel MFC e comparadas com informações decorrentes dos ensaios de desempenho para a amostra de cada lote.

Figura 58 – Inferência dos valores de consumo para lote de 768 peças do modelo 70C.




Fonte: Autor.

Figura 59 – Inferência dos valores de consumo para lote de 1416 peças do modelo 80B.



Fonte: Autor.

Figura 60 – Inferência dos valores de consumo para lote de 1380 peças do modelo 100A.



Fonte: Autor.

O tempo médio demandado pelo processamento das informações (6,6 s) se mostrou compatível com o tempo de ciclo da linha de produção considerada para os estudos de caso. Da mesma forma, a parcela mais expressiva dos resultados ficou enquadrada no IC_{LAB} , disponibilizado pela empresa para os lotes, confirmando o bom desempenho da ferramenta neural, também para o consumo. Na sequência são apresentados resultados obtidos para MTP.

6.3.3. Mínima tensão de partida


Como nos estudos de caso anteriores, o $EInf_{MTP}$ é constituído de 1000 redes *MLP* enquanto o $EInf_{MTP}$ possui 350, que processam 1000 SMCu. Os resultados da aplicação dessas ferramentas neurais aos vinte casos do conjunto de teste estão relacionados na tabela 23 e ilustrados pela figura 61.

Tabela 23 – Comparação dos resultados das inferências para MTP com valores dados em laboratório.

Peça	MTP (laboratório) [V]	MTP (inferência) [V]	Diferença %	IInf [V]	IInf %
70A-1	94,50	92,25	-2,38	± 6,25	± 6,8
70A-2	90,50	91,50	+1,10	± 6,50	± 7,1
70A-4	95,50	94,75	-0,79	± 4,75	± 5,0
70B-1	92,50	91,00	-1,62	± 4,50	± 4,9
70B-6	91,50	90,75	-0,82	± 4,75	± 5,2
70B-7	90,50	91,00	+0,55	± 4,50	± 4,9
70C-4	179,00	178,00	-0,56	± 15,00	± 8,4
70D-3	177,00	176,50	-0,28	± 10,50	± 5,9
80A-1	153,00	153,50	+0,33	± 15,50	± 10,1
80C-2	83,50	83,50	-0,00	± 8,50	± 10,1
80D-3	163,00	162,00	-0,61	± 10,00	± 6,2
80F-5	173,00	176,50	+2,02	± 15,00	± 8,5
100A-1	90,50	91,00	+0,55	± 3,25	± 3,6
100A-3	91,50	91,00	-0,55	± 2,75	± 3,0
100A-4	90,50	91,25	+0,83	± 3,25	± 3,6
100B-1	157,00	154,00	-1,91	± 7,50	± 4,9
100B-2	155,00	154,50	-0,32	± 8,00	± 5,2
100B-6	159,00	153,50	-3,46	± 7,50	± 4,9
100C-4	161,00	164,50	+2,17	± 13,50	± 8,2
100C-5	165,00	163,50	-0,91	± 13,50	± 8,2

Fonte: Autor.

Figura 61 – Inferências de MTP para peças dos modelos 70A, 70B, 70C, 70D, 80A, 80C, 80D, 80E, 80F, 100A, 100B e 100C.



Fonte: Autor.


O valor absoluto da diferença percentual superou 2% em quatro casos e a média de todos os resultados ficou em 1,1%, mostrando que os valores de inferência obtidos são próximos dos valores de MTP medidos em laboratório, para a maioria dos elementos do conjunto de teste.

Como para este estudo de caso não foi disponibilizada a IM considerada na empresa para MTP, as IInf obtidas podem estar representando a aleatoriedade presente nas informações de laboratório, as IM das variáveis de linha (Col e Cel), e as incertezas associadas ao treinamento (5.6.3). Os menores valores encontrados decorreram novamente do modelo com maior representação no conjunto de treinamento, 100A, que possui informações adicionais de resfriamento, sendo retratado no total por 33 casos.

Nas figuras 62 a 64 estão ilustrados os resultados das avaliações sobre três lotes completos de compressores. Vale destacar que as redes para MTP foram treinadas para todos os modelos relacionados na tabela 12 (página 124) e não apenas para aqueles relacionados no conjunto de teste, função do pequeno número de informações disponíveis. Entretanto, os *ensembles* foram aplicados, com êxito, em lotes de todos os modelos, como é o caso daquele ilustrado pela figura 63. Como nos resultados dos estudos de caso anteriores, as respostas estão ordenadas pelo tempo da submissão ao painel MFC e comparadas com


informações decorrentes dos ensaios de mínima tensão de partida para a amostra de cada lote.

Figura 62 – Inferência dos valores de MTP para lote de 4147 peças do modelo 70A.




Fonte: Autor.

Figura 63 – Inferência dos valores de MTP para lote de 1416 peças do modelo 80B.



Fonte: Autor.

Figura 64 – Inferência dos valores de MTP para lote de 1380 peças do modelo 100A.



Fonte: Autor.

O tempo médio requerido para o processamento também se mostrou compatível com o tempo de ciclo da linha de produção, como nos estudos de caso anteriores. A quase totalidade das inferências de MTP ficou dentro do IC_{LAB} , considerado pela empresa para tais lotes, confirmando o bom desempenho da ferramenta neural, apesar da pequena quantidade de dados disponíveis para o treinamento das redes envolvidas.

6.4. CONSIDERAÇÕES

No capítulo anterior foi apresentado inicialmente o teste de capacidade de elevação de pressão, empregado como ferramenta de apoio ao controle da qualidade de produção em empresa com elevadíssimo fluxo de produção de compressores. Por meio de análise de dados, constatou-se que existe correlação entre variáveis características desses testes e parâmetros normalmente obtidos em ensaios de desempenho e de mínima tensão de partida, realizados em condições laboratoriais, para pequenas amostras dos lotes produzidos. Com base nos níveis de correlação identificados, apresentou-se proposta do trabalho de tese, que consiste em realizar inferências, com garantia

metrológica, dos parâmetros normalmente obtidos em laboratório a partir das variáveis resultantes dos ensaios de linha de produção. Adicionalmente, discutiu-se a forma de encaminhamento da solução, por meio de ferramenta baseada em redes neurais artificiais.

No capítulo atual, detalharam-se três estudos de caso realizados na empresa líder mundial na produção de compressores, com tempo de ciclo muito pequeno (7 s), objetivando avaliar a validade da proposta de estimar *COP*, consumo e MTP, e a viabilidade de integração da solução ao controle da qualidade da produção em uma empresa com tais características. Foram apresentados aspectos relevantes da implementação das ferramentas neurais e das estratégias empregadas na solução. Também foram apresentados e discutidos diversos resultados da aplicação das ferramentas neurais aos conjuntos de testes e lotes completos de compressores, que indicaram a validade e viabilidade de integração da solução.

No próximo são apresentadas considerações sobre a conclusão deste trabalho de tese, enumerando os resultados alcançados e discutindo sua relação com os objetivos propostos, destacando a importância e ineditismo do trabalho, e apontando os ganhos que dele deverão decorrer. Oportunamente, são destacados pontos que necessitam de abordagens complementares e são sugeridos trabalhos adicionais em temas identificados durante a pesquisa.

7. CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS

O objetivo principal deste trabalho foi desenvolver métodos que possibilitassem obter estimativas de parâmetros típicos de ensaios de desempenho – *COP*, consumo – e de mínima tensão de partida – *MTP* – em tempo muito reduzido e com níveis de incerteza conhecidos, de forma a serem integráveis ao controle da qualidade junto à linha de produção, em plantas com elevado fluxo produtivo.

Ampla consulta à literatura técnica e científica não revelou conjunto estruturado de recursos aplicáveis à solução desses casos. Entretanto, ao investigar o estado da arte em ensaios de desempenho e de mínima tensão de partida, redes neurais artificiais (RNA), e determinação de intervalos de confiança na aplicação de RNA, assentaram-se bases para estabelecer ferramentas que possibilitaram lograr êxito na consecução dos objetivos propostos.

Na sequência são apresentadas considerações sobre a conclusão deste trabalho de tese e sugestões para trabalhos complementares.

7.1. CONCLUSÕES

Nesta seção estão apresentados aspectos técnicos e científicos que nortearam o desenvolvimento do trabalho, além de considerações sobre o alcance dos objetivos propostos, face aos resultados obtidos.

7.1.1. Sobre a revisão bibliográfica

Por meio da revisão bibliográfica, identificaram-se vários aspectos limitantes à aplicação dos ensaios de desempenho e de mínima tensão de partida de compressores ao controle da qualidade em empresas com elevado fluxo de produção. Quando empregados com esse objetivo, o uso de tais ensaios fica restrito apenas a pequenas amostras dos lotes produzidos, especialmente devido ao custo e ao longo tempo necessário para realizá-los. O levantamento bibliográfico revelou inúmeros esforços que vêm sendo despendidos na diminuição desses tempos.

A aparente limitação de avanços em nível de hardware, função das peculiaridades dos ensaios, tem motivado a incessante busca por soluções em nível de software. Sob esse enfoque, várias publicações destacam o uso de ferramentas de inteligência artificial, com vistas à diminuição do tempo dos ensaios. Apesar dos inúmeros esforços, os resultados atuais ainda estão muito longe de possibilitar adequá-los às

rotinas do controle da qualidade em plantas de reduzido tempo de ciclo – segundos ou poucos minutos.

Trabalhos atuais mostraram ser possível estabelecer correlação entre resultados de testes rápidos, realizados na linha de produção, com valores de capacidade de refrigeração, que é outro parâmetro normalmente obtido em ensaio de desempenho. Devido ao significativo nível apresentado pelas correlações, foi estabelecido modelo baseado em RNA para inferência de tal parâmetro, a partir dos dados de linha a ele correlacionados.

Quando ferramentas baseadas em RNA são empregadas, especialmente em sistemas industriais, é imprescindível que sejam estabelecidas formas para quantificar a incerteza associada às suas saídas. Esse tema motivou o desenvolvimento de vários trabalhos visando estimar intervalos de confiança para modelos neurais, mas a maioria das abordagens tipicamente empregadas é limitada, e quase sempre voltada para alguma aplicação mais específica.

Recentemente, publicou-se método que combina a reamostragem *bootstrap*, tipicamente utilizada para fornecer intervalos de confiança em redes neurais, com o método de Monte Carlo, frequentemente empregado na avaliação da incerteza de medição (CORAL, 2014; CORAL *et al.*, 2015). A integração desses métodos representou significativa evolução no estado da arte, por ter se consubstanciado em abordagem alinhada aos preceitos metrológicos vigentes, adequada à avaliação da incerteza da saída de ferramentas baseadas em redes neurais. Entretanto, identificaram-se limitações à sua aplicação aos casos em questão. A solução proposta pelo autor do presente trabalho para superar tais limitações consiste em fornecer por meio de dois *ensembles* distintos, de forma independente, a inferência e sua incerteza.

7.1.2. Sobre a realização das inferências

De maneira geral, um estudo mais aprofundado das relações existentes entre os dados de linha e os parâmetros de laboratório ficou prejudicado pela pequena quantidade de informações disponíveis para alguns modelos de compressores. Tratá-los individualmente teria limitado ainda mais a capacidade de investigação deste trabalho, no qual se optou pela modelagem de cada um dos parâmetros de interesse por meio de uma única relação funcional, em domínio que envolvesse todos os modelos de compressores disponíveis. Essa representação tornou o problema mais complexo do ponto de vista da modelagem pretendida. Com o necessário acréscimo da influência da temperatura, o grau de

dificuldade do problema ficou ainda maior, o que tornou o uso da ferramenta neural para a aproximação das funções pretendidas uma opção, que se mostrou eficaz.

A opção pelo uso do *ensemble* conferiu ao método a robustez desejável, especialmente quando da sua integração às aplicações industriais. A decisão por *ensemble* específico para a inferência ($EInf$) é plenamente justificada no âmbito da proposta estabelecida neste trabalho, por se considerar que a estimativa dos parâmetros de interesse não deve ser susceptível ao método empregado para avaliação da incerteza da inferência ($IInf$).

7.1.3. Sobre a avaliação da incerteza das inferências

Da forma como foi estruturado, o processo de treinamento das redes do *Ensemble* de Incerteza da Inferência ($EInf$) permite considerar na incerteza que dele decorre (I_{EInf}) as componentes aleatórias da incerteza de medição dos parâmetros de laboratório (IM_{lab}), desde que o conjunto de treinamento seja representativo. Tal aleatoriedade pode ser tanto da natureza física do parâmetro quanto inserida pelo processo de medição da grandeza. Por outro lado, o resultado da Incerteza da Inferência ($IInf$) é a combinação da incerteza resultante do $EInf$ (I_{EInf}) e da IM_{lab} . Caso a aleatoriedade presente nas informações de treinamento fosse apenas relativa à medição, então bastaria considerar aquela que não está prevista no método: a componente sistemática. Entretanto, como não é possível separar tais componentes, a partir dos dados disponíveis, optou-se por considerar a eventual duplicidade da componente aleatória, o que vai a favor da segurança na indicação da incerteza da inferência.

7.1.4. Sobre os resultados experimentais

Os valores de inferência obtidos para os três estudos resultaram muito próximos dos valores medidos em laboratório. A média do valor absoluto das diferenças resultantes, em termos percentuais, foi de apenas 0,7%, 0,9%, e 1,1%, respectivamente, para os conjuntos de teste de *COP* e consumo (que possuem 49 elementos cada) e para os 20 elementos do conjunto de teste de MTP. Ademais, essa diferença foi superior a 2% para apenas uma peça no caso do *COP* e duas no caso de consumo. Para o caso MTP, essa diferença foi superior a 2% para 4 elementos, o que é justificável pelo volume muito menor de informações para o treinamento das redes envolvidas.

As *IInf* estimadas se mostraram muito próximas dos valores das *IM* consideradas das medições em laboratório para o caso do *COP*. Enquanto a *IM* em laboratório é de 3,2% a média das *IInf* para os elementos do conjunto de teste ficou em 3,9%. Para o caso do consumo essa relação foi pouco menos favorável, enquanto a *IM* em laboratório é de 0,9%, a *IInf* média resultou em 3,2%. De maneira geral, a *IInf* está estreitamente vinculada à qualidade da instrumentação empregada nos testes de linha e na obtenção dos valores em laboratório. Consequentemente, a diminuição dos níveis obtidos de *IInf* requer que se invista na redução das incertezas de medição das variáveis envolvidas.

Nos diagramas oriundos da aplicação da ferramenta neural aos lotes completos de compressores, observam-se muitas inferências que se distinguem do comportamento médio resultante. A análise desses casos revelou que, invariavelmente, essas informações decorriam de regiões externas ao domínio de formação das redes envolvidas, aí incluídas aquelas submetidas aos testes de linha com temperatura de carcaça muito baixa. De maneira geral, os níveis de incerteza e de *IInf* se mostraram compatíveis para os casos compreendidos na região de definição das redes envolvidas. Consequentemente, o aumento da capacidade de fornecer informações ainda mais consistentes e para todos os resultados dos lotes de produção está intimamente ligado à disponibilização de volume maior de amostras representativas para treinamento das redes.

Nos três estudos de caso, todos os resultados de inferência e *IInf* foram obtidos em menos de 7 segundos, compatíveis com o tempo de ciclo da linha de produção envolvida, proporcionando expressiva economia de tempo na obtenção das informações dos parâmetros, visto que o tempo médio do ensaio de desempenho é superior a 4 horas e o de partida maior que 50 minutos.

Por meio dos estudos de caso, constatou-se a validade da proposta de estimar *COP*, consumo e *MTP*, e confirmou-se a viabilidade de integração da solução ao controle da qualidade integrado ao processo de produção de compressores de refrigeração.

7.1.5. Sobre as inovações concretizadas

De modo geral, os resultados do trabalho propiciaram avanços no estado da arte, gerando perspectivas muito favoráveis de integração dos métodos estabelecidos aos procedimentos de controle da qualidade em plantas com elevadíssimo fluxo de produção de compressores,

proporcionando maior aproveitamento das informações obtidas em testes atualmente realizados. Os procedimentos propostos nesta tese permitem realizar em poucos segundos ensaios em linha de produção com resultados muito próximos daqueles obtidos em horas de ensaio em laboratório. A confiabilidade dos resultados, que é requisito essencial para aplicação da solução em processos metroológicos em ambientes industriais, também é assegurada no método proposto pelo autor do presente trabalho. Assim, as ferramentas geradas representam benefícios diretos às empresas do setor de produção de compressores, e servem para consolidar ainda mais o Laboratório de Metrologia e Automação do Departamento de Engenharia Mecânica da UFSC como referência no desenvolvimento de recursos de inteligência artificial aplicados em metrologia e instrumentação.

7.2. SUGESTÕES PARA TRABALHOS FUTUROS

Nesta seção estão apontados itens que necessitam de maior investigação para o aprimoramento do trabalho. Da mesma forma, também é sugerida investigação da viabilidade de aplicação das ferramentas em outra etapa da manufatura.

7.2.1. Sobre o aperfeiçoamento do método

Neste trabalho foi aperfeiçoada técnica disponibilizada em publicações recentes para avaliação de incerteza de inferência realizada por meio de ferramenta baseada em redes neurais. O método havia se mostrado útil para avaliação de outro parâmetro – capacidade de refrigeração – e se configurava no estado da arte, por considerar erros do processo de aprendizagem e, também, incertezas de medição durante o treinamento e uso do modelo neural. Entretanto, ele não se mostrou adequado no âmbito deste trabalho.

Para garantir que a versão modificada do método possa firmar-se como abordagem efetivamente útil e aplicável de forma geral, propõe-se avaliá-la exaustivamente em diversas situações. Entretanto, alguns aspectos importantes necessitam de estudos complementares mais imediatos, mediante uso de informações que não estavam disponíveis durante a realização deste trabalho.

Assim como as simulações de Monte Carlo acabam provocando perda da capacidade de generalização das redes envolvidas, o número excessivo de informações de resfriamento, em comparação com informações típicas, pode provocar efeito semelhante, forçando as saídas

a um comportamento marcadamente definido pela média das informações do conjunto de treinamento. Sugere-se, então, adicionar rotina ao pré-processamento dos dados que permita levar as informações obtidas em temperaturas mais baixas aos valores considerados típicos. Para tanto, faz-se necessário levar em conta informações de resfriamento dos vários modelos envolvidos.

Outro aspecto que merece atenção pode ser mais bem compreendido com o auxílio da figura 74 do Apêndice J (página 227). Na imagem superior estão destacadas quatro informações de *COP*, a partir de duas elipses. Cada uma dessas elipses traz informações do parâmetro de uma das vinte distintas bancadas de ensaios empregadas. Os quatro valores estão associados a uma região muito próxima no plano dado por *Col* e *Cel*, logo, esperava-se que os valores resultantes de *COP* fossem muito próximos, ou estivessem dentro dos limites de suas incertezas. Do caso ilustrado, pode-se intuir que exista parcela sistemática, de valor considerável, entre os resultados das diferentes bancadas. Do ponto de vista das redes empregadas, esse comportamento é aleatório, e dificilmente pode ser assimilado por qualquer um dos recursos utilizados no método proposto. Assim, propõem-se outros dois estudos adicionais, vinculados a tal característica:

- avaliar o treinamento de redes que considerem informações de ensaios de desempenho obtidas de uma única bancada;
- avaliar a reprodutibilidade do ensaio de desempenho e inserir na equação (24) – página 149 – uma parcela de incerteza relacionada ao resultado obtido.

Acredita-se que a adoção de qualquer uma das estratégias diminuiria em muito a probabilidade de ocorrência de resultados como aqueles ilustrados pela figura 56 (página 176), para os dois primeiros elementos do modelo 70B, onde o valor de laboratório sequer ficou compreendido nos limites do intervalo de confiança gerado a partir da *Inf*.

7.2.2. Sobre a proposta de aplicação na pré-montagem de compressores

Os testes de capacidade de elevação de pressão também são realizados no meio da linha de montagem de compressores. Nesse estágio, o compressor ainda se encontra aberto e os testes são feitos objetivando encontrar defeitos que possam ser reparados antes que a tampa seja selada ao corpo do mesmo. Para a realização desse primeiro

teste, o equipamento conta com uma tampa móvel, que, sobre pressão, sela temporariamente o compressor. As variáveis características do ensaio são obtidas de maneira semelhante ao teste realizado nos painéis da montagem final (MFC), com exceção da medição do ruído vibroacústico, nesse caso obtido por meio de um transdutor de pressão sonora. Devido ao local onde estão posicionados, esses painéis de elevação de pressão são denominados PMC (pré-montagem de compressores). Nesses painéis os testes também são realizados em 7 segundos. A análise nos painéis PMC pode se revelar mais complexa, função da influência de outras características da etapa do processo, como tampa solta, vedação hermética e queda de pressão. Entretanto, sugere-se avaliar a aplicabilidade das ferramentas desenvolvidas, para inferir valores de *COP*, consumo e mínima tensão de partida, a partir das variáveis resultantes dos testes nesses painéis.

REFERÊNCIAS

ABLAMEYKO S. *et al.* **Neural Networks for Instrumentation, Measurement and Related Industrial Applications**. NATO Science Series: Computer & Systems Sciences, v. 185, 2003.

ABLOW, C. M.; KAYLOR, D. J. **A Committee Solution of the Pattern Recognition Problem**. IEEE Transaction on Information Theory, v. 11, n. 3, pp. 453-455, 1965.

ABNT. **NBR 5383-1**: Máquinas Elétricas Girantes Parte 1: Motores de Indução Trifásicos – Ensaios. 2002.

ADAMOWICZ, E. C.; SAMPAIO, M. E. C. S.; BARBOZA, A. O. **Reconhecimento de Padrões de Análise Econômico-Financeira de Empresas**. XXII Encontro Nacional de Engenharia de Produção. Curitiba. Enegep, 2002.

AHMAD, Z.; ZHANG, J. **A Comparison of Different Method for Combining Multiple Neural Network Models**. Proceedings of the International Joint Conference on Neural Network, v. 1, pp. 828-833, May 2002.

ALBERTAZZI, A.; SOUSA, A. R. **Fundamentos de Metrologia Científica e Industrial**. Malone, 2008. 407 p.

ARCAKLIOĞLU, E.; ÇAVUŞOĞLU, A.; ERIŞEN, A. **Thermodynamic Analyses of Refrigerant Mixtures Using Artificial Neural Networks**. Applied Energy, n 78, pp. 219-230, 2004.

ARENCIBIA, K.; TRICIO, V. **Evaluación Experimental de Compresores Herméticos em Condiciones de Clima Tropical. Eficiencia y Capacidad Frigorífica**. Informacion Tecnológica, Vol. 25, n° 2, pp. 103-110, 2014.

ASHRAE STANDARD. **ANSI/ASHRAE 23-2005**: Methods of testing for rating positive displacement refrigerant compressors and condensing units. Atlanta, EUA, 2005.

BARBOSA, B. H. G. **Computação Evolucionária e Máquinas de Comitê na Identificação de Sistemas Não-lineares**. 224 f. Tese (Doutorado em Engenharia Elétrica) – Programa de Pós-graduação em Engenharia Elétrica, Universidade Federal de Minas, Belo Horizonte, 2009.

BARBOSA, F. Q. **Redução de Incertezas nas Medições de Grandezas Elétricas em uma Bancada de Ensaio de Desempenho de Compressores**. 190 f. Dissertação (Mestrado em Metrologia Científica e Industrial) – Programa de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina, Florianópolis, 2006.

BARRON, W. R. **Princípios de Termometria com Infravermelho**. Manual de referência técnica de temperatura. OMEGA, pp. 68-71, 2014.

BASHEER, I. A.; HAJMEER, M. **Artificial Neural Networks: Fundamentals, Computing, Design, and Application**. Journal of Microbiological Methods, v. 43, pp. 3-31, 2000.

BASTES, J. M.; GRANGER, C. W. J. **The Combination of Forecasts**. Operations Research Quarterly, 20, pp. 451-468, 1969.

BIPM, IEC, IFCC, ILAC, ISO, IUPAC, IUPAP, OIML. **JCGM 100**: Evaluation of measurement data – Guide to the expression of uncertainty in measurement. Sep. 2008a. 134 p.

BIPM, IEC, IFCC, ILAC, ISO, IUPAC, IUPAP, OIML. **JCGM 101**: Supplement 1 to the “Guide to the expression of uncertainty in measurement” – Propagation of distributions using a Monte Carlo method. Sep. 2008b. 90 p.

BISHOP, C. M. **Neural Networks for Pattern Recognition**. Clarendon Press, Oxford, 1995.

BJÖRCK, Å. **Numerical Methods for Least Squares Problems**. SIAM. Philadelphia, 1996.

BOYER, C. B; MERZBACH, U. C. **História da Matemática**. Tradução Helena Castro. 3. ed. Editora Blucher, São Paulo, 2012.

BREIMAN, L. **Bagging Predictors**. Machine Learning, n. 24, pp. 123-140, 1996.

CARDOSO, R. B. **Avaliação da Economia de Energia Atribuída ao Programa Selo Procel em Freezers e Refrigeradores**. Dissertação (Mestrado em Engenharia da Energia) – Programa de Pós-graduação em Ciências em Engenharia da Energia, Universidade Federal de Itajubá, Itajubá, 2008.

CASELLA, A. V. **Ferramenta Fuzzy-Bayesiana para Identificação do Instante de Entrada no Regime Permanente em Ensaios de Desempenho de Compressores**. 110 f. Dissertação (Mestrado em

Metrologia Científica e Industrial) – Programa de Pós-Graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina, Florianópolis, 2008.

CICHOCKI, A.; UNBENHAUEN. **Neural Networks for Optimisation and Signal Processing**. New York. John Wiley & Sons: 1993.

COLORADO, D. *et al.* **Error Propagation on COP Prediction by Artificial Neural Network in a Water Purification System Integrated to an Absorption Heat Transformer**. *Renewable energy*. n. 36, 2011. pp. 1315-1322.

CORAL, R. *et al.* **Development of a Committee of Artificial Neural Networks for the Performance Testing of Compressors for Thermal Machines in Very Reduced Times**. *Metrologia i Systemy Pomiarowe/ Metrology and Measuring Systems*. v. 22, PP. 79-88, 2015.

CORAL, R. **Método para Estimar a Capacidade de Refrigeração de Compressores Herméticos Integrável à Linha de Produção**. 238 f. Tese (Doutorado) – Curso de Pós-Graduação em Engenharia Mecânica, Departamento de Engenharia Mecânica, Universidade Federal de Santa Catarina, Florianópolis, 2014.

COSTA, J. G. F. **Automação de Ensaios de Compressores de Refrigeração Operando sob Condições Extremas**. 195 f. Dissertação (Mestrado em Metrologia Científica e Industrial) – Programa de Pós-Graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina, Florianópolis, 2010.

CYBENKO, G. V. **Approximation by Superpositions of a Sigmoidal Function**. *Mathematics of Control, Signal and Systems*. Vol. 2, n. 4, PP. 303-314, 1989.

CHRYSSOLOURIS, G.; LEE, M.; RAMSEY, A. **Confidence Interval Prediction for Neural Network Models**. *IEEE Transactions on Neural Networks*, v. 7, n. 1, pp. 229-232, Jan. 1996.

DAQSYS. **Sistema de Teste de Compressores**. (Manual do usuário). 2008.

DENCKER, R. B. **Detecção de Falha na Montagem de Compressores Herméticos por Redes Neurais Artificiais**. Dissertação (Mestrado em Engenharia Mecânica) – Programa de Pós-Graduação em Engenharia Mecânica, Universidade Federal de Santa Catarina, Florianópolis, 2002.

DEVORE, J. L. **Probabilidade e Estatística para Engenharia e Ciências**. Tradução Joaquim P. N. da Silva. Editora Thomson, São Paulo, 2006.

DIN – DEUTSCHES INSTITUT FÜR NORMUNG. **EN 12900**: Refrigerant Compressors – Rating Conditions, Tolerances and Presentation of Manufacturer’s Performance Data (English version), Germany, Jan. 2006.

DIN – DEUTSCHES INSTITUT FÜR NORMUNG. **EN 13771-1**: Compressors and condensing units for refrigeration – Performance testing and test methods – Part 1: Refrigerant compressors. Germany, Aug. 2008.

DONATELLI, G. D.; KONRATH, A. C. **Simulação de Monte Carlo na Avaliação de Incertezas de Medição**. Revista de Ciência & Tecnologia. V. 13, n. 25/26, PP. 5-15, 2005.

DRUCKER, H. *et al.* **Boosting and other Ensemble Methods**. Neural Computation, v. 6, n. 6, PP. 1289-1301, 1994.

ELETROBRÁS. **Procel – Programa Nacional de Conservação de Energia Elétrica**. 2010. Disponível em <<http://www.eletronbras.com/elb/data/Pages/LUMIS0389BBA8PTBRIE.htm>>. Acesso: mar 2015.

ECKHARDT, R. **Stan Ulam, John Von Neumann, and the Monte Carlo Method**. Los Alamos Science, Special Issue 15, pp. 131-137, 1987.

EDWARDS, P. J. *et al.* **Minimizing Risk Using Prediction Uncertainty in Neural Network Estimation Fusion and its Application to Papermaking**. IEEE Transactions on Neural Networks, v. 13, i. 3, May 2002.

EFRON, B. **Bootstrap Methods: Another Look at the Jackknife**. The Anals of Statistics, n. 1, pp. 1-20, 1979.

EFRON, B.; TIBSHIRANI, R. **An Introduction to the Bootstrap**. Chapman & Hall, NY, 1993.

EFRON, B.; TIBSHIRANI, R. **Bootstrap Methods for Standard Errors, Confidence Intervals, and Other Measures of Statistical Accuracy**. Statistical Science, v. 1, n. 1, PP. 54-77, 1986.

EMBRACO. **Catálogo Eletrônico de Produtos**. Joinville. Disponível em <<http://www.embraco.com/catalog/Default.aspx>> acesso: dez 2015.

EMBRACO. **Embraco Renova sua Marca**. Joinville, jul. 2011. Disponível em <<http://www.embraco.com/default.aspx?idNoticia=171&tabid=99>> acesso: jan 2014.

EMBRACO. **Manual de Aplicação de Compressores**. Joinville, set. 2009. Disponível em <<http://www.embraco.com/DesktopModules/DownloadsAdmin/Arquivos/00004.pdf>> acesso: dez 2013.

EMBRACO. **Perfil e História**. Joinville, 2011a. Disponível em <<http://www.embraco.com/Default.aspx?tabid=77>>. Acesso em Fevereiro de 2012.

EMBRACO. **Teste de Mínima Tensão de Partida**. Procedimento Operacional Padrão, Joinville, 2012.

ERTUNC, H. M.; HOSOZ, M. **Artificial Neural Network Analysis of a Refrigeration System with an Evaporative Condenser**. Applied Thermal Engineering 26 (2005), pp. 627-635, 2005.

FERREIRA, L. **Intervalos de Confiança para o Ponto Crítico de Modelos de Regressão Quadrática: Abordagens Bootstrap, Bayesiana e Fuzzy**. 176 f. Tese (Doutorado) – Curso de Pós-Graduação em Estatística e Experimentação Agropecuária, Universidade Federal de Lavras, Lavras, 2012.

FLESCH, R. C. C.; NORMEY-RICO, J. E. **Modelling, Identification, and Control of a Calorimeter Used for Performance Evaluation of Refrigerant Compressors**. Control Engineering Practice, v. 18, n. 3, Mar. 2010, p. 254-261.

FLESCH, R. C. C. **Desenvolvimento e Instalação de Recursos de Automação Aplicados a Ensaios de Compressores de Refrigeração de Embraco**. Monografia (Curso de Engenharia de Controle e Automação Industrial), Universidade Federal de Santa Catarina, Florianópolis, 2006.

FORTUNA, L. *et al.* **Virtual Instruments Based on Stacked Neural Networks to Improve Product Quality Monitoring in a Refinery**. IEEE Transactions on Instrumentation and Measurement, v. 56, i. 1, Feb. 2007.

- GHOBADIAN, B.; RAHIMI, H.; NIKBAKHT, A. M.; NAJAFI, G.; YUSAF, T. F. **Diesel Engine Performance and Exhaust Emission Analysis Using Waste Cooking Biodiesel Fuel with an Artificial Neural Network**. *Renewable energy*, v. 34, n. 4, pp. 976-982, 2009.
- GONZÁLEZ-MANTEIGA, W. G.; SÁNCHEZ, J. M. P.; URROZ, J. J. R. **The Bootstrap: A Review**. *Computational Statistics*, v. 9, n. 1, pp. 165-205, 1994.
- GRANITTO, P. M.; VERDES, P. F.; CECCATTO, H. A. **Neural Networks Ensembles: Evaluation of Aggregation algorithms**. *Artificial Intelligence*, vol. 163, i. 2, p. 139-162, 2005.
- GUSMAN, C. S. A. **Incerteza de Medição em Redes Neurais Artificiais Aplicadas à Manutenção Preditiva de Transformadores**. Dissertação (Mestrado em Metrologia) – Programa de Pós-graduação em Metrologia, Pontifícia Universidade Católica, Rio de Janeiro, 2011.
- HAGAN, M. T.; DEMUTH, H. B.; BEALE, M. H. **Neural Network Design**. PWS Publishing, Boston, Massachusetts, 1996.
- HAGAN, M. T.; MENHAJ, M. B. **Training Feedforward Networks with the Marquardt Algorithm**. *IEEE Transactions on Neural Networks*, vol. 5, n. 6, pp. 989-993, 1994.
- HANSEN, L. D.; HART, R. M. **The Art of Calorimetry**. Departamento de Química e Bioquímica. University of Brigham Young. EUA, 2003.
- HANSEN, L. K.; SALAMON, P. **Neural Networks Ensembles**. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 12, n. 10, pp. 993-1001, 1990.
- HAYKIN, S. **Redes Neurais: Princípios e Prática**. Tradução Paulo Martins Engel. 2. ed. Porto Alegre: Bookman, 2001.
- HE, S.; LI, J. **Confidence Intervals for Neural Networks and Applications to Modeling Engineering Materials**, in *Artificial Neural Networks – Application*, InTech, n. 11, pp. 337-360, 2011.
- HECKMANN, J. R. **Identificação de Potenciais Aplicações da Inteligência Artificial na Metrologia**. 142 f. Dissertação (Mestrado) - Curso de Pós-Graduação em Metrologia Científica e Industrial, Departamento de Engenharia Mecânica, Universidade Federal de Santa Catarina, Florianópolis, 1999.

HENKLEIN, P. **Análise de Ensaios de Desempenho de Compressores Herméticos Durante o Transitório**. 136 f. Dissertação (Mestrado em Metrologia Científica e Industrial) – Programa de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina, Florianópolis, 2006.

HIGGINS, J. **The Radical Statistician: A Beginners Guide to Unleashing the Power of Applied Statistics in the Real World**. 5 ed. California: Jim Higgins Publishing 2005.

HOUAISS, A. **Dicionário Eletrônico Houaiss da Língua Portuguesa**. Editora Objetiva, 2002.

HU, Y. H.; HWANG, J. **Handbook of Neural Network Signal Processing**. CRC Press LLC, USA, 2002. 384 p.

HWANG, J. T. G.; DING, A. A. **Prediction Intervals for Artificial Neural Networks**. Journal of the American Statistical Association, v. 92, n. 438, June 1997.

IBGE – Instituto Brasileiro de Geografia e Estatística. **Pesquisa Nacional por Amostra de Domicílios**. 2013.

INMETRO. **Sistema Internacional de Unidades – SI**. 9. Ed., Rio de Janeiro. 2012. 94 p.

ISO – INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. **ISO 917: Testing of refrigerant compressors**. 2. ed. Switzerland, 1989.

JACOBS, R. A. *et al.* **Adaptive Mixtures of Local Experts**. Neural Computation, n. 3, pp. 79-87, 1991.

JAIN, A. K.; MAO, J. **Neural Networks and Their Applications**. Review of Scientific Instruments, vol. 65, nº 6, pp. 1803-1832, 1994.

KASKI, S.; KOHONEN, T. **Exploratory Data Analysis by the Self-Organizing Map: Structures of Welfare and Poverty in the World**. Proceedings of the Third International Conference on Neural Networks in the Capital Markets, Londres, Inglaterra, pp. 498-507, 1995.

KOHONEN, T. **MATLAB Implementations and Applications of the Self-Organizing Maps**. Helsinki: Unigrafia Oy, 2014.

KOHONEN, T. **Self-Organized Formation of Topologically Correct Feature Maps**. Biological Cybernetics, vol. 43, pp. 59-69. 1982.

KOHONEN, T. **Self-Organization and Associate Memory**. London, UK: Springer-Verlag, 1984.

KOLMOGOROV, A. N. **On the Representation of Continuous Functions of Several Variables by Superposition of Continuous Functions of the Variable and Addition**. Doklady Akademii. Nauk USSR, vol. 114, pp. 679-681, 1957.

LEIGHTON, D. T. **Investigation of Household Refrigerator with Alternative Low Global Warming Potential Refrigerants**. 124 f. Thesis (master of Science), University of Maryland, College Park, USA, 2011.

LEONARD, J. A.; KRAMER, M. A.; UNGAR, L. H.; **A Neural Network Architecture that Computes its Own Reliability**. Computers Chem. Engng. V. 16, n. 9, pp. 819-835, 1992.

LEVENBERG, K. **A Method for the Solution of Certain Problems in Least Squares**. Quarterly of Applied Mathematics, n. 5, pp. 164-168, 1944.

LIMA, C. A. M. **Comitê de Máquinas: Uma Abordagem Unificada Empregando Máquinas de Vetor Suporte**. 342 f. Tese (Doutorado) – Curso de Pós-Graduação da Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas, 2004.

LIMA, V. R. **Desenvolvimento e Validação de Sistema Neural para Redução de Tempo de Ensaios de Desempenho de Compressores**. 173 f. Dissertação (Mestrado em Metrologia Científica e Industrial) – Programa de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina, Florianópolis, 2010.

LIPPMANN, R. P. **An Introduction to Computing with Neural Nets**. IEEE ASSP Magazine, vol. 4, pp. 4-22, 1987.

LOESCH, C.; SARI, S. T. **Redes Neurais Artificiais: Fundamentos e Modelos**. Blumenau: Editora da FURB, 1996.

MARQUARDT, D. **An Algorithm for Least-Squares Estimation of Nonlinear Parameters**. SIAM Journal on Applied Mathematics, vol. 11, n. 2, pp413-441, 1963.

MATHWORKS. **Neural Networks Toolbox – User's Manual**. Versão 5, 2007.

McCULLOCH, W. S.; PITTS, W. **A Logical Calculus of the Ideas Immanent in Nervous Activity**. Bulletin of Mathematical Biophysics, vol. 5, pp. 115-133. 1943.

MICHAELIS. **Moderno Dicionário Inglês**. Editora Melhoramentos, 2011. Disponível em <<http://michaelis.uol.com.br/moderno/ingles/-index.php>>. Acesso em Outubro de 2014.

MIDANY, T. T. El; BAZ, M. A. El; ADBELWAHED, M. S. **Improve Characteristics of Manufactured Products Using Artificial Neural Network Performance Prediction Model**. International Journal of Recent advances in Mechanical Engineering (IJMECH), v. 2, n. 4, Nov. 2013.

MINITAB. **User Manual**. Version 17.2.1, 2015.

MONTGOMERY, D. C.; RUNGER, G. C. **Estatística Aplicada e Probabilidade para Engenheiros**. 2. ed., Rio de Janeiro: LTC, 2003.

MONTGOMERY, D. C.; PECK, E. A.; VINING, G. G. **Introduction to Linear Regression Analysis**. 3 ed. New York: Wiley, 2001.

NILSSON, N. J. **Artificial Intelligence: A New Synthesis**. 2. ed. [S.l.]: Morgan Kaufmann, 1998.

NILSSON, N. J. **Learning Machines: Foundations of Trainable Pattern-Classifying Systems**. New York, McGraw-Hill, 1965.

OLIVEIRA, M. A.; MONTINI, A. A.; BERGMANN, D. R. **Construction of Prediction Intervals for Neural Networks Via Multivariate Regression and Their Application to Heterocedastic Series**. Facef pesquisa, v. 10, n. 3, Franca, São Paulo, 2007.

OSBORNE, M. R. **Fisher's Method of Scoring**. International Statistical Review. N. 86, PP. 271-286, 1992.

PACHECO, A. L. S. **Desenvolvimento de Sistema para Medir a Resistência de Isolamento em Motores de Compressores Energizados**. 180 f. Dissertação (Mestrado em Metrologia Científica e Industrial) – Programa de Pós-Graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina, Florianópolis, 2007.

PAPADOPOULOS, G.; EDWARDS, P. J.; MURRAY, A. F. **Confidence Estimation Methods for Neural Networks: A Practical Comparison**. IEEE Transactions on Neural Networks, v.12, i. 6, Nov. 2001.

PAPADOPOULOS, G.; EDWARDS, P. J.; MURRAY, A. F.

Confidence Estimation Methods for Neural Networks: A Practical Comparison. ESANN'2000 proceedings – European Symposium on Artificial Neural Networks, Bruges, Belgium, pp. 75-80, Apr. 2000.

PENZ, C. A. **Procedimentos para Prover Confiabilidade ao Uso de Inteligência Artificial em Ensaios de Desempenho de Compressores Herméticos de Refrigeração.** 179 f. Tese (Doutorado) – Curso de Pós-Graduação em Engenharia Mecânica, Departamento de Engenharia Mecânica, Universidade Federal de Santa Catarina, Florianópolis, 2011.

PERRONE, M. P.; COOPER, L. N. **When Networks Disagree: Ensemble Methods for Hybrid Neural Networks.** In R. J. Mammone (Ed.). Artificial Networks for Speech and Vision, PP. 126-142. Chapman & Hall, London, 1993.

PETROVIC, S. A. B. **Proposta de Arquitetura do Sistema de Automação Aplicado a Ensaios de Desempenho de Compressores Herméticos de Refrigeração.** 115 f. Dissertação (Mestrado em Metrologia Científica e Industrial) – Programa de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina, Florianópolis, 2007.

POLETTI, E. L. **Aprimoramento de uma Bancada de Ensaios de Desempenho de Compressores Herméticos Visando Reduzir Incertezas de Medição.** 107 f. Dissertação (Mestrado em Metrologia Científica e Industrial) – Programa de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina, Florianópolis, 2006.

POLYAK, B. T. **Some Methods of Speeding the Convergence of Iteration Methods.** USSR Computational Mathematics and Mathematics Physics, vol. 4, n. 5, pp. 1-17, 1964.

PROCEL/ELETRÓBRÁS. **Pesquisa de Posse de Equipamentos e Hábitos de Uso – Ano Base 2005 –.** Avaliação do Mercado de Eficiência Energética no Brasil, 2007.

RADEMACHER, R.; KIM, K. **Domestic Refrigerators: Recent Developments.** International Journal of Refrigeration, Vol. 19, n. 1, pp. 61-69, 1996.

REED, R. D.; MARKS II, R. J. **Neural Smoothing: Supervised Learning in Feedforward Artificial Neural Networks.** MIT Press, Cambridge, Massachusetts, 1999.

RICH, E.; KNIGHT, K. **Artificial Intelligence**. 2. ed. [S.l.]: McGraw-Hill, 2001.

RUMELHART, D. E. *et al.* **Parallel Distributed Processing: Explorations in the Microstructure of Cognition**. Bradford Book and MIT Press, Cambridge, MA, 1986.

RUSSEL, S.; NORVIG, P.; **Inteligência Artificial**. Rio de Janeiro, Elsevier, 2013.

SCHAPIRE, R. E. **A Brief Introduction to Boosting**. In Proceedings of the Sixteenth International Joint Conference on Artificial Intelligence, pp. 1401-1406, Morgan Kaufmann, 1999.

SCHLICKMANN, D. G. **Aprimoramento e Caracterização do Comportamento Metrológico de uma Bancada de Ensaios de Partida e Tombamento de Compressores de Refrigeração**. 142 f. Dissertação (Mestrado em Engenharia Mecânica) – Programa de Pós-Graduação em Engenharia Mecânica, Universidade Federal de Santa Catarina, Florianópolis, 2012.

SCUSSEL, J. N. **Proposta de Ações para Reduzir o Tempo Demandado por Ensaio de Desempenho de Compressores**. 152 f. Dissertação (Mestrado em Metrologia Científica e Industrial) – Programa de Pós-Graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina, Florianópolis, 2006.

SHARKEY, A.; SHARKEY, N. (1997). **Combining Diverse Neural Networks**. The Knowledge Engineering Review, v. 12, n. 3, pp. 231-247, 1997.

SHARKEY, A. **Combining Artificial Neural Nets: Ensemble and Modular Multi-Net System**, in Multi-Net Systems, Springer-Verlag, 1999.

SHEPHERD, A. J. **Second-Order Methods for Neural Networks – Fast and Reliable Methods for Multi-Layer Perceptron**. Springer, 1997.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais para Engenharia e Ciências Aplicadas – Curso Prático**. São Paulo: Artiber, 2010.

SILVEIRA, A. N. **Diminuição do Tempo de Transitório em Ensaios de Desempenho de Compressores Utilizando Injeção de Corrente Contínua**. 225 f. Dissertação (Mestrado em Metrologia Científica e

Industrial) – Programa de Pós-Graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina, Florianópolis, 2010.

SINGARAM, L. **ANN Prediction Models for Mechanical Properties of AZ61 MG Alloy Fabricated by Equal Channel Angular Pressing.** International Journal of Research and Reviews in Applied Sciences, v. 8, n. 3, pp. 337-345, sep. 2011.

STEINBACH, K. **Identificação do Instante de Entrada em Condições de Regime Permanente em Ensaios de Desempenho de Compressores.** 198 f. Dissertação (Mestrado em Metrologia Científica e Industrial) – Programa de Pós-Graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina, Florianópolis, 2008.

SWIDER, D. J.; BROWNE, P. K.; BANSAL, V. **Modelling of Vapour-Compression Liquid Chillers with Neural Networks.** Applied Thermal Engineering, n. 21, pp. 311-329, 2001.

THOMAZINI JR, J. C. **Desenvolvimento de Recursos para Aumentar a Produtividade de uma Bancada de Ensaios de Partida e Tombamento de Compressores de Refrigeração.** 147 f. Dissertação (Mestrado em Engenharia Mecânica) – Programa de Pós-Graduação em Engenharia Mecânica, Universidade Federal de Santa Catarina, Florianópolis, 2013.

TIBSHIRANI, R. **A Comparison of Some Error Estimates for Neural Network Models.** Department of Preventive Medicine and Biostatistics, University of Toronto, 1994.

TIWARI, A.; GUPTA, R. C. **Recent Developments on Domestic Refrigerator – a Review.** International Journal of Engineering and Science Technology (IJEST), v. 3, n. 5, pp. 4233-4239, 2011.

TRICHAKIS, I.; NIKOLOS, I.; KARATZAS, G. P. **Comparison of Bootstrap Confidence Intervals for an ANN Model of a Karstic Aquifer Response.** Hydrological Processes, DOI: 10.1002/hyp.8044, 2011.

VEAUX, R. D. De; *et al.* **Prediction Intervals for Neural Networks Via Nonlinear Regression.** Technometrics, v. 40, n. 4, Nov. 1998.

WELSTEAD, S. T. **Neural Network and Fuzzy Logic Applications in C/C++.** New York: John Willey & Sons, 1994.

WIDROW, B.; HOFF, M. E. **Adaptative Switching Circuits.** Proceedings of the IRE Wescon Convention Record, pp. 96-104, 1960.

WOLPERT, D. H. **Stacked Generalization**. Neural Networks, v. 5, n. 2, pp. 241-259, 1992.

WU, B.; YU, J. **A Neural Network Ensemble Model for On-line Monitoring of Process Mean and Variance Shifts in Correlated Processes**. Expert Systems with Applications. vol. 37, i. 6, p. 4058-4065, 2010.

YANG, B. S. *et al.* **Condition Classification of Small Reciprocating Compressor for Refrigerators Using Artificial Neural Networks and Support Vector Machines**. Mechanical Systems and Signal Processing 19 (2005), pp. 371 – 390, 2005.

YANG, L. *et al.* **An Evaluation of Confidence Bound Estimation Methods for Neural Networks**. ESIT 2000, Aachen, Germany, pp. 322 – 329, Sep. 2000.

YU, H Yu; WILAMOWSKI, B. M. “Levenberg–Marquardt Training” **Industrial Electronics Handbook**, vol. 5 – Intelligent Systems, 2 Ed., chapter 12, pp. 12-1 to 12-15, CRC Press, 2011.

YU, J. B.; XI, L. F. A. **Neural Network Ensemble-Based Model for Online Monitoring and Diagnosis of Out-of-Control Signals in Multivariate Manufacturing Processes**. Expert Systems with Applications. vol. 36, i. 1, p. 909-921, 2009.

ZANOL, M. G. **Concepção de Arquitetura para Aquisição de Dados e Controle de Bancada para Teste de Compressores**. 62 f. Monografia (Curso de Engenharia de Controle e Automação Industrial), Universidade Federal de Santa Catarina, Florianópolis, 2015.

ZHU *et al.* **One Parameterized Model of Indirect Measurement Based on Neural Network and its Sensitivity Coefficient Computing**. Journal of Physics: Conference Series, v. 13, pp. 202-205, 2005.

ZIO, E. **A Study of the Bootstrap Method for Estimating the Accuracy of Artificial Neural Networks in Predicting Nuclear Transient Processes**. IEEE Transactions on Nuclear Sciences, v.53, n. 3, Jun. 2006.

ZOU, R.; LUNG, W. **Neural Network Embedded Monte Carlo Approach for Water Quality Modeling under Input Information Uncertainty**. Journal of computing in civil engineering. April 2002. P. 135-142.

APÊNDICE A – CARACTERIZAÇÃO DOS COMPRESSORES HERMÉTICOS DE REFRIGERAÇÃO EMPREGADOS

Tabela 24 – Características do compressor de modelo 70A.

Parâmetro	Característica nominal
Capacidade de refrigeração	208 W
Eficiência (<i>COP</i>)	1,53
Motor (tipo/torque)	<i>RSIR</i> ³⁹ / <i>LST</i> ⁴⁰
Alimentação/ Frequência	115-127 V/ 60 Hz
Tipo de refrigerante	R-600a

Fonte: Adaptado de Embraco (2015).

Tabela 25 – Características do compressor de modelo 70B.

Parâmetro	Característica nominal
Capacidade de refrigeração	201 W
Eficiência (<i>COP</i>)	1,52
Motor (tipo/torque)	<i>RSIR/LST</i>
Alimentação/ Frequência	115-127 V/ 60 Hz
Tipo de refrigerante	R-134a

Fonte: Adaptado de Embraco (2015).

Tabela 26 – Características do compressor de modelo 70C.

Parâmetro	Característica nominal
Capacidade de refrigeração	199 W
Eficiência (<i>COP</i>)	1,55
Motor (tipo/torque)	<i>RSIR/LST</i>
Alimentação/ Frequência	220-240 V/ 50-60 Hz
Tipo de refrigerante	R-134a

Fonte: Adaptado de Embraco (2015).

³⁹ (*Resistive Start – Inductive Run – RSIR*) – motor de indução de fase auxiliar, caracterizado por enrolamento de partida com alta resistência ôhmica, que deve ser desconectado por relé eletromecânico ou de estado sólido, quando for atingido um determinado percentual da velocidade síncrona (PACHECO, 2007).

⁴⁰ (*Low Starting Torque – LST*) – motor com baixo torque de partida empregado em sistemas com tubo capilar (PACHECO, 2007).

Tabela 27 – Características do compressor de modelo 70D.

Parâmetro	Característica nominal
Capacidade de refrigeração	208 W
Eficiência (<i>COP</i>)	1,51
Motor (tipo/torque)	<i>RSIR/LST</i>
Alimentação/ Frequência	220 V/ 60 Hz
Tipo de refrigerante	R-600a

Fonte: Adaptado de Embraco (2015).

Tabela 28 – Características do compressor de modelo 80A.

Parâmetro	Característica nominal
Capacidade de refrigeração	189 W
Eficiência (<i>COP</i>)	1,54
Motor (tipo/torque)	<i>RSIR/LST</i>
Alimentação/ Frequência	220 V/ 50 Hz
Tipo de refrigerante	R-134a

Fonte: Adaptado de Embraco (2015).

Tabela 29 – Características do compressor de modelo 80B.

Parâmetro	Característica nominal
Capacidade de refrigeração	238 W
Eficiência (<i>COP</i>)	1,54
Motor (tipo/torque)	<i>RSIR-CSIR⁴¹/LST</i>
Alimentação/ Frequência	115-127 V/ 60 Hz
Tipo de refrigerante	R-134a

Fonte: Adaptado de Embraco (2015).

Tabela 30 – Características do compressor de modelo 80C.

Parâmetro	Característica nominal
Capacidade de refrigeração	237 W
Eficiência (<i>COP</i>)	1,45
Motor (tipo/torque)	<i>RSIR/LST</i>
Alimentação/ Frequência	115-127 V/ 60 Hz
Tipo de refrigerante	R-134a

Fonte: Adaptado de Embraco (2015).

⁴¹ (*Capacitive Start – Inductive Run – CSIR*) – é um motor de fase auxiliar, como o *RSIR*, mas o deslocamento no tempo entre as duas correntes é obtido por meio de um capacitor em série com o enrolamento auxiliar, o que prove torque de partida mais alto.

Tabela 31 – Características do compressor de modelo 80D.

Parâmetro	Característica nominal
Capacidade de refrigeração	236 W
Eficiência (<i>COP</i>)	1,48
Motor (tipo/torque)	<i>RSIR/LST</i>
Alimentação/ Frequência	220 V/ 60 Hz
Tipo de refrigerante	R-134a

Fonte: Adaptado de Embraco (2015).

Tabela 32 – Características do compressor de modelo 80E.

Parâmetro	Característica nominal
Capacidade de refrigeração	245 W
Eficiência (<i>COP</i>)	1,55
Motor (tipo/torque)	<i>RSIR/LST</i>
Alimentação/ Frequência	115-127 V/ 60 Hz
Tipo de refrigerante	R-600a

Fonte: Adaptado de Embraco (2015).

Tabela 33 – Características do compressor de modelo 80F.

Parâmetro	Característica nominal
Capacidade de refrigeração	242 W
Eficiência (<i>COP</i>)	1,59
Motor (tipo/torque)	<i>RSIR/LST</i>
Alimentação/ Frequência	220 V/ 50-60 Hz
Tipo de refrigerante	R-600a

Fonte: Adaptado de Embraco (2015).

Tabela 34 – Características do compressor de modelo 80G.

Parâmetro	Característica nominal
Capacidade de refrigeração	233 W
Eficiência (<i>COP</i>)	1,59
Motor (tipo/torque)	<i>RSIR/LST</i>
Alimentação/ Frequência	220-240 V/ 50-60 Hz
Tipo de refrigerante	R-134a

Fonte: Adaptado de Embraco (2015).

Tabela 35 – Características do compressor de modelo 90A.

Parâmetro	Característica nominal
Capacidade de refrigeração	210 W
Eficiência (<i>COP</i>)	1,50
Motor (tipo/torque)	<i>RSIR-CSIR/LST</i>
Alimentação/ Frequência	220-240 V/ 50-60 Hz
Tipo de refrigerante	R-134a

Fonte: Adaptado de Embraco (2015).

Tabela 36 – Características do compressor de modelo 100A.

Parâmetro	Característica nominal
Capacidade de refrigeração	308 W
Eficiência (<i>COP</i>)	1,58
Motor (tipo/torque)	<i>RSIR-CSIR/LST</i>
Alimentação/ Frequência	115-127 V/ 60 Hz
Tipo de refrigerante	R-134a

Fonte: Adaptado de Embraco (2015).

Tabela 37 – Características do compressor de modelo 100B.

Parâmetro	Característica nominal
Capacidade de refrigeração	308 W
Eficiência (<i>COP</i>)	1,58
Motor (tipo/torque)	<i>RSIR-CSIR/LST</i>
Alimentação/ Frequência	220-240 V/ 50-60 Hz
Tipo de refrigerante	R-134a

Fonte: Adaptado de Embraco (2015).

Tabela 38 – Características do compressor de modelo 100C.

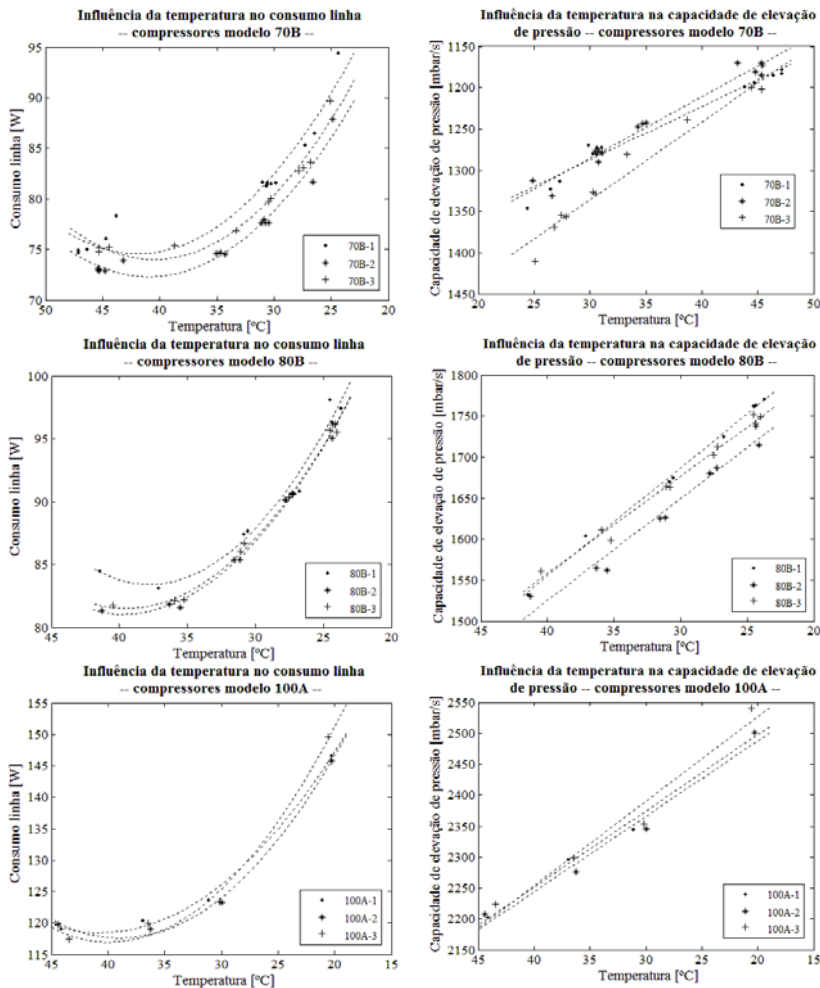
Parâmetro	Característica nominal
Capacidade de refrigeração	243 W
Eficiência (<i>COP</i>)	1,53
Motor (tipo/torque)	<i>RSCR⁴²/LST</i>
Alimentação/ Frequência	220-240 V/ 50 Hz
Tipo de refrigerante	R-134a

Fonte: Adaptado de Embraco (2015).

⁴² (*Resistive Start – Capacitive Run – RSCR*) – motor de indução de fase auxiliar que utiliza capacitor de funcionamento permanente (PACHECO, 2007).


APÊNDICE B – AVALIAÇÃO DA POTÊNCIA ELÉTRICA CONSUMIDA E CAPACIDADE DE ELEVAÇÃO DE PRESSÃO DURANTE O RESFRIAMENTO DE COMPRESSORES

Figura 65 – Influência da temperatura no consumo linha e capacidade de elevação de pressão - compressores de modelo 70B, 80B e 100A.



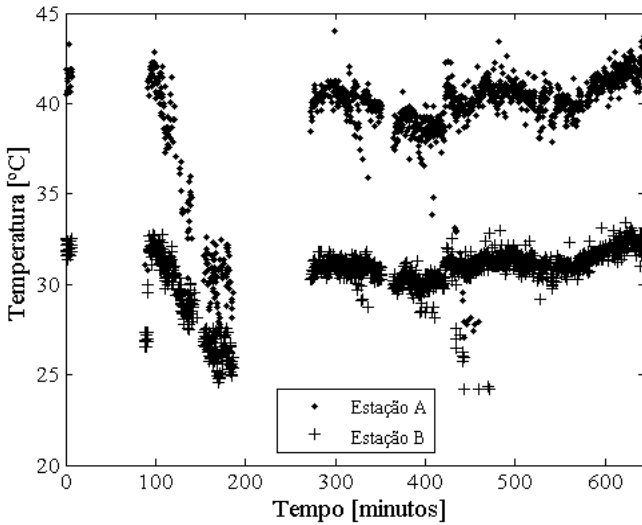
Fonte: Autor.

Figura 66 – Valores de temperatura da carcaça obtidos nas estações A e B para o lote 70D-04.



Fonte: Autor.

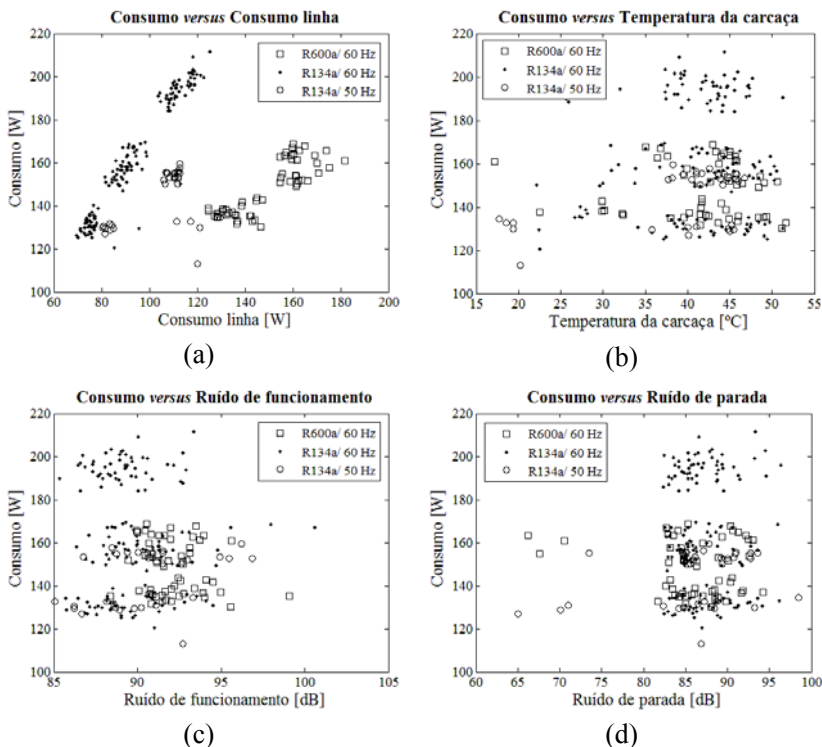
Figura 67 – Valores de temperatura da carcaça obtidos nas estações A e B para o lote 80C-02.



Fonte: Autor.

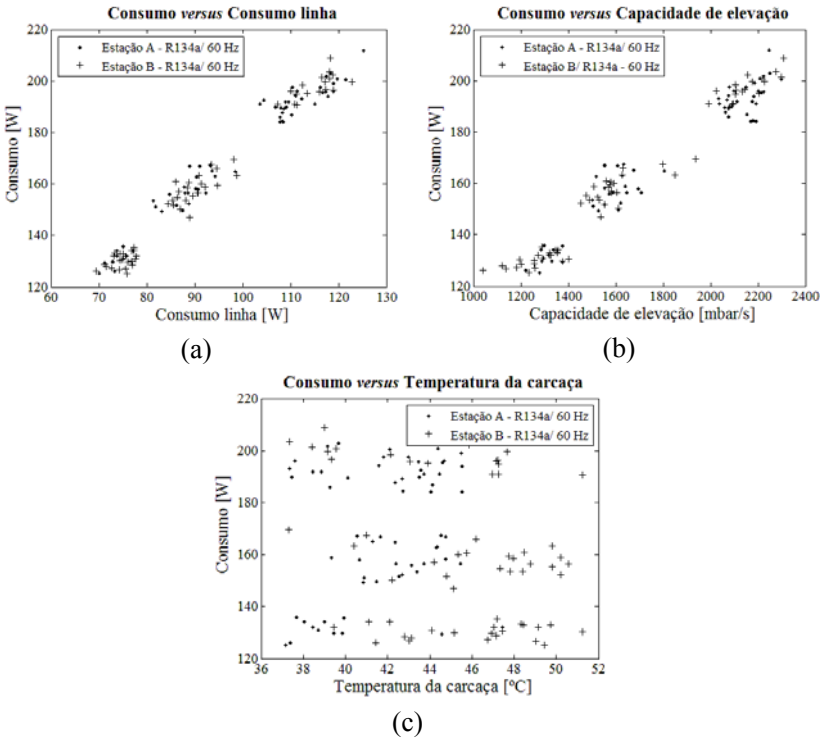
APÊNDICE C – DIAGRAMAS DE DISPERSÃO DE CONSUMO VERSUS RESULTADOS DE TESTES DE LINHA DE PRODUÇÃO

Figura 68 – Diagramas de dispersão do consumo *versus* resultados dos testes de linha de produção – avaliação global das informações.



Fonte: Autor.

Figura 69 – Diagramas de dispersão do consumo *versus* resultados dos testes de linha de produção – avaliação do agrupamento dado por refrigerante R134a e frequência de 60 Hz com temperatura de carcaça menor que 37 °C.



Fonte: Autor.

Tabela 39 – Correlações lineares para os agrupamentos R600a/ 60 Hz e R134a/ 50 Hz para dados tomados com temperatura de carcaça superior aos 37 °C.

agrupamento	coeficiente de correlação (<i>r</i>)		nº de peças
	Co-Col	Co-Cel	
R600a\ 60 Hz	0,842	0,879	45
R134a\ 50 Hz	0,979	0,963	26

Obs.: Em todos os casos o valor p encontrado foi 0,000.

Fonte: Autor.

APÊNDICE D – RESULTADO DA ANÁLISE DE REGRESSÃO DO CONSUMO *VERSUS* RESULTADOS DE TESTES DE LINHA DE PRODUÇÃO

Análise de Regressão: Co versus Cel; Tcr; Col; Rf; Rp

Análise de Variância

Fonte	GL	SQ (Aj.)	QM (Aj.)	Valor F	Valor-P
Regressão	5	98472	19694,4	660,65	0,000
Cel	1	2499	2499,2	83,84	0,000
Tcr	1	237	236,6	7,94	0,006
Col	1	815	815,3	27,35	0,000
Rf	1	40	39,8	1,34	0,250
Rp	1	92	92,4	3,10	0,080
Erro	144	4293	29,8		
Total	149	102765			

Sumário do Modelo

S	R2	R2(aj)	R2(pred)
5,45992	95,82%	95,68%	95,15%

Coeficientes

Termo	Coef	EP de Coef	Valor T	Valor-P	VIF
Constante	23,0	20,5	1,12	0,263	
Cel	0,04561	0,00498	9,16	0,000	16,20
Tcr	0,1970	0,0699	2,82	0,006	1,03
Col	0,589	0,113	5,23	0,000	16,24
Rf	0,232	0,201	1,16	0,250	1,08
Rp	-0,253	0,143	-1,76	0,080	1,06

Equação de Regressão

$$\text{Co} = 23,0 + 0,04561 \text{ Cel} + 0,1970 \text{ Tcr} + 0,589 \text{ Col} + 0,232 \text{ Rf} - 0,253 \text{ Rp}$$

Ajustados e Diagnósticos para Observações Atípicas

Obs.	Co	Ajuste	Resid	Resid Pad	
14	120,62	137,04	-16,42	-3,15	R
21	166,81	155,30	11,51	2,14	R

22	167,03	154,62	12,41	2,31	R	
30	168,30	159,29	9,01	1,77		X
61	184,08	195,27	-11,19	-2,10	R	
75	140,26	128,34	11,92	2,24	R	
96	129,50	142,79	-13,28	-2,71	R	X
109	150,11	172,65	-22,54	-4,56	R	X
112	167,05	167,38	-0,33	-0,07		X

R Resíduo grande

X Atípicos X

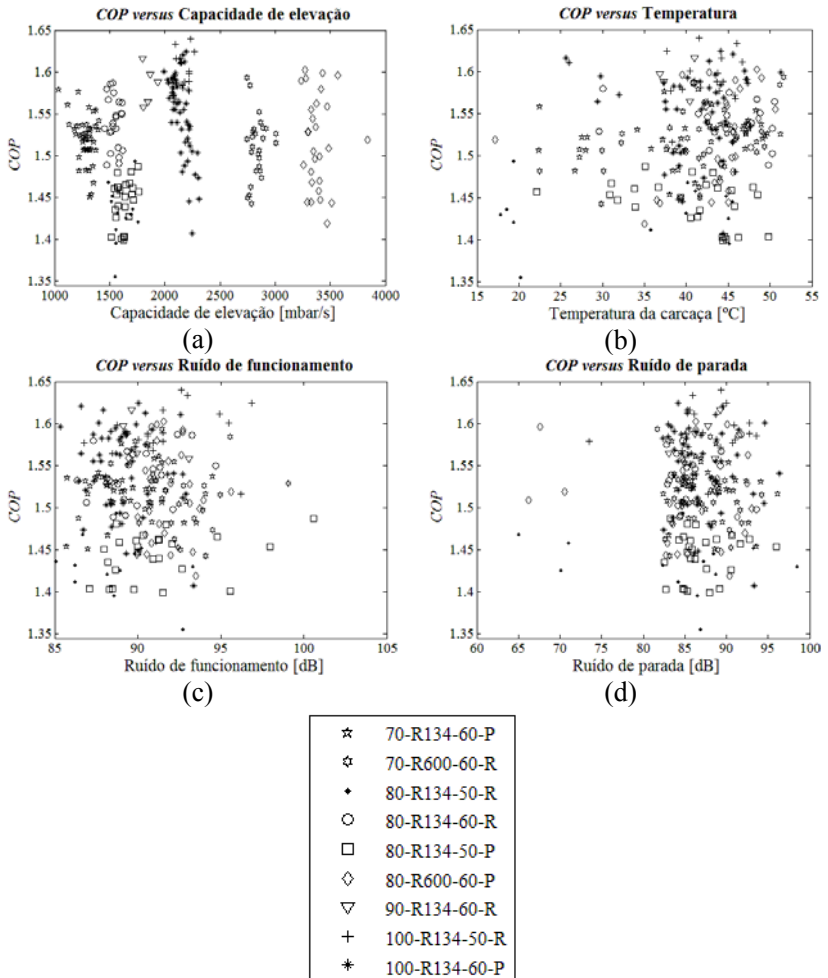
Regressão dos Melhores Subconjuntos: Co versus Cel; Tcr; Col; Rf; Rp

Resposta é Co

Vars	R2	R2 (aj)	R2 (pred)	Cp de Mallows	S	C T C				
						e	c	o	R	R
						l	r	l	f	p
1	94,8	94,7	94,6	33,9	6,0192	X				
1	92,9	92,8	92,7	100,4	7,0450			X		
2	95,5	95,4	95,0	11,7	5,6184	X		X		
2	94,9	94,9	94,7	30,5	5,9485	X	X			
3	95,7	95,6	95,2	5,7	5,4914	X	X	X		
3	95,6	95,5	95,0	10,7	5,5831	X		X		X
4	95,8	95,7	95,2	5,3	5,4663	X	X	X		X
4	95,7	95,6	95,1	7,1	5,4993	X	X	X	X	
5	95,8	95,7	95,2	6,0	5,4599	X	X	X	X	X

APÊNDICE E – DIAGRAMAS DE DISPERSÃO DE *COP* VERSUS RESULTADOS DE TESTES DE LINHA DE PRODUÇÃO

Figura 70 – Diagramas de dispersão do *COP* versus resultados dos testes de linha de produção – avaliação global das informações.



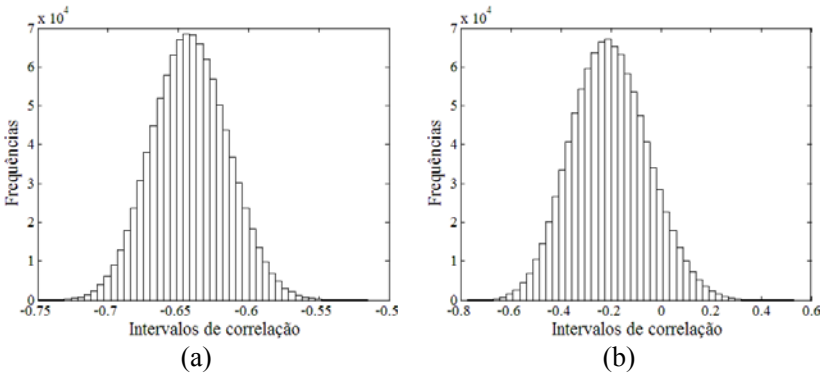
Fonte: Autor.

Tabela 40 – Correlações lineares entre *COP*-Col e *COP*-Cel para dados tomados com temperatura de carcaça superior aos 37 °C.

modelo de compressor	<i>COP</i> -Col		<i>COP</i> -Cel		Número de peças
	correlação linear (<i>r</i>)	valor p	correlação linear (<i>r</i>)	valor p	
7-R1-6-P	-0,495	0,003	-0,442	0,003	34
7-R6-6-R	-0,047	0,840	+0,051	0,826	21
8-R1-5-R	-0,462	0,297	-0,210	0,652	7
8-R1-6-R	-0,479	0,028	-0,050	0,829	21
8-R1-6-P	-0,648	0,004	+0,171	0,498	18
8-R6-6-P	-0,238	0,264	+0,137	0,523	24
10-R1-5-P	-0,428	0,068	+0,094	-0,701	19

Fonte: Autor.

Figura 71 – Simulação de correlação entre *COP* e consumo linha frente aos efeitos de 10% (a) e 100% das incertezas características - grupo 8-R1-6-P.



Fonte: Autor.

APÊNDICE F – RESULTADO DA ANÁLISE DE REGRESSÃO DO COP VERSUS RESULTADOS DE TESTES DE LINHA DE PRODUÇÃO

Análise de Regressão: COP versus Cel; Col; Rf; Rp

Análise de Variância

Fonte	GL	SQ (Aj.)	QM (Aj.)	Valor F	Valor-P
Regressão	4	0,078549	0,019637	24,36	0,000
Cel	1	0,002623	0,002623	3,25	0,078
Col	1	0,020595	0,020595	25,55	0,000
Rf	1	0,001333	0,001333	1,65	0,206
Rp	1	0,001277	0,001277	1,58	0,215
Erro	42	0,033862	0,000806		
Total	46	0,112410			

Sumário do Modelo

S	R2	R2(aj)	R2(pred)
0,0283942	69,88%	67,01%	61,14%

Coefficientes

Termo	Coef	EP de Coef	Valor T	Valor-P	VIF
Constante	2,706	0,245	11,04	0,000	
Cel	-0,000140	0,000078	-1,80	0,078	2,12
Col	-0,00641	0,00127	-5,05	0,000	2,44
Rf	-0,00313	0,00243	-1,29	0,206	1,09
Rp	0,00167	0,00133	1,26	0,215	1,19

Equação de Regressão

$$COP = 2,706 - 0,000140 \text{ Cel} - 0,00641 \text{ Col} - 0,00313 \text{ Rf} + 0,00167 \text{ Rp}$$

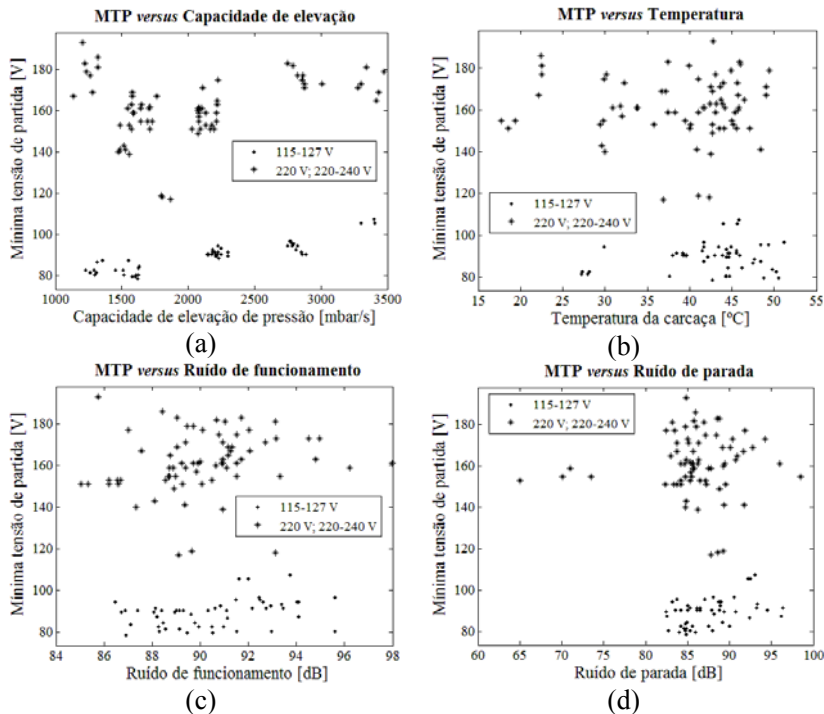
Ajustados e Diagnósticos para Observações Atípicas

Obs.	COP	Ajuste	Resid	Resid Pad	
5	1,4450	1,5043	-0,0593	-2,14	R
14	1,5350	1,4749	0,0601	2,23	R
35	1,6241	1,5641	0,0600	2,28	R

R Resíduo grande

APÊNDICE G – DIAGRAMAS DE DISPERSÃO DE MTP VERSUS RESULTADOS DE TESTES DE LINHA DE PRODUÇÃO

Figura 72 – Diagramas de dispersão do MTP *versus* resultados dos testes de linha de produção – avaliação global das informações.



Fonte: Autor.

APÊNDICE H – RESULTADO DA ANÁLISE DE REGRESSÃO DA MTP *VERSUS* RESULTADOS DE TESTES DE LINHA DE PRODUÇÃO

Análise de Regressão: MTP versus Cel; Tcr; Col; Rf; Rp

Análise de Variância

Fonte	GL	SQ (Aj.)	QM (Aj.)	Valor F	Valor-P
Regressão	5	1729,19	345,838	53,84	0,000
Cel	1	17,54	17,544	2,73	0,106
Tcr	1	0,02	0,020	0,00	0,956
Col	1	24,82	24,823	3,86	0,056
Rf	1	0,41	0,414	0,06	0,801
Rp	1	103,27	103,269	16,08	0,000
Erro	40	256,92	6,423		
Total	45	1986,11			

Sumário do Modelo

S	R2	R2(aj)	R2(pred)
2,53435	87,06%	85,45%	82,44%

Coeficientes

Termo	Coef	EP de Coef	Valor T	Valor-P	VIF
Constante	28,4	15,1	1,88	0,067	
Cel	0,00452	0,00274	1,65	0,106	17,28
Tcr	0,006	0,110	0,06	0,956	1,13
Col	0,1344	0,0684	1,97	0,056	16,96
Rf	-0,044	0,175	-0,25	0,801	1,29
Rp	0,454	0,113	4,01	0,000	1,23

Equação de Regressão

$$\text{MTP} = 28,4 + 0,00452 \text{ Cel} + 0,006 \text{ Tcr} + 0,1344 \text{ Col} - 0,044 \text{ Rf} + 0,454 \text{ Rp}$$

Ajustados e Diagnósticos para Observações Atípicas

Obs.	MTP	Ajuste	Resid	Resid Pad	R
22	87,50	81,43	6,07	2,52	R

R Resíduo grande


Regressão dos Melhores Subconjuntos: MTP versus Cel; Tcr; Col; Rf; Rp

Resposta é MTP

Vars	R2	R2 (aj)	R2 (pred)	Cp de Mallows	S	C T C				
						e	l	r	l	R R
						1	r	l	f	p
1	80,9	80,5	77,9	16,9	2,9331					
1	78,8	78,3	76,1	23,5	3,0918	X				
2	86,2	85,5	83,1	2,8	2,5288			X		X
2	85,7	85,0	83,3	4,2	2,5690	X				X
3	87,0	86,1	83,7	2,1	2,4753	X		X		X
3	86,2	85,2	82,5	4,7	2,5565		X	X		X
4	87,1	85,8	83,1	4,0	2,5033	X		X	X	X
4	87,0	85,8	83,1	4,1	2,5053	X	X	X		X
5	87,1	85,4	82,4	6,0	2,5343	X	X	X	X	X

APÊNDICE I – RESULTADOS DE DIFERENTES CONFIGURAÇÕES DE *ENSEMBLE* PARA INCERTEZA DA INFERÊNCIA DE *COP*

Figura 73 – Histogramas de frequência da propagação de 1000 SMCu sobre 50 (a), 200 (b), 350 (c), 500 (d), 750 (e) e 1000 (f) RNA.



Fonte: Autor.

